

ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ Σχολή Ηλεκτρολογών Μηχανικών και Μηχανικών Υπολογιστών Τομέας Συστηματών Μεταδοσής Πληροφορίας και Τεχνολογίας Υλικών

Ανίχνευση νοητικής κόπωσης μέσω ΗΕΓ σε κατάσταση ηρεμίας: Διερεύνηση υπολογιστικών παραμέτρων και πόρων

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

της

Σοφίας Βουζίκα

Επιβλέπων : Γεώργιος Ματσόπουλος. Καθηγητής Ε.Μ.Π

Αθηνά, Ιούνιος 2025



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ Σχολή Ηλεκτρολογών Μηχανικών και Μηχανικών Υπολογιστών Τομέας Συστηματών Μεταδοσής Πληροφορίας και Τεχνολογίας Υλικών

Ανίχνευση νοητικής κόπωσης μέσω ΗΕΓ σε κατάσταση ηρεμίας: Διερεύνηση υπολογιστικών παραμέτρων και πόρων

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

της

Σοφίας Βουζίκα

Επιβλέπων : Γεώργιος Ματσόπουλος Καθηγητής Ε.Μ.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 27^η Ιουνίου 2025.

..... Γεώργιος Ματσόπουλος Καθηγητής Ε.Μ.Π. Αθανάσιος Δ. Παναγόπουλος Καθηγητής Ε.Μ.Π. Παναγιώτης Τσανάκας Καθηγητής Ε.Μ.Π.

Αθήνα, Ιούνιος 2025

 ∇ ' V ∇ ''

Σοφία Χ. Βουζίκα

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

Copyright © Σοφία Βουζίκα, 2025 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

Η παρούσα διπλωματική εργασία εξετάζει τον σχεδιασμό και την εκπόνηση μιας πολυπαραμετρικής διαδικασίας επεξεργασίας σημάτων ΗΕΓ με στόχο την αξιολόγηση συνδυασμών μεθόδων προεπεξεργασίας και αλγορίθμων στο πρόβλημα της κατηγοριοποίησης των διαθέσιμων δεδομένων μεταξύ κατάστασης νοητικής κόπωσης και ξεκούρασης. Η αξιολόγηση εστιάζει στα βήματα της επιλογής χαρακτηριστικών ταξινόμησης και των απαιτήσεων υπολογιστικών πόρων και χρόνου επεξεργασίας των αλγορίθμων.

Τα δεδομένα που χρησιμοποιήθηκαν προέρχονται από μια σειρά καταγραφών ΗΕΓ σε 71 συμμετέχοντες σε κατάσταση ηρεμίας, όπου για κάθε συμμετέχον μέλος έχουν πραγματοποιηθεί καταγραφές σε κατάσταση νοητικής ξεκούρασης και νοητικής κόπωσης. Πραγματοποιήθηκε αρχικά η προεπεξεργασία των δεδομένων ακολουθώντας τα τυπικά βήματα προεπεξεργασίας ΗΕΓ. Για την κατασκευή των εγκεφαλικών δικτύων αξιοποιήθηκε ο δείκτης Phase Lag Index (PLI), ενώ εφαρμόστηκαν μετρικές από τη θεωρία γράφων (Συντελεστής συγκέντρωσης, Μήκος Διαδρομής, Ιδιότητα Μικρόκοσμου, Παγκόσμια Αποδοτικότητα) για τη μελέτη της τοπολογικής διαφοροποίησης των δικτύων μεταξύ των δύο καταστάσεων. Παράλληλα, πραγματοποιήθηκε συγκριτική αξιολόγηση έντεκα μεθόδων επιλογής χαρακτηριστικών σε συνδυασμό με τέσσερις ταξινομητές (SVM linear kernel, SVM rbf kernel, KNN, LDA).

Από τα αποτελέσματα διαπιστώθηκε διαφοροποίηση στη μορφολογία των δικτύων με την αύξηση της συχνότητας, και αναδείχθηκε η σημασία της συνδυαστικής προσέγγισης τοπολογικών δεικτών και ταξινομητών στην αποτίμηση της λειτουργικής συνδεσιμότητας σε συνθήκες κόπωσης. Οι ακρίβειες που επιτεύχθηκαν αποδίδονται στη φύση των δεδομένων σε κατάσταση ηρεμίας, ενώ ορισμένοι συνδυασμοί μεθόδων αναδείχθηκαν αποτελεσματικοί, ιδιαίτερα για τις χαμηλότερες συχνότητες, προσφέροντας ενδείξεις για πιθανές περιοχές λειτουργικής διαφοροποίησης.

Λέξεις κλειδιά

Ηλεκτροεγκεφαλογράφημα, Νοητική κόπωση, Κατάσταση ηρεμίας, Λειτουργική συνδεσιμότητα, Αλγόριθμοι μηχανικής μάθησης

Abstract

This thesis examines the design and implementation of a multiparametric EEG signal processing pipeline, aiming to evaluate combinations of preprocessing methods and algorithms in the task of classifying available data between mental fatigue and rest conditions. The evaluation focuses on preprocessing steps as well as computational resource and time requirements of the algorithms.

The data used originate from a series of resting-state EEG recordings involving 71 participants, each of whom underwent recordings in both mental rest and fatigue states. Data preprocessing was initially performed following standard EEG preprocessing steps. To construct the brain networks, the Phase Lag Index (PLI) was employed, while graph-theoretic metrics (Clustering Coefficient, Path Length, Small Worldness, Global Efficiency) were applied to investigate topological differentiation between the two conditions. Additionally, a comparative assessment of eleven feature selection methods was carried out in combination with four classifiers (SVM with linear and RBF kernels, KNN, LDA).

The results indicated a morphological differentiation of the networks as frequency increased, highlighting the significance of the combined use of topological metrics and classifiers in assessing functional connectivity under fatigue. The classification accuracies achieved were influenced by the resting-state nature of the data; however, certain method combinations proved effective, particularly in lower frequency bands, suggesting regions of functional differentiation.

Key words

Electroencephalogram, Mental fatigue, Resting-state, Functional connectivity, Machine learning algorithms

Ευχαριστίες

Θα ήθελα πρωτίστως να εκφράσω τις θερμές μου ευχαριστίες στον επιβλέποντα καθηγητή μου, κ. Γεώργιο Ματσόπουλο, για την εμπιστοσύνη που μου έδειξε αναθέτοντάς μου αυτό το ιδιαίτερα ενδιαφέρον θέμα. Επίσης, θα ήθελα να ευχαριστήσω ιδιαίτερα την υποψήφια διδάκτορα Βαΐα Κοντοπούλου, διότι η καθοδήγηση, η διαρκής βοήθειά της και η πολύτιμη υποστήριξή της σε κάθε στάδιο της εργασίας ήταν καθοριστικής σημασίας για την ολοκλήρωσή της. Είμαι πολύ ευγνώμων για τους φίλους μου Έλενα, Δημήτρη και Πέννυ που μεγαλώνουμε και εξελισσόμαστε μαζί όλα αυτά τα χρόνια. Ακόμη, ευχαριστώ τις φίλες μου Άντα, Ελίνα, Χριστιάνα και Δέσποινα, που από την αρχή της σχολής έως και σήμερα αποτελούν για μένα στήριγμα, έμπνευση και την πιο όμορφη παρέα. Τέλος, το μεγαλύτερο ευχαριστώ πηγαίνει στην οικογένειά μου, για την αμέριστη αγάπη, την ενθάρρυνση και τη στήριξή της σε κάθε μου βήμα.

Σοφία Χ. Βουζίκα, Αθήνα, Ιούνιος 2025

Πίνακας περιεχομένων

Περίληψη	. 6
Abstract	. 8
Ευχαριστίες	10
Πίνακας περιεχομένων	12
Κατάλογος εικόνων	14
Κατάλογος πινάκων	16
1 Εισαγωγή	17
1.1 Αντικείμενο της εργασίας	17
1.2 Δομή και οργάνωση της εργασίας	17
2 Θεωρητικό Υπόβαθρο	19
2.1 Ανθρώπινος εγκέφαλος	19
2.1.1 Ανατομία του εγκεφάλου	19
2.1.2 Ηλεκτροφυσιολογία του εγκεφάλου	21
2.1.3 Νευρώνες και ηλεκτρική δραστηριότητα	21
2.2 Ηλεκτροεγκεφαλογράφημα	23
2.2.1 Ιστορική αναδρομή	24
2.2.2 Λειτουργία του ηλεκτροεγκεφαλογράφου και διαδικασία καταγραφής	24
2.2.3 Ζώνες συχνοτήτων	28
2.2.4 Καταγραφή ΗΕΓ σε κατάσταση ηρεμίας με ανοιχτά και με κλειστά μάτια	30
2.2.5 Παρεμβολές στο ΗΕΓ σε κατάσταση ηρεμίας	31
2.3 Λειτουργική συνδεσιμότητα του εγκεφάλου	31
2.3.1 Τεχνικές υπολογισμού λειτουργικής συνδεσιμότητας από ΗΕΓ	32
2.3.2 Δίκτυα PLI και ανάλυση μετρικών	32
2.4 Νοητική κόπωση	35
2.4.1 Έννοια της νοητικής κόπωσης	35
2.4.2 Νοητική κόπωση και λειτουργική συνδεσιμότητα	36
3 Μεθοδολογική Προσέγγιση και Υπολογιστικά Εργαλεία	38
3.1 Μηχανική Μάθηση	38
3.1.1 Κατηγορίες μηχανικής μάθησης και προβλημάτων	38
3.1.2 Μηχανική μάθηση στα ιατρικά δεδομένα	40
3.1.3 Αλγόριθμοι Ταξινόμησης	40
3.1.4 Επιλογή χαρακτηριστικών	45
3.2 Υπολογιστικοί πόροι και αξιολόγηση αλγορίθμων	48
Ερευνητική αναδρομή	50

4 Πειραματική Διαδικασία
4.1 Περιγραφή δεδομένων
4.2 Επεξεργασία και ανάλυση δεδομένων53
4.2.1 Προεπεξεργασία δεδομένων53
4.2.2 Υπολογισμός PLI και εξαγωγή μετρικών δικτύου
4.3 Επιλογή χαρακτηριστικών και ταξινόμηση56
5 Πειραματικά Αποτελέσματα και Σχολιασμός58
5.1 P-values μετρικών δικτύου58
5.2 Έλλειψη ισχυρών στατιστικών διαφορών58
5.3 Μέσες τιμές των μετρικών δικτύου58
5.4 Διαφοροποίηση της μορφής του δικτύου με βάση τη συχνότητα
5.5 Αποτελέσματα ταξινόμησης62
5.6 Ανάλυση ταξινομητικών αποτελεσμάτων και επιρροή επιλογής χαρακτηριστικών
6 Συμπεράσματα και Μελλοντικές Προεκτάσεις
6.1 Συμπεράσματα
6.2 Μελλοντικές προεκτάσεις
Βιβλιογραφία

Κατάλογος εικόνων

Εικόνα 2. 1: Ανατομία του εγκεφάλου [6]	21
Εικόνα 2. 2: Δομή τυπικού νευρώνα [8]	22
Εικόνα 2. 3: Κατανομή φορτίων στην μεμβράνη σε κατάσταση ηρεμίας [12]	23
Εικόνα 2. 4: Τοποθέτηση ηλεκτροδίων με το διεθνές σύστημα "10-20" [17]	26
Εικόνα 2. 5: Διαδικασία ψηφιοποίησης Ηλεκτροεγκεφαλογραφήματος [19]	27
Εικόνα 2. 6: Κυματομορφές των πέντε ρυθμών [20]	28
Εικόνα 3. 1: Διάγραμμα διαδικασίας Μηχανικής Μάθησης [55]	39
Εικόνα 3. 2: Αλγόριθμος ταξινόμησης KNN, με K=1,3,4 [58]	41
Εικόνα 3. 3: Γραφική απεικόνιση της Γραμμικής Διακριτής Ανάλυσης [59]	42
Εικόνα 3. 4: Απεικόνιση γραμμικού βέλτιστου υπερεπιπέδου που δημιουργείται από	τον
γραμμικό SVM [62]	43
Εικόνα 3. 5: Απεικόνιση μη γραμμικού υπερεπιπέδου που δημιούργησε μη γραμμικός S	VM
[62]	44
Εικόνα 5. 1: Συντελεστής συγκέντρωσης (CC) - Μέσες τιμές	59
Εικόνα 5. 2: Παγκόσμια Αποδοτικότητα (Eff global) - Μέσες τιμές	60
Εικόνα 5. 3: Μήκος Διαδρομής (L) - Μέσες τιμές	61
Εικόνα 5. 4: Ιδιότητα Μικρόκοσμου (SW)- Μέσες τιμές	62
Εικόνα 5. 5: Συνοπτική παρουσίαση ταξινομήσεων με ακρίβεια >75%	63
Εικόνα 5. 6: Απεικόνιση σημαντικών συνδέσεων δικτύου για την ταξινόμηση του ΚΝΝ	ί για
τη ζώνη Θήτα με τη μέθοδο reliefF	64
Εικόνα 5. 7: Μέση ακρίβειας ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του Κ	INN
για τη ζώνη Θήτα με τη μέθοδο reliefF	65
Εικόνα 5. 8: Μέσος χρόνος πρόβλεψης ανά το πλήθος χαρακτηριστικών για την ταξινόμ	ηση
του KNN για τη ζώνη Θήτα με τη μέθοδο reliefF	65
Εικόνα 5. 9: Μέσος χρόνος εκπαίδευσης ανά το πλήθος χαρακτηριστικών για την ταξινόμ	ηση
του KNN για τη ζώνη Θήτα με τη μέθοδο reliefF	66
Εικόνα 5. 10: Απεικόνιση σημαντικών συνδέσεων δικτύου για την ταξινόμηση του LDA	ι για
τη ζώνη Θήτα με τη μέθοδο reliefF	67
Εικόνα 5. 11: Μέση ακρίβεια ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του Ι	LDA
για τη ζώνη Θήτα με τη μέθοδο reliefF	67
Εικόνα 5. 12: Μέσος χρόνος πρόβλεψης ανά το πλήθος χαρακτηριστικών για την ταξινόμ	ηση
του LDA για τη ζώνη Θήτα με τη μέθοδο reliefF	68
Εικόνα 5. 13: Μέσος χρόνος εκπαίδευσης ανά το πλήθος χαρακτηριστικών για	την
ταξινόμηση του LDA για τη ζώνη Θήτα με τη μέθοδο reliefF	68
Εικόνα 5. 14: Απεικόνιση σημαντικών συνδέσεων δικτύου για την ταξινόμηση του LDA	για
τη ζώνη Δέλτα με τη μέθοδο reliefF	69
Εικόνα 5. 15: Μέση ακρίβεια ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του Ι	JDA
για τη ζώνη Δέλτα με τη μέθοδο reliefF	70
Εικόνα 5. 16: Μέσος χρόνος πρόβλεψης ανά το πλήθος χαρακτηριστικών για την ταξινόμ	ηση
του LDA για τη ζώνη Δέλτα με τη μέθοδο reliefF	70
Εικόνα 5. 17: Μέσος χρόνος εκπαίδευσης ανά το πλήθος χαρακτηριστικών για	την
ταξινόμηση του LDA για τη ζώνη Δέλτα με τη μέθοδο reliefF	71
Εικονα 5. 18: Απεικόνιση σημαντικών συνδέσεων δικτύου για την ταξινόμηση του ΚΝΝ	ι για
τη ζωνη Δελτα με τη μέθοδο relief Γ	
Εικονα 5. 19: Μέση ακριβεία ανα το πληθος χαρακτηριστικών για την ταξινόμηση του Κ	
για τη ζωνη Δελτα με τη μεθοδο relietF	72

Εικόνα 5. 20: Μέσος χρόνος πρόβλεψης ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του KNN για τη ζώνη Δέλτα με τη μέθοδο reliefF73 Εικόνα 5. 21: Μέσος χρόνος εκπαίδευσης ανά το πλήθος χαρακτηριστικών για την Εικόνα 5. 22: Απεικόνιση σημαντικών συνδέσεων δικτύου για την ταξινόμηση του SVM Εικόνα 5. 23: Μέση ακρίβεια ανά το πλήθος γαρακτηριστικών για την ταξινόμηση του SVM Εικόνα 5. 24: Μέσος γρόνος πρόβλεψης ανά το πλήθος γαρακτηριστικών για την ταξινόμηση Εικόνα 5. 25: Μέσος χρόνος εκπαίδευσης ανά το πλήθος χαρακτηριστικών για την Εικόνα 5. 26: Απεικόνιση σημαντικών συνδέσεων δικτύου για την ταξινόμηση του SVM με Εικόνα 5. 27: Μέση ακρίβεια ανά το πλήθος γαρακτηριστικών για την ταξινόμηση του SVM Εικόνα 5. 28: Μέσος χρόνος πρόβλεψης ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του SVM με πυρήνα συνάρτησης ακτινικής βάσης για τη ζώνη Θήτα με τη μέθοδο LASSO Εικόνα 5. 29: Μέσος χρόνος εκπαίδευσης ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του SVM με πυρήνα συνάρτησης ακτινικής βάσης για τη ζώνη Θήτα με τη Εικόνα 5. 30: Μέση ακρίβεια ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του LDA Εικόνα 5. 31: Μέσος χρόνος πρόβλεψης ανά το πλήθος χαρακτηριστικών για την ταξινόμηση Εικόνα 5. 32: Μέσος χρόνος εκπαίδευσης ανά το πλήθος χαρακτηριστικών για την Εικόνα 5. 33: Μέση ακρίβεια ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του LDA Εικόνα 5. 34: Μέσος χρόνος πρόβλεψης ανά το πλήθος χαρακτηριστικών για την ταξινόμηση Εικόνα 5. 35: Μέσος χρόνος εκπαίδευσης ανά το πλήθος χαρακτηριστικών για την Εικόνα 5. 36: Μέση ακρίβεια ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του LDA Εικόνα 5. 37: Μέσος χρόνος πρόβλεψης ανά το πλήθος χαρακτηριστικών για την ταξινόμηση Εικόνα 5. 38: Μέσος χρόνος εκπαίδευσης ανά το πλήθος χαρακτηριστικών για την

Κατάλογος πινάκων

Πίνακας 2. 1: Περιληπτική ανάλυση των ρυθμών
Πίνακας 3. 1:Δημοσιοποιήσεις με θέματα σχετικά με την Μηχανική μάθηση, το ΗΕΓ και την
νοητική κόπωση
Πίνακας 5. 1: Τιμές των p-values των μετρικών δικτύου ανά ζώνη συχνοτήτων
Πίνακας 5. 2: Συντελεστής συγκέντρωσης (CC) - Μέσες τιμές
Πίνακας 5. 3: Παγκόσμια Αποδοτικότητα (Eff global) - Μέσες τιμές
Πίνακας 5. 4: Μήκος Διαδρομής (L) - Μέσες τιμές
Πίνακας 5. 5: Ιδιότητα Μικρόκοσμου (SW)- Μέσες τιμές
Πίνακας 5. 6: Στοιχεία ταξινόμησης του KNN για την ζώνη Θήτα με την μέθοδο reliefF 63
Πίνακας 5. 7: Στοιχεία ταξινόμησης του LDA για την ζώνη Θήτα με την μέθοδο reliefF 66
Πίνακας 5. 8: Στοιχεία ταξινόμησης του LDA για την ζώνη Δέλτα με την μέθοδο reliefF. 69
Πίνακας 5. 9: Στοιγεία ταξινόμησης του KNN για την ζώνη Δέλτα με την μέθοδο reliefF. 71
Πίνακας 5, 10: Στοιχεία ταξινόμησης του SVM γραμμικού πυρήνα για την ζώνη Θήτα με την
μέθοδο LASSO
Πίνακας 5. 11: Στοιγεία ταξινόμησης του SVM με πυρήνα συνάρτησης ακτινικής βάσης για
την ζώνη Θήτα με την μέθοδο LASSO
Πίνακας 5. 12: Στοιγεία των βέλτιστων ταξινομήσεων για τις ζώνες Άλωα. Βήτα και Γάμμα
80

1 Εισαγωγή

1.1 Αντικείμενο της εργασίας

Η νοητική κόπωση αποτελεί μια σύνθετη ψυχοφυσιολογική κατάσταση, η οποία έχει άμεση επιρροή στη γνωστική απόδοση, την προσοχή και την επεξεργασία πληροφοριών από το άτομο. Για αυτό το λόγο, η κατανόηση και η αξιόπιστη ανίχνευση της νοητικής κόπωσης αποτελεί κρίσιμο ερευνητικό ζήτημα στον τομέα της γνωσιακής νευροεπιστήμης και της ανθρώπινης απόδοσης, καθώς σχετίζεται άμεσα με την ασφάλεια, την παραγωγικότητα και τη λήψη αποφάσεων σε απαιτητικά περιβάλλοντα. Στην κατεύθυνση αυτή, το ηλεκτροεγκεφαλογράφημα προσφέρει μια μη επεμβατική και υψηλής χρονικής ανάλυσης μέθοδο παρακολούθησης της εγκεφαλικής δραστηριότητας.

Η παρούσα διπλωματική εργασία διερευνά τη δυνατότητα ανίχνευσης της νοητικής κόπωσης μέσω ανάλυσης σημάτων ΗΕΓ σε κατάσταση ηρεμίας, εφαρμόζοντας μεθοδολογία βασισμένη στη λειτουργική συνδεσιμότητα και στη θεωρία γράφων. Στο πλαίσιο αυτό, εξετάζονται οι διαφοροποιήσεις των εγκεφαλικών δικτύων σε δύο καταστάσεις — ξεκούρασης και κόπωσης — με στόχο να εντοπιστούν εκείνα τα πρότυπα τοπολογίας ή χαρακτηριστικά που μπορούν να λειτουργήσουν ως δείκτες της νοητικής κατάστασης.

Η επιλογή δεδομένων σε κατάσταση ηρεμίας παρουσιάζει σημαντικό επιστημονικό ενδιαφέρον, καθώς σε αυτές τις συνθήκες δεν υπάρχει εξωτερική εργασία που να επιβάλλει εγκεφαλική οργάνωση, γεγονός που καθιστά την ταξινόμηση πιο απαιτητική. Ωστόσο, τυχόν διαφορές που αναδύονται μπορούν να αποδοθούν σε εσωτερικές λειτουργικές διαφοροποιήσεις μεταξύ των δύο καταστάσεων, γεγονός που ενισχύει τη σημασία της προσέγγισης [1].

Η εργασία επίσης, ενσωματώνει σύγχρονες μεθόδους επιλογής χαρακτηριστικών και ταξινόμησης, σε συνδυασμό με αξιολόγηση της κατανάλωσης υπολογιστικών πόρων, δημιουργώντας ένα ολοκληρωμένο πλαίσιο αξιολόγησης. Με αυτόν τον τρόπο, επιχειρείται μια πολυδιάστατη προσέγγιση της νοητικής κόπωσης που συνδυάζει βιοφυσικά, αλγοριθμικά και υπολογιστικά κριτήρια.

1.2 Δομή και οργάνωση της εργασίας

Η εργασία οργανώνεται σε έξι ενότητες:

Κεφάλαιο 1 – Εισαγωγή

Στο πρώτο κεφάλαιο παρουσιάζεται το γενικό πλαίσιο και το αντικείμενο της μελέτης. Αναλύεται το επιστημονικό και πρακτικό ενδιαφέρον πίσω από την εργασία και παρουσιάζονται οι στόχοι και τα ερευνητικά ζητήματα.

Κεφάλαιο 2 – Θεωρητικό υπόβαθρο

Σε αυτό το κεφάλαιο περιγράφονται οι βασικές έννοιες της δομής και λειτουργίας του εγκεφάλου, της ηλεκτροεγκεφαλογραφίας, των καταστάσεων κόπωσης και ανάπαυσης, της λειτουργικής συνδεσιμότητας και της θεωρίας γράφων.

Κεφάλαιο 3 – Μεθοδολογική προσέγγιση και υπολογιστικά εργαλεία

Ακολουθεί η ανάλυση των μεθόδων επιλογής χαρακτηριστικών και των αλγορίθμων ταξινόμησης. Επιπλέον παρουσιάζονται οι δείκτες αξιολόγησης αυτών.

Κεφάλαιο 4 – Πειραματική διαδικασία

Στο κεφάλαιο αυτό περιγράφεται αναλυτικά η δομή και τα χαρακτηριστικά του συνόλου δεδομένων που χρησιμοποιήθηκε στο πειραματικό μέρος. Παρουσιάζεται η επεξεργασία των δεδομένων, η εξαγωγή χαρακτηριστικών με τη χρήση του Phase Lag Index (PLI), καθώς και η κατασκευή και ανάλυση των εγκεφαλικών δικτύων. Τέλος, περιγράφεται η διαδικασία της ταξινόμησης.

Κεφάλαιο 5 – Πειραματικά αποτελέσματα και σχολιασμός

Παρουσιάζονται αναλυτικά τα σημαντικά αποτελέσματα των πειραμάτων τόσο για τις τοπολογικές μετρικές των εγκεφαλικών δικτύων, όσο και για τις επιδόσεις των ταξινομητών. Έπειτα ερμηνεύονται τα ευρήματα σε σχέση με την υπάρχουσα βιβλιογραφία και τη λειτουργική σημασία τους. Συζητείται η διαφοροποίηση των εγκεφαλικών δομών ανάμεσα σε συνθήκες νοητικής κόπωσης και νοητικής ξεκούρασης, με έμφαση στον ρόλο των υψηλών συχνοτήτων.

Κεφάλαιο 6 – Συμπεράσματα και μελλοντικές προεκτάσεις

Συνοψίζονται τα βασικά συμπεράσματα της μελέτης και προτείνονται μελλοντικές ερευνητικές κατευθύνσεις.

2 Θεωρητικό Υπόβαθρο

Στο παρόν κεφάλαιο αναλύονται βασικές θεωρητικές έννοιες που αφορούν τον ανθρώπινο εγκέφαλο, την ηλεκτροεγκεφαλογραφία, καθώς και την νοητική κόπωση. Επιπλέον περιγράφεται η λειτουργική συνδεσιμότητα, που αξιοποιείται σε συνδυασμό με εργαλεία από τη θεωρία γράφων για την ανάλυση της εγκεφαλικής δραστηριότητας.

2.1 Ανθρώπινος εγκέφαλος

Ο εγκέφαλος αποτελεί ένα από τα πιο πολύπλοκα όργανα του ανθρώπινου σώματος. Είναι το όργανο που ελέγχει όλες τις λειτουργίες του ανθρώπινου σώματος και αποτελεί το μεγαλύτερο όργανο του Κεντρικού Νευρικού Συστήματος (ΚΝΣ).

Απαρτίζεται από ένα εξαιρετικά πολυ-σύνθετο δίκτυο κυττάρων, οι λειτουργίες του οποίου είναι υπεύθυνες για τις ζωτικές και νοητικές λειτουργίες του ανθρώπου, για τον έλεγχο των κινήσεων και την επεξεργασία ερεθισμάτων από το περιβάλλον. Με βάρος περίπου 1,2-1,4 κιλά, αποτελείται από δισεκατομμύρια νευρώνες και γλοιακά κύτταρα που συνεργάζονται για την εκτέλεση αυτών των πολύπλοκων λειτουργιών [2].

2.1.1 Ανατομία του εγκεφάλου

Ο ανθρώπινος εγκέφαλος αποτελείται από τρία κύρια μέρη:

 Τον πρόσθιο εγκέφαλο ή αλλιώς εγκεφαλικό φλοιό. Αποτελεί το μεγαλύτερο μέρος του εγκεφάλου και είναι αυτό που συνδέεται με την υψηλότερη λειτουργία, όπως είναι η σκέψη και η ενέργεια. Χωρίζεται σε τέσσερις λοβούς: τον μετωπιαίο, τον βρεγματικό, τον ινιακό και τον κροταφικό λοβό.

Μετωπιαίος λοβός

Ο μετωπιαίος λοβός είναι ο μεγαλύτερος από τους λοβούς και βρίσκεται μπροστά από τα εγκεφαλικά ημισφαίρια, κάτω από το μέτωπο. Είναι υπεύθυνος αρχικά, για την μνήμη προοπτικής, την ανάμνηση δηλαδή σχεδίων που έχει κάνει το άτομο για το τώρα αλλά και το μέλλον. Περιέχει την περιοχή που καλείται "Broca", που εμπλέκεται στην παραγωγή ομιλίας. Ρυθμίζει την προσωπικότητα και την αλλαγή της, καθώς όταν υπάρξει βλάβη στον προμετωπιαίο φλοιό προκύπτουν οι εξής διαταραχές: α) εκτελεστικές διαταραχές, β) διαταραγμένη κοινωνική συμπεριφορά, γ) συναισθηματική απορρύθμιση, δ) υπο-συναισθηματικότητα / απενεργοποίηση ε) άγχος, στ) αδυναμία στη λήψη αποφάσεων. Τέλος, περιλαμβάνει τον κινητικό φλοιό που ευθύνεται και για την πραγματοποίηση της κίνησης [2].

Βρεγματικός λοβός

Ο βρεγματικός λοβός βρίσκεται πίσω από τον μετωπιαίο λοβό, ψηλότερα από τον κροταφικό και χωρίζεται σε δύο λειτουργικές περιοχές, τον πρόσθιο και τον οπίσθιο. Ο πρόσθιος βρεγματικός λοβός φιλοξενεί τον πρωτοταγή σωματοαισθητικό φλοιό, ο οποίος εντοπίζεται στην μετακεντρική έλικα. Το κομμάτι αυτό του εγκεφάλου έχει ως ρόλο την επεξεργασία των κύριων αισθητηριακών πληροφοριών, οι οποίες μεταφέρονται κυρίως μέσω του θαλάμου. Οι πληροφορίες αυτές περιλαμβάνουν τα ερεθίσματα της αφής, της πίεσης, της αίσθησης του πόνου, της θερμοκρασίας και της αντίληψης του χώρου. Από την άλλη ο οπίσθιος βρεγματικό λοβό. Αυτές οι δύο

περιοχές συμβάλουν σε γνωστικές λειτουργίες, όπως είναι η γλωσσική επεξεργασία, η εκμάθηση, η χωρική αντίληψη και η στερεογνωσία, δηλαδή η δυνατότητα να αναγνωριστεί ένα αντικείμενο με βάση κάποιο χαρακτηριστικό του όπως είναι το μέγεθος, το σχήμα και το βάρος του, χωρίς να είναι απαραίτητη η όραση [3].

Κροταφικός λοβός

Ο κροταφικός λοβός αποτελεί τον δεύτερο μεγαλύτερο λοβό και βρίσκεται πίσω από τον μετωπιαίο λοβό και κάτω από τον βρεγματικό. Ο ρόλος του αφορά την ανάλυση και την επεξεργασία των ήχων και των τόνων. Ένα επιπλέον χαρακτηριστικό του είναι ότι περιέχει δομές που συνδέονται με την δηλωτική μνήμη, μια μακροχρόνια μνήμη που σχετίζεται με την ανάμνηση ιδεών, εννοιών και γεγονότων ολόκληρης της ζωής του ατόμου. Χωρίζεται επιπλέον σε τριών ειδών μνήμες, την σημασιολογική, την μνήμη αναγνώρισης αντικειμένων και τις λεπτομέρειες που σχετίζονται με αυτό, και με την επεισοδιακή μνήμη, η οποία αφορά στην ενθύμηση ενός συγκεκριμένου γεγονότος με τις λεπτομέρειες του [2].

Ινιακός λοβός

Ο ινιακός λοβός είναι ο μικρότερος λοβός στον φλοιό του εγκεφάλου και βρίσκεται πίσω από τον βρεγματικό και τον κροταφικό λοβό. Ο ρόλος του είναι η λήψη, η επεξεργασία και η ερμηνεία οπτικών πληροφοριών και η αποστολή τους στις άλλες περιοχές του εγκεφάλου για περαιτέρω ανάλυση [4].

2. Τον εγκέφαλο. Αποτελείται από το δεξιό και το αριστερό ημισφαίριο, την παρεγκεφαλίδα και το στέλεχος [5].

Εγκεφαλικά ημισφαίρια

Ο εγκέφαλος διαιρείται σε δεξί και αριστερό ημισφαίριο που αποτελούν το μεγαλύτερο μέρος του. Η επιφάνειά τους παρουσιάζει πτυχώσεις με εξογκώματα που ονομάζονται έλικες και αύλακες. Οι βαθιές αύλακες ονομάζονται σχισμές. Τα δύο ημισφαίρια περιλαμβάνουν έναν εξωτερικό φλοιό από φαιά ουσία, που ονομάζεται εγκεφαλικός φλοιός, και εσωτερικά στρώματα λευκής ουσίας [4].

Παρεγκεφαλίδα

Η παρεγκεφαλίδα βρίσκεται στο οπίσθιο μέρος του κρανίου, πάνω από το ινιακό τμήμα και συνδέεται με τον εγκέφαλο μέσω των παρεγκεφαλιδικών ποδίσκων. Πρωταρχικός ρόλος της είναι να ρυθμίζει τον συντονισμό της κίνησης, της στάσης και της ισορροπίας του σώματος. Αποτελείται από τον φλοιό της παρεγκεφαλίδας, ο οποίος έχει τρία στρώματα (το μοριακό, το στρώμα Purkinje και το κοκκώδες), και από βαθύτερους παρεγκεφαλιδικούς πυρήνες [5].

Εγκεφαλικό στέλεχος

Το εγκεφαλικός στέλεχος περιλαμβάνει το μέσο εγκέφαλο, τη γέφυρα και τον προμήκη μυελό. Βρίσκεται μπροστά από την παρεγκεφαλίδα, ανάμεσα στη βάση του τελικού εγκεφάλου και του νωτιαίου μυελού. Η λειτουργία του περιλαμβάνει βασικές ζωτικές δραστηριότητες, όπως είναι η αναπνοή, ο καρδιακός ρυθμός και η αρτηριακή πίεση [5].

3. Τον οπίσθιο εγκέφαλο.



Εικόνα 2. 1: Ανατομία του εγκεφάλου [6]

2.1.2 Ηλεκτροφυσιολογία του εγκεφάλου

Ο ανθρώπινος εγκέφαλος είναι υπεύθυνος για λειτουργίες που αφορούν την δημιουργία σκέψεων, την μνήμη, τον έλεγχο των δραστηριοτήτων του σώματος και των συναισθημάτων. Αυτό το έργο επιτελείται από τους περίπου 10¹⁰ νευρώνες του εγκεφάλου, οι οποίοι συναντιούνται μεταξύ τους σε 10¹⁴ έως 10¹⁵ σημεία. [7]

Τα αισθητικά ερεθίσματα λαμβάνονται, μέσω των κεντρομόλων νεύρων και χαρακτηρίζονται ως αισθήσεις, που αποτελούν τη βάση της αντίληψης. Τα κινητικά ερεθίσματα μεταβιβάζονται, διαμέσου φυγόκεντρων νεύρων στους μυς και τους αδένες, εκλύοντας τις δραστηριότητες [2]. Χιλιάδες πληροφορίες εισέρχονται στον εγκέφαλο, οποίος δημιουργεί αντίστοιχα χιλιάδες αποστολές πληροφοριών, σε δευτερόλεπτα. Τα κύτταρα τα οποία είναι υπεύθυνα για αυτές τις δραστηριότητες είναι οι νευρώνες. Αυτές οι δραστηριότητες εκτελούνται με μεγάλη ταχύτητα και ταυτόχρονα με μεγάλη ακρίβεια [8].

Αυτή η μετάδοση των πληροφοριών πραγματοποιείται, κατά τη διάρκεια των συνάψεων, όπου οι νευρώνες και τα κύτταρα, έρχονται σε επαφή και μέσω χημικών λήψεων και ηλεκτρικών ωθήσεων, ανταλλάσσουν νευροδιαβιβαστές, που είναι υπεύθυνοι, για τη διέγερση ή την αναστολή της δράσης του άλλου κυττάρου. Αυτή η διαδικασία δημιουργεί την ηλεκτρική δραστηριότητα του εγκεφάλου.

2.1.3 Νευρώνες και ηλεκτρική δραστηριότητα

Το νευρικό κύτταρο ή αλλιώς νευρώνας είναι αυτόνομο και παράγει ηλεκτρικά σήματα που μεταδίδονται από το ένα μέρος του κυττάρου στο άλλο με τη μορφή νευρικής ώσης, ενώ ταυτόχρονα εκλύει βιοχημικές ουσίες προκειμένου να επικοινωνήσει με άλλα κύτταρα. Οι νευρώνες αποτελούνται από τρία βασικά κομμάτια, το κυτταρικό σώμα, τον άξονα και τους δενδρίτες.



Εικόνα 2. 2: Δομή τυπικού νευρώνα [8]

Οι περισσότερες συνάψεις, τα σημεία δηλαδή τα οποία λαμβάνουν τα σήματα από τους άλλους νευρώνες, βρίσκονται στους δενδρίτες και το κυρίως σώμα του κυττάρου. Ο άξονας ή νευρική ίνα, αποτελεί μια προέκταση του κυτταρικού σώματος. Το τμήμα του άξονα που βρίσκεται πλησιέστερα στο σώμα του κυττάρου, μαζί με το σημείο όπου γίνεται η σύνδεση, ονομάζεται αρχικό τμήμα. Από το σημείο αυτό, ξεκινούν τα ηλεκτρικά σήματα που διαδίδονται μακριά από το σώμα, κατά μήκος του άξονα. Ο άξονας επίσης μπορεί να έχει και άλλες εγκάρσιες διακλαδώσεις ενώ στις απολήξεις τόσο του άξονα, όσο και των διακλαδώσεων υπάρχουν περαιτέρω διακλαδώσεις. Όλες οι διακλαδώσεις καταλήγουν σε απολήξεις που είναι υπεύθυνες για την μεταβίβαση των χημικών σημάτων από τους νευρώνες [9].

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

Σε κατάσταση ηρεμίας κατά μήκος της μεμβράνης των κυττάρων διατηρείται μια διαφορά δυναμικού (πόλωση της μεμβράνης) γύρω στα - 70mV στον εσωτερικό ως προς τον εξωτερικό χώρο. Το δυναμικό αυτό προκύπτει επίσης λόγω του ότι στο εσωτερικό του κυττάρου τα αρνητικά φορτία βρίσκονται σε περίσσεια ποσότητα, ενώ στο εξωτερικό του κυττάρου επικρατεί περίσσεια θετικών ιόντων. Τα αρνητικά και τα θετικά αυτά φορτία έλκονται το ένα από το άλλο και έτσι η περίσσεια ιόντων συγκεντρώνεται σε ένα λεπτό φλοιό στην εσωτερική και εξωτερική επιφάνεια της μεμβράνης, ενώ ο κύριος όγκος του ενδοκυττάριου και ο κύριος όγκος του εξωκυττάριου υγρού παραμένουν ηλεκτρικώς ουδέτεροι [10], [11]. Αυτό το δυναμικό που διατηρεί η μεμβράνη του κυττάρου ονομάζεται δυναμικό ηρεμίας.



Εικόνα 2. 3: Κατανομή φορτίων στην μεμβράνη σε κατάσταση ηρεμίας [12]

Οι παροδικές μεταβολές στο δυναμικό της μεμβράνης προκαλούν ηλεκτρικά σήματα που μπορούν να αλλάξουν τις λειτουργίες του κυττάρου. Οι αλλαγές αυτές αποτελούν τον βασικό μηχανισμό με τον οποίο τα νευρικά κύτταρα διαχειρίζονται και μεταφέρουν πληροφορίες.

2.2 Ηλεκτροεγκεφαλογράφημα

Η ηλεκτροεγκεφαλογραφία (ΗΕΓ) είναι μια μέθοδος εξέτασης που χρησιμοποιείται για την καταγραφή της ηλεκτρικής δραστηριότητας του εγκεφάλου με μη επεμβατικό τρόπο. Βασίζεται στη μέτρηση των διακυμάνσεων δυναμικού που καταγράφονται στην επιφάνεια του κρανίου, μέσω ειδικών ηλεκτροδίων που τοποθετούνται στο τριχωτό της κεφαλής.

Αυτά τα δυναμικά είναι αποτέλεσμα της συγχρονισμένης ηλεκτρικής δραστηριότητας μεγάλου αριθμού νευρώνων – κυρίως πυραμιδικών κυττάρων του εγκεφαλικού φλοιού. Λόγω των ιοντικών ρευμάτων κατά μήκος των μεμβρανών των νευρώνων δημιουργούνται ηλεκτρικά πεδία, τα οποία τελικά προκαλούν εξωκυτταρικά δυναμικά που μπορούν και ανιχνεύονται επιφανειακά [7]. Το σήμα που καταγράφεται ονομάζεται ηλεκτροεγκεφαλογράφημα, και συνιστά το άθροισμα των ταυτόχρονων ηλεκτρικών μεταβολών από έναν πληθυσμό νευρικών κυττάρων, σε έκταση περίπου 6 cm² κάτω από κάθε ηλεκτρόδιο.

Ωστόσο, επειδή το ηλεκτρικό σήμα πρέπει να διαπεράσει διαδοχικά το δέρμα, το κρανίο και τις μήνιγγες (συνολικό πάχος περίπου 2-3 cm), εξασθενεί σημαντικά – ακόμα και δέκα φορές – μέχρι να φτάσει στα ηλεκτρόδια. Για τον λόγο αυτό, είναι αναγκαία η ενίσχυση των σημάτων και η χρήση πολλών ηλεκτροδίων για μεγαλύτερη ακρίβεια και εποπτεία [12].

Η ΗΕΓ χρησιμοποιείται ευρέως για την εκτίμηση της λειτουργίας του εγκεφάλου, ιδίως σε διαταραχές όπως η επιληψία, καθώς και σε περιπτώσεις διαταραχών συνείδησης, εγκεφαλοπαθειών ή παρακολούθησης της δραστηριότητας κατά τη διάρκεια εγχειρήσεων.

Αν και η μέθοδος παρουσιάζει περιορισμούς στον ακριβή χωρικό εντοπισμό των νευρωνικών πηγών, οι βιοηλεκτρικές αρχές στις οποίες βασίζεται είναι καλά τεκμηριωμένες, με θεμέλια στη φυσιολογία και την ηλεκτροχημεία των νευρώνων.

2.2.1 Ιστορική αναδρομή

Η ιστορία του ηλεκτροεγκεφαλογραφήματος ξεκινά στα τέλη του 19ου αιώνα, όταν ο Βρετανός επιστήμονας Richard Caton (1875) κατέγραψε για πρώτη φορά ηλεκτρική δραστηριότητα από τον εγκέφαλο ζώων χρησιμοποιώντας ένα γαλβανόμετρο, καταδεικνύοντας την ύπαρξη ηλεκτρικών μεταβολών που συνοδεύουν τη νευρική δραστηριότητα. Αργότερα, το 1924, ο Γερμανός ψυχίατρος Hans Berger κατέγραψε για πρώτη φορά επιτυχώς την αυτόματη ηλεκτρική δραστηριότητα από τον ανθρώπινο εγκέφαλο [13]. Για ηλεκτρόδια χρησιμοποίησε δύο λεπτά φύλλα αλουμινίου στο μέτωπο και στο πίσω μέρος του κεφαλιού και κατάφερε να ανιχνεύσει διαφορές δυναμικού στην επιφάνεια του κρανίου, δημιουργώντας έτσι μια πρωτογενή μορφή συστήματος ΗΕΓ. Η πρώτη του δημοσίευση το 1929 θεωρείται το επίσημο σημείο έναρξης της μελέτης των λειτουργιών του εγκεφάλου μέσω του ΗΕΓ. Ήταν επίσης ο πρώτος που αναφέρθηκε σε χαρακτηριστικά ηλεκτρικά πρότυπα, εισάγοντας τους όρους "άλφα" και "βήτα" κύματα [14].

Η αποδοχή του ΗΕΓ από τη διεθνή επιστημονική κοινότητα ενισχύθηκε με τις μελέτες των Fisher και Lowenback (1934), που συνέδεσαν χαρακτηριστικά ηλεκτρικά πρότυπα με την επιληψία, καθώς και με τη συμβολή των Gibbs, Davis και Lennox (1935), οι οποίοι περιέγραψαν τη δραστηριότητα μεταξύ των επιληπτικών κρίσεων [15]. Μετά τον Β' Παγκόσμιο Πόλεμο, η ηλεκτροεγκεφαλογραφία γνώρισε διεθνή άνθηση με την καθοριστική συμβολή ερευνητών όπως οι Α. Forbes, Η. Jasper, Μ. Gastaut και Grey Walter. Αρχικά τα σήματα που λαμβάνονταν παρουσίαζαν μεγάλη εξασθένιση λόγω της παρεμβολής του κρανίου και των μηνίγγων. Με τα χρόνια όμως, την εξέλιξη της τεχνολογίας και την ενίσχυση των σημάτων, αυξήθηκε και η ακρίβεια , και ταυτόχρονα η χρηστικότητα του ΗΕΓ. Η ΗΕΓ αποτέλεσε μια μέθοδο υψηλής σημασίας για την διάγνωση εγκεφαλοπαθειών, ψυχιατρικών διαταραχών και άλλων νευρολογικών καταστάσεων. Παρότι η εισαγωγή της αξονικής τομογραφίας τη δεκαετία του '70 περιόρισε τη χρήση του ΗΕΓ κατά 40% περίπου, σήμερα διατηρεί τη αξία του ως διαγνωστικό εργαλείο, ειδικά στην επιληψία και στη μελέτη παθολογιών που επηρεάζουν τη λειτουργία του εγκεφάλου [14].

2.2.2 Λειτουργία του ηλεκτροεγκεφαλογράφου και διαδικασία καταγραφής

Ο ηλεκτροεγκεφαλογράφος αποτελεί μία βιοϊατρική συσκευή που απαρτίζεται από ένα σύστημα εξειδικευμένων ηλεκτρονικών μονάδων, το οποίο ανιχνεύει, ενισχύει, φιλτράρει και ψηφιοποιεί την ηλεκτρική δραστηριότητα του εγκεφάλου, την οποία τελικά αποδίδει μέσω οθόνης ή καταγραφικού μέσου. Το σύστημα αυτό λειτουργεί, όπως προαναφέρθηκε, με βάση τη μέτρηση διαφορών δυναμικού που προκύπτουν από τη ροή ιόντων στους φλοιώδεις νευρώνες, όπως αυτή καταγράφεται στην επιφάνεια του κρανίου. Οι εν λόγω μετρήσεις είναι μη επεμβατικές, κάτι που καθιστά το ΗΕΓ πολύτιμο εργαλείο για διαγνωστικούς και ερευνητικούς σκοπούς, με εφαρμογές στη νευρολογία, στην ψυχιατρική, στην ανάλυση γνωστικών λειτουργιών και σε τεχνολογίες διεπαφής εγκεφάλου–υπολογιστή.

Η διαδικασία καταγραφής περιλαμβάνει την τοποθέτηση ηλεκτροδίων σε συγκεκριμένα σημεία της κεφαλής, σύμφωνα με το διεθνώς αναγνωρισμένο σύστημα τοποθέτησης "10–20", το οποίο εξασφαλίζει τη χωρική συνέπεια και επαναληψιμότητα μεταξύ των καταγραφών διαφορετικών ατόμων ή συνθηκών. Το "10" και το "20" στο όνομα του συστήματος αναφέρονται στο γεγονός ότι η απόσταση μεταξύ γειτονικών ηλεκτροδίων αντιστοιχεί είτε στο 10% είτε στο 20% της συνολικής απόστασης του κρανίου από το μπροστινό έως και το πίσω αλλά και από το δεξί έως και το αριστερό μέρος (front-back and right-left distance).

Κάθε τοποθεσία ηλεκτροδίου αντιστοιχεί σε ένα γράμμα για να αναγνωρίζεται σε ποιο λοβό βρίσκεται και έναν αριθμό για να προσδιορίσει τη θέση του στο ημισφαίριο. Τα γράμματα F, T, C, P, O αντιπροσωπεύουν τους μετωπικούς (Frontal), κροταφικούς (Temporal), κεντρικούς (Central), βρεγματικούς (Parietal) και ινιακούς (Occipital) λοβούς αντίστοιχα. Σημειώνεται ότι δεν υπάρχει κεντρικός λοβός, το γράμμα "C" χρησιμοποιείται μόνο για σκοπούς αναγνώρισης. Οι άρτιοι αριθμοί (2, 4, 6, 8) αναφέρονται σε θέσεις ηλεκτροδίων στο δεξιό ημισφαίριο, ενώ οι περιττοί αριθμοί (1, 3, 5, 7) αναφέρονται σε θέσεις του αριστερού ημισφαιρίου. Το γράμμα 'z' αναγράφεται στους αισθητήρες εκείνους που τοποθετούνται στην μεσαία γραμμή. Εκτός από αυτές τις ονομασίες, οι κωδικοί των χαρακτήρων A, Pg και Fp αναφέρονται στους λοβούς του αυτιού, στις ρινοφαρυγγικές και στις εμπρόσθιες πολικές περιοχές αντίστοιχα [16].

Ακολουθεί η αντιστοίχιση των 61 ηλεκτροδίων ΗΕΓ (που εφαρμόστηκαν στο σύνολο δεδομένων που χρησιμοποιήθηκε στο πειραματικό κομμάτι), χρησιμοποιώντας το σύστημα "10-20", με τις αντίστοιχες εγκεφαλικές περιοχές, βασισμένη σε ανατομικά δεδομένα και τη λογική τοποθέτησης:

Εμπρόσθιος Λοβός (Frontal Lobe)

- Fp1, Fp2, Fpz: Προμετωπιαία περιοχή (Prefrontal Cortex)
- AF3, AF4, AF7, AF8: Μέση/Πλάγια μετωπιαία περιοχή (Anterior Frontal)
- F1, F2, Fz: Δορσομετωπιαίος φλοιός (Dorsolateral Prefrontal Cortex)
- F3, F4: Αριστερή/δεξιά πλάγια μετωπιαία περιοχή
- F5, F6, F7, F8: Κάτω πλάγιος μετωπιαίος φλοιός (Inferior Frontal Gyrus)
- FC1, FC2, FCz: Προκινητική περιοχή (Premotor Cortex)
- FC3, FC4, FC5, FC6: Πλάγια προκινητική περιοχή
- FT7, FT8: Κάτω μετωπιαία-κροταφική περιοχή (Near Broca's area ανά πλευρά)

Κεντρική Περιοχή (Central)

- C1, C2, Cz: Κύρια κινητική/αισθητηριακή περιοχή (Primary Motor/Sensory Cortex)
- C3, C4: Αριστερή/δεξιά κινητική-αισθητηριακή περιοχή (πάνω από κεντρική αύλακα)
- C5, C6: Πλάγια επέκταση της αισθητηριακής περιοχής

Κροταφική Περιοχή (Temporal)

• T7, T8: Κροταφικός φλοιός (Auditory Cortex, Superior Temporal Gyrus)

Βρεγματικός Λοβός (Parietal Lobe)

- CP1, CP2, CPz: Οπίσθια αισθητηριακή περιοχή (Postcentral Gyrus)
- CP3, CP4, CP5, CP6: Πλάγια βρεγματική περιοχή
- TP7, TP8, TP9, TP10: Κάτω βρεγματική-κροταφική περιοχή (Near Wernicke's area)
- P1, P2, Pz: Ανώτερος βρεγματικός φλοιός (Superior Parietal Lobule)
- P3, P4, P5, P6, P7, P8: Πλάγιος/κάτω βρεγματικός φλοιός (Inferior Parietal Lobule)

Ινιακός Λοβός (Occipital Lobe)

• Oz, O1, O2: Κύρια οπτική περιοχή (Primary Visual Cortex, Calcarine Sulcus)

Ινιακο-βρεγματική Περιοχή (Parieto-Occipital)

• PO3, PO4, PO7, PO8, POz: Οπτικός συνειρμικός φλοιός (Visual Association Cortex)



Εικόνα 2. 4: Τοποθέτηση ηλεκτροδίων με το διεθνές σύστημα "10-20" [17]

Τα ηλεκτρόδια, τα οποία κατασκευάζονται συνήθως από άργυρο/χλωριούχο άργυρο (Ag/AgCl), έρχονται σε επαφή με το δέρμα μέσω αγώγιμου gel, με στόχο τη μείωση της αντίστασης επαφής κάτω των 5 kΩ και την εξασφάλιση σταθερής μετάδοσης των βιοηλεκτρικών σημάτων. Το παραγόμενο δυναμικό στη διεπιφάνεια δέρματος-ηλεκτροδίου είναι ευαίσθητο στις μεταβολές των ιοντικών συγκεντρώσεων που προκύπτουν από εγκεφαλική δραστηριότητα [16].

Στην επεξεργασία των εγκεφαλικών σημάτων, αρχικά το σήμα ενισχύεται μέσω διαφορικών ενισχυτών υψηλής απόδοσης. Αυτοί οι ενισχυτές διακρίνονται για την ικανότητά τους να καταστέλλουν το κοινό σήμα (με λόγο απόρριψης πάνω από 100 dB), ενώ ταυτόχρονα διαθέτουν υψηλή αντίσταση εισόδου, γεγονός που ενισχύει την ποιότητα της καταγραφής. Η ενίσχυση που επιτυγχάνεται μπορεί να φτάσει ακόμα και τις 100.000 φορές, ανάλογα με τις ανάγκες.

Μετά την ενίσχυση του σήματος, εφαρμόζονται φίλτρα για να εξαλειφθούν συχνότητες που δεν ενδιαφέρουν ή προκαλούν θόρυβο. Συνήθως χρησιμοποιούνται υψιπερατά φίλτρα για την απομάκρυνση χαμηλόσυχνων παρεμβολών, όπως αυτών που σχετίζονται με την αγωγιμότητα του δέρματος, και βαθυπερατά για την αποκοπή υψηλόσυχνων ενοχλήσεων, όπως είναι τα σήματα από μυϊκές κινήσεις.

Αφού καθαριστεί το σήμα, μετατρέπεται σε ψηφιακή μορφή μέσω ειδικών μετατροπέων (A/D converters), ώστε να μπορεί να αναλυθεί από υπολογιστικά συστήματα [14]. Στην οθόνη εμφανίζονται οι κυματομορφές του σήματος, η καθεμία αντιστοιχεί σε συγκεκριμένο ηλεκτρόδιο ή ομάδα ηλεκτροδίων, επιτρέποντας την παρακολούθηση της εγκεφαλικής δραστηριότητας σε πραγματικό χρόνο.

Ο υπεύθυνος του συστήματος μπορεί να ελέγχει την ποιότητα του σήματος και να επεμβαίνει εφόσον εντοπίσει προβλήματα, όπως κακή σύνδεση των ηλεκτροδίων ή παρεμβολές λόγω

κίνησης. Ένας σημαντικός δείκτης αξιοπιστίας είναι η εμπέδηση σε κάθε κανάλι· εάν είναι υψηλή, τότε πιθανόν να υπάρχει πρόβλημα στην καταγραφή.

Υπάρχουν πολλές περιπτώσεις κατά τις οποίες το ΗΕΓ ακολουθείται από ερεθίσματα ή πρωτόκολλα δοκιμών, όπως φωτοδιέγερση ή υπεραερισμός, που αποσκοπούν στην ενεργοποίηση συγκεκριμένων λειτουργιών του εγκεφάλου και στην ενίσχυση συγκεκριμένων ζωνών συχνότητας. Για παράδειγμα, αυτό συμβαίνει σε εφαρμογές νευροανάδρασης και εγκεφαλικών διεπαφών (BCI), όπου πραγματοποιείται η καταγραφή σε ζωντανό χρόνο και τα σήματα χρησιμοποιούνται είτε για να παράγουν εντολές είτε για να εξετάσουν μια νοητική κατάσταση, όπως η προσοχή, η συγκέντρωση ή η κόπωση [18]. Σε ερευνητικά πρωτόκολλα, είναι πιθανή και η χρήση κινητών συσκευών για την καταγραφή του ΗΕΓ, με ασύρματη μετάδοση, οι οποίες αποδεικνύονται ιδιαίτερα χρήσιμες σε εφαρμογές πραγματικού χρόνου ή σε φυσικά περιβάλλοντα.

Γενικά, βασική προϋπόθεση για μια επιτυχημένη και έγκυρη καταγραφή ΗΕΓ, είναι η τήρηση αυστηρών τεχνικών προδιαγραφών, καθώς και η σωστή προετοιμασία του ατόμου πριν την υποβολή του στην καταγραφή, η οποία περιλαμβάνει την αποφυγή ουσιών που μπορεί να επηρεάσουν την νευρική του δραστηριότητα.



Εικόνα 2. 5: Διαδικασία ψηφιοποίησης Ηλεκτροεγκεφαλογραφήματος [19]

2.2.3 Ζώνες συχνοτήτων

Τα σήματα που καταγράφονται από το ηλεκτροεγκεφαλογράφημα μπορούν να αναλυθούν ως προς τη συχνότητα τους και χωρίζονται με βάση αυτή, σε πέντε βασικές ζώνες – ρυθμούς:

- 1. Δέλτα (δ)
- Θήτα (θ)
- Άλφα (α)
- Βήτα (β)
- Γάμμα (γ)



Εικόνα 2. 6: Κυματομορφές των πέντε ρυθμών [20]

Δέλτα ρυθμός

Ο ρυθμός δέλτα περιλαμβάνει χαμηλές συχνότητες που κυμαίνονται στο εύρος 0-4 Hz και μεγάλο πλάτος, μεγέθους 100-200μV. Σχετίζεται με την αναισθησία αλλά και με τα στάδια III και IV του βαθύ ύπνου (μη ονειρικός ύπνος) σε ενήλικες. Έχει δειχθεί ότι η παρουσία του ρυθμού δέλτα σε καταστάσεις εγρήγορσης σχετίζεται πιθανά με παθολογίες ή νευρολογικές

βλάβες. Επιπλέον, έχει παρατηρηθεί πως η τοποθεσία των νευρώνων που εμφανίζουν αυτές τις συχνότητες, βρίσκεται στον θάλαμο και στον εγκεφαλικό φλοιό στην περιοχή του εγκεφάλου [21].

Θήτα ρυθμός

Αποτελείται από συχνότητες που κυμαίνονται στη ζώνη 4-8 Hz ενώ το πλάτος κυμαίνεται στην περιοχή 50-100 μV. Έρευνες έχουν δείξει πως οι νευρώνες των οποίων η συντονισμένη δραστηριότητα οδηγεί στην εμφάνιση αυτών των κυμάτων μπορούν, για την ώρα, να εντοπιστούν σε δυο ανατομικές περιοχές τού εγκεφάλου: στον θάλαμο και στον εγκεφαλικό φλοιό[22], [23]. Εμφανίζεται κατά τη διάρκεια ελαφρού ύπνου ή κατάστασης ονειροπόλησης (Ι στάδιο ύπνου) και θεωρείται σημαντική για την επεξεργασία μνήμης και την ενδοσκόπηση. Ταυτόχρονα, εμφανίζεται έντονα σε γνωσιακές δραστηριότητες που σχετίζονται με την προσήλωση, τη σιωπηρή νοητική δραστηριότητα, την αισθητικοκινητική ενοποίηση, την πλοήγηση στον χώρο, αλλά και τη μνήμη.

Άλφα ρυθμός

Οι συχνότητες που τον αποτελούν βρίσκονται στη ζώνη 8-13 Hz, ενώ το πλάτος τού ρυθμού άλφα βρίσκεται συνήθως στην περιοχή των 10-50 μV. Ο ρυθμός άλφα παρατηρείται κυρίως στις ινιακές περιοχές όταν το άτομο επιδεικνύει μειωμένη οπτική προσήλωση και στον σωματοκινητικό φλοιό, όταν υπάρχει μυϊκή χαλάρωση. Θεωρείται δείκτης χαλάρωσης και εσωτερικής συγκέντρωσης, ενώ η καταστολή του συνδέεται με δραστηριότητες που σχετίζονται με την προσοχή και τον οπτικό προσανατολισμό στον χώρο [21].

Βήτα ρυθμός

Ο ρυθμός βήτα αφορά συχνότητες που ανήκουν στη ζώνη 15-30 Hz. Το πλάτος αυτού του ρυθμού είναι χαμηλό, και συνήθως κυμαίνεται γύρω από την τιμή των 30 μV. Σχετίζεται με καταστάσεις διέγερσης, αυξημένης γνωστικής δραστηριότητας, προσοχής και συγκέντρωσης. Εμφανίζεται κυρίως στις μετωπιαίες περιοχές κατά τη διάρκεια έντονης νοητικής εργασίας ή άγχους. Οι έρευνες γύρω από τον ρυθμό βήτα οδήγησαν στην υπόθεση πως η εμφάνισή του στον εγκεφαλικό φλοιό ίσως συντονίζει απομακρυσμένα νευρωνικά δίκτυα, προετοιμάζοντάς τα για συνεργασία στην επεξεργασία κάποιας πληροφορίας. Οι ανατομικές πηγές προέλευσης αυτού του ρυθμού εντοπίζονται στις πολύπλοκες, δικτυακές συναπτικές συσχετίσεις των νευρώνων σε διάφορα στρώματα και περιοχές τού εγκεφαλικού φλοιού [24].

Γάμμα ρυθμός

Τις υψηλότερες συχνότητες ταλάντωσης από τους πέντε ρυθμούς παρουσιάζει ο ρυθμός γάμμα: εντοπίζονται στη ζώνη 30-70 Hz συνηθέστερα γύρω από την τιμή των 40Hz, και παρουσιάζει το μικρότερο πλάτος τάσης από τους πέντε ρυθμούς. Όπως και ο ρυθμός βήτα, συνδέεται με διαδικασίες ανώτερης γνωστικής ολοκλήρωσης, όπως η επίλυση προβλημάτων και η ενοποίηση αισθητηριακής πληροφορίας. Επιπλέον συνδέεται και με τον συγκερασμό πληροφοριών από διαφορετικά σημεία τού φλοιού, με στόχο την ενοποίησή τους και την προετοιμασία για απόκριση. Έντονη δραστηριότητα ρυθμού γάμμα έχει, μάλιστα, καταγραφεί στον οπτικό φλοιό και το οσφρητικό σύστημα θηλαστικών, αλλά και στον κινητικό φλοιό ανθρώπων, αμέσως πριν την εκτέλεση κίνησης των δαχτύλων. Η γρήγορη ταλαντωτική φύση αυτού του ρυθμού φαίνεται να οδηγεί σε συγχρονισμό των νευρωνικών δικτύων, κάνοντας δυνατή την ταχεία δρομολόγηση και επεξεργασία τής πληροφορίας στον εγκέφαλο. Ανατομικά, ο ρυθμός γάμμα, όπως και ο βήτα, πηγάζει από τις πολύπλοκες συναπτικές σχέσεις των νευρώνων τού εγκεφαλικού φλοιού. Έρευνες έχουν δείξει πως ο ρυθμός γάμμα πηγάζει από τα ανώτερα στρώματα τού φλοιού, ενώ ο βήτα από τα βαθύτερα [21].

Ρυθμός	Συχνότητα(Hz)	Πλάτος (μV)	Κατάσταση	Περιοχές	Σημασία
Δέλτα	0.5–4	100–200	Βαθύς ύπνος, αναισθησία	Θάλαμος, φλοιός	Αργή δραστηριότητα, παθολογική σε εγρήγορση
Θήτα	4-8	50–100	Υπνηλία, γνωσιακές διεργασίες	Ιππόκαμπος, φλοιός	Προσοχή, μνήμη, πλοήγηση
Άλφα	8–13	10–50	Ξύπνιος, μάτια κλειστά	Ινιακός λοβός	Αναμονή, χαλάρωση, οπτική απουσία
Βήτα	13–30	~30	Εγρήγορση, σκέψη	Εμπρόσθιες περιοχές	Συγκέντρωση, αισθητικοκινητικές λειτουργίες
Γάμμα	30–70 (ως 100)	<10	Εστίαση, επεζεργασία	Φλοιός (ανώτερα στρώματα)	Ανώτερες λειτουργίες, συνείδηση

Πίνακας 2. 1: Περιληπτική ανάλυση των ρυθμών

2.2.4 Καταγραφή ΗΕΓ σε κατάσταση ηρεμίας με ανοιχτά και με κλειστά μάτια

Η κατάσταση ηρεμίας του εγκεφάλου ορίζεται ως μια κατάσταση στην οποία το άτομο βρίσκεται σε εγρήγορση, χωρίς όμως να εκτελεί κάποια δραστηριότητα. Μέσα από έρευνες των τελευταίων χρόνων σχετικά με την διεξαγωγή του ΗΕΓ σε κατάσταση ηρεμίας, παρατηρείται ένα μοτίβο ρυθμικής δραστηριότητας, ενώ σε πιο ειδικές καταστάσεις ηρεμίας εμφανίζονται επιπλέον διαφορές στα μοτίβα αυτά. Η κατάσταση ηρεμίας με ανοιχτά μάτια (resting state – eyes open, REO) και η κατάσταση ηρεμίας με κλειστά μάτια (resting state – eyes open, REO) και η κατάσταση ηρεμίας με κλειστά μάτια (resting state – eyes open, REO) και η κατάσταση ηρεμίας με κλειστά μάτια (resting state – eyes closed, REC) ανήκουν στις ειδικότερες περιπτώσεις [25].

Η μετάβαση από την μια κατάσταση στην άλλη παρουσιάζει εμφανείς αλλαγές στα επίπεδα της παρατηρούμενης ηλεκτρικής δραστηριότητας στο ΗΕΓ. Αυτό αντικατοπτρίζει μια αναδιοργάνωση της εγκεφαλικής δραστηριότητας ως αντίδραση στα οπτικά ερεθίσματα, χωρίς, βέβαια, αυτές να περιορίζονται στις περιοχές τού οπτικού φλοιού. Συγκεκριμένα, η κατάσταση στην οποία το άτομο έχει ανοιχτά μάτια αφορά κυρίως την εξωτερική αντίληψη, ενώ όταν έχει κλειστά μάτια, την εσωτερική αντίληψη.

Οι προαναφερθείσες αλλαγές αποτυπώνονται στο ηλεκτροεγκεφαλογράφημα (ΗΕΓ) ως διαφοροποιήσεις στη συνεκτικότητα και στην ισχύ των εγκεφαλικών ρυθμών. Αυτές οι μεταβολές εντοπίζονται σε ολόκληρη την έκταση του εγκεφαλικού φλοιού και αφορούν όλους τους ρυθμούς που προαναφέρθηκαν [26].

Η πιο έντονη και φανερή μεταβολή ισχύος εμφανίζεται στον άλφα ρυθμό, ενώ και στους υπόλοιπους 4 ρυθμούς παρατηρούνται σημαντικές διαφορές, ιδίως όσον αφορά την κατανομή τους τοπογραφικά. Πιο συγκεκριμένη, υποθέτοντας φυσιολογικές συνθήκες φωτισμού, η μετάβαση από την κατάσταση REC στην κατάσταση REO, σημειώνει μείωση στην ισχύ όλων των ρυθμών, με τον άλφα να παρουσιάζει τη μεγαλύτερη πτώση και τον δέλτα να ακολουθεί.

Αυτή η μείωση δεν είναι ομοιόμορφη, αλλά προκύπτει από τοπικές αυξήσεις ή μειώσεις της ισχύος σε διαφορετικές περιοχές του εγκεφάλου.

Εντοπίζονται χαρακτηριστικές τοπογραφικές διαφορές στην ισχύ των εγκεφαλικών ρυθμών κατά τη μετάβαση στην κατάσταση REO. Ο δέλτα και ο θήτα ρυθμός μειώνονται κυρίως σε μετωπιαίες και οπίσθιες περιοχές αντίστοιχα, ενώ ο βήτα και ο γάμμα παρουσιάζουν μείωση στο πίσω μέρος του εγκεφάλου, με παράλληλες αυξήσεις στο μέτωπο. Αντίθετα, ο άλφα ρυθμός εμφανίζει εκτεταμένη και σημαντική μείωση, περίπου 40%, σε όλο τον φλοιό.

Έχει παρατηρηθεί πως στην κατάσταση REO παρουσιάζεται χαμηλότερη συνεκτικότητα, κυρίως σε περιοχές με μειωμένη ισχύ. Παρόμοια, υπό συνθήκες συσκότισης, εμφανίζονται αντίστοιχες αλλαγές, κυρίως με πτώσεις στην ισχύ και την συνεκτικότητα συγκεκριμένων ρυθμών (α, β, γ). Ωστόσο, σε αυτές τις συνθήκες εντοπίζεται αύξηση στην ισχύ των β και γ ρυθμών, ενώ ο θήτα και ο α δεν παρουσιάζουν σημαντικές αλλαγές [25], [27].

Οι μεταβολές που εμφανίζονται μεταξύ των δύο καταστάσεων, ιδιαίτερα η ενεργοποίηση συγκεκριμένων περιοχών που αφορούν την οπτική επεξεργασία στην κατάσταση REO, αποδεικνύουν ότι η κατάσταση REC συνδέεται με εσωτερικά ερεθίσματα, ενώ η REO με εξωτερικά αισθητηριακά.

2.2.5 Παρεμβολές στο ΗΕΓ σε κατάσταση ηρεμίας

Κατά τη διάρκεια την καταγραφής ενός ΗΕΓ είναι πολύ συχνή η εμφάνιση παρεμβολών, μη προερχόμενων από τον ίδιο τον εγκέφαλο. Αυτές οι παρεμβολές, γνωστές και ως τεχνήματα, είναι αναπόφευκτες και συχνά αλλοιώνουν σοβαρά το ηλεκτρικό σήμα που παράγεται από τον εγκεφαλικό φλοιό. Αυτό έχει ως αποτέλεσμα, την αναγκαία επεξεργασία του σήματος, ώστε να παραχθεί και η ορθή του ερμηνεία.

Οι πηγές των τεχνημάτων διακρίνονται σε δύο βασικές κατηγορίες: τις φυσιολογικές, που συνδέονται με τις βιολογικές και βιοηλεκτρικές λειτουργίες του εξεταζόμενου, και τις μη φυσιολογικές, που δεν έχουν βιολογική προέλευση.

Στις φυσιολογικές παρεμβολές περιλαμβάνονται ηλεκτρικά σήματα από τις κινήσεις των ματιών, τις μυϊκές συσπάσεις στο πρόσωπο και την κεφαλή, τη δραστηριότητα της καρδιάς, την κίνηση της γλώσσας, την αναπνοή και την εφίδρωση. Επίσης, η κίνηση του σώματος, ιδίως αν είναι ρυθμική, μπορεί να αλλοιώσει το σήμα του ΗΕΓ [28].

Οι μη φυσιολογικές παρεμβολές περιλαμβάνουν, μεταξύ άλλων, την ασταθή επαφή ή μετακίνηση των ηλεκτροδίων, βλάβες ή δυσλειτουργίες στον εξοπλισμό καταγραφής, παρεμβολές από ηλεκτρικό ρεύμα, ηλεκτροστατικές φορτίσεις στα καλώδια, καθώς και επιδράσεις από ηλεκτρομαγνητικά κύματα υψηλής συχνότητας ή τάσης, όπως αυτά που εκπέμπουν κινητά τηλέφωνα, τηλεοράσεις, οθόνες υπολογιστών ή άλλες ηλεκτρονικές συσκευές με κινητήρες.

Παρά τις παραπάνω δυσκολίες, μεγάλο μέρος των επιπτώσεων των τεχνημάτων μπορεί να περιοριστεί ή και να εξαλειφθεί με τη χρήση κατάλληλων μεθόδων επεξεργασίας και ανάλυσης των ΗΕΓ δεδομένων.

2.3 Λειτουργική συνδεσιμότητα του εγκεφάλου

Ο όρος λειτουργική συνδεσιμότητα – $\Lambda\Sigma$ (Functional Connectivity – FC) αναφέρεται στον στατιστικό συσχετισμό ή συγχρονισμό της λειτουργικής δραστηριότητας μεταξύ διαφορετικών περιοχών του εγκεφάλου. Λειτουργεί ως ένα εργαλείο που αποτυπώνει την επικοινωνία και την κοινή ενεργοποίηση απομακρυσμένων νευρωνικών δομών, όταν βρίσκεται το άτομο εν μέσω μιας γνωστικής κατάστασης ή εργασίας. Αντίθετα με τη δομική συνδεσιμότητα, η οποία βασίζεται σε φυσικές, ανατομικές συνδέσεις, η λειτουργική

συνδεσιμότητα είναι δυναμική και εξαρτάται από τη χρονική συσχέτιση της δραστηριότητας μεταξύ των περιοχών.

2.3.1 Τεχνικές υπολογισμού λειτουργικής συνδεσιμότητας από ΗΕΓ

Η αποτίμηση της λειτουργικής συνδεσιμότητας μπορεί να πραγματοποιηθεί μέσω διαφόρων νευροαπεικονιστικών τεχνικών, όπως η Λειτουργική Μαγνητική Τομογραφία, η Μαγνητοεγκεφαλογραφία και το Ηλεκτροεγκεφαλογράφημα.

Χρησιμοποιώντας την τεχνική του ΗΕΓ, η ΛΣ υπολογίζεται κυρίως μέσω συνάρτησης συγχρονισμού μεταξύ των σημάτων που καταγράφονται από διαφορετικά ηλεκτρόδια. Όσο πιο μεγάλος είναι ο συσχετισμός, τόσο πιο υψηλή η επικοινωνία και η κοινή ενεργοποίηση μεταξύ των καταγεγραμμένων περιοχών.

Υπολογιστικές Τεχνικές

Οι πιο συνήθεις μετρικές που χρησιμοποιούνται για την αποτίμηση της ΛΣ:

- Συντελεστής συσχέτισης (Pearson correlation)
- Συνεκτικότητα (Coherence)
- Αλληλοεντροπία (Mutual Information)
- Δείκτες βασισμένοι στη φάση όπως:
 - Phase Locking Value (PLV)
 - Phase Lag Index (PLI)
 - Weighted Phase Lag Index (wPLI)

Σε αυτή την εργασία χρησιμοποιείται ο Phase Lag Index (PLI) ως βασική μετρική ΛΣ.

Οι πιο κοινές τεχνικές αφορούν υπολογισμούς μεταξύ ζευγών ηλεκτροδίων, όπως οι δείκτες συσχέτισης, συνοχής και συγχρονισμού φάσης. Η συσχέτιση ήταν μία από τις πρώτες τεχνικές που εφαρμόστηκαν, χρησιμοποιούμενη για την ανίχνευση ομοιότητας μεταξύ σημάτων ΗΕΓ [29], βασισμένη στην υπόθεση ότι η ισχυρότερη συσχέτιση υποδηλώνει πιο στενή λειτουργική σύνδεση. Αυτή η προσέγγιση υιοθετήθηκε ευρέως σε τομείς όπως η επεξεργασία των αισθητήριων, οι διαταραχές ύπνου και η ψυχοπαθολογία [30].

Από την άλλην πλευρά, ο δείκτης της συνοχής επεκτείνει την έννοια της συσχέτισης στην περιοχή της συχνότητας, υπολογίζοντας τη στατιστική σχέση δύο σημάτων ως προς τη συνδιακύμανσή τους στο φάσμα. Η χρήση της είναι ευρέως γνωστή στην έρευνα για τη φυσιολογία [31], σε μελέτες νευρολογικών διαταραχών [32], καθώς και στην ανάλυση της εγκεφαλικής δραστηριότητας κατά τη σωματική άσκηση [33].

Όσον αφορά την ανάλυση συγχρονισμού φάσης, αποτελεί ένα πιο εξειδικευμένο μέτρο, καθώς κοιτάει δύο σήματα ΗΕΓ και υπολογίζει κατά πόσο είναι σταθερή η φασική τους διαφορά. Εάν η διαφορά φάσης είναι πράγματι σταθερή, τότε είναι πιθανή και η λειτουργική σύνδεση των αντίστοιχων περιοχών του εγκεφάλου. Αυτές οι μέθοδοι βρίσκουν εφαρμογή σε μελέτες που αφορούν νευρολογικά νοσήματα, λόγω της ικανότητας τους να εντοπίζουν ανωμαλίες στη συνδεσιμότητα που δεν θα ήταν εμφανείς χρησιμοποιώντας άλλες τεχνικές [34].

2.3.2 Δίκτυα PLI και ανάλυση μετρικών

Το PLI είναι μια πολύ δημοφιλής μετρική που χρησιμοποιείται για την εκτίμηση της λειτουργικής συνδεσιμότητας στα σήματα ΗΕΓ. Πρακτικά, η λειτουργία του είναι να μετρά τον βαθμό ασυμμετρίας στην κατανομή της διαφοράς φάσης δύο σημάτων σε πραγματικό χρόνο. Όταν ο δείκτης PLI είναι υψηλός αυτό σημαίνει ότι η διαφορά φάσης είναι σταθερή και μη μηδενική, και ο συγχρονισμός μεταξύ των αντίστοιχων περιοχών του εγκεφάλου είναι αξιόπιστος. Αυτό που κάνει τον δείκτη PLI να πλεονεκτεί συγκριτικά με τους υπόλοιπους είναι ότι δεν επηρεάζεται από ψευδείς συσχετισμούς, όπως είναι μια κοινή πηγή ή το φαινόμενο του όγκου αγωγής. Αυτή του η ιδιότητα είναι που τον καθιστά και βασικό εργαλείο στην μελέτη μεγάλων εγκεφαλικών δικτύων (π.χ. resting state networks) και των μεταβολών τους λόγω παθολογίας ή γνωστικού φορτίου [35].

Μαθηματική περιγραφή

Έστω δύο χρονοσειρές ΗΕΓ, x(t) και y(t), με στιγμιαίες φάσεις $\phi_x(t)$ και $\phi_y(t)$, όπως προκύπτουν μέσω Hilbert Transform ή Wavelet Transform.

Η διαφορά φάσης ορίζεται ως:

$$\Delta \varphi(t) = \varphi_x(t) - \varphi_v(t)$$

Ο PLI ορίζεται ως:

 $PLI = |\langle sign[sin (\Delta \varphi(t))] \rangle|$

Όπου:

- Sign, δίνει το πρόσημο της διαφοράς φάσης
- Τ: αριθμός χρονικών στιγμών
- Οι στιγμιαίες φάσεις εξάγονται μέσω Hilbert Transform

Η τιμή του PLI κυμαίνεται μεταξύ 0 και 1:

- \square PLI = 0: Τέλεια συμμετρική κατανομή των διαφόρων φάσης (καμία σταθερή καθυστέρηση \rightarrow μη συνδεδεμένα σήματα)
- PLI = 1: Απόλυτα σταθερή φορά στη χρονική καθυστέρηση (ισχυρή συνδεσιμότητα)

To PLI έχει άλλο ένα πολύ χρήσιμο χαρακτηριστικό, το οποίο είναι ότι δεν διευκρινίζει την ποια περιοχή του εγκεφάλου επηρεάζεται από ποια. Αντιθέτως, προσδιορίζει την ύπαρξη μιας σταθερής χρονικής καθυστέρησης, το οποίο είναι αρκετό για την αναγνώριση λειτουργικών δικτύων. Με αυτόν τον τρόπο το μέτρο που υπολογίζεται δεν είναι κατευθυνόμενο, αλλά δεν είναι και μηδενικό όσον αφορά την λειτουργική συνδεσιμότητα.

Επιπλέον, ο δείκτης PLI έχει τη δυνατότητα να εφαρμοστεί στις διάφορες ζώνες συχνοτήτων, παρέχοντας έτσι ένα μεγάλο εύρος πληροφοριών για την συνδεσιμότητα περιοχών σε διαφορετικά χρονικά πλαίσια [36].

Συμπερασματικά, ο υπολογισμός της λειτουργικής συνδεσιμότητας με την χρήση του PLI, έχει ως αποτέλεσμα την μετατροπή του σε έναν μη κατευθυνόμενο, σταθμισμένο ή δυαδικό γράφο, όπου οι κόμβοι αντιστοιχούν στις περιοχές του εγκεφάλου και οι ακμές αντικατοπτρίζουν την συνδεσιμότητα μεταξύ των περιοχών, μέσω της διαφοράς φάσεως που αποτιμάται. Αυτό το γράφημα αποτελεί τη βάση για τοπολογική ανάλυση του εγκεφάλου ως λειτουργικού δικτύου [37].

Η γραφική αναπαράσταση του πίνακα PLI επιτρέπει την εφαρμογή εργαλείων από τη θεωρία γράφων, προκειμένου να μελετηθεί η οργανωτική δομή του εγκεφαλικού δικτύου. Οι παρακάτω μετρικές περιγράφουν σημαντικά χαρακτηριστικά του δικτύου και προσφέρουν βαθύτερη κατανόηση της εγκεφαλικής λειτουργίας:

Συντελεστής Συγκέντρωσης – Clustering Coefficient (CC)

Ο συντελεστής συγκέντρωσης είναι ένας δείκτης που μετράει τον βαθμό συνδεσιμότητας μεταξύ των γειτόνων που βρίσκονται γύρω από έναν κόμβο στο δίκτυο. Όσο πιο πολλοί γείτονες είναι συνδεδεμένοι, τόσο πιο υψηλό το μέτρο CC. Αυτό υποδεικνύει ότι σχηματίζονται λειτουργικά εξειδικευμένες τοπικές ομάδες, σχετιζόμενες με συγκεκριμένες

νοητικές ή νευρωνικές λειτουργίες. Συγκεκριμένα όσον αφορά τα εγκεφαλικά δίκτυα από ΗΕΓ, εάν ο δείκτης CC είναι υψηλός σημαίνει αυξημένη τοπική επεξεργασία πληροφορίας ή αυξημένο συγχρονισμό [38].

Χαρακτηριστικό Μήκος Διαδρομής – Characteristic Path Length (L)

Το χαρακτηριστικό μήκος διαδρομής αναφέρεται στην μέση απόσταση μεταξύ όλων των ζευγαριών-κόμβων στο δίκτυο, μετράει δηλαδή σε πόσα βήματα μεταφέρεται μια πληροφορία από τον έναν κόμβο στο ζευγάρι του. Ανάλογα με το μέτρο αυτής της απόστασης, φαίνεται και πόσο αποδοτική είναι η διαδικασία διάδοσης πληροφοριών στο εγκεφαλικό δίκτυο. Αυτός ο δείκτης αποτελεί βασικό μέτρο της συνολικής επικοινωνίας του εγκεφάλου [38].

Ιδιότητα Μικρόκοσμου – Small-Worldness (SW)

Η ιδιότητα του μικρόκοσμου συνδυάζει δύο χαρακτηριστικά: υψηλό CC, δηλαδή ισχυρή τοπική οργάνωση και μικρό L, που σημαίνει μικρές αποστάσεις επικοινωνίας. Ο εγκέφαλος αποτελεί ένα βασικό παράδειγμα δικτύου με ιδιότητα μικρόκοσμου, καθώς έχει αυτά τα χαρακτηριστικά σε μεγάλο βαθμό. Για τον υπολογισμό του δείκτη SW συγκρίνονται τα μέτρα CC και L με αυτά από τυχαία δίκτυα ίδιου μεγέθους. Σε πολλές νευρολογικές διαταραχές έχει παρατηρηθεί ανισορροπία στη λειτουργική συνδεσιμότητα, το οποίο αντικατοπτρίζεται στις μεταβολές της τιμής του SW [39].

Παγκόσμια Αποδοτικότητα – Global Efficiency (Eff global)

Η παγκόσμια αποδοτικότητα είναι ένας δείκτης της ολικής ικανότητας του εγκεφάλου να μεταφέρει εύκολα και αποτελεσματικά πληροφορίες σε διαφορετικά σημεία του εγκεφάλου. Υπολογίζεται ως το μέσο όρο του αντιστρόφου της μικρότερης των διαδρομών μεταξύ κάθε ζεύγους κόμβων. Όσο πιο υψηλή υπολογίζεται η αποδοτικότητα αυτή, τόσο πιο αποδοτική είναι η κυκλοφορία της πληροφορίας σε μακρινές περιοχές του εγκεφάλου, σε "παγκόσμιο" δηλαδή επίπεδο. Από την άλλη, χαμηλή τιμή μπορεί να συσχετίζεται με γνωστική δυσλειτουργία ή με παθολογική κατάσταση [38].

Τοπική Αποδοτικότητα – Local Efficiency (Eff local)

Αντίθετα με την παγκόσμια, η τοπική αποδοτικότητα αφορά την αξιολόγηση της επικοινωνίας σε τοπικό επίπεδο, ανάμεσα σε γείτονες. Ο υπολογισμός της γίνεται μεταξύ των γειτόνων ενός κόμβου όταν ο ίδιος αφαιρεθεί από το δίκτυο. Κατά την αφαίρεση του κόμβου εάν οι γείτονες παρουσιάζουν καλή σύνδεση, τότε το δίκτυο είναι ανθεκτικό σε τοπικές βλάβες. Στα δίκτυα ΗΕΓ, η τοπική αποδοτικότητα συνδέεται με την ευελιξία και εφεδρεία στην λειτουργία συγκεκριμένων περιοχών του εγκεφάλου [38].

Κεντρικότητα Διαμεσολάβησης – Betweeness Centrality (BC)

Η κεντρικότητα διαμεσολάβησης αποτελεί ένα μέτρο που δείχνει την σημασία ενός κόμβου κατά τη διαδικασία μεταβίβασης πληροφορίας. Αυτό που υπολογίζει είναι πόσες από τις συντομότερες διαδρομές μεταξύ άλλων κόμβων περνούν από αυτόν. Με αυτό το μέτρο αντικατοπτρίζεται η στρατηγική αξία του κόμβου καθώς φαίνεται πόσο βοηθάει στην επικοινωνία διαφόρων μερών του εγκεφάλου. Έχει παρατηρηθεί πως η μείωση της κεντρικής διαμεσολάβησης συσχετίζεται με νευροεκφυλιστικές παθήσεις [40].

Ανάλυση σε πολλαπλά επίπεδα πυκνότητας – GS_all και Sparsity Thresholding

Ο δείκτης GS_all αφορά την ανάλυση τοπολογικών μετρικών ενός γράφου σε διάφορα επίπεδα "πυκνότητας", με διαφορετικά κατώφλια για την δημιουργία συνδέσεων στο γράφημα. Με αυτόν τον τρόπο διερευνάται η σταθερότητα των ιδιοτήτων του εγκεφάλου σε

πολλαπλά επίπεδα συνδεσιμότητας. Αυτού του είδους η προσέγγιση είναι απαραίτητη καθώς η λειτουργική αρχιτεκτονική του εγκεφάλου είναι πολυεπίπεδη και όχι μονοδιάστατη.

Όλες οι παραπάνω μετρικές είναι εξαρτώμενες του PLI, το οποίο εξασφαλίζει ότι οι ακμές που περιλαμβάνονται στο γράφημα αντανακλούν πραγματικούς λειτουργικούς συγχρονισμούς, απαλλαγμένους από τεχνικές παρεμβολές. Έτσι, η τοπολογική ανάλυση δεν εξετάζει απλώς την παρουσία συνδέσεων, αλλά και την λειτουργική δομή και αρχιτεκτονική του εγκεφάλου – όπως αυτή προκύπτει από δυναμικές αλληλεπιδράσεις.

2.4 Νοητική κόπωση

2.4.1 Έννοια της νοητικής κόπωσης

Η νοητική κόπωση (mental fatigue) ερμηνεύεται ως μια πολύπλοκη ψυχοβιολογική κατάσταση, η οποία προκύπτει ως αποτέλεσμα συνεχούς εμπλοκής σε απαιτητικές γνωστικές διεργασίες. Εκδηλώνεται με την εξάντληση των γνωστικών πόρων και με τη μειωμένη ικανότητα επεξεργασίας πληροφοριών, συγκέντρωσης και αδυναμίας λήψης αποφάσεων Μια αξιοσημείωτη παρατήρηση είναι ότι η νοητική κόπωση υφίσταται και δεν συνδέεται απαραίτητα με την υπνηλία, καθώς το άτομο μπορεί να αισθάνεται νοητικά εξαντλημένο χωρίς να είναι νυσταγμένο [41],[42].

Η νοητική κόπωση διαφοροποιείται ουσιωδώς από την σωματική καθώς δεν σχετίζεται με μερικές λειτουργίες αλλά με εγκεφαλικές. Εκδηλώνεται συνήθως με ελάττωση στην επαγρύπνηση, μείωση της ακρίβειας, αυξημένο χρόνο αντίδρασης και λάθη στη μνήμη εργασίας, ενώ σχετίζεται στενά με την απώλεια κινήτρων και την απροθυμία για ολοκλήρωση καθηκόντων. Έχει αποδειχθεί η μεγάλη επιρροή που έχει στην απόδοση του ατόμου κυρίως σε περιβάλλοντα και τομείς που απαιτείται η ακρίβεια και η εγρήγορση, όπως είναι ένας επαγγελματικός χώρος και η οδήγηση [43].

Στη βιβλιογραφία διακρίνονται τρεις τύποι νοητικής κόπωσης με διακριτές αιτίες και χαρακτηριστικά:

Κόπωση σχετιζόμενη με τον ύπνο

Αναφέρεται στην πνευματική εξάντληση που προκύπτει από ανεπαρκή ή μη ποιοτικό ύπνο. Η κόπωση αυτού του είδους επηρεάζεται από τον κιρκάδιο ρυθμό, δηλαδή το εσωτερικό 24ωρο "ρολόι" του ανθρώπινου οργανισμού, το οποίο ρυθμίζει κύκλους εγρήγορσης και ύπνου. Συχνά παρατηρείται κατά τις νυχτερινές ώρες (ιδίως μεταξύ 2 π.μ. και 4 π.μ.) και νωρίς το απόγευμα (περίπου μεταξύ 1 μ.μ. και 3 μ.μ.), χρονικά διαστήματα κατά τα οποία η φυσιολογική ανάγκη για ύπνο κορυφώνεται. Τα συμπτώματα που εκδηλώνονται είναι υπνηλία, βραδύτητα αντιδράσεων, δυσκολία συγκέντρωσης και μείωση της πνευματικής διαύγειας, ενώ ακόμη μπορεί να επηρεαστεί η λειτουργία του ανοσοποιητικού, του καρδιαγγειακού και του συναισθηματικού συστήματος [44]. Άτομα που εργάζονται νυχτερινές βάρδιες, βιώνουν διαταραχές ύπνου ή πάσχουν από παθήσεις όπως η υπνική άπνοια και η ναρκοληψία, είναι ιδιαίτερα επιρρεπή σε αυτό το είδος κόπωσης.

Ενεργητική κόπωση (active fatigue)

Η ενεργητική κόπωση προέρχεται από συνεχή και απαιτητική γνωστική προσπάθεια. Οι γνωστικοί πόροι του ατόμου λειτουργούν διαρκώς για να επιτύχουν συγκέντρωση, διαχείριση περίπλοκων πληροφοριών και επίλυσης προβλημάτων. Αυτές οι απαιτήσεις παρατηρούνται κυρίως σε περιβάλλοντα ακαδημαϊκά ή εργασιακά, σε περιόδους εξετάσεων ή σε υψηλά απαιτητικά καθήκοντα αντίστοιχα. Το αποτέλεσμα αυτής της κατάστασης είναι η γνωστική

επιβράδυνση, αύξηση των λαθών, απώλεια κινήτρου και αισθήματα ψυχικής εξουθένωσης [45].

Παθητική κόπωση (passive fatigue)

Η παθητική νοητική κόπωση προκαλείται από την έκθεση του ατόμου σε επαναλαμβανόμενες, μονότονες δραστηριότητες που δεν δημιουργούν καμία νοητική πρόκληση. Παρόλο που δεν υπάρχει υψηλή γνωστική απαίτηση όπως στην περίπτωση της ενεργητικής νοητικής κόπωσης, η απουσία ερεθισμάτων και η μειωμένη διέγερση του ενδιαφέροντος του ατόμου οδηγεί στην μείωση της εγρήγορσης και στην ψυχική αποσύνδεση. Αυτή η κατάσταση είναι χαρακτηριστική σε περιόδους που το άτομο καλείται να παραμείνει σε ετοιμότητα για μεγάλο χρονικό διάστημα χωρίς αν θέλει να λαμβάνει κάποιο εξωτερικό ερέθισμα, παραμένοντας σε μονοδιάστατες διαδικασίες. Αποτέλεσμα της παθητικής κόπωσης είναι να διασπάται η προσοχή του ατόμου, να μειώνεται το ενδιαφέρον του και η ψυχική του νωθρότητα, χωρίς όμως να είναι ικανό να αντιληφθεί το επίπεδο της κόπωσης που βιώνει [45].

Συνολικά, οι τρεις διαφορετικοί τύποι νοητικής κόπωσης μπορεί να προέρχονται από διαφορετικές αιτίες αλλά κοινά συναντώνται σε σύγχρονα επαγγελματικά και κοινωνικά περιβάλλοντα. Οι συνέπειες που προκαλούν συντελούν όλες στην μείωση της εγρήγορσης, της αποτελεσματικότητας, και της γνωστικής ικανότητας του ατόμου. Γι' αυτό το λόγο είναι πολύ σημαντική η αναγνώριση, η αντιμετώπιση και πιο βασικό η πρόληψη τους.

Η ανίχνευση της νοητικής κόπωσης αποτελεί σημαντική πρόκληση, καθώς τα πιο διαδεδομένα εργαλεία είναι τα ερωτηματολόγια αυτοαναφοράς, τα οποία είναι υποκειμενικά και επιρρεπή σε προκαταλήψεις. Ως εναλλακτικές μέθοδοι έχουν προταθεί η μεταβλητότητα καρδιακού ρυθμού, τα επίπεδα κορτιζόλης στο σάλιο και οι οφθαλμικές κινήσεις τύπου antisaccade, που αντανακλούν την ικανότητα ελέγχου αποκρίσεων και φαίνεται να προσφέρουν πιο αντικειμενικές ενδείξεις [45]. Στο πλαίσιο της παρούσας εργασίας, η διερεύνηση της νοητικής κόπωσης προσεγγίζεται μέσω της ηλεκτροφυσιολογικής καταγραφής και ανάλυσης ΗΕΓ.

2.4.2 Νοητική κόπωση και λειτουργική συνδεσιμότητα

Η νοητικής κόπωση και η ηλεκτροφυσιολογική της αποτύπωση, ιδίως μέσω ηλεκτροεγκεφαλογραφήματος, έχει αναδείξει αξιοσημείωτες μεταβολές στη λειτουργική συνδεσιμότητα του εγκεφάλου. Από ερευνητικές μελέτες φαίνεται πως η κόπωση αντικατοπτρίζεται στη λειτουργική συνδεσιμότητα του εγκεφάλου, παρατηρώντας αλλαγές στη συνεργασία μεταξύ διαφόρων εγκεφαλικών περιοχών.

Είναι σημαντικό ότι οι μελέτες δείχνυον ότι σε κατάσταση ηρεμίας μπορούν να αναγνωριστούν τα λειτουργικά δίκτυα αξιόπιστα [46], γεγονός που αυξάνει την αξία της μελέτης των καταγραφών ΗΕΓ σε συνθήκες κόπωσης. Επιπλέον οι μεταβολές που σημειώνονται φαίνεται να ακολουθούν νευροψυχιατρικές αναπτυξιακές μεταβλητές και διαταραχές [47],[48].

Για παράδειγμα, σε μελέτη [49], διαπιστώθηκε ότι η μείωση της εγκεφαλικής συνδεσιμότητας, κυρίως μεταξύ μετωπιαίων και βρεγματικών περιοχών, συσχετίζεται με μειωμένη γνωστική απόδοση υπό συνθήκες κόπωσης. Αντίστοιχα, χρησιμοποιώντας fNIRS έχει δειχθεί ότι η μακροχρόνια εκτέλεση απαιτητικών εργασιών οδηγεί σε χαρακτηριστικές μεταβολές στη λειτουργική συνδεσιμότητα, όπως είναι η αποδυνάμωση των συνδέσεων στον
προμετωπιαίο φλοιό [50]. Σε άλλη μελέτη [51], με χρήση ΗΕΓ, η μείωση του Phase Lag Index (PLI) σε καταστάσεις κόπωσης υποδήλωσε χαμηλότερο επίπεδο συντονισμού μεταξύ εγκεφαλικών περιοχών. Τέλος, ελληνική μελέτη στο ΑΠΘ [52], κατέδειξε ότι η νοητική κόπωση επηρεάζει τη συνδεσιμότητα κυρίως στις άλφα και θήτα ζώνες, επηρεάζοντας δείκτες όπως ο συντελεστής συμπλέγματος και η παγκόσμια αποδοτικότητα.

Η νοητική κόπωση μπορεί και μεταβάλει την δυναμική επικοινωνία μεταξύ των εγκεφαλικών περιοχών, κυρίως στο θάλαμο-μετωπιαίο δίκτυο και τα default mode networks, τα οποία σχετίζονται με τη διατήρηση της προσοχής και τον έλεγχο της προσπάθειας όπως φαίνεται παρακάτω:

Μετρική	Μεταβολή λόγω κόπωσης	Ερμηνεία	
PLI	Μείωση	Υποδηλώνει απορρύθμιση φασικού συγχρονισμού μεταξύ περιοχών	
Συντελεστής	Ενδεχόμενη αύξηση	Αντιστάθμιση μέσω αυξημένης τοπικής	
Συγκέντρωσης	τοπικά	οργάνωσης	
Χαρακτηριστικό Μήκος Διαδρομής	Αύξηση	Μείωση αποδοτικότητας μακρινής επικοινωνίας	
Ιδιότητα Μικρόκοσμου	Ελάττωση	Διαταραχή της ισορροπίας μεταξύ τοπικής και παγκόσμιας σύνδεσης	
Παγκόσμια Αποδοτικότητα Μείωση		Χαμηλότερη συνολική αποτελεσματικότητα πληροφορικής ροής	
Τοπική Αποδοτικότητα	Ελαφρά αύξηση ή σταθερότητα	Ανθεκτικότητα σε τοπικές βλάβες	
Κεντρικότητα Διαμεσολάβησης	Μεταβλητή, συχνά μειώνεται	Χαμηλότερη σημασία ορισμένων περιοχών ως κόμβοι μετάδοσης	

Πίνακας 2. 2: Μεταβολές Μετρικών Λειτουργικής Συνδεσιμότητας σε Κατάσταση Νοητικής Κόπωσης

Τα παραπάνω ευρήματα καταδεικνύουν ότι η νοητική κόπωση δεν είναι απλώς μια "ψυχολογική" κατάσταση, αλλά συνοδεύεται από συγκεκριμένες και μετρήσιμες αλλαγές στην δομή της λειτουργικής συνδεσιμότητας, όπως αυτή προκύπτει από δείκτες όπως ο PLI και οι μετρικές γράφων. Ως εκ τούτου, η τοπολογική ανάλυση της ΛΣ προσφέρει αντικειμενικά νευροφυσιολογικά δείκτες της κόπωσης, χρήσιμους σε εφαρμογές όπως η νευροεργονομία, η παρακολούθηση απόδοσης σε πραγματικό χρόνο, και η διάγνωση νευρογνωστικών δυσλειτουργιών.

3 Μεθοδολογική Προσέγγιση και Υπολογιστικά Εργαλεία

Σε αυτό το κεφάλαιο παρουσιάζονται αναλυτικά τα βασικά εργαλεία που αξιοποιήθηκαν στην παρούσα εργασία. Εξετάζονται οι μέθοδοι επιλογής χαρακτηριστικών, οι ταξινομητικοί αλγόριθμοι και οι δείκτες αξιολόγησης που χρησιμοποιήθηκαν για την αποτίμηση της επίδοσης κάθε συνδυασμού.

3.1 Μηχανική Μάθηση

Η Τεχνητή Νοημοσύνη (Artificial Intelligence - AI) αποτελεί έναν από τους πιο ραγδαία εξελισσόμενους κλάδους της Επιστήμης των Υπολογιστών, συνδυάζοντας τη χρήση δεδομένων με υπολογιστικές τεχνικές για την ανάπτυξη έξυπνων συστημάτων. Στο επίκεντρο της TN βρίσκονται δύο υποκλάδοι: Η Μηχανική Μάθηση (Machine Learning - ML) και η Βαθιά Μάθηση (Deep Learning - DL), οι οποίοι αξιοποιούν αλγορίθμους για τη δημιουργία συστημάτων πρόβλεψης και κατηγοριοποίησης.

Η Μηχανική Μάθηση είναι ο επιστημονικός κλάδος που εστιάζει στην ανάπτυξη αλγορίθμων που έχουν εκπαιδευτεί με τέτοιο τρόπο έτσι ώστε να αναπτύσσονται και να μεταβάλλονται όταν εκτίθενται σε νέα δεδομένα. Ο όρος Μηχανική Μάθηση εισήχθη από τον Arthur Samuel το 1959, ο οποίος όρισε τη μηχανική μάθηση ως «το πεδίο που δίνει στους υπολογιστές την ικανότητα να μαθαίνουν χωρίς να προγραμματίζονται ρητά». Ένας ευρέως αποδεκτός ορισμός όμως, ειπώθηκε από τον Tom Mitchell (1997): «Ένα πρόγραμμα υπολογιστή λέγεται ότι μαθαίνει από την εμπειρία Ε σχετικά με μια κατηγορία εργασιών Τ και μετρητή απόδοσης P, αν η απόδοσή του στις εργασίες Τ, όπως μετριέται από το P, βελτιώνεται με την εμπειρία Ε.» [53].

Γενικότερα, για την εκπαίδευση των αλγορίθμων μηχανικής μάθησης χρησιμοποιούνται σύνολα δεδομένων – εκπαιδευτικά δεδομένα, τα οποία περιέχουν χαρακτηριστικά – features και μπορεί να συνοδεύονται και από τις επιθυμητές εξόδους, αναλόγως τον τύπο της μάθησης. Τα σύνολα περιέχουν δεδομένα αριθμητικά, κατηγορικά ή δυαδικά, με τα οποία κατασκευάζονται μαθηματικά μοντέλα που έχουν ως στόχο την πρόβλεψη, τη λήψη απόφασης ή την ανάλυση συσχετίσεων [54].

3.1.1 Κατηγορίες μηχανικής μάθησης και προβλημάτων

Ανάλογα με τον τρόπο εκμάθησης και την παρουσία ή απουσία επισημασμένων δεδομένων εξόδου, η μηχανική μάθηση διακρίνεται σε τρεις βασικές κατηγορίες:

Επιβλεπόμενη Μάθηση (Supervised Learning)

Ο αλγόριθμος αυτής τη κατηγορίας εκπαιδεύεται έχοντας πρόσβαση σε τιμές εισόδου και εξόδου. Χρησιμοποιεί τις τιμές εισόδου, οι οποίες θα είναι είτε χαρακτηριστικά είτε μεταδεδομένα, και τις τιμές εξόδου, συγκεκριμένες δηλαδή ταμπέλες μιας κλάσης. Ο στόχος αυτής της μάθησης είναι γνωρίζοντας την δομή των δεδομένων να εκπαιδευτεί ο αλγόριθμος ώστε να μπορεί να προβλέψει σωστές τάξεις ή κατηγορίες για νέα, άγνωστα δεδομένα.

Μη Επιβλεπόμενη Μάθηση (Unsupervised Learning)

Σε αντίθεση με την επιβλεπόμενη μάθηση, εδώ τα δεδομένα εισόδου δεν συνοδεύονται από επισημασμένες εξόδους. Έτσι ο αλγόριθμος προσπαθεί να ανακαλύψει τη δομή των δεδομένων, να εντοπίσει μοτίβα ή να δημιουργήσει ομάδες βάσει εγγενών χαρακτηριστικών από μόνος του.

Ενισχυτική Μάθηση (Reinforcement Learning)

Με την ενισχυτική μάθηση, πάλι τα δεδομένα εισόδου δεν συνοδεύονται από επισημασμένες εξόδους. Αντιθέτως τώρα, ο αλγόριθμος αλληλοεπιδρά με ένα περιβάλλον και μαθαίνει μέσω της έννοιας της ανταμοιβής (reward) και της τιμωρίας (penalty). Μέσω συνεχών δοκιμών και λαθών, μαθαίνει ποιες ενέργειες οδηγούν στη μέγιστη ανταμοιβή.



Εικόνα 3. 1: Διάγραμμα διαδικασίας Μηχανικής Μάθησης [55]

Αντίστοιχα υπάρχουν και υποκατηγορίες για τα προβλήματα της μηχανικής μάθησης, που χωρίζονται με βάση το είδος της πρόβλεψης που πραγματοποιείται, δηλαδή ανάλογα με το επιθυμητό αποτέλεσμα.

Ταζινόμηση (Classification)

Τα προβλήματα αυτά αφορούν τα δεδομένα εισόδου που χωρίζονται σε δύο ή περισσότερες κλάσεις, στις οποίες το εκπαιδευόμενο μοντέλο πρέπει να τα αντιστοιχίσει σωστά. Η προβλεπόμενη έξοδος είναι μια διακριτή τιμή – ταμπέλα από τις κλάσεις του προβλήματος. Αυτή η κατηγορία προβλημάτων είναι χαρακτηριστική της επιβλεπόμενης μάθησης.

Στα πλαίσια της διπλωματικής εργασίας χρησιμοποιήθηκαν αλγόριθμοι ταξινόμησης προκειμένου να κατηγοριοποιηθούν τα ηλεκτροεγκεφαλογραφήματα σε δύο

κατηγορίες: Υποκείμενα με κόπωση και υποκείμενα χωρίς κόπωση.

Παλινδρόμηση (Regression)

Σε αυτή την περίπτωση, το εκπαιδευόμενο μοντέλο παράγει στην έξοδο του συνεχείς αριθμητικές τιμές. Αυτή η κατηγορία αντίστοιχα, είναι χαρακτηριστική της επιβλεπόμενης μάθησης.

Συσταδοποίηση (Clustering)

Αυτή η κατηγορία προβλημάτων αφορά δεδομένα που χωρίζονται σε συστάδες – ομάδες, οι οποίες όμως είναι αρχικά άγνωστες και δημιουργούνται κατά την εκπαίδευση του μοντέλου. Αυτό αποτελεί χαρακτηριστικό της μη επιβλεπόμενης μάθησης.

3.1.2 Μηχανική μάθηση στα ιατρικά δεδομένα

Η μηχανική μάθηση λόγω του ότι επιτρέπει τη δημιουργία υπολογιστικών συστημάτων που όχι μόνο εκτελούν εργασίες, αλλά και προσαρμόζονται, βελτιώνονται, και μαθαίνουν καθώς εκτίθενται σε νέα δεδομένα, καθίστανται αναπόσπαστο εργαλείο στη σύγχρονη επιστήμη. Εφαρμογή βρίσκει και στον ιατρικό τομέα, τον οποίο έχει αρχίσει να μετασχηματίζει ριζικά. Μέσω της ανάλυσης τεράστιων όγκων ιατρικών δεδομένων, όπως ακτινογραφίες, γενετικά προφίλ ή ηλεκτρονικοί φάκελοι ασθενών, τα συστήματα μηχανικής μάθησης είναι πλέον σε θέση να εντοπίζουν πρόωρα παθήσεις, να προτείνουν εξατομικευμένες θεραπείες και να βελτιώνουν τη διάγνωση με μεγαλύτερη ακρίβεια απ' ό,τι οι παραδοσιακές μέθοδοι. Η ανάλυση ιατρικών δεδομένων μέσω Μηχανικής Μάθησης περιλαμβάνει τεχνικές όπως οι αλγόριθμοι ταξινόμησης (classification algorithms), η εξόρυξη δεδομένων (data mining) και οι μοντελοποιήσεις πρόβλεψης (predictive modeling) [56]. Αυτές οι τεχνολογίες δεν αντικαθιστούν τον ιατρό, αλλά λειτουργούν ως εργαλεία υποστήριξης, ενισχύοντας την απόδοση και μειώνοντας τα ποσοστά σφάλματος. Οι τομείς που βρίσκουν εφαρμογή εκτείνονται από την ιατρική διάγνωση έως τη ρομποτική και την ανάλυση νευροφυσιολογικών δεδομένων.

3.1.3 Αλγόριθμοι Ταξινόμησης

Οι αλγόριθμοι ταξινόμησης, όπως προαναφέρθηκε, ανήκουν στην κατηγορία της επιβλεπόμενης μηχανικής μάθησης. Σκοπός είναι να μπορέσουν να προβλέψουν σε ποια κατηγορία ανήκει ένα νέο και άγνωστο δεδομένο, βασισμένοι στα δεδομένα με τα οποία εκπαιδεύονται.

Παρακάτω παρουσιάζονται οι αλγόριθμοι που αποτέλεσαν αντικείμενο διερεύνησης και εφαρμογής στην παρούσα εργασία.

Κ-πλησιέστεροι γείτονες (K-Nearest Neighbors (KNN)):

Ο αλγόριθμος Κ πλησιέστερων γειτόνων αποτελεί έναν από τους πιο απλούς αλλά ταυτόχρονα ισχυρούς αλγορίθμους. Συνήθως χρησιμοποιείται όταν υπάρχει μικρή έως και καθόλου γνώση σχετικά με την κατανομή των δεδομένων. Ο τρόπος που λειτουργεί για την ταξινόμηση δεδομένων βασίζεται στην ομοιότητα των Κ πιο κοντινών αντικειμένων στο χώρο. Ανήκει στην κατηγορία των "τεμπέλικων» μεθόδων εκμάθησης (lazy learning), διότι βασίζεται σε στιγμιότυπα, παραλείπει το στάδιο της εκπαίδευσης και όλοι οι υπολογισμοί αναβάλλονται μέχρι την ταξινόμηση [57]. Αντί για την εκπαίδευση, διατηρεί ολόκληρο το σύνολο εκπαίδευσης και κατά τη διάρκεια της μάθησης, αναθέτει σε κάθε μια κλάση την ετικέτα που αντιπροσωπεύει την πλειοψηφία των Κ κοντινότερων γειτόνων της στο σύνολο εκπαίδευσης.

Για παράδειγμα, εάν το K=1 αυτή είναι η πιο απλή περίπτωση, κατά την οποία το κάθε δείγμα ταξινομείται με βάση τα κοντινά δείγματά του. Έτσι, εάν η ταξινόμηση ενός δείγματος είναι άγνωστη, τότε θα μπορούσε να προβλεφθεί λαμβάνοντας υπόψη την ταξινόμηση των πλησιέστερων γειτονικών δειγμάτων του. Κοιτώντας ένα δείγμα που είναι άγνωστο και ένα σετ με δεδομένα εκπαίδευσης, είναι δυνατός ο υπολογισμός όλων των αποστάσεων μεταξύ του δείγματος αυτού και όλων των άλλων στο σύνολο. Η μικρότερη τιμή απόστασης αντιστοιχεί στο πλησιέστερο δείγμα από το σύνολο και με βάση αυτό θα ταξινομηθεί το άγνωστο δείγμα.



Εικόνα 3. 2: Αλγόριθμος ταξινόμησης KNN, με K=1,3,4 [58]

Η απόδοση του ταξινομητή εξαρτάται κυρίως από το πλήθος των γειτόνων (k) καθώς και από την επιλογή της κατάλληλης μετρικής απόστασης.

Μια από τις πιο δημοφιλής επιλογές για τον υπολογισμό της απόστασης είναι η Ευκλείδεια Απόσταση:

$$d(p,q) = \sqrt{(p-q)^2}$$

Αντίστοιχα υπάρχει και ένα απλούστερο και πιο ευρέως χρησιμοποιούμενο μέτρο Manhattan, ιδιαίτερα όταν τα χαρακτηριστικά έχουν ίδια κλίμακα και όταν η γεωμετρία των δεδομένων επιβάλλει περιορισμούς κινήσεων σε ορθογώνια διαδρομή.

$$d_1(p,q) = \sum_{i=1}^n |p_i - q_i|$$

Τα πλεονεκτήματα που έχει ο αλγόριθμος KNN είναι ότι είναι απλός και καταφέρνει καλά ποσοστά ακρίβειας Δεν μπορεί βέβαια να συγκριθεί με άλλα καλύτερα μοντέλα επιβλεπόμενης μάθησης. Από την άλλη, υπάρχει μεγάλο κόστος λόγω του ότι ο αλγόριθμος αποθηκεύει όλα τα δεδομένα εκπαίδευσης και απαιτεί μνήμη. Επιπλέον, το στάδιο της πρόβλεψης μπορεί να αποβεί πολύ αργό αναλόγως το πλήθος των δεδομένων εισόδου, ενώ

Γραμμική Διακριτική Ανάλυση (Linear Discriminant Analysis (LDA))

Η γραμμική διακριτική ανάλυση είναι μία μέθοδος μετασχηματισμού δεδομένων συγκεκριμένων κλάσεων, η οποία χρησιμοποιείται στη μηχανική μάθηση για τον καλύτερο χαρακτηρισμό ή διαχωρισμό των κλάσεων. Στόχος της μεθόδου είναι η εύρεση ενός γραμμικού συνδυασμού χαρακτηριστικών που θα χρησιμοποιηθεί είτε ως ταξινομητής είτε για μείωση των διαστάσεων πριν από την μεταγενέστερη ταξινόμηση.

Απαραίτητη προϋπόθεση για να εφαρμοστεί η LDA, είναι τα δεδομένα να είναι αριθμητικά με συνεχείς τιμές και να ανήκουν σε δύο ή περισσότερες γνωστές κλάσεις. Από εκεί και πέρα η LDA μετασχηματίζει τα δεδομένα ούτως ώστε η απόσταση μεταξύ των κλάσεων να είναι η μέγιστη. Εντός κάθε κλάσης ελαχιστοποιεί τη διασπορά έχοντας τα δεδομένα της συγκεντρωμένα γύρω από τη μέση τιμή τους. Επιπλέον μειώνει τις διαστάσεις των δεδομένων για να βελτιστοποιήσει την ταξινόμηση [59].



Εικόνα 3. 3: Γραφική απεικόνιση της Γραμμικής Διακριτής Ανάλυσης [59]

Η διασπορά μεταξύ της μεταβλητότητας κλάσης μπορεί να οριστεί από τη απόσταση των μέσων τιμών των κλάσεων ως εξής:

$$S_b = \sum_{i=1}^k N_i (\bar{x}_i - \bar{x}) (\bar{x}_i - \bar{x})^T$$

Ενώ η διασπορά εντός των κλάσεων υπολογίζεται από το άθροισμα των πινάκων διασπορών κάθε κλάσης (j=1,2...,N) ως εξής:

$$S_w = \sum_{i=1}^k \sum_{j=1}^N (\overline{x_{ij}} - \overline{x}_i) (\overline{x_{ij}} - \overline{x})^T$$

Τέλος, για την μείωση των διαστάσεων των δεδομένων πρέπει να βρεθεί ο κατάλληλος πίνακας μετασχηματισμού ώστε να μεγιστοποιηθεί το κριτήριο Fisher, το οποίο ορίζεται ως:

$$J(V) = \frac{V^T S_b V}{V^T S_W V}$$

Η LDA είναι ιδιαίτερα αποτελεσματική όταν τα χαρακτηριστικά ακολουθούν κανονική κατανομή και ισχύουν ίδιες διακυμάνσεις για όλες τις κατηγορίες. Επίσης, είναι υπολογιστικά γρήγορη και αποδοτική για μεγάλα σύνολα δεδομένων.

Μηχανή Διανυσμάτων Υποστήριζης (Support Vector Machine (SVM))

O Support Vector Machine είναι ένας αλγόριθμος επιβλεπόμενης μάθησης, πολύ χρήσιμος στην ταξινόμηση δεδομένων. Η διαδικασία της ταξινόμησης περιλαμβάνει την εκπαίδευση και την δοκιμή δεδομένων που περιέχουν συγκεκριμένες παρουσίες δεδομένων. Καθεμία από αυτές περιέχει μια τιμή στόχου και πολλά χαρακτηριστικά. Στόχος του SVM είναι η

παραγωγή ενός μοντέλου που θα προβλέψει την τιμή-στόχο των δεδομένων στο σύνολο δοκιμών που δίνεται στα χαρακτηριστικά [60].

Είναι ένας υπολογιστικός αλγόριθμος ο οποίος βασίζεται στην ιδέα της κατασκευής ενός υπερεπιπέδου (hyperplane), το οποίο διαχωρίζει τις κλάσεις και λειτουργεί ως συνάρτηση απόφασης. Οι νέες παρατηρήσεις θα καταταχθούν σε κατηγορία αναλόγως την πλευρά του υπερεπιπέδου στην οποία βρίσκονται. Στόχος είναι να βρεθεί το καλύτερο υπερεπίπεδο διαχωρισμού, δηλαδή το υπερεπίπεδο που παρέχει την υψηλότερη απόσταση περιθωρίου μεταξύ των πλησιέστερων σημείων των δύο κατηγοριών (λειτουργικό περιθώριο).

Μηχανή διανυσμάτων υποστήριζης με γραμμικό πυρήνα (SVM linear kernel)

Η μορφή αυτή της γραμμικής ταξινόμησης είναι η απλούστερη του αλγορίθμου και χρησιμοποιείται όταν οι παρατηρήσεις είναι γραμμικά διαχωρίσιμες.

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 Α επισημαίνονται για παράδειγμα με την τιμή +1 και όλα τα σημεία που ανήκουν στην κατηγορία Β με την -1 [61].



Εικόνα 3. 4: Απεικόνιση γραμμικού βέλτιστου υπερεπιπέδου που δημιουργείται από τον γραμμικό SVM [62]

Αυτή η προσέγγιση είναι γραμμική, ωστόσο υπάρχουν πολλά υπερεπίπεδα που μπορούν να ταξινομήσουν το ίδιο σύνολο δεδομένων όπως φαίνεται στο Σχήμα 3.2 παραπάνω. Η γραμμική ταξινόμηση, γενικά, εγγυάται ότι όσο μεγαλύτερο είναι το περιθώριο τόσο χαμηλότερο είναι το σφάλμα γενίκευσης του ταξινομητή. Ως περιθώριο ορίζεται η μικρότερη απόσταση ενός σημείου από το υπερεπίπεδο διαγωρισμού.

Έστω ότι υπάρχει βέλτιστο υπερεπίπεδο, είναι σαφές ότι θα 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.

Ο γραμμικός SVM επιλύει το πρόβλημα μεγιστοποίησης του περιθωρίου με γραμμική συνάρτηση απόφασης της μορφής:

$$f(x) = w^T x + b$$

Η μορφή αυτή του αλγορίθμου είναι ιδιαίτερα απλή και γρήγορη στο κομμάτι της εκπαίδευσης και της πρόβλεψης. Επιπλέον χρησιμοποιείται για δεδομένα με μεγάλο αριθμό δειγμάτων, αλλά μικρό αριθμό χαρακτηριστικών. Από την άλλη όμως, παραμένει ακατάλληλος στην περίπτωση που τα δεδομένα είναι μη γραμμικά διαχωρίσιμα.

Μηχανή διανυσμάτων υποστήριζης με πυρήνα συνάρτησης ακτινικής βάσης (SVM Radial Basis Function kernel)

Όταν τα δεδομένα δεν μπορούν να διαχωριστούν γραμμικά, χρησιμοποιείται ο πυρήνας της συνάρτησης ακτινικής βάσης (RBF), γνωστός και ως πυρήνας Gaussian. Ο πυρήνας RBF βρίσκει ευρεία χρήση λόγω της ικανότητας του να καταγράφει σύνθετες μη γραμμικές σχέσεις μεταξύ σημείων δεδομένων [61].



Εικόνα 3. 5: Απεικόνιση μη γραμμικού υπερεπιπέδου που δημιούργησε μη γραμμικός SVM [62]

Ο πυρήνας RBF ορίζεται ως:

$$K(x, y) = e^{-\gamma ||x-y||^2}$$

όπου το γ ελέγχει τη "σφαίρα επιρροής" ενός δείγματος, τα x και y είναι διανύσματα χαρακτηριστικών εισόδου και το $||x - y||^2$ είναι το τετράγωνο της Ευκλείδειας απόστασης μεταξύ x και y.

Με την συνάρτηση πυρήνα μετριέται η ομοιότητα μεταξύ δύο διανυσμάτων χαρακτηριστικών εισόδου. Αυτό επιτρέπει στον SVM να μετασχηματίσει τα δεδομένα σε έναν υψηλότερης διάστασης χώρο όπου η γραμμική διάκριση είναι εφικτή.

Η προεπιλεγμένη συνάρτηση πυρήνα στο SVM είναι ο πυρήνας της συνάρτησης ακτινικής βάσης (RBF). Ωστόσο, τα SVM μπορούν να χρησιμοποιήσουν άλλες συναρτήσεις πυρήνα, όπως γραμμικούς, πολυωνυμικούς, σιγμοειδείς, Λαπλασιανούς και Chi-Square πυρήνες. Η επιλογή της συνάρτησης πυρήνα θα πρέπει να βασίζεται στα χαρακτηριστικά των δεδομένων και στο πρόβλημα που επιλύεται.

Συμπερασματικά, ο SVM, είτε με γραμμικό είτε με μη γραμμικό πυρήνα, παραμένει ένας από τους πιο ισχυρούς αλγορίθμους μηχανικής μάθησης, ιδίως σε προβλήματα δυαδικής ταξινόμησης. Παρέχει υψηλή ακρίβεια και σταθερότητα όταν οι υπερπαράμετροι επιλεγούν κατάλληλα, ενώ αποδεικνύεται ιδιαίτερα χρήσιμος σε δεδομένα με υψηλή διαστασιμότητα ή πολύπλοκες οριακές επιφάνειες.

Συνοψίζοντας, παρουσιάστηκαν οι βασικότεροι αλγόριθμοι μηχανικής μάθησης που χρησιμοποιούνται ευρέως στην ταξινόμηση βιοσημάτων. Οι αλγόριθμοι αυτοί έχουν

αξιοποιηθεί εκτενώς στη σύγχρονη έρευνα, καθώς και στην συγκεκριμένη, για την επεξεργασία ΗΕΓ σημάτων, όντας ισχυρά εργαλεία για την αυτοματοποιημένη εξαγωγή και ανάλυση πληροφορίας.

Η εφαρμογή τους αποκτά ιδιαίτερη σημασία στο πεδίο της αναγνώρισης της νοητικής κόπωσης, ένα πεδίο που γνωρίζει σημαντική ερευνητική πρόοδο τα τελευταία χρόνια. Σε επόμενη ενότητα ακολουθεί μια ιστορική αναδρομή της βιβλιογραφίας που αφορά τόσο τη μηχανική μάθηση όσο και τις τεχνικές ανάλυσης ΗΕΓ, με σκοπό την πληρέστερη κατανόηση της εξέλιξης του πεδίου και των τεχνολογιών που χρησιμοποιούνται.

3.1.4 Επιλογή χαρακτηριστικών

Στα προβλήματα της ταξινόμησης πολύ βασικό κομμάτι είναι η επιλογή χαρακτηριστικών (feature selection). Στόχος είναι ο εντοπισμός εκείνων των χαρακτηριστικών που είναι απαραίτητα για τη σωστή κατάταξη των αντικειμένων σε κατηγορίες .Ένα από τα σημαντικότερα ζητήματα που προκύπτουν κατά την ανάλυση βιοϊατρικών δεδομένων, και ειδικότερα σημάτων ΗΕΓ, είναι η λεγόμενη «κατάρα της διαστατικότητας» (curse of dimensionality). Πρόκειται για το φαινόμενο όπου η ύπαρξη ενός πολύ μεγάλου αριθμού χαρακτηριστικών (features) σε συνδυασμό με περιορισμένο αριθμό δειγμάτων οδηγεί σε σημαντική επιδείνωση της απόδοσης των μοντέλων μηχανικής μάθησης.

Στην πράξη, υπάρχουν πολλά χαρακτηριστικά, των οποίων η γνώση δεν είναι απαραίτητη για το διαχωρισμό των αντικειμένων σε κατηγορίες. Αυτό συμβαίνει είτε γιατί τα χαρακτηριστικά αυτά δίνουν πληροφορία άσχετη με το πρόβλημα είτε γιατί είναι περιττά, περιέχουν δηλαδή πληροφορία που δίνεται και από άλλα χαρακτηριστικά. Αυτό έχει ως αποτέλεσμα όχι μόνο να μην ενισχύει την ακρίβεια, αλλά δύναται να την υποβαθμίσει. Η παρουσία πλεοναζόντων ή θορυβωδών χαρακτηριστικών οδηγεί σε αυξημένη πολυπλοκότητα των μοντέλων, υπερπροσαρμογή και δυσκολία στη γενίκευση των αποτελεσμάτων.

Για να αντιμετωπιστεί αυτό το πρόβλημα, εφαρμόζεται η διαδικασία της επιλογής χαρακτηριστικών, η οποία αποτελεί κρίσιμο βήμα στην προεπεξεργασία δεδομένων και στη δημιουργία αποδοτικών ταξινομητών. Ο σκοπός της είναι η ταυτοποίηση και διατήρηση μόνο εκείνων των χαρακτηριστικών που είναι περισσότερο πληροφοριακά και διακριτικά ως προς τις κατηγορίες του προβλήματος. Αυτό οδηγεί σε πιο ελαφριά και κατανοητά μοντέλα, βελτιωμένη απόδοση, μειωμένο χρόνο εκπαίδευσης και λιγότερες απαιτήσεις αποθήκευσης και υπολογιστικής ισχύος. Τα επιλεγμένα χαρακτηριστικά βελτιστοποιούν επίσης τη δυνατότητα οπτικοποίησης και ερμηνείας των δεδομένων [63],[64].

Ο βασικός στόχος είναι η επιλογή ενός υποσυνόλου χαρακτηριστικών που μεγιστοποιούν τη διακριτική ικανότητα του μοντέλου, ενώ παράλληλα ελαχιστοποιούν τη συνάρτηση κόστους. Χρησιμοποιώντας λιγότερα χαρακτηριστικά, ο χρόνος εκπαίδευσης ταξινομητών είναι μικρότερος, το ίδιο και η διαδικασία της κατάταξης, ενώ μειώνονται και οι απαιτήσεις σε αποθηκευτικό χώρο. Επιπλέον, τα ιδανικά χαρακτηριστικά είναι εκείνα που παρουσιάζουν υψηλή διαφοροποίηση μεταξύ κατηγοριών και ταυτόχρονα μικρή διακύμανση εντός της ίδιας κατηγορίας. Τέτοια χαρακτηριστικά συμβάλλουν στον καθαρό διαχωρισμό των τάξεων και κατά συνέπεια στην αποτελεσματικότερη ταξινόμηση.

Τα τελευταία χρόνια έχει υπάρξει έντονο ερευνητικό ενδιαφέρον για την ανάπτυξη μεθόδων επιλογής χαρακτηριστικών από τομείς όπως η στατιστική, η εξόρυξη δεδομένων, η μηχανική μάθηση και η αναγνώριση προτύπων [65]. Οι μέθοδοι που έχουν προταθεί κατατάσσονται κυρίως σε τρεις βασικές κατηγορίες, filter methods, wrapper methods και embedded methods.

Filter methods (Μέθοδοι φιλτραρίσματος)

Σε αυτή την κατηγορία ανήκουν όσοι αλγόριθμοι χρησιμοποιούν στατιστικά κριτήρια για να εντοπίσουν παρόμοια χαρακτηριστικά, χωρίς να εξαρτώνται από κάποιον ταξινομητή.

Wrapper methods (Μέθοδοι περιτυλίγματος)

Αυτή η κατηγορία μεθόδων περιλαμβάνει αλγορίθμους επιλογής χαρακτηριστικών που χρησιμοποιούν σαν κριτήριο αξιολόγησης των υποσυνόλων, την ακρίβεια ταξινόμησης. Χρησιμοποιούν ένα μοντέλο μάθησης ως «μαύρο κουτί» για να αξιολογήσουν την ποιότητα των χαρακτηριστικών με βάση την απόδοση του μοντέλου. Η αποτίμηση κάθε υποψήφιου υποσυνόλου συνεπάγεται την εκπαίδευση του ταξινομητή και τη μέτρηση της απόδοσης στο σύνολο επικύρωσης, γεγονός που αυξάνει το υπολογιστικό κόστος. Παρά το μειονέκτημα τους αυτό, βρίσκουν ευρεία χρήση ιδίως σε συνδυασμό με φίλτρα για την ανάπτυξη υβριδικών αλγορίθμων [66].

Embedded methods (Ενσωματωμένες μέθοδοι)

Αυτές οι μέθοδοι έχουν σχεδιαστεί για να δουλεύουν συνεργατικά με ταξινομητές συγκεκριμένου τύπου. Αντίθετα με τις μεθόδους wrapper, επιλέγουν τα χαρακτηριστικά βασισμένοι στην επιρροή κάποιας συνάρτησης κόστους που εμπλέκεται στη διαδικασία εκπαίδευση του ταξινομητή. Εμφανίζουν πλεονέκτημα όσον αφορά το υπολογιστικό κόστος. Επιπλέον, καταφέρνουν να κάνουν καλύτερη χρήση των διαθέσιμων δεδομένων αφού δεν υπάρχει η ανάγκη αυτά να χωριστούν σε σύνολα εκπαίδευσης και επικύρωσης [67].

Στο πλαίσιο της παρούσας εργασίας, εφαρμόστηκε ένα ευρύ φάσμα από σύγχρονες μεθόδους επιλογής χαρακτηριστικών που ανήκουν και στις τρεις παραπάνω κατηγορίες, ώστε να διερευνηθεί η επίδρασή τους στην ακρίβεια ταξινόμησης και την απόδοση των μοντέλων μηχανικής μάθησης που χρησιμοποιήθηκαν.

Συγκεκριμένα εφαρμόστηκαν οι εξής 11 μέθοδοι¹:

ILFS (Infinite Latent Feature Selection)

Η ILFS είναι μια μέθοδος φιλτραρίσματος, δεν απαιτεί εκπαίδευση μοντέλου και είναι βασισμένη στη θεωρία πιθανοτήτων και συγκεκριμένα στην πιθανολογική γραφική αναπαράσταση. Δημιουργεί έναν γράφο για τα χαρακτηριστικά και τις συνδέσεις τους και χρησιμοποιεί πιθανότητες για την απόδοση βαρών στα χαρακτηριστικά. Εξετάζει όλα τα πιθανά υποσύνολα επιτρέποντας απεριόριστο αριθμό "λανθανουσών" αλληλεπιδράσεων. Αποδίδει καλύτερα σε χαρακτηριστικά που δεν έχουν ξεκάθαρες συσχετίσεις.

ReliefF

Αυτή η μέθοδος εκτιμά την διαφορά μεταξύ των χαρακτηριστικών, δίνοντας πιο μεγάλη βάση στις κοντινότερες παρατηρήσεις. Αξιολογεί τα χαρακτηριστικά ανάλογα με το πόσο καλά διακρίνονται μεταξύ διαφορετικών κλάσεων. Η συμπεριφορά αυτή την καθιστά χρήσιμη για προβλήματα με αλληλεπιδράσεις μεταξύ χαρακτηριστικών [68].

MutInfFS (Mutual Information Feature Selection)

Η μέθοδος αυτή επιλέγει χαρακτηριστικά με βάση την αμοιβαία πληροφορία μεταξύ κάθε χαρακτηριστικού και της ετικέτας εξόδου, εστιάζοντας σε αυτά που παρέχουν την

¹ Feature Selection Library: <u>https://www.mathworks.com/matlabcentral/fileexchange/56937-feature-selection-library</u>

μεγαλύτερη πληροφορία για την κλάση. Σημειώνει επιτυχία κυρίως σε υψηλής διάστασης δεδομένα [69].

FSV (Feature Selection via SVM)

Η FSV είναι μια μέθοδος wrapper που βασίζεται στην εκπαίδευση του SVM για την επιλογή χαρακτηριστικών. Διαλέγει αυτά που επηρεάζουν περισσότερο την πρόβλεψη του μοντέλου. Λειτουργεί καλύτερα όταν τα χαρακτηριστικά έχουν γραμμική συσχέτιση με την έξοδο.

Laplacian Score

Αποτελεί μια μέθοδο φιλτραρίσματος που εντοπίζει χαρακτηριστικά τα οποία διατηρούν την τοπική δομή των δεδομένων. Υπολογίζει τη σημασία των χαρακτηριστικών με βάση το πόσο καλά διατηρούν τη δομή των δεδομένων σε έναν γράφο εγγύτητας. Τα πιο σημαντικά χαρακτηριστικά είναι αυτά με την μικρότερη βαθμολογία Laplacian. Είναι ιδανική για προβλήματα με έντονες εσωτερικές συσχετίσεις και για μη επιβλέποντα προβλήματα.

Fisher Score

Είναι μια κλασική στατιστική μέθοδος που αξιολογεί τα χαρακτηριστικά με βάση την ικανότητά τους να διαχωρίζουν τις διάφορες κλάσεις. Υπολογίζεται ως ο λόγος διασποράς μεταξύ των κλάσεων προς τη διασπορά εντός των κλάσεων. Όσο πιο μεγάλη τιμή, τόσο πιο διακριτική ικανότητα έχει. Αποτελεί μια από τις πιο απλές αλλά ισχυρές μεθόδους.

LLCFS (Local Learning-based Clustering Feature Selection)

Η LLCFS συνδυάζει τη γραμμική συνεργατική επιλογή χαρακτηριστικών με τη χαμηλόβαθμη αναπαράσταση των δεδομένων. Λαμβάνοντας υπόψη τις τοπικές σχέσεις μεταξύ των δεδομένων και τη χωρική τους κατανομή, επιλέγει τα πιο αντιπροσωπευτικά χαρακτηριστικά. Παρουσιάζει μεγάλη ακρίβεια και εφαρμόζει καλά με δεδομένα υψηλής διάστασης, αλλά απαιτεί υπολογιστική ισχύ.

CFS (Correlation-based Feature Selection)

Βασίζεται στην ιδέα ότι τα καλά υποσύνολα χαρακτηριστικών είναι εκείνα που παρουσιάζουν υψηλή συσχέτιση με την κατηγορική μεταβλητή και χαμηλή μεταξύ τους συσχέτιση. Είναι ιδανική μέθοδος για αρχική επιλογή σε μεγάλα σύνολα χαρακτηριστικών.

LASSO (Least Absolute Shrinkage and Selection Operator)

Η LASSO είναι μια ενσωματωμένη μέθοδος που χρησιμοποιεί penalty L1 στον γραμμικό παλινδρομικό μοντέλο. Θέτει τις ασήμαντες συντεταγμένες μηδενικές και επιλέγει έτσι μόνο τα σημαντικά χαρακτηριστικά. Είναι και αυτή κατάλληλη για προβλήματα υπερδιάστασης.

RFC-CBR-linear

Αυτή η μέθοδος συνδυάζει Random Forest Classification με Case-Based Reasoning, με χρήση γραμμικού kernel για την επιλογή χαρακτηριστικών. Διαλέγει βάσει της συνεισφοράς τους στη διαχωριστική ικανότητα του μοντέλου. Είναι ιδιαίτερα χρήσιμη όταν θέλουμε να συνδυάσουμε στατιστικά και ευρετικά κριτήρια.

RFC-CBR-gaussian

Είναι παρόμοια μέθοδος με την RFC-CBR-linear με τη διαφορά ότι χρησιμοποιεί Gaussian (RBF) kernel, το οποίο δίνει τη δυνατότητα εντοπισμού μη γραμμικών σχέσεων μεταξύ χαρακτηριστικών και κατηγοριών. Είναι πιο ευέλικτη μέθοδος, όμως απαιτεί μεγαλύτερη υπολογιστική ισχύ.

Η εφαρμογή αυτών των μεθόδων επιτρέπει την αξιολόγηση και σύγκριση διαφορετικών στρατηγικών επιλογής χαρακτηριστικών, εξασφαλίζοντας ισχυρή βάση για την επόμενη φάση της ταξινόμησης.

3.2 Υπολογιστικοί πόροι και αξιολόγηση αλγορίθμων

Στο πεδίο της επεξεργασίας βιοσημάτων και ειδικότερα της ανάλυσης ΗΕΓ για την κατηγοριοποίηση γνωστικών καταστάσεων, όπως η νοητική κόπωση, η αποδοτικότητα των αλγοριθμικών επιλογών δεν κρίνεται αποκλειστικά από την ακρίβεια τους. Η επιλογή και η αξιολόγηση αυτών των μοντέλων προϋποθέτει και την εξέταση των υπολογιστικών τους απαιτήσεων και της γενικής αποδοτικότητάς τους.

αξιολόγηση ενός ταξινομητή συνήθως περιλαμβάνει κλασικούς δείκτες απόδοσης, όπως:

Accuracy (Ακρίβεια)

Η ακρίβεια ορίζεται ως το ποσοστό των σωστών ταξινομήσεων (σωστά θετικά + σωστά αρνητικά) επί του συνολικού αριθμού δειγμάτων. Παρότι είναι εύκολα κατανοητή και χρήσιμη σε ισορροπημένα σύνολα, χάνει σημασία όταν η μία κατηγορία υπερέχει αριθμητικά. Για παράδειγμα, ένας ταξινομητής που προβλέπει πάντα "ξεκούραση" σε ένα σύνολο με 80% ξεκούραση, θα έχει ακρίβεια 80%, παρότι αποτυγχάνει πλήρως να ανιχνεύσει την κόπωση [70].

Sensitivity / Recall (Ευαισθησία ή Ανάκληση)

Η ευαισθησία (true positive rate) μετρά την ικανότητα του ταξινομητή να ανιχνεύσει σωστά τις θετικές περιπτώσεις – στην προκειμένη περίπτωση, τα δείγματα νοητικής κόπωσης. Είναι ιδιαίτερα σημαντική όταν η λανθασμένη παράβλεψη κόπωσης (false negative) μπορεί να έχει σημαντικές επιπτώσεις (π.χ. σε συστήματα ασφάλειας, μεταφορές κ.λπ.).

$$Sensitivity = \frac{TP}{TP + FN}$$

Specifity (Ειδικότητα)

Η ειδικότητα μετρά την ικανότητα του μοντέλου να αναγνωρίσει σωστά τα αρνητικά δείγματα (π.χ. καταστάσεις μη κόπωσης). Σε συνδυασμό με την ευαισθησία, βοηθά στην κατανόηση του πώς ο ταξινομητής ανταποκρίνεται στις δύο κατηγορίες.

$$Specificity = \frac{TN}{TN + FP}$$

Precision (Ακρίβεια θετικής πρόβλεψης)

Η precision αναφέρεται στο ποσοστό των σωστών θετικών προβλέψεων επί όλων των θετικών προβλέψεων. Είναι σημαντική όταν η λανθασμένη θετική διάγνωση (false positive) έχει κόστος — π.χ. σε εφαρμογές όπου η ανίχνευση κόπωσης οδηγεί σε διακοπή δραστηριότητας.

$$Precision = \frac{TP}{TP + FP}$$

F1 Score

To F1-score είναι ο αρμονικός μέσος της ευαισθησίας και της ακρίβειας θετικής πρόβλεψης. Προσφέρει ένα ισορροπημένο μέτρο όταν οι δύο τιμές έχουν μεγάλη απόκλιση. Είναι ιδιαίτερα χρήσιμο όταν υπάρχει ανισορροπία μεταξύ των τάξεων [70].

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall}$$

Ωστόσο, σε εφαρμογές ΗΕΓ, και ιδιαίτερα σε μελέτες με πρακτική σημασία, απαιτείται η συνυπολογισμός και άλλων αξόνων για την αξιολόγηση των ταξινομητών που περιλαμβάνουν τον χρόνο εκπαίδευσης, τον χρόνο πρόβλεψης, την κατανάλωση μνήμης και την κλιμακωσιμότητα.

Χρόνος εκπαίδευσης

Ο χρόνος εκπαίδευσης αναφέρεται στη χρονική διάρκεια που απαιτείται για να κατασκευαστεί το ταξινομητικό μοντέλο με βάση τα διαθέσιμα δεδομένα εκπαίδευσης. Αλγόριθμοι όπως οι μη γραμμικοί SVM και τα ensemble μοντέλα (όπως τα Random Forests ή τα Gradient Boosted Trees) ενδέχεται να παρουσιάζουν σημαντικά αυξημένο χρόνο εκπαίδευσης, κυρίως όταν το μέγεθος του συνόλου δεδομένων ή ο αριθμός χαρακτηριστικών είναι μεγάλος. Αντίθετα, γραμμικά μοντέλα όπως η λογιστική παλινδρόμηση, καθώς και μέθοδοι όπως το Naïve Bayes, προσφέρουν σημαντικά ταχύτερους χρόνους εκπαίδευσης, γεγονός που τα καθιστά πιο ευέλικτα σε σενάρια όπου απαιτείται δυναμική ή επαναληπτική επανεκπαίδευση του μοντέλου.

Χρόνος πρόβλεψης

Εξίσου κρίσιμος είναι ο χρόνος πρόβλεψης, δηλαδή ο χρόνος που απαιτείται ώστε ο εκπαιδευμένος ταξινομητής να εξάγει μια απόφαση για ένα νέο, άγνωστο παράδειγμα. Σε εφαρμογές που απαιτούν χαμηλή καθυστέρηση, όπως τα συστήματα Brain–Computer Interface, η χρονική αποδοτικότητα σε επίπεδο πρόβλεψης είναι ζωτικής σημασίας. Μοντέλα όπως τα Decision Trees και η Logistic Regression συνήθως προσφέρουν σχεδόν ακαριαία πρόβλεψη, ενώ αλγόριθμοι όπως το k-Nearest Neighbors, οι οποίοι βασίζονται στην αποθήκευση του συνόλου εκπαίδευσης και στον επαναληπτικό υπολογισμό αποστάσεων, είναι λιγότερο κατάλληλοι για real-time εφαρμογές.

Κατανάλωση μνήμης

Η κατανάλωση μνήμης αποτελεί έναν ακόμη παράγοντα που επηρεάζει την πρακτική χρησιμότητα ενός ταξινομητή, ειδικά όταν το σύστημα στο οποίο θα αναπτυχθεί διαθέτει περιορισμένους πόρους (π.χ. φορητές ΗΕΓ συσκευές, embedded hardware, ή κινητά συστήματα νευροτεχνολογίας). Ορισμένοι αλγόριθμοι, όπως το k-NN, απαιτούν την αποθήκευση ολόκληρου του συνόλου εκπαίδευσης στη μνήμη, γεγονός που αυξάνει σημαντικά το αποτύπωμα RAM σε μεγάλα datasets. Από την άλλη πλευρά, γραμμικά μοντέλα, ή ακόμη και δέντρα με περιορισμένο βάθος, είναι σημαντικά πιο ελαφριά ως προς τις μνημονικές απαιτήσεις.

Κλιμακωσιμότητα

Η κλιμακωσιμότητα (scalability) σχετίζεται με τη συμπεριφορά του αλγορίθμου όταν το πρόβλημα ταξινόμησης αυξάνεται σε κλίμακα, είτε ως προς τον αριθμό των παραδειγμάτων, είτε ως προς τη διαστατικότητα των χαρακτηριστικών, είτε ακόμη και ως προς την πολυπλοκότητα της ετικετοδότησης (π.χ. binary έναντι multi-class). Ένα καλά σχεδιασμένο ταξινομητικό σύστημα πρέπει να διατηρεί την υπολογιστική του σταθερότητα, αποφεύγοντας εκθετικές αυξήσεις σε χρόνο ή μνήμη, καθώς η πολυπλοκότητα της ανάλυσης αυξάνεται. Μοντέλα με γραμμική ή υπογραμμική πολυπλοκότητα θεωρούνται καταλληλότερα για μεγάλα ή επεκτεινόμενα ΗΕΓ σύνολα δεδομένων, ειδικά όταν πρόκειται να εφαρμοστούν σε υπολογιστικά περιορισμένα ή φορητά περιβάλλοντα.

Εν κατακλείδι, η αξιολόγηση ενός ταξινομητή στο πλαίσιο ανάλυσης ΗΕΓ δεδομένων για την ανίχνευση νοητικής κόπωσης απαιτεί μια πολυπαραγοντική προσέγγιση. Η υψηλή ακρίβεια είναι μεν επιθυμητή, αλλά δεν είναι επαρκής, εφόσον δεν συνοδεύεται από λειτουργική αποδοτικότητα και υλοποιήσιμη υπολογιστική επιβάρυνση. Συνεπώς, η αξιολόγηση των αλγορίθμων οφείλει να λαμβάνει υπόψη την εξισορρόπηση μεταξύ ακρίβειας, ταχύτητας και αποδοτικότητας. Η ενσωμάτωση των παραμέτρων αυτών στον συνολικό σχεδιασμό των πειραμάτων και την επιλογή μοντέλων είναι καίριας σημασίας για την ανάπτυξη βιώσιμων, αποδοτικών και μεταφέρσιμων συστημάτων ταξινόμησης ΗΕΓ σημάτων.

Ερευνητική αναδρομή

Τα τελευταία χρόνια, έχει αυξηθεί σημαντικά το ερευνητικό ενδιαφέρον από την πλευρά της υπολογιστικής όρασης και της τεχνητής νοημοσύνης, προς την αυτοματοποιημένη αναγνώριση της νοητικής κόπωσης. Αυτό έχει ως αποτέλεσμα την πλούσια ποικιλία σε βιβλιογραφία και έρευνες πάνω σε μεθόδους ανίχνευσης της κόπωσης ανεξαρτήτως από την δραστηριότητα που το προκαλεί. Παρακάτω παρατίθεται ένας πίνακας με κορυφαίες επισκοπήσεις των τελευταίων χρόνων σχετικά με την μηχανική μάθηση, το ηλεκτροεγκεφαλογράφημα και την ανίχνευση κόπωσης καθώς και σχετικές μελέτες.

Δημοσίευση	Έτος	Θέμα Επισκόπησης	Μηχανική Μάθηση	НЕГ	Νοητική Κόπωση
[71]	2024	Αλγόριθμοι για ανίχνευση κόπωσης μέσω ΗΕΓ	\checkmark	\checkmark	\checkmark
[72]	2021	Μέθοδοι ανίχνευσης κόπωσης με Μηχανική Μάθηση	\checkmark	\checkmark	\checkmark
[73]	2023	Μοντελοποίηση κόπωσης με φυσιολογικά σήματα και Μηχανική Μάθηση	\checkmark	\checkmark	\checkmark
[74]	2023	Αισθητήρες και συστήματα για παρακολούθηση κόπωσης	\checkmark	\checkmark	\checkmark
[75]	2023	Μέτρα και μοντέλα κόπωσης	\checkmark	\checkmark	\checkmark
[76]	2015	Εκτίμηση και ταξινόμηση κόπωσης με ΗΕΓ	\checkmark	\checkmark	\checkmark
[77]	2023	Πρόβλεψη γνωστικού φορτίου από ΗΕΓ	\checkmark	\checkmark	\checkmark
[78]	2021	Αναγνώριση επιπέδων κόπωσης σε γλωσσική εργασία με ΗΕΓ	\checkmark	\checkmark	\checkmark
[79]	2023	Σύστημα ανίχνευσης νοητικής κόπωσης με ΗΕΓ	\checkmark	\checkmark	\checkmark
[80]	2024	Σχεδιασμός πρακτικού συστήματος ανίχνευσης κόπωσης	\checkmark	\checkmark	\checkmark
[45]	2023	Κατανόηση και ανίχνευση νοητικής κόπωσης	Х	\checkmark	\checkmark
[81]	2020	Επίδραση της νοητικής κόπωσης στη δραστηριότητα του εγκεφάλου	Х	\checkmark	\checkmark

[82]	2023	Μοντελοποίηση νοητικής	\checkmark	X	\checkmark
		κόπωσης με Τεχνητή Νοημοσύνη			
[83]	2024	Βελτίωση πρόβλεψης νοητικής	\checkmark	Х	\checkmark
		κόπωσης με Μηχανική Μάθηση			
[84]	2021	Αντικειμενικές αξιολογήσεις	X	\checkmark	\checkmark
		νοητικής κόπωσης υπό συνεχή			
		πίεση			

Πίνακας 3. 1:Δημοσιοποιήσεις με θέματα σχετικά με την Μηχανική μάθηση, το ΗΕΓ και την νοητική κόπωση

4 Πειραματική Διαδικασία

Το κεφάλαιο αυτό περιγράφει αναλυτικά τη δομή των δεδομένων, τα στάδια προεπεξεργασίας τους και τη διαδικασία δημιουργίας των εγκεφαλικών δικτύων PLI. Παρουσιάζεται επίσης η επακόλουθη εφαρμογή μεθόδων επιλογής χαρακτηριστικών και ταξινόμησης.

4.1 Περιγραφή δεδομένων

Η παρούσα μελέτη βασίστηκε σε μια σειρά πειραμάτων ΗΕΓ σε 71 συμμετέχοντες² σε κατάσταση ηρεμίας.

To dataset περιέχει δεδομένα ηρεμίας ΗΕΓ (resting-state EEG) και ψυχομετρικές μετρήσεις που συλλέχθηκαν από 71 υγιείς ενήλικες συμμετέχοντες, ηλικίας μεταξύ 17 και 23 ετών (μέσος όρος: 20 έτη). Το δείγμα περιλάμβανε 34 γυναίκες και 37 άνδρες. Ως κριτήρια αποκλεισμού ορίστηκαν η ύπαρξη ιστορικού ψυχικών παθήσεων, διαταραχών ύπνου ή πρόσφατης ασθένειας. Η έρευνα διεξήχθη σύμφωνα με τις ηθικές αρχές του Southwest University και εγκρίθηκε από τη σχετική Επιτροπή Ηθικής (κωδικός H20039). Η συλλογή δεδομένων πραγματοποιήθηκε από τον Μάρτιο του 2019 έως τον Οκτώβριο του 2021 στο Sleep and NeuroImaging Center του Southwest University.

Κάθε συμμετέχων συμμετείχε σε δύο διαδοχικές πειραματικές συνθήκες, μία μετά από κανονικό ύπνο (Normal Sleep – NS) και μία μετά από στέρηση ύπνου (Sleep Deprivation – SD), αντίστροφα ισορροπημένες για κάθε συμμετέχοντα (δηλαδή NS \rightarrow SD ή SD \rightarrow NS) ώστε να αποφεύγονται τα αποτελέσματα ακολουθίας, δηλαδή τυχόν επιδράσεις που μπορεί να είχε η εμπειρία της πρώτης συνεδρίας στα αποτελέσματα της δεύτερης. Με αυτήν την προσέγγιση, διασφαλίστηκε ότι η διαφορά μεταξύ NS και SD δεν οφείλεται απλώς στη σειρά που έγινε το πείραμα, αλλά πραγματικά στις συνθήκες ύπνου. Οι καταγραφές ΗΕΓ πραγματοποιήθηκαν τόσο με ανοιχτά όσο και με μερικώς κλειστά μάτια. Τα δημογραφικά στοιχεία (φύλο, ηλικία, Participant ID) και οι πληροφορίες για τη σειρά συνεδριών (Session Order) συνοδεύονται από χρονικά δεδομένα καταγραφής ΗΕΓ σε κάθε συνθήκη.

Επιπλέον, το dataset περιλαμβάνει δεδομένα σχετικά με την υπνηλία και τη συναισθηματική κατάσταση των συμμετεχόντων, καθώς και μετρήσεις από διάφορες ψυχολογικές και γνωστικές κλίμακες.

Η αξιολόγηση της γνωστικής απόδοσης και της συναισθηματικής κατάστασης των συμμετεχόντων πραγματοποιήθηκε με την εφαρμογή του Psychomotor Vigilance Task (PVT), το οποίο παρείχε μετρήσεις όπως ο αριθμός λαθών (lapses), η διάμεσος και η διακύμανση του χρόνου αντίδρασης (reaction time – RT). Επιπλέον, χρησιμοποιήθηκαν ψυχομετρικές κλίμακες, όπως η κλίμακα PANAS για τη θετική και αρνητική συναισθηματική διάθεση, η ATQ για την αξιολόγηση χαρακτηριστικών της προσοχής, καθώς και οι SAI, SSS και KSS για την εκτίμηση του άγχους και της υπνηλίας. Οι συμμετέχοντες συμπλήρωσαν επίσης ημερολόγιο ύπνου, όπου κατέγραφαν την ώρα κατάκλισης, την ώρα αφύπνισης και την υποκειμενική ποιότητα του ύπνου. Τέλος, χρησιμοποιήθηκαν επιπρόσθετες κλίμακες για την αξιολόγηση κοινωνικών και συναισθηματικών παραμέτρων, όπως ο Συναισθηματικός Δείκτης (EQ), η κλίμακα Buss-Perry για την επιθετικότητα, και το Pittsburgh Sleep Quality Index (PSQI), μαζί με τις επιμέρους υποκατηγορίες του.

² open neuro dataset: <u>https://openneuro.org/datasets/ds004902/versions/1.0.0</u>

Κατά τη συνεδρία του κανονικού ύπνου (NS), οι συμμετέχοντες προσέρχονταν στο εργαστήριο έχοντας κοιμηθεί φυσιολογικά την προηγούμενη νύχτα. Πριν την καταγραφή ΗΕΓ, επιβεβαιωνόταν η ποιότητα του ύπνου μέσω ημερολογίου και, σε ορισμένες περιπτώσεις, μέσω συσκευής actigraphy. Ακολουθούσε πλύσιμο των μαλλιών, τοποθέτηση των ηλεκτροδίων και καταγραφή των ψυχολογικών και γνωστικών μεταβλητών, προτού ξεκινήσει η καταγραφή ΗΕΓ διάρκειας δέκα λεπτών (πέντε λεπτά με ανοιχτά και πέντε λεπτά με κλειστά μάτια). Μετά την καταγραφή, συμπληρώνονταν επιπλέον ερωτηματολόγια. Αντίθετα, στη συνεδρία στέρησης ύπνου (SD), οι συμμετέχοντες προσέρχονταν στο εργαστήριο στις 21:00 το βράδυ της προηγούμενης ημέρας και παρέμεναν άγρυπνοι για χρονικό διάστημα που κυμαινόταν από 24 έως 30 ώρες. Η αγρυπνία επιβεβαιωνόταν μέσω συνεχούς επιτήρησης από δύο ερευνητές και με τη χρήση συσκευής actigraphy. Καθ' όλη τη διάρκεια της παραμονής τους στο εργαστήριο, δεν επιτρεπόταν η κατανάλωση καφεΐνης ή αλκοόλ, η σωματική άσκηση ή οποιαδήποτε μορφή ύπνου. Μετά την ολοκλήρωση της περιόδου στέρησης, οι συμμετέχοντες ακολουθούσαν την ίδια διαδικασία με εκείνη της NS συνεδρίας.

Η καταγραφή του ηλεκτροεγκεφαλογραφήματος πραγματοποιήθηκε με τη χρήση 61 ηλεκτροδίων τύπου Ag/AgCl, τοποθετημένων σύμφωνα με το διεθνώς αποδεκτό σύστημα τοποθέτησης 10–20. Η θέση αναφοράς ήταν το ηλεκτρόδιο FCz, ενώ η αντίσταση όλων των ηλεκτροδίων διατηρήθηκε κάτω από τα 5 kΩ. Ο ρυθμός δειγματοληψίας καθορίστηκε στα 500 Hz. Οι καταγραφές πραγματοποιήθηκαν σε ειδικά διαμορφωμένο περιβάλλον, με συνθήκες ελεγχόμενου φωτισμού κάτω από 50 Lux και θερμοκρασίας περίπου 25°C, προκειμένου να ελαχιστοποιηθούν εξωτερικά ερεθίσματα και παρεμβολές.

4.2 Επεξεργασία και ανάλυση δεδομένων

4.2.1 Προεπεξεργασία δεδομένων

Η διαδικασία προεπεξεργασίας των ηλεκτροεγκεφαλογραφικών σημάτων πραγματοποιήθηκε εξ' ολοκλήρου στο περιβάλλον του Matlab³, με τη χρήση του λογισμικού EEGLAB⁴, το οποίο αποτελεί ένα από τα πιο ευρέως χρησιμοποιούμενα εργαλεία για την ανάλυση ΗΕΓ δεδομένων. Για τους σκοπούς της παρούσας ανάλυσης, χρησιμοποιήθηκαν αποκλειστικά οι καταγραφές που πραγματοποιήθηκαν σε κατάσταση ανοιχτών ματιών, δεδομένου ότι αυτή η κατάσταση παρέχει σταθερότερα και πιο συνεπή δεδομένα για τον υπολογισμό των δικτύων λειτουργικής συνδεσιμότητας [85].

Το πρώτο στάδιο της επεξεργασίας περιλαμβάνει την εφαρμογή φιλτραρίσματος συχνοτήτων, ώστε να απομονωθεί το εύρος που περιέχει το μεγαλύτερο μέρος των εγκεφαλικών σημάτων ενδιαφέροντος. Συγκεκριμένα, εφαρμόστηκε ζωνοπερατό φίλτρο με κατώτερο όριο στα 0.2 Hz και ανώτερο στα 45 Hz. Το υψηλοπερατό φίλτρο στους 0.2 Hz απομακρύνει τις πολύ αργές διακυμάνσεις και τα σταδιακά drifts που μπορεί να οφείλονται σε κίνηση ή άλλες αργές φυσιολογικές διεργασίες, ενώ το χαμηλοπερατό φίλτρο στα 45 Hz συμβάλλει στην εξάλειψη υψηλών συχνοτήτων που σχετίζονται κυρίως με ηλεκτρικό θόρυβο, μυϊκές κινήσεις ή παρεμβολές από το ηλεκτρικό ρεύμα.

Ακολουθεί ο διαχωρισμός της καταγραφής σε μικρότερα, ισομεγέθη τμήματα (epochs), διάρκειας 4 δευτερολέπτων το καθένα. Η τεχνική αυτή διευκολύνει την επεξεργασία,

³ Matlab: <u>https://www.mathworks.com/products/matlab.html</u>

⁴ EEGLAB: <u>https://sccn.ucsd.edu/eeglab/</u>

επιτρέποντας την ανάλυση και αξιολόγηση της ποιότητας των δεδομένων σε τοπικό επίπεδο. Κατόπιν πραγματοποιείται οπτική επιθεώρηση των epochs με σκοπό τον εντοπισμό και την απομάκρυνση εκείνων που παρουσιάζουν έντονα τεχνουργήματα ή θόρυβο, όπως για παράδειγμα μυσηλεκτρική δραστηριότητα, καρδιογενή ή οφθαλμογενή σήματα (EOG), ή παρεμβολές εξωτερικής προέλευσης. Στο τέλος αυτής της διαδικασίας, κρατήθηκαν και επεξεργάστηκαν περαιτέρω τα ΗΕΓ των 53 από τους 71 συμμετέχοντες, λόγω παρουσίας υψηλού και συνεχόμενου θορύβου στα υπόλοιπα.

Σε επόμενο στάδιο, ακολουθεί η ανάλυση φασματικής ισχύος, με στόχο την εκτίμηση της ποιότητας των σημάτων ανά κανάλι και την ταυτοποίηση πιθανώς προβληματικών ηλεκτροδίων. Η διαδικασία αυτή προϋποθέτει τη σωστή φόρτωση των τοποθεσιών των καναλιών σύμφωνα με το διεθνές σύστημα "10–20", το οποίο εξασφαλίζει τη χωρική συνέπεια και την αναφορά των ηλεκτροδίων στη σωστή ανατομική θέση. Για κάθε καταγραφή δημιουργούνται γραφήματα φασματικής ισχύος και κατανομής στον χώρο, βάσει των οποίων εντοπίζονται κανάλια με εμφανείς αποκλίσεις, όπως ασυνήθιστα υψηλή ισχύς ή αστάθεια. Τα κανάλια που εμφανίζουν έντονο θόρυβο απομακρύνονται από την ανάλυση και αποκαθίστανται με τη μέθοδο της παρεμβολής (interpolation). Η τεχνική αυτή βασίζεται στα σήματα των γειτονικών ηλεκτροδίων, με σκοπό την αντικατάσταση του προβληματικού σήματος από μια εκτιμώμενη τιμή που διατηρεί την ηλεκτροφυσιολογική συνέχεια στην περιοχή.

Τα κανάλια που εμφάνισαν συχνότερα έντονο θόρυβο ήταν τα FP1, FP2, FC1, FC2, AF7 και AF8. Τα μετωπιαία ηλεκτρόδια, FP1/FP2, AF7/AF8, είναι πάντα ευαίσθητα σε artifacts λόγω της κοντινής απόστασης με μύες του προσώπου και επηρεάζονται έντονα από τις κινήσεις των ματιών. Τα FC1/FC2 μπορεί να εμφανίσουν περιοδικό θόρυβο λόγω κινήσεων του θώρακα/λαιμού κατά την αναπνοή.

Κατόπιν εφαρμόζεται Ανάλυση Ανεξάρτητων Συνιστωσών (Independent Component Analysis – ICA), μία τεχνική που επιτρέπει τον διαχωρισμό των εγκεφαλικών σημάτων από τεχνητά τεχνουργήματα. Η μέθοδος αυτή αναλύει το πολυκαναλικό ΗΕΓ σήμα σε μια σειρά από ανεξάρτητες συνιστώσες, κάθε μία εκ των οποίων αντιστοιχεί σε διακριτή πηγή σήματος. Ορισμένες από αυτές τις συνιστώσες είναι εγκεφαλικής προέλευσης και περιέχουν πληροφορία σχετική με τη γνωστική κατάσταση του συμμετέχοντα, ενώ άλλες σχετίζονται με πηγές θορύβου, όπως κινήσεις των οφθαλμών (π.χ. blinks ή saccades), κινήσεις της κεφαλής ή ηλεκτρομυογραφική δραστηριότητα.

Για την αυτόματη απομάκρυνση των ανεπιθύμητων συνιστωσών, χρησιμοποιείται η μέθοδος MARA (Multiple Artifact Rejection Algorithm). Η MARA είναι ένας εποπτευόμενος αλγόριθμος μηχανικής μάθησης, εκπαιδευμένος σε πλήθος καταγεγραμμένων ΗΕΓ σημάτων, ο οποίος αξιολογεί κάθε ανεξάρτητη συνιστώσα και εκτιμά την πιθανότητα να περιέχει τεχνουργήματα. Συνιστώσες για τις οποίες η πιθανότητα απομάκρυνσης υπερβαίνει το 0.9 θεωρούνται κατά κύριο λόγο μη εγκεφαλικής προέλευσης και αφαιρούνται από το σήμα. Με τον τρόπο αυτό διατηρούνται αποκλειστικά οι πιο αξιόπιστες και αντιπροσωπευτικές συνιστώσες για περαιτέρω ανάλυση.

Το τελικό στάδιο της προεπεξεργασίας αφορά την εκ νέου αναφορά των καναλιών (average re-referencing). Κατά την επαναναφορά αυτή, κάθε κανάλι αναπροσαρμόζεται έτσι ώστε η τιμή του να εκφράζεται ως η διαφορά από τον μέσο όρο όλων των καναλιών. Αυτή η τεχνική συμβάλλει στην εξισορρόπηση των τάσεων μεταξύ των ηλεκτροδίων, μειώνοντας την επίδραση κοινών πηγών θορύβου και ενισχύοντας τη χωρική διακριτικότητα των εγκεφαλικών σημάτων.

Συνολικά, η διαδικασία προεπεξεργασίας εξασφάλισε υψηλή ποιότητα και καθαρότητα των ΗΕΓ σημάτων, προετοιμάζοντάς τα κατάλληλα για τη φάση της εξαγωγής χαρακτηριστικών και της εφαρμογής των μοντέλων μηχανικής μάθησης.

4.2.2 Υπολογισμός PLI και εξαγωγή μετρικών δικτύου

Μετά την ολοκλήρωση της προεπεξεργασίας, για την εκτίμηση της λειτουργικής συνδεσιμότητας μεταξύ των εγκεφαλικών περιοχών, εξάγεται ο δείκτης Phase Lag Index (PLI), ο οποίος υπολογίστηκε για όλα τα πιθανά ζεύγη καναλιών $\left(\frac{61\cdot(61-1)}{2} = 1830\right)$, για κάθε συμμετέχοντα, για κάθε κατάσταση (rest,fatigue) και κάθε συχνοτική ζώνη (δέλτα, θήτα, άλφα, βήτα, γάμμα). Οι πίνακες PLI που προέκυψαν ήταν διαστάσεων 61×61×53 και 53×1830. Καθώς ο δείκτης PLI παρέχει έναν μη κατευθυνόμενο και με βάρη πίνακα συσχετίσεων, αξιοποιήθηκε στο επόμενο βήμα για την κατασκευή γραφημάτων.

Η ανάλυση βασίστηκε στη θεωρία γράφων, με στόχο την ποσοτικοποίηση των τοπολογικών ιδιοτήτων των δικτύων. Για κάθε συμμετέχοντα και κάθε συχνοτική ζώνη, εφαρμόστηκε κατωφλίωση (thresholding) στον πίνακα PLI ώστε να διατηρηθεί μόνο ένα προκαθορισμένο ποσοστό (sparsity) των ισχυρότερων συνδέσεων. Το εύρος των sparsity τιμών κυμάνθηκε από 15% έως 30%, με βήμα 1%, προκειμένου να εξεταστούν οι τοπολογικές ιδιότητες του δικτύου σε διαφορετικά επίπεδα πυκνότητας.

Προκειμένου να διασφαλιστεί ότι το προκύπτον δίκτυο είναι συνδεδεμένο, χρησιμοποιήθηκε ο αλγόριθμος Ελάχιστου Συζευκτικού Δένδρου (Minimum Spanning Tree - MST), ο οποίος εξασφαλίζει τη συνδεσιμότητα του γράφου χωρίς την προσθήκη κύκλων. Ο MST υπολογίστηκε με βάση το συμπληρωματικό βάρος των συνδέσεων (1–PLI), ώστε να δοθεί προτεραιότητα στις ισχυρότερες φάσεις συγχρονισμού. Στη συνέχεια, ο MST ενσωματώθηκε εκ νέου στο γράφο, ο οποίος είχε υποστεί thresholding, εξασφαλίζοντας ότι το τελικό δίκτυο διατηρεί τις βασικές ισχυρές συνδέσεις.

Για κάθε τέτοιο γράφο υπολογίστηκαν οι εξής βασικοί δείκτες τοπολογίας:

- Συντελεστής συγκέντρωσης (CC): βαθμός τοπικής συνδεσιμότητας ενός κόμβου.
- Χαρακτηριστικό Μήκος Διαδρομής (L): μέσος αριθμός βημάτων που απαιτούνται για να συνδεθούν όλα τα ζεύγη κόμβων.
- Παγκόσμια Αποδοτικότητα (Eg): μέτρο της συνολικής πληροφορικής απόδοσης του δικτύου.
- Τοπική Αποδοτικότητα (Eloc): μέτρο της αποδοτικότητας τοπικών υποδικτύων.
- Κεντρικότητα Διαμεσολάβησης (BC): μέτρο της σημασίας ενός κόμβου ως μεσολαβητή πληροφορίας.
- Ιδιότητα Μικρόκοσμου (SW): δείκτης που συγκρίνει τη συμπεριφορά του γράφου με αντίστοιχα τυχαία δίκτυα ως προς CC και L.
- GS_all: περιλαμβάνει τα κατωφλιωμένα γραφήματα για διαφορετικά επίπεδα sparsity, επιτρέποντας τη μελέτη της τοπολογίας των δικτύων ΗΕΓ σε διάφορες κλίμακες συνδεσιμότητας.

Για την αξιολόγηση των παραπάνω δεικτών, δημιουργούνται τυχαία δίκτυα και συγκρίνονται με τα πραγματικά δεδομένα. Αυτό βοηθά στην κατανόηση αν το ΗΕΓ δίκτυο έχει διαφορετική τοπολογία από ένα τυχαίο σύστημα και εάν παρουσιάζει χαρακτηριστικά μικρόκοσμου. Τα τυχαία αυτά δίκτυα διατηρούν τον ίδιο αριθμό κόμβων, ακμών και μέσου βαθμού σύνδεσης. Ο λόγος μεταξύ του πραγματικού και του αναμενόμενου συντελεστή

συγκέντρωσης και μήκους διαδρομής χρησιμοποιήθηκε για τον υπολογισμό του δείκτη Ιδιότητας Μικρόκοσμου.

Τα παραπάνω μέτρα υπολογίστηκαν για κάθε συμμετέχοντα, σε κάθε επίπεδο sparsity, και αποθηκεύτηκαν για περαιτέρω ανάλυση. Προκειμένου να αποκτηθεί ένας συνοπτικός δείκτης για κάθε μέγεθος γραφήματος, υπολογίστηκε η επιφάνεια κάτω από την καμπύλη (Area Under Curve - AUC) για κάθε τοπολογική παράμετρο ως προς τις sparsity τιμές.

Στατιστική Ανάλυση και Οπτικοποίηση Αποτελεσμάτων

Για τη σύγκριση των τοπολογικών χαρακτηριστικών των εγκεφαλικών δικτύων μεταξύ των καταστάσεων "rest" και "fatigue", πραγματοποιήθηκε στατιστική ανάλυση σε κάθε μία από τις υπολογισθείσες μετρικές και για κάθε συχνοτική ζώνη.

Η στατιστική σύγκριση υλοποιήθηκε μέσω μονοπαραγοντικής ανάλυσης διασποράς (ANOVA), με στόχο την ανίχνευση ενδεχόμενων στατιστικά σημαντικών διαφορών μεταξύ των δύο καταστάσεων. Για κάθε συνδυασμό τοπολογικής μετρικής και συχνοτικής ζώνης, υπολογίστηκε η τιμή p (p-value) που προκύπτει από το ANOVA, η οποία αναδεικνύει αν οι διαφορές που παρατηρούνται είναι στατιστικά σημαντικές (τυπικά με όριο σημαντικότητας p < 0.05).

Παράλληλα με την αριθμητική στατιστική ανάλυση, αξιοποιήθηκαν και τεχνικές οπτικοποίησης των αποτελεσμάτων για την καλύτερη αποτύπωση της κατανομής των δεδομένων και την ερμηνεία των διαφορών. Δημιουργήθηκαν διαγράμματα τύπου boxplot, στα οποία αποτυπώνονται οι κατανομές των τιμών των μετρικών για τις δύο καταστάσεις, επιτρέποντας την άμεση σύγκριση της διασποράς, της διάμεσου, και των ενδεχόμενων αποκλίσεων. Πάνω στα boxplots προστέθηκαν και οι μέσες τιμές των ομάδων μέσω σημείων scatter, ώστε να διευκολύνεται η παρακολούθηση της κεντρικής τάσης.

Πριν την εφαρμογή της ANOVA, εξετάστηκε η ύπαρξη ακραίων τιμών (outliers) που ενδέχεται να αλλοιώνουν την ανάλυση. Τα δεδομένα αξιολογήθηκαν ως προς την κανονικότητα και την ομοιογένεια της διασποράς, ενώ τα αποκλίνοντα σημεία επισημάνθηκαν και, όπου κρίθηκε απαραίτητο, εξαιρέθηκαν από την περαιτέρω ανάλυση ώστε να διατηρηθεί η αξιοπιστία των αποτελεσμάτων.

Η παραπάνω διαδικασία αποσκοπεί στην ενίσχυση της εγκυρότητας των συμπερασμάτων, αναδεικνύοντας με ποιον τρόπο διαφοροποιούνται οι εγκεφαλικές τοπολογικές ιδιότητες κατά την κατάσταση κόπωσης σε σχέση με την κατάσταση ηρεμίας, τόσο ποσοτικά όσο και οπτικά.

4.3 Επιλογή χαρακτηριστικών και ταξινόμηση

Η πειραματική διαδικασία ακολουθείται από δύο τελευταία βήματα, την επιλογή χαρακτηριστικών και την ταξινόμηση (classification), με σκοπό την αποδοτική διάκριση μεταξύ των δύο καταστάσεων, κόπωσης και ξεκούρασης, βάσει των χαρακτηριστικών αυτών. Αυτά τα βήματα εφαρμόστηκαν για καθεμία από τις πέντε ζώνες συχνοτήτων.

Για την επιλογή των πιο σχετικών χαρακτηριστικών εφαρμόστηκαν πολλαπλές μέθοδοι feature selection, οι οποίες περιλαμβάνουν τόσο στατιστικές μεθόδους, όσο και πιο εξελιγμένες αλγοριθμικές προσεγγίσεις. Συγκεκριμένα, εφαρμόστηκαν οι μέθοδοι ILFS, ReliefF, MutInfFS, FSV, Laplacian Score, Fisher Score, LLCFS, CFS, LASSO, RFC-CBR-linear και RFC-CBR-gaussian που αναλύθηκαν παραπάνω (ενότητα 3.1.3).

Για την εκτίμηση της απόδοσης των μεθόδων επιλέχθηκε η στρατηγική διασταυρούμενου ελέγχου leave-one-subject-out (LOSO), που αποτελεί μια μορφή διασταύρωσης όπου, σε κάθε fold, αφαιρείται από το σύνολο εκπαίδευσης το δείγμα ενός συμμετέχοντα και χρησιμοποιείται ως σύνολο δοκιμής. Αυτό διασφαλίζει ανεξαρτησία μεταξύ εκπαίδευσης και

δοκιμής και επιτρέπει την αξιολόγηση της ικανότητας γενίκευσης των μοντέλων σε νέα, άγνωστα υποκείμενα.

Για κάθε fold και μέθοδο, υπολογίστηκε η κατάταξη των χαρακτηριστικών με βάση το πόσο σημαντικά είναι για τη διάκριση μεταξύ των δύο καταστάσεων. Με βάση την κατάταξη αυτή, δημιουργήθηκαν υποσύνολα χαρακτηριστικών που περιλαμβάνουν από 1 έως και το μέγιστο αριθμό διαθέσιμων χαρακτηριστικών.

Προχωρώντας στο κομμάτι της ταξινόμησης χρησιμοποιήθηκαν πέντε διαφορετικοί ταξινομητές, οι οποίοι εκπαιδεύτηκαν και αξιολογήθηκαν με βάση τα επιλεγμένα χαρακτηριστικά από κάθε μέθοδο feature selection. Χρησιμοποιήθηκαν ο K-Nearest Neighbors, ο Linear Discriminant Analysis, ο Support Vector Machine (SVM) με γραμμικό πυρήνα και με RBF πυρήνα.

Για κάθε fold του LOSO, τα δεδομένα του συγκεκριμένου υποκειμένου αφαιρούνταν από το σύνολο εκπαίδευσης και χρησιμοποιούνταν αποκλειστικά ως σύνολο δοκιμής. Οι ταξινομητές εκπαιδεύονταν με τα χαρακτηριστικά που επέλεξε η αντίστοιχη μέθοδος feature selection για τον δεδομένο αριθμό χαρακτηριστικών και στη συνέχεια πραγματοποιούνταν πρόβλεψη στο δοκιμαστικό σύνολο. Το πλήθος των επαναλήψεων ισούται με το πλήθος των υποκείμενων, δηλαδή 53.

Τέλος, για κάθε συνδυασμό μεθόδου επιλογής χαρακτηριστικών, αριθμού χαρακτηριστικών και ταξινομητή, καταγράφηκαν:

- 1. Η ακρίβεια ταξινόμησης ως ποσοστό σωστών προβλέψεων: Το ποσοστό των σωστά ταξινομημένων δειγμάτων στα δεδομένα.
- 2. Ο χρόνος εκπαίδευσης του μοντέλου: Ο χρόνος που απαιτείται για την κατασκευή του εκάστοτε μοντέλου με βάση τα δεδομένα εκπαίδευσης.
- 3. Ο χρόνος πρόβλεψης: Ο χρόνος που απαιτείται για την ταξινόμηση νέων δεδομένων με το εκπαιδευμένο μοντέλο.
- 4. Η απαιτούμενη μνήμη: Η μνήμη (σε bytes) που καταλαμβάνει το εκπαιδευμένο μοντέλο.

Τα αποτελέσματα ομαδοποιήθηκαν και αναλύθηκαν, με στόχο την εύρεση του βέλτιστου αριθμού χαρακτηριστικών και της βέλτιστης μεθόδου feature selection για κάθε ταξινομητή. Επιπλέον, αναδείχθηκαν τα χαρακτηριστικά που επιλέχθηκαν συχνότερα για την επίτευξη της καλύτερης απόδοσης, προσφέροντας έτσι και ερμηνευτική πληροφόρηση για το ποιες περιοχές ή ζώνες ΗΕΓ συμβάλλουν περισσότερο στη διάκριση μεταξύ κόπωσης και ξεκούρασης.

Η χρήση της μεθόδου LOSO cross-validation εξασφαλίζει ότι τα αποτελέσματα έχουν γενίκευση σε νέα υποκείμενα, αποφεύγοντας την υπερεκπαίδευση και παρέχοντας μία ρεαλιστική εκτίμηση της απόδοσης του συστήματος σε πραγματικές εφαρμογές.

5 Πειραματικά Αποτελέσματα και Σχολιασμός

Η παρούσα ανάλυση αποσκοπεί στην κατανόηση του τρόπου με τον οποίο διαφοροποιείται η μορφολογία και λειτουργική οργάνωση των εγκεφαλικών δικτύων σε σχέση με τις διαφορετικές συχνοτικές ζώνες, τόσο υπό φυσιολογική κατάσταση όσο και υπό κόπωση. Η ερμηνεία βασίζεται συνδυαστικά στις αποδόσεις των ταξινομητών για κάθε συχνοτική ζώνη και μέθοδο επιλογής χαρακτηριστικών και στις μέσες τιμές των μετρικών γραφικής θεωρίας, που περιγράφουν την τοπική και ολιστική δομή των εγκεφαλικών δικτύων.

5.1 P-values μετρικών δικτύου

Αρχικά παρατίθενται ο Πίνακας 5. 1 με τις τιμές των p-values που παράχθηκαν από την ανάλυση anova για κάθε μετρική σε κάθε ζώνη συχνότητας:

Μετρική	Δέλτα (δ)	Θήτα (θ)	Άλφα (α)	Βήτα (β)	Γάμμα (γ)
Συντελεστής Συγκέντρωσης (CC)	0.3933	0.5553	0.7036	0.9198	0.6358
Μήκος Διαδρομής (L)	0.1313	0.2244	0.8725	0.8789	0.4105
Ιδιότητα Μικρόκοσμου (SW)	0.0038	0.0037	0.5361	0.1126	0.3332
Παγκόσμια Αποδοτικότητα (Eff global)	0.2926	0.4078	0.7805	0.9558	0.8567

Πίνακας 5. 1: Τιμές των p-values των μετρικών δικτύου ανά ζώνη συχνοτήτων

5.2 Έλλειψη ισχυρών στατιστικών διαφορών

Οι τιμές των p-values για τις μετρικές: Συντελεστής συγκέντρωσης, Μήκος Διαδρομής, Ιδιότητα Μικρόκοσμου και Παγκόσμια Αποδοτικότητα, δεν παρουσιάζουν σημαντικές διαφορές μεταξύ των καταστάσεων rest και fatigue σχεδόν σε όλες τις συχνοτικές ζώνες. Μια εξαίρεση είναι οι τιμές της ιδιότητας μικρόκοσμου για τους ρυθμούς δέλτα και θήτα, όπου φαίνεται μια στατιστικά σημαντική διαφορά ($p \approx 0.0038$).

Αυτές οι τιμές συνολικά δείχνουν ότι η οργάνωση του εγκεφαλικού δικτύου είναι σε μεγάλο βαθμό υποκειμενική (subject-specific) και όχι καθολικά διαφοροποιήσιμη μεταξύ των δύο καταστάσεων, καθώς πρόκειται για δίκτυα σε κατάσταση ηρεμίας, καταστάσεις χωρίς γνωστικό έργο.

Αυτό δεν αναιρεί την επίδραση της κόπωσης, αλλά υποδηλώνει ότι αυτή επιδρά περισσότερο σε διακριτούς συνδυασμούς συνδέσεων, παρά στο συνολική δομή του εγκεφάλου [1].

5.3 Μέσες τιμές των μετρικών δικτύου

Έπειτα παρουσιάζονται στους παρακάτω πίνακες και στα αντίστοιχα γραφήματα οι μέσες τιμές των μετρικών του δικτύου, CC (Εικ. 5.1 – Πιν. 5.2), Eff global (Εικ. 5.2 - Πιν. 5.3), L (Εικ. 5.3 - Πιν. 5.4) και SW (Εικ. 5.4 - Πιν. 5.5), σε κατάσταση νοητικής ξεκούρασης και κόπωσης. Σε αντίθεση με τις μικρές στατιστικές διαφορές, παρατηρώντας τις μέσες τιμές των γραφικών μετρικών διακρίνονται τάσεις μορφολογικής διαφοροποίησης του εγκεφαλικού δικτύου που σχετίζονται με την αλλαγή στη συχνότητα.

- Συντελεστής Συγκέντρωσης -



Εικόνα 5. 1: Συντελεστής συγκέντρωσης (CC) - Μέσες τιμές

Κατάσταση	Δέλτα (δ)	Θήτα (θ)	Άλφα (α)	Βήτα (β)	Γάμμα (γ)
Ξεκούραση	0.014884	0.012075	0.013097	0.0066731	0.0064341
Κούραση	0.01551	0.011553	0.012648	0.0065741	0.0062342

Πίνακας 5. 2: Συντελεστής συγκέντρωσης (CC) - Μέσες τιμές

Οι τιμές του συντελεστή συγκέντρωσης είναι υψηλότερες στις χαμηλές ζώνες συχνοτήτων, ιδιαίτερα στην δέλτα και τη θήτα, ενώ παρατηρείται σταδιακή μείωση τιμής από την άλφα προς την γάμμα. Αυτό μπορεί να μεταφραστεί σαν ελάττωση της τοπικής συνδεσιμότητας στις ψηλές συχνότητες, συγκριτικά με τις χαμηλές, και πιθανώς αυξημένη κατανομή της πληροφορίας σε απομακρυσμένος κόμβους [37].

- Παγκόσμια Αποδοτικότητα -



Εικόνα 5. 2: Παγκόσμια Αποδοτικότητα (Eff global) - Μέσες τιμές

Κατάσταση	Δέλτα (δ)	Θήτα (θ)	Άλφα (α)	Βήτα (β)	Γάμμα (γ)
Ξεκούραση	0.018738	0.015157	0.016323	0.008363	0.0081986
Κούραση	0.019378	0.014683	0.015922	0.0083164	0.0080033

Πίνακας 5. 3: Παγκόσμια Αποδοτικότητα (Eff global) - Μέσες τιμές

Η Παγκόσμια Αποδοτικότητα είναι υψηλότερη στις χαμηλές συχνότητες και μειώνεται στις υψηλότερες. Οι χαμηλές συχνότητες επιτρέπουν πιο αποδοτική συνολική επικοινωνία, ενώ η μετάβαση προς υψηλές συχνότητες αντιστοιχεί σε πιο αραιή και αποδοτική πληροφορική ανταλλαγή μεταξύ περιοχών [86].

- Μήκος Διαδρομής -



Εικόνα 5. 3: Μήκος Διαδρομής (L) - Μέσες τιμές

Κατάσταση	Δέλτα (δ)	Θήτα (θ)	Άλφα (α)	Βήτα (β)	Γάμμα (γ)
Ξεκούραση	2.0017	2.5710	2.4496	4.5822	4.5396
Κούραση	1.9726	2.5956	2.4839	4.5972	4.6200

Πίνακας 5. 4: Μήκος Διαδρομής (L) - Μέσες τιμές

Αντιθέτως με πριν, στις τιμές του μήκους διαδρομής υπάρχει αισθητή αύξηση στις ζώνες βήτα και γάμμα, γεγονός που υποδεικνύει μια μεγαλύτερη απόσταση μεταξύ των κόμβων και αντίστοιχα μικρότερης συνεκτικότητας στο δίκτυο.

- Ιδιότητα Μικρόκοσμου -



Εικόνα 5. 4: Ιδιότητα Μικρόκοσμου (SW)- Μέσες τιμές

Κατάσταση	Δέλτα (δ)	Θήτα (θ)	Άλφα (α)	Βήτα (β)	Γάμμα (γ)
Ξεκούραση	0.2335	0.23436	0.2222	0.22105	0.21969
Κούραση	0.22909	0.23497	0.22484	0.22069	0.22101

Πίνακας 5. 5: Ιδιότητα Μικρόκοσμου (SW)- Μέσες τιμές

Οι τιμές SW είναι γενικά σταθερές διατηρώντας την ιδιότητα μικρού κόσμου σε όλες τις συχνότητες.

5.4 Διαφοροποίηση της μορφής του δικτύου με βάση τη συχνότητα

Οι παραπάνω παρατηρήσεις φανερώνουν ότι με την αύξηση συχνότητας συνεπάγεται μια μορφολογική αλλαγή του δικτύου, από πιο πυκνά και συνεργατικά δίκτυα σε πιο πολυδιάστατα και αραιά. Αυτή η μετάβαση είναι συνεπής με γνωστά φαινόμενα λειτουργικής οργάνωσης σε καταστάσεις ηρεμίας, με το πως ο εγκέφαλος οργανώνεται "από μόνος του" όταν δεν εκτελεί κάποια εξωτερική εργασία [87].

5.5 Αποτελέσματα ταξινόμησης

Στη συνέχεια παρουσιάζονται οι πίνακες με τα αποτελέσματα των ταξινομήσεων. Αρχικά επιλέχθηκαν οι ταξινομήσεις που συνδυάζουν υψηλή ακρίβεια με μικρό αριθμό χαρακτηριστικών. Σε κάθε πίνακα φαίνεται ο ταξινομητής, η μέθοδος επιλογής χαρακτηριστικών με την καλύτερη ακρίβεια, η τιμή της ακρίβειας, το πλήθος και οι συνδέσεις

ηλεκτροδίων (χαρακτηριστικά) που επιλέχθηκαν. Έπειτα παρουσιάζεται η αντίστοιχη οπτικοποίηση των συνδέσεων αυτών. Τέλος για καθεμία από τις επιλεγμένες περιπτώσεις, παρατίθενται και τα διαγράμματα με την μέση ακρίβεια, τον μέσο χρόνο εκπαίδευσης και τον μέσο χρόνο πρόβλεψης συναρτήσει του πλήθους χαρακτηριστικών.

Αρχικά στην Εικόνα 5. 5 παρουσιάζονται οι ταξινομήσεις που πέτυχαν ακρίβεια μεγαλύτερη του 0.75:

Classifier		FrequencyBand	FS_Method	maxACC	Features
{ ' knn '	}	{'beta' }	2	0.78302	86
{'knn'	}	{'delta'}	2	0.76415	9
{'knn'	}	{'gamma'}	2	0.78302	147
{'knn'	}	{ 'theta ' }	2	0.80189	7
{'lda'	}	{'alpha'}	10	0.75472	110
{'lda'	}	{'alpha'}	11	0.76415	85
{'lda'	}	{'beta' }	2	0.79245	89
{'lda'	}	{'delta'}	2	0.77358	7
{'lda'	}	{'gamma'}	2	0.78302	108
{'lda'	}	{'gamma'}	8	0.76415	140
{'lda'	}	{'gamma'}	9	0.75472	118
{'lda'	}	{'gamma'}	10	0.77358	106
{'lda'	}	{ 'theta' }	2	0.78302	4
{'lda'	}	{ 'theta ' }	9	0.75472	123
{'svm linear kerned	L'}	{'theta'}	9	0.77358	34
{'svm rbf kernel'	}	{'theta'}	9	0.76415	32

Εικόνα 5. 5: Συνοπτική παρουσίαση ταξινομήσεων με ακρίβεια >75%

Από αυτούς οι 6 πιο αποδοτικοί συνολικά επισημαίνονται παρακάτω με τη σειρά, ξεκινώντας από τον καλύτερο.

Ο Πίνακας 5. 6 παρουσιάζει τα στοιχεία της ταξινόμησης για τον συνδυασμό του KNN ταξινομητή, της μεθόδου reliefF για τη ζώνη Θήτα, και έπειτα στις Εικόνες 5.6-5.9 αναπαρίστανται γραφικά οι σημαντικές συνδέσεις δικτύου, η μέση ακρίβεια, ο χρόνος πρόβλεψης και ο χρόνος εκπαίδευσης αντίστοιχα, για τον συγκεκριμένο συνδυασμό.

Ταξινομητής	Ζώνη	Μέθοδος FS	Μέγιστη ακρίβεια	Πλήθος χαρακτηριστικών	Αντιστοίχιση χαρακτηριστικών
KNN	Θήτα	reliefF	0.80189	7	$1193: P3 \leftrightarrow P2$ $1157: P1 \leftrightarrow P2$ $125: AF7 \leftrightarrow FC1$ $674: Cz \leftrightarrow Fp2$ $35: Fp1 \leftrightarrow F2$ $85: AF3 \leftrightarrow P7$ $850: T7 \leftrightarrow P7$

Πίνακας 5. 6: Στοιχεία ταξινόμησης του ΚΝΝ για την ζώνη Θήτα με την μέθοδο reliefF

Ο KNN ταξινομητής πέτυχε την υψηλότερη ακρίβεια (80.2%) με μόλις 7 χαρακτηριστικά, γεγονός που υποδηλώνει την υψηλή πληροφοριακή αξία της ζώνης θήτα. Οι περισσότερες συνδέσεις που αντιστοιχούν στα χαρακτηριστικά αυτά αφορούν μετωπιαίες και βρεγματικές περιοχές, κάτι που ευθυγραμμίζεται με τη γνωστική επεξεργασία και τη διατήρηση προσοχής σε κατάσταση ηρεμίας [88]. Επιπλέον η καμπύλη του χρόνου εκπαίδευσης είναι αρκετά ομαλή, με πολύ μικρές τιμές ανεξαρτήτως αριθμού χαρακτηριστικών, το οποίο αντικατοπτρίζει την μικρή εξάρτηση του KNN από το στάδιο εκπαίδευσης, λόγω της φύσης του αλγορίθμου [57].



PLI-Based Brain Network (Top Features)

Εικόνα 5. 6: Απεικόνιση σημαντικών συνδέσεων δικτύου για την ταξινόμηση του ΚΝΝ για τη ζώνη Θήτα με τη μέθοδο reliefF



Εικόνα 5. 7: Μέση ακρίβειας ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του KNN για τη ζώνη Θήτα με τη μέθοδο reliefF



Εικόνα 5. 8: Μέσος χρόνος πρόβλεψης ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του KNN για τη ζώνη Θήτα με τη μέθοδο reliefF



Εικόνα 5. 9: Μέσος χρόνος εκπαίδευσης ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του ΚΝΝ για τη ζώνη Θήτα με τη μέθοδο reliefF

Ο Πίνακας 5. 7 παρουσιάζει τα στοιχεία της ταξινόμησης για τον συνδυασμό του LDA ταξινομητή, της μεθόδου reliefF για τη ζώνη Θήτα, και έπειτα στις Εικόνες 5.10-5.13 αναπαρίστανται γραφικά οι σημαντικές συνδέσεις δικτύου, η μέση ακρίβεια, ο χρόνος πρόβλεψης και ο χρόνος εκπαίδευσης αντίστοιχα, για τον συγκεκριμένο συνδυασμό.

Ταξινομητής	Ζώνη	Μέθοδος FS	Μέγιστη ακρίβεια	Πλήθος χαρακτηριστικών	Συνδέσεις χαρακτηριστικών
		4	$1193: P3 \leftrightarrow P2$ $1157: P1 \leftrightarrow P2$		
LDA	Θητα	relieff	0.78302	4	125: AF7 \leftrightarrow FC1 674: Cz \leftrightarrow Fp2

Πίνακας 5. 7: Στοιχεία ταξινόμησης του LDA για την ζώνη Θήτα με την μέθοδο reliefF

Παρόμοια συμπεριφορά καταγράφεται με τον LDA στην ίδια ζώνη, όπου η ακρίβεια πλησιάζει το 78.3% με μόλις 4 χαρακτηριστικά. Αυτό δείχνει τη σταθερότητα της ζώνης θήτα στην ανάδειξη διαφορών μεταξύ των δύο καταστάσεων. Κυριαρχούν ξανά βρεγματικές και μετωπιαίες συνδέσεις. Εδώ, η καμπύλη εκπαίδευσης αυξάνεται γραμμικά με τον αριθμό χαρακτηριστικών, όμως παραμένει σε απόλυτες τιμές πολύ χαμηλή ακόμη και για υψηλό αριθμό, υποδεικνύοντας τη χαμηλή υπολογιστική απαίτηση του LDA [59].



PLI-Based Brain Network (Top Features)

Εικόνα 5. 10: Απεικόνιση σημαντικών συνδέσεων δικτύου για την ταξινόμηση του LDA για τη ζώνη Θήτα με τη μέθοδο reliefF



Εικόνα 5. 11: Μέση ακρίβεια ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του LDA για τη ζώνη Θήτα με τη μέθοδο reliefF



Εικόνα 5. 12: Μέσος χρόνος πρόβλεψης ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του LDA για τη ζώνη Θήτα με τη μέθοδο reliefF



Εικόνα 5. 13: Μέσος χρόνος εκπαίδευσης ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του LDA για τη ζώνη Θήτα με τη μέθοδο reliefF

Ο Πίνακας 5. 8 παρουσιάζει τα στοιχεία της ταξινόμησης για τον συνδυασμό του LDA ταξινομητή, της μεθόδου reliefF για τη ζώνη Δέλτα, και έπειτα στις Εικόνες 5.14-5.17 αναπαρίστανται γραφικά οι σημαντικές συνδέσεις δικτύου, η μέση ακρίβεια, ο χρόνος πρόβλεψης και ο χρόνος εκπαίδευσης αντίστοιχα, για τον συγκεκριμένο συνδυασμό.

Ταξινομητής	Ζώνη	Μέθοδος FS	Μέγιστη ακρίβεια	Πλήθος χαρακτηριστικών	Συνδέσεις χαρακτηριστικών
LDA	Δέλτα	reliefF	0.77358	7	$295: F3 \leftrightarrow FC5$ $588: FC5 \leftrightarrow C2$ $296: F3 \leftrightarrow FT7$ $305: F3 \leftrightarrow TP7$ $507: FC3 \leftrightarrow Cz$ $1326: PO7 \leftrightarrow TP10$ $1561: F6 \leftrightarrow C4$

Πίνακας 5. 8: Στοιχεία ταξινόμησης του LDA για την ζώνη Δέλτα με την μέθοδο reliefF

Η επίδοση της τάξεως του 77.4% με 7 χαρακτηριστικά τονίζει τη σημασία της ζώνης δέλτα, με κυρίαρχες διασυνδέσεις μετωπιαίων και κεντρικών περιοχών. Η δέλτα φαίνεται να συνδέεται με ευρύτερες διεργασίες που σχετίζονται με την ψυχική κόπωση. Επιπλέον εμφανίζεται ισχυρή εμπλοκή μετωπιαίων και κροταφικών περιοχών, που σχετίζονται με κόπωση και μείωση εγρήγορσης [89]. Όσον αφορά τον χρόνο εκπαίδευσης, ομοίως με την προηγούμενη περίπτωση, η αύξηση είναι ήπια και σταθερή και επηρεάζεται γραμμικά από τον αριθμό των χαρακτηριστικών.



PLI-Based Brain Network (Top Features)

Εικόνα 5. 14: Απεικόνιση σημαντικών συνδέσεων δικτύου για την ταξινόμηση του LDA για τη ζώνη Δέλτα με τη μέθοδο reliefF



Εικόνα 5. 15: Μέση ακρίβεια ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του LDA για τη ζώνη Δέλτα με τη μέθοδο reliefF



Εικόνα 5. 16: Μέσος χρόνος πρόβλεψης ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του LDA για τη ζώνη Δέλτα με τη μέθοδο reliefF



Εικόνα 5. 17: Μέσος χρόνος εκπαίδευσης ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του LDA για τη ζώνη Δέλτα με τη μέθοδο reliefF

Ο Πίνακας 5. 9 παρουσιάζει τα στοιχεία της ταξινόμησης για τον συνδυασμό του KNN ταξινομητή, της μεθόδου reliefF για τη ζώνη Δέλτα, και έπειτα στις Εικόνες 5.18-5.21 αναπαρίστανται γραφικά οι σημαντικές συνδέσεις δικτύου, η μέση ακρίβεια, ο χρόνος πρόβλεψης και ο χρόνος εκπαίδευσης αντίστοιχα, για τον συγκεκριμένο συνδυασμό.

Ταξινομητής	Ζώνη	Μέθοδος FS	Μέγιστη ακρίβεια	Πλήθος χαρακτηριστικών	Συνδέσεις χαρακτηριστικών
KNN	Δέλτα	reliefF	0.76415	9	$\begin{array}{c} 295: F3 \leftrightarrow FC5\\ 588: FC5 \leftrightarrow C2\\ 305: F3 \leftrightarrow TP7\\ 296: F3 \leftrightarrow FT7\\ 507: FC3 \leftrightarrow Cz\\ 1326: PO7 \leftrightarrow TP10\\ 864: T7 \leftrightarrow FC4\\ 1561: F6 \leftrightarrow C4\\ 178: Fz \leftrightarrow F1\end{array}$

. Πίνακας 5. 9: Στοιχεία ταξινόμησης του ΚΝΝ για την ζώνη Δέλτα με την μέθοδο reliefF

Στην ίδια συχνότητα, ο KNN φτάνει το 76.4% με 9 χαρακτηριστικά, επιβεβαιώνοντας την αξία των χαμηλών συχνοτήτων στην αναγνώριση κόπωσης. Οι επιλεγμένες συνδέσεις υποδεικνύουν συμμετοχή τόσο μετωπιαίων όσο και βρεγματικών περιοχών. Η καμπύλη του χρόνου εκπαίδευσης παραμένει σχεδόν επίπεδη, όπως και στην πρώτη περίπτωση,



0

ότι

KNN

δεν

απαιτεί

εκπαίδευση.

διαπίστωση

τη

ενισχύοντας

Εικόνα 5. 18: Απεικόνιση σημαντικών συνδέσεων δικτύου για την ταξινόμηση του ΚΝΝ για τη ζώνη Δέλτα με τη μέθοδο reliefF






Εικόνα 5. 20: Μέσος χρόνος πρόβλεψης ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του KNN για τη ζώνη Δέλτα με τη μέθοδο reliefF



Εικόνα 5. 21: Μέσος χρόνος εκπαίδευσης ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του ΚΝΝ για τη ζώνη Δέλτα με τη μέθοδο reliefF

Ο Πίνακας 5. 10 παρουσιάζει τα στοιχεία της ταξινόμησης για τον συνδυασμό του SVM γραμμικού πυρήνα ταξινομητή, της μεθόδου LASSO για τη ζώνη Θήτα, και έπειτα στις Εικόνες 5.22-5.25 αναπαρίστανται γραφικά οι σημαντικές συνδέσεις δικτύου, η μέση ακρίβεια, ο χρόνος πρόβλεψης και ο χρόνος εκπαίδευσης αντίστοιχα, για τον συγκεκριμένο συνδυασμό.

Ταξινομητής	Ζώνη	Μέθοδος FS	Μέγιστη ακρίβεια	Πλήθος χαρακτηριστικώ ν	Συνδέσεις χαρακτηριστικών	
SVM γραμμικού πυρήνα	Θήτα	LASSO	0.77358	34	4: Fp1 \leftrightarrow F1 98: AF3 \leftrightarrow FC2 143: AF7 \leftrightarrow P7 322: F3 \leftrightarrow F6 1020: TP7 \leftrightarrow O1 260: F1 \leftrightarrow O1 1683: C2 \leftrightarrow CP4 1588: F8 \leftrightarrow CP4 120: AF7 \leftrightarrow F2 200: Fz \leftrightarrow P7 12: Fp1 \leftrightarrow Cz 400: F7 \leftrightarrow FC1 845: T7 \leftrightarrow TP9 1239: P7 \leftrightarrow O1 1033: TP7 \leftrightarrow C2 1166: P3 \leftrightarrow P7	$1247: P7 \leftrightarrow F8$ $1346: Oz \leftrightarrow FC6$ $138: AF7 \leftrightarrow TP9$ $1222: P5 \leftrightarrow CPz$ $702: Cz \leftrightarrow O2$ $1243: P7 \leftrightarrow AF8$ $443: F7 \leftrightarrow TP8$ $605: FC5 \leftrightarrow O2$ $89: AF3 \leftrightarrow O1$ $516: FC3 \leftrightarrow TP9$ $125: AF7 \leftrightarrow FC1$ $1218: P5 \leftrightarrow C2$ $447: F7 \leftrightarrow P6$ $1618: FC2 \leftrightarrow PO4$ $360: F5 \leftrightarrow TP9$ $504: FC1 \leftrightarrow O2$ $1404: Fpz \leftrightarrow FC4$

Πίνακας 5. 10: Στοιχεία ταξινόμησης του SVM γραμμικού πυρήνα για την ζώνη Θήτα με την μέθοδο LASSO

Ο SVM γραμμικού πυρήνα, αν και πιο πολύπλοκος ταξινομητής, πέτυχε 77.4% ακρίβεια με 34 χαρακτηριστικά, υποδηλώνοντας ότι απαιτείται μεγαλύτερος όγκος πληροφορίας για παρόμοια απόδοση με τα απλούστερα μοντέλα. Εδώ παρατηρούνται πολυδιάστατες συνδέσεις με έμφαση σε κεντρικές, μετωπιαίες και ινιακές περιοχές. Η μεγάλη διασπορά εξηγεί και την ανάγκη για περισσότερα χαρακτηριστικά. Στον χρόνο εκπαίδευσης, παρατηρείται αισθητή αύξηση για μεγαλύτερο αριθμό χαρακτηριστικών, το οποίο υποδηλώνει πως η εκπαίδευση είναι πιο απαιτητική σε σχέση με τους απλούστερους ταξινομητές, ωστόσο παραμένει σε χαμηλές τιμές.



PLI-Based Brain Network (Top Features)

Εικόνα 5. 22: Απεικόνιση σημαντικών συνδέσεων δικτύου για την ταξινόμηση του SVM γραμμικού πυρήνα για τη ζώνη Θήτα με τη μέθοδο LASSO



Εικόνα 5. 23: Μέση ακρίβεια ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του SVM γραμμικού πυρήνα για τη ζώνη Θήτα με τη μέθοδο LASSO



Εικόνα 5. 24: Μέσος χρόνος πρόβλεψης ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του SVM γραμμικού πυρήνα για τη ζώνη Θήτα με τη μέθοδο LASSO



Εικόνα 5. 25: Μέσος χρόνος εκπαίδευσης ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του SVM γραμμικού πυρήνα για τη ζώνη Θήτα με τη μέθοδο LASSO

Ο Πίνακας 5. 11 παρουσιάζει τα στοιχεία της ταξινόμησης για τον συνδυασμό του SVM με πυρήνα συνάρτησης ακτινικής βάσης ταξινομητή, της μεθόδου LASSO για τη ζώνη Θήτα, και έπειτα Εικόνες 5.26-5.29 αναπαρίστανται γραφικά οι σημαντικές συνδέσεις δικτύου, η μέση ακρίβεια, ο χρόνος πρόβλεψης και ο χρόνος εκπαίδευσης αντίστοιχα, για τον συγκεκριμένο συνδυασμό.

Ταξινομητής	Ζώνη	Μέθοδος FS	Μέγιστη ακρίβεια	Πλήθος χαρακτηριστικών	Συνδέσεις χαρακτηριστικών	
SVM με πυρήνα συνάρτησης ακτινικής βάσης	Θήτα	LASSO	0.76415	32	98: AF3 \leftrightarrow FC2 322: F3 \leftrightarrow F6 4: Fp1 \leftrightarrow F1 143: AF7 \leftrightarrow P7 260: F1 \leftrightarrow O1 1020: TP7 \leftrightarrow O1 1683: C2 \leftrightarrow CP4 120: AF7 \leftrightarrow Fz 629: FT7 \leftrightarrow F2 1588: F8 \leftrightarrow CP4 200: Fz \leftrightarrow P7 845: T7 \leftrightarrow TP9 1239: P7 \leftrightarrow O1 12: Fp1 \leftrightarrow Cz 400: F7 \leftrightarrow FC1 1166: P3 \leftrightarrow P7	$1247: P7 \leftrightarrow F8$ $1033: TP7 \leftrightarrow C2$ $1346: Oz \leftrightarrow FC6$ $138: AF7 \leftrightarrow TP9$ $605: FC5 \leftrightarrow O2$ $1243: P7 \leftrightarrow AF8$ $702: Cz \leftrightarrow O2$ $1222: P5 \leftrightarrow CPz$ $89: AF3 \leftrightarrow O1$ $443: F7 \leftrightarrow TP8$ $447: F7 \leftrightarrow P6$ $125: AF7 \leftrightarrow FC1$ $516: FC3 \leftrightarrow TP9$ $1218: P5 \leftrightarrow C2$ $1618: FC2 \leftrightarrow PO4$ $360: F5 \leftrightarrow TP9$

Πίνακας 5. 11: Στοιχεία ταξινόμησης του SVM με πυρήνα συνάρτησης ακτινικής βάσης για την ζώνη Θήτα με την μέθοδο LASSO

Η παρόμοια ακρίβεια (76.4%) με 32 χαρακτηριστικά ενισχύει την υπόθεση ότι οι SVM ταξινομητές αποδίδουν καλύτερα με πιο πλούσια και εκτεταμένα χαρακτηριστικά, αλλά δεν υπερέχουν αισθητά των απλούστερων ταξινομητών. Σε αυτήν την περίπτωση, υπάρχει έντονη παρουσία οπισθίων συνδέσεων, ινιακών και κροταφικών περιοχών, πιθανή ένδειξη διαφοροποίησης αισθητηριακής επεξεργασίας υπό συνθήκες κόπωσης. Τέλος, η αύξηση που φαίνεται στον χρόνο εκπαίδευσης του μοντέλου είναι πιο έντονη λόγω της μη γραμμικής φύσης του πυρήνα RBF, με μεγαλύτερη ευαισθησία στον αριθμό χαρακτηριστικών [61].



PLI-Based Brain Network (Top Features)

Εικόνα 5. 26: Απεικόνιση σημαντικών συνδέσεων δικτύου για την ταξινόμηση του SVM με πυρήνα συνάρτησης ακτινικής βάσης για τη ζώνη Θήτα με τη μέθοδο LASSO







Εικόνα 5. 28: Μέσος χρόνος πρόβλεψης ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του SVM με πυρήνα συνάρτησης ακτινικής βάσης για τη ζώνη Θήτα με τη μέθοδο LASSO



Εικόνα 5. 29: Μέσος χρόνος εκπαίδευσης ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του SVM με πυρήνα συνάρτησης ακτινικής βάσης για τη ζώνη Θήτα με τη μέθοδο LASSO

Συνολικά, οι περισσότερες συνδέσεις που επιλέχθηκαν από τις μεθόδους επιλογής χαρακτηριστικών εντοπίζονται μεταξύ των μετωπιαίων, κεντρικών και βρεγματικών περιοχών. Αυτή η παρατήρηση συμβαδίζει με γνωστά ευρήματα για τα ΗΕΓ σε κατάσταση ηρεμίας και υποστηρίζει τη λειτουργική σημασία αυτών των περιοχών στην αντίληψη και ανταπόκριση στην εγκεφαλική κόπωση [88], [89].

Επιπλέον, σε όλες τις περιπτώσεις παρατηρείται σαφής κορύφωση της ακρίβειας σε συγκεκριμένο αριθμό χαρακτηριστικών, με σταθεροποίηση ή πτώση πέρα από αυτό το σημείο.

Όσον αφορά τον χρόνο πρόβλεψης, για όλα τα μοντέλα παραμένει σχετικά χαμηλός και σχεδόν γραμμικά εξαρτώμενος από τον αριθμό χαρακτηριστικών, όπως και αναμενόταν.

Από την άλλη, οι χρόνοι εκπαίδευσης αυξάνονται πιο απότομα σε μοντέλα όπως το SVM, Οι ταξινομήσεις με KNN και LDA εμφανίζουν εξαιρετικά μικρούς χρόνους εκπαίδευσης, ανεξαρτήτως το πλήθος των χαρακτηριστικών, διατηρώντας την ακρίβεια, γεγονός που τις καθιστά ιδιαίτερα αποδοτικές σε πρακτικά περιβάλλοντα.

Πέρα από αυτές τις έξι περιπτώσεις, παρακάτω στον Πίνακας 5. 12 παρατίθενται για κάθε ρυθμό από τους υπόλοιπους τρεις, ο συνδυασμός FS και αλγορίθμου που δίνει την καλύτερη ακρίβεια για τα λιγότερα δυνατά χαρακτηριστικά και τα αντίστοιχα διαγράμματα. Οι Εικόνες 5.30-5.32 αφορούν την ζώνη Άλφα, οι Εικόνες 5.33-5.35 αφορούν την ζώνη Βήτα και οι Εικόνες 5.36-5.38 αφορούν την ζώνη Γάμμα.

Ταξινομητής	Ζώνη	Μέθοδος FS	Μέγιστη ακρίβεια	Πλήθος χαρακτηριστικών
LDA	Άλφα	RFC-CBR- gaussian	0.76415	85
LDA	Βήτα	reliefF	0.79245	89
LDA	Γάμμα	reliefF	0.78302	108

Πίνακας 5. 12: Στοιχεία των βέλτιστων ταξινομήσεων για τις ζώνες Άλφα, Βήτα και Γάμμα

Ιδιαίτερο ενδιαφέρον παρουσιάζει η κυριαρχία του LDA σε όλους τους συνδυασμούς, επιβεβαιώνοντας την αποτελεσματικότητά του σε χαμηλής πολυπλοκότητας προβλήματα με διακριτές κλάσεις.

Αντίστοιχα με πριν, και στις τρεις περιπτώσεις τα διαγράμματα ακολουθούν παρόμοιο πρότυπο. Ιδιαίτερη αναφορά αξίζει στο γεγονός ότι η ακρίβεια κορυφώνεται κοντά στα 100 χαρακτηριστικά, ενώ η καμπύλη του χρόνου εκπαίδευσης παραμένει κατά κύριο λόγο ήπια, αυξανόμενη με τον αριθμό των χαρακτηριστικών. Αυτό υποδεικνύει ότι ακόμη και με την εφαρμογή του απλούστερου ταξινομητή, επιτυγχάνονται παρόμοιες επιδόσεις με χαμηλό υπολογιστικό κόστος.

Για την ζώνη άλφα:



Εικόνα 5. 30: Μέση ακρίβεια ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του LDA για τη ζώνη Άλφα με τη μέθοδο RFC-CBR-gaussian



Εικόνα 5. 31: Μέσος χρόνος πρόβλεψης ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του LDA για τη ζώνη Άλφα με τη μέθοδο RFC-CBR-gaussian



Εικόνα 5. 32: Μέσος χρόνος εκπαίδευσης ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του LDA για τη ζώνη Άλφα με τη μέθοδο RFC-CBR-gaussian



Για την ζώνη βήτα:





Εικόνα 5. 34: Μέσος χρόνος πρόβλεψης ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του LDA για τη ζώνη Βήτα με τη μέθοδο reliefF



Εικόνα 5. 35: Μέσος χρόνος εκπαίδευσης ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του LDA για τη ζώνη Βήτα με τη μέθοδο reliefF

Τέλος, για την ζώνη γάμμα:



Εικόνα 5. 36: Μέση ακρίβεια ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του LDA για τη ζώνη Γάμμα με τη μέθοδο reliefF







Εικόνα 5. 38: Μέσος χρόνος εκπαίδευσης ανά το πλήθος χαρακτηριστικών για την ταξινόμηση του LDA για τη ζώνη Γάμμα με τη μέθοδο reliefF

5.6 Ανάλυση ταξινομητικών αποτελεσμάτων και επιρροή επιλογής χαρακτηριστικών

Από τα αποτελέσματα φαίνεται πως οι μέγιστες επιδόσεις ακριβείας περιορίστηκαν σε εύλογα αλλά όχι εξαιρετικά υψηλά επίπεδα. Αυτό πιθανόν οφείλεται στο γεγονός ότι η κόπωση σε συνθήκες ηρεμίας δεν αποτυπώνεται μέσα από έντονες ή καθολικές διαφορές σε όλες τις περιοχές του εγκεφάλου.

Παρόλα αυτά, τα αποτελέσματα των ταξινομήσεων αποκαλύπτουν πως η διάκριση μεταξύ της κατάστασης ξεκούρασης και κόπωσης είναι εφικτή κυρίως μέσω των απλών ταξινομητών KNN, LDA, οι οποίοι υπερτερούν έναντι πιο σύνθετων μοντέλων SVM, καθώς καταφέρνουν συγκρίσιμες ή και καλύτερες επιδόσεις (έως και 80,2% ακρίβεια) με σαφώς μικρότερες υπολογιστικές απαιτήσεις.

Ιδιαίτερο ενδιαφέρον παρουσιάζει η σχέση μεταξύ της συχνότητας, της ταξινομητικής ακρίβειας και του αριθμού των χαρακτηριστικών.

Οι χαμηλές συχνότητες, θήτα και δέλτα, φαίνεται να ενσωματώνουν το πιο χρήσιμο φάσμα πληροφορίας για τη διάκριση ανάμεσα στις καταστάσεις, και μάλιστα με χαμηλό αριθμό χαρακτηριστικών. Καταφέρνουν οι ταξινομητές να επιτύχουν υψηλές ακρίβειες με εξαιρετικά μικρό αριθμό χαρακτηριστικών, που κυμαίνεται από 4 έως 34.

Αντιθέτως, στις υψηλές συχνότητες, άλφα, βήτα και γάμμα, απαιτήθηκε πολύ μεγαλύτερο πλήθος χαρακτηριστικών (έως και 486 χαρακτηριστικά) σε κάποιες περιπτώσεις για να φτάσουν ακόμα και οριακά αποδεκτές επιδόσεις, γεγονός που υποδηλώνει ότι οι αντίστοιχες συνδέσεις του δικτύου περιέχουν λιγότερη πληροφορία σχετική με τη διάκριση κόπωσης.

Τέλος, όσον αφορά τους υπολογιστικούς πόρους, η μνήμη που καταναλώνεται κατά τη διάρκεια εφαρμογής ενός μοντέλου ταξινόμησης εξαρτάται κυρίως από το πλήθος των χαρακτηριστικών που χρησιμοποιούνται στο μοντέλο. Η διαφοροποίηση σε σχέση με το μοντέλο. μηχανικής μάθησης που χρησιμοποιείται, έχει να κάνει κυρίως με τη διαφορά ανάμεσα σε μοντέλα που απαιτούν τη φόρτωση ολόκληρου του συνόλου χαρακτηριστικών στη μνήμη τους (πχ, KNN) και μοντέλα που μπορούν να εκπαιδευτούν σταδιακά, χρησιμοποιώντας υποσύνολα του συνόλου χαρακτηριστικών κάθε φορά.

Αντίστοιχα, ο χρόνος πρόβλεψης σχεδόν σε όλες τις περιπτώσεις αυξάνεται γραμμικά με το πλήθος χαρακτηριστικών και για αυτόν τον λόγο δεν αποτελεί κρίσιμο και αντιπροσωπευτικό παράγοντα. Αντίθετα, ο χρόνος εκπαίδευσης διαφοροποιείται αισθητά μεταξύ ταξινομητών και πρέπει να λαμβάνεται υπόψη ως βασικό κριτήριο. Επιπλέον, αυτό που παρατηρείται για την μέση ακρίβεια των μοντέλων είναι πως αυξάνεται μέχρι έναν αριθμό χαρακτηριστικών και έπειτα από αυτόν είτε παραμένει ίδια είτε μειώνεται. Αυτό υποδεικνύει ότι η πληροφορία συγκεντρώνεται σε ένα συγκεκριμένο αριθμό συνδέσεων στον οποίο η ακρίβεια πετυχαίνει τις μέγιστες τιμές της.

6 Συμπεράσματα και Μελλοντικές Προεκτάσεις

Η παρούσα διπλωματική εργασία εστίασε στη διερεύνηση της νοητικής κόπωσης μέσω της επεξεργασίας σημάτων ΗΕΓ σε συνθήκες ηρεμίας, με στόχο την κατηγοριοποίηση μεταξύ των καταστάσεων ξεκούρασης και κόπωσης. Εξετάστηκε ένα πλήρες πειραματικό πλαίσιο που περιλάμβανε προεπεξεργασία δεδομένων, υπολογισμό λειτουργικής συνδεσιμότητας με χρήση του Phase Lag Index (PLI), εξαγωγή τοπολογικών μετρικών από θεωρία γράφων, εφαρμογή έντεκα μεθόδων επιλογής χαρακτηριστικών και τέσσερις ταξινομητές για την τελική ταξινόμηση.

6.1 Συμπεράσματα

Τα αποτελέσματα έδειξαν ότι δεν προκύπτουν σημαντικές διαφορές μεταξύ των δύο καταστάσεων σε επίπεδο συνολικής τοπολογίας του εγκεφαλικού δικτύου. Η γενικότερη απουσία ισχυρών διαφορών αντικατοπτρίζει την subject-specific φύση των δικτύων σε κατάσταση ηρεμίας, στα οποία η εγκεφαλική δραστηριότητα δεν προσανατολίζεται σε εξωτερικό στόχο αλλά χαρακτηρίζεται από ενδογενή οργάνωση και διαφοροποίηση μεταξύ των ατόμων.

Αξιοσημείωτη ήταν η διαφοροποίηση της μορφολογίας των εγκεφαλικών δικτύων με βάση τη συχνότητα. Στις χαμηλές συχνότητες παρατηρείται υψηλότερη τοπική συνδεσιμότητα και καλύτερη συνολική απόδοση, ενώ στις υψηλές, τα δίκτυα φαίνεται να είναι πιο αραιά και λιγότερο οργανωμένα, κάτι που συνάδει με βιβλιογραφικά δεδομένα για τη λειτουργική οργάνωση σε καταστάσεις ηρεμίας.

Οι παραπάνω παρατηρήσεις συμβάλλουν στην ερμηνεία των αποτελεσμάτων ταξινόμησης, όπου παρά τη χρήση εξελιγμένων μεθόδων επιλογής χαρακτηριστικών και ισχυρών ταξινομητών, οι μέγιστες επιδόσεις ακριβείας περιορίστηκαν σε εύλογα αλλά όχι εξαιρετικά υψηλά επίπεδα (μέγιστο 80,2%). Αυτό πιθανόν οφείλεται στο γεγονός ότι η κόπωση σε συνθήκες ηρεμίας δεν αποτυπώνεται μέσα από έντονες ή καθολικές διαφορές σε όλες τις περιοχές του εγκεφάλου, αλλά περισσότερο σε επιλεκτικές αλλαγές στη συνδεσιμότητα συγκεκριμένων ζωνών και κόμβων, κάτι που δυσχεραίνει την κατηγοριοποίηση.

Οι καλύτερες επιδόσεις ταξινόμησης εμφανίστηκαν στις χαμηλές συχνοτικές ζώνες, θήτα και δέλτα. Συγκεκριμένοι συνδυασμοί μεθόδων επιλογής χαρακτηριστικών (όπως ReliefF και LASSO) και ταξινομητών (όπως KNN και LDA) προσέφεραν πιο υψηλές επιδόσεις, με τα χαρακτηριστικά να εντοπίζονται σε περιοχές όπως οι βρεγματικές και μετωπιαίες, γνωστές για τη συμβολή τους σε γνωσιακές και αντιληπτικές διεργασίες.

Η ανάγκη αυξημένου αριθμού χαρακτηριστικών στις υψηλές συχνότητες ερμηνεύεται ως απόρροια της μειωμένης συνοχής των δικτύων, όπως αυτή αντικατοπτρίζεται και στις γραφικές μετρικές (μειωμένος CC, αυξημένο L, μειωμένο GE). Η συνδυαστική ανάλυση επιβεβαιώνει ότι η δομή των δικτύων κατάστασης ηρεμίας στις υψηλές συχνότητες είναι πιο αραιή, λιγότερο οργανωμένη, γεγονός που περιπλέκει τη διαχωρισιμότητα μεταξύ των δύο καταστάσεων.

Όσον αφορά τις υπολογιστικές απαιτήσεις των μοντέλων, παρατηρήθηκε ότι η μνήμη που καταναλώνεται εξαρτάται κυρίως από το πλήθος των επιλεγμένων χαρακτηριστικών και όχι από τον ίδιο τον ταξινομητή. Ο χρόνος πρόβλεψης ακολουθεί σχεδόν γραμμική αύξηση με τον αριθμό χαρακτηριστικών και επομένως δεν αποτελεί αξιόπιστο δείκτη συγκριτικής αξιολόγησης. Αντίθετα, ο χρόνος εκπαίδευσης διαφοροποιείται σημαντικά ανάλογα με τον ταξινομητή και μπορεί να λειτουργήσει ως κρίσιμος παράγοντας επιλογής, ιδίως σε εφαρμογές όπου απαιτείται χαμηλό υπολογιστικό κόστος. Οι απλούστεροι αλγόριθμοι, όπως

ο KNN και ο LDA, εμφάνισαν χαμηλή υπολογιστική επιβάρυνση, ενώ πιο σύνθετοι αλγόριθμοι, όπως ο SVM με RBF kernel, παρουσίασαν σημαντικά αυξημένες απαιτήσεις, ιδιαίτερα σε περιπτώσεις υψηλής διαστασιμότητας. Τέλος, παρατηρήθηκε ότι η ακρίβεια των μοντέλων αυξάνεται μέχρι έναν συγκεκριμένο αριθμό χαρακτηριστικών, πέρα από τον οποίο σταθεροποιείται ή και μειώνεται. Το εύρημα αυτό υποδηλώνει την ύπαρξη ενός βέλτιστου υποσυνόλου συνδέσεων που φέρει το μεγαλύτερο πληροφοριακό φορτίο για την κατηγοριοποίηση μεταξύ των δύο καταστάσεων.

6.2 Μελλοντικές προεκτάσεις

Η εργασία καταδεικνύει τη σημασία της πολυεπίπεδης αξιολόγησης (τοπολογία, χαρακτηριστικά, ταξινομητές, υπολογιστικοί πόροι) για την κατανόηση και την ανίχνευση της νοητικής κόπωσης.

Πιθανές επεκτάσεις περιλαμβάνουν:

- Τη σύγκριση resting state με task-based δεδομένων για την κατανόηση του τρόπου με τον οποίο η κόπωση επηρεάζει την εκτελεστική λειτουργία επιπλέον της κατάστασης ηρεμίας.
- Τη συσχέτιση των αποτελεσμάτων με ψυχομετρικά δεδομένα ή δείκτες απόδοσης, για βαθύτερη κατανόηση της λειτουργικής σημασίας των δικτύων.
- Την εφαρμογή πιο εξελιγμένων τεχνικών βαθιάς μάθησης (π.χ. Graph Neural Networks) με ενσωματωμένη ανάλυση γραφημάτων.
- Την ανάλυση δεδομένων υπό ρεαλιστικές συνθήκες νοητικής κόπωσης με παράλληλη μέτρηση συμπεριφορικών δεικτών απόδοσης ή υποκειμενικής εκτίμησης κόπωσης.
- Την αξιολόγηση μεθόδων με βάση πραγματικού χρόνου εφαρμογές (online fatigue monitoring).

Συνολικά, η εργασία καταδεικνύει την σημασία της συνδυαστικής αξιολόγησης τοπολογικών δεικτών και ταξινομητικών επιδόσεων στην ανάλυση σύνθετων εγκεφαλικών καταστάσεων. Προσφέρει ένα ολοκληρωμένο πλαίσιο αξιολόγησης της λειτουργικής συνδεσιμότητας σε συνθήκες κόπωσης, και θέτει τις βάσεις για περαιτέρω διερεύνηση της επίδρασης νοητικής κατάστασης στις εγκεφαλικές συνδέσεις.

Βιβλιογραφία

- M. E. Raichle, A. M. MacLeod, A. Z. Snyder, W. J. Powers, D. A. Gusnard, and G. L. Shulman, "A default mode of brain function," *Proc. Natl. Acad. Sci. U. S. A.*, vol. 98, no. 2, pp. 676–682, 2001, doi: 10.1073/PNAS.98.2.676/ASSET/0D756665-76C2-42A2-ACA7-01DE9C6DEDA4/ASSETS/GRAPHIC/PQ0115125005.JPEG.
- [2] K. H. Jawabri and S. Sharma, "Physiology, Cerebral Cortex Functions," *StatPearls*, 2023, [Online]. Available: https://www.ncbi.nlm.nih.gov/books/NBK538496/.
- [3] "Νευροανατομία University Studio Press." [Online]. Available: https://www.universitystudiopress.gr/item/neyroanatomia--029950.
- [4] A. M. M. Sousa, K. A. Meyer, G. Santpere, F. O. Gulden, and N. Sestan, "Evolution of the Human Nervous System Function, Structure, and Development.," *Cell*, vol. 170, no. 2, pp. 226–247, Jul. 2017, doi: 10.1016/j.cell.2017.06.036.
- [5] "Βασικές Γνώσεις Ανατομίας του Εγκεφάλου." [Online]. Available: https://pediatricneurosurgery.com/anatomy.
- [6] Α. Τσιατούχας, "Ανατομία του Ανθρώπινου Σώματος," 2011. https://lepaldafnis.mysch.gr/bima/ergask/anatomy/egefalos.htm.
- [7] Σ. Παυλόπουλος, Α. Πρέντζα, and Δ. Κουτσούρης, Εισαγωγή στη Βιοϊατρική Τεχνολογία και Ανάλυση Ιατρικών Σημάτων. Εκδόσεις Τζιόλα, 2003.
- [8] "Ανατομία Φυσιολογία: Μαρία Νίκη Αιγυπτιάδου, Αικατερίνη Κορφιάτη, Ροδόπη Κουρσούμη | metabook.gr." [Online]. Available: https://metabook.gr/books/anatomiafisiologhia-maria-niki-aighiptiadoy-180288.
- [9] J. Zhang, "Basic Neural Units of the Brain: Neurons, Synapses and Action Potential," 2019, [Online]. Available: https://arxiv.org/pdf/1906.01703.
- [10] C. Y. M. Huang and M. N. Rasband, "Axon initial segments: structure, function, and disease," Ann. N. Y. Acad. Sci., vol. 1420, no. 1, p. 46, 2018, doi: 10.1111/NYAS.13718.
- [11] K. Cherry, "Parts of a Neuron and How Signals are Transmitted." 2023, [Online]. Available: https://www.verywellmind.com/structure-of-a-neuron-2794896?utm_source=chatgpt.com.
- [12] R. Srinivasan, D. M. Tucker, and M. Murias, "Estimating the spatial Nyquist of the human EEG," *Behav. Res. Methods, Instruments, Comput.*, vol. 30, no. 1, pp. 8–19, 1998, doi: 10.3758/BF03209412/METRICS.
- [13] R. Carter, S. Parker, M. Page, and S. Aldridge, "The Human Brain Book : an Illustrated Guide to its Structure, Function, and Disorders," 2019.
- [14] Μ. Τσιπούρας et al., "Medical Informatics," 2016, doi: 10.57713/KALLIPOS-733.
- [15] E. K. St. Louis *et al.*, "Electroencephalography (EEG): An Introductory Text and Atlas of Normal and Abnormal Findings in Adults, Children, and Infants," *Electroencephalogr. An Introd. Text Atlas Norm. Abnorm. Find. Adults, Child. Infants*, 2016, [Online]. Available: https://www.ncbi.nlm.nih.gov/books/NBK390354/.
- [16] G. H. Klem, H. O. Lüders, H. H. Jasper, and C. Elger, "The ten-twenty electrode system of the International Federation. The International Federation of Clinical Neurophysiology.," *Electroencephalogr. Clin. Neurophysiol. Suppl.*, vol. 52, pp. 3–6, 1999.
- [17] M. Piwowarski, U. S. Singh, and K. Nermend, "Application of EEG Metrics in the Decision-Making Process," *Springer Proc. Bus. Econ.*, pp. 187–199, 2020, doi: 10.1007/978-3-030-30251-1_14.
- [18] M. Orban, M. Elsamanty, K. Guo, S. Zhang, and H. Yang, "A Review of Brain Activity and EEG-Based Brain-Computer Interfaces for Rehabilitation Application.," *Bioeng.* (*Basel, Switzerland*), vol. 9, no. 12, Dec. 2022, doi: 10.3390/bioengineering9120768.

- [19] "Επεξεργασία Ηλεκτροεγκεφαλογραφήματος υπό την Παρουσία Ηλεκτρομαγνητικής Ακτινοβολίας 1800MHz με Χρήση Πολλαπλής Συνολοκλήρωσης," 2008.
- [20] "Pictorial illustration of the classified waveforms | Download Scientific Diagram." [Online]. Available: https://www.researchgate.net/figure/Pictorial-illustration-of-theclassified-waveforms_fig1_360891538.
- [21] C. S. Nayak and A. C. Anilkumar, "EEG Normal Waveforms," *StatPearls*, pp. 1–6, 2023, [Online]. Available: https://www.ncbi.nlm.nih.gov/books/NBK539805/.
- [22] B. A. Moore and J. E. Barnett, "Niedermeyer's Electroencephalography: Basic Principles, Clinical Applications, and Related Fields," *Case Stud. Clin. Psychol. Sci. Bridg. Gap from Sci. to Pract.*, no. August, pp. 1–7, 2017, doi: 10.1093/MED/9780190228484.001.0001.
- [23] C. Mulert and L. Lemieux, "EEG fMRI: Physiological basis, technique, and applications," *EEG - fMRI Physiol. Basis, Tech. Appl.*, pp. 1–539, 2010, doi: 10.1007/978-3-540-87919-0.
- [24] D. McAuliffe *et al.*, "Increased mirror overflow movements in ADHD are associated with altered EEG alpha/beta band desynchronization," *Eur. J. Neurosci.*, vol. 51, no. 8, pp. 1815–1826, 2020, doi: 10.1111/EJN.14642,.
- [25] Y. A. Boytsova and S. G. Danko, "EEG differences between resting states with eyes open and closed in darkness," *Hum. Physiol.*, vol. 36, no. 3, pp. 367–369, 2010, doi: 10.1134/S0362119710030199.
- [26] T. Gao, D. Wu, and D. Yao, "EEG Scaling Difference Between Eyes-Closed and Eyes-Open Conditions by Detrended Fluctuation Analysis," in *Advances in Cognitive Neurodynamics ICCN 2007*, 2008, pp. 501–504.
- [27] S. G. Danko, "The reflection of different aspects of brain activation in the electroencephalogram: Quantitative electroencephalography of the states of rest with the eyes open and closed," *Hum. Physiol.*, vol. 32, no. 4, pp. 377–388, 2006, doi: 10.1134/S0362119706040013.
- [28] F. Amzica and F. H. L. Da Silva, "Cellular Substrates of Brain Rhythms," *Niedermeyer's Electroencephalogr.*, vol. 1, pp. 20–62, 2017, [Online]. Available: https://www.konstadaras.gr/product/niedermeyers-electroencephalography/.
- [29] M. A. B. Brazier and J. U. Casby, "Crosscorrelation and autocorrelation studies of electroencephalographic potentials," *Electroencephalogr. Clin. Neurophysiol.*, vol. 4, no. 2, pp. 201–211, 1952, doi: 10.1016/0013-4694(52)90010-2.
- [30] M. A. Guevara and M. Corsi-Cabrera, "EEG coherence or EEG correlation?," Int. J. Psychophysiol., vol. 23, no. 3, pp. 145–153, 1996, doi: 10.1016/S0167-8760(96)00038-4.
- [31] J. L. Cantero, M. Atienza, R. M. Salas, and C. M. Gómez, "Direct projections from the medial preoptic area to spinally-projecting neurons in Barrington's nucleus: An electron microscope study in the rat," *Neurosci. Lett.*, vol. 271, no. 3, pp. 167–170, 1999, doi: 10.1016/S0304-3940(99)00565-0,.
- [32] G. Adler, S. Brassen, and A. Jajcevic, "EEG coherence in Alzheimer's dementia," J. Neural Transm., vol. 110, no. 9, pp. 1051–1058, 2003, doi: 10.1007/S00702-003-0024-8,.
- [33] S. P. Deeny, C. H. Hillman, C. M. Janelle, and B. D. Hatfield, "Cortico-cortical communication and superior performance in skilled marksmen: An EEG coherence analysis," *J. Sport Exerc. Psychol.*, vol. 25, no. 2, pp. 188–204, 2003, doi: 10.1123/JSEP.25.2.188.
- [34] P. J. Franaszczuk and G. K. Bergey, "An autoregressive method for the measurement of synchronization of interictal and ictal EEG signals," *Biol. Cybern.*, vol. 81, no. 1, pp. 3–9, 1999, doi: 10.1007/S004220050540,.

- [35] M. Hardmeier, F. Hatz, H. Bousleiman, C. Schindler, C. J. Stam, and P. Fuhr, "Reproducibility of Functional Connectivity and Graph Measures Based on the Phase Lag Index (PLI) and Weighted Phase Lag Index (wPLI) Derived from High Resolution EEG," PLoS 9. 10, One. vol. no. p. e108648, 2014. doi: 10.1371/JOURNAL.PONE.0108648.
- [36] C. J. Stam, G. Nolte, and A. Daffertshofer, "Phase lag index: Assessment of functional connectivity from multi channel EEG and MEG with diminished bias from common sources," *Hum. Brain Mapp.*, vol. 28, no. 11, pp. 1178–1193, 2007, doi: 10.1002/HBM.20346,.
- [37] E. Bullmore and O. Sporns, "Complex brain networks: Graph theoretical analysis of structural and functional systems," *Nat. Rev. Neurosci.*, vol. 10, no. 3, pp. 186–198, 2009, doi: 10.1038/NRN2575;KWRD=BIOMEDICINE.
- [38] M. Rubinov and O. Sporns, "Complex network measures of brain connectivity: Uses and interpretations," *Neuroimage*, vol. 52, no. 3, pp. 1059–1069, 2010, doi: 10.1016/j.neuroimage.2009.10.003.
- [39] D. S. Bassett and E. Bullmore, "Small-world brain networks," *Neuroscientist*, vol. 12, no. 6, pp. 512–523, 2006, doi: 10.1177/1073858406293182,.
- [40] L. C. Freeman, "A Set of Measures of Centrality Based on Betweenness," *Sociometry*, vol. 40, no. 1, p. 35, 1977, doi: 10.2307/3033543.
- [41] "Brain Basics: Understanding Sleep | National Institute of Neurological Disorders and Stroke." [Online]. Available: https://www.ninds.nih.gov/health-information/public-education/brain-basics/brain-basics-understanding-sleep.
- [42] E. Wascher *et al.*, "Frontal theta activity reflects distinct aspects of mental fatigue.," *Biol. Psychol.*, vol. 96, pp. 57–65, Feb. 2014, doi: 10.1016/j.biopsycho.2013.11.010.
- [43] R. Bhardwaj, S. Parameswaran, and V. Balasubramanian, "Performance Comparison of Machine Learning and Deep Learning While Classifying Driver's Cognitive State," 2018, pp. 89–93, doi: 10.1109/ICIINFS.2018.8721374.
- [44] A. Othmani *et al.*, "EEG-based neural networks approaches for fatigue and drowsiness detection: A survey," *Neurocomputing*, vol. 557, no. July, 2023, doi: 10.1016/j.neucom.2023.126709.
- [45] K. Kunasegaran, A. M. H. Ismail, S. Ramasamy, J. V. Gnanou, B. A. Caszo, and P. L. Chen, "Understanding mental fatigue and its detection: a comparative analysis of assessments and tools," *PeerJ*, vol. 11, p. e15744, 2023, doi: 10.7717/PEERJ.15744/TABLE-3.
- [46] M. L. Elliott *et al.*, "General functional connectivity: Shared features of resting-state and task fMRI drive reliable and heritable individual differences in functional brain networks," *Neuroimage*, vol. 189, pp. 516–532, 2019, doi: 10.1016/J.NEUROIMAGE.2019.01.068,.
- [47] E. S. Finn *et al.*, "Functional connectome fingerprinting: Identifying individuals using patterns of brain connectivity," *Nat. Neurosci.*, vol. 18, no. 11, pp. 1664–1671, 2015, doi: 10.1038/NN.4135;TECHMETA=36,59;SUBJMETA=378,3920,631;KWRD=NEUR

10.1038/NN.4135;TECHMETA=36,59;SUBJMETA=378,3920,631;KWRD=NEUR AL+CIRCUITS,NEUROSCIENCE.

- [48] Y. Takagi, J. ichiro Hirayama, and S. C. Tanaka, "State-unspecific patterns of wholebrain functional connectivity from resting and multiple task states predict stable individual traits," *Neuroimage*, vol. 201, p. 116036, 2019, doi: 10.1016/J.NEUROIMAGE.2019.116036.
- [49] L. J. Nestor, T. V. Lim, T. W. Robbins, and K. D. Ersche, "Reduced brain connectivity underlying value-based choices and outcomes in stimulant use disorder," *Neuroimage* (*Amst*)., vol. 44, p. 103676, 2024, doi: 10.1016/J.NICL.2024.103676.

- [50] E. J. Doherty *et al.*, "Interdisciplinary views of fNIRS: Current advancements, equity challenges, and an agenda for future needs of a diverse fNIRS research community," *Front. Integr. Neurosci.*, vol. 17, p. 1059679, 2023, doi: 10.3389/FNINT.2023.1059679.
- [51] C. Delorme *et al.*, "COVID-19-related encephalopathy: a case series with brain FDG-positron-emission tomography/computed tomography findings," *Eur. J. Neurol.*, vol. 27, no. 12, pp. 2651–2657, 2020, doi: 10.1111/ENE.14478,.
- [52] "Παπαδόπουλος Νικόλαος-Ιωάννης (2017 Αριστοτέλειο Πανεπιστήμιο Θεσσαλονίκης (ΑΠΘ)) Μοντελοποίηση και απεικόνιση αυτοματοποιημένων φυσικοχημικών διεργασιών." [Online]. Available: https://freader.ekt.gr/eadd/index.php?doc=42596&lang=el#p=97.
- [53] R. Khanna and M. Awad, Efficient Learning Machines: Theories, Concepts, and Applications for Engineers and System Designers. 2015.
- [54] H. Simon, Neural Networks and Learning Machines, 3d ed. Pearson, 2008.
- [55] A. Sahoo, A. Rathi, S. Bashishth, S. Roy, and C. Pradhan, "Predictive Farmland Optimization and Crop Monitoring Using Artificial Intelligence Techniques," *Enabling Technol. Eff. Plan. Manag. Sustain. Smart Cities*, pp. 79–121, 2023, doi: 10.1007/978-3-031-22922-0_4.
- [56] G. N. Ahmad, H. Fatima, Shafiullah, A. S. Saidi, and Imdadullah, "Efficient Medical Diagnosis of Human Heart Diseases Using Machine Learning Techniques with and Without GridSearchCV," *IEEE Access*, vol. 10, pp. 80151–80173, 2022, doi: 10.1109/ACCESS.2022.3165792.
- [57] COVER TM, "Rates of Convergence for Nearest Neighbor Procedures." pp. 413–415, 1968.
- [58] "K-Nearest Neighbors (KNN). One of the simplest machine learning I... | by Anjali Kumari | Medium." [Online]. Available: https://medium.com/@somepuja489/knearest-neighbour-knn-e6721697e8d8.
- [59] "Linear Discriminant Analysis. Linear Discriminant Analysis is one of... | by Vivek Salunkhe | Medium." [Online]. Available: https://medium.com/@viveksalunkhe80/linear-discriminant-analysis-2b7bfc409f9b.
- [60] N. Cristianini and J. Shawe-Taylor, "An Introduction to Support Vector Machines and Other Kernel-based Learning Methods," An Introd. to Support Vector Mach. Other Kernel-based Learn. Methods, 2000, doi: 10.1017/CBO9780511801389.
- [61] "(PDF) SVM Classification with Linear and RBF kernels." [Online]. Available: https://www.researchgate.net/publication/279913074_SVM_Classification_with_Linear_and_RBF_kernels.
- [62] Y. Vichianin *et al.*, "Accuracy of Support-Vector Machines for Diagnosis of Alzheimer's Disease, Using Volume of Brain Obtained by Structural MRI at Siriraj Hospital," *Front. Neurol.*, vol. 12, 2021, doi: 10.3389/FNEUR.2021.640696,.
- [63] I. Guyon, J. Weston, S. Barnhill, and V. Vapnik, "Gene selection for cancer classification using support vector machines," *Mach. Learn.*, vol. 46, no. 1–3, pp. 389– 422, 2002, doi: 10.1023/A:1012487302797/METRICS.
- [64] H. Liu and H. Motoda, "Feature Selection for Knowledge Discovery and Data Mining," *Featur. Sel. Knowl. Discov. Data Min.*, 1998, doi: 10.1007/978-1-4615-5689-3.
- [65] "(PDF) Fast SFFS-Based Algorithm for Feature Selection in Biomedical Datasets." [Online]. Available: https://www.researchgate.net/publication/303658983 Fast SFFS-

Based Algorithm for Feature Selection in Biomedical Datasets.

[66] A. L. Blum and P. Langley, "Selection of relevant features and examples in machine learning," *Artif. Intell.*, vol. 97, no. 1–2, pp. 245–271, 1997, doi: 10.1016/S0004-

3702(97)00063-5.

- [67] GuyonIsabelle and ElisseeffAndré, "An introduction to variable and feature selection," *J. Mach. Learn. Res.*, vol. 3, pp. 1157–1182, 2003, doi: 10.5555/944919.944968.
- [68] R. J. Urbanowicz, M. Meeker, W. La Cava, R. S. Olson, and J. H. Moore, "Reliefbased feature selection: Introduction and review," *J. Biomed. Inform.*, vol. 85, pp. 189– 203, 2018, doi: 10.1016/j.jbi.2018.07.014.
- [69] J. R. Vergara and P. A. Estévez, "A Review of Feature Selection Methods Based on Mutual Information," *Neural Comput. Appl.*, vol. 24, no. 1, pp. 175–186, 2015, doi: 10.1007/s00521-013-1368-0.
- [70] Y. Roy, H. Banville, I. Albuquerque, A. Gramfort, T. H. Falk, and J. Faubert, "Deep learning-based electroencephalography analysis: a systematic review," *J. Neural Eng.*, vol. 16, no. 5, 2019, doi: 10.1088/1741-2552/ab260c.
- [71] I. Rakhmatulin, "Review of algorithms for predicting fatigue using EEG," 2024, [Online]. Available: https://arxiv.org/pdf/2402.09443.
- [72] R. Hooda, V. Joshi, and M. Shah, "A comprehensive review of approaches to detect fatigue using machine learning techniques," *Chronic Dis. Transl. Med.*, vol. 8, no. 1, pp. 26–35, 2022, doi: 10.1016/J.CDTM.2021.07.002.
- [73] C. A. Cos, A. Lambert, A. Soni, H. Jeridi, C. Thieulin, and A. Jaouadi, "Enhancing Mental Fatigue Detection through Physiological Signals and Machine Learning Using Contextual Insights and Efficient Modelling," *J. Sens. Actuator Networks 2023, Vol. 12, Page 77*, vol. 12, no. 6, p. 77, 2023, doi: 10.3390/JSAN12060077.
- [74] P. Sharma, J. C. Justus, M. Thapa, and G. R. Poudel, "Sensors and Systems for Monitoring Mental Fatigue: A systematic review," 2023, [Online]. Available: https://arxiv.org/pdf/2307.01666.
- [75] A. Laverghetta *et al.*, "A survey of fatigue measures and models," J. Def. Model. Simul., 2023, doi: 10.1177/15485129231158580;WEBSITE:WEBSITE:SAGE;JOURNAL:JOURNAL: DMSA;WGROUP:STRING:PUBLICATION.
- [76] L. J. Trejo *et al.*, "EEG-Based Estimation and Classification of Mental Fatigue," *Psychology*, vol. 6, no. 5, pp. 572–589, 2015, doi: 10.4236/PSYCH.2015.65055.
- [77] G. Yoo, H. Kim, and S. Hong, "Prediction of Cognitive Load from Electroencephalography Signals Using Long Short-Term Memory Network," *Bioengineering*, vol. 10, no. 3, p. 361, 2023, doi: 10.3390/BIOENGINEERING10030361.
- [78] C. Ye, Z. Yin, M. Zhao, Y. Tian, and Z. Sun, "Identification of mental fatigue levels in a language understanding task based on multi-domain EEG features and an ensemble convolutional neural network," *Biomed. Signal Process. Control*, vol. 72, p. 103360, 2022, doi: 10.1016/J.BSPC.2021.103360.
- [79] E. Karim *et al.*, "An EEG-based Cognitive Fatigue Detection System," *ACM Int. Conf. Proceeding Ser.*, pp. 131–136, 2023, doi: 10.1145/3594806.3594848/ASSETS/HTML/IMAGES/PETRA23-42-FIG7.JPG.
- [80] M. A. Al Imran, F. Nasirzadeh, and C. Karmakar, "Designing a practical fatigue detection system: A review on recent developments and challenges," *J. Safety Res.*, vol. 90, pp. 100–114, 2024, doi: 10.1016/J.JSR.2024.05.015.
- [81] G. Li *et al.*, "The impact of mental fatigue on brain activity: A comparative study both in resting state and task state using EEG," *BMC Neurosci.*, vol. 21, no. 1, pp. 1–9, 2020, doi: 10.1186/s12868-020-00569-1.
- [82] A. Lambert, A. Soni, A. Soukane, A. R. Cherif, and A. Rabat, "Artificial intelligence modelling human mental fatigue: A comprehensive survey," *Neurocomputing*, vol. 567, p. 126999, 2024, doi: 10.1016/J.NEUCOM.2023.126999.

- [83] V. Formánek and V. Juřík, "IMPROVING MACHINE LEARNING PREDICTION OF CONSTRUCTS: MENTAL FATIGUE," 2024, [Online]. Available: https://www.phil.muni.cz/en/research/publishing-and-editorial-activities-of-thefaculty/overview-of-publishing-and-scientific-activities/2399877.
- [84] H. Zhang, J. Wang, X. Geng, C. Li, and S. Wang, "Objective Assessments of Mental Fatigue During a Continuous Long-Term Stress Condition," *Front. Hum. Neurosci.*, vol. 15, p. 733426, 2021, doi: 10.3389/FNHUM.2021.733426/FULL.
- [85] C. Xiang, X. Fan, D. Bai, K. Lv, and X. Lei, "A resting-state EEG dataset for sleep deprivation," *Sci. Data*, vol. 11, no. 1, pp. 1–7, 2024, doi: 10.1038/s41597-024-03268-2.
- [86] C. J. Stam and E. C. W. van Straaten, "The organization of physiological brain networks," *Clin. Neurophysiol.*, vol. 123, no. 6, pp. 1067–1087, 2012, doi: 10.1016/J.CLINPH.2012.01.011.
- [87] L. Wang *et al.*, "Changes in hippocampal connectivity in the early stages of Alzheimer's disease: Evidence from resting state fMRI," *Neuroimage*, vol. 31, no. 2, pp. 496–504, 2006, doi: 10.1016/J.NEUROIMAGE.2005.12.033.
- [88] S. Sadaghiani and M. D'Esposito, "Functional Characterization of the Cingulo-Opercular Network in the Maintenance of Tonic Alertness," *Cereb. Cortex*, vol. 25, no. 9, pp. 2763–2773, 2015, doi: 10.1093/CERCOR/BHU072.
- [89] B. T. Jap, S. Lal, P. Fischer, and E. Bekiaris, "Using EEG spectral components to assess algorithms for detecting fatigue," *Expert Syst. Appl.*, vol. 36, no. 2, pp. 2352–2359, 2009, doi: 10.1016/J.ESWA.2007.12.043.