



ΠΑΝΕΠΙΣΤΗΜΙΟ
ΙΩΑΝΝΙΝΩΝ

ΣΧΟΛΗ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΤΗΛΕΠΙΚΟΙΝΩΝΙΩΝ
ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΤΗΛΕΠΙΚΟΙΝΩΝΙΩΝ
ΠΡΟΓΡΑΜΜΑ ΜΕΤΑΠΤΥΧΙΑΚΩΝ ΣΠΟΥΔΩΝ ΜΕ ΤΙΤΛΟ
«ΠΛΗΡΟΦΟΡΙΚΗ ΚΑΙ ΔΙΚΤΥΑ»

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΑΝΑΠΤΥΞΗ ΜΟΝΤΕΛΟΥ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΓΙΑ
ΚΑΤΗΓΟΡΙΟΠΟΙΗΣΗ ΑΝΟΙΑΚΩΝ
ΗΛΕΚΤΡΟΕΓΚΕΦΑΛΟΓΡΑΦΙΚΩΝ ΚΑΤΑΓΡΑΦΩΝ ΜΕ ΤΗ ΧΡΗΣΗ
ΤΕΧΝΙΚΩΝ ΕΠΕΞΕΡΓΑΣΙΑΣ ΣΗΜΑΤΟΣ

Μαρία Σταυροπούλου

Επιβλέπων: Τζάλλας Αλέξανδρος

Κοσμήτορας, Αναπληρωτής Καθηγητής

Άρτα, Ιούλιος, 2025

**DEVELOPMENT OF A MACHINE LEARNING MODEL FOR
CATEGORIZING DEMENTIAL EEG RECORDINGS USING SIGNAL
PROCESSING TECHNIQUES**

Εγκρίθηκε από τριμελή εξεταστική επιτροπή

Άρτα, 25/7/2025

ΕΠΙΤΡΟΠΗ ΑΞΙΟΛΟΓΗΣΗΣ

a. Επιβλέπων καθηγητής

Αλέξανδρος Τζάλλας,

b. Μέλος επιτροπής

Νίκος Γιαννακέας,

c. Μέλος επιτροπής

Πέτρος Καρβέλης,

© Σταυροπούλου, Μαρία, 2025.

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

Δήλωση μη λογοκλοπής

Δηλώνω υπεύθυνα και γνωρίζοντας τις κυρώσεις του Ν. 2121/1993 περί Πνευματικής Ιδιοκτησίας, ότι η παρούσα μεταπτυχιακή εργασία είναι εξ ολοκλήρου αποτέλεσμα δικής μου ερευνητικής εργασίας, δεν αποτελεί προϊόν αντιγραφής ούτε προέρχεται από ανάθεση σε τρίτους. Όλες οι πηγές που χρησιμοποιήθηκαν (κάθε είδους, μορφής και προέλευσης) για τη συγγραφή της περιλαμβάνονται στη βιβλιογραφία.

Σταυροπούλου, Μαρία

Υπογραφή

ΠΕΡΙΛΗΨΗ

Η άνοια είναι μια σημαντική νευρολογική διαταραχή που εμφανίζεται κυρίως στους ηλικιωμένους, επηρεάζοντας σημαντικά την ποιότητα ζωής τους. Η ανάλυση των σημάτων EEG παρουσιάζει μια πολλά υποσχόμενη μέθοδο για την ανίχνευση και την ταξινόμηση της άνοιας. Αυτή η μελέτη στοχεύει να αναπτύξει ένα μοντέλο μηχανικής μάθησης που χρησιμοποιεί τεχνικές επεξεργασίας σήματος για την κατηγοριοποίηση των εγγραφών ΗΕΓ από ασθενείς με άνοια. Η έρευνα θα εφαρμόσει διάφορες μεθόδους, όπως ανάλυση χρονικής συχνότητας και φιλτράρισμα, για την εξαγωγή σχετικών χαρακτηριστικών από τα δεδομένα EEG. Αυτά τα χαρακτηριστικά θα χρησιμοποιηθούν στη συνέχεια για την εκπαίδευση αλγορίθμων μηχανικής μάθησης όπως μηχανές διανυσμάτων υποστήριξης (SVM) και νευρωνικά δίκτυα, με στόχο την επίτευξη ακριβούς ταξινόμησης ΗΕΓ. Επιπλέον, θα διεξαχθεί μια διεξοδική βιβλιογραφική ανασκόπηση χρησιμοποιώντας επιστημονικές βάσεις δεδομένων όπως το Google Scholar και το Scopus για να εξεταστούν οι υπάρχουσες ερευνητικές μεθοδολογίες που σχετίζονται με την ανάλυση ΗΕΓ και τη μηχανική μάθηση σε αυτό το πλαίσιο. Αυτή η ανασκόπηση θα αναλύσει προηγούμενες τεχνικές, την απόδοσή τους και τα αποτελέσματά τους. Οι στόχοι της μελέτης περιλαμβάνουν τη διερεύνηση των τρεχουσών ερευνητικών τάσεων και βασικών χαρακτηριστικών στη διάγνωση άνοιας με βάση το ΗΕΓ, την ανασκόπηση και σύνθεση υπάρχουσών μεθοδολογιών, την ανάπτυξη και αξιολόγηση ενός αποτελεσματικού μοντέλου μηχανικής μάθησης για την ταξινόμηση ΗΕΓ και τον εντοπισμό προκλήσεων και μελλοντικών ευκαιριών σε αυτόν τον τομέα.

Λέξεις-κλειδιά: ΗΕΓ, Άνοια, Μηχανική Μάθηση, WEKA, PyEEG

ABSTRACT

Dementia is a major neurological disorder that occurs mainly in the elderly, significantly affecting their quality of life. EEG signal analysis presents a promising method for the detection and classification of dementia. This study aims to develop a machine learning model that uses signal processing techniques to categorize EEG recordings from dementia patients. The research will apply various methods, such as time-frequency analysis and filtering, to extract relevant features from EEG data. These features will then be used to train machine learning algorithms such as support vector machines (SVM) and neural networks, with the aim of achieving accurate EEG classification. In addition, a comprehensive literature review will be conducted using scientific databases such as Google Scholar and Scopus to examine existing research methodologies related to EEG analysis and machine learning in this context. This review will analyze previous techniques, their performance, and their results. The objectives of the study include exploring current research trends and key features in EEG-based dementia diagnosis, reviewing and synthesizing existing methodologies, developing and evaluating an effective machine learning model for EEG classification, and identifying challenges and future opportunities in this field.

Keywords: EEG, Dementia, Machine Learning, WEKA, PyEEG

ΠΙΝΑΚΑΣ ΠΕΡΙΕΧΟΜΕΝΩΝ

ΠΕΡΙΛΗΨΗ	ix
ABSTRACT	x
ΠΙΝΑΚΑΣ ΠΕΡΙΕΧΟΜΕΝΩΝ	xi
1. ΕΙΣΑΓΩΓΗ.....	xiii
1.1 ΑΝΤΙΚΕΙΜΕΝΟ ΚΑΙ ΣΗΜΑΣΙΑ ΤΗΣ ΕΡΕΥΝΑΣ.....	xiv
1.2 ΣΚΟΠΟΣ ΚΑΙ ΣΤΟΧΟΙ ΤΗΣ ΕΡΕΥΝΑΣ.....	xiv
1.3 ΔΟΜΗ ΤΗΣ ΕΡΓΑΣΙΑΣ	xv
2. ΘΕΩΡΗΤΙΚΟ ΥΠΟΒΑΘΡΟ	xvi
2.1 ΑΝΟΙΑ ΚΑΙ ΝΕΥΡΟΕΚΦΥΛΙΣΤΙΚΕΣ ΔΙΑΤΑΡΑΧΕΣ	xvii
2.2 ΗΛΕΚΤΡΟΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑ (ΗΕΓ): ΟΡΙΣΜΟΣ ΚΑΙ ΧΡΗΣΕΙΣ	xxvi
2.3 ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ ΚΑΙ ΕΠΕΞΕΡΓΑΣΙΑ ΒΙΟΣΗΜΑΤΩΝ	xxxi
3. ΒΙΒΛΙΟΓΡΑΦΙΚΗ ΑΝΑΣΚΟΠΗΣΗ	xxxvii
3.1 ΤΕΧΝΙΚΕΣ ΠΡΟΕΠΕΞΕΡΓΑΣΙΑΣ ΕΕΓ ΣΗΜΑΤΩΝ	xxxviii
3.2 ΜΕΘΟΔΟΙ ΕΞΑΓΩΓΗΣ ΧΑΡΑΚΤΗΡΙΣΤΙΚΩΝ	xli
3.3 ΜΟΝΤΕΛΑ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΓΙΑ ΕΕΓ ΚΑΤΗΓΟΡΙΟΠΟΙΗΣΗ	xlvi
3.4 ΑΠΟΤΕΛΕΣΜΑΤΑ ΚΑΙ ΣΥΜΠΕΡΑΣΜΑΤΑ ΑΠΟ ΠΡΟΗΓΟΥΜΕΝΕΣ ΈΡΕΥΝΕΣ .	xlvi
4. ΜΕΘΟΔΟΛΟΓΙΑ.....	l
4.1 ΑΝΑΛΥΣΗ ΒΑΣΗΣ ΔΕΔΟΜΕΝΩΝ ΕΕΓ	l
4.2 ΕΞΑΓΩΓΗ ΚΑΙ ΕΠΙΛΟΓΗ ΧΑΡΑΚΤΗΡΙΣΤΙΚΩΝ	liv
4.3 ΟΜΑΔΟΠΟΙΗΣΗ ΤΩΝ ΔΕΔΟΜΕΝΩΝ	lix
4.4 ΑΝΑΠΤΥΞΗ ΚΑΙ ΕΚΠΑΙΔΕΥΣΗ ΜΟΝΤΕΛΩΝ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ	lxv
5. ΑΠΟΤΕΛΕΣΜΑΤΑ ΚΑΙ ΑΝΑΛΥΣΗ	lxviii
5.1 ΠΑΡΟΥΣΙΑΣΗ ΠΕΙΡΑΜΑΤΙΚΩΝ ΑΠΟΤΕΛΕΣΜΑΤΩΝ	lxviii
5.2 ΣΥΓΚΡΙΣΗ ΜΕΘΟΔΩΝ ΚΑΙ ΜΟΝΤΕΛΩΝ	lxix
5.3 ΣΥΖΗΤΗΣΗ ΚΑΙ ΕΡΜΗΝΕΙΑ ΤΩΝ ΕΥΡΗΜΑΤΩΝ	lxxi

6.	ΣΥΜΠΕΡΑΣΜΑΤΑ ΚΑΙ ΜΕΛΛΟΝΤΙΚΗ ΈΡΕΥΝΑ.....	lxxiii
6.1	ΣΥΝΟΨΗ ΣΥΜΠΕΡΑΣΜΑΤΩΝ	lxxiii
6.2	ΠΕΡΙΟΡΙΣΜΟΙ ΤΗΣ ΠΑΡΟΥΣΑΣ ΜΕΛΕΤΗΣ	lxxiv
6.3	ΠΡΟΤΑΣΕΙΣ ΓΙΑ ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΚΑΙ ΕΠΕΚΤΑΣΗ	lxxvi
	ΠΑΡΑΡΤΗΜΑ - ΚΩΔΙΚΑΣ.....	lxxvii
	ΒΙΒΛΙΟΓΡΑΦΙΑ	lxxviii

1. ΕΙΣΑΓΩΓΗ

Η άνοια είναι μια πολύπλοκη νευροεκφυλιστική πάθηση που επηρεάζει εκατομμύρια άτομα παγκοσμίως, έχοντας σημαντικές επιπτώσεις τόσο για τους ασθενείς όσο και για το ευρύτερο κοινωνικοοικονομικό πλαίσιο. Ως εκ τούτου, είναι απαραίτητο να δοθεί προτεραιότητα στην έγκαιρη και ακριβή διάγνωση των διαφόρων μορφών άνοιας, ιδιαίτερα δεδομένου ότι η επιτυχία πολλών παρεμβάσεων συχνά επηρεάζεται από το στάδιο στο οποίο εισάγονται.

Τα τελευταία χρόνια, υπάρχει αυξανόμενο ερευνητικό ενδιαφέρον για τους βιοδείκτες, ιδιαίτερα την ηλεκτροεγκεφαλογραφία (EEG), καθώς προσφέρουν πολύτιμες γνώσεις για τη λειτουργική κατάσταση του εγκεφάλου με μη επεμβατικό και οικονομικά αποδοτικό τρόπο. Ταυτόχρονα, οι γρήγορες εξελίξεις στη μηχανική μάθηση επέτρεψαν την αυτόματη ανάλυση εκτεταμένων συνόλων δεδομένων, διευκολύνοντας την εξαγωγή ουσιαστικών συμπερασμάτων και μοτίβων, ακόμη και σε περιπτώσεις όπου δεν υπάρχουν διαθέσιμες προκαθορισμένες ετικέτες ή διαγνώσεις.

Η παρούσα διπλωματική εργασία διερευνά τη χρήση τεχνικών μηχανικής μάθησης χωρίς επίβλεψη για τη ομαδοποίηση σημάτων EEG που λαμβάνονται από άτομα με άνοια, με βάση χαρακτηριστικά που εξάγονται από καταγραφές εγκεφαλικής δραστηριότητας. Χρησιμοποιώντας αλγόριθμους ταξινόμησης, η μελέτη στοχεύει να αποκαλύψει πιθανά υποκείμενα μοτίβα που θα μπορούσαν να σχετίζονται με διάφορους τύπους ή στάδια άνοιας.

1.1 ΑΝΤΙΚΕΙΜΕΝΟ ΚΑΙ ΣΗΜΑΣΙΑ ΤΗΣ ΕΡΕΥΝΑΣ

Αντικείμενο της εργασίας αποτελεί η ανάπτυξη και αξιολόγηση μεθόδων μη επιβλεπόμενης μάθησης για την κατηγοριοποίηση EEG σημάτων ασθενών με άνοια, με στόχο την αναγνώριση πιθανών προτύπων εγκεφαλικής δραστηριότητας. Μέσω της εφαρμογής τεχνικών κατηγοριοποίησης όπως οι **K-Means**, **EM** και **Ιεραρχική Ομαδοποίηση**, επιχειρείται η αποκάλυψη κρυφών δομών στα δεδομένα EEG.

Η σημασία της παρούσας έρευνας έγκειται στο γεγονός ότι:

- Δεν απαιτεί προκαθορισμένες διαγνώσεις, καθιστώντας τη χρήσιμη σε περιβάλλοντα με ελλιπή κλινικά δεδομένα.
- Ενσωματώνει σύγχρονες τεχνικές επεξεργασίας σήματος για την εξαγωγή πληροφορίας από EEG δεδομένα.
- Συνεισφέρει στην κατανόηση της εγκεφαλικής δραστηριότητας που σχετίζεται με την άνοια, προσφέροντας πιθανές βάσεις για μελλοντικά διαγνωστικά εργαλεία.

1.2 ΣΚΟΠΟΣ ΚΑΙ ΣΤΟΧΟΙ ΤΗΣ ΕΡΕΥΝΑΣ

Σκοπός της παρούσας διπλωματικής είναι η ανάπτυξη και αξιολόγηση ενός αποτελεσματικού πλαισίου μηχανικής μάθησης για την κατηγοριοποίηση EEG σημάτων ατόμων με άνοια μέσω μη επιβλεπόμενων τεχνικών κατηγοριοποίησης.

Οι **επιμέρους στόχοι** της εργασίας είναι:

- Να εξετάσει τις κύριες κατευθύνσεις της έρευνας στην ανάλυση EEG σημάτων για την άνοια, μέσω βιβλιογραφικής ανασκόπησης (Google Scholar, Scopus).
- Να αναλύσει την υπάρχουσα ερευνητική γνώση σε τεχνικές προεπεξεργασίας, εξαγωγής χαρακτηριστικών και clustering EEG δεδομένων.

- Να εφαρμόσει τεχνικές επεξεργασίας σήματος (π.χ. time-frequency ανάλυση, φίλτρα) για την εξαγωγή διακριτών χαρακτηριστικών από τα EEG σήματα.
- Να εκπαιδεύσει και να αξιολογήσει αλγορίθμους clustering όπως οι K-Means, EM και Hierarchical Clustering σε δεδομένα EEG.
- Να αναδείξει προκλήσεις και ανοιχτά ερευνητικά ερωτήματα, εστιάζοντας στα όρια και τις δυνατότητες των μη επιβλεπόμενων προσεγγίσεων.

1.3 ΔΟΜΗ ΤΗΣ ΕΡΓΑΣΙΑΣ

Η παρούσα διπλωματική εργασία αναπτύσσεται σε έξι διακριτά κεφάλαια, καθένα εκ των οποίων συμβάλλει στην ολοκληρωμένη παρουσίαση του ερευνητικού έργου:

- **Κεφάλαιο 1 – Εισαγωγή:** Στο εισαγωγικό αυτό κεφάλαιο, τίθεται το πλαίσιο του προβλήματος, καθορίζεται το αντικείμενο και αναλύεται η σημασία της έρευνας. Επιπλέον, προσδιορίζονται οι επιδιωκόμενοι στόχοι και παρουσιάζεται η συνολική δομή της εργασίας.
- **Κεφάλαιο 2 - Θεωρητικό Υπόβαθρο:** Το κεφάλαιο αυτό επικεντρώνεται στην παροχή του απαραίτητου θεωρητικού υποβάθρου, καλύπτοντας βασικές έννοιες που αφορούν την άνοια, το Ηλεκτροεγκεφαλογράφημα (ΗΕΓ) και τις θεμελιώδεις αρχές της μηχανικής μάθησης.
- **Κεφάλαιο 3 - Βιβλιογραφική Ανασκόπηση:** Πραγματοποιείται εκτενής βιβλιογραφική ανασκόπηση προηγούμενων μελετών και ερευνητικών κατευθύνσεων στον τομέα της ανάλυσης σημάτων EEG για την άνοια, αναδεικνύοντας τα κυριότερα ευρήματα και τις μεθοδολογίες.
- **Κεφάλαιο 4 - Μεθοδολογία:** Αναλύεται λεπτομερώς η μεθοδολογία που ακολουθήθηκε, περιγράφοντας τη διαδικασία εξαγωγής χαρακτηριστικών από τα σήματα EEG, την εφαρμογή των αλγορίθμων ομαδοποίησης και τη δημιουργία των προβλεπτικών μοντέλων.

- **Κεφάλαιο 5 - Αποτελέσματα και Ανάλυση:** Παρουσιάζονται τα ευρήματα των πειραμάτων και διενεργείται κριτική ανάλυση των αποτελεσμάτων, συμπεριλαμβανομένης της συγκριτικής αξιολόγησης της απόδοσης των διαφορετικών εφαρμοζόμενων μεθόδων.
- **Κεφάλαιο 6 - Συμπεράσματα και Μελλοντική Έρευνα:** Το τελευταίο κεφάλαιο συνοψίζει τα βασικά συμπεράσματα της έρευνας, επισημαίνει τους περιορισμούς της παρούσας μελέτης και προτείνει κατευθύνσεις για περαιτέρω έρευνα και επέκταση του έργου.

2. ΘΕΩΡΗΤΙΚΟ ΥΠΟΒΑΘΡΟ

Σε αυτό το κεφάλαιο, θα διερευνήσουμε στοχαστικά τρεις βασικές θεωρητικές έννοιες που στηρίζουν την μετέπειτα έρευνα και ανάλυσή μας. Πρώτον, θα παρέχουμε μια εις βάθος επισκόπηση της άνοιας, εξετάζοντας τους διάφορους τύπους, τα χαρακτηριστικά της και τους υποκείμενους μηχανισμούς που διακρίνουν τη μια μορφή από την άλλη. Αυτή η ενότητα έχει σκοπό να δώσει μια σαφή και ολοκληρωμένη κατανόηση της πάθησης, συμπεριλαμβανομένων των κλινικών εκδηλώσεων της και της σημασίας της ακριβούς διάγνωσης. Στη συνέχεια, θα εισαγάγουμε την ηλεκτροεγκεφαλογραφία (ΗΕΓ), συζητώντας τις θεμελιώδεις αρχές, τις διαδικασίες και το ευρύ φάσμα των εφαρμογών που προσφέρει στη νευροεπιστήμη και την κλινική πρακτική. Αυτό το μέρος στοχεύει να υπογραμμίσει την αξία του ΗΕΓ ως μη επεμβατικής μεθόδου για την παρακολούθηση της εγκεφαλικής δραστηριότητας και τον αυξανόμενο ρόλο του στη διάγνωση νευρολογικών διαταραχών. Τέλος, θα εξετάσουμε τις τεχνικές μεθοδολογίες που χρησιμοποιήθηκαν στην έρευνά μας, με ιδιαίτερη προσοχή στην ενσωμάτωση τεχνικών μηχανικής μάθησης στην ανάλυση βιοδεικτών. Αυτό το τμήμα θα περιγράψει τους βασικούς αλγόριθμους, τις προσεγγίσεις επεξεργασίας δεδομένων και τις αναλυτικές στρατηγικές που μας επιτρέπουν να ερμηνεύουμε αποτελεσματικά πολύπλοκα νευρωνικά δεδομένα. Μέσα από μια ενδελεχή εξέταση αυτών των τριών θεμελιωδών εννοιών—άνοια, ΗΕΓ και μηχανική μάθηση—δημιουργείται ένα ισχυρό θεωρητικό πλαίσιο που θα καθοδηγήσει και θα υποστηρίξει τα κύρια στάδια της εργασίας.

2.1 ΑΝΟΙΑ ΚΑΙ ΝΕΥΡΟΕΚΦΥΛΙΣΤΙΚΕΣ ΔΙΑΤΑΡΑΧΕΣ

Η λέξη «άνοια» προέρχεται ετυμολογικά από τα αρχαία ελληνικά ("ἄ" + "νοῦς") και σημαίνει «χωρίς νου». Ωστόσο δεν χρησιμοποιούμε τον συγκεκριμένο όρο μόνο για περιγραφή της απώλειας μνήμης αλλά ευρύτερα για διαταραχές της νόησης. Ο ορισμός της άνοιας έχει λάβει πολλές διαφορετικές μορφές ανά τα χρόνια, με κοινό χαρακτηριστικό σε όλους την νοητική εξασθένηση. Πιο συγκεκριμένα, ο βασικός ορισμός της άνοια δηλώνει ότι είναι μία νευροεκφυλιστική διαταραχή που χαρακτηρίζεται από την σταδιακή εξασθένηση των γνωσιακών λειτουργιών επηρεάζοντας την καθημερινότητα του ατόμου σε βασικές δραστηριότητες.

Όλα τα είδη άνοιας σε όποια κατηγορία κι αν ανήκουν παρουσιάζουν κάποια κοινά κλινικά χαρακτηριστικά. Η απώλεια μνήμης και η αδυναμία εκτέλεσης βασικών καθημερινών δραστηριοτήτων, όπως να χάνουν τον προσανατολισμό τους, να μην ανταποκρίνονται στις απαιτήσεις της εργασίας τους, να έχουν γλωσσικά προβλήματα καθώς και μεγάλες αλλαγές στην συμπεριφορά, αποτελούν κοινά προβλήματα.

Ένα ακόμη χαρακτηριστικό που έχει παρατηρηθεί είναι ότι οι πιο πρόσφατες αναμνήσεις και οι νέες πληροφορίες χάνονται πιο γρήγορα ή δυσκολεύονται να τις συγκρατήσουν από ότι οι παλαιότερες. Χαρακτηριστικό παράδειγμα αποτελεί ότι ο ασθενής μπορεί να κάνει μια ερώτηση στην οποία θα λάβει απάντηση όμως επειδή δεν μπορεί να την συγκρατήσει μετά από λίγο θα ξανακάνει την ίδια ερώτηση.

Επιπλέον, οι γλωσσικές ικανότητες όπως η ικανότητα ονομασίας αντικειμένων (ανομία) ή η κατηγοριοποίηση λέξεων μειώνεται και μπορεί να φτάσει σε σημείο ο ασθενής να μην μπορεί να δομήσει μια ολοκληρωμένη πρόταση

Σε έναν εξελισσόμενο τύπο άνοιας όσο περισσότερο αναπτύσσεται η νόσος τόσο ο ασθενής θα εξαρτάται από τους οικείους του. Ο αποπροσανατολισμός στο χώρο αλλά και στον χρόνο καθώς και η περιπλάνηση του ατόμου είναι συχνό φαινόμενο της σταδιακής ανικανότητας τους να φροντίζουν τον εαυτό τους.

Οι τύποι άνοιας ποικίλουν ανάλογα την αναστρεψιμότητα, την εξέλιξη και τις συγκεκριμένες περιοχές του εγκεφάλου που επηρεάζονται.

➤ Νευροεκφυλιστικές Άνοιες

Οι νευροεκφυλιστικές άνοιες παίρνουν την ονομασία τους από στην σταδιακή εκφύλιση που υφίστανται ο εγκέφαλος. Με τον όρο εκφύλιση εννοούμε την αλλοίωση των ιστών ή των κυττάρων ενός οργάνου όπου επιφέρει την δυσλειτουργία του. Επομένως, ο εγκέφαλος εκφυλίζεται λόγω κάποιων κοινών ή διαφορετικών παραγόντων (ανάλογα τον τύπο άνοιας) με αποτέλεσμα να ατροφεί και να χάνει εκτός από τα δομικά του χαρακτηριστικά και τη λειτουργικότητά του. Ο ρυθμός της εκφύλισης μπορεί να είναι είτε γρήγορος (μήνες), είτε αργός (χρόνια).

A. Νόσος Alzheimer

Η νόσος Alzheimer είναι μια φλοιώδης άνοια, προοδευτικά εξελισσόμενη. Αποτελεί τον πιο κοινό τύπο νευροεκφυλιστικής άνοιας, αφού υπολογίζεται ότι περίπου 26.5 εκατομμύρια άτομα πλήττονται από αυτή την νόσο καθώς επίσης ότι έως το 2050 1 στους 85 ανθρώπους θα πάσχει από αυτή την νόσο.

Η ασθένεια είναι κατά ένα ελάχιστο ποσοστό κληρονομική. Ξεκινώντας από τα πρώτα στάδια της νόσου, ο πάσχων χάνει ή δεν θυμάται που άφησε τα προσωπικά του αντικείμενα, ξεχνάει σημαντικά ραντεβού, τηλεφωνεί και ρωτά συνέχεια τους οικείους του τα ίδια πράγματα. Σε μεταγενέστερα στάδια, ξεχνά πρόσωπα, ονόματα επωνύμων (ηθοποιών, πολιτικών) αλλά και γνωστών του, και αργότερα ακόμη και των οικείων του. Επιπλέον, δεν είναι ικανός να κλείσει κάποιο ραντεβού και ξεχνά πρόσφατα σημαντικά περιστατικά. Καταλήγοντας, στα τελικά στάδια που θα μπορούσαμε να πούμε ότι δεν έχει συναίσθηση των παροντικών καταστάσεων, δηλαδή ζει στο παρελθόν και συγχέει τα πρόσωπα της οικογένειάς του, για παράδειγμα θεωρεί ότι η κόρη του είναι η μητέρα του.

Ως προς τις διαταραχές του λόγου που παρατηρούνται στα πρώιμα στάδια περισσότερο διαταράσσεται η σημασιολογική μνήμη που επιφέρει την δυσκολία εξερεύνησης λέξεων, χρήση περιφράσεων ενώ μειώνεται σημαντικά και η ροή του λόγου. Επιπλέον η ικανότητα συζήτησης περιορίζεται οδηγώντας στην κοινωνική απομόνωση του πάσχοντα. Σε μεταγενέστερα στάδια η επανάληψη κρίνεται αναγκαία για την κατανόηση των βασικών εννοιών από το άτομο καθώς και χάνει τον ειρμό του. Στα τελικά στάδια της νόσου παρατηρείται πλήρης απώλεια παραγωγής και κατανόησης του λόγου.

Όσον αφορά τις αλλαγές στην συμπεριφορά των ασθενών με νόσο Alzheimer, στα πολύ πρώιμα στάδια οι ασθενείς φαίνονται ήρεμοι έως και αδιάφοροι ή απαθείς ενώ μπορεί να περιορίζουν τις κοινωνικές τους συναναστροφές. Γίνονται πιο απρόσεκτοι και η διορατικότητά τους μειώνεται αισθητά. Όσο εξελίσσεται η νόσος, εμφανίζονται και αισθήματα καχυποψίας και αυταπάτες καταλήγοντας σε οξυθυμία, επιθετικότητα ή ακόμη και κατάθλιψη. Ακόμα, δεν λείπουν οι διαταραχές στον ύπνο και οι ανησυχίες, ενώ πιο σπάνιο φαινόμενο αποτελεί η υπερσεξουαλικότητα.

Συμπερασματικά, στα τελευταία στάδια της νόσου ο πάσχων δεν μπορεί να αυτοσυντηρηθεί χρειάζεται συνεχή φροντίδα και προσοχή από κάποιον πλησίον του ή από έναν φροντιστή. Όλα τα συμπτώματα επιδεινώνονται και οι ασθενείς βρίσκονται με σοβαρά κινητικά ελλείμματα (ακαμψία ή σπαστικότητα), πλήρη ακράτεια και απώλεια όλων σχεδόν των νοητικών και γνωστικών λειτουργιών. Οι ασθενείς με νόσο Alzheimer πεθαίνουν συνήθως από πνευμονία ή μόλυνση 5 με 10 έτη μετά τη διάγνωση.

B. Νόσος των σωματιδίων Lewy

Επόμενος πιο γνωστός τύπος άνοιας είναι η νόσος των σωματιδίων Lewy, αφού στο ¼ των ηλικιωμένων ανοϊκών ασθενών που διενεργείται αυτοψία, ανευρίσκονται ενδοκυττάρια νευρωνικά έγκλειστα (σωμάτια Lewy) στον φλοιό και στο στέλεχος του εγκεφάλου. Η αιτία της νόσου σχετίζεται με τη συσσώρευση της πρωτεΐνης α-συνουκλεΐνης, η οποία σχηματίζει οργανωμένα σωματίδια εντός των νευρώνων, επηρεάζοντας τη λειτουργία των υπόλοιπων ενδοκυτταρικών οργανιδίων. Η πορεία της νόσου είναι ταχύτερη σε σύγκριση με αυτή της νόσου Alzheimer και συνοδεύεται από διακυμάνσεις στην ένταση των συμπτωμάτων.

Η άνοια με σωματίδια Lewy χαρακτηρίζεται από αλλαγές στη συμπεριφορά, στις νοητικές λειτουργίες, στην κίνηση, αλλά και από απώλεια μνήμης η οποία όμως δεν είναι πάντοτε εμφανής από τα αρχικά στάδιά της. Μερικοί ασθενείς αρχίζουν με κινητικά προβλήματα (που οδηγούν λανθασμένα στη διάγνωση της νόσου Πάρκινσον) και αργότερα παρουσιάζουν άνοια, οπότε θα γίνει η διάγνωση της άνοιας με σωματίδια Lewy. Μία άλλη ομάδα ασθενών θα αρχίσουν με νοητικά προβλήματα και προβλήματα μνήμης που αρχικά θα εκληφθούν ως νόσος Άλτσχάιμερ. Με τον καιρό όμως θα παρουσιάσουν ένα-δύο πιο χαρακτηριστικά συμπτώματα, τα οποία θα οδηγήσουν στην διάγνωση της άνοιας με σωματίδια Lewy. Τέλος, μια μικρή ομάδα ασθενών θα εκδηλώσουν πρώτα νευροψυχιατρικά

συμπτώματα, στα οποία μπορεί να συμπεριλαμβάνονται παραισθήσεις, συμπεριφορικά προβλήματα και δυσκολίες διεκπεραίωσης πολύπλοκων νοητικών δραστηριοτήτων. Και αυτοί οι ασθενείς, όμως, θα διαγνωστούν τελικά με άνοια με σωματίδια Lewy.

C. Μετωποκροταφική άνοια

Η μετωποκροταφική άνοια είναι μια σπάνια μορφή νευροεκφυλιστικής νόσου που επηρεάζει κυρίως τους μετωπιαίους και κροταφικούς λοβούς του εγκεφάλου. Η εκδήλωση της νόσου εμφανίζεται σε ηλικία 50-60 ετών και η συχνότητα της συμπίπτει με αυτή της νόσου Alzheimer. Στην πορεία της ανάπτυξης της νόσου εμφανίζονται τρία σύνδρομα, τα οποία αντανakλώνται στην διάχυτη διαταραχή του μετωπιαίου και του κροταφικού λοβού.

Η Άνοια μετωπιαίου τύπου είναι το πρώτο σύνδρομο και χαρακτηρίζεται από αλλαγές στην προσωπικότητα και τη συμπεριφορά του ατόμου. Αυτή η κατάσταση μπορεί να οδηγήσει σε μια ποικιλία αλλαγών συμπεριφοράς, συμπεριλαμβανομένης της απάθειας και της απελευθέρωσης. Τα άτομα μπορεί να εκδηλώνουν κοινωνικές συμπεριφορές που θεωρούνται ακατάλληλες, όπως να κάνουν άσεμνες χειρονομίες ή προσβλητικά σχόλια, να εμπλέκονται σε υπερφαγία ή να επιδεικνύουν χειριστικές ή απρόσεκτες συμπεριφορές. Συνήθως, οι νευροψυχολογικές αξιολογήσεις που αξιολογούν τις λειτουργίες του μετωπιαίου λοβού, όπως η προσοχή και οι εκτελεστικές λειτουργίες, μπορεί να παρουσιάζουν προκλήσεις. Ωστόσο, είναι σημαντικό να σημειωθεί ότι η μνήμη και η οπτικοχωρική αντίληψη συχνά παραμένουν άθικτες κατά τα πρώιμα στάδια της πάθησης.

Η Πρωτοπαθώς προϊούσα μη ρέουσα αφασία είναι το δεύτερο σύνδρομο κατά το οποίο υπάρχουν εμφανείς δυσκολίες στην ομιλία από την αρχή όμοιες με την αφασία τύπου Broca, δηλαδή εμφανίζουν φωνητικές παραφασίες. Ευτυχώς, άλλες γνωστικές λειτουργίες συνήθως παραμένουν σχετικά άθικτες κατά τα πρώιμα στάδια, όταν η ατροφία εντοπίζεται γενικά στις κυρίαρχες μετωπιαίες και κροταφικές περιοχές.

Τέλος, το τρίτο σύνδρομο κατονομάζεται Σημασιολογική άνοια και κύριο χαρακτηριστικό της είναι η ανομία, δηλαδή η αδυναμία κατονομασίας αντικειμένων, προσώπων και άλλων, πραγματοποιώντας συχνά σημασιολογικές παραφασίες. Στα αρχικά στάδια του συνδρόμου οι υπόλοιπες νοητικές λειτουργίες παραμένουν σχετικά ανεπηρέαστες και η ατροφία περιορίζεται στον αριστερό πρόσθιο και τον κάτω έξω κροταφικό λοβό.

Σε γενικές γραμμές, μπορούμε να παρατηρήσουμε ότι ορισμένα συμπτώματα παίζουν σημαντικό ρόλο στην μετωποκροταφική άνοια. Ζητήματα συμπεριφοράς όπως η απόσυρση, η αναστολή, η απάθεια, η κατάθλιψη και η κοινωνικά ακατάλληλη συμπεριφορά είναι αξιοσημείωτοι παράγοντες. Επιπλέον, διαταραχές που σχετίζονται με εκτελεστικές λειτουργίες και κίνηση ενισχύουν περαιτέρω το κλινικό προφίλ των ασθενών. Είναι σημαντικό να σημειωθεί ότι η μνήμη και ο προσανατολισμός τείνουν να παραμένουν σχετικά σταθεροί μέχρι τα τελευταία στάδια του συγκεκριμένου τύπου άνοιας.

D. Νόσος Parkinson

Η νόσος Parkinson επηρεάζει κυρίως την κινητική ικανότητα αλλά και την διάθεση του ασθενούς, ο οποίος συχνά χαρακτηρίζεται από βραδύτητα στις κινήσεις, δυσκαμψία, αστάθεια βάδισης και τρέμουλο, χαρακτηριστικό συνήθως του ενός άνω άκρου ή του ενός κάτω άκρου ή και των δύο από την ίδια πλευρά. Επιπλέον, μπορεί να συνυπάρχει και κατάθλιψη.

Όσον αφορά την νευροανατομική πλευρά της νόσου παρατηρείται σταδιακή απώλεια της μέλαινας ουσίας από τον μέσο εγκέφαλο. Όσο εξελίσσεται η νόσος δημιουργεί περαιτέρω προβλήματα για τον ασθενή προκαλώντας συμπτώματα άνοιας.

Αξίζει να αναφερθεί ότι υπάρχει κάποια επικάλυψη στα κλινικά και παθοανατομικά χαρακτηριστικά της νόσου του Πάρκινσον και της άνοιας με τα σωμάτια Lewy. Η διάκριση μεταξύ αυτών των δύο καταστάσεων βασίζεται κυρίως στο χρονοδιάγραμμα έναρξης της άνοιας σε σχέση με τα εξωπυραμιδικά συμπτώματα. Συγκεκριμένα, στην περίπτωση της άνοιας με σωμάτια Lewy, η άνοια τείνει να εκδηλώνεται είτε πριν είτε λίγο μετά την έναρξη του παρκινσονισμού, τυπικά εντός του ίδιου έτους. Αντίθετα, με τη νόσο του Πάρκινσον, η άνοια αναπτύσσεται συνήθως αρκετά χρόνια μετά την αρχική εμφάνιση των κινητικών συμπτωμάτων.

E. Νόσος Huntington

Κύριο χαρακτηριστικό της νόσου Huntington είναι ότι εμφανίζεται σε μικρότερες ηλικίες από την νόσο Alzheimer. Επιπλέον, παρατηρείται η ύπαρξη ακούσιων κινήσεων των άκρων του ασθενούς οι οποίες μοιάζουν με χορευτικές κινήσεις και για αυτόν τον λόγο αποκαλείτε και Χορεία του Huntington. Η νόσος αυτή είναι κληρονομική και

μεταβιβάζεται με αυτοσωματικό επικρατητικό τρόπο, με πλήρη διεισδυτικότητα και προκαλεί πρωτοπαθή έκπτωση νοητικών λειτουργιών, χορειακές κινήσεις και ψυχικές διαταραχές.

Οι εκτελεστικές λειτουργίες, η προσοχή και η οπτικοχωρική αντίληψη μπορεί συχνά να επηρεαστούν. Αξίζει να σημειωθεί ότι οι ψυχικές διαταραχές συχνά προηγούνται της εμφάνισης κινητικών συμπτωμάτων. Η κατάθλιψη είναι η πιο συχνά παρατηρούμενη ψυχιατρική εκδήλωση. Ωστόσο, τα άτομα μπορεί επίσης να εμφανίσουν απάθεια, μανία, άγχος, παρανοϊκές σκέψεις και διάφορες διαταραχές συμπεριφοράς. Η νόσος του Huntington, αν και σπάνια, εκδηλώνεται κυρίως στη μέση ενήλικη ζωή. Σε παθολογικό επίπεδο, προκύπτει από μια μετάλλαξη στο γονίδιο της πρωτεΐνης huntingtin που βρίσκεται στο χρωμόσωμα 4. Συγκεκριμένα, η κατάσταση εμφανίζεται όταν υπάρχουν περισσότερες από 39 επαναλήψεις της τριπλής νουκλεοτιδίων CAG, με 36 έως 39 επαναλήψεις να ταξινομούνται ως ενδιάμεσες.

➤ Αγγειακές άνοιες

Οι αγγειακές άνοιες σχετίζονται με δυσλειτουργία του κυκλοφορικού συστήματος και των αιμοφόρων αγγείων του εγκεφάλου, η οποία μπορεί να συμβεί με διάφορους τρόπους, όπως από εγκεφαλικό επεισόδιο που προκαλείται από φραγμένο αγγείο (ισχαιμικό έμφραγμα) λόγω θρόμβων αίματος ή λίπους (όπως αυτοί που σχετίζονται με τη χοληστερόλη). Όταν ένα αγγείο φράξει, δεν μπορεί πλέον να παρέχει αίμα στις περιοχές που εξυπηρετεί, οδηγώντας σε νέκρωση σε αυτές τις περιοχές. Εάν αυτές οι πληγείσες περιοχές είναι κρίσιμες για τη λειτουργία του εγκεφάλου, μπορεί να προκληθεί άνοια. Συνήθως, σε αυτές τις περιπτώσεις, η ζημιά αφορά πρωτίστως τη λευκή ουσία, η οποία παίζει βασικό ρόλο στη μετάδοση πληροφοριών. Ως αποτέλεσμα, τα συμπτώματα της αγγειακής άνοιας μπορεί να διαφέρουν σημαντικά από αυτά της νευροεκφυλιστικής άνοιας, η οποία επηρεάζει κυρίως τον εγκεφαλικό φλοιό (φαιά ουσία υπεύθυνη για την επεξεργασία πληροφοριών).

Είναι σημαντικό να τονιστεί ότι αρκετοί σημαντικοί παθογόνοι παράγοντες συμβάλλουν σε αυτά τα φαινόμενα, όπως τα επίπεδα χοληστερόλης, η αρτηριακή υπέρταση, το κάπνισμα, η παχυσαρκία, οι ελλείψεις σε φολικό οξύ και βιταμίνη B12, αυξημένη ομοκυστεΐνη (η οποία μπορεί να προκύψει σποραδικά από έλλειψη B12 και φολικού οξέος), διαταραχές του θυρεοειδούς και, σίγουρα, σακχαρώδη διαβήτη. Το τελευταίο όχι

μόνο προκαλεί αγγειακή βλάβη αλλά συμβάλλει και στον εκφυλισμό του εγκεφάλου μέσω διαφόρων άλλων μηχανισμών. Σε ορισμένες περιπτώσεις, η παρουσία πολυάριθμων ανωμαλιών μικρών αγγείων—λόγω αυτοάνοσων καταστάσεων, μεταβολικών διαταραχών (όπως αναφέρθηκε προηγουμένως) ή άλλων αγγειακών παθήσεων—μπορεί να εμποδίσει σοβαρά τη μικροκυκλοφορία στον εγκέφαλο. Ακόμη και όταν το σώμα προσπαθεί να αντισταθμίσει το έλλειμμα με παράπλευρες κυκλοφορίες, μπορεί να μην είναι επιτυχές, οδηγώντας σε γνωστικές βλάβες. Αξιοσημείωτα παραδείγματα αυτού περιλαμβάνουν άνοιες πολλαπλών εμφράκτων και νόσο των μικρών αγγείων.

➤ **Μεταβολικές άνοιες**

Όσον αφορά τις μεταβολικές άνοιες, καταστάσεις όπως η ηπατική και νεφρική ανεπάρκεια, οι διαταραχές του θυρεοειδούς, οι πορφυρίες και οι παθήσεις των επινεφριδίων (όπως η νόσος του Cushing) μπορεί να οδηγήσουν σε σταδιακή και ανεπαίσθητη εμφάνιση άνοιας. Αυτή η μείωση της νοητικής ικανότητας μπορεί να είναι ανησυχητική, καθώς, εάν δεν εντοπιστεί έγκαιρα, η άνοια μπορεί να εδραιωθεί σταθερά και να είναι δύσκολο να προληφθεί.

➤ **Άνοιες εκ συστηματικών νόσων**

Οι συστηματικές ασθένειες, συμπεριλαμβανομένης της σαρκοείδωσης, του ερυθρελάτου, της νόσου του Sjogren και της νόσου του Αδαμαντιάδη-Bechet, μπορούν να δημιουργήσουν προκλήσεις σε όλο το σώμα, οδηγώντας δυνητικά σε άνοια. Ενώ οι παθοφυσιολογικοί μηχανισμοί κάθε πάθησης διαφέρουν, οι εκτεταμένες επιπτώσεις αυτών των ασθενειών μπορούν να επηρεάσουν ολόκληρο το σώμα, συμπεριλαμβανομένου του εγκεφάλου. Επιπλέον, οι ασθενείς μπορεί να εμφανίσουν πιο οξεία προβλήματα του Κεντρικού Νευρικού Συστήματος, όπως εγκεφαλικά επεισόδια. Σε πολλές περιπτώσεις, ωστόσο, η βλάβη εμφανίζεται πιο σταδιακά και διακριτικά, καταλήγοντας τελικά σε άνοια.

➤ **Άνοιες από λοιμώδη νοσήματα**

Αυτή η κατηγορία περιλαμβάνει άνοιες που προέρχονται από μολυσματικές ασθένειες που επηρεάζουν τον εγκέφαλο, όπως η νόσος του Lyme, η σύφιλη, η φυματίωση, το AIDS, η νόσος Creutzfeldt-Jakob, καθώς και άλλες μικροβιακές, ιογενείς ή μυκητιακές λοιμώξεις. Αυτές οι καταστάσεις τείνουν να εξελίσσονται πιο γρήγορα σε σύγκριση με άλλες μορφές άνοιας.

➤ Άλλες άνοιες

Αυτή η κατηγορία περιλαμβάνει διάφορες μορφές άνοιας που προκύπτουν από λιγότερο κοινές καταστάσεις. Αν και αυτές οι μορφές μπορεί να μην εμφανίζονται τόσο συχνά όσο αυτές που αναφέρθηκαν προηγουμένως, ωστόσο υπάρχουν και απαιτούν κατάλληλη θεραπεία, καθώς και μέτρα πρόληψης. Μεταξύ των πιθανών αιτιών είναι οι όγκοι του εγκεφάλου, οι κρανιοεγκεφαλικές κακώσεις, ο υδροκέφαλος (είτε αποφρακτικός είτε με φυσιολογική πίεση), η έκθεση σε βαρέα μέταλλα (όπως ο μόλυβδος και ο υδράργυρος), ορισμένες φαρμακευτικές ουσίες (συμπεριλαμβανομένων των αντιχολινεργικών και βενζοδιαζεπινών) και η χρόνια χρήση αλκοόλ.

Καθώς η συχνότητα εμφάνισης της άνοιας αυξάνεται τα τελευταία χρόνια, ένας αυξανόμενος αριθμός ερευνητών αφιερώνει τις προσπάθειές του στην αποκάλυψη των πιθανών αιτιών αυτής της περίπλοκης ασθένειας. Τα ευρήματά τους υπογραμμίζουν μια σειρά από πολυπαραγοντικές επιρροές, συμπεριλαμβανομένων γενετικών, δημογραφικών, κοινωνικών, συμπεριφορικών και ψυχοσωματικών παραγόντων, μεταξύ άλλων.

Γενετικοί παράγοντες: Όσον αφορά τους γενετικούς παράγοντες, γίνεται κατανοητό ότι μεταλλάξεις σε ορισμένα γονίδια και συγκεκριμένες πρωτεΐνες μπορεί να συμβάλλουν στην ανάπτυξη άνοιας τύπου Alzheimer σε περίπου 50-60% των περιπτώσεων. Επιπλέον, άλλες καταστάσεις όπως η αγγειακή νόσος και οι μικτές μορφές άνοιας παίζουν επίσης ρόλο. Αξίζει να σημειωθεί ότι παράγοντες όπως οι τραυματισμοί στο κεφάλι, η υπερβολική κατανάλωση αλκοόλ και οι κινητικές διαταραχές όπως η νόσος του Huntington και η νόσος του Πάρκινσον, καθώς και η μόλυνση από τον ιό HIV, μπορεί να επηρεάσουν περαιτέρω τον κίνδυνο εμφάνισης άνοιας.

Νευροπαθολογικοί παράγοντες: Τα νευροπαθολογικά ευρήματα σχετίζουν την εμφάνιση άνοιας με μάζες νευροϊνικής, γεροντικές πλάκες και κενотоπιώδεις εκφυλίσεις. Ενώ αυτές οι αλλαγές μπορούν επίσης να παρατηρηθούν στη φυσιολογική διαδικασία γήρανσης, παρατηρούνται σταθερά στον εγκέφαλο ατόμων με νόσο του Αλτσχάιμερ. Είναι σημαντικό να σημειωθεί ότι η οριστική διάγνωση μπορεί να τεθεί μόνο μέσω ιστοπαθολογικής εξέτασης. Ως εκ τούτου, η κλινική διάγνωση της νόσου του Αλτσχάιμερ θα πρέπει να θεωρείται ως πιθανή και όχι βέβαιη, καθώς η οριστική ταυτοποίηση μπορεί να γίνει μόνο μεταθανάτια. Επιπλέον, άλλες καταστάσεις που σχετίζονται με αυτή τη διάγνωση μπορεί να περιλαμβάνουν σημαντική ατροφία του φλοιού, η οποία μπορεί να

ανιχνευθεί μέσω αξονικής τομογραφίας ή μαγνητικής τομογραφίας, καθώς και διεύρυνση των κοιλιών του εγκεφάλου και μειωμένος εγκεφαλικός μεταβολισμός της ακετυλοχολίνης.

Δημογραφικοί παράγοντες: Μεταξύ των δημογραφικών παραγόντων κινδύνου τονίζεται ότι το κατώτερο ηλικιακό όριο που σχετίζεται με την αύξηση του επιπολασμού της νόσου είναι στα 65 έτη. Όσον αφορά το φύλο, παρατηρείται κυρίως σε γυναίκες, ωστόσο τίθενται πολλοί παράμετροι τόσο από άποψη βιολογίας όσο και ως προς το μέσο όρο ζωής σε σχέση με το άλλο φύλο. Ένα ακόμη δημογραφικό χαρακτηριστικό που χρήζει ιδιαίτερης σημασίας στην συσχέτιση με την πρόκληση της νόσου αποτελεί το μορφωτικό επίπεδο στο οποίο βρίσκονται τα άτομα που προσβάλλονται. Πιο αναλυτικά, όταν λέμε χαμηλό μορφωτικό επίπεδο συμπεριλαμβάνεται και οι ποικίλες κοινωνικές, οικονομικές και υγειονομικές επιπτώσεις που επιβαρύνουν την ψυχοσωματική υγεία και συνδυαστικά συμβάλουν στην εκδήλωση της άνοιας. Από την άλλη πλευρά όμως, παρατηρείται ότι η άνοια τύπου Alzheimer έχει προσβάλλει προσωπικότητες υψηλού μορφωτικού διαμετρήματος. Επομένως, αυτό το πεδίο είναι ανοιχτό για μελλοντικές έρευνες αφού δεν έχουν εξαχθεί σαφή συμπεράσματα.

Κοινωνικοί και ψυχοσωματικοί παράγοντες: Οι κοινωνικοοικονομικοί παράμετροι που διερευνώνται προκειμένου να αποσαφηνιστεί η σχέση τους με την άνοια μπορούν να θεωρηθούν η ποιότητα και η ένταση της εργασίας, η ανεργία, οι διατροφικές συνήθειες και η υπερβολική κατανάλωση αλκοόλ. Παράλληλα, η κατάθλιψη σύμφωνα με ειδικούς αποτελεί έναν ακόμη παράγοντα εμφάνισης της άνοιας. Τέλος, είναι σημαντικό να σημειωθεί ότι ένας κοινός παράγοντας που σχετίζεται με την άνοια μπορεί να προέρχεται από τη χρήση ορισμένων φαρμακευτικών σκευασμάτων. Σε ορισμένες περιπτώσεις, αυτά τα φάρμακα μπορεί να οδηγήσουν σε γνωστικές διαταραχές, είτε ως αποτέλεσμα υπερδοσολογίας είτε λόγω ανισορροπίας στους νευροδιαβιβαστές.

2.2 ΗΛΕΚΤΡΟΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑ (ΗΕΓ): ΟΡΙΣΜΟΣ ΚΑΙ ΧΡΗΣΕΙΣ

Τα ηλεκτροεγκεφαλογραφήματα (ΗΕΓ) γίνονται όλο και περισσότερο απαραίτητο εργαλείο για την αξιολόγηση της εγκεφαλικής δραστηριότητας στη διάγνωση και τη διαχείριση διαφόρων ψυχικών και νευρολογικών καταστάσεων. Οι καταγραφές ΗΕΓ προσφέρουν πολύτιμες πληροφορίες για την ηλεκτρική δραστηριότητα του εγκεφάλου, με συγκεκριμένες παραμέτρους και μοτίβα που αντικατοπτρίζουν τη συνολική υγεία του εγκεφάλου. Η ανάλυση της ηλεκτρικής δραστηριότητας μέσω ΗΕΓ θεωρείται ως μια από τις πιο σημαντικές μεθόδους για τη διάγνωση νευρολογικών διαταραχών όπως επιληψία, όγκοι εγκεφάλου, τραύμα κεφαλής, διαταραχές ύπνου και άνοιας. Επιπλέον, τα ΗΕΓ μπορεί να συνιστώνται ως μέρος των στρατηγικών θεραπείας για ορισμένες ανωμαλίες και καταστάσεις συμπεριφοράς, όπως ο αυτισμός, οι διαταραχές προσοχής, οι μαθησιακές δυσκολίες και οι καθυστερήσεις ομιλίας.

Η ηλεκτροεγκεφαλογραφία (ΗΕΓ) όπως αναφέρθηκε είναι μια θεμελιώδης ηλεκτροφυσιολογική μέθοδος που έχει συμβάλει σημαντικά στην κατανόηση της λειτουργίας του ανθρώπινου εγκεφάλου για σχεδόν έναν αιώνα. Η ανάπτυξη της χρονολογείται από το 1929, όταν ο Γερμανός επιστήμονας Hans Berger εισήγαγε για πρώτη φορά αυτή την τεχνική για την καταγραφή της ηλεκτρικής δραστηριότητας του εγκεφάλου. Μόλις έξι χρόνια αργότερα, το 1935, εμφανίστηκαν οι πρώτες αναφορές ανθρώπινης δραστηριότητας ΗΕΓ από τις Ηνωμένες Πολιτείες, προσελκύοντας αυξανόμενο ενδιαφέρον τόσο από ακαδημαϊκούς όσο και από κλινικούς ερευνητές που επικεντρώθηκαν στη λειτουργία του εγκεφάλου. Αυτή η εκτεταμένη και πολύτιμη ιστορία επέτρεψε το ΗΕΓ να εξελιχθεί και να υποστηρίξει ένα ευρύ και ποικίλο φάσμα εφαρμογών.

Στη σύγχρονη νευροφυσιολογία, το ΗΕΓ κατέχει μια θέση μεγάλης σημασίας. Προσφέρει πληροφορίες σε πραγματικό χρόνο για τη δραστηριότητα του εγκεφάλου συλλαμβάνοντας τα ηλεκτρικά σήματα που παράγονται μέσα στον εγκέφαλο. Ως μη επεμβατική και οικονομικά αποδοτική τεχνική, το ΗΕΓ είναι ένα προσιτό και πρακτικό εργαλείο για την αξιολόγηση νευροφυσιολογικών λειτουργιών. Η αξιοσημείωτη χρονική του ανάλυση, με ακρίβεια επιπέδου χιλιοστών του δευτερολέπτου, το καθιστά ουσιαστική μέθοδο για την εξέταση δυναμικών εγκεφαλικών διεργασιών και την απόκτηση βαθύτερης κατανόησης

περίπλοκων γνωστικών και νευρολογικών φαινομένων. Η καταγραφή ΗΕΓ απαιτεί λεπτομερή τεχνική ρύθμιση για τη διασφάλιση της ποιότητας του σήματος.

Ηλεκτρόδια και ρύθμιση: Συνήθως, τα ηλεκτρόδια είναι από χρυσό ή χλωριούχο ασήμι/άργυρο και εφαρμόζονται απαλά στο τριχωτό της κεφαλής χρησιμοποιώντας μια αγωγίμη πάστα ή τζελ για να διασφαλιστεί χαμηλή αντίσταση και αξιόπιστη ποιότητα σήματος. Ειδικά καλύμματα ηλεκτροδίων χρησιμοποιούνται επίσης συνήθως για τη διευκόλυνση της συνεπούς τοποθέτησης. Για βέλτιστη κάλυψη και ανίχνευση επιληπτικών εκκενώσεων, συνιστάται το τυπικό σύστημα τοποθέτησης ηλεκτροδίων 10-20 ή η πιο ολοκληρωμένη διάταξη IFCN 25 ηλεκτροδίων (με βάση το σύστημα 10-10). Ένα ηλεκτρόδιο γείωσης, συνήθως τοποθετημένο στο μέτωπο, χρησιμοποιείται για τη γείωση του συστήματος και την ελαχιστοποίηση του ηλεκτρικού θορύβου. Συνιστάται να διατηρείται η αντίσταση μεταξύ των ηλεκτροδίων στην περιοχή από 100 έως 10.000 Ohms. Επιπλέον, συχνά περιλαμβάνονται επιπλέον κανάλια για ηλεκτροκαρδιογράφημα (ΗΚΓ) για παρακολούθηση της καρδιακής δραστηριότητας, ηλεκτρομυογραφία (ΗΜΓ) για ανίχνευση μυϊκής δραστηριότητας —ιδιαίτερα κατά τη διάρκεια ύποπτων κινητικών συμβάντων— και ηλεκτροοφθαλμογραφία (ΗΟΓ) για παρακολούθηση των κινήσεων των ματιών, που μπορεί να βοηθήσει στην αναγνώριση θορύβου.

Επεξεργασία και ενίσχυση σήματος: Οι μικρές τάσεις που παράγονται από τον εγκέφαλο ενισχύονται μέσω διαφορικής ενίσχυσης, η οποία συγκρίνει τις διαφορές τάσης μεταξύ ζευγών ηλεκτροδίων. Αυτά τα ενισχυμένα σήματα στη συνέχεια ψηφιοποιούνται και υποβάλλονται σε επεξεργασία από έναν υπολογιστή, επιτρέποντας στη δραστηριότητα να εμφανίζεται ως κυματομορφές (τάση έναντι χρόνου). Ο χρήστης έχει τη δυνατότητα να προσαρμόσει τις ρυθμίσεις ευαισθησίας (κέρδος) και φίλτρου όπως απαιτείται για να επιτύχει την πιο αποτελεσματική απεικόνιση και αξιολόγηση.

Αναγνώριση και μετριάσμός θορύβου: Οι καταγραφές ΗΕΓ μπορεί να επηρεαστούν σημαντικά από θορύβους που προέρχονται από διάφορες πηγές, όπως η μυϊκή δραστηριότητα του τριχωτού της κεφαλής (ΗΜΓ), οι κινήσεις των ματιών (ΗΟΓ), τα καρδιακά σήματα (ΗΚΓ), οι κινήσεις της γλώσσας και οι εξωτερικές ηλεκτρικές παρεμβολές. Επιπλέον, οι προσωρινές αποκολλήσεις ηλεκτροδίων μπορεί να εισάγουν θόρυβο. Για να ελαχιστοποιηθούν αυτά τα ζητήματα, συνιστάται η χρήση σταθερών συστημάτων ηλεκτροδίων χαμηλής σύνθετης αντίστασης, η διεξαγωγή εγγραφών σε ηλεκτρικά θωρακισμένα περιβάλλοντα και η διασφάλιση της ενδεδειγμένης προετοιμασίας

του ασθενούς και η σαφής καθοδήγηση. Συνίσταται επίσης ανεπιφύλακτα συγχρονισμένες εγγραφές βίντεο για τη διευκόλυνση της συσχέτισης των κλινικών συμβάντων με τα μοτίβα ΗΕΓ και για την αποτελεσματική αναγνώριση των θορύβων.

Η ηλεκτροεγκεφαλογραφία (ΗΕΓ) προσφέρει αξιοσημείωτη χρονική ανάλυση, επιτρέποντάς μας να παρακολουθούμε αποτελεσματικά τις γρήγορες αλλαγές στην εγκεφαλική δραστηριότητα. Ωστόσο, έχει ορισμένους περιορισμούς όσον αφορά τη χωρική ανάλυση. Αυτό οφείλεται κυρίως στο ότι τα ηλεκτρικά σήματα πρέπει να περάσουν από διάφορους βιολογικούς ιστούς - όπως ο εγκέφαλος, το εγκεφαλονωτιαίο υγρό, οι μήνιγγες, το κρανίο και το δέρμα - πριν φτάσουν στα ηλεκτρόδια του τριχωτού της κεφαλής. Αυτοί οι ιστοί μπορούν να εξασθενήσουν και να διαχέουν τα σήματα, γεγονός που καθιστά τον εντοπισμό της ακριβούς προέλευσης της δραστηριότητας στον εγκέφαλο αρκετά δύσκολο. Αυτό το ζήτημα, που συχνά αναφέρεται ως «αντίστροφο πρόβλημα», σημαίνει ότι το ΗΕΓ είναι ιδιαίτερα πολύτιμο για την ανίχνευση του χρονισμού των νευρικών συμβάντων, αλλά είναι λιγότερο ακριβές όταν πρόκειται για τον εντοπισμό των συγκεκριμένων πηγών τους. Ως εκ τούτου, για να αποκτηθούν ολοκληρωμένες γνώσεις, το ΗΕΓ συχνά συμπληρώνεται από άλλες τεχνικές νευροαπεικόνισης, όπως η μαγνητική τομογραφία (MRI), οι οποίες παρέχουν λεπτομερείς δομικές πληροφορίες. Σε αυτό το πλαίσιο, το ΗΕΓ θεωρείται καλύτερα ως εργαλείο για την αξιολόγηση της εγκεφαλικής λειτουργίας παρά ως λεπτομερής ανατομία.

Η κύρια και πιο ουσιαστική λειτουργία του ΗΕΓ είναι να βοηθήσει στην ανίχνευση και διερεύνηση της επιληψίας, μιας κατάστασης που χαρακτηρίζεται από επαναλαμβανόμενες κρίσεις. Το ΗΕΓ παρέχει πολύτιμες πληροφορίες στους κλινικούς ιατρούς βοηθώντας στον εντοπισμό του συγκεκριμένου τύπου επιληψίας, πιθανών πυροδοτήσεων επιληπτικών κρίσεων και των καταλληλότερων θεραπευτικών επιλογών. Η σημασία του στο πλαίσιο της επιληψίας είναι τόσο βαθιά που έχουν αναπτυχθεί διάφοροι εξειδικευμένοι τύποι εγγραφών ΗΕΓ για την ενίσχυση της ανίχνευσης και του εντοπισμού των επιληπτικών κρίσεων. Για παράδειγμα, οι επιληπτικές εκκρίσεις είναι γνωστό ότι επηρεάζονται από τον ύπνο, που εμφανίζονται πιο συχνά κατά τη διάρκεια του ύπνου με μη γρήγορη κίνηση των ματιών (NREM) παρά κατά τη διάρκεια της εγρήγορσης. Επιπλέον, οι συγχρονισμένες εγγραφές βίντεο-EEG είναι ιδιαίτερα ωφέλιμες για τον συσχετισμό κλινικών συμβάντων με την ηλεκτρική δραστηριότητα του εγκεφάλου, βοηθώντας στον προσδιορισμό του εάν

ένα συμβάν είναι επιληπτική κρίση και βοηθώντας στον εντοπισμό της περιοχής του εγκεφάλου από την οποία προέρχονται οι κρίσεις.

Εκτός από το ρόλο του στην επιληψία, το ΗΕΓ χρησιμοποιείται επίσης για τη διερεύνηση μιας ποικιλίας άλλων νευρολογικών καταστάσεων, τραυματισμοί στο κεφάλι και διάσειση, όγκοι εγκεφάλου, εγκεφαλίτιδα (φλεγμονή του εγκεφάλου) και διαταραχές ύπνου όπως η υπνική άπνοια. Το ΗΕΓ παίζει ζωτικό ρόλο στη διάγνωση, την ανίχνευση και τη συνεχή παρακολούθηση των νευρολογικών και γνωστικών διαταραχών. Θα παρέχουμε μια πιο λεπτομερή ανασκόπηση για το πώς χρησιμοποιείται το ΗΕΓ στη διερεύνηση της άνοιας σε επόμενο κεφάλαιο.

Το ΗΕΓ διαδραματίζει, επίσης, ζωτικό ρόλο στις μονάδες εντατικής θεραπείας (ΜΕΘ), ειδικά σε ασθενείς που παρουσιάζουν αλλοιωμένα επίπεδα συνείδησης. Είναι εξαιρετικά πολύτιμο για την επιβεβαίωση ή τον αποκλεισμό της παρουσίας μη σπασμωδικών κρίσεων ή επιληπτικής κατάστασης (NCSE), καταστάσεις που συχνά δεν είναι ανιχνεύσιμες μέσω τεχνικών νευροαπεικόνισης όπως η αξονική τομογραφία ή η μαγνητική τομογραφία. Η φορητότητα και η δυνατότητα παρακολούθησης του ΗΕΓ σε πραγματικό χρόνο το καθιστούν ιδιαίτερα κατάλληλο για χρήση δίπλα στο κρεβάτι στη ρύθμιση της ΜΕΘ. Επιπλέον, η συνεχής παρακολούθηση ΗΕΓ αναγνωρίζεται ολοένα και περισσότερο ως σημαντικό εργαλείο για την ανίχνευση δευτερογενών βλαβών του εγκεφάλου και ισχαιμίας σε βαρέως πάσχοντες ασθενείς, καθώς και για την αξιολόγηση του επιπέδου συνείδησης σε ασθενείς που λαμβάνουν ενδοφλέβια καταστολή ή βρίσκονται σε φαρμακολογικά επαγόμενο κώμα.

Εκτός από τις κλινικές του χρήσεις, το ΗΕΓ έχει γίνει ένα πολύτιμο εργαλείο στην έρευνα, ειδικά στα πεδία της γνωστικής νευροεπιστήμης και της μελέτης ψυχιατρικών διαταραχών. Η ικανότητά του να συλλαμβάνει τη δυναμική νευρωνική δραστηριότητα με εξαιρετική χρονική ανάλυση το καθιστά ιδιαίτερα κατάλληλο για την εξερεύνηση των νευρικών μηχανισμών που βρίσκονται κάτω από πολύπλοκες γνωστικές λειτουργίες.

Στον τομέα της γνωστικής νευροεπιστήμης, το ΗΕΓ χρησιμοποιείται εκτενώς για τη διερεύνηση θεμελιωδών νευρικών διεργασιών που στηρίζουν ανώτερες γνωστικές λειτουργίες. Μια ιδιαίτερα σημαντική εφαρμογή περιλαμβάνει την ανάλυση των δυνητικών που σχετίζονται με συμβάντα (ERP). Τα ERP αντιπροσωπεύουν ανεπαίσθητες διακυμάνσεις στην ηλεκτρική δραστηριότητα του εγκεφάλου που προκαλούνται από

συγκεκριμένα αισθητηριακά, γνωστικά ή κινητικά γεγονότα. Με τον μέσο όρο ενός μεγάλου αριθμού χρονικά ευθυγραμμισμένων πειραματικών δοκιμών, οι ερευνητές είναι σε θέση να εξετάσουν την αισθητηριακή, την αντιληπτική και τη γνωστική επεξεργασία με ακρίβεια επιπέδου χιλιοστών του δευτερολέπτου. Αυτή η εξαιρετική χρονική ανάλυση καθιστά το ΗΕΓ ιδιαίτερα πολύτιμο για την εξερεύνηση των πρώιμων σταδίων επεξεργασίας πληροφοριών και τις επακόλουθες μεταβάσεις από τις αισθητηριακές-αντιληπτικές δραστηριότητες σε γνωστικές λειτουργίες ανώτερης τάξης.

Το ΗΕΓ έχει αποδειχτεί καθοριστικό στη μελέτη των νευρικών μηχανισμών που κρύβουν την προσοχή και την αντίληψη, την κωδικοποίηση και ανάκτηση μνήμης και την επεξεργασία της γλώσσας. Επιπλέον, παίζει ζωτικό ρόλο στην προώθηση της κατανόησής μας για τη νευρωνική βάση της λήψης αποφάσεων και του εκτελεστικού ελέγχου, επιτρέποντας στους ερευνητές να εντοπίσουν συγκεκριμένους νευρικούς δείκτες που σχετίζονται με διάφορες γνωστικές διαδικασίες.

Στον τομέα της κλινικής νευροεπιστήμης, το ΗΕΓ είναι ένα πολύτιμο εργαλείο για τη διερεύνηση των νευρικών υποστρωμάτων διαφόρων ψυχιατρικών διαταραχών, όπως η κατάθλιψη, το άγχος και η σχιζοφρένεια. Για παράδειγμα, οι ανωμαλίες που παρατηρήθηκαν στη ζώνη α έχουν συσχετιστεί με την κατάθλιψη, ενώ οι ανωμαλίες στη ζώνη θ έχουν συνδεθεί με το άγχος. Η εφαρμογή των Δυνατοτήτων που σχετίζονται με Συμβάντα (ERPs) στο ΗΕΓ προσφέρει μια σημαντική σύνδεση μεταξύ της βασικής έρευνας της νευροεπιστήμης και της κλινικής πρακτικής. Μέσω λεπτομερούς εξέτασης των γνωστικών διεργασιών μέσω ERP, όπως η καταστολή P50 και η αρνητικότητα ασυμφωνίας (MMN), οι ερευνητές εντόπισαν συγκεκριμένα νευρικά ελλείμματα χαρακτηριστικά παθήσεων όπως η σχιζοφρένεια. Αυτό υπογραμμίζει τη δυνατότητα βασικών ερευνητικών εργαλείων να συμβάλλουν στην ανακάλυψη πολλά υποσχόμενων βιοδεικτών για ψυχιατρικές διαταραχές.

Τέτοιες εξελίξεις υποδηλώνουν ότι η χρησιμότητα του ΗΕΓ εκτείνεται πέρα από την απλή κατανόηση της λειτουργίας του εγκεφάλου, για να περιλαμβάνει την αναγνώριση νέων διαγνωστικών και προγνωστικών δεικτών. Επιπλέον, η ικανότητα του ΗΕΓ να διερευνά τους νευρικούς μηχανισμούς που κρύβουν την προσοχή, την αντίληψη, τη μνήμη, τη γλώσσα, τη λήψη αποφάσεων και τις εκτελεστικές λειτουργίες τονίζει τη σημασία του ως μέσου για την κατανόηση δυναμικών δικτύων εγκεφάλου. Η υψηλή χρονική του ανάλυση καθιστά το ΗΕΓ ιδιαίτερα κατάλληλο για την καταγραφή του τρόπου με τον οποίο

διαφορετικές περιοχές ή δίκτυα του εγκεφάλου αλληλεπιδρούν με την πάροδο του χρόνου κατά τη διάρκεια πολύπλοκων γνωστικών δραστηριοτήτων. Κατά συνέπεια, το ΗΕΓ διαδραματίζει κρίσιμο ρόλο όχι μόνο στη διασαφήνιση των γνωστικών διαδικασιών αλλά και στην προώθηση της κατανόησής μας για τη δυναμική δραστηριότητα του εγκεφάλου.

2.3 ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ ΚΑΙ ΕΠΕΞΕΡΓΑΣΙΑ ΒΙΟΣΗΜΑΤΩΝ

Η επεξεργασία βιοσημάτων είναι ένας κρίσιμος και συνεχώς εξελισσόμενος διεπιστημονικός τομέας που ενσωματώνει έννοιες από τη μηχανική, την επιστήμη των υπολογιστών και την υγειονομική περίθαλψη. Ο πρωταρχικός του στόχος είναι να εξάγει σημαντικές πληροφορίες από φυσιολογικά σήματα που παράγονται από το ανθρώπινο σώμα, συμπεριλαμβανομένων των Ηλεκτροκαρδιογραφημάτων (ΗΚΓ), Ηλεκτροεγκεφαλογραφημάτων (ΗΕΓ) και Ηλεκτρομυογραφημάτων (ΗΜΓ), καθώς και δεδομένων που λαμβάνονται από ιατρική απεικόνιση. Χρησιμοποιώντας εξελιγμένες τεχνικές επεξεργασίας σήματος, στατιστικές μεθόδους, μηχανική μάθηση (ML) και τεχνητή νοημοσύνη (AI), η ανάλυση βιοδεικτών συμβάλλει σημαντικά στην πρόοδο της ιατρικής έρευνας, στη βελτίωση των κλινικών πρακτικών και στην ανάπτυξη τεχνολογιών υγειονομικής περίθαλψης. Η ικανότητά του να παρέχει ακριβείς και έγκαιρες γνώσεις υπογραμμίζει τη σημασία του για τη διάγνωση, την παρακολούθηση και τη θεραπεία ενός ευρέος φάσματος ιατρικών καταστάσεων.

Η ενσωμάτωση της μηχανικής μάθησης στην επεξεργασία βιοδεικτών αναγνωρίζεται ολοένα και περισσότερο ως μια μεταμορφωτική εξέλιξη, προσφέροντας σημαντικές δυνατότητες βελτίωσης της έγκαιρης ανίχνευσης ασθενειών και ενίσχυσης των συνολικών αποτελεσμάτων υγειονομικής περίθαλψης. Ιδιαίτερα, η εφαρμογή μοντέλων βαθιάς μάθησης (DL) για την ανάλυση και την ερμηνεία βιοϊατρικών σημάτων έχει δείξει αξιοσημείωτη υπόσχεση στον ιατρικό τομέα.

Αυτά τα μοντέλα είναι ικανά να παρέχουν συνεχή, σε πραγματικό χρόνο παρακολούθηση των ζωτικών σημείων των ασθενών, προειδοποιώντας έτσι τους κλινικούς γιατρούς για πιθανά προβλήματα ή αποκλίσεις από την κανονική λειτουργία. Επιπλέον, τα μοντέλα βαθιάς μάθησης μπορούν να αναλύσουν εκτεταμένα βιοϊατρικά σύνολα δεδομένων σε βάθος, διευκολύνοντας τον εντοπισμό πολύπλοκων βιοδεικτών και επιτρέποντας

προβλέψεις για την εξέλιξη της νόσου. Αυτή η προγνωστική ικανότητα υποστηρίζει ταχύτερη διάγνωση και, τελικά, καλύτερα αποτελέσματα θεραπείας.

Η βαθιά μάθηση δεν είναι απλώς ένα συμπληρωματικό εργαλείο, αλλά χρησιμεύει ως καταλύτης που μεταμορφώνει θεμελιωδώς τον τρόπο προσέγγισης των βιοδεικτών στην ιατρική. Η βιβλιογραφία του 2025 τονίζει συχνά την υπεροχή της βαθιάς μάθησης έναντι των παραδοσιακών μεθόδων, σημειώνοντας την ικανότητά της να επιτυγχάνει έως και 15% αύξηση στην ακρίβεια ταξινόμησης και βελτιωμένη ευρωστία θορύβου σε κρίσιμους βιοδείκτες όπως το HKΓ, το HEΓ και το HMG.

Αυτές οι εξελίξεις αντιπροσωπεύουν όχι μόνο ποσοτικές βελτιώσεις αλλά και μια ποιοτική μετατόπιση, απομακρυνόμενη από την εντατική, χειρωνακτική, βασισμένη στους ειδικούς μηχανική χαρακτηριστικών, προς πιο αυτοματοποιημένες και αποτελεσματικές μεθοδολογίες. Η βελτιωμένη ακρίβεια και η στιβαρότητα του θορύβου είναι ιδιαίτερα σημαντικά για κλινική εφαρμογή, δεδομένου του εγγενούς θορύβου και της μεταβλητότητας των βιοδεικτών. Η ικανότητα της βαθιάς μάθησης να αυτοματοποιεί την εξαγωγή χαρακτηριστικών και να επιτρέπει την επεξεργασία σε πραγματικό χρόνο είναι ζωτικής σημασίας για την επανάσταση στην υγειονομική περίθαλψη, καθώς ανοίγει το δρόμο για πιο εξατομικευμένες και ακριβείς στρατηγικές θεραπείας.

Η προεπεξεργασία παίζει ζωτικό και απαραίτητο ρόλο στην ανάλυση βιοσημάτων, καθώς αυτά τα σήματα συχνά επηρεάζονται από εγγενή θόρυβο (όπως αυτό που προκαλείται από κίνηση ή εξωτερικές παρεμβολές) και άλλες εξωτερικές διαταραχές. Η διασφάλιση υψηλής ποιότητας δεδομένων είναι απαραίτητη για την αξιοπιστία οποιουδήποτε μοντέλου μηχανικής εκμάθησης. Τεχνικές όπως η αποθορυβοποίηση κυματιδίων και η κανονικοποίηση του φάσματος είναι σημαντικά εργαλεία για τον καθαρισμό του σήματος, συμβάλλοντας στη βελτιωμένη ακρίβεια του μοντέλου, στην αυξημένη ανθεκτικότητα στο θόρυβο και στη βελτιωμένη υπολογιστική απόδοση. Ενώ η βαθιά μάθηση είναι γνωστή για την ικανότητά της να μαθαίνει χαρακτηριστικά απευθείας από ακατέργαστα δεδομένα, η υπάρχουσα βιβλιογραφία τονίζει ότι οι τεχνικές προεπεξεργασίας συνεχίζουν να έχουν σημαντική σημασία.

Ειδικότερα, οι διαδικασίες απόκτησης και προεπεξεργασίας δεδομένων, μαζί με τη διατήρηση της ποιότητάς τους, αναγνωρίζονται ως μερικές από τις πιο απαιτητικές πτυχές της ανάπτυξης αποτελεσματικών μοντέλων βαθιάς μάθησης. Αυτό υπογραμμίζει ότι, παρά

την πρόοδο στις αυτοματοποιημένες μεθόδους εξαγωγής χαρακτηριστικών, η ποιότητα των βιοδεικτών εισόδου παραμένει θεμελιώδης περιορισμός. Κατά συνέπεια, η προεπεξεργασία δεν είναι παρωχημένη. Αντίθετα, εξελίσσεται για να υποστηρίξει και να βελτιστοποιεί την απόδοση των συστημάτων βαθιάς μάθησης, παραμένοντας ζωτικής σημασίας για τη διασφάλιση της αξιοπιστίας και της ευρωστίας τους σε κλινικές εφαρμογές.

Εκτός από την προεπεξεργασία, η εξαγωγή χαρακτηριστικών περιλαμβάνει στρατηγικές που μετατρέπουν ακατέργαστα σήματα σε πιο ερμηνεύσιμες και χρήσιμες αναπαραστάσεις για αλγόριθμους μηχανικής μάθησης. Τεχνικές όπως η ανάλυση χρόνου-συχνότητας και οι μηχανισμοί προσοχής επιτρέπουν την εξαγωγή ουσιαστικών πληροφοριών από βιοδείκτες. Η βαθιά μάθηση ξεπερνά σημαντικά τις παραδοσιακές προσεγγίσεις σε αυτό το στάδιο, επιτρέποντας την αυτοματοποιημένη εξαγωγή χαρακτηριστικών, μειώνοντας έτσι την εξάρτηση από τη χειροκίνητη παρέμβαση και την τεχνογνωσία στον τομέα.

Ο όρος μηχανική μάθηση περιλαμβάνει ένα σύνολο τεχνικών και μεθόδων για την ανάπτυξη αλγορίθμων που μπορούν να εκπαιδευτούν πάνω σε παλιά δεδομένα με τέτοιο τρόπο που να μπορούν να προβλέψουν νέα δεδομένα αλλά και να επιλύσουν τυχόν θέματα που δημιουργούνται. Το εκάστοτε μοντέλο μηχανικής μάθησης μπορεί να επεξεργαστεί τεράστιο όγκο δεδομένων με μεγάλη ταχύτητα και να αναγνωρίσει συσχετίσεις ή να εξάγει παρατηρήσεις που δεν είναι προφανείς. Τα εργαλεία αυτά είναι πολύτιμα για τις προβλέψεις εκδήλωσης μιας ασθένειας ή την διάγνωση της, σε συντομότερο χρονικό διάστημα από όσο θα έκανε ένας άνθρωπος για να το προβλέψει.

Ο τομέας της επεξεργασίας βιοσημάτων έχει γνωρίσει αξιοσημείωτες προόδους στην υιοθέτηση αλγορίθμων, που χαρακτηρίζεται από τη μετάβαση από τις παραδοσιακές τεχνικές μηχανικής μάθησης σε πιο προηγμένες αρχιτεκτονικές βαθιάς μάθησης. Η ανασκόπηση που πραγματοποιήθηκε από τους Alqudah και Moussavi (2025) προσφέρει μια καλά οργανωμένη ταξινόμηση αυτών των αρχιτεκτονικών βαθιάς μάθησης, οι οποίες χρησιμοποιούνται σε βασικές εργασίες όπως η ταξινόμηση αρρυθμιών, η ανίχνευση επιληπτικών κρίσεων και η κατάτμηση ανωμαλιών. Εκτός από τη βαθιά μάθηση, συνεχίζει να χρησιμοποιείται μια σειρά από παραδοσιακούς αλγόριθμους μηχανικής μάθησης, ανάλογα με τα χαρακτηριστικά των βιοδεικτών και τις συγκεκριμένες απαιτήσεις της εφαρμογής. Παρακάτω βλέπουμε ένα πίνακα με όλους τους αλγορίθμους.

Κατηγορία Αλγόριθμου	Αλγόριθμος	Βασικά Χαρακτηριστικά
Βαθιά Μάθηση (Deep Learning)	Συνελικτικά Νευρωνικά Δίκτυα (Convolutional Neural Networks, CNNs)	Ιδιαίτερα αποτελεσματικά για την επεξεργασία δεδομένων με δομή πλέγματος (π.χ., χρονοσειρές βιοσημάτων), όπου μπορούν να ανιχνεύσουν τοπικά μοτίβα.
	Αναδρομικά Νευρωνικά Δίκτυα (Recurrent Neural Networks, RNNs)	Κατάλληλα για την ανάλυση χρονοσειρών, καθώς μπορούν να διατηρήσουν πληροφορίες από προηγούμενα βήματα, καθιστώντας τα χρήσιμα για την κατανόηση της δυναμικής των βιοσημάτων.
	Μοντέλα βασισμένα σε Transformers	Αναδυόμενες αρχιτεκτονικές με εξαιρετικές επιδόσεις στην επεξεργασία ακολουθιών, αξιοποιώντας μηχανισμούς προσοχής για την καταγραφή μακροπρόθεσμων εξαρτήσεων στα δεδομένα.
	Υβριδικά Συστήματα	Συνδυάζουν στοιχεία από διαφορετικές αρχιτεκτονικές για να αξιοποιήσουν τα πλεονεκτήματά τους και να αντιμετωπίσουν συγκεκριμένες προκλήσεις.
	Ιεραρχική Ομαδοποίηση (Hierarchical Clustering)	Δεν απαιτεί προκαθορισμό του αριθμού των συστάδων.
	K-Means	Απλός, υπολογιστικά αποδοτικός, κατάλληλος για μεγάλα σύνολα δεδομένων.
	Fuzzy C-Means	Κατάλληλος για ασαφή δεδομένα, επιτρέπει εκχώρηση σημείων σε πολλαπλά συμπλέγματα.
	DBSCAN	Ανιχνεύει μη γραμμικές δομές συστάδων, ανθεκτικός σε θόρυβο και ακραίες τιμές.
	Ομαδοποίηση Γραφήματος (Graph Clustering)	Καταγράφει σχέσεις που μοιάζουν με δίκτυο σε βιοδείκτες, χρήσιμος για ανάλυση λειτουργικής συνδεσιμότητας.

Ομαδοποίηση (Clustering)	Μοντέλο-βασισμένη Ομαδοποίηση (π.χ., GMM)	Επιτρέπει πιθανολογική μοντελοποίηση επικαλυπτόμενων φυσιολογικών καταστάσεων.
	Νευρωνικά Δίκτυα (π.χ. SOM, LVQ, ART)	Μαθαίνουν πολύπλοκες μη γραμμικές δομές σημάτων, προσαρμόζονται δυναμικά σε αλλαγές βιοσημάτων σε πραγματικό χρόνο.
Παλινδρόμηση (Regression)	Γραμμική Παλινδρόμηση (Linear Regression)	Υψηλή υπολογιστική απόδοση, γρήγορη εκτέλεση, απλή ερμηνευσιμότητα.
	Ridge Linear Regression	Μειώνει την υπερπροσαρμογή, βελτιώνει την προγνωστική απόδοση.
	Δέντρο Παλινδρόμησης (Regression Tree)	Αποτελεσματική μοντελοποίηση μη γραμμικών σχέσεων, διαισθητική ερμηνευσιμότητα.
	Μοντέλο Τυχαίου Δάσους (Random Forest Model)	Ενισχύει την ακρίβεια πρόβλεψης, μειώνει την υπερπροσαρμογή, ανθεκτικό σε διάφορους τύπους βιοσημάτων.
	Τεχνητό Νευρωνικό Δίκτυο (Artificial Neural Network, ANN)	Κατάλληλο για μέτρια πολύπλοκη μη γραμμική μοντελοποίηση προτύπων, επεκτασιμότητα σε μεγάλα σύνολα δεδομένων βιοσημάτων.
	Βαθύ Νευρωνικό Δίκτυο (Deep Neural Network, DNN)	Ικανότητα ιεραρχικής εξαγωγής χαρακτηριστικών και αναπαράστασης πολύπλοκων δομών βιοσημάτων.

Ταξινόμηση (Classification)	Λογιστική Παλινδρόμηση (Logistic Regression)	Εκτελεί πιθανολογική ταξινόμηση με γραμμικό όριο απόφασης, κατάλληλη για δυαδική και πολλαπλών κλάσεων ταξινόμηση βιοσημάτων. Γρήγορη εκπαίδευση και υψηλή ερμηνευσιμότητα.
	Μηχανές Υποστήριξης Διανυσμάτων (Support Vector Machines, SVM)	Χειρίζονται αποτελεσματικά δεδομένα υψηλής διάστασης, επιλύουν μη γραμμικά προβλήματα μέσω συναρτήσεων πυρήνα, ανθεκτικές στην υπερπροσαρμογή.
	k-NN (k-nearest neighbors)	Μέθοδος βασισμένη σε στιγμιότυπα, ταξινομεί δεδομένα με βάση την εγγύτητα σε γείτονες, ιδανική για μικρής κλίμακας ή χωρικά κατανεμημένα σύνολα δεδομένων βιοσημάτων.
	Δέντρο Απόφασης (Decision Tree)	Χρησιμοποιεί ιεραρχική δομή δέντρου για τη διαίρεση δεδομένων με βάση συνθήκες χαρακτηριστικών.
	Τυχαίο Δάσος (Random Forest)	Μοντέλο συνόλου που συγκεντρώνει πολλαπλά δέντρα απόφασης για την ενίσχυση της ακρίβειας ταξινόμησης και της σταθερότητας.
	Gradient Boosting	Ελαχιστοποιεί διαδοχικά τα υπολειπόμενα σφάλματα για τη μοντελοποίηση πολύπλοκων προτύπων σε βιοσήματα, επιδεικνύει υψηλή ακρίβεια σε πραγματικές εφαρμογές.

Πίνακας 2.3 Αλγόριθμοι Μηχανικής Μάθησης

Η αξιολόγηση της απόδοσης των μοντέλων μηχανικής μάθησης και βαθιάς μάθησης στην επεξεργασία βιοσημάτων περιλαμβάνει τη χρήση περιεκτικών πλαισίων και μετρήσεων αξιολόγησης. Συνήθως, η απόδοση μετριέται μέσω μετρήσεων όπως η ακρίβεια

(precision), η ανάκληση (recall), οι F1-scores, η περιοχή κάτω από την καμπύλη Receiver Operating Characteristic (AUC-ROC) και οι μετρικές υπολογιστικής πολυπλοκότητας. Αυτές οι μετρήσεις προσφέρουν μια τυποποιημένη προσέγγιση για τη σύγκριση της αποτελεσματικότητας διαφορετικών μοντέλων.

Η μηχανική μάθηση, ιδιαίτερα η βαθιά μάθηση, εφαρμόζεται όλο και περισσότερο σε διάφορους τύπους βιοδεικτών, προσφέροντας πολλά υποσχόμενες λύσεις για τη διάγνωση, την παρακολούθηση και τη θεραπεία διαφορετικών ασθενειών. Στον τομέα της ανάλυσης σήματος EEG, έχουν σημειωθεί αξιοσημείωτες πρόοδοι στην ανίχνευση νευρολογικών καταστάσεων όπως η επιληψία, η νόσος Alzheimer και η νόσος του Parkinson. Συγκεκριμένα, μοντέλα βαθιάς μάθησης όπως τα Συνελικτικά Νευρωνικά Δίκτυα (CNN) και τα δίκτυα Μακροπρόθεσμης Βραχυπρόθεσμης Μνήμης (LSTM) έχουν χρησιμοποιηθεί για την ταξινόμηση σημάτων ΗΕΓ, επιτυγχάνοντας συχνά υψηλά επίπεδα ακρίβειας στον εντοπισμό επιληπτικών κρίσεων και στην πρόβλεψη της εξέλιξης της νόσου. Για παράδειγμα, μια μελέτη που διεξήχθη από τους He et al. (2020) απέδειξε ότι οι προσεγγίσεις βαθιάς μάθησης που εφαρμόζονται στα δεδομένα EEG θα μπορούσαν να ενισχύσουν αξιοσημείωτα την ανίχνευση επιληπτικών κρίσεων.

3. ΒΙΒΛΙΟΓΡΑΦΙΚΗ ΑΝΑΣΚΟΠΗΣΗ

Η άνοια, συμπεριλαμβανομένης της νόσου του Αλτσχάιμερ (AD) και της μείζονος γνωστικής διαταραχής (MCI), αποτελεί σημαντική παγκόσμια πρόκληση για την υγεία, που χαρακτηρίζεται από προοδευτική μείωση των γνωστικών λειτουργιών. Η έγκαιρη και ακριβής διάγνωση είναι ζωτικής σημασίας για τη χορήγηση της κατάλληλης ιατρικής θεραπείας και τη βελτίωση της ποιότητας ζωής των ασθενών. Συγκεκριμένα, οι παθολογικές αλλαγές μπορούν να ξεκινήσουν 15-20 χρόνια πριν από την εμφάνιση αξιοσημείωτων γνωστικών συμπτωμάτων, υπογραμμίζοντας τη σημασία της ανάπτυξης ταχύτερων και πιο ευαίσθητων μεθόδων ανίχνευσης για έγκαιρη παρέμβαση. Από αυτή την άποψη, η ηλεκτροεγκεφαλογραφία (EEG) παρουσιάζει μια πολλά υποσχόμενη, μη επεμβατική, εξαιρετικά προσιτή και οικονομικά αποδοτική προσέγγιση για τη διάγνωση της άνοιας.

Όπως αναφέρθηκε και σε προηγούμενα κεφάλαια, καταγράφοντας την ηλεκτρική δραστηριότητα του εγκεφάλου μέσω ηλεκτροδίων του τριχωτού της κεφαλής, το ΗΕΓ

παρέχει πολύτιμες πληροφορίες για τις εγκεφαλικές αλλοιώσεις που σχετίζονται με την άνοια. Οι έρευνες που έχουν γίνει στο παρελθόν δείχνουν ότι οι διακυμάνσεις σε διαφορετικές ζώνες συχνотήτων EEG μπορεί να χρησιμεύσουν ως πιθανοί βιοδείκτες για την άνοια. Η μη επεμβατική φύση και η προσιτή τιμή του καθιστούν το ΗΕΓ ένα πρακτικό διαγνωστικό εργαλείο που μπορεί να εφαρμοστεί ευρέως, ακόμη και σε χώρους πρωτοβάθμιας περίθαλψης. Μια τέτοια ευρεία προσβασιμότητα θα μπορούσε να επιτρέψει ταχύτερες διαγνώσεις, διευκολύνοντας την έγκαιρη θεραπεία και ενδεχομένως επιβραδύνοντας την εξέλιξη της νόσου βελτιώνοντας παράλληλα τα αποτελέσματα των ασθενών. Κατά συνέπεια, η προώθηση της ακρίβειας των διαγνωστικών με βάση το ΗΕΓ για την άνοια έχει άμεσα και ουσιαστικά κλινικά, καθώς και κοινωνικοοικονομικά, οφέλη.

Επιπλέον, οι τεχνικές μηχανικής μάθησης (ML) και βαθιάς μάθησης (DL) έχουν γίνει ταχέως διευρυνόμενοι τομείς έρευνας για την ταξινόμηση των σημάτων EEG. Αυτές οι προηγμένες μέθοδοι επιτρέπουν την ανάλυση μεγάλων συνόλων δεδομένων EEG για τον εντοπισμό λεπτών μοτίβων, υποστηρίζοντας έτσι την έγκαιρη διάγνωση καταστάσεων όπως η νόσος του Αλτσχάιμερ.

3.1 ΤΕΧΝΙΚΕΣ ΠΡΟΕΠΕΞΕΡΓΑΣΙΑΣ EEG ΣΗΜΑΤΩΝ

Η προεπεξεργασία αποτελεί ένα θεμελιώδες βήμα στην ανάλυση σημάτων EEG, καθώς είναι απαραίτητη για την αφαίρεση θορύβου, καθώς και για την προετοιμασία των δεδομένων για περαιτέρω ανάλυση και εξαγωγή χαρακτηριστικών. Η ποιότητα των προεπεξεργασμένων δεδομένων επηρεάζει άμεσα την αξιοπιστία και την ακρίβεια των μοντέλων μηχανικής μάθησης.

Τα βήματα προεπεξεργασίας περιλαμβάνουν:

Δειγματοληψία (Downsampling): Η μείωση του ρυθμού δειγματοληψίας των εγγραφών, για παράδειγμα με μείωση της δειγματοληψίας στα 125 Hz, μπορεί να βοηθήσει στη μείωση του υπολογιστικού φορτίου διατηρώντας παράλληλα την ακεραιότητα των σχετικών πληροφοριών συχνότητας.

Αφαίρεση DC Συνιστώσας: Η εξάλειψη του στοιχείου DC από κάθε κανάλι είναι ένα σημαντικό βήμα για την αντιμετώπιση και τη μείωση των μετατοπίσεων της γραμμής βάσης στο σήμα.

Φιλτράρισμα: Τα φίλτρα χρησιμοποιούνται για τη στόχευση συγκεκριμένων περιοχών συχνοτήτων και τη μείωση του θορύβου. Για παράδειγμα, μπορεί να εφαρμοστεί ένα υψηλοπερατό φίλτρο στα 3 Hz ή ένα φίλτρο ζώνης μεταξύ 1 Hz και 45 Hz χρησιμοποιώντας ένα φίλτρο πεπερασμένης απόκρισης παλμών (FIR). Αυτές οι τεχνικές είναι χρήσιμες για την ελαχιστοποίηση θορύβων χαμηλής συχνότητας, όπως οι κινήσεις του κεφαλιού, καθώς και θορύβων υψηλής συχνότητας, όπως η μουσική δραστηριότητα.

Αναφορά (Referencing): Οι εγγραφές ΗΕΓ αναφέρονται συχνά σε ένα κοινό σημείο, όπως ο μέσος όρος όλων των ηλεκτροδίων (κοινή μέση αναφορά), προκειμένου να ελαχιστοποιηθεί ο κοινός θόρυβος και να βελτιωθεί η χωρική ανάλυση.

Τμηματοποίηση (Windowing/Epoching): Οι συνεχείς εγγραφές ΗΕΓ χωρίζονται σε μικρότερα χρονικά διαστήματα ή εποχές. Αυτά τα τμήματα μπορεί να έχουν διάρκεια 250 χιλιοστών του δευτερολέπτου, 4 δευτερολέπτων ή 1 δευτερολέπτου και συχνά επικαλύπτονται για να βοηθήσουν στη διατήρηση της συνέχειας των δεδομένων.

Κανονικοποίηση (Normalization): Τεχνικές όπως η βαθμολογία Z ανά κανάλι ή η κανονικοποίηση ελάχιστων μέγιστων χρησιμοποιούνται για την κανονικοποίηση των δεδομένων, συμβάλλοντας στο να διασφαλιστεί ότι όλα τα χαρακτηριστικά είναι σε συγκρίσιμη κλίμακα. Αυτό το βήμα θεωρείται σημαντικό για τη βέλτιστη απόδοση πολλών αλγορίθμων μηχανικής μάθησης.

Πρόσφατες μελέτες έχουν εισαγάγει πιο προηγμένες τεχνικές προεπεξεργασίας. Για παράδειγμα, μια μελέτη χρησιμοποίησε έναν αγωγό προεπεξεργασίας που σχεδιάστηκε για την εξάλειψη του θορύβου από μεμονωμένα κανάλια EEG, χρησιμοποιώντας ένα δίκτυο φιλτραρίσματος EEG που βασίζεται στην προσοχή (attention-based EEG filtration network). Αυτό το μοντέλο, που αναφέρεται ως AT-AT denoising, εκπαιδεύτηκε στο σύνολο δεδομένων EEGdenoiseNet και αφαίρεσε επιτυχώς θορύβους από αόρατα δεδομένα, ενώ επίσης ενίσχυσε τη διαχωριστικότητα κλάσεων εντός του λανθάνοντος χώρου, υποδηλώνοντας βελτίωση στην ποιότητα του σήματος. Ομοίως, η μελέτη LEAD, η οποία εισήγαγε ένα ουσιαστικό θεμελιώδες μοντέλο για την ανίχνευση της νόσου του

Αλτσχάιμερ, περιλαμβάνει ένα ολοκληρωμένο pipeline που εκτείνεται από την επιλογή δεδομένων έως την προεπεξεργασία.

Η πρόοδος των τεχνικών προεπεξεργασίας—από τα βασικά φίλτρα έως τα εξελιγμένα μοντέλα βαθιάς μάθησης—αντανακλά μια σημαντική εξέλιξη στο πεδίο. Ιστορικά, η προεπεξεργασία EEG εξαρτιόταν από σταθερά φίλτρα και χειροκίνητη αφαίρεση θορύβων. Ωστόσο, η ενσωμάτωση προηγμένων νευρωνικών δικτύων για αυτόματη εξάλειψη θορύβου σηματοδοτεί μια κίνηση προς πιο αυτοματοποιημένες και προσαρμόσιμες προσεγγίσεις. Τέτοιες μέθοδοι έχουν τη δυνατότητα να βελτιώσουν ουσιαστικά την ποιότητα του σήματος και, με τη σειρά τους, να βελτιώσουν την απόδοση των μοντέλων μηχανικής μάθησης, ιδιαίτερα όταν αντιμετωπίζουμε πολύπλοκα και θορυβώδη κλινικά δεδομένα. Η ικανότητα αυτών των μοντέλων να «καθαρίζουν» αυτόματα τα σήματα βοηθά στην ελαχιστοποίηση της ανάγκης για εκτεταμένη χειροκίνητη προσπάθεια, συμβάλλοντας έτσι σε πιο αξιόπιστα και αναπαραγώγιμα αποτελέσματα.

Τεχνική	Σκοπός	Παραδείγματα Εφαρμογής
Φιλτράρισμα	Αφαίρεση θορύβου, απομόνωση ζωνών συχνοτήτων	Υψηλοπερατό φίλτρο 3 Hz , FIR φίλτρο 1-45 Hz
Δειγματοληψία	Μείωση υπολογιστικού φόρτου, διατήρηση πληροφορίας	Υποδειγματοληψία σε 125 Hz
Αφαίρεση DC Συνιστώσας	Εξάλειψη μετατοπίσεων γραμμής βάσης	Αφαίρεση DC από κάθε κανάλι
Αναφορά	Μείωση κοινού θορύβου, ενίσχυση χωρικής ανάλυσης	Αναφορά στο μέσο όρο
Τμηματοποίηση	Διαίρεση σε διαχειρίσιμα χρονικά παράθυρα	250 ms εποχές , 4s παράθυρα , 1s παράθυρα
Κανονικοποίηση	Ομαλοποίηση δεδομένων για βελτιωμένη ML απόδοση	Z-scoring ανά κανάλι , Min-max normalization
Αφαίρεση Θορύβου με ML	Αυτόματη αφαίρεση τεχνουργημάτων	Attention-based EEG filtration network (AT-AT denoising)

Πίνακας 3.1 Μέθοδοι προεπεξεργασίας EEG

3.2 ΜΕΘΟΔΟΙ ΕΞΑΓΩΓΗΣ ΧΑΡΑΚΤΗΡΙΣΤΙΚΩΝ

Η εξαγωγή χαρακτηριστικών είναι η διαδικασία μέσω της οποίας οι ακατέργαστες εγγραφές ΗΕΓ μετατρέπονται σε μια συλλογή ποσοτικών μεταβλητών που μπορούν να χρησιμοποιηθούν αποτελεσματικά από αλγόριθμους μηχανικής μάθησης. Αυτά τα χαρακτηριστικά μπορούν να προέρχονται από διαφορετικούς τομείς, συμπεριλαμβανομένου του χρόνου, της συχνότητας και της συνδεσιμότητας, καθώς και από μεθόδους μη γραμμικής ανάλυσης.

Χαρακτηριστικά Πεδίου Χρόνου: Αυτά τα χαρακτηριστικά παρέχουν πληροφορίες για τα θεμελιώδη χαρακτηριστικά του σήματος EEG. Περιλαμβάνουν μια σειρά βασικών στατιστικών μετρήσεων, όπως ελάχιστο, μέγιστο, μέσος όρος, ρίζα μέσου τετραγώνου (RMS), διακύμανση, τυπική απόκλιση, συντελεστής κορυφής, λοξότητα, κύρτωση και εκατοστημόρια (25η, 50η, 75η). Τέτοια μέτρα είναι πολύτιμα για την κατανόηση του εύρους, της κεντρικής τάσης, της μεταβλητότητας και της κατανομής της εγκεφαλικής δραστηριότητας. Επιπλέον, το πλήθος των μηδενικών διασταυρώσεων χρησιμεύει ως ένα απλό αλλά ενημερωτικό χαρακτηριστικό εντός του τομέα χρόνου.

Χαρακτηριστικά Πεδίου Συχνότητας: Αυτά τα χαρακτηριστικά είναι απαραίτητα για την ανάλυση ΗΕΓ, καθώς οι διακυμάνσεις στις ζώνες συχνοτήτων συνδέονται στενά με νευρολογικές παθήσεις.

- **Απόλυτες Συχνότητες Ζώνης:** Μετασχηματισμός Fast Fourier Transformation (FFT) χρησιμοποιείται για την εξαγωγή της ισχύος σε συγκεκριμένες ζώνες συχνοτήτων: Theta (4.0–7.9 Hz), Alpha (8.0–12.9 Hz), Low-Beta (13.0–20.9 Hz), High-Beta (21.0–30.9 Hz).
- **Peak Frequency (PF):** Ορίζεται ως η συχνότητα όπου παρατηρείται η υψηλότερη ισχύς εντός ενός συγκεκριμένου εύρους συχνοτήτων, π.χ., 4.0-12.9 Hz.
- **Λόγοι Συχνοτήτων:** Οι λόγοι μεταξύ των ζωνών συχνοτήτων, όπως Alpha προς Theta (A/T), Alpha προς Low-Beta (A/BL) και Theta προς Low-Beta (T/BL), έχουν αναφερθεί ως σημαντικοί βιοδείκτες.

- **Μετρικές Πυκνότητας Φασματικής Ισχύος (PSD):** Περιλαμβάνουν την κορυφή PSD, την κορυφή-προς-κορυφή PSD, και την ισχύ σε συγκεκριμένες ζώνες συχνοτήτων (Delta, Theta, Alpha, Beta, Gamma), καθώς και σχετικούς λόγους. Οι ασθενείς με AD τυπικά εμφανίζουν αυξημένη ισχύ χαμηλών συχνοτήτων και μειωμένη ισχύ υψηλών συχνοτήτων.
- **Άλλες Μετρικές Συχνότητας:** Μέγιστη συχνότητα, άθροισμα συχνοτήτων, μέση συχνότητα, διάμεση συχνότητα, συχνότητα κορυφής, ασυμμετρία συχνότητας και κύρτωση συχνότητας.
- **Τροποποιημένη Σχετική Ισχύ Ζώνης (RBP):** Χρησιμοποιείται για την ανάλυση έξι ζωνών συχνοτήτων EEG.

Χαρακτηριστικά Συνδεσιμότητας: Αυτά τα χαρακτηριστικά αξιολογούν τις λειτουργικές αλληλεπιδράσεις μεταξύ διαφορετικών περιοχών του εγκεφάλου.

- **Συνεκτικότητα (Coherence - CH):** Αυτή η μέτρηση αξιολογεί την ισχύ της συνδεσιμότητας συγκεκριμένης συχνότητας μεταξύ δύο καναλιών EEG. Καθορίζεται παίρνοντας το τετράγωνο του μεγέθους της διασταυρούμενης φασματικής πυκνότητας (CSD) και διαιρώντας το με το γινόμενο των αυτοφασματικών πυκνοτήτων (ASD).
- **Δυναμικά Χαρακτηριστικά Λειτουργικής Συνδεσιμότητας:** Μετρήσεις που περιλαμβάνουν τη μέση τιμή, τη διακύμανση, τη λοξότητα και την εντροπία Shannon - που προέρχονται από δεδομένα συνδεσιμότητας εγκεφάλου σε κατάσταση ηρεμίας - έχουν εξεταστεί ως πιθανοί βιοδείκτες.
- **Connectogram-COH:** Μια καινοτόμος στρατηγική μετασχηματισμού που δημιουργεί μια γραφική αναπαράσταση με χρονική ανάλυση, μετατρέποντας τμήματα EEG σε ένα γράφημα ομοιότητας βασισμένο στη συνεκτικότητα σήματος μεταξύ των διαθέσιμων καναλιών. Από την συμμετρική μήτρα συνεκτικότητας (adjacency matrix), το άνω τρίγωνο ισοπεδώνεται σε ένα διάγραμμα, το οποίο αντιπροσωπεύει το μοτίβο συνδεσιμότητας για ένα συγκεκριμένο χρονικό παράθυρο.

Εξειδικευμένα και Μη Γραμμικά Χαρακτηριστικά:

- **Μετρικές Εντροπίας:** Sample entropy, permutation entropy, spectral entropy, singular value decomposition entropy, και approximate entropy. Αυτές μετρούν την πολυπλοκότητα, την ακανόνιστοτητα και την προβλεψιμότητα των σημάτων EEG, με χαμηλότερες τιμές να υποδηλώνουν συχνά μειωμένη πολυπλοκότητα σε ασθενείς με AD.
- **Φράκταλ Διαστάσεις και Μετρικές Πολυπλοκότητας:** Katz fractal dimension, Higuchi fractal dimension, Detrended fluctuation analysis, Petrosian fractal dimension, Hjorth mobility, και Hjorth complexity. Αυτά τα χαρακτηριστικά μετρούν την πολυπλοκότητα και τη μεταβλητότητα του σήματος EEG, με χαμηλότερες τιμές σε ασθενείς με AD να υποδηλώνουν μειωμένη πολυπλοκότητα.

Η αυτόματη εκμάθηση χαρακτηριστικών μέσω μοντέλων βαθιάς μάθησης αντιπροσωπεύει μια αξιοσημείωτη πρόοδο στον τομέα. Μοντέλα όπως το xEEGNet και το LEAD αποτελούν παράδειγμα της δυνατότητας αυτόματης εξαγωγής χαρακτηριστικών, μειώνοντας έτσι την εξάρτηση από τη χειροκίνητη μηχανική χαρακτηριστικών. Για παράδειγμα, το xEEGNet χρησιμοποιεί παγωμένα αρχικά στρώματα με εκ των προτέρων αρχικοποιημένους πυρήνες που λειτουργούν ως φίλτρα προσαρμοσμένα στις ζώνες EEG (δέλτα, θήτα, άλφα, βήτα, γάμμα), μαζί με ένα επόμενο στρώμα που μαθαίνει ερμηνεύσιμες τοπολογίες του τριχωτού της κεφαλής, ειδικές για αυτές τις ζώνες. Αυτή η προσέγγιση υπογραμμίζει μια τάση προς μοντέλα που όχι μόνο διευκολύνουν την αυτόματη εξαγωγή χαρακτηριστικών αλλά και ενισχύουν την ερμηνευσιμότητα. Ομοίως, το LEAD χρησιμοποιεί αυτοεποπτευόμενη αντιθετική προκατάσταση τόσο σε επίπεδο δείγματος όσο και σε επίπεδο υποκειμένου για να καταγράψει αποτελεσματικά σημαντικά χαρακτηριστικά EEG.

Η εμφάνιση αυτών των προσεγγίσεων υποδεικνύει μια πιθανή σύγκλιση μεταξύ παραδοσιακών και αυτοματοποιημένων τεχνικών εξαγωγής χαρακτηριστικών. Ενώ οι παραδοσιακές μέθοδοι —όπως η φασματική ισχύς, η συνοχή και η εντροπία— προσφέρουν κλινικά ερμηνεύσιμα χαρακτηριστικά, τα μοντέλα βαθιάς μάθησης είναι ικανά να μαθαίνουν αυτόματα πιο αφηρημένα και δυνητικά πιο διακριτικά χαρακτηριστικά. Η ανάπτυξη μοντέλων όπως το xEEGNet, τα οποία ενσωματώνουν βιολογικά ενημερωμένα αρχικά στρώματα, προτείνει μια πολλά υποσχόμενη υβριδική προσέγγιση. Αυτή η στρατηγική στοχεύει να συνδυάσει τα δυνατά σημεία της αυτόματης

εκμάθησης χαρακτηριστικών με την κλινική ερμηνευτικότητα των συμβατικών μεθόδων, ενισχύοντας έτσι τη δύναμη και την αξιοπιστία των διαγνωστικών εργαλείων και συμβάλλοντας στη γεφύρωση του χάσματος μεταξύ της υψηλής απόδοσης που συχνά συνδέεται με τα μοντέλα «μαύρου κουτιού» βαθιάς μάθησης και της αναγκαιότητας για κλινική διαφάνεια.

Κατηγορία Χαρακτηριστικών	Συγκεκριμένες Μέθοδοι/Χαρακτηριστικά	Σημασία/Κλινική Σύνδεση
Πεδίο Χρόνου	Μέση τιμή, Διάμεση τιμή, Ελάχιστο, Μέγιστο, Τυπική Απόκλιση, Διακύμανση, Ασυμμετρία, Κύρτωση	Ποσοτικοποιούν το εύρος, τη διασπορά και την κατανομή της εγκεφαλικής δραστηριότητας
Πεδίο Συχνότητας	Peak Frequency (PF), Alpha/Theta Ratio (A/T), Alpha/Low-Beta Ratio (A/BL), Theta, Alpha, Low-Beta, High-Beta ισχύς	Αναδεικνύουν αλλαγές στην εγκεφαλική δραστηριότητα, όπως μειωμένη alpha και αυξημένη theta σε AD
Συνδεσιμότητα	Coherence (CH_A/T, CH_A/BL), Mean, Variance, Skewness, Shannon Entropy από συνδεσιμότητα, Connectogram-COH	Μετρούν τη συγχρονικότητα και τις λειτουργικές αλληλεπιδράσεις μεταξύ περιοχών του εγκεφάλου
Μη-Γραμμικά/Πολυπλοκότητας	Sample Entropy, Permutation Entropy, Spectral Entropy, Approximate Entropy, Katz Fractal Dimension, Higuchi Fractal Dimension, Hjorth Mobility, Hjorth Complexity	Ποσοτικοποιούν την πολυπλοκότητα, την ακανόνιστοτητα και τη μεταβλητότητα του σήματος, μειωμένη σε AD
Αυτόματη Εκμάθηση (DL)	Προ-αρχικοποιημένοι πυρήνες για ζώνες EEG, τοπολογίες τριχωτού κεφαλής, self-supervised contrastive features	Εξάγουν αφηρημένα και ερμηνεύσιμα χαρακτηριστικά αυτόματα

Πίνακας 3.2 Μέθοδοι εξαγωγής χαρακτ.

3.3 ΜΟΝΤΕΛΑ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΓΙΑ EEG ΚΑΤΗΓΟΡΙΟΠΟΙΗΣΗ

Η επιλογή του καταλληλότερου μοντέλου μηχανικής μάθησης είναι απαραίτητη για την επίτευξη ακριβούς ταξινόμησης των σημάτων EEG στη διάγνωση της άνοιας. Το πεδίο έχει διερευνήσει τη χρήση τόσο συμβατικών αλγορίθμων όσο και αρχιτεκτονικών αιχμής βαθιάς μάθησης.

Τα παραδοσιακά μοντέλα μηχανικής μάθησης έχουν αποτελέσει τη βάση για την κατηγοριοποίηση σημάτων EEG για πολλά χρόνια.

- **Extreme Gradient Boosting (Xgboost):** Αυτός ο αλγόριθμος, ο οποίος αξιοποιεί τα δέντρα αποφάσεων και τις μεθόδους συνόλου, είναι ευρέως αναγνωρισμένος για την αποτελεσματικότητα και τη δημοτικότητα του. Βελτιώνει την παραδοσιακή ενίσχυση κλίσης ενσωματώνοντας χαρακτηριστικά όπως η τακτοποίηση για την αποφυγή υπερβολικής προσαρμογής, η υποστήριξη για παράλληλους και κατανεμημένους υπολογισμούς και εξελιγμένες τεχνικές κλαδέματος δέντρων. Έχει χρησιμοποιηθεί αποτελεσματικά σε συνδυασμό με την Recursive Feature Elimination with Cross-Validation (RFECV) για τη διάκριση μεταξύ ασθενών με άνοια και υγιών μαρτύρων, με αποτέλεσμα υψηλή ισορροπημένη ακρίβεια.
- **Random Forests (RF):** Πρόκειται για μια κλασική μέθοδος μηχανικής μάθησης που χρησιμοποιήθηκε ευρέως πριν το 2017. Μια συγκριτική μελέτη έδειξε ότι ένα μοντέλο RFECV-RF πέτυχε ακρίβεια 93.28%.
- **Support Vector Machines (SVM):** Επίσης μια κλασική μέθοδος μηχανικής μάθησης, η οποία ήταν δημοφιλής πριν την επικράτηση των μοντέλων βαθιάς μάθησης.

Τα μοντέλα βαθιάς μάθησης έχουν φέρει επανάσταση στην ανάλυση σημάτων EEG, λόγω της ικανότητάς τους να μαθαίνουν αυτόματα ιεραρχικά χαρακτηριστικά από τα ακατέργαστα δεδομένα.

- **Convolutional Neural Networks (CNNs):** Τα συνελκτικά νευρωνικά δίκτυα (CNN) χρησιμοποιούνται εκτενώς στην ανάλυση σημάτων EEG λόγω της ισχυρής

ικανότητάς τους να αναγνωρίζουν χωρικά και χρονικά μοτίβα. Για παράδειγμα, ένα μοντέλο CNN ενισχυμένο με χαρακτηριστικά δυναμικής συνδεσιμότητας -όπως η μέση τιμή, η διακύμανση, η λοξότητα και η εντροπία Shannon- επέδειξε υψηλή ακρίβεια στη διάκριση μεταξύ υποτύπων άνοιας (AD, FTD) και υγιών μαρτύρων. Επιπλέον, αρχιτεκτονικές όπως το ResNet, μια εξειδικευμένη μορφή του CNN, έχει αποδειχθεί ότι υπερέχουν άλλων μοντέλων, συμπεριλαμβανομένων των VGG16, InceptionV3, EfficientNetB7 και DenseNet121, επιτυγχάνοντας εντυπωσιακή ακρίβεια 99,49% με εικόνες Connectogram-COH, οι οποίες χρησιμεύουν ως γραφικές αναπαραστάσεις δεδομένων EEG. Επιπλέον, τα CNN αναγνωρίζονται συχνά για την αποτελεσματικότητά τους στη μοντελοποίηση σημάτων EEG εντός του πεδίου χρόνου.

- **Temporal Convolutional Networks (TCNs) και Long Short-Term Memory (LSTM) Networks:** Ένα πλαίσιο που ενσωματώνει δίκτυα Temporal Convolutional Networks (TCN) και Long Short-Term Memory (LSTM) δίκτυα έχει προταθεί για την αποτελεσματική ταξινόμηση της μετωποκροταφικής άνοιας (FTD), της νόσου του Alzheimer (AD) και των υγιών ελέγχων, επιδεικνύοντας ιδιαίτερα υψηλή ακρίβεια. Αυτοί οι τύποι δικτύων είναι ιδιαίτερα κατάλληλοι για την ανάλυση δεδομένων χρονοσειρών, όπως τα σήματα EEG.
- **Transformer-based classifiers:** Έχουν σημειώσει άνοδο από το 2018 και μετά, ωθώντας την ακρίβεια πάνω από το 90% σε ορισμένα datasets. Όπως και τα CNN, μπορούν να μοντελοποιήσουν σήματα EEG στο πεδίο του χρόνου.
- **xEEGNet:** Έχει αναπτυχθεί ένα νέο, συμπαγές και εξηγήσιμο νευρωνικό δίκτυο ειδικά προσαρμοσμένο για ανάλυση δεδομένων EEG. Αυτό το μοντέλο βασίζεται στην αρχιτεκτονική ShallowNet, αλλά μειώνει σημαντικά τον αριθμό των παραμέτρων —μόνο 168, που είναι περίπου 200 φορές λιγότερες από το ShallowNet— διατηρώντας παράλληλα την ερμηνευτικότητα και την ευρωστία έναντι της υπερβολικής προσαρμογής. Η ερμηνευσιμότητα του μοντέλου επιτυγχάνεται μέσω της χρήσης παγωμένων αρχικών στρωμάτων με προ-αρχικοποιημένους πυρήνες που στοχεύουν συγκεκριμένες περιοχές EEG, ένα σε βάθος συνελικτικό δεύτερο στρώμα σχεδιασμένο για τοπολογίες του τριχωτού της κεφαλής και την ενσωμάτωση του Global Average Pooling. Η ανάπτυξη του xEEGNet υπογραμμίζει μια σημαντική τάση στην ιατρική τεχνητή νοημοσύνη: την

αυξανόμενη ανάγκη για εξηγήσιμα μοντέλα (XAI). Η επίτευξη ερμηνευσιμότητας μέσω βιολογικά ενημερωμένων αρχιτεκτονικών είναι εξίσου σημαντική με την απόδοση, ενισχύοντας μεγαλύτερη κλινική εμπιστοσύνη και διασφαλίζοντας την ασφαλή εφαρμογή. Επιπλέον, η σημαντική μείωση των παραμέτρων καταδεικνύει ότι οι μικρότερες αρχιτεκτονικές μπορούν να είναι εξίσου αποτελεσματικές, γεγονός που συμβάλλει στη μείωση των υπολογιστικών απαιτήσεων και ενισχύει την προσβασιμότητα της τεχνητής νοημοσύνης σε κλινικά περιβάλλοντα με περιορισμένους πόρους.

- **LEAD (Large Foundation Model for EEG-Based AD Detection):** Το LEAD αποτελεί το πρώτο μεγάλο foundation model ειδικά για την ανίχνευση AD βασισμένο σε EEG. Χρησιμοποιεί αυτοεποπτευόμενη αντιθετική προεκπαίδευση τόσο σε επίπεδο δείγματος όσο και σε επίπεδο θέματος, ακολουθούμενη από λεπτομέρεια σε πολλαπλά σύνολα δεδομένων (11 για προεκπαίδευση και 5 για λεπτομέρεια) για την αποτελεσματική αντιμετώπιση της μεταβλητότητας μεταξύ των θεμάτων. Η ανάπτυξη του LEAD σηματοδοτεί μια σημαντική πρόοδο, εισάγοντας την έννοια των "foundation models" - τα οποία εκπαιδεύονται σε εκτεταμένα και διαφορετικά σύνολα δεδομένων και στη συνέχεια προσαρμόζονται σε συγκεκριμένες εργασίες - εντός του τομέα EEG. Αυτή η προσέγγιση βοηθά να ξεπεραστούν δύο σημαντικές προκλήσεις: η σπανιότητα μεγάλων συνόλων δεδομένων για ισχυρή εκμάθηση χαρακτηριστικών και η μειωμένη απόδοση που προκαλείται από τη μεταβλητότητα μεταξύ των θεμάτων. Με την εκμάθηση γενικεύσιμων χαρακτηριστικών από ένα ευρύ φάσμα δεδομένων, αυτά τα μοντέλα έχουν τη δυνατότητα να διευκολύνουν πιο ισχυρά και προσαρμόσιμα διαγνωστικά εργαλεία, μειώνοντας έτσι την εξάρτηση από περιορισμένα σύνολα δεδομένων και ενισχύοντας την κλινική εφαρμογή.
- **Γεωμετρική Μηχανική Μάθηση (Geometric Machine Learning):** Αυτή η αναδυόμενη προσέγγιση δίνει έμφαση στην εξερεύνηση των υποκείμενων γεωμετρικών δομών χαμηλής διάστασης μέσα σε δεδομένα εγκεφαλικών κυμάτων υψηλών διαστάσεων. Χρησιμοποιεί τεχνικές όπως ο Fast Fourier Transform, Laplacian eigenmap, ένα διακριτό ανάλογο της ροής Ricci (μέσω της έννοιας της καμπυλότητας Ricci του Ollivier) και Graph Convolutional Networks (GCN) για σκοπούς μείωσης διαστάσεων και ταξινόμησης. Δεδομένου ότι τα δεδομένα EEG

είναι εγγενώς υψηλών και πολύπλοκων διαστάσεων, η γεωμετρική μηχανική μάθηση παρέχει μια νέα προοπτική, θέτοντας ότι ένα υποκείμενο γεωμετρικό πλαίσιο χαμηλής διάστασης μπορεί να αντιστοιχεί σε σημασιολογικές σκέψεις ή νοητικές καταστάσεις. Η επιτυχία αυτής της μεθοδολογίας στην αποκάλυψη τέτοιων δομών και στην επίτευξη ανταγωνιστικών επιδόσεων υπογραμμίζει τη δυνητική σημασία της κατανόησης της «γεωμετρίας» των δεδομένων EEG. Αυτή η κατανόηση θα μπορούσε να είναι καθοριστική για την προώθηση της ανάπτυξης πιο αποτελεσματικών και ερμηνεύσιμων μοντέλων, που ξεπερνούν τις παραδοσιακές αναλύσεις που βασίζονται σε χαρακτηριστικά.

3.4 ΑΠΟΤΕΛΕΣΜΑΤΑ ΚΑΙ ΣΥΜΠΕΡΑΣΜΑΤΑ ΑΠΟ ΠΡΟΗΓΟΥΜΕΝΕΣ ΈΡΕΥΝΕΣ

Οι πρόσφατες έρευνες στον τομέα της κατηγοριοποίησης ανοιακών καταγραφών EEG με τη χρήση μηχανικής μάθησης έχουν επιδείξει εντυπωσιακά αποτελέσματα, αλλά έχουν επίσης αναδείξει σημαντικούς περιορισμούς και προκλήσεις που πρέπει να αντιμετωπιστούν για την κλινική εφαρμογή. Ορισμένες πτυχές που εντόπισα είναι:

- **Xgboost με RFECV:** Μια πρόσφατη μελέτη χρησιμοποίησε ένα μοντέλο Xgboost σε συνδυασμό με την Recursive Feature Elimination with Cross-Validation (RFECV) για να διακρίνει τους ασθενείς με άνοια από τους υγιείς μάρτυρες. Το μοντέλο επέδειξε εντυπωσιακή απόδοση, επιτυγχάνοντας ισορροπημένη ακρίβεια 97,05% χρησιμοποιώντας μόνο ένα επιλεγμένο χαρακτηριστικό (Συχνότητα αιχμής - PF1). Επιπλέον, η ευαισθησία και η ειδικότητα αναφέρθηκαν ως 97,96% και 96,14%, αντίστοιχα.
- **xEEGNet:** Το xEEGNet είναι ένα συμπαγές και ερμηνεύσιμο νευρωνικό δίκτυο που εμφανίζει συγκρίσιμη διάμεση απόδοση (μόνο -1,5% απόκλιση από το ShallowNet) με μέση σταθμισμένη ακρίβεια 53,7%. Ωστόσο, το πιο αξιοσημείωτο επίτευγμά του είναι ότι χρησιμοποιεί 200 φορές λιγότερες παραμέτρους από το ShallowNet και μειώνει σημαντικά τη μεταβλητότητα της απόδοσης.

- **Πολλαπλοί Αλγόριθμοι ML (με βάση χαρακτηριστικά χρόνου-συχνότητας):** Μια στρατηγική που χρησιμοποίησε 43 χαρακτηριστικά χρόνου-συχνότητας μαζί με 10 συμπιεστές δεδομένων έδειξε εντυπωσιακά αποτελέσματα, επιτυγχάνοντας τέλεια ακρίβεια στις δυαδικές ταξινομήσεις μεταξύ υγιών ατόμων (C) και ατόμων με ήπια γνωστική εξασθένηση (MCI), καθώς και μεταξύ υγιών ατόμων (C) και νόσου Alzheimer (AD). Ωστόσο, στην ταξινόμηση μεταξύ AD και MCI, η ακρίβεια ήταν ελαφρώς χαμηλότερη στο 92,8%.
- **Γεωμετρική Μηχανική Μάθηση:** Αυτή η προσέγγιση, δίνοντας έμφαση στην αναγνώριση της θεμελιώδους γεωμετρικής δομής χαμηλών διαστάσεων εντός των σημάτων EEG, πέτυχε ακρίβεια ταξινόμησης 0,97 στη διάκριση των σκέψεων που σχετίζονται με digit- από τις σκέψεις non-digit-.
- **LEAD Foundation Model:** Το LEAD, το πρώτο μεγάλο foundation model για ανίχνευση AD βασισμένο σε EEG, επέτυχε έως και 9.86% αύξηση στο F1 score σε επίπεδο δείγματος και έως 9.31% σε επίπεδο υποκειμένου σε σύγκριση με state-of-the-art μεθόδους.
- **CNN με Δυναμικά Χαρακτηριστικά Συνδεσιμότητας:** Ένα μοντέλο CNN, συμπληρωμένο με χαρακτηριστικά δυναμικής λειτουργικής συνδεσιμότητας EEG, πέτυχε ακρίβεια 93,6% στην ταξινόμηση πολλαπλών κατηγοριών μεταξύ AD, FTD και υγιών ατόμων. Σε εργασίες δυαδικής ταξινόμησης, το μοντέλο πέτυχε ακρίβεια 97,8% για AD έναντι υγιών ατόμων, 96,7% για FTD έναντι υγιών ατόμων και 97,4% για AD έναντι FTD.
- **TCNs και LSTMs με RBP Ανάλυση:** Ένα πλαίσιο που συνδυάζει Temporal Convolutional Networks (TCNs) και Long Short-Term Memory (LSTMs) με ανάλυση Relative Band Power (RBP) πέτυχε 99.7% ακρίβεια για δυαδικές εργασίες και 80.34% για ταξινόμηση πολλαπλών κλάσεων.
- **ResNet με Connectogram-COH:** Η χρήση της αρχιτεκτονικής ResNet με τις γραφικές αναπαραστάσεις Connectogram-COH οδήγησε σε 99.49% μέση ακρίβεια για τμήματα δεδομένων 10 δευτερολέπτων.

Η διαφορά μεταξύ εργαστηριακής απόδοσης και κλινικής εφαρμογής στον πραγματικό κόσμο παραμένει βασικό μέλημα. Αν και οι αναφερόμενες ακρίβειες είναι ιδιαίτερα

εντυπωσιακές, ορισμένοι περιορισμοί -όπως η χρήση μικρών συνόλων δεδομένων, τα προβλήματα με τη γενίκευση και οι προκλήσεις που δημιουργούνται από τις αλλαγές διανομής- υποδεικνύουν ότι υπάρχει σημαντική διαφορά μεταξύ της απόδοσης σε ελεγχόμενα εργαστηριακά περιβάλλοντα και της πρακτικής χρήσης σε κλινικά περιβάλλοντα. Η παρατήρηση ότι τα μοντέλα που εκπαιδεύονται σε ένα σύνολο δεδομένων συχνά δεν έχουν καλή απόδοση σε ένα άλλο υποδηλώνει ότι τα στοιχεία υψηλής ακρίβειας από μόνα τους μπορεί να μην διασφαλίζουν αξιόπιστη διάγνωση στην καθημερινή ιατρική πρακτική. Αυτό υπογραμμίζει τη σημασία της εφαρμογής πιο αυστηρών διαδικασιών επικύρωσης, της χρήσης μεγαλύτερων και πιο διαφορετικών συνόλων δεδομένων που αντιπροσωπεύουν καλύτερα τα πραγματικά κλινικά σενάρια και της ανάπτυξης μοντέλων ικανών να φιλοξενούν εγγενείς αβεβαιότητες και επικαλυπτόμενα χαρακτηριστικά.

4. ΜΕΘΟΔΟΛΟΓΙΑ

Η παρούσα ενότητα περιγράφει τη μεθοδολογική προσέγγιση που ακολουθήθηκε για την κατηγοριοποίηση EEG σημάτων ατόμων με άνοια μέσω μη επιβλεπόμενων τεχνικών μηχανικής μάθησης. Η μεθοδολογία περιλαμβάνει την επιλογή και ανάλυση των δεδομένων EEG, την εξαγωγή χαρακτηριστικών, την κατηγοριοποίηση των εγγραφών με αλγορίθμους clustering και, τέλος, την αξιολόγηση των αποτελεσμάτων.

4.1 ΑΝΑΛΥΣΗ ΒΑΣΗΣ ΔΕΔΟΜΕΝΩΝ EEG

Η βάση δεδομένων που χρησιμοποιήθηκε στην παρούσα διπλωματική εργασία είναι δομημένη σε μορφή BIDS. BIDS (Brain Imaging Data Structure) ονομάζεται μια τυποποιημένη μορφή για την οργάνωση και την κοινή χρήση δεδομένων νευροαπεικόνισης και ηλεκτροεγκεφαλογραφίας (EEG). Αρχικά σχεδιάστηκε για δεδομένα μαγνητικής τομογραφίας, αλλά έχει επεκταθεί για να υποστηρίζει άλλες μορφές δεδομένων όπως EEG, MEG και iEEG (ενδοκρανικό ΗΕΓ). Ο στόχος του BIDS είναι να καταστήσει τα δεδομένα νευροαπεικόνισης πιο προσιτά, αναπαραγώγιμα και εύκολα χρησιμοποιήσιμα στην υπολογιστική έρευνα της νευροεπιστήμης. Τα κύρια στοιχεία του BIDS είναι:

➤ **Τυποποιημένη Δομή Φακέλων**

Η μορφή BIDS παρέχει οδηγίες σχετικά με τον τρόπο οργάνωσης των αρχείων μέσα σε ένα σύνολο δεδομένων, χρησιμοποιώντας μια σαφή και συνεπή δομή φακέλων. Συνήθως, τα δεδομένα για κάθε θέμα αποθηκεύονται σε μεμονωμένους φακέλους και μέσα σε αυτούς, τα αρχεία οργανώνονται περαιτέρω ανά περίοδο λειτουργίας, τρόπο λειτουργίας (όπως EEG ή MRI) και τύπο εργασίας. Στην δική μας περίπτωση υπάρχει ένας φάκελος για κάθε συμμετέχοντα όπου μέσα του περιέχει έναν φάκελο eeg όπου βρίσκονται όλα τα δεδομένα για τον εκάστοτε συμμετέχοντα. Επιπλέον υπάρχει κι ένας φάκελος ο οποίος περιέχει φιλτραρισμένα τα παραπάνω δεδομένα.

➤ **Συμβάσεις Ονοματοδοσίας**

Τα ονόματα αρχείων ακολουθούν μια συγκεκριμένη σύμβαση, ενσωματώνοντας λεπτομέρειες σχετικά με το θέμα, την περίοδο λειτουργίας, την εργασία και τη μέθοδο απευθείας στο όνομα του αρχείου. Για παράδειγμα, το πρώτο αρχείο που βρίσκεται στην βάση έχει το όνομα sub-001_task-eyesclosed_eeg.set, το οποίο υποδεικνύει τη συνεδρία (01), μια εργασία σε κατάσταση ηρεμίας με κλειστά μάτια και τη μέθοδο EEG.

➤ **Αρχεία Μεταδεδομένων**

Τα σύνολα δεδομένων BIDS ενσωματώνουν αρχεία JSON που χρησιμεύουν ως κοντέινερ μεταδεδομένων για κάθε αρχείο δεδομένων. Αυτά τα αρχεία παρέχουν βασικές πληροφορίες, όπως ρυθμούς δειγματοληψίας, θέσεις ηλεκτροδίων, παραμέτρους απόκτησης και άλλες σχετικές λεπτομέρειες. Στην περίπτωση δεδομένων EEG, αυτό μπορεί επίσης να περιλαμβάνει ρυθμίσεις τοποθέτησης ηλεκτροδίων ή φιλτραρίσματος.

➤ **Υποστήριξη Διαφορετικών Μεθόδων**

Αν και το BIDS αναπτύχθηκε αρχικά για δεδομένα MRI, τώρα περιλαμβάνει επίσης προδιαγραφές για EEG, MEG, iEEG και διάφορα σύνολα δεδομένων συμπεριφοράς. Όσον αφορά το EEG, φιλοξενεί πολλαπλές μορφές αρχείων (όπως EDF και BDF) και προωθεί τη συμβατότητα με μια σειρά εργαλείων νευροαπεικόνισης.

➤ Ευκολία στον Διαμοιρασμό και Ανάλυση Δεδομένων

Οι ερευνητές μπορούν να χρησιμοποιήσουν σύνολα δεδομένων BIDS με μια ποικιλία εργαλείων ανάλυσης νευροαπεικόνισης, καθώς τα δεδομένα μορφοποιημένα με BIDS είναι εύκολα αναγνωρίσιμα και μπορούν να εισαχθούν απρόσκοπτα σε λογισμικό όπως το MNE-Python, το FieldTrip και το EEGLAB, από όπου και κατέβασα την βάση.

Το σύνολο δεδομένων που χρησιμοποίησα περιλαμβάνει εγγραφές ΗΕΓ σε κατάσταση ηρεμίας με κλειστά μάτια από συνολικά 88 συμμετέχοντες. Οι συμμετέχοντες κατηγοριοποιούνται σε τρεις ομάδες: 36 άτομα με διάγνωση νόσου Αλτσχάιμερ (ομάδα AD), 23 άτομα με διάγνωση ευθραυστότητας άνοιας (ομάδα FTD) και 29 υγιείς μάρτυρες (ομάδα CN). Η γνωστική και νευροψυχολογική λειτουργία αξιολογήθηκε με τη χρήση της διεθνώς αναγνωρισμένης Mini-Mental State Examination (MMSE), η οποία βαθμολογείται από 0 έως 30, ενώ οι χαμηλότερες βαθμολογίες υποδεικνύουν πιο σοβαρή γνωστική εξασθένηση. Η διάρκεια της νόσου καταγράφηκε σε μήνες, με διάμεσο 25 μήνες και διατεταρτημόριο (Q1–Q3) από 24 έως 28,5 μήνες. Όσον αφορά την ομάδα AD, δεν έχουν αναφερθεί επιπλέον συννοσηρότητες που σχετίζονται με την άνοια. Οι μέσες βαθμολογίες MMSE ήταν 17,75 (τυπική απόκλιση = 4,5) για την ομάδα με άνοια, 22,17 (τυπική απόκλιση = 8,22) για την ομάδα με μετωποκροταφική άνοια και 30 για την υγιή ομάδα ελέγχου. Η μέση ηλικία των ομάδων ήταν 66,4 έτη (τυπική απόκλιση = 7,9) για την ομάδα με άνοια, 63,6 έτη (τυπική απόκλιση = 8,2) για την ομάδα της μετωποκροταφικής άνοιας και 67,9 έτη (τυπική απόκλιση = 5,4) για τους υγιείς μάρτυρες.

Παρατηρήσεις: Οι παρατηρήσεις λήφθηκαν από εξειδικευμένη ομάδα νευρολόγων της Β' Νευρολογικής Κλινικής του Γενικού Νοσοκομείου ΑΧΕΠΑ Θεσσαλονίκης. Για τη συλλογή δεδομένων, χρησιμοποιήθηκε η κλινική συσκευή EEG 2100 της Nihon Kohden, που χρησιμοποιεί 19 ηλεκτρόδια τριχωτού της κεφαλής (Fp1, Fp2, F7, F3, Fz, F4, F8, T3, C3, Cz, C4, T4, T5, P3, Pz, P4, T6, O1 και O2) σύμφωνα με το διεθνές σύστημα θέσης, O1, 2 ηλεκτρόδια αναφοράς (A1 και A2) τοποθετημένα στους κροτάφους για την παρακολούθηση της επαγωγικής αντίστασης, όπως ορίζεται στο εγχειρίδιο της συσκευής. Κάθε καταγραφή διενεργήθηκε σύμφωνα με καθιερωμένα κλινικά πρωτόκολλα, με τους συμμετέχοντες να κάθονται αναπαυτικά σε καθιστή θέση και τα μάτια τους κλειστά. Πριν από κάθε εγγραφή, καταβάλλονταν προσπάθειες για να διασφαλιστεί ότι η αντίσταση του δέρματος ήταν κάτω από 5 kΩ. Ο ρυθμός δειγματοληψίας ορίστηκε στα 500 Hz, με

ανάλυση 10 $\mu\text{V}/\text{mm}$. Οι ηχογραφήσεις χρησιμοποίησαν τόσο διεπίπεδα όσο και προσθιοοπίσθια αναφορικά μοντάζ, χρησιμοποιώντας το Cz ως κοινό σημείο αναφοράς. Η αναφορική σύνθεση συμπεριλήφθηκε σε αυτό το σύνολο δεδομένων. Τα αρχεία λήφθηκαν εντός του εύρους των ακόλουθων παραμέτρων του ενισχυτή: Ευαισθησία: 10 $\mu\text{V}/\text{mm}$, σταθερά χρόνου: 0,3s και υψηλή συχνότητα φίλτρου στα 70 Hz. Κάθε ηχογράφηση διήρκεσε περίπου 13,5 λεπτά για την ομάδα AD (ελάχιστο=5,1, μέγιστο=21,3), 12 λεπτά για την ομάδα FTD (ελάχιστο=7,9, μέγιστο=16,9) και 13,8 για την ομάδα CN (ελάχιστο=12,5, μέγιστο=16,5). Συνολικά, συγκεντρώθηκαν 485,5 λεπτά AD, 276,5 λεπτά FTD και 402 λεπτά CN και συμπεριλήφθηκαν στο σύνολο δεδομένων.

Προεπεξεργασία: Οι εγγραφές EEG εξήχθησαν αρχικά σε μορφή .eeg και μετατράπηκαν σε μορφή .set που γίνεται αποδεκτή από το BIDS για συμπερίληψη στο σύνολο δεδομένων. Οι αυτόματες σημειώσεις του εγκεφαλικού ηλεκτροεγκεφαλογράφηματος (EEG) της Nihon Kohden που σηματοδοτούν τη μυϊκή δραστηριότητα, το ανοιγοκλείσιμο των ματιών και την κατάποση δεν έχουν συμπεριληφθεί για λόγους συμβατότητας γλώσσας. Οι μη επεξεργασμένες εγγραφές EEG περιλαμβάνονται σε φακέλους με την ονομασία: sub-0XX. Στο φάκελο με την ονομασία sub-0XX του υποφακέλου derivatives περιέχονται τα προεπεξεργασμένα και απαλλαγμένα θορύβου δεδομένα EEG, όπου χρησιμοποιήθηκαν στην παρούσα εργασία. Η προεπεξεργασία των σημάτων EEG που πραγματοποιήθηκε είναι η ακόλουθη. Πρώτον, εφαρμόστηκε ένα φίλτρο Butterworth ζώνης περάσματος 0,5-45 Hz και τα σήματα αναφέρονταν εκ νέου στα A1-A2. Στη συνέχεια, εφαρμόστηκε στα σήματα η διαδικασία αποκατάστασης του υποχώρου των τεχνητών (ASR), μια μέθοδος διόρθωσης των τεχνητών σημάτων EEG που περιλαμβάνεται στο λογισμικό EEGLab Matlab, αφαίρεση των κακών περιόδων δεδομένων που υπερέβησαν τη μέγιστη αποδεκτή διακύμανση του παραθύρου 0,5 δευτερολέπτων, των 17, που θεωρείται ένα συντηρητικό παράθυρο. Στη συνέχεια, εφαρμόστηκε η μέθοδος Ανεξάρτητης Ανάλυσης Συνιστωσών (ICA) (αλγόριθμος RunICA), μετατρέποντας τα 19 σήματα EEG σε 19 συνιστώσες ICA. Τα συστατικά του ICA που ταξινομήθηκαν ως "αποκλίσεις οφθαλμών" ή "αποκλίσεις γνάθου" από την αυτόματη διαδικασία ταξινόμησης "ICLabel" στην πλατφόρμα EEGLAB απορρίφθηκαν αυτόματα. Πρέπει να σημειωθεί ότι, παρόλο που η εγγραφή πραγματοποιήθηκε σε κατάσταση ηρεμίας, με κλειστά τα μάτια, σε ορισμένες εγγραφές EEG εντοπίστηκαν ακόμα και ίχνη κινήσεων των ματιών.

4.2 ΕΞΑΓΩΓΗ ΚΑΙ ΕΠΙΛΟΓΗ ΧΑΡΑΚΤΗΡΙΣΤΙΚΩΝ

Για την ανάλυση των ηλεκτροεγκεφαλογραφικών (EEG) σημάτων και την εξαγωγή βασικών χαρακτηριστικών, αναπτύχθηκε ένα υπολογιστικό pipeline χρησιμοποιώντας Python. Ο πρωταρχικός στόχος αυτού του pipeline είναι να μετατρέψει τα ακατέργαστα δεδομένα EEG σε ένα καλά οργανωμένο σύνολο αριθμητικών χαρακτηριστικών, καθιστώντας τα κατάλληλα για εφαρμογή σε αλγόριθμους μηχανικής μάθησης και μεθόδους ταξινόμησης.

Η βιβλιοθήκη PyEEG χρησιμοποιήθηκε για αυτή η διαδικασία, αφού είναι ανοιχτού κώδικα γραμμένη στη γλώσσα Python, σχεδιασμένη να διευκολύνει την εξαγωγή χαρακτηριστικών από δεδομένα χρονοσειρών ηλεκτροεγκεφαλογραφικών (EEG) και μαγνητοεγκεφαλογραφικών (MEG) σημάτων. Η ανάπτυξή της στοχεύει να υποστηρίξει τις ερευνητικές προσπάθειες στον τομέα της ανάλυσης βιοσημάτων, προσφέροντας ένα ευέλικτο και επεκτάσιμο εργαλείο για την ποσοτική αξιολόγηση της εγκεφαλικής δραστηριότητας.

Η αρχιτεκτονική της PyEEG υιοθετεί έναν αρθρωτό σχεδιασμό, διαιρώντας τη λειτουργικότητά της σε δύο κύρια επίπεδα: προεπεξεργασία σήματος και εξαγωγή χαρακτηριστικών. Το στάδιο της προεπεξεργασίας ενσωματώνει θεμελιώδεις τεχνικές, όπως ο υπολογισμός παραγώγων και η δημιουργία ενσωματωμένων ακολουθιών (embedding), οι οποίες είναι απαραίτητες για ορισμένες μη γραμμικές μεθόδους ανάλυσης. Επιπλέον, η βιβλιοθήκη παρέχει μια ολοκληρωμένη επιλογή συναρτήσεων εξαγωγής χαρακτηριστικών, καθεμία από τις οποίες παίρνει μια χρονική σειρά ως είσοδο και παράγει είτε έναν αριθμητικό δείκτη είτε ένα διάνυσμα χαρακτηριστικών.

Οι υποστηριζόμενες λειτουργίες καλύπτουν μια σειρά από κατηγορίες και είναι ιδιαίτερα πολύτιμες στην ανάλυση σήματος EEG. Συγκεκριμένα, περιλαμβάνουν χαρακτηριστικά φασματικού περιεχομένου, όπως ισχύ σε διάφορες ζώνες συχνοτήτων (π.χ., δ , θ , α , β , γ), καθώς και θεωρία πληροφοριών και μη γραμμικά μέτρα πολυπλοκότητας, όπως η sample entropy, η approximate entropy, ο εκθέτης Hurst, η fractal διάσταση (Petrosian και Higuchi), οι παράμετροι Hjorth, καθώς και η DFA (Detrended Fluctuation Analysis). Αυτά τα χαρακτηριστικά έχουν χρησιμοποιηθεί εκτενώς στη βιβλιογραφία για τη μελέτη

παθολογιών του εγκεφάλου, συμπεριλαμβανομένης της άνοιας και άλλων νευρολογικών διαταραχών.

Ένα αξιοσημείωτο πλεονέκτημα της PyEEG είναι η παραμετρική φύση των λειτουργιών της, η οποία επιτρέπει στους χρήστες να προσαρμόζουν τις παραμέτρους κάθε μεθόδου εξαγωγής για να ταιριάζουν στις συγκεκριμένες ανάγκες εφαρμογής τους. Η βιβλιοθήκη έχει επίσης ελεγχθεί διεξοδικά σε δεδομένα πραγματικού κόσμου και έχει αναφερθεί σε πολυάριθμες δημοσιεύσεις, υπογραμμίζοντας την πρακτική της χρησιμότητα και την αξιοπιστία των αποτελεσμάτων της στην επιστημονική κοινότητα. Συνολικά, το PyEEG είναι ένα φιλικό προς το χρήστη, αποτελεσματικό και ευρέως διαδεδομένο εργαλείο για ανάλυση χρονοσειρών EEG/MEG. Ο συνδυασμός της ευκολίας χρήσης, της ευελιξίας, της συμβατότητας με άλλα λογισμικά όπως το EEGLAB και το Biosig και η υποστήριξη για ένα ευρύ φάσμα χαρακτηριστικών το καθιστά ιδιαίτερα κατάλληλο για εφαρμογές μηχανικής μάθησης και ταξινόμηση σημάτων EEG.

Η διαδικασία που ακολουθήθηκε για την εξαγωγή των χαρακτηριστικών περιλαμβάνει τα εξής βασικά βήματα:

➤ **Ανάκτηση EEG Αρχείων**

Η ανάλυση ξεκινά με μια αναδρομική αναζήτηση σε όλα τα αρχεία .set που βρίσκονται στον κατάλογο των επεξεργασμένων δεδομένων EEG. Αυτά τα αρχεία όπως αναφέραμε και πριν προέρχονται από την πλατφόρμα OpenNeuro και είναι οργανωμένα σύμφωνα με το πρότυπο BIDS. Η βιβλιοθήκη του λειτουργικού συστήματος (os) χρησιμοποιείται για την πλοήγηση στο σύστημα αρχείων και την αναγνώριση των σχετικών αρχείων προς επεξεργασία.

➤ **Φόρτωση και Φιλτράρισμα EEG Σήματος**

Για κάθε αρχείο, τα δεδομένα φορτώνονται χρησιμοποιώντας τη βιβλιοθήκη MNE, η οποία προσφέρει εργαλεία για την ανάγνωση και την επεξεργασία βιοσημάτων. Στη συνέχεια εφαρμόζεται ένα band-pass φίλτρο που εκτείνεται από 0,5 έως 50 Hz χρησιμοποιώντας ένα φίλτρο FIR τύπου Hamming για την απομόνωση του σχετικού εύρους συχνοτήτων του ΗΕΓ και για την εξάλειψη πιθανών ανεπιθύμητων στοιχείων, όπως η μετατόπιση DC και ο θόρυβος της γραμμής ισχύος στα 50 Hz.

➤ Υπολογισμός Power Spectral Density (PSD)

Για κάθε κανάλι EEG, η πυκνότητα φασματικής ισχύος (PSD) υπολογίζεται χρησιμοποιώντας τη μέθοδο Welch, η οποία προσφέρει αξιόπιστες εκτιμήσεις της ισχύος του σήματος σε διαφορετικές συχνότητες. Αυτές οι τιμές στη συνέχεια χρησιμοποιούνται για την κατανομή της ενέργειας του σήματος σε συγκεκριμένες ζώνες συχνοτήτων.

➤ Ανάλυση Συχνοτικών Ζωνών

Η συνολική φασματική ισχύς κάθε σήματος διαχωρίζεται σε τέσσερις βασικές συχνοτικές ζώνες:

- **Δέλτα (0.5–4 Hz):** συνδέεται με βαθύ ύπνο ή παθολογικές καταστάσεις.
- **Θήτα (4–8 Hz):** σχετίζεται με χαλάρωση και μνημονικές λειτουργίες.
- **Άλφα (8–12 Hz):** εμφανίζεται σε καταστάσεις ηρεμίας.
- **Βήτα (12–30 Hz):** υποδηλώνει ενεργή εγρήγορση και συγκέντρωση.

Το άθροισμα της ισχύος εντός κάθε ζώνης καταγράφεται ως ξεχωριστό χαρακτηριστικό.

➤ Υπολογισμός Spectral Entropy

Επιπλέον, η βιβλιοθήκη PyEEG χρησιμοποιείται για τον υπολογισμό της Φασματικής Εντροπίας, η οποία χρησιμεύει ως δείκτης της φασματικής «διαταραχής» εντός του σήματος. Οι υψηλότερες τιμές της φασματικής εντροπίας συνδέονται γενικά με αυξημένη πολυπλοκότητα ή μειωμένη συνέπεια στα δεδομένα EEG και αυτό το μέτρο έχει αποδειχθεί ότι είναι πολύτιμο σε εφαρμογές που σχετίζονται με τη διάγνωση νευροεκφυλιστικών ασθενειών.

➤ Αποθήκευση και Εξαγωγή Δεδομένων

Όλα τα εξαγόμενα χαρακτηριστικά αποθηκεύονται σε μία δομή τύπου πίνακα (DataFrame), μέσω της βιβλιοθήκης pandas, και τελικά εξάγονται σε αρχείο CSV. Το αρχείο αυτό θα χρησιμοποιηθεί για την εφαρμογή αλγορίθμων μηχανικής μάθησης σε εργαλεία όπως το WEKA.

Το σύνολο δεδομένων που αποθηκεύτηκε στο .csv αρχείο περιλαμβάνει χαρακτηριστικά από **19 διακριτά κανάλια ΗΕΓ**, που κυμαίνονται από το ch0 έως το ch18. Για κάθε κανάλι, έχουν υπολογιστεί πέντε συγκεκριμένα χαρακτηριστικά πολυπλοκότητας:

hfd (Κλασματική Διάσταση Higuchi), pfd (Κλασματική Διάσταση Petrosian), spectral_entropy (Φασματική Εντροπία), sample_entropy (Εντροπία Δείγματος) και approx_entropy (Προσεγγιστική Εντροπία). Αυτό έχει ως αποτέλεσμα συνολικά 95 στήλες χαρακτηριστικών (19 κανάλια * 5 χαρακτηριστικά/κανάλι).

Εκτός από τις στήλες χαρακτηριστικών, το σύνολο δεδομένων περιλαμβάνει στήλες μεταδεδομένων: file, η οποία πιθανότατα προσδιορίζει την αρχική συνεδρία καταγραφής ΗΕΓ (π.χ., sub-001_task-eyesclosed_eeg.set), και epoch, η οποία υποδεικνύει το συγκεκριμένο τμήμα χρόνου 2 δευτερολέπτων από το οποίο προήλθαν τα χαρακτηριστικά. Οι τιμές των χαρακτηριστικών αναπαρίστανται ως αριθμοί κινητής υποδιαστολής σε επιστημονική σημειογραφία (π.χ. 7,40988E+15), ενώ η στήλη file περιέχει δεδομένα τύπου συμβολοσειράς και η στήλη epoch περιέχει ακέραια δεδομένα.

Οι αριθμητικές τιμές των χαρακτηριστικών εκφράζονται σε επιστημονική σημείωση με πολύ μεγάλους εκθέτες (για παράδειγμα, 7.40988E+15). Αυτό μπορεί να υποδεικνύει ότι αυτές οι τιμές είναι ακατέργαστες, μη κλιμακωμένες έξοδοι από εσωτερικούς υπολογισμούς εντός της βιβλιοθήκης pyeeg ή ότι πρέπει να ληφθεί υπόψη ή να αντιστραφεί ένας σιωπηρός παράγοντας κλιμάκωσης.

Αυτά τα χαρακτηριστικά επιλέχθηκαν επειδή εκτείνονται πέρα από τις παραδοσιακές γραμμικές αναλύσεις -όπως η βασική φασματική πυκνότητα ισχύος χωρίς εντροπία- για να συλλάβουν πιο διαφοροποιημένες πτυχές της δυναμικής του εγκεφάλου, συμπεριλαμβανομένων της ανωμαλίας, της προβλεψιμότητας και των κλασματικών ιδιοτήτων. Είναι ιδιαίτερα κατάλληλες για την ανάλυση των σύντομων και μη σταθερών χρονοσειρών που απαντώνται συνήθως στις εγγραφές ΗΕΓ.

Όνομα Χαρακτηριστικού	Βασική Έννοια	Τι Ποσοτικοποιεί	Βασική Σημασία στο HEG
HFD	Κλασματική Διάσταση	Πολυπλοκότητα, κλασματικές ιδιότητες, ακανόνιστο	Εγκεφαλική ωρίμανση που σχετίζεται με την ηλικία, βιοδείκτης νευρολογικών διαταραχών, τοπογραφικές παραλλαγές
PFD	Κλασματική Διάσταση	Πολυπλοκότητα, αυτοομοιότητα, πολυπλοκότητα σήματος	Ταχύς υπολογισμός, διάκριση εγκεφαλικών καταστάσεων (π.χ. επιληψία, AD)
Φασματική Εντροπία	Θεωρία Πληροφορίας	Ακανόνιστο, προβλεψιμότητα στο φασματικό πεδίο	Κατανομή ισχύος σε συχνότητες, συνολική «τυχαία» του σήματος
Εντροπία Δείγματος	Θεωρία Πληροφορίας	Πολυπλοκότητα, απρόβλεπτο, κανονικότητα μοτίβων	Ανθεκτικότητα στο θόρυβο, ανεξαρτησία από το μήκος της χρονοσειράς, σύγκριση επανάληψης μοτίβων
Προσεγγιστική Εντροπία	Θεωρία Πληροφορίας	Ακανόνιστο, απρόβλεπτο, κανονικότητα μοτίβων	Συνολική πολυπλοκότητα και προβλεψιμότητα, ευαίσθητο σε μικρές χρονοσειρές, αξιολογεί τη μεταβλητότητα μοτίβων

Πίνακας 4.2 Περίληψη των Χαρακτηριστικών


4.3 ΟΜΑΔΟΠΟΙΗΣΗ ΤΩΝ ΔΕΔΟΜΕΝΩΝ

Για το επόμενο στάδιο της εργασίας αξιοποιήθηκε το WEKA. Το Waikato Environment for Knowledge Analysis (WEKA) είναι μια ολοκληρωμένη συλλογή εργαλείων μηχανικής μάθησης και ανάλυσης δεδομένων που αναπτύχθηκε στο Πανεπιστήμιο του Waikato στη Νέα Ζηλανδία. Κατασκευασμένο σε Java, διαθέτει ένα διαισθητικό γραφικό περιβάλλον χρήστη, το οποίο ενισχύει την προσβασιμότητά του τόσο για εκπαιδευτικές όσο και για ερευνητικές εφαρμογές. Το WEKA προσφέρει υποστήριξη για ένα ευρύ φάσμα εργασιών εξόρυξης δεδομένων, συμπεριλαμβανομένης της προεπεξεργασίας δεδομένων, της ομαδοποίησης, της ταξινόμησης, της παλινδρόμησης, της οπτικοποίησης και της επιλογής χαρακτηριστικών.

Τα βήματα που ακολουθήθηκαν για την ανάλυση των δεδομένων είναι τα εξής:


➤ Φόρτωση του Συνόλου Δεδομένων στο WEKA:

- Ανοίγοντας το WEKA επιλέγουμε το Explorer.




Εικόνα 4.3.1 Άνοιγμα WEKA

- Μεταβαίνουμε στην καρτέλα "Preprocess".



Εικόνα 4.3.2 Preprocess

- Κάνουμε κλικ στο κουμπί "Open file..." και επιλέγουμε το προετοιμασμένο αρχείο .csv που περιέχει τα χαρακτηριστικά του HEG.
- Μόλις φορτωθεί, το WEKA θα εμφανίσει μια επισκόπηση των δεδομένων, συμπεριλαμβανομένου του αριθμού των περιπτώσεων (γραμμών) και των χαρακτηριστικών (στηλών).



Εικόνα 4.3.3 Φόρτωση δεδομένων

➤ Κατανόηση Δεδομένων:


- **Επισκόπηση Χαρακτηριστικών:** Στο αριστερό παράθυρο "Attributes", διακρίνονται τα χαρακτηριστικά προς επιλογή (π.χ., `ch0_hfd`). Εάν επιλέξουμε ένα από αυτά (π.χ. `epochs`) βλέπουμε λεπτομέρειες όπως τον τύπο του (π.χ., `Numeric`), τον αριθμό των ελλειπόντων τιμών και την κατανομή των τιμών.
- **Αφαίρεση μη σχετικών χαρακτηριστικών:** Οι στήλες `file` και `epochs` χρησιμεύουν ως μεταδεδομένα. Αν και η στήλη `epochs` μπορεί να είναι χρήσιμη για την ανάλυση χρονοσειρών, μπορεί να μην είναι απαραίτητα ως χαρακτηριστικά εισόδου για ορισμένες εργασίες μηχανικής εκμάθησης. Στην ανάλυση μου αυτές οι δύο στήλες δεν χρειαζόταν, οπότε αφαιρέθηκαν επιλέγοντας τις στήλες και κάνοντας κλικ στο κουμπί "Κατάργηση" που βρίσκεται στο κάτω μέρος.

- **Ομαδοποίηση Δεδομένων:** Το WEKA υποστηρίζει διάφορους αλγόριθμους clustering, όπως ο Simple k-means, ο EM (Expectation-Maximization) και ο HierarchicalClusterer που χρησιμοποιήθηκαν στο πλαίσιο της εργασίας. Στην καρτέλα "Cluster" κάνοντας κλικ στο κουμπί "Choose" επιλέγουμε κάθε φορά τον επιθυμητό αλγόριθμο clustering.

SimpleKMeans:

Ο αλγόριθμος K-Means είναι μια κοινώς χρησιμοποιούμενη τεχνική ομαδοποίησης βασισμένη σε κεντροειδές που χωρίζει ένα δεδομένο σύνολο δεδομένων σε έναν καθορισμένο αριθμό συστάδων (K), χρησιμοποιώντας συνήθως την Ευκλείδεια απόσταση ως μέτρο ομοιότητας. Το κεντρικό σημείο κάθε συστάδας είναι γνωστό ως κέντρο. Αναγνωρισμένο για την ταχύτητα και την απλή εφαρμογή του, θεωρείται ένας από τους πιο προσιτούς αλγόριθμους μάθησης χωρίς επίβλεψη.

Για να τον τρέξουμε στα δεδομένα επιλέγουμε όπως αναφέρθηκε πριν τον αλγόριθμο και στην συνέχεια τον παραμετροποιούμε. Εδώ, το πιο σημαντικό βήμα είναι να ορίσουμε την τιμή του `numClusters` (K), δηλαδή τον αριθμό των ομάδων που θέλουμε να δημιουργήσουμε. Εάν δεν ξέρουμε ποιος είναι ο αριθμός των clusters δοκιμάζουμε ένα εύρος τιμών και έπειτα αξιολογώντας τις WSS τιμές επιλέγουμε τον κατάλληλο. Μπορούμε επίσης να ρυθμίσουμε άλλες παραμέτρους, όπως τον αριθμό των επαναλήψεων (`maxIterations`) ή την αρχικοποίηση των κεντροειδών (π.χ., επιλέγοντας τα πρώτα K σημεία από τα δεδομένα ως αρχικά κεντροειδή αντί για τυχαία επιλογή, κάτι που μπορεί να βοηθήσει στη σύγκριση αποτελεσμάτων σε διαφορετικές ρυθμίσεις ομαδοποίησης).



Εικόνα 4.3.4 SimpleKMeans

Στην περίπτωση της παρούσας εργασίας δοκίμασα τα εξής numClusters: 5, 6, 7, 8, 9, 10. Οι προκύπτουσες συστάδες στη συνέχεια αξιολογήθηκαν με βάση τον δείκτη WSS (Within-Cluster Sum of Squares), μαζί με μια εξέταση της κατανομής των δειγμάτων σε κάθε ομάδα. Ο στόχος ήταν να επιλεγεί μια τιμή k που να εξασφαλίζει αποτελεσματική συνοχή συμπλέγματος αποφεύγοντας την περιττή κατάτμηση του συνόλου δεδομένων. Παρακάτω βλέπουμε τον πίνακα των αποτελεσμάτων.


numClusters	WSS	Μέγιστο ποσοστό ομάδας	Σύνολο ομάδων <10%
5	3265949.0	44%	1
6	3262478.0	37%	2
7	3259512.0	31%	4
8	3257755.0	28%	5
9	3254938.0	25%	6
10	3252108.0	23%	7

Πίνακας 4.3 WSS

Παραπάνω παρατηρούμε ότι η μείωση του WSS είναι ιδιαίτερα σημαντική όταν μετακινείται από $k = 5$ σε $k = 6$. Πέρα από το $k = 7$, ωστόσο, ο ρυθμός μείωσης του WSS φαίνεται να επιβραδύνεται, υποδηλώνοντας την παρουσία ενός "αγκώνα" στην καμπύλη. Επιπλέον, ξεκινώντας από το $k = 7$, αρχίζουν να εμφανίζονται αρκετές ομάδες με πολύ μικρά ποσοστά συμμετοχής (<10%), γεγονός που μπορεί να υποδηλώνει υπερομαδοποίηση χωρίς να παρέχει ουσιαστική πρόσθετη εικόνα. Λαμβάνοντας υπόψη τόσο το κριτήριο πτώσης του WSS όσο και τον στόχο της επίτευξης μιας ισορροπημένης κατανομής δεδομένων, επιλέξαμε το $k = 6$ ως τον βέλτιστο αριθμό συστάδων. Αυτή η επιλογή αντιπροσωπεύει έναν εύλογο συμβιβασμό μεταξύ της ακρίβειας του μοντέλου και της ερμηνευσιμότητας των αποτελεσμάτων.

EM (Expectation-Maximization):

Ο αλγόριθμος Expectation-Maximization (EM) χρησιμοποιείται συχνά σε καταστάσεις όπου ο αλγόριθμος K-Means μπορεί να μην έχει καλή απόδοση, ιδιαίτερα όταν τα συμπλέγματα δεν είναι απαραίτητα κυκλικά ή όταν τα κέντρα συστάδων είναι πολύ κοντά το ένα στο άλλο. Στο πλαίσιο των Gaussian Mixture Models (GMM), θεωρείται ότι τα σημεία δεδομένων ακολουθούν μια Gaussian κατανομή. Τόσο η μέση όσο και η τυπική απόκλιση χρησιμεύουν ως παράμετροι που χαρακτηρίζουν το σχήμα κάθε συστάδας. Ο αλγόριθμος EM είναι μια τεχνική βελτιστοποίησης που χρησιμοποιείται για την εκτίμηση αυτών των παραμέτρων, οι οποίες με τη σειρά τους διευκολύνουν το σχηματισμό συστάδων με βάση τις παραγόμενες τιμές. Το βασικό μειονέκτημα αυτής της τεχνικής είναι ότι παίρνει πολύ χρόνο να τρέξει εάν δεν της ορίσουμε numClusters και αφήσουμε την default τιμή -1. Επιπλέον, καταναλώνει πολλή μνήμη γεγονός που με περιόρισε στις δοκιμές με διαφορετικές τιμές numClusters όπως στον k-Means.




Εικόνα 4.3.5 EM

HierarchicalClusterer (Agglomerative Hierarchical Clustering - AHC):

Ο αλγόριθμος Agglomerative Hierarchical Clustering (AHC) διεξάγει ιεραρχική ομαδοποίηση με τρόπο από κάτω προς τα πάνω. Ξεκινά θεωρώντας κάθε μεμονωμένο σημείο δεδομένων ως τη δική του ξεχωριστή ομάδα. Στη συνέχεια, σε κάθε επόμενο βήμα, ο αλγόριθμος συγχωνεύει τα δύο πλησιέστερα σημεία ή ομάδες δεδομένων, σχηματίζοντας μια δομή που μοιάζει με δέντρο. Αυτή η διαδικασία συνεχίζεται έως ότου όλα τα σημεία δεδομένων συμπεριληφθούν σε μια ενιαία, ενοποιημένη ομάδα. Η διαδικασία

ομαδοποίησης βασίζεται στις αποστάσεις μεταξύ των «αντικειμένων» για τη δημιουργία «ομάδων» και συγκεκριμένα, δεν απαιτεί προηγούμενη γνώση του αριθμού των ομάδων. Αυτή η προσέγγιση επιτρέπει τον εντοπισμό των πιο κατάλληλα δομημένων συστάδων. Όμως και αυτός ο αλγόριθμος είναι αρκετά αργός.




Εικόνα 4.3.6 HierarchicalClusterer

Μετά από αυτά τα πειράματα κατέληξα στην επιλογή του αλγορίθμου k-means με $\text{numCluster} = 6$ και αποθήκευσα τα νέα δεδομένα εφαρμόζοντας το k-means για να προχωρήσουμε στα μοντέλα μηχανικής μάθησης που θα εκπαιδεύσουμε τα δεδομένα μας.

4.4 ΑΝΑΠΤΥΞΗ ΚΑΙ ΕΚΠΑΙΔΕΥΣΗ ΜΟΝΤΕΛΩΝ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ

Παίρνοντας τα δεδομένα ομαδοποιημένα πλέον ξεκινάμε το κομμάτι της πειραματικής διαδικασίας. Για την πειραματική αξιολόγηση των δεδομένων EEG, επιλέχθηκαν κάποιοι αλγόριθμοι μηχανικής μάθησης από διάφορες οικογένειες ταξινομητών για να συγκριθεί η απόδοσή τους. Η διαδικασία επιλογής διεξήχθη χρησιμοποιώντας την πλατφόρμα WEKA, ενσωματώνοντας τόσο θεμελιώδεις όσο και προηγμένους αλγόριθμους. Στην εικόνα βλέπουμε τους αλγόριθμους που χρησιμοποιήθηκαν. Μια σύντομη επισκόπηση των βασικών αρχών αυτών των αλγορίθμων παρέχεται παρακάτω.



Εικόνα 4.4 Experiment

➤ **weka.classifiers.functions.SMO (Support Vector Machine)**

Ο SMO (Sequential Minimal Optimization) είναι μια εξαιρετικά αποτελεσματική μέθοδος για την εφαρμογή Υποστήριξης Διανυσματικών Μηχανών (SVM).

Εμπίπτει στην κατηγορία των αλγορίθμων γραμμικής ταξινόμησης, ενώ προσφέρει επίσης την ευελιξία για την ενσωμάτωση μη γραμμικών πυρήνων (όπως RBF) για την προβολή δεδομένων σε χώρους υψηλότερων διαστάσεων. Αυτή η προσέγγιση είναι ιδιαίτερα κατάλληλη για την αντιμετώπιση προκλήσεων υψηλών διαστάσεων, όπως αυτές που παρουσιάζονται από την ανάλυση σήματος EEG.

➤ **weka.classifiers.functions.MultilayerPerceptron (Τεχνητό Νευρωνικό Δίκτυο)**

Ο Multilayer Perceptron (MLP) είναι ένας τύπος πλήρως συνδεδεμένου τεχνητού νευρωνικού δικτύου που αποτελείται από ένα ή περισσότερα κρυφά στρώματα. Χρησιμοποιεί τον αλγόριθμο backpropagation για εκπαίδευση και είναι κατάλληλος για την αντιμετώπιση πολύπλοκων, μη γραμμικών προβλημάτων, όπως η ταξινόμηση προτύπων EEG.

➤ **weka.classifiers.trees.RandomForest (Random Forest)**

Ο Random Forest είναι ένας αλγόριθμος λήψης αποφάσεων συνόλου που δημιουργεί πολλά δέντρα αποφάσεων χρησιμοποιώντας διάφορα υποσύνολα χαρακτηριστικών και παρατηρήσεων. Η τελική πρόβλεψη καθορίζεται μέσω της διαδικασίας της πλειοψηφίας. Αυτή η μέθοδος εκτιμάται καλά για τη σταθερότητα και την ακρίβειά της, ακόμη και σε δύσκολες συνθήκες όπως τα θορυβώδη δεδομένα EEG.

➤ **weka.classifiers.bayes.NaiveBayes (NaiveBayes)**

Ο Naive Bayes είναι ένας απλός πιθανολογικός ταξινομητής που βασίζεται στο θεώρημα του Bayes, κάνοντας την υπόθεση ότι τα χαρακτηριστικά είναι ανεξάρτητα. Αν και είναι σχετικά απλό, έχει επιδείξει σημαντική αποτελεσματικότητα σε πολλές εφαρμογές του πραγματικού κόσμου και χρησιμοποιείται συχνά ως σημείο αναφοράς για σύγκριση.

➤ **weka.classifiers.meta.AdaBoostM1 (Adaptive Boosting)**

Ο αλγόριθμος AdaBoost (Adaptive Boosting) ταξινομείται ως μετα-αλγόριθμος που έχει σχεδιαστεί για να βελτιώνει την ακρίβεια των αδύναμων ταξινομητών. Κατά τη διάρκεια της εκπαιδευτικής διαδικασίας, δίνει μεγαλύτερη έμφαση στα λάθη που έγιναν σε προηγούμενες επαναλήψεις και ενσωματώνει πολλαπλούς ταξινομητές για να καταλήξει σε μια τελική απόφαση. Στο WEKA, το AdaBoost χρησιμοποιείται συνήθως με απλά decision stumps ή άλλα βασικά μοντέλα.

➤ **weka.classifiers.meta.Bagging (Bootstrap Aggregation)**

Ο Bagging (Bootstrap Aggregation) είναι ένας μετα-αλγόριθμος που περιλαμβάνει τη δημιουργία πολλαπλών υποσυνόλων δεδομένων μέσω δειγματοληψίας με

ταξινομητές αντικατάστασης και εκπαίδευσης ξεχωριστά σε κάθε υποσύνολο. Στη συνέχεια, η συνολική πρόβλεψη καθορίζεται μέσω μιας διαδικασίας ψηφοφορίας. Αυτή η προσέγγιση είναι ιδιαίτερα ωφέλιμη για τη σημαντική μείωση της διακύμανσης των μοντέλων και την ενίσχυση της ικανότητάς τους να γενικεύονται σε νέα δεδομένα.

➤ **weka.classifiers.lazy.IBk (k-Nearest Neighbors)**

Ο IBk είναι η υλοποίηση του αλγορίθμου k-Nearest Neighbors (k-NN) εντός του WEKA. Ως τεμπέλικος αλγόριθμος (lazy learner), εκτελεί μάθηση τη στιγμή της πρόβλεψης. Η διαδικασία ταξινόμησης περιλαμβάνει την εξέταση της πλειοψηφίας μεταξύ των k πιο κοντινών παρατηρήσεων στον χώρο χαρακτηριστικών. Η απόδοσή του μπορεί να επηρεαστεί από την επιλογή της παραμέτρου k και την κανονικοποίηση των χαρακτηριστικών.

➤ **weka.classifiers.trees.J48 (Απόφαση Δέντρου - C4.5)**

Ο J48 είναι μια υλοποίηση του ευρέως αναγνωρισμένου αλγορίθμου C4.5 που χρησιμοποιείται για τη δημιουργία δέντρων αποφάσεων. Δημιουργεί δυαδικά δέντρα με βάση το κριτήριο της εντροπίας, χρησιμοποιώντας συγκεκριμένα το κέρδος πληροφοριών. Η ερμηνευτικότητά του το καθιστά ιδιαίτερα κατάλληλο για εφαρμογές όπου η διαφάνεια και η επεξήγηση είναι σημαντικές.

Η χρήση μιας ποικιλίας ταξινομητών επιτρέπει μια συγκριτική αξιολόγηση της απόδοσης κάθε μεθόδου σε ένα συγκεκριμένο πρόβλημα. Αυτή η προσέγγιση είναι ιδιαίτερα πολύτιμη όταν εργάζομαστε με πολύπλοκα βιοϊατρικά δεδομένα, όπως το ΗΕΓ, όπου τα αποτελέσματα μπορεί να διαφέρουν σημαντικά με βάση τον επιλεγμένο αλγόριθμο, τις διαμορφώσεις υπερπαραμέτρων και τα χαρακτηριστικά των εμπλεκόμενων χαρακτηριστικών.

5. ΑΠΟΤΕΛΕΣΜΑΤΑ ΚΑΙ ΑΝΑΛΥΣΗ

Για την αξιολόγηση της ταξινομητικής ικανότητας των επιλεγμένων αλγορίθμων μηχανικής μάθησης, πραγματοποιήθηκε εκπαίδευση και δοκιμή τους επί του συνόλου των χαρακτηριστικών που εξήχθησαν από τις EEG καταγραφές. Τα αποτελέσματα καταγράφηκαν για τους εξής δείκτες απόδοσης:

- Ποσοστό Ορθής Ταξινόμησης (Percent Correct)
- F-measure
- Εμβαδόν κάτω από την καμπύλη ROC (Area under ROC)
- Χρόνος Εκπαίδευσης (Elapsed Time Training)
- Χρόνος Δοκιμής (Elapsed Time Testing)

5.1 ΠΑΡΟΥΣΙΑΣΗ ΠΕΙΡΑΜΑΤΙΚΩΝ ΑΠΟΤΕΛΕΣΜΑΤΩΝ

Ο Πίνακας που ακολουθεί παρουσιάζει τα αριθμητικά αποτελέσματα, μεγεθυμένα για καλύτερη αναγνωσιμότητα (τα δεδομένα εξήχθησαν σε μορφή επιστημονικής γραφής):

Αλγόριθμος	Percent Correct (%)	F-measure	Area under ROC	Χρόνος Εκπαίδευσης (ms)	Χρόνος Δοκιμής (ms)
SMO	97,3	9.75×10^{15}	9.95×10^{15}	109,541	3,855
MultilayerPerceptron	95,3	9.47×10^{15}	9.98×10^{15}	45,350,063	4,389
RandomForest	91,2	9.09×10^{15}	9.95×10^{15}	3.39×10^{16}	23,756

NaiveBayes	86,6	8.70×10^{15}	9.84×10^{15}	78,919	45,639
AdaBoostM1	86,6	8.60×10^{15}	9.84×10^{15}	1.55×10^{16}	5,655
Bagging	85,4	8.48×10^{14}	9.83×10^{15}	9,395,794	5.12×10^{16}
IBk (k-NN)	82,1	8.35×10^{15}	9.02×10^{15}	672	3,569,067
J48 (Decision Tree)	75,5	7.46×10^{15}	8.77×10^{15}	1.12×10^{16}	7.06×10^{16}

Πίνακας 5.1 Αποτελέσματα

5.2 ΣΥΓΚΡΙΣΗ ΜΕΘΟΔΩΝ ΚΑΙ ΜΟΝΤΕΛΩΝ

Η παρούσα ενότητα επικεντρώνεται στη συγκριτική αξιολόγηση των αλγορίθμων ταξινόμησης, βάσει των αποτελεσμάτων που παρουσιάστηκαν στην προηγούμενη ενότητα, με ιδιαίτερη έμφαση στην ερμηνεία των αριθμητικών τιμών. Η σύγκριση αυτή διεξήχθη με βάση τους ακόλουθους, κρίσιμους, δείκτες απόδοσης:

- **Ποσοστό σωστής ταξινόμησης (Percent Correct):** Αντικατοπτρίζει την ακρίβεια του μοντέλου ως προς την ορθή πρόβλεψη της κατηγορίας κάθε δείγματος.
- **F-measure:** Πρόκειται για έναν ενοποιημένο δείκτη που συνδυάζει την ακρίβεια (precision) και την ανάκληση (recall), προσφέροντας μια πιο ισορροπημένη εκτίμηση της συνολικής απόδοσης του μοντέλου.

- **Εμβαδόν κάτω από την καμπύλη ROC (Area Under ROC Curve - AUC):**
Αξιολογεί την ικανότητα του μοντέλου να διακρίνει αποτελεσματικά ανάμεσα στις διαφορετικές κατηγορίες, ανεξαρτήτως του επιλεγμένου κατωφλίου απόφασης.
- **Χρόνος Εκπαίδευσης και Δοκιμής:** Αναφέρονται στην υπολογιστική απόδοση του μοντέλου, μετρώντας τον χρόνο που απαιτείται για την εκπαίδευσή του στα δεδομένα και την πρόβλεψη νέων δειγμάτων αντίστοιχα.

Ανάλυση Απόδοσης Ακρίβειας

Ο αλγόριθμος Perceptron Multilayer πέτυχε τις υψηλότερες βαθμολογίες σε όλες τις μετρήσεις απόδοσης ακρίβειας. Αυτό υποδηλώνει την αξιοσημείωτη αποτελεσματικότητα των νευρωνικών δικτύων στην ταξινόμηση χαρακτηριστικών που προέρχονται από σήματα EEG. Η απόδοση του Multilayer Perceptron συμπληρώνεται ιδιαίτερα από τους αλγόριθμους SMO (SVM) και Random Forest, οι οποίοι επίσης επέδειξαν ισχυρά αποτελέσματα, ιδιαίτερα όσον αφορά τον δείκτη AUC. Οι αλγόριθμοι NaiveBayes και AdaBoostM1 επιδεικνύουν επίσης ισχυρές επιδόσεις, ιδιαίτερα όσον αφορά την AUC, αν και τα ποσοστά μέτρησης F και σωστής ταξινόμησης είναι ελαφρώς χαμηλότερα.

Αντίθετα, οι αλγόριθμοι J48 (δέντρο αποφάσεων) και IBk (k-Κοντινότεροι γείτονες) τείνουν να παρουσιάζουν κάπως χαμηλότερη απόδοση, με αισθητά μειωμένους σωστούς ρυθμούς ταξινόμησης και μέτρηση F σε σύγκριση με τους άλλους ταξινομητές.

Ανάλυση Υπολογιστικής Απόδοσης

Η ανάλυση των χρόνων εκτέλεσης δείχνει μεγάλη διακύμανση μεταξύ των αλγορίθμων. Το IBk είχε τον μικρότερο χρόνο εκπαίδευσης και έναν από τους μεγαλύτερους χρόνους δοκιμών. Αυτό οφείλεται στη συγκεκριμένη συμπεριφορά της IBk να αποθηκεύει όλα τα δεδομένα εκπαίδευσης και να υπολογίζει τις αποστάσεις σε πραγματικό χρόνο κατά τη φάση της δοκιμής. Από την άλλη πλευρά, οι αλγόριθμοι SMO και NaiveBayes δείχνουν σύντομους χρόνους τόσο για εκπαίδευση όσο και για δοκιμές, καθιστώντας τους ιδιαίτερα κατάλληλους για περιβάλλοντα με περιορισμένους υπολογιστικούς πόρους.

Αν και το MultilayerPerceptron επιδεικνύει εντυπωσιακή ακρίβεια, τείνει να απαιτεί μια ιδιαίτερα μεγάλη διάρκεια προπόνησης. Αυτό μπορεί να δημιουργήσει προκλήσεις για εφαρμογές που απαιτούν γρήγορη και συχνή επανεκπαίδευση. Επιπλέον, οι αλγόριθμοι Bagging και J48 σχετίζονται με σημαντικά υψηλούς χρόνους δοκιμών, οι οποίοι θα μπορούσαν να παρουσιάσουν εμπόδια κατά την ανάπτυξή τους σε συστήματα σε πραγματικό χρόνο που απαιτούν άμεσες αποκρίσεις.

5.3 ΣΥΖΗΤΗΣΗ ΚΑΙ ΕΡΜΗΝΕΙΑ ΤΩΝ ΕΥΡΗΜΑΤΩΝ

Η συγκριτική αξιολόγηση των αλγορίθμων ταξινόμησης προσφέρει πολύτιμες γνώσεις και ενισχύει την κατανόησή μας για το πώς αποδίδουν διάφορες προσεγγίσεις κατά την ανάλυση δεδομένων ΗΕΓ. Αυτά τα ευρήματα χρησιμεύουν ως πηγή για την επιλογή του καταλληλότερου αλγορίθμου, λαμβάνοντας υπόψη τόσο την ακρίβεια όσο και τους υπολογιστικούς περιορισμούς.

Η εντυπωσιακή απόδοση του Multilayer Perceptron υπογραμμίζει την εγγενή ικανότητα των νευρωνικών δικτύων να καταγράφουν πολύπλοκες και μη γραμμικές σχέσεις μεταξύ χαρακτηριστικών που προέρχονται από βιολογικά σήματα. Η πολυεπίπεδη και διασυνδεδεμένη αρχιτεκτονική του επιτρέπει την εκμάθηση αφηρημένων και ιεραρχικών αναπαραστάσεων δεδομένων, κάτι που είναι ιδιαίτερα πλεονεκτικό για την ταξινόμηση σημάτων EEG, όπου τα υποκείμενα μοτίβα μπορεί συχνά να είναι διακριτικά ή δύσκολο να διακριθούν. Ωστόσο, όπως σημειώθηκε, οι σημαντικοί υπολογιστικοί πόροι που απαιτούνται για την εκπαίδευση τέτοιων μοντέλων μπορεί να περιορίσουν την πρακτικότητά τους σε περιβάλλοντα με περιορισμένους πόρους ή σε σενάρια που απαιτούν συχνές και γρήγορες ενημερώσεις μοντέλων.

Ο SMO, ως υλοποίηση του αλγορίθμου Support Vector Machine (SVM), επιτυγχάνει συγκρίσιμα επίπεδα υψηλής ακρίβειας ενώ απαιτεί σημαντικά λιγότερη υπολογιστική προσπάθεια σε σύγκριση με το Multilayer Perceptron. Αυτό το χαρακτηριστικό το καθιστά μια εξαιρετικά ανταγωνιστική και ελκυστική επιλογή, ιδιαίτερα σε σενάρια όπου είναι επιθυμητή η υψηλή απόδοση χωρίς να επιβάλλονται υπερβολικές απαιτήσεις σε υπολογιστικούς πόρους. Η αποτελεσματικότητα των SVM μπορεί να αποδοθεί στην

ικανότητά τους να αναγνωρίζουν το βέλτιστο διαχωριστικό υπερεπίπεδο, ακόμη και σε χώρους χαρακτηριστικών υψηλών διαστάσεων.

Ενώ οι αλγόριθμοι RandomForest και AdaBoostM1 γενικά επιδεικνύουν υψηλή ακρίβεια, τείνουν να απαιτούν περισσότερους υπολογιστικούς πόρους. Αυτό συμβαίνει επειδή, ως μέθοδοι συνόλου, συγκεντρώνουν πολλαπλά υπομοντέλα για να καταλήξουν σε μια τελική απόφαση. Αν και αυτή η προσέγγιση συχνά ενισχύει την ακρίβεια και βοηθά στην αποφυγή της υπερβολικής προσαρμογής, έχει επίσης ως αποτέλεσμα αυξημένες υπολογιστικές απαιτήσεις, ιδιαίτερα καθώς αυξάνεται η πολυπλοκότητα των συνδυασμένων μοντέλων.

Αντίθετα, πιο παραδοσιακοί και απλοί αλγόριθμοι, όπως οι NaiveBayes και J48, τείνουν να παρέχουν ικανοποιητικά αποτελέσματα ενώ απαιτούν σημαντικά λιγότερους υπολογιστικούς πόρους. Αυτό το χαρακτηριστικό τα καθιστά ιδιαίτερα κατάλληλα για προκαταρκτικές αξιολογήσεις, γρήγορες αναλύσεις ή ενσωματωμένα συστήματα λήψης αποφάσεων, όπου οι υπολογιστικοί περιορισμοί και η ανάγκη για απλότητα συχνά παίζουν βασικό ρόλο. Επιπλέον, η ερμηνευσιμότητα του J48 (δέντρα απόφασης) προσφέρει ένα αξιοσημείωτο όφελος, διευκολύνοντας μια σαφέστερη κατανόηση των κανόνων ταξινόμησης.

Ένα κρίσιμο σημείο που προκύπτει από τα δεδομένα είναι η παρουσία ασυνήθιστα υψηλών αριθμητικών τιμών στους δείκτες απόδοσης (για παράδειγμα, της τάξης των 10^{15}). Αυτή η κατάσταση μπορεί να προέρχεται από πιθανά σφάλματα κωδικοποίησης κατά την εξαγωγή αποτελεσμάτων, την υπερβολική προσαρμογή του μοντέλου στα δεδομένα εκπαίδευσης ή τη χρήση μη κανονικοποιημένων δεδομένων εισόδου. Η υπερπροσαρμογή συμβαίνει όταν το μοντέλο απομνημονεύει ουσιαστικά τα δεδομένα προπόνησης αντί να καταγράφει τα υποκείμενα μοτίβα, γεγονός που μπορεί να οδηγήσει σε εξαιρετική απόδοση στο σετ εκπαίδευσης αλλά σε κακή γενίκευση σε νέα, αόρατα δεδομένα. Δεδομένου αυτού, συνιστάται η περαιτέρω επικύρωση των μοντέλων χρησιμοποιώντας ένα ανεξάρτητο σύνολο δεδομένων ή τεχνικές διασταυρούμενης επικύρωσης. Τέτοια βήματα θα συμβάλουν στη διασφάλιση της στιβαρότητας και της αξιοπιστίας των αποτελεσμάτων, αποτρέποντας παράλληλα την παρερμηνεία των τεχνητά διογκωμένων μετρήσεων απόδοσης.

Συνοψίζοντας, ενώ το Multilayer Perceptron παρέχει την υψηλότερη ακρίβεια ταξινόμησης, ο αλγόριθμος SMO παρουσιάζει μια καλά ισορροπημένη επιλογή μεταξύ ακρίβειας και υπολογιστικής απόδοσης, καθιστώντας τον ιδιαίτερα κατάλληλο για εφαρμογές που απαιτούν ισχυρή απόδοση χρησιμοποιώντας λογικούς πόρους. Επιπλέον, το Naive Bayes και το Random Forests προσφέρουν έναν ικανοποιητικό συμβιβασμό μεταξύ της ακρίβειας και των απαιτήσεων πόρων για συγκεκριμένες περιπτώσεις χρήσης. Οι αλγόριθμοι Bagging, J48 και IBk, λόγω των μεγαλύτερων χρόνων δοκιμής ή της συγκριτικά χαμηλότερης ακρίβειάς τους, μπορεί να επωφεληθούν από περαιτέρω βελτιστοποίηση ή θα μπορούσαν να είναι καλύτερα κατάλληλοι για εξειδικευμένες εφαρμογές όπου χαρακτηριστικά όπως η απλότητα και η ερμηνευτικότητα είναι ιδιαίτερα σημαντικά.

6. ΣΥΜΠΕΡΑΣΜΑΤΑ ΚΑΙ ΜΕΛΛΟΝΤΙΚΗ ΈΡΕΥΝΑ

Η παρούσα διπλωματική εργασία διερεύνησε την εφαρμογή και αξιολόγηση διαφόρων αλγορίθμων μηχανικής μάθησης για την ταξινόμηση χαρακτηριστικών σημάτων EEG.

6.1 ΣΥΝΟΨΗ ΣΥΜΠΕΡΑΣΜΑΤΩΝ

Τα κύρια συμπεράσματα που προκύπτουν από την ανάλυση των αποτελεσμάτων είναι τα εξής:

Αποδοτικότητα νευρωνικών δικτύων (MultilayerPerceptron): Ο αλγόριθμος MultilayerPerceptron έδειξε εξαιρετική απόδοση σε όλες τις μετρήσεις ακρίβειας (Percent Correct, F-measure, AUC). Αυτό υπογραμμίζει την ισχυρή ικανότητα των νευρωνικών δικτύων να συλλαμβάνουν και να μοντελοποιούν αποτελεσματικά τις πολύπλοκες και μη γραμμικές σχέσεις που είναι εγγενείς στα δεδομένα EEG, επιτρέποντας την ανίχνευση αφηρημένων μοτίβων που μπορεί να αποτελούν πρόκληση για απλούστερες μεθόδους αναγνώρισης.

Ισορροπημένη Απόδοση των SMO (SVM): Ο αλγόριθμος SMO (Support Vector Machine) πέτυχε επίπεδα ακρίβειας συγκρίσιμα με αυτά του Multilayer Perceptron, ενώ

συνεπαγόταν σημαντικά χαμηλότερο υπολογιστικό κόστος. Αυτό υποδηλώνει ότι το SMO είναι μια καλά ισορροπημένη και αποτελεσματική επιλογή για εφαρμογές που απαιτούν υψηλή απόδοση ταξινόμησης χωρίς να επιβάλλουν υπερβολικές απαιτήσεις πόρων.

Ευνοϊκή αντιστάθμιση που παρατηρήθηκε με το RandomForest και το AdaBoostM1:

Αυτοί οι αλγόριθμοι επέδειξαν επίσης εξαιρετική απόδοση ακρίβειας. Ενώ τείνουν να απαιτούν περισσότερους υπολογιστικούς πόρους σε σύγκριση με τα SVM, λόγω της προσέγγισής τους που βασίζεται σε σύνολο, προσφέρουν βελτιωμένη ευρωστία και μεγαλύτερη γενίκευση.

Πρακτικότητα Απλών Αλγορίθμων (NaiveBayes, J48):

Απλούστεροι αλγόριθμοι όπως ο NaiveBayes και ο J48, αν και με ελαφρώς χαμηλότερη ακρίβεια, επέδειξαν σημαντικά μειωμένο υπολογιστικό κόστος. Αυτό τους καθιστά κατάλληλους για εφαρμογές όπου οι υπολογιστικοί πόροι είναι περιορισμένοι ή για αρχικές εκτιμήσεις και γρήγορες αναλύσεις.

Υπολογιστικοί περιορισμοί: Σημαντικές διαφορές στη διάρκεια της εκπαίδευσης και των δοκιμών παρατηρήθηκαν σε όλα τα μοντέλα. Ενώ το Multilayer Perceptron επέδειξε υψηλή ακρίβεια, απαιτεί μια σχετικά μακρά διαδικασία εκπαίδευσης, η οποία μπορεί να δημιουργήσει προκλήσεις για εφαρμογές που απαιτούν συχνή επανεκπαίδευση. Ομοίως, αλγόριθμοι όπως Bagging, J48 και IBk έδειξαν εκτεταμένους χρόνους δοκιμών που θα μπορούσαν να είναι ακατάλληλοι για σενάρια σε πραγματικό χρόνο. Αυτά τα ευρήματα υπογραμμίζουν τη σημασία της προσεκτικής επιλογής αλγορίθμων, λαμβάνοντας υπόψη τις συγκεκριμένες λειτουργικές απαιτήσεις και περιορισμούς.

6.2 ΠΕΡΙΟΡΙΣΜΟΙ ΤΗΣ ΠΑΡΟΥΣΑΣ ΜΕΛΕΤΗΣ

Η παρούσα μελέτη, ενώ παρέχει πολύτιμες γνώσεις, έχει ορισμένους περιορισμούς που πρέπει να λαμβάνονται υπόψη κατά την ερμηνεία των ευρημάτων και τον σχεδιασμό μελλοντικής έρευνας.

Πιθανές αριθμητικές ανωμαλίες: Οι ιδιαίτερα υψηλές αριθμητικές τιμές που παρατηρούνται σε ορισμένους δείκτες απόδοσης μπορεί να δημιουργήσουν ανησυχία. Αυτό θα μπορούσε να υποδηλώνει την παρουσία σφαλμάτων κωδικοποίησης, πιθανή

υπερπροσαρμογή των μοντέλων στα δεδομένα εκπαίδευσης ή ανεπαρκή κανονικοποίηση των δεδομένων εισόδου. Για να εξασφαλιστεί η εμπιστοσύνη σε αυτά τα αποτελέσματα, συνιστάται περαιτέρω διερεύνηση και επικύρωση αυτών των τιμών. Μέχρι να ολοκληρωθεί αυτή η επαλήθευση, θα πρέπει να δίνεται προσοχή κατά την ερμηνεία της απόδοσης των μοντέλων.

Μέγεθος και ποιότητα συνόλου δεδομένων: Η αποτελεσματικότητα των μοντέλων μηχανικής μάθησης επηρεάζεται σε μεγάλο βαθμό από το μέγεθος, την ποιότητα και την αντιπροσωπευτικότητα του συνόλου δεδομένων. Εάν το σύνολο δεδομένων που χρησιμοποιήθηκε ήταν κάπως περιορισμένο ή δεν καταλάμβανε πλήρως το πλήρες φάσμα των πιθανών περιπτώσεων, τότε τα συμπεράσματα που εξάγονται μπορεί να έχουν περιορισμένη εφαρμογή σε ευρύτερα περιβάλλοντα.

Δυνατότητα βελτιωμένης απόδοσης μέσω βελτιστοποίησης υπερπαραμέτρων: Η μελέτη δεν περιλάμβανε μια ολοκληρωμένη ρύθμιση των υπερπαραμέτρων για κάθε αλγόριθμο. Δεδομένου ότι η επιλογή των βέλτιστων υπερπαραμέτρων μπορεί να επηρεάσει ουσιαστικά την απόδοση ενός μοντέλου, η ενσωμάτωση μιας τέτοιας βελτιστοποίησης μπορεί να είχε αποφέρει πιο ευνοϊκά αποτελέσματα για ορισμένους αλγόριθμους.

Εστίαση σε συγκεκριμένα χαρακτηριστικά ΗΕΓ: Η μελέτη βασίστηκε σε ένα συγκεκριμένο σύνολο χαρακτηριστικών που προέρχονται από τα σήματα ΗΕΓ. Η διερεύνηση ή η επιλογή εναλλακτικών χαρακτηριστικών, όπως εκείνων που σχετίζονται με αναλύσεις χρονικής συχνότητας ή συνδεσιμότητα, μπορεί να αποφέρει διαφορετικές πληροφορίες και να αποκαλύψει πρόσθετη δυναμική στα δεδομένα.

Περιορισμένη υλοποίηση σε πραγματικό χρόνο: Ενώ αναλύθηκαν οι χρόνοι εκτέλεσης, η μελέτη δεν περιελάμβανε μια ολοκληρωμένη υλοποίηση και δοκιμή των μοντέλων σε περιβάλλον πραγματικού χρόνου. Η διεξαγωγή μιας τέτοιας αξιολόγησης θα μπορούσε ενδεχομένως να αποκαλύψει πρόσθετα πρακτικά ζητήματα.

6.3 ΠΡΟΤΑΣΕΙΣ ΓΙΑ ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΚΑΙ ΕΠΕΚΤΑΣΗ

Βάσει των συμπερασμάτων και των περιορισμών της παρούσας μελέτης, προτείνονται οι ακόλουθες κατευθύνσεις για μελλοντική έρευνα και βελτιστοποίηση:

- **Αναθεώρηση και διόρθωση αριθμητικών τιμών:** Είναι επιτακτική ανάγκη να επανεξεταστούν διεξοδικά οι αριθμητικές τιμές των δεικτών απόδοσης. Αυτό μπορεί να επιτευχθεί με
 - a. **Χρήσης μεθόδων διασταυρούμενης επικύρωσης (cross-validation)** (π.χ., K-fold cross-validation) για πιο στιβαρή εκτίμηση της απόδοσης και αποφυγή υπερπροσαρμογής.
 - b. **Κανονικοποίηση (normalization) ή τυποποίηση (standardization)** των δεδομένων εισόδου πριν την εκπαίδευση των μοντέλων, για βελτίωση της σταθερότητας και της απόδοσης.
- **Βελτιστοποίηση υπερπαραμέτρων:** Μια ενδεδεγμένη και συστηματική εφαρμογή τεχνικών βελτιστοποίησης υπερπαραμέτρων (όπως αναζήτηση πλέγματος, τυχαία αναζήτηση, βελτιστοποίηση Bayes) για κάθε αλγόριθμο έχει τη δυνατότητα να αποφέρει αξιοσημείωτες βελτιώσεις στην απόδοση, ιδιαίτερα για εκείνους τους αλγόριθμους που έδειξαν συγκριτικά χαμηλότερα αποτελέσματα.
- **Εξερεύνηση Προηγμένων Αλγορίθμων και Αρχιτεκτονικών:**
 - Βαθιά Μάθηση (Deep Learning):** Πέρα από το βασικό MultilayerPerceptron, η διερεύνηση πιο σύνθετων αρχιτεκτονικών βαθιάς μάθησης, όπως τα Convolutional Neural Networks (CNNs) ή Recurrent Neural Networks (RNNs) ειδικά σχεδιασμένα για χρονοσειρές, θα μπορούσε να αποκαλύψει ακόμα πιο σύνθετα μοτίβα στα σήματα EEG.
 - Ensemble Μέθοδοι:** Πειραματισμός με άλλες ensemble μεθόδους (π.χ., Gradient Boosting Machines όπως XGBoost, LightGBM) που συχνά επιτυγχάνουν εξαιρετική ακρίβεια.
- **Ερμηνευσιμότητα (Explainability) των Μοντέλων:** Για εφαρμογές στον τομέα της υγείας, η κατανόηση του "γιατί" ένα μοντέλο έλαβε μια συγκεκριμένη απόφαση είναι εξίσου σημαντική με την ίδια την απόφαση. Η χρήση ερμηνεύσιμων μοντέλων (π.χ., LIME, SHAP) ή η ανάπτυξη εγγενώς ερμηνεύσιμων αλγορίθμων αποτελεί σημαντικό πεδίο μελλοντικής έρευνας.

ΠΑΡΑΡΤΗΜΑ - ΚΩΔΙΚΑΣ

```
# Εισαγωγή βιβλιοθηκών
import os
import numpy as np
import pandas as pd
import mne
import pyeeg

# Ορισμός του φακέλου με τα EEG δεδομένα
eeg_folder = 'C:/Users/stavr/ds004504/' # Προσαρμόστε τη διαδρομή
output_file = 'features_summary.csv' # Όνομα αρχείου εξόδου

# Δημιουργία λίστας για τα χαρακτηριστικά
all_features = []

# Διαδικασία επεξεργασίας για κάθε αρχείο
for root, dirs, files in os.walk(eeg_folder):
    for file in files:
        if file.endswith('.set'): # Φόρτωση μόνο αρχείων EEG τύπου .set
            eeg_file = os.path.join(root, file)
            print(f"Επεξεργασία αρχείου: {eeg_file}")

            # Φόρτωση δεδομένων
            raw_data = mne.io.read_raw_eeglab(eeg_file, preload=True)

            # Φιλτράρισμα δεδομένων
            raw_data.filter(0.5, 50.0, fir_design='firwin')

            # Απόκτηση δεδομένων
            eeg_data = raw_data.get_data() # Σχήμα: (κανάλια, δείγματα)
            sampling_frequency = int(raw_data.info['sfreq'])

            # Υπολογισμός χαρακτηριστικών για κάθε κανάλι
            for channel_idx, channel_data in enumerate(eeg_data):
                # Υπολογισμός Power Spectral Density (PSD)
                psds, freqs = mne.time_frequency.psd_array_welch(
                    channel_data.reshape(1, -1), sfreq=sampling_frequency,
                    fmin=0.5, fmax=50.0, n_fft=2048
                )
                psds = psds[0] # Απομόνωση δεδομένων από τη λίστα

                # Διαχωρισμός σε συχνотικές ζώνες
                delta_power = np.sum(psds[(freqs >= 0.5) & (freqs < 4)])
                theta_power = np.sum(psds[(freqs >= 4) & (freqs < 8)])
                alpha_power = np.sum(psds[(freqs >= 8) & (freqs < 12)])
                beta_power = np.sum(psds[(freqs >= 12) & (freqs < 30)])

            # Χρήση της δικής μας spectral_entropy
```

```

        spectral_entropy_value = pyeeg.spectral_entropy(
            channel_data, Band=[0.5, 4, 8, 12, 30],
Fs=sampling_frequency
        )

        # Προσθήκη χαρακτηριστικών
        all_features.append({
            'File': file,
            'Channel': raw_data.ch_names[channel_idx],
            'Delta Power': delta_power,
            'Theta Power': theta_power,
            'Alpha Power': alpha_power,
            'Beta Power': beta_power,
            'Spectral Entropy': spectral_entropy_value
        })

# Δημιουργία DataFrame και αποθήκευση σε CSV
features_df = pd.DataFrame(all_features)
features_df.to_csv(output_file, index=False)
print(f"Η εξαγωγή χαρακτηριστικών ολοκληρώθηκε. Αποθηκεύτηκε στο αρχείο:
{output_file}")

```

ΒΙΒΛΙΟΓΡΑΦΙΑ

Aayush Mishra, David Joffe, Sankara Surendra Telidevara, David S Oakley, Anqi Liu, 2025. *On the challenges of detecting MCI using EEG in the wild*, ΗΠΑ: Johns Hopkins University.

Ali Mohammad Alqudah, Z. M., 2025. *A Review of Deep Learning for Biomedical Signals: Current Applications, Advancements, Future Prospects, Interpretation, and Challenges*. [Ηλεκτρονικό]

Available at: <http://www.techscience.com/cmc/v83n3/61052>

[Πρόσβαση 24 Ιούνιος 2025].

Aljanabi, E. a. I. T., 2025. *Connectogram-COH: A Coherence-Based Time-Graph Representation for EEG-Based Alzheimer's Disease Detection..* [Ηλεκτρονικό]

Available at: <https://doi.org/10.3390/diagnostics15111441>

[Πρόσβαση 28 Ιούνιος 2025].

American Clinical Neurophysiology Society (ACNS) , 2025. *History*. [Ηλεκτρονικό]

Available at: <https://www.acns.org/about-acns/history>

[Πρόσβαση 24 Ιούνιος 2025].

Andrea Zanola, L. F. T. F. D. P. M. B. M. A., 2025. *xEEGNet: Towards Explainable AI in EEG Dementia Classification*. [Ηλεκτρονικό]

Available at: <https://arxiv.org/abs/2504.21457>

[Πρόσβαση 25 Ιούνιος 2025].

Andres M., K. M., 2024. *Video EEG Test*. [Ηλεκτρονικό]

Available at: <https://www.epilepsy.com/diagnosis/eeg/video-eeg>

[Πρόσβαση 24 Ιούνιος 2025].

Aviles, M., Sánchez-Reyes, L., Álvarez-Alvarado, J. & Rodríguez-Reséndiz, J., 2024. *Machine and Deep Learning Trends in EEG-Based Detection and Diagnosis of Alzheimer's Disease: A Systematic Review..* [Ηλεκτρονικό]

Available at: <https://doi.org/10.3390/eng5030078>

[Πρόσβαση 29 Ιούνιος 2025].

Bao, F. S. L. X. Z. C., 2011. *PyEEG: An Open Source Python Module for EEG/MEG Feature Extraction*. [Ηλεκτρονικό]

Available at: <https://doi.org/10.1155/2011/406391>

[Πρόσβαση 25 Ιούνιος 2025].

Biasiucci, A. F. B. & M. M. M., 2019. *Electroencephalography*. [Ηλεκτρονικό]

Available at: <https://doi.org/10.1016/j.cub.2018.11.052>

[Πρόσβαση 28 Ιούνιος 2025].

Blaj, A., 2025. *EEG or MRI? When to Choose the Right Brain Imaging Tool*. [Ηλεκτρονικό]

Available at: <https://blog.medicalai.io/en/what-can-an-eeg-show-that-an-mri-cannot/>

[Πρόσβαση 26 Ιούνιος 2025].

Britton JW, F. L. H. J. a., 2016. *Electroencephalography (EEG): An Introductory Text and Atlas of Normal and Abnormal Findings in Adults, Children, and Infants*. [Ηλεκτρονικό]

Available at: <https://www.ncbi.nlm.nih.gov/books/NBK390346/>

[Πρόσβαση 25 Ιούνιος 2025].

Choi, B. J., 2025. *Geometric Machine Learning on EEG Signals*. [Ηλεκτρονικό]

Available at: <https://arxiv.org/abs/2502.05334>

[Πρόσβαση 27 Ιούνιος 2025].

DTU Health Tech, 2025. *Biomedical Signal Processing*. [Ηλεκτρονικό]

Available at: <https://www.healthtech.dtu.dk/research/research-sections/section-digital-health/group-biomedical-signal-processing>

[Πρόσβαση 25 Ιούνιος 2025].

Durongbhan, P. a. Z. Y. a. C. L. a. Z. P. a. D. M. M. a. U. Z. C. a. V. A. a. H. X. a. L. S. a. Z. Y. a. B. D. J. a. S. P. G., 2019. *A Dementia Classification Framework Using Frequency and Time-Frequency Features Based on EEG Signals*. [Ηλεκτρονικό]

Available at: <https://ieeexplore.ieee.org/abstract/document/8681406>

[Πρόσβαση 19 Ιούνιος 2025].

epilepsy foundation, 2019. *Tests and Investigation*. [Ηλεκτρονικό]

Available at: <https://epilepsyfoundation.org.au/understanding-epilepsy/diagnosing-epilepsy/testing-and-investigation/?pdf=496>

[Πρόσβαση 25 Ιούνιος 2025].

generated, S. L. A., 2025. *The Power of EEG in Neuroscience Research*. [Ηλεκτρονικό]

Available at: www.numberanalytics.com/blog/eeg-in-neuroscience-research

[Πρόσβαση 26 Ιούνιος 2025].

Inhea Jeong ab, W. G. C. a. E. K. a. W. P. a. H. S. a. J. L. a. M. O. a. E. K. a. J. P. a. T. L. a. D. K. a. S. H. A. a. S. K. a. H. C. O. I. a. J.-U. P., 2025. *Machine learning in biosignal analysis from wearable devices*. [Ηλεκτρονικό]

Available at: <https://pubs.rsc.org/en/content/articlehtml/2025/mh/d5mh00451a>

[Πρόσβαση 26 Ιούνιος 2025].

Jang, K. K. Y. J. H. e. a., 2025. *Dementia classification using two-channel electroencephalography features..* [Ηλεκτρονικό]

Available at: <https://doi.org/10.1038/s41598-025-93513-4>

[Πρόσβαση 27 Ιούνιος 2025].

Jungrungrueang, T., Chairat, S., Rasitanon, K., Limsakul, P., & Charupanit, K. (2025)., 2025.

Translational approach for dementia subtype classification using convolutional neural network

based on EEG connectome dynamics.. [Ηλεκτρονικό]

Available at: <https://doi.org/10.1038/s41598-025-02018-7>

[Πρόσβαση 28 Ιούνιος 2025].

K. AlSharabi, Y. B. S. A. M. A. M. A. a. F. A. A., 2022. *EEG Signal Processing for Alzheimer's Disorders Using Discrete Wavelet Transform and Machine Learning Approaches.* [Ηλεκτρονικό]

Available at: <https://ieeexplore.ieee.org/document/9857825?denied=>

[Πρόσβαση 22 Ιούνιος 2025].

K. AlSharabi, Y. B. S. A. M. A. M. A. a. F. A. A., 2022. *EEG Signal Processing for Alzheimer's Disorders Using Discrete Wavelet Transform and Machine Learning Approaches.* [Ηλεκτρονικό]

Available at: <https://ieeexplore.ieee.org/abstract/document/9857825>

[Πρόσβαση 24 Ιούνιος 2025].

Lal, U., Chikkankod, A. & Longo, L., 2024. *A Comparative Study on Feature Extraction Techniques for the Discrimination of Frontotemporal Dementia and Alzheimer's Disease with Electroencephalography in Resting-State Adults..* [Ηλεκτρονικό]

Available at: <https://doi.org/10.3390/brainsci14040335>

[Πρόσβαση 25 Ιούνιος 2025].

Light, G. A. W. L. E. M. F. S. J. R. A. S. R. S. N. R. & B. D. L., 2010. *Electroencephalography (EEG) and Event-Related Potentials (ERP's) with Human Participants.* [Ηλεκτρονικό]

Available at: <https://doi.org/10.1002/0471142301.ns0625s52>

[Πρόσβαση 27 Ιούνιος 2025].

Miltiadous, A. T. K. D. A. T. I. P. G. N. T. D. G. A. P. T. M. G. G. E. G. N. & T. A. T., 2023. *A Dataset of Scalp EEG Recordings of Alzheimer's Disease, Frontotemporal Dementia and Healthy Subjects from Routine EEG..* [Ηλεκτρονικό]

Available at: <https://doi.org/10.3390/data8060095>

[Πρόσβαση 29 Ιουνίος 2025].

NHS, 2025. *Electroencephalogram (EEG).* [Ηλεκτρονικό]

Available at: <https://www.nhs.uk/tests-and-treatments/electroencephalogram/>

[Πρόσβαση 25 Ιούνιος 2025].

Noor, R. & Z. O., 2025. *Machine Learning in Biomedical Signal Processing: A Next- Generation Approach for Early Disease Detection..* [Ηλεκτρονικό]

Available at:

[https://www.researchgate.net/publication/388641297 Machine Learning in Biomedical Signal Processing A Next- Generation Approach for Early Disease Detection](https://www.researchgate.net/publication/388641297_Machine_Learning_in_Biomedical_Signal_Processing_A_Next-Generation_Approach_for_Early_Disease_Detection)

[Πρόσβαση 26 Ιούνιος 2025].

Paik, M.-j. K. a. Y. C. Y. a. J., 2023. *Deep learning-based EEG analysis to classify normal, mild cognitive impairment, and dementia: Algorithms and dataset*. [Ηλεκτρονικό]

Available at: <https://www.sciencedirect.com/science/article/pii/S1053811923002008>

[Πρόσβαση 26 Ιούνιος 2025].

Peltola, M. E. L. M. H. J. J. V. K. P. K. K. P. R. M. M. I. M. L. C. L. L. & B. S., 2023. *Routine and sleep EEG: Minimum recording standards of the International Federation of Clinical Neurophysiology and the International League Against Epilepsy*.. [Ηλεκτρονικό]

Available at: <https://doi.org/10.1111/epi.17448>

[Πρόσβαση 24 Ιούνιος 2025].

Pirrone, D. και συν., 2022. *EEG Signal Processing and Supervised Machine Learning to Early Diagnose Alzheimer's Disease*.. [Ηλεκτρονικό]

Available at: <https://doi.org/10.3390/app12115413>

[Πρόσβαση 24 Ιούνιος 2025].

Scarpino, M. V. M. T. G. A. L. F. P. B. N. P. N. P. B. C. & N. A., 2025. *The role of EEG in the emergency department: Its contribution to the patient's diagnostic-therapeutic pathway*..

[Ηλεκτρονικό]

Available at: <https://doi.org/10.1016/j.cnp.2025.02.010>

[Πρόσβαση 23 Ιούνιος 2025].

Sérgio Daniel Rodrigues, P. M. R., 2024. *Electroencephalogram-based time-frequency analysis for Alzheimer's disease detection using machine learning*.. [Ηλεκτρονικό]

Available at: <https://doi.org/10.14440/jbm.2025.0069>

[Πρόσβαση 28 Ιούνιος 2025].

Society, A. C. N., 2006. *Guideline 3: Minimum Technical Standards for EEG Recording in Suspected Cerebral Death*, ΗΠΑ: American Clinical Neurophysiology Society .

vedantu, 2025. *Electroencephalography (EEG)*. [Ηλεκτρονικό]
Available at: <https://www.vedantu.com/biology/electroencephalography>
[Πρόσβαση 27 Ιουνίου 2025].

Wikipedia, 2025. <https://en.wikipedia.org>. [Ηλεκτρονικό]
Available at: [https://en.wikipedia.org/wiki/Weka_\(software\)](https://en.wikipedia.org/wiki/Weka_(software))
[Πρόσβαση 28 6 2025].

Yihe Wang, N. H. N. M. M. C. X. Z., 2025. *LEAD: Large Foundation Model for EEG-Based Alzheimer's Disease Detection*. [Ηλεκτρονικό]
Available at: <https://openreview.net/forum?id=cz4EevJGHf>
[Πρόσβαση 28 Ιουνίου 2025].

Γκίζα, Ο. Β., 2021. *ΧΡΗΣΗ ΑΛΓΟΡΙΘΜΩΝ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΓΙΑ ΤΗΝ ΑΝΑΛΥΣΗ EEG ΜΕ ΕΦΑΡΜΟΓΗ ΣΤΗΝ ΆΝΟΙΑ*, Άρτα: ΠΑΝΕΠΙΣΤΗΜΙΟ ΙΩΑΝΝΙΝΩΝ.

Διαμαντίδου, Ε., 2020. *Νέες τεχνολογίες ως εργαλείο στην αντιμετώπιση της άνοιας*, Αθήνα: Πανεπιστήμιο Δυτικής Αττικής.

Ελένη, Π., 2013 - 2015. *ΑΠΟΤΕΛΕΣΜΑΤΙΚΟΤΗΤΑ ΔΙΕΤΟΥΣ ΝΟΗΤΙΚΗΣ ΕΚΠΑΙΔΕΥΣΗΣ ΣΕ ΑΣΘΕΝΕΙΣ ΜΕ ΗΠΙΑ ΑΝΟΙΑ*, Αλεξανδρούπολη: ΔΗΜΟΚΡΙΤΕΙΟ ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΡΑΚΗΣ .

Zikos, P., 2025. *Άνοια με σωμάτια Lewy*. [Ηλεκτρονικό]
Available at: <https://zikospanagiotis.gr/department/anoia-me-somatia-levy/>
[Πρόσβαση 22 Απρίλιος 2025].

Κολέντση Φωτεινή, Κ. Θ., 2022. *Μη φαρμακευτικές παρεμβάσεις στην άνοια*, Αθήνα: Πανεπιστήμιο Δυτικής Αττικής.

Κοντομάρη, Μ., Ζορμπά, Γ. & Τσοφύλα, Μ., 2021. *Η επιβάρυνση φροντιστών ασθενών με άνοια τη περίοδο της πανδημίας του Covid-19*, Πάτρα: Πανεπιστήμιο Πατρών.

Κορωναίου, Β., 2016. *Τεχνικές Πρόληψης και αντιμετώπισης της άνοιας*, Πάτρα: ΤΕΙ Δυτικής Ελλάδας.

Κουλούρη, Μ. Δ., 2024. *ΕΦΑΡΜΟΓΕΣ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΣΤΗΝ ΝΟΣΟ ΤΟΥ ALZHEIMER*, Πειραιάς: Πανεπιστήμιο Πειραιώς.

Προεστάκη, Χ., 2023. *Ερμηνεύσιμη Μηχανική Μάθηση για τη μελέτη της εξέλιξης της Ήπιας Μορφής Νοητικής Εξασθένησης σε Άνοια*, Αθήνα: ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ.

Τριανταφύλλου, Ν. & Κουλαργιός, Κ., 2022. *Αλκοολική Άνοια*, Ιωάννινα: ΠΑΝΕΠΙΣΤΗΜΙΟ ΙΩΑΝΝΙΝΩΝ.

Φραντζίδης, Χ., 2014. *Ανίχνευση συναισθηματικού περιεχομένου σε άτομα τρίτης ηλικίας με τη χρήση γραμμικών και μη γραμμικών τεχνικών επεξεργασίας νευροφυσιολογικών καταγραφών*, Θεσσαλονίκη: Αριστοτέλειο Πανεπιστήμιο .