



ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΙΑΣ
ΣΧΟΛΗ ΘΕΤΙΚΩΝ ΕΠΙΣΤΗΜΩΝ
ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ ΜΕ ΕΦΑΡΜΟΓΕΣ
ΣΤΗ ΒΙΟΙΑΤΡΙΚΗ

**Ψηφιακό σύστημα ανίχνευσης επιληπτικών κρίσεων βασισμένο σε
TinyML**

Αικατερίνη Αντωνίου

ΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ
Υπεύθυνος
Αθανάσιος Κακαρούνας
Αναπληρωτής Καθηγητής

Λαμία, 2023



**ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΙΑΣ
ΣΧΟΛΗ ΘΕΤΙΚΩΝ ΕΠΙΣΤΗΜΩΝ
ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ ΜΕ ΕΦΑΡΜΟΓΕΣ ΣΤΗ
ΒΙΟΙΑΤΡΙΚΗ**

**Ψηφιακό σύστημα ανίχνευσης επιληπτικών κρίσεων βασισμένο σε
TinyML**

Αικατερίνη Αντωνίου

ΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ

**Επιβλέπων
Αθανάσιος Κακαρούντας
Αναπληρωτής Καθηγητής**

Λαμία, 2023

Με ατομική μου ευθύνη και γνωρίζοντας τις κυρώσεις ⁽¹⁾, που προβλέπονται από της διατάξεις της παρ. 6 του άρθρου 22 του Ν. 1599/1986, δηλώνω ότι:

1. Δεν παραθέτω κομμάτια βιβλίων ή άρθρων ή εργασιών άλλων αυτολεξεί **χωρίς να τα περικλείω σε εισαγωγικά** και χωρίς να αναφέρω το συγγραφέα, τη χρονολογία, τη σελίδα. Η αυτολεξεί παράθεση χωρίς εισαγωγικά χωρίς αναφορά στην πηγή, είναι λογοκλοπή. Πέραν της αυτολεξεί παράθεσης, λογοκλοπή θεωρείται και η παράφραση εδαφίων από έργα άλλων, συμπεριλαμβανομένων και έργων συμφοιτητών μου, καθώς και η παράθεση στοιχείων που άλλοι συνέλεξαν ή επεξεργάστηκαν, χωρίς αναφορά στην πηγή. Αναφέρω πάντοτε με πληρότητα την πηγή κάτω από τον πίνακα ή σχέδιο, όπως στα παραθέματα.
2. Δέχομαι ότι η αυτολεξεί **παράθεση χωρίς εισαγωγικά**, ακόμα κι αν συνοδεύεται από αναφορά στην πηγή σε κάποιο άλλο σημείο του κειμένου ή στο τέλος του, είναι αντιγραφή. Η αναφορά στην πηγή στο τέλος π.χ. μιας παραγράφου ή μιας σελίδας, δεν δικαιολογεί συρραφή εδαφίων έργου άλλου συγγραφέα, έστω και παραφρασμένων, και παρουσίασή τους ως δική μου εργασία.
3. Δέχομαι ότι υπάρχει επίσης περιορισμός στο μέγεθος και στη συχνότητα των παραθεμάτων που μπορώ να εντάξω στην εργασία μου εντός εισαγωγικών. Κάθε μεγάλο παράθεμα (π.χ. σε πίνακα ή πλαίσιο, κλπ), προϋποθέτει ειδικές ρυθμίσεις, και όταν δημοσιεύεται προϋποθέτει την άδεια του συγγραφέα ή του εκδότη. Το ίδιο και οι πίνακες και τα σχέδια
4. Δέχομαι όλες τις συνέπειες σε περίπτωση λογοκλοπής ή αντιγραφής.

Ημερομηνία: 16/10/2023

Η Δηλούσα

Αντωνίου Αικατερίνη

(1) «Όποιος εν γνώσει του δηλώνει ψευδή γεγονότα ή αρνείται ή αποκρύπτει τα αληθινά με έγγραφη υπεύθυνη δήλωση του άρθρου 8 παρ. 4 Ν. 1599/1986 τιμωρείται με φυλάκιση τουλάχιστον τριών μηνών. Εάν ο υπαίτιος αυτών των πράξεων σκόπευε να προσπορίσει στον εαυτόν του ή σε άλλον περιουσιακό όφελος βλάπτοντας τρίτον ή σκόπευε να βλάψει άλλον, τιμωρείται με κάθειρξη μέχρι 10 ετών.

**Ψηφιακό σύστημα ανίχνευσης επιληπτικών κρίσεων βασισμένο σε
TinyML
Αικατερίνη Αντωνίου**

Τριμελής Επιτροπή:

Αθανάσιος Κακαρούντας, Αναπληρωτής Καθηγητής (επιβλέπων)

Χαράλαμπος Καρανίκας, Επίκουρος Καθηγητής

Σωτήριος Τασουλής, Επίκουρος Καθηγητής

Περίληψη

Η παρούσα πτυχιακή εργασία παρουσιάζει μια διαφορετική προσέγγιση για την ανάπτυξη ενός ενσωματωμένου συστήματος αυτόματης ανίχνευσης επιληπτικών κρίσεων, αξιοποιώντας τις καινοτόμες ιδιότητες της τεχνολογίας TinyML. Πιο συγκεκριμένα, διερευνάται η δυνατότητα σχεδίασης ενός συστήματος αναγνώρισης της κατάστασης του ασθενή από σήματα ΗΕΓ κεφαλής. Η μελέτη εμβαθύνει στην προεπεξεργασία του συνόλου δεδομένων CHB-MIT, εστιάζοντας σε 18 κανάλια. Χρησιμοποιώντας παράθυρο τμηματοποίησης 2 δευτερολέπτων, εξάγεται ένα πλήθος σημαντικών χαρακτηριστικών στο πεδίο του χρόνου. Έπειτα, χρησιμοποιείται ο αλγόριθμος επιλογής των k καλύτερων χαρακτηριστικών, δοκιμάζοντας διαφορετικές τιμές για το k . Για τη διαχείριση της ανισορροπίας των κλάσεων ακολουθούνται και συγκρίνονται 3 προσεγγίσεις, η εξισορρόπηση όλου του συνόλου μέσω της υποδειγματοληψίας επικρατούσας κλάσης, η εξισορρόπηση μόνο του συνόλου αξιολόγησης με την ίδια μέθοδο και η αλλαγή κατωφλίου των ταξινομητών. Σε όλες τις προσεγγίσεις εφαρμόστηκε διαχωρισμός 70-30, ενώ στην πρώτη εφαρμόστηκε και διασταυρωμένη επικύρωση k τμημάτων. Εξετάζεται ένα ευρύ φάσμα αλγορίθμων ταξινόμησης, από γραμμικούς ταξινομητές μέχρι και αρχιτεκτονικές νευρωνικών δικτύων. Από το πλήθος των αλγορίθμων που αξιολογήθηκαν μόνο τα νευρωνικά δίκτυα υποστηρίζονται από την TinyML, ενώ προέκυψαν μόνο δύο μοντέλα που ήταν συμβατά με την πλατφόρμα Arduino Nano 33 BLE Sense: ένα απλό νευρωνικό δίκτυο και ένα συνελικτικό νευρωνικό δίκτυο. Για τα παραπάνω δίκτυα καλύτερα αποτελέσματα παρουσιάζει η πρώτη προσέγγιση, αλλά δεν διασφαλίζεται η απόδοσή της σε πραγματικά δεδομένα. Οι άλλες δύο προσεγγίσεις είναι πιο αξιόπιστες, αλλά δεν έχουν τα ίδια ικανοποιητικά αποτελέσματα.

Λέξεις κλειδιά: Επιληψία, Ηλεκτροεγκεφαλογράφημα, Μηχανική Μάθηση, Ενσωματωμένα Συστήματα, TinyML

Abstract

This thesis presents a different approach to the development of an embedded automatic seizure detection system, leveraging the innovative capabilities of TinyML technology. More specifically, the possibility of designing a system that identifies the patient's condition from scalp EEG signals is investigated. The study delves into the preprocessing of the CHB-MIT dataset, focusing on 18 channels. Using a 2-second segmentation window, several important features are extracted in the time domain. Simultaneously, the k best features selection algorithm was implemented, for different values of k. To manage class imbalance, 3 approaches are followed and compared, balancing the whole set through majority class undersampling, balancing only the test set with the same method, and changing the threshold of the classifiers. In all approaches a 70-30 split was applied, while in the first approach k-fold cross-validation was applied as well. A wide range of classification algorithms were considered, from linear classifiers to neural network architectures. Out of the multitude of algorithms evaluated, only neural networks are supported by TinyML, while only two models emerged that are compatible with the Arduino Nano 33 BLE Sense platform: a simple neural network and a convolutuonal neural network. For these networks, better results are obtained by the first approach, but its performance on real time data is not guaranteed. The other two approaches are more reliable, but do not have the same satisfactory results.

Keywords: Epilepsy, EEG, Machine Learning, Embedded Systems, TinyML

Ευχαριστίες

Αρχικά, θα ήθελα να ευχαριστήσω θερμά τον επιβλέποντα καθηγητή μου, Αθανάσιο Κακαρούντα, για την εμπιστοσύνη που μου έδειξε με την ανάθεση της παρούσας εργασίας και την καθοδήγηση που μου προσέφερε καθ' όλη τη διάρκεια της παρούσας έρευνας. Τα πολύτιμα σχόλια και η ενθάρρυνσή του συνέβαλαν καθοριστικά στη διαμόρφωση αυτής της πτυχιακής εργασίας.

Επιπλέον, ευχαριστώ μέσα από την καρδιά μου την οικογένειά μου για την αγάπη, την υπομονή και την κατανόησή που μου έδειξαν στα χρόνια των σπουδών μου και όχι μόνο. Η πίστη τους στις ικανότητές μου αποτέλεσε κινητήρια δύναμη, ώστε να επιτύχω τους στόχους μου.

Τέλος, θα ήθελα να ευχαριστήσω πολύ τις φίλες και τους φίλους που στάθηκαν δίπλα μου κατά τη διάρκεια των σπουδών μου. Με υποστήριξαν στις εύκολες και δύσκολες στιγμές κάνοντας αυτό το ακαδημαϊκό ταξίδι πραγματικά αξέχαστο.

Περιεχόμενα

Περίληψη	i
Abstract	ii
Ευχαριστίες	iii
1 Εισαγωγή.....	1
1.1 Επιληψία.....	1
1.2 Μηχανική μάθηση	1
1.3 Ερευνητικό τοπίο	2
1.4 Στόχος.....	3
1.5 Μεθοδολογία	4
1.5.1 Δεδομένα.....	4
1.5.2 Εξαγωγή χαρακτηριστικών	4
1.5.3 Αλγόριθμοι ταξινόμησης	4
1.5.4 Μέθοδοι αξιολόγησης.....	5
1.6 Δομή εργασίας.....	5
2 Βασικές αρχές	6
2.1 Κεντρικό νευρικό σύστημα	6
2.2 Επιληψία.....	8
2.2.1 Ορισμός.....	8
2.2.2 Συμπτώματα	9
2.2.3 Αιτίες.....	9
2.2.4 Διάγνωση	9
2.2.5 Θεραπεία	12
2.2.6 Ποιότητα ζωής	12
2.3 Εντοπισμός επιληπτικών κρίσεων στο ΗΕΓ	12
2.4 Τεχνητή νοημοσύνη και μηχανική μάθηση.....	13
2.4.1 Τεχνητή νοημοσύνη	13
2.4.2 Μηχανική μάθηση.....	14
2.5 Μηχανική μάθηση και φορητές συσκευές	14
2.5.1 Ενσωματωμένα συστήματα	14
2.5.2 Μοντέλα μηχανικής μάθησης σε φορητές συσκευές.....	15
2.5.3 TinyML	16
2.6 Μηχανική μάθηση και ΗΕΓ	17
3 Βιβλιογραφική ανασκόπηση.....	18
3.1 Ανασκόπηση μεθόδων με κοινό σύνολο δεδομένων	19

3.2	Ανασκόπηση συστημάτων με κοινό σύνολο δεδομένων	27
3.3	Ανασκόπηση εμπορικά διαθέσιμων συσκευών.....	33
3.4	Σύνοψη	34
4	Περιβάλλον ανάπτυξης	35
5	Δεδομένα.....	36
5.1	Σύνολο δεδομένων CHB-MIT	36
5.2	Λήψη δεδομένων.....	38
6	Εξαγωγή χαρακτηριστικών	38
6.1	Χαρακτηριστικά	38
6.1.1	Μέση τιμή	39
6.1.2	Διάμεσος	39
6.1.3	Διακύμανση.....	40
6.1.4	Τυπική απόκλιση.....	40
6.1.5	Ασυμμετρία.....	40
6.1.6	Κύρτωση	41
6.1.7	Ρυθμός διάσχισης μηδενικού άξονα	42
6.1.8	Ενεργός μέση τιμή	42
6.1.9	Εύρος μεταβολής	43
6.1.10	Εντροπία δείγματος.....	43
6.2	Κανονικοποίηση και καθαρισμός συνόλου.....	44
6.3	Επιλογή χαρακτηριστικών.....	45
6.3.1	Κ καλύτερα χαρακτηριστικά.....	45
6.4	Εξισορρόπηση συνόλου	45
6.4.1	Cluster Centroids	46
6.4.2	Αλλαγή κατωφλίου	47
6.5	Διαχωρισμός συνόλου.....	47
6.5.1	Διαχωρισμός 70-30	48
6.5.2	Διασταυρωμένη επικύρωση k τμημάτων	48
7	Αλγόριθμοι ταξινόμησης	49
7.1	Γραμμική διακριτική ανάλυση	49
7.2	Λογιστική παλινδρόμηση.....	51
7.3	Μηχανές διανυσμάτων υποστήριξης.....	51
7.4	Απλοϊκός Bayes.....	53
7.5	Κ πλησιέστεροι γείτονες	54
7.6	Δέντρο απόφασης.....	55
7.7	Τυχαίο δάσος.....	56

1 Εισαγωγή

Το πρώτο κεφάλαιο της παρούσας πτυχιακής εργασίας αποτελεί μια σύντομη εισαγωγή για όσα θα ακολουθήσουν στα επόμενα κεφάλαια. Σκοπός του είναι να παρέχει μια σφαιρική εικόνα ολόκληρης της έρευνας, αναλύοντας την επιληψία, τη μηχανική μάθηση, το τρέχον ερευνητικό τοπίο, τον στόχο μας, τα βήματα της μεθοδολογίας και τη δομή της εργασίας.

1.1 Επιληψία

Η επιληψία, μια νευρολογική διαταραχή που χαρακτηρίζεται από επαναλαμβανόμενες και απρόβλεπτες κρίσεις, επηρεάζει εκατομμύρια ανθρώπους σε ολόκληρο τον κόσμο. Οι επιληπτικές κρίσεις, που προκύπτουν από μη φυσιολογική ηλεκτρική δραστηριότητα στον εγκέφαλο, ποικίλλουν ευρέως ως προς την εκδήλωση, την συχνότητα και την έντασή τους με κάθε ασθενή να τις βιώνει διαφορετικά. Διαγνωστικά μια επιληπτική κρίση εντοπίζεται, από τους ειδικούς, μελετώντας τα ηλεκτρικά σήματα του εγκεφάλου, τα οποία λαμβάνονται μέσω μιας τυπικής εξέτασης ηλεκτροεγκεφαλογραφήματος (ΗΕΓ).


Μία από τις πιο προκλητικές πτυχές της επιληψίας είναι η απρόβλεπτη συμπεριφορά της. Σε αντίθεση με άλλες χρόνιες παθήσεις, ο χρόνος και η εμφάνιση των επιληπτικών κρίσεων, στην πλειονότητα των περιπτώσεων, δεν μπορούν να προβλεφθούν. Μια επιληπτική κρίση μπορεί να συμβεί ανά πάσα στιγμή, διαταράσσοντας την καθημερινότητα, εντείνοντας την ανησυχία και, ενδεχομένως, απειλώντας τη σωματική ασφάλεια των ασθενών. Επομένως, η απροβλεψιμότητα της συγκεκριμένης διαταραχής δημιουργεί ένα αίσθημα αβεβαιότητας στα άτομα, προκαλώντας δυσκολία διατήρησης μιας ισορροπημένης ρουτίνας και μειώνοντας τη συνολική ποιότητα ζωής τους.

1.2 Μηχανική μάθηση

Η μηχανική μάθηση, ένα υποσύνολο τεχνικών της τεχνητής νοημοσύνης, έχει αναδειχθεί ως ένας ταχύτατα αναπτυσσόμενος κλάδος, αλλάζοντας ριζικά τον τρόπο με τον οποίο επεξεργαζόμαστε και ερμηνεύουμε μεγάλους όγκους δεδομένων. Επιτρέπει στα συστήματα να εξάγουν νέες γνώσεις από τα δεδομένα, να μαθαίνουν μοτίβα και να προβλέπουν ή να αποφασίζουν για το αποτέλεσμα αυτόματα και σε πραγματικό χρόνο. Οι αλγόριθμοι μηχανικής μάθησης βρίσκουν εφαρμογή σε διάφορους τομείς, που κυμαίνονται από την αναγνώριση εικόνας και την επεξεργασία φυσικής γλώσσας έως την υγειονομική περίθαλψη και τα αυτόνομα οχήματα. Από τις επιτυχημένες εφαρμογές της μηχανικής μάθησης δεν λείπουν εκείνες που επικεντρώνονται στην ανίχνευση επιληπτικών κρίσεων από καταγραφές σημάτων ΗΕΓ.

Τα τελευταία χρόνια, η σύγκλιση της μηχανικής μάθησης με τα ενσωματωμένα συστήματα οδήγησε σε μια επαναστατική ιδέα: την μικροσκοπική μηχανική μάθηση ή Tiny Machine Learning (TinyML). Η TinyML εστιάζει στην ανάπτυξη μοντέλων μηχανικής μάθησης ικανά να εκτελούνται σε μικρές συσκευές χαμηλής κατανάλωσης, όπως οι μικροελεγκτές. Έτσι, οι πολύπλοκες διεργασίες μπορούν να

εκτελούνται τοπικά, χωρίς την ανάγκη συνεχούς σύνδεσης με ισχυρούς διακομιστές, σώζοντας ακόμα περισσότερη ενέργεια. Η τεχνολογία της TinyML είναι πολλά υποσχόμενη, καθώς ανοίγει τον δρόμο για την δημιουργία καινοτόμων εφαρμογών που προηγουμένως η ανάπτυξή τους θεωρούνταν αδύνατη λόγω των περιορισμένων πόρων. Στον τομέα της υγείας, η TinyML έχει τεράστιες προοπτικές για τη σχεδίαση συστημάτων παρακολούθησης χρόνιων παθήσεων και όχι μόνο. Επομένως, θα μπορούσε να δώσει μια νέα οπτική και στην διαχείριση της επιληψίας. Μια φορητή συσκευή ειδοποίησης επιληπτικών κρίσεων, βασισμένη σε TinyML, η οποία θα διαβάζει τα δεδομένα ΗΕΓ, θα τα μελετάει και θα ειδοποιεί τον ασθενή σε πραγματικό χρόνο, θα μπορούσε να δώσει μια λύση στο πρόβλημα της απροβλεψιμότητας των κρίσεων, μειώνοντας ελαφρώς το βαρύ φορτίο αυτής της χρόνιας διαταραχής.



Εικόνα 1: Ένας μικροεπεξεργαστής με υποστήριξη TinyML. [1]

1.3 Ερευνητικό τοπίο

Ρίχνοντας μια γρήγορη ματιά στο ερευνητικό πεδίο, βλέπουμε ότι οι τρέχουσες έρευνες επικεντρώνονται τόσο στην ανάπτυξη μεθόδων όσο και στη σχεδίαση ενσωματωμένων συστημάτων για τον αυτόματο εντοπισμό επιληπτικών κρίσεων. Ειδικότερα οι δημοσιευμένες εργασίες, που βασίζονται σε δεδομένα ΗΕΓ κεφαλής, χρησιμοποιούν μια πληθώρα εργαλείων και τεχνικών μηχανικής μάθησης με τα δεδομένα να υποβάλλονται σε αρκετά στάδια επεξεργασίας μέχρι την παραγωγή του τελικού αποτελέσματος. Επιπροσθέτως, τα υπό ανάπτυξη ενσωματωμένα συστήματα είτε εκτελούν όλες τις διεργασίες εσωτερικά (Edge Computing), δηλαδή στον επεξεργαστή ή σε ειδικές μονάδες επεξεργασίας, είτε βασίζονται σε εξωτερικούς διακομιστές (Cloud Computing). Τέλος, φαίνεται ότι οι περισσότερες μελέτες μπορούν να χωριστούν σε 2 κατηγορίες ανίχνευσης επιληπτικών κρίσεων, την γενικευμένη και την εξατομικευμένη. Στην περίπτωση της γενικευμένης ανίχνευσης, σκοπός του συστήματος είναι να εντοπίζει τις κρίσεις όλων των ασθενών με την ίδια ακρίβεια, χωρίς να χρειάζεται να τροφοδοτηθεί με δεδομένα του ασθενή για τον οποίο προορίζεται. Αντίθετα, στην εξατομικευμένη ανίχνευση το σύστημα έχει στόχο να εντοπίζει τις κρίσεις ενός συγκεκριμένου ασθενή, αφού πρώτα έχει τροφοδοτηθεί με προγενέστερες καταγραφές ΗΕΓ του.

Η εξατομικευμένη ανίχνευση, αν και αρκετές φορές έχει καλύτερα αποτελέσματα, αντιμετωπίζει σημαντικές προκλήσεις στην πρακτική υλοποίησή της. Σε αυτό το σενάριο ο χρήστης (δηλαδή ο ασθενής) θα χρειαζόταν να υποστεί έναν επαρκή αριθμό επιληπτικών κρίσεων, οι οποίες θα έπρεπε να καταγράφονται με τη βοήθεια του γιατρού του. Αυτή η διαδικασία όχι μόνο θα επέφερε επιπλέον

δυσκολίες στους ασθενείς, αλλά θα τους υποχρέωνε, επίσης, να υπομείνουν πολλαπλές επιληπτικές κρίσεις προκειμένου να συλλεχθούν τα απαραίτητα δεδομένα. Αυτό θα μπορούσε να είναι σωματικά εξουθενωτικό για τους ασθενείς, ενώ παράλληλα θα καθυστερούσε την παροχή μιας άμεσης λύσης, λόγω των απαιτήσεων περισσότερου χρόνου και ιατρικής επίβλεψης.


1.4 Στόχος

Έχοντας συζητήσει τις προκλήσεις της επιληψίας, τη σημασία της μηχανικής μάθησης, τις προοπτικές της TinyML και την εικόνα του παρόντος ερευνητικού τοπίου, μπορούμε να θέσουμε ξεκάθαρα τους στόχους της παρούσας πτυχιακής εργασίας. Οι στόχοι μας είναι πολύπλευροι, όμως επικεντρώνονται στην αντιμετώπιση του σημαντικού ζητήματος της μη προβλεψιμότητας των επιληπτικών κρίσεων, χρησιμοποιώντας τα εργαλεία της TinyML. Επομένως, πρωταρχικός μας στόχος είναι η ανάπτυξη ενός αξιόπιστου ψηφιακού συστήματος για την γενικευμένη ανίχνευση επιληπτικών κρίσεων, μέσω εξωκρανιακών δεδομένων ΗΕΓ. Αυτό το ψηφιακό σύστημα θα πρέπει να παρέχει έγκαιρες ειδοποιήσεις, δίνοντας στα άτομα ένα αίσθημα ασφάλειας και ελέγχου της πάθησής τους. Έτσι, ευελπιστούμε ότι θα μειωθεί η συναισθηματική επιβάρυνση που σχετίζεται με την απροβλεψιμότητα των επιληπτικών κρίσεων, επιτρέποντας στους ασθενείς να ζουν με μεγαλύτερη αυτονομία και αυτοπεποίθηση.

Για να αναπτυχθεί το παραπάνω σύστημα είναι απαραίτητο να μελετήσουμε την επιληπτική διαταραχή εις βάθος και να κατανοήσουμε την εξέταση του ηλεκτροεγκεφαλογραφήματος. Στη συνέχεια, είναι αναγκαία η διερεύνηση των δυνατοτήτων ενσωμάτωσης της μηχανικής μάθησης σε συσκευές με περιορισμένους πόρους, μέσω της τεχνολογίας TinyML. Ειδικότερα, θεωρούμε σημαντικό να αναπτυχθούν διάφορα μοντέλα, τα οποία είναι διαθέσιμα στο Cloud, ώστε να εξακριβωθεί η συμβατότητά τους με τον μικροεπεξεργαστή της πλατφόρμας Arduino Nano 33 BLE Sense. Τέλος, η αξιολόγηση των μοντέλων είναι κρίσιμη, εφόσον το τελικό σύστημα θα πρέπει να είναι όσο πιο αξιόπιστο γίνεται και να κάνει ελάχιστα έως καθόλου λάθη.

Συνοψίζοντας θα μπορούσαμε να πούμε ότι οι βασικότεροι στόχοι της εργασίας μας είναι οι εξής:

- Σχεδίαση ενός αξιόπιστου συστήματος γενικευμένης ανίχνευσης επιληπτικών κρίσεων, μέσω δεδομένων ΗΕΓ κεφαλής, βασισμένο στην τεχνολογία TinyML, όπως φαίνεται στην Εικόνα 2.
- Σύγκριση των διαθέσιμων μοντέλων στο Cloud με εκείνα που υποστηρίζει η TinyML.
- Ανάπτυξη μοντέλων μηχανικής μάθησης συμβατά με Arduino Nano 33 BLE Sense.
- Έμφαση στην αξιολόγηση των μοντέλων μηχανικής μάθησης.



Εικόνα 2: Η επιθυμητή λειτουργία του συστήματος.

7.8	Νευρωνικά δίκτυα	57
7.8.1	Τεχνητό νευρωνικό δίκτυο.....	57
7.8.2	Συνελικτικό νευρωνικό δίκτυο	60
7.8.3	Αναδρομικά νευρωνικά δίκτυα.....	61
7.8.4	Δίκτυο μακράς βραχύχρονης μνήμης	62
7.8.5	Περιφραγμένη επαναλαμβανόμενη μονάδα	64
8	Μέθοδοι αξιολόγησης.....	66
8.1	Πίνακας σύγκρισης.....	66
8.2	Ακρίβεια	67
8.3	Ευαισθησία.....	68
8.4	Ειδικότητα	68
8.5	Μνήμη	68
8.6	Χρόνος αποτελέσματος	69
9	Πειράματα και αποτελέσματα.....	69
9.1	Εξισορροπημένα σύνολα εκπαίδευσης και αξιολόγησης.....	69
9.1.1	Μεθοδολογία.....	69
9.1.2	Αποτελέσματα.....	70
9.2	Μη ισορροπημένο σύνολο εκπαίδευσης και ισορροπημένο σύνολο αξιολόγησης	74
9.2.1	Μεθοδολογία.....	74
9.2.2	Αποτελέσματα.....	75
9.3	Αλλαγή καταωφλίου	76
9.3.1	Μεθοδολογία.....	76
9.3.2	Αποτελέσματα.....	77
9.4	Συζήτηση	79
10	Συμπεράσματα.....	80
10.1	Συμπεράσματα	80
10.2	Περιορισμοί	81
10.3	Μελλοντικές επεκτάσεις.....	81
	Αναφορές	82

1.5 Μεθοδολογία

Στην ενότητα αυτή, αναφέρονται όλα τα βήματα ανάπτυξης και αξιολόγησης των μοντέλων μηχανικής μάθησης. Με άλλα λόγια, περιγράφεται η μεθοδολογία της έρευνάς μας συμπεριλαμβανομένων των δεδομένων, της εξαγωγής και επεξεργασίας χαρακτηριστικών, των αλγόριθμων ταξινόμησης και των μεθόδων αξιολόγησης. Σημειώνεται ότι όλη η πειραματική διαδικασία έλαβε χώρα στο περιβάλλον Google Colab και η συγγραφή των αλγορίθμων έγινε σε γλώσσα Python.

1.5.1 Δεδομένα

Τα δεδομένα που χρησιμοποιήθηκαν στην εργασία, προέρχονται από το σύνολο CHB-MIT, το οποίο περιέχει καταγραφές ΗΕΓ παιδιών με επιληψία. Από ολόκληρο το σύνολο λήφθηκαν τα αρχεία που περιέχουν τουλάχιστον μια επιληπτική κρίση και από αυτά κρατήσαμε μόνο τα 18 κοινά κανάλια των αρχείων. Τέλος, για κάθε εγγραφή σημειώθηκε η κλάση στην οποία ανήκει, δηλαδή «επιληπτική κρίση» ή «μη επιληπτική κρίση».

1.5.2 Εξαγωγή χαρακτηριστικών

Η εξαγωγή των χαρακτηριστικών έγινε στο πεδίο του χρόνου με τις καταγραφές ΗΕΓ να έχουν χωριστεί σε τμήματα των 2 δευτερολέπτων. Για κάθε τμήμα υπολογίστηκαν η μέση τιμή, η διάμεσος, η διακύμανση, η τυπική απόκλιση, η ασυμμετρία, η κύρτωση, ο ρυθμός διάσχισης μηδενικού άξονα, η ενεργός μέση τιμή, το εύρος μεταβολής και η εντροπία δείγματος. Έτσι προέκυψαν συνολικά 180 χαρακτηριστικά (10 χαρακτηριστικά x 18 κανάλια). Έπειτα, το σύνολο χαρακτηριστικών κανονικοποιήθηκε και παράλληλα διαγράφηκαν τυχόν μη αριθμητικές ή άπειρες τιμές. Στη συνέχεια, έγινε επιλογή των k καλύτερων χαρακτηριστικών, συγκρίνοντας τα αποτελέσματα των ταξινομητών όταν το k είναι ίσο με 90, 45, 25 και 12. Για την αντιμετώπιση της ανισορροπίας μεταξύ των κλάσεων που χαρακτηρίζει το σύνολο, δοκιμάστηκαν 3 προσεγγίσεις. Κατά την πρώτη προσέγγιση όλο το σύνολο εξισορροπήθηκε με υποδειγματοληψία επικρατούσας κλάσης με τη μέθοδο Cluster Centeroids, κατά τη δεύτερη προσέγγιση μόνο το σύνολο αξιολόγησης εξισορροπήθηκε με τη μέθοδο Cluster Centeroids και κατά την τρίτη προσέγγιση μεταβάλλουμε το κατώφλι των ταξινομητών. Αυτό το βήμα είναι απαραίτητο διότι τα δείγματα που αντιστοιχούν σε επιληπτική κρίση είναι πολύ λιγότερα από αυτά που αντιστοιχούν σε μη επιληπτική κρίση, προκαλώντας ανισορροπία στο σύνολο και κατά συνέπεια μεροληψία στους ταξινομητές. Τέλος, ο διαχωρισμός των δεδομένων σε σύνολο εκπαίδευσης και σύνολο αξιολόγησης έγινε με διαχωρισμό 70-30. Στην πρώτη προσέγγιση δοκιμάστηκε και ο διαχωρισμός με διασταυρωμένη επικύρωσης k τμημάτων, με $k = 5$. Πρόκειται για μια επαναληπτική μέθοδος που χωρίζει το σύνολο σε k υποσύνολα και κάθε φορά χρησιμοποιεί διαφορετικούς συνδυασμούς για τη δημιουργία των συνόλων, δίνοντας πιο αξιόπιστα αποτελέσματα από έναν απλό διαχωρισμό.

1.5.3 Αλγόριθμοι ταξινόμησης

Στα πλαίσια της έρευνάς μας, θελήσαμε να μελετήσουμε αρκετούς αλγορίθμους ταξινόμησης, οι οποίοι στηρίζονται σε διαφορετικό μαθηματικό υπόβαθρο, ώστε να δούμε ποια προσέγγιση λειτουργεί αποδοτικότερα. Οι αλγόριθμοι κυμαίνονται από γραμμικούς ταξινομητές και δέντρα απόφασης έως μη

γραμμικούς ταξινομητές και νευρωνικά δίκτυα. Εμβαθύνοντας, στους αλγόριθμους περιλαμβάνονται ένας ταξινομητής γραμμικής διακριτικής ανάλυσης, ένας ταξινομητής λογιστικής παλινδρόμησης, μια μηχανή υποστήριξης διανυσμάτων, ένας απλοϊκός Bayes, ένας ταξινομητής k πλησιέστερων γειτόνων, ένα δέντρο απόφασης, ένας αλγόριθμος τυχαίου δάσους, ένα απλό νευρωνικό δίκτυο, ένα συνελκτικό νευρωνικό δίκτυο, ένα αναδρομικό νευρωνικό δίκτυο, ένα δίκτυο μακράς βραχύχρονης μνήμης και μια περιφραγμένη επαναλαμβανόμενη μονάδα. Κατά τον σχεδιασμό των ταξινομητών, δόθηκε έμφαση στην απλότητά τους μειώνοντας τις απαιτήσεις τους σε πόρους και αυξάνοντας την πιθανότητα να μπορούν να εκτελεστούν σε έναν μικροελεγκτή.

1.5.4 Μέθοδοι αξιολόγησης

Η ορθή αξιολόγηση των αλγορίθμων έγινε δοκιμάζοντας την διακριτική ικανότητα των εκπαιδευμένων αλγορίθμων στο σύνολο αξιολόγησης. Το μοντέλο αφού εκπαιδευτεί αξιολογείται με τις μετρικές της ακρίβειας, της ευαισθησίας και της ειδικότητας. Συνδυάζοντας αυτές τις μετρικές έχουμε μια πλήρη εικόνα της απόδοσης του κάθε μοντέλου σε άγνωστα γι' αυτό δεδομένα. Παράλληλα, ελέγχεται η δυνατότητα του μοντέλου να εκτελεστεί στον μικροεπεξεργαστή του Arduino Nano 33 BLE Sense. Σε αυτή τη φάση εξάγονται μετρικές σχετικές με την μνήμη και τον χρόνο αποτελέσματος.

1.6 Δομή εργασίας

Κλείνοντας το κεφάλαιο στο οποίο βρισκόμαστε δίνουμε μια επισκόπηση των κεφαλαίων που ακολουθούν και αναλύουν περεταίρω όσα συζητήθηκαν προηγουμένως. Ειδικότερα, η δομή της εργασίας περιλαμβάνει τα κεφάλαια:

1. Εισαγωγή: Το παρόν κεφάλαιο, το οποίο έχει στόχο την ένταξη του αναγνώστη στο ερευνητικό πλαίσιο της εργασίας.
2. Βασικές αρχές: Συζητούνται οι απαραίτητες έννοιες για την κατανόηση του αντικειμένου της εργασίας μας, όπως η επιληψία, η μηχανική μάθηση και η μεταξύ τους σχέση.
3. Βιβλιογραφική ανασκόπηση: Μελετώνται και συνοψίζονται οι τελευταίες εξελίξεις στον τομέα της ανίχνευσης επιληπτικών κρίσεων, με επίκεντρο εργασίες που χρησιμοποιούν κοινό σύνολο δεδομένων με εμάς.
4. Περιβάλλον ανάπτυξης: Αναλύονται οι τεχνικές ιδιότητες του περιβάλλοντος και της γλώσσας προγραμματισμού που αξιοποιήθηκαν.
5. Δεδομένα: Περιγράφονται οι καταγραφές του συνόλου CHB-MIT και η μεθοδολογία λήψης και επιλογής των δεδομένων που αξιοποιήσαμε.
6. Εξαγωγή χαρακτηριστικών: Καλύπτεται ολόκληρη η διαδικασία εξαγωγής χαρακτηριστικών από τον υπολογισμό του πίνακα των χαρακτηριστικών έως τον διαχωρισμό του.
7. Αλγόριθμοι ταξινόμησης: Παρουσιάζονται όλοι οι δυαδικοί αλγόριθμοι ταξινόμησης που σχεδιάστηκαν στα πλαίσια της έρευνας μας.


8. Μέθοδοι αξιολόγησης: Ορίζονται οι μετρικές αξιολόγησης, που επιλέξαμε να εμπιστευτούμε για την ποσοτικοποίηση της αποτελεσματικότητας του κάθε αλγορίθμου.
9. Πειράματα και αποτελέσματα: Δίνεται μια περιγραφή των πειραμάτων και τα αποτελέσματά τους απεικονίζονται σε πίνακες.
10. Συμπεράσματα: Εξάγεται ένα πλήθος συμπερασμάτων από τα αποτελέσματα της πειραματικής διαδικασίας και προτείνεται την κατεύθυνση που θα μπορούσε να ακολουθήσει η μελλοντική έρευνα σε αυτόν τον τομέα.

2 Βασικές αρχές


Στο παρόν κεφάλαιο εισάγονται οι βασικές αρχές, οι οποίες συνιστούν το πλαίσιο του προβλήματος. Αρχικά, αναλύονται οι απαραίτητες έννοιες για την κατανόηση της δραστηριότητας του εγκεφάλου, την φυσιολογία των επιληπτικών κρίσεων, της αναγνώρισής τους από τους ειδικούς και την επιρροή τους στην καθημερινότητα του ασθενή. Έπειτα, συζητούνται η τεχνητή νοημοσύνη και η μηχανική μάθηση, ώστε να καταλήξουμε στην επεξήγηση της χρησιμότητας και των ιδιοτήτων της πρώιμης τεχνολογίας TinyML. Τέλος, παρέχεται μια σύντομη περιγραφή της σχέσης μεταξύ της μηχανικής μάθησης και της ανάγνωσης των σημάτων του εγκεφάλου για εργασίες διάγνωσης ασθενειών, όπως και η επιληψία.

2.1 Κεντρικό νευρικό σύστημα

Το κεντρικό νευρικό σύστημα (ΚΝΣ) είναι υπεύθυνο για την επεξεργασία δεδομένων και περιλαμβάνει τον εγκέφαλο και τον νωτιαίο μυελό (βλ. Εικόνα 3). Ο εγκέφαλος περιέχει δύο ημισφαίρια και στο καθένα βρίσκονται τέσσερις λοβοί. Κάθε λοβός εκτελεί διαφορετικές λειτουργίες μέσω διάφορων δικτύων διασυνδεδεμένων νευρώνων. Οι λοβοί του εγκεφάλου φαίνονται στην Εικόνα 4 και οι λειτουργίες του κάθε λοβού συνοψίζονται στον Πίνακα 1. [2]



Εικόνα 3: Το κεντρικό νευρικό σύστημα.
Πηγή: Προσαρμοσμένο από [77]




Εικόνα 4: Οι λοβοί του εγκεφάλου.
Πηγή: Προσαρμοσμένο από [78]

Πίνακας 1: Επισκόπηση των λειτουργιών των λοβών του εγκεφάλου.

Λοβός	Λειτουργία
Μετωπιαίος	Κίνηση και αντιπροσώπευση των μυών
Βρεγματικός	Αίσθηση αφής, πίεσης, πόνου και θερμότητας
Ινιακός	Λήψη οπτικών ερεθισμάτων
Κροταφικός	Λήψη ακουστικών ερεθισμάτων

Ο νευρώνας (ή νευρικό κύτταρο) αποτελεί τη βασική δομική και λειτουργική μονάδα του νευρικού συστήματος. Αποτελείται από το κυτταρικό σώμα και τις αποφυάδες του, δηλαδή τους δενδρίτες και τον νευράξονα. Όταν ένας νευρώνας διεγείρεται, το σήμα ταξιδεύει κατά μήκος του άξονά του, φτάνει στην απόληξή του και στέλνεται προς τη σύναψη, μια δομή που είναι υπεύθυνη για την ανταλλαγή δεδομένων μεταξύ των νευρώνων. Εκεί, έρχεται σε επαφή με τον δενδρίτη ενός άλλου νευρώνα, ο οποίος συλλέγει τα σήματα και τελικά τα μεταδίδει στο κυτταρικό σώμα. Η διαδικασία απεικονίζεται στην Εικόνα 5. [2], [3]




Εικόνα 5: Σχηματική αναπαράσταση νευρώνων. [3]

Δύο κύριοι τύποι ηλεκτρικών σημάτων εμπλέκονται σε μια σύναψη:

α) Το δυναμικό ενεργείας που εκλύεται στους άξονες. Δημιουργείται όταν το δυναμικό της μεμβράνης στο κυτταρικό σώμα του νευρώνα ανεβαίνει πάνω από ένα όριο, πυροδοτώντας μια σειρά αντιδράσεων που οδηγούν στην εμφάνιση μιας αιχμής στο ηλεκτρικό δυναμικό.

β) Το μετασυναπτικό δυναμικό που περιγράφει τη μεταβολή στο δυναμικό της μεμβράνης. Η άθροιση των συνεισφορών από άλλες συνάψεις στο σώμα του κυττάρου μπορεί να καθορίσει εάν θα υπάρξει αποπόλωση. Σε σχέση με το δυναμικό ενεργείας, έχει πιο συνεχή μορφολογία, είναι χωρικά πιο περιορισμένο και έχει χαμηλότερη τιμή. [2], [3]

Η Εικόνα 6 δείχνει τις γραφικές παραστάσεις των δυο δυναμικών.



Εικόνα 6: Τα δύο είδη ηλεκτρικών σημάτων στα νευρικά κύτταρα. Α. Το δυναμικό ενεργείας Β. Το μετασυναπτικό δυναμικό. [2]

Συνολικά, το ΚΝΣ είναι ένα σύνθετο σύστημα που διαχειρίζεται ένα ευρύ φάσμα λειτουργιών. Η κατανόησή αυτού και των ηλεκτρικών δυναμικών που δημιουργούνται στα νευρικά κύτταρα είναι ζωτικής σημασίας για τη μελέτη, τη διάγνωση και τη θεραπεία νευρολογικών διαταραχών, όπως η επιληψία.

2.2 Επιληψία

Η επιληψία είχε αναγνωριστεί στην καθημερινότητα και στην ιατρική κοινότητα από τα αρχαία χρόνια. Ετυμολογικά παράγεται από το ρήμα «επιλαμβάνειν», που σημαίνει «προσβάλλω αιφνίδια» και φανερώνει την απώλεια ελέγχου που δημιουργεί η ασθένεια. Στο παρελθόν, οι περισσότεροι άνθρωποι πίστευαν ότι προκαλείται από πνεύματα, και έτσι χαρακτηζόταν ως ιερή ασθένεια. Ωστόσο, ο Ιπποκράτης, ο θεμελιωτής της ορθολογικής ιατρικής, πίστευε ότι η επιληψία είναι μια διαταραχή που προκαλεί ένας ασθενής εγκέφαλος. [2], [4]


Σήμερα, σύμφωνα με τον Παγκόσμιο Οργανισμό Υγείας, η επιληψία αποτελεί μια από τις συχνότερες και σοβαρότερες νευρολογικές διαταραχές. Εμφανίζεται συνήθως τον πρώτο χρόνο της ζωής ή μετά την ηλικία των 65 ετών, επηρεάζοντας περίπου 50 εκατομμύρια ανθρώπους παγκοσμίως. Ωστόσο, οι προκαταλήψεις, οι διακρίσεις και το κοινωνικό στίγμα που περιβάλλουν την επιληψία εδώ και αιώνες δεν έχουν εξαλειφθεί. Το στίγμα δημιουργεί νέες προκλήσεις και δυσχεραίνει όσους ήδη διαχειρίζονται μια απαιτητική ασθένεια, υποβαθμίζοντας την ποιότητα ζωής αυτών και των οικογενειών τους. [5]

Επομένως, πρόκειται για μια πολύπλοκη νόσο με επιρροή σε διαφορετικές πτυχές της ζωής. Για την πλήρη κατανόησή της κρίνεται σημαντική η σαφή διατύπωση της ασθένειας, των συμπτωμάτων, των αιτιών, της διάγνωσης, της θεραπείας και της ποιότητας ζωής όσων επηρεάζονται.

2.2.1 Ορισμός

Ο όρος επιληψία αναφέρεται σε μια μη μεταδοτική, νευρολογική διαταραχή με βασικό σύμπτωμα την επαναλαμβανόμενη εμφάνιση κρίσεων. [5] Οι κρίσεις αυτές, ονομάζονται επιληπτικές κρίσεις και ορίζονται από τη Διεθνή Επιτροπή κατά της Επιληψίας (International League Against Epilepsy) και το Διεθνές Γραφείο Επιληψίας (International Bureau for Epilepsy) ως η παροδική εμφάνιση ενδείξεων ή συμπτωμάτων λόγω μη φυσιολογικής υπερβολικής ή σύγχρονης νευρωνικής δραστηριότητας στον εγκέφαλο. Για να γίνει διάγνωση απαιτείται η ύπαρξη τουλάχιστον δύο απρόκλητων επιληπτικών κρίσεων με διαφορά λιγότερη των 24 ωρών. [6] Οι επιληπτικές διαταραχές κατηγοριοποιούνται ως:

- Εστιακές, όταν οι κρίσεις επηρεάζουν μόνο μια περιοχή του εγκεφάλου.
- Γενικευμένες, όταν οι κρίσεις επηρεάζουν και τα δύο εγκεφαλικά ημισφαίρια ταυτόχρονα.
- Συνδυασμός γενικευμένων και εστιακών, όταν εμφανίζονται και οι δύο τύποι κρίσεων.



Εικόνα 7: Οι δύο κύριοι τύποι επιληπτικών κρίσεων.

Πηγή: Προσαρμοσμένο από [80]

- Άγνωστες. [7]

2.2.2 Συμπτώματα

Μια επιληπτική κρίση ξεκινάει αιφνιδίως, με ήπια συμπτώματα όπως αύρα, ναυτία, αίσθηση ζέστης ή αίσθηση μη πραγματικότητας να την προμηνύουν. Κατά την κρίση, ο ασθενής μπορεί να παρουσιάσει παροξυσμικές και ακούσιες κινήσεις, ξαφνικές διαταραχές στην αίσθηση ή τη συμπεριφορά, έλλειψη ελέγχου του εντέρου ή της ουροδόχου κύστης, ενώ συχνή είναι η απώλεια συνείδησης. Η κλινική εικόνα του ατόμου μετά την κρίση είναι πιθανό να περιλαμβάνει αδυναμία ανάκλησης του επεισοδίου, εξάντληση, τραυματισμό, δάγκωμα γλώσσας, αιμορραγία, κάταγμα οστού ή εξάρθρωση ώμου. [5], [8] Οι τρεις παρακάτω περίοδοι χαρακτηρίζουν τα στάδια των επιληπτικών κρίσεων:

- Η κριτική περίοδος, είναι η περίοδος που εκδηλώνονται τα συμπτώματα.
- Η μετακριτική περίοδος, ακολουθεί μετά από τα συμπτώματα.
- Η μεσοκριτική περίοδος, επικρατεί μεταξύ των επιληπτικών προσβολών. [9]

Η αλληλουχία των συμπτωμάτων που εκδηλώνει ένας συγκεκριμένος ασθενής είναι πανομοιότυπη σε κάθε επεισόδιο. Ωστόσο, αυτή η αλληλουχία αλλά και η συχνότητα των επεισοδίων διαφέρουν για κάθε άτομο. Συνήθως, μια επιληπτική κρίση διαρκεί μερικά δευτερόλεπτα, όμως είναι δυνατό να διαρκέσει περισσότερο από 20 λεπτά, οδηγώντας σε μια σπάνια και επικίνδυνη επιληπτική κατάσταση (Status Epilepticus). [4], [5]

2.2.3 Αιτίες

Η επιληψία μπορεί να προκύψει από οτιδήποτε διαταράσσει τη φυσιολογική λειτουργία του εγκεφάλου. [2] Σύμφωνα με τη Διεθνή Επιτροπή κατά της Επιληψίας, οι αιτίες της ασθένειας χωρίζονται στις παρακάτω έξι κατηγορίες:


1. Δομικές βλάβες στον εγκέφαλο (πχ ουλή, όγκος, συγγενής δυσπλασία, αναπτυξιακή ανωμαλία).
2. Μεταβολικές διαταραχές ή τοξικές επιδράσεις.
3. Μολύνσεις.
4. Ανοσοποιητικές διαταραχές.
5. Γενετική προδιάθεση (πχ μεταλλάξεις στο γονιδίωμα).
6. Άγνωστοι παράγοντες.

Σημειώνεται ότι η επιληψία μπορεί να οφείλεται σε περισσότερα από ένα αίτια, με κυριότερο την γενετική προδιάθεση (ο κίνδυνος για ένα παιδί με δύο επιληπτικούς γονείς ξεπερνάει το 1:25). [4], [6]


2.2.4 Διάγνωση

Οι πρώτες ενέργειες για τη διάγνωση της επιληψίας είναι η καταγραφή ιστορικού και η φυσική εξέταση. Αν υπάρχουν ενδείξεις επιληπτικού επεισοδίου γίνονται εξετάσεις για την παρακολούθηση της

ηλεκτρικής δραστηριότητας του εγκεφάλου (ηλεκτροεγκεφαλογράφημα) και για τον εντοπισμό επιληπτικών εστιών (μαγνητοεγκεφαλογράφημα, τομογραφία, διάγνωση ισοτόπων). [8]



Εικόνα 8: Τυπική εξέταση ΗΕΓ. [81]



Εικόνα 9: Το σύστημα 10-20. Πηγή: Προσαρμοσμένο από [11]

Το ηλεκτροεγκεφαλογράφημα (ΗΕΓ) έχει κυρίαρχο ρόλο στη διάγνωση και διαχείριση της επιληψίας. [10] Αποτελεί μια εξέταση ευρείας διαθεσιμότητας και χαμηλού κόστους, κατά την οποία καταγράφονται αλλαγές στα ηλεκτρικά δυναμικά και μελετάται η εγκεφαλική δραστηριότητα. [9], [11]

Πίνακας 2: Οι κυριότεροι ρυθμοί στο ΗΕΓ.

Ρυθμός	Περιοχή συχνότητας (Hz)	Μορφή [11]
Δέλτα	0,4 - 3,5	
Θήτα	4 - 7,5	
Αλφα	8 - 12	
Βήτα	13 - 30	

Το κλινικό ΗΕΓ λαμβάνεται με τον ασθενή ξαπλωμένο, με κλειστά μάτια μέσω του ηλεκτροεγκεφαλογραφού [11], ο οποίος αποτελείται από:

- Ένα σύστημα εύκολα προσαρτώμενων ηλεκτροδίων, τοποθετημένα στο τριχωτό της κεφαλής σύμφωνα με το διεθνές σύστημα 10–20 (βλ. Εικόνα 9).
- Ενισχυτές χαμηλού θορύβου και φίλτρα.
- Έναν μετατροπέα ADC, για την μετατροπή των σημάτων από αναλογικά σε ψηφιακά.
- Μια συσκευή πολυπλεξίας, που οδηγεί τα αναλογικά σήματα στον μετατροπέα ADC.
- Ένα ηλεκτρικό βολτόμετρο για τη μέτρηση των σημάτων.
- Έναν ηλεκτρονικό υπολογιστή που εκτελεί ψηφιακή επεξεργασία και απεικόνιση των σημάτων.
- Μπορεί να υπάρχει και συσκευή χορήγησης ερεθισμών ελεγχόμενη από τον υπολογιστή. [3]

Το ηλεκτρικό δυναμικό υπολογίζεται ως διαφορά μεταξύ δύο σημείων και η καταγραφή στο ΗΕΓ μπορεί να είναι:

- Διπολική, όταν μετρούνται οι διαφορές δυναμικού σε ζεύγη ηλεκτροδίων. Αυτή η μέθοδος απορρίπτει τυχόν κοινά παράσιτα σε δύο ηλεκτρόδια.

- Μονοπολική, όταν υπολογίζεται η διαφορά μεταξύ κάθε ηλεκτροδίου και ενός ηλεκτροδίου αναφοράς.

Οι διαφορές στο τριχωτό της κεφαλής είναι της τάξεως των 10-100 μV , ενώ οι διαφορές στην επιφάνεια του εγκεφάλου είναι περίπου δέκα φορές υψηλότερες. Οι κυριότεροι ρυθμοί του φυσιολογικού


ΗΕΓ φαίνονται στον Πίνακα 2. [2].

Η διάγνωση γίνεται με τον εντοπισμό μοτίβων που δεν αντιστοιχούν σε φυσιολογική εγκεφαλική λειτουργία. Μοτίβα που εντοπίζονται περίπου στο 50% των ασθενών κατά την πρώτη εξέταση αποτελούν οι μεσοκριτικές επιληπτικές εκφορτίσεις, που εμφανίζονται ως αιχμές και βραχέα κύματα υψηλής συχνότητας. [10]

Άλλοι αποτελεσματικοί τρόποι λήψεως του ΗΕΓ περιλαμβάνουν:

- Την τηλεμετρία ΗΕΓ, που μεγιστοποιεί την πιθανότητα καταγραφής μιας κρίσης για ανάλυση (όπως το βιντεοεγκεφαλογράφημα και το περιπατητικό ΗΕΓ). [4]
 - Το επεμβατικό ΗΕΓ, που χρησιμοποιεί ηλεκτρόδια τοποθετούμενα με χειρουργική επέμβαση στην επιφάνεια του φλοιού. [4]
- Όμως, υπάρχει κίνδυνος μόλυνσης, αιμορραγίας ή φλοιώδους βλάβης. [10]


Οι βασικότερες εξετάσεις για την ανίχνευση επιληπτογενών εστιών



Εικόνα 10: Μεσοκριτικές επιληπτικές εκφορτίσεις σε μονοπολική καταγραφή ΗΕΓ

Πηγή: Προσαρμοσμένο από [79]
είναι:

- Το μαγνητοεγκεφαλογράφημα (ΜΕΓ) για την καταγραφή μεταβολών στα μαγνητικά πεδία που δημιουργεί η δραστηριότητα των νευρώνων. [11]
- Η αξονική τομογραφία (CT), για τη δημιουργία ψηφιακών εικόνων από ακτίνες X. [11]
- Η απεικόνιση μαγνητικού συντονισμού (MRI), για τη δημιουργία ψηφιακών εικόνων με χρήση μη ιοντίζουσας ακτινοβολίας. [11]
- Η λειτουργική απεικόνιση μαγνητικού συντονισμού (fMRI), για την αναπαράσταση τοπικής εγκεφαλικής αιμάτωσης. [9]
- Η υπολογιστική τομογραφία εκπομπής μονού φωτονίου (SPECT), για την ανίχνευση μεταβολών στην εγκεφαλική αιμάτωση με χορήγηση ραδιενεργών ισοτόπων. [4]
- Η ποζιτρονική τομογραφία (PET), για τη δημιουργία τομογραφικών εικόνων τοπικής εγκεφαλικής αιμάτωσης και κατανάλωσης οξυγόνου, με χορήγηση ραδιενεργών ισοτόπων. [4]



Εικόνα 11: Παραδείγματα εξετάσεων εντοπισμού επιληπτικών εστιών. Α. Κριτική (αριστερά) και μεσοκριτική (δεξιά) φάση στο PET. Β. Αιμάτωση εγκεφάλου σε fMRI. Γ. Εντοπισμός δομικών ανωμαλιών με MRI.

Πηγή: Προσαρμοσμένο από [9]

2.2.5 Θεραπεία

Η θεραπεία ακολουθεί μια θετική διάγνωση. Αν έχουν σημειωθεί 2 κρίσεις, ο κίνδυνος περαιτέρω κρίσεων εντός 2 ετών φτάνει το 70-80%, με την επόμενη κρίση να συμβαίνει συνήθως εντός 1 έτους. Συνεπώς, χωρίς θεραπεία οι κρίσεις πιθανώς να συνεχιστούν, αυξάνοντας τον κίνδυνο νευρικού, σωματικού ή ψυχικού τραυματισμού και ξαφνικού, απροσδόκητου θανάτου (Sudden Unexpected Death in Epilepsy). [2], [4] Η κατάλληλη πορεία για την αντιμετώπιση των κρίσεων μπορεί να βασίζεται σε:

- Φαρμακευτική αγωγή, η πιο γνωστή θεραπεία με το 60-70% των ασθενών να απαλλάσσονται από τις κρίσεις.
- Νευροχειρουργική εκτομή, σε περιπτώσεις που υπάρχει γνωστή επιληπτική εστία.
- Αλλαγή τρόπου ζωής, με την αποφυγή παραγόντων όπως η στέρηση ύπνου, η κατάχρηση αλκοόλ, τα φώτα που τρεμοπαίζουν κ.α.

Το μεγαλύτερο ποσοστό των ασθενών σταματάει να υποφέρει από επιληπτικές κρίσεις ακολουθώντας τις παραπάνω μεθόδους. Όμως, για αρκετούς ασθενείς οι κρίσεις μειώνονται χωρίς να εξαλείφονται ή έχουν μηδενικό θεραπευτικό όφελος από τις θεραπείες. [2], [4]

2.2.6 Ποιότητα ζωής

Η επιληψία, όπως ορίστηκε νωρίτερα, είναι μια χρόνια ασθένεια, συνεπώς είναι εύλογη η αξιολόγηση της ποιότητας ζωής των ασθενών, οι οποίοι έρχονται αντιμέτωποι με αρκετές προκλήσεις. Σε έρευνες που έχουν διεξαχθεί με ερωτηματολόγια ειδικά σχεδιασμένα για τον σκοπό αυτό (όπως το QOLIE-31) φαίνεται ότι οι μεγαλύτερες ανησυχίες τους βασίζονται στη συχνότητα, στην απροβλεψιμότητα και στις κοινωνικές συνέπειες των κρίσεων. Οι φοβίες που συνοδεύουν την επιληψία δυσχεραίνουν τους ασθενείς, γεγονός που αποτυπώνεται στην αυξημένη συννοσηρότητα με την κατάθλιψη. Γενικά, η επίδραση της διαταραχής στην καθημερινότητα εξαρτάται από τον τύπο της και την θεραπεία που ακολουθείται. [12], [13]


2.3 Εντοπισμός επιληπτικών κρίσεων στο ΗΕΓ

Παραδοσιακά, ο εντοπισμός της κριτικής φάσης γίνεται από τους επιληπτολόγους με την εύρεση επιληπτόμορφων μοτίβων στο ΗΕΓ και την διαφοροποίηση τους από άλλα ευρήματα. Συχνά, η έναρξη ενός φαινομένου σηματοδοτείται με μια από τις παρακάτω μορφές:

- Ρυθμικά εξελισσόμενες συχνότητες στις ζώνες θήτα, δέλτα ή άλφα.

- Ρυθμικές αιχμές.
- Εκφορτίσεις αιχμής-κύματος.
- Εξομάλυνση των εγκεφαλικών ρυθμών.
- Κρίση χωρίς αλλαγή στο ΗΕΓ, πιθανώς λόγω δειγματοληπτικού σφάλματος [14].

Λόγω του μεγάλου όγκου των δεδομένων που δημιουργεί το ΗΕΓ η ανάλυση και μελέτη του είναι χρονοβόρα και δύσκολη. Για την αντιμετώπιση αυτών των περιορισμών, διατίθενται εμπορικά διαθέσιμοι αλγόριθμοι που συμβάλλουν στην ανάδειξη αιχμών και άλλων επιληπτόμορφων φαινομένων. [10]



Εικόνα 12: Γνωστά μοτίβα ΗΕΓ, που σηματοδοτούν έναρξη επιληπτικής κρίσης.

Πηγή: Προσαρμοσμένο από [14]

2.4 Τεχνητή νοημοσύνη και μηχανική μάθηση

Πριν προχωρήσουμε σε ειδικότερες έννοιες, είναι απαραίτητο να κατανοήσουμε τις έννοιες της τεχνητής νοημοσύνης και της μηχανικής μάθησης, τη μεταξύ τους σχέση, τα κοινά τους σημεία, αλλά και τα σημεία που τις διαφοροποιούν. Έτσι, στην συνέχεια αυτής της υποενότητας συζητάμε αυτές τις συνεχώς εξελισσόμενες τεχνολογίες και τον αντίκτυπο τους στον σύγχρονο κόσμο της πληροφορικής.

2.4.1 Τεχνητή νοημοσύνη

Η τεχνητή νοημοσύνη συνιστά ένα συνεχώς αναπτυσσόμενο πεδίο. Ασχολείται με την δημιουργία υπολογιστικών συστημάτων ικανών να εκτελούν εργασίες που απαιτούν ανθρώπινες γνωστικές δεξιότητες, όπως η αναγνώριση προτύπων, η επίλυση προβλημάτων και η λήψη αποφάσεων. Το φάσμα των εφαρμογών τεχνητής νοημοσύνης είναι ευρύ, καθώς αξιοποιείται σε διάφορους ερευνητικούς τομείς, από την επεξεργασία φυσικής γλώσσας ως τη ρομποτική. Σήμερα, τα μεγαλύτερα επιτεύγματά της αφορούν έξυπνα συστήματα, για την επίλυση καθημερινών προβλημάτων, βασισμένα στη μηχανική και βαθιά μάθηση. Αυτή η επιτυχία οφείλεται:

- Στον μεγάλο όγκο διαθέσιμων δεδομένων, που παράγονται από συσκευές και κοινωνικά δίκτυα,
- Στη διαθεσιμότητα τεράστιας υπολογιστικής ισχύος, που μειώνει τους χρόνους εκπαίδευσης,
- Στους νέους, αποδοτικότερους αλγορίθμους.

Η εξέλιξη της τεχνητής νοημοσύνης έχει την προοπτική να αλλάξει σημαντικά την κοινωνία, δίνοντας ώθηση στην καινοτομία και την ανάπτυξη. [15]

2.4.2 Μηχανική μάθηση

Η μηχανική μάθηση είναι ο κλάδος της τεχνητής νοημοσύνης που στοχεύει στη δημιουργία μοντέλων ή προτύπων από ένα υπολογιστικό σύστημα, με βάση κάποιο σύνολο δεδομένων. [15] Ανάλογα με τη μορφή των δεδομένων η μηχανική μάθηση χωρίζεται σε τέσσερις κατηγορίες:

1. Στη μη επιβλεπόμενη μάθηση, όπου τα δεδομένα είναι μη επισημασμένα, με σκοπό την ομαδοποίησή τους.
2. Στην επιβλεπόμενη μάθηση, όπου τα δεδομένα είναι επισημασμένα και θεωρείται ότι ανήκουν σε μια κλάση, με σκοπό την κατηγοριοποίησή τους.
3. Στην ημι-επιβλεπόμενη μάθηση, όπου υπάρχουν επισημασμένα και μη επισημασμένα δεδομένα.
4. Στην ενισχυτική μάθηση, όπου γίνεται εκπαίδευση μέσω της αλληλεπίδρασης του συστήματος με το περιβάλλον. [16]

Τέλος, εξέλιξη παρουσιάζει και η βαθιά μηχανική μάθηση. Ο συγκεκριμένος τομέας δίνει έμφαση στην ανάπτυξη λύσεων με τη βοήθεια βαθέων νευρωνικών δικτύων. [15]


2.5 Μηχανική μάθηση και φορητές συσκευές

Σήμερα, σχεδιάζονται όλο και περισσότερες φορητές συσκευές που χρησιμοποιούν τη μηχανική μάθηση για την επεξεργασία δεδομένων. Σε αυτή την υποενότητα αναλύεται η έννοια των ενσωματωμένων συστημάτων, οι τρόποι ενσωμάτωσης μηχανικής μάθησης σε αυτά και η ανερχόμενη τεχνολογία TinyML.

2.5.1 Ενσωματωμένα συστήματα

Ένα ενσωματωμένο σύστημα είναι ένα μικρό υπολογιστικό σύστημα ειδικού σκοπού, το οποίο περιέχεται σε μια συσκευή και εκτελεί προκαθορισμένες εργασίες. Το ενσωματωμένο σύστημα απαρτίζεται από:

- Τον μικροεπεξεργαστή, όπου εκτελείται ένας βασικός αλγόριθμος.
- Τη μνήμη, για αποθήκευση του αλγορίθμου και άλλων δεδομένων.
- Τις θύρες εισόδου/εξόδου, για σύνδεση περιφερειακών.



Εικόνα 13: Τα μέρη ενός ενσωματωμένου συστήματος.


Πηγή: Προσαρμοσμένο από [82]

Τα ενσωματωμένα συστήματα χρησιμοποιούνται ευρέως σε φορητές συσκευές, σε διάφορους τομείς όπως στον τομέα της υγείας και της βιοϊατρικής. [17]

2.5.2 Μοντέλα μηχανικής μάθησης σε φορητές συσκευές

Σε μια φορητή συσκευή τα δεδομένα συλλέγονται από αισθητήρες και επεξεργάζονται από τα ενσωματωμένα συστήματα. Η ενσωμάτωση μοντέλων μηχανικής μάθησης γίνεται με τεχνικές όπως:

- Η υπολογιστική νέφους, όπου τα μοντέλα εκτελούνται σε κάποιο χώρο νέφους, για την κάλυψη απαιτήσεων σε υπολογιστικούς πόρους.
- Η υπολογιστική στην άκρη του δικτύου, όπου τα μοντέλα εκτελούνται κοντά στην πηγή των δεδομένων (πχ σε έναν διακομιστή ή στον μικροεπεξεργαστή του συστήματος).




Εικόνα 14: Παραδείγματα υπολογιστικής νέφους (αριστερά) και υπολογιστικής στην άκρη του δικτύου (δεξιά).

Πηγή: Προσαρμοσμένο από [83]

Η υπολογιστική νέφους έχει βασικές αδυναμίες σχετικές με:

- Το απόρρητο των μεταδιδόμενων πληροφοριών.
- Την καθυστέρηση λόγω της μετάδοσης δεδομένων.
- Την ανάγκη εύρους ζώνης.
- Την αποθήκευση τεράστιων όγκων δεδομένων.
- Την απαίτηση ενέργειας για συνεχή ανίχνευση και ανάλυση.


Απάντηση στα παραπάνω ζητήματα μπορεί να δώσει η υπολογιστική στην άκρη του δικτύου, καθώς τα δεδομένα αποστέλλονται σε κοντινή απόσταση ή δεν αποστέλλονται καθόλου. [18] Αυτή η αναδυόμενη μέθοδος δίνει τη δυνατότητα βελτίωσης των ευφύων συστημάτων και έτσι έχει κερδίσει το ενδιαφέρον των ερευνητών.



Εικόνα 15: Η εξέλιξη των αποτελέσματα του όρου "Edge Computing" στο Google Scholar τα τελευταία χρόνια (2018 - 2022).

2.5.3 TinyML

Μια τεχνολογία υπολογιστικής στην άκρη του δικτύου είναι η TinyML (δηλαδή η μικροσκοπική μηχανική μάθηση). Πρόκειται για έναν ταχέως αναπτυσσόμενο τομέα τεχνικών και εφαρμογών μηχανικής μάθησης, που στοχεύουν στην τοπική ανάλυση δεδομένων, στη συσκευή, καταναλώνοντας εξαιρετικά χαμηλή ισχύ. [19] Συνδυάζοντας το υλικό με το λογισμικό, επιτρέπει την εκτέλεση μοντέλων μηχανικής μάθησης στους μικροεπεξεργαστές των ενσωματωμένων συστημάτων. Τα βήματα για την ανάπτυξη μοντέλων σε TinyML είναι:



Εικόνα 16: Συσχέτιση της TinyML με την μηχανική μάθηση και τα ενσωματωμένα συστήματα.

1. Εκπαίδευση μοντέλου σε περιβάλλον με αρκετή υπολογιστική ισχύ.
2. Βελτιστοποίηση του μοντέλου.
3. Ενσωμάτωση μοντέλου στον μικροεπεξεργαστή.

Στα πλεονεκτήματα των εφαρμογών της TinyML περιλαμβάνονται:

- Η χαμηλή κατανάλωση ενέργειας, συνήθως μικρότερη του 1 mWatt
- Το μικρό κόστος, λόγω των φθηνών μικροεπεξεργαστών που χρησιμοποιούνται
- Η μείωση της καθυστέρησης, καθώς δεν υπάρχει η ανάγκη για μετάδοση σε κάποια οντότητα
- Η διασφάλιση της ιδιωτικότητας του χρήστη, αφού δεν μεταδίδονται δεδομένα
- Η δυνατότητα συλλογής και ανάλυσης δεδομένων, αλλά και παραγωγής αποτελεσμάτων σε πραγματικό χρόνο


Όμως, υπάρχουν προκλήσεις στην εκτέλεση Μηχανικής Μάθησης στους μικροεπεξεργαστές, όπως:

- Η περιορισμένη μνήμη τυχαίας προσπέλασης (RAM) των ενσωματωμένων συσκευών (συνήθως της τάξεως των kiloByte)

- Η περιορισμένη ισχύς, η οποία μερικές φορές δεν επαρκεί για την εκτέλεση των μοντέλων μηχανικής μάθησης

Οι περιορισμοί στους πόρους γίνεται να αντιμετωπιστούν με τις εξής πρακτικές:

- Μείωση μεγέθους μοντέλου, με μεθόδους όπως η κβαντοποίηση, το κλάδεμα ή η αξιοποίηση απλών αρχιτεκτονικών
- Ανάπτυξη μοντέλων και αλγορίθμων με τη βοήθεια ενός γενικού πλαισίου, όπως το TensonFlow Lite. [15] Οι υποστηριζόμενες πλατφόρμες συνοψίζονται στον Πίνακα 3.




Εικόνα 17: Η ιεραρχική κατάταξη των πεδίων της τεχνητής νοημοσύνης.

Πίνακας 3: Οι πλατφόρμες που υποστηρίζονται από το Tensorflow Lite και οι αντίστοιχοι επεξεργαστές. [20]

Πλατφόρμα	Επεξεργαστής
Arduino Nano 33 BLE Sense	ARM® Cortex®-M4
SparkFun Edge	ARM® Cortex®-M4F
STM32F746 Discovery kit	ARM® Cortex®-M7
Adafruit EdgeBadge	ARM® Cortex®-M4
Adafruit TensorFlow Lite for Microcontrollers Kit	ARM® Cortex®-M4
Adafruit Circuit Playground Bluefruit	ARM® Cortex®-M4
Espressif ESP32-DevKitC	Xtensa®
Espressif ESP-EYE	Xtensa®
Wio Terminal: ATSAMD51	ARM® Cortex®-M4F
Himax WE-I Plus EVB Endpoint AI Development Board	DesignWare® ARC® EM9D
Synopsys DesignWare ARC EM Software Development Platform	DesignWare® ARC® EM
Sony Spresense	ARM® Cortex®-M4F

2.6 Μηχανική μάθηση και ΗΕΓ

Η μηχανική μάθηση έχει σημαντική συνεισφορά και στον τομέα της υγείας, όπου ο όγκος των ακατέργαστων δεδομένων αυξάνεται εκθετικά. Τα μοντέλα που έχουν αναπτυχθεί στοχεύουν κυρίως στη πρόγνωση, στη διάγνωση, στη θεραπεία και στην απομακρυσμένη παρακολούθηση ασθενειών. [16] Στην



Εικόνα 18: Ανάπτυξη ταξινομητή σημάτων ΗΕΓ.

νευρολογία, η ταξινόμηση των σημάτων του ΗΕΓ έχει σημαντικό ρόλο στη διάγνωση και παρακολούθηση νευρολογικών διαταραχών, αλλά και στην κατανόηση της εγκεφαλικής λειτουργίας. [21]

Στόχος της ταξινόμησης είναι η αντιστοίχιση των δεδομένων σε μια από τις προκαθορισμένες κλάσεις, με ειδικούς αλγορίθμους που ονομάζονται ταξινομητές. Μια συχνή πρακτική προεπεξεργασίας για τη μείωση του μεγάλου όγκου των δεδομένων του ΗΕΓ είναι η εξαγωγή χαρακτηριστικών. Με τη δημιουργία του διανύσματος των χαρακτηριστικών επιτυγχάνεται η περιγραφή των σημάτων με λίγα, όμως σημαντικά στοιχεία, που διαφοροποιούν αρκετά τις κλάσεις μεταξύ τους. Το διάνυσμα των επιλεγμένων χαρακτηριστικών χωρίζεται συνήθως σε δύο σύνολα: το σύνολο εκπαίδευσης και το σύνολο δοκιμής. Ο ταξινομητής εκπαιδεύεται με το σύνολο εκπαίδευσης και στη συνέχεια αξιολογείται στην ταξινόμηση του συνόλου δοκιμής, το οποίο περιέχει άγνωστα, για εκείνον, δεδομένα. Τέλος, αν τα αποτελέσματα είναι ικανοποιητικά το μοντέλο ταξινόμησης βελτιστοποιείται, ώστε να έχει βέλτιστη απόδοση σε πραγματικά δεδομένα. [21] Στην Εικόνα 18 φαίνεται η διαδικασία ανάπτυξης ενός ταξινομητή σημάτων ΗΕΓ.

3 Βιβλιογραφική ανασκόπηση

Στην περίπτωση της επιληψίας, η μηχανική μάθηση χρησιμοποιείται σε μια ποικιλία εφαρμογών, με μεγαλύτερο ενδιαφέρον να παρουσιάζουν εκείνες για την ανίχνευση και πρόβλεψη επιληπτικών κρίσεων. [22] Συγκεκριμένα, στη βιβλιογραφία περιγράφονται μοντέλα για τον εντοπισμό κρίσεων μέσω χαρακτηριστικών εξαγόμενων από μερικά ή όλα τα κανάλια του ΗΕΓ κεφαλής. Πρόσφατες έρευνες, με διάφορους ταξινομητές, έχουν δείξει ενθαρρυντικά αποτελέσματα με υψηλές επιδόσεις, ενώ αρκετές προτείνουν την εκτέλεσή τους σε ενσωματωμένα συστήματα.

Η ανάπτυξη ευφών ενσωματωμένων συστημάτων ανίχνευσης επιληπτικών κρίσεων είναι στο επίκεντρο των ερευνών, εφόσον θα αποτελέσει θεμέλιο για τη σχεδίαση φορητών συσκευών. Γενικά, η βασική λειτουργία αυτών των συστημάτων περιέχει τα ακόλουθα βήματα:

1. Λήψη σημάτων ΗΕΓ
2. Προεπεξεργασία με ενισχυτές ή φίλτρα
3. Εξαγωγή χαρακτηριστικών
4. Ταξινόμηση
5. Ειδοποίηση σε περίπτωση κρίσης

Στόχος αυτής της ενότητας, είναι η διερεύνηση και η κατανόηση των τελευταίων εξελίξεων στον τομέα της κατηγοριοποίησης εξωκρανιακών σημάτων ΗΕΓ, ως επιληπτικά ή μη, με μοντέλα μηχανικής μάθησης. Συγκεκριμένα, περιγράφονται υλοποιήσεις μεθόδων, ενσωματωμένων συστημάτων και φορητών συσκευών που αξιοποιούν το σύνολο δεδομένων CHB-MIT, το οποίο χρησιμοποιείται στην παρούσα πτυχιακή εργασία, ενώ γίνεται αναφορά και στις εμπορικά διαθέσιμες συσκευές.

3.1 Ανασκόπηση μεθόδων με κοινό σύνολο δεδομένων

Η πρώτη μελέτη [23] που αξιοποίησε το σύνολο CHB-MIT δημοσιεύτηκε το 2010 και είχε στόχο τον εντοπισμό της έναρξης των επιληπτικών κρίσεων. Χρησιμοποιήθηκαν 916 ώρες συνεχούς ΗΕΓ, με 173 κρίσεις, χωρισμένες σε τμήματα διάρκειας 2 δευτερολέπτων. Με ένα ζωνοπερατό φίλτρο αφαιρέθηκαν οι συχνότητες μικρότερες των 0.5 Hz και μεγαλύτερες των 25 Hz. Από τα επεξεργασμένα δεδομένα εξήχθησαν χωρικά, φασματικά και χρονικά χαρακτηριστικά. Η κατηγοριοποίηση πραγματοποιήθηκε με μια μηχανή διανυσμάτων υποστήριξης, η οποία εκπαιδεύτηκε και αξιολογήθηκε για κάθε ασθενή ξεχωριστά. Κατά μέσο όρο επιτεύχθηκε 96% ευαισθησία με καθυστέρηση 4,6 δευτερολέπτων και 2 ψευδείς ανιχνεύσεις ανά 24 ώρες.

Στην εργασία [24] διερευνάται περαιτέρω η αυτόματη ανίχνευση της έναρξης επιληπτικών κρίσεων. Από το σύνολο CHB-MIT επιλέχθηκαν δεδομένα ΗΕΓ δέκα ασθενών, με συνολικά 55 κρίσεις. Μετά την αφαίρεση της παρεμβολής της τηλεφωνικής γραμμής στα 60 Hz, τα δεδομένα τμηματοποιήθηκαν σε διαστήματα του 1 δευτερολέπτου και κανονικοποιήθηκαν. Στο πεδίο του χρόνου υπολογίστηκε η ασυμμετρία και η κυρτότητα. Στη συνέχεια, τα δεδομένα μετασχηματίστηκαν με ένα κυματίδιο Daubechies για την εξαγωγή του κανονικοποιημένου συντελεστή διακύμανσης σε τέσσερις ζώνες συχνοτήτων. Χρησιμοποιώντας έναν γραμμικό ταξινομητή, σημειώθηκε 100% μέση ευαισθησία με καθυστέρηση 3,2 δευτερολέπτων και 1,1 ψευδείς ανιχνεύσεις ανά ώρα.

Στην μελέτη [25] προτείνεται μια μεθοδολογία, ειδική προς τον ασθενή, για την αυτόματη ανίχνευση της έναρξης των κρίσεων σε πραγματικό χρόνο, χρησιμοποιώντας δύο διαφορετικά σύνολα δεδομένων, ένα με εξωκρανιακά και ένα ενδοκρανιακά δεδομένα. Στο εξωκρανιακό ΗΕΓ, διατηρήθηκαν οι συχνότητες μεταξύ 3 Hz και 32 Hz από τις καταγραφές 22 ασθενών του συνόλου CHB-MIT, ενώ στο ενδοκρανιακό ΗΕΓ, διατηρήθηκαν οι συχνότητες μεταξύ 3 Hz και 80 Hz. Τα δεδομένα τμηματοποιήθηκαν ανά 2 δευτερόλεπτα, υποβλήθηκαν σε αρμονικό μετασχηματισμό κυματιδίων και εξήχθησαν ενεργειακά και μορφοκλασματικά χαρακτηριστικά. Την ταξινόμηση ανέλαβε μια μηχανή διανυσμάτων συνάφειας, η οποία πέτυχε μέση ευαισθησία 96,2%, 0,1 ψευδείς ανιχνεύσεις ανά ώρα και καθυστέρηση 1,89 δευτερολέπτων για τα εξωκρανιακά δεδομένα, ενώ για τα ενδοκρανιακά δεδομένων, έφτασε σε μέση ακρίβεια 99,8%, ευαισθησία 99% και ειδικότητα 100%.

Στην εργασία [26] περιγράφεται μια μέθοδος, προσαρμοσμένη σε κάθε ασθενή, για την ανίχνευση επιληπτικών επεισοδίων αλλά και για τον εντοπισμό της έναρξής τους, αξιοποιώντας διαφορετικά σύνολα δεδομένων σε κάθε περίπτωση. Για τον εντοπισμό της έναρξης μιας κρίσης χρησιμοποιήθηκαν δεδομένα από το σύνολο CHB-MIT, τμηματοποιημένα ανά 1 δευτερόλεπτο. Στο πεδίο του χρόνου υπολογίστηκε το διατεταρτημοριακό εύρος και η μέση απολυτή απόκλιση. Αφού εφαρμόστηκε μετασχηματισμός με κυματίδιο Daubechies εξήχθησαν η ενέργεια, η εντροπία, το μέγιστο, το ελάχιστο, η μέση τιμή και η τυπική απόκλιση από τις συνιστώσες που προέκυψαν. Με αυτά τα χαρακτηριστικά εκπαιδεύτηκε ένας γραμμικός ταξινομητής, ο οποίος πέτυχε 84,2% μέση ακρίβεια στην ανίχνευση

συμβάντων και 98,5% μέση ευαισθησία με μέση καθυστέρηση 1.76 δευτερολέπτων στον εντοπισμό της έναρξης.

Στόχος της εργασίας [27] είναι η διερεύνηση της αυτόματης ανίχνευσης επιληπτικών κρίσεων χρησιμοποιώντας τεχνικές επιλογής καναλιών και μη γραμμικής μείωσης διαστάσεων στα ηλεκτροεγκεφαλογραφικά δεδομένα. Οι καταγραφές ΗΕΓ από τους 23 ασθενείς του συνόλου CHB-MIT χωρίστηκαν σε διαστήματα των 10 δευτερολέπτων. Σε αυτά, εφαρμόστηκε μετασχηματισμός Fourier για τον υπολογισμό της κανονικοποιημένης φασματικής πυκνότητας ισχύος στις πέντε ζώνες συχνοτήτων. Με αλγόριθμο τυχαίου δάσους επιλέχθηκαν τα τρία πιο σημαντικά κανάλια τα οποία, στη συνέχεια, αναπαραστάθηκαν σε δύο διαστάσεις. Η ταξινόμηση πραγματοποιήθηκε με τον αλγόριθμο κ πλησιέστερων γειτόνων, ο οποίος για όλα τα κανάλια πέτυχε 89,80% ευαισθησία και 48,98% αξιοπιστία με 2,2 ψευδείς ανιχνεύσεις την ώρα, ενώ για τα μειωμένα κανάλια πέτυχε 80,87% ευαισθησία και 47,45% αξιοπιστία με 2,5 ψευδείς ανιχνεύσεις την ώρα.

Στην μελέτη [28], προτείνεται ένα μοντέλο για την ανίχνευση και πρόβλεψη της έναρξης των επιληπτικών κρίσεων βάσει ενδοκρανιακών και εξωκρανιακών εγκεφαλογραφικών καταγραφών, από διαφορετικά σύνολα δεδομένων. Από το σύνολο CHB-MIT χρησιμοποιήθηκαν τα εξωκρανιακά δεδομένα 22 ασθενών. Όλες οι καταγραφές ΗΕΓ διαιρέθηκαν σε τμήματα των 8 δευτερολέπτων και αντιστοιχήθηκαν σε 3 κλάσεις, την κριτική, την μεσοκριτική και την προκριτική. Μετά από ανάλυση κύριων συνιστωσών για αφαίρεση θορύβου, εφαρμόστηκαν τρεις τρόποι αποσύνθεσης του σήματος, ώστε να συγκριθούν. Για τις ζώνες που προέκυψαν υπολογίστηκαν η μέση τιμή, η μέση ισχύς, η τυπική απόκλιση, η ασυμμετρία, η κυρτότητα και ο λόγος απόλυτων μέσων τιμών γειτονικών ζωνών. Για την ταξινόμηση δοκιμάστηκαν ένας ταξινομητής τυχαίου δάσους, μια μηχανή διανυσμάτων υποστήριξης, ένα νευρωνικό δίκτυο και ένας ταξινομητής κ πλησιέστερων γειτόνων. Τελικά, για την εξαγωγή δεδομένων προτείνεται η αποσύνθεση πακέτων κυματιδίων και για την ανίχνευση επιληπτικών κρίσεων προτείνεται ο αλγόριθμος τυχαίου δάσους, με 100% ποσοστά ευαισθησίας, ειδικότητας και ακρίβειας.

Η έρευνα [29] προτείνει μια τεχνική εποπτευόμενης μηχανικής μάθησης για την κατηγοριοποίηση του ΗΕΓ ως επιληπτικού ή μη επιληπτικού. Από το σύνολο δεδομένων CHB-MIT επιλέχθηκαν 171 επιληπτικές και 171 μη επιληπτικές εγγραφές και χωρίστηκαν σε τμήματα 60 δευτερολέπτων. Με ζωνοπερατό φίλτρο δημιουργήθηκαν 5 ζώνες συχνοτήτων, για τις οποίες εξήχθησαν η μέγιστη συχνότητα, η διάμεση συχνότητα, η διακύμανση, η ενεργός τιμή σήματος, η εντροπία δείγματος, η ασυμμετρία και η κυρτότητα. Βάσει διάφορων στατιστικών αναλύσεων δημιουργήθηκε ένα σύνολο με τα 20 πιο ασυσχέτιστα χαρακτηριστικά και ένα με τα 5 καλύτερα χαρακτηριστικά κάθε εγκεφαλικής περιοχής. Για κάθε σύνολο εκπαιδεύτηκαν ένας ταξινομητής γραμμικής διάκρισης, ένας ταξινομητής τετραγωνικής διάκρισης, ένας μη συσχετισμένος ταξινομητής, ένας πολωνυμικός ταξινομητής, ένας λογιστικός ταξινομητής, ένας ταξινομητής κ πλησιέστερων γειτόνων, ένα δέντρο απόφασης, ένας

ταξινομητής parzen και μια μηχανή διανυσμάτων υποστήριξης. Την βέλτιστη επίδοση είχε ο ταξινομητής κ πλησιέστερων γειτόνων, για τα 5 καλύτερα χαρακτηριστικά, με 88% ευαισθησία και 88% ειδικότητα.

Στην εργασία [30] αναπτύχθηκε μια γενικευμένη μέθοδος για την ανίχνευση επιληπτικών κρίσεων βασισμένη σε μετασχηματισμένα σήματα ΗΕΓ. Επιλέχθηκαν οι καταγραφές ΗΕΓ 18 ασθενών του συνόλου CHB-MIT και χωρίστηκαν σε τμήματα των 2 δευτερολέπτων. Με ζωνοπερατό φίλτρο διατηρήθηκαν οι συχνότητες μεταξύ των 0.5 Hz και των 30 Hz. Εφαρμόστηκε μετασχηματισμός κυματιδίων με κυματίδιο Daubechies και εξήχθησαν 4 ζώνες συχνοτήτων. Στη συνέχεια, υπολογίστηκαν η μέση και η μέγιστη συχνότητα, η ενέργεια κάθε ζώνης και η συνολική ενέργεια σήματος. Τα κανάλια χωρίστηκαν σε 6 περιοχές και σε κάθε μία λήφθηκε ο μέσος όρος για κάθε χαρακτηριστικό. Με τη μέθοδο λάμδα του Wilkis επιλέχθηκαν 26 χαρακτηριστικά και βάσει αυτών εκπαιδεύτηκαν ένας ταξινομητής γραμμικής διακριτικής ανάλυσης και ένα νευρωνικό δίκτυο. Αρχικά, οι δύο ταξινομητές αξιολογήθηκαν για κάθε ασθενή ξεχωριστά, με τον ταξινομητή γραμμικής διακριτικής ανάλυσης να έχει την καλύτερη επίδοση με 92,6% ευαισθησία και 99,9% ειδικότητα. Ο ταξινομητής γραμμικής διακριτικής ανάλυσης αξιολογήθηκε και στη γενικευμένη ταξινόμηση, όπου πέτυχε 87,5% ευαισθησία και 99,9% ειδικότητα με 0,9 ψευδείς ανιχνεύσεις την ώρα.

Η διπλωματική εργασία [31] αποσκοπεί στην γενικευμένη ανίχνευση επιληπτικών κρίσεων μέσω μεθόδων μηχανικής μάθησης. Το ΗΕΓ των 22 ασθενών από το σύνολο CHB-MIT χωρίστηκε σε τμήματα των 2 δευτερολέπτων. Στο πεδίο του χρόνου υπολογίστηκαν η μέση τιμή, η διακύμανση, η ασυμμετρία, η κύρτωση, η τυπική απόκλιση, η διάμεσος, οι διασχίσεις μηδενικού άξονα, η ενεργός τιμή, το εύρος μεταβολής και η εντροπία δείγματος. Στη συνέχεια, εκτιμήθηκε η ισχύς στις 5 ζώνες συχνοτήτων και η μέγιστη αλληλοσυσχέτιση. Εφαρμόστηκε κανονικοποίηση και μείωση διαστάσεων, ενώ για την εξισορρόπηση των δειγμάτων δοκιμάστηκαν διάφορες τακτικές υποδειγματοληψίας και υπερδειγματοληψίας. Έπειτα εκπαιδεύτηκαν και βελτιστοποιήθηκαν μια μηχανή διανυσμάτων υποστήριξης, ένας ταξινομητής κ πλησιέστερων γειτόνων, ένας απλοϊκός Bayes, ένα δέντρο απόφασης, ένας ταξινομητής τυχαίου δάσους, ένας ταξινομητής γραμμικής διακριτικής ανάλυσης, ένας ταξινομητής λογιστικής παλινδρόμησης και ένα δίκτυο μακράς βραχύχρονης μνήμης. Για κάθε μοντέλο διεξήχθησαν τρία πειράματα. Το πρώτο πείραμα αφορούσε ένα μέσο κανάλι, το δεύτερο κανάλια που αντιπροσωπεύουν το αριστερό και δεξί ημισφαίριο και το τρίτο όλα τα κανάλια. Το βέλτιστο μοντέλο στην περίπτωση όλων των καναλιών ήταν το δίκτυο μακράς βραχύχρονης μνήμης με 100% ακρίβεια, 100% ευαισθησία και 99% ειδικότητα. Στις άλλες δύο περιπτώσεις τα καλύτερα αποτελέσματα είχε ο ταξινομητής τυχαίου δάσους, ο οποίος πέτυχε 85% ακρίβεια, 90% ευαισθησία και 80% ειδικότητα για το μέσο κανάλι και 89% ακρίβεια, 93% ευαισθησία και 84% ειδικότητα για τα κανάλια του αριστερού και του δεξιού ημισφαιρίου.

Στην εργασία [32] προτείνεται ένα βαθύ νευρωνικό δίκτυο για την αυτόματη ανίχνευση επιληπτικών κρίσεων. Επίσης, προτείνεται μια μέθοδος χαρτογράφησης, ώστε να μαθαίνει το δίκτυο ταυτόχρονα τα

χωρικά και τα χρονικά χαρακτηριστικά από ακατέργαστα δεδομένα ΗΕΓ. Από το σύνολο CHB-MIT επιλέχθηκαν περίπου 34 ώρες ΗΕΓ από πέντε ασθενείς. Αρχικά, με τη χρήση ενός ζωνοπερατού φίλτρου διατηρήθηκαν μόνο οι συχνότητες μεταξύ 3 Hz και 30 Hz. Μετά έγινε χαρτογράφηση και το ΗΕΓ χωρίστηκε σε τμήματα του 1 δευτερολέπτου. Το βαθύ αναδρομικό νευρωνικό δίκτυο εκπαιδεύτηκε και αξιολογήθηκε για κάθε ασθενή ξεχωριστά. Κατά μέσο όρο επιτεύχθηκε 100% ευαισθησία με 0,08 λάθος ανιχνεύσεις την ώρα και καθυστέρηση 7 δευτερολέπτων.

Η μελέτη [33] παρουσιάζει ένα δίκτυο δυαδικών ταξινομητών για την κατηγοριοποίηση μακροχρόνιων καταγραφών ΗΕΓ. Από το σύνολο CHB-MIT επιλέχθηκαν 21 ασθενείς και το ΗΕΓ χωρίστηκε σε τμήματα του 1 δευτερολέπτου. Εφαρμόστηκε χαμηλοπερατό φίλτρο για την διατήρηση των συχνοτήτων μεταξύ 0.5 Hz και 30 Hz. Στο πεδίο του χρόνου εξήχθησαν χαρακτηριστικά όπως η ασυμμετρία, η κυρτότητα, το πλήθος μέγιστων και ελάχιστων, η μέση τιμή, η διακύμανση, η τυπική απόκλιση, η ενεργός τιμή σήματος, η εντροπία Shannon, η προσεγγιστική εντροπία, το εύρος μεταβολής και το πλήθος διασχίσεων του μηδενικού άξονα. Για την εξαγωγή χαρακτηριστικών στο πεδίο της συχνότητας έγινε εξομάλυνση και μετασχηματισμός Fourier. Στη συνέχεια, εξήχθησαν πολλά φασματικά και ενεργειακά χαρακτηριστικά καθώς και χαρακτηριστικά που προκύπτουν από μετασχηματισμό κυματιδίων. Τέλος, έγινε κανονικοποίηση του διανύσματος των χαρακτηριστικών. Η ταξινόμηση πραγματοποιήθηκε με δίκτυο δυαδικών ταξινομητών, αποτελούμενο από βελτιστοποιημένα νευρωνικά δίκτυα. Στην έξοδο του συνολικού δικτύου εφαρμόστηκε μορφολογικό φίλτρο. Η εκπαίδευση και αξιολόγηση έγινε για κάθε ασθενή ξεχωριστά και κατά μέσο όρο επιτεύχθηκε 89,01% ευαισθησία και 94,71% ειδικότητα.

Στόχος της εργασίας [34] είναι ο εντοπισμός επιληπτικών κρίσεων, βάσει ενός βαθιού αμφίδρομου δικτύου μακράς βραχύχρονης μνήμης. Για την εξαγωγή δεδομένων χρησιμοποιήθηκε το ΗΕΓ των 23 ασθενών, χωρισμένο ανά 4 δευτερόλεπτα. Σε κάθε τμήμα εφαρμόστηκε τοπική μέση αποσύνθεση και εξήχθησαν το μέγιστο, το ελάχιστο, η διάμεσος, η μέση τιμή, η τυπική απόκλιση, η διακύμανση, η μέση απόλυτη απόκλιση, η ενεργός τιμή σήματος, η ασυμμετρία και η κυρτότητα. Επιλέχθηκαν τυχαία 6 επιληπτικά συμβάντα για κάθε ασθενή και ανάλογα με τη διάρκεια τους επιλέχθηκε το αντίστοιχο πλήθος μη επιληπτικών τμημάτων. Έπειτα, εκπαιδεύτηκε το αμφίδρομο δίκτυο μακράς βραχύχρονης μνήμης. Η έξοδος του δικτύου επεξεργάστηκε με φίλτρο κινούμενου μέσου όρου, ώστε να μειωθούν οι ψευδείς ανιχνεύσεις. Το τελικό σύστημα έφτασε κατά μέσο όρο 93,61% ευαισθησία και 91,85% ειδικότητα.

Στην [35] προτείνεται μια τεχνική βαθιάς μάθησης για την ανίχνευση επιληπτικών κρίσεων σε καταγραφές ΗΕΓ κεφαλής. Από το σύνολο δεδομένων CHB-MIT επιλέχθηκαν οι καταγραφές 8 ασθενών και χωρίστηκαν σε τμήματα των 2 δευτερολέπτων. Με ένα ζωνοπερατό φίλτρο διατηρήθηκαν οι συχνότητες μεταξύ 0.5 Hz και 150 Hz. Στη συνέχεια, έγινε μετασχηματισμός Fourier και υπολογίστηκε το φασματογράφημα. Η ταξινόμηση έγινε με ένα μονοδιάστατο συνελκτικό νευρωνικό δίκτυο, το οποίο

εκπαιδεύτηκε και αξιολογήθηκε για κάθε ασθενή ξεχωριστά. Κατά την αξιολόγηση, το σύστημα πέτυχε κατά μέσο όρο 77,57% ακρίβεια, 75,59% ευαισθησία και 79,54% ειδικότητα.

Πίνακας 4: Έρευνες εξατομικευμένης ανίχνευσης επιληπτικών κρίσεων με δεδομένα του συνόλου CHB-MIT

Συγγραφείς	Τμήματα	Προεπεξεργασία	Χαρακτηριστικά	Ταξινόμηση	Αξιολόγηση
Shoeb και Guttag [23]	2 s	Ζωνοπερατό φίλτρο στα 0.5, 25 Hz	Χωρικά, φασματικά και χρονικά	SVM	Ευαισθησία: 96% Καθυστέρηση: 4,6 s 2 FD/24h
Khan και άλλοι [24]	1 s	Αφαίρεση 60 Hz, μετασχηματισμός κυματιδίων Daubechies	Χρονικά και χαρακτηριστικά κυματιδίων	Γραμμικός ταξινομητής	Ευαισθησία: 100% Καθυστέρηση: 3,2 s 1,1 FD/h
Vidyaratne και Iftekharuddin [25]	2 s	Ζωνοπερατό φίλτρο στα 3, 32 Hz	Ενεργειακά και μορφοκλασματικά	SVM	Ευαισθησία: 96,2% Καθυστέρηση: 1,89 s 0,1 FD/h
Ahammad και άλλοι [26]	1 s	Μετασχηματισμός κυματιδίων Daubechies	Χρονικά και Χαρακτηριστικά κυματιδίων	Γραμμικός ταξινομητής	Ευαισθησία: 98,5% Καθυστέρηση: 1.76 s
Birjandtalab και άλλοι [27]	10 s	Μετασχηματισμός Fourier, επιλογή καναλιών με Random Forest	Φασματικά	K-NN	Ευαισθησία: 89,80% Αξιοπιστία: 48,98% 2,2 FD/h
Orosco [29]	2 s	Ζωνοπερατό φίλτρο στα 0.5, 30 Hz, μετασχηματισμός κυματιδίων Daubechies	Χαρακτηριστικά κυματιδίων	LDA	Ευαισθησία: 92,6% Ειδικότητα: 99,9%
Hu και άλλοι [34]	4 s	Τοπική μέση αποσύνθεση	Χαρακτηριστικά κυματιδίων	Bi-LSTM	Ευαισθησία: 93,61% Ειδικότητα: 91,85%

Συγγραφείς	Τμήματα	Προεπεξεργασία	Χαρακτηριστικά	Ταξινόμηση	Αξιολόγηση
Jana και άλλοι [35]	2 s	Ζωνοπερατό φίλτρο στα 0.5, 150 Hz, μετασχηματισμός Fourier.	Φασματογράφημα	CNN	Ακρίβεια: 77,57% Ευαισθησία: 75,59% Ειδικότητα: 79,54%
Hossain και άλλοι [36]	2 s	-	-	DCNN	Ακρίβεια: 99,65%

Στην [37] αναπτύχθηκε μια μέθοδος ανίχνευσης επιληπτικών κρίσεων βασισμένη σε ένα βαθύ συνελκτικό νευρωνικό δίκτυο. Ως σύνολο δεδομένων HEG, επιλέχθηκαν εγγραφές από δύο σύνολα δεδομένων, συμπεριλαμβανομένου του CHB-MIT. Για την τμηματοποίηση του HEG δοκιμάστηκαν παράθυρα 10, 20 και 30 δευτερολέπτων. Στα τμήματα που περιέχουν επιληπτική κρίση έγινε υπερδειγματοληψία. Για αφαίρεση θορύβου, δοκιμάστηκαν δύο χαμηλοπερατά φίλτρα με συχνότητα αποκοπής 30 Hz και 60 Hz. Τα τμήματα δόθηκαν ως είσοδος στο συνελκτικό νευρωνικό δίκτυο για την εξαγωγή χαρακτηριστικών σχετικών με τον χώρο και τον χρόνο. Στο τελικό στρώμα του δικτύου έγινε η ταξινόμηση. Η βέλτιστη επίδοση επιτεύχθηκε για παράθυρο 30 δευτερολέπτων και για συχνότητα αποκοπής 60 Hz. Για το σύνολο CHB-MIT, το μοντέλο πέτυχε 85,6% ακρίβεια, 80,6% ευαισθησία και 91,7% ειδικότητα.

Στην εργασία [38] αναπτύχθηκε μια μέθοδος βαθιάς μάθησης για τον εντοπισμό των μη φυσιολογικών εγκεφαλικών σημάτων που αντιστοιχούν σε επιληπτικές κρίσεις. Οι καταγραφές των ασθενών του συνόλου CHB-MIT χωρίστηκαν σε τμήματα διάρκειας 3 δευτερολέπτων. Ύστερα, εφαρμόστηκε μετασχηματισμός Fourier και υπολογίστηκε το φασματογράφημα. Για την ταξινόμηση αναπτύχθηκε ένας αυτόματος κωδικοποιητής βασισμένος σε συνελκτικά νευρωνικά δίκτυα, ο οποίος συγκρίθηκε κυρίως με διάφορα νευρωνικά δίκτυα αλλά και μια μηχανή διανυσμάτων υποστήριξης. Κατά την αξιολόγηση, το προτεινόμενο μοντέλο είχε την βέλτιστη επίδοση με 94,37% ακρίβεια.

Στην [36] χρησιμοποιείται ένα βαθύ συνελκτικό νευρωνικό δίκτυο για τον εντοπισμό επιληπτικών κρίσεων. Οι καταγραφές HEG του συνόλου CHB-MIT χωρίστηκαν σε τμήματα των 2 δευτερολέπτων. Κάθε τμήμα μετασχηματίστηκε σε δισδιάστατο πίνακα και δόθηκε ως είσοδος στο συνελκτικό νευρωνικό δίκτυο. Το δίκτυο αρχικά εξήγαγε χρονικά και φασματικά χαρακτηριστικά και, στη συνέχεια, ταξινόμησε το κάθε τμήμα ως επιληπτική κρίση ή μη επιληπτική κρίση. Το μοντέλο πέτυχε 98,05% ακρίβεια, 90% ευαισθησία και 91,65% ειδικότητα, όταν εκπαιδεύτηκε και αξιολογήθηκε με το HEG όλων των ασθενών, ενώ πέτυχε κατά μέσο όρο 99,65% ακρίβεια όταν εκπαιδεύτηκε και αξιολογήθηκε με το HEG κάθε ασθενή ξεχωριστά.

Στην εργασία [39] προτείνεται μια βελτιωμένη μέθοδος αυτόματης ανίχνευσης επιληπτικών κρίσεων, βασισμένη στη βαθιά μάθηση. Το ΗΕΓ των 23 ασθενών διαιρέθηκε με παράθυρο 5 δευτερολέπτων και βήμα 1 δευτερολέπτου. Τα τμήματα θεωρήθηκαν ως δισδιάστατες εικόνες και συγχωνεύτηκαν η αύξουσα και η φθίνουσα ακολουθία για την ανάδειξη συγκεκριμένων χαρακτηριστικών. Στη συνέχεια, τα δεδομένα αυξήθηκαν αξιοποιώντας ένα παραγωγικό μοντέλο αποτελούμενο από δύο αντιμαχόμενα νευρωνικά δίκτυα. Για την ταξινόμηση εκπαιδεύτηκε ένα συνελκτικό νευρωνικό δίκτυο. Κατά την αξιολόγηση του δικτύου με τη μέθοδο της συγχώνευσης σημειώθηκε 74,08% ευαισθησία και 92,46% ειδικότητα, ενώ με την αύξηση δεδομένων σημειώθηκε 72,11% ευαισθησία και 95,89% ειδικότητα.

Στην [40] παρουσιάζεται μια μέθοδος αυτόματης ανίχνευσης της έναρξης των επιληπτικών κρίσεων βασισμένη σε μη επιβλεπόμενη μηχανική μάθηση. Οι καταγραφές ΗΕΓ του συνόλου δεδομένων χωρίστηκαν ανά 5 δευτερόλεπτα. Με ένα ζωνοπερατό φίλτρο αφαιρέθηκαν οι συχνότητες μικρότερες του 1 Hz και οι συχνότητες μεγαλύτερες των 30 Hz. Για την εξισσορόπηση των δεδομένων έγινε τυχαία υποδειματοληψία. Η ταξινόμηση έγινε με ένα συνελκτικό νευρωνικό δίκτυο και επιτεύχθηκε 77,57% ακρίβεια, 0.74 ψευδείς ανιχνεύσεις την ώρα και καθυστέρηση 2,1 δευτερολέπτων.

Στην μελέτη [41] ακολουθείται μια προσέγγιση βαθιάς μάθησης για την ανίχνευση επιληπτικών κρίσεων σε καταγραφές παιδιατρικού ΗΕΓ. Από το σύνολο δεδομένων επιλέχθηκαν οι καταγραφές 16 ασθενών και για την τμηματοποίησή τους δοκιμάστηκαν παράθυρα των 1, 2 και 4 δευτερολέπτων. Στα επιλεγμένα δεδομένα έγινε υποδειματοληψία και κανονικοποίηση. Στη συνέχεια, εκπαιδεύτηκε ένας δισδιάστατος βαθύς συνελκτικός αυτόματος κωδικοποιητής, βασισμένος σε ένα αμφίδρομο δίκτυο μακράς βραχύχρονης μνήμης. Η βέλτιστη μέθοδος ήταν αυτή για παράθυρο μήκους 4 δευτερολέπτων, που κατά την αξιολόγηση έφτασε περίπου 98,79% ακρίβεια, 98,72% ευαισθησία, 98,86% ειδικότητα και 98,86% αξιοπιστία.

Πίνακας 5: Έρευνες γενικευμένης ανίχνευσης επιληπτικών κρίσεων με δεδομένα του συνόλου CHB-MIT

Συγγραφείς	Τμήματα	Προεπεξεργασία	Χαρακτηριστικά	Ταξινόμηση	Αξιολόγηση
Alickovic και άλλοι [28]	8 s	Ανάλυση κύριων συνιστωσών για αφαίρεση θορύβου, αποσύνθεση πακέτων κυματιδίων	Χαρακτηριστικά κυματιδίων	Random Forest	Ακρίβεια: 100%
					Ευαισθησία: 100%
					Ειδικότητα: 100%
Fergus και άλλοι [29]	60 s	Ζωνοπερατό φίλτρο δημιουργήθηκαν 5 ζώνες συχνοτήτων	Φασματικά χαρακτηριστικά	K-NN	Ευαισθησία: 88%
					Ειδικότητα: 88%

Συγγραφείς	Τμήματα	Προεπεξεργασία	Χαρακτηριστικά	Ταξινόμηση	Αξιολόγηση
Orosco [30]	2 s	Ζωνοπερατό φίλτρο στα 0.5, 30 Hz, μετασχηματισμός κυματιδίων Daubechies	Χαρακτηριστικά κυματιδίων	LDA	Ευαισθησία: 87,5% Ειδικότητα: 99,9% 0,9 FD\h
Πατσούρας [31]	2 s	-	Χρονικά και φασματικά	LSTM	Ακρίβεια: 100% Ευαισθησία: 100% Ειδικότητα: 99%
Park και άλλοι [37]	30 s	Χαμηλοπερατό φίλτρο στα 60 Hz	-	CNN	Ακρίβεια: 85,6% Ευαισθησία: 80,6% Ειδικότητα: 91,7%
Yuan και άλλοι [38]	3 s	Μετασχηματισμός Fourier	Φασματογράφημα	Autoencoder	Ακρίβεια: 94,37%
Hossain και άλλοι [36]	2 s	-	-	DCNN	Ακρίβεια: 98,05% Ευαισθησία: 90% Ειδικότητα: 91,65%
Wei και άλλοι [39]	5 s με βήμα 1 s	Αύξηση δεδομένων με παραγωγικό μοντέλο	-	CNN	Ευαισθησία: 72,11% Ειδικότητα: 95,89%
Yunvaraj και άλλοι [40]	5 s	Ζωνοπερατό φίλτρο στα 1, 30 Hz	-	CNN	Ακρίβεια: 77,57% Καθυστέρηση: 2,1 s 0.74 FD\h

Συγγραφείς	Τμήματα	Προεπεξεργασία	Χαρακτηριστικά	Ταξινόμηση	Αξιολόγηση
Abdelhameed και Bayoumi [41]	4 s	-	-	2D Deep Autoencoder, Bi-LSTM	Ακρίβεια: 98,79%
					Ευαισθησία: 98,72%
					Ειδικότητα: 98,86%
					Αξιοπιστία: 98,86%

3.2 Ανασκόπηση συστημάτων με κοινό σύνολο δεδομένων

Στόχος της εργασίας [42] είναι η αυτόματη ταξινόμηση σημάτων ΗΕΓ, ως επιληπτικά ή μη, χρησιμοποιώντας ένα υπό ανάπτυξη σύστημα. Το σύστημα λαμβάνει σήματα από 3 ηλεκτρόδια, τα ενισχύει, τα μετατρέπει από αναλογικά σε ψηφιακά και τα αποθηκεύει στο νέφος. Εκεί, σε δεύτερο χρόνο, χωρίζονται σε τμήματα των 12 δευτερολέπτων, μετασχηματίζονται μέσω κυματιδίων και εξάγονται η μέση τιμή, η διάμεσος, η τυπική απόκλιση, η κυρτότητα, η ασυμμετρία, η επικρατούσα τιμή και η ενέργεια στις 5 ζώνες συχνοτήτων που προκύπτουν. Η ταξινόμηση γίνεται με μια μηχανή διανυσμάτων υποστήριξης. Κατά την αξιολόγηση της μεθόδου, χρησιμοποιήθηκαν δεδομένα ενός ασθενή του συνόλου CHB-MIT και δοκιμάστηκαν διάφορα φίλτρα για αφαίρεση θορύβου στα σύνολα εκπαίδευσης και αξιολόγησης. Το βέλτιστο μοντέλο έφτασε 99,46% ακρίβεια, 100% ευαισθησία και 98,94% ειδικότητα.

Στην [43] αναπτύχθηκε μια ολοκληρωμένη μέθοδος για την αυτόματη ανίχνευση και ανάλυση επιληπτικών κρίσεων χρησιμοποιώντας πληροφορίες που περιέχονται στα σήματα ΗΕΓ. Το σύστημα αποτελείται από μια συσκευή, μια εφαρμογή κινητού τηλεφώνου και έναν διακομιστή νέφους. Η συσκευή είναι υπεύθυνη για τη λήψη και αποστολή σημάτων στο νέφος, όπου πραγματοποιείται προεπεξεργασία, εξαγωγή χαρακτηριστικών, κανονικοποίηση, επιλογή χαρακτηριστικών και ομαδοποίηση. Μέσω της εφαρμογής γίνεται η απεικόνιση των σημάτων και η ειδοποίηση του γιατρού σε περίπτωση κρίσης. Η αξιολόγηση του συστήματος έγινε με το ΗΕΓ ενός ασθενή του συνόλου CHB-MIT. Τα σήματα χωρίστηκαν σε 3 κλάσεις προκριτική, κριτική και μετακριτική. Εφαρμόστηκαν 2 φίλτρα για την διατήρηση των συχνοτήτων 0.1-60 Hz και την αφαίρεση των 50 Hz. Στη συνέχεια, έγινε εξομάλυνση και τμηματοποίηση ανά 3 δευτερόλεπτα. Εξήχθησαν χαρακτηριστικά στο πεδίο του χρόνου, της συχνότητας, καθώς και χαρακτηριστικά εντροπίας και κυματιδίων. Επιπλέον, δοκιμάστηκαν διαφορετικοί αλγόριθμοι για επιλογή 15 χαρακτηριστικών. Ο αλγόριθμος k μέσων χρησιμοποιήθηκε για ομαδοποίηση, πετυχαίνοντας ικανοποιητική διαχωριστική ικανότητα μεταξύ των κλάσεων. Τέλος, έγινε και δοκιμή σε πραγματικό χρόνο με δεδομένα από αισθητήρα ΗΕΓ.

Στην μελέτη [44] παρουσιάζεται ένας ειδικός επεξεργαστής για την εξατομικευμένη, αυτόματη ανίχνευση και καταγραφή επιληπτικών κρίσεων βάσει του ΗΕΓ 8 καναλιών. Αρχικά, τα σήματα χωρίζονται σε τμήματα των 2 δευτερολέπτων και με την εφαρμογή ζωνοπερατών φίλτρων εξάγεται η φασματική ενέργεια σε 7 ζώνες συχνοτήτων. Στη συνέχεια, για κάθε 3 τιμές ενέργειας δημιουργούνται διανύσματα που αντιστοιχούν σε ΗΕΓ διάρκειας 6 δευτερολέπτων. Για την ταξινόμηση χρησιμοποιείται μια μηχανή διανυσμάτων υποστήριξης, η οποία εκπαιδεύτηκε και αξιολογήθηκε με δεδομένα του συνόλου CHB-MIT και πέτυχε κατά μέσο όρο 82,7% ακρίβεια με 4,5% ψευδείς ανιχνεύσεις. Επιπλέον, το σύστημα δοκιμάστηκε στον εντοπισμό ταχέως ανοιγοκλεισίματος των ματιών, όπου πέτυχε 84,4% ακρίβεια και κατανάλωση 2.03 uJ ανά ταξινόμηση.

Στην εργασία [45] προτείνεται ένας πολυκαναλικός επεξεργαστής εξατομικευμένης ανίχνευσης της έναρξης και λήξης των επιληπτικών κρίσεων. Τα δεδομένα ΗΕΓ λαμβάνονται από το τριχωτό της κεφαλής μέσω ηλεκτροδίων και χωρίζονται σε τμήματα με παράθυρο 2 δευτερολέπτων και βήμα 1 δευτερολέπτου. Έπειτα, σε μια μονάδα εξαγωγής δεδομένων, γίνεται ο υπολογισμός της φασματικής ενέργειας σε 7 ζώνες συχνοτήτων και εφαρμόζονται βάρη. Για την ταξινόμηση χρησιμοποιείται μια μηχανή υποστήριξης διανυσμάτων. Σε περίπτωση κρίσης τα σήματα καταγράφονται και μέσω μιας ειδικής μονάδας παρέχεται διακρανιακή ηλεκτρική διέγερση για την καταστολή του ασθενή. Το σύστημα αξιολογήθηκε με τις καταγραφές του συνόλου CHB-MIT, πετυχαίνοντας 93% ακρίβεια, 95,1% ευαισθησία και 96,2% ειδικότητα με καθυστέρηση 1 δευτερολέπτου και κατανάλωση 1.85 uJ ανά ταξινόμηση.

Η εργασία [46] στοχεύει στην αναγνώριση επιληπτικών κρίσεων σε σήματα ΗΕΓ, συνδυάζοντας ένα βαθύ συνελκτικό νευρωνικό δίκτυο και ένα νευρωνικό δίκτυο. Αρχικά, γίνεται αποσύνθεση των σημάτων ΗΕΓ σε διάφορες ζώνες συχνοτήτων. Στη συνέχεια, στο βαθύ συνελκτικό νευρωνικό δίκτυο εξάγονται τα σημαντικότερα χαρακτηριστικά και στο νευρωνικό δίκτυο ταξινομούνται. Η αξιολόγηση της μεθόδου έγινε μέσω προσομοίωσης με 3 διαφορετικά σύνολα δεδομένων, συμπεριλαμβανομένου και του CHB-MIT. Στην εξατομικευμένη ανίχνευση κρίσεων του συνόλου CHB-MIT επιτεύχθηκε 99,37% ακρίβεια, 100% ευαισθησία και 99,34% ειδικότητα με 0,663 ψευδείς ανιχνεύσεις την ώρα. Τέλος, οι αλγόριθμοι υλοποιήθηκαν σε συστοιχία επιτόπια προγραμματιζόμενων πυλών με σκοπό την ανάπτυξη ενός συστήματος διάγνωσης επιληπτικών κρίσεων σε πραγματικό χρόνο.

Στην μελέτη [47] διερευνάται η ανίχνευση επιληπτικών κρίσεων λαμβάνοντας σήματα περιπατικού ΗΕΓ. Το ΗΕΓ των ασθενών του συνόλου CHB-MIT χωρίστηκε σε τμήματα των 15 δευτερολέπτων. Τα τμήματα χρησιμοποιήθηκαν ως είσοδος σε ένα συνελκτικό νευρωνικό δίκτυο, με μεταφορά μάθησης, για εξαγωγή χαρακτηριστικών και ταξινόμηση. Συγκρίθηκαν τρία διαφορετικά μοντέλα, ένα γενικευμένο μοντέλο, ένα εξατομικευμένο μοντέλο και ένα συνδυαστικό μοντέλο. Κατά την αξιολόγηση το βέλτιστο μοντέλο ήταν το συνδυαστικό, για το οποίο σημειώθηκε 100% ευαισθησία, με μέση καθυστέρηση 1,47

δευτερολέπτων και 3,2 ψευδείς ανιχνεύσεις την μέρα. Τέλος, σχεδιάστηκε ένα ενσωματωμένο σύστημα για την εκτέλεση της παραπάνω μεθοδολογίας με διάρκεια μπαταρίας μεγαλύτερη των 80 ωρών.

Στην εργασία [48] σχεδιάστηκε ένα εύκαμπτο σύστημα λήψης σημάτων ΗΕΓ και εξαγωγής βιοδεικτών. Αρχικά, τα σήματα λαμβάνονται από 7 κανάλια, ενισχύονται και συμπιέζονται. Στη συνέχεια, εξάγεται η φασματική ενέργεια σε 8 ζώνες συχνοτήτων για κάθε κανάλι και βάσει αυτών των χαρακτηριστικών γίνεται ταξινόμηση με μια μηχανή διανυσμάτων υποστήριξης. Στα πλαίσια της εργασίας, σχεδιάστηκε ένα πρωτότυπο σύστημα για ανάγνωση και επεξεργασία κυμάτων άλφα. Για την αξιολόγηση, επιλέχθηκαν οι καταγραφές ενός ασθενή από το σύνολο CHB-MIT και επιτεύχθηκε ποσοστό λάθους < 8%

Στην εργασία [49] αναπτύχθηκαν 3 μοντέλα βαθιάς μάθησης, εκτελέστηκαν σε έναν μικροελεγκτή και αξιολογήθηκαν στην ανίχνευση και πρόβλεψη επιληπτικών κρίσεων. Το ΗΕΓ όλων των περιστατικών αντιστοιχήθηκε σε 3 κλάσεις, την κριτική, την μεσοκριτική και την προ κριτική. Για την τμηματοποίησή του δοκιμάστηκαν παράθυρα των 0.25, 0.5, 1, 2 και 4 δευτερολέπτων. Τα δεδομένα εξισορροπήθηκαν με υπερδειγματοληψία και ανάθεση βαρών. Στη συνέχεια, εκπαιδεύτηκαν ένα βαθύ νευρωνικό δίκτυο, ένα συνελκτικό νευρωνικό δίκτυο και ένα δίκτυο μακράς βραχύχρονης μνήμης. Έγινε επιλογή καναλιών και η επίδοση κάθε δικτύου αξιολογήθηκε για 1, 5, 9, 13 και 18 κανάλια. Το καλύτερο μοντέλο, στην ανίχνευση κρίσεων, ήταν το δίκτυο μακράς βραχύχρονης μνήμης με παράθυρο 2 δευτερολέπτων και 9 κανάλια ως είσοδο. Κατά την αξιολόγηση πέτυχε 97,61% ευαισθησία και 0,071 ψευδείς προβλέψεις την ώρα. Τέλος, τα μοντέλα εκτελέστηκαν σε έναν μικροελεγκτή (ARM Cortex-M4) και εκτιμήθηκαν το απαιτούμενο μέγεθος μνήμης, ο χρόνος αποτελέσματος και η κατανάλωση ενέργειας κάθε μοντέλου. Σε αυτή την περίπτωση το δίκτυο μακράς βραχύχρονης μνήμης είχε τα χειρότερα αποτελέσματα, με βασικότερο μειονέκτημα την υψηλή κατανάλωση ενέργειας.

Πίνακας 6: Ενσωματωμένα συστήματα εξατομικευμένης ανίχνευσης επιληπτικών κρίσεων με δεδομένα του συνόλου CHB-MIT

Συγγραφείς	Τμήματα	Προεπεξεργασία	Χαρακτηριστικά	Ταξινόμηση	Αξιολόγηση	Μέθοδος
Dobre και άλλοι [42]	12 s	Αφαίρεση θορύβου, μετασχηματισμός κυματιδίων	Χαρακτηριστικά κυματιδίων	SVM	Ακρίβεια: 99,46% Ευαισθησία: 100% Ειδικότητα: 98,94%	Cloud

Συγγραφείς	Τμήματα	Προεπεξεργασία	Χαρακτηριστικά	Ταξινόμηση	Αξιολόγηση	Μέθοδος
El Menshawy και άλλοι [43]	3 s	Διατήρηση των 0.1- 60 Hz και αφαίρεση των 50 Hz, μετασχηματισμός κυματιδίων, επιλογή χαρακτηριστικών	Χρονικά και φασματικά χαρακτηριστικά, χαρακτηριστικά εντροπίας και κυματιδίων	K means	-	Cloud
Yoo και άλλοι [44]	2 s	Ζωνοπερατά φίλτρα για δημιουργία 7 ζωνών συχνοτήτων.	Ενεργειακά	SVM	Ακρίβεια: 83.7% 4,5 FD\h Κατανάλωση: 2.03 μ J / ταξινόμηση	Edge
Zhang και άλλοι [45]	2 s με βήμα 1 s	Διαχωρισμός 7 ζωνών συχνοτήτων	Ενεργειακά	SVM	Ακρίβεια: 93% Ευσαιθησία: 95,1% Ειδικότητα: 96,2% Κατανάλωση: 1.85 μ J / ταξινόμηση Καθυστέρηση: 1 s	Edge
Sahani και άλλοι [46]	30 s	Αποσύνθεση σε διάφορες ζώνες συχνοτήτων.	-	CNN, ANN	Ακρίβεια: 99,37% Ευσαιθησία: 100% Ειδικότητα: 99,34% 0,663 FD\h	Edge

Συγγραφείς	Τμήματα	Προεπεξεργασία	Χαρακτηριστικά	Ταξινόμηση	Αξιολόγηση	Μέθοδος
Page και άλλοι [47]	15 s	-	-	CNN	Ευαισθησία: 100% 3,2 FD\24h Καθυστέρηση: 1,47 s Μπαταρία > 80 h	Edge
Moy και άλλοι [48]	-	Ενίσχυση και συμπίεση σημάτων, δημιουργία 8 ζωνών συχνотήτων	Ενεργειακά	SVM	Ποσοστό λάθους < 8%	Edge
Liu και Richardson [49]	0.25, 0.5, 1, 2, 4 s	Υπερδειγματοληψία, ανάθεση βαρών, επιλογή καναλιών	-	LSTM CNN DNN	Ευαισθησία: 97,61% 0,071 FD\h Ευαισθησία: 96,70% 0,102 FD\h Ευαισθησία: 87,36% 0,169 FD\h	Edge
Sopic και άλλοι [50]	-	Μετασχηματισμός κυματιδίων	Χαρακτηριστικά κυματιδίων και ενέργειας	Random Forest	Ευαισθησία: 98,80% Ειδικότητα: 93,37% Μπαταρία: 2,71 μέρες	Edge

Στην μελέτη [50] προτείνεται το φορητό σύστημα e-Glass, για την ανίχνευση επιληπτικών κρίσεων, βάσει των καταγραφών 4 ηλεκτροδίων. Η συσκευή περιέχει μνήμη, επεξεργαστή, μετατροπέα αναλογικού σήματος σε ψηφιακό και Bluetooth. Στον επεξεργαστή γίνεται εντοπισμός κρίσεων με ταξινομητή τυχαίου δάσους. Σε περίπτωση κρίσης, στέλνεται ειδοποίηση στο κινητό τηλέφωνο του ασθενή και μετά ειδοποιείται ο φροντιστής. Το σύστημα αξιολογήθηκε στην εξατομικευμένη και την γενικευμένη ταξινόμηση, αξιοποιώντας το σύνολο CHB-MIT. Στα δεδομένα, εφαρμόστηκε μετασχηματισμός με κυματίδιο Daubechies 4 και υπολογίστηκαν η εντροπία δείγματος, η εντροπία

μετάθεσης, η εντροπία Renyi, η εντροπία Shannon, η εντροπία Tsallis και η συνολική και σχετική ενέργεια σε 7 ζώνες συχνοτήτων. Στην εξατομικευμένη ταξινόμηση, σημειώθηκε 93,80% ευαισθησία και 93,37% ειδικότητα, ενώ στην γενικευμένη 80,82% ευαισθησία και 80,15% ειδικότητα, με την μπαταρία του συστήματος να διαρκεί 2,71 μέρες.

Στην [51] σχεδιάστηκε ένα έξυπνο σύστημα εντοπισμού επιληπτικών κρίσεων. Το σύστημα απαρτίζεται από μια έξυπνη κορδέλα κεφαλής και μια εφαρμογή κινητού. Η κορδέλα περιέχει 3 ηλεκτρόδια, ενισχυτές, φίλτρα, έναν επεξεργαστή και ειδικές μονάδες υπολογισμού. Τα σήματα ΗΕΓ λαμβάνονται από τα ηλεκτρόδια, ενισχύονται και φιλτράρονται. Στον μικροεπεξεργαστή γίνεται περαιτέρω ενίσχυση και μετατροπή των αναλογικών σημάτων σε ψηφιακά. Στις ειδικές μονάδες γίνεται μετασχηματισμός Fourier, υπολογισμός της προσεγγιστικής εντροπίας και ταξινόμηση των σημάτων. Αν ανιχνευτεί επιληπτική κρίση, τα δεδομένα στέλνονται μέσω Bluetooth από την κορδέλα στην εφαρμογή κινητού και από εκεί ανεβαίνουν στο νέφος. Ο γιατρός, μέσω του νέφους, έχει πρόσβαση στα σήματα ΗΕΓ που αντιστοιχούν σε 30-60 δευτερόλεπτα πριν την κρίση και στην κρίση, καθώς και την ημερομηνία, την ώρα και την τοποθεσία, όπου λήφθηκαν τα σήματα. Η ταξινόμηση γίνεται με έναν βελτιστοποιημένο ταξινομητή γραμμικής διακριτικής ανάλυσης, ο οποίος εκπαιδεύτηκε χρησιμοποιώντας τις καταγραφές του συνόλου δεδομένων CHB-MIT. Κατά την αξιολόγηση του συστήματος επιτεύχθηκε 92,68% ακρίβεια με 0,527 ψευδείς ανιχνεύσεις την ώρα και διάρκεια μπαταρίας 30 ωρών.

Στην εργασία [52] παρουσιάζεται ένας επεξεργαστής ανίχνευσης επιληπτικών κρίσεων σε συμπιεσμένα σήματα ΗΕΓ. Αρχικά, τα σήματα εισόδου συμπίεζονται και μέσω ζωνοπερατών φίλτρων εξάγεται η φασματική ενέργεια σε 8 ζώνες συχνοτήτων για κάθε κανάλι ΗΕΓ. Έπειτα, βάσει των χαρακτηριστικών ταξινομούνται με μια μηχανή διανυσμάτων υποστήριξης. Το σύστημα υλοποιήθηκε σε έναν επεξεργαστή και αξιολογήθηκε χρησιμοποιώντας τις καταγραφές ΗΕΓ 21 ασθενών του συνόλου CHB-MIT, χωρισμένες ανά 2 δευτερόλεπτα. Για κατανάλωση ενέργειας 70,8-1,8 nJ σημειώθηκε 96-91% ευαισθησία, καθυστέρηση 4,7- 5,3 δευτερολέπτων και 0,17-03 ψευδείς ανιχνεύσεις την ώρα, αντίστοιχα.

Πίνακας 7: Ενσωματωμένα συστήματα γενικευμένης ανίχνευσης επιληπτικών κρίσεων με δεδομένα του συνόλου CHB-MIT

Συγγραφείς	Τμήματα	Προεπεξεργασία	Χαρακτηριστικά	Ταξινόμηση	Αξιολόγηση	Μέθοδος
Sopic και άλλοι [50]	-	Μετασχηματισμός κυματιδίων	Χαρακτηριστικά κυματιδίων και ενέργειας	Random Forest	Ευαισθησία:	Edge
					80,82%	
					Ειδικότητα:	
					80,15%	
					Μπαταρία:	
					2,71 μέρες	

Lin και άλλοι [51]	-	Ενίσχυση, φιλτράρισμα, μετασχηματισμός Fourier	Χαρακτηριστικά εντροπίας	LDA	Ακρίβεια: 92.68% 0.527 FD\h Μπαταρία: 30 h	Edge
Shoaib και άλλοι [52]	2 s	Συμπίεση και φιλτράρισμα για τη δημιουργία 8 ζωνών συχνοτήτων	Φασματικά	SVM	Ευαισθησία: 96-91% 0,17-0,3 FD\h Καθυστέρηση: 4,7- 5,3 s Κατανάλωση: 70,8-1,8 nJ	Edge

3.3 Ανασκόπηση εμπορικά διαθέσιμων συσκευών

Οι συσκευές εξωκρανιακού εντοπισμού επιληπτικών κρίσεων, εκτός κλινικού περιβάλλοντος, που διατίθενται στην αγορά βασίζονται στην ιδέα της υπολογιστικής νέφους. Ειδικότερα, οι διαθέσιμες συσκευές είναι το epihunter και το mjn-SERAS.

Το epihunter περιέχει μια φορετή κορδέλα κεφαλής με ηλεκτρόδια και μια εφαρμογή έξυπνου κινητού τηλεφώνου. Η κορδέλα συλλέγει δεδομένα, τα οποία αναλύονται και αποθηκεύονται στο νέφος και τελικά αναπαρίστανται στην εφαρμογή. Αν ανιχνευτεί ένα περιστατικό τότε η εφαρμογή το καταγράφει με την κάμερα του κινητού και δημιουργεί μια εγγραφή στο ημερολόγιο του ασθενή, ώστε να αναλυθεί και να αξιολογηθεί μελλοντικά από τον γιατρό του. [53]



Εικόνα 19: Η συσκευή epihunter. [53]

Το mjn-SERAS είναι ένα ακουστικό με αισθητήρες καταγραφής εγκεφαλικών κυμάτων και, λόγω του καινοτόμου σχεδιασμού του, προσφέρει άνεση στους χρήστες. Τα καταγεγραμμένα κύματα στέλνονται σε έναν διακομιστή για αποθήκευση και υπολογισμό της πιθανότητας επιληπτικής κρίσης με εξειδικευμένα μοντέλα Τεχνητής Νοημοσύνης. Ο χρήστης έχει πρόσβαση στις παραγόμενες πληροφορίες και τα στατιστικά σε πραγματικό χρόνο μέσω της αντίστοιχης εφαρμογής έξυπνου κινητού τηλεφώνου. [54]



Εικόνα 20: Η συσκευή mjn-SERAS. [54]

Τέλος, μια υπό ανάπτυξη αλλά αμφιλεγόμενη συσκευή είναι το SeizeIT2. Έχει δημιουργηθεί για να φοριέται πίσω από τα αυτιά από όπου συγκεντρώνει διάφορα βιοσήματα, όπως σήματα ΗΕΓ. Στα επόμενα βήματα, τα μεταδίδει σε έναν χώρο νέφους, παράγει αναφορές σχετικά με την κατάσταση του ασθενή και τις αποθηκεύει για να μελετηθούν από τον γιατρό. [55], [56]



Εικόνα 21: Η συσκευή SeizeIT2. [55]

Στην έρευνα που έγινε στα πλαίσια της πτυχιακής εργασίας, δεν βρέθηκε καμία εμπορικά διαθέσιμη συσκευή εξωκρανιακής ανίχνευσης κρίσεων, βασισμένη στην υπολογιστική άκρης δικτύου.

3.4 Σύνοψη

Οι μεθοδολογίες των εργασιών, που περιγράφονται στις προηγούμενες υποενότητες, βασίζονται τόσο σε μηχανική όσο και σε βαθιά μάθηση, εφαρμόζοντας ένα ευρύ φάσμα διαφορετικών τεχνικών σε κάθε στάδιο ανάλυσης των σημάτων ΗΕΓ. Οι αρχικές έρευνες, που χρησιμοποίησαν το σύνολο CHB-MIT, επικεντρώνονταν στην εξατομικευμένη ανίχνευση επιληπτικών κρίσεων, όμως σταδιακά άρχισαν να δημοσιεύονται και έρευνες με σκοπό την γενικευμένη ανίχνευση. Οι περισσότερες εργασίες ανάπτυξης ενσωματωμένων συστημάτων αφορούν την εξατομικευμένη ανίχνευση κρίσεων μέσω υπολογιστικής στην άκρη του δικτύου.

Στις εργασίες που αξιοποιούν την υπολογιστική νέφους η προεπεξεργασία του σήματος ανατίθεται κυρίως στον επεξεργαστή του ενσωματωμένου συστήματος και οι διεργασίες μηχανικής μάθησης στο νέφος. Σχεδόν σε όλες τις εργασίες που αξιοποιούν υπολογιστική στην άκρη του δικτύου οι διεργασίες εκτελούνται σε κάποιον διακομιστή άκρης ή σε μια σειρά από ειδικές μονάδες, προγραμματισμένες για συγκεκριμένους υπολογισμούς. Μερικές από τις εν λόγω έρευνες δίνουν έμφαση στη χαμηλή

κατανάλωση και την γρήγορη απόκριση, ενώ παράλληλα κάποιες χρησιμοποιούν λίγα κανάλια για τη μείωση του όγκου των δεδομένων. Μόνο μια μελέτη στηρίζεται στην τεχνολογία TinyML, με σκοπό την εξατομικευμένη ανίχνευση επιληπτικών κρίσεων.

Επιπλέον, μελετώντας τις παραπάνω εργασίες δημιουργούνται ερωτήματα για την αντιπροσωπευτικότητα των συνόλων εκπαίδευσης και αξιολόγησης που χρησιμοποιούν. Στις περισσότερες περιπτώσεις γίνεται εξισορρόπηση και των δύο συνόλων, με αποτέλεσμα να δημιουργούνται αναξιόπιστα αποτελέσματα που δεν αντικατοπτρίζουν τη λειτουργία των αλγορίθμων ταξινόμησης σε πραγματικά δεδομένα, τα οποία συνήθως παρουσιάζουν υψηλό βαθμό ανισορροπίας μεταξύ των δύο κλάσεων.

Παρατηρώντας την εξέλιξη της έρευνας, η παρούσα πτυχιακή εργασία στοχεύει στην ανάπτυξη μιας προσέγγισης γενικευμένης ανίχνευσης επιληπτικών κρίσεων με τη βοήθεια της τεχνολογίας TinyML, διερευνώντας την δυνατότητα εκτέλεσης των διαθέσιμων αλγορίθμων σε μικροεπεξεργαστές και επεκτείνοντας την έρευνα της διπλωματικής εργασίας [30].

4 Περιβάλλον ανάπτυξης

Η ανάπτυξη των αλγορίθμων και των μοντέλων αυτής της έρευνας πραγματοποιήθηκε σε ένα υπολογιστικό περιβάλλον, συνιστάμενο από ισχυρά εργαλεία και τεχνολογίες αιχμής. Ειδικότερα, το περιβάλλον στηρίζεται στις παρακάτω 4 τεχνολογίες:

1. Google Colab: Αυτή η υπηρεσία, που παρέχεται δωρεάν από την Google, ήταν ο βασικός χώρος διεξαγωγής των πειραμάτων. Βασίζεται σε ένα διακομιστή νέφους, προσφέροντας επιλογές για την χρήση GPU ή TPU, αυξάνοντας την ταχύτητα των υπολογισμών. Επιπλέον, δίνει τη δυνατότητα σύνδεσης στο Google Drive, αξιοποιώντας τον διαθέσιμο χώρο του. Στην κεντρική σελίδα του Google Colab δημιουργείται ένα βασικό Jupyter Notebook με το οποίο μπορούν να ληφθούν πακέτα, να αναπτυχθούν αλγόριθμοι αλλά και να τρέξουν εκτελέσιμα αρχεία.
2. Python: Η Python είναι μια γλώσσα προγραμματισμού που χρησιμοποιείται ευρέως για την ανάπτυξη αλγορίθμων στον τομέα της μηχανικής μάθησης. Για τη διαχείριση των δεδομένων και τον σχεδιασμό, την εκπαίδευση και αξιολόγηση των μοντέλων χρησιμοποιήθηκαν βιβλιοθήκες της Python, οι οποίες αναλύονται περισσότερο στα αντίστοιχα κεφάλαια. Οι βασικότερες από αυτές είναι η NumPy, η scikit-learn και η Keras/TensorFlow.
3. Edge Impulse – Bring Your Own Model (BYOM): Το Edge Impulse είναι μια δωρεάν πλατφόρμα ανάπτυξης μοντέλων μηχανικής μάθησης για μικροελεγκτές εξαιρετικά χαμηλής κατανάλωσης. Στις αρχές του 2023, οι δημιουργοί του Edge Impulse έδωσαν τη δυνατότητα αξιολόγησης μοντέλων που έχουν αναπτυχθεί σε διαφορετικό περιβάλλον, μέσω του Bring Your Own Model. Εκτός της ιστοσελίδας, όπου ο χρήστης αναρτά το ήδη εκπαιδευμένο μοντέλο, επιλέγει τον επιθυμητό μικροελεγκτή και το Edge Impulse δίνει ως αποτέλεσμα αν το μοντέλο είναι συμβατό

με τον μικροελεγκτή, είναι διαθέσιμη και η αντίστοιχη βιβλιοθήκη Python. Η βιβλιοθήκη παρέχει συναρτήσεις, που ουσιαστικά εκτελούν την ίδια διεργασία με την ιστοσελίδα. Σε αυτή την εργασία η βιβλιοθήκη εγκαταστάθηκε στο Google Colab και βάσει αυτής αξιολογήθηκε η συμβατότητα των μοντέλων με την πλατφόρμα Arduino Nano 33 BLE Sense.

4. Arduino Nano 33 BLE Sense: Πρόκειται για μια πλατφόρμα Arduino που συνδυάζει έναν μικροελεγκτή nRF52840, μια πληθώρα διαφορετικών αισθητήρων, μια μονάδα Bluetooth χαμηλής ενέργειας, αλλά και την ικανότητα εκτέλεσης αλγορίθμων μηχανικής μάθησης αξιοποιώντας τις τεχνολογίες TinyML και TensorFlow Lite. Τα παραπάνω χαρακτηριστικά καθιστούν την πλατφόρμα Arduino Nano 33 BLE Sense ιδανική επιλογή για τους σκοπούς της παρούσας εργασίας.

5 Δεδομένα

Το πρώτο βήμα για την ανάπτυξη ενός μοντέλου μηχανικής μάθησης είναι η συλλογή ή η εύρεση διαθέσιμων δεδομένων, τα οποία θα χρησιμοποιηθούν στην φάση της εκπαίδευσής και αξιολόγησής του. Στην περίπτωση μας, χρειαζόμαστε ένα σύνολο καταγραφών ΗΕΓ επιληπτικών ασθενών, που θα συμπεριλαμβάνει τόσο μη επιληπτικά όσο και επιληπτικά συμβάντα. Ένα τέτοιο σύνολο είναι το CHB-MIT. Σε αυτό το κεφάλαιο, περιγράφονται οι εγγραφές του συνόλου CHB-MIT, ο τρόπος λήψης τους με τη βοήθεια της γλώσσας προγραμματισμού Python και η μεθοδολογία επιλογής συγκεκριμένων καταγραφών ΗΕΓ από τον μεγάλο όγκο καταγραφών του αρχικού συνόλου.

5.1 Σύνολο δεδομένων CHB-MIT

Το σύνολο δεδομένων που χρησιμοποιήθηκε σε αυτήν την έρευνα προήλθε από τη βάση δεδομένων CHB-MIT Scalp EEG [57], [58], η οποία περιλαμβάνει καταγραφές ΗΕΓ κεφαλής που συλλέχθηκαν στο Παιδιατρικό Νοσοκομείο στη Βοστώνη της Μασαχουσέτης. Η διαδικασία συλλογής δεδομένων αφορούσε αρχικά 23 περιπτώσεις, αποτελούμενες από 22 παιδιατρικούς ασθενείς διαγνωσμένων με ανίατη επιληψία. Αργότερα, ένα επιπλέον περιστατικό από διαφορετικό ασθενή ενσωματώθηκε στη βάση. Αυτές οι λήψεις πραγματοποιήθηκαν κατά τη διακοπή της αντιεπιληπτικής φαρμακευτικής αγωγής, ώστε να μελετηθεί η δυνατότητα υποβολής τους σε χειρουργική επέμβαση. Οι ασθενείς παρακολουθήθηκαν για αρκετές ημέρες, με αποτέλεσμα το ολοκληρωμένο σύνολο δεδομένων που περιλαμβάνει συνολικά 198 επιληπτικές κρίσεις. Στο σύνολο περιλαμβάνονται εγγραφές ΗΕΓ από 5 άνδρες ηλικίας μεταξύ 3 και 22 ετών και 17 γυναίκες ηλικίας μεταξύ 1,5 και 19 ετών.

Πίνακας 8: Οι πληροφορίες του συνόλου CHB-MIT

Περίπτωση	Φύλο	Ηλικία	Πλήθος κρίσεων
1	Θ	11	7
2	A	11	3
3	Θ	14	7

Περίπτωση	Φύλο	Ηλικία	Πλήθος κρίσεων
4	A	22	4
5	Θ	7	5
6	Θ	1,5	10
7	Θ	14,5	3
8	A	3,5	5
9	Θ	10	4
10	A	3	7
11	Θ	12	3
12	Θ	2	27
13	Θ	3	12
14	Θ	9	8
15	A	16	20
16	Θ	7	10
17	Θ	12	3
18	Θ	18	6
19	Θ	19	3
20	Θ	6	8
21	Θ	13	4
22	Θ	9	3
23	Θ	6	7
24	-	-	16

Τα σήματα ΗΕΓ του συνόλου δειγματολήφθηκαν με ρυθμό 256 δειγμάτων ανά δευτερόλεπτο, με ανάλυση 16 bit. Κάθε περίπτωση, που δηλώνεται ως chb01, chb02, κ.λπ., περιλαμβάνει από 9 έως 42 διαδοχικά αρχεία τύπου edf, με εγγραφές ΗΕΓ ενός μόνο ασθενούς. Αξίζει να σημειωθεί ότι δύο περιπτώσεις, chb01 και chb21, προέρχονται από την ίδια ασθενή. Στις περισσότερες περιπτώσεις, κάθε αρχείο περιέχει μία ώρα ψηφιοποιημένων σημάτων ΗΕΓ. Ωστόσο, υπάρχουν εξαιρέσεις όπου τα αρχεία έχουν μεγαλύτερη διάρκεια. Τα περισσότερα αρχεία της βάσης περιέχουν δεδομένα από 23 κανάλια ΗΕΓ, όπου τα ηλεκτρόδια είναι τοποθετημένα σύμφωνα με το διεθνές σύστημα 10-20.

Από τα 664 διαθέσιμα αρχεία, τα 129 περιέχουν μία ή περισσότερες επιληπτικές κρίσεις. Οι επιληπτικές κρίσεις εντοπίστηκαν από έναν ειδικό, ο οποίος μελέτησε όλες τις καταγραφές και υπέδειξε τα ακριβή σημεία έναρξης και λήξης κάθε κρίσης.

Τέλος, αρκετές εγγραφές στο σύνολο δεδομένων περιέχουν συμπληρωματικά σήματα. Για παράδειγμα, τα τελευταία 36 αρχεία της περίπτωσης chb04 περιλαμβάνουν σήμα

ηλεκτροκαρδιογραφήματος, ενώ τα τελευταία 18 αρχεία της περίπτωσης chb09 ενσωματώνουν ένα σήμα που σχετίζεται με τη διέγερση του πνευμονογαστρικού νεύρου.

5.2 Λήψη δεδομένων


Η πρόσβαση στα δεδομένα της βάσης CHB-MIT γίνεται μέσω της πλατφόρμας PhysioNet. Για τη λήψη τους ακολουθήθηκε παρόμοια διαδικασία με την εργασία [31], βασισμένη στην εντολή wget. Συγκεκριμένα, από το σύνολο επιλέχθηκαν μόνο οι καταγραφές ΗΕΓ που περιέχουν τουλάχιστον μια επιληπτική κρίση και διατηρούν συνέπεια στα κανάλια. Τα κοινά κανάλια για τους περισσότερους ασθενείς είναι τα FP1-F7, F7-T7, T7-P7, P7-O1, FP1-F3, F3-C3, C3-P3, P3-O1, FP2-F4, F4-C4, C4-P4, P4-O2, FP2-F8, F8-T8, T8-P8, P8-O2, FZ-CZ και CZ-PZ. Οι εγγραφές της περίπτωσης chb12 έχουν ληφθεί με διαφορετικό συνδυασμό καναλιών και γι' αυτό τον λόγο παραλείφθηκαν. Η ανάγνωση των αρχείων κάθε περίπτωσης έγινε μέσω της βιβλιοθήκης PyEDFlib και οι τιμές κάθε καναλιού αποθηκεύτηκαν στην αντίστοιχη στήλη ενός πίνακα NumPy. Στη συνέχεια, σύμφωνα με τις εκτιμήσεις των ειδικών, δημιουργήθηκε η στήλη seizure, η οποία αντιστοιχίζει τα δεδομένα ΗΕΓ με την κλάση στην οποία ανήκουν. Αν ένα δείγμα έχει ληφθεί στο χρονικό διάστημα μιας επιληπτικής κρίσης η αντίστοιχη τιμή της στήλης είναι 1. Σε διαφορετική περίπτωση είναι 0. Τέλος, τα δεδομένα αποθηκεύτηκαν σε ένα αρχείο μορφής csv, ώστε να είναι ευκολότερα προσβάσιμα στα επόμενα βήματα της πτυχιακής εργασίας.

6 Εξαγωγή χαρακτηριστικών

Το επόμενο βήμα συντελεί η εξαγωγή χαρακτηριστικών από το επιλεγμένο υποσύνολο δεδομένων και η περεταίρω επεξεργασία τους, ώστε να μπορέσουν να χρησιμοποιηθούν αποτελεσματικά ως παραδείγματα στη διαδικασία εκμάθησης του μοντέλου. Αυτό το κεφάλαιο επικεντρώνεται στην περιγραφή των χαρακτηριστικών που εξάγονται, στην κανονικοποίηση και στον καθαρισμό του νέου συνόλου χαρακτηριστικών, στην επίλυση του προβλήματος της ισορροπίας των δυο κλάσεων και στον τρόπο διαχωρισμού του συνόλου σε σύνολα εκπαίδευσης και αξιολόγησης. Επιπλέον, για κάθε επεξεργασία, στην οποία υποβάλλονται τα δεδομένα, παρέχεται η αντίστοιχη υλοποίηση στην γλώσσα προγραμματισμού Python, η οποία χρησιμοποιήθηκε στην ανάλυση μας.

6.1 Χαρακτηριστικά

Οι εγγραφές ΗΕΓ, του επιλεγμένου υποσυνόλου, χωρίζονται αρχικά σε τμήματα των 2 δευτερολέπτων. Για κάθε τμήμα στο πεδίο του χρόνου, εξάγονται τα εξής χαρακτηριστικά σε κάθε κανάλι: μέση τιμή, διάμεσος, διακύμανση, τυπική απόκλιση, ασυμμετρία, κύρτωση, ρυθμός διάσχισης του μηδενικού άξονα, ενεργός μέση τιμή, εύρος μεταβολής και εντροπία δείγματος.



Εικόνα 22: Η διαδικασία εξαγωγής χαρακτηριστικών.

Έτσι, το διάνυσμα το χαρακτηριστικών που προκύπτει αποτελείται από 180 χαρακτηριστικά, συνολικά (10 χαρακτηριστικά x 18 κανάλια). Στη συνέχεια της ενότητας, για κάθε χαρακτηριστικό περιγράφεται η στατιστική του σημασία και αναγράφεται ο μαθηματικός του τύπος.

mean 0	var 0	skew0	kurt0	std0	median 0	zrc0	rms0	p2p0	sampEn 0	...	sampEn1 7	seizure
-----------	----------	-------	-------	------	-------------	------	------	------	-------------	-----	--------------	---------

Εικόνα 23: Η μορφή του διανύσματος των χαρακτηριστικών (όπου ο αριθμός συμβολίζει το κανάλι από 0-17).

6.1.1 Μέση τιμή

Η αριθμητική μέση τιμή ή μέσος όρος εκφράζει τον αριθμό που εκπροσωπεί τις τιμές ενός αριθμητικού συνόλου. Υπολογίζεται ως το άθροισμα των τιμών του συνόλου διαιρούμενο με το πλήθος τους.

$$\text{Μέση τιμή} = \bar{x} = \frac{\sum_{i=1}^n x_i}{n}$$

Όπου:

- x_i η κάθε τιμή του συνόλου
- n το πλήθος των τιμών του συνόλου

Ένα σημαντικό μειονέκτημα της μέσης τιμής είναι ότι υπολογίζεται αθροίζοντας όλες τις τιμές του συνόλου, γεγονός που δεν την καθιστά αρκετά αντιπροσωπευτική όταν υπάρχουν ακραίες τιμές.

Στα πλαίσια της πτυχιακής, η μέση τιμή υπολογίζεται στην Python μέσω της μεθόδου `mean` της βιβλιοθήκης NumPy.

6.1.2 Διάμεσος

Η διάμεσος αποτελεί έναν άλλο τρόπο αντιπροσώπευσης των αριθμών ενός συνόλου δεδομένων, ταξινομημένου κατά αύξουσα ή φθίνουσα σειρά. Ουσιαστικά, είναι εκείνος ο αριθμός που βρίσκεται ακριβώς στη μέση, έτσι ώστε το 50% των ταξινομημένων αριθμών να είναι μεγαλύτερο και το άλλο 50% μικρότερο από αυτή. Η διάμεσος υπολογίζεται με δυο τρόπους, ανάλογα με το αν το πλήθος των αριθμών του συνόλου είναι περιττό ή άρτιο όπως φαίνεται παρακάτω.

$$\text{Διάμεσος} = \begin{cases} x_{(n+1)/2}, & \text{αν } n \text{ περιττός} \\ \frac{x_{n/2} + x_{(n/2)+1}}{2}, & \text{αν } n \text{ άρτιος} \end{cases}$$

Όπου:

- n το πλήθος των τιμών του συνόλου

Ένα σημαντικό πλεονέκτημα της διαμέσου είναι ότι δεν παρουσιάζει ευαισθησία στις ακραίες τιμές, σε αντίθεση με τη μέση τιμή.

Στα πλαίσια της πτυχιακής, η διάμεσος υπολογίζεται στην Python μέσω της μεθόδου `median` της βιβλιοθήκης NumPy.

6.1.3 Διακύμανση

Η διακύμανση είναι το στατιστικό μέτρο με το οποίο μελετάται η απόκλιση μεταξύ των τιμών ενός συνόλου δεδομένων. Πιο συγκεκριμένα, εκτιμά την απόσταση κάθε αριθμού από την μέση τιμή και επομένως δείχνει τον βαθμό μεταβλητότητας των δεδομένων γύρω από αυτή. Στη στατιστική, η διακύμανση συμβολίζεται συνήθως ως σ^2 και υπολογίζεται με τον παρακάτω τύπο.

$$\text{Διακύμανση} = \sigma^2 = \frac{\sum_i^n (x_i - \bar{x})^2}{n}$$

Όπου:

- x_i η κάθε τιμή του συνόλου
- $\bar{x}$ η μέση τιμή του συνόλου
- n το πλήθος των τιμών του συνόλου

Στα πλαίσια της πτυχιακής, η διακύμανση υπολογίζεται στην Python μέσω της μεθόδου `var` της βιβλιοθήκης NumPy.

6.1.4 Τυπική απόκλιση

Η τυπική απόκλιση υπολογίζεται ως η τετραγωνική ρίζα της διακύμανσης και δείχνει τη διασπορά των δεδομένων σε σχέση με την μέση τιμή συνόλου. Με άλλα λόγια, όσο πιο απομακρυσμένα είναι τα σημεία από με τη μέση τιμή, τόσο μεγαλύτερη είναι η τυπική απόκλιση.

$$\text{Τυπική απόκλιση} = \sigma = \sqrt{\frac{\sum_i^n (x_i - \bar{x})^2}{n}}$$

Όπου:

- x_i η κάθε τιμή του συνόλου
- $\bar{x}$ η μέση τιμή του συνόλου
- n το πλήθος των τιμών του συνόλου

Στα πλαίσια της πτυχιακής, η τυπική απόκλιση υπολογίζεται στην Python μέσω της μεθόδου `std` της βιβλιοθήκης NumPy.

6.1.5 Ασυμμετρία


Η ασυμμετρία ή λοξότητα περιγράφει την έλλειψη συμμετρίας που παρουσιάζει μια κατανομή. Στην γραφική παράσταση συναντάται όταν τα σημεία του συνόλου δεν κατανέμονται συμμετρικά μεταξύ της αριστερής και της δεξιάς πλευράς της καμπύλης καμπάνας. Ο τύπος υπολογισμού της ασυμμετρίας είναι ο εξής:

$$\text{Ασυμμετρία} = \frac{\sum_i^n (x_i - \bar{x})^3}{n\sigma^3}$$

Όπου:

- x_i η κάθε τιμή του συνόλου
- $\bar{x}$ η μέση τιμή του συνόλου
- σ η τυπική απόκλιση του συνόλου
- n το πλήθος των τιμών του συνόλου

Εάν οι περισσότερες τιμές βρίσκονται αριστερά της μέσης τιμής παρατηρείται θετική ασυμμετρία, ενώ εάν οι περισσότερες τιμές βρίσκονται δεξιά της μέσης τιμής παρατηρείται αρνητική ασυμμετρία. Η κανονική κατανομή έχει μηδενική ασυμμετρία και έτσι η ασυμμετρία δείχνει τον βαθμό απόκλισης μιας δεδομένης κατανομής από αυτή.



Εικόνα 24: Παράδειγμα αρνητικής και θετικής λοξότητας. [59]

Στα πλαίσια της πτυχιακής, η ασυμμετρία υπολογίζεται στην Python μέσω της συνάρτησης `skew`, που παρέχεται στην ενότητα `stats` της βιβλιοθήκης `SciPy`.

6.1.6 Κύρτωση


Η κύρτωση είναι το στατιστικό μέτρο που περιγράφει την πλάτυνση μιας κατανομής. Η γραφική παράσταση της κανονικής κατανομής έχει τη μορφή καμπύλης καμπάνας. Τα δεδομένα που απέχουν περισσότερο από τη μέση τιμή του συνόλου συνήθως σχηματίζουν δυο ουρές σε κάθε πλευρά της καμπύλης. Η κύρτωση εκφράζει το πλήθος των δεδομένων που βρίσκονται στις ουρές και εκτιμάται με την παρακάτω εξίσωση.

$$\text{Κύρτωση} = \frac{\sum_i^n (x_i - \bar{x})^4}{n\sigma^4}$$

Όπου:

- x_i η κάθε τιμή του συνόλου
- $\bar{x}$ η μέση τιμή του συνόλου
- σ η τυπική απόκλιση του συνόλου
- n το πλήθος των τιμών του συνόλου

Οι κατανομές με μεγάλη κύρτωση έχουν τις ουρές κοντά στη μέση τιμή και ονομάζονται λεπτόκυρτες. Οι κατανομές με χαμηλή κύρτωση έχουν περισσότερο απομακρυσμένες ουρές από τη μέση τιμή και ονομάζονται πλατύκυρτες.



Εικόνα 25: Παράδειγμα λεπτόκυρτης, μεσόκυρτης και πλατύκυρτης κατανομής. [59]

Στα πλαίσια της πτυχιακής, η κύρτωση υπολογίζεται στην Python μέσω της συνάρτησης `kurtosis`, που παρέχεται στην ενότητα `stats` της βιβλιοθήκης `SciPy`.

6.1.7 Ρυθμός διάσχισης μηδενικού άξονα


Ο ρυθμός διάσχισης του μηδενικού άξονα είναι ο ρυθμός με τον οποίο εναλλάσσεται το πρόσημο ενός σήματος. Συμβολίζει δηλαδή πόσες φορές η κυματομορφή αλλάζει τιμή από θετική σε αρνητική και το αντίστροφο και εκτιμάται ως:

$$\text{Ρυθμός διάσχισης του μηδενικού άξονα} = ZCR = \frac{1}{2n} \sum_{i=2}^n |\text{sgn}(x_i) - \text{sgn}(x_{i-1})|$$

Όπου:

- x_i η κάθε τιμή του συνόλου
- n το πλήθος των τιμών του συνόλου

$$\text{Με } \text{sgn}(x) = \begin{cases} -1, & x < 0 \\ 1, & x \geq 0 \end{cases}$$



Εικόνα 26: Παράδειγμα διασχίσεων του μηδενικού άξονα. [60]

Στα πλαίσια της πτυχιακής, ο ρυθμός διάσχισης του μηδενικού άξονα υπολογίζεται στην Python με τη βοήθεια της βιβλιοθήκης `Math`.

6.1.8 Ενεργός μέση τιμή

Ως ενεργός μέση τιμή του σήματος ή τετραγωνικός μέσος όρος ονομάζεται η τετραγωνική ρίζα των μέσων τετραγώνων των τιμών του συνόλου.

$$\text{Ενεργός μέση τιμή} = RMS = \sqrt{\frac{\sum_{i=1}^n x_i^2}{n}}$$

Όπου:

- x_i η κάθε τιμή του συνόλου

- n το πλήθος των τιμών του συνόλου

Η ενεργός μέση τιμή μιας κυματομορφής είναι ένα σημαντικό στατιστικό μέτρο, διότι δείχνει πόση ενέργεια περιέχεται σε αυτή.

Στα πλαίσια της πτυχιακής η ενεργός μέση τιμή υπολογίζεται στην Python με τη βοήθεια της βιβλιοθήκης Math.


6.1.9 Εύρος μεταβολής

Το εύρος μεταβολής εκφράζει τη μεταβολή του σήματος και υπολογίζεται ως η διαφορά μεταξύ της υψηλότερης και της χαμηλότερης τιμής που παρατηρούνται σε μια κυματομορφή.

$$\text{Εύρος μεταβολής} = PP = x_{max} - x_{min}$$

Όπου:

- x_{max} η μέγιστη τιμή του συνόλου
- x_{min} η ελάχιστη τιμή του συνόλου



Εικόνα 27: Παράδειγμα εύρους μεταβολής σε μια κυματομορφή. [61]

Στα πλαίσια της πτυχιακής, το εύρος μεταβολής υπολογίζεται στην Python με τη βοήθεια της βιβλιοθήκης Math.

6.1.10 Εντροπία δείγματος

Η εντροπία δείγματος [62] βασίζεται στην προσεγγιστική εντροπία, χωρίζοντας το σύνολο σε διανύσματα μικρότερου μεγέθους και συγκρίνοντας την ομοιότητα μεταξύ τους για τον εντοπισμό προτύπων. Η ομοιότητα υπολογίζεται για κάθε ζεύγος διανυσμάτων με μια συνάρτηση ϕ και εξαρτάται από την ανοχή, καθορίζει το όριο τη μέγιστη επιτρεπτή διαφορά για να θεωρείται όμοιο ένα ζεύγος διανυσμάτων. Η εντροπία δείγματος υπολογίζεται ως:

$$\text{Εντροπία δείγματος} = \text{SampEn}(x, m, r) = \log \phi^m(r) - \log \phi^{m+1}(r),$$

$$\text{με } \phi^m(r) = \sum_{j=0, j \neq i}^{n-m} \sum_{i=0}^{n-m} \Theta(r - \|u_i - u_j\|_{\infty})$$

Όπου:

- $\Theta(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases}$ η μοναδιαία συνάρτηση βηματισμού Heaviside
- u_i, u_j κάθε ζεύγος διανυσμάτων παραθύρου, με $u_i = [x_i \ x_{i+1} \ \dots \ x_{i+m-1}]^T$ και u_j αντίστοιχα.
- r η ανοχή
- m το μέγεθος του προτύπου

- n το πλήθος των τιμών του αρχικού συνόλου

Δηλαδή η εντροπία δείγματος ορίζεται ως ο αρνητικός φυσικός λογάριθμος του πηλίκου του πλήθους των όμοιων ζευγών με μέγεθος προτύπου m προς το πλήθος των όμοιων ζευγαριών με μέγεθος προτύπου $m+1$. Αξίζει να τονιστεί ότι η εντροπία δείγματος χρησιμοποιείται συχνά σε εφαρμογές βιοϊατρικής για τη διάγνωση νοσημάτων, εφόσον αποτελεί ένα μέτρο αξιολόγησης της πολυπλοκότητας σημάτων φυσιολογίας που λαμβάνονται μέσω ιατρικών εξετάσεων.

Στα πλαίσια της πτυχιακής, η εντροπία δείγματος υπολογίζεται στην Python μέσω της συνάρτησης `entropy` της βιβλιοθήκης `Pyentrp`.

6.2 Κανονικοποίηση και καθαρισμός συνόλου

Η κανονικοποίηση αποτελεί μια διαδικασία αλλαγής της κλίμακας των χαρακτηριστικών, ώστε οι τιμές τους να βρίσκονται σε παρόμοιο εύρος. Είναι σημαντική για την ανάλυση, μοντελοποίηση και απόδοση των αλγορίθμων ταξινόμησης, καθώς αρκετές διαδικασίες μηχανικής μάθησης είναι ευαίσθητες στις μεγάλες αποκλίσεις στο εύρος των χαρακτηριστικών.

Σε αυτή την πτυχιακή εργασία χρησιμοποιείται η κανονικοποίηση z -score, συμβολίζεται με το γράμμα z και υπολογίζεται ως εξής:

$$z = \frac{x - \bar{x}}{\sigma}$$

Όπου:

- x η μη κανονικοποιημένη τιμή
- $\bar{x}$ η μέση τιμή του συνόλου
- σ η τυπική απόκλιση του συνόλου

Μετά την κανονικοποίηση κάθε χαρακτηριστικό έχει $\bar{x} = 0$ και $\sigma = 1$, ακολουθεί δηλαδή τυπική κανονική κατανομή. Πρακτικά, η κανονικοποίηση στα δεδομένα έγινε εφαρμόζοντας τη συνάρτηση `StandardScaler` που παρέχεται στην ενότητα `preprocessing` της βιβλιοθήκης της Python `scikit-learn` και υλοποιεί τους παραπάνω υπολογισμούς.

Επίσης, πριν προχωρήσουμε στα επόμενα βήματα είναι απαραίτητος ο καθαρισμός του συνόλου και συγκεκριμένα η διαχείριση των μη αριθμητικών και άπειρων τιμών. Οι μη αριθμητικές τιμές, γνωστές και ως `nan`, προκύπτουν συνήθως από σφάλματα κατά τη συλλογή δεδομένων ή απλά από την έλλειψη επαρκών παρατηρήσεων. Οι τιμές που αντιστοιχούν σε θετικό ή αρνητικό άπειρο μπορεί να είναι αποτέλεσμα μαθηματικών πράξεων κατά την εξαγωγή χαρακτηριστικών, όπως για παράδειγμα η διαίρεση με το 0. Στα πλαίσια αυτής της εργασίας, οι συγκεκριμένες τιμές διαγράφονται την ποιότητα και αξιοπιστία των υπόλοιπων δεδομένων. Συγκεκριμένα, στο διάνυσμα των χαρακτηριστικών εφαρμόζεται πρώτα η μέθοδος `replace`, για την αντικατάσταση των άπειρων τιμών με `nan`, και έπειτα η μέθοδος `dropna` για την διαγραφή των γραμμών που περιέχουν μη αριθμητικές τιμές.

6.3 Επιλογή χαρακτηριστικών

Ένα κρίσιμο πρόβλημα στη μηχανική μάθηση είναι η «κατάρτα της διαστασιμότητας», η οποία προκύπτει όταν ένα σύνολο δεδομένων έχει έναν μεγάλο αριθμό χαρακτηριστικών. Η μείωση των διαστάσεων γίνεται λαμβάνοντας υπόψη μόνο τις σημαντικότερες πληροφορίες και συχνά οδηγεί σε πιο αποδοτικά μοντέλα με λιγότερες υπολογιστικές απαιτήσεις. Μια προσέγγιση για τη μείωση των διαστάσεων είναι η επιλογή χαρακτηριστικών, μέσω της οποίας εξάγεται ένα υποσύνολο αποτελούμενο από τα χαρακτηριστικά που έχουν την υψηλότερη συνεισφορά στο αποτέλεσμα της ταξινόμησης, εξαλείφοντας όλα τα υπόλοιπα.

Το σύνολο δεδομένων που αξιοποιείται στην έρευνά μας, περιέχει 180 χαρακτηριστικά (10 στατιστικά μέτρα x 18 κανάλια). Εφόσον, στοχεύουμε στην ανάπτυξη αποτελεσματικών μοντέλων ικανών να εκτελούνται σε περιβάλλοντα περιορισμένων πόρων, θεωρήθηκε σημαντική η μείωση του χώρου των χαρακτηριστικών διατηρώντας τα σημαντικότερα από αυτά. Γι' αυτό τον λόγο εφαρμόστηκε η τεχνική επιλογής των k καλύτερων χαρακτηριστικών (K best feature selection), η οποία αναλύεται στη συνέχεια της υποενότητας.

6.3.1 K καλύτερα χαρακτηριστικά

Η μέθοδος επιλογής των k καλύτερων χαρακτηριστικών είναι σχετικά απλή και βασίζεται σε προσεγγίσεις της στατιστικής. Ειδικότερα σε κάθε χαρακτηριστικό αντιστοιχίζεται μια βαθμολογία, η οποία εκφράζει τη στατιστική του σημασία ή αλλιώς τη συνεισφορά του στην ταξινόμηση. Τα k χαρακτηριστικά που πετυχαίνουν την υψηλότερη βαθμολογία είναι και εκείνα που τελικά επιλέγονται. Η συνάρτηση βαθμολόγησης καθορίζεται ανάλογα με το πρόβλημα, ενώ συνήθως δοκιμάζονται και συγκρίνονται διαφορετικές τιμές για το k . Στην παρούσα εργασία, έγινε επιλογή 90, 45, 25 και 12 χαρακτηριστικών από τα 180 του αρχικού συνόλου, ώστε να διερευνηθεί αν για κάποια τιμή μπορεί να επιτευχθεί ένας ικανοποιητικός συμβιβασμός μεταξύ των επιδόσεων ενός μοντέλου και της υπολογιστικής του κατανάλωσης.

Στην Python η επιλογή των k καλύτερων χαρακτηριστικών έγινε μέσω της συνάρτησης `SelectKBest`, που βρίσκεται στην ενότητα `feature_selection` της βιβλιοθήκης `scikit-learn`. Ως ορίσματα δόθηκαν οι διάφορες τιμές του k . Η βαθμολογία του κάθε χαρακτηριστικού υπολογίστηκε με την προεπιλεγμένη συνάρτηση ANOVA F-value, καθώς είναι κατάλληλη για εργασίες παλινδρόμησης και ταξινόμησης.

6.4 Εξισορρόπηση συνόλου

Όταν σε ένα σύνολο δεδομένων μια κλάση υπερτερεί σημαντικά της άλλης παρατηρείται το πρόβλημα της ανισορροπίας των κλάσεων. Η κλάση στην οποία ανήκει το μεγαλύτερο πλήθος δειγμάτων ονομάζεται επικρατούσα κλάση, ενώ η κλάση με τα λιγότερα δείγματα χαρακτηρίζεται ως μειονεκτούσα κλάση. Η μεγάλη διαφορά στο πλήθος των περιπτώσεων που ανήκουν σε κάθε κατηγορία αποτελεί πρόκληση, διότι κατά την ταξινόμηση οι περισσότεροι αλγόριθμοι μηχανικής μάθησης θεωρούν τα

δεδομένα εισόδου ισορροπημένα και τείνουν να ευνοούν την επικρατούσα κλάση, οδηγώντας σε μεροληπτικά αποτελέσματα και χαμηλά ποσοστά γενίκευσης.

Η ανισορροπία μεταξύ των κλάσεων συναντάται σε πολλά σύνολα δεδομένων του πραγματικού κόσμου. Στην περίπτωση της επιληψίας τα δεδομένα που αντιπροσωπεύουν την επιληπτική κρίση είναι πολύ λιγότερα από αυτά που αντιπροσωπεύουν την μη επιληπτική κρίση. Επομένως είναι λογικό να μην υπάρχει ισορροπία μεταξύ των κλάσεων όπως παρατηρείται και στα επιλεγμένα δεδομένα του συνόλου CHB-MIT. Η ανισορροπία αντιμετωπίζεται με διάφορους τρόπους

Μια λύση είναι η εξισορρόπηση του συνόλου και μπορεί να πραγματοποιηθεί εφαρμόζοντας:

- Υποδειγματοληψία της επικρατούσας κλάσης, με αφαίρεση πλεοναζόντων δειγμάτων
- Υπερδειγματοληψία της μειονεκτούσας κλάσης, με αντιγραφή δειγμάτων ή σύνθεση νέων

Στην παρούσα εργασία για την αντιμετώπιση της ανισορροπίας των δυο κλάσεων επιλέξαμε να αποφύγουμε την δημιουργία συνθετικών δειγμάτων, επειδή τα νέα δείγματα μπορεί να έχουν μεγάλη ομοιότητα μειώνοντας την ικανότητα γενίκευσης των μοντέλων. Επομένως, αξιοποιήθηκε η τεχνική Cluster Centroids για την υποδειγματοληψία της επικρατούσας κλάσης, που αντιστοιχεί στην «μη επιληπτική κρίση».

Άλλη μια λύση που εφαρμόζεται στα πλαίσια της πτυχιακής εργασίας είναι η αλλαγή του κατωφλίου των ταξινομητών, αξιοποιώντας την καμπύλη ROC.


6.4.1 Cluster Centroids

Η τεχνική υποδειγματοληψίας Cluster Centroids έχει σχεδιαστεί ειδικά για την επίλυση του προβλήματος της ανισορροπίας των κλάσεων και βασίζεται σε μεθόδους ομαδοποίησης.

Τα βασικά βήματα που ακολουθεί ο αλγόριθμος του Cluster Centroids είναι τα εξής:

- 1) Ομαδοποίηση των δειγμάτων της επικρατούσας κλάσης, χρησιμοποιώντας τον αλγόριθμο k-means.
- 2) Επιλογή του κεντρικού δείγματος της κάθε ομάδας, το οποίο αντιπροσωπεύει τον μέσο όρο των δειγμάτων που ανήκουν σε αυτή.
- 3) Αντικατάσταση των δειγμάτων της επικρατούσας κλάσης με τα κεντρικά δείγματα.

Εφαρμόζοντας την παραπάνω μέθοδο παραλήφθηκαν αρκετά δείγματα που αντιστοιχούσαν σε «μη επιληπτική κρίση», εξισορροπώντας το σύνολο δεδομένων.



Εικόνα 28: Τα δεδομένα μετά την εφαρμογή Cluster Centroids.

Στην Python η υποδειγματοληψία έγινε μέσω της συνάρτησης `ClusterCentroids`, που βρίσκεται στην ενότητα `undersampling_sampling` της βιβλιοθήκης διαχείρισης μη εξισορροπημένων δεδομένων `imblearn`.

6.4.2 Αλλαγή κατωφλίου

Συνήθως, οι αλγόριθμοι δυαδικής ταξινόμησης, αφού υπολογίσουν την πιθανότητα ενός δείγματος, ελέγχουν αν αυτή είναι μεγαλύτερη του 0,5. Αν είναι την αντιστοιχούν στην κλάση 1, ενώ σε αντίθετη περίπτωση την αντιστοιχούν στην κλάση 0. Με άλλα λόγια η τιμή 0,5 αποτελεί την τιμή του κατωφλίου απόφασης. Μια αποτελεσματική μέθοδος διαχείρισης της ανισορροπίας των κλάσεων είναι η αλλαγή αυτού του κατωφλίου, καθώς η πιθανότητα να προκύψει η μια κλάση είναι πολύ μικρότερη από την πιθανότητα να προκύψει η άλλη.

Η καμπύλη ROC είναι μια γραφική παράσταση του ποσοστού αληθώς θετικών προβλέψεων (ευαισθησία) έναντι του ποσοστού ψευδώς θετικών προβλέψεων για διαφορετικά κατώφλια. Ουσιαστικά, παρέχει μια ολοκληρωμένη εικόνα της απόδοσης ενός μοντέλου σε διάφορα όρια διάκρισης. Τις περισσότερες φορές το σημείο στην καμπύλη ROC που βρίσκεται πιο κοντά στην επάνω αριστερή γωνία αντιπροσωπεύει τον ιδανικό συμβιβασμό μεταξύ ευαισθησίας και ειδικότητας. Κατά την αλλαγή κατωφλίου τείνει να επιλέγεται αυτό το σημείο ως νέο κατώφλι, καθώς μεγιστοποιεί το ποσοστό των αληθώς θετικών ενώ ελαχιστοποιεί το ποσοστό των ψευδώς θετικών.

Στην Python η καμπύλη ROC εξάγεται μέσω της συνάρτησης `roc_curve`, που βρίσκεται στην ενότητα `metrics` της βιβλιοθήκης `scikit-learn` και το βέλτιστο κατώφλι υπολογίζεται με τη βοήθεια των συναρτήσεων της βιβλιοθήκης `NumPy`.

6.5 Διαχωρισμός συνόλου

Η διαίρεση ενός συνόλου δεδομένων σε υποσύνολα εκπαίδευσης και αξιολόγησης είναι ένα απαραίτητο βήμα στην διαδικασία ανάπτυξης μοντέλων μηχανικής μάθησης. Το σύνολο εκπαίδευσης χρησιμοποιείται ώστε το μοντέλο να μάθει να διαφοροποιεί τις κλάσεις, ενώ το σύνολο αξιολόγησης

χρησιμοποιείται ώστε να εξεταστεί η ικανότητα του μοντέλου να ταξινομεί σωστά άγνωστα σε αυτό δείγματα. Στα πλαίσια της πτυχιακής εργασίας, ο διαχωρισμός των συνόλων έγινε αξιοποιώντας δύο τρόπους, τον διαχωρισμό 70-30 και τη διασταυρωμένη επικύρωση k τμημάτων. Σε αυτή την ενότητα περιγράφονται αναλυτικά και οι δυο προσεγγίσεις.

6.5.1 Διαχωρισμός 70-30

Ο διαχωρισμός 70-30 αποτελεί μια τεχνική κατά την οποία 70% του συνόλου ορίζεται ως το σύνολο εκπαίδευσης και το υπόλοιπο 30% ως το σύνολο αξιολόγησης. Η αναλογία διαίρεσης των δεδομένων επιλέγεται με βάση το πλήθος των διαθέσιμων δειγμάτων και επηρεάζει σημαντικά τη συνολική επίδοση των ταξινομητών. Εφόσον, διαθέτουμε περιορισμένα δεδομένα, η συγκεκριμένη αναλογία μας επιτρέπει να αξιοποιήσουμε ένα επαρκές μέρος των δεδομένων για την εκμάθηση των μοντέλων, διατηρώντας παράλληλα ένα σημαντικό ποσοστό δειγμάτων για την αξιολόγηση.

6.5.2 Διασταυρωμένη επικύρωση k τμημάτων

Η διασταυρωμένη επικύρωση k τμημάτων είναι μια μέθοδος μηχανικής μάθησης που χρησιμοποιείται ευρέως για την αξιολόγηση ταξινομητών. Ουσιαστικά καταφέρνει να υπολογίσει πιο δίκαια την συνολική απόδοση και δυνατότητα γενίκευσης ενός μοντέλου, σε σχέση με τον απλό διαχωρισμό.

Τα βήματα της μεθόδου αναλύονται παρακάτω:

- 1) Το σύνολο δεδομένων χωρίζεται σε k μη επικαλυπτόμενα υποσύνολα περίπου ίσου μεγέθους.
- 2) Το μοντέλο εκπαιδεύεται και δοκιμάζεται k φορές, με κάθε επανάληψη να χρησιμοποιεί ένα διαφορετικό τμήμα ως σύνολο δοκιμής και τα υπόλοιπα $k-1$ τμήματα ως ένα ενιαίο σύνολο εκπαίδευσης.
- 3) Μετά από κάθε γύρο εκπαίδευσης και αξιολόγησης, καταγράφονται ορισμένες μετρήσεις απόδοσης (όπως η ακρίβεια, η ευαισθησία και η ειδικότητα). Αυτές οι μετρήσεις περιγράφουν την αποτελεσματικότητα του μοντέλου σε μια επανάληψη.
- 4) Για να επιτευχθεί μια ολοκληρωμένη αξιολόγηση, υπολογίζεται ο μέσος όρος των μετρήσεων απόδοσης για όλες τις k επαναλήψεις. Έτσι παρέχεται μια ολοκληρωμένη εικόνα της απόδοσης του μοντέλου.

Εκτός της πιο αξιόπιστης αξιολόγησης του μοντέλου, η διασταυρωμένη επικύρωση k τμημάτων έχει το πλεονέκτημα να εντοπίζει τάσεις υπερπροσαρμογής των αλγορίθμων, αξιοποιώντας k δυνατούς συνδυασμούς δεδομένων εκπαίδευσης και αξιολόγησης. Το κύριο μειονέκτημά της είναι ότι αποτελεί μια χρονοβόρα διεργασία, αφού το μοντέλο ταξινόμησης πρέπει να εκπαιδευτεί k φορές.



Εικόνα 29: Παράδειγμα διασταρωμένης επικύρωσης k τμημάτων με k ίσο με 4. [65]

Η επιλογή του αριθμού επαναλήψεων k εξαρτάται από το μέγεθος των δεδομένων και τις απαιτήσεις του προβλήματος. Συνηθίζεται να επιλέγονται οι τιμές 5 ή 10, όμως σε ορισμένες περιπτώσεις άλλες τιμές είναι καταλληλότερες. Εδώ επιλέγουμε k ίσο με 5.

Ο διαχωρισμός του συνόλου υλοποιείται με τη συνάρτηση `KFold`, που ανήκει στην ενότητα `model_selection` της βιβλιοθήκης `scikit-learn`. Στη συνάρτηση δίνεται ως όρισμα η τιμή του k και η τιμή του `shuffle` θέτεται ως `true`, ώστε να αναμιχθούν τυχαία τα δείγματα κατά τον διαχωρισμό.


7 Αλγόριθμοι ταξινόμησης

Ο σκοπός των αλγορίθμων ταξινόμησης ή ταξινομητών είναι η αναγνώριση της κλάσης στην οποία ανήκει η κάθε εγγραφή του συνόλου των χαρακτηριστικών. Αφού κατασκευαστούν οι ταξινομητές, εκπαιδεύονται με το σύνολο εκπαίδευσης, ώστε να μάθουν τις σημαντικές πληροφορίες που διαφοροποιούν τις κλάσεις μεταξύ τους. Στη συνέχεια, δοκιμάζεται η ικανότητά τους να ξεχωρίζουν τις κλάσεις σε δεδομένα που δεν χρησιμοποιήθηκαν κατά την εκπαίδευση, δηλαδή στο σύνολο αξιολόγησης.

Στο παρόν κεφάλαιο περιγράφονται οι αλγόριθμοι ταξινόμησης που αναπτύχθηκαν στα πλαίσια της έρευνάς μας, συμπεριλαμβανομένης της λειτουργίας τους, των μαθηματικών στα οποία στηρίζονται και την υλοποίησή τους στη γλώσσα προγραμματισμού Python, την οποία στηριχθήκαμε και σε αυτό το στάδιο της εργασίας.

7.1 Γραμμική διακριτική ανάλυση

Η γραμμική διακριτική ανάλυση (Linear Discriminant Analysis - LDA) είναι μια τεχνική μείωσης διαστάσεων, η οποία συχνά εφαρμόζεται και σε προβλήματα ταξινόμησης. Στην μείωση διαστάσεων, στοχεύει στην προβολή των σημείων ενός συνόλου σε έναν χώρο χαμηλότερης διάστασης, ο οποίος μεγιστοποιεί τη διακριτικότητα μεταξύ των κλάσεων. Στην ταξινόμηση, με την ίδια μεθοδολογία καθορίζει τα γραμμικά όρια απόφασης εξάγοντας τους απαραίτητους κανόνες.



Εικόνα 30: Τα βήματα της Γραμμικής Διακριτικής Ανάλυσης. Α. Μη γραμμικώς διαχωρίσιμα δεδομένα Β. Υπολογισμός νέου άξονα. Γ. Προβολή των σημείων στον νέο άξονα.

Πηγή: Προσαρμοσμένο από [66]

Μαθηματικά, οι διαστάσεις του συνόλου μειώνονται μέσω ενός πίνακα μετασχηματισμού, ο οποίος αντιστοιχίζει τον αρχικό χώρο χαρακτηριστικών σε έναν χώρο χαμηλότερης διάστασης. Στον νέο χώρο, τα σημεία που ανήκουν στην ίδια κλάση τείνουν να συγκεντρώνονται μαζί, με αποτέλεσμα οι κλάσεις είναι να καλά διαχωρισμένες. Για παράδειγμα στην Εικόνα 30, φαίνεται ο μετασχηματισμός ενός δυσδιάστατου χώρου σε μονοδιάστατο βάσει των αξόνων x και y του αρχικού χώρου.

Ο νέος χώρος χρειάζεται να ικανοποιεί τα παρακάτω κριτήρια:

- Να μεγιστοποιεί την απόσταση μεταξύ των μέσων τιμών των δυο κλάσεων
- Να ελαχιστοποιεί την διακύμανση κάθε κλάσης

Θεωρώντας ότι έχουμε 2 κλάσεις, αυτό επιτυγχάνεται βρίσκοντας την μέγιστη ιδιοτιμή λ και το αντίστοιχο ιδιοδιάνυσμα u , λύνοντας την εξίσωση:

$$Mu = \lambda u, \text{ με } M = s_w^{-1} s_b, \lambda = \frac{u^T s_b u}{u^T s_w u} \text{ και}$$

$$s_b = (\bar{x}_1 - \bar{x}_2)(\bar{x}_1 - \bar{x}_2)^T, s_w = \sum_i^{n_1} (x_i - \bar{x}_1)(x_i - \bar{x}_1)^T + \sum_i^{n_2} (x_i - \bar{x}_2)(x_i - \bar{x}_2)^T$$

Όπου:

- x_i η κάθε τιμή του συνόλου
- $\bar{x}_1, \bar{x}_2$ η μέση τιμή των δειγμάτων που ανήκουν σε κάθε κλάση αντίστοιχα
- n_1, n_2 το πλήθος των δειγμάτων που ανήκουν σε κάθε κλάση αντίστοιχα


Ένας βασικός περιορισμός της γραμμικής διακριτικής ανάλυσης είναι οι θεωρήσεις ότι τα δεδομένα ακολουθούν κανονική κατανομή, οι πίνακες συνδιακύμανσης των διαφορετικών κλάσεων είναι ίσοι και τα δεδομένα είναι γραμμικά διαχωρίσιμα. Αν οι παραπάνω υποθέσεις δεν ισχύουν, μπορεί να επηρεαστεί αρνητικά η επίδοση του ταξινομητή.

Η υλοποίηση του αλγορίθμου LDA στην Python, γίνεται με τη συνάρτηση `LinearDiscriminantAnalysis`, που ανήκει στην ενότητα `discriminant_analysis` της βιβλιοθήκης `scikit-learn`. Στη συνάρτηση δεν δίνονται ορίσματα, διατηρώντας τις προκαθορισμένες παράμετρούς της.

7.2 Λογιστική παλινδρόμηση

Η λογιστική παλινδρόμηση (Logistic Regression) αποτελεί έναν θεμελιώδη αλγόριθμο ταξινόμησης στην μηχανική μάθηση. Είναι παρόμοια με την Γραμμική Παλινδρόμηση, όμως αντί να δίνει ως έξοδο τις τιμές 0 και 1 δίνει τις πιθανές τιμές που βρίσκονται ενδιάμεσα. Το μοντέλο Λογιστικής Παλινδρόμησης μετατρέπει την τιμή εισόδου σε έξοδο κατηγορικής τιμής χρησιμοποιώντας μια σιγμοειδή συνάρτηση ως συνάρτηση κατωφλίου.

Η σιγμοειδής ή λογιστική συνάρτηση είναι μια μαθηματική συνάρτηση που μετατρέπει τις τιμές μιας συνεχούς μεταβλητής σε πιθανότητες, δηλαδή σε τιμές που κυμαίνονται από 0 έως 1. Αφού υπολογιστούν οι πιθανότητες, συγκρίνονται με μια τιμή κατωφλίου με την οποία ορίζεται αν η πιθανότητα ανήκει σε μια κλάση. Με άλλα λόγια, οι πιθανότητες πάνω από την τιμή κατωφλίου τείνουν στο 1 και οι πιθανότητες κάτω από την τιμή κατωφλίου τείνουν στο 0. Στην Εικόνα 31 φαίνεται η γραφική παράσταση της λογιστικής συνάρτησης.



Εικόνα 31: Η σιγμοειδής συνάρτηση. [67]

Η πιθανότητα να ανήκει ένα δείγμα σε μια κλάση δίνεται από την συνάρτηση κατωφλίου:

$$f(w \cdot x) = \frac{1}{1 + e^{-w \cdot x}}$$

Όπου:

- x το διάνυσμα των χαρακτηριστικών
- w το διάνυσμα των βαρών, το οποίο προκύπτει από την ελαχιστοποίηση της συνάρτησης απώλειας στα δεδομένα εκπαίδευσης

Η υλοποίηση της λογιστικής παλινδρόμησης στην Python, γίνεται με τη συνάρτηση `LogisticRegression`, που ανήκει στην ενότητα `linear_model` της βιβλιοθήκης `scikit-learn`. Στη συνάρτηση δεν δίνονται ορίσματα, διατηρώντας τις προκαθορισμένες παράμετρούς της.

7.3 Μηχανές διανυσμάτων υποστήριξης

Οι μηχανές διανυσμάτων υποστήριξης (Support Vector Machine - SVM) θεωρούνται μια από τις πιο διαδεδομένες μεθόδους ταξινόμησης και παλινδρόμησης. Στην ταξινόμηση, μια SVM επιδιώκει να βρει ένα όριο απόφασης σε έναν χώρο N διαστάσεων, ώστε να απέχει όσο το δυνατόν περισσότερο από τα

δείγματα των διαφορετικών κλάσεων που διαχωρίζονται από αυτό. Η επιφάνεια που σχηματίζει το όριο είναι γνωστή ως υπερεπιφάνεια μεγίστου περιθωρίου. Όσο μεγαλύτερα είναι τα περιθώρια, τόσο μεγαλύτερη είναι η ανοχή της μεθόδου σε φαινόμενα υπερπροσαρμογής. Το ισχυρότερο πλεονέκτημα των SVM είναι ότι μπορούν να διαχειριστούν δεδομένα υψηλών διαστάσεων, ακραίες τιμές και μη γραμμικές σχέσεις.

Υπάρχουν δύο τύποι SVM:

- Γραμμικές SVM, που επιλύουν γραμμικώς διαχωρίσιμα προβλήματα
- Μη γραμμικές SVM, που επιλύουν μη γραμμικώς διαχωρίσιμα προβλήματα

Οι γραμμικές SVM χρησιμοποιούν ένα γραμμικό όριο απόφασης για να διαχωρίσουν τα δείγματα σε διαφορετικές κλάσεις. Συγκεκριμένα, η υπερεπιφάνεια καθορίζεται από έναν πεπερασμένο αριθμό δειγμάτων του συνόλου, που ονομάζονται διανύσματα υποστήριξης.

Στα μαθηματικά, η υπερεπιφάνεια εκφράζεται από την εξίσωση ευθείας:

$$w \cdot x + b = 0$$

Η κλάση που ανήκει κάθε σημείο αποφασίζεται βάση της συνάρτησης:

$$f(x_i) = \begin{cases} 0, & w \cdot x_i + b < 0 \\ 1, & w \cdot x_i + b \geq 0 \end{cases}$$


Όπου:

- x_i η κάθε τιμή του συνόλου
- w και b οι παράμετροι της ευθείας.

Οι παράμετροι w και b υπολογίζονται κατά την εκπαίδευση ώστε να ελαχιστοποιείται το μήκος $\|w\|$, όπως φαίνεται παρακάτω:

$$\min_w \frac{\|w\|^2}{2}$$

Οι μη γραμμικές SVM αξιοποιούνται όταν τα δεδομένα είναι αδύνατον να διαχωριστούν με μια υπερεπιφάνεια. Με τη χρήση συναρτήσεων πυρήνα μετασχηματίζουν και προβάλλουν τα χαρακτηριστικά εισόδου σε έναν χώρο υψηλότερης διάστασης, όπου τα δεδομένα γίνονται πλέον γραμμικά διαχωρίσιμα. Έπειτα, ακολουθεί η ίδια διαδικασία με τις γραμμικές SVM για την εύρεση του ορίου απόφασης στον νέο χώρο.



Εικόνα 32: Οι τύποι SVM. Α. Γραμμική SVM Β. Μη γραμμική SVM. [68]

Το εσωτερικό γινόμενο των διανυσμάτων υποστήριξης $\Phi(u), \Phi(v)$ στον μετασχηματισμένο χώρο εκφράζεται συναρτήσει των ίδιων διανυσμάτων στον αρχικό χώρο, ως εξής:

$$\Phi(u) \cdot \Phi(v) = f(u \cdot v)$$

Η συνάρτηση f ονομάζεται συνάρτηση πυρήνα και συμβολίζεται ως $K(u, v)$. Ουσιαστικά, μετατρέπει τα μη γραμμικά διαχωρίσιμα προβλήματα σε γραμμικά διαχωρίσιμα μέσω πολύπλοκων υπολογισμών. Ως συναρτήσεις πυρήνα συχνά χρησιμοποιούνται οι παρακάτω:

- Συνάρτηση εσωτερικού γινομένου: $K(u, v) = u \cdot v$
- Συνάρτηση ακτινικής βάσης: $K(u, v) = e^{-g \cdot \|u - v\|^2}$, όπου g μια σταθερά εξαρτώμενη από το πρόβλημα
- Πολυωνυμικές συναρτήσεις: $K(u, v) = (u \cdot v + 1)^d$, όπου d ο βαθμός του πολυωνύμου.

Στην παρούσα εργασία, χρησιμοποιείται μια μη γραμμική SVM με πυρήνα την πολυωνυμική συνάρτηση. Η υλοποίηση της SVM στην Python, γίνεται με τη συνάρτηση SVC, που ανήκει στην ενότητα svm της βιβλιοθήκης scikit-learn. Στη συνάρτηση δίνονται τα ορίσματα poly, για τον προσδιορισμό της συνάρτησης πυρήνα ως την πολυωνυμική, και auto, για τον καθορισμό του βαθμού d του πολυωνύμου.

7.4 Απλοϊκός Bayes

Ο απλοϊκός ταξινομητής Bayes (Naive Bayes) είναι ένας αλγόριθμος μηχανικής μάθησης που στηρίζεται σε κατανομές πιθανότητας για την κατηγοριοποίηση των δεδομένων. Βασίζεται στο θεώρημα του Bayes για τον υπολογισμό των πιθανοτήτων κάθε κλάσης, κάνοντας την «αφελή» υπόθεση ότι οι τιμές των χαρακτηριστικών είναι ανεξάρτητες μεταξύ τους.

Σύμφωνα με το θεώρημα του Bayes, η πιθανότητα μια παρατήρηση να αντιστοιχεί στην κλάση y εκφράζεται από τον τύπο:

$$P(y|X) = \frac{P(X|y) \cdot P(y)}{P(X)}, \text{ με } P(X) \neq 0$$

Όπου:

- $P(y)$: Η πιθανότητα να ανήκει μια τιμή στην κλάση y
- $P(X)$: Η εκ των προτέρων πιθανότητα του X
- $P(X|y)$: Η εκ των υστέρων πιθανότητα του X , δηλαδή όταν ισχύει το y

Επομένως, ο ταξινομητής επιλέγει την κλάση που έχει τη μέγιστη πιθανότητα, όπως φαίνεται στον ακόλουθο απλοποιημένο τύπο:

$$\hat{y} = \underset{y}{\operatorname{argmax}} P(y) \cdot \prod_{i=1}^n P(x_i|y)$$

Σε αυτή την πτυχιακή εργασία χρησιμοποιείται ο γκαουσιανός απλοϊκός Bayes. Αποτελεί μια παραλλαγή της μεθόδου που υποθέτει ότι η κατανομή των χαρακτηριστικών είναι γκαουσιανή και η πιθανότητα υπολογίζεται ως:

$$P(x_i|y) = \frac{1}{\sqrt{2\pi\sigma_y^2}} e^{\left(-\frac{(x_i-\mu_y)^2}{2\sigma_y^2}\right)}$$


Όπου:

- x_i η κάθε τιμή του συνόλου
- μ_y η μέση τιμή των τιμών της κλάσης
- σ_y η τυπική απόκλιση των τιμών της κλάσης

Η υλοποίηση του απλοϊκού Bayes στην Python, γίνεται με τη συνάρτηση GaussianNB, που ανήκει στην ενότητα `naive_bayes` της βιβλιοθήκης `scikit-learn`. Στη συνάρτηση δεν δίνονται ορίσματα, διατηρώντας τις προκαθορισμένες παράμετρούς της.

7.5 Κ πλησιέστεροι γείτονες

Ο αλγόριθμος των k πλησιέστερων γειτόνων (k Nearest Neighbors - kNN) είναι ένας από τους πιο γνωστούς και βασικούς αλγόριθμους ταξινόμησης και παλινδρόμησης στη μηχανική μάθηση. Αξιοποιείται σε σενάρια πραγματικής ζωής, καθώς βασίζεται στη λογική ότι παρόμοια παραδείγματα ανήκουν στην ίδια κλάση. Αρχικά, κάνει την παραδοχή ότι τα σύνολα των χαρακτηριστικών μπορούν να αναπαρασταθούν σε έναν n -διάστατο Ευκλείδειο χώρο $\mathbb{R}^n$, όπου n είναι το πλήθος των χαρακτηριστικών. Όταν ένα νέο σημείο αναπαρίσταται στον χώρο αυτό, υπολογίζεται η απόστασή του με τα ήδη υπάρχοντα ταξινομημένα σημεία και βρίσκονται τα k πλησιέστερα σε αυτό. Τέλος, το νέο σημείο ταξινομείται στην κλάση στην οποία ανήκουν τα περισσότερα από τα k πλησιέστερα σημεία. Στην Εικόνα 33, απεικονίζεται η κατηγοριοποίηση ενός νέου παραδείγματος με τον αλγόριθμο k -NN.



Εικόνα 33: Παράδειγμα ταξινόμησης με τον αλγόριθμο k -NN. [69]

Για τον υπολογισμό της απόστασης μεταξύ των σημείων συχνά χρησιμοποιούνται οι μετρικές απόστασης:

- Ευκλείδεια απόσταση
- Απόσταση Manhattan
- Απόσταση Minkowski

Ουσιαστικά, η Ευκλείδεια και η απόσταση Manhattan, είναι ειδικές περιπτώσεις της απόστασης Minkowski. Στην μελέτη μας επιλέχθηκε η Ευκλείδεια απόσταση, η οποία για ένα νέο σημείο x_q υπολογίζεται από τον τύπο:

$$d(x_q, x_i) = \sqrt{\sum_{j=1}^n (x_{qj} - x_{ij})^2}$$

Όπου:

- x_{qj} η κάθε τιμή της νέας περίπτωσης
- x_{ij} η κάθε τιμή μιας περίπτωσης του αρχικού συνόλου
- n το πλήθος των δεδομένων


Εκτός από το μέτρο της απόστασης είναι σημαντική και η επιλογή του αριθμού k για τον καθορισμό του αριθμού των γειτόνων. Η τιμή του k συνήθως επιλέγεται με βάση τα δεδομένα εισόδου. Εάν τα δεδομένα εισόδου έχουν περισσότερες ακραίες τιμές ή θόρυβο, τότε προτιμώνται υψηλές τιμές k . Εντός αυτού του ερευνητικού πλαισίου η τιμή του k αποφασίστηκε να είναι 5.

Η υλοποίηση του αλγορίθμου kNN στην Python, γίνεται με τη συνάρτηση `KNeighborsClassifier`, που ανήκει στην ενότητα `neighbors` της βιβλιοθήκης `scikit-learn`. Στη συνάρτηση δεν δίνονται ορίσματα, διατηρώντας τις προκαθορισμένες παράμετρους της.

7.6 Δέντρο απόφασης

Τα δέντρα απόφασης (Decision Trees) αποτελούν ισχυρά εργαλεία στον τομέα της μηχανικής μάθησης για εργασίες ταξινόμησης και παλινδρόμησης. Ο όρος δέντρο απόφασης αναφέρεται σε μια δενδροειδή δομή με ρίζα, παρόμοια με διάγραμμα ροής, όπου κάθε εσωτερικός κόμβος υποδηλώνει ένα χαρακτηριστικό, οι κλάδοι εκφράζουν τους κανόνες απόφασης και οι τερματικοί κόμβοι υποδηλώνουν το αποτέλεσμα της κατηγοριοποίησης. Κατασκευάζεται με αναδρομικό τρόπο, ακολουθώντας τα βήματα:

- 1) Το δέντρο ξεκινά από τον ριζικό κόμβο, ο οποίος περιέχει το πλήρες σύνολο δεδομένων.
- 2) Εντοπίζεται το χαρακτηριστικό που μπορεί να διαχωρίσει βέλτιστα το σύνολο δεδομένων
- 3) Γίνεται ο διαχωρισμός
- 4) Η διαδικασία συνεχίζεται για τον επόμενο κόμβο μέχρι να μην είναι δυνατόν κάποιος περαιτέρω διαχωρισμός



Εικόνα 34: Παράδειγμα δέντρου απόφασης με τα συμπτώματα του COVID-19. [70]

Κατά τη διάρκεια της εκπαίδευσης, το χαρακτηριστικό για τη διαχώριση των δεδομένων επιλέγεται υπολογίζοντας τον βαθμό ανομοιογένειας στα υποσύνολα που προκύπτουν. Οι βασικότερες μετρικές που χρησιμοποιούνται είναι:

- Η Εντροπία της πληροφορίας: Εκφράζει την τυχαιότητα βάσει της κατανομής των κλάσεων στο σύνολο δεδομένων. Ως κριτήριο διαχωρισμού επιλέγεται το χαρακτηριστικό που ελαχιστοποιεί την Εντροπία των υποσυνόλων.
- Ο δείκτης Gini: Δίνει ως αποτέλεσμα μια βαθμολογία μεταξύ 0 και 1. Το 0 εκφράζει την αντιστοίχιση των τιμών σε μια μόνο κλάση, ενώ το 1 εκφράζει μια τυχαία κατανομή των στοιχείων μεταξύ των κλάσεων. Επομένως, για τον διαχωρισμό προτιμάται το χαρακτηριστικό με τη μικρότερη βαθμολογία του δείκτη Gini.
- Το κέρδος πληροφορίας: Μετρά τη μείωση της Εντροπίας που προκύπτει από τον διαχωρισμό. Όσο υψηλότερο είναι το κέρδος πληροφοριών, τόσο προτιμότερο είναι το χαρακτηριστικό για την τελική πρόβλεψη.

Στα πειράματα που διεξήχθησαν χρησιμοποιήθηκε ο δείκτης Gini:

$$Gini = 1 - \sum_{i=1}^c p_i^2$$

Όπου:

- p_i η κλάση των σημείων που ανήκουν στην κατηγορία i

Η υλοποίηση του δέντρου απόφασης στην Python, γίνεται με τη συνάρτηση `DecisionTreeClassifier`, που ανήκει στην ενότητα `tree` της βιβλιοθήκης `scikit-learn`. Στη συνάρτηση δεν δίνονται ορίσματα, διατηρώντας τις προκαθορισμένες παράμετρος της.


7.7 Τυχαίο δάσος

Ο αλγόριθμος τυχαίου δάσους (Random Forest) είναι μια μέθοδος συλλογικής μάθησης, η οποία αξιοποιεί αποκλειστικά δέντρα απόφασης. Κατά την εκτέλεση του αλγορίθμου, κατασκευάζονται και συνδυάζονται πολλά διαφορετικά δέντρα απόφασης, στα οποία ανατίθεται η ταξινόμηση ή η παλινδρόμηση. Στην περίπτωση της ταξινόμησης, η τελική ταξινόμηση γίνεται λαμβάνοντας υπόψιν τις

προβλέψεις όλων των δέντρων και επιλέγοντας την επικρατέστερη. Η λειτουργία του αλγορίθμου Τυχαίου Δάσους συμπεριλαμβάνει τα παρακάτω βήματα:

- 1) Διαχωρισμός του συνόλου δεδομένων σε τυχαία υποσύνολα.
- 2) Κατασκευή ενός δέντρου αποφάσεων για κάθε υποσύνολο.
- 3) Λήψη αποτελέσματος από κάθε δέντρο και εφαρμογή ψηφοφορίας.
- 4) Το τελικό αποτέλεσμα καθορίζεται από την πρόβλεψη με τις περισσότερες ψήφους.

Το διάγραμμα στην Εικόνα 35 περιγράφει τη λειτουργία του αλγορίθμου.



Εικόνα 35: Η διαδικασία ταξινόμησης με αλγόριθμο τυχαίου δάσους. [71]

Τις περισσότερες φορές τα τυχαία δάση προσφέρουν καλύτερα αποτελέσματα από ένα μεμονωμένο δέντρο απόφασης, ξεπερνώντας την τάση που έχουν σε φαινόμενα υπερπροσαρμογής. Ωστόσο, η κατασκευή των διάφορων δέντρων αυξάνει την υπολογιστική πολυπλοκότητα, την απαίτηση σε πόρους και τον χρόνο εκτέλεσης της μεθόδου.

Η υλοποίηση του αλγορίθμου τυχαίου δάσους στην Python, γίνεται με τη συνάρτηση `RandomForestClassifier`, που ανήκει στην ενότητα `ensemble` της βιβλιοθήκης `scikit-learn`. Στη συνάρτηση δεν δίνονται ορίσματα, διατηρώντας τις προκαθορισμένες παράμετρούς της.

7.8 Νευρωνικά δίκτυα

Τα τεχνητά νευρωνικά δίκτυα χρησιμοποιούνται με επιτυχία για την επίλυση όλο και περισσότερων προβλημάτων ταξινόμησης σε διάφορους τομείς. Επομένως θεωρήσαμε σημαντική την αξιοποίησή τους και στην παρούσα μελέτη. Συγκεκριμένα, δημιουργήθηκε ένα απλό νευρωνικό δίκτυο, ένα συνελκτικό νευρωνικό δίκτυο, ένα αναδρομικό νευρωνικό δίκτυο, ένα δίκτυο μακράς βραχύχρονης μνήμης και μια περιφραγμένη επαναλαμβανόμενη μονάδα. Στην εργασία μας όλες οι αρχιτεκτονικές νευρωνικών δικτύων είναι πολύ απλές, ώστε να έχουν μικρή πολυπλοκότητα και ελάχιστες απαιτήσεις, αυξάνοντας την πιθανότητα να μπορούν να εκτελεστούν με τους περιορισμένους πόρους ενός μικροεπεξεργαστή. Στις επόμενες υποενότητες, περιγράφονται τα χαρακτηριστικά του κάθε δικτύου.


7.8.1 Τεχνητό νευρωνικό δίκτυο

Τα τεχνητά νευρωνικά δίκτυα (Artificial Neural Networks - ANN) είναι μια θεμελιώδης προσέγγιση μηχανικής μάθησης, εμπνευσμένη από τη δομή και τη λειτουργία του ανθρώπινου εγκεφάλου. Πρόκειται

για μια κατηγορία υπολογιστικών μοντέλων, τα οποία μαθαίνουν από τα δεδομένα και προσφέρουν τη δυνατότητα μοντελοποίησης σύνθετων σχέσεων. Η δομή τους απαρτίζεται από τεχνητούς νευρώνες οργανωμένους σε στρώματα. Υπάρχουν τρεις κύριοι τύποι στρωμάτων:

- Επίπεδο εισόδου: Λαμβάνει τα χαρακτηριστικά του σύνολο δεδομένων και τα μεταδίδει στα επόμενα επίπεδα. Κάθε νευρώνας σε αυτό το επίπεδο αντιπροσωπεύει ένα χαρακτηριστικό των δεδομένων εισόδου.
- Κρυφά επίπεδα: Αυτά τα στρώματα περιέχουν πολλαπλούς νευρώνες που εκτελούν πολύπλοκους υπολογισμούς. Το βάθος αυτών των επιπέδων επηρεάζει την ικανότητα του δικτύου να καταγράφει περίπλοκα μοτίβα στα δεδομένα. Μεταξύ των επιπέδων εισόδου και εξόδου, μπορεί να υπάρχουν ένα ή περισσότερα κρυφά επίπεδα.
- Επίπεδο εξόδου: Εξάγει τα τελικά αποτελέσματα των υπολογισμών του δικτύου. Ένα πρόβλημα δυαδικής ταξινόμησης έχει έναν νευρώνα εξόδου, ενώ οι εργασίες ταξινόμησης πολλαπλών κλάσεων θα μπορούσαν να έχουν πολλαπλούς νευρώνες εξόδου.

Ο κάθε νευρώνας (βλ. Εικόνα 36) δέχεται ένα πλήθος τιμών εισόδου οι οποίες πολλαπλασιάζονται με αντίστοιχα βάρη και, έπειτα, αθροίζονται σε έναν αθροιστή. Στην έξοδο του αθροιστή, εφαρμόζεται μια συνάρτηση ενεργοποίησης και το αποτέλεσμα προωθείται στους νευρώνες του επόμενου στρώματος. Αυτή η διαδικασία συνεχίζεται έως ότου το επίπεδο εξόδου να παράγει την τελική ταξινόμηση. Κατά την εκπαίδευση, η έξοδος συγκρίνεται με την πραγματική κλάση των δεδομένων και τα βάρη προσαρμόζονται έτσι ώστε να ελαχιστοποιηθεί το σφάλμα της ταξινόμησης.




Εικόνα 36: Δομή νευρώνα στο τεχνητό νευρωνικό δίκτυο. [72]

Στην Εικόνα 37 παρουσιάζεται η δομή του ANN που αναπτύχθηκε στα πλαίσια της παρούσας εργασίας. Συγκεκριμένα, περιλαμβάνει:

- Ένα επίπεδο εισόδου
- Ένα κρυφό επίπεδο με 512 τεχνητούς νευρώνες, με συνάρτηση ενεργοποίησης τη ReLU
- Ένα κρυφό επίπεδο με 128 τεχνητούς νευρώνες, με συνάρτηση ενεργοποίησης τη ReLU
- Ένα κρυφό επίπεδο με 64 τεχνητούς νευρώνες, με συνάρτηση ενεργοποίησης τη ReLU
- Ένα επίπεδο Dropout με ποσοστό 0.2

- Ένα στρώμα εξόδου με συνάρτηση ενεργοποίησης τη σιγμοειδή




Εικόνα 37: Η αρχιτεκτονική ANN της παρούσας εργασίας.

Το επίπεδο Dropout αποκλείει κάθε φορά ένα ποσοστό των τιμών από το σύνολο εκπαίδευσης του νευρωνικού δικτύου, με σκοπό την αποφυγή της υπερπροσαρμογής.

Η γραφική παράσταση της συνάρτησης ReLU φαίνεται στην Εικόνα 38 και υπολογίζεται ως:

$$f(x) = \max(0, x)$$

Η σιγμοειδής συνάρτηση και η γραφική της παράσταση ορίζονται με τον ίδιο τρόπο που περιγράφεται στην υποενότητα της Λογιστικής Παλινδρόμησης (6.1.2).



Εικόνα 38: Η συνάρτηση ReLU. [73]

Η υλοποίηση του νευρωνικού δικτύου στην Python, αποτελείται από στρώματα Dense και Dropout του πακέτου Keras.

7.8.2 Συνελικτικό νευρωνικό δίκτυο


Τα συνελικτικά νευρωνικά δίκτυα (Convolutional Neural Network - CNN), συνιστούν μια ειδική κατηγορία νευρωνικών δικτύων, σχεδιασμένων με στόχο την επεξεργασία δεδομένων που είναι σε μορφή πλέγματος. Η αρχιτεκτονική των CNN περιλαμβάνει τρία στάδια εξεργασίας:

- Στάδιο συνέλιξης: Αποτελείται από φίλτρα ανίχνευσης μοτίβων ή χαρακτηριστικών στα δεδομένα εισόδου. Σε κάθε στάδιο παράγεται ένα πλήθος επιπέδων νευρώνων και καθένα τροφοδοτείται με δεδομένα μιας υποπεριοχής του πλέγματος του προηγούμενου σταδίου.
- Στάδιο συγκέντρωσης: Μειώνει τις χωρικές διαστάσεις των δεδομένων, διατηρώντας μόνο τα πιο σημαντικά χαρακτηριστικά. Οι πιο συνηθισμένοι υπολογισμοί, σε αυτό το στάδιο, είναι το μέγιστο και η μέση τιμή.
- Πλήρως διασυνδεδεμένα επίπεδα: Είναι παρόμοια με τα επίπεδα των παραδοσιακών νευρωνικών δικτύων και υλοποιούν τον ταξινομητή. Πριν την τελική έξοδο του CNN, οι τιμές μετασχηματίζονται σε μονοδιάστατο πίνακα.

Ουσιαστικά, τα χαμηλότερα στρώματα καταγράφουν τα χαρακτηριστικά, ενώ τα βαθύτερα στρώματα μαθαίνουν σταδιακά πιο περίπλοκα χαρακτηριστικά και μοτίβα. Η εκπαίδευση ενός CNN είναι παρόμοια με την εκπαίδευση ενός απλού νευρωνικού δικτύου.

Στην Εικόνα 39 φαίνεται η αρχιτεκτονική του CNN που αξιοποιήθηκε στα πειράματα της παρούσας εργασίας. Συγκεκριμένα, αποτελείται από:

- Ένα επίπεδο εισόδου
- Ένα στάδιο συνέλιξης με φίλτρο 3x3, 64 τεχνητούς νευρώνες και συνάρτηση ενεργοποίησης τη ReLU
- Ένα στάδιο σμίκρυνσης βάσει του μέγιστου
- Ένα επίπεδο Flatten, υπεύθυνο για τον μετασχηματισμό των δεδομένων σε μονοδιάστατο πίνακα
- Ένα κρυφό επίπεδο με 32 τεχνητούς νευρώνες και συνάρτηση ενεργοποίησης τη ReLU
- Ένα επίπεδο Dropout με ποσοστό 0.2, για την αποφυγή υπερπροσαρμογής
- Ένα στρώμα εξόδου με συνάρτηση ενεργοποίησης τη σιγμοειδή



Εικόνα 39: Η αρχιτεκτονική CNN της παρούσας εργασίας.

Η υλοποίηση του συνελκτικού νευρωνικού δικτύου στην Python, αποτελείται από στρώματα ένα στρώμα Conv1D, ένα στρώμα MaxPooling1D, στρώματα Dense, ένα στρώμα Flatten και ένα στρώμα Dropout του πακέτου Keras.


7.8.3 Αναδρομικά νευρωνικά δίκτυα

Τα αναδρομικά νευρωνικά δίκτυα (Recurrent Neural Networks – RNN) είναι μια κατηγορία τεχνητών νευρωνικών δικτύων που στοχεύουν κυρίως στη διαχείριση αλληλουχιών δεδομένων, όπως οι χρονοσειρές. Σε αντίθεση με τα παραδοσιακά νευρωνικά δίκτυα, τα RNN διαθέτουν επίπεδα ανατροφοδότησης καθιστώντας τα ικανά να μαθαίνουν σύντομα μοτίβα διατηρώντας τις χρήσιμες πληροφορίες κάθε επανάληψης. Κάθε νευρώνας σε ένα RNN έχει μια κρυφή κατάσταση, η οποία λειτουργεί ως μνήμη. Η κρυφή κατάσταση ενημερώνεται σε κάθε επανάληψη του επιπέδου, επιτρέποντας στο δίκτυο να διατηρεί πληροφορίες μεταξύ των διαδοχικών εισόδων.

Η Εικόνα 40 απεικονίζει την δομή του απλού RNN που χρησιμοποιήθηκε στην παρούσα εργασία. Το δίκτυο απαρτίζεται από:

- Ένα επίπεδο εισόδου
- Ένα επαναλαμβανόμενο επίπεδο με 64 τεχνητούς νευρώνες και συνάρτηση ενεργοποίησης την Tanh
- Ένα επίπεδο Dropout με ποσοστό 0.2, για την αποφυγή υπερπροσαρμογής


- Ένα κρυφό επίπεδο με 16 τεχνητούς νευρώνες και συνάρτηση ενεργοποίησης τη ReLU
- Ένα επίπεδο Dropout με ποσοστό 0.1, για την αποφυγή υπερπροσαρμογής
- Ένα επίπεδο εξόδου με συνάρτηση ενεργοποίησης τη σιγμοειδή



Εικόνα 40: Η αρχιτεκτονική RNN της παρούσας εργασίας.

Η γραφική παράσταση της συνάρτησης Tanh φαίνεται στην Εικόνα 41 και ορίζεται ως:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$



Εικόνα 41: Η συνάρτηση Tanh. [74]

Η υλοποίηση του αναδρομικού νευρωνικού δικτύου στην Python, αποτελείται από ένα στρώμα SimpleRNN, στρώματα Dense και Dropout του πακέτου Keras.

7.8.4 Δίκτυο μακράς βραχύχρονης μνήμης


Τα δίκτυα μακράς βραχύχρονης μνήμης (Long Short-Term Memory Networks - LSTM) είναι μια παραλλαγή των RNN που έχει διαμορφωθεί έτσι ώστε να μοντελοποιούνται καλύτερα οι μακροπρόθεσμες συσχετίσεις σε μια ακολουθία δεδομένων. Εκ πρώτης όψεως είναι ίδια με τα RNN,

καθώς περιέχουν επαναλαμβανόμενα επίπεδα με εσωτερική κατάσταση, όμως η διαφορά τους συναντάται στον τρόπο υπολογισμού της εσωτερικής κατάστασης. Ο υπολογισμός αυτός γίνεται με ειδικά νευρωνικά δίκτυα, γνωστά και ως πύλες, τα οποία είναι υπεύθυνα για το ποιες πληροφορίες θα διατηρούνται στη μνήμη του δικτύου. Με άλλα λόγια, οι πληροφορίες προστίθενται και διαγράφονται από την εσωτερική κατάσταση μέσω των πυλών και, στη συνέχεια, προωθούνται στα επόμενα στρώματα.

Υπάρχουν τρεις τύποι πυλών:

- Πύλη λήθης: Αποφασίζει τις πληροφορίες που θα απορριφθούν από την εσωτερική κατάσταση. Πρόκειται για ένα σιγμοειδές στρώμα που δέχεται ως είσοδο την προηγούμενη κρυφή κατάσταση και την τρέχουσα είσοδο και εξάγει έναν αριθμό μεταξύ 0 και 1, για κάθε αριθμό της εσωτερικής κατάστασης. Το 1 αντιπροσωπεύει τη διατήρηση των δεδομένων ενώ το 0 αντιπροσωπεύει τη διαγραφή.
- Πύλη εισόδου: Ενημερώνει την εσωτερική κατάσταση προσθέτοντας νέες πληροφορίες. Αποτελείται από ένα σιγμοειδές στρώμα που αποφασίζει ποιες τιμές θα ενημερωθούν και ένα στρώμα Tanh που δημιουργεί το διάνυσμα των νέων τιμών.
- Πύλη εξόδου: Αποφασίζει την επόμενη κρυφή κατάσταση με βάση την εσωτερική κατάσταση. Ένα σιγμοειδές στρώμα καθορίζει ποια μέρη της εσωτερικής κατάστασης εξάγονται στην επόμενη κρυφή κατάσταση. Παράλληλα, η εσωτερική κατάσταση δίνεται ως είσοδος σε μια συνάρτηση Tanh, πολλαπλασιάζεται με την έξοδο του σιγμοειδούς στρώματος και παράγει την νέα κρυφή έξοδο.


Ουσιαστικά, η εσωτερική κατάσταση διασχίζει την μονάδα LSTM από τα αριστερά προς τα δεξιά. Πρώτα περνάει από μια πύλη λήθης, όπου ελέγχονται οι πληροφορίες που θα ξεχαστούν. Έπειτα, στην πύλη εισόδου παράγεται το διάνυσμα που αντιστοιχεί στις νέες πληροφορίες που πρέπει να προστεθούν στη μνήμη του δικτύου. Τέλος, φτάνει στην πύλη εξόδου όπου παράγεται το διάνυσμα εξόδου με όλες τις πληροφορίες που θεωρούνται σημαντικές. Η ροή των δεδομένων σε μια μονάδα LSTM φαίνεται στην Εικόνα 42.



Εικόνα 42: Η μονάδα LSTM. [75]

Στο διάγραμμα της Εικόνας 43 φαίνεται η μορφή του δικτύου LSTM που σχεδιάστηκε στην παρούσα πτυχιακή εργασία. Η δομή του περιέχει:

- Ένα επίπεδο εισόδου
- Ένα επαναλαμβανόμενο επίπεδο τύπου LSTM με 64 μονάδες, 256 τεχνητούς νευρώνες και συνάρτηση ενεργοποίησης την Tanh
- Ένα κρυφό επίπεδο με 64 τεχνητούς νευρώνες και συνάρτηση ενεργοποίησης τη ReLU
- Ένα επίπεδο εξόδου με συνάρτηση ενεργοποίησης τη σιγμοειδή



Εικόνα 43: Η αρχιτεκτονική LSTM της παρούσας εργασίας.

Η υλοποίηση του δικτύου μακράς βραχύχρονης μνήμης στην Python, αποτελείται από ένα στρώμα LSTM και στρώματα Dense του πακέτου Keras.

7.8.5 Περιγραφόμενη επαναλαμβανόμενη μονάδα


Μια περιγραφόμενη επαναλαμβανόμενη μονάδα (Gated Recurrent Unit - GRU) είναι μια απλοποιημένη έκδοση της μονάδας LSTM. Συγκεκριμένα, οι πύλες λήθης και εισόδου συγχωνεύονται σε μια πύλη, που ονομάζονται πύλη ενημέρωσης, ενώ η πύλη εξόδου ονομάζεται πλέον πύλη επαναφοράς..

Η κάθε πύλη λειτουργεί ως εξής:

- Πύλη ενημέρωσης: Καθορίζει τις πληροφορίες των προηγούμενων βημάτων που θα διατηρηθούν στο μέλλον. Συνδυάζει τις πληροφορίες από την προηγούμενη κρυφή κατάσταση και την τρέχουσα είσοδο, οι οποίες δίνονται ως είσοδος σε μια σιγμοειδή συνάρτηση. Η έξοδος της πύλης είναι ένας αριθμός μεταξύ 0 και 1, όπου το 1 σημαίνει ότι διατηρούνται μόνοι οι προηγούμενες πληροφορίες και το 0 ότι διατηρείται μόνο η τρέχουσα είσοδος.
- Πύλη επαναφοράς: Αποφασίζει τις πληροφορίες των προηγούμενων βημάτων που θα αγνοηθούν στο μέλλον. Ομοίως με την πύλη ενημέρωσης, η πύλη επαναφοράς συνδυάζει τις

πληροφορίες από την προηγούμενη κρυφή κατάσταση και την τρέχουσα είσοδο, οι οποίες δίνονται ως είσοδος σε μια σιγμοειδή συνάρτηση. Η έξοδος της πύλης είναι ένας αριθμός μεταξύ 0 και 1, όπου το 1 σημαίνει ότι αγνοείται η τρέχουσα κατάσταση και το 0 ότι αγνοούνται μόνοι οι προηγούμενες πληροφορίες.

Η ροή των δεδομένων σε μια μονάδα GRU ξεκινά από την πύλη ενημέρωσης, η οποία καθορίζει ποιες νέες πληροφορίες θα αποθηκευτούν. Παράλληλα, η πύλη επαναφοράς αποφασίζει ποιες πληροφορίες από την προηγούμενη κρυφή κατάσταση. Στη συνέχεια, η έξοδος της πύλης επαναφοράς και η τρέχουσα είσοδος δίνονται ως είσοδος σε μια συνάρτηση Tanh. Το αποτέλεσμα της συνάρτησης πολλαπλασιάζεται με τον συμπληρωματικό αριθμό της εξόδου της πύλης ενημέρωσης. Ταυτόχρονα, η έξοδος της πύλης ενημέρωσης πολλαπλασιάζεται με την τρέχουσα είσοδο. Τέλος, τα αποτελέσματα των δυο προηγούμενων πράξεων προθέτονται και προκύπτει η νέα κρυφή κατάσταση. Διαγραμματικά, οι διεργασίες ενός GRU απεικονίζονται στην Εικόνα 44.




Εικόνα 44: Η μονάδα GRU. [76]

Η παραπάνω απλοποίηση καθιστά τα δίκτυα GRU υπολογιστικά αποδοτικότερα, εφόσον έχουν λιγότερες παραμέτρους σε σύγκριση με τα LSTM, γεγονός που τα καθιστά δημοφιλή επιλογή σε διάφορες εφαρμογές.

Στην Εικόνα 45 παρουσιάζεται η αρχιτεκτονική του δικτύου GRU που χρησιμοποιήθηκε στην παρούσα εργασία. Όπως φαίνεται, το δίκτυο αποτελούν:

- Ένα επίπεδο εισόδου
- Ένα επαναλαμβανόμενο επίπεδο τύπου GRU με 64 μονάδες, 192 τεχνητούς νευρώνες και συνάρτηση ενεργοποίησης την Tanh
- Ένα επίπεδο Dropout με ποσοστό 0.2, για την αποφυγή υπερπροσαρμογής
- Ένα κρυφό επίπεδο με 16 τεχνητούς νευρώνες και συνάρτηση ενεργοποίησης τη ReLU
- Ένα επίπεδο Dropout με ποσοστό 0.1, για την αποφυγή υπερπροσαρμογής
- Ένα επίπεδο εξόδου με συνάρτηση ενεργοποίησης τη σιγμοειδή



Εικόνα 45: Η αρχιτεκτονική GRU της παρούσας εργασίας.

Η υλοποίηση της περιγραφμένης επαναλαμβανόμενης μονάδας στην Python, αποτελείται από ένα στρώμα GRU, στρώματα Dense και Dropout του πακέτου Keras.

8 Μέθοδοι αξιολόγησης

Κατά την ερευνητική διαδικασία, ένα κρίσιμο σημείο αποτελεί η αξιολόγηση των αλγορίθμων ταξινόμησης. Είναι σημαντικό να επιλέξουμε τις κατάλληλες μετρικές, οι οποίες θα αντανakλούν την ικανότητα του κάθε μοντέλου να εκτελέσει τις επιθυμητές ενέργειες.

Στην παρούσα εργασία, οι μετρικές που συμβουλευόμαστε για την ποσοτικοποίηση της ικανότητας γενίκευσης ενός μοντέλου είναι η ακρίβεια, η ευαισθησία και η ειδικότητα, ενώ για τον έλεγχο της συμβατότητας ενός μοντέλου με τον επιλεγμένο μικροεπεξεργαστή λαμβάνουμε υπόψιν τις απαιτήσεις μνήμης και τον χρόνο αποτελέσματος. Σε αυτό το κεφάλαιο, παρουσιάζουμε όλες τις αναφερόμενες μετρικές, τους μαθηματικούς τους τύπους και την υλοποίησή τους στην Python.

8.1 Πίνακας σύγχυσης

Ο πίνακας σύγχυσης είναι ένα θεμελιώδες εργαλείο για την αξιολόγηση της απόδοσης ενός ταξινομητή. Χρησιμοποιείται ευρέως, διότι παρέχει μια σαφή και λεπτομερή ανάλυση των προβλέψεων ενός ταξινομητή σε σχέση με τα πραγματικά αποτελέσματα με τη μορφή ενός πίνακα. Στην Εικόνα 46, παρουσιάζεται ο κλασσικός πίνακας σύγχυσης.

Είναι εμφανές ότι ένας πίνακας σύγχυσης αποτελείται από τέσσερα βασικά στοιχεία:

- Αληθώς θετική (True Positive – TP): Υποδηλώνει τον αριθμό των περιπτώσεων, όπου το μοντέλο προέβλεψε τη θετική κλάση και η πραγματική κλάση ήταν η θετική. Δηλαδή, το μοντέλο προέβλεψε επιληπτική κρίση όταν ο ασθενής βίωσε μια επιληπτική κρίση.
- Αληθώς αρνητική (True Negative – TN): Υποδηλώνει τον αριθμό των περιπτώσεων, όπου το μοντέλο προέβλεψε την αρνητική κλάση και η πραγματική κλάση ήταν η αρνητική. Δηλαδή, το μοντέλο προέβλεψε μη επιληπτική κρίση όταν ο ασθενής δεν βίωσε μια επιληπτική κρίση.
- Ψευδώς θετική (False Positive – FP): Υποδηλώνει τον αριθμό των περιπτώσεων, όπου το μοντέλο προέβλεψε τη θετική τάξη και η πραγματική τάξη ήταν η αρνητική. Δηλαδή, το μοντέλο προέβλεψε επιληπτική κρίση όταν ο ασθενής δεν βίωσε μια επιληπτική κρίση.
- Ψευδώς αρνητική (False Negative – FN): Υποδηλώνει τον αριθμό των περιπτώσεων, όπου το μοντέλο προέβλεψε την αρνητική τάξη και η πραγματική τάξη ήταν η θετική. Δηλαδή, το μοντέλο προέβλεψε μη επιληπτική κρίση όταν ο ασθενής βίωσε μια επιληπτική κρίση.

		Προβλεπόμενη κλάση	
		Θετική	Αρνητική
Πραγματική κλάση	Θετική	Αληθώς θετική (TP)	Ψευδώς αρνητική (FN)
	Αρνητική	Ψευδώς θετική (FP)	Αληθώς αρνητική (TN)

Εικόνα 46: Πίνακας σύγχυσης.

Στην Python τα στοιχεία του πίνακα σύγχυσης υπολογίζονται μέσω της συνάρτησης `confusion_matrix`, που βρίσκεται στην ενότητα `metrics` της βιβλιοθήκης `scikit-learn`. Με βάση τα στοιχεία του πίνακα σύγχυσης, εξάγονται διάφορες χρήσιμες μετρήσεις για την αξιολόγηση της επίδοσης ενός μοντέλου. Στην παρούσα εργασία, χρησιμοποιούνται η ακρίβεια, η ευαισθησία και η ειδικότητα, οι οποίες αναλύονται στις επόμενες τρεις υποενότητες του κεφαλαίου.

8.2 Ακρίβεια

Η ακρίβεια μετρά το ποσοστό των σωστών προβλέψεων του μοντέλου. Υπολογίζεται ως:

$$\text{Ακρίβεια} = \text{Acc} = \frac{TP + TN}{TP + TN + FP + FN}$$

Στην περίπτωση των μη εξιστορημένων δεδομένων, η ακρίβεια τείνει να μην είναι μια αξιόπιστη μέτρηση, εφόσον το σφάλμα μπορεί να μην αντικατοπτρίζεται στην τιμή του παρονομαστή. Όμως, είναι χρήσιμη αν μελετηθεί σε συνδυασμό με τις υπόλοιπες μετρήσεις. Στην Python η ακρίβεια υπολογίζεται μέσω της συνάρτησης `accuracy_score`, που βρίσκεται στην ενότητα `metrics` της βιβλιοθήκης `scikit-learn`.

8.3 Ευαισθησία

Η ευαισθησία υπολογίζει το ποσοστό των θετικών περιπτώσεων που ταξινομήθηκαν σωστά ως θετικές. Με άλλα λόγια, εκφράζει την ικανότητα του μοντέλου να αναγνωρίζει όλες τις θετικές περιπτώσεις. Εκτιμάται από τον τύπο:

$$\text{Ευαισθησία} = \text{Sen} = \frac{TP}{TP + FN}$$

Είναι μια εξαιρετικά χρήσιμη μέτρηση για το υπό μελέτη πρόβλημα, αφού δίνει πληροφορίες για τη δυνατότητα εντοπισμού της μειονεκτούσας κλάσης (επιληπτική κρίση) από το μοντέλο. Στην Python η ευαισθησία υπολογίζεται με τη βοήθεια των αποτελεσμάτων της συνάρτησης `confusion_matrix`, που βρίσκεται στην ενότητα `metrics` της βιβλιοθήκης `scikit-learn`.

8.4 Ειδικότητα

Η εκτίμηση της ειδικότητας δίνει ως αποτέλεσμα το ποσοστό των αρνητικών περιπτώσεων που ταξινομήθηκαν σωστά ως αρνητικές. Δηλαδή, δείχνει την ικανότητα του μοντέλου να αναγνωρίζει όλες τις αρνητικές περιπτώσεις. Ορίζεται με την εξίσωση:

$$\text{Ειδικότητα} = \text{Spe} = \frac{TN}{TN + FP}$$

Η συγκεκριμένη μετρική, χρησιμοποιείται για την καλύτερη κατανόηση του ποσοστού της ακρίβειας και μελετάται σε συνδυασμό με την ευαισθησία. Στην Python η ειδικότητα υπολογίζεται με τη βοήθεια των αποτελεσμάτων της συνάρτησης `confusion_matrix`, που βρίσκεται στην ενότητα `metrics` της βιβλιοθήκης `scikit-learn`.

8.5 Μνήμη

Ένα κρίσιμο πρόβλημα, στον τομέα της ενσωματωμένης μηχανικής μάθησης, είναι η αποτελεσματική διαχείριση της διαθέσιμης μνήμης ενός ενσωματωμένου συστήματος. Το πακέτο `Edge Impulse`, καθώς αξιολογεί την δυνατότητα ενσωμάτωσης ενός μοντέλου σε έναν μικροελεγκτή δεδομένων των περιορισμών στους πόρους του, παρέχει τρεις διαφορετικές μετρήσεις μνήμης (σε Bytes): τη RAM, τη ROM και το μέγεθος αρένας (arena size). Παρακάτω, περιγράφεται συνοπτικά η κάθε μέτρηση:

- **RAM:** Οι απαιτήσεις του μοντέλου σε RAM (μνήμη τυχαίας πρόσβασης), εκτός του πίνακα εισόδου. Πρόκειται για τον χώρο μνήμης, όπου αποθηκεύονται οι μεταβλητές του μοντέλου και τα δεδομένα χρόνου εκτέλεσης κατά την εκτέλεση του προγράμματος.
- **ROM:** Οι απαιτήσεις του μοντέλου σε ROM (μνήμη μόνο για ανάγνωση), δηλαδή σε μνήμη Flash. Πρόκειται για τον χώρο μνήμης, όπου αποθηκεύεται ο κώδικας και τα στατικά δεδομένα του προγράμματος.
- **Μέγεθος αρένας:** Το μέγεθος της μνήμης που δεσμεύεται, για την αποθήκευση των πινάκων εισόδου, εξόδου και των ενδιάμεσων πινάκων.

Στην Python οι μετρήσεις, που αφορούν στις απαιτήσεις μνήμης συγκαταλέγονται στις εξόδους της συνάρτησης `profile`, που βρίσκεται στην ενότητα `model` της βιβλιοθήκης `EdgeImpulse`, θέτοντας ως στόχο την πλατφόρμα `Arduino Nano 33 BLE Sense`.

8.6 Χρόνος αποτελέσματος

Μια ακόμα σημαντική μέτρηση, όσο αφορά την ενσωματωμένη μηχανική μάθηση, είναι ο χρόνος ανά αποτέλεσμα (`time per inference`). Συγκεκριμένα, μετριέται ως ο χρόνος που χρειάζεται το μοντέλο για να επεξεργαστεί ένα σύνολο δεδομένων εισόδου και να εξάγει μια πρόβλεψη εξόδου. Αποτελεί ένα χρήσιμο δείκτη της αποτελεσματικότητας του μοντέλου σε σενάρια πραγματικού κόσμου, ιδιαίτερα σε εφαρμογές όπου η ταχύτητα είναι απαραίτητη, όπως στην ανίχνευση επιληπτικών κρίσεων. Στα πλαίσια της εργασίας, ο χρόνος ανά αποτέλεσμα μετριέται σε ms μέσω της συνάρτησης `profile` του πακέτου `Edge Impulse`, μαζί με τις μετρήσεις μνήμης.

9 Πειράματα και αποτελέσματα

Σε αυτό το κεφάλαιο, περιγράφονται τα πειράματα που διεξήχθησαν και τα αποτελέσματά τους. Συγκεκριμένα, αναλύεται η μεθοδολογία 3 πειραμάτων. Το πρώτο πείραμα αφορά την εκπαίδευση και αξιολόγηση των ταξινομητών σε εξισορροπημένα σύνολα, το δεύτερο την εκπαίδευση με μη ισορροπημένο σύνολο και την αξιολόγηση σε εξισορροπημένο σύνολο και το τρίτο πείραμα την αξιοποίηση της μεθόδου αλλαγής κατωφλίου. Έπειτα, για κάθε πείραμα αναγράφονται όλες οι μετρικές αξιολόγησης, δηλαδή αυτές που προκύπτουν από τις δοκιμές των αλγορίθμων ταξινόμησης στο σύνολο αξιολόγησης, αλλά και οι μετρήσεις του `Edge Impulse`. Επίσης, αναφέρονται οι αντίστοιχες μετρήσεις όταν γίνεται επιλογή χαρακτηριστικών. Τέλος, συγκρίνονται και συζητούνται τα αποτελέσματα, ενώ εξετάζεται ποιο μοντέλο που θα μπορούσε να επιλεγεί ώστε να επιτευχθεί η κατάλληλη ισορροπία μεταξύ της αποδοτικότητας, της κατανάλωσης πόρων και της ταχύτητας.


9.1 Εξισορροπημένα σύνολα εκπαίδευσης και αξιολόγησης

Στην παρούσα ενότητα παρουσιάζονται η μεθοδολογία της εξισορρόπησης ολόκληρου του συνόλου δεδομένων και τα αποτελέσματα της αξιολόγησης για όλους τους ταξινομητές.

9.1.1 Μεθοδολογία

Η μεθοδολογία του πρώτου πειράματος βασίζεται στην εξαγωγή των χαρακτηριστικών, με τον τρόπο που αναφέρθηκε στα προηγούμενα κεφάλαια, στην εξισορρόπηση του πίνακα των χαρακτηριστικών με τον αλγόριθμο `Cluster Centeroids`, την επιλογή των k καλύτερων χαρακτηριστικών, όταν k είναι ίσο με 90, 45, 25 και 12, και στην εκπαίδευση και αξιολόγηση των ταξινομητών χωρίζοντας το αρχικό σύνολο σε σύνολα εκπαίδευσης και αξιολόγησης με τον διαχωρισμό 70-30 και με τη διασταυρωμένη επικύρωση k τμημάτων. Η αξιολόγηση περιλαμβάνει τον υπολογισμό των μετρικών που αντιστοιχούν στην απόδοση των αλγορίθμων, όταν ταξινομούν άγνωστα δεδομένα, αλλά και τις μετρικές που εξάγονται με τη

βοήθεια του Edge Impulse. Στο τέλος, συγκρίνονται τόσο τα αποτελέσματα για τους δύο διαχωρισμούς, όσο και για τα χαρακτηριστικά που επιλέγονται σε κάθε περίπτωση.



Εικόνα 43: Διαγραμματική απεικόνιση της διαδικασίας εκπαίδευσης και αξιολόγησης σε εξισορροπημένα δεδομένα.

9.1.2 Αποτελέσματα

Οι παρακάτω πίνακες συνοψίζουν τις μετρικές αξιολόγησης των ταξινομητών για τον διαχωρισμό 70-30 και την διασταυρωμένη επικύρωση k τμημάτων. Στην δεύτερη περίπτωση, για κάθε μετρική αναγράφεται η μέση τιμή που προκύπτει λαμβάνοντας υπόψη όλες τις επαναλήψεις.

Πίνακας 9: Αποτελέσματα ταξινομητών για όλα τα χαρακτηριστικά στον διαχωρισμό 70-30.

Ταξινομητής	Ακρίβεια	Εναισθησία	Ειδικότητα
LDA	76,74%	82,38%	70,98%
Logistic Regression	73,45%	74,33%	72,55%
SVM	69,00%	87,74%	49,80%
Naïve Bayes	64,73%	92,34%	36,47%
K-NN	65,50%	37,48%	94,12%
Decision Tree	82,95%	82,00%	83,92%
Random Forest	92,25%	95,02%	89,41%
ANN	76,74%	82,76%	70,59%
CNN	92,83%	93,10%	92,55%
RNN	78,89%	73,18%	84,71%
LSTM	80,43%	82,00%	78,82%
GRU	79,65%	78,16%	81,18%

Πίνακας 10: Αποτελέσματα ταξινομητών για όλα τα χαρακτηριστικά στην διασταυρωμένη επικύρωση k τμημάτων.

Ταξινομητής	Ακρίβεια	Εναισθησία	Ειδικότητα
-------------	----------	------------	------------

LDA	75,50%	77,91%	73,18%
Logistic Regression	74,97%	74,64%	75,42%
SVM	70,31%	86,58%	54,12%
Naïve Bayes	64,09%	88,84%	39,42%
K-NN	65,95%	36,98%	94,86%
Decision Tree	82,36%	80,86%	84,05%
Random Forest	92,38%	95,54%	89,31%
ANN	94,65%	94,45%	94,77%
CNN	97,13%	97,01%	97,47%
RNN	92,96%	92,65%	93,27%
LSTM	94,24%	94,23%	94,18%
GRU	92,80%	92,96%	92,58%

Το Edge Impulse λειτουργεί μόνο για τα νευρωνικά δίκτυα, τα οποία αναπτύχθηκαν στο Keras/Tensorflow. Επομένως, αξιολογήθηκε η συμβατότητα των 5 διαφορετικών νευρωνικών δικτύων με το Arduino Nano 33 BLE Sense. Από το παραπάνω πείραμα προέκυψε ότι μόνο τα δίκτυα ANN και CNN, έχουν τη δυνατότητα να εκτελεστούν στον μικροεπεξεργαστή της επιλεγμένης πλατφόρμας. Στον Πίνακα 11, φαίνονται τα αποτελέσματα για τα δύο μοντέλα.

Πίνακας 11: Οι μετρήσεις του Edge Impulse για τα δύο δίκτυα.

Δίκτυο	ROM (Bytes)	RAM (Bytes)	Arena size (Bytes)	Time per Inference (ms)
ANN	156248	4344	4192	4
CNN	777352	113403	113075	1188

Στη συνέχεια, αναφέρονται τα χαρακτηριστικά, που επιλέγονται για κάθε διαφορετική εκτέλεση του αλγορίθμου επιλογής των k καλύτερων χαρακτηριστικών. Παράλληλα, στους πίνακες που ακολουθούν συνοψίζονται οι μετρικές αξιολόγησης των δύο νευρωνικών δικτύων για τον διαχωρισμό 70-30 και την διασταυρωμένη επικύρωση k τμημάτων. Στην δεύτερη περίπτωση, για κάθε μετρική αναγράφεται η μέση τιμή που προκύπτει λαμβάνοντας υπόψη όλες τις επαναλήψεις.

90 χαρακτηριστικά

Πίνακας 12: Τα 90 καλύτερα χαρακτηριστικά (όπου ο αριθμός συμβολίζει το κανάλι από 0-17).

var0	sampEn ₁	rms4	std7	p2p8	rms10	var12	rms13	var15	rms16
kurt0	kurt2	p2p4	rms7	sampEn ₈	p2p10	std12	p2p13	kurt15	p2p16
std0	sampEn ₂	sampEn ₄	p2p7	kurt9	sampEn ₁₀	zcr12	sampEn ₁₃	std15	sampEn ₁₆
zcr0	skew3	kurt5	sampEn ₇	std9	var11	rms12	var14	rms15	var17

rms0	kurt3	sampEn ₅	var8	rms9	kurt11	p2p12	kurt14	p2p15	kurt17
p2p0	sampEn ₃	kurt6	kurt8	p2p9	std11	sampEn ₁₂	std14	sampEn ₁₅	std17
sampEn ₀	var4	sampEn ₆	std8	sampEn ₉	rms11	var13	rms14	var16	rms17
kurt1	kurt4	var7	zcr8	std10	p2p11	kurt13	p2p14	kurt16	p2p17
median ₁	std4	kurt7	rms8	zcr10	sampEn ₁₁	std13	sampEn ₁₄	std16	sampEn ₁₇

45 χαρακτηριστικά

Πίνακας 13: Τα 45 καλύτερα χαρακτηριστικά (όπου ο αριθμός συμβολίζει το κανάλι από 0-17).

rms0	var7	sampEn8	std12	std15
sampEn0	std7	kurt9	rms12	rms15
sampEn1	rms7	sampEn9	p2p12	p2p15
sampEn2	p2p7	sampEn10	sampEn12	sampEn15
sampEn3	sampEn7	std11	sampEn13	kurt16
sampEn4	var8	rms11	std14	p2p16
kurt5	std8	p2p11	rms14	sampEn16
sampEn5	rms8	sampEn11	sampEn14	p2p17
sampEn6	p2p8	var12	var15	sampEn17

25 χαρακτηριστικά

Πίνακας 14: Τα 25 καλύτερα χαρακτηριστικά (όπου ο αριθμός συμβολίζει το κανάλι από 0-17).

sampEn0	sampEn5	rms8	sampEn11	sampEn13
sampEn1	sampEn6	p2p8	var12	sampEn14
sampEn2	sampEn7	sampEn8	std12	sampEn15
sampEn3	var8	sampEn9	rms12	sampEn16
sampEn4	std8	sampEn10	p2p12	sampEn17

12 χαρακτηριστικά

Πίνακας 15: Τα 12 καλύτερα χαρακτηριστικά (όπου ο αριθμός συμβολίζει το κανάλι από 0-17).

sampEn0	sampEn6	p2p8
---------	---------	------


sampEn1	sampEn7	rms12
sampEn2	std8	sampEn16
sampEn5	rms8	sampEn17

Πίνακας 16: Οι μετρικές των δύο νευρωνικών δικτύων για διαφορετικό πλήθος χαρακτηριστικών εισόδου στον διαχωρισμό 70-30.


Χαρακτηριστικά	Δίκτυο	Ακρίβεια	Ευαισθησία	Ειδικότητα
180	ANN	76,74%	82,76%	70,59%
	CNN	92,83%	93,10%	92,55%
90	ANN	82,95%	86,59%	79,22%
	CNN	88,57%	90,42%	86,67%
45	ANN	85,85%	82,38%	89,41%
	CNN	90,51%	91,57%	89,41%
25	ANN	88,37%	87,77%	89,02%
	CNN	91,86%	93,87%	89,80%
12	ANN	84,50%	83,91%	85,10%
	CNN	91,09%	90,80%	91,37%

Πίνακας 17: Οι μετρικές των δύο νευρωνικών δικτύων για διαφορετικό πλήθος χαρακτηριστικών εισόδου στην διασταυρωμένη επικύρωση k τμημάτων.

Χαρακτηριστικά	Δίκτυο	Ακρίβεια	Ευαισθησία	Ειδικότητα
180	ANN	94,65%	94,45%	94,77%
	CNN	97,13%	97,01%	97,47%
90	ANN	96,16%	97,25%	95,05%
	CNN	95,99%	96,18%	95,73%
45	ANN	95,64%	95,99%	95,31%
	CNN	95,46%	96,69%	94,27%
25	ANN	95,40%	95,74%	95,01%
	CNN	93,83%	96,07%	91,73%
12	ANN	88,42%	95,13%	94,30%
	CNN	90,86%	90,17%	91,63%



Εικόνα 44: Όλα τα αποτελέσματα των ANN και CNN για τον διαχωρισμό 70-30.



Εικόνα 45: Όλα τα αποτελέσματα των ANN και CNN για το K-fold cross validation.

Ακολουθούν τα αποτελέσματα του πακέτου Edge Impulse για τα δύο νευρωνικά δίκτυα, καθώς μειώνεται το πλήθος των χαρακτηριστικών που απαιτούνται ως είσοδος.

Πίνακας 18: Όλες οι μετρήσεις του Edge Impulse.


Χαρακτηριστικά	Δίκτυο	ROM (Bytes)	RAM (Bytes)	Arena size (Bytes)	Time per Inference (ms)
180	ANN	156248	4344	4192	4
	CNN	777352	113403	113075	1188
90	ANN	110240	3921	3769	3
	CNN	408712	58107	57779	516
45	ANN	87208	3787	3635	2
	CNN	220296	30459	30131	191
25	ANN	76968	3787	3635	2
	CNN	138376	18171	17843	116
12	ANN	70312	3787	3635	2
	CNN	89288	10184	9856	97

9.2 Μη ισορροπημένο σύνολο εκπαίδευσης και ισορροπημένο σύνολο αξιολόγησης

Η παραπάνω προσέγγιση, αν και έχει ενθαρρυντικά αποτελέσματα, είναι πολύ πιθανό να μην αντιπροσωπεύει την λειτουργία των ταξινομητών σε δεδομένα πραγματικού χρόνου, όπου θα υπήρχε ένας αρκετά μεγάλος βαθμός ανισορροπίας των κλάσεων. Επομένως, ως επόμενο βήμα δοκιμάστηκε η εκπαίδευση των αλγορίθμων σε μη ισορροπημένο σύνολο και η αξιολόγηση σε ισορροπημένο σύνολο, ώστε να διαπιστωθεί η αποδοτικότητά τους σε πραγματικά δεδομένα. Στη συνέχεια αυτής της ενότητας, αναλύεται η παραπάνω μεθοδολογία και παρουσιάζονται τα αποτελέσματα της αξιολόγησης για τους ταξινομητές.

9.2.1 Μεθοδολογία

Η μεθοδολογία είναι παρόμοια με αυτή του προηγούμενου πειράματος, όμως διαφέρει στο στάδιο της υποδειγματοληψίας. Το σύνολο των χαρακτηριστικών, πρώτα χωρίζεται σε σύνολα εκπαίδευσης και αξιολόγησης, με τη μέθοδο 70-30, και έπειτα το κάθε σύνολο υποβάλλεται σε υποδειγματοληψία επικρατούσας κλάσης. Στην περίπτωση του σετ εκπαίδευσης, εφαρμόζεται Cluster Centeroids με ποσοστό 0,2, για την εξομάλυνση της υπερβολικής ανισορροπίας μεταξύ των κλάσεων αλλά όχι την πλήρη εξισορρόπηση του συνόλου. Στο σετ αξιολόγησης εφαρμόζεται Cluster Centeroids, έτσι ώστε το σύνολο να είναι πλέον ισορροπημένο.



Εικόνα 46: Διαγραμματική απεικόνιση της διαδικασίας εκπαίδευσης με μη εξισορροπημένα δεδομένα και αξιολόγησης με εξισορροπημένα δεδομένα.

9.2.2 Αποτελέσματα


Στους παρακάτω πίνακες φαίνονται οι μετρικές αξιολόγησης των ταξινομητών για τον διαχωρισμό 70-30, για όλα τα χαρακτηριστικά άλλα και για την επιλογή χαρακτηριστικών. Σημειώνεται ότι τα επιλεγμένα χαρακτηριστικά είναι τα ίδια που επιλέχθηκαν στο πρώτο πείραμα.

Πίνακας 19: Αποτελέσματα ταξινομητών για όλα τα χαρακτηριστικά με διαχωρισμό 70-30.

Ταξινομητής	Ακρίβεια	Εναισθησία	Ειδικότητα
LDA	65,15%	33,20%	97,10%
Logistic Regression	68,67%	40,25%	97,10%
SVM	62,86%	31,12%	94,61%
Naïve Bayes	64,11%	85,48%	42,74%
K-NN	60,37%	21,99%	98,76%
Decision Tree	70,54%	48,55%	92,53%
Random Forest	76,35%	52,70%	100%
ANN	80,91%	63,07%	98,76%
CNN	82,37%	66,40%	98,34%
RNN	73,03%	49,79%	96,27%
LSTM	72,82%	48,13%	97,51%
GRU	81,95%	65,98%	97,93%

Πίνακας 20: Οι μετρικές των δύο νευρωνικών δικτύων για διαφορετικό πλήθος χαρακτηριστικών εισόδου στον διαχωρισμό 70-30.

Χαρακτηριστικά	Δίκτυο	Ακρίβεια	Εναισθησία	Ειδικότητα
180	ANN	80,91%	63,07%	98,76%
	CNN	82,37%	66,40%	98,34%
90	ANN	80,91%	67,22%	98,76%
	CNN	90,04%	80,91%	99,17%
45	ANN	74,90%	53,94%	95,85%
	CNN	73,03%	51,04%	95,02%
25	ANN	77,18%	64,73%	89,63%
	CNN	67,84%	38,59%	97,10%
12	ANN	61,00%	27,80%	94,19%
	CNN	50,00%	0%	100%




Εικόνα 47: Όλα τα αποτελέσματα των ANN και CNN για τον διαχωρισμό 70-30.

9.3 Αλλαγή κατωφλίου

Μια πιο αξιόπιστη προσέγγιση, έναντι της εξισορρόπησης του συνόλου, θα ήταν η αλλαγή του κατωφλίου. Εφόσον δεν γίνεται υποδειγματοληψία, υπάρχει ένας μεγάλος όγκος δεδομένων και η εκπαίδευση όλων των ταξινομητών θα ήταν μια πολύ χρονοβόρα διαδικασία, γι' αυτό τον λόγο αυτή η μέθοδος εφαρμόστηκε μόνο στα δύο νευρωνικά δίκτυα ANN και CNN. Σε αυτή την ενότητα αναλύονται η μέθοδος επιλογής του βέλτιστου κατωφλίου και τα αποτελέσματα της αξιολόγησης των δύο νευρωνικών δικτύων.

9.3.1 Μεθοδολογία

Αυτή η μέθοδος είναι αρκετά παρόμοια με τις προηγούμενες, με τη διαφορά ότι αντί της εφαρμογής υποδειγματοληψίας δοκιμάστηκε η μέθοδος αλλαγής κατωφλίου στα δύο νευρωνικά δίκτυα ANN και CNN. Η επιλογή του κατάλληλου κατωφλίου έγινε με τη βοήθεια της καμπύλης ROC, η οποία δείχνει το ποσοστό αληθώς θετικών προς το ποσοστό των ψευδών θετικών για διαφορετικές τιμές κατωφλίου.




Εικόνα 48: Διαγραμματική απεικόνιση της διαδικασίας επιλογής κατωφλίου.


9.3.2 Αποτελέσματα

Στις εικόνες που ακολουθούν απεικονίζονται οι καμπύλες ROC για τα δυο νευρωνικά δίκτυα, δίνοντας ως είσοδο κάθε φορά διαφορετικό πλήθος χαρακτηριστικών. Από αυτές επιλέγεται και το βέλτιστο κατώφλι σε κάθε περίπτωση.

180 χαρακτηριστικά




Εικόνα 49: Η καμπύλη ROC του ANN για όλα τα χαρακτηριστικά (Best Threshold=0.005795).




Εικόνα 50: Η καμπύλη ROC του CNN για όλα τα χαρακτηριστικά (Best Threshold=0.015047).

90 χαρακτηριστικά




Εικόνα 51: Η καμπύλη ROC του ANN για 90 χαρακτηριστικά (Best Threshold=0.011350).




Εικόνα 7: Η καμπύλη ROC του CNN για όλα τα χαρακτηριστικά (Best Threshold=0.013202).


45 χαρακτηριστικά




Εικόνα 53: Η καμπύλη ROC του ANN για 45 χαρακτηριστικά (Best Threshold=0.009954).




Εικόνα 54: Η καμπύλη ROC του CNN για 45 χαρακτηριστικά (Best Threshold=0.012307).

25 χαρακτηριστικά


Εικόνα 55: Η καμπύλη ROC του ANN για 25 χαρακτηριστικά (Best Threshold=0.011994).



Εικόνα 56: Η καμπύλη ROC του CNN για 25 χαρακτηριστικά (Best Threshold=0.013747).

12 χαρακτηριστικά

Εικόνα 57: Η καμπύλη ROC του ANN για 12 χαρακτηριστικά (Best Threshold=0.009001).




Εικόνα 58: Η καμπύλη ROC του CNN για 12 χαρακτηριστικά (Best Threshold=0.012022).

Στον παρακάτω πίνακα φαίνονται οι μετρικές αξιολόγησης των ταξινομητών για τον διαχωρισμό 70-30, για όλα τα χαρακτηριστικά άλλα και για την επιλογή χαρακτηριστικών. Σημειώνεται ότι τα επιλεγμένα χαρακτηριστικά είναι τα ίδια που επιλέχθηκαν στο αρχικό πείραμα.

Πίνακας 21: Οι μετρικές των δύο νευρωνικών δικτύων για διαφορετικό πλήθος χαρακτηριστικών εισόδου στον διαχωρισμό 70-30.

Χαρακτηριστικά	Δίκτυο	Ακρίβεια	Ευαισθησία	Ειδικότητα
180	ANN	74,05%	82,57%	73,94%
	CNN	81,25%	78,00%	81,30%
90	ANN	84,08%	78,84%	84,15%
	CNN	85,32%	77,18%	85,42%
45	ANN	75,76%	80,08%	75,70%
	CNN	84,09%	74,69%	84,21%
25	ANN	80,11%	78,84%	80,13%
	CNN	79,19%	72,20%	79,28%
12	ANN	67,25%	65,15%	67,28%

	CNN	70,72%	61,00%	70,84%
--	-----	--------	--------	--------



Εικόνα 59: Όλα τα αποτελέσματα των ANN και CNN για τον διαχωρισμό 70-30.

9.4 Συζήτηση

Από τα αποτελέσματα, του πρώτου πειράματος παρατηρείται ότι υπάρχουν ελαφρώς υψηλότερες επιδόσεις στην διασταυρωμένη επικύρωση k τμημάτων σε σχέση με τον διαχωρισμό 70-30. Παράλληλα, φαίνεται ότι και τα δύο δίκτυα πετυχαίνουν αρκετά υψηλές επιδόσεις και για τα μειωμένα χαρακτηριστικά. Ωστόσο στο δεύτερο πείραμα, όπου αντικατοπτρίζονται οι επιδόσεις των ταξινομητών στα πραγματικά δεδομένα, παρουσιάζεται μεγάλη μείωση των μετρικών σε σχέση με το πρώτο πείραμα, ειδικά στην ευαισθησία. Επιπροσθέτως, βλέπουμε ότι όσο μειώνονται τα χαρακτηριστικά μειώνονται σημαντικά και οι επιδόσεις των δύο δικτύων, με εξαίρεση το δίκτυο CNN όταν δίνονται ως είσοδος 90 χαρακτηριστικά όπου οι μετρικές είναι αυξημένες. Στο τρίτο πείραμα, έχουμε καλύτερα αποτελέσματα σε σχέση με το δεύτερο πείραμα, με τα δίκτυα παρουσιάζουν παρόμοια αποτελέσματα εκτός από την περίπτωση των 12 χαρακτηριστικών. Γενικά και στα τρία πειράματα βλέπουμε ότι όταν δίνουμε ως είσοδο 12 χαρακτηριστικά οι επιδόσεις των ταξινομητών είναι αρκετά χαμηλότερες. Παρατηρώντας τα αποτελέσματα του Edge Impulse, βλέπουμε ότι όσο μειώνονται τα απαιτούμενα δεδομένα εισόδου τόσο λιγότερες είναι και οι απαιτήσεις σε μνήμη και σε χρόνο. Το δίκτυο ANN απαιτεί λιγότερο χώρο και χρόνο, σε αντίθεση με το δίκτυο CNN.

Η τελική επιλογή δικτύου πρέπει να γίνει λαμβάνοντας υπόψιν το αρχικό πρόβλημα και τους συμβιβασμούς που επιτρέπεται να κάνουμε ως προς την αποτελεσματικότητα και την χρήση πόρων. Με βάση το πρώτο πείραμα θα λέγαμε ότι μια καλή επιλογή θα ήταν το ANN με 25 χαρακτηριστικά, καθώς συνδυάζει υψηλά ποσοστά ευαισθησίας, ελάχιστες απαιτήσεις μνήμης και μικρό χρόνο εκτέλεσης. Όμως, σύμφωνα με το δεύτερο πείραμα, καταλαβαίνουμε ότι είναι πολύ πιθανό το συγκεκριμένο δίκτυο να αποδειχθεί αναποτελεσματικό όταν δοκιμαστεί στην ανίχνευση επιληπτικών κρίσεων σε πραγματικό χρόνο. Στην περίπτωση αυτή, οδηγούμαστε στην επιλογή του CNN με 90 χαρακτηριστικά ως είσοδο. Βάσει του τρίτου πειράματος καταλαβαίνουμε ότι η αλλαγή κατωφλίου βελτιώνει ως ένα βαθμό τα αποτελέσματα. Από το δεύτερο και τρίτο πείραμα δεν προκύπτει κάποιος ταξινομητής, ο οποίος θα ήταν

αρκετά αξιόπιστος για την ανίχνευση επιληπτικών κρίσεων σε πραγματικό χρόνο, λόγω των χαμηλών ποσοστών ευαισθησίας.

10 Συμπεράσματα

Στο τελευταίο κεφάλαιο της παρούσας πτυχιακής εργασίας συζητούνται τα συμπεράσματα των προσεγγίσεων που ακολουθήσαμε, οι περιορισμοί που συναντήσαμε, αλλά και οι μελλοντικές έρευνες και επεκτάσεις, στις οποίες θα μπορούσαν να αξιοποιηθούν τα αποτελέσματα μας.

10.1 Συμπεράσματα

Ο στόχος της παρούσας εργασίας ήταν η σχεδίαση ενός συστήματος γενικευμένης ανίχνευσης επιληπτικών κρίσεων βασισμένο στην τεχνολογία TinyML. Για την υλοποίηση του στόχου, διατηρήθηκαν τα αρχεία του συνόλου CHB-MIT που περιέχουν επιληπτική κρίση και τα 18 κοινά κανάλια που συναντώνται σε όλες τις καταγραφές. Στη συνέχεια, τα δεδομένα χωρίστηκαν στις κλάσεις «επιληπτική κρίση» και «μη επιληπτική κρίση» και τμηματοποιήθηκαν ανά 2 δευτερόλεπτα. Στο πεδίο του χρόνου εξήχθησαν η μέση τιμή, η διάμεσος, η διακύμανση, η τυπική απόκλιση, η ασυμμετρία, η κύρτωση, ο ρυθμός διάσχισης μηδενικού άξονα, η ενεργός μέση τιμή, το εύρος μεταβολής και η εντροπία δείγματος. Ο πίνακας των χαρακτηριστικών, που αποτελούταν από 180 χαρακτηριστικά, κανονικοποιήθηκε και αφαιρέθηκαν οι μη αριθμητικές τιμές. Έπειτα, έγινε επιλογή των k καλύτερων χαρακτηριστικών για k ίσο με 90, 45, 25 και 12. Το σύνολο χαρακτηριστικών που προέκυψε παρουσίαζε υψηλό βαθμό ανισορροπίας μεταξύ των δύο κλάσεων και γι' αυτό αποφασίσαμε να εκτελέσουμε 3 διαφορετικά πειράματα για την αντιμετώπιση της ανισορροπίας με διαφορετικούς τρόπους. Συγκεκριμένα, στο πρώτο πείραμα και στο δεύτερο πείραμα έχουμε εφαρμόσει υποδειγματοληψία επικρατούσας κλάσης σε ολόκληρο το σύνολο δεδομένων και μόνο στο σύνολο αξιολόγησης αντίστοιχα. Στο τελευταίο πείραμα έχουμε εφαρμόσει αλλαγή κατωφλίου. Επιπροσθέτως, σε όλα τα πειράματα διαχωρίζουμε το σύνολο με τη μέθοδο 70-30 σε σετ εκπαίδευσης και αξιολόγησης, όμως στο πρώτο πείραμα δοκιμάζεται και η διασταυρωμένη επικύρωση k τμημάτων.

Για την διερεύνηση της ταξινόμησης αναπτύχθηκε ένα ευρύ φάσμα ταξινομητών. Ειδικότερα, σχεδιάστηκαν ένας ταξινομητής γραμμικής διακριτικής ανάλυσης, ένας ταξινομητής λογιστικής παλινδρόμησης, μια μηχανή υποστήριξης διανυσμάτων, ένας απλοϊκός Bayes, ένας ταξινομητής k πλησιέστερων γειτόνων, ένα δέντρο απόφασης, ένας αλγόριθμος τυχαίου δάσους, ένα απλό νευρωνικό δίκτυο, ένα συνελκτικό νευρωνικό δίκτυο, ένα αναδρομικό νευρωνικό δίκτυο, ένα δίκτυο μακράς βραχύχρονης μνήμης και μια περιφραγμένη επαναλαμβανόμενη μονάδα. Ο κάθε ταξινομητής αξιολογήθηκε με τις μετρικές της ακρίβειας, της ευαισθησίας και της ειδικότητας, που εκφράζουν τη δυνατότητα γενίκευσης του μοντέλου, και τις μετρικές μνήμης και χρόνου αποτελέσματος, που απαιτούνται για την εκτέλεσή του μοντέλου στον μικροελεγκτή του Arduino Nano 33 BLE Sense.

Τελικά, μόνο το απλό νευρωνικό δίκτυο και το συνελκτικό νευρωνικό δίκτυο ήταν συμβατά με τον μικροελεγκτή της επιλεγμένης πλατφόρμας. Ακόμα, ενώ στο πρώτο πείραμα οι επιδόσεις των δύο δικτύων είναι αρκετά υψηλές, δεν μπορούμε να εγγυηθούμε ότι θα έχουν τα ίδια αποτελέσματα σε πραγματικό χρόνο. Τα άλλα δύο πειράματα είναι πιο αξιόπιστα, όμως σε καμία περίπτωση συνδυασμού δικτύου και πλήθους χαρακτηριστικών το ποσοστό της ευαισθησίας δεν ξεπερνά το 85%.

10.2 Περιορισμοί

Κατά την διεξαγωγή της πειραματικής διαδικασίας συναντήσαμε αρκετές δυσκολίες και περιορισμούς, κυρίως λόγω της πολυπλοκότητας του παρόντος εγχειρήματος. Συγκεκριμένα, το μεγαλύτερο εμπόδιο αποτέλεσε η μη συμβατότητα πολλών μοντέλων μηχανικής μάθησης με την τεχνολογία TinyML και η δυσκολία εύρεσης σχετικών πληροφοριών και εργαλείων, καθώς είναι ακόμα μια πρώιμη τεχνολογία.

Άλλο ένα σημαντικό πρόβλημα ήταν η μη ισορροπία του συνόλου δεδομένων CHB-MIT και ειδικότερα η μη διαθεσιμότητα καταγραφών επιληπτικών κρίσεων. Αυτό μας οδήγησε στην αντιμετώπιση του προβλήματος με διαφορετικές μεθόδους, όπως η υποδειγματοληψία των δειγμάτων που αντιστοιχούν στην μη επιληπτική κρίση και η αλλαγή κατωφλίου στους ταξινομητές. Γενικά, η εξισορρόπηση ολόκληρου του συνόλου, είναι μια μέθοδος που χρησιμοποιείται συχνά, όμως δεν έχει πρακτικά αποτελέσματα.

10.3 Μελλοντικές επεκτάσεις

Η βασικότερη επέκταση των αποτελεσμάτων της παρούσας πτυχιακής εργασίας είναι η περαιτέρω διερεύνηση ή βελτιστοποίηση των νευρωνικών δικτύων και η εκτέλεση του βέλτιστου μοντέλου στον μικροελεγκτή του Arduino Nano 33 BLE Sense για τη λήψη σημαντικών μετρήσεων, όπως η κατανάλωση ενέργειας. Ένα επόμενο βήμα, θα ήταν η σχεδίαση και αξιολόγηση ενός φορητού συστήματος που, εκτός της ταξινόμησης, θα εκτελεί την λήψη και εξαγωγή δεδομένων σε πραγματικό χρόνο.

Επιπροσθέτως, θα μπορούσε να γίνει παρόμοια μελέτη εξάγοντας διαφορετικά χαρακτηριστικά, όπως χαρακτηριστικά στο πεδίο της συχνότητας ή στο πεδίο του χρόνου προς τη συχνότητα ή εφαρμόζοντας διαφορετικές μεθόδους εξισορρόπησης των δεδομένων ή ακόμα χρησιμοποιώντας διαφορετικό σύνολο δεδομένων με περισσότερες εγγραφές επιληπτικών κρίσεων.

Τέλος, θα παρουσίαζε ιδιαίτερο ενδιαφέρον η διερεύνηση των συσχετίσεων μεταξύ των καναλιών του ΗΕΓ και η διατήρηση μόνο αυτών που συνεισφέρουν περισσότερο στην ορθότερη ταξινόμηση, δηλαδή να εφαρμοστεί επιλογή καναλιών αντί της επιλογής χαρακτηριστικών. Έτσι, θα ήταν δυνατό να αφαιρεθούν τα κανάλια, τα οποία δεν προσφέρουν χρήσιμες πληροφορίες στους ταξινομητές, ανοίγοντας τον δρόμο για την ανάπτυξη ενός άνετου φορητού συστήματος χαμηλότερης κατανάλωσης ενέργειας.

Αναφορές

- [1] A. Joby, «A Tiny Introduction to TinyML,» 14 Φεβρουαρίου 2022. [Ηλεκτρονικό]. Available: <https://www.g2.com/articles/introduction-to-tinyml>. [Πρόσβαση 12 Σεπτεμβρίου 2023].
- [2] Κ. Σιδηροπούλου, Βασικές αρχές λειτουργίας του νευρικού συστήματος: από τη νευροφυσιολογία στη συμπεριφορά, Κάλλιπος, Ανοικτές Ακαδημαϊκές Εκδόσεις, 2015.
- [3] Δ. Κουτσούρης, Σ. Παυλόπουλος και Α. Πρέντζα, «Φυσιολογία εγκεφάλου και ηλεκτροεγκεφαλογράφημα,» σε *Εισαγωγή στη βιοϊατρική τεχνολογία και ανάλυση ιατρικών σημάτων*, Θεσσαλονίκη, Τζιόλα, 2003, pp. 181-215.
- [4] M. Mumenthaler και H. Mattle, «Epilepsy, Other Episodic Disorders of Neurologic Function, and Sleep Disorders,» σε *Neurology*, 4η Έκδοση επιμ., E. Taub, Επιμ., Νέα Υόρκη, Thieme, 2004, pp. 493-547.
- [5] «Epilepsy,» Επίσημη Ιστοσελίδα του Παγκόσμιου Οργανισμού Υγείας, [Ηλεκτρονικό]. Available: <https://www.who.int/news-room/fact-sheets/detail/epilepsy>. [Πρόσβαση 26 Απρίλιος 2023].
- [6] R. S. Fisher και άλλοι, «ILAE Official Report: A practical clinical definition of epilepsy,» *Epilepsia*, τόμ. 55, αρ. 4, pp. 475-482, Απρίλιος 2014.
- [7] I. E. Scheffer και άλλοι, «ILAE classification of the epilepsies: Position paper of the ILAE Commission for Classification and Terminology,» *Epilepsia*, τόμ. 58, αρ. 4, p. 512–521, Μάρτιος 2017.
- [8] H. Mattle και M. Mumenthaler, «Epilepsy and Its Differential Diagnosis,» σε *Fundamentals of Neurology*, 2η Έκδοση επιμ., E. Taub, Επιμ., Νέα Υόρκη, Thieme, 2017, pp. 247-264.
- [9] Δ. Αντωνίου και Β. Πρασόπουλος, «Επιληψία,» σε *Κλινική και εργαστηριακή Πυρηνική Ιατρική σε 20 ειδικότητες*, Θεσσαλονίκη, Εκδοτικός Οίκος Αδελφών Κυριακίδη Α.Ε., 2014, pp. 204-208.
- [10] S. J. M. Smith, «EEG in the Diagnosis, Classification, and Management of patients with Epilepsy,» *Journal of Neurology, Neurosurgery & Psychiatry*, τόμ. 76, αρ. 2, Ιούνιος 2005.
- [11] J. G. Webster και άλλοι, Ιατρική Οργανολογία: Εφαρμογή και Σχεδιασμός, 1η Ελληνική Έκδοση επιμ., I. Βαλαής, N. Κοντοδημόπουλος και I. Λούκος, Επιμ., Περιστέρι: ιών εκδόσεις έλλην, 2004.
- [12] D. W. McCandless, «Quality of Life for Epileptics,» σε *Epilepsy: Animal and Human Correlations*, Νέα Υόρκη, Springer, 2012, pp. 445-456.
- [13] Α. Μ. Σιγάλα, «ΜΕΛΕΤΗ ΤΟΥ ΕΠΙΠΕΔΟΥ ΤΗΣ ΠΟΙΟΤΗΤΑΣ ΖΩΗΣ ΓΙΑ ΑΤΟΜΑ ΜΕ ΕΠΙΛΗΨΙΑ ΣΤΗΝ ΕΛΛΑΔΑ,» 2012. [Ηλεκτρονικό]. Available: <https://dione.lib.unipi.gr/xmlui/handle/unipi/4863>. [Πρόσβαση 27 Απρίλιος 2023].
- [14] R. Fisher και άλλοι, «How Can We Identify Ictal and Interictal Abnormal Activity?,» σε *Issues in Clinical Epileptology: A View from the Bench. Advances in Experimental Medicine and Biology*, τόμ. 813, H. Scharfman και P. Buckmaster, Επιμ., Dordrecht, Springer, 2014, pp. 3-23.
- [15] I. Βλαχάβας και άλλοι, Τεχνητή Νοημοσύνη, 4η Έκδοση επιμ., Θεσσαλονίκη: Εκδόσεις Πανεπιστημίου Μακεδονίας, 2020.
- [16] Β. Τσούκας και άλλοι, «A Review of Machine Learning and TinyML in Healthcare,» *25th Pan-Hellenic Conference on Informatics*, pp. 69-73, Νοέμβριος 2021.
- [17] S. Maitanmi και άλλοι, «Embedded Systems in Healthcare Systems,» *1st International Conference on Advanced Computerised Systems and Emerging Technologies*, pp. 74-77, 2014.
- [18] W. Shi και άλλοι, «Edge Computing: Vision and Challenges,» *IEEE Internet of Things Journal*, τόμ. 3, αρ. 5, pp. 637-646, Οκτώβρης 2016.
- [19] «About,» tinyML Foundation, [Ηλεκτρονικό]. Available: <https://www.tinyml.org/about/>. [Πρόσβαση 1 Μαΐου 2023].
- [20] «TensorFlow Lite for Microcontrollers,» tensorflow, [Ηλεκτρονικό]. Available: <https://www.tensorflow.org/lite/microcontrollers>. [Πρόσβαση 4 Μαΐου 2023].

- [21] S. Siuly και άλλοι, «Significance of EEG Signals in Medical and Health Research: Techniques and Applications,» σε *EEG Signal Analysis and Classification, Health Information Science*, Ζούγκ, Ολλανδία, Springer, 2016, pp. 23-43.
- [22] S. Beniczky και άλλοι, «Machine learning and wearable devices of the future,» *Epilepsia*, τόμ. 62, αρ. 2, pp. 116-124, 2021.
- [23] A. Shoeb και J. Guttag, «Application of machine learning to epileptic seizure detection,» *Proceedings of the 27th International Conference on International Conference on Machine Learning*, pp. 975-982, 2010.
- [24] Y. Khan και άλλοι, «Automatic Detection of Seizure ONSET in Pediatric EEG,» *International Journal of Embedded Systems and Applications (IJESA)*, τόμ. 2, αρ. 3, pp. 81-89, 2012.
- [25] L. S. Vidyaratne και K. M. Iftikharuddin, «Real-Time Epileptic Seizure Detection Using EEG,» *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, τόμ. 25, αρ. 11, pp. 2146-2156, 2017.
- [26] N. Ahammad και άλλοι, «Detection of Epileptic Seizure Event and Onset Using EEG,» *BioMed Research International*, τόμ. 2014, 2014.
- [27] J. Birjandtalab και άλλοι, «Automated seizure detection using limited-channel EEG and non-linear dimension reduction,» *Computers in Biology and Medicine*, τόμ. 82, pp. 49-58, 2017.
- [28] E. Alickovic και άλλοι, «Performance evaluation of empirical mode decomposition, discrete wavelet transform, and wavelet packed decomposition for automated epileptic seizure detection and prediction,» *Biomedical Signal Processing and Control*, τόμ. 39, pp. 94-102, 2018.
- [29] P. Fergus και άλλοι, «A machine learning system for automated whole-brain seizure detection,» *Applied Computing and Informatics*, τόμ. 12, αρ. 1, pp. 70-89, 2016.
- [30] L. Orosco, «Patient non-specific algorithm for seizures detection in scalp EEG,» *Computers in Biology and Medicine*, τόμ. 71, pp. 128-134, 2016.
- [31] X. Πατσούρας, *Ανίχνευση κρίσεων επιληψίας σε δεδομένα ηλεκτροεγκεφαλογράφου*, Αθήνα: Τμήμα Πληροφορικής & Τηλεπικοινωνιών, ΕΚΠΑ, 2020.
- [32] L. Vidyaratne και άλλοι, «Deep recurrent neural network for seizure detection,» *2016 International Joint Conference on Neural Networks (IJCNN)*, pp. 1202-1207, 2016.
- [33] S. Kiranyaz και άλλοι, «Automated patient-specific classification of long-term Electroencephalography,» *Journal of Biomedical Informatics*, τόμ. 49, pp. 16-31, 2014.
- [34] X. Hu και άλλοι, «Scalp EEG classification using deep Bi-LSTM network for seizure detection,» *Computers in Biology and Medicine*, τόμ. 124, 2020.
- [35] G. C. Jana και άλλοι, «A 1D-CNN-Spectrogram Based Approach for Seizure Detection from EEG Signal,» *Procedia Computer Science*, τόμ. 167, pp. 403-412, 2020.
- [36] M. S. Hossain και άλλοι, «Applying Deep Learning for Epilepsy Seizure Detection and Brain Mapping Visualization,» *ACM Transactions on Multimedia Computing, Communications, and Applications*, τόμ. 15, αρ. 1, 2019.
- [37] C. Park και άλλοι, «Epileptic seizure detection for multi-channel EEG with deep convolutional neural network,» *2018 International Conference on Electronics, Information, and Communication (ICEIC)*, 2018.
- [38] Y. Yuan και άλλοι, «A Multi-View Deep Learning Framework for EEG Seizure Detection,» *IEEE Journal of Biomedical and Health Informatics*, τόμ. 23, αρ. 1, pp. 83-94, 2019.
- [39] Z. Wei και άλλοι, «Automatic epileptic EEG detection using convolutional neural network with improvements in time-domain,» *Biomedical Signal Processing and Control*, τόμ. 53, 2019.
- [40] R. Yuvaraj και άλλοι, «A deep Learning Scheme for Automatic Seizure Detection from Long-Term Scalp EEG,» *2018 52nd Asilomar Conference on Signals, Systems, and Computers*, Τόμ. 1 από 1, pp. 368-372, 2018.

- [41] A. Abdelhameed και M. Bayoumi, «A Deep Learning Approach for Automatic Seizure Detection in Children With Epilepsy,» *Frontiers in Computational Neuroscience*, τόμ. 15, 2021.
- [42] A. L. Dobre και άλλοι, «Monitoring System For Patients With Epilepsy,» *2021 International Conference on e-Health and Bioengineering (EHB)*, Σεπτέμβριος 2021.
- [43] M. El Menshawy και άλλοι, «An automatic mobile-health based approach for EEG epileptic seizures detection,» *Expert Systems with Applications*, τόμ. 42, αρ. 20, pp. 7157-7174, 2015.
- [44] J. Yoo και άλλοι, «An 8-Channel Scalable EEG Acquisition SoC With Patient-Specific Seizure Classification and Recording Processor,» *IEEE Journal of Solid-State Circuits*, τόμ. 48, αρ. 1, pp. 214-228, 2013.
- [45] C. Zhang και άλλοι, «Design and Implementation of an On-Chip Patient-Specific Closed-Loop Seizure Onset and Termination Detection System,» *IEEE Journal of Biomedical and Health Informatics*, τόμ. 20, αρ. 4, pp. 996-1007, 2016.
- [46] M. Sahani και άλλοι, «FPGA implementation of epileptic seizure detection using semisupervised reduced deep convolutional neural network,» *Applied Soft Computing*, τόμ. 110, 2021.
- [47] A. Page και άλλοι, «Wearable seizure detection using convolutional neural networks with transfer learning,» *2016 IEEE International Symposium on Circuits and Systems (ISCAS)*, pp. 1086-1089, Μάιος 2016.
- [48] T. Moy και άλλοι, «An EEG Acquisition and Biomarker-Extraction System Using Low-Noise-Amplifier and Compressive-Sensing Circuits Based on Flexible, Thin-Film Electronics,» *IEEE Journal of Solid-State Circuits*, τόμ. 52, αρ. 1, pp. 309-321, 2017.
- [49] X. Liu και A. G. Richardson, «Edge deep learning for neural implants: a case study of seizure detection and prediction,» *Journal of Neural Engineering*, τόμ. 18, αρ. 4, 2021.
- [50] D. Sopic και άλλοι, «e-Glass: A Wearable System for Real-Time Detection of Epileptic Seizures,» *2018 IEEE International Symposium on Circuits and Systems (ISCAS)*, 2018.
- [51] S. K. Lin και άλλοι, «An Ultra-Low Power Smart Headband for Real-Time Epileptic Seizure Detection,» *IEEE Journal of Translational Engineering in Health and Medicine*, τόμ. 6, 2018.
- [52] M. Shoaib και άλλοι, «A 0.6–107 μ W Energy-Scalable Processor for Directly Analyzing Compressively-Sensed EEG,» *IEEE Transactions on Circuits and Systems I: Regular Papers*, τόμ. 61, αρ. 4, pp. 1105-1118, 2014.
- [53] «epihunter,» [Ηλεκτρονικό]. Available: <https://www.epihunter.com/>.
- [54] «mjn-SERAS,» [Ηλεκτρονικό]. Available: <https://mjn.cat/en/>.
- [55] «SeizeIT2,» [Ηλεκτρονικό]. Available: <https://eithealth.eu/product-service/seizeit2/>.
- [56] S. Boeckx και άλλοι, «Live Demonstration: SeizeIT - A wearable multimodal epileptic seizure detection device,» *2018 IEEE Biomedical Circuits and Systems Conference (BioCAS)*, 2018.
- [57] A. H. Shoeb, *Application of machine learning to epileptic seizure onset detection and treatment*, Μασαχουσέτη, ΗΠΑ: Massachusetts Institute of Technology, 2009.
- [58] A. Goldberger και άλλοι, «PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals,» *Circulation*, τόμ. 101, αρ. 23, p. 215–220, 2000.
- [59] «Περιγραφική Στατιστική,» *Στατιστική Ι*, 2016.
- [60] R. G. Bachu και άλλοι, «Separation of Voiced and Unvoiced using Zero crossing rate and Energy of the Speech Signal,» *Electrical Engineering Department. School of Engineering. University of Bridgeport*, 2008.
- [61] «Measurements of AC Magnitude,» [Ηλεκτρονικό]. Available: <https://www.allaboutcircuits.com/textbook/alternating-current/chpt-1/measurements-ac-magnitude/>. [Πρόσβαση 15 Σεπτεμβρίου 2023].
- [62] J. S. Richman και J. R. Moorman, «Physiological time-series analysis using approximate entropy and

- sample entropy,» *American Journal of Physiology-Heart and Circulatory Physiology*, τόμ. 278, αρ. 6, pp. H2039-H2049, 2000.
- [63] H. He και άλλοι, «ADASYN: Adaptive synthetic sampling approach for imbalanced learning,» *2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence)*, pp. 1322-1328, Ιούνιος 2008.
- [64] «ADASYN,» [Ηλεκτρονικό]. Available: https://glemaitre.github.io/imbalanced-learn/auto_examples/over-sampling/plot_adasyn.html. [Πρόσβαση 15 Σεπτεμβρίου 2023].
- [65] «Cross-Validation,» Mathworks, [Ηλεκτρονικό]. Available: <https://www.mathworks.com/discovery/cross-validation.html>. [Πρόσβαση 15 Σεπτεμβρίου 2023].
- [66] «ML | Linear Discriminant Analysis,» GeeksforGeeks, [Ηλεκτρονικό]. Available: <https://www.geeksforgeeks.org/ml-linear-discriminant-analysis/>. [Πρόσβαση 15 Σεπτεμβρίου 2023].
- [67] S. Pandey, «Logistic Regression- Geometric Interpretation,» Medium, [Ηλεκτρονικό]. Available: <https://medium.com/datasciencechannel/logistic-regression-geometric-interpretation-37f08a315a0b>. [Πρόσβαση 15 Σεπτεμβρίου 2023].
- [68] «Introduction to Support Vector Machines (SVM),» GeeksforGeeks, [Ηλεκτρονικό]. Available: <https://www.geeksforgeeks.org/introduction-to-support-vector-machines-svm/>. [Πρόσβαση 17 Σεπτεμβρίου 2023].
- [69] S. H. Roshna , «K-Nearest Neighbors Algorithm,» Intuitive Tutorials, [Ηλεκτρονικό]. Available: <https://intuitivetutorial.com/2023/04/07/k-nearest-neighbors-algorithm/>. [Πρόσβαση 17 Σεπτεμβρίου 2023].
- [70] «What if you're exposed to COVID-19 over the holidays?,» Regence, 2 Δεκεμβρίου 2020. [Ηλεκτρονικό]. Available: <https://news.regence.com/blog/what-if-youre-exposed-to-covid-19-over-the-holidays>. [Πρόσβαση 17 Σεπτεμβρίου 2023].
- [71] R. Yehoshua, «Random Forests,» Medium, [Ηλεκτρονικό]. Available: <https://medium.com/@roiyeo/random-forests-98892261dc49>. [Πρόσβαση 17 Σεπτεμβρίου 2023].
- [72] A. Arnx, «First neural network for beginners explained (with code),» Medium, 13 Ιανουαρίου 2019. [Ηλεκτρονικό]. Available: <https://towardsdatascience.com/first-neural-network-for-beginners-explained-with-code-4cfd37e06eaf>. [Πρόσβαση 17 Σεπτεμβρίου 2023].
- [73] N. Daldal και άλλοι, «A New Generation Communication System Based on Deep Learning Methods for the Process of Modulation and Demodulation from the Modulated Images,» *Mathematical Problems in Engineering*, pp. 1-13, 2022.
- [74] «Tanh Activation,» Papers With Code, [Ηλεκτρονικό]. Available: <https://paperswithcode.com/method/tanh-activation>. [Πρόσβαση 17 Σεπτεμβρίου 2023].
- [75] «LSTM Gradients,» Medium, 29 Ιουνίου 2020. [Ηλεκτρονικό]. Available: <https://towardsdatascience.com/lstm-gradients-b3996e6a0296>. [Πρόσβαση 17 Σεπτεμβρίου 2023].
- [76] S. Kostadinov, «Understanding GRU Networks,» Medium, 16 Δεκεμβρίου 2017. [Ηλεκτρονικό]. Available: <https://towardsdatascience.com/understanding-gru-networks-2ef37df6c9be>. [Πρόσβαση 17 Σεπτεμβρίου 2023].
- [77] «central nervous system,» [Ηλεκτρονικό]. Available: <https://www.britannica.com/science/central-nervous-system>. [Πρόσβαση 21 Απριλίου 2023].
- [78] «Lobes of the brain,» [Ηλεκτρονικό]. Available: <https://qbi.uq.edu.au/brain/brain-anatomy/lobes-brain>. [Πρόσβαση 21 Απριλίου 2023].
- [79] K. Westin και άλλοι, «Detection of interictal epileptiform discharges: A comparison of on-scalp MEG and conventional MEG measurements,» *bioRxiv*, 2019.
- [80] «Epilepsy 101,» The Epilepsy Foundation of Connecticut, [Ηλεκτρονικό]. Available: <https://www.epilepsyct.com/get-help/epilepsy-101>. [Πρόσβαση 27 Απριλίου 2023].
- [81] «Electroencephalogram (EEG),» Επίσημη Ιστοσελίδα NHS, [Ηλεκτρονικό]. Available: <https://www.nhs.uk/conditions/electroencephalogram/>. [Πρόσβαση 27 Απριλίου 2023].

- [82] S. Wong και άλλοι, «Embedded Processors: Characteristics and Trends,» Faculty of Electrical Engineering, Mathematics and Computer Science, Ντελφτ, 2004.
- [83] «Edge computing vs. cloud computing: What's the difference?,» fauna, [Ηλεκτρονικό]. Available: http://ce-publications.et.tudelft.nl/publications/933_embedded_processors_characteristics_and_trends.pdf. [Πρόσβαση 4 Μαΐου 2023].

