



ΔΙΑΤΜΗΜΑΤΙΚΟ ΠΡΟΓΡΑΜΜΑ
ΜΕΤΑΠΤΥΧΙΑΚΩΝ ΣΠΟΥΔΩΝ
«ΕΠΙΣΤΗΜΗ ΔΕΔΟΜΕΝΩΝ ΚΑΙ
ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ»

ΜΕΤΑΠΤΥΧΙΑΚΗ ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Σπύρος Πούρος

Επιβλέπων: Γεώργιος Ματσόπουλος

Αθήνα, Ιανουάριος 2021

ΔΙΑΤΜΗΜΑΤΙΚΟ ΠΡΟΓΡΑΜΜΑ
ΜΕΤΑΠΤΥΧΙΑΚΩΝ ΣΠΟΥΔΩΝ
«ΕΠΙΣΤΗΜΗ ΔΕΔΟΜΕΝΩΝ ΚΑΙ
ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ»

Ταξινόμηση Νοητικής Κόπωσης των Εγκεφαλικών
Δικτύων σε Δεδομένα Εγκεφαλογραφήματος
κατά την Οδήγηση

ΜΕΤΑΠΤΥΧΙΑΚΗ ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ
Σπύρος Πούρος

Επιβλέπων: Γεώργιος Ματσόπουλος

Εγκρίθηκε από την τριμελή επιτροπή την 2021

.....
Γ. Ματσόπουλος
Καθηγητής

.....
Δ.-Δ. Κουτσούρης
Καθηγητής

.....
Π. Τσανάκας
Καθηγητής

Περίληψη

Το αντικείμενο της διπλωματικής αφορά τη μελέτη δεδομένων που προέκυψαν από ηλεκτροεγκεφαλογράφημα. Για τη συλλογή των δεδομένων προσφέρθηκαν μέχρι αυτήν τη στιγμή 21 άτομα(subjects) για να λάβουν μέρος στο πείραμα και να συνεισφέρουν νέα δεδομένα στην έρευνα. Ο τελικός στόχος ήταν να κατηγοριοποιηθούν αυτά τα δεδομένα με βάση την νοητική κόπωση που προκαλείται στον εκάστοτε οδηγό.

Για να επιτευχθεί αυτό, αρχικά πραγματοποιήθηκε προεπεξεργασία (preprocessing) στα πειραματικά δεδομένα. Δοκιμάστηκαν αρκετοί αλγόριθμοι και τεχνικές για Feature Selection και Classification, καταλήγοντας τελικά σε εκείνες τις μεθόδους που πρόσφεραν τα καλύτερα αποτελέσματα.

Λέξεις Κλειδιά
Ηλεκτροεγκεφαλογράφημα,
Επιλογή Χαρακτηριστικών, Ταξινόμηση, Μηχανική Μάθηση

Abstract

The subject of this thesis was the study of electroencephalogram's data. The data came from 21 individuals who have participated so far to the experiment. The main purpose was to classify those data according to their mental fatigue.

In order to achieve a good classification score, several algorithms and techniques of feature selection and classification were implemented. After that, the best methods were selected and used in order to achieve better scores and accuracy.

Keywords

Electroencephalogram, Mental Fatigue, Feature Selection,
Classification, Machine Learning

Ευχαριστίες

Θα ήθελα να ευχαριστήσω τον αναπληρωτή καθηγητή Γ.Ματσόπουλο για την ανάθεση αυτής της ενδιαφέρουσας διπλωματικής σε μένα. Επίσης, θα ήθελα να ευχαριστήσω θερμά τον υποψήφιο διδάκτορα Ιωάννη Κάκκο για τον χρόνο που διέθεσε απλόχερα και την προθυμία του να με βοηθήσει σε οποιοδήποτε πρόβλημα παρουσιάστηκε κατά την εκπόνηση της διπλωματικής, όπως επίσης και όλα τα υπόλοιπα μέλη της ομάδας του εργαστηρίου για τη βοήθεια τους. Τέλος, θα ήθελα να ευχαριστήσω του γονείς μου, Γιώργο και Μαρία, και τους φίλους μου που στάθηκαν στο πλευρό μου όλα αυτά τα χρόνια της παρουσίας μου στα ακαδημαϊκά ιδρύματα.

Περιεχόμενα

Περίληψη	5
Abstract.....	6
Ευχαριστίες	7
1. ΘΕΩΡΗΤΙΚΟ ΥΠΟΒΑΘΡΟ	12
1.1 Σκοπός.....	12
1.2 Δομή Εργασίας.....	13
1.3 Ο εγκέφαλος	13
1.4 Ηλεκτροεγκεφαλογράφημα (EEG).....	14
1.5 Βασικοί Εγκεφαλικοί Ρυθμοί.....	16
1.6 Συνδεσιμότητα - Connectivity.....	19
1.7 Μέθοδοι Υπολογισμού	19
1.7.1 Ανατομική συνδεσιμότητα.....	19
1.7.2 Λειτουργική συνδεσιμότητα	20
1.7.3 Αιτιατή συνδεσιμότητα.....	20
1.8 Αναπαράταση Συνδεσιμότητας.....	21
1.9 Ανάλυση Συνδεσιμότητας	22
2. Ιστορικό Ερευνών – Πληροφορίες Αλγορίθμων	23
2.1 Ερευνητική Αναδρομή	23
2.2 Μηχανική Μάθηση	24
2.3 Αλγόριθμοι Classification	25
2.3.1 KNN.....	25
2.3.2 LDA	26
2.3.3 Μηχανές Διανυσμάτων Υποστήριξης (SVM).....	27
3. ΠΕΙΡΑΜΑΤΙΚΗ ΔΙΑΔΙΚΑΣΙΑ.....	31
3.1 Γενικά Στοιχεία.....	31
3.2 Διαδικασία	32
4. ΕΠΕΞΕΡΓΑΣΙΑ & ΑΝΑΛΥΣΗ ΔΕΔΟΜΕΝΩΝ.....	34
4.1 Προ-επεξεργασία Δεδομένων	34
4.2 Μορφή Δεδομένων.....	34
4.2 Feature Selection.....	35
4.3 Recursive Feature Selection (RFE)	36
4.4 Classifications με εφαρμογή Feature Selection	37
5. ΑΠΟΤΕΛΕΣΜΑΤΑ.....	38
5.1 Χρήση κάθε μπάντας.....	38

5.2 Χρήση όλων εκτός της Gamma Band	46
5.3 Χρήση μόνο Theta Band	52
6. Αξιολόγηση Αποτελεσμάτων και Μελλοντικές Επεκτάσεις	59
6.1 Αξιολόγηση Αποτελεσμάτων	59
6.2 Μελλοντικές Επεκτάσεις.....	59
Βιβλιογραφία	61

Περιεχόμενα Εικόνων

Εικόνα 1: Τα μέρη του ανθρώπινου εγκεφάλου	14
Εικόνα 2: Σήμα ηλεκτροεγκεφαλογραφήματος διάρκειας 8 δευτερολέπτων	15
Εικόνα 3: Θέσεις ηλεκτροδίων	16
Εικόνα 4: Βασικοί Εγκεφαλικοί Ρυθμοί	17
Εικόνα 5: Μετρικές Υπολογισμού Συνδεσιμότητας.....	21
Εικόνα 6: Είδη συνδεσιμότητας και αναπαράσταση με μητρώα	22
Εικόνα 7: Το “καπέλο” για τη σύνδεση με τα ηλεκτρόδια.....	32
Εικόνα 8: Σήμα EEG και οι αντίστοιχες κυματομορφές του στις μπάντες Delta, Theta, Alpha, Beta.	34
Εικόνα 9: Σύνολο δεδομένων για 12 labels	35
Εικόνα 10: KNN (5 λεπτά)	39
Εικόνα 11: LDA (5 λεπτά).....	39
Εικόνα 12: Random Forest (5 λεπτά)	40
Εικόνα 13: SVM Gaussian (5 λεπτά).....	40
Εικόνα 14: SVM Linear (5 λεπτά).....	41
Εικόνα 15: KNN (10 λεπτά)	41
Εικόνα 16: LDA (10 λεπτά).....	42
Εικόνα 17: Random Forest (10 λεπτά).....	42
Εικόνα 18: SVM Gaussian (10 λεπτά).....	43
Εικόνα 19: SVM Linear (10 λεπτά).....	43
Εικόνα 20: KNN (15 λεπτά)	44
Εικόνα 21: LDA (15 λεπτά).....	44
Εικόνα 22: Random Forest (15 λεπτά).....	45
Εικόνα 23: SVM Gaussian (15 λεπτά)	45
Εικόνα 24: SVM Linear (15 λεπτά).....	46
Εικόνα 25: KNN (5 λεπτά-No Gamma)	47
Εικόνα 26: LDA (5 λεπτά-No Gamma)	47

Εικόνα 27: SVM Gaussian (5 λεπτα-No Gamma)	48
Εικόνα 28: SVM Linear (5 λεπτα-No Gamma)	48
Εικόνα 29: KNN (10 λεπτα-No Gamma)	49
Εικόνα 30: LDA (10 λεπτα-No Gamma)	49
Εικόνα 31: SVM Gaussian (10 λεπτα-No Gamma)	50
Εικόνα 32: SVM Linear (10 λεπτα-No Gamma)	50
Εικόνα 33: KNN (15 λεπτα-No Gamma)	51
Εικόνα 34: LDA (15 λεπτα-No Gamma)	51
Εικόνα 35: SVM Gaussian (15 λεπτα-No Gamma)	52
Εικόνα 36: SVM Linear (15 λεπτα-No Gamma)	52
Εικόνα 37: KNN (5 λεπτα-Only Theta)	53
Εικόνα 38: LDA (5 λεπτα-Only Theta)	53
Εικόνα 39: SVM Gaussian (5 λεπτα-Only Theta)	54
Εικόνα 40: SVM Linear (5 λεπτα-Only Theta)	54
Εικόνα 41: KNN (10 λεπτα-Only Theta)	55
Εικόνα 42: LDA (10 λεπτα-Only Theta)	55
Εικόνα 43: SVM Gaussian (10 λεπτα-Only Theta)	56
Εικόνα 44: SVM Linear (10 λεπτα-Only Theta)	56
Εικόνα 45: KNN (15 λεπτα-Only Theta)	57
Εικόνα 46: LDA (15 λεπτα-Only Theta)	57
Εικόνα 47: SVM Gaussian (15 λεπτα-Only Theta)	58
Εικόνα 48: SVM Linear (15 λεπτα-Only Theta)	58

1. ΘΕΩΡΗΤΙΚΟ ΥΠΟΒΑΘΡΟ

1.1 Σκοπός

Πνευματική κόπωση είναι μια σύνθετη κατάσταση του εγκεφάλου, που προκύπτει από εμπλοκή σε μονότονες ή απαιτητικές γνωστικές δραστηριότητες για παρατεταμένη χρονική περίοδο [1], [2]. Αυτό το φαινόμενο συνήθως εκδηλώνεται με τη μορφή υπνηλίας και επιδείνωση του επιπέδου επαγρύπνησης, η οποία θα οδηγούσε σε ανεπιθύμητη μείωση της απόδοσης, όπως μεγαλύτερος χρόνος αντίδρασης ή / και απώλεια προσοχής [3]. Σε αυτό το πλαίσιο, έχουν γίνει συνεχείς προσπάθειες για να κατανοήσουμε τους νευρικούς μηχανισμούς που βρίσκονται σε ψυχική κόπωση και στη συνέχεια να αναπτυχθούν εφαρμόσιμες μέθοδοι με σκοπό την αξιόπιστη ανίχνευση κόπωσης[4] και την αποτροπή ενός ανθρώπινου σφάλματος σε πραγματικές καταστάσεις.

Συνήθως, σε καλά ελεγχόμενες πειραματικές συνθήκες, οι περιπτώσεις, που προκαλούν κόπωση, περιλαμβάνουν παρατεταμένη εκτέλεση διαφόρων ενεργειών, όπως επαγρύπνηση ή συνεχή προσοχή σε εργασίες [5], [6], εργασίες οπτικής προσοχής [7] - [9] και εργασίες μνήμης [10], [11]. Σε ορισμένες μελέτες και πειράματα έχει χρησιμοποιηθεί επανειλημμένα η προσομοιωμένη οδήγηση [3], [12], [13], κυρίως λόγω της έντονης προσοχής που πρέπει να δείχνει ο εκάστοτε οδηγός, λαμβάνοντας υπόψη το γεγονός ότι αποτελεί συχνή αιτία θανατηγόρων ατυχημάτων. Στην πραγματικότητα, τα στοιχεία έχουν δείξει ότι η παρατεταμένη οδήγηση θα μπορούσε να μειώσει σημαντικά την ικανότητα λήψης αποφάσεων και την ψυχική εγρήγορση του οδηγού [14], [15].

Λόγω της δυνατότητάς του για καταγραφές μεγαλύτερης διάρκειας, της άνεσης των συμμετεχόντων και της δυνατότητας για μεταφορά της καταγραφής σε ρεαλιστικά πειράματα, το ηλεκτρο-εγκεφαλογράφημα έχει χρησιμοποιηθεί ευρέως και έχει αποδειχθεί επιτυχημένο στην προσπάθεια αποκωδικοποίησης των γνωστικών διαδικασιών κατά τη διάρκεια μίας κατάστασης που προκαλεί ψυχική κόπωση. Συγκεκριμένα, μελέτες έχουν δείξει ότι οι μεταβολές της ισχύος ενός ΗΕΓ σε ζώνες διαφορετικών συχνοτήτων, παρουσιάζουν μεγάλη συσχέτιση με την ψυχική κόπωση [4], [16] - [18], προτείνοντας έναν ισχυρό και αποτελεσματικό τρόπο για την ανίχνευση κόπωσης σε επαγρύπνηση και κατά την διάρκεια οδήγησης [13], [19], [20].

Δεδομένου ότι η ψυχική κόπωση είναι μια πολύπλοκη διαδικασία που επηρεάζει πολλές περιοχές του εγκεφάλου, ο συνδυασμός λειτουργικής συνδεσιμότητας και η θεωρία γράφων [21], [22] είναι μια κατάλληλη προσέγγιση που παρέχει μια ποσοτική και ολοκληρωμένη εικόνα της λειτουργικής αναδιοργάνωσης του εγκεφάλου [6], [9], [23]. Επιπλέον, πρόσφατα έχουν γίνει προσπάθειες για τη κατάταξη της λειτουργικής συνδεσιμότητας ως χαρακτηριστικό / κριτήριο για την ταξινόμηση κόπωσης. Στην προσπάθεια αυτή υπήρξαν ικανοποιητικά αποτελέσματα[5], [24], προτείνοντας μια νέα μέθοδο συνδεσιμότητας για την αξιολόγηση και παρακολούθηση της ψυχικής κόπωσης. Ωστόσο, παρουσιάστηκαν εμφανείς διαφορές μεταξύ διαφορετικών μελετών, που δείχνουν μια πολύπλοκη φύση που σχετίζεται με την μηχανισμούς νευρικής κόπωσης.

Στην παρούσα διπλωματική εργασία γίνεται μια προσπάθεια να δοθεί λύση και εξήγηση στο πρόβλημα της νοητικής κόπωσης κατά τη διάρκεια της

οδήγησης. Με τη χρήση σημάτων από ηλεκτροεγκεφαλογράφημα(EEG), διαιρούμε τα δεδομένα που έχουμε σε ίσους χρόνους και μελετούμε την αυξημένη λειτουργία και τη διέγερση ορισμένων περιοχών του εγκεφάλου. Το βασικό ζητούμενο είναι ταξινομηθούν τα δεδομένα από το ηλεκτροεγκεφαλογράφημα έτσι ώστε να επιτευχθεί η μέγιστη δυνατή ακρίβεια. Τελικός στόχος είναι να προκύψουν ικανοποιητικά αποτελέσματα τα οποία θα μπορούν να αξιοποιηθούν ώστε να γνωρίζουμε σε ποιά σημεία επικεντρώνεται η κόπωση του οδηγού, ποιά χρονική στιγμή, κατά μέσο όρο, επέρχεται η κόπωση κ.ά..

1.2 Δομή Εργασίας

Στο κεφάλαιο 1 γίνεται μια εισαγωγή και παρουσιάζονται ορισμένες ενδιαφέρουσες πληροφορίες για τον ανθρώπινο εγκέφαλο και για το ηλεκτροεγκεφαλογράφημα.

Στο κεφάλαιο 2 γίνεται μία σύντομη ιστορική αναδρομή ενώ γίνεται και περιγραφή των αλγορίθμων που χρησιμοποιούνται.

Στο κεφάλαιο 3 γίνεται επεξήγηση σε θεωρητικό επίπεδο της δημοσίευσης και του πειράματος από τα οποία αντλήθηκαν τα αποτελέσματα που επεξεργάστηκαν στη συνέχεια.

Στο κεφάλαιο 4 γίνεται περιγραφή για τον τρόπο με τον οποίο έγινε η επεξεργασία των δεδομένων και η εφαρμογή των αλγορίθμων ταξινόμησης.

Στο κεφάλαιο 5 παρουσιάζονται τα τελικά αποτελέσματα που προέκυψαν.


Στο κεφάλαιο 6 δίνονται τα συμπεράσματα εργασίας καθώς επίσης και προτάσεις για μελλοντική αξιοποίηση αυτής της δουλειάς.

1.3 Ο εγκέφαλος

Ο εγκέφαλος είναι το όργανο που χρησιμεύει ως το κέντρο του νευρικού συστήματος. Βρίσκεται εντός του εγκεφαλικού κρανίου και περιβάλλεται από τρεις προστατευτικούς υμένες, τις μήνιγγες.

Αποτελείται από δύο ημισφαίρια (που αποτελούνται επιμέρους από 4 λοβούς, τον Μετωπιαίο, τον Βρεγματικό, τον Κροταφικό και τον Ινιακό) τα οποία χωρίζονται μεταξύ τους από την επιμήκη σχισμή. Από την κάτω επιφάνεια του εγκεφάλου εκφύονται οι εγκεφαλικές συζυγίες ή νεύρα και ξεκινά ο νωτιαίος μυελός. Η βάση του εγκεφαλικού κρανίου εφάπτεται με την κάτω επιφάνεια του εγκεφάλου και διαθέτει αντίστοιχα τμήματα για την δίοδο των κρανιακών νεύρων και του νωτιαίου μυελού. Από τα τμήματα αυτά περνούν επίσης τα διάφορα αγγεία για την αιμάτωση του εγκεφάλου. Η άνω και οι πλάγιες επιφάνειες του εγκεφάλου αποτελούν τον εγκεφαλικό φλοιό και εφάπτονται τον θόλο του κρανίου.

Άλλες περιοχές του εγκεφάλου είναι το εγκεφαλικό στέλεχος και η παρεγκεφαλίδα [25].




Εικόνα 1: Τα μέρη του ανθρώπινου εγκεφάλου

Στον μέσο άνθρωπο, ο εγκέφαλος, εκτιμάται πως έχει περισσότερα από 100 δισεκατομμύρια νευρικά κύτταρα, το κάθε ένα από τα οποία συνδέεται με συνάψεις με αρκετές χιλιάδες άλλα νευρικά κύτταρα [26]. Αυτοί οι νευρώνες επικοινωνούν μεταξύ τους μέσω δομών που ονομάζονται νευράξονες, οι οποίοι μεταφέρουν ηλεκτρικούς παλμούς σε άλλα μέρη του εγκεφάλου ή σε κύτταρα με εξειδικευμένους υποδοχείς στο υπόλοιπο σώμα [27].

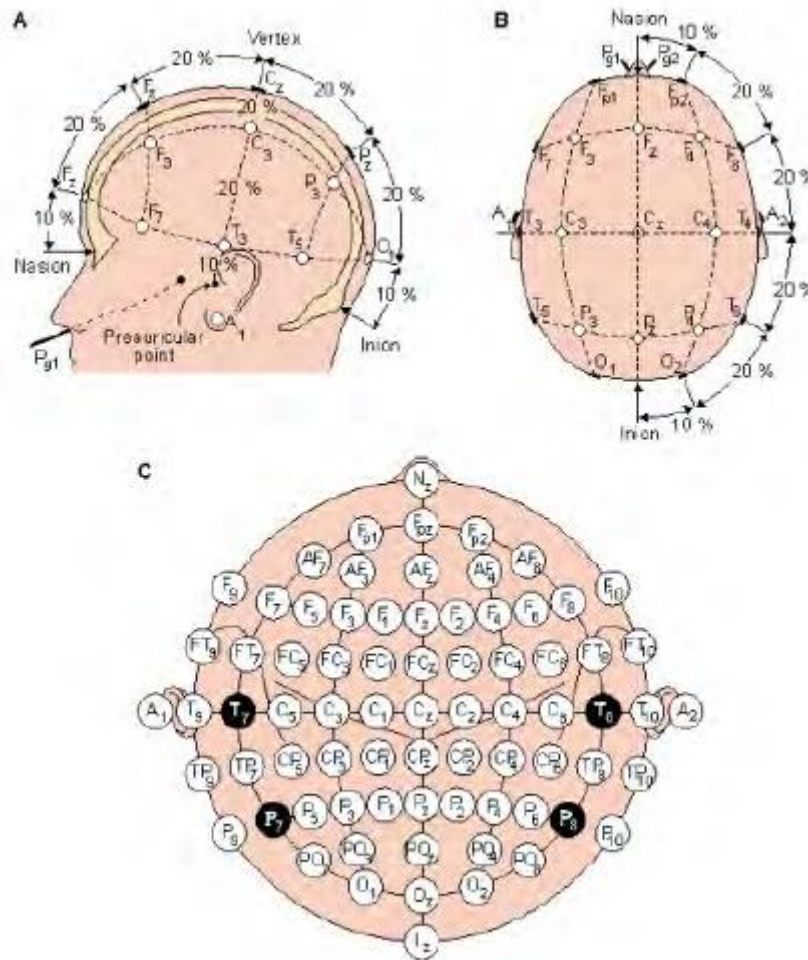
1.4 Ηλεκτροεγκεφαλογράφημα (EEG)

Το ηλεκτροεγκεφαλογράφημα (EEG) είναι μια μη επεμβατική μέθοδος για την καταγραφή της ηλεκτρικής δραστηριότητας του εγκεφάλου κατά μήκος του τριχωτού της κεφαλής. Το EEG μετρά τις διακυμάνσεις της ηλεκτρικής τάσης που προκύπτουν από ιοντικό ρεύμα εντός των νευρώνων του εγκεφάλου. Γενικά το EEG αναφέρεται στην καταγραφή της αυθόρμητης ηλεκτρικής δραστηριότητας του εγκεφάλου κατά τη διάρκεια μιας χρονικής περιόδου, όπως καταγράφεται από πολλαπλά ηλεκτρόδια τοποθετημένα στην τριχωτό της κεφαλής [28].



Εικόνα 2: Σήμα ηλεκτροεγκεφαλογράφηματος διάρκειας 8 δευτερολέπτων

Για την επιλογή των θέσεων των ηλεκτροδίων στην κεφαλή έχει καθιερωθεί διεθνώς το τοπολογικό σύστημα 10/20. Το σύστημα 10/20 ακολουθεί δύο άξονες: τον προσθιοπίσθιο ή οβελιαίο άξονα και τον εγκάρσιο άξονα που ενώνει τους δύο ακουστικούς πόρους. Οι ποσοστιαίες απεικονίσεις 10% και 20% αναφέρονται στις αποστάσεις που απέχουν οι διάφορες θέσεις ηλεκτροδίων από τον έξω ακουστικό πόρο (δηλαδή το 10% της απόστασης A1 – A2, π.χ. η απόσταση A1 – T3) και μεταξύ των ηλεκτροδίων (20% της ίδιας απόστασης A1 – A2, π.χ. C3 – CZ). Οι μονοί αριθμοί του συστήματος αναφέρονται στο αριστερό ημισφαίριο (F3, P3, C3 κ.τ.λ.) και οι ζυγοί στο δεξιό (F4, P4, C4 κ.τ.λ.). Οι θέσεις Fi, Ci, Ti, Pi και Oi αντιστοιχίζονται στις περιοχές του εγκεφάλου ως εξής: FP1, FP2 στην πρόσθια μετωπιαία περιοχή οι F7, F3, FZ, F4, F8 στην μετωπιαία περιοχή οι C3, CZ, C4 στην κεντρική περιοχή, οι T3, T5, T6, T4 στην κροταφική περιοχή, οι P3, P4 στην βρεγματική περιοχή και οι θέσεις O1, O2 στην ινιακή περιοχή [29].

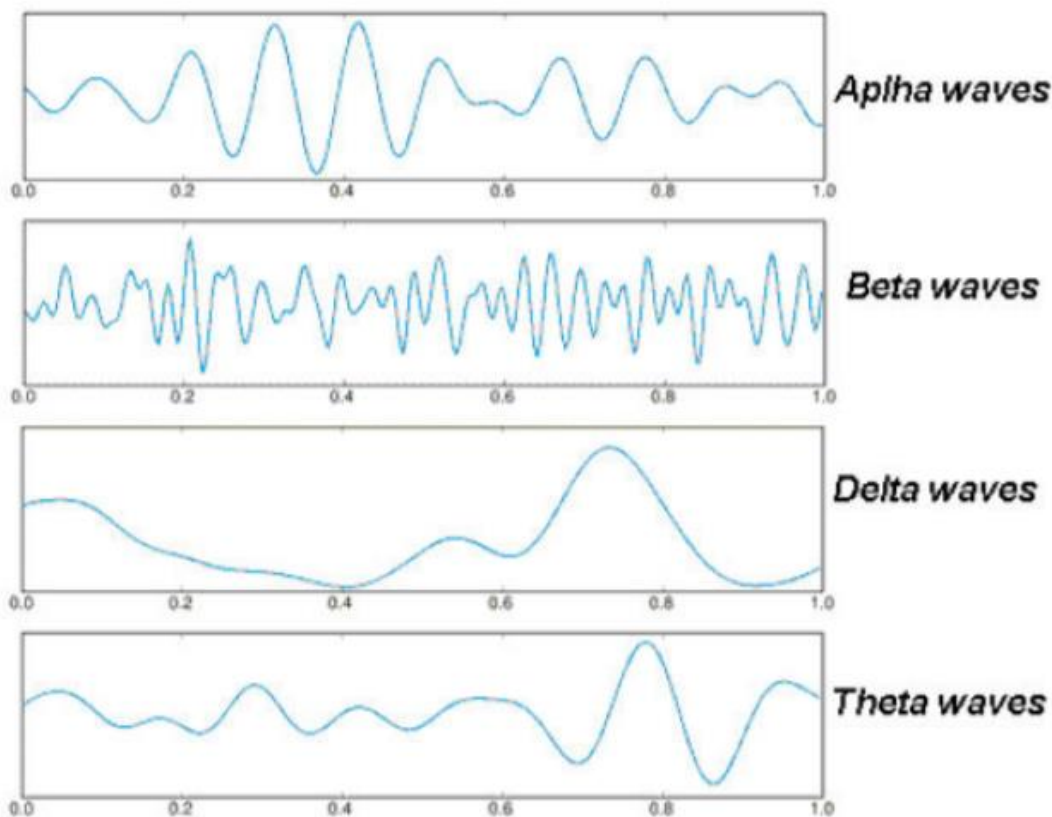


Εικόνα 3: Θέσεις ηλεκτροδίων

1.5 Βασικοί Εγκεφαλικοί Ρυθμοί

Τα σήματα δραστηριότητας αλλά και ηρεμίας του εγκεφάλου είναι συνήθως ημιτονοειδή. Ένα τυπικό σήμα εγκεφαλογραφήματος κυμαίνεται από 0.5 έως 100 μV σε πλάτος, δηλαδή είναι περίπου 100 φορές μικρότερο από ένα τυπικό ηλεκτροκαρδιογράφημα [30]. Η απεικόνιση του φάσματος ισχύος αυτών των σημάτων είναι δυνατή με χρήση του μετασχηματισμού Fourier. Παρά το γεγονός ότι το φάσμα είναι συνεχές από 0Hz μέχρι το μισό της συχνότητας δειγματοληψίας του σήματος, η κατάσταση του εγκεφάλου κάνει κάποιες συγκεκριμένες συχνότητες να υπερισχύουν των υπολοίπων. Τα εγκεφαλικά κύματα κατηγοριοποιούνται σε πέντε βασικές ομάδες:

- Δέλτα (0.5-4 Hz)
- Θήτα (4-8 Hz),
- Άλφα (8-13 Hz),
- Βήτα (13-30 Hz),
- Γάμα (>30 Hz)



Εικόνα 4: Βασικοί Εγκεφαλικοί Ρυθμοί

Τα μοτίβα των εγκεφαλικών κυμάτων είναι μοναδικά για κάθε άτομο. Εν γένει, σύμφωνα με μελέτες, έχουν παρατηρηθεί οι εξής δραστηριότητες των πέντε βασικών ρυθμών: Ο ρυθμός γάμα εμφανίζεται σε όλους του εγκεφαλικούς λοβούς ταυτόχρονα και σχετίζεται με την επεξεργασία ερεθισμάτων πλουσίων σε πληροφορία και με την συντονισμένη λειτουργία ολόκληρου του εγκεφάλου. Υπάρχουν επίσης ενδείξεις, ότι ο ρυθμός αυτός συνδέεται με την ισχυρή μνήμη, την αντίληψη και τον αυτοέλεγχο. Η δραστηριότητα στον ρυθμό γάμα και ο συγχρονισμός της δραστηριότητας των νευρώνων σε αυτές τις συχνότητες έχει παρατηρηθεί σε διαφορετικές δομές του φλοιούς και του υποφλοιού και έχει συσχετιστεί με διαφορετικές γνωσιακές λειτουργίες. Ωστόσο, παραμένει άγνωστο αν ο συγχρονισμός στο ρυθμό γάμα εξυπηρετεί μία καθολική λειτουργία ή μία ποικιλία λειτουργιών στο εύρος των γνωσιακών λειτουργιών. Η δραστηριότητα στο ρυθμό γάμα προέρχεται από την αλληλεπίδραση μεταξύ της αναστολής και διέγερσης. Σύμφωνα με το [29], όπου διεξήγαγαν μελέτες για την παρουσία του ρυθμού γάμα κατά την αντίληψη, την επιλεκτική προσοχή, τη μνήμη, το κίνητρο και τον έλεγχο της συμπεριφοράς, κατέληξαν στο συμπέρασμα ότι ο ρυθμός αυτός είναι παρών όχι μόνο σε μία αλλά σε πολλές γνωσιακές λειτουργίες, κάτι το οποίο μπορεί να οδηγήσει στο συμπέρασμα ύπαρξης ενός περιορισμένου συνόλου μοτίβων κυκλωμάτων στη δομή του εγκεφάλου. Τέλος, ο ρυθμός γάμα έχει συσχετισθεί με τη σύνθεση χαρακτηριστικών (Keil and Mueller, 2010), την ταξινόμηση αντικειμένων (Castelo-Branco et al, 2000), και την επιλεκτική εστίαση της

προσοχής (Fries et al., 2001; Kahlbrock et al., 2012). Ο ρυθμός βήτα είναι ο κυρίαρχος ρυθμός που επικρατεί στη φάση της εγρήγορσης ενός φυσιολογικού ατόμου. Σύμφωνα με το [30] σχετίζεται, εκτός από την επεξεργασία κινητικών ερεθισμάτων, με την επιλεκτική προσοχή και την επεξεργασία διαφορετικών αισθητηριακών ερεθισμάτων. Τα κύματα βήτα συχνά συσχετίζονται με προετοιμασία και εκτέλεση κίνησης (Neuper et al., 2006) και με σωματοαισθητήρια επεξεργασία (Kilavik et al. 2013). Πρόσφατα έχει υποστηριχθεί ότι η δραστηριότητα στο ρυθμό βήτα παίζει ρόλο σε ανώτερες γνωσιακές επεξεργασίες (Engel and Fries, 2010; Donner and Siegel, 2011). Ο ρυθμός άλφα εμφανίζεται στο 75% περίπου των ενηλίκων. Το κλείσιμο ή το άνοιγμα των ματιών προκαλεί αντίστοιχα αύξηση ή μείωση του συγκεκριμένου ρυθμού. Επίσης, η μείωση της δραστηριότητας του ρυθμού άλφα έχει συσχετιστεί με τον αισθητήριο ερεθισμό ή τη νοητική δραστηριότητα. Η δραστηριότητα του ρυθμού άλφα θεωρείται ότι δρα ως τοπικός μηχανισμός-πύλη σε αισθητήρια ερεθίσματα, μέσω του οποίου αυξάνεται η επεξεργασία πληροφοριών που σχετίζονται με το ερέθισμα και περιορίζεται η επεξεργασία πληροφοριών που είναι άσχετες με το ερέθισμα (Foxe and Snyder, 2011). Επιπλέον, έχει γίνει ένας συσχετισμός του ρυθμού άλφα και της λειτουργικής μνήμης (Klimesch et al., 2006). Ο ρυθμός άλφα είναι ο πλέον μελετημένος ρυθμός του εγκεφάλου. Παρατηρείται συνήθως στις οπίσθιες ινιακές περιοχές του εγκεφάλου με τυπικό πλάτος σημάτων από κορυφή σε κορυφή τα 50 μV . Σύμφωνα με μελέτες [28] ο ρυθμός άλφα επικρατεί συνήθως στις περιοχές μεταξύ του οπίσθιου και κεντρικού τμήματος του εγκεφάλου και λιγότερο στις υπόλοιπες περιοχές. Η δραστηριότητα του ρυθμού άλφα πυροδοτείται από το κλείσιμο των ματιών και την κατάσταση χαλάρωσης και απενεργοποιείται από το άνοιγμα των ματιών και την κατάσταση εγρήγορσης την οποία προκαλεί οποιοσδήποτε μηχανισμός (σκέψη, υπολογισμός). Σύμφωνα με μελέτες, οι περισσότεροι άνθρωποι είναι πολύ ευαίσθητοι στην ενέργεια του κλεισίματος των ματιών. Όταν κλείνουν τα μάτια ο ρυθμός του εγκεφάλου αλλάζει απότομα από βήτα σε άλφα. Η ακριβής προέλευση του ρυθμού άλφα δεν είναι ακόμα γνωστή. Τα κύματα του ρυθμού άλφα συνήθως οφείλονται σε αθροιστικά δυναμικά δενδριτών. Τα προκλητά δυναμικά (όπως αυτά που παράγονται στο εγκεφαλικό στέλεχος) συνήθως αποτελούνται από δυναμικά ινών (αξόνων) και συναπτικά δυναμικά [31]. Ο ρυθμός θήτα, ιδιαίτερα στον ιππόκαμπο, φαίνεται πως εξυπηρετεί μία κρίσιμη λειτουργία σχετικά με την λειτουργική μνήμη (Miller, 1991). Συνδέεται με μηχανισμούς καταστολής ή με την είσοδο στη φάση χαλάρωσης. Εμφανίζεται επίσης σε συνδυασμό με τον ρυθμό βήτα σε φάσεις αυξημένης προσοχής. Φαίνεται να αυξάνεται ιδιαίτερα στη φάση της κωδικοποίησης και σε πλάτος δεν ξεπερνά τα 30 μV . Σύμφωνα με αρκετές μελέτες που έχουν γίνει μέχρι σήμερα [32], [33], ο ρυθμός θήτα ενεργοποιείται κατά την αντίληψη ακουστικού ερεθίσματος, κάτι το οποίο επιβεβαιώνεται και από την παρούσα διπλωματική. Ο ρυθμός δέλτα συσχετίζεται στον φυσιολογικό άνθρωπο με τον ύπνο και είναι ο κυρίαρχος ρυθμός στα νεογέννητα μέχρι και το δεύτερο έτος της ηλικίας τους. Έχει το μεγαλύτερο πλάτος από όλους τους ρυθμούς, γύρω στα 100 μV . Το ΗΕΓ είναι ευαίσθητο σε εναλλαγή καταστάσεων μεταξύ κατάστασης άγχους, εγρήγορσης σε

κατάσταση ανάπαυσης, ύπνωσης και ύπνου. Κατά τη διάρκεια μιας κανονικής κατάστασης, όταν το άτομο είναι ξύπνιο με τα μάτια ανοιχτά, κυριαρχεί ο ρυθμός βήτα. Σε κατάσταση χαλάρωσης ή υπνηλίας κυρίαρχος γίνεται ο ρυθμός άλφα, ενώ σε κατάσταση ύπνου αυξάνεται η ισχύς και των χαμηλότερων ρυθμών. Ο ύπνος γενικά χωρίζεται σε δύο φάσεις: στη φάση μη γρήγορης κίνησης των ματιών (NREM) και στη φάση γρήγορης κίνησης των ματιών (REM). Οι NREM και REM συμβαίνουν σε εναλλασσόμενους κύκλους. Η NREM χωρίζεται στα στάδια I, II, III και IV. Τα δύο τελευταία στάδια αντιστοιχούν στον βαθύτερο ύπνο, όπου εμφανίζονται με υψηλότερα ποσοστά τα βραδέα κύματα δέλτα. Όταν ο εγκέφαλος λειτουργεί σε χαμηλές συχνότητες δέλτα, η αντίδρασή του σε ερεθίσματα μειώνεται.

1.6 Συνδεσιμότητα - Connectivity

Η εγκεφαλική συνδεσιμότητα ορίζεται ως ένα σύνολο είτε ανατομικών συνδέσεων (ανατομική συνδεσιμότητα), είτε στατιστικών εξαρτήσεων (λειτουργική συνδεσιμότητα), είτε αιτιακών αλληλεπιδράσεων (αιτιατή συνδεσιμότητα) μεταξύ διακριτών μονάδων σε ένα νευρικό σύστημα [32]. Ως μονάδες νοούνται νευρώνες, νευρωνικοί πληθυσμοί, ή ακόμα και ξεχωριστές ανατομικά περιοχές του εγκεφάλου. Συνδέσεις θεωρούνται είτε οι ανατομικές συνδέσεις με τις οποίες ενώνονται οι νευρώνες μεταξύ τους, δηλαδή οι συνάψεις, είτε οι στατιστικές ή αιτιακές εξαρτήσεις μεταξύ απομακρυσμένων περιοχών.

1.7 Μέθοδοι Υπολογισμού

Δεδομένου ότι κάθε είδος συνδεσιμότητας αναφέρεται σε διαφορετικό είδος συνδέσεων, αντίστοιχα διαφέρει ο τρόπος υπολογισμού αυτών.

1.7.1 Ανατομική συνδεσιμότητα

Οι ανατομικές συνδέσεις, δηλαδή συνάψεις, μεταξύ νευρώνων ή νευρωνικών πληθυσμών οι οποίες ορίζουν την ανατομική συνδεσιμότητα του εγκεφάλου, είναι σχετικά σταθερές σε επίπεδο δευτερολέπτων ή λεπτών, ενώ σε επίπεδο ωρών ή ημερών είναι πιθανό να αλλάξουν, εξ' αιτίας της πλαστικότητας του εγκεφάλου, δηλαδή της ιδιότητάς του να επιτρέπει αλλαγές στις συνάψεις και στην ισχύ διασύνδεσης αυτών, ανάλογα με εσωτερικούς ή εξωτερικούς παράγοντες-ερεθίσματα. Εξ' αιτίας αυτής της σχετικής σταθερότητας σε επίπεδο τουλάχιστον λεπτών, ο υπολογισμός της ανατομικής συνδεσιμότητας, δηλαδή του δομικού δικτύου των νευρώνων και συνάψεων, είναι εφικτός μέσω νευροαπεικονιστικών μεθόδων όπως η Diffusion MRI, η οποία απεικονίζει τη διάχυση μορίων κυρίως νερού στους βιολογικούς ιστούς, καταφέροντας έτσι να δημιουργηθεί ένας "χάρτης" της περιοχής απεικόνισης. Όλες οι τεχνικές μαγνητικής απεικόνισης (MRI) έχουν χρονική ακρίβεια της τάξης μερικών δεκάδων δευτερολέπτων, δηλαδή περίπου λεπτού, γι' αυτό και μπορούν να χρησιμοποιηθούν για την καταγραφή των ανατομικών συνδέσεων όπως αναφέρθηκε και παραπάνω.

1.7.2 Λειτουργική συνδεσιμότητα

Σε αντίθεση με την προηγούμενη περίπτωση, η λειτουργική συνδεσιμότητα στοχεύει στην ανίχνευση αλλαγών στη στατιστική ανεξαρτησία μεταξύ απομακρυσμένων συνήθως περιοχών του εγκεφάλου, επομένως αποτελεί μια ευαίσθητη χρονικά πληροφορία, αφού οι διακυμάνσεις στις στατιστικές εξαρτήσεις συμβαίνουν σε επίπεδο χιλιοστών του δευτερολέπτου. Οι πιο συνήθεις τρόποι υπολογισμού της λειτουργικής συνδεσιμότητας είναι οι κάτωθι :

- **Συσχέτιση (correlation)** : Μετρική που ορίζει το βαθμό ομοιότητας δύο μεταβλητών/διανυσμάτων/χρονοσειρών και ορίζεται ως

$$\text{Cor}_{x,y} = \frac{\text{Cov}_{x,y}}{\sigma_x \sigma_y}, \quad (2.1)$$

όπου $\text{Cov}_{x,y}$ η συνδιακύμανση (convolution) των μεταβλητών x , y , και σ_x , σ_y η τυπική απόκλιση των x , y αντίστοιχα.

- **Φασματική Συνάφεια (spectral coherence)** : Είναι η συσχέτιση μεταξύ δύο χρονοσειρών στο πεδίο της συχνότητας, οριζόμενη ως :

$$\text{Coh}_{xy}(f) = \frac{|G_{xy}(f)|^2}{G_{xx}(f)G_{yy}(f)}, \quad (2.2)$$

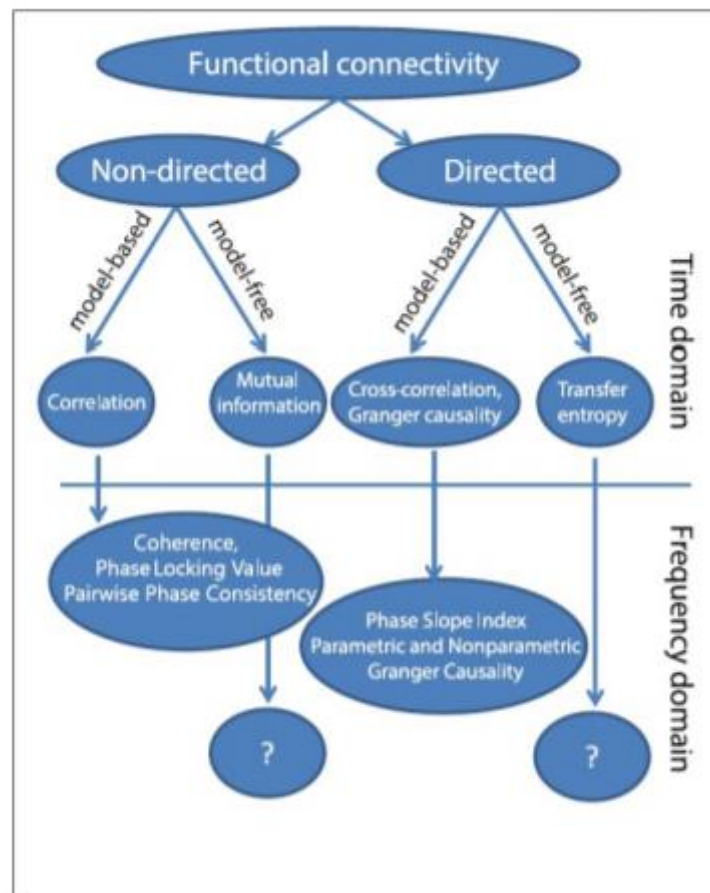
όπου $G_{xy}(f)$ το συχνотικό διάφασμα (cross-spectrum density) των x , y διαιρεμένο με τις τιμές ισχύος της συχνότητας κάθε σήματος του υπό σύγκριση ζεύγους

- **Αμοιβαία Πληροφορία (mutual information)** : Υπολογίζει την αμοιβαία εξάρτηση μεταξύ δύο σημάτων μετρώντας την πληροφορία που εμπεριέχεται σε ένα σήμα από τη μέτρηση του άλλου σήματος σαν συνάρτηση της μεταξύ τους καθυστέρησης. Πρακτικά υπολογίζεται ως η διαφορά του αθροίσματος των επιμέρους εντροπιών δύο μονάδων A , B από την κοινή τους εντροπία : $MI(A, B) = H(A) + H(B) - H(AB)$. Ο υπολογισμός προκύπτει από δεδομένα είτε ηλεκτροφυσιολογικά (EEG) είτε νευροαπεικονιστικά (fMRI), και είθισται να υπολογίζεται μεταξύ όλων των στοιχείων που έχουν οριστεί ως νευροφυσιολογικές μονάδες στο εκάστοτε πείραμα.

1.7.3 Αιτιατή συνδεσιμότητα

Η αιτιατή συνδεσιμότητα, η οποία στην πραγματικότητα είναι επέκταση της λειτουργικής συνδεσιμότητας, μετρά το βαθμό επίδρασης και την κατεύθυνση ροής της πληροφορίας μεταξύ δύο νευρωνικών στοιχείων. Εδώ σημασία έχει να οριστεί όχι μόνο η ύπαρξη αλληλεπίδρασης μεταξύ δύο περιοχών, όπως συμβαίνει με τη λειτουργική συνδεσιμότητα, αλλά και το κατά πόσο η έναρξη ροής της πληροφορίας γίνεται από τη μία ή την άλλη περιοχή. Συνήθη μέτρα που χρησιμοποιούνται για την ποσοτικοποίηση της αιτιατής συνδεσιμότητας είναι η Μεταφορά Εντροπίας (Transfer Entropy) ή η μετρική Granger causality. Περισσότερες μετρικές λειτουργικής/αιτιατής συνδεσιμότητας φαίνονται στην εικόνα 5, όπου οι μετρικές κατηγοριοποιούνται ανάλογα με το εάν αναφέρονται στο πεδίο του χρόνου ή της συχνότητας, και

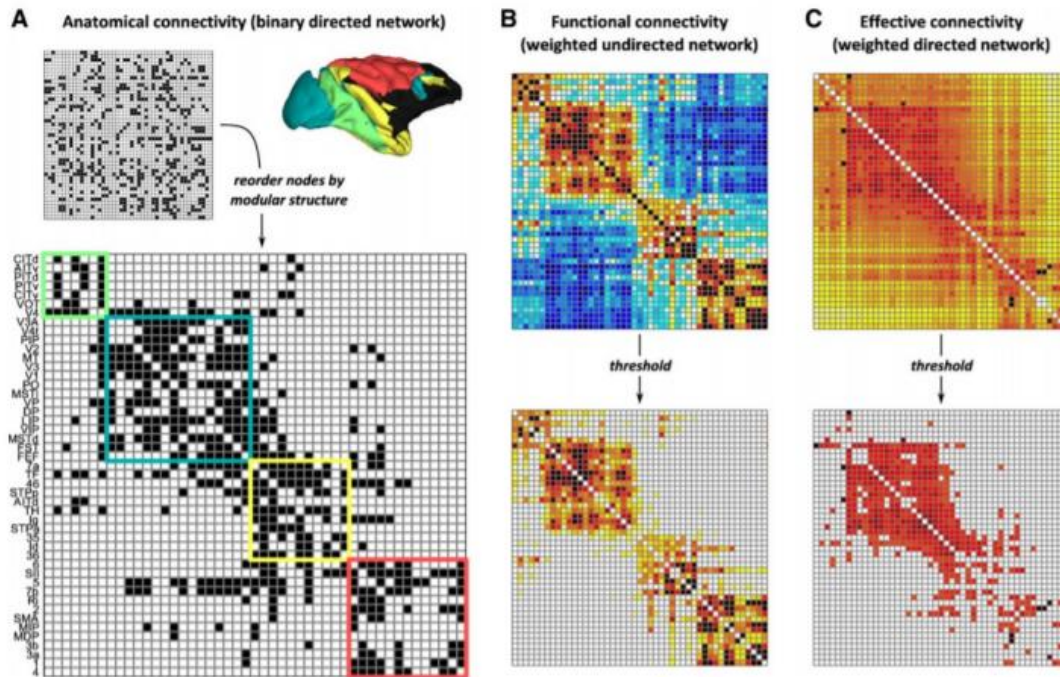
κατά πόσο λαμβάνουν υπόψιν την κατεύθυνση της ροής της πληροφορίας ή όχι.



Εικόνα 5: Μετρικές Υπολογισμού Συνδεσιμότητας

1.8 Αναπαράσταση Συνδεσιμότητας

Η συνήθης μορφή αναπαράστασης της εγκεφαλικής συνδεσιμότητας είναι χρησιμοποιώντας γράφους, ή αλλιώς μητρώα (matrices). Η ιδέα προκύπτει από το γεγονός ότι η συνδεσιμότητα μεταξύ στοιχειωδών μονάδων του εγκεφάλου δεν είναι τίποτε άλλο παρά ένα δίκτυο αποτελούμενο από κόμβους και συνδέσεις. Επομένως, εάν θεωρήσει κανείς σαν κόμβους τις περιοχές, τους νευρώνες, ή τα ηλεκτρόδια μεταξύ των οποίων εξετάζεται η συνδεσιμότητα, και ως ακμές την υπολογισμένη συνδεσιμότητα, όπου αυτή υπάρχει, δημιουργείται αυτόματα ένας γράφος/δίκτυο/μητρώο, υιοθετώντας τα αντίστοιχα χαρακτηριστικά των δομών αυτών. Και εφόσον πρόκειται για γράφο, αυτός μπορεί να είναι κατευθυνόμενος ή μη, δυαδικός ή όχι, ενώ συνήθως αφού υπολογιστεί η συνδεσιμότητα ορίζεται κάποια τιμή κατωφλίου ώστε να παραμείνουν οι συνδέσεις εκείνες που είναι πιο ισχυρές, οι οποίες ξεπερνούν το κατώφλι. Ένα παράδειγμα με μητρώα για τα τρία είδη συνδεσιμότητας φαίνεται στην παρακάτω εικόνα .



Εικόνα 6: Είδη συνδεσιμότητας και αναπαράσταση με μητρώα

1.9 Ανάλυση Συνδεσιμότητας

Η προσέγγιση της συνδεσιμότητας του εγκεφάλου με γράφους/δίκτυα, έχει εισαγάγει μετρικές και τεχνικές στην ανάλυση της συνδεσιμότητας δανεισμένες από τη γραφοθεωρία, οι οποίες έχουν αναδειχθεί σε σημαντικό εργαλείο για την κατανόηση και σύνδεση της δομής με τη λειτουργία του εγκεφάλου [25]. Το ενδιαφέρον της ανάλυσης από τη γραφοθεωρητική σκοπιά εστιάζεται σε μετρικές που σχετίζονται με :

- την εξειδίκευση ή τμηματοποίηση (segregation) του δικτύου, δηλαδή κατά πόσο τα στοιχεία του δικτύου τείνουν να σχηματίζουν συστάδες
- την ολοκλήρωση (integration) του δικτύου, η οποία αναφέρεται στην ικανότητα του δικτύου να είναι διασυνδεδεμένο και να ανταλλάσσεται πληροφορία
- την επιρροή (influence) του δικτύου, δηλαδή κόμβοι οι οποίοι έχουν εξέχοντα ρόλο στη λειτουργία του δικτύου.

Η ανάλυση τόσο στατικών ή δυναμικών εγκεφαλικών δικτύων με την προσέγγιση που περιγράψαμε παραπάνω, έχει οδηγήσει σε πλήθος δημοσιευμένων εργασιών μέσω των οποίων αποδεικνύεται η αποτύπωση δυσλειτουργιών του εγκεφάλου σε ανατομικό και λειτουργικό επίπεδο [35][36]. Η επεξήγηση φυσιολογικών ή μη λειτουργιών του εγκεφάλου δια μέσου της γραφοθεωρητικής ανάλυσης μπορεί να οδηγήσει σταδιακά στην εξαγωγή χρήσιμων βιοδεικτών οι οποίοι θα είναι ικανοί να χαρακτηρίζουν μια πιθανή δυσλειτουργία.

2. Ιστορικό Ερευνών – Πληροφορίες Αλγορίθμων

2.1 Ερευνητική Αναδρομή

Είναι γεγονός πως υπάρχει πλούσια βιβλιογραφία και μεγάλο ερευνητικό ενδιαφέρον σχετικά με την διανοητική – εγκεφαλική κόπωση (mental fatigue). Η διανοητική – εγκεφαλική κόπωση μπορεί να παρουσιαστεί σε διάφορες μορφές και δραστηριότητες, όπως η οδήγηση, η μελέτη, η έξουθενωτική αθλητική άσκηση κ.ά..

Αναμφίβολα πρόκειται για ένα φαινόμενο που απαντάται πολύ συχνά στους ανθρώπους και την καθημερινότητα τους και για ένα γεγονός που ταλαιπωρεί πολλούς. Η συστηματική παρακολούθηση αυτού του φαινομένου και επιστημονική εξήγηση των συνθηκών που προκαλούν αυτή την κόπωση και διαταράσσουν την ψυχική και σωματική υγεία των ανθρώπων, μπορεί να λειτουργήσει καταλυτικά στην καταπολέμηση του φαινομένου.

Όπως αναφέρεται παραπάνω, το φαινόμενο του mental fatigue έχει εξεταστεί από πολλές ερευνητικές ομάδες ανεξαρτήτως από την δραστηριότητα που το προκαλεί. Με στόχο να γίνει περισσότερο κατανοητή η έρευνα της παρούσας διπλωματικής εργασίας, κρίνεται αναγκαίο να πραγματοποιηθεί μία μικρή ερευνητική ανασκόπηση σε αντίστοιχες έρευνες που σχετίζονται με το φαινόμενο και στα αποτελέσματα αυτών.

Στην έρευνα που διεξήγαν οι *Kai-Quan Shen, Xiao-Ping Li* κ.ά..[36] στη δημοσίευση με τίτλο «*EEG-based mental fatigue measurement using multi-class support vector machines with confidence estimate*» παρουσιάζεται και αξιολογείται η μέτρηση της νοητικής κόπωσης που προκαλείται από την έλλειψη ύπνου. Σε όσους υποβλήθηκαν στο πείραμα, επιβλήθηκε στέρηση ύπνου για συνεχόμενες 25 ώρες ενώ επίσης ταυτόχρονα, ανά διαστήματα μία ώρα, διεξήχθη μία διαδικασία όπου τα subjects θα έπρεπε να ακολουθήσουν ένα σετ φωνητικών εντολών (Auditory Vigilance Task). Στο σύνολο δεδομένων το οποίο εν τέλει δημιουργήθηκε, εφαρμόστηκαν τεχνικές Feature Extraction και Feature Selection, ενώ επίσης για το classification χρησιμοποιήθηκε ο multi-class αλγόριθμος SVM.

Στην ερευνητική εργασία που ανέπτυξαν οι *G Xu, R., Zhang* [35] με τίτλο «*How Physical Activities Affect Mental Fatigue Based on EEG Energy, Connectivity, and Complexity*» αξιολογούνται οι επιπτώσεις που μπορεί να επιφέρει στην νοητική κατάσταση ενός ανθρώπου η φυσική δραστηριότητα του.

Στην έρευνα που διεξήγαν οι *G. Borghini, G. Vecchiato* κ.ά..[3] στη δημοσίευση με τίτλο «*Assessment of mental fatigue during car driving by using high resolution EEG activity and neurophysiologic indices*» παρουσιάζεται και αξιολογείται η μέτρηση της νοητικής κόπωσης που προκαλείται κατά τη διάρκεια της οδήγησης. Συμπληρωματικά με το ΗΕΓ έχουν χρησιμοποιηθεί κι άλλα αποτελέσματα από νευροφυσιολογικές τιμές, όπως είναι ο χτύπος της

καρδίας και το πόσες φορές ανοίγει και κλείνει ο οδηγός τα μάτια του. Για το πείραμα ζητήθηκε από εκείνους που θα υποβληθούν, να αποφύγουν την καφεΐνη, το βαριά γεύματα και η κατανάλωση όποιουδήποτε προϊόντος θα μπορούσε να επηρεάσει την τυπική απόδοση του οδηγού.

2.2 Μηχανική Μάθηση

Η μηχανική μάθηση (machine learning) είναι μια περιοχή της τεχνητής νοημοσύνης η οποία αφορά αλγορίθμους και μεθόδους που επιτρέπουν στους υπολογιστές να «μαθαίνουν».

Η μηχανική μάθηση εστιάζει στην ανάπτυξη προγραμμάτων υπολογιστών που να έχουν διδαχθεί με τέτοιο τρόπο έτσι ώστε να αναπτύσσονται και να μεταβάλλονται όταν εκτίθενται σε νέα δεδομένα. Εκτός από την επιστήμη των υπολογιστών και την τεχνητή νοημοσύνη, η μηχανική μάθηση έχει ισχυρούς δεσμούς με τη στατιστική και τη βελτιστοποίηση καθώς διατυπώνει και παρέχει τη θεωρία και τις μεθόδους σε αυτά τα δύο πεδία.

Τα συστήματα με ικανότητα μηχανικής μάθησης είναι σε θέση να μεταβάλλονται διαρκώς προς το καλύτερο, αναφορικά με τις λειτουργίες που είναι σε θέση να εκτελέσουν. Επιπλέον να μεταβάλλουν τη βάση γνώσης τους είτε μετασχηματίζοντας την εσωτερική τους δομή (π.χ. νευρωνικά δίκτυα) ή αποκτώντας επιπλέον γνώση (π.χ. έμπειρα συστήματα). Τέλος είναι σε θέση να εκτελούν γενικεύσεις, δηλαδή να αγνοούν χαρακτηριστικά και ιδιότητες που δεν είναι αντιπροσωπευτικά της έννοιας που πρέπει να μάθουν.

Με τη μηχανική μάθηση καθίσταται εφικτή η κατασκευή προσαρμοσίμων (adaptable) προγραμμάτων υπολογιστών τα οποία λειτουργούν με βάση την αυτοματοποιημένη ανάλυση συνόλων δεδομένων και όχι τη διαίσθηση των μηχανικών που τα προγραμμάτισαν.

Οι αλγόριθμοι μηχανικής μάθησης κατηγοριοποιούνται ανάλογα με το επιθυμητό αποτέλεσμα του αλγορίθμου. Οι συνηθέστερες κατηγορίες είναι οι εξής:

- Επιτηρούμενη μάθηση, επιβλεπόμενη μάθηση ή μάθηση με επίβλεψη (supervised learning), όπου ο αλγόριθμος κατασκευάζει μια συνάρτηση που απεικονίζει δεδομένες εισόδους σε γνωστές, επιθυμητές εξόδους (σύνολο εκπαίδευσης), με απώτερο στόχο τη γενίκευση της συνάρτησης αυτής και για εισόδους με άγνωστη έξοδο (σύνολο ελέγχου). Η συνάρτηση στόχος χρησιμοποιείται για την πρόβλεψη της τιμής μιας μεταβλητής, που ονομάζεται εξαρτημένη μεταβλητή ή μεταβλητή εξόδου, βάσει των τιμών ενός συνόλου μεταβλητών, που ονομάζονται ανεξάρτητες μεταβλητές ή μεταβλητές εισόδου ή χαρακτηριστικά. Το σύστημα τροφοδοτείται με ένα σύνολο γνωστών παραδειγμάτων, δηλαδή ένα σύνολο καταστάσεων στις οποίες μπορεί να περιέλθει το δίκτυο, μαζί με τα αποτελέσματα που θέλουμε να δίνει το δίκτυο για τις καταστάσεις αυτές.

- Μη επιτηρούμενη μάθηση, ανεπίβλεπτη μάθηση ή μάθηση χωρίς επίβλεψη (unsupervised learning), όπου ο αλγόριθμος κατασκευάζει ένα μοντέλο για κάποιο σύνολο εισόδων χωρίς να γνωρίζει επιθυμητές εξόδους για το σύνολο εκπαίδευσης. Στη μάθηση χωρίς επίβλεψη το σύστημα έχει στόχο να ανακαλύψει συσχετίσεις ή ομάδες σε ένα σύνολο δεδομένων, βασιζόμενο μόνο στις ιδιότητές τους. Το δίκτυο καλείται να αναγνωρίσει ομοιότητες και μοτίβα σε δεδομένα που του έχουμε τροφοδοτήσει. Τα δεδομένα παρουσιάζονται στο σύστημα και αυτό οφείλει να προσαρμοστεί έτσι ώστε να τα χωρίσει σε ομάδες. Η διαδικασία αυτή επαναλαμβάνεται, ώσπου δεν παρατηρείται μεταβολή στην ταξινόμηση των δεδομένων. Σαν αποτέλεσμα δημιουργούνται πρότυπα (περιγραφές), χωρίς να είναι γνωστό αν υπάρχουν, πόσα και ποια είναι, κάθε ένα από τα οποία περιγράφει ένα μέρος από τα δεδομένα. Συγκεκριμένα, ο αλγόριθμος κατασκευάζει ένα μοντέλο για κάποιο σύνολο εισόδων χωρίς να γνωρίζει επιθυμητές εξόδους για το σύνολο εκπαίδευσης.
- Ενισχυτική μάθηση (reinforcement learning), όπου ο αλγόριθμος μαθαίνει μια στρατηγική ενεργειών για μια δεδομένη παρατήρηση. Η έννοια της ενισχυτικής μάθησης είναι εμπνευσμένη από τα αντίστοιχα ανάλογα της μάθησης με επιβράβευση και τιμωρία που συναντώνται ως μοντέλα μάθησης των έμβιων όντων. Σκοπός του συστήματος μάθησης είναι να μεγιστοποιήσει μια συνάρτηση του αριθμητικού σήματος ενίσχυσης (ανταμοιβή), για παράδειγμα την αναμενόμενη τιμή του σήματος ενίσχυσης στο επόμενο βήμα. Το σύστημα δεν καθοδηγείται από κάποιον εξωτερικό επιβλέποντα για το ποια ενέργεια θα πρέπει να ακολουθήσει αλλά πρέπει να ανακαλύψει μόνο του ποιες ενέργειες είναι αυτές που θα του αποφέρουν το μεγαλύτερο κέρδος.

2.3 Αλγόριθμοι Classification

Η ταξινόμηση είναι το πρόβλημα του προσδιορισμού της κλάσης στην οποία ανήκει μία νέα παρατήρηση, δεδομένου ενός συνόλου δεδομένων εκπαίδευσης που περιέχει παρατηρήσεις των οποίων η κατηγορία είναι γνωστή. Στην κόσμο της μηχανικής μάθησης, η ταξινόμηση θεωρείται ένα παράδειγμα εποπτευόμενης μάθησης, δηλαδή μάθηση όπου ένα σύνολο δεδομένων είναι διαθέσιμο για την εκπαίδευση ενός αλγορίθμου. Η αντίστοιχη μη επιβλεπόμενη διαδικασία είναι γνωστή ως ομαδοποίηση, και περιλαμβάνει ομαδοποίηση των δεδομένων σε κατηγορίες με βάση κάποιο μέτρο της εγγενούς ομοιότητας ή της απόστασης. Ένα από τα πλέον χαρακτηριστικά παραδείγματα ταξινόμησης είναι αυτή του διαχωρισμού των e-mails με βάση το εάν είναι spam ή όχι.

2.3.1 KNN

Στην αναγνώριση προτύπων, ο αλγόριθμος K-Nearest Neighbors (k-NN) είναι μια μη παραμετρική μέθοδος που χρησιμοποιείται για την ταξινόμηση και την παλινδρόμηση. Και στις δύο περιπτώσεις, η είσοδος αποτελείται από τα k

πιο κοντινά παραδείγματα εκπαίδευσης στο χώρο χαρακτηριστικών. Η έξοδος εξαρτάται από το εάν το k-NN χρησιμοποιείται για ταξινόμηση ή παλινδρόμηση:

- Στην ταξινόμηση k-NN, η έξοδος είναι μέλος μιας κλάσης. Ένα αντικείμενο ταξινομείται με μια πλειοψηφία ψήφου των γειτόνων του, με το αντικείμενο να αντιστοιχεί στην τάξη που είναι πιο κοινή μεταξύ των k πλησιέστερων γειτόνων του (το k είναι θετικός ακέραιος, συνήθως μικρός). Εάν $k = 1$, τότε το αντικείμενο απλώς αντιστοιχίζεται στην κατηγορία αυτού του πλησιέστερου γείτονα.
- Στην παλινδρόμηση k-NN, η έξοδος είναι η τιμή ιδιότητας του αντικειμένου. Αυτή η τιμή είναι ο μέσος όρος των τιμών των πλησιέστερων γειτόνων.

Το k-NN είναι ένας τύπος μάθησης που βασίζεται σε γεγονότα, όπου η συνάρτηση προσεγγίζεται μόνο τοπικά. Τόσο για την ταξινόμηση όσο και για την παλινδρόμηση, μια χρήσιμη τεχνική μπορεί να είναι να αντιστοιχίζονται βάρη στις συνεισφορές των γειτόνων, έτσι ώστε οι πιο κοντινοί γείτονες να συνεισφέρουν περισσότερο στον μέσο όρο από τους πιο απομακρυσμένους. Οι γείτονες λαμβάνονται από ένα σύνολο αντικειμένων για τα οποία είναι γνωστή η κλάση (για την ταξινόμηση k-NN) ή η τιμή της ιδιότητας του αντικειμένου (για παλινδρόμηση k-NN). Αυτό μπορεί να θεωρηθεί ως το σύνολο εκπαίδευσης για τον αλγόριθμο, αν και δεν απαιτείται ρητό βήμα training. Μια ιδιαιτερότητα του αλγόριθμου k-NN είναι ότι είναι ευαίσθητος στην δομή των δεδομένων.

2.3.2 LDA

Η ανάλυση γραμμικής διάκρισης (LDA) είναι μια μέθοδος που χρησιμοποιείται στη στατιστική, την αναγνώριση προτύπων και τη μηχανική μάθηση για την εύρεση ενός γραμμικού συνδυασμού χαρακτηριστικών που χαρακτηρίζει ή χωρίζει δύο ή περισσότερες κατηγορίες αντικειμένων. Ο συνδυασμός που προκύπτει μπορεί να χρησιμοποιηθεί ως γραμμικός ταξινομητής ή, συνηθέστερα, για μείωση διαστάσεων πριν από την μεταγενέστερη ταξινόμηση. Παρακάτω παρουσιάζεται η μαθηματική διατύπωση του ταξινομητή. Στην περίπτωση που υπάρχουν περισσότερες από δύο κλάσεις, η ανάλυση που χρησιμοποιείται στην παραγωγή του Fisher Discriminant μπορεί να επεκταθεί για να βρει έναν υποχώρο που φαίνεται να περιέχει όλη τη μεταβλητότητα της κλάσης. Αυτή η γενίκευση οφείλεται στον C. R. Rao. Ας υποθέσουμε ότι κάθε κατηγορία C έχει μέσο όρο μ_i και την ίδια συνδιακύμανση Σ . Στη συνέχεια, η διασπορά μεταξύ της μεταβλητότητας κλάσης μπορεί να οριστεί από τη συνδιακύμανση δείγματος των μέσων της κλάσης

$$\Sigma_b = \frac{1}{C} \sum_{i=1}^C (\mu_i - \mu)(\mu_i - \mu)^T$$

όπου μ είναι ο μέσος όρος των μέσων της κλάσης. Ο διαχωρισμός της κλάσης προς μια κατεύθυνση w σε αυτήν την περίπτωση θα δοθεί από

$$S = \frac{\vec{w}^T \Sigma_b \vec{w}}{\vec{w}^T \Sigma_w \vec{w}}$$

Αυτό σημαίνει ότι όταν το w είναι ένα ιδιοδιάνυσμα του $\Sigma_b - \Sigma_w$ ο διαχωρισμός θα είναι ίσος με την αντίστοιχη ιδιοτιμή. Αν $\Sigma_b - \Sigma_w$ είναι διαγωνοποιήσιμος, η μεταβλητότητα μεταξύ των χαρακτηριστικών θα περιέχεται στον υποχώρο που ορίζεται από τα ιδιοδιανύσματα που αντιστοιχούν στις $C-1$ μεγαλύτερες ιδιοτιμές, (αφού Σ_b είναι τάξης $C-1$ το πολύ). Αυτά τα ιδιοδιανύσματα χρησιμοποιούνται κυρίως στη μείωση των χαρακτηριστικών, όπως στην PCA. Τα ιδιοδιανύσματα που αντιστοιχούν στις μικρότερες ιδιοτιμές θα τείνουν να είναι πολύ ευαίσθητα στην ακριβή επιλογή των δεδομένων εκπαίδευσης και συχνά είναι απαραίτητο να χρησιμοποιηθεί regularization.

2.3.3 Μηχανές Διανυσμάτων Υποστήριξης (SVM)

Οι μηχανές διανυσμάτων υποστήριξης (ή μηχανές διανυσματικής υποστήριξης) θεωρείται ως ο πιο επιτυχημένος αλγόριθμος κατηγοριοποίησης. Αν υποθέσουμε ότι υπάρχει γραμμική διαχωριστικότητα των δεδομένων που έχουμε για να κατηγοριοποιήσουμε, τότε η επιλογή του βέλτιστου υπερεπιπέδου, όσο αφορά την απόσταση των δύο κλάσεων είναι αυτό που επιτυγχάνει ο αλγόριθμος. Επιλέγει ένα μικρό αριθμό δεδομένων εκπαίδευσης (στιγμιότυπα), από κάθε κλάση τα οποία ορίζουν το μέγιστο περιθώριο (margin), μεταξύ των δύο κλάσεων και ανήκουν στην εποπτευόμενη μάθηση.

Η κύρια ιδέα ενός SVM είναι να δημιουργήσει ένα υπερεπίπεδο (hyperplane) ως την επιφάνεια απόφασης με τέτοιο τρόπο ώστε το περιθώριο ανάμεσα στα θετικά και αρνητικά παραδείγματα να είναι το μέγιστο. Η μηχανή επιτυγχάνει αυτό την επιθυμητή ιδιότητα, ακολουθώντας μια αρχή που έχει τις βάσεις της στην θεωρία στατιστικής μάθησης (statistical learning theory). Πιο συγκεκριμένα, τα SVMs είναι μια κατά προσέγγιση υλοποίηση της μεθόδου structural risk minimization. Αυτή η συνεπαγωγή βασίζεται στο γεγονός ότι το ποσοστό λάθους μιας μηχανής εκμάθησης στα δεδομένα ελέγχου (δηλαδή το generalization error rate) περικλείεται από το άθροισμα του ποσοστού λάθους εκπαίδευσης και ενός όρου που βασίζεται στο Vapnik- Chervonenkis (VC) dimension. Στην περίπτωση όπου έχουμε διαχωρίσιμα πρότυπα, το SVM παράγει μηδενική τιμή για τον πρώτο όρο και ελαχιστοποιεί το δεύτερο όρο.

Επομένως, ένα SVM μπορεί να παράξει καλά αποτελέσματα γενίκευσης σε προβλήματα pattern classification παρά το γεγονός ότι δεν έχει ενσωματωμένη γνώση για το πρόβλημα. Αυτό το χαρακτηριστικό είναι μοναδικό στα support vector machines.

Η λογική μια μηχανής εκμάθησης είναι να δίνει την τιμή y_i μιας συνάρτησης (άγνωστη προς εμάς) που αντιστοιχεί σε δοσμένο σημείο (διάνυσμα) x_i . Αυτό πραγματοποιείται με τον ακόλουθο τρόπο: Για δεδομένο σύνολο I σημείων $x_i \in \mathbb{R}^N$ και έχοντας τις αντίστοιχες τιμές $y_i \in \mathbb{R}^N$ που παίρνει η άγνωστη συνάρτηση, εκπαιδεύουμε τη μηχανή εκμάθησης να μάθει τη σχέση που συνδέει τα x_i με τα y_i . Δηλαδή, η μηχανή μαθαίνει την αντιστοίχιση $x_i \rightarrow y_i$ και έτσι για ένα σημείο x_m , διαφορετικό από αυτά του συνόλου της εκμάθησης, θα μας δώσει την τιμή που y_m θα έπαιρνε η άγνωστη συνάρτηση.

Στην περίπτωση ταξινόμησης με τα SVM, το σύνολο των σημείων I αποτελείται από δύο υποσύνολα τα k και n . Έτσι, το αποτέλεσμα της συνάρτησης θα είναι 1 ή -1 δηλαδή $y_i = 1$ ή $y_i = -1$, ανάλογα σε ποιο υποσύνολο ανήκει το δοθέν σημείο x_i . Τα δύο αυτά υποσύνολα ονομάζονται κλάσεις και η τιμή 1/ - 1 είναι η «ετικέτα» της κλάσης. Κατά αυτόν τον τρόπο, τα SVM μαθαίνουν να κατατάσσουν σωστά τα σημεία x_i στις δύο κλάσεις.


Τα σημεία x_i και οι αντίστοιχες τιμές τους y_i , αποτελούν την πληροφορία εκπαίδευσης (training set). Τα σημεία x_i ονομάζονται πρότυπα εκπαίδευσης (training patterns) και είναι διανύσματα που προκύπτουν από τα χαρακτηριστικά του εκάστοτε προβλήματος, ενώ οι τιμές y_i που αντιστοιχούν σε αυτά, ονομάζονται στόχοι εκπαίδευσης (training targets).

Γενικά οι μηχανές διανυσμάτων υποστήριξης:

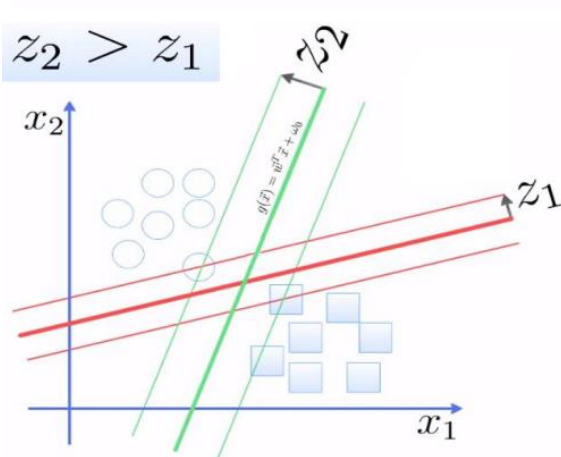
- Ανήκουν στην εποπτευόμενη μάθηση
- Σκοπός η σχεδίαση ενός υπερεπιπέδου που ταξινομεί τα στοιχεία σε κατηγορίες 20
- Η βέλτιστη επιλογή είναι εκείνο το υπερεπίπεδο με την μέγιστη απόσταση μεταξύ των κατηγοριών
- Η ελαχιστοποίηση της απόστασης είναι μια μη γραμμική διαδικασία βελτιστοποίησης που λύνεται από τις υποθέσεις Karush-Kuhn-Tucker (KKT), με χρήση πολλαπλασιαστών Lagrange λ_i

$$g(\vec{x}) \geq 1, \quad \forall \vec{x} \in \text{class 1}$$

$$g(\vec{x}) \leq -1, \quad \forall \vec{x} \in \text{class 2}$$



$$\frac{1}{\|\vec{w}\|} + \frac{1}{\|\vec{w}\|} = \frac{2}{\|\vec{w}\|}$$



$$\vec{w} = \sum_{i=0}^N \lambda_i y_i \vec{x}_i$$

$$\sum_{i=0}^N \lambda_i y_i = 0$$

Η πιο γενική περίπτωση των SVM είναι αυτή των γραμμικά μη διαχωρίσιμων κλάσεων δηλαδή αυτών που είναι μη διαχωρίσιμες από υπερεπίπεδο στο N-διάστατο χώρο. Στην περίπτωση διαχωρισμού των κλάσεων με κάποια άλλη γραμμή (καμπύλη) 21 θεωρείται επιβεβλημένη, καθώς μόνο με μια τέτοια αντιμετώπιση θα μπορούσαμε να διαχωρίσουμε τις κλάσεις. Η αναζήτηση γραμμών (καμπυλών) μεγαλύτερου βαθμού από την περίπτωση της ευθείας γραμμής, θα αύξανε την πολυπλοκότητα. Έτσι, αν ανάγουμε το πρόβλημα σε κάποιο χώρο μεγαλύτερων διαστάσεων H, θα έχουμε εκεί μόνο την εμφάνιση του εσωτερικού γινομένου $x_i y_i$. Αυτό που μας ενδιαφέρει ουσιαστικά είναι το αποτέλεσμα του εσωτερικού γινομένου στο χώρο H και όχι ο χώρος αυτός καθαυτός.

Η συνάρτηση που μας δίνει το αποτέλεσμα του εσωτερικού γινομένου στο χώρο, ονομάζεται συνάρτηση πυρήνα (Kernel function). Αν ισχύει $K(x_i, y_i) = \langle x_i, y_i \rangle$ τότε η κατηγορία αυτή των SVM μεταπίπτει στην περίπτωση των πλήρως γραμμικά διαχωρίσιμων κλάσεων. Όπως λοιπόν προκύπτει, αρκεί το αποτέλεσμα του εσωτερικού γινομένου των σημείων εκπαίδευσης σε αυτό το χώρο κάτι το οποίο δίνεται από την συνάρτηση πυρήνα (kernel function).

Οι συναρτήσεις πυρήνα που χρησιμοποιήθηκαν και αναλύθηκαν για την περίπτωση του διαχωρισμού κλάσεων ήταν:

- $K(x, y) = \langle xy \rangle$, Γραμμικό Πυρήνας

- $K(x, y) = e^{-\gamma \|x-y\|}, \gamma = \frac{1}{2\sigma^2}$, RBF Πυρήνας

Οι συναρτήσεις πυρήνα έχουν κάποιες μεταβλητές που καθορίζονται από το χρήστη. Οι μεταβλητές αυτές δεν έχουν καθορισμένη τιμή και σε κάθε περίπτωση πρέπει να επιλεγεί σωστά η τιμή τους. Οι βέλτιστες τιμές των παραμέτρων των συναρτήσεων πυρήνα είναι αυτές για τις οποίες θα έχουμε τα λιγότερα λάθη στην διαδικασία της κατάταξης.

3. ΠΕΙΡΑΜΑΤΙΚΗ ΔΙΑΔΙΚΑΣΙΑ

3.1 Γενικά Στοιχεία

Η πειραματική διαδικασία, τα αποτελέσματα της οποίας επεξεργάζονται και αναλύονται στην παρούσα διπλωματική εργασία, βασίστηκε πάνω στην δημοσίευση των Γιάννη Κάκκου και Γιώργου Δημητρακόπουλου [37] με τίτλο «*Functional connectivity analysis of mental fatigue reveals different network topological alterations between driving and vigilance tasks*».

Συνολικά για το πείραμα, συμμετείχαν 40 φοιτητές από το Πανεπιστήμιο της Σιγκαπούρης. Όλοι οι συμμετέχοντες ήταν υποχρεωμένοι να πληρούν τα εξής κριτήρια ώστε να μπορούν να πάρουν μέρος στην διαδικασία: να μην έχουν ιστορικό ψυχική ή νοητικής διαταραχής, να μην έχουν υποστεί οι ίδιοι χρόνια σωματική ή πνευματική κόπωση/ασθένεια, να μην έχουν κάνει χρήση φαρμάκων, καφεΐνης ή οποιασδήποτε ουσίας που μπορεί να προκαλέσει αλλαγή στην κατάσταση ηρεμίας τους και να έχουν συμπληρώσει παραπάνω από 7 ώρες ύπνου έως και δύο ημέρες πριν την πραγματοποίηση του πειράματος.

Για να είναι δυνατή η λήψη των ηλεκτροεγκεφαλικών σημάτων το κάθε άτομο έπρεπε να φορέσει μια συσκευή στο κεφάλι του, όπως φαίνεται και στο σχήμα 5, η οποία πρέπει να συνδεθεί στις κατάλληλες θέσεις με τα 64 κανάλια του ηλεκτροεγκεφαλογραφήματος. Τα οποία είναι τα εξής:

Iz, Fp1, AF7, AF3, F1, F3, F5, F7, FT7, FC5, FC3, FC1, C1, C3, C5, T7, TP7, CP5, CP3, CP1, P1, P3, P5, P7, P9, PO7, PO3, O1, Oz, POz, Pz, CPz, Fpz, Fp2, AF8, AF4, AFz, Fz, F2, F4, F6, F8, FT8, FC6, FC4, FC2, FCz, Cz, C2, C4, C6, T8, TP8, CP6, CP4, CP2, P2, P4, P6, P8, P10, PO8, PO4, O2.

Όπου τα γράμματα F,P, C αντιστοιχούν στις λέξεις Frontal, Central, Peripheral, δείχνουν δηλαδή μια εικόνα για την θέση που θα πρέπει να το τοποθετηθεί το αντίστοιχο ηλεκτρόδιο.



Εικόνα 7: Το “καπέλο” για τη σύνδεση με τα ηλεκτρόδια

Πριν από την τοποθέτηση των ηλεκτροδίων τοποθετείται ειδικό τζελ στα αντίστοιχα σημεία με στόχο να βοηθήσει στην καλύτερη λήψη των σημάτων. Η συχνότητα δειγματοληψίας που χρησιμοποιήθηκε για να μετατραπούν τα σήματα σε ψηφιακά ήταν 512Hz. Ακόμη, χρησιμοποιήθηκε ένα Band-Pass φίλτρο (0.5-70HZ) για επιτευχθεί anti-aliasing καθώς επίσης και ένα notch φίλτρο για την αποφυγή των παρεμβολών.

3.2 Διαδικασία

Στόχος της έρευνας που γίνεται στην προαναφερθείσα δημοσίευση είναι η ανάλυση και η σύνδεση της νοητικής/ψυχικής κόπωσης που προκαλείται τόσο από την οδήγηση όσο και από την διεξαγωγή ορισμένων δραστηριοτήτων. Για το λόγο αυτό, οι 40 συμμετέχοντες στο πείραμα χωρίστηκαν σε δύο.

Η μία ομάδα υπεβλήθει σε μία ώρα αδιάκοπης οδήγησης και στην διενέργεια μίας PVT. Το PVT είναι μία δραστηριότητα όπου κάποιος παρακολουθεί μία οθόνη στην οποία εμφανίζεται ένα τετράγωνο κουτί. Το αντικείμενο αυτό επανεμφανίζεται σε ένα διάστημα μεταξύ 2 και 10 δευτερολέπτων. Η διαδικασία αυτή διήρκησε 30 λεπτά και για αυτή την ώρα ο συμμετέχων έπρεπε να ακουμπά το τετράγωνο που εμφανίστηκε. Η διαδικασία της οδήγησης κράτησε 1 ώρα τόσο σε αυτοκινητόδρομο όσο και σε μικρότερους αστικούς δρόμους. Επιλέχθηκαν δρόμοι με πολύ χαμηλή κίνηση ώστε να επιτευχθεί χαμηλότερη πίεση στον οδηγό.

Η δεύτερη ομάδα υπεβλήθη σε μία διαδικασία γνωστικών γρίφων και προβλημάτων. Οι συμμετέχοντες κλήθηκαν να δούν μία εικόνα και στη συνέχεια

να αναγνωρίσουν στις επόμενες εικόνες που εμφανίζονταν μπροστά τους, αν αυτές ήταν ίδιες με την πρωτότυπη ή υπήρξε αλλαγή.

Τέλος, και οι δύο ομάδες έπρεπε να κάνουν μία ακόμα δραστηριότητα. Αυτή ήταν να παρατηρήσουν ένα αντικείμενο και στη συνέχεια να αποφασίσουν αν το νέο αντικείμενο που εμφανίστηκε στην οθόνη ήταν το ίδιο με κάποια κλίση ή έχει αντικατοπτριστεί. Τα μοτίβα αυτά επαναλήφθηκαν αρκετές φορές ώστε να είναι αντικειμενικά βέβαιο πως έχουν κουράσει τους συμμετέχοντες.

Για τη παρούσα διπλωματική εργασία χρησιμοποιήθηκαν τα αποτελέσματα των ΗΕΓ από όσους συμμετείχαν στην δοκιμασία της οδήγησης, συνολικά 21 άτομα.

4. ΕΠΕΞΕΡΓΑΣΙΑ & ΑΝΑΛΥΣΗ ΔΕΔΟΜΕΝΩΝ


4.1 Προ-επεξεργασία Δεδομένων

Μετά το τέλος του πειράματος και την καταγραφή των μετρήσεων, τα δεδομένα μεταφέρονται σε έναν υπολογιστή ώστε να γίνει το κομμάτι της προεπεξεργασίας. Τα δεδομένα αρχικά βρισκόντουσαν σε αρχεία με καταλήξεις .set και .fdt, η επεξεργασία των οποίων ενδείκνυται μέσω MATLAB.

4.2 Μορφή Δεδομένων

Μετά και το κομμάτι της προ-επεξεργασίας καταλήγουμε να έχουμε για κάθε ένα συμμετέχοντα 5 αρχεία, ένα αρχείο για κάθε μία μπάντα. Σε περιπτώσεις που γίνεται κάποια ανάλυση σε δεδομένα ηλεκτροεγκεφαλογραφήματος συνηθίζεται να χωρίζεται το σήμα στις συχνότητες

- Delta (1-4Hz)
- Theta (4-7Hz)
- Alpha (8-12Hz)
- Beta (12-30Hz)
- Gamma (30-45Hz)



Εικόνα 8: Σήμα EEG και οι αντίστοιχες κυματομορφές του στις μπάντες Delta, Theta, Alpha, Beta.

Αυτό μπορεί να γίνει εφαρμόζοντας στο αρχικό σήμα, με τη βοήθεια του EEGLAB, ένα Band-Pass φίλτρο που αποκόπτει κάθε φορά όλες τις συχνότητες εκτός από αυτές της μπάντας.

Όσον αφορά την καταγραφή των δεδομένων αυτή γίνεται ξεχωριστά για κάθε συμμετέχοντα σε 5 φασματικούς κύβους, έναν για κάθε μπάντα. Το κάθε αρχείο έχει μέγεθος 80*80*12. Η ποσότητα 80*80 είναι επειδή πρόκειται για καταγραφή από ένα δίκτυο 80 περιοχών, που όπως είναι προφανές όλες συνδέονται μεταξύ τους. Ο αριθμός 12 είναι επειδή πρόκειται για καταγραφές

τιμών ανά 5 λεπτά. Στη συνέχεια θα δούμε συγκρίσεις αποτελεσμάτων όπου έχουν γίνει καταγράψεις ανά 10, 15 και 20 λεπτά.

Επειδή, πρόκειται για ένα δίκτυο περιοχών που έχουν αποθηκευτεί σε έναν τετραγωνικό πίνακα, είναι αναγκαίο να ξεκαθαρίσουμε πως χρειάζεται να κρατήσουμε μόνο τον άνω (ή κάτω) τριγωνικό πίνακα χωρίς την κύρια διαγώνιο. Συνεπώς, από τον κάθε πίνακα χρησιμοποιούμε $\frac{80 \cdot 79}{2} = 3160$ τιμές. Εφόσον, έχουμε για κάθε υποδιαίρεση (πεντάλεπτο) 5 αρχεία, αυτό σημαίνει πως, για παράδειγμα, για τον πρώτο συμμετέχοντα και το πρώτο πεντάλεπτο έχουμε συνολικά 15800 τιμές. Αν σε αυτές τις τιμές που αποτελούν μία γραμμή προσθέσουμε άλλη μία που είναι η ετικέτα (label), ώστε να αναγνωρίσουμε σε ποιό πεντάλεπτο ανήκει η κάθε σειρά, καταλήγουμε τελικά με 15801 τιμές. Αυτές οι τιμές είναι οι στήλες του πίνακα, στον οποίο αποθηκεύονται το σύνολο των δεδομένων μας, και αποτελούν μία γραμμή. Συνολικά θα έχουμε για κάθε πεντάλεπτο 21 καταγραφές εφόσον τόσο είναι οι συμμετέχοντες στο πείραμα. Άρα συνολικά ο πίνακας μας θα είναι $(12 \cdot 21 = 252) \cdot 15801$. Αντίστοιχα για την υποδιαίρεση των 10 λεπτών θα είναι $126 \cdot 15801$ και στα 15 λεπτά θα είναι $84 \cdot 15801$. Εν τέλει, ο πίνακας με τα δεδομένα μας έχει την παρακάτω μορφή:

Παράδειγμα για την υποδιαίρεση των 5 λεπτών

252x15801 double											
	15791	15792	15793	15794	15795	15796	15797	15798	15799	15800	15801
13	0.0123	0.0088	0.0017	0.0013	0.0022	0.0117	0.0127	5.9896e-04	0.0104	1.8229e-04	1
14	0.0016	0.0051	0.0069	0.0036	0.0087	0.0077	0.0011	0.0079	0.0077	0.0084	1
15	0.0152	0.0078	3.9063e-04	0.0018	0.0016	0.0183	0.0124	0.0049	0.0130	1.8229e-04	1
16	0.0181	0.0060	0.0025	4.6875e-04	0.0044	0.0167	0.0189	0.0055	0.0079	0.0017	1
17	0.0111	4.9479e-04	2.6042e-05	0.0022	0.0020	0.0130	0.0077	1.5625e-04	7.8125e-05	0.0029	1
18	0.0163	0.0093	6.7708e-04	0.0057	0.0044	0.0177	0.0089	0.0071	0.0093	3.6458e-04	1
19	0.0170	0.0077	0.0012	0.0103	0.0021	0.0156	0.0127	0.0054	0.0104	2.8646e-04	1
20	0.0225	0.0114	0.0019	0.0070	0.0051	0.0200	0.0167	0.0028	0.0135	7.8125e-04	1
21	0.0151	0.0124	8.5938e-04	0.0059	0.0016	0.0174	0.0126	7.8125e-04	0.0150	0.0022	1
22	0.0185	0.0226	0.0078	0.0063	0.0268	0.0177	0.0219	0.0063	0.0324	0.0077	2
23	0.0063	0.0063	0.0029	0.0031	0.0167	0.0116	0.0085	0.0015	0.0097	0.0049	2
24	0.0063	0.0110	0.0071	0.0161	0.0040	0.0137	4.4271e-04	0.0097	0.0102	0.0071	2
25	0.0125	0.0185	1.8229e-04	0.0072	0.0065	0.0188	0.0075	0.0104	0.0155	0.0019	2
26	0.0134	0.0091	0.0022	0.0114	0.0045	0.0072	0.0083	0.0057	0.0121	0.0025	2
27	0.0178	0.0159	0.0038	0.0077	0.0018	0.0180	0.0141	0.0068	0.0179	0.0012	2
28	0.0210	0.0122	0.0043	0.0049	0.0044	0.0166	0.0139	0.0060	0.0140	6.5104e-04	2
29	0.0155	0.0084	0.0024	0.0099	0.0016	0.0121	0.0101	0.0056	0.0117	0.0011	2

Εικόνα 9: Σύνολο δεδομένων για 12 labels

4.2 Feature Selection

Στον κλάδο της μηχανικής μάθησης και γενικά στη στατιστική, η διαδικασία κατά την οποία επιλέγεται ένα υποσύνολο που περιλαμβάνει ορισμένα από τα αρχικά χαρακτηριστικά του συνόλου δεδομένων είναι γνωστή ως feature selection. Ο κύριος στόχος του feature selection είναι να επιλεγθούν εκείνα τα χαρακτηριστικά που περιέχουν την περισσότερη και πιο χρήσιμη πληροφορία. Διαφορετικά, να απορριφθούν εκείνα τα χαρακτηριστικά των οποίων η αφαίρεση θα έχει ελάχιστη επιρροή στο μοντέλο. Οι βασικοί λόγοι για τους οποίους η συγκεκριμένη διαδικασία είναι ιδιαίτερα σημαντική για την κατασκευή ενός μοντέλου είναι οι εξής:

- Απλοποίηση του μοντέλου και κατά συνέπεια ευκολότερη ανάλυση και ερμηνεία
- Μειώνονται αισθητά οι χρόνοι εκπαίδευσης
- Μπορεί να αντιμετωπιστεί το overfitting, δεδομένου ότι το μοντέλο εξετάζεται σε πιο γενικευμένες περιστάσεις

Η λειτουργία του feature selection δεν θα πρέπει να συγχέεται με αυτήν του feature extraction. Αφού, όπως αναλύθηκε και προηγουμένως, το feature extraction στοχεύει στην δημιουργία νέων χαρακτηριστικών από τα αρχικά. Αντίθετα, το feature selection στοχεύει στην επιλογή ενός υποσυνόλου.

4.3 Recursive Feature Selection (RFE)

Το RFE είναι μια δημοφιλής τεχνική ειδικά σε περιπτώσεις με σχετικά μικρό αριθμό δεδομένων. Ο λόγος είναι η επαναληπτική διαδικασία που ακολουθεί. Το RFE προσπαθεί να βελτιώσει την ακρίβεια του μοντέλου αφαιρώντας επαναληπτικά τα λιγότερο σημαντικά features, εκείνα δηλαδή των οποίων η απόρριψη θα έχει τη μικρότερη δυνατή επίδραση στο σφάλμα εκπαίδευσης. Πιο συγκεκριμένα, αφαιρούνται επαναληπτικά features που δεν συνεισφέρουν σημαντικά στο μοντέλο και έπειτα δημιουργείται νέο μοντέλο με εκείνα που μένουν.

Στο σημείο αυτό θα παρουσιαστεί η μαθηματική επεξήγηση του RFE χρησιμοποιώντας SVM[30]. Έστω ένα πρόβλημα στο οποίο υπάρχουν σημεία που δεν είναι γραμμικά διαχώριμα, στο σύστημα μπορούν να εισαχθούν κάποιες παράμετροι ξ_i που περιέχουν πληροφορία για την απόσταση της εκάστοτε μέτρησης από το βέλτιστο υπερεπίπεδο που μπορεί να τα διαχωρίσει. Ο SVM κατασκευάζεται ελαχιστοποιώντας τη συνάρτηση

$$\Phi(w, \xi) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i$$

που προβάλλεται στο

$$y(wx_i + b) \geq 1 - \xi_i$$

Όπου με w συμβολίζεται το διάνυσμα βαρών και με x το σύνολο δεδομένων εκπαίδευσης. Η βέλτιστη λύση εξάγεται λύνοντας το πρόβλημα:

$$W(a) = \sum_{i=1}^m a_i - \frac{1}{2} \sum_{i,j=1}^m y_i y_j a_i a_j (x_i x_j)$$

με τους κάτωθι περιορισμούς

$$0 \leq a_i \leq C, i = 1, \dots, m$$

$$\sum_{i=1}^n a_i y_i = 0$$

Όπου τα a_i αντιστοιχούν στους συντελεστές Lagrange.

Όπως αναφέρθηκε και νωρίτερα ο RFE διώχνει από το μοντέλο τα λιγότερο σημαντικά χαρακτηριστικά, τα οποία είναι αυτά με τη μικρότερη τιμή w . Ο πίνακας W από τον οποίο προκύπτει η απόφαση που θα λάβει ο αλγόριθμος υπολογίζεται από τις επόμενες σχέσεις, για πλήρως γραμμικά διαχωρίσιμο πρόβλημα και μη γραμμικά διαχωρίσιμο αντίστοιχα.

$$W = \sum_{k \in SV(y_k a_k X_k)}$$

$$w_i = \frac{1}{2} a^T K a - \frac{1}{2} a^T K(-i) a$$

Το $K(-i)$ αναφέρεται στον πίνακα Kernel από τον οποίο απουσιάζει η i -οστή γραμμή.

Η διαδικασία του Feature Selection πραγματοποιήθηκε στα δεδομένα, και πιο συγκεκριμένα χρησιμοποιήθηκε η μέθοδος RFE, που αναλύθηκε παραπάνω με τη βοήθεια του αλγορίθμου SVM. Στο τέλος της διαδικασίας υπήρξαν αποθηκευμένες, εκτός των άλλων, οι τιμές των σημαντικότερων features σε φθίνουσα σειρά.

4.4 Classifications με εφαρμογή Feature Selection

Για να πραγματοποιηθεί τελικά το classification δεν απαιτείται κάποια ιδιαίτερη προσπάθεια δεδομένου ότι τα αρχεία έχουν έρθει σε μορφή που εξυπηρετεί αυτή τη διαδικασία. Το classification μπορεί να υλοποιηθεί ακόμα και με το toolbox της MATLAB, classification learner, σε περίπτωση που υπάρχει η επιθυμία για την αποφυγή κώδικα.

Οι αλγόριθμοι που χρησιμοποιήθηκαν για το classification είναι οι: LDA, KNN, Gaussian SVM, Linear SVM και RandomForest (μονο στα δεδομένα με υποδιαίρεση 5 λεπτών). Μαζί με τα αποτελέσματα από το classification, παρήχθησαν και τα κατάλληλα confusion matrices και δείκτες ακρίβειας για τα μοντέλα που δημιουργήθηκαν.

5. ΑΠΟΤΕΛΕΣΜΑΤΑ

Για την αξιολόγηση των μοντέλων και την ανάλυση των αποτελεσμάτων έγινε πληθώρα συγκρίσεων με μικρότερες ή μεγαλύτερες υποδιαίρεσεις και με την αφαίρεση ορισμένων μπαντών ώστε να εξεταστεί αν υπάρχουν καλύτερα αποτελέσματα.

5.1 Χρήση κάθε μπάντας


Όπως αναφέρθηκε και παραπάνω, στην περίπτωση που δεν αφαιρέθηκε καμία μπάντα έγινε χρήση των αλγορίθμων KNN, Gaussian SVM, Linear SVM και RandomForest. Τα αποτελέσματα όσον αφορά την ακρίβεια για αυτή την περίπτωση σε κάθε σενάριο υποδιαίρεσης φαίνεται στον παρακάτω πίνακα:

Αλγόριθμος	PLI_5MIN	PLI_10MIN	PLI_15MIN
KNN	0.3333 (75)	0,5833 (1)	0.75 (2)
LDA	0.4583 (140)	0,5833 (30)	0.75 (12)
Random Forest	0.3750 (45)	0,5 (2)	0.75 (66)
SVM_Gaussian	0.25 (19)	0,4167 (192)	0.6250 (19)
SVM_Linear	0.2915 (2)	0,5 (16)	0.75 (44)


Μέσα σε παρένθεση, είναι ο αριθμός των features που χρειάστηκαν ώστε να βρεθεί η μέγιστη ακρίβεια.

Ακολουθούν οι γραφικές παραστάσεις στις οποίες απεικονίζεται για κάθε αλγόριθμο ταξινόμησης και αντίστοιχα για κάθε υποδιαίρεση ο αριθμός των features με την αντίστοιχη ακρίβεια.


Για τα 5 λεπτά:




Εικόνα 10: KNN (5 λεπτα)




Εικόνα 11: LDA (5 λεπτα)



Εικόνα 12: Random Forest (5 λεπτα)




Εικόνα 13: SVM Gaussian (5 λεπτα)




Εικόνα 14: SVM Linear (5 λεπτά)


Για τα 10 λεπτά:




Εικόνα 15: KNN (10 λεπτά)




Εικόνα 16: LDA (10 λεπτα)



Εικόνα 17: Random Forest (10 λεπτα)




Εικόνα 18: SVM Gaussian (10 λεπτά)




Εικόνα 19: SVM Linear (10 λεπτά)


Για τα 15 λεπτά:




Εικόνα 20: KNN (15 λεπτα)




Εικόνα 21: LDA (15 λεπτα)



Εικόνα 22: Random Forest (15 λεπτα)



Εικόνα 23: SVM Gaussian (15 λεπτα)



Εικόνα 24: SVM Linear (15 λεπτά)

5.2 Χρήση όλων εκτός της Gamma Band


Στην περίπτωση αυτή αφαιρέθηκε τα features της Gamma band και έγινε χρήση των αλγορίθμων KNN, Gaussian SVM, Linear SVM. Τα αποτελέσματα όσον αφορά την ακρίβεια για αυτή την περίπτωση σε κάθε σενάριο υποδιαίρεσης φαίνεται στον παρακάτω πίνακα:

Αλγόριθμος	PLI_5MIN	PLI_10MIN	PLI_15MIN
KNN	0.2917 (5)	0,5833 (9)	0.75 (11)
LDA	0.3333 (127)	0,5833 (33)	0.75 (12)
SVM_Gaussian	0.2917 (18)	0,4167 (7)	0.6250 (23)
SVM_Linear	0.3333 (13)	0,5 (54)	0.75 (34)


Μέσα σε παρένθεση, είναι ο αριθμός των features που χρειάστηκαν ώστε να βρεθεί η μέγιστη ακρίβεια.

Ακολουθούν οι γραφικές παραστάσεις στις οποίες απεικονίζεται για κάθε αλγόριθμο ταξινόμησης και αντίστοιχα για κάθε υποδιαίρεση ο αριθμός των features με την αντίστοιχη ακρίβεια.


Για τα 5 λεπτά:




Εικόνα 25: KNN (5 λεπτα-No Gamma)



Εικόνα 26: LDA (5 λεπτα-No Gamma)




Εικόνα 27: SVM Gaussian (5 λεπτα-No Gamma)




Εικόνα 28: SVM Linear (5 λεπτα-No Gamma)


Για τα 10 λεπτά:




Εικόνα 29: KNN (10 λεπτα-No Gamma)



Εικόνα 30: LDA (10 λεπτα-No Gamma)




Εικόνα 31: SVM Gaussian (10 λεπτα-No Gamma)




Εικόνα 32: SVM Linear (10 λεπτα-No Gamma)


Για τα 15 λεπτά:




Εικόνα 33: KNN (15 λεπτα-No Gamma)



Εικόνα 34: LDA (15 λεπτα-No Gamma)



Εικόνα 35: SVM Gaussian (15 λεπτα-No Gamma)



Εικόνα 36: SVM Linear (15 λεπτα-No Gamma)

5.3 Χρήση μόνο Theta Band


Στην περίπτωση αυτή αφαιρέθηκε όλα τα features, πλην της Theta band και έγινε χρήση των αλγορίθμων KNN, Gaussian SVM, Linear SVM. Τα αποτελέσματα όσον αφορά την ακρίβεια για αυτή την περίπτωση σε κάθε σενάριο υποδιαίρεσης φαίνεται στον παρακάτω πίνακα:

Αλγόριθμος	PLI_5MIN	PLI_10MIN	PLI_15MIN
KNN	0.2917 (4)	0,5833 (33)	0.6250 (1)
LDA	0.3333 (129)	0,5833 (33)	0.75 (12)
SVM_Gaussian	0.2917 (18)	0,4167 (16)	0.75 (195)
SVM_Linear	0.3333 (57)	0,5 (16)	0.6250 (3)


Μέσα σε παρένθεση, είναι ο αριθμός των features που χρειάστηκαν ώστε να βρεθεί η μέγιστη ακρίβεια.

Ακολουθούν οι γραφικές παραστάσεις στις οποίες απεικονίζεται για κάθε αλγόριθμο ταξινόμησης και αντίστοιχα για κάθε υποδιαίρεση ο αριθμός των features με την αντίστοιχη ακρίβεια.


Για τα 5 λεπτά:




Εικόνα 37: KNN (5 λεπτα-Only Theta)



Εικόνα 38: LDA (5 λεπτα-Only Theta)




Εικόνα 39: SVM Gaussian (5 λεπτα-Only Theta)




Εικόνα 40: SVM Linear (5 λεπτα-Only Theta)


Για τα 10 λεπτά:




Εικόνα 41: KNN (10 λεπτα-Only Theta)



Εικόνα 42: LDA (10 λεπτα-Only Theta)




Εικόνα 43: SVM Gaussian (10 λεπτα-Only Theta)




Εικόνα 44: SVM Linear (10 λεπτα-Only Theta)


Για τα 15 λεπτά:




Εικόνα 45: KNN (15 λεπτα-Only Theta)



Εικόνα 46: LDA (15 λεπτα-Only Theta)



Εικόνα 47: SVM Gaussian (15 λεπτα-Only Theta)



Εικόνα 48: SVM Linear (15 λεπτα-Only Theta)

6. Αξιολόγηση Αποτελεσμάτων και Μελλοντικές Επεκτάσεις

6.1 Αξιολόγηση Αποτελεσμάτων

Στο πλαίσιο των αποτελεσμάτων και της αξιολόγησης αυτών, κρίθηκε απαραίτητο να εντοπιστούν οι συνδέσεις μέσα στο δίκτυο. Η διαδικασία για την εύρεση των συνδέσεων μέσα στο δίκτυο είναι αρχικά να βρούμε τα μικρότερο αριθμό features που μπορούν να χρησιμοποιηθούν ώστε να έχουμε την μέγιστη ακρίβεια στο classification. Στη συνέχεια χρησιμοποιούνται αυτά τα features για να βρεθούν οι συνδέσεις. Μετά από έλεγχο για όλα τα classifications και για όλες τις υποδιαιρέσεις της ώρας καταλήγουμε στο συμπέρασμα πως όλες οι συνδέσεις ανήκουν στο Theta band και στις συνδέσεις που βρίσκονται μπροστινό μέρος του εγκεφάλου. Στην δημοσίευση των Δημητρακόπουλου, Κάκκου [37], πάνω στην οποία βασίστηκε η παρούσα διπλωματική εργασία, αναφέρεται πως έχουν γίνει εκτενής έρευνες όπου διαπιστώθηκε η συσχέτιση της νοητικής κόπωσης με αύξηση της Theta δραστηριότητας στην μετωπιαία, προμετωπιαία, μετωποκεντρική και βρεγματική περιοχή του εγκεφάλου.

Όσον αφορά τα αποτελέσματα που παρουσιάζονται παραπάνω σχετικά με το classification, πολλά συμπεράσματα μπορούν να εξαχθούν. Από τα βασικότερα που μπορούμε να σημειώσουμε είναι πως υπάρχει σαφής βελτίωση όσον γίνεται αφαίρεση ορισμένων μπαντών. Αυτό συμβαίνει διότι εκ του αποτελέσματος και ελέγχοντας τα features που χρειάστηκαν για τον υπολογισμό της εκάστοτε ακρίβειας, καταλήγουμε πως χρησιμοποιήθηκαν μόνον εκείνα που βρίσκονται στη Theta Band.

6.2 Μελλοντικές Επεκτάσεις

Είναι γεγονός πως η νοητική κόπωση και η προσπάθεια να ερευνηθεί, αν και με τί τρόπους σχετίζεται με διάφορες δραστηριότητες, απασχολεί ένα κομμάτι της ερευνητικής κοινότητας. Υπάρχει πληθώρα εργασιών και δημοσιεύσεων όπου διενεργούνται διάφορα πειράματα και εξάγονται χρήσιμα συμπεράσματα.

Η έρευνα γύρω από την νοητική κόπωση και την σχέση της με την οδήγηση αποτελεί ένα πολύ ενδιαφέρον και κρίσιμο κομμάτι αυτού του πεδίου. Και αυτό συμβαίνει διότι η οδήγηση αποτελεί αναπόσπαστο κομμάτι της καθημερινότητας εκατομμυριών ανθρώπων ανά τον κόσμο είτε για προσωπικούς λόγους εξυπηρέτησης και ανάγκης είτε για βιοποριστικούς λόγους. Οι δεύτεροι είναι και οι πιο σημαντικοί καθώς τα φαινόμενα ατυχημάτων και δυστυχημάτων στους αυτοκινητιστές είναι δυστυχώς πολλά. Η οδήγηση για μακρά χρονικά διαστήματα σε συνδυασμό με τις μεταμεσονύκτιες και όχι μόνο ώρες που δουλεύει πολύς κόσμος στο δρόμο έχουν αποβεί μοιραία. Η ερευνητική κοινότητα, εφόσον διαθέτει τα εργαλεία, οφείλει να στραφεί πως την κατεύθυνση της εξεύρεσης ορισμένων σχέσεων και εκτιμήσεων σχετικά με την χρονική στιγμή που επέρχεται η κόπωση στους οδηγούς ώστε να συμβάλει,

κατα το δυνατόν, στην αποφυγή δυσάρεστων και μη αναστρέψιμων φαινομένων.

Βιβλιογραφία

- [1] S. M. Marcora, W. Staiano, and V. Manning, "Mental fatigue impairs physical performance in humans." *J. Appl. Physiol.*, vol. 106, no. 3, pp. 857–864, Mar. 2009.
- [2] S. Charbonnier, R. N. Roy, S. Bonnet, and A. Campagne, "EEG index for control operators' mental fatigue monitoring using interactions between brain regions," *Expert Syst. Appl.*, vol. 52, pp. 91–98, 2016.
- [3] G. Borghini, L. Astolfi, G. Vecchiato, D. Mattia, and F. Babiloni, "Measuring neurophysiological signals in aircraft pilots and car drivers for the assessment of mental workload, fatigue and drowsiness," *Neurosci. Biobehav. Rev.*, vol. 44, pp. 58–75, July 2014.
- [4] K. Q. Shen, X. P. Li, C. J. Ong, S. Y. Shao, and E. P. V. Wilder-Smith, "EEG-based mental fatigue measurement using multi-class support vector machines with confidence estimate," *Clin. Neurophysiol.*, vol. 119, no. 7, pp. 1524–1533, July 2008.
- [5] Y. Sun, J. Lim, J. Meng, K. Kwok, N. Thakor, and A. Bezerianos, "Discriminative Analysis of Brain Functional Connectivity Patterns for Mental Fatigue Classification," *Ann. Biomed. Eng.*, vol. 42, no. 10, pp. 2084–2094, Oct. 2014.
- [6] 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 Cogn.*, vol. 85, no. 1, pp. 220–230, Mar. 2014.
- [7] T. P. K. Breckel, C. M. Thiel, E. T. Bullmore, A. Zalesky, A. X. Patel, and C. Giessing, "Long-Term Effects of Attentional Performance on Functional Brain Network Topology," *PLoS ONE*, vol. 8, no. 9, p. e74125, 2013.
- [8] M. M. Lorist, "Impact of top-down control during mental fatigue," *Brain Res.*, vol. 1232, pp. 113–123, Sep. 2008.
- [9] Y. Sun, J. Lim, Z. Dai, K. Wong, F. Taya, Y. Chen, J. Li, N. Thakor, and A. Bezerianos, "The effects of a mid-task break on the brain connectome in healthy participants: A resting-state functional mri study," *NeuroImage*, vol. 152, pp. 19–30, May 2017.
- [10] M. Alavash, P. Doebler, H. Holling, C. M. Thiel, and C. Gießing, "Is functional integration of resting state brain networks an unspecific biomarker for working memory performance?" *NeuroImage*, vol. 108, pp. 182–193, Mar. 2015.
- [11] M. G. Kitzbichler, R. N. A. Henson, M. L. Smith, P. J. Nathan, and E. T. Bullmore, "Cognitive Effort Drives Workspace Configuration of Human Brain Functional Networks," *J. Neurosci.*, vol. 31, no. 22, pp. 8259–8270, June 2011.

- [12] C. S. Huang, N. R. Pal, C. H. Chuang, and C. T. Lin, "Identifying changes in EEG information transfer during drowsy driving by transfer entropy." *Front. Hum. Neurosci.*, vol. 9, no. 570, 2015.
- [13] R. N. Khushaba, S. Kodagoda, S. Lal, and G. Dissanayake, "Driver drowsiness classification using fuzzy wavelet-packet-based feature extraction algorithm," *IEEE Trans. Biomed. Eng.*, vol. 58, no. 1, pp. 121–131, Jan. 2011.
- [14] S. Lal, A. Craig, P. Boord, L. Kirkup, and H. Nguyen, "Development of an algorithm for an EEG-based driver fatigue countermeasure," *J. Safety Res.*, vol. 34, no. 3, pp. 321–328, 2003.
- [15] L. L. P. Kostyniuk, F. F. M. Streff, and J. Zakrajsek, "Identifying Unsafe Driver Actions that Lead to Fatal Car-Truck Crashes," *AAA Found. Traffic Saf.*, vol. 9, no. 10, 2002.
- [16] M. V. Yeo, X. Li, K. Shen, and E. P. Wilder-Smith, "Can svm be used for automatic eeg detection of drowsiness during car driving?" *Safety Sci.*, vol. 47, no. 1, pp. 115–124, 2009.
- [17] K. Q. Shen, C. J. Ong, X. P. Li, Z. Hui, and E. P. Wilder-Smith, "A feature selection method for multilevel mental fatigue EEG classification," *IEEE Trans. Biomed. Eng.*, vol. 54, no. 7, pp. 1231–1237, July 2007.
- [18] G. Shou, L. Ding, and D. Dasari, "Probing neural activations from continuous EEG in a real-world task: Time-frequency independent component analysis," *J. Neurosci. Methods*, vol. 209, no. 1, pp. 22–34, 2012.
- [19] S. Kar, M. Bhagat, and A. Routray, "Eeg signal analysis for the assessment and quantification of drivers fatigue," *Transp. Res. Part F Traffic Psychol. Behav.*, vol. 13, no. 5, pp. 297–306, 2010.
- [20] C. Zhang, C.-X. Zheng, and X.-L. Yu, "Automatic recognition of cognitive fatigue from physiological indices by using wavelet packet transform and kernel learning algorithms," *Expert Syst. Appl.*, vol. 36, no. 3, pp. 4664–4671, Apr. 2009.
- [21] D. S. Bassett and E. T. Bullmore, "Small-World Brain Networks Revisited." *Neuroscientist*, p. 1073858416667720, Sep. 2016.
- [22] M. Rubinov and O. Sporns, "Complex network measures of brain connectivity: Uses and interpretations," *NeuroImage*, vol. 52, no. 3, pp. 1059–1069, Sep. 2010.
- [23] J. Li, J. Lim, Y. Chen, K. Wong, N. Thakor, A. Bezerianos, and Y. Sun, "Mid-Task Break Improves Global Integration of Functional Connectivity in Lower Alpha Band," *Front. Hum. Neurosci.*, vol. 10, no. 304, 2016.
- [24] D. Huang, A. Ren, J. Shang, Q. Lei, Y. Zhang, Z. Yin, J. Li, K. M. von Deneen, and L. Huang, "Combining partial directed coherence and graph theory to analyse effective brain networks of different mental tasks," *Front. Hum. Neurosci.*, vol. 10, no. 235, 2016.

[25] Posner I. Michael ,(1993), Foundations of Cognitive sciences , The MIT PRESS

[26] Pelvig DP, Pakkenberg, H, Stark, AK, Pakkenberg, B., (2008), "Neocortical glial cell numbers in human brains", στο Neurobiology of Aging

[27] Andrew BL, Part NJ, (1972), "Properties of fast and slow motor units in hind limb and tail muscles of the rat", στο Quarterly journal of experimental physiology and cognate medical sciences

[28] Niedermeyer E., da Silva F.L., (2004), "Electroencephalography: Basic Principles, Clinical Applications, and Related Fields", Lippincot Williams & Wilkins

[29] Jasper, H.H., (1958), "The ten-twenty electrode system of the International Federation", Electroencephalography and Clinical Neurophysiology

[30] Joseph N. Mak, and Jonathan R. Wolpaw ,(2009) "Clinical Applications of Brain-Computer Interfaces: Current State and Future Prospects", στο IEEE Reviews in Biomedical Engineering, pages 187-199

[31] Caldwell, J.A. Prazinko, B. Caldwell, J.L ,(2003), "Body posture affects electroencephalographic activity and psychomotor vigilance task performance in sleep-deprived subjects", στο Clinical Neurophysiology

[32] Thibault R.T.Lifshitz M, Jones JM, Raz A. ,(2014), "Posture alters human resting-state", στο Cortex

[33] Zakaria Moutakki, Imad Mohamed Ouloul, Karim Afdel, Abdellah Amghar,(2018), "Real-Time System Based on Feature Extraction for Vehicle Detection and Classification",στο Transport and Telecommunication

[34] Ramalingam Shanmugam,Rajan Chattamvelli ,(2015),"Skewness and Kurtosis", στο Statistics for Scientists and Engineers

[35] G Xu, R., Zhang, C., He, F., Zhao, X., Qi, H., Zhou, P., ... Ming, D. (2018). How Physical Activities Affect Mental Fatigue Based on EEG Energy, Connectivity, and Complexity. *Frontiers in Neurology*, 9.

[36] Kai-Quan Shena , Xiao-Ping Lib,* , Chong-Jin Onga , Shi-Yun Shaoa and Einar P.V. Wilder-Smithc, "EEG-based mental fatigue measurement using multi-class support vector machines with confidence estimate," *Neurosci. Biobehav. Rev.*, vol. 44, pp. 58–75, July 2014.

[37] Dimitrakopoulos, G. N., Kakkos, I., Dai, Z., Wang, H., Sgarbas, K., Thakor, N., ... Sun, Y. (2018). Functional Connectivity Analysis of Mental Fatigue Reveals Different Network Topological Alterations Between Driving and Vigilance Tasks. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 26(4), 740–749.

