



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ
ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΣΥΣΤΗΜΑΤΩΝ ΜΕΤΑΔΟΣΗΣ ΠΛΗΡΟΦΟΡΙΑΣ
ΚΑΙ ΤΕΧΝΟΛΟΓΙΑΣ ΥΛΙΚΩΝ

Εφαρμογές των Ακουστικών Προκλητών Δυναμικών σε
κλινικό κι ερευνητικό τομέα

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Παντελεήμων Κοτρόζος

Επιβλέπων: Δημήτριος - Διονύσιος Κουτσούρης

Καθηγητής Ε.Μ.Π

Συνεπιβλέπουσα: Ουρανία Πετροπούλου

ΕΔΙΠ Ε.Μ.Π

Αθήνα, Οκτώβριος 2022



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ
ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΣΥΣΤΗΜΑΤΩΝ ΜΕΤΑΔΟΣΗΣ ΠΛΗΡΟΦΟΡΙΑΣ
ΚΑΙ ΤΕΧΝΟΛΟΓΙΑΣ ΥΛΙΚΩΝ

Εφαρμογές των Ακουστικών Προκλητών Δυναμικών σε
κλινικό κι ερευνητικό τομέα

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Παντελεήμων Κοτρόζος

Επιβλέπων: Δημήτριος - Διονύσιος Κουτσούρης

Καθηγητής Ε.Μ.Π

Συνεπιβλέπουσα: Ουρανία Πετροπούλου

ΕΔΙΠ Ε.Μ.Π

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 31η Οκτωβρίου 2022

.....

Δ.-Δ. Κουτσούρης

Καθηγητής Ε.Μ.Π.

.....

Γεώργιος Ματσόπουλος

Καθηγητής Ε.Μ.Π

.....

Παναγιώτης Τσανάκας

Καθηγητής Ε.Μ.Π.

Αθήνα, Οκτώβριος 2022

.....
Παντελεήμων Κοτρόζος

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

Copyright © Κοτρόζος Παντελεήμων, 2022

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας, εξ ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για σκοπό μη κερδοσκοπικό, εκπαιδευτικής ή ερευνητικής φύσης, υπό την προϋπόθεση να αναφέρεται η πηγή προέλευσης και να διατηρείται το παρόν μήνυμα. Ερωτήματα που αφορούν τη χρήση της εργασίας για κερδοσκοπικό σκοπό πρέπει να απευθύνονται προς τον συγγραφέα. Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν το συγγραφέα και δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις επίσημες θέσεις του Εθνικού Μετσόβιου Πολυτεχνείου.

Περίληψη

Οι πρόσφατες εξελίξεις στη μηχανική μάθηση έχουν οδηγήσει σε ένα κύμα ενδιαφέροντος για την ταξινόμηση των Ακουστικών Προκλητών Δυναμικών και κυρίως των Ακουστικών Προκλητών Δυναμικών του Εγκεφαλικού Στελέχους. Στην παρούσα διπλωματική εργασία πραγματοποιείται μια αναζήτηση στις βάσεις δεδομένων PubMed, Google Scholar, SpringerLink, ScienceDirect και Scopus και εντοπίζονται 19 μελέτες που διερεύνησαν τη χρήση της μηχανικής μάθησης για την ταξινόμηση των Ακουστικών Προκλητών Δυναμικών ως συμπληρωματική και αντικειμενική μέθοδο. Η διαδικασία αυτή μπορεί να βοηθήσει τους κλινικούς ιατρούς να διαγνώσουν αποτελεσματικότερα τη δυσλειτουργία της ακοής διακρίνοντας καλύτερα τις υγιείς από τις παθολογικές κυματομορφές ακουστικών προκλητών δυναμικών. Επίσης μπορεί όχι μόνο να παρουσιάσει έναν νευρωνικό δείκτη για τις ρυθμίσεις μελλοντικών υποσχόμενων εφαρμογών σχετικά με την ακουστική περίθαλψη αλλά και να παράσχουν έναν βιομετρικό δείκτη για τις διακρίσεις των χαρακτηριστικών των ατόμων. Κάποια σύγκριση μεταξύ των μελετών που παρουσιάζονται σε αυτήν την εργασία δεν είναι δυνατή καθώς χρησιμοποίησαν διαφορετικά υποκείμενα δοκιμής, μεγέθη ομάδων και ερεθίσματα και αξιολόγησαν διαφορετικά την ακουστική απόκριση του εγκεφαλικού στελέχους. Αντίθετα, θα παρουσιαστεί το αποτέλεσμα αυτών των μελετών και θα συζητηθούν οι περιορισμοί τους καθώς και οι πιθανές εφαρμογές τους. Συνολικά, τα ευρήματα αυτών των μελετών υποδηλώνουν ότι η ταξινόμηση των Ακουστικών Προκλητών Δυναμικών με χρήση μηχανικής μάθησης είναι ένα πολλά υποσχόμενο εργαλείο για την αξιολόγηση ασθενών με απώλεια ακοής, τη βελτιστοποίηση τεχνολογιών για την ρύθμιση ακουστικών βοηθημάτων και τη διάκριση των χαρακτηριστικών των ατόμων.

Λέξεις Κλειδιά: Ακουστικά Προκλητά Δυναμικά; Ακουστικά Προκλητά Δυναμικά Εγκεφαλικού Στελέχους; Μεσαία Ακουστικά Δυναμικά; Μηχανική Μάθηση; Τεχνητή Νοημοσύνη; Ταξινόμηση; Εξαγωγή Χαρακτηριστικών;

Abstract

The latest developments of machine learning have led generation for the classification of auditory evoked potentials and mainly for auditory brainstem responses. In this dissertation we went through research on the database PubMed, Google Scholar, SpringerLink, ScienceDirect and Scopus that explored 90 studies which investigated the use of machine learning for the classification of auditory evoked potentials as a complementary and impartial method. This process can be very helpful for the clinical doctors to effectively diagnose the hearing malfunction by seeing the difference between the healthy and pathological evoked responses. In addition, not only can it present a neurological indicator which can regulate promising future implements regarding the hearing care but also provide a biometrical indicator which distinguishes the individual characteristics. We cannot make a comparison between the studies which are presented in this dissertation as we used different testing subjects, groups and stimuli which evaluated differently the hearing response of the brainstem. Conversely, the results of these studies are going to be presented as well as their restrictions and potentials implementation. All in all, the findings of these studies show that the classification of auditory evoked potentials by using machine learning, is a very promising tool for assessing patients with hearing loss, optimizing technologies for tuning hearing aids, and discriminating between subjects.

Key words: Auditory evoked potential; Auditory brainstem response; Auditory middle latency response; Classification; Feature Extraction; Artificial Intelligence; Machine Learning;

Ευχαριστίες

Με τη συγγραφή της παρούσης διπλωματικής εργασίας, ολοκληρώνεται η απόκτηση του διπλώματος Ηλεκτρολόγου Μηχανικού και Μηχανικού Η/Υ από την ομώνυμη σχολή του Εθνικού Μετσόβιου Πολυτεχνείου. Η πορεία μου έως τώρα, δε θα ήταν δυνατή χωρίς τη βοήθεια ορισμένων ατόμων που θα ήθελα να ευχαριστήσω από καρδιάς. Καταρχάς, θα ήθελα να ευχαριστήσω τον κ. Δημήτριο Κουτσούρη, Καθηγητή Ε.Μ.Π., για την ευκαιρία που μου προσέφερε κατά την ανάθεση της διπλωματικής μου εργασίας στο Εργαστήριο Βιοϊατρικής Τεχνολογίας του Εθνικού Μετσόβιου Πολυτεχνείου. Επίσης, θα ήθελα να ευχαριστήσω ιδιαίτερω την Δρ. Ουρανία Πετροπούλου, ΕΔΙΠ Ε.Μ.Π καθώς και την Ουρανία Μαντά, ΥΔ στο Εργαστήριο Βιοϊατρικής Τεχνολογίας Ε.Μ.Π για την άριστη συνεργασία, την καθοδήγηση και τον πολύτιμο χρόνο που διέθεσαν για να με βοηθήσουν κατά την εκπόνηση της εργασίας. Κλείνοντας, θα ήθελα επίσης με όλη μου την καρδιά να ευχαριστήσω την οικογένειά μου και τους κοντινούς μου ανθρώπους, οι οποίοι ήταν δίπλα μου σε κάθε δύσκολη στιγμή, καθώς και τους φίλους και συμφοιτητές, οι οποίοι με στήριξαν σε όλη αυτήν την προσπάθεια.

Πρόλογος

Η παρούσα διπλωματική εργασία, διεκπεραιώθηκε με σκοπό να αναδείξει τη θετική επίδραση που μπορεί να έχει η μηχανική μάθηση στην ανάλυση των κυματομορφών που προκύπτουν από τα ακουστικά προκλητά δυναμικά. Η δομή της εργασίας συνοψίζεται ως εξής: Στο πρώτο κεφάλαιο δίνονται ορισμοί για τα Ακουστικά Προκλητά Δυναμικά (ΑΠΔ) και συγκεκριμένα αναλύονται τα Ακουστικά Προκλητά Δυναμικά του Εγκεφαλικού Στελέχους (ΑΠΔΕΣ) και τα Μεσαία Ακουστικά Δυναμικά (ΜΑΔ). Στη συνέχεια, περιγράφεται η διαδικασία καταγραφής των ΑΠΔΕΣ και ΜΑΔ και αναφέρονται οι κυριότερες κλινικές εφαρμογές της εξέτασής τους. Στο δεύτερο κεφάλαιο γίνεται μια αναφορά στην τεχνητή νοημοσύνη και ειδικότερα στη μηχανική μάθηση που αποτελεί παρακλάδι αυτής. Ακολούθως, στο κεφάλαιο τρία αναλύονται αδρά οι τεχνολογίες και τεχνικές που χρησιμοποιήθηκαν για την ανάλυση των δεδομένων των μελετών των ΑΠΔ και παρουσιάζεται η διαθέσιμη σχετική βιβλιογραφία. Αντί επιλόγου, στο τέταρτο και πέμπτο κεφάλαιο, αναφέρονται οι δυσκολίες που προέκυψαν, περιορισμοί που λήφθηκαν υπόψιν και παρουσιάζονται πιθανές μελλοντικές επεκτάσεις.

Ευρετήριο Εικόνων

ΕΙΚΟΝΑ 1 ΤΥΠΙΚΗ ΚΥΜΑΤΟΜΟΡΦΗ ΑΠΔΕΣ [11].....	15
ΕΙΚΟΝΑ 2 ΝΕΥΡΙΚΑ ΚΕΝΤΡΑ ΠΑΡΑΓΩΓΗΣ ΤΩΝ ΑΚΟΥΣΤΙΚΩΝ ΠΡΟΚΛΗΤΩΝ ΔΥΝΑΜΙΚΩΝ ΕΓΚΕΦΑΛΙΚΟΥ ΣΤΕΛΕΧΟΥΣ[12].....	16
ΕΙΚΟΝΑ 3 ΑΠΕΙΚΟΝΙΣΗ ΚΥΜΑΤΟΜΟΡΦΗΣ ΜΑΔ ΔΕΙΧΝΟΝΤΑΣ ΤΑ ΔΙΑΦΟΡΑ ΚΥΜΑΤΑ ΚΑΙ ΕΝΑ ΠΑΡΑΔΕΙΓΜΑ ΜΕΤΡΗΣΗΣ ΚΑΘΥΣΤΕΡΗΣΗΣ ΚΑΙ ΠΛΑΤΟΥΣ [14]	17
ΕΙΚΟΝΑ 4 ΤΟΠΟΘΕΤΗΣΗ ΗΛΕΚΤΡΟΔΙΩΝ ΣΤΟΝ ΑΣΘΕΝΗ [28]	19
ΕΙΚΟΝΑ 5 Η ΜΗΧΑΝΗ ΒΟΜΒΕ [42].....	24
ΕΙΚΟΝΑ 6 Η ΣΧΕΣΗ ΜΕΤΑΞΥ ARTIFICIAL INTELLIGENCE, MACHINE LEARNING ΚΑΙ DEEP LEARNING [52]	28
ΕΙΚΟΝΑ 7 ΣΦΑΙΡΙΚΗ ΕΙΚΟΝΑ ΤΗΣ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΣΕ ΕΝΑ ΕΕΓ [57]	31
ΕΙΚΟΝΑ 8 ΓΡΑΜΜΙΚΟΣ ΤΑΞΙΝΟΜΗΤΗΣ SVM [55].....	33
ΕΙΚΟΝΑ 9 ΑΝΤΙΛΗΨΗ ΤΟΥ KNN [61]	34
ΕΙΚΟΝΑ 10 ΜΟΝΤΕΛΟ ΠΟΛΥΣΤΡΩΜΑΤΙΚΟΥ PERCEPTRON. ΤΟ Χ ΥΠΟΔΗΛΩΝΕΙ ΜΕΤΑΒΛΗΤΗ ΕΙΣΟΔΟΥ. ΤΟ Η ΥΠΟΔΗΛΩΝΕΙ ΚΡΥΦΗ ΜΕΤΑΒΛΗΤΗ. ΤΟ Υ ΥΠΟΔΗΛΩΝΕΙ ΤΗΝ ΕΞΟΔΟ ΤΟΥ ΤΑΞΙΝΟΜΗΤΗ [57]	35
ΕΙΚΟΝΑ 11 ΑΠΟΔΟΣΗ ΤΑΞΙΝΟΜΗΤΗ MLP ΧΡΗΣΙΜΟΠΟΙΩΝΤΑΣ ΠΡΟΤΥΠΑ ΔΟΚΙΜΩΝ [74].....	40
ΕΙΚΟΝΑ 12 ΑΠΟΔΟΣΗ ΤΑΞΙΝΟΜΗΤΗ ΕΝ ΧΡΗΣΙΜΟΠΟΙΩΝΤΑΣ ΠΡΟΤΥΠΑ ΔΟΚΙΜΩΝ [74]	40
ΕΙΚΟΝΑ 13 ΔΕΙΚΤΗΣ ΒΑΘΜΟΛΟΓΙΑΣ ΙΣΧΥΟΣ ΓΑΜΜΑ ΑΠΟ ΔΕΚΑΕΝΝΕΑ ΚΑΝΑΛΙΑ ΗΛΕΚΤΡΟΔΙΩΝ [75].....	41
ΕΙΚΟΝΑ 14 ΑΚΡΙΒΕΙΑ ΤΑΞΙΝΟΜΗΣΗΣ ΓΙΑ MLPNN ΜΟΝΤΕΛΑ [76].....	42
ΕΙΚΟΝΑ 15 ΑΚΡΙΒΕΙΑ ΤΑΞΙΝΟΜΗΣΗΣ ΓΙΑ ELN ΜΟΝΤΕΛΑ [76].....	43
ΕΙΚΟΝΑ 16 ΜΕΓΙΣΤΗ ΑΠΟΔΟΣΗ ΑΚΡΙΒΕΙΑΣ ΕΚΠΑΙΔΕΥΜΕΝΟΥ ΜΟΝΤΕΛΟΥ ΚΑΙ ΑΠΟΚΡΙΣΗ ΚΑΘΥΣΤΕΡΗΣΗΣ ΓΙΑ ΤΗΝ ΑΝΑΛΥΣΗ ΟΛΟΚΛΗΡΟΥ ΤΟΥ ΕΓΚΕΦΑΛΟΥ. ΑΡΙΣΤΕΡΑ: ΚΑΘΑΡΗ ΚΑΤΑΣΤΑΣΗ ΟΜΙΛΙΑΣ. ΔΕΞΙΑ: ΚΑΤΑΣΤΑΣΗ ΟΜΙΛΙΑΣ ΜΕ ΥΠΟΒΑΘΜΙΣΗ ΤΟΥ ΘΟΡΥΒΟΥ. Η LH ΑΝΑΦΕΡΕΤΑΙ ΩΣ ΑΡΙΣΤΕΡΟ ΗΜΙΣΦΑΙΡΙΟ. Η RH ΑΝΑΦΕΡΕΤΑΙ ΩΣ ΔΕΞΙΟ ΗΜΙΣΦΑΙΡΙΟ. ΤΟ WHOLE ΑΝΑΦΕΡΕΤΑΙ ΣΤΑ ΔΕΔΟΜΕΝΑ ΟΛΟΚΛΗΡΟΥ ΤΟΥ ΕΓΚΕΦΑΛΟΥ [84].....	46
ΕΙΚΟΝΑ 17 ΧΡΟΝΙΚΑ ΜΕΤΑΒΑΛΛΟΜΕΝΗ ΤΑΞΙΝΟΜΗΣΗ ΟΜΑΔΑΣ (NH ΕΝΑΝΤΙ HI) ΩΣ ΣΥΝΑΡΤΗΣΗ ΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΕΔΟΜΕΝΩΝ (ΣΥΝΘΗΚΕΣ ΚΑΘΑΡΟΥ ΚΑΙ ΘΟΡΥΒΟΥ) ΚΑΙ ΤΟΥ ΗΜΙΣΦΑΙΡΙΟΥ. ΑΚΡΙΒΕΙΑ ΤΑΞΙΝΟΜΗΣΗΣ ΟΜΑΔΑΣ ΑΠΟ (Α) ΔΕΔΟΜΕΝΑ ΟΛΟΚΛΗΡΟΥ ΤΟΥ ΕΓΚΕΦΑΛΟΥ (ΚΑΙ ΤΑ 68 ROI), (Β) ΔΕΔΟΜΕΝΑ LH ΜΟΝΟ (34 ROI) ΚΑΙ (C) ΔΕΔΟΜΕΝΑ RH ΜΟΝΟ (34 ROI). LH ΑΡΙΣΤΕΡΟ ΗΜΙΣΦΑΙΡΙΟ; RH ΔΕΞΙΟ ΗΜΙΣΦΑΙΡΙΟ. 0 MS = ΕΝΑΡΞΗ ΕΡΕΘΙΣΜΑΤΟΣ. Η ΠΡΑΣΙΝΗ ΣΥΜΠΛΗΡΩΣΗ ΓΡΑΜΜΗ ΥΠΟΔΕΙΚΝΥΕΙ ΔΙΑΧΩΡΙΣΜΟ ΟΜΑΔΑΣ ΚΑΤΑ ΤΗΝ ΚΑΘΑΡΗ ΑΝΤΙΛΗΨΗ ΟΜΙΛΙΑΣ, Η ΚΟΚΚΙΝΗ ΔΙΑΚΕΚΟΜΜΕΝΗ ΓΡΑΜΜΗ ΥΠΟΔΕΙΚΝΥΕΙ ΔΙΑΧΩΡΙΣΜΟ ΟΜΑΔΑΣ ΚΑΤΑ ΤΗΝ ΑΝΤΙΛΗΨΗ ΟΜΙΛΙΑΣ ΜΕ ΥΠΟΒΑΘΜΙΣΗ ΤΟΥ ΘΟΡΥΒΟΥ [84].	47
ΕΙΚΟΝΑ 18 ΜΕΓΙΣΤΗ ΑΚΡΙΒΕΙΑ ΤΑΞΙΝΟΜΗΤΗ (ΑΞΟΝΑΣ Υ) ΚΑΙ ΑΝΤΙΣΤΟΙΧΗ ΚΑΘΥΣΤΕΡΗΣΗ (ΑΞΟΝΑΣ Χ) ΓΙΑ ΤΗ ΔΙΑΚΡΙΣΗ ΑΚΡΟΑΤΩΝ NH ΚΑΙ HI ΧΡΗΣΙΜΟΠΟΙΩΝΤΑΣ ΠΛΑΤΗ ΠΗΓΗΣ ΑΠΟ ΤΟ ΟΛΟΚΛΗΡΟΣ ΕΓΚΕΦΑΛΟΣ (ΜΠΛΕ ΤΡΙΓΩΝΟ) ΚΑΙ LH (ΠΟΡΤΟΚΑΛΙ ΤΕΤΡΑΓΩΝΟ) ΕΝΑΝΤΙ RH (ΠΡΑΣΙΝΟΣ ΚΥΚΛΟΣ) ΧΩΡΙΣΤΑ. (Α) ΣΑΦΕΙΣ ΑΠΑΝΤΗΣΕΙΣ ΟΜΙΛΙΑΣ. (Β) ΑΠΟΚΡΙΣΕΙΣ ΟΜΙΛΙΑΣ ΜΕ ΥΠΟΒΑΘΜΙΣΗ ΤΟΥ ΘΟΡΥΒΟΥ.	47

Περιεχόμενα

Περίληψη.....	5
Abstract	6
Ευχαριστίες.....	7
Πρόλογος.....	8
Ευρετήριο Εικόνων	9
1 Εισαγωγή.....	11
1.1 Προκλητά δυναμικά εγκεφάλου	12
1.2 Ακουστικά προκλητά δυναμικά	12
1.2.1 Ακουστικά προκλητά δυναμικά εγκεφαλικού στελέχους	13
1.2.2 Μεσαία ακουστικά δυναμικά	16
1.3 Καταγραφή Ακουστικών Προκλητών Δυναμικών	18
1.4 Κλινική χρήση των ΑΠΔΕΣ και ΜΑΔ	20
1.4.1 Κλινική χρήση των ΑΠΔΕΣ.....	20
1.4.2 Κλινική χρήση των ΜΑΔ.....	22
2 Τεχνητή Νοημοσύνη (Artificial Intelligence).....	24
2.1 Ιστορική Αναδρομή	24
2.2 Μηχανική Μάθηση (Machine Learning)	26
3 Μηχανική μάθηση και ακουστικά προκλητά δυναμικά	28
3.1 Εισαγωγή	29
3.2 Μεθοδολογία.....	30
3.3 Αλγόριθμοι μηχανικής μάθησης	31
3.3.1 Support Vector Machine (SVM).....	32
3.3.2 K-Nearest Neighbours (KNN).....	33
3.3.3 Naïve Bayes (NB).....	34
3.3.4 Multilayer perceptron neural network (MLPNN).....	34
3.3.5 Elman Network (ELN).....	35
3.3.6 Random Forest (RF)	36
3.3.7 Adaptive boosting	36
3.4 Ανάλυση απόδοσης ταξινόμησης.....	37
4. Συζήτηση και συμπεράσματα	56
4.1. Κύρια ευρήματα	56
4.2. Προκλήσεις και λύσεις	59
5 Συμπεράσματα και μελλοντικές αναφορές.....	62
5.1 Μελλοντικές έρευνες	63
Βιβλιογραφία-Παραπομπές	64

1 Εισαγωγή

Οι ακουστικές αποκρίσεις του εγκεφαλικού στελέχους προσφέρουν μια μοναδική ευκαιρία για την αξιολόγηση της νευρικής ακεραιότητας του περιφερειακού ακουστικού νευρικού συστήματος σε άτομα που παρουσιάζουν δυσκολίες στην ακοή. Τα ΑΠΔΕΣ και τα ΜΑΔ καταγράφονται και αναλύονται τυπικά από έναν ακουολόγο ο οποίος χειροκίνητα προσδιορίζει τον χρονισμό και την ποιότητα των κυματομορφών. Η ερμηνεία των ΑΠΔΕΣ, ΜΑΔ απαιτεί σημαντική εμπειρία και εκπαίδευση, και η ακατάλληλη ερμηνεία μπορεί να οδηγήσει σε εσφαλμένες κρίσεις σχετικά με την ακεραιότητα της ποιότητας των δεδομένων των κυματομορφών. Οι τεχνικές μηχανικής μάθησης μπορεί να είναι μια κατάλληλη προσέγγιση για την αυτοματοποίηση της ερμηνείας των ΑΠΔΕΣ, ΜΑΔ και τη μείωση του ανθρώπινου λάθους.

1.1 Προκλητά δυναμικά εγκεφάλου

Σύμφωνα με την έρευνα του Oken και των συνεργατών του [1] τα προκλητά δυναμικά ορίζονται ως ηλεκτρικά σήματα που παράγει το νευρικό σύστημα αποκρινόμενο σε εξωτερικά ερεθίσματα ή γεγονότα. Ο Legatt μέσα από την δική του έρευνα το 2014 [2], οδηγήθηκε στο συμπέρασμα πως ανάλογα με το είδος του εξωτερικού ερεθίσματος διαμορφώνονται οι εξής υποκατηγορίες προκλητών δυναμικών.

- Οπτικά προκλητά δυναμικά (Visual evoked Potentials -VEP): οπτικός ερεθισμός (π.χ. εμφάνιση εικόνας, λάμψη).
- Ακουστικά προκλητά δυναμικά (Auditory Evoked Potentials-AEP): ακουστικός ερεθισμός (π.χ. ήχοι, λέξεις, τόνοι διάφορων συχνοτήτων)
- Σωματοαισθητικά προκλητά δυναμικά (Somatosensory Evoked Potentials-SEP): ερεθισμός κάποιου νεύρου μέσω μικρής διάρκειας και έντασης ηλεκτρικού ρεύματος.

Επίσης, τα προκλητά δυναμικά ανάλογα με τον χρόνο εμφάνισης τους μετά το εκλυτικό γεγονός (λανθάνων χρόνος), ταξινομούνται στις εξής κατηγορίες [2]:

- Πρώιμα (Early, fast): εμφανίζονται έως 12 msec από την στιγμή του εξωτερικού ερεθίσματος
- Μεσαία (Middle): εμφανίζονται 12-50 msec από την στιγμή του εξωτερικού ερεθίσματος
- Αργοπορημένα ή Ύστερα (Late): εμφανίζονται 50-800 msec από την στιγμή του εξωτερικού ερεθίσματος

Η συγκεκριμένη διπλωματική εργασία επικεντρώνεται στα ακουστικά προκλητά δυναμικά, και συγκεκριμένα στα πρώιμα και τα μεσαία τα οποία απεικονίζουν τη λειτουργία του ακουστικού νεύρου και του τμήματος της ακουστικής νευρικής οδού.

1.2 Ακουστικά προκλητά δυναμικά

Τα ΑΠΔ αντιπροσωπεύουν τη δραστηριότητα που λαμβάνει χώρα εντός του ακουστικού συστήματος όταν εκείνο διεγείρεται από ήχους. Σε γενικές γραμμές, η περιγραφή των ΑΠΔ βασίζεται όχι μόνο στην περιοχή του ακουστικού συστήματος όπου δημιουργούνται άλλα και στην χρονική σχέση που αναπτύσσεται μεταξύ αυτών και άλλων απαντήσεων. Για παράδειγμα, ο όρος ηλεκτροκοχλεογράφημα (ECochG), χρησιμοποιείται για να περιγράψει την πρώτη ανταπόκριση καθώς, κατά κύριο λόγο, η δημιουργία των συστατικών γίνεται στην ευρύτερη περιοχή του εσωτερικού αυτιού

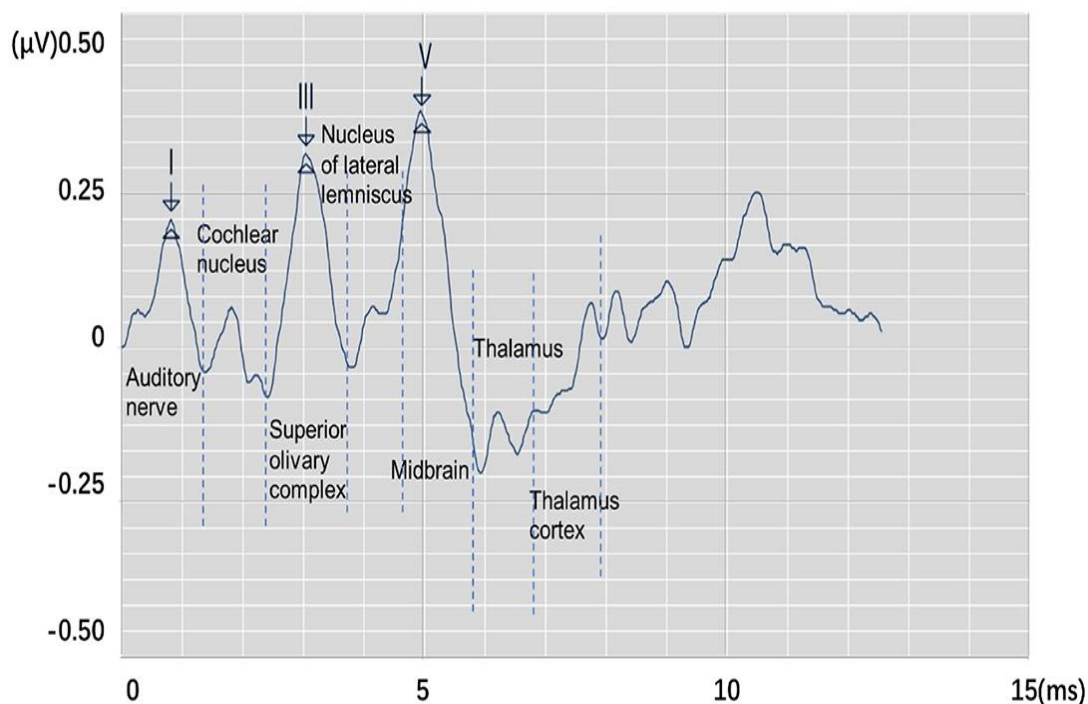
(κοχλία). Ταυτόχρονα, η ακουστική απόκριση του εγκεφαλικού στελέχους ή ΑΠΔΕΣ προέρχεται από ακουστικές περιοχές του εγκεφαλικού στελέχους και η ακουστική απόκριση μέσης λανθάνουσας περιόδου ή ΜΑΔ έλαβε το όνομα αυτό επειδή κάνει την εμφάνιση της μεταξύ των ΑΠΔΕΣ και των αποκρίσεων μακράς λανθάνουσας καθυστέρησης που έχουν την μεγαλύτερη καθυστέρηση σε σχέση με οποιαδήποτε άλλη απόκριση που καταγράφεται κλινικά. Αξίζει να σημειωθεί πως η χρήση του όρου δυναμικό, αντί για απόκριση, χρησιμοποιείται από αρκετούς για την περιγραφή της ηχητικής δραστηριότητας εντός του ακουστικού συστήματος, καθώς όπως είναι γνωστό, ο όρος ηλεκτρικό δυναμικό χρησιμοποιείται στην φυσική για να αναφερθεί σε μια ποσότητα ηλεκτρικής δυναμικής ενέργειας ή ηλεκτρικού φορτίου. Σε συζητήσεις λοιπόν που σχετίζονται με την ακουστική εγκεφαλική δραστηριότητα, οι όροι δυναμικό και η απόκριση χρησιμοποιούνται σε πολλές περιπτώσεις εναλλάξ. Διάφοροι ερευνητές και κλινικοί ιατροί κάνουν χρήση διάφορων φράσεων που ενσωματώνουν τον όρο και συνεπώς την λέξη δυναμικό ενώ παράλληλα διάφοροι συνάδελφοί τους κάνουν αναφορά στα ίδια παραδείγματα ακουστικής εγκεφαλικής δραστηριότητας χρησιμοποιώντας τον όρο απόκριση. Στην ακουολογία η ακουστική απόκριση εγκεφαλικού στελέχους, είναι ο όρος που εφαρμόζεται πιο συχνά στην ηλεκτροφυσιολογική διαδικασία, ωστόσο η συγκεκριμένη εργασία θα χρησιμοποιήσει τον όρο δυναμικό όταν γίνεται αναφορά στην εγκεφαλική δραστηριότητα που προκαλείται από τον ήχο. Τέλος, είναι απαραίτητο να επισημανθεί πως με τα κατάλληλα ακουστικά ερεθίσματα, η καταγραφή των ακουστικών προκλητών δυναμικών μπορεί να γίνει από το εσωτερικό αυτί, το ακουστικό νεύρο ή ακουστικές περιοχές του εγκεφάλου [3].

1.2.1 Ακουστικά προκλητά δυναμικά εγκεφαλικού στελέχους

Αρχικές έρευνες του Jewett και των συνεργατών του [4] έδειξαν πως η λήψη ενός ακουστικού ερεθίσματος από το πτερύγιο του ωτός έχει ως αποτέλεσμα την δημιουργία ηλεκτρικών ώσεων ή αλλιώς νευρικών σημάτων εντός του εγκεφάλου. Η καταγραφή και η ανίχνευση των ώσεων αυτών μπορούν να γίνουν καθ' όλη την ακουστική οδό ,μέσω των ΑΠΔΕΣ. Αφού ο Jewett και οι συνεργάτες του καθιέρωσαν την χρήση του, στα τέλη της δεκαετίας του 1960, το ΑΠΔΕΣ αποτελεί βασικό εργαλείο διάφορων ακουολόγων ανά τον κόσμο. Αρκετά χρόνια μετά ,ο Krishnan το έτος 2002 [5], και λίγο αργότερα ο Skoe και οι συνεργάτες του το έτος 2010 [6], συμπέραναν πως η χρήση ηλεκτροδίων επιφανείας και η σύνδεσή τους με κατάλληλο σύστημα Η/Υ,

επιτρέπει την καταγραφή των ΑΠΔΕΣ κατά τα πρώτα 1-12 περίπου msec από την στιγμή που χορηγείται ένα εξωτερικό ακουστικό ερέθισμα. Ο εκάστοτε ασθενής δέχεται το εξωτερικό ερέθισμα κυρίως μέσω ακουστικών και μπορεί να είναι σε μορφή κλικ (click-evoked) , τόνων βραχείας διάρκειας (tone-bursts) ή ακόμη και συλλαβών. Είναι σημαντικό να υπογραμμισθεί πως η μέθοδος αυτή παρουσιάζει την μεγαλύτερη κλινική εφαρμογή κυρίως επειδή τα δυναμικά του ασθενούς δεν αλλοιώνονται ανάλογα με την κατάστασή του αλλά και επειδή η ίδια η εξέταση δεν στηρίζεται στο πόσο συνεργάσιμος είναι ο εξεταζόμενος. Ένα χαρακτηριστικό παράδειγμα του πόσο πολύπλευρα είναι τα ΑΠΔΕΣ δίνεται και από την Külekçi και τους συνεργάτες της το έτος 2007 [7] αλλά και από τον Eder και τους δικούς του συνεργάτες το έτος 2020 οι οποίοι τόνισαν ότι αυτά τα σήματα δεν επηρεάζονται από τον ύπνο, φυσικό ή φαρμακευτικό, και άρα η εξέταση είναι εφικτή να γίνει σε νεογνά αλλά και σε άτομα νεαρής ηλικίας ή σε άτομα που χρήζουν ιδιαίτερης μεταχείρισης (π.χ. λόγω νοητικής υστέρησης, ψυχιατρικών διαταραχών κ.λπ.) και δεν έχουν την δυνατότητα να συνεργαστούν με τον κλινικό ή ιατρό σύμφωνα με την Talge και τους συνεργάτες της (2018) [8] . Βέβαια ο Oken και οι συνεργάτες του [1] τόνισαν πως, ενώ τα ακουστικά δυναμικά αποτελούν τις ηλεκτροφυσιολογικές αποκρίσεις του εγκεφάλου σε ακουστικά ερεθίσματα, δεν επιβεβαιώνουν την ύπαρξη της ακοής και πως αντιθέτως, εκτιμάται αντικειμενικά η συγχρονισμένη λειτουργικότητα του ακουστικού συστήματος αλλά και των δυναμικών κατωφλίων στα φάσματα συχνοτήτων 1-4 και 2-4 kHz σύμφωνα με την Lu και τους συνεργάτες της (2017) [9]. Οι κυματομορφές του ΑΠΔΕΣ υπόκεινται στα πρώιμα προκλητά δυναμικά και αποτελούνται από 1-7 θετικές κορυφές αναγραφόμενες σε Λατινικό σύστημα αρίθμησης (I-VII) και αναφέρονται ως κορυφές Jewett. Η Xie και οι συνεργάτες της [10] τόνισαν πως η χρονική διαφορά μεταξύ του εξωτερικού ερεθίσματος και της εμφάνισης της κάθε κορυφής, ονομάζεται λανθάνων χρόνος (latency), ενώ η χρονική διαφορά μεταξύ δύο κορυφών έχει ονομασθεί μεσολανθάνων χρόνος (interpeak latency). Οι λανθάνοντες χρόνοι του ΑΠΔΕΣ σηματοδοτούν δύο αλλαγές στο εγκεφαλικό στέλεχος, αυτήν της απώλειας μεταγωγής ηλεκτρικής ενέργειας από τον κοχλία και αυτήν της μείωσης της νευρο-μεταβιβαστικής ικανότητάς του. Η απώλεια της ακοής συνδέεται με την αύξηση των λανθανόντων χρόνων όλων των κορυφών, ενώ η μείωση της μεταβιβαστικής ικανότητας του στελέχους έχει ως αποτέλεσμα την αύξηση των μεσολανθανόντων χρόνων και κυρίως του χρόνου μεταξύ των κορυφών I και V. Υπογράμμισαν επίσης πως στους ανθρώπους, οι κορυφές I, III και V εμφανίζονται αρκετά συχνότερα και

χρησιμοποιούνται, για να εκτιμηθεί μια εξέταση ΑΠΔΕΣ και πως οι κορυφές III και V, αλλά κυρίως η κορυφή V, που είναι οι μεγαλύτερες σε μέγεθος, χρησιμοποιούνται κυρίως για την εκτίμηση των ακουστικών κατωφλίων και για να αναγνωρισθούν οι υπόλοιπες κορυφές. Μια τυπική κυματομορφή ΑΠΔΕΣ παρουσιάζεται παρακάτω στην Εικόνα 1.




Εικόνα 1 Τυπική κυματομορφή ΑΠΔΕΣ [11]

Συγκεκριμένα, για την ταξινόμηση μιας καταγεγραμμένης κυματομορφής ΑΠΔΕΣ ως φυσιολογικής ή μη, οι ακουολόγοι και κλινικοί εστιάζουν στα εξής χαρακτηριστικά:

- Παρουσία/Απουσία κορυφών Jewett
- Πλάτος κορυφής (μV)
- Λανθάνων χρόνος (ms)
- Μεσολανθάνων χρόνος (ms)
- Συνάρτηση λανθάνοντα χρόνου ως προς την ένταση του ερεθίσματος (Latency /Intensity Function – LIF)

Τα παραπάνω χαρακτηριστικά είναι καθοριστικής σημασίας στην κατηγοριοποίηση των ΑΠΔ ενός ασθενή. Στο σημείο αυτό αναφέρονται συνοπτικά κάποια νευρικά κέντρα παραγωγής ή νευρικοί γεννήτορες των ΑΠΔΕΣ και συγκεκριμένα η «προέλευση» των βασικών κορυφών Jewett (I έως V). Οι κορυφές I και II πηγάζουν

από το 9ο κρανιακό νεύρο και σε μια τυπική κυματομορφή ΑΠΔΕΣ κάνουν την εμφάνιση τους στα 1.5 και 2.5 msec αντίστοιχα. Ακολουθώντας το 9ο κρανιακό νεύρο, η κορυφή III πηγάζει από νευρώνες του κοχλιακού πυρήνα και εμφανίζεται συνήθως στα 3.5 msec. Τέλος, η κορυφή IV προέρχεται από την περιοχή του συμπλέγματος άνω ελαίας και έξω λημνίσκου ενώ η κορυφή V παράγεται από την περιοχή του έξω λημνίσκου και του κάτω διδύμιου. Οι κορυφές αυτές εμφανίζονται μεταξύ 4.5 και 5.5 msec από την στιγμή που παρέχεται το ακουστικό ερέθισμα, αντίστοιχα.




Εικόνα 2 Νευρικά κέντρα παραγωγής των Ακουστικών Προκλητών Δυναμικών Εγκεφαλικού Στελέχους[12]

1.2.2 Μεσαία ακουστικά δυναμικά

Η μεσαία λανθάνουσα απόκριση ή ΜΑΔ εμφανίστηκε για πρώτη φορά το έτος 1958 από τον Geisler [13]. Έκτοτε, έχει προκαλέσει σημαντικό ενδιαφέρον και έρευνα τόσο από κλινικούς ιατρούς όσο και από ερευνητές. Στην πρόσφατη ιστορία, η χρήση και η δημοτικότητα της έχουν μειωθεί παράλληλα με διάφορα άλλα ακουστικά προκλητά δυναμικά στην ακουολογία. Ένας τομέας για τον οποίο η έρευνα και η εφαρμογή των ΜΑΔ έχει παραλειφθεί είναι η πιθανή αξία της στη μέτρηση της νευρικής ακεραιότητας της ακουστικής θαλαμοφλοιώδους οδού. Με μια ευρύτερη έννοια, τα ΜΑΔ, όταν συνδυάζονται με την απόκριση του ακουστικού εγκεφαλικού στελέχους, μπορούν να παρέχουν πληροφορίες σχετικά με την κατάσταση πολλών από τις οδούς του κεντρικού ακουστικού νευρικού συστήματος (Center Auditory Nervous System-CANS) [14]. Τα ΜΑΔ ακολουθούν την ακουστική απόκριση του εγκεφαλικού στελέχους στο χρόνο και

αποτελούνται από ένα αρνητικό κύμα Na (~15–22 msec), ένα πρώτο θετικό κύμα Pa (~24–34 msec), ένα δεύτερο αρνητικό κύμα Nb (~35–50 msec) και ένα δεύτερο θετικό κύμα Pb (~50–60 msec) [15], [16]. Το πλάτος του ΜΑΔ, συγκεκριμένα του κύματος Na-Pa, είναι μεγαλύτερο από το ΑΠΔΕΣ και συχνά είναι κατά μέσο όρο περίπου 1 μV σε μέτριες εντάσεις [16], [17]. Τόσο η καθυστέρηση όσο και το πλάτος ποικίλλουν ανάλογα με τον τύπο του ερεθίσματος, την έντασή του, το φιλτράρισμα και μια σειρά από άλλους παράγοντες [15]–[18]. Οι περισσότεροι ερευνητές συμφωνούν ότι η ακουστική μέση λανθάνουσα απόκριση δημιουργείται από ανατομική άποψη μεταξύ του κατώτερου κολπικού και του ακουστικού φλοιού, και πολλοί άλλοι πιστεύουν ότι αυτή η απόκριση εμφανίζεται κάπου κατά μήκος της οδού του θαλαμοφλοιού. Το ΜΑΔ εμφανίζεται περίπου 12–75 msec μετά την έναρξη του ακουστικού ερεθίσματος [17], [19]. Μια τυπική κυματομορφή ΜΑΔ φαίνεται στην Εικόνα 3. Τυπικά, μόνο τα πρώιμα συστατικά των ΜΑΔ, Na και Pa, χρησιμοποιούνται κλινικά για κρίσεις παρουσίας/απουσίας, ανάλυση πλάτους και λανθάνουσας κατάστασης καθώς το κύμα Pb δεν προκαλείται αξιόπιστα από τυπικά κλινικά παραδείγματα κυματομορφών ΜΑΔ [18]–[20],[23].



Εικόνα 3 Απεικόνιση κυματομορφής ΜΑΔ δείχνοντας τα διάφορα κύματα και ένα παράδειγμα μέτρησης καθυστέρησης και πλάτους [14]


Το ΜΑΔ μπορεί να καταγραφεί τόσο σε παιδιά όσο και σε ενήλικες με κατάλληλες ρυθμίσεις, αλλά η κυματομορφή υφίσταται αλλαγές στη μορφολογία, την καθυστέρηση και το πλάτος που σχετίζονται με την ωρίμανση του κεντρικού νευρικού συστήματος [15]. Σε βρέφη και μικρά παιδιά, το Pa μπορεί να εμφανιστεί αργότερα και

να έχει μικρότερο πλάτος καθώς και ευρύτερη κορυφή [15], [22]. Όσο τα παιδιά μεγαλώνουν, το πλάτος Pa αυξάνεται σταθερά, με το ΜΑΔ να μοιάζει με ενήλικα στην ηλικία των 8-10 ετών [15], [17]. Το συστατικό Pb, αντίθετα, ωριμάζει πιο αργά, φτάνοντας τις τιμές των ενηλίκων σε ηλικία περίπου 15 ετών. Η ωρίμανση αυτού του συστατικού έχει αποδειχθεί ότι καθυστερεί σε άτομα με ακουστική στέρηση λόγω απώλειας ακοής [23]. Έχει επίσης αναφερθεί ότι το πλάτος μιας κυματομορφής ΜΑΔ μπορεί να επηρεαστεί σύμφωνα με την ομόπλευρη ή ετερόπλευρη καταγραφή της απόκρισης. Ο Seki και οι συνεργάτες του το έτος 1993 διαπίστωσαν ότι τα πλάτη των κυμάτων Na και Pa στους ανθρώπους τείνουν να είναι ελαφρώς μεγαλύτερα στο ηλεκτρόδιο αντίθετα προς το ερέθισμα [24]. Επίσης οι Tucker και Ruth το 1996 έδειξαν αποτελέσματα που επιβεβαίωσαν τα ευρήματα του Seki [25]. Αυτοί οι ερευνητές παρατήρησαν ότι το ομόπλευρο δυναμικό ήταν παρών για όλους τους συμμετέχοντες, ενώ η παρουσία του ετερόπλευρου ΜΑΔ καταγράφηκε σε ενήλικες στο 70-100% του χρόνου.

1.3 Καταγραφή Ακουστικών Προκλητών Δυναμικών

Για να μπορέσει να γίνει καταγραφή των ΑΠΔ, τοποθετούνται στον ασθενή τέσσερα ηλεκτρόδια. Το ενεργό ή αλλιώς θετικό ηλεκτρόδιο τοποθετείται στο μέτωπο, τα ηλεκτρόδια αναφοράς ή αλλιώς αρνητικά τοποθετούνται στις μαστοειδείς αποφύσεις και τέλος το ηλεκτρόδιο γείωσης στο κάτω μέρος του μετώπου. Όπως αναφέρθηκε παραπάνω, ως ακουστικά ερεθίσματα χρησιμοποιούνται συνήθως κλικ ή τόνοι βραχείας διάρκειας, μέσω ακουστικών που τοποθετούνται στους έξω ακουστικούς πόρους, και εντάσεως 40 dB έως 120 dB άνω του φυσιολογικού ουδού ακοής. Το ηλεκτρικό δυναμικό που προέρχεται από το εγκεφαλικό στέλεχος και καταγράφεται στο μακρινό πεδίο (επιφάνεια του κρανίου) από τα ηλεκτρόδια, είναι περίπου 100 nV έως 20μV. Δυστυχώς, εκτός από τα δυναμικά του εγκεφαλικού στελέχους, καταγράφονται και μη ενδιαφέροντα δείγματα ηλεκτροεγκεφαλογραφήματος (ΗΕΓ). Τα δείγματα αυτά προέρχονται συνήθως από την αυτόματη ηλεκτρική δραστηριότητα του εγκεφάλου και από «θόρυβο», όπως μυϊκές συσπάσεις και παρεμβολές του ηλεκτρικού ρεύματος και είναι προφανώς τυχαία [26]. Παρατηρούμε λοιπόν, ότι ο σηματοθορυβικός λόγος (SNR – Signal to Noise Ratio) είναι αρκετά μικρός και ως αποτέλεσμα τα ΑΠΔ βρίσκονται επί της ουσίας μέσα στα ανεπιθύμητα σήματα [26].

Όπως έχει αναφερθεί και προηγουμένως, ο «θόρυβος» είναι τυχαίου χαρακτήρα, σε αντίθεση με τα ΑΠΔ, που τείνουν να συμπίπτουν όταν χορηγείται το ίδιο ακουστικό ερέθισμα στον ασθενή. Κατά τη διάρκεια της εξέτασης λοιπόν, το ίδιο ακουστικό ερέθισμα χορηγείται στον ασθενή έως και 4.000 φορές και κάθε φορά που χορηγείται, το σήμα που λαμβάνουν τα ηλεκτρόδια καταγράφεται μέσω κατάλληλου λογισμικού, σε ένα χρονικό διάστημα που ξεκινάει από τη στιγμή της χορήγησης του ερεθίσματος έως και μερικά msec. Καθώς τα ΑΠΔ τείνουν να έχουν την ίδια μορφολογία, για κάθε επανάληψη του ερεθίσματος, τα καταγεγραμμένα σήματα αθροίζονται μεταξύ τους και «αυξάνονται σε μέγεθος», αφού οι θετικές και αρνητικές αποκλίσεις τους συμπίπτουν. Αντιθέτως, τα ανεπιθύμητα δείγματα ΗΕΓ αλλά και ο θόρυβος, τείνουν να αλληλοεξουδετερώνονται με την επανάληψη κάθε καταγραφής [27].



Εικόνα 4 Τοποθέτηση ηλεκτροδίων στον ασθενή [28]

Η παραπάνω διαδικασία είναι αλλιώς γνωστή ως η διαδικασία του μέσου όρου (averaging). Έχοντας ως βασική αρχή για την καταγραφή ενός ΑΠΔ ότι η αλλαγή στην δραστηριότητα του εγκεφάλου είναι χρονικά άρρηκτα συνδεδεμένη με κάποιο εξωτερικό ερέθισμα, ενώ οποιαδήποτε άλλη δραστηριότητα του εγκεφάλου παραμένει σταθερή, μπορούμε να θεωρήσουμε το προκλητό δυναμικό ως «σήμα» και τα υπόλοιπα δείγματα ΗΕΓ ως «θόρυβο». Η βελτίωση του σηματοθορυβικού λόγου, με τη διαδικασία του μέσου όρου, ισούται με $1/\sqrt{N}$, όπου N ο αριθμός των δειγμάτων [26]. Παρατηρούμε λοιπόν, ότι η ποιότητα του ABR που τελικά καταγράφεται, είναι ανάλογη με τον αριθμό της επανάληψης της διαδικασίας του μέσου όρου, γι' αυτό και ο αριθμός της χορήγησης του ακουστικού ερεθίσματος ανέρχεται σε μερικές χιλιάδες.

1.4 Κλινική χρήση των ΑΠΔΕΣ και ΜΑΔ

1.4.1 Κλινική χρήση των ΑΠΔΕΣ

Η κλινική χρησιμότητα των ΑΠΔΕΣ έγκειται στο γεγονός ότι πρόκειται για μια μη επεμβατική, αντικειμενική εξέταση, η οποία δε βασίζεται στη συνεργασία του ασθενή. Επιπρόσθετα, η γνώση των κέντρων παραγωγής (νευρολογικών και φυσιολογικών) των επιμέρους χαρακτηριστικών της κάθε κυματομορφής, επιτρέπει τη διάγνωση πιθανών διαταραχών στη ακουστική νευρική οδό[29]. Οι κύριες κλινικές εφαρμογές του ΑΠΔΕΣ είναι:

1.4.1.1 Υπολογισμός ουδών ακοής σε νεογνά, βρέφη ή άτομα που χρήζουν ειδικής μεταχείρισης.

Για τον υπολογισμό των ουδών ακοής, οι ακουολόγοι και κλινικοί, εκμεταλλεύονται το γεγονός, ότι η κορυφή V εμφανίζεται ακόμα και σε ερεθίσματα των οποίων η ένταση είναι λίγο μεγαλύτερη. Υπάρχουν δύο τρόποι υπολογισμού των ουδών ακοής: α) Η εξέταση αρχίζει με την χορήγηση ερεθισμάτων μεγάλης έντασης, η οποία μειώνεται με την εμφάνιση και ταυτοποίηση της κορυφής V ή β) Η εξέταση αρχίζει με χαμηλές εντάσεις, οι οποίες αυξάνονται έως ότου εμφανιστεί η κορυφή V.[30], [31] Όταν υπάρχουν παθολογικά ευρήματα πρέπει να υπάρχουν συνοδευτικές εξετάσεις όπως υποκειμενικές μέθοδοι – ακουόγραμμα ανάλογα με την ηλικία).

1.4.1.2 Δοκιμή ελέγχου ακοής νεογέννητου

Η δοκιμή ελέγχου ακοής νεογέννητου (Newborn Hearing Screening test - NHS) χρησιμοποιείται για τη διερεύνηση ακουστικής νευροπάθειας σε νεογνά η βρέφη. Δύο συμπληρωματικές τεχνικές προσυμπτωματικού ελέγχου είναι τώρα σε ευρεία χρήση. Η αυτοματοποιημένη ακουστική απόκριση εγκεφαλικού στελέχους ή ΑΠΔΕΣ μετρά τη μέση νευρωνική απόκριση σε μεγάλο αριθμό επαναλαμβανόμενων ηχητικών σημάτων του ίδιου ύψους και έντασης, ενώ η μέτρηση αυθόρμητων ή προκαλούμενων από ήχο ωτακουστικών εκπομπών ανιχνεύει ήχο που παράγεται από κινήσεις των εξωτερικών τριχωτών κυττάρων του κοχλίου. Και οι δύο μέθοδοι είναι αποδεκτές σε ευαισθησίες και ιδιαιτερότητες και χρησιμοποιούνται συχνά μαζί σε πρωτόκολλα διαλογής δύο σταδίων. Ωστόσο, σε ασθενείς με ακουστική νευροπάθεια, η ανταπόκριση των τριχοειδών κυττάρων μετρούμενες από τις ωτακουστικές εκπομπές μπορεί να είναι απολύτως φυσιολογικές, ενώ η ακουστική απόκριση εγκεφαλικού

στελέχους είναι ανώμαλη λόγω ασύγχρονης μετάδοσης νευρικών σημάτων. Έτσι, στα πρωτόκολλα ελέγχου δύο σταδίων, όπου χρησιμοποιείται η ακουστική απόκριση εγκεφαλικού στελέχους μόνο για την επιβεβαίωση των μη φυσιολογικών ωτακουστικών εκπομπών, οι απαντήσεις συχνά αποτυγχάνουν να εντοπίσουν αυτήν τη μορφή απώλειας ακοής. Διαφορές στα διαγνωστικά κριτήρια, την πληρότητα της παρακολούθησης και τα πρωτόκολλα ελέγχου συνέβαλαν στη διακύμανση της αναφερόμενης συχνότητας κώφωσης κατά τη γέννηση. Η εισαγωγή του προγράμματος που διευκολύνει στην άμεση επιβεβαίωση της απώλειας ακοής θα επέτρεπε επίσης την άμεση έναρξη της γενετικής αξιολόγησης, την παροχή συμβουλών και δοκιμών και θα χρησίμευε ως πρότυπο προγράμματος για την παροχή αυτών των υπηρεσιών. Εκτός από την ταυτοποίηση βρεφών που θα επωφεληθούν από την έγκαιρη παρέμβαση, αυτά τα προγράμματα θα πρέπει να είναι σε θέση να παρέχουν πολύτιμα επιδημιολογικά δεδομένα σχετικά με τις πληθυσμιακές τάσεις στην συχνότητα εμφάνισης γενετικών και περιβαλλοντικών αιτιών απώλειας ακοής, καθώς και με τη διαφοροποίηση σε συγκεκριμένες μορφές απώλειας ακοής μεταξύ πληθυσμών. Το NHS έχει τεράστιο προσωπικό, κοινωνικό και οικονομικό όφελος για τις αναπτυγμένες χώρες που το χρησιμοποιούν επιτυχώς [32].

1.4.1.3 Ενδείξεις για νευρολογικές βλάβες στο εγκεφαλικό στέλεχος.

Η παρουσία αυξημένων μεσολανθανόντων χρόνων για το διάστημα III-V ή η απουσία μεταγενέστερων κορυφών, συνήθως υποδηλώνουν βλάβη στο ανώτερο μέρος του εγκεφαλικού στελέχους. Παραδείγματα νοσημάτων και βλαβών που μπορούν να υποδηλωθούν, αποτελούν οι όγκοι σε οποιαδήποτε θέση της ακουστικής οδού, η σκλήρυνση κατά πλάκας, απομυελωτικοί νόσοι, αγγειακές βλάβες, φλεγμονές κ.ά.[33]

1.4.1.4 Διάγνωση ακουστικής νευροπάθειας ή αντιστρόφως, αποκλεισμός ακουστικής νευροπάθειας.

Η ακουστική νευροπάθεια είναι μια πάθηση που αφορά την νευρική κωδικοποίηση των ακουστικών ερεθισμάτων[34]. Τα άτομα που πάσχουν από αυτή τη διαταραχή, ενώ είναι ικανοί να αντιληφθούν και να αντιδράσουν σε ακουστικά ερεθίσματα, εμφανίζουν δυσκολία στην αποκωδικοποίηση του λόγου[35]. Οι τελευταίες θεωρίες υποστηρίζουν ότι η βλάβη εντοπίζεται στο σύστημα έσω τριχωτών κυττάρων- γαγγλιακών κυττάρων- ακουστικού νεύρου, με αποτέλεσμα τη διαταραχή στο συγχρονισμό των νευρικών ώσεων και την απώλεια των ακουστικών προκλητών δυναμικών.

1.4.2 Κλινική χρήση των ΜΑΔ

1.4.2.1 Υποψία ψυχογενούς ή μη οργανικής απώλειας ακοής

Οι κλινικές χρήσεις των ΜΑΔ περιλαμβάνουν την εκτίμηση συγκεκριμένης συχνότητας κατωφλιού ακοής, ειδικά στις χαμηλότερες συχνότητες αξιολόγησης της λειτουργίας της ακουστικής οδού, συμπεριλαμβανομένου του αποκλεισμού μιας κεντρικής παθολογίας όταν υπάρχει υποψία απώλειας ακοής και τον εντοπισμό βλαβών της ακουστικής οδού και εκτίμηση της λειτουργίας του κοχλιακού εμφυτεύματος.[36]

1.4.2.2 Ασθενείς με νευρολογικές ασθένειες

Η απόκτηση ακουστικών δεδομένων μέσης καθυστέρησης είναι εξαιρετικά σημαντική σε μια προσπάθεια βελτίωσης της αντικειμενικότητας της αξιολόγησης των ασθενών με απώλεια ακοής, τόσο όσον αφορά τον καθορισμό των ορίων τους, όσο και τον εντοπισμό της βλάβης. Σήμερα, έχουν επίσης χρησιμοποιηθεί για τη μελέτη των μεταβολών που συμβαίνουν σε διαφορετικές νευρολογικές διαταραχές. Έχει παρατηρηθεί ότι οι δυνατότητες των ΜΑΔ αποτελούν ένα εξαιρετικά σημαντικό εργαλείο για την αξιολόγηση της εγκεφαλικής λειτουργίας, όχι μόνο από άποψη ακουστικής, αλλά και σε ασθενείς με νευρολογικές διαταραχές, όπως έχει αποδειχθεί σε πολλές μελέτες με ασθενείς σε κωματώδη κατάσταση ή και σε άλλους που υπέστησαν τραυματισμούς στο κεφάλι. Οι μέσες τιμές των καθυστερήσεων εκτροπής Ρο, Να, Ρα, Νβ, Ρβ και το διάστημα Να-Ρα στις ομάδες νευρολογικών διαταραχών έχει διαπιστωθεί ότι είναι σημαντικά υψηλότερες. Οι σημαντικότερες στατιστικές διαφορές ήταν κυρίως συνδεδεμένες με τις εκτροπές Ρα, Νβ και Ρβ[37].

1.4.2.3 Σε ασθενείς με διάφορους τύπους όγκων

Η ανάλυση των κυματομορφών ΜΑΔ σε ασθενείς με διάφορους τύπους όγκων (αιθουσαία σβαννώματα, λιπώματα, μηνιγγιώματα κ.α.) έχει ως αποτέλεσμα τις σημαντικά μεγαλύτερες καθυστερήσεις (latencies) των συστατικών Να και Ρα ή ακόμα και την απουσία ολόκληρης της κυματομορφής ΜΑΔ. Επίσης οι ασθενείς είναι πιθανό να εμφανίσουν μη φυσιολογική καθυστέρηση (latency) τουλάχιστον ενός συστατικού[38].

1.4.3.4 Εγκεφαλικά Επεισόδια

Έχουν διεξαχθεί αρκετές κλινικές μελέτες σε άτομα με νευρολογικές βλάβες λόγω αγγειακών προβλημάτων στον εγκέφαλο (ανευρύσματα, ισχαιμικά και/ή αιμορραγικά

εγκεφαλικά επεισόδια). Τα αποτελέσματα τέτοιων ΜΑΔ είναι μη φυσιολογικά κύματα Pa στις θέσεις καταγραφής κορυφής. Οι ανωμαλίες αυτές περιλαμβάνουν καθυστερήσεις, μειωμένο πλάτος ή απουσία κυματομορφών [39].


1.4.2.5 Εσωτερικοί τραυματισμοί στην περιοχή της κεφαλής

Εκτός από τα εγκεφαλοαγγειακά ατυχήματα και τα εγκεφαλικά επεισόδια, ο τραυματισμός στο κεφάλι είναι μια άλλη κύρια αιτία φλοιικών και υποφλοιωδών βλαβών. Σε πολλές μελέτες, ωστόσο, ειδικά σε περιπτώσεις εσωτερικών ή ελαφρών τραυματισμών στο κεφάλι, οι βλάβες μπορεί να είναι πιο διαδεδομένες και διακριτές βλάβες μπορεί να μην εντοπιστούν. Εναλλακτικά, ο τραυματισμός στο κεφάλι μπορεί να ταξινομηθεί σε βαθμούς και όχι σε συγκεκριμένη θέση. Οι ασθενείς χωρίζονται σε ήπια, μέτρια ή σοβαρή κατάσταση ανάλογα με την σοβαρότητα του χτυπήματος και λαμβάνονται αποτελέσματα μέσω του ΜΑΔ. Σημαντικά χαμηλότερα πλάτη Pa, σημαντικές διαφορές στο πλάτος Na, τη λανθάνουσα κατάσταση (latency) και το πλάτος Pa αναφέρονται μεταξύ των διαφορετικών ομάδων κρανιοεγκεφαλικής βλάβης (ήπια/μέτρια/σοβαρή). Ωστόσο το μειωμένο πλάτος Pa είναι η πιο συχνή ανωμαλία που έχει παρατηρηθεί σε ασθενείς με τραυματισμούς στο κεφάλι [40].

2 Τεχνητή Νοημοσύνη (Artificial Intelligence)

2.1 Ιστορική Αναδρομή

Αν και είναι αδιαμφισβήτητο ότι είναι αρκετά δύσκολο να προσδιοριστεί με ακρίβεια, η γέννηση του κλάδου της τεχνητής νοημοσύνης έχει συνδεθεί με τη δεκαετία του 1940, καθώς εκείνη την εποχή ο Άγγλος μαθηματικός Alan Turing με την ομάδα του Hut 8 κατασκεύασε την Bombe, μία μηχανή που είχε ως στόχο να αποκρυπτογραφήσει τον κώδικα Enigma που χρησιμοποιούσε κατά βάση ο γερμανικός στρατός κατά τη διάρκεια του Β΄ Παγκοσμίου Πολέμου. Το 1950 ο Alan Turing δημοσίευσε το άρθρο “Computing Machinery and Intelligence” [41] στο οποίο παράθεσε ένα κριτήριο για τον προσδιορισμό της ύπαρξης ευφυών μηχανών, γνωστό ως Turing Test: Αν μία μηχανή καταφέρει να ξεγελάσει έναν άνθρωπο πείθοντάς τον πως συνομιλεί με έναν άλλον άνθρωπο τότε θεωρείται ότι η μηχανή διαθέτει νοημοσύνη.



Εικόνα 5 Η μηχανή Bombe [42]

Ο όρος «τεχνητή νοημοσύνη» (Artificial Intelligence - AI) καθιερώθηκε μετά από έξι χρόνια το 1956, όταν οι Marvin Minsky και John McCarthy φιλοξένησαν το συνέδριο “Dartmouth Summer Research Project on Artificial Intelligence” (DSRPAI)[43] στο πανεπιστήμιο του Dartmouth. Ο σκοπός του συγκεκριμένου συνεδρίου ήταν η δημιουργία ενός καινούργιου ερευνητικού πεδίου που είχε ως βασικό στόχο την υλοποίηση μηχανών ικανών να παρέχουν μια προσομοίωση της ανθρώπινης νοημοσύνης. Οι συνέδριοι του συνεδρίου αυτού θεμελίωσαν την τεχνητή νοημοσύνη. Τα επόμενα χρόνια, ο κλάδος της τεχνητής νοημοσύνης αναπτύχθηκε ιδιαίτερα.

Χαρακτηριστικό παράδειγμα θεωρείται το πρόγραμμα Eliza [44] που ανέπτυξε το 1966 ο Joseph Weizenbaum στο MIT το οποίο κατάφερε να πείσει την γραμματέα του πως αυτός που συνομιλούσε ήταν ο ίδιος ο Weizenbaum. Το πρόγραμμα αυτό θεωρείται το πρώτο που πέρασε επιτυχώς το Turing Test. Επιτυχημένο θεωρήθηκε επίσης το πρόγραμμα General Problem Solver του νομπελίστα Herbert Simon το οποίο είχε καταφέρει να λύνει αυτόματα μία σειρά προβλημάτων όπως ο πύργος του Hanoi. Οι παραπάνω επιτυχίες συνέβαλαν σημαντικά στη αύξηση της χρηματοδότησης του συγκεκριμένου ερευνητικού πεδίου της τεχνητής νοημοσύνης ειδικά, αλλά και στην επικράτηση ενός ευχάριστου και αισιόδοξου κλίματος για το μέλλον του κλάδου γενικά. Το 1970, σε συνέντευξή του στο περιοδικό Life Magazine, ο Marvin Minsky δήλωσε ότι 8 χρόνια αργότερα οι μηχανές θα είναι εξίσου ευφυείς με τον άνθρωπο. Παρόλα αυτά, μόλις τρία χρόνια αργότερα, το 1973, άρχισαν να εμφανίζονται οι πρώτοι επικριτές της ιδέας αυτής, με τον Βρετανό μαθηματικό James Lighthill να υποστηρίζει πως οι μηχανές δεν θα καταφέρουν να φτάσουν σε επίπεδο πέραν του ερασιτεχνικού σε παιχνίδια όπως το σκάκι, ενώ τόνισε επίσης ότι δε θα μπορέσουν ποτέ να αναπτύξουν συλλογιστική σκέψη. Οι παραπάνω φωνές και αντιρρήσεις είχαν ως αποτέλεσμα την μείωση της χρηματοδότησης και την εγκατάλειψη αρκετών μεγάλων ερευνητικών προγραμμάτων, σηματοδοτώντας την απαρχή μιας περιόδου που έγινε γνωστή ως «Χειμώνας της Τεχνητής Νοημοσύνης». Ένας από τους λόγους που δεν ικανοποιήθηκαν οι προσδοκίες της εποχής σχετίζεται περισσότερο στην προσέγγιση που ακολουθούσαν οι προγραμματιστές κατά την διάρκεια της ανάπτυξης συστημάτων όπως το Eliza και το General Problem Solver για την προσομοίωση της ανθρώπινης νοημοσύνης. Συγκεκριμένα τα προγράμματα αυτά ήταν Expert Systems και έβγαζαν το συμπέρασμα ότι η ανθρώπινη νοημοσύνη μπορεί να τυποποιηθεί και να ανακατασκευαστεί με την βοήθεια μιας σειράς “if-then” εντολών. Τα Expert systems είχαν πράγματι εξαιρετική απόδοση προβλήματα που ήταν δυνατόν να τυποποιηθούν. Χαρακτηριστικό παράδειγμα πετυχημένου Expert System αποτελεί το Deep Blue [45] της IBM το οποίο, το 1997 κατάφερε να νικήσει τον παγκόσμιο πρωταθλητή στο σκάκι Gary Kasparov, καθώς και την πρόβλεψη του James Lighthill πως κάτι τέτοιο δεν επρόκειτο να συμβεί ποτέ. Αντιθέτως, τα Expert System δεν αποδίδουν καλά σε προβλήματα που δεν μπορούν να τυποποιηθούν. Για παράδειγμα, δεν είναι εύκολο με μία σειρά εντολών “if-then” να υλοποιηθεί επιτυχώς ένα πρόγραμμα αναγνώρισης προσώπου. Για την επίλυση τέτοιων προβλημάτων, ένα σύστημα πρέπει να μαθαίνει από εξωτερικά δεδομένα και να χρησιμοποιεί αυτήν τη γνώση για την επίτευξη

συγκεκριμένων στόχων και την ανάπτυξη προσαρμοστικότητας - ικανότητας γενίκευσης. Τα Expert Systems δεν διαθέτουν αυτά τα χαρακτηριστικά, και τεχνικά δεν μπορούν να προσδιοριστούν ως τεχνητή νοημοσύνη. Στατιστικές μέθοδοι για την επίτευξη πραγματικής τεχνητής νοημοσύνης είχαν ήδη εμφανιστεί το 1940 όταν ο Καναδός ψυχολόγος Donald Hebb ανέπτυξε μία θεωρία μάθησης γνωστή ως Hebbian Learning που προσομοιώνει την λειτουργία των νευρώνων του ανθρώπινου εγκεφάλου. Η θεωρία του Hebb αποτέλεσε ένα επιμέρους ερευνητικό πεδίο της τεχνητής νοημοσύνης το οποίο όμως το 1969 διεκόπη όταν οι Marvin Minsky και Seymour Papert απέδειξαν ότι η επεξεργαστική ισχύς των υπολογιστών δεν μπορούσε να ανταπεξέλθει στις απαιτήσεις των λεγόμενων τεχνητών νευρωνικών δικτύων (Artificial Neural Networks) [46], [47]. Τα τεχνητά νευρωνικά δίκτυα επανήλθαν στα πλαίσια της βαθιάς μάθησης όταν το 2015 το AlfaGo κέρδισε τον παγκόσμιο πρωταθλητή του Go, Ke Jie. Το Go είναι ένα παιχνίδι πολύ πιο περίπλοκο από το σκάκι για το οποίο επικρατούσε η άποψη ότι οι υπολογιστές δεν θα καταφέρουν ποτέ να κερδίσουν τον άνθρωπο. Σήμερα, τα νευρωνικά δίκτυα και η βαθιά μάθηση χρησιμοποιούνται για την ανάπτυξη των περισσότερων εφαρμογών που χαρακτηρίζονται ως ΑΙ [47]. Τέτοιες εφαρμογές είναι η αναγνώριση προσώπου(face recognition), η αναγνώριση λόγου(speech recognition) κ.ά. . «Αυτή η πρόταση για παράδειγμα δεν πληκτρολογήθηκε αλλά εκφωνήθηκε και στη συνέχεια μετατράπηκε σε κείμενο μέσω της υπηρεσίας speech to text Recognition της Google».

2.2 Μηχανική Μάθηση (Machine Learning)

Η μηχανική μάθηση είναι ένας κλάδος της τεχνητής νοημοσύνης (AI), η οποία είναι η αρχή της χρήσης μηχανών για την αυτοματοποίηση σύνθετων εργασιών που κανονικά θα απαιτούσε ανθρώπινη νοημοσύνη για να ολοκληρωθεί [48]. Η μηχανική μάθηση είναι η έννοια της χρήσης υπολογιστών με σκοπό να εκτελεστεί μια εργασία, όχι μέσω άμεσου προγραμματισμού, αλλά μέσω της εκμάθησης μιας εργασίας από τα δεδομένα που παρέχονται[49]. Ήταν η βάση για την ταχεία ανάπτυξη σε μια σειρά τεχνολογιών και βιομηχανιών, συμπεριλαμβανομένης της αναγνώρισης φωνής, της μετάφρασης και της αναγνώρισης εικόνας καθώς και της υπεράνθρωπης σκακιστικής μηχανής [50]. Σε αντίθεση με τις παραδοσιακές αντικειμενικές μεθόδους ταξινόμησης κυματομορφών ΑΠΔΕΣ, η μηχανική μάθηση επιτρέπει στους υπολογιστές να επιλέξουν και να μάθουν τα χαρακτηριστικά μιας κυματομορφής ΑΠΔΕΣ που σχετίζονται καλύτερα με τη

σωστή ερμηνεία του. Αυτά τα χαρακτηριστικά είναι συχνά δύσκολο να καθοριστούν με το χέρι και μπορεί να περιλαμβάνουν χρονικές και/ ή συστατικά συχνότητας του σήματος, ή μάλιστα συνδυασμό διαφορετικών χαρακτηριστικών τα οποία μπορεί να μην παρατηρούνται εύκολα από έναν άνθρωπο - αξιολογητή που επιθεωρεί οπτικά την κυματομορφή ΑΠΔΕΣ. Η μηχανική μάθηση είναι ένα παρακλάδι της τεχνητής νοημοσύνης, καθώς το 1959 ο Arthur Samuel εισάγει τον όρο «μηχανική μάθηση» ως «το ερευνητικό πεδίο που παρέχει στους υπολογιστές την δυνατότητα να μαθαίνουν λύνοντας προβλήματα τα οποία δεν είναι προγραμματισμένοι να λύσουν» [10] Παράλληλα ο ορισμός για τη μηχανική μάθηση δόθηκε από τον Tom M. Mitchell το 1997 και σύμφωνα με τον Mitchell «ένα πρόγραμμα υπολογιστή λέμε ότι μαθαίνει από την εμπειρία E ως προς κάποια κλάση εργασιών T και μέτρο απόδοσης P, αν η απόδοσή του σε εργασίες από το T, όπως μετριέται από το P, βελτιώνεται μέσω της εμπειρίας E» [11]. Επιπλέον, είναι σημαντικό να σημειωθεί πως οι τεχνικές μηχανικής μάθησης που έχουν αναπτυχθεί μπορούν να κατηγοριοποιηθούν ανάλογα με το πρόβλημα το οποίο πρέπει να αντιμετωπίσουν :

➤ **Επιβλεπόμενη Μάθηση (Supervised Learning)**

Το υπολογιστικό σύστημα χρειάζεται να "μάθει" μία συνάρτηση μέσα από ένα σύνολο δεδομένων. Η τεχνική αυτή έχει ονομαστεί επιβλεπόμενη μάθηση καθώς θεωρείται ότι υπάρχει κάποιος ο οποίος επιβλέπει την διαδικασία παρέχοντας τη σωστή τιμή εξόδου της συνάρτησης και ταυτόχρονα βρίσκει εφαρμογή σε προβλήματα :

➤ Ταξινόμησης (Classification)

➤ Παρεμβολής (Regression)

➤ **Μη Επιβλεπόμενη Μάθηση (Unsupervised Learning)**

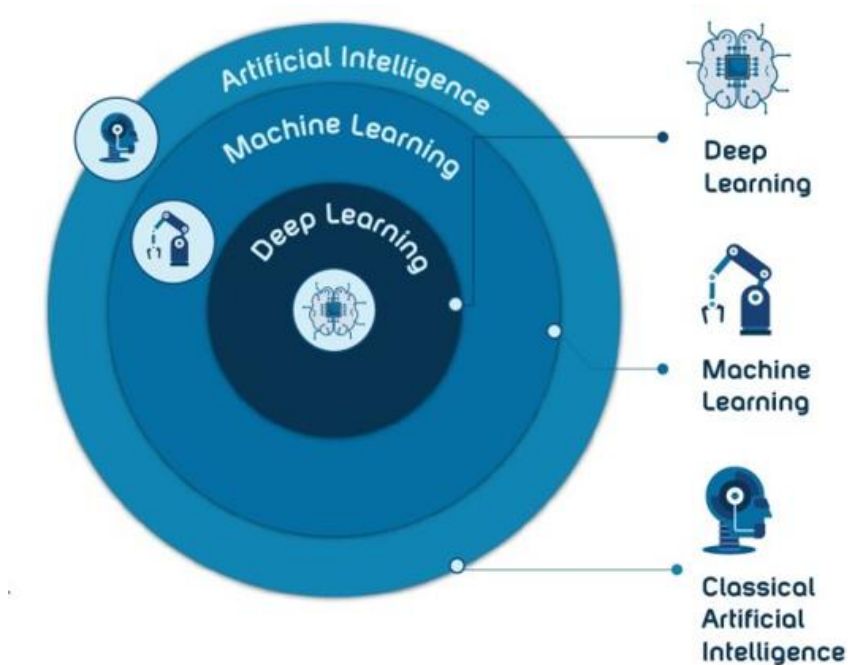
Σε αυτή την περίπτωση το σύστημα καλείται να βρει διάφορες συσχετίσεις μεταξύ του συνόλου δεδομένων από μόνο του, χωρίς να είναι εξαρχής γνωστό αν υπάρχουν και ποιες είναι. Το σύστημα αυτό μπορεί να βρει εφαρμογή σε προβλήματα : • Ανάλυσης Συσχετίσεων (Association Analysis) • Ομαδοποίησης (Clustering)

➤ **Ενισχυτική Μάθηση (Reinforcement Learning)**

Το συγκεκριμένο υπολογιστικό σύστημα προσπαθεί να μάθει διάφορες πληροφορίες αλληλοεπιδρώντας άμεσα με το περιβάλλον. Αυτό μπορεί να επιτευχθεί μέσω "επιβράβευσης" ή "τιμωρίας" του συστήματος ενώ αυτό αλληλοεπιδρά με το περιβάλλον Και ο βασικός του στόχος είναι η μεγιστοποίηση της επιβράβευσης. Καθώς και αυτό το σύστημα διαφοροποιείται από τα υπόλοιπα, έχει ως στόχο την εύρεση εφαρμογής σε προβλήματα σχεδιασμού (Planning).

➤ Βαθιά Μάθηση (Deep Learning)

Η βαθιά μάθηση θεωρείται ένα παρακλάδι της μηχανικής μάθησης που τα τελευταία χρόνια έχει καταφέρει να παρουσιάσει σημαντική ανάπτυξη. Η βαθιά μάθηση χρησιμοποιεί δίκτυα πολλαπλών επιπέδων, με άλλα λόγια αυξημένου βάθους, έτσι ώστε να εξάγει χαρακτηριστικά υψηλού επιπέδου από τα δεδομένα που έχουν ληφθεί. Η χρήση πολλαπλών επιπέδων κάνει εφικτή την αποτελεσματική εκπαίδευση δικτύων σε μη-δομημένα δεδομένα όπως είναι οι εικόνες, η φωνή κ.ά. Ένα από τα μεγαλύτερα επιτεύγματα του συγκεκριμένου συστήματος είναι πως οι μέθοδοι βαθιάς μάθησης βελτίωσαν και εξέλιξαν την όραση υπολογιστών (Computer vision), την επεξεργασία φυσικής γλώσσας (natural language processing) και πολλές άλλες εφαρμογές [51].



Εικόνα 6 Η σχέση μεταξύ Artificial Intelligence, Machine Learning και Deep Learning [52]

3 Μηχανική μάθηση και ακουστικά προκλητά δυναμικά

3.1 Εισαγωγή

Είναι αδιαμφισβήτητο πως η ανάλυση αλλά και η ερμηνεία των ABR απαιτεί όχι μόνο γνώσεις αλλά και εκπαίδευση. Είναι γνωστό πως άριστα εκπαιδευμένοι και έμπειροι ακοολόγοι συνήθως συμφωνούν ως προς την διαδικασία αναγνώρισης σημάτων σε ποσοστό μεγαλύτερου του 90%. Ωστόσο, οι ακοολόγοι που δεν έχουν αποκτήσει τόσο εκτενή εμπειρία μπορεί να ερμηνεύσουν τα ΑΠΔΕΣ με λάθος τρόπο και να μην μπορούν πάρα να καταλήξουν σε μια ψευδή ή λανθασμένη διάγνωση [53]. Δυστυχώς, έχει διαπιστωθεί πως τα κλινικά πρότυπα για την αξιολόγηση της μορφολογίας της κυματομορφής ABR σε κάποιες συγκεκριμένες ομάδες ατόμων δεν είναι επαρκώς καθορισμένα. Για αυτόν τον λόγο, μια αυτοματοποιημένη ανάλυση των κυματομορφών ΑΠΔΕΣ θα διασφαλίσει την βελτίωση όχι μόνο της αντικειμενικότητας αλλά και της αναπαραγωγικότητας. Πέρα από τις δυσκολίες και συνεπώς τις βελτιώσεις που μπορούν να πραγματοποιηθούν σε αυτούς τους τομείς, είναι αλήθεια ότι διαγνώσεις τέτοιων ομάδων ακολουθούν διάφορα τεστ, τα οποία μπορούν να διαρκέσουν έως και 4 ώρες. Μέσα σε αυτό το χρονικό διάστημα, οι ακοολόγοι έχουν την υποχρέωση να συμπληρώσουν κλινικές αναφορές των ευρημάτων τους, κάτι το οποίο μπορεί να δημιουργήσει μεγάλο φόρτο εργασίας. Συνεπώς, μια αυτοματοποιημένη ανάλυση θα κάνει την συγκεκριμένη διαδικασία πιο αποτελεσματική και θα ελαττώσει τον κλινικό φόρτο εργασίας των ειδικών. Επομένως, μια τέτοια εργασία μπορεί να συνδράμει στην βελτίωση της ικανότητά των ακοολόγων να κρίνουν με τη βοήθεια ενός αυτοματοποιημένου εργαλείου. Μια προσέγγιση που μπορεί να είναι αποδοτική και προτείνεται για την αυτοματοποίηση της ανάλυσης ABR είναι η χρήση αλγορίθμων μηχανικής μάθησης. Μέσω της εκπαίδευσης, οι αλγόριθμοι μηχανικής μάθησης μπορούν να χρησιμοποιηθούν με τέτοιο τρόπο έτσι ώστε να ερμηνεύουν τις κυματομορφές μαθαίνοντας κατά βάση να ανιχνεύουν ανωμαλίες. Αρχικά, τα μοντέλα αυτά μπορούν να προσαρμοστούν, να εκπαιδευτούν και να επικυρωθούν με ετικέτες που παρέχονται από τους ίδιους τους ειδικούς. Αργότερα, αυτά τα πλήρως εκπαιδευμένα και κατάλληλα επικυρωμένα μοντέλα θα μπορούσαν να χρησιμοποιηθούν έτσι ώστε να προβλέπουν τυχόν ανωμαλίες σε νέες κυματομορφές με παρόμοιες συνθήκες. Παράλληλα, μια αντικειμενική μέτρηση των αποκρίσεων ABR θα έδινε την δυνατότητα στους ειδικούς να βελτιώσουν το διαγνωστικό προφίλ οδηγώντας έτσι σε καλύτερη ιατρική διαχείριση.

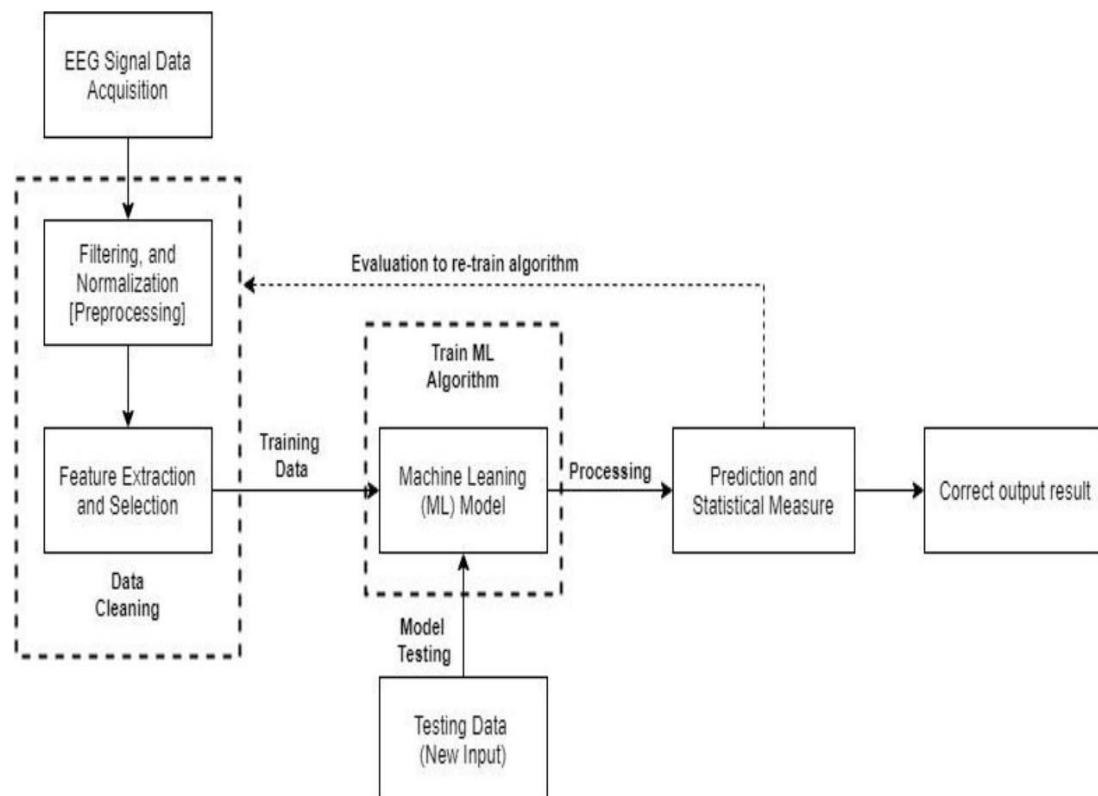
3.2 Μεθοδολογία

Η μηχανική μάθηση ενσωματώνει άμεσα τη χρήση μαθηματικών μοντέλων και υπολογιστικών αλγορίθμων για την εξαγωγή σημαντικών πληροφοριών από ένα δεδομένο ή διαθέσιμο σύνολο δεδομένων. Η αναγνώριση προτύπων από το σύνολο δεδομένων εκπαίδευσης θα προσαρμοστεί και θα εφαρμοστεί εκ νέου για την ανάλυση των επερχόμενων περιπτώσεων με μια εξαιρετικά αξιόπιστη απόφαση. Το σταδιακά αυξημένο μέγεθος δεδομένων βελτιώνει τη μαθησιακή απόδοση μιας αντίστοιχης εργασίας. Στην πραγματικότητα, η μηχανική εκμάθηση εξαλείφει με επιτυχία την ανάγκη επαναπρογραμματισμού από επαγγελματία όταν παρέχονται νέα στοιχεία. Πρόσφατα, η μηχανική μάθηση έχει δείξει ουσιαστική υπόσχεση για να βοηθήσει στην κατανόηση των σημάτων ΗΕΓ, γεγονός που κατέστησε δυνατή την εκμάθηση πληροφοριών και την παροχή ώθησης στην επιθυμητή ιατρική διαγνωστική πρόβλεψη, και αυτό μπορεί να επεκταθεί σε διάφορες κλινικές καταστάσεις [54],[55].

Συνολικά, η τελευταία λέξη της τεχνολογίας της μηχανικής μάθησης φαίνεται πολύτιμη στο πλαίσιο της περίπλοκης κλινικής απόφασης. Ωστόσο, η ιδιαιτερότητα των πλεονεκτημάτων μπορεί να αλλάξει ανάλογα με τις επιλεγμένες τεχνικές. Η μηχανική μάθηση γενικά θα μπορούσε να ταξινομηθεί σε εποπτευόμενη μάθηση και μάθηση χωρίς επίβλεψη. Η μάθηση χωρίς επίβλεψη είναι μια συνθήκη όπου ο αλγόριθμος αναπτύσσει ένα μοτίβο χαρτογράφησης από ένα σύνολο δεδομένων εισόδου χωρίς γνωστές αποκρίσεις εξόδου, όπως στην ανάλυση συμπλέγματος. Η εποπτευόμενη μάθηση δημιουργεί έναν αλγόριθμο πρόβλεψης χρησιμοποιώντας ένα γνωστό σύνολο δεδομένων εισόδου, το οποίο είναι χρήσιμο ως σύνολο δεδομένων εκπαίδευσης για να συμπεράνει μια συνάρτηση για τη δημιουργία προγνωστικού μοντέλου [54],[56].

Η χρήση εργαλείων μηχανικής εκμάθησης είναι ένας καλός σύντροφος για την αυτοματοποίηση, την επέκταση και τη βελτίωση της ανάλυσης δεδομένων ΑΕΡ. Η Εικόνα 6 παρουσιάζει την επισκόπηση της μηχανικής μάθησης σε μια εκπαιδευμένη διαδικασία ροής αλγορίθμου. Ο πιο συνηθισμένος αγωγός στην επεξεργασία σήματος EEG ξεκινά με προ-επεξεργασία ακατέργαστων δεδομένων EEG μέσω κανονικοποίησης σήματος και απόρριψης ή φιλτραρίσματος τεχνουργημάτων. Στη συνέχεια, τα καθαρισμένα δεδομένα EEG υποβάλλονται σε επεξεργασία για να εξαχθούν τα επιλεγμένα χαρακτηριστικά ενδιαφέροντος. Το επιλεγμένο

χαρακτηριστικό της εξαγωγής χρησιμοποιείται στη συνέχεια ως σύνολο δεδομένων εκπαίδευσης προκειμένου να εκπαιδεύσει ένα μοντέλο που μπορεί να μάθει να ταξινομεί, να προβλέπει ή να αναγνωρίζει το μοτίβο του συνόλου δεδομένων εισόδου. Η υπολογιστική μοντελοποίηση πρέπει να επανεκπαιδευτεί με βάση το ενημερωμένο σύνολο δεδομένων για να βελτιωθεί η απόδοσή της. Το νέο σύνολο δεδομένων εισόδου θα παρασχεθεί στη συνέχεια για τη δοκιμή του προηγουμένως εκπαιδευμένου μοντέλου και του προγνωστικού. Στη συνέχεια, η απόδοση του ταξινομητή της υπολογιστικής μοντελοποίησης αξιολογείται με βάση τους πίνακες δεικτών απόδοσης. Σε αυτή την εργασία, συζητείται η επιλογή των τεχνικών μηχανικής μάθησης που εφαρμόζονται στην ερευνητική εργασία αξιολόγησης ΑΠΔ και η απόδοση του προγνωστικού μοντέλου τους για την ακουστική τυπικότητα.




Εικόνα 7 Σφαιρική εικόνα της μηχανικής μάθησης σε ένα EEG [57]

3.3 Αλγόριθμοι μηχανικής μάθησης

Σε αυτήν την ενότητα παρουσιάζονται αρκετές τεχνικές μηχανικής μάθησης που εφαρμόστηκαν στα άρθρα που περιλαμβάνονται για ακουστική αξιολόγηση τα τελευταία χρόνια.

3.3.1 Support Vector Machine (SVM)


Η SVM ταξινομείται στην κατηγορία της εποπτευόμενης μάθησης που χρησιμοποιείται κυρίως στην ανάλυση ταξινόμησης και παλινδρόμησης. Αρχικά ανακαλύφθηκε το 1995 [58]. Η SVM αναφέρθηκε ότι είχε μεγαλύτερη εφαρμογή στο βιοϊατρικό περιβάλλον όταν αυτό είναι σε θέση να διατηρήσει καλή ακρίβεια καθώς ασχολείται με μεγάλους αριθμούς προγνωστικών [59]. Ο στόχος αυτής της τεχνικής είναι να σχεδιάσει ένα υπερεπίπεδο που ταξινομεί όλα τα διανύσματα εκπαίδευσης σε διαχωρισμένες τάξεις με μέγιστο περιθώριο εντός του χώρου πρόβλεψης N διαστάσεων (Εικόνα 7). Σε γραμμικά διαχωρισμένα σύνολα δεδομένων, η θέση του υπερεπίπεδου μπορεί να ποικίλλει ως προς τη θέση και τον προσανατολισμό για να μεγιστοποιηθεί το περιθώριο του ταξινομητή. Η SVM διαφοροποιεί την υπολογιστική χαρτογράφηση υπερεπιπέδου όταν τα σημεία δεδομένων δεν μπορούν να διαχωριστούν γραμμικά, μετατρέποντας τα προγνωστικά από έναν χώρο χαμηλότερης διάστασης σε χώρο υψηλότερης διάστασης για να διορθώσει τον περιορισμό του. Υπολογιστικά, η διαμόρφωση των βέλτιστων ορίων απόφασης επηρεάζεται σε μεγάλο βαθμό από τις θέσεις δεδομένων εκπαίδευσης όπου μπορεί να προσκολληθούν διανύσματα εισόδου και προϊόντα κουκκίδων για την επίλυση αυτού του προβλήματος βελτιστοποίησης. Το SVM χρησιμοποιεί τη συνάρτηση πυρήνα στο γινόμενο κουκκίδων όπου μετρά τις αποστάσεις μεταξύ των διανυσμάτων, τα οποία στη συνέχεια θα μπορούσαν να χρησιμοποιηθούν για τον εντοπισμό του υπερεπιπέδου που ταιριάζει καλύτερα στο χώρο χαρακτηριστικών. Η εφαρμογή της συνάρτησης K στο γινόμενο κουκκίδων δύο διανυσμάτων επιτρέπει την εκτέλεση ενός ακριβούς μηχανισμού διαχωρισμού, χωρίς να χρειάζεται να γνωρίζουμε τη διαδικασία μετατροπής στον άλλο χώρο. Αντίθετα, ο ταξινομητής SVM διαχωρίζει τις κατηγορίες δεδομένων με τέτοιο τρόπο ώστε το περιθώριο διαχωρισμού να μεγιστοποιείται βέλτιστα [60],[54],[59].



Εικόνα 8 Γραμμικός ταξινομητής SVM [55]

3.3.2 K-Nearest Neighbours (KNN)

Η KNN είναι πιθανώς μια από τις πιο δημοφιλείς μη παραμετρικές εποπτευόμενες μεθόδους μηχανικής μάθησης που εφαρμόζεται στον ερευνητικό τομέα της νευροεπιστήμης της ακοής. Λειτουργεί αποτελεσματικά σε μη γραμμική κυματομορφή εγκεφάλου [61],[62]. Αυτός ο αλγόριθμος χρησιμοποιεί την πλησιέστερη τιμή K από την περιοχή γειτονιάς για να ταξινομήσει το δοθέν σύνολο δεδομένων εισόδου. Η κατηγορία των μη ταξινομημένων σημείων δεδομένων μπορεί να προσδιοριστεί λαμβάνοντας υπόψη τη συγκεκριμένη κατηγορία των πλησιέστερων γειτόνων της, όπως βλέπουμε και στην Εικόνα 8. Για να καθοριστούν με ακρίβεια οι πλησιέστεροι γείτονες δεδομένων σημείων δεδομένων, η μέτρηση της απόστασης υπολογίζεται από το σύνολο δεδομένων δοκιμής που βρίσκεται πλησιέστερα σε όλα τα γνωστά σημεία δεδομένων χρησιμοποιώντας την Ευκλείδεια απόσταση. Η βέλτιστη τιμή K υποστηρίζει την εκχώρηση της κλάσης της εισόδου δοκιμής με βάση την κλάση πληθώρας του πλησιέστερου συνόλου εκπαίδευσης K όπου η πολυπλοκότητα εξαρτάται σε μεγάλο βαθμό από το μέγεθος του δείγματος δεδομένων. Η KNN είναι επωφελής για την ικανοποίηση τόσο της ταξινόμησης όσο και της εφαρμογής της προσανατολισμένης παλινδρόμησης.



Εικόνα 9 Αντίληψη του KNN [61]


3.3.3 Naïve Bayes (NB)

Ο ταξινομητής Naïve Bayes, γνωστός και ως πιθανοτικός ταξινομητής, προήλθε από τη λειτουργία βασισμένη στο θεώρημα Bayes, η οποία εφαρμόζει την έννοια της κανονικής κατανομής για να μοντελοποιήσει έναν αλγόριθμο μέσω της μέτρησης της μέσης τυπικής απόκλισης για κάθε κατηγορία μελέτης. Αυτό περιέχει ισχυρή υπόθεση ανεξαρτησίας υπό όρους μεταξύ των κατανομών των μετρούμενων μεταβλητών [54],[63]. Τα πλεονεκτήματα του NB είναι η απλότητα και η ικανότητά του να υποστηρίζει σωστά την ταξινόμηση μεταξύ τάξεων μελέτης χρησιμοποιώντας περιορισμένη ποσότητα συνόλων δεδομένων εκπαίδευσης λόγω των χαρακτηριστικών υποθέσεων πρόβλεψης.

3.3.4 Multilayer perceptron neural network (MLPNN)

Το MLPNN είναι ένας μη γραμμικός αλγόριθμος νευρωνικού δικτύου τροφοδοσίας με πολλαπλά επίπεδα υπολογιστικών μονάδων που ξεκινούν από ένα μόνο επίπεδο εισόδου, ένα ή πολλαπλά κρυφά υπολογιστικά στρώματα και ένα μόνο επίπεδο εξόδου. Αυτή η εποπτευόμενη τεχνική εκμάθησης καθιστά δυνατή την προσέγγιση οποιασδήποτε μη γραμμικής συνάρτησης προβλήματος μέσω της μεθόδου εκπαίδευσης οπισθοδιάδοσης [9],[18],[31],[48]. Είναι επίσης χρήσιμο για ανάλυση παλινδρόμησης. Γενικά, οι μεταβλητές εισόδου χρησιμοποιούνται για τον καθορισμό του αριθμού των κόμβων εισόδου και όλοι οι κόμβοι διασυνδέονται μεταξύ κρυφών

επιπέδων που τελικά τροφοδοτούνται στο επίπεδο εξόδου. Η αρχιτεκτονική του MLPNN παρουσιάζεται στην Εικόνα 9.



Εικόνα 10 Μοντέλο πολυστρωματικού perceptron. Το X υποδηλώνει μεταβλητή εισόδου. Το H υποδηλώνει κρυφή μεταβλητή. Το Y υποδηλώνει την έξοδο του ταξινομητή [57]

3.3.5 Elman Network (ELN)

Το ELN είναι ένα μη γραμμικό σύστημα επεξεργασίας υπολογισμών με υποκατηγορία νευρωνικού δικτύου ανάδρασης. Αποτελείται από τέσσερα επίπεδα επεξεργασίας, τα οποία είναι: το επίπεδο εισόδου, το κρυφό στρώμα, το επίπεδο επιχείρησης και το στρώμα εξόδου. Η δυναμική μεταβαλλόμενη χρονικά προσαρμοστικότητα του ELN συνεισφέρει από το πρόσθετο επίπεδο επεξεργασίας που είναι γνωστό ως επίπεδο ανάληψης. Αυτό το στρώμα λειτουργεί ως μνήμη για τη νευρική απόκριση πίσω διάδοσης και τη βελτίωση της σταθερότητας μετά το βήμα καθυστέρησης χειριστή. Λόγω της παρουσίας του επιπέδου ανάληψης, το ELN είναι εξαιρετικά ευαίσθητο στην αποθηκευμένη εσωτερική μνήμη και τη μετατρέπει σε έναν εξαιρετικά δυναμικό αλγόριθμο απλής ροής. Το ELN επιβεβαίωσε την απουσία μηχανισμού βρόχου ή κύκλου και επιτρέπει μόνο μονόδρομη ροή επεξεργασίας πληροφοριών στους κόμβους εξόδου [54],[55],[64].

3.3.6 Random Forest (RF)

Η RF λειτουργεί αναπτύσσοντας νέα τυχαία δειγματοληψία bootstrap ως παρατηρήσεις εκπαίδευσης. Αυτή η εποπτευόμενη μηχανική εκμάθηση δημιουργεί σταθερή πρόβλεψη αξιολογώντας πολλαπλά δέντρα αποφάσεων από τυχαίο υποσύνολο των επιλεγμένων χαρακτηριστικών που είναι γνωστά ως κόμβος ρίζας και αυξάνοντας περαιτέρω τα δέντρα αποφάσεων. Ο αλγόριθμος RF συγχωνεύει την απλότητα των δέντρων αποφάσεων με την ευελιξία με αποτέλεσμα σημαντική βελτίωση στην ακρίβεια. Λόγω των ιδιοτήτων του, το όριο για κάθε μεταβλητή επιλέγεται τυχαία αντί να αξιολογηθεί το καλύτερο όριο για τη διαδικασία λήψης αποφάσεων. Η τελική απόφαση λαμβάνεται μέσω της συγκέντρωσης των αποτελεσμάτων πρόβλεψης από τα δέντρα αποφάσεων μέσω της βαθμολογίας ψηφοφορίας. Είναι σημαντικό ότι το RF κατηγοριοποιείται ως ένα ευρέως διαφοροποιημένο και καλό μοντέλο ταξινόμησης λόγω της ευκολίας του να εκπαιδευτεί με αποδεκτή ακρίβεια πρόβλεψης [61],[54]. Ωστόσο, λόγω της φύσης της υπολογιστικής διαδικασίας σύμφωνα με τον τεράστιο αριθμό δομών δέντρων, αυτός ο αλγόριθμος συνήγαγε αργή ταχύτητα επεξεργασίας που οδηγεί σε αναποτελεσματικότητα σε εφαρμογή σε πραγματικό χρόνο [65],[55].

3.3.7 Adaptive boosting

Η προσαρμοστική ενίσχυση, γνωστή και ως ταξινομητής AdaBoost, εισήχθη με βάση την αρχή εκπαίδευσης των κολοβωμάτων (stumps) στη διαδικασία λήψης αποφάσεων. Αυτός ο αλγόριθμος ενίσχυσης συνδυάζει τους αδύναμους «μαθητές» (weak learners) που αντιπροσωπεύονται από τη σειρά μεμονωμένων κολοβωμάτων με συγκεκριμένη σταθμισμένη συνάρτηση για την παραγωγή καλής και ισχυρής τελικής απόφασης ταξινομητή. Από μια άλλη άποψη, αυτός ο ταξινομητής λειτουργεί ενοποιώντας και εκπαιδεύοντας μια σειρά από αποφάσεις χαμηλής ακρίβειας με στόχο τη δημιουργία μοντέλου υψηλότερης ακρίβειας. Το σφάλμα ή η ανακρίβεια που δημιουργήθηκε από το πρώτο δέντρο αποφάσεων θα ληφθεί υπόψη στα επόμενα αναπτυγμένα κολοβώματα απόφασης. Δημιουργήθηκε το έτος 1995 και είχε χρησιμοποιηθεί ευρέως σε πολλές εφαρμογές μηχανικής λόγω της καλής ακρίβειας και προσαρμοστικότητας του [61],[63],[66].

3.4 Ανάλυση απόδοσης ταξινόμησης

Στο παρελθόν, οι ειδικοί έχουν κάνει χρήση διάφορων μεθόδων μηχανικής για την ανάλυση των ΑΠΔΕΣ. Ο Alpsan D. [67] εκμεταλλεύτηκε ένα πολύ-επίπεδο τεχνητό νευρωνικό δίκτυο (Neural Network) με σκοπό να ανιχνεύσει τα κατώφλια ΑΠΔΕΣ εισάγοντας τα ακατέργαστα ηλεκτρικά σήματα. Η συγκεκριμένη μελέτη έδειξε ότι οι κλινικές ετικέτες (που σημειώνονται από έναν ειδικό) σχετίζονται σε μεγάλο βαθμό με εκείνες που δημιουργούνται από το νευρωνικό δίκτυο. Παρόλα αυτά, η μελέτη του, δεν βασίστηκε στην εξαγωγή χαρακτηριστικών σήματος, μέσω της οποίας χρήσιμα χαρακτηριστικά από το πρωτογενές σήμα εισάγονται στον αλγόριθμο έτσι ώστε να επιτευχθεί μια ακριβή ταξινόμηση των αποκρίσεων. Οι επόμενες μελέτες επικεντρώθηκαν σε μεθόδους εξαγωγής χαρακτηριστικών σήματος που βασίζονται περισσότερο σε τεχνικές επεξεργασίας σήματος.

Μια από αυτές της μελέτες είναι αυτή του Rui Zhang [68], ο οποίος χρησιμοποίησε το Discrete Wavelet Transform (DWT) για να εξάγει χαρακτηριστικά από τα ΑΠΔΕΣ και παράλληλα βασίστηκε σε ένα Bayesian δίκτυο για να έχει την δυνατότητα να ανιχνεύσει αποκρίσεις ΑΠΔΕΣ, και ευτυχώς, αντίθετα με τα αποτελέσματα και ευρήματα που παρείχαν προηγούμενες έρευνες, ο Zhang και η ομάδα του κατάφεραν να βελτιώσουν την ακρίβεια της ανίχνευσης κυματομορφής χρησιμοποιώντας την μέθοδο εξαγωγής χαρακτηριστικών.

Η χρήση ενός αλγόριθμου που επιλέγει συγκεκριμένα χαρακτηριστικά και βασίζεται σε SVM για την ταξινόμηση κυματομορφών ΑΠΔΕΣ από τους Acir N, Özdamar Ö, Güzelis C [69] εντόπισε και επισήμανε την ύπαρξη μιας βελτιωμένης ικανότητας ανίχνευσης κυματομορφής. Αυτός ο προσαρμοστικός αλγόριθμος επιλογής χαρακτηριστικών βασίζεται στην χρήση χαρακτηριστικών που εξάγονται από τις τεχνικές Discrete Cosine Transform (DCT) και DWT. Αυτές οι μέθοδοι είχαν ως αποτέλεσμα την επίτευξη μεγαλύτερης ακρίβειας σε σύγκριση με τα αποτελέσματα που επέφεραν προηγούμενοι αλγόριθμοι.

Οι S. Rahbar, M. Abolhassani, H. Arabalibeik, A. Jafari [70] χρησιμοποίησαν ένα πολυστρωματικό νευρωνικό δίκτυο τροφοδοσίας το οποίο θα μπορούσε να ταξινομήσει τις αποκρίσεις ΑΠΔΕΣ χρησιμοποιώντας τα χαρακτηριστικά που εξάγονται από το

DWT. Η χρήση διαφορετικών τύπων ταξινομητών όπως Naïve Bayes, Decision Trees (DT) και υβριδικών μοντέλων με διαφορετικές μεθόδους μηχανικής χαρακτηριστικών συνέβαλε στην επιτυχημένη και ακριβή ανίχνευση των αλγορίθμων μηχανικής μάθησης. Κατά συνέπεια, είναι ξεκάθαρο από τις προαναφερθείσες μελέτες ότι οι αλγόριθμοι μηχανικής μάθησης με εξαγωγή χαρακτηριστικών και επιλογή χαρακτηριστικών καθιστούν τους ειδικούς ικανούς να παρέχουν πολλά υποσχόμενα αποτελέσματα κατά την ανάλυση των ΑΠΔΕΣ.

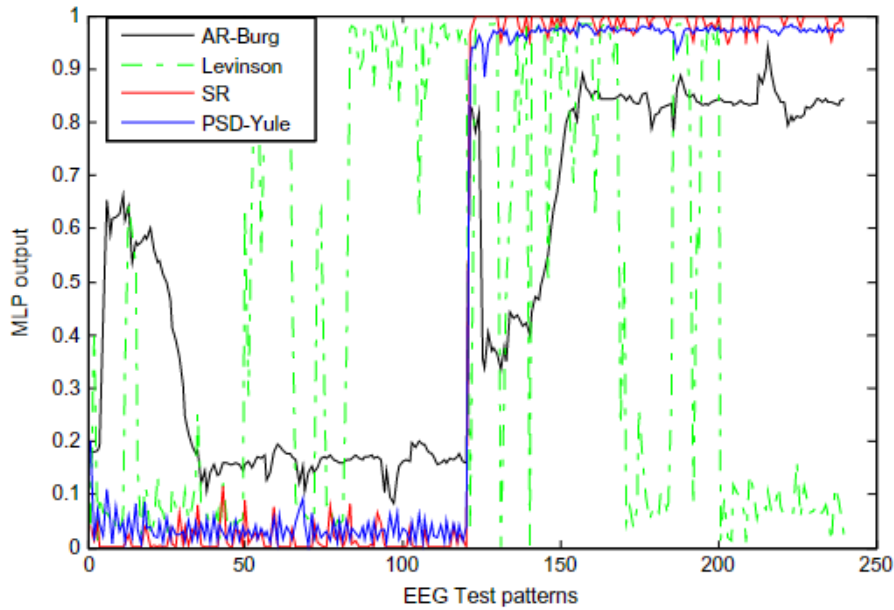
Μια μελέτη που διεξήχθη από τους Dobrowolski A, Suchocki M, Tomczykiewicz K, Majda-Zdancewicz E [71] χρησιμοποίησε ένα SVM με χαρακτηριστικά DWT έτσι ώστε να ταξινομήσει διάφορες παθολογικές αποκρίσεις ΑΠΔΕΣ. Η ακρίβεια της ομάδας δοκιμής ανήλθε σε ποσοστό 92% με ευαισθησία και ειδικότητα 88% και 96%, αντίστοιχα.

Οι Molina M, Perez A, Valente J [72] κατάφεραν να εισάγουν μια νέα τεχνική εξαγωγής χαρακτηριστικών καθώς μετέτρεπαν αρχικά το σήμα ΑΠΔΕΣ σε ένα συμβολικό μοτίβο ακολουθίας, μια παρόμοια μέθοδο ταξινόμησης ΑΠΔΕΣ που διάφοροι ακουολόγοι χρησιμοποιούσαν και εφάρμοζαν αυτά τα χρόνια. Η συγκεκριμένη μελέτη επισήμανε ότι η γνώση των τεχνικών διαφορετικών τομέων είναι δυνατόν να βελτιώσει σημαντικά την αποτελεσματικότητα των ταξινομητών, με αναφερόμενη τελική ακρίβεια ακόμα και σε ποσοστό 99,4%. Ωστόσο, αυτή η προσέγγιση μπορεί να περιοριστεί, καθώς κάποιος ειδικός απαιτείται να εξάγουν χαρακτηριστικά και έτσι ο ίδιος ειδικός πρέπει να μετατρέψει χειροκίνητα την καταγεγραμμένη κυματομορφή σε συμβολική αναπαράσταση πριν ολοκληρωθεί η εκπαίδευση του αλγόριθμου.

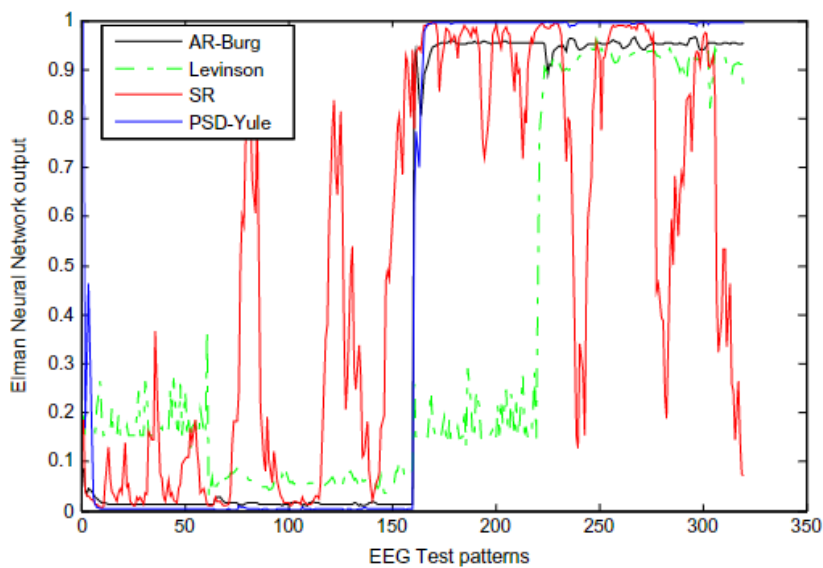
Μια μελέτη από τον McCullagh και τους συναδέλφους του [73] διερεύνησε την καταλληλότητα διαφορετικών επιλογών ταξινομητών στην ανάλυση προκλητού δυναμικού για την πρόσβαση στην καλύτερη απόδοση ταξινόμησης στην αναλογία ισχύος ΑΠΔ προ-διέγερσης και μετά από ερέθισμα ατόμων με προβλήματα ακοής. Τα μήκη κλιμάκωσης κατά μήκος των συχνοτήτων κινούμενων παραθύρων παρουσιάστηκαν σε συντελεστές κυματιδίων. Εδώ, η ανάλυση βάσει αριθμητικής στάθμισης εφαρμόστηκε ως χαρακτηριστικό για ταξινόμηση ως απόκριση στην κατάτμηση του λόγου ισχύος. Οι ταξινομητές NB,SVM και MLPNN αναλύθηκαν για

τη μέτρηση της στατιστικής παραγωγής της ταξινόμησης. Το NB κατέληξε στο συμπέρασμα ότι παρέχει μέγιστη ακρίβεια στο 83,4% μεταξύ των πέντε κορυφαίων χαρακτηριστικών. Επιπλέον, ο ταξινομητής NB παρείχε μια καλή ισορροπία μεταξύ της ειδικότητας (86,3%) και της ευαισθησίας (82,2%) για την ανίχνευση της απώλειας ακοής (Απόκριση = «OXI»). Κάτω από τα ίδια πειραματικά χαρακτηριστικά, το SVM πέτυχε το υψηλότερο επίπεδο ευαισθησίας που καταγράφηκε στο 93,1%, αλλά ανέφερε χαμηλότερη βαθμολογία ειδικότητας (54,9%). Μεταξύ των δύο κορυφαίων χαρακτηριστικών ταξινόμησης, η NB παραμένει ως ο καλύτερος ταξινομητής ανταποκρινόμενος με ακρίβεια 81,4% σε σύγκριση με άλλους ταξινομητές. Ουσιαστικά, η μελέτη απέδειξε με επιτυχία την υιοθέτηση της μηχανικής μάθησης στην παροχή ουσιαστικής ποσοτικοποίησης για την ανίχνευση απώλειας ακοής.

Περαιτέρω γνώση δημιουργήθηκε από τον Sriraam [74] όταν ο συγγραφέας καθόρισε το όφελος των ταξινομητών MLPNN και ELN για την ανίχνευση της απώλειας ακοής. Αυτή η πιλοτική μελέτη εφαρμόστηκε σε ενήλικες για τη διαφοροποίηση μεταξύ των εξωτερικών ερεθισμάτων και της κατάστασης μη ερεθισμάτων, αξιολογώντας τα χαρακτηριστικά του τομέα χρόνου-συχνότητας του σήματος από ΑΠΔ. Ο συγγραφέας προσπάθησε να εκμεταλλευτεί χαρακτηριστικά χρόνου-συχνότητας από σήματα ΑΠΔ για να παρουσιαστούν ως είσοδοι ταξινομητών: (1) Χαρακτηριστικά πεδίου χρόνου, π.χ. ρυθμικότητα αιχμής (SR) και αυτοπαλινδρομική μέθοδος Levinson-Dublin και (2) Χαρακτηριστικά τομέα συχνότητας, π.χ. εκτίμηση φασματικής πυκνότητας ισχύος από Burg's (AR Burg) και Yule-Walker (PSD-Yule). Ο ταξινομητής MLPNN έδειξε καλή απόδοση ταξινόμησης στη διάκριση των PSD-Yule και SR με βαθμολογία ακρίβειας 99,6% και 100% αντίστοιχα σε σύγκριση με τον ταξινομητή ELN, που αναφέρθηκαν σε 99,3% και 79,3% αντίστοιχα. Αντίθετα, το χαρακτηριστικό SR βρέθηκε να είναι το λιγότερο συμβατό κατά τη χρήση του ταξινομητή ELN, που αναφέρεται στο 79,3% [74]. Ιδανικά, ο συγγραφέας δίνει καλά κίνητρα για τη ρύθμιση του συστήματος νοημοσύνης με εξαιρετικά ακριβή κλινική απόφαση που λαμβάνεται από ειδικούς ιατρούς μέσω της εξέτασης της αυτοματοποιημένης υπολογιστικής τοπολογίας. Οι εικόνες 10 και 11 δείχνουν τον ταξινομητή απόδοσης με τη χρήση των χαρακτηριστικών του τομέα συχνότητας. Προβλέπεται ότι η αποδεδειγμένη μέθοδος μπορεί να υιοθετηθεί αποτελεσματικά για εφαρμογές σε νεογέννητα.




Εικόνα 11 Απόδοση ταξινομητή MLP χρησιμοποιώντας πρότυπα δοκιμών [74]



Εικόνα 12 Απόδοση ταξινομητή EN χρησιμοποιώντας πρότυπα δοκιμών [74]

Μια άλλη αναφερόμενη εργασία του Pandiyan και του συναδέλφου του [75] χρησιμοποίησε μοντέλα νευρωνικών δικτύων ανατροφοδότησης και ανάδρασης για την ταξινόμηση των καταστάσεων ακοής των υποκειμένων χρησιμοποιώντας απόκριση σημάτων ΑΠΔ. Οι συγγραφείς απέδειξαν την ικανότητα του προτεινόμενου νευρωνικού δικτύου να διακρίνει την απόκριση ΑΠΔ μεταξύ ατόμων με φυσιολογική ακοή και ατόμων με απώλεια ακοής με ακρίβεια ταξινόμησης 96,75% [75]. Τα

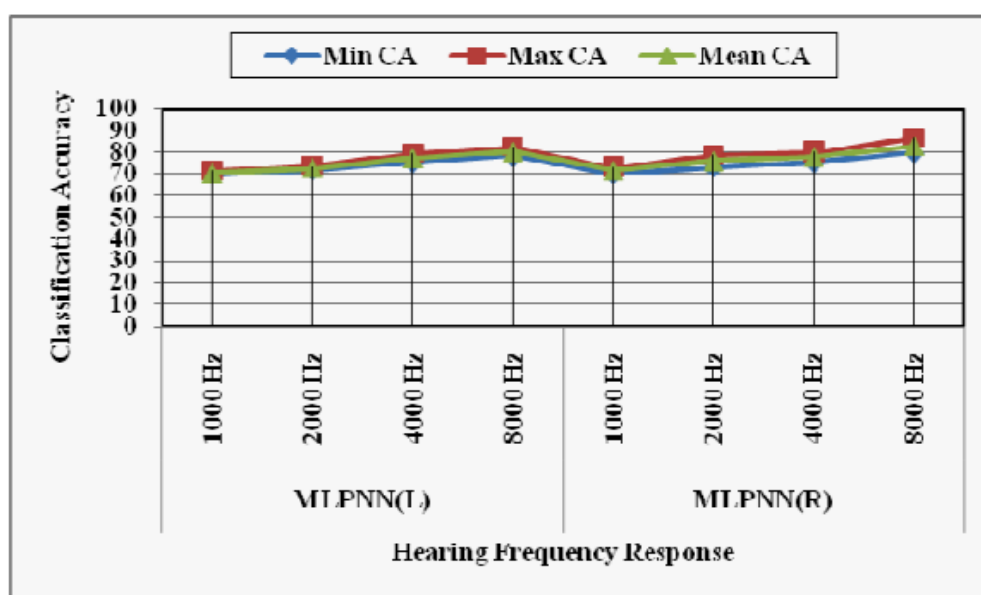
προτεινόμενα μοντέλα, MLPNN και ELN προσπάθησαν να ταξινομήσουν τα θέματα με βάση το διάλυμα των 19 χαρακτηριστικών εισόδου, δηλαδή το χαρακτηριστικό φασματικής ζώνης γάμμα ισχύος (PSGB19) και το χαρακτηριστικό ζώνης φασματικής εντροπίας γάμμα (SEGB19) χρησιμοποιώντας τη συνάρτηση λογαριθμικού σιγμοειδούς για την ενεργοποίηση των νευρώνων εξόδου. Το δεξί αντί PSGB19 ποσοτικοποιήθηκε ως το καλύτερο χαρακτηριστικό στην ταξινόμηση της κατάστασης ακοής που εμφανίστηκε και στους δύο προτεινόμενους ταξινομητές με βαθμολογία ακρίβειας μεγαλύτερη από 92%. Διαπιστώθηκε ότι η επιλεγμένη μηχανική εκμάθηση θα μπορούσε να παρέχει δυναμικές διακριτικές πληροφορίες με βάση τα εξαγόμενα χαρακτηριστικά εισόδου. Αυτό το κρίσιμο εύρημα έδωσε τη δυνατότητα στους ερευνητές να επεκτείνουν την ικανότητα αναγνώρισης της κατάστασης ακοής σε μεγαλύτερη κλινική κοινότητα.




Εικόνα 13 Δείκτης βαθμολογίας ισχύος γάμμα από δεκαεννέα κανάλια ηλεκτροδίων [75]

Στη συνέχεια, οι ίδιοι ερευνητές επέκτειναν το ίδιο ενδιαφέρον αναπτύσσοντας ένα έξυπνο σύστημα αξιολόγησης επιπέδου ικανότητας ακοής μέσω της υποστήριξης της μηχανικής μάθησης [76]. Τα MLPNN και ELN χρησιμοποιήθηκαν ευρέως στην εργασία για τον προσδιορισμό των διαφορετικών αποκρίσεων ΑΠΔ σε επίπεδα ακουστικής αντίληψης. Η ανάλυση με βάση το χρόνο, γνωστή ως Fractal Dimension (FD) χρησιμοποιώντας την τεχνική Higuchi χρησιμοποιήθηκε για τον ποσοτικό

προσδιορισμό του χαρακτηριστικού σήματος. Εξήγησαν ότι το MLPNN παρουσίασε μέγιστη ακρίβεια ταξινόμησης στο 82,78% όταν διαφοροποιούσε την απόκριση ακοής χρησιμοποιώντας το επίπεδο συχνότητας 8000 Hz που παραδόθηκε στα κανονικά ενήλικα άτομα που δοκιμάζονται. Επιπλέον, το ELN κατάφερε επίσης να σημειώσει μέση ακρίβεια 78,52% σε παρόμοια πειραματική διάταξη. Η ακρίβεια ταξινόμησης των μοντέλων MLPNN και ELN χρησιμοποιώντας Higuchi fractal χαρακτηριστικά για το δεξί και το αριστερό αυτί φαίνεται στις εικόνες 13 και 14. Γενικά, η εργασία ταξινόμησης διαμορφώθηκε ώστε να έχει καλύτερη απόδοση στο δεξί αυτί σε σύγκριση με το αριστερό αυτί και στους δύο ταξινομητές. Παρατηρήθηκε πώς οι προτεινόμενες τεχνικές μηχανικής μάθησης θα διεύρυναν την δυνατότητα να βοηθήσουν τους ιατρούς στην αξιολόγηση ανίχνευσης απώλειας ακοής με κατευθυνόμενες προσπάθειες σε σχετικά προγράμματα αποκατάστασης της ακοής.



Εικόνα 14 Ακρίβεια ταξινόμησης για MLPNN μοντέλα [76]



Εικόνα 15 Ακρίβεια ταξινόμησης για ELN μοντέλα [76]

Στην ίδια ερευνητική κατεύθυνση, το ενδιαφέρον υποδομήθηκε μέσω της κλιμάκωσης μιας έρευνας σχετικά με την αντιληπτική διάκριση ΑΠΔ στα αγγλικά φωνήεντα [77]. Η εργασία τους χρησιμοποίησε τον ταξινομητή Linear Discriminant Analysis (LDA), για να διακρίνει τα χαρακτηριστικά που παρουσιάζονται στους δύο τύπους παροδικής απόκρισης έναρξης, δηλαδή ως απόκριση περιβάλλουσας (envelope) (EFR) και απόκριση συχνότητας (FFR). Οι συγγραφείς έδειξαν ότι η απόκριση παροδικής έναρξης ολόκληρου του εγκεφάλου προσέφερε την υψηλότερη ακρίβεια 83,33% κατά τη διάρκεια της διαχωριστικής εργασίας από το εκπαιδευμένο μοντέλο. Η ακρίβεια EFR και FFR αναφέρθηκε σε 70,83% και 59,58% αντίστοιχα. Η καλή ακρίβεια του EFR πρότεινε ότι η αντιληπτική διάκριση των διακριτικών φωνηέντων είναι ισοδύναμη μεταξύ της θεμελιώδους συχνότητας και της συχνότητας σχηματισμού, F0, και διοχετεύεται σε συγκεκριμένες πληροφορίες για τα φωνήεντα. Η εργασία τους περιέγραψε μια αντικειμενική αξιολόγηση ταξινόμησης πολύπλοκων ερεθισμάτων σχετικά με την ακουστική λειτουργικότητα για την ομιλητική επικοινωνία, αντί για συμβατικά χρησιμοποιούμενα υποκειμενικά μέτρα που ελήφθησαν χρησιμοποιώντας εκρήξεις ήχου ή ηχητικά κλικ. Γενικά, η προσαρμογή συντονισμού των ακουστικών βαρηκοΐας σύμφωνα με την καθιερωμένη εργασία θα ήταν χρήσιμη για την ακριβή ομαδοποίηση της αναγνώρισης ήχου ομιλίας.

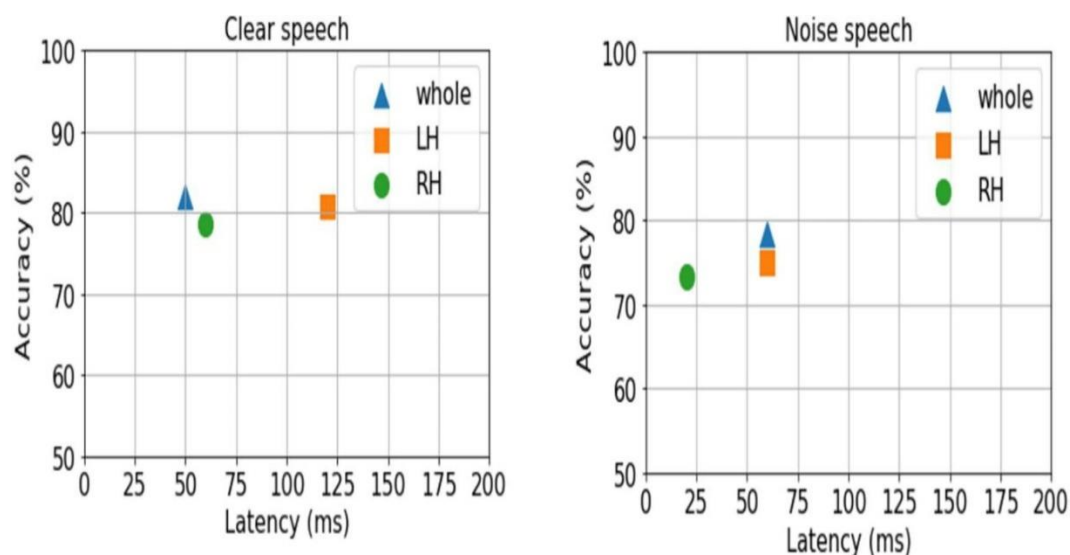
Για να αυξήσουν τις άγνωστες δυνατότητες μηχανικής μάθησης, οι ερευνητές εφάρμοσαν μέθοδο βάσει δεδομένων για την αποκωδικοποίηση φωνηέντων με βάση την απόκριση μιας δοκιμής χρησιμοποιώντας φασματικά χαρακτηριστικά του ΑΕΡ, γνωστά ως απόκριση παρακολούθησης συχνότητας (FFR) [78]. Κυρίως, η προτεινόμενη χρησιμότητα μιας δοκιμής προσπάθησε να ελαχιστοποιήσει τις πιθανότητες διακυμάνσεων των συνθηκών προσοχής κατά τη διάρκεια του μέσου όρου της απόκρισης και να αποφύγει τη νευρική προσαρμογή ή την πρόβλεψη στο παρουσιαζόμενο ακουστικό ερέθισμα μεταξύ των δοκιμών. Οι συγγραφείς χρησιμοποίησαν τον ταξινομητή Gradient Boosted Decision Tree (GBDT) για να εκπαιδεύσουν τις εξαγόμενες μεταβλητές εισόδου. Και οι δύο μετρήσιμες αποκρίσεις ταξινομήθηκαν μεταξύ των διακριτικών φωνηέντων ($N = 2$) και των μεμονωμένων ερεθισμάτων ($N = 4$) μεταξύ του σχεδιασμού πειράματος που δοκιμάστηκε. Σε όλους τους συμμετέχοντες, η κατανομή της περιοχής κάτω από την καμπύλη (AUC) έδειξε ότι η απόδοση ευαισθησίας της αποκωδικοποίησης φωνηέντων και της αποκωδικοποίησης ερεθισμάτων αναφέρθηκαν σε 86% και 68% αντίστοιχα. Δεν υπήρχε μετρήσιμος δείκτης ακρίβειας στον εκπαιδευμένο ταξινομητή που χρησιμοποιεί το προτεινόμενο χαρακτηριστικό FFR. Επομένως, το FFR μιας δοκιμής από ερέθισμα-απόκριση φωνηέντων ΑΠΔ μπορεί να θεωρηθεί ότι ταξινομείται χρησιμοποιώντας την προτεινόμενη μηχανική μάθηση. Η εκλεπτυσμένη ερμηνευτικότητα των χαρακτηριστικών αποδείχθηκε ότι προσδίδει οφέλη στον τομέα της ακουστικής αξιολόγησης.

Πραγματοποιήθηκε μια εκτεταμένη μελέτη από τον Ibrahim, Ting [79] για τη διαμόρφωση δεικτών ΗΕΓ χρησιμοποιώντας χαρακτηριστικά ΗΕΓ για την ταξινόμηση των εγκεφαλικών αποκρίσεων με διαφορετικές ικανότητες ακοής. Χρησιμοποιήθηκαν πέντε τεχνικές ταξινόμησης προκειμένου να εκπληρωθεί ο κύριος στόχος της μελέτης, δηλαδή SVM, KNN, LDA, RF και NB. Η ανάλυση διεξήχθη χρησιμοποιώντας μεθόδους μη γραμμικού δείκτη εντροπίας όπως οι εντροπίες Kolmogorov-Sinai, Sample και Approximate Entropies. Παρατηρήθηκε ότι ο ταξινομητής SVM παρήγαγε την υψηλότερη ακρίβεια (90% και για τα δύο ακουστικά ερεθίσματα) η οποία ξεπέρασε τους άλλους ταξινομητές στον διαχωρισμό των ανθρώπινων ακουστικών ικανοτήτων. Οι ερευνητές ισχυρίστηκαν ότι η παρούσα ιδέα ήταν σε θέση να ταξινομήσει βέλτιστα τις ακουστικές ικανότητες, συμπεριλαμβανομένων των δύσκολα δοκιμασμένων

θεμάτων σε σύγκριση με τη συμβατική προσέγγιση χωρίς δείκτη. Πολλά συστήματα είναι πλέον εξοπλισμένα με παρόμοιες μεθοδολογίες όπως η εφαρμογή διεπαφής εγκεφάλου-υπολογιστή, η μελέτη επιληψίας και η διερεύνηση καρδιακού θανάτου[80]–[82]. Παράλληλα με την επιτυχία της ταξινόμησης ΑΕΡ σε πολλούς άλλους τομείς εφαρμογής ΗΕΓ, οι ερευνητές [79] δημιούργησαν μια νέα μελέτη για την ταξινόμηση της ανθρώπινης εθνότητας με βάση τις ακουστικές αποκρίσεις του εγκεφάλου. Η σύνθεση των ολοκληρωμένων δεικτών από τις υποκείμενες ομάδες χρησιμοποιήθηκε για εκπαίδευση και δοκιμάστηκε σε τρεις επιλεγμένες μηχανές μάθησης: SVM, KNN και LDA. Παρόμοια μη γραμμικά χαρακτηριστικά ευρετηρίου εντροπιών από προηγούμενες εργασίες παρασχέθηκαν ως σύνολο δεδομένων εκπαίδευσης. Διευκρίνισε ότι οι προτεινόμενοι δείκτες ταξινόμησης ήταν ικανοί να διαχωρίσουν με σαφήνεια τη διακύμανση της ανθρώπινης εθνικότητας σύμφωνα με την ακουστική απόκριση με την υψηλότερη απόδοση ταξινόμησης που έδειξε η τεχνική SVM σε 90% μετρούμενη ακρίβεια για την ομάδα ελέγχου και 84% μετρούμενη ακρίβεια για ομάδα με προβλήματα ακοής. Αυτά τα ευρήματα θα μπορούσαν να αντιμετωπίσουν τις εκτιμήσεις σχεδιασμού για αλγόριθμους ταξινόμησης σε μη γραμμικά σήματα, ειδικά όσον αφορά τα χαρακτηριστικά μεταβλητής στο σύνολο δεδομένων.

Το 2019, μια ομάδα ερευνητών εξέτασε την ταξινόμηση της μηχανικής μάθησης των εργασιών διάκρισης φωνημάτων μεταξύ της ομάδας δεικτών ακοής λαμβάνοντας υπόψη τον παράγοντα διακύμανσης που σχετίζεται με την ηλικία σε διαφορετικές συνθήκες ακοής [83]. Η έρευνά τους συζήτησε την ανάλυση χρονικών και χωρικών αποκρίσεων του φλοιού του εγκεφάλου μεταξύ των ημισφαιρίων μετά την έναρξη του ερεθίσματος. Η απόκριση των εξαγόμενων χαρακτηριστικών από το σήμα του εγκεφάλου χρησιμοποιήθηκε ως το σύνολο δεδομένων εισόδου για τον ταξινομητή SVM. Η ουσία της μελέτης αποκάλυψε ότι η ανάλυση καθαρής ομιλίας ολόκληρου του εγκεφάλου είχε εξαιρετική ακρίβεια ταξινόμησης στο 82,03% με λανθάνουσα απόκριση ομαδικού διαχωρισμού περίπου 50 ms. Αντίθετα, σε συνθήκες θορύβου, η ακρίβεια ταξινόμησης αναφέρθηκε στο 78,39% με καθυστερημένο διαχωρισμό ομάδων σε λανθάνουσα κατάσταση 60 ms. όπως μπορούμε να δούμε και στην Εικόνα 15. Η μέθοδος βάσει δεδομένων απέδειξε ότι το αριστερό ημισφαίριο παρουσιάστηκε πιο εύρωστο όσον αφορά την ταξινόμηση της ικανότητας ακοής σε συγκεκριμένες συνθήκες σε σύγκριση με το δεξί ημισφαίριο. Όπως προαναφέρθηκε, η μελέτη τους

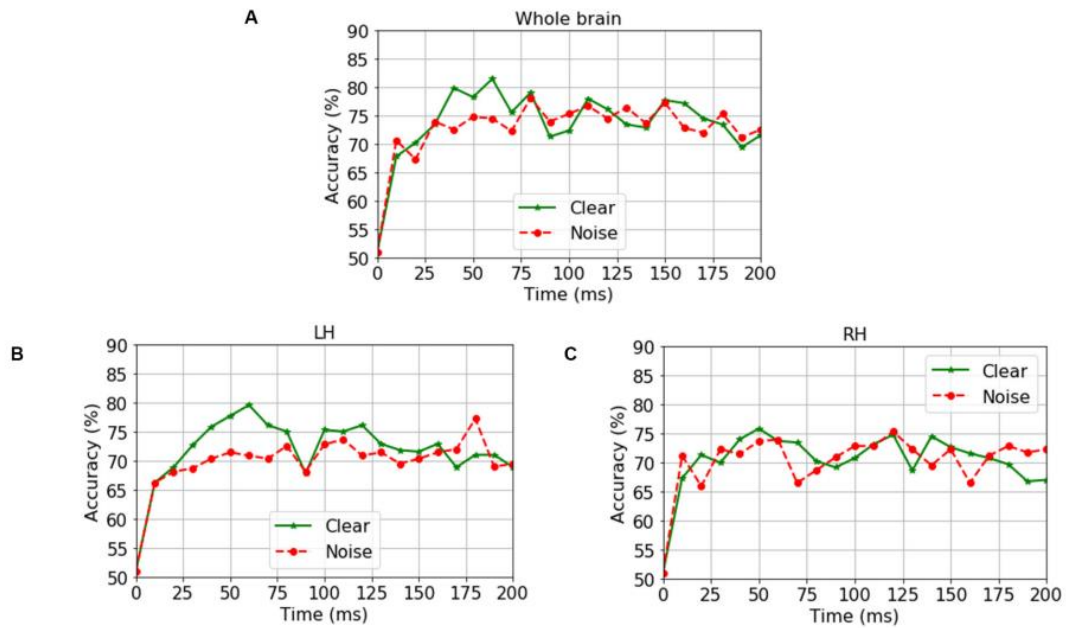
διευκρίνισε το νέο ισχυρό μοντέλο που προσδιορίζει το βασικό στοιχείο στη διάκριση της κατάστασης του δείκτη ακοής των δοκιμαστικών ομάδων λαμβάνοντας υπόψη την επίδραση που σχετίζεται με την ηλικία και τη διερεύνηση στην περιοχή ενδιαφέροντος επεξεργασίας.



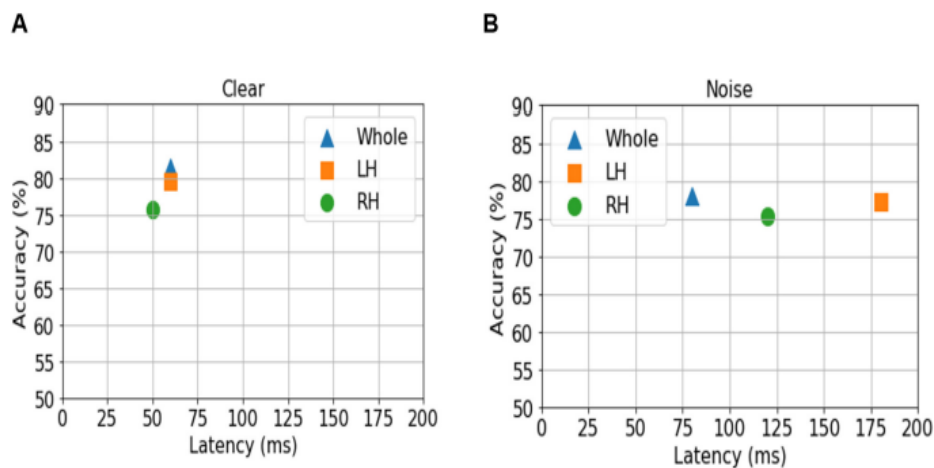
Εικόνα 16 Μέγιστη απόδοση ακρίβειας εκπαιδευμένου μοντέλου και απόκριση καθυστέρησης για την ανάλυση ολόκληρου του εγκεφάλου. Αριστερά: Καθαρή κατάσταση ομιλίας. Δεξιά: Κατάσταση ομιλίας με υποβάθμιση του θορύβου. Η LH αναφέρεται ως αριστερό ημισφαίριο. Η RH αναφέρεται ως δεξιό ημισφαίριο. Το whole αναφέρεται στα δεδομένα ολόκληρου του εγκεφάλου [84]

Περαιτέρω έρευνα από τους ίδιους ερευνητές αξιολόγησε τη χρονική και χωρική ανάλυση του φλοιώδους ΑΠΔ σε ενήλικες μεγαλύτερης ηλικίας χρησιμοποιώντας μηχανική μάθηση [84]. Διατήρησαν το διακριτικό μοτίβο απόκρισης μεταξύ των ημισφαιρίων του εγκεφάλου στην παρούσα εργασία, προκειμένου να διευκολυνθεί ο ενημερωτικός μετρήσιμος διαχωρισμός σε μεγαλύτερη ηλικία στο έργο της νευροφυσιολογικής ταξινόμησης. Ο βελτιστοποιημένος ταξινομητής SVM δημιούργησε υπερπλάνες με μέγιστο περιθώριο κατά τη διαδικασία αυτοματοποιημένης ταξινόμησης των δοκιμαστικών ομάδων σε δύο διαφορετικά ακουστικά περιβάλλοντα (καθαρή ομιλία έναντι ομιλίας θορύβου). Κατέληξαν στο συμπέρασμα ότι ο ταξινομητής είχε καλύτερη απόδοση με ακρίβεια 81,50% σε καθυστέρηση 60 ms για τα καθαρά δεδομένα ολόκληρου του εγκεφάλου ομιλίας σε σύγκριση με 78,12% με λανθάνουσα κατάσταση 80 ms σε κατάσταση θορύβου. Αυτή η εργασία υποδεικνύει σε γενικές γραμμές την αποτελεσματικότητα και την ευαισθησία που χαρακτηρίζει το συστατικό P1 στη διάκριση της ακουστικής ικανότητας σε μεγαλύτερη ηλικία, με επιπλέον ιδιαίτερα χαμηλότερους νευρικούς

πόρους που παρατηρούνται στο αριστερό ημισφαίριο σε σύγκριση με το δεξί ημισφαίριο.



Εικόνα 17 Χρονικά μεταβαλλόμενη ταξινόμηση ομάδας (NH έναντι HI) ως συνάρτηση των νευρωνικών δεδομένων (συνθήκες καθαρού και θορύβου) και του ημισφαιρίου. Ακρίβεια ταξινόμησης ομάδας από (A) Δεδομένα ολόκληρου του εγκεφάλου (και τα 68 ROI), (B) δεδομένα LH μόνο (34 ROI) και (C) Δεδομένα RH μόνο (34 ROI). LH αριστερό ημισφαίριο; RH δεξί ημισφαίριο. 0 ms = έναρξη ερεθίσματος. Η πράσινη συμπαγής γραμμή υποδεικνύει διαχωρισμό ομάδας κατά την καθαρή αντίληψη ομιλίας, η κόκκινη διακεκομμένη γραμμή υποδεικνύει διαχωρισμό ομάδας κατά την αντίληψη ομιλίας με υποβάθμιση του θορύβου [84]



Εικόνα 18 Μέγιστη ακρίβεια ταξινομητή (άξονας y) και αντίστοιχη καθυστέρηση (άξονας x) για τη διάκριση ακροατών NH και HI χρησιμοποιώντας πλάτη πηγής από το ολόκληρο εγκεφάλου (μπλε τρίγωνο) και LH (πορτοκαλί τετράγωνο) έναντι RH (πράσινος κύκλος) χωριστά. (A) Σαφείς απαντήσεις ομιλίας. (B) Αποκρίσεις ομιλίας με υποβάθμιση του θορύβου.

Πιο πρόσφατα, το έτος 2020, οι ερευνητές ανέπτυξαν ένα στρατηγικό υπολογιστικό πλαίσιο για τη διαφοροποίηση μεταξύ πληθυσμών κανονικής ακοής και πληθυσμών με προβλήματα ακοής με βάση την ανάλυση χαρακτηριστικών της φασματικής πηγής μεταξύ των ηλικιωμένων [62]. Πέντε ζώνες συχνοτήτων που δημιουργήθηκαν από τον ανθρώπινο εγκέφαλο κατά τη διάρκεια της διαδικασίας ακοής εξήχθησαν και υποβλήθηκαν σε τρεις επιλεγμένους ταξινομητές, και συγκεκριμένα: SVM, KNN και AdaBoost για να ταξινομηθούν οι ομάδες δοκιμής ανάλογα σε παραλλαγμένη ακουστική κατάσταση. Τα δεδομένα ολόκληρου του εγκεφάλου χρησιμοποιήθηκαν για την αξιολόγηση της απόδοσης του ταξινομητή, όπου συγκεκριμένα δεδομένα ημισφαιρίου προσδιορίστηκαν ως η καλύτερη περιοχή πρόβλεψης ενδιαφέροντος. Τα αποδιδόμενα αποτελέσματα σε συνδυασμένα φασματικά χαρακτηριστικά έδειξαν ότι ο ταξινομητής SVM παρουσίασε την καλύτερη απόδοση ακρίβειας ξεπερνώντας τον ταξινομητή KNN και AdaBoost. Υπό καθαρές συνθήκες, το SVM ανέφερε ακρίβεια 94,90% σε σύγκριση με το KNN στο 93,56% και το AdaBoost στο 90,08%, ενώ για συνθήκες που προκαλούνται από θόρυβο, το SVM πέτυχε ακρίβεια 92,52% σε σύγκριση με 92,16% και 84,48% για KNN και AdaBoost class αντίστοιχα. Η μελέτη επιβεβαίωσε ότι η ζώνη γάμμα συχνοτήτων EEG θα μπορούσε να αντιμετωπίσει με επιτυχία τη μέγιστη ομαδική ταξινόμηση μεταξύ φυσιολογικής ακοής και ατόμων με προβλήματα ακοής και είναι πολύ ισχυρή στην περιοχή απόκρισης του αριστερού ημισφαιρίου του εγκεφάλου σε σύγκριση με το δεξί ημισφαίριο.

Αυτό που ώθησε την ερευνητική κοινότητα να χρησιμοποιήσει, να εξετάσει αλλά και να εφαρμόσει διαφορετικές αλγοριθμικές προσεγγίσεις σε διάφορες εργασίες ταξινόμησης, ήταν η εισαγωγή της βαθιάς μάθησης. Σχετικά πρόσφατα, οι Richard and Robert(2019) [85] βασίστηκαν στην χρήση ενός μονοδιάστατου Συνελκτικού Νευρωνικού Δικτύου (CNN) έχοντας ως στόχο να ταξινομήσουν τις αποκρίσεις ABR είτε παρούσες είτε απύσες είτε ασαφείς. Σε σχέση αλλά και σύγκριση με προηγούμενες μελέτες, τα ευρήματα υποδεικνύουν ότι μια εργασία ταξινόμησης θα μπορούσε να ολοκληρωθεί και να στεφθεί με επιτυχία με λογική ακρίβεια χωρίς την ανάγκη εξαγωγής χαρακτηριστικών σε κυματομορφές. Δυστυχώς όμως, ο όγκος δεδομένων κυματομορφής είναι τόσο σπάνιος, που εμποδίζει τη χρήση τέτοιου είδους προσεγγίσεων βαθιάς μάθησης σε παρόμοιες εργασίες ταξινόμησης.

Μια περίληψη της βιβλιογραφίας που χρησιμοποιείται σε αυτήν την ενότητα περιλαμβάνεται στον Πίνακα 1. Πρέπει να σημειωθεί ότι παρατίθενται και εξετάζονται μόνο τα άρθρα που έχουν εφαρμόσει εκτενώς τεχνικές μηχανικής εκμάθησης στην ανάλυση κυματομορφής ABR. Παρόλο που η πλειονότητα των προηγούμενων μελετών είχε ως βασικό στόχο την χρήση αυτοματοποιημένων μηχανικών λύσεων για την ανίχνευση της παρουσίας ή απουσίας ενός ABR για την εκτίμηση των ορίων ακοής, η αλήθεια είναι πως υπάρχουν περιορισμένες έως ελάχιστες έρευνες που εστιάζουν στην ταξινόμηση των κυματομορφών με βάση τις μη φυσιολογικές κλινικές μορφολογίες τους [72],[71].

Πίνακας 1 Τεχνικές μηχανικής εκμάθησης στην ανάλυση κυματομορφής ABR

Paper	Διαδικασία ταξινόμησης	Σύνολο δεδομένων		Τεχνικές Machine Learning		Αποτελέσματα			Σκοπός
		Άτομα	Κυματομορφές	Χαρακτηριστικά	Αλγόριθμοι	Ακρίβεια	Ευαισθησία	Ειδικότητα	
[85]	Response vs no-response	8	232		CNN	92.9	92.9	96.4	Ακουμετρική εκτίμηση κατωφλίου
[72]	Healthy vs pathological	43	83	Symbolic Pattern Discovery	X-means clustering	99.4	97.6	100	Ανίχνευση μη φυσιολογικής κυματομορφής
[71]	Healthy vs pathological	130	130	DWT	SVM	92	85	96	Ανίχνευση μη φυσιολογικής κυματομορφής
[73]	Response vs no-response	85	550	DWT	Naïve Bayes, SVM, NN, K-star	83.4	93.1	86.3	Ακουμετρική εκτίμηση κατωφλίου
[70]	Response vs no-response	81	320	DWT	NN	R 92.4 NR 77.06 w.o.V 80.47			Ακουμετρική εκτίμηση κατωφλίου

[86]	Response vs no-response	85	550	Χαρακτηριστικά τομέα χρόνου και τομέα συχνότητας	NN, Decision Trees	95.6			Ακοομετρική εκτίμηση κατοφλίου
[87]	Response vs no-response	8	314	DWT	Bayesian network	84,17			Ακοομετρική εκτίμηση κατοφλίου
[68]	Response vs no-response	8	172	DWT	Bayesian network	Results on 64 averaged ABR (test) = 77 Results on 128 averaged ABR (test) = 80			Ακοομετρική εκτίμηση κατοφλίου
[67]	Response vs no-response	8	285		NN	Κανονική True+ve True-ve False+ve False-ve	Κλίμακα 65,4 9,4 9,7 15,4	60.7 11.7 7.5 20.1	Ακοομετρική εκτίμηση κατοφλίου
[69]	Response vs no-response	24	648	Τιμές πλάτους, συντελεστές μετασχηματισμού συνημίτονου και συντελεστές DWT	SVM and NN	F1 93.8 F2 97.7 F3 96.2	95.3 99.2 96.2	84.6 94 90.4	Ακοομετρική εκτίμηση κατοφλίου

[74]	Response vs no-response	8		Χαρακτηριστικά τομέα χρόνου και τομέα συχνότητας	MLPNN, ELN	MLPNN 65.6 84.3 99.6 100 ELN 81.3 100 99.3 79.3	Levinson-Durbin AR Burg PSD-Yule SR Levinson-Durbin AR Burg PSD-Yule SR	65.6 84.3 99.6 100 81.3 100 99.3 79.3	Ακρομετρική εκτίμηση κατοφλίου
[75]	Normal hearing vs abnormal hearing	9		Χαρακτηριστικά φασματικής ισχύος και φασματικής εντροπίας των ρυθμών γάμμα	MLPNN, ELN	MLPNN 94.45 96.75 92.29 93.45 ELN 90.32 92.45 88.97 90.74	PSGB19 - L PSGB19 - R SEGB19 - L SEGB19 - R PSGB19 - L PSGB19 - R SEGB19 - L SEGB19 - R	Levinson-Durbin AR Burg PSD-Yule SR Levinson-Durbin AR Burg PSD-Yule	

[76]	Normal hearing vs abnormal hearing	14		Χαρακτηριστικά Higuchi fractal.	MLPNN, ELN	MLPNN	79.99 Fractal Dimension at 8000 Hz – L 82.78 Fractal Dimension at 8000 Hz- R ELN 77.14 Fractal Dimension at 8000 Hz – L 78.54 Fractal Dimension at 8000 Hz - R		Διάκριση διαφορετικών επιπέδων ακουστικής αντίληψης με βάση το σύστημα αξιολόγησης επιπέδου ακουστικής ικανότητας
[77]	Response vs no-response	8		Χαρακτηριστικά τομέα χρόνου και τομέα συχνότητας	LDA	88.33 70.83 59.58	Whole brain data – transient onset response EFR FFR		Ταξινόμηση του επιπέδου ομιλίας με τα εκ δοθέντα αγγλικά φωνήεντα χρησιμοποιώντας χαρακτηριστικά παροδικής απόκρισης έναρξης

[78]	Normal hearing vs abnormal hearing	25		Spectral features; FFR	GBDT	NA	NA	NA	Ταξινόμηση ερεθισμάτων φωνηέντων με βάση FFR που προκαλούνται από ομιλία μίας δοκιμής
[79]	Normal hearing vs abnormal hearing	27		Kolmogorov-Sinai entropy, Sample Entropy and Approximate Entropy – NH AND SNHL	KNN, SVM, LDA	87.91 90 86.66 82.14 84.52 82.73	KNN SVM LDA KNN SVM LDA		Ταξινόμηση της ανθρώπινης εθνότητας με βάση το σήμα απόκρισης του AEP μετά από παρουσίαση ερεθίσματος και ελεγμένο σε διαφορετικές ακουστικές ικανότητες
[83]	Response vs no-response	32		Multivariate source analysis, sliding window AEP	SVM	82.03 SVM 78.39 SVM	Whole brain (clear condition) Whole brain (noise condition)		Ταξινόμηση της ικανότητας ακοής που σχετίζεται με την ηλικία με βάση την ανάλυση φασματικής πηγής σε διαφορετικό ακουστικό περιβάλλον (συνθήκη καθαρού έναντι θορύβου)
[84]	NH vs HI	32		Multivariate source analysis, sliding window AEP	SVM	81.50 SVM 78.12 SVM	Whole brain (clear condition) Whole brain (noise condition)		Κατηγοριοποίηση της ακουστικής ικανότητας στην αντίληψη ομιλίας των ηλικιωμένων σε διαφορετικό ακουστικό περιβάλλον (κατάσταση καθαρού έναντι θορύβου)

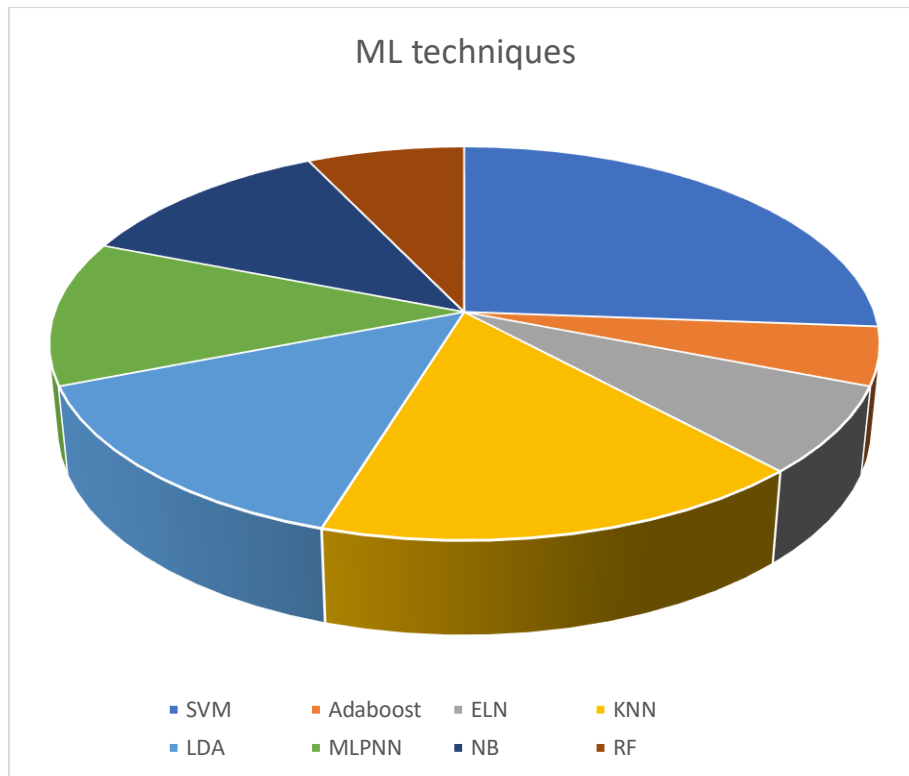
[62]	NH vs HI	32		Spectral features; PSD all band	SVM, KNN, Adaboost	94.9 SVM 93.56 KNN 90.08 AdaBoost	Spectral features; PSD all band (Whole-brain) – Clear		Ταξινόμηση της ικανότητας ακοής στην αντίληψη ομιλίας των ηλικιωμένων σύμφωνα με την ανάλυση φασματικών χαρακτηριστικών σε διαφορετικό ακουστικό περιβάλλον (κατάσταση καθαρού έναντι θορύβου)
						92.52 SVM 92.16 KNN 84.48 AdaBoost	Spectral features; PSD all band (Whole-brain) - Noise		

4. Συζήτηση και συμπεράσματα

4.1. Κύρια ευρήματα

Η παρούσα ανασκόπηση εξέτασε τα επιστημονικά στοιχεία για πολλά συγκριτικά μοντέλα μηχανικής μάθησης αιχμής που αυτοματοποιούν αξιόπιστα την αξιολόγηση της ακουστικής διαδικασίας με βάση την επεξεργασία σήματος προκληθέντος EEG. Έτσι, η ύπαρξη ενός μηχανισμού αυτοματισμού μειώνει έμμεσα τις ελλείψεις που σχετίζονται με την υποκειμενική επαγγελματική ερμηνεία με υποσχόμενη θετική μετατροπή σε κλινική πράξη. Το σήμα EEG συλλαμβάνεται από τη δραστηριότητα του ηλεκτρικού δυναμικού κατά μήκος του τριχωτού της κεφαλής, που παράγεται από τον εγκέφαλο ως απόκριση σε μια συνεχιζόμενη αυθόρμητη εργασία επεξεργασίας. Αυτό το μη επεμβατικό σήμα είναι γνωστό ότι είναι μη στάσιμη κυματομορφή που παράγεται ως απόκριση σε παραλλαγές κλειδώματος χρόνου χιλιοστού του δευτερολέπτου. Από τότε, υπάρχει αυξανόμενο ενδιαφέρον για την ενίσχυση της ακρίβειας της ερμηνείας του σήματος EEG στον εντοπισμό συγκεκριμένων αποκρίσεων εργασίας χρησιμοποιώντας την αντικειμενική νευρωνική αναπαράστασή του. Μέχρι σήμερα, η μηχανική μάθηση φαίνεται να είναι ένα αδιαμφισβήτητο εργαλείο που έχει υιοθετηθεί παγκοσμίως στον τομέα της υγειονομικής περίθαλψης για την ελαχιστοποίηση των προκλήσεων στον ερευνητικό τομέα του ΗΕΓ [60],[88]. Η επαναληπτική αρχή του ταξινομητή μηχανικής μάθησης είναι ζωτικής σημασίας, επειδή αυτός ο υπολογιστικός αλγόριθμος ανακτά νέα δεδομένα, τα αναλύει και τα μαθαίνει, εκπαιδεύεται με βάση την ανάλυση προτύπων και προσαρμόζεται ανεξάρτητα για να κάνει μια επιθυμητή μελλοντική πρόβλεψη με επαναληψιμότητα απόφασης. Η ακρίβεια του μοντέλου αναμένεται να βελτιώνεται συνεχώς με τη βελτίωση του αλγορίθμου και την κλιμάκωση του όγκου των κλινικών δεδομένων που είναι εφικτά στο πλαίσιο της υγειονομικής περίθαλψης [56],[88]. Αρκετοί τομείς κλινικών διαγνωστικών ασθενειών έχουν δείξει σημαντική συμβολή του ακουστικού προκληθέντος δυναμικού (ΑΕΡ) χρησιμοποιώντας την ταξινόμηση μηχανικής μάθησης. Για παράδειγμα, διάφορα χαρακτηριστικά εντροπίας εξήχθησαν από το σήμα του εγκεφάλου ΑΕΡ κατά την εκτέλεση της διαδικασίας ταξινόμησης της επιληψίας [80], καθώς και της ποιότητας του ύπνου [65]. Σε άλλη μελέτη που σχετίζεται με τον αυτισμό, το σήμα ΑΕΡ διέκρινε επιτυχώς τον κίνδυνο μεταξύ των βρεφών που χρησιμοποιούν μηχανική μάθηση [89]. Η ανασκόπησή μας ανέπτυξε στρατηγικές για την επιλογή των κυρίαρχων τεχνικών

μηχανικής εκμάθησης με βάση τις μεταβλητές που διερευνήθηκαν και τις ιδιότητες δεδομένων. Η ανασκόπησή μας υπογραμμίζει την ανάγκη παροχής νέων συλλογικών άρθρων που εφαρμόζουν την επεξεργασία σήματος AEP και τα εξαγόμενα χαρακτηριστικά ως είσοδο για διαφορετικές τεχνικές μηχανικής μάθησης ειδικά στον τομέα της ακουστικής αξιολόγησης. Με τον τεράστιο αριθμό αυτοματοποιημένων υπολογιστικών αλγορίθμων που είναι διαθέσιμοι για άμεση επεξεργασία, τείνουν να διαφέρουν μεταξύ τους ως προς την πολυπλοκότητα, την ευελιξία, την απόδοση και την ταχύτητα επεξεργασίας αλγορίθμων [54], [60], [90]. Οι προτεινόμενοι ταξινομητές που χρησιμοποιούνται από τα συμπεριλαμβανόμενα άρθρα και η κατάταξη απόδοσης και η αξιοπιστία του αλγορίθμου κατά την επεξεργασία των επιθυμητών εξαγωγών χαρακτηριστικών παρουσιάζονται στον Πίνακα 1. Συνολικά, υπάρχουν περίπου οκτώ μοντέλα υπολογιστικής μηχανικής μάθησης που χρησιμοποιούνται στην τοποθεσία ακουστικής αξιολόγησης ΑΠΔ. Το Σχ. 8 αντιπροσωπεύει τα δεδομένα διανομής των τεχνικών μηχανικής εκμάθησης που χρησιμοποιούνται στην παρούσα ανασκόπηση. Η SVM αυξήθηκε ως η πιο δημοφιλής τεχνική στη διαδικασία ταξινόμησης ($n = 11$) με συνολική μέση ακρίβεια 87,13%. Από την άλλη πλευρά, το KNN έδειξε την υψηλότερη μέση ακρίβεια που αναφέρθηκε στο 88,50% και έγινε η δεύτερη πιο προτιμώμενη τεχνική μηχανικής μάθησης ($n = 7$). Ο LDA ήταν ο επόμενος πιο δημοφιλής ταξινομητής μετά τον SVM και τον LDA ($n = 6$) με τη συνολική μέση ακρίβεια στο 84,83%. Η κατανομή του γραφήματος συνοψίζει ότι τα SVM, KNN και LDA ήταν οι τρεις πρώτες τεχνικές που χρησιμοποιήθηκαν ευρέως στον τομέα της ακουστικής αξιολόγησης, ειδικά κατά την εξαγωγή των ενδιαφερομένων χαρακτηριστικών από την απόκριση σήματος ΑΠΔ. Ωστόσο, κάθε μηχανική μάθηση είχε τη δική της μοναδική υπολογιστική πολυπλοκότητα με βάση τα επιλεγμένα χαρακτηριστικά εισόδου κάθε μελέτης και αυτό θα πρέπει να λαμβάνεται κυρίως υπόψη σε οποιοδήποτε μελλοντικές εφαρμογές.



Εικόνα 17 Διάγραμμα πίτας που δείχνει την κατανομή των παραδειγμάτων μηχανικής μάθησης στις συμπεριλαμβανόμενες μελέτες. Κάθε τομέας του γραφήματος πίτας επισημαίνεται με βάση τις τεχνικές μηχανικής εκμάθησης (τις αντίστοιχες τεχνικές μηχανικής μάθησης), τον αριθμό μετρήσεων (συνολικό πλήθος αντίστοιχης μηχανικής μάθησης) και το μέσο ποσοστό ακρίβειας (συνολική μέση ακρίβεια αντίστοιχων τεχνικών μηχανικής μάθησης).

Με βάση τη συνολική βαθμολογία ακρίβειας, μία από τις μελέτες απέδειξε ότι η NB είναι ένας από τους πιο επιλεκτικούς ικανούς ταξινομητές στον διαχωρισμό ομάδων ικανότητας ακοής χρησιμοποιώντας εισόδου αναλογίας ισχύος [73]. Η περιττή προκαθορισμένη παράμετρος και ο αριθμός των διαθέσιμων συνόλων δεδομένων θα μπορούσαν να είναι η αιτία της υπεροχής. Ωστόσο, ο συνδυασμός διαφορετικών ταξινομητών για τη συσχέτιση μη ορατών δεδομένων στην ανάλυση, ειδικά για την αποφυγή εσφαλμένης ταξινόμησης εισόδου μεμονωμένης απόκρισης, θα ήταν μια καλή στρατηγική. Η χρήση της ανάλυσης μηχανικής μάθησης σε νεογέννητα βρέφη βρέθηκε συχνά στη βιβλιογραφία [89],[91],[92]. Για να μετριαστούν οι ευαίσθητες προκλήσεις στην αποτελεσματικότητα της ακουστικής αξιολόγησης νεογνών, οι λειτουργίες χρόνου-συχνότητας που χρησιμοποιούν τεχνικές μηχανικής μάθησης θα μπορούσαν να ενημερώσουν την υποκείμενη γνώση. Με βάση την αναφερόμενη μελέτη, το χαρακτηριστικό PSD-Yule φαινόταν να είναι συνεπές και σταθερό στη διάκριση των συνθηκών ερεθίσματος και μη διέγερσης[74]. Αυτό το χαρακτηριστικό

εμφανίστηκε περισσότερο από 99% και στους ταξινομητές MLPNN και ELN με ελάχιστες εγγραφές ανταλλαγής. Το χαρακτηριστικό SR έδειξε ότι η διακύμανση συμβατότητας μεταξύ των δύο ταξινομητών θα μπορούσε να επηρεαστεί από τη σύγκλιση δικτύου μεταξύ των μοντέλων. Αυτή η πολύτιμη ιδέα θα μπορούσε να υιοθετηθεί με ασφάλεια στη μελέτη της ταξινόμησης απόκρισης της ανίχνευσης ερεθισμάτων μεταξύ αυτού του νεογνικού πληθυσμού. Κατά τη μέτρηση της δυναμικής διακριτικής προσέγγισης, η βαθμολογία του δείκτη ταξινόμησης του εύρους ζώνης συχνότητας γάμμα θα μπορούσε να ενισχύσει την πρακτικότητά της μεταξύ των συνθηκών κατάστασης ακοής. Μια μελέτη για τη ζώνη γάμμα EEG έδειξε ότι το φασματικό χαρακτηριστικό ισχύος αποδείχθηκε ότι είναι το χαρακτηριστικό γνώρισμα που ξεχωρίζει σε σύγκριση με τον δείκτη φασματικής εντροπίας παρά την όψη του αυτιού και στους ταξινομητές MLPNN και ELN. Παρατηρήθηκε ότι ήταν πιο κατατοπιστικό και ήταν σε θέση να ενισχύσει καλύτερα τον διαχωρισμό στο δεξιό αυτί [75]. Αυτή η εργασία είναι σε συμφωνία με την εργασία του Paulraj, Subramaniam [76], ο οποίος υποστήριξε ότι υψηλότερες ακρίβειες ταξινόμησης τείνουν να παρατηρούνται πιο έντονα στο δεξιό αυτί κατά τη διάκριση της εργασίας απόκρισης ακοής σε διάφορα επίπεδα συχνοτήτων. Η διαφορετική απόδοση ταξινόμησης δυνητικά αντιμετωπίζει την ανισορροπία νευρωνικής απόκρισης μεταξύ των χρονικών καθεστώτων για την παροχή επιπέδων ακουστικής αντίληψης. Ως εκ τούτου, περαιτέρω έρευνα θα πρέπει να επικεντρωθεί βαθύτερα στην άγνωστη ασύμμετρη απόκριση στα δεξιά αυτιά που εμπλέκονται ενεργά στην ακουστική αντίληψη σε σύγκριση με τα αριστερά αυτιά.

4.2. Προκλήσεις και λύσεις

Η πρόκληση για την κατανόηση του τρόπου με τον οποίο ο εγκέφαλος επεξεργάζεται το σήμα ομιλίας είναι μια πολύπλοκη διαγνωστική εργασία. Στα τέλη της δεκαετίας του 2010, οι ερευνητές κατέδειξαν φυσικά παραγόμενα σήματα ομιλίας για να καλύψουν το κενό στην επεξεργασία ομιλίας του εγκεφάλου υψηλότερου επιπέδου [93],[94], [95]. Σύμφωνα με τον κύριο στόχο, μια άλλη εκτεταμένη εργασία που χρησιμοποιεί μεταδιδόμενα σήματα ομιλίας έγινε από τον Sadeghian, και τους συνεργάτες του [77]. Ανέφεραν ότι ο ταξινομητής LDA υπολογίστηκε καλύτερα κάτω από όλα τα μεταβατικά δεδομένα έναρξης σε σύγκριση με το σύνολο δεδομένων δοκιμής EFR και FFR, πιθανώς επειδή ολόκληρο το σύνολο δεδομένων δεν έπασχε από

περιορισμένη φωνητική ιδιότητα με μεγαλύτερη συλλογή χαρακτηριστικών μεγέθους. Συγκεκριμένα, οι συχνότητες σχηματισμού των φωνέντων θεωρήθηκε ότι είναι η προέλευση των κριτηρίων διάκρισης ομιλίας και αντίληψης στην εργασία ταξινόμησης EFR από τη μηχανική μάθηση. Χρησιμοποιώντας μια παρόμοια απόκριση χαρακτηριστικών FFR, οι ερευνητές επαλήθευσαν την κωδικοποίηση προσοχής που εξαρτάται από ένα φασματικό προφίλ μίας δοκιμής μέσω της χρήσης ενός ταξινομητή GBDT [78]. Η ιδέα αρχικά ήταν να προβλεφθεί η συμβολή της μηχανικής μάθησης στη διάκριση φωνέντων χρησιμοποιώντας ένα FFR που προκαλείται από μία δοκιμή. Σημαντικά πλεονεκτήματα θα ήταν ο εντοπισμός της περιττής ενεργητικής προσοχής μεταξύ των συμμετεχόντων κατά τη διάρκεια της εργασίας διάκρισης. Εκτός από αυτό, παρουσίασε την αξιοπιστία της καινοτόμου απόκρισης μιας δοκιμής στην εκτέλεση εργασιών ταξινόμησης, προωθώντας την ευελιξία στην πειραματική ρύθμιση και μειώνοντας τη νευρωνική μεταβλητότητα μεταξύ των δοκιμών. Είναι σημαντικό να σημειωθεί ότι η απόκριση FFR θα επηρεαζόταν σε μεγάλο βαθμό από οποιαδήποτε απόκλιση από την επιθυμητή κατάσταση προσοχής [96], [97]. Δυστυχώς, αυτή η εργασία δεν έδειξε τη στατιστική ακρίβεια του προτεινόμενου αλγορίθμου και οποιαδήποτε κρίση για την αποτελεσματικότητά του θα ήταν αμφισβητήσιμη. Για τη δημιουργία μιας νέας λεωφόρου, συνιστάται η επόμενη προσπάθεια να περιλαμβάνει πιο ολοκληρωμένα ηχητικά σήματα ομιλίας με συγκρίσιμες υπολογιστικές τεχνικές για την επίλυση του προβλήματος βελτιστοποίησης χρησιμοποιώντας FFR μίας δοκιμής. Μερικές πιο πρόσφατες εργασίες σε αυτόν τον τομέα ανέπτυξαν λεπτομερή ταξινόμηση με βάση την εθνικότητα, την ικανότητα ακοής και το διακριτικό ακουστικό ερέθισμα [62],[79],[84]. Η διαδικασία ταξινόμησης μεταξύ εθνότητας αναφέρθηκε σπάνια στη βιβλιογραφία και θα πρέπει να συνεχίσει να διαφωτίζει τον περιορισμό που υπάρχει λαμβάνοντας υπόψη τη γλωσσική μνήμη και τη φωνητική αντίχρεωση μεταξύ εθνότητας με αξιόπιστο μέγεθος δείγματος [93],[98]. Για την επίλυση της κακής αντίληψης ομιλίας κατά την καθημερινή επικοινωνία μεταξύ των χρηστών απώλειας ακοής και ακουστικών βαρηκοΐας, η ερευνητική εργασία που έγινε από τον Mahmud, Ahmed [84] θα μπορούσε να δημιουργήσει θετική εικόνα για την κατανόηση της ειδικής για τον εγκέφαλο επεξεργασίας. Επιπλέον, ο παράγοντας που σχετίζεται με την ηλικία υποδείχθηκε στην εργασία για περαιτέρω κατανόηση. Ένα από τα σημαντικά ευρήματα είναι ότι η μελέτη κατάφερε να προτείνει μια ισχυρή μηχανική μάθηση στην εκτέλεση της εργασίας ταξινόμησης μεταξύ διαφορετικών φωνολογικών σημάτων ομιλίας. Συλλογικά, η καθυστέρηση ταξινόμησης μεταξύ του ηλικιωμένου

πληθυσμού θα παρείχε μεγάλη κατανόηση της δυσκολίας του εγκεφάλου στο διαχωρισμό πολλών ιδιοτήτων ομιλίας σε νευρωνικό επίπεδο, γεγονός που μπορεί να υποδηλώνει τεράστια γνωστικά ελλείμματα. Ένας άλλος πολλά υποσχόμενος τομέας ταξινόμησης της ικανότητας ακοής με χρήση μηχανικής μάθησης καταδείχθηκε με τον υπολογισμό των φασματικών χαρακτηριστικών της δραστηριότητας EEG [62]. Η ζώνη γάμμα ήταν η καλύτερη ζώνη συχνοτήτων για την ταξινόμηση της απόκρισης ικανότητας ακοής. Μέχρι σήμερα, αυτές οι έρευνες έχουν προσδώσει μια καλύτερη άποψη για τα συστήματα που χρησιμοποιούν ταξινόμηση εγκεφαλικών σημάτων για βελτίωση. Συμπερασματικά, η παρούσα βιβλιογραφική μας μελέτη εξέτασε αρκετά υπολογιστικά μοντέλα μηχανικής μάθησης στην πρακτική της ακουστικής αξιολόγησης. Διάφορα χαρακτηριστικά της εξαγωγής θα μπορούσαν να παρέχουν σημαντικές πληροφορίες από την ηλεκτροφυσιολογική δραστηριότητα του εγκεφάλου και ο εντοπισμός της καλύτερης μηχανικής μάθησης που θα μπορούσε να ταιριάζει καλά με τις μεταβλητές εισόδου είναι πολύ σχετικός. Ουσιαστικά, αυτή η ανασκόπηση συζήτησε τις διαφορετικές τεχνικές μηχανικής εκμάθησης που αποδείχθηκαν χρήσιμες και περιέγραψε τα μειονεκτήματα που εξαρτώνται από τις υπό διερεύνηση μεταβλητές δεδομένων. Σε μια ευρύτερη άποψη, το SVM θα μπορούσε να θεωρηθεί ως το καλύτερο μοντέλο για την ακουστική αξιολόγηση με βάση τον ανταποκρινόμενο αλγόριθμό του με ακρίβεια άνω του 80% σε σύγκριση με όλα τα πειραματικά παραδείγματα, και χρησιμοποιήθηκε στην πλειονότητα των μελετών. Οδηγώντας σε πιο καινοτόμες διαδικασίες αυτοματοποίησης, ο συνδυασμός δύο ή περισσότερων αλγορίθμων μηχανικής μάθησης φάνηκε να είναι μια πολύτιμη ανακάλυψη. Αυτή η ιδέα προσέφερε πολυτροπικούς αλγόριθμους συναρμολογώντας μοναδικά χαρακτηριστικά κάθε μεθόδου στην επεξεργασία του σήματος. Ωστόσο, αυτή η ανάλυση θα αύξανε την πολυπλοκότητα του αλγορίθμου και η μέτρηση της απόδοσης ακρίβειας θα ήταν μια σημαντική δυσκολία. Από όσο γνωρίζουμε, δεν έχουν ακόμη αναφερθεί αποδεδειγμένες συνδυασμένες τεχνικές που είναι διαθέσιμες για ακουστική αξιολόγηση. Ωστόσο, μια διάσημη ομάδα επιστημόνων διερεύνησε τις δυνατότητες και απέδειξε την αποτελεσματικότητα των συνδυασμένων τεχνικών μηχανικής μάθησης σε μια άλλη κλινική λειτουργία, όπως η σκλήρυνση κατά πλάκας [99]. Συνιστάται οι μελλοντικές προσπάθειες στις ακουστικές αξιολογήσεις να εξετάζουν το αποτέλεσμα της συνδυαστικής μεθόδου. Με αυτά τα ευρήματα, θα μπορούσε να επιτευχθεί η αποτελεσματικότητα και η βελτίωση της αυτοματοποιημένης ακουστικής αξιολόγησης

στην αντιμετώπιση των προκλήσεων της πραγματικής ζωής μεταξύ του πληθυσμού με απώλεια ακοής.

5 Συμπεράσματα και μελλοντικές αναφορές

Συμπερασματικά, η παρούσα βιβλιογραφική μας μελέτη εξέτασε αρκετά υπολογιστικά μοντέλα μηχανικής μάθησης στην πρακτική της ακουστικής αξιολόγησης. Διάφορα χαρακτηριστικά της εξαγωγής θα μπορούσαν να παρέχουν σημαντικές πληροφορίες από την ηλεκτροφυσιολογική δραστηριότητα του εγκεφάλου και ο εντοπισμός της καλύτερης μηχανικής μάθησης που θα μπορούσε να ταιριάζει καλά με τις μεταβλητές εισόδου είναι πολύ σχετικός. Ουσιαστικά, αυτή η ανασκόπηση συζήτησε τις διαφορετικές τεχνικές μηχανικής εκμάθησης που αποδείχθηκαν χρήσιμες και περιέγραψε τα μειονεκτήματα που εξαρτώνται από τις υπό διερεύνηση μεταβλητές δεδομένων. Με μια ευρύτερη άποψη, το SVM θα μπορούσε να θεωρηθεί ως το καλύτερο μοντέλο για την ακουστική αξιολόγηση με βάση τον ανταποκρινόμενο αλγόριθμό του με ακρίβεια άνω του 80% σε σύγκριση με όλα τα πειραματικά παραδείγματα, και χρησιμοποιήθηκε στην πλειονότητα των μελετών. Οδηγώντας σε πιο καινοτόμες διαδικασίες αυτοματοποίησης, ο συνδυασμός δύο ή περισσότερων αλγορίθμων μηχανικής μάθησης φάνηκε να είναι μια πολύτιμη ανακάλυψη. Αυτή η ιδέα προσέφερε πολυτροπικούς αλγόριθμους συναρμολογώντας μοναδικά χαρακτηριστικά κάθε μεθόδου στην επεξεργασία του σήματος. Ωστόσο, αυτή η ανάλυση θα αύξανε την πολυπλοκότητα του αλγορίθμου και η μέτρηση της απόδοσης ακρίβειας θα ήταν σημαντικά δύσκολη. Από όσο γνωρίζουμε, δεν έχουν ακόμη αναφερθεί αποδεδειγμένες συνδυασμένες τεχνικές που είναι διαθέσιμες για ακουστική αξιολόγηση. Ωστόσο, μια διάσημη ομάδα επιστημόνων διερεύνησε τις δυνατότητες και απέδειξε την αποτελεσματικότητα των συνδυασμένων τεχνικών μηχανικής μάθησης σε μια άλλη κλινική λειτουργία, όπως η σκλήρυνση κατά πλάκας [69]. Συνιστάται οι μελλοντικές προσπάθειες στις ακουστικές αξιολογήσεις να εξετάζουν το αποτέλεσμα της συνδυαστικής μεθόδου. Με αυτά τα ευρήματα, θα μπορούσε να επιτευχθεί η αποτελεσματικότητα και η βελτίωση της αυτοματοποιημένης ακουστικής αξιολόγησης στην αντιμετώπιση των προκλήσεων της πραγματικής ζωής μεταξύ του πληθυσμού με απώλεια ακοής.

5.1 Μελλοντικές έρευνες

Πρώτον, οι μελλοντικές μελέτες θα πρέπει να έχουν μεγαλύτερο μέγεθος δείγματος και να επωφελούνται από σύγχρονους ταξινομητές βαθιάς μάθησης όπως το CNN ή να συνδυάζουν το CNN με παραδοσιακούς ταξινομητές σε ένα σύνολο ή να δημιουργούν μια αρχιτεκτονική καταρράκτη. Οι περισσότερες από τις μελέτες που περιλαμβάνονται σε αυτήν την ανασκόπηση ανέφεραν δυσκολίες στην επίτευξη μεγάλου μεγέθους δείγματος. Αυτός ο περιορισμός θα μπορούσε να αμβλυνθεί με τη δημοσιοποίηση των δεδομένων ΑΠΔΕΣ, έτσι ώστε άλλοι να μπορούν να τα χρησιμοποιήσουν ή/και να τα συνδυάσουν με πρόσθετα δεδομένα. Επιπλέον, μελλοντικές μελέτες θα πρέπει να χρησιμοποιούν φυσικά ερεθίσματα ομιλίας που προσομοιώνονται σε θόρυβο και αντήχηση για να διασφαλίσουν ότι αναπαράγουμε πιστά τις πραγματικές συνθήκες ακρόασης. Επιπλέον, μελλοντική έρευνα θα πρέπει να εξετάσει τη δυνατότητα χρήσης μηχανικής μάθησης για τη δημιουργία συσχέτισης μεταξύ του ΑΠΔΕΣ και των ακουστικών ορίων σε διάφορους πληθυσμούς, συμπεριλαμβανομένων των παιδιών και των ηλικιωμένων με και χωρίς απώλεια ακοής, καθώς και εκείνων με και χωρίς κοχλιακά εμφυτεύματα. Οι περισσότερες από τις μελέτες που καλύπτονται σε αυτήν την ανασκόπηση περιλάμβαναν νεαρούς ενήλικες συμμετέχοντες με φυσιολογική ακοή. Για να γενικευθεί η αποτελεσματικότητα των τεχνικών μηχανικής μάθησης, χρειάζονται διαφορετικοί πληθυσμοί με διάφορους τύπους βαρηκοΐας για να εξασφαλιστεί καλή κλινική εφαρμογή και αποτελεσματικότητα.

Βιβλιογραφία-Παραπομπές

- [1] B. S. Oken and T. S. Phillips, “Evoked Potentials: Clinical,” *Encyclopedia of Neuroscience*, pp. 19–28, Jan. 2009, doi: 10.1016/B978-008045046-9.00587-8.
- [2] A. D. Legatt, “Evoked Potentials,” *Encyclopedia of the Neurological Sciences*, pp. 228–231, Jan. 2014, doi: 10.1016/B978-0-12-385157-4.00529-7.
- [3] James W. Hall, *eHandbook of Auditory Evoked Responses*.
- [4] D. L. Jewett, M. N. Romano, and J. S. Williston, “Human Auditory Evoked Potentials: Possible Brain Stem Components Detected on the Scalp,” *Science (1979)*, vol. 167, no. 3924, Mar. 1970, doi: 10.1126/science.167.3924.1517.
- [5] A. Krishnan, “Human frequency-following responses: representation of steady-state synthetic vowels,” *Hearing Research*, vol. 166, no. 1–2, pp. 192–201, Apr. 2002, doi: 10.1016/S0378-5955(02)00327-1.
- [6] E. Skoe and N. Kraus, “Auditory Brain Stem Response to Complex Sounds: A Tutorial,” *Ear & Hearing*, vol. 31, no. 3, Jun. 2010, doi: 10.1097/AUD.0b013e3181cdb272.
- [7] S. Külekcı, Ş. Terlemez, A. Çıprut, and F. Akdaş, “500Hz logon versus click ABR maturation,” *International Journal of Pediatric Otorhinolaryngology*, vol. 71, no. 5, May 2007, doi: 10.1016/j.ijporl.2007.01.016.
- [8] N. M. Talge, B. M. Tudor, and P. R. Kileny, “Click-evoked auditory brainstem responses and autism spectrum disorder: A meta-analytic review,” *Autism Research*, vol. 11, no. 6, Jun. 2018, doi: 10.1002/aur.1946.
- [9] T.-M. Lu, F.-W. Wu, H. Chang, and H.-C. Lin, “Using click-evoked auditory brainstem response thresholds in infants to estimate the corresponding pure-tone audiometry thresholds in children referred from UNHS,” *International Journal of Pediatric Otorhinolaryngology*, vol. 95, Apr. 2017, doi: 10.1016/j.ijporl.2017.02.004.
- [10] L. Xie *et al.*, “The characterization of auditory brainstem response (ABR) waveforms: A study in tree shrews (*Tupaia belangeri*),” *Journal of Otology*, vol. 13, no. 3, Sep. 2018, doi: 10.1016/j.joto.2018.05.004.
- [11] C. Chen *et al.*, “Automatic Recognition of Auditory Brainstem Response Characteristic Waveform Based on Bidirectional Long Short-Term Memory,” *Frontiers in Medicine*, vol. 7, Jan. 2021, doi: 10.3389/fmed.2020.613708.
- [12] <https://www.evokedpotential.com/the-auditory-brainstem-response.html>, “ABR.”
- [13] Geisler C, Frishkopf L, and Rosenblith W, “Extracranial Responses to Acoustic Clicks in Man,” 1958.
- [14] F. Musiek and S. Nagle, “The Middle Latency Response: A Review of Findings in Various Central Nervous System Lesions,” *J Am Acad Audiol*, vol. 29, no. 09, Oct. 2018, doi: 10.3766/jaaa.16141.
- [15] Hall J., *New Handbook of Auditory Evoked Responses*. 2007.
- [16] Musiek F and Lee W, “Auditory middle and late potentials.,” 1999.
- [17] Pratt H., “Middle-latency response,” 2007.

- [18] Picton TW., “Human Auditory Evoked Potentials,” 2011.
- [19] H. J. J. GP. Nelson MD, “Factors affecting the recordability of auditory evoked response (AER) component Pb (P1).,” 1997.
- [20] B. JS. Erwin R, “Midlatency auditory 175 evoked responses: differential effects of sleep in the human.,” 1986.
- [21] K. N. Özdamar Ö, “Auditory middle-latency responses in humans.,” 1983.
- [22] Fifer RC and Sierra-Irizarry B., “ Clinical applications of the auditory middle latency response.,” 1988.
- [23] Ponton CW, Don M, Eggermont JJ, Waring MD, and Masuda A., “Maturation of human cortical auditory function: differences between normal-hearing children and children with cochlear implants.,” 1996.
- [24] Seki H, Kimura I, Ohnuma A, Saso S, and Kogure K., “ The auditory evoked middle-latency responses (MLRs): their normative variation and generators.,” 1993.
- [25] Tucker D and Ruth R, “ Effects of age, signal level, and signal rate on the auditory middle latency response.,” 1996.
- [26] A. Δαγγύλας, “ΑΚΟΥΣΤΙΚΑ ΠΡΟΚΛΗΤΑ ΔΥΝΑΜΙΚΑ,” 1996.
- [27] M. Don and J. J. Eggermont, “Analysis of the click-evoked brainstem potentials in man using high-pass noise masking,” *J Acoust Soc Am*, vol. 63, no. 4, pp. 1084–1092, Apr. 1978, doi: 10.1121/1.381816.
- [28] “[https://www.interacoustics.com/download/eclipse/eclipse-manuals/.](https://www.interacoustics.com/download/eclipse/eclipse-manuals/)”
- [29] F. A. Boettcher, “Presbycusis and the Auditory Brainstem Response,” *Journal of Speech, Language, and Hearing Research*, vol. 45, no. 6, Dec. 2002, doi: 10.1044/1092-4388(2002/100).
- [30] G. G. Celesia, “Brainstem auditory evoked responses,” 2013. doi: 10.1016/B978-0-7020-5310-8.00007-7.
- [31] T.-M. Lu, F.-W. Wu, H. Chang, and H.-C. Lin, “Using click-evoked auditory brainstem response thresholds in infants to estimate the corresponding pure-tone audiometry thresholds in children referred from UNHS,” *International Journal of Pediatric Otorhinolaryngology*, vol. 95, Apr. 2017, doi: 10.1016/j.ijporl.2017.02.004.
- [32] Ph. D. , and W. E. N. M. D. , Ph. D. Cynthia C. Morton, “Newborn Hearing Screening — A Silent Revolution,” 2006.
- [33] I. el Khateeb, B. A. Razzak, and A. Moosa, “Auditory brainstem responses (ABR) in children with neurological disorders,” *Brain and Development*, vol. 10, no. 4, Jan. 1988, doi: 10.1016/S0387-7604(88)80005-6.
- [34] T. Moser and A. Starr, “Auditory neuropathy — neural and synaptic mechanisms,” *Nature Reviews Neurology*, vol. 12, no. 3, Mar. 2016, doi: 10.1038/nrneurol.2016.10.
- [35] A. Radeloff, M. Cebulla, and W. Shehata-Dieler, “Akustisch evozierte Potenziale: Grundlagen und klinische Anwendung,” *Laryngo-Rhino-Otologie*, vol. 93, no. 09, Aug. 2014, doi: 10.1055/s-0034-1385868.

- [36] Zarin Mehta, "Limitations of Pure-Tone Audiometry in the Detection of Nonorganic Hearing Loss: A Case Study," 2003.
- [37] P. R. Pialarissi, F. S. Almeida, L. C. B. M. Camanducaia, and J. J. Jorge, "Middle-latency auditory responses in neurological diseases," *Brazilian Journal of Otorhinolaryngology*, vol. 73, no. 4, Jul. 2007, doi: 10.1016/S1808-8694(15)30107-5.
- [38] Harker LA and Backoff P., "Middle latency electric auditory responses in patients with acoustic neuroma.," 1980.
- [39] Kraus N, Özdamar Ö, Hier D, and Stein L, "Auditory middle latency responses (MLRs) in patients with cortical lesions.," 1982.
- [40] Munjal SK, Panda NK, and Pathak A., "Audiological deficits after closed head injury.," 2010.
- [41] A. M. Turing, "Computing Machinery and Intelligence," in *Parsing the Turing Test*, Dordrecht: Springer Netherlands, 2009. doi: 10.1007/978-1-4020-6710-5_3.
- [42] <https://en.wikipedia.org/wiki/Bombe>, "Bombe."
- [43] M. L. M. N. R. και C. E. S. John McCarthy, "A proposal for the dartmouth summer research project on artificial intelligence," 1955.
- [44] Joseph Weizenbaum, "ELIZA—a computer program for the study of natural language communication between man and machine.," 1966.
- [45] A. J. H. J. και F. hsiung H. Murray Campbell, "Deep Blue.Artificial intelligence".
- [46] M. Minsky and S. A. Papert, *Perceptrons*. The MIT Press, 2017. doi: 10.7551/mitpress/11301.001.0001.
- [47] M. Haenlein and A. Kaplan, "A Brief History of Artificial Intelligence: On the Past, Present, and Future of Artificial Intelligence," *California Management Review*, vol. 61, no. 4, pp. 5–14, Aug. 2019, doi: 10.1177/0008125619864925.
- [48] C. L. Chang and R. C. T. Lee, "Problem-Solving Methods in Artificial Intelligence (Nils J. Nilsson)," *SIAM Review*, vol. 14, no. 3, Jul. 1972, doi: 10.1137/1014093.
- [49] A. L. Samuel, "Some Studies in Machine Learning Using the Game of Checkers. II—Recent Progress," *IBM Journal of Research and Development*, vol. 11, no. 6, pp. 601–617, Nov. 1967, doi: 10.1147/rd.116.0601.
- [50] D. Silver *et al.*, "Mastering Chess and Shogi by Self-Play with a General Reinforcement Learning Algorithm," Dec. 2017.
- [51] Yann LeCun, Yoshua Bengio, and Geoffrey Hinton, "Deep learning," 2015.
- [52] "<https://top6sites.com/2020/05/15/ai-vs-machine-learning-vs-deep-learning/>."
- [53] M. Zaitoun, S. Cumming, A. Purcell, and K. O'brien, "Inter and intra-reader variability in the threshold estimation of auditory brainstem response (ABR) results," *Hearing, Balance and Communication*, vol. 14, no. 1, pp. 59–63, Jan. 2016, doi: 10.3109/21695717.2016.1110957.
- [54] M.-P. Hosseini, A. Hosseini, and K. Ahi, "A Review on Machine Learning for EEG Signal Processing in Bioengineering," *IEEE Reviews in Biomedical Engineering*, vol. 14, pp. 204–218, 2021, doi: 10.1109/RBME.2020.2969915.

- [55] F. Lotte *et al.*, “A review of classification algorithms for EEG-based brain–computer interfaces: a 10 year update,” *Journal of Neural Engineering*, vol. 15, no. 3, p. 031005, Jun. 2018, doi: 10.1088/1741-2552/aab2f2.
- [56] M. Ghassemi, T. Naumann, P. Schulam, A. L. Beam, I. Y. Chen, and R. Ranganath, “A Review of Challenges and Opportunities in Machine Learning for Health,” Jun. 2018.
- [57] A. R. Abu Bakar, K. W. Lai, and N. A. Hamzaid, “The emergence of machine learning in auditory neural impairment: A systematic review,” *Neuroscience Letters*, vol. 765, Nov. 2021, doi: 10.1016/j.neulet.2021.136250.
- [58] S. Chandaka, A. Chatterjee, and S. Munshi, “Cross-correlation aided support vector machine classifier for classification of EEG signals,” *Expert Systems with Applications*, vol. 36, no. 2, pp. 1329–1336, Mar. 2009, doi: 10.1016/J.ESWA.2007.11.017.
- [59] A. Subasi and M. I. Gursoy, “EEG signal classification using PCA, ICA, LDA and support vector machines,” *Expert Systems with Applications*, vol. 37, no. 12, pp. 8659–8666, Dec. 2010, doi: 10.1016/J.ESWA.2010.06.065.
- [60] R. Pillai, P. Oza, and P. Sharma, “Review of Machine Learning Techniques in Health Care,” 2020, pp. 103–111. doi: 10.1007/978-3-030-29407-6_9.
- [61] K. V. Park *et al.*, “Machine Learning Models for Predicting Hearing Prognosis in Unilateral Idiopathic Sudden Sensorineural Hearing Loss,” *Clinical and Experimental Otorhinolaryngology*, vol. 13, no. 2, May 2020, doi: 10.21053/ceo.2019.01858.
- [62] M. S. Mahmud, F. Ahmed, M. Yeasin, and G. M. Bidelman, “Decoding Categorical Speech Perception from Evoked Brain Responses,” 2020. doi: 10.1109/TENSYP50017.2020.9230856.
- [63] T. Wuest, D. Weimer, C. Irgens, and K.-D. Thoben, “Machine learning in manufacturing: advantages, challenges, and applications,” *Production & Manufacturing Research*, vol. 4, no. 1, Jan. 2016, doi: 10.1080/21693277.2016.1192517.
- [64] W. Jia, D. Zhao, T. Shen, Y. Tang, and Y. Zhao, “Study on Optimized Elman Neural Network Classification Algorithm Based on PLS and CA,” *Computational Intelligence and Neuroscience*, vol. 2014, 2014, doi: 10.1155/2014/724317.
- [65] M. Ravan, “A machine learning approach using EEG signals to measure sleep quality,” *AIMS Electronics and Electrical Engineering*, vol. 3, no. 4, 2019, doi: 10.3934/ElectrEng.2019.4.347.
- [66] Y. Freund and R. E. Schapire, “A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting,” *Journal of Computer and System Sciences*, vol. 55, no. 1, Aug. 1997, doi: 10.1006/jcss.1997.1504.
- [67] D. Alpsan, “Classification Of Auditory Brainstem Responses By Human Experts And Backpropagation Neural Networks,” in *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society Volume 13: 1991*, pp. 1425–1426. doi: 10.1109/IEMBS.1991.684525.
- [68] Rui Zhang, G. McAllister, B. Scotney, S. McClean, and G. Houston, “Classification of the Auditory Brainstem Response (ABR) Using Wavelet Analysis and Bayesian

- Network,” in *18th IEEE Symposium on Computer-Based Medical Systems (CBMS'05)*, pp. 485–490. doi: 10.1109/CBMS.2005.41.
- [69] N. Acir, Ö. Özdamar, and C. Güzeliş, “Automatic classification of auditory brainstem responses using SVM-based feature selection algorithm for threshold detection,” *Engineering Applications of Artificial Intelligence*, vol. 19, no. 2, pp. 209–218, Mar. 2006, doi: 10.1016/J.ENGAPPAI.2005.08.004.
- [70] S. Rahbar, M. D. Abolhassani, H. Arabalibeik, and A. H. Jafari, “Auditory Brainstem Response Classification Using Wavelet Transform and Multilayer Feed-forward Networks,” in *2007 4th IEEE/EMBS International Summer School and Symposium on Medical Devices and Biosensors*, Aug. 2007, pp. 128–131. doi: 10.1109/ISSMDBS.2007.4338309.
- [71] A. Dobrowolski, M. Suchocki, K. Tomczykiewicz, and E. Majda-Zdancewicz, “Classification of auditory brainstem response using wavelet decomposition and SVM network,” *Biocybernetics and Biomedical Engineering*, vol. 36, no. 2, pp. 427–436, Jan. 2016, doi: 10.1016/J.BBE.2016.01.003.
- [72] M. E. Molina, A. Perez, and J. P. Valente, “Classification of auditory brainstem responses through symbolic pattern discovery,” *Artificial Intelligence in Medicine*, vol. 70, pp. 12–30, Jun. 2016, doi: 10.1016/J.ARTMED.2016.05.001.
- [73] H. W. H. Z. G. L. and G. M. Paul McCullagh, “A Comparison of Supervised Classification Methods for Auditory Brainstem Response Determination,” 2007.
- [74] N. Sriraam, “EEG based automated detection of auditory loss: A pilot study,” *Expert Systems with Applications*, vol. 39, no. 1, Jan. 2012, doi: 10.1016/j.eswa.2011.07.064.
- [75] P. M. Pandiyan, K. Subramaniam, Y. Sazali, Abdul Hamid, and C. R. Hema, “EEG based detection of conductive and sensorineural hearing loss using artificial neural networks,” May 2013.
- [76] M. P. Paulraj, K. Subramaniam, S. bin Yacob, A. H. bin Adom, and C. R. Hema, “A machine learning approach for distinguishing hearing perception level using auditory evoked potentials,” Dec. 2014. doi: 10.1109/IECBES.2014.7047661.
- [77] A. Sadeghian, H. R. Dajani, and A. D. C. Chan, “Classification of speech-evoked brainstem responses to English vowels,” *Speech Communication*, vol. 68, Apr. 2015, doi: 10.1016/j.specom.2015.01.003.
- [78] H. G. Yi, Z. Xie, R. Reetzke, A. G. Dimakis, and B. Chandrasekaran, “Vowel decoding from single-trial speech-evoked electrophysiological responses: A feature-based machine learning approach,” *Brain and Behavior*, vol. 7, no. 6, Jun. 2017, doi: 10.1002/brb3.665.
- [79] I. A. Ibrahim, H.-N. Ting, and M. Moghavvemi, “A Novel Approach for Classifying Native Chinese and Malay Speaking Persons According to Cortical Auditory Evoked Responses,” *The Journal of International Advanced Otolology*, vol. 15, no. 1, May 2019, doi: 10.5152/iao.2019.4553.
- [80] U. R. Acharya, S. Vinitha Sree, G. Swapna, R. J. Martis, and J. S. Suri, “Automated EEG analysis of epilepsy: A review,” *Knowledge-Based Systems*, vol. 45, Jun. 2013, doi: 10.1016/j.knosys.2013.02.014.

- [81] U. R. Acharya *et al.*, “An integrated index for detection of Sudden Cardiac Death using Discrete Wavelet Transform and nonlinear features,” *Knowledge-Based Systems*, vol. 83, Jul. 2015, doi: 10.1016/j.knosys.2015.03.015.
- [82] M. R. N. Kousarrizi, A. A. Ghanbari, M. Teshnehlab, M. A. Shorehdeli, and A. Gharaviri, “Feature Extraction and Classification of EEG Signals Using Wavelet Transform, SVM and Artificial Neural Networks for Brain Computer Interfaces,” 2009. doi: 10.1109/IJCBS.2009.100.
- [83] Mahmud M.S. *et al.*, “Decoding age-related changes in the spatiotemporal neural processing of speech using machine learning,” 2019.
- [84] M. S. Mahmud *et al.*, “Decoding Hearing-Related Changes in Older Adults’ Spatiotemporal Neural Processing of Speech Using Machine Learning,” *Frontiers in Neuroscience*, vol. 14, Jul. 2020, doi: 10.3389/fnins.2020.00748.
- [85] R. M. McKearney and R. C. MacKinnon, “Objective auditory brainstem response classification using machine learning,” *International Journal of Audiology*, vol. 58, no. 4, pp. 224–230, Apr. 2019, doi: 10.1080/14992027.2018.1551633.
- [86] R. Davey, P. McCullagh, G. Lightbody, and G. McAllister, “Auditory brainstem response classification: A hybrid model using time and frequency features,” *Artificial Intelligence in Medicine*, vol. 40, no. 1, pp. 1–14, May 2007, doi: 10.1016/J.ARTMED.2006.07.001.
- [87] R. Zhang, G. McAllister, B. Scotney, S. McClean, and G. Houston, “Combining Wavelet Analysis and Bayesian Networks for the Classification of Auditory Brainstem Response,” *IEEE Transactions on Information Technology in Biomedicine*, vol. 10, no. 3, pp. 458–467, Jul. 2006, doi: 10.1109/TITB.2005.863865.
- [88] J. Wiens and E. S. Shenoy, “Machine Learning for Healthcare: On the Verge of a Major Shift in Healthcare Epidemiology,” *Clinical Infectious Diseases*, vol. 66, no. 1, Jan. 2018, doi: 10.1093/cid/cix731.
- [89] D. Stahl, A. Pickles, M. Elsabbagh, M. H. Johnson, and The BASIS Team, “Novel Machine Learning Methods for ERP Analysis: A Validation From Research on Infants at Risk for Autism,” *Developmental Neuropsychology*, vol. 37, no. 3, Apr. 2012, doi: 10.1080/87565641.2011.650808.
- [90] K. Wolfgang, “Artificial Intelligence and Machine Learning,” *The Hearing Journal*, vol. 72, no. 3, p. 26, Mar. 2019, doi: 10.1097/01.HJ.0000554346.30951.8d.
- [91] M. Ravan, J. P. Reilly, L. J. Trainor, and A. Khodayari-Rostamabad, “A machine learning approach for distinguishing age of infants using auditory evoked potentials,” *Clinical Neurophysiology*, vol. 122, no. 11, Nov. 2011, doi: 10.1016/j.clinph.2011.04.002.
- [92] B. Boashash and S. Ouelha, “Automatic signal abnormality detection using time-frequency features and machine learning: A newborn EEG seizure case study,” *Knowledge-Based Systems*, vol. 106, pp. 38–50, Aug. 2016, doi: 10.1016/j.knosys.2016.05.027.
- [93] H. N. Ting, A. R. A Bakar, J. Santhosh, M. G. Al-Zidi, I. Amer Ibrahim, and S. C. Ng, “Effects of Speech Phonological Features during Passive Perception on Cortical Auditory Evoked Potential in Sensorineural Hearing Loss,” *Sains Malays*, vol. 46, no. 12, Jan. 2017, doi: 10.17576/jsm-2017-4612-25.

- [94] O. M. Cañete, S. C. Purdy, M. Neeff, C. R. S. Brown, and P. R. Thorne, “Cortical auditory evoked potential (CAEP) and behavioural measures of auditory function in an adult with a single sided deafness: case study,” *Hearing, Balance and Communication*, vol. 16, no. 1, pp. 64–72, Jan. 2018, doi: 10.1080/21695717.2018.1426297.
- [95] B. van Dun, H. Dillon, and M. Seeto, “Estimating Hearing Thresholds in Hearing-Impaired Adults through Objective Detection of Cortical Auditory Evoked Potentials,” *J Am Acad Audiol*, vol. 26, no. 04, pp. 370–383, Apr. 2015, doi: 10.3766/jaaa.26.4.5.
- [96] S. Losorelli, B. Kaneshiro, G. A. Musacchia, N. H. Blevins, and M. B. Fitzgerald, “Factors influencing classification of frequency following responses to speech and music stimuli,” *Hearing Research*, vol. 398, p. 108101, Dec. 2020, doi: 10.1016/j.heares.2020.108101.
- [97] A. Lehmann, D. J. Arias, and M. Schönwiesner, “Tracing the neural basis of auditory entrainment,” *Neuroscience*, vol. 337, pp. 306–314, Nov. 2016, doi: 10.1016/j.neuroscience.2016.09.011.
- [98] F. Becker and I. Reinvang, “Mismatch negativity elicited by tones and speech sounds: Changed topographical distribution in aphasia,” *Brain and Language*, vol. 100, no. 1, pp. 69–78, Jan. 2007, doi: 10.1016/j.bandl.2006.09.004.
- [99] A. Torabi, M. R. Daliri, and S. H. Sabzposhan, “Diagnosis of multiple sclerosis from EEG signals using nonlinear methods,” *Australasian Physical & Engineering Sciences in Medicine*, vol. 40, no. 4, pp. 785–797, Dec. 2017, doi: 10.1007/s13246-017-0584-9.