



Εθνικό Μετσόβιο Πολυτεχνείο
Σχολή Ηλεκτρολόγων Μηχανικών
και Μηχανικών Υπολογιστών
Τομέας Τεχνολογίας Πληροφορικής και Υπολογιστών

**Αναγνώριση Συναισθήματος από Σήματα
Ηλεκτροεγκεφαλογραφήματος με Χρήση Ευφύων Τεχνικών**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

του

ΒΑΣΙΛΕΙΟΥ ΣΕΡΕΝΤΕΛΛΟΥ

Επιβλέπων: Ανδρέας – Γεώργιος Σταφυλοπάτης

Καθηγητής Ε.Μ.Π.

Αθήνα, Δεκέμβριος 2017



Εθνικό Μετσόβιο Πολυτεχνείο
Σχολή Ηλεκτρολόγων Μηχανικών
και Μηχανικών Υπολογιστών
Τομέας Τεχνολογίας Πληροφορικής και Υπολογιστών

**Αναγνώριση Συναισθήματος από Σήματα
Ηλεκτροεγκεφαλογραφήματος με Χρήση Ευφύων Τεχνικών**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

του

ΒΑΣΙΛΕΙΟΥ ΣΕΡΕΝΤΕΛΛΟΥ

Επιβλέπων: Ανδρέας – Γεώργιος Σταφυλοπάτης

Καθηγητής Ε.Μ.Π.

Εγκρίθηκε από την τριμελή επιτροπή την

.....		
Ανδρέας-Γεώργιος Σταφυλοπάτης	Παναγιώτης Τσανάκας	Γεώργιος Στάμου
Καθηγητής Ε.Μ.Π.	Καθηγητής Ε.Μ.Π	Αναπληρωτής Καθηγητής Ε.Μ.Π

Αθήνα, Δεκέμβριος 2017

.....

Σερεντέλλος Βασίλειος

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

Copyright © Βασίλειος Σερεντέλλος, 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.

Περίληψη

Σκοπός της παρούσας διπλωματικής εργασίας είναι η διερεύνηση της ποιότητας διαφόρων προσεγγίσεων για την ανίχνευση συναισθήματος μέσω της επεξεργασίας σημάτων ηλεκτροεγκεφαλογράφηματος (ΗΕΓ) και της χρήσης τεχνικών μηχανικής μάθησης. Τα τελευταία χρόνια η κατηγοριοποίηση συναισθημάτων από δεδομένα ΗΕΓ λαμβάνει όλο και μεγαλύτερη προσοχή με τη ραγδαία ανάπτυξη των μη παρεμβατικών συστημάτων καταγραφής βιοσημάτων του ανθρώπινου εγκεφάλου, που καθιστούν αυτήν τη διαδικασία ευκολότερη και πιο αξιόπιστη. Το γεγονός ότι τα σήματα αυτά πηγάζουν από ακούσιες εγκεφαλικές λειτουργίες, και άρα δεν μπορούν να χειραγωγηθούν, καθιστά την πληροφορία που μπορεί να ληφθεί από αυτά ιδιαίτερα σημαντική για την κατανόηση των διαφόρων ανθρώπινων συναισθηματικών καταστάσεων και της σχέσης τους με συγκεκριμένες φυσιολογικές λειτουργίες, καθώς και για τη δημιουργία ενός συστήματος αναγνώρισης συναισθήματος υψηλής ακρίβειας. Στα πλαίσια της παρούσας εργασίας αρχικά παρουσιάζονται οι απαραίτητες έννοιες για την κατανόηση του αντικειμένου της αναγνώρισης συναισθήματος από σήματα ΗΕΓ, ενώ ακολούθως γίνεται εκτενής αναφορά στη λειτουργία και τα αποτελέσματα διαφόρων συστημάτων μηχανικής μάθησης που κατασκευάστηκαν και ελέγχθηκαν πάνω σε ένα πειραματικό σύνολο δεδομένων.

Πιο συγκεκριμένα, τα συστήματα, που αναπτύχθηκαν, δημιουργήθηκαν σε 3 φάσεις. Στην πρώτη, εξήχθησαν διάφορα είδη χαρακτηριστικών από τα σήματα του συνόλου δεδομένων, προκειμένου να δημιουργηθεί ο πίνακας χαρακτηριστικών πάνω στον οποίο θα γινόταν η τελική κατηγοριοποίηση. Στη δεύτερη φάση, εφαρμόστηκαν 4 τεχνικές επιλογής χαρακτηριστικών λόγω του μεγάλου όγκου των εξαχθέντων χαρακτηριστικών. Πιο αναλυτικά, οι μέθοδοι που χρησιμοποιήθηκαν ήταν οι ReliefF, Cohen's f^2 , minimum-Redundancy-Maximum-Relevance (mRMR) και Infinite Feature Selection (Inf-FS), των οποίων η λειτουργικότητα εξηγείται πλήρως στα πλαίσια της εργασίας αυτής. Στη τελευταία φάση, τα χαρακτηριστικά που είχαν επιλεγεί από τις προηγούμενες μεθόδους δόθηκαν σε 5 κατηγοριοποιητές (Quadratic Discriminant Analysis - QDA, K-Nearest Neighbors - KNN, Random Forest, Support Vector Machine - SVM, Deep Belief Network - DBN), προκειμένου να προκύψουν τα τελικά αποτελέσματα των συστημάτων αυτών.

Τέλος, γίνεται σύγκριση και αξιολόγηση των αποτελεσμάτων των διαφόρων συστημάτων που προέκυψαν από το συνδυασμό των μεθόδων επιλογής και κατηγοριοποίησης, ενώ δίνονται και μελλοντικές κατευθύνσεις.

Λέξεις Κλειδιά: Αναγνώριση συναισθήματος, Συναισθηματική Υπολογιστική, Αλληλεπίδραση Ανθρώπου – Μηχανής, Ηλεκτροεγκεφαλογράφημα - ΗΕΓ, Μηχανική Μάθηση, Εξαγωγή Χαρακτηριστικών, Επιλογή Χαρακτηριστικών, Κατηγοριοποίηση

Abstract

The purpose of this diploma thesis is the examination of the quality of various approaches towards emotion recognition through the processing of electroencephalogram (EEG) signals and the usage of machine learning techniques. In recent years, emotion classification from EEG data is attracting growing attention due to the rapid development of non-invasive recording systems of the biosignals of the human brain, which render that procedure easier and more reliable. The fact that these signals derive from unintentional brain function, thus it is impossible to be manipulated, renders their extracted information highly important for understanding various human emotional states and their relationship with discrete physiologic functionalities, as well as the construction of a highly accurate emotion recognition system. In the premises of the present diploma thesis the necessary concepts for understanding the subject of EEG-based emotion recognition are initially introduced, while subsequently the functionality and the results of the various machine learning systems, having been constructed and tested on an experimental dataset, are thoroughly presented.

In particular, the developed systems were constructed in 3 phases. In the first of them, multiple types of features were extracted from the signals of the dataset in order for the feature array, on which the final classification was going to be based, to be constructed. In the second phase, due to the huge volume of the extracted features 4 Feature Selection methods were implemented. More analytically, the methods used were ReliefF, Cohen's f^2 , minimum-Redundancy-Maximum-Relevance (mRMR) and Infinite Feature Selection (Inf-FS), the functionality of which is wholly explained in the present work. In the last phase the selected features from the methods mentioned above were given as input to 5 classifiers (Quadratic Discriminant Analysis - QDA, K-Nearest Neighbors - KNN, Random Forest, Support Vector Machine - SVM, Deep Belief Network - DBN), in order for the final results to be produced.

Finally, the results from the various systems, which were developed from the combination of the feature selection and classification techniques, are compared and evaluated, while future research directions are also given.

Key Words: Emotion recognition, Affective Computing, Human-Computer Interaction, Electroencephalogram - EEG, Machine Learning, Feature Extraction, Feature Selection, Classification

Ευχαριστίες

Αρχικά, θα ήθελα να ευχαριστήσω τον κ. Ανδρέα-Γεώργιο Σταφυλοπάτη, Καθηγητή Ε.Μ.Π., από τον οποίο μου δόθηκε η ευκαιρία να εκπονήσω την παρούσα διπλωματική εργασία και να ασχοληθώ με ένα άκρως ενδιαφέρον για εμένα αντικείμενο.

Ακολούθως, θα ήθελα να ευχαριστήσω τους κ. Παναγιώτη Τσανάκα, Καθηγητή Ε.Μ.Π. και Γεώργιο Στάμου, Αναπληρωτή Καθηγητή Ε.Μ.Π., για την τιμή που μου έκαναν όντας μέλη της επιτροπής εξέτασης της διπλωματικής μου εργασίας.

Ιδιαίτερα θερμές ευχαριστίες θα ήθελα να αποδώσω και στον κ. Γεώργιο Σιόλα, Ερευνητή στο Εργαστήριο Ευφών Συστημάτων, με τον οποίο συνεργαστήκαμε άψογα σε όλα τα στάδια εκπόνησης της διπλωματικής μου εργασίας. Η βοήθεια που μου παρείχε όλο αυτό το διάστημα ήταν καθοριστική για την επιτυχή ολοκλήρωση της εργασίας αυτής, γι' αυτό και τον ευχαριστώ θερμότατα.

Τέλος, θα ήθελα να εκφράσω την ευγνωμοσύνη μου τόσο στην οικογένεια μου, η οποία με στήριζε αδιαλείπτως από την αρχή της φοίτησής μου στη σχολή όντας δίπλα μου σε όλες τις δυσκολίες που αντιμετώπισα αυτά τα χρόνια, όσο και στους φίλους μου, εκ των οποίων αρκετοί και συμφοιτητές μου, οι οποίοι ήταν συνεχώς δίπλα μου σε όλη αυτήν την πορεία.

Βασίλειος Σερεντέλλος,

Αθήνα, 19η Δεκεμβρίου 2017

Περιεχόμενα

Περίληψη.....	5
Abstract	7
Ευχαριστίες.....	9
Κατάλογος Πινάκων.....	13
Κατάλογος Σχημάτων.....	14
Κεφάλαιο 1 – Εισαγωγή.....	15
1.1 Το Ανθρώπινο Συναισθήμα.....	15
1.2 Η Αναγνώριση Συναισθήματος σε Ανθρωποκεντρικό Επίπεδο.....	17
1.3 Η Αναγνώριση Συναισθήματος στη σχέση Ανθρώπου – Μηχανής.....	18
1.4 Αναγνώριση Συναισθήματος και Σήματα EEG.....	19
1.5 Σκοπός της Διπλωματικής.....	21
1.6 Παρουσίαση των Κεφαλαίων.....	22
Κεφάλαιο 2 – Αναγνώριση Συναισθήματος Βασισμένη σε Σήματα EEG	23
2.1 Η Ηλεκτροεγκεφαλογραφία	23
2.1.1 Γενικά.....	23
2.1.2 Πλεονεκτήματα και μειονεκτήματα της μεθόδου	24
2.1.3 Οι τεχνικές πίσω από την Ηλεκτροεγκεφαλογραφία.....	26
2.1.4 Οι ζώνες συχνοτήτων των σημάτων EEG.....	30
2.1.5 Τέχνεργα και μέθοδοι αφαίρεσής των.....	32
2.2 Η Χρήση EEG Σημάτων στην Ανάλυση Συναισθήματος.....	33
Κεφάλαιο 3 – Στάδια της διαδικασίας Ανίχνευσης Συναισθήματος.....	35
3.1 Εξαγωγή Χαρακτηριστικών	35
3.1.1 Χαρακτηριστικά στο Πεδίο του Χρόνου.....	36
3.1.2 Χαρακτηριστικά στο Πεδίο της Συχνότητας.....	39
3.1.3 Χαρακτηριστικά στο Πεδίο του Χρόνου και της Συχνότητας.....	41
3.1.4 Χαρακτηριστικά από το Συνδυασμό Ηλεκτροδίων.....	43
3.2 Επιλογή Χαρακτηριστικών.....	44
3.2.1 ReliefF	45
3.2.2 Min-Redundancy-Max-Relevance (mRMR).....	46
3.2.3 Cohen’s Effect Size f^2	47
3.2.4 Infinite Feature Selection	47
3.3 Κατηγοριοποίηση	49
3.3.1 Κατηγοριοποιητής Quadratic Discriminant Analysis (QDA)	50

3.3.2 Κατηγοριοποιητής K-Nearest Neighbors (KNN).....	51
3.3.3 Κατηγοριοποιητής Random Forest.....	52
3.3.4 Κατηγοριοποιητής Support Vector Machine (SVM)	53
3.3.5 Deep Belief Networks (DBN)	55
Κεφάλαιο 4 – Πειραματική Διαδικασία και Αποτελέσματα	59
4.1 Η συλλογή των δεδομένων	59
4.2 Η Πειραματική Διαδικασία	60
4.3 Οι Μετρικές Αξιολόγησης.....	65
4.4 Τα Αποτελέσματα.....	67
4.4.1 Συγκριτικά Αποτελέσματα μεταξύ Κατηγοριοποιητών	67
4.4.2 Συγκριτικά Αποτελέσματα μεταξύ Χαρακτηριστικών	74
Κεφάλαιο 5 – Συμπεράσματα και Μελλοντικές Επεκτάσεις	77
5.1 Συμπεράσματα.....	77
5.2 Μελλοντικές Επεκτάσεις.....	79
Βιβλιογραφία.....	82

Κατάλογος Πινάκων

Πίνακας 1: Σημασιολογία στο International 10-20 Placement System	28
Πίνακας 2: Σημασιολογία στο International 10-20 Placement System με MCN	29
Πίνακας 3: Στατιστικά μεγέθη του EEG σήματος	37
Πίνακας 4: Χαρακτηριστικά Hjorth.....	37
Πίνακας 5: Οι συνδυασμοί των ζωνών συχνοτήτων για τα μεγέθη Bispectrum και Bicoherence.....	41
Πίνακας 6: Η αντιστοίχιση των ζωνών συχνοτήτων και των επιπέδων αποσύνθεσης των EEG σημάτων	43
Πίνακας 7: Δομή confusion matrix.....	66
Πίνακας 8: Μετρικές αξιολόγησης αποτελεσμάτων.....	67
Πίνακας 9: Βέλτιστοι Υπερπαράμετροι SVM ανά μέθοδο επιλογής	74
Πίνακας 10: Βέλτιστοι παράμετροι Inf-FS μεθόδου ανά κατηγοριοποιητή.....	74

Κατάλογος Σχημάτων

Σχήμα 1: Ο τροχός των συναισθημάτων του Plutchik.....	15
Σχήμα 2: Τα στάδια επεξεργασίας σήματος στο πεδίο του Affective Computing	16
Σχήμα 3: Το δισδιάστατο μοντέλο συναισθημάτων	20
Σχήμα 4: Τα βασικά στάδια του Emotion Recognition από Εγκεφαλικά Σήματα	21
Σχήμα 5: Ασαφής απεικόνιση EEG σημάτων.....	23
Σχήμα 6: Απλουστευτικό Μοντέλο Καταγραφής σημάτων EEG.....	26
Σχήμα 7: Η κάτοψη της θέσης των ηλεκτροδίων με βάση το Διεθνές Σύστημα Τοποθέτησης 10-20 (International 10-20 Placement System).....	28
Σχήμα 8: Η κάτοψη της θέσης των ηλεκτροδίων με βάση το Διεθνές Σύστημα Τοποθέτησης 10-20 (International 10-20 Placement System) με Τροποποιημένη Συνδυαστική Ονοματολογία	29
Σχήμα 9: Τα εύρη συχνότητων στα EEG σήματα	31
Σχήμα 10: Παράδειγμα κατηγοριοποίησης KNN τριών κλάσεων	51
Σχήμα 11: Απλοποιημένο μοντέλο της μεθόδου Random Forest.....	53
Σχήμα 12: Απλοποιημένο μοντέλο της αντιστοίχισης των χώρων των χαρακτηριστικών στο SVM.....	54
Σχήμα 13: Απλοποιημένο μοντέλο Restricted Boltzmann Machine	55
Σχήμα 14: Απλοποιημένο μοντέλο Deep Belief Network.....	56
Σχήμα 15: Απλοποιημένο μοντέλο ενός unrolled Deep Belief Network.....	58
Σχήμα 16: Το πρωτόκολλο του πειράματος για τη δημιουργία του συνόλου δεδομένων	60
Σχήμα 17: Κατανομή Εξαχθέντων Χαρακτηριστικών.....	62
Σχήμα 18: Accuracy κάθε κατηγοριοποιητή ανά μέθοδο Επιλογής.....	68
Σχήμα 19: Error Rate κάθε κατηγοριοποιητή ανά μέθοδο Επιλογής	68
Σχήμα 20: Macro f1-score κάθε κατηγοριοποιητή ανά μέθοδο Επιλογής.....	69
Σχήμα 21: Macro Recall κάθε κατηγοριοποιητή ανά μέθοδο Επιλογής.....	69
Σχήμα 22: Macro Precision κάθε κατηγοριοποιητή ανά μέθοδο Επιλογής.....	70
Σχήμα 23: Micro f1-score κάθε κατηγοριοποιητή ανά μέθοδο Επιλογής	70
Σχήμα 24: Micro Recall κάθε κατηγοριοποιητή ανά μέθοδο Επιλογής	71
Σχήμα 25: Micro Precision κάθε κατηγοριοποιητή ανά μέθοδο Επιλογής.....	71
Σχήμα 26: Πλήθος χαρακτηριστικών ανά βέλτιστο μοντέλο	72
Σχήμα 27: Πλήθος γειτόνων της ReliefF μεθόδου ανά κατηγοριοποιητή.....	72
Σχήμα 28: Πλήθος δέντρων του κατηγοριοποιητή Random Forest ανά μέθοδο Επιλογής.....	73
Σχήμα 29: Πλήθος γειτόνων του κατηγοριοποιητή KNN ανά μέθοδο Επιλογής.....	73
Σχήμα 30: Πλήθος νευρώνων του δικτύου Deep Belief ανά μέθοδο Επιλογής	74
Σχήμα 31: Κατανομή των χαρακτηριστικών των βέλτιστων μεθόδων Επιλογής για πλήθος ίσο με 823	75
Σχήμα 32: Κατανομή χαρακτηριστικών των βέλτιστων μεθόδων Επιλογής για πλήθος ίσο με 1646	76

Κεφάλαιο 1 – Εισαγωγή

1.1 Το Ανθρώπινο Συναίσθημα

Το συναίσθημα θεωρείται θεμελιώδες στοιχείο των ανθρωπίνων εμπειριών, καθώς επηρεάζει την ανθρώπινη νόηση και αντίληψη, αλλά και εργασίες καθημερινού τύπου που συνδέονται με την επικοινωνία και τη μάθηση. Ως συναίσθημα τυπικά ορίζεται κάθε ενσυνείδητη εμπειρία η οποία χαρακτηρίζεται από έντονη πνευματική δραστηριότητα και υψηλό βαθμό είτε ευχαρίστησης είτε δυσαρέσκειας, χωρίς βέβαια ο ορισμός αυτός να είναι δεσμευτικός καθώς υπάρχουν αρκετές διαμάχες ακόμη και σε επιστημονικό επίπεδο σχετικά με την εύρεση ενός κοινά αποδεκτού ορισμού της έννοιας αυτής. Συχνά το συναίσθημα μπερδεύεται με άλλες έννοιες, όπως η διάθεση, η ιδιοσυγκρασία, η προσωπικότητα και η κινητοποίηση, οι οποίες αρκετές φορές χρησιμοποιούνται στην περιγραφή καταστάσεων συνδεόμενων με την εμφάνιση συναισθήματος με αποτέλεσμα να συγχέονται με την πολύπλευρη αυτή έννοια.


Όπως φαίνεται και από τα παραπάνω σε επιστημονικό επίπεδο υπήρχαν και υπάρχουν αρκετές συζητήσεις και διαφωνίες στο πεδίο της έρευνας του ανθρώπινου συναισθήματος, οι οποίες επικεντρώνονται κυρίως στο αν το συναίσθημα συνδέεται με τη γνωστική λειτουργία και τη νόηση ή προηγείται των λειτουργιών αυτών. Έτσι, εύκολα γίνεται κατανοητό πως τα συναισθήματα είναι περίπλοκα και πως το εγχείρημα να αποκωδικοποιηθούν και να αναλυθούν είναι ιδιαίτερα δύσκολο, αλλά ταυτόχρονα και εξόχως ενδιαφέρον, με αποτέλεσμα να έχει απασχολήσει πληθώρα ερευνητών από διάφορα επιστημονικά πεδία. Ιδιαίτερα τις τελευταίες δύο δεκαετίες οι σχετιζόμενες με το συναίσθημα έρευνες έχουν αυξηθεί σημαντικά από επιστήμονες προερχόμενους από μία ευρεία γκάμα επιστημονικών πεδίων, όπως η Ψυχολογία, η Κοινωνιολογία αλλά και από πιο θετικά επιστημονικά πεδία όπως η Νευροεπιστήμη, η Φαρμακευτική και η Επιστήμη των Υπολογιστών [1].



Σχήμα 1: Ο τροχός των συναισθημάτων του Plutchik

Η φυσιολογία των συναισθημάτων είναι άμεσα σχετιζόμενη με τη διέγερση του ανθρώπινου νευρικού συστήματος με διακριτές καταστάσεις διέγερσης να αντιστοιχούν σε διαφορετικά συναισθήματα. Αυτά τα διαφορετικά συναισθήματα, βέβαια, δεν είναι τόσο εύκολο να κατηγοριοποιηθούν με τυπικό τρόπο. Πιο συγκεκριμένα, η κατηγοριοποίηση των συναισθημάτων έχει ερευνηθεί κυρίως από δύο θεμελιώδεις οπτικές γωνίες. Σύμφωνα με τους υποστηρικτές της πρώτης σκοπιάς τα συναισθήματα αποτελούν διακριτές και θεμελιωδώς διαφορετικές μεταξύ τους δομές, ενώ από την άλλη οπτική τα συναισθήματα μπορούν να χαρακτηριστούν σε κατηγορίες πάνω σε μία διαστατή βάση.

Ένας από τους κύριους υποστηρικτές της πρώτης σκοπιάς είναι ο Αμερικανός ψυχολόγος Paul Ekman, ο οποίος θεωρείται πρωτοπόρος στην έρευνα των συναισθημάτων και της σχέσης τους με τις εκφράσεις του προσώπου και κατά τον οποίο τα συναισθήματα είναι διακριτά, μετρήσιμα και φυσιολογικά διαχωρίσιμα. Σύμφωνα με την έρευνα του κάποια συγκεκριμένα συναισθήματα εμφανίζονται να είναι ευρέως αναγνωρίσιμα, ενώ παράλληλα ο ίδιος αναγνώρισε ως βασικά συναισθήματα το θυμό, την απέχθεια, το φόβο, τη χαρά, τη λύπη και την έκπληξη. Πιο κοντά στη δεύτερη από τις απόψεις που παρουσιάζονται στην προηγούμενη παράγραφο ήταν ο Robert Plutchik, επίτιμος καθηγητής στο Albert Einstein College of Medicine και σπουδαίος ερευνητής στο χώρο του συναισθήματος, ο οποίος συμφώνησε αρχικά στην βιολογικά βασισμένη οπτική που παρουσίασε ο Paul Ekman, αλλά παράλληλα ανέπτυξε τον τροχό των συναισθημάτων (wheel of emotions), που παρουσιάζεται στο σχήμα 1.1 και σύμφωνα με τον οποίο υπάρχουν 8 πρωτεύοντα συναισθήματα ομαδοποιημένα στη σχέση θετικού-αρνητικού (χαρά - λύπη, θυμός - φόβος, εμπιστοσύνη - απέχθεια και έκπληξη - προσμονή). Όπως φαίνεται και από τον τροχό των συναισθημάτων ο Plutchik υποστήριξε ότι υπάρχουν κάποια κυρίαρχα συναισθήματα από των συνδυασμό των οποίων μπορεί να προκύψει το πλήρες φάσμα των ανθρώπινων συναισθημάτων.



Σχήμα 2: Τα στάδια επεξεργασίας σήματος στο πεδίο του Affective Computing

Τέλος, όσον αφορά τη σύνδεση του χώρου της Επιστήμης των Υπολογιστών με την έρευνα του ανθρώπινου συναισθήματος ιδιαίτερα τις τελευταίες δεκαετίες έχει διεξαχθεί πληθώρα ερευνών από επιστήμονες του χώρου αυτού άμεσα συνεργαζόμενων με επιστήμονες από πεδία όπως η Ψυχολογία, η Νευροεπιστήμη και η Μηχανική. Στα πλαίσια αυτής της διεπιστημονικής συνεργασίας έχει δημιουργηθεί τα τελευταία χρόνια ένα ταχεία αναπτυσσόμενο επιστημονικό πεδίο, αυτό του Affective Computing [1]. Αντικείμενο του συγκεκριμένου πεδίου αποτελεί η ανάπτυξη ευφών συστημάτων, των οποίων η λειτουργία βασίζεται κυρίως σε τεχνικές μηχανικής μάθησης, ικανών να αναγνωρίζουν, να ερμηνεύουν, να επεξεργάζονται και να προσομοιώνουν ανθρώπινα συναισθήματα και αντιδράσεις. Ένας από τους σημαντικότερους τομείς στους οποίους δρουν οι ερευνητές του πεδίου αυτού είναι και η Αναγνώριση Συναισθήματος.

1.2 Η Αναγνώριση Συναισθήματος σε Ανθρωποκεντρικό Επίπεδο

Το συναίσθημα παίζει εξέχοντα ρόλο τόσο στην ανθρώπινη επικοινωνία όσο και στην επαφή. Η πλειοψηφία των ανθρώπων μεταβάλλει τη συμπεριφορά και τις αντιδράσεις της ανάλογα με τη συναισθηματική κατάσταση στην οποία βρίσκεται τη στιγμή που θα κληθεί να αλληλεπιδράσει με το περιβάλλον της, να λάβει αποφάσεις και να ανταποκριθεί σε πιθανά ερεθίσματα που δέχεται από το περιβάλλον αυτό. Είναι αρκετά συχνό φαινόμενο στις ανθρώπινες διαπροσωπικές σχέσεις να παρατηρείται διαφορετική διαχείριση και αντιμετώπιση πανομοιότυπων καταστάσεων από το ίδιο άτομο, η οποία και σχετίζεται άμεσα με τις αλλαγές στη συναισθηματική κατάσταση του ατόμου αυτού. Λόγου χάρη, ένας άνθρωπος θα αντιδράσει διαφορετικά αν λάβει ένα αρνητικό ερέθισμα (π.χ. άσχημα νέα) αν βρίσκεται και ο ίδιος σε αρνητική συναισθηματική κατάσταση (λύπη, στεναχώρια, κλπ) σε σχέση με το να βρισκόταν σε μία άκρως θετική συναισθηματική κατάσταση (χαρά, αισιοδοξία, κλπ).

Η ικανότητα μας να αναγνωρίζουμε σε ικανοποιητικό επίπεδο τη διάθεση και τα συναισθήματα των ανθρώπων που μας περιβάλλουν και με τους οποίους ερχόμαστε σε επαφή και αλληλεπιδρούμε αποτελεί μία από τις σημαντικότερες παραμέτρους που επηρεάζουν τη διαδικασία της ανθρώπινης επικοινωνίας και τελικά αποτελούν καθοριστικό παράγοντα για την επιτυχία της διαδικασίας αυτής. Βέβαια, παρ' όλο που οι άνθρωποι παρουσιάζουν μία γενικευμένη συνέπεια στην έκφραση της ικανότητας τους αυτής, παρουσιάζουν εξίσου και σημαντική μεταβλητότητα όσον αφορά την επιτυχή χρήση της. Όλα τα παραπάνω προφανώς δεν αποτελούν πεδίο της Επιστήμης των Υπολογιστών, αλλά επιστημονικών πεδίων που σχετίζονται με την ανάλυση του ανθρώπου και των πτυχών της ανθρώπινης συμπεριφοράς, όπως η Ψυχολογία, χωρίς βέβαια αυτό να σημαίνει πως το αντικείμενο αυτό παραβλέπεται από τους ερευνητές του πρώτου πεδίου. Αντιθέτως, προκειμένου οι ερευνητές της Επιστήμης των Υπολογιστών, που ασχολούνται με το πεδίο του Affective Computing [1], να παραγάγουν αξιόπιστα συστήματα οφείλουν πρωτίστως να έχουν κατανοήσει

σε βάθος τους μηχανισμούς πίσω από την ανθρώπινη έκφραση της αναγνώρισης συναισθήματος.

1.3 Η Αναγνώριση Συναισθήματος στη σχέση Ανθρώπου – Μηχανής

Δεδομένης της ραγδαίως αυξανόμενης και ευρύτερης χρήσης των υπολογιστών καθώς και άλλων ειδών υπολογιστικών συστημάτων που παρατηρείται τα τελευταία χρόνια η συναισθηματική αλληλεπίδραση μεταξύ ανθρώπου και υπολογιστή έχει αναχθεί σε ένα από τα πιο σημαντικά πεδία στην Επιστήμη της Αλληλεπίδρασης Ανθρώπου-Μηχανής (Human Computer Interaction - HCI) καθώς και στην ανάπτυξη λογισμικού επικοινωνίας μεταξύ του υπολογιστή και του ανθρώπινου εγκεφάλου (brain-computer interface). Έτσι, προκειμένου να προσεγγιστεί με επιτυχία η αλληλεπίδραση ανθρώπου μηχανής τίθεται πλέον ως απαραίτητη προϋπόθεση η ανάπτυξη ενός αξιόπιστου συστήματος αναγνώρισης συναισθήματος ικανό να εγγυηθεί έναν κοινά αποδεκτό βαθμό ακρίβειας στην αναγνώριση, ανθεκτικότητα (robustness) καθώς και προσαρμοστικότητα σε πρακτικές εφαρμογές. Όπως αναφέρθηκε και παραπάνω αυτή η διαδικασία αποτελεί αντικείμενο του Affective Computing, κυρίαρχο πεδίο του οποίου αποτελεί η Αναγνώριση Συναισθήματος

Τις τελευταίες δεκαετίες έχουν διεξαχθεί πληθώρα ερευνών πάνω στην αυτοματοποίηση της αναγνώρισης συναισθήματος με τρεις κυρίαρχες προσεγγίσεις να έχουν ακολουθηθεί [2].


- Η πρώτη αφορά την ανάλυση εκφράσεων του προσώπου και του λόγου (facial and speech recognition), η οποία αποτελεί μία μη παρεμβατική μέθοδο, καθώς δεν έχουμε φυσική επαφή του ανθρώπου με τον υπολογιστή. Βέβαια, ανάλογες τεχνικές πάρα το γεγονός ότι ως μη παρεμβατικές διαδικασίες αποτρέπουν πιθανή δυσaréσκεια του χρήστη, πολλές φορές θεωρούνται επιρρεπείς στην εξαπάτηση (έλλειψη robustness), ενώ αρκετά συχνό είναι και το φαινόμενο οι παράμετροι των τεχνικών να διαφέρουν από περίπτωση σε περίπτωση.
- Η δεύτερη κατηγορία προσεγγίσεων σχετίζεται με την ανάλυση περιφερειακών φυσιολογικών σημάτων και τη σύνδεση τους με την εναλλαγή συναισθηματικών καταστάσεων. Αρκετές έρευνες έχουν δείξει πως οι αλλαγές σε διάφορα περιφερειακά αυτόνομα μέρη του ανθρώπινου νευρικού συστήματος, όπως το ηλεκτροκαρδιογράφημα (Electrocardiogram - ECG), η αγωγιμότητα του δέρματος (Skin Conductance - SC), η αναπνοή και ο παλμός, δημιουργούνται από τα περιφερειακά φυσιολογικά σήματα που συνδέονται με αυτά, όταν παρατηρούνται μεταβάσεις μεταξύ διαφορετικών συναισθηματικών καταστάσεων σε έναν άνθρωπο. Συγκριτικά με την πρώτη κατηγορία τα χαρακτηριστικά που μπορούν να εξαχθούν από τα προαναφερθέντα σήματα μπορούν να δώσουν σημαντικά πιο σύνθετες

πληροφορίες σχετικά με την αναγνώριση διακριτών συναισθηματικών καταστάσεων.

- Τέλος, οι ερευνητές που ασχολούνται με την τρίτη κατηγορία, στην οποία αναφέρεται και η παρούσα διπλωματική εργασία, επικεντρώνονται στην ανάλυση εγκεφαλικών σημάτων προερχόμενων από το κεντρικό νευρικό σύστημα. Η αποτύπωση τέτοιων σημάτων προκύπτει από διαδικασίες όπως το ηλεκτροεγκεφαλογράφημα (Electroencephalogram - EEG), η ηλεκτροκορτικογραφία (Electrocorticography - ECoG) και η λειτουργική απεικόνιση μαγνητικού συντονισμού (functional Magnetic Resonance Imaging - fMRI). Μεταξύ των εγκεφαλικών σημάτων αυτών έχει αποδειχτεί πως τα EEG σήματα μεταφέρουν την περισσότερη σχετιζόμενη με τις διάφορες συναισθηματικές καταστάσεις πληροφορία.

1.4 Αναγνώριση Συναισθήματος και Σήματα EEG


Όπως αναφέρθηκε παραπάνω, δεδομένου ότι όλοι οι άνθρωποι εκφράζουν τα συναισθήματά τους με διαφορετικό τρόπο, η κατηγοριοποίηση των ανθρωπίνων συναισθημάτων αποτελεί ένα ιδιαίτερα δύσκολο εγχείρημα, το οποίο και έχει αναλυθεί κυρίως γύρω από τις δύο θεμελιώδεις σκοπιές που περιγράφηκαν και στην ενότητα 1.1. Η πρώτη από αυτές, όπως εξηγήθηκε και παραπάνω, βασίζεται στην αποδοχή κάποιων διακριτών συναισθημάτων ως βασικών και στη παραδοχή πως όλα τα υπόλοιπα συναισθήματα πηγάζουν από αυτά. Βέβαια, ένα εμφανές μειονέκτημα αυτής της θεωρίας είναι οι διαφωνίες που δημιουργούνται μεταξύ διαφόρων επιστημόνων σχετικά με τα συναισθήματα που ανήκουν στην κατηγορία των βασικών. Από την άλλη μεριά η δεύτερη αφορούσε τη διαστατή απεικόνιση των συναισθημάτων και την κατηγοριοποίησή τους ανάλογα με τη θέση τους στον πολυδιάστατο χώρο που θα έχει οριστεί. Τη συγκεκριμένη θεωρία ασπάζεται και ο καθηγητής Ψυχολογίας και Ψυχιατρικής του University of Wisconsin-Madison Richard Davidson, ο οποίος ανέπτυξε το δισδιάστατο μοντέλο συναισθήματος που απεικονίζεται παρακάτω [2]. Σύμφωνα με το μοντέλο αυτό τα συναισθήματα κατηγοριοποιούνται με βάση τη θέση τους στο δισδιάστατο χώρο που ορίζεται από δύο άξονες, της δραστηρότητας (valence) στο οριζόντιο άξονα και της διέγερσης (arousal) στον κατακόρυφο. Η δραστηρότητα αντιπροσωπεύει την ποιότητα του συναισθήματος και κυμαίνεται από τη δυσάρεσκη (unpleasant) έως την ευχαρίστηση (pleasant), ενώ η διέγερση αφορά το ποσοτικό επίπεδο ενεργοποίησης και κυμαίνεται από τη χαλάρωση (calm) έως και τον ενθουσιασμό (excited) [2]. Αντίστοιχα μοντέλα έχουν αναπτυχθεί και για χώρους με περισσότερες διαστάσεις, όπως το τρισδιάστατο μοντέλο το οποίο περιλαμβάνει και την κυριαρχία (dominance), δηλαδή το βαθμό αίσθησης ελέγχου μίας κατάστασης κυμαινόμενο από την αδυναμία (weak) μέχρι και την πλήρη δυνατότητα ελέγχου (strong).



Σχήμα 3: Το δισδιάστατο μοντέλο συναισθημάτων

Με δεδομένο τον παραπάνω τρόπο κατηγοριοποίησης των ανθρωπίνων συναισθημάτων αλλά και της θεωρίας που ανέπτυξε ο Davidson σχετικά με τη συσχέτιση της μπροστινής εγκεφαλικής ηλεκτρικής δραστηριότητας με την εμφάνιση θετικών και αρνητικών συναισθημάτων εντάθηκε η έρευνα ανάμεσα στη σχέση των σημάτων EEG και των συναισθημάτων. Μάλιστα με τη ραγδαία ανάπτυξη πεδίων όπως η ψηφιακή επεξεργασία σήματος, η μηχανική μάθηση, η κατασκευή στεγνών ηλεκτροδίων και οι brain-computer εφαρμογές, δημιουργήθηκαν και τα κατάλληλα εργαλεία για περαιτέρω εμβάθυνση στον τομέα αυτό [2]. Έτσι, λόγω αυτού του σημαντικού ενδιαφέροντος που υπήρξε για τον τομέα αυτό δημιουργήθηκε και πληθώρα διαφορετικών προσεγγίσεων γύρω από την αναγνώριση συναισθήματος μέσω EEG σημάτων. Πάρα το εύρος των προσεγγίσεων αυτών τα βασικά βήματα που ακολουθούνται στις περισσότερες έρευνες που σχετίζονται με το αντικείμενο είναι τα ακόλουθα (τα οποία παρουσιάζονται και στο σχήμα 4).

- Διέγερση του εγκεφάλου με κάποιο εξωτερικό ερέθισμα
- Λήψη των εγκεφαλικών σημάτων που προκύπτουν
- Προεπεξεργασία των σημάτων
- Κύρια επεξεργασία των σημάτων (Επιλογή παραμέτρων και Κατηγοριοποίηση)
- Παραγωγή των κατηγοριοποιημένων συναισθηματικών καταστάσεων



Σχήμα 4: Τα βασικά στάδια του Emotion Recognition από Εγκεφαλικά Σήματα

Βεβαίως η υλοποίηση των βημάτων αυτών μπορεί να γίνει με διάφορες μεθόδους και τεχνικές οι οποίες και παρουσιάζουν μεγάλη ποικιλομορφία μεταξύ των διαφόρων ερευνών. Έτσι, έχουν χρησιμοποιηθεί διαφορετικά είδη ερεθισμάτων (εικόνες, ήχοι, βίντεο, κλπ), διαφορετικές τεχνικές επεξεργασίας (διαφορετικές μέθοδοι Feature Extraction και Selection και διαφορετικοί classifiers), καθώς και διαφορετική μοντελοποίηση των τελικών αποτελεσμάτων (positive-negative-neutral, happy-curious-angry-sad-quiet, κλπ). Περισσότερες πληροφορίες σχετικά με τη διαδικασία αυτή καθώς και τα βήματα που ακολουθούνται θα δοθούν, όμως, στα επόμενα κεφάλαια.

1.5 Σκοπός της Διπλωματικής

Σκοπός της παρούσας διπλωματικής είναι η μελέτη της δυνατότητας χρήσης σημάτων ηλεκτροεγκεφαλογραφήματος για την κατηγοριοποίηση και την αναγνώριση συναισθημάτων μέσω τεχνικών μηχανικής μάθησης. Πιο συγκεκριμένα, χρησιμοποιήθηκε ένα σύνολο δεδομένων, που είχε προκύψει από αντίστοιχα ερευνητικά πειράματα από ερευνητές του Center for Brain-like Computing and Machine Intelligence του Shanghai Jiao Tong University, τους οποίους και ευχαριστούμε για την άμεση αποστολή του dataset, και στου οποίου τη δημιουργία και τη δομή θα αναφερθούμε εκτενώς σε επόμενο κεφάλαιο, προκειμένου να εξαχθούν τα κατάλληλα χαρακτηριστικά για την επίτευξη αξιόλογων αποτελεσμάτων στην κατηγοριοποίηση και ακολούθως την αναγνώριση 3 κυρίαρχων συναισθηματικών καταστάσεων (θετικά, αρνητικά και ουδέτερα συναισθήματα). Για τη μελέτη αυτή χρησιμοποιήθηκε το περιβάλλον λογισμικού Matlab, κυρίως λόγω της πληθώρας μαθηματικών συναρτήσεων καθώς και εργαλείων επεξεργασίας σήματος που διαθέτει, στο οποίο υλοποιήθηκαν όλες οι διαδικασίες που απαιτούσαν τη

συγγραφή κώδικα. Παράλληλα αξιοποιήθηκαν διάφορες γνωστές τεχνικές επιλογής χαρακτηριστικών (Feature Selection techniques), ενώ για το στάδιο της κατηγοριοποίησης (Classification) χρησιμοποιήθηκαν συγκριτικά 4 γνωστοί ταξινομητές (Quadratic Discriminant Analysis, KNN, Random Forest και SVM) καθώς και ένα είδος νευρωνικού δικτύου (Deep Belief Network), των οποίων η ανάλυση θα ακολουθήσει σε επόμενα κεφάλαια.

1.6 Παρουσίαση των Κεφαλαίων

Το ακόλουθα κεφάλαια της παρούσας διπλωματικής εργασίας οργανώνονται ως εξής:

Στο δεύτερο κεφάλαιο παρουσιάζεται εκτενώς το πρόβλημα της Αναγνώρισης Συναισθήματος από EEG σήματα και οι σημαντικότερες πτυχές του, ενώ επίσης γίνεται αναφορά και στις τεχνικές και τα αποτελέσματα αντίστοιχων σύγχρονων μελετών και εργασιών τελευταίας αιχμής (state of the art).

Στο τρίτο κεφάλαιο παρουσιάζεται σε βάθος το απαιτούμενο θεωρητικό υπόβαθρο πίσω από κάθε ένα από τα τρία στάδια (Feature Extraction – Feature Selection – Classification) που ακολουθήθηκαν μέχρι και την εξαγωγή των τελικών αποτελεσμάτων. Έτσι, στο κεφάλαιο αυτό γίνεται εκτενής αναφορά στα ακόλουθα:

- στο είδος και τον τρόπο εξαγωγής των απαραίτητων για το στάδιο της κατηγοριοποίησης χαρακτηριστικών από τα EEG σήματα
- στις μεθόδους επιλογής χαρακτηριστικών που χρησιμοποιήθηκαν
- στον τρόπο λειτουργίας των 4 κατηγοριοποιητών που χρησιμοποιήθηκαν, με μεγαλύτερη έμφαση να δίνεται στο SVM, καθώς και στη δομή και τη λειτουργία των Deep Belief Networks

Στο τέταρτο κεφάλαιο γίνεται εκτενής περιγραφή της πειραματικής διαδικασίας που ακολουθήθηκε, καθώς και παράθεση των αποτελεσμάτων που προέκυψαν μέσω αυτής. Ειδικότερα, παρουσιάζεται αναλυτικά το σύνολο δεδομένων που χρησιμοποιήθηκε, επεξηγούνται οι χρησιμοποιούμενες για την αξιολόγηση του συνόλου της πειραματικής διαδικασίας μετρικές και τελικά παρατίθενται τα αποτελέσματα μέσω διαφόρων πινάκων και γραφικών παραστάσεων.

Τέλος, στο πέμπτο και τελευταίο κεφάλαιο συνοψίζονται τα συμπεράσματα που προκύπτουν από τα πειραματικά αποτελέσματα, ενώ παράλληλα προτείνονται μελλοντικές κατευθύνσεις έρευνας στο πεδίο μελέτης της παρούσας διπλωματικής.

Κεφάλαιο 2 – Αναγνώριση Συναισθήματος Βασισμένη σε Σήματα EEG

Όπως αναφέρθηκε και παραπάνω ανάμεσα στις προσεγγίσεις που έχουν γίνει στο πεδίο της Αναγνώρισης Συναισθήματος σημαντικό μέρος κατέχει και αυτή της ανάλυσης της σχέσης των εγκεφαλικών σημάτων, και δη των σημάτων EEG, με τις συναισθηματικές καταστάσεις ενός ανθρώπινου οργανισμού. Βασική προϋπόθεση για την αξιοποίηση των σημάτων αυτών στο πεδίο έρευνας του Affective Computing και του Emotion Recognition αποτέλεσε η ανάπτυξη της Ηλεκτροεγκεφαλογραφίας (Electroencephalography) καθώς και των απαραίτητων για την καταγραφή εγκεφαλικών σημάτων εργαλείων που χρησιμοποιούνται σε αυτή. Στο κεφάλαιο αυτό θα γίνει εκτενής αναφορά στη μέθοδο της Ηλεκτροεγκεφαλογραφίας και την εξέλιξη της, θα αναλυθεί η σύνδεση του τομέα του Emotion Recognition με την ανάλυση βιολογικών σημάτων, όπως τα EEG σήματα, και τέλος θα παρουσιαστούν και σχετικές εργασίες που έχουν γίνει στον τομέα αυτό την τελευταία περίοδο.

2.1 Η Ηλεκτροεγκεφαλογραφία

2.1.1 Γενικά

Η Ηλεκτροεγκεφαλογραφία αποτελεί μία ηλεκτροφυσιολογική μέθοδο παρακολούθησης που χρησιμοποιείται για την καταγραφή εγκεφαλικών σημάτων. Πιο συγκεκριμένα, αποτελεί μία κυρίως μη παρεμβατική μέθοδο κατά την οποία ηλεκτρόδια τοποθετούνται στο ανθρώπινο κρανίο προκειμένου να μετρηθούν διακυμάνσεις της τάσης προερχόμενες από το ιοντικό ρεύμα που διαπερνά τους εγκεφαλικούς νευρώνες. Οι εφαρμογές που βασίζονται στη μέθοδο αυτή εστιάζουν κυρίως σε δύο κατηγορίες ανάλυσης των αποτελεσμάτων, το φασματικό περιεχόμενο (spectral content) των EEG σημάτων και το πιθανώς σχετιζόμενο με κάποιο γεγονός δυναμικό (event-related potentials – ERPs).



Σχήμα 5: Ασαφής απεικόνιση EEG σημάτων

Η πρώτη κατηγορία σχετίζεται με την ανάλυση του τύπου των εγκεφαλικών ταλαντώσεων που παρατηρούνται στα εγκεφαλικά σήματα στο πεδίο της συχνότητας, ενώ η δεύτερη μελετά πιθανές διακυμάνσεις χρονικά σχετιζόμενες με ένα εξωτερικό γεγονός, όπως κάποιο οπτικοακουστικό ερέθισμα ή κάποια μυϊκή αντίδραση, και χρησιμοποιείται ιδιαίτερος σε επιστημονικά πεδία όπως αυτό του Affective Computing [1] και του Cognitive Science. Τέλος, η Ηλεκτροεγκεφαλογραφία έχει κυρίως ιατρικές εφαρμογές αφού χρησιμοποιείται κατά κόρον στη διάγνωση παθήσεων άμεσα συνδεδεμένων με τη λειτουργία του εγκεφάλου, όπως η επιληψία και οι διαταραχές του ύπνου.

2.1.2 Πλεονεκτήματα και μειονεκτήματα της μεθόδου

Όπως αναφέρθηκε και παραπάνω τεχνικές επεξεργασίας EEG σημάτων χρησιμοποιούνται εκτενώς σε ερευνητικό επίπεδο, κυρίως στο πλαίσιο ερευνών πεδίων όπως εκείνα της Νευροεπιστήμης και του Cognitive Science. Οι τεχνικές αυτές συχνά προτιμώνται σε σχέση με άλλες γνωστές τεχνικές μελέτης του ανθρώπινου εγκεφάλου και των νευρολογικών διεργασιών του, όπως η Ηλεκτροκορτικογραφία (ECoG), η λειτουργική απεικόνιση μαγνητικού συντονισμού (fMRI) και η Μαγνητοεγκεφαλογραφία (Magnetoencephalography - MEG), καθώς χαρακτηρίζονται από πληθώρα σημαντικών πλεονεκτημάτων, άμεσα σχετιζόμενων με τις ανάγκες που προκύπτουν στα ερευνητικά πλαίσια.

Τα κύρια πλεονεκτήματα των τεχνικών αυτών συγκρινόμενων με τις υπόλοιπες γνωστές τεχνικές στο πεδίο της ανάλυσης και της μελέτης του ανθρώπινου εγκεφάλου συνοψίζονται στα εξής:

- Το κόστος του απαιτούμενου υλικού υπολογιστών (hardware) είναι σημαντικά μικρότερο σε σχέση με εκείνο άλλων γνωστών τεχνικών
- Οι αισθητήρες των EEG τεχνικών διαθέτουν μεγαλύτερη μεταφορεσιμότητα, καθώς οι περισσότερες από τις υπόλοιπες τεχνικές απαιτούν ογκώδη εξοπλισμό
- Τα σήματα EEG χαρακτηρίζονται από υψηλή χρονική ανάλυση (temporal resolution), της τάξης των milliseconds. Πιο συγκεκριμένα, τα σήματα αυτά καταγράφονται συνήθως σε ρυθμούς δειγματοληψίας μεταξύ 250 και 2000 Hz σε κλινικό και ερευνητικό επίπεδο, ενώ τα state of the art EEG συστήματα συλλογής δεδομένων μπορούν να καταγράψουν σήματα με ρυθμό δειγματοληψίας μεγαλύτερο των 20000 Hz. Μάλιστα, μόνο οι MEG και οι EROS (Σχετιζόμενο με Γεγονός Οπτικό Σήμα - Event-related optical signal) τεχνικές ανήκουν επίσης στις μη παρεμβατικές τεχνικές με αντίστοιχες δυνατότητες καταγραφής.
- Τα σήματα EEG είναι σχετικά ανθεκτικά σε πιθανή κίνηση του εξεταζόμενου υποκειμένου (subject). Μάλιστα έχουν αναπτυχθεί και τεχνικές για την

ελαχιστοποίηση, ακόμη και την πλήρη αφαίρεση, κινητικών τεχνέργων (artifacts) από σήματα EEG, στις οποίες θα γίνει εκτενέστερη αναφορά παρακάτω καθώς αποτελούν σημαντικό κομμάτι της προεπεξεργασίας των σημάτων αυτών.

- Οι τεχνικές EEG είναι αθόρυβες και άρα μπορούν να χρησιμοποιηθούν σε πειράματα που περιλαμβάνουν τη χρήση και ακουστικών ερεθισμάτων, όπως άλλωστε είναι και αυτό στο οποίο βασίζεται η παρούσα διπλωματική εργασία.
- Οι τεχνικές EEG δεν περιλαμβάνουν την έκθεση σε υψηλής έντασης μαγνητικά πεδία, όπως σε άλλες τεχνικές (κυρίως στη fMRI), τα οποία μπορούν να προκαλέσουν σημαντικές αλλοιώσεις στα δεδομένα που καταγράφονται ενώ παράλληλα αποκλείουν και τη συμμετοχή υποκειμένων με μεταλλικά εμφυτεύματα στα διεξαγόμενα πειράματα.
- Οι τεχνικές EEG είναι άκρως μη παρεμβατικές, αφού απαιτούν μόνο την επαφή των ηλεκτροδίων με το ανθρώπινο κρανίο, χωρίς να απαιτείται άμεση επαφή με κάποιο ανθρώπινο όργανο, όπως λόγου χάρη στις ECoG τεχνικές, όπου απαιτείται η τοποθέτηση των ηλεκτροδίων σε άμεση επαφή με τον ανθρώπινο εγκέφαλο.
- Οι τεχνικές EEG μπορούν να χρησιμοποιηθούν σε υποκείμενα που δεν έχουν κινητική δυνατότητα
- Μέσω των τεχνικών EEG οι ERP μελέτες μπορούν να παράσχουν πληροφορία σχετική με όλα τα στάδια της επεξεργασίας ενός πειράματος και όχι μόνο σχετικά με το τελικό αποτέλεσμα.


Βέβαια, οι τεχνικές αυτές χαρακτηρίζονται και από κάποια μειονεκτήματα, τα βασικότερα εκ των οποίων ακολουθούν:

- Οι τεχνικές αυτές συνδέονται με χαμηλή χωρική ανάλυση του κρανίου, αφού για παράδειγμα μέσω των τεχνικών fMRI μπορούν να παρουσιαστούν άμεσα όλες οι ενεργές περιοχές του εγκεφάλου μετά από κάποια παρατηρούμενη αντίδραση κάτι που είναι δύσκολα υλοποιήσιμο με τις EEG τεχνικές.
- Οι τεχνικές EEG παρουσιάζουν αδυναμία στη μέτρηση νευρολογικής δραστηριότητας σε βαθύτερα στρώματα του εγκεφάλου.
- Απαιτείται σημαντικός χρόνος για τη σύνδεση ενός υποκειμένου με κάποιο σύστημα EEG, καθώς η διαδικασία της ακριβούς τοποθέτησης τόσο των δεκάδων απαραίτητων ηλεκτροδίων στο ανθρώπινο κρανίο όσο και των κατάλληλων αλοιφών για τη σταθεροποίησή τους σε αυτό είναι ιδιαίτερα χρονοβόρα.
- Ο λόγος σήματος προς θόρυβο (Signal-to-Noise Ratio - SNR) είναι χαμηλός με αποτέλεσμα να απαιτούνται προηγμένες τεχνικές ανάλυσης δεδομένων και υψηλός αριθμός υποκειμένων για την εξαγωγή χρήσιμων και αξιόπιστων αποτελεσμάτων.

2.1.3 Οι τεχνικές πίσω από την Ηλεκτροεγκεφαλογραφία

Ο βασικός τρόπος λειτουργίας των EEG τεχνικών στηρίζεται στη μέτρηση της διαφοράς δυναμικού που καταγράφεται από τα διάφορα ζεύγη ηλεκτροδίων του συστήματος και την εξαγωγή συμπερασμάτων από τη μελέτη των μετρήσεων αυτών. Ο μηχανισμός βάσει του οποίου οι μετρούμενες τιμές αυτές βοηθούν στη σκιαγράφηση των λειτουργιών του ανθρώπινου εγκεφάλου και κατ' επέκταση στη μελέτη και την ανάλυσή του παρουσιάζεται εν συντομία ακολούθως.

Το ηλεκτρικό φορτίο του ανθρώπινου εγκεφάλου συντηρείται από δισεκατομμύρια νευρώνες, οι οποίοι είναι πολωμένοι από πρωτεΐνες μεταφοράς μεμβράνης (membrane transport proteins) που διοχετεύουν ιόντα στις μεμβράνες τους. Οι νευρώνες αυτοί ανταλλάσσουν ιόντα με το εξωκυτταρικό τους περιβάλλον συνεχώς. Ως γνωστόν ιόντα ίδιου φορτίου απωθούνται και έτσι όταν πολλά ιόντα απωθούνται από πολλούς νευρώνες την ίδια στιγμή, τα απωθούμενα ιόντα αυτά θα απωθήσουν με τη σειρά τους γείτονές τους και αυτοί τους δικούς τους γείτονες κλπ, δημιουργώντας έτσι ένα κύμα. Όταν αυτό το κύμα των ιόντων φτάσει στα ηλεκτρόδια που έχουν τοποθετηθεί στο κρανίο, αυτά μπορούν να προσελκύσουν και να απωθήσουν ηλεκτρόνια από και προς τη μεταλλική επιφάνεια από την οποία αποτελούνται. Έτσι, δεδομένου ότι το μέταλλο άγει τα ηλεκτρόνια αυτά εύκολα, η διαφορά δυναμικού στα προσελκόμενα και στα απωθούμενα ηλεκτρόνια μεταξύ δύο διαφορετικών ηλεκτροδίων μπορεί να μετρηθεί από ένα βολτόμετρο. Αυτές ακριβώς οι διαφορές δυναμικού που παρατηρούνται καταγράφονται στα EEG σήματα.



Σχήμα 6: Απλουστευτικό Μοντέλο Καταγραφής σημάτων EEG


Όσον αφορά το πρακτικό κομμάτι της χρήσης συστημάτων καταγραφής σημάτων EEG, αυτό περιλαμβάνει κυρίως την τοποθέτηση ηλεκτροδίων στο ανθρώπινο κρανίο και τη σύνδεση τους με κάποιους αισθητήρες καταγραφής προκειμένου να καθίσταται δυνατή η συνεχής και αξιόπιστη λήψη αποτελεσμάτων. Πιο συγκεκριμένα, αφού έχει προετοιμαστεί κατάλληλα το κρανίο του εξεταζόμενου υποκειμένου μέσω μίας απαλής απόξεσης του με σκοπό τη μείωση της εμπέδησης που μπορεί να δημιουργηθεί από την παρουσία νεκρών κυττάρων σε αυτό, τοποθετούνται σε συγκεκριμένες θέσεις πάνω σε αυτό τα ηλεκτρόδια μαζί με κάποια ειδική αλοιφή που θα βοηθήσει την καλύτερη μετάδοση των EEG σημάτων στα ηλεκτρόδια αυτά. Τα ονόματα και οι θέσεις των ηλεκτροδίων καθορίζονται από το Διεθνές Σύστημα Τοποθέτησης 10-20 (International 10-20 Placement System) για τις περισσότερες κλινικές και ερευνητικές εφαρμογές, έτσι ώστε να διασφαλίζεται η κοινή ονοματοδοσία των ηλεκτροδίων καθώς και η δυνατότητα αναπαραγωγής των μελετών μεταξύ διαφορετικών εργαστηρίων. Το σύστημα αυτό βασίζεται στη σχέση μεταξύ της θέσης ενός ηλεκτροδίου και της υποκείμενης περιοχής του εγκεφαλικού φλοιού. Μάλιστα το '10' και το '20' στο όνομα του συστήματος αυτού αναφέρονται στο γεγονός ότι η απόσταση μεταξύ γειτονικών ηλεκτροδίων αντιστοιχεί είτε στο 10% είτε στο 20% της συνολικής απόστασης του κρανίου από το μπροστινό έως και το πίσω αλλά και από το δεξί έως και το αριστερό μέρος (front-back and right-left distance). Το όνομα κάθε θέσης με βάση το σύστημα αυτό αποτελείται από ένα γράμμα που αντιστοιχεί στο λοβό και από ένα αριθμό που αντιστοιχεί στο ημισφαίριο που ανήκει η θέση. Πιο αναλυτικά, η αντιστοίχιση γραμμάτων και νούμερων με τις αντίστοιχες σημασίες τους παρουσιάζονται στον επόμενο πίνακα.

Γράμμα	Λοβός
F	Μετωπιαίος (Frontal)
T	Κροταφικός (Temporal)
C	Κεντρικός (Central) (τυπικά δεν ορίζεται κεντρικός λοβός αλλά το συγκεκριμένο γράμμα χρησιμοποιείται μόνο για σκοπούς αναγνώρισης)
P	Βρεγματικός (Parietal)
O	(Ινιακός) Occipital
Αριθμός	Ημισφαίριο
2,4,6,8	Δεξί
1,3,5,7	Αριστερό
Ειδικά Σύμβολα	Σημασία
Z	Αναφέρεται σε ηλεκτρόδια που βρίσκονται στη μέση της επιφάνειας του κρανίου
A	Αναφέρεται σε ηλεκτρόδια κοντά στους λοβούς των αυτιών

Pg	Αναφέρεται σε ηλεκτρόδια στη ρινοφαρυγγική μετωπιαία περιοχή
Fp	Αναφέρεται σε ηλεκτρόδια στη πολική μετωπιαία περιοχή


Πίνακας 1: Σημασιολογία στο International 10-20 Placement System

Για την τοποθέτηση των ηλεκτροδίων χρησιμοποιούνται 2 ανατομικά σημεία αναφοράς, το ριζορρίνιο (nasion), το οποίο είναι το σημείο ανάμεσα στα μάτια πάνω από τη μύτη, και το ίνιο (inion), που είναι το χαμηλότερο σημείο του κρανίου στο πίσω μέρος του κεφαλιού.



Σχήμα 7: Η κάτοψη της θέσης των ηλεκτροδίων με βάση το Διεθνές Σύστημα Τοποθέτησης 10-20 (International 10-20 Placement System)

Όπως φαίνεται και στο παραπάνω σχήμα, στο σύστημα αυτό χρησιμοποιούνται κατά βάση 21 ηλεκτρόδια, ενώ εάν είναι απαραίτητη μία πιο λεπτομερής EEG καταγραφή, όπως και στην περίπτωση της παρούσας διπλωματικής, προστίθενται επιπλέον ηλεκτρόδια με την τεχνική διαίρεσης του 10%. Σύμφωνα με την τεχνική αυτή νέα ηλεκτρόδια τοποθετούνται στη μέση του κενού χώρου μεταξύ γειτονικών ηλεκτροδίων τοποθετημένων με βάση το International 10-20 System. Το νέο σύστημα ονοματοδοσίας που προκύπτει από την τεχνική αυτή χαρακτηρίζεται από τη λεγόμενη Τροποποιημένη Συνδυαστική Ονοματολογία (Modified Combinatorial Nomenclature - MCN) και του οποίου η τοπολογία παρουσιάζεται στο επόμενο σχήμα, ενώ οι διαφορές στα σύμβολα και τη σημασία τους σε σχέση με το απλό σύστημα καταγράφεται στον πίνακα 2.



Σχήμα 8: Η κάτοψη της θέσης των ηλεκτροδίων με βάση το Διεθνές Σύστημα Τοποθέτησης 10-20 (International 10-20 Placement System) με Τροποποιημένη Συνδυαστική Ονοματολογία

Γράμμα	Λοβός
AF	Ανάμεσα στη θέση των συμβόλων Fp και F
FC	Ανάμεσα στη θέση των συμβόλων F και C
FT	Ανάμεσα στη θέση των συμβόλων F και T
CP	Ανάμεσα στη θέση των συμβόλων C και P
TP	Ανάμεσα στη θέση των συμβόλων T και P
PO	Ανάμεσα στη θέση των συμβόλων P και O
Αριθμός	Ημισφαίριο
2,4,6,8,10	Δεξί
1,3,5,7,9	Αριστερό

Πίνακας 2: Σημασιολογία στο International 10-20 Placement System με MCN

Κάθε ηλεκτρόδιο συνδέεται με τη μία είσοδο ενός διαφορικού ενισχυτή ενώ με την άλλη συνδέεται ένα ηλεκτρόδιο αναφοράς κοινού συστήματος, προκειμένου να μετρηθεί η διαφορά δυναμικού μεταξύ των δύο ηλεκτροδίων αυτών. Ακολουθώντας, στους μοντέρνους ψηφιακούς ενισχυτές, το ενισχυμένο σήμα περνά μέσα από έναν Α/Ψ μετατροπέα (Analog-to-Digital converter), αφού πρώτα περάσει και από ένα αντιπαραποιητικό φίλτρο (anti-aliasing filter). Τέλος, το ψηφιακό EEG σήμα μπορεί να αποθηκευτεί ηλεκτρονικά και να φιλτραριστεί κατάλληλα ώστε να είναι δυνατή η εξαγωγή αξιολογών πληροφοριών από αυτό. Τα πιο συνήθη φίλτρα που χρησιμοποιούνται για αυτόν το λόγο είναι:

- Ένα υπεραπώ φίλτρο με συχνότητα αποκοπής στα 0.5-1 Hz και σκοπό την αφαίρεση αργών τεχνέργων (slow artifacts), όπως τα ηλεκτρογαλβανικά σήματα και τα κινητικά τέχνεργα (motion artifacts)

- Ένα βαθυπερατό φίλτρο με συχνότητα αποκοπής στα 35-70 Hz και σκοπό την αφαίρεση τεχνέργων υψηλής συχνότητας, όπως τα ηλεκτρομυογραφικά σήματα


Όπως γίνεται εύκολα κατανοητό, τουλάχιστον σε ερευνητικό επίπεδο, για την αξιολόγηση και την αποδοτική εκμετάλλευση των πληροφοριών των σημάτων EEG είναι απαραίτητη η γνώση πεδίων όπως η Ψηφιακή Επεξεργασία Σήματος, κάτι που γίνεται ιδιαίτερα εμφανές και κατά τη διαδικασία εξαγωγής χαρακτηριστικών από τα σήματα, η οποία θα περιγραφεί παρακάτω.

2.1.4 Οι ζώνες συχνοτήτων των σημάτων EEG

Η κρανιακή EEG δραστηριότητα παρουσιάζει ταλαντώσεις σε ένα εύρος συχνοτήτων. Αρκετές από τις ταλαντώσεις αυτές έχουν κατηγοριοποιηθεί με βάση κάποια κοινά χαρακτηριστικά που παρουσιάζουν, όπως το εύρος συχνοτήτων στο οποίο ανήκουν και τη χωρική τους κατανομή, προκειμένου να καταστεί δυνατή η αντιστοίχιση τους με διακριτές καταστάσεις της εγκεφαλικής λειτουργίας. Πιο συγκεκριμένα, τα περισσότερα από τα εγκεφαλικά σήματα που παρατηρούνται σε μία κρανιακή EEG καταγραφή ανήκουν στο εύρος 1-20 Hz, με τη δραστηριότητα που καταγράφεται εκτός του εύρους αυτού να αντιμετωπίζεται συνήθως ως τεχνητή (artifactual). Οι κυματομορφές των σημάτων αυτών κατατάσσονται κυρίως στα παρακάτω εύρη ζώνης:

- Delta (≥ 1 & < 4 Hz): Οι κυματομορφές του εύρους αυτού τείνουν να έχουν το μεγαλύτερο πλάτος συγκριτικά με εκείνο των άλλων κατηγοριών, ενώ επίσης θεωρούνται και τα πιο «αργά» κύματα. Παρατηρούνται κυρίως σε ενήλικους σε κατάσταση βαθέος ύπνου (slow-wave sleep) καθώς και σε νεογνά.
- Theta (≥ 4 & < 8 Hz): Παρατηρούνται κυρίως σε νεαρά παιδιά, καθώς και κάποιες φορές σε καταστάσεις υπνηλίας ή διέγερσης σε μεγαλύτερης ηλικίας παιδιά και σε ενήλικες.
- Alpha (≥ 8 & < 12 Hz): Οι κυματομορφές της ζώνης αυτής χαρακτηρίζονται ως ο βασικός οπίσθιος ρυθμός (posterior basic rhythm) και παρατηρούνται και στις δύο πλευρές του οπίσθιου μέρους του κεφαλιού, με εκείνες της κυρίαρχης πλευράς να έχουν μεγαλύτερο πλάτος. Οι συγκεκριμένες κυματομορφές δημιουργούνται κατά το άνοιγμα και το κλείσιμο των ματιών και συνδέονται με την πνευματική έξαρση και χαλάρωση αντίστοιχα.
- Beta (≥ 12 & < 30 Hz): Παρατηρούνται συνήθως και στις δύο πλευρές του εγκεφάλου σε συμμετρικές κατανομές, αλλά καταγράφονται καθαρότερα στις μπροστινές περιοχές. Συνδέονται κυρίως με την κινητική συμπεριφορά, ενώ οι χαμηλού πλάτους κυματομορφές της ζώνης αυτής συνδέονται και με την ανήσυχη σκέψη και την ενεργητική συγκέντρωση.

- Gamma (≥ 30 & < 64 Hz): Για τα κύματα του εύρους αυτού θεωρείται πως συσχετίζονται με το «δέσιμο» διαφορετικών πληθυσμών νευρώνων σε ένα κοινό δίκτυο με σκοπό την εκτέλεση κάποιας είτε νοητικής είτε κινητικής λειτουργίας.



Σχήμα 9: Τα εύρη συχνοτήτων στα EEG σήματα

Στο σημείο αυτό αξίζει να σημειωθεί ότι έχουν υπάρξει αρκετές διαφωνίες στον επιστημονικό κλάδο ως προς τα τυπικά όρια κάθε ζώνης συχνοτήτων (ιδιαίτερα για τα διαχωριστικό όριο μεταξύ της alpha και της beta ζώνης), με αποτέλεσμα τα όρια που παρουσιάζονται παραπάνω να συμπίπτουν κυρίως με αυτά που χρησιμοποιήθηκαν στα πλαίσια της παρούσας διπλωματικής εργασίας.

2.1.5 Τέχνηργα και μέθοδοι αφαίρεσής των

Τα ηλεκτρικά σήματα που ανιχνεύονται στο κρανίο από τα EEG συστήματα αλλά προέρχονται από μη εγκεφαλικές λειτουργίες ονομάζονται τέχνηργα (artifacts). Τα τέχνηργα αυτά κατηγοριοποιούνται κυρίως σε βιολογικά και περιβαλλοντικά, είναι σχεδόν πάντα παρόντα σε EEG καταγραφές και απαιτείται αρκετή εμπειρία για τον εντοπισμό και την αφαίρεση τους προκειμένου να ολοκληρωθεί ορθά η εκάστοτε διαδικασία επεξεργασίας EEG σημάτων.

Τα βιολογικά τέχνηργα περιλαμβάνουν κυματομορφές που πηγάζουν από άλλες δραστηριότητες του σώματος, εκτός των εγκεφαλικών, και οι οποίες τις επηρεάζουν με αποτέλεσμα αρκετές φορές να αποτυπώνονται και στις EEG καταγραφές. Τα πιο συνηθή παραδείγματα τέτοιων τεχνέργων είναι:

- Τέχνηργα επαγόμενα από το μάτι (Eye-induced artifacts), όπως το ανοιγοκλείσιμο του ματιού, οι διάφορες κινήσεις του ματιού καθώς και άλλες εξωοφθαλμικές δραστηριότητες
- Τέχνηργα Ηλεκτροκαρδιογραφίας (ECG artifacts), δηλαδή σήματα που κανονικά προέρχονται από τη διαδικασία καταγραφής της ηλεκτρικής δραστηριότητας της καρδιάς και παρεμβαίνουν στα EEG σήματα λόγω της προφανούς παράλληλης λειτουργίας της καρδιάς κατά την EEG καταγραφή. Μάλιστα αξίζει να σημειωθεί πως στα πιο μοντέρνα συστήματα EEG καταγραφών έχει ενσωματωθεί και ένα ECG σύστημα ενός καναλιού για την αναγνώριση αυτών των τεχνέργων.
- Τέχνηργα Ηλεκτρομυογραφίας (EMG artifacts), δηλαδή σήματα που κανονικά προέρχονται από τη διαδικασία καταγραφής της ηλεκτρικής δραστηριότητας των σκελετικών μυών και παρεμβαίνουν στα EEG εξαιτίας της παράλληλης ασυνείδητης λειτουργίας πληθώρας μυών.
- Γλωσσοκινητικά τέχνηργα (Glossokinetic artifacts), τα οποία και δημιουργούνται κυρίως από ασθενείς κινήσεις της γλώσσας κατά τη διάρκεια της καταγραφής.

Τα περιβαλλοντικά τέχνηργα αφορούν εκείνα που πηγάζουν από την αλληλεπίδραση του ανθρωπίνου σώματος με γεγονότα που συμβαίνουν στο περιβάλλον του κατά τη διάρκεια της EEG καταγραφής. Τα συχνότερα παραδείγματα τέτοιων τεχνέργων αποτελούν πιθανές κινήσεις του εξεταζόμενου ατόμου, κάποια μετακίνηση σε κάποιο από τα ηλεκτρόδια που έχουν τοποθετηθεί στο κρανίο του εξεταζόμενου, αδυναμία σωστής γείωσης των ηλεκτροδίων ή ακόμα και επιρροές από πιθανή παράλληλη ενδοφλέβια εισροή ουσιών.

Τέλος, όσον αφορά τη διόρθωση των τεχνέργων αυτών έχουν χρησιμοποιηθεί διάφορες τεχνικές επεξεργασίας σήματος. Πρόσφατα, αξιοποιούνται προς την κατεύθυνση αυτή τεχνικές Ανεξάρτητης Ανάλυσης Συνιστωσών (Independent Component Analysis - ICA) με σκοπό την ανάλυση των EEG σημάτων στις

υποκείμενες συνιστώσες τους. Εν συνεχεία, για την επίτευξη της εξάλειψης των τεχνέργων έχει χρησιμοποιηθεί μία πληθώρα αλγορίθμων διαχωρισμού με κύριο κοινό χαρακτηριστικό μεταξύ των διαφόρων μεθόδων τη αποδυνάμωση των βαρών που συνδέονται με ανεπιθύμητες συνιστώσες. Μάλιστα, τα τελευταία χρόνια παρατηρήθηκε πως ειδικά η σχετιζόμενη με τους μύες μόλυνση των EEG σημάτων είναι περισσότερο εμφανής σε συχνότητες μεγαλύτερες των 20 Hz (Gamma band) με αποτέλεσμα τη χρήση της surface Laplacian τεχνικής για την αφαίρεση των σχετιζόμενων με τη μυϊκή δραστηριότητα τεχνέργων [3]. Έτσι, τα περισσότερα σύγχρονα συστήματα αφαίρεσης τεχνέργων χρησιμοποιούν τον συνδυασμό της τεχνικής αυτής με κάποιες αυτοματοποιημένες μεθόδους βασισμένες στην Independent Component Analysis.

2.2 Η Χρήση EEG Σημάτων στην Ανάλυση Συναισθήματος

Ανάμεσα στις διάφορες τεχνικές που έχουν αναπτυχθεί και δοκιμαστεί στο χώρο της Αναγνώρισης Συναισθήματος η μέθοδος που βασίζεται στην αξιοποίηση και την ανάλυση της πληροφορίας που μεταφέρουν τα EEG σήματα, και η οποία μελετήθηκε στα πλαίσια της παρούσας διπλωματικής, θεωρείται ως πιο αξιόπιστη κυρίως λόγω της αντικειμενικότητας της σε σχέση με άλλες μεθόδους, όπως η ανάλυση εκφράσεων του προσώπου καθώς και χειρονομιών. Η βαθιά κατανόηση της αντίδρασης του εγκεφάλου σε διαφορετικές συναισθηματικές καταστάσεις μπορεί να οδηγήσει στη θεμελιώδη ανάπτυξη του τομέα της αναγνώρισης συναισθήματος, καθώς η συγκεκριμένη μέθοδος βασίζεται στην ανάλυση βιολογικών σημάτων που συνδέονται με την έκφραση συναισθήματος και των οποίων η δημιουργία αποτελεί εγγενή διαδικασία του ανθρώπινου οργανισμού, σε αντίθεση με τη βάση των άλλων μεθόδων η οποία είναι σαφέστατα πιο υποκειμενική καθώς σχετίζεται με αντιδράσεις που μαθαίνονται από κάθε άνθρωπο και άρα μπορούν να ελεγχθούν από αυτόν. Μάλιστα, αρκετές ψυχοφυσιολογικές έρευνες έχουν καταδείξει τη συσχέτιση μεταξύ των ανθρωπίνων συναισθημάτων και των σημάτων EEG, ενώ με τη ραγδαία ανάπτυξη της σχετικής τεχνολογίας με τις φορητές συσκευές καταγραφής EEG σημάτων είναι πλέον ακόμη πιο εφικτή η αξιοποίηση της συγκεκριμένης μεθόδου στο χώρο της Ανάλυσης Συναισθήματος.

Βέβαια, η ανάλυση των EEG σημάτων, όπως έχει αναφερθεί και παραπάνω, παρουσιάζει και αρκετές δυσκολίες που δεν υφίστανται στις υπόλοιπες γνωστές μεθόδους. Οι πιο σημαντικές εξ αυτών αφορούν το χαμηλό λόγο σήματος προς θόρυβο (Signal-to-Noise Ratio – SNR) των σημάτων EEG, καθώς και το γεγονός πως σε αντίθεση με τα σήματα εικόνων και λόγου (image και speech signals) τα σήματα EEG είναι χρονικά ασύμμετρα και μη στατικά. Έτσι, προκειμένου να προκύψουν αξιόπιστα και αξιόλογα αποτελέσματα από την ανάλυση των σημάτων αυτών απαιτείται η επιμελής και λεπτομερής προεπεξεργασία των καταγεγραμμένων σημάτων καθώς επίσης και η χρήση τεχνικών εξαγωγής και επιλογής

χαρακτηριστικών που ταιριάζουν ειδικά στην ανάλυση των σημάτων αυτών και στην επίτευξη του τελικού επιζητούμενου στόχου. Στις περισσότερες σχετικές μελέτες που έχουν πραγματοποιηθεί η εξαγωγή χαρακτηριστικών βασίζεται σε νευροεπιστημονικές εικασίες. Στο πλαίσιο αυτών των εικασιών ανήκουν και η διασύνδεση διαφορετικών συναισθηματικών καταστάσεων με τη φασματική ενέργεια διαφορετικών ζωνών συχνοτήτων [4], όπως και η συσχέτιση της μετωπιαίας ασυμμετρίας της α ζώνης συχνοτήτων με τα διάφορα επίπεδα δραστηριότητας (valence) των συναισθημάτων [5]. Βέβαια, εκτός από τις νευροεπιστημονικές εικασίες αυτές εξαγωγή χρήσιμων χαρακτηριστικών από τα EEG σήματα μπορεί να επιτευχθεί και μέσω της αξιοποίησης τεχνικών αναπτυγμένης επεξεργασίας σήματος (Advanced Signal Processing), κάτι που δημιουργεί ένα τεράστιο εύρος πιθανών χαρακτηριστικών που μπορούν να εξαχθούν.

Όσον αφορά τις προσεγγίσεις και τα αποτελέσματα σύγχρονων σχετικών εργασιών αυτά ποικίλουν. Στις περισσότερες εξ αυτών το πλήθος και το είδος των χαρακτηριστικών που εξάγονται είναι περιορισμένο σε ένα σύνολο 5-6 διακριτών ειδών χαρακτηριστικών, κάτι που δεν ισχύει στο πλαίσιο της παρούσας διπλωματικής στην οποία συλλέχθηκε πληθώρα διαφορετικών χαρακτηριστικών, όπως φαίνεται και στα επόμενα κεφάλαια. Μάλιστα, μόλις σε μία άλλη σύγχρονη εργασία [6] παρουσιάζεται αντίστοιχο εύρος χαρακτηριστικών, στην οποία όμως τα αποτελέσματα είναι αρκετά φτωχότερα (mean accuracy 43%) σε σχέση με εκείνα της παρούσας διπλωματικής. Άλλες εργασίες που παρουσιάζουν εξίσου αξιόλογα αποτελέσματα (best mean accuracy > 85%) είτε λαμβάνουν αποτελέσματα για το ίδιο υποκείμενο σε διαφορετικά πειράματα [2], [7], κάτι το οποίο δεν ισχύει στην παρούσα εργασία όπου το τμήμα της κατηγοριοποίησης εφαρμόζεται σε σύνολο δεδομένων που αποτελείται από διαφορετικά υποκείμενα - ανθρώπους, είτε παρουσιάζουν το μέσο όρο των επιμέρους αποτελεσμάτων τους [2], κάτι το οποίο οδηγεί πάλι σε υψηλά αποτελέσματα τα οποία όμως δεν είναι αντιπροσωπευτικά για τη δυνατότητα της μεθόδου να εφαρμοστεί με επιτυχία μεταξύ διαφορετικών υποκειμένων.

Έτσι, στο πλαίσιο της παρούσας διπλωματικής, αφού επεξεργάστηκε καταλλήλως το χρησιμοποιηθέν σύνολο δεδομένων ώστε κάθε παρατήρηση να αντιστοιχεί σε διαφορετικό υποκείμενο, χρησιμοποιήθηκαν μέθοδοι εξαγωγής χαρακτηριστικών τόσο από το πεδίο των νευροεπιστημονικών συσχετίσεων όσο και από εκείνο της επεξεργασίας σήματος, ενώ παράλληλα έγινε χρήση και τεχνικών επιλογής χαρακτηριστικών με σκοπό τη μείωση του μεγάλου πλήθους των εξαχθέντων χαρακτηριστικών και την κατάσταση βιώσιμης υπολογιστικά της λειτουργίας των τεχνικών μηχανικής μάθησης που χρησιμοποιήθηκαν στο τελευταίο στάδιο της πειραματικής διαδικασίας.

Κεφάλαιο 3 – Στάδια της διαδικασίας Ανίχνευσης Συναισθήματος

Αφού αναλύθηκε εις βάθος το απαραίτητο θεωρητικό υπόβαθρο των σημάτων EEG καθώς και της σύνδεσής τους με τη διαδικασία αναγνώρισης συναισθήματος μέσω τεχνικών μηχανικής μάθησης, θα πρέπει να αναλυθούν και τα απαιτούμενα στάδια που πρέπει να εκτελεστούν προκειμένου να υλοποιηθεί η λειτουργία αυτή. Όπως αναφέρθηκε και παραπάνω τα βασικά στάδια που ακολουθήθηκαν κατά τη διαδικασία αναγνώρισης συναισθήματος από σήματα EEG με την αξιοποίηση τεχνικών EEG περιλαμβάνουν:

- την εξαγωγή χαρακτηριστικών (Feature Extraction), δηλαδή τη διαδικασία κατά την οποία τα καταγεγραμμένα σήματα που αποτελούν το σύνολο δεδομένων επεξεργάζονται με διάφορες μεθόδους έτσι ώστε να προκύψουν κάποια ποιοτικά χαρακτηριστικά ικανά να χρησιμοποιηθούν κατά τη διαδικασία της κατηγοριοποίησης. Οι μέθοδοι που ακολουθήθηκαν καθώς και το είδος το χαρακτηριστικών που εξήχθησαν θα αναλυθούν εκτενώς στο παρόν κεφάλαιο.
- την επιλογή χαρακτηριστικών (Feature Selection), δηλαδή τη διαδικασία κατά την οποία επιλέγεται ένα υποσύνολο των χαρακτηριστικών που έχουν εξαχθεί από το προηγούμενο στάδιο το οποίο αξιολογείται μέσω διαφόρων μετρικών ως καταλληλότερο για την επιτυχή εκτέλεση της διαδικασίας της κατηγοριοποίησης. Προφανώς οι μέθοδοι που χρησιμοποιήθηκαν για την αξιολόγηση αυτή των εξαχθέντων χαρακτηριστικών θα αναλυθούν εκτενώς στο δεύτερο μέρος του κεφαλαίου.
- και τέλος την κατηγοριοποίηση (Classification), δηλαδή τη διαδικασία κατά την οποία γίνεται η ανάθεση κάθε δείγματος (sample) του συνόλου δεδομένων σε μία από τις κατηγορίες που έχουν οριστεί μέσω κάποιας τεχνικής μηχανικής μάθησης. Οι τεχνικές που χρησιμοποιήθηκαν στην παρούσα διπλωματική εργασία θα αναλυθούν εκτενώς στο τελευταίο μέρος αυτού του κεφαλαίου.

3.1 Εξαγωγή Χαρακτηριστικών

Στον τομέα της αναγνώρισης συναισθήματος από σήματα EEG δεν έχει υπάρξει επιστημονικά κάποια γενικώς αποδεκτή συμφωνία ως προς το ποια χαρακτηριστικά θεωρούνται τα πιο κατάλληλα, ενώ λίγες είναι οι έρευνες που περιλαμβάνουν συγκριτική μελέτη των διαφόρων τεχνικών εξαγωγής χαρακτηριστικών που έχουν υλοποιηθεί [6]. Στη παρούσα διπλωματική έχουν συγκεντρωθεί διάφορα είδη χαρακτηριστικών που έχουν χρησιμοποιηθεί σε EEG μελέτες και έχουν υλοποιηθεί οι μέθοδοι εξαγωγής τους προκειμένου να προκύψει ένα μεγάλο σύνολο δεδομένων το

οποίο εκτός από την όσο το δυνατόν ακριβότερη κατηγοριοποίηση των δειγμάτων να επιτρέψει και τη σύγκριση της χρησιμότητας και της αποτελεσματικότητας κάθε διακριτού τύπου χαρακτηριστικού. Ανάμεσα στην πληθώρα των διαφόρων χαρακτηριστικών που μπορούν να εξαχθούν για τα σήματα EEG μπορούν να εντοπιστούν κάποιες ευρύτερες κατηγορίες στις οποίες αυτά τα χαρακτηριστικά μπορούν να ενταχθούν. Οι κατηγορίες αυτές είναι οι ακόλουθες:

- Χαρακτηριστικά στο Πεδίο του Χρόνου (Time Domain Features)
- Χαρακτηριστικά στο Πεδίο της Συχνότητας (Frequency Domain Features)
- Χαρακτηριστικά στο Πεδίο του Χρόνου και της Συχνότητας (Time-Frequency Domain Features)
- Χαρακτηριστικά που προκύπτουν από το Συνδυασμό Ηλεκτροδίων (Features Calculated from Combinations of Electrodes)

Στο σημείο αυτό πρέπει να τονιστεί πως στα πλαίσια του παρόντος κειμένου η δειγματοληπτημένη χρονική ακολουθία κάθε ηλεκτροδίου θα αναφέρεται ως $\xi(t)$, όπου η μεταβλητή t λαμβάνει τιμές από 0 έως και όσο το πλήθος των δειγμάτων από το σήμα καθενός ηλεκτροδίου, το οποίο συμβολίζεται με τη σειρά του ως T .

3.1.1 Χαρακτηριστικά στο Πεδίο του Χρόνου

Παρ' όλο που τα χαρακτηριστικά της κατηγορίας αυτής δεν είναι τα κυρίαρχα που χρησιμοποιούνται στα EEG σήματα, κάποια εξ αυτών έχουν συνδεθεί με την ανίχνευση διακριτών συναισθηματικών καταστάσεων. Πιο συγκεκριμένα, τα χαρακτηριστικά της κατηγορίας αυτής τα οποία εξάχθηκαν στην παρούσα διπλωματική εργασία παρουσιάζονται ακολούθως:

- Στατιστικά μεγέθη του σήματος (Statistics of a signal)
- Χαρακτηριστικά του Hjorth (Hjorth Features)
- Μη στατικός δείκτης (Non-Stationary Index - NSI)
- Περάσματα υψηλής τάξης (Higher Order Crossings - HOC)

Στατιστικά μεγέθη του σήματος (Statistics of a Signal)

Πιο συγκεκριμένα, αξιοποιήθηκαν 7 στατιστικά μεγέθη για την εξαγωγή χαρακτηριστικών [8-9], τα οποία παρουσιάζονται στον ακόλουθο πίνακα

Στατιστικό Μέγεθος του $\xi(t)$	Αλγεβρικός Τύπος
Ενέργεια (Power)	$P_{\xi} = \frac{1}{T} \sum_{t=-\infty}^{+\infty} \xi(t) ^2$
Μέση Τιμή (Mean)	$\mu_{\xi} = \frac{1}{T} \sum_{t=1}^T \xi(t)$

Τυπική Απόκλιση (Standard Deviation)	$\sigma_{\xi} = \sqrt{\frac{1}{T} \sum_{t=1}^T (\xi(t) - \mu_{\xi})^2}$
Πρώτη Διαφορά (First Difference)	$\delta_{\xi} = \frac{1}{T-1} \sum_{t=1}^{T-1} \xi(t+1) - \xi(t) $
Κανονικοποιημένη Πρώτη Διαφορά (Normalized 1 st Difference)	$\overline{\delta_{\xi}} = \frac{\delta_{\xi}}{\sigma_{\xi}}$
Δεύτερη Διαφορά (Second Difference)	$\gamma_{\xi} = \frac{1}{T-2} \sum_{t=1}^{T-2} \xi(t+2) - \xi(t) $
Κανονικοποιημένη Δεύτερη Διαφορά (Normalized 2 nd Difference)	$\overline{\gamma_{\xi}} = \frac{\gamma_{\xi}}{\sigma_{\xi}}$

Πίνακας 3: Στατιστικά μεγέθη του EEG σήματος

Πέρα των γνωστών στατιστικών μεγεθών, όπως η μέση τιμή και η τυπική απόκλιση, αξίζει να σημειωθεί πως η κανονικοποιημένη πρώτη διαφορά $\overline{\delta_{\xi}}$ είναι επίσης γνωστή και ως Κανονικοποιημένη Πυκνότητα Μήκους (Normalized Length Density) και αποτελεί μέτρο της ομοιότητας στο εσωτερικό ενός EEG σήματος (self-similarity).

Χαρακτηριστικά του Hjorth (Hjorth Features)

Όσον αφορά τα χαρακτηριστικά που ανέπτυξε ο Hjorth [10] για χρονικές ακολουθίες και τα οποία χρησιμοποιήθηκαν στην παρούσα εργασία, αυτά παρουσιάζονται στον παρακάτω πίνακα.

Hjorth Features	Αλγεβρικός Τύπος
Δραστηριότητα (Activity)	$A_{\xi} = \frac{\sum_{t=1}^T (\xi(t) - \mu_{\xi})^2}{T}$
Κινητικότητα (Mobility)	$M_{\xi} = \sqrt{\frac{var(\xi'(t))}{var(\xi(t))}}$
Πολυπλοκότητα (Complexity)	$C_{\xi} = \frac{M(\xi'(t))}{M(\xi(t))}$

Πίνακας 4: Χαρακτηριστικά Hjorth

Στον παραπάνω πίνακα η συνάρτηση var αντιπροσωπεύει την διακύμανση του σήματος ενώ το σύμβολο $\xi'(t)$ αναφέρεται στην παράγωγο του σήματος $\xi(t)$. Πιο αναλυτικά, η Δραστηριότητα (Activity) αποτελεί μέτρο του τετραγώνου της τυπικής απόκλισης, δηλαδή της διακύμανσης, του πλάτους του σήματος και δεδομένου πως αντίστοιχο μέτρο έχει υπολογιστεί και στο προηγούμενο μέρος των χαρακτηριστικών στο πεδίο του χρόνου παραλήφθηκε ο υπολογισμός του για δεύτερη φορά. Η κινητικότητα (Mobility) αποτελεί μέτρο της τυπικής απόκλισης της κλίσης σε σχέση με την τυπική απόκλιση του πλάτους του σήματος. Εκφράζεται σαν λόγος ανά μονάδα του χρόνου και συχνά συναντάται στη βιβλιογραφία ως μέση συχνότητα. Τέλος, η Πολυπλοκότητα (Complexity) εκφράζεται ως ο αριθμός των τυπικών

κλίσεων που δημιουργούνται κατά το μέση χρονικό διάστημα που απαιτείται για τη δημιουργία ενός τυπικού πλάτους όπως αυτό ορίζεται από την Κινητικότητα.

Μη στατικός δείκτης (Non-Stationary Index)

Όσον αφορά το είδος των χαρακτηριστικών που αποτελούν το Μη Στατικό Δείκτη (Non-Stationary Index), αυτά εισήχθηκαν πρώτη φορά από τον Κρουρί [11], ο οποίος επιχείρησε να δημιουργήσει μία μετρική της πολυπλοκότητας ενός σήματος αναλύοντας τη μεταβολή τοπικών μέσων τιμών του συναρτήσεως του χρόνου. Για τον υπολογισμό του δείκτη αυτού, αρχικά, το σήμα κανονικοποιείται και χωρίζεται σε μικρά τμήματα, τα οποία στα πλαίσια της παρούσας διπλωματικής αντιστοιχούσαν σε παράθυρα μήκους 1s. Εν συνεχεία, υπολογίζεται η μέση τιμή κάθε τμήματος αυτού, ενώ, τέλος, υπολογίζεται η τυπική απόκλιση των μέσων τιμών αυτών. Ακριβώς αυτή η τυπική απόκλιση αποτελεί τον NSI, με υψηλότερες τιμές του δείκτη να αντιστοιχούν σε πιο ασύμβατες τοπικές μέσες τιμές.

Μεταβάσεις υψηλής τάξης (Higher Order Crossings)

Τέλος, στο πεδίο της αναγνώρισης συναισθήματος από EEG σήματα την έννοια των Higher Order Crossings την εισήγαγαν οι Πετραντωνάκης και Χατζηλεοντιάδης με σκοπό να αναπτύξουν μία αποδοτική και ανθεκτική τεχνική εξαγωγής χαρακτηριστικών που να αποτυπώνει το μοτίβο ταλάντωσης των EEG σημάτων [12]. Πιο συγκεκριμένα, κάθε παρατηρούμενη χρονική σειρά παρουσιάζει τοπικά και ολικά μέγιστα και ελάχιστα με την πρόοδο του χρόνου. Αυτή ακριβώς η συμπεριφορά σε μία διακριτή χρονική σειρά πεπερασμένου μήκους, όπως και τα σήματα που επεξεργαζόμαστε στα πλαίσια της παρούσας διπλωματικής εργασίας, μπορεί να εκφραστεί μέσω του μετρητή των περασμάτων από το μηδέν (zero-crossing count). Επίσης, είναι γενικά αποδεκτό πως αν εφαρμοστεί ένα φίλτρο σε μία χρονική σειρά τότε ο αριθμός των περασμάτων από το μηδέν μεταβάλλεται. Έτσι, οι δύο προαναφερθέντες ερευνητές θεώρησαν τη διαδικασία κατά την οποία στο σήμα EEG εφαρμόζεται επαναλαμβανόμενα ένα φίλτρο και σε κάθε νέο σήμα που προκύπτει υπολογίζονταν ο αριθμός των zero-crossings, το σύνολο των οποίων αποτελεί και το HOC. Έτσι, η ακολουθία zero-crossings που προκύπτει από τη διαδικασία αυτή αποτελεί την HOC ακολουθία, ενώ γίνεται εύκολα εμφανές πως ανάλογα με το φίλτρο που θα εφαρμοστεί θα προκύψει και διαφορετική HOC ακολουθία, γεγονός που παρέχει ευελιξία σε κάθε ερευνητή σχετικά με τη φασματική ανάλυση που επιθυμεί να κάνει. Στη δική μας υλοποίηση, και βασιζόμενοι στη μελέτη των δύο παραπάνω ερευνητών, το φίλτρο που εφαρμόστηκε ήταν της μορφής

$$\mathfrak{Z}_k\{Z(t)\} = \nabla^{k-1}Z(t),$$

όπου $Z(t)$ είναι μία ακολουθία μηδενικής μέσης τιμής (έγινε κατάλληλος μετασχηματισμός στο EEG σήμα ώστε να πληρεί το κριτήριο αυτό) που δέχεται ως είσοδο το φίλτρο, ∇ είναι ο διαφορικός τελεστής, ο οποίος είναι το υπερεπατό φίλτρο και ισχύει ότι

$$\nabla Z_t \stackrel{\text{def}}{=} Z_t - Z_{t-1},$$

και $\mathfrak{Z}_k$ είναι μία ακολουθία υψιπερατών φίλτρων με αναλυτικό τύπο $\mathfrak{Z}_k = \nabla^{k-1}$, $k = 1, 2, 3, \dots$ και $\mathfrak{Z}_1 = \nabla^0$. Έτσι, μπορεί να υπολογιστεί η ζητούμενη HOC ακολουθία ως

$$D_k = \text{NZC}\{\mathfrak{Z}_k\{Z(t)\}\}, k = 1, 2, 3, \dots \text{ και } t = 1, \dots, T,$$

όπου ο τελεστής $\text{NZC}\{\cdot\}$ δηλώνει τον αριθμό των περασμάτων από το μηδέν (number of zero-crossings) και

$$\nabla^{k-1} Z_t = \sum_{j=1}^k \binom{k-1}{j-1} (-1)^{j-1} Z_{t-j+1} \quad \text{με} \quad \binom{k-1}{j-1} = \frac{(k-1)!}{(j-1)!(k-j)!}$$

Βέβαια, στην πράξη έχουμε μόνο διακριτές χρονικές σειρές με αποτέλεσμα να χάνεται μία παρατήρηση με κάθε εφαρμογή του διαφορικού τελεστή. Για να αντιμετωπιστεί το πρόβλημα αυτό θα πρέπει να μετακινηθεί ο μηδενικός δείκτης των δεδομένων κατά k θέσεις αν θέλουμε να εφαρμόσουμε k φορές το φίλτρο αυτό. Εκτός αυτού, για τον υπολογισμό του αριθμού των zero-crossings δημιουργήθηκε η ακόλουθη δυαδική σειρά

$$X_t(k) = \begin{cases} 1, & \text{if } \mathfrak{Z}_k\{Z(t)\} \geq 0 \\ 0, & \text{if } \mathfrak{Z}_k\{Z(t)\} < 0 \end{cases}, k = 1, 2, 3, \dots \text{ και } t = 1, \dots, T$$

με αποτέλεσμα ο υπολογισμός κάθε όρου της ζητούμενης HOC ακολουθίας να γίνεται μέσω της μέτρησης των δυαδικών αλλαγών στις τιμές $X_1(k), \dots, X_T(k)$, που τυπικά μπορεί να δοθεί από τη σχέση:

$$D_k = \sum_{t=2}^T [X_t(k) - X_{t-1}(k)]^2$$

Προφανώς σε πεπερασμένα σύνολα δεδομένων ισχύει ότι $D_{k+1} \geq D_k - 1$, ενώ επίσης όσο το k αυξάνει τόσο μειώνεται η δύναμη διάκρισης κάθε HOC όρου, με αποτέλεσμα από μία τιμή του k και πάνω να παράγονται σχεδόν πανομοιότυποι όροι D_k . Στα πλαίσια της παρούσας διπλωματικής η τιμή που τέθηκε για το k ήταν ίση με 10.

3.1.2 Χαρακτηριστικά στο Πεδίο της Συχνότητας

Ως χαρακτηριστικά στο πεδίο της συχνότητας χρησιμοποιήθηκαν τα ακόλουθα:

- Η ενέργεια διαφόρων ευρών συχνοτήτων (Band Power) και
- Τα φάσματα υψηλής τάξης (Higher Order Spectra - HOS)

Η αναλυτική περιγραφή των μεγεθών αυτών παρατίθεται ακολούθως.

Ενέργεια ζωνών συχνοτήτων (Band Power)

Ο πιο δημοφιλής και ευρέως χρησιμοποιούμενος τύπος χαρακτηριστικών στο χώρο της Αναγνώρισης Συναισθήματος από EEG σήματα είναι εκείνος που σχετίζεται με την εκμετάλλευση των ενεργειακών χαρακτηριστικών διαφόρων ζωνών συχνοτήτων. Βέβαια, οι τεχνικές που βασίζονται σε αυτά τα χαρακτηριστικά προϋποθέτουν την στατικότητα του σήματος. Οι πιο γνωστές ζώνες συχνοτήτων που χρησιμοποιούνται σε EEG μελέτες είναι εκείνες που αναφέρθηκαν και παραπάνω (Κεφάλαιο 2.1.4), ενώ σε αρκετές μελέτες χρησιμοποιούνται χρονικά τμήματα συγκεκριμένου μήκους (time bins) ως διακριτές ζώνες συχνοτήτων προς μελέτη [6]. Στη παρούσα διπλωματική εργασία χρησιμοποιήθηκαν και οι δύο σκοπιές μελέτης του φασματικού περιεχομένου των EEG σημάτων. Πιο συγκεκριμένα, για τον υπολογισμό των απαιτούμενων μεγεθών στο πεδίο της συχνότητας χρησιμοποιήθηκε ο Μετασχηματισμός Fourier Βραχέος Χρόνου (Short Time Fourier Transform - STFT), καθώς θεωρείται πιο ανθεκτική στο θόρυβο τεχνική.

Ο Μετασχηματισμός Fourier Βραχέος Χρόνου χρησιμοποιείται για τον καθορισμό της ημιτονοειδούς συχνότητας και του φασικού περιεχομένου τοπικών τμημάτων ενός σήματος συναρτήσει του χρόνου. Κατά τη διαδικασία υπολογισμού του STFT το σήμα διαιρείται σε μικρότερα τμήματα ίδιου μήκους και ακολούθως εκτελείται ο Μετασχηματισμός Fourier ξεχωριστά σε κάθε ένα από τα τμήματα που έχουν προκύψει. Με τον τρόπο αυτό μπορεί να προκύψει το φάσμα Fourier κάθε μικρότερου τμήματος, του οποίου η ανάλυση στον άξονα του χρόνου συμβάλλει στην απόκτηση μίας εικόνας του φασματικού περιεχομένου του προς μελέτη σήματος συναρτήσει της χρονικής του διάρκειας. Στα πλαίσια της παρούσας διπλωματικής εργασίας υλοποιήθηκε ο STFT Διακριτού Χρόνου, κατά τον οποίο τα δεδομένα πρέπει να διαιρεθούν σε μικρότερα τμήματα (μήκους 1000ms χωρίς επικάλυψη) και εν συνεχεία να εφαρμοστεί ο Μετασχηματισμός Fourier σε κάθε τμήμα. Το αποτέλεσμα που προκύπτει δίνεται μαθηματικά από τον τύπο $STFT\{\xi[n]\}(m, \omega) = \sum_{-\infty}^{+\infty} \xi[n]w[n-m]e^{-j\omega n}$, όπου w η συνάρτηση παραθύρου που χρησιμοποιείται και η οποία στην περίπτωση μας συμπίπτει με το παράθυρο Hamming (Hamming Window). Το πλάτος υψωμένο στο τετράγωνο ενός STFT χαρακτηρίζεται ως Φασματογράφημα (Spectrogram) και αποτελεί συνάρτηση τόσο του χρόνου όσο και της συχνότητας.

Μάλιστα, στα πλαίσια της παρούσας διπλωματικής ο STFT υλοποιήθηκε στο περιβάλλον του Matlab μέσω της ενσωματωμένης συνάρτησης spectrogram, ενώ τα μεγέθη που υπολογίστηκαν στο πεδίο της συχνότητας ήταν η μέση ενέργεια των ζωνών συχνοτήτων και των διαφόρων τμημάτων (μήκους 2 Hz), η ελάχιστη και η μέγιστη τιμή τους καθώς και η διακύμανση τους. Πιο αναλυτικά, για τον υπολογισμό της ενέργειας των ζωνών χρησιμοποιήθηκε η ενσωματωμένη συνάρτηση bandpower, ενώ για τα υπόλοιπα μεγέθη χρησιμοποιήθηκαν οι ενσωματωμένες συναρτήσεις mean, max, min και var. Τέλος, χρησιμοποιήθηκε και ο λόγος της μέσης τιμής της ενέργειας της Beta ζώνης προς την αντίστοιχη της Alpha ($\frac{Power_{\beta}}{Power_{\alpha}}$).

Φάσματα Υψηλής Τάξης (Higher Order Spectra)

Στο σύνολο των χαρακτηριστικών στο πεδίο της συχνότητας ανήκουν και τα πλάτη των μεγεθών του Bispectrum και του Bicoherence [13], η υλοποίηση της διαδικασίας υπολογισμού των οποίων έχει γίνει μέσω του HOSA Toolbox [14], το οποίο χρησιμοποιήθηκε και στη παρούσα διπλωματική εργασία. Πιο αναλυτικά, το Bispectrum αντιπροσωπεύει το μετασχηματισμό Fourier της ορμής τρίτης τάξης του σήματος και δίνεται από τον ακόλουθο τύπο:

$$Bis(f1, f2) = E[E(f1) \cdot E(f2) \cdot E^*(f1 + f2)],$$

όπου $E(f)$ ο μετασχηματισμός Fourier του σήματος $\xi(t)$, το σύμβολο $*$ δηλώνει το συζυγές ισοδύναμο, ενώ ο τελεστής $E[\cdot]$ δηλώνει την αναμενόμενη τιμή. Όσον αφορά το Bicoherence, αυτό ισούται ουσιαστικά με το κανονικοποιημένο Bispectrum και άρα ο αναλυτικός του τύπος είναι:

$$Bic(f1, f2) = \frac{Bis(f1, f2)}{\sqrt{P(f1) \cdot P(f2) \cdot P(f1+f2)}},$$

όπου $P(f) = E[E(f)E^*(f)]$ και αντιπροσωπεύει το ενεργειακό φάσμα του σήματος. Στα πλαίσια της παρούσας διπλωματικής υπολογίστηκαν τα παραπάνω μεγέθη για τα ζεύγη ζωνών συχνοτήτων που φαίνονται στον ακόλουθο πίνακα.

Ζώνες συχνοτήτων	Delta	Theta	Alpha	Beta	Gamma
Delta	δ-δ	δ-θ	δ-α	δ-β	δ-γ
Theta		θ-θ	θ-α	θ-β	θ-γ
Alpha			α-α	α-β	α-γ
Beta				β-β	β-γ
Gamma					γ-γ

Πίνακας 5: Οι συνδυασμοί των ζωνών συχνοτήτων για τα μεγέθη Bispectrum και Bicoherence

Αξίζει επιπροσθέτως να σημειωθεί ότι για τα συγκεκριμένα μεγέθη εκτός από τα πλάτη τους υπολογίστηκαν και τα τετράγωνα των πλατών τους για καθεμία από τις ζώνες συχνοτήτων που αναφέρθηκαν και παραπάνω.

3.1.3 Χαρακτηριστικά στο Πεδίο του Χρόνου και της Συχνότητας

Όταν ένα σήμα είναι μη στατικό, όπως στην περίπτωση μας, τότε τα χαρακτηριστικά που σχετίζονται τόσο με το πεδίο του χρόνου όσο και το πεδίο της συχνότητας μπορούν να προσφέρουν επιπρόσθετες πληροφορίες καθώς λαμβάνουν υπ' όψιν και τις δυναμικές αλλαγές του σήματος. Έτσι, τα χαρακτηριστικά του πεδίου αυτού που εξετάστηκαν ήταν:

- το φάσμα Hilbert-Huang (Hilbert-Huang Spectrum) και
- ο διακριτός μετασχηματισμός Wavelet (Discrete Wavelet Transform)

Η λεπτομερής περιγραφή των μεγεθών αυτών παρατίθεται ακολούθως.

Το φάσμα Hilbert-Huang (Hilbert-Huang Spectrum)

Ο Χατζηδημητρίου [15] στην έρευνά του μελέτησε τρεις μεθόδους της κατηγορίας αυτής, ονομαστικά ένα φασματογράμμο βασισμένο στο μετασχηματισμό STFT (SPG), την κατανομή Zhao-Atlas-Marks (ZAM Distribution) και το φάσμα των Hilbert-Huang (Hilbert-Huang Spectrum), καταλήγοντας ότι παρ' όλο που και οι τρεις μέθοδοι αυτοί παράγουν συγκρίσιμα αποτελέσματα η τελευταία, μη γραμμική, μέθοδος παρουσιάστηκε πιο ανθεκτική στο θόρυβο, χαρακτηριστικό υψίστης σημασίας στην έρευνα των σημάτων EEG. Έτσι, και στα πλαίσια της παρούσας διπλωματικής υλοποιήθηκε η μέθοδος αυτή. Πιο συγκεκριμένα, η μέθοδος αυτή περιλαμβάνει τη χρήση της εμπειρικής αποσύνθεσης επικρατούσας τιμής (Empirical Mode Decomposition) με σκοπό τη ανάπτυξη των λεγόμενων Intrinsic Mode Functions (IMFs) που αντιπροσωπεύουν το αρχικό σήμα με τον εξής τρόπο:

$$\xi(t) = \sum_{i=1}^K IMF_i(t) + r_K(t),$$

όπου ο όρος r_K υποδηλώνει το υπόλοιπο που θα προκύψει από τη διαδικασία της αποσύνθεσης και είναι είτε σταθερά είτε μονοτονική συνάρτηση. Ακολούθως μέσω του μετασχηματισμού Hilbert κάθε όρου IMF_i , το αναλυτικό σήμα μπορεί να περιγραφεί από το πλάτος του $A_i(t)$ και τη φάση του $\theta_i(t)$. Μέσω της παραγωγίσης της φάσης μπορεί να προκύψει η συχνότητα του σήματος ($f_i(t) = \frac{1}{2\pi} \frac{d\theta_i}{dt}$), η οποία αποτελεί και μία αναπαράσταση του πλάτους στο πεδίο του χρόνου και της συχνότητας. Τέλος, ως χαρακτηριστικό υπολογίζεται ο μέσος όρος του τετραγωνισμένου πλάτους σε κάθε μία από τις ζώνες συχνοτήτων των EEG σημάτων.

Ο διακριτός μετασχηματισμός Wavelet (Discrete Wavelet Transform)

Μία σχετικά μοντέρνα μέθοδος επεξεργασίας σήματος είναι ο διακριτός μετασχηματισμός Wavelet (Discrete Wavelet Transform) [16], ο οποίος αποσυνθέτει ένα δοθέν σήμα σε διάφορα επίπεδα λεπτομέρειας (detail coefficients) και προσέγγισης (approximation coefficients) άμεσα σχετιζόμενα με το επιλεγμένα εύρη συχνοτήτων, ενώ παράλληλα διατηρεί τη σχετιζόμενη με το χρόνο πληροφορία του σήματος. Το μειονέκτημα της μεθόδου αυτής είναι ότι σε κάθε στάδιο της διαδικασίας το δοθέν σήμα υποδειγματοληπτείται. Η αντιστοίχιση των επιπέδων της αποσύνθεσης Wavelet και των ζωνών συχνοτήτων βασίζεται στη συχνότητα δειγματοληψίας, η οποία στην περίπτωσή μας είναι 200 Hz, και δίνεται στον παρακάτω πίνακα.

Bandwidth (Hz)	Frequency Band	Decomposition Level
1-4	Δ	A5
4-8	Θ	D5
8-10	Low A	D4
8-12	A	
12-30	B	D3

30-64	Γ	D2
-------	---	----

Πίνακας 6: Η αντιστοίχιση των ζωνών συχνοτήτων και των επιπέδων αποσύνθεσης των EEG σημάτων

Μάλιστα στα πλαίσια της διπλωματικής εργασίας αυτής εξάχθηκαν χαρακτηριστικά από την υλοποίηση δύο διαφορετικών Wavelet συναρτήσεων, της ‘db4’ και της ‘bior3.3’ [17]. Πιο αναλυτικά, χρησιμοποιήθηκαν οι ενσωματωμένες συναρτήσεις wavedec και wrcoef προκειμένου να υπολογιστούν οι συντελεστές (coefficients) σε κάθε decomposition level. Όσον αφορά τη συνάρτηση ‘bior3.3’ υπολογίστηκε η ενέργεια στις δ, θ, και α ζώνες συχνοτήτων, ενώ από τη συνάρτηση ‘db4’ εξήχθησαν πληροφορίες για την ενέργεια και την εντροπία των συντελεστών που αντιστοιχούν στις α, β, και γ ζώνες συχνοτήτων. Πιο αναλυτικά, υπολογίστηκαν οι rms (Root Mean Square) τιμές τους, η αναδρομική ενεργειακή απόδοση (Recursive Energy Efficiency - REE), ο λογάριθμος του προηγούμενου μεγέθους (log(REE)), καθώς και η απόλυτη τιμή του λογαρίθμου $\text{abs}((\log(\text{REE})))$. Όσον αφορά τα δύο πρώτα μεγέθη, αυτά δίνονται από τις ακόλουθες σχέσεις

$$RMS(j) = \sqrt{\frac{\sum_{i=1}^j \sum n_i D_i(n)^2}{\sum_{i=1}^j n_i}},$$

όπου D_i οι συντελεστές λεπτομέρειας (detail coefficients), n_i ο αριθμός των D_i στο i -οστό επίπεδο της αποσύνθεσης και j ο αριθμός των επιπέδων και

$$REE = \frac{E_{band}}{E_{total-3b}},$$

όπου E_{band} η ενέργεια κάθε ζώνης, ενώ $E_{total-3b}$ η συνολική ενέργεια και των τριών ζωνών.

3.1.4 Χαρακτηριστικά από το Συνδυασμό Ηλεκτροδίων

Στην κατηγορία αυτή ανήκουν μεγέθη που προκύπτουν από το συνδυασμό πληροφορίας που λαμβάνεται από διαφορετικά ηλεκτρόδια, σε αντίθεση με τα παραπάνω χαρακτηριστικά όπου και γινόταν επεξεργασία κάθε σήματος από κάθε ηλεκτρόδιο ξεχωριστά. Συγκεκριμένα, στην κατηγορία αυτή αξιοποιήθηκαν τα ακόλουθα μεγέθη:

- η Διαφορική Ασυμμετρία (Differential Asymmetry) και
- η Ασυμμετρία Λόγου (Rational Asymmetry)

Η αναλυτική περιγραφή των χαρακτηριστικών αυτών ακολουθεί.

Διαφορική Ασυμμετρία (Differential Asymmetry)

Όσον αφορά τη Διαφορική Ασυμμετρία [6] έχουν υπολογιστεί οι διαφορές στα στατιστικά μεγέθη του σήματος που έχουν παρουσιαστεί και παραπάνω μεταξύ

αντιστοιχούντων ηλεκτροδίων του αριστερού και του δεξιού ημισφαιρίου του ανθρωπίνου κρανίου. Ο αναλυτικός τύπος που χρησιμοποιήθηκε είναι:

$$DASM = Power_{x_{left}} - Power_{x_{right}}$$

Πιο αναλυτικά, στο αριστερό ημισφαίριο ανήκουν τα ηλεκτρόδια Fp1, F7, F3, FT7, FC3, T7, P7, C3, TP7, CP3, P3, O1, AF3, F5, F7, FC5, FC1, C5, C1, CP5, CP1, P5, P1, PO7, PO5, PO3 και CB1, ενώ τα αντίστοιχά τους στο δεξί ημισφαίριο είναι τα Fp2, F8, F4, FT8, FC4, T8, P8, C4, TP8, CP4, P4, O2, AF4, F6, F8, FC6, FC2, C6, C2, CP6, CP2, P6, P2, PO8, PO6, PO4 και CB2.

Ασυμμετρία Λόγου (Rational Asymmetry)

Όσον αφορά την Ασυμμετρία Λόγου [6] έχουν υπολογιστεί οι λόγοι στις ενέργειες των βασικών ζωνών συχνοτήτων μεταξύ αντιστοιχούντων ηλεκτροδίων του αριστερού και του δεξιού ημισφαιρίου του ανθρωπίνου κρανίου. Ο αναλυτικός τύπος που χρησιμοποιήθηκε είναι:

$$RASM = \frac{Power_{x_{left}}}{Power_{x_{right}}}$$

3.2 Επιλογή Χαρακτηριστικών

Το μεγάλο πλήθος των εξαχθέντων χαρακτηριστικών (εξήχθησαν ακριβώς 16460 χαρακτηριστικά για κάθε δείγμα) κατέστησαν αναγκαία τη μείωση της διάστασης τους προκειμένου να αποφευχθούν προβλήματα υπερ-συγκεκριμενοποίησης (over-specification) αλλά και για να είναι εφικτός και ο χρόνος υπολογισμού που θα χρειαστεί για την κατηγοριοποίηση των δειγμάτων. Για αυτόν ακριβώς το λόγο εφαρμόστηκαν και κάποιες μέθοδοι επιλογής χαρακτηριστικών (Feature Selection methods) πάνω στο σύνολο δεδομένων που είχε προκύψει. Γενικά οι μέθοδοι αυτοί μπορούν να κατηγοριοποιηθούν σε μεθόδους φιλτραρίσματος (Filter methods), σε μεθόδους περιτυλίγματος (Wrapper Methods) και σε ενσωματωμένες μεθόδους (Embedded Methods). Η βασική διαφορά μεταξύ των κατηγοριών αυτών αφορά το γεγονός ότι οι Filter methods είναι ανεξάρτητες του μοντέλου κατηγοριοποιητή (Classifier model) που έχει επιλεγεί, σε αντίθεση με τις δύο άλλες μεθόδους των οποίων η διαδικασία εκτέλεσης συνδέεται άμεσα με τον εκάστοτε χρησιμοποιούμενο κατηγοριοποιητή, αφού οι Wrapper methods επιλέγουν τα πιο ταιριαστά χαρακτηριστικά αλληλεπιδρώντας με τον εκάστοτε κατηγοριοποιητή, ενώ οι Embedded methods ενσωματώνουν τη διαδικασία της επιλογής στη διαδικασία μάθησης του κατηγοριοποιητή. Προφανώς ένα σημαντικό πλεονέκτημα των Filter methods είναι πως απαιτούν σημαντικά λιγότερη υπολογιστική ισχύ, και άρα ταιριάζουν περισσότερο σε μεγάλα σύνολα δεδομένων, ενώ παράλληλα μπορούν να εξαχθούν πιο γενικά και ακριβή συμπεράσματα σχετικά με την καταλληλότητα κάθε χαρακτηριστικού για το εκάστοτε πρόβλημα κατηγοριοποίησης που χρησιμοποιείται, ειδικά όταν γίνεται σύγκριση μεταξύ διαφορετικών κατηγοριοποιητών. Οι δύο παραπάνω λόγοι οδήγησαν στην υλοποίηση μόνο state-of-the-art Filter μεθόδων στα

πλαίσια της παρούσας διπλωματικής. Οι μέθοδοι επιλογής χαρακτηριστικών που χρησιμοποιήθηκαν, και οι οποίες θα αναλυθούν ακολούθως, είναι:

- reliefF
- Min-Redundancy-Max-Relevance (mRMR)
- Cohen's Effect Size f^2
- Infinite Feature Selection Method

3.2.1 ReliefF

Ο αλγόριθμος ReliefF (Kononenko, 1994) [18] είναι μία μονομεταβλητή (univariate) μέθοδος επιλογής χαρακτηριστικών, η οποία βασίζεται στον κλασικό αλγόριθμο Relief και χρησιμοποιείται επίσης για την εκτίμηση της ποιότητας των χαρακτηριστικών με τρεις βασικές διαφοροποιήσεις σε σχέση με τον κλασικό αλγόριθμο, καθώς δεν περιορίζεται σε δυϊκό πρόβλημα κατηγοριοποίησης, θεωρείται γενικά ως μία πιο ανθεκτική τεχνική, ενώ παράλληλα μπορεί να εφαρμοστεί σε σύνολα δεδομένων με αρκετό θόρυβο, όπως είναι και τα σήματα EEG. Όσον αφορά τον τρόπο λειτουργίας του αλγορίθμου αυτού, όπως και στον απλό Relief δίνεται ως είσοδος κάθε δείγμα του συνόλου δεδομένων και αρχικά επιλέγεται τυχαία ένα δείγμα από το σύνολο των χαρακτηριστικών, έστω R_i . Ακολούθως επιλέγονται k από τους κοντινότερους γείτονες του δείγματος που ανήκουν στην ίδια κλάση, οι οποίοι και ονομάζονται ως κοντινότερες επιτυχίες (nearest hits H_j), καθώς και k από τους κοντινότερους γείτονες του από κάθε άλλη κλάση του συνόλου δεδομένων, οι οποίοι και ονομάζονται κοντινότερες αποτυχίες (nearest misses $M_j(c)$, όπου c συμβολίζεται η κάθε κλάση). Εν συνεχεία, ενημερώνεται ο πίνακας εκτιμήσεων $W[\cdot]$, ο οποίος έχει μέγεθος ίσο με το πλήθος των χαρακτηριστικών του συνόλου δεδομένων, ανάλογα με τις τιμές των R_i , H_j και $M_j(c)$. Πιο συγκεκριμένα, ο ψευδοκώδικας [18] πίσω από τον συγκεκριμένο αλγόριθμο παρουσιάζεται ακολούθως.

```

1. set all weights  $W[a] = 0.0$ 
2. for  $i = 1$  to  $m$  do:
3.     randomly select an instance  $R_i$ 
4.     find  $k$  nearest hits  $H_j$ 
5.     for each class  $c \neq \text{class}(R_i)$  do:
6.         from class  $c$  find  $k$  nearest misses  $M_j(c)$ 
7.     end for
8.     for  $a = 1$  to  $F$  do:
9.          $W[a] = W[a] - \sum_{j=1}^k \text{diff}(a, R_i, H_j) I(m \cdot k)$ 
            $+ \sum_{c \neq \text{class}(R_i)} \left[ \frac{p(c)}{1 - p(\text{class}(R_i))} \sum_{j=1}^k \text{diff}(a, R_i, M_j(c)) \right] I(m \cdot k)$ 
10.    end for
11. end for
```

Αξίζει να σημειωθεί ότι στον παραπάνω ψευδοκώδικα ως F συμβολίζεται το πλήθος των χαρακτηριστικών που έχουν εξαχθεί, και ο τελεστής $p(c)$ αντιστοιχεί στην πρωτότερη πιθανότητα (prior probability) της κλάσης c. Στα πλαίσια της παρούσας διπλωματικής ο αλγόριθμος ReliefF υλοποιήθηκε μέσω της ενσωματωμένης συνάρτησης του Matlab relieff, ενώ ως πλήθος γειτόνων δοκιμάστηκαν τιμές από 5 έως και 30 με βήμα 5.

3.2.2 Min-Redundancy-Max-Relevance (mRMR)

Μία από τις πιο γνωστές πολυμεταβλητές (multivariate) μεθόδους επιλογής χαρακτηριστικών που βασίζεται στην αξιοποίηση αμοιβαίας πληροφορίας (mutual information) για το χαρακτηρισμό της καταλληλότητας ενός υποσυνόλου χαρακτηριστικών είναι η minimal-Redundancy-Maximal-Relevance (mRMR), η οποία αναπτύχθηκε από τους Ding και Peng [19]. Πιο αναλυτικά, η αμοιβαία πληροφορία μεταξύ δύο τυχαίων μεταβλητών x και y δίνεται από τον ακόλουθο τύπο

$$I(x; y) = \iint p(x, y) \log \frac{p(x, y)}{p(x)p(y)} dx dy,$$

όπου $p(x)$, $p(y)$ οι οριακές συναρτήσεις πυκνότητας πιθανότητας των μεταβλητών x και y αντίστοιχα, ενώ $p(x, y)$ η συνδυαστική κατανομή πιθανότητας. Προφανώς αν η αμοιβαία πληροφορία ισούται με το μηδέν, τότε οι δύο εξεταζόμενες μεταβλητές είναι στατιστικά ανεξάρτητες. Σκοπός της συγκεκριμένης τεχνικής είναι η ταυτόχρονη βελτιστοποίηση των δύο παρακάτω κριτηρίων:

- το κριτήριο Maximal-Relevance, δηλαδή τη μεγιστοποίηση της μέσης αμοιβαίας πληροφορίας $I(x_i; y)$ μεταξύ κάθε χαρακτηριστικού x_i και κάθε διανύσματος κατηγοριών y
- το κριτήριο minimal-Redundancy, δηλαδή την ελαχιστοποίηση της μέσης αμοιβαίας πληροφορίας $I(x_i; x_j)$ μεταξύ δύο διακριτών χαρακτηριστικών

Πιο συγκεκριμένα, ο αλγόριθμος της μεθόδου αυτής βρίσκει τα “βέλτιστα” χαρακτηριστικά χρησιμοποιώντας την τεχνική της εμπρόσθιας επιλογής (forward selection), αφού δεδομένου ενός ήδη διαμορφωμένου συνόλου k επιλεγμένων χαρακτηριστικών S_k το επόμενο χαρακτηριστικό που επιλέγεται για να προστεθεί στο σύνολο αυτό βασίζεται στη βελτιστοποίηση του συνδυασμού των δύο προαναφερθέντων κριτηρίων μέσω της μεγιστοποίησης του παρακάτω τύπου:

$$\max_{x_j \in X - S_k} [I(x_j; y) - \frac{1}{k} \sum_{x_i \in S_k} I(x_j; x_i)],$$

όπου X το σύνολο όλων των χαρακτηριστικών του συνόλου δεδομένων.

Για την υλοποίηση του συγκεκριμένου αλγορίθμου χρησιμοποιήθηκε το “MutualInfo 0.9 package”, που δημιουργήθηκε από τον Hanchuan Peng και είναι διαθέσιμο στο

περιβάλλον του Matlab, ενώ παράλληλα ένα απαραίτητο βήμα προεπεξεργασίας της μεθόδου αυτής ήταν η διακριτοποίηση του συνόλου δεδομένων σε 20 επίπεδα.

3.2.3 Cohen's Effect Size f^2

Η συγκεκριμένη μονομεταβλητή μέθοδος αποτελεί μία γενίκευση σε περισσότερες από δύο κλάσεις μίας άλλης γνωστής στατιστικής μετρικής του Cohen, που δίνεται από τον τύπο $d = \left| \frac{\mu_x^1 - \mu_x^2}{\sigma} \right|$, η οποία χρησιμοποιείται ευρέως για το t-test [20]. Ο νέος τύπος που προκύπτει για την αξιολόγηση των χαρακτηριστικών στην περίπτωση ύπαρξης περισσότερων από 2 κλάσεων, όπως και στην περίπτωση της παρούσας διπλωματικής, είναι $f = \frac{\sigma_m}{\sigma}$, όπου $\sigma_m = \sqrt{\frac{\sum_{i=1}^c (\mu_x^i - \mu_x)^2}{c}}$, μ_x^i η μέση τιμή του χαρακτηριστικού x για δείγματα της κλάσης i , μ_x η γενική μέση τιμή του χαρακτηριστικού x και c το πλήθος των διακριτών κλάσεων. Ο υπολογισμός της συγκεκριμένης μετρικής υλοποιήθηκε όπως και στις περιπτώσεις των υπολοίπων μεθόδων επιλογής χαρακτηριστικών στο περιβάλλον του Matlab.

3.2.4 Infinite Feature Selection

Η ιδέα του Infinite Feature Selection εισήχθηκε από τους G. Roffo, S. Melzi και M. Cristani το 2015 [21] και βασίζεται στην αντιστοίχιση του προβλήματος της επιλογής χαρακτηριστικών σε ένα γράφο συγγένειας (affinity graph), θεωρώντας ως κόμβο του γράφου κάθε διακριτό χαρακτηριστικό του συνόλου δεδομένων, και την αναγνώριση του “βέλτιστου” υποσυνόλου χαρακτηριστικών ως ένα μονοπάτι που τα συνδέει. Το κόστος του μονοπατιού αυτού δίνεται από το συνδυασμό των ανά ζεύγος σχέσεων μεταξύ των χαρακτηριστικών, οι οποίες στη μέθοδο αυτή έχουν μοντελοποιηθεί ως συναρτήσεις τόσο της διακύμανσης όσο και της συσχέτισης των χαρακτηριστικών.

Πιο αναλυτικά, ο αλγόριθμος που χρησιμοποιήθηκε για την δημιουργία του προαναφερθέντος γράφου καθώς και για την τελική επιλογή χαρακτηριστικών παρουσιάζεται ακολούθως. Αρχικά, δεδομένου του συνόλου X των χαρακτηριστικών κατασκευάζεται τον μη κατευθυνόμενο πλήρως συνδεδεμένο γράφο συγγένειας $G(V,E)$ στον οποίο μοντελοποιείται το πρόβλημα. Αν θεωρηθεί πως ο γράφος G έχει παρασταθεί με έναν πίνακα γειννίας A , τότε κάθε κελί a_{ij} του πίνακα αυτού θα ισούται με το κόστος κάθε ακμής του γράφου και η τιμή του θα δίνεται από τη σχέση $a_{ij} = a\sigma_{ij} + (1 - a)c_{ij}$, όπου οι δείκτες i και j αντιστοιχούν σε κάποιο ζεύγος χαρακτηριστικών, ο όρος a αποτελεί έναν συντελεστή φόρτωσης (loading coefficient) που ανήκει στο $[0,1]$, $\sigma_{ij} = \max(\sigma_i, \sigma_j)$ με σ_i την τυπική απόκλιση του χαρακτηριστικού i πάνω σε όλα τα δείγματα του συνόλου δεδομένων, ενώ τέλος

$c_{ij} = 1 - |Spearman(x_i, x_j)|$ με τον τελεστή Spearman να συμβολίζει το συντελεστή κατάταξης συσχέτισης του Spearman που ορίζεται ως $Spearman(x, y) = \frac{\sum_i (x_i - \mu_x)(y_i - \mu_y)}{\sqrt{\sum_i (x_i - \mu_x)^2 \sum_i (y_i - \mu_y)^2}}$. Γενικά μία μεγάλη τιμή του κόστους a_{ij}

υποδηλώνει πως τουλάχιστον ένα από τα δύο υπό σύγκριση χαρακτηριστικά είναι διακριτό, αφού καλύπτει ένα μεγάλο χώρο χαρακτηριστικών και άρα τα υπό σύγκριση χαρακτηριστικά δεν είναι πλεονάζοντα. Εν συνεχεία, αν συμβολιστεί ως γ το μονοπάτι μήκους l μεταξύ δύο κόμβων-χαρακτηριστικών i και j και θεωρηθεί πως το μήκος l είναι μικρότερο του πλήθους των χαρακτηριστικών και πως το μονοπάτι δεν έχει κύκλους, τότε ως ενέργεια του μονοπατιού μπορεί να οριστεί το ακόλουθο μέγεθος $E_\gamma = \prod_{k=0}^{l-1} \alpha_{v_k, v_{k+1}}$, το οποίο θεωρείται και ως η συνδυαστική ενέργεια του υποσυνόλου των χαρακτηριστικών που αποτελούν το μονοπάτι. Τώρα αν αφαιρεθεί η παραδοχή για την απουσία κύκλων μπορεί να οριστεί το σύνολο $P_{i,j}^l$ ως το σύνολο που περιέχει όλα τα μονοπάτια μήκους l από το χαρακτηριστικό i στο χαρακτηριστικό j . Έτσι, η συνολική ενέργεια όλων των μονοπατιών αυτών μπορεί να δοθεί από τον τύπο $R_l(i, j) = \sum_{\gamma \in P_{i,j}^l} E_\gamma$, ο οποίος εφαρμόζοντας απλή άλγεβρα πινάκων ισούται με την ποσότητα $A^l(i, j)$. Όσον αφορά το ζήτημα της ύπαρξης κύκλων στα επιλεγμένα μονοπάτια, κάτι που θα δημιουργούσε πρόβλημα αφού θα σήμαινε πως το ίδιο χαρακτηριστικό έχει επιλεγεί περισσότερες από μία φορές στο “βέλτιστο” υποσύνολο, αν επεκταθεί το μήκος του μονοπατιού στο άπειρο τότε η πιθανότητα κάποιο χαρακτηριστικό να βρεθεί σε κύκλο γίνεται ενιαία για κάθε χαρακτηριστικό, κάτι που λαμβάνεται υπ’ όψιν στην κατασκευή του μεγέθους R_l και άρα το πρόβλημα ουσιαστικά αντιμετωπίζεται μέσω αυτού του τύπου της, όχι και τόσο εμφανούς, κανονικοποίησης. Ακολουθώντας, μπορεί να υπολογιστεί το ατομικό σκορ ενέργειας κάθε χαρακτηριστικού i (single feature energy score) σε ένα συγκεκριμένο μήκος μονοπατιού μέσω της σχέσης $s_l(i) = \sum_{j \in V} R_l(i, j) = \sum_{j \in V} A^l(i, j)$. Εύκολα γίνεται εμφανές πως όσο μεγαλύτερο είναι το μέγεθος αυτό για κάθε χαρακτηριστικό τόσο σημαντικότερη είναι η συνεισφορά του στην υπολογιζόμενη ενέργεια, κάτι το οποίο αποτελεί και τη μετρική της συγκεκριμένης μεθόδου. Εξίσου εύκολα εμφανές γίνεται και το γεγονός πως το κόστος υπολογισμού του μεγέθους αυτού είναι υπολογιστικά αρκετά υψηλό (της τάξης του $O(n^4)$) και θα ήταν κάθε άλλο παρά πρακτικό να χρησιμοποιηθεί αυτή η μέθοδος για σύνολα δεδομένων μεγάλων διαστάσεων, όπως και αυτό που προέκυψε για την παρούσα διπλωματική. Έτσι, η βασική ιδέα της μεθόδου αυτής για την υπερπήδηση του σκοπέλου αυτού είναι η επέκταση των μονοπατιών στο άπειρο και η απλοποίηση των παραπάνω υπολογισμών μέσω της χρήσης απλής άλγεβρας.

Πιο αναλυτικά, ο νέος τύπος που προκύπτει για το single feature energy score είναι $s(i) = \sum_{l=1}^{\infty} s_l(i) = \sum_{l=1}^{\infty} \sum_{j \in V} R_l(i, j)$, ενώ αν οριστεί και ως S η γεωμετρική σειρά του πίνακα γειτνίασης A , δηλαδή ισχύει ότι $S = \sum_{l=1}^{\infty} A^l$, τότε ο προηγούμενος τύπος μπορεί να γραφτεί και ως $s(i) = [(\sum_{l=1}^{\infty} A^l)e]_i = [Se]_i$, όπου e το μοναδιαίο διάνυσμα. Ακολουθώντας, επειδή το παραπάνω άπειρο άθροισμα μπορεί να οδηγήσει σε

μη σύγκλιση, θεωρείται απαραίτητη η εφαρμογή κάποιας τεχνικής κανονικοποίησης, η οποία στην προκείμενη περίπτωση είναι η χρήση γεννήτριας συνάρτησης (generating function). Έτσι, προκύπτει ο ακόλουθος τύπος για το single feature energy score

$$\check{s}(i) = \sum_{l=1}^{\infty} r^l s_l(i) = \sum_{l=1}^{\infty} \sum_{j \in V} r^l R_l(i, j)$$

, όπου r ένας παράγοντας κανονικοποίησης. Έτσι, για κατάλληλες τιμές του r είναι δυνατό να εξασφαλιστεί η σύγκλιση του παραπάνω άπειρου αθροίσματος. Από αλγεβρικής σκοπιάς, τώρα, το μέγεθος αυτό μπορεί να υπολογιστεί αποδοτικά αν αξιοποιηθεί η αλγεβρική ιδιότητα σύγκλισης γεωμετρικών σειρών πινάκων, σύμφωνα με την οποία ισχύει ότι $\check{S} = (I - rA)^{-1} - I$, όπου ο πίνακας $\check{S}$ κωδικοποιεί όλη την πληροφορία σχετικά με την ενέργεια του επιλεγμένου υποσυνόλου χαρακτηριστικών. Επομένως, η τελική σχέση για το single feature energy score δίνεται από τον τύπο

$$\check{s}(i) = [\check{S}e]_i$$

και κατατάσσοντας τα χαρακτηριστικά σε φθίνουσα σειρά με βάση την τιμή του μεγέθους αυτού είναι δυνατό να επιλεγεί ένα “βέλτιστο” υποσύνολο αυτών μεταβλητού μεγέθους.

Ο ψευδοκώδικας [21] του παραπάνω αλγορίθμου παρουσιάζεται ακολούθως.

```

1. for i = 1 to n do:
2.     for j = 1 to n do:
3.          $\sigma_{ij} = \max(\text{std}(x_i), \text{std}(x_j))$ 
4.          $c_{ij} = 1 - |\text{Spearman}(x_i, x_j)|$ 
5.          $A(i, j) = \alpha \sigma_{ij} + (1 - \alpha) c_{ij}$ 
6.     end for
7. end for
8. Letting paths tend to infinite
9.  $r = 0.9/p(A)$ 
10.  $S = (I - rA)^{-1} - I$ 
11.  $s = Se$ 

```

Τέλος, αξίζει να σημειωθεί πως ο παραπάνω αλγόριθμος υλοποιήθηκε σε Matlab με την παράμετρο α να λαμβάνει τιμές από 0.1 έως και 1 με βήμα 0.1.

3.3 Κατηγοριοποίηση

Αφού ολοκληρωθεί και το στάδιο επιλογής των “καλύτερων” βάσει κάποιων μετρικών χαρακτηριστικών, οι οποίες και αναλύθηκαν εκτενώς στην προηγούμενη ενότητα, ακολουθεί το βήμα της εισόδου των χαρακτηριστικών αυτών καθώς και των επιθυμητών εξόδων τους στους κατηγοριοποιητές που χρησιμοποιήθηκαν έτσι ώστε

να ληφθούν τα αποτελέσματα της πειραματικής διαδικασίας που ακολουθήθηκε στα πλαίσια της παρούσας διπλωματικής. Ο τρόπος με τον οποίο διαχειριστήκαμε τα δεδομένα εισόδου καθώς και λεπτομέρειες σχετικά με τις ιδιαιτερότητες του συνόλου δεδομένων μας που επηρέασαν το στάδιο αυτό θα παρατεθούν στο επόμενο κεφάλαιο, το οποίο περιέχει όλες τις σχετικές με την πειραματική διαδικασία πληροφορίες. Οι κατηγοριοποιητές που χρησιμοποιήθηκαν είναι οι εξής:

- Quadratic Discriminant Analysis Classifier
- KNN Classifier
- Random Forest Classifier
- Support Vector Machine Classifier
- Deep Belief Networks

Αναλυτικές πληροφορίες σχετικά με τους παραπάνω κατηγοριοποιητές ακολουθούν στις αμέσως επόμενες ενότητες.

3.3.1 Κατηγοριοποιητής Quadratic Discriminant Analysis (QDA)

Η συγκεκριμένη μέθοδος κατηγοριοποίησης χρησιμοποιείται κυρίως για το διαχωρισμό δειγμάτων από δύο ή περισσότερες κλάσεις μέσω μίας τετραγωνικής υπερεπιφάνειας (quadric hyperplane). Στον κατηγοριοποιητή αυτό προκειμένου να αποφασιστεί η πιο “ταιριαστή” κλάση y χρησιμοποιείται ο τύπος

$$y = x^T A x + B^T x + c$$

Η Quadratic Discriminant Analysis σχετίζεται άμεσα με τη Linear Discriminant Analysis (LDA), όπου και θεωρείται πως τα δείγματα κάθε κλάσης ακολουθούν κανονική κατανομή, κάτι που δεν ισχύει στην περίπτωση της QDA, καθώς σε αυτή τη μέθοδο δεν γίνεται η υπόθεση πως κάθε κλάση έχει πανομοιότυπη συνδιακύμανση. Η συνάρτηση κόστους που χρησιμοποιείται για τη λήψη της απόφασης σχετικά με την κατηγοριοποίηση κάθε δείγματος ακολουθεί

$$s_i^Q(x) = -\frac{1}{2} \log |\Sigma_i| - \frac{1}{2} (x - \mu_i)' \Sigma_i^{-1} (x - \mu_i) + \log p_i$$


, όπου Σ_i ο πίνακας διακύμανσης - συνδιακύμανσης των δειγμάτων της κλάσης i , p_i η προϋπολογισμένη πιθανότητα (prior probability) για την κλάση i και x το δείγμα για το οποίο θέλουμε να αποφανθούμε την κλάση στην οποία ανήκει. Έτσι, κάθε δείγμα του συνόλου ελέγχου κατηγοριοποιείται στην κλάση για την οποία το κόστος της προηγούμενης συνάρτησης λαμβάνει τη μέγιστη τιμή.

Η μέθοδος αυτή ήταν μία από τις αρχικές μεθόδους που χρησιμοποιήθηκαν για κατηγοριοποίηση στα πλαίσια της παρούσας διπλωματικής και τα αποτελέσματα του συγκεκριμένου κατηγοριοποιητή αποτελούν κυρίως επίπεδο αναφοράς (baseline method) για την παρούσα διπλωματική. Τέλος, αξίζει να σημειωθεί πως αυτή η

μέθοδος υλοποιήθηκε στο περιβάλλον του Matlab μέσω της ενσωματωμένης συνάρτησης `fitcdiscr` με δοσμένη υπερπαράμετρο την “DiscrimType” ως “diagquadratic”, η οποία καθιστά τους πίνακες συνδιακύμανσης που χρησιμοποιεί η μέθοδος διάγωνιους.

3.3.2 Κατηγοριοποιητής K-Nearest Neighbors (KNN)

Ο αλγόριθμος KNN είναι από τους πιο διαδεδομένους, και σχετικά απλούς, αλγόριθμους μηχανικής μάθησης και χρησιμοποιήθηκε επίσης ως baseline τεχνική στα πλαίσια της παρούσας διπλωματικής. Η βασική ιδέα πάνω στην οποία στηρίζεται ο συγκεκριμένος αλγόριθμος, για την περίπτωση της κατηγοριοποίησης, είναι πως για κάθε δείγμα του συνόλου ελέγχου η κλάση στην οποία θα κατηγοριοποιηθεί εξαρτάται από την κλάση της πλειοψηφίας των k γειτονικών του δειγμάτων. Πιο αναλυτικά, κατά τη φάση της εκπαίδευσης απλώς αποθηκεύονται τα δείγματα του συνόλου εκπαίδευσης μαζί με το διάνυσμα με τις κλάσεις που ανήκει κάθε ένα από αυτά. Κατά τη φάση της κατηγοριοποίησης κάθε μη επισημασμένο δείγμα του συνόλου κατηγοριοποιείται ανάλογα με την πλειοψηφική “ψήφο” των k γειτόνων του. Η μετρική που χρησιμοποιείται για τον καθορισμό των γειτονικών δειγμάτων διαφέρει, με την Ευκλείδεια απόσταση να αποτελεί την πιο συνήθη, ενώ άλλες ευρέως διαδεδομένες μετρικές απόστασης είναι οι αποστάσεις Chebysev, Hamming, Mahalanobis, Cityblock και Spearman.



Σχήμα 10: Παράδειγμα κατηγοριοποίησης KNN τριών κλάσεων


Ένα εμφανές μειονέκτημα της συγκεκριμένης μεθόδου είναι πως μέσω της διαδικασίας της πλειοψηφικής ανάθεσης κλάσεων, αν τα δείγματα μίας συγκεκριμένης κλάσης υπερισχύουν μέσα στο σύνολο δεδομένων, αυτή ακριβώς η κλάση τείνει να υπερισχύσει και στη διαδικασία της μάθησης με αποτέλεσμα πολλά από τα δείγματα που ανήκουν κανονικά σε άλλες κλάσεις να κατηγοριοποιηθούν λανθασμένα στην “επικρατούσα” κλάση. Βέβαια, στα πλαίσια της παρούσας διπλωματικής δεν υπήρξε τέτοιο ζήτημα καθώς τα δείγματα κάθε κλάσης ήταν

ισομοιρασμένα. Προφανώς η σημαντικότερη παράμετρος της συγκεκριμένης τεχνικής είναι το πλήθος k των γειτόνων, για το οποίο δοκιμάστηκε ένα πλήθος διαφορετικών τιμών από 5 έως 30 με βήμα 5. Γενικά θεωρείται πως μεγαλύτερες τιμές του πλήθους k μειώνουν την επίδραση του θορύβου στη διαδικασία της κατηγοριοποίησης, αλλά παράλληλα καθιστούν τα όρια μεταξύ των διαφορετικών κλάσεων λιγότερο εμφανή. Η συγκεκριμένη μέθοδος όπως φαίνεται και από την σχετικά απλή περιγραφή του σκελετού του αλγορίθμου αποτελεί ένα είδος περιστασιακής μάθησης (instance-based learning), ή όπως αποκαλείται αλλιώς οκνηρή μάθηση (lazy learning), καθώς τα χαρακτηριστικά κάθε δείγματος εξετάζονται τοπικά, ενώ κάθε υπολογισμός αναβάλλεται μέχρι και το στάδιο της κατηγοριοποίησης. Τέλος, πρέπει να αναφερθεί πως η συγκεκριμένη τεχνική μηχανικής μάθησης υλοποιήθηκε στο περιβάλλον του Matlab μέσω της ενσωματωμένης συνάρτησης `fitcknn` και με τις ακόλουθες υπερπαραμέτρους:

- “BreakTies” = “random”, κάτι που σημαίνει πως σε περίπτωση ίσου πλήθους γειτόνων από διαφορετικές κλάσεις η ισοπαλία να ξεπερνιέται με τυχαία επιλογή μεταξύ των ισοψηφούντων κλάσεων
- “Distance” = “correlation”, η οποία ισούται με 1 μείον τη γραμμική συσχέτιση μεταξύ των παρατηρήσεων

3.3.3 Κατηγοριοποιητής Random Forest

Η μέθοδος Random Forest αποτελεί μία μέθοδο Αθροιστικής Μάθησης (Ensemble Learning), της οποίας η βασική ιδέα είναι η κατασκευή και η χρησιμοποίηση πολλών διαφορετικών δέντρων απόφασης (decision trees) κατά τη φάση της εκπαίδευσης. Πιο αναλυτικά, στο πεδίο του Ensemble Learning ανήκουν μέθοδοι μηχανικής μάθησης, οι οποίες περιλαμβάνουν τη συνδυαστική χρήση διαφορετικών ατομικών μεθόδων μηχανικής μάθησης με σκοπό την επίτευξη καλύτερων αποτελεσμάτων από ότι θα επιτύγχαναν οι συστατικές μέθοδοι ξεχωριστά. Έτσι, ο αλγόριθμος της μεθόδου περιλαμβάνει τη δημιουργία ενός πλήθους από τυχαία κατασκευασμένα υποσύνολα του αρχικού συνόλου δεδομένων και την παράλληλη δημιουργία αντίστοιχου πλήθους δέντρων απόφασης έτσι ώστε να ταιριαστούν τα υποσύνολα αυτά πάνω στα δέντρα απόφασης. Ο στόχος είναι η δημιουργία ασυσχέτιστων δέντρων απόφασης, τα οποία μειώνουν τη διακύμανση του μοντέλου και των οποίων η πλειοψηφική έξοδος για κάθε δείγμα του συνόλου ελέγχου θα είναι σημαντικά περισσότερο ανθεκτική στο θόρυβο από ότι θα ήταν η αντίστοιχη έξοδος κάθε δέντρου απόφασης ξεχωριστά. Επομένως, αφού δημιουργηθεί και εκπαιδευτεί το μοντέλο, η προβλεπόμενη έξοδος προκύπτει ως η επικρατούσα τιμή των επί μέρους εξόδων των δέντρων απόφασης του μοντέλου.



Σχήμα 11: Απλοποιημένο μοντέλο της μεθόδου Random Forest

Η συγκεκριμένη μέθοδος υλοποιήθηκε στο περιβάλλον του Matlab μέσω της ενσωματωμένης συνάρτησης TreeBagger [22], στην οποία δινόταν ως παράμετρος το πλήθος των δέντρων που θα κατασκευάζονταν και το οποίο λάμβανε τιμές στο εύρος [50,300] με βήμα 50.


3.3.4 Κατηγοριοποιητής Support Vector Machine (SVM)

Ο κατηγοριοποιητής Support Vector Machine (SVM) αποτελεί έναν από τους πιο γνωστούς κατηγοριοποιητές επιβλεπόμενης μάθησης (supervised learning) στο χώρο της μηχανικής μάθησης και βασίζεται κυρίως στην κατασκευή ενός συνόλου από υπερεπιφάνειες (hyperplanes) σε κάποιο πολυδιάστατο χώρο για το διαχωρισμό του συνόλου δεδομένων σε κλάσεις. Πρακτικά, θεωρείται πως έχει επιτευχθεί ένας αξιόπιστος διαχωρισμός από κάποια υπερεπιφάνεια όταν αυτή η υπερεπιφάνεια έχει τη μέγιστη απόσταση από το πιο κοντινό δείγμα κάθε κλάσης, καθώς θεωρείται ότι όσο μεγαλύτερη είναι η απόσταση αυτή τόσο μικρότερο θα είναι το λάθος γενίκευσης (generalization error) του κατηγοριοποιητή.

Ο κορμός της συγκεκριμένης τεχνικής βασίζεται στην ιδέα που περιγράφεται ακολούθως. Συχνά οι κλάσεις στις οποίες είναι επιθυμητό να κατηγοριοποιηθούν τα δεδομένα μπορεί να μην είναι γραμμικά διαχωρίσιμες στον αρχικό χώρο πεπερασμένης διάστασης των χαρακτηριστικών. Έτσι αν ο αρχικός πολυδιάστατος χώρος αντιστοιχιστεί σε έναν χώρο αρκετά υψηλότερης διάστασης, είναι πιθανό το σύνολο δεδομένων να είναι διαχωρίσιμο. Αυτή η αντιστοίχιση μεταξύ των διαφορετικών πολυδιάστατων χώρων γίνεται μέσω μίας συνάρτησης πυρήνα (kernel function), η οποία συμβολίζεται συνήθως ως $k(x,y)$ και διασφαλίζει πως το επιπρόσθετο κόστος για την αντιστοίχιση αυτή θα είναι υπολογιστικά βιώσιμο. Οι

υπερεπιφάνειες στο νέο χώρο ορίζονται ως το σύνολο των σημείων για τα οποία το εσωτερικό γινόμενο τους με κάποιο διάνυσμα του χώρου αυτού είναι σταθερό. Μάλιστα τα διανύσματα που αποτελούν τις επιλεγμένες υπερ επιφάνειες μπορούν να προκύψουν ως γραμμικοί συνδυασμοί κάποιων διανυσμάτων x_i του συνόλου δεδομένων. Έτσι, με την επιλογή της υπερ επιφάνειας τα σημεία x του αρχικού χώρου που αντιστοιχούνται στο νέο χώρο δίνονται μέσω της σχέσης $\sum_i a_i k(x_i, x) = constant$, όπου a_i οι συντελεστές του γραμμικού συνδυασμού.

Principle of Support Vector Machines (SVM)



Σχήμα 12: Απλοποιημένο μοντέλο της αντιστοίχισης των χώρων των χαρακτηριστικών στο SVM

Γενικά υπάρχουν διάφορες συναρτήσεις πυρήνα που χρησιμοποιούνται στη συγκεκριμένη μέθοδο, αλλά οι πιο γνωστές από αυτές είναι:


- Linear kernel: $k(\vec{x}_i, \vec{x}_j) = \vec{x}_i \cdot \vec{x}_j$
- Polynomial kernel: $k(\vec{x}_i, \vec{x}_j) = (\vec{x}_i \cdot \vec{x}_j)^d$
- Radial Basis Function kernel: $k(\vec{x}_i, \vec{x}_j) = \exp(-\gamma \|\vec{x}_i - \vec{x}_j\|^2)$, $\gamma > 0$
- Hyperbolic Tangent: $k(\vec{x}_i, \vec{x}_j) = \tanh(\kappa \vec{x}_i \cdot \vec{x}_j + c)$, για κάποιο $\kappa > 0$ και $c > 0$

Στα πλαίσια της παρούσας διπλωματικής χρησιμοποιήθηκε ο πυρήνας rbf, ενώ η συγκεκριμένη τεχνική υλοποιήθηκε μέσω της εργαλειοθήκης LIBSVM [23] στο περιβάλλον του Matlab. Ως παράμετροι κατά τη διαδικασία κατηγοριοποίησης μέσω της τεχνικής αυτής δόθηκαν τα παρακάτω μεγέθη:

- Κόστος λανθασμένης κατηγοριοποίησης c (Misclassification cost), το οποίο λάμβανε τιμές από 2^1 έως 2^{10} με το βήμα να τίθεται 1 και να αφορά τον εκθέτη του μεγέθους
- Παράμετρος γ (gamma parameter), η οποία λάμβανε τιμές από 2^{-15} έως 2^{-7} με το βήμα να τίθεται 1 και να αφορά και πάλι τον εκθέτη του μεγέθους


3.3.5 Deep Belief Networks (DBN)

Το δίκτυο Deep Belief [7], [24-26] είναι ένα πιθανοτικό αναπαραγωγικό μοντέλο (probabilistic generative model) με βαθιά αρχιτεκτονική, το οποίο κατηγοριοποιεί τα δεδομένα εισόδου με τη χρήση κάποιων κρυφών μεταβλητών. Κάθε στρώμα του δικτύου αυτού αποτελείται από μία περιορισμένη μηχανή Boltzmann (Restricted Boltzmann Machine – RBM) με εμφανείς και κρυφές μονάδες, όπως φαίνεται στο παρακάτω σχήμα.



Σχήμα 13: Απλοποιημένο μοντέλο Restricted Boltzmann Machine

Όπως φαίνεται και παραπάνω δεν υπάρχουν συνδέσεις ούτε μεταξύ κρυφών μονάδων ούτε μεταξύ εμφανών μονάδων, ενώ κάθε μία από αυτές τις μονάδες διαθέτει και ένα διάνυσμα πόλωσης (bias vector), συμβολιζόμενο με a για τις κρυφές μονάδες και b για τις εμφανείς. Έτσι, ένα δίκτυο Deep Belief κατασκευάζεται από την ένωση ενός συγκεκριμένου αριθμού από RBM σε μία διάταξη, όπου η έξοδος από ένα RBM χαμηλότερου επιπέδου δίνεται ως είσοδος σε ένα RBM υψηλότερου επιπέδου, όπως φαίνεται στο ακόλουθο σχήμα.



Σχήμα 14: Απλοποιημένο μοντέλο Deep Belief Network

Για την προ-εκπαίδευση κάθε στρώματος του δικτύου χρησιμοποιείται ένας αποδοτικός άπληστος αλγόριθμος. Σε ένα RBM η συνδυαστική κατανομή (joint distribution) $P(v, h; \theta)$ πάνω στις εμφανείς μονάδες v και τις κρυφές h και τις δοσμένες παραμέτρους θ του μοντέλου δίνεται από τον όρο μίας συνάρτησης ενέργειας $E(v, h; \theta)$ όπως φαίνεται ακολούθως

$$P(v, h; \theta) = \frac{\exp(-E(v, h; \theta))}{Z}$$

, όπου $Z = \sum_v \sum_h \exp(-E(v, h; \theta))$ και αποτελεί έναν παράγοντα κανονικοποίησης. Η περιθωριακή πιθανότητα (marginal probability) που το μοντέλο αναθέτει σε μία εμφανή μονάδα εκφράζεται από τον τύπο

$$P(v; \theta) = \frac{\sum_h \exp(-E(v, h; \theta))}{Z}$$

Τώρα για ένα Gaussian (εμφανής μονάδα) – Bernoulli (κρυφή μονάδα) RBM η συνάρτηση ενέργειας δίνεται από την ακόλουθη σχέση

$$E(v, h; \theta) = - \sum_{i=1}^I \sum_{j=1}^J w_{ij} u_i h_j - \frac{1}{2} \sum_{i=1}^I (u_i - b_i)^2 - \sum_{j=1}^J a_j h_j$$

, όπου w_{ij} είναι το συμμετρικό κόστος μεταξύ των εμφανών μονάδων i και των κρυφών j , ενώ I και J τα πλήθη των εμφανών και των κρυφών μονάδων αντίστοιχα. Οι υπό συνθήκη πιθανότητες μπορούν να υπολογιστούν αποδοτικά ως εξής

$$P(h_j = 1|v; \theta) = \sigma\left(\sum_{i=1}^I w_{ij}u_i + a_j\right)$$

$$P(v_i = 1|h; \theta) = N\left(\sum_{j=1}^J w_{ij}h_j + b_i, 1\right)$$

, όπου $\sigma(x) = \frac{1}{(1+\exp(x))}$, και ο όρος v_i παίρνει πραγματικές τιμές και ακολουθεί Gaussian κατανομή με μέση τιμή ίση με $\sum_{j=1}^J w_{ij}h_j + b_i$ και διακύμανση ίση με 1. Ο κανόνας ενημέρωσης για την προσαρμογή των βαρών του RBM δίνεται από τη σχέση


$$\Delta w_{ij} = E_{data}(v_i h_j) - E_{model}(v_i h_j)$$

, όπου $E_{data}(v_i h_j)$ είναι η αναμενόμενη έξοδος του συνόλου εκπαίδευσης και $E_{model}(v_i h_j)$ η έξοδος που παράγει το μοντέλο. Μερικές φορές χρησιμοποιείται στον κανόνα ενημέρωσης και ένας όρος ορμής (momentum) για την αποφυγή από τον εγκλωβισμό του μοντέλου σε τοπικά ελάχιστα, ενώ η κανονικοποίηση που πραγματοποιείται στα πλαίσια της μεθόδου αυτής έχει ως στόχο την αποφυγή της λήψης πολύ μεγάλων τιμών από τους όρους βάρους w_{ij} .

Στα πλαίσια της παρούσας διπλωματικής η εκπαίδευση του μοντέλου αυτού υλοποιήθηκε σε 3 στάδια, των οποίων η περιγραφή ακολουθεί:

- Μη επιβλεπόμενη προ-εκπαίδευση κάθε στρώματος (unsupervised pre-training)
- Μη επιβλεπόμενη ακριβής προσαρμογή (unsupervised fine-tuning) όλων των στρωμάτων με ανάστροφη διάδοση (backpropagation)
- Επιβλεπόμενη ακριβής προσαρμογή (supervised fine-tuning) όλων των στρωμάτων με ανάστροφη διάδοση (backpropagation)

Πιο αναλυτικά, για το στάδιο του unsupervised fine-tuning η το πλήθος RBM “ξετυλίγονται” σχεδιάζοντας έναν κατευθυνόμενο δίκτυο κωδικοποιητή-αποκωδικοποιητή (encoder-decoder network) μήκους $2n-1$, όπως φαίνεται στο παρακάτω σχήμα.



Σχήμα 15: Απλοποιημένο μοντέλο ενός unrolled Deep Belief Network

Ο στόχος της εκπαίδευσης ενός τόσο βαθιού αυτόματου κωδικοποιητή (autoencoder) είναι η επίτευξη όσο το δυνατόν καλύτερης διαδικασίας μάθησης των βαρών από το δίκτυο έτσι ώστε η ανακατασκευή που θα προκύψει από το μοντέλο να προσεγγίζει όσο το δυνατόν περισσότερο την πραγματική είσοδο. Τέλος, όσον αφορά το στάδιο του supervised fine-tuning προστίθεται ένα στρώμα “ετικέτας” (label layer) στην έξοδο του ήδη εκπαιδευμένου DBN και τα βάρη ενημερώνονται μέσω της διαδικασίας της οπίσθιας διάδοσης λάθους (error backpropagation). Το βαθύ δίκτυο αυτό, όπως και οι υπόλοιποι κατηγοριοποιητές, υλοποιήθηκε στο περιβάλλον του Matlab.

Κεφάλαιο 4 – Πειραματική Διαδικασία και Αποτελέσματα

Αφού παρουσιάστηκε αναλυτικά το θεωρητικό υπόβαθρο τόσο των σταδίων προεπεξεργασίας της διαδικασίας που ακολουθήθηκε για την εκπόνηση της παρούσας διπλωματικής (Εξαγωγή και Επιλογή των Χαρακτηριστικών) όσο και του σταδίου της κατηγοριοποίησης μέσω της εκτεταμένης παρουσίασης των διαφόρων ειδών των χαρακτηριστικών, των διαφόρων μεθόδων επιλογής καθώς και των κατηγοριοποιητών που χρησιμοποιήθηκαν και ελέγχθηκαν, θα πρέπει να παρουσιαστεί και το πρακτικό μέρος της διαδικασίας, δηλαδή τα βήματα που ακολουθήθηκαν για την πρακτική εφαρμογή όλων των παραπάνω καθώς και τα αποτελέσματα που ελήφθησαν από την πειραματική διαδικασία.

4.1 Η συλλογή των δεδομένων


Όπως έχει αναφερθεί και στο κεφάλαιο 1.5 το σύνολο δεδομένων που χρησιμοποιήθηκε στα πλαίσια της παρούσας διπλωματικής είχε προκύψει από κάποια ερευνητικά πειράματα του Center for Brain-like Computing and Machine Intelligence του Shanghai Jiao Tong University. Τα πειράματα αυτά [7], [24] περιλάμβαναν την αναπαραγωγή συναισθηματικού οπτικοακουστικού υλικού (βίντεο) μικρής διάρκειας σε κάποια υποκείμενα (ανθρώπους) και την καταγραφή της εγκεφαλικής τους λειτουργίας κατά τη διάρκεια της διαδικασίας αυτής μέσω ενός ηλεκτροεγκεφαλογράφου με σκοπό την εκμαίευση των συναισθημάτων τους και την κατηγοριοποίηση τους σε 3 εξεταζόμενες κατηγορίες. Πιο αναλυτικά, οι κατηγορίες αυτές ήταν

- Θετικό (positive)
- Αρνητικό (negative) και
- Ουδέτερο (neutral)

και αντιστοιχούσαν 5 κλιπ σε κάθε κατηγορία. Έτσι, κάθε πείραμα αποτελούνταν από 15 κλιπ και κάθε ένα από αυτά διαρκούσε 4 λεπτά. Όπως αναφέρεται και στη μελέτη του Shanghai Jiao Tong University [7] τα κλιπ αυτά είχαν επιλεγεί προσεκτικά έτσι ώστε να βοηθούν το υποκείμενο να παρουσιάσει το ζητούμενο συναίσθημα. Το πρωτόκολλο που ακολουθήθηκε σε κάθε πείραμα, το οποίο φαίνεται και στο παρακάτω σχήμα, επεξηγείται ακολούθως.

- Κάθε πείραμα αποτελούταν από 15 συνεδρίες
- Κάθε συνεδρία διαρκούσε 305 sec και χωριζόταν στα ακόλουθα μέρη:
 - 5 sec: παρουσίαση ενός συμβόλου που καταδείκνυε την αρχή μίας νέας συνεδρίας
 - 240 sec: προβολή του 4-λεπτου κλιπ που αντιστοιχούσε στη συνεδρία

- 45 sec: ατομική αξιολόγηση του υποκειμένου μέσω της απάντησης των 3 παρακάτω ερωτήσεων:
 - Τί συναίσθημα ένιωσαν κατά τη διάρκεια της προβολής του κλιπ;
 - Αν έχουν ξαναδεί το συγκεκριμένο κλιπ;
 - Αν έχουν καταλάβει το συγκεκριμένο κλιπ;
- 15 sec: ξεκούραση του υποκειμένου
- Με την ολοκλήρωση κάθε συνεδρίας ακολουθούσε η επόμενη μέχρι και την ολοκλήρωση του πειράματος



Σχήμα 16: Το πρωτόκολλο του πειράματος για τη δημιουργία του συνόλου δεδομένων

Στα πειράματα αυτά έλαβαν μέρος 15 υποκείμενα, με 8 εξ αυτών να είναι αρσενικού γένους και 7 εξ αυτών θηλυκού. Κάθε πείραμα έλαβε χώρα σε ήρεμο περιβάλλον και επαναλήφθηκε 3 φορές σε κάθε υποκείμενο προκειμένου να διευρυνθεί και το σύνολο δεδομένων, ενώ τα απαραίτητα σήματα EEG λήφθηκαν μέσω του συστήματος ESI NeuroScan σε συχνότητα δειγματοληψίας 1000 Hz και με τη χρήση διάταξης 62 ηλεκτροδίων στο Διεθνές Σύστημα 10-20, όπως αυτή παρουσιάστηκε στο σχήμα 7. Έτσι, το σύνολο δεδομένων που προέκυψε περιελάμβανε 675 δείγματα, αφού για κάθε υποκείμενο είχαμε 15 εξεταζόμενα κλιπ και για κάθε υποκείμενο η διαδικασία επαναλήφθηκε 3 φορές, με κάθε νέα καταγραφή να θεωρείται ανεξάρτητο δείγμα.

4.2 Η Πειραματική Διαδικασία


Μετά από επικοινωνία που είχαμε με τα μέλη του Center for Brain-like Computing and Machine Intelligence του Shanghai Jiao Tong University μας απέστειλαν το σύνολο δεδομένων που είχαν δημιουργήσει, όπως περιγράφηκε στην προηγούμενη ενότητα. Στο αρχείο που μας απέστειλαν περιέχονταν τόσο κάποια προεπεξεργασμένα δεδομένα όσο και τα χαρακτηριστικά που είχαν εξαγάγει αυτοί από τα δείγματα, τα οποία για προφανείς λόγους δεν χρησιμοποιήθηκαν, καθώς το ζητούμενο ήταν να λάβουμε χαρακτηριστικά δικής μας προτίμησης από τα δεδομένα. Το στάδιο προεπεξεργασίας που είχε εφαρμοστεί στα αρχικά ανεπεξέργαστα χαρακτηριστικά αφορούσε κυρίως τη βελτίωση της ποιότητάς τους και έτσι δεν

κρίθηκε αναγκαίο να ζητηθούν τα τελείως ανεπεξέργαστα δεδομένα. Πιο αναλυτικά, το στάδιο αυτό περιλάμβανε τα ακόλουθα βήματα:

- Έγινε υποδειγματοληψία των αρχικών καταγεγραμμένων EEG σημάτων από τα 1000 Hz στα 200 Hz.
- Τα καταγεγραμμένα EEG σήματα ελέγχθηκαν και οπτικά και τα σήματα που παρουσίαζαν τη μεγαλύτερη μόλυνση από EMG και EOG σήματα αφαιρέθηκαν χειροκίνητα.
- Τα σήματα EOG είχαν καταγραφεί επίσης κατά τη διάρκεια των πειραμάτων προκειμένου να αναγνωριστούν τέχνηρα βλεφαρίσματος από την EEG καταγραφή.
- Προκειμένου να αφαιρεθούν ο θόρυβος και τα πιθανά τέχνηρα τα EEG σήματα επεξεργάστηκαν μέσω ζωνοπερατού φίλτρου με ζώνης επίτρεψης από 0.3 Hz έως 50 Hz.
- Με το τέλος της προεπεξεργασίας από κάθε καταγραφή εξήχθησαν τα κομμάτια που αφορούσαν τα 4-λεπτα κλιπ, ενώ αξίζει να σημειωθεί πως κάθε κανάλι (καταγραφή κάθε ηλεκτροδίου) των EEG δεδομένων χωρίστηκε εποχές κοινού μήκους ίσου με 1 sec χωρίς επικαλύψεις, με αποτέλεσμα να υπάρχουν 3300 εποχές σε κάθε πείραμα.
- Όλα το στάδιο της προεπεξεργασίας είχε γίνει στο περιβάλλον του Matlab.

Από τα προεπεξεργασμένα αυτά δεδομένα ελήφθησαν τα είδη χαρακτηριστικών που έχουν αναλυθεί στο προηγούμενο κεφάλαιο μέσω κατάλληλα υλοποιημένων συναρτήσεων στο περιβάλλον του Matlab (Ο σχετικός κώδικας τόσο με τις συναρτήσεις αυτές όσο και με το σύνολο της πειραματικής διαδικασίας θα αναρτηθεί σε κάποιο δημόσια προσβάσιμο ιστότοπο). Έτσι, από τη συνένωση των αποτελεσμάτων των συναρτήσεων αυτών προέκυψε ο τελικός πίνακας χαρακτηριστικών διαστάσεων 675x16460 (δείγματα x χαρακτηριστικά), του οποίου η κατανομή των χαρακτηριστικών φαίνεται στον ακόλουθο γράφημα.

Κατανομή Εξαχθέντων Χαρακτηριστικών



Σχήμα 17: Κατανομή Εξαχθέντων Χαρακτηριστικών

Πιο αναλυτικά, η παραπάνω κατανομή προέκυψε ως εξής:

- **Signal statistics:** Για κάθε κανάλι του ηλεκτροεγκεφαλογράφου υπολογίστηκαν τα 7 στατιστικά μεγέθη που περιγράφηκαν αναλυτικά στην αντίστοιχη παράγραφο (power, mean value, standard deviation, 1st difference, normalized 1st difference, 2nd difference, normalized 2nd difference). Έτσι, προέκυψαν συνολικά $62 \cdot 7 = 434$ χαρακτηριστικά στην κατηγορία αυτή.
- **Hjorth Features:** Για κάθε κανάλι υπολογίστηκαν 2 μεγέθη (mobility, complexity), οπότε στην κατηγορία αυτή δημιουργήθηκαν $62 \cdot 2 = 124$ χαρακτηριστικά.
- **Non-Stationary Index:** Στην κατηγορία αυτή δεδομένου ότι υπολογιζόταν μόνο ένα μέγεθος ανά κανάλι έχουμε 62 χαρακτηριστικά.
- **Higher Order Crossings:** Για κάθε κανάλι υπολογίστηκαν 10 όροι της ακολουθίας HOC με αποτέλεσμα να προκύψουν $62 \cdot 10 = 620$ χαρακτηριστικά.
- **STFT-related Features:** Για τη κατηγορία αυτή υπολογίστηκαν για κάθε κανάλι 4 μεγέθη (mean power, max, min, variance) τόσο σχετικά με τις 6 εξεταζόμενες ζώνες συχνότητων (delta, theta, low alpha, alpha, beta και gamma) όσο και με σχετικά με τα 31 frequency bins που εξετάστηκαν. Εκτός των παραπάνω υπολογίστηκε και ο λόγος της ενέργειας των ζωνών beta προς alpha. Έτσι, το πλήθος των χαρακτηριστικών της κατηγορίας αυτής είναι $62 \cdot (6 \cdot 4 + 31 \cdot 4 + 1) = 9238$
- **Higher Order Spectra:** Για την κατηγορία αυτή υπολογίστηκαν 4 μεγέθη (Bispectrum, Bicoherence και τα τετράγωνα αυτών) για 15 συνδυασμούς συχνότητων για κάθε κανάλι. Επομένως, υπολογίστηκαν συνολικά $62 \cdot 60 = 3720$ χαρακτηριστικά.

- Hilbert-Huang Spectrum: Για την κατηγορία αυτή υπολογίστηκαν 5 μεγέθη (όσα και οι ζώνες συχνοτήτων) για κάθε κανάλι και άρα προέκυψαν $62 \cdot 5 = 310$ χαρακτηριστικά.
- Discrete Wavelet – ‘bior3.3’: Για την κατηγορία αυτή υπολογίστηκαν 3 μεγέθη (οι ενέργειες των ζωνών συχνοτήτων δ , θ και α) για κάθε κανάλι. Επομένως, προέκυψαν $62 \cdot 3 = 186$ χαρακτηριστικά.
- Discrete Wavelet – ‘db4’: Για την κατηγορία αυτή υπολογίστηκαν 18 μεγέθη (6 μεγέθη (ενέργεια, εντροπία, rms, ree, $\log(\text{ree})$ και $\text{abs}(\log(\text{ree}))$) για 3 τις ζώνες συχνοτήτων α , β και γ) για κάθε κανάλι. Έτσι, υπολογίστηκαν $62 \cdot 18 = 1116$ χαρακτηριστικά.
- Rational Asymmetry: Για την κατηγορία αυτή υπολογίστηκαν 6 μεγέθη (όσα και οι 6 ζώνες συχνοτήτων) για τα ζεύγη ηλεκτροδίων left-right (27 ζεύγη) και frontier-posterior (23 ζεύγη). Επομένως, προέκυψαν $50 \cdot 6 = 300$ χαρακτηριστικά.
- Differential Asymmetry: Για την κατηγορία αυτή υπολογίστηκαν 7 μεγέθη (όσα και τα 7 στατιστικά μεγέθη του σήματος που είχαν υπολογιστεί) για τα ζεύγη ηλεκτροδίων left-right (27 ζεύγη) και frontier-posterior (23 ζεύγη). Επομένως, προέκυψαν $50 \cdot 7 = 350$ χαρακτηριστικά.

Αφού δημιουργήθηκε ο πίνακας των χαρακτηριστικών αυτός αφαιρέθηκαν τα σχεδόν όμοια χαρακτηριστικά [6], προκειμένου να αποφευχθούν μελλοντικά προβλήματα στη διαδικασία τις επιλογής χαρακτηριστικών, μέσω της ενσωματωμένης συνάρτησης του Matlab `removeconstantrows`, ενώ παράλληλα κανονικοποιήθηκαν τα χαρακτηριστικά, μέσω της ενσωματωμένης συνάρτησης του Matlab `zscore`, ώστε να έχουν μέση τιμή ίση με 0 και τυπική απόκλιση ίση με 1.

Εν συνεχεία, ο πίνακας αυτός δόθηκε ως είσοδος στις 4 μεθόδους επιλογής χαρακτηριστικών που αναλύθηκαν παραπάνω και τα επιμέρους σύνολα επιλεχθέντων χαρακτηριστικών προέκυψαν με την ακόλουθη στρατηγική:

- Μέσω των τεχνικών ReliefF και Cohen’s f^2 λήφθηκαν δύο είδη κατατάξεων (ranks) των χαρακτηριστικών με βάση τη βελτιστοποίηση του κριτηρίου κάθε τεχνικής σε φθίνουσα σειρά (τα “βέλτιστα” χαρακτηριστικά πρώτα). Όσον αφορά την τεχνική ReliefF υπολογίστηκαν 6 κατατάξεις καθώς δοκιμάστηκαν 6 μεγέθη γειτόνων όπως έχει αναφερθεί και παραπάνω.
- Μέσω της τεχνικής mRMR παρήχθησαν 2 είδη αποτελεσμάτων, τα οποία προέκυπταν από τα δύο πιθανά σχήματα εύρεσης επόμενου βέλτιστου χαρακτηριστικού της μεθόδου, τη διαφορά της αμοιβαίας πληροφορίας (Mutual Information Difference – MID) και του πηλίκου της αμοιβαίας πληροφορίας (Mutual Information Quotient – MIQ). Μέσω της τεχνικής αυτής ζητήθηκε σύνολο χαρακτηριστικών ίσου με το 5% του συνόλου των χαρακτηριστικών (δηλ. 823 χαρακτηριστικά).
- Τέλος, στη τεχνική του Infinite Feature Selection επειδή δεν θα ήταν υπολογιστικά εφικτό να δοθεί το σύνολο των χαρακτηριστικών καθώς η

δημιουργία και η επεξεργασία του Affinity Graph που απαιτεί ο αλγόριθμος θα αργούσε υπερβολικά, δόθηκαν εν τέλει ως είσοδοι τα “βέλτιστα” χαρακτηριστικά που είχαν προκύψει από τις προηγούμενες μεθόδους επιλογής. Πιο συγκεκριμένα, δόθηκαν οι 6 κατατάξεις που είχαν προκύψει από τη μέθοδο ReliefF (για πλήθος γειτόνων στο διάστημα [5,30] με βήμα 5), η κατάταξη από την Cohen’s f^2 μέθοδο, καθώς και οι 2 κατατάξεις από τη mRMR μέθοδο. Από τις πρώτες 2 μεθόδους επιλέχθηκαν τα πρώτα 1646 χαρακτηριστικά (το 10% του συνόλου), ενώ για τη mRMR μέθοδο τα 823 χαρακτηριστικά που είχαν προκύψει από την ίδια τη μέθοδο. Έτσι, δεδομένου πως στα πλαίσια της μεθόδου αυτής παραμετροποιήθηκε και η μεταβλητή α για 10 τιμές το σύνολο των αποτελεσμάτων που προέκυψε για τη μέθοδο αυτή ήταν ίσο με 90 $((6+1+2) \cdot 10 = 90)$.

- Γίνεται εύκολα εμφανές πως το αθροιστικό πλήθος όλων των υποσυνόλων των επιλεγμένων χαρακτηριστικών ήταν ίσο με 99, αφού έχουμε 6 από τη ReliefF, 1 από τη Cohen’s f^2 , 2 από τη mRMR και 90 από την Infinite Feature Selection.

Αξίζει να σημειωθεί πως τα διάφορα πλήθη των χαρακτηριστικών στις μεθόδους επιλογής προέκυψαν μετά από πληθώρα ελέγχων σε διάφορα μεγέθη του συνόλου δεδομένων από τα οποία προέκυψε το συμπέρασμα πως προκειμένου να επιτευχθούν αξιόπιστα και αξιολογικά χαρακτηριστικά θα έπρεπε να κρατηθεί το πολύ 10% του συνόλου των χαρακτηριστικών. Αυτό συνέβη για τους εξής δύο λόγους. Αφ’ ενός αν επιλεγόταν μεγάλο μέρος του συνόλου των χαρακτηριστικών τότε τα χαρακτηριστικά ήταν σημαντικά περισσότερα από τις παρατηρήσεις με αποτέλεσμα να τίθενται θέματα υπερειδίκευσης (overspecification) των κατηγοριοποιητών, αφ’ ετέρου αν δινόταν η πλειοψηφία των χαρακτηριστικών κάποιοι μέθοδοι είτε επιλογής είτε κατηγοριοποίησης θα ήταν ανέφικτο υπολογιστικά να δώσουν αποτέλεσμα. Βέβαια, ακόμη και όταν δοκιμάστηκε να δοθεί μεγάλο μέρος του συνόλου των χαρακτηριστικών (της τάξης του 50-60%) τα αποτελέσματα ήταν σαφώς χειρότερα από εκείνα που δίνονταν με είσοδο το 5-10% των χαρακτηριστικών. Τέλος, όσον αφορά το στάδιο της επιλογής υπολογίστηκαν και στοιχεία σχετικά με το ποιόν των χαρακτηριστικών που επιλέγονταν από κάθε μέθοδο προκειμένου να είναι εφικτή μία καθολική αξιολόγηση της ποιότητας των χαρακτηριστικών που χρησιμοποιήθηκαν.

Αφού ολοκληρώθηκε και το στάδιο της επιλογής προκειμένου να προχωρήσουμε στο στάδιο της κατηγοριοποίησης και δεδομένου πως δεν υπήρχαν ξεχωριστά σύνολα εκπαίδευσης και ελέγχου στο σύνολο δεδομένων εφαρμόστηκε η τεχνική του cross-validation. Πιο αναλυτικά, εφαρμόστηκε 9-fold cross-validation μέσω της ενσωματωμένης συνάρτησης του Matlab cvpartition με κάθε σύνολο εκπαίδευσης να περιέχει 600 παρατηρήσεις και κάθε σύνολο ελέγχου 75 παρατηρήσεις με το πλήθος των παρατηρήσεων κάθε κλάσης να είναι ισότιμο σε κάθε σύνολο. Ακολούθως εφαρμόστηκαν οι 5 κατηγοριοποιητές που αναλύθηκαν παραπάνω, τροφοδοτημένοι με τις παραμέτρους που έχουν αναφερθεί παραπάνω, με στόχο την ένταξη των παρατηρήσεων σε 1 εκ των 3 ακόλουθων συναισθηματικών καταστάσεων του.

- Θετικά (positive) συναισθήματα
- Αρνητικά (negative) συναισθήματα
- Ουδέτερα (neutral) συναισθήματα

Όσον αφορά το Deep Belief Network αρχικά δοκιμάστηκε μία δομή με 2 επίπεδα με την ακόλουθη δομή:

- 1^ο επίπεδο: πλήθος νευρώνων στο διάστημα [50, 800] με βήμα 50
- 2^ο επίπεδο: πλήθος νευρώνων στο διάστημα [50, 400] με βήμα 50
- Επίπεδο εξόδου: 3 νευρώνες, δηλ. όσες και οι κλάσεις προς κατηγοριοποίηση

Αφού αξιολογήθηκαν τα αποτελέσματα του συγκεκριμένου δικτύου διαπιστώθηκε πως δεν ήταν καθόλου ικανοποιητικά και μάλιστα ήταν χαμηλότερα και από τα αποτελέσματα baseline κατηγοριοποιητών, όπως ο QDA και ο KNN. Έτσι, αποφασίστηκε να δοκιμαστεί μία πιο απλή δομή δικτύου, η οποία περιλάμβανε μόνο ένα επίπεδο και είχε την παρακάτω δομή:

- 1^ο επίπεδο: πλήθος νευρώνων στο διάστημα [50, 800] με βήμα 50
- Επίπεδο εξόδου: 3 νευρώνες, δηλ. όσες και οι κλάσεις προς κατηγοριοποίηση

Τα αποτελέσματα που προέκυψαν από τη δομή αυτή ήταν αρκετά ικανοποιητικά με αποτέλεσμα να καταλήξουμε στη δομή αυτή. Η αξιολόγηση της απόδοσης κάθε μοντέλου έγινε μέσω της χρήσης των μετρικών που παρουσιάζονται στην επόμενη ενότητα. Τα τελικά αποτελέσματα που προέκυψαν από κάθε μέθοδο παρουσιάζονται αναλυτικά στην τελευταία ενότητα του παρόντος κεφαλαίου.

4.3 Οι Μετρικές Αξιολόγησης

Για την αξιολόγηση των αποτελεσμάτων που λήφθηκαν μέσω της πειραματικής διαδικασίας που αναλύθηκε παραπάνω χρησιμοποιήθηκαν κάποιες ευρέως γνωστές στο χώρο της μηχανικής μάθησης και της στατιστικής ανάλυσης μετρικές. Εν συντομία οι μετρικές αυτές είναι:

- Η ακρίβεια (accuracy)
- Η ανάκληση (recall), ή αλλιώς και ποσοστό επιτυχιών (hit rate)
- Η ακριβολογία (precision)
- Το ποσοστό λαθών (error rate)
- Η μικροσκοπική ανάκληση (micro recall)
- Η μικροσκοπική ακριβολογία (micro precision)
- Η μικροσκοπική μετρική f1 (micro f1-score)
- Η μακροσκοπική ανάκληση (macro recall)
- Η μακροσκοπική ακριβολογία (macro precision)
- Η μακροσκοπική μετρική f1 (macro f1-score)

Για την ανάγκη του υπολογισμού των παραπάνω μεγεθών υπολογίστηκαν και το πλήθος των true-positive, true-negative, false-positive και false-negative δειγμάτων, ενώ επίσης δημιουργήθηκε και ο confusion matrix για κάθε κλάση. Η σημασία κάθε μετρικής, καθώς και η σχέση μέσω της οποίας υπολογίζεται, παρουσιάζονται ακολούθως.

Είδος δειγμάτων και Confusion Matrix

Ως true-positive (TP) χαρακτηρίζονται τα δείγματα του συνόλου ελέγχου τα οποία κατηγοριοποιήθηκαν ορθώς στην εξεταζόμενη κλάση, δηλαδή ισχύει ότι predicted label == actual label. Ως false-positive (FP) χαρακτηρίζονται τα δείγματα του συνόλου ελέγχου τα οποία κατηγοριοποιήθηκαν λανθασμένα στην εξεταζόμενη κλάση. Ως false-negative (FN) χαρακτηρίζονται τα δείγματα του συνόλου ελέγχου τα οποία κατηγοριοποιήθηκαν λανθασμένα σε άλλη κλάση του συνόλου δεδομένων, ενώ στην πραγματικότητα ανήκουν στην εξεταζόμενη κλάση. Τέλος, ως true-negative (TN) χαρακτηρίζονται τα υπόλοιπα δείγματα του συνόλου ελέγχου, τα οποία προφανώς κατηγοριοποιήθηκαν ορθώς σε άλλες κλάσεις του συνόλου. Ο confusion matrix ενός συνόλου δεδομένων προκύπτει μέσω της παρουσίασης των παραπάνω στοιχείων σε μορφή πίνακα για κάθε δυνατή κλάση, όπως φαίνεται παρακάτω (βέβαια στο πλαίσιο της παρούσας διπλωματικής εργασίας δεν παρουσιάζεται κάποιος confusion matrix, καθώς λόγω του 9-fold cross-validation, που χρησιμοποιήθηκε, τα αποτελέσματα που παρουσιάζονται αποτελούν το μέσο όρο των αποτελεσμάτων των επιμέρους folds, ο υπολογισμός του οποίου δεν θα είχε νόημα για ακέραια μεγέθη, όπως είναι τα περιεχόμενα ενός confusion matrix).

		Actual Class	
		Class i	Other Class
Predicted Class	Class i	True-positive	False-positive
	Other Class	False-negative	True-negative

Πίνακας 7: Δομή confusion matrix

Υπόλοιπες Μετρικές

Όσον αφορά τις υπόλοιπες μετρικές αυτά υπολογίζονται μέσω της χρήσης των παραπάνω μεγεθών ως εξής.

Μετρική	Τύπος
Accuracy	$ACC = \frac{TP + TN}{TP + TN + FP + FN}$
Recall	$REC = \frac{TP}{TP + FN}$
Precision	$PRC = \frac{TP}{TP + FP}$
Error Rate	$ERR = \frac{FP + FN}{TP + TN + FP + FN}$
Micro Recall	$microREC = \frac{\sum_i TP_i}{\sum_i TP_i + \sum_i FN_i}$

Micro Precision	$microPRC = \frac{\sum_i TP_i}{\sum_i TP_i + \sum_i FP_i}$
Micro f1-score	$microF1 = 2 \cdot \frac{microPRC \cdot microREC}{microPRC + microREC}$
Macro Recall	$macroREC = \frac{\sum_i REC_i}{n}$
Macro Precision	$macroPRC = \frac{\sum_i PRC_i}{n}$
Macro f1-score	$macroF1 = 2 \cdot \frac{macroPRC \cdot macroREC}{macroPRC + macroREC}$

Πίνακας 8: Μετρικές αξιολόγησης αποτελεσμάτων

4.4 Τα Αποτελέσματα

Στο σημείο αυτό πρέπει να σημειωθεί πως το πλήθος των αποτελεσμάτων που συλλέχθηκαν είναι αρκετά μεγάλο για να παρουσιαστεί στα πλαίσια της παρούσας διπλωματικής καθώς μόνο τα διάφορα υποσύνολα επιλεγμένων χαρακτηριστικών φτάνουν τα 99, όπως αναφέρθηκε και παραπάνω, ενώ αν υπολογιστούν και οι συνδυασμοί των υποσυνόλων αυτών με τους 5 κατηγοριοποιητές που εξετάστηκαν αλλά και το πλήθος των διαφορετικών μοντέλων που προκύπτουν από την αναζήτηση που εκτελείται στο χώρο των υπερπαραμέτρων κάθε κατηγοριοποιητή, τότε γίνεται εύκολα κατανοητό το γεγονός ότι το πλήθος των εξαχθέντων αποτελεσμάτων υπερβαίνει ένα λογικό αριθμό που θα μπορούσε να παρουσιαστεί στα πλαίσια της εργασίας. Έτσι, αποφασίστηκε να παρουσιαστούν μόνο τα “βέλτιστα” μοντέλα που προέκυψαν, τόσο από άποψη μεθόδων επιλογής όσο και κατηγοριοποιητών. Εξετάζοντας αναλυτικά τα αποτελέσματα κάθε μοντέλου παρατηρήθηκε πως οι καλύτερες συμπεριφορές καταγράφονταν στις περιπτώσεις που είχαμε τα υψηλότερα ποσοστά ακρίβειας (accuracy) με αποτέλεσμα να επιλεγούν τα συγκεκριμένα μοντέλα ως “βέλτιστα”. Πιο αναλυτικά, τα αποτελέσματα που συλλέχθηκαν ανήκουν στις εξής 2 κατηγορίες:


- Συγκριτικά αποτελέσματα μεταξύ κατηγοριοποιητών
- Συγκριτικά αποτελέσματα μεταξύ χαρακτηριστικών

Αναλυτικά κάθε κατηγορία αποτελεσμάτων παρουσιάζεται παρακάτω.


4.4.1 Συγκριτικά Αποτελέσματα μεταξύ Κατηγοριοποιητών

Στο πλαίσιο των αποτελεσμάτων αυτών ανήκουν κάποια τα συγκριτικά αποτελέσματα των βέλτιστων μοντέλων των κατηγοριοποιητών για κάθε μέθοδο επιλογής. Εκτός αυτού, στα παρακάτω γραφήματα παρουσιάζονται και οι


υπερπαραμέτροι κάθε βέλτιστου μοντέλου ανά μέθοδο επιλογής. Αρχικά, παρουσιάζονται τα αποτελέσματα που λάβαμε για κάθε μετρική.




Σχήμα 18: Accuracy κάθε κατηγοριοποιητή ανά μέθοδο Επιλογής




Σχήμα 19: Error Rate κάθε κατηγοριοποιητή ανά μέθοδο Επιλογής




Σχήμα 20: Macro f1-score κάθε κατηγοριοποιητή ανά μέθοδο Επιλογής




Σχήμα 21: Macro Recall κάθε κατηγοριοποιητή ανά μέθοδο Επιλογής




Σχήμα 22: Macro Precision κάθε κατηγοριοποιητή ανά μέθοδο Επιλογής



Σχήμα 23: Micro f1-score κάθε κατηγοριοποιητή ανά μέθοδο Επιλογής




Σχήμα 24: Micro Recall κάθε κατηγοριοποιητή ανά μέθοδο Επιλογής




Σχήμα 25: Micro Precision κάθε κατηγοριοποιητή ανά μέθοδο Επιλογής


Ακολούθως, παρουσιάζονται οι υπερπαράμετροι που έδωσαν τα βέλτιστα αποτελέσματα ανά μέθοδο επιλογής.




Σχήμα 26: Πλήθος χαρακτηριστικών ανά βέλτιστο μοντέλο




Σχήμα 27: Πλήθος γειτόνων της ReliefF μεθόδου ανά κατηγοριοποιητή



Σχήμα 28: Πλήθος δέντρων του κατηγοριοποιητή Random Forest ανά μέθοδο Επιλογής



Σχήμα 29: Πλήθος γειτόνων του κατηγοριοποιητή KNN ανά μέθοδο Επιλογής



Σχήμα 30: Πλήθος νευρώνων του δικτύου Deep Belief ανά μέθοδο Επιλογής

	ReliefF	Cohen's f^2	mRMR	Inf-FS
Κόστος	2^5	2^6	2^{10}	2^5
γ	2^{-11}	2^{-11}	2^{-12}	2^{-11}


Πίνακας 9: Βέλτιστοι Υπερπαράμετροι SVM ανά μέθοδο επιλογής

	QDA	KNN	Random Forest	SVM	DBN
Prior Selection Method	mRMR (MIQ Scheme)	mRMR (MIQ Scheme)	mRMR (MIQ Scheme)	ReliefF (25 γείτονες)	ReliefF (10 γείτονες)
α	0.1	0.1	0.6	0.5	0.8


Πίνακας 10: Βέλτιστοι παράμετροι Inf-FS μεθόδου ανά κατηγοριοποιητή

4.4.2 Συγκριτικά Αποτελέσματα μεταξύ Χαρακτηριστικών

Στο σημείο αυτό παρουσιάζεται το είδος των χαρακτηριστικών που επιλέχθηκαν σε κάθε βέλτιστο μοντέλο που προέκυψε. Τα χαρακτηριστικά αυτά φαίνονται στο ακόλουθα γραφήματα.



Σχήμα 31: Κατανομή των χαρακτηριστικών των βέλτιστων μεθόδων Επιλογής για πλήθος ίσο με 823



Σχήμα 32: Κατανομή χαρακτηριστικών των βέλτιστων μεθόδων Επιλογής για πλήθος ίσο με 1646

Κεφάλαιο 5 – Συμπεράσματα και Μελλοντικές Επεκτάσεις

Ολοκληρώνοντας την παρούσα μελέτη κρίνεται ωφέλιμο να γίνει αναφορά τόσο στη σημασία όσο και στην κατάλληλη ερμηνεία των αποτελεσμάτων που προέκυψαν από τη χρήση των προαναφερθέντων συστημάτων για την αναγνώριση συναισθήματος. Εκτός αυτού, στα πλαίσια του παρόντος κεφαλαίου θα παρουσιαστούν και κάποιες σκέψεις και ιδέες για πιθανές μελλοντικές επεκτάσεις των τεχνικών που χρησιμοποιήθηκαν με σκοπό τόσο την επίτευξη καλύτερων αποτελεσμάτων όσο και την ανάδειξη πτυχών της αναγνώρισης συναισθήματος που δεν αναλύθηκαν στα πλαίσια της παρούσας διπλωματική εργασία.

5.1 Συμπεράσματα

Στη παρούσα διπλωματική εργασία παρουσιάστηκε μία συγκριτική μελέτη μεταξύ διαφόρων ειδών εξαχθέντων χαρακτηριστικών, διαφόρων μεθόδων επιλογής χαρακτηριστικών καθώς και διαφόρων κατηγοριοποιητών με σκοπό την ανίχνευση συναισθήματος από βιοσήματα όπως τα EEGs. Από την πληθώρα των διαφορετικών συστημάτων ανίχνευσης συναισθήματος που προέκυψαν από το διακριτό συνδυασμό όλων των προαναφερθέντων διαφορετικών δομών σε κάθε επίπεδο της διαδικασίας κατηγοριοποίησης εύκολα γίνεται κατανοητό πως έχουν ανακύψει και ποικίλα συμπεράσματα τόσο για κάθε επίπεδο της διαδικασίας ξεχωριστά όσο και για το συνολικό συνδυασμό τους σε ένα ολοκληρωμένο σύστημα.

Αρχικά, όπως φαίνεται από τα σχήματα 18-25, τα οποία περιλαμβάνουν τα αποτελέσματα σχετικά με τις μετρούμενες μετρικές για τις διάφορες δομές των συστημάτων μηχανικής μάθησης που χρησιμοποιήθηκαν, για τους κατηγοριοποιητές SVM, Random Forest και DBN λαμβάνουμε αρκετά ικανοποιητικά αποτελέσματα (best mean accuracy > 85%, best mean (macro και micro) precision $\approx$ 80%, best mean (macro και micro) recall $\approx$ 80%, best mean (macro και micro) f1-score $\approx$ 80%), ενώ για τους εναπομείναντες 2 κατηγοριοποιητές (QDA και KNN), για τους οποίους δεν λαμβάνονται ιδιαίτερα “καλά” αποτελέσματα, αυτό είναι λογικό καθώς χρησιμοποιήθηκαν ως baseline methods, προκειμένου να ελεγχθεί η απόδοση της μεθόδου και σε σχετικά απλούς κατηγοριοποιητές (μάλιστα τα αποτελέσματα τους είναι κάθε άλλο παρά απογοητευτικά). Πιο αναλυτικά, σχετικά με τα αποτελέσματα που λαμβάνονται από τους κατηγοριοποιητές SVM, Random Forest και DBN παρατηρείται ότι ο SVM παρουσιάζει συνολικά τους πιο υψηλούς δείκτες σε όλες τις μετρικές για την περίπτωση χρήσης της μεθόδου ReliefF για την επιλογή των χαρακτηριστικών. Γενικά η περίπτωση της ReliefF παράγει τα καλύτερα αποτελέσματα και για τους 2 άλλους κατηγοριοποιητές συγκριτικά με τις υπόλοιπες μεθόδους επιλογής με τη μέθοδο Inf-FS να ακολουθεί. Μάλιστα, η συγκεκριμένη μέθοδος επιλογής παράγει καλύτερα αποτελέσματα για τους κατηγοριοποιητές

Random Forest και DBN από ότι για τον SVM. Τέλος, οι μέθοδοι Cohen's f^2 και mRMR παράγουν αντίστοιχα αποτελέσματα με μία σημαντική διαφορά όσον αφορά τα DBN στα οποία η δεύτερη μέθοδος δεν είναι τόσο αποδοτική. Με βάση τα παραπάνω μπορούν να εξαχθούν τα ακόλουθα γενικά συμπεράσματα για την απόδοση της εξεταζόμενης μεθόδου σε σχέση με τους κατηγοριοποιητές και τις μεθόδους επιλογής που εξετάστηκαν:

- Μπορούμε να συμπεράνουμε πως γενικά η πρόκληση της αναγνώρισης συναισθήματος από σήματα EEG μέσω των συστημάτων που αναπτύχθηκαν στο πλαίσιο της παρούσας εργασίας αντιμετωπίστηκε επιτυχώς καθώς τόσο οι πιο ανεπτυγμένες μέθοδοι κατηγοριοποίησης (SVM, DBN, Random Forest) όσο και οι baseline μέθοδοι (QDA, KNN) παρουσιάζουν αξιοπρεπή αποτελέσματα. Έτσι, δεδομένου ότι το σύνολο δεδομένων μας αποτελούταν από παρατηρήσεις από διαφορετικά άτομα μπορούμε να συμπεράνουμε πως η μέθοδος που ακολουθήθηκε μπορεί να γενικευτεί για τελείως διαφορετικά άτομα και όχι μόνο για το ίδιο άτομο σε διαφορετικές χρονικές στιγμές όπως ισχύει στις περισσότερες σύγχρονες εργασίες [2], [7].
- Εκτός αυτού, βλέπουμε πως οι διαφορές στις αποδόσεις μεταξύ των κατηγοριοποιητών SVM και Random Forest είναι σχετικά μικρές εγείροντας έτσι το ερώτημα του αν είναι προτιμότερο να χρησιμοποιηθεί μία σχετικά ακριβή υπολογιστικά τεχνική κατηγοριοποίησης (SVM) προκειμένου να ληφθούν τα βέλτιστα δυνατά αποτελέσματα ή να θυσιάσθει ένα μικρό μέρος της απόδοσης, αλλά να χρησιμοποιηθεί ένας αρκετά “ελαφρύτερος” και ταχύτερος κατηγοριοποιητής (Random Forest). Πέραν αυτού στις παρούσες υλοποιήσεις χρησιμοποιήθηκε μία σχετικά απλή δομή του δικτύου Deep Belief, γεγονός που προσθέτει το δίκτυο αυτό στο εύρος του παραπάνω ερωτήματος. Βέβαια, αν ήταν διαθέσιμες αρκετά παραπάνω παρατηρήσεις ίσως να ήταν απαραίτητη και αρκετά βαθύτερη δομή νευρωνικού για την επίτευξη αξιολογών αποτελεσμάτων.
- Τέλος, παρατηρούμε πως τα σχετικά με τις μετρικές precision, recall και f1-score αποτελέσματα συμπίπτουν και σε μικροσκοπικό και σε μακροσκοπικό επίπεδο, κάτι που καταδεικνύει την ορθή συμπεριφορά των βέλτιστων συστημάτων τόσο σε συνολικό επίπεδο όσο και για τις επιμέρους κλάσεις. Βέβαια, αυτή η παρόμοια μακροσκοπική και μικροσκοπική συμπεριφορά ήταν αναμενόμενη καθώς τα δείγματα κάθε κλάσης ήταν ισοπληθή.

Εκτός αυτών, συλλέχθηκαν στοιχεία και σχετικά με το καταλληλότερο πλήθος χαρακτηριστικών για κάθε σύστημα. Όπως έχει αναφερθεί και παραπάνω από το εκτεταμένο σύνολο των 16460 εξαχθέντων χαρακτηριστικών εν τέλει αξιολογικά αποτελέσματα λήφθηκαν από ένα μικρό υποσύνολο αυτών που δεν υπερέβαινε το 10% του συνόλου. Έτσι, όπως φαίνεται και από το σχήμα 26 για τα περισσότερα μοντέλα που χρησιμοποιήθηκαν καλύτερα αποτελέσματα δόθηκαν με τη χρήση 823 χαρακτηριστικών (5%) με εξαίρεση τα μοντέλα

- Selection method: Cohen's f^2 Classifier: QDA

- Selection method: Inf-FS Classifier: QDA
- Selection method: Inf-FS Classifier: Random Forest

όπου και παρήχθησαν καλύτερα αποτελέσματα από τη χρήση 1646 χαρακτηριστικών (10%). Βέβαια, δεδομένου ότι ο κατηγοριοποιητής QDA χρησιμοποιήθηκε κυρίως ως baseline method ουσιαστικά μόνο σε έναν σημαντικό κατηγοριοποιητή χρειάστηκαν πάνω από το 5% του συνόλου των εξαχθέντων χαρακτηριστικών για την παραγωγή αξιολογών αποτελεσμάτων, κάτι που επιβεβαιώνει και τον ισχυρισμό πως λόγω του μικρού πλήθους των δειγμάτων του συνόλου δεδομένων δυσανάλογα πολλά χαρακτηριστικά θα οδηγούσαν σε χειρότερα αποτελέσματα. Ακολούθως συλλέχθηκαν και κάποια στοιχεία σχετικά με τις υπερπαραμέτρους κάθε μοντέλου που μας έδωσαν τα καλύτερα αποτελέσματα και τα οποία παρουσιάζονται στα σχήματα 27-30 και τους πίνακες 9 και 10.

Τέλος, η επιλεκτική χρήση των χαρακτηριστικών που αναφέρθηκε παραπάνω δεν έγινε τυχαία αλλά μέσω των αποτελεσμάτων που μας έδωσαν οι μέθοδοι επιλογής χαρακτηριστικών που έχουν αναλυθεί σε παραπάνω κεφάλαια, γεγονός που καθιστά ενδιαφέρουσα και τη μελέτη του τύπου των χαρακτηριστικών που επιλέχθηκαν. Πιο αναλυτικά, όπως φαίνεται και από τα σχήματα 31 και 32, οι κυρίαρχοι τύποι χαρακτηριστικών είναι οι ακόλουθοι:

- STFT
- Discrete Wavelet Transform “db4”
- Higher Order Crossings
- Signal Statistics

τα χαρακτηριστικά των οποίων και επιλέχθηκαν κατά κόρον από όλες τις μεθόδους επιλογής που δοκιμάστηκαν σε αντίθεση με τα χαρακτηριστικά των κατηγοριών HHS και HOS τα οποία επιλέχθηκαν από ελάχιστα έως και καθόλου. Παρατηρούμε, επομένως, πως ακόμη και αν θεωρηθεί πως τα χαρακτηριστικά της κατηγορίας STFT έχουν επιλεγεί κατά κόρον λόγω και της κυριαρχίας της κατηγορίας αυτής στο σύνολο των χαρακτηριστικών, ο ισχυρισμός αυτός δεν μπορεί να γενικευτεί, καθώς κάτι αντίστοιχο δεν ισχύει για τα HOS χαρακτηριστικά (2^η μεγαλύτερη κατηγορία) τα οποία και έχουν επιλεγεί ελάχιστες φορές. Έτσι, γίνεται εύκολα κατανοητό πως όντως οι χρησιμοποιημένες μέθοδοι επιλογής δεν έχουν περιοριστεί στα επικρατούντα χαρακτηριστικά, αλλά έχουν όντως επιλέξει τα πιο ταιριαστά από αυτά.

5.2 Μελλοντικές Επεκτάσεις

Στα πλαίσια της παρούσας διπλωματικής, όπως αναφέρθηκε και παραπάνω, εκτελέστηκε κυρίως μία συγκριτική μελέτη μεταξύ της απόδοσης διαφορετικών προσεγγίσεων για την ανίχνευση συναισθήματος από σήματα EEG με αποτέλεσμα να δοθεί μεγαλύτερη βάση στην επιλογή μίας ευρείας ποικιλίας τόσο χαρακτηριστικών

όσο και μεθόδων επιλογής και κατηγοριοποίησης προκειμένου να μελετηθούν και να συγκριθούν τα αποτελέσματά που θα επιδείκνυαν συνδυαστικά. Το γεγονός αυτό είχε ως αποτέλεσμα να μην δοθεί αντίστοιχη έμφαση σε κάποια τεχνικά ζητήματα που θα μπορούσαν να βελτιώσουν υπό προϋποθέσεις τα εξαχθέντα αποτελέσματα καθώς και να προσθέσουν επιπλέον ανθεκτικότητα σε αυτά. Προς αυτήν την κατεύθυνση θα μπορούσαν να κινηθούν μελλοντικές μελέτες στο χώρο της αναζήτησης συναισθήματος έχοντας ως βάση την παρούσα διπλωματική εργασία.

Πιο αναλυτικά, παρατίθενται ακολούθως κάποια θέματα τα οποία θα μπορούσαν να ερευνηθούν σε μεγαλύτερο βάθος μελλοντικά:

- Δεδομένου ότι κάθε κατηγορία εξαχθέντων χαρακτηριστικών συνδέεται άμεσα με το σήμα που λήφθηκε από το εκάστοτε ηλεκτρόδιο του ηλεκτροεγκεφαλογράφου γίνεται εύκολα κατανοητό πως η τελική απόδοση ενός συστήματος μηχανικής μάθησης για την ανίχνευση συναισθήματος μέσω των σημάτων EEG επηρεάζεται άμεσα από την ποιότητα των σημάτων που δίδονται από κάθε ηλεκτρόδιο. Έτσι, θα ήταν επιθυμητό ως ένα βήμα προεπεξεργασίας να ανιχνευθούν και τα ηλεκτρόδια των οποίων τα συμβαλλόμενα χαρακτηριστικά δεν παρουσιάζουν ιδιαίτερο ενδιαφέρον για το πρόβλημα που αντιμετωπίζεται με στόχο να αφαιρεθούν από το τελικό στάδιο της επεξεργασίας ώστε να αποφευχθεί η επιρροή τους στη διαδικασία της κατηγοριοποίησης και πιθανότατα να προκύψουν “καλύτερα” αποτελέσματα.
- Σε συνέχεια της παραπάνω επέκτασης θα ήταν θεμιτό να ανιχνευθούν και τα ηλεκτρόδια που δίνουν τα πιο αξιόλογα και αξιόπιστα χαρακτηριστικά και να εξεταστεί κατά πόσο τα συγκεκριμένα ηλεκτρόδια συνεχίζουν να δίνουν τα πιο αξιόπιστα χαρακτηριστικά σε διάφορα σύνολα δεδομένων προκειμένου να εξεταστεί η δυνατότητα σύνδεσης συγκεκριμένων περιοχών του ανθρωπίνου εγκεφάλου με την ανίχνευση συναισθήματος.
- Ένα ακόμη ζήτημα που προέκυψε κατά την εκτέλεση των διαφόρων πειραμάτων στη μελέτη μας αφορούσε τα μη ενθαρρυντικά αποτελέσματα που προέκυψαν αρχικά από τη χρήση βαθέων αρχιτεκτονικών στα δίκτυα DBN γεγονός που αποδόθηκε στο μικρό πλήθος των διαθέσιμων δειγμάτων σε σχέση με εκείνο των διαθέσιμων χαρακτηριστικών με αποτέλεσμα να οδηγηθούμε στη χρήση πιο απλών αρχιτεκτονικών. Έτσι, θα ήταν επιθυμητό να ελεγχθεί αν με τη χρήση μεγαλύτερων συνόλων δεδομένων κάποιες αρχιτεκτονικές βαθέων νευρωνικών δικτύων θα μπορούσαν να παράξουν ακόμη καλύτερα αποτελέσματα από εκείνα που λήφθηκαν στα πλαίσια της παρούσας διπλωματικής από σχετικά απλές δομές.
- Επίσης, θα ήταν επιθυμητό να υπολογιστούν και τα αποτελέσματα των διαφόρων χρησιμοποιηθέντων διατάξεων μηχανικής μάθησης ανά ζώνη συχνότητας των εγκεφαλικών σημάτων από τα οποία προέκυψαν (delta, theta, alpha, beta, gamma) ώστε να εξεταστεί κάποια πιθανή σύνδεση μεταξύ της αναγνώρισης συναισθήματος και συγκεκριμένων ζωνών συχνοτήτων.

- Τέλος, ενδιαφέρον θα συγκέντρωνε και η χρήση δομών μη επιβλεπόμενης μάθησης για την προσέγγιση του προβλήματος που αντιμετωπίστηκε στα πλαίσια της παρούσας διπλωματικής, μία προσέγγιση η οποία απουσιάζει σε μεγάλο βαθμό από τα state-of-the-art συστήματα που έχουν αναπτυχθεί στο χώρο αυτό.

Βιβλιογραφία

- [1] Rosalind W. Picard, “Affective Computing”, *M.I.T Media Laboratory Perceptual Computing Section Technical Report No. 321*, 1995
- [2] Xiao-Wei Wang, Dan Nie, and Bao-Liang Lu, “Emotional State Classification from EEG Data Using Machine Learning Approach”, *ScienceDirect, Elsevier, Neurocomputing*, vol.129, pp.94-106, 2014.
- [3] Claudio Carvalhaes and J. Acacio de Barros, “The surface Laplacian technique in EEG: Theory and methods”, *International Journal of Psychophysiology*, vol. 97, no. 3, pp. 174-188, 2015.
- [4] D. Sammler, M. Grigutsch, T. Fritz, and S. Koelsch, “Music and Emotion: electrophysiological correlates of the processing of pleasant and unpleasant music”, *Physiology*, vol. 44, no. 2, pp. 293-304, 2007.
- [5] D. Mathersul, L. M. Williams, P. J. Hopkinson, and A. H. Kemp, “Investigating models of affect: relationships among EEG alpha asymmetry, depression, and anxiety”, *Emotion*, vol. 8, no. 4, pp. 560-572, 2008.
- [6] Robert Jenke, Angelika Peer, and Martin Buss, “Feature Extraction and Selection for Emotion Recognition from EEG”, *IEEE Transactions on Affective Computing* , vol.5, no. 3, pp. 327-339, 2014.
- [7] Wei-Long Zheng and Bao-Liang Lu, “Investigating Critical Frequency Bands and Channels for EEG-based Emotion Recognition with Deep Neural Networks”, *IEEE Transactions on Autonomous Mental Development*, vol. 7, no. 3, pp. 162-175,2015.
- [8] X. Wang. D. Nie, and B. Lu, “EEG-based emotion recognition using frequency domain features and support vector machines”, in *Proc. Int. Conf. Neural Inf. Process*, pp. 734-743, 2011.
- [9] Robert Jenke, Angelika Peer, and Martin Buss, Effect-Size-Based Electrode and Feature Selection for Emotion Recognition from EEG, *2013 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2013.
- [10] Bo Hjorth, “EEG Analysis Based on Time Domain Properties”, *Electroencephalography and Clinical Neurophysiology*, vol. 29, no. 3, pp. 306-310, 1970.
- [11] E. Kroupi, A. Yazdani, and T. Ebrahimi, “EEG correlates of different emotional states elicited during watching music videos”, in *Proc. Int. Conf. Affect. Comput. Intell. Interact.*, pp. 457-466, 2011.
- [12] P. C. Petrantonakis and L. J. Hadjileontiadis, “Emotion Recognition From EEG Using Higher Order Crossings”, *IEEE Trans. Inf. Technol. Biomed.*, vol. 14, no. 2, pp. 186-197, March 2010.
- [13] S. Hosseini, M. Khalilzadeh, M. Naghibi-Sistani, and V. Niazmand, “Higher Order Spectra Analysis of EEG Signals in Emotional Stress States”, *Proc. IEEE International Conference on Information Technology and Computer Science*,pp. 60–63, 2010.

- [14] A. Swami, J. Mendel, and C. Nikias (2000). Higher-order spectra analysis (HOSA) toolbox, version 2.0.3 [Online]. Available: www.mathworks.com/matlabcentral/fileexchange/3013/
- [15] Stelios K. Hadjidimitriou and Leontios J. Hadjileontiadis, "Towards an EEG-Based Recognition of Music Liking Using Time-Frequency Analysis", *IEEE Transactions on Biomedical Engineering*, vol. 59, no. 12, pp 3498-3510, 2012.
- [16] Chethan Parameswariah and Mickey Cox, "Frequency Characteristics of Wavelets", *IEEE Trans. Power Delivery*, vol. 17, no. 3, pp. 800-804, July 2002.
- [17] Christos A. Frantzidis, Charalampos Bratsas, Christos L. Papadelis, Evdokimos Konstantinidis, Costas Pappas, and Panagiotis D. Bamidis, "Toward Emotion Aware Computing: An Integrated Approach Using Multichannel Neurophysiological Recordings and Affective Visual Stimuli", *IEEE Trans. Inf. Technol. Biomed.*, vol. 14, no. 3, pp. 589-597, May 2010.
- [18] M. Robnik-Sikonja and I. Kononenko, "Theoretical and empirical analysis of ReliefF and RReliefF," *Machine Learning*, vol. 53, pp. 23–69, 2003.
- [19] Hanchuan Peng, Fuhui Long, and Chris Ding, "Feature Selection Based on Mutual Information: Criteria of Max-Dependency, Max-Relevance, and Min-Redundancy", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 27, no.8, 2005.
- [20] Arielle S. Selya, Jennifer S. Rose, Lisa C. Dierker , Donald Hedeker , and Robin J. Mermelstein, "A practical guide to calculating Cohen's f^2 , a measure of local effect size, from PROC MIXED", *Frontiers in Psychology*, 2012.
- [21] Giorgio Roffo, Simone Melzi, and Marco Cristani, "Infinite Feature Selection", *2015 IEEE International Conference on Computer Vision (ICCV)*, 2015.
- [22] Pascal Ackermann, Christian Kohlschein, Jo AgilaBitsch, Klaus Wehrle, and Sabina Jeschke, "EEG-based Emotion Recognition: Feature Extraction, Selection and Classification Methods", *2016 IEEE 18th International Conference on e-Health Networking, Applications and Services (Healthcom)*, 2016.
- [23] Chih-Chung Chang and Chih-Jen Lin, "LIBSVM: A Library for Support Vector Machines", *ACM Transactions on Intelligent Systems and Technology (TIST)*, vol.2, no. 3, pp. 27, 2011.
- [24] Wei-long Zheng, Hao-Tian Guo, and Bao-Liang Lu, "Revealing Critical Channels and Frequency Bands for Emotion Recognition from EEG with Deep Belief Network", *7th Annual International IEEE EMBS Conference on Neural Engineering Montpellier, France, 22-24 April, 2015*.
- [25] M. Längkvist, L. Karlsson, and A. Loutfi, "Sleep Stage Classification Using Unsupervised Feature Learning", *Advances in Artificial Neural Systems*, 2012.

- [26] D. Wulsin, J. Gupta, R. Mani, J. Blanco, and B. Litt, “Modelling Electroencephalography Waveforms with Semi-Supervised Deep Belief Nets: Fast Classification and Anomaly Measurement”, *Journal of Neural Engineering*, vol. 8, no. 3, p. 036015, 2011.