



ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ
ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ ΒΙΟΪΑΤΡΙΚΗΣ

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

της φοιτήτριας του Τμήματος Μηχανικών Βιοϊατρικής

ΓΡΗΓΟΡΑΚΟΥ ΕΥΤΥΧΙΑΣ

ΑΡΙΘΜΟΣ ΜΗΤΡΩΟΥ: 48016023

ΘΕΜΑ

**Επεξεργασία και ανάλυση ηλεκτροεγκεφαλογραφικών
σημάτων για την αναγνώριση συγκέντρωσης του
υποκειμένου**

Επιβλέπων Καθηγητής: Καλατζής Ιωάννης, Αναπληρωτής Καθηγητής

Αθήνα, Ιούλιος 2021

ΠΙΣΤΟΠΟΙΗΣΗ

Πιστοποιείται πως η διπλωματική εργασία με θέμα

Επεξεργασία και ανάλυση ψηφιακών ηλεκτροεγκεφαλογραφικών σημάτων για την αναγνώριση συγκέντρωσης του υποκειμένου

της φοιτήτριας του Τμήματος Μηχανικών Βιοϊατρικής

Γρηγοράκου Ευτυχίας

(ΑΡΙΘΜΟΣ ΜΗΤΡΩΟΥ: 48016023)

Παρουσιάστηκε και εξετάστηκε στο Τμήμα Μηχανικών Βιοϊατρικής στις

22/07/2021

Η Τριμελής Εξεταστική Επιτροπή

Επιβλέπων	Μέλος	Μέλος
Ιωάννης Καλατζής	Παντελεήμων Ασβεστάς	Δημήτριος Αραμπατζής
Αναπληρωτής Καθηγητής	Αναπληρωτής Καθηγητής	Ακαδημαϊκός Υπότροφος



ΔΗΛΩΣΗ ΣΥΓΓΡΑΦΕΑ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ

Η υπογράφουσα Γρηγοράκου Ευτυχία του Δημήτριου Γρηγοράκου, με αριθμό μητρώου 48016023 φοιτήτρια του Τμήματος Μηχανικών Βιοϊατρικής της Σχολής Μηχανικών του Πανεπιστημίου Δυτικής Αττικής, δηλώνω υπεύθυνα ότι:

«Είμαι συγγραφέας αυτής της διπλωματικής εργασίας και κάθε βοήθεια την οποία είχα για την προετοιμασία της είναι πλήρως αναγνωρισμένη και αναφέρεται στην εργασία. Επίσης, οι όποιες πηγές από τις οποίες έκανα χρήση δεδομένων, ιδεών ή λέξεων, είτε ακριβώς είτε παραφρασμένες, αναφέρονται στο σύνολό τους, με πλήρη αναφορά στους συγγραφείς, τον εκδοτικό οίκο ή το περιοδικό, συμπεριλαμβανομένων και των πηγών που ενδεχομένως χρησιμοποιήθηκαν από το διαδίκτυο. Επίσης, βεβαιώνω ότι αυτή η εργασία έχει συγγραφεί από μένα αποκλειστικά και αποτελεί προϊόν πνευματικής ιδιοκτησίας τόσο δικής μου, όσο και του Ιδρύματος.

Παράβαση της ανωτέρω ακαδημαϊκής μου ευθύνης αποτελεί ουσιώδη λόγο για την ανάκληση του διπλώματός μου».

Ημερομηνία

22/07/2021

Η Δηλούσα



Περίληψη

Τα τελευταία χρόνια, η τεχνική της Ηλεκτροεγκεφαλογραφίας (ΗΕΓ) χρησιμοποιείται ολοένα και περισσότερο σε συνδυασμό με υπολογιστικά εργαλεία της Μηχανικής Μάθησης, με σκοπό την αποκωδικοποίηση και την κατανόηση των εγκεφαλογραφικών σημάτων. Σε αυτό το πλαίσιο, η παρούσα διπλωματική εργασία αποσκοπεί στη δημιουργία ενός αλγορίθμου ο οποίος θα χρησιμοποιεί ηλεκτροεγκεφαλογραφικά σήματα ανθρώπων, ώστε να αναγνωρίζει την ύπαρξη πνευματικής συγκέντρωσης σε αυτούς.

Για τη δημιουργία ενός τέτοιου συστήματος χρησιμοποιήθηκαν ΗΕΓ σήματα που προέρχονται από μία βάση δεδομένων ανοιχτής πρόσβασης. Τα σήματα αυτά υπέστησαν ψηφιακή επεξεργασία, ώστε να αποκτήσουν την κατάλληλη μορφή για να αποτελέσουν είσοδο στο Σύστημα Αναγνώρισης Προτύπων, που δημιουργήθηκε στα πλαίσια της παρούσας διπλωματικής εργασίας. Το Σύστημα αυτό αναλύει τα εγκεφαλογραφικά σήματα, μέσω των τεχνικών της εξαγωγής και έπειτα επιλογής χαρακτηριστικών, ώστε τελικά να τα ταξινομήσει σε κλάσεις ανάλογα με την ύπαρξη ή μη συγκέντρωσης στους εθελοντές κατά τη διάρκεια της καταγραφής. Ως εκ τούτου, προκύπτουν δύο κλάσεις. Στην πρώτη ανήκουν τα σήματα που προέρχονται από εθελοντές που βρίσκονται σε κατάσταση πνευματικής συγκέντρωσης, και στη δεύτερη ανήκουν τα σήματα που προέρχονται από εθελοντές που βρίσκονται σε κατάσταση απουσίας συγκέντρωσης - χαλάρωσης.

Το αποτέλεσμα του λογισμικού συστήματος αποδεικνύει ότι είναι εφικτός ο επιτυχής διαχωρισμός και η κατηγοριοποίηση σημάτων ηλεκτροεγκεφαλογραφίας ανάλογα με την ύπαρξη ή μη συγκέντρωσης στα υποκείμενα των καταγραφών.

Λέξεις-Κλειδιά: Ηλεκτροεγκεφαλογραφία (ΗΕΓ), αναγνώριση συγκέντρωσης, ρυθμός άλφα, Αναγνώρισης Προτύπων.

Abstract

In the last years, the use of Electroencephalogram (EEG) signals in the field of Machine Learning has obtained a lot of interest, since it would be very useful to deeply understand these signals. In this context, the aim of the present thesis is to create an algorithm, which will use humans' EEG signals in order to recognize whether or not these humans are concentrated during the measurement (Attentiveness Recognition System).

To develop this system, an open access dataset of EEG signals was used. These signals were processed digitally so they are suitable to be fed in the Pattern Recognition System that was built for the purpose of this thesis. This System analyzes the EEG signals, employing Feature Extraction and Feature Selection techniques, in order to classify them depending on the concentration of the volunteers during the EEG measurement. Thus, the data were classified into two classes; the signals which correspond to volunteers who were concentrated belong to the first class, and the signals which correspond to volunteers who were in relaxed-not concentrated state, belong to the second class.

The results of the System show that it is possible to successfully discriminate and classify EEG signals according to the concentration of the subject.

Key words: Electroencephalography (EEG), Attentiveness Recognition, alpha rhythm, Pattern Recognition System.

Πίνακας Περιεχομένων

ΠΕΡΙΛΗΨΗ.....	5
ABSTRACT.....	6
I. ΘΕΩΡΗΤΙΚΟ ΥΠΟΒΑΘΡΟ ΑΝΘΡΩΠΙΝΗΣ ΕΓΚΕΦΑΛΙΚΗΣ ΛΕΙΤΟΥΡΓΙΑΣ	10
1. ΑΝΘΡΩΠΙΝΟ ΝΕΥΡΙΚΟ ΣΥΣΤΗΜΑ	10
1.1 Νευρώνας	10
1.2 Δυναμικό ηρεμίας και Δυναμικό δράσης.....	11
1.3 Μεταφορά πληροφορίας μεταξύ των νευρώνων	12
2. ΑΠΕΙΚΟΝΙΣΗ ΕΓΚΕΦΑΛΙΚΟΥ ΣΗΜΑΤΟΣ.....	13
2.1 Ηλεκτροεγκεφαλογραφία.....	13
2.2 Διατάξεις Ηλεκτροεγκεφαλογραφίας.....	14
2.3 Ρυθμοί Εγκεφαλικής Δραστηριότητας	15
II. ΘΕΩΡΗΤΙΚΟ ΥΠΟΒΑΘΡΟ ΕΠΕΞΕΡΓΑΣΙΑΣ ΕΓΚΕΦΑΛΙΚΩΝ ΣΗΜΑΤΩΝ	18
3. ΣΥΣΤΗΜΑΤΑ ΑΝΑΓΝΩΡΙΣΗΣ ΠΡΟΤΥΠΩΝ.....	18
3.1 Ανάκτηση και Προεπεξεργασία δεδομένων.....	19
3.1.1 Αφαίρεση Ψευδών Απεικονίσεων.....	19
3.1.2 Φίλτρα στο πεδίο των συχνοτήτων.....	20
3.2 Εξαγωγή χαρακτηριστικών	21
3.2.1 Χρονικές Μέθοδοι	22
3.2.2 Φασματικές μέθοδοι.....	23
3.2.3 Μέθοδοι στο πεδίο του Χρόνου και των Συχνοτήτων	26
3.2.3.2 Κυματίδια	28
3.3 Μείωση Χαρακτηριστικών.....	30
3.3.1 Ανάλυση Κύριων Συνιστωσών (Principal Components Analysis).....	30
3.3.2 Ανάλυση Ανεξάρτητων Συνιστωσών (Independent Principal Analysis)	31
3.4 Επιλογή Χαρακτηριστικών.....	32
3.4.1 Recursive Feature Elimination (RFE).....	32
3.5 Ταξινόμηση	33
3.5.1 Μπαϊσιανός Ταξινομητής (Bayes Classifier).....	34
3.5.2 Ταξινομητής k πλησιέστερων γειτόνων - k Nearest Neighbors (k-NN).....	35
3.5.3 Support Vector Machine (SVM).....	36
3.5.4 Δέντρα Απόφασης (Decision Trees ή Classification Trees)	37
3.5.5 Random Forest	39
3.5.6 Νευρωνικά Δίκτυα.....	40
3.5.7 Πολυεπίπεδα Δίκτυα Perceptron – Multilayer Perceptron (MLP)	41
3.5.8 Πιθανοκρατικό Νευρωνικό Δίκτυο – Probabilistic Neural Network (PNN).....	43
3.6 Αξιολόγηση Συστήματος.....	44
3.6.1 Μέθοδοι Αξιολόγησης Συστήματος	44
3.6.2 Μέτρα απόδοσης συστήματος.....	45

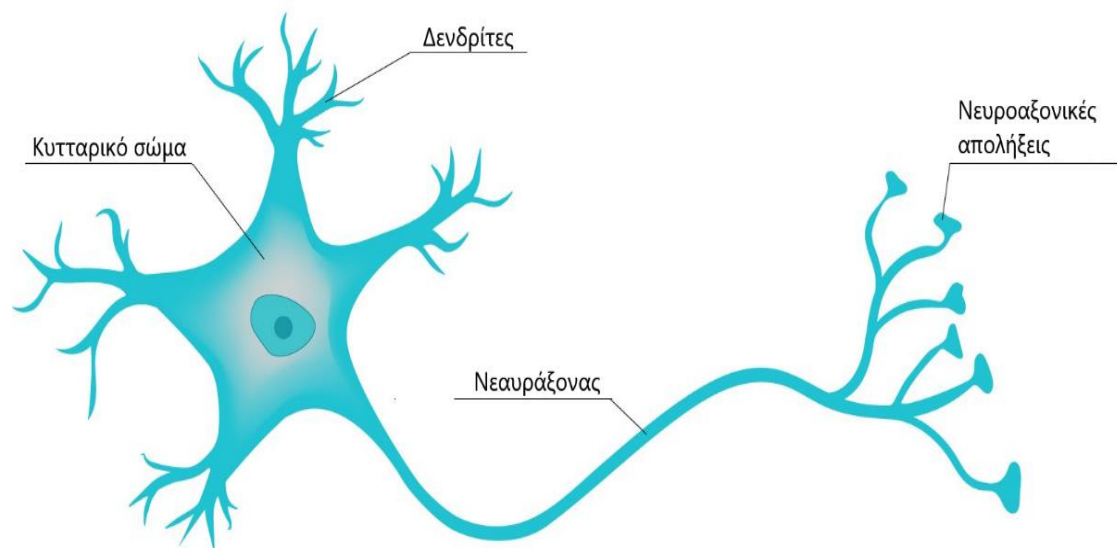
III. ΑΝΑΠΤΥΞΗ ΣΥΣΤΗΜΑΤΟΣ ΑΝΑΓΝΩΡΙΣΗΣ ΠΡΟΤΥΠΩΝ.....	48
4. ΠΕΡΙΓΡΑΦΗ ΣΗΜΑΤΩΝ	48
5. ΑΝΑΠΤΥΞΗ ΣΥΣΤΗΜΑΤΟΣ ΑΝΑΓΝΩΡΙΣΗΣ ΠΡΟΤΥΠΩΝ	49
5.1 Προεπεξεργασία Σημάτων	49
5.2 Εξαγωγή Χαρακτηριστικών.....	51
6.3 Επιλογή χαρακτηριστικών	52
6.4 Ταξινόμηση.....	53
6.5 Αποτελέσματα Ταξινόμησης.....	53
7. ΑΠΟΤΕΛΕΣΜΑΤΑ ΚΑΙ ΕΦΑΡΜΟΓΕΣ	54
7.1 Αξιολόγηση αποτελεσμάτων και βελτιώσεις	54
7.2 Εφαρμογές.....	54
ΠΑΡΑΡΤΗΜΑ Α	56
ΒΙΒΛΙΟΓΡΑΦΙΑ	63

I. Θεωρητικό Υπόβαθρο Ανθρώπινης Εγκεφαλικής Λειτουργίας

1. Ανθρώπινο Νευρικό Σύστημα

1.1 Νευρώνας

Το νευρικό κύτταρο ή αλλιώς ο νευρώνας αποτελεί τη θεμελιώδη δομική και λειτουργική μονάδα του νευρικού συστήματος. Αποτελείται από το κυτταρικό σώμα, τους δενδρίτες, τον νευράξονα και τις νευροαξονικές απολήξεις (Εικόνα 1.1).



Εικόνα 1.1: Η δομή του νευρώνα [1].

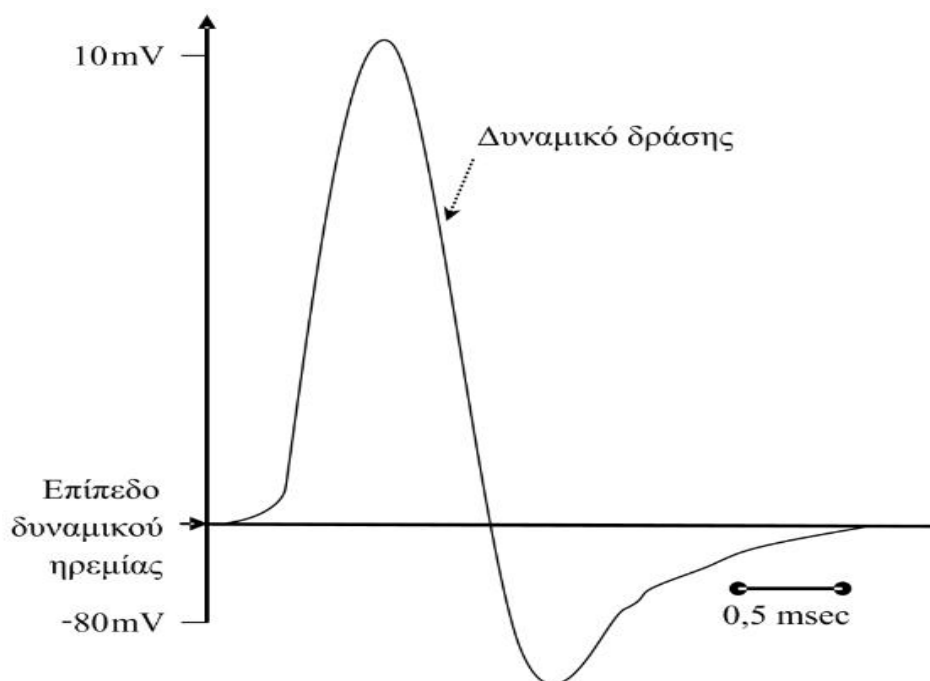
Όπως όλα τα κύτταρα, έτσι και ο νευρώνας περιβάλλεται από την κυτταρική μεμβράνη που τον διαχωρίζει από τον υπόλοιπο εξωκυττάριο χώρο. Πέρα από διαχωριστικό μέσο, η κυτταρική μεμβράνη αποτελεί ταυτόχρονα και το μέσο επικοινωνίας του νευρώνα με το περιβάλλον του. Πιο αναλυτικά, η μεμβράνη διαθέτει ειδικές πρωτεΐνες που τη διαπερνούν σε όλο της το πάχος και επιτρέπουν επιλεκτικά σε μόρια και ιόντα να εισέλθουν ή να εξέλθουν από τον νευρώνα. Αποτελούν δηλαδή τις διόδους του νευρώνα. Οι δίοδοι οι οποίες ελέγχουν τη ροή ιόντων (Na^+ , K^+ , Ca^{++}) από και προς το νευρώνα, ονομάζονται ιοντικές δίοδοι και ελέγχονται («ανοίγουν» και «κλείνουν») είτε από τη διαφορά δυναμικού που δημιουργείται λόγω της κατανομής ιόντων εντός και εκτός της μεμβράνης και έτσι ονομάζονται ηλεκτρικά

ελεγχόμενες διόδους, είτε από την παρουσία συγκεκριμένων μορίων στο εξωκυττάριο και εσωκυττάριο χώρο και έτσι ονομάζονται χημικά ελεγχόμενες διόδους. [2]

1.2 Δυναμικό ηρεμίας και Δυναμικό δράσης

Μέσω λοιπόν αυτών των ιοντικών διόδων, ελέγχεται πόσα και ποια ανιόντα και κατιόντα βρίσκονται εντός και εκτός του νευρώνα, διατηρώντας με αυτόν τον τρόπο μια ανισοκατανομή φορτίου εκατέρωθεν της μεμβράνης. Αυτή η ανισοκατανομή συνεπάγεται την ύπαρξη μίας χρονικά σταθερής διαφοράς δυναμικού εντός και εκτός της μεμβράνης, η οποία ονομάζεται δυναμικό ηρεμίας. Το δυναμικό ηρεμίας αφορά τη λεγόμενη κατάσταση ηρεμίας και για τους νευρώνες έχει τιμή περίπου -70mV , με το αρνητικό πρόσημο να δηλώνει πως το εσωτερικό του κυττάρου βρίσκεται σε αρνητικό δυναμικό σε σχέση με το εξωτερικό.

Οι νευρώνες όμως μπορεί να διαταραχθούν από την κατάσταση ηρεμίας και έτσι το δυναμικό εντός και εκτός της μεμβράνης να αυξηθεί ή να μειωθεί, ανάλογα με το πρόσημο των ιόντων που θα εισέλθουν και θα εξέλθουν από το νευρικό κύτταρο. Εάν λοιπόν το δυναμικό αυξηθεί και ξεπεράσει μία συγκεκριμένη τιμή ($\approx -50\text{mV}$), η οποία αποτελεί την τιμή κατωφλίου, τότε δημιουργείται το λεγόμενο δυναμικό δράσης. Στην ουσία, πρόκειται για μία ταχεία (συνήθως της τάξης των ms) και απότομη μεταβολή του δυναμικού της μεμβράνης, η οποία δημιουργείται λόγω της ροής ιόντων μέσω των ηλεκτρικά ελεγχόμενων διόδων. Λόγω του δυναμικού δράσης, η διαφορά δυναμικού εντός και εκτός του νευρώνα φθάνει τη μέγιστη τιμή των περίπου τα 10mV , και έπειτα την ελάχιστη τιμή των περίπου -80mV , ώστε τελικά να επανέλθει στην τιμή του δυναμικού ηρεμίας (**Εικόνα 1.2**). [3]



Εικόνα 1.2 : Σχηματική αναπαράσταση του δυναμικού δράσης [3].

Το δυναμικό δράσης παράγεται σε συγκεκριμένες περιοχές του νευρικού κυττάρου, στις οποίες η κατανομή των ηλεκτρικά ελεγχόμενων διόδων είναι πιο πυκνή. Τέτοιες περιοχές βρίσκονται συνήθως στην αρχή του νευράξονα κοντά στο κυτταρικό σώμα. Αφού λοιπόν το

δυναμικό δράσης παραχθεί εκεί, διαδίδεται σε όλο το μήκος του νευράξονα υπό την μορφή παλμού, μέχρι να φθάσει στο τέλος του, δηλαδή στις νευροαξονικές απολήξεις και από εκεί να διαδοθεί στον επόμενο κατά σειρά νευρώνα. [3]

1.3 Μεταφορά πληροφορίας μεταξύ των νευρώνων

Η μετάδοση πληροφορίας μεταξύ των νευρώνων στην ουσία γίνεται μέσω της μεταφοράς των δυναμικών δράσης. Συγκεκριμένα, η μετάδοση αυτή γίνεται μέσω των συνάψεων (**Εικόνα 1.3**), οι οποίες αποτελούν το σημείο επαφής δύο ή περισσότερων νευρώνων. Στην επικρατέστερη μορφή σύναψης που συναντάται μεταξύ των νευρικών κυττάρων, οι νευροαξονικές απολήξεις του προσυναπτικού νευρώνα, δηλαδή του νευρώνα που αποστέλλει το ηλεκτρικό σήμα, βρίσκονται σε κοντινή απόσταση από τον δενδρίτη του νευρώνα που θα λάβει το σήμα, δηλαδή του μετασυναπτικού νευρώνα. [3]



Εικόνα 1.3 : Σύναψη μεταξύ δύο νευρώνων [3].

Όταν το δυναμικό δράσης φθάσει στο τέλος του προσυναπτικού κυττάρου, λόγω της μεταβολής στη διαφορά δυναμικού που θα δημιουργηθεί σε εκείνη την περιοχή, θα εκκριθεί μία χημική ουσία, ο νευροδιαβιβαστής, ο οποίος μέχρι τότε βρισκόταν δεσμευμένος εντός κυψελίδων στις προσυναπτικές νευροαξονικές απολήξεις. Κατόπιν, ο νευροδιαβιβαστής θα διαδοθεί στον χώρο μεταξύ των νευρώνων, που ονομάζεται μετασυναπτική σχισμή, μέχρι να φθάσει στον δενδρίτη του μετασυναπτικού κυττάρου και να δεσμευτεί από ειδικούς

υποδοχείς που βρίσκονται στην επιφάνειά του. Ο συνδυασμός νευροδιαβιβαστή και υποδοχέα μπορεί να οδηγήσει στην ενεργοποίηση ιοντικών διόδων του μετασυναπτικού νευρώνα, οι οποίες μέχρι τότε ήταν «κλειστές», δεν επέτρεπαν δηλαδή τη ροή ιόντων, μιας που το κύτταρο βρισκόταν σε κατάσταση ηρεμίας. Μέσω αυτών των διόδων θα εισέλθουν ιόντα στον μετασυναπτικό νευρώνα, τα οποία θα μεταβάλλουν τη διαφορά δυναμικού εντός και εκτός της μεμβράνης στην περιοχή της σύναψης, δημιουργώντας κατά αυτόν τον τρόπο το μετασυναπτικό δυναμικό. Αυτό θα διαδοθεί από τον δενδρίτη στον οποίο παράχθηκε μέχρι το κυτταρικό σώμα, όπου εκεί και συγκεκριμένα στην αρχή του νευράξονα, θα ολοκληρωθεί, θα αθροιστεί δηλαδή, με όλα τα μετασυναπτικά δυναμικά που φθάνουν στο ίδιο σημείο από τις πολλές συνάψεις που υπάρχουν σε όλους τους δενδρίτες του μετασυναπτικού κυττάρου και διεγείρονται ταυτόχρονα.

Τα σήματα που φθάνουν εκεί μπορεί να είναι είτε διεγερτικά, είτε κατασταλτικά, ανάλογα με το πρόσημο των ιόντων που εισήλθαν στο κύτταρο από τις ιοντικές διόδους. Εάν το αποτέλεσμα της ολοκλήρωσης αυτών είναι τέτοιο έτσι ώστε το δυναμικό που θα δημιουργηθεί τοπικά να ξεπεράσει την τιμή κατωφλίου ($\approx -50\text{mV}$), τότε θα παραχθεί ένα νέο δυναμικό δράσης, το οποίο θα διαδοθεί κατά μήκος του νευράξονα μέχρι να φθάσει στις απολήξεις του και να επαναληφθεί η ίδια διαδικασία με τον επόμενο νευρώνα.

Επομένως γίνεται αντιληπτό πως υπάρχουν δύο είδη ηλεκτρικών σημάτων: το δυναμικό δράσης και το μετασυναπτικό δυναμικό. Το πρώτο δημιουργείται ως «όλο ή ουδέν», δηλαδή κάθε φορά που παράγεται θα έχει πάντα την ίδια μορφή, αρκεί η διαφορά δυναμικού να έχει ξεπεράσει την τιμή κατωφλίου. Αντίθετα, το μετασυναπτικό δυναμικό, αυξομειώνεται σε μέγεθος αναλόγως την ποσότητα και τη δράση του νευροδιαβιβαστή. Οι παράγοντες που διαφοροποιούν τη πληροφορία που φέρει το κάθε δυναμικό δράσης, είναι η συχνότητα του καθώς και ο αριθμός των συνάψεων, που διαθέτει ο νευρώνας στον οποίο παράχθηκε αυτό [3].

2. Απεικόνιση Εγκεφαλικού Σήματος

Μετρώντας και καταγράφοντας αυτά τα ηλεκτρικά σήματα που λαμβάνουν χώρα στον ανθρώπινο εγκέφαλο, γίνεται εφικτή η απεικόνιση αυτών των εγκεφαλικών σημάτων και κατ'επέκταση η μελέτη της ηλεκτρικής δραστηριότητας του ανθρώπινου εγκεφάλου.

2.1 Ηλεκτροεγκεφαλογραφία

Η καταγραφή της εγκεφαλικής δραστηριότητας μέσω συσκευών ηλεκτροεγκεφαλογραφίας (ΗΕΓ ή EEG), αποτελεί τη παλαιότερη και πιο διαδεδομένη μη επεμβατική μέθοδο απεικόνισης εγκεφαλικών σημάτων.

Ήδη από τα μέσα του 19^{ου} αιώνα, υπήρχαν σοβαρές ενδείξεις ύπαρξης ηλεκτρικών δυναμικών στον ανθρώπινο εγκέφαλο, προερχόμενες από πειράματα και μελέτες που είχαν πραγματοποιηθεί στον εγκεφαλικό φλοιό πυθικών και γατών. Ο πρώτος που κατάφερε να καταγράψει την ηλεκτρική δραστηριότητα του ανθρώπινου εγκεφάλου ήταν ο Γερμανός ψυχίατρος Hans Berger, του οποίου η συσκευή που χρησιμοποίησε, μπορεί να θεωρηθεί ο πρώτος ηλεκτροεγκεφαλογράφος [4].

Στη σημερινή εποχή, οι περισσότερες καταγραφές εγκεφαλικών σημάτων γίνονται μέσω ηλεκτροδίων, τοποθετημένων στη δερματική επιφάνεια του κεφαλιού. Πρέπει να σημειωθεί,

πως λόγω της μεγάλης εξασθένησης σήματος που προκαλεί το ανθρώπινο κρανίο, είναι αδύνατη η μέτρηση σημάτων μεμονωμένων νευρώνων. Για αυτό τον λόγο, απαιτείται ταυτόχρονη ενεργοποίηση μεγάλου αριθμού νευρώνων, γεγονός το οποίο συμβαίνει συνήθως, χάρη στους σχηματισμούς που δημιουργούν μεταξύ τους οι νευρώνες. [3]

Το σήμα που μετράται δεν είναι το δυναμικό δράσης των νευρώνων αυτών, αλλά το μετασυναπτικό δυναμικό. Αυτό συμβαίνει διότι, συνήθως οι νευράξονες διακλαδίζονται προς πολλαπλές κατευθύνσεις, με αποτέλεσμα οι ιοντικές ροές που τους διαρρέουν, να διακλαδίζονται και αυτές και να αλληλοαναιρούνται, μην παράγοντας τελικά ένα ανιχνεύσιμο σήμα. Αντίθετα, τα μετασυναπτικά δυναμικά οφείλονται σε εισροή ιόντων στους μετασυναπτικούς νευρώνες και άρα σε τοπικές αλλαγές των διαφορών δυναμικού εντός και εκτός της κυτταρικής τους μεμβράνης. Πιο συγκεκριμένα, στην περιοχή κοντά της σύναψης, το δυναμικό της μεμβράνης θα μεταβληθεί τοπικά, λόγω της εισόδου θετικών ιόντων και από το δυναμικό ισορροπίας (-70mV) θα μεταβεί σε ένα ελαφρώς υψηλότερο δυναμικό, περίπου -50mV εντός του κυττάρου σε σχέση με τον εξωκυττάριο χώρο. Όμως, στα σημεία του μετασυναπτικού νευρώνα, τα οποία δεν βρίσκονται πλησίον της σύναψης, η διαφορά δυναμικού παραμένει στην τιμή του δυναμικού ηρεμίας. Κατά αυτόν τον τρόπο, ο εξωκυττάριος χώρος κοντά της διεγερμένης σύναψης διαθέτει περισσότερο αρνητικό φορτίο από ότι ο εξωκυττάριος χώρος του υπόλοιπου κυττάρου. Αποτέλεσμα αυτής της μικρής ανισοκατανομής φορτίου, είναι μία ροή ανιόντων από την εξωκυττάρια περιοχή της σύναψης προς το σώμα του νευρώνα και μία ταυτόχρονη αντίθετη ροή κατιόντων από την εξωκυττάρια περιοχή του σώματος προς αυτή της σύναψης.


Ως απόρροια, δημιουργείται ένα πολύ ασθενές ηλεκτρικό δίπολο, το οποίο όμως ενισχύεται, λόγω της άθροισης πολλών τέτοιων μικρών δίπολων, δοθέντος πως ο νευρώνας διεγείρεται ταυτόχρονα σε πολλές συνάψεις. Έτσι, το πλέον ενισχυμένο δίπολο, προκαλεί ιοντικές ροές, οι οποίες είναι αρκετά ισχυρές, ώστε να φθάσουν έως τη δερματική επιφάνεια του κεφαλιού και εν τέλει να μετρηθούν [3].

2.2 Διατάξεις Ηλεκτροεγκεφαλογραφίας

Κάθε ηλεκτροεγκεφαλογραφικό σήμα προέρχεται από ένα ηλεκτρόδιο καταγραφής και υπολογίζεται ως η διαφορά δυναμικού μεταξύ αυτού του ηλεκτροδίου και ενός ηλεκτροδίου αναφοράς. Για να μετρηθεί η διαφορά αυτή, χρειάζεται και ένα τρίτο ηλεκτρόδιο, το ηλεκτρόδιο γείωσης. Επομένως, κάθε ηλεκτροεγκεφαλογραφική διάταξη αποτελείται από τουλάχιστον τρία ηλεκτρόδια. Ο ακριβής αριθμός ηλεκτροδίων καταγραφής εξαρτάται από την εκάστοτε εφαρμογή.

Τα ηλεκτρόδια συνήθως τοποθετούνται στην κεφαλή του εξεταζομένου σύμφωνα με το σύστημα 10-10, το οποίο προβλέπει τη χρήση έως και 74 ηλεκτροδίων. Η διάταξη αυτών απεικονίζεται στην **Εικόνα 1.4**.

Το όνομα αυτού του συστήματος προέρχεται από τον τρόπο με τον οποίο τα γειτονικά ηλεκτρόδια είναι διατεταγμένα στο κρανίο του ατόμου. Συγκεκριμένα, οι αριθμοί “10” και “10” αναφέρονται στις αποστάσεις των γειτονικών ηλεκτροδίων, οι οποίες ισούνται με το 10% της συνολικής απόστασης είτε του δεξιού τμήματος του κρανίου από το αριστερό, είτε του μπροστινού από το πίσω. [5]



Εικόνα 1.4: Διάταξη ηλεκτροδίων στο διεθνές σύστημα 10-10 για την καταγραφή ηλεκτροεγκεφαλογραφικών σημάτων. [6]


2.3 Ρυθμοί Εγκεφαλικής Δραστηριότητας


Αφού λοιπόν μετρηθούν αυτές οι ιοντικές ροές που αποτελούν τα καταγεγραμμένα εγκεφαλικά σήματα, μπορούν να εξεταστούν και να αναλυθούν, ώστε να εξαχθεί μία πληθώρα συμπερασμάτων για την ανθρώπινη εγκεφαλική λειτουργία. Πιο συγκεκριμένα, αναλύοντας το φάσμα συχνοτήτων του καταγεγραμμένου EEG σήματος, γίνεται εμφανές πως το σήμα αυτό αποτελείται από ένα σύνολο σημάτων διαφορετικών συχνοτήτων, τα οποία αντιστοιχούν σε διαφορετικούς τύπους συνεχούς ρυθμικής ημιτονοειδούς εγκεφαλικής λειτουργίας, που ονομάζονται ρυθμοί εγκεφαλικής δραστηριότητας. Οι ρυθμοί αυτοί είναι 5 στο πλήθος και διαφοροποιούνται με βάση το τμήμα του φάσματος συχνοτήτων, στο οποίο αυτοί εμφανίζονται, χωρίς όμως να υπάρχει απόλυτη ακρίβεια και συμφωνία στα όρια των τμημάτων αυτών. Οι διαφορές που παρουσιάζουν οι ρυθμοί εγκεφαλικής λειτουργίας δεν περιορίζονται μόνο στο πεδίο των συχνοτήτων, αλλά συνεπάγονται και διαφοροποιήσεων στην εγκεφαλική κατάσταση του ανθρώπου. Για παράδειγμα, οι συχνότητες των εγκεφαλικών

σημάτων ενός ανθρώπου που βρίσκεται σε κατάσταση ηρεμίας με κλειστά μάτια, είναι πολύ διαφορετικές από αυτές ενός ανθρώπου που βρίσκεται σε εγρήγορση και με ανοιχτά μάτια. [3]

Συγκεκριμένα οι 5 ρυθμοί εγκεφαλικής δραστηριότητας είναι οι παρακάτω και απεικονίζονται στην **Εικόνα 1.5**:

- 1. Ρυθμός δ :** Ο ρυθμός δέλτα περιλαμβάνει κύματα, των οποίων οι συχνότητες κυμαίνονται από 0,5 έως 4Hz, και το πλάτος τους μπορεί να φθάσει έως κάποιες εκατοντάδες μV . Ο ρυθμός αυτός παρατηρείται κατά κόρον έως το δεύτερο έτος της ηλικίας του ανθρώπου [3], σε συγκεκριμένα στάδια βαθέως ύπνου σε έναν υγιή ενήλικα, κατά τα οποία παρουσιάζεται έλλειψη ονείρων και σε καταστάσεις αναισθησίας. [7]
- 2. Ρυθμός θ :** Οι συχνότητες των εγκεφαλικών σημάτων του ρυθμού θήτα έχουν εύρος περίπου από 4 έως 7Hz, και τα κύματα αυτού του ρυθμού φθάνουν μέχρι τα 100 μV . [3] Εντοπίζονται κυρίως σε παιδιά και σε ενήλικές σε στάδια ελαφριού ύπνου και βαθιάς χαλάρωσης. [8]
- 3. Ρυθμός α:** Ο ρυθμός άλφα ονομάστηκε έτσι, διότι ήταν ο πρώτος ρυθμός που μελετήθηκε από τον Hans Berger. Περιλαμβάνει κύματα, των οποίων η βασική αρμονική βρίσκεται στη ζώνη των 7 με 12Hz και το πλάτος τους συνήθως δεν υπερβαίνει τα 30 μV . Αποτελεί τον συχνότερα εμφανιζόμενο ρυθμό σε υγιείς ανθρώπους όταν έχουν τα μάτια τους κλειστά και βρίσκονται σε κατάσταση χαλάρωσης. Η κίνηση των βλεφάρων ή η σκέψη μπορούν να οδηγήσουν σε γρήγορη μείωση του ρυθμού α. [7]
- 4. Ρυθμός β :** Ο ρυθμός βήτα πήρε την ονομασία αυτή διότι ήταν ο δεύτερος που μελετήθηκε και περιλαμβάνει κύματα συχνότητων εύρους από 12 έως 30 Hz και πλάτους που φθάνουν τα 30 μV . Είναι ο κύριος ρυθμός σε καταστάσεις εγρήγορσης, ενεργούς σκέψης και συγκέντρωσης. [7]
- 5. Ρυθμός γ :** Ο ρυθμός γάμμα αποτελεί τον πιο υψίσυχο εγκεφαλικό ρυθμό, περιλαμβάνοντας κύματα με συχνότητες άνω των 30Hz. Παρατηρείται σε περιπτώσεις εστιασμένης εγρήγορσης, ενώ συνδέονται με την κίνηση του σώματος [9] και με εγκεφαλικές διεργασίες που απαιτούν τον συνδυασμό των πέντε αισθήσεων [10].





Εικόνα 1.5 : Δείγματα των εγκεφαλικών ρυθμών διάρκειας 1 δευτερολέπτου [11]

Όποιος ρυθμός και αν επικρατεί στον ανθρώπινο εγκέφαλο κατά τη διάρκεια διεξαγωγής ενός ηλεκτροεγκεφαλογραφήματος, είναι σκόπιμο να επεξηγηθεί τι αντιπροσωπεύει η συχνότητα του καταγεγραμμένου σήματος. Όπως προαναφέρθηκε, τα σήματα που μετρούνται και καταγράφονται οφείλονται στα μετασυναπτικά δυναμικά και όχι στα δυναμικά δράσης. Εάν όμως η ομάδα των νευρώνων, που παρήγαγε τις αρχικές διεγέρσεις στις συνάψεις, είχε νευρώνες που παρήγαγαν δυναμικά δράσης με μία συγκεκριμένη συχνότητα A Hz, τότε και τα μετασυναπτικά δυναμικά θα παραγόntonταν με την ίδια περίπου συχνότητα A Hz, η οποία θα καταγραφόταν. Επομένως, τα καταγεγραμμένα σήματα ενός ηλεκτροεγκεφαλογράφου, παρ' όλο που προέρχονται από τα μετασυναπτικά δυναμικά, στην ουσία αντιπροσωπεύουν τη συχνότητα με την οποία παράγονται τα δυναμικά δράσης. [3]

II. Θεωρητικό Υπόβαθρο Επεξεργασίας Εγκεφαλικών Σημάτων

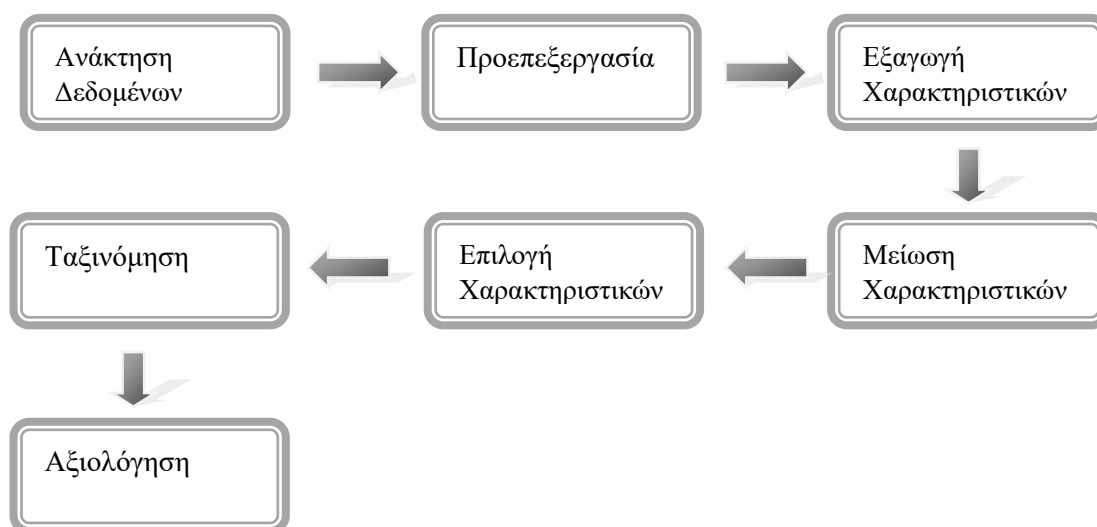
Σκοπός της παρούσας εργασίας είναι αφενός η περιγραφή της φύσεως των εγκεφαλικών σημάτων και αφετέρου η χρήση αυτών ως σήματα εισόδου σε ένα σύστημα που θα τα επεξεργάζεται και θα τα κατηγοριοποιεί ανάλογα με τον βαθμό συγκέντρωσης που παρουσιάζει το υποκείμενο της καταγραφής. Όπως αναφέρθηκε παραπάνω, η ύπαρξη του ρυθμού α είναι αυτή που καθορίζει σε μεγάλο βαθμό τα επίπεδα συγκέντρωσης και χαλάρωσης ενός ανθρώπου. Επομένως, εάν ένα σύστημα είναι ικανό να ανιχνεύει τον βαθμό ύπαρξης αυτού του ρυθμού στα εγκεφαλογραφικά σήματα, τότε επίσης είναι ικανό να ανιχνεύει και την ύπαρξη συγκέντρωσης ή χαλάρωσης στο υποκείμενο.

Η διαδικασία της επεξεργασίας και ταξινόμησης των σημάτων πραγματοποιείται μέσω ενός Συστήματος Αναγνώρισης Προτύπων, το οποίο αναλύεται παρακάτω.

3. Συστήματα Αναγνώρισης Προτύπων

Αναγνώριση Προτύπων είναι η επιστημονική αρχή, η οποία αποσκοπεί στην αναγνώριση κανονικοτήτων, δηλαδή μοτίβων, μεταξύ των διαθέσιμων δεδομένων, με στόχο την ταξινόμησή τους σε έναν αριθμό κλάσεων. Ο αλγόριθμος που εκτελεί αυτήν τη διαδικασία ονομάζεται Σύστημα Αναγνώρισης Προτύπων. Ανάλογα με την εκάστοτε εφαρμογή, τα δεδομένα που χρησιμοποιούνται ως είσοδος του συστήματος, που ονομάζονται πρότυπα (patterns), δύναται να είναι εικόνες, σήματα, ή οποιουδήποτε τύπου μετρήσεις. Στην προκειμένη περίπτωση, τα πρότυπα δεν είναι άλλα από τα σήματα εγκεφαλογραφίας που θα ταξινομηθούν σε δύο κατηγορίες : υψηλής και χαμηλής συγκέντρωσης. Από τα σήματα αυτά, εξάγονται μετρήσιμες τιμές (π.χ. η μέση τιμή του πλάτους του σήματος), οι οποίες αποτελούν τα χαρακτηριστικά (features), μέσω των οποίων θα γίνει η ταξινόμηση των προτύπων.

Τα στάδια ενός Συστήματος Αναγνώρισης Προτύπων παρουσιάζονται στην **Εικόνα 2.1** και περιγράφονται πιο αναλυτικά παρακάτω. [12]



Εικόνα 2.1 : Στάδια ενός Συστήματος Αναγνώρισης Προτύπων

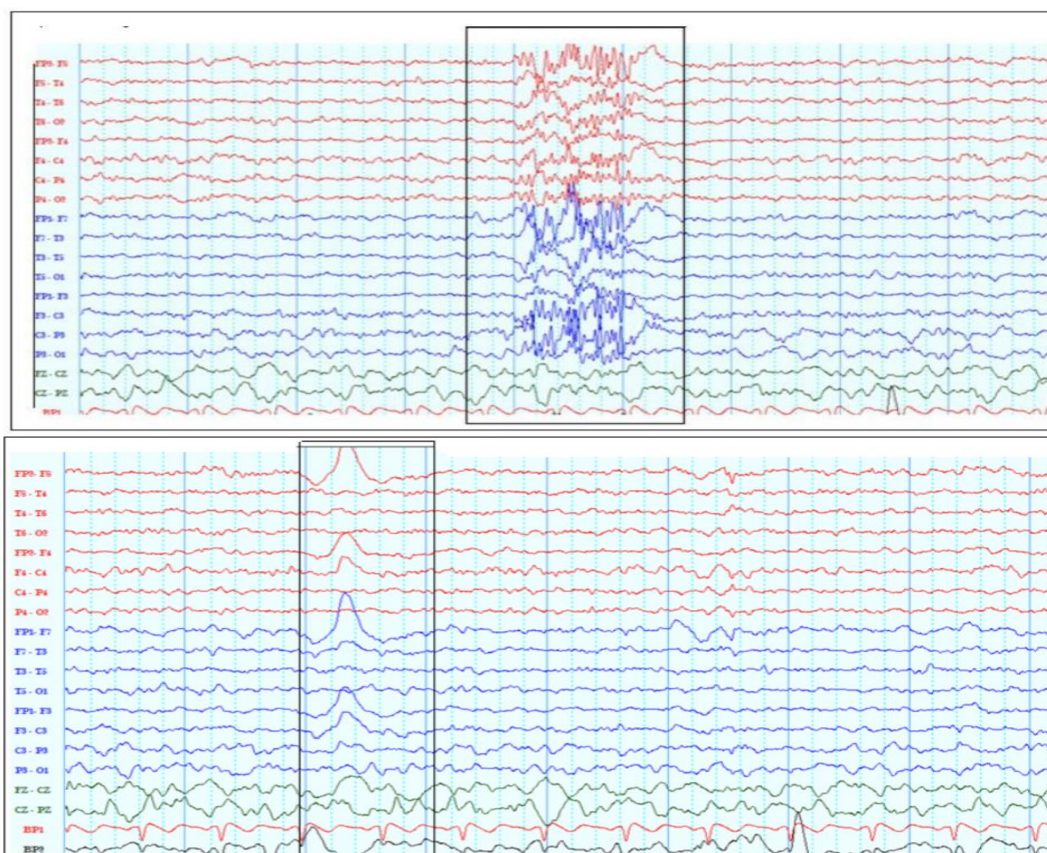
3.1 Ανάκτηση και Προεπεξεργασία δεδομένων

Το πρώτο βήμα είναι η ανάκτηση των δεδομένων, δηλαδή των σημάτων εγκεφαλικής δραστηριότητας, διαδικασία που γίνεται μέσω της ηλεκτροεγκεφαλογραφίας που περιγράφηκε παραπάνω. Όμως, τα καταγεγραμμένα σήματα είναι σε εντελώς ακατέργαστη μορφή και έτσι καθίστανται ακατάλληλα για την άμεση επεξεργασία τους από το Σύστημα Αναγνώρισης Προτύπων. Για αυτόν τον λόγο είναι αναγκαία η προεπεξεργασία τους.

Η προεπεξεργασία αποσκοπεί στην συγκράτηση και ανάδειξη της χρήσιμης πληροφορίας, αλλά ταυτόχρονα και στην απομάκρυνση του θορύβου και των ψευδών απεικονίσεων που υπάρχουν στα καταγεγραμμένα εγκεφαλικά σήματα. Με άλλα λόγια, στοχεύει στη μεγιστοποίηση του λόγου σήματος προς θόρυβο (SNR: Signal to Noise Ratio).

3.1.2 Αφαίρεση Ψευδών Απεικονίσεων

Οι ψευδείς απεικονίσεις ή artifacts ενός σήματος εγκεφαλογραφίας είναι στην ουσία δυναμικά, μη εγκεφαλικής προέλευσης, που καταγράφονται μαζί με τα δυναμικά της εγκεφαλικής δραστηριότητας και συνήθως οφείλονται σε κινήσεις μυών του κεφαλιού και των οφθαλμών, στον καρδιακό παλμό ή σε μετακινήσεις των ηλεκτροδίων. Αποτελούν δηλαδή μη χρήσιμη διαγνωστικά πληροφορία και ταυτόχρονα αλλοιώνουν τα σήματα που προέρχονται όντως από τον εγκέφαλο. Μερικά συχνά εμφανιζόμενα artifacts μπορούν να παρατηρηθούν στην **Εικόνα 2.2**.



Εικόνα 2.2 : Artifacts (επάνω: λόγω κίνησης μυών, κάτω: λόγω βλεφαρισμών) [13].

Ως εκ τούτου, είναι αναγκαίο να αποφεύγεται η δημιουργία τους κατά τη διάρκεια της καταγραφής, καθώς και να απορρίπτονται κατά το στάδιο της επεξεργασίας των ληφθέντων σημάτων. Όσο γίνεται η καταγραφή, το υποκείμενο έχει λάβει οδηγίες ώστε να αποφύγει, όσο είναι δυνατόν, την κίνηση οποιουδήποτε σημείου του σώματος του και τον έντονο βλεφαρισμό.

Όσον αφορά στην εκ των υστέρων επεξεργασία του σήματος, η αφαίρεση τέτοιων ψευδών απεικονίσεων μπορεί να γίνει είτε χειροκίνητα, είτε αυτόματα. Η χειροκίνητη αφαίρεση τους γίνεται μέσω του οπτικού εντοπισμού δυναμικών με απότομες και μεγάλες μεταβολές στο πλάτος ή στη συχνότητά τους. Το πλεονέκτημα αυτής της μεθόδου είναι πως το σύστημα δεν επιβαρύνεται υπολογιστικά, όμως το μειονέκτημα είναι πως απαιτείται εκτενής και ενδελεχής εργασία των ειδικών για τον εντοπισμό των τμημάτων αυτών ανάμεσα σε ολόκληρο το σήμα. Το γεγονός αυτό, εκτός της χρονοτριβής, συνεπάγεται και με την εισαγωγή του ανθρώπινου παράγοντα, άρα και με την εισαγωγή της υποκειμενικότητας και αναπόφευκτα της πιθανότητας λάθους. Για αυτόν τον λόγο, η χειροκίνητη απομάκρυνση ψευδών απεικονίσεων γίνεται είτε σε περιπτώσεις που είναι εντελώς ξεκάθαρο πως συγκεκριμένα τμήματα αποτελούν σήματα μη εγκεφαλικής λειτουργίας, είτε σε περιπτώσεις που τα τμήματα αυτά έχουν αναγνωριστεί ως artifacts κατά τη διάρκεια της καταγραφής, λόγω κάποιου συμβάντος που έγινε εκείνη τη στιγμή (π.χ. κίνηση του υποκειμένου ή αποκόλληση ηλεκτροδίου).

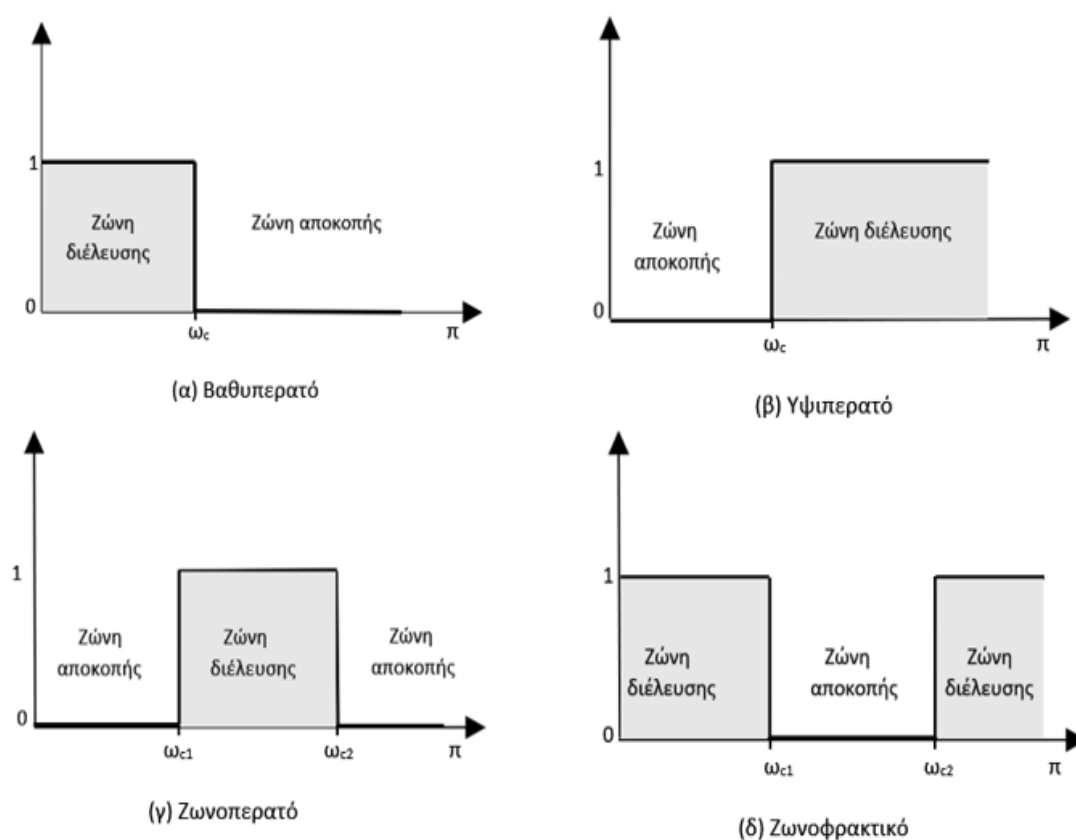
Από την άλλη μεριά, ο αυτόματος τρόπος απόρριψης των artifacts δίνει λύση σε αυτά τα προβλήματα. Πιο συγκεκριμένα, δύναται να πραγματοποιηθεί με δύο τρόπους. Σύμφωνα με τον πρώτο, ταυτόχρονα με την καταγραφή της εγκεφαλικής δραστηριότητας, γίνεται και καταγραφή μυϊκής ή οφθαλμικής δραστηριότητας. Όταν το σήμα αυτής της επιπλέον καταγραφής ξεπεράσει ένα προκαθορισμένο όριο, τότε αυτό σημαίνει πως ενυπάρχει έντονη μη εγκεφαλική δραστηριότητα στα δυναμικά που καταγράφονται και για αυτόν τον λόγο το αντίστοιχο τμήμα του σήματος απορρίπτεται. Ο δεύτερος τρόπος, μοιάζει με τον πρώτο, αλλά δεν χρησιμοποιεί επιπλέον καταγραφές πέραν της εγκεφαλικής. Αναλυτικά, όταν μία συγκεκριμένη παράμετρος του καταγεγραμμένου σήματος, για παράδειγμα το πλάτος, ξεπεράσει ένα προκαθορισμένο όριο, τότε το τμήμα αυτό του σήματος αφαιρείται αυτόματα. Όποιος και από τους δύο τρόπους κι αν εφαρμοστεί, η διαδικασία απόρριψης των ψευδών απεικονίσεων γίνεται γρηγορότερα και εγκυρότερα από ότι αν γινόταν χειροκίνητα.

3.1.2 Φίλτρα στο πεδίο των συχνοτήτων

Η χρήση φίλτρων συχνοτήτων στα ψηφιακά σήματα γενικότερα, αλλά και στα εγκεφαλικά σήματα ειδικότερα, αποτελεί βασικό και απαραίτητο τρόπο μείωσης θορύβου και ανάδυσης των επιθυμητών πληροφοριών, μεταβάλλοντας το φάσμα συχνοτήτων των σημάτων. Τα πλέον συνηθέστερα φίλτρα που χρησιμοποιούνται είναι τα φίλτρα 0-1, τα οποία είτε αποκόπτουν εντελώς κάποιο εύρος συχνοτήτων, είτε το αφήνουν εντελώς αναλλοίωτο.

Αναλυτικά, τα κυριότερα είδη αυτών των φίλτρων είναι 4: α) τα βαθυπερατά φίλτρα, τα οποία αποκόπτουν τις συχνότητες που είναι υψηλότερες από μία καθορισμένη συχνότητα, που ονομάζεται κρίσιμη και αφήνει ανεπηρέαστες τις υπόλοιπες, β) τα υψιπερατά φίλτρα, που επιτελούν την αντίθετη λειτουργία των βαθυπερατών, δηλαδή αποκόπτουν τις συχνότητες που ξεπερνούν την κρίσιμη και ταυτόχρονα αφήνουν αναλλοίωτες τις υπόλοιπες, γ) τα ζωνοπερατά φίλτρα, τα οποία επιτρέπουν τη διέλευση των συχνοτήτων που βρίσκονται ανάμεσα στις δύο κρίσιμες συχνότητες και αποκόπτουν τις υπόλοιπες και δ) τα ζωνοφρακτικά φίλτρα, τα οποία λειτουργώντας αντίθετα από ότι τα ζωνοπερατά, αποκόπτουν τις συχνότητες

που βρίσκονται εντός του ορίου που δημιουργούν οι δύο κρίσιμες συχνότητες (Εικόνα 2.3). Τα δύο τελευταία μπορούν να θεωρηθούν ως συνδυασμός των δύο πρώτων [14].



Εικόνα 2.3: Είδη φίλτρων (ω_c : κρίσιμη συχνότητα)

Ειδικότερα, όσον αφορά τα σήματα εγκεφαλογραφήματος, τα φίλτρα εφαρμόζονται σε αρκετές περιπτώσεις στην προ-επεξεργασία αυτών. Αρχικά, η χρήση βαθυπερατού φίλτρου είναι απαραίτητη, μιας που ο θόρυβος υπάρχει στις υψηλότερες συχνότητες. Ταυτόχρονα όμως, στις χαμηλότερες τιμές συχνοτήτων δύναται να υπάρχει θόρυβος που προέρχεται από την αναπνοή του υποκειμένου ή μία DC συνιστώσα, γεγονός που θέτει τη χρήση ενός υψιπερατού φίλτρου αναγκαία. Η διαδικασία αυτή μπορεί να πραγματοποιηθεί επίσης και με την εφαρμογή ενός ζωνοπερατού φίλτρου. Εκτός αυτού, τα ζωνοπερατά φίλτρα μπορούν να χρησιμοποιηθούν και για την απομόνωση των εγκεφαλικών ρυθμών. Τέλος, μία μορφή ζωνοφρακτικού φίλτρου που χρησιμοποιείται εκτενώς, είναι το notch filter, το οποίο διαθέτει μία πολύ μικρή ζώνη αποκοπής, μέσω της οποίας απομακρύνεται η συχνότητα της ηλεκτρικής παρεμβολής των καλωδίων ρεύματος (50Hz), που αναπόφευκτα βρίσκονται κοντά στο σύστημα καταγραφής [15].

3.2 Εξαγωγή χαρακτηριστικών

Το επόμενο στάδιο ενός Συστήματος Αναγνώρισης Προτύπων είναι η διαδικασία της εξαγωγής χαρακτηριστικών. Όπως προαναφέρθηκε χαρακτηριστικά ή αλλιώς features είναι μετρήσιμες ποσότητες που υπολογίζονται από τα δεδομένα, δηλαδή στην προκειμένη περίπτωση από τα ληφθέντα εγκεφαλικά σήματα, με σκοπό να τα περιγράψουν και να τα

προσδιορίσουν. Για την πλήρη και ακριβή περιγραφή των αρχικών δεδομένων μέσω των χαρακτηριστικών, χρησιμοποιούνται πολλά χαρακτηριστικά x_i με $i=1,2,3,\dots,n$ (n : πλήθος χαρακτηριστικών), τα οποία σχηματίζουν το διάνυσμα χαρακτηριστικών γνωρισμάτων (feature vector) : $X=[x_1,x_2,\dots,x_n]^T$. Κάθε ένα από τα διανύσματα αυτά προσδιορίζει με μοναδικό τρόπο κάθε ένα πρότυπο. Έτσι, δημιουργείται ένας πίνακας που περιέχει όλα τα διανύσματα για όλα τα πρότυπα με διαστάσεις $M \times N$, όπου M είναι το πλήθος των προτύπων και άρα και των διανυσμάτων χαρακτηριστικών γνωρισμάτων, και N είναι το πλήθος χαρακτηριστικών που περιέχει κάθε διάνυσμα. [16]

Το σύνολο των χαρακτηριστικών πρέπει να επιλεγεί με τέτοιο τρόπο, ώστε να παρουσιάζουν κοινά σημεία για εγκεφαλικά σήματα που προέρχονται από καταγραφές της ίδιας εγκεφαλικής κατάστασης και ταυτόχρονα να διαφέρουν για σήματα που προέρχονται από καταγραφές διαφορετικών εγκεφαλικών καταστάσεων. Ως εκ τούτου, το στάδιο της εξαγωγής χαρακτηριστικών είναι ιδιαίτερα σημαντικό για την επιτυχία ολόκληρου του Συστήματος Αναγνώρισης Προτύπων. [16]

Για την πραγματοποίηση της εξαγωγής χαρακτηριστικών χρησιμοποιούνται διάφορες μέθοδοι, οι οποίες εφαρμόζονται είτε στο πεδίο του χρόνου, είτε στο πεδίο των συχνοτήτων, είτε και στα δύο μαζί. Μερικές από αυτές αναλύονται παρακάτω.

3.2.1 Χρονικές Μέθοδοι

Οι χρονικές μέθοδοι εξαγωγής χαρακτηριστικών βασίζονται στη μορφολογία του καταγεγραμμένου σήματος, δηλαδή στις μεταβολές που παρουσιάζει αυτό σε διάρκεια ενός συγκεκριμένου χρονικού τμήματος της καταγραφής. Για να πραγματοποιηθεί η μέτρηση των μεταβολών αυτών, ορίζεται ένα χρονικό παράθυρο συγκεκριμένης διάρκειας και μέσω των τιμών του πλάτους που παρουσιάζει το σήμα εντός αυτού του παραθύρου, υπολογίζονται διάφορα μεγέθη ως χαρακτηριστικά.

3.2.1.1 Στατιστικά χαρακτηριστικά

Τα πιο συνήθη μεγέθη, που υπολογίζονται μέσω της στατιστικής και χρησιμοποιούνται ως χαρακτηριστικά σημάτων εγκεφαλογραφίας, παρουσιάζονται στον **Πίνακα 3.1**.

Πίνακας 3.1 : Στατιστικά Χαρακτηριστικά (N : αριθμός δειγμάτων στο χρονικό παράθυρο, $x(t)$: καταγεγραμμένο σήμα)

Μέση τιμή (Mean)	$\mu = \frac{1}{N} \sum_{t=1}^N x(t)$
Ισχύς (Power)	$E = \frac{1}{N} \sum_{t=1}^N x(t) ^2$
Τυπική απόκλιση (Standard Deviation)	$\sigma = \sqrt{\frac{1}{N} \sum_{t=1}^N (x(t) - \mu)^2}$
Ασυμμετρία (Skewness)	$s = \frac{1}{N} \frac{\sum_{t=1}^N (x(t) - \mu)^3}{\sigma^3}$
Κυρτότητα (Kurtosis)	$k = \frac{1}{N} \frac{\sum_{t=1}^N (x(t) - \mu)^4}{\sigma^4}$

Διαφορά μέγιστης και ελάχιστης τιμής	$d = x(t)_{max} - x(t)_{min}$
--------------------------------------	-------------------------------

3.2.1.2 Χαρακτηριστικά Hjorth

Τα χαρακτηριστικά Hjorth, είναι στην ουσία τρεις παράμετροι που υπολογίζονται για χρονικές ακολουθίες και παρατίθενται παρακάτω στον **Πίνακα 3.2**.

Πίνακας 3.2 : Χαρακτηριστικά Hjorth (N: αριθμός δειγμάτων στο χρονικό παράθυρο, x(t): καταγεγραμμένο σήμα)

Δραστηριότητα (Activity)	$A = \text{var}(x(t)) = \frac{\sum_{t=1}^N (x(t) - \mu)^2}{N}$
Κινητικότητα (Mobility)	$M = \sqrt{\frac{\text{var}\left(\frac{dx(t)}{dt}\right)}{\text{var}(x(t))}}$
Πολυπλοκότητα (Complexity)	$C = \frac{\text{Mobility}\left(\frac{dx(t)}{dt}\right)}{\text{Mobility}(x(t))}$

Το πρώτο χαρακτηριστικό, η Δραστηριότητα ή αλλιώς Activity, αποτελεί μέτρο του τετραγώνου της τυπικής απόκλισης, δηλαδή της διακύμανσης, του πλάτους του σήματος. Η Κινητικότητα ή αλλιώς Mobility αποτελεί μέτρο της τυπικής απόκλισης της κλίσης σε σχέση με την τυπική απόκλιση του πλάτους του σήματος. Εκφράζεται σαν λόγος ανά μονάδα του χρόνου και συχνά συναντάται στη βιβλιογραφία ως μέση συχνότητα. Τέλος, η Πολυπλοκότητα ή Complexity αποτελεί μέτρο ομοιότητας του σήματος με ένα ημίτονο. Για την ακρίβεια, όσο η τιμή της Πολυπλοκότητας πλησιάζει τη μονάδα, τόσο η μορφή του σήματος x(t), πλησιάζει τη μορφή ενός ημιτονοειδούς σήματος [17], [18].


3.2.2 Φασματικές μέθοδοι

Πέρα από τις μεταβολές του πλάτους, από την περιγραφή των εγκεφαλικών ρυθμών που προηγήθηκε, είναι εμφανές πως οι μεταβολές της συχνότητας του καταγεγραμμένου εγκεφαλικού σήματος, είναι και αυτές πολύ σημαντικές και εμπεριέχουν πολλή και σημαντική διαγνωστική πληροφορία. Για αυτόν τον λόγο, είναι ιδιαίτερα χρήσιμη η μετατροπή του ληφθέντος σήματος από το πεδίο του χρόνου στο πεδίο των συχνοτήτων. Με αυτόν τον τρόπο, μπορεί να υπολογιστεί το φάσμα ισχύος του σήματος, το οποίο περιγράφει το πώς διανέμεται η ισχύς του σήματος σε συγκεκριμένες συχνότητες [19], και από αυτό να υπολογιστούν μεγέθη που εν τέλει θα αποτελούν τα χαρακτηριστικά του σήματος στο πεδίο των συχνοτήτων. Οι πιο συνήθεις τεχνικές εξαγωγής φασματικών χαρακτηριστικών για σήματα ηλεκτροεγκεφαλογραφίας περιγράφονται παρακάτω.

3.2.2.1 Μετασχηματισμός Fourier και Ταχύς Μετασχηματισμός Fourier

Ο μετασχηματισμός Fourier αποτελεί την πιο γνωστή και ευρέως χρησιμοποιούμενη τεχνική μετατροπής σημάτων από το πεδίο του χρόνου στο πεδίο των συχνοτήτων. Σύμφωνα λοιπόν με αυτήν την τεχνική, κάθε σήμα μπορεί να αναλυθεί ως ένα άθροισμα ημιτονοειδών

σημάτων συγκεκριμένων συχνοτήτων και πλατών. Το πλάτος της κάθε συχνότητας δηλώνει τη «συνεισφορά» του κάθε επιμέρους ημιτονοειδούς σήματος στο αρχικό (Εικόνα 2.4). [20]



Εικόνα 2.4 : Ανάλυση σήματος στο πεδίο του χρόνου και στο πεδίο των συχνοτήτων. Το υπό μελέτη σήμα (κόκκινη γραμμή) αποτελείται από τον συνδυασμό πολλών ημιτονοειδών (γκρι γραμμές). Κάθε κάθετη μπλε γραμμή στο πεδίο της συχνότητας αντιστοιχεί σε μία συχνότητα, το ύψος της οποίας καθορίζεται από το πλάτος του κάθε σήματος και όλες μαζί διαμορφώνουν το φάσμα ισχύος [21].

Μαθηματικά ο μετασχηματισμός Fourier είναι η διαδικασία που συνδέει δυο συναρτήσεις $x(t)$ και $X(\omega)$, όπου ω είναι πραγματικός αριθμός, έτσι ώστε:

$$X(\omega) = \int_{-\infty}^{+\infty} x(t)e^{-j\omega t} dt, \text{ με την προϋπόθεση πως το ολοκλήρωμα υπάρχει.}$$

Εάν αντί της κυκλικής συχνότητας ω , χρησιμοποιηθεί η γραμμική συχνότητα f (όπου $f = \frac{\omega}{2\pi}$), τότε η παραπάνω εξίσωση γράφεται ως εξής: $X(f) = \int_{-\infty}^{+\infty} x(t)e^{-j2\pi ft} dt$.

Δηλαδή, το σήμα $x(t)$ πολλαπλασιάζεται με έναν εκθετικό όρο συχνότητας f και ολοκληρώνεται για όλους τους χρόνους. Αν το αποτέλεσμα της άπειρης άθροισης δίνει μεγάλη τιμή, τότε το σήμα $x(t)$ έχει μια κύρια φασματική συνιστώσα στην συγκεκριμένη συχνότητα f . Αυτό σημαίνει πως, ένα μεγάλο μέρος του σήματος $x(t)$ αποτελείται από αυτή την συχνότητα f . Αντίθετα, εάν το αποτέλεσμα των αθροίσεων είναι μηδενικό, τότε το σήμα δεν περιέχει καθόλου τη συχνότητα f . Με αυτόν τον τρόπο ο μετασχηματισμός Fourier εντοπίζει ποιες συχνότητες υπάρχουν και ποιες δεν υπάρχουν στο υπό ανάλυση σήμα. Επίσης, ο μετασχηματισμός Fourier είναι μία αντιστρέψιμη διαδικασία, δηλαδή το αρχικό σήμα $x(t)$ μπορεί να ανασυντεθεί από τις ημιτονοειδείς συναρτήσεις που προκύπτουν, μέσω του Αντίστροφου Μετασχηματισμού Fourier (IDFT). [20]

Σε περιπτώσεις διακριτών περιοδικών σημάτων, χρησιμοποιείται ο Διακριτός Μετασχηματισμός Fourier (DFT), ο οποίος δίνεται από την παρακάτω εξίσωση:

$$X[k] = \sum_{n=0}^{N-1} x[n]e^{-j\frac{2\pi}{N}kn}$$

όπου x είναι το σήμα στο πεδίο του χρόνου, N το πλήθος των τιμών του, $n=0\dots N-1$ οι χρονικές στιγμές του x και $k=0\dots N-1$ οι συχνότητες του X [22].

Τέλος, υπάρχει και ο Γρήγορος Μετασχηματισμός Fourier (Fast Fourier Transform), ο οποίος είναι ένας αποδοτικός τρόπος εφαρμογής του Διακριτού Μετασχηματισμού, μειώνοντας όμως τον αριθμό πράξεων που χρειάζονται για τον υπολογισμό του.

3.2.2.2 Πυκνότητα Φασματικής Ισχύος (Power Spectral Density)

Η Πυκνότητα Φασματικής Ισχύος (PSD) ορίζεται ως η κατανομή της ισχύος του σήματος στο πεδίο των συχνοτήτων. Είναι μία ευρέως χρησιμοποιούμενη τεχνική για την επεξεργασία σημάτων και σε περιπτώσεις ηλεκτροεγκεφαλογραφημάτων χρησιμοποιείται για την ποσοτικοποίησή αυτών και για την εύρεση και ανάλυση περιοδικοτήτων που δύναται να περιέχουν [23].

Για τον υπολογισμό της PSD ενός σήματος, υπάρχουν διάφορες μέθοδοι. Ακολούθως θα αναλυθεί μία από αυτές, η μέθοδος Welch.

Σύμφωνα με αυτή τη μέθοδο, ένα σήμα $X(j)$, $j=0 \dots N-1$, χωρίζεται σε K τμήματα μεγέθους L . Τα τμήματα αυτά είναι αλληλεπικαλυπτόμενα, συνήθως κατά 50% ή 75%. Έτσι, τα $k=1$ έως K τμήματα προκύπτουν ως εξής:

$$\begin{aligned} X_1(j) &= X(j) , j=0, \dots, L-1 \\ X_2(j) &= X(j+D) , j=0, \dots, L-1 \\ &\vdots \\ X_k(j) &= X(j+(K-1)D) , j=0, \dots, L-1 \end{aligned}$$

όπου D είναι ο αριθμός των σημείων μεταξύ των σημείων έναρξης κάθε τμήματος.

Στη συνέχεια, σε κάθε τμήμα σήματος ($k=1$ έως K) εφαρμόζεται ένα παράθυρο $W[j]$, $j=0 \dots L-1$. Έτσι, προκύπτουν τα εξής γινόμενα: $X_1(j)W(j)$, \dots , $X_k(j)W(j)$.

Έπειτα, υπολογίζεται ο Ταχύς Μετασχηματισμός Fourier (FFT) για κάθε ένα τέτοιο γινόμενο A_1, \dots, A_k .

$$A_k(n) = \frac{1}{L} \sum_{j=0}^{L-1} X_k(j)W(j)e^{-2\pi jn/L}$$

Το αποτέλεσμα του μετασχηματισμού αυτού ονομάζεται περιοδόγραμμα. Έτσι τελικά προκύπτουν K περιοδογράμματα, των οποίων ο μέσος όρος αποτελεί την εκτίμηση της PSD του σήματος μέσω της μεθόδου Welch. [24] [25]

$$S_x(n) = \frac{1}{K} \sum_{k=1}^K A_k(n)$$

Συνήθως, ως χαρακτηριστικά του σήματος εξάγονται στατιστικά στοιχεία της PSD, όπως η μέγιστη και η ελάχιστη τιμή, η μέση τιμή και η τυπική απόκλιση. [26]

3.2.2.3 Φασματική Εντροπία (Spectral Entropy)

Η Εντροπία αποτελεί ένα μέτρο της αβεβαιότητας και του χάους που περιέχεται σε ένα σύστημα. Για μια τυχαία μεταβλητή X με πιθανές τιμές X_1, \dots, X_n , οι οποίες εμφανίζονται με πιθανότητα $P(X_1), \dots, P(X_n)$ ορίζεται από τον Shannon ως εξής [27]:

$$H(X) = - \sum_{i=1}^n P(X_i) \log_2 p(X_i)$$

Δηλαδή, η εντροπία μετρά την προβλεψιμότητα της μεταβλητής X. Για παράδειγμα, εάν η μεταβλητή X είχε δύο πιθανές τιμές, τότε η πιθανότητα εμφάνισης της μίας τιμής είναι p και η πιθανότητα εμφάνισης της άλλης τιμής είναι p-1. Σε περιπτώσεις στις οποίες το αποτέλεσμα είναι καθορισμένο, δηλαδή για p=1 ή για p=0, τότε η εντροπία είναι η ελάχιστη, δηλαδή μηδενική. Αντίθετα, η μέγιστη εντροπία επιτυγχάνεται όταν p=1/2 [28].

Η Φασματική Εντροπία, βασίζεται στην Εντροπία του Shannon, και μετρά την αβεβαιότητα της φασματικής ισχύος ενός σήματος. Έτσι υπολογίζεται εφαρμόζοντας την εντροπία του Shannon στη συνάρτηση Πυκνότητας Φασματικής Ισχύος:

$$SE = - \sum_{f=0}^{f_s} S(f) \log_2 (S(f))$$

όπου S είναι η PSD του σήματος και f_s η συχνότητα δειγματοληψίας [29].

3.2.3 Μέθοδοι στο πεδίο του Χρόνου και των Συχνοτήτων

Η τρίτη κατηγορία συμπεριλαμβάνει τις τεχνικές που αναλύουν το σήμα και στο πεδίο του χρόνου και στο πεδίο των συχνοτήτων ανακτώντας με αυτόν τον τρόπο όσο το δυνατόν περισσότερη πληροφορία και από τα δύο. Αυτό συμβαίνει διότι με αυτές τις φασματικές μεθόδους που αναλύθηκαν παραπάνω περιγράφονται ποιες συχνότητες υπάρχουν στο υπό μελέτη σήμα και πόσο σημαντικό ρόλο παίζουν στη δημιουργία του, αλλά όχι σε ποιες χρονικές στιγμές του σήματος αυτές εμφανίζονται, γεγονός που αποτελεί σοβαρό πρόβλημα σε περιπτώσεις που η συχνότητα του σήματος μεταβάλλεται με τον χρόνο, δηλαδή σε περιπτώσεις μη στατικών σημάτων, όπως προφανώς είναι και τα σήματα εγκεφαλογραφίας.

3.2.3.1 Μετασχηματισμός Fourier Βραχέως Χρόνου

Ένας τρόπος άρσης του προβλήματος αυτού, είναι η διαίρεση του καταγεγραμμένου σήματος μέσω χρονικών παραθύρων συγκεκριμένου εύρους, σε μικρότερα τμήματα σταθερού μήκους. Αυτό γίνεται μέσω της εφαρμογής μιας συνάρτησης παραθύρου, η οποία μετακινείται με επικαλυπτόμενο τρόπο κατά μήκος του χρονικού σήματος, χωρίζοντας το σε τμήματα, μήκους ίσου με αυτό του παραθύρου. Τα τμήματα αυτά είναι τόσο μικρά, ώστε να μπορεί να θεωρηθεί ότι σε κάθε ένα από αυτά το σήμα είναι στατικό και έτσι να μπορεί να εφαρμοστεί ο μετασχηματισμός Fourier. Η τεχνική αυτή αποτελεί τον Μετασχηματισμό Fourier Βραχέως Χρόνου (Short-Time Fourier Transform) εκφράζεται μέσω της παρακάτω σχέσης:


$$X(m, \omega) = \sum_{n=-\infty}^{+\infty} x[n] w[n - m] e^{-j\omega n}$$

όπου x[n] είναι το σήμα, w[n] είναι το παράθυρο που χρησιμοποιείται, m είναι το μήκος του τμήματος και ω είναι η γωνιακή συχνότητα.

Ως αποτέλεσμα, προκύπτουν φάσματα συχνότητας για κάθε ένα τμήμα, τα οποία είναι χρονικά εντοπισμένα σε σχέση με τη διάρκεια του αρχικού σήματος, και έτσι μπορεί να γίνει ανάλυση του φασματικού περιεχομένου του τελευταίου συναρτήσει με τη χρονική του διάρκεια. Πρέπει να σημειωθεί, πως όσο μικρότερο είναι το εύρος του παραθύρου, τόσο ακριβέστερη είναι και η υπόθεση πώς το επιλεγμένο τμήμα του σήματος είναι στατικό και άρα τόσο καλύτερη είναι η χρονική ανάλυση αλλά και τόσο χειρότερη είναι στο πεδίο των συχνοτήτων. Αντίθετα, όταν το εύρος του παραθύρου είναι μεγάλο, μειώνεται το υπολογιστικό κόστος και αυξάνεται η ανάλυση στο πεδίο των συχνοτήτων, αλλά ταυτόχρονα ελαττώνεται στο πεδίο του χρόνου. Έτσι, εάν το παράθυρο έχει άπειρο εύρος, δηλαδή εάν

εφαρμοστεί ο μετασχηματισμός Fourier σε όλο το σήμα, τότε ο μετασχηματισμός θα γίνει με άριστη συχνοτική αλλά μηδενική χρονική ανάλυση [30].

Αφού λοιπόν υπολογιστεί ο Μετασχηματισμός Fourier Βραχέος Χρόνου με τη βέλτιστη επιλογή παραθύρου ανάλογα την εφαρμογή, έπειτα υπολογίζεται το πλάτος του υψωμένο στο τετράγωνο, δηλαδή η ενέργειά του, που χαρακτηρίζεται ως το Φασματογράφημα (Spectrogram) του σήματος και αποτελεί συνάρτηση του χρόνου και της συχνότητας (Εικόνα 2.5).

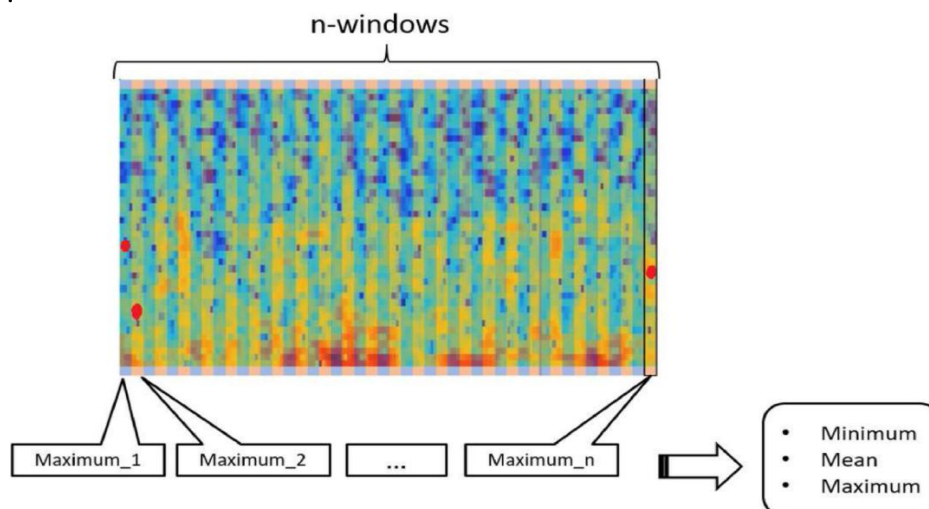


Εικόνα 2.5 : Τμήμα εγκεφαλικού σήματος (επάνω) και το Φασματογράφημά του (κάτω). Ο θερμικός χρωματικός κώδικας δηλώνει το μέγεθος του πλάτους των συχνοτήτων (όσο πιο πορφυρά είναι τα σημεία, τόσο μεγαλύτερη είναι η τιμή του πλάτους) [31].

Αφού έχει γίνει ο μετασχηματισμός και έχει δημιουργηθεί το Φασματογράφημα, είναι δυνατή η εξαγωγή χαρακτηριστικών. Ακολουθούν μερικά συνήθη χαρακτηριστικά.

- **Ισχύς ζωνών συχνοτήτων:** Το εγκεφαλογραφικό σήμα συνήθως χωρίζεται σε ζώνες συχνοτήτων που αντιστοιχούν στους 5 ρυθμούς νοητικής κατάστασης. (δ : 0,5Hz-4 Hz, θ : 4 Hz-7Hz, α : 7Hz-12Hz, β : 12Hz-30Hz, γ : >30Hz). Έπειτα, υπολογίζεται η Ισχύς του σήματος σε αυτές τις ζώνες. Μια επίσης συχνά χρησιμοποιούμενη τεχνική είναι η εύρεση του λόγου των ισχύων δύο ζωνών (π.χ. $\frac{Power_a}{Power_b}$). [7]
- **Φασματικές κορυφές:** Το Φασματογράφημα μπορεί να εκφραστεί ως ένας πίνακας X με r γραμμές και l στήλες, που θα αντιπροσωπεύουν την συχνότητα και τον χρόνο αντίστοιχα. Έτσι, οι φασματικές κορυφές υπολογίζονται ως εξής: $E(l) = \max(X(l))$, όπου E είναι η μέγιστη ενέργεια όλων των συχνοτήτων για συγκεκριμένο χρόνο l. Είναι προφανές πως η μέγιστη ενέργεια εντοπίζεται οπτικά από τις κόκκινες περιοχές του Φασματογραφήματος. Εάν θεωρήσουμε πως το αρχικό σήμα διαιρέθηκε σε n παράθυρα, τότε θα προκύψει ένας πίνακας X με n στήλες που θα περιέχει τις συχνότητες του σήματος στο συγκεκριμένο χρονικό τμήμα. Έτσι, ο πίνακας αυτός διαβάζεται κατά στήλες, ώστε να υπολογιστεί το μέγιστο της κάθε μίας που θα αντιστοιχεί στη μέγιστη ενέργεια του n_i παραθύρου. Όταν ολοκληρωθεί η διαδικασία


αυτή για όλες τις στήλες, τότε υπολογίζεται η μέση τιμή, η μέγιστη και η ελάχιστη τιμή αυτών, όπως φαίνεται στην **Εικόνα 2.6**.



Εικόνα 2.6: Εύρεση φασματικών κορυφών και εξαγωγή των 3 χαρακτηριστικών από αυτές [32].

Επιπροσθέτως, με αυτόν τον τρόπο, μπορούν να μετρηθούν και ο αριθμός κορυφών που υπάρχει σε κάθε παράθυρο, αλλά και σε ποια συχνότητα αυτά εμφανίζονται. [32]

- Όγκος: Το συγκεκριμένο χαρακτηριστικό βασίζεται στην αναπαράσταση του Φασματογραφήματος σε τρεις διαστάσεις, όπως φαίνεται στην **Εικόνα 2.7**, και έπειτα στον υπολογισμό του όγκου που προκύπτει στον χώρο από αυτό. Επίσης, με αυτόν τον τρόπο γίνεται εφικτός ο υπολογισμός του εμβαδού της επιφάνειας που σχηματίζουν οι φασματικές κορυφές [33].



Εικόνα 2.7: Τρισδιάστατη αναπαράσταση Φασματογραφήματος [34].

3.2.3.2 Κυματίδια

Τα Κυματίδια ή αλλιώς Wavelets βασίζονται στη λογική του Μετασχηματισμού Fourier Βραχέος Χρόνου, χρησιμοποιώντας χρονικά παράθυρα, με τη διαφορά πως αυτά έχουν μεταβαλλόμενο εύρος, μειώνοντας έτσι την απώλεια πληροφορίας και στα δύο πεδία. Πιο


συγκεκριμένα, το προς ανάλυση σήμα πολλαπλασιάζεται με μια συνάρτηση παραθύρου μηδενικής μέσης τιμής, της οποίας όμως η χρονική διάρκεια, δηλαδή το μήκος του παραθύρου, μεταβάλλεται καθώς αναλύονται όλο ένα και μεγαλύτερες συχνότητες. Η διαδικασία αυτή ονομάζεται Μετασχηματισμός Wavelet. Τα κυματίδια δύναται να έχουν ποικίλες μορφές, αλλά μία μορφή αρκετά συνήθης σε εφαρμογές σημάτων εγκεφαλογραφίας είναι το κυματίδιο Morlet, που φαίνεται στην **Εικόνα 2.6**. Η αρχική ή αλλιώς μητρική μορφή του κυματιδίου «συμπιέζεται» ή «επιμηκώνεται» ανάλογα με τις συχνότητες που αναλύονται.



Εικόνα 2.6 : Μητρική μορφή Κυματιδίου Morlet [35] .

Όσο και να μεταβληθεί η μορφή του μητρικού κυματιδίου, πρέπει αυτό να ικανοποιεί την εξής συνθήκη : $\int_{-\infty}^{+\infty} \psi(t)dt = 0$.

Η αλλαγή αυτή της μορφής του κυματιδίου καθορίζεται από τον συντελεστή κλίμακας a , ο οποίος μικραίνει σε τιμή όσο πιο «συμπιεσμένο» είναι το κυματίδιο και αντίστοιχα αυξάνεται όσο πιο «επιμηκυνόμενο» είναι. Για την ανάλυση υψηλών συχνοτήτων, οι οποίες παρουσιάζουν ταχέως μεταβαλλόμενες λεπτομέρειες χρειάζεται ένα μικρού μήκους παράθυρο, άρα μικρή κλίμακα a για τη βέλτιστη χρονική τους ανάλυση. Αντίθετα, στις χαμηλές συχνότητες, όπου οι μεταβολές είναι αργές, χρησιμοποιείται παράθυρο μεγάλου μήκους και άρα μεγάλη κλίμακα a .



Εικόνα 2.7 : Διάγραμμα χρονο-φασματικής ανάλυσης για Μετασχηματισμό Wavelet (αριστερά) και για Μετασχηματισμού Fourier Βραχέος Χρόνου (δεξιά). Η κλίμακα a μεταβάλλεται αντιστρόφως ανάλογα της συχνότητας.

Με αυτούς τους τρόπους, μπορεί να γίνει ανάλυση μη στατικών σημάτων διατηρώντας χρήσιμες πληροφορίες του σήματος που υπάρχουν και στο πεδίο του χρόνου και στο πεδίο των συχνοτήτων. Σήματα με παρόμοιες συχνότητες μπορούν πλέον να διαχωριστούν με βάση

την χρονική τους θέση και ομοίως, χρονικά επικαλυπτόμενες διαδικασίες μπορούν να διαχωριστούν με βάση το διαφορετικό φασματικό περιεχόμενό τους.

3.3 Μείωση Χαρακτηριστικών

Όπως είναι φανερό από τα παραπάνω, όσο περισσότερες τεχνικές χρησιμοποιηθούν για την εξαγωγή χαρακτηριστικών, τόσο περισσότερα χαρακτηριστικά θα προκύψουν και κατ'επέκταση τόσο μεγαλύτερες διαστάσεις θα έχει το διάνυσμα $X=[x_1, x_2, \dots, x_n]^T$. Το γεγονός αυτό, παρόλο που στην αρχή φαίνεται επιθυμητό, μιας που σημαίνει πως έχει εξαχθεί μεγάλο ποσοστό πληροφορίας των σημάτων εισόδου, στην πραγματικότητα δεν είναι για τους παρακάτω λόγους.

Αρχικά, ο πιο προφανής είναι πως όσο μικρότερος είναι ο αριθμός των χαρακτηριστικών, τόσο μειώνεται και η υπολογιστική πολυπλοκότητα του συστήματος. Ο επόμενος λόγος είναι πως παρότι όταν κάποια χαρακτηριστικά μελετηθούν μεμονωμένα περιέχουν σημαντική πληροφορία για τον διαχωρισμό των σημάτων, εντούτοις όταν μελετηθούν συνδυαστικά προσφέρουν μικρό κέρδος στο σύστημα, λόγω υψηλής αμοιβαίας συσχέτισης. Έτσι, η πολυπλοκότητα του συστήματος αυξάνεται, χωρίς να υπάρχει ταυτόχρονα μεγάλο κέρδος πληροφορίας. Τέλος, η μείωση των διαστάσεων του X συνεπάγεται την αύξηση της γενίκευσης του συστήματος. Αυτό σημαίνει πως όταν στο σύστημα εισαχθούν σήματα διαφορετικά από αυτά με τα οποία έχει γίνει η εκπαίδευση, το σύστημα θα παρουσιάσει καλή απόδοση. Το γεγονός αυτό συμβαίνει διότι, όσο μεγαλύτερος είναι ο λόγος του αριθμού των προτύπων εκπαίδευσης προς τον αριθμό των ανεξάρτητων παραμέτρων του ταξινομητή, τόσο αυξάνεται η γενίκευση του συστήματος. Όμως, ένας μεγάλος αριθμός χαρακτηριστικών οδηγεί σε μεγάλο αριθμό παραμέτρων του ταξινομητή. Έτσι, δεδομένου ενός σταθερού συνόλου εκπαίδευσης, η μείωση στον αριθμό των χαρακτηριστικών, συνεπάγεται σε μείωση του αριθμού των παραμέτρων και εν τέλει σε αύξηση της γενίκευσης. [16]

Συνεπώς, μετά την εξαγωγή των χαρακτηριστικών είναι απαραίτητο να μειωθεί ο αριθμός τους. Όμως η διαδικασία αυτή πρέπει να εκτελεστεί με τέτοιο τρόπο ώστε να διατηρηθεί όσο τον δυνατόν μεγαλύτερο μέρος της πληροφορίας που φέρουν τα χαρακτηριστικά, παρόλη τη μείωση του αριθμού τους. Έτσι, τα χαρακτηριστικά που θα προκύψουν θα πρέπει αφενός να δημιουργούν μεγάλη απόσταση μεταξύ των στοιχείων διαφορετικών κλάσεων και αφετέρου να τοποθετεί πλησιέστερα τα στοιχεία των ιδίων κλάσεων στον χώρο των χαρακτηριστικών.

Η διαδικασία που έχει ως σκοπό τη μείωση των διαστάσεων του διανύσματος χαρακτηριστικών για τους λόγους που αναφέρθηκαν παραπάνω, ονομάζεται μείωση χαρακτηριστικών (features reduction) [36]. Υπάρχουν διάφοροι αλγόριθμοι μείωσης χαρακτηριστικών, εκ των οποίων οι πιο συχνά χρησιμοποιούμενοι αναλύονται παρακάτω.

3.3.1 Ανάλυση Κύριων Συνιστωσών (Principal Components Analysis)

Η Ανάλυση Κύριων Συνιστωσών (PCA) είναι μία από τις πιο ευρέως χρησιμοποιούμενες στατιστική διαδικασία μείωσης χαρακτηριστικών. Βασίζεται στη μετατροπή των χαρακτηριστικών, που ενδέχεται να συσχετίζονται, σε μία ομάδα νέων χαρακτηριστικών, τα οποία είναι γραμμικά ανεξάρτητα μεταξύ τους και ονομάζονται Κύριες Συνιστώσες ή Principal Components. Ο αριθμός αυτών των νέων χαρακτηριστικών είναι ίσος ή και συχνότερα πολύ μικρότερος από τον αριθμό των αρχικών.

Μαθηματικά η ανάλυση βασίζεται στην παρακάτω αρχή:

Αρχικά, απαιτείται να γίνει τυποποίηση των χαρακτηριστικών, ώστε να έχουν μέσο όρο 0 και τυπική απόκλιση ίση με 1. Έπειτα, από τα n σε πλήθος χαρακτηριστικά X_1, X_2, \dots, X_n δημιουργούνται n συνδυασμοί αυτών Z_1, Z_2, \dots, Z_n με τέτοιο τρόπο ώστε να μην συμμεταβάλλονται. Οι διακυμάνσεις, δηλαδή η μεταβλητότητα που εμφανίζεται μεταξύ των n μεταβλητών Z , διαβαθμίζονται έτσι ώστε η πρώτη μεταβλητή Z που επιλέγεται, δηλαδή η μεταβλητή Z_1 , να περιέχει όσο το δυνατόν μεγαλύτερο ποσοστό της ολικής μεταβλητότητας. Ακολούθως, η μεταβλητή Z_2 περιέχει το αμέσως επόμενο μεγαλύτερο ποσοστό της διακύμανσης των αρχικών χαρακτηριστικών κοκ, υπακούοντας στη σχέση: $\lambda_1 > \lambda_2 > \dots > \lambda_n$, όπου λ_i είναι η i ποσότητα της διακύμανσης. Οι νέες μεταβλητές Z_i αποτελούν τις Κύριες Συνιστώσες. Έτσι η πρώτη Κύρια Συνιστώσα προκύπτει από τον γραμμικό συνδυασμό των n χαρακτηριστικών, σύμφωνα με την παρακάτω σχέση:

$$Z_1 = \alpha_{11} X_1 + \alpha_{12} X_2 + \dots + \alpha_{1n} X_n$$

όπου α_{ij} είναι ο ειδικός συντελεστής στάθμισης (weight) του χαρακτηριστικού j στην i συνιστώσα, αρκεί να ισχύει: $\alpha_{11}^2 + \alpha_{12}^2 + \dots + \alpha_{1n}^2 = 1$, προκειμένου να εξασφαλιστεί η μέγιστη δυνατή διακύμανση λ_1 της πρώτης κύριας συνιστώσας. Ο ειδικός συντελεστής στάθμισης α_{ij} υπολογίζεται μέσω του πίνακα C που περιέχει τις συνδιακυμάνσεις των αρχικών n χαρακτηριστικών.

$$C = \begin{pmatrix} c_{11} & c_{12} & \dots & c_{1n} \\ c_{21} & c_{22} & \dots & c_{2n} \\ c_{31} & c_{32} & \dots & c_{nn} \end{pmatrix}$$

Δηλαδή στον πίνακα περιέχονται οι διακυμάνσεις μεταξύ του χαρακτηριστικού X_i και του χαρακτηριστικού X_j . Άρα είναι προφανές που όλα τα στοιχεία της διαγωνίου του πίνακα θα είναι ίσα με 1.

Στη συνέχεια, η διαδικασία αυτή επαναλαμβάνεται για όλες τις n συνιστώσες Z_i .

Από τα παραπάνω γίνεται προφανές πως η PCA βασίζεται σε μεγάλο βαθμό στην ύπαρξη και στον βαθμό ύπαρξης συμμεταβολής μεταξύ των αρχικών χαρακτηριστικών. Κατά συνέπεια, για να θεωρηθεί η τεχνική αυτή επιτυχημένη, δηλαδή οι Κύριες Συνιστώσες που θα προκύψουν να περιέχουν μεγάλο ποσοστό της αρχικής πληροφορίας, θα πρέπει κάποια από τα χαρακτηριστικά να εμφανίζουν μεγάλη συνδιακύμανση, με άλλα λόγια ο συντελεστής συσχέτισης τους να λαμβάνει υψηλές τιμές, είτε θετικές, είτε αρνητικές ($r \geq \pm 0,70$). Όμως, χαρακτηριστικά που παρουσιάζουν πολύ υψηλό συντελεστή συσχέτισης μεταξύ τους, δηλαδή $r > \pm 0,99$, θεωρούνται πλεονάζοντα και μη εποικοδομητικά για το σύστημα και για αυτό απορρίπτονται πριν την εφαρμογή της PCA [37].

3.3.2 Ανάλυση Ανεξάρτητων Συνιστωσών (Independent Principal Analysis)

Παρόλο που οι Κύριες Συνιστώσες που προκύπτουν από την PCA είναι γραμμικά ανεξάρτητες μεταξύ τους, δεν αναιρείται η πιθανότητα να είναι στατιστικά αλληλοεξαρτώμενες. Αυτός είναι ο σκοπός της Ανάλυση Ανεξάρτητων Συνιστωσών (ICA), η οποία είναι μια στατιστική μέθοδος που αποσκοπεί στην αποσύνθεση ενός πολυμεταβλητού χώρου χαρακτηριστικών σε ανεξάρτητες μεταξύ τους συνιστώσες. Η ICA αποτελεί και αυτή μέθοδο μείωσης διαστάσεων των δεδομένων και θεωρείται επέκταση της PCA, με την πρώτη

να χρησιμοποιεί στατιστικά μεγέθη υψηλότερης τάξης από αυτά που χρησιμοποιεί η δεύτερη, που είναι ο πίνακας συνδιακυμάνσεων C [38].

Πιο συγκεκριμένα, το μοντέλο της ICA θεωρεί πως τα δεδομένα εισόδου, δηλαδή τα εξαγμένα χαρακτηριστικά, είναι τυχαίοι γραμμικοί συνδυασμοί λανθάνων μεταβλητών, δηλαδή μεταβλητών που δεν μπορούν να παρατηρηθούν. Οι μεταβλητές αυτές είναι στατιστικά ανεξάρτητες μεταξύ τους και αποτελούν τις Ανεξάρτητες Συνιστώσες. Κατά αυτόν τον τρόπο, για κάθε χαρακτηριστικό X_i από τα n συνολικά χαρακτηριστικά που έχουν εξαχθεί, ισχύει η παρακάτω σχέση:

$$X_i = \alpha_{i1} S_1 + \alpha_{i2} S_2 + \dots + \alpha_{in} S_n$$

όπου S είναι οι λανθάνουσες μεταβλητές και $i = 1, 2, \dots, n$.

Από την παραπάνω σχέση είναι εμφανές πως τα χαρακτηριστικά παράγονται από τις συνιστώσες S_i με μια διαδικασία μίξης που καθορίζεται από τους συντελεστές μίξης α_{ij} , οι οποίοι όμως είναι άγνωστοι. Η παραπάνω σχέση μπορεί να εκφραστεί και υπό τη μορφή πινάκων ως εξής:

$$X = A S$$

όπου X είναι το τυχαίο διάνυσμα των χαρακτηριστικών X_1, X_2, \dots, X_n , S το τυχαίο διάνυσμα S_1, S_2, \dots, S_n και A ο πίνακας με τους συντελεστές μίξης α_{ij} . Αφού εκτιμηθούν οι τιμές των στοιχείων του πίνακα A , γίνεται η αντίστροφη διαδικασία που εκφράζεται από την παρακάτω σχέση, ώστε να υπολογιστούν οι Ανεξάρτητες Συνιστώσες S_i .

$$S = W X$$

όπου W είναι ο ψευδο-αντίστροφος πίνακας του A .

Αντίθετα από την PCA, στην ICA είναι αδύνατος ο καθορισμός της τάξης των Ανεξάρτητων Συνιστωσών που προκύπτουν. Αυτό συμβαίνει διότι παρόλο που οι διαστάσεις του διανύσματος S και του πίνακα A της ανωτέρω σχέσης είναι γνωστές, οι τιμές τους είναι άγνωστες. Έτσι, είναι επιτρεπτό να μεταβληθεί η σειρά των όρων της σχέσης $X_i = \alpha_{i1} S_1 + \alpha_{i2} S_2 + \dots + \alpha_{in} S_n$, με αποτέλεσμα οποιαδήποτε Ανεξάρτητη Συνιστώσα να μπορεί να θεωρηθεί ως πρώτη [39].

3.4 Επιλογή Χαρακτηριστικών

Το επόμενο στάδιο ενός Συστήματος Αναγνώρισης Προτύπων είναι η Επιλογή Χαρακτηριστικών (Feature Selection). Η διαδικασία αυτή αποσκοπεί επίσης στη μείωση του αριθμού των χαρακτηριστικών για τους λόγους που αναφέρθηκαν παραπάνω. Η διαφορά της από τη διαδικασία Μείωσης Χαρακτηριστικών είναι πως κατά την Επιλογή Χαρακτηριστικών δεν πραγματοποιείται μετασχηματισμός των χαρακτηριστικών, αλλά απλώς επιλέγεται ένα υποσύνολο των αρχικών χαρακτηριστικών. Τα χαρακτηριστικά που αποτελούν αυτό το υποσύνολο θεωρούνται τα βέλτιστα, δηλαδή είναι αυτά που διαχωρίζουν τα δεδομένα σε κλάσεις με τον καλύτερο δυνατό τρόπο.

3.4.1 Recursive Feature Elimination (RFE)

Μία ευρέως χρησιμοποιούμενη τεχνική Επιλογής Χαρακτηριστικών είναι η RFE. Η τεχνική αυτή λαμβάνει υπόψη αρχικά όλα τα χαρακτηριστικά που έχουν εξαχθεί και μέσω ενός ταξινομητή, κατηγοριοποιεί τα δεδομένα σε κλάσεις (τα είδη και η λειτουργία των ταξινομητών αναλύεται παρακάτω). Μέσω αυτής της διαδικασίας υπολογίζεται η σημασία

του κάθε χαρακτηριστικού για τον διαχωρισμό των σημάτων. Ανάλογα με το πόσο σημαντικό είναι κάθε χαρακτηριστικό, αντιστοιχίζεται σε αυτό ένα βάρος (weight). Το βάρος είναι ένας αριθμός ο οποίος πολλαπλασιάζεται με την τιμή του αντίστοιχου χαρακτηριστικού πριν γίνει η ταξινόμηση. Ένα χαρακτηριστικό που συμβάλλει σημαντικά στον διαχωρισμό των δεδομένων θα έχει υψηλό βάρος, ενώ ένα χαρακτηριστικό που είναι λιγότερο σημαντικό, θα έχει μικρότερο βάρος. Με αυτόν τον τρόπο, ανάλογα το βάρος που έχει κάθε χαρακτηριστικό, εκτιμάται και η σημασία του.

Έπειτα, το χαρακτηριστικό που έχει το μικρότερο βάρος αφαιρείται από το σύνολο των χαρακτηριστικών. Η διαδικασία αυτή επαναλαμβάνεται για τα $N-1$ χαρακτηριστικά που έχουν απομείνει (N : αριθμός αρχικών χαρακτηριστικών που έχουν εξαχθεί). Έτσι, υπολογίζονται εκ νέου τα βάρη για τα εναπομείναντα χαρακτηριστικά και αφαιρείται αυτό με το μικρότερο βάρος. Η διαδικασία τελειώνει όταν έχει απομείνει ο επιθυμητός αριθμός χαρακτηριστικών. Αυτά τα χαρακτηριστικά θεωρούνται τα καλύτερα. [40]


3.5 Ταξινόμηση

Αφού τα χαρακτηριστικά εξαχθούν και έπειτα μειωθούν, είναι έτοιμα να τροφοδοτηθούν σε έναν αλγόριθμο ο οποίος θα βασίζεται σε αυτά και θα ταξινομεί τα δεδομένα σε κατηγορίες ή αλλιώς κλάσεις. Ο αλγόριθμος αυτός ονομάζεται ταξινομητής (classifier) και στην προκειμένη περίπτωση ταξινομεί τα σήματα εγκεφαλογραφίας σε δύο κλάσεις, ανάλογα με την συγκέντρωση του υποκειμένου.

Η διαδικασία εκπαίδευσης του ταξινομητή και έπειτα η χρήση του για την ταξινόμηση αγνώστων στοιχείων, υπάγεται στον γενικότερο κλάδο της Μηχανικής Μάθησης (Machine Learning). Υπάρχουν δύο είδη Μηχανικής Μάθησης: η επιβλεπόμενη (supervised) και η μη επιβλεπόμενη (unsupervised). Στην πρώτη περίπτωση, είναι γνωστό εκ των προτέρων σε πόσες και ποιες κλάσεις χωρίζονται τα δεδομένα εκπαίδευσης, καθώς και σε ποια κλάση ανήκει το καθένα. Αντίθετα, στη μη επιβλεπόμενη ταξινόμηση, δεν είναι γνωστό αν τα δεδομένα διαχωρίζονται και ο σκοπός του ταξινομητή είναι να εντοπίσει κοινά στοιχεία μεταξύ τους, ώστε να μπορέσει να κατηγοριοποιήσει τα όμοια δεδομένα μεταξύ τους στην ίδια ομάδα (συστάδα). Για αυτό και η διαδικασία της μη επιβλεπόμενης Μηχανικής Μάθησης ονομάζεται και συσταδοποίηση (clustering). Στην παρούσα εργασία, το σύστημα που αναπτύχθηκε είναι επιβλεπόμενης Μηχανικής Μάθησης.

Για να γίνει λοιπόν η ταξινόμηση, χρειάζεται πρώτα ένα σύνολο εκπαίδευσης πάνω στο οποίο θα εκπαιδευτεί ο ταξινομητής. Σκοπός της εκπαίδευσης είναι ο υπολογισμός της συνάρτησης απόφασης, η οποία θα διαχωρίζει τα δεδομένα σε κλάσεις. Ανάλογα τον αριθμό των χαρακτηριστικών που χρησιμοποιούνται και άρα ανάλογα τις διαστάσεις του χώρου στον οποίο αυτά υπάρχουν, η μορφή της συνάρτησης απόφασης διαφέρει. Σε περίπτωση δυδιάστατου χώρου, έχει τη μορφή ευθείας γραμμής, ενώ σε χώρους υψηλότερων διαστάσεων έχει τη μορφή υπερπλάνου. Σε κάθε περίπτωση, ο σκοπός είναι ο διαχωρισμός του χώρου χαρακτηριστικών σε περιοχές, όπου η καθεμία από αυτές θα αντιστοιχεί σε μία κλάση. Βάσει του συνόλου εκπαίδευσης υπολογίζονται οι παράμετροι της συνάρτησης αυτής, ώστε η τμηματοποίηση του χώρου να γίνει όσο το δυνατόν πιο σωστά. Έτσι, όταν τεθεί ως είσοδος στο σύστημα ένα άγνωστο πρότυπο, θα ταξινομηθεί στον αντίστοιχο χώρο που καθορίζει η συνάρτηση. [16]

Το απλούστερο παράδειγμα ταξινόμησης, παρουσιάζεται στην παρακάτω εικόνα, στην οποία απεικονίζεται η κατηγοριοποίηση προτύπων δύο χαρακτηριστικών σε δύο κλάσεις και η συνάρτηση απόφασης είναι η ευθεία γραμμή.



Εικόνα 2.8: Αναπαράσταση ταξινόμησης προτύπων σε δύο κλάσεις A(o) και B(+) μέσω της διαχωριστικής γραμμής (decision line) του ταξινομητή. Κατά τη διαδικασία της ταξινόμησης υπάρχει η περίπτωση το άγνωστο πρότυπο να μην ταξινομηθεί σωστά (*). [16]

Ανάλογα με τον αριθμό των προτύπων που θα ταξινομηθούν λανθασμένα, προκύπτει η απόδοση του ταξινομητή.

Ακολουθώς αναλύονται μερικοί από τους πιο σημαντικούς και συχνά χρησιμοποιούμενους ταξινομητές.

3.5.1 Μπαϊσιανός Ταξινομητής (Bayes Classifier)

Ο Bayesian Classifier ταξινομεί ένα άγνωστο πρότυπο X σε μία κλάση βάσει του θεωρήματος του Bayes. Σύμφωνα με αυτό, για ένα στοιχείο X με N σε πλήθος χαρακτηριστικά, για ω_i κλάσεις όπου $i=1,2,\dots,k$ και για ένα σύνολο εκπαίδευσης D , ισχύει η παρακάτω σχέση για κάθε κλάση:

$$P(\omega_i | X) = \frac{p(X|\omega_i)P(\omega_i)}{p(X)}$$

όπου $p(X|\omega_i)$ είναι η Συνάρτηση Πυκνότητας Πιθανότητας (Probability Density Function - PDF) της κάθε κλάσης. Δηλαδή, περιγράφει την κατανομή των προτύπων σε κάθε κλάση ω_i . Ο όρος $P(\omega_i)$ αντιστοιχεί στην πιθανότητα το στοιχείο X να ανήκει στην κλάση ω_i , χωρίς όμως να έχει ληφθεί υπόψη το σύνολο D . Για αυτόν τον λόγο ονομάζεται εκ των προτέρων πιθανότητα (a priori). $p(X)$ είναι η Συνάρτηση Πυκνότητας Πιθανότητας του προτύπου X , για την οποία ισχύει:

$$p(X) = \sum_{i=1}^c p(X|\omega_i) P(\omega_i)$$

όπου $p(X|\omega_i)$ είναι η συνάρτηση πυκνότητας του X , δοθείσας της κλάσης ω_i .

Επειδή ο όρος $P(X)$ είναι σταθερός για όλες τις κλάσεις, δεν λαμβάνεται υπόψιν και έτσι μπορεί να παραλειφθεί από την παραπάνω σχέση. Τέλος, ο ζητούμενος όρος $P(\omega_i|X)$ δηλώνει την πιθανότητα το στοιχείο X να ανήκει στην κλάση y , αφού έχει ληφθεί υπόψιν το σύνολο D . Για αυτόν τον λόγο, ονομάζεται εκ των υστέρων πιθανότητα (a posteriori).

Αφού υπολογιστεί η πιθανότητα $P(\omega_i|X)$ για κάθε μία από τις c κλάσεις, ο Bayes Classifier θα ταξινομήσει το X στην κλάση με τη μεγαλύτερη τιμή $P(\omega_i|X)$. [16] [41]

Ένα είδος του Bayes Classifier είναι ο Naïve Bayes Classifier. Ο ταξινομητής αυτός βασίζεται στο θεώρημα του Bayes που περιγράφηκε παραπάνω, θεωρώντας όμως ως δεδομένη τη στατιστική ανεξαρτησία των χαρακτηριστικών μεταξύ τους. Σύμφωνα με αυτή την παραδοχή η Συνάρτηση Πυκνότητας Πιθανότητας της κάθε κλάσης δίνεται από την εξής σχέση:

$$p(X|\omega_i) = \prod_{n=1}^N p(X_n|\omega_i)$$

όπου n είναι το πλήθος των χαρακτηριστικών του κάθε προτύπου.

Επομένως, η ζητούμενη εκ των υστέρων πιθανότητα υπολογίζεται πλέον ως εξής:

$$P(\omega_i|X) = \frac{\prod_{n=1}^N p(X_n|\omega_i) P(\omega_i)}{p(X)}$$

Ο ταξινομητής θα ταξινομήσει το άγνωστο πρότυπο X στην κλάση ω_m με τη μεγαλύτερη πιθανότητα, άρα:

$$\omega_m = \operatorname{argmax}_{(k)} \prod_{n=1}^N p(X_n|\omega_i) P(\omega_i)$$

Η παραπάνω εξίσωση αποτελεί την συνάρτηση απόφασης των Naïve Bayes ταξινομητών. Ένα είδος Naïve Bayes ταξινομητή, ευρέως χρησιμοποιούμενο είναι ο Gaussian Naïve Bayes, που χρησιμοποιείται για δεδομένα που παρουσιάζουν Γκαουσιανή κατανομή. Σε αυτήν την περίπτωση η κατανομή $p(X_i|\omega_i)$ δίνεται από την εξής σχέση:

$$p(X|\omega_i) = \frac{1}{\sqrt{2\pi} \sigma_{\omega_i}^2} e^{-\frac{(X-\mu_{\omega_i})^2}{2\sigma_{\omega_i}^2}}$$

Όπου μ_{ω_i} και σ_{ω_i} είναι η μέση τιμή και η τυπική απόκλιση του X για κάθε κλάση ω_i [42].

3.5.2 Ταξινομητής k πλησιέστερων γειτόνων - k Nearest Neighbors (k -NN)

Ο ταξινομητής k πλησιέστερων γειτόνων αποτελεί έναν από τους πιο διάσημους ταξινομητές και βασίζεται σε στην εξής πολύ απλή αρχή:


Για ω_i κλάσεις όπου $i=1,2,\dots,c$, για ένα σύνολο δεδομένων εκπαίδευσης D με $N=1,\dots,n$ χαρακτηριστικά και για ένα στοιχείο $X=(X_1,X_2,\dots,X_n)$, το οποίο είναι προς ταξινόμηση, ο ταξινομητής k πλησιέστερων γειτόνων θα ταξινομήσει το X στην κλάση που απέχει λιγότερο από αυτό. Αναλυτικά, στην αρχή ο ταξινομητής υπολογίζει τις αποστάσεις του X από όλα τα στοιχεία του συνόλου D , χρησιμοποιώντας ένα μέτρο απόστασης (π.χ. Ευκλείδεια απόσταση, Mahalanobis απόσταση). Έπειτα, εντοπίζονται τα k στοιχεία του D , τα οποία έχουν τη μικρότερη απόσταση από το X . Το X θα ταξινομηθεί στην κλάση στην οποία ανήκει η πλειοψηφία των k στοιχείων, δηλαδή των k πλησιέστερων γειτόνων.

Η επιλογή του αριθμού k είναι στην κρίση του χρήστη και εξαρτάται από το μέγεθος του διαθέσιμου συνόλου εκπαίδευσης. Συνήθως, όσο μεγαλύτερος είναι ο αριθμός k , τόσο

μειώνεται η επίδραση του θορύβου στα δεδομένα, διότι μειώνεται η επίδραση των ακραίων σημείων (outliers). Ένα μειονέκτημα του συγκεκριμένου ταξινομητή είναι η υπολογιστική πολυπλοκότητα που σχετίζεται με την αναζήτηση των k πλησιέστερων γειτόνων, ιδιαίτερα σε χώρους μεγάλους διαστάσεων [41].

3.5.3 Support Vector Machine (SVM)

Ο ταξινομητής SVM διαχωρίζει τα δεδομένα σε κλάσεις βρίσκοντας υπερεπίπεδα απόφασης (decision hyperplane) και έπειτα ταξινομεί τα άγνωστα στοιχεία στις κλάσεις που προέκυψαν. Για παράδειγμα, έστω ένα σύνολο εκπαίδευσης $D=(d_1,d_2,\dots,d_M)$ το οποίο περιέχει M στοιχεία 2 διαστάσεων και έστω ένα άγνωστο πρότυπο X προς ταξινόμηση. Το σύνολο D χωρίζεται σε δύο κλάσεις $\omega_i=\{-1,1\}$. Ο SVM βρίσκει ένα υπερεπίπεδο απόφασης, που στη συγκεκριμένη περίπτωση είναι μία ευθεία γραμμή, αφού τα δεδομένα είναι δυσδιάστατα, το οποίο διαχωρίζει τα δεδομένα στο επίπεδο στις 2 κλάσεις (Εικόνα2.9). Ανάλογα με τη θέση του άγνωστου στοιχείου σε σχέση με τη γραμμή αυτή, καθορίζεται σε ποια κλάση θα ταξινομηθεί το στοιχείο.



Εικόνα 2.9: Η μπλε και η πράσινη ομάδα στοιχείων αποτελούν τις δύο κλάσεις και η κόκκινη γραμμή είναι το υπερεπίπεδο απόφασης που τις διαχωρίζει [43].

Είναι προφανές πως υπάρχουν πολλές γραμμές που μπορούν να διαχωρίσουν τα δεδομένα επιτυχώς. Η καλύτερη είναι αυτή η οποία απέχει τη μεγαλύτερη απόσταση και από τις δύο κλάσεις ταυτόχρονα. Η γραμμή αυτή αποτελεί το υπερεπίπεδο μεγίστου εύρους (maximum margin hyperplane). Τα δύο στοιχεία, ένα από κάθε κλάση, που απέχουν τη μικρότερη απόσταση από το υπερεπίπεδο μεγίστου εύρους ονομάζονται support vectors και η απόσταση αυτή αποτελεί το εύρος (margin). Οι δύο παράλληλες στο υπερεπίπεδο μεγίστου εύρους γραμμές που διέρχονται από τα support vectors ονομάζονται εφαπτόμενα υπερεπίπεδα (tangential hyperplanes). Επομένως οι εξισώσεις αυτών των δύο είναι οι εξής: $w \cdot x + b = -1$ και

$w d + b = 1$, όπου w και b είναι παράμετροι του μοντέλου. Έτσι, εξίσωση του υπερεπιπέδου μεγίστου εύρους θα είναι: $w d + b = 0$.

Από τις παραπάνω σχέσεις είναι εύκολο να υπολογιστεί το εύρος του ταξινομητή:

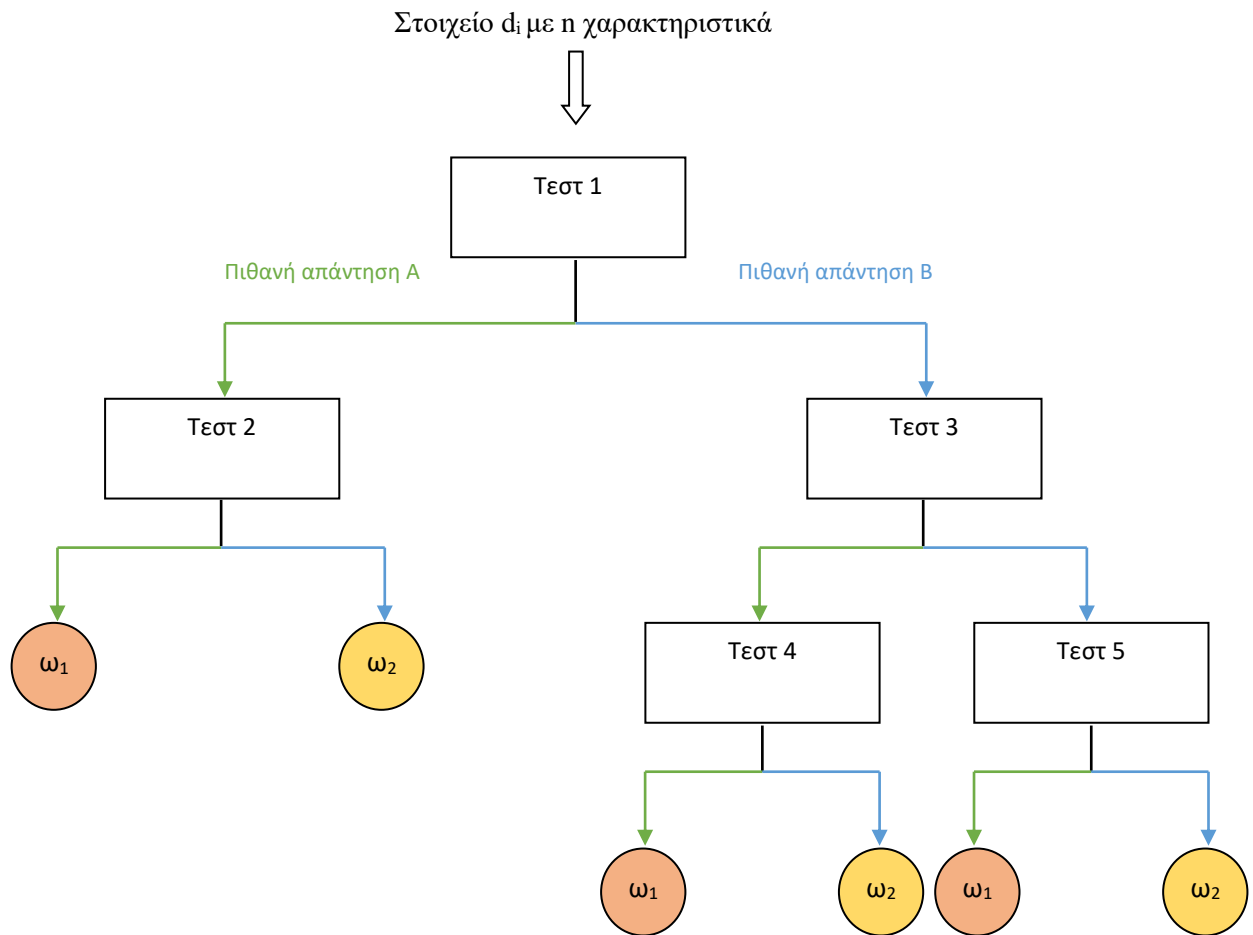
$$w \cdot \Delta d = 2 \text{ άρα } \|w\| \cdot \text{εύρος} = 2 \text{ άρα } \text{εύρος} = \frac{2}{\|w\|}$$

Το παραπάνω παράδειγμα αφορά σύνολα εκπαίδευσης των οποίων οι κλάσεις είναι γραμμικά διαχωρίσιμες. Σε αντίθετες περιπτώσεις ο SVM μεταφέρει τα δεδομένα σε έναν χώρο μεγαλύτερων διαστάσεων από τον αρχικό και τα διαχωρίζει γραμμικά σε αυτόν σύμφωνα με τη μεθοδολογία που περιγράφηκε παραπάνω. Εάν $\Phi(d)$ είναι η συνάρτηση που αλλάζει τις διαστάσεις των δεδομένων, τότε η γραμμική επιφάνεια απόφασης θα είναι η ακόλουθη: $w \cdot \Phi(d) + b = 0$ [44].

Η συνάρτηση $\Phi(d)$ ονομάζεται συνάρτηση πυρήνων (kernel function) και μπορεί να είναι διαφόρων ειδών (π.χ. πολυωνυμική). Μέσω της διαδικασίας που ονομάζεται kernel trick, η συνάρτηση υπολογίζει τις σχέσεις μεταξύ των στοιχείων σε χώρους μεγαλύτερων διαστάσεων, χωρίς να υλοποιεί στην πραγματικότητα τη μετατροπή διαστάσεων. Κατά αυτόν τον τρόπο, μειώνεται το υπολογιστικό κόστος, ιδιαίτερα σε περιπτώσεις που γίνονται υπολογισμοί σε μεγάλους χώρους διαστάσεων [45].

3.5.4 Δέντρα Απόφασης (Decision Trees ή Classification Trees)


Τα Δέντρα Απόφασης είναι ένα είδος ταξινομητή με τη μορφή «αντίστροφου δέντρου». Κατά το στάδιο εκπαίδευσης του ταξινομητή, ως είσοδος τίθεται το κάθε στοιχείο του συνόλου εκπαίδευσης $D=(d_1, d_2, \dots, d_M)$, το οποίο αντιστοιχεί σε μία κλάση ω_i . Για κάθε στοιχείο d_i υπάρχει ένας κόμβος (node) από τον οποίον απορρέουν δύο «κλαδιά» (branches), τα οποία με τη σειρά τους καταλήγουν σε άλλους κόμβους. Η δομή αυτή επαναλαμβάνεται έως ότου τα «κλαδιά» να καταλήξουν σε έναν κόμβο που ονομάζεται «φύλλο» (leaf), το οποίο αντιστοιχεί σε μία από τις κλάσεις ω_i . Ακριβέστερα, κάθε κόμβος αντιστοιχεί σε ένα χαρακτηριστικό του d_i και σε αυτόν πραγματοποιείται ένα «τεστ» για αυτό το χαρακτηριστικό (π.χ. αν η τιμή του είναι μεγαλύτερη από μία τιμή κατωφλίου). Τα δύο «κλαδιά» του κόμβου αντιστοιχούν στα δύο πιθανά αποτελέσματα του «τεστ» και το καθένα τους καταλήγει σε έναν άλλο κόμβο, στον οποίο πραγματοποιείται ένα «τεστ» για κάποιο άλλο χαρακτηριστικό του d_i . Η διαδικασία αυτή συνεχίζεται μέχρι τα δεδομένα να μην μπορούν να απλοποιηθούν άλλο, δηλαδή να μην μπορούν να πραγματοποιηθούν άλλα «τεστ» και έτσι τα «κλαδιά» να καταλήξουν σε ένα «φύλλο» που θα δηλώσει τελικά σε ποια κλάση ω_i ανήκει το d_i . Μέσω της ταξινόμησης των δειγμάτων του συνόλου εκπαίδευσης, προκύπτουν οι κανόνες απόφασης (decision rules) που ορίζουν τη διαδρομή που θα ακολουθήσει το κάθε στοιχείο και με βάση αυτούς θα ταξινομηθεί ένα άγνωστο πρότυπο X [46].



Εικόνα 2.10: Σχηματική αναπαράσταση της διαδικασίας ταξινόμησης ενός στοιχείου d_i σε μία από τις δύο κλάσεις ω_1 και ω_2 . Τα παραλληλόγραμμα σχήματα αναπαριστούν τους κόμβους, ενώ τα κυκλικά στο τέλος του διαγράμματος είναι τα «φύλλα».

Ανάλογα με τα κριτήρια που χρησιμοποιούνται ώστε να επιλεγεί ποιο θα είναι το «τεστ» που εφαρμόζεται σε κάθε κόμβο αλλά και πότε θα τερματίσει η διαδικασία ανάπτυξης του δέντρου υπάρχουν διάφοροι τύποι αλγορίθμων Δέντρων Απόφασης. Στη παρούσα εργασία παρουσιάζεται ο CART (Classification and Regression Tree), ο οποίος ως κριτήριο διάσπασης των κόμβων χρησιμοποιεί την τιμή του δείκτη Gini (Gini Impurity). Ο δείκτης αυτός δηλώνει την πιθανότητα ύπαρξης λανθασμένης ταξινόμησης του δείγματος d_i . [47]

Παρόλο που ο συγκεκριμένος αλγόριθμος παρουσιάζει υψηλές αποδόσεις, το βασικό πρόβλημα που προκύπτει στις εφαρμογές του είναι η ευαισθησία του στο φαινόμενο της υπερειδίκευσης (over fitting) (Εικόνα 2.11). Σε αυτή την περίπτωση, ο ταξινομητής θα εντοπίσει και θα διαχωρίσει με πολύ μεγάλη ακρίβεια τις δύο κλάσεις του συνόλου εκπαίδευσης, όμως θα παρουσιάσει πολύ χειρότερες επιδόσεις στην ταξινόμηση άγνωστων δεδομένων. Αυτό συμβαίνει διότι ο αλγόριθμος προσαρμόζεται ακόμα και στον θόρυβο ή στις τυχαίες μεταβολές που έχει το συγκεκριμένο σύνολο εκπαίδευσης, γεγονός που τον καθιστά ελάχιστα προσαρμοστικό σε διαφορετικά δεδομένα [48].



Εικόνα 2.11: Παράδειγμα υπερειδικευμένου μοντέλου. Η πράσινη γραμμή αντιστοιχεί σε ένα υπερειδικευμένο μοντέλο ταξινομητή, ενώ η μαύρη γραμμή σε ένα πιο γενικευμένο μοντέλο.

Οι κουκίδες αποτελούν τα δείγματα ενός συνόλου εκπαίδευσης με δύο κλάσεις (μπλε και κόκκινη). Παρόλο που το μοντέλο της πράσινης γραμμής διαχωρίζει αλάνθαστα τα δεδομένα, είναι πολύ εξαρτημένο από αυτά. Για αυτόν τον λόγο όταν τροφοδοτηθεί με άγνωστα δεδομένα θα τα διαχωρίσει χειρότερα από ότι η μαύρη γραμμή [49].

3.5.5 Random Forest

Ο ταξινομητής Random Forest βασίζεται σε πολύ μεγάλο βαθμό στα Δένδρα Απόφασης που αναφέρθηκαν παραπάνω. Για την ακρίβεια, ο Random Forest αποτελεί μία συλλογή πολλών τέτοιων Δένδρων. Κάθε ένα Δένδρο Απόφασης τροφοδοτείται με στοιχεία d_i του συνόλου εκπαίδευσης $D=(d_1, d_2, \dots, d_M)$ και κάνει την ταξινόμηση του d_i σε μία κλάση ω_i . Με αυτόν τον τρόπο, κάθε Δένδρο «ψηφίζει» κάποια κλάση. Εν τέλει, η ταξινόμηση του d_i γίνεται στην κλάση με τις περισσότερες ψήφους. Ο λόγος που προτιμάται να χρησιμοποιούνται πολλά Δένδρα Απόφασης είναι διότι με αυτόν τον τρόπο επιτυγχάνεται καλύτερη απόδοση και ταυτόχρονα ο ταξινομητής είναι λιγότερο ευαίσθητος στον θόρυβο [50].

Όμως, τα πολλά Δένδρα Απόφασης που σχηματίζονται δεν έχουν ως είσοδο το ίδιο σύστημα εκπαίδευσης. Από το αρχικό σύνολο εκπαίδευσης D , το οποίο περιέχει M στοιχεία d_i επιλέγονται M στοιχεία στην τύχη με εναπόθεση. Αυτό σημαίνει πως κάποια στοιχεία θα επιλεγούν παραπάνω από μία φορά και πως κάποια δεν θα επιλεγούν καθόλου. Η τεχνική αυτή ονομάζεται bootstrap sampling ή sampling with replacement και επαναλαμβάνεται τόσες φορές, όσες και τα Δένδρα Απόφασης που χρησιμοποιεί ο Random Forest. Κατά αυτόν τον τρόπο, το κάθε Δένδρο Απόφασης έχει το δικό του σύνολο εκπαίδευσης. Ο λόγος που προτιμάται το κάθε Δένδρο Απόφασης να εκπαιδεύεται με διαφορετικό σύνολο, είναι πως έτσι τα Δένδρα που δημιουργούνται δεν συσχετίζονται (uncorrelated) μεταξύ τους. Ως αποτέλεσμα, καταπολεμάται το μειονέκτημα της υπερειδίκευσης (over fitting) των Δένδρων Απόφασης.

Ένας τρόπος εκτίμησης της βεβαιότητας με την οποία θα γίνει η ταξινόμηση ενός άγνωστου στοιχείου X είναι ο υπολογισμός της διακύμανσης των αποτελεσμάτων του κάθε Δένδρου του Random Forest. Θεωρητικά, είναι προφανές πως όσο αυξάνεται ο αριθμός των Δένδρων του ταξινομητή, τόσο θα μειώνεται και η τυπική απόκλιση. Στην πράξη όμως αυτός ο αριθμός αυτός επιλέγεται από τον χρήστη και συνήθως είναι μερικές εκατοντάδες.


3.5.6 Νευρωνικά Δίκτυα

Τα Νευρωνικά Δίκτυα είναι υπολογιστικά συστήματα τα οποία αποτελούνται από πολυάριθμες υπολογιστικές μονάδες που ονομάζονται νευρώνες. Όλοι οι νευρώνες του συστήματος είναι οργανωμένοι μεταξύ τους με τέτοιο τρόπο που προσομοιάζουν τη δομή και τη λειτουργία του ανθρώπινου νευρωνικού δικτύου. Οργανώνονται σε επίπεδα (layers) και ενώνονται μεταξύ τους μέσω συνδέσεων, που ονομάζονται συνάψεις. Κάθε σύναψη καθορίζεται από ένα αριθμό, το βάρος (weight), ο οποίος πολλαπλασιάζεται με την τιμή εισόδου προτού φθάσει στον κάθε νευρώνα. Οι τιμές των βαρών καθορίζονται κατά τη διαδικασία της εκπαίδευσης. Σε περίπτωση που οι έξοδοι του κάθε επιπέδου αποτελούν τις εισόδους του επόμενου, το δίκτυο ονομάζεται πρόσθιας τροφοδότησης (feedforward).

Υπάρχουν διαφορετικά είδη νευρώνων, οι οποίοι διαχειρίζονται διαφορετικά τα δεδομένα εισόδου τους. Παρακάτω θα αναλυθεί ένας βασικός τύπος νευρώνα που ονομάζεται Perceptron (Εικόνα 2.12).

Ο Perceptron μπορεί να έχει πολλά στοιχεία εισόδου, αλλά μόνο ένα στοιχείο εξόδου. Συγκεκριμένα, ως εισοδοί του τίθενται τα χαρακτηριστικά δυαδικών προτύπων και η έξοδος του είναι η μία εκ των δύο κλάσεων στην οποία ταξινομούνται τα πρότυπα αυτά. Ο Perceptron αθροίζει τις τιμές X_i των χαρακτηριστικών πολλαπλασιασμένες με τα αντίστοιχα βάρη w_i . Επομένως, για τον νευρώνα ισχύει η παρακάτω σχέση: $d(x) = \sum_{i=1}^n w_i x_i$, όπου n είναι ο αριθμός των χαρακτηριστικών του προτύπου X που τίθεται προς ταξινόμηση.

Στο αποτέλεσμα που προκύπτει εφαρμόζεται η συνάρτηση ενεργοποίησης (activation function), η οποία καθορίζει την τιμή εξόδου του νευρώνα, μέσω ενός κατωφλίου. Εάν το αποτέλεσμα της άθροισης είναι μεγαλύτερο από μία καθορισμένη τιμή κατωφλίου, τότε η έξοδος του νευρώνα παίρνει την τιμή (π.χ. -1 ή 1) που δηλώνει την αντίστοιχη κλάση. [51]




Εικόνα 2.12: Σχηματική αναπαράσταση λειτουργίας ενός νευρώνα Perceptron. Είσοδος του νευρώνα είναι ένα πρότυπο x με n σε πλήθος χαρακτηριστικά, τα οποία πολλαπλασιάζονται με τα αντίστοιχα βάρη τους w_1, w_2, \dots, w_n . Το άθροισμά τους συγκρίνεται με την τιμή κατωφλίου w_{n+1} και έτσι καθορίζεται η έξοδος του νευρώνα (+1 ή -1) που δηλώνει την κλάση στην οποία ταξινομήθηκε το πρότυπο x . [51]

3.5.7 Πολυεπίπεδα Δίκτυα Perceptron – Multilayer Perceptron (MLP)

Όπως προαναφέρθηκε οι νευρώνες οργανώνονται σε διαδοχικά επίπεδα δημιουργώντας έτσι πολύπλοκα Νευρωνικά Δίκτυα. Ένα παράδειγμα τέτοιου δικτύου πρόσθιας τροφοδοσίας αποτελούν τα Πολυεπίπεδα Δίκτυα Perceptron (MLP), τα οποία όπως δηλώνει και το όνομά τους, απαρτίζονται από πολλαπλούς νευρώνες Perceptron. Η δομή τους διαμορφώνεται ως εξής: το πρώτο επίπεδο είναι το επίπεδο εισόδου (input layer), το οποίο δέχεται τα χαρακτηριστικά των προτύπων. Το τελευταίο επίπεδο είναι το επίπεδο εξόδου (output layer), το οποίο παράγει το τελικό αποτέλεσμα της ταξινόμησης. Ενδιάμεσα αυτών δύναται να μεσολαβούν από ένα έως πολλά ενδιάμεσα επίπεδα, τα οποία ονομάζονται κρυμμένα επίπεδα (hidden layers). Συνήθως ο αριθμός των νευρώνων του επιπέδου εισόδου είναι ίσος με τον αριθμό των χαρακτηριστικών των προτύπων και ο αριθμός των νευρώνων του επιπέδου εξόδου είναι ίσος με τον αριθμό των κλάσεων στις οποίες ανήκουν τα πρότυπα αυτά.

Η διαφορά ενός πολυεπίπεδου δικτύου από ένα νευρώνα Perceptron είναι αρχικά πως με το δίκτυο είναι δυνατή η ταξινόμηση προτύπων σε πάνω από δύο κλάσεις και πως το δίκτυο χρησιμοποιεί διαφορετική συνάρτηση ενεργοποίησης. Οι πιο ευρέως χρησιμοποιούμενες συναρτήσεις ενεργοποίησης είναι η Σιγμοειδής (Sigmoid) και η Rectified Linear Unit (ReLU). Και οι δύο μετατρέπουν τις τιμές που λαμβάνουν ως είσοδο σε τιμές μεταξύ του μηδενός και της μονάδας. Επίσης και οι δύο διαθέτουν μία παράμετρο παρόμοια με την τιμή κατωφλίου που αναλύθηκε παραπάνω, η οποία ονομάζεται bias. Η παράμετρος αυτή καθορίζει την κλίση της συνάρτησης ενεργοποίησης και άρα το κατά πόσο το αποτέλεσμά της θα είναι πλησιέστερα του μηδενός ή της μονάδας. [51]



Εικόνα 2.13: Σχηματική αναπαράσταση Πολυεπίεδου Δικτύου Perceptron με 2 κρυμμένα επίπεδα για την ταξινόμηση προτύπων σε 4 κλάσεις. [51]

Κατά τη διαδικασία εκπαίδευσης υπολογίζονται οι τιμές των βαρών και των παραμέτρων bias κάθε σύναψης και κάθε νευρώνα αντίστοιχα, με τέτοιο τρόπο ώστε κατά την ταξινόμηση να υπάρχουν όσο το δυνατόν λιγότερα πρότυπα που δεν θα έχουν ταξινομηθεί σωστά. Αυτό γίνεται μέσω της μεθόδου οπισθοδιάδοσης (backpropagation – BP). Πιο συγκεκριμένα, η εκπαίδευση του συστήματος ξεκινάει ταξινομώντας τα πρότυπα του συνόλου εκπαίδευσης με κάποιες αρχικές τιμές για τα βάρη και για τις παραμέτρους bias. Η έξοδος του δικτύου είναι η κλάση στην οποία ανήκει τα κάθε πρότυπο, η οποία στη συνέχεια συγκρίνεται με την γνωστή εκ των προτέρων κλάση του κάθε προτύπου. Έτσι προκύπτει η συνάρτηση σφάλματος:

$$E = \sum_{i=1}^n (\omega_i - o_i)^2$$

όπου n είναι το πλήθος των χαρακτηριστικών, ω_i η κλάση στην οποία ανήκει το πρότυπο και ω_j η έξοδος του δικτύου, δηλαδή η τάξη στην οποία ταξινομήθηκε το πρότυπο.

Εν συνεχεία, το δίκτυο τροφοδοτείται με τη συνάρτηση σφάλματος και μέσω μεταβολών στα τιμές των βαρών και των biases, προσπαθεί να βρει το ελάχιστο της. Στην πραγματικότητα η συνάρτηση σφάλματος παρουσιάζει πολλά τοπικά ελάχιστα, επομένως γίνεται αντιληπτό πως η επιλογή των αρχικών τιμών επηρεάζει την απόδοση του MLP. Αφού ολοκληρωθεί η διαδικασία αυτή, τροφοδοτούνται στο δίκτυο τα άγνωστα πρότυπα και ταξινομούνται με τον βέλτιστο συνδυασμό των παραμέτρων. [41]

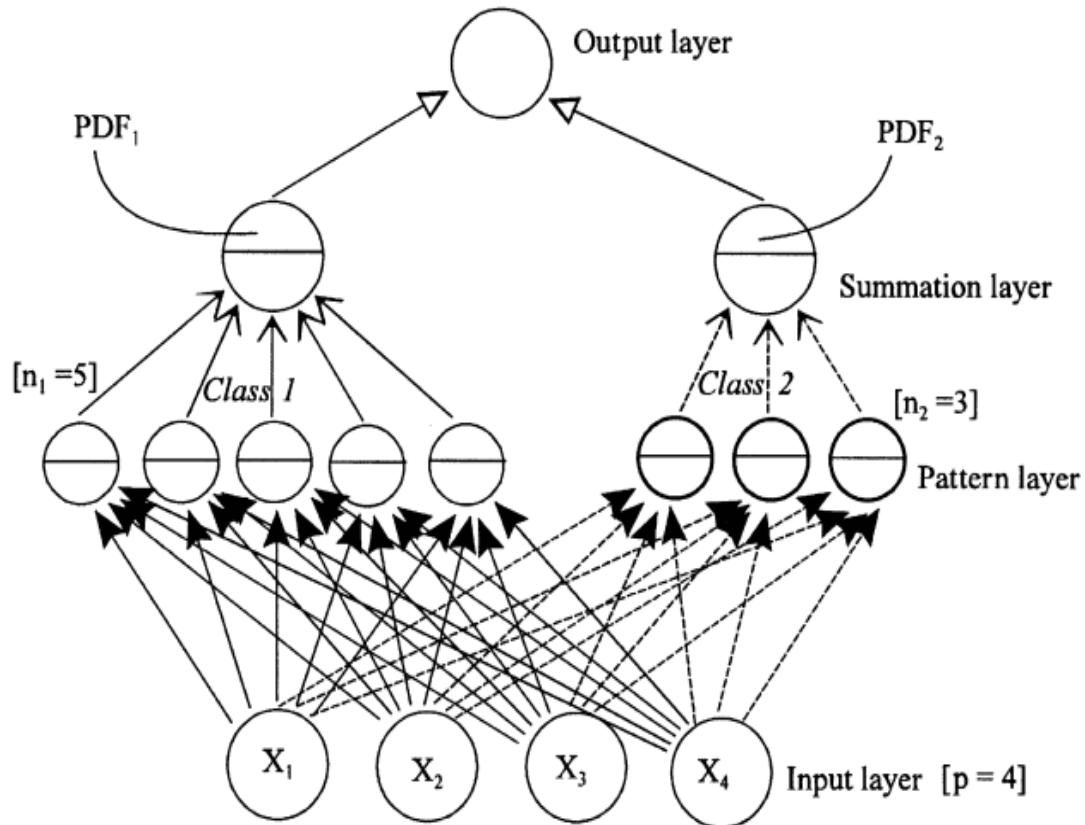
3.5.8 Πιθανοκρατικό Νευρωνικό Δίκτυο – Probabilistic Neural Network (PNN)

Το Πιθανοκρατικό Νευρωνικό διαφέρει από τα υπόλοιπα Νευρωνικά Δίκτυα, διότι κάνει χρήση των στατιστικών. Συγκεκριμένα, βασίζεται στο θεώρημα του Bayes και στη μέθοδο Parzen. Όπως αναλύθηκε και παραπάνω το θεώρημα του Bayes για ένα άγνωστο πρότυπο X και για $\omega=(\omega_1,\omega_2,\dots,\omega_k)$ κλάσεις εκφράζεται από την ακόλουθη εξίσωση:

$$P(\omega_i|X) = \frac{p(X|\omega_i)P(\omega_i)}{p(X)}$$

όπου $p(X|\omega_i)$ είναι η Συνάρτηση Πυκνότητας Πιθανότητας (PDF) της κάθε κλάσης και $p(X)$ είναι η Συνάρτηση Πυκνότητας Πιθανότητας του προτύπου X . Οι δύο αυτές συναρτήσεις υπολογίζονται μέσω της μεθόδου Parzen.

Όσο αφορά στη δομή του δικτύου, υπάρχουν συνολικά 4 επίπεδα: το επίπεδο εισόδου (input layer), το επίπεδο προτύπων (pattern layer), το επίπεδο άθροισης (summation layer) και το επίπεδο εξόδου (output layer) (Εικόνα 2.14). Το επίπεδο εισόδου αποτελείται από τόσους νευρώνες, όσα είναι και τα χαρακτηριστικά των προτύπων. Τα επόμενο επίπεδο, το επίπεδο προτύπων είναι διαχωρισμένο ανάλογα με τον αριθμό και το μέγεθος της κάθε κλάσης. Δηλαδή, οι νευρώνες του είναι οργανωμένοι σε ομάδες και κάθε ομάδα περιέχει τόσους νευρώνες, όσα είναι τα πρότυπα της αντίστοιχης κλάσης. Κάθε ένας από αυτούς, υπολογίζει την απόσταση μεταξύ των προτύπων του συνόλου εκπαίδευσης και του άγνωστου προτύπου που θέτεται για ταξινόμηση. Έπειτα, εφαρμόζει τη μέθοδο Parzen σε κάθε μία απόσταση που προέκυψε και τις προωθεί στο επόμενο επίπεδο, δηλαδή στο επίπεδο άθροισης. Σε αυτό υπάρχει ένας νευρώνας για κάθε κλάση ο οποίος αθροίζει όλες τις τιμές που φθάνουν σε αυτόν, υπολογίζοντας τη Συνάρτηση Πυκνότητας Πιθανότητας για κάθε κλάση και έπειτα την εκ των υστέρων πιθανότητα το πρότυπο να ανήκει σε κάθε μία από τις διαθέσιμες κλάσεις $P(\omega_i|X)$. Τέλος, τα αποτελέσματα που προκύπτουν συγκρίνονται μεταξύ τους και αυτό με τη μεγαλύτερη τιμή οδηγείται στην έξοδο, δηλώνοντας έτσι σε ποια κλάση ταξινομήθηκε το πρότυπο X . [52]



Εικόνα 2.14: Σχηματική αναπαράσταση PNN για πρότυπα εισόδου 4 χαρακτηριστικών τα οποία διαχωρίζονται σε 2 κλάσεις με 5 και 3 πρότυπα αντίστοιχα. [52]

3.6 Αξιολόγηση Συστήματος

Αφού ολοκληρωθεί η διαδικασία της ταξινόμησης, χρειάζεται να γίνει αξιολόγηση του συστήματος, ώστε να εκτιμηθεί η απόδοσή του. Η διαδικασία αυτή πραγματοποιείται μέσω της ταξινόμησης ενός συνόλου δεδομένων, τα οποία είναι άγνωστα στον ταξινομητή, δηλαδή δεν περιέχονται στο σύνολο εκπαίδευσης. Αυτό το σύνολο αποτελεί το σύνολο ελέγχου (test set). Το στάδιο αυτό είναι πολύ σημαντικό καθώς συντελεί στην εκτίμηση της απόδοσης όταν το σύστημα λάβει ως είσοδο άγνωστα δεδομένα.

3.6.1 Μέθοδοι Αξιολόγησης Συστήματος

Μερικές από τις πιο γνωστές μεθόδους αξιολόγησης περιγράφονται παρακάτω.

3.6.1.1 Μέθοδος Holdout

Σύμφωνα με τη μέθοδο Holdout, το αρχικό σύνολο δεδομένων χωρίζεται σε δύο υποσύνολα, το σύνολο εκπαίδευσης (training set) και το σύνολο ελέγχου (test set). Στις περισσότερες περιπτώσεις, το σύνολο εκπαίδευσης είναι μεγαλύτερο (π.χ. 70%-30%, 80%-20%). Αρχικά, στο σύστημα τροφοδοτείται το σύνολο εκπαίδευσης, ώστε να υπολογιστούν οι βέλτιστοι

παράμετροι του ταξινομητή. Στη συνέχεια ως είσοδοι θέτονται τα πρότυπα του συνόλου ελέγχου. Αφού τα πρότυπα αυτά ταξινομηθούν, ελέγχεται πόσα από αυτά ταξινομήθηκαν στη σωστή κλάση και πόσα όχι. Το αποτέλεσμα αυτό αποτελεί μία πολύ καλή εκτίμηση για την απόδοση του συστήματος για άγνωστα δεδομένα σε πραγματικές συνθήκες. [16]

3.6.1.2 Μέθοδος k-fold Cross Validation

Μία άλλη μέθοδος αξιολόγησης είναι η k-fold Cross Validation. Σύμφωνα με αυτή τη μέθοδο, το αρχικό σύνολο δεδομένων διαιρείται σε k υποσύνολα ή αλλιώς folds. Τα υποσύνολα αυτά πρέπει να είναι ίδιου μεγέθους και μη επικαλυπτόμενα. Τα k-1 υποσύνολα χρησιμοποιούνται για την εκπαίδευση του ταξινομητή και το ένα εναπομένει για τον έλεγχο. Η διαδικασία αυτή επαναλαμβάνεται μέχρι να χρησιμοποιηθούν όλα τα υποσύνολα ως σύνολα ελέγχου. Ο μέσος όρος που προκύπτει από τα k αποτελέσματα αποτελεί την απόδοση του συστήματος. [53]

Μία υποκατηγορία της μεθόδου αυτής είναι η Leave-one-out μέθοδος. Σε αυτή, ακολουθείται η ίδια διαδικασία με αυτή της k-fold Cross Validation μεθόδου με τη διαφορά πως η παράμετρος k ισούται με 1. Έτσι, σε κάθε επανάληψη εξαιρείται μόνο 1 πρότυπο από το αρχικό σύνολο το οποίο αποτελεί το σύνολο ελέγχου, ενώ τα υπόλοιπα πρότυπα συνιστούν το σύνολο εκπαίδευσης. Ένα σημαντικό μειονέκτημα της μεθόδου αυτής είναι ο μεγάλος χρόνος που απαιτείται, καθώς η διαδικασία πρέπει να εφαρμοστεί σχεδόν τόσες φορές, όσα είναι και τα πρότυπα του αρχικού συνόλου. [16]

3.6.2 Μέτρα απόδοσης συστήματος

Όποια μέθοδος κι αν χρησιμοποιηθεί, χρειάζονται κάποια ποσοτικά μέτρα για τον προσδιορισμό της απόδοσης του ταξινομητή. Μερικά από αυτά αναλύονται παρακάτω:

- **Ευαισθησία (Sensitivity/Recall):** Η ευαισθησία μετρά το ποσοστό των προτύπων που ταξινομήθηκαν ως θετικά και είναι αληθώς θετικά (TP) προς το σύνολο όλων των δειγμάτων που ταξινομήθηκαν ως θετικά (TP + TN, όπου TN είναι τα αληθώς αρνητικά πρότυπα που λανθασμένα ταξινομήθηκαν ως θετικά).

$$\text{SENS} = \frac{TP}{TP+FN} 100\%$$

- **Ειδικότητα (Specificity):** Η Ειδικότητα είναι το αντίθετο της Ευαισθησίας, δηλαδή μετρά το ποσοστό των προτύπων που ταξινομήθηκαν ως αρνητικά και είναι αληθώς αρνητικά (TN) προς το σύνολο όλων των δειγμάτων που ταξινομήθηκαν ως αρνητικά (TN + FP, όπου FP είναι τα αληθώς θετικά πρότυπα που λανθασμένα ταξινομήθηκαν ως αρνητικά).

$$\text{SPEC} = \frac{TN}{TN+FP} 100\%$$

- **Ακρίβεια (Accuracy):** Η ακρίβεια αποτελεί το πιο απλό μέτρο για την έκφραση της απόδοσης. Αποτελεί το συνολικό ποσοστό των ορθών ταξινομήσεων του ταξινομητή προς το συνολικό αριθμό προτύπων που ταξινομήθηκαν.

$$ACC = \frac{TP+TN}{TP+TN+FP+FN} 100\%$$

- **Precision:** Μετρά το ποσοστό των προτύπων που ταξινομήθηκαν ως θετικά και είναι αληθώς θετικά (TP) προς το σύνολο όλων των δειγμάτων που είναι θετικά (TP + FP).

$$Precision = \frac{TP}{TP+FP} 100\%$$

Δηλαδή, ισχύει: Precision = 1-Specificity.

Μέσω της Ευαισθησίας και της Ειδικότητας μπορεί να εξεταστεί αν το σύστημα τείνει να ταξινομήσει πρότυπα σε μία κλάση περισσότερο από κάποια άλλη. Τα παραπάνω μέτρα μπορούν να εκφραστούν μέσω του Πίνακα Σύγχυσης (Confusion Matrix), που παρουσιάζεται στον **Πίνακα 3.3:**

Πίνακας 3.3: Πίνακα Σύγχυσης (Confusion Matrix) [54]

		Πρόβλεψη Ταξινομητή	
		Θετικό (ανοιχτά βλέφαρα/συγκέντρωση)	Αρνητικό (κλειστά βλέφαρα/χαλάρωση)
Κλάση	Θετικό	TP	FN
	Αρνητικό	FP	TN

- **F1 score:** Το F1 score προκύπτει από τα μεγέθη Precision και Recall, σύμφωνα με την παρακάτω εξίσωση: $F1 = \frac{2 \cdot precision \cdot recall}{precision+recall}$

Η μέγιστη δυνατή τιμή του F1 score είναι 1 και σε αυτή την περίπτωση οι Precision και Recall θα είναι βέλτιστες, δηλαδή ίσες με 100%. Αντίστοιχα, η ελάχιστη τιμή του F1 score είναι 0. Αυτό θα συμβεί σε περίπτωση που τουλάχιστον ένα από τα δύο μεγέθη είναι ίσο με 0.

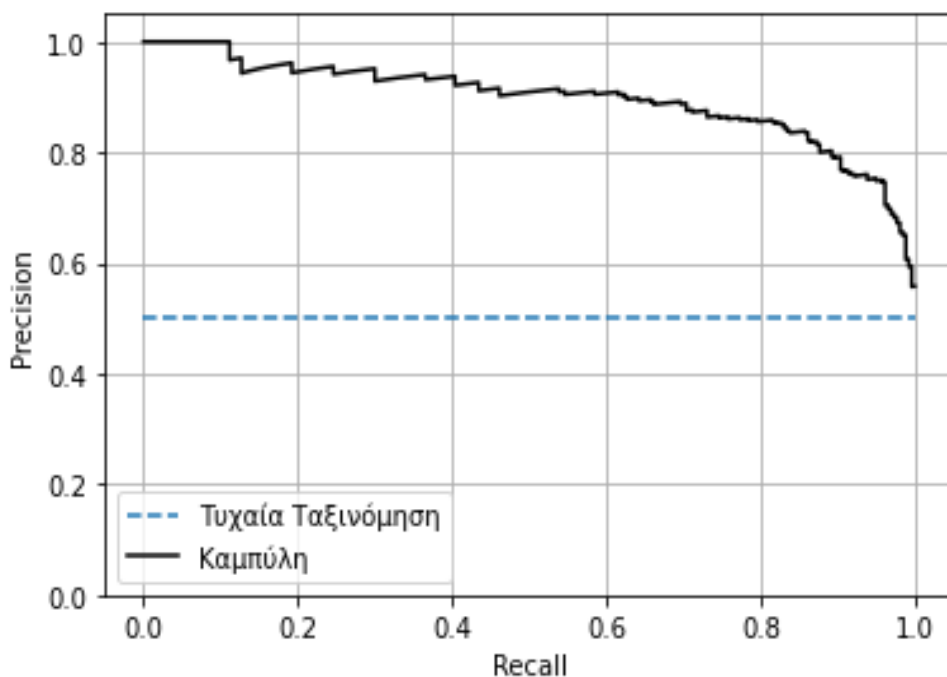
- **Καμπύλη Precision-Recall:** Η καμπύλη Precision-Recall είναι η γραφική παράσταση στην οποία η Ευαισθησία (Sensitivity/Recall) αναπαριστάται στον άξονα x και η Precision στον άξονα y. Η καμπύλη αυτή αποτελεί έναν τρόπο οπτικοποίησης της απόδοσης των ταξινομητών και άρα ολόκληρου του συστήματος.

Οι ταξινομητές, στη δυαδική ταξινόμηση, δίνουν την πιθανότητα σύμφωνα με την οποία ένα άγνωστο πρότυπο ανήκει στη μία κλάση. Εάν η πιθανότητα αυτή είναι μεγαλύτερη από μία τιμή κατωφλίου τότε το πρότυπο θα ταξινομηθεί στη μία κλάση, ειδάλλως θα ταξινομηθεί στην άλλη. Έτσι, για συγκεκριμένη τιμή κατωφλίου γίνεται η ταξινόμηση των άγνωστων προτύπων και προκύπτει μία τιμή Precision και μία τιμή Recall. Το ζεύγος αυτών των δύο τιμών μπορεί να αναπαρασταθεί ως ένα σημείο στο επίπεδο που ορίζουν τα δύο αυτά μεγέθη. Εάν αλλάξει η τιμή κατωφλίου, τότε θα δημιουργηθεί ένα νέο ζεύγος και αν η διαδικασία αυτή επαναληφθεί για διάφορες τιμές κατωφλίου, τότε μπορεί να σχηματιστεί η καμπύλη Precision-Recall, η οποία θα αναπαριστά τη μεταβολή σε αυτά τα μεγέθη, ανάλογα με τις τιμές κατωφλίου. (**Εικόνα 2.15**) [55]

Η βέλτιστη απόδοση ενός ταξινομητή θα αναπαρασταθεί μέσω του σημείου (1,1), διότι τότε και τα δύο μεγέθη θα είναι μέγιστα. Αντίστοιχα, το σημείο (0,0) αντιστοιχεί στη χειρότερη απόδοση.

Ένας ταξινομητής που δεν επιδεικνύει ικανότητα ταξινόμησης και ταξινομεί τα πρότυπα τυχαία, αναπαριστάται με μία οριζόντια γραμμή με Precision ίσο με τον αριθμό των θετικών δειγμάτων προς τον συνολικό αριθμό όλων των δειγμάτων. Σε περίπτωση που τα δεδομένα περιέχουν ίσο αριθμό θετικών και αρνητικών δειγμάτων, η οριζόντια γραμμή θα δίνεται από την εξίσωση: $y=0.5$, όπως φαίνεται στην **Εικόνα 2.15**.

Οποιαδήποτε καμπύλη βρίσκεται κάτω από αυτή τη γραμμή, αντιστοιχεί σε ταξινομητή με απόδοση χειρότερη της τυχαίας. [56]



Εικόνα 2.15: Παράδειγμα Καμπύλης Precision-Recall

Ανάλογα με τα αποτελέσματα της διαδικασίας αξιολόγησης, δύναται να αναθεωρηθούν και να τροποποιηθούν τμήματα ολόκληρου του συστήματος, με σκοπό να βελτιστοποιηθεί η απόδοσή του. [16]

III. Ανάπτυξη Συστήματος Αναγνώρισης Προτύπων

Παραπάνω αναλύθηκαν εκτενώς το θεωρητικό υπόβαθρο πίσω από τη φύση των εγκεφαλικών σημάτων, την καταγραφή τους και τη δομή των Συστημάτων Αναγνώρισης Προτύπων. Το παρόν μέρος της εργασίας σκοπεύει στην περιγραφή των σημάτων που χρησιμοποιήθηκαν και της διαδικασίας που ακολουθήθηκε ώστε να δημιουργηθεί ένα σύστημα, το οποίο θα δέχεται ως είσοδο εγκεφαλογραφικά σήματα και θα τα ταξινομεί ανάλογα με τον βαθμό ύπαρξης του ρυθμού α , άρα και κατ'επέκταση ανάλογα με την ύπαρξη συγκέντρωσης ή χαλάρωσης στο υποκειμένο κατά τη διάρκεια της καταγραφής. Έτσι θα δημιουργηθούν δύο κλάσεις σημάτων, η κλάση συγκέντρωσης και η κλάση χαλάρωσης.


4. Περιγραφή Σημάτων

Τα εγκεφαλογραφικά σήματα που χρησιμοποιήθηκαν για την παρούσα εργασία προέρχονται από μία ανοιχτή βάση δεδομένων, η οποία σχηματίστηκε στα πλαίσια ενός πιλοτικού πειράματος στο GIPSA-lab στην Γαλλία [57]. Πρόκειται για ηλεκτροεγκεφαλογραφικά σήματα τα οποία προέρχονται μία ομάδα 20 εθελοντών (7 γυναίκες, 13 άντρες) ηλικίας από 18 ετών μέχρι 44 ετών, με μέση ηλικία 25,8. Τα σήματα αυτά συλλέχθηκαν από τους εθελοντές σε κατάσταση ηρεμίας σε δύο περιπτώσεις, όταν αυτοί είχαν ανοιχτά και κλειστά βλέφαρα. Και στις δύο περιπτώσεις η καταγραφή διήρκεσε 10 δευτερόλεπτα. Όπως αναφέρεται και παραπάνω, ο επικρατέστερος ρυθμός σε καταστάσεις χαλάρωσης με κλειστά βλέφαρα είναι ο ρυθμός α , ενώ το άνοιγμα των βλεφάρων ή η ενεργός σκέψη μπορούν να μειώσουν απότομα την εμφάνιση του. Έτσι, τα σήματα αυτά, παρουσιάζουν διαφοροποιήσεις όσον αφορά τον ρυθμό α και έτσι μπορούν να χρησιμοποιηθούν για την αναγνώριση χαλάρωσης/συγκέντρωσης του υποκειμένου.

Η καταγραφή των σημάτων πραγματοποιήθηκε μέσω ενός δεκαεξακάναλου εγκεφαλογράφου με συχνότητα δειγματοληψίας 512Hz (EasyCap, Herrschingam Ammersee, Germany) και ενός ενισχυτή (g.USBamp, g.tec, Schiedlberg, Austria).

Τα ηλεκτρόδια που χρησιμοποιήθηκαν αντιστοιχίζονται στις παρακάτω θέσεις του συστήματος 10-10: FP1, FP2, FC5, FC6, FZ, T7, CZ, T8, P7, P3, PZ, P4, P8, O1, Oz και O2 (Εικόνα 3.1). Ως ηλεκτρόδιο αναφοράς χρησιμοποιήθηκε το ηλεκτρόδιο που τοποθετήθηκε στον δεξιό λοβό του υποκειμένου και ως ηλεκτρόδιο γείωσης χρησιμοποιήθηκε το ηλεκτρόδιο AFz. [58]

Στα πλαίσια της εργασίας χρησιμοποιήθηκαν τα σήματα που ανακτήθηκαν μέσω του ηλεκτροδίου P3. Το ηλεκτρόδιο αυτό επιλέχθηκε διότι είναι ένα από τα ηλεκτρόδια που παράγουν σήματα που μπορούν να κατηγοριοποιηθούν επιτυχώς ανάλογα με τον βαθμό εμφάνισης του ρυθμού α .




Εικόνα 3.1: Με πράσινο χρώμα απεικονίζονται τα ηλεκτρόδια που χρησιμοποιήθηκαν για τη καταγραφή. Το AFz ηλεκτρόδιο(κίτρινο) χρησιμοποιήθηκε ως ηλεκτρόδιο αναφοράς και το A2(μπλε) ως γείωση [57].

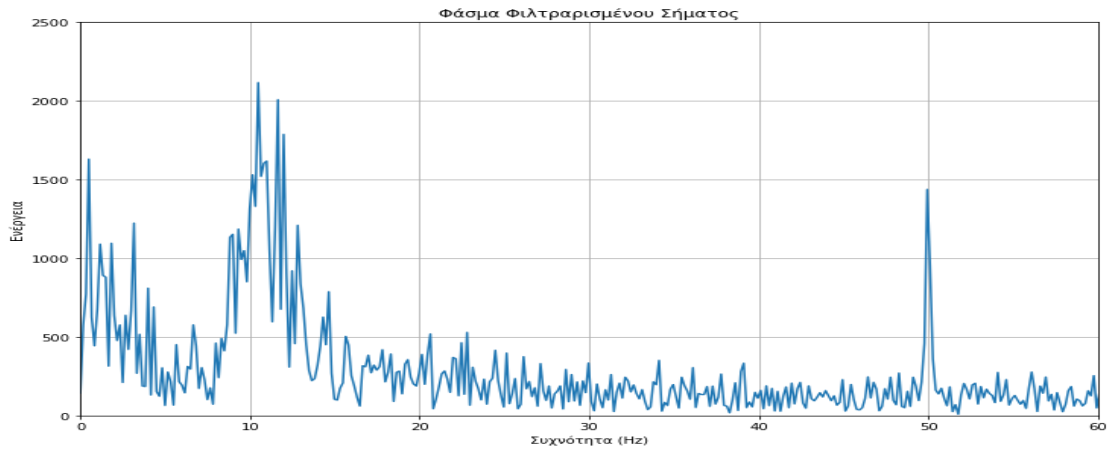
5. Ανάπτυξη Συστήματος Αναγνώρισης Προτύπων

Η επεξεργασία και η ανάλυση των σημάτων για τη δημιουργία του Συστήματος Αναγνώρισης Προτύπων έγινε σε γλώσσα Python.

5.1 Προεπεξεργασία Σημάτων

Όπως αναλύθηκε και παραπάνω, τα εγκεφαλογραφικά σήματα πρέπει να φιλτραριστούν ώστε να αναδειχθεί η χρήσιμη πληροφορία. Έτσι, σε κάθε δείγμα εφαρμόστηκε αρχικά ένα υπερπλάτος φίλτρο με συχνότητα αποκοπής 0,5Hz, με σκοπό την απαλοιφή πολύ χαμηλών συχνοτήτων που σχετίζονται με την αναπνοή των υποκειμένων.

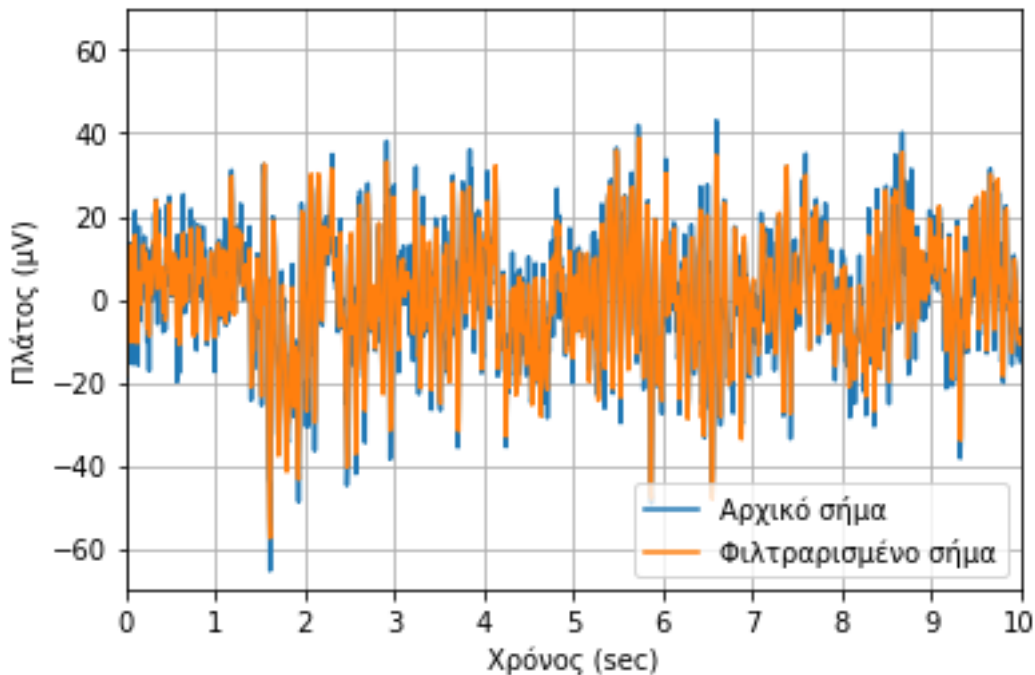




Εικόνα 3.3: Παράδειγμα φάσματος συχνοτήτων αρχικού (πάνω) και φιλτραρισμένου σήματος (κάτω)

Έπειτα, χρησιμοποιήθηκε ένα βαθυπερατό φίλτρο με συχνότητα αποκοπής 40Hz, ώστε να απορριφθούν οι συχνότητες που δεν σχετίζονται με την εγκεφαλική λειτουργία και απλώς αποτελούν θόρυβο για το σύστημα. Έτσι, το φάσμα του κάθε σήματος αλλάζει όπως φαίνεται στην **Εικόνα 3.3**.

Η αλλαγή της μορφή του σήματος μετά την εφαρμογή φίλτρων φαίνεται στην **Εικόνα 3.4**.



Εικόνα 3.4: Παράδειγμα ΗΕΓ σήματος πριν και μετά το φιλτράρισμα.

Με σκοπό τη μείωση του υπολογιστικού κόστους, πραγματοποιήθηκε υποδειγματοληψία (downsampling) στα σήματα σε συχνότητα 128Hz.

Για την απόρριψη των ψευδενδείξεων κίνησης, εφαρμόστηκαν δύο κατώφλια με τιμές 40 και -40 στα σήματα. Έτσι, όποιο σημείο του σήματος έχει πλάτος πάνω από 40, αποκτά τιμή

πλάτους 40 και αντίστοιχα όσες τιμές πλάτους χαμηλότερες από -40, αντικαθιστώνται με την τιμή -40.

5.2 Εξαγωγή Χαρακτηριστικών

Για την εξαγωγή χαρακτηριστικών χρησιμοποιήθηκαν και χρονικές και φασματικές μέθοδοι. Συγκεκριμένα, τα χρονικά χαρακτηριστικά που εξάχθηκαν παρατίθενται στον **Πίνακα 5.1** μαζί με τις συναρτήσεις της Python που χρησιμοποιήθηκαν:

Πίνακας 5.1: Χρονικά χαρακτηριστικά και οι αντίστοιχες συναρτήσεις που χρησιμοποιήθηκαν για την εξαγωγή τους.

Χαρακτηριστικά	Συναρτήσεις
1) Μέση τιμή	numpy.mean()
2) Ενδιάμεση τιμή	numpy.median()
3) Τυπική Απόκλιση	statistics.stdev()
4) Διακύμανση	statistics.variance()
5) Λοξότητα	scipy.stats.skew()
6) Κυρτότητα	scipy.stats.kurtosis()
7) Hjorth κινητικότητα	pyeeg.hjorth()
8) Hjorth πολυπλοκότητα	pyeeg.hjorth()

Στη συνέχεια, εξάχθηκαν τα φασματικά χαρακτηριστικά που φαίνονται στον **Πίνακα 5.2** με τις αντίστοιχες συναρτήσεις :

Πίνακας 5.2: Χρονικά χαρακτηριστικά και οι αντίστοιχες συναρτήσεις που χρησιμοποιήθηκαν για την εξαγωγή τους.

Χαρακτηριστικά	Συναρτήσεις
1) Ισχύς του ρυθμού δέλτα	pyeeg.bin_power()
2) Ισχύς του ρυθμού θήτα	pyeeg.bin_power()
3) Ισχύς του ρυθμού άλφα	pyeeg.bin_power()
4) Ισχύς του ρυθμού βήτα	pyeeg.bin_power()
5) Λόγος των Ισχύων των ρυθμών άλφα και βήτα	Power _a / Power _b
6) Λόγος των Ισχύων των ρυθμών θήτα και βήτα	Power _θ / Power _β

7) Φασματική Εντροπία	antropy.spectral_entropy()
8) Φασματική Εντροπία του ρυθμού θήτα	antropy.spectral_entropy()
9) Φασματική Εντροπία του ρυθμού άλφα	antropy.spectral_entropy()
10) Φασματική Εντροπία του ρυθμού βήτα	antropy.spectral_entropy()
11),12) Μέγιστη και μέση τιμή της Πυκνότητας Φασματικής Ισχύος μέσω της μεθόδου Welch	scipy.signal.welch(),
13),14) Μέγιστη και μέση τιμή της Πυκνότητας Φασματικής Ισχύος του ρυθμού άλφα μέσω της μεθόδου Welch	scipy.signal.welch()
15),16) Μέγιστη και μέση τιμή της Πυκνότητας Φασματικής Ισχύος του ρυθμού βήτα μέσω της μεθόδου Welch	scipy.signal.welch()

Επομένως, προέκυψαν συνολικά 24 χαρακτηριστικά και έτσι σχηματίστηκε ο πίνακας διανυσμάτων με διαστάσεις 261x24.

6.3 Επιλογή χαρακτηριστικών

Δεδομένου πως ο αριθμός των δειγμάτων και των χαρακτηριστικών δεν είναι ιδιαίτερα μεγάλος και το υπολογιστικό φόρτο του συστήματος είναι μικρό, δεν κρίθηκε σκόπιμο να εφαρμοσθεί κάποια μέθοδος Μείωσης Χαρακτηριστικών. Έτσι, πραγματοποιήθηκε κατευθείαν η Επιλογή Χαρακτηριστικών.

Εφαρμόστηκε η μέθοδος Recursive Feature Elimination (RFE), κάνοντας χρήση των ταξινομητή Random Forest με 100 δένδρα απόφασης. Ορίστηκε να επιλεγθούν 11 χαρακτηριστικά εκ των 24 ως τα καλύτερα. Η επιλογή αυτού του αριθμού προέκυψε μετά από εξέταση της απόδοσης του συστήματος για διαφορετικούς αριθμούς επιλεγμένων χαρακτηριστικών.

Τα 11 καλύτερα χαρακτηριστικά παρατίθενται στον **Πίνακα 5.3**.

Πίνακας 5.3: Χαρακτηριστικά που προέκυψαν μετά τη διαδικασία Επιλογής Χαρακτηριστικών.

1) Ασυμμετρία	2) Ισχύς του ρυθμού δέλτα
3) Ισχύς του ρυθμού άλφα	4) Ισχύς του ρυθμού βήτα
5) Λόγος των Ισχύων των ρυθμών άλφα και βήτα	6) Λόγος των Ισχύων των ρυθμών θήτα και βήτα
7) Φασματική Εντροπία του ρυθμού άλφα	8) Μέση τιμή της Πυκνότητας Φασματικής Ισχύος μέσω της μεθόδου Welch
9) Μέση τιμή της Πυκνότητας Φασματικής Ισχύος του ρυθμού άλφα μέσω της μεθόδου Welch	10) Μέση τιμή της Πυκνότητας Φασματικής Ισχύος του ρυθμού βήτα μέσω της μεθόδου Welch

11) Hjorth πολυπλοκότητα	
--------------------------	--

6.4 Ταξινόμηση

Τα 2/3 των 24 σημάτων σχημάτισαν το σύνολο εκπαίδευσης των ταξινομητών και το 1/3 αποτέλεσε το σύνολο εξέτασης .

Για την ταξινόμηση των σημάτων χρησιμοποιήθηκαν οι παρακάτω ταξινομητές:

1. k Πλησιέστερων Γειτόνων (k-NN,k=9)
2. Μπαϊσιανός Ταξινομητής (Gaussian Naïve Bayes)
3. Support Vector Machine (SVM)
4. Δένδρα Απόφασης (Decision Trees)
5. Random Forest (RF)

Η διαδικασία της ταξινόμησης πραγματοποιήθηκε 1.000 φορές και σε κάθε επανάληψη γίνονταν τυχαία επιλογή των σημάτων που θα αποτελέσουν το σύνολο εκπαίδευσης και το σύνολο εξέτασης.

6.5 Αποτελέσματα Ταξινόμησης

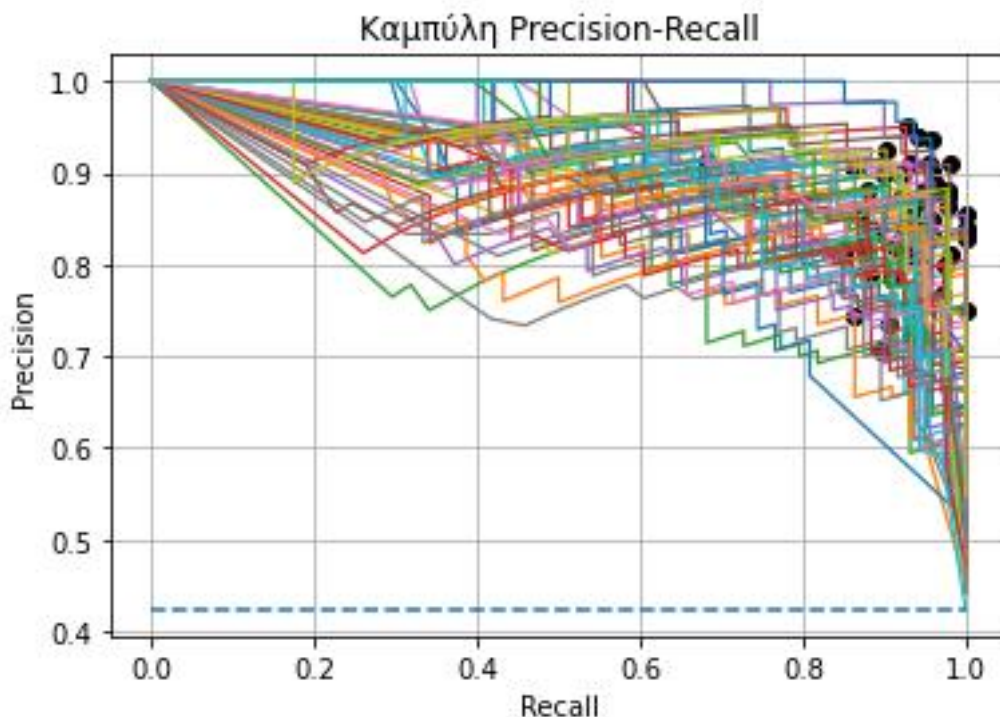
Από τις 1.000 επαναλήψεις υπολογίστηκε η μέση τιμή και η τυπική απόκλιση της ακρίβειας, της ευαισθησίας και της ειδικότητας κάθε ταξινομητή, όπως παρουσιάζονται στον **Πίνακα 5.4**.

Πίνακας 5.4: Απόδοση ταξινομητών για 1.000 επαναλήψεις.

Ταξινομητής	Ακρίβεια (%)	Ευαισθησία (%)	Ειδικότητα (%)
k Πλησιέστερων Γειτόνων	77,01 ± 9,03	80,82 ± 11,17	75,08 ± 10,24
Μπαϊσιανός Ταξινομητής	83,60 ± 9,74	86,31 ± 10,58	82,93 ± 10,55
Support Vector Machine	79,12 ± 9,54	81,56 ± 10,95	78,31 ± 8,49
Decision Trees	80,59 ± 8,81	81,58 ± 9,65	80,65 ± 10,71
Random Forest	78,77 ± 10,31	82,65 ± 9,42	75,69 ± 9,34

Όπως είναι προφανές, ο βέλτιστος ταξινομητής είναι ο Μπαϊσιανός διότι έχει την υψηλότερη ακρίβεια και ταυτόχρονα έχει μικρή απόκλιση μεταξύ Ευαισθησίας και Ειδικότητας.

Για επιπλέον αξιολόγηση των αποτελεσμάτων δημιουργήθηκε και η καμπύλη Precision-Recall για Μπαϊσιανό ταξινομητή. Η καμπύλη σχηματίστηκε 70 φορές για τον συγκεκριμένο ταξινομητή και τα αποτελέσματα των επαναλήψεων παρουσιάζονται όλα μαζί στην **Εικόνα 3.5**. Όπως φαίνεται στην εικόνα όλες οι καμπύλες βρίσκονται πιο πάνω από την διακεκομμένη γραμμή, που αντιστοιχεί στην τυχαία ταξινόμηση. Το γεγονός αυτό αποτελεί άλλη μία ένδειξη της επιτυχούς ταξινόμησης των δειγμάτων.



Εικόνα 3.5: 70 Καμπύλες Precision-Recall για τον Μπαϊσιανό ταξινομητή. Οι μαύρες κουκίδες αντιστοιχούν στο ζευγάρι Precision-Recall, για το οποίο το F1-score γίνεται μέγιστο και η διακεκομμένη γραμμή δείχνει την απόδοση ενός ταξινομητή που κατηγοριοποιεί τα δεδομένα τυχαία.

7. Αποτελέσματα και Εφαρμογές

7.1 Αξιολόγηση αποτελεσμάτων και βελτιώσεις

Με την υλοποίηση των παραπάνω βημάτων ολοκληρώνεται η δημιουργία ενός συστήματος αναγνώρισης συγκέντρωσης με χρήση ηλεκτροεγκεφαλογραφικών σημάτων. Η μέγιστη μέση ακρίβεια 83,6% είναι ένα αρκετά υψηλό ποσοστό, το οποίο υποδεικνύει τις μεγάλες προοπτικές της χρήσης αυτού του αλγορίθμου για την επιτυχή αναγνώριση συγκέντρωσης υποκειμένων. Η σταθερή απόκλιση μεταξύ της Ευαισθησίας και της Ειδικότητας δηλώνει πως το σύστημα μπορεί να αναγνωρίσει με μεγαλύτερη ευκολία τα σήματα που προέρχονται από υποκείμενα σε κατάσταση συγκέντρωσης (ανοιχτά βλέφαρα), γεγονός που έχει παρατηρηθεί και σε άλλες παρόμοιες μελέτες [7].

Η απόδοση του συστήματος θα μπορούσε να βελτιωθεί εάν χρησιμοποιούταν μεγαλύτερος όγκος δεδομένων, δηλαδή εάν συλλέγονταν σήματα από περισσότερους εθελοντές.

7.2 Εφαρμογές

Μέσω λοιπόν του συστήματος που δημιουργήθηκε στα πλαίσια της παρούσας διπλωματικής εργασίας, γίνεται εφικτή η συσχέτιση της καταγεγραμμένης εγκεφαλικής δραστηριότητας με νοητικές λειτουργίες ή καταστάσεις. Η συσχέτιση αυτή αποτελεί τη θεμελιώδη ιδέα βάση της

οποίας σχηματίζονται οι διεπαφές μεταξύ εγκεφάλου και υπολογιστή (Brain-Computer Interface /BCI). Τα συστήματα διεπαφής εγκεφάλου-υπολογιστή αποτελούν ένα μέσο επικοινωνίας και αλληλεπίδρασης μεταξύ του ανθρώπου και μίας συσκευής. Η ιδιαιτερότητα τους όμως έγκειται στο γεγονός πως για η επικοινωνία αυτή βασίζεται στην εγκεφαλική δραστηριότητα του ανθρώπου και όχι στους μυς ή στα νεύρα του υπόλοιπου σώματός του [59]. Συνεπώς, τα συστήματα αυτά αποτελούν ένα καινοτόμο εργαλείο για τα άτομα που αντιμετωπίζουν κινητικές δυσκολίες.

Έτσι λοιπόν ο ρόλος αυτών των συστημάτων είναι η συλλογή ηλεκτροεγκεφαλογραφικών σημάτων από το υποκείμενο, η κατάλληλη επεξεργασία και ανάλυσή τους με σκοπό την παραγωγή μίας εξόδου, η οποία θα ελέγχει μία εξωτερική συσκευή. Οι συσκευές που μπορούν να ελεγχθούν από ένα σύστημα διεπαφής εγκεφάλου-υπολογιστή είναι πάρα πολλές. Αρκετά συχνά αναπτύσσονται τέτοιου είδους συστήματα τα οποία προσφέρουν τη δυνατότητα στους χρήστες να ελέγξουν τον κέρσορα στην οθόνη του υπολογιστή [60], κάποιο προσθετικό μέλος [61] ή και ακόμα ένα αναπηρικό αμαξίδιο [62].

Η διαφορά των συστημάτων αυτών από το σύστημα που αναπτύχθηκε στα πλαίσια της εν λόγω εργασίας, είναι πως στις διεπαφές εγκεφάλου-υπολογιστή είναι απαραίτητο τα εγκεφαλικά σήματα να είναι πραγματικού χρόνου. Δηλαδή χρειάζεται να γίνεται η ανάλυση των σημάτων ταυτόχρονα με τη διαδικασία καταγραφής, και όχι σε ύστερο χρόνο. Μόνο έτσι ο χρήστης θα μπορεί να ελέγχει τη συσκευή που επιθυμεί τη στιγμή που επιθυμεί. [63]

ΠΑΡΑΡΤΗΜΑ Α

Κώδικας

Παρατίθενται οι κώδικες που αναπτύχθηκαν σε λογισμικό Python για την προεπεξεργασία των σημάτων, την εξαγωγή χαρακτηριστικών και την ταξινόμηση.

Κώδικας 1: Προεπεξεργασία σημάτων

```
import warnings
warnings.filterwarnings("ignore")

# define the dataset instance (dataset from [57], [64])
dataset = AlphaWaves()

Closed = np.empty((0)); Open = np.empty((0));
for i in range(len(dataset.subject_list)):
    # get the data from subject of interest
    subject = dataset.subject_list[i]
    raw = dataset._get_single_subject_data(subject)

    # filter data and resample
    fmin = 0.5
    fmax = 40
    raw.filter(fmin, fmax, verbose=False)
    raw.resample(sfreq=128, verbose=False)

    # detect the events and cut the signal into epochs
    events = mne.find_events(raw=raw, shortest_event=1,
verbose=False)
    event_id = {'closed': 1, 'open': 2}
    epochs = mne.Epochs(raw, events, event_id, tmin=0.0, tmax=10.0,
baseline=None,
                        verbose=False, preload=True)
    epochs.pick_types(eeg=True)
    epochs.load_data().pick_channels(['P3'])

    # get trials and labels
    X = epochs.get_data()
    y = events[:, -1]

    X_closed = X[y==1]
    X_open = X[y==2]

    X_closed = X_closed[0,0,0:-1]
    X_open = X_open[0,0,0:-1]

    for i in range(len(X_closed)): #drop artifacts
        if X_closed[i] > 40 :
            X_closed[i] = 40
        elif X_closed[i] < -40:
            X_closed[i] = -40
```



```

elif X_open[i]> 40 :
    X_open[i]=40
elif X_open[i] < -40:
    X_open[i]=-40

Closed = np.append(Closed,X_closed,axis=0)
Open = np.append(Open,X_open,axis=0)
Closed = np.reshape(Closed, (len(X_closed),
len(dataset.subject_list)), 'F')
Open = np.reshape(Open, (len(X_open), len(dataset.subject_list)), 'F')

Closed = pd.DataFrame(Closed)
Open = pd.DataFrame(Open)
Closed.to_excel('signals_open.xlsx')
Open.to_excel('signals_closed.xlsx')

```

Κώδικας 2: Εξαγωγή χαρακτηριστικών

```

import pandas as pd
import numpy as np
import statistics as st
import scipy.stats as scst
import pyeeg
import antropy as ant
import scipy
import matplotlib.pyplot as plt
from scipy import signal

def features_extraction (filename_to_read , filename_to_write, fs):
    file = pd.ExcelFile(filename_to_read)
    worksheets = file.sheet_names
    print(worksheets)

    sheets = {}
    writer = pd.ExcelWriter(filename_to_write)

    binning=[0.5, 4, 7, 12, 30 ,55]

    for sheet in worksheets:
        sheets[sheet] = pd.read_excel(filename_to_read,
sheet_name=sheet)

        data = sheets[sheet]
        data = np.array(data)

        features = pd.DataFrame(index=range(0,np.size(data,1)) ,
columns=['MEAN', 'MEDIAN', 'STD', 'VAR', 'SKW',
'KURT', 'Delta Power', 'Theta
Power', 'Alpha Power',
'Beta
Power', 'Theta/Beta', 'Alpha/Beta',
'Spectral Entropy', 'Spectral

```

```

Entropy_Theta', 'Spectral Entropy_Alpha',
                                'Spectral Entropy_Beta', 'Welch MAX-
Alpha', 'Welch MEAN-Alpha',
                                'Welch MAX-Beta', 'Welch MEAN-
Beta', 'Welch MAX-All', 'Welch MEAN-All',
                                'Hjorth mobility', 'Hjorth
complexity'])

    for i in range (np.size(data,1)):
        features['MEAN'][i] = np.mean(data[:,i])
        features['MEDIAN'][i] = np.median(data[:,i])
        features['STD'][i] = st.stdev(data[:,i])
        features['VAR'][i] = st.variance(data[:,i])
        features['SKW'][i] = scst.skew(data[:,i])
        features['KURT'][i] = scst.kurtosis(data[:,i])
        power, power_ratio = pyeeg.bin_power(data[:,i], binning,
fs)

        features['Delta Power'][i] = power[0]
        features['Theta Power'][i] = power[1]
        features['Alpha Power'][i] = power[2]
        features['Beta Power'][i] = power[3]
        features['Theta/Beta'][i] = power[1] / power[3]
        features['Alpha/Beta'][i] = power[2] / power[3]
        features['Spectral Entropy'][i] =
ant.spectral_entropy(data[:,i], sf=512, method='fft', normalize=True)
        features['Hjorth mobility'][i] =
pyeeg.hjorth(data[:,i])[0]
        features['Hjorth complexity'][i] =
pyeeg.hjorth(data[:,i])[1]

        f, Pxx_den = scipy.signal.welch(data[:,i], fs=fs,
window='hann', nperseg=None, noverlap=None, nfft=None)
        arg = np.argmax(Pxx_den)
        features['Welch MAX-All'][i] = f[arg]
        features['Welch MEAN-All'][i] = np.mean(Pxx_den)

        #-----Features for each rhythm-----
        #--rhythm  $\theta$  (4-7Hz)--
        b, a = signal.butter(N=5, Wn=[4,7],
btype='bandpass', fs=fs ,output='ba')
        y_th = signal.lfilter(b, a, data[:,i])
        features['Spectral Entropy_Theta'][i] =
ant.spectral_entropy(y_th, sf=fs, method='fft', normalize=True)

        #--rhythm  $\alpha$  (8-13Hz)--
        b, a = signal.butter(N=6, Wn=[8,13],
btype='bandpass', fs=fs ,output='ba')
        y_a = signal.lfilter(b, a, data[:,i])
        features['Spectral Entropy_Alpha'][i] =
ant.spectral_entropy(y_a, sf=fs, method='fft', normalize=True)

        f, Pxx_den = scipy.signal.welch(y_a, fs=fs,
window='hann', nperseg=None, noverlap=None, nfft=None)
        arg = np.argmax(Pxx_den)

```

```

        features['Welch MAX-Alpha'][i] = f[arg]
        features['Welch MEAN-Alpha'][i] = np.mean(Pxx_den)

        #--rhythm b (14-30Hz)--
        b, a = signal.butter(N=8, Wn=[14,30],
btype='bandpass',fs=fs ,output='ba')
        y_b = signal.lfilter(b, a, data[:,i])
        features['Spectral Entropy Beta'][i] =
ant.spectral_entropy(y_b, sf=fs, method='fft', normalize=True)

        f, Pxx_den = scipy.signal.welch(y_b, fs=fs,
window='hann', nperseg=None, noverlap=None, nfft=None)
        arg = np.argmax(Pxx_den)
        features['Welch MAX-Beta'][i] = f[arg]
        features['Welch MEAN-Beta'][i] = np.mean(Pxx_den)

    features.to_excel(writer, sheet_name = sheet, index = False)
    writer.save()

fs = 128
filename_to_read = 'signals_open.xlsx'
filename_to_write = 'features_open.xlsx'

features_extraction(filename_to_read, filename_to_write, fs)

filename_to_read = 'signals_closed.xlsx'
filename_to_write = 'features_closed.xlsx'

features_extraction(filename_to_read, filename_to_write, fs)

```

Κώδικας 3: Επιλογή χαρακτηριστικών και ταξινόμηση

```

import pandas as pd
import numpy as np
import random
import moduleUtils as Ut
from sklearn.metrics import accuracy_score
from sklearn.metrics import f1_score
from sklearn.metrics import roc_auc_score
from sklearn.metrics import confusion_matrix

def to_labels(pos_probs, threshold):
    return (pos_probs >= threshold).astype('int')
#-----
#-----LOAD DATA-----
data_open =
pd.read_excel(r'C:\Users\Dimitris\anaconda3\DIPLOMATIKH\open_signals
_features.xlsx')
data_close =
pd.read_excel(r'C:\Users\Dimitris\anaconda3\DIPLOMATIKH\closed_signa
ls_features.xlsx')

```

```

features_names = np.array(data_open.columns.values)

data_open.insert(loc=0, column='Class', value=1)
data_close.insert(loc=0, column='Class', value=0)

data = pd.concat((data_open, data_close), ignore_index=True, axis=0)

#-----
accuracy = []; sensitivity = []; specificity = [];

N = 1000
for n in range(N):
    print('\n=====REPETITION %d====='\n)
    data = data.sample(frac=1).reset_index(drop=True)

    train_set = data.iloc[0:25,:]
    test_set = data.iloc[25:38,:]

    X_train = np.array( train_set.loc[:,train_set.columns !=
'Class'] )
    # from sklearn.preprocessing import StandardScaler
    # X_train = StandardScaler().fit_transform(X_train)
    y_train = np.array( train_set['Class'] )
    X_test = np.array( test_set.loc[:,test_set.columns !=
'Class'] )
    # X_test = StandardScaler().fit_transform(X_test)
    y_test = np.array( test_set['Class'] )

    #-----RFE-----

    from sklearn.feature_selection import RFE
    from sklearn.ensemble import RandomForestClassifier
    rfe=
RFE(RandomForestClassifier(n_estimators=100,random_state=1,n_jobs=-
1),n_features_to_select=11)
    rfe=rfe.fit(X_train,y_train)
    X = rfe.transform(X_train)

    selected=pd.DataFrame({'Features
indecas':np.arange(np.size(X_train,1)), 'Ranking':rfe.ranking_})
    ranked=selected.sort_values(by='Ranking')
    ranking = np.array(ranked['Ranking'])
    best_features = selected.nsmallest(sum(ranking ==
1), 'Ranking')

    idx = np.array(best_features['Features indecas'])
    best_features_names = features_names[idx]
    print('%d best Features after RFE: '%len(best_features))
    print(best_features_names)

#-----CLASSIFICATION-----
classifiers=['KNN', 'Naive Bayes', 'MLP',
'SVM', 'Decision Trees', 'Random Forest']
nClassifiers=len(classifiers)

Acc = []; Sens = []; Spec=[];

```

```

y_test_roc=[]; y_score_roc=[]; y_prob_roc=[]

for j in range (nClassifiers):

    if j == 0: #----KNN-----
        from sklearn.neighbors import KNeighborsClassifier
        clf = KNeighborsClassifier(n_neighbors=9)

    if j == 1: #---Naive Bayes---
        from sklearn.naive_bayes import GaussianNB
        clf = GaussianNB()

    if j == 2: #----MLP----
        from sklearn.neural_network import MLPClassifier
        clf = MLPClassifier(activation = 'relu', alpha=1e-
5,max_iter=300)

    if j == 3: #---SVM---
        from sklearn.svm import SVC
        clf = SVC(kernel='rbf',probability=True)

    if j == 4: #---DECISION TREES---
        from sklearn.tree import DecisionTreeClassifier
        clf = DecisionTreeClassifier()

    if j == 5: #----RANDOM FOREST----
        clf = RandomForestClassifier(n_estimators=100)

    clf.fit(X_train[:,idx],y_train)
    y_prob = clf.predict_proba(X_train[:,idx])
    y_prob = y_prob[:,1]

    thresholds = np.arange(0, 1, 0.01)
    scores = [f1_score(y_train, to_labels(y_prob, t)) for t
in thresholds]
    ix = np.argmax(scores)
    best_threshold_training = thresholds[ix]

    y_score = (clf.predict_proba(X_test[:,idx])[:,1] >=
best_threshold_training).astype(int)

    tn, fp, fn, tp = confusion_matrix(y_test,y_score).ravel()
    acc =100 * ( (tp+tn)/(tp+tn+fp+fn) )
    sens =100 * ( tp/(tp+fn) )
    spec = 100 * ( tn/(tn+fp) )
    Acc.append(acc); Sens.append(sens); Spec.append(spec)

    Acc = np.array(Acc); Sens = np.array(Sens); Spec =
np.array(Spec)
    accuracy = np.append(accuracy,Acc)
    sensitivity = np.append(sensitivity,Sens)
    specificity = np.append(specificity,Spec)

```

```

accuracy = np.reshape(accuracy, (nClassifiers, N), 'F')
sensitivity = np.reshape(sensitivity, (nClassifiers, N), 'F')
specificity = np.reshape(specificity, (nClassifiers, N), 'F')

#-----MEAN AND STD OF N REPETITIONS-----

Mean_Acc_Matrix=[]; Mean_Sens_Matrix=[]; Mean_Spec_Matrix=[]
Std_Acc_Matrix=[]; Std_Sens_Matrix=[]; Std_Spec_Matrix=[]

for i in range(nClassifiers):
    Mean_Acc=np.mean(accuracy[i,:])
    Mean_Acc_Matrix.append(Mean_Acc)
    Std_Acc=np.std(accuracy[i,:])
    Std_Acc_Matrix.append(Std_Acc)

    Mean_Sens=np.mean(sensitivity[i,:])
    Mean_Sens_Matrix.append(Mean_Sens)
    Std_Sens=np.std(sensitivity[i,:])
    Std_Sens_Matrix.append(Std_Sens)

    Mean_Spec=np.mean(specificity[i,:])
    Mean_Spec_Matrix.append(Mean_Spec)
    Std_Spec=np.std(specificity[i,:])
    Std_Spec_Matrix.append(Std_Spec)

data = {'Classifier':classifiers, 'Mean Accuracy':Mean_Acc_Matrix,
        'Std Accuracy':Std_Acc_Matrix,
        'Mean Sensitivity':Mean_Sens_Matrix, 'Std
Sensitivity':Std_Sens_Matrix,
        'Mean Specificity':Mean_Spec_Matrix, 'Std
Specificity':Std_Spec_Matrix}
results = pd.DataFrame(data=data)
print(results)

```

ΒΙΒΛΙΟΓΡΑΦΙΑ

- [1] University of California-San Diego, "Why are neuron axons long and spingly? ," *ScienceDaily*, July 2018.
- [2] Σιδηροπούλου Κυριακή, "Βασικές αρχές λειτουργίας του νευρικού συστήματος," pp. 13-15, 2015.
- [3] Ερρίκος Βεντούρας, "Τεχνολογία της in-vivo διαγνωστικής - Διατάξεις απαγωγής βιοηλεκτρικών σημάτων," pp. 11-20,99-120, 2015.
- [4] L F Haas, "Hans Berger (1873-1941), Richard Caton (1842-1926), and electroencephalography," *Journal of Neurology, Neurosurgery & Psychiatry*, vol. 74, no. 1, p. 9, 2003.
- [5] Peter Praamstra Robert Oostenveld, "The five percent electrode system for high-resolution EEG and ERP measurements," *Clinical Neurophysiology*, vol. 12, no. 4, pp. 713-719, 2001.
- [6] Alvarez Carolina, Montoya Carlos E., de la Iglesia-Vayá María, Cisternas Jaime E., Gálvez Marcelo Rojas Gonzalo M., "Study of Resting-State Functional Connectivity Networks Using EEG Electrodes Position As Seed ," *Frontiers in Neuroscience*, vol. 12, p. 235, 2018.
- [7] Cheng-Yu Chiang and Hsuan-Chin Chu Ning-Han Liu, "Recognizing the Degree of Human Attention Using EEG Signals," *Sensors (Basel, Switzerland)*, vol. 13, no. 8, pp. 10273–10286, 2013.
- [8] Fanny & Oniga, Stefan Monori, "Processing EEG signals acquired from a consumer grade BCI device," *Carpathian Journal of Electronic and Computer Engineering*, vol. 11, pp. 29-34, 2018.
- [9] Carlos & Santiago, L. & Barea, Rafael & López-Dorado, Almudena & Boquete, Luciano Amo, "Analysis of Gamma-Band Activity from Human EEG Using Empirical Mode Decomposition," *Sensors (Switzerland)*, vol. 17, no. 5, p. 989, 2017.
- [10] Zoe M. Cornwell Michael A. Kisley, "Gamma and beta neural activity evoked during a sensory gating paradigm: Effects of auditory, somatosensory and cross-modal stimulation," *Clinical Neurophysiology*, vol. 17, pp. 2549-2563, 2006.
- [11] Wikipedia contributors, "Electroencephalography," *Wikipedia, The Free Encyclopedia*.
- [12] Christopher M. Bishop, *Pattern Recognition and Machine Learning*.: Springer, 2006.
- [13] Nandini Jog, Pancham D'cunha Tandle Avinash, "Classification of Artefacts in EEG Signal Recordings and EOG Artefact Removal using EOG Subtraction," *Communications on applied Electronics*, vol. 4, pp. 16-19, 2016.

- [14] Γ. Μουστακίδης, *Βασικές Τεχνικές Ψηφιακής επεξεργασίας Σημάτων*, 2nd ed.: Εκδόσεις Τζιόλα, 2003.
- [15] Abdul-bary & Suleiman, Abdul-Bary & Fatehi, Abdul-Hameed & A. Fathi, Toka uleiman, "Features Extraction Techniques of EEG Signals for BCI Applications," *Computer Science*, 2011.
- [16] S. Theodoridis K. Koutroumbas, *Pattern Recognition, Fourth Edition.*: Academic Press, Inc., 2008, pp. 1-9,13-14,569-573.
- [17] Yu-Ri Kim, Hyoung-Nam Oh Seung-Hyeon, "A Novel EEG Feature Extraction Method Using Hjorth Parameter," *International Journal of Electronics and Electrical Engineering*, pp. 106-110, 2014.
- [18] Bo Hjorth, "EEG analysis based on time domain properties," *Electroencephalography and Clinical Neurophysiology*, vol. 29, pp. 306-310, 1970.
- [19] Wikipedia contributors, "Spectral density," *Wikipedia, The Free Encyclopedia*, 2021.
- [20] Σ. Καραμπογιάν, "Σήματα και Συστήματα," *Εκδόσεις Κάλλιπος*, pp. 82-88, 2015.
- [21] Wikipedia contributors, "Fourier transform," *Wikipedia, The Free Encyclopedia*, 2020.
- [22] Αδάμ Μ. Ασημάκης Ν., "Σήματα και Συστήματα," *Εκδόσεις Κάλλιπος*, p. 287, 2015.
- [23] Zhi & Saidatul, A. & Ibrahim, Zunaidi Ong, "Power Spectral Density Analysis for Human EEG-based Biometric Identification," *2018 International Conference on Computational Approach in Smart Systems Design and Applications (ICASSDA)*, pp. 1-6, 2018.
- [24] P. Welch, "The use of the fast Fourier transform for the estimation of power spectra: A method based on time averaging over short, modified periodograms," *IEEE Trans. Audio Electroacoust*, vol. 15, pp. 70-73, 1967.
- [25] Jr, O M Solomon, "PSD computations using Welch's method. [Power Spectral Density (PSD)]," 1991.
- [26] M. A. Naderi and H. Mahdavi-Nasab, "Analysis and classification of EEG signals using spectral analysis and recurrent neural networks," *17th Iranian Conference of Biomedical Engineering (ICBME)*, pp. 1-4, 2010.
- [27] Claude E Shannon, "A Mathematical Theory of Communication," *Bell System Technical Journal*, vol. 27, pp. 379-423, 1948.
- [28] A. LESNE, "Shannon entropy: A rigorous notion at the crossroads between probability, information theory, dynamical systems and statistical physics," *Mathematical Structures in Computer Science*, vol. 24, 2014.
- [29] K. Shinosaki, H. Sakamoto, S. Toi, S. Ukai, A. Iyama, Y. Katsuda, M. Hirano T. Inouye, "Quantification of EEG irregularity by use of the entropy of the power spectrum," *Electroencephalography and Clinical Neurophysiology*, vol. 79, no. 3, pp. 204-210, 1991.

- [30] Ricardo & Olvera-López, José & Pineda, Ivan & Sánchez-Urrieta, Susana & Martín-Ortiz, Manuel Ramos, "Parameter Experimentation for Epileptic Seizure Detection in EEG Signals using Short-Time Fourier Transform," *Research in Computing Science*, vol. 148, 2019.
- [31] L., Espinosa-Oviedo, J.J. & Castellanos-Dominguez, C.G Duque-Muñoz, "Identification and monitoring of brain activity based on stochastic relevance analysis of short-time EEG rhythms," *BioMed Eng OnLine*, vol. 13, 2014.
- [32] J. Arturo Olvera-López, Ivan Olmos-Pineda, Susana Sánchez-Urrieta Ricardo Ramos-Aguilar, "Feature extraction from EEG spectrograms for epileptic seizure detection," *Pattern Recognition Letters*, vol. 133, pp. 202-209, 2020.
- [33] Ricardo & Olvera-López, José & Pineda, Ivan & Sánchez-Urrieta, Susana & Martín-Ortiz, Manuel Ramos, "Parameter Experimentation for Epileptic Seizure Detection in EEG Signals using Short-Time Fourier Transform," *Research in Computing Science*, vol. 148, 2019.
- [34] Ramy & Ward, Rabab & Wang, Z. & Kuhlmann, Levin & Guo, Yi Hussein, "Human Intracranial EEG Quantitative Analysis and Automatic Feature Learning for Epileptic Seizure Prediction," *The University of British Columbia*, 2019.
- [35] P., Kar, R., Mandal, D., & Ghoshal Upadhyay, "IIR system identification using differential evolution with wavelet mutation," *Engineering Science and Technology*, pp. 8-24, 2014.
- [36] Laurens Van der Maaten, Eric Postma, and Jaap van den Herik, "Dimensionality Reduction: A Comparative Review," *J Mach Learn Res*, pp. 66-71, 2009.
- [37] Δ. Πετρίδης, *Ανάλυση πολυμεταβλητών τεχνικών*.: Εκδόσεις Κάλλιπος, 2015.
- [38] Tharwat Alaa, "Independent Component Analysis: an Introduction," *Applied Computing and Informatics*, 2018.
- [39] E. Oja A. Hyvärinen, "Independent component analysis: algorithms and applications," *Neural Networks*, vol. 13, pp. 411-430, 2000.
- [40] I., Weston, J., Barnhill, S., & Vapnik, V. Guyon, "Gene selection for cancer classification using support vector machines," vol. 46, pp. 389–422, 2002.
- [41] Άγγελος Πικράκης, Κωνσταντίνος Κουτρούμπας, Διονύσης Κάβουρας Σέργιος Θεοδωρίδης, *Εισαγωγή στην Αναγνώριση Προτύπων με MALTB*.: Εκδόσεις Πασχαλίδης, 2010, pp. 1-2,31-32,82-85.
- [42] H. Zhang, "The optimality of Naive Bayes," *FLAIRS*, 2004.
- [43] Wikipedia contributors, "Support-vector machine," *Wikipedia, The Free Encyclopedia*, 2020.
- [44] Corinna Cortes and Vladimir N Vapnik, "Support-vector networks," *Machine Learning*, vol. 20, pp. 273–297, 1995.

- [45] Bernhard E. Boser, Isabelle M. Guyon, and Vladimir N Vapnik, "A training algorithm for optimal margin classifiers," *Proceedings of the fifth annual workshop on Computational learning theory – COLT '92*, p. 144, 1992.
- [46] Wikipedia contributors, "Predictive analytics," *Wikipedia, The Free Encyclopedia*, 2020.
- [47] Maciej Jaworski, Lena Pietruczuk, and Piotr Duda Leszek Rutkowski, "The CART decision tree for mining data streams," *Inf. Sci.*, pp. 1–15, 2014.
- [48] Xue Ying, "An Overview of Overfitting and its Solutions," *Journal of Physics: Conference Series*, vol. 1168, 2019.
- [49] Wikipedia contributors, "Overfitting," *Wikipedia, The Free Encyclopedia*, 2020.
- [50] J. A. Benediktsson and J. R. Sveinsson G. J. Briem, "Multiple Classifiers Applied to Multisource Remote Sensing Data," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 40, pp. 2291-2299, 2002.
- [51] R. C., Woods, R. E. Gonzalez, "Digital image processing," *Upper Saddle River*, pp. 594-599, 2018.
- [52] I. Basheer M. Hajmeer, "A probabilistic neural network approach for modeling and classification of bacterial growth/no-growth data," *Journal of Microbiological Methods*, vol. 51, 2002.
- [53] Havaš L, Srpak D Horvat T, "The Impact of Selecting a Validation Method in Machine Learning on Predicting Basketball Game Outcomes," *Symmetry*, p. 431, 2020.
- [54] Arif & Alalyani, Meshiel & Hussain, Ibrar & Musa, & Almutheibi, M. Hanga, "Brief review on Sensitivity, Specificity and Predictivities," *IOSR Journal of Dental and Medical Sciences*, no. 14, 2015.
- [55] David M W Powers, "Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation," *Journal of Machine Learning Technologies*, vol. 2, no. 1, pp. 37–63, 2011.
- [56] Fawcett Tom, "Introduction to ROC analysis," *Pattern Recognition Letters*, no. 27, pp. 861-874, 2006.
- [57] Andreev A, Mendoza C, Congedo M Cattan G, "The Impact of Passive Head-Mounted Virtual Reality Devices on the Quality of EEG Signals," *VRIPHYS 2018 - Workshop on Virtual Reality*, 2018.
- [58] Pedro Luiz Coelho Rodrigues, Marco Congedo Grégoire Cattan, "EEG Alpha Waves Dataset," *[Research Report] GIPSA-LAB*, 2018.
- [59] Jonathan & Birbaumer, N & Heetderks, W.J. & Mcfarland, Dennis & Peckham, P. & Schalk, Gerwin & Donchin, Emanuel & Quatrano, L.A. & Robinson, Charles & Vaughan, Theresa Wolpaw, "Brain-computer interface technology: a review," *IEEE transactions on rehabilitation engineering : a publication of the IEEE Engineering in Medicine and*

Biology Society, pp. 164-173, 2000.

- [60] Bai O, Henriquez CS, Lin P, Furlani SJ, Vorbach S, Hallett M Kayagil TA, "A binary method for simple and accurate two-dimensional cursor control from EEG with minimal subject training," *J Neuroeng Rehabil*, vol. 6, no. 14, 2009.
- [61] Leigh R Hochberg Marco Vilela, "Applications of brain-computer interfaces to the control of robotic and prosthetic arms," *Handb Clin Neurol.*, pp. 87-99, 2020.
- [62] Nurullah Akkaya, Ersin Aytac, Irfan Günsel, Ahmet Çağman Rahib H. Abiyev, "Brain-Computer Interface for Control of Wheelchair Using Fuzzy Neural Networks," *BioMed Research International*, 2016.
- [63] Jonathan R. Wolpaw Joseph N. Mak, "Clinical Applications of Brain-Computer Interfaces: Current State and Future Prospects," *IEEE Rev Biomed Eng.* , pp. 187-199, 2009.
- [64] GIPSA-lab. (2020) GitHub repository. [Online].
<https://github.com/plcrodrigues/py.ALPHA.EEG.2017-GIPSA>