



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

**Εξαγωγή Χαρακτηριστικών και Ταξινόμηση
Βιολογικών Σημάτων για χρήση στα
Συστήματα Υποβοήθησης της Διάγνωσης**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Αγγελική Ε. Δημαράκη

Επιβλέπων : Γεώργιος Ματσόπουλος
Αν. Καθηγητής Ε.Μ.Π.

Αθήνα, Ιούλιος 2017



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ

ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

ΤΟΜΕΑΣ ΣΥΣΤΗΜΑΤΩΝ ΜΕΤΑΔΟΣΗΣ ΠΛΗΡΟΦΟΡΙΑΣ

ΚΑΙ ΤΕΧΝΟΛΟΓΙΑΣ ΥΛΙΚΩΝ

Εξαγωγή Χαρακτηριστικών και Ταξινόμηση Βιολογικών Σημάτων για χρήση στα Συστήματα Υποβοήθησης της Διάγνωσης

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Αγγελική Ε. Δημαράκη

Επιβλέπων : Γεώργιος Ματσόπουλος
Αν. Καθηγητής Ε.Μ.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 17^η Ιουλίου 2017.

.....
Γ. Ματσόπουλος
Αν. Καθηγητής Ε.Μ.Π.

.....
Δ. Κουτσούρης
Καθηγητής Ε.Μ.Π.

.....
Ν. Ουζούνγλου
Καθηγητής Ε.Μ.Π.

Αθήνα, Ιούλιος 2017

.....
Αγγελική Ε. Δημαράκη

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

Copyright © Αγγελική Δημαράκη, 2017.

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας, εξ ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για σκοπό μη κερδοσκοπικό, εκπαιδευτικής ή ερευνητικής φύσης, υπό την προϋπόθεση να αναφέρεται η πηγή προέλευσης και να διατηρείται το παρόν μήνυμα. Ερωτήματα που αφορούν τη χρήση της εργασίας για κερδοσκοπικό σκοπό πρέπει να απευθύνονται προς τον συγγραφέα.

Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον συγγραφέα και δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις επίσημες θέσεις του Εθνικού Μετσόβιου Πολυτεχνείου.

*Η παρούσα μελέτη είναι αφιερωμένη
στους γονείς και τα αδέρφια μου*

Περίληψη

Ο σκοπός της διπλωματικής εργασίας ήταν η μελέτη και ανάλυση των τεχνικών που χρησιμοποιούνται για την επιλογή των χαρακτηριστικών και την ταξινόμηση των βιοσημάτων, στα συστήματα υποβοήθησης της διάγνωσης.

Για να μπορέσουμε να εστιάσουμε στην ουσία της λειτουργίας αυτών των μεθόδων, κρίθηκε σκόπιμο να απλοποιήσουμε λίγο το πρόβλημα και έτσι στην παρούσα μελέτη γίνεται ανάλυση των τεχνικών που εφαρμόζονται μόνο σε μονοδιάστατα βιολογικά σήματα, και πιο συγκεκριμένα στις τρεις σημαντικότερες κατηγορίες τους, δηλαδή στο ηλεκτροεγκεφαλογράφημα (ΗΕΓ), στο ηλεκτρομυογράφημα (ΗΜΓ) και στο ηλεκτροκαρδιογράφημα (ΗΚΓ).

Αρχικά, έγινε μια εισαγωγική, θεωρητική προσέγγιση των εννοιών της αναγνώρισης και ταξινόμησης προτύπων και στη συνέχεια έγινε παρουσίαση των συστημάτων υποστήριξης της διάγνωσης για την κατανόηση της δομής και της λειτουργίας τους, οι οποίες βασίζονται στις προηγούμενες αρχές.

Στη συνέχεια της εργασίας έγινε πρώτα μια αναλυτική παρουσίαση των σύγχρονων μεθόδων εξαγωγής χαρακτηριστικών που προτείνονται στη βιβλιογραφία και έπειτα μια παράθεση των αντίστοιχων τεχνικών (αλγόριθμων) ταξινόμησης, με τις οποίες τα βιοσήματα ταξινομούνται στις αντίστοιχες τάξεις. Τα διάφορα ζεύγη μεθόδων που προκύπτουν από το συνδυασμό μιας μεθόδου εξαγωγής με έναν αλγόριθμο ταξινόμησης, είναι φανερό πως θα έχουν διαφορετική απόδοση στην ταξινόμηση των σημάτων. Έτσι, γίνεται φανερή η σημασία της σύγκρισης των τεχνικών αυτών, για την εύρεση του ζεύγους μεθόδων που μπορεί να οδηγήσει σε βέλτιστα αποτελέσματα.

Στο τελευταίο μέρος, λοιπόν, της εργασίας μας πραγματοποιείται μια συγκριτική ανάλυση όλων των μεθόδων, τα αποτελέσματα της οποίας παρατίθενται σε συνολικούς πίνακες, με σκοπό την εξαγωγή χρήσιμων συμπερασμάτων για τα πλεονεκτήματα και τα μειονεκτήματα κάθε μεθόδου, αλλά και την καταλληλότητά της για μελλοντική χρήση σε ιατρικές εφαρμογές τέτοιου είδους.

Λέξεις Κλειδιά

Βιοσήματα, Αναγνώριση Προτύπων, Μηχανική Μάθηση, Συστήματα Υποστήριξης της Διάγνωσης, Ταξινόμηση Βιοσημάτων, Αλγόριθμοι ταξινόμησης, Επιλογή Χαρακτηριστικών, Εξαγωγή Χαρακτηριστικών, Τεχνητά Νευρωνικά Δίκτυα, Μηχανές Διανυσμάτων Υποστήριξης, Αλγόριθμος k-Κοντινότερων Γειτόνων, Αλγόριθμος Ασαφών C-Μέσων, Μέθοδος Διασταυρούμενης Επικύρωσης k-φορών.

Abstract

The aim of this diploma thesis is to study and analyze the techniques used for the feature selection and the bio-signal classification in the diagnosis support systems (DSS).

In order to be able to focus on the essence of the operation of these methods, it was considered appropriate to simplify the problem a bit, and so the present study analyzes the techniques applied only to one-dimensional biological signals, and more specifically to their three major categories, namely the electroencephalogram (EEG), electrocardiogram (ECG) and electromyogram (EMG).

Initially, an introductory, theoretical approach to the concepts of pattern recognition and classification was made, followed by a presentation of diagnosis support systems to understand their structure and function, which are based on previous principles.

Afterwards, a detailed presentation of the current methods of feature extraction proposed in the literature, was made and after that, the corresponding classification techniques by which the bio-signals are classified into the different classes, were presented. The various pairs of methods which result from combining an extraction method with a classification algorithm, will accordingly have a different performance in the classification of the signals. Thus, it becomes clear that the importance of comparing these techniques to finding the pair of methods that can lead to optimal results is great.

In the last part of our thesis, we perform a comparative analysis of all the methods, the results of which are presented in overall tables, in order to draw useful conclusions about the advantages and disadvantages of each method, as well as its suitability for future use in medical applications of this kind.

Key Words

Biological Signals, Pattern Recognition, Machine Learning, Diagnosis Support Systems, Biosignal Classification, Classification Algorithms, Feature Selection, Feature Extraction, Artificial Neural Networks, Support Vector Machines, k-Nearest Neighbors Algorithm, Fuzzy C-Means Algorithm, k-fold Cross Validation.

Ευχαριστίες

Θα ήθελα να εκφράσω τις ειλικρινείς μου ευχαριστίες στον επιβλέποντα καθηγητή μου, Αν. Καθηγητή του Ε.Μ.Π., Γεώργιο Ματσόπουλο που με χαρά με καθοδήγησε και με βοήθησε να επιλέξω θέμα διπλωματικής, δίνοντάς μου την ευκαιρία να ασχοληθώ με ένα τόσο ενδιαφέρον και σημαντικό θέμα, όπως είναι η ταξινόμηση προτύπων στη Βιοϊατρική. Στην συνέχεια, καθ' όλη την διάρκεια της διπλωματικής εργασίας στάθηκε δίπλα μου με υπομονή και κατανόηση, ενώ η καλή του διάθεση σε κάθε μας συνάντηση, ανανέωνε εκ νέου το κίνητρό μου. Η βοήθειά του ήταν πολύτιμη και τόσο με τις εύστοχες επιστημονικές του συμβουλές, όσο και με την ψυχολογική του στήριξη.

Εξίσου σημαντική, αν όχι περισσότερο, ήταν η υποστήριξη της οικογένειάς μου για την ολοκλήρωση αυτής της εργασίας. Θα ήθελα να ευχαριστήσω τον πατέρα μου Βαγγέλη, που μου παρείχε όλα όσα χρειαζόμουν και δεν με άφησε ποτέ να ανησυχήσω για τίποτα, τη μητέρα μου Κατερίνα, που ήταν πάντα δίπλα μου όταν την είχα ανάγκη βοηθώντας με έμπρακτα, τον αδερφό μου Στέλιο που μου έκανε παρέα τις νύχτες που διάβαζα μέχρι αργά και που μου προσέφερε απλόχερα τη βοήθειά του τις τελευταίες μέρες για την ολοκλήρωση της διπλωματικής και τέλος, τη μικρή μου αδερφή, Κλεοπάτρα, η οποία αν και από μακριά, με ενθάρρυνε δυναμικά καθ' όλη τη διάρκεια της διπλωματικής και με παρότρυνε συνεχώς να συνεχίζω, παρ' όλες τις δυσκολίες που κατά καιρούς συναντούσα.

Κλείνοντας, θα ήθελα να πω ένα μεγάλο ευχαριστώ στους αγαπητούς μου φίλους, Βάσω, Δημήτρη Λιάκ., Αντιγόνη, Θάλεια, Μαρίνα, Πάτρικ και Δημήτρη Λασκ., οι οποίοι με τη συμπαράσταση και την αγάπη τους, συνέβαλαν στην περάτωση της εργασίας αυτής. Η γνωριμία μας ήταν πραγματικό δώρο για μένα και η βοήθειά τους όλα αυτά τα χρόνια, αποδείχθηκε ανεκτίμητη. Ελπίζω να μου δοθεί η ευκαιρία να τους το ανταποδώσω, βοηθώντας τους και εγώ με τη σειρά μου σε κάτι που έχει αξία για αυτούς.

Πίνακας περιεχομένων

Κεφάλαιο 1^ο: Εισαγωγή

| | |
|--|----|
| 1.1 Σκοπός διπλωματικής εργασίας..... | 20 |
| 1.2 Διάρθρωση διπλωματικής εργασίας..... | 20 |

Κεφάλαιο 2^ο: Θεωρητικό Υπόβαθρο: Αναγνώριση Προτύπων και Ταξινόμηση Βιολογικών Σημάτων - Συστήματα Υποβοήθησης της Διάγνωσης

| | |
|---|----|
| 2.1 Αναγνώριση Προτύπων | 21 |
| 2.1.1 Τεχνητή Νοημοσύνη - Ευφυείς μηχανές | 21 |
| 2.1.2 Εισαγωγή στην Αναγνώριση Προτύπων..... | 21 |
| 2.1.3 Βασική Φιλοσοφία και Μεθοδολογικές Κατευθύνσεις της Αναγνώρισης Προτύπων - Ταξινόμηση Προτύπων..... | 22 |
| 2.1.4 Επιβλεπόμενη, Μη-επιβλεπόμενη και Ημι-επιβλεπόμενη Μάθηση..... | 25 |
| 2.1.5 Αναγνώριση Προτύπων και Συστήματα Υποβοήθησης Διάγνωσης | 26 |
| 2.2 Η Ιατρική Διάγνωση σαν πρόβλημα της Αναγνώρισης Προτύπων..... | 27 |
| 2.3 Βιολογικά Σήματα και Ιατρική Διάγνωση..... | 28 |
| 2.4 Συστήματα Υποβοήθησης Ιατρικής Διάγνωσης (Diagnosis Support Systems) | 30 |
| 2.4.1 Εισαγωγή | 30 |
| 2.4.2 Ιστορική Αναδρομή Συστημάτων Υποβοήθησης Διάγνωσης | 32 |
| 2.4.3 Πλεονεκτήματα Συστημάτων Υποστήριξης Διάγνωσης σε σχέση με τον ανθρώπινο παράγοντα..... | 33 |

Κεφάλαιο 3^ο: Επιλογή και Εξαγωγή Χαρακτηριστικών για Ταξινόμηση Βιοσημάτων

| | |
|---|----|
| 3.1 Επιλογή Χαρακτηριστικών | 36 |
| 3.1.1 Εισαγωγή | 36 |
| 3.1.2 Μέθοδοι Επιλογής των Χαρακτηριστικών | 37 |
| 3.1.3 Στατιστικά Χαρακτηριστικά | 42 |
| 3.2 Εξαγωγή Χαρακτηριστικών..... | 44 |
| 3.2.1 Εισαγωγή | 44 |
| 3.3 Πειραματικές μεθοδολογίες εξαγωγής χαρακτηριστικών σε προβλήματα ταξινόμησης μονοδιάστατων βιολογικών σημάτων | 45 |
| 3.3.1 Μέθοδοι Εξαγωγής Χαρακτηριστικών σε Ηλεκτροεγκεφαλογραφήματα | 46 |
| 3.3.1.1 Εξαγωγή χαρακτηριστικών με χρήση της μεθόδου του μονοδιάστατου δυαδικού προτύπου (1D-LBP) | 46 |

| | |
|--|----|
| 3.3.1.2 Εξαγωγή χαρακτηριστικών με χρήση μη-γραμμικών μεθόδων | 53 |
| 3.3.1.3 Εξαγωγή τετραγωνικών χαρακτηριστικών με χρήση μεθόδου βασισμένης στο AR μοντέλο | 62 |
| 3.3.1.4 Εξαγωγή χαρακτηριστικών με χρήση φασματικών μεθόδων (τράπεζα φίλτρων, μέθοδος Welch και STFT)..... | 68 |
| 3.3.2 Μέθοδοι εξαγωγής Χαρακτηριστικών σε Ηλεκτρομυογραφήματα..... | 77 |
| 3.3.2.1 Εξαγωγή χαρακτηριστικών με χρήση του διακριτού μετασχηματισμού κυματιδίου (DWT)..... | 77 |
| 3.3.3 Μέθοδοι Εξαγωγής Χαρακτηριστικών σε Ηλεκτροκαρδιογραφήματα..... | 82 |
| 3.3.3.1 Εξαγωγή ενός συνδυασμού γραμμικών και μη γραμμικών χαρακτηριστικών με χρήση των μεθόδων PCA και ICA | 82 |

Κεφάλαιο 4^ο: Ταξινομητές - Μέθοδοι Ταξινόμησης

| | |
|--|-----|
| 4.1 Εισαγωγή | 93 |
| 4.2 Μπεϋζιανοί Ταξινομητές (Bayesian Classifiers)..... | 93 |
| 4.2.1 Απλοϊκός Μπεϋζιανός Ταξινομητής (Naive Bayes Classifier)..... | 95 |
| 4.3 Γραμμικοί Ταξινομητές (Linear Classifiers) | 96 |
| 4.3.1 Ο Αλγόριθμος Perceptron | 97 |
| 4.3.2 Γραμμική Διακριτική Ανάλυση | 101 |
| 4.4 Μη γραμμικοί Ταξινομητές (Non-linear Classifiers) | 102 |
| 4.4.1 Τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Networks)..... | 102 |
| 4.4.2 Αλγόριθμος k-Κοντινότερων Γειτόνων (k-Nearest Neighbor Algorithm) .. | 116 |
| 4.4.3 Μηχανές Διανυσμάτων Υποστήριξης (Support Vector Machines)..... | 121 |
| 4.4.4 Αλγόριθμος Ασαφών C-Μέσων (Fuzzy C-means algorithm) | 129 |
| 4.5 Παραδείγματα άλλων ταξινομητών | 134 |
| 4.5.1 Least Square - SVM..... | 135 |
| 4.5.2 Ταξινομητής τυχαίου δάσους (Random forest classifier)..... | 135 |
| 4.5.3 Μηχανές ακραίας μάθησης (Extreme Learning Machines - ELM)..... | 137 |

Κεφάλαιο 5^ο: Κριτική και Σύγκριση των Μεθόδων Εξαγωγής Χαρακτηριστικών

| | |
|--|-----|
| 5.1 Αξιολόγηση της Απόδοσης των Ταξινομητών | 138 |
| 5.2 Πειραματικά αποτελέσματα..... | 140 |
| 5.3 Συνολικός Συγκριτικός Πίνακας Ακρίβειας Ταξινόμησης..... | 171 |

Κεφάλαιο 6^ο: Συμπεράσματα - Μελλοντικές Επεκτάσεις

6.1 Συμπεράσματα 175

6.2 Μελλοντικές Επεκτάσεις 176

Βιβλιογραφία 178

Κατάλογος Σχημάτων

Κεφάλαιο 2:

- Σχήμα 2.1:** Γραφική παράσταση της μέσης τιμής προς την τυπική απόκλιση για έναν αριθμό διαφορετικών προτύπων που προέρχονται από την τάξη A (o) και την τάξη B (+). Σε αυτή την περίπτωση, μια ευθεία γραμμή χωρίζει τις δύο κλάσεις.....22
- Σχήμα 2.2:** Ένα γραμμικά διαχωρίσιμο πρόβλημα. Τα πρότυπα που παριστάνονται με “o” ανήκουν στη μία τάξη και αυτά με “x” στην άλλη. Η διάταξη των προτύπων στο χώρο των δεδομένων επιτρέπει το διαχωρισμό των προτύπων της μίας τάξης από αυτά της άλλης με ευθεία γραμμή.....23
- Σχήμα 2.3:** Ένα μη γραμμικά διαχωρίσιμο πρόβλημα. Τα πρότυπα των δύο τάξεων δεν μπορούν να διαχωριστούν με μία μόνο ευθεία γραμμή.....24
- Σχήμα 2.4:** Τα βασικά στάδια που εμπλέκονται στο σχεδιασμό ενός συστήματος ταξινόμησης.....24
- Σχήμα 2.5:** Παράδειγμα εισόδων και εξόδων ενός συστήματος ταξινόμησης προτύπων για ένα υποθετικό πρόβλημα. Η είσοδος με τιμή 180 αντιστοιχεί στο ύψος ενός ανθρώπου σε εκατοστά ενώ η άλλη στο βάρος του σε κιλά. Η έξοδος δείχνει ότι ο άνθρωπος με αυτό το ύψος και βάρος δεν είναι παχύσαρκος.....26

Κεφάλαιο 3:

- Σχήμα 3.1:** Διάγραμμα ροής του αλγόριθμου επιλογής χαρακτηριστικών SFFS.....41
- Σχήμα 3.2:** Οι μορφές των διαφόρων κατανομών ανάλογα με την τιμή (θετική, αρνητική ή μηδενική) της κύρτωσης.....43
- Σχήμα 3.3:** Η ασυμμετρία είναι αρνητική όταν η καμπύλη εξογκώνεται προς τα δεξιά και έχει μια μεγάλη ουρά προς τα αριστερά και θετική στην αντίθετη περίπτωση.....44
- Σχήμα 3.4:** Η μεθοδολογία που προτείνεται για τη βελτιστοποίηση των καναλιών HEG.....59
- Σχήμα 3.5:** Προτεινόμενη μεθοδολογία για την αυτόματη ανίχνευση της εγρήγορσης.....61
- Σχήμα 3.6:** Βασικό διάγραμμα της τεχνικής ανίχνευσης κρίσεων που παρουσιάζεται.....67
- Σχήμα 3.7:** Σύστημα τράπεζας φίλτρων με δύο συχνότητες.....73
- Σχήμα 3.8:** Το σχεδιάγραμμα της μελέτης.....78
- Σχήμα 3.9:** Το προτεινόμενο αυτοματοποιημένο σύστημα αναγνώρισης.....85

Κεφάλαιο 4:

- Σχήμα 4.1:** Γεωμετρία της αποφασιστικής γραμμής. Στη μια πλευρά της γραμμής είναι $g(x) > 0$ (+) και στην άλλη $g(x) < 0$ (-).....97
- Σχήμα 4.2:** Γεωμετρική ερμηνεία του αλγόριθμου Perceptron. Η διόρθωση του διανύσματος βάρους είναι προς την κατεύθυνση του x ώστε να μετατρέψει το υπερεπίπεδο για να συμπεριλάβει το x στη σωστή τάξη.....98
- Σχήμα 4.3:** Ένα παράδειγμα του αλγόριθμου perceptron. Μετά τη διόρθωση του διανύσματος βάρους, το υπερεπίπεδο μετατοπίζεται από την αρχική του θέση (διακεκομμένη γραμμή) στη νέα του θέση (κανονική γραμμή) και όλα τα σημεία ταξινομούνται σωστά.....98
- Σχήμα 4.4:** Το βασικό μοντέλο perceptron. (α) Ένας γραμμικός συνδυαστής ακολουθείται από τη συνάρτηση ενεργοποίησης. (β) Ο συνδυαστής και η συνάρτηση ενεργοποίησης συγχωνεύονται.....99
- Σχήμα 4.5:** Μη γραμμικό μοντέλο τεχνητού νευρώνα. (α) Σχηματική αναπαράσταση. (β) Μαθηματική αναπαράσταση.....102
- Σχήμα 4.6:** Η δομή του Τεχνητού Νευρωνικού Δικτύου ενός επιπέδου.....106
- Σχήμα 4.7:** Μια πιθανολογική αρχιτεκτονική νευρωνικού δικτύου με N σημεία δεδομένων εκπαίδευσης. Ο κάθε κόμβος αντιστοιχεί σε ένα δεδομένο εκπαίδευσης και αριθμείται αναλόγως. Στο σχήμα έχουν σχεδιαστεί μόνο τα συναπτικά βάρη του k -οστού κόμβου.

| | |
|--|-----|
| Έχουμε υποθέσει ότι υπάρχουν δύο διαθέσιμες τάξεις ω_1 , ω_2 , καθώς και ότι τα πρώτα k σημεία προέρχονται από την τάξη ω_1 , ενώ τα υπόλοιπα από την τάξη ω_2 | 106 |
| Σχήμα 4.8: Σχηματική απεικόνιση ενός TND εμπρόσθιας τροφοδότησης..... | 107 |
| Σχήμα 4.9: Σχηματική απεικόνιση ενός TND ανατροφοδότησης..... | 108 |
| Σχήμα 4.10: Παράδειγμα ταξινόμησης κοντινότερων γειτόνων. Ο μικρότερος (ανοιχτός γκρι) κύκλος αναφέρεται στην ταξινόμηση κοντινότερου γείτονα, ενώ ο μεγάλος (μαύρος) κύκλος αναφέρεται στην ταξινόμηση 3 κοντινότερων γειτόνων..... | 115 |
| Σχήμα 4.11: Υπερεπίπεδο ελαστικού περιθωρίου διαχωρισμού σε διδιάστατο χώρο. (α) Το σημείο δεδομένων βρίσκεται στη σωστή πλευρά του υπερεπιπέδου αλλά εντός της περιοχής διαχωρισμού. (β) Το σημείο δεδομένων βρίσκεται στη λάθος πλευρά του υπερεπιπέδου.... | 121 |
| Σχήμα 4.12: Γραφική απεικόνιση της έννοιας του βέλτιστου υπερεπιπέδου για γραμμικά διαχωρίσιμα πρότυπα σε χώρο 2 διαστάσεων. Τα σημεία δεδομένων με μαύρο χρώμα είναι τα διανύσματα υποστήριξης..... | 121 |
| Σχήμα 4.13: Μη γραμμικός μετασχηματισμός $\phi(\cdot)$ από το χώρο εισόδου (input space) σε ένα χώρο χαρακτηριστικών (feature space). Με κατάλληλο μη γραμμικό μετασχηματισμό, είναι δυνατόν ένα μη γραμμικό πρόβλημα να μετατραπεί σε γραμμικό..... | 123 |
| Σχήμα 4.14: Η αρχιτεκτονική της SVM, χρησιμοποιώντας συναρτήσεις πυρήνα..... | 125 |
| Σχήμα 4.15: (α) Συμπαγής συστάδα με εκπρόσωπο ένα σημείο. (β) Γραμμική συστάδα με εκπρόσωπο ένα υπερεπίπεδο. (γ) Υπερσφαιρική συστάδα με εκπρόσωπο μία υπερσφαίρα.. | 130 |
| Σχήμα 4.16: Βήματα αλγορίθμου FCM..... | 133 |
| Σχήμα 4.17: Δομή του ταξινομητή τυχαίου δάσους..... | 135 |
| Σχήμα 4.18: Βασική δομή της ELM..... | 136 |

Κεφάλαιο 5:

| | |
|--|-----|
| Σχήμα 5.1: Διάγραμμα του προτεινόμενου συστήματος ταξινόμησης..... | 139 |
| Σχήμα 5.2: Το LBP ιστόγραμμα χαρακτηριστικών των συνόλων δεδομένων HEG..... | 140 |
| Σχήμα 5.3: Απόδοση του ταξινομητή SVM με χρήση διαφορετικών συναρτήσεων πυρήνα..... | 147 |
| Σχήμα 5.4: Απόδοση του ταξινομητή LS-SVM με χρήση διαφορετικών συναρτήσεων πυρήνα..... | 147 |
| Σχήμα 5.5: Καμπύλη ROC για LS-SVM με χρήση πολυωνυμικής συνάρτησης πυρήνα και συνάρτησης πυρήνα ακτινικής βάσης..... | 149 |
| Σχήμα 5.6: Διάγραμμα των καναλιών με τη μεγαλύτερη συνεισφορά στην ταξινόμηση..... | 161 |
| Σχήμα 5.7: Η συνολική σύγκριση της ακρίβειας, για ταξινόμηση ατόμων με ALS και υγιών ατόμων, ταξινόμηση ατόμων με ALS και ατόμων με PD και ταξινόμηση ατόμων με ALS και ατόμων με HD..... | 164 |
| Σχήμα 5.8: Η συνολική σύγκριση της ακρίβειας που σχετίζεται με τα χαρακτηριστικά, για ταξινόμηση ατόμων με ALS και ατόμων με PD ή HD και ταξινόμηση ατόμων με ALS και ατόμων με PD ή HD ή υγιών ατόμων..... | 164 |
| Σχήμα 5.9: Η επιλογή του τύπου κυματιδίου για κάθε ταξινόμηση..... | 165 |
| Σχήμα 5.10: Διακύμανση της μέσης ακρίβειας σε συνάρτηση των διαφορετικών τιμών της παραμέτρου C , κατά τη διάρκεια της SVM-RBF ταξινόμησης, χρησιμοποιώντας συνδυασμό γραμμικών και μη γραμμικών χαρακτηριστικών..... | 167 |
| Σχήμα 5.11: Σύγκριση των γραμμικών, μη γραμμικών και προτεινόμενων χαρακτηριστικών με τη χρήση του SVM-RBF ταξινομητή..... | 168 |
| Σχήμα 5.12: Σύγκριση των γραμμικών, μη γραμμικών και προτεινόμενων χαρακτηριστικών με τη χρήση του NN ταξινομητή..... | 169 |

Κατάλογος Εικόνων

Κεφάλαιο 2:

Εικόνα 2.1: Ηλεκτρομαγνητική δραστηριότητα εγκεφάλου όπως έχει καταγραφεί από ειδικό σύστημα ιατρικής απεικόνισης. Η εικόνα αυτή μπορεί να αποτελέσει είσοδο σε σύστημα ιατρικής διάγνωσης μετά από ψηφιοποίηση.....29

Εικόνα 2.2: Σήμα ηλεκτροκαρδιογραφήματος που μπορεί με κατάλληλη επεξεργασία να αποτελέσει είσοδο σε σύστημα ιατρικής διάγνωσης.....29

Εικόνα 2.3: Λειτουργία ενός τυπικού Συστήματος Υποστήριξης Κλινικών Αποφάσεων.....32

Κεφάλαιο 3:

Εικόνα 3.1: Παραδείγματα ΗΕΓ σημάτων για κάθε ένα από τα πέντε διαφορετικά σετ.....48

Εικόνα 3.2: Κυκλικά συμμετρικά σύνολα γειτόνων για διαφορετικά (P, R).....49

Εικόνα 3.3: Υπολογισμός των αρχικών LBP κωδικών.....49

Εικόνα 3.4: Στάδια υλοποίησης του κωδικού, (a) ένα τμήμα ενός δείγματος εγκεφαλικού σήματος, (b) τιμές δειγμάτων του υπο-σήματος, (c) συγκρίνοντας γειτονικά δείγματα με το κεντρικό και 8 bit δυαδική αναπαράσταση και (d) δεκαδική αναπαράσταση.....51

Εικόνα 3.5: Εξαγωγή χαρακτηριστικών από εφαρμοζόμενο 1D-LBP σήμα, (a) ένα τμήμα του δείγματος ΗΕΓ, (b) το σήμα μετασχηματίζεται στο LBP πεδίο, (c) το ιστόγραμμα όλων των LBP κωδικών, (d)το ιστόγραμμα των ομοιόμορφων LBP κωδικών.....52

Εικόνα 3.6: Δείγματα ΗΕΓ σημάτων σε κατάσταση υπνηλίας (a-c) και σε κατάσταση εγρήγορης (d-f), από το κανάλι C_z55

Εικόνα 3.7: Η συνάρτηση συνημιτόνου Weierstrass για το θεωρητικό fractal dimension ($FD_{id}=1.6$).....56

Εικόνα 3.8: Το σχετικό σφάλμα για τις εκτιμήσεις των Higuchi FD με i_{max}57

Εικόνα 3.9: Βελτιστοποιημένα κανάλια ΗΕΓ ως προς το σύστημα 10-20.....60

Εικόνα 3.10: Πειραματική ρύθμιση. (a) Οθόνη με σκακιέρες που χρησιμοποιούνται για να παράγουν οπτικά ερεθίσματα σε συχνότητα 12 και 15 Hz. (b) Διαμόρφωση του εξοπλισμού και του περιβάλλοντος συλλογής δεδομένων.....70

Εικόνα 3.11: Εναπόθεση των ηλεκτροδίων στο κρανίο για την απόκτηση του ηλεκτροεγκεφαλογραφήματος.....71

Εικόνα 3.12: Εξαγωγή χαρακτηριστικών απόκρισης SSVEP στα 12 και 15 Hz, (a) φασματική πυκνότητα ισχύος, (b) χώρος φασματικών χαρακτηριστικών λαμβάνοντας υπόψη μόνο ένα ινιακό κανάλι.....72

Εικόνα 3.13: Απόκριση ζωνοπερατού φίλτρου για κάθε οπτικό ερέθισμα (a) 12Hz και (b) 15Hz.....73

Εικόνα 3.14: Το σήμα δύναμης του αριστερού ποδιού, το σήμα δύναμης του δεξιού ποδιού και το CFS.....79

Εικόνα 3.15: Αναλυτικοί συντελεστές σε CFS σήμα.....81

Εικόνα 3.16: Οι πέντε τύποι τάξεων των χτύπων στην πρότυπη βάση δεδομένων ANSI/AAMI EC57: 1998, σε δύο κατηγορίες προεπεξεργασίας: (α) την εξομάλυνση των χτύπων του σήματος χρησιμοποιώντας τον DWT και (β) χτύποι του σήματος χωρίς τη χρήση DWT.....87

Εικόνα 3.17: Λεπτομέρεια τρίτου επιπέδου (cd3) και λεπτομέρεια τέταρτου επιπέδου (cd4) του DWT για τους πέντε τύπους τάξεων χτύπων στην πρότυπη βάση δεδομένων ANSI/AAMI EC57: 1998.....89

Κεφάλαιο 4:

Εικόνα 4.1: Συναρτήσεις πυκνότητας υπό συνθήκης πιθανότητας για δύο τάξεις ω_1 και ω_2 και οι δύο περιοχές R_1 και R_2 που σχηματίζονται με βάση το κατώφλι x_095

| | |
|---|-----|
| Εικόνα 4.2: Σχηματική αναπαράσταση της δομής ενός βιολογικού νευρώνα (αριστερά) και ενός τεχνητού νευρώνα (δεξιά)..... | 102 |
| Εικόνα 4.3: Περιοχές απόφασης που δημιουργεί ο αλγόριθμος κοντινότερων γειτόνων k-NN σε ένα δεδομένο σύνολο εκπαίδευσης με τρεις τάξεις, σε δύο διαφορετικές περιπτώσεις. (α) ταξινομητής ενός κοντινότερου γείτονα ($k=1$). (β) ταξινομητής 5 κοντινότερων γειτόνων ($k=5$)..... | 119 |
| Εικόνα 4.4: Παράδειγμα ενός μη γραμμικού ταξινομητή SVM για την περίπτωση των δύο μη γραμμικώς διαχωρίσιμων τάξεων. Χρησιμοποιήθηκε η Γκαουσιανή συνάρτηση πυρήνα ακτινικής βάσης (RBF). Οι διακεκομμένες γραμμές σημειώνουν το περιθώριο και τα κυκλωμένα σημεία τα διανύσματα υποστήριξης..... | 126 |
| Εικόνα 4.5: Βήματα συσταδοποίησης..... | 128 |
| Εικόνα 4.6: Μέθοδος Ασαφούς Συσταδοποίησης..... | 129 |

Κεφάλαιο 5:

| | |
|---|-----|
| Εικόνα 5.1: Σύγκριση των μεθόδων DWT και 1D-LBP όσον αφορά το χρόνο της CPU.... | 142 |
| Εικόνα 5.2: (a) Higuchi FD για άτομο σε επαγρύπνηση, (b) DFA για άτομο σε επαγρύπνηση, (c) Petrosian FD για άτομο σε επαγρύπνηση, (d) Higuchi FD για άτομο σε υπνηλία, (e) DFA για άτομο σε υπνηλία, (f) Petrosian FD για άτομο σε υπνηλία..... | 148 |
| Εικόνα 5.3: Διαγράμματα του αρχικού HEΓ (πρώτη γραμμή) και των αντίστοιχών του BLIMFs (γραμμές από δύο έως δεκαέξι)..... | 151 |
| Εικόνα 5.4: Σφάλματα ταξινόμησης με μεταβολή του αριθμού των αναπτυγμένων δέντρων, χρησιμοποιώντας τέσσερα κριτήρια..... | 153 |
| Εικόνα 5.5: Αποδόσεις του ταξινομητή τυχαίου δάσους με τη μεταβολή του α , χρησιμοποιώντας διαφορετικά κριτήρια. (a) Αποδόσεις του ταξινομητή τυχαίου δάσους με τη μεταβολή του α , χρησιμοποιώντας το κριτήριο FPE. (b) Αποδόσεις του ταξινομητή τυχαίου δάσους με τη μεταβολή του α , χρησιμοποιώντας το κριτήριο AIC. (c) Αποδόσεις του ταξινομητή τυχαίου δάσους με τη μεταβολή του α , χρησιμοποιώντας το κριτήριο BIC. (d) Αποδόσεις του ταξινομητή τυχαίου δάσους με τη μεταβολή του α , χρησιμοποιώντας το κριτήριο CAT..... | 154 |
| Εικόνα 5.6: Αποδόσεις του ταξινομητή τυχαίου δάσους με τη μεταβολή του α , χρησιμοποιώντας διαφορετικά AR μοντέλα σταθερής τάξης. (a) Αποδόσεις του ταξινομητή τυχαίου δάσους με τη μεταβολή του α , χρησιμοποιώντας AR μοντέλα έκτης τάξης. (b) Αποδόσεις του ταξινομητή τυχαίου δάσους με τη μεταβολή του α , χρησιμοποιώντας AR μοντέλα έβδομης τάξης. (c) Αποδόσεις του ταξινομητή τυχαίου δάσους με τη μεταβολή του α , χρησιμοποιώντας AR μοντέλα όγδοης τάξης. (d) Αποδόσεις του ταξινομητή τυχαίου δάσους με τη μεταβολή του α , χρησιμοποιώντας AR μοντέλα ένατης τάξης. (e) Αποδόσεις του ταξινομητή τυχαίου δάσους με τη μεταβολή του α , χρησιμοποιώντας AR μοντέλα δέκατης τάξης..... | 155 |
| Εικόνα 5.7: Μέση απόδοση των συστημάτων ταξινόμησης με τυπική απόκλιση..... | 159 |
| Εικόνα 5.8: Απόδοση των συστημάτων ταξινόμησης για υποκείμενα με (a) εξαιρετική, (b) καλή και (c) κανονική απόκριση VEP..... | 160 |

Κατάλογος Πινάκων

Κεφάλαιο 3:

| | |
|---|----|
| Πίνακας 3.1: Σύνοψη του αλγορίθμου SFFS..... | 41 |
| Πίνακας 3.2: Τα εύρη των συχνοτήτων για κάθε έναν λεπτομερή συντελεστή DWT..... | 81 |
| Πίνακας 3.3: Ταξινόμηση των χτύπων αρρυθμίας με βάση το πρότυπο ANSI/AAMI EC57:1998..... | 84 |

Κεφάλαιο 5:

| | |
|---|-----|
| Πίνακας 5.1: Πίνακας Σύγκρισης και Αντίστοιχα Σύνολα..... | 138 |
| Πίνακας 5.2: Αποτελέσματα ταξινόμησης από πέντε διαφορετικούς ταξινομητές για τα χαρακτηριστικά LBP^{all} | 141 |
| Πίνακας 5.3: Αποτελέσματα ταξινόμησης από πέντε διαφορετικούς ταξινομητές για τα χαρακτηριστικά LBP^{u2} | 141 |
| Πίνακας 5.4: Πειραματικά αποτελέσματα του ταξινομητή BayesNet για τα χαρακτηριστικά LBP^{all} | 141 |
| Πίνακας 5.5: Πειραματικά αποτελέσματα του ταξινομητή BayesNet για τα χαρακτηριστικά LBP^{u2} | 142 |
| Πίνακας 5.6: Σύγκριση των αναφερθέντων εργασιών πάνω στην ταξινόμηση επιληπτικών ΗΕΓ σημάτων..... | 143 |
| Πίνακας 5.7: Απόδοση ταξινόμησης για τη μέθοδο 10-fold cross validation..... | 144 |
| Πίνακας 5.8: Confusion matrix of SVM using PUK kernel..... | 145 |
| Πίνακας 5.9: Confusion matrix of SVM using Poly kernel..... | 145 |
| Πίνακας 5.10: Confusion matrix of SVM using normalized Poly kernel..... | 145 |
| Πίνακας 5.11: Confusion matrix of SVM using RBF kernel..... | 145 |
| Πίνακας 5.12: Confusion matrix of LS-SVM using Polynomial kernel..... | 145 |
| Πίνακας 5.13: Confusion matrix of LS-SVM using RBF kernel..... | 145 |
| Πίνακας 5.14: Confusion matrix of ANN..... | 145 |
| Πίνακας 5.15: Αξιολόγηση της απόδοσης ταξινόμησης για το πρώτο σετ δεδομένων ΗΕΓ με χρήση των SVM, LS-SVM και ANN..... | 146 |
| Πίνακας 5.16: Απόδοση των ταξινομητών SVM με πυρήνα PUK, LS-SVM με πολυωνυμικό πυρήνα και ANN για τη ζώνη συχνοτήτων άλφα-βήτα..... | 149 |
| Πίνακας 5.17: Συγκριτική μελέτη μεταξύ της παρούσας εργασίας και προηγούμενων ερευνητικών εργασιών δημοσιευμένων στη βιβλιογραφία..... | 150 |
| Πίνακας 5.18: Στατιστικές τιμές (μέση τιμή \pm τυπική απόκλιση) της φυσιολογικής τάξης των ΗΕΓ..... | 152 |
| Πίνακας 5.19: Στατιστικές τιμές (μέση τιμή \pm τυπική απόκλιση) της τάξης των ΗΕΓ στο διάστημα μεταξύ δύο κρίσεων..... | 152 |
| Πίνακας 5.20: Στατιστικές τιμές (μέση τιμή \pm τυπική απόκλιση) της τάξης των ΗΕΓ εν μέσω κρίσης..... | 152 |
| Πίνακας 5.21: Οι τιμές του p για διάφορους συνδυασμούς χρησιμοποιώντας το Wilcoxon rank sum test βασισμένο στην ακρίβεια..... | 156 |
| Πίνακας 5.22: Οι τιμές του p για διάφορους συνδυασμούς χρησιμοποιώντας το Wilcoxon rank sum test βασισμένο στην ευαισθησία..... | 156 |
| Πίνακας 5.23: Οι τιμές του p για διάφορους συνδυασμούς χρησιμοποιώντας το Wilcoxon rank sum test βασισμένο στην εξειδίκευση..... | 156 |
| Πίνακας 5.24: Οι τιμές του p για διάφορους συνδυασμούς χρησιμοποιώντας το Wilcoxon rank sum test βασισμένο στην τιμή θετικής πρόβλεψης..... | 156 |
| Πίνακας 5.25: Συνολικά Αποτελέσματα Αξιολόγησης..... | 165 |
| Πίνακας 5.26: Συνολική ακρίβεια, μέση ακρίβεια όλων των τάξεων και ποσοστά ακρίβειας της κάθε τάξης που επιτεύχθηκαν με τους ταξινομητές SVM-RBF και NN..... | 168 |

| | |
|--|-----|
| Πίνακας 5.27: Αποτελέσματα ταξινόμησης των συνδυασμένων γραμμικών και μη γραμμικών μεθόδων, με δύο διαφορετικούς ταξινομητές..... | 169 |
| Πίνακας 5.28: Σύγκριση της απόδοσης ταξινόμησης του προτεινόμενου συστήματος και άλλων ήδη υπαρχόντων συστημάτων..... | 170 |
| Πίνακας 5.29: Συγκεντρωτικός συγκριτικός πίνακας με τα βέλτιστα αποτελέσματα κάθε μεθόδου..... | 171 |

ΚΕΦΑΛΑΙΟ 1

Εισαγωγή

1.1 Σκοπός διπλωματικής

Ο σκοπός της εργασίας αυτής είναι η σε βάθος ανάλυση ενός συστήματος υποβοήθησης της διάγνωσης και πιο συγκεκριμένα των δύο βασικών βαθμίδων του, δηλαδή της βαθμίδας εξαγωγής χαρακτηριστικών και της βαθμίδας ταξινόμησης των βιοσημάτων στις διάφορες τάξεις (κατηγορίες).

Η χρησιμότητα ενός τέτοιου συστήματος είναι εμφανής ιδιαίτερα στον τομέα των ιατρικών εφαρμογών, όπου το ζητούμενο είναι η έγκαιρη και έγκυρη διάγνωση, αφού από αυτά κρίνεται η υγεία και πολλές φορές και η ζωή των ασθενών. Για αυτό το λόγο, είναι λογικό να θέλουμε να μειώσουμε τα λάθη που γίνονται στις διαγνώσεις εξαιτίας του ανθρώπινου παράγοντα, αλλά και να αυξήσουμε την ικανότητα ανίχνευσης των ασθενειών, με τη χρήση της τεχνητής νοημοσύνης.

Με τα χρόνια έχουν αναπτυχθεί άπειρες τεχνικές για την εξαγωγή των κατάλληλων χαρακτηριστικών από ένα βιοσήμα έτσι ώστε αυτό να ταξινομείται σωστά από τον αντίστοιχο ταξινομητή. Καταλαβαίνουμε, επομένως, ότι είναι υψίστης σημασίας η ανάπτυξη ενός βέλτιστου συνδυασμού μιας μεθόδου εξαγωγής και ενός αλγόριθμου ταξινόμησης –ανάλογα πάντα με την περίπτωση και την εφαρμογή– ο οποίος θα δίνει πολύ υψηλή απόδοση ταξινόμησης.

Στην παρούσα εργασία, λοιπόν, γίνεται μια σύγκριση διαφόρων μεθόδων που προτείνονται στη βιβλιογραφία για την ανίχνευση διαφόρων ασθενειών ή καταστάσεων των ατόμων, όπως η επιληψία, η νοητική κατάσταση του ατόμου (εργήγορη ή υπνηλία) κ.ά., με σκοπό την εξαγωγή συμπερασμάτων για το ποια μέθοδος είναι καλύτερη για κάθε εφαρμογή.

1.2 Διάρθρωση

Η παρούσα διπλωματική εργασία διαρθρώνεται στα εξής κεφάλαια: στο 1^ο κεφάλαιο παρουσιάζεται ο σκοπός και η διάρθρωση της εργασίας. Στο κεφάλαιο 2, ο αναγνώστης έρχεται σε μια πρώτη επαφή με το θεωρητικό υπόβαθρο και τις έννοιες που χρησιμοποιούνται συχνά καθ' όλη τη μελέτη και είναι απαραίτητες για την καλή κατανόησή της, όπως η αναγνώριση και η ταξινόμηση προτύπων, η επιβλεπόμενη, μη-επιβλεπόμενη και ημι-επιβλεπόμενη μάθηση, το βιοσήμα, η επιλογή και εξαγωγή των χαρακτηριστικών και τα συστήματα υποβοήθησης της διάγνωσης. Στο 3^ο κεφάλαιο μελετώνται κάποιοι αλγόριθμοι επιλογής χαρακτηριστικών, ενώ έμφαση δίνεται κυρίως στην ανάλυση μερικών από τις πιο πρόσφατες μεθόδους εξαγωγής χαρακτηριστικών που έχουν δημοσιευθεί στη βιβλιογραφία. Στο κεφάλαιο 4, που ακολουθεί, παρατίθενται κάποιοι από τους γνωστότερους αλγόριθμους ταξινόμησης και εξηγείται αναλυτικά η λειτουργία τους. Στο κεφάλαιο 5, παρουσιάζονται αρχικά κάποιες μέθοδοι αξιολόγησης της απόδοσης των ταξινομητών, ενώ στη συνέχεια παρατίθενται συνολικοί πίνακες με τα αποτελέσματα της σύγκρισης μεταξύ των διαφόρων μεθόδων. Τέλος, στο 6^ο κεφάλαιο αποτυπώνονται τα συμπεράσματα που προκύπτουν από την εργασία και τονίζονται οι πιθανές μελλοντικές επεκτάσεις ενός συστήματος υποβοήθησης της διάγνωσης που χρησιμοποιεί βέλτιστες τεχνικές εξαγωγής χαρακτηριστικών και ταξινόμησης.

ΚΕΦΑΛΑΙΟ 2

Θεωρητικό Υπόβαθρο: Αναγνώριση Προτύπων και Ταξινόμηση Βιολογικών Σημάτων - Συστήματα Υποβοήθησης της Διάγνωσης

2.1 Αναγνώριση Προτύπων

2.1.1 Τεχνητή Νοημοσύνη - Ευφυείς μηχανές

Στην παρούσα εργασία προσπαθούμε να μελετήσουμε βήμα-βήμα μία ευφυή μηχανή, η οποία θα μας βοηθήσει να βρούμε λύσεις σε προβλήματα ιατρικής διάγνωσης. Ειδικότερα, θέλουμε να αναλύσουμε ένα ευφυές υπολογιστικό σύστημα, δηλαδή ένα πρόγραμμα σε υπολογιστή που να έχει κάποια έξυπνη συμπεριφορά. Η έννοια της «έξυπνάδας» ενός υπολογιστικού συστήματος αναφέρεται σε ικανότητα μάθησης, σε ικανότητα λύσης δύσκολων προβλημάτων, σε ικανότητα γενίκευσης, σε ικανότητα εξαγωγής συμπερασμάτων και άλλα. Γενικότερα, έξυπνο είναι ένα υπολογιστικό σύστημα (μια μηχανή γενικότερα) όταν μιμείται τον τρόπο λειτουργίας του ανθρώπινου εγκεφάλου. Σύμφωνα, λοιπόν, με τα παραπάνω, μια μηχανή για να χαρακτηριστεί έξυπνη (ευφυής), πρέπει να είναι ικανή να μιμείται την ανθρώπινη συμπεριφορά [3]. Ο κλάδος της πληροφορικής ο οποίος ασχολείται με τη σχεδίαση και την υλοποίηση υπολογιστικών συστημάτων που μιμούνται στοιχεία της ανθρώπινης συμπεριφοράς, τα οποία υπονοούν έστω και στοιχειώδη ευφυΐα, ονομάζεται Τεχνητή Νοημοσύνη.

Ανεξαρτήτως, τώρα, του είδους του ευφυούς συστήματος που κατασκευάζεται κάθε φορά, υπάρχουν κάποια βασικά προβλήματα που προσπαθεί να αντιμετωπίσει η Τεχνητή Νοημοσύνη, τα οποία απαιτούν ευφυΐα και που μέχρι πρόσφατα μόνο ο άνθρωπος ήταν ικανός να λύσει. Τέτοια προβλήματα είναι για παράδειγμα το παίξιμο παιχνιδιών (π.χ. σκάκι), η αναγνώριση φωνής, η υπολογιστική όραση, η γενικότερη ανάπτυξη αντίληψης-αισθήσεων στις μηχανές, η επίλυση εξειδικευμένων προβλημάτων όπως τα προβλήματα ιατρικής διάγνωσης και άλλα. Μπορούμε να πούμε ότι η Τεχνητή Νοημοσύνη προσπαθεί να φτιάξει μηχανές που να ανεβαίνουν σταδιακά κάποια βασικά σκαλοπάτια ανθρώπινης ευφυΐας. Τέτοια είναι η αντίληψη-αντίδραση, ο προσανατολισμός, η όραση, η κοινή λογική, η δυνατότητα επικοινωνίας, ο σχεδιασμός δράσης, η εξειδίκευση [3].

Στην παρούσα εργασία ασχολούμαστε με προβλήματα ιατρικής διάγνωσης και έτσι, θα αναλύσουμε τη λειτουργία μιας μηχανής-εργαλείου που θα ενσωματώνει κάποια ευφυΐα και θα έχει τη δυνατότητα να παρέχει μία εξειδικευμένη γνώμη στον γιατρό σε ό, τι αφορά τη διάγνωση μιας ασθένειας [3].

2.1.2 Εισαγωγή στην Αναγνώριση Προτύπων


Αναγνώριση προτύπων είναι η επιστημονική αρχή (κλάδος του machine learning), που επικεντρώνεται στην αναγνώριση κανονικοτήτων (μοτίβων), μεταξύ των διαθέσιμων *δεδομένων*, με στόχο την ταξινόμησή τους σε έναν αριθμό κατηγοριών ή *τάξεων* [1a], [2]. Ανάλογα με την εφαρμογή τους, τα δεδομένα αυτά μπορεί να είναι εικόνες, κυματομορφές ή οποιουδήποτε τύπου μετρήσεις, οι οποίες χρειάζεται να ταξινομηθούν. Η αναφορά στα δεδομένα αυτά, γίνεται με τον γενικό όρο *πρότυπα* (patterns). Η αναγνώριση προτύπων έχει μεγάλη ιστορία, αλλά πριν το 1960 ήταν κυρίως το αποτέλεσμα θεωρητικής έρευνας στο πεδίο της στατιστικής. Στη συνέχεια,

η έλευση των ηλεκτρονικών υπολογιστών αύξησε την ανάγκη για πρακτικές εφαρμογές της αναγνώρισης προτύπων, γεγονός που με τη σειρά του δημιούργησε απαιτήσεις για περαιτέρω θεωρητικές εξελίξεις. Καθώς η κοινωνία μας περνά από τη βιομηχανική στη μετα-βιομηχανική της φάση, ο αυτοματισμός στη βιομηχανική παραγωγή και η ανάγκη για διαχείριση και ανάκτηση των πληροφοριών, γίνονται ολοένα και πιο σημαντικά. Η τάση αυτή έχει ωθήσει την αναγνώριση προτύπων στο επίπεδο των σημερινών μηχανολογικών εφαρμογών και έρευνας. Έτσι, η αναγνώριση προτύπων είναι πλέον αναπόσπαστο κομμάτι της σύγχρονης τεχνολογίας και συναντάται στα περισσότερα συστήματα μηχανικής νοημοσύνης (machine intelligence) που έχουν κατασκευαστεί με σκοπό τη λήψη αποφάσεων. Οι σημαντικότερες εφαρμογές της είναι: στην όραση υπολογιστών, στην αναγνώριση δακτυλικών αποτυπωμάτων, στην πιστοποίηση υπογραφής, στην ανάκτηση κειμένου, στην αναγνώριση προσώπου και χειρονομίας, την αναγνώριση φωνής και στην υποβοήθηση της διάγνωσης μέσω υπολογιστή [2].

2.1.3 Βασική Φιλοσοφία και Μεθοδολογικές Κατευθύνσεις της Αναγνώρισης Προτύπων - Ταξινόμηση Προτύπων

Ο ορισμός του προβλήματος της ταξινόμησης προτύπων δεν διαφέρει ουσιαστικά από τον αντίστοιχο που είδαμε για την αναγνώριση προτύπων. Γενικά, ένα σύστημα ταξινόμησης παίρνει ως είσοδο δεδομένα και βγάζει στην έξοδο τις κατηγορίες, στις οποίες αυτά αντιστοιχούν (π.χ. διαβητικός ή όχι διαβητικός, με καρδιακή ανεπάρκεια ή υγιής και άλλα που δεν περιορίζονται στον ιατρικό χώρο). Ο λόγος που διαχωρίζουμε τα δύο αυτά προβλήματα είναι ότι για την αναγνώριση ενός προτύπου απαιτούνται κι άλλες λειτουργίες πέραν της ταξινόμησης. Οι λειτουργίες αυτές είναι βοηθητικές και γίνονται μόνο και μόνο για να διευκολυνθεί και να γίνει αποδοτικότερη η ταξινόμηση.


Για να εισάγουμε, τώρα, τις βασικές έννοιες της αναγνώρισης προτύπων, θα χρησιμοποιήσουμε ένα απλουστευμένο παράδειγμα. Υποθέτουμε λοιπόν, ότι έχουμε δύο τάξεις A και B και έναν αριθμό προτύπων, εκ των οποίων κάποια είναι γνωστό ότι προέρχονται από την τάξη A και κάποια από την τάξη B. Στο παρακάτω διάγραμμα (Σχήμα 2.1) φαίνονται δύο περιοχές (o) και (+), όπως δημιουργήθηκαν από τις μετρήσεις της μέσης τιμής και της τυπικής απόκλισης των προτύπων και οι οποίες αντιστοιχούν στις τάξεις A και B, αντίστοιχα.



Σχήμα 2.1: Γραφική παράσταση της μέσης τιμής προς την τυπική απόκλιση για έναν αριθμό διαφορετικών προτύπων που προέρχονται από την τάξη A (o) και την τάξη B (+). Σε αυτή την περίπτωση, μια ευθεία γραμμή χωρίζει τις δύο κλάσεις [2].


Το πρώτο βήμα, είναι να αναγνωρίσουμε τις μετρήσιμες ποσότητες που κάνουν τις δύο περιοχές (ο) και (+), να διαφέρουν μεταξύ τους. Οι μετρήσεις αυτές (όπως π.χ. η μέση τιμή και η τυπική απόκλιση), που χρησιμοποιούνται για την ταξινόμηση των προτύπων, ονομάζονται *χαρακτηριστικά* (features). Στη γενική περίπτωση χρησιμοποιούνται n στον αριθμό χαρακτηριστικά x_i , με $i=1,2,3,\dots,n$, και σχηματίζουν το *διάνυσμα χαρακτηριστικών γνωρισμάτων* (feature vector) $x=[x_1,x_2,\dots,x_n]^T$. Κάθε ένα από τα διανύσματα αυτά προσδιορίζει μοναδικά ένα μόνο πρότυπο. Το σύνολο των χαρακτηριστικών που χαρακτηρίζουν ένα πρότυπο και τα οποία διατάσσονται σε ένα διάνυσμα, έχει μέγεθος ίσο με τη διάσταση του χώρου. Δηλαδή, σε ένα διδιάστατο χώρο θα έχουμε δύο χαρακτηριστικά, σε έναν τριδιάστατο τρία κοκ. Το επόμενο βήμα είναι να βρούμε τη γραμμή (ή την επιφάνεια) η οποία διαχωρίζει βέλτιστα το χώρο των χαρακτηριστικών (feature space) σε περιοχές οι οποίες αντιστοιχούν είτε στην τάξη A, είτε στην τάξη B. Η γραμμή (ή επιφάνεια) αυτή, ονομάζεται *αποφασιστική γραμμή* (ή αποφασιστική επιφάνεια αντίστοιχα) και αποτελεί τον *ταξινομητή* (classifier). Στο παράδειγμά μας ο ταξινομητής είναι μια ευθεία γραμμή που διαχωρίζει πλήρως τις περιοχές (ο) και (+). Αν ένα διάνυσμα χαρακτηριστικών γνωρισμάτων x , το οποίο αντιστοιχεί σε ένα άγνωστο πρότυπο, βρεθεί στην περιοχή της τάξης A, ταξινομείται ως τάξης A, αλλιώς ως τάξης B, χωρίς αυτό να σημαίνει αναγκαστικά ότι η απόφαση που πάρθηκε είναι η σωστή. Αν η απόφαση δεν είναι σωστή, έχουμε *εσφαλμένη ταξινόμηση* (misclassification). Για να μπορέσουμε να σχεδιάσουμε τον ταξινομητή, εκμεταλλευόμαστε το γεγονός ότι γνωρίζουμε εκ των προτέρων τις ετικέτες (τάξη A ή B) για κάποια συγκεκριμένα πρότυπα. Τα πρότυπα (ή διανύσματα χαρακτηριστικών γνωρισμάτων) των οποίων οι πραγματικές τάξεις είναι γνωστές και τα οποία χρησιμοποιούνται για τη σχεδίαση του ταξινομητή είναι γνωστά ως *training patterns* (ή training feature vectors) [2].

Γενικά, τα προβλήματα ταξινόμησης είναι δύο κατηγοριών. Αυτά που είναι γραμμικά διαχωρίσιμα και αυτά που δεν είναι. Η γραμμική διαχωρισιμότητα αφορά το πώς κατατάσσονται τα δεδομένα του προβλήματος στο διανυσματικό χώρο. Για χώρο δύο διαστάσεων, αν οι δύο τάξεις μπορούν να χωριστούν με ευθεία γραμμή, ώστε σε κάθε πλευρά της να βρίσκονται πρότυπα μίας τάξης και μόνο, τότε μιλάμε για ένα *γραμμικά διαχωρίσιμο* πρόβλημα. Στη γενική περίπτωση ενός διανυσματικού χώρου n διαστάσεων ο αντίστοιχος διαχωρισμός πρέπει να γίνεται με ένα υπερεπίπεδο στον n -διάστατο αυτό χώρο (για παράδειγμα ένα επίπεδο στον τρισδιάστατο χώρο). Στο Σχήμα 2.2 τα πρότυπα σημειώνονται με (ο) ή (+) ανάλογα με την τάξη στην οποία ανήκουν.




Σχήμα 2.2: Ένα γραμμικά διαχωρίσιμο πρόβλημα. Τα πρότυπα που παριστάνονται με “ο” ανήκουν στη μία τάξη και αυτά με “+” στην άλλη. Η διάταξη των προτύπων στο χώρο των δεδομένων επιτρέπει το διαχωρισμό των προτύπων της μίας τάξης από αυτά της άλλης με ευθεία γραμμή [2].

Αν, αντίθετα, οι τάξεις δεν μπορούν να χωριστούν με τον προηγούμενο τρόπο, όπως φαίνεται στο Σχήμα 2.3, τότε το πρόβλημα λέγεται *μη-γραμμικά διαχωρίσιμο*. Σε γραμμικά διαχωρίσιμα προβλήματα είναι φανερό ότι το μόνο που αρκεί να κάνει ένας ταξινομητής είναι να βρει μία ευθεία (ή γενικά ένα υπερεπίπεδο) που χωρίζει τις τάξεις. Σε μη-γραμμικά διαχωρίσιμα προβλήματα η διαχωριστική επιφάνεια των δύο τάξεων είναι πιο πολύπλοκη και κατά συνέπεια θα είναι πιο δύσκολο για έναν ταξινομητή να διαχωρίσει τις τάξεις. Κάποιο συγκεκριμένο πρόβλημα δεν μπορεί να χαρακτηριστεί γραμμικά διαχωρίσιμο ή όχι εκ των προτέρων. Η γραμμικότητα εξαρτάται κάθε φορά από τα δεδομένα που έχουμε για το πρόβλημα. Η πλειονότητα πάντως των προβλημάτων, και μάλιστα τα πραγματικά προβλήματα, είναι μη-γραμμικά διαχωρίσιμα [3].



Σχήμα 2.3: Ένα μη γραμμικά διαχωρίσιμο πρόβλημα. Τα πρότυπα των δύο τάξεων δεν μπορούν να διαχωριστούν με μία μόνο ευθεία γραμμή [2].

Η διαδικασία της αναγνώρισης προτύπων ακολουθεί τα βασικά στάδια ενός συστήματος αναγνώρισης προτύπων. Στο Σχήμα 2.4 απεικονίζονται τα διάφορα στάδια που ακολουθούνται κατά την κατασκευή ενός συστήματος ταξινόμησης (όπως π.χ. το σύστημα υποβοήθησης της διάγνωσης που μελετάται στην παρούσα εργασία). Όπως είναι προφανές από τα βέλη, τα στάδια αυτά δεν είναι ανεξάρτητα μεταξύ τους. Αντιθέτως, εξαρτώνται το ένα από το άλλο και ανάλογα με τα αποτελέσματα, κάποιος μπορεί να επιστρέψει στο σχεδιασμό προηγούμενων σταδίων με σκοπό να βελτιώσει τη συνολική επίδοση του συστήματος. Επιπλέον, υπάρχουν ορισμένες μέθοδοι οι οποίες συνενώνουν στάδια, όπως για παράδειγμα το feature selection stage και το classifier design stage, σε ένα κοινό βελτιστοποιημένο στάδιο [2].



Σχήμα 2.4: Τα βασικά στάδια που εμπλέκονται στο σχεδιασμό ενός συστήματος ταξινόμησης.

Εδώ πρέπει να τονίσουμε ότι μία μηχανή Αναγνώρισης Προτύπων δεν είναι απαραίτητο να κάνει πάντα συλλογή και προ-επεξεργασία δεδομένων. Υπάρχει περίπτωση να παίρνει τα δεδομένα έτοιμα –θεωρώντας ότι έχουν προκύψει από κάποιες τέτοιες διαδικασίες– και να αναλαμβάνει μόνο την ταξινόμηση. Σε αυτή την κατηγορία εμπίπτει και το σύστημα που μελετάμε εμείς, σε αυτή την εργασία.


Σε επόμενο κεφάλαιο, παρουσιάζονται αναλυτικά σημαντικά ζητήματα που σχετίζονται με την κατασκευή ενός συστήματος αναγνώρισης προτύπων όπως: ποια είναι τα χαρακτηριστικά που χρησιμοποιούμε για ταξινόμηση και πώς παράγονται (*feature generation stage*), ποιός είναι ο κατάλληλος αριθμός χαρακτηριστικών που πρέπει να χρησιμοποιήσουμε (*feature selection stage*), πώς σχεδιάζουμε τον ταξινομητή (*classifier design stage*) και πώς μπορούμε να αξιολογήσουμε την επίδοση του ταξινομητή όταν αυτός έχει σχεδιαστεί (*system evaluation stage*) [2].

2.1.4 Επιβλεπόμενη, Μη-επιβλεπόμενη και Ημι-επιβλεπόμενη Μάθηση

Στην προηγούμενη παράγραφο υποθέσαμε ότι είχαμε στη διάθεσή μας ένα σύνολο δεδομένων εκπαίδευσης (*training data*) και ότι ο ταξινομητής σχεδιάστηκε με τη βοήθεια αυτών των πληροφοριών που είναι γνωστές εκ των προτέρων. Αυτή είναι γνωστή ως επιβλεπόμενη αναγνώριση προτύπων (*supervised pattern recognition*) ή στο γενικότερο πλαίσιο του machine learning, ως επιβλεπόμενη μάθηση. Ωστόσο, δεν υπάρχει πάντα ένα σύνολο δεδομένων των οποίων οι τάξεις να είναι γνωστές και έτσι εισάγεται ένα άλλο είδος αναγνώρισης προτύπων, για το οποίο δεν υπάρχουν διαθέσιμα δεδομένα εκπαίδευσης γνωστών τάξεων. Σε προβλήματα τέτοιου τύπου, μας δίνεται ένα σύνολο διανυσμάτων χαρακτηριστικών γνωρισμάτων x και ο στόχος μας είναι να εντοπίσουμε τις βασικές ομοιότητες μεταξύ τους και να ομαδοποιήσουμε τα “παρόμοια” διανύσματα. Αυτή είναι γνωστή ως αναγνώριση προτύπων χωρίς επίβλεψη (*unsupervised pattern recognition*) ή μάθηση χωρίς επίβλεψη (*unsupervised learning*) ή συσταδοποίηση (*clustering*). Τέτοια προβλήματα προκύπτουν σε πολλές εφαρμογές στις κοινωνικές επιστήμες και στη μηχανική. Η ημι-επιβλεπόμενη μάθηση (*semi-supervised learning*) για τη σχεδίαση ενός συστήματος ταξινόμησης, μοιράζεται τους ίδιους στόχους με την επιβλεπόμενη μάθηση, ωστόσο σε αυτήν την περίπτωση ο σχεδιαστής έχει στη διάθεσή του ένα σύνολο προτύπων με άγνωστη τάξη προέλευσης (*unlabeled*) σε συνδυασμό με *training patterns* των οποίων η τάξη είναι γνωστή (*labeled*). Η ημι-επιβλεπόμενη μάθηση μπορεί να φανεί χρήσιμη όταν ο σχεδιαστής του συστήματος έχει πρόσβαση σε ένα σχετικά μικρό αριθμό από *labeled data*. Σε τέτοιες περιπτώσεις, οι πρόσθετες πληροφορίες που μπορεί να εξάγει από τα *unlabeled* δεδομένα, οι οποίες είναι σχετικές με τη γενική δομή των διαθέσιμων δεδομένων, μπορεί να χρησιμεύσουν στη βελτίωση της σχεδίασης του συστήματος [2].

Αφού ορίσαμε τις βασικές έννοιες της ταξινόμησης προτύπων, παραθέτουμε ένα απλό παράδειγμα για την καλύτερη κατανόησή τους. Θεωρούμε, λοιπόν, ως παράδειγμα το πρόβλημα του καθορισμού του αν κάποιος είναι παχύσαρκος ή όχι. Το πρόβλημα αυτό είναι δύο τάξεων (παχύσαρκος και όχι παχύσαρκος) και μπορούμε να επιλέξουμε ποια θα είναι τα χαρακτηριστικά που θα καθορίζουν πού κατατάσσεται ένα πρότυπο. Αν λάβουμε υπόψη μόνο το ύψος και το βάρος, τότε έχουμε διδιάστατο χώρο. Αν συνυπολογίσουμε και το ποσοστό λίπους στο σώμα (το οποίο μπορεί να προκύψει με κατάλληλες μετρήσεις), τότε περνάμε σε τριδιάστατο χώρο. Ας μείνουμε στο χώρο των δύο διαστάσεων με χαρακτηριστικά το ύψος και το βάρος [3]. Ένα πρότυπο του προβλήματος αυτού θα είναι ένα διάνυσμα με δύο στοιχεία, π.χ. [180,

75], όπου το πρώτο στοιχείο είναι το ύψος σε εκατοστά και το δεύτερο το βάρος σε κιλά. Αν με 0 συμβολίσουμε την τάξη «μη παχύσαρκος» και με 1 την τάξη «παχύσαρκος» τότε το σύστημα πρέπει να λειτουργεί σύμφωνα με τη διάταξη του σχήματος 2.5.



Σχήμα 2.5: Παράδειγμα εισόδων και εξόδων ενός συστήματος ταξινόμησης προτύπων για ένα υποθετικό πρόβλημα. Η είσοδος με τιμή 180 αντιστοιχεί στο ύψος ενός ανθρώπου σε εκατοστά ενώ η άλλη στο βάρος του σε κιλά. Η έξοδος δείχνει ότι ο άνθρωπος με αυτό το ύψος και βάρος δεν είναι παχύσαρκος [3].

Έτσι, ένα δεδομένο εκπαίδευσης για επιβλεπόμενη μάθηση θα μπορούσε να ήταν το $[180,75]:0$. Μαζί με τα δεδομένα $[150,80]:1$, $[160,60]:0$, $[210,120]:0$ και $[170,85]:1$, θα μπορούσε να αποτελεί ένα σύνολο εκπαίδευσης (*training set*) για έναν αλγόριθμο επιβλεπόμενης μάθησης. Αυτό που ουσιαστικά γίνεται στην περίπτωση αυτή, είναι ότι το σύστημα χρησιμοποιεί την πληροφορία της τάξης κάθε προτύπου για να φτιάξει την απεικόνιση εισόδων-εξόδων που επιλύει το πρόβλημα. Στην περίπτωση, τώρα, της μη επιβλεπόμενης μάθησης, το σύνολο εκπαίδευσης είναι όπως το προηγούμενο με τη διαφορά ότι δεν υπάρχουν τα 0 και τα 1 που δείχνουν την κατηγορία. Εδώ, το σύστημα προσπαθεί μόνο του να φτιάξει την απεικόνιση εισόδων-εξόδων στηριζόμενο στις εσωτερικές σχέσεις μεταξύ των δεδομένων εκπαίδευσης, όπως π.χ. στις σχετικές τους αποστάσεις στο διανυσματικό χώρο.

2.1.5 Αναγνώριση Προτύπων και Συστήματα Υποβοήθησης Διάγνωσης

Η υποβοηθούμενη από υπολογιστή διάγνωση με την οποία ασχολούμαστε στην παρούσα εργασία, είναι μια σημαντική εφαρμογή της αναγνώρισης προτύπων, η οποία στοχεύει στο να βοηθήσει τους γιατρούς στη λήψη αποφάσεων που αφορούν τη διάγνωση κάποιας ασθένειας. Η τελική διάγνωση, φυσικά, γίνεται από τον αρμόδιο γιατρό. Η υποβοηθούμενη διάγνωση έχει μεγάλο ενδιαφέρον και έχει εφαρμοστεί σε ποικιλία ιατρικών δεδομένων, όπως ακτίνες-X, αξονικές τομογραφίες, υπερήχους, ηλεκτροκαρδιογραφήματα (ΗΚΓ) και ηλεκτροεγκεφαλογραφήματα (ΗΕΓ). Η ανάγκη για συστήματα υποβοήθησης της διάγνωσης, προκύπτει από το γεγονός ότι τα ιατρικά δεδομένα είναι συχνά δύσκολο να ερμηνευτούν και η ερμηνεία τους εξαρτάται σε μεγάλο βαθμό από τις ικανότητες του γιατρού. Ας πάρουμε για παράδειγμα τη μαστογραφία με ακτίνες X, για τον εντοπισμό του καρκίνου του μαστού. Παρόλο που η μαστογραφία είναι μέχρι στιγμής η καλύτερη μέθοδος για την ανίχνευση του καρκίνου του μαστού, το 10 με 30% των γυναικών που έχουν την ασθένεια και υποβάλλονται σε μαστογραφία, παίρνουν αρνητικά αποτελέσματα. Περίπου στα δύο τρίτα αυτών των περιπτώσεων με λανθασμένα αποτελέσματα, ο ακτινολόγος απέτυχε

να ανιχνεύσει τον καρκίνο, ο οποίος ήταν εμφανής εκ των υστέρων. Αυτό μπορεί να οφείλεται στην κακή ποιότητα εικόνας, στην κούραση των ματιών του ακτινολόγου ή στη λεπτή φύση των ευρημάτων. Ωστόσο, το ποσοστό των επιτυχημένων διαγνώσεων αυξάνεται αισθητά με μια δεύτερη ανάγνωση της μαστογραφίας από άλλο ακτινολόγο. Έτσι, είναι σημαντική η ανάπτυξη ενός συστήματος αναγνώρισης προτύπων το οποίο να βοηθά τους γιατρούς παρέχοντάς τους μια «δεύτερη γνώμη». Παράλληλα, η αύξηση των επιτυχημένων διαγνώσεων που στηρίζονται στις μαστογραφίες θα προκαλέσει μείωση στον αριθμό των ασθενών που πιθανώς έχουν καρκίνο και οι οποίοι πρέπει να υποβληθούν σε βιοψία για να το επιβεβαιώσουν, με τις γνωστές-σχετιζόμενες με τις χειρουργικές επεμβάσεις- επιπλοκές [2].

2.2 Η Ιατρική Διάγνωση σαν πρόβλημα της Αναγνώρισης Προτύπων

Ιατρική διάγνωση ονομάζεται η διαδικασία του προσδιορισμού της ασθένειας ή της κατάστασης, η οποία εξηγεί τα συμπτώματα και τα σημάδια ενός ανθρώπου. Οι πληροφορίες που απαιτούνται για τη διάγνωση συγκεντρώνονται τυπικά από το ιστορικό και τη φυσική εξέταση του ατόμου που ζητά ιατρική φροντίδα. Επίσης, πολύ συχνά, μία ή περισσότερες διαγνωστικές διαδικασίες, όπως τα διαγνωστικά τεστ, συμβάλλουν και αυτά στη διαδικασία. Η διάγνωση είναι συχνά δύσκολη, επειδή πολλά συμπτώματα είναι μη ειδικά. Για παράδειγμα, η ερυθρότητα του δέρματος (ερύθημα), από μόνη της, μπορεί να είναι σημάδι πολλών διαταραχών και έτσι δεν καταδεικνύει στον επαγγελματία υγείας τι ακριβώς συμβαίνει. Σε τέτοιες περιπτώσεις πρέπει να εκτελείται διαφορική διάγνωση, στην οποία οι διάφορες πιθανές εξηγήσεις συγκρίνονται και αντιπαραβάλλονται. Η διαδικασία αυτή, περιλαμβάνει τη συσχέτιση διαφόρων στοιχείων, η οποία ακολουθείται από την αναγνώριση και τη διαφοροποίηση των προτύπων [1b]. Η ιατρική διάγνωση είναι, δηλαδή, η εξαγωγή των ιδιαίτερων χαρακτηριστικών της κατάστασης της υγείας ενός ανθρώπου και η κατάταξή της σε μια κατηγορία. Έτσι είναι φανερό πως πρόκειται για μια διαδικασία που ανήκει στον τομέα της αναγνώρισης προτύπων.

Σε μια μέθοδο αναγνώρισης προτύπων ο πάροχος χρησιμοποιεί την εμπειρία για να αναγνωρίσει ένα μοτίβο κλινικών χαρακτηριστικών [4]. Με βάση αυτό, μπορούμε να πούμε ότι η εξειδίκευση του γιατρού λειτουργεί έως ένα βαθμό με κανόνες υπόθεσης-αποτελέσματος: «αν συμβαίνει αυτό, τότε ευθύνεται εκείνο». Συνδυάζοντας έναν αριθμό τέτοιων κανόνων με πληροφορίες και γνώσεις, ο γιατρός είναι σε θέση να αναγνωρίσει την κατάσταση της υγείας ενός ανθρώπου [5]. Αυτή η «αναγνώριση» έχει μεγάλη σημασία, αφού αποτελεί το κλειδί για το πέρασμα από την ιατρική διάγνωση που γίνεται από εξειδικευμένους ανθρώπους (γιατρούς), στην ιατρική διάγνωση που γίνεται από έξυπνες μηχανές μέσω της αναγνώρισης προτύπων, για την οποία μιλήσαμε προηγουμένως.

Για να ανταποκριθεί στις απαιτήσεις μιας τέτοιας διαδικασίας ένας γιατρός πρέπει καταρχήν να έχει εμπειρία και γνώση. Ο τρόπος λειτουργίας του ανθρώπινου σώματος, η ανατομία του, η αλληλεπίδραση των διάφορων μερών μεταξύ τους, καθώς και η αλληλεπίδραση του σώματος με το περιβάλλον, πρέπει να του είναι γνωστά. Έπειτα, πρέπει να γνωρίζει το σύνολο των πιθανών ασθενειών καθώς και τα συμπτώματα που αυτά προκαλούν στην υγεία. Εκτός από τις γνώσεις, η διαδικασία της διάγνωσης απαιτεί και πληροφορία. Ο γιατρός πρέπει να εξετάσει τον πιθανό ασθενή, να πάρει δηλαδή πληροφορίες από το σώμα του και από τον ίδιο και στο τέλος να συνδυάζει τις γνώσεις, την εμπειρία (αν υπάρχει) και τις πληροφορίες αυτές και κρίνοντας αντίστροφα, από τα συμπτώματα να καταλήξει στην ασθένεια [4], [5].


Υπάρχει, δηλαδή μια απόλυτη αντιστοιχία μεταξύ των διαδικασιών που εκτελεί ένας γιατρός για τη διάγνωση μιας ασθένειας και των βημάτων που ακολουθεί μια «έξυπνη» μηχανή για την ταξινόμηση των προτύπων που εισάγονται σ' αυτή. Καταλαβαίνουμε, λοιπόν, γιατί το πρόβλημα της ιατρικής διάγνωσης μπορεί να ενταχθεί στα πλαίσια ενός γενικότερου προβλήματος της Τεχνητής Νοημοσύνης, την Αναγνώριση Προτύπων.

2.3 Βιολογικά Σήματα και Ιατρική Διάγνωση

Ως ιατρική πληροφορική (κλάδος της Βιοϊατρικής Πληροφορικής) ορίζεται, συνοπτικά, η ανάπτυξη και εκτίμηση μεθόδων και συστημάτων για συλλογή (acquisition), επεξεργασία (processing) και ερμηνεία (interpretation) δεδομένων από ασθενείς σε συνδυασμό με τη γνώση που προέρχεται από την επιστημονική έρευνα σε διάφορους τομείς όπως είναι η ιατρική/βιολογία, τα μαθηματικά, τα συστήματα πληροφοριών, η επιστήμη υπολογιστών, η στατιστική, η ανάλυση και υποστήριξη αποφάσεων, τα οικονομικά, η ψυχολογία κ.λπ. [6], [7], [8]. Εξηγήσαμε στην προηγούμενη παράγραφο γιατί η ιατρική διάγνωση με ευφυή υπολογιστικά συστήματα είναι πρόβλημα που εντάσσεται στην Αναγνώριση Προτύπων. Θα δούμε εδώ κάποιους από τους πιο συνηθισμένους τύπους προβλημάτων ιατρικής διάγνωσης και ποια είναι η συνηθέστερη μορφή δεδομένων που χρησιμοποιούνται.

Στη φάση της συλλογής των δεδομένων ένα σύστημα ιατρικής διάγνωσης μπορεί να λειτουργήσει περίπου όπως ο γιατρός. Όπως ο τελευταίος εξετάζει το σώμα του υποψήφιου ασθενούς και παίρνει κατάλληλες μετρήσεις συγκεντρώνοντας πληροφορίες, έτσι και το σύστημα μπορεί να συλλέξει δεδομένα. Δεν είναι, βέβαια, απαραίτητο να γίνεται η συλλογή των δεδομένων απευθείας από το ίδιο το σύστημα ή και ακόμα γενικότερα από κάποιο ειδικό σύστημα. Ο ειδικός γιατρός μπορεί να τα παρέχει αφού τα έχει συλλέξει, τα έχει αποθηκεύσει και τα έχει ομαδοποιήσει με κατάλληλο τρόπο.

Μία συνηθισμένη μορφή δεδομένων είναι τα αριθμητικά και τα λεξικογραφικά δεδομένα. Με τον όρο λεξικογραφικά, εννοούμε δεδομένα με χαρακτηριστικά που είναι λέξεις. Αριθμητικά είναι τα δεδομένα των οποίων τα χαρακτηριστικά είναι αριθμοί (π.χ. το πρόβλημα της παχυσαρκίας). Άλλοι δυνατοί τύποι δεδομένων είναι εικόνες και σήματα. Οι εικόνες μπορεί να είναι φωτογραφίες περιοχών του σώματος προς εξέταση. Μπορούμε να πάρουμε για παράδειγμα δερματολογικά προβλήματα όπως είναι η διάγνωση για την κακοήθεια του μελανώματος του δέρματος. Η είσοδος του συστήματος θα είναι μία εικόνα που περικλείει το μελάνωμα και μια μικρή περιοχή δέρματος γύρω από αυτό. Άλλοι δυνατοί τύποι εικόνας είναι αυτές που προκύπτουν από συσκευές ιατρικής απεικόνισης τους είναι ο αξονικός ή ο μαγνητικός τομογράφος (Εικόνα 2.1). Όταν έχουμε εικόνες πρέπει πρώτα να τις ψηφιοποιήσουμε και να περάσουμε στο σύστημα κάθε pixel τους με καθορισμένη σειρά σαν χαρακτηριστικά των δεδομένων εισόδου. Η διάσταση του χώρου εισόδου σε τέτοιες περιπτώσεις είναι ιδιαίτερα υψηλή [3].



Εικόνα 2.1: Ηλεκτρομαγνητική δραστηριότητα εγκεφάλου όπως έχει καταγραφεί από ειδικό σύστημα ιατρικής απεικόνισης. Η εικόνα αυτή μπορεί να αποτελέσει είσοδο σε σύστημα ιατρικής διάγνωσης μετά από ψηφιοποίηση [3].

Τα σήματα που συνήθως χρησιμοποιούνται για ιατρική διάγνωση είναι καταγραφές ηλεκτρικής δραστηριότητας μιας περιοχής του σώματος για κάποιο χρονικό διάστημα. Χαρακτηριστικά παραδείγματα είναι το ηλεκτροκαρδιογράφημα (Εικόνα 2.2) και το ηλεκτροεγκεφαλογράφημα. Οι είσοδοι στο σύστημα ταξινόμησης σε τέτοιες περιπτώσεις προκύπτουν από κατάλληλη εξαγωγή χαρακτηριστικών στην προ-επεξεργασία, όπως από το μετασχηματισμό Fourier.



Εικόνα 2.2: Σήμα ηλεκτροκαρδιογραφήματος που μπορεί με κατάλληλη επεξεργασία να αποτελέσει είσοδο σε σύστημα ιατρικής διάγνωσης [3].

Γενικά, μπορούμε να πούμε ότι η ιδιαιτερότητα των προβλημάτων ιατρικής διάγνωσης έγκειται στη συλλογή των δεδομένων και στην κατάλληλη προ-επεξεργασία τους. Όπως ισχύει σε όλα τα προβλήματα, έτσι κι εδώ, είναι πολύ κρίσιμη η σωστή επιλογή των δεδομένων εκπαίδευσης του ταξινομητή με την έννοια ότι πρέπει να περιγράφουν πλήρως το πρόβλημα, ώστε να του δίνουν τη δυνατότητα να το μοντελοποιήσει επαρκώς. Ακόμα, σε κάθε πρόβλημα ο στόχος είναι να γίνεται η ταξινόμηση με το μικρότερο δυνατό αριθμό σφαλμάτων. Ιδιαίτερα σε προβλήματα ιατρικής διάγνωσης η απαίτηση αυτή είναι ακόμα πιο έντονη μιας και θέλουμε υψηλή αξιοπιστία στα αποτελέσματα που θα προταθούν σε έναν γιατρό.

2.4 Συστήματα Υποβοήθησης Ιατρικής Διάγνωσης (Diagnosis Support Systems)

2.4.1 Εισαγωγή

Όπως αναφέρθηκε και προηγουμένως, οι άνθρωποι έχουν περιορισμένες δυνατότητες στο να ενσωματώσουν πληροφορίες στη λήψη απόφασης. Η βραχυπρόθεσμη μνήμη τους μπορεί να διατηρήσει και να συνδυάσει αποτελεσματικά μόνο ένα πολύ μικρό αριθμό παραμέτρων. Για το λόγο αυτό, προέκυψε η ανάγκη ανάπτυξης ιατρικών συστημάτων, τα οποία να έχουν μεγαλύτερες υπολογιστικές αλλά κυρίως συνδυαστικές ικανότητες και να είναι σε θέση να επεξεργάζονται περισσότερο αποτελεσματικά τις κλινικές πληροφορίες, παράγοντας πιο αξιόπιστα αποτελέσματα.

Ευτυχώς, οι εξελίξεις στους τομείς των υπολογιστών και της Τεχνητής Νοημοσύνης επέτρεψαν την ανάπτυξη τέτοιων υπολογιστικών συστημάτων με σκοπό την υποβοήθηση κλινικών αποφάσεων διαγνωστικού ή θεραπευτικού χαρακτήρα με βάση εξατομικευμένα δεδομένα του ασθενούς [6], [9], [10]. Τα Συστήματα Υποβοήθησης Διάγνωσης (Diagnosis Support Systems), που είναι μια κατηγορία των Συστημάτων Υποστήριξης Κλινικών Αποφάσεων (Clinical Decision Support Systems), είναι διαδραστικά συμβουλευτικά υπολογιστικά προγράμματα, σχεδιασμένα για να βοηθούν τους επαγγελματίες υγείας σε προβλήματα λήψης αποφάσεων. Ο κλινικός ιατρός αλληλεπιδρά με το λογισμικό και χρησιμοποιεί τόσο τις γνώσεις του, όσο και το ίδιο το λογισμικό για να κάνει μια καλύτερη ανάλυση των δεδομένων των ασθενών, απ' ότι θα μπορούσε να κάνει μόνος του ένας άνθρωπος, ή μόνο του το λογισμικό. Τυπικά, το σύστημα κάνει προτάσεις για αξιοποίηση στο γιατρό και ο γιατρός με τη σειρά του επιλέγει τις χρήσιμες πληροφορίες και απορρίπτει τις λανθασμένες προτάσεις [11]. Τα συστήματα υποστήριξης κλινικών αποφάσεων χρησιμοποιούν μαθηματικά εργαλεία προσομοίωσης, μεθόδους επεξεργασίας ιατρικών δεδομένων και μεθόδους τεχνητής νοημοσύνης (όπως η αναγνώριση προτύπων), για την κωδικοποίηση της διαθέσιμης γνώσης και την επίλυση σύνθετων προβλημάτων που προκύπτουν στην κλινική πράξη [6], [12]. Τα συστήματα αυτά, αποσκοπούν τόσο στη βελτίωση της ικανότητας ανίχνευσης παθολογικών ευρημάτων σε ιατρικές εξετάσεις, όσο και στην υποβοήθηση της αξιολόγησης παθολογικών ευρημάτων κατά τη διαγνωστική διαδικασία. Ένα σύστημα υποβοήθησης διάγνωσης (ΣΥΔ), αποτελείται από τέσσερα υποσυστήματα, τα οποία παρουσιάζονται παρακάτω:

- το υποσύστημα προεπεξεργασίας δεδομένων,
- το υποσύστημα προσδιορισμού περιοχών ενδιαφέροντος
- το υποσύστημα εξαγωγής και επιλογής χαρακτηριστικών μεγεθών και
- το υποσύστημα ταξινόμησης

Υποσύστημα Προεπεξεργασίας Δεδομένων

Το υποσύστημα προεπεξεργασίας έχει ως στόχο τη βελτίωση της ποιότητας των δεδομένων με εφαρμογή κατάλληλων διαδικασιών για την ανάσχεση του θορύβου (εφαρμογή φίλτρων μέσης τιμής, ενδιάμεσης τιμής κ.λπ.), την επαναδειγματοληψία (γραμμική παρεμβολή, παρεμβολή με χρήση splines κ.λπ.) και την ενίσχυση της αντίθεσης (εξισορρόπηση ιστογράμματος, χρήση μετασχηματισμού κυματιδίου κ.λπ.) στην περίπτωση εικόνων [13].

Υποσύστημα Ορισμού Περιοχών Ενδιαφέροντος

Το υποσύστημα ορισμού περιοχών ενδιαφέροντος αναφέρεται συνήθως στον εντοπισμό πιθανών παθολογικών ευρημάτων. Συγκεκριμένα, στην περίπτωση βιοσημάτων εντοπίζονται τα τμήματα του καταγεγραμμένου σήματος που σχετίζονται με πιθανή παθολογία, ενώ στην περίπτωση ιατρικών εικόνων εντοπίζονται περιοχές που ενδεχομένως αντιστοιχούν σε βλάβη (π.χ. όγκο, κύστη). Ο ορισμός περιοχών ενδιαφέροντος μπορεί να πραγματοποιηθεί με χρήση ημιαυτόματων μεθοδολογιών, όπου ο χρήστης ορίζει την πιθανή παθολογική περιοχή ή αυτόματων μεθοδολογιών, όπου οι ύποπτες περιοχές προσδιορίζονται με κατάλληλες τεχνικές ψηφιακής επεξεργασίας σημάτων ή εικόνων [13], [14], [15], [16].

Υποσύστημα Εξαγωγής και Επιλογής Χαρακτηριστικών

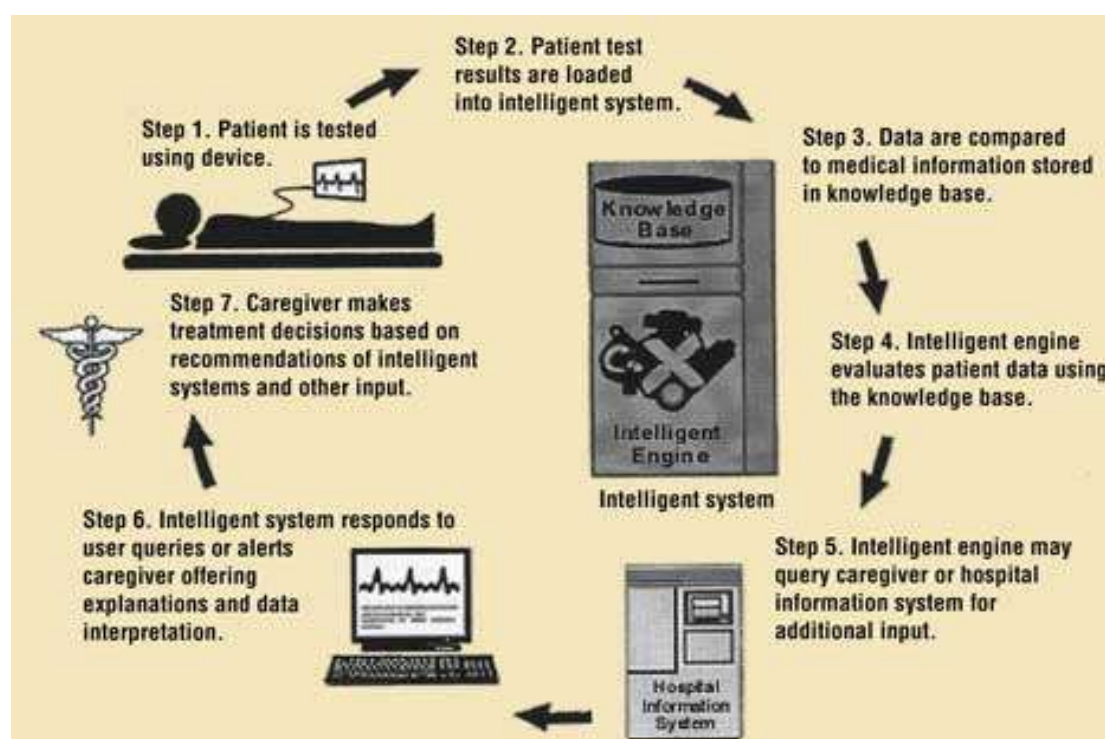
Ο όρος «χαρακτηριστικά», όπως επισημάνθηκε και παραπάνω, χρησιμοποιείται για να υποδηλώσει ένα σύνολο (διάνυσμα) ποσοτικών δεικτών που εξάγονται ύστερα από κατάλληλη επεξεργασία των δεδομένων του ασθενή (βιοσημάτων, απεικονιστικών και άλλων εργαστηριακών εξετάσεων, ιστορικού), με στόχο την αξιόπιστη διάκριση μεταξύ παθολογικών και φυσιολογικών οντοτήτων ή το χαρακτηρισμό μιας παθολογικής οντότητας (π.χ. καλοήθης ή κακοήθης όγκος). Τα χαρακτηριστικά αυτά μπορεί να προέρχονται από μετασχηματισμούς των καταγεγραμμένων βιοσημάτων (π.χ. μετασχηματισμός κυματιδίου), από χαρακτηριστικά μέσης χρωματικής πυκνότητας ή υφής εικόνων, γεωμετρικά χαρακτηριστικά κ.λπ.. Συχνά, είναι απαραίτητη η μείωση της διάστασης του διανύσματος των χαρακτηριστικών που έχουν εξαχθεί από τα δεδομένα του ασθενούς [17]. Η επιλογή των πιο εύρωστων χαρακτηριστικών αποσκοπεί αφενός στη μεγιστοποίηση της ακρίβειας ταξινόμησης και αφετέρου στην ελαχιστοποίηση της πολυπλοκότητας του συστήματος. Επειδή η εξέταση όλων των πιθανών συνδυασμών των χαρακτηριστικών μεγεθών (εξαντλητική αναζήτηση) είναι υπολογιστικά απαγορευτική, ακόμη και για μικρό πλήθος χαρακτηριστικών, έχουν αναπτυχθεί μέθοδοι αναζήτησης για την επιλογή των πιο εύρωστων χαρακτηριστικών. Οι μέθοδοι αυτές, εξισορροπούν την υπολογιστική πολυπλοκότητα με την ακρίβεια της ταξινόμησης, δηλαδή την εξαγωγή της μέγιστης δυνατής πληροφορίας στο μικρότερο δυνατό όγκο δεδομένων.

Υποσύστημα Ταξινόμησης

Ο ρόλος του υποσυστήματος ταξινόμησης αφορά στην απόφαση για την ένταξη των διανυσμάτων χαρακτηριστικών γνωρισμάτων που εμφανίζονται στην είσοδό του σε μια κατηγορία-κλάση, επιλέγοντας από ένα προκαθορισμένο πλήθος κατηγοριών-κλάσεων ενδιαφέροντος. Η ανάπτυξη και υλοποίηση του υποσυστήματος ταξινόμησης μπορεί να βασίζεται σε χρήση μεθόδων εκμάθησης με επίβλεψη (supervised training) ή χωρίς επίβλεψη (unsupervised training). Οι ταξινομητές με επίβλεψη που συνήθως χρησιμοποιούνται για την ανάπτυξη των ΣΥΔ είναι ταξινομητές που βασίζονται στον κανόνα του Bayes, ταξινομητές πλησιέστερου γείτονα, δέντρα αποφάσεων και νευρωνικά δίκτυα [17], [18], [19]. Στους ταξινομητές που βασίζονται στον κανόνα του Bayes, κάθε χαρακτηριστικό ανήκει σε εκείνη την κατηγορία με τη μέγιστη υπολογισμένη εκ των υστέρων πιθανότητα, στους ταξινομητές πλησιέστερου γείτονα τα χαρακτηριστικά ταξινομούνται στις κατηγορίες ανάλογα με τη σχετική ομοιότητά τους, στα δέντρα αποφάσεων η ταξινόμηση είναι το αποτέλεσμα επιλογής από μια σειρά εναλλακτικών λογικών βημάτων που

αναπαρίστανται με μορφή κόμβων και κλάδων, ενώ τα νευρωνικά δίκτυα χρησιμοποιούνται σε προβλήματα που δεν μπορούν να περιγραφούν με κανόνες ή μαθηματικούς τύπους. Κατά την εκμάθηση χωρίς επίβλεψη, η οποία αναφέρεται και ως ομαδοποίηση (clustering), η κατάταξη των διανυσμάτων στις κατηγορίες ενδιαφέροντος γίνεται αυτόματα κατά τη δόμηση του ταξινομητή. Στη συνέχεια, όπως και πριν, κάθε νέο χαρακτηριστικό διάνυσμα κατατάσσεται σε μία από τις κατηγορίες. Χαρακτηριστικοί ταξινομητές χωρίς επίβλεψη για την ανάπτυξη ΣΥΔ είναι οι ταξινομητές c-μέσων (c-means), ασαφών c-μέσων (fuzzy c-means) [20], [21], τα νευρωνικά δίκτυα αυτό-οργάνωσης χάρτη [22], η ιεραρχική ομαδοποίηση [22], η ομαδοποίηση με χρήση γενετικών αλγορίθμων [24] κ.λπ..

Στην παρούσα διπλωματική εργασία γίνεται διεξοδική ανάλυση και μελέτη των κυριότερων υποσυστημάτων ενός συστήματος υποβοήθησης διάγνωσης (υποσύστημα εξαγωγής και επιλογής χαρακτηριστικών, υποσύστημα ταξινόμησης) στα κεφάλαια που ακολουθούν (κεφάλαια 3 και 4, αντίστοιχα).



Εικόνα 2.3: Λειτουργία ενός τυπικού Συστήματος Υποστήριξης Κλινικών Αποφάσεων [5].

2.4.2 Ιστορική Αναδρομή Συστημάτων Υποβοήθησης Διάγνωσης

Η αρχική προσπάθεια δημιουργίας ΣΥΔ έγινε στα μέσα τις δεκαετίας του '50 όπου οι υλοποιήσεις ήταν σχετικά απλές με απλούς κανόνες παραγωγής και πλαίσια αποφάσεων (frames). Ωστόσο συστηματική έρευνα γύρω από αυτό έγινε την δεκαετία του '70 όπου χρησιμοποιήθηκαν έμπειρα συστήματα. Τα έμπειρα συστήματα αναπαριστούν την ιατρική γνώση με κανόνες παραγωγής «εάν ... τότε» μέχρι να εξαχθεί το τελικό συμπέρασμα. Τέτοια συστήματα αντιμετωπίζουν προβλήματα στο να διατηρούν κανόνες πάνω από λίγες χιλιάδες, καθώς η πολυπλοκότητα τους αυξάνεται δραματικά. Επίσης δεν αντιμετωπίζουν με αποτελεσματικότητα την αβεβαιότητα που ενδεχομένως να υπάρχει στα δεδομένα. Αυτοί οι λόγοι οδήγησαν τα

έμπειρα συστήματα στο να περιοριστούν σε μικρό εύρος εφαρμογών. Αργότερα, ακολούθησαν ΣΥΔ βασισμένα σε πιθανότητες όπου γινόταν στατιστική ανάλυση δεδομένων και ΣΥΔ στηριζόμενα στον κανόνα του Bayes όπου στηρίζονταν σε υπό συνθήκη πιθανότητες. Τα συστήματα αυτά αναπαριστούσαν το πρόβλημα με φυσικό τρόπο και χειρίζονταν την αβεβαιότητα με συνοχή. Παρόλα αυτά, είχαν το μειονέκτημα ότι ήταν απαραίτητη η γνώση των πιθανοτήτων εφαρμογής των δεδομένων για να δημιουργηθεί το σύστημα. Η πραγματική καινοτομία έγινε όταν αναπτύχθηκαν ΣΥΔ με τεχνητά νευρωνικά δίκτυα [25]. Τα συστήματα αυτά είναι σε θέση να προσαρμόζονται στα εκάστοτε δεδομένα και να μαθαίνουν από καινούργια δεδομένα. Έχουν δηλαδή την δυνατότητα να αυτοβελτιώνονται. Μία άλλη τεχνολογία που αναπτύχθηκε είναι η εξόρυξη δεδομένων (data mining) όπου μπορεί να αντιμετωπίσει μεγάλες ποσότητες δεδομένων (data warehouse) και να βρει την κρυμμένη ενυπάρχουσα πληροφορία σε αυτά, δηλαδή συγκεκριμένες τάσεις ή ανωμαλίες. Αναπτύχθηκαν επίσης συστήματα στηριζόμενα σε ευφυείς πράκτορες (intelligent agents). Σε αυτά το λογισμικό οργανώνεται σε ανεξάρτητες μονάδες λογισμικού (πράκτορες) που εκτελούν αυτόνομους στόχους. Τα συστήματα αυτά έχουν καλή απόδοση σε σύνθετα και πολυπαραμετρικά προβλήματα. Άλλη τεχνολογία είναι οι γενετικοί αλγόριθμοι (genetic algorithms). Οι γενετικοί αλγόριθμοι στηρίζονται στους κανόνες της φυσικής επιλογής και χρησιμοποιούνται κυρίως σε προβλήματα βελτιστοποίησης ή σε υβριδικά συστήματα μαζί με νευρωνικά δίκτυα. Έχουν καλή απόδοση σε πολυδιάστατα προβλήματα βελτιστοποίησης αλλά δεν εγγυώνται πάντα την βέλτιστη λύση. Τέλος, υπάρχουν συστήματα που χρησιμοποιούν ασαφή λογική (fuzzy logic), δηλαδή υπερσύνολα της συμβατικής λογικής. Τα συστήματα αυτά μπορούν να αντιμετωπίσουν προβλήματα όπου οι σαφείς τιμές αλήθειας ή οι πιθανότητες δεν είναι διαθέσιμες [2], [5].

2.4.3 Πλεονεκτήματα Συστημάτων Υποστήριξης Διάγνωσης (ΣΥΔ) σε σχέση με τον ανθρώπινο παράγοντα

Τα ΣΥΔ παρουσιάζουν αρκετά πλεονεκτήματα [26] σε σχέση με τον ανθρώπινο παράγοντα και για αυτό εξάλλου η χρήση τους, αν και αρχικά γινόταν με διστακτικότητα, γίνεται όλο και πιο ευρεία. Τα κυριότερα πλεονεκτήματα είναι [5]:

- Οι άνθρωποι έχουν την δυνατότητα στην γρήγορη ανάλυση των οπτικών δεδομένων όπως γραφικές παραστάσεις σημάτων κλπ, όμως είναι πολύ αργοί σε αριθμητικούς υπολογισμούς ειδικά αν οι τελευταίοι περιέχουν μεγάλους αριθμούς. Στα βιολογικά δεδομένα, ωστόσο, πολλές φορές χρειάζεται μεγάλος αριθμός τιμών για να εξαχθεί η απαραίτητη πληροφορία. Ενδεικτικά αναφέρεται ότι το ΗΚΓ ενός καρδιακού παλμού θα μπορούσε να έχει μέχρι 200 αριθμητικές τιμές και το αντίστοιχο φωνοκαρδιογράφημα μέχρι 2000 [26]. Επίσης θα ήταν μη πρακτικό οι άνθρωποι να αναλώνονται σε τετριμμένες εργασίες που δεν έχουν παθολογικό ενδιαφέρον, όπως η αφαίρεση θορύβου από τα σήματα. Αντίθετα, οι υπολογιστές μπορούν να εκτελούν εκατομμύρια αριθμητικών πράξεων ανά δευτερόλεπτο και με πολύ μεγάλη ακρίβεια που πέραν των άλλων συντελούν σε οικονομία χρόνου και αξιοπιστία.
- Οι άνθρωποι επηρεάζονται από την κούραση, την έλλειψη προσοχής και διάφορους περιβαλλοντικούς παράγοντες που ενδεχομένως τους οδηγούν σε λάθη. Για παράδειγμα, η συνεχής παρακολούθηση ενός ασθενούς με καρδιακό επεισόδιο μπορεί να είναι μία κουραστική διαδικασία. Επιπλέον, ο άνθρωπος

μπορεί να αποσπαστεί από διάφορα γεγονότα και να χάσει σύντομα γεγονότα ή ανωμαλίες στο σήμα που εξετάζει, τα οποία όμως ίσως είναι κρίσιμα για την πορεία του ασθενή. Επίσης, το να χρησιμοποιηθεί άνθρωπος για πολύ μεγάλης χρονικής διάρκειας παρακολούθηση, δεν είναι μια εφικτή επιλογή και έχει τεράστιο κόστος. Από την άλλη μεριά, οι υπολογιστές είναι πάντα ακριβείς και συνεπείς από μαθηματική άποψη και μπορούν να προγραμματιστούν ώστε να εκτελούν συγκεκριμένες εργασίες χωρίς τους παραπάνω περιορισμούς.

- Η ανάλυση δεδομένων που γίνεται από ανθρώπους είναι συνήθως υποκειμενική. Όταν απαιτείται συγκριτική μελέτη μεταξύ ενός σήματος και ενός τυποποιημένου σήματος, ένας ανθρώπινος παρατηρητής θα έδινε ποιοτική απάντηση. Παραδείγματος χάριν, το εύρος μίας κορύφωσης ενός ΗΕΓ ένας άνθρωπος μπορεί να αποφανθεί ότι είναι πλατύτερο ή πιο στενό από το κανονικό. Αντίθετα τα ΣΥΔ, επιτρέπουν μία πιο συγκεκριμένη και αντικειμενική σύγκριση με ικανοποιητική ακρίβεια.
- Η ανάλυση από ανθρώπους είναι επίσης υποκειμενική με την έννοια ότι σχετίζεται με τον εκάστοτε παρατηρητή που κάνει την διάγνωση. Για αυτό δύο ξεχωριστές διαγνώσεις για την ίδια περίπτωση, ενδεχομένως να διαφέρουν ανάλογα με την χρονική στιγμή που έγιναν (αν πρόκειται για τον ίδιο παρατηρητή) ή να διαφέρουν από παρατηρητή σε παρατηρητή. Η πρώτη διαφοροποίηση μπορεί να οφείλεται σε λανθασμένη εφαρμογή μεθόδου και η δεύτερη σε διαφορετικές αντιλήψεις που προκύπτουν από την διαφορετική κατανόηση του προβλήματος. Τα ΣΥΔ, αντίθετα, μπορούν να εκτελέσουν μια διεργασία πολλές φορές και πάντα με συνεπή τρόπο. Επίσης, μπορούν να κωδικοποιήσουν γνώση από πολλούς εμπειρογνώμονες και για αυτό να ενσωματώνουν μία "συλλογική" ευφυΐα για την περιοχή ενδιαφέροντος.
- Για τη διάγνωση μιας ασθένειας ο ιατρός στηρίζεται, στις περισσότερες περιπτώσεις, στο ιστορικό και την κλινική εικόνα του ασθενούς, στην οπτική εξέταση των απεικονιστικών εξετάσεων, καθώς και στα αποτελέσματα εργαστηριακών εξετάσεων. Υπάρχουν όμως περιπτώσεις, που η επιβεβαίωση της διάγνωσης είναι ιδιαίτερα δύσκολη απαιτώντας υψηλή εξειδίκευση και εμπειρία, ή ακόμη και εφαρμογή επεμβατικών μεθοδολογιών (βιοψία). Αυτό γίνεται κατανοητό, αν θεωρήσουμε την περίπτωση διάγνωσης με βάση απεικονιστικές εξετάσεις (αξονική ή μαγνητική τομογραφία, υπερηχοτομογραφία κ.λπ.), όπου είναι πιθανή η εσφαλμένη διάγνωση είτε εξαιτίας επικάλυψης ύποπτων παθολογικών οντοτήτων από την παρουσία ανατομικών δομών, ή λόγω εικόνων χαμηλής ποιότητας, ως αποτέλεσμα θορύβου ή/και χαμηλής αντίθεσης μεταξύ γειτονικών δομών ή ακόμη και εξαιτίας παρουσίας παρόμοιων χαρακτηριστικών τόσο στις παθολογικές, όσο και στις φυσιολογικές δομές. Τα Συστήματα Υποστήριξης Διάγνωσης (ΣΥΔ) ενισχύουν τη διαγνωστική δυνατότητα των ιατρών και μειώνουν το χρόνο που απαιτείται για ορθή διάγνωση [6].

Ωστόσο, πρέπει να σημειωθεί ότι τα ΣΥΔ δεν είναι σε θέση να αντικαταστήσουν τους γιατρούς γιατί σχετίζονται με μία σειρά περιορισμών, οι οποίοι αίρονται όταν έχουμε να κάνουμε με τον ανθρώπινο παράγοντα. Για παράδειγμα, ένας γιατρός έχει απευθείας επαφή με τον ασθενή και έτσι μπορεί να ανιχνεύσει πληροφορίες που δεν παρέχονται από το ιστορικό του. Επίσης, ο γιατρός κατά την διάγνωση μπορεί να υποκινείται από εσωτερικούς κανόνες, που αναφέρονται συχνά ως «διαγνωστική αίσθηση» (“diagnostic feeling”) [13] και που δεν μπορούν πάντα να αναπαραχθούν από κάποιον αλγόριθμο. Γενικά η γνώση που ενσωματώνεται σε ένα ΣΥΔ είναι κατώτερη των προσδοκιών, γιατί δεν μπορεί να αναπαρασταθεί η πολυπλοκότητα της

ανθρώπινης σκέψης προκειμένου το σύστημα να φτάσει σε ένα συμπέρασμα. Όσο η πολυπλοκότητα αυξάνεται, το ΣΥΔ αναδεικνύει τις αδυναμίες του στο να φτάνει σε αξιόπιστα αποτελέσματα. Παράλληλα, η έννοια του τι είναι φυσιολογικό και τι παθολογικό είναι δυναμική και συνήθως μεταβάλλεται με την πάροδο του χρόνου, όταν προκύπτουν νέες πληροφορίες για συγκεκριμένες ασθένειες. Αν προκύψουν νέα στοιχεία για τις ασθένειες το σύστημα πρέπει να είναι σε θέση να τις ενσωματώνει. Για τον λόγο αυτό, αναπτύσσονται τα ανοιχτά συστήματα (open systems) [27], που όμως δεν είναι πάντα σε θέση να αφομοιώνουν τις αλλαγές με την ταχύτητα που χρειάζεται. Αν και ο χρήστης του συστήματος είναι φαινομενικά ελεύθερος να επιλέξει οποιαδήποτε από τις επιλογές που προσφέρονται σε κάθε πρόταση, ωστόσο περιορίζεται στις επιλογές που ορίστηκαν από τον εμπειρογνώμονα που συντέλεσε στη σύνταξη του προγράμματος. Το πρόγραμμα περιορίζεται έτσι από τις αρχιτεκτονικές καθορισμένες εισόδους που διατυπώθηκαν κατά την δημιουργία του συστήματος. Τέλος, οι εργαζόμενοι σε τομείς υγείας, λόγω της τεχνοφοβίας (technophobia) ή ελλιπών υπολογιστικών γνώσεων [28] είναι απρόθυμοι να χρησιμοποιούν ΣΥΔ, καθιστώντας τα τελευταία μη αποδοτικά.

ΚΕΦΑΛΑΙΟ 3

Εξαγωγή και Επιλογή Χαρακτηριστικών για την Ταξινόμηση των Βιολογικών Σημάτων

Όπως έχουμε τονίσει στη θεωρία, ο αριθμός των χαρακτηριστικών που έχει στη διάθεσή του ο σχεδιαστής ενός συστήματος ταξινόμησης, είναι συνήθως πολύ μεγάλος. Μάλιστα ο αριθμός τους μπορεί εύκολα να φτάσει τις μερικές δεκάδες ή ακόμη και εκατοντάδες. Ένα μεγάλο πρόβλημα που σχετίζεται με την αναγνώριση προτύπων είναι η αποκαλούμενη «κατάρτα της διαστασιμότητας». Για ένα δεδομένο μέγεθος δείγματος, δηλαδή, υπάρχει ένας μέγιστος αριθμός χαρακτηριστικών πάνω από τον οποίο η απόδοση του ταξινομητή αντί να βελτιωθεί, μειώνεται. Το φαινόμενο αυτό, μας οδηγεί στο συμπέρασμα ότι στις περισσότερες περιπτώσεις η πληροφορία που χάνεται με την απόρριψη κάποιων χαρακτηριστικών, μπορεί να αντισταθμιστεί με μια πιο ακριβή χαρτογράφηση των χαρακτηριστικών, σε χώρο χαμηλότερης διάστασης. Έτσι, γίνεται φανερό ότι η λύση σε ένα μεγάλο αριθμό προβλημάτων αναγνώρισης προτύπων μπορεί να επιτευχθεί με την επιλογή ενός καταλληλότερου χώρου χαρακτηριστικών ή όπως αλλιώς την ονομάζουμε, με τη *μείωση της διάστασης των χαρακτηριστικών*.

Οι δύο μεγάλες κατηγορίες μεθόδων μείωσης των διαστάσεων είναι η *επιλογή χαρακτηριστικών* (feature selection) και η *εξαγωγή χαρακτηριστικών* (feature extraction) τις οποίες θα αναλύσουμε παρακάτω [6], [31]. Ο όρος εξαγωγή χαρακτηριστικών αναφέρεται σε αλγορίθμους μετασχηματισμού του αρχικού συνόλου δεδομένων σε ένα νέο σύνολο μικρότερης διάστασης, ενώ ο όρος επιλογή χαρακτηριστικών αναφέρεται σε αλγορίθμους που επιλέγουν το «καλύτερο» υποσύνολο του αρχικού διανύσματος χαρακτηριστικών. Η επιλογή της καταλληλότερης από τις δύο μεθοδολογίες εξαρτάται από το είδος της εφαρμογής και τα διαθέσιμα δεδομένα [6]. Για τις ανάγκες της παρούσας μελέτης αναπτύχθηκαν τόσο μεθοδολογίες εξαγωγής, όσο και μεθοδολογίες επιλογής χαρακτηριστικών, ωστόσο ιδιαίτερη έμφαση δίνεται στις μεθόδους εξαγωγής χαρακτηριστικών, αφού σε αυτές εστιάζεται η εργασία μας.

3.1 Επιλογή Χαρακτηριστικών

3.1.1 Εισαγωγή

Στόχος αυτής της ενότητας είναι η μελέτη μεθοδολογιών σχετικών με την επιλογή των χαρακτηριστικών πάνω στα οποία βασιζόμαστε για να κάνουμε ταξινόμηση των προτύπων.

Υπάρχουν περισσότεροι από ένας λόγοι για τη μείωση του αριθμού των χαρακτηριστικών σε ένα επαρκές ελάχιστο όριο. Ο προφανής είναι η υπολογιστική πολυπλοκότητα. Ένας άλλος λόγος είναι το ότι παρόλο που δύο χαρακτηριστικά μπορεί να περιέχουν ικανοποιητική πληροφορία για την ταξινόμηση όταν αντιμετωπίζονται ξεχωριστά, εντούτοις υπάρχει πολύ μικρό κέρδος αν ενωθούν σε ένα διάνυσμα χαρακτηριστικών λόγω της υψηλής αμοιβαίας συσχέτισης. Έτσι, η πολυπλοκότητα αυξάνεται χωρίς μεγάλο κέρδος όσον αφορά την πληροφορία. Τέλος, η μείωση του αριθμού των χαρακτηριστικών που χρησιμοποιούνται για την ταξινόμηση, επιβάλλεται από τις απαιτούμενες ιδιότητες γενίκευσης του ταξινομητή. Μάλιστα όσο μεγαλύτερος είναι ο λόγος των προτύπων εκπαίδευσης (training

patterns) προς τον αριθμό των ελεύθερων παραμέτρων του ταξινομητή, τόσο καλύτερες είναι οι ιδιότητες γενίκευσης του ταξινομητή που προκύπτει [2].

Ένας μεγάλος αριθμός χαρακτηριστικών μετατρέπονται απευθείας σε ένα μεγάλο αριθμό παραμέτρων ταξινομητή (π.χ. συναπτικά βάρη σε ένα νευρωνικό δίκτυο, βάρη σε ένα γραμμικό ταξινομητή). Έτσι, για έναν πεπερασμένο και συνήθως μικρό αριθμό προτύπων εκπαίδευσης, το να κρατάμε τον αριθμό των χαρακτηριστικών όσο το δυνατόν μικρότερο ευθυγραμμίζεται με την επιθυμία μας να σχεδιάζουμε ταξινομητές με καλές ικανότητες γενίκευσης [2].

Συνοψίζοντας, το ερώτημα που καλούμαστε να απαντήσουμε σε αυτή την ενότητα τίθεται ως εξής: δεδομένου ενός αριθμού χαρακτηριστικών, πώς μπορεί κάποιος να επιλέξει τα σημαντικότερα εξ' αυτών έτσι ώστε να μειώσει τον αριθμό τους, ενώ ταυτόχρονα να διατηρήσει όσο το δυνατόν περισσότερη από την πληροφορία που περιέχουν για τον διαχωρισμό των τάξεων; Η διαδικασία που χρησιμοποιείται γι' αυτό το σκοπό είναι η επιλογή χαρακτηριστικών (*feature selection*) ή μείωση (*reduction*). Στην ουσία στην επιλογή χαρακτηριστικών επιλέγουμε έναν αριθμό από τα ήδη υπάρχοντα χαρακτηριστικά, ελαχιστοποιώντας κάποια συνάρτηση κόστους. Τα χαρακτηριστικά που επιλέγονται παραμένουν αυτούσια, δηλαδή δεν μετασχηματίζονται, ενώ πρέπει να έχουν υψηλή διακριτική ικανότητα. Το στάδιο αυτό είναι πολύ κρίσιμο. Αν επιλέξουμε χαρακτηριστικά με μικρή διακριτική δύναμη, η μετέπειτα σχεδίαση ενός ταξινομητή θα οδηγήσει σε χαμηλή απόδοση του συστήματος. Από την άλλη πλευρά, αν επιλεγθούν χαρακτηριστικά πλούσια σε πληροφορία, ο σχεδιασμός του ταξινομητή θα μπορέσει σε μεγάλο βαθμό να απλοποιηθεί. Σε μια πιο ποσοτική περιγραφή, σκοπός μας είναι να επιλέγουμε χαρακτηριστικά τα οποία οδηγούν σε μεγάλη απόσταση των διαφορετικών τάξεων μεταξύ τους και σε μικρές διακυμάνσεις εντός των προτύπων της ίδιας τάξης. Αυτό σημαίνει ότι τα χαρακτηριστικά πρέπει να παίρνουν μακρινές τιμές σε ξεχωριστές τάξεις και κοντινές τιμές αν βρίσκονται μέσα στην ίδια τάξη. Για το σκοπό αυτό, θα υιοθετηθούν διαφορετικά σενάρια. Το ένα είναι να εξεταστούν τα χαρακτηριστικά ατομικά και απορριφθούν εκείνα με τη μικρότερη ικανότητα διάκρισης. Μια καλύτερη εναλλακτική, είναι να εξεταστούν τα χαρακτηριστικά σε συνδυασμούς. Μερικές φορές η εφαρμογή ενός γραμμικού ή μη γραμμικού μετασχηματισμού σε ένα διάνυσμα χαρακτηριστικών γνωρισμάτων, μπορεί να οδηγήσει σε ένα νέο διάνυσμα με καλύτερες ιδιότητες διάκρισης [2].

3.1.2 Μέθοδοι Επιλογής των Χαρακτηριστικών

Η επιλογή των χαρακτηριστικών (*feature selection*) είναι μια τεχνική που χρησιμοποιείται ευρέως στη μηχανική μάθηση (*machine learning*) ώστε να επιλέγεται, όπως αναφέραμε, ένα υποσύνολο σχετικών χαρακτηριστικών προκειμένου να κατασκευαστούν ισχυρά μοντέλα εκπαίδευσης. Ο στόχος του σταδίου αυτού σε ένα σύστημα ταξινόμησης προτύπων είναι να αφαιρεθούν τα περισσότερα από τα περιττά και μη σχετικά χαρακτηριστικά από τα δεδομένα, για να ανακουφιστεί η συχνά επιβλαβής επίδραση της υψηλής διαστασιμότητας (ύπαρξη πολλών διαστάσεων) και να επιτευχθεί βελτίωση της γενίκευσης και της επεξηγηματικότητας του μοντέλου [2].

Ένα πρώτο βήμα στην επιλογή των χαρακτηριστικών είναι να κοιτάξουμε το καθένα από τα χαρακτηριστικά ξεχωριστά και να εξετάσουμε την ικανότητα διάκρισής τους για το συγκεκριμένο πρόβλημα που καλούμαστε να λύσουμε. Παρόλο που ο τρόπος αυτός δεν είναι βέλτιστος, η διαδικασία αυτή μας βοηθά να απορρίψουμε τις

εύκολα αναγνωρίσιμες “κακές” επιλογές και ταυτόχρονα ελαφρύνει τις πιο περίπλοκες τεχνικές από αχρείαστο υπολογιστικό φόρτο. Ωστόσο, τέτοιες τεχνικές που αναφέρονται στις ιδιότητες διάκρισης συγκεκριμένων χαρακτηριστικών, αποτυγχάνουν να λάβουν υπ’ όψιν τους το συσχετισμό που αναπόφευκτα υπάρχει ανάμεσα στα χαρακτηριστικά και που επηρεάζει τις ικανότητες ταξινόμησης των διανυσμάτων χαρακτηριστικών που σχηματίζονται. Από την άλλη πλευρά, η μέτρηση της αποτελεσματικότητας διάκρισης των διανυσμάτων χαρακτηριστικών είναι μια άλλη προσέγγιση η οποία μπορεί να χρησιμοποιηθεί για την επιλογή των χαρακτηριστικών, σε ένα πρόβλημα ταξινόμησης [2]. Η πληροφορία από τη μέτρηση της αποτελεσματικότητας διάκρισης των διανυσμάτων χαρακτηριστικών, μπορεί να χρησιμοποιηθεί με δύο τρόπους. Ο πρώτος είναι ώστε να μπορέσουμε να συνδυάσουμε χαρακτηριστικά με το σωστό τρόπο και να φτάσουμε στο καλύτερο δυνατό διάνυσμα για μια συγκεκριμένη διάσταση l . Ο δεύτερος τρόπος είναι να μετατρέψουμε τα αρχικά δεδομένα, με βάση ένα κριτηρίου βελτιστοποίησης, ώστε να πάρουμε χαρακτηριστικά που να προσφέρουν μεγάλη δύναμη ταξινόμησης. Έχοντας ορίσει έναν αριθμό κριτηρίων τα οποία μετρούν την αποδοτικότητα της ταξινόμησης συγκεκριμένων χαρακτηριστικών ή/και διανυσμάτων χαρακτηριστικών, ερχόμαστε στην καρδιά του προβλήματος που είναι η επιλογή ενός υποσυνόλου l χαρακτηριστικών από τα m που ήταν αρχικά διαθέσιμα. Υπάρχουν δύο βασικές κατευθύνσεις να ακολουθήσουμε:

1. Βαθμωτή Επιλογή Χαρακτηριστικών (Scalar Feature Selection)

Τα χαρακτηριστικά αντιμετωπίζονται ξεχωριστά. Οποιοδήποτε από τα κριτήρια μέτρησης της διαχωρισιμότητας των τάξεων μπορεί να υιοθετηθεί όπως για παράδειγμα η τυπική απόκλιση κλπ. Η τιμή του κριτηρίου $C(k)$ υπολογίζεται για καθένα από τα χαρακτηριστικά $k=1, 2, \dots, m$. Στη συνέχεια, τα χαρακτηριστικά κατατάσσονται σε φθίνουσα σειρά με βάση τις τιμές του $C(k)$. Τα l χαρακτηριστικά που αντιστοιχούν στις l καλύτερες τιμές του $C(k)$ επιλέγονται για να σχηματίσουν το διάνυσμα χαρακτηριστικών. Το μεγαλύτερο πλεονέκτημα του να αντιμετωπίζουμε τα χαρακτηριστικά ξεχωριστά είναι η υπολογιστική απλότητα. Ωστόσο, τέτοιες προσεγγίσεις δεν λαμβάνουν υπ’ όψιν τους υπάρχοντες συσχετισμούς μεταξύ των χαρακτηριστικών.

2. Επιλογή Διανύσματος Χαρακτηριστικών (Feature Vector Selection)

Η αντιμετώπιση ξεχωριστών χαρακτηριστικών ως βαθμωτά, μπορεί να μην είναι τόσο αποτελεσματική για πολύπλοκα προβλήματα και χαρακτηριστικά με υψηλή αμοιβαία συσχέτιση. Σε αυτήν την παράγραφο θα αναλύσουμε τεχνικές που μετρούν την ικανότητα ταξινόμησης των διανυσμάτων χαρακτηριστικών. Σε μια τέτοια προσέγγιση, ο μεγαλύτερος περιοριστικός παράγοντας είναι η υπολογιστική πολυπλοκότητα. Εδώ, το κριτήριο βελτιστοποίησης απαιτεί να δημιουργήσουμε όλους τους πιθανούς συνδυασμούς διανυσμάτων με l χαρακτηριστικά, από τα m που υπήρχαν αρχικά στη διάθεσή μας. Σύμφωνα με τον τύπο του κανόνα βελτιστοποίησης που επιλέγει κάποιος, η επιλογή των χαρακτηριστικών μπορεί να γίνει με δύο τρόπους:

Filter approach. Σε αυτήν την προσέγγιση, το κριτήριο βελτιστοποίησης για την επιλογή των χαρακτηριστικών είναι ανεξάρτητο από τον ταξινομητή, που θα χρησιμοποιηθεί στο στάδιο σχεδιασμού του ταξινομητή. Για κάθε συνδυασμό

μπορούμε να χρησιμοποιήσουμε ένα από τα κριτήρια διαχωρισιμότητας που αναφέρθηκαν προηγουμένως και να επιλέξουμε τον καλύτερο συνδυασμό διανυσμάτων χαρακτηριστικών [2]. Ο συνολικός αριθμός των διανυσμάτων θα είναι:

$$\binom{m}{l} = \frac{m!}{l!(m-l)!}$$

Ένας τέτοιος αριθμός είναι μεγάλος ακόμη και για μικρές τιμές των l , m . Επιπλέον, σε πολλές πρακτικές εφαρμογές ο αριθμός l δεν είναι γνωστός εκ των προτέρων. Έτσι, κάποιος θα πρέπει να δοκιμάσει συνδυασμούς χαρακτηριστικών για διαφορετικές τιμές του l και να επιλέξει την καλύτερη τιμή για αυτό (πέρα από την οποία δεν παρατηρείται κέρδος στην απόδοση) και αντίστοιχα την τιμή του καλύτερου διανύσματος χαρακτηριστικών l -διάστασης.

Wrapper approach. Μερικές φορές είναι επιθυμητό να βασίσουμε την απόφαση για επιλογή των χαρακτηριστικών όχι σε τιμές κάποιου κριτηρίου διαχωρισιμότητας των τάξεων, αλλά στην απόδοση του ίδιου του ταξινομητή. Αυτό σημαίνει, ότι για κάθε συνδυασμό διανυσμάτων χαρακτηριστικών, η πιθανότητα λάθος ταξινόμησης πρέπει να υπολογίζεται και τελικά επιλέγεται ο συνδυασμός που καταλήγει στη χαμηλότερη πιθανότητα λάθους [2]. Αυτή η προσέγγιση μπορεί να αυξήσει τις απαιτήσεις πολυπλοκότητας περισσότερο, ανάλογα με τον τύπο του ταξινομητή.

Και για τις δύο προσεγγίσεις, ένας αριθμός από αποτελεσματικές μεθόδους αναζήτησης έχει προταθεί, για να μειωθεί η πολυπλοκότητα. Κάποιες από αυτές είναι μη βέλτιστες και κάποιες βέλτιστες (κάτω από συγκεκριμένες υποθέσεις ή περιορισμούς).

Suboptimal Searching Techniques

A. Σειριακή Οπίσθια Επιλογή (Sequential Backward Selection - SBS)

Στην Σειριακή Οπίσθια επιλογή, ο αλγόριθμος της μεθόδου, ακολουθεί την παρακάτω λογική: ξεκινώντας από το αρχικό σύνολο χαρακτηριστικών που διαθέτουμε, αφαιρείται κάθε φορά ένα χαρακτηριστικό έτσι ώστε να μεγιστοποιείται το ποσοστό αναγνώρισης, στο σύνολο που απομένει.

Αλγόριθμος μεθόδου:

- Υιοθετούμε ένα κριτήριο διαχωρισιμότητας των τάξεων, C , και υπολογίζουμε την τιμή του για το διάνυσμα χαρακτηριστικών διάστασης m .
- Αποκλείουμε ένα χαρακτηριστικό και για κάθε έναν από τους εναπομείναντες πιθανούς συνδυασμούς των $(m-1)$ χαρακτηριστικών, υπολογίζουμε την αντίστοιχη τιμή του κριτηρίου. Επιλέγουμε το συνδυασμό με την καλύτερη τιμή, δηλ. ένα διάνυσμα διάστασης $m-1$.
- Από το επιλεγμένο διάνυσμα χαρακτηριστικών διάστασης $m-1$, αποκλείουμε άλλο ένα χαρακτηριστικό και για κάθε έναν από τους εναπομείναντες συνδυασμούς διανυσμάτων χαρακτηριστικών διάστασης $m-2$, υπολογίζουμε την τιμή του κριτηρίου και επιλέγουμε το διάνυσμα με την καλύτερη τιμή.

Έτσι, αρχίζοντας από m χαρακτηριστικά, σε κάθε βήμα “πετάμε” ένα χαρακτηριστικό από τον καλύτερο συνδυασμό μέχρι να πάρουμε ένα διάνυσμα l χαρακτηριστικών, το οποίο θα θεωρήσουμε βέλτιστο. Ο αριθμός συνδυασμών που αναζητούνται σε αυτή

τη διαδικασία είναι $1+1/2((m+1)m - l(l+1))$, ο οποίος είναι σημαντικά μικρότερος από το συνολικό αριθμό όλων των συνδυασμών.

B. Σειριακή Εμπρόσθια Επιλογή (Sequential Forward Selection - SFS)

Στη Σειριακή εμπρόσθια επιλογή, το βέλτιστο σύνολο χαρακτηριστικών X_l , όπου l το πλήθος των χαρακτηριστικών, προκύπτει από ένα αρχικά κενό σύνολο X_0 στο οποίο σταδιακά προστίθενται χαρακτηριστικά από το αρχικό σύνολο m χαρακτηριστικών, σύμφωνα με κάποιο κριτήριο. Για τη δημιουργία του τελικού συνόλου χαρακτηριστικών, ακολουθείται δηλαδή, η στρατηγική «bottom up». Η διαδικασία επιλογής της SFS, ακολουθεί την αντίστροφη διαδικασία από την SBS και αποτελείται από τα παρακάτω βήματα:

- Υπολογίζουμε την τιμή του κριτηρίου για κάθε ένα από τα χαρακτηριστικά και επιλέγουμε το χαρακτηριστικό με την καλύτερη τιμή.
- Σχηματίζουμε όλα τα πιθανά διδιάστατα διανύσματα που περιέχουν το χαρακτηριστικό του προηγούμενου βήματος. Στη συνέχεια υπολογίζουμε την τιμή του κριτηρίου για το καθένα από αυτά τα διανύσματα και επιλέγουμε αυτό με την καλύτερη τιμή.

Συνεχίζουμε με τον ίδιο τρόπο ώσπου η διάσταση των διανυσμάτων να γίνει ίση με l . Έτσι, το διάνυσμα που προκύπτει, περιέχει τελικά τα στοιχεία του X_l . Με αυτή τη μέθοδο, ο αριθμός των συνδυασμών οι οποίοι αναζητούνται είναι $lm - l(l-1)/2$. Έτσι, από υπολογιστικής πλευράς, η σειριακή οπίσθια επιλογή είναι πιο αποτελεσματική από ότι η εμπρόσθια, όσο το l είναι πιο κοντά στο m απ' ότι στο 1.

Γ. Μεταβλητές Μέθοδοι Αναζήτησης (Floating Search Methods)

Προφανώς, οι δύο προηγούμενες μέθοδοι δεν είναι βέλτιστες, αφού πάσχουν από το λεγόμενο “φαινόμενο φωλιάσματος” (*nesting effect*). Πιο συγκεκριμένα, στη Σειριακή Οπίσθια Επιλογή, όταν ένα χαρακτηριστικό απορριφθεί δεν υπάρχει τρόπος για να θεωρηθεί πάλι υποψήφιο. Το αντίστροφο ισχύει και για τη μέθοδο της Σειριακής Εμπρόσθιας Επιλογής, στην οποία όταν ένα χαρακτηριστικό επιλεγεί, δεν υπάρχει δυνατότητα να απορριφθεί αργότερα, μέσω της διαδικασίας του αλγορίθμου. Έτσι, προκειμένου να προκύψει ένα βέλτιστο υποσύνολο χαρακτηριστικών, είναι απαραίτητο να προστεθεί ένας μηχανισμός επανεξέτασης όλων των στοιχείων του υποσυνόλου σε κάθε επανάληψη, ώστε να υπάρχει η δυνατότητα να αφαιρεθεί ή να προστεθεί κάποιο χαρακτηριστικό, αν αυτό κριθεί απαραίτητο. Στην δημοσίευση [29] προτείνεται μια τεχνική η οποία προσφέρει την ευελιξία της αναθεώρησης χαρακτηριστικών που έχουν προηγουμένως απορριφθεί και αντίστροφα, χαρακτηριστικών που έχουν ήδη επιλεγεί. Αυτή η τεχνική ονομάζεται *Μεταβλητή Μέθοδος Αναζήτησης* (floating search method) και εφαρμόζεται σε δύο συστήματα. Ένα παράδειγμα αποτελεί η *Σειριακή Εμπρόσθια Μεταβλητή Επιλογή* (Sequential Forward Floating Selection - SFFS), ο αλγόριθμος της οποίας αποτελεί βελτιστοποίηση της μεθόδου της Σειριακής Εμπρόσθιας Επιλογής (SFS). Η βασική ιδέα της μεθόδου αυτής είναι ότι τα νέα χαρακτηριστικά επιλέγονται σύμφωνα με τη διαδικασία SFS, ξεκινώντας από το τρέχον σύνολο, ενώ στη συνέχεια ακολουθεί μια σειρά από διαδοχικούς αποκλεισμούς του χειρότερου χαρακτηριστικού του μόλις ανανεωμένου υποσυνόλου. Ο αλγόριθμος SFFS παρουσιάζεται στον πίνακα 3.1 [30] που ακολουθεί, ενώ το αντίστοιχο διάγραμμα ροής φαίνεται στο σχήμα 3.1.

Πίνακας 3.1: Σύνοψη του αλγορίθμου SFFS

1. Αρχική Επιλογή

Χρησιμοποιώντας τη βασική μέθοδο SFS, επέλεξε το σημαντικότερο χαρακτηριστικό x_{k+1} ως προς το σύνολο X_k , από το σύνολο των διαθέσιμων χαρακτηριστικών $Y - X_k$, ώστε να σχηματιστεί το σύνολο $X_{k+1} = X_k + x_{k+1}$

2. Εξαίρεση υπό Συνθήκη

Βρες το λιγότερο σημαντικό χαρακτηριστικό στο σύνολο X_{k+1} .

2.1. Αν το x_{k+1} είναι το λιγότερο σημαντικό χαρακτηριστικό του X_k , δηλαδή $J(X_{k+1} - x_{k+1}) \geq J(X_{k+1} - x_j), \forall j = 1, 2, \dots, k$

Θέσε $k = k+1$ και επίστρεψε στο βήμα 1.

2.2. Αν κάποιο $x_r, 1 \leq r \leq k$ είναι το λιγότερο σημαντικό χαρακτηριστικό στο σύνολο X_{k+1} , δηλαδή $J(X_{k+1} - x_r) > J(X_k)$, τότε αφάιρεσε το x_r από το X_{k+1} , οπότε προκύπτει το σύνολο $X'_k = X_{k+1} - x_r$.

(Ισχύει $J(X'_k) > J(X_k)$)

2.2.1. Αν $k=2$, τότε θέσε $X_k = X'_k$ και $J(X'_k) = J(X_k)$ και επίστρεψε στο βήμα 1. Αλλιώς πήγαινε στο βήμα 3.

3. Συνέχιση Εξαίρεσης υπό Συνθήκη

Βρες το λιγότερο σημαντικό χαρακτηριστικό x_s στο σύνολο X'_k .

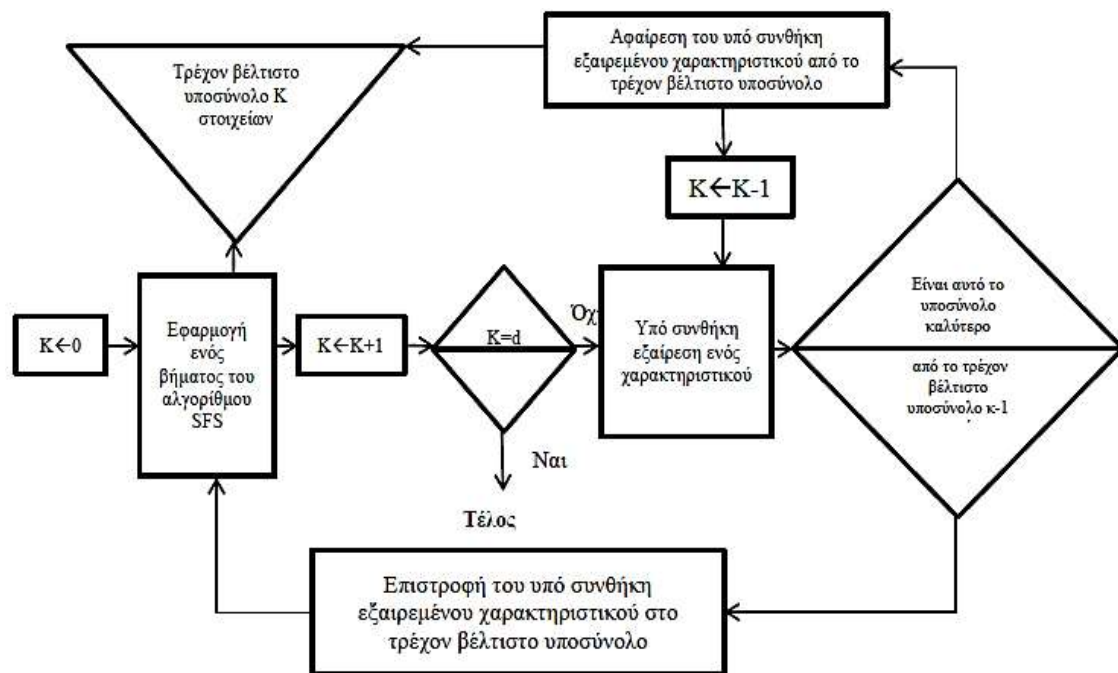
3.1. Αν $J(X'_k - x_s) \leq J(X'_{k-1})$, τότε θέσε $X_k = X'_k$ και $J(X'_k) = J(X_k)$ και επίστρεψε στο βήμα 1.

3.2. Αν $J(X'_k - x_s) > J(X'_{k-1})$, τότε αφάιρεσε το x_s από το X'_k , οπότε προκύπτει το σύνολο $X'_{k-1} = X'_k - x_s$.

Θέσε $k = k - 1$.

3.2.1. Αν $k=2$, τότε θέσε $X_k = X'_k$ και $J(X'_k) = J(X_k)$ και επίστρεψε στο βήμα 1.

Αλλιώς, πήγαινε στο βήμα 3.



Σχήμα 3.1: Διάγραμμα ροής του αλγορίθμου επιλογής χαρακτηριστικών SFFS [30].

Ο αλγόριθμος SFFS του πίνακα αρχικοποιείται με $k=0$ και $X_0 = \emptyset$ και στη συνέχεια χρησιμοποιείται ο αλγόριθμος SFS, μέχρι να προκύψει το X_2 , να προκύψει δηλαδή ένα σύνολο με δύο χαρακτηριστικά και στη συνέχεια μεταβαίνει στο βήμα 1. Τερματίζεται όταν προκύψει σύνολο με τον επιθυμητό αριθμό χαρακτηριστικών l . Παρόλο που ο SFFS δεν εγγυάται την εύρεση όλων των βέλτιστων υποσυνόλων, αποδίδει πολύ καλύτερα σε σύγκριση με τον απλό SFS, υπό το κόστος βέβαια της αυξημένης πολυπλοκότητας [2], [30].

Optimal Searching Techniques

Οι τεχνικές αυτές είναι εφαρμόσιμες όταν το κριτήριο διαχωρισιμότητας είναι μονότονο, δηλαδή ισχύει η σχέση:

$$C(x_1, \dots, x_i) \leq C(x_1, \dots, x_i, x_{i+1})$$

Η ιδιότητα αυτή επιτρέπει την αναγνώριση του βέλτιστου συνδυασμού, με αρκετά χαμηλότερο υπολογιστικό κόστος σε σχέση με την filter approach [2]. Δεν θα ασχοληθούμε περισσότερο με αυτές τις τεχνικές στην παρούσα εργασία.

3.1.3 Στατιστικά Χαρακτηριστικά

Στα πλαίσια της παρούσας μελέτης, τα βιοσήματα τα οποία καλούμαστε να ταξινομήσουμε είναι τα μονοδιάστατα βιοσήματα και πιο συγκεκριμένα τα ΗΕΓ, ΗΜΓ και ΗΚΓ. Συνδυάζοντας το δεδομένο αυτό με τους κανόνες που παρουσιάστηκαν παραπάνω για την επιλογή των χαρακτηριστικών ενός βιοσήματος, καταλήξαμε στην τελική λίστα με τα ευρύτερα διαδεδομένα στατιστικά χαρακτηριστικά, τα οποία διευκολύνουν την ταξινόμηση. Τα χαρακτηριστικά αυτά επιλέγονται πολύ συχνά, σε εφαρμογές ταξινόμησης, αφού με τις πληροφορίες που περιέχουν, ενισχύουν την ικανότητα διάκρισης μεταξύ των προτύπων. Έτσι, επιτυγχάνεται υψηλότερη απόδοση των ταξινομητών σε ένα δεδομένο πρόβλημα ταξινόμησης. Εξάγουμε, λοιπόν, οκτώ κοινά στατιστικά χαρακτηριστικά στο πεδίο του χρόνου και ένα ένατο στο πεδίο της συχνότητας, για κάθε τύπο αποθορυβοποιημένου βιοσήματος μεγέθους N ($X_n, n \in [1 \dots N]$), τα οποία θα βοηθήσουν στην καλύτερη και γρηγορότερη ταξινόμησή του. Τα χαρακτηριστικά αυτά είναι: η μέγιστη τιμή (max), η ελάχιστη τιμή (min), η μέση τιμή (mean value), η τυπική απόκλιση (standard deviation), η μέση τιμή της απόλυτης πρώτης διαφοράς, η κύρτωση (kurtosis), η ασυμμετρία (skewness), η εντροπία (entropy) του συστήματος και οι συντελεστές του μοντέλου αυτό-παλινδρόμησης (auto regressive model) [30], [32]:

1. **Μέγιστη τιμή:** x_{max}
2. **Ελάχιστη τιμή:** x_{min}
3. **Μέση Τιμή:** δηλαδή το άθροισμα των τιμών του σήματος για κάθε χρονική στιγμή, προς τον αριθμό των χρονικών στιγμών. Αν το σήμα λαμβάνει και

αρνητικές τιμές είναι αρκετά συχνό το φαινόμενο να χρησιμοποιούμε την απόλυτη τιμή του σήματος για τον υπολογισμό της μέσης τιμής του.

$$\bar{x} = \frac{1}{N} \sum_{n=1}^N |x_n|$$

4. **Τυπική Απόκλιση** (μεταβλητότητα): δηλαδή πόσο μεταβάλλονται οι τιμές του σήματος από τη μέση τιμή του.


$$\sigma = \left(\frac{1}{N-1} \sum_{n=1}^N (x_n - \bar{x})^2 \right)^{1/2}$$

5. **Μέση τιμή της απόλυτης πρώτης διαφοράς:**

$$\delta = \left(\frac{1}{N-1} \sum_{n=1}^{N-1} |x_{n+1} - x_n| \right)$$

6. **Κύρτωση:** δηλαδή το πώς κατανέμονται οι τιμές κατά μήκος μιας γραφικής παράστασης, με τη μεγάλη κύρτωση να αναφέρεται σε κατανομές με εντονότερες κορυφές και μακρύτερες ουρές, ενώ τη μικρότερη κύρτωση αναφέρεται σε κατανομές με πιο στρογγυλοποιημένες κορυφές και κοντύτερες ουρές.


$$k = \frac{\frac{1}{N} \sum_{n=1}^N (x_n - \bar{x})^4}{\left(\frac{1}{N} \sum_{n=1}^N (x_n - \bar{x})^2 \right)^2} - 3$$



Σχήμα 3.2: Οι μορφές των διαφόρων κατανομών ανάλογα με την τιμή (θετική, αρνητική ή μηδενική) της κύρτωσης.

7. **Ασυμμετρία:** δηλαδή πόσο ασύμμετρο είναι το σύστημα των δεδομένων μας σε σχέση με το μεσαίο σημείο (πόσο “γέρνει” η κατανομή πιθανότητας μιας τυχαίας μεταβλητής προς τη μια πλευρά του μέσου όρου), όσο απομακρύνεται από το μέσο μεγαλώνει, αρνητικά προς τα δεξιά και θετικά προς τα αριστερά.

$$\gamma = \frac{\frac{1}{N} \sum_{n=1}^N (x_n - \bar{x})^3}{\left(\frac{1}{N} \sum_{n=1}^N (x_n - \bar{x})^2\right)^{3/2}}$$



Σχήμα 3.3: Η ασυμμετρία είναι αρνητική όταν η καμπύλη εξογκώνεται προς τα δεξιά και έχει μια μεγάλη ουρά προς τα αριστερά και θετική στην αντίθετη περίπτωση.

8. **Εντροπία:** δηλ. το μέτρο αβεβαιότητας, το μέγεθος της τάξης-αταξίας των δεδομένων που παρατηρείται.

$$H(X) = \sum_{n=1}^N p_n \log_2 \left(\frac{1}{p_n} \right) = - \sum_{n=1}^N p_n \log_2(p_n)$$

9. **Μοντέλο Αυτο-παλινδρόμησης** (Auto Regressive model - AR): αποτελεί την αναπαράσταση ενός τύπου τυχαίας διαδικασίας και περιγράφει το κάθε δείγμα του σήματος ως άθροισμα του γραμμικού συνδυασμού των προηγούμενων δειγμάτων και του σφάλματος του λευκού θορύβου.

$$x_n = - \sum_{i=1}^p a_i x_{n-i} + w_n$$

όπου x_n είναι δείγμα του σήματος, a_i είναι AR συντελεστής, w_n είναι ο λευκός θόρυβος και p είναι ο βαθμός του AR μοντέλου.

3.2 Εξαγωγή Χαρακτηριστικών

3.2.1 Εισαγωγή

Στην ενότητα αυτή, παρουσιάζεται το θεωρητικό υπόβαθρο των μεθόδων που είναι ευρέως διαδεδομένες και χρησιμοποιούνται για την εξαγωγή χαρακτηριστικών από βιοσήματα στα πλαίσια διαφόρων εφαρμογών ταξινόμησης. Η εξαγωγή χαρακτηριστικών πραγματοποιείται μετά από την προεπεξεργασία των συλλεγόμενων

σημάτων (preprocessing - αποθορυβοποίηση με φίλτρα κλπ) και την επιλογή των περιοχών ενδιαφέροντος και έχει ως στόχο την λήψη των χαρακτηριστικών εκείνων, τα οποία περιέχουν πληροφορία κατάλληλη για χρήση σε συστήματα ταξινόμησης, δηλαδή την πληροφορία που θα επιτρέψει τον ευκολότερο διαχωρισμό των διαφόρων τάξεων του προβλήματος και την αποδοτικότερη αναγνώριση των διαφόρων προτύπων [5]. Για το σκοπό αυτό, επιδιώκεται η μείωση του μεγέθους των δεδομένων έτσι ώστε να είναι γρηγορότερη και αποδοτικότερη η ταξινόμηση τους, η οποία πραγματοποιείται στο επόμενο στάδιο. Οι μέθοδοι εξαγωγής χαρακτηριστικών, δηλαδή, μετασχηματίζουν τα δεδομένα σε ένα χώρο χαμηλότερης διάστασης στον οποίο αυτά διατηρούν την Ευκλείδεια δομή τους, αλλά δεν πάσχουν από την «κατάρα της διαστασιμότητας». Η εξαγωγή χαρακτηριστικών συνήθως περιλαμβάνει τη δημιουργία νέων σύνθετων χαρακτηριστικών, τα οποία σχηματίζονται από τα αρχικά χαρακτηριστικά.

Στην παρούσα εργασία θα μελετήσουμε αναλυτικά και τους πέντε βασικούς τύπους μεθόδων εξαγωγής χαρακτηριστικών από βιοσήματα [5]:

1. Μέθοδος Εξαγωγής Χαρακτηριστικών στο Πεδίο του Χρόνου (π.χ. στατιστικά μεγέθη, ιστογράμματα).
2. Μέθοδος Εξαγωγής Χαρακτηριστικών στο Πεδίο της Συχνότητας (π.χ. μετασχηματισμός Fourier (FT), DTF, μοντέλο αυτοπαλινδρόμησης, μοντέλο κινούμενων μέσων όρων).
3. Μέθοδος Εξαγωγής Χαρακτηριστικών στο Πεδίο Χρόνου-Συχνότητας (π.χ. μετασχηματισμός wavelet (WT), μετασχηματισμός Fourier βραχέως χρόνου (STFT)).
4. Μη γραμμική Μέθοδος Εξαγωγής Χαρακτηριστικών (π.χ. ανάλυση εντροπίας Shannon, ανάλυση διακύμανσης μετά την αφαίρεση της τάσης (DFA), fractals).
5. Μέθοδος Εξαγωγής Χαρακτηριστικών με ευφυείς τεχνικές, δηλαδή με συνδυασμό των παραπάνω μεθόδων.

3.3 Πειραματικές μεθοδολογίες εξαγωγής χαρακτηριστικών σε προβλήματα ταξινόμησης μονοδιάστατων βιολογικών σημάτων

Όπως καταλαβαίνουμε, η απόδοση των μεθόδων εξαγωγής χαρακτηριστικών δεν είναι πάντα σταθερή και εξαρτάται εκτός από τον τύπο της μεθόδου και από το βιοσήμα στο οποίο η μέθοδος εφαρμόζεται. Η ίδια μέθοδος, δηλαδή, θα έχει διαφορετική απόδοση αν εφαρμοστεί σε δύο διαφορετικά είδη βιολογικών σημάτων. Σε αυτό το σημείο, λοιπόν, θα χωρίσουμε τις μεθόδους εξαγωγής χαρακτηριστικών που θα μελετήσουμε, σε τρεις μεγάλες κατηγορίες με βάση το μονοδιάστατο βιολογικό σήμα στο οποίο εφαρμόζονται, για να προκύψουν τα βέλτιστα αποτελέσματα ταξινόμησης. Οι τρεις αυτές κατηγορίες μεθόδων είναι: (1) οι μέθοδοι που χρησιμοποιούνται για την ταξινόμηση ηλεκτροεγκεφαλογραφημάτων (HEΓ), (2) οι μέθοδοι που εφαρμόζονται συχνότερα για την ταξινόμηση ηλεκτροκαρδιογραφημάτων (HKΓ) και (3) οι μέθοδοι που εφαρμόζονται με επιτυχία στην ταξινόμηση ηλεκτρομυογραφημάτων (HMG). Τα τρία αυτά σήματα είναι τα πιο ευρέως διαδεδομένα μονοδιάστατα βιοσήματα, γι' αυτό και στην παρούσα μελέτη θεωρήθηκε σωστό να μελετηθούν οι μέθοδοι εξαγωγής χαρακτηριστικών που συνδυάζονται καλύτερα με αυτά. Έτσι, το τρίτο κεφάλαιο της εργασίας μας διαρθρώνεται σε 3 υποενότητες, η καθεμία από τις οποίες αντιστοιχεί στην ανάλυση ενός από τα παραπάνω βιολογικά σήματα.

3.3.1 Μέθοδοι Εξαγωγής Χαρακτηριστικών σε Ηλεκτροεγκεφαλογραφήματα

3.3.1.1 Εξαγωγή χαρακτηριστικών με χρήση της μεθόδου του μονοδιάστατου δυαδικού προτύπου (1D-LBP)

Σε αυτήν την ενότητα θα αναφερθούμε στη μέθοδο των *τοπικών δυαδικών προτύπων* (local binary patterns) και τη χρήση της στην ταξινόμηση ηλεκτροεγκεφαλογραφημάτων για επιληψία, η οποία παρουσιάζεται λεπτομερώς στην ερευνητική εργασία [33]. Σε αυτή τη μελέτη, εφαρμόζεται μια αποδοτική προσέγγιση για την εξαγωγή χαρακτηριστικών από σήματα ηλεκτροεγκεφαλογραφήματος (HEG signals), μέσω της μεθόδου one-dimensional local binary pattern (1D-LBP). Οι συγγραφείς περιγράφουν μια μέθοδο που αποτελείται από δύο στάδια: α) εξαγωγή χαρακτηριστικών με την 1D-LBP και β) ταξινόμηση του σήματος με αλγόριθμους ταξινόμησης. Τα αποτελέσματα εφαρμογής της μεθόδου έδειξαν ότι η προτεινόμενη τεχνική θα μπορούσε να έχει υψηλή ακρίβεια όσον αφορά την ταξινόμηση ηλεκτροεγκεφαλογραφημάτων για επιληψία. Επίσης, στην παρούσα μελέτη [33], γίνεται μια προσπάθεια για την ανάπτυξη ενός συστήματος εξαγωγής χαρακτηριστικών γενικού σκοπού, το οποίο μπορεί να χρησιμοποιηθεί για την εξαγωγή χαρακτηριστικών από διαφορετικές κατηγορίες ηλεκτροεγκεφαλογραφημάτων.


Το ηλεκτροεγκεφαλογράφημα είναι μια από τις πιο συνηθισμένες μεθόδους εντοπισμού για τη διάγνωση της επιληψίας [34]. Τα ηλεκτροεγκεφαλογραφήματα περιέχουν κάποιες πληροφορίες, όπως αιχμές (κορυφές) και αιχμηρά κύματα, τα οποία έχουν σημαντικό ρόλο στην αναγνώριση επιληπτικής ζώνης πριν από χειρουργικές εκτιμήσεις [35, 36]. Στις μέρες μας, η επιληψία διαγιγνώσκεται με οπτική παρατήρηση των εγκεφαλογραφημάτων [37]. Αυτή η διαδικασία είναι αρκετά κουραστική και χρονοβόρα, καθώς ο όγκος των σημάτων που λαμβάνονται από ειδικά ηλεκτρόδια που εμφυτεύονται στον εγκέφαλο κατά τη διάρκεια μιας εγχείρισης, είναι τεράστιος. Έτσι, η ανάπτυξη αυτόματων εργαλείων για την ταξινόμηση των εγκεφαλογραφημάτων είναι υψίστης σημασίας.

Τα τελευταία χρόνια, νέες μέθοδοι έχουν αναπτυχθεί για την αυτόματη ταξινόμηση των κρίσεων στα ηλεκτροεγκεφαλογραφήματα, χωρίς να απαιτούνται ώρες οπτικού ελέγχου [36]. Τα χαρακτηριστικά εξάγονται από το ηλεκτροεγκεφαλογράφημα στα πρώτα βήματα και στη συνέχεια χρησιμοποιούνται ως είσοδος για τη διαδικασία ταξινόμησης στο δεύτερο στάδιο. Η εξαγωγή χαρακτηριστικών από το ηλεκτροεγκεφαλογράφημα γίνεται συνήθως με χρήση τεχνικών μετασχηματισμού χρόνου-συχνότητας ή time-scale, όπως ο μετασχηματισμός Fourier βραχέος χρόνου (short time Fourier transform - STFT) [38], ο γρήγορος μετασχηματισμός Fourier (fast Fourier transform - FFT) [39] και ο μετασχηματισμός κυματιδίου (Wavelet transform - WT) [40, 41]. Στο στάδιο της ταξινόμησης, τα διανύσματα χαρακτηριστικών που αποκτήθηκαν από τη διαδικασία του μετασχηματισμού εφαρμόζονται ως είσοδος στον αλγόριθμο ταξινόμησης, όπως τα τεχνητά νευρωνικά δίκτυα (ANN) [42, 43], οι μηχανές διανυσμάτων υποστήριξης (SVM) [40], το μοντέλο ανάμιξης (Mixture model) [41] και η μηχανή ακραίας μάθησης (Extreme learning machine - ELM) [44].

Στη συγκεκριμένη μελέτη προτείνεται μια αποδοτική προσέγγιση βασισμένη στη μέθοδο one-dimensional local binary pattern (1D-LBP), για την εξαγωγή ποσοτικών χαρακτηριστικών από ηλεκτροεγκεφαλογραφήματα. Τα τοπικά δυαδικά πρότυπα (LBP) έχουν χρησιμοποιηθεί εκτενώς για την ανάλυση της υψής διδιάστατων εικόνων

λόγω της διακριτικής τους ικανότητας και υπολογιστικής απλότητας [45, 46, 47]. Πρόσφατα, αναπτύχθηκε μια νέα LBP μέθοδος για επεξεργασία σημάτων [47], η οποία χρησιμοποιήθηκε επιτυχώς στην ανίχνευση φωνητικής δραστηριότητας σε σήματα ομιλίας που μπορούν να είναι μη-στάσιμα στη φύση [48]. Έτσι, η 1D-LBP μέθοδος μπορεί να θεωρηθεί ως μια αποδοτική προσέγγιση εξαγωγής των μοναδικών και εξεχόντων χαρακτηριστικών σε μη-στάσιμα εγκεφαλικά σήματα. Ωστόσο, η απόδοση της προτεινόμενης μεθόδου θα πρέπει να επαληθευθεί για θέματα ταξινόμησης επιληπτικών ηλεκτροεγκεφαλογραφημάτων. Γι' αυτό το λόγο, το σύστημα ταξινόμησης που βασίζεται στην 1D-LBP μέθοδο εξαγωγής χαρακτηριστικών εφαρμόστηκε για προβλήματα ταξινόμησης ΗΕΓ. Το προτεινόμενο σύστημα αποτελείται από δύο στάδια: αντιπροσωπευτική εξαγωγή χαρακτηριστικών από ΗΕΓ και ταξινόμηση των εξαγόμενων χαρακτηριστικών με χρήση αλγορίθμου ταξινόμησης. Στο πρώτο στάδιο, η 1D-LBP χρησιμοποιήθηκε για την εξαγωγή χρήσιμων χαρακτηριστικών από ΗΕΓ. Έτσι, η διάσταση των χαρακτηριστικών εισόδου μειώθηκε σημαντικά, για τη διάκριση των επιληπτικών ΗΕΓ. Στο δεύτερο στάδιο, τα χαρακτηριστικά που εξήχθησαν χρησιμοποιήθηκαν ως είσοδοι σε διαφορετικούς ταξινομητές για την ταξινόμηση επιληπτικών ΗΕΓ, όπως BayesNet, SVM, ANN, λογιστική παλινδρόμηση (logistic regression - LR) και functional tree (FT). Ο σκοπός ήταν να αποδειχθεί ότι τα χαρακτηριστικά που εξάχθηκαν με τη 1D-LBP μέθοδο, λειτουργούν καλά σε διαφορετικούς ταξινομητές. Η προτεινόμενη μέθοδος ελέγχθηκε σε ένα σύνολο δεδομένων επιληπτικών ΗΕΓ, το οποίο αποκτήθηκε από το τμήμα Επιληψίας του πανεπιστημίου της Βόννης στη Γερμανία. Στην παρούσα μελέτη χρησιμοποιήθηκαν πέντε τύποι επιληπτικών ΗΕΓ (A, B, C, D και E) καθένας από τους οποίους έχει 100 σειρές δεδομένων. Επιπλέον, για μια καλύτερη επικύρωση, παρουσιάστηκαν η σύγκριση των επιδόσεων μεταξύ της προτεινόμενης μεθόδου και προηγούμενων αναφορών της βιβλιογραφίας.

Το σύνολο δεδομένων, λοιπόν, το οποίο αποκτήθηκε από το Κέντρο Επιληψίας του πανεπιστημίου της Βόννης, αποτελείται από πέντε σετ (ομάδες) που ονομάζονται σετ A έως E. Το κάθε σετ διαρκεί 23,6s, αποτελούμενο από 100 τμήματα ΗΕΓ που καταγράφονται στην επιφάνεια του κεφαλιού με ένα μονό κανάλι. Ως εκ τούτου, υπάρχουν 100 δείγματα για κάθε ομάδα (A, B, C, D, E). Τα σήματα ΗΕΓ των ομάδων A και B καταγράφηκαν σε πέντε υγιείς εθελοντές, ενώ τα μάτια τους ήταν ανοιχτά και κλειστά, αντίστοιχα. Τα σήματα της ομάδας C καταγράφηκαν σε ασθενείς πριν την επιληπτική κρίση στον ημισφαιρικό σχηματισμό του ιππόκαμπου, ενώ τα ΗΕΓ της ομάδας D καταγράφηκαν από επιληπτογενή ζώνη. Τέλος, τα σήματα ΗΕΓ στην ομάδα E καταγράφηκαν από ασθενείς κατά τη διάρκεια μιας επιληπτικής κρίσης. Όλα τα δεδομένα ψηφιοποιήθηκαν μέσω ενός 12 bit A/D μετατροπέα με συχνότητα δειγματοληψίας 173.61 Hz. Έτσι, κάθε τμήμα ΗΕΓ περιείχε 4096 σημεία δειγματοληψίας. Η εικόνα 3.1 απεικονίζει το δείγμα των σημάτων ΗΕΓ για καθένα από τα πέντε σύνολα.



Εικόνα 3.1: Παραδείγματα ΗΕΓ σημάτων για κάθε ένα από τα πέντε διαφορετικά σετ [33].

Local Binary Patterns

Η μέθοδος LBP [49], είναι ένα ισχυρό εργαλείο περιγραφής της υφής και ορίζεται ως ένα γκρι-κλίμακας σταθερό μέτρο της υφής, που προέρχεται από ένα γενικό ορισμό της υφής σε μια τοπική «γειτονιά» [45]. Για κάθε εικονοστοιχείο σε μία 2D εικόνα, ένας δυαδικός κωδικός παράγεται θέτοντας ως κατώφλι στην τιμή του εικονοστοιχείου, την τιμή του κεντρικού pixel. Η βασική εκδοχή της LBP λαμβάνει υπ' όψιν της μόνο τους οκτώ γείτονες ενός pixel, αλλά ο ορισμός έχει επεκταθεί για να συμπεριλάβει όλες τις κυκλικές «γειτονιές» με οποιοδήποτε αριθμό εικονοστοιχείων [49, 50]. Διαφορετικές παραλλαγές της LBP μπορούν να οριστούν ανάλογα με τους γείτονες (βλ. Εικόνα 3.2).

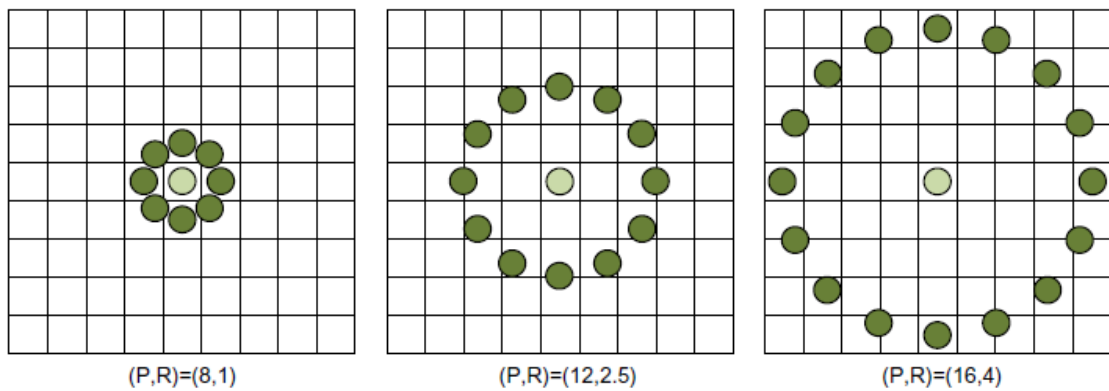
Σε γενικές γραμμές, στην $LBP_{P,R}$, όπου το R ορίζεται από ένα σύνολο διαφορετικών μοντέλων πολλαπλής κλίμακας, το R δηλώνει την ακτίνα του μοντέλου, ενώ το P είναι ο αριθμός των γειτόνων. Σε μια δεδομένη θέση ενός εικονοστοιχείου (pixel) (x_k, y_k) , η LBP “βάζει ετικέτες” στα pixels μιας εικόνας χρησιμοποιώντας την τιμή του κεντρικού pixel ως τιμή κατωφλίου της «γειτονιάς» του κάθε pixel. Εάν η τιμή του γειτονικού pixel είναι μεγαλύτερη ή ίση με την τιμή του κεντρικού pixel, αυτό το εικονοστοιχείο λαμβάνει την τιμή 1, αλλιώς παίρνει την τιμή 0. Στη συνέχεια, δημιουργείται ένας LBP κωδικός για μια γειτονιά, όπως φαίνεται στην Εικόνα 3.3. Η δεκαδική τιμή αυτού του δυαδικού κωδικού δίνει τις τοπικές δομικές πληροφορίες γύρω από το δεδομένο pixel.

Η Εικόνα 3.3 δείχνει μια βασική LBP μέθοδο, όπου $P = 8$ και $R = 1$. Μελέτες έδειξαν επίσης ότι ένα μικρό υποσύνολο των 2^P (LBP^{all}) προτύπων αντιπροσώπευαν την πλειοψηφία της υψής των εικόνων, πάνω από το 90% όλων των προτύπων για LBP (8, 1). Αυτά τα πρότυπα, που ονομάζονται ομοιόμορφα πρότυπα (LBP^{u2}), περιέχουν το πολύ δύο bitwise μεταβάσεις από το 0 στο 1 ή αντίστροφα για μια κυκλική δυαδική συμβολοσειρά. Η μαθηματική διατύπωση της LBP για ένα pixel έχει ως εξής [46, 51]:


$$t = G(x_i) - G(x)$$

$$LBP(x) = \sum_{i=0}^{P-1} S(t) \times 2^i, \text{ όπου } S(t) = \begin{cases} 1, & t \geq 0 \\ 0, & t < 0 \end{cases}$$

όπου x η τοποθεσία του κεντρικού pixel, x_i η τοποθεσία του i -οστού γειτονικού pixel και $G(\bullet)$ η τιμή της έντασης του pixel. Σημειώνουμε σε αυτό το σημείο ότι το κάθε bit από τον LBP κωδικό έχει το ίδιο επίπεδο σημαντικότητας και ότι δύο διαδοχικές τιμές bits μπορεί να έχουν τελείως διαφορετικό νόημα.



Εικόνα 3.2: Κυκλικά συμμετρικά σύνολα γειτόνων για διαφορετικά (P, R) [33].



Εικόνα 3.3: Υπολογισμός των αρχικών LBP κωδικών [33].

1D - Local Binary Patterns

Η μέθοδος 1D - LBP, η οποία προήλθε από τα στάδια υλοποίησης της 2D - LBP μεθόδου, προτάθηκε για πρώτη φορά από τον *Chatlani et al.* για την ανίχνευση σημάτων ομιλίας τα οποία είναι μη-στάσιμα στη φύση [47]. Η βασική λειτουργία της 1D - LBP είναι αρκετά παρόμοια με τη λειτουργία της διδιάστατης μεθόδου για την υφή. Ωστόσο, αναλύει διαδοχικά μια «γειτονιά» δειγμάτων σε δεδομένα χρονοσειρών. Για κάθε δείγμα δεδομένων σε ένα σήμα, παράγεται ένας δυαδικός κωδικός θέτοντας ως κατώφλι στην τιμή του δείγματος, την τιμή του κεντρικού δείγματος. Αυτή η διαδικασία πραγματοποιείται επαναληπτικά σε ολόκληρο το σήμα. Η συνάρτηση της 1D - LBP σε ένα δείγμα δίνεται ως εξής:

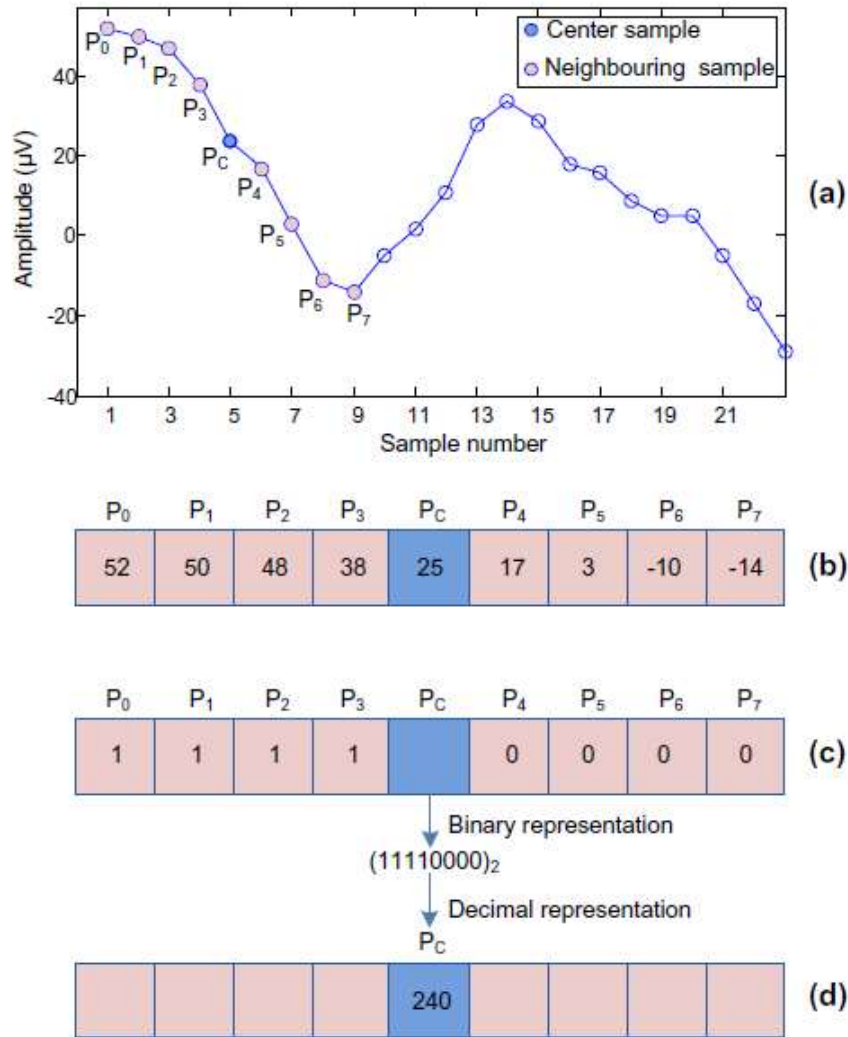
$$t = P_i - P_C$$
$$LBP(x) = \sum_{i=0}^P F(t) \times 2^i, \text{ όπου } F(t) = \begin{cases} 1, & t \geq 0 \\ 0, & t < 0 \end{cases}$$

όπου P_i, P_C είναι οι τιμές των γειτόνων και του κεντρικού σημείου, αντίστοιχα.

Εξαγωγή χαρακτηριστικών με την 1D - Local Binary Pattern

Στην ερευνητική εργασία που μελετάμε, η 1D - LBP χρησιμοποιήθηκε ως η μέθοδος εξαγωγής χαρακτηριστικών για την αιχμαλώτιση των σημαντικών πληροφοριών από τα ηλεκτροεγκεφαλογράφημα. Η μέθοδος 1D - LBP περιγράφηκε βήμα προς βήμα μέσα από ένα τμήμα ενός δείγματος ηλεκτροεγκεφαλογραφήματος.

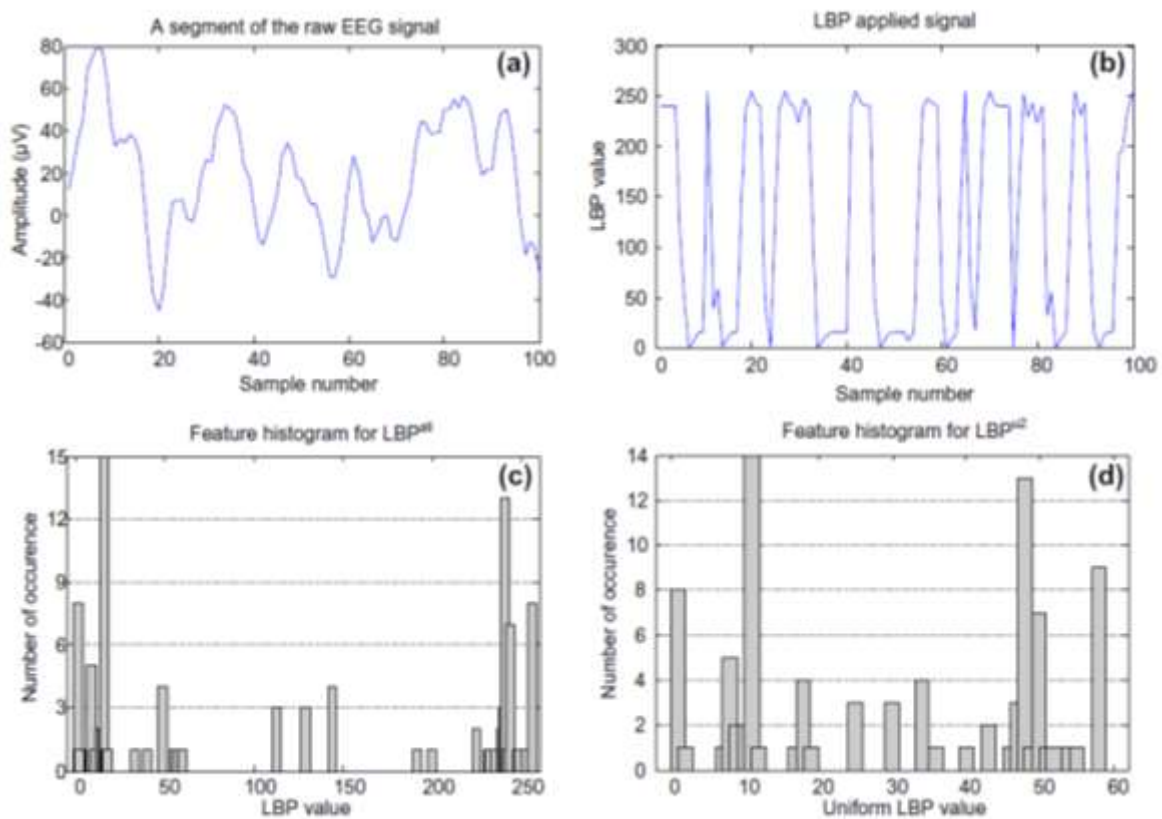
Σε μια δεδομένη θέση του σήματος, όπως φαίνεται στην Εικόνα 3.4(α), η 1D-LBP ορίστηκε ως ένα διατεταγμένο σύνολο των δυαδικών συγκρίσεων, μεταξύ της κεντρικής τιμής και των γειτονικών της τιμών. Για κάθε δείγμα του σήματος, $P/2$ γειτονικά δείγματα θεωρήθηκαν πριν το κεντρικό δείγμα P_C και ο ίδιος αριθμός θεωρήθηκε και μετά το P_C (βλ. Εικόνα 3.4(b)). Έτσι, για $P = 8$, όπως φαίνεται στην Εικόνα 3.4(b), ελήφθησαν τέσσερα γειτονικά δείγματα πριν (P_0, P_1, P_2, P_3) και τέσσερα μετά (P_4, P_5, P_6, P_7) από κάθε κεντρικό δείγμα (P_C). Όπως φαίνεται στην Εικόνα 3.4(c), οι τιμές όλων των γειτονικών δειγμάτων $P = \{P_0, P_1, P_2, P_3, P_4, P_5, P_6, P_7\}$, συγκρίθηκαν με την τιμή του κεντρικού δείγματος (P_C). Όπως και στην Εξίσωση (3), τα 8 γειτονικά δείγματα συγκρίθηκαν με το P_C για την παραγωγή ενός δυαδικού αριθμού $S(P_i - P_C)$. Εάν η γειτονική τιμή P_i είναι μεγαλύτερη ή ίση με την κεντρική τιμή, τότε η τιμή P_i λαμβάνεται 1, ενώ διαφορετικά τίθεται ίση με 0. Έτσι, σχηματίστηκε ένας δυαδικός LBP κωδικός για μια «γειτονιά». Η δεκαδική τιμή αυτού του δυαδικού κώδικα αντιπροσωπεύει τις τοπικές δομικές πληροφορίες γύρω από το δεδομένο P_C (βλέπε Εικόνα 3.4(d)).



Εικόνα 3.4: Στάδια υλοποίησης του κωδικού. (a) ένα τμήμα ενός δείγματος εγκεφαλικού σήματος, (b) τιμές δειγμάτων του υπο-σήματος, (c) συγκρίνοντας γειτονικά δείγματα με το κεντρικό και 8 bit δυαδική αναπαράσταση και (d) δεκαδική αναπαράσταση [33].

Τα παραπάνω στάδια διεξήχθησαν για όλα τα δείγματα του διανύσματος του σήματος. Με την εφαρμογή αυτής της διαδικασίας, σχηματίστηκε ένα σήμα LBP, το οποίο έχει τιμές που κυμαίνονται από 0 (00000000) έως 255 (11111111). Κάθε τιμή LBP αντιστοιχεί σε ένα διαφορετικό πρότυπο. Όταν δημιουργήθηκε το ιστόγραμμα του λαμβανόμενου LBP σήματος, έδειξε πόσο συχνά κάθε ένα από αυτά τα 256 διαφορετικά πρότυπα (LBP^{all}) εμφανίζεται σε ένα δεδομένο σήμα. Ωστόσο, είναι δυνατό να μειωθεί ο αριθμός των προτύπων σε ένα LBP ιστόγραμμα χωρίς να χάσουμε πολλή πληροφορία χρησιμοποιώντας μόνο ομοιόμορφα πρότυπα. Ένα 1D-LBP πρότυπο ονομάζεται *ομοιόμορφο πρότυπο* (LBP^{u2}) εάν περιέχει το πολύ δύο bitwise μεταβάσεις από το 0 στο 1 ή από το 1 στο 0 στη δυαδική του αναπαράσταση, όταν η δυαδική συμβολοσειρά θεωρείται κυκλική. Για παράδειγμα, το 11100001 (με 2 μεταβάσεις) είναι ένα ομοιόμορφο πρότυπο, ενώ 11110101 (με 4 μεταβάσεις) είναι ένα μη-ομοιόμορφο πρότυπο. Έτσι, η διάσταση των χαρακτηριστικών μειώθηκε σε 58 χαρακτηριστικά. Σε αυτή τη μελέτη, η μέθοδος 1D-LBP χρησιμοποιήθηκε για να

παραχθεί ένα ιστόγραμμα των LBP κωδικών οι οποίοι χρησιμοποιήθηκαν ως εναλλακτική αναπαράσταση των ηλεκτροεγκεφαλογραφημάτων. Η διαδικασία αυτή απεικονίζεται μέσω ενός τμήματος του δείγματος ηλεκτροεγκεφαλογραφήματος που παρουσιάζεται στην Εικόνα 3.5(a). Το πρωτογενές ΗΕΓ αρχικά μετασχηματίστηκε στο πεδίο LBP χρησιμοποιώντας την 1D-LBP προσέγγιση με τα 8 γειτονικά δείγματα (βλέπε Εικόνα 3.5(b)). Όπως φαίνεται στην Εικόνα 3.5(b), το εφαρμοζόμενο LBP σήμα έχει τιμές που κυμαίνονται μεταξύ 0 και 255 για κάθε δείγμα του σήματος. Στη συνέχεια, οι εμφανίσεις του LBP κωδικού από κάθε δείγμα σχεδιάστηκαν μέσω της κατανομής του ιστογράμματος, όπως φαίνεται στην Εικόνα 3.5(c). Αυτή η κατανομή αντιπροσωπεύει ένα διάλυμα χαρακτηριστικών το οποίο περιγράφηκε παραπάνω ως LBP^{all} . Η Εικόνα 3.5(d) δείχνει τις εμφανίσεις των ομοιόμορφων LBP κωδικών κάθε δείγματος (LBP^{u2}). Στο επόμενο στάδιο, οι επιπτώσεις στην επίδοση του συστήματος ταξινόμησης του LBP^{all} και τα μειωμένα LBP^{u2} χαρακτηριστικά που λαμβάνονται από τα σήματα ΗΕΓ, εξετάστηκαν ξεχωριστά.



Εικόνα 3.5: Εξαγωγή χαρακτηριστικών από εφαρμοζόμενο 1D-LBP σήμα, (a) ένα τμήμα του δείγματος ΗΕΓ, (b) το σήμα μετασχηματίζεται στο LBP πεδίο, (c) το ιστόγραμμα όλων των LBP κωδικών, (d) το ιστόγραμμα των ομοιόμορφων LBP κωδικών [33].

3.3.1.2 Εξαγωγή χαρακτηριστικών με χρήση μη-γραμμικών μεθόδων (Higuchi fractal dimension, Petrosian fractal dimension και DFA)

Στην ενότητα αυτή, παρουσιάζεται, με τη βοήθεια της ερευνητικής εργασίας [52], μια μεθοδολογία για την αυτόματη ανίχνευση του επιπέδου επαγρύπνησης του ανθρώπινου εγκεφάλου χρησιμοποιώντας μη γραμμικά χαρακτηριστικά του ηλεκτροεγκεφαλογραφήματος (HEG). Η μεθοδολογία ανίχνευσης του επιπέδου επαγρύπνησης, όπως εφαρμόστηκε από τους ερευνητές, αποτελείται από τρία στάδια: την επιλογή καναλιών HEG, την εξαγωγή χαρακτηριστικών και την ταξινόμηση του HEG. Ηλεκτροεγκεφαλογραφήματα που λαμβάνονται από 64 κανάλια, λοιπόν, υποδιαιρούνται σε τέσσερις επιμέρους ζώνες συχνοτήτων: την άλφα, τη βήτα, τη δέλτα και τη θήτα. Το κριτήριο επιλογής καναλιού που εφαρμόζεται σε κάθε ζώνη συχνοτήτων για την επιλογή των κατάλληλων καναλιών HEG, είναι ο λόγος *Maximum Energy* προς *Shannon Entropy*. Τα σήματα HEG που λαμβάνονται από τα επιλεγμένα κανάλια χωρίζονται περαιτέρω σε επιμέρους ζώνες συχνοτήτων: την άλφα, τη βήτα και την άλφα-βήτα ζώνη. Τρία μη γραμμικά χαρακτηριστικά, τα **Higuchi fractal dimension**, **Petrosian fractal dimension** και **Detrended fluctuation Analysis**, υπολογίζονται για να δημιουργήσουν τρία διανύσματα χαρακτηριστικών ως αντιστοιχία σε κάθε επιμέρους ζώνη συχνοτήτων.

Η δυναμική, μη γραμμική και μη-στατική φύση των σημάτων HEG κάνει την ταξινόμησή τους ένα δύσκολο έργο [53]. Επιπλέον, μελέτες έχουν δείξει ότι η φύση των σημάτων HEG αλλάζει σημαντικά με διαφορετικές καταστάσεις επαγρύπνησης, οι οποίες μπορούν εύκολα να αναγνωριστούν σε διάφορους ρυθμούς σημάτων HEG (δηλ. ρυθμός δέλτα (1-4 Hz), ρυθμός θήτα (4-8 Hz), ρυθμός άλφα (8-13 Hz), ρυθμός βήτα (13-30 Hz), και ρυθμός γάμμα (> 30 Hz)). Τα HEG σήματα δείχνουν χαμηλή τάση (10-30 μV) και γρήγορη δραστηριότητα (16-25 Hz) για ξύπνιους ανθρώπους, ενώ υψηλή τάση (20-40 μV) και αργή δραστηριότητα HEG (8-12 Hz, άλφα ρυθμού) για ανθρώπους που είναι σε κατάσταση υπνηλίας [53]. Η μετάβαση από την εγρήγορση στο στάδιο του ύπνου, χαρακτηρίζεται από υψηλότερες τάσεις και σταδιακά πιο αργές συχνότητες, γνωστές και ως μειώσεις βήτα ρυθμού [53]. Ωστόσο, όταν ένα άτομο εισέρχεται στη φάση του ύπνου, οι θήτα ρυθμοί αυξάνονται και παίρνουν τη θέση των προηγουμένως ισχυρότερων ρυθμών άλφα και βήτα [54].


Η σοβαρή αλλαγή που παρατηρείται στην ηλεκτρική δραστηριότητα του εγκεφάλου ανάλογα με τις διαφορετικές νοητικές καταστάσεις στις οποίες βρίσκεται το άτομο (π.χ. υπνηλία και εγρήγορση), αλλάζει τα εξαγόμενα χαρακτηριστικά σε μεγάλο βαθμό, πράγμα το οποίο προκαλεί ψευδή ερμηνεία των σημάτων HEG από τον αλγόριθμο ταξινόμησης. Ως εκ τούτου, μια διεπαφή εγκεφάλου-υπολογιστή θα πρέπει να παρακολουθεί το επίπεδο της πνευματικής εγρήγορσης του ασθενούς κατά τη διάρκεια της λειτουργίας της. Μελέτες έχουν δείξει ότι ο περιορισμένος αριθμός των ηλεκτροδίων και η φασματική ανάλυση των τυποποιημένων ζωνών των σημάτων HEG θα μπορούσαν να χρησιμοποιηθούν για ταξινόμηση [56]. Προηγουμένως διαθέσιμες μεθοδολογίες εξαγωγής χαρακτηριστικών για την ανίχνευση του επιπέδου επαγρύπνησης, περιλαμβάνουν συνήθως τα χαρακτηριστικά στο πεδίο του χρόνου, χαρακτηριστικά στο πεδίο της συχνότητας, τα χαρακτηριστικά στο πεδίο χρόνου-συχνότητας και μη γραμμικά χαρακτηριστικά [53, 55, 57]. Τα χαρακτηριστικά που βασίζονται στο πεδίο του χρόνου και στο πεδίο της συχνότητας δεν είναι κατάλληλα για μη γραμμικά και μη στάσιμα σήματα HEG [55]. Επίσης, η προσέγγιση στο πεδίο χρόνου-συχνότητας (wavelet) είναι μια μη-προσαρμοστική τεχνική, καθώς το βασικό wavelet δεν μπορεί να αλλάξει εφόσον επιλεγεί. Επιπλέον, το wavelet παρέχει κακή ανάλυση του χρόνου στις χαμηλότερες συχνότητες. Ωστόσο, τα μη γραμμικά

χαρακτηριστικά είναι κατάλληλα για την ανάλυση των σημάτων ΗΕΓ. Οι μελέτες δείχνουν ότι ο συγχρονισμός των δυναμικών συστημάτων αποτελεί βασικό μη γραμμικό φαινόμενο [58] και αρκετές μη γραμμικές τεχνικές εξαγωγής χαρακτηριστικών (π.χ. *Lyapunov Entropy*, *Hurst exponent* και *fractal dimensions*) έχουν αποδειχθεί αποτελεσματικές μέθοδοι για την ανάλυση σημάτων ΗΕΓ για την ανίχνευση της υπνηλίας [57].

Η βέλτιστη επιλογή καναλιού ΗΕΓ γίνεται για να μειώσει το μέγεθος των δεδομένων, την πολυπλοκότητα και το χρόνο υπολογισμού που απαιτείται για την ταξινόμηση. Ο στόχος της παρούσας εργασίας είναι να προτείνει μια αυτόματη μέθοδο για την ανίχνευση των καταστάσεων εγρήγορσης και υπνηλίας του εγκεφάλου, με τη χρήση μη γραμμικών χαρακτηριστικών και τεχνικών μηχανικής μάθησης, σε συνδυασμό με την απαίτηση για ελάχιστο αριθμό των ΗΕΓ καναλιών, έτσι ώστε η BCI να αποφύγει τη δημιουργία εντολής, εάν το άτομο αναγνωρίζεται με υπνηλία. Στην παρούσα μελέτη, μη γραμμικές τεχνικές για την εξαγωγή χαρακτηριστικών των σημάτων ΗΕΓ όπως π.χ. τα Fractal dimensions (FD) και η Detrended Fluctuation Analysis (DFA), με βέλτιστα κανάλια ΗΕΓ έχουν χρησιμοποιηθεί για την ανίχνευση του νοητικού επιπέδου επαγρύπνησης με μειωμένη πολυπλοκότητα και χρόνο υπολογισμού. Η τεχνική βελτιστοποίησης καναλιών και εξαγωγής χαρακτηριστικών που προτείνεται στην παρούσα εργασία, εξετάζεται από τρεις τεχνικές μηχανικής μάθησης, τις Support Vector Machine (SVM), Least Square-Support Vector Machine (LS-SVM) και Artificial Neural Network (ANN) για 10 σετ δεδομένων ΗΕΓ, που καταγράφονται από είκοσι άτομα υπό κατάσταση εγρήγορσης και υπνηλίας.

Τα δεδομένα ΗΕΓ αποκτήθηκαν από μια ανοιχτή βάση δεδομένων ΗΕΓ του Πολιτειακού Πανεπιστημίου του Κέντρου Υγείας Νέας Υόρκης. Η βάση δεδομένων αποτελείται από τα αρχεία ηλεκτροεγκεφαλογραφημάτων 244 ατόμων, όταν κάθε άτομο είχε εκτεθεί σε μια σειρά από εικόνες. Από τα 244 άτομα, τα 122 άτομα ήταν σε κατάσταση εγρήγορσης και τα υπόλοιπα 122 άτομα ήταν σε κατάσταση υπνηλίας. Κάθε άτομο εξετάστηκε για 120 φορές χρησιμοποιώντας 64 ΗΕΓ κανάλια, ενώ ο ρυθμός δειγματοληψίας ήταν 256 Hz.

Στην παρούσα εργασία, τα ΗΕΓ και των 64 ηλεκτροδίων υπό δύο διαφορετικές νοητικές καταστάσεις (εγρήγορση και υπνηλία) υπόκεινται σε βελτιστοποίηση καναλιού. Επιπλέον, τα προτεινόμενα μη γραμμικά χαρακτηριστικά υπολογίζονται από το βελτιστοποιημένο σύνολο των ΗΕΓ καναλιών των είκοσι ατόμων και γίνεται ταξινόμηση. Η Εικόνα 3.6 δείχνει δείγματα ηλεκτροεγκεφαλογραφημάτων που λαμβάνονται από το κανάλι C_z κατά τη διάρκεια τεσσάρων διαφορετικών δοκιμών.



Εικόνα 3.6: Δείγματα ΗΕΓ σημάτων σε κατάσταση υπνηλίας (a-c) και σε κατάσταση εγρήγορσης (d-f), από το κανάλι C_z [52].

Fractal dimensions (FD)

Δεδομένου ότι, η προσέγγιση FD μπορεί να χρησιμοποιηθεί αποτελεσματικά για την ανάλυση μη περιοδικών και ταραχωδών (turbulent) συμπεριφορών των μη κανονικών χρονοσειρών, πολλοί ερευνητές έχουν χρησιμοποιήσει αυτή την προσέγγιση για την εξαγωγή χαρακτηριστικών από βιοϊατρικά σήματα. Τα fractal dimensions μπορούν να υπολογιστούν από διάφορες προσεγγίσεις. Στην παρούσα εργασία, οι αλγόριθμοι *Higuchi* και *Petrosian* χρησιμοποιούνται για την ανάλυση της χρησιμότητας των βασισμένων σε fractal dimensions χαρακτηριστικών, για την ανίχνευση του επιπέδου επαγρύπνησης του ανθρώπου.

A. Higuchi's algorithm. Ο αλγόριθμος του Higuchi [59] υπολογίζει fractal dimensions με υψηλή χρονική ανάλυση, η οποία βασίζεται στη μέτρηση του μήκους καμπύλης. Ο αλγόριθμος Higuchi αξιολογεί το μέσο μήκος της καμπύλης, χρησιμοποιώντας ένα τμήμα από i δείγματα ως μονάδα μέτρησης [64]. Η εκτίμηση Higuchi για τα FD απαιτεί παρακάτω βήματα:

- **Βήμα 1** - Περιγράψτε ένα πεπερασμένο σύνολο με παρατηρήσεις χρονοσειρών, οι οποίες λαμβάνονται σε τακτά χρονικά διαστήματα, ως $y(1), y(2), y(3), \dots, y(m), \dots, y(N)$, όπου $m = 1, 2, 3, \dots, N$ (N : αριθμός των σημείων στις χρονοσειρές). Στην παρούσα εργασία, οι χρονοσειρές είναι οι διαδοχικές τιμές του ΗΕΓ. Για δεδομένες χρονοσειρές, κατασκευάζουμε i νέες χρονοσειρές y_i^j , για ένα εύρος των τιμών του i που κυμαίνονται από 1 έως i_{max} ως εξής:

$$y_i^j = \left\{ y(j), y(j+i), y(j+2i), \dots, y\left(j + \left\lfloor \frac{N-j}{i} \right\rfloor i\right) \right\}, (j = 1, 2, 3, \dots, i) \quad (1),$$

όπου το $[\cdot]$ παριστάνει το συμβολισμό Gauss και τα i, j είναι ακέραιοι. Το j υποδεικνύει τον αρχικό χρόνο και i υποδεικνύει το χρονικό διάστημα.

- **Βήμα 2** - Υπολογίστε το μήκος $L_j(i)$ κάθε καμπύλης y_i^j ως εξής:

$$L_j(i) = \left[\left(\sum_{m=1}^{\text{int} \left(\frac{N-j}{i} \right)} |y(j+m*i) - y(j+(m-1)*i)| \right) \frac{(N-1)}{\text{int} \left(\frac{N-j}{i} \right)} \right] i^{-1} \quad (2)$$

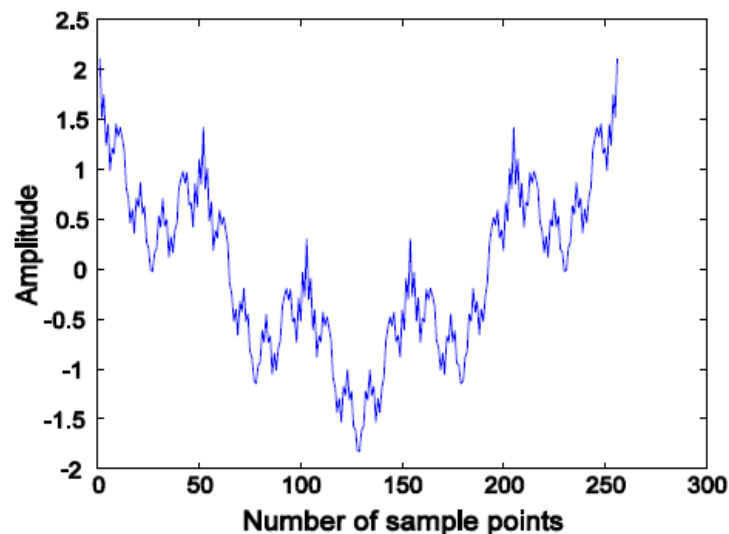
Εδώ ο όρος $\frac{(N-1)}{\text{int} \left(\frac{N-j}{i} \right)}$ αντιπροσωπεύει τον παράγοντα κανονικοποίησης (normalization factor) για το μήκος της καμπύλης του υποσυνόλου των χρονοσειρών [59].

- **Βήμα 3** - Υπολογίστε το μέσο μήκος της καμπύλης για κάθε τιμή του i , $\langle L(i) \rangle$, ως τη μέση τιμή για i σύνολα του $L_j(i)$, για $j = 1, 2, 3, \dots, i$ και επαναλάβετε τον υπολογισμό για $i = 1$ έως i_{max} .
- **Βήμα 4** - Εάν $\langle L(i) \rangle \propto i^{-D}$, τότε η καμπύλη είναι fractal με διάσταση D .


Στην παρούσα εργασία, η τιμή του i_{max} λαμβάνεται από ένα εύρος τιμών i_{max} που εκτείνονται από το 1 έως το 50 χρησιμοποιώντας μία μέθοδο που προτάθηκε από τον Πολυχρονάκη et al. [60]. Το FD του Higuchi υπολογίζεται για κάθε μία από τις τιμές i_{max} για ένα συνθετικό σήμα (ακολουθία Weierstrass). Το σχετικό σφάλμα (relative error - RE) υπολογίζεται για να εκτιμηθεί η ακρίβεια του προτεινόμενου αλγορίθμου χρησιμοποιώντας διαφορετικές τιμές i_{max} , οι οποίες δίνονται ως εξής:

$$RE = FD_e - FD_{td}, \quad (3)$$

όπου FD_e είναι η εκτιμώμενη τιμή fractal dimension του συνθετικού σήματος και FD_{td} είναι η θεωρητική. Η Εικόνα 3.7 δείχνει τη συνθετική ακολουθία Weierstrass με $FD_{td}=1.6$, το οποίο χρησιμοποιείται στην παρούσα μελέτη και η Εικόνα 3.8 δείχνει τη γραφική παράσταση του σχετικού σφάλματος για την ακολουθία Weierstrass. Από την Εικόνα 3.8 παρατηρείται ότι για $i_{max} = 18$, το RE είναι ελάχιστο. Έτσι, τα Higuchi fractal dimensions εκτιμώνται χρησιμοποιώντας $i_{max}=18$.



Εικόνα 3.7: Η συνάρτηση συνημιτόνου Weierstrass για το θεωρητικό fractal dimension ($FD_{td}=1.6$) [52].



Εικόνα 3.8: Το σχετικό σφάλμα για τις εκτιμήσεις των Higuchi FD με i_{max} [52].

B. Petrosian's algorithm. Τα Petrosian FD είναι η απλούστερη και ταχύτερη μέθοδος εκτίμησης FD, η οποία μπορεί να εκφραστεί ως εξής:

$$D = \frac{\log_{10} k}{\log_{10} k + \log_{10} \left(\frac{k}{k + 0.4 * N_d} \right)} \quad (4)$$

όπου το N_d αντιπροσωπεύει τον αριθμό των αλλαγών προσήμου στην παράγωγο του σήματος και D είναι τα Petrosian fractal dimensions [61].

Ανάλυση διακύμανσης μετά την απομάκρυνση της τάσης (Detrended Fluctuation Analysis - DFA)

Η DFA είναι μια μη γραμμική τεχνική, η οποία χρησιμοποιείται για την ποσοτικοποίηση του fractal scaling και των ιδιοτήτων συσχέτισης του σήματος. Επιπλέον, είναι ικανή να διακρίνει μεταξύ των εγγενών διαταραχών που δημιουργούνται από το σύστημα και αυτών που προκαλούνται από κάποιο εξωτερικό σύστημα [62]. Η τεχνική DFA εφαρμόζεται στα σήματα των οποίων η στατιστική ή η δυναμική είναι μη στάσιμες στη φύση. Στον DFA υπολογισμό μιας χρονοσειράς, το $x(t)$ ενός πεπερασμένου μήκους N , ολοκληρώνεται για να δημιουργήσει μια νέα χρονοσειρά $y(i)$ ως εξής:

$$y(i) = \sum_{j=1}^i [x(j) - \langle x \rangle] \quad (5)$$

$$\text{όπου } \langle x \rangle \text{ είναι η μέση τιμή του } x \text{ και προκύπτει ως: } \langle x \rangle = \frac{1}{N} \sum_{j=1}^N x(j) \quad (6)$$

Το βήμα της ολοκλήρωσης χαρτογραφεί (maps) την αρχική χρονοσειρά σε μια αυτο-παρόμοια (self-similar) διαδικασία. Περαιτέρω, μετρείται η κάθετη χαρακτηριστική κλίμακα της χρονοσειράς που ολοκληρώνεται. Για να γίνει αυτό, η $y(i)$ διαιρείται σε χρονικά παράθυρα ίσου μήκους l . Σε κάθε παράθυρο, μια γραμμή

ελαχίστων τετραγώνων προσαρμόζεται στα δεδομένα. Αυτή η γραμμή ελαχίστων τετραγώνων αντιπροσωπεύει την τάση στο παράθυρο και η y συντεταγμένη του τμήματος της ευθείας γραμμής συμβολίζεται με $y_l(i)$. Η τοπική τάση $y_l(i)$ αφαιρείται από την $y(i)$ για κάθε παράθυρο, για να ληφθούν οι ολοκληρωμένες χρονοσειρές από τις οποίες έχει αφαιρεθεί η τάση. Η τάση (trend) στην τετραγωνική ρίζα της μέσης τετραγωνικής διακύμανσης αφαιρείται, για να αποκτήσουμε detrended fluctuation [66].

$$F(l) = \sqrt{\frac{1}{N} \sum_{i=1}^N [y(i) - y_l(i)]^2}$$

Ο υπολογισμός της αφαίρεσης της τάσης επαναλαμβάνεται σε ολόκληρο το σήμα για διαφορετικά μεγέθη παραθύρων l , για να ληφθεί μια σχέση μεταξύ της $F(l)$ και του μεγέθους του παραθύρου l . Μια γραμμική σχέση μεταξύ του $\log(F(l))$ και του μεγέθους του παραθύρου l δείχνει την ύπαρξη κλιμάκωσης δυναμικού νόμου (power law scaling). Ο εκθέτης κλιμάκωσης δείχνει τη στατιστική αυτο-συγγένεια (self-affinity) και μπορεί να υπολογιστεί ως η κλίση της γραφικής παράστασης του $\log(F(l))$ ως προς το $\log(l)$.


Μεθοδολογία επιλογής καναλιού

Η βάση δεδομένων ΗΕΓ που χρησιμοποιήθηκε στην παρούσα μελέτη περιλαμβάνει, όπως αναφέρθηκε, 64 κανάλια με αρχεία ΗΕΓ. Η διαδικασία για την εξεύρεση διανυσμάτων χαρακτηριστικών και την περαιτέρω εκτέλεση ταξινόμησης των σημάτων ΗΕΓ χρησιμοποιώντας και τα 64 κανάλια δεν είναι υπολογιστικά αποδοτική προσέγγιση. Έτσι, είναι επιθυμητό να βελτιστοποιηθούν τα κανάλια ΗΕΓ, προκειμένου να αναπτυχθεί μια υπολογιστικά αποδοτική ΒCI. Το Σχήμα 3.4 αντιπροσωπεύει τη μεθοδολογία που παρουσιάζεται σε αυτήν την ενότητα για τη βέλτιστη επιλογή των καναλιών ΗΕΓ.

Στην προτεινόμενη μεθοδολογία βελτιστοποίησης καναλιού, τα ΗΕΓ σήματα που λαμβάνονται από τα 64 κανάλια αρχικά υποδιαιρούνται σε τέσσερις επιμέρους ζώνες συχνοτήτων δηλ. άλφα, βήτα, δέλτα και θήτα. Ο λόγος της ενέργειας προς την εντροπία Shannon υπολογίζεται από κάθε επιμέρους ζώνη συχνοτήτων ως χαρακτηριστικό των σημάτων ΗΕΓ και δίνεται από τον τύπο:

$$\frac{\text{Energy}}{\text{Shannon Entropy}} = \frac{\sum y(n)^2}{-\sum p_k \log(p_k)}$$

όπου το $y(n)$ αντιπροσωπεύει δείγματα στη ακολουθία δεδομένων ΗΕΓ και p_k είναι οι πιθανότητες ενός δεδομένου να βρίσκεται στον κάδο (being in bin). Εδώ, η Shannon Entropy περιγράφει στατιστικά τη μεταβλητότητα εντός του σήματος ΗΕΓ και θεωρείται ως ο βαθμός της διαταραχής του συστήματος [66].



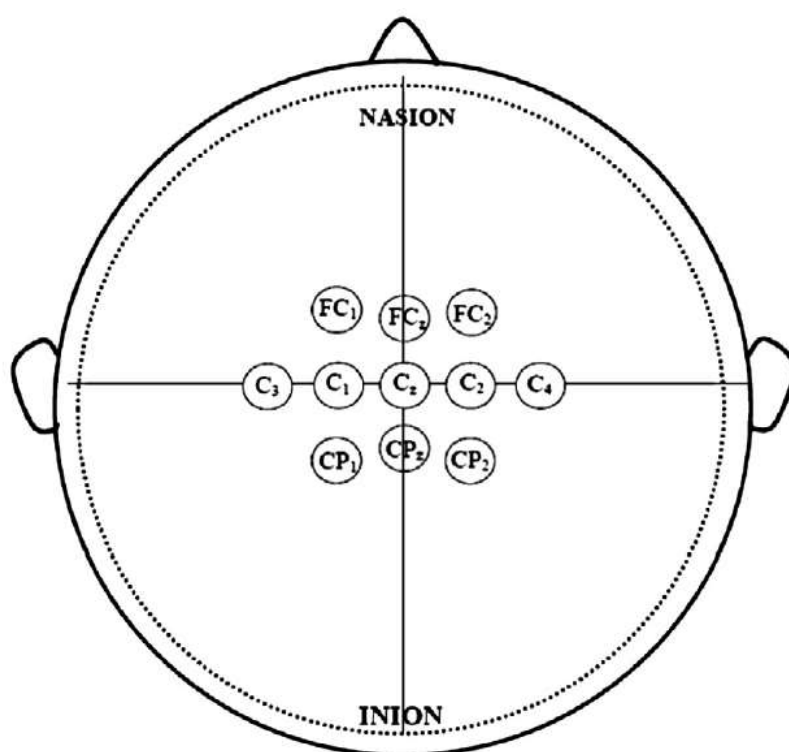
Σχήμα 3.4: Η μεθοδολογία που προτείνεται για τη βελτιστοποίηση των καναλιών ΗΕΓ [52].

Το κριτήριο του λόγου της Μέγιστης Ενέργειας προς την Εντροπία Shannon

Το κριτήριο του λόγου Μέγιστης ενέργειας προς την εντροπία Shannon χρησιμοποιείται, όπως προαναφέρθηκε, για τη βέλτιστη επιλογή των καναλιών ΗΕΓ. Τα κανάλια ΗΕΓ τα οποία δείχνουν μέγιστο ποσό ενέργειας, ενώ ταυτόχρονα ελάχιστο ποσό Εντροπίας Shannon, επιλέγονται για εξαγωγή χαρακτηριστικών. Για να επιτευχθεί αυτό, δεδομένα ΗΕΓ από 64 κανάλια και 70 δοκιμές υποδιαιρούνται σε άλφα και βήτα ζώνες συχνοτήτων. Επιπλέον, τέσσερις κατηγορίες δεδομένων ΗΕΓ

έχουν μοντελοποιηθεί, δηλαδή άλφα δραστηριότητα για κατάσταση εγρήγορσης και υπνηλίας και βήτα δραστηριότητα για εγρήγορση και υπνηλία. Ο λόγος της Ενέργειας προς την Εντροπία Shannon και για τις τέσσερις κατηγορίες δεδομένων ΗΕΓ υπολογίζεται και 10 κανάλια ΗΕΓ με μέγιστο λόγο Ενέργειας προς Εντροπία τα οποία αντιστοιχούν σε κάθε κατηγορία, σημειώνονται.

Έχει παρατηρηθεί ότι έντεκα κεντρικά τοποθετημένα κανάλια (δηλαδή τα Cz, C1, C2, C3, C4, FCz, FC1, FC2, CPz, CP1, CP2) παρουσιάζουν μέγιστο λόγο Ενέργειας προς Εντροπία Shannon για περισσότερες από δύο κατηγορίες. Αυτά τα έντεκα κεντρικά τοποθετημένα κανάλια ΗΕΓ επιλέχθηκαν από 64 κανάλια ΗΕΓ. Στη συνέχεια, τα δεδομένα ΗΕΓ που παρέχονται από αυτά τα έντεκα βελτιστοποιημένα κανάλια προεπεξεργάζονται και εξάγονται μη γραμμικά χαρακτηριστικά για σκοπούς ταξινόμησης. Η Εικόνα 3.9 δείχνει τη θέση των βελτιστοποιημένων καναλιών ηλεκτροεγκεφαλογραφήματος ως προς το σύστημα τοποθέτησης ηλεκτροδίων 10-20.




Εικόνα 3.9: Βελτιστοποιημένα κανάλια ΗΕΓ ως προς το σύστημα 10-20 [52].

Εξαγωγή χαρακτηριστικών και ταξινόμηση

Τα αρχικά δεδομένα ΗΕΓ υποδιαιρούνται σε τρεις επιμέρους ζώνες συχνοτήτων, τις: άλφα (8-12 Hz), βήτα (12-30 Hz) και άλφα-βήτα (8-30 Hz) και στη συνέχεια, τρία μη γραμμικά χαρακτηριστικά τα Higuchi FD, Petrosian FD και DFA υπολογίζονται από κάθε επιμέρους ζώνη συχνοτήτων των σημάτων ΗΕΓ. Οι ζώνες συχνοτήτων δέλτα (1-4 Hz) και Theta (4-8 Hz) δεν λαμβάνονται υπόψη, καθώς δεν προσφέρουν πληροφορίες για το έργο αυτόματης ανίχνευσης της στάθμης επαγρύπνησης.

Μη γραμμικά διανύσματα χαρακτηριστικών δημιουργούνται από τα εξαγόμενα χαρακτηριστικά, για την εκπαίδευση των αλγορίθμων ταξινόμησης. Αφού, τα

χαρακτηριστικά των σημάτων ΗΕΓ υπολογίζονται για τις ζώνες συχνοτήτων άλφα, βήτα και άλφα-βήτα, αυτό εξασφαλίζει την απομάκρυνση του πρόσθετου θορύβου που σχετίζεται με τα σήματα ΗΕΓ πάνω από 30 Hz. Επιπλέον, η εξαγωγή των χαρακτηριστικών για κάθε ζώνη ξεχωριστά και η περαιτέρω ταξινόμηση των δύο νοητικών καταστάσεων, χρησιμοποιώντας αυτά τα χαρακτηριστικά, παρέχουν καλύτερη εικόνα σχετικά με τη συμβολή της κάθε ζώνης για την αυτόματη ανίχνευση της επαγρύπνησης. Το Σχήμα 3.5 παρουσιάζει την προτεινόμενη μεθοδολογία για την αυτόματη ανίχνευση της επαγρύπνησης του ανθρώπινου εγκεφάλου.



Σχήμα 3.5: Προτεινόμενη μεθοδολογία για την αυτόματη ανίχνευση της επαγρύπνησης [52].

3.3.1.3 Εξαγωγή τετραγωνικών χαρακτηριστικών με χρήση μεθόδου βασισμένης στο AR μοντέλο

Η οπτική παρατήρηση ενός επιληπτικού εγκεφαλογραφήματος (HEΓ) από νευρολόγους είναι χρονοβόρα και κοπιαστική. Για να ξεπεραστούν αυτά τα προβλήματα, έχουν αναπτυχθεί πολλές τεχνικές αυτόματης ανίχνευσης της κρίσης που συνδυάζουν επεξεργασία σήματος και μηχανική μάθηση. Παρά το γεγονός ότι σε πρόσφατα άρθρα έχει επιτευχθεί 100% ακρίβεια για ταξινόμηση εγγραφών HEΓ που αντιστοιχούν σε κρίση ή όχι σε κρίση, το αποτέλεσμα της διάκρισης ενός φυσιολογικού HEΓ από ένα επιληπτικό, εξακολουθεί να μην είναι ικανοποιητικό. Σε αυτή την εργασία, προτάθηκε μια μέθοδος που συνδυάζει την Variational Mode Decomposition (VMD) με μια μέθοδο εξαγωγής χαρακτηριστικών βασισμένη στο μοντέλο αυτοπαλινδρόμησης (AR) για την εξαγωγή χαρακτηριστικών και ο ταξινομητής τυχαίου δάσους (random forest classifier) χρησιμοποιήθηκε για το έργο της τριπλής ταξινόμησης. Το αρχικό HEΓ αποσυντίθεται σε ένα σταθερό αριθμό ζωνο-περιορισμένων συναρτήσεων εγγενούς λειτουργίας (BLIMFs) χρησιμοποιώντας τη VMD και μετά, μια λογαριθμική διαδικασία επιβάλλεται σε κάθε BLIMF. Στη συνέχεια, η βέλτιστη εξαγωγή τετραγωνικών χαρακτηριστικών βασισμένη σε AR μοντέλο διεξάγεται σε όλες τις BLIMFs και τα εξαγόμενα διανύσματα χαρακτηριστικών δίνονται ως είσοδος στον ταξινομητή τυχαίου δάσους για ταξινόμηση. Πειραματικά αποτελέσματα σχετικά με το σύνολο δεδομένων επιληπτικών HEΓ της Βόννης δείχνουν ότι η καλύτερη ακρίβεια του προτεινόμενου συστήματος είναι 97.352% και υπερτερεί από τη τεχνική εξαγωγής χαρακτηριστικών σταθερής τάξης που βασίζεται στο AR μοντέλο.

Οι επιληπτικές κρίσεις είναι ένα σύμπτωμα ασθένειας του εγκεφάλου, το οποίο πάντα συμβαίνει αυθόρμητα (ενστικτωδώς) και περιοδικά. Το αξιοσημείωτο αυτό χαρακτηριστικό της επιληψίας, όχι μόνο μπορεί να βρεθεί στον επιληπτικό εγκέφαλο, αλλά υπάρχει και σε ένα φυσιολογικό εγκέφαλο κάτω από μια ποικιλία συνθηκών στα περισσότερα δίκτυα νευρώνων, χωρίς να έχει σημασία σε ποιο είδος ανήκει ο ξενιστής [69]. Το ηλεκτροεγκεφαλογράφημα είναι η συλλογή νευρωνικής πυροδότησης του εγκεφάλου και είναι η πιο συχνά χρησιμοποιούμενη και αποτελεσματική κλινική τεχνική για την εκτίμηση διαταραχών του εγκεφάλου, ειδικά της επιληψίας [70]. Η συμβατική μέθοδος διάγνωσης της επιληψίας βασίζεται σε τεχνητή επισκόπηση του HEΓ από τον ιατρό, αλλά ο οπτικός έλεγχος του HEΓ είναι εξαιρετικά επίπονος και κουραστικός, και μάλιστα, τα αποτελέσματα διαγνώσεων που εκτελούνται από διαφορετικούς νευρολόγους είναι εμπειρικά και μπορεί να παρουσιάζουν σημαντικές διαφορές [71]. Ως εκ τούτου, είναι απαραίτητο να αναπτυχθούν αυτοματοποιημένες -με τη βοήθεια υπολογιστή- διαγνωστικές τεχνικές οι οποίες παίζουν ένα πολύ σημαντικό ρόλο στην πρόβλεψη της εμφάνισης των κρίσεων και βοηθούν τον ιατρό στη διάγνωση της νόσου [72].

Η εξαγωγή και ταξινόμηση των χαρακτηριστικών είναι οι δύο βασικές διαδικασίες για ένα αυτοματοποιημένο σύστημα ανίχνευσης κρίσεων. Για να ανακαλύψουμε μια βέλτιστη μέθοδο εξαγωγής χαρακτηριστικών, πολλές μέθοδοι έχουν προταθεί, καθεμία από τις οποίες ανήκει στο πεδίο του χρόνου, στο πεδίο της συχνότητας, στο πεδίο χρόνου-συχνότητας, στα πλαίσια μη γραμμικής ανάλυσης, ή σε συνδυασμό αυτών [73]. Η ανάλυση χρόνου-συχνότητας χαρακτηρίζεται από την ικανότητα να αντιπροσωπεύει τις στιγμιαίες διακυμάνσεις ενός σήματος στο πεδίο του χρόνου και στο πεδίο συχνοτήτων, ταυτόχρονα. Ο μετασχηματισμός Fourier βραχέος χρόνου (STFT) [74] και ο μετασχηματισμός κυματιδίου (WT) [75-77] είναι οι πιο συχνά χρησιμοποιούμενες μέθοδοι λόγω της ικανότητάς τους να παρέχουν

μετρήσιμα χαρακτηριστικά χρόνου-συχνότητας των σημάτων HEG. Ωστόσο, το σταθερό χρονικό παράθυρο του STFT οδηγεί σε αδυναμία της μεταβλητής συγκέντρωσης χρόνου-συχνότητας. Παρόλο που ο WT ξεπερνά αυτό το μειονέκτημα, είναι ένα μέτρο αναπαράστασης που βασίζεται στο πρότυπο (μητρικό wavelet) και γι' αυτό, το ασαφές επίπεδο αποσύνθεσης είναι η κύρια δυσκολία στη χρήση του WT. Σε αντίθεση με τον STFT και τον WT, παρ' όλα αυτά, η Εμπειρική Μέθοδος Αποσύνθεσης (Empirical Mode Decomposition - EMD), ένας εξαρτώμενος από τα δεδομένα αλγόριθμος ανάλυσης χρόνου-συχνότητας, είναι σε θέση να αποσυνθέσει αναδρομικά ένα τυχαίο σήμα σε μια σειρά από δευτερεύοντα στοιχεία, τα οποία ονομάζονται συναρτήσεις εγγενούς λειτουργίας (Intrinsic Mode Functions - IMFs) [78,79]. Η EMD έχει εφαρμοστεί ευρέως σε πολλούς τομείς, ιδίως για τη μη γραμμική και μη στάσιμη ανάλυση σημάτων, όπως των HEG [80-82]. Πιο πρόσφατα, είχε προταθεί μια νέα τροποποιημένη EMD μέθοδος που ονομάζεται Μεταβλητή Μέθοδος Αποσύνθεσης (Variational Mode Decomposition -VMD) [83]. Ως προσαρμοστική τεχνολογία αποσύνθεσης, η VMD έχει το πλεονέκτημα να αποσυνθέτει ένα σήμα πολλών συνιστωσών σε έναν αριθμό ζωνο-περιορισμένων συναρτήσεων εγγενούς λειτουργίας (BLIMFs) μη-αναδρομικά και συγχρονισμένα. Σε σύγκριση με τους προκατόχους του, τα κύρια πλεονεκτήματα του VMD είναι ότι διαθέτει μια πιο πειστική μαθηματική θεωρία και αυστηρή διαδικασία παραγοντοποίησης, και έχει την ικανότητα να διαχωρίζει δύο αρμονικά σήματα παρόμοιας συχνότητας [83].

Όταν οι προαναφερθείσες μεθοδολογίες αποσύνθεσης χρόνου-συχνότητας εφαρμόζονται στο αρχικό σήμα HEG, το σήμα αποσυντίθεται σε έναν πεπερασμένο αριθμό υπο-συνιστωσών σύμφωνα με ειδικές αρχές και κανόνες. Μετά από αυτό, εξετάζονται πολλές παράμετροι και υπολογίζονται ως χαρακτηριστικά των υπο-συνιστωσών, για παράδειγμα ο μέσος όρος, η ασυμμετρία, η μέγιστη τιμή, η κατά προσέγγιση εντροπία, η ασαφής εντροπία κλπ. [73]. Το μοντέλο αυτό-παλινδρόμησης (AR) είναι ένα μοντέλο (μόνο) πόλων και έχει αποδειχθεί ότι είναι ένα παραγωγικό πλαίσιο χαρακτηρισμού για την εκτέλεση της αυτοματοποιημένης ανίχνευσης κρίσεων [22], πρόβλεψης [23] και τεχνικών διασύνδεσης εγκεφάλου-υπολογιστή [24]. Αν και έχει αναφερθεί ότι η AR είναι μια προτιμητέα μέθοδος φασματικής αναπαράστασης σε σύγκριση με τον κλασσικό γρήγορο μετασχηματισμό Fourier (FFT) και το περιόδωγραμμα (periodogram) [22], οι χρήστες τείνουν να προσδιορίζουν εμπειρικά την τάξη AR σε πρακτικές εφαρμογές. Σε μια προσπάθεια να διαπιστωθεί η βέλτιστη τάξη του μοντέλου AR, οι ερευνητές έχουν προτείνει διαδοχικά πολλά κριτήρια. Μεταξύ αυτών των κριτηρίων, τα κριτήρια: σφάλμα τελικής πρόβλεψης (FPE), κριτήριο πληροφοριών Akaike (AIC), κριτήριο πληροφοριών Bayesian (BIC) και κριτήριο της αυτοπαλινδρομικής μεταφοράς (CAT), είναι αυτά που χρησιμοποιούνται πιο συχνά. Με δεδομένο αυτό, υιοθετήθηκε το μοντέλο AR για την εξαγωγή των συντελεστών AR των αποσυντιθέμενων BLIMFs και τα τέσσερα κριτήρια διερευνήθηκαν, αντίστοιχα.

Στην τρέχουσα μελέτη, γίνεται προσπάθεια για την επαλήθευση της σκοπιμότητας του συστήματος ανίχνευσης κρίσεων που βασίζεται στη μέθοδο VMD. Συγκεκριμένα, μια εξαγωγή τετραγωνικών χαρακτηριστικών βασισμένη στο μοντέλο AR σχεδιάστηκε για να εξάγει χαρακτηριστικά από τη λογαριθμική κλίμακα των BLIMFs. Συγκεκριμένα, η VMD εφαρμόστηκε αρχικά για να αποσυνθέσει το ακατέργαστο τμήμα HEG σε μια σειρά BLIMFs. Στη συνέχεια εφαρμόστηκε η λογαριθμική συνάρτηση σε όλες τις BLIMFs. Έπειτα, διερευνήθηκαν χωριστά τα προαναφερθέντα τέσσερα κριτήρια, δηλαδή τα FPE, AIC, BIC και CAT, για να εκτιμηθεί η βέλτιστη τάξη AR και μετά ακολούθησε ο υπολογισμός των συντελεστών

του βέλτιστου μοντέλου AR για τη λογαριθμική κλίμακα των BLIMFs. Για να διασφαλιστεί η συνοχή της διαστασιμότητας κάθε εγγραφής ΗΕΓ, στο τελευταίο βήμα της εξαγωγής χαρακτηριστικών, οκτώ στατιστικές παράμετροι των συντελεστών AR εξήχθησαν και συγχωνεύθηκαν μαζί ως διανύσματα χαρακτηριστικών της ακολουθίας ΗΕΓ. Τέλος, τα υβριδικά διανύσματα χαρακτηριστικών τροφοδοτήθηκαν σε ένα τυχαίο δάσος και τα αποτελέσματα ταξινόμησης αξιολογήθηκαν και συγκρίθηκαν με την διακύμανση των δέντρων αποφάσεων.

Η βάση δεδομένων ΗΕΓ αποκτήθηκε από το Κέντρο Επιληψίας του Πανεπιστημιακού Νοσοκομείου της Βόννης, Freiburg, στη Γερμανία [100]. Η βάση δεδομένων αποτελείται από πέντε υποσύνολα ΗΕΓ σημάτων τα οποία παρουσιάζονται ως ομάδες A-E (Z, O, N, P και S). Κάθε ομάδα περιέχει 100 εγγραφές ΗΕΓ μονού καναλιού, ενώ το κάθε τμήμα ΗΕΓ έχει διάρκεια 23.6 sec και συλλαμβάνεται από το διεθνές σύστημα τοποθέτησης ηλεκτροδίου 10-20. Οι ομάδες A και B έχουν καταγραφεί εξωκρανιακά, ενώ οι ομάδες C-E έχουν καταγραφεί ενδοκρανιακά. Όλα τα τμήματα ΗΕΓ επιλέχθηκαν και αποκόπηκαν από συνεχείς καταγραφές ΗΕΓ πολλαπλών καναλιών, μετά την οπτική επιθεώρηση για ευρήματα. Οι ομάδες A και B ελήφθησαν από πέντε υγιείς εθελοντές με τα μάτια ανοιχτά και κλειστά, αντίστοιχα. Οι υπόλοιπες ομάδες, δηλαδή οι C-E μετρήθηκαν όλες από πέντε ασθενείς. Συγκεκριμένα, οι ομάδες C και D συλλέχθηκαν από την επιληπτογενή ζώνη (D) και από το σχηματισμό ιππόκαμπου του αντίθετου ημισφαιρίου του εγκεφάλου (C) σε χρονικά διαστήματα κατά τα οποία οι ασθενείς δεν βρίσκονταν σε κρίση. Η ομάδα E περιέχει μόνο επιληπτική δραστηριότητα, που επιλέχθηκε από όλες τις θέσεις καταγραφής που παρουσιάζουν κρίση. Η συχνότητα δειγματοληψίας είναι 173.61 Hz. Σε αυτήν την εργασία, οι ομάδες A και B συνδυάζονται μαζί για να αποτελέσουν την φυσιολογική τάξη του ΗΕΓ, ομοίως, η τάξη του ΗΕΓ για ασθενείς στο χρονικό διάστημα μεταξύ δύο κρίσεων αποτελείται από τις ομάδες C και D, ενώ η ομάδα E σχηματίζει την τάξη των ασθενών κατά τη διάρκεια επιληπτικής κρίσης. Ο απώτερος στόχος της μελέτης αυτής είναι να ταξινομήσει αυτά τα τρία είδη ΗΕΓ με ακρίβεια.

Variational Mode Decomposition

Η Empirical Mode Decomposition (EMD) είναι ένας εξαρτώμενος από τα δεδομένα αλγόριθμος εμπειρικής αποσύνθεσης, για τον οποίο τα δεδομένα IMFs προσφέρουν έναν πιο ολοκληρωμένο χαρακτηρισμό απ' ό,τι οι αρχικές χρονοσειρές [78]. Σύμφωνα με το κριτήριο του EMD, ένα σήμα $x(t)$ αποσυντίθεται σε ένα άθροισμα IMFs εφαρμόζοντας τον αλγόριθμο EMD και το οποίο μπορεί να παρασταθεί ως εξής [79]:

$$x(t) = \sum_{m=1}^M c_m(t) + r(t), \quad m = 1, 2, \dots, M, \quad ,$$

όπου το M είναι ο αριθμός των IMFs, $c_m(t)$ και $r(t)$ είναι η m -οστή IMF και το υπόλειμμα αποσύνθεσης (decomposition residue), αντίστοιχα.

Σαν μια επεκταμένη έκδοση του EMD, ο Dragomiretskiy et al. [83] πρότεινε την VMD για το σκοπό της αποσύνθεσης ενός σήματος εισόδου πραγματικών τιμών σε ένα διακριτό αριθμό δευτερευόντων στοιχείων u_k που έχουν συγκεκριμένες ιδιότητες αραιότητας (sparsity properties), ενώ αναπαράγουν την είσοδο. Κάθε τέτοιο υπο-

σήμα, είναι μια BLIMF και είναι συμπαγές γύρω από ένα κέντρο παλμών ω_k , και το εύρος ζώνης του BLIMF εκτιμάται χρησιμοποιώντας την H^1 Gaussian ομαλότητα (smoothness) του μετατοπισμένου σήματος. Η VMD είναι ισοδύναμη με ένα περιορισμένο πρόβλημα μεταβολών [83]:

$$\min\left\{\sum_{k=1}^K \left\| \partial_t \left[\delta(t) + \frac{j}{\pi t} * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\}$$

$$\text{s. t. } \sum_{k=1}^K u_k = f,$$

όπου K είναι ο αναμενόμενος αριθμός BLIMFs, και u_k και ω_k είναι οι συμβολισμοί των BLIMFs και των κεντρικών συχνοτήτων τους, αντίστοιχα.

Για την επίλυση αυτού του περιορισμού ανασυγκρότησης, εισάγεται ο επαυξημένος Lagrangian L , ως εξής [83]:

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \left\| \partial_t \left[\delta(t) + \frac{j}{\pi t} * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \|f(t) - \sum_k u_k(t)\|_2^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle.$$

Εδώ, το $K = 15$ βρέθηκε εμπειρικά να είναι ευκολότερα διακριτό και έτσι, ο αριθμός των BLIMFs στην παρούσα μελέτη ορίστηκε σε 15. Για περισσότερες λεπτομέρειες και μια συγκεκριμένη παραγωγική διαδικασία του αλγορίθμου VMD, οι αναγνώστες πρέπει να ανατρέξουν στην βιβλιογραφία [83]. Με την εκτέλεση του VMD, το πρωτογενές σήμα ΗΕΓ χωρίζεται σε 15 BLIMFs. Για κάθε BLIMF, το πλάτος του κυμαίνεται βίαια. Για να μειωθούν οι συνέπειες της μεταβλητότητας, όλες οι BLIMFs υποβλήθηκαν σε λογαρίθμηση με βάση α και έτσι δημιουργήθηκαν οι νέες BLIMFs (nBLIMFs). Η λογαριθμική λειτουργία εκφράζεται ως εξής:

$$nBLIMF = \text{sgn}(BLIMF) \cdot \log_{\alpha}(1 + |BLIMF|)$$

Εξαγωγή τετραγωνικών χαρακτηριστικών βασισμένη στο AR μοντέλο

Σύμφωνα με την διαφορά σε μηχανισμούς, οι μέθοδοι εκτίμησης των AR παραμέτρων μπορούν να χωριστούν σε δύο κατηγορίες: (1) τη μεγιστοποίηση της συνάρτησης πιθανοφάνειας και (2) την ελαχιστοποίηση της ισχύος του σφάλματος πρόβλεψης [101]. Συγκεκριμένα, η εκτίμηση μέγιστης πιθανοφάνειας (MLE) ανήκει στην πρώτη κατηγορία, και η δεύτερη κατηγορία αποτελείται από τους αλγόριθμους Yule-Walker, συνδιακύμανσης, τροποποιημένης συνδιακύμανσης, ελαχίστων τετραγώνων και Burg [101]. Σε αυτό το έργο, ο αλγόριθμος του Burg [102] χρησιμοποιήθηκε για τον υπολογισμό των AR παραμέτρων.

Αν για μία διακριτή σειρά δεδομένων $x(n)$, N σημείων δειγματοληψίας, υποθέσουμε ότι m είναι η τάξη του μοντέλου αυτοπαλινδρόμησης (AR), το εμπρόσθιο σφάλμα πρόγνωσης (forward prediction error) μπορεί να εκφραστεί ως εξής:

$$e_m^{\hat{f}}(n) = x(n) + \sum_{i=1}^m a_{m,i} x(\hat{n} - i), n = m + 1, \dots, N$$

Ομοίως, το οπίσθιο σφάλμα πρόβλεψης δίνεται από την:

$$e_m^{\hat{b}}(n) = x(n - m) + \sum_{i=1}^m a_{m,i}^* x(\hat{n} - m + i), n = m + 1, \dots, N$$

Η αρχική συνθήκη των δύο αυτών σφαλμάτων πρόβλεψης ορίζεται ως εξής:

$$e_0^{\hat{f}}(n) = e_0^{\hat{b}}(n) = x(n)$$

Ορίζουμε τον συντελεστή ανάκλασης ως εξής:

$$\hat{k}_m = \frac{-2 \sum_{n=m+1}^N e_{m-1}^{\hat{f}}(n) e_{m-1}^{\hat{b}}(n)}{\sum_{n=m+1}^N [|e_{m-1}^{\hat{f}}(n)|^2 + |e_{m-1}^{\hat{b}}(n-1)|^2]}$$

και οι συντελεστές AR $\hat{a}_{m,i}$, συνοψίζονται στην επόμενη αναδρομική εξίσωση:

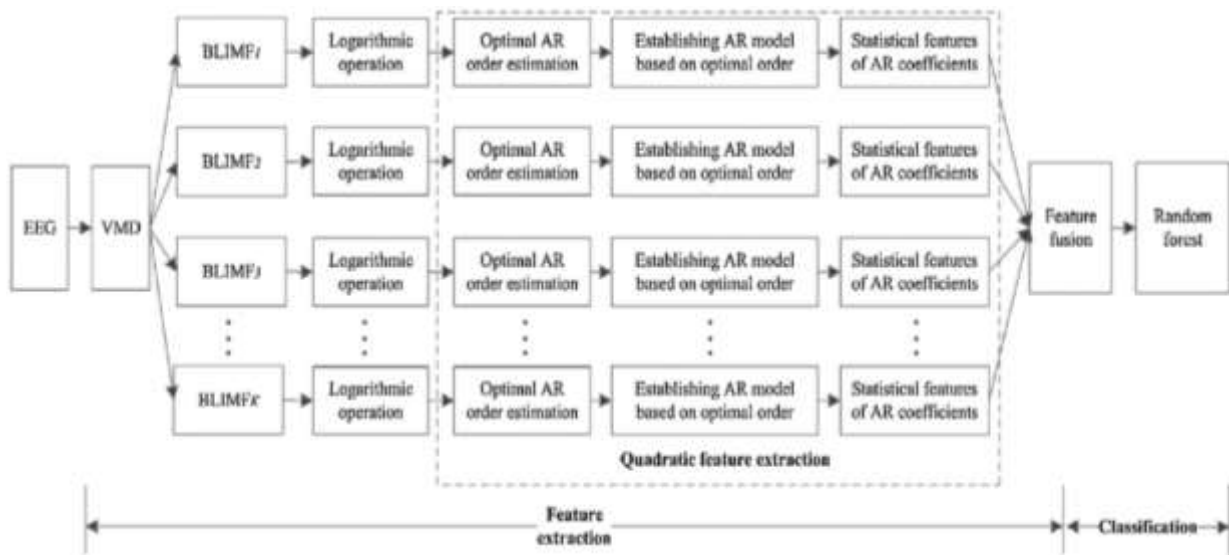
$$\hat{a}_{m,i} = \begin{cases} \hat{a}_{m-1,i} + \hat{k}_m \hat{a}_{m-1,m-i}^* & i = 1, 2, \dots, m-1 \\ \hat{k}_m & i = m \end{cases}$$

Για να υπολογιστεί η βέλτιστη τάξη του AR μοντέλου, τέσσερα κριτήρια, δηλαδή τα FPE, AIC, BIC και CAT εξετάστηκαν αντιστοίχως στη μελέτη μας. Αυτά τα κριτήρια ορίζονται ως [25]:

$$\begin{cases} FPE(m) = \frac{N+m+1}{N-m+1} \cdot \sigma_m^2 \\ AIC(m) = N \cdot \ln(\sigma_m^2) + 2m \\ BIC(m) = N \cdot \ln(\sigma_m^2) + m \cdot \ln(N) \\ CAT(m) = \frac{1}{N} \cdot \sum_{j=1}^m \frac{1}{\hat{\sigma}_j^2} - \frac{1}{\hat{\sigma}_m^2}, \hat{\sigma}_j^2 = \frac{N}{N-j} \cdot \sigma_j^2 \end{cases}$$

όπου το σ_j^2 συμβολίζει την εκτιμώμενη διακύμανση του σφάλματος πρόβλεψης χρησιμοποιώντας αλγόριθμο AR τάξης j .

Με την ελαχιστοποίηση των κριτηρίων αυτών, παίρνουμε αντίστοιχα τα βέλτιστα μοντέλα. Ωστόσο, θα πρέπει να τονιστεί ότι, αν και η βέλτιστη τάξη του μοντέλου AR μπορεί να εκτιμηθεί από τα κριτήρια που αναφέρονται παραπάνω και τα αντίστοιχα -υψηλής απόδοσης- μοντέλα τους είναι σε θέση να ταιριάζουν με την τάση διακύμανσης της ακολουθίας όσο το δυνατόν ακριβέστερα, η διαστασιμότητα των AR συντελεστών του κάθε δεδομένου είναι διαφορετική από τις άλλες. Κάτω από αυτές τις συνθήκες, είναι πολύ δύσκολο να ταξινομήσουμε τις διάφορες τάξεις σημάτων ΗΕΓ χρησιμοποιώντας τους συντελεστές AR, οι διαστασιμότητες των οποίων είναι ασυνεπείς. Με δεδομένο αυτό, μια δευτερεύουσα διαδικασία εξαγωγής χαρακτηριστικών, τίθεται ακολούθως σε ισχύ και οκτώ στατιστικά χαρακτηριστικά: η ενέργεια, το μήκος, η μέγιστη, η ελάχιστη και η μέση τιμή, η διακύμανση, η ασυμμετρία και η κύρτωση των συντελεστών του καλύτερου μοντέλου AR υπολογίστηκαν. Με την ευκαιρία αυτή, τα διαφορετικά μήκη των συντελεστών AR μετασχηματίστηκαν στην ίδια διάσταση και κατόπιν εκτελέστηκε η διαδικασία ταξινόμησης (Σχήμα 3.6).



Σχήμα 3.6: Βασικό διάγραμμα της τεχνικής ανίχνευσης κρίσεων που παρουσιάζεται [68].

3.3.1.4 Εξαγωγή χαρακτηριστικών με χρήση φασματικών μεθόδων (τράπεζα φίλτρων, μέθοδος Welch και STFT)

Τα συστήματα διεπαφής εγκεφάλου-υπολογιστή (BCI) που βασίζονται στην ηλεκτροεγκεφαλογραφία χρησιμοποιούνται όλο και περισσότερο για διαφορετικούς σκοπούς, δημιουργώντας εφαρμογές από ψυχαγωγία έως αποκατάσταση σε ένα μη επεμβατικό πλαίσιο. Σε αυτή τη μελέτη, πραγματοποιείται μια συγκριτική ανάλυση των διαφορετικών τεχνικών επεξεργασίας σήματος για κάθε στάδιο του συστήματος BCI σχετικά με τα οπτικά προκλητά δυναμικά σταθερής κατάστασης (SSVEP), στα οποία περιλαμβάνονται: (1) η εξαγωγή χαρακτηριστικών που εκτελείται με διαφορετικές φασματικές μεθόδους (τράπεζα φίλτρων, μέθοδος Welch και μετασχηματισμός Fourier βραχέως χρόνου (STFT)). (2) η επιλογή χαρακτηριστικών μέσω ενός στοιχειώδους *wrapper*, ενός φίλτρου που χρησιμοποιεί τη μέθοδο *Pearson*, ενός μέτρου ομάδας (cluster measure) με βάση τον δείκτη *Davies-Bouldin* και ενός σεναρίου χωρίς στρατηγική επιλογής. (3) τα συστήματα ταξινόμησης που χρησιμοποιούν γραμμική διακριτή ανάλυση (LDA), μηχανές διανυσμάτων υποστήριξης (SVM) και μηχανές ακραίας μάθησης (ELM).

Μια διεπαφή εγκεφάλου-υπολογιστή (BCI) είναι μια συσκευή που στοχεύει στην αντιστοίχιση των σημάτων του εγκεφάλου σε εντολές για εξωτερικές συσκευές, καθορίζοντας ένα εναλλακτικό κανάλι επικοινωνίας για χρήστες σε διαφορετικά πρακτικά πλαίσια, το οποίο μπορεί να περιλαμβάνει εφαρμογές από παιχνίδια στον υπολογιστή έως και βοηθητικές τεχνολογίες [105, 106].

Τα BCI, γενικά, κάνουν χρήση της ηλεκτροεγκεφαλογραφίας (HEG) [107], ως συνέπεια παραγόντων όπως η φορητότητα, η μη επεμβατικότητα και το κόστος. Τα σήματα HEG αποκτώνται με τη βοήθεια ενός καλύμματος ηλεκτροδίου τοποθετημένου στο κρανίο του χρήστη, το οποίο συνδέεται με μονάδες προεπεξεργασίας και δειγματοληψίας. Ο σχεδιασμός ενός BCI καθορίζεται από το επιλεγμένο κάθε φορά παράδειγμα, με τις κύριες τάσεις του πεδίου [108] να είναι οι νοερή κινητική απεικόνιση (motor imagery), το P300 και τα οπτικά προκλητά δυναμικά σταθερής κατάστασης (SSVEP). Οι δύο τελευταίες είναι προσεγγίσεις που βασίζονται σε βιοματικά δυναμικά (ERP). Το πρότυπο SSVEP, το αντικείμενο αυτής της μελέτης, βασίζεται στην ανάλυση ταλαντευόμενων μοτίβων ηλεκτροεγκεφαλογραφήματος που παράγονται στον φλοιό, σε απόκριση ορισμένων οπτικών ερεθισμάτων. Ειδικότερα, όταν ένα άτομο διεγείρεται οπτικά από ένα πρότυπο που αναβοσβήνει επανειλημμένα μέσα σε ένα ορισμένο εύρος συχνοτήτων, μπορεί να ανιχνευθεί συγχρονισμένο SSVEP στην ηλεκτρική δραστηριότητα του εγκεφάλου του. Ως εκ τούτου, εάν χρησιμοποιούνται πηγές φωτός με διαφορετικές συχνότητες τρεμοπαίγματος για την κατασκευή διεπαφής εντολών, είναι δυνατό να προσδιοριστεί σε ποιο φως το υποκείμενο εστίασε την προσοχή του σε μια δεδομένη χρονική περίοδο, με κατάλληλη επεξεργασία και ταξινόμηση του σήματος HEG.

Σε αυτή τη μελέτη, θα εκτελέσουμε μια συγκριτική ανάλυση μεθόδων για την εξαγωγή χαρακτηριστικών, την επιλογή χαρακτηριστικών και την ταξινόμηση σε SSVEP BCIs. Τρεις προσεγγίσεις εξαγωγής χαρακτηριστικών – η φασματική εκτίμηση χρησιμοποιώντας μια τράπεζα ζωνοπερατών φίλτρων, η μέθοδος του Welch και το μέτρο του μετασχηματισμού Fourier βραχέως χρόνου (STFT) που υπολογίζεται στις προκληθείσες συχνότητες, τρεις μέθοδοι επιλογής χαρακτηριστικών και τρεις ταξινομητές – ένας γραμμικός ταξινομητής, μια μηχανή ακραίας μάθησης (ELM) [109] και μια μηχανή διανυσμάτων υποστήριξης (SVM) [110] – θα ληφθούν υπόψη. Επιπλέον, οι επιδόσεις κάθε δομής θα αναλυθούν με τρεις προσεγγίσεις επιλογής χαρακτηριστικών: ένα *incremental wrapper* [111], ένα φίλτρο

που χρησιμοποιεί τη μέθοδο Pearson [112] και μια στρατηγική βασισμένη στον δείκτη Davies-Bouldin [113], καθώς επίσης και μια περίπτωση χωρίς επιλογή χαρακτηριστικών. Αυτό το ρεπερτόριο 36 σεναρίων που εφαρμόζονται στην ίδια βάση δεδομένων, ορίζει ενδιαφέροντα συγκριτικά στοιχεία: (1) δεδομένου ότι τα SSVEP δημιουργούν μια σαφώς καθορισμένη φασματική απάντηση, αυτή η μελέτη είναι σχετική ως ανάλυση της απόδοσης διακεκριμένων διαφορετικών μεθόδων εξαγωγής χαρακτηριστικών στο πεδίο της συχνότητας. (2) Διερευνάται η ευρωστία μη γραμμικών δομών, όπως η ELM και η SVM, όσον αφορά το χειρισμό της απαιτούμενης εργασίας ταξινόμησης των SSVEP. (3) Η διαδικασία της επιλογής καναλιών αναλύεται υιοθετώντας τρεις στρατηγικές με ξεχωριστά εννοιολογικά θεμέλια. (4) Γίνονται στατιστικές εκτιμήσεις σχετικά με την καλύτερη διαμόρφωση των ηλεκτροδίων σύμφωνα με διάφορες μεθόδους επιλογής χαρακτηριστικών.

Θεμελιώδη στοιχεία των οπτικών προκλητών δυναμικών σταθερής κατάστασης

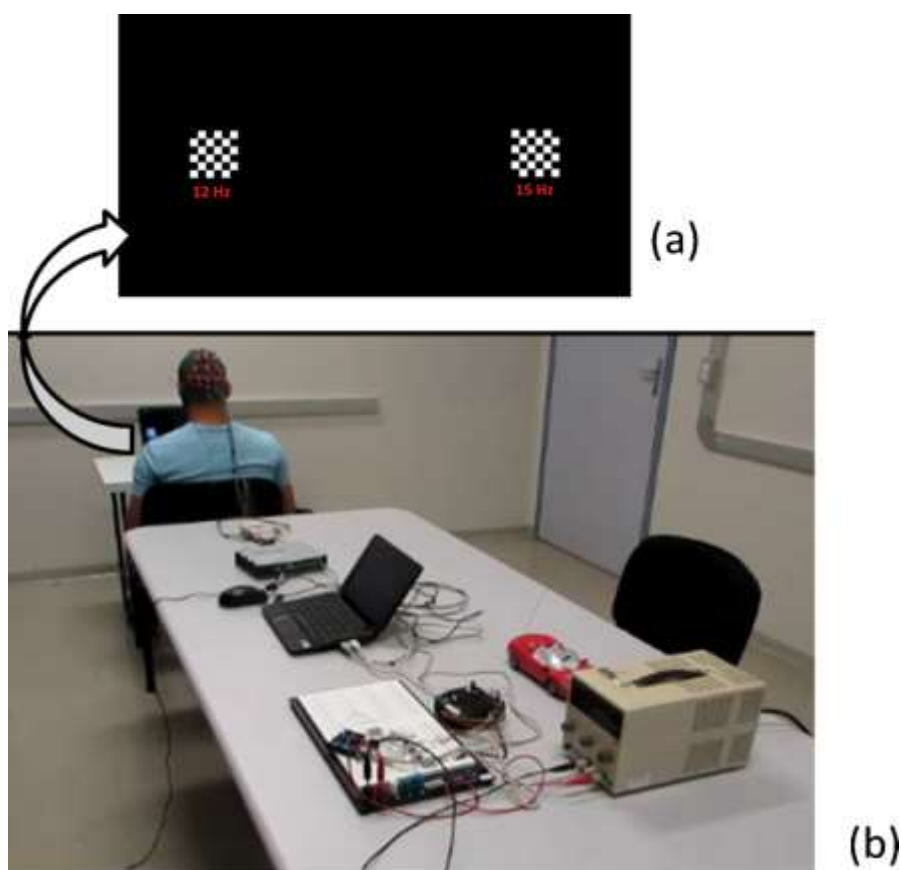
Η νευροφυσιολογία του ανθρώπινου οπτικού συστήματος αναφέρει ότι η νευρωνική δραστηριότητα των κυττάρων του οπτικού φλοιού μεταβάλλεται με την οπτική διέγερση και είναι δυνατόν να αναγνωριστούν αλλαγές της απόκρισης του εγκεφάλου που σχετίζονται με τις ιδιότητες του οπτικού ερεθίσματος, όπως η φωτεινότητα, η αντίθεση και η συχνότητα (μεταξύ 1 Hz και 100 Hz [114]). Οι νευρώνες στον οπτικό φλοιό συγχρονίζουν την πυροδότησή τους με τη συχνότητα στην οποία αναβοσβήνουν τα οπτικά ερεθίσματα. Τα οπτικά προκλητά δυναμικά σταθερής κατάστασης εμφανίζονται όταν παρουσιάζονται επανειλημμένα οπτικά ερεθίσματα, δημιουργώντας σχεδόν ημιτονοειδείς ταλαντώσεις [115,116]. Η απόκριση του ΗΕΓ παρουσιάζει αύξηση της ενέργειας στην ίδια συχνότητα στην οποία αναβοσβήνει το ερέθισμα [117]. Η ισχυρότερη απόκριση λαμβάνει χώρα στον πρωτοταγή οπτικό φλοιό, αν και άλλες περιοχές του εγκεφάλου ενεργοποιούνται σε διαφορετικούς βαθμούς. Τα SSVEP μπορούν να ανιχνευθούν σε στενές ζώνες συχνοτήτων (π.χ. 0,1 Hz) γύρω από τη συχνότητα της οπτικής διέγερσης μέσω μεθόδων επεξεργασίας σήματος που εκμεταλλεύονται συγκεκριμένα χαρακτηριστικά του σήματος, όπως το χρονισμό και το ρυθμό.

Τα συστήματα SSVEP BCI χρησιμοποιούν οπτικά ερεθίσματα ως τρόπο για να προκαλέσουν ένα συγκεκριμένο ηλεκτρικό μοτίβο στον οπτικό φλοιό. Σε αντίθεση με τα ανεξάρτητα BCI συστήματα, όπου η εφαρμογή βασίζεται σε εκούσιο έλεγχο της νευρικής δραστηριότητας του υποκειμένου [118, 119], η λειτουργία των συστημάτων SSVEP εξαρτάται από την ικανότητα του υποκειμένου να συγκεντρωθεί και να ακολουθήσει τα οπτικά ερεθίσματα σύμφωνα με μια προβλεπόμενη πράξη.


Πειραματική εγκατάσταση

Η διεπαφή διέγερσης (βλέπε Εικόνα 3.10) αποτελείται από δύο τετράγωνα σκακιέρες με πλευρές 3,8 cm, που εμφανίζονται στο δεξί και στο αριστερό κέντρο μιας μαύρης οθόνης και αναβοσβήνουν στα 12 και 15 Hz, αντίστοιχα. Για την παρακολούθηση χρησιμοποιήθηκε ένα μόνιτορ 14 ιντσών με ρυθμό ανανέωσης 60 Hz. Το υποκείμενο εστίασε στο βλέμμα του για 12 δευτερόλεπτα σε κάθε ερέθισμα, επαναλαμβάνοντας αυτή τη διαδικασία οκτώ φορές με διαστήματα ανάπαυσης. Τα δεδομένα ΗΕΓ συλλέχθηκαν από επτά υγιείς εθελοντές, με μέση ηλικία τα $26,3 \pm 3,3$ έτη. Το πρωτόκολλο απόκτησης εγκρίθηκε από την επιτροπή δεοντολογίας του Πανεπιστημίου Campinas (αριθ. 791/2010). Η βάση δεδομένων αποτελείται από 1344

δεδομένα ΗΕΓ που καταγράφηκαν με ρυθμό δειγματοληψίας 256 Hz, χρησιμοποιώντας μία g[®].SAHARAsys κάσκα ξηρού ηλεκτροδίου με 16 κανάλια και ένα g[®].USBamp ενισχυτή βιοσήματος [120] και καταχωρήθηκε στο MATLAB[®] 2012b, χρησιμοποιώντας μια διεπαφή προγραμματισμού εφαρμογών (Application Programming Interface-API) που παρέχεται από τον προαναφερθέντα κατασκευαστή συσκευών. Οι λήψεις πραγματοποιήθηκαν μόνο μετά από την ακόλουθη διαδικασία σχετικά με τη συσκευή ΗΕΓ: βαθμονόμηση της σύνθετης αντίστασης του καναλιού, επαλήθευση της βαθμονόμησης της σύνθετης αντίστασης του ηλεκτροδίου (μεταξύ 0.5 και 5.0 kΩ), σύνδεση των υποδοχών των καναλιών γείωσης και αναφοράς, αντίστοιχα, προς την κοινή γείωση και την αναφορά και σταθεροποίηση του σήματος. Η γείωση και η αναφορά τοποθετούνται στις μαστοειδείς αποφύσεις. Η Εικόνα 3.11 δείχνει τη διάταξη των ηλεκτροδίων στα O1, O2, Oz, POz, Pz, PO4, PO3, PO8, PO7, P2, P1, Cz, C1, C2, CPz, FCz, σύμφωνα με το διεθνές σύστημα 10-20 [121].



Εικόνα 3.10: Πειραματική ρύθμιση. (a) Οθόνη με σκακιέρες που χρησιμοποιούνται για να παράγουν οπτικά ερεθίσματα σε συχνότητα 12 και 15 Hz. (b) Διαμόρφωση του εξοπλισμού και του περιβάλλοντος συλλογής δεδομένων [104].



Εικόνα 3.11: Εναπόθεση των ηλεκτροδίων στο κρανίο για την απόκτηση του ηλεκτροεγκεφαλογραφήματος [104].

Προεπεξεργασία

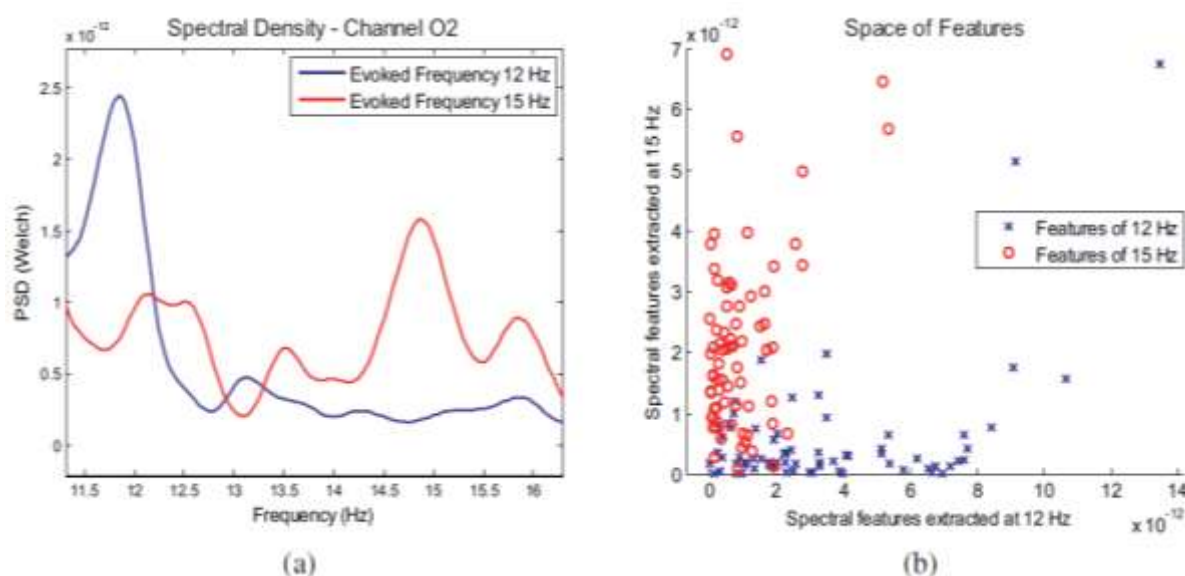
Διάφορες παρεμβολές προστίθενται στο σήμα ΗΕΓ κατά τη διάρκεια της εγγραφής. Αυτά τα ευρήματα διακινδυνεύουν την ποιότητα του λαμβανόμενου σήματος, επηρεάζοντας την απόδοση του ΒCI. Οι κύριες πηγές θορύβου είναι: ο εξοπλισμός ΗΕΓ και οι συνδέσεις του με το τριχωτό της κεφαλής, η ηλεκτρική πηγή (60 Hz) και η φυσιολογική ηλεκτρική δραστηριότητα του ατόμου όπως η καρδιά, το άνοιγμα και το κλείσιμο των ματιών, η κίνηση των ματιών και οι μύες γενικά. Η αναγνώριση και η εξάλειψη του θορύβου σε σήματα ΗΕΓ είναι πολύπλοκο έργο, αλλά απαραίτητο για την ανάπτυξη πρακτικών συστημάτων.

Σε αυτή τη μελέτη, το σήμα ΗΕΓ φιλτράρεται μέσω ενός αναλογικού ζωνοπερατού φίλτρου Butterworth (5-60 Hz) και ενός φίλτρου απόρριψης ζώνης (notch) (58-62 Hz) προκειμένου να απομακρυνθεί η ομαλή μετατόπιση (smooth displacement) και ο ηλεκτρομαγνητικός θόρυβος. Στη συνέχεια, για να απομακρυνθεί ο υπόλοιπος θόρυβος που υπάρχει στη ζώνη συχνοτήτων, όπως τα μάτια που ανοιγοκλείνουν και οι κινήσεις του λαιμού, τα δεδομένα υποβάλλονται σε χωρικό φιλτράρισμα χρησιμοποιώντας τη μέθοδο Κοινής Μέσης Αναφοράς (Common Average Reference-CAR) [122]. Παρόλο που οι πηγές θορύβου είναι πολύπλοκες και ποικίλλουν μεταξύ των υποκειμένων, το χρονικό και χωρικό φιλτράρισμα έχει αποδειχθεί ότι είναι βολικό για τη μεγιστοποίηση του λόγου του σήματος προς το θόρυβο και για τη βελτίωση της ακρίβειας του συστήματος SSVEP BCI [123, 124].

Προσεγγίσεις για την εξαγωγή χαρακτηριστικών

Τα χαρακτηριστικά είναι, με απλά λόγια, στοιχεία μιας συμπαγούς και αποτελεσματικής απεικόνισης δεδομένων [125]. Στο πλαίσιο ενός συστήματος BCI, είναι σημαντικό τα χαρακτηριστικά που εξάγονται από τα εγκεφαλικά σήματα να διευκολύνουν το έργο της διάκρισης που εκτελείται στο στάδιο της ταξινόμησης. Όπως αναλύθηκε πιο πάνω, το μοντέλο SSVEP βασίζεται στην ανίχνευση ταλαντευόμενων μοτίβων μέσα στα κύματα ΗΕΓ, επομένως η χρήση των φασματικών χαρακτηριστικών είναι μια φυσική επιλογή [126]. Η Εικόνα 3.12 δείχνει τα φασματικά χαρακτηριστικά των αποκρίσεων SSVEP που παρατηρούνται στο κανάλι O2 για τις προκληθείσες συχνότητες 12 και 15 Hz. Είναι αξιοσημείωτο ότι το φασματικό περιεχόμενο συγκεντρώνεται γύρω από τις προκληθείσες συχνότητες.

Στην πραγματικότητα, η τυποποιημένη τεχνική για την αναγνώριση της απόκρισης SSVEP που σχετίζεται με ένα σήμα ΗΕΓ είναι να αναλύσει το σήμα στο πεδίο των συχνοτήτων, υπολογίζοντας τη φασματική πυκνότητα ισχύος σε όλες τις πιθανώς προκληθείσες ζώνες συχνοτήτων. Καθώς η κάθε μία από αυτές τις ζώνες αντιστοιχεί στην άμεση γειτνίαση με έναν από τους ρυθμούς αναβοσβήσματος διεπαφής, είναι δυνατόν να προσδιοριστεί η επιθυμητή εντολή BCI. Σε αυτή τη μελέτη, το φασματικό περιεχόμενο εκτιμήθηκε χρησιμοποιώντας τρεις προσεγγίσεις: μια τράπεζα φίλτρων, το μετασχηματισμό Fourier βραχέως χρόνου και τη μέθοδο Welch.




Εικόνα 3.12: Εξαγωγή χαρακτηριστικών απόκρισης SSVEP στα 12 και 15 Hz, (a) φασματική πυκνότητα ισχύος, (b) χώρος φασματικών χαρακτηριστικών λαμβάνοντας υπόψη μόνο ένα ινιακό κανάλι [104].

A. Τράπεζα φίλτρων

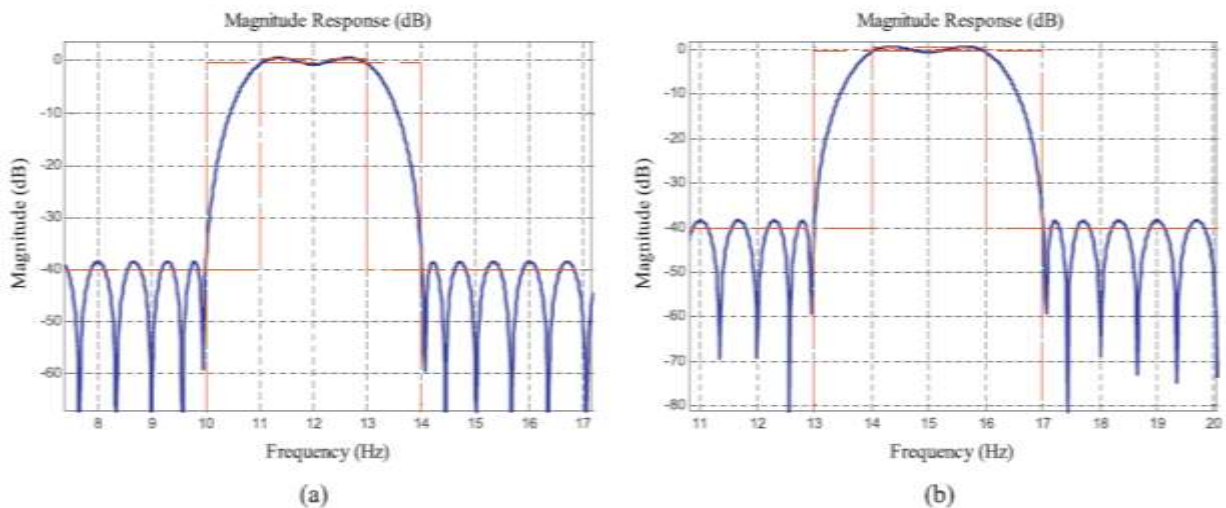
Ένας διαισθητικός τρόπος για να εκτιμηθεί η φασματική ισχύς ενός σήματος SSVEP είναι να επικεντρωθούμε στο εύρος των συχνοτήτων ενδιαφέροντος για την εκτίμηση του φασματικού περιεχομένου αυτού του διαστήματος. Η τράπεζα φίλτρων χρησιμοποιεί αυτή την ιδέα συνδυάζοντας ένα σύνολο ζωνοπερατών φίλτρων που χωρίζει το σήμα εισόδου σε πολλαπλές συνιστώσες [127], καθεμία από τις οποίες

φέρει μία υπο-ζώνη μιας συχνότητας του αρχικού σήματος, όπως φαίνεται στο Σχήμα 3.7.



Σχήμα 3.7: Σύστημα τράπεζας φίλτρων με δύο συχνότητες [104].

Στη μελέτη μας, η τράπεζα φίλτρων έχει σχεδιαστεί με δύο equiripple ζωνοπερατά φίλτρα με το κέντρο τους στις προκληθείσες συχνότητες, εύρος ζώνης 2 Hz, εξασθένηση 40 dB στη ζώνη διακοπής και 1 Hz εύρος μετάβασης (βλέπε Εικόνα 3.13). Η ισχύς εξόδου των στοιχείων της τράπεζας θεωρείται ως μια εκτίμηση του φάσματος ισχύος στις κεντρικές συχνότητες.



Εικόνα 3.13: Απόκριση ζωνοπερατού φίλτρου για κάθε οπτικό ερέθισμα (a) 12Hz και (b) 15Hz [104].

B. Μετασχηματισμός Fourier Βραχέως Χρόνου

Ο μετασχηματισμός Fourier βραχέως χρόνου επιτρέπει την εκτίμηση του φάσματος ισχύος μέσω του υπολογισμού του μετασχηματισμού Fourier σε τμήματα του σήματος, συνήθως με μια επικάλυψη για τη μείωση του θορύβου στα όρια [127]. Οι τιμές που προκύπτουν παρέχουν πληροφορίες σχετικά με το μέγεθος και τη φάση κάθε σημείου στο χρόνο και τη συχνότητα. Ο STFT δίνεται από τη σχέση:

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

όπου $x[n]$ είναι το σήμα, $w[n]$ είναι το παράθυρο, m είναι το μήκος του τμήματος και ω είναι η γωνιακή συχνότητα. Το τετραγωνικό μέγεθος του STFT δίνεται από το φασματογράφημα ως εξής:

$$\text{spectrogram} \equiv |X(m, \omega)|^2$$

και παρέχει μια εκτίμηση του φάσματος ισχύος του σήματος.

Στη μελέτη μας, το φασματογράφημα υπολογίζεται γύρω από τις δύο προκληθείσες συχνότητες (12 και 15 Hz), χρησιμοποιώντας παράθυρα Hamming των 3sec με αλληλοεπικάλυψη 1sec.

Γ. Μέθοδος Welch

Η μέθοδος Welch υπολογίζει τη πυκνότητα φασματικής ισχύος (PSD) εφαρμόζοντας τον αλγόριθμο γρήγορου μετασχηματισμού Fourier (FFT) [127, 128]. Η μέθοδος χωρίζει τα δεδομένα εισόδου σε N τμήματα, υπολογίζει τροποποιημένα περιοδογράμματα (periodograms) των τμημάτων μέσω FFT και εκτιμά την PSD παίρνοντας το μέσο όρο των περιοδογραμμάτων που προκύπτουν. Η μαθηματική διατύπωση της PSD μπορεί να εκφραστεί από το

$$\hat{S}(\omega) = \frac{1}{KNU} \sum_{k=1}^K \left| \sum_{n=1}^N W(n)x(n+kD)\exp(-j\omega n) \right|^2$$

στην οποία το σήμα διαιρείται σε K τμήματα μήκους N και μετατοπίζεται κατά D μονάδες. Το W είναι μια συνάρτηση παραθύρου και το U είναι μια σταθερά που δίνεται από τη σχέση:

$$U = \frac{1}{N} \sum_{n=1}^N |W(n)|^2$$

Στην παρούσα μελέτη, τα δεδομένα περιορίστηκαν από παράθυρα Hamming των 3sec και με 1sec επικάλυψη. Η PSD εκτιμήθηκε για κάθε οπτικό ερέθισμα χρησιμοποιώντας ζώνες του 1Hz με κέντρο τις συχνότητες των 12 και 15 Hz και με βήμα των 0.01 Hz.

Επιλογή χαρακτηριστικών

Ο αριθμός των διαθέσιμων χαρακτηριστικών για το σχεδιασμό ενός συστήματος ταξινόμησης είναι συνήθως μεγάλος σε σύγκριση με τον περιορισμένο αριθμό χαρακτηριστικών που απαιτούνται για να εξασφαλιστούν οι κατάλληλες ιδιότητες γενίκευσης του ταξινομητή, η εύλογη υπολογιστική πολυπλοκότητα και ο χρόνος επεξεργασίας.

Προκειμένου να βρεθούν τα πιο σχετικά χαρακτηριστικά για το σχεδιασμό του συστήματος ταξινόμησης, συνήθως εφαρμόζεται η επιλογή χαρακτηριστικών. Αυτή η τεχνική εκμεταλλεύεται την αμοιβαία (γραμμική και/ή μη γραμμική) συσχέτιση μεταξύ των χαρακτηριστικών, επιλέγοντας αυτά που διατηρούν περισσότερες πληροφορίες διάκρισης μεταξύ των τάξεων. Οι στρατηγικές για την εκτέλεση αυτής της επιλογής ακολουθούν δύο προσεγγίσεις: φίλτρα ή wrappers [111,112]. Η πρώτη

χρησιμοποιεί στατιστικά μέτρα για να ποσοτικοποιήσει τη συνάφεια κάθε χαρακτηριστικού και είναι πιθανώς η πιο απλή τεχνική που λειτουργεί στο χώρο των χαρακτηριστικών [112, 129]. Η δεύτερη προσέγγιση λαμβάνει υπόψη την απόδοση του εκπαιδευμένου ταξινομητή για την κατάταξη των χαρακτηριστικών. Στη συνέχεια περιγράφονται δύο τεχνικές φίλτρων (Pearson και Davies Bouldin), καθώς και ο αλγόριθμος forward wrapper που χρησιμοποιήθηκε σε αυτή τη μελέτη.

A. Pearson's filter

Ο συντελεστής συσχέτισης Pearson [129, 130] ορίζει ένα είδος στρατηγικής φίλτρου στο οποίο ένα διάνυμα εισόδου x_i συνδέεται με ένα χαρακτηριστικό και την ετικέτα του y με τον τύπο:

$$R_i = \frac{cov(x_i, y)}{\sqrt{var(x_i) var(y)}} \quad ,$$

όπου $cov(.)$ είναι η συσχέτιση και $var(.)$ η διακύμανση.

Αυτή η στρατηγική πρώτα αξιολογεί το R_i για $i = 1, \dots, M$, όπου M είναι ο αριθμός των χαρακτηριστικών και, στη συνέχεια, κατατάσσει τα K χαρακτηριστικά χρησιμοποιώντας το κριτήριο των μέγιστων τιμών του R_i . Καθώς η συσχέτιση ορίζει ένα στατιστικό μέτρο δεύτερης τάξης, αυτός ο συντελεστής είναι ικανός να καταγράψει μόνο γραμμική εξάρτηση μεταξύ των χαρακτηριστικών. Ωστόσο, λόγω της υπολογιστικής του απλότητας, μπορεί να χρησιμοποιηθεί κατάλληλα ως βασικό μέτρο για την κατανόηση του χώρου των χαρακτηριστικών.

B. Davies Bouldin

Ο δείκτης Davies Bouldin (DB) είναι ένα μέτρο ομαδοποίησης που επιχειρεί να ποσοτικοποιήσει τη διαχωρισιμότητα των διαφόρων τάξεων λαμβάνοντας υπόψη δύο βασικές πτυχές της ομαδοποίησης δεδομένων: την ελαχιστοποίηση της απόστασης εντός μιας τάξης και τη μεγιστοποίηση της απόστασης μεταξύ των διαφορετικών τάξεων. Για τάξεις w_i με $i = 1, 2, \dots, m$, ο δείκτης DB μπορεί να περιγραφεί από τον λόγο:

$$DB = \frac{1}{m} \sum_{i=1}^m \left(\max_{j=1, \dots, m, j \neq i} \frac{s_i + s_j}{d_{ij}} \right)$$

όπου s_i είναι η μέση απόσταση μεταξύ κάθε σημείου της τάξης i και του κεντροειδούς αυτής της τάξης και s_j είναι το αντίστοιχο για την τάξη j . Η παράμετρος d_{ij} είναι η Ευκλείδεια απόσταση μεταξύ των κεντροειδών των τάξεων i και j .

Λαμβάνοντας την Εικόνα 3.12 (b) ως παράδειγμα ενός διδιάστατου χώρου χαρακτηριστικών, δεν είναι δύσκολο να συνειδητοποιήσουμε ότι μια διασπορά χαμηλής τάξης με κεντροειδή μακριά το ένα από το άλλο, συμβάλλει σε μια επιθυμητή διαχωρίσιμη διαμόρφωση, η οποία συνεπάγεται μικρές τιμές DB και σε ένα ενδιαφέρον μέτρο ταξινόμησης. Σε αυτή την περίπτωση χρησιμοποιήθηκε το αντίστροφο αυτού του δείκτη (DBinv) προκειμένου να αναζητηθούν τα καλύτερα κανάλια (ηλεκτρόδια) στις συχνότητες διέγερσης και κατά συνέπεια να καθοριστεί το διάνυμα χαρακτηριστικών. Μια λεπτομερής περιγραφή του δείκτη DB μπορεί να βρεθεί στο [113].

F. Wrappers

Η μεθοδολογία των wrappers [111, 112] εκτελεί την επιλογή χαρακτηριστικών ως προς την απόδοση του ταξινομητή. Με απλά λόγια, υπάρχουν τρεις πτυχές που ορίζουν την εφαρμογή του [111]: (i) η στρατηγική αναζήτησης που εφαρμόζεται στο χώρο των χαρακτηριστικών, (ii) το κριτήριο διακοπής (stopping criterion) και (iii) η δομή του ταξινομητή.

Το πρώτο βήμα βασίζεται στην αποτελεσματική αναζήτηση στο χώρο των χαρακτηριστικών λόγω του μεγάλου αριθμού δυνατοτήτων της τάξης των 2^M-1 , όπου M είναι ο αριθμός των χαρακτηριστικών. Υπάρχουν πολλές δυνατότητες για να πραγματοποιηθεί μια τέτοια αναζήτηση, όπως οι γενετικοί αλγόριθμοι, η προσομοίωση απόκτησης ή οι greedy heuristics. Στη μελέτη, επιλέχθηκε ο αλγόριθμος greedy heuristic βασισμένος στην εμπρόσθια επιλογή, αφού υποθεθεί ότι τα χαρακτηριστικά συσχετίζονται καλύτερα από μια προοδευτική ενσωμάτωση (progressive incorporation). Το απλούστερο κριτήριο διακοπής συνίσταται από τον κανόνα "αν δεν υπάρχει βελτίωση, σταμάτα". Αυτή η προσέγγιση μπορεί, ωστόσο, να οδηγήσει σε τοπική σύγκλιση. Ένα πιο ισχυρό κριτήριο διακοπής θεωρεί k διαδοχικά βήματα χωρίς κέρδος απόδοσης. Στη μελέτη αυτή υιοθετήθηκε το $k = 2$. Η τρίτη πτυχή, η δομή του ταξινομητή, έχει ισχυρή επίδραση στην επιλογή χαρακτηριστικών, καθώς η απόδοση του ταξινομητή αξιολογείται συνεχώς. Είναι σημαντικό να σημειωθεί ότι τα wrappers δεν εγγυώνται την ολική σύγκλιση.

3.3.2 Μέθοδοι εξαγωγής Χαρακτηριστικών σε Ηλεκτρομυογραφήματα

3.3.2.1 Εξαγωγή χαρακτηριστικών με χρήση του διακριτού μετασχηματισμού κυματιδίου (DWT)


Οι νευροεκφυλιστικές νόσοι (NDD), συμπεριλαμβανομένης της Αμυοτροφικής Πλευρικής Σκλήρυνσης (ALS), της νόσου του Πάρκινσον (PD) και της νόσου Huntington (HD), μπορούν να οριστούν ως εκφυλισμός στη δομή των νευρώνων στο ανθρώπινο σώμα. Αναφέρεται στη σχετική βιβλιογραφία ότι οι NDD μπορούν να προκαλέσουν διάφορα κλινικά συμπτώματα που διαταράσσουν τη δυναμική της βάδισης. Ο χαρακτηρισμός της ανάλυσης βάδισης είναι κρίσιμος για την έγκαιρη διάγνωση, τον αποτελεσματικό σχεδιασμό της θεραπείας και την παρακολούθηση της εξέλιξης της ALS και άλλων NDD. Η βάση δεδομένων που χρησιμοποιήθηκε στη μελέτη, αποτελείται από 64 μονόλεπτες εγγραφές του σήματος σύνθετης δύναμης (Compound Force Signal-CFS) που ελήφθησαν από 13 άτομα με ALS, 15 με PD, 20 με HD και 16 υγιή άτομα. Το CFS είναι η σύνθεση των σημάτων δύναμης τόσο για το αριστερό όσο και για το δεξί πόδι του κάθε ατόμου κατά τη διάρκεια του βηματισμού. Το CFS αποσυντέθηκε στη μελέτη για τον προσδιορισμό των χαρακτηριστικών, χρησιμοποιώντας το διακριτό μετασχηματισμό κυματιδίου επιπέδου 6 (6-level Discrete Wavelet Transform - DWT) με διαφορετικά wavelets. Τα χαρακτηριστικά που ελήφθησαν, αξιολογήθηκαν χρησιμοποιώντας τα μέσα 20 δοκιμών για διασταυρούμενη επικύρωση πέντε φορών (FFCV) στη γραμμική διακριτική ανάλυση (LDA) και τον ταξινομητή Naive Bayesian (NBC).

Το PD είναι μια προοδευτική διαταραχή του νευρικού συστήματος που προκαλεί δυσκαμψία ή επιβράδυνση των κινήσεων, η HD είναι μια κληρονομική ασθένεια που προκαλεί τον εκφυλισμό των νευρικών κυττάρων στον εγκέφαλο, ενώ είναι γνωστό ότι η ALS είναι μια ιδιοπαθής και θανατηφόρα νευροεκφυλιστική νόσος του κινητικού συστήματος στο Ανθρώπινο σώμα [135]. Παρόλο που κλινική ανάλυση (η οποία συμπεριλαμβάνει την ανάλυση ηλεκτρομυογραφήματος (ΗΜΓ), τις εξετάσεις αίματος, τις γενετικές εξετάσεις και εξέταση της σπονδυλικής στήλης) είναι διαθέσιμη για τη διάγνωση των NDD, αυτοί οι τύποι αναλύσεων μπορεί να οδηγήσουν σε προβλήματα κατανάλωσης χρόνου και παρερμηνείας για τις τρεις νευροεκφυλιστικές καταστάσεις στο πρώτο στάδιο [136]. Ως εκ τούτου, η διάκριση της ALS από άλλα NDD και υγιή άτομα είναι πολύ σημαντική για την έγκαιρη διάγνωση και την έγκαιρη παρέμβαση για να βοηθήσει τους ασθενείς που πάσχουν από αυτή τη θανατηφόρα ασθένεια.

Οι NDD μπορούν να παρουσιάσουν διάφορα κλινικά συμπτώματα: Η ALS προκαλεί μυϊκή ατροφία και εκφυλισμό, ενώ το PD προκαλεί βραδυκίνησια, τρέμουλο, ακαμψία και διαταραχές της στάσης και η HD προκαλεί γνωστικές διαταραχές και διαταραχές της προσωπικότητας. Αυτές οι ακανόνιστες κινήσεις προκαλούν δυσκολίες στο συντονισμό των ποδιών και επηρεάζουν τη δυναμική του βηματισμού. Επιπλέον, πολλές μελέτες στη βιβλιογραφία επικεντρώθηκαν στην ανάλυση της δυναμικής της βάδισης για να διερευνήσουν τις επιδράσεις των NDD στη μετακίνηση του ανθρώπου [137-143]. Αυτές οι ερευνητικές μελέτες επικεντρώνονται στην ανάλυση των διαστημάτων διασκελισμού χρονοσειρών (stride interval time series) και των διακυμάνσεων της χρονικής διάρκειας της στάσης (stance time fluctuations) σε αρχεία βαδίσματος πέντε λεπτών. Αντίστροφα, η παρούσα μελέτη εξασφαλίζει ταχύτερη ανάλυση και διάγνωση μέσω ανάλυσης εγγραφών βάδισης του ενός λεπτού. Ο κύριος στόχος αυτής της μελέτης είναι η

απόκτηση κρίσιμων ζωνών συχνοτήτων στο CFS για γρήγορη διάκριση της ALS μεταξύ άλλων NDD και υγιών ατόμων. Ως εκ τούτου, προτείνεται μια μέθοδος βασισμένη σε DWT, LDA και NBC στην παρούσα μελέτη.


Το σχεδιάγραμμα της μελέτης φαίνεται στο Σχήμα 3.8. Στην έρευνα, αρχικά υπολογίστηκε η άθροιση των σημάτων δύναμης που καταγράφηκαν από το δεξί και το αριστερό πόδι των ατόμων, αντίστοιχα. Αυτά τα σωρευτικά σήματα (cumulative signals) αναφέρονται ως CFS σε αυτή τη μελέτη. Στη συνέχεια, το CFS αποσυντέθηκε σε μια ανακατασκευασμένη προσέγγιση και σε λεπτομερείς συντελεστές χρησιμοποιώντας το DWT για να αποκτήσουμε τα χαρακτηριστικά [143]. Αυτά τα χαρακτηριστικά αξιολογήθηκαν λαμβάνοντας υπόψη τις επιδόσεις ακρίβειας ταξινόμησης χρησιμοποιώντας τους LDA και NBC στο τελευταίο στάδιο της μελέτης. Τέλος, τα κρίσιμα χαρακτηριστικά προσδιορίστηκαν και αναφέρθηκαν στη μελέτη. Οι τάξεις επιλέχθηκαν ως εξής: άτομα με ALS (τάξη 1) έναντι φυσιολογικών ατόμων (τάξη 2), άτομα με ALS (τάξη 1) έναντι ατόμων με PD (τάξη 2), άτομα με ALS (τάξη 1) έναντι ατόμων με HD (τάξη 2), άτομα με ALS (τάξη 1) έναντι ατόμων με PD ή HD (τάξη 2) και άτομα με ALS (τάξη 1) έναντι ατόμων με PD ή HD ή φυσιολογικών ατόμων (τάξη 2), στην έξοδο του αλγορίθμου κατά την ανάλυση.



Σχήμα 3.8: Το σχεδιάγραμμα της μελέτης [134].

Στη μελέτη αυτή χρησιμοποιήθηκε η δυναμική βάδισης στη βάση δεδομένων των NDD της ιστοσελίδας www.physionet.org [146]. Αυτή η βάση δεδομένων περιλαμβάνει 64 σήματα δύναμης που καταγράφονται από το δεξί και το αριστερό πόδι και ανήκουν σε 13 (10 αρσενικά, 3 θηλυκά) άτομα με ALS (ηλικιακή ομάδα: 36-70), 15 (10 αρσενικά και 5 θηλυκά) άτομα με PD (ηλικιακό εύρος: 44-79) 20 (6 αρσενικά και 14 θηλυκά) άτομα με HD (ηλικιακό εύρος: 29-71) και 16 (2 αρσενικά και 14 θηλυκά) υγιή αντικείμενα ελέγχου (ηλικιακό εύρος: 20-74) [139, 147]. Τα πρωτογενή δεδομένα της βάσης δεδομένων καταγράφηκαν χρησιμοποιώντας αντιστάσεις ευαίσθητες στη δύναμη που τοποθετήθηκαν κάτω από το δεξί και αριστερό πόδι [147-151]. Επίσης, η παρατήρηση του συντονισμού των ποδιών είναι σημαντική για την ανάλυση της βάδισης. Δεδομένου ότι μόνο το σήμα του ενός ποδιού δεν είναι αρκετό, το CFS είναι ένα πιο χρήσιμο σήμα για τη μοντελοποίηση του συντονισμού μεταξύ δύο ποδιών στη μελέτη. Οι καταγραφές σημάτων των 6 δευτερολέπτων από το αριστερό πόδι, το δεξί πόδι και το CFS, φαίνονται στην Εικόνα 3.14. Όλα τα πρωτογενή δεδομένα υποβλήθηκαν σε δειγματοληψία συχνότητας 300 Hz. Υπάρχουν διάφοροι περιορισμοί [140] στη βάση δεδομένων: (1) οι ομάδες δεν έχουν σωστή αντιστοιχία όσον αφορά το φύλο και την ηλικία. Παρόλα αυτά, απαιτούνται περαιτέρω έρευνες για να αποσαφηνιστούν οι επιδράσεις της ηλικίας και του φύλου στη δυναμική της βάδισης, αφού εξηγείται ότι οι NDD συνήθως δεν διαφέρουν μεταξύ των φύλων και των ηλικιακών ομάδων όσον αφορά με τη δυναμική της βάδισης στη βιβλιογραφία [139-141,152]. (2) τα υποκείμενα δεν

ήταν κατάλληλα μοιρασμένα σε σχέση με το ύψος τους. Αυτός ο περιορισμός σχετίζεται με την αύξηση της διακύμανσης του χρόνου διασκελισμού (stride time fluctuation) στη δυναμική του βηματισμού, αλλά μπορεί να μην επηρεάσει την CFS ανάλυση και τα CFS πρότυπα, λαμβάνοντας υπόψη τη διακύμανση του χρόνου διασκελισμού. (3) ο σχετικά μικρός αριθμός ατόμων μέσα σε κάθε ομάδα προκαλεί τη λανθασμένη αντιστοίχιση της ομαδοποίησης κατά την ταξινόμηση και την διαδικασία αξιολόγησης. Στην περίπτωση αυτή, οι παράμετροι επεξεργασίας της διασταυρούμενης επικύρωσης πρέπει να επιλεγούν με ισορροπημένο τρόπο για την επικύρωση της απόδοσης ταξινόμησης. Ως εκ τούτου, το FFCV χρησιμοποιήθηκε για τη μέτρηση της απόδοσης στη μελέτη. (4) η βάση δεδομένων στη βιβλιογραφία περιλαμβάνει καταγραφές βάδισης των πέντε λεπτών. Το πεντάλεπτο περπάτημα μπορεί να αποδειχθεί δύσκολο για ορισμένα άτομα, ενώ μπορεί να είναι ένα συγκριτικά απλό έργο για άλλους. Ως αποτέλεσμα, μπορεί τα άτομα που έχουν κουραστεί να παρουσιάσουν απώλεια της προσπάθειάς τους. Εκτός αυτού, ενδέχεται να εμφανιστούν μερικά λανθασμένα σήματα κατά τη διάρκεια των πεντάλεπτων εγγραφών, λόγω ασυνεχειών και πίεσης-καταναγκασμού. Επομένως, η χρήση εγγραφών του ενός λεπτού είναι σχετικά ταχύτερη για αναλύσεις και επίσης ελαχιστοποιεί τις σφάλματα στα σήματα βηματισμού.



Εικόνα 3.14: Το σήμα δύναμης του αριστερού ποδιού, το σήμα δύναμης του δεξιού ποδιού και το CFS [134].

Διακριτός Μετασχηματισμός Κυματιδίου (DWT)

Η ανάλυση κυματιδίου (Wavelet analysis), η οποία διερευνά το σήμα τόσο στο πεδίο του χρόνου όσο και στο πεδίο της συχνότητας, χρησιμοποιείται ειδικά για την ανάλυση σημάτων χαμηλής συχνότητας στη μηχανική και τη βιοϊατρική. Υπάρχουν αρκετές μέθοδοι μετασχηματισμού κυματιδίου στη βιβλιογραφία, όπως ο συνεχής μετασχηματισμός κυματιδίου (CWT), ο DWT και ο Wavelet Packet Transform (WPT). Ενώ ο CWT και ο WPT παρέχουν περιττές παραμέτρους σήματος, ο DWT που προέρχεται από την κριτική δειγματοληψία του CWT, μειώνει αισθητά τον αριθμό παραμέτρων διαστολής και μετατόπισης. Για αυτό το λόγο, ο DWT προτιμήθηκε στη μελέτη.

Το CFS αποσυντέθηκε σε προσεγγιστικές και λεπτομερείς συνιστώσες και οι συντελεστές αποκτήθηκαν χρησιμοποιώντας την ανακατασκευή του DWT σε κάθε επίπεδο σε αυτό το τμήμα της μελέτης. Το αρχικό CFS που ορίζεται ως $x(k)$, δίνεται από την Εξ. (1) μετά την αποσύνθεση (decomposition) και την ανακατασκευή (reconstruction) της επεξεργασίας DWT [144].


$$x(k) = \sum_{i=1}^M \sum_{j \in \mathbb{Z}} d_{2^i}(j) \psi_{ij}(k) + \sum_{j \in \mathbb{Z}} a_{2^0}(j) \phi_{ij}(k)$$

Εδώ, το M είναι το επίπεδο αποσύνθεσης του DWT, το k είναι το μήκος του αρχικού σήματος $x(k)$, η παράμετρος i δηλώνει την κλίμακα της διαστολής, ενώ η j είναι ο δείκτης του χρόνου. Επίσης, τα προσεγγιστικά και τα λεπτομερή σήματα του αρχικού σήματος $x(k)$ σημειώνονται ως $a_{2^i}(j)$ και $d_{2^i}(j)$, αντίστοιχα. Οι συναρτήσεις κυματιδίου $\psi_{ij}(k)$ και κλιμάκωσης (scaling) $\phi_{ij}(k)$ υπολογίζονται μαθηματικά από τις επόμενες εξισώσεις:

$$\phi_{ij}(k) = 2^{-\frac{i}{2}} \phi(2^{-i}k - j)$$

$$\psi_{ij}(k) = 2^{-\frac{i}{2}} \psi(2^{-i}k - j)$$

Ο κύριος σκοπός του DWT είναι να ανιχνεύσει τις μεταβολές στο CFS και να αξιολογήσει τις ανακατασκευασμένες λεπτομερείς ενέργειες σήματος στην μελέτη. Αναλυτικά οι συντελεστές και το CFS για τον DWT έκτου επιπέδου, εμφανίζονται στην εικόνα 3.15. Παρατηρείται ότι οι διακυμάνσεις των λεπτομερών συντελεστών (detailed components) μεταβάλλονται, αν λάβουμε υπόψη τις γρήγορες αλλαγές στο CFS. Παρατηρείται επίσης, ότι η σχέση μεταξύ των λεπτομερών συντελεστών και του CFS διαταράσσεται στις αποσυνθέσεις υψηλότερου επιπέδου, ενώ οι αποσυνθέσεις χαμηλότερου επιπέδου δεν μπορούν να φτάσουν σε αρκετές ζώνες συχνοτήτων συμπεριλαμβανομένων των σημαντικών χαρακτηριστικών στην Εικόνα 3.15. Ως εκ τούτου, το CFS αποσυντέθηκε σε 6 επίπεδα για να παρέχει τα βέλτιστα χαρακτηριστικά διάκρισης.



Εικόνα 3.15: Αναλυτικοί συντελεστές σε CFS σήμα [134].

Διαφορετικοί τύποι οικογενειών κυματιδίων εφαρμόστηκαν στο CFS και επιλέχθηκαν τα πιο επιτυχημένα wavelets από κάθε οικογένεια, λαμβάνοντας υπόψη τη σύγκριση επιδόσεων ταξινόμησης των αλγορίθμων LDA και NBC, αντίστοιχα. Τα «Haar» και «db3» από τα Daubechies, το «coif2» από τα coiflets, το «sym4» από τα symlets και το «bior2.6» από τα biorthogonal wavelets αξιολογήθηκαν στην παρούσα μελέτη.

Τα εύρη συχνοτήτων των λεπτομερών συντελεστών παρουσιάζονται στον Πίνακα 3.2 [134]. Δεδομένου ότι η συχνότητα δειγματοληψίας του CFS είναι 300 Hz, το εύρος ζώνης του CFS είναι μεταξύ 0 και 150 Hz.

Πίνακας 3.2: Τα εύρη των συχνοτήτων για κάθε έναν λεπτομερή συντελεστή DWT.

| DWT Detailed Components | Frequency Ranges (Hz) |
|-------------------------|-----------------------|
| D6 | 2.3438–4.6875 |
| D5 | 4.6875–9.375 |
| D4 | 9.375–18.75 |
| D3 | 18.75–37.5 |
| D2 | 37.5–75 |
| D1 | 75–150 |

Τα χαρακτηριστικά της μελέτης ελήφθησαν από το λόγο της ενέργειας των λεπτομερών συντελεστών προς τη συνολική ενέργεια του CFS. Διατυπώνεται ως εξής:

$$E_{Per} = \frac{E_{Det}}{E_{Total}} \times 100$$

Το E_{Det} είναι η ενέργεια σήματος κάθε λεπτομερούς συντελεστή, αντίστοιχως, προκειμένου να υπολογιστεί ο αντίκτυπος τους στο CFS. Το E_{Total} είναι η συνολική ενέργεια του αρχικού CFS. Το E_{Per} δηλώνει το ποσοστό ενέργειας κάθε λεπτομερούς συντελεστή. Στην παρούσα μελέτη, τα ποσοστά ενέργειας υπολογίστηκαν για κάθε CFS αντίστοιχα.

3.3.3 Μέθοδοι Εξαγωγής Χαρακτηριστικών σε Ηλεκτροκαρδιογραφήματα

3.3.3.1 Εξαγωγή ενός συνδυασμού γραμμικών και μη γραμμικών χαρακτηριστικών με χρήση των μεθόδων PCA και ICA

Η αρρυθμία είναι καρδιακή πάθηση που προκαλείται από τη μη φυσιολογική ηλεκτρική δραστηριότητα της καρδιάς και το ηλεκτροκαρδιογράφημα (ΗΚΓ) είναι η μη επεμβατική μέθοδος που χρησιμοποιείται για την ανίχνευση αρρυθμιών ή καρδιακών ανωμαλιών. Λόγω της παρουσίας θορύβου, της μη-στατικής φύσης του σήματος ΗΚΓ (δηλαδή της μεταβαλλόμενης μορφολογίας του σήματος ΗΚΓ σε σχέση με το χρόνο) και της ανομοιομορφίας του καρδιακού παλμού, οι γιατροί αντιμετωπίζουν δυσκολίες στη διάγνωση των αρρυθμιών. Η -υποβοηθούμενη από υπολογιστή- ανάλυση των αποτελεσμάτων των ΗΚΓ, βοηθά τους γιατρούς να ανιχνεύσουν καρδιαγγειακές παθήσεις. Η ανάπτυξη πολλών υφισταμένων συστημάτων αρρυθμίας έχει στηριχθεί στα ευρήματα των γραμμικών πειραμάτων σε δεδομένα ΗΚΓ, τα οποία επιτυγχάνουν υψηλή απόδοση σε δεδομένα χωρίς θόρυβο. Ωστόσο, τα μη γραμμικά πειράματα χαρακτηρίζουν το σήμα του ΗΚΓ αποτελεσματικότερα, αφού εξάγουν πληροφορίες που είναι κρυμμένες στο ΗΚΓ και επιτυγχάνουν καλή απόδοση κάτω από θορυβώδεις συνθήκες. Η παρούσα έρευνα διερευνά την ικανότητα αναπαράστασης των γραμμικών και μη γραμμικών χαρακτηριστικών και προτείνει ένα συνδυασμό τέτοιων χαρακτηριστικών προκειμένου να βελτιωθεί η ταξινόμηση των δεδομένων ΗΚΓ. Σε αυτή τη μελέτη, αναλύονται πέντε τύποι τάξεων χτύπων αρρυθμίας, όπως συνιστώνται από την Ένωση για την Προώθηση Ιατρικών Συσκευών (Association for Advancement of Medical Instrumentation): μη-εκτοπικές συστολές (non-ectopic beats) (N), υπερκοιλιακές εκτοπικές συστολές (S), κοιλιακές εκτοπικές συστολές (V), συστολές από συγχώνευση (F) και οι μη ταξινομούμενες και οι ρυθμικές συστολές (U). Η ικανότητα χαρακτηρισμού των μη γραμμικών χαρακτηριστικών όπως οι στατιστικές υψηλής τάξης και οι μέθοδοι μείωσης των μη γραμμικών χαρακτηριστικών, όπως η ανεξάρτητη ανάλυση συνιστωσών, συνδυάζονται με γραμμικά χαρακτηριστικά, δηλαδή με την ανάλυση κύριων συνιστωσών (PCA) των συντελεστών του διακριτού μετασχηματισμού κυματιδίου. Τα χαρακτηριστικά δοκιμάζονται για την ικανότητά τους να διαφοροποιούν τις διαφορετικές τάξεις δεδομένων χρησιμοποιώντας διαφορετικούς ταξινομητές, (όπως τις μηχανές διανυσμάτων υποστήριξης και τα νευρωνικά δίκτυα), με διασταυρούμενη επικύρωση 10 φορών. Η προτεινόμενη μέθοδος είναι ικανή να ταξινομήσει τις τάξεις αρρυθμίας N, S, V, F και U με υψηλή ακρίβεια (98.91%) χρησιμοποιώντας μια συνδυαστική μέθοδο μηχανών διανυσμάτων υποστήριξης και συνάρτησης ακτινικής βάσης.

Η καρδιαγγειακή νόσος (CVD) έχει γίνει μία από τις κύριες αιτίες θανάτου στον κόσμο [156]. Δύο από τους κύριους παράγοντες της CVD είναι οι κοιλιακές και υπερκοιλιακές αρρυθμίες που διαταράσσουν τον καρδιακό ρυθμό. Οι καρδιακές αρρυθμίες εμφανίζονται γενικά σε άτομα με ασθένειες, όπως καρδιομυοπάθεια, υπέρταση και στεφανιαία νόσο. Η ηλεκτρική δραστηριότητα της καρδιάς μπορεί να καταγραφεί χρησιμοποιώντας επιφανειακά ηλεκτρόδια. Η καταγραφή περιγράφει την κύρια κατεύθυνση των ηλεκτρικών παλμών σε όλη την καρδιά για οποιοδήποτε χρονικό διάστημα και είναι γνωστή ως ηλεκτροκαρδιογράφημα (ΗΚΓ). Το ΗΚΓ είναι μια μη επεμβατική μέθοδος που χρησιμοποιείται για την ανίχνευση αρρυθμιών ή καρδιακών ανωμαλιών. Λόγω της παρουσίας θορύβου και της ανομοιομορφίας του καρδιακού παλμού, οι γιατροί αντιμετωπίζουν δυσκολίες στη διάγνωση των αρρυθμιών.

Επιπλέον, μόνο ο οπτικός έλεγχος μπορεί να οδηγήσει σε εσφαλμένη διάγνωση ή ασήμαντη ανίχνευση αρρυθμιών [157]. Επομένως, η ανάλυση με τη βοήθεια ηλεκτρονικού υπολογιστή των δεδομένων ΗΚΓ βοηθά τους γιατρούς να ανιχνεύσουν αποτελεσματικά την αρρυθμία [158, 159].

Υπάρχουν τρεις κύριες διαδικασίες σε ένα σύστημα ανίχνευσης αρρυθμιών ΗΚΓ, δηλαδή η εξαγωγή χαρακτηριστικών, η επιλογή χαρακτηριστικών και η κατασκευή ταξινομητών [160]. Ως μία διαδικασία κλειδί, η εξαγωγή χαρακτηριστικών μετατρέπει τα δεδομένα εισόδου σε ένα σύνολο χαρακτηριστικών και παίζει σημαντικό ρόλο στην ανίχνευση των περισσότερων καρδιακών παθήσεων.

Η εξαγωγή των κρυφών πληροφοριών που υπάρχουν στα σήματα ΗΚΓ και η βελτίωση της απόδοσης ταξινόμησης, είναι ζωτικής σημασίας. Για την ανάλυση των ΗΚΓ σημάτων χρησιμοποιούνται διάφορες τεχνικές εξόρυξης δεδομένων, οι οποίες ταξινομούνται σε τεχνικές χρόνου, τεχνικές συχνότητας και τεχνικές χρόνου-συχνότητας.

Στο πεδίο χρόνου, τα εξαγόμενα χαρακτηριστικά είναι το διάστημα καρδιακού ρυθμού, οι παράμετροι διάρκειας (QRS, QT, και PR) και οι παράμετροι πλάτους (QRS, ST) [161]. Λόγω των λεπτών αλλαγών στο πλάτος και τη διάρκεια του ΗΚΓ, οι χρονικές μέθοδοι δεν παρέχουν καλή διακριτική ικανότητα [162]. Επομένως, χρησιμοποιούνται μέθοδοι συχνότητας όπως ο μετασχηματισμός Fourier και η φασματική πυκνότητα ισχύος (PSD). Ωστόσο, οι μέθοδοι συχνότητας δεν παρέχουν χρονικές πληροφορίες για τα σήματα ΗΚΓ. Μια σωστή τεχνική χρόνου-συχνότητας θα μπορούσε να αντιμετωπίσει αυτό το πρόβλημα. Ο μετασχηματισμός wavelet είναι η πιο ευρέως χρησιμοποιούμενη μέθοδος χρόνου-συχνότητας [163-166]. Παρέχει καλή ανάλυση τόσο στο πεδίο του χρόνου, όσο και στο πεδίο της συχνότητας.

Το σήμα ΗΚΓ είναι μη στάσιμο, δηλαδή η μορφολογία του σήματος μεταβάλλεται σε σχέση με το χρόνο και οι διακυμάνσεις αυτές δεν παρουσιάζονται μόνο μεταξύ διαφορετικών ασθενών αλλά και εντός των ίδιων ασθενών [169]. Το σήμα ΗΚΓ μπορεί να αναπαρασταθεί χρησιμοποιώντας μη γραμμικά πειράματα τα οποία χαρακτηρίζουν το σήμα πιο αποτελεσματικά, εξάγουν τις κρυμμένες στο ΗΚΓ πληροφορίες και αποδίδουν καλά υπό συνθήκες θορύβου [170]. Για παράδειγμα, η χρήση συσσωρευτών φάσματος υψηλότερης τάξης (HOS) παρέχει πολύ καλή αναγνώριση και επηρεάζεται λιγότερο από τις μορφολογικές μεταβολές του σήματος ΗΚΓ [168,169].

Ωστόσο, οι περισσότερες τεχνικές που έχουν προταθεί στη βιβλιογραφία για την εξαγωγή χαρακτηριστικών από ΗΚΓ, έχουν τα ακόλουθα μειονεκτήματα:

- (α) Είναι πιθανό το σήμα ΗΚΓ να καλύπτεται από θόρυβο, ενώ είναι γνωστό ότι η μεγαλύτερη ακρίβεια επιτυγχάνεται σε συνθήκες χωρίς θόρυβο [168].
- (β) Μερικές από τις μεθόδους εξαγωγής χαρακτηριστικών είναι υπολογιστικά πολύπλοκες, δεν περιλαμβάνουν τις ιδιότητες συμμετρίας και ανάκλασης και δεν ακολουθούν την αρχή της υπέρθεσης. Επομένως, οι αρχές της προσθετικότητας και ομοιογένειας δεν ακολουθούνται από αυτές τις μεθόδους [168].

Επομένως, ένας συνδυασμός γραμμικών χαρακτηριστικών με μη γραμμικά χαρακτηριστικά θα ήταν μια εξαιρετική λύση για αυτά τα μειονεκτήματα.

Η παρούσα μελέτη προτείνει μια νέα τεχνική για την αναγνώριση της αρρυθμίας και την ταξινόμηση των σημάτων ΗΚΓ με βάση έναν συνδυασμό γραμμικών και μη γραμμικών τεχνικών εξαγωγής χαρακτηριστικών για συνθήκες με και χωρίς θόρυβο, σε σύγκριση με τις γραμμικές τεχνικές που έχουν μικρότερη υπολογιστική πολυπλοκότητα. Αυτή η συνδυασμένη τεχνική είναι σε θέση να αναγνωρίσει τα πιο διακριτά χαρακτηριστικά μεταξύ φυσιολογικών και μη φυσιολογικών τάξεων των σημάτων εισόδου. Μια γραμμική PCA της μεθόδου DWT εφαρμόζεται,

μετασχηματίζοντας αρχικά τους παλμούς ΗΚΓ χρησιμοποιώντας DWT και στη συνέχεια εφαρμόζοντας τη μέθοδο μείωσης των διαστάσεων της PCA για να εξάγει τα χαρακτηριστικά. Επιπλέον, η μη γραμμική μέθοδος HOS cumulants και μια μη γραμμική τεχνική μείωσης των διαστάσεων ([ICA]) χρησιμοποιούνται για την ανάλυση των μη γραμμικών σημάτων ΗΚΓ. Αυτά τα χαρακτηριστικά με μειωμένη διαστασιμότητα τροφοδοτούνται στους ταξινομητές NN και SVM με τη συνάρτηση πυρήνα ακτινικής βάσης για αυτοματοποιημένη διάκριση μεταξύ φυσιολογικών και μη φυσιολογικών τάξεων των σημάτων ΗΚΓ.


Η πηγή των αρχείων ΗΚΓ που χρησιμοποιήθηκαν σε αυτή τη μελέτη είναι η βάση δεδομένων αρρυθμίας MIT-BIH [171]. Η βάση δεδομένων περιέχει 48 σήματα που έχουν υποστεί δειγματοληψία στα 360 Hz, και κάθε ένα από τα 48 σήματα είναι χρονικής διάρκειας λίγο μεγαλύτερης των 30 λεπτών. Εικοσιτρείς εγγραφές επιλέχθηκαν τυχαία από ένα σύνολο 4000 24-ωρων καταγραφών ΗΚΓ που συλλέχθηκαν από ασθενείς στο νοσοκομείο Beth Israel της Βοστώνης. Οι υπόλοιπες 25 εγγραφές επιλέχθηκαν από το ίδιο σετ για να συμπεριλάβουν άλλες κλινικά σημαντικές αρρυθμίες που μπορεί να μην αντιπροσωπεύονται καλά σε μια μικρή τυχαία ομάδα δειγμάτων, επειδή είναι λιγότερο συχνές. Ένας χτύπος ΗΚΓ θεωρείται ένας κύκλος της ηλεκτρικής δραστηριότητας της καρδιάς. Οι ανωμαλίες των χτύπων ονομάζονται εκτοπικοί χτύποι. Το πρότυπο ANSI/AAMI EC57: 1998 συνιστά το σύνολο των δεδομένων αρρυθμίας της MIT-BIH να ταξινομηθούν σε πέντε κύριες κατηγορίες χτύπων [167]. Οι πέντε κατηγορίες είναι: φυσιολογικοί χτύποι (N), χτύποι από συγχώνευση (F), υπερ-κοιλιακοί εκτοπικοί χτύποι (S), κοιλιακοί εκτοπικοί χτύποι (V) και άγνωστοι χτύποι (U). Τα δεδομένα που χρησιμοποιήθηκαν στη μελέτη αυτή περιελάμβαναν (90.580) N, (2973) S, (7707) V, (1784) F και (7050) U. Ο Πίνακας 3.3 [155] παρουσιάζει τις λεπτομέρειες των διαφορετικών παλμών της βάσης δεδομένων MIT- BIH και συνοψίζει τους πέντε τύπους δειγμάτων παλμών του ΗΚΓ, που χρησιμοποιούνται σε αυτήν την εργασία.

Πίνακας 3.3:

MIT-BIH arrhythmia beats classification per ANSI/AAMI EC57:1998 standard database.

| AAMI classes | MIT-BIH heartbeat classes |
|------------------------------------|---|
| Non-ectopic beat (N) | Normal beat (N) Left bundle branch block (LBBB) Right bundle branch block (RBBB) Nodal (junctional) escape (j) Atrial escape beat (e) |
| Supra-ventricular ectopic beat (S) | Aberrated atrial premature (A) Atrial premature (a) Supraventricular premature (S) Nodal (junctional) premature (J) |
| Ventricular ectopic beat (V) | Ventricular escape (V) Premature ventricular contraction (E) |
| Fusion beat (F) | Fusion of ventricular and normal (F) |
| Unknown beat (U) | Unclassifiable (U) Paced (p) Fusion of paced and normal (f) |

Το προτεινόμενο αυτόματο σύστημα αναγνώρισης υιοθετεί διάφορες μεθόδους ακολουθώντας διαφορετικές μεθόδους προεπεξεργασίας, εξαγωγής χαρακτηριστικών και ταξινόμησης. Το Σχήμα 3.9 δείχνει ένα γενικό διάγραμμα του κατασκευασμένου συστήματος. Το έργο που αφορά κάθε τμήμα εξηγείται λεπτομερώς στις επόμενες ενότητες.



Σχήμα 3.9: Το προτεινόμενο αυτοματοποιημένο σύστημα αναγνώρισης [155].

Προεπεξεργασία

Το σήμα ΗΚΓ περιέχει διαφορετικές φύσεις θορύβου. Ο θόρυβος της επαφής, η παραμόρφωση της γραμμής βάσης, τα μυϊκά αντικείμενα, τις ηλεκτρομαγνητικές παρεμβολές, το τεχνητό ηλεκτρόδιο κίνησης, το τεχνητό ηλεκτρομυογράφημα, ο θόρυβος της συσκευής συλλογής δεδομένων και ο θόρυβος κβαντισμού αποτελούν παραδείγματα θορύβου. Η ποιότητα της ταξινόμησης ΗΚΓ εξαρτάται από την ακρίβεια της ανίχνευσης κάθε καρδιακού κύκλου [172]. Σε αυτή την εργασία, η μονάδα προ-επεξεργασίας αναλύεται σε τρία συστατικά στοιχεία, όπως φαίνεται παραπάνω στο Σχήμα 3.9. Αρχικά εκτελείται μείωση του σήματος ΗΚΓ με βάση το DWT, το δεύτερο στοιχείο είναι η ανίχνευση του συμπλέγματος QRS (δηλαδή ο συνδυασμός τριών από τις γραφικές παραμορφώσεις που παρατηρούνται σε ένα τυπικό ΗΚΓ, δηλαδή το Q, R και S κύματα), και το τελευταίο στοιχείο είναι η κατάτμηση του σήματος. Κάθε στοιχείο περιγράφεται εν συντομία ως εξής.

A. Αποθορυβοποίηση

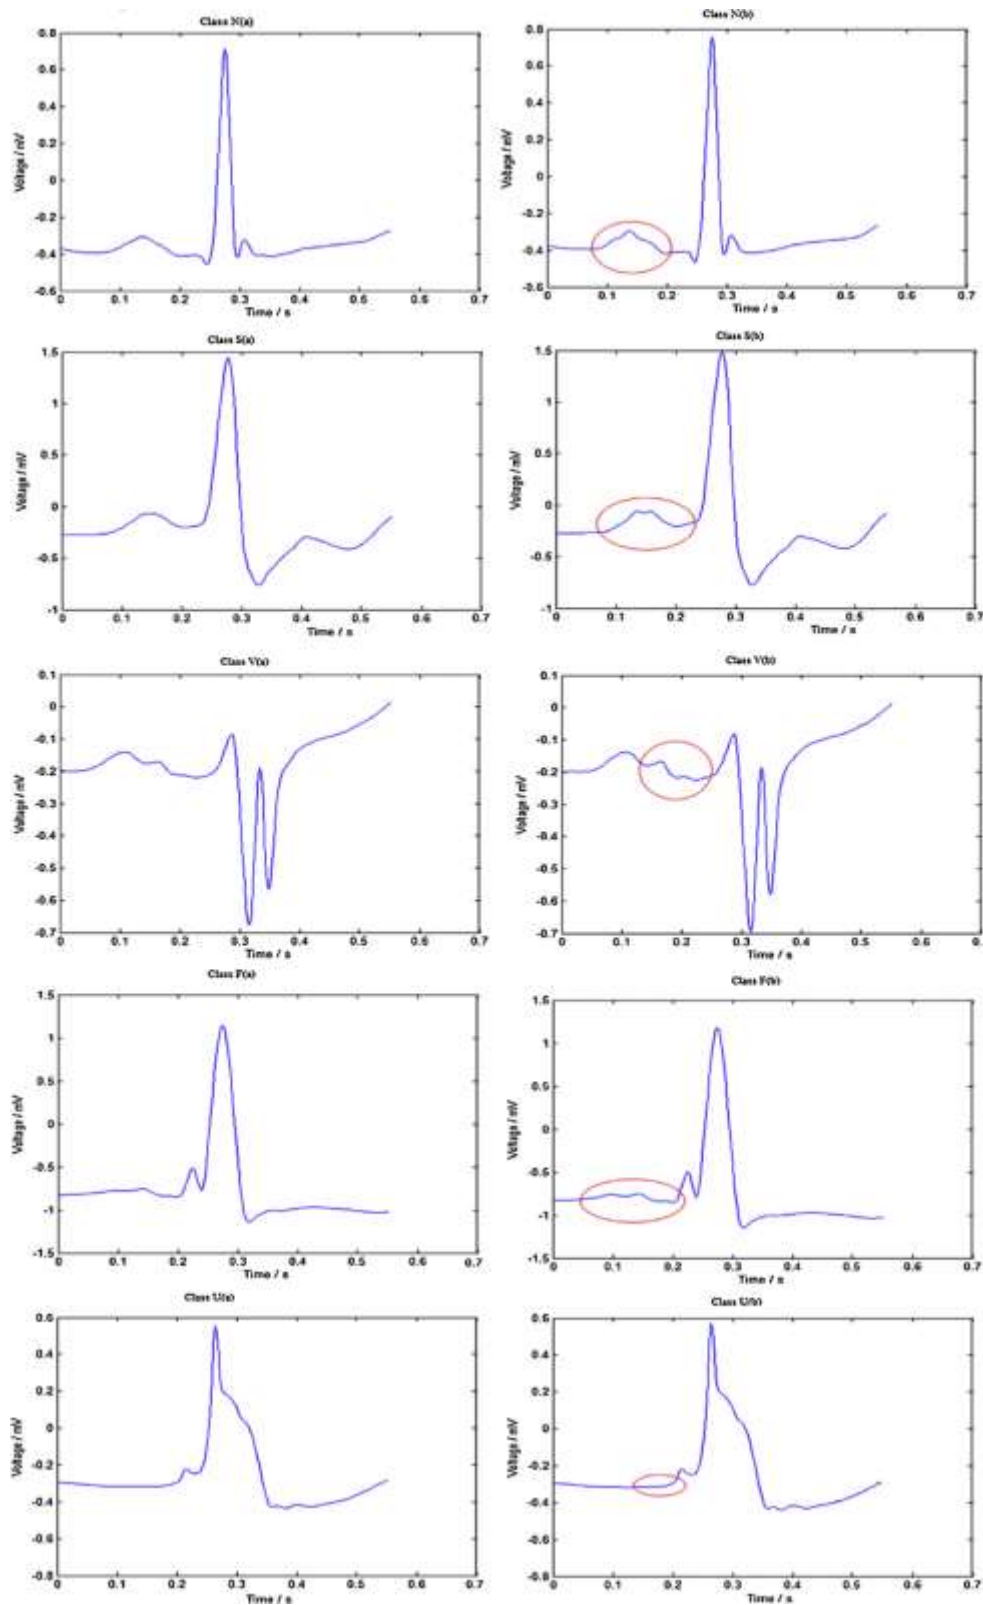
Δεδομένου ότι ο DWT είναι αποτελεσματικός στην ανάλυση μη στατικών σημάτων, χρησιμοποιείται σε αυτή την ερευνητική εργασία. Η συνάρτηση βάσης κυματιδίου Daubechies D6 (db6), χρησιμοποιείται για την αποθορυβοποίηση των δεδομένων, με τα σήματα ΗΚΓ να αποσυντίθενται σε εννέα επίπεδα [173]. Ένα εύρος συχνοτήτων από 0 έως 0.351 Hz στην υπο-ζώνη προσέγγισης του ένατου επιπέδου, δεν χρησιμοποιείται για την ανασύσταση του αποθορυβοποιημένου σήματος. Επιπλέον, τα εύρη συχνοτήτων 90-180 Hz και 45-90 Hz δεν εξετάστηκαν, επειδή η πληροφορία μετά από τα 45 Hz δεν είναι σημαντική για την ανίχνευση της αρρυθμίας. Ο αντίστροφος μετασχηματισμός κυματιδίου υπολογίζεται από τις υπο-ζώνες λεπτομέρειας του τρίτου έως ένατου επιπέδου, για να ληφθεί το αποθορυβοποιημένο και ομαλοποιημένο σήμα ΗΚΓ [173].

B. Ανίχνευση του συμπλέγματος QRS

Ο αλγόριθμος Pan-Tompkins χρησιμοποιήθηκε στον αλγόριθμο του αποθορυβοποιημένου σήματος ΗΚΓ, για την ανίχνευση του συμπλέγματος QRS [174]. Ο αλγόριθμος αναλύει την κλίση, το πλάτος και το εύρος και αποτελείται από τρία βήματα. Στο πρώτο βήμα, τα βαθυπερατά και υψηπερατά φίλτρα σχηματίζουν ένα ζωνοπερατό φίλτρο, το οποίο μειώνει το θόρυβο στο σήμα ΗΚΓ, όπως το θόρυβο των μυών. Στο δεύτερο βήμα, για να διακρίνουν τα συμπλέγματα QRS από τις συνιστώσες ΗΚΓ χαμηλής συχνότητας, όπως τα κύματα P και T, το σήμα περνά από έναν διαφοριστή για να ενισχύσει τις υψηλές κλίσεις. Το τρίτο βήμα είναι η τετραγωνική λειτουργία, η οποία δίνει έμφαση στις υψηλότερες τιμές που υπάρχουν κυρίως λόγω των συμπλεγμάτων QRS. Στη συνέχεια, το τετραγωνισμένο σήμα περνάει μέσα από έναν ολοκληρωτή κινούμενου παραθύρου του μήκους του παραθύρου. Το αποτέλεσμα είναι ένας κύκλος ΗΚΓ με ομαλή κορυφή. Η έξοδος του ολοκληρωτή κινούμενου παραθύρου μπορεί να χρησιμοποιηθεί για την εύρεση συμπλεγμάτων QRS.

Γ. Κατάτμηση

Μετά την ανίχνευση του συμπλέγματος QRS, επιλέχθηκαν 99 δείγματα από την αριστερή πλευρά του μεσαίου σημείου του QRS και 100 δείγματα μετά το μεσαίο σημείο του QRS και το ίδιο το μεσαίο σημείο ως τμήμα ή χτύπος 200 δειγμάτων [167]. Η Εικόνα 3.16 αντιπροσωπεύει τους πέντε τύπους τάξεων των χτύπων, στην πρότυπη βάση δεδομένων ANSI/AAMI EC57: 1998, σε δύο κατηγορίες προεπεξεργασίας: (α) την εξομάλυνση των χτύπων του σήματος με τη χρήση DWT + την ανίχνευση του συμπλέγματος QRS σε 200 δείγματα, και (β) την ανίχνευση του συμπλέγματος QRS σε 200 δείγματα. Ο κύκλος δείχνει την ύπαρξη μη-εξομαλυμένων χτύπων του σήματος.



Εικόνα 3.16: Οι πέντε τύποι τάξεων των χτύπων στην πρότυπη βάση δεδομένων ANSI/AAMI EC57: 1998, σε δύο κατηγορίες προεπεξεργασίας: (α) την εξομάλυνση των χτύπων του σήματος χρησιμοποιώντας τον DWT και (β) χτύποι του σήματος χωρίς τη χρήση DWT [155].

Τεχνικές εξαγωγής χαρακτηριστικών

Η αυτόματη αναγνώριση και ταξινόμηση του παλμού του ΗΚΓ εξαρτάται από διάφορα χαρακτηριστικά [175]. Τα σύνολα χαρακτηριστικών από το σύνολο δεδομένων του ΗΚΓ δημιουργήθηκαν με την εξαγωγή γραμμικών και μη γραμμικών χαρακτηριστικών. Στις επόμενες υποενότητες, συζητούνται οι γραμμικές και μη γραμμικές μέθοδοι.

A. Γραμμική μέθοδος βασισμένη στα wavelets και την ανάλυση κύριων συνιστωσών (principle component analysis - PCA)

Ο DWT χρησιμοποιείται για να εξαγάγει κρυμμένες πληροφορίες από το σήμα ΗΚΓ [167]. Σε αυτή τη μελέτη, εφαρμόστηκε μετά από την αποθρομβοποίηση του σήματος ΗΚΓ, την ανίχνευση του συμπλέγματος QRS και την κατάτμηση του ΗΚΓ. Η PCA εφαρμόστηκε τόσο στους συντελεστές υποζώνης της λεπτομέρειας του τρίτου επιπέδου όσο και της λεπτομέρειας του τέταρτου επιπέδου. Η λεπτομέρεια του τρίτου επιπέδου και η λεπτομέρεια του τέταρτου επιπέδου του DWT φαίνονται στην Εικόνα 3.17. Από κάθε μία από τις υπο-ζώνες, οι πρώτες έξι στήλες της μεταβλητής p θεωρήθηκαν ως τα έξι χαρακτηριστικά για την ταξινόμηση που ακολουθεί. Συνολικά, χρησιμοποιήθηκαν 12 χαρακτηριστικά (έξι από την καθεμία από τις δύο υπο-ζώνες) για την επερχόμενη ταξινόμηση προτύπων με τη χρήση ταξινομητών. Ο μετασχηματισμός wavelet εμφανίζει καλό χρονικό εντοπισμό τόσο στο πεδίο του χρόνου, όσο και στο πεδίο της συχνότητας. Παρέχει διάκριση μεταξύ δύο φυσιολογικών και μη φυσιολογικών τάξεων. Η τεχνική DWT αποσυνθέτει ένα σήμα σε συνιστώσες χαμηλής και υψηλής συχνότητας. Η συνιστώσα χαμηλής συχνότητας ονομάζεται προσέγγιση και η συνιστώσα υψηλής συχνότητας ονομάζεται λεπτομέρεια.

Χρησιμοποιώντας μια τράπεζα φίλτρων, ένα βαθυπερατό φίλτρο $h(n)$ χαμηλώνει το σήμα ΗΚΓ $x(n)$ κατά ένα συντελεστή δύο για να ληφθούν οι συντελεστές προσέγγισης στο επίπεδο ένα. Το υπερπερατό φίλτρο δίνεται από:

$$g(L - 1 - n) = (-1)^n h(n)$$

όπου L είναι το μήκος του φίλτρου. Ο συντελεστής λεπτομέρειας αποκτήθηκε με τη διέλευση του σήματος μέσω $g(n)$ και στη συνέχεια με δειγματοληψία με συντελεστή δύο. Το φιλτράρισμα DWT και η υπο-δειγματοληψία δίνονται από:


$$y_{low}(k) = \sum_n x(n)h(-n + 2k)$$

και

$$y_{high}(k) = \sum_n x(n)g(-n + 2k)$$

Μια λεπτομερής αναφορά δίνεται από τον Addison [176].

Μετά την εφαρμογή της προεπεξεργασίας, 200 δείγματα ως ένας ΗΚΓ χτύπος αποσυντέθηκαν σε προσεγγίσεις τέταρτου επιπέδου του εύρους συχνοτήτων 0-11.25 Hz χρησιμοποιώντας το Mayer's wavelet. Η λεπτομέρεια τέταρτου επιπέδου αποτελείται από την περιοχή συχνοτήτων 11.25-22.5 Hz.



Εικόνα 3.17: Λεπτομέρεια τρίτου επιπέδου (cd3) και λεπτομέρεια τέταρτου επιπέδου (cd4) του DWT για τους πέντε τύπους τάξεων χτύπων στην πρότυπη βάση δεδομένων ANSI/AAMI EC57: 1998 [155].

Η PCA είναι μία από τις κύριες τεχνικές γραμμικής μείωσης των διαστάσεων για την εξαγωγή αποτελεσματικών χαρακτηριστικών από μεγάλες διαστάσεις. Συνήθως η PCA γίνεται με την προβολή των δεδομένων στο χώρο των χαρακτηριστικών και την εύρεση της συσχέτισης μεταξύ αυτών των χαρακτηριστικών. Υπολογίζει τις κύριες συνιστώσες ως ποσοστό της συνολικής μεταβλητότητας των δεδομένων που χρησιμοποιήθηκαν για την επιλογή ενός αριθμού από αυτά. Η πρώτη κύρια συνιστώσα παρέχει το διάνυσμα της υψηλότερης

μεταβλητότητας (ασυσχέτιστη). Η δεύτερη κύρια συνιστώσα παρέχει το διάνυσμα για την επόμενη κατεύθυνση, ορθογώνια στην πρώτη κύρια συνιστώσα και ούτω καθεξής. Η PCA χρησιμοποιείται ευρέως για τη μείωση των διαστάσεων των χαρακτηριστικών για την ανίχνευση της αρρυθμίας στο ΗΚΓ [177], [178]. Ο υπολογισμός των κύριων συνιστωσών περιλαμβάνει τον υπολογισμό της μήτρας συνδιακύμανσης των δεδομένων, την αποσύνθεση των ιδιοτιμών, το διαχωρισμό (sorting) των ιδιοδιανυσμάτων κατά τη φθίνουσα σειρά των ιδιοτιμών και την προβολή των δεδομένων στη νέα βάση που ορίζεται από τις κύριες συνιστώσες, λαμβάνοντας το εσωτερικό γινόμενο των αρχικών σημάτων και των ταξινομημένων ιδιοδιανυσμάτων. Η PCA περιλαμβάνει τις ακόλουθες τρεις φάσεις:

Φάση 1: Υπολογισμός της μήτρας συνδιακύμανσης από τα δεδομένα, ως εξής:

$$C = (x - \tilde{x})(x - \tilde{x})^T$$

, όπου x είναι η μήτρα δεδομένων, και το \tilde{x} αντιπροσωπεύει το μέσο διάνυσμα του x .

Φάση 2: Υπολογισμός της μήτρας των ιδιοδιανυσμάτων V και τον διαγώνιο πίνακα των ιδιοτιμών D ως εξής:

$$V^{-1}CV = D$$

Φάση 3: Ταξινόμηση των ιδιοδιανυσμάτων στον πίνακα V κατά τη φθίνουσα σειρά των ιδιοτιμών στον D και προβολή των δεδομένων στις κατευθύνσεις αυτών των ιδιοδιανυσμάτων με τη λήψη του εσωτερικού γινομένου μεταξύ της μήτρας δεδομένων και της μήτρας των ταξινομημένων ιδιοκυμάτων ως εξής:

$$p = [V^T(x - \tilde{x})^T]^T$$

Η PCA εφαρμόστηκε και στους δύο συντελεστές υπο-ζώνης της λεπτομέρειας του τρίτου επιπέδου και της λεπτομέρειας του τέταρτου επιπέδου. Από κάθε μία από τις υπο-ζώνες, οι πρώτες έξι στήλες της μεταβλητής p θεωρήθηκαν ως τα έξι χαρακτηριστικά για την επακόλουθη ταξινόμηση. Συνολικά, 12 χαρακτηριστικά (έξι από καθεμιά από τις δύο υπο-ζώνες) χρησιμοποιήθηκαν για την επακόλουθη αναγνώριση προτύπων χρησιμοποιώντας τους ταξινομητές.

B. Μη γραμμική μέθοδος βασισμένη στην high order statistics και στην πολυπαραγοντική ανάλυση

Προκειμένου να επεξηγηθούν οι μη γραμμικές ιδιότητες στην προεπεξεργασία του ΗΚΓ, χρησιμοποιήθηκαν μόνο δύο στοιχεία, συγκεκριμένα η ανίχνευση συμπλέγματος QRS και η κατάτμηση του ΗΚΓ των σημάτων ΗΚΓ. Εφαρμόστηκαν HOS cumulant χαρακτηριστικά και τεχνικές μείωσης μη γραμμικών χαρακτηριστικών όπως η ICA.

Η τεχνική HOS χρησιμοποιείται για την ανάλυση μη γραμμικών, μη στατικών και μη-Γκαουσιανών σημάτων [169, 179]. Η μη γραμμικότητα της HOS έχει δημιουργηθεί από την Gaussian απόκλιση και τις αμοιβαίες σχέσεις της φάσης μεταξύ των διαφόρων συνιστωσών συχνότητας. Επιπλέον, η HOS αφαιρεί τον Gaussian θόρυβο. Καθώς η Gaussian διαδικασία κατηγοριοποιείται από τα

στατιστικά στοιχεία των πρώτων δύο τάξεων, τα στατιστικά στοιχεία πρώτης και δεύτερης τάξης δεν είναι σημαντικά για να αντιπροσωπεύσουν το μη γραμμικό μοντέλο. Ως εκ τούτου, στην ανάλυση αυτή χρησιμοποιούνται στατιστικά στοιχεία τρίτης και τέταρτης τάξης. Υποθέστε ότι το $x(n)$ είναι ένα σταθερό σήμα διακριτού χρόνου και οι στιγμές του είναι διαθέσιμες μέχρι την τάξη n . Έτσι, η στιγμιαία συνάρτηση n -οστής τάξης ορίζεται ως:

$$m_n^x(\tau_1, \tau_2, \dots, \tau_{n-1}) = E[x(n)x(n + \tau_1) \dots x(n + \tau_{n-1})]$$

Η στιγμιαία συνάρτηση εξαρτάται μόνο από τις χρονικές υστερήσεις $\tau_1, \tau_2, \dots, \tau_{n-1}, \tau_i = 0, \pm 1, \pm 2$, για όλα τα i . Η στιγμιαία δεύτερης τάξης $m_2^m(\tau_1)$, είναι η ακολουθία αυτοσυσχέτισης του $x(n)$ και υπολογίζεται ως εξής:

$$m_2^m(\tau_1) = E[x(n)x(n + \tau_1)]$$

Ενώ οι στιγμιαίες συναρτήσεις τρίτης και τέταρτης τάξης δίνονται από τις $m_3^x(\tau_1, \tau_2)$ και $m_4^x(\tau_1, \tau_2, \tau_3)$, αντίστοιχα. Η $E[\cdot]$ είναι ο τελεστής προσδοκώμενης αξίας (statistical expectation operator). Χρησιμοποιώντας τη στιγμιαία n -οστής τάξης, ο συντελεστής

$$C_n^x(\tau_1, \tau_2, \dots, \tau_{n-1}) = m_n^x(\tau_1, \tau_2, \dots, \tau_{n-1}) - m_n^G(\tau_1, \tau_2, \dots, \tau_{n-1})$$

$$C_1^x = m_1^x$$

$$C_2^x = m_2^x(\tau_1)$$

$$C_3^x = m_3^x(\tau_1, \tau_2)$$

$$C_4^x = m_4^x(\tau_1, \tau_2, \tau_3) - m_2^x(\tau_1)m_2^x(\tau_2 - \tau_3) - m_2^x(\tau_2)m_2^x(\tau_3 - \tau_1) - m_2^x(\tau_3)m_2^x(\tau_1 - \tau_2)$$

Μια μη γραμμική μέθοδος μείωσης των διαστάσεων, η ICA, είναι μια υπολογιστική στατιστική τεχνική που είναι πολύ αποτελεσματική στην αποκάλυψη των κρυμμένων παραγόντων που αποτελούν τα μικτά δείγματα τυχαίων μεταβλητών μετρήσεων [168, 180]. Η ICA περιλαμβάνει μια ανάλυση πολλών μεταβλητών για τη μείωση ενός σήματος πολλαπλών πηγών σε προστιθέμενες συνιστώσες. Μπορεί να αναπαρασταθεί μαθηματικά ως εξής:

$$X = A \cdot S$$

όπου το X είναι η μήτρα των n σημάτων που παρατηρούνται, $X = [x_1, x_2, \dots, x_n]^T$, S είναι η μήτρα των m υποκείμενων σημάτων, $S = [s_1, s_2, \dots, s_m]^T$ και A είναι η μήτρα ανάμιξης του $[n \times m]$. Ο αριθμός των ανεξάρτητων συνιστωσών (ICs) μπορεί να υπολογιστεί με την εύρεση μιας μήτρας μη-ανάμιξης που ονομάζεται w όπου:

$$S = w \cdot X$$

Για να υπολογίσουμε το w , τα δεδομένα πρέπει να είναι κεντραρισμένα και «λευκασμένα». Η πιο συνηθισμένη μέθοδος για τη λεύκανση¹ είναι η αποσύνθεση ιδιοτιμών του πίνακα συνδιακύμανσης:

$$EXX^T = EDE^T$$

όπου E είναι ο ορθογώνιος πίνακας των ιδιοδιανυσμάτων του EXX^T , και D είναι ο διαγώνιος πίνακας των ιδιοτιμών του [$D = \text{diag}(d_1, d_2, \dots, d_n)$]. Η λευκασμένη μήτρα X^- μπορεί να υπολογιστεί ως:

$$X^- = ED^{1/2}E^T X$$

Η λεύκανση μετασχηματίζει τον πίνακα μη-ανάμιξης για τον οποίο:

$$S^{\wedge} = w \cdot X = wED^{\frac{1}{2}}E^T X^- = w^- \cdot X$$

Αφού το w^- είναι ορθογώνιο, αυτό ελαχιστοποιεί τον αριθμό των παραμέτρων που πρέπει να υπολογισθούν. Γι' αυτό, ο πίνακας μη-ανάμιξης w :

$$w = w^- ED^{\frac{1}{2}}E^T$$

Συνεπώς, ο πίνακας A λαμβάνεται από την ακόλουθη εξίσωση:

$$A = (w^T w)^{-1} w^T$$

Συνδυασμός γραμμικών και μη γραμμικών μεθόδων

Τα σύνολα χαρακτηριστικών από το σύνολο δεδομένων του ΗΚΓ δημιουργήθηκαν συνδυάζοντας τα γραμμικά και μη γραμμικά χαρακτηριστικά. Το συνδυασμένο σύνολο χαρακτηριστικών αποτελείται από την προσάρτηση των δώδεκα PCA από τα χαρακτηριστικά DWT, δεκαέξι ICA χαρακτηριστικά και σωρευμένα (cumulative) χαρακτηριστικά HOS. Μπορεί να είναι λογικό να θεωρήσουμε ένα διάνυσμα χαρακτηριστικών να αποτελείται από ένα γραμμικό χαρακτηριστικό και ένα μη γραμμικό χαρακτηριστικό. Αυτό είναι:

$$Z_t = L_t + N_t \quad ,$$

όπου L_t είναι το γραμμικό χαρακτηριστικό και N_t το μη γραμμικό χαρακτηριστικό της συνδυαστικής μεθόδου.

¹ Η μέθοδος Independent Components Analysis (ICA) βρίσκει τη συσχέτιση μεταξύ των δεδομένων και αποσυσχετίζει τα δεδομένα μεγιστοποιώντας ή ελαχιστοποιώντας την πληροφορία αντίθεσης (contrast information). Η διαδικασία αυτή ονομάζεται «λεύκανση». Ο πίνακας λεύκανσης στη συνέχεια περιστρέφεται για να ελαχιστοποιήσει τη της προβολής και ως συνέπεια, να ανακτήσει στατιστικώς ανεξάρτητα δεδομένα. Η μέθοδος αυτή μπορεί να εφαρμοστεί σε συνδυασμό με την PCA και μάλιστα όταν οι δύο μέθοδοι συνδυάζονται, παρατηρείται ότι επιτυγχάνονται καλύτερα αποτελέσματα.

ΚΕΦΑΛΑΙΟ 4

Ταξινομητές - Μέθοδοι Ταξινόμησης

4.1 Εισαγωγή

Σε αυτό το κεφάλαιο, αναπτύσσεται το τελευταίο στάδιο ενός Συστήματος Υποβοήθησης της Διάγνωσης, που δεν είναι άλλο από το στάδιο της ταξινόμησης των βιοσημάτων. Μετά από τις μεθόδους εξαγωγής χαρακτηριστικών που παρουσιάστηκαν παραπάνω, είναι σειρά να εξηγηθεί και η λειτουργία των μεθόδων ταξινόμησης, οι οποίες με βάση τις τιμές των εξαγόμενων χαρακτηριστικών, κατατάσσουν το βιολογικό σήμα στην αντίστοιχη κλάση (τάξη), ολοκληρώνοντας έτσι το έργο της ταξινόμησης. Στη συνέχεια, λοιπόν, αναλύονται οι βασικότερες μέθοδοι ταξινόμησης που χρησιμοποιούνται σε εφαρμογές της Βιοϊατρικής και οι οποίες χωρίζονται σε τρεις μεγάλες κατηγορίες: τους *Μπεϋζιανούς ταξινομητές*, τους *γραμμικούς ταξινομητές* και τους *μη-γραμμικούς ταξινομητές*.

4.2 Μπεϋζιανοί Ταξινομητές (Bayesian Classifiers)

Οι Μπεϋζιανοί ταξινομητές ή ταξινομητές κατά Bayes βασίζονται, όπως είπαμε, στον υπολογισμό της εκ των υστέρων πιθανότητας όπως υπολογίζεται από τον κανόνα του Bayes και μοντελοποιούν την πιθανοτική σχέση μεταξύ του συνόλου χαρακτηριστικών και της κατηγορίας. Συγκεκριμένα, δοθέντος των τιμών των χαρακτηριστικών ενός νέου παραδείγματος, στόχος του Μπεϋζιανού ταξινομητή είναι να υπολογίσει τις υπό συνθήκη πιθανότητες για όλες τις πιθανές κατηγορίες. Ο Μπεϋζιανός ταξινομητής ελαχιστοποιεί την αναμενόμενη πιθανότητα σφάλματος (error rate) και υπό αυτήν την έννοια είναι βέλτιστος [2].

Μπεϋζιανή Θεωρία Απόφασης

Με δεδομένο ένα πρόβλημα ταξινόμησης M τάξεων, $\omega_1, \omega_2, \dots, \omega_M$ και ένα άγνωστο δείγμα με διάνυσμα χαρακτηριστικών x , σχηματίζονται M υπό συνθήκη πιθανότητες οι οποίες ονομάζονται *εκ των υστέρων πιθανότητες* (a posteriori probabilities). Κάθε $P(\omega_i|x)$ αναπαριστά την πιθανότητα ένα άγνωστο δείγμα να ανήκει στην τάξη ω_i , δεδομένου του γεγονότος ότι το διάνυσμα χαρακτηριστικών του δείγματος παίρνει την τιμή x .

Θεωρώντας ένα πρόβλημα ταξινόμησης με δύο τάξεις, έστω ω_1 και ω_2 οι δύο τάξεις στις οποίες μπορούν να ανήκουν τα δείγματα. Γίνεται η υπόθεση ότι οι μη δεσμευμένες, εκ των προτέρων πιθανότητες να ανήκει ένα δείγμα σε μία τάξη, $P(\omega_1)$ και $P(\omega_2)$, είναι γνωστές. Αν δεν είναι γνωστές, μπορεί εύκολα να προκύψει μια εκτίμησή τους από τα διαθέσιμα δείγματα εκπαίδευσης, αφού αν N είναι ο συνολικός αριθμός των δειγμάτων εκπαίδευσης και N_1, N_2 από αυτά ανήκουν στις τάξεις ω_1, ω_2 αντίστοιχα, τότε $P(\omega_1) \approx N_1/N$ και $P(\omega_2) \approx N_2/N$ [2], [183].

Εκτός από τις εκ των προτέρων πιθανότητες, επίσης θεωρούνται γνωστές οι συναρτήσεις πυκνότητας υπό συνθήκης πιθανότητας, $p(x|\omega_i)$, $i=1, 2, \dots, M$, οι οποίες περιγράφουν την κατανομή των διανυσμάτων χαρακτηριστικών σε κάθε μια από τις τάξεις. Αν δεν είναι γνωστές μπορούν να υπολογιστούν από τα διαθέσιμα δεδομένα. Η συνάρτηση πυκνότητας πιθανότητας $p(x|\omega_i)$, πολλές φορές αναφέρεται και σε

συνάρτηση πιθανοφάνειας (likelihood function) των ω_i ως προς \mathbf{x} . Στο παραπάνω έχει γίνει η υπόθεση ότι τα διανύσματα χαρακτηριστικών μπορούν να πάρουν οποιαδήποτε τιμή στον l -διάστατο διανυσματικό χώρο χαρακτηριστικών. Αν τα διανύσματα χαρακτηριστικών παίρνουν διακριτές τιμές, οι συναρτήσεις $p(\mathbf{x}|\omega_i)$ γίνονται πιθανότητες και σημειώνονται ως $P(\mathbf{x}|\omega_i)$ [2], [183].

Ο κανόνας του Bayes χρησιμοποιεί τις παραπάνω πιθανότητες και είναι ο εξής [2], [183]:

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

όπου $p(\mathbf{x})$ η συνάρτηση πυκνότητας πιθανότητας για την οποία ισχύει:

$$p(\mathbf{x}) = \sum_{i=1}^2 p(\mathbf{x}|\omega_i)P(\omega_i)$$

Επομένως, ο κανόνας ταξινόμησης του Bayes μπορεί να εκφραστεί ως εξής:


$$\begin{aligned} \text{Αν } P(\omega_1 | \mathbf{x}) > P(\omega_2 | \mathbf{x}), \text{ το } \mathbf{x} \text{ ταξινομείται στην } \omega_1 \\ \text{Αν } P(\omega_1 | \mathbf{x}) < P(\omega_2 | \mathbf{x}), \text{ το } \mathbf{x} \text{ ταξινομείται στην } \omega_2 \end{aligned}$$

Η περίπτωση της ισότητας είναι τετριμμένη και το δείγμα μπορεί να ταξινομηθεί σε οποιαδήποτε από τις δύο τάξεις. Επομένως θα πρέπει να γίνει αναζήτηση της μέγιστης τιμής των συναρτήσεων πυκνότητας της υπό συνθήκης πιθανότητας υπολογισμένη στο σημείο \mathbf{x} . Η Εικόνα 4.1 παρουσιάζει ένα δείγμα δύο ισοπίθανων τάξεων και δείχνει τις δύο συναρτήσεις $p(\mathbf{x}|\omega_i)$, $i=1, 2$ για διαφορετικές τιμές του \mathbf{x} για την απλή περίπτωση του ενός χαρακτηριστικού ($l=1$). Η διακεκομμένη γραμμή x_0 ορίζει ένα κατώφλι διαχωρισμού, το οποίο χωρίζει το διανυσματικό χώρο χαρακτηριστικών σε δύο περιοχές, την R_1 και την R_2 . Σύμφωνα με τον κανόνα ταξινόμησης του Bayes, για όλες τις τιμές του \mathbf{x} στην περιοχή R_1 ο ταξινομητής επιλέγει την τάξη ω_1 και για τις τιμές του στην περιοχή R_2 επιλέγει την τάξη ω_2 . Παρόλα αυτά, από το διάγραμμα αυτό είναι προφανές ότι τα σφάλματα ταξινόμησης δεν είναι δυνατό να αποφευχθούν [2], [183].

Υπάρχει μια πεπερασμένη πιθανότητα για ένα διάνυσμα \mathbf{x} να βρίσκεται στην περιοχή R_2 αλλά να ανήκει στην τάξη ω_1 , οπότε σε αυτήν την περίπτωση θα υπάρξει σφάλμα ταξινόμησης. Το ίδιο θα συμβεί και για σημεία της περιοχής R_1 με τάξη ω_2 . Η συνολική πιθανότητα σφάλματος ταξινόμησης P_e στην περίπτωση δύο ισοπίθανων τάξεων δίνεται από την εξίσωση:

$$P_e = \frac{1}{2} \int_{-\infty}^{x_0} p(\mathbf{x}|\omega_2)dx + \frac{1}{2} \int_{x_0}^{+\infty} p(\mathbf{x}|\omega_1)dx$$

το οποίο ισούται με τη συνολική γραμμοσκιασμένη περιοχή στην Εικόνα 4.1



Εικόνα 4.1: Συναρτήσεις πυκνότητας υπό συνθήκης πιθανότητας για δύο τάξεις ω_1 και ω_2 και οι δύο περιοχές R_1 και R_2 που σχηματίζονται με βάση το κατώφλι x_0 [2], [183].

4.2.1 Απλοϊκός Μπεϋζιανός Ταξινομητής (Naive Bayes Classifier - NBC)

Μπορεί ο Μπεϋζιανός ταξινομητής να είναι, όπως είπαμε, βέλτιστος υπό μία έννοια, καθώς όμως οι ακριβείς ταξινομητές είναι δύσκολο να εξασφαλιστούν (εκτός αν τα δεδομένα εκπαίδευσης καλύπτουν πλήρως τον χώρο των χαρακτηριστικών και δεν υπάρχει καθόλου θόρυβος), συγκεκριμένες προσεγγίσεις και υποθέσεις πρέπει να χρησιμοποιηθούν κατά τον υπολογισμό των υπό συνθήκη πιθανοτήτων [2].

Ο ταξινομητής Naive Bayes υποθέτει την υπό συνθήκη ανεξαρτησία των χαρακτηριστικών της δεδομένης κατηγορίας. Αυτή η ισχυρή υπόθεση συνήθως εξασφαλίζει αξιόπιστες εκτιμήσεις των υπό συνθήκη πιθανοτήτων οι οποίες απαιτούνται για ταξινόμηση, ακόμα και από πολύ μικρά σύνολα δεδομένων [2].

Οι υλοποιήσεις του ταξινομητή Naive Bayes συχνά υποθέτουν ότι χρησιμοποιούνται μόνο διακριτά χαρακτηριστικά, επομένως τα συνεχή χαρακτηριστικά πρέπει να διακριτοποιηθούν εκ των προτέρων [2]. Ο Απλοϊκός Μπεϋζιανός Ταξινομητής είναι ένας τρόπος αντιμετώπισης της ανάγκης για μεγάλο πλήθος δεδομένων εκπαίδευσης. Εκμεταλλεύεται περισσότερο αποδοτικά τα διαθέσιμα δεδομένα εκπαίδευσης, όμως αποτελεί μια ακραία θεώρηση καθώς υποθέτει ότι όλα τα χαρακτηριστικά είναι εντελώς ανεξάρτητα μεταξύ τους [183].

Μια γενίκευση του ταξινομητή Naive Bayes αποτελούν τα Μπεϋζιανά δίκτυα πεποίθησης (Bayesian belief networks). Η συγκεκριμένη μέθοδος χρησιμοποιεί άκυκλους γράφους για να μοντελοποιήσει τις εξαρτήσεις ανάμεσα στα χαρακτηριστικά των παραδειγμάτων και τις τάξεις. Υποθέτει έμμεσα την υπό συνθήκη ανεξαρτησία μεταξύ κόμβων (χαρακτηριστικών) οι οποίοι δεν συνδέονται απευθείας. Η τοπολογία ενός Μπεϋζιανού δικτύου μπορεί να δίνεται εκ των προτέρων (ως τμήμα του υπόβαθρου των γνώσεων για το πρόβλημα), ή μπορεί να κατασκευαστεί από τα δεδομένα. Οι υπό συνθήκη εξαρτήσεις υπολογίζονται και αυτές από τα δεδομένα, ενώ η τοπολογία άκυκλου γράφου εξασφαλίζει τον αποτελεσματικό υπολογισμό των υπό συνθήκη πιθανοτήτων για όλες τις κατηγορίες. Τα Μπεϋζιανά δίκτυα πεποίθησης μπορούν να χρησιμοποιηθούν για να μοντελοποιήσουν κατανομές πιθανότητας [2].

4.3 Γραμμικοί Ταξινομητές (Linear Classifiers)

Σε αυτήν την παράγραφο, θα μελετήσουμε τους γραμμικούς ταξινομητές και θα αναλύσουμε τη λειτουργία των δύο πιο αντιπροσωπευτικών αλγορίθμων αυτής της κατηγορίας, του αλγορίθμου Perceptron και της Γραμμικής Διακριτικής Ανάλυσης (LDA).

Οι γραμμικοί ταξινομητές είναι αλγόριθμοι που χρησιμοποιούν γραμμικές συναρτήσεις για να διαχωρίζουν τις τάξεις και αποτελούν τους δημοφιλέστερους αλγόριθμους ταξινόμησης για BCI εφαρμογές. Το βασικό πλεονέκτημα των γραμμικών ταξινομητών είναι η απλότητά τους και η υπολογιστική τους ελκυστικότητα. Καθ' όλη τη διάρκεια αυτής της παραγράφου θα θεωρούμε ότι όλα τα διανύσματα χαρακτηριστικών από τις διαθέσιμες τάξεις, μπορούν να ταξινομηθούν σωστά χρησιμοποιώντας ένα γραμμικό ταξινομητή [2].

Ας επικεντρωθούμε στο πρόβλημα ταξινόμησης δύο τάξεων και ας θεωρήσουμε γραμμικές διακριτικές συναρτήσεις. Τότε η αντίστοιχη αποφασιστική υπερ-επιφάνεια στον l -διάστατο χώρο χαρακτηριστικών είναι ένα υπερεπίπεδο [2]:

$$g(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + w_0 = 0$$

όπου το $\mathbf{w} = [w_1, w_2, \dots, w_l]^T$ είναι γνωστό ως το διάνυσμα βαρών και το w_0 ως το κατώφλι (threshold). Αν $\mathbf{x}_1, \mathbf{x}_2$ είναι δύο σημεία στο αποφασιστικό υπερεπίπεδο, τότε ισχύει η παρακάτω σχέση [2]:

$$\mathbf{0} = \mathbf{w}^T \mathbf{x}_1 + w_0 = \mathbf{w}^T \mathbf{x}_2 + w_0 \quad \Rightarrow$$

$$\mathbf{w}^T (\mathbf{x}_1 - \mathbf{x}_2) = 0$$

Αφού το διάνυσμα διαφοράς $\mathbf{x}_1 - \mathbf{x}_2$ προφανώς κείται στο αποφασιστικό υπερεπίπεδο (για οποιαδήποτε $\mathbf{x}_1, \mathbf{x}_2$), φαίνεται από την παραπάνω εξίσωση ότι το διάνυσμα \mathbf{w} είναι ορθογώνιο στο αποφασιστικό υπερεπίπεδο.


Το Σχήμα 4.1 δείχνει την αντίστοιχη γεωμετρία (για $w_1 > 0$, $w_2 > 0$, $w_0 < 0$). Είναι εύκολο να δούμε ότι οι ποσότητες που εισάγονται στο σχήμα, δίνονται από τις σχέσεις:

$$d = \frac{|w_0|}{\sqrt{w_1^2 + w_2^2}}$$

και

$$z = \frac{|g(\mathbf{x})|}{\sqrt{w_1^2 + w_2^2}}$$

Με άλλα λόγια, το $|g(\mathbf{x})|$ είναι ένα μέτρο της Ευκλείδειας απόστασης του σημείου \mathbf{x} από το αποφασιστικό υπερεπίπεδο. Στη μια πλευρά του επιπέδου το $g(\mathbf{x})$ παίρνει θετικές τιμές και στην άλλη αρνητικές. Στην ειδική περίπτωση που το $w_0 = 0$, το υπερεπίπεδο περνάει από την αρχή των αξόνων.



Σχήμα 4.1: Γεωμετρία της αποφασιστικής γραμμής. Στη μια πλευρά της γραμμής είναι $g(x) > 0$ (+) και στην άλλη $g(x) < 0$ (-) [2].

4.3.1 Ο Αλγόριθμος Perceptron

Το κύριο μέλημά μας, εδώ, είναι ο υπολογισμός των άγνωστων παραμέτρων (δηλ. των βαρών) $w_i, i = 0, \dots, l$ που ορίζουν το αποφασιστικό υπερεπίπεδο διαχωρισμού. Θα προσεγγίσουμε αυτό το πρόβλημα σαν ένα τυπικό πρόβλημα βελτιστοποίησης, υιοθετώντας μια κατάλληλη συνάρτηση κόστους και έναν αλγόριθμο που να την βελτιστοποιεί.

Η συνάρτηση κόστους ορίζεται ως $J(\mathbf{w}) = \sum_{x \in Y} (\delta_x \mathbf{w}^T \mathbf{x})$, όπου Y είναι το υποσύνολο των διανυσμάτων εκπαίδευσης που ταξινομούνται λανθασμένα από το υπερεπίπεδο το οποίο ορίζεται από το διάνυσμα βαρών \mathbf{w} . Η μεταβλητή δ_x επιλέγεται ώστε $\delta_x = -1$ αν $x \in \omega_1$ και $\delta_x = 1$ αν $x \in \omega_2$. Όταν η συνάρτηση κόστους πάρει την ελάχιστη τιμή της, δηλ. μηδέν, τότε η λύση έχει επιτευχθεί, αφού όλα τα διανύσματα εκπαίδευσης έχουν ταξινομηθεί σωστά.

Για να λάβουμε τον αλγόριθμο για την ελαχιστοποίηση της συνάρτησης κόστους, υιοθετούμε μια επαναληπτική διαδικασία ως εξής:

$$\mathbf{w}(t+1) = \mathbf{w}(t) - \rho_t \frac{\partial J(\mathbf{w})}{\partial \mathbf{w}} \Big|_{\mathbf{w}=\mathbf{w}(t)}$$

όπου είναι η προσέγγιση του διανύσματος βαρών στο t -οστό βήμα της επανάληψης και ρ_t είναι μια ακολουθία θετικών πραγματικών αριθμών. Από τον ορισμό της συνάρτησης κόστους και στα σημεία όπου ισχύει η συνέχεια, παίρνουμε $\frac{\partial J(\mathbf{w})}{\partial \mathbf{w}} = \sum_{x \in Y} (\delta_x \mathbf{x})$ και αντικαθιστώντας αυτή τη σχέση στην επαναληπτική διαδικασία, έχουμε:


$$\mathbf{w}(t+1) = \mathbf{w}(t) - \rho_t \sum_{x \in Y} (\delta_x \mathbf{x})$$

Ο αλγόριθμος αυτός, είναι γνωστός ως ο *αλγόριθμος perceptron* και είναι αρκετά απλός στη δομή του. Ο αλγόριθμος αρχικοποιείται από ένα αυθαίρετο διάνυσμα βάρους $\mathbf{w}(0)$, και το διάνυσμα διόρθωσης $\sum_{\mathbf{x} \in Y} \delta_{\mathbf{x}} \mathbf{x}$ σχηματίζεται χρησιμοποιώντας τα χαρακτηριστικά που έχουν ταξινομηθεί λανθασμένα. Στη συνέχεια το διάνυσμα βάρους διορθώνεται σύμφωνα με τον προηγούμενο κανόνα. Αυτό επαναλαμβάνεται μέχρι ο αλγόριθμος να συγκλίνει σε μια λύση, δηλαδή όλα τα χαρακτηριστικά να ταξινομούνται σωστά. Ένας ψευδοκώδικας για τον αλγόριθμο perceptron δίνεται παρακάτω [2].


The Perceptron Algorithm

- Choose $\mathbf{w}(0)$ randomly
- Choose ρ_0
- $t = 0$
- Repeat
 - $Y = \emptyset$
 - For $i = 1$ to N
 - If $\delta_{\mathbf{x}_i} \mathbf{w}(t)^T \mathbf{x}_i \geq 0$ then $Y = Y \cup \{\mathbf{x}_i\}$
 - End (For)
 - $\mathbf{w}(t + 1) = \mathbf{w}(t) - \rho_t \sum_{\mathbf{x} \in Y} \delta_{\mathbf{x}} \mathbf{x}$
 - Adjust ρ_t
 - $t = t + 1$
- Until $Y = \emptyset$

Το Σχήμα 4.2 παρέχει μια γεωμετρική ερμηνεία του αλγορίθμου, ενώ στο Σχήμα 4.3 παρουσιάζεται γραφικά, ένα παράδειγμα χρήσης του αλγορίθμου. Έχει υποτεθεί ότι στο βήμα t υπάρχει μόνο ένα λανθασμένα ταξινομημένο δείγμα, \mathbf{x} , και $\rho_t = 1$. Ο αλγόριθμος perceptron διορθώνει το διάνυσμα βάρους προς την κατεύθυνση \mathbf{x} . Η επίδρασή του είναι να μετατρέψει το αντίστοιχο υπερεπίπεδο έτσι ώστε το \mathbf{x} να ταξινομηθεί στη σωστή τάξη ω_t . Για να επιτευχθεί αυτό, μπορεί να χρειαστούν περισσότερα από ένα βήματα επανάληψης, ανάλογα με την τιμή (ή τις τιμές) του ρ_t . Αναμφίβολα, αυτή η ακολουθία είναι κρίσιμη για τη σύγκλιση. Ο αλγόριθμος perceptron συγκλίνει σε μια λύση σε ένα πεπερασμένο αριθμό επαναληπτικών βημάτων, υπό την προϋπόθεση ότι η ακολουθία ρ_t είναι κατάλληλα επιλεγμένη. Η λύση δεν είναι μοναδική, επειδή υπάρχουν περισσότερα από ένα υπερεπίπεδα που να χωρίζουν δύο γραμμικά διαχωρίσιμες κλάσεις [2].



Σχήμα 4.2: Γεωμετρική ερμηνεία του αλγόριθμου Perceptron. Η διόρθωση του διανύσματος βάρους είναι προς την κατεύθυνση του \mathbf{x} ώστε να μετατρέψει το υπερεπίπεδο για να συμπεριλάβει το \mathbf{x} στη σωστή τάξη [2].



Σχήμα 4.3: Ένα παράδειγμα του αλγόριθμου perceptron. Μετά τη διόρθωση του διανύσματος βάρους, το υπερεπίπεδο μετατοπίζεται από την αρχική του θέση (διακεκομμένη γραμμή) στη νέα του θέση (κανονική γραμμή) και όλα τα σημεία ταξινομούνται σωστά [2].

Ο αλγόριθμος που παρουσιάσαμε είναι απλά μια μορφή από ένα μεγάλο αριθμό παραλλαγών που έχουν προταθεί για την εκπαίδευση ενός γραμμικού ταξινομητή στην περίπτωση γραμμικά διαχωριζόμενων τάξεων.

Ο αλγόριθμος perceptron προτάθηκε αρχικά από τον Rosenblatt στα τέλη της δεκαετίας του 1950. Ο αλγόριθμος αναπτύχθηκε για την εκπαίδευση του *perceptron*, της βασικής μονάδας που χρησιμοποιείται για τη μοντελοποίηση των νευρώνων του


εγκεφάλου. Αυτό θεωρήθηκε η βάση για την ανάπτυξη ισχυρών μοντέλων για μηχανική μάθηση [184, 185].

The Perceptron

Μόλις ο αλγόριθμος perceptron έχει συγκλίνει σε ένα διάνυσμα βαρών \mathbf{w} και σε ένα κατώφλι w_0 , ο επόμενος στόχος μας είναι η ταξινόμηση ενός άγνωστου διανύσματος χαρακτηριστικών σε οποιαδήποτε από τις δύο διαθέσιμες τάξεις. Η ταξινόμηση επιτυγχάνεται μέσω του απλού κανόνα [2]:

$$\begin{aligned} \text{Αν } \mathbf{w}^T \mathbf{x} + w_0 > 0, & \quad \text{ταξινόμησησε το } \mathbf{x} \text{ στην τάξη } \omega_1 \\ \text{Αν } \mathbf{w}^T \mathbf{x} + w_0 < 0, & \quad \text{ταξινόμησησε το } \mathbf{x} \text{ στην τάξη } \omega_2 \end{aligned}$$

Μια βασική μονάδα δικτύου που υλοποιεί αυτή τη λειτουργία φαίνεται στο Σχήμα 4.4(a):



Σχήμα 4.4: Το βασικό μοντέλο perceptron. (a) Ένας γραμμικός συνδυαστής ακολουθείται από τη συνάρτηση ενεργοποίησης. (b) Ο συνδυαστής και η συνάρτηση ενεργοποίησης συγχωνεύονται [2].

Τα στοιχεία του διανύσματος χαρακτηριστικών x_1, x_2, \dots, x_l εφαρμόζονται στους κόμβους εισόδου του δικτύου. Στη συνέχεια, το κάθε ένα πολλαπλασιάζεται με τα αντίστοιχα βάρη w_i , με $i = 1, 2, \dots, l$. Αυτά είναι γνωστά ως συναπτικά βάρη ή απλά συνάψεις. Τα προϊόντα αθροίζονται μαζί με την τιμή κατωφλίου w_0 . Στη συνέχεια, το αποτέλεσμα περνά από μια μη γραμμική συσκευή, η οποία υλοποιεί τη λεγόμενη συνάρτηση ενεργοποίησης. Μια κοινή επιλογή είναι ένας σκληρός περιοριστής. Δηλαδή, η $f(\cdot)$ είναι η βηματική συνάρτηση [$f(x) = -1$ εάν $x < 0$ και $f(x) = 1$ αν $x > 0$]. Το αντίστοιχο διάνυσμα χαρακτηριστικών ταξινομείται σε μία από τις τάξεις ανάλογα με το σήμα της εξόδου. Εκτός από το 1 και το -1, είναι επίσης δυνατές και άλλες τιμές (ετικέτες τάξης) για τον σκληρό περιοριστή [2]. Μια άλλη δημοφιλής επιλογή είναι η 1 και 0, και επιτυγχάνεται με την κατάλληλη επιλογή των δύο επιπέδων της βηματικής συνάρτησης. Αυτό το βασικό δίκτυο είναι γνωστό ως *perceptron* ή *neuron* (νευρώνας). Τα perceptrons είναι απλά παραδείγματα των αποκαλούμενων μηχανών μάθησης, δηλαδή δομών των οποίων οι ελεύθερες παράμετροι ενημερώνονται από έναν αλγόριθμο μάθησης, όπως ο αλγόριθμος perceptron, προκειμένου να «μάθουν» μια συγκεκριμένη εργασία, βασισμένη σε ένα σύνολο δεδομένων εκπαίδευσης. Το Σχήμα 4.4(b) είναι ένα απλοποιημένο γράφημα του νευρώνα όπου ο αθροιστής και η μη γραμμική συσκευή έχουν συγχωνευθεί για τη συμβολική απλοποίηση [2].

4.3.2 Γραμμική Διακριτική Ανάλυση

Η Γραμμική Διακριτική Ανάλυση (LDA: Linear Discriminant Analysis ή Fisher's LDA [153]), είναι μια ευεργετική μέθοδος για τη μείωση της διαστασιμότητας και την ταξινόμηση προτύπων με το μετασχηματισμό τους από έναν πολυδιάστατο σε ένα μονοδιάστατο χώρο, στον οποίο οι τάξεις είναι γραμμικώς διαχωρίσιμες.

Ο στόχος της LDA είναι να χρησιμοποιεί υπερεπίπεδα για να διαχωρίζει τα δεδομένα που εκπροσωπούν τις διάφορες κλάσεις. Για ένα πρόβλημα 2 κλάσεων, λοιπόν, η κλάση ενός διανύσματος χαρακτηριστικών θα εξαρτάται από την πλευρά του υπερεπίπεδου στην οποία θα βρίσκεται το διάνυσμα. Η LDA υποθέτει κανονική κατανομή των δεδομένων, με ίσες μήτρες συνδιασποράς και για τις δύο κλάσεις. Το διαχωριστικό υπερεπίπεδο βρίσκεται εντοπίζοντας την προβολή που μεγιστοποιεί την απόσταση μεταξύ των μέσων τιμών των δύο κλάσεων και ελαχιστοποιεί τη διασπορά στο εσωτερικό τους [183].

Με απλά λόγια, συνίσταται στην εύρεση του γραμμικού συνδυασμού w που διαχωρίζει καλύτερα τις τάξεις, πράγμα που συνεπάγεται και σε αυτήν την περίπτωση τη δημιουργία μιας επιφάνειας απόφασης στη μορφή $w^T w + w_o = 0$, για μια σταθερή τιμή κατωφλίου w_o . Το κατώφλι (Threshold - Thr) ορίζεται ως:

$$Thr = \frac{N_1\mu_1 + N_2\mu_2}{N_1 + N_2}$$

Όπου N_1 και N_2 υποδηλώνουν τους αριθμούς των δύο δειγμάτων στην εξίσωση.

Για την επίλυση ενός προβλήματος N κλάσεων ($N > 2$) χρησιμοποιούνται περισσότερα υπερεπίπεδα και η στρατηγική που ακολουθείται έχει ως στόχο το διαχωρισμό της κάθε κλάσης από τις υπόλοιπες. Η τεχνική LDA έχει χαμηλές υπολογιστικές απαιτήσεις, οπότε κρίνεται κατάλληλη προς χρήση σε on-line BCI συστήματα. Ο ταξινομητής παρέχει γρήγορη πρόβλεψη, χαμηλή χρήση μνήμης, καλή σταθερότητα, είναι απλός στη χρήση και γενικά προσφέρει καλά αποτελέσματα. Γι' αυτό προτιμάται ως εργαλείο για την εξαγωγή χαρακτηριστικών. Έχει εφαρμοστεί επιτυχώς σε πολλά BCI συστήματα, όπως για παράδειγμα σε BCI εικονικής κίνησης, συλλαβιστές P300, ασύγχρονα και πολλών κλάσεων BCI [183]. Το σημαντικό μειονέκτημα της LDA είναι η γραμμικότητα που μπορεί να οδηγήσει σε χαμηλής απόδοσης αποτελέσματα σε σύνθετα, μη γραμμικά, HEG δεδομένα. Η κανονικοποιημένη LDA ή Fisher (RFLDA) έχει επίσης εφαρμοστεί κατά το σχεδιασμό συστημάτων BCI. Αυτός ο ταξινομητής εισάγει μία παράμετρο κανονικοποίησης C που μπορεί να επιτρέπει ή να αποτρέπει σφάλματα ταξινόμησης στο σύνολο δεδομένων εκπαίδευσης. Ο ταξινομητής που προκύπτει μπορεί να αντιμετωπίσει τις ακραίες τιμές και να επιτύχει καλύτερες δυνατότητες γενίκευσης. Καθώς οι ακραίες τιμές είναι ένα συχνό φαινόμενο στα HEG δεδομένα, η κανονικοποιημένη αυτή μορφή της LDA μπορεί να δώσει καλύτερα αποτελέσματα για ένα BCI [183].

4.4 Μη γραμμικοί Ταξινομητές (Non-linear Classifiers)

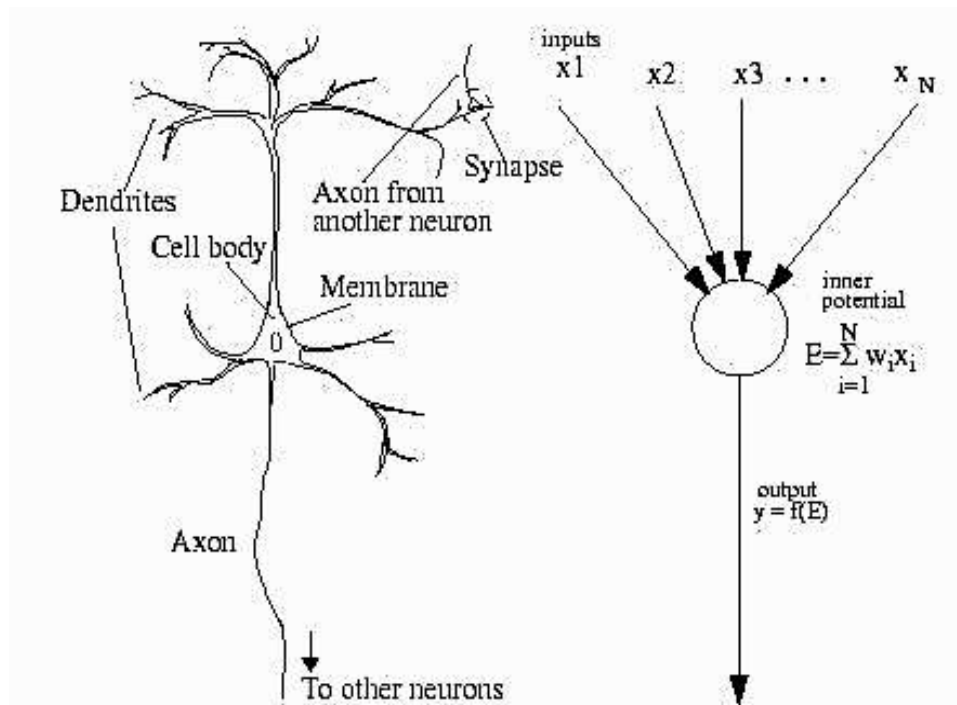
4.4.1 Τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Networks - ANN)

Εισαγωγή

Μια από τις πιο δημοφιλείς μεθόδους ταξινόμησης με επίβλεψη βασίζεται στη χρήση τεχνητών νευρωνικών δικτύων. Η βασική ιδέα πίσω από την ανάπτυξη των Τεχνητών Νευρωνικών Δικτύων ή απλά Νευρωνικών Δικτύων (ΝΔ), είναι η προσπάθεια προσομοίωσης του τρόπου λειτουργίας του ανθρώπινου εγκεφάλου και γενικότερα του νευρικού συστήματος, για τη δημιουργία μηχανών που να έχουν ένα ποσοστό ευφυΐας. [3, 5].

Τα ΝΔ είναι παράλληλοι καταναμημένοι επεξεργαστές αποτελούμενοι από απλές μονάδες επεξεργασίας, που έχουν τη δυνατότητα αποθήκευσης «γνώσης» προερχόμενης από την εμπειρία μέσω μιας διαδικασίας εκπαίδευσης [3, 6, 186]. Τα Τεχνητά Νευρωνικά Δίκτυα (ΤΝΔ) αποτελούν ισχυρά εργαλεία για τη διαδικασία μοντελοποίησης ειδικά σε περιπτώσεις που η σχέση μεταξύ των υποκείμενων δεδομένων δεν είναι γνωστή και έχουν την ικανότητα να αναγνωρίζουν και να θυμούνται συσχετισμένα πρότυπα ανάμεσα σε ένα σύνολο δεδομένων εισόδου και συγκεκριμένες αντίστοιχες τιμές. Μετά τη διαδικασία της εκπαίδευσης, τα νευρωνικά δίκτυα μπορούν να χρησιμοποιηθούν για να προβλέψουν το αποτέλεσμα ενός νέου ανεξάρτητου συνόλου δεδομένων. Καθώς νευρωνικά δίκτυα μιμούνται τη διαδικασία εκπαίδευσης του ανθρώπινου εγκεφάλου, όπως προαναφέραμε, μπορούν να επεξεργαστούν προβλήματα που περιλαμβάνουν μη γραμμικά και σύνθετα δεδομένα ακόμα και αν τα δεδομένα είναι ανακριβή ή έχουν θόρυβο [30].

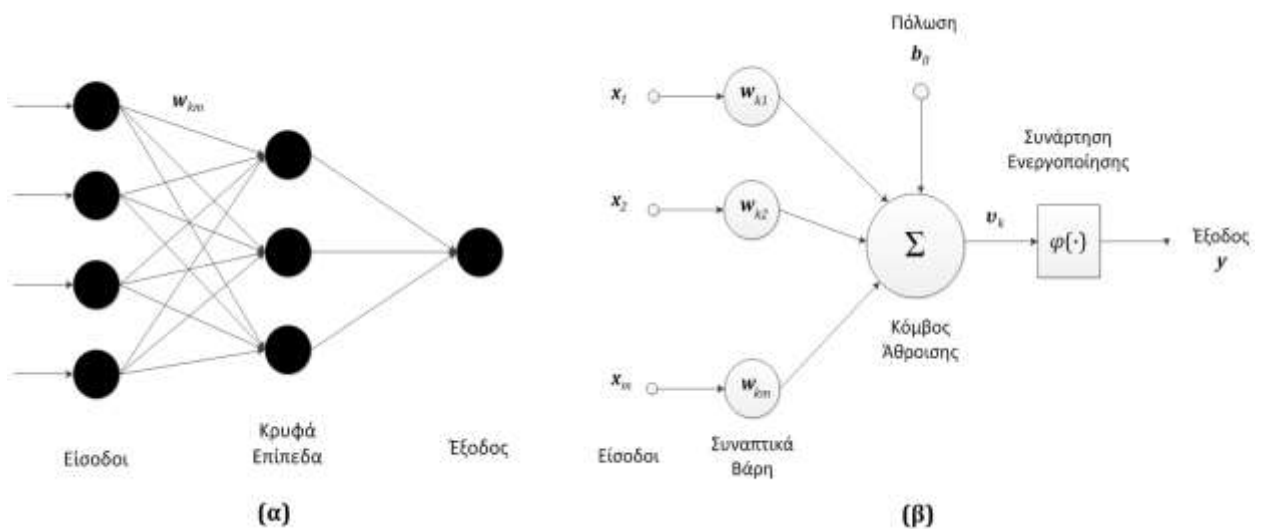
Στα πρότυπα, λοιπόν, της οργάνωσης του εγκεφάλου και για να επιτύχουν υψηλή απόδοση, τα ΤΝΔ αποτελούνται από διασυνδέσεις απλούστερων στοιχειωδών υπολογιστικών κυττάρων, τους νευρώνες (neurons). Κάθε νευρώνας έχει έναν συγκεκριμένο αριθμό εισόδων και εξόδων και συνδέεται κατάλληλα με τους άλλους νευρώνες μέσω συναπτικών συνδέσεων, στις οποίες αναθέτονται κάποια βάρη ανάλογα με την ισχύ τους. Οι συνδέσεις μπορεί να είναι διεγερτικές ή ανασταλτικές με τρόπο ώστε να ενεργοποιείται κάθε φορά ένας νευρώνας από ένα σύνολο [3] [183, 187]. Οι τιμές των βαρών των συνδέσεων αποτελούν την γνώση που είναι αποθηκευμένη στο δίκτυο και καθορίζουν την λειτουργικότητα του νευρώνα [5]. Στην Εικόνα 4.2 παρουσιάζονται σε αντιστοιχία η δομή ενός βιολογικού και ενός τεχνητού νευρώνα.



Εικόνα 4.2: Σχηματική αναπαράσταση της δομής ενός βιολογικού νευρώνα (αριστερά) και ενός τεχνητού νευρώνα (δεξιά).

Δομή Τεχνητών Νευρωνικών Δικτύων

Σε αυτό το σημείο θα σταθούμε για λίγο στην εσωτερική δομή ενός ΤΝΔ. Ο κάθε νευρώνας k του ΝΔ είναι μια *σύναψη* των εισόδων του. Όταν μιλάμε για σύναψη αναφερόμαστε στην άθροιση των γινομένων των x_i εισόδων, με $i=1, \dots, m$ με συντελεστές βάρους w_{ki} . Ένας τυπικός τεχνητός νευρώνας φαίνεται στο Σχήμα 4.5.



Σχήμα 4.5: Μη γραμμικό μοντέλο τεχνητού νευρώνα. (α) Σχηματική αναπαράσταση. (β) Μαθηματική αναπαράσταση. [30].

Τα τρία βασικά στοιχεία του μοντέλου νευρώνα που διακρίνονται στο Σχήμα 4.5 είναι τα εξής [30]:

1. Ένα σύνολο συνάψεων οι οποίες αντιστοιχούν στην ιδέα των συνάψεων των νευρικών κυττάρων. Κάθε σύναψη χαρακτηρίζεται από ένα βάρος. Ένα σήμα εισόδου x_i στην είσοδο της σύναψης i που συνδέεται με το νευρώνα k , πολλαπλασιάζεται επί το συναπτικό βάρος w_{ki} . Σε αντίθεση με τον ανθρώπινο εγκέφαλο, το συναπτικό βάρος ενός νευρώνα λαμβάνει και αρνητικές και θετικές τιμές.
2. Έναν *αθροιστή (adder)* για την άθροιση των σημάτων εισόδου, σταθμισμένων από τα αντίστοιχα συναπτικά βάρη του νευρώνα. Ουσιαστικά πρόκειται για έναν γραμμικό συνδυαστή (*linear combiner*).
3. Μια *συνάρτηση ενεργοποίησης (activation function)* για τον περιορισμό του πλάτους του σήματος εξόδου ενός νευρώνα. Η συνάρτηση ενεργοποίησης αναφέρεται επίσης και ως συνάρτηση περιορισμού επειδή περιορίζει το επιτρεπτό εύρος πλάτους του σήματος εξόδου σε κάποια πεπερασμένη τιμή. Συνήθως το κανονικοποιημένο εύρος τιμών πλάτους της εξόδου ενός νευρώνα γράφεται ως μοναδιαίο κλειστό διάστημα με τη μορφή $[0, 1]$ ή $[-1, 1]$.


Η σύναψη σε ένα ΝΔ είναι, όπως αναφέραμε, εντελώς ανάλογη με τη βιολογική σύναψη των φυσικών νευρώνων. Οι εισοδοί μπορεί να είναι κάποια εξωτερικά σήματα, ή οι εξοδοί από άλλους νευρώνες. Επίσης, πρέπει να αναφέρουμε την ύπαρξη μιας επιπλέον εισόδου b_k , που είναι γνωστή ως *πόλωση (bias)*, και χρησιμοποιείται προκειμένου να αυξήσει ή να μειώσει το αποτέλεσμα της σύναψης ενός νευρώνα ανάλογα με το αν αυτό είναι θετικό ή αρνητικό [6]. Στη συνέχεια, το άθροισμα των εισόδων με τα αντίστοιχα βάρη μετασχηματίζεται από μια γραμμική ή μη γραμμική συνάρτηση μετασχηματισμού (συνάρτηση ενεργοποίησης) f σύμφωνα με τη σχέση [6, 30]:

$$y_k = f\left(\sum_{i=1}^m w_{ki}x_i + b_k\right)$$


όπου x_1, x_2, \dots, x_m τα σήματα εισόδου, $w_{k1}, w_{k2}, \dots, w_{km}$ τα αντίστοιχα συναπτικά βάρη του νευρώνα k , b_k η πόλωση, $f(\cdot)$ η συνάρτηση ενεργοποίησης και y_k το σήμα εξόδου του νευρώνα.

Υπάρχουν διάφορες συναρτήσεις ενεργοποίησης οι κυριότερες των οποίων είναι [5]:


- Συνάρτηση κατωφλίου:



- Σιγμοειδής εφαπτομενική συνάρτηση:



- Σιγμοειδής υπερβολική εφαπτομενική συνάρτηση



Αρχιτεκτονική και Οργάνωση Τεχνητών Νευρωνικών Δικτύων


Οι νευρώνες σε ένα ΝΔ είναι οργανωμένοι σε *επίπεδα (layers)*. Τα τρία βασικά επίπεδα των νευρωνικών δικτύων παρατίθενται παρακάτω: Τα εξωτερικά σήματα εφαρμόζονται στους νευρώνες του *επιπέδου εισόδου (input layer)*. Οι εξοδοί των νευρώνων του επιπέδου εισόδου μεταφέρουν τις πληροφορίες τους στους νευρώνες των *ενδιάμεσων ή κρυμμένων επιπέδων (hidden layers)*, οι οποίοι δεν έχουν άμεση

σχέση με το περιβάλλον. Τέλος, οι νευρώνες του επιπέδου εξόδου (*output layer*) ενημερώνουν το χρήστη για την έξοδο του ΝΔ. Όταν καθένας από τους νευρώνες ενός επιπέδου συνδέεται με όλους τους νευρώνες του επόμενου επιπέδου, τότε το ΝΔ είναι *πλήρως συνδεδεμένο* (*fully connected*), αλλιώς είναι *μερικώς συνδεδεμένο* (*partially connected*) [6]. Στο Σχήμα 4.6 παρουσιάζεται η δομή των βαθμίδων του τεχνητού νευρωνικού δικτύου ενός επιπέδου.


Η αρχιτεκτονική ενός ΝΔ περιλαμβάνει τον αριθμό των επιπέδων και το πλήθος νευρώνων από τους οποίους αποτελείται καθένα από τα επίπεδα. Η επιλογή των νευρώνων του επιπέδου εισόδου εξαρτάται από το πλήθος των χαρακτηριστικών που χρησιμοποιούνται για το προς επίλυση πρόβλημα, ενώ οι νευρώνες του επιπέδου εξόδου προσδιορίζονται, συνήθως απευθείας, από το πρόβλημα. Αντίθετα, ο προσδιορισμός του μεγέθους του ΝΔ, δηλαδή η επιλογή του αριθμού των ενδιάμεσων επιπέδων και του αριθμού των νευρώνων από τους οποίους αποτελούνται, παρουσιάζει δυσκολίες, μιας και συνδέεται με την απόδοση του ΝΔ. Συγκεκριμένα, ΝΔ μικρού μεγέθους μπορεί να αποτύχει σε σύνθετο πρόβλημα, ενώ μεγάλο ΝΔ έχει χρονοβόρα εκπαίδευση, απαιτεί μεγάλο αριθμό δεδομένων και παρουσιάζει πρόβλημα γενίκευσης [6].

Το πλήθος των ενδιάμεσων επιπέδων «αντιστοιχεί» στην πολυπλοκότητα του προβλήματος. Ένα ενδιάμεσο επίπεδο δημιουργεί μια υπερεπιφάνεια, ενώ δύο ενδιάμεσα επίπεδα συνδυάζουν τις υπερεπιφάνειες για τη δημιουργία κυρτών περιοχών απόφασης. Στην πράξη δε χρησιμοποιούνται σχεδόν ποτέ περισσότερα από δύο ενδιάμεσα επίπεδα, αφού αυτά είναι αρκετά για τη δημιουργία περιοχών ταξινόμησης οποιασδήποτε μορφής [6, 188]. Ωστόσο, έχειδειχτεί ότι ΝΔ με ένα ενδιάμεσο επίπεδο είναι ικανό να αναπαραστήσει οποιαδήποτε συνεχή συνάρτηση πολλών μεταβλητών [6, 189], [6, 190].

Ο βέλτιστος αριθμός των νευρώνων που πρέπει να χρησιμοποιηθούν εξαρτάται από το πρόβλημα, το μέγεθος του συνόλου εκπαίδευσης και το επιλεγέν ΝΔ. Υπάρχουν διάφοροι ευρετικοί κανόνες, όπως του Kolmogorov [6, 188], σύμφωνα με τον οποίο το κατώτατο όριο χρησιμοποιούμενων ενδιάμεσων νευρώνων είναι 2, ενώ το ανώτατο $2N + 1$, όπου N ο αριθμός δεδομένων του διανύσματος εισόδου, ενώ ο πιο πιθανός αριθμός νευρώνων είναι $N \cdot M$, όπου M ο αριθμός των νευρώνων του επιπέδου εξόδου [6, 192], ή το 75% του αριθμού των νευρώνων του επιπέδου εισόδου [6, 191]. Ανεξάρτητα από τους παραπάνω κανόνες, οι οποίοι δίνουν μια «αίσθηση» για την τάξη μεγέθους των ενδιάμεσων νευρώνων που πρέπει να χρησιμοποιηθούν, στην πράξη εκτελούνται συνεχείς εκπαιδεύσεις του ΝΔ για διαφορετικό αριθμό ενδιάμεσων νευρώνων και επιλέγεται εκείνος που ικανοποιεί με καλύτερο τρόπο το κριτήριο τερματισμού της εκπαίδευσης. Πρέπει να σημειωθεί ότι έχουν αναπτυχθεί διάφορες μέθοδοι βελτιστοποίησης της διαδικασίας εύρεσης βέλτιστου αριθμού νευρώνων. Οι μέθοδοι αυτές βασίζονται στην αυτόματη προσαρμογή του πλήθους των νευρώνων κατά τη διάρκεια της εκπαίδευσης του ΝΔ [6]. Στο Σχήμα 4.7 παρουσιάζεται συγκεντρωτικά η αρχιτεκτονική ενός νευρωνικού δικτύου, για την καλύτερη κατανόηση του αλγορίθμου.



Σχήμα 4.6: Η δομή του Τεχνητού Νευρωνικού Δικτύου ενός επιπέδου [193].




Σχήμα 4.7: Μια πιθανολογική αρχιτεκτονική νευρωνικού δικτύου με N σημεία δεδομένων εκπαίδευσης [2]. Ο κάθε κόμβος αντιστοιχεί σε ένα δεδομένο εκπαίδευσης και αριθμείται αναλόγως. Στο σχήμα έχουν σχεδιαστεί μόνο τα συναπτικά βάρη του k -οστού κόμβου. Έχουμε υποθέσει ότι υπάρχουν δύο διαθέσιμες τάξεις ω_1 , ω_2 , καθώς και ότι τα πρώτα k σημεία προέρχονται από την τάξη ω_1 , ενώ τα υπόλοιπα από την τάξη ω_2 .


Υπάρχουν διάφοροι τύποι νευρωνικών δικτύων που μοιράζονται τα βασικά χαρακτηριστικά που προαναφέρθηκαν, αλλά που μπορεί να διαφοροποιούνται κατά πολύ στη δομή και στη λειτουργία τους. Ανάλογα, λοιπόν, (α) με την αρχιτεκτονική τους (δηλαδή το πλήθος των βαθμίδων και τον τρόπο σύνδεσης των νευρώνων μεταξύ τους) και (β) το χρησιμοποιούμενο αλγόριθμο εκπαίδευσης, τα νευρωνικά δίκτυα μπορούν να χωριστούν σε διάφορες κατηγορίες. Ως προς τον τρόπο σύνδεσης των νευρώνων τα ΝΔ κατατάσσονται σε δύο μεγάλες κατηγορίες: τα δίκτυα εμπρόσθιας τροφοδότησης (feed-forward) και τα δίκτυα ανατροφοδότησης (feedback/recurrent) [5],[193,194, 195].

Στα δίκτυα πρόσθιας τροφοδότησης τα σήματα μεταφέρονται προς μία μόνο κατεύθυνση, από το επίπεδο εισόδου προς το επίπεδο εξόδου [6]. Αν δεν υπάρχει κάποιο ενδιάμεσο επίπεδο αναφερόμαστε σε *ΝΔ εμπρόσθιας τροφοδότησης ενός επιπέδου* (single layer feed-forward), ενώ στην περίπτωση ενός ή περισσότερων ενδιάμεσων επιπέδων αναφερόμαστε σε *πολυεπίπεδα ΝΔ εμπρόσθιας τροφοδότησης* (multilayer feed-forward). Τα ΝΔ εμπρόσθιας τροφοδότησης δεν περιέχουν βρόχους ανάδρασης, δηλαδή η έξοδος ενός νευρώνα δεν αποτελεί είσοδο σε νευρώνα του ίδιου ή προηγούμενου επιπέδου. Το χαρακτηριστικό τους αυτό διασφαλίζει ότι οι έξοδοι του δικτύου μπορούν να εκφραστούν ως συνάρτηση των εισόδων και των συναπτικών βαρών του δικτύου [183]. Σε αυτήν την κατηγορία ανήκουν Νευρωνικά Δίκτυα που χρησιμοποιούνται σε ένα μεγάλο εύρος εφαρμογών, όπως τα πολυεπίπεδα Perceptrons, τα Νευρωνικά Δίκτυα Ακτινικής Βάσης και τα Πιθανοτικά Νευρωνικά Δίκτυα [183]. Ένα παράδειγμα ΝΔ εμπρόσθιας τροφοδότησης παρουσιάζεται στο Σχήμα 4.8 [5].

Αντίθετα, στην περίπτωση των ΝΔ ανατροφοδότησης οι αναδράσεις επιτρέπονται και συνεπώς τα σήματα μπορούν να μεταφέρονται και προς τις δύο κατευθύνσεις, όπως φαίνεται και από το Σχήμα 4.9. Τα ΝΔ ανατροφοδότησης διαθέτουν τουλάχιστον ένα βρόχο ανάδρασης και μπορούν, εντελώς αντίστοιχα με τα ΝΔ εμπρόσθιας τροφοδότησης, να αποτελούνται από ένα ή περισσότερα ενδιάμεσα επίπεδα [6]. Το ιδιαίτερο χαρακτηριστικό τους είναι ότι έχουν δυναμική συμπεριφορά δηλαδή η κατάσταση τους αλλάζει συνεχόμενα μέχρι να φτάσει ένα σημείο ισορροπίας. Παραμένουν στο σημείο ισορροπίας μέχρις ότου να γίνουν αλλαγές στην είσοδο και μια νέα ισορροπία να βρεθεί. Επομένως, δίνεται η δυνατότητα μέσω αυτών των δικτύων η προσομοίωση χρονικά μεταβαλλόμενων προτύπων [193].



Σχήμα 4.8: Σχηματική απεικόνιση ενός ΤΝΔ εμπρόσθιας τροφοδότησης [5].



Σχήμα 4.9: Σχηματική απεικόνιση ενός ΤΝΔ ανατροφοδότησης [5].

Αλγόριθμοι Εκπαίδευσης

Ένα ΤΝΔ για να μπορεί να εξάγει συμπεράσματα από τα δεδομένα που εισάγονται σε αυτό πρέπει πρώτα να περάσει από μία διαδικασία εκπαίδευσης. Κατά τη διαδικασία αυτή μεταβάλλονται οι συντελεστές βάρους ενός ΝΔ προκειμένου να βρεθεί η βέλτιστη τιμή τους. Ανάλογα, λοιπόν, με τον τρόπο με τον οποίο μεταβάλλονται αυτοί οι συντελεστές, τα ΝΔ διακρίνονται τρεις βασικές μορφές εκπαίδευσης [5,6,196]: η *εκπαίδευση με επίβλεψη* (*supervised training*), η *εκπαίδευση χωρίς επίβλεψη* (*unsupervised training*) και η *υβριδική εκπαίδευση* (*hybrid training*).

A. Εκπαίδευση με Επίβλεψη

Στην εκπαίδευση με επίβλεψη οι εισοδοί εφαρμόζονται στο ΝΔ ταυτόχρονα με την επιθυμητή έξοδο του δικτύου και τα βάρη μεταβάλλονται με τέτοιο τρόπο ώστε να ελαχιστοποιηθεί η διαφορά μεταξύ της εξόδου του ΝΔ και της επιθυμητής εξόδου. Ο πιο δημοφιλής αλγόριθμος αυτής της κατηγορίας είναι ο *αλγόριθμος όπισθεν διάδοσης σφάλματος* (*back-propagation*) [6, 197]. Η *ενισχυμένη εκπαίδευση* (*reinforcement training*) είναι ειδική περίπτωση της εκπαίδευσης με επίβλεψη. Στην *ενισχυμένη εκπαίδευση* ή *εκπαίδευση με ημιεπίβλεψη*, αντί για τη σωστή έξοδο εξάγεται ένας χαρακτηρισμός σχετικός με την απόδοση του ΤΝΔ («καλή» ή «κακή») και τα βάρη μεταβάλλονται έτσι ώστε να ελαχιστοποιηθεί η πιθανότητα «κακού» χαρακτηρισμού του ΝΔ [6].

B. Εκπαίδευση Χωρίς Επίβλεψη

Στην εκπαίδευση χωρίς επίβλεψη η επιθυμητή έξοδος δεν είναι γνωστή. Εφαρμόζεται στο ΝΔ ένα σύνολο από εισόδους-χαρακτηριστικά και στη συνέχεια το ΝΔ αφήνεται να φτάσει σε σταθερή κατάσταση, στην οποία τα δεδομένα ταξινομούνται σε κατηγορίες ανάλογα με τη σχετική τους ομοιότητα. Στην ουσία δηλαδή, στην εκπαίδευση χωρίς επίβλεψη, το ΤΝΔ αναζητά από μόνο του την «κρυμμένη πληροφορία» που υπάρχει στα δεδομένα για να πραγματοποιήσει την ταξινόμηση [5, 6].

Γ. Υβριδική Εκπαίδευση

Στην υβριδική εκπαίδευση, ένα μέρος των βαρών ανανεώνεται με εκπαίδευση με επίβλεψη, ενώ ένα άλλο με εκπαίδευση χωρίς επίβλεψη. Συνήθως η εκπαίδευση χωρίς επίβλεψη εφαρμόζεται στα πρώτα επίπεδα νευρώνων, έτσι ώστε τα δεδομένα να ομαδοποιηθούν ανάλογα με τη σχετική ομοιότητα τους, ενώ σε επόμενα επίπεδα νευρώνων εφαρμόζεται ο αλγόριθμος της Όπισθεν Διάδοσης Σφάλματος, έτσι ώστε οι ομάδες που προέκυψαν να συσχετισθούν με την επιθυμητή έξοδο [6].

Αλγόριθμος Όπισθεν Διάδοσης Σφάλματος

Όπως αναφέρθηκε παραπάνω, ο πιο δημοφιλής τρόπος εκπαίδευσης πολυεπίπεδων ΤΝΔ πρόσθιας ανατροφοδότησης είναι ο αλγόριθμος όπισθεν διάδοσης σφάλματος, ο οποίος επινοήθηκε πρώτα από τον Werbos [198] το 1974 και βελτιώθηκε αργότερα από τον Parker [199] και από τους Rumelhart, Hinton and Williams [200].

Σε ένα πολυεπίπεδο ΤΝΔ εμπρόσθιας τροφοδότησης εισάγονται τα p διανύσματα του συνόλου εκπαίδευσης μαζί με τις επιθυμητές τους εξόδους d_i , $i=1,2,\dots,p$. Η πληροφορία από το επίπεδο εισόδου μεταφέρεται στους νευρώνες του ενδιάμεσου επιπέδου ή των ενδιάμεσων επιπέδων και από εκεί στο επίπεδο εξόδου. Συνήθως κάθε νευρώνας του επιπέδου εισόδου ή ενός ενδιάμεσου επιπέδου συνδέεται με όλους τους νευρώνες του επόμενου επιπέδου. Η τιμή εξόδου του y_{pj} του j νευρώνα για την εμφάνιση του προτύπου n , $n=1,2,\dots,p$ δίνεται από τη σχέση:

$$y_{pj}(n) = f(u_{pj}(n))$$

όπου f η συνάρτηση ενεργοποίησης του συγκεκριμένου νευρώνα και u_{pj} το συναπτικό άθροισμα, δηλαδή

$$u_{pj}(n) = \sum_{i=1}^p w_{ji}(n)x_{pi}(n) + b_{pj}$$

Αν ο νευρώνας i ανήκει στο επίπεδο εισόδου τότε:

$$u_j(n) = \sum_{i \in C} w_{ji}(n)y_i(n) + b_j$$

όπου το w_{ji} συνδέει τον j νευρώνα με τον i νευρώνα του προηγούμενου επιπέδου και y_i οι έξοδοι των νευρώνων του προηγούμενου επιπέδου. Αφού το σήμα φτάσει στο επίπεδο εξόδου, μπορεί να υπολογιστεί τα σφάλματα στην έξοδο του νευρώνα j που ανήκει σε επίπεδο εξόδου και το οποίο δίνεται από τον τύπο:

$$e_j(n) = d_j(n) - y_j(n)$$

όπου $d_j(n)$ η επιθυμητή και $y_j(n)$ η πραγματική έξοδος του νευρώνα j .

Ορίζουμε την στιγμιαία τιμή του τετραγωνικού σφάλματος για το νευρώνα εξόδου j ως $\frac{1}{2}e_j^2(n)$. Αντίστοιχα, ορίζουμε το άθροισμα των τετραγωνικών σφαλμάτων όλων των νευρώνων εξόδου ως:

$$J(n) = \frac{1}{2} \sum_{j=1}^M e_j^2(n), \text{ όπου } M \text{ είναι ο αριθμός των νευρώνων εξόδου.}$$

Επίσης ορίζουμε την μέση τιμή των σφαλμάτων ως:

$$J_{av} = \frac{1}{P} \sum_{n=1}^P J(n)$$

Τόσο το J όσο και το J_{av} είναι συναρτήσεις των ελεύθερων παραμέτρων του δικτύου (βάρη των συνδέσεων και πολώσεις). Ο αντικειμενικός στόχος της διαδικασίας εκπαίδευσης είναι η ελαχιστοποίηση του J_{av} προσαρμόζοντας τις ελεύθερες παραμέτρους του δικτύου. Η ελαχιστοποίηση της συνάρτησης σφάλματος γίνεται με τη μέθοδο *απότομης καθόδου* (*gradient steepest descent*) [3, 6, 201]. Η εφαρμογή της μεθόδου έγκειται στη μεταβολή των βαρών με τέτοιο τρόπο, ώστε να ελαχιστοποιηθεί το σφάλμα μεταξύ της πραγματικής και της υπολογισμένης από το ΝΔ εξόδου. Η ενημέρωση των συντελεστών w_{ji} και b_j γίνεται, σύμφωνα με τον αλγόριθμο, από τους παρακάτω τύπους

$$\Delta w_{pj}(n) = -\eta \frac{\partial J(n)}{\partial w_{ji}(n)} = \eta \delta_{pj}(n) y_{pi}(n) \quad \Delta b_{pj}(n) = \eta \delta_{pj}(n)$$

όπου το η είναι ο *ρυθμός εκπαίδευσης* (learning rate) και $\delta_{pj}(n)$ ονομάζεται τοπική κλίση για την οποία ισχύει ότι

$$\delta_{pj}(n) = \begin{cases} e_{pj}(n) f'_j(u_{pj}(n)) & , \text{ αν } j \text{ αντιστοιχεί σε νευρώνα εξόδου} \\ f'_j(u_{pj}(n)) \sum_k \delta_{pk}(n) w_{kj}(n) & , \text{ αν } j \text{ αντιστοιχεί σε νευρώνα ενδιάμεσου επιπέδου} \end{cases}$$

Όπως διαφαίνεται, η λειτουργία του αλγόριθμου έχει δύο στάδια. Το πρώτο αναφέρεται ως πέρασμα ορθής φοράς (forward pass), και το δεύτερο ως πέρασμα ανάστροφης φοράς (reverse pass). Στο ευθύ πέρασμα, τα βάρη των συνδέσεων παραμένουν αναλλοίωτα σε όλο το δίκτυο και τα σήματα υπολογίζονται σε κάθε νευρώνα υπολογίζοντας τις αντίστοιχες εξόδους. Το πέρασμα αυτό ξεκινά στο πρώτο κρυμμένο επίπεδο με την παρουσίαση του διανύσματος εισόδου, και τελειώνει στο επίπεδο εξόδου με τον υπολογισμό του σφάλματος, για κάθε νευρώνα αυτού του επιπέδου.

Το ανάστροφο πέρασμα, αντίθετα, αρχίζει από το επίπεδο εξόδου, περνώντας τα σήματα σφάλματος προς τα πίσω και υπολογίζοντας αναδρομικά το δ για κάθε νευρώνα. Η διαδικασία αυτή επιτρέπει στα βάρη των συνδέσεων να υποστούν αλλαγές σύμφωνα με τον κανόνα δέλτα. Για τους νευρώνες του επιπέδου εξόδου, το δ ισούται με το γινόμενο του σφάλματος επί την πρώτη παράγωγο της μη-γραμμικής συνάρτησης. Στη συνέχεια, χρησιμοποιούμε αυτό το δ για να υπολογίσουμε τα δ του προτελευταίου επιπέδου και ούτω καθεξής για τα υπόλοιπα. Δηλαδή το σφάλμα εξόδου διαδίδεται από το επίπεδο εξόδου μέσω των ενδιάμεσων επιπέδων προς την είσοδο (όπισθεν διάδοση σφάλματος).

Σημειώνεται ότι η διαδικασία των δύο περασμάτων εκτελείται για κάθε πρότυπο του συνόλου εκπαίδευσης με μία κυκλική επανάληψη μέχρι να εισαχθούν όλα τα πρότυπα που ανήκουν στο σύνολο εκπαίδευσης.

Ο αλγόριθμος της όπισθεν διάδοσης σφάλματος μπορεί να εφαρμοστεί με δύο τρόπους σε ένα σύνολο εκπαίδευσης. Ο ένας τρόπος, γνωστός και ως *on-line εκπαίδευση*, ανανεώνει τα βάρη κάθε φορά που εφαρμόζεται στο ΝΔ ένα νέο διάνυσμα του συνόλου εκπαίδευσης. Ο άλλος τρόπος εκπαίδευσης, γνωστός και ως *batch εκπαίδευση*, ανανεώνει τα βάρη μετά την εφαρμογή p διανυσμάτων του συνόλου εκπαίδευσης, που μπορεί να είναι όλο το σύνολο εκπαίδευσης ή ένα υποσύνολό του. Η περίοδος με την οποία ανανεώνονται τα βάρη ονομάζεται *επανάληψη* ή *εποχή* (epoch). Κάθε ένας από τους προαναφερθέντες τρόπους εκπαίδευσης έχει πλεονεκτήματα και μειονεκτήματα. Συγκεκριμένα, στην on-line εκπαίδευση η ανανέωση των βαρών ανά εφαρμοζόμενο διάνυσμα καθιστά την

αναζήτηση στο χώρο των βαρών στοχαστική, που σημαίνει ότι ο αλγόριθμος είναι δύσκολο να εγκλωβιστεί σε κάποιο τοπικό ελάχιστο (local minimum). Η on-line εκπαίδευση προτιμάται στις hardware υλοποιήσεις ΝΔ, όπου υπάρχουν περιορισμοί στη διαθεσιμότητα πόρων αποθήκευσης. Στην batch εκπαίδευση το διάνυσμα της κλίσης (gradient) υπολογίζεται με μεγαλύτερη ακρίβεια και ο αλγόριθμος μπορεί να συγκλίνει σε κάποιο ελάχιστο, αλλά ύστερα από μεγαλύτερο χρόνο εκπαίδευσης [5, 6].

Παράμετροι Βελτιστοποίησης ΤΝΔ

Γίνεται κατανοητό ότι για να λειτουργήσει σωστά και με υψηλή απόδοση ο ταξινομητής νευρωνικών δικτύων, θα πρέπει να επιλεχθούν προσεκτικά όλες οι παράμετροί του. Στο σημείο αυτό πρέπει να τονίσουμε ότι το πλήθος των επιπέδων και των νευρώνων, που αναλύθηκαν προηγουμένως στην ενότητα της Αρχιτεκτονικής των Νευρωνικών Δικτύων, αποτελούν και αυτά μια σημαντική παράμετρο βελτιστοποίησης του ΝΔ.

A. Αρχικοποίηση Βαρών

Έχει αποδειχτεί ότι η ταχύτητα σύγκλισης ενός ΤΝΔ εξαρτάται σε μεγάλο βαθμό από τα αρχικά βάρη. Για το λόγο αυτό πραγματοποιείται αρχικοποίηση της μήτρας βαρών είτε με τυχαία αρχικά βάρη, ή χρησιμοποιώντας ως αρχικά βάρη τις προσεγγιστικές λύσεις που προκύπτουν από άλλες τεχνικές μοντελοποίησης όπως είναι η μέθοδος πρωτευουσών συνιστωσών [5, 202], ο ταξινομητής κοντινότερου γείτονα [5, 203] κ.λ.π. με σκοπό τόσο τη μείωση του απαιτούμενου χρόνου εκπαίδευσης, όσο και τη μείωση της πιθανότητας σύγκλισης σε κάποιο τοπικό ελάχιστο (μη τυχαία αρχικοποίηση).

Στην τυχαία αρχικοποίηση τα αρχικά βάρη παίρνουν μικρές τυχαίες τιμές. Οι τιμές αυτές χρειάζεται να είναι τυχαίες προκειμένου να μην υπάρχουν συμμετρίες, δηλαδή κάθε νευρώνας να επεξεργάζεται διαφορετικές συναρτήσεις. Στην αντίθετη περίπτωση η απόκριση όλων των νευρώνων του ίδιου επιπέδου θα ήταν παρόμοια, το συγκεκριμένο επίπεδο θα συμπεριφερόταν σαν να αποτελείται ουσιαστικά από ένα νευρώνα, με αποτέλεσμα η πληροφορία για το σφάλμα να είναι παρόμοια και συνεπώς η μεταβολή των βαρών κατά τη διάρκεια της εκπαίδευσης θα ήταν δύσκολη. Η επιλογή «μικρών» τιμών αρχικοποίησης των βαρών είναι απαραίτητη προκειμένου να αποφεύγεται η μετάβαση των σιγμοειδών συναρτήσεων σε κόρο. Μεγάλα βάρη μπορούν να ενισχύσουν μια μεσαίου μεγέθους είσοδο παράγοντας πολύ μεγάλες τιμές για τα αθροίσματα, που σημαίνει πολύ μεγάλη είσοδο για τους νευρώνες του επόμενου επιπέδου. Αυτό θα έχει ως συνέπεια οι νευρώνες να κινηθούν σε επίπεδες επιφάνειες κοντά στο σημείο εκκίνησης ή να εγκλωβιστούν σε κάποιο τοπικό ελάχιστο. Από την άλλη, οι τιμές των βαρών δεν επιτρέπεται να είναι πάρα πολύ μικρές, γιατί αυτό σημαίνει πολύ μικρή τιμή για το σήμα σφάλματος επιδρώντας στην ταχύτητα εκπαίδευσης. Για την τυχαία αρχικοποίηση των βαρών έχουν αναπτυχθεί διάφορες μεθοδολογίες οι περισσότερες από τις οποίες αναφέρονται στο εύρος των αρχικών τιμών [5, 204].

Στη μη τυχαία αρχικοποίηση, το ΝΔ ξεκινά από μια σχετικά καλή λύση και ο αλγόριθμος της όπισθεν διάδοσης σφάλματος χρησιμοποιείται στη συνέχεια για την εύρεση της βέλτιστης λύσης. Με τον τρόπο αυτό μειώνεται ο απαιτούμενος χρόνος εκπαίδευσης προκειμένου το σύστημα να συγκλίνει στο πραγματικό ολικό ελάχιστο και όχι σε κάποιο τοπικό [5].

B. Τερματισμός Εκπαίδευσης

Ο καθορισμός της χρονικής στιγμής τερματισμού της εκπαίδευσης ενός ΤΝΔ είναι πολύ σημαντικό ζήτημα. Αν η εκπαίδευση σταματήσει πολύ νωρίς τότε ενδεχομένως το ΤΝΔ να μην έχει εκπαιδευτεί επαρκώς (δεν έχει μάθει σωστά) και έτσι δεν θα μπορεί να ανταποκριθεί στις ανάγκες του προβλήματος κάνοντας λάθος εκτιμήσεις για τα δεδομένα. Αντίθετα, αν το ΤΝΔ αφεθεί να εκπαιδευτεί παραπάνω από όσο χρειάζεται τότε κινδυνεύει να υπερεκπαιδευτεί και να χάσει την ικανότητα γενίκευσης. Σε αυτή την περίπτωση το ΤΝΔ «αποστηθίζει» τα δεδομένα εκπαίδευσης σε τέτοιο βαθμό που δεν μπορεί να εκτιμήσει σωστά δεδομένα που απέχουν λίγο από αυτά. Είναι ζητούμενο λοιπόν η εύρεση του βέλτιστου αριθμού εποχών εκπαίδευσης ώστε να μεγιστοποιηθεί η απόδοση του δικτύου.

Συνήθη κριτήρια τερματισμού της εκπαίδευσης είναι τα παρακάτω [5, 205]:

- Η τιμή της συνάρτησης σφάλματος να είναι μικρότερη από μία προκαθορισμένη τιμή.
- Να έχει εκτελεστεί προκαθορισμένος αριθμός επαναλήψεων
- Η κλίση της συνάρτησης σφάλματος να είναι μικρότερη από μια προκαθορισμένη τιμή.

Τα παραπάνω κριτήρια έχουν το μειονέκτημα ότι από τη μία εξαρτώνται αποκλειστικά από τις παραμέτρους του ΝΔ και από την άλλη δε λαμβάνουν υπόψη τον παράγοντα γενίκευσης του ΝΔ, δηλαδή την ικανότητα του να ανταποκρίνεται αξιόπιστα σε νέα δεδομένα που δεν έχουν χρησιμοποιηθεί κατά τη διάρκεια της εκπαίδευσης.

Για βελτίωση της γενίκευσης έχουν προταθεί διάφοροι μέθοδοι τερματισμού της εκπαίδευσης. Μία από αυτές είναι η μέθοδος του *έγκαιρου τερματισμού* (*early stopping*) [5, 206]. Για την υλοποίηση της απαιτούνται δύο φάσεις: η *φάση εκπαίδευσης* (*training phase*) και η *φάση γενίκευσης* (*testing phase*). Στη φάση εκπαίδευσης χρησιμοποιούνται δύο σύνολα δεδομένων, το *σύνολο εκπαίδευσης* (*training set*) και το *σύνολο επαλήθευσης* (*validation set*), ενώ στη φάση γενίκευσης χρησιμοποιείται το *σύνολο γενίκευσης* (*testing set*). Τα ΤΝΔ εκπαιδεύεται με τα δεδομένα του συνόλου εκπαίδευσης και η διαδικασία της εκπαίδευσης ολοκληρώνεται όταν μεγιστοποιηθεί η απόδοση του ΤΝΔ στο σύνολο επαλήθευσης, οπότε οι βέλτιστες τιμές για τις μήτρες των βαρών και των πολώσεων αποθηκεύονται για να χρησιμοποιηθούν στη φάση γενίκευσης. Στη φάση γενίκευσης οι εισοδοί στο ΝΔ είναι τα δεδομένα του συνόλου γενίκευσης, ενώ η προκύπτουσα έξοδος δίνει μια εκτίμηση για την ικανότητα του ΝΔ να ανταποκρίνεται σε νέα άγνωστα δεδομένα.

Μια άλλη μέθοδος τερματισμού είναι η μέθοδος της *διασταυρούμενης επικύρωσης* (*cross-validation*) [5, 207], γενική περίπτωση της οποίας είναι η *k* διασταυρούμενη επικύρωση. Η μέθοδος αυτή, όπως και η μέθοδος του έγκαιρου τερματισμού, πραγματοποιείται σε δύο φάσεις. Αρχικά τα δεδομένα της φάσης εκπαίδευσης διαιρούνται σε *k* υποσύνολα ίδιας διάστασης. Το ΝΔ εκπαιδεύεται *k* φορές χρησιμοποιώντας ως σύνολο εκπαίδευσης τα *k-1* υποσύνολα δεδομένων, ενώ το *k* υποσύνολο δεδομένων, διαφορετικό κάθε φορά, χρησιμοποιείται ως σύνολο επαλήθευσης. Η ικανότητα γενίκευσης του ΝΔ ελέγχεται στα δεδομένα του συνόλου επαλήθευσης και προκύπτει ως ο μέσος όρος της απόδοσης του ΤΝΔ μετά το πέρας των *k* εκπαιδεύσεων. Το κύριο μειονέκτημα αυτής της μεθόδου είναι το υψηλό υπολογιστικό κόστος, μιας και κάθε ΝΔ πρέπει να εκπαιδευτεί *k* φορές.

Γ. Επιλογή Συνόλου Εκπαίδευσης, Επαλήθευσης και Γενίκευσης

Η απόδοση και η ικανότητα γενίκευσης ενός ΝΔ εξαρτώνται άμεσα από την ποσότητα και την ποιότητα των δεδομένων που θα χρησιμοποιηθούν για την εκπαίδευση του. Το σύνολο εκπαίδευσης θα πρέπει να είναι αντιπροσωπευτικό των διαφορετικών προτύπων που χαρακτηρίζουν το προς επίλυση πρόβλημα. Η απόκριση ενός εκπαιδευμένου ΝΔ είναι πάρα πολύ καλή σε δεδομένα παραπλήσια αυτών που χρησιμοποιήθηκαν κατά τη διάρκεια εκπαίδευσής του (*παρεμβολή-interpolation*), ενώ δεν ισχύει το ίδιο σε περιπτώσεις ακραίες σε σχέση με τα δεδομένα εκπαίδευσης (*υπερβολή-extrapolation*). Αυτό καθιστά προφανή την απαίτηση για δεδομένα εκπαίδευσης που καλύπτουν όσο το δυνατό μεγαλύτερο εύρος πιθανών διαφορετικών τιμών, έτσι ώστε να μειώνεται η πιθανότητα παρουσίασης ακραίων περιπτώσεων. Επίσης, τα διάφορα πρότυπα θα πρέπει να εκπροσωπούνται με παρόμοια ποσοστά στα σύνολα εκπαίδευσης, επαλήθευσης και γενίκευσης [5].

Δ. Προεπεξεργασία Δεδομένων

Τα διανύσματα εισόδου πριν εφαρμοστούν στους νευρώνες του επιπέδου εισόδου πρέπει να υποστούν κάποιο είδος προεπεξεργασίας. Η προεπεξεργασία έχει ως στόχο την αναγωγή των δεδομένων σε τέτοιο εύρος τιμών έτσι ώστε αυτά να μην βρίσκονται σε περιοχή των σιγμοειδών συναρτήσεων που παρουσιάζουν κόρο. Παράλληλα τα δεδομένα εισόδου κανονικοποιούνται, έτσι ώστε η μέση τιμή τους να είναι ίση με μηδέν και η τυπική απόκλιση ίση με ένα. Με αυτόν τον τρόπο όλοι οι συντελεστές βάρους «μαθαίνουν» με την ίδια περίπου ταχύτητα. Εναλλακτικά, τα δεδομένα μπορούν να κανονικοποιηθούν από 0 έως 1 ή -1 έως 1 ανάλογα με το αν η χρησιμοποιούμενη συνάρτηση μετασχηματισμού είναι η σιγμοειδής εφαιτομενική ή η υπερβολική. Τέλος, για την επιτάχυνση του αλγόριθμου της όπισθεν διάδοσης σφάλματος θα πρέπει οι μεταβλητές του διανύσματος εισόδου να είναι ασυσχέτιστες, κάτι που μπορεί να επιτευχθεί με διάφορες μεθοδολογίες μείωσης της διάστασης του διανύσματος εισόδου σε ένα ΝΔ. Ιδανικά, θα έπρεπε να εξεταστούν όλοι οι 2^N διαφορετικοί συνδυασμοί των N μεταβλητών του διανύσματος εισόδου και να επιλεγούν εκείνες οι μεταβλητές που ικανοποιούν με βέλτιστο τρόπο κάποια συνάρτηση ποιότητας που μπορεί να είναι είτε το κριτήριο τερματισμού του ΝΔ ή κάποιο μέτρο απόστασης, πληροφορίας, εξάρτησης κ.λ.π. Επειδή, η συγκεκριμένη μέθοδος έχει μεγάλο υπολογιστικό κόστος ακόμη και για σχετικά μικρό πλήθος μεταβλητών συνήθως χρησιμοποιούνται τεχνικές, οι οποίες βασίζονται σε ευρετικές μεθόδους επιλογής, οι οποίες επιχειρούν να εξισορροπήσουν την υπολογιστική πολυπλοκότητα με την ικανοποίηση της συνάρτησης ποιότητας.

Εφαρμογές των Νευρωνικών Δικτύων στη Βιοϊατρική

Τα ΝΔ έχουν αποδειχτεί χρήσιμη και αποτελεσματική επιλογή για την ανάπτυξη συστημάτων αναγνώρισης, επεξεργασίας και ανάλυσης βιοϊατρικών σημάτων, μιας και οι επιδόσεις τους είναι καλύτερες συγκριτικά με τις αντίστοιχες κλασικές μεθόδους, καθώς και σε προβλήματα βιολογικών συστημάτων, τα οποία χαρακτηρίζονται από έντονη παρουσία θορύβου και μεγάλη μεταβλητότητα προερχόμενη από εσωτερικούς μηχανισμούς και μη προβλεπόμενες εξωγενείς διεγέρσεις [6].

Πιο συγκεκριμένα, τα ΝΔ έχουν χρησιμοποιηθεί για την αναγνώριση και ταξινόμηση ηλεκτροκαρδιογραφικών (ΗΚΓ) σημάτων, δίνοντας πιο αξιόπιστα

αποτελέσματα σε σχέση με τις κλασικές μεθόδους ταξινόμησης [208], [209], [210]. Η υλοποίηση αυτοματοποιημένων συστημάτων αξιόπιστης ανίχνευσης και ταξινόμησης ΗΚΓ σε πραγματικό χρόνο είναι ιδιαίτερα κρίσιμη σε χώρους όπως οι μονάδες εντατικής θεραπείας ή τα ασθενοφόρα [211]. Βιοσήματα προερχόμενα από καταγραφές ηλεκτροεγκεφαλογραφήματος (ΗΕΓ) έχουν αναλυθεί με χρήση ΝΔ, όχι μόνο για την πρόιμη ανίχνευση διαταραχών της ομαλής εγκεφαλικής λειτουργίας [212], αλλά και για την ανάπτυξη επικοινωνιακών συστημάτων προκειμένου να διευκολυνθούν άτομα με κινητικά προβλήματα [213], [214]. Αντίστοιχα, η ανάλυση καταγραφών από ηλεκτρομυογράφημα (ΗΜΓ) με χρήση ΝΔ έχει χρησιμοποιηθεί για το διαχωρισμό των ατόμων σε υγιή και σε άτομα με νευρομυϊκές ασθένειες [215].

Στον τομέα της επεξεργασίας και ανάλυσης ιατρικών εικόνων που λαμβάνονται από αξονικούς τομογράφους (CT), τομογράφους μαγνητικού συντονισμού (MRI) και τομογράφους εκπομπής ποζιτρονίων (PET), τα ΝΔ έχουν χρησιμοποιηθεί για την απομόνωση και ταξινόμηση δομών ενδιαφέροντος, με στόχο την έγκαιρη, αξιόπιστη και κατά το δυνατό λιγότερο επεμβατική διάγνωση. Παράλληλα, η χρήση των ΝΔ έχει ενισχύσει τη διαγνωστική αξία των ενδοσκοπικών τεχνικών, μιας και επιτρέπει την πραγματικού χρόνου ανίχνευση καρκινικών βλαβών σε εικόνες video που λαμβάνονται κατά τη διάρκεια της κολonosκόπησης [216].

Περιπτώσεις καρκίνων όπως οι δερματικοί έχει αποδειχτεί ότι ταξινομούνται με μεγαλύτερη αξιοπιστία (97.7%) με χρήση γενετικών αλγορίθμων και ΝΔ, σε σχέση με την κλινική αξιοπιστία των δερματολόγων, που είναι της τάξης του 85% [217]. Επίσης, συστήματα υποστήριξης διάγνωσης βασισμένα σε ΝΔ και εικόνες μαστογραφίας [218], [219], ή υπερήχου [220] όχι μόνο έδωσαν καλύτερα αποτελέσματα σε σχέση με τις στατιστικές μεθόδους, αλλά θα μπορούσαν να χρησιμοποιηθούν και για την επιβεβαίωση της διάγνωσης, λειτουργώντας ως «δεύτερη γνώμη».


Τα ΝΔ στη βιοϊατρική τεχνολογία μπορούν να χρησιμοποιηθούν ως εργαλεία μοντελοποίησης φυσιολογικών φαινομένων για την εκπαίδευση ασθενών, όπως είναι οι διαβητικοί, για την ανάπτυξη συστημάτων μη επεμβατικού προσδιορισμού μεγεθών, όπως είναι η συγκέντρωση της γλυκόζης και το οξυγόνο αίματος [6]. Επίσης, η δυναμική παρακολούθηση και ο έλεγχος τόσο της χορηγούμενης δόσης αναισθητικού, όσο και της εξέλιξης της αναισθησίας κατά τη διάρκεια χειρουργικών επεμβάσεων μπορεί να γίνει χρησιμοποιώντας ΝΔ. Τα τελευταία χρόνια τα ΝΔ εφαρμόζονται και για τη διαχείριση του μεγάλου όγκου πληροφοριών που υπάρχει στις ιατρικές βάσεις δεδομένων [221], καθώς και για την εξαγωγή πληροφορίας είτε από δεδομένα ασθενών που περιέχονται σε ηλεκτρονικούς φακέλους, ή από καταγραφές γενετικού υλικού [222], [223].

Η χρήση των ΝΔ στη βιοϊατρική τεχνολογία αυξάνει την ικανότητα ακριβούς και έγκαιρης λήψης κλινικών αποφάσεων, μειώνοντας την ανάγκη για επιβεβαίωσή τους με επιπλέον εξετάσεις (εργαστηριακές, επεμβατικές π.χ. βιοψία κ.λπ.). Παράλληλα, η χρήση ΝΔ για την υλοποίηση υποστηρικτικών διαγνωστικών συστημάτων παρέχει το πλεονέκτημα ελαχιστοποίησης της επίδραση παραγόντων, όπως είναι η ανθρώπινη κόπωση, η συναισθηματική φόρτιση και η υποκειμενικότητα του ιατρού, ενώ η ικανότητά τους για ταχεία αναγνώριση της χρήσιμης πληροφορίας, ανάλυση καταστάσεων και πραγματικού χρόνου υποβοήθησης της διάγνωσης μειώνουν το χρόνο αναμονής για τη λήψη αποτελεσμάτων, μειώνοντας κατά συνέπεια και την ψυχολογική επιβάρυνση των ασθενών [6].

4.4.2 Αλγόριθμος k-Κοντινότερων Γειτόνων (k-Nearest Neighbor Algorithm)

Η ταξινόμηση Κοντινότερου Γείτονα είναι μια στατιστική μέθοδος επιβλεπόμενης ταξινόμησης. Ο συγκεκριμένος μη γραμμικός ταξινομητής αποτελεί την απλούστερη μέθοδο ταξινόμησης καθώς είναι μη παραμετρική, δηλαδή δεν κάνει υποθέσεις σχετικά με την κατανομή των δεδομένων [193]. Η λογική της ταξινόμησης κοντινότερου γείτονα, είναι πολύ απλή, καθώς το υπό ταξινόμηση πρότυπο κατατάσσεται στην τάξη στην οποία ανήκει το κοντινότερο σε αυτό πρότυπο εκπαίδευσης. Για περισσότερη ασφάλεια στην ταξινόμηση, συνήθως λαμβάνονται υπ' όψιν περισσότερα του ενός κοντινά πρότυπα του δείγματος εκπαίδευσης, έστω k στον αριθμό. Σ' αυτό συνίσταται και η μέθοδος των k -Κοντινότερων Γειτόνων (k -Nearest Neighbor, k -NN) [30].

Πιο συγκεκριμένα, η ταξινόμηση του k -πλησιέστερου γείτονα χωρίζει τα δεδομένα σε ένα σύνολο δοκιμών και ένα σύνολο εκπαίδευσης. Για την ταξινόμηση ενός νέου δεδομένου από το σύνολο δοκιμών, ο αλγόριθμος χρησιμοποιεί τα αποθηκευμένα δεδομένα για να βρει ένα συγκεκριμένο πλήθος (k) των πιο όμοιων προτύπων εκπαίδευσης (κοντινότεροι γείτονες), σύμφωνα με μια μετρική απόστασης. Το νέο δεδομένο δοκιμής ανατίθεται στην κατηγορία που είναι επικρατέστερη μεταξύ των κοντινότερων γειτόνων του, δηλαδή η κατάταξη του δεδομένου δοκιμής καθορίζεται από τα δεδομένα εκπαίδευσης που επικρατούν σε αριθμό σε εκείνη την περιοχή [30], [193]. Στην περίπτωση που τα k κοντινότερα πρότυπα δεν είναι όλα της ίδιας τάξης, τότε χρησιμοποιείται η ψήφος πλειοψηφίας ή ψήφος σταθμισμένων αποστάσεων. Το k επιλέγεται ώστε να μην είναι πολλαπλάσιο του πλήθους M των τάξεων που υπάρχουν στο πρόβλημα [30]. Ο αριθμός k είναι συνήθως ένας μικρός περιττός αριθμός (π.χ. 5 ή 7), ενώ μια συνηθισμένη μέθοδος μέτρησης απόστασης για συνεχείς μεταβλητές είναι η Ευκλείδεια. Ας δώσουμε τώρα ένα απλό παράδειγμα της λειτουργίας του αλγορίθμου. Παρατηρώντας το παρακάτω σχήμα (Σχήμα 4.10), το άγνωστο πρότυπο a (τρίγωνο) με εφαρμογή του κριτηρίου του κοντινότερου γείτονα θα καταταχθεί στην τάξη των κύκλων (ο). Ωστόσο, αν στο ίδιο σχήμα εφαρμοστεί ταξινόμηση τριών κοντινότερων γειτόνων, τότε το πρότυπο a θα καταταχθεί στην τάξη των σταυρών (+), καθώς αφού δύο από τα τρία κοντινότερα πρότυπα είναι (+), χρησιμοποιείται η ψήφος πλειοψηφίας [30].



Σχήμα 4.10: Παράδειγμα ταξινόμησης κοντινότερων γειτόνων. Ο μικρότερος (ανοιχτός γκρι) κύκλος αναφέρεται στην ταξινόμηση κοντινότερου γείτονα, ενώ ο μεγάλος (μαύρος) κύκλος αναφέρεται στην ταξινόμηση 3 κοντινότερων γειτόνων [30].

Τα πρότυπα εκπαίδευσης είναι διανύσματα χαρακτηριστικών ενός πολυδιάστατου χώρου, το καθένα με μια ετικέτα κατηγορίας (τάξης). Η φάση της εκπαίδευσης του αλγορίθμου αποτελείται μόνο από την αποθήκευση του διανύσματος των χαρακτηριστικών και της ετικέτας τάξης, για κάθε δείγμα εκπαίδευσης [193]. Η φάση εκπαίδευσης είναι, επίσης, αρκετά γρήγορη, καθώς δεν χρησιμοποιεί τα δεδομένα αυτά για να κάνει οποιαδήποτε γενίκευση, πράγμα που σημαίνει ότι ο kNN διατηρεί όλα τα δεδομένα εκπαίδευσης [193].

Στη φάση της ταξινόμησης, η σταθερά k από ένα χρήστη και ένα μη καθορισμένο δείγμα ή αλλιώς σημείο δοκιμής, ταξινομείται καθορίζοντας την τάξη του με βάση την πιο συχνά εμφανιζόμενη τάξη από δείγματα εκπαίδευσης μεταξύ των k δειγμάτων που βρίσκονται πλησιέστερα στο σημείο [193].

Υπάρχει, λοιπόν, μια ελάχιστη φάση εκπαίδευσης, αλλά μια δαπανηρή φάση δοκιμών με κόστος τόσο από άποψη χρόνου όσο και μνήμης. Μπορεί να διαρκέσει περισσότερο χρόνο, στη χειρότερη περίπτωση, αλλά όλα τα σημεία δεδομένων θα λάβουν μέρος στην απόφαση κατάταξης. Περισσότερη μνήμη είναι απαραίτητη καθώς θα πρέπει να αποθηκευθούν όλα τα δεδομένα εκπαίδευσης [193, 224]. Επειδή τα δείγματα εκπαίδευσης χρειάζονται κατά το χρόνο εκτέλεσης του ταξινομητή και πρέπει να βρίσκονται στη μνήμη, η μέθοδος πολλές φορές ονομάζεται **Ταξινόμηση Βασιζόμενη σε Μνήμη** (Memory Based Classification) και ανήκει στην κατηγορία των τεχνικών **Οκνηρής Μάθησης** (Lazy Learning) επειδή δεν υπάρχει διαδικασία εκπαίδευσης και όλοι οι υπολογισμοί που χρειάζονται πραγματοποιούνται κατά την εκτέλεση της ταξινόμησης. Επίσης, επειδή η ταξινόμηση προκύπτει μόνο από τη χρήση των δειγμάτων η τεχνική είναι γνωστή και ως **Ταξινόμηση Βασιζόμενη σε Δείγματα** (Example Based/Case Based/Instance Classification) [183], [225], [226].

Αλγόριθμος k-NN [227]

Βήμα 1^ο: Καθορισμός ενός θετικού ακεραίου k μαζί με τον καθορισμό ενός νέου δείγματος.

Βήμα 2^ο: Επιλογή k καταχωρήσεων στη βάση δεδομένων μας που βρίσκονται πλησιέστερα στο νέο δείγμα.

Βήμα 3^ο: Χρήση της πιο κοινής κατάταξης από αυτές τις καταχωρήσεις ώστε να δοθεί σε αυτό το δείγμα.

Ταξινόμηση με τον k-NN

Το πρόβλημα της ταξινόμησης kNN ορίζεται ως εξής: Έστω ότι διαθέτουμε ένα σύνολο εκπαίδευσης $T = \{x_i\}_{i=1}^N$, όπου N το πλήθος των προτύπων του συνόλου T . Τα χαρακτηριστικά των προτύπων αυτών συγκροτούν σύνολο F και οι τιμές τους κανονικοποιούνται, ώστε να βρίσκονται στο διάστημα $[0, 1]$. Κάθε πρότυπο του T αντιστοιχίζεται σε μία τάξη $y_j, j = 1, 2, \dots, M$, όπου M το πλήθος των τάξεων. Το ζητούμενο είναι να ταξινομηθεί ένα άγνωστο πρότυπο \mathbf{a} . Η κατηγοριοποίηση αποτελείται από δύο επιμέρους διαδικασίες, τον προσδιορισμό των k κοντινότερων γειτόνων και τον καθορισμό της τάξης με χρήση των k κοντινότερων γειτόνων [30]. Έτσι αρχικά υπολογίζεται η απόσταση d του \mathbf{a} από κάθε x_i :

$$d(\mathbf{a}, \mathbf{x}_i) = \sum_{f \in F} w_f \delta(\alpha_f, x_{if})$$

, όπου w_f είναι ο συντελεστής βάρους του χαρακτηριστικού f . Υπάρχει μεγάλη ποικιλία δυνατοτήτων για το μετρικό d . Με βάση αυτό το μετρικό υπολογίζονται οι k κοντινότεροι γείτονες του προτύπου \mathbf{a} . Σύμφωνα με τον μαθηματικό ορισμό ένα μετρικό πρέπει να ικανοποιεί τα παρακάτω τέσσερα κριτήρια:

- | | |
|---|-----------------------|
| (1) $d(x, y) \geq 0$ | (μη αρνητικότητα) |
| (2) $d(x, y) = 0 \Leftrightarrow x = y$ | (ταυτότητα) |
| (3) $d(x, y) = d(y, x)$ | (συμμετρία) |
| (4) $d(x, z) \leq d(x, y) + d(y, z)$ | (τριγωνική ανισότητα) |

Αν τα χαρακτηριστικά των προτύπων παίρνουν συνεχείς τιμές, χρησιμοποιείται το μετρικό απόστασης *Minkowski*, ο γενικός τύπος του οποίου είναι

$$MD_p(\mathbf{a}, \mathbf{x}_i) = \left(\sum_{f \in F} |\alpha_f - x_{if}|^p \right)^{\frac{1}{p}}$$

όπου f ένα χαρακτηριστικό από το σύνολο των χαρακτηριστικών F , q_f η τιμή του άγνωστου δείγματος για το χαρακτηριστικό f και x_{if} η τιμή του δείγματος εκπαίδευσης για το χαρακτηριστικό αυτό. Η παράμετρος p καθορίζεται εκ των προτέρων [183, 225].

Αν επιλεγθεί $p=1$, τότε προκύπτει η λεγόμενη απόσταση L_1 ή απόσταση Manhattan, ενώ αν επιλεγθεί $p=2$, τότε προκύπτει η απόσταση L_2 η οποία είναι γνωστή και ως Ευκλείδεια απόσταση. Οι δύο αυτές περιπτώσεις είναι οι πιο συνήθεις, υπάρχει όμως δυνατότητα να χρησιμοποιηθούν και μεγαλύτερες τιμές του p . Όσο μεγαλύτερη είναι η τιμή του p , τόσο μεγαλύτερη βαρύτητα δίνεται στα χαρακτηριστικά τα οποία διαφέρουν πολύ μεταξύ των δύο προτύπων.

Μια ακόμη περίπτωση είναι να χρησιμοποιηθεί η απόσταση Minkowski για $p \rightarrow \infty$, η οποία συμβολίζεται ως L_∞ και ονομάζεται απόσταση *Chebyshev*:

$$MD_\infty(\mathbf{a}, \mathbf{x}_i) = \max_{f \in F} |\alpha_f - x_{if}|$$

Η απόσταση αυτή είναι ουσιαστικά η διαφορά μεταξύ των τιμών του χαρακτηριστικού στο οποίο τα δύο πρότυπα διαφέρουν περισσότερο μεταξύ τους.

Αν τώρα τα χαρακτηριστικά των προτύπων λαμβάνουν δυαδικές τιμές, μπορεί να χρησιμοποιηθεί απόσταση *Hamming*:

$$HD(\mathbf{a}, \mathbf{x}_i) = |\{j \mid \alpha_j \neq x_{ij}\}|$$

η οποία ουσιαστικά υπολογίζει τον αριθμό των σημείων στα οποία τα διανύσματα των δύο προτύπων διαφέρουν. Η απόσταση Hamming συμπίπτει με την απόσταση L_1 στην περίπτωση δυαδικών χαρακτηριστικών.

Αν τα χαρακτηριστικά λαμβάνουν διακριτές τιμές χρησιμοποιείται το μέτρο

$$D(\mathbf{a}, \mathbf{x}_i) = \sum_{f \in \mathcal{F}} d_f(\mathbf{a}_f, \mathbf{x}_{if})$$

όπου d_f είναι κάποια συνάρτηση απόστασης για το κάθε χαρακτηριστικό. Έτσι, χρησιμοποιώντας κάποιο από τα παραπάνω μετρικά δημιουργείται μια υπερσφαίρα με κέντρο το διάνυσμα του προτύπου \mathbf{a} και ακτίνα την απόσταση του k -οστού μακρύτερου γείτονα από το πρότυπο \mathbf{a} .

Ο τρόπος με τον οποίο θα προσδιοριστεί η τάξη του \mathbf{a} αξιοποιώντας τη γνώση για την τάξη των k κοντινότερων γειτόνων που περικλείονται στην υπερσφαίρα, παρουσιάζει επίσης ποικιλία. Η πιο απλή περίπτωση είναι να επιλεγθεί η τάξη κατά πλειοψηφία των k κοντινότερων γειτόνων. Μια πιο κομψή προσέγγιση είναι να σταθμιστούν οι ψήφοι των γειτόνων ως προς την απόστασή τους από το υπό ταξινόμηση πρότυπο, δηλαδή τα πιο κοντινά στο \mathbf{a} πρότυπα να επηρεάζουν περισσότερο το αποτέλεσμα. Οι ψήφοι που θα δίνονται σε κάθε τάξη y_j είναι επομένως [30]:

$$Vote(y_j) = \sum_{c=1}^k \frac{1}{[d(\mathbf{a}, \mathbf{x}_i)]^n} 1(y_j, y_c)$$

$$\text{όπου } 1(y_j, y_c) = \begin{cases} 1, & y_j = y_c \\ 0, & \text{αλλιώς} \end{cases}$$

και το n επιλέγεται από το χρήστη ανάλογα με το πόσο επιθυμεί να μειωθεί η επίδραση των μακρινότερων από τους k κοντινότερους γείτονες (συνήθως ισούται με 1). Μία άλλη προσέγγιση [Shepard, 1987] χρησιμοποιεί εκθετική μείωση της επίδρασης των μακρινότερων γειτόνων αντί του αντιστρόφου της απόστασης:


$$Vote(y_j) = \sum_{c=1}^k e^{-\frac{d(\mathbf{a}, \mathbf{x}_i)}{h}} 1(y_j, y_c)$$

Έτσι, με κάποιον από τους παραπάνω τύπους υπολογίζονται οι ψήφοι κάθε τάξης και το πρότυπο \mathbf{a} κατατάσσεται στην τάξη με τις περισσότερες ψήφους.

Όσον αφορά τώρα στη στατιστική συμπεριφορά του ταξινομητή, αυτός χαρακτηρίζεται μη βέλτιστος (suboptimal). Παρόλα αυτά έχει γίνει πολύ δημοφιλής, καθώς, ενώ δεν ανήκει στους ταξινομητές Bayes, ασυμπτωτικά (δηλ. για $k \rightarrow \infty$) προσεγγίζει τη βέλτιστη συμπεριφορά ενός ταξινομητή Bayes. Ενδεικτικά για την περίπτωση δύο τάξεων, η πιθανότητα σφάλματος του kNN , P_{kNN} προκύπτει:

$$P_B \leq P_{kNN} \leq P_B + \frac{1}{\sqrt{ke}}$$

όπου P_B η πιθανότητα σφάλματος ενός ταξινομητή Bayes, η οποία ως γνωστόν είναι ελάχιστη. Από τη σχέση αυτή είναι εμφανές ότι για μεγάλες τιμές του k η συμπεριφορά του ταξινομητή προσεγγίζει τη βέλτιστη [30]. Ωστόσο, είναι πιθανό στην πεπερασμένη περίπτωση η ταξινόμηση κοντινότερου γείτονα ($k=1$) να παρουσιάζει μικρότερη πιθανότητα σφάλματος απ' ό,τι η ταξινόμηση για μεγαλύτερο k [30]. Ενδεικτικά παρουσιάζουμε ένα συγκριτικό παράδειγμα στην Εικόνα 4.3:



Εικόνα 4.3: Περιοχές απόφασης που δημιουργεί ο αλγόριθμος κοντινότερων γειτόνων k -NN σε ένα δεδομένο σύνολο εκπαίδευσης με τρεις τάξεις, σε δύο διαφορετικές περιπτώσεις. (α) ταξινομητής ενός κοντινότερου γείτονα ($k=1$). (β) ταξινομητής 5 κοντινότερων γειτόνων ($k=5$) [30].

Υπολογιστική Πολυπλοκότητα

Ο σημαντικότερος περιορισμός της ταξινόμησης kNN είναι η πολυπλοκότητα της διαδικασίας προσδιορισμού των k κοντινότερων γειτόνων μεταξύ του συνόλου εκπαίδευσης. Η αναζήτηση των γειτόνων έχει πολυπλοκότητα της τάξης του $O(kN)$, είναι δηλαδή ψευδοπολυωνυμικού χρόνου, ενώ το πρόβλημα εντείνεται σε διανυσματικούς χώρους χαρακτηριστικών υψηλότερων διαστάσεων, κάνοντας τη λύση του ακόμη πιο δύσκολη [30, 183]. Για το λόγο αυτό έχουν αναπτυχθεί πολλές τεχνικές τόσο για το φιλτράρισμα των προτύπων του συνόλου εκπαίδευσης και τη μείωση της διαστασιμότητας των διανυσμάτων χαρακτηριστικών. Ένας άλλος τρόπος βελτίωσης της απόδοσης του ταξινομητή είναι η εύρεση κατάλληλων μέτρων απόστασης για το εκάστοτε σύνολο δεδομένων.

Συμπερασματικά, η μέθοδος των k Κοντινότερων Γειτόνων είναι μία μέθοδος που είναι απλή, κατανοητή και εύκολη στην υλοποίηση, της οποίας μάλιστα οι επιδόσεις είναι δυνατό να βελτιωθούν με χρήση τεχνικών για την αφαίρεση του θορύβου, αλλά και τη μείωση των απαιτήσεων μνήμης. Ωστόσο, χρειάζεται να βελτιωθεί η χρονική πολυπλοκότητά της, καθώς από τη φύση του αλγορίθμου kNN , όλος ο φόρτος εργασίας αντιμετωπίζεται κατά την εκτέλεση. Επίσης, η μέθοδος είναι ευαίσθητη σε άσχετα ή περιττά χαρακτηριστικά, καθώς όλα τα χαρακτηριστικά συμμετέχουν στο μέτρο της απόστασης, οπότε και απαιτούνται μέθοδοι για την επιλογή των κατάλληλων χαρακτηριστικών ή τη στάθμιση των χαρακτηριστικών. Γενικά, σε δύσκολες εργασίες ταξινόμησης, η μέθοδος kNN παραγκωνίζεται από άλλες τεχνικές όπως τα Νευρωνικά Δίκτυα ή οι Μηχανές Διανυσμάτων Υποστήριξης [30].


4.4.3 Μηχανές Διανυσμάτων Υποστήριξης (Support Vector Machines - SVM)

Εισαγωγή


Οι Μηχανές Διανυσμάτων Υποστήριξης (Support Vector Machines-SVM) ([29], [30]) είναι μια μέθοδος μηχανικής μάθησης για δυαδικά προβλήματα ταξινόμησης. Όπως συμβαίνει και με τα Νευρωνικά Δίκτυα, μία SVM εκπαιδεύεται με ένα σύνολο δεδομένων και έχει τη δυνατότητα από εκεί και πέρα να γενικεύει ταξινομώντας άγνωστα πρότυπα [5]. Η βασική αρχή στην οποία στηρίζεται η ανάπτυξη των SVM είναι η αντιστοίχιση των διανυσμάτων με κάποιο κριτήριο που επιλέγεται εξ αρχής σε έναν πολυδιάστατο χώρο χαρακτηριστικών [30]. Στο χώρο αυτό κατασκευάζεται μια γραμμική επιφάνεια απόφασης με ειδικές ιδιότητες ώστε ο ταξινομητής να έχει την ικανότητα να λειτουργεί στη γενική περίπτωση διανυσμάτων εισόδου [30]. Το πρόβλημα που τίθεται είναι η εύρεση/κατασκευή του βέλτιστου υπερεπιπέδου διαχωρισμού των τάξεων. Η λύση του προβλήματος αυτού διαφοροποιείται ανάλογα με το αν τα πρότυπα είναι γραμμικώς διαχωρίσιμα ή όχι [30].

Λειτουργία των SVM

Όπως ήδη γνωρίζουμε, τα προβλήματα ταξινόμησης είναι γενικά δύο κατηγοριών. Αυτά που είναι γραμμικά διαχωρίσιμα και αυτά που δεν είναι. Ανάλογα με τον τύπο του προβλήματος φτιάχνεται από τον ταξινομητή μία υπερεπιφάνεια διαχωρισμού των τάξεων η οποία είναι ένα υπερεπίπεδο για **γραμμικά προβλήματα**. Είπαμε, λοιπόν, ότι ένας ταξινομητής αρκεί να βρει μία ευθεία σε ένα γραμμικά διαχωρίσιμο πρόβλημα. Αν θεωρήσουμε την απόσταση μεταξύ της ευθείας αυτής και του πλησιέστερου σε αυτή προτύπου και την ονομάσουμε *περιθώριο διαχωρισμού* (margin), τότε η βέλτιστη ευθεία διαχωρισμού είναι αυτή που αντιστοιχεί στο μεγαλύτερο περιθώριο [3]. Αντίστοιχα, γενικεύοντας και για τις n διαστάσεις φτάνουμε στην έννοια του βέλτιστου υπερεπιπέδου. Θεωρητικά, όσο μεγαλύτερο είναι το περιθώριο που αντιστοιχεί στο βέλτιστο υπερεπίπεδο, τόσο πιο μεγάλη δυνατότητα γενίκευσης έχει η μηχανή που προκύπτει. Αυτά ισχύουν για γραμμικά διαχωρίσιμα προβλήματα. Για **μη-γραμμικά προβλήματα**, όπως αυτά που αναλύουμε στην παρούσα ενότητα της διπλωματικής εργασίας, η έννοια του βέλτιστου υπερεπιπέδου αλλάζει, αφού εδώ το σύνολο εκπαίδευσης είναι τέτοιο που δεν επιτρέπει την κατασκευή ενός υπερεπιπέδου διαχωρισμού, χωρίς να υπεισέλθουν σφάλματα στην ταξινόμηση και συνεπώς δεν γίνεται απευθείας διαχωρισμός των τάξεων [3], [30]. Στην περίπτωση αυτή, μπορούμε να πούμε ότι γενικά το έργο της ταξινόμησης είναι η εύρεση ενός βέλτιστου υπερεπιπέδου το οποίο να ελαχιστοποιεί την πιθανότητα λανθασμένης ταξινόμησης κατά μέσο όρο για ολόκληρο το σύνολο δεδομένων εκπαίδευσης [3]. Το περιθώριο διαχωρισμού μεταξύ των τάξεων χαρακτηρίζεται *ελαστικό* (soft) στην περίπτωση που ένα διάνυσμα είτε εμπίπτει στην περιοχή διαχωρισμού και στην σωστή πλευρά της επιφάνειας απόφασης (Σχήμα 4.11α), οπότε η ταξινόμηση είναι σωστή, είτε εμπίπτει στη λάθος πλευρά της επιφάνειας απόφασης (Σχήμα 4.11β), οπότε η ταξινόμηση αποτυγχάνει [30]. Για λόγους πληρότητας, απεικονίζεται στο Σχήμα 4.12 η έννοια του βέλτιστου υπερεπιπέδου για τα γραμμικώς διαχωρίσιμα πρότυπα.



Σχήμα 4.11: Υπερεπίπεδο ελαστικού περιθωρίου διαχωρισμού σε διδιάστατο χώρο [30]. (α) Το σημείο δεδομένων βρίσκεται στη σωστή πλευρά του υπερεπιπέδου αλλά εντός της περιοχής διαχωρισμού. (β) Το σημείο δεδομένων βρίσκεται στη λάθος πλευρά του υπερεπιπέδου.

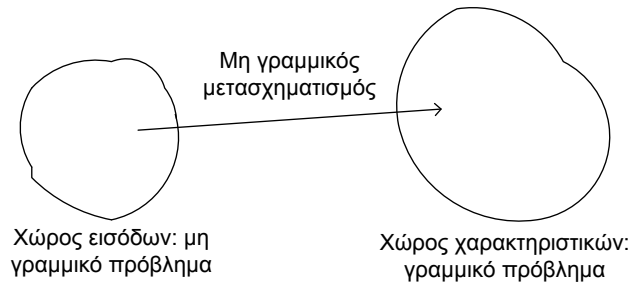


Σχήμα 4.12: Γραφική απεικόνιση της έννοιας του βέλτιστου υπερεπιπέδου για γραμμικά διαχωρίσιμα πρότυπα σε χώρο 2 διαστάσεων. Τα σημεία δεδομένων με μαύρο χρώμα είναι τα διανύσματα υποστήριξης [30].

Το υπερεπίπεδο «ελαστικού» περιθωρίου, λοιπόν, είναι μια επιφάνεια απόφασης η οποία διαχωρίζει τα δεδομένα εκπαίδευσης κάνοντας τα λιγότερα λάθη. Για το λόγο αυτό, εισάγονται στο πρόβλημα οι λεγόμενες *μεταβλητές χαλάρωσης* (slack variables), $\xi_i \geq 0$, οι οποίες αποτελούν μια εκτίμηση του σφάλματος του επιπέδου απόφασης για το i -οστό παράδειγμα εκπαίδευσης. Τέλος η μεταβλητή C καθορίζει πόσο αυστηροί είμαστε με τα λάθη της ταξινόμησης [30, 229].

Όσον αφορά, τώρα, την κατασκευή του βέλτιστου υπερεπιπέδου, υπάρχουν κάποια πρότυπα τα οποία παίζουν σημαντικό ρόλο σε αυτή τη διαδικασία. Αυτά λέγονται *διανύσματα υποστήριξης* (support vectors) από όπου προέρχεται και το όνομα του εν λόγω ταξινομητή. Συγκεκριμένα, τα διανύσματα υποστήριξης είναι αυτά τα πρότυπα που στο διανυσματικό χώρο κείτονται πλησιέστερα στην επιφάνεια διαχωρισμού, είναι δηλαδή πιο δύσκολο να ταξινομηθούν σωστά.

Περνάμε τώρα σε πιο λεπτομερείς έννοιες της υλοποίησης μίας SVM. Δύο βασικές μαθηματικές λειτουργίες γίνονται από μία SVM. Η πρώτη λειτουργία εκτελείται σύμφωνα με το θεώρημα του Cover για τη γραμμική διαχωρισιμότητα των προτύπων. Θεωρούμε ένα χώρο εισόδου που αποτελείται από μη γραμμικά διαχωρίσιμα πρότυπα. Το θεώρημα του Cover δηλώνει ότι ένας τέτοιος πολυδιάστατος χώρος μπορεί να μετασχηματιστεί σε ένα καινούργιο χώρο χαρακτηριστικών (feature space) όπου τα πρότυπα είναι γραμμικά διαχωρίσιμα με μεγάλη πιθανότητα όταν ικανοποιούνται δύο συνθήκες. Πρώτον, ο μετασχηματισμός να είναι μη γραμμικός και δεύτερον, η διάσταση του χώρου χαρακτηριστικών να είναι αρκετά ψηλή. Σύμφωνα με τα παραπάνω, λοιπόν, γίνεται αρχικά μία μη γραμμική απεικόνιση από το χώρο των εισόδων σε έναν υψηλότερης διάστασης χώρο χαρακτηριστικών που αποτελεί κάτι σαν ενδιάμεσο χώρο μεταξύ εισόδου και εξόδου [3]. Ο ενδιάμεσος χώρος χαρακτηριστικών είναι εσωτερικός του συστήματος, δηλαδή άγνωστος προς την είσοδο και την έξοδο και η διαστασιμότητά του καθορίζεται από τον αριθμό των διανυσμάτων υποστήριξης, ώστε να διασφαλίζεται η βέλτιστη ταξινόμηση [30]. Με την απεικόνιση αυτή είναι δυνατόν το πρόβλημα που θέλουμε να επιλύσουμε να γίνει γραμμικά διαχωρίσιμο [3]. Με άλλα λόγια, αν στο χώρο των εισόδων το πρόβλημα είναι μη γραμμικά διαχωρίσιμο, με την απεικόνιση αυτή είναι δυνατόν να πάρουμε έναν νέο χώρο εισόδων, τον χώρο των χαρακτηριστικών, όπου πια το πρόβλημα είναι γραμμικά διαχωρίσιμο και να δουλέψουμε εκεί (Σχήμα 4.13). Στο σημείο αυτό έρχεται η δεύτερη λειτουργία που δεν είναι άλλη από την κατασκευή του βέλτιστου υπερεπιπέδου διαχωρισμού για το νέο χώρο. Η διαχωριστική υπερεπιφάνεια ορίζεται τώρα ως μια γραμμική συνάρτηση από διανύσματα που εξάγεται από το χώρο χαρακτηριστικών (feature space) αντί από τον αρχικό χώρο εισόδου. Η κατασκευή της επιφάνειας αυτής εξαρτάται από τον υπολογισμό του *πυρήνα εσωτερικού γινομένου* (inner product kernel) [30]. Στην πράξη, οι SVM προβάλλουν τα σημεία του συνόλου εκπαίδευσης σε έναν χώρο περισσότερων διαστάσεων και βρίσκουν το υπερεπίπεδο το οποίο διαχωρίζει βέλτιστα τα σημεία των δύο τάξεων. Τα άγνωστα σημεία ταξινομούνται σύμφωνα με την πλευρά του υπερεπιπέδου στην οποία βρίσκονται, ενώ τα διανύσματα τα οποία ορίζουν το υπερεπίπεδο που χωρίζει τις δύο τάξεις είναι τα διανύσματα υποστήριξης (support vectors). Ουσιαστικά, δηλαδή, μετατρέπουμε ένα μη γραμμικά διαχωρίσιμο πρόβλημα σε ένα γραμμικά διαχωρίσιμο με μία μη γραμμική απεικόνιση και έπειτα βρίσκουμε το βέλτιστο υπερεπίπεδο του γραμμικού προβλήματος [3].



Σχήμα 4.13: Μη γραμμικός μετασχηματισμός $\phi(\cdot)$ από το χώρο εισόδου (input space) σε ένα χώρο χαρακτηριστικών (feature space). Με κατάλληλο μη γραμμικό μετασχηματισμό, είναι δυνατόν ένα μη γραμμικό πρόβλημα να μετατραπεί σε γραμμικό [3].

Προφανώς υπάρχουν πολλές δυνατές μη γραμμικές απεικονίσεις. Διάφοροι τύποι SVM μπορούν να προκύψουν ανάλογα με την απεικόνιση που επιλέγεται. Η απεικόνιση αυτή λέγεται αλλιώς και πυρήνας της SVM. Μερικοί τύποι πυρήνων είναι ο πολυωνυμικός, ο εκθετικός και ο πυρήνας υπερβολικής εφαπτομένης οι οποίοι χρησιμοποιούν τις ομώνυμες συναρτήσεις για το μη γραμμικό μετασχηματισμό. Οι αντίστοιχοι τύποι SVM που προκύπτουν από την επιλογή καθενός από αυτούς είναι η πολυωνυμική SVM, το δίκτυο ακτινικών συναρτήσεων βάσης (radial basis function network-RBF network) και το perceptron δύο επιπέδων [3]. Η επιλογή της κατάλληλης συνάρτησης πυρήνα για το εκάστοτε πρόβλημα είναι ιδιαίτερα σημαντική, δεδομένου ότι καθορίζει το διανυσματικό χώρο χαρακτηριστικών που προκύπτει από το μετασχηματισμό και στον οποίο θα πραγματοποιηθεί η ταξινόμηση των δεδομένων. Είναι κοινή πρακτική να δοκιμάζονται διάφορες μορφές συναρτήσεων πυρήνα εσωτερικού γινομένου. Η απόδοσή τους υπολογίζεται πειραματικά με τεχνικές επικύρωσης και με βάση την απόδοσή τους, επιλέγεται η κατάλληλη συνάρτηση [183].

Κλείνοντας την αναφορά μας στις SVM, αναφέρουμε ένα αξιοσημείωτο χαρακτηριστικό τους. Η υπολογιστική πολυπλοκότητα μιας SVM είναι ανεξάρτητη από την διάσταση του τελικού γραμμικού χώρου των χαρακτηριστικών που προκύπτει από το μη γραμμικό μετασχηματισμό και είναι υψηλότερης διάστασης από τον αρχικό χώρο των εισόδων. Αντίθετα, αυτό που χαρακτηρίζει την πολυπλοκότητα αυτών των μηχανών είναι ο αριθμός των διανυσμάτων υποστήριξης που προκύπτουν από τα δεδομένα. Πρακτικά, δηλ. η απόδοση των SVM εξαρτάται από την παράμετρο C και την παράμετρο του πυρήνα, καθώς αυτές οι παράμετροι καθορίζουν τον αριθμό των διανυσμάτων υποστήριξης και το περιθώριο μεγιστοποίησης του SVM. Το γεγονός αυτό, έχει σαν αποτέλεσμα να μην υπάρχει μεγάλος κίνδυνος εμφάνισης του προβλήματος του overfitting (υπερεκπαίδευσης), όπως στα Νευρωνικά Δίκτυα.

Μαθηματική Περιγραφή των SVM

Σε αυτήν την παράγραφο θα παραθέσουμε, για λόγους πληρότητας, σε αυστηρά μαθηματικό πλαίσιο, τους κανόνες και τους μαθηματικούς τύπους που περιγράφουν τη μέθοδο των SVM για τα μη γραμμικά διαχωρίσιμα πρότυπα και η οποία αποτελεί απαραίτητη προσθήκη για την ολοκληρωμένη ανάλυση του ταξινομητή.

Ας υποθέσουμε, λοιπόν, ότι υπάρχει μια αντιστοίχιση $x \in R^l \rightarrow y \in R^k$ από το χώρο των χαρακτηριστικών γνωρισμάτων εισόδου, σε ένα k -διάστατο χώρο, όπου οι τάξεις μπορούν να διαχωριστούν ικανοποιητικά από ένα υπερεπίπεδο. Στη συνέχεια, η μέθοδος SVM μπορεί να κινητοποιηθεί για το σχεδιασμό του ταξινομητή-

υπερεπιπέδου στο νέο k -διάστατο χώρο. Ωστόσο, υπάρχει μια κομψή ιδιότητα στη μεθοδολογία των SVM η οποία μπορεί να αξιοποιηθεί για την ανάπτυξη μιας πιο γενικής προσέγγισης. Αυτό θα μας επιτρέψει να πραγματοποιούμε απεικονίσεις ακόμη και σε χώρους άπειρων διαστάσεων, εάν απαιτείται.

Γνωρίζουμε ότι στους υπολογισμούς που συμπεριλαμβάνονται στη διπλή αναπαράσταση Wolfe, τα διανύσματα χαρακτηριστικών συμμετέχουν σε ζεύγη μέσω της διαδικασίας του εσωτερικού γινομένου. Επίσης, μόλις υπολογιστεί το βέλτιστο υπερεπίπεδο (\mathbf{w}, w_0), η ταξινόμηση εκτελείται σύμφωνα με το αν το πρόσημο του

$$g(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + w_0 = \sum_{i=1}^{N_s} \lambda_i y_i \mathbf{x}_i^T \mathbf{x} + w_0,$$

είναι $+$ ή $-$, όπου N_s ο αριθμός των *support vectors*. Έτσι, για άλλη μια φορά, μόνο τα εσωτερικά γινόμενα εισέρχονται στη σχέση. Εάν ο σχεδιασμός πρόκειται να λάβει χώρα στο νέο k -διάστατο χώρο, η μόνη διαφορά είναι ότι τα εμπλεκόμενα διανύσματα θα είναι οι k -διάστατες απεικονίσεις των αρχικών διανυσμάτων χαρακτηριστικών γνωρισμάτων εισόδου. Όπως αναφέρθηκε προηγουμένως, η πολυπλοκότητα δεν αυξάνεται, παρόλο που το k είναι πολύ υψηλότερο από τη διάσταση του χώρου εισόδου l . Ας δώσουμε τώρα ένα απλό παράδειγμα για να αποδείξουμε τον ισχυρισμό αυτό [2]. Υποθέτουμε ότι

$$x \in R^2 \rightarrow y = \begin{bmatrix} x_1^2 \\ \sqrt{2}x_1x_2 \\ x_2^2 \end{bmatrix}$$

Εύκολα αποδεικνύεται ότι

$$y_i^T y_j = (x_i^T x_j)^2$$

Με άλλα λόγια, το εσωτερικό γινόμενο των διανυσμάτων στο νέο (υψηλότερης διάστασης) χώρο, έχει εκφραστεί ως συνάρτηση του εσωτερικού γινομένου των αντίστοιχων διανυσμάτων στο αρχικό χώρο των διανυσμάτων χαρακτηριστικών (feature space).

Όσον αφορά τώρα τα μη-γραμμικά διαχωρίσιμα προβλήματα και τις μεταβλητές χαλάρωσης, ισχύει:

$$\min \left(\frac{\|\mathbf{w}\|^2}{2} + C \sum_{i=1}^N \xi_i \right)$$

με $\xi_i \geq 0$ και $y_i (\mathbf{w} \cdot \Phi(\mathbf{x}_i) + b) \geq 1 - \xi_i, i = 1, 2, \dots, N$

Θεώρημα του Mercer: Έστω $x \in R^l$ και μια απεικόνιση $\phi: x \rightarrow \phi(x) \in H$, όπου H είναι ένας χώρος Hilbert. Το εσωτερικό γινόμενο έχει μια ισοδύναμη απεικόνιση $\langle \phi(x) | \phi(x) \rangle = K(x, z)$, όπου $\langle \cdot | \cdot \rangle$ δηλώνει το εσωτερικό γινόμενο στο χώρο H και $K(x, z)$ είναι μια συνεχής συμμετρική συνάρτηση που ικανοποιεί την παρακάτω συνθήκη:

$$\int_C \int_C K(x, z) g(x) g(z) dx dz \geq 0 \quad (1), \quad \text{για κάθε } g(x), x \in C \subset R^l \text{ τέτοια ώστε}$$

$$\int_C g(x)^2 dx < +\infty \quad (2), \quad \text{όπου } C \text{ ένα γνήσιο υποσύνολο του } R^l. \text{ Το αντίθετο είναι πάντα}$$

αληθές, δηλαδή για κάθε συνεχή, συμμετρική συνάρτηση $K(x, z)$, η οποία ικανοποιεί τις σχέσεις (1) και (2), υπάρχει ένας χώρος στον οποίο η $K(x, z)$ ορίζει ένα εσωτερικό γινόμενο. Τέτοιες συναρτήσεις είναι γνωστές και ως πυρήνες (kernels) και ο χώρος H , ως Reproducing kernel Hilbert space (RKHS). Αυτό, όμως, που το θεώρημα του Mercer δεν μας αποκαλύπτει είναι πώς να βρούμε αυτό το χώρο. Δηλαδή, δεν έχουμε ένα γενικό εργαλείο για να κατασκευάσουμε την απεικόνιση $\phi(\cdot)$ όταν γνωρίζουμε το εσωτερικό γινόμενο του αντίστοιχου χώρου. Επιπλέον, δεν διαθέτουμε τα μέσα για να γνωρίζουμε την διάσταση του χώρου, η οποία μπορεί ακόμη και να είναι άπειρη [2].

Τυπικά παραδείγματα πυρήνων (kernels) που χρησιμοποιούνται σε εφαρμογές αναγνώρισης προτύπων είναι όπως αναφέραμε τα εξής:

- Πολυωνυμική: $K(x, z) = (x^T z + 1)^q, q > 0$
- Συνάρτηση Ακτινικής Βάσης (Radial Basis Function): $K(x, z) = \exp\left(\frac{\|x-z\|^2}{\sigma^2}\right)$
- Υπερβολική Εφαπτομένη (Hyperbolic Tangent): $K(x, z) = \tanh(\beta x^T z + \gamma)$, για τιμές των β, γ ώστε να ικανοποιούνται οι συνθήκες του θεωρήματος Mercer. Για παράδειγμα δύο αποδεκτές τιμές είναι $\beta=2, \gamma=1$.

Όταν υιοθετηθεί η κατάλληλη συνάρτηση πυρήνα, ορίζει μια απεικόνιση σε ένα υψηλότερο διαστάσεων χώρο (RKHS) και έτσι:


$$\max_{\lambda} \left(\sum_i \lambda_i - \sum_{i,j} \lambda_i \lambda_j y_i y_j K(x_i, x_j) \right), \text{ όπου } 0 \leq \lambda_i \leq C, i = 1, 2, \dots, N \text{ και}$$

$$\sum_i \lambda_i y_i = 0$$


και ο προκύπτων γραμμικός (στον RKHS) ταξινομητής είναι:

$$\text{assign } x \text{ in } \omega_1 \text{ (ή } \omega_2) \text{ if } g(x) = \sum_{i=1}^{N_s} \lambda_i y_i K(x_i, x) + \omega_0 > \text{ (ή } <) 0$$

Λόγω της μη γραμμικότητας της συνάρτησης πυρήνα, ο ταξινομητής που προκύπτει είναι μη γραμμικός στον αρχικό χώρο R^l . Παρόμοια επιχειρήματα ισχύουν και για την ν -SVM διατύπωση. Παρακάτω παρουσιάζονται δύο σχήματα για την κατανόηση της περιγραφόμενης μεθόδου. Το Σχήμα 4.14 δείχνει την αντίστοιχη αρχιτεκτονική των SVM. Ο αριθμός των κόμβων καθορίζεται από τον αριθμό των διανυσμάτων υποστήριξης N_s . Οι κόμβοι εκτελούν τα εσωτερικά γινόμενα μεταξύ της απεικόνισης του x και των αντίστοιχων απεικονίσεων των διανυσμάτων υποστήριξης στον χώρο μεγάλης διάστασης, μέσω της συνάρτησης πυρήνα. Η Εικόνα 4.4 δείχνει τον SVM ταξινομητή που προκύπτει για δύο μη γραμμικώς διαχωρίσιμες τάξεις, όπου χρησιμοποιήθηκε η Γκαουσιανή συνάρτηση πυρήνα ακτινικής βάσης, με $\sigma=1.75$. Οι διακεκομμένες γραμμές σημειώνουν το *περιθώριο* (margin) και τα κυκλωμένα σημεία τα *διανύσματα υποστήριξης* (support vectors).



Σχήμα 4.14: Η αρχιτεκτονική της SVM, χρησιμοποιώντας συναρτήσεις πυρήνα [2].



Εικόνα 4.4: Παράδειγμα ενός μη γραμμικού ταξινομητή SVM για την περίπτωση των δύο μη γραμμικώς διαχωρίσιμων τάξεων. Χρησιμοποιήθηκε η Γκαουσιανή συνάρτηση πυρήνα ακτινικής βάσης (RBF). Οι διακεκομμένες γραμμές σημειώνουν το περιθώριο και τα κυκλωμένα σημεία τα διανύσματα υποστήριξης [2].

Πλεονεκτήματα των SVM

1. **Μεγιστοποίηση της δυνατότητας γενίκευσης.** Οι SVM εκπαιδεύονται ώστε να μεγιστοποιεί το περιθώριο, επομένως η ικανότητα γενίκευσης διατηρείται ακόμα σε περιπτώσεις αραιών και γραμμικώς διαχωρίσιμων δεδομένων [183, 228].
2. **Αποφυγή τοπικών ελαχίστων.** Οι SVM αποφεύγουν τα τοπικά ελάχιστα διότι διατυπώνονται ως προβλήματα τετραγωνικού προγραμματισμού, οπότε η μέθοδος καταλήγει σε γενική βέλτιστη λύση. Άλλες κατηγορίες ταξινομητών, (όπως τα νευρωνικά δίκτυα) ενδεχομένως να παγιδεύονται σε τοπικά ελάχιστα και το γεγονός αυτό απαιτεί ειδική μέριμνα για την αποφυγή τους κατά τη διάρκεια της εκπαίδευσης [183, 228].
3. **Ευρύ φάσμα εφαρμογών.** Η ικανότητα γενίκευσης των SVM ρυθμίζεται αλλάζοντας τη συνάρτηση πυρήνα, μια παράμετρό της ή αλλάζοντας το περιθώριο. Πέρα από τις συνηθέστερες συναρτήσεις πυρήνα υπάρχει η δυνατότητα ανάπτυξης συνάρτησης πυρήνα συγκεκριμένα για μια δοσμένη εφαρμογή, βελτιώνοντας με αυτόν τον τρόπο την ικανότητα γενίκευσης. Τα νευρωνικά δίκτυα είναι περισσότερο περιορισμένα σε σιγμοειδείς συναρτήσεις και σε συναρτήσεις ακτινικής βάσης ως συναρτήσεις ενεργοποίησης για τους νευρώνες [183, 228].

4. **Ευρωστία σε ακραίες τιμές δεδομένων.** Το σφάλμα λανθασμένης ταξινόμησης στις SVM μπορεί να ελεγχθεί από την παράμετρο C . Αν η παράμετρος αυτή πάρει μεγάλες τιμές, η λανθασμένη ταξινόμηση μπορεί να περιοριστεί και αν οι τιμές της είναι μικρές δεδομένα εκπαίδευσης που απέχουν πολύ από τα δεδομένα που έχουν συλλεχθεί επιτρέπουν στο μοντέλο να τα ταξινομήσει εσφαλμένα. Συνεπώς, θέτοντας μια κατάλληλη τιμή στην παράμετρο C περιορίζονται οι ακραίες τιμές των δεδομένων εκπαίδευσης (outliers). Επίσης με τον τρόπο αυτό μπορεί να περιοριστεί το πρόβλημα της υπερπροσαρμογής [183, 228].


Μειονεκτήματα των SVM

1. **Επέκταση σε προβλήματα ταξινόμησης πολλών κλάσεων.** Οι SVM είναι δυαδικοί ταξινομητές. Σε αντίθεση με τα πολυεπίπεδα νευρωνικά δίκτυα, χρησιμοποιούν άμεσες συναρτήσεις απόφασης, επομένως η επέκταση σε προβλήματα ταξινόμησης πολλών τάξεων δεν μπορεί να πραγματοποιηθεί απευθείας. Μπορεί να γίνει χρήση τεχνικών για τη μετατροπή προβλημάτων ταξινόμησης πολλών τάξεων σε προβλήματα δυαδικής ταξινόμησης (one-against-all, all-pairs, error-correcting output codes) [228].
2. **Μεγάλη διάρκεια εκπαίδευσης.** Δεδομένου ότι η διαδικασία εκπαίδευσης μιας SVM πραγματοποιείται επιλύοντας το αντίστοιχο δυϊκό πρόβλημα βελτιστοποίησης, ο αριθμός των μεταβλητών ισούται με το πλήθος των δειγμάτων εκπαίδευσης. Συνεπώς, για ένα μεγάλο πλήθος δεδομένων εκπαίδευσης, η λύση του δυϊκού προβλήματος απαιτεί αρκετή μνήμη και χρόνο εκτέλεσης για τους υπολογισμούς [228].
3. **Επιλογή παραμέτρων.** Κατά την εκπαίδευση της SVM θα πρέπει να επιλεγεί η κατάλληλη συνάρτηση πυρήνα και στη συνέχεια οι τιμές των παραμέτρων της. Ωστόσο, μέχρι τώρα δεν έχει υπάρξει αποτελεσματική πρακτική μέθοδος για την επιλογή της καλύτερης συνάρτησης πυρήνα. Επίσης, μόλις υιοθετηθεί μια συνάρτηση πυρήνα, οι λεγόμενες παράμετροι πυρήνα (π.χ. σ για τον Gaussian kernel), καθώς και η παράμετρος εξομάλυνσης C , στη συνάρτηση κόστους, επιλέγονται έτσι ώστε να μπορεί να βελτιστοποιηθεί η απόδοση σφάλματος του προκύπτοντος ταξινομητή. Η εύρεση των βέλτιστων παραμέτρων για ένα πρόβλημα ονομάζεται *επιλογή μοντέλου*. Για τις SVM η επιλογή μοντέλου γίνεται εκπαιδεύοντας διαρκώς ταξινομητές με διαφορετικές τιμές παραμέτρων. Στη συνέχεια αξιολογείται η ικανότητα γενίκευσής τους πειραματικά και επιλέγονται οι βέλτιστες τιμές. Επομένως, η επιλογή των παραμέτρων απαιτεί αρκετό χρόνο για την εκτέλεσή της και για το λόγο αυτό έχουν προταθεί δείκτες για τον υπολογισμό της απόδοσης μιας συγκεκριμένης επιλογής παραμέτρων, δίχως να απαιτείται η εκπαίδευση και ο έλεγχος απόδοσης του ταξινομητή [228].

4.4.4 Αλγόριθμος Ασαφών C-Μέσων (Fuzzy C-means algorithm)

Συσταδοποίηση (Clustering)

Η συσταδοποίηση (clustering) ορίζεται ως η οργάνωση μίας συλλογής προτύπων σε ομάδες με παρόμοια χαρακτηριστικά. Αυτό επιτυγχάνεται μέσω της εύρεσης ομοιοτήτων μεταξύ των προτύπων σύμφωνα με ένα αντικειμενικά επιλεγμένο μέτρο ομοιότητας. Οι ομάδες αυτές ονομάζονται *συστάδες* (clusters). Τα πρότυπα που αποτελούν μία συστάδα είναι πιο όμοια μεταξύ τους, σε σχέση με άλλα πρότυπα τα οποία ανήκουν σε άλλη συστάδα [230]. Η συσταδοποίηση ανήκει στις τεχνικές μη επιβλεπόμενης μάθησης, δηλαδή δοθέντων κάποιων δεδομένων χωρίς κλάσεις, οι αλγόριθμοι συσταδοποίησης ομαδοποιούν τα δεδομένα σε συστάδες, έτσι ώστε εγγραφές, οι οποίες ανήκουν στην ίδια συστάδα, να έχουν όμοια ή παραπλήσια χαρακτηριστικά. Η Εικόνα 4.5 αποτελεί μία συνοπτική παρουσίαση των βασικών σταδίων μίας διαδικασίας συσταδοποίησης. Σε αυτό παρουσιάζονται τα αρχικά δεδομένα από τα οποία εξάγονται τα κύρια χαρακτηριστικά τους. Στη συνέχεια και με βάση κάποιο αλγόριθμο συσταδοποίησης, πραγματοποιείται η διαδικασία της ομαδοποίησης των κυριότερων χαρακτηριστικών, με απώτερο σκοπό την ταξινόμησή τους και την ερμηνεία του αποτελέσματος ανάλογα με το γνωστικό αντικείμενο [230].



Εικόνα 4.5: Βήματα συσταδοποίησης [230].

Οι μέθοδοι συσταδοποίησης που έχουν προταθεί/χρησιμοποιηθεί στα διάφορα επιστημονικά πεδία, διαχωρίζονται στις παρακάτω κατηγορίες:

- Ιεραρχική Συσταδοποίηση
- Διαμεριστική Συσταδοποίηση (C-Means)
- Συσταδοποίηση βασισμένη στην πυκνότητα
- Πιθανοτική Συσταδοποίηση (Συνδυασμός Γκαουσιανών μοντέλων)

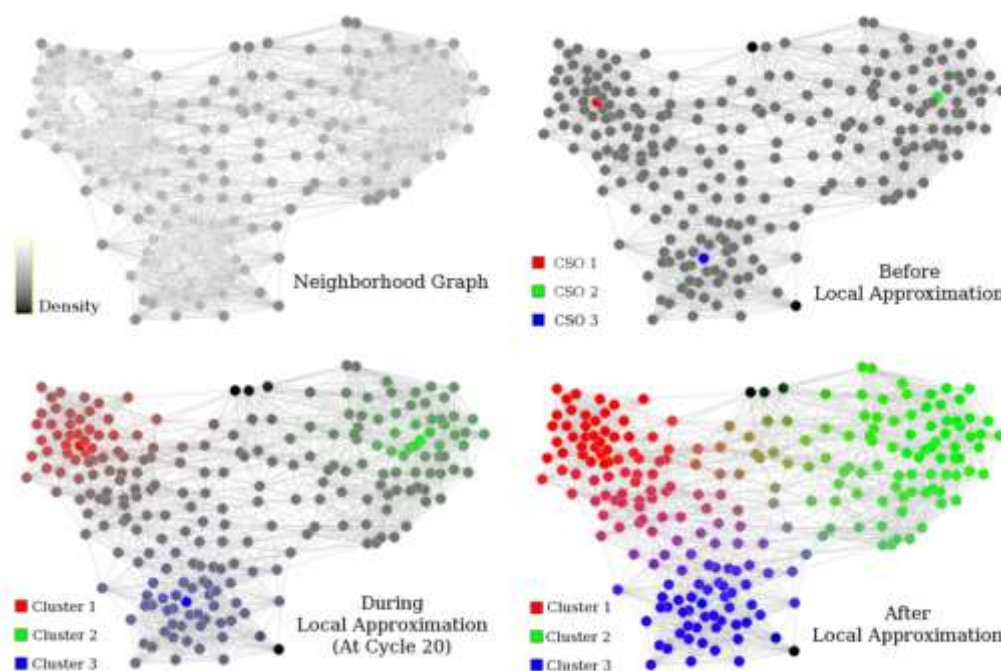
Τα δεδομένα αποτελούν μία βασική παράμετρο των τεχνικών συσταδοποίησης, καθώς η φύση τους και ο τρόπος μοντελοποίησής τους παίζει χαρακτηριστικό ρόλο κατά τη συσταδοποίηση. Επίσης, ιδιαίτερο στοιχείο ενός αλγορίθμου συσταδοποίησης είναι η έννοια της απόστασης. Η χρήση ενός συγκεκριμένου τύπου

απόστασης εξαρτάται και αυτή από τη μορφή των δεδομένων και το αποτέλεσμα που δίνει, αντικατοπτρίζει την έννοια της ομοιότητας ή ανομοιότητας που υπάρχει ανάμεσά τους [231].

Ο δυαδικός χαρακτήρας της κλασσικής συσταδοποίησης, δηλαδή το να ανήκει ή να μην ανήκει ένα πρότυπο σε μία συστάδα, μερικές φορές αποτελεί τροχοπέδη για την επίλυση ορισμένων προβλημάτων. Σε μία διαδικασία συσταδοποίησης, τα δεδομένα μπορεί να συντελούν στη δημιουργία μίας συμπαγούς συστάδας, διευκολύνοντας έτσι τον αλγόριθμο στην εξαγωγή έγκυρων αποτελεσμάτων. Ωστόσο, δύναται να υπάρχουν δεδομένα τα οποία να μην είναι εμφανές σε ποια συστάδα ανήκουν και γι' αυτό η διαδικασία της συσταδοποίησής τους να χρειάζεται μία διαφορετική προσέγγιση. Οι κλασσικοί αλγόριθμοι συσταδοποίησης που προαναφέρθηκαν δεν μπορούν να διαχειριστούν αυτού του είδους την *ασάφεια* [231].

Για το λόγο αυτό, επιστρατεύτηκαν έννοιες από τη θεωρία ασαφών συνόλων που εμπλέκουν μέσα τους την ιδέα της *μερικής συμμετοχής* (partial membership), δηλαδή ένα πρότυπο να ανήκει μερικώς σε μία συστάδα και μερικώς σε άλλες με ποσοτικές εκφράσεις (*βαθμοί συμμετοχής*). Με αυτό τον τρόπο η ασάφεια φαίνεται να είναι πολύ χρήσιμη έννοια αφού συχνά οι συστάδες δεν είναι εύκολα διαχωρίσιμες λόγω παρουσίας θορύβου ή λανθασμένης επιλογής χαρακτηριστικών. Η *ασαφής συσταδοποίηση* (fuzzy clustering) προσφέρει μία πιο λεπτομερή επεξεργασία μέσα από τους βαθμούς συμμετοχής του κάθε προτύπου σε κάθε συστάδα.

Ένα παράδειγμα εφαρμογής της μεθόδου Ασαφούς Συσταδοποίησης παρουσιάζεται στην Εικόνα 4.6, όπου φαίνονται συνοπτικά τα βήματα του ασαφούς αλγορίθμου. Στο τελικό αποτέλεσμα (κάτω δεξιά) η κωδικοποίηση του «που ανήκει το κάθε δεδομένο (κουκκίδα)» γίνεται μέσω της ανάθεσης κάποιου χρωματικού κώδικα σε αυτό. Όπως παρατηρείται, στα σύνορα των ομάδων/συστάδων έχουν ανατεθεί χρωματικοί κώδικες οι οποίοι ουσιαστικά αποτελούν μείξη των αντίστοιχων από τις δύο πλησιέστερες συστάδες. Έτσι, γίνεται αντιληπτό ότι η διαδικασία της ασαφούς συσταδοποίησης εμπεριέχει την αβεβαιότητα η οποία περιβάλλει τα αρχικά δεδομένα.




Εικόνα 4.6: Μέθοδος Ασαφούς Συσταδοποίησης [230].

Αλγόριθμος Ασαφών C-Μέσων (Fuzzy C-Means - FCM)

Η πιο διαδεδομένη μέθοδος ασαφούς ανάλυσης συστάδων είναι ο αλγόριθμος Ασαφών C-Μέσων (Fuzzy C-Means). Ο αλγόριθμος αυτός, ανήκει στην ευρύτερη οικογένεια των αλγορίθμων ασαφούς συσταδοποίησης (fuzzy clustering) η οποία βασίζεται στην ασαφή λογική (fuzzy logic), στην ιδέα δηλαδή ότι ένα πρότυπο μπορεί να ανήκει ταυτόχρονα σε περισσότερες από μια τάξεις. Αυτή η θεώρηση αντιπροσωπεύει ουσιαστικά την κατάσταση όπου η γνώση είναι προσεγγιστική, όπως συμβαίνει πολύ συχνά και στην ανθρώπινη νόηση [30].

Στόχος του αλγορίθμου Ασαφών C-Μέσων είναι να ελαχιστοποιήσει μία συνάρτηση κόστους που μετρά το βαθμό «μη ομοιότητας» ενός προτύπου σε μία συστάδα. Η βασική ιδέα σε μία τέτοια προσέγγιση, είναι ότι ένα πρότυπο ανήκει σε όλες τις συστάδες με διαφορετικό βαθμό συμμετοχής, όπου το άθροισμα των βαθμών είναι μονάδα, όπως και στους περισσότερους ασαφείς αλγορίθμους [230]. Πιο συγκεκριμένα, στον αλγόριθμο FCM, κάθε μέτρηση από τα δεδομένα ανήκει σε κάποια συστάδα (cluster) με κάποιο βαθμό που καθορίζεται από ένα πίνακα συμμετοχών. Τα δεδομένα αποθηκεύονται σε ένα 2D πίνακα X , ενώ το πλήθος των συστάδων καθώς και ο συντελεστής ασάφειας καθορίζονται σε αρχικό στάδιο. Στη συνέχεια, μέσω μίας επαναληπτικής διαδικασίας υπολογίζονται τα κεντροειδή των συστάδων βάσει των οποίων γίνεται η συσταδοποίηση κι έπειτα δημιουργείται ο πίνακας των βαθμών συμμετοχής των στοιχείων του X σε κάθε συστάδα [230].

Το σχήμα των συστάδων χαρακτηρίζεται από τις παραμέτρους που υιοθετούνται, όπως φαίνεται στο Σχήμα 4.15 Σε κάθε συστάδα αντιστοιχίζεται ανάλογα με το σχήμα της ένας «εκπρόσωπος» (κεντροειδής), οπότε η απόσταση ενός διανύσματος x από μία συστάδα ορίζεται ως η απόσταση του x από το αντίστοιχο κεντροειδές.



Σχήμα 4.15: (α) Συμπαγής συστάδα με εκπρόσωπο ένα σημείο. (β) Γραμμική συστάδα με εκπρόσωπο ένα υπερεπίπεδο. (γ) Υπερσφαιρική συστάδα με εκπρόσωπο μία υπερσφαίρα [30].

Ας προχωρήσουμε τώρα στη μαθηματική διατύπωση του μοντέλου. Η κατασκευή του αλγορίθμου είναι τέτοια ώστε να ικανοποιούνται κάποιες ιδιαίτερες συνθήκες. Ειδικότερα, θα πρέπει για όλα τα πρότυπα του αρχικού συνόλου δεδομένων να ισχύει:

$$\sum_{i=1}^c u_{ik} = 1, \forall k \quad (1)$$

$$0 < \sum_{k=1}^n u_{ik} < n \quad (2)$$

$U=[u_{ik}]$, $i=1, \dots, c$, $k=1, \dots, n$, όπου u_{ik} είναι ο βαθμός συμμετοχής του προτύπου k σε μια συστάδα.

Τα πρότυπα-αντικείμενα (διανύσματα) που περιέχονται σε μία συστάδα C_i είναι περισσότερο όμοια μεταξύ τους και λιγότερο όμοια με αυτά που βρίσκονται σε άλλες συστάδες. Η ομοιότητα αυτή είναι θεμελιώδης έννοια στον ορισμό μίας συστάδας και ένα μέτρο για την ομοιότητα μεταξύ δύο προτύπων με τα ίδια χαρακτηριστικά είναι βασικό στις περισσότερες διαδικασίες συσταδοποίησης [230].

Όπως και σε κάθε αλγοριθμική προσέγγιση, στο γενικότερο πρόβλημα της συσταδοποίησης, η ύπαρξη μίας συνάρτησης κόστους προς ελαχιστοποίηση είναι κρίσιμη για την εγκυρότητα του τελικού αποτελέσματος. Η συνάρτηση κόστους που προσπαθεί να ελαχιστοποιήσει ο αλγόριθμος υπολογίζεται από την παρακάτω σχέση [230, 232]:

$$J = \sum_{i=1}^c \sum_{k=1}^n u_{ik}^m d_{ik}^2(v_i, x_k) \quad (3)$$

Για τον υπολογισμό του κεντροειδούς κάθε συστάδας λαμβάνεται υπόψη η τιμή του κάθε προτύπου της συστάδας και ο βαθμός με τον οποίο ανήκει σε αυτή. Το κεντροειδές δίνεται από την παρακάτω σχέση:

$$v_i = \frac{\sum_{k=1}^n u_{ik}^m x_k}{\sum_{k=1}^n u_{ik}^m} \quad (4)$$

Ο υπολογισμός του βαθμού συμμετοχής ενός προτύπου, ο οποίος πρέπει να ικανοποιεί τις σχέσεις (1) και (2), σε μία συστάδα δίνεται από τον τύπο:

$$v_{ik}(x) = \frac{1}{\sum_{j=1}^c \left(\frac{d(v_i, x_k)}{d(v_j, x_k)} \right)^{\frac{2}{m-1}}} \quad (5)$$

όπου d είναι μία μετρική συνάρτηση που υπολογίζει την απόσταση μεταξύ του κεντροειδούς της συστάδας και του υπό εξέταση προτύπου και m είναι η παράμετρος «ασάφειας» (fuzzy coefficient) η οποία καθορίζει το πόσο ασαφής είναι η τιμή της $u(x)$, με $m \geq 1$.

Όταν το m πάρει τιμές κοντά στο 1, τότε το κεντροειδές της συστάδας που είναι κοντά στο εκάστοτε πρότυπο έχει περισσότερη συμμετοχή. Από την άλλη πλευρά όμως, για πολύ μεγάλες τιμές του m , όλα τα πρότυπα θα έχουν τον ίδιο βαθμό συμμετοχής σε όλες τις συστάδες. Συνήθως μία τιμή κοντά στο 2 δίνει καλά αποτελέσματα.

Ανάλυση σταδίων αλγορίθμου

Ο αλγόριθμος *FCM* διαχωρίζει ένα σύνολο προτύπων σε συστάδες με κάποιο βαθμό που καθορίζεται από ένα πίνακα συμμετοχής. Η διαδικασία αυτή εκτελείται επαναληπτικά μέχρις ότου να ελαχιστοποιηθεί μία συγκεκριμένη συνάρτηση κόστους. Κατά την εκτέλεσή της, υπολογίζονται τα κεντροειδή των συστάδων και στη συνέχεια σύμφωνα με αυτά υπολογίζεται η απόσταση μεταξύ των προτύπων και των κεντροειδών των συστάδων. Επομένως, τα πρότυπα «κατανέμονται» σε

συστάδες, με βαθμούς συμμετοχής ανάλογους της απόστασης που απέχουν από την αντίστοιχη συστάδα.

Η επαναληπτική διαδικασία που υλοποιείται μέσω του αλγόριθμου *FCM* αναλύεται σε στάδια προκειμένου να γίνει περισσότερο κατανοητή η μεθοδολογία η οποία ακολουθείται [231].

1. Στο πρώτο βήμα, είναι απαραίτητος ο καθορισμός του πλήθους των ασαφών συστάδων, της παραμέτρου ασάφειας m , καθώς και η αρχικοποίηση των κεντροειδών των συστάδων.
2. Στη συνέχεια, αρχικοποιείται ο πίνακας των βαθμών συμμετοχής $U^0 = [u_{ik}]^0$ ο οποίος όπως προαναφέρθηκε πρέπει να ικανοποιεί τις σχέσεις (1) και (2).
3. Με βάση τον πίνακα U υπολογίζονται τα κεντροειδή των συστάδων $V^{(n)} = [v_i]$

$$v_i = \frac{\sum_{k=1}^n u_{ik}^m x_k}{\sum_{k=1}^n u_{ik}^m} \quad (4.7)$$

4. Ακολούθως, γίνεται ενημέρωση των πινάκων $U^{(n)}$, $U^{(n+1)}$ εφόσον υπολογιστούν οι αποστάσεις μεταξύ των προτύπων και των κεντροειδών των συστάδων.

$$v_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{d(v_i, x_k)}{d(v_j, x_k)} \right)^{\frac{2}{m-1}}}$$

Σε κάθε βήμα, δηλαδή, το πρότυπο εκπαίδευσης που εξετάζεται «συμμετέχει» σε κάθε μια από τις κατηγορίες ανάλογα με την ευκλείδεια απόσταση από τα κέντρα των κατηγοριών αυτών [5]. Η ευκλείδεια απόσταση δίνεται από την σχέση

$$d^2(\bar{x}, \bar{w}) = \|\bar{x} - \bar{w}\|^2$$

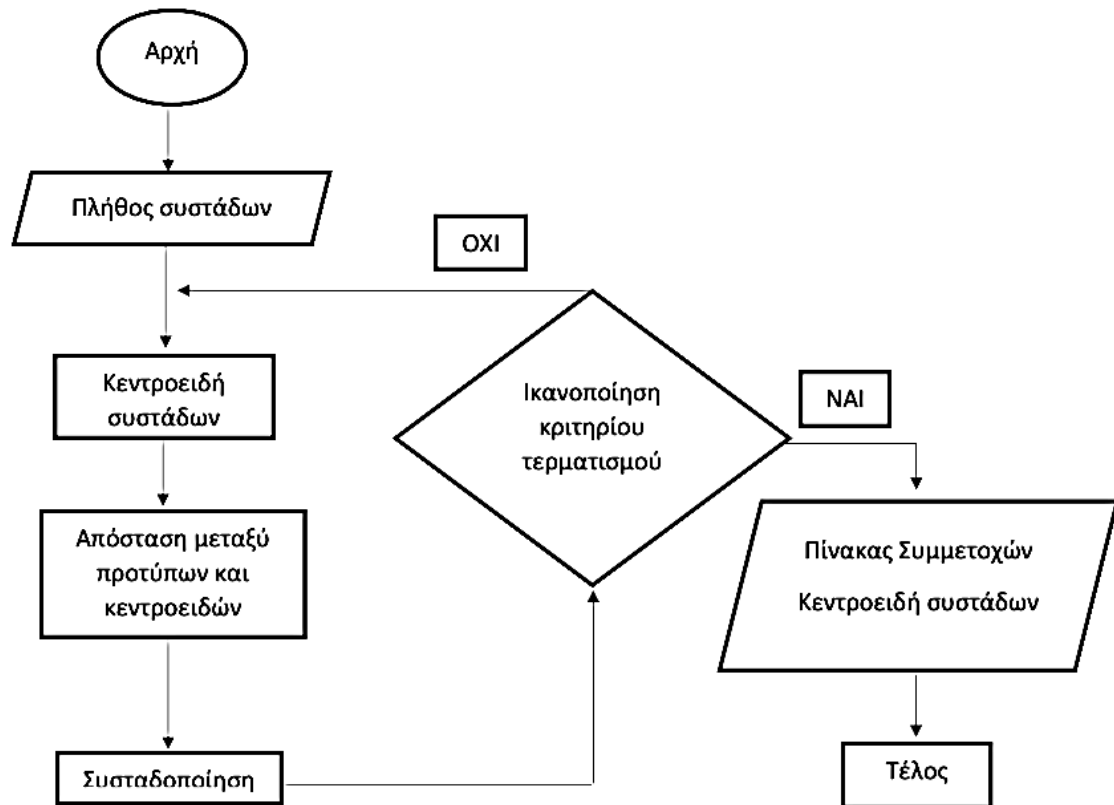
όπου \bar{x} το πρότυπο που εξετάζεται και \bar{w} είναι το κέντρο κάθε κατηγορίας. Μετά την εμφάνιση του κάθε προτύπου, τα κέντρα των κατηγοριών μετατοπίζονται προς την κατεύθυνση του προτύπου με ορμή ανάλογη με τον βαθμό συμμετοχής που τις αντιστοιχεί. Όταν επιδειχθούν όλα τα πρότυπα, τα κέντρα σταθεροποιούνται οπότε κάθε πρότυπο ανήκει στην κατηγορία με την μικρότερη ευκλείδεια απόσταση [5].

5. Όπως παρουσιάζεται και στο σχήμα 4.5 αν η συνάρτηση κόστους $J(U, v_1, \dots, v_c)$ ελαχιστοποιηθεί ο αλγόριθμος σταματάει, διαφορετικά επιστρέφει στο 3^ο βήμα και επαναλαμβάνεται η ίδια διαδικασία με τα νέα U και V .

Ο αλγόριθμός αυτός δίνει μεγάλη ευελιξία στην περιγραφή της κατανομής των προτύπων στις ομάδες, ενώ παράλληλα αποφεύγεται η δυσκολία που δημιουργείται όταν υπάρχει επικάλυψη δύο ομάδων. Είναι προφανές ότι ο αλγόριθμός έχει μεγαλύτερη απόδοση όταν τα δεδομένα είναι σε μορφή «νεφών» δηλαδή τα δεδομένα κάθε ομάδας είναι κοντά μεταξύ τους και μακριά από τα δεδομένα άλλων ομάδων. Σε αυτές τις περιπτώσεις τα ποσοστά ορθής ομαδοποίησης γίνονται υψηλά.

Έχει αποδειχθεί ότι ο *FCM* συγκλίνει πάντα. Έχει όμως το μειονέκτημα ότι για διαφορετικές αρχικές τιμές μπορεί να οδηγήσει σε διαφορετικά τοπικά ελάχιστα.

Παρόλα αυτά, είναι ο πιο διαδομένος αλγόριθμος στη θεωρία της ασαφούς συσταδοποίησης δεδομένων, γιατί είναι απλός, συγκλίνει πολύ εύκολα και όπως έχουν δείξει οι μέχρι τώρα εφαρμογές, μπορεί να πετύχει πολύ ικανοποιητικά αποτελέσματα [233]. Στη συνέχεια παρουσιάζεται ένα διάγραμμα με τα βήματα του αλγορίθμου ασαφών C-μέσων (σχήμα 4.16):



Σχήμα 4.16: Βήματα αλγορίθμου FCM [230].

4.5 Παραδείγματα άλλων ταξινομητών

Με την παραπάνω παράγραφο για τον αλγόριθμο των ασαφών C-μέσων, ολοκληρώθηκε η ανάλυση των βασικών αλγορίθμων που χρησιμοποιούνται ευρέως στα προβλήματα ταξινόμησης. Στη συνέχεια, θα αφιερώσουμε την τελευταία ενότητα του 4ου κεφαλαίου στην συνοπτική παρουσίαση κάποιων επιπλέον ταξινομητών οι οποίοι χρησιμοποιήθηκαν στις πειραματικές μεθοδολογίες εξαγωγής χαρακτηριστικών του κεφαλαίου 3. Αυτές οι μέθοδοι ταξινόμησης είναι τα Least Square – SVM, ο ταξινομητής τυχαίου δάσους και οι μηχανές ακραίας μάθησης.

4.5.1 Least Square - SVM

Τα LS-SVM είναι μια τεχνική που προτάθηκε πρόσφατα, η οποία θέτει περιορισμούς ισότητας για το πρόβλημα ταξινόμησης με ένα σχηματισμό με την έννοια των ελαχίστων τετραγώνων. Αυτό ενθαρρύνει την απευθείας απόκτηση της λύσης με την επίλυση ενός συνόλου γραμμικών εξισώσεων, αντί του τετραγωνικού προγραμματισμού [63].

Δεδομένου ενός συνόλου δεδομένων με N ζεύγη εκπαίδευσης εισόδου-εξόδου $\{x_j, y_j\}_{j=1}^N$, όπου $y_j = 1$ ή -1 , ανάλογα με το αν το x_j ανήκει στην τάξη 1 ή 2 αντίστοιχα. Για τη δυαδική ταξινόμηση μηχανής διανυσμάτων υποστήριξης, ακολουθώντας τη συνάρτηση απόφασης, έχουμε [63]:

$$S(x) = \text{sign}[w^T \varphi(x) + b]$$

όπου w είναι το διάνυσμα βάρους και b είναι το σφάλμα (bias). Το $\varphi(\cdot)$ είναι μια μη γραμμική συνάρτηση που χαρτογραφεί το χώρο εισόδου σε χώρο υψηλότερων διαστάσεων. Προκειμένου να ληφθεί η τιμή των w και b , το ακόλουθο πρόβλημα βελτιστοποίησης διατυπώνεται με την εισαγωγή μιας έκδοσης ελαχίστων τετραγώνων στο SVM:

Ελαχιστοποιείται η $J(w, b, e) = \frac{1}{2} w^T w + \frac{\gamma}{2} \sum_1^N e_j^2$, όπου $e = (e_1, e_2, \dots, N)^T$. Σύμφωνα με τους περιορισμούς ισότητας,

$$y_j [w^T \varphi(x) + b] = 1 - e_j, j = 1, 2, \dots, N$$

Η Λαγκραντζιανή δίνεται ως:

$$L(w, b, e; a) = J(w, b, e) - \sum_{j=1}^N a_j \{y_j [w^T \varphi(x_j) + b] - 1 + e_j\}$$

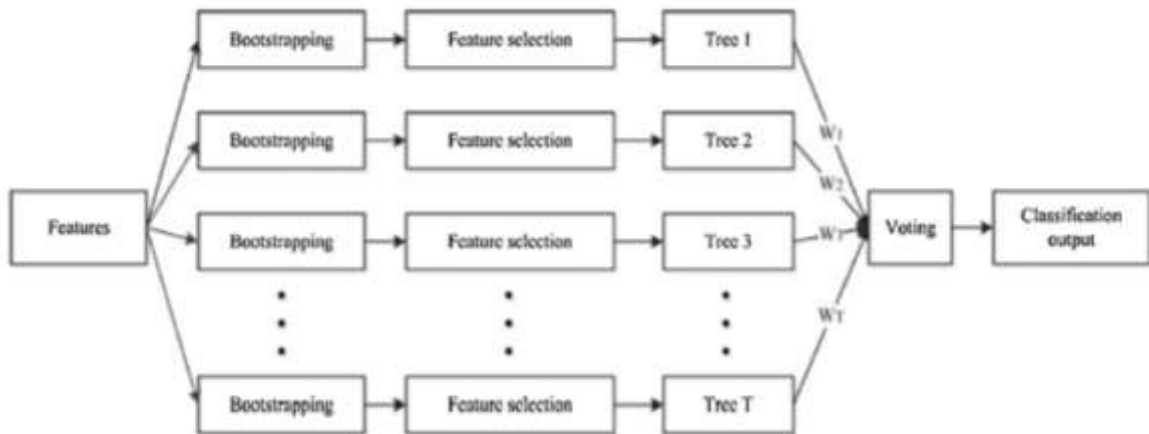
όπου οι είναι οι πολλαπλασιαστές Lagrange και $a = (a_1, a_2, \dots, a_N)^T$. Τα LS-SVM μπορεί να δοθεί από τη σχέση:

$$S(x) = \text{sign} \left[\sum_{j=1}^N a_j y_j \psi(x, x_j) + b \right]$$

όπου $\psi(x, x_j)$ είναι η συνάρτηση του πυρήνα.

4.5.2 Ταξινομητής τυχαίου δάσους (Random forest classifier)

Ο ταξινομητής τυχαίου δάσους είναι μια συνάθροιση πολλαπλών δέντρων αποφάσεων και αυτός ο αλγόριθμος μάθησης προτάθηκε για πρώτη φορά από τον Breiman [103]. Κάθε δένδρο μπορεί να θεωρηθεί ως ένας μεμονωμένος ταξινομητής και η έξοδος της ταξινόμησης ψηφίζεται από όλα τα δέντρα απόφασης. Η δομή του τυχαίου δάσους απεικονίζεται στο Σχήμα 4.17.



Σχήμα 4.17: Δομή του ταξινομητή τυχαίου δάσους [68].

Για την κατασκευή ενός ταξινομητή τυχαίου δάσους που αποτελείται από T δέντρα, οι κανόνες ανάπτυξης του κάθε δέντρου συνοψίζονται ως εξής [98]:

(1) Ας υποθέσουμε ότι N είναι ο αριθμός των περιπτώσεων στο σύνολο εκπαίδευσης, στη συνέχεια, δειγματοληπτούμε N τυχαία δείγματα από το σύνολο εκπαίδευσης, με αντικατάσταση σε κάθε διαδικασία δειγματοληψίας, αποκτώντας έτσι N δείγματα εκπαίδευσης. Πρέπει να τονιστεί, ότι δεν θα χρησιμοποιηθούν όλα τα δεδομένα εκπαίδευσης. Ορισμένα δεδομένα μπορεί να χρησιμοποιηθούν περισσότερες από μία φορές, ενώ άλλα μπορεί να μη χρησιμοποιηθούν ποτέ.

(2) Ας υποθέσουμε ότι το M είναι η διάσταση των χαρακτηριστικών εισόδου, m ($m < M$) είναι η καθορισμένη διάσταση των τυχαία επιλεγμένων υπο-χαρακτηριστικών από τα αρχικά διανύσματα χαρακτηριστικών. Στη συνέχεια, οι m μεταβλητές χαρακτηριστικών επιλέγονται τυχαία από τα M χαρακτηριστικά και ο καλύτερος διαχωρισμός σε αυτά τα m -διάστατα χαρακτηριστικά χρησιμοποιείται για τον διαχωρισμό του κόμβου.

(3) Κάθε δέντρο συνεχίζει να αναπτύσσεται μέχρις ότου όλα αυτά τα δείγματα εκπαίδευσης να διαχωριστούν πλήρως μεταξύ τους, χωρίς κλάδεμα.

Όπως αποκαλύφθηκε, το ποσοστό σφάλματος του δάσους εξαρτάται από δύο πτυχές [103]:

- Η συσχέτιση μεταξύ οποιωνδήποτε δύο δένδρων στο δάσος. Όσο μεγαλύτερη είναι η συσχέτιση, τόσο μεγαλύτερο είναι το ποσοστό σφάλματος και αντίστροφα, όσο μικρότερη είναι η συσχέτιση, τόσο μικρότερο είναι το ποσοστό σφάλματος.
- Η δύναμη (strength) κάθε δέντρου στο δάσος. Η αύξηση της δύναμης σημαίνει τη μείωση του ποσοστού σφάλματος στο δάσος.

Η μόνη ρυθμιζόμενη και ευαίσθητη παράμετρος του τυχαίου δάσους είναι ο αριθμός των επιλεγμένων χαρακτηριστικών και η μείωση του m μειώνει τόσο τη συσχέτιση, όσο και τη δύναμη (strength). Ως εκ τούτου, υπάρχει μια ισορροπία μεταξύ συσχέτισης και δύναμης. Για να διαπιστώσουμε την καλύτερη απόδοση του

τυχαίου δάσους, ερευνήσαμε τις επιδράσεις διαφορετικών συνδυασμών δένδρων στην ακρίβεια ταξινόμησης.


4.5.3 Μηχανές ακραίας μάθησης (Extreme Learning Machines - ELM)

Δομικά, μια ELM μπορεί να οριστεί ως ένα πολλαπλών βαθμίδων νευρωνικό δίκτυο perceptron με μια μόνο κρυμμένη βαθμίδα και μια γραμμική βαθμίδα εξόδου (βλέπε Σχήμα 4.18). Οι παράμετροι των νευρώνων που σχηματίζουν την κρυμμένη βαθμίδα επιλέγονται τυχαία [109], και η διαδικασία εκπαίδευσης της βαθμίδας εξόδου είναι ουσιαστικά ισοδύναμη με την προσαρμογή ενός γραμμικού ταξινομητή. Η επιλογή του αριθμού των νευρώνων στην ενδιάμεση βαθμίδα μπορεί να γίνει με μεθόδους διασταυρούμενης επικύρωσης.

Το μοντέλο προάγει στοιχεία της λειτουργίας των βιολογικών νευρώνων - τα δεδομένα εισόδου σταθμίζονται, αντιπροσωπεύοντας την συναπτική απόδοση και η συνάρτηση ενεργοποίησης καθορίζει την πυροδότηση (επιστρέφει έξοδο +1) ή την απουσία πυροδότησης (επιστρέφει έξοδο -1) του νευρώνα. Μια τυπική συνάρτηση ενεργοποίησης είναι η υπερβολική εφαιπτομένη, η οποία παρουσιάζει ακριβώς μία μη-γραμμικότητα αυτού του είδους.

Με απλά λόγια, η κρυμμένη βαθμίδα δημιουργεί έναν αριθμό μη γραμμικών τυχαίων προβολών που μετασχηματίζουν το χώρο διανυσμάτων εισόδου σε ένα χώρο χαρακτηριστικών, πάνω από τον οποίο η βαθμίδα εξόδου λειτουργεί ως ένας γραμμικός regressor (ανεξάρτητη μεταβλητή). Η κανονική προσέγγιση είναι να χρησιμοποιηθεί η μέθοδος των ελαχίστων τετραγώνων. Η ELM είναι μια ενδιαφέρουσα επιλογή στο πλαίσιο του BCI όσον αφορά την απλότητα της διαδικασίας εκπαίδευσης και των εγγενών ιδιοτήτων κανονικοποίησης [131, 132].

Στην ανάλυσή μας, ο αριθμός των νευρώνων στην κρυμμένη βαθμίδα της ELM καθορίστηκε στους 20, μετά από προκαταρκτικές δοκιμές. Η υπερβολική εφαιπτομένη χρησιμοποιήθηκε ως συνάρτηση ενεργοποίησης. Τα βάρη της κρυμμένης βαθμίδας δημιουργήθηκαν χρησιμοποιώντας μια τυχαία Gaussian συνάρτηση. Η απόδοση της ELM καθορίστηκε με βάση το μέσο όρο των 20 διαδρομών για κάθε υποκείμενο για να ληφθεί υπόψη ο τυχαίος χαρακτήρας του δικτύου.



Σχήμα 4.18: Βασική δομή της ELM [104].

ΚΕΦΑΛΑΙΟ 5

Κριτική και Σύγκριση των Μεθόδων Εξαγωγής Χαρακτηριστικών

Η πρώτη ενότητα αυτού του κεφαλαίου αφιερώνεται στην παρουσίαση των μεθόδων οι οποίες χρησιμοποιούνται για την αξιολόγηση της απόδοσης των ταξινομητών. Εδώ αναλύονται τα ευρέως διαδεδομένα στατιστικά κριτήρια -που συναντήσαμε πολλές φορές στις μεθόδους που αναλύσαμε σε προηγούμενα κεφάλαια-, αλλά και άλλες σημαντικές μέθοδοι που χρησιμοποιούνται για να υπολογίσουν τις επιδόσεις των ταξινομητών και να αποφανθούν για το ποια μέθοδος ταξινόμησης λειτουργεί καλύτερα σε κάθε περίπτωση. Τα διάφορα κριτήρια αξιολόγησης της απόδοσης των ταξινομητών, αναπτύσσονται παρακάτω.

5.1 Αξιολόγηση της Απόδοσης των Ταξινομητών

Ένας κοινός τρόπος για σύγκριση της απόδοσης αλγορίθμων Μηχανικής Μάθησης είναι η πραγματοποίηση στατιστικών συγκρίσεων των ταξινομητών σε συγκεκριμένα σύνολα δεδομένων. Έχουν αναπτυχθεί διάφορες εκδόσεις του στατιστικού *t-test* ώστε να επιτελούν αυτές τις συγκρίσεις. Επίσης, υπάρχουν τεχνικές εκ των προτέρων αποτίμησης της ποιότητας πρόβλεψης, με χρήση της θεωρίας υπολογιστικής μάθησης [183], [234], [235].

Το πιο απλό μέτρο για την έκφραση της απόδοσης ενός ταξινομητή, όπως έχουμε δει, είναι η **ακρίβεια** (accuracy - ACC). Το μέτρο αυτό είναι το συνολικό ποσοστό των ορθών ταξινομήσεων του ταξινομητή. Δύο στατιστικά μέτρα που χρησιμοποιούνται συχνά για την αξιολόγηση ενός δυαδικού ταξινομητή, ο οποίος ταξινομεί τα δεδομένα σε θετικά και αρνητικά αποτελέσματα ως προς κάποια υπόθεση, είναι η **ευαισθησία** (sensitivity - SEN) και η **εξειδίκευση** (specificity - SPE). Η ευαισθησία μετράει την αναλογία των θετικών αποτελεσμάτων που ανιχνεύει ο ταξινομητής, τα οποία είναι αληθώς θετικά, από το σύνολο των θετικών δειγμάτων, ενώ η εξειδίκευση μετράει την αναλογία των αρνητικών αποτελεσμάτων που ανιχνεύει ο ταξινομητής, τα οποία είναι αληθώς αρνητικά, από το σύνολο των αρνητικών δειγμάτων. Ο ιδανικός ταξινομητής θα είχε 100% ευαισθησία, οπότε όλες οι θετικές προβλέψεις του θα ήταν σωστές και 100% εξειδίκευση, οπότε όλες οι αρνητικές προβλέψεις θα ήταν επίσης σωστές [236], [237]. Οι παραπάνω στατιστικοί δείκτες ορίζονται ως εξής:

$$SPE = \frac{TN}{TN + FP} \times 100\%$$

$$SEN = \frac{TP}{TP + FN} \times 100\%$$

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

Δύο επιπλέον χρήσιμα μέτρα, τα οποία όμως χρησιμοποιούνται σπανιότερα, είναι η **Θετική Προγνωστική Αξία** (Positive Predictive Value – PPV) και **Αρνητική Προγνωστική Αξία** (Negative Predictive Value – NVP). Η θετική προγνωστική αξία

είναι η πιθανότητα ένα αποτέλεσμα που έχει προβλεφθεί θετικό να είναι αληθώς θετικό, ενώ η αρνητική προγνωστική αξία είναι η πιθανότητα ένα αποτέλεσμα που έχει προβλεφθεί αρνητικό να είναι αληθώς αρνητικό. Τα μέτρα αυτά εξαρτώνται από την εξειδίκευση και την ευαισθησία του ταξινομητή που χρησιμοποιείται, αλλά και από την επικράτηση (prevalence) του υπό εξέταση χαρακτηριστικού στον πληθυσμό [183]. Οι τιμές τους δίνονται από τους αντίστοιχους τύπους:

$$PPV = \frac{TP}{TP + FP} \times 100\%$$

$$NPV = \frac{TN}{TN + FN} \times 100\%$$

Αφού ολοκληρωθεί η διαδικασία ελέγχου ενός ταξινομητή, τα αποτελέσματα που προκύπτουν μπορούν να παρουσιαστούν χρησιμοποιώντας τον **Πίνακα Σύγχυσης** (*Confusion Matrix*). Στον πίνακα αυτό, οι στήλες περιέχουν την πρόβλεψη του ταξινομητή για τα δείγματα, ενώ οι γραμμές τις πραγματικές τάξεις των δειγμάτων. Το όνομα του πίνακα προέρχεται από το ότι μπορεί εύκολα να διαπιστωθεί από αυτόν εάν ο ταξινομητής δεν διακρίνει σωστά τις τάξεις του προβλήματος [183].

Στον παρακάτω πίνακα (Πίνακας 5.1) [183] παρατίθεται ένα παράδειγμα Πίνακα Σύγχυσης που προβλέπει εάν κάποιο άτομο έχει μια συγκεκριμένη ασθένεια ή όχι [238].

Πίνακας 5.1:

Πίνακας Σύγχυσης και Αντίστοιχα Σύνολα.

| | | Πρόβλεψη Ταξινομητή | | |
|------------------|-------------------|---|---|---|
| | | Θετικό | Αρνητικό | Σύνολα |
| Πραγματική Κλάση | Ασθένεια | A (True Positive) | C (False Negative) | T_D (Σύνολο Ασθένειας) |
| | Απουσία Ασθένειας | B (False Positive) | D (True Negative) | T_{ND} (Σύνολο Απουσία Ασθένειας) |
| Σύνολα | | T_{TP} (Σύνολο Test Positive) | T_{TN} (Σύνολο Test Negative) | T (Σύνολο) |

Ένας ταξινομητής, λοιπόν, έχει σχεδιαστεί επιτυχώς όταν παράγει υποθέσεις που αποδίδουν καλά στην πρόβλεψη της ταξινόμησης δειγμάτων τα οποία δεν έχουν εμφανιστεί ξανά στο παρελθόν, ούτε υπάρχουν στο σύνολο εκπαίδευσης [183]. Ωστόσο, εκτός από τα στατιστικά κριτήρια, υπάρχουν και άλλες τεχνικές για την αξιολόγηση των ταξινομητών.

Η πιο διαδεδομένη τεχνική είναι η ***k-φορές αναδιπλωμένη διασταυρούμενη επικύρωση*** (*k-fold cross-validation*). Το σύνολο των δειγμάτων διαμερίζεται σε *k* αμοιβαίως αποκλειόμενα υποσύνολα του ίδιου μεγέθους και για κάθε υποσύνολο, ο ταξινομητής εκπαιδεύεται με δείγματα εκπαίδευσης που προκύπτουν από την ένωση όλων των υπολοίπων *k-1* υποσυνόλων και το υποσύνολο που μένει χρησιμοποιείται

ως σύνολο ελέγχου. Η διαδικασία αυτή επαναλαμβάνεται k φορές μέχρι να χρησιμοποιηθούν όλα τα υποσύνολα ως σύνολα ελέγχου. Στη συνέχεια, υπολογίζεται ο μέσος όρος από τους k ρυθμούς σφάλματος και έτσι προκύπτει η εκτίμηση του ρυθμού σφάλματος για τον ταξινομητή [183].


Αν η διαδικασία αξιολόγησης δείχνει ότι ο ταξινομητής δεν είναι αποδοτικός, θα πρέπει να εξεταστούν μια σειρά από παράγοντες. Ενδεχομένως να μην χρησιμοποιούνται χαρακτηριστικά που είναι σχετικά με το πρόβλημα, να απαιτείται μεγαλύτερο σύνολο εκπαίδευσης, η διάσταση του προβλήματος να είναι ιδιαίτερα μεγάλη, ο επιλεγμένος ταξινομητής να είναι ακατάλληλος για το συγκεκριμένο πρόβλημα ή να χρειάζεται διαφορετική ρύθμιση στις παραμέτρους [183].

5.2 Πειραματικά αποτελέσματα


Σε αυτή την ενότητα, θα παρουσιάσουμε τα πειραματικά αποτελέσματα που αφορούν την ταξινόμηση των μονοδιάστατων βιοσημάτων και τα οποία προέκυψαν από την εφαρμογή των διαφόρων μεθόδων εξαγωγής χαρακτηριστικών που αναπτύχθηκαν στο κεφάλαιο 3. Με αυτόν τον τρόπο, γίνεται δυνατή η άμεση σύγκριση των μεθόδων ταξινόμησης και η εξαγωγή συμπερασμάτων σχετικά με τη χρήση και την καταλληλότητα της κάθε μεθόδου.

1D-LBP

Ας παρουσιάσουμε, λοιπόν, αρχικά τα αποτελέσματα της μεθόδου 1D-LBP. Το σύστημα ταξινόμησης ΗΕΓ, το οποίο χρησιμοποιεί την προτεινόμενη μέθοδο εξαγωγής χαρακτηριστικών που βασίζεται στην 1D-LBP, φαίνεται στο Σχήμα 5.1. Η είσοδος στο σύστημα ταξινόμησης είναι το πρωτογενές σήμα ΗΕΓ στο πεδίο του χρόνου και η έξοδος ήταν το ταξινομημένο ΗΕΓ πρότυπο. Το σήμα ΗΕΓ στο πεδίο του χρόνου αρχικά μετασχηματίστηκε στο LBP πεδίο, πριν από την εφαρμογή του ως είσοδος στον ταξινομητή. Στο Σχήμα 5.1, η διαδικασία αυτή αντιπροσωπεύεται από το στάδιο εξαγωγής χαρακτηριστικών. Σε αυτό το στάδιο, τα ιστογράμματα χαρακτηριστικών LBP^{all} και LBP^{u2} (διανύσματα χαρακτηριστικών), τα οποία λήφθηκαν από όλες τις ομάδες των ΗΕΓ, δημιουργήθηκαν ακολουθώντας τα βήματα που αναφέρθηκαν στο κεφάλαιο 3. Οι μέσοι όροι των χαρακτηριστικών που λαμβάνονται από τα LBP^{all} ιστογράμματα των ομάδων Α, Β, C, D και Ε παρουσιάζονται ξεχωριστά στο Σχήμα 5.2. Η προσέγγιση αυτή διευκολύνει οπτικά την αξιολόγηση της φύσης των χαρακτηριστικών που λαμβάνονται από κάθε ομάδα ΗΕΓ. Με την πρώτη ματιά, αν και φαίνονται παρόμοια το ένα με το άλλο, η συχνότητα εμφάνισης στο ιστόγραμμα LBP έδειξε διαφορετικά χαρακτηριστικά για κάθε σύνολο δεδομένων. Ως εκ τούτου, οι επιπτώσεις στην απόδοση του συστήματος ταξινόμησης των LBP^{all} και LBP^{u2} χαρακτηριστικών, πρέπει να εξεταστούν χωριστά.



Σχήμα 5.1: Διάγραμμα του προτεινόμενου συστήματος ταξινόμησης [33].



Σχήμα 5.2: Το LBP ιστόγραμμα χαρακτηριστικών των συνόλων δεδομένων HEG [33].

Στο στάδιο της ταξινόμησης, τα χαρακτηριστικά που εξάχθηκαν με την 1D-LBP, εφαρμόστηκαν ως είσοδος στον ταξινομητή για την ταξινόμηση επιληπτικών HEG. Εδώ, η απόδοση της προτεινόμενης μεθόδου αξιολογήθηκε με χρήση πέντε διαφορετικών ταξινομητών, των *BayesNet*, *SVM*, *ANN*, *LR* και *FT*. Για τους διάφορους ταξινομητές, χρησιμοποιήθηκε το open source πακέτο λογισμικού για εξόρυξη δεδομένων, *WEKA* (Waikato Environment for Knowledge Analysis) [239].

Σε αυτή τη μελέτη, έξι διαφορετικοί συνδυασμοί ταξινόμησης, όπως οι A-E, A-D, D-E, E-CD, AB-CDE και A-D-E συγκροτήθηκαν από το παραπάνω σύνολο δεδομένων, προκειμένου να δοκιμαστεί η προτεινόμενη μέθοδος. Στους πρώτους πέντε από αυτούς τους συνδυασμούς, εξετάστηκε το πρόβλημα ταξινόμησης HEG με δύο τάξεις, ενώ ο τελευταίος συνδυασμός εξετάζει ένα πρόβλημα ταξινόμησης με τρεις τάξεις. Τα πειράματα πραγματοποιήθηκαν ξεχωριστά για τα LBP^{all} και LBP^{u2} χαρακτηριστικά. Για την καλύτερη επιλογή μοντέλου για τα προβλήματα ταξινόμησης που περιγράφηκαν, χρησιμοποιήθηκε η τεχνική 10-fold cross-validation. Τα αποτελέσματα έδειξαν ότι η υψηλότερη ακρίβεια ταξινόμησης που λαμβάνεται για τα χαρακτηριστικά LBP^{all} βρέθηκε να είναι 99.50%, 99.50%, 93.00%, 95.66%, 93.00% και 95.67% για κάθε συνδυασμό, αντίστοιχα. Από την άλλη πλευρά, όσον αφορά τα χαρακτηριστικά LBP^{u2} , η καλύτερη ακρίβεια που επιτεύχθηκε για κάθε συνδυασμό είναι 99.00%, 99.50%, 95.50%, 97.00%, 95.40% και 95.67%, αντίστοιχα. Γενικά, η υψηλότερη ακρίβεια ταξινόμησης παρατηρήθηκε από τη μεθοδολογία ταξινόμησης με βάση το διάνυσμα χαρακτηριστικών LBP^{u2} . Αυτό σημαίνει ότι το μειωμένο διάνυσμα χαρακτηριστικών LBP^{u2} έχει καλύτερη διακριτική ικανότητα από το LBP^{all} διάνυσμα χαρακτηριστικών. Ως αποτέλεσμα, η διάσταση χαρακτηριστικών

της εισόδου μειώθηκε σημαντικά σε 58 χαρακτηριστικά για την ταξινόμηση επιληπτικών ΗΕΓ. Εν τω μεταξύ, τα αποτελέσματα έδειξαν ότι η προτεινόμενη μέθοδος μπορεί να αποκτήσει υψηλή ακρίβεια στην ταξινόμηση των επιληπτικών ΗΕΓ τόσο στα προβλήματα ταξινόμησης δύο τάξεων, όσο και στα προβλήματα με τρεις τάξεις.

Ένας άλλος στόχος της μελέτης αυτής ήταν μια αναπαράσταση της προτεινόμενης μεθόδου εξαγωγής χαρακτηριστικών και πως αυτή λειτουργεί καλά με διαφορετικούς ταξινομητές. Παρατηρείται από τους Πίνακες 5.2 και 5.3 [33], ότι τα αποτελέσματα ταξινόμησης ΗΕΓ που λαμβάνονται από διαφορετικούς ταξινομητές ήταν σχετικά κοντά το ένα στο άλλο. Ωστόσο, ο ταξινομητής BayesNet ήταν ελαφρώς καλύτερος από τους άλλους ταξινομητές. Διαπιστώθηκε επίσης ότι η προτεινόμενη μέθοδος ήταν «στιβαρή» σε μια ευρεία ποικιλία αλγορίθμων ταξινόμησης.

Πίνακας 5.2

Αποτελέσματα ταξινόμησης από πέντε διαφορετικούς ταξινομητές για τα χαρακτηριστικά LBP^{all}

| Ομάδα δεδομένων | BayesNet (%) | SVM (%) | ANN (%) | LR (%) | FT (%) |
|-----------------|--------------|---------|---------|--------|--------|
| A-E | 97.50 | 98.00 | 98.50 | 96.50 | 99.50 |
| A-D | 99.50 | 98.50 | 97.00 | 96.50 | 99.00 |
| D-E | 93.00 | 91.50 | 91.50 | 88.50 | 91.50 |
| E-CD | 95.66 | 95.33 | 94.33 | 84.66 | 93.66 |
| AB-CDE | 93.00 | 88.40 | 89.00 | 88.80 | 91.00 |
| A-D-E | 95.67 | 93.67 | 92.33 | 66.67 | 92.00 |

Πίνακας 5.3

Αποτελέσματα ταξινόμησης από πέντε διαφορετικούς ταξινομητές για τα χαρακτηριστικά LBP^{u2}

| Ομάδα δεδομένων | BayesNet (%) | SVM (%) | ANN (%) | LR (%) | FT (%) |
|-----------------|--------------|---------|---------|--------|--------|
| A-E | 98.00 | 98.50 | 98.00 | 97.00 | 99.00 |
| A-D | 99.50 | 99.00 | 98.50 | 99.50 | 97.50 |
| D-E | 95.50 | 93.00 | 93.50 | 89.50 | 93.00 |
| E-CD | 97.00 | 96.00 | 95.33 | 90.66 | 95.33 |
| AB-CDE | 92.80 | 92.80 | 95.40 | 87.80 | 92.00 |
| A-D-E | 95.67 | 94.00 | 94.33 | 91.33 | 93.33 |

Ως ένας διαφορετικός τύπος μελέτης περιπτώσεων, η απόδοση του συστήματος ταξινόμησης με βάση τον ταξινομητή BayesNet διερευνήθηκε επίσης από τα στατιστικά μέτρα της ευαισθησίας, της εξειδίκευσης και της ακρίβειας ταξινόμησης για τα χαρακτηριστικά LBP^{u2} και LBP^{all} . Τα μέσα αποτελέσματα της ταξινόμησης με τον BayesNet για τα χαρακτηριστικά LBP^{u2} και LBP^{all} καταγράφηκαν στους Πίνακες 5.4 και 5.5 [33].

Πίνακας 5.4

Πειραματικά αποτελέσματα του ταξινομητή BayesNet για τα χαρακτηριστικά LBP^{all} .

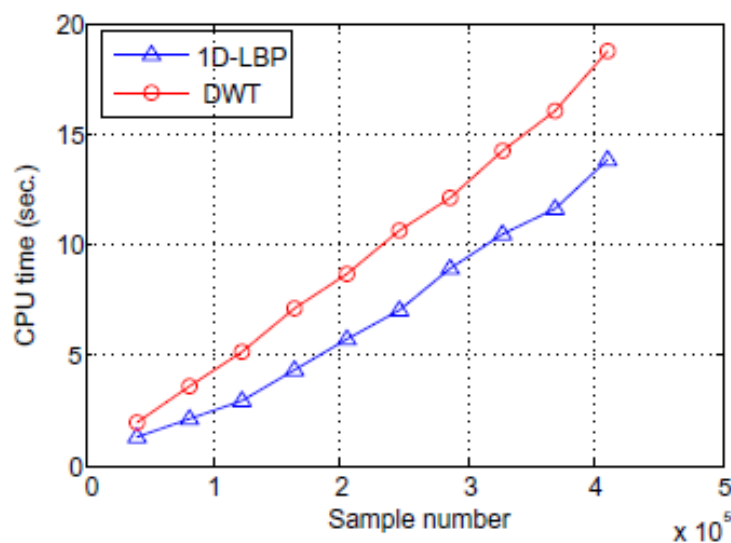
| Data cluster | Sensitivity (%) | Specificity (%) | Accuracy (%) |
|--------------|-----------------|-----------------|--------------|
| A-E | 96.00 | 99.00 | 97.50 |
| A-D | 99.0 | 100.00 | 99.50 |
| D-E | 94.00 | 92.00 | 93.00 |
| E-CD | 95.00 | 96.00 | 95.50 |
| AB-CDE | 99.50 | 88.66 | 93.00 |
| A-D-E | - | - | 95.67 |

Πίνακας 5.5

Πειραματικά αποτελέσματα του ταξινομητή BayesNet για τα χαρακτηριστικά LBP^{u2} .

| Data cluster | Sensitivity (%) | Specificity (%) | Accuracy (%) |
|--------------|-----------------|-----------------|--------------|
| A-E | 99.00 | 97.00 | 98.00 |
| A-D | 99.00 | 100.00 | 99.50 |
| D-E | 96.00 | 95.00 | 95.50 |
| E-CD | 95.00 | 98.00 | 97.00 |
| AB-CDE | 100 | 88.00 | 92.80 |
| A-D-E | - | - | 95.67 |

Για να αξιολογηθεί η υπολογιστική αποδοτικότητα της μεθόδου 1D-LBP, οι συγγραφείς τη συνέκριναν με τη μέθοδο πολλαπλής ανάλυσης DWT, όσον αφορά το χρόνο CPU. Στην DWT ανάλυση, ο αριθμός των επιπέδων αποσύνθεσης επιλέχθηκε ίσος με 4, το οποίο συνιστάται από τις έρευνες [240,241]. Επιπλέον, η συνάρτηση κυματιδίου που επιλέχθηκε ήταν Daubechies με τάξη 4, το οποίο επίσης αποδείχθηκε ότι είναι η καταλληλότερη συνάρτηση κυματιδίου για ανάλυση επιληπτικών ΗΕΓ [242]. Τα πειράματα διεξήχθησαν σε πακέτο λογισμικού MATLAB, περιβάλλον R2009a και έτρεξαν σε 2.93 GHz Intel Pentium dual core επεξεργαστή CPU με 1,99 GB μνήμης RAM. Η Εικόνα 5.1: παρουσιάζει το χρόνο της CPU και των δύο μεθόδων. Ο συνολικός αριθμός των σημείων δειγματοληψίας των πρώτων σημάτων ΗΕΓ με 100 παρατηρήσεις χαράχθηκαν στον οριζόντιο άξονα, ενώ ο συνολικός χρόνος τρεξίματος του προγράμματος σε δευτερόλεπτα αναγράφεται στον κάθετο άξονα. Όπως μπορεί να φανεί από την Εικόνα 5.1, ο χρόνος που τρέχει το πρόγραμμα για τη μέθοδο 1D-LBP ήταν 3.01s, ενώ ο αλγόριθμος απασχολούσε 122.880 σημεία δειγματοληψίας. Από την άλλη πλευρά, η μέθοδος DWT χρειάστηκε 5.168s για ίσο αριθμό δειγμάτων. Ομοίως, η προτεινόμενη μέθοδος 1D-LBP χρειάστηκε 10.46s για 327.760 σημεία δειγματοληψίας, ενώ η μέθοδος DWT χρειάστηκε 14.26s για τα ίδια δείγματα. Στην Εικόνα 5.1 φαίνεται ξεκάθαρα ότι η μέθοδος 1D-LBP χρειάστηκε λιγότερο χρόνο από ό, τι η μέθοδος DWT, για όλα τα σημεία δειγματοληψίας. Ως αποτέλεσμα, η υπολογιστική πολυπλοκότητα της μεθόδου 1D-LBP ήταν σημαντικά μικρότερη από αυτή της DWT στο να μετασχηματίσει τα σήματα ΗΕΓ.



Εικόνα 5.1: Σύγκριση των μεθόδων DWT και 1D-LBP όσον αφορά το χρόνο της CPU [33].

Προηγούμενες μελέτες που σχετίζονται με την ταξινόμηση σημάτων ΗΕΓ έχουν δείξει ότι όλες οι μέθοδοι που χρησιμοποιούνται για την εξαγωγή χαρακτηριστικών και ταξινόμηση έχουν διαφορετικές αποδόσεις. Στον Πίνακα 5.6 [33] παρουσιάζεται μια συγκριτική μελέτη της ποσοτικής απόδοσης που επιτυγχάνεται με εφαρμογή του προτεινόμενου αλγόριθμου, έναντι άλλων αλγορίθμων που έχουν αναφερθεί πρόσφατα στη βιβλιογραφία.

Όπως φαίνεται από αυτόν τον πίνακα, η προτεινόμενη μέθοδος θα μπορούσε να προσφέρει σημαντική ακρίβεια ταξινόμησης σε σύγκριση με μελέτες άλλων μεθόδων. Η προτεινόμενη προσέγγιση έχει δύο βασικά πλεονεκτήματα. Το πρώτο πλεονέκτημα είναι ότι η μέθοδος αυτή χρησιμοποιεί όλα τα σημεία δεδομένων (datapoints) για την εξαγωγή των χαρακτηριστικών. Το δεύτερο πλεονέκτημα ήταν ότι επέτρεψε την αποσύνθεση των σημάτων ΗΕΓ χωρίς τη χρήση τεχνικής μετασχηματισμού χρόνου-συχνότητας. Έτσι, επιτεύχθηκε σημαντική ακρίβεια ταξινόμησης. Τα ευρήματα της έρευνας κατέδειξαν ότι η προτεινόμενη προσέγγιση ήταν πολύ αποτελεσματική για την εξαγωγή αντιπροσωπευτικών χαρακτηριστικών. Περαιτέρω εργασίες μπορούν να εκτελεστούν για τη βελτίωση της ακρίβειας ταξινόμησης, με τη χρήση διαφορετικής προεπεξεργασίας, διαφορετικές μεθόδους επιλογής χαρακτηριστικών (όσον αφορά τα LBP^{all} χαρακτηριστικά) και διαφορετικές μεθόδους μηχανικής μάθησης.

Πίνακας 5.6:

Σύγκριση των αναφερθέντων εργασιών πάνω στην ταξινόμηση επιληπτικών ΗΕΓ σημάτων.

| Συγγραφείς | Μοντέλο | Σύνολο δεδομένων | Ακρίβεια (%) |
|------------------|--|--------------------|-------------------|
| [1] | WT and k-means clustering | C-E D-E CD-E | 99 97 97.67 |
| [9] | Fast Fourier transform and decision trees | A-E | 98.72 |
| [10] | WT + Lyapunov exponents and SVM | A-B-C-D-E | 99.28 |
| [11] | DWT and mixture of expert model | A-E | 94.50 |
| [13] | Time-frequency analysis and ANN | A-E A-D-E | 100 99.28 |
| [43] | WT and linear classifier | A-E | 99.50 |
| [44] | Approximate entropy features of multiwavelet transform and ANN | A-E | 99.85 |
| [45] | Non-linear preprocessing filter and diagnostic neural network | A-E | 97.20 |
| [46] | Time-frequency domain features and recurrent neural network | A-E | 99.60 |
| [47] | Wavelet entropy features and recurrent Elman network | A-E | 99.75 |
| [48] | DWT + k-means and MLPNN | A-E A-D-E | 100 96.67 |
| [49] | Entropy measures and adaptive neuro-fuzzy inference system | A-E | 92.22 |
| [Παρούσα μελέτη] | 1D-LBP ^{all} + FT | A-E | 99.50 |
| | 1D-LBP ^{all} + BayesNet | A-D | 99.50 |
| | 1D-LBP ^{u2} + BayesNet | D-E | 95.50 |
| | 1D-LBP ^{u2} + BayesNet | E-CD | 97 |
| | 1D-LBP ^{all} + BayesNet | AB-CDE | 93 |
| | 1D-LBP ^{all} + BayesNet | A-D-E | 95.67 |

Όπως φαίνεται από τα πειραματικά αποτελέσματα, η προτεινόμενη μέθοδος παρουσιάζει υψηλή ακρίβεια στην ταξινόμηση των επιληπτικών σημάτων ΗΕΓ. Για διάφορους συνδυασμούς των επιληπτικών ΗΕΓ, όπως οι A-E, A-D, D-E, E-CD, AB-CDE και A-D-E, τα ποσοστά επιτυχούς ταξινόμησης που επιτεύχθηκαν με τις μεθόδους ταξινόμησης SVM, ANN, LR και FT, αντίστοιχα, ήταν 99.50%, 99.50%,

95.50%, 97.00%, 95.40% και 95.67%. Γενικά υψηλή ακρίβεια επετεύχθη για διαφορετικά επιληπτικά σύνολα δεδομένων ΗΕΓ, με χαρακτηριστικά που βασίζονται στη μέθοδο 1D-LBP. Η προτεινόμενη μέθοδος μπορεί να αξιοποιηθεί στη διάκριση των άλλων χρονομεταβλητών σημάτων, ιδιαίτερα όταν εργάζεται με μη-στάσιμα σήματα. Επιπλέον, ο χρόνος υπολογισμού, ο οποίος απαιτείται για τον μετασχηματισμό των δεδομένων συγκρινόμενος με την DWT 4^{ης} τάξης, μειώθηκε από την προτεινόμενη προσέγγιση. Ένα από πλεονεκτήματα της προτεινόμενης μεθοδολογίας ήταν η υπολογιστική αποδοτικότητα και χρηστικότητα. Με την υψηλή της απόδοση και χαμηλής υπολογιστικής πολυπλοκότητας χαρακτηριστικά, η μέθοδος 1D-LBP είναι μια εξαιρετική προτίμηση για εφαρμογές επεξεργασίας σήματος σε πραγματικό χρόνο.

Μη γραμμικές μέθοδοι (fractals και DFA)

Στη συνέχεια θα παρουσιάσουμε τα πειραματικά αποτελέσματα της μη γραμμικής εξαγωγής χαρακτηριστικών με χρήση των μεθόδων fractals και DFA. Τρία διανύσματα χαρακτηριστικών, που αντιστοιχούν σε κάθε επιμέρους ζώνη συχνοτήτων δημιουργούνται από 70 δείγματα δεδομένων από κάθε τάξη (δηλαδή υπνηλία και επαγρύπνηση) για το πρώτο σύνολο δεδομένων ΗΕΓ. Η ταξινόμηση των σημάτων ΗΕΓ για αυτόματη ανίχνευση του επιπέδου επαγρύπνησης γίνεται από τους ταξινομητές SVM, LS-SVM και ANN για κάθε ένα από τα τρία διανύσματα χαρακτηριστικών, ξεχωριστά. Πιο συγκεκριμένα, όσον αφορά τα ANN, έχουμε αρχιτεκτονική νευρωνικού δικτύου με πέντε κρυμμένα επίπεδα, η οποία εκπαιδεύεται χρησιμοποιώντας αλγόριθμο εκπαίδευσης οπίσθιας διάδοσης με ρυθμό εκμάθησης 0.3 και οι παράμετροι υπολογίζονται με βάση τα αποτελέσματα ταξινόμησης πολλαπλών πειραμάτων που διεξάγονται σε δεδομένα ΗΕΓ. Η εκπαίδευση ANN και η ταξινόμηση για ψυχική κατάσταση πραγματοποιείται με τη χρήση του εργαλείου εξόρυξης δεδομένων WEKA έκδοσης 3.6.0.

Τα αποτελέσματα της ταξινόμησης, χρησιμοποιώντας διασταυρούμενη επικύρωση 10 φορών (10-fold cross validation) παρουσιάζονται στον Πίνακα 5.7 [52]. Τα αποτελέσματα δείχνουν τη σημασία της κάθε ζώνης συχνοτήτων για την ανίχνευση του επιπέδου επαγρύπνησης. Από την παρατήρηση των αποτελεσμάτων της ταξινόμησης που παρουσιάζονται στον Πίνακα 5.7, μπορεί να εξαχθεί το συμπέρασμα ότι οι ταξινομητές SVM, LS-SVM και ANN, κατατάσσουν τα δεδομένα ΗΕΓ σε δύο τάξεις (εγρήγορη και υπνηλία) με υψηλή απόδοση ταξινόμησης για τις ζώνες άλφα και βήτα. Ωστόσο, η αποτελεσματικότητα ταξινόμησης για τις ζώνες δέλτα και θήτα είναι αρκετά χαμηλή. Επίσης, παρατηρείται ότι οι πληροφορίες που μεταφέρονται από τις άλφα και βήτα ζώνες συχνοτήτων είναι πιο αξιόπιστες για την αυτόματη ανίχνευση του επιπέδου επαγρύπνησης.

Πίνακας 5.7

Απόδοση ταξινόμησης για τη μέθοδο 10-fold cross validation.

| Frequency bands (Hz) | SVM classifier (%) | LS-SVM classifier (%) | ANN classifier (%) |
|----------------------|--------------------|-----------------------|--------------------|
| Delta (0.5-4) | 71.42 | 73.57 | 57.14 |
| Theta (4-8) | 69.28 | 70.71 | 78.57 |
| Alpha (8-13) | 88.57 | 89.28 | 91.57 |
| Beta (13-30) | 93.47 | 93.47 | 93.27 |

Για να αποκτήσουν την κατάλληλη συνάρτηση πυρήνα (kernel function) για την αυτόματη ανίχνευση της επαγρύπνησης, η απόδοση ταξινόμησης των LS-SVM

αξιολογείται με τη χρήση της πολυωνυμικής συνάρτησης πυρήνα και της συνάρτησης πυρήνα ακτινικής βάσης. Ωστόσο, η απόδοση του SVM αξιολογείται χρησιμοποιώντας τις PUK, poly, normalized poly και RBF ως συναρτήσεις πυρήνα. Η εκπαίδευση και ο έλεγχος των ταξινομητών γίνεται με την μέθοδο 10-fold cross validation για να εξασφαλιστεί ότι δεν θα υπάρχει στατιστικό σφάλμα (statistical biasing) στα αποτελέσματα. Οι πίνακες με τις αποδόσεις των ταξινομητών για το πρώτο σύνολο δεδομένων ΗΕΓ με 10-fold cross validation, χρησιμοποιώντας διαφορετικές συναρτήσεις kernel, φαίνονται στους Πίνακες 5.8-5.14 [52].

Πίνακας 5.8:

Confusion matrix of SVM using PUK kernel.

| Alpha and beta | | Alpha | | Beta | | Classified as |
|----------------|------|-------|------|------|------|---------------|
| DRW | ALRT | DRW | ALRT | DRW | ALRT | |
| 70 | 0 | 61 | 9 | 70 | 0 | Drowsy (DRW) |
| 0 | 70 | 3 | 67 | 1 | 69 | Alert (ALRT) |

Πίνακας 5.9:

Confusion matrix of SVM using Poly kernel.

| Alpha and beta | | Alpha | | Beta | | Classified as |
|----------------|------|-------|------|------|------|---------------|
| DRW | ALRT | DRW | ALRT | DRW | ALRT | |
| 70 | 0 | 68 | 2 | 69 | 1 | Drowsy (DRW) |
| 1 | 69 | 4 | 66 | 3 | 67 | Alert (ALRT) |

Πίνακας 5.10:

Confusion matrix of SVM using normalized Poly kernel.

| Alpha and beta | | Alpha | | Beta | | Classified as |
|----------------|------|-------|------|------|------|---------------|
| DRW | ALRT | DRW | ALRT | DRW | ALRT | |
| 70 | 0 | 68 | 2 | 70 | 0 | Drowsy (DRW) |
| 1 | 69 | 5 | 65 | 1 | 69 | Alert (ALRT) |

Πίνακας 5.11:

Confusion matrix of SVM using RBF kernel.

| Alpha and beta | | Alpha | | Beta | | Classified as |
|----------------|------|-------|------|------|------|---------------|
| DRW | ALRT | DRW | ALRT | DRW | ALRT | |
| 70 | 0 | 70 | 0 | 68 | 2 | Drowsy (DRW) |
| 2 | 68 | 21 | 49 | 4 | 66 | Alert (ALRT) |

Πίνακας 5.12:

Confusion matrix of LS-SVM using Polynomial kernel.

| Alpha and beta | | Alpha | | Beta | | Classified as |
|----------------|------|-------|------|------|------|---------------|
| DRW | ALRT | DRW | ALRT | DRW | ALRT | |
| 70 | 0 | 69 | 1 | 70 | 0 | Drowsy (DRW) |
| 1 | 69 | 5 | 65 | 1 | 69 | Alert (ALRT) |

Πίνακας 5.13:

Confusion matrix of LS-SVM using RBF kernel.

| Alpha and beta | | Alpha | | Beta | | Classified as |
|----------------|------|-------|------|------|------|---------------|
| DRW | ALRT | DRW | ALRT | DRW | ALRT | |
| 69 | 1 | 70 | 0 | 68 | 2 | Drowsy (DRW) |
| 1 | 69 | 17 | 53 | 3 | 67 | Alert (ALRT) |

Πίνακας 5.14:

Confusion matrix of ANN.


| Alpha and beta | | Alpha | | Beta | | Classified as |
|----------------|------|-------|------|------|------|---------------|
| DRW | ALRT | DRW | ALRT | DRW | ALRT | |
| 70 | 0 | 67 | 3 | 70 | 0 | Drowsy (DRW) |
| 1 | 69 | 6 | 64 | 1 | 69 | Alert (ALRT) |

Για να αποκτήσουμε τον πιο κατάλληλο ταξινομητή και την πιο κατάλληλη συνάρτηση kernel για την αυτόματη ανίχνευση του επιπέδου επαγρύπνησης, τα αποτελέσματα της ταξινόμησης όσον αφορά την ακρίβεια ταξινόμησης χρησιμοποιώντας διαφορετικές τεχνικές ταξινόμησης, συγκρίνονται στον Πίνακα 5.15 [52]. Το Σχήμα 5.3 παρουσιάζει την ακρίβεια ταξινόμησης που επιτεύχθηκε με τη χρήση SVM ταξινομητή με διαφορετικές συναρτήσεις kernel. Παρατηρώντας την εικόνα, βλέπουμε ότι ο SVM κατατάσσει το πρώτο σύνολο δεδομένων HEG με 100% ακρίβεια ταξινόμησης, όταν η ταξινόμηση γίνεται με τη συνάρτηση kernel PUK για χαρακτηριστικά που βασίζονται στην άλφα-βήτα ζώνη συχνοτήτων. Το Σχήμα 5.4 παρουσιάζει τα αποτελέσματα ταξινόμησης που αποκτώνται χρησιμοποιώντας τον LS-SVM ταξινομητή με διαφορετικές συναρτήσεις kernel. Από αυτήν την εικόνα παρατηρείται ότι ο LS-SVM κατατάσσει το πρώτο σύνολο δεδομένων HEG με ακρίβεια ταξινόμησης 99,28% όταν η ταξινόμηση γίνεται με πολυωνυμική συνάρτηση πυρήνα για χαρακτηριστικά που βασίζονται στις άλφα-βήτα και βήτα ζώνες συχνοτήτων. Από τα Σχήματα 5.3 και 5.4, ανιχνεύεται ότι η μέση απόδοση ταξινόμησης του LS-SVM ταξινομητή για χαρακτηριστικά που βασίζονται στις επιμέρους ζώνες συχνοτήτων άλφα και βήτα, είναι καλύτερη από ό, τι του SVM, όταν η ταξινόμηση γίνεται με τη χρήση πολυωνυμικής και RBF συνάρτησης πυρήνα. Ωστόσο, η ακρίβεια ταξινόμησης που λαμβάνεται για χαρακτηριστικά που βασίζονται στην άλφα-βήτα ζώνη συχνοτήτων, είναι συγκρίσιμη τόσο για τον SVM, όσο και για τον LS-SVM ταξινομητή.


Πίνακας 5.15:

Αξιολόγηση της Απόδοσης Ταξινόμησης για το πρώτο σετ δεδομένων HEG, με χρήση των SVM, LS-SVM and ANN.

| Classifiers | Kernel | Kernel parameters | Parameters | Alpha and beta | Alpha | Beta |
|-------------|--|--------------------------|---------------------------|---------------------------|---------------------------|---------------------------|
| SVM | PUK kernel | $\omega=1$ $\gamma=1$ | Correctly classified | 140 instances (100%) | 128 instances (91.42%) | 139 instances (99.28%) |
| | | | Incorrectly classified | 0 instances (0%) | 12 instances (8.57%) | 1 instance (0.71%) |
| | Poly kernel | Exponent=2 | Correctly classified | 139 instances (99.28%) | 134 instances (95.71%) | 136 instances (97.14%) |
| | | | Incorrectly classified | 1 instance (0.71%) | 6 instances (4.28%) | 4 instances (2.8%) |
| | Normalized Poly kernel | Exponent=2 | Correctly classified | 139 instances (99.28%) | 133 instances (95%) | 139 instances (99.28%) |
| | | | Incorrectly classified | 1 instance (0.71%) | 7 instances (5%) | 1 instance (0.71%) |
| | RBF kernel | $\gamma=0.5$ | Correctly classified | 138 instances (98.57%) | 119 instances (85%) | 134 instances (95.71%) |
| | | | Incorrectly classified | 2 instances (1.4%) | 21 instances (15%) | 6 instances (4.2%) |
| LS-SVM | Polynomial kernel | Exponent=3 | Correctly classified | 139 instances (99.28%) | 134 instances (95.71%) | 139 instances (99.28%) |
| | | | Incorrectly classified | 1 instance (0.71%) | 6 instances (4.2%) | 1 instance (0.71%) |
| | RBF kernel | $\gamma=0.4$ | Correctly classified | 138 instances (98.57%) | 123 instances (87.85%) | 135 instances (96.42%) |
| | | | Incorrectly classified | 2 instances (1.4%) | 17 instances (12.14%) | 5 instances (3.5%) |
| ANN | Five hidden layered structure with 0.3 learning rate | Correctly classified | 139 instances (99.28%) | 131 instances (93.57%) | 139 instances (99.28%) | |
| | | Incorrectly classified | 1 instance (0.71%) | 9 instances (6.42%) | 1 instance (0.71%) | |




Σχήμα 5.3: Απόδοση του ταξινομητή SVM με χρήση διαφορετικών συναρτήσεων πυρήνα [52].




Σχήμα 5.4: Απόδοση του ταξινομητή LS-SVM με χρήση διαφορετικών συναρτήσεων πυρήνα [52].

Παρατηρώντας τον Πίνακα 5.15, η απόδοση ταξινόμησης των τριών ταξινομητών (SVM, LS-SVM και ANN) για χαρακτηριστικά που βασίζονται στις επιμέρους ζώνες συχνοτήτων άλφα-βήτα, άλφα και βήτα, συνάγεται το συμπέρασμα ότι τα χαρακτηριστικά που βασίζονται στην άλφα-βήτα ζώνη συχνοτήτων είναι τα πιο κατάλληλα για το έργο της αυτόματης ανίχνευσης του επιπέδου επαγρύπνησης. Τα αποτελέσματα της ταξινόμησης που εκτελέστηκε στο πρώτο σύνολο δεδομένων ΗΕΓ, εγκρίνουν την ικανότητα των SVM (με συνάρτηση πυρήνα PUK), LS-SVM (με πολυωνυμική συνάρτηση πυρήνα) και ANN, για την αυτόματη ανίχνευση του επιπέδου επαγρύπνησης. Η διακριτική ικανότητα των μη γραμμικών χαρακτηριστικών που βασίζονται στην άλφα-βήτα ζώνη συχνοτήτων (Higuchi FD, Petrosian FD και DFA) φαίνεται στην Εικόνα 5.2 για το πρώτο σύνολο δεδομένων ΗΕΓ. Από την Εικόνα 5.2 παρατηρείται ότι η κεντρική τάση και διασπορά των μη γραμμικών παραμέτρων αποκλίνει για τις δύο τάξεις δεδομένων ΗΕΓ. Τα Higuchi FD είναι θετικά ασύμμετρα για ηλεκτροεγκεφαλογραφήματα υπνηλίας, στα εννιά από τα έντεκα κανάλια ΗΕΓ. Αντίθετα, τα Higuchi FD είναι αρνητικά ασύμμετρα ή μηδενικά για ηλεκτροεγκεφαλογραφήματα εγρήγορσης, σε οκτώ από τα έντεκα ΗΕΓ κανάλια. Ο διάμεσος (median) των διαγραμμάτων που παρουσιάζονται στην Εικόνα 5.2, μετατοπίζεται σημαντικά και στα τρία μη γραμμικά χαρακτηριστικά για ηλεκτροεγκεφαλογραφήματα εγρήγορσης και υπνηλίας.



Εικόνα 5.2: (a) Higuchi FD για άτομο σε επαγρύπνηση, (b) DFA για άτομο σε επαγρύπνηση, (c) Petrosian FD για άτομο σε επαγρύπνηση, (d) Higuchi FD για άτομο σε υπνηλία, (e) DFA για άτομο σε υπνηλία, (f) Petrosian FD για άτομο σε υπνηλία [52].

Η καμπύλη Receiver Operating Characteristics (ROC) είναι ένα διάστατο μέτρο της απόδοσης της ταξινόμησης. Το διάγραμμα ROC παρέχει μια όψη του φάσματος των ευαισθησιών και εξειδικεύσεων. Για μια αποτελεσματική δοκιμή της απόδοσης, η ευαισθησία αυξάνεται ραγδαία και 1-εξειδίκευση αυξάνει ελάχιστα, έως ότου η ευαισθησία γίνει σημαντικά μεγάλη [243]. Το εμβαδό κάτω από την καμπύλη (Area Under Curve-AUC) του διαγράμματος ROC δίνει ένα μέτρο της συνολικής απόδοσης ταξινομητή. Η μέθοδος ταξινόμησης με το μεγαλύτερο AUC παρουσιάζει καλύτερη απόδοση ταξινόμησης σε ένα εύρος κατωφλίων. Η απόδοση του LS-SVM αξιολογείται με τη γραφική παράσταση ROC που φαίνεται στο Σχήμα 5.5 χρησιμοποιώντας την πολυωνυμική και την RBF συνάρτηση πυρήνα. Μπορεί να παρατηρηθεί ότι το εμβαδό ROC για πολυωνυμική και RBF συνάρτηση πυρήνα είναι 0.99989 και 0.98037, αντίστοιχα, γεγονός που δείχνει ότι η πολυωνυμική συνάρτηση πυρήνα είναι καλύτερη από ό, τι η RBF συνάρτηση πυρήνα για το έργο της αυτόματης ανίχνευσης της επαγρύπνησης χρησιμοποιώντας σήματα ΗΕΓ.



Σχήμα 5.5: Καμπύλη ROC για LS-SVM με χρήση πολυωνυμικής συνάρτησης πυρήνα και συνάρτησης πυρήνα ακτινικής βάσης [52].

Η απόδοση της δοκιμής ταξινόμησης που προέκυψε για το πρώτο σύνολο δεδομένων επαγρύπνησης και υπνηλίας επαληθεύεται από μεγάλα σύνολα δεδομένων HEG που καταγράφονται από 20 άτομα σε εγρήγορση και υπνηλία, χρησιμοποιώντας μόνο χαρακτηριστικά που βασίζονται στην επιμέρους ζώνη συχνοτήτων άλφα-βήτα. Η απόδοση της δοκιμής ταξινόμησης των ταξινομητών SVM (με συνάρτηση πυρήνα PUK), του LS-SVM (με πολυωνυμική συνάρτηση πυρήνα) και ANN, καθορίζεται από τον υπολογισμό της ευαισθησίας (SEN), της εξειδίκευσης (SPE) και της ακρίβειας (ACC).

Ο μέσος όρος της ακρίβειας ταξινόμησης, της ευαισθησίας και της εξειδίκευσης των SVM, LS-SVM και ANN ταξινομητών για τα δεδομένα HEG των 20 ατόμων, παρουσιάζεται στον Πίνακα 5.16 [52]. Τα μη γραμμικά χαρακτηριστικά (Higuchi FD, Petrosian FD και DFA) που χρησιμοποιήθηκαν για την εκπαίδευση και τη δοκιμή των αλγορίθμων ταξινόμησης εξάγονται μόνο για την επιμέρους ζώνη συχνοτήτων άλφα-βήτα. Η ταξινόμηση πραγματοποιείται με τη χρήση της μεθόδου 10-fold cross validation για να εξασφαλιστεί η απουσία στατιστικού λάθους στα αποτελέσματα.

Τα αποτελέσματα της ταξινόμησης που λαμβάνονται από τον Πίνακα 5.16 για δέκα σετ δεδομένων HEG σε εγρήγορση και υπνηλία, εγκρίνουν την ικανότητα του SVM ταξινομητή (με συνάρτηση πυρήνα PUK) για το έργο της αυτόματης ανίχνευσης της επαγρύπνησης, χρησιμοποιώντας σήματα HEG. Ο ταξινομητής SVM ταξινομεί τις δύο κατηγορίες (τάξεις) δεδομένων -εγρήγορση και υπνηλία- με 98.84% ακρίβεια, 98.83% ευαισθησία και 98.75% εξειδίκευση. Ο ταξινομητής SVM υπερτερεί μεταξύ των άλλων δύο τεχνικών ταξινόμησης για τα χαρακτηριστικά που βασίζονται στην άλφα-βήτα ζώνη συχνοτήτων. Μια συγκριτική μελέτη μεταξύ της παρούσας εργασίας και της δημοσιευμένης βιβλιογραφίας φαίνεται στον Πίνακα 5.17 [52].

Πίνακας 5.16:

Απόδοση των ταξινομητών SVM με πυρήνα PUK, LS-SVM με πολυωνυμικό πυρήνα και ANN για τη ζώνη συχνοτήτων άλφα-βήτα.

| Classifiers | Accuracy (%) | Sensitivity | Specificity |
|-------------|--------------|-------------|-------------|
| SVM | 98.84 | 98.83 | 98.75 |
| LS-SVM | 98.58 | 98.75 | 98.40 |
| NN | 98.30 | 98.57 | 98.04 |

Πίνακας 5.17:


Συγκριτική μελέτη μεταξύ της παρούσας εργασίας και προηγούμενων ερευνητικών εργασιών δημοσιευμένων στη βιβλιογραφία.

| References | Classifier used | Classes | Dimension reduction technique | Feature extraction methodology | Classification efficiency (%) | |
|------------------------|-----------------|-----------------------|-------------------------------|--------------------------------|--|-----------------------------------|
| | | | | | Single subject | Average classification efficiency |
| Kousarrizi et al. [23] | SVM/NN | Alert & alcoholic | Principal component analysis | Haar wavelet based features | NA | SVM-94.67% NN-98.83% |
| Vyas et al. [24] | SVM | Alert & alcoholic | Principal component analysis | Discrete wavelet transform | SVM-99.22% | NA |
| Pan et al. [25] | RF | Alert, drowsy & sleep | RF based | Fractal dimension | NA | RF-92% |
| Yildiz et al. [1] | ANFIS | Alert, drowsy & sleep | Entropy based | Discrete wavelet transform | NA | ANFIS-98.34 |
| Sobasi [9] | ANN | Alert, drowsy & sleep | NA | Discrete wavelet transform | NA | ANN-93.33% |
| Present work | SVM/LS-SVM/ANN | Alert & alcoholic | Energy-entropy based approach | Nonlinear parameters | SVM-100% LS-SVM-99.28% NN-99.28% | SVM-98.84% LS-SVM NN-98.30% |

Από την παράθεση των πειραματικών αποτελεσμάτων παρατηρούμε ότι τα μη γραμμικά χαρακτηριστικά των σημάτων ΗΕΓ έχουν καλή διακριτική ικανότητα για το έργο εντοπισμού του επιπέδου επαγρύπνησης. Στη συγκεκριμένη μεθοδολογία, η βελτιστοποίηση των ΗΕΓ καναλιών γίνεται πριν από την εξαγωγή χαρακτηριστικών και τα μη γραμμικά χαρακτηριστικά εξάγονται από τα βελτιστοποιημένα ΗΕΓ κανάλια για την ανίχνευση του επιπέδου επαγρύπνησης. Παρατηρείται ότι όλοι οι ταξινομητές θα μπορούσαν να διακρίνουν μεταξύ της κατάστασης επαγρύπνησης και της υπνηλίας με υψηλή ακρίβεια ταξινόμησης, για μη-γραμμικά χαρακτηριστικά τα οποία βασίζονται στη ζώνη συχνοτήτων άλφα-βήτα. Τα αποτελέσματα δείχνουν ότι ο SVM με συνάρτηση πυρήνα PUK είναι η καλύτερη τεχνική μηχανικής μάθησης για την ανίχνευση του επιπέδου επαγρύπνησης χρησιμοποιώντας σήματα ΗΕΓ. Η προτεινόμενη μεθοδολογία εξαγωγής χαρακτηριστικών με τεχνικές μηχανικής μάθησης έχει πιθανή εφαρμογή στην ανάπτυξη ενός συστήματος ανίχνευσης του επιπέδου νοητικής επαγρύπνησης, πραγματικού χρόνου.

Τεχνική βασισμένη στο AR μοντέλο

Η τρίτη τεχνική που μελετήσαμε αφορά την εξαγωγή χαρακτηριστικών στο πεδίο της συχνότητας και πιο συγκεκριμένα στηρίζεται στο autoregressive (AR) model. Για να εκτιμηθεί η ιδιότητα του προτεινόμενου αλγόριθμου ανίχνευσης επιληπτικών κρίσεων, χρησιμοποιήθηκε το σύνολο δεδομένων επιληπτικών ΗΕΓ της Βόννης. Δεδομένου ότι το ΗΕΓ είναι ένα μη γραμμικό και μη σταθερό σήμα στη φύση, η συμβατική μέθοδος ανάλυσης του πεδίου συχνότητας, όπως ο FFT, μπορεί να αποκαλύψει μόνο τους ολιστικούς χαρακτήρες του σήματος ΗΕΓ, ενώ τα επιληπτικά χαρακτηριστικά κύματα μπορεί να εμφανιστούν στιγμιαία. Προκειμένου, λοιπόν, να καταγραφούν οι παροδικές συμπεριφορές του σήματος ΗΕΓ, εφαρμόστηκε η μέθοδος VMD. Χρησιμοποιώντας το VMD, η αρχική ΗΕΓ εγγραφή αποσυντέθηκε σε ένα σταθερό αριθμό BLIMFs. Οι τυπικές κυματομορφές ΗΕΓ (μία από κάθε τάξη) και οι αντίστοιχες BLIMFs τους, απεικονίζονται στην Εικόνα 5.3. Στο σχήμα αυτό, οι BLIMFs είναι διατεταγμένες από τη χαμηλότερη προς την υψηλότερη συνιστώσα συχνότητας και οι αντίστοιχες κεντρικές τους συχνότητες υπολογίζονται ταυτόχρονα. Παρ' όλα αυτά, όπως παρουσιάστηκε στο [82], όταν χρησιμοποιήθηκε η μέθοδος EMD για την ανάλυση του ΗΕΓ, οι IMFs δημιουργήθηκαν αναδρομικά. Ειδικότερα, η IMF_1 περιέχει τη συνιστώσα υψηλότερης συχνότητας, μια συνιστώσα χαμηλότερης συχνότητας περιλαμβάνεται στην IMF_2 και ούτω καθεξής. Το πιο σημαντικό από όλα, ωστόσο, είναι ότι ο αριθμός των BLIMFs είναι μεταβλητός και εξαρτάται μόνο από το πόσες BLIMFs θέλει ο ερευνητής, αλλά ο αριθμός των IMFs είναι εγγενής και αμετάβλητος.



Εικόνα 5.3: Διαγράμματα του αρχικού ΗΕΓ (πρώτη γραμμή) και των αντίστοιχών του BLIMFs (γραμμές από δύο έως δεκαέξι) [68].

Μετά την εκτέλεση της VMD, η αρχική εγγραφή ΗΕΓ διασπάστηκε ταυτόχρονα σε δεκαπέντε BLIMFs, οι οποίες στη συνέχεια λογαριθμίστηκαν. Στη συνέχεια, τέθηκαν σε εφαρμογή τέσσερα είδη κριτηρίων τάξης για να προσδιοριστεί η βέλτιστη AR τάξη και τα αντίστοιχα AR μοντέλα τους κατασκευάστηκαν χρησιμοποιώντας τη μέθοδο του Burg. Δεδομένου ότι η βέλτιστη τάξη οδήγησε σε ποικίλες διαστάσεις των AR συνιστωσών, διεξήχθη μια δευτερεύουσα διαδικασία εξαγωγής χαρακτηριστικών. Οι Πίνακες 5.18-5.20 [68] δείχνουν τις στατιστικές τιμές οκτώ χαρακτηριστικών των τριών τάξεων ΗΕΓ (δηλ. φυσιολογικό ΗΕΓ, ΗΕΓ στο διάστημα μεταξύ δύο επιληπτικών κρίσεων και ΗΕΓ κατά τη διάρκεια επιληπτικής κρίσης), χρησιμοποιώντας το κριτήριο FPE και ενώ η τιμή του α ήταν 3. Μπορεί να παρατηρηθεί ότι οι μέσες τιμές ενέργειας και η διακύμανση των AR παραμέτρων είναι οι πιο αξιοσημείωτες διαφορές μεταξύ των φυσιολογικών/επιληπτικών ΗΕΓ στο διάστημα μεταξύ κρίσεων και επιληπτικών εν μέσω κρίσης ΗΕΓ, οι τιμές των ΗΕΓ σημάτων εν μέσω κρίσης είναι υψηλότερες από εκείνες των κανονικών/ επιληπτικών στο διάστημα μεταξύ κρίσεων ΗΕΓ εγγραφών. Από την άλλη πλευρά, οι στατιστικές τιμές της μέσης τιμής των AR παραμέτρων, παρέχουν τη δυνατότητα διαφοροποίησης των φυσιολογικών ΗΕΓ από τα επιληπτικά ΗΕΓ στο διάστημα μεταξύ κρίσεων και τα ΗΕΓ εν μέσω κρίσης.

Πίνακας 5.18

Στατιστικές τιμές (μέση τιμή ± τυπική απόκλιση) της φυσιολογικής τάξης των ΗΕΓ.

| Feature | Energy | Length | Maximum | Minimum | Mean | Variance | Skewness | Kurtosis |
|---------------------|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|
| BLIMF ₁ | 0.7230 ± 0.5699 | 60.750 ± 81.116 | 0.0933 ± 0.1074 | -0.692 ± 0.2793 | -0.046 ± 0.0312 | 0.0237 ± 0.0201 | -4.302 ± 4.6160 | 45.215 ± 80.973 |
| BLIMF ₂ | 0.6507 ± 0.1922 | 55.475 ± 15.690 | 0.0817 ± 0.0261 | -0.711 ± 0.1428 | -0.014 ± 0.0104 | 0.0132 ± 0.0070 | -5.272 ± 0.8973 | 33.603 ± 9.8470 |
| BLIMF ₃ | 0.5953 ± 0.2015 | 43.365 ± 14.094 | 0.2594 ± 0.1907 | -0.597 ± 0.1161 | 0.0050 ± 0.0101 | 0.0158 ± 0.0081 | -3.080 ± 2.0501 | 21.827 ± 8.3064 |
| BLIMF ₄ | 0.5883 ± 0.2414 | 45.490 ± 18.746 | 0.4365 ± 0.2020 | -0.428 ± 0.0874 | 0.0133 ± 0.0091 | 0.0147 ± 0.0068 | -0.037 ± 2.0580 | 15.328 ± 6.9210 |
| BLIMF ₅ | 0.5048 ± 0.1616 | 51.950 ± 18.676 | 0.4565 ± 0.1424 | -0.350 ± 0.0525 | 0.0110 ± 0.0065 | 0.0112 ± 0.0055 | 1.1931 ± 1.2072 | 15.185 ± 6.6346 |
| BLIMF ₆ | 0.3804 ± 0.1170 | 47.385 ± 16.753 | 0.3802 ± 0.1061 | -0.280 ± 0.0438 | 0.0087 ± 0.0054 | 0.0091 ± 0.0042 | 1.1973 ± 0.8508 | 11.841 ± 5.1632 |
| BLIMF ₇ | 0.3304 ± 0.0825 | 43.090 ± 13.948 | 0.3727 ± 0.0855 | -0.229 ± 0.0358 | 0.0082 ± 0.0047 | 0.0086 ± 0.0037 | 1.4616 ± 0.7908 | 10.953 ± 4.8202 |
| BLIMF ₈ | 0.3015 ± 0.0689 | 45.095 ± 15.362 | 0.3497 ± 0.0727 | -0.210 ± 0.0514 | 0.0074 ± 0.0051 | 0.0076 ± 0.0032 | 1.4539 ± 0.8228 | 10.946 ± 4.6659 |
| BLIMF ₉ | 0.1234 ± 0.0895 | 88.050 ± 41.955 | 0.1415 ± 0.1087 | -0.173 ± 0.0420 | 0.0011 ± 0.0054 | 0.0024 ± 0.0034 | -0.983 ± 1.4700 | 33.426 ± 6.2567 |
| BLIMF ₁₀ | 0.2471 ± 0.0721 | 36.440 ± 14.849 | 0.3122 ± 0.0763 | -0.190 ± 0.0489 | 0.0077 ± 0.0057 | 0.0077 ± 0.0029 | 1.1805 ± 0.7527 | 8.4220 ± 3.8241 |
| BLIMF ₁₁ | 0.1726 ± 0.0776 | 27.830 ± 18.902 | 0.2557 ± 0.1213 | -0.174 ± 0.0566 | 0.0045 ± 0.0137 | 0.0077 ± 0.0036 | 0.7392 ± 1.4797 | 7.8440 ± 3.7872 |
| BLIMF ₁₂ | 0.1153 ± 0.0499 | 15.015 ± 7.4196 | 0.1335 ± 0.0898 | -0.227 ± 0.1022 | -0.005 ± 0.0191 | 0.0088 ± 0.0039 | -0.726 ± 1.6644 | 6.3317 ± 2.5691 |
| BLIMF ₁₃ | 0.0913 ± 0.0337 | 12.575 ± 5.7628 | 0.1500 ± 0.0810 | -0.199 ± 0.0804 | 0.0038 ± 0.0158 | 0.0085 ± 0.0037 | -0.738 ± 1.4813 | 5.8633 ± 2.5948 |
| BLIMF ₁₄ | 0.0756 ± 0.0306 | 25.995 ± 21.592 | 0.2003 ± 0.0538 | -0.102 ± 0.0330 | 0.0089 ± 0.0060 | 0.0040 ± 0.0021 | 1.5537 ± 1.0846 | 9.0922 ± 7.6117 |
| BLIMF ₁₅ | 0.2316 ± 0.0824 | 7.410 ± 6.3001 | 0.4612 ± 0.0788 | -0.091 ± 0.0234 | 0.0805 ± 0.0386 | 0.0511 ± 0.0263 | 1.5529 ± 0.9803 | 4.9594 ± 5.0497 |

Πίνακας 5.19

Στατιστικές τιμές (μέση τιμή ± τυπική απόκλιση) της τάξης των ΗΕΓ στο διάστημα μεταξύ δύο κρίσεων.

| Feature | Energy | Length | Maximum | Minimum | Mean | Variance | Skewness | Kurtosis |
|---------------------|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|
| BLIMF ₁ | 0.7877 ± 0.5964 | 79.050 ± 85.749 | 0.1206 ± 0.1574 | -0.714 ± 0.2520 | -0.034 ± 0.0298 | 0.0211 ± 0.0271 | -5.102 ± 4.6885 | 58.513 ± 80.911 |
| BLIMF ₂ | 0.7236 ± 0.3528 | 68.085 ± 21.911 | 0.0908 ± 0.0528 | -0.738 ± 0.2173 | -0.014 ± 0.0111 | 0.0120 ± 0.0078 | -5.761 ± 1.3889 | 42.800 ± 16.075 |
| BLIMF ₃ | 0.6231 ± 0.2079 | 60.015 ± 40.687 | 0.1228 ± 0.0790 | -0.676 ± 0.1922 | -0.007 ± 0.0058 | 0.0118 ± 0.0063 | -5.047 ± 1.2516 | 33.733 ± 12.466 |
| BLIMF ₄ | 0.4810 ± 0.2196 | 47.110 ± 14.902 | 0.2090 ± 0.0960 | -0.534 ± 0.1651 | 0.0027 ± 0.0057 | 0.0116 ± 0.0067 | -3.109 ± 1.2577 | 19.470 ± 8.1918 |
| BLIMF ₅ | 0.3385 ± 0.1821 | 43.870 ± 14.852 | 0.2673 ± 0.1048 | -0.406 ± 0.1303 | 0.0073 ± 0.0064 | 0.0104 ± 0.0073 | -1.320 ± 1.0350 | 12.283 ± 4.2385 |
| BLIMF ₆ | 0.3091 ± 0.1610 | 41.410 ± 13.811 | 0.2798 ± 0.1173 | -0.308 ± 0.0928 | 0.0075 ± 0.0068 | 0.0085 ± 0.0060 | -0.155 ± 0.8297 | 9.4300 ± 4.1166 |
| BLIMF ₇ | 0.2603 ± 0.1429 | 37.950 ± 12.036 | 0.2956 ± 0.1143 | -0.231 ± 0.0760 | 0.0081 ± 0.0058 | 0.0074 ± 0.0043 | 0.7803 ± 0.7798 | 8.3779 ± 3.8897 |
| BLIMF ₈ | 0.2091 ± 0.1241 | 34.585 ± 14.353 | 0.2800 ± 0.0948 | -0.174 ± 0.0639 | 0.0086 ± 0.0065 | 0.0067 ± 0.0040 | 1.1353 ± 0.7480 | 7.7872 ± 3.3283 |
| BLIMF ₉ | 0.1461 ± 0.1028 | 49.660 ± 30.258 | 0.1860 ± 0.1241 | -0.177 ± 0.0556 | 0.0038 ± 0.0075 | 0.0044 ± 0.0038 | -0.469 ± 1.9975 | 11.625 ± 6.9772 |
| BLIMF ₁₀ | 0.1495 ± 0.0865 | 23.870 ± 13.542 | 0.2541 ± 0.0885 | -0.137 ± 0.0571 | 0.0109 ± 0.0115 | 0.0076 ± 0.0049 | 1.1020 ± 1.0808 | 5.7583 ± 3.1736 |
| BLIMF ₁₁ | 0.1173 ± 0.0578 | 22.670 ± 18.174 | 0.1659 ± 0.0909 | -0.194 ± 0.1024 | 0.0016 ± 0.0164 | 0.0073 ± 0.0043 | -0.300 ± 1.7864 | 7.2320 ± 3.6526 |
| BLIMF ₁₂ | 0.0033 ± 0.0472 | 16.805 ± 14.377 | 0.1738 ± 0.1079 | -0.192 ± 0.1115 | 0.0043 ± 0.0214 | 0.0094 ± 0.0054 | -0.160 ± 1.8311 | 6.6957 ± 3.1975 |
| BLIMF ₁₃ | 0.1024 ± 0.0389 | 12.600 ± 5.4625 | 0.1603 ± 0.0777 | -0.214 ± 0.0895 | 0.0050 ± 0.0144 | 0.0097 ± 0.0045 | -0.668 ± 1.5070 | 5.9053 ± 2.6478 |
| BLIMF ₁₄ | 0.0841 ± 0.0298 | 18.045 ± 14.023 | 0.1979 ± 0.0493 | -0.118 ± 0.0400 | 0.0124 ± 0.0087 | 0.0063 ± 0.0031 | 0.9885 ± 0.9562 | 5.7589 ± 4.3768 |
| BLIMF ₁₅ | 0.2252 ± 0.0093 | 8.0800 ± 10.649 | 0.4516 ± 0.0937 | -0.088 ± 0.0272 | 0.0777 ± 0.0387 | 0.0489 ± 0.0267 | 1.490 ± 1.0486 | 4.9405 ± 4.9055 |


Πίνακας 5.20

Στατιστικές τιμές (μέση τιμή ± τυπική απόκλιση) της τάξης των ΗΕΓ εν μέσω κρίσης.

| Feature | Energy | Length | Maximum | Minimum | Mean | Variance | Skewness | Kurtosis |
|---------------------|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|
| BLIMF ₁ | 1.6612 ± 0.5996 | 51.720 ± 37.161 | 0.2873 ± 0.1523 | -1.178 ± 0.2547 | -0.027 ± 0.0227 | 0.0474 ± 0.0342 | -5.200 ± 2.1084 | 37.713 ± 29.155 |
| BLIMF ₂ | 1.4083 ± 0.4019 | 60.860 ± 38.237 | 0.3336 ± 0.0990 | -1.066 ± 0.2124 | -0.008 ± 0.0077 | 0.0268 ± 0.0128 | -5.250 ± 1.3100 | 41.420 ± 13.866 |
| BLIMF ₃ | 1.0529 ± 0.2249 | 51.810 ± 30.763 | 0.4128 ± 0.1635 | -0.814 ± 0.2121 | -0.004 ± 0.0114 | 0.0260 ± 0.0123 | -2.717 ± 2.5259 | 25.896 ± 13.484 |
| BLIMF ₄ | 0.9608 ± 0.1672 | 47.080 ± 31.920 | 0.6165 ± 0.1930 | -0.554 ± 0.1788 | 0.0148 ± 0.0197 | 0.0291 ± 0.0164 | 0.0204 ± 2.3914 | 17.685 ± 9.7603 |
| BLIMF ₅ | 1.0207 ± 0.2535 | 48.240 ± 27.694 | 0.7579 ± 0.1909 | -0.386 ± 0.1212 | 0.0219 ± 0.0197 | 0.0273 ± 0.0148 | 2.3952 ± 1.8268 | 19.167 ± 12.030 |
| BLIMF ₆ | 1.0355 ± 0.3270 | 47.620 ± 25.793 | 0.8081 ± 0.2272 | -0.329 ± 0.0937 | 0.0233 ± 0.0218 | 0.0298 ± 0.0205 | 2.9188 ± 1.5571 | 20.507 ± 11.151 |
| BLIMF ₇ | 0.9839 ± 0.3651 | 43.300 ± 21.312 | 0.7823 ± 0.2569 | -0.324 ± 0.1423 | 0.0198 ± 0.0182 | 0.0291 ± 0.0171 | 2.7621 ± 1.9728 | 20.079 ± 11.037 |
| BLIMF ₈ | 0.8919 ± 0.3877 | 41.240 ± 21.921 | 0.7177 ± 0.2666 | -0.331 ± 0.1732 | 0.0198 ± 0.0192 | 0.0280 ± 0.0200 | 2.3629 ± 2.0325 | 18.219 ± 10.783 |
| BLIMF ₉ | 0.8493 ± 0.4013 | 42.719 ± 22.596 | 0.7217 ± 0.2714 | -0.276 ± 0.1423 | 0.0201 ± 0.0194 | 0.0261 ± 0.0194 | 2.7885 ± 1.9660 | 19.663 ± 12.974 |
| BLIMF ₁₀ | 0.6797 ± 0.3255 | 39.700 ± 18.973 | 0.5869 ± 0.2252 | -0.323 ± 0.1720 | 0.0156 ± 0.0157 | 0.0225 ± 0.0169 | 1.8509 ± 1.8225 | 15.022 ± 8.2580 |
| BLIMF ₁₁ | 0.6382 ± 0.3900 | 36.110 ± 14.481 | 0.6006 ± 0.2948 | -0.245 ± 0.1359 | 0.0160 ± 0.0181 | 0.0216 ± 0.0185 | 2.2500 ± 2.0037 | 15.921 ± 8.9194 |
| BLIMF ₁₂ | 0.4690 ± 0.2087 | 31.760 ± 13.583 | 0.4274 ± 0.2028 | -0.309 ± 0.1972 | 0.0098 ± 0.0155 | 0.0179 ± 0.0134 | 1.0733 ± 1.9594 | 11.706 ± 7.5572 |
| BLIMF ₁₃ | 0.2590 ± 0.1898 | 26.390 ± 15.206 | 0.2710 ± 0.1662 | -0.266 ± 0.1236 | 0.0050 ± 0.0106 | 0.0115 ± 0.0086 | 0.0715 ± 1.7527 | 8.4020 ± 5.5677 |
| BLIMF ₁₄ | 0.1834 ± 0.1413 | 19.010 ± 11.115 | 0.2496 ± 0.1306 | -0.197 ± 0.0896 | 0.0105 ± 0.0116 | 0.0101 ± 0.0053 | 0.3990 ± 1.1841 | 5.8813 ± 3.4540 |
| BLIMF ₁₅ | 0.1567 ± 0.1151 | 15.290 ± 6.7404 | 0.3013 ± 0.1377 | -0.135 ± 0.0728 | 0.0224 ± 0.0245 | 0.0143 ± 0.0143 | 1.3677 ± 1.3076 | 7.0310 ± 4.3563 |

Για να επικυρωθεί η αποτελεσματικότητα του προτεινόμενου αλγόριθμου εξαγωγής τετραγωνικών χαρακτηριστικών στο VMD πεδίο, εξερευνήθηκε ο νεο-αναπτυχθείς ταξινομητής τυχαίου δάσους [103, 244] στη διαδικασία ταξινόμησης. Η απόδοση ταξινόμησης του τυχαίου δάσους συνδέεται με τον αριθμό των δέντρων απόφασης ως συνέπεια του γεγονότος ότι ένα τυχαίο δάσος είναι η συνάθροιση δέντρων αποφάσεων [103]. Επομένως, σε αυτή τη μελέτη, διερευνήσαμε αρχικά τις επιδόσεις ταξινόμησης του τυχαίου δάσους με τη μεταβολή των αριθμών των δέντρων αποφάσεων. Η Εικόνα 5.4 παρουσιάζει τα συνεχή σφάλματα ταξινόμησης με την αύξηση των αναπτυγμένων (grown) δέντρων χρησιμοποιώντας τα τέσσερα κριτήρια που αναφέρθηκαν παραπάνω όταν το α ήταν 3. Όπως φαίνεται στην Εικόνα 5.4, ανεξάρτητα από το ποιο κριτήριο χρησιμοποιήθηκε, η αύξηση του αριθμού των δέντρων αποφάσεων, μειώνει γρήγορα τα σφάλματα ταξινόμησης όταν ο αριθμός των δέντρων είναι μικρότερος από 100, ενώ τα σφάλματα ταξινόμησης παραμένουν χαμηλά όταν ο αριθμός των δέντρων είναι μεγαλύτερος από 250. Το φαινόμενο αυτό καταδεικνύει ότι η δομή του ταξινομητή τυχαίου δάσους είναι σταθερή και επιτυγχάνεται το καλύτερο αντιστάθμισμα μεταξύ συσχέτισης και δύναμης (strength).

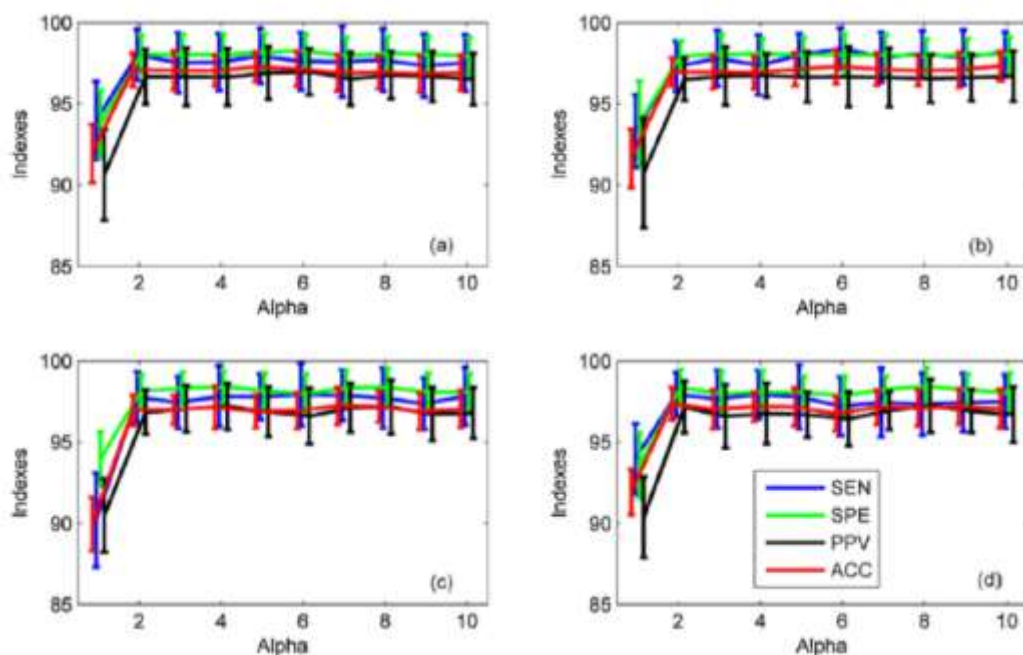
Έτσι, στα επόμενα πειράματα, ο αριθμός των δέντρων αποφάσεων του τυχαίου δάσους ορίστηκε σε 250.



Εικόνα 5.4: Σφάλματα ταξινόμησης με μεταβολή του αριθμού των αναπτυγμένων δέντρων, χρησιμοποιώντας τέσσερα κριτήρια [68].

Για να εκθέσουμε τις επιρροές του α και των κριτηρίων στην απόδοση ταξινόμησης, εκτελέστηκαν ανεξάρτητα πειράματα ταξινόμησης φυσιολογικών σημάτων, επιληπτικών σημάτων στο διάστημα μεταξύ δύο κρίσεων και επιληπτικών σημάτων εν μέσω κρίσης, 20 φορές για κάθε συνδυασμό, αντίστοιχα. Σε κάθε πείραμα διεξήχθη η τεχνική 10-folds cross validation. Συγκεκριμένα, ολόκληρο το σύνολο δεδομένων διανυσμάτων χαρακτηριστικών, χωρίστηκε τυχαία σε 10 ομάδες. Στη συνέχεια, εννέα ομάδες επιλέχθηκαν εναλλάξ ως σύνολα εκπαίδευσης για να εκπαιδεύσουν το μοντέλο του ταξινομητή και η υπολειπόμενη ομάδα χρησιμοποιήθηκε για να τεστάρει το μοντέλο που καθιερώθηκε. Έτσι, συνολικά εκτελέστηκαν δέκα υπο-πειράματα και η τελική ακρίβεια ήταν η μέση τιμή των ακριβειών αυτών των δέκα υπο-πειραμάτων. Οι τελικοί δείκτες αξιολόγησης της ταξινόμησης (SEN, SPE, PPV και ACC) παρουσιάζονται στην Εικόνα 5.5. Όταν το α είναι 1, η εφαρμογή λογαρίθμου δεν έχει νόημα. Έτσι, στις Εικόνες 5.5 και 5.6, οι δείκτες της περίπτωσης $\alpha=1$ αντιστοιχούν σε αποδόσεις τυχαίου δάσους που χρησιμοποιούν εξαγωγή τετραγωνικών χαρακτηριστικών βασισμένη στο AR ή σταθερής τάξης εξαγωγή χαρακτηριστικών βασισμένη στο AR, χωρίς χρήση λογαρίθμου. Μπορεί προφανώς να παρατηρηθεί ότι το α διαδραματίζει καθοριστικό ρόλο στον καθορισμό του βέλτιστου AR μοντέλου, καθώς επίσης και της μελλοντικής ακρίβειας ταξινόμησης. Εν τω μεταξύ, μπορεί να βρεθεί από την Εικόνα 5.5 ότι η λογαριθμική διαδικασία ενισχύει πράγματι την επακόλουθη απόδοση ταξινόμησης ανεξάρτητα από το ποιο κριτήριο χρησιμοποιήθηκε. Χωρίς τη χρήση λογαρίθμου, οι μέσες τιμές ακρίβειας ταξινόμησης, που αντιστοιχούν στις εφαρμογές FPE, AIC, BIC και CAT, είναι 91.936%, 91.64%, 89.944% και 91.928%, αντίστοιχα. Από την άλλη πλευρά, οι μέσες τιμές ακρίβειας ταξινόμησης με τη χρήση των προαναφερθέντων κριτηρίων και της λογαριθμικής λειτουργίας είναι μεγαλύτερες ή ίσες με 96.912%, 96.92%, 96.872% και 96.76%, αντίστοιχα. Από τα παραπάνω πειραματικά αποτελέσματα, μπορούμε να συμπεράνουμε ότι οι τελικοί δείκτες ταξινόμησης έχουν ελάχιστη σχέση με την τιμή του α . Όπως μπορούμε να δούμε από

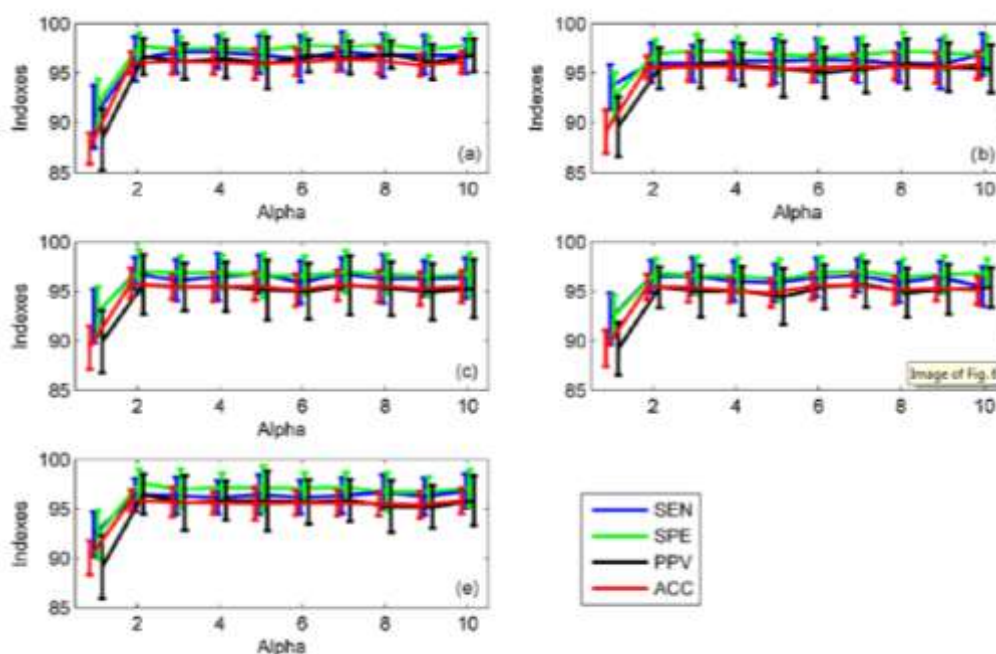
την Εικόνα 5.5, οι μέσες τιμές αυτών των δεικτών, συγκεκριμένα των SEN, SPE, PPV και ACC, δείχνουν ελάχιστη μεταβολή με την αύξηση του α . Συγκρίνοντας αυτά τα τέσσερα υπο-γραφήματα, το τέταρτο κριτήριο, δηλαδή το CAT, είναι πιο ευαίσθητο στο α απ' ό,τι άλλα κριτήρια. Συγκεκριμένα, οι υψηλότερες ακρίβειες ταξινόμησης του ταξινομητή τυχαίου δάσους με χρήση FPE, AIC, BIC και CAT είναι 97.28%, 97.32%, 97.232% και 97.352% αντίστοιχα και αποδεικνύουν την αποτελεσματικότητα της προσέγγισής μας.



Εικόνα 5.5: Αποδόσεις του ταξινομητή τυχαίου δάσους με τη μεταβολή του α , χρησιμοποιώντας διαφορετικά κριτήρια. (a) Αποδόσεις του ταξινομητή τυχαίου δάσους με τη μεταβολή του α , χρησιμοποιώντας το κριτήριο FPE. (b) Αποδόσεις του ταξινομητή τυχαίου δάσους με τη μεταβολή του α , χρησιμοποιώντας το κριτήριο AIC. (c) Αποδόσεις του ταξινομητή τυχαίου δάσους με τη μεταβολή του α , χρησιμοποιώντας το κριτήριο BIC. (d) Αποδόσεις του ταξινομητή τυχαίου δάσους με τη μεταβολή του α , χρησιμοποιώντας το κριτήριο CAT [68].

Προκειμένου να επισημανθεί το πλεονέκτημα της εξαγωγής τετραγωνικών χαρακτηριστικών, διεξήγαμε επίσης την εξαγωγή χαρακτηριστικών σταθερής τάξης που βασίζεται στο AR, σε BLIMFs και nBLIMFs, αντί να εφαρμόσουμε την προτεινόμενη εξαγωγή τετραγωνικών χαρακτηριστικών. Συγκεκριμένα, σχεδιάσαμε ένα άλλο πείραμα: το VMD χρησιμοποιήθηκε αρχικά για να αποσυνθέσει το αρχικό HEΓ σε 15 BLIMFs. Τότε, η λογαριθμική διαδικασία που περιγράφεται στην Εξίσωση (6) επιβλήθηκε στις BLIMF. Στη συνέχεια, χρησιμοποιήθηκαν πέντε είδη AR μοντέλων σταθερής τάξης (έκτης, έβδομος, όγδοος, ένατος και δέκατος) για την εξαγωγή των AR συνιστωσών, αντίστοιχα. Τέλος, οι συνιστώσες όλων των nBLIMFs συνενώθηκαν και τροφοδοτήθηκαν στον ταξινομητή τυχαίου δάσους για ταξινόμηση. Τα πειραματικά αποτελέσματα φαίνονται στην Εικόνα 5.6. Όπως απεικονίζεται στην Εικόνα 5.6, η λογαριθμική συνάρτηση για άλλη μια φορά δείχνει την αποτελεσματικότητά της. Συγκεκριμένα, εάν η λογαρίθμηση δεν υιοθετηθεί και τα AR μοντέλα σταθερής τάξης εφαρμοστούν απευθείας στις BLIMFs για να υπολογιστούν οι παράμετροι AR, οι ακρίβειες για τη χρήση αυτών των πέντε τύπων AR μοντέλων σταθερής τάξης, είναι όλες μικρότερες από 90%. Αντίθετα, με την

εφαρμογή της λογαριθμικής λειτουργίας, οι καλύτερες ακρίβειες του ταξινομητή τυχαίου δάσους με την εφαρμογή AR μοντέλων έκτης, έβδομης, όγδοης, ένατης και δέκατης τάξης ανέρχονται σε 96.384%, 95.816%, 95.84%, 95.672% και 95.872%, αντίστοιχα. Εκτός αυτού, μπορεί να παρατηρηθεί ότι και οι τιμές του α έχουν παρομοίως μικρό αντίκτυπο στις αποδόσεις ταξινόμησης.



Εικόνα 5.6: Αποδόσεις του ταξινομητή τυχαίου δάσους με τη μεταβολή του α , χρησιμοποιώντας διαφορετικά AR μοντέλα σταθερής τάξης. (a) Αποδόσεις του ταξινομητή τυχαίου δάσους με τη μεταβολή του α , χρησιμοποιώντας AR μοντέλα έκτης τάξης. (b) Αποδόσεις του ταξινομητή τυχαίου δάσους με τη μεταβολή του α , χρησιμοποιώντας AR μοντέλα έβδομης τάξης. (c) Αποδόσεις του ταξινομητή τυχαίου δάσους με τη μεταβολή του α , χρησιμοποιώντας AR μοντέλα όγδοης τάξης. (d) Αποδόσεις του ταξινομητή τυχαίου δάσους με τη μεταβολή του α , χρησιμοποιώντας AR μοντέλα ένατης τάξης. (e) Αποδόσεις του ταξινομητή τυχαίου δάσους με τη μεταβολή του α , χρησιμοποιώντας AR μοντέλα δέκατης τάξης [68].

Συγκρίνοντας τις Εικόνες 5.5 και 5.6, μπορούμε να δούμε ότι: (1) η βασισμένη σε AR εξαγωγή τετραγωνικών χαρακτηριστικών ξεπερνάει σε απόδοση την εξαγωγή χαρακτηριστικών βασισμένη στο μοντέλο AR σταθερής τάξης στο πεδίο VMD, (2) η λογαριθμική λειτουργία βελτιώνει αποτελεσματικά την ικανότητα ταξινόμησης του ταξινομητή τυχαίου δάσους και το τελικό αποτέλεσμα ταξινόμησης δεν είναι ευαίσθητο στη βάση της λογαριθμικής συνάρτησης, (3) η προτεινόμενη τετραγωνική εξαγωγή χαρακτηριστικών βασισμένη στο AR μοντέλο, μας δείχνει εξαιρετική ευρωστία (robustness) σε διάφορα κριτήρια. Για να εκτιμηθεί εάν υπάρχει σημαντική διαφορά μεταξύ της προσέγγισης που παρουσιάστηκε και της εξαγωγής χαρακτηριστικών βασισμένης στο μοντέλο AR σταθερής τάξης, διεξήχθη το *Wilcoxon rank sum test*, με ποσοστό εμπιστοσύνης 95%, βασισμένο στα στατιστικά τεστ. Οι p -τιμές διαφόρων συνδυασμών στο καλύτερό τους α , παρουσιάζονται στους Πίνακες 5.21-5.24 [68]. Όπως μπορούμε να δούμε από αυτούς τους πίνακες, οι περισσότερες από τις τιμές p είναι μικρότερες από 0.05 και απορρίπτεται η μηδενική υπόθεση των ίσων διάμεσων (median) στο επίπεδο σημαντικότητας (significance

level) 5%. Συγκεκριμένα, λαμβάνοντας υπόψη τη σύγκριση της εξαγωγής τετραγωνικών χαρακτηριστικών βασισμένης σε AR μοντέλα χρησιμοποιώντας CAT, με την εξαγωγή χαρακτηριστικών βασισμένη στο πρότυπο AR έκτης τάξης, οι p -τιμές είναι 0.0109, 3.7291E-5, 2.3337E-9 και 0.0352 χρησιμοποιώντας το Wilcoxon rank sum test βασισμένο στα ACC, SEN, SPE και PPV. Αυτές οι p τιμές είναι όλες μικρότερες από το όριο-κατώφλι (0.05). Με άλλα λόγια, μπορεί να εξαχθεί το συμπέρασμα ότι αυτές οι δύο προσεγγίσεις είναι σημαντικά διαφορετικές μεταξύ τους και η παρουσιαζόμενη εξαγωγή τετραγωνικών χαρακτηριστικών βασισμένη στο AR μοντέλο, είναι καλύτερη από την εξαγωγή χαρακτηριστικών βασισμένη στο μοντέλο AR σταθερής τάξης.

Πίνακας 5.21:

Οι τιμές του p για διάφορους συνδυασμούς χρησιμοποιώντας το Wilcoxon rank sum test βασισμένο στην ακρίβεια.

| p -value | Sixth-order AR model | Seventh-order AR model | Eighth-order AR model | Ninth-order AR model | Tenth-order AR model |
|------------|----------------------|------------------------|-----------------------|----------------------|----------------------|
| FPE | 0.2697 | 3.7262E-4 | 1.7433E-5 | 2.3672E-8 | 1.5109E-6 |
| AIC | 0.0217 | 1.3804E-5 | 1.7134E-6 | 2.7614E-9 | 1.4319E-7 |
| BIC | 0.2449 | 5.9304E-4 | 4.5321E-5 | 9.3783E-8 | 4.7196E-6 |
| CAT | 0.0109 | 4.5330E-6 | 6.7408E-7 | 9.3115E-10 | 4.1647E-8 |

Πίνακας 5.22:

Οι τιμές του p για διάφορους συνδυασμούς χρησιμοποιώντας το Wilcoxon rank sum test βασισμένο στην ευαισθησία.

| p -value | Sixth-order AR model | Seventh-order AR model | Eighth-order AR model | Ninth-order AR model | Tenth-order AR model |
|------------|----------------------|------------------------|-----------------------|----------------------|----------------------|
| FPE | 7.1366E-8 | 1.7929E-10 | 7.9054E-11 | 1.2016E-12 | 1.8612E-11 |
| AIC | 1.2529E-6 | 7.9416E-9 | 6.5974E-9 | 1.7970E-10 | 6.8050E-10 |
| BIC | 1.0393E-5 | 2.7990E-8 | 3.4371E-8 | 3.6649E-10 | 1.2292E-9 |
| CAT | 3.7291E-5 | 4.5091E-8 | 3.2669E-8 | 2.6825E-10 | 2.7072E-9 |

Πίνακας 5.23:

Οι τιμές του p για διάφορους συνδυασμούς χρησιμοποιώντας το Wilcoxon rank sum test βασισμένο στην εξειδίκευση.

| p -value | Sixth-order AR model | Seventh-order AR model | Eighth-order AR model | Ninth-order AR model | Tenth-order AR model |
|------------|----------------------|------------------------|-----------------------|----------------------|----------------------|
| FPE | 1.4471E-7 | 1.7336E-9 | 1.6090E-9 | 1.3765E-10 | 2.8242E-10 |
| AIC | 1.6919E-10 | 9.4741E-13 | 6.6290E-12 | 1.5230E-13 | 2.5409E-13 |
| BIC | 1.2926E-10 | 7.4769E-13 | 8.1668E-12 | 1.4211E-13 | 2.2396E-13 |
| CAT | 2.3337E-9 | 7.7490E-12 | 1.5096E-11 | 3.8023E-13 | 9.3584E-13 |

Πίνακας 5.24:

Οι τιμές του p για διάφορους συνδυασμούς χρησιμοποιώντας το Wilcoxon rank sum test βασισμένο στην τιμή θετικής πρόβλεψης.

| p -value | Sixth-order AR model | Seventh-order AR model | Eighth-order AR model | Ninth-order AR model | Tenth-order AR model |
|------------|----------------------|------------------------|-----------------------|----------------------|----------------------|
| FPE | 0.1413 | 0.0443 | 0.0102 | 5.5281E-4 | 0.0059 |
| AIC | 0.0422 | 0.0502 | 0.0033 | 9.2626E-5 | 0.0021 |
| BIC | 0.1203 | 0.0884 | 0.0082 | 3.1960E-4 | 0.0061 |
| CAT | 0.0352 | 0.0215 | 0.0026 | 1.4485E-4 | 0.0012 |

Συγκρίνοντας τα nBLIMFs με τα BLIMFs, τα πλάτη των nBLIMFs είναι πιο απαλά. Σε αυτή την περίπτωση, το προσαρμοσμένο μοντέλο AR μπορεί να αξιολογήσει με μεγαλύτερη ακρίβεια τους συντελεστές και έτσι να βελτιώσει την απόδοση του ταξινομητή τυχαίου δάσους. Συνοπτικά, το σύστημα που παρουσιάζεται είναι ανώτερο από τη μέθοδο που χρησιμοποιεί AR μοντέλο σταθερής τάξης και είναι ιδιαίτερα ανθεκτικό στα κριτήρια και στη βάση της λογαριθμικής συνάρτησης. Ωστόσο, πρέπει να τονιστεί ότι αυτή η προσέγγιση αντιμετωπίζει, επίσης, δύο βασικές δυσκολίες:

1. Ο αριθμός των BLIMFs, δηλαδή το K , πρέπει να προσδιοριστεί πριν εκτελέσουμε το VMD. Ωστόσο, είναι πολύ δύσκολο να επιβεβαιώσουμε την κατάλληλη τιμή του K εκ των προτέρων. Δεν υπάρχει αμφιβολία ότι μας παίρνει αρκετό χρόνο για να βρούμε τη βέλτιστη τιμή του K .
2. Η εξαγωγή τετραγωνικών χαρακτηριστικών αποτελείται από τον καθορισμό του βέλτιστου AR μοντέλου σύμφωνα με το κριτήριο και τον υπολογισμό των στατιστικών χαρακτηριστικών των AR συντελεστών. Παρόλο που το κριτήριο μπορεί να οδηγήσει σε ένα βέλτιστο μοντέλο AR που να ταιριάζει με την κανονικότητα μεταβολής πλάτους των nBLIMFs στο πρώτο υπο-βήμα, αυτές οι οκτώ στατιστικές που χρησιμοποιούνται στο δεύτερο υπο-βήμα αντανακλούν μόνο ένα μέρος των κρυφών χαρακτηριστικών ενός ΗΕΓ. Η πλειοψηφία των χαρακτηριστικών παραμένει ανεξερεύνητη. Υπό αυτές τις συνθήκες, ο ελαττωματικός χειριστής εξαγωγής χαρακτηριστικών είναι αναγκασμένος να οδηγήσει στην απώλεια πληροφοριών. Εάν υπάρχει ένας ταξινομητής ικανός να αντιμετωπίσει τα υψηλής διάστασης χαρακτηριστικά διαφορετικής διαστασιμότητας, η αντίστοιχη απόδοση ταξινόμησης μπορεί να βελτιωθεί.

Σε μια προσπάθεια επίτευξης του στόχου της αυτοματοποιημένης ανίχνευσης κρίσεων με τεχνολογία υπολογιστών, υποβλήθηκε, σε αυτή τη μελέτη, ένα σχέδιο σύντηξης της μεθόδου VMD, της λογαριθμικής λειτουργίας, της εξαγωγής τετραγωνικών χαρακτηριστικών βασισμένης στο AR μοντέλο και του τυχαίου δάσους. Με την εφαρμογή του παραπάνω συστήματος, ταξινομήσαμε με επιτυχία τα φυσιολογικά τμήματα ΗΕΓ, τμήματα ΗΕΓ στο διάστημα μεταξύ κρίσεων και τμήματα ΗΕΓ κατά τη διάρκεια επιληπτικής κρίσης. Τα πειραματικά αποτελέσματα για το σύνολο δεδομένων επιληπτικών ΗΕΓ της Βόννης, καταδεικνύουν την αποτελεσματικότητα της προτεινόμενης μεθόδου και η καλύτερη ακρίβεια ταξινόμησης που επετεύχθη είναι **97.352%** με τη χρήση του κριτηρίου CAT.

Μια περαιτέρω εξέλιξη προς την κατεύθυνση αυτή θα μπορούσε να περιλαμβάνει, χωρίς να περιορίζεται σε αυτήν, την εφαρμογή του παρουσιαζόμενου συστήματος στη διάγνωση άλλων ασθενειών όπως η νόσος Alzheimer, οι διαταραχές ύπνου και ούτω καθεξής.

Φασματικές μέθοδοι (τράπεζα φίλτρων, μέθοδος Welch, μέτρο του STFT)

Οι επόμενες μέθοδοι που μελετήσαμε στο 3^ο κεφάλαιο και των οποίων τα πειραματικά αποτελέσματα θα παρουσιάσουμε και θα συγκρίνουμε εδώ, είναι η *τράπεζα φίλτρων*, ο μετασχηματισμός *SFTF* και η μέθοδος *Welch*. Η απόδοσή όλων των χρησιμοποιούμενων συστημάτων ταξινόμησης αξιολογήθηκε με τη μέθοδο της διασταυρωμένης επικύρωσης (cross validation), με έξι δοκιμές για εκπαίδευση και δύο για επικύρωση. Οι 36 συνδυασμοί διαφορετικών τεχνικών εξαγωγής χαρακτηριστικών, επιλογής χαρακτηριστικών και ταξινομητών έχουν δοκιμαστεί για κάθε άτομο, λαμβάνοντας υπόψη το παράθυρο των 3 δευτερολέπτων. Η Εικόνα 5.7 συνοψίζει τις επιδόσεις όλων των συστημάτων ταξινόμησης με την αντίστοιχη τυπική τους απόκλιση.

Παρά το γεγονός ότι το περιβάλλον και η απόκτηση δεδομένων έχουν διατηρηθεί σταθερά, η καλύτερη απόδοση BCI είναι μεταβλητή ανάλογα με τα άτομα. Στη βάση δεδομένων μας είχαμε:

- 1 υποκείμενο με ποσοστό ακρίβειας 100%,
- 4 υποκείμενα με απόδοση μεταξύ 90% και 100%,
- 1 υποκείμενο με απόδοση μεταξύ 80% και 90%
- 1 υποκείμενο με τακτική απόδοση περίπου 70%.

Οι μεταβολές μεταξύ των υποκειμένων είναι ένα κλασικό χαρακτηριστικό των συστημάτων BCI, που συνήθως αναφέρονται στη βιβλιογραφία (βλ. [245,246] για να αναφέρουμε μερικές). Αυτή η μεταβλητότητα σχετίζεται με διάφορους παράγοντες, όπως η ηλικία του εθελοντή, η εγκεφαλική φυσιολογία και η ικανότητα συγκέντρωσης. Επιπλέον, σύμφωνα με [245], μερικά άτομα δεν έχουν επαρκή απόκριση σε οπτικά προκλητά δυναμικά (VEP) για τη λειτουργία ενός SSVEP-BCI.




Οι Εικόνες 5.7 και 5.8 δείχνουν ότι οι επιδόσεις του γραμμικού ταξινομητή, της ELM και της SVM ήταν πολύ κοντά για τα υποκείμενα ($p = 0.3992$). Οι ELMs είναι δυνητικά ικανές να λειτουργούν με την ίδια ευρωστία όπως οι γραμμικοί ταξινομητές, παρέχοντας παράλληλα ένα χρήσιμο βαθμό ευελιξίας. Ο ταξινομητής SVM εξαρτάται σε μεγάλο βαθμό από το στάδιο επιλογής: για παράδειγμα, χρησιμοποιώντας και τα 16 κανάλια, η απόδοση μειώνεται σημαντικά κατά 8% περίπου σε σύγκριση με το καλύτερο αποτέλεσμα που επιτυγχάνεται χρησιμοποιώντας επιλεγμένα χαρακτηριστικά. Η σχετικά χαμηλή απόδοση του SVM, σε αυτή την περίπτωση, μπορεί να οφείλεται στο γεγονός ότι οι παράμετροι του πυρήνα ήταν σταθερές: Μια πιο συστηματική επιλογή που βασίζεται στην διασταυρούμενη επικύρωση θα μπορούσε να οδηγήσει σε καλύτερη απόδοση και θα διερευνηθεί στο εγγύς μέλλον. Σε αυτό το σημείο πρέπει να σημειώσουμε ότι για τον ταξινομητή SVM επιλέχθηκε ο πυρήνας MLP, μετά από προκαταρκτικές δοκιμές με όλες τις μεθόδους, λόγω της σταθερότητάς του για πολλαπλές δοκιμές. Ο πυρήνας MLP ορίζεται ως:

$$k(x, x_i) = \tan h (P_1 x_i^T x + P_2),$$

όπου x_i είναι τα δεδομένα εισόδου και οι παράμετροι των πυρήνων ήταν $P_1 = 1$ και $P_2 = -1$.


Όσον αφορά την εξαγωγή χαρακτηριστικών, οι μελετημένες μέθοδοι παρουσίαζαν παρόμοιες συμπεριφορές (βλέπε Εικόνα 5.7), αν και η χρήση των μεθόδων Welch και STFT φαίνεται να είναι ελαφρώς πιο αποτελεσματικές από τη χρήση τράπεζας φίλτρων ($p = 0.011$).

Οι στρατηγικές επιλογής χαρακτηριστικών αποδείχθηκαν σχετικές ($p = 0.0001$), καθώς η χρήση διαφόρων καναλιών HEG είχε σαφή θετική επίδραση στην απόδοση του συστήματος. Όλες οι στρατηγικές που μελετήθηκαν οδήγησαν σε παρόμοια ποσοστά επιτυχίας, με το *incremental wrapper* να φτάνει μια ελαφρώς καλύτερη απόδοση (περίπου 3%).



Εικόνα 5.7: Μέση απόδοση των συστημάτων ταξινόμησης με τυπική απόκλιση [104].

Από την Εικόνα 5.8 (c), είναι δυνατόν να σημειωθεί ότι, για μια χαμηλή απόκριση VEP, ορισμένοι συνδυασμοί μεθόδων επεξεργασίας σήματος δίνουν ένα κέρδος απόδοσης. Στην καλύτερη περίπτωση, το σύστημα επιτυγχάνει το 75% του ποσοστού επιτυχίας χρησιμοποιώντας γραμμικό ταξινομητή με τα χαρακτηριστικά να εξάγονται από την τράπεζα φίλτρων και να επιλέγονται με *wrappers*. Από την άλλη πλευρά, η απόδοση του συστήματος πέφτει μόλις στο 45% στη χειρότερη περίπτωση, όταν για τα ίδια χαρακτηριστικά που εξάγονται από την τράπεζα φίλτρων δεν υιοθετείται κανένα κριτήριο επιλογής χαρακτηριστικών και χρησιμοποιείται ο ταξινομητής SVM (με σταθερές παραμέτρους πυρήνα). Περιέργως, για αυτά τα άτομα, τα ηλεκτρόδια που έδωσαν τη μεγαλύτερη πληροφορία δεν βρίσκονται στην ινιακή ζώνη, όπως φαίνεται στην Εικόνα 5.8 (c). Τα κανάλια που σχετίζονται με τον κινητικό φλοιό και τη βρεγματική ζώνη προσέφεραν επίσης χρήσιμες πληροφορίες στον ταξινομητή και εμφανίζονται στην κατάταξη του επιλογέα χαρακτηριστικών.




Εικόνα 5.8: Απόδοση των συστημάτων ταξινόμησης για υποκείμενα με (a) εξαιρετική, (b) καλή και (c) κανονική απόκριση VEP [104].

Όσον αφορά τα καλύτερα επιλεγμένα χαρακτηριστικά, η Εικόνα 5.8 δείχνει την απόδοση κάθε συστήματος ταξινόμησης που απαριθμεί τα κανάλια που χρησιμοποιούνται στις καλύτερες διαμορφώσεις για κάθε περίπτωση. Είναι ενδιαφέρον ότι, όπως αναφέρθηκε, τα επιλεγμένα κανάλια δεν βρίσκονται πάντοτε στην ινιακή ζώνη, γεγονός που θα δικαιολογούσε έντονα τη χρήση ενός σταδίου επιλογής χαρακτηριστικών για τα συστήματα SSVEP-BCI. Επίσης, μπορεί να σημειωθεί ότι κάθε υποκείμενο σχετίζεται με μια συγκεκριμένη διαμόρφωση καναλιού, η οποία μπορεί να ποικίλει ανάλογα με τη στρατηγική επιλογής

χαρακτηριστικών και το υιοθετούμενο σύστημα ταξινομητή. Κατά κανόνα, υπάρχει ένα κέρδος πληροφορίας, χρησιμοποιώντας κανάλια από διαφορετικές περιοχές. Ένα τέτοιο κέρδος απόδοσης μπορεί να αποδοθεί στη μεταβλητότητα μεταξύ των επιλεγμένων καναλιών, αφού η επιλογή ηλεκτροδίων από την ίδια περιοχή μπορεί να οδηγήσει σε ένα ανεπιθύμητο σφάλμα που σχετίζεται με σήματα που έχουν υψηλή συσχέτιση. Το γεγονός αυτό μπορεί να επιβεβαιωθεί από την επιλογή που έγινε με τη χρήση *wrappers*, η οποία δεν λαμβάνει υπόψη την ποσότητα πληροφοριών που υπάρχουν στα κανάλια από την άποψη της μη συσχέτισης (*uncorrelatedness*), αλλά θεωρώντας τον ταξινομητή και τα χαρακτηριστικά μαζί για να επιλεγθούν τα ηλεκτρόδια που δίνουν περισσότερες πληροφορίες για το σύστημα.

Το Σχήμα 5.6 κατατάσσει τα 16 κανάλια κατά σειρά συχνότητας εμφάνισης, όπως αυτά εμφανίζονται στην καλύτερη διαμόρφωση για κάθε σενάριο, λαμβάνοντας υπόψη τα επτά υποκείμενα. Τα ινιακά κανάλια (Oz, O1 και O2) είναι τα πιο συχνά, όπως αναμενόταν [247], εμφανιζόμενα 14%, 11% και 9% των φορών, αντίστοιχα, δηλ. σε ένα ποσοστό 34% συνολικά. Στην συνέχεια ακολουθούν τα PO7 (9%) και Cz (8%), με το σύνολο αυτών των πέντε ηλεκτροδίων να αντιστοιχούν στο 51% της συχνότητας εμφάνισης. Τα κανάλια Pz, FCz και P2 εμφανίζονται περιστασιακά, αλλά αυτό δεν σημαίνει ότι δεν πρέπει να ληφθούν υπόψη. Αυτή η κατάταξη συχνότητας εμφάνισης είναι μια μέση τιμή μεταξύ των υποκειμένων και θα μπορούσε να χρησιμοποιηθεί για να περιγράψει αρχικά τα καλύτερα κανάλια. Όμως, για κάθε άτομο, η καλύτερη διαμόρφωση είναι μεταβλητή: όπως απεικονίζεται στο Σχήμα 5.8 (b), το FCz είναι ένα σχετικό κανάλι για αυτόν τον συγκεκριμένο εθελοντή.



Σχήμα 5.6: Διάγραμμα των καναλιών με τη μεγαλύτερη συνεισφορά στην ταξινόμηση [104].

Τα αποτελέσματα αποκάλυψαν ότι, για το πρόβλημα SSVEP δύο τάξεων, η καλύτερη δομή ήταν ο γραμμικός ταξινομητής χρησιμοποιώντας τη μέθοδο Welch για την εξαγωγή χαρακτηριστικών και τα incremental wrappers για την πραγματοποίηση επιλογής χαρακτηριστικών. Αυτή η διαμόρφωση έδωσε μέση ακρίβεια περίπου 95%, με παράθυρο 3 δευτερολέπτων, για τα 7 άτομα, φτάνοντας στο 100% για κάποια από αυτά, το οποίο είναι πολύ ικανοποιητικό. Οι τεχνικές εξαγωγής χαρακτηριστικών έδειξαν ότι είναι ισοδύναμες με την εκτίμηση της φασματικής ισχύος. Οι μέθοδοι Welch και STFT παρουσίασαν παρόμοια απόδοση, ενώ ελαφρώς καλύτερη επίδοση (περίπου 6%) επιτεύχθηκε χρησιμοποιώντας τράπεζα φίλτρων, αν και αυτό φαίνεται να βρίσκεται εντός του περιθωρίου σφάλματος των υποκειμένων. Η επιλογή των χαρακτηριστικών έδειξε ότι είναι ένα εξαιρετικά σημαντικό βήμα, υποδεικνύοντας την ύπαρξη σχετικών πληροφοριών στις βρεγματικές, κινητικές και κεντρικές ζώνες, καθώς και στον ινιακό λοβό. Τα αποτελέσματα δείχνουν ότι οι τρεις ταξινομητές μπορούν να χρησιμοποιηθούν αποτελεσματικά για την κατασκευή ενός συστήματος BCI βασισμένου σε SSVEP. Ωστόσο, ο ταξινομητής SVM είναι πολύ ευαίσθητος στη στρατηγική επιλογής χαρακτηριστικών, ειδικά όταν συνδέεται με την εξαγωγή χαρακτηριστικών με τράπεζα φίλτρων. Οι ELMs είναι πολλά υποσχόμενοι ταξινομητές στο πλαίσιο των SSVEP και αξίζει να θεωρηθούν ως μέρος του παρόντος ρεπερτορίου για συστήματα ταξινομητών BCI, καθώς παρουσιάζουν καλή απόδοση γενίκευσης. Τα αποτελέσματα που προκύπτουν υποστηρίζουν τη χρήση των ELMs, οι οποίες μπορούν να είναι ακόμα πιο αποτελεσματικές και υποσχόμενες όταν εξετάζονται εφαρμογές με περισσότερες τάξεις.

Μέθοδος που στηρίζεται στον DWT

Στη συνέχεια παραθέτουμε τα πειραματικά αποτελέσματα της μεθόδου που μελετήσαμε για την εξαγωγή χαρακτηριστικών από ηλεκτρομυογράφημα και η οποία στηρίζεται στη χρήση των *wavelets*.

Πέντε διαφορετικές ταξινομήσεις αποτελούμενες από ALS εναντίον υγιών ατόμων, ALS εναντίον PD, ALS έναντι HD, ALS έναντι PD ή HD και ALS έναντι PD ή HD ή υγιών ατόμων, δημιουργήθηκαν για τη διάκριση της ALS στη μελέτη. Ενώ η «τάξη 1» επιλέχθηκε ως η ομάδα ALS, η «τάξη 2» επιλέχθηκε από άλλες ομάδες. Τα χαρακτηριστικά εφαρμόστηκαν στις εισόδους των ταξινομητών λαμβάνοντας υπόψη τις δημιουργούμενες τάξεις και διερευνήθηκε η απόδοση διάκρισης σε σχέση με τον τύπο wavelet που χρησιμοποιήθηκε κάθε φορά. Οι επιδόσεις υπολογίστηκαν χρησιμοποιώντας την εξειδίκευση, την ευαισθησία και την ακρίβεια μετά από τους LDA και NBC.

Αρχικά, τα wavelets προσδιορίστηκαν σε σχέση με τον εντοπισμό των καλύτερων επιδόσεων διάκρισης μεταξύ κάθε οικογένειας wavelet, συμπεριλαμβανομένων των Daubechies, biorthogonal, symlet και coiflet, αντίστοιχα. Ως εκ τούτου, προσδιορίστηκαν ως υποψήφιοι για την εξαγωγή χαρακτηριστικών τα 'haar' και 'db3' από τα Daubechies, το 'coif2' από τα coiflet, το 'sym4' από τα symlet και το 'bior2.6' από τα biorthogonal wavelets, τα οποία έχουν την καλύτερη ακρίβεια στις οικογένειές τους. Το ποσοστό του λεπτομερούς συντελεστή ως διπλά χαρακτηριστικά αξιολογήθηκε χρησιμοποιώντας τους αλγόριθμους LDA και NBC. Για παράδειγμα, το ποσοστό ενέργειας των D1 και D2, διπλών χαρακτηριστικών, αποκτήθηκε μετά από το DWT επιπέδου 6 χρησιμοποιώντας το 'haar' wavelet και τα χαρακτηριστικά αυτά εφαρμόζονται σε LDA και NBC. Τα αποτελέσματα αξιολογήθηκαν ως ο μέσος όρος των 20 δοκιμών χρησιμοποιώντας FFCV έτσι ώστε το 80% να είναι για

εκπαίδευση και το 20% για δοκιμή. Οι τιμές *SPE*, *SEN*, *ACC* και οι τυπικές αποκλίσεις τους εξοικονομούνται (saved) τόσο με το LDA όσο και με το NBC, αντίστοιχα. Αυτή η διαδικασία επαναλήφθηκε και για άλλα wavelets αντίστοιχα. Ο σκοπός αυτής της διαδικασίας είναι να προσδιοριστούν τα διπλά χαρακτηριστικά που παρέχουν την καλύτερη διάκριση για την ALS μεταξύ των άλλων NDD και των υγιών ατόμων.

Η σύγκριση που περιλαμβάνει τον μέσο όρο των τιμών LDA και NBC και τις τυπικές αποκλίσεις τους για κάθε τύπο κυματιδίου, παρουσιάζεται στο Σχήμα. 5.7.

Παρατηρείται ότι τα D5 και D6 σε ταξινόμηση μεταξύ ατόμων με ALS και υγιών ατόμων, τα D4 και D5 σε ταξινόμηση μεταξύ ατόμων με ALS και ατόμων με PD και τα D2 και D5 σε ταξινόμηση μεταξύ ατόμων με ALS και ατόμων με HD, επιτυγχάνουν τις καλύτερες επιδόσεις που φαίνονται με τα μπλε σημεία στο Σχήμα 5.7.


Ομοίως, οι λεπτομερείς συντελεστές D4 και D5 για ταξινόμηση μεταξύ ατόμων με ALS και ατόμων με PD ή HD και σε ταξινόμηση μεταξύ ατόμων με ALS και ατόμων με PD ή HD ή υγιών ατόμων, πέτυχαν την καλύτερη ακρίβεια απόδοσης μεταξύ των άλλων χαρακτηριστικών στο Σχήμα 5.8. Έτσι, τα κρίσιμα χαρακτηριστικά αποκτήθηκαν για τη διάκριση της ALS μεταξύ υγιών και άλλων ατόμων με NDD.

Επιπλέον, οι τύποι κυματιδίων που επιτυγχάνουν τις καλύτερες επιδόσεις προσδιορίζονται και απεικονίζονται στο Σχήμα 5.9. Παρατηρείται ότι το 'bior2.6' έχει την υψηλότερη απόδοση μεταξύ των άλλων wavelets στην ταξινόμηση ατόμων με ALS και υγιών ατόμων. Ομοίως, το 'sym4' είναι το καλύτερο μεταξύ των άλλων στην ταξινόμηση ατόμων με ALS και ατόμων με PD, ενώ το wavelet 'bior2.6' έχει την υψηλότερη απόδοση στην ταξινόμηση ατόμων με ALS και ατόμων με HD.


Ενώ το 'sym4' από την οικογένεια symlet καθορίστηκε ως η καλύτερη παράμετρος wavelet σε ταξινόμηση μεταξύ ALS και PD ή HD, τόσο το 'sym4' όσο και το 'coif2' που ήταν τόσο κοντά μεταξύ τους, θα μπορούσαν να χρησιμοποιηθούν στην ταξινόμηση μεταξύ ALS και PD ή HD ή υγιών ατόμων. Επίσης, παρατηρείται ότι ο NBC είναι συνήθως πιο ωφέλιμη μέθοδος από την LDA για αυτές τις ταξινομήσεις στο Σχήμα 5.9.

Τα αποτελέσματα που λαμβάνονται παρουσιάζονται στον Πίνακα 5.24 [134]. Είναι σαφές ότι ο αλγόριθμος NBC πέτυχε καλύτερη απόδοση από την LDA. Παρατηρείται ότι ο λεπτομερής συντελεστής D5 είναι πολύ σημαντικό χαρακτηριστικό διάκρισης. Επιπλέον, μπορεί να ειπωθεί ότι τα wavelets «sym4» και «bior2.6» είναι πολύ αποτελεσματικές συναρτήσεις κυματιδίου για την ανάλυση του CFS.


Τέλος, τα συνολικά αποτελέσματα ακρίβειας αξιολογούνται μετά τη μέση και τυπική απόκλιση των 20 δοκιμών για κάθε FFCV. Δείχνεται ότι οι τυπικές αποκλίσεις που αναφέρονται ως «std» είναι 5.65 ως μέγιστες στον Πίνακα 5.25.



Σχήμα 5.7: Η συνολική σύγκριση της ακρίβειας, για ταξινόμηση ατόμων με ALS και υγιών ατόμων, ταξινόμηση ατόμων με ALS και ατόμων με PD και ταξινόμηση ατόμων με ALS και ατόμων με HD [134].



Σχήμα 5.8: Η συνολική σύγκριση της ακρίβειας που σχετίζεται με τα χαρακτηριστικά, για ταξινόμηση ατόμων με ALS και ατόμων με PD ή HD και ταξινόμηση ατόμων με ALS και ατόμων με PD ή HD ή υγιών ατόμων [134].



Σχήμα 5.9: Η επιλογή του τύπου κυματιδίου για κάθε ταξινόμηση [134].

Πίνακας 5.25:

Συνολικά Αποτελέσματα Αξιολόγησης.

| Groups | Wavelet Function | Features | Classification Methods LDA | | | NBC | | |
|-------------------|------------------|----------|-------------------------------|--------------|--------------|--------------|--------------|--------------|
| | | | Sp (std) | Se (std) | Acc (std) | Sp (std) | Se (std) | Acc (std) |
| ALS vs. Co. | bioe2.6 | D5-D6 | 92.92 (0.30) | 80.93 (3.21) | 86.72 (2.02) | 93.48 (0.36) | 88.32 (5.09) | 90.93 (2.82) |
| ALS vs. PD | sym4 | D4-D5 | 82.62 (3.34) | 71.41 (4.37) | 76.43 (3.74) | 84.45 (3.17) | 80.74 (4.42) | 82.39 (2.90) |
| ALS vs. HD | bioe2.6 | D2-D5 | 85.09 (3.29) | 64.47 (3.36) | 74.85 (3.12) | 82.80 (5.38) | 64.40 (5.65) | 73.45 (4.00) |
| ALS vs. PD+HD | sym4 | D4-D5 | 92.01 (0.29) | 48.00 (1.86) | 70.94 (1.85) | 85.44 (4.10) | 55.77 (2.82) | 76.29 (1.28) |
| ALS vs. Co.+PD+HD | sym4 | D4-D5 | 94.59 (0.62) | 42.17 (2.63) | 73.20 (2.45) | 90.38 (2.60) | 58.03 (2.31) | 83.11 (0.89) |

Τα κρίσιμα χαρακτηριστικά αποκτήθηκαν για την ανάπτυξη γρήγορων αλγορίθμων για τη διάκριση ALS στη μελέτη. Οι προηγούμενες μελέτες έχουν επικεντρωθεί στη διάρκεια του κύκλου διασκελισμού (stride cycle time), το μήκος βήματος (stride length), την ταχύτητα των σημάτων βηματισμού και την ανάλυση ΗΜΓ σήματος [137, 142, 143, 145, 248, 249]. Αυτές οι μελέτες απέδωσαν πολύ επιτυχημένα αποτελέσματα για τη διάκριση της ALS. Ωστόσο, αυτοί οι τύποι ερευνών μπορεί να χρειαστούν μεγαλύτερο χρονικό διάστημα συγκριτικής ανάλυσης λόγω του γεγονότος ότι περιλαμβάνουν σήματα βάδισης των πέντε λεπτών. Αυτές οι πεντάλεπτες μετρήσεις του χρόνου μπορεί να επιφέρουν ορισμένους περιορισμούς, όπως ο καταναγκασμός, η κόπωση και η απότομη διακοπή για ορισμένους ασθενείς. Αυτοί οι τύποι μετρήσεων μπορεί να διακόψουν το βήμα και να αχρηστεύουν τα αρχεία των σημάτων. Η παρούσα μελέτη προτείνει μια νέα μέθοδο που βασίζεται στην ανάλυση βάδισης ενός λεπτού σε αντίθεση με τις μεθόδους άλλων ερευνητικών μελετών. Αυτή η μέθοδος ελαχιστοποιεί αυτούς τους παραπάνω περιορισμούς και επιπλέον, μπορεί να προσφέρει το πλεονέκτημα της γρήγορης λήψης αποφάσεων και χαμηλής χρήσης μνήμης για τη διάκριση της ALS.

Παρατηρείται ότι η αποσύνθεση μεγαλύτερου επιπέδου εμφανίζει πιο μικρή ταχύτητα αλγορίθμου και υψηλή χρήση μνήμης, ενώ παρουσιάζει και κακές επιδόσεις διάκρισης κατά τη διάρκεια πειραμάτων. Η αποσύνθεση χαμηλότερου επιπέδου δεν θα μπορούσε να περιλαμβάνει τους λεπτομερείς συντελεστές D5 και D6 οι οποίοι αποτελούν σημαντικά χαρακτηριστικά για τη διάκριση μεταξύ CFS και ALS. Ως εκ

τούτου, χρησιμοποιείται στην ανάλυση η αποσύνθεση του DWT 6 επιπέδων. Η θεμελιώδης επίπτωση της μελέτης είναι στην εξαγωγή χαρακτηριστικών και όχι τόσο στην ταξινόμηση. Γι' αυτό, αρκεί οι αλγόριθμοι αξιολόγησης (LDA και NBC) να είναι γρήγοροι και απλοί.

Συνεπώς, το D5 (4.6875-9.375 Hz) είναι ένα σημαντικό χαρακτηριστικό για όλες τις ταξινομήσεις, ενώ το D4 (9.375-18.75 Hz) είναι αποτελεσματικό για την ταξινόμηση μεταξύ ατόμων με σε ALS και ατόμων με PD, για την ταξινόμηση μεταξύ ατόμων με ALS και ατόμων με PD ή HD και για την ταξινόμηση μεταξύ ατόμων με ALS και ατόμων με PD ή HD ή υγιών ατόμων. Τα D2 (37.5-75 Hz) και D6 (2.3438-4.6875 Hz) είναι τα καλύτερα χαρακτηριστικά για την ταξινόμηση μεταξύ ατόμων με ALS και υγιών ατόμων και μεταξύ ατόμων με ALS και ατόμων με HD, αντίστοιχα. Ο αλγόριθμος NBC πέτυχε απόδοση ακρίβειας 90,93% χρησιμοποιώντας τους λεπτομερείς συντελεστές D5 και D6 με το 'bior2,6' wavelet σε ταξινόμηση μεταξύ ατόμων με ALS και υγιών ατόμων. Τα D4 και D5 έδωσαν απόδοση 82,39% στην ταξινόμηση μεταξύ ατόμων με ALS και ατόμων με PD με το 'sym4' wavelet, 76,29% στην ταξινόμηση μεταξύ ατόμων με ALS και ατόμων με PD ή HD και 83,11% στην ταξινόμηση μεταξύ ατόμων με ALS και ατόμων με PD ή HD ή υγιών ατόμων. Από την άλλη πλευρά, η LDA πέτυχε ακρίβεια 74,85% χρησιμοποιώντας τους λεπτομερείς συντελεστές D2 και D5 με το 'bior2,6' wavelet. Είναι σημαντικό να τονιστεί, αυτές οι τιμές ακρίβειας μπορεί να αυξηθούν χρησιμοποιώντας προηγμένες μεθόδους ταξινόμησης στις μελλοντικές εργασίες.

Αυτή η μελέτη προτείνει μια νέα μέθοδο για την ανάλυση βάδισης βασισμένη στο DWT, για να αποκτηθούν διπλά χαρακτηριστικά για την αξιολόγηση της διάκρισης της ALS. Τα διπλά χαρακτηριστικά που εξάγονται από το CFS και βασίζονται σε φορητό σύστημα μεταγωγής ποδιών (foot-switch) σε μια κλινική, μπορούν να συμβάλλουν σημαντικά μαζί με άλλους κλινικούς δείκτες για τη διάκριση της ALS. Από μια σφαιρική εποπτεία των αποτελεσμάτων συμπεραίνουμε ότι οι διάφοροι αλγόριθμοι ταξινόμησης μπορούν να αναπτυχθούν εύκολα μέσω των χαρακτηριστικών που αποκτώνται και αυτές οι μέθοδοι μπορούν να παρέχουν γρήγορη και σταθερή διάγνωση των NDD. Εκτός αυτού, η μελέτη παρουσιάζει ότι η ζώνη συχνοτήτων D5 (4.6875-9.375 Hz) πετυχαίνει την καλύτερη απόδοση σε σχέση με την παρατήρηση της διάκρισης της ALS από αυτή των άλλων ομάδων.


Συμπερασματικά, η μελέτη παρέχει μια λύση στις αλλαγές των πραγματικών παραμέτρων ενός σήματος λόγω περιστάσεων ως κόπωση ή η δυσκολία κατά τη διάρκεια μακροχρόνιας καταγραφής που λαμβάνεται από τους ασθενείς. Στο μέλλον, με τη χρήση προηγμένων αλγορίθμων τεχνητής νοημοσύνης, η μέθοδος μπορεί να αναπτυχθεί για να γίνει μια εμπορική συσκευή που είναι πιο γρήγορη, πολύ ακριβής και πιο σταθερή. Η συσκευή αυτή σε συνδυασμό με άλλες εργαστηριακές εξετάσεις που χρησιμοποιούνται στη διάγνωση των NDD έχει την ικανότητα να είναι ένας συνδυασμός που διευκολύνει τη διάκριση της ALS.

Συνδυασμός των μεθόδων (PCA-DWT) και (ICA-HOS)

Τέλος, εξετάζουμε τα πειραματικά αποτελέσματα της μεθόδου που αναλύσαμε για την εξαγωγή χαρακτηριστικών από ηλεκτροκαρδιογράφημα.

Τα πειράματα στο σύστημα αυτόματης ανίχνευσης αρρυθμίας διεξήχθησαν χρησιμοποιώντας τη βάση δεδομένων αρρυθμίας MIT-BIH. Χρησιμοποιήθηκε ένας συνδυασμός γραμμικών και μη γραμμικών μεθόδων και το σημείο δεδομένων αποτελούταν από 28 χαρακτηριστικά (12 γραμμικά και 16 μη γραμμικά). Τα μετασχηματισμένα σημεία δεδομένων διαμορφώθηκαν σε διανύσματα

χαρακτηριστικών που εισήχθησαν στην SVM-με συνάρτηση πυρήνα RBF και στα NN. Η μη γραμμική SVM βασίστηκε στον δημοφιλή Gaussian πυρήνα (που αναφέρεται ως SVM-RBF). Η παράμετρος C για αυτόν τον πυρήνα επιλέχθηκε έτσι ώστε να καλύπτει την υψηλή και μικρή κανονικοποίηση του μοντέλου ταξινόμησης και τέθηκε ίση με 70, ενώ η παράμετρος γ ήταν ίση με 0.7, όπως φαίνεται στο Σχήμα 5.10. Επιπλέον, για σκοπούς σύγκρισης, στο πρώτο πείραμα εφαρμόστηκε ο ταξινομητής NN εμπρόσθιας τροφοδότησης (feed-forward). Ο αριθμός των κρυμμένων βαθμίδων και η τιμή του ρυθμού εκμάθησης του NN εμπρόσθιας τροφοδότησης που επιλέχθηκαν με δοκιμή και σφάλμα, ήταν ίσα με 40 και 0.3 αντίστοιχα.



Σχήμα 5.10: Διακύμανση της μέσης ακρίβειας σε συνάρτηση των διαφορετικών τιμών της παραμέτρου C, κατά τη διάρκεια της SVM-RBF ταξινόμησης, χρησιμοποιώντας συνδυασμό γραμμικών και μη γραμμικών χαρακτηριστικών [155].

Στο σημείο αυτό πρέπει να σημειώσουμε ότι για τα NN, το στρώμα εισόδου αποτελείται από 28 κόμβους, που αντιστοιχούν στα 28 χαρακτηριστικά που χρησιμοποιούνται. Χρησιμοποιήθηκε μια κρυμμένη βαθμίδα 40 νευρώνων και ένα στρώμα εξόδου πέντε νευρώνων που αντιστοιχούν σε πέντε κατηγορίες. Για να βελτιωθεί η διαδικασία εκμάθησης, χρησιμοποιήθηκε η μέθοδος οπίσθιας διάδοσης (back propagation). Με βάση τον υπολογισμό του μέσου τετραγωνικού σφάλματος (μεταξύ της επιθυμητής απόκρισης και της πραγματικής απόκρισης του NN), τα βάρη στο δίκτυο ενημερώθηκαν και η διαδικασία συνεχίστηκε μέχρις ότου το μέσο τετραγωνικό σφάλμα ήταν κάτω από το συγκεκριμένο όριο. Τα δεδομένα δοκιμών διαβιβάστηκαν έπειτα στο εκπαιδευμένο NN για να αποκτήσουν την παραγωγή και τα πρότυπα δοκιμής ταξινομήθηκαν.

Η τεχνική διασταυρούμενης επικύρωσης 10 φορές χρησιμοποιήθηκε για την εκπαίδευση και τη δοκιμή των ταξινομητών. Η συνολική απόδοση των ταξινομητών αξιολογήθηκε λαμβάνοντας τον μέσο όρο των διασταυρούμενων επικυρώσεων 10 φορές.


Η αντίστοιχη συνολική ακρίβεια και η μέση ακρίβεια για όλες τις τάξεις του προτεινόμενου μοντέλου ήταν 98.91% και 99.57% αντίστοιχα. Συγκρίνοντας αυτά τα αποτελέσματα με αυτά που επιτεύχθηκαν με τον ταξινομητή NN, παρατηρήθηκε μια ελαφριά αύξηση της τάξης του 0.1% τόσο στη συνολική ακρίβεια, όσο και στη μέση ακρίβεια για όλες τις τάξεις, όπως φαίνεται στον Πίνακα 5.26 [155].

Πίνακας 5.26:

Συνολική ακρίβεια, μέση ακρίβεια όλων των τάξεων και ποσοστά ακρίβειας της κάθε τάξης που επιτεύχθηκαν με τους ταξινομητές SVM-RBF και NN.


| Classifiers | Features | Overall Acc. (%) | Avg. acc. of all classes | N | S | V | F | U |
|-------------|-----------------------|------------------|--------------------------|--------|--------|--------|--------|-------|
| SVM-RBF | PCA-DWT | 88.04% | 94.97% | 91.01% | 94.19% | 92.05% | 97.59% | 100% |
| NN | | 93.48% | 97.34% | 98.85% | 94.51% | 100% | 98.85% | 94.5% |
| SVM-RBF | ICA-HOS | 97.83% | 99.13% | 98.90% | 100% | 97.83% | 98.90% | 100% |
| NN | | 94.57% | 97.76% | 97.75% | 98.86% | 97.75% | 97.75% | 96.6% |
| SVM-RBF | (PCA-DWT) + (ICA-HOS) | 98.91% | 99.57% | 98.91% | 100% | 98.91% | 100% | 100% |
| NN | | 98.90% | 99.56% | 100% | 98.90% | 100% | 98.90% | 100% |

Το Σχήμα 5.11 απεικονίζει την ακρίβεια ταξινόμησης των σημάτων ΗΚΓ χρησιμοποιώντας τον ταξινομητή SVM-RBF για τα γραμμικά χαρακτηριστικά, τα μη γραμμικά χαρακτηριστικά και τα προτεινόμενα χαρακτηριστικά. Αυτό δείχνει ότι τα προτεινόμενα χαρακτηριστικά (PCA-DWT) + (ICA-HOS) παρέχουν πολύ μεγαλύτερη ακρίβεια όταν δίδονται ως είσοδος στον SVM-RBF ταξινομητή σε σύγκριση με μόνο γραμμικά ή μόνο μη γραμμικά χαρακτηριστικά, επιτυγχάνοντας μέγιστη μέση ακρίβεια 97.83% και 99.13% για όλες τις τάξεις. Η χειρότερη ακρίβεια της τάξης των προτεινόμενων χαρακτηριστικών επιτεύχθηκε για τους χτύπους N και V (98.91%), ενώ το 100% ελήφθη για τους παλμούς S, F και U.



Σχήμα 5.11: Σύγκριση των γραμμικών, μη γραμμικών και προτεινόμενων χαρακτηριστικών με τη χρήση του SVM-RBF ταξινομητή [155].

Τα αποτελέσματα από την ταξινόμηση των σημάτων ΗΚΓ χρησιμοποιώντας το NN των γραμμικών χαρακτηριστικών, των μη γραμμικών χαρακτηριστικών και των προτεινόμενων χαρακτηριστικών φαίνονται στο Σχήμα 5.12. Αυτό δείχνει ότι τα NN είναι πολύ πιο ακριβή όταν τα προτεινόμενα χαρακτηριστικά (PCA-DWT) + (ICA-HOS) δίδονται ως είσοδος, επιτυγχάνοντας μέγιστη ακρίβεια 98.90% και μέση ακρίβεια 99.56% για όλες τις τάξεις. Η χειρότερη ακρίβεια της τάξης του λήφθηκε ήταν για τους χτύπους S και F (98.90%), ενώ το 100% ελήφθη για τους υπόλοιπους παλμούς.



Σχήμα 5.12: Σύγκριση των γραμμικών, μη γραμμικών και προτεινόμενων χαρακτηριστικών με τη χρήση του NN ταξινομητή [155].

Με βάση την αξιολόγηση της απόδοσης, η ευαισθησία, η εξειδίκευση και η ακρίβεια των συνδυασμένων γραμμικών και μη γραμμικών μεθόδων με τους ταξινομητές SVM-RBF και NN συνοψίζονται στον Πίνακα 5.27 [155]. Σημειώνεται ότι τα NN και SVM-RBF παρείχαν ίση ευαισθησία, ειδικότητα και ακρίβεια (98.9%). Για να πραγματοποιηθούν οι υπολογισμοί, χρησιμοποιήθηκε το MATLAB 2012A. Όλες οι μέθοδοι, συμπεριλαμβανομένης της αποθορυβοποίησης DWT, της PCA, της ICA, των HOS και των αλγορίθμων ταξινόμησης, αναπτύχθηκαν στο MATLAB με το προσαρμοσμένο λογισμικό. Για την εφαρμογή του ICA, εγκαταστάθηκε και συνδεόταν με τα αναπτυγμένα προγράμματα, η γρήγορη εργαλειοθήκη ICA.

Πίνακας 5.27:

Αποτελέσματα ταξινόμησης των συνδυασμένων γραμμικών και μη γραμμικών μεθόδων, με δύο διαφορετικούς ταξινομητές.

| Classifier | Sensitivity (%) | Specificity (%) | Accuracy (%) |
|------------|-----------------|-----------------|--------------|
| SVM-RBF | 98.91% | 97.85% | 98.91% |
| NN | 98.90% | 98.90% | 98.90% |

Αποδεικνύεται, λοιπόν, ότι ο προτεινόμενος συνδυασμός γραμμικών και μη γραμμικών μεθόδων ως τεχνική εξαγωγής χαρακτηριστικών είναι σε θέση να εξάγει πολύ καλά τις κρυμμένες πληροφορίες από το μη στατικό σήμα ΗΚΓ και τα διακριτικά χαρακτηριστικά, χρησιμοποιώντας τα πειραματικά δεδομένα MIT-BIH. Η τεχνική παρέχει μια καλή εξαγωγή των πιο διακριτικών χαρακτηριστικών και διακρίνει σαφώς τις τάξεις αρρυθμίας N, S, V, F και U. Οι κρυφές πληροφορίες στο σήμα ΗΚΓ παρατηρήθηκαν εμφανέστερα στο πεδίο του μετασχηματισμού, απ' ότι στο πεδίο χρόνου. Τα χαρακτηριστικά του παλμού ΗΚΓ εξήχθησαν χρησιμοποιώντας τη μέθοδο HOS cumulants και DWT. Επιπλέον, το σήμα ΗΚΓ και οι DWT αναπαραστάσεις περιείχαν περίσσεια πληροφοριών και έτσι εφαρμόστηκε η μέθοδος μείωσης των διαστάσεων σε DWT και στα σήματα ΗΚΓ. Η μέθοδος PCA εφαρμόστηκε για τη μείωση της διαστασιμότητας των συντελεστών DWT και η ICA χρησιμοποιήθηκε για να μειώσει την αναπαράσταση των σημάτων ΗΚΓ. Ο

συνδυασμός 16 HOS cumulants και ICA και 12 PCA των χαρακτηριστικών DWT, έδωσε μέγιστη ακρίβεια ταξινόμησης σε σύγκριση με τις άλλες μεθόδους.

Από τα αποτελέσματα αυτά, προκύπτει ότι η προτεινόμενη μέθοδος είναι ικανή να ταξινομήσει τις τάξεις αρρυθμίας S, F και U με ακρίβεια 100% χρησιμοποιώντας τον ταξινομητή SVM-RBF. Σε αυτή την ενότητα συγκρίνουμε την απόδοση ταξινόμησης του προτεινόμενου PCA του DWT, HOS cumulants και ICA με SVM, NN για την ταξινόμηση της αρρυθμίας ΗΚΓ με αυτά άλλων συστημάτων στη βιβλιογραφία χρησιμοποιώντας διαφορετικές μεθόδους μείωσης χαρακτηριστικών και ταξινομητές. Επιλέχθηκαν οκτώ υπάρχοντα συστήματα ταξινόμησης ΗΚΓ που χρησιμοποιούν τη βάση δεδομένων αρρυθμίας MIT-BIH για σύγκριση με το προτεινόμενο σύστημα. Ο αριθμός των ταξινομημένων τύπων αρρυθμίας και η ακρίβεια του προτεινόμενου συστήματος και των οκτώ υφιστάμενων συστημάτων συνοψίζονται στον Πίνακα 5.28 [155].

Πίνακας 5.28:

Σύγκριση της απόδοσης ταξινόμησης του προτεινόμενου συστήματος και άλλων ήδη υπαρχόντων συστημάτων.

| Literature | Features | Classifier | Classes | Accuracy (%) |
|--------------------------|-----------------------|--------------------|---------|--------------|
| Linear methods | | | | |
| Hu et al. [36] | Time domain features | Mixture of experts | 2 | 94.00% |
| Inco et al. [37] | DWT + PCA | MDPSO | 5 | 95.58% |
| Martis et al. [17] | PCA | SVM-RBF | 5 | 98.11% |
| Martis et al. [14] | DWT + PCA | SVM-RBF | 5 | 96.92% |
| | DWT + PCA | NN | 5 | 98.78% |
| Nonlinear methods | | | | |
| Osowski and Linh [16] | HOS | Hybrid fuzzy NN | 7 | 96.06% |
| Martis et al. [18] | Bispectrum + PCA | SVM-RBF | 5 | 93.48% |
| Martis et al. [31] | Cumulant + PCA | NN | 5 | 94.52% |
| Proposed Methodology | PCA + DWT + HOS + ICA | SVM-RBF | 5 | 98.91% |
| | | NN | 5 | 98.90% |

Τα αποτελέσματα έδειξαν ότι το προτεινόμενο σύστημα που περιλαμβάνει το PCA των συσσωρευτών DWT, HOS και ICA με διαφορετικούς ταξινομητές (SVM-RBF και NN) μπορεί να παρέχει καλύτερη ακρίβεια ταξινόμησης σε σχέση με τα άλλα συστήματα, γεγονός που επιβεβαιώνει ότι το προτεινόμενο σύστημα μπορεί να χρησιμεύσει ως αποτελεσματικό εργαλείο για τους καρδιολόγους ώστε να διαγνώσουν καρδιακές παθήσεις με βάση σήματα ΗΚΓ.

5.3 Συνολικός Συγκριτικός Πίνακας Ακρίβειας Ταξινόμησης

Αφού παρουσιάσαμε όλα τα αποτελέσματα των μεθόδων που αναλύονται στην μελέτη μας, κρίνουμε σκόπιμο σε αυτή την ενότητα να δημιουργήσουμε έναν συγκεντρωτικό συγκριτικό πίνακα (Πίνακας 5.29) για όλες τις μεθόδους, ώστε η διεξαγωγή συμπερασμάτων να είναι πιο εύκολη και σωστή. Στον συνολικό συγκριτικό πίνακα παρουσιάζονται **μόνο** τα βέλτιστα αποτελέσματα για κάθε υποσύνολο δεδομένων και κάθε μέθοδο που εξετάσαμε στο κεφάλαιο 3. Η καλύτερη απόδοση ταξινόμησης από κάθε μέθοδο επισημαίνεται με έντονο χρώμα για τη διευκόλυνση της σύγκρισης και στην παράγραφο που ακολουθεί μετά τον πίνακα, αναλύονται τα αποτελέσματα της σύγκρισης, με σκοπό την εύρεση της καλύτερης και πιο αποδοτικής μεθόδου.

Πίνακας 5.29:

Συνολικός συγκριτικός πίνακας με τα βέλτιστα αποτελέσματα ταξινόμησης κάθε μεθόδου.

| Εργασίες | Τεχνική Μείωσης Διαστάσεων - Επιλογή χαρακτηριστικών | Μέθοδος Εξαγωγής Χαρακτηριστικών | Αλγόριθμος Ταξινόμησης | Σύνολο Δεδομένων | Αριθμός Τάξεων | Ακρίβεια Ταξινόμησης (%) | |
|---------------------------------|--|---------------------------------------|--------------------------|--------------------------------|---------------------------------------|-----------------------------|-------------------|
| [33] | Χωρίς επιλογή χαρακτηριστικών (LBP ^{all}) | 1D-LBP | Functional Tree | A-E | 2 | 99.50 | |
| | | | BayesNet | A-D | 2 | 99.50 | |
| | | | | D-E | 2 | 93.00 | |
| | | | | E-CD | 2 | 95.66 | |
| | | | | AB-CDE | 2 | 93.00 | |
| | | | | A-D-E | 3 | 95.67 | |
| | Ομοιόμορφα χαρακτηριστικά (LBP ^{u2}) | 1D-LBP | Functional Tree | A-E | 2 | 99.50 | |
| | | | BayesNet | A-D | 2 | 99.50 | |
| | | | LR | A-D | 2 | 99.50 | |
| | | | BayesNet | D-E | 2 | 95.50 | |
| | | | | E-CD | 2 | 97.00 | |
| | | | ANN | AB-CDE | 2 | 95.40 | |
| | | | BayesNet | A-D-E | 3 | 95.67 | |
| | | | [52] | Energy-Entropy based approach | Non-linear parameters (fractals, DFA) | SVM (with PUK kernel) | Alpha-beta band |
| LS-SVM (with polynomial kernel) | 2 | 98.58 | | | | | |
| ANN | 2 | 98.30 | | | | | |
| [68] | VMD+logarithmic operation | AR based quadratic feature extraction | Random forest classifier | - | 3 | 97.280 (με το κριτήριο FPE) | |
| | | | | | 3 | 97.320 (με το κριτήριο AIC) | |
| | | | | | 3 | 97.232 (με το κριτήριο BIC) | |
| | | | | | 3 | 97.352 (με το κριτήριο CAT) | |
| [104] | Incremental wrappers | Filter Bank | LDA/ELM/SVM | - | 2 | 92.00/86.00/88.00 | |
| | | | | | Davies-Bouldin | 2 | 85.00/83.00/82.00 |
| | | | | | Pearson's filter | 2 | 84.50/83.00/82.00 |
| | | | | | No selection method | 2 | 75.00/85.00/86.00 |
| | Incremental wrappers | SFTF | LDA/ELM/SVM | | 2 | 92.00/89.00/89.00 | |
| | | | | | Davies-Bouldin | 2 | 90.50/88.00/88.00 |
| | | | | | Pearson's filter | 2 | 90.00/88.00/89.50 |
| | | | | | No selection method | 2 | 75.00/85.00/85.50 |
| | Incremental wrappers | Welch's method | LDA/ELM/SVM | | 2 | 93.50/90.50/89.50 | |
| | | | | | Davies-Bouldin | 2 | 93.00/86.50/90.00 |
| | | | | | Pearson's filter | 2 | 90.50/88.00/89.80 |
| | | | | | No selection method | 2 | 73.00/84.00/85.00 |
| [134] | - | wavelets (WT) | Naïve Bayes (NBC) | D4, D5 για ALS vs PD | 2 | 82.39 | |
| | | | LDA | D2, D5 για ALS vs HD | 2 | 74.85 | |
| | | | Naïve Bayes | D5, D6 για ALS vs normal | 2 | 90.93 | |
| | | | Naïve Bayes | D4, D5 για ALS vs PD+HD | 2 | 76.29 | |
| | | | Naïve Bayes | D4, D5 για ALS vs normal+PD+HD | 2 | 83.11 | |
| [155] | ICA, PCA | Combination of DWT+PCA and HOS+ICA | SVM (RBF kernel) | N, S, V, F, U | 5 | 98.91 | |
| | | | NN | N, S, V, F, U | 5 | 98.90 | |

Από τον παραπάνω πίνακα μπορούμε εύκολα να παρατηρήσουμε ότι η μέθοδος με την υψηλότερη ακρίβεια ταξινόμησης, συγκριτικά με τις υπόλοιπες, αφορά την εξαγωγή χαρακτηριστικών από ΗΕΓ με σκοπό την ταξινόμηση της επιληψίας και είναι **η μέθοδος των τοπικών δυαδικών προτύπων μίας διάστασης (1D-LBP)**. Συνοψίζοντας, λοιπόν, η μέθοδος αυτή εφαρμόστηκε για δύο ομάδες χαρακτηριστικών, τα αρχικά (συνολικά) χαρακτηριστικά LBP^{all} και τα ομοιόμορφα (μειωμένα) χαρακτηριστικά LBP^{u2} , τα οποία ταξινομήθηκαν με τους ταξινομητές Functional Tree (FT), BayesNet, SVM, ANN και Logistic Regression (LR). Όπως παρατηρείται από τον πίνακα, οι ακρίβειες ταξινόμησης για τις διάφορες ομάδες δεδομένων (A, B, C, D, E) αναφορικά με την ταξινόμηση δύο τάξεων, είναι σαφώς βελτιωμένες με τη χρήση των μειωμένων χαρακτηριστικών LBP^{u2} , ωστόσο αυτό που κάνει εντύπωση είναι ότι η μέγιστη ακρίβεια ταξινόμησης που παρατηρείται για τη συγκεκριμένη μέθοδο (1D-LBP), είναι η ίδια για τόσο για τα LBP^{all} , όσο και τα LBP^{u2} χαρακτηριστικά. Η μέγιστη αυτή ακρίβεια είναι αρκετά υψηλή με τιμή 99.50% και επιτεύχθηκε για τα LBP^{all} χαρακτηριστικά για τις ταξινομήσεις μεταξύ των ομάδων A-E και A-D με τους ταξινομητές FT και BayesNet αντίστοιχα, ενώ για τα LBP^{u2} χαρακτηριστικά για τις ταξινομήσεις μεταξύ των ομάδων A-E και A-D με τους ταξινομητές FT (για την A-E) και BayesNet και LR (για την A-D). Η μέθοδος αυτή μπορεί να σταθεί αρωγός στην προσπάθεια για τη διάγνωση της επιληψίας καθώς τα αποτελέσματά της είναι ιδιαίτερος ενθαρρυντικά.

Σε σύγκριση με την άλλη μέθοδο που προτάθηκε για την ανίχνευση των επιληπτικών ΗΕΓ [68], η οποία έχει μέγιστη απόδοση ταξινόμησης 97.352%, η 1D-LBP παρουσιάζει ένα σαφές προβάδισμα για ασφαλέστερη και πιο σωστή ταξινόμηση των ΗΕΓ. Η άλλη μέθοδος χρησιμοποιεί για την εξαγωγή των χαρακτηριστικών μια μέθοδο βασισμένη στο AR μοντέλο και για την ταξινόμηση, ταξινομητή τυχαίου δάσους, ενώ επιτυγχάνει την μέγιστη απόδοσή της με τη χρήση του κριτηρίου CAT. Αρχικά, με τη βοήθεια της μεθόδου VMD το ΗΕΓ αποσυντέθηκε σε 15 συναρτήσεις εγγενούς λειτουργίας (BLIMFs) και στη συνέχεια εξήχθησαν από τις BLIMFs οι βέλτιστοι AR συντελεστές. Τέλος, υπολογίστηκαν οκτώ στατιστικές παράμετροι (η ενέργεια, το μήκος, η μέγιστη, η ελάχιστη και η μέση τιμή, η διακύμανση, η ασυμμετρία και η κύρτωση των συντελεστών) από το συντελεστή του καλύτερου μοντέλου AR, για να γίνει η ταξινόμηση. Η τεχνική αυτή ταξινομεί τα ΗΕΓ σε τρεις τάξεις (φυσιολογικά ΗΕΓ, ΗΕΓ στο χρονικό διάστημα μεταξύ κρίσεων και ΗΕΓ κατά τη διάρκεια επιληπτικής κρίσης) και κατατάσσεται 4η στο σύνολο των 6 μεθοδολογιών που αναπτύχθηκαν και 3η μεταξύ των μεθόδων που εφαρμόζονται σε ηλεκτροεγκεφαλογραφήματα.

Πολύ καλή απόδοση λαμβάνεται και από τη μέθοδο που εφαρμόζεται στα ηλεκτροκαρδιογραφήματα για τη διάγνωση των αρρυθμιών, η οποία χρησιμοποιεί ένα συνδυασμό γραμμικών και μη γραμμικών χαρακτηριστικών για την ταξινόμησή των ΗΚΓ [155]. Η μέθοδος αυτή είναι η δεύτερη πιο πετυχημένη μέθοδος, αφού η μέγιστη μέση απόδοσή της για όλες τις τάξεις αρρυθμίας με τον ταξινομητή SVM με RBF kernel αγγίζει το 98.91%. Τα προτεινόμενα χαρακτηριστικά (12 με DWT και 16 με HOS) σε συνδυασμό με τις μεθόδους για τη μείωση των χαρακτηριστικών (PCA και ICA, για γραμμικά και μη γραμμικά χαρακτηριστικά, αντίστοιχα), παρέχουν πολύ μεγαλύτερη ακρίβεια σε σύγκριση με μόνο γραμμικά ή μόνο μη γραμμικά χαρακτηριστικά, τα οποία πετυχαίνουν μέγιστη μέση ακρίβεια για όλες τις τάξεις 88.04% και 97.83%, αντίστοιχα. Αξίζει να σημειωθεί, ότι προτεινόμενη μέθοδος είναι ικανή να ταξινομήσει τις τάξεις αρρυθμίας S, F και U με ακρίβεια 100% με τη χρήση του ταξινομητή SVM-RBF.

Τρίτη στην συνολική κατάταξη και δεύτερη από την πλευρά των τεχνικών που εφαρμόζονται σε ΗΕΓ είναι η μέθοδος [52] που εφαρμόζει εξαγωγή τριών μη γραμμικών χαρακτηριστικών (Higuchi fractals, Petrosian fractals και DFA). Τα τρία, αυτά, μη γραμμικά χαρακτηριστικά που εξάγονται, σχηματίζουν τρία διανύσματα χαρακτηριστικών, ένα για κάθε υποζώνη συχνότητας (άλφα, βήτα και άλφα-βήτα), ενώ η τιμή τους σχετίζεται με τη μέτρηση του μήκους της καμπύλης του ΗΕΓ. Η μέθοδος αυτή έχει μέγιστη απόδοση 98.84%, η οποία επιτυγχάνεται με τον ταξινομητή SVM με PUK kernel για την άλφα-βήτα ζώνη συχνότητας. Χρησιμοποιήθηκε για την ανίχνευση του επιπέδου επαγρύπνησης των ατόμων, με ταξινόμηση των αντίστοιχων ΗΕΓ σε δύο τάξεις, ενώ κατά την εφαρμογή της γίνεται βελτιστοποίηση των καναλιών από τα οποία παρέχονται τα βιοσήματα (ΗΕΓ).

Τη χρήση μη γραμμικών τεχνικών για εξαγωγή χαρακτηριστικών, ακολουθεί από άποψη απόδοσης ταξινόμησης η χρήση της μεθόδου Welch. Η μέθοδος αυτή υπολογίζει την πυκνότητα φασματικής ισχύος ως το μέσο όρο των περιοδογραμμάτων των τμημάτων του ΗΕΓ, με χρήση του μετασχηματισμού FFT. Η μέγιστη ακρίβεια ταξινόμησης της μεθόδου Welch είναι 92% και επιτεύχθηκε με μέθοδο επιλογής χαρακτηριστικών την incremental wrapper και ταξινομητή την LDA.

Ακολουθούν οι άλλες δύο φασματικές μέθοδοι εξαγωγής χαρακτηριστικών με χρήση τράπεζας φίλτρων και SFTF, οι οποίες έχουν και οι δύο μέγιστη ακρίβεια ταξινόμησης 92% και την επιτυγχάνουν με χρήση incremental wrapper και LDA ταξινομητή. Η τράπεζα φίλτρων αποσυνθέτει το ΗΕΓ σε συνιστώσες συχνότητας με ένα σύνολο 2 ζωνοπερατών φίλτρων και έτσι λαμβάνει μια εκτίμηση του φάσματος ισχύος από τον υπολογισμό της ισχύος εξόδου των στοιχείων της. Η δεύτερη μέθοδος από την άλλη, υπολογίζει το φασματογράφημα, δηλαδή το μέτρο του SFTF υψωμένο στο τετράγωνο, γύρω από τις προκληθείσες συχνότητες.

Τέλος, η μέθοδος που κατατάσσεται τελευταία από το σύνολο των έξι τεχνικών είναι εκείνη που επιχειρεί να ταξινομήσει την ALS με χρήση του DWT. Η χρήση του DWT αποσυνθέτει το σήμα CFS σε συνιστώσες υψηλής συχνότητας (λεπτομέρειες) και χαμηλής συχνότητας (προσεγγίσεις), έξι επιπέδων για να μπορέσει να εξάγει τα βέλτιστα χαρακτηριστικά για την ταξινόμηση, δηλαδή τους συντελεστές των συνιστωσών. Ωστόσο, η χρήση των wavelets, παρόλο που παρέχει αρκετά πλεονεκτήματα σε σχέση με τεχνικές χρόνου ή συχνότητας, δεν αποδείχθηκε ιδιαίτερα ικανοποιητική, καθώς η υψηλότερη ακρίβεια ταξινόμησης που επιτεύχθηκε είναι 90.93% με χρήση του ταξινομητή Naïve Bayes και για το διαχωρισμό των φυσιολογικών ΗΜΓ από τα ΗΜΓ που πάσχουν από ALS.

ΚΕΦΑΛΑΙΟ 6

Συμπεράσματα - Μελλοντικές Επεκτάσεις

6.1 Συμπεράσματα

Στην παρούσα διπλωματική εργασία παρουσιάστηκαν διάφοροι αλγόριθμοι για την εξαγωγή των χαρακτηριστικών των βασικών μονοδιάστατων βιολογικών σημάτων, που περιέχουν τη βέλτιστη πληροφορία ταξινόμησης, ώστε να χρησιμοποιηθούν σε εφαρμογές της Βιοϊατρικής. Η βασική λειτουργία των αλγορίθμων αυτών ήταν ο μετασχηματισμός των αρχικών χαρακτηριστικών των σημάτων σε έναν χώρο μικρότερης διάστασης, έτσι ώστε να μειωθεί ο αριθμός τους και στη συνέχεια η εξαγωγή των καταλληλότερων χαρακτηριστικών, δηλ η επιλογή εκείνων που προσφέρουν τα μέγιστα στην επερχόμενη ταξινόμηση. Αναλυτικότερα, όλοι οι τεχνικές που αναπτύχθηκαν, υλοποιούν εξαγωγή των χαρακτηριστικών με χρήση μεθόδων είτε στο πεδίο του χρόνου, είτε στο πεδίο της συχνότητας, είτε στο πεδίο χρόνου-συχνότητας. Χρησιμοποιήθηκαν, ακόμη, μη γραμμικές μέθοδοι για την εξαγωγή χαρακτηριστικών και στη συνέχεια τα σήματα ταξινομήθηκαν με βάση τα εξαγόμενα χαρακτηριστικά τους. Η ταξινόμηση, που ακολούθησε την εξαγωγή χαρακτηριστικών, υλοποιήθηκε με τη χρήση διαφόρων αλγορίθμων, ώστε να μπορέσει να διεξαχθεί μια ικανοποιητική σύγκριση της απόδοσής τους.

Συνολικά η μέθοδος που παρουσίασε το υψηλότερο ποσοστό σωστών ταξινομήσεων ήταν η μέθοδος 1D-LBP, η οποία αντιμετωπίζει τη διάγνωση της επιληψίας, ως ένα πρόβλημα ταξινόμησης προτύπων δύο τάξεων. Όσον αφορά την εξαγωγή χαρακτηριστικών, η μέθοδος αυτή μετασχηματίζει το ΗΕΓ μέσω της μεθόδου 1D-LBP, δημιουργώντας δεκαδικούς κωδικούς (από 0-255) για κάθε σημείο του ΗΕΓ ανάλογα με το αν το πλάτος τους είναι μεγαλύτερο από το πλάτος του κεντρικού σημείου. Στη συνέχεια, από το σύνολο αυτών των 256 διαφορετικών χαρακτηριστικών που δημιουργήσε, επιλέγει τα ομοιόμορφα μετασχηματισμένα χαρακτηριστικά (LBP^{u2} -58 στον αριθμό-) για την εκτέλεση της ταξινόμησης. Ως διανύσματα χαρακτηριστικών, θεωρήθηκαν τα ιστογράμματα των LBP^{all} και LBP^{u2} , τα οποία παρουσιάζουν τη συχνότητα των LBP κωδικών μεταξύ των σημείων του ΗΕΓ. Η επιλογή των ομοιόμορφων, μόνο, χαρακτηριστικών από το σύνολο όλων των χαρακτηριστικών, φαίνεται ότι συνέβαλε αρκετά στη βελτίωση της απόδοσης ταξινόμησης. Αξίζει να σημειωθεί ότι η μέγιστη ακρίβεια ταξινόμησης της μεθόδου (99.50%), επιτεύχθηκε –με τα ομοιόμορφα χαρακτηριστικά– για τρεις από τους πέντε ταξινομητές που χρησιμοποιήθηκαν. Τα αποτελέσματα αυτά μας δείχνουν ότι έχει γίνει σημαντική πρόοδος στην ανίχνευση και ταξινόμηση της επιληψίας και υπάρχει πρόσφορο έδαφος για περαιτέρω εξέλιξη στον τομέα αυτό.

Όσον αφορά τις μελλοντικές επεκτάσεις της μεθόδου, για περαιτέρω βελτιώσεις της ακρίβειας ταξινόμησης θα μπορούσαν να χρησιμοποιηθούν άλλες τεχνικές προεπεξεργασίας των δεδομένων και διαφορετικές μέθοδοι επιλογής των χαρακτηριστικών (όσον αφορά τα αρχικά χαρακτηριστικά LBP^{all}). Επίσης, θα μπορούσαν να χρησιμοποιηθούν διαφορετικοί ταξινομητές για την ταξινόμηση των ΗΕΓ ή/και να γίνει χρήση μιας μεθόδου επικύρωσης των ταξινομητών η οποία να χρησιμοποιεί μεγαλύτερο ποσοστό των δεδομένων την για εκπαίδευση των ταξινομητών (π.χ. 70%) και το υπόλοιπο για δοκιμή. Η μέθοδος 1D-LBP, με τις όποιες βελτιώσεις δέχεται, θα μπορούσε να γίνει ένα χρήσιμο εργαλείο για την ανίχνευση των επιληπτικών ΗΕΓ και θα βοηθούσε πολλούς γιατρούς στο έργο τους,

αλλά και ασθενείς οι οποίοι θα λάμβαναν γρηγορότερη και σωστότερη διάγνωση, γλιτώνοντας την ταλαιπωρία.

Από την άλλη πλευρά, συνοψίζοντας τα αποτελέσματα όλων των μεθόδων, καταλήγουμε στο συμπέρασμα ότι η ακρίβεια ταξινόμησης για τις τεχνικές που χρησιμοποιούν μη γραμμική εξαγωγή χαρακτηριστικών, είναι ιδιαίτερος υψηλή. Πιο συγκεκριμένα, η ανίχνευση της αρρυθμίας στην οποία χρησιμοποιήθηκε ένας συνδυασμός γραμμικών και μη γραμμικών χαρακτηριστικών, αλλά και η ανίχνευση του επιπέδου επαγρύπνησης με τις μεθόδους fractals και DFA για την εξαγωγή των χαρακτηριστικών, καταλαμβάνουν τη δεύτερη και τρίτη θέση αντίστοιχα στην κατάταξή μας. Φτάνουμε, έτσι, στο συμπέρασμα ότι οι τεχνικές εξαγωγής μη γραμμικών χαρακτηριστικών, ίσως μπορούν να μας βοηθήσουν να επιλέξουμε τα χαρακτηριστικά του σήματος που να περικλείουν τη μέγιστη πληροφορία που περιέχει ένα μη στάσιμο σήμα, όπως το ΗΚΓ και το ΗΕΓ. Επίσης, εύκολα παρατηρούμε ότι στις μεθόδους Higuchi FD, Petrosian FD και DFA, η ακρίβεια ταξινόμησης για κάθε ταξινομητή είναι πολύ κοντά με αυτή των υπολοίπων. Αυτό μας οδηγεί στο συμπέρασμα ότι η επιλογή της μεθόδου εξαγωγής χαρακτηριστικών ίσως να είναι ένα έργο ακόμη πιο σημαντικό και από την επιλογή του ταξινομητή, αφού φαίνεται να παίζει μεγαλύτερο ρόλο στην ακρίβεια της ταξινόμησης.

6.2 Μελλοντικές Επεκτάσεις

Ολοκληρώνοντας αυτή τη διπλωματική εργασία, θα παραθέσουμε ως επίλογο στο τελευταίο αυτό κεφάλαιο τα συμπεράσματα στα οποία καταλήξαμε όσον αφορά σημασία των μεθόδων εξαγωγής χαρακτηριστικών στα Συστήματα Υποβοήθησης της Διάγνωσης, τονίζοντας παράλληλα τις μελλοντικές χρήσεις και επεκτάσεις μιας τέτοιας τεχνολογίας, η ανάπτυξη και βελτιστοποίηση της οποίας αποτελεί αναγκαιότητα στη σύγχρονη εποχή.

Σε μια εποχή που παρατηρείται μεγάλη αύξηση στη διαθεσιμότητα των δεδομένων προς επεξεργασία σε όλους τους τομείς, η Μηχανική Μάθηση παρέχει τεχνικές για την καλύτερη αξιοποίηση των δεδομένων αυτών, σε περιβάλλοντα υψηλής πολυπλοκότητας όπου ο ανθρώπινος παράγοντας και οι κλασικές προσεγγίσεις με μαθηματικά μοντέλα δεν μπορούν να αποδώσουν ικανοποιητικά [183].

Πιο συγκεκριμένα ο τομέας της Ιατρικής, ο οποίος στηρίζεται σε μεγάλο βαθμό στα ηλεκτρονικά ιατρικά μηχανήματα για να εκτελέσουν στους ασθενείς τις διαγνωστικές εξετάσεις, έχει να διαχειριστεί μια ευρεία ποικιλία δεδομένων, αλλά και έναν τεράστιο όγκο από αυτά, ο οποίος είναι απαγορευτικός για να εξεταστεί εξ ολοκλήρου. Γι' αυτό το λόγο, η Ιατρική έχει στραφεί τα τελευταία χρόνια στη μηχανική μάθηση και στηρίζεται στις μεθόδους της για τη μείωση του όγκου των προς επεξεργασία δεδομένων, αλλά και τη διευκόλυνση των ιατρών, δίνοντας μια ένδειξη σχετικά με την κατεύθυνση της διάγνωσης.

Σε τέτοιες εφαρμογές της Βιοϊατρικής και Βιοπληροφορικής, λοιπόν, που αφορούν τη διάγνωση διαφόρων ασθενειών, καταλαβαίνουμε ότι είναι υψίστης σημασίας η ανάπτυξη εξειδικευμένων συστημάτων με πολλή υψηλή ακρίβεια ταξινόμησης των προτύπων που εισάγονται για αναγνώριση, καθώς αυτό που διακυβεύεται είναι η ανθρώπινη ζωή και υγεία. Η εξαγωγή των καταλληλότερων χαρακτηριστικών (αυτών δηλ. που περιέχουν τις σημαντικότερες πληροφορίες) από τα σήματα-πρότυπα, είναι ίσως το κυριότερο στάδιο των Συστημάτων Υποβοήθησης

της Διάγνωσης, το οποίο επηρεάζει – όπως είδαμε από τα πειραματικά αποτελέσματα –σε μεγάλο βαθμό την απόδοση της ταξινόμησης.

Η ανάπτυξη βελτιστοποιημένων Συστημάτων Υποβοήθησης της Διάγνωσης με υψηλή απόδοση, τα οποία θα μπορούν να «εμπιστεύονται» περισσότερο οι γιατροί, αποτελεί πρόκληση για τους επιστήμονες του κλάδου της Βιοϊατρικής Μηχανικής. Υπάρχουν αρκετοί τρόποι με τους οποίους θα μπορούσαν να βελτιωθούν μελλοντικά τα Συστήματα Υποβοήθησης της Διάγνωσης και αυτοί περιλαμβάνουν την βελτίωση όλων των επιμέρους σταδίων τους. Έτσι, θα μπορούσε να γίνεται αποτελεσματικότερο φιλτράρισμα στην προεπεξεργασία των λαμβανόμενων σημάτων, ώστε να απομακρύνεται ο θόρυβος και να μην αλλοιώνονται τα χαρακτηριστικά του σήματος που θα χρησιμοποιηθούν για την ταξινόμηση. Όσον αφορά την εξαγωγή των χαρακτηριστικών, θα πρέπει πάντα να τηρείται η ισορροπία μεταξύ του αριθμού των χαρακτηριστικών που επιλέγονται και της πληροφορίας που περιέχουν. Χρήσιμη θα ήταν, επίσης, η επέκταση των τεχνικών αυτών στην αντιμετώπιση προβλημάτων ταξινόμησης με περισσότερες από δύο ομάδες, καθότι πλέον τα περισσότερα προβλήματα αφορούν ταξινόμηση σε περισσότερες από δύο τάξεις. Τέλος, η ταξινόμηση θα μπορούσε να βελτιωθεί με τη χρήση ταξινομητών, οι οποίοι δεν θα εκπαιδεύονται από πριν σε ένα σύνολο δεδομένων, αλλά θα χρησιμοποιούν κατάλληλα το σύνολο χαρακτηριστικών του συγκεκριμένου προβλήματος, για την εκπαίδευσή τους και την υλοποίηση της ταξινόμησης. Με αυτόν τον τρόπο, θα είναι σε θέση να αξιοποιήσουν καλύτερα το υπάρχον σύνολο χαρακτηριστικών, σύμφωνα με τις ανάγκες του συγκεκριμένου προβλήματος ταξινόμησης και να επιτύχουν υψηλότερη ακρίβεια ταξινόμησης. Επίσης, μια αξιολογη ερευνητική κατεύθυνση είναι η ανάπτυξη μεθόδων, είτε από το χώρο της μάθησης με μερική επίβλεψη ή της περιγραφής έννοιας, που να επιτρέπουν την εξέλιξη ενός υπάρχοντος μοντέλου ταξινόμησης, μέσω σχημάτων επαυξητικής μάθησης (incremental learning). Τα αποτελέσματα τέτοιων μεθόδων θα αποδεικνύονταν ευεργετικά σε περιπτώσεις που η κατανομή των στιγμιότυπων του προβλήματος ταξινόμησης που συναντώνται στην πράξη άλλαζε με την πάροδο του χρόνου.

Με αυτόν τον τρόπο, η διάγνωση των διαφόρων ασθενειών θα γίνεται γρηγορότερα, ευκολότερα και πιο σωστά, σώζοντας ακόμα και τις ζωές των ασθενών σε περιπτώσεις όπου η έγκαιρη διάγνωση είναι απαραίτητη για την εφαρμογή θεραπείας. Επίσης, οι ασφαλέστερες διαγνώσεις συντελούν στην αποφυγή άσκοπων εξετάσεων ή και θεραπειών, με αποτέλεσμα να μειώνεται η ταλαιπωρία των ασθενών.

Παράλληλα, η ανάπτυξη αποδοτικότερων αυτοματοποιημένων Συστημάτων Υποβοήθησης της Διάγνωσης συμβάλει σημαντικά και στην εξοικονόμηση πόρων σε χρήματα, χρόνο νοσηλείας, ενασχόλησης των ειδικών και σε εξοπλισμό, αφού γίνεται καλύτερη κατανομή των διαθέσιμων πόρων για διάγνωση και θεραπεία.

Συμπερασματικά, η συνεχής και αδιάκοπη ενασχόληση και προσήλωση προς την κατεύθυνση της συνεχούς ανάπτυξης νέων, καλύτερων μεθόδων που έχουν εφαρμογή στα Συστήματα Υποβοήθησης της Διάγνωσης, αποτελεί μονόδρομο για τους επιστήμονες του κλάδου, όχι μόνο για την ανακάλυψη νέας γνώσης στο πεδίο αυτό, αλλά και για τη βελτίωση των υπηρεσιών υγείας που παρέχονται στους ασθενείς. Η ραγδαία εξέλιξη των τεχνικών Μηχανικής Μάθησης τα τελευταία χρόνια, μας παρέχει το απαραίτητο υπόβαθρο για να υλοποίηση αυτής της προσπάθειας.

Βιβλιογραφία

2^ο Κεφάλαιο

- [1a] Wikipedia, pattern recognition, https://en.wikipedia.org/wiki/Pattern_recognition
- [1b] Wikipedia, medical diagnosis, https://en.wikipedia.org/wiki/Medical_diagnosis
- [2] S. Theodoridis, K. Koutroumbas, “*Pattern Recognition*”, fourth edition, pp. 1-9, 2009
- [3] Γεώργιος Λ. Τσιρογιάννης, “Ευφυές σύστημα συνδυασμού μεθόδων ταξινόμησης για ιατρική διάγνωση”, Διπλωματική εργασία Ε.Μ.Π., 2003
- [4] Making a diagnosis, John P. Langlois, Chapter 10 in *Fundamentals of clinical practice* (2002). Mark B. Mengel, Warren Lee Holleman, Scott A. Fields. 2nd edition. p.198.
- [5] Γεώργιος Α. Γιαννακάκης, “Ανάπτυξη Συστήματος Υποστήριξης Διάγνωσης Ψυχικών Ασθενειών με Χρήση Προκλητών Εγκεφαλικών Δυναμικών”, Διπλωματική εργασία Ε.Μ.Π., 2003
- [6] Σ. Μουγιακάκου, “Ανάπτυξη Συστημάτων Υποστήριξης Κλινικών Αποφάσεων με Χρήση Μεθόδων Τεχνητής Νοημοσύνης”, Διδακτορική Διατριβή Ε.Μ.Π., 2003.
- [7] E.H. Shortliffe, “The Science of Biomedical Computing,” *Medical Informatics*, vol. 9, pp. 185-193, 1985.
- [8] J.H. Van Bommel, “The Structure of Medical Informatics,” *Medical Informatics*, vol. 9, pp. 175-180, 1984.
- [9] E.H. Shortliffe, L. Perrault, G. Wiederhold, L. Fagan, *Medical Informatics*, Wokingham: Addison-Wesley, 1990.
- [10] D. Hunt, R.B. Haynes, S. Hanna, K. Smith, “Effects of Computer-based Clinical Decision Support Systems on Physician Performance and Patient Outcomes”, *Journal of American Medical Association*, vol. 280, pp. 1339-1346, 1998.
- [11] Decision support systems. 26 July 2005. 17 Feb. 2009 <<http://www.openclinical.org/dss.html>>
- [12] I.N. Bankmann, *Handbook of Medical Imaging*, Academic Press, 2000.
- [13] B. Spyropoulos, G. Panagopoulos, A theoretical approach to artificial intelligence systems in medicine, *Artificial Intelligence in Medicine*, vol. 7, p. 455-465, 1995.
- [14] B. Van Ginneken, B.M. Ter Haar Romeny, M.A. Viergever, “Computer-Aided Diagnosis in Chest Radiography: A Survey,” *IEEE Transactions on Medical Imaging*, vol. 20, no. 12, pp. 1228-1241, 2001.
- [15] S. Dinggang, Z. Yiqiang, C. Davatzikos, “Segmentation of Prostate Boundaries from Ultrasound Images using Statistical Shape Model,” *IEEE Transactions on Medical Imaging*, vol. 22, no. 4, pp. 539-551, 2003.
- [16] X. Muñoz, J. Freixenet, X. Cufí and J. Martí, “Strategies for Image Segmentation Combining Region and Boundary Information,” *Pattern Recognition Letters*, vol. 24, no. 1-3, pp. 375-392, 2003.
- [17] A.K. Jain, R.P.W. Duin, M. Jianchang, “Statistical Pattern Recognition: A Review,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 22, no. 1, pp. 4-37, Jan 2000.
- [18] P. Asvestas, S. Golemati, G.K. Matsopoulos, K.S. Nikita, A.N. Nicolaidis, “Fractal Dimension Estimation of Carotid Atherosclerotic from B-mode Ultrasound: A Pilot Study,” *Ultrasound in Medicine and Biology*, vol. 28, pp. 1129-1136, 2002.
- [19] K.N. Bhanu-Prakash, A.G. Ramakrishnan, S. Suresh, T.W.P. Chow, “Fetal Lung Maturity Analysis using Ultrasound Image Features,” *IEEE Transactions on Information Technology in Biomedicine*, vol. 6, no. 1, pp. 38-45, 2002.
- [20] J.C. Bezdek, *Pattern Recognition with Fuzzy Objective Function Algorithms*, Plenum Press, New York, NY, 1981.
- [21] L.A. Zadeh, “Fuzzy Sets,” *Inf. Control*, vol. 8, pp. 338-353, 1965.
- [22] T. Kohonen, *Self-Organization and Associative Memory*, 3rd ed. Springer Information Sciences Series. Springer-Verlag, New York, NY, 1989.
- [23] B. King, “Step-wise Clustering Procedures,” *Journal of the American Statistical Association*, vol. 69, pp. 86-101, 1967.
- [24] D.E. Goldberg, *Genetic Algorithms in Search, Optimization and Machine Learning*, Addison-Wesley Publishing Co., Inc., Redwood City, CA, 1989.
- [25] Monique Frize, Colleen M. Ennett, Maryhelen Stevenson, Heather C. E. Trigg, *Clinical Decision Support Systems for intensive care units: using Artificial Neural Networks*, *Medical Engineering & Physics*, vol. 23, Issue 3, p. 217-225, April 2001.
- [26] R.M. Rangayyan, *Biomedical Signal Analysis: A Case-Study Approach*, IEEE Press Series in Biomedical Engineering, John Wiley & Sons, Inc, 2002.
- [27] C. Hewitt, *Artificial intelligence: the challenge of open systems*, *BYTE*, p. 223-273, April 1985.

[28] E. Coiera, *Artificial Intelligence in Medicine. Guide to Medical Informatics, the Internet and Telemedicine*, Oxford University Press, 1997

3^ο Κεφάλαιο

- [29] Pudil P., Novovicova J., Kittler J. “Floating search methods in feature selection,” *Pattern Recognition Letters*, Vol. 15, pp. 1119–1125, 1994.
- [30] Παναγιώτα Δ. Σκουρουμούνη, “Μελέτη Εγκεφαλικής Δραστηριότητας Παρατηρητών”, Διπλωματική εργασία Ε.Μ.Π., 2013.
- [31] A.K. Jain, R.P.W. Duin, J. Mao, “Statistical Pattern Recognition: A Review,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 22, no. 1, pp. 4-37, 2000.
- [32] Εμμανουήλ Γ. Χαμηλάκης, “Αλληλεπίδραση ανθρώπου-υπολογιστή με χρήση βιοσημάτων”, Διπλωματική εργασία Ε.Μ.Π., 2014
- [33] Yılmaz Kaya, Murat Uyar, Ramazan Tekin, Selcuk Yildirim, 1D-local binary pattern based feature extraction for classification of epileptic EEG signals, *Applied Mathematics and Computation* 243 (2014) 209–219.
- [34] L.M. Patnaik, O.K. Manyam, Epileptic EEG detection using neural networks and post-classification, *Comput. Methods Programs Biomed.* 91 (2) (2008) 100–109.
- [35] A. Ropper, R.H. Brown, *Principles of Neurology*, eighth ed., McGraw-Hill, Boston, USA, 2005.
- [36] S. Altunay, Z. Telatar, O. Erogul, Epileptic EEG detection using the linear prediction error energy, *Expert Syst. Appl.* 37 (8) (2010) 5661–5665.
- [37] N. Paivinen, S. Lammi, A. Pitkanen, J. Nissinen, M. Penttonen, T. Gronfors, Epileptic seizure detection: a nonlinear viewpoint, *Comput. Methods Programs Biomed.* 79 (2) (2005) 151–159.
- [38] H. Mohseni, A. Maghsoudi, M. Kadbi, J. Hashemi, A. Ashourvan, Automatic detection of epileptic seizure using time–frequency distributions, in: *IET 3rd International Conference on Advances in Medical, Signal and Information Processing, MEDSIP 2006*, 2006, pp. 1–4.
- [39] K. Polat, S. Gunes, Classification of epileptiform EEG using a hybrid system based on decision tree classifier and fast Fourier transform, *Appl. Math. Comput.* 187 (2) (2007) 1017–1026.
- [40] N.F. Guler, E.D. Ubeyli, Multiclass support vector machines for EEG-signals classification, *IEEE Trans. Inf. Technol. Biomed.* 11 (2) (2007) 117–126.
- [41] A. Subasi, EEG signal classification using wavelet feature extraction and a mixture of expert model, *Expert Syst. Appl.* 32 (4) (2007) 1084–1093.
- [42] A. Subasi, E. Ercelebi, Classification of EEG signals using neural network and logistic regression, *Comput. Methods Programs Biomed.* 78 (2) (2005) 87–99.
- [43] A. Tzallas, M. Tsipouras, D. Fotiadis, Automatic seizure detection based on time–frequency analysis and artificial neural networks, *Comput. Intell. Neurosci.* 18 (2007) 80510.
- [44] Q. Yuan, W. Zhou, S. Li, D. Cai, Epileptic EEG classification based on extreme learning machine and nonlinear features, *Epilepsy Res.* 96 (1–2) (2011) 29–38.
- [45] B. Kurt, V.V. Nabiyev, Down syndrome recognition using local binary patterns and statistical evaluation of the system, *Expert Syst. Appl.* 38 (7) (2011) 8690–8695.
- [46] S. Moore, R. Bowden, Local binary patterns for multi-view facial expression recognition, *Comp. Vis. Img. Underst.* 115 (4) (2011) 541–558.
- [47] N. Chatlani, J.J. Soraghan, Local binary patterns for 1-D signal processing, in: *18th European Signal Processing Conference (EUSIPCO-2010)*, August 23–27, Aalborg, Denmark, 2010, pp. 95–99.
- [48] Q. Zhu, N. Chatlani, J.J. Soraghan, 1-D Local binary patterns based VAD used INHMM-based improved speech recognition, in: *20th European Signal Processing Conference (EUSIPCO-2012)*, Bucharest, Romania, August 27–31, 2012, pp. 1633–1637.
- [49] T. Ojala, M. Pietikainen, D. Harwood, A comparative study of texture measures with classification based on feature distributions, *Pattern Recogn.* 29 (1) (1996) 51–59.
- [50] T. Ojala, M. Pietikainen, T. Maenpaa, Multiresolution gray-scale and rotation invariant texture classification with local binary patterns, *IEEE Trans. Pattern Anal. Mach. Intell.* 24 (7) (2002) 971–987.
- [51] E. Tekeli, M. Cetin, A. Ercil, Shape and data driven texture segmentation using local binary patterns, in: *15th European Signal Processing Conference (Eusipco 2007)*, Poznan, Poland, September 3–7, 2007.
- [52] R. Upadhyay, A. Manglick, D.K. Reddy, P.K. Padhy, P.K. Kankar, Channel optimization and nonlinear feature extraction for Electroencephalogram signals classification, *Computers and Electrical Engineering* 45 (2015) 222–234.

- [53] Yildiz A, Akin M, Poyraz M, Kirbas G. Application of adaptive neuro-fuzzy inference system for vigilance level estimation by using wavelet-entropy feature extraction. *Expert Syst Appl* 2009; 36:7390–9.
- [54] Hazarika N, Chen JZ, Tsio AC, Sergejew A. Classification of EEG signals using the wavelet transform. *Signal Proc* 1997; 59(1):61–72.
- [55] Subasi A. Automatic recognition of alertness level from EEG by using neural network and wavelet coefficients. *Expert Syst Appl* 2005;28:701–11.
- [56] Jung TP, Makeig S. Estimating level of alertness from EEG. In: *Proceedings of the 16th annual international conferences of the IEEE engineering in medicine and biology society*, vol. 1. 1994. p. 103–4.
- [57] Inouye T, Ukai S, Shinosaki K, Iyama A, Matsumoto Y, Toi S. Changes in the FD of alpha envelope from wakefulness to drowsiness in the human electroencephalogram. *Neurosci Lett* 1994;174(1):105–8.
- [58] Stan CJ. Nonlinear dynamical analysis of EEG and MEG: review of an emerging field. *Clin Neurophysiol* 2005.
- [59] Higuchi T. Approach to an irregular time series on the basis of the fractal theory. *Physica D* 1988;31:277–83.
- [60] Polychronaki GE, Ktonas PY, Gatzonis S, Siatouni A, Asvestas PA, Tsekou H, et al. Comparison of fractal dimension estimation algorithms for epileptic seizure onset detection. *J Neural Eng* 2010;7(4).
- [61] Mardi Z, Ashtiani SNM, Mikaili M. EEG-based drowsiness detection for safe driving using chaotic features and statistical tests. *J Med Signals Sensors* 2011;1:130–7.
- [62] Hossenifarad B, Hassan MM, Rostami R. Classifying depression patients and normal subjects using machine learning techniques and nonlinear features from EEG signal. *Comput Methods Programs Biomed* 2013;109(3):339–45.
- [63] Sukens JAK, Vandewalle J. Least squares support vector machine classifiers. *Neural Process Lett* 1999;9:293–300.
- [64] LS-SVMlab Toolbox (Version1.5). <<http://www.esat.kuleuven.ac.be/sista/lssvmlab/>>.
- [65] Hall M, Frank E, Holmes G, Pfahringer B, Reutemann P, Witten IH. The WEKA data mining software: an update. *SIGKDD Explor* 2009;11(1).
- [66] Kannathal N, Choo ML, Acharya UR, Sadasivan PK. Entropies for detection of epilepsy in EEG. *Comput Methods Programs Biomed* 2005;80(3):187–94.
- [67] Vakharia V, Kankar PK, Gupta VK. A multiscale permutation entropy based approach to select wavelet for fault diagnosis of ball bearings. *J Vib Control* 2014:1–9.
- [68] Tao Zhang, Wanzhong Chen, Mingyang Li, AR based quadratic feature extraction in the VMD domain for the automated seizure detection of EEG using random forest classifier, *Biomedical Signal Processing and Control* 31 (2017) 550–559.
- [69] V.K. Jirsa, W.C. Stacey, P.P. Quilichini, et al., On the nature of seizure dynamics, *Brain* 137 (2014) 2210–2230.
- [70] R.B. Pachori, S. Patidar, Epileptic seizure classification in EEG signals using second-order difference plot of intrinsic mode functions, *Comput. Methods Prog. Biomed.* 113 (2) (2014) 494–502.
- [71] P.J. Martis, J.H. Tan, C.K. Chua, et al., Epileptic EEG classification using nonlinear parameters on different frequency bands, *J. Mech. Med. Biol.* 15 (3)(2015) 1550040.
- [72] L.D. Iasemidis, D. Shiau, W. Chaovalitwongse, et al., Adaptive epileptic seizure prediction system, *IEEE Trans. Biomed. Eng.* 50 (5) (2003) 616–627.
- [73] U.R. Acharya, S.V. Sree, G. Swapna, et al., Automated EEG analysis of epilepsy: a review, *Knowl.-Based Syst.* 45 (2013) 147–165.
- [74] K. Sivasankari, K. Thanushkodi, An improved EEG signal classification using neural network with the consequence of ICA and STFT, *J. Electr. Eng. Technol.* 9 (3) (2014) 1060–1071.
- [75] T. Zhang, W. Chen, M. Li, Recognition of epilepsy electroencephalography based on AdaBoost algorithm, *Acta Phys. Sin.* 64 (12) (2015) 128701.
- [76] U.R. Acharya, S.V. Sree, A.P.C. Alvin, et al., Application of non-linear and wavelet based features for the automated identification of epileptic EEG signals, *Int. J. Neural Syst.* 22 (2) (2012) 565–579.
- [77] S. Lee, J.S. Lim, J. Kim, et al., Classification of normal and epileptic seizure EEG signals using wavelet transform, phase-space reconstruction, and Euclidean distance, *Comput. Methods Prog. Biomed.* 116 (1) (2014) 10–25.
- [78] V. Bajaj, R.B. Pachori, Classification of seizure and non-seizure EEG signals using empirical mode decomposition, *IEEE Trans. Inform. Technol. Biomed.* 16(6) (2012) 1135–1142.

- [79] N.E. Huang, Z. Shen, S.R. Long, et al., The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis, *Proc. R. Soc. A* 454 (1971) (1998) 903–995.
- [80] R.B. Pachori, V. Barun, Analysis of normal and epileptic seizure EEG signals using empirical mode decomposition, *Comput. Methods Prog. Biomed.* 104(3) (2011) 373–381.
- [81] S. Li, W. Zhou, Q. Yuan, et al., Feature extraction and recognition of ictal EEG using EMD and SVM, *Comput. Biol. Med.* 43 (7) (2013) 807–816.
- [82] S.M.S. Alam, M.I.H. Bhuiyan, Detection of seizure and epilepsy using higher order statistics in the EMD domain, *IEEE J. Biomed. Health Inform.* 17 (2)(2013) 312–318.
- [83] K. Dragomiretskiy, D. Zosso, Variational mode decomposition, *IEEE Trans. Signal Proc.* 62 (3) (2014) 531–544.
- [84] Z. Wu, N.E. Huang, Ensemble empirical mode decomposition: a noise-assisted data analysis method, *Adv. Adapt. Data Anal.* 1 (1) (2009) 1–41.
- [85] J.R. Yeh, J.S. Shieh, N.E. Huang, Complementary ensemble empirical mode decomposition: a novel noise enhanced data analysis method, *Adv. Adapt. Data Anal.* 2 (2) (2010) 135–156.
- [86] P.A. Bizopoulos, D.G. Tsalikakis, A.T. Tzallas, et al., EEG epileptic seizure detection using k-means clustering and marginal spectrum based on ensemble empirical mode decomposition, *IEEE Int. Conf. Bioinform. Bioeng.* 7789 (1) (2013) 1–4.
- [87] A.R. Hassan, M.A. Haque, Epilepsy and seizure detection using statistical features in the complete ensemble empirical mode decomposition domain, *IEEE Region 10 Conf.* 30 (192) (2015) 1–6.
- [88] Y. Wang, R. Markert, J. Xiang, et al., Research on variational mode decomposition and its application in detecting rub-impact fault of the rotor system, *Mech. Syst. Signal Proc.* 60–61 (2015) 243–251.
- [89] H. Khamis, A. Mohamed, S. Simpson, Seizure state detection of temporal lobe seizures by autoregressive spectral analysis of scalp EEG, *Clin. Neurophysiol.* 120 (8) (2009) 1479–1488.
- [90] S.H. Kim, C. Faloutsos, H.J. Yang, Coercively adjusted auto regression model for forecasting in epilepsy EEG, *Comput. Math. Methods Med.* 2013 (2013) 545613.
- [91] H. Wei-Yen, Assembling a multi-feature EEG classifier for left–right motor imagery data using wavelet-based fuzzy approximate entropy for improved accuracy, *Int. J. Neural Syst.* 25 (8) (2015) 1550037.
- [92] J.G. de Gooijer, B. Abraham, A. Gould, et al., Methods for determining the order of an autoregressive-moving average process: a survey, *Int. Stat. Rev.* 53(3) (1985) 301–329.
- [93] A. Subasi, Automatic detection of epileptic seizure using dynamic fuzzy neural networks, *Expert Syst. Appl.* 31 (2) (2006) 320–328.
- [94] Y. Kumar, M.L. Dewal, R.S. Anand, Epileptic seizures detection in EEG using DWT-based ApEn and artificial neural network, *Signal Image Video Proc.* 8 (7)(2014) 1323–1334.
- [95] Q. Yuan, W. Zhou, Y. Liu, Epileptic EEG classification based on extremelearning machine and nonlinear features, *Epilepsy Res.* 96 (1–2) (2011) 29–38.
- [96] E.D. Ubeyli, Lyapunov exponents/probabilistic neural networks for analysis of EEG signals, *Expert Syst. Appl.* 37 (2) (2010) 985–992.
- [97] U.R. Acharya, F. Molinari, S.V. Sree, et al., Automated diagnosis of epileptic EEG using entropies, *Biomed. Signal Process. Control* 7 (4) (2012) 401–408.
- [98] K. Fu, J. Qu, Y. Chai, Hilbert marginal spectrum analysis for automatic seizure detection in EEG signals, *Biomed. Signal Process. Control* 18 (2015) 179–185.
- [99] T. Zhang, W. Chen, M. Li, Automatic seizure detection of electroencephalogram signals based on frequency slice wavelet transform and support vector machine, *Acta Phys. Sin.* 65 (3) (2016) 038703.
- [100] R.G. Andrzejak, K. Lehnertz, C. Rieke, et al., Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: dependence on recording region and brain state, *Phys. Rev. E* 64 (6) (2001) 061907.
- [101] A. Subasi, Selection of optimal AR spectral estimation method for EEG signals using Cramer–Rao bound, *Comput. Biol. Med.* 37 (2) (2007) 183–194.
- [102] J. Burg, Maximum entropy spectral analysis, in: PhD Thesis, Stanford University, 1975.
- [103] L. Breiman, Random forests, *Mach. Learn.* 45 (1) (2001) 5–32
- [104] Sarah N. Carvalho, Thiago B.S. Costa, Luisa F.S. Uribe, Diogo C. Soriano, Glauco F.G. Yared, Luis C. Coradine, Romis Attux, Comparative analysis of strategies for feature extraction and classification in SSVEP BCIs, *Biomedical Signal Processing and Control* 21 (2015) 34–42.
- [105] J.R. Wolpaw, N.B.D.J. McFarland, G. Pfurtscheller, T.M. Vaughan, Brain–computer interfaces for communication and control, *Clin. Neurophysiol.* 113 (6) (2002) 767–791.

- [106] J.D.R. Millán, et al., Combining brain–computer interfaces and assistive technologies: state-of-the-art and challenges, *Front. Neurosci.* 4 (2010) 1–15, <http://dx.doi.org/10.3389/fnins.2010.00161>, Article 161.
- [107] A. Nihjolt, D. Tan, Brain–computer interfacing for intelligent systems, *IEEE Intell. Syst.* vol. 23 (3) (2008) 72–79.
- [108] G. Dornhege, *Toward Brain–Computer Interfacing*, MIT Press, United States of America, 2007.
- [109] G.B. Huang, D.H. Wang, Y. Lan, Extreme learning machines: a survey, *Int. J. Mach. Learn. Cybern.* 2 (May (2)) (2011) 107–122.
- [110] C.J.C. Burges, A tutorial on support vector machines for pattern recognition, *Data Min. Knowl. Discovery* 2 (2) (1998) 1–47.
- [111] R. Kohavi, G.H. John, Wrappers for feature subset selection, *Artif. Intell.* 97 (1)(1997) 273–324.
- [112] I. Guyon, A. Elisseeff, An introduction to variable and feature selection, *J. Mach. Learn. Res.* 3 (2003) 1157–1182.
- [113] D.L. Davies, D.W. Bouldin, A cluster separation measure, *IEEE Trans. Pattern Anal. Mach. Intell.* PAMI-1 (2) (1979) 224–227.
- [114] C.S. Hermann, Human EEG responses to 1–100 Hz flicker: resonance phenomena in visual cortex and their potential correlation to cognitive phenomena, *Exp. Brain Res.* 137 (3–4) (2001) 346–353, <http://dx.doi.org/10.1007/s002210100682>
- [115] G. Bin, X. Gao, Y. Wang, VEP-based brain–computer interfaces: time, frequency, and code modulations, *IEEE Comput. Intell. Mag.* 4 (4) (2009)22–26.
- [116] Kian B. Ng, A.P. Bradley, R. Cunnington, Stimulus specificity of a steady-state visual-evoked potential-based brain–computer interface, *J. Neural Eng.* 9 (3)(2012) 036008.
- [117] D. Regan, *Human Brain Electrophysiology: Evoked Potentials and Evoked Magnetic Fields in Science and Medicine*, Elsevier, New York, NY, 1989.
- [118] L.J. Trejo, R. Rosipal, B. Matthews, Brain–computer interfaces for 1-D and 2-D cursor control: designs using volitional control of the EEG spectrum or steady-state visual evoked potentials, *IEEE Trans. Neural Syst. Rehabil. Eng.* 14 (2)(2006) 225–229.
- [119] G. Pfurtscheller, C. Neuper, Motor imagery and direct brain–computer communication, *Proc. IEEE* 89 (7) (2001) 1123–1134.
- [120] G.tec, G.tec Medical Engineering, 2015, Available [_http://www.gtec.at/_](http://www.gtec.at/)[accessed Jan., 2015].
- [121] B. Graimann, B. Allison, G. Pfurtscheller, Brain–computer interfaces: a gentle introduction, in: *Brain–Computer Interfaces*, Springer, Springer Berlin Heidelberg, 2010, pp. 1–27, http://dx.doi.org/10.1007/978-3-642-02091-9_1
- [122] G.G. Molina, D. Zhu, Optimal spatial filtering for the steady state visual evoked potential: BCI application, in: *Fifth International IEEE/EMBS Conference on Neural Engineering (NER)*, 2011, pp. 156–160.
- [123] O. Friman, I. Volosyak, A. Graser, Multiple channel detection of steady-state visual evoked potentials for brain–computer interfaces, *IEEE Trans. Biomed. Eng.* 54 (4) (2007) 742–750.
- [124] P. Martinez, H. Bakardjian, A. Cichocki, Fully online multi command brain–computer interface with visual neurofeedback using SSVEP paradigm, *Comput. Intell. Neurosci.* (2007) 13–22, <http://dx.doi.org/10.1155/2007/94561>
- [125] C.M. Bishop, *Neural Networks for Pattern Recognition*, Clarendon Press, Oxford, New York, 1995.
- [126] M.H. Chang, K.S. Park, Frequency recognition methods for dual-frequency SSVEP based brain–computer interface, in: *Engineering in Medicine and Biology Society (EMBC), 35th Annual International Conference of the IEEE*, 2013, pp. 2220–2223.
- [127] S.S. Haykin, *Adaptive Filter Theory*, Pearson Education India, New Delhi, India, 2008.
- [128] P.D. Welch, The use of fast Fourier transform for the estimation of power spec-tra: a method based on time averaging over short, modified periodograms, *IEEE Trans. Audio Electroacoust.* AU-15 (June) (1967) 70–73.
- [129] S. Theodoridis, K. Koutroumbas, *Pattern Recognition*, Fourth ed., Academic Press, London, UK, 2008.
- [130] C.M. Bishop, et al., *Pattern Recognition and Machine Learning*, Springer, New York, NY, 2006.
- [131] A. Bamdadian, C. Guan, K.K. Ang, J. Xu, Improving session-to-session transfer performance of motor imagery-based BCI using adaptive extreme learning machine, in: *Engineering in Medicine and Biology Society. 35th Annual Inter-national Conference of the IEEE*, 2013, pp. 2188–2191.
- [132] L. Duan, H. Zhong, J. Miao, Z. Yang, W. Ma, X. Zhang, A voting optimized strategy based on ELM for improving classification of motor imagery BCI data, *Cogn. Comput.* 6 (3) (2014) 477–483.
- [133] N. Cristianini, J. Shawe-Taylor, *An Introduction to Support Vector Machines and Other Kernel-based Learning Methods*, Cambridge University Press, Cambridge, UK, 2000.

- [134] Suleyman Bilgin, The impact of feature extraction for the classification of amyotrophic lateral sclerosis among neurodegenerative diseases and healthy subjects, *Biomedical Signal Processing and Control* 31 (2017) 288–294.
- [135] M.C. Kiernan, S. Vucic, C.C. Benjamin, R.T. Martin, E. Andrew, H. Orla, R. B. James, C.Z. Margaret, Amyotrophic lateral sclerosis, *Lancet* 377 (2011)942–955.
- [136] G.A. Qureshi, S.H. Parvez, *Oxidative Stress and Neurodegenerative Disorders*, Elsevier Science, Amsterdam, 2007.
- [137] M.W. Whittle, Clinical gait analysis: a review, *Hum. Mov. Sci.* 15 (3) (1996)369–387.
- [138] J.D. Schaafsma, N. Giladi, Y. Balash, A.L. Bartels, T. Gurevich, J.M. Hausdorff, Gait dynamics in Parkinson’s disease: relationship to Parkinsonian features, falls and response to levodopa, *J. Neurol. Sci.* 212 (1) (2003) 47–53.
- [139] J.M. Hausdorff, S.L. Mitchell, R. Firtion, C.K. Peng, M.E. Cudkowicz, J.Y. Wei, A.L. Goldberger, Altered fractal dynamics of gait: reduced stride-interval correlations with aging and Huntington’s disease, *J. Appl. Physiol.* 82 (1)(1997) 262–269.
- [140] J.M. Hausdorff, A. Lertratanakul, M.E. Cudkowicz, A.L. Peterson, D. Kaliton, A.L. Goldberger, Dynamic markers of altered gait rhythm in amyotrophic lateral sclerosis, *J. Appl. Physiol.* 88 (6) (2000) 2045–2053.
- [141] J.M. Hausdorff, Gait dynamics, fractals and falls: finding meaning in the stride-to-stride fluctuations of human walking, *Hum. Mov. Sci.* 26 (4) (2007)555–589.
- [142] T. Chau, A review of analytical techniques for gait data part 1: fuzzy, statistical and fractal methods, *Gait Posture* 13 (1) (2001) 49–66.
- [143] T. Chau, A review of analytical techniques for gait data: part 2: neuralnetwork and wavelet methods, *Gait Posture* 13 (2) (2001) 102–120.
- [144] M. Sekine, T. Tamura, M. Akay, T. Fujimoto, T. Togawa, Y. Fukui, Discrimination of walking patterns using wavelet-based fractal analysis, *IEEETrans. Neural Syst. Rehabil. Eng.* 10 (3) (2002) 188–196.
- [145] Y. Xia, Q. Gao, Q. Ye, Classification of gait rhythm signals between patients with neurodegenerative diseases and normal subjects: experiments with statistical features and different classification models, *Biomed. Signal Process. Control* 18 (2015) 254–262.
- [146] G.B. Moody, R.G. Mark, A.L. Goldberger, Physionet: a web-based resource for the study of physiologic signals, *IEEE Eng. Med. Biol. Mag.* 20 (3) (2001) 70–75.
- [147] J.M. Hausdorff, Z. Ladin, J.Y. Wei, Footswitch system for measurement of the temporal parameters of gait, *J. Biomech.* 28 (3) (1995) 347–351.
- [148] H.A.R. Abdul, Z. Aladin, K.B. Rezaul, W. Yufridin, Foot plantar pressure measurement system: a review, *Sensors* 12 (7) (2012) 9884–9912.
- [149] S. Miyazaki, H. Iwakura, Foot-force measuring device for clinical assessment of pathological gait, *Med. Biol. Eng. Comput.* 16 (4) (1978) 429–436.
- [150] C.L. Vaughan, L.D. Brian, C.O. Jeremy, *Dynamics of Human Gait*, Human Kinetics Publishers, Illinois, 1992.
- [151] S. Miyazaki, T. Kubota, Quantification of gait abnormalities on the basis of continuous foot-force measurement: correlation between quantitative indices and visual rating, *Med. Biol. Eng. Comput.* 22 (1) (1984) 70–76.
- [152] A. Gabell, U.S.L. Nayak, The effect of age on variability in gait, *J. Gerontol.* 39(1984) 662–666.
- [153] R.A. Fisher, The use of multiple measurements in taxonomic problems, *Ann.Eugen.* 7 (1936) 179–188.
- [154] R.O. Duda, P.E. Hart, *Pattern Classification and Scene Analysis*, 3, Wiley, NewYork, 1973.
- [155] Fatin A. Elhaj, Naomie Salim, Arief R. Harris, Tan Tian Swee, Taqwa Ahmed, Arrhythmia recognition and classification using combined linear and nonlinear features of ECG signals, *Computer Methods and Programs in Biomedicine* 127 (2016) 52-63.
- [156] C. Mathers, A. Lopez, C. Stein, D. Fat, C. Rao, *Deaths and Disease Burden by Cause: Global Burden of Disease Estimates for 2001 by World Bank Country Groups, 2005(revised 2005)*.
- [157] A.L. Goldberger, *Clinical Electrocardiography: A Simplified Approach*, Elsevier Health Sciences, 2012.
- [158] M.M. Hadhoud, M.I. Eladawy, A. Farag, Computer aided diagnosis of cardiac arrhythmias, in: *The 2006 International Conference on Computer Engineering and Systems*, IEEE,2006, pp. 262–265.
- [159] A. Shiyovich, A. Wolak, L. Yacobovich, A. Grosbard, A. Katz, Accuracy of diagnosing atrial flutter and atrial fibrillation from a surface electrocardiogram by hospital physicians: analysis of data from internal medicine departments, *Am. J.Med. Sci.* 340 (4) (2010) 271–275.
- [160] J.-S. Wang, W.-C. Chiang, Y.-L. Hsu, Y.-T.C. Yang, ECG arrhythmia classification using a probabilistic neural network with a feature reduction method, *Neurocomputing*116 (2013) 38–45.

- [161] I. Jekova, G. Bortolan, I. Christov, Assessment and comparison of different methods for heartbeat classification, *Med. Eng. Phys.* 30 (2) (2008) 248–257.
- [162] C.-H. Lin, Frequency-domain features for ECG beat discrimination using grey relational analysis-based classifier, *Comput. Math. Appl.* 55 (4) (2008) 680–690.
- [163] M. Arif, Robust electrocardiogram (ECG) beat classification using discrete wavelet transform, *Physiol. Meas.* 29 (5) (2008)555.
- [164] B. Gramatikov, I. Georgiev, Wavelets as alternative to short-time Fourier transform in signal-averaged electrocardiography, *Med. Biol. Eng. Comput.* 33 (3) (1995)482–487.
- [165] C. Li, C. Zheng, C. Tai, Detection of ECG characteristic points using wavelet transforms, *Biomed. Eng. IEEE Trans.* 42 (1)(1995) 21–28.
- [166] Q.B. Zhao, L.Q. Zhang, ECG feature extraction and classification using wavelet transform and support vector machines, in: *Proceedings of the 2005 International Conference on Neural Networks and Brain*, vol. 1–3, 2005, pp.1089–1092.
- [167] R.J. Martis, U.R. Acharya, L.C. Min, ECG beat classification using PCA, LDA, ICA and discrete wavelet transform, *Biomed. Signal Process. Control* 8 (5) (2013) 437–448.
- [168] R.J. Martis, U.R. Acharya, H. Adeli, Current methods in electrocardiogram characterization, *Comput. Biol. Med.* 48(2014) 133–149.
- [169] S. Osowski, T.H. Linh, ECG beat recognition using fuzzy hybrid neural network, *Biomed. Eng. IEEE Trans.* 48 (11)(2001) 1265–1271.
- [170] R.J. Martis, U.R. Acharya, K. Mandana, A.K. Ray, C.Chakraborty, Application of principal component analysis to ECG signals for automated diagnosis of cardiac health, *Expert Syst. Appl.* 39 (14) (2012) 11792–11800.
- [171] G.B. Moody, R.G. Mark, The impact of the Mit-Bih arrhythmia database, *Eng. Med. Biol. Mag. IEEE* 20 (3) (2001) 45–50.
- [172] E.D. Übeyli, Combining recurrent neural networks with eigenvector methods for classification of ECG beats, *Digit. Signal Process.* 19 (2) (2009) 320–329.
- [173] B.N. Singh, A.K. Tiwari, Optimal selection of wavelet basis function applied to ECG signal denoising, *Digit. Signal Process.* 16 (3) (2006) 275–287.
- [174] J. Pan, W.J. Tompkins, A real-time QRS detection algorithm, *Biomed. Eng. IEEE Trans.* (3) (1985) 230–236.
- [175] H.-S. Park, S.-M. Woo, Y.-S. Kim, B.-J. Kang, S.-W. Ban, ECG pattern classification based on generic feature extraction, in: *Proceedings of the 3rd WSEAS International Conference on Circuits, Systems, Signal and Telecommunications(CISST'2009)*, 2009, pp. 21–25.
- [176] P.S. Addison, Wavelet transforms and the ECG: a review, *Physiol. Meas.* 26 (5) (2005) R155.
- [177] J. Kim, H.S. Shin, K. Shin, M. Lee, Robust algorithm for arrhythmia classification in ECG using extreme learning machine, *Biomed. Eng. Online* 8 (2009) 31.
- [178] K. Polat, S. Güneş, Detection of ECG arrhythmia using a differential expert system approach based on principal component analysis and least square support vector machine, *Appl. Math. Comput.* 186 (1) (2007) 898–906.
- [179] R.J. Martis, U.R. Acharya, C.M. Lim, K. Mandana, A.K. Ray, C. Chakraborty, Application of higher order cumulate features for cardiac health diagnosis using ECG signals, *Int. J. Neural Syst.* 23 (04) (2013).
- [180] C. Jutten, J. Herault, Blind separation of sources. Part I: an adaptive algorithm based on neuro-mimetic architecture, *Signal Process.* 24 (1) (1991) 1–10.
- [181] C.M. Bishop, *Neural Networks for Pattern Recognition*, 1995.
- [182] V. Vapnik, *The Nature of Statistical Learning Theory*, Springer, 2000.

4^ο Κεφάλαιο

- [183] Χαρίδημος Ε. Τζεδάκης, “Ανασκόπηση της Εφαρμογής των Μεθόδων Μηχανικής Μάθησης στη Βιοπληροφορική”, Ε.Μ.Π., 2014.
- [184] Rosenblatt F. “The perceptron: only A probabilistic model for information storage and organization in the brain,” *Psychological Review*, Vol. 65, pp. 386–408, 1958.
- [185] Minsky M. L., Papert S.A. *Perceptrons*, expanded edition, MIT Press, MA, 1988.
- [186] S. Haykin, “Neural Networks: A comprehensive foundation”, Second Edition, Prentice Hall, 1999.
- [187] Simon Haykin, *Neural Networks, A Comprehensive Foundation*, 2nd Edition, Prentice Hall International, 1999.

- [188] R.P. Lippman, "An Introduction to Computing with Neural Nets," *ASSP Magazine*, pp. 4-22, April 1987.
- [189] A.N. Kolmogorov, "On the Representation of Continuous Functions of Several Variables by Superpositions of Continuous Functions of one Variable and Addition," *American Mathematical Society Translations*, vol. 28, pp. 55-59, 1963.
- [190] D.A. Sprecher, "A Universal Mapping for Kolmogorov's Superposition Theorem," *Neural Networks*, vol. 6, no. 8, pp. 1089-1094, 1993.
- [191] B.A. Jain, B.R. Nag, "Artificial Neural Network Models for Pricing Initial Public Offerings," *Decision Science*, vol. 26, no. 3, pp. 283-302, 1995.
- [192] T. Masters, *Practical Neural Network Recipes in C++*, Academic Press, 1993.
- [193] Σαβάνης Α. Χρήστος, "Αναγνώριση βασικών κινήσεων του χεριού με χρήση Ηλεκτρομυογραφήματος", Διπλωματική Εργασία Τμήματος Ηλεκτρολόγων Μηχανικών και Τεχνολογίας Υπολογιστών, Πανεπιστήμιο Πατρών, 2013.
- [194] J. Zuranda, "Introduction to Artificial Neural Networks", West Publishing Company, 1992.
- [195] Ε. Δερματάς, "Αναγνώριση Προτύπων", Πανεπιστήμιο Πατρών.
- [196] A.K. Jain, J. Mao, K. Mohiuddin, "Artificial Neural Networks: A Tutorial," *Computer, Special Issue on Neural Computing*, vol. 29, no. 3, pp. 31-44, 1996.
- [197] S. Walczak, N. Cepura, "Heuristic Principle for the Design of Artificial Neural Networks," *Information and Software Technology*, vol. 41, no. 2, pp. 109-119, 1999
- [198] P.J. Werbos, *Beyond Regression: New tools for prediction and analysis in the Behavioral Sciences*. Ph.D. thesis, Harvard University, 1974.
- [199] D.B. Parker, *Learning-Logic*, Technical Report TR-47, MIT, 1985.
- [200] D.E. Rumelhart, G.E. Hinton, R.J. Williams, *Learning Internal Representations by Error Propagation*, *Parallel distributed processing: explorations in the microstructure of cognition*, vol. 1: foundations, MIT Press, Cambridge, MA, 1986
- [201] D.E. Rumelhart, G.E. Hinton, R.J. Williams, "Learning Internal Representations by Error Propagation," In D.E. Rumelhart, J.L. McClelland, editors, *Parallel Distributed Processing*, vol. I, ch. 8, MIT Press, Cambridge, 1986.
- [202] G.M. Georgiou, C. Koutsougeras, *Embedding Domain Information in Backpropagation*, In *Proceedings of SPIE Conference on Adaptive and Learning Systems*, Orlando, Fla. Society of Photo-Optical Instrumentation Engineers, Bellingham, WA, 1992.
- [203] S.G. Smyth, *Designing Multi Layer Perceptrons from Nearest Neighbor Systems*, *IEEE Transactions on Neural Networks*, vol. 3, no. 2, pp. 329-333, 1992.
- [204] R. Rojas, *Optimal Weight Initialization for Neural Networks*, In *Proceedings of the International Conference on Artificial Neural Networks (ICANN'94)*, pp. 577-580, Springer Verlag, London, 1994.
- [205] S. Haykin, *Neural Networks: A Comprehensive Foundation*, Prentice-Hall, 1999.
- [206] S.M. Weiss, C.A. Kulikowski, *Computer Systems that Learn*, Morgan Kaufmann, 1991.
- [207] M. Stone, *Cross-validation Choice and Assessment of Statistical Predictions*, *Journal of Royal Statistical Society*, vol. B32, pp. 111-133, 1974.
- [208] R. Silipo, M. Gori, A. Taddei, M. Varanini, C. Marchesi, "Classification of Arrhythmic Events in Ambulatory Electrocardiogram, Using Artificial Neural Networks," *Computers and Biomedical Research*, vol. 28, no. 4, pp. 305-318, August 1995.
- [209] R. Silipo, C. Marchesi, "Artificial Neural Network for Automatic ECG Analysis," *IEEE Transaction on Signal Processing*, vol. 46, no. 5, pp. 1417-1425, 1998.
- [210] G. Bortolan, R. Degani, J.L. Willems, "Neural Networks for ECG Classification," *Proceedings of Computers in Cardiology*, pp. 269-272, 23-26 September 1990.
- [211] Z. Dokur, T. Ölmez, "ECG Beat Classification by a Novel Hybrid Neural Network," *Computer Methods and Programs in Biomedicine*, vol. 66, pp. 167-181, 2001.
- [212] D. Hoyer, R. Bauer, K. Conrad, M. Galicki, A. Döring, H. Hoyer, B. Walter, H. Witte, U. Zwiener, "Specific Monitoring of Neonatal Brain Function with Optimized Frequency Bands," *IEEE Engineering in Medicine and Biology*, vol. 20, no. 5, pp. 40-46, 2001.
- [213] H. Ramoser, J. Muller-Gerking, G. Pfurtscheller, "Optimal Spatial Filtering of Single Trial EEG During Imagined Hand Movement," *IEEE Transactions on Rehabilitation Engineering*, vol. 8, no. 4, pp. 441-446, Dec. 2000.
- [214] E. Haselsteiner, G. Pfurtscheller, "Using Time-dependent Neural Networks for EEG Classification," *IEEE Transactions on Rehabilitation Engineering*, vol. 8, no. 4, pp. 457-463, Dec. 2000.
- [215] C. Pattichis, N. Schizas, L. Middleton, "Neural Network Models in EMG Diagnosis," *IEEE Transactions on Biomedical Engineering*, vol. 42, no. 5, pp. 486-496, 1995.

- [216] D.E. Maroulis, D.K. Iakovidis, S.A. Karkanis, D.A. Karras, "CoLD: A Versatile Detection System for Colorectal Lesions in Endoscopy Video-frames," *Computer Methods and Programs in Biomedicine*, vol. 70, no. 2, pp. 151-166, February 2003.
- [217] H. Handels, Th. Roß, J. Kreuzsch, H.H. Wolff, S.J. Pöpl, "Feature Selection for Optimized Skin Tumor Recognition using Genetic Algorithm," *Artificial Intelligence in Medicine*, vol. 16, pp. 283-297, 1999.
- [218] L. Zhang, R. Sankar, W. Qian, "Advances in Micro-calcification Clusters Detection in Mammography," *Computers in Biology and Medicine*, vol. 32, no. 6, pp. 515-528, November 2002.
- [219] B. Verma, J. Zakos, "A Computer-Aided Diagnosis System for Digital Mammograms based on Fuzzy-neural and Feature Extraction Techniques," *IEEE Transactions on Information Technology in Biomedicine*, vol. 5, no. 1, pp. 46-54, March 2001.
- [220] D. Buller, A. Buller, P.R. Innocent, W. Pawlak, "Determining and Classifying the Region of Interest in Ultrasonic Images of the Breast using Neural Networks," *Artificial Intelligence in Medicine*, vol. 8, no. 1, pp. 53-66, February 1996.
- [221] L.W. Man, L. Wai, S.L. Kwong, S.N. Po, C.Y. Jack, "Discovering Knowledge from Medical Databases using Evolutionary Algorithms," *IEEE Engineering in Medicine and Biology Society Magazine*, vol. 19, no. 4, pp. 45-55, July 2000.
- [222] J.M. Cho, "Chromosome Classification using Backpropagation Neural Networks," *IEEE Engineering in Medicine and Biology Magazine*, vol. 19, no. 1, pp. 28-33, Jan/Feb 2000.
- [223] C. Peterson, M. Ringnér, "Analyzing Tumor Gene Expression Profiles," *Artificial Intelligence in Medicine*, vol. 28, no. 1, pp. 59-74, 2003.
- [224] S. Thirumuruganathan, "A Detailed Introduction to K-Nearest Neighbor (KNN) Algorithm", 2010.
- [225] Padraig Cunningham, Sarah Jane Delany, *k-Nearest Neighbour Classifiers*, Technical Report UCD-CSI-2007-4, March 27, 2007.
- [226] Δημήτριος Κουτσούρης, Κωνσταντίνα Νικήτα, Εργαστηριακές Ασκήσεις για το Μάθημα «Εργαστήριο Βιοϊατρικής Τεχνολογίας», Εθνικό Μετσόβιο Πολυτεχνείο, 2013.
- [227] Claudio Gallicchio, Alessio Micheli, *Architectural and Markovian factors of echo state networks*, Neural Networks 24 (2011) 440-456, Elsevier.
- [228] Shigeo Abe, *Support Vector Machines for Pattern Classification*, 2nd edition, Springer, 2010.
- [229] Αγγελική Τσιάρα, "Ταξινόμηση εικόνων με τυχαία δάση", Μεταπτυχιακή διπλωματική εργασία, Τμήμα Πληροφορικής του Πανεπιστημίου Ιωαννίνων, 2012
- [230] Μαρία Ε. Δημητροπούλου "Αναγνώριση Ενεργοποιημένων Περιοχών του Εγκεφάλου με Χρήση Ασαφούς Αλγόριθμου C-Μέσων", Διπλωματική εργασία, Ε.Μ.Π, 2016.
- [231] Zigkolis, C.N. and N.A. Laskaris, Using conditional FCM to mine event-related brain dynamics. *Comput Biol Med*, 2009. 39(4): p. 346-54.
- [232] H., I., Clustering Spatiotemporal Data: An Augmented Fuzzy C-Means. *IEEE Transactions on Fuzzy Systems*, 2013. 21(5): p. 855-68.
- [233] I., Δ., Μελέτη της Επίπτωσης της Διασποράς των Συναρτήσεων Βάσης στο Σχεδιασμό Νευρωνικών Δικτύων Συναρτήσεων Ακτινικής Βάσης, in Τμήμα Πολιτισμικής Τεχνολογίας και Επικοινωνίας. 2010, Πανεπιστήμιο Αιγαίου.

5^ο Κεφάλαιο

- [234] S. B. Kotsiantis, I. D. Zaharakis, P.E Pintelas, *Machine learning: a review of classification and combining techniques*, *Artif Intell Rev* (2006) 26:159-190.
- [235] Stuart Russel, Peter Norvig, *Τεχνητή Νοημοσύνη Μια σύγχρονη προσέγγιση*, 2^η Αμερικανική έκδοση, εκδόσεις Κλειδάριθμος, 2005.
- [236] H. Kelly, A. Bull, P. Russo, E. S. McBryde, *Estimating sensitivity and specificity from positive predictive value, negative predictive value and prevalence: application to surveillance systems for hospital-acquired infections*, *Journal of Hospital Infection* (2008) 69, 164-168.
- [237] Martin Bland, *An Introduction to Medical Statistics*, 3rd edition, OUP Oxford, 2000.
- [238] Σύνδεσμος: <https://onlinecourses.science.psu.edu/stat507/node/71>, Ηλεκτρονικές Σημειώσεις Μαθήματος "Epidemiological Research Methods", Department of Statistics, Pennsylvania State University.
- [239] E. Frank, I.H. Witten, *Data Mining: Practical Machine Learning Tools and Techniques*, Morgan Kaufmann, San Francisco, 2005. 0-12-088407-0.
- [240] M. Uyar, S. Yildirim, M.T. Gencoglu, A pattern recognition approach for classification of power quality disturbance types, *J. Faculty Eng. Archit. Gazi Univ.* 26 (2011) 141-156.

- [241] M. Uyar, ST and LSSVR-based the fault location algorithm for the series compensated power transmission lines, *Energy Educ. Sci. Technol. Part A: Energy Sci. Res.* 30 (1) (2012) 75–88.
- [242] T. Fathima, M. Bedeuzzaman, O. Farooq, Y.U. Khan, Wavelet based features for epileptic seizure detection, *MES J. Technol. Manage.* (2011) 108–112.
- [243] Bajaj V, Pachori RB. Classification of seizure and nonseizure EEG signals using empirical mode decomposition. *IEEE Trans Inf Technol Biomed* 2012;16(6):1135–41.
- [244] C. Donos, M. Duempelmann, A. Schulze-Bonhage, Early seizure detection algorithm based on intracranial EEG and random forest classification, *Int. J. Neural Syst.* 25 (5) (2015) 1550023.
- [245] B. Allison, et al., BCI demographics: How many (and what kinds of) people can use an SSVEP BCI? *IEEE Trans. Neural Syst. Rehabil. Eng.* 18 (2) (2010)107–116.
- [246] B.Z. Allison, C. e Neuper, Could Anyone Use a BCI?, *Brain–computer Interfaces*, Springer, London, 2010, pp. 35–54.
- [247] Y. Wang, X. Gao, B. Hong, C. Jia, S. Gao, Brain–computer interfaces based on visual evoked potentials, *IEEE Eng. Med. Biol. Mag.* 27 (5) (2008) 64–71.
- [248] Y. Xia, G. Qingwei, L. Yixiang, A novel approach for analysis of altered gait variability in amyotrophic lateral sclerosis, *Med. Biol. Eng. Comput.* (2015)1–10, <http://dx.doi.org/10.1007/s11517-015-1413-5>.
- [249] W. Zeng, W. Cong, Classification of Neurodegenerative diseases using gait dynamics via deterministic learning, *Inf. Sci.* 317 (2015) 246–258