



ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ

ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ

ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ ΒΙΟΪΑΤΡΙΚΗΣ

Χρήση Αλγορίθμων Μηχανικής Μάθησης για την ταξινόμηση καταθλιπτικών καταστάσεων

Καραμουλά Λεμονιά
Αριθμός Μητρώου: 19388037

Επιβλέπων Καθηγητής
Σπυρίδων Κωστόπουλος, Αναπληρωτής Καθηγητής

Αθήνα, Σεπτέμβριος 2024

Η Τριμελής Εξεταστική Επιτροπή

Ο Επιβλέπων Καθηγητής

Σπυρίδων Κωστόπουλος

Αναπληρωτής Καθηγητής

[ΨΗΦΙΑΚΗ ΥΠΟΓΡΑΦΗ]

Δημήτριος Γκλώτσος

Καθηγητής

[ΨΗΦΙΑΚΗ ΥΠΟΓΡΑΦΗ]

Παντελεήμων Ασβεστάς

Καθηγητής

[ΨΗΦΙΑΚΗ ΥΠΟΓΡΑΦΗ]

ΔΗΛΩΣΗ ΣΥΓΓΡΑΦΕΑ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ

Η υπογράφουσα Καραμουλά Λεμονιά του Ηλία, με αριθμό μητρώου 19388037 φοιτήτρια του Τμήματος Μηχανικών Βιοϊατρικής της Σχολής Μηχανικών του Πανεπιστημίου Δυτικής Αττικής, δηλώνω υπεύθυνα ότι:

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

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

Ημερομηνία

27/9/2024

Η Δηλούσα



Λεμονιά Καραμουλά

Περίληψη

Σκοπός της παρούσας διπλωματικής εργασίας είναι η χρήση αλγορίθμων Μηχανικής Μάθησης για την Ταξινόμηση Καταθλιπτικών Καταστάσεων. Επικεντρώνεται στη χρήση των τεχνικών αυτών για την κατηγοριοποίηση δεδομένων που σχετίζονται με καταθλιπτικές διαταραχές. Η μελέτη αναλύει τον τρόπο με τον οποίο η κινητική δραστηριότητα των ατόμων συνδέεται με τις ψυχικές τους καταστάσεις και προτείνει αλγορίθμους για την ταξινόμηση αυτών των δεδομένων. Χρησιμοποιήθηκαν τα δεδομένα της βάσης “[Depresjon](#)” από το ελεύθερα διαθέσιμο αποθετήριο [Simula](#). Συνολικά, υπάρχουν τρεις κατηγορίες στις οποίες κατατάσσονται οι ασθενείς. Στην πρώτη κατηγορία κατατάσσονται τα άτομα τα οποία έχουν διαγνωσθεί με μονοπολική διαταραχή. Στη δεύτερη κατηγορία ανήκουν οι ασθενείς με διπολική διαταραχή. Και στη τρίτη κατηγορία ταξινομούνται όλα τα υγιή άτομα. Για όλους τους ασθενείς δίνονται πληροφορίες σχετικά με την ημερήσια καταγραφή της κινητικής τους δραστηριότητας για κάποιες ημέρες.

Στο θεωρητικό μέρος, παρουσιάζονται οι διαφορές μεταξύ μονοπολικής και διπολικής διαταραχής, οι μηχανισμοί της κινητικής δραστηριότητας, καθώς και εργαλεία όπως το Actiwatch, που χρησιμοποιούνται για την παρακολούθηση αυτών των δεδομένων. Επίσης, αναλύονται οι βασικές αρχές και τα κριτήρια αξιολόγησης των αλγορίθμων μηχανικής μάθησης (π.χ. ακρίβεια, ευαισθησία, F1-score κτλπ.) που εφαρμόζονται στην ταξινόμηση των δεδομένων.

Στο πειραματικό μέρος, χρησιμοποιούνται τα δεδομένα της εν λόγω βάσης για τη μελέτη της κινητικής δραστηριότητας ατόμων με καταθλιπτικές διαταραχές από τις ημερήσιες καταγραφές. Γίνονται πειράματα με διάφορους ταξινομητές σε πρόβλημα δύο και τριών κλάσεων, με χρήση των τεχνικών αξιολόγησης, διασταυρούμενης επικύρωσης (Cross Validation) και επικύρωση με παρακράτηση (Holdout Validation). Επίσης γίνεται χρήση των στατιστικών τεχνικών Kruskal Wallis και ANOVA.

Τα βέλτιστα ποσοστά ταξινόμησης που επιτυγχάνονται είναι 80.7% στη ταξινόμηση δύο κλάσεων και 69.6% στη ταξινόμηση τριών κλάσεων. Συγκεκριμένα, στη ταξινόμηση δύο κλάσεων, των χρονικών παραθύρων καταγραφής κινητικής δραστηριότητας των καταθλιπτικών και των υγιών ατόμων, το βέλτιστο ποσοστό 80.7% επιτυγχάνεται με τον Weighted KNN και τη χρήση της μεθόδου Holdout Validation ενώ στην ταξινόμηση τριών κλάσεων, των χρονικών παραθύρων καταγραφής κινητικής δραστηριότητας των μονοπολικών καταθλιπτικών, των διπολικών καταθλιπτικών και των υγιή ατόμων, το βέλτιστο ποσοστό 69.6% επιτυγχάνεται με τον Ensemble Bagged Trees και χρήση της μεθόδου Cross Validation και Kruskal Wallis Test. Τέλος, προτείνονται βελτιώσεις για τη δημιουργία ενός εύρωστου μοντέλου για την καλύτερη πρόβλεψη και ανάλυση των καταθλιπτικών καταστάσεων και την πιο εν τω βάθει μελέτη.

Η εφαρμογή των αλγορίθμων μηχανικής μάθησης σε δεδομένα που αφορούν τη ψυχική υγεία, με έμφαση στη διασύνδεση κινητικής δραστηριότητας και καταθλιπτικών συμπτωμάτων, μπορεί να προσφέρει ποσοτική πληροφορία στην ταξινόμηση των καταθλιπτικών καταστάσεων και στη μελέτη της κατάθλιψης.

Λέξεις κλειδιά: Κινητική Δραστηριότητα, Μονοπολική Διαταραχή, Διπολική Διαταραχή, MADRS κλίμακα, Μηχανική Μάθηση, Ταξινόμηση, MATLAB

Abstract

The purpose of this thesis is the use of Machine Learning algorithms for the Classification of Depressive States. It focuses on utilizing these techniques to categorize data related to depressive disorders. The study analyzes how individuals' physical activity is connected to their mental states and proposes algorithms for classifying this data. The “[Depresjon](#)” dataset, available from the [Simula](#) open repository, was used. Overall, there are three categories in which patients are classified. The first category includes individuals diagnosed with unipolar disorder. The second category comprises patients with bipolar disorder. The third category contains all healthy individuals. For all patients, information is provided for the daily recording of their physical activity over several days

In the theoretical section, the differences between unipolar and bipolar disorder are presented, along with the mechanisms of physical activity and tools such as Actiwatch, which are used for monitoring this data. Additionally, the fundamental principles and evaluation criteria of machine learning algorithms (e.g., precision, recall, F1-score, etc.) applied in data classification are analyzed.

In the experimental section, the data from the aforementioned database is used to study the motor activity of individuals with depressive disorders based on daily recordings. Experiments are conducted with various classifiers in both two-class and three-class problems, utilizing Cross Validation and Holdout Validation evaluation techniques. Statistical techniques such as Kruskal-Wallis and ANOVA are also used.

The optimal classification rates achieved are 80.7% for two-class classification and 69.6% for three-class classification. Specifically, for the two-class classification, between motor activity time windows of depressive and healthy individuals, the optimal rate of 80.7% is achieved with the Weighted KNN and Holdout Validation method. For the three-class classification, between motor activity time windows of unipolar depressive, bipolar depressive, and healthy individuals, the optimal rate of 69.6% is achieved with the Ensemble Bagged Trees, Cross Validation method, and Kruskal-Wallis Test. Finally, improvements are proposed for the creation of a robust model for better prediction and analysis of depressive states and for more in-depth study.

The application of machine learning algorithms to data related to mental health, with an emphasis on the connection between physical activity and depressive symptoms, can provide quantitative information for the classification of depressive states and the study of depression.

Keywords: Motor Activity, Unipolar Disorder, Bipolar Disorder, MADRS Scale, Machine Learning, Classification, MATLAB

Ευχαριστίες

Πρώτα απ' όλα θα ήθελα να ευχαριστήσω τον επιβλέποντα καθηγητή μου, Σπυρίδων Κωστόπουλο για την καθοδήγηση και την εμπιστοσύνη του καθ' όλη τη διάρκεια εκπόνησης της διπλωματικής μου εργασίας.

Ακόμη, ευχαριστώ τους φίλους και συμφοιτητές μου για την υποστήριξη και την πολύτιμη βοήθεια τους.

Τέλος, ευχαριστώ ιδιαίτερα τους γονείς μου και το σύντροφο μου που μου έδωσαν τη δυνατότητα να εκπληρώσω το όνειρο μου στηρίζοντας με ο καθένας με το δικό του τρόπο.

Περιεχόμενα

Περίληψη	4
Abstract	5
Ευχαριστίες	6
Περιεχόμενα.....	7
Θεωρητικό μέρος	9
Εισαγωγή	9
1. Μονοπολική διαταραχή - Unipolar depression.....	10
1.1. Συμπτώματα.....	10
1.2. Παράγοντες εμφάνισης της νόσου.....	11
1.3. Αντιμετώπιση.....	11
2. Διπολική διαταραχή - Bipolar depression.....	13
2.1. Συμπτώματα.....	13
2.2. Αξιολόγηση Συμπτωμάτων.....	14
2.3. Αιτίες.....	15
2.4. Θεραπεία.....	16
3. Κινητική δραστηριότητα - Motor Activity	18
3.1. Τύποι Κινητικής Δραστηριότητας	18
3.2. Μηχανισμοί Κινητικής Δραστηριότητας.....	18
3.3. Τεχνολογίες και Εργαλεία Παρακολούθησης.....	21
3.4. Ημερήσιες Μεταβολές στην Κινητική Δραστηριότητα και Φυσική Άσκηση ..	21
3.5. Κλινικές Εφαρμογές	21
4. Κλίμακα Αξιολόγησης Κατάθλιψης – Κλίμακα MADRS.....	23
4.1. Βασικά χαρακτηριστικά της κλίμακας MADRS	23
4.2. Χρήση της κλίμακας	23
4.3. Προέλευση και Ανάπτυξη.....	24
5. Φορετές συσκευές καταγραφής κινητικής δραστηριότητας.....	26
5.1. Χαρακτηριστικά του Actiwatch Model AW4.....	26
5.2. Εφαρμογές του Actiwatch AW4.....	27
5.3. Τεχνικά Χαρακτηριστικά.....	27
5.4. Λογισμικό και Ανάλυση Δεδομένων	28
5.5. Κλινικές Εφαρμογές και Έρευνα	28
6. Μέτρα Αξιολόγησης ταξινόμησης.....	29
6.1. Ευστοχία/Ακρίβεια - Precision	30
6.2. Ευαισθησία – Recall/Sensitivity	31
6.3. Ακρίβεια - Accuracy	31
6.4. Εξειδίκευση - Specificity	32
6.5. Συντελεστής Συσχέτισης του Matthews - Matthews correlation coefficient (MCC).....	33
6.6. F1-score (F1).....	33
6.7. Καμπύλη ROC & AUC – ROC Curve & AUC	34
7. Μηχανική Μάθηση και Ταξινομητές.....	37
7.1. Κατηγορίες Μηχανικής Μάθησης	37
7.2. Στοιχεία Μηχανικής Μάθησης	38
7.3. Προκλήσεις στη Μηχανική Μάθηση.....	39
7.4. Ταξινομητές	39
8. Στατιστική Ανάλυση.....	58
8.1. Matlab	58

8.2. Matlab - Classification learner app	58
8.3. Στατιστικό τεστ Kruskal Wallis - Kruskal Wallis Statistical Test.....	59
8.4. Στατιστική μέθοδος ANOVA - ANOVA Statistical Method	60
8.5. Διασταυρούμενη Επικύρωση - Cross Validation	62
8.6. Επικύρωση με Παρακράτηση - Holdout Validation.....	63
8.7. Χαρακτηριστικά.....	63
Πειραματικό Μέρος	66
9. Πειραματική Διαδικασία.....	66
9.1. Υλικό.....	66
9.2. Επεξεργασία δεδομένων	67
9.3. Ταξινόμηση και Αξιολόγηση.....	68
9.4. Ταξινόμηση με βάση την ιεράρχηση της σημαντικότητας των χαρακτηριστικών με στατιστικά κριτήρια	69
10. Αποτελέσματα.....	70
10.1. Ταξινόμηση στα χρονικά παράθυρα καταγραφής κινητικής δραστηριότητας των υγιών και καταθλιπτικών ατόμων με τρία χαρακτηριστικά.....	70
10.2. Ταξινόμηση στα χρονικά παράθυρα καταγραφής κινητικής δραστηριότητας των υγιών και καταθλιπτικών ατόμων με δεκαεπτά χαρακτηριστικά	71
10.3. Ταξινόμηση δεδομένων στα χρονικά παράθυρα καταγραφής της κινητικής δραστηριότητας των μονοπολικών καταθλιπτικών, των διπολικών καταθλιπτικών και των υγιών ατόμων με τρία χαρακτηριστικά	75
10.4 .Ταξινόμηση δεδομένων στα χρονικά παράθυρα καταγραφής της κινητικής δραστηριότητας των μονοπολικών καταθλιπτικών, των διπολικών καταθλιπτικών και των υγιών ατόμων με δεκαεπτά χαρακτηριστικά	76
11. Συμπεράσματα - Συζήτηση.....	81
12. Μελλοντικές Προοπτικές.....	82
Βιβλιογραφικές Πηγές	83
Συμπληρωματικό υλικό	87

Θεωρητικό μέρος

Εισαγωγή

Η εξέλιξη και ανάπτυξη των εργαλείων και συστημάτων αξιολόγησης και παρακολούθησης λειτουργιών του ανθρώπινου σώματος έδωσε τη δυνατότητα της λεπτομερούς μελέτης της κινητικής δραστηριότητας του ανθρώπου. Η συνεχής και αλματώδη βελτίωση των μηχανημάτων ως προς τους αισθητήρες κίνησης για μετρήσεις σε τρεις διαστάσεις, τη μνήμη για μακροπρόθεσμη παρακολούθηση, τη μπαταριά για αυξημένη λειτουργία, την αδιαβροχοποίηση για συνεχή χρήση, το λογισμικό για όλο και περισσότερες επιλογές δεδομένων ενίσχυσε την ακρίβεια της μελέτης και παρακολούθησης και κατ' επέκταση της θεραπείας. Παρόλα αυτά προβλήματα συνεχίζουν να υπάρχουν και οφείλονται στα τεχνικά χαρακτηριστικά και τις αστοχίες των συστημάτων.

Ταυτόχρονα η συνεχής βελτίωση του τομέα της πληροφορικής και των υπολογιστών και η ανάπτυξη της Τεχνητής Νοημοσύνης και της Μηχανικής μάθησης άνοιξε τους ορίζοντες για καινοτόμες εφαρμογές όπως η μελέτη των καταθλιπτικών καταστάσεων συγκριτικά με τη κινητική δραστηριότητα του ανθρώπου, που θα μελετηθεί στη παρούσα διπλωματική.

Οι τεχνικές της τεχνητής νοημοσύνης καθίσταται εργαλείο μελέτης σε πολλά επιστημονικά πεδία, με έντονη δραστηριότητα στην Ιατρική, τη Βιοϊατρική και τη Βιολογία και πιο συγκεκριμένα στη μελέτη δεδομένων που αφορούν ζωτικές λειτουργίες του ανθρώπινου σώματος. Οι μέθοδοι επεξεργασίας των ιατρικών πληροφοριών απαιτούν εξειδικευμένες στρατηγικές που βασίζονται κυρίως σε αλγορίθμους μηχανικής μάθησης. Το πεδίο της μηχανικής μάθησης έφερε μία επανάσταση στους αλγορίθμους που αναλύουν και ταξινομούν τα ιατρικά δεδομένα και συνεπώς στην ανάπτυξη software και hardware λογισμικών που υπόσχονται αυτοματοποιημένες λύσεις στην εξαγωγή χαρακτηριστικών, ταξινομήσεων και αποτελεσμάτων.

Έχοντας σχεδιάσει αλγορίθμους που ομαδοποιούν τα διαθέσιμα δεδομένα και παράγουν και πρόσθετα χαρακτηριστικά που μας ενδιαφέρουν επιλύσαμε ένα σημαντικό πρόβλημα. Πλέον χρησιμοποιώντας το Classification Learner App του Matlab επιτυγχάνουμε ταξινόμηση των επιθυμητών δεδομένων με πολλαπλούς ταξινομητές (SVMs, KNNs, Ensembles, Neural Networks, Naïve Bayes, QDA) και εφαρμόζουμε ANOVA και Kruskal Wallis Statistical Test προσφέροντας αυτοματοποιημένα αποτελέσματα.

Εκπαιδευοντας μεγάλο όγκο δεδομένων μπορούμε να δημιουργήσουμε ένα μοντέλο ικανό να ταξινομεί αποτελεσματικά διάφορων ειδών δεδομένα, ιδανικά και μη. Οπότε χρησιμοποιούμε ποικίλες τεχνικές ώστε να επιτευχθεί ο παραπάνω στόχος, καθώς φαινόμενα υπερπροσαρμογής εμφανίζονται συχνά. Ποικίλες τεχνικές ακολουθήθηκαν και μοντέλα αναπτύχθηκαν αξιολογώντας με διαφορετικά κριτήρια τα δεδομένα και την αποτελεσματικότητά τους, καθώς τελικός σκοπός είναι η ανάπτυξη ενός εύρωστου μοντέλου. Για το σκοπό αυτό συχνά χρησιμοποιούμε μοντέλα συνδυαστικά προσεγγίζοντας ένα πρόβλημα από διαφορετικές οπτικές γωνίες, αυξάνοντας την πιθανότητα για μία ικανοποιητική προσέγγιση.

1. Μονοπολική διαταραχή - Unipolar depression

Ως μια κοινή, εξουθενωτική και δυνητικά θανατηφόρα διαταραχή ή πάθηση ψυχικής υγείας θα μπορούσε να χαρακτηριστεί η κατάθλιψη καθώς τα συμπτώματα που την χαρακτηρίζουν μπορεί να είναι από ήπια έως σοβαρά. Πολλά εκατομμύρια άνθρωποι (πάνω από 300εκατομμύρια) πάσχουν από κατάθλιψη ενώ ραγδαία αύξηση παρατηρείται την τελευταία δεκαετία. Ένας στους δέκα ανθρώπους επηρεάζονται κάποια στιγμή της ζωής τους από κάποιο είδος κατάθλιψης. Γενικά τα κύρια συμπτώματα που παρατηρούνται σε αυτή τη κοινή διαταραχή περιλαμβάνουν έντονες εναλλαγές στη διάθεση αλλά και τα συναισθήματα του ασθενή. Παράλληλα παρουσιάζεται αισθητά μειωμένη η γνωστική λειτουργία, με κίνδυνο την κοινωνική εξέλιξη και συμπεριφορά του ατόμου. Άτομα με κατάθλιψη βλέπουν τον κόσμο μέσα από έναν παραμορφωμένο φακό, ο οποίος μπορεί να επηρεάσει το τι σκέφτονται και αισθάνονται για τους άλλους ανθρώπους και τον εαυτό τους. Ως αποτέλεσμα, μπορεί να αντιμετωπίσουν διαπροσωπικές συγκρούσεις, χαμηλή αυτοεκτίμηση, ευαισθησία απόρριψης και παρόμοιες προκλήσεις[69].

Η μονοπολική διαταραχή ή αλλιώς μείζον καταθλιπτικό επεισόδιο είναι διαφορετική από τη διπολική διαταραχή καθώς δεν παρουσιάζονται μανιακές ή υπομανιακές καταστάσεις. Το μονοπολικό αναφέρεται στην ιδέα ότι υπάρχει μόνο ένας 'πόλος' ή πλευρά στην ανώμαλη διάθεση. Στη διπολική διαταραχή υπάρχουν δύο πόλοι, η μανία και η κατάθλιψη. Η βασική διαφορά μεταξύ της μονοπολικής και διπολικής διαταραχής είναι ότι τα άτομα με μονοπολική διαταραχή βιώνουν μόνο κατάθλιψη και όχι κύκλους κατάθλιψης και μανίας που παρουσιάζονται στη διπολική διαταραχή. Τα άτομα με μονοπολική διαταραχή δεν είναι απαραίτητα πάντα καταθλιπτικοί, μερικοί μπορεί να φαίνονται χαρούμενοι, να προσποιούνται ότι είναι ευτυχισμένοι ή να βιώνουν στιγμές κατά τις οποίες τα συμπτώματα τους να παρουσιάζουν βελτίωση. Οι ασθενείς που παρουσιάζουν διπολική διαταραχή βιώνουν περιόδους κατάθλιψης(όπως και στη μείζονα κατάθλιψη) αλλά και περιόδους μανίας κατά τις οποίες η διάθεση τους είναι πολύ ανεβασμένη, είναι ασυνήθιστα ευτυχισμένοι και μπορούν να πάρουν παρορμητικές ή επιβλαβείς αποφάσεις.

1.1. Συμπτώματα

Η μονοπολική διαταραχή χαρακτηρίζεται από μια σειρά συμπτωμάτων που επηρεάζουν τόσο τη σωματική όσο και την ψυχική υγεία του ατόμου. Ένα από τα κύρια συμπτώματα είναι η απάθεια, όπου το άτομο νιώθει πλήρη αδιαφορία και έλλειψη αντίδρασης προς ανθρώπους, γεγονότα και καταστάσεις. Συνοδεύεται συχνά από έντονη θλίψη, με το άτομο να βιώνει συντριπτικά συναισθήματα απελπισίας, λύπης, αβεβαιότητας και κενού, ενώ μπορεί να κλαίει για μεγάλα χρονικά διαστήματα, αν και αυτό δεν ισχύει για όλους τους καταθλιπτικούς. Παράλληλα, η κόπωση είναι ένα άλλο σημαντικό σύμπτωμα, με το άτομο να νιώθει εξαντλημένο σωματικά και συναισθηματικά, γεγονός που επηρεάζει την καθημερινότητά του, συχνά σε συνδυασμό με προβλήματα ύπνου. Η ευερεθιστότητα επίσης είναι συχνή, καθώς το άτομο αισθάνεται θυμό και εκνευρισμό για πράγματα και ανθρώπους που παλαιότερα δεν το ενοχλούσαν, ενώ χάνει το ενδιαφέρον του για δραστηριότητες που άλλοτε απολάμβανε. Η επιβράδυνση στις σκέψεις, στις κινήσεις και στην ομιλία, καθώς και η δυσκολία στη συγκέντρωση, είναι επίσης συχνά φαινόμενα, ενώ ορισμένοι ασθενείς μπορεί να βιώσουν εγκεφαλική ομίχλη. Τέλος, η διαταραχή αυτή

συχνά συνοδεύεται από σωματικές διαταραχές όπως η απώλεια της όρεξης, οι αυξομειώσεις βάρους και η δυσκολία στην αυτοφροντίδα, ενώ οι σκέψεις ή τα σχέδια αυτοκτονίας μπορεί να είναι επαναλαμβανόμενες, με το άτομο να φαντασιώνεται συχνά το θάνατο ή την αυτοκτονία.

Η εμφάνιση των συμπτωμάτων της μονοπολικής διαταραχής μπορεί να προκληθεί ή να επιδεινωθεί από διάφορες καταστάσεις. Αυτές περιλαμβάνουν τον θάνατο αγαπημένου προσώπου, τη γέννηση παιδιού, μια κρίση στην επαγγελματική σταδιοδρομία, καθώς και ιατρικές παθολογικές καταστάσεις, όπως οι διαταραχές του θυρεοειδούς, οι οποίες επηρεάζουν σημαντικά τη διάθεση. Επιπλέον, η γενετική προδιάθεση παίζει σημαντικό ρόλο, καθώς οι πιθανότητες εμφάνισης κατάθλιψης είναι αυξημένες αν κάποιο συγγενικό πρόσωπο πάσχει από αυτήν. Η προηγούμενη εμπειρία με κατάθλιψη ή μια ιατρική κατάσταση που καθιστά τη ζωή πιο δύσκολη, καθώς και τα παιδικά τραύματα από δυσμενείς εμπειρίες, μπορούν επίσης να συμβάλουν στην εμφάνιση της διαταραχής. Τέλος, ακόμη και η έλλειψη ηλιακού φωτός κατά τη χειμερινή περίοδο μπορεί να αποτελέσει έναν επιπλέον παράγοντα που επιβαρύνει την κατάσταση[13].

Ωστόσο, η ύπαρξη μονοπολικής κατάθλιψης δεν σημαίνει ότι ένα άτομο έχει κατάθλιψη ανά πάσα στιγμή. Η εναλλαγή των περιόδων ύφεσης και υποτροπής της κατάθλιψης είναι ένα κοινό φαινόμενο στο άτομο με μείζονα καταθλιπτική διαταραχή. Το αίσθημα ευτυχίας μάλιστα μπορεί να εντείνεται κατά την αλλαγή των συνθηκών ειδικά στα περιστατικά ατόμων που πάσχουν από άτυπη κατάθλιψη, έναν υπότυπο της μείζονος καταθλιπτικής διαταραχής. Η άτυπη κατάθλιψη συνήθως είναι χρόνια αλλά τα συμπτώματά της είναι πιο ήπια και πιο διαχειρίσιμα σε περιόδους ύφεσης[75].

Υπάρχουν διάφορες μορφές κατάθλιψης που χαρακτηρίζονται ως μονοπολικές και δεν περιλαμβάνουν μανιακά επεισόδια εκτός από τη μείζονα καταθλιπτική διαταραχή. Μερικά παραδείγματα είναι η επιλόχειος κατάθλιψη που εμφανίζεται έπειτα από τη γέννηση ενός μωρού, η ψυχωτική κατάθλιψη που προκαλεί σκέψεις ψυχωσικές, που δεν συνδέονται με την πραγματικότητα όπως αυταπάτες, ψευδαισθήσεις, η εποχιακή συναισθηματική διαταραχή κυρίως κατά τους χειμερινούς μήνες λόγω έλλειψης ηλιακού φωτός και η επίμονη καταθλιπτική διαταραχή που είναι μία χρόνια μορφή κατάθλιψης αλλά με ήπια συμπτώματα.

1.2. Παράγοντες εμφάνισης της νόσου

Η εμφάνιση της μείζονος καταθλιπτικής διαταραχής καθορίζεται από έναν συνδυασμό γενετικών, ψυχολογικών και διαπροσωπικών αιτιών και καθίσταται μία πολύπλοκη κατάσταση. Δεν είναι πλήρως κατανοητή από τους ερευνητές η αιτία πρόκλησης της κατάθλιψης άλλα επιβεβαιωμένα σχετίζεται με διαταραχές που προκαλούνται στους νευροδιαβιβαστές που είναι χημικές ουσίες του εγκεφάλου.

Η σεροτονίνη, η νορεπινεφρίνη και η ντοπαμίνη είναι αντικαταθλιπτικές ουσίες που δρουν και επηρεάζουν τους νευροδιαβιβαστές και μάλιστα διαδραματίζουν σημαντικό ρόλο στη διάθεση.

1.3. Αντιμετώπιση

Εκτός από τα αντικαταθλιπτικά που θεραπεύουν αποτελεσματικά αρκετά περιστατικά ασθενών λαμβάνονται υπόψιν και άλλοι παράγοντες που περιλαμβάνουν την

γενικότερη υγεία του ατόμου, τις παρενέργειες και τον υπότυπο της κατάθλιψης. Επομένως η ανακούφιση των συμπτωμάτων ενός ατόμου ηγείται από μια σειρά διαδικασιών που περιλαμβάνουν εναλλαγή πολλών διαφορετικών φαρμάκων και διαφορετικών δοσολογιών. Μάλιστα η συζήτηση των ανησυχιών και παρενεργειών και η συνεργασία με κάποιον έμπειρο ψυχίατρο μπορεί να επιταχύνει ακόμη περισσότερο την εξάλειψη των συμπτωμάτων

Έχουν αναπτυχθεί και τεχνικές ψυχοθεραπείας αποκλειστικά για την κατάθλιψη που είναι αρκετά βοηθητικές και έχουν κύριο σκοπό να ωθήσουν το άτομο να πραγματοποιήσει θετικές αλλαγές και να διαχειριστεί τη ζωή. Αυτές είναι η γνωσιακή συμπεριφορική θεραπεία (CBT) και η διαπροσωπική θεραπεία.

Σε περίπτωση που οι αγωγές με αντικαταθλιπτικές ουσίες και τεχνικές ψυχοθεραπείας αποβούν μη αποτελεσματικές υπάρχουν κάποιες εναλλακτικές και πιο επεμβατικές θεραπείες που διεγείρουν άμεσα τον εγκέφαλο όπως η ηλεκτροσπασμοθεραπεία, η διέγερση του πνευμονογαστρικού νεύρου και η διακρανιακή μαγνητική διέγερση.

Βέβαια υπάρχουν και οι περιπτώσεις περιστατικών που με μία απλή προσαρμογή του τρόπου ζωής τους όπως περισσότερη άσκηση, ισορροπημένη διατροφή, διαλογισμός ή νέα χόμπι αντιμετωπίζουν μόνη τους τη κατάθλιψη [73].

2. Διπολική διαταραχή - Bipolar depression

Η διπολική διαταραχή ή αλλιώς μανιοκατάθλιψη όπως ονομαζόταν παλαιότερα είναι κι αυτή μία πάθηση ψυχικής υγείας που επηρεάζει σημαντικά τη διάθεση, την ενέργεια, τη συγκέντρωση και τη δραστηριότητα του ατόμου προκαλώντας ασυνήθιστες αλλαγές που πολλές φορές διαδραματίζουν καθοριστικό ρόλο στη καθημερινότητα. Υπάρχουν τρία είδη διπολικής διαταραχής:

Η διπολική διαταραχή τύπου I όπου για τουλάχιστον επτά ημέρες υπάρχουν μανιακά επεισόδια και μάλιστα για το μεγαλύτερο μέρος της ημέρας. Μάλιστα κάποιες φορές τα συμπτώματα είναι τόσο έντονα και σοβαρά που χρήζουν άμεση ιατρική βοήθεια. Τα καταθλιπτικά επεισόδια έχουν διάρκεια δύο εβδομάδων με πιθανότητα εμφάνισης συμπτωμάτων και κατάθλιψης και μανίας ταυτόχρονα δηλαδή επεισοδίων με ανάμεικτα χαρακτηριστικά,. Σε περίπτωση που τα περιστατικά μανίας ή κατάθλιψης είναι πάνω από 4 ανά έτος πρόκειται για "ταχεία ποδηλασία" όπως ονομάζεται.

Η διπολική διαταραχή τύπου II όπου παρατηρείται αλληλουχία υπομανιακών και καταθλιπτικών επεισοδίων. Ηπιότερης μορφής θα μπορούσαν να χαρακτηριστούν τα υπομανιακά επεισόδια συγκριτικά με τα μανιακά επεισόδια που παρατηρούνται στη διπολική διαταραχή τύπου I.

Και η κυκλοθυμική διαταραχή ή αλλιώς κυκλοθυμία όπου τα καταθλιπτικά και υπομανιακά περιστατικά είναι επαναλαμβανόμενα αλλά η σοβαρότητα και η διάρκεια τους δεν είναι αρκετή ώστε να χαρακτηριστούν υπομανιακά ή καταθλιπτικά επεισόδια

Βέβαια υπάρχουν και περιπτώσεις όπου τα συμπτώματα της διπολικής διαταραχής δεν ταυτίζονται με τις παραπάνω κατηγορίες χωρίς αυτό να σημαίνει ότι δεν επρόκειτο για κάποια διαταραχή. Ωστόσο αναφέρεται γενικά από την επιστημονική κοινότητα η ύπαρξη καθορισμένων και μη καθορισμένων διπολικών και σχετικών διαταραχών.

Τα συμπτώματα εμφανίζονται κυρίως κατά την εφηβική ηλικία ή τη πρώιμη ενήλικη ζωή χωρίς να εξαιρείται και η εμφάνιση σε παιδιά. Παρόλη τη ποικιλομορφία των συμπτωμάτων ανά χρονικά διαστήματα απαραίτητη καθίσταται η δια βίου θεραπεία. Επιβεβαιωμένα η συνταγογράφηση και η υιοθέτηση ενός σχεδίου θεραπείας μπορεί να έχει ευεργετικά αποτελέσματα στο τρόπο διαχείρισης των συμπτωμάτων και στη βελτίωση του τρόπου ζωής των ατόμων αυτών[47].

2.1. Συμπτώματα

Τα άτομα που εμφανίζουν διπολική διαταραχή βιώνουν κάποιες περιόδους όπου εμφανίζονται ασυνήθιστα έντονα συναισθήματα και αλλαγές στα επίπεδα δραστηριότητας, στα πρότυπα ύπνου και στις συμπεριφορές τους που πολλές φορές είναι άγνωστες γι αυτούς .Μάλιστα τις περισσότερες φορές δεν έχουν ενσυναίσθηση της βλαβερότητας και της επικινδυνότητας των καταστάσεων αυτών ούτε των ανεπιθύμητων συνεπειών. Αυτές οι διακριτές περίοδοι ονομάζονται επεισόδια διάθεσης και μπορεί να διαρκέσουν από μερικές ώρες της ημέρας έως αρκετές ημέρες

ή εβδομάδες. Γενικά στα επεισόδια διάθεσης τα άτομα παρουσιάζουν διαθέσεις και συμπεριφορές ασυνήθιστες και διαφορετικές από τα καθιερωμένα.

Πίνακας 2.1: Συμπτώματα μανιακών και καταθλιπτικών επεισοδίων

Συμπτώματα Μανιακών Επεισοδίων	Συμπτώματα Καταθλιπτικών Επεισοδίων
Αίσθημα μεγάλης ευδιαθεσίας, ευερεθιστότητας ή ευαισθησίας	Αίσθημα πίεσης, λύπης ή ανησυχίας
Υπερκινητικότητα, μεγαλύτερη δραστηριότητα από το συνηθισμένο	Αίσθημα επιβράδυνσης, κόπωσης-κούρασης
Μειωμένες ανάγκες ύπνου	Προβλήματα ύπνου
Γρήγορή ομιλία για πολλά και διαφορετικά πράγματα που μπορεί και να μην σχετίζονται ('flight of ideas')	Αργή ομιλία, αίσθημα ότι δεν έχεις κάτι να πεις ή ξεχνάς
Αγωνιστικές σκέψεις	Πρόβλημα συγκέντρωσης και λήψης αποφάσεων
Αίσθημα ικανότητας για πραγματοποίηση πολλών πραγμάτων ταυτόχρονα χωρίς κούραση	Αίσθημα ανικανότητας ακόμη και για βασικά πράγματα
Υπερβολικά αυξημένη όρεξη για ευχάριστες δραστηριότητες (φαγητό, ποτό, σεξ κλπ.)	Απουσία ενδιαφέροντος για το οτιδήποτε
Αίσθημα ασυνήθιστης δύναμης, ταλέντου και ότι είσαι σημαντικός και ικανός	Αίσθημα απελπισίας, αναξιοσύνης και σκέψεις θανάτου και αυτοκτονίας

Συχνά, οι άνθρωποι βιώνουν επεισόδια που συνδυάζουν διάφορα χαρακτηριστικά, δηλαδή παρουσιάζουν τόσο μανιακά όσο και καταθλιπτικά συμπτώματα. Αυτό σημαίνει ότι μπορεί να νιώθουν έντονα λυπημένοι, κενωμένοι ή απελπισμένοι, ενώ ταυτόχρονα να αισθάνονται εξαιρετικά ενεργητικοί. Ένα άτομο μπορεί να διαγνωστεί με διπολική διαταραχή, ακόμη και αν τα συμπτώματά του δεν είναι ιδιαίτερα ακραία. Για παράδειγμα, ορισμένα άτομα με διπολική διαταραχή τύπου II μπορεί να εμφανίζουν υπομανία, η οποία είναι μια λιγότερο σοβαρή μορφή μανίας. Κατά τη διάρκεια ενός υπομανιακού επεισοδίου, το άτομο μπορεί να αισθάνεται εξαιρετικά καλά, να είναι παραγωγικό και να διαχειρίζεται την καθημερινότητά του. Ενδέχεται το άτομο να μην αντιλαμβάνεται ότι υπάρχει κάποιο πρόβλημα, ωστόσο οι συγγενείς και οι φίλοι του μπορεί να παρατηρήσουν τις αλλαγές στη διάθεση ή τα επίπεδα δραστηριότητας ως πιθανά σημάδια διπολικής διαταραχής. Χωρίς την κατάλληλη θεραπεία, τα άτομα με υπομανία ενδέχεται να εξελιχθούν σε σοβαρή μανία ή κατάθλιψη [47].

2.2. Αξιολόγηση Συμπτωμάτων

Τα άτομα που πάσχουν από διπολική διαταραχή μπορούν να διατηρήσουν μια υγιή και ενεργή ζωή με τη λήψη σωστής διάγνωσης και θεραπείας. Οι πάροχοι υγειονομικής περίθαλψης μπορούν να παρέχουν μια φυσική εξέταση και να καθοδηγήσουν τον ασθενή στις απαραίτητες ιατρικές εξετάσεις ώστε να αποκλειστεί

το ενδεχόμενο ύπαρξης κάποιου άλλου παθολογικού αιτίου που προκαλεί τα συμπτώματα. Μετά την εκτίμηση των αποτελεσμάτων, είναι επιτακτική η αξιολόγηση της ψυχικής υγείας, είτε από τον ίδιο τον ασθενή είτε από έναν εκπαιδευμένο επαγγελματία ψυχικής υγείας, όπως ψυχίατρο, ψυχολόγο ή κλινικό κοινωνικό λειτουργό, ο οποίος διαθέτει εμπειρία στη διάγνωση και θεραπεία της διπολικής διαταραχής, προκειμένου να διασφαλιστεί η σωστή διάγνωση και θεραπεία.

Τα συμπτώματα, το βιογραφικό ενός ατόμου, οι εμπειρίες του και το οικογενειακό του ιστορικό είναι κρίσιμα στοιχεία που διευκολύνουν τους επαγγελματίες ψυχικής υγείας στη διάγνωση της διπολικής διαταραχής. Ιδιαίτερα για τη νεολαία, η διάγνωση αυτή αποκτά ιδιαίτερη σημασία.

Διπολική διαταραχή σε συνδυασμό με άλλες καταστάσεις

Πολλά άτομα με διπολική διαταραχή έχουν επίσης άλλες ψυχικές διαταραχές ή καταστάσεις όπως αγχώδεις διαταραχές, διαταραχή ελλειμματικής προσοχής/υπερκινητικότητας (ADHD), κατάχρηση ναρκωτικών ή αλκοόλ ή διατροφικές διαταραχές. Μερικές φορές τα άτομα που έχουν σοβαρά μανιακά ή καταθλιπτικά επεισόδια έχουν επίσης συμπτώματα ψύχωσης, τα οποία μπορεί να περιλαμβάνουν παραισθήσεις ή παραισθήσεις. Τα ψυχωτικά συμπτώματα συχνά αντικατοπτρίζουν την έντονη διάθεση του ατόμου. Για παράδειγμα, ένα άτομο που βιώνει ψυχωσικά συμπτώματα κατά τη διάρκεια μιας καταθλιπτικής φάσης μπορεί να έχει την ψευδαίσθηση ότι έχει υποστεί οικονομική καταστροφή, ενώ ένα άτομο με ψυχωσικά συμπτώματα σε μανιακή φάση μπορεί να πιστεύει λανθασμένα ότι είναι διάσημο ή ότι διαθέτει ιδιαίτερες ικανότητες.

Η εξέταση των συμπτωμάτων ενός ατόμου κατά τη διάρκεια της ασθένειας και η εξέταση του οικογενειακού του ιστορικού μπορεί να βοηθήσει έναν πάροχο υγειονομικής περίθαλψης να προσδιορίσει εάν το άτομο έχει διπολική διαταραχή μαζί με άλλη διαταραχή[47].

2.3.Αιτίες

Έρευνες έχουν δείξει ότι υπάρχουν διάφοροι παράγοντες που επηρεάζουν την πιθανότητα ανάπτυξης διπολικής διαταραχής όπως η δομή και λειτουργία του εγκεφάλου και η γενετική. Ο εγκέφαλος των ατόμων που πάσχουν από διπολική διαταραχή παρουσιάζει συγκεκριμένες διαφορές σε σύγκριση με τον εγκέφαλο ατόμων που δεν έχουν διπολική διαταραχή ή άλλες ψυχικές διαταραχές. Η σε βάθος ανάλυση αυτών των διαφορών στον εγκέφαλο μπορεί να προσφέρει πολύτιμες πληροφορίες στους επιστήμονες για την κατανόηση της διπολικής διαταραχής και να συμβάλει στον προσδιορισμό των πιο αποτελεσματικών θεραπειών. Από την άλλη τα άτομα με συγκεκριμένα γονιδιακά χαρακτηριστικά είναι πιο επιρρεπή στην ανάπτυξη διπολικής διαταραχής. Επιπλέον, έρευνες αποκαλύπτουν ότι τα άτομα που έχουν γονείς ή αδέρφια με διπολική διαταραχή διατρέχουν αυξημένο κίνδυνο να εμφανίσουν και οι ίδιοι τη διαταραχή. Πολλά γονίδια εμπλέκονται στην κατάσταση αυτή, χωρίς κανένα από αυτά να είναι αποκλειστικός αιτιολογικός παράγοντας. Η κατανόηση του ρόλου των γονιδίων στη διπολική διαταραχή μπορεί να προσφέρει πολύτιμες πληροφορίες στους ερευνητές για την ανάπτυξη νέων θεραπευτικών προσεγγίσεων.

Παρόλα αυτά ακόμη και σήμερα, οι πάροχοι υγειονομικής περίθαλψης βασίζονται στο σχέδιο διάγνωσης και θεραπείας στα συμπτώματα και το ιστορικό ενός ατόμου, αντί για απεικόνιση εγκεφάλου ή άλλες διαγνωστικές εξετάσεις [47].

2.4. Θεραπεία

Η διπολική διαταραχή αποτελεί μια χρόνια πάθηση. Τα επεισόδια μανίας και κατάθλιψης τείνουν να επαναλαμβάνονται με την πάροδο του χρόνου. Ανάμεσα στα επεισόδια, πολλοί ασθενείς με διπολική διαταραχή δεν παρουσιάζουν μεταβολές στη διάθεση, ωστόσο ορισμένα άτομα μπορεί να βιώνουν παρατεταμένα συμπτώματα. Η μακροχρόνια και σταθερή θεραπεία μπορεί να συμβάλλει στην αποτελεσματική διαχείριση αυτών των συμπτωμάτων.

Η θεραπεία έχει τη δυνατότητα να υποστηρίξει πλήθος ατόμων, συμπεριλαμβανομένων αυτών που πάσχουν από τις πιο σοβαρές εκδηλώσεις διπολικής διαταραχής. Ένα επιτυχές θεραπευτικό πλάνο συνήθως περιλαμβάνει έναν συνδυασμό φαρμακευτικής αγωγής και ψυχοθεραπείας, η οποία είναι επίσης γνωστή ως θεραπεία μέσω της ομιλίας.

Όσον αφορά τη φαρμακευτική αγωγή υπάρχουν ορισμένα φάρμακα που είναι ικανά να υποστηρίξουν τη διαχείριση των συμπτωμάτων της διπολικής διαταραχής. Ορισμένα άτομα ενδέχεται να χρειαστεί να δοκιμάσουν διάφορες φαρμακευτικές επιλογές και να συνεργαστούν με τον επαγγελματία υγειονομικής περίθαλψης προκειμένου να εντοπίσουν τα φάρμακα που είναι πιο αποτελεσματικά για εκείνα.

Οι πιο συνηθισμένοι τύποι φαρμάκων που συνταγογραφούνται από τους επαγγελματίες υγειονομικής περίθαλψης περιλαμβάνουν τους σταθεροποιητές διάθεσης και τα άτυπα αντιψυχωσικά. Οι σταθεροποιητές διάθεσης, όπως το λίθιο και το βαλπροϊκό, είναι ικανοί να συμβάλλουν στην πρόληψη επεισοδίων διάθεσης ή στη μείωση της έντασής τους. Επιπλέον, το λίθιο μπορεί να μειώσει τον κίνδυνο αυτοκτονικών σκέψεων. Παράλληλα, οι επαγγελματίες υγειονομικής περίθαλψης ενδέχεται να συμπεριλάβουν στο θεραπευτικό σχέδιο φάρμακα που στοχεύουν στη βελτίωση του ύπνου ή στη μείωση του άγχους.

Παρόλο που η διπολική κατάθλιψη συχνά θεραπεύεται με τη χρήση αντικαταθλιπτικών φαρμάκων, είναι απαραίτητο να χορηγείται και ένας σταθεροποιητής διάθεσης. Η χορήγηση αντικαταθλιπτικού χωρίς τη συνοδεία σταθεροποιητή διάθεσης μπορεί να οδηγήσει σε μανιακό επεισόδιο ή ταχεία εναλλαγή διάθεσης σε άτομα που πάσχουν από διπολική διαταραχή.

Δεδομένου ότι τα άτομα που πάσχουν από διπολική διαταραχή είναι πιο επιρρεπή να ζητούν βοήθεια κατά τη διάρκεια επεισοδίων κατάθλιψης σε σύγκριση με περιόδους μανίας ή υπομανίας, είναι κρίσιμης σημασίας για τους επαγγελματίες υγειονομικής περίθαλψης να συλλέγουν λεπτομερή ιατρικό ιστορικό, προκειμένου να διασφαλίσουν ότι η διπολική διαταραχή δεν συγχέεται με την κατάθλιψη.

Τα άτομα που χρησιμοποιούν φάρμακα θα πρέπει να επικοινωνούν τακτικά με τον πάροχο υγειονομικής περίθαλψης, κατανοώντας πλήρως τα οφέλη και τους κινδύνους της θεραπείας τους. Είναι επίσης σημαντικό να ενημερώνουν τον γιατρό τους για οποιαδήποτε άλλα συνταγογραφούμενα ή μη φάρμακα ή συμπληρώματα λαμβάνουν ήδη, ώστε να αποφευχθούν πιθανές αλληλεπιδράσεις. Εάν εμφανιστούν παρενέργειες, πρέπει να αναφέρουν άμεσα τις ανησυχίες τους, καθώς μπορεί να απαιτείται προσαρμογή της δόσης ή δοκιμή ενός εναλλακτικού φαρμάκου. Τέλος, είναι ζωτικής σημασίας να θυμούνται ότι η αγωγή πρέπει να λαμβάνεται και να ακολουθείται με συνέπεια, ακόμη και όταν αισθάνονται καλά.

Από την άλλη η ψυχοθεραπεία, γνωστή και ως θεραπεία μέσω της ομιλίας, μπορεί να αποδειχθεί και αυτή αποτελεσματική για άτομα που πάσχουν από διπολική διαταραχή. Ο όρος ψυχοθεραπεία αναφέρεται σε διάφορες θεραπευτικές τεχνικές που αποσκοπούν στην αναγνώριση και την τροποποίηση ανησυχητικών συναισθημάτων, σκέψεων και συμπεριφορών. Αυτή η μορφή θεραπείας μπορεί να παρέχει

υποστήριξη, εκπαίδευση και καθοδήγηση σε άτομα με διπολική διαταραχή καθώς και στις οικογένειές τους.

Η γνωσιακή συμπεριφορική θεραπεία (CBT) αποτελεί μια ουσιαστική προσέγγιση για την αντιμετώπιση της κατάθλιψης, ενώ η προσαρμοσμένη CBT για την αϋπνία μπορεί να αποδειχθεί ιδιαίτερα ωφέλιμη ως τμήμα της θεραπείας της διπολικής κατάθλιψης. Η θεραπεία μπορεί να περιλαμβάνει επίσης σύγχρονες προσεγγίσεις που έχουν σχεδιαστεί ειδικά για την αντιμετώπιση της διπολικής διαταραχής, όπως η διαπροσωπική και κοινωνικού ρυθμού θεραπεία (IPSRT) καθώς και η οικογενειακή θεραπεία.

Σε περιπτώσεις που η φαρμακευτική αγωγή και η ψυχοθεραπεία δεν επωφελεί σημαντικά τον ασθενή και δεν βοηθάει στην διαχείριση των συμπτωμάτων υπάρχουν και άλλες πιο εξειδικευμένες μορφές θεραπείας, συνήθως για βαριά περιστατικά. Αυτές είναι η ηλεκτροσπασμοθεραπεία (ECT), η επαναλαμβανόμενη διακρανιακή μαγνητική διέγερση (rTMS) και η θεραπεία με φως.

Η ηλεκτροσπασμοθεραπεία (ECT) είναι μια διαδικασία διέγερσης του εγκεφάλου που μπορεί να βοηθήσει στην ανακούφιση από σοβαρά συμπτώματα διπολικής διαταραχής. Οι πάροχοι υγειονομικής περίθαλψης μπορεί να εξετάσουν την ECT όταν η ασθένεια ενός ατόμου δεν έχει βελτιωθεί μετά από άλλες θεραπείες ή σε περιπτώσεις που απαιτούν ταχεία ανταπόκριση, όπως με άτομα που έχουν υψηλό κίνδυνο αυτοκτονίας ή κατατονία (κατάσταση μη ανταπόκρισης).

Η επαναλαμβανόμενη διακρανιακή μαγνητική διέγερση (rTMS) είναι ένας τύπος εγκεφαλικής διέγερσης που χρησιμοποιεί μαγνητικά κύματα για να ανακουφίσει την κατάθλιψη σε μια σειρά από συνεδρίες θεραπείας. Αν και δεν είναι τόσο ισχυρό όσο το ECT, το rTMS δεν απαιτεί γενική αναισθησία και έχει χαμηλό κίνδυνο αρνητικών επιπτώσεων στη μνήμη και τη σκέψη.

Η θεραπεία με φως είναι η καλύτερη βασισμένη σε στοιχεία θεραπεία για την εποχιακή συναισθηματική διαταραχή (SAD) και πολλά άτομα με διπολική διαταραχή εμφανίζουν εποχιακή επιδείνωση της κατάθλιψης ή SAD το χειμώνα. Η θεραπεία με φως μπορεί επίσης να χρησιμοποιηθεί για τη θεραπεία μικρότερων μορφών εποχιακής επιδείνωσης της διπολικής κατάθλιψης [47].

3. Κινητική δραστηριότητα - Motor Activity

Η κινητική δραστηριότητα ή αλλιώς Motor Activity αναφέρεται σε όλες τις κινήσεις και ενέργειες που πραγματοποιούνται από το σώμα και τους μυς του ανθρώπου ή άλλων ζωντανών οργανισμών μέσω της συντονισμένης δράσης των μυών και του νευρικού συστήματος. Η κινητική δραστηριότητα είναι θεμελιώδης για την καθημερινή λειτουργία και περιλαμβάνει τόσο εκούσιες όσο και ακούσιες κινήσεις.

3.1. Τύποι Κινητικής Δραστηριότητας

Υπάρχουν τέσσερις τύποι κινητικής δραστηριότητας, η αδρή, η λεπτή, η ακούσια και η εκούσια.

Η Αδρή Κινητικότητα (Gross Motor Activity), περιλαμβάνει τις μεγαλύτερες κινήσεις που εκτελούνται από τους μεγάλους μύες του σώματος, όπως περπάτημα, τρέξιμο, άλματα, και άλλες δραστηριότητες που απαιτούν συντονισμό και ισορροπία. Είναι πολύ σημαντική για τη φυσική ανάπτυξη, ειδικά σε παιδιά, καθώς αναπτύσσει τις βασικές κινητικές δεξιότητες.

Η Λεπτή Κινητικότητα (Fine Motor Activity) ενσωματώνει μικρότερες, πιο ακριβείς κινήσεις, όπως η σύλληψη αντικειμένων, το γράψιμο, η χρήση εργαλείων ή η πλοήγηση σε ένα πληκτρολόγιο. Γι αυτό απαιτείται λεπτός συντονισμός μεταξύ των μυών και του νευρικού συστήματος και είναι κρίσιμη για καθημερινές δραστηριότητες, όπως η αυτοεξυπηρέτηση και η εργασία.

Η Ακούσια Κινητικότητα (Involuntary Motor Activity) περιέχει κινήσεις που δεν ελέγχονται συνειδητά, όπως αντανάκλαστικές κινήσεις (π.χ. τραβήγματα όταν αγγίζουμε κάτι καυτό) και κινήσεις που σχετίζονται με την αναπνοή, την καρδιακή λειτουργία και άλλες βασικές λειτουργίες.

Τέλος, η Εκούσια Κινητικότητα (Voluntary Motor Activity) που αφορά τις κινήσεις που ελέγχονται συνειδητά και εκτελούνται με πρόθεση, όπως το να σηκώνουμε ένα αντικείμενο ή να εκτελούμε μια άσκηση.

3.2. Μηχανισμοί Κινητικής Δραστηριότητας

Η κινητική δραστηριότητα ελέγχεται από το κεντρικό νευρικό σύστημα (ΚΝΣ), το οποίο περιλαμβάνει τον εγκέφαλο και τον νωτιαίο μυελό.


Ο Κινητικός Φλοιός (Motor Cortex), όπως απεικονίζεται στην Εικόνα 1, βρίσκεται στον εγκέφαλο και είναι υπεύθυνος για τον σχεδιασμό, την έναρξη και τον έλεγχο εκούσιων κινήσεων.



Εικόνα 1: Κινητικός Φλοιός – Motor Cortex. Πηγή:

<https://www.sciencephoto.com/media/863484/view/human-brain-primary-motor-cortex-3d-mri-composite-image>

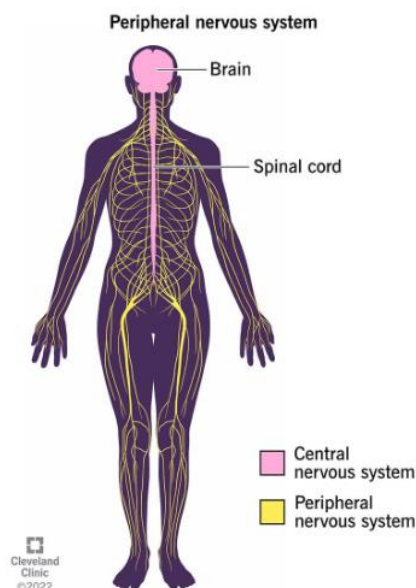
Στην Εικόνα 2 βλέπουμε τον νωτιαίο μυελό (spinal cord), ο οποίος μεταδίδει κινητικά σήματα από τον εγκέφαλο στους μύες και παρέχει διάφορες διαδρομές για αντανακλαστικές αντιδράσεις.



Εικόνα 2 : Νωτιαίος Μυελός – Spinal Cord. Πηγή:


<https://www.britannica.com/science/spinal-cord>

Το Περιφερικό Νευρικό Σύστημα (Peripheral Nervous System), αποτελείται από νεύρα που μεταφέρουν σήματα μεταξύ του ΚΝΣ και των μυών για την εκτέλεση κινήσεων, όπως φαίνεται στην Εικόνα 3.



Εικόνα 3 : Περιφερικό Νευρικό Σύστημα - Peripheral Nervous System. *Πηγή:* <https://my.clevelandclinic.org/health/body/23123-peripheral-nervous-system-pns>

Τέλος, στην Εικόνα 4 απεικονίζεται το μυϊκό σύστημα (muscular system) που περιλαμβάνει τους μύες και οι οποίοι λαμβάνουν σήματα από τα νεύρα και εκτελούν τη συστολή ή χαλάρωση που απαιτείται για την κίνηση.



Εικόνα 4 : Μυϊκό Σύστημα - Muscular System. *Πηγή:* <https://nurseslabs.com/muscular-system-anatomy-physiology/>

3.3. Τεχνολογίες και Εργαλεία Παρακολούθησης

Υπάρχουν διάφορα εργαλεία και συστήματα που χρησιμοποιούνται για την αξιολόγηση και παρακολούθηση της κινητικής δραστηριότητας σε κλινικές, αθλητικές και καθημερινές εφαρμογές:

Συσκευές όπως τα επιταχυνσιόμετρα, τα γυροσκόπια, και άλλοι αισθητήρες ενσωματώνονται σε wearables και χρησιμοποιούνται σε καθημερινές εφαρμογές για τη λεπτομερή καταγραφή των κινητικών μοτίβων κατά τη διάρκεια της ημέρας και της νύχτας. Από την άλλη, τα Συστήματα Ανάλυσης Κίνησης (Motion Analysis Systems) και η Ηλεκτρομυογραφία (EMG), χρησιμοποιούνται κυρίως σε κλινικές και αθλητικές εγκαταστάσεις για τη λεπτομερή ανάλυση της κίνησης, π.χ. καταγραφή βάρδισης ή ανάλυση τεχνικής σε αθλήματα και μέτρηση της μυϊκής δραστηριότητας μέσω ηλεκτρικών σημάτων που παράγονται κατά τη διάρκεια της μυϊκής συστολής, για τη μελέτη της μυϊκής λειτουργίας και της νευρομυϊκής απόκρισης.

Τα λογισμικά ανάλυσης μπορούν να επεξεργαστούν τα δεδομένα για να παρέχουν πληροφορίες για την ποσότητα και την ποιότητα της κίνησης, για προσωπική χρήση ή για κλινική ανάλυση βοηθώντας τους επαγγελματίες υγείας να κατανοήσουν τις ανάγκες του ασθενούς.

3.4. Ημερήσιες Μεταβολές στην Κινητική Δραστηριότητα και Φυσική Άσκηση

Η κινητική δραστηριότητα δεν είναι σταθερή κατά τη διάρκεια της ημέρας, αλλά παρουσιάζει κύκλους που συνδέονται με τους κερκάρδιους ρυθμούς. Συνήθως, η δραστηριότητα είναι αυξημένη κατά τη διάρκεια της ημέρας και μειωμένη κατά τη διάρκεια της νύχτας. Οι παραβιάσεις αυτών των μοτίβων μπορούν να είναι ενδείξεις διαταραχών ύπνου ή άλλων καταστάσεων όπως το σύνδρομο καθυστερημένης φάσης ύπνου.

Η φυσική άσκηση αποτελεί έναν από τους κύριους τρόπους αύξησης της κινητικής δραστηριότητας. Τακτική άσκηση βελτιώνει την καρδιοαναπνευστική υγεία, ενισχύει τους μυς και τα οστά, και συμβάλλει στη μείωση του άγχους και της κατάθλιψης.

3.5. Κλινικές Εφαρμογές

Η παρακολούθηση και ανάλυση της κινητικής δραστηριότητας χρησιμοποιείται συχνά για τη διάγνωση και τη θεραπεία διαταραχών όπως η νόσος του Parkinson, οι διαταραχές ύπνου, και άλλες νευρολογικές παθήσεις ενώ σημαντική είναι η χρήση της και στη παρακολούθηση της αποκατάστασης μετά από τραυματισμούς ή εγκεφαλικά επεισόδια.

Στην ψυχολογία και την ψυχιατρική, μπορεί να αξιολογηθεί για να κατανοηθεί η επίδραση της ψυχικής κατάστασης στη σωματική δραστηριότητα, όπως σε περιπτώσεις κατάθλιψης όπου η κινητική δραστηριότητα μπορεί να είναι μειωμένη.

Οι αλλαγές στη σωματική δραστηριότητα μπορεί να συνδέονται με ψυχικές διαταραχές, και η μείωση της κινητικότητας συχνά παρατηρείται σε περιπτώσεις κατάθλιψης ή άγχους.

Η παρακολούθηση της κινητικής δραστηριότητας μπορεί να βοηθήσει στη διαμόρφωση θεραπευτικών παρεμβάσεων, προσαρμόζοντας τις ανάγκες του

ασθενούς. Η μελέτη της κινητικής δραστηριότητας είναι πολύπλευρη και καλύπτει από βασικές βιολογικές λειτουργίες μέχρι προχωρημένες έρευνες σε κλινικές και αθλητικές εφαρμογές [32-33,60].

4. Κλίμακα Αξιολόγησης Κατάθλιψης – Κλίμακα MADRS

Η κλίμακα MADRS (Montgomery-Åsberg Depression Rating Scale) είναι ένα εργαλείο που χρησιμοποιείται ευρέως για την αξιολόγηση της σοβαρότητας της κατάθλιψης. Αναπτύχθηκε το 1979 από τους Montgomery και Åsberg και έχει σχεδιαστεί κυρίως για την αξιολόγηση της αλλαγής στην ένταση των καταθλιπτικών συμπτωμάτων κατά τη διάρκεια της θεραπείας.

4.1. Βασικά χαρακτηριστικά της κλίμακας MADRS

Η κλίμακα MADRS χρησιμοποιείται για τη μέτρηση της σοβαρότητας των συμπτωμάτων κατάθλιψης, όπως αυτά μπορεί να μεταβάλλονται κατά τη διάρκεια της θεραπείας. Μπορεί να χρησιμοποιηθεί τόσο σε κλινικές μελέτες όσο και στην κλινική πρακτική. Η κλίμακα περιλαμβάνει 10 ερωτήσεις (αντικείμενα), κάθε μία από τις οποίες σχετίζεται με διαφορετικά συμπτώματα κατάθλιψης. Κάθε ερώτηση βαθμολογείται από 0 έως 6, όπου το 0 αντιπροσωπεύει την απουσία του συμπτώματος και το 6 αντιπροσωπεύει τη μέγιστη σοβαρότητα του συμπτώματος. Το συνολικό σκορ μπορεί να κυμαίνεται από 0 έως 60 [42].

Τα συμπτώματα που αξιολογούνται είναι τα εξής:

1. Θλίψη
2. Δυσκολία συγκέντρωσης
3. Εσωτερική ανησυχία
4. Μειωμένη υπερβολική διέγερση
5. Αϋπνία
6. Μείωση της όρεξης
7. Δύναμη (ψυχοκινητική επιβράδυνση ή διέγερση)
8. Αίσθημα αναξιοσύνης
9. Δυσκολία συναισθηματικής απόκρισης
10. Ιδεασμός αυτοκτονίας

Ερμηνεία του αποτελέσματος:

- (0-6) : Καμία ή ελάχιστη κατάθλιψη
- (7-19) : Ήπια κατάθλιψη
- (20-34) : Μέτρια κατάθλιψη
- (35-60) : Σοβαρή κατάθλιψη

4.2. Χρήση της κλίμακας

Η κλίμακα MADRS μπορεί να χρησιμοποιηθεί από επαγγελματίες ψυχικής υγείας, όπως ψυχιάτρους ή ψυχολόγους, για την παρακολούθηση της πορείας της κατάθλιψης σε έναν ασθενή. Μπορεί επίσης να βοηθήσει στην αξιολόγηση της αποτελεσματικότητας μιας θεραπευτικής παρέμβασης (π.χ. φαρμακευτική αγωγή, ψυχοθεραπεία).

Η κλίμακα είναι ιδιαίτερα ευαίσθητη σε μεταβολές των συμπτωμάτων, γεγονός που την καθιστά ένα χρήσιμο εργαλείο για τη μέτρηση των αποτελεσμάτων των θεραπευτικών παρεμβάσεων [3].

4.3. Προέλευση και Ανάπτυξη

Η κλίμακα MADRS δημιουργήθηκε για να παρέχει ένα ευαίσθητο εργαλείο αξιολόγησης της κατάθλιψης που να είναι πιο εστιασμένο και λεπτομερές από την προηγούμενη κλίμακα, την Hamilton Depression Rating Scale (HDRS). Οι Montgomery και Åsberg σχεδίασαν την κλίμακα για να είναι πιο ευαίσθητη στις αλλαγές στη σοβαρότητα των συμπτωμάτων κατά τη διάρκεια της θεραπείας.

Σε αντίθεση με την HDRS, η MADRS επικεντρώνεται περισσότερο σε συναισθηματικά και γνωστικά συμπτώματα της κατάθλιψης, και λιγότερο σε σωματικά συμπτώματα, όπως διαταραχές ύπνου ή απώλεια βάρους.

Διαδικασία Χορήγησης

Η χορήγηση της κλίμακας MADRS είναι σχετικά σύντομη και διαρκεί περίπου 15-20 λεπτά. Οι ερωτήσεις μπορούν να γίνουν είτε μέσω συνέντευξης είτε μέσω αυτοαναφοράς, αν και η χορήγηση από κλινικό είναι η πιο συνηθισμένη μέθοδος.

Οι κλινικοί που χρησιμοποιούν την κλίμακα MADRS συνήθως έχουν εκπαιδευτεί να αναγνωρίζουν και να αξιολογούν τα καταθλιπτικά συμπτώματα. Αυτό εξασφαλίζει ότι οι απαντήσεις που δίνονται από τους ασθενείς βαθμολογούνται με ακρίβεια.

Αξιοπιστία και Εγκυρότητα

Η κλίμακα MADRS έχει αποδειχθεί ότι έχει υψηλή εσωτερική συνοχή, δηλαδή τα αντικείμενα της κλίμακας είναι συνεπή μεταξύ τους. Επιπλέον, παρουσιάζει καλή διαβαθμιστική αξιοπιστία, που σημαίνει ότι διαφορετικοί αξιολογητές τείνουν να καταλήγουν σε παρόμοια αποτελέσματα.

Η κλίμακα MADRS έχει αποδειχθεί ότι είναι έγκυρη τόσο ως προς τη σύγκριση με άλλες κλίμακες κατάθλιψης όσο και ως προς την ικανότητά της να ανιχνεύει αλλαγές στα συμπτώματα. Είναι ιδιαίτερα χρήσιμη στην παρακολούθηση της αποτελεσματικότητας της θεραπείας.

Πλεονεκτήματα και Περιορισμοί

- Ευαισθησία στις αλλαγές: Η MADRS είναι ιδιαίτερα χρήσιμη στην παρακολούθηση της εξέλιξης της κατάθλιψης, καθώς είναι ευαίσθητη στις αλλαγές στη σοβαρότητα των συμπτωμάτων.
- Ευκολία στη χρήση: Είναι γρήγορη και εύκολη στη χρήση, τόσο για τον κλινικό όσο και για τον ασθενή.
- Εστίαση σε συγκεκριμένα συμπτώματα: Επειδή η MADRS επικεντρώνεται σε συγκεκριμένα συμπτώματα της κατάθλιψης, μπορεί να μην είναι κατάλληλη για την αξιολόγηση άλλων ψυχιατρικών διαταραχών που εμφανίζονται παράλληλα με την κατάθλιψη (συνοσηρότητα).
- Υποκειμενικότητα: Παρόλο που έχει υψηλή διαβαθμιστική αξιοπιστία, η ερμηνεία των απαντήσεων μπορεί να διαφέρει ελαφρώς ανάλογα με τον αξιολογητή [68].

Χρήση σε Έρευνες και Κλινικές Μελέτες

Η MADRS χρησιμοποιείται συχνά σε κλινικές δοκιμές φαρμακευτικών αγωγών για την κατάθλιψη, καθώς επιτρέπει την ακριβή παρακολούθηση της αποτελεσματικότητας της θεραπείας με την πάροδο του χρόνου.

Χρησιμοποιείται επίσης σε ερευνητικές μελέτες για την εξέταση της πορείας της κατάθλιψης, την αποτελεσματικότητα διαφόρων θεραπευτικών προσεγγίσεων και τη διερεύνηση των παραγόντων που επηρεάζουν τη σοβαρότητα της κατάθλιψης [45-46].

5. Φορετές συσκευές καταγραφής κινητικής δραστηριότητας

Γενικά υπάρχει ποικιλομορφία φορετών συσκευών (wearables) που ενσωματώνουν διάφορους αισθητήρες και χρησιμοποιούνται σε καθημερινές εφαρμογές για τη λεπτομερή καταγραφή των κινητικών μοτίβων κατά τη διάρκεια της ημέρας και της νύχτας. Οι μετρήσεις που λήφθηκαν και χρησιμοποιήθηκαν στην παρούσα μελέτη πραγματοποιήθηκαν με το Actiwatch Model AW4.

Το Actiwatch Model AW4 είναι μια συσκευή παρακολούθησης δραστηριότητας (activity monitor) που χρησιμοποιείται κυρίως για την καταγραφή δεδομένων σχετικά με τις κινήσεις και τον ύπνο των χρηστών. Είναι ένα από τα προϊόντα της οικογένειας Actiwatch, που χρησιμοποιούνται ευρέως στην κλινική έρευνα και σε ιατρικές μελέτες για τη συλλογή δεδομένων σχετικά με τον καρδιακό ρυθμό, τις συνήθειες ύπνου και την ημερήσια δραστηριότητα. Στην Εικόνα 5 απεικονίζεται το Actiwatch Spectrum.



Εικόνα 5 : Actiwatch Spectrum. Πηγή:

<https://www.philips.gr/healthcare/product/HC1046964/actiwatch-spectrum-activity-monitor>

5.1. Χαρακτηριστικά του Actiwatch Model AW4

- Παρακολούθηση Δραστηριότητας: Η συσκευή καταγράφει τις κινήσεις του χρήστη, παρέχοντας δεδομένα σχετικά με το επίπεδο της σωματικής δραστηριότητας. Αυτό μπορεί να είναι χρήσιμο για την αξιολόγηση της συνολικής δραστηριότητας ενός ατόμου κατά τη διάρκεια της ημέρας και της νύχτας.
- Παρακολούθηση Ύπνου: Είναι σχεδιασμένο για την παρακολούθηση των συνηθειών ύπνου, καταγράφοντας δεδομένα σχετικά με την έναρξη του ύπνου, τη διάρκεια, την ποιότητα και τις αφυπνίσεις κατά τη διάρκεια της νύχτας. Αυτά τα δεδομένα μπορούν να χρησιμοποιηθούν για τη διάγνωση διαταραχών ύπνου και τη βελτίωση των θεραπειών.
- Σχεδίαση και Φορεσιμότητα: Η συσκευή είναι μικρή και ελαφριά, φοριέται στον καρπό και μοιάζει με ρολόι. Αυτό την καθιστά άνετη για μακροχρόνια χρήση,

απαραίτητη για την παρακολούθηση των δραστηριοτήτων και του ύπνου για αρκετές ημέρες ή εβδομάδες.

- Αισθητήρες: Το Actiwatch AW4 διαθέτει έναν αισθητήρα επιταχυνσιόμετρο που καταγράφει τη συχνότητα και την ένταση των κινήσεων. Αυτά τα δεδομένα μετατρέπονται σε μετρήσεις που χρησιμοποιούνται για την αξιολόγηση της δραστηριότητας και του ύπνου.
- Λογισμικό και Ανάλυση Δεδομένων: Τα δεδομένα από το Actiwatch AW4 συλλέγονται και αναλύονται μέσω ειδικού λογισμικού, το οποίο παρέχει γραφήματα και αναφορές που βοηθούν στην κατανόηση των μοτίβων δραστηριότητας και ύπνου. Αυτό το λογισμικό επιτρέπει την εξαγωγή δεδομένων για περαιτέρω ανάλυση σε ερευνητικές ή κλινικές μελέτες.
- Χρήση στην Κλινική Έρευνα: Το Actiwatch AW4 χρησιμοποιείται συχνά σε μελέτες σχετικά με τον ύπνο, την ανησυχία, τον πόνο και τη διάθεση, καθώς τα δεδομένα που συλλέγει είναι κρίσιμα για την κατανόηση του πώς αυτά τα ζητήματα επηρεάζουν την καθημερινή ζωή και την υγεία των ασθενών.

5.2. Εφαρμογές του Actiwatch AW4

Η συλλογή δεδομένων από μελέτες ύπνου παρέχει σημαντικές πληροφορίες για την εκτίμηση της αϋπνίας, της υπερυπνίας και άλλων διαταραχών ύπνου. Στην εργαστηριακή έρευνα, αυτά τα δεδομένα χρησιμοποιούνται σε πειράματα για τη μελέτη της ανθρώπινης συμπεριφοράς, του καρδιακού ρυθμού και της επίδρασης της φυσικής δραστηριότητας στην ψυχική υγεία. Παράλληλα, στην κλινική πρακτική, τα δεδομένα αυτά βοηθούν τους γιατρούς να παρακολουθούν την πρόοδο των ασθενών τους και να προσαρμόζουν τις θεραπείες με βάση τις πληροφορίες για τη δραστηριότητα και τον ύπνο τους.

5.3. Τεχνικά Χαρακτηριστικά

Το Actiwatch AW4 είναι μια συσκευή που χρησιμοποιεί έναν τριών αξόνων επιταχυνσιόμετρο - triaxial accelerometer (αισθητήρας κίνησης) για τη μέτρηση της κίνησης σε τρεις διαστάσεις (x, y, z), επιτρέποντας έτσι τη λεπτομερή καταγραφή των κινήσεων και τη διαφοροποίηση μεταξύ διαφορετικών τύπων δραστηριότητας, όπως το περπάτημα, το τρέξιμο και ο ύπνος. Η συσκευή διαθέτει ενσωματωμένη μνήμη που μπορεί να αποθηκεύσει δεδομένα για αρκετές εβδομάδες, ανάλογα με τη ρύθμιση του χρονικού διαστήματος καταγραφής, όπως κάθε 30 δευτερόλεπτα ή κάθε λεπτό. Επιπλέον, η μπαταρία του Actiwatch AW4 έχει μεγάλη διάρκεια ζωής, επιτρέποντας τη χρήση της για εβδομάδες με μία μόνο φόρτιση, καθιστώντας την ιδανική για μακροχρόνιες μελέτες χωρίς συχνή ανάγκη φόρτισης. Τέλος, η αδιαβροχοποίηση της συσκευής επιτρέπει τη συνεχή χρήση της, ακόμη και κατά τη διάρκεια του ντους ή της κολύμβησης, εξασφαλίζοντας τη συνεχή καταγραφή δεδομένων.

Γενικότερα το Actiwatch AW4 είναι μια βελτιωμένη έκδοση προηγούμενων μοντέλων της σειράς Actiwatch, προσφέροντας αυξημένη ακρίβεια, καλύτερη διάρκεια μπαταρίας και βελτιωμένα χαρακτηριστικά λογισμικού.

5.4. Λογισμικό και Ανάλυση Δεδομένων

Το Actiwatch AW4 συνήθως συνοδεύεται από λογισμικό που επιτρέπει τη λήψη, αποθήκευση και ανάλυση των δεδομένων. Το λογισμικό αυτό μπορεί να προσφέρει διαγράμματα, γραφήματα και στατιστικά δεδομένα, που βοηθούν στην ερμηνεία των μοτίβων δραστηριότητας και ύπνου. Το λογισμικό περιλαμβάνει επίσης ειδικούς αλγορίθμους που αναλύουν τα δεδομένα για τον εντοπισμό των περιόδων ύπνου και αφύπνισης (Αλγόριθμοι Ανάλυσης Ύπνου). Αυτοί οι αλγόριθμοι χρησιμοποιούν τα δεδομένα από τον επιταχυνσιόμετρο για να προσδιορίσουν πότε ο χρήστης είναι πιθανόν να κοιμάται ή να είναι ξύπνιος.

5.5. Κλινικές Εφαρμογές και Έρευνα

Το Actiwatch AW4 είναι πολύτιμο εργαλείο για τη διάγνωση και παρακολούθηση διαταραχών ύπνου όπως η αϋπνία, το σύνδρομο άπνοιας στον ύπνο και οι διαταραχές του καρδιακού ρυθμού. Επιτρέπει στους ερευνητές και τους κλινικούς να συγκεντρώσουν αντικειμενικά δεδομένα για τις συνήθειες ύπνου του ασθενούς σε φυσικό περιβάλλον (σπίτι). Χρησιμοποιείται επίσης σε μελέτες για την αξιολόγηση της καθημερινής σωματικής δραστηριότητας και της σχέσης της με την υγεία. Για παράδειγμα, μπορεί να χρησιμοποιηθεί για την παρακολούθηση της δραστηριότητας σε ασθενείς με χρόνιες παθήσεις όπως ο διαβήτης ή η καρδιοπάθεια, ώστε να αξιολογηθεί η επίδραση της φυσικής άσκησης στην κατάστασή τους. Ακόμη, μπορεί να βοηθήσει σε μελέτες που αφορούν τη ψυχική υγεία και συγκεκριμένα στην κατανόηση της σχέσης μεταξύ της δραστηριότητας και της διάθεσης, παρακολουθώντας πώς οι αλλαγές στην κινητικότητα μπορεί να συνδέονται με συμπτώματα κατάθλιψης ή άγχους.

Σε σύγκριση με άλλα παρόμοια wearables, το Actiwatch AW4 έχει το πλεονέκτημα της κλινικής εγκυρότητας, καθώς είναι ειδικά σχεδιασμένο για ιατρική χρήση και έρευνα, ενώ πολλά εμπορικά wearables επικεντρώνονται κυρίως στη χρήση από καταναλωτές χωρίς κλινική πιστοποίηση [52].

6. Μέτρα Αξιολόγησης ταξινόμησης

Πίνακας αληθείας (Confusion matrix)

Ο πίνακας αληθείας είναι ένα εργαλείο που χρησιμοποιείται στην ανάλυση απόδοσης αλγορίθμων ταξινόμησης, ειδικά σε περιπτώσεις όπου ο στόχος είναι η αξιολόγηση ενός μοντέλου μηχανικής μάθησης. Ο πίνακας σύγχυσης εμφανίζει τις πραγματικές τιμές (actual values) και τις προβλέψεις (predicted values) σε μια μορφή πίνακα, επιτρέποντας έτσι την εύκολη αναγνώριση των σωστών και λανθασμένων προβλέψεων του μοντέλου.

Στοιχεία του Confusion Matrix:

True Positives – TP (Αληθώς Θετικά): Ο αριθμός των δειγμάτων που ανήκουν στη θετική κλάση και το μοντέλο τα ταξινόμησε σωστά ως θετικά.

True Negatives – TN (Αληθώς Αρνητικά): Ο αριθμός των δειγμάτων που ανήκουν στη αρνητική κλάση και το μοντέλο τα ταξινόμησε σωστά ως αρνητικά.

False Positives – FP (Ψευδώς Θετικά): Ο αριθμός των δειγμάτων που ανήκουν στη αρνητική κλάση, αλλά το μοντέλο τα ταξινόμησε λανθασμένα ως θετικά. Αυτό συχνά αναφέρεται και ως "Type I Error".

False Negatives – FN (Ψευδώς Αρνητικά): Ο αριθμός των δειγμάτων που ανήκουν στη θετική κλάση, αλλά το μοντέλο τα ταξινόμησε λανθασμένα ως αρνητικά. Αυτό συχνά αναφέρεται και ως "Type II Error".

Ένας τυπικός πίνακας αληθείας για ένα πρόβλημα δυαδικής ταξινόμησης απεικονίζεται στην Εικόνα 6:

Confusion Matrix

	Actually Positive (1)	Actually Negative (0)
Predicted Positive (1)	True Positives (TPs)	False Positives (FPs)
Predicted Negative (0)	False Negatives (FNs)	True Negatives (TNs)

Εικόνα 6 : Πίνακας Αληθείας - Confusion Matrix. Πηγή:

<https://glassboxmedicine.com/2019/02/17/measuring-performance-the-confusion-matrix/>

Ο πίνακας αληθείας είναι πολύ χρήσιμος όταν θέλουμε να κατανοήσουμε καλύτερα τις αδυναμίες του μοντέλου μας, ιδιαίτερα σε περιπτώσεις που έχουμε ανισομερή κλάσεις ή σε περιπτώσεις όπου η ακρίβεια δεν είναι το μοναδικό μέτρο που θέλουμε να λάβουμε υπόψη.

Είναι ένα από τα βασικότερα εργαλεία στην αξιολόγηση μοντέλων μηχανικής μάθησης και χρησιμοποιείται ευρέως σε πολλούς τομείς της επιστήμης των δεδομένων και της τεχνητής νοημοσύνης [4,22].

Για προβλήματα τριαδικής ταξινόμησης (3-class classification), ο πίνακας αληθείας είναι λίγο πολύπλοκος και χρειάζονται κάποιοι υπολογισμοί. Θεωρώντας ότι ο πίνακας αληθείας που χρησιμοποιούμε είναι παρόμοιος με τον Πίνακα 6.1., οι τιμές των TP, TN, FP, FN θα προκύπτουν όπως θα αναλυθεί παρακάτω [17].

Πίνακας 6.1: 3x3 Πίνακας Αληθείας

		Predicted		
		A	B	C
Actual	A	c11	c12	c13
	B	c21	c22	c23
	C	c31	c32	c33

Για την κλάση A:

$$TP(A) = c11$$

$$TN(A) = c22 + c23 + c32 + c33$$

$$FP(A) = c21 + c31$$

$$FN(A) = c12 + c13$$

Για την κλάση B:

$$TP(B) = c22$$

$$TN(B) = c11 + c13 + c31 + c33$$

$$FP(B) = c12 + c32$$

$$FN(B) = c21 + c23$$

Για την κλάση C:

$$TP(C) = c33$$

$$TN(C) = c11 + c12 + c21 + c22$$

$$FP(C) = c13 + c23$$

$$FN(C) = c31 + c32$$

6.1. Ευστοχία/Ακρίβεια - Precision

Ο όρος "Precision" γενικά συνδέεται με την ακρίβεια και την ευστοχία των αποτελεσμάτων ή των μετρήσεων.

Στη Στατιστική και τη Μηχανική Μάθηση είναι ένας δείκτης αξιολόγησης της απόδοσης ενός μοντέλου κατηγοριοποίησης. Συγκεκριμένα, η ακρίβεια (precision) αναφέρεται στο ποσοστό των σωστών θετικών προβλέψεων σε σχέση με το σύνολο των προβλέψεων που ήταν θετικές όπως φαίνεται στη σχέση (1) [58].

$$Precision = \frac{TP}{TP + FP} \quad (1)$$

Ένα υψηλό precision δείχνει ότι το μοντέλο έχει χαμηλό ποσοστό ψευδών θετικών (false positives).

Στα επιστημονικά όργανα και εργαλεία μέτρησης, το precision αναφέρεται στη συνέπεια των μετρήσεων που λαμβάνονται. Δηλαδή, εάν ένα όργανο δίνει παρόμοια αποτελέσματα κάθε φορά που εκτελείται μια μέτρηση υπό τις ίδιες συνθήκες, τότε το όργανο αυτό χαρακτηρίζεται ως υψηλής ακρίβειας (precision).

Στα συστήματα τεχνητής νοημοσύνης το precision είναι σημαντικός παράγοντας αξιολόγησης [17,54].

6.2. Ευαισθησία – Recall/Sensitivity

Στα βιοϊατρικά δεδομένα, την ανάλυση δεδομένων και τη μηχανική μάθηση, ο όρος ευαισθησία (recall ή sensitivity) αναφέρεται σε ένα βασικό μέτρο απόδοσης ενός ταξινομητή. Η ευαισθησία μετρά το ποσοστό των πραγματικά θετικών περιπτώσεων που εντοπίζονται από το μοντέλο. Με άλλα λόγια, από όλες τις περιπτώσεις που είναι θετικές, η ευαισθησία δείχνει πόσες από αυτές εντοπίστηκαν σωστά από τον ταξινομητή. Ορίζεται όπως φαίνεται παρακάτω στην εξίσωση (2).

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (2)$$

Η ευαισθησία είναι σημαντική σε περιπτώσεις όπου είναι κρίσιμο να ανιχνευτούν όλες οι θετικές περιπτώσεις, όπως σε ιατρικές διαγνώσεις, όπου η μη διάγνωση μιας ασθένειας (Ψευδώς Αρνητικό) μπορεί να έχει σοβαρές συνέπειες.

Είναι ένα από τα μέτρα που χρησιμοποιούνται για την αξιολόγηση της απόδοσης ενός ταξινομητή. Συνήθως χρησιμοποιείται μαζί με την ειδικότητα (specificity) και την ακρίβεια (precision) για μια πλήρη εικόνα της απόδοσης. Η ισορροπία μεταξύ αυτών των μέτρων είναι σημαντική, ανάλογα με το πρόβλημα που προσπαθείς να λύσεις.

Συχνά υπάρχει ένας συμβιβασμός (trade-off) μεταξύ ευαισθησίας και ειδικότητας μήπως. Η αύξηση της ευαισθησίας μπορεί να μειώσει την ακρίβεια και το αντίστροφο. Για να επιτευχθεί η καλύτερη ισορροπία μεταξύ ευαισθησίας και ακρίβειας, χρησιμοποιείται συχνά το F1-score που θα αναλυθεί παρακάτω.

Συνολικά, η ευαισθησία είναι ένα πολύτιμο μέτρο που, σε συνδυασμό με άλλες μετρήσεις, μπορεί να δώσει μια πλήρη εικόνα της απόδοσης ενός μοντέλου ή ενός συστήματος ταξινόμησης [18,22,53].

6.3. Ακρίβεια - Accuracy

Η έννοια της ακρίβειας (accuracy) χρησιμοποιείται σε διάφορα πεδία και μπορεί να έχει διαφορετικές σημασίες ανάλογα με το πλαίσιο: Στο πλαίσιο της μηχανικής μάθησης και της στατιστικής, η ακρίβεια είναι ένα μέτρο της απόδοσης ενός αλγορίθμου ή μοντέλου. Συγκεκριμένα, αναφέρεται στο ποσοστό των σωστών προβλέψεων από το σύνολο των προβλέψεων που κάνει το μοντέλο όπως φαίνεται στη σχέση (3).

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (3)$$

Αυτός ο τύπος υπολογίζει το ποσοστό των σωστών προβλέψεων (σωστά ταξινομημένα δεδομένα) σε σχέση με το σύνολο των δεδομένων.

Η ακρίβεια δεν είναι πάντα ο καλύτερος δείκτης, ειδικά όταν υπάρχουν ανισορροπίες στις κλάσεις για παράδειγμα όταν η μία κλάση είναι πολύ πιο συχνή από την άλλη.

Η ακρίβεια είναι ένας γενικός όρος που μπορεί να χρησιμοποιηθεί σε πολλές επιστήμες και τεχνολογίες, και είναι πάντα σημαντικό να κατανοείται το πλαίσιο στο οποίο χρησιμοποιείται για να γίνει σωστή ερμηνεία του όρου.

Στην ιατρική, η ακρίβεια είναι κρίσιμη για την αξιολόγηση της αποτελεσματικότητας διαγνωστικών τεστ. Η ακρίβεια ενός διαγνωστικού τεστ αναφέρεται στο πόσο καλά το τεστ μπορεί να προσδιορίσει σωστά τα άτομα με και χωρίς μια συγκεκριμένη ασθένεια.

Θετική Προγνωστική Αξία (Positive Predictive Value, PPV): Πόσο πιθανό είναι ένα άτομο με θετικό αποτέλεσμα να έχει πραγματικά την ασθένεια.

Αρνητική Προγνωστική Αξία (Negative Predictive Value, NPV): Πόσο πιθανό είναι ένα άτομο με αρνητικό αποτέλεσμα να μην έχει την ασθένεια.

Η συνολική ακρίβεια του τεστ είναι το ποσοστό των σωστών αποτελεσμάτων (τόσο θετικών όσο και αρνητικών) σε σχέση με το σύνολο των αποτελεσμάτων.

Η ακρίβεια, σε κάθε περίπτωση, αποτελεί έναν βασικό δείκτη απόδοσης ή ποιότητας σε διάφορα επιστημονικά, τεχνολογικά και κοινωνικά πεδία [4,31].

6.4. Ειδικότητα - Specificity

Ο όρος ειδικότητα (specificity) χρησιμοποιείται σε διάφορους τομείς, όπως η επιστήμη, η ιατρική, η βιολογία, και η τεχνητή νοημοσύνη. Η έννοια αυτή αναφέρεται στην ικανότητα ενός συστήματος, ενός τεστ ή μιας διαδικασίας να αναγνωρίζει με ακρίβεια και να διακρίνει συγκεκριμένα χαρακτηριστικά ή στοιχεία. Στη σχέση (4) φαίνεται ο ορισμός της.

$$\text{Specificity} = \frac{TN}{TN + FP} \quad (4)$$

Η ειδικότητα είναι κρίσιμη για την αξιολόγηση της αξιοπιστίας των τεστ και των αλγορίθμων, ειδικά όταν οι λανθασμένες θετικές διαγνώσεις μπορούν να έχουν σοβαρές επιπτώσεις, όπως στη διάγνωση ασθενειών. Μια υψηλή ειδικότητα είναι απαραίτητη όταν είναι σημαντικό να αποφεύγονται τα ψευδώς θετικά αποτελέσματα.

Στην τεχνητή νοημοσύνη και τη μηχανική μάθηση, η specificity αναφέρεται στην ακρίβεια ενός αλγορίθμου ή ενός μοντέλου στην αναγνώριση αρνητικών περιπτώσεων μέσα από ένα σύνολο δεδομένων. Είναι ένα από τα κριτήρια αξιολόγησης των αλγορίθμων και χρησιμοποιείται συχνά σε συνδυασμό με την ευαισθησία (sensitivity) για να κατανοηθεί η απόδοση ενός μοντέλου. Η εξισορρόπηση μεταξύ sensitivity και specificity είναι σημαντική για τη βελτιστοποίηση της απόδοσης ενός μοντέλου και είναι κρίσιμη σε πολλές εφαρμογές [9,40].

6.5. Συντελεστής Συσχέτισης του Matthews - Matthews correlation coefficient (MCC)

Η έννοια του Matthews correlation coefficient (MCC) ή γνωστός και ως συντελεστής συσχέτισης του Matthews, είναι ένας στατιστικός δείκτης που χρησιμοποιείται για την αξιολόγηση της απόδοσης ενός ταξινομητή. Ο MCC λαμβάνει υπόψη όλες τις τέσσερις τιμές που μπορούν να προκύψουν από μια ταξινόμηση: αληθώς θετικά (TP), αληθώς αρνητικά (TN), ψευδώς θετικά (FP) και ψευδώς αρνητικά (FN). Αυτό τον καθιστά ιδιαίτερα χρήσιμο για μη ισορροπημένα σύνολα δεδομένων, όπου οι κλάσεις μπορεί να έχουν διαφορετικά μεγέθη.

Ο MCC ορίζεται στη σχέση (5).

$$MCC = \frac{TP * TN - FP * FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (5)$$

Μπορεί να λάβει τιμές από -1 έως 1:

MCC = 1: Τέλεια πρόβλεψη, όπου το μοντέλο ταξινομεί σωστά όλες τις περιπτώσεις.

MCC = 0: Το μοντέλο δεν έχει καμία προβλεπτική ικανότητα και δίνει τυχαίες προβλέψεις (αυτό είναι παρόμοιο με το να ρίχνεις κέρμα).

MCC = -1: Το μοντέλο ταξινομεί όλες τις περιπτώσεις με λάθος τρόπο, δηλαδή κάνει το ακριβώς αντίθετο από το σωστό.

Ο MCC χρησιμοποιείται ευρέως σε εφαρμογές όπου τα σύνολα δεδομένων είναι μη ισορροπημένα και θεωρείται η πιο αντικειμενική και αξιόπιστη μέτρηση απόδοσης για δυαδικούς ταξινομητές. Σε αυτές τις περιπτώσεις, παραδοσιακοί δείκτες όπως η ακρίβεια (accuracy) μπορεί να μην είναι τόσο χρήσιμοι, καθώς μπορούν να επηρεαστούν σημαντικά από την επικρατούσα κλάση. Ο MCC, αντίθετα, παρέχει μια πιο αξιόπιστη μέτρηση της απόδοσης του μοντέλου, λαμβάνοντας υπόψη την ισορροπία μεταξύ των θετικών και αρνητικών κλάσεων. Σε περιπτώσεις με μικρά σύνολα δεδομένων δεν είναι η καλύτερη επιλογή καθώς η ύπαρξη ενός λανθασμένου αποτελέσματος μπορεί να επηρεάσει πολύ περισσότερο το τελικό αποτέλεσμα.

Συνδέεται στενά με άλλους δείκτες, όπως η ακρίβεια (accuracy), η ευαισθησία (sensitivity), η ειδικότητα (specificity), και το F1-score, αλλά είναι πιο γενικευμένος, καθώς χρησιμοποιεί όλες τις τιμές από τον πίνακα σύγχυσης (confusion matrix).

Ο MCC αξιοποιείται σε πολλές εφαρμογές όπως η Βιοϊατρική και τα διαγνωστικά Τεστ, η αναγνώριση απάτης και η ανάλυση γονιδιωματικών δεδομένων ειδικά όταν υπάρχει ανισορροπία στις κλάσεις [16,43,65].

6.6. F1-score (F1)

Το F1-score είναι ένας στατιστικός δείκτης που χρησιμοποιείται για την αξιολόγηση της απόδοσης ενός δυαδικού ταξινομητή. Το F1-score είναι ιδιαίτερα χρήσιμο όταν οι κλάσεις είναι ανισόρροπες, δηλαδή όταν οι αριθμοί των θετικών και αρνητικών περιπτώσεων διαφέρουν σημαντικά.

Το F1-score είναι ο αρμονικός μέσος του precision (ακρίβεια) και του recall (ανάκληση) και ορίζεται στη σχέση (6).

$$F1 - score = 2 * \frac{precision * recall}{precision + recall} \quad (6)$$

Το F1-score κυμαίνεται από 0 έως 1:

FI = 1: Υποδεικνύει τέλεια ακρίβεια και ανάκληση, δηλαδή το μοντέλο εντοπίζει σωστά όλες τις θετικές περιπτώσεις χωρίς να δημιουργεί ψευδώς θετικά.

FI = 0: Υποδεικνύει ότι είτε η ακρίβεια είτε η ανάκληση είναι 0, δηλαδή το μοντέλο είτε δεν εντοπίζει καθόλου θετικές περιπτώσεις είτε έχει πολλές ψευδώς θετικές περιπτώσεις.

Το F1-score χρησιμοποιείται ευρέως σε διάφορους τομείς όπως η ανίχνευση απάτης, η ιατρική διάγνωση, η Μηχανική Μάθηση και η Τεχνητή Νοημοσύνη.

Μπορεί να συγκριθεί με άλλους δείκτες όπως το accuracy (ακρίβεια) και το MCC (Matthews correlation coefficient). Ενώ το accuracy είναι απλό, το F1-score προσφέρει μια πιο ισορροπημένη εκτίμηση όταν οι κλάσεις δεν είναι ισορροπημένες. Το MCC, από την άλλη, λαμβάνει υπόψη και τις τέσσερις τιμές του πίνακα σύγχυσης (TP, TN, FP, FN), ενώ το F1-score επικεντρώνεται μόνο στις θετικές προβλέψεις.

Το F1-score όμως παρουσιάζει ορισμένες αδυναμίες. Η ευαισθησία του σε ακραίες τιμές, ειδικά όταν το precision ή το recall πλησιάζουν το 0, επηρεάζοντας δυσανάλογα το αποτέλεσμα και επιπλέον το γεγονός ότι δεν λαμβάνει υπόψη τα αρνητικά αποτελέσματα, καθώς δεν χρησιμοποιεί τις τιμές των αληθώς αρνητικών (TN) και ψευδώς αρνητικών (FN), κάτι που μπορεί να οδηγήσει σε ελλιπή απόδοση του μοντέλου [27,53,66].

6.7. Καμπύλη ROC & AUC – ROC Curve & AUC

Η καμπύλη ROC ή ROC Curve (Receiver Operating Characteristic Curve) είναι ένα εργαλείο που χρησιμοποιείται για την αξιολόγηση της απόδοσης ενός αλγορίθμου ταξινόμησης, ιδιαίτερα σε δυαδικά προβλήματα ταξινόμησης. Απεικονίζει τη σχέση μεταξύ του ποσοστού των αληθώς θετικών προβλέψεων (True Positive Rate, TPR) και του ποσοστού των ψευδώς θετικών προβλέψεων (False Positive Rate, FPR) για διάφορα κατώφλια (thresholds) πιθανότητας.

True Positive Rate (TPR) ή Sensitivity: Είναι το ποσοστό των πραγματικά θετικών δειγμάτων που αναγνωρίστηκαν σωστά από το μοντέλο. Υπολογίζεται στη σχέση (7).

$$TPR = \frac{TP}{TP + FN} \quad (7)$$

False Positive Rate (FPR): Είναι το ποσοστό των δειγμάτων που είναι αρνητικά, αλλά ταξινομήθηκαν λανθασμένα ως θετικά από το μοντέλο. Υπολογίζεται στη σχέση (8).

$$FPR = \frac{FP}{FP + TN} \quad (8)$$

Η ROC Curve είναι ένα γράφημα όπου ο άξονας x αντιπροσωπεύει το FPR (False Positive Rate) και ο άξονας y το TPR (True Positive Rate). Ένα παράδειγμα αναπαρίσταται στην Εικόνα 7.


Κάθε σημείο στην καμπύλη αντιπροσωπεύει την απόδοση του μοντέλου για ένα συγκεκριμένο κατώφλι ταξινόμησης. Ένα μοντέλο που κάνει τυχαίες προβλέψεις θα έχει ROC Curve που βρίσκεται κοντά στη διαγώνιο (από το σημείο (0,0) στο σημείο (1,1)). Ένα ιδανικό μοντέλο θα έχει μια ROC Curve που φτάνει κοντά στο σημείο (0,1), δηλαδή υψηλό TPR και χαμηλό FPR.

Area Under the Curve (AUC):

AUC (Area Under the Curve) είναι το εμβαδόν κάτω από την ROC Curve και αποτελεί ένα συνοπτικό μέτρο της απόδοσης του μοντέλου.

Το AUC κυμαίνεται από 0 έως 1, όπου:

- Ένα AUC ίσο με 0,5 υποδηλώνει ότι το μοντέλο έχει απόδοση ίση με μια τυχαία πρόβλεψη.
- Ένα AUC κοντά στο 1 υποδηλώνει ένα πολύ καλό μοντέλο, όπου οι προβλέψεις του είναι σε μεγάλο βαθμό ακριβείς.
- Ένα AUC μικρότερο από 0,5 υποδηλώνει ότι το μοντέλο έχει χειρότερη απόδοση από μια τυχαία πρόβλεψη.



Εικόνα 7: Καμπύλη ROC - ROC Curve. Πηγή: <https://www.geeksforgeeks.org/auc-roc-curve/>

Χρήσεις της ROC Curve:

- ❖ **Επιλογή Κατωφλίου (Threshold Selection):** Η ROC Curve επιτρέπει στους χρήστες να επιλέξουν το βέλτιστο κατώφλι για το μοντέλο τους, εξισορροπώντας το TPR και το FPR ανάλογα με τις ανάγκες της εφαρμογής.

- ❖ Σύγκριση Μοντέλων: Χρησιμοποιείται για τη σύγκριση διαφορετικών μοντέλων ταξινόμησης. Ένα μοντέλο με υψηλότερο AUC γενικά θεωρείται καλύτερο.
- ❖ Κατανόηση της Ισορροπίας μεταξύ Ευαισθησίας και Ειδικότητας: Η ROC Curve δείχνει πώς μεταβάλλεται η ευαισθησία (Sensitivity) και η ειδικότητα (Specificity) του μοντέλου όταν αλλάζει το κατώφλι ταξινόμησης.

Η ROC Curve είναι ένα πολύ ισχυρό εργαλείο στην ανάλυση των αποτελεσμάτων ταξινόμησης, ιδιαίτερα όταν τα δεδομένα είναι ανισομερώς κατανομημένα [18,24,55].

7. Μηχανική Μάθηση και Ταξινομητές

Η μηχανική μάθηση αποτελεί έναν συνεχώς εξελισσόμενο κλάδο υπολογιστικών αλγορίθμων που κύριο στόχο έχει την μίμηση της ανθρώπινης νοημοσύνης, “εκπαιδευόμενο” από το περιβάλλον. Το ιδανικό της μηχανικής μάθησης είναι να αφομοιώσει τον τρόπο με τον οποίο κάθε αισθανόμενο ον επεξεργάζεται τα δεδομένα που λαμβάνει (στοιχεία εισόδου) προκειμένου να διαχειριστεί μία κατάσταση ή να επιτύχει κάποιο στόχο (στοιχεία εξόδου).

Η φύση των εν δυνάμει δεδομένων καθορίζει κάθε φορά το είδος-κατηγορία της μηχανικής μάθησης που είναι κατάλληλο για την επεξεργασία τους.

Η Μηχανική μάθηση ασχολείται με αλγορίθμους ταξινόμησης αλλά και παλινδρόμησης. Στην παρούσα διπλωματική θα ασχοληθούμε με αλγορίθμους ταξινόμησης [35,71].

Η μηχανική μάθηση (Machine Learning) είναι ένας κλάδος της τεχνητής νοημοσύνης (AI) που εστιάζει στην ανάπτυξη αλγορίθμων και μοντέλων που επιτρέπουν στους υπολογιστές να μαθαίνουν και να βελτιώνονται αυτόματα μέσω της εμπειρίας, χωρίς να είναι ρητά προγραμματισμένοι για αυτό. Αντί να ακολουθούν μια σταθερή σειρά κανόνων, τα μοντέλα μηχανικής μάθησης εκπαιδεύονται χρησιμοποιώντας δεδομένα και στη συνέχεια μπορούν να κάνουν προβλέψεις ή να λάβουν αποφάσεις με βάση νέα δεδομένα.

Γενικά, η μηχανική μάθηση είναι ένας ταχέως αναπτυσσόμενος τομέας που συνδυάζει στατιστική, πληροφορική και εφαρμογές τεχνητής νοημοσύνης, και έχει σημαντικό αντίκτυπο σε πολλές βιομηχανίες και πτυχές της καθημερινής ζωής.

7.1. Κατηγορίες Μηχανικής Μάθησης

Εποπτευόμενη Μηχανική Μάθηση (Supervised Learning)

Είναι μια προσέγγιση στην οποία το σύστημα εκπαιδεύεται χρησιμοποιώντας ένα σύνολο δεδομένων που περιλαμβάνει παραδείγματα εισόδων και τις αντίστοιχες σωστές εξόδους. Το μοντέλο μαθαίνει να συσχετίζει τις εισόδους με τις εξόδους και στη συνέχεια μπορεί να προβλέψει την έξοδο για νέες εισόδους. Η έξοδος επισημαίνεται π.χ. ταξινόμηση ή παλινδρόμηση. Αυτή η μέθοδος χρησιμοποιείται κυρίως για προβλήματα ταξινόμησης και παλινδρόμησης, με παραδείγματα εφαρμογών όπως η ανάλυση συναισθημάτων, η αναγνώριση εικόνων και η πρόβλεψη τιμών ακινήτων.

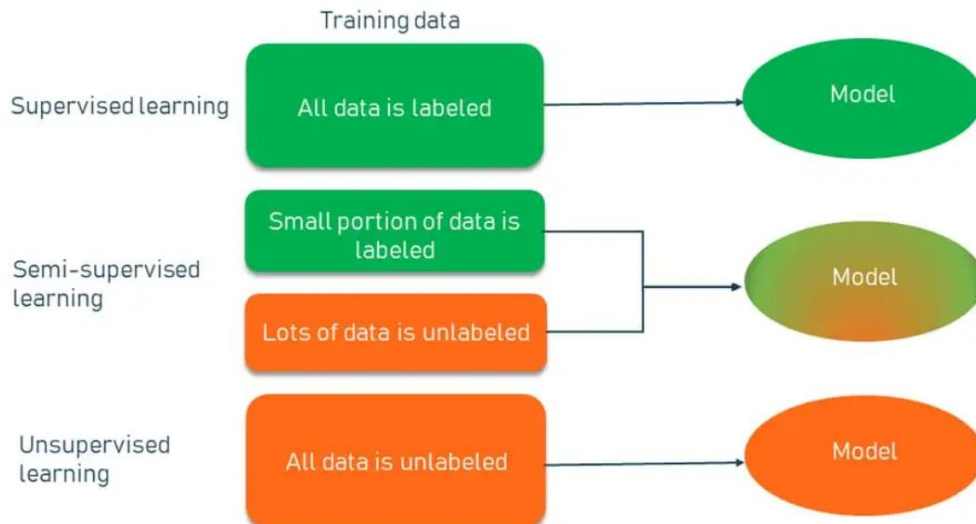
Μη εποπτευόμενη Μηχανική Μάθηση (Unsupervised Learning)

Το σύστημα εκμάθησης λαμβάνει μόνο δείγματα εισόδου. Εκπαιδεύεται δηλαδή με δεδομένα χωρίς καθορισμένες ετικέτες ή εξόδους. Ουσιαστικά, το σύστημα προσπαθεί να εντοπίσει δομές ή μοτίβα μέσα στα δεδομένα και χρησιμοποιείται συχνά για ομαδοποίηση, εκτίμηση συνάρτησης πυκνότητας, πιθανότητας και μείωση διαστάσεων. Παραδείγματα εφαρμογών περιλαμβάνουν την ομαδοποίηση πελατών για στοχευμένο μάρκετινγκ, την ανίχνευση ανωμαλιών και την ανάλυση βασικών συνιστωσών (PCA).

Ημι-εποπτευόμενη Μηχανική Μάθηση (Semi-supervised Learning)

Αποτελεί έναν συνδυασμό της εποπτευόμενης και της μη εποπτευόμενης μηχανικής μάθησης όπου μέρος των δεδομένων που έχουν ταξινομηθεί χρησιμοποιούνται για την ταξινόμηση των μη ταξινομημένων (π.χ. συστήματα ανάκτησης κειμένου/εικόνων).

Στην Εικόνα 8 γίνεται συνοπτική γραφική απεικόνιση των κύριων κατηγοριών της Μηχανικής Μάθησης.



Εικόνα 8: Machine Learning Scheme. Πηγή: <https://www.altexsoft.com/blog/semi-supervised-learning/>

Ενισχυτική Μηχανική Μάθηση (Reinforcement Learning)

Είναι μια μέθοδος όπου ο αλγόριθμος μαθαίνει μέσω δοκιμής και σφάλματος, επιδιώκοντας να μεγιστοποιήσει κάποια ανταμοιβή. Ο πράκτορας αλληλεπιδρά με το περιβάλλον και λαμβάνει ανατροφοδότηση με τη μορφή ανταμοιβής ή τιμωρίας, μαθαίνοντας έτσι ποια ενέργεια να επιλέγει σε κάθε κατάσταση. Παραδείγματα αυτής της προσέγγισης περιλαμβάνουν την ανάπτυξη αλγορίθμων για παιχνίδια όπως το σκάκι ή το Go, αυτόνομα οχήματα και τη ρομποτική [4,48].

7.2. Στοιχεία Μηχανικής Μάθησης

Δεδομένα (Data): Τα δεδομένα είναι το θεμέλιο της μηχανικής μάθησης. Τα μοντέλα εκπαιδεύονται και αξιολογούνται με βάση τα δεδομένα, και η ποιότητα των δεδομένων επηρεάζει άμεσα την απόδοση των μοντέλων.

Αλγόριθμοι (Algorithms): Οι αλγόριθμοι μηχανικής μάθησης είναι τα εργαλεία που χρησιμοποιούνται για την εκμάθηση από τα δεδομένα. Υπάρχουν πολλοί διαφορετικοί τύποι αλγορίθμων, όπως δέντρα αποφάσεων (decision trees), νευρωνικά δίκτυα (neural networks), και μηχανές υποστήριξης διανυσμάτων (SVMs).

Μοντέλα (Models): Ένα μοντέλο είναι το τελικό αποτέλεσμα της εκπαίδευσης ενός αλγορίθμου με δεδομένα. Το μοντέλο μπορεί στη συνέχεια να χρησιμοποιηθεί για να κάνει προβλέψεις ή να λάβει αποφάσεις με βάση νέα δεδομένα.

Εκπαίδευση (Training): Η διαδικασία εκπαίδευσης περιλαμβάνει την προσαρμογή των παραμέτρων ενός μοντέλου ώστε να ελαχιστοποιηθεί η διαφορά μεταξύ των προβλέψεων του μοντέλου και των πραγματικών τιμών στα δεδομένα εκπαίδευσης.

Αξιολόγηση (Evaluation): Μετά την εκπαίδευση, το μοντέλο πρέπει να αξιολογηθεί για την απόδοσή του. Αυτό μπορεί να γίνει χρησιμοποιώντας ένα ξεχωριστό σύνολο δεδομένων, γνωστό ως "σύνολο ελέγχου" ή "σύνολο επικύρωσης".


7.3. Προκλήσεις στη Μηχανική Μάθηση

Οι προκλήσεις στη μηχανική μάθηση περιλαμβάνουν τη διαθεσιμότητα και την ποιότητα των δεδομένων, που είναι κρίσιμες για την ανάπτυξη αξιόπιστων μοντέλων. Μη αντιπροσωπευτικά ή μη ισορροπημένα δεδομένα μπορεί να οδηγήσουν σε μεροληπτικά μοντέλα. Επιπλέον, η υπερπροσαρμογή αποτελεί πρόβλημα όταν το μοντέλο μαθαίνει πολύ καλά τα δεδομένα εκπαίδευσης, αλλά αποτυγχάνει να γενικεύσει σε νέα δεδομένα. Τέλος, η επεξήγηση και η διαφάνεια των μοντέλων, ιδιαίτερα των πιο περίπλοκων όπως τα βαθιά νευρωνικά δίκτυα, παραμένουν σημαντικές προκλήσεις στην κατανόηση και αποδοχή τους [39,44].

7.4. Ταξινομητές

Δέντρα Απόφασης (Decision Trees)

Τα δέντρα απόφασης είναι μια τεχνική μηχανικής μάθησης που χρησιμοποιείται για την επίλυση προβλημάτων ταξινόμησης και παλινδρόμησης. Η βασική ιδέα πίσω από τα δέντρα απόφασης είναι η διαίρεση ενός συνόλου δεδομένων σε μικρότερα υποσύνολα βασισμένα σε κριτήρια απόφασης, τα οποία παρουσιάζονται σε μορφή δέντρου. Το κάθε "φύλλο" του δέντρου αντιπροσωπεύει μια πρόβλεψη, ενώ κάθε "κόμβος" είναι ένα σημείο όπου γίνεται μια απόφαση [4]. Στην Εικόνα 9 φαίνεται ένα παράδειγμα από ένα δέντρο απόφασης.



Εικόνα 9: Δέντρο Απόφασης - Tree Classifier. Πηγή: <https://algodaily.com/lessons/decision-trees-basics>

Δέντρο Απόφασης 'Fine' - Fine Tree

Το Fine Tree είναι ένας τύπος αλγορίθμου μηχανικής μάθησης που ανήκει στην κατηγορία των δέντρων απόφασης. Ο όρος "fine tree" συνήθως αναφέρεται σε ένα δέντρο απόφασης που έχει εκπαιδευτεί με αρκετά μεγάλο βάθος ή αριθμό διακλαδώσεων, επιτρέποντας στο μοντέλο να κάνει λεπτομερείς διακρίσεις μεταξύ των δεδομένων εισόδου. Αυτό μπορεί να αυξήσει την ακρίβεια του μοντέλου, αλλά επίσης αυξάνει τον κίνδυνο υπερπροσαρμογής (overfitting). Για να αντιμετωπιστούν οι προκλήσεις της υπερπροσαρμογής σε fine trees, συχνά εφαρμόζονται τεχνικές όπως το pruning, το οποίο μειώνει το μέγεθος του δέντρου αφαιρώντας διακλαδώσεις που δεν συμβάλλουν σημαντικά στην ακρίβεια του μοντέλου.

Το Fine Tree δημιουργεί πολλαπλά splits, βασισμένα σε κανόνες που προκύπτουν από τα χαρακτηριστικά των δεδομένων, για να καταλήξει σε μια τελική απόφαση. Χρησιμοποιείται συχνά σε προβλήματα που απαιτούν υψηλή ακρίβεια στην ταξινόμηση ή την πρόβλεψη, όπως σε αναλύσεις δεδομένων, ιατρικές διαγνώσεις και χρηματοοικονομικές αναλύσεις. Εκτός από την υπερπροσαρμογή το κύριο μειονέκτημά τους είναι η αυξημένη υπολογιστική απαίτηση, καθιστώντας τα, πιο δύσκολα στην ερμηνεία σε σύγκριση με απλούστερα μοντέλα δέντρων απόφασης [56,76].

Μεσαίο Δέντρο Απόφασης - Medium Tree

Ένα "Medium Tree" (Μεσαίο Δέντρο) στην μηχανική μάθηση αναφέρεται σε ένα μοντέλο δέντρου απόφασης με μέτριο βάθος και αριθμό κόμβων, το οποίο προσπαθεί να ισορροπήσει μεταξύ απλότητας και απόδοσης.

Τα Medium Trees έχουν μέτριο βάθος, δηλαδή δεν είναι τόσο βαθιά όσο τα Fine Trees αλλά ούτε και τόσο ρηχά όσο τα Shallow Trees. Το βάθος τους επιτρέπει να κάνουν πιο συγκεκριμένες διακρίσεις στα δεδομένα από τα απλούστερα δέντρα, αλλά χωρίς να φτάνουν στο σημείο να υπερπροσαρμόζουν τόσο εύκολα.

Σε αντίθεση με τα πολύπλοκα Fine Trees, τα Medium Trees είναι λιγότερο επιρρεπή στην υπερπροσαρμογή επειδή δεν προσπαθούν να χωρίσουν τα δεδομένα σε υπερβολικά μικρές κατηγορίες. Το μέτριο βάθος τους τα βοηθά να γενικεύουν καλύτερα σε νέα δεδομένα, καθιστώντας τα πιο αξιόπιστα σε περιπτώσεις όπου η πρόβλεψη για νέα δεδομένα είναι κρίσιμη.

Χρησιμοποιούνται ευρέως σε εφαρμογές όπου απαιτείται καλή ισορροπία μεταξύ απόδοσης και απλότητας. Είναι κατάλληλα για προβλήματα ταξινόμησης και παλινδρόμησης σε διάφορους τομείς, όπως η ανάλυση δεδομένων, οι ιατρικές διαγνώσεις και η πρόβλεψη σε οικονομικά μοντέλα.

Σε σύγκριση με τα Fine Trees, τα Medium Trees είναι λιγότερο απαιτητικά υπολογιστικά, επειδή έχουν λιγότερους κόμβους και χαμηλότερο βάθος. Αυτό τα καθιστά πιο εύκολα στην εκπαίδευση και την εφαρμογή τους σε μεγαλύτερα σύνολα δεδομένων ή σε περιβάλλοντα με περιορισμένους πόρους.

Τα Medium Trees είναι πιο ερμηνεύσιμα από τα Fine Trees, επειδή η δομή τους είναι πιο απλή και δεν περιλαμβάνει τόσους πολλούς κανόνες και διακλαδώσεις. Αυτό διευκολύνει την κατανόηση του πώς το μοντέλο λαμβάνει αποφάσεις, καθιστώντας το χρήσιμο σε περιπτώσεις όπου η ερμηνεία των αποτελεσμάτων είναι σημαντική.

Γενικά προσφέρουν έναν καλό συμβιβασμό μεταξύ της ικανότητας πρόβλεψης και της γενίκευσης, καθιστώντας τα ιδανικά για πολλές πρακτικές εφαρμογές μηχανικής μάθησης [6,43].

Δέντρο Απόφασης 'Coarse' - Coarse Tree

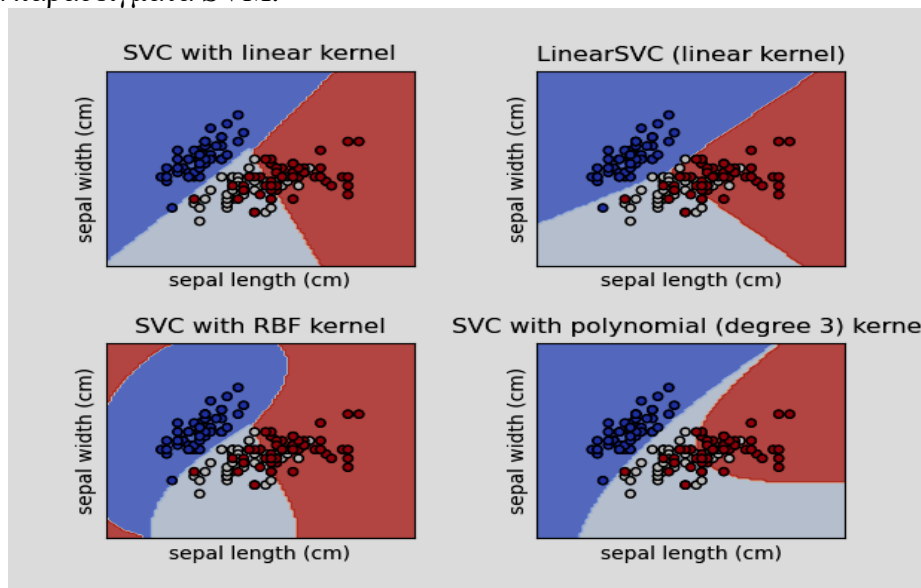
Το "Coarse Tree" ή "Coarse Decision Tree" είναι ένας τύπος αλγορίθμου μηχανικής μάθησης που χρησιμοποιείται για την ταξινόμηση και την παλινδρόμηση (regression). Ανήκει στην οικογένεια των αλγορίθμων Decision Tree (Δέντρα Απόφασης).

Αναφέρεται σε ένα Decision Tree που έχει περιορισμένο βάθος ή περιορισμένο αριθμό κόμβων και φύλλων. Συχνά ονομάζεται "coarse" επειδή το δέντρο είναι σχετικά απλό και δεν περιλαμβάνει πολλές λεπτομέρειες στη δομή του. Αυτό σημαίνει ότι έχει λίγους κόμβους και παράγει γενικές προβλέψεις χωρίς να πηγαίνει σε μεγάλο βάθος ανάλυσης των δεδομένων.

Το Coarse Tree είναι ένα μοντέλο απόφασης που διακρίνεται για την απλότητά του και τη δυνατότητά του να γενικεύει καλά, ιδιαίτερα όταν τα δεδομένα περιέχουν θόρυβο ή είναι πολύπλοκα. Με μικρό βάθος, το Coarse Tree αποφεύγει την υπερπροσαρμογή (overfitting) εξαιτίας του περιορισμένου αριθμού διακλαδώσεων και φύλλων, κάτι που το καθιστά χρήσιμο σε περιπτώσεις όπου απαιτείται ένα γρήγορο και απλό μοντέλο ή όταν τα δεδομένα είναι περιορισμένα. Παρά τα πλεονεκτήματά του, όπως η γρήγορη εκπαίδευση και η ευκολία κατανόησης των αποφάσεών του, το Coarse Tree υστερεί σε ακρίβεια συγκριτικά με πιο περίπλοκα μοντέλα και μπορεί να χάσει λεπτομέρειες που σχετίζονται με πιο πολύπλοκες σχέσεις μεταξύ των χαρακτηριστικών των δεδομένων [2,4].

Μηχανή Υποστήριξης Διανυσμάτων – Support Vector Machine (SVM)

Η Μηχανή Υποστήριξης Διανυσμάτων ή αλλιώς SVM είναι ένας δημοφιλής αλγόριθμος μηχανικής μάθησης που χρησιμοποιείται για την επίλυση προβλημάτων ταξινόμησης και παλινδρόμησης. Η βασική ιδέα πίσω από το SVM είναι η εύρεση ενός υπερεπίπεδου (hyperplane) που χωρίζει τα δεδομένα σε διαφορετικές κλάσεις με τον καλύτερο δυνατό τρόπο, μεγιστοποιώντας την απόσταση μεταξύ των πλησιέστερων σημείων των κλάσεων, που ονομάζονται support vectors. Όταν τα δεδομένα δεν είναι γραμμικά διαχωρίσιμα, χρησιμοποιούνται πυρήνες (kernels) για να χαρτογραφηθεί το πρόβλημα σε έναν υψηλότερο διαστασιακό χώρο, όπου είναι ευκολότερο να βρεθεί ένα γραμμικό διαχωριστικό [4]. Στην Εικόνα 10 απεικονίζονται κάποια παραδείγματα SVM.



Εικόνα 10: Ταξινόμητης SVM. Πηγή: <https://scikit-learn.org/stable/modules/svm.html>

Τετραγωνικός SVM - Quadratic SVM

Ο Quadratic SVM (Support Vector Machine) είναι μια παραλλαγή του αλγορίθμου SVM, η οποία χρησιμοποιεί έναν τετραγωνικό (quadratic) πυρήνα για την ταξινόμηση δεδομένων.

Αναφέρεται σε ένα SVM που χρησιμοποιεί έναν τετραγωνικό πυρήνα (quadratic kernel) για να χαρτογραφήσει τα δεδομένα από τον αρχικό χώρο χαρακτηριστικών σε έναν υψηλότερο διαστασιακό χώρο, όπου μπορεί να βρεθεί μια καλύτερη διαχωριστική γραμμή ή επιφάνεια.

Ο τετραγωνικός πυρήνας είναι μια ειδική περίπτωση του πολυωνυμικού πυρήνα (polynomial kernel), όπου ο βαθμός (degree) είναι ίσος με 2. Ο πυρήνας αυτός ορίζεται στη σχέση (9).

$$K(x_i, x_j) = (x_i * x_j + c)^2 \quad (9)$$

Όπου:

x_i και x_j είναι τα διανύσματα χαρακτηριστικών

c είναι μία παράμετρος που μπορεί να ρυθμιστεί για να επηρεάσει τη χαρτογράφηση

Ο Quadratic SVM προσφέρει πλεονεκτήματα όπως η δυνατότητα χειρισμού μη γραμμικών δεδομένων, καθώς ο τετραγωνικός πυρήνας μπορεί να διαχωρίσει δεδομένα που δεν είναι διαχωρίσιμα με γραμμική προσέγγιση. Επιπλέον, παρέχει αυξημένη ευελιξία, λειτουργώντας ως ενδιάμεση λύση μεταξύ της απλότητας του γραμμικού SVM και της πολυπλοκότητας ενός πολυωνυμικού SVM υψηλότερου βαθμού, κάτι που μπορεί να οδηγήσει σε καλύτερη απόδοση σε ορισμένα σύνολα δεδομένων με σαφή, αλλά μη γραμμική, σχέση μεταξύ των χαρακτηριστικών και των κλάσεων. Ωστόσο, ο Quadratic SVM συνοδεύεται και από μειονεκτήματα, όπως η αυξημένη υπολογιστική πολυπλοκότητα και ο χρόνος εκπαίδευσης σε σύγκριση με το γραμμικό SVM, καθώς και ο κίνδυνος υπερπροσαρμογής εάν το μοντέλο δεν ρυθμιστεί σωστά.

Γενικά, χρησιμοποιείται σε προβλήματα όπου τα δεδομένα δεν είναι γραμμικά διαχωρίσιμα, αλλά ο τετραγωνικός πυρήνας επιτρέπει στο SVM να διαχωρίζει τα δεδομένα και προσφέρει μια καλή ισορροπία μεταξύ ακρίβειας και πολυπλοκότητας. Ενδεικτικά παραδείγματα εφαρμογών περιλαμβάνουν την αναγνώριση προτύπων, την ανάλυση εικόνας και τη βιοπληροφορική [8,49,72].

Κυβικός SVM - Cubic SVM

Ο Cubic SVM (Support Vector Machine) αναφέρεται σε έναν SVM αλγόριθμο που χρησιμοποιεί έναν κυβικό πυρήνα (cubic kernel) για την ταξινόμηση δεδομένων. Ο κυβικός πυρήνας είναι μια ειδική περίπτωση του πολυωνυμικού πυρήνα, όπου ο βαθμός του πολυωνύμου είναι 3. Η μαθηματική του έκφραση φαίνεται στη σχέση (10).

$$K(x_i, x_j) = (x_i * x_j + c)^3 \quad (10)$$

Όπου:

x_i και x_j είναι τα διανύσματα χαρακτηριστικών

c είναι μία παράμετρος που μπορεί να ρυθμιστεί για να επηρεάσει τη χαρτογράφηση

Ο κυβικός πυρήνας επιτρέπει στο SVM να διαχωρίζει δεδομένα που δεν είναι γραμμικά ή τετραγωνικά διαχωρίσιμα στον αρχικό χώρο χαρακτηριστικών, επιτρέποντας πιο σύνθετες μη γραμμικές σχέσεις.

Ο Cubic SVM προσφέρει τη δυνατότητα χειρισμού πιο σύνθετων σχέσεων στα δεδομένα, σε σύγκριση με τους γραμμικούς και τετραγωνικούς πυρήνες. Με την αυξημένη ευελιξία του, μπορεί να αντιμετωπίσει δεδομένα με περίπλοκες δομές, και σε ορισμένες περιπτώσεις, να προσφέρει καλύτερη γενίκευση από τους απλούστερους πυρήνες. Ωστόσο, η χρήση του Cubic SVM συνοδεύεται από αυξημένη πολυπλοκότητα, γεγονός που μπορεί να οδηγήσει σε μεγαλύτερους χρόνους εκπαίδευσης και δυσκολότερη ερμηνεία των αποτελεσμάτων. Επιπλέον, υπάρχει κίνδυνος υπερπροσαρμογής, ειδικά όταν το μοντέλο εφαρμόζεται σε μικρά σύνολα δεδομένων με μεγάλο αριθμό χαρακτηριστικών, ενώ οι αυξημένες απαιτήσεις σε υπολογιστικούς πόρους μπορεί να αποτελέσουν πρόκληση. Ο Cubic SVM είναι ιδιαίτερα χρήσιμο σε περιπτώσεις όπου οι σχέσεις μεταξύ των χαρακτηριστικών και των κλάσεων είναι ιδιαίτερα πολύπλοκες και δεν μπορούν να αναπαρασταθούν επαρκώς με γραμμικούς ή τετραγωνικούς πυρήνες, όπως στην αναγνώριση προτύπων, την ανάλυση εικόνας και τη βιοπληροφορική, όπου οι αλληλεπιδράσεις είναι συχνά περίπλοκες [49,61,72].

Fine Gaussian SVM

Ο Fine Gaussian SVM είναι μια παραλλαγή του αλγορίθμου Support Vector Machine (SVM) που χρησιμοποιεί έναν Gaussian πυρήνα (επίσης γνωστό ως Radial Basis Function ή RBF πυρήνα) με λεπτή ρύθμιση της παραμέτρου του εύρους (σ). Αυτή η μέθοδος είναι ιδιαίτερα χρήσιμη όταν τα δεδομένα δεν είναι γραμμικά διαχωρίσιμα στον αρχικό τους χώρο και απαιτείται μια μη γραμμική χαρτογράφηση για τη δημιουργία ενός αποτελεσματικού διαχωριστικού υπερεπιπέδου.

Ο πυρήνας Gaussian (RBF) είναι ένας από τους πιο δημοφιλείς πυρήνες που χρησιμοποιούνται σε SVM. Ο RBF πυρήνας χαρτογραφεί τα δεδομένα σε έναν άπειρα διαστασιακό χώρο, όπου μπορεί να εφαρμοστεί ένας γραμμικός διαχωρισμός. Η συνάρτηση του Gaussian πυρήνα δίνεται από την σχέση (11).

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (11)$$

Όπου:

x_i και x_j είναι τα διανύσματα χαρακτηριστικών.

$\|x_i - x_j\|^2$ είναι η Ευκλείδεια απόσταση μεταξύ των δύο σημείων.

σ είναι η παράμετρος του πυρήνα που καθορίζει το εύρος της γκαουσιανής καμπύλης.

Το "Fine" αναφέρεται στη χρήση μιας μικρής τιμής για την παράμετρο σ η οποία κάνει τη γκαουσιανή καμπύλη πιο στενή και το μοντέλο πιο ευαίσθητο στις λεπτές διαφορές μεταξύ των σημείων δεδομένων. Ένας Fine Gaussian SVM μπορεί να εντοπίσει μικρά, αλλά σημαντικά μοτίβα στα δεδομένα, που διαφορετικά θα

μπορούσαν να αγνοηθούν από μοντέλα με πιο ευρεία καμπύλη (δηλαδή, μεγαλύτερη τιμή σ).

Ο Fine Gaussian SVM προσφέρει σημαντικά πλεονεκτήματα, όπως η ικανότητα αναγνώρισης μικρών δομών στα δεδομένα, λόγω της μικρής τιμής του σ , επιτρέποντας στο μοντέλο να διαχωρίζει με μεγαλύτερη ακρίβεια δεδομένα που βρίσκονται κοντά μεταξύ τους. Είναι επίσης ικανό να διαχειρίζεται πολύπλοκες, μη γραμμικές σχέσεις μεταξύ των χαρακτηριστικών και των κλάσεων, παρέχοντας αυξημένη ευαισθησία σε μικρές διακυμάνσεις στα δεδομένα, κάτι που είναι κρίσιμο για την επίτευξη υψηλής ακρίβειας. Ωστόσο, ο Fine Gaussian SVM συνοδεύεται από μειονεκτήματα, όπως ο κίνδυνος υπερπροσαρμογής, λόγω της μικρής τιμής του σ , που μπορεί να μειώσει την ικανότητα του μοντέλου να γενικεύσει σε νέα δεδομένα. Επιπλέον, η αυξημένη ευαισθησία του μοντέλου μπορεί να οδηγήσει σε υψηλότερη υπολογιστική πολυπλοκότητα και δυσκολία στη ρύθμιση του σ , η οποία απαιτεί προσεκτική διαδικασία μέσω cross-validation για να αποφευχθεί η υπερπροσαρμογή. Ο Fine Gaussian SVM χρησιμοποιείται κυρίως σε εφαρμογές όπου οι διαφορές μεταξύ των κλάσεων είναι μικρές και απαιτείται μεγάλη ακρίβεια στον διαχωρισμό των δεδομένων, όπως στην ανάλυση εικόνας, τη βιοπληροφορική και σε άλλες περιπτώσεις όπου η αναγνώριση λεπτών προτύπων είναι απαραίτητη. Συνολικά, ο Fine Gaussian SVM είναι κατάλληλο για εφαρμογές που απαιτούν ένα μοντέλο υψηλής ευαισθησίας, αλλά η ρύθμισή του πρέπει να γίνεται προσεκτικά για να διατηρηθεί η ικανότητα γενίκευσης και να αποφευχθεί η υπερπροσαρμογή [1,61,72].

Medium Gaussian SVM

Ο Medium Gaussian SVM είναι μια παραλλαγή του αλγορίθμου Support Vector Machine (SVM) που χρησιμοποιεί έναν Gaussian πυρήνα (Radial Basis Function, RBF) (με μέτρια τιμή για την παράμετρο του εύρους (συνήθως αναφέρεται ως σ ή γ). Αυτή η προσέγγιση προσπαθεί να ισορροπήσει μεταξύ της δυνατότητας αναγνώρισης λεπτομερών μοτίβων στα δεδομένα και της αποφυγής υπερπροσαρμογής (overfitting). Η παράμετρος σ καθορίζει την "ευαισθησία" του SVM. Στο Medium Gaussian SVM, η τιμή του σ επιλέγεται έτσι ώστε να μην είναι ούτε πολύ μικρή ούτε πολύ μεγάλη, αλλά να βρίσκεται σε μια ενδιάμεση τιμή. Αυτό σημαίνει ότι το μοντέλο θα είναι ικανό να συλλαμβάνει τις σχέσεις μεταξύ των σημείων δεδομένων, χωρίς όμως να επικεντρώνεται υπερβολικά στις μικρές λεπτομέρειες που θα μπορούσαν να οδηγήσουν σε υπερπροσαρμογή.

Ο Medium Gaussian SVM προσφέρει μια ισορροπία μεταξύ ευαισθησίας και γενίκευσης και δίνει τη δυνατότητα στο μοντέλο να συλλαμβάνει σημαντικά μοτίβα στα δεδομένα, διατηρώντας παράλληλα την ικανότητα γενίκευσης σε νέα, άγνωστα δεδομένα. Είναι ιδιαίτερα αποτελεσματικό σε εφαρμογές με πολυδιάστατα δεδομένα, όπου οι σχέσεις μεταξύ των χαρακτηριστικών δεν είναι εύκολα διαχωρίσιμες με γραμμικούς ή πολυωνυμικούς πυρήνες. Επιπλέον, σε σύγκριση με τον Fine Gaussian SVM, ο Medium Gaussian SVM μειώνει τον κίνδυνο υπερπροσαρμογής, καθιστώντας το πιο ανθεκτικό σε θόρυβο στα δεδομένα. Ωστόσο, ο Medium Gaussian SVM μπορεί να μην είναι αρκετά ευαίσθητο για να αναγνωρίσει πολύ λεπτά μοτίβα που είναι κρίσιμα για την ταξινόμηση, και η επιλογή της παραμέτρου σ απαιτεί προσεκτική ρύθμιση μέσω διαδικασιών όπως το cross-validation για την επίτευξη της βέλτιστης απόδοσης.

Ο Medium Gaussian SVM προσφέρει μια ισορροπημένη προσέγγιση στην ταξινόμηση δεδομένων με μη γραμμικές σχέσεις, αποφεύγοντας τα ακραία

προβλήματα υπερπροσαρμογής και υποπροσαρμογής που μπορεί να προκύψουν με άλλες παραμέτρους του πυρήνα [49,61,72].

Coarse Gaussian SVM

Ο Coarse Gaussian SVM είναι ένας τύπος Support Vector Machine (SVM), που είναι μια επιβλεπόμενη τεχνική μηχανικής μάθησης που χρησιμοποιείται για ταξινόμηση και παλινδρόμηση. Η διαφορά μεταξύ του Coarse Gaussian SVM και άλλων SVM έγκειται στον πυρήνα (kernel) που χρησιμοποιείται και στις παραμέτρους του.

Στον Gaussian SVM, χρησιμοποιείται ένας Gaussian (ή Radial Basis Function - RBF) πυρήνας. Αυτός ο πυρήνας επιτρέπει στον SVM να δημιουργεί ένα μη γραμμικό υπερεπίπεδο που μπορεί να διαχωρίσει πιο σύνθετα δεδομένα. Ο Gaussian πυρήνας εξαρτάται από μια παράμετρο που ονομάζεται sigma (σ), η οποία καθορίζει τη διάμετρο της γκαουσιανής κατανομής. Το σφάλμα εκπαίδευσης μπορεί να ελαχιστοποιηθεί προσαρμόζοντας αυτή την παράμετρο.

Ο Coarse Gaussian SVM αναφέρεται σε μια συγκεκριμένη ρύθμιση του Gaussian SVM όπου χρησιμοποιείται ένα σχετικά μεγάλο σ . Το "coarse" υποδηλώνει ότι η τιμή του σ είναι μεγάλη, πράγμα που σημαίνει ότι ο πυρήνας έχει ευρύτερη επιρροή. Αυτό οδηγεί σε ένα πιο "ομαλό" διαχωριστικό υπερεπίπεδο που μπορεί να είναι πιο γενικευμένο αλλά λιγότερο ακριβές σε λεπτομέρειες.


Ο Coarse Gaussian SVM χρησιμοποιεί τη Gaussian συνάρτηση πυρήνα (RBF) με μεγάλο σ , επιτρέποντας στο μοντέλο να γενικεύει καλά, αποφεύγοντας την υπερπροσαρμογή στα δεδομένα εκπαίδευσης. Ωστόσο, μπορεί να μην καταγράφει όλες τις λεπτές διαφορές στα δεδομένα. Αυτό το μοντέλο είναι κατάλληλο για περιπτώσεις όπου τα δεδομένα είναι πολύπλοκα, αλλά δεν απαιτείται υπερβολική λεπτομέρεια στην ανάλυση. Σε σύγκριση με άλλους τύπους SVM, όπως το Fine Gaussian SVM που χρησιμοποιεί μικρότερο σ και είναι πιο λεπτομερές με μεγαλύτερο κίνδυνο υπερπροσαρμογής, το Coarse Gaussian SVM προσφέρει μια πιο ισορροπημένη προσέγγιση. Αντίθετα, το Linear SVM εφαρμόζεται όταν τα δεδομένα είναι γραμμικά διαχωρίσιμα και δεν απαιτείται μη γραμμικός πυρήνας.

Ο Coarse Gaussian SVM είναι κατάλληλος για προβλήματα όπου απαιτείται ένα πιο γενικευμένο μοντέλο που μπορεί να λειτουργήσει καλά με δεδομένα που είναι πιο θορυβώδη ή όπου δεν χρειάζεται να ανιχνευτούν όλες οι λεπτές διαφορές [4,25,62].

Ταξινομητής Πλησιέστερου Γείτονα - KNN

Ο Ταξινομητής Πλησιέστερου Γείτονα KNN είναι ένας αλγόριθμος μηχανικής μάθησης που βασίζεται στην ομοιότητα μεταξύ δεδομένων. Για να ταξινομήσει ένα νέο δείγμα, ο KNN εξετάζει τα K πλησιέστερα γειτονικά σημεία στο χώρο χαρακτηριστικών και αναθέτει την κατηγορία που είναι πιο κοινή-συχνή μεταξύ αυτών των γειτόνων, όπως φαίνεται στην Εικόνα 11. Ο αλγόριθμος KNN ξεχωρίζει για την απλότητά του, καθώς δεν απαιτεί διαδικασία εκπαίδευσης και βασίζεται αποκλειστικά στα δεδομένα που αποθηκεύονται στη μνήμη. Ωστόσο, η επιλογή του αριθμού K είναι κρίσιμη για την απόδοσή του. Ένα μικρό K μπορεί να προκαλέσει υπερπροσαρμογή, οδηγώντας σε θορυβώδη ταξινόμηση, ενώ ένα μεγάλο K μπορεί να υπεραπλοποιήσει το μοντέλο, με αποτέλεσμα υποπροσαρμογή [4].

K Nearest Neighbors



Εικόνα 11: Ταξινομητής Πλησιέστερου Γείτονα - KNN Classifier. Πηγή: <https://medium.com/data-hackers/knn-k-nearest-neighbor-o-que-%C3%A9-aebe0f833eb>

Ταξινομητής Πλησιέστερου Γείτονα 'Fine' - Fine KNN

Ο Fine K-Nearest Neighbors (Fine KNN) είναι μια παραλλαγή του αλγόριθμου K-Nearest Neighbors (KNN), η οποία χρησιμοποιεί έναν συγκεκριμένο αριθμό γειτόνων για την ταξινόμηση δεδομένων. Ο χαρακτηρισμός "Fine" αναφέρεται στον αριθμό των γειτόνων που επιλέγονται, και συνήθως σημαίνει ότι χρησιμοποιείται ένας μικρότερος αριθμός γειτόνων για να γίνει η ταξινόμηση πιο λεπτομερής και ακριβής. Συνήθως χρησιμοποιείται ένα πολύ μικρό K, όπως K=1 ή K=3, για να δημιουργηθεί μια πιο ακριβής και λεπτομερής ταξινόμηση. Στη παρούσα μελέτη χρησιμοποιήθηκε K=1.

Ο Fine KNN είναι ένα μοντέλο με μικρό αριθμό γειτόνων (K), το οποίο το καθιστά πιο ακριβές, ιδιαίτερα σε προβλήματα όπου οι κατηγορίες είναι καλά διαχωρισμένες και η απόσταση μεταξύ των σημείων παίζει σημαντικό ρόλο στην ταξινόμηση. Ωστόσο, λόγω του μικρού K, το Fine KNN είναι πιο ευαίσθητο σε θόρυβο στα δεδομένα, καθώς λαμβάνει υπόψη μόνο λίγους γείτονες. Χρησιμοποιείται κυρίως σε εφαρμογές όπου η λεπτομερής διαφοροποίηση μεταξύ κατηγοριών είναι κρίσιμη, όπως στην ιατρική διάγνωση ή σε συστήματα αναγνώρισης μοτίβων. Σε σύγκριση με το Coarse KNN, το οποίο χρησιμοποιεί μεγαλύτερο K και παρέχει πιο γενικευμένη ταξινόμηση με λιγότερη ευαισθησία στον θόρυβο, το Fine KNN προσφέρει πιο λεπτομερή ανάλυση αλλά με μεγαλύτερο κίνδυνο επηρεασμού από τον θόρυβο.

Ο Fine KNN είναι ιδιαίτερα χρήσιμος όταν τα δεδομένα είναι καλά διαχωρισμένα και η ακρίβεια στην ταξινόμηση είναι πιο σημαντική από την ταχύτητα ή την ανθεκτικότητα στον θόρυβο [4,25,63].

Ταξινομητής Πλησιέστερου Γείτονα 'Medium' - Medium KNN

Ο Medium K-Nearest Neighbors (Medium KNN) είναι μια παραλλαγή του αλγόριθμου K-Nearest Neighbors (KNN), όπου επιλέγεται ένας μεσαίος αριθμός γειτόνων (K) για να γίνει η ταξινόμηση ενός νέου δείγματος δεδομένων.

Στον αλγόριθμο Medium KNN, το K επιλέγεται να είναι ένας μεσαίος αριθμός, συνήθως κάπου ανάμεσα σε μικρό και μεγάλο K . Αυτό σημαίνει ότι ο αλγόριθμος χρησιμοποιεί έναν μέτριο αριθμό γειτόνων για να αποφασίσει σε ποια κατηγορία ανήκει ένα νέο δείγμα.

Ο Medium KNN χαρακτηρίζεται από έναν μεσαίο αριθμό γειτόνων, συνήθως μεταξύ 5 και 10, προσφέροντας μια ισορροπία μεταξύ λεπτομέρειας και γενίκευσης. Δεν είναι τόσο λεπτομερές όσο ο Fine KNN με μικρότερο K , αλλά ούτε τόσο γενικευμένο όσο ο Coarse KNN με μεγαλύτερο K . Στη παρούσα μελέτη χρησιμοποιήθηκε $K=5$. Συνήθως παρέχει καλή ακρίβεια και σταθερότητα, καθώς χρησιμοποιεί αρκετούς γείτονες για να αποφύγει την ευαισθησία στον θόρυβο, χωρίς να υπεραπλοποιεί τις αποφάσεις. Λόγω του μέτριου αριθμού γειτόνων, είναι λιγότερο ευαίσθητο στον θόρυβο από το Fine KNN, καθώς η απόφαση στηρίζεται σε περισσότερους γείτονες, μειώνοντας την επίδραση μεμονωμένων θορυβωδών δεδομένων. Ο Medium KNN χρησιμοποιείται συχνά σε προβλήματα ταξινόμησης όπου απαιτείται μια καλή ισορροπία μεταξύ ακρίβειας και γενίκευσης, όπως στην αναγνώριση προτύπων και την ανάλυση δεδομένων με μέτρια πολυπλοκότητα. Σε σύγκριση με το Fine KNN, που εστιάζει στις λεπτομέρειες αλλά είναι πιο ευαίσθητο στον θόρυβο, και ο Coarse KNN, που δίνει έμφαση στη γενίκευση με λιγότερη ευαισθησία στον θόρυβο, ο Medium KNN προσφέρει μια ιδανική ενδιάμεση λύση.

Ο Medium KNN είναι κατάλληλο για περιπτώσεις όπου τα δεδομένα δεν είναι ούτε πολύ απλά ούτε πολύ περίπλοκα, και χρειάζεται ένα μοντέλο που να μπορεί να αποδώσει καλά σε ποικίλα σενάρια ταξινόμησης [4,25,63].

Ταξινόμητης Πλησιέστερου Γείτονα 'Coarse' - Coarse KNN

Ο Coarse K-Nearest Neighbors (Coarse KNN) είναι μια παραλλαγή του αλγόριθμου K-Nearest Neighbors (KNN), στην οποία επιλέγεται ένας μεγάλος αριθμός γειτόνων (K) για την ταξινόμηση ενός δείγματος δεδομένων. Αυτή η επιλογή οδηγεί σε μια πιο γενικευμένη προσέγγιση ταξινόμησης, καθώς η απόφαση βασίζεται σε μεγαλύτερη ομάδα γειτόνων, μειώνοντας έτσι την ευαισθησία σε μεμονωμένα σημεία δεδομένων. Στον αλγόριθμο Coarse KNN, το K επιλέγεται να είναι ένας μεγάλος αριθμός, συχνά μεγαλύτερος από 10, ή ακόμα και 20 ή περισσότερους, ανάλογα με το μέγεθος του συνόλου δεδομένων και την πυκνότητα του χώρου χαρακτηριστικών. Στη παρούσα μελέτη χρησιμοποιήθηκε $K=10$.

Ο Coarse KNN χαρακτηρίζεται από τη χρήση μεγάλου αριθμού γειτόνων (K), γεγονός που οδηγεί σε πιο γενικευμένες αποφάσεις ταξινόμησης. Αυτή η προσέγγιση προσφέρει μεγαλύτερη γενίκευση, καθώς στηρίζεται σε πολλούς γείτονες, κάνοντάς την λιγότερο ευαίσθητη σε θορυβώδη ή μη αντιπροσωπευτικά δεδομένα. Η μεγάλη τιμή του K καθιστά το μοντέλο πιο ανθεκτικό στον θόρυβο, αφού μεμονωμένα θορυβώδη σημεία δεν επηρεάζουν σημαντικά τη συνολική απόφαση. Ωστόσο, η ακρίβεια μπορεί να επηρεαστεί, καθώς η υπεραπλοποίηση που προκύπτει από το μεγάλο K μπορεί να αγνοήσει λεπτές διαφοροποιήσεις μεταξύ των κατηγοριών. Ο Coarse KNN χρησιμοποιείται κυρίως σε περιπτώσεις όπου απαιτείται ένα σταθερό και ανθεκτικό μοντέλο, ειδικά όταν τα δεδομένα είναι θορυβώδη ή οι κατηγορίες δεν είναι σαφώς διαχωρισμένες. Σε σύγκριση με άλλα είδη KNN, όπως ο Fine και ο Medium, ο Coarse KNN προσφέρει μεγαλύτερη γενίκευση και ανθεκτικότητα στον θόρυβο, αλλά ενδέχεται να χάσει σε λεπτομέρεια. Αντίθετα, ο Fine KNN χρησιμοποιεί μικρό K για πιο λεπτομερείς ταξινομήσεις, ενώ ο Medium KNN προσφέρει έναν συμβιβασμό μεταξύ ακρίβειας και γενίκευσης.

Ο Coarse KNN είναι ιδιαίτερα χρήσιμο σε εφαρμογές όπου προτεραιότητα έχει η σταθερότητα του μοντέλου και η αντίσταση στον θόρυβο, όπως σε συστήματα με δεδομένα που έχουν μεγάλη ποικιλία ή που μπορεί να περιέχουν θορυβώδη σημεία [4,25,63].

Ταξινόμητης Πλησιέστερου Γείτονα Συνημιτόνου - Cosine KNN

Ο Cosine K-Nearest Neighbors (Cosine KNN) είναι μια παραλλαγή του αλγορίθμου K-Nearest Neighbors (KNN) που χρησιμοποιεί τη συνημιτονική ομοιότητα (cosine similarity) για να μετρήσει την ομοιότητα μεταξύ των σημείων δεδομένων. Η συνημιτονική ομοιότητα είναι ένα μέτρο που υπολογίζει την ομοιότητα μεταξύ δύο διανυσμάτων βάσει της γωνίας μεταξύ τους. Ορίζεται ως το συνημίτονο της γωνίας μεταξύ δύο μηδενικών διανυσμάτων και παίρνει τιμές από -1 έως 1.

Σε αντίθεση με τον παραδοσιακό KNN, ο οποίος συχνά χρησιμοποιεί την Ευκλείδεια απόσταση. Ο Cosine KNN είναι ιδανικό για προβλήματα όπου η κατεύθυνση των διανυσμάτων (και όχι το μέγεθός τους) είναι πιο σημαντική.

Στον αλγόριθμο Cosine KNN, η συνημιτονική ομοιότητα χρησιμοποιείται για να μετρηθεί η "απόσταση" μεταξύ των σημείων δεδομένων. Η προσέγγιση αυτή είναι ιδιαίτερα χρήσιμη όταν τα δεδομένα είναι υψηλής διάστασης και αντιπροσωπεύονται καλύτερα ως διανύσματα σε έναν χώρο χαρακτηριστικών.

Ο Cosine KNN διακρίνεται από το ότι εστιάζει στην κατεύθυνση των διανυσμάτων και όχι στο μέγεθός τους. Αυτό σημαίνει ότι δύο διανύσματα με την ίδια κατεύθυνση θεωρούνται παρόμοια, ανεξάρτητα από το μήκος τους. Αυτή η προσέγγιση είναι ιδιαίτερα κατάλληλη για προβλήματα υψηλής διάστασης, όπως η ταξινόμηση κειμένων, όπου τα δεδομένα αναπαρίστανται ως διανύσματα λέξεων. Η συνημιτονική ομοιότητα προσφέρει ανθεκτικότητα στη μεταβλητότητα του μεγέθους των χαρακτηριστικών, σε αντίθεση με την Ευκλείδεια απόσταση που επηρεάζεται απόλυτα από το μέγεθος. Ο Cosine KNN χρησιμοποιείται ευρέως σε εφαρμογές επεξεργασίας φυσικής γλώσσας (NLP), όπως η σύσταση εγγράφων, η κατηγοριοποίηση κειμένων και η ανάλυση συναισθήματος, όπου τα δεδομένα είναι συχνά σπάνια και υψηλής διάστασης. Σε σύγκριση με την Ευκλείδεια απόσταση, ο Cosine KNN είναι ιδανικό όταν η κατεύθυνση των διανυσμάτων είναι πιο σημαντική από την απόλυτη απόσταση, ενώ η Ευκλείδεια απόσταση είναι καταλληλότερη για προβλήματα όπου οι μετρήσεις σε απόλυτες κλίμακες έχουν ουσιαστική σημασία.

Ο Cosine KNN είναι ιδιαίτερα χρήσιμος όταν αντιμετωπίζουμε δεδομένα όπως διανύσματα λέξεων, εικόνες, ή άλλα προβλήματα όπου η σχετική κατεύθυνση των δεδομένων είναι πιο σημαντική από το απόλυτο μέγεθός τους [4,36,63].

Κυβικός Ταξινόμητης Πλησιέστερου Γείτονα - Cubic KNN

Ο "Cubic KNN" αναφέρεται στον κοντινότερο γείτονα k (k-nearest neighbors, KNN) με χρήση κυβικής παρεμβολής (cubic interpolation) για την ταξινόμηση ή την παλινδρόμηση. Το KNN είναι ένας αλγόριθμος μηχανικής μάθησης που χρησιμοποιείται τόσο για ταξινόμηση όσο και για παλινδρόμηση και βασίζεται στην ιδέα ότι οι παρατηρήσεις με παρόμοια χαρακτηριστικά βρίσκονται κοντά στον χώρο των χαρακτηριστικών.

Στον αλγόριθμο Cubic KNN, όταν απαιτείται η πρόβλεψη της κατηγορίας ή της τιμής μιας νέας παρατήρησης, ο αλγόριθμος πρώτα εντοπίζει τους k πλησιέστερους γείτονες της παρατήρησης στον χώρο των χαρακτηριστικών. Στη συνέχεια, χρησιμοποιεί κυβική παρεμβολή για να υπολογίσει την απόσταση ή την ομοιότητα

μεταξύ της νέας παρατήρησης και των γειτόνων της. Η κυβική παρεμβολή είναι μια τεχνική που χρησιμοποιεί ένα κυβικό πολυώνυμο για να "λειάνει" την καμπύλη που περιγράφει τις σχέσεις μεταξύ των δεδομένων, προσφέροντας μεγαλύτερη ακρίβεια από τη γραμμική παρεμβολή και παράγοντας πιο ομαλές καμπύλες και επιφάνειες. Αυτό προσφέρει το πλεονέκτημα της παραγωγής λεπτομερέστερων και ακριβέστερων αποτελεσμάτων, ιδιαίτερα σε δεδομένα με πιο πολύπλοκες, μη γραμμικές σχέσεις. Ο Cubic KNN εφαρμόζεται συχνά σε προβλήματα παλινδρόμησης, αλλά μπορεί επίσης να χρησιμοποιηθεί σε προβλήματα ταξινόμησης, ειδικά όταν οι σχέσεις μεταξύ των κλάσεων δεν είναι γραμμικές.

Ο Cubic KNN συνδυάζει την ευκολία του κλασικού KNN με τη δύναμη της κυβικής παρεμβολής για πιο ακριβείς και ρεαλιστικές προβλέψεις σε προβλήματα που απαιτούν μη γραμμική προσέγγιση [4,51].

Ταξινομητής Πλησιέστερου Γείτονα 'Weighted' - Weighted KNN

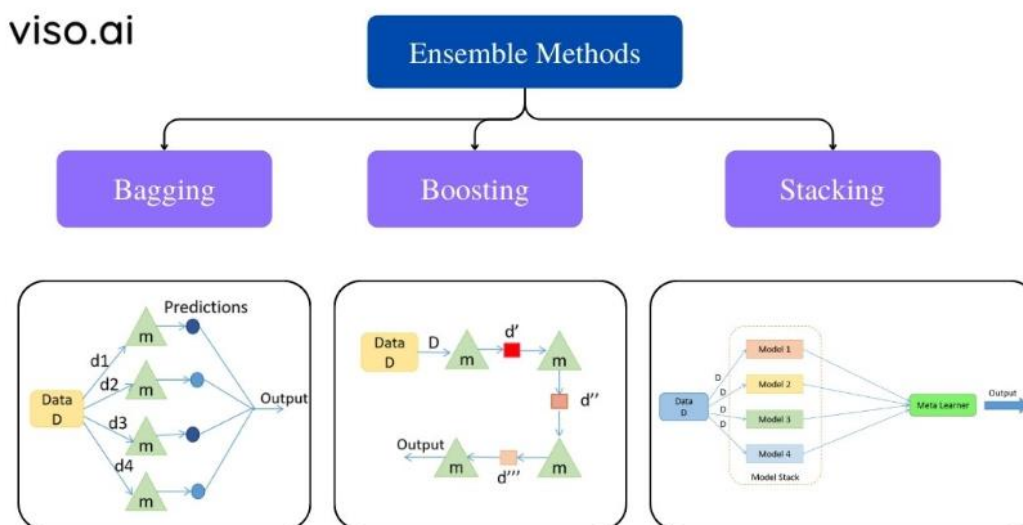
Ο Weighted K-Nearest Neighbors (Weighted KNN) είναι μια παραλλαγή του κλασικού αλγορίθμου KNN, στην οποία οι γείτονες δεν συνεισφέρουν εξίσου στην πρόβλεψη. Στον κλασικό KNN, κάθε ένας από τους k κοντινότερους γείτονες συνεισφέρει με ίσο βάρος στην πρόβλεψη της κατηγορίας ή της τιμής ενός νέου δείγματος. Αντίθετα, στον Weighted KNN, οι γείτονες συνεισφέρουν με βάρος που εξαρτάται από την απόστασή τους από το υπό εξέταση δείγμα.

Ο Weighted KNN λειτουργεί παρόμοια με τον κλασικό αλγόριθμο KNN, αλλά με τη χρήση βαρών για καλύτερη ακρίβεια. Αρχικά, υπολογίζονται οι αποστάσεις του νέου δείγματος από όλα τα υπάρχοντα δεδομένα. Στη συνέχεια, επιλέγονται οι k πλησιέστεροι γείτονες. Οι αποστάσεις αυτές μετατρέπονται σε βάρη, με τους πιο κοντινούς γείτονες να έχουν μεγαλύτερη βαρύτητα. Για την ταξινόμηση, το βάρος κάθε κατηγορίας υπολογίζεται για την πρόβλεψη, ενώ για την παλινδρόμηση χρησιμοποιείται ένας σταθμισμένος μέσος όρος. Ο Weighted KNN συχνά αποδίδει καλύτερα από τον απλό KNN, καθώς δίνει μεγαλύτερη σημασία στους πιο σχετικούς γείτονες και μειώνει την επίδραση του θορύβου. Ωστόσο, έχει αυξημένη υπολογιστική πολυπλοκότητα λόγω των επιπλέον υπολογισμών και είναι ευαίσθητος στις παραμέτρους, όπως η επιλογή της απόστασης και η μέθοδος στάθμισης.

Ο Weighted KNN είναι χρήσιμο σε εφαρμογές όπου η ακρίβεια είναι κρίσιμη και οι σχέσεις μεταξύ των δειγμάτων είναι περίπλοκες και μη γραμμικές [4,12].

Ensembles

Οι ταξινομητές Ensembles στην τεχνητή νοημοσύνη και τη μηχανική μάθηση αναφέρονται σε μεθόδους που συνδυάζουν την απόδοση πολλαπλών μοντέλων για τη βελτίωση της ακρίβειας και της ικανότητας γενίκευσης ενός συστήματος. Η βασική ιδέα πίσω από τις μεθόδους ensemble είναι ότι, συνδυάζοντας την απόδοση διαφόρων μοντέλων, μπορούμε να μειώσουμε την πιθανότητα λάθους που μπορεί να κάνει ένα μεμονωμένο μοντέλο, βελτιώνοντας τη συνολική απόδοση [78]. Στην Εικόνα 12 φαίνεται ένα παράδειγμα.



Εικόνα 12: Ταξινομητής Ensemble . Πηγή: <https://viso.ai/deep-learning/ensemble-learning/>

Δέντρα Απόφασης 'Boosted' - Boosted Trees

Τα Boosted Trees (ή Gradient Boosted Trees) είναι μια ισχυρή τεχνική μηχανικής μάθησης που βασίζεται σε σύνολα αποφασιστικών δέντρων (decision trees) για ταξινόμηση και παλινδρόμηση. Η βασική ιδέα πίσω από αυτήν την τεχνική είναι η βελτίωση της ακρίβειας του μοντέλου προσθέτοντας σταδιακά δέντρα που διορθώνουν τα λάθη των προηγούμενων δέντρων.

Η τεχνική Boosted Trees λειτουργεί με τη σταδιακή βελτίωση των προβλέψεων μέσα από επαναληπτική εκπαίδευση δέντρων. Ξεκινά με ένα απλό αποφασιστικό δέντρο και στη συνέχεια υπολογίζει τα λάθη του, γνωστά ως υπόλοιπα (residuals). Τα επόμενα δέντρα εκπαιδεύονται για να διορθώσουν αυτά τα λάθη, προσθέτοντας σταδιακά βελτιώσεις στο τελικό μοντέλο. Αυτό επαναλαμβάνεται για πολλές επαναλήψεις, με κάθε νέο δέντρο να συμβάλλει ελαφρώς στη συνολική ακρίβεια. Το τελικό αποτέλεσμα προκύπτει από τον συνδυασμό των δέντρων, των οποίων οι προβλέψεις αθροίζονται για να δώσουν την τελική απόφαση.

Μια από τις πιο δημοφιλείς μεθόδους για το boosting είναι το Gradient Boosting, όπου τα δέντρα προστίθενται ώστε να ελαχιστοποιηθεί η απώλεια του μοντέλου. Για την αποφυγή υπερπροσαρμογής (overfitting), χρησιμοποιούνται τεχνικές κανονικοποίησης, όπως ο περιορισμός του βάθους των δέντρων και η ρύθμιση των παραμέτρων μάθησης. Το τελικό μοντέλο είναι ένα σύνολο από πολλά δέντρα, που εξασφαλίζει υψηλή ακρίβεια και ανθεκτικότητα.

Παρότι τα Boosted Trees προσφέρουν εξαιρετική ακρίβεια και μπορούν να μοντελοποιήσουν πολύπλοκες σχέσεις, έχουν ορισμένα μειονεκτήματα. Απαιτούν υψηλή υπολογιστική ισχύ και χρόνο εκπαίδευσης, ειδικά για μεγάλα σύνολα δεδομένων, και υπάρχει κίνδυνος υπερπροσαρμογής αν δεν εφαρμοστούν σωστές τεχνικές κανονικοποίησης [20,25].

Δέντρα Απόφασης 'Bagged' - Bagged Trees

Τα Bagged Trees (ή Bagging Trees) αποτελούν μια μέθοδο συνόλου (ensemble method) που βασίζεται στη δημιουργία πολλών αποφασιστικών δέντρων για τη

βελτίωση της ακρίβειας των προβλέψεων. Η μέθοδος bagging είναι μια σύντμηση του "Bootstrap Aggregation" και στοχεύει στη μείωση της διακύμανσης των μοντέλων μέσω του συνδυασμού πολλαπλών τυχαία δειγματοληπτημένων δέντρων.

Η τεχνική των Bagged Trees λειτουργεί μέσω της δειγματοληψίας με επανατοποθέτηση (bootstrap sampling), όπου δημιουργούνται πολλά υποσύνολα δεδομένων από το αρχικό σύνολο, με επαναλαμβανόμενη εμφάνιση των ίδιων δεδομένων σε κάθε υποσύνολο. Στη συνέχεια, εκπαιδεύονται πολλά ανεξάρτητα αποφασιστικά δέντρα, ένα για κάθε υποσύνολο. Για την πρόβλεψη νέων τιμών ή κατηγοριών, οι προβλέψεις των δέντρων συνδυάζονται, χρησιμοποιώντας ψηφοφορία πλειοψηφίας για την ταξινόμηση και τον μέσο όρο για την παλινδρόμηση. Τα Bagged Trees προσφέρουν πλεονεκτήματα όπως η μείωση του overfitting, χάρη στην τυχαία δειγματοληψία που μειώνει την επίδραση μεμονωμένων δεδομένων, και η αύξηση της ακρίβειας, καθώς ο συνδυασμός των προβλέψεων πολλών δέντρων είναι συνήθως πιο ακριβής από τη χρήση ενός μόνο δέντρου. Επιπλέον, η μέθοδος είναι εύκολη στην κατανόηση και υλοποίηση. Ωστόσο, η χρήση πολλών δέντρων αυξάνει τον υπολογιστικό χρόνο και τους πόρους, ενώ η ερμηνεία του τελικού συνδυασμένου αποτελέσματος είναι πιο περίπλοκη σε σχέση με την ερμηνεία ενός μεμονωμένου δέντρου.

Μία από τις πιο γνωστές υλοποιήσεις της μεθόδου bagging είναι το Random Forest, που επεκτείνει την ιδέα προσθέτοντας και τυχαία επιλογή χαρακτηριστικών κατά την εκπαίδευση των δέντρων [5,25].

Subspace Discriminant

Το Subspace Discriminant είναι μια μέθοδος ταξινόμησης που χρησιμοποιείται στην κατηγορία των ensemble models. Βασίζεται στη δημιουργία πολλών ταξινομητών που εκπαιδεύονται σε τυχαία υποσύνολα (subspaces) των χαρακτηριστικών, και συνδυάζει τις προβλέψεις τους για τη λήψη της τελικής απόφασης. Αυτή η μέθοδος είναι ιδιαίτερα αποτελεσματική όταν τα δεδομένα έχουν υψηλή διάσταση, δηλαδή όταν υπάρχουν πολλά χαρακτηριστικά.

Η μέθοδος subspace discriminant λειτουργεί μέσω της διάσπασης των διαθέσιμων χαρακτηριστικών σε τυχαία υποσύνολα (subspaces), όπου κάθε υποσύνολο περιλαμβάνει έναν μικρότερο αριθμό χαρακτηριστικών από το συνολικό σύνολο. Στη συνέχεια, εκπαιδεύονται πολλαπλοί ταξινομητές, συχνά γραμμικοί όπως το LDA, πάνω σε κάθε υποσύνολο. Οι προβλέψεις αυτών των ταξινομητών συνδυάζονται μέσω ψηφοφορίας πλειοψηφίας για την τελική ταξινόμηση. Αυτή η προσέγγιση προσφέρει διάφορα πλεονεκτήματα, όπως η μείωση της διαστασιακής κατάρτας, καθιστώντας τον αλγόριθμο πιο αποτελεσματικό και ανθεκτικό στον θόρυβο. Η τυχαία επιλογή χαρακτηριστικών αποτρέπει την υπερεκπαίδευση σε θορυβώδη δεδομένα, ενώ η μέθοδος είναι ιδιαίτερα κατάλληλη για πολυδιάστατα δεδομένα και μεγάλα σύνολα δεδομένων, όπου η πολυπλοκότητα αποτελεί πρόκληση [4,74].

Ταξινομητής Πλησιέστερου Γείτονα 'Subspace' - Subspace KNN

Ο Subspace K-Nearest Neighbors (Subspace KNN) είναι μια παραλλαγή του αλγορίθμου k-Nearest Neighbors που συνδυάζει τη βασική ιδέα του KNN με τη μέθοδο των υποχώρων (subspaces). Στον Subspace KNN, ο αλγόριθμος επιλέγει τυχαία υποσύνολα χαρακτηριστικών (subspaces) από το πλήρες σύνολο

χαρακτηριστικών και εφαρμόζει την κλασική διαδικασία KNN σε αυτά τα υποσύνολα. Η μέθοδος αυτή επιδιώκει να βελτιώσει την ακρίβεια και να μειώσει την πολυπλοκότητα σε περιβάλλοντα με δεδομένα υψηλής διάστασης.


Η μέθοδος Subspace KNN βασίζεται σε τρία κύρια στοιχεία. Αρχικά, δημιουργεί υποχώρους επιλέγοντας τυχαία υποσύνολα χαρακτηριστικών από το dataset, γεγονός που βελτιώνει την αναπαράσταση των δεδομένων και μειώνει την πιθανότητα υπερπροσδιορισμού (overfitting). Στη συνέχεια, σε κάθε υποσύνολο εφαρμόζεται ο κλασικός αλγόριθμος KNN, με κάθε υποσύνολο να παράγει διαφορετικές προβλέψεις, συμβάλλοντας στη γενίκευση του τελικού μοντέλου. Τα αποτελέσματα αυτών των προβλέψεων συνδυάζονται, συνήθως μέσω πλειοψηφίας (για ταξινόμηση) ή σταθμισμένου μέσου όρου (για παλινδρόμηση). Η μέθοδος παρουσιάζει πλεονεκτήματα, όπως βελτίωση της ακρίβειας, μείωση της πολυπλοκότητας και ανθεκτικότητα στον θόρυβο, αλλά και περιορισμούς, όπως η αυξημένη υπολογιστική πολυπλοκότητα και η ανάγκη επιλογής κατάλληλων υποχώρων για την επίτευξη της βέλτιστης επίδοσης [4,28].

Δέντρα Απόφασης 'RUSBoosted' - RUSBoosted Trees

Τα RUSBoosted Trees είναι ένας αλγόριθμος ενίσχυσης (boosting) που συνδυάζει την τεχνική ενίσχυσης (boosting) με την υποδειγματοληψία τυχαίου υποδείγματος μειοψηφίας (Random UnderSampling - RUS). Ο αλγόριθμος αυτός είναι ιδιαίτερα χρήσιμος για την αντιμετώπιση προβλημάτων ταξινόμησης σε μη ισορροπημένα σύνολα δεδομένων, όπου οι κατηγορίες δεν εκπροσωπούνται εξίσου (π.χ. ένα σύνολο δεδομένων με 90% δείγματα της κατηγορίας A και 10% δείγματα της κατηγορίας B). Ο αλγόριθμος RUSBoost συνδυάζει την τεχνική του Random UnderSampling (RUS) με το κλασικό boosting για την αποτελεσματική αντιμετώπιση μη ισορροπημένων δεδομένων. Σε κάθε επανάληψη, εφαρμόζεται τυχαία υποδειγματοληψία της πλειοψηφικής κατηγορίας, ενώ διατηρούνται όλες οι παρατηρήσεις της κατηγορίας μειοψηφίας, επιτρέποντας στον αλγόριθμο να εστιάσει καλύτερα στην εκμάθηση των σπάνιων περιπτώσεων. Στη συνέχεια, ο αλγόριθμος ακολουθεί τη λογική του boosting, όπου τα λάθη των προηγούμενων μοντέλων διορθώνονται σταδιακά με τη δημιουργία νέων μοντέλων, συνήθως με αποφασιστικά δέντρα ως βασικά μοντέλα. Οι τελικές προβλέψεις προκύπτουν από τον συνδυασμό των ενδιάμεσων μοντέλων, με τα πιο πρόσφατα να έχουν μεγαλύτερη βαρύτητα, εξασφαλίζοντας μεγαλύτερη ακρίβεια. Τα βασικά πλεονεκτήματα του RUSBoost περιλαμβάνουν την αποτελεσματική διαχείριση μη ισορροπημένων δεδομένων, την υψηλή ακρίβεια και την ευκολία εφαρμογής σε διάφορα προβλήματα. Ωστόσο, η τυχαία υποδειγματοληψία μπορεί να οδηγήσει σε απώλεια σημαντικών δεδομένων από την πλειοψηφική κατηγορία, ενώ η διαδικασία είναι πιο αργή και υπολογιστικά απαιτητική σε σύγκριση με απλούστερες τεχνικές [26,67].

Νευρωνικά Δίκτυα (Neural Networks)

Τα νευρωνικά δίκτυα είναι ένα θεμελιώδες εργαλείο της τεχνητής νοημοσύνης και της μηχανικής μάθησης, εμπνευσμένο από τον τρόπο που λειτουργεί ο ανθρώπινος εγκέφαλος. Αυτά τα δίκτυα αποτελούνται από διάφορα στρώματα τεχνητών νευρώνων, τα οποία συνδέονται μεταξύ τους και επεξεργάζονται δεδομένα, μαθαίνοντας να εκτελούν συγκεκριμένες εργασίες μέσω παραδειγμάτων όπως φαίνεται στην Εικόνα 13 [22].



Εικόνα 13: Νευρωνικό Δίκτυο - Neural Network Πηγή: <https://srnghn.medium.com/deep-learning-overview-of-neurons-and-activation-functions-1d98286cf1e4>

Στενό Νευρωνικό Δίκτυο - Narrow Neural Network

Το "Narrow Neural Network" (Στενό Νευρωνικό Δίκτυο) δεν αναφέρεται συνήθως ως ξεχωριστή τεχνική στην επιστήμη των υπολογιστών ή στη μηχανική μάθηση, αλλά μπορεί να υπονοεί ένα νευρωνικό δίκτυο που είναι στενό με την έννοια ότι έχει λίγα νευρώνες σε κάθε κρυφό στρώμα του.

Τα Narrow Neural Networks χαρακτηρίζονται από μικρό αριθμό νευρώνων στα κρυφά στρώματά τους, περιορίζοντας έτσι την ικανότητά τους να μαθαίνουν και να εκφράζουν πολύπλοκα μοτίβα. Λόγω της απλότητας αυτής, έχουν χαμηλότερη υπολογιστική πολυπλοκότητα, κάτι που επιτρέπει ταχύτερη εκπαίδευση με λιγότερη κατανάλωση πόρων. Αν και είναι αποτελεσματικά για απλά προβλήματα, η περιορισμένη χωρητικότητά τους δυσχεραίνει τη γενίκευση σε πιο σύνθετα προβλήματα. Η δομή τους είναι απλή και χρησιμοποιούνται συχνά όταν τα δεδομένα είναι μικρά ή όταν οι υπολογιστικοί πόροι είναι περιορισμένοι. Συγκριτικά με τα βαθιά νευρωνικά δίκτυα, τα οποία είναι πιο ισχυρά αλλά απαιτούν περισσότερους πόρους, τα στενά δίκτυα είναι λιγότερο πολύπλοκα και προσφέρουν μια πρακτική λύση για εφαρμογές με περιορισμένες απαιτήσεις [22].

Μεσαίο Νευρωνικό Δίκτυο - Medium Neural Network

Ο όρος "Medium Neural Network" (Μεσαίου Μεγέθους Νευρωνικό Δίκτυο) αναφέρεται σε νευρωνικά δίκτυα που έχουν ενδιάμεσο αριθμό κρυφών στρωμάτων και νευρώνων σε σχέση με τα στενά (Narrow) και βαθιά (Deep) νευρωνικά δίκτυα. Αυτά τα δίκτυα συνήθως προσπαθούν να ισορροπήσουν μεταξύ της πολυπλοκότητας και της αποδοτικότητας.

Ένα Medium Neural Network χαρακτηρίζεται από την παρουσία περισσότερων από δύο κρυφών στρωμάτων, αλλά χωρίς να φτάνει το βάθος ενός βαθιού νευρωνικού δικτύου. Ο αριθμός των νευρώνων σε κάθε στρώμα είναι μέτριος, προσφέροντας έτσι μεγαλύτερη εκφραστική δύναμη σε σύγκριση με ένα στενό δίκτυο, ενώ παραμένει λιγότερο απαιτητικό από ένα βαθύ δίκτυο. Αυτά τα δίκτυα επιτυγχάνουν μια ισορροπία μεταξύ απόδοσης και πολυπλοκότητας, καθιστώντας τα ικανότερα να

μαθαίνουν από πολύπλοκα δεδομένα χωρίς να απαιτούν υπερβολικούς υπολογιστικούς πόρους. Είναι ιδιαίτερα κατάλληλα για προβλήματα που είναι πιο σύνθετα από αυτά που μπορεί να διαχειριστεί ένα στενό δίκτυο, αλλά δεν χρειάζονται την πλήρη ισχύ ενός βαθιού δικτύου. Συχνά χρησιμοποιούνται σε εφαρμογές όπως ανάλυση κειμένου, αναγνώριση προτύπων και άλλες εργασίες μηχανικής μάθησης, όπου απαιτείται καλή απόδοση χωρίς την ανάγκη για υπερβολική πολυπλοκότητα. Η εκπαίδευση αυτών των δικτύων είναι πιο εύκολη σε σύγκριση με τα βαθιά νευρωνικά δίκτυα, με λιγότερες απαιτήσεις σε πόρους, καθιστώντας τα πιο πρακτικά για χρήση σε διάφορα περιβάλλοντα [50].

Ευρύ Νευρωνικό Δίκτυο - Wide Neural Network

Ένα Wide Neural Network (Ευρύ Νευρωνικό Δίκτυο) αναφέρεται σε ένα νευρωνικό δίκτυο που χαρακτηρίζεται από την ύπαρξη μεγάλου αριθμού νευρώνων σε κάθε στρώμα, ιδιαίτερα στα κρυφά στρώματα. Αυτά τα δίκτυα είναι σχεδιασμένα να έχουν μεγαλύτερη εκφραστική δύναμη, επιτρέποντας την αναπαράσταση πιο πολύπλοκων σχέσεων και μοτίβων στα δεδομένα.

Τα Wide Neural Networks χαρακτηρίζονται από τον μεγάλο αριθμό νευρώνων σε κάθε κρυφό στρώμα, γεγονός που τους επιτρέπει να καταγράφουν και να μαθαίνουν πολύπλοκες αλληλεπιδράσεις στα δεδομένα. Αυτή η δομή τα καθιστά ιδιαίτερα κατάλληλα για προβλήματα με υψηλή διάσταση ή μεγάλη πολυπλοκότητα στα δεδομένα. Η αυξημένη εκφραστική δύναμη αυτών των δικτύων, λόγω του μεγάλου αριθμού παραμέτρων, τους δίνει τη δυνατότητα να μάθουν και να αποθηκεύσουν περισσότερες λεπτομέρειες σχετικά με τα δεδομένα. Ωστόσο, αυτή η πολυπλοκότητα μπορεί να οδηγήσει σε υπερπροσαρμογή (overfitting) αν δεν εφαρμοστούν κατάλληλες τεχνικές κανονικοποίησης. Η εκπαίδευση ενός Wide Neural Network είναι πιο απαιτητική τόσο σε χρόνο όσο και σε υπολογιστικούς πόρους, λόγω του πλήθους των παραμέτρων που πρέπει να προσαρμοστούν. Αυτά τα δίκτυα είναι ιδανικά για εφαρμογές όπως η αναγνώριση εικόνων, η επεξεργασία φυσικής γλώσσας και άλλες εργασίες που απαιτούν την αναγνώριση πολύπλοκων δομών στα δεδομένα, ιδιαίτερα όταν τα δεδομένα έχουν υψηλή διάσταση και απαιτούν την καταγραφή περισσότερων λεπτομερειών και σχέσεων [22].

Δίστρωμα Νευρωνικό Δίκτυο - Bilayerd Neural Network

Ο όρος "Bilayered Neural Network" (Δίστρωμα Νευρωνικό Δίκτυο) αναφέρεται σε μια συγκεκριμένη αρχιτεκτονική νευρωνικού δικτύου, η οποία αποτελείται από δύο διακριτά στρώματα νευρώνων που συνδέονται διαδοχικά. Αυτή η δομή είναι απλούστερη σε σύγκριση με βαθύτερα δίκτυα, αλλά πιο πολύπλοκη από τα τυπικά μονοστρώματα νευρωνικά δίκτυα.

Ένα Bilayered Neural Network διαθέτει δύο κρυφά στρώματα μεταξύ του επιπέδου εισόδου και εξόδου, τα οποία μπορούν να έχουν διαφορετικό αριθμό νευρώνων και να χρησιμοποιούν διαφορετικές συναρτήσεις ενεργοποίησης. Αυτή η δομή προσφέρει μια ισορροπία πολυπλοκότητας, καθώς είναι πιο εκφραστική από ένα μονοστρώμα δίκτυο, επιτρέποντας την εκμάθηση πιο σύνθετων σχέσεων στα δεδομένα, ενώ παραμένει λιγότερο περίπλοκη και απαιτητική σε πόρους σε σύγκριση με βαθύτερα δίκτυα. Χάρη στην απλότητά του, το bilayered network εκπαίδευεται σχετικά γρήγορα και είναι κατάλληλο για προβλήματα μεσαίας πολυπλοκότητας, όπως η κατηγοριοποίηση δεδομένων ή η αναγνώριση προτύπων. Ωστόσο, παρόλο που μπορεί να μοντελοποιήσει πιο σύνθετες σχέσεις από ένα μονοστρώμα δίκτυο, μπορεί να μην

είναι επαρκές για την επίλυση προβλημάτων που απαιτούν βαθιές αναπαραστάσεις δεδομένων, όπως η αναγνώριση εικόνων ή η επεξεργασία φυσικής γλώσσας [70].

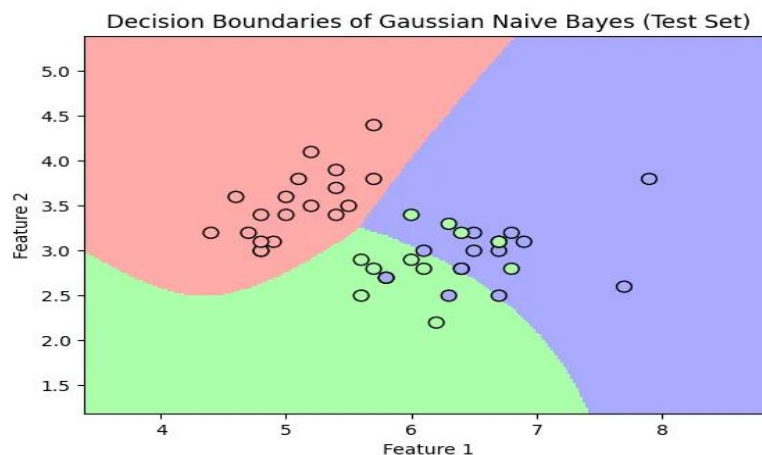
Τρίστρωμα Νευρωνικό Δίκτυο - Trilayerd Neural Network

Ένα Trilayered Neural Network (Τρίστρωμα Νευρωνικό Δίκτυο) αναφέρεται σε ένα νευρωνικό δίκτυο που διαθέτει τρία διακριτά κρυφά στρώματα νευρώνων. Αυτή η αρχιτεκτονική είναι πιο πολύπλοκη από τα μονοστρώματα και δίστρωμα δίκτυα, αλλά πιο απλή σε σχέση με τα βαθιά νευρωνικά δίκτυα (deep neural networks), τα οποία μπορούν να έχουν πολύ περισσότερα κρυφά στρώματα.

Ένα Trilayered Neural Network χαρακτηρίζεται από τρία κρυφά στρώματα που βρίσκονται μεταξύ του επιπέδου εισόδου και εξόδου. Κάθε στρώμα μπορεί να διαθέτει διαφορετικό αριθμό νευρώνων και να χρησιμοποιεί διαφορετικές συναρτήσεις ενεργοποίησης, ανάλογα με την επιλεγμένη αρχιτεκτονική. Τα τρία κρυφά στρώματα αυξάνουν την εκφραστική δύναμη του δικτύου, επιτρέποντάς του να μάθει πιο σύνθετες σχέσεις στα δεδομένα, καθιστώντας το κατάλληλο για εφαρμογές με μεσαία πολυπλοκότητα, όπως η κατηγοριοποίηση εικόνων ή η ανάλυση κειμένου. Παρόλο που δεν είναι τόσο πολύπλοκο όσο ένα βαθύ νευρωνικό δίκτυο, το τρίστρωμα δίκτυο προσφέρει καλύτερη απόδοση από τα απλούστερα δίκτυα, όπως τα μονοστρώματα ή δίστρωμα, χωρίς να απαιτεί τόσο μεγάλους πόρους ή χρόνο εκπαίδευσης. Επιπλέον, η εκπαίδευση του δικτύου αυτού είναι πιο αργή σε σύγκριση με ένα απλό δίκτυο, αλλά ταχύτερη από τα βαθιά δίκτυα, καθιστώντας το μια καλή επιλογή όταν χρειάζεται να επιτευχθεί ισορροπία μεταξύ απόδοσης και υπολογιστικού κόστους [22].

Naive Bayes

Ο Naive Bayes είναι μια απλή, αλλά εξαιρετικά ισχυρή και ευρέως χρησιμοποιούμενη μέθοδος ταξινόμησης, βασισμένη σε θεωρητικές βάσεις πιθανοτήτων. Είναι μέρος της κατηγορίας των πιθανοθεωρητικών ταξινομητών και χρησιμοποιείται συχνά σε εφαρμογές όπως η φιλτράρισμα ανεπιθύμητων μηνυμάτων (spam filtering), η ανάλυση συναισθήματος και η ταξινόμηση κειμένου [10,77]. Στην Εικόνα 14 απεικονίζεται ο Gaussian Naïve Bayes, μία παραλλαγή του Naïve Bayes.



Εικόνα 14: Gaussian Naïve Bayes. Πηγή:

<https://medium.com/@nandiniverma78988/understanding-and-implementing-gaussian-naive-bayes-classification-with-python-dbd9cf2939f7>

Gaussian Naive Bayes

Ο Gaussian Naive Bayes (GNB) είναι μια παραλλαγή του αλγορίθμου Naive Bayes, ο οποίος είναι ένας απλός, αλλά αποτελεσματικός ταξινομητής που βασίζεται στο Θεώρημα του Bayes. Ο Gaussian Naive Bayes χρησιμοποιείται κυρίως για την κατηγοριοποίηση δεδομένων όπου οι μεταβλητές εισόδου είναι συνεχείς και ακολουθούν κανονική κατανομή (Gaussian distribution).

Ο Naive Bayes βασίζεται στο Θεώρημα του Bayes για τον υπολογισμό της πιθανότητας μιας κλάσης δεδομένων, λαμβάνοντας υπόψη τις τιμές των χαρακτηριστικών του συγκεκριμένου δεδομένου. Στην περίπτωση του Gaussian Naive Bayes, υποτίθεται ότι τα δεδομένα ακολουθούν κανονική κατανομή, πράγμα που σημαίνει ότι η πιθανότητα για κάθε χαρακτηριστικό σε μια κλάση μπορεί να υπολογιστεί χρησιμοποιώντας τη συνάρτηση πυκνότητας πιθανότητας της κανονικής κατανομής. Ένα από τα κύρια πλεονεκτήματα του Gaussian Naive Bayes είναι η απλότητα και η ταχύτητά του, καθιστώντας το ιδιαίτερα αποτελεσματικό σε μεγάλα σύνολα δεδομένων, ειδικά όταν τα δεδομένα είναι καλά προσδιορισμένα και η υπόθεση της κανονικής κατανομής ισχύει. Αυτή η μέθοδος χρησιμοποιείται συχνά σε προβλήματα ταξινόμησης με συνεχείς μεταβλητές, όπως η αναγνώριση προσώπων, η διάγνωση ασθενειών και η ανάλυση κειμένου, όταν τα χαρακτηριστικά έχουν μετατραπεί σε συνεχείς τιμές [4,64].

Kernel Naive Bayes

Ο Kernel Naive Bayes (Kernel Naive Bayes Classifier) είναι μια παραλλαγή του αλγορίθμου Naive Bayes που συνδυάζει την απλότητα και την αποδοτικότητα του Naive Bayes με τη δύναμη των πυρηνικών συναρτήσεων (kernels). Η βασική ιδέα πίσω από τον Kernel Naive Bayes είναι να επιτρέψει την ταξινόμηση σε περιπτώσεις όπου τα δεδομένα δεν είναι γραμμικά διαχωρίσιμα στον αρχικό χώρο χαρακτηριστικών, χρησιμοποιώντας έναν μη γραμμικό μετασχηματισμό του χώρου χαρακτηριστικών σε έναν υψηλότερων διαστάσεων χώρο, όπου τα δεδομένα γίνονται πιο διαχωρίσιμα.

Ο Naive Bayes είναι ένα απλό μοντέλο που βασίζεται στην υπόθεση ότι τα χαρακτηριστικά είναι ανεξάρτητα, κάτι που συχνά δεν ισχύει στην πραγματικότητα, αλλά παρόλα αυτά αποδίδει εξαιρετικά καλά σε πολλές πρακτικές εφαρμογές. Αυτό το μοντέλο ακολουθεί μια πιθανοθεωρητική προσέγγιση, υπολογίζοντας την πιθανότητα κάθε κατηγορίας με βάση ένα σύνολο χαρακτηριστικών και επιλέγοντας την κατηγορία με τη μέγιστη πιθανότητα.

Όσον αφορά τους πυρήνες (kernels), αυτοί χρησιμοποιούνται για τη δημιουργία μη γραμμικών μετασχηματισμών. Με τη χρήση μιας πυρηνικής συνάρτησης, όπως η Gaussian RBF, τα δεδομένα μετασχηματίζονται σε έναν υψηλότερων διαστάσεων χώρο, όπου οι κατηγορίες μπορεί να είναι γραμμικά διαχωρίσιμες. Κοινές πυρηνικές συναρτήσεις περιλαμβάνουν τις Gaussian RBF, Polynomial, και Sigmoid.

Στον Kernel Naive Bayes, οι κλασικές πυκνότητες πιθανότητας του Naive Bayes αντικαθίστανται από πυρηνικές πυκνότητες πιθανότητας. Αυτές βασίζονται σε ένα πυρηνικό τέχνασμα, το οποίο επιτρέπει τον υπολογισμό των αποστάσεων στον μετασχηματισμένο χώρο χωρίς να χρειάζεται να υπολογιστούν ρητά οι συντεταγμένες σε αυτόν τον χώρο. Η διαδικασία υλοποίησης περιλαμβάνει τον υπολογισμό των πυρηνικών πυκνοτήτων, τον υπολογισμό της πιθανότητας κάθε κατηγορίας με βάση αυτές τις πυκνότητες, και την τελική απόφαση, η οποία γίνεται με την επιλογή της κατηγορίας με τη μέγιστη πιθανοφάνεια [44,57,77]

QDA

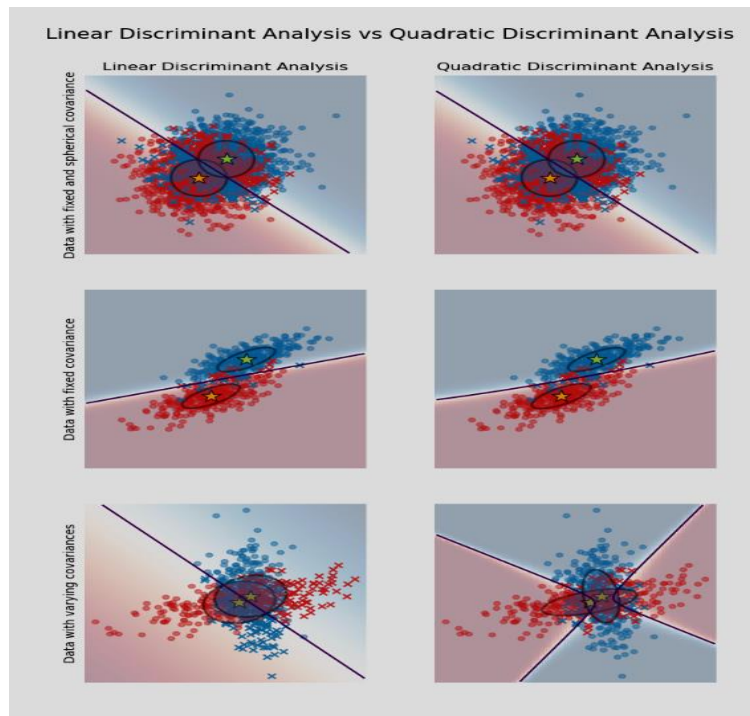
Quadratic Discriminant

Το Quadratic Discriminant Analysis (QDA) είναι μια κλασική μέθοδος ταξινόμησης που ανήκει στην κατηγορία των διαχωριστικών αναλυτικών τεχνικών (discriminant analysis). Όπως και το Linear Discriminant Analysis (LDA), το QDA χρησιμοποιείται για να διαχωρίσει δείγματα σε διαφορετικές κατηγορίες με βάση τα χαρακτηριστικά τους, αλλά διαφέρει στον τρόπο με τον οποίο το επιτυγχάνει. Στην Εικόνα 15 φαίνεται ένα παράδειγμα εφαρμογής τους.

Οι βασικές αρχές του QDA περιλαμβάνουν την ικανότητά του να επιτρέπει μη γραμμικό διαχωρισμό των κατηγοριών, σε αντίθεση με το LDA που προϋποθέτει γραμμικότητα. Αυτό σημαίνει ότι η επιφάνεια διαχωρισμού μεταξύ των κατηγοριών στο QDA έχει τετραγωνικό σχήμα. Επιπλέον, το QDA επιτρέπει σε κάθε κατηγορία να έχει τη δική της συνάρτηση κατανομής πιθανοτήτων, με διαφορετικούς μέσους όρους και συναρτήσεις συνδιακύμανσης, ενώ στο LDA όλες οι κατηγορίες μοιράζονται την ίδια συνδιακύμανση. Το QDA βασίζεται στην υπόθεση ότι τα δεδομένα κάθε κατηγορίας ακολουθούν πολυμεταβλητή κανονική κατανομή, αλλά με διαφορετικές μήτρες συνδιακύμανσης ανά κατηγορία.

Τα βασικά βήματα στη διαδικασία του QDA περιλαμβάνουν τον υπολογισμό των μέσων όρων και των συναρτήσεων συνδιακύμανσης για κάθε κατηγορία, τη δημιουργία των συναρτήσεων απόφασης που είναι τετραγωνικές ως προς τα χαρακτηριστικά, και την τελική ταξινόμηση των νέων δειγμάτων με βάση την πιθανότητα που υπολογίζεται για κάθε κατηγορία.

Τα πλεονεκτήματα του QDA περιλαμβάνουν τη μεγαλύτερη ευελιξία στον διαχωρισμό των κατηγοριών και την καταλληλότητά του για προβλήματα όπου οι κατηγορίες έχουν διαφορετικές μήτρες συνδιακύμανσης. Ωστόσο, το QDA είναι λιγότερο σταθερό από το LDA όταν υπάρχουν λίγα δεδομένα, καθώς απαιτεί την εκτίμηση περισσότερων παραμέτρων. Επιπλέον, είναι πιο ευαίσθητο στην ύπαρξη θορύβου και εξωγενών τιμών [11,38,44].



Εικόνα 15: QDA. Πηγή: https://scikit-learn.org/stable/modules/lda_qda.html

8. Στατιστική Ανάλυση

8.1. Matlab

Η επεξεργασία των δεδομένων και η εξαγωγή των χαρακτηριστικών τους πραγματοποιήθηκε σε γλώσσα προγραμματισμού Matlab.

Το Matlab (Matrix Laboratory) είναι ένα λογισμικό που χρησιμοποιείται ευρέως σε πολλούς επιστημονικούς και μηχανικούς τομείς για αριθμητικούς υπολογισμούς, προσομοιώσεις και ανάλυση δεδομένων. Αναπτύχθηκε από την MathWorks και είναι ιδιαίτερα δημοφιλές σε ακαδημαϊκούς και βιομηχανικούς χώρους λόγω της ευκολίας χρήσης του και της ισχυρής υποστήριξης που παρέχει σε πολλές τεχνικές εργασίες.

Βασικά Χαρακτηριστικά του MATLAB:

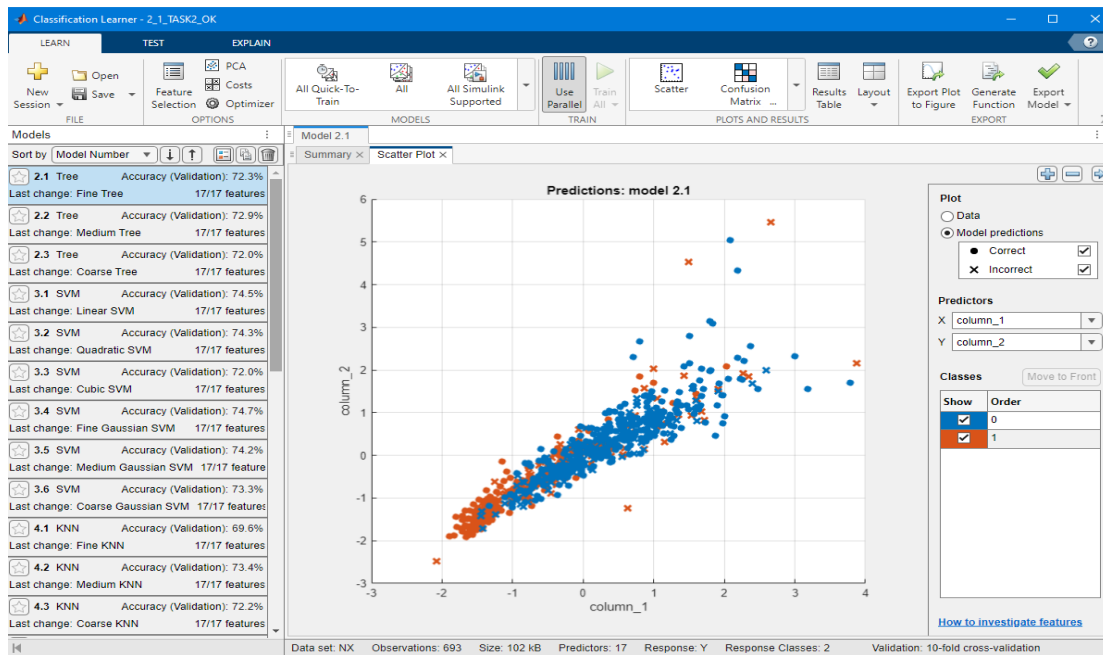
- Υπολογισμοί Πινάκων
- Εργαλεία Προσομοίωσης και Μοντελοποίησης
- Ανάλυση Δεδομένων
- Ανάλυση Εικόνας και Σήματος: Υποστηρίζει την επεξεργασία εικόνας και σήματος με ειδικά εργαλεία που διευκολύνουν τη μετατροπή, ανάλυση και φιλτράρισμα εικόνων και σημάτων.
- Γλώσσα Προγραμματισμού
- Εργαλεία Γραφικών και Visualization: Παρέχει ισχυρά εργαλεία για τη δημιουργία 2D και 3D γραφημάτων, επιτρέποντας στους χρήστες να παρουσιάζουν δεδομένα με τρόπο που διευκολύνει την ανάλυση και την ερμηνεία.

MATLAB είναι ένα από τα πιο δημοφιλή εργαλεία για τεχνικούς υπολογισμούς και χρησιμοποιείται εκτενώς τόσο στην έρευνα όσο και στη βιομηχανία [23,37].

8.2. Matlab - Classification learner app

Για την κατηγοριοποίηση των δεδομένων επιλέχθηκε η πλατφόρμα MATLAB. Πολλοί μηχανικοί και ερευνητές χρησιμοποιούν το MATLAB προκειμένου να αναλύσουν ή να σχεδιάσουν συστήματα και προϊόντα, καθώς προσφέρει έναν απλό και φυσικό τρόπο για την εκφραστικότητα υπολογισμών και την οπτικοποίηση των δεδομένων.

Η εφαρμογή Classification Learner έχει σχεδιαστεί για να εκπαιδεύει μοντέλα που είναι ικανά να ταξινομούν δεδομένα. Μέσω αυτής της εφαρμογής, οι χρήστες έχουν τη δυνατότητα να επιλέξουν ανάμεσα σε διάφορους ταξινομητές, επιλογές δεδομένων και μεθόδους εκτίμησης των αποτελεσμάτων. Παράλληλα είναι εφικτή η χρήση επιβλεπόμενης μηχανικής μάθησης σε ένα σύνολο εισαγόμενων δεδομένων με διάφορους αλγόριθμους (SVM, KNN, Logistic Regression, Bayesian)[7]. Στην Εικόνα 16 γίνεται απεικόνιση του Classification Learner App.



Εικόνα 16 : Περιβάλλον Matlab Classification Learner App

8.3. Στατιστικό τεστ Kruskal Wallis - Kruskal Wallis Statistical Test

Το Kruskal-Wallis test είναι μια μη παραμετρική στατιστική μέθοδος που χρησιμοποιείται για να συγκρίνει τις διαμέσους (ή γενικά τις κατανομές) μεταξύ δύο ή περισσότερων ανεξάρτητων ομάδων. Είναι η μη παραμετρική εναλλακτική του One-way ANOVA και χρησιμοποιείται όταν οι υποθέσεις του ANOVA, όπως η κανονικότητα και η ομοσκεδαστικότητα, δεν ικανοποιούνται.

Βασικές Αρχές του Kruskal-Wallis Test

Υποθέσεις:

- Ανεξαρτησία των Παρατηρήσεων: Οι παρατηρήσεις στις διαφορετικές ομάδες πρέπει να είναι ανεξάρτητες μεταξύ τους.
- Συνεχής ή Ταξινομημένη Κλίμακα: Τα δεδομένα πρέπει να είναι σε μια κλίμακα μέτρησης που να επιτρέπει την ταξινόμηση των παρατηρήσεων (ordinal ή interval).
- Μη Κανονική Κατανομή: Το τεστ δεν απαιτεί κανονική κατανομή των δεδομένων, καθιστώντας το ιδανικό για περιπτώσεις όπου αυτή η υπόθεση δεν μπορεί να ικανοποιηθεί.

Διαδικασία:

- Όλες οι παρατηρήσεις από όλες τις ομάδες κατατάσσονται σε αυξανόμενη σειρά, ανεξάρτητα από την ομάδα στην οποία ανήκουν.
- Υπολογίζεται η μέση κατάταξη (rank) για κάθε ομάδα.
- Το τεστ βασίζεται στη σύγκριση των μέσων κατατάξεων μεταξύ των ομάδων.

Υπόθεση:

- Μηδενική Υπόθεση (H_0): Οι διανομές των ομάδων είναι ίδιες (οι διαμέσοι είναι ίσοι).
- Εναλλακτική Υπόθεση (H_1): Τουλάχιστον μία από τις διανομές διαφέρει από τις άλλες (τουλάχιστον ένας διάμεσος διαφέρει).

Ερμηνεία:

- Αν το Kruskal-Wallis test δείξει στατιστικά σημαντική διαφορά (συνήθως $p < 0,05$), απορρίπτουμε τη μηδενική υπόθεση, δηλαδή θεωρούμε ότι υπάρχει στατιστικά σημαντική διαφορά μεταξύ των ομάδων.
- Αν το αποτέλεσμα είναι στατιστικά σημαντικό, μπορούμε να εκτελέσουμε post-hoc tests για να εντοπίσουμε ποιες συγκεκριμένες ομάδες διαφέρουν.

Το Kruskal-Wallis test παρουσιάζει αρκετά πλεονεκτήματα, αλλά και μειονεκτήματα. Από τη μία πλευρά, είναι ένα μη παραμετρικό τεστ, το οποίο σημαίνει ότι μπορεί να χρησιμοποιηθεί ακόμα και με δεδομένα που δεν πληρούν τις υποθέσεις της κανονικότητας ή έχουν διαφορετικές διακυμάνσεις. Επιπλέον, είναι ευέλικτο, καθιστώντας το ιδανικό για δεδομένα με άνιση κατανομή ή μικρά δείγματα. Ένα ακόμα πλεονέκτημα είναι η απλότητα του, καθώς το τεστ είναι εύκολο να υπολογιστεί και να ερμηνευτεί.

Ωστόσο, το Kruskal-Wallis test έχει και ορισμένα μειονεκτήματα. Ένας από τους κύριους περιορισμούς είναι η απώλεια πληροφορίας. Όπως συμβαίνει με όλα τα μη παραμετρικά τεστ, το γεγονός ότι το Kruskal-Wallis βασίζεται στην κατάταξη των δεδομένων μπορεί να οδηγήσει σε απώλεια λεπτομερούς πληροφορίας που υπάρχει στα πρωτογενή δεδομένα. Επιπλέον, το τεστ αυτό δεν καθορίζει το μέγεθος της διαφοράς. Αν και δείχνει ότι υπάρχει διαφορά μεταξύ των ομάδων, δεν παρέχει πληροφορίες για το μέγεθος αυτής της διαφοράς. Τέλος, όταν τα δεδομένα είναι κανονικά κατανομημένα και πληρούνται οι προϋποθέσεις του ANOVA, το Kruskal-Wallis παρουσιάζει μικρότερη ισχύ σε σύγκριση με το ANOVA, γεγονός που το καθιστά λιγότερο αποτελεσματικό σε τέτοιες περιπτώσεις [19,29].

8.4. Στατιστική μέθοδος ANOVA - ANOVA Statistical Method

Το ANOVA (Analysis of Variance) είναι μια στατιστική μέθοδος που χρησιμοποιείται για να συγκρίνει μέσα όρων μεταξύ δύο ή περισσότερων ομάδων και να διαπιστώσει αν υπάρχουν στατιστικά σημαντικές διαφορές μεταξύ τους. Είναι ιδιαίτερα χρήσιμο όταν θέλουμε να συγκρίνουμε τα μέσα περισσότερων από δύο ομάδων, κάτι που δεν είναι εύκολο να γίνει με απλά t-tests χωρίς να αυξήσουμε την πιθανότητα σφάλματος τύπου I (αποδοχή μιας ψευδούς θετικής υπόθεσης).

Βασικές αρχές του ANOVA

Υποθέσεις:

- Οι ομάδες είναι ανεξάρτητες μεταξύ τους.
- Τα δεδομένα σε κάθε ομάδα ακολουθούν κανονική κατανομή.

- Οι διακυμάνσεις (διασπορές) των δεδομένων είναι περίπου ίσες μεταξύ των ομάδων (ομοσκεδαστικότητα).

Είδη ANOVA:

- One-way ANOVA: Χρησιμοποιείται όταν υπάρχει μία ανεξάρτητη μεταβλητή με δύο ή περισσότερα επίπεδα (ομάδες) και θέλουμε να συγκρίνουμε τους μέσους όρους μεταξύ αυτών των ομάδων.
- Two-way ANOVA: Χρησιμοποιείται όταν υπάρχουν δύο ανεξάρτητες μεταβλητές. Αυτό μας επιτρέπει να ελέγξουμε τις κύριες επιδράσεις κάθε μεταβλητής καθώς και την αλληλεπίδραση μεταξύ τους.
- Repeated measures ANOVA: Χρησιμοποιείται όταν τα ίδια υποκείμενα συμμετέχουν σε περισσότερες από μία συνθήκες (π.χ., μετρήσεις σε διαφορετικές χρονικές στιγμές).

Διαδικασία:

- Υπολογίζεται η συνολική διακύμανση στα δεδομένα και διαχωρίζεται σε δύο μέρη: τη διακύμανση μεταξύ των ομάδων και τη διακύμανση εντός των ομάδων.
- Υπολογίζεται η αναλογία των δύο αυτών διακυμάνσεων (F-statistic).
- Εάν η F-statistic είναι αρκετά μεγάλη, μπορούμε να απορρίψουμε την μηδενική υπόθεση (ότι δηλαδή οι μέσοι όροι όλων των ομάδων είναι ίσοι) και να συμπεράνουμε ότι υπάρχει στατιστικά σημαντική διαφορά μεταξύ των ομάδων.

Ερμηνεία:

- Εάν το p-value της F-statistic είναι μικρότερο από το επίπεδο σημαντικότητας (συνήθως 0,05), απορρίπτουμε την μηδενική υπόθεση και υποθέτουμε ότι τουλάχιστον ένας από τους μέσους όρους των ομάδων διαφέρει σημαντικά από τους υπόλοιπους.
- Αν απορριφθεί η μηδενική υπόθεση, μπορεί να χρειαστούν περαιτέρω αναλύσεις (post-hoc tests) για να εντοπιστεί ποιοι μέσοι όροι διαφέρουν.

Οι υποθέσεις του ANOVA είναι κρίσιμες για την αξιοπιστία των αποτελεσμάτων που προκύπτουν από τη χρήση του. Πρώτη υπόθεση είναι η κανονικότητα των δεδομένων, σύμφωνα με την οποία τα δεδομένα κάθε ομάδας πρέπει να είναι κατανομημένα κανονικά. Αυτή η υπόθεση είναι ιδιαίτερα σημαντική σε μικρά δείγματα, αν και όταν το δείγμα είναι μεγάλο, το ANOVA παραμένει αρκετά ανθεκτικό σε αποκλίσεις από την κανονικότητα.

Η δεύτερη υπόθεση αφορά την ομοσκεδαστικότητα, δηλαδή το ότι οι διακυμάνσεις μεταξύ των ομάδων πρέπει να είναι περίπου ίσες. Η ομοσκεδαστικότητα μπορεί να ελεγχθεί με το Levene's test ή το Bartlett's test. Αν αυτή η υπόθεση δεν ισχύει, μπορεί να χρησιμοποιηθεί μια τροποποιημένη έκδοση του ANOVA, όπως το Welch's ANOVA, που είναι πιο ανθεκτικό σε παραβιάσεις αυτής της υπόθεσης.

Η τρίτη υπόθεση είναι η ανεξαρτησία των παρατηρήσεων, η οποία απαιτεί οι παρατηρήσεις σε κάθε ομάδα να είναι ανεξάρτητες μεταξύ τους. Αυτό σημαίνει ότι οι

μετρήσεις από ένα άτομο δεν πρέπει να επηρεάζουν τις μετρήσεις από άλλα άτομα, ώστε τα αποτελέσματα του ANOVA να είναι αξιόπιστα.

Το ANOVA είναι ένα ισχυρό εργαλείο στατιστικής ανάλυσης με πολλά πλεονεκτήματα, αλλά δεν στερείται και μειονεκτημάτων. Ένα από τα βασικά μειονεκτήματα του ANOVA είναι η ευαισθησία του στις παραβάσεις των βασικών υποθέσεων, όπως η ομοσκεδαστικότητα. Εάν αυτές οι υποθέσεις δεν ικανοποιούνται, τα αποτελέσματα μπορεί να είναι αναξιόπιστα. Επιπλέον, το ANOVA δεν παρέχει πληροφορίες για το ποια συγκεκριμένη ομάδα διαφέρει από τις υπόλοιπες, καθιστώντας απαραίτητη τη χρήση post-hoc tests. Η F-statistic του ANOVA δείχνει μόνο αν υπάρχει διαφορά μεταξύ των ομάδων, χωρίς να αποκαλύπτει το μέγεθος αυτής της διαφοράς, κάτι που απαιτεί τη χρήση άλλων μετρικών όπως το effect size.

Από την άλλη πλευρά, το ANOVA έχει πολλά πλεονεκτήματα. Ένα από τα μεγαλύτερα είναι η δυνατότητά του να συγκρίνει πολλαπλές ομάδες ταυτόχρονα, αποφεύγοντας τον κίνδυνο σφάλματος τύπου I που προκύπτει από πολλαπλά t-tests. Το ANOVA είναι επίσης ανθεκτικό σε μικρές παρεκκλίσεις από την κανονική κατανομή, ιδιαίτερα όταν τα μεγέθη των δειγμάτων είναι μεγάλα και ίσα μεταξύ τους. Η ευελιξία του ANOVA είναι ένα ακόμα σημαντικό πλεονέκτημα, καθώς μπορεί να εφαρμοστεί σε διάφορες καταστάσεις, όπως το One-way ANOVA για μία ανεξάρτητη μεταβλητή, το Two-way ANOVA για δύο ανεξάρτητες μεταβλητές, και το Repeated Measures ANOVA για επαναλαμβανόμενες μετρήσεις στα ίδια άτομα.

Επιπλέον, το Two-way ANOVA μπορεί να αποκαλύψει την αλληλεπίδραση μεταξύ δύο ανεξάρτητων μεταβλητών, προσφέροντας μια πιο σύνθετη εικόνα της σχέσης μεταξύ των μεταβλητών. Η υψηλή στατιστική ισχύς του ANOVA το καθιστά ικανό να ανιχνεύει πραγματικές διαφορές μεταξύ των ομάδων όταν αυτές υπάρχουν. Τέλος, το ANOVA απλοποιεί την επεξεργασία και ανάλυση μεγάλων συνόλων δεδομένων, καθιστώντας το έναν ευέλικτο και οργανωμένο τρόπο ανάλυσης. Χρησιμοποιείται ευρέως σε διάφορους επιστημονικούς τομείς, από τη βιολογία και την ιατρική μέχρι την ψυχολογία και τις κοινωνικές επιστήμες, καθιστώντας το ένα ευρέως αποδεκτό και αναγνωρισμένο εργαλείο.

Αυτά τα πλεονεκτήματα κάνουν το ANOVA ένα πολύτιμο εργαλείο για τους στατιστικούς και τους ερευνητές, καθώς προσφέρει έναν ισχυρό και ευέλικτο τρόπο να αναλύσουν τα δεδομένα τους και να βγάλουν έγκυρα συμπεράσματα [19,41].

8.5. Διασταυρούμενη Επικύρωση - Cross Validation

Η διασταυρούμενη επικύρωση (Cross Validation) είναι μια τεχνική που χρησιμοποιείται στην επιβλεπόμενη μάθηση για την αξιολόγηση της απόδοσης ενός μοντέλου μάθησης. Ο στόχος του cross-validation είναι να αξιολογήσει πόσο καλά θα αποδίδει το μοντέλο όταν εφαρμοστεί σε ανεξάρτητα δεδομένα, δηλαδή δεδομένα που δεν έχουν χρησιμοποιηθεί κατά τη διαδικασία εκπαίδευσης του μοντέλου.

Η πιο συνηθισμένη μορφή του cross-validation είναι η k-fold cross-validation, στην οποία τα δεδομένα διαχωρίζονται σε k ίσα μέρη (folds). Το μοντέλο εκπαιδεύεται k φορές, με κάθε φορά ένα διαφορετικό fold να χρησιμοποιείται ως σύνολο επικύρωσης, ενώ τα υπόλοιπα k-1 folds χρησιμοποιούνται για την εκπαίδευση του μοντέλου. Στο τέλος, τα αποτελέσματα από κάθε fold συνδυάζονται για να υπολογιστεί μια μέση απόδοση του μοντέλου.

Το cross-validation βοηθά στο να αποφεύγεται η υπερπροσαρμογή (overfitting) και παρέχει μια πιο αξιόπιστη εκτίμηση της απόδοσης του μοντέλου, ειδικά όταν ο όγκος των δεδομένων είναι μικρός [4,25].

8.6. Επικύρωση με Παρακράτηση - Holdout Validation

Η επικύρωση με παρακράτηση (holdout validation) είναι μια απλή μέθοδος αξιολόγησης της απόδοσης ενός μοντέλου στη μηχανική μάθηση. Σε αυτή τη μέθοδο, τα διαθέσιμα δεδομένα χωρίζονται σε δύο σύνολα: το Training Set (Σύνολο Εκπαίδευσης), το οποίο αποτελείται από ένα μέρος των δεδομένων (συνήθως το 70-80%) που χρησιμοποιείται για την εκπαίδευση του μοντέλου, και το Test Set (Σύνολο Δοκιμών), το οποίο περιλαμβάνει το υπόλοιπο μέρος των δεδομένων (20-30%) και χρησιμοποιείται για να αξιολογηθεί η απόδοση του μοντέλου σε δεδομένα που δεν έχει δει κατά τη διάρκεια της εκπαίδευσης.

Η μέθοδος αυτή είναι γρήγορη και απλή στην εφαρμογή, αλλά μπορεί να είναι λιγότερο αξιόπιστη από άλλες τεχνικές όπως το cross-validation, ειδικά αν το σύνολο δεδομένων είναι μικρό ή αν το training set και το test set δεν είναι αντιπροσωπευτικά του συνόλου των δεδομένων [4,43].

8.7. Χαρακτηριστικά

Mean Intensity

Ο μέσος όρος των τιμών δραστηριότητας ορίζεται στη σχέση (13).

$$\mu = \frac{1}{N} \sum_i \sum_j I(i, j) \quad (13)$$

Median intensity

Η μεσαία τιμή δραστηριότητας από το σύνολο των τιμών.

Maximum intensity

Η μέγιστη τιμή από το σύνολο των τιμών, σχέση (14).

$$\text{maximum} = \max(X) \quad (14)$$

Minimum intensity

Η ελάχιστη τιμή από το σύνολο των τιμών, σχέση (15).

$$\text{minimum} = \min(X) \quad (15)$$

Intensity Range

Το εύρος των τιμών ενδιαφέροντος όπως ορίζεται από τη σχέση (16).

$$\text{Range} = \max(X) - \min(X) \quad (16)$$

Intensity interquartile range

Το εύρος μεταξύ του 75ου και 25ου εκατοστημορίου όπως ορίζεται από τη σχέση (17).

$$\text{interquartile range} = P_{75} - P_{25} \quad (17)$$

10th & 90th intensity percentile

Το 10ο και το 90ο εκατοστημόριο των τιμών που δίνουν μια εναλλακτική για το μικρότερο και το μεγαλύτερο αριθμό έντασης της δραστηριότητας.

Intensity-based mean absolute deviation

Το απόλυτο της μέσης τιμής της απόστασης κάθε τιμής δραστηριότητας από τη μέση τιμή του συνόλου των τιμών.

Intensity-based median absolute deviation

Το απόλυτο της μεσαίας τιμής της απόστασης κάθε τιμής δραστηριότητας από τη μεσαία τιμή του συνόλου των τιμών δραστηριότητας.

Intensity Standard Deviation

Η τυπική απόκλιση αποτελεί τη διακύμανση μεταξύ των τιμών της δραστηριότητας και της μέση τιμή τους, σχέση (18).

$$\sigma = \sqrt{\frac{1}{N} \sum_i \sum_j (I(i, j) - \mu)^2} \quad (18)$$

Intensity-based coefficient of variation

Ο ορισμός της φαίνεται στη σχέση (19).

$$\text{var} = \frac{1}{N_p} \sum_i (X(i) - \bar{X})^2 \quad (19)$$

Intensity Skewness

Λοξότητα ή ασυμμετρία είναι η ασυμμετρία της κατανομής των τιμών δραστηριότητας με βάση τη μέση τιμή και μαθηματικά ορίζεται στη σχέση (20).

$$s = \frac{1}{N} \frac{\sum_i \sum_j (I(i, j) - \mu)^3}{\sigma^3} \quad (20)$$

Intensity Kurtosis

Κυρτότητα είναι η κατανομή που παρουσιάζουν οι τιμές δραστηριότητας σε σύγκριση με την κανονική κατανομή και μαθηματικά ορίζεται στη σχέση (21).

$$k = \frac{1}{N} \frac{\sum_i \sum_j (I(i, j) - \mu)^4}{\sigma^4} \quad (21)$$

Intensity- based quartile coefficient of dispersion

Ο συντελεστής τεταρτημορίου διασποράς είναι μια περιγραφική στατιστική που μετρά τη διασπορά και χρησιμοποιείται για να κάνει συγκρίσεις εντός και μεταξύ συνόλων δεδομένων. Ο ορισμός της είναι η σχέση (22).

$$\frac{Q_3 - Q_1}{Q_3 + Q_1} \quad (22)$$

Όπου:

Q1 το πρώτο τεταρτημόριο για κάθε σύνολο δεδομένων

Q3 το τρίτο τεταρτημόριο για κάθε σύνολο δεδομένων

Intensity-based energy

Η ενέργεια αποδίδει την ομοιογένεια των τιμών και ισούται με το άθροισμα των τετραγώνων των στοιχείων του πίνακα συνεμφάνισης της. Οι τιμές που εξάγει έχουν εύρος 0-1 και μαθηματικά ορίζεται στη σχέση (23).

$$\text{energy} = \sum p(i, j)^2 \quad (23)$$

Intensity Based Entropy

Η εντροπία εκφράζει το εύρος της τυχαίας κατανομής των γειτονικών τιμών. Ο ορισμός της είναι η σχέση (24).

$$\text{entropy} = - \sum p(i, j) * \log(p(i, j)) \quad (24)$$

Η τελική τιμή για κάθε χαρακτηριστικό ισούται με τη μέση τιμή των 4 πινάκων συνεμφάνισης των τιμών έτσι ώστε να εξαλειφθεί η εξάρτηση περιστροφής. Επιπρόσθετα, υπολογίζεται η διαφορά του μέγιστου και του ελάχιστου, δηλαδή του εύρους, για καθεμία από τις 4 διευθύνσεις [30,59].

Πειραματικό Μέρος

9. Πειραματική Διαδικασία

Η πειραματική διαδικασία που ακολουθήθηκε στη παρούσα διπλωματική εργασία είναι η εξής:

9.1. Υλικό

Όλα τα στοιχεία που χρησιμοποιήθηκαν για ταξινόμηση προέρχονται από την βάση δεδομένων “[Depresjon](#)” από το ελεύθερα διαθέσιμο αποθετήριο [Simula](#). Καθίσταται μία συλλογή από σύνολα δεδομένων που συλλέγονται και δημοσιοποιούνται από το ερευνητικό εργαστήριο της Simula και το SimulaMet. Επομένως αποτελεί μία αξιόπιστη και αξιόλογη επιλογή με δεδομένα για ευρεία χρήση μαθησιακών και ερευνητικών σκοπών [21].

Η συγκεκριμένη βιβλιοθήκη περιέχει 2 φακέλους (condition & control) και ένα αρχείο scores.csv.

Ο φάκελος condition περιλαμβάνει 23 αρχεία .csv καθένα από τα οποία περιλαμβάνουν 3 στήλες με τις τιμές της χρονικής διάρκειας, της ημερομηνίας και της κινητικής δραστηριότητας.

Ο φάκελος control περιλαμβάνει 32 αρχεία .csv καθένα από τα οποία περιλαμβάνουν και αυτά 3 στήλες με τις τιμές της χρονικής διάρκειας, της ημερομηνίας και της κινητικής δραστηριότητας.

Και στους δύο αυτούς φακέλους ουσιαστικά δίνονται πληροφορίες σχετικά με την ημερήσια καταγραφή της κινητικής δραστηριότητας των ασθενών για κάποιες ημέρες.

Κάθε αρχείο αντιπροσωπεύει έναν ασθενή και συνολικά τα δεδομένα που έχουμε αφορούν 55 άτομα, υγιή και καταθλιπτικά.

Επομένως, υπάρχουν 23 άτομα που ανήκουν στο condition group και πάσχουν είτε από μονοπολική είτε από διπολική διαταραχή και αντίστοιχα 32 άτομα που ανήκουν στο control group και είναι υγιή.

Συνολικά, υπάρχουν τρεις κατηγορίες στις οποίες κατατάσσονται οι ασθενείς. Στην πρώτη κατηγορία κατατάσσονται τα άτομα τα οποία έχουν διαγνωσθεί με μονοπολική διαταραχή (condition group). Στη δεύτερη κατηγορία ανήκουν οι ασθενείς με διπολική διαταραχή (condition group). Τέλος, στη τρίτη κατηγορία ταξινομούνται όλα τα υγιή άτομα (control group).

Το αρχείο scores.csv περιλαμβάνει 12 στήλες με δεδομένα για : την κατηγορία δηλαδή εάν ο ασθενής ανήκει στην κατηγορία control ή condition, τον αριθμό των ημερών που λήφθηκαν υπόψη, το φύλο, την ηλικία, το afftype, το melanch, το inpatient, την εκπαίδευση, την οικογενειακή κατάσταση, την εργασία και τα madsr1 & madsr2.

Αξιοσημείωτο είναι ότι ο αριθμός των ημερών που λήφθηκαν υπόψη ή αλλιώς ndays όπως αναφέρετε στα δεδομένα, διαφέρει από τον αριθμό των ημερών που διήρκεσαν οι μετρήσεις. Στο πίνακα 9.1. απεικονίζονται οι μέρες αυτές.

Για κάθε φάκελο δημιουργήθηκαν οι αντίστοιχες μέρες καταγραφής που συνολικά φτάνουν τις 693. Από αυτές οι 402 αφορούν τα υγιή άτομα και οι 291 τα καταθλιπτικά άτομα, μονοπολικά και διπολικά.

Πίνακας 9.1:Αριθμός ημερών που λήφθηκαν υπόψη, ndays

	Ndays	
	Control	Condition
1	8	11
2	20	18
3	12	13
4	13	13
5	13	13
6	13	7
7	13	11
8	13	5
9	13	13
10	8	9
11	13	14
12	14	12
13	13	14
14	13	14
15	11	13
16	13	16
17	9	13
18	13	13
19	13	13
20	13	13
21	8	13
22	13	14
23	13	16
24	13	-
25	13	-
26	13	-
27	13	-
28	16	-
29	13	-
30	9	-
31	13	-
32	14	-
Σύνολο: 402 + 291 = 693		

Συνοψίζοντας έγινε χρήση όλων αυτών των δεδομένων και πραγματοποιήθηκε ταξινόμηση σε δύο και τρεις κλάσεις των χρονικών παραθύρων καταγραφής της κινητικής δραστηριότητας (ndays) και για τις τρεις κατηγορίες ασθενών, υγιείς, μονοπολικούς και διπολικούς καταθλιπτικούς.

9.2. Επεξεργασία δεδομένων

Η επεξεργασία των δεδομένων έγινε σε γλώσσα προγραμματισμού Matlab. Στο κύριο κομμάτι κώδικα, έγινε εισαγωγή των φακέλων με τις διάφορες κατηγορίες δεδομένων

και δημιουργήθηκε ένας πίνακας με όλα τα δεδομένα συγκεντρωτικά. Στη συνέχεια, δημιουργήθηκαν μικρά scripts όπου :

1. Γίνεται ταξινόμηση σε 2 κλάσεις, των χρονικών παραθύρων καταγραφής κινητικής δραστηριότητας των υγιή και καταθλιπτικών ατόμων, με 3 χαρακτηριστικά, την μέση κινητική δραστηριότητα, την αντίστοιχη τυπική απόκλιση και το ποσοστό των γεγονότων χωρίς δραστηριότητα.
2. Γίνεται ταξινόμηση σε 2 κλάσεις, των χρονικών παραθύρων καταγραφής κινητικής δραστηριότητας των υγιή και καταθλιπτικών ατόμων, με 17 χαρακτηριστικά, Mean Intensity, Intensity Standard Deviation, Intensity Skewness, Intensity Kurtosis, Median intensity, Minimum intensity, 10th intensity percentile, 90th intensity percentile, Maximum intensity, Intensity interquartile range, Intensity Range, Intensity-based mean absolute deviation, Intensity-based median absolute deviation, Intensity-based coefficient of variation, Intensity-based quartile coefficient of dispersion, Intensity-based energy, Intensity-based Entropy
3. Γίνεται ταξινόμηση σε 3 κλάσεις, των χρονικών παραθύρων καταγραφής κινητικής δραστηριότητας των μονοπολικών καταθλιπτικών, των διπολικών καταθλιπτικών και των υγιή ατόμων, με 3 χαρακτηριστικά, την μέση κινητική δραστηριότητα, την αντίστοιχη τυπική απόκλιση και το ποσοστό των γεγονότων χωρίς δραστηριότητα.
4. Γίνεται ταξινόμηση σε 3 κλάσεις, των χρονικών παραθύρων καταγραφής κινητικής δραστηριότητας των μονοπολικών καταθλιπτικών, των διπολικών καταθλιπτικών και των υγιή ατόμων, με 17 χαρακτηριστικά, Mean Intensity, Intensity Standard Deviation, Intensity Skewness, Intensity Kurtosis, Median intensity, Minimum intensity, 10th intensity percentile, 90th intensity percentile, Maximum intensity, Intensity interquartile range, Intensity Range, Intensity-based mean absolute deviation, Intensity-based median absolute deviation, Intensity-based coefficient of variation, Intensity-based quartile coefficient of dispersion, Intensity-based energy, Intensity-based Entropy

Συγκριτικά με το dataset από την βάση δεδομένων “[Depresjon](#)” από το ελεύθερα διαθέσιμο αποθετήριο [Simula](#) δουλέψαμε παραπάνω χαρακτηριστικά(17 αντί για 3) και πραγματοποιήσαμε και ταξινόμηση σε τρεις κλάσεις όπως φαίνεται παραπάνω στα 2, 3,4 για να βελτιώσουμε τα αποτελέσματα των ποσοστών ταξινόμησης [21].

9.3. Ταξινόμηση και Αξιολόγηση

Για την ταξινόμηση των προτύπων έγινε χρήση της εφαρμογής Matlab-ClassificationLearner. Η συγκεκριμένη εφαρμογή δίνει την επιλογή πολλών διαφορετικών ταξινομητών. Οι ταξινομητές που επιλέχθηκαν είναι: **Trees** (Fine Tree, Medium Tree, Coarse Tree), **SVM** (Linear SVM, Quadratic SVM, Cubic SVM, Fine Gaussian SVM, Medium Gaussian SVM, Coarse Gaussian SVM), **KNN** (Fine KNN, Medium KNN, Coarse KNN, Cosine KNN, Cubic KNN, Weighted KNN), **Ensembles** (Boosted Trees, Bagged Trees, Subspace Discriminant, Subspace KNN, RUSBoosted Trees), **Neural Networks**(Narrow Neural Network, Medium Neural Network, Wide Neural Network, Bilayered Neural Network, Trilayered Neural Network), **Naive Bayes** (Gaussian Naive Bayes, Kernel Naive Bayes), **QDA** (Quadratic Discriminant).

Στις περιπτώσεις 1 & 3 όπου έγινε ταξινόμηση σε 2 και 3 κλάσεις με 3 χαρακτηριστικά εφαρμόστηκε η μέθοδος του Cross Validation και Holdout Validation με τους παραπάνω ταξινομητές. Για το Cross Validation χρησιμοποιήθηκε $k=10$ και στο Holdout Validation έγινε ένα split 70/30.

9.4. Ταξινόμηση με βάση την ιεράρχηση της σημαντικότητας των χαρακτηριστικών με στατιστικά κριτήρια

Στις περιπτώσεις 2 & 4 όπου έγινε ταξινόμηση σε 2 και 3 κλάσεις αλλά με 17 χαρακτηριστικά εφαρμόστηκε αρχικά μία μέθοδος για την επιλογή - μείωση των χαρακτηριστικών. Συγκεκριμένα εφαρμόστηκε η μέθοδος ANOVA και το στατιστικό τεστ Kruskal Wallis και τα χαρακτηριστικά ταξινομήθηκαν σε φθίνουσα σειρά όπως φαίνεται στα διαγράμματα των Εικόνων 19,21,25,27, στην παρακάτω ενότητα. Σε κάθε περίπτωση δεν λήφθηκαν υπόψη τα χαρακτηριστικά που παρουσίαζαν χαμηλή σημαντικότητα και η ταξινόμηση προχώρησε χωρίς αυτά. Έπειτα εφαρμόστηκε παρομοίως η μέθοδος του Cross Validation (με $k=10$) και του Holdout Validation (split 70/30) και με τους παραπάνω ταξινομητές εξήχθησαν τα επιθυμητά δεδομένα.

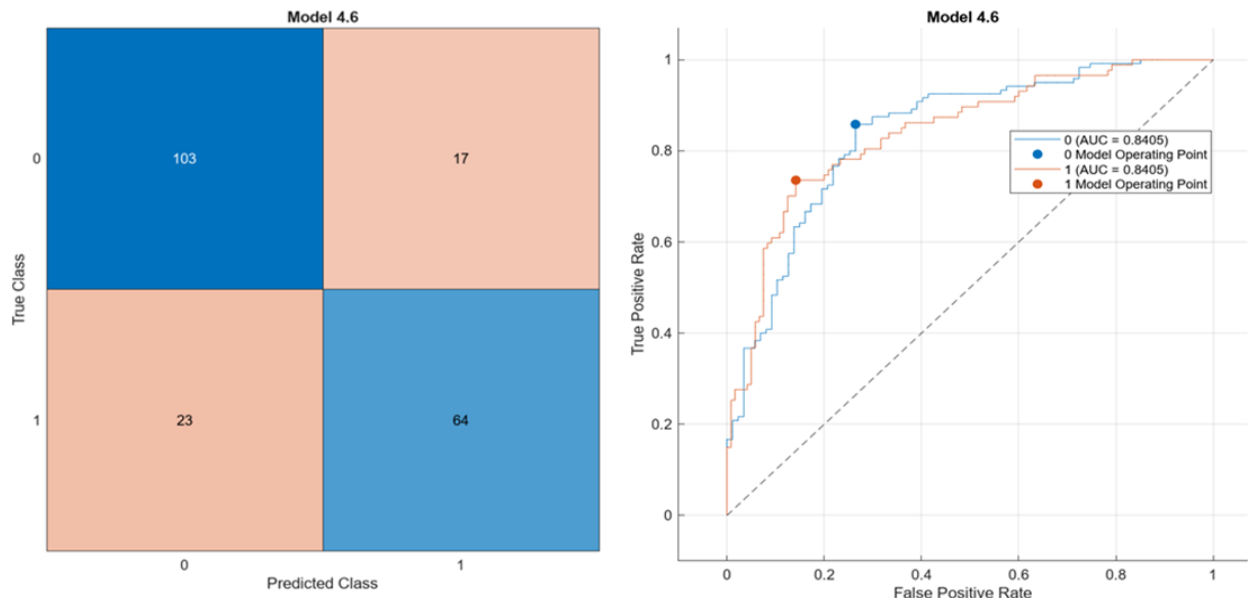
10. Αποτελέσματα

10.1. Ταξινόμηση στα χρονικά παράθυρα καταγραφής κινητικής δραστηριότητας των υγιών και καταθλιπτικών ατόμων με τρία χαρακτηριστικά

Στον Πίνακα 10.1 παρουσιάζονται τα βέλτιστα αποτελέσματα για την ταξινόμηση των δεδομένων σε δύο κλάσεις με τρία χαρακτηριστικά, την μέση κινητική δραστηριότητα, την αντίστοιχη τυπική απόκλιση και το ποσοστό των γεγονότων χωρίς δραστηριότητα. Με την μέθοδο του Cross Validation προκύπτει καλύτερος ταξινομητής ο Fine Gaussian SVM ενώ αντίστοιχα με Holdout Validation ο Weighted KNN. Τα αναλυτικά αποτελέσματα με όλους τους ταξινομητές που δοκιμάστηκαν παρουσιάζονται στους Πίνακες Σ.1 και Σ.2 στην συμπληρωματική ενότητα και κυμαίνονται από 62.3% έως 80.7%. Ο πίνακας αληθείας και η καμπύλη ROC του, απεικονίζονται στην Εικόνα 17.

Πίνακας 10.1 : Αποτελέσματα ταξινόμησης σε δύο κλάσεις με 3 χαρακτηριστικά

%	ACC	PREC	REC	SPEC	MCC	F1
Cross Validation						
Fine Gaussian SVM	76.1	75.6	86.6	61.5	50.2	80.7
Holdout Validation						
Weighted KNN	80.7	81.8	85.8	73.6	60.1	83.7



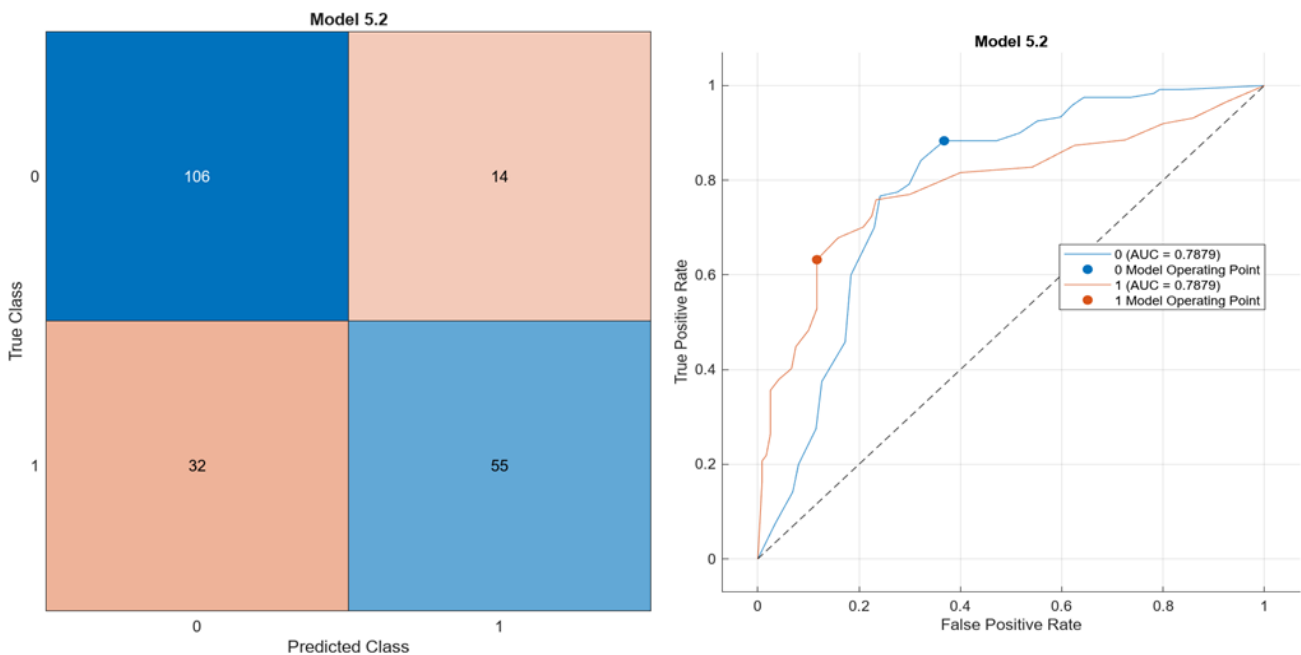
Εικόνα 17: Πίνακας Αληθείας και καμπύλη ROC του Weighted KNN με τη μέθοδο Holdout Validation

10.2. Ταξινόμηση στα χρονικά παράθυρα καταγραφής κινητικής δραστηριότητας των υγιών και καταθλιπτικών ατόμων με δεκαεπτά χαρακτηριστικά

Στον Πίνακα 10.2 παρουσιάζονται τα βέλτιστα αποτελέσματα για την ταξινόμηση των δεδομένων σε δύο κλάσεις με δεκαεπτά χαρακτηριστικά. Και με την μέθοδο του Cross Validation και του Holdout Validation προκύπτει καλύτερος ταξινομητής ο Ensemble Bagged Trees. Τα αναλυτικά αποτελέσματα με όλους τους ταξινομητές που δοκιμάστηκαν παρουσιάζονται στους Πίνακες Σ.3 και Σ.4 στην συμπληρωματική ενότητα και κυμαίνονται από 66.7% έως 77.8%. Το βέλτιστο ποσοστό που επιτυγχάνεται είναι 77.8% με Ensemble Bagged Trees και Holdout Validation. Στην Εικόνα 18 φαίνονται ο πίνακας αληθείας και η καμπύλη ROC του.

Πίνακας 10.2 : Αποτελέσματα ταξινόμησης σε δύο κλάσεις με 17 χαρακτηριστικά

%	ACC	PREC	REC	SPEC	MCC	F1
Cross Validation						
Ensemble Bagged Trees	76.3	76.7	85.1	64.3	50.8	80.7
Holdout Validation						
Ensemble Bagged Trees	77.8	76.8	88.3	63.2	54	82.2




Εικόνα 18: Πίνακας Αληθείας και καμπύλη ROC του Ensemble Bagged Trees με τη μέθοδο Holdout Validation

Για την βελτίωση των ποσοστών των αποτελεσμάτων πραγματοποιείται ταξινόμηση με βάση την ιεράρχηση της σημαντικότητας των χαρακτηριστικών με στατιστικά κριτήρια. Εφαρμόζεται η μέθοδος ANOVA και Kruskal Wallis.

ANOVA

Θέτοντας ως κατώφλι το 10, τα τρία τελευταία χαρακτηριστικά παρουσιάζουν χαμηλή σημαντικότητα και δεν λαμβάνονται υπόψη. Τα χαρακτηριστικά αυτά είναι: Intensity-based quartile coefficient of dispersion, 10th intensity percentile, Intensity-based Entropy

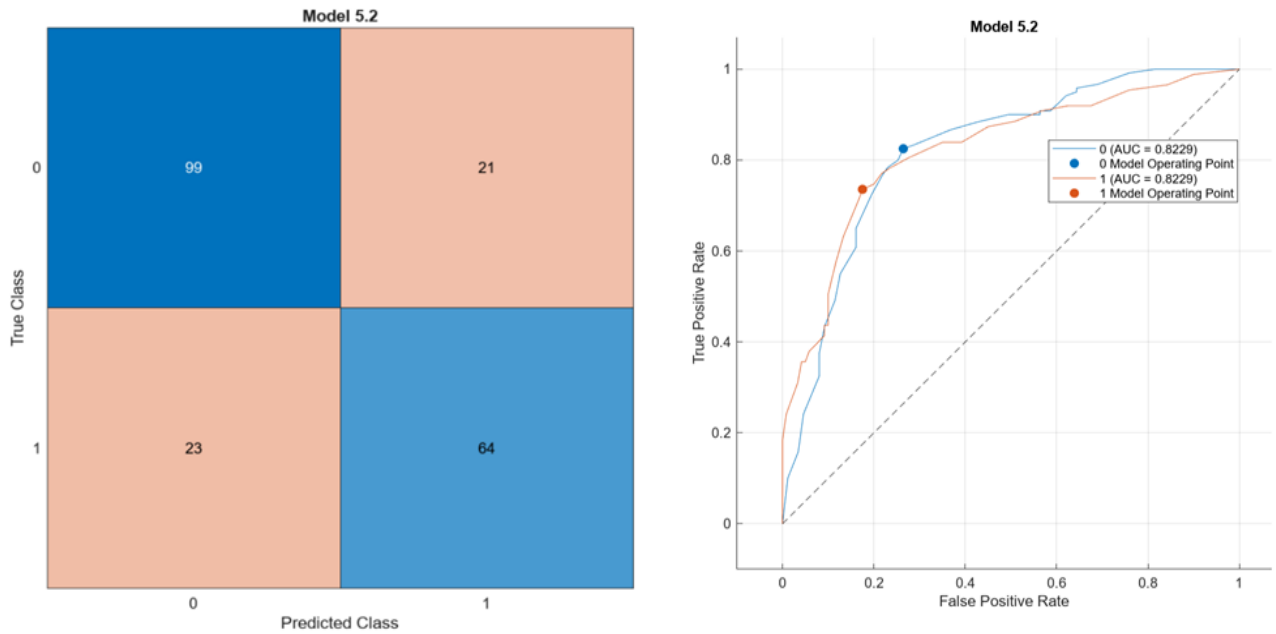


Εικόνα 19: Ιεράρχηση σημαντικότητας χαρακτηριστικών με χρήση της μεθόδου ANOVA

Στον Πίνακα 10.3 παρουσιάζονται τα βέλτιστα αποτελέσματα για την ταξινόμηση των δεδομένων σε δύο κλάσεις με δεκατέσσερα χαρακτηριστικά έπειτα από εφαρμογή ANOVA. Με την μέθοδο του Cross Validation προκύπτει καλύτερος ταξινομητής ο Ensemble Boosted Trees ενώ αντίστοιχα με Holdout Validation ο Ensemble Bagged Trees. Τα αναλυτικά αποτελέσματα με όλους τους ταξινομητές που δοκιμάστηκαν παρουσιάζονται στους Πίνακες Σ.5 και Σ.6 στην συμπληρωματική ενότητα και κυμαίνονται από 65.7% έως 78.7%. Το βέλτιστο ποσοστό που επιτυγχάνεται είναι 78.7% με Ensemble Bagged Trees και Holdout Validation. Ο πίνακας αληθείας και η καμπύλη ROC του, απεικονίζονται στην Εικόνα 20.

Πίνακας 10.3 : Αποτελέσματα ταξινόμησης σε δύο κλάσεις με 14 χαρακτηριστικά και χρήση ANOVA


	ACC	PREC	REC	SPEC	MCC	F1
Cross Validation						
Ensemble Boosted Trees	76.6	76.2	86.8	62.5	51.5	81.2
Holdout Validation						
Ensemble Bagged Trees	78.7	81.2	82.5	73.6	56.3	81.8



Εικόνα 20: Πίνακας Αληθείας και καμπύλη ROC του Ensemble Bagged Trees με τη μέθοδο Holdout Validation

Kruskal Wallis

Θέτοντας ως κατώφλι το 10, τα δύο τελευταία χαρακτηριστικά παρουσιάζουν χαμηλή σημαντικότητα και δεν λαμβάνονται υπόψη. Τα χαρακτηριστικά αυτά είναι: Intensity-based quartile coefficient of dispersion, 10th intensity percentile




Εικόνα 21: Ιεράρχηση σημαντικότητας χαρακτηριστικών με χρήση της μεθόδου Kruskal Wallis

Στον Πίνακα 10.4 παρουσιάζονται τα βέλτιστα αποτελέσματα για την ταξινόμηση των δεδομένων σε δύο κλάσεις με δεκαπέντε χαρακτηριστικά έπειτα από εφαρμογή Kruskal Wallis. Με την μέθοδο του Cross Validation προκύπτει καλύτερος ταξινομητής ο Quadratic SVM ενώ αντίστοιχα με Holdout Validation ο Trilayered Neural Network. Τα αναλυτικά αποτελέσματα με όλους τους ταξινομητές που δοκιμάστηκαν παρουσιάζονται στους Πίνακες Σ.7 και Σ.8 στην συμπληρωματική ενότητα και κυμαίνονται από 66.7% έως 79.2%. Το βέλτιστο ποσοστό που επιτυγχάνεται είναι 79.2% με Trilayered Neural Network και Holdout Validation. Στην Εικόνα 22 φαίνονται ο πίνακας αληθείας και η καμπύλη ROC του.

Πίνακας 10.4 : Αποτελέσματα ταξινόμησης σε δύο κλάσεις με 15 χαρακτηριστικά και χρήση Kruskal Wallis

	ACC	PREC	REC	SPEC	MCC	F1
Cross Validation						
Quadratic SVM	75.3	75.6	84.8	62.2	48.7	80
Holdout Validation						
Trilayered Neural Network	79.2	80.3	85	71.3	57	82.6





Εικόνα 22: Πίνακας Αληθείας και καμπύλη ROC του Trilayerd Neural Network με τη μέθοδο Holdout Validation

10.3. Ταξινόμηση δεδομένων στα χρονικά παράθυρα καταγραφής της κινητικής δραστηριότητας των μονοπολικών καταθλιπτικών, των διπολικών καταθλιπτικών και των υγιών ατόμων με τρία χαρακτηριστικά

Στον Πίνακα 10.5 παρουσιάζονται τα βέλτιστα αποτελέσματα για την ταξινόμηση των δεδομένων σε τρεις κλάσεις με τρία χαρακτηριστικά, την μέση κινητική δραστηριότητα, την αντίστοιχη τυπική απόκλιση και το ποσοστό των γεγονότων χωρίς δραστηριότητα. Με την μέθοδο του Cross Validation προκύπτει καλύτερος ταξινομητής ο Cubic KNN ενώ αντίστοιχα με Holdout Validation ο Trilayered Neural Network. Τα αναλυτικά αποτελέσματα με όλους τους ταξινομητές που δοκιμάστηκαν παρουσιάζονται στους Πίνακες Σ.9 και Σ.10 στην συμπληρωματική ενότητα και κυμαίνονται από 55.9% έως 69%. Ο Cubic KNN επιτυγχάνει το βέλτιστο ποσοστό με επιτυχία 69%. Ο πίνακας αληθείας και η καμπύλη ROC του, απεικονίζονται στην Εικόνα 23.

Πίνακας 10.5 : Αποτελέσματα ταξινόμησης σε τρεις κλάσεις με τρία χαρακτηριστικά

	Class	Total ACC	PREC	REC	ACC	SPEC	MCC	F1
Cross Validation								
Cubic KNN	Control	69	71.8	90.6	73.4	48.6	44.1	80.1
	Bipolar II		57.5	24.2	86.9	97.1	31.4	34.1
	Unipolar Depressive		61.7	44.9	77.7	89.7	38.6	51.9
Holdout Validation								
Trilayered Neural Network	Control	66.7	77.5	83.3	76	65.5	49.8	80.3
	Bipolar II		40.9	31	83.8	92.6	26.6	35.3
	Unipolar Depressive		50.9	49.1	73.5	82.6	32	50




Εικόνα 23: Πίνακας Αληθείας και καμπύλη ROC του Cubic KNN με τη μέθοδο Cross Validation

10.4 .Ταξινόμηση δεδομένων στα χρονικά παράθυρα καταγραφής της κινητικής δραστηριότητας των μονοπολικών καταθλιπτικών, των διπολικών καταθλιπτικών και των υγιών ατόμων με δεκαεπτά χαρακτηριστικά

Στον Πίνακα 10.6 παρουσιάζονται τα βέλτιστα αποτελέσματα για την ταξινόμηση των δεδομένων σε τρεις κλάσεις με δεκαεπτά χαρακτηριστικά.. Με την μέθοδο του Cross Validation προκύπτει καλύτερος ταξινομητής ο Ensemble Boosted Trees ενώ αντίστοιχα με Holdout Validation ο Weighted KNN. Τα αναλυτικά αποτελέσματα με όλους τους ταξινομητές που δοκιμάστηκαν παρουσιάζονται στους Πίνακες Σ.11 και Σ.12 στην συμπληρωματική ενότητα και κυμαίνονται από 51.8% έως 68.1%. Ο Ensemble Boosted Trees επιτυγχάνει το βέλτιστο ποσοστό με επιτυχία 68.1%. Στην Εικόνα 24 φαίνονται ο πίνακας αληθείας και η καμπύλη ROC του.

Πίνακας 10.6 : Αποτελέσματα ταξινόμησης σε 3 κλάσεις με 17 χαρακτηριστικά

%	Class	Total ACC	PREC	REC	ACC	SPEC	MCC	F1
Cross Validation								
Ensemble Boosted Trees	Control	68.1	72.5	89.8	73.8	50.7	45	80.2
	Bipolar II		59.5	23.2	87.1	97.4	31.5	33.3
	Unipolar Depressive		55.2	43.7	75.3	86.9	33.2	48.8
Holdout Validation								
Weighted KNN	Control	67.6	76.5	86.7	76.5	61.9	50.7	81.3
	Bipolar II		44.4	27.6	84.8	94.3	26.9	34
	Unipolar Depressive		52	47.3	74	83.9	32.2	49.5




Εικόνα 24: Πίνακας Αληθείας και καμπύλη ROC του Ensemble Boosted Trees με τη μέθοδο Cross Validation

ANOVA

Θέτοντας ως κατώφλι το 10, τα τρία τελευταία χαρακτηριστικά παρουσιάζουν χαμηλή σημαντικότητα και δεν λαμβάνονται υπόψη.

Τα χαρακτηριστικά αυτά είναι: Intensity-based quartile coefficient of dispersion, 10th intensity percentile, Intensity-based Entropy





Εικόνα 25: Ιεράρχηση σημαντικότητας χαρακτηριστικών με χρήση της μεθόδου ANOVA

Στον Πίνακα 10.7 παρουσιάζονται τα βέλτιστα αποτελέσματα για την ταξινόμηση των δεδομένων σε τρεις κλάσεις με δεκατέσσερα χαρακτηριστικά έπειτα από εφαρμογή ANOVA. Με την μέθοδο του Cross Validation προκύπτει καλύτερος ταξινομητής ο Ensemble Bagged Trees ενώ αντίστοιχα με Holdout Validation ο Quadratic SVM. Τα αναλυτικά αποτελέσματα με όλους τους ταξινομητές που δοκιμάστηκαν παρουσιάζονται στους Πίνακες Σ.13 και Σ.14 στην συμπληρωματική ενότητα και κυμαίνονται από 50% έως 69.1%. Το βέλτιστο ποσοστό που επιτυγχάνεται είναι 69.1% με Ensemble Bagged Trees και Cross Validation. Στην Εικόνα 26 φαίνονται ο πίνακας αληθείας και η καμπύλη ROC του.

Πίνακας 10.7 : Αποτελέσματα ταξινόμησης σε 3 κλάσεις με 14 χαρακτηριστικά και χρήση ANOVA


	Class	Total ACC	PREC	REC	ACC	SPEC	MCC	F1
Cross Validation								
Ensemble Bagged Trees	Control	69.1	74.9	87.1	75.1	57.9	47.7	80.6
	Bipolar II		54.4	32.6	86.8	95.6	35.2	40.8
	Unipolar Depressive		57.1	48.6	76.3	86.5	37.1	52.5
Holdout Validation								
Quadratic SVM	Control	67.2	69.7	90	71.1	44.1	39.2	78.6
	Bipolar II		50	20.7	85.8	96.6	25.6	29.3
	Unipolar Depressive		62.2	41.8	77.5	90.6	37.3	50



Εικόνα 26: Πίνακας Αληθείας και καμπύλη ROC του Ensemble Bagged Trees με τη μέθοδο Cross Validation

Kruskal Wallis

Θέτοντας ως κατώφλι το 10, τα δύο τελευταία χαρακτηριστικά παρουσιάζουν χαμηλή σημαντικότητα και δεν λαμβάνονται υπόψη. Τα χαρακτηριστικά αυτά είναι: 10th intensity percentile, Intensity-based quartile coefficient of dispersion




Εικόνα 27: Ιεράρχηση σημαντικότητας χαρακτηριστικών με χρήση της μεθόδου Kruskal Wallis

Στον Πίνακα 10.8 παρουσιάζονται τα βέλτιστα αποτελέσματα για την ταξινόμηση των δεδομένων σε τρεις κλάσεις με δεκαπέντε χαρακτηριστικά έπειτα από εφαρμογή Kruskal Wallis. Με την μέθοδο του Cross Validation προκύπτει καλύτερος ταξινομητής ο Ensemble Bagged Trees ενώ αντίστοιχα με Holdout Validation ο Weighted KNN. Τα αναλυτικά αποτελέσματα με όλους τους ταξινομητές που δοκιμάστηκαν παρουσιάζονται στους Πίνακες Σ.15 και Σ.16 στην συμπληρωματική ενότητα και κυμαίνονται από 47.5% έως 69.6%. Το βέλτιστο ποσοστό που επιτυγχάνεται είναι 69.6% με Ensemble Bagged Trees και Cross Validation. Ο πίνακας αληθείας και η καμπύλη ROC του, απεικονίζονται στην Εικόνα 28.

Πίνακας 10.8 : Αποτελέσματα ταξινόμησης σε 3 κλάσεις με 15 χαρακτηριστικά και χρήση Kruskal Wallis

	Class	Total ACC	PREC	REC	ACC	SPEC	MCC	F1
Cross Validation								
Ensemble Bagged Trees	Control	69.6	74.9	88.6	75.7	57.2	49	81.2
	Bipolar II		55.8	30.5	86.7	96.1	34.7	39.5
	Unipolar Depressive		57.5	48.1	76.5	86.9	37.2	52.4
Holdout Validation								
Weighted KNN	Control	68.6	76.8	87.6	77	61.5	51.5	81.9
	Bipolar II		41.7	17.2	84.8	96	19.7	24.4
	Unipolar Depressive		53.7	53.7	75.5	83.3	37	53.7



Εικόνα 28: Πίνακας Αληθείας και καμπύλη ROC του Ensemble Bagged Trees με τη μέθοδο Cross Validation

11. Συμπεράσματα - Συζήτηση

Τα αποτελέσματα μας συνάδουν και μάλιστα παρουσιάζουν βελτίωση σύμφωνα με τη διεθνή βιβλιογραφία και συγκεκριμένα με το άρθρο των Garcia-Ceja, E., και άλλοι [21]. Η ταξινόμηση των δεδομένων κινητικής δραστηριότητας διεξάγεται με επιτυχία παρόλο την ετερογένεια και την πληθώρα που παρουσιάζουν. Ικανοποιητική εμφανίζεται η απόδοση της ταξινόμησης σε δύο κλάσεις των χρονικών παραθύρων καταγραφής κινητικής δραστηριότητας των υγιή και καταθλιπτικών ατόμων, είτε με τρία είτε με δεκαεπτά χαρακτηριστικά με χρήση τόσο Cross Validation όσο και Holdout Validation, με ποσοστά πάνω από 70%. Συγκεκριμένα παρατηρούμε το βέλτιστο ποσοστό στη ταξινόμηση δύο κλάσεων με τρία χαρακτηριστικά και Holdout Validation αγγίζοντας το ποσοστό 80.7% με Weighted KNN. Στη διεθνή βιβλιογραφία, το βέλτιστο ποσοστό που επιτυγχάνεται είναι 72.7% με Linear SVM.

Ομοίως ικανοποιητικά είναι και τα αποτελέσματα με ταξινόμηση σε τρεις κλάσεις των χρονικών παραθύρων καταγραφής κινητικής δραστηριότητας των μονοπολικών καταθλιπτικών, των διπολικών καταθλιπτικών και των υγιή ατόμων, χωρίς τα ποσοστά να πέφτουν πολύ κάτω από 70%. Σε αυτή τη περίπτωση η χρήση περισσότερων χαρακτηριστικών (17 αντί για 3) βοηθάει στη βελτίωση των ποσοστών ταξινόμησης. Το καλύτερο ποσοστό επιτυγχάνεται στην ταξινόμηση τριών κλάσεων με δεκαεπτά χαρακτηριστικά, με χρήση Kruskal Wallis test για ιεράρχηση σημαντικότητας χαρακτηριστικών και Cross Validation. Ειδικότερα ο Ensemble Bagged Trees φτάνει το 69.6%.

Παράλληλα, παρατηρούμε ότι στις περιπτώσεις που έγινε χρήση του ANOVA και Kruskal Wallis test για την ιεράρχηση της σημαντικότητας των χαρακτηριστικών οι αποδόσεις των ταξινομήσεων είναι βελτιωμένες.

Τα καλύτερα ποσοστά που πετυχαίνουμε σε κάθε περίπτωση προκύπτουν με διάφορους και διαφορετικούς ταξινομητές.

Γενικά, η παρούσα διπλωματική εξετάζει μία εφαρμογή που στηρίζεται στη χρήση αλγορίθμων μηχανικής μάθησης για την ταξινόμηση καταθλιπτικών καταστάσεων. Παρόλο που η απόδοση των μοντέλων μηχανικής μάθησης είναι σε αρκετά ικανοποιητικό επίπεδο σε πληθώρα εφαρμογών, η ανίχνευση της κατάθλιψης διπολικής ή μονοπολικής και η θεραπεία της δεν έχει δοκιμαστεί ακόμα παρόλο που η εφαρμογή σε κλινικό περιβάλλον αποτελεί των απώτερο σκοπό. Επίσης, περιορισμοί όπως μικρά dataset, ελλιπή χαρακτηριστικά και κλινικές παράμετροι όπως ιστορικό ασθενούς, κληρονομικότητα, φαρμακευτικές αγωγές, ομάδες ατόμων δεν παρέχονται. Συνεπώς η απόδοση των μοντέλων είναι σε ένα περιβάλλον που θα το έλεγε κανείς εξιδανικευμένο και διαφοροποιημένο από την πραγματική κλινική εικόνα του ασθενούς.

Άρα λύσεις, όπως η χρήση μεγάλων dataset, η προσθήκη όλο και περισσότερων αξιοσημείωτων χαρακτηριστικών και κλινικών παραμέτρων, η δειγματοληψία σε διάφορες ομάδες ατόμων και η συνεχής εκπαίδευση των μοντέλων και ταξινόμηση των δεδομένων θα ενισχύσει σημαντικά την αποτελεσματικότητα και ευρωστία των ταξινομήσεων για όλες τις υποβοηθούμενες εφαρμογές στην ιατρική.

12. Μελλοντικές Προοπτικές

Ενδιαφέρον θα παρουσίαζε ο πειραματισμός με την κλίμακα MADRS μελλοντικά. Αξιοποιώντας τις τιμές `madr1` και `madr2` από το αρχείο `scores.csv` μπορούμε να ταξινομήσουμε και να κατηγοριοποιήσουμε τους ασθενείς με βάση τη σοβαρότητα της κατάθλιψής τους (ελάχιστη, ήπια, μέτρια, σοβαρή).

Επίσης η εύρεση ή συλλογή περισσότερων δεδομένων από διάφορες ομάδες ατόμων ενδεχομένως να μας δώσει τη δυνατότητα να επιτύχουμε καλύτερα ποσοστά ταξινόμησης.

Παράλληλα, κλινικές παράμετροι όπως ιστορικό ασθενούς, κληρονομικότητα και φαρμακευτικές αγωγές θα έδιναν τη δυνατότητα για την πιο εν των βάθην μελέτη των ασθενών και συνεπώς την απόκτηση όλο και πιο έγκυρων αποτελεσμάτων που σχετίζονται με τη πραγματική ζωή και όχι με ένα εξιδανικευμένο περιβάλλον.

Βιβλιογραφικές Πηγές

- [1] Abe S., (2010), Support Vector Machines for Pattern Classification Second Edition, Springer.
- [2] Alpaydin E., (2014), Introduction to Machine Learning Third Edition, MIT Press
- [3] Bech, P., Tanghoj, P., Cialdella, P., & Andersen, H. F., (2001), Psychometric evaluation of the Bech-Rafaelsen Melancholia Scale and the Montgomery-Asberg Depression Scale in the treatment of major depression, *Journal of Affective Disorders*, 64(2-3), 203-213.
- [4] Bishop, Christopher M., (2016), Pattern Recognition and Machine Learning, SpringerLink.
- [5] Breiman, L., (1996), Bagging predictors, *Machine Learning*, 24(2), 123–140.
- [6] Caruana R., Niculescu-Mizil A., (2006), An Empirical Comparison of Supervised Learning Algorithms, Department of Computer Science, Cornell University.
- [7] Classification Learner Help Center, MathWorks.
<https://www.mathworks.com/help/stats/classificationlearner-app.html>
- [8] Cortes, C., Vapnik Vladimir, (1995), Support-vector networks, *Machine Learning*, 20(3), 273–297. <https://doi.org/10.1007/bf00994018>
- [9] Daniel Wayne W., Cross Chad L., Biostatistics: A Foundation for Analysis in the Health Sciences, 10th edition, Edwards Brothers Malloy,
https://faculty.ksu.edu.sa/sites/default/files/145_stat_-_textbook.pdf
- [10] Domingos, P., Pazzani, M., (1997), On the Optimality of the Simple Bayesian Classifier under Zero-One Loss, *Machine Learning*, 29(2-3), 103-130.
- [11] Duda, R. O., Hart, P. E., Stork, D. G., (2000), Pattern Classification, Wiley.
- [12] Dudani S.A., (1976), The Distance-weighted k-Nearest Neighbor Rule, *IEEE Transactions On System Man and Cybernetics*, vol. SMC-6, pp. 325-327.
- [13] Elliott Rebecca., (1998), The Neuropsychological Profile in Unipolar Depression, *Trends in Cognitive Sciences*, vol. 2, no. 11, pp. 447–454.
- [14] Enoka Roger M., (2001), Neuromechanics of Human Movement, Human Kinetics.
- [15] Evans, Chris., (2012), Precision Engineering: An Evolutionary Perspective. *Philosophical transactions. Series A, Mathematical, physical, and engineering sciences*. 370. 3835-51. 10.109.
- [16] Ewens, W. J., & Grant, G., (2019), Statistical Methods in Bioinformatics, SpringerLink.
- [17] Fahmy Amin, M. (2023). Confusion Matrix in Three-class Classification Problems: A Step-by-Step Tutorial. *Journal of Engineering Research*, 7(1).
- [18] Fawcett, T., (2006), An introduction to ROC analysis, *Pattern Recognition Letters*, 27(8), 861–874.
- [19] Field A., (2013), Discovering Statistics Using IBM SPSS Statistics, Sage Publications.
- [20] Freund, Y., Schapire, R. E., (1997), A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting, *Journal of Computer and System Sciences*, 55(1), 119–139, Elsevier.
- [21] Garcia-Ceja, E., Riegler, M., Jakobsen, P., Tørresen, J., Nordgreen, T., Oedegaard, K. J., & Fasmer, O. B. (2018). Depresjon: a motor activity database of depression episodes in unipolar and bipolar patients, *Proceedings of the 9th ACM Multimedia Systems Conference*. <https://doi.org/10.1145/3204949.3208125>
- [22] Goodfellow, I., Bengio, Y., & Courville, A., (2016), Deep Learning. MIT Press.

- [23] Grus Joel, (2019), Data Science from Scratch, Εκδόσεις Παπασωτηρίου , ISBN 978-1-492-04113-9.
- [24] Hanley, J. A., & McNeil, B. J., (1982), The meaning and use of the area under a receiver operating characteristic (ROC) curve, *Radiology*, 143(1), 29-36.
- [25] Hastie, T., Tibshirani, R., & Friedman, J., (2009), *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*, Springer.
- [26] He H., Yunqian M., (2013), *Imbalanced Learning: Foundations, Algorithms, and Applications*, IEEE.
- [27] He K., Zhang, X., Ren, S., & Sun, J., (2016), Deep Residual Learning for Image Recognition, IEEE, <https://doi.org/10.1109/cvpr.2016.90>
- [28] Ho, K., (1998), The random subspace method for constructing decision forests, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 20(8), 832–844.
- [29] Hollander M., Wolfe D. A., Chicken E., (2013), *Nonparametric Statistical Methods*, Wiley.
- [30] Image Biomarker Standardisation Initiative IBSI , Image Features v10 version, Creative Commons Attribution .
- [31] James G., Witten D., Hastie T., Tibshirani R., Taylor J., (2023), *An introduction to Statistical Learning*, Springer.
- [32] Kande Eric R., Koester John D., Mack Sarah H., Siegelbaum Steven A., (2021), *Principles of Neural Science*, McGraw Hill.
- [33] Kelso, J.A. Scott, (1982), *Human Motor Behavior: An Introduction*, Lawrence Erlbaum Associates.
- [34] Magill Richard A., Anderson David I., (2016), *Motor Learning and Control: Concepts and Applications 11th Edition*, McGraw Hill.
- [35] Mahesh, Batta., (2018), *Machine Learning Algorithms -A Review*, *International Journal of Science and Research (IJSR) ResearchGate Impact Factor*, vol. 9, no. 1.
- [36] Manning Christopher D., Prabhakar Raghavan, and Hinrich Schütze, (2008), *Introduction to Information Retrieval*, Cambridge University Press.
- [37] MATLAB Help Center Documentation, <https://www.mathworks.com/products/matlab.html>
- [38] McLachlan, G. J., (2004), *Discriminant Analysis and Statistical Pattern Recognition*, Wiley.
- [39] Mitchell, T. M., (1997), *Machine Learning*, McGraw-Hill.
- [40] Monaghan, T. F., Rahman, S. N., Agudelo, C. W., Wein, A. J., Lazar, J. M., Karel Everaert, Dmochowski, R. R., (2021), Foundational Statistical Principles in Medical Research: Sensitivity, Specificity, Positive Predictive Value, and Negative Predictive Value, *Medicina*, 57(5), 503–503, <https://doi.org/10.3390/medicina57050503>
- [41] Montgomery D. C., (2017), *Design and Analysis of Experiments*, Wiley.
- [42] Montgomery, S. A., & Åsberg, M., (1979), A new depression scale designed to be sensitive to change, *British Journal of Psychiatry*, 134(4), 382-389.
- [43] Müller Andreas C., Guido Sarah, (2016), *Introduction to Machine Learning with Python*, O'Reilly Media Inc.
- [44] Murphy, K. P., (2012), *Machine Learning: A Probabilistic Perspective*, MIT Press.
- [45] National Institute for Health and Care Excellence (NICE), (2009), *Depression in adults with a chronic physical health problem: recognition and management*, <https://www.nice.org.uk/guidance/cg91>

- [46] National Institute for Health and Care Excellence (NICE), (2022), Depression in adults: treatment and management, <https://www.nice.org.uk/guidance/ng222>
- [47] National Institute of Mental Health (NIMH), (2024), Bipolar Disorder, <https://www.nimh.nih.gov/health/topics/bipolar-disorder>
- [48] Naqa Issam El., Murphy Martin J., (2015), What Is Machine Learning ?, Springer EBooks.
- [49] Nello Cristianini, & Shawe-Taylor, J., (2000), An Introduction to Support Vector Machines and Other Kernel-based Learning Methods, Cambridge University Press.
- [50] Nielsen M., (2015), Neural Networks and Deep Learning, Determiation Press.
- [51] Okfalisa, Gazalba I., Mustakim, Reza I., (2017), Comparative analysis of k-nearest neighbor and modified k-nearest neighbor algorithm for data classification, IEEE.
- [52] Philips RESPIRONICS, <https://www.philips.gr/healthcare/product/HC1046964/actiwatch-spectrum-activity-monitor>
- [53] Powers, D. M. W., (2011), Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation, Journal of Machine Learning Technologies, 2(1), 37-63.
- [54] Press William H., Teukolsky Saul A., Vetterling William T., Flannery Brian P., (2007), Numerical Recipes, Cambridge University Press.
- [55] Provost, F., & Fawcett, T., (2001), Robust classification for imprecise environments, Machine Learning, 42, 203-231.
- [56] Quinlan, J. R., (1986), Induction of decision trees, Machine Learning, 1(1), 81–106, Springer.
- [57] Rish, I., (2001), An empirical study of the naive Bayes classifier, IJCAI Workshop on Empirical Methods in Artificial Intelligence.
- [58] Slocum A., (1989), Precision Engineering: An Evolutionary View, Cranfield.
- [59] Scapicchio C., Gabelloni M., Barucci A., Cioni D., Saba L., Neri E., (2021), A deep look into radiomics , La radiologia medica
- [60] Schmidt, R., & Lee, T., (2019), Motor Learning and Performance (6th ed.), Human Kinetics.
- [61] Scholkopf, B., & Smola, A. J., (2002), Learning with Kernels, MIT Press.
- [62] Scikit-learn: SVM, <https://scikit-learn.org/stable/modules/svm.html>
- [63] Scikit-learn: K-Neighbors Classifier, <https://scikit-learn.org/stable/modules/generated/sklearn.neighbors.KNeighborsClassifier.html>
- [64] Scikit-learn Naïve Bayes, https://scikit-learn.org/stable/modules/naive_bayes.html#gaussian-naive-bayes
- [65] Scikit-learn MCC, https://scikit-learn.org/stable/modules/model_evaluation.html#matthews-corrcoef
- [66] Scikit-learn F1-Score, https://scikit-learn.org/stable/modules/model_evaluation.html#f1-macro
- [67] Seiffert, C., Khoshgoftaar, T. M., Van Hulse, J., & Napolitano, A. (2010). RUSBoost: A Hybrid Approach to Alleviating Class Imbalance. IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans, 40(1), 185–197.
- [68] Snaith, R. P., (1987), The Montgomery-Asberg Depression Scale, British Journal of Psychiatry, 150(6), 782-786.
- [69] Stringaris Argyris., (2017), Editorial: What Is Depression?, Journal of Child Psychology and Psychiatry, vol. 58, no. 12, pp. 1287–1289.
- [70] Suzuki K., (2013), Artificial Neural Networks: Architectures and Applications, Intechopen.

- [71] Σκιπιτάρης Δ., Σακιώτης Α.,(2019), Μοντελοποίηση Αλγορίθμων Συσταδοποίησης και Εφαρμογές στη Μηχανική Μάθηση , Τμήμα Μηχανικών Πληροφορικής, ΤΕΙ Δυτικής Ελλάδος.
- [72] Vapnik, V. N., (2000), The Nature of Statistical Learning Theory, Springer-Verlag.
- [73] Villines, Zawn., (2022), What to Know about Unipolar Depression., Medical News Today, <https://www.medicalnewstoday.com/articles/unipolar-depression#treatment> .
- [74] Watanabe, S., Pakvasa, N., (1973), Subspace method of pattern recognition, IJCP, pp. 25-32.
- [75] Wendt, Taylor., (2023), What Is Unipolar Depression?, WebMD, <https://www.webmd.com/depression/what-is-unipolar-depression>
- [76] Witten Ian H., Frank Eibe, (2005), Data Mining: Practical Machine Learning Tools and Techniques Second Edition, Elsevier.
- [77] Zhang, H., (2004), The Optimality of Naive Bayes, Proceedings of the Seventeenth International Florida Artificial Intelligence Research Society Conference.
- [78] Zhi-Hua Zhou, (2012), Ensemble Methods: Foundations and Algorithms, CRC Press.

Συμπληρωματικό υλικό

Ταξινόμηση δεδομένων σε δύο κλάσεις με τρία χαρακτηριστικά

Cross Validation

Πίνακας Σ.1 : Αποτελέσματα ταξινόμησης σε 2 κλάσεις με 3 χαρακτηριστικά με τη μέθοδο Cross Validation

		%	PREC	REC	ACC	SPEC	MCC	F1
Trees	Fine Tree	68.5	0.7371	0.7114	0.6854	0.6495	0.3589	0.7241
	Medium Tree	71.6	0.7243	0.8234	0.7157	0.5670	0.4066	0.7707
	Coarse Tree	72.2	0.7173	0.8582	0.7215	0.5326	0.4186	0.7814
SVM	Linear SVM	72.3	0.7244	0.8433	0.7229	0.5567	0.4216	0.7793
	Quadratic SVM	71.4	0.7008	0.8856	0.7143	0.4777	0.4053	0.7824
	Cubic SVM	63.5	0.6511	0.7985	0.6349	0.4089	0.2260	0.7173
	Fine Gaussian SVM	76	0.7565	0.8657	0.7605	0.6151	0.5023	0.8074
	Medium Gaussian SVM	74.2	0.7528	0.8259	0.7417	0.6254	0.4630	0.7877
	Coarse Gaussian SVM	71.3	0.6971	0.8930	0.7128	0.4639	0.4032	0.7830
KNN	Fine KNN	69.4	0.7474	0.7139	0.6941	0.6667	0.3779	0.7303
	Medium KNN	73.6	0.7296	0.8657	0.7359	0.5567	0.4501	0.7918
	Coarse KNN	72.3	0.7143	0.8706	0.7229	0.5189	0.4224	0.7848
	Cosine KNN	70.7	0.7236	0.8010	0.7071	0.5773	0.3895	0.7603
	Cubic KNN	74	0.7342	0.8657	0.7403	0.5670	0.4593	0.7945
	Weighted KNN	73.3	0.7640	0.7811	0.7330	0.6667	0.4498	0.7724
Ensemble	Boosted Trees	73.4	0.7455	0.8234	0.7345	0.6117	0.4475	0.7825
	Bagged Trees	72	0.7500	0.7761	0.7201	0.6426	0.4219	0.7628
	Subspace Discriminant	71.4	0.7318	0.8010	0.7143	0.5945	0.4054	0.7648
	Subspace KNN	69.7	0.7286	0.7612	0.6970	0.6082	0.3732	0.7445
	RUSBoosted Trees	72.9	0.7716	0.7562	0.7287	0.6907	0.4454	0.7638
Neural Networks	Narrow Neural Network	73.3	0.7449	0.8209	0.7330	0.6117	0.4446	0.7811
	Medium Neural Network	69.3	0.7345	0.7363	0.6926	0.6323	0.3688	0.7354
	Wide Neural Network	69	0.7367	0.7239	0.6898	0.6426	0.3654	0.7302
	Bilayered Neural Network	70.7	0.7421	0.7587	0.7071	0.6357	0.3963	0.7503
	Trilayered Neural Network	72	0.7441	0.7886	0.7201	0.6254	0.4198	0.7657
Naive Bayes	Gaussian Naive Bayes	71.6	0.7608	0.7438	0.7157	0.6770	0.4191	0.7522
	Kernel Naive Bayes	73.2	0.7422	0.8234	0.7316	0.6048	0.4412	0.7807
QDA	Quadratic Discriminant	72.7	0.7825	0.7338	0.7273	0.7182	0.4479	0.7574

Holdout Validation**Πίνακας Σ.2 :** Αποτελέσματα ταξινόμησης σε 2 κλάσεις με 3 χαρακτηριστικά με τη μέθοδο Holdout Validation

		%	PREC	REC	ACC	SPEC	MCC	F1
Trees	Fine Tree	62.3	0.6810	0.6583	0.6232	0.5747	0.2318	0.6695
	Medium Tree	71	0.7083	0.8500	0.7101	0.5172	0.3940	0.7727
	Coarse Tree	75.4	0.7447	0.8750	0.7536	0.5862	0.4885	0.8046
SVM	Linear SVM	74.4	0.7376	0.8667	0.7440	0.5747	0.4675	0.7969
	Quadratic SVM	74.4	0.7134	0.9333	0.7440	0.4828	0.4798	0.8087
	Cubic SVM	63.3	0.6279	0.9000	0.6329	0.2644	0.2165	0.7397
	Fine Gaussian SVM	80.2	0.7883	0.9000	0.8019	0.6667	0.5912	0.8405
	Medium Gaussian SVM	77.8	0.7721	0.8750	0.7778	0.6437	0.5393	0.8203
	Coarse Gaussian SVM	71	0.6899	0.9083	0.7101	0.4368	0.4008	0.7842
KNN	Fine KNN	70.5	0.7479	0.7417	0.7053	0.6552	0.3962	0.7448
	Medium KNN	74.9	0.7429	0.8667	0.7488	0.5862	0.4778	0.8000
	Coarse KNN	72.5	0.7203	0.8583	0.7246	0.5402	0.4257	0.7833
	Cosine KNN	74.9	0.7500	0.8500	0.7488	0.6092	0.4775	0.7969
	Cubic KNN	76.8	0.7571	0.8833	0.7681	0.6092	0.5196	0.8154
	Weighted KNN	80.7	0.8175	0.8583	0.8068	0.7356	0.6007	0.8374
Ensemble	Boosted Trees	73.4	0.7519	0.8083	0.7343	0.6322	0.4487	0.7791
	Bagged Trees	71	0.7381	0.7750	0.7101	0.6207	0.4002	0.7561
	Subspace Discriminant	72.9	0.7424	0.8167	0.7295	0.6092	0.4373	0.7778
	Subspace KNN	66.7	0.7008	0.7417	0.6667	0.5632	0.3091	0.7206
	RUSBoosted Trees	73.9	0.7845	0.7583	0.7391	0.7126	0.4684	0.7712
Neural Networks	Narrow Neural Network	75.4	0.7717	0.8167	0.7536	0.6667	0.4899	0.7935
	Medium Neural Network	75.4	0.7805	0.8000	0.7536	0.6897	0.4922	0.7901
	Wide Neural Network	65.2	0.7143	0.6667	0.6522	0.6322	0.2960	0.6897
	Bilayered Neural Network	72.9	0.7759	0.7500	0.7295	0.7011	0.4487	0.7627
	Trilayered Neural Network	71	0.7381	0.7750	0.7101	0.6207	0.4002	0.7561
Naive Bayes	Gaussian Naive Bayes	74.9	0.7881	0.7750	0.7488	0.7126	0.4862	0.7815
	Kernel Naive Bayes	72.5	0.7442	0.8000	0.7246	0.6207	0.4285	0.7711
QDA	Quadratic Discriminant	77.3	0.8230	0.7750	0.7729	0.7701	0.5404	0.7983

Ταξινόμηση δεδομένων σε δύο κλάσεις με δεκαεπτά χαρακτηριστικά

Cross Validation**Πίνακας Σ.3 :** Αποτελέσματα ταξινόμησης σε 2 κλάσεις με 17 χαρακτηριστικά με τη μέθοδο Cross Validation

		%	PREC	REC	ACC	SPEC	MCC	F1
Trees	Fine Tree	72.3	0.7561	0.7711	0.7229	0.6564	0.4293	0.7635
	Medium Tree	72.9	0.7326	0.8383	0.7287	0.5773	0.4342	0.7819
	Coarse Tree	72	0.7364	0.8060	0.7201	0.6014	0.4176	0.7696
SVM	Linear SVM	74.5	0.7517	0.8358	0.7446	0.6186	0.4687	0.7915
	Quadratic SVM	74.3	0.7424	0.8532	0.7431	0.5911	0.4652	0.7940
	Cubic SVM	72	0.7430	0.7910	0.7201	0.6220	0.4195	0.7663
	Fine Gaussian SVM	74.7	0.7506	0.8458	0.7475	0.6117	0.4745	0.7953
	Medium Gaussian SVM	74.2	0.7461	0.8408	0.7417	0.6048	0.4622	0.7906
	Coarse Gaussian SVM	73.3	0.7343	0.8458	0.7330	0.5773	0.4434	0.7861
KNN	Fine KNN	69.6	0.7393	0.7338	0.6955	0.6426	0.3759	0.7366
	Medium KNN	73.4	0.7309	0.8582	0.7345	0.5636	0.4467	0.7895
	Coarse KNN	72.2	0.7191	0.8532	0.7215	0.5395	0.4185	0.7804
	Cosine KNN	75.2	0.7650	0.8259	0.7518	0.6495	0.4849	0.7943
	Cubic KNN	74	0.7352	0.8632	0.7403	0.5704	0.4592	0.7941
	Weighted KNN	74.2	0.7599	0.8109	0.7417	0.6460	0.4644	0.7846
Ensemble	Boosted Trees	74.9	0.7664	0.8159	0.7489	0.6564	0.4796	0.7904
	Bagged Trees	76.3	0.7668	0.8507	0.7633	0.6426	0.5084	0.8066
	Subspace Discriminant	75	0.7596	0.8333	0.7504	0.6357	0.4813	0.7948
	Subspace KNN	71.6	0.7494	0.7662	0.7157	0.6460	0.4141	0.7577
	RUSBoosted Trees	75	0.7855	0.7836	0.7504	0.7045	0.4878	0.7846
Neural Networks	Narrow Neural Network	71	0.7445	0.7612	0.7100	0.6392	0.4022	0.7528
	Medium Neural Network	68.5	0.7244	0.7388	0.6854	0.6117	0.3519	0.7315
	Wide Neural Network	71.1	0.7416	0.7711	0.7114	0.6289	0.4035	0.7561
	Bilayered Neural Network	69.7	0.7400	0.7363	0.6970	0.6426	0.3786	0.7382
	Trilayered Neural Network	70.4	0.7420	0.7512	0.7042	0.6392	0.3914	0.7466
Naive Bayes	Gaussian Naive Bayes	69.3	0.8039	0.6219	0.6926	0.7904	0.4091	0.7013
	Kernel Naive Bayes	70	0.7709	0.6866	0.6999	0.7182	0.3998	0.7263
QDA	Quadratic Discriminant	68.8	0.7943	0.6244	0.6883	0.7766	0.3974	0.6992

Holdout Validation

Πίνακας Σ.4 : Αποτελέσματα ταξινόμησης σε 2 κλάσεις με 17 χαρακτηριστικά με τη μέθοδο Holdout Validation

		%	PREC	REC	ACC	SPEC	MCC	F1
Trees	Fine Tree	68.1	0.7177	0.7417	0.6812	0.5977	0.3418	0.7295
	Medium Tree	71	0.7174	0.8250	0.7101	0.5517	0.3945	0.7674
	Coarse Tree	71	0.7000	0.8750	0.7101	0.4828	0.3953	0.7778
SVM	Linear SVM	73.9	0.7357	0.8583	0.7391	0.5747	0.4569	0.7923
	Quadratic SVM	76.8	0.7535	0.8917	0.7681	0.5977	0.5205	0.8168
	Cubic SVM	75.8	0.7692	0.8333	0.7585	0.6552	0.4989	0.8000
	Fine Gaussian SVM	69.6	0.6966	0.8417	0.6957	0.4943	0.3620	0.7623
	Medium Gaussian SVM	72.9	0.7254	0.8583	0.7295	0.5517	0.4361	0.7863
	Coarse Gaussian SVM	71	0.7143	0.8333	0.7101	0.5402	0.3941	0.7692
	KNN	Fine KNN	71	0.7632	0.7250	0.7101	0.6897	0.4115
Medium KNN	74.4	0.7376	0.8667	0.7440	0.5747	0.4675	0.7969	
Coarse KNN	68.6	0.6871	0.8417	0.6860	0.4713	0.3405	0.7566	
Cosine KNN	74.9	0.7576	0.8333	0.7488	0.6322	0.4780	0.7937	
Cubic KNN	72.9	0.7286	0.8500	0.7295	0.5632	0.4359	0.7846	
Weighted KNN	74.4	0.7597	0.8167	0.7440	0.6437	0.4689	0.7871	
Ensemble	Boosted Trees	74.9	0.7394	0.8750	0.7488	0.5747	0.4783	0.8015
	Bagged Trees	77.8	0.7681	0.8833	0.7778	0.6322	0.5398	0.8217
	Subspace Discriminant	74.4	0.7519	0.8333	0.7440	0.6207	0.4676	0.7905
	Subspace KNN	72	0.7541	0.7667	0.7198	0.6552	0.4233	0.7603
	RUSBoosted Trees	74.4	0.7410	0.8583	0.7440	0.5862	0.4672	0.7954
Neural Networks	Narrow Neural Network	73.9	0.7750	0.7750	0.7391	0.6897	0.4647	0.7750
	Medium Neural Network	71	0.7500	0.7500	0.7101	0.6552	0.4052	0.7500
	Wide Neural Network	72.5	0.7692	0.7500	0.7246	0.6897	0.4378	0.7595
	Bilayered Neural Network	72.9	0.7424	0.8167	0.7295	0.6092	0.4373	0.7778
	Trilayered Neural Network	66.7	0.7073	0.7250	0.6667	0.5862	0.3128	0.7160
Naive Bayes	Gaussian Naive Bayes	69.1	0.8333	0.5833	0.6908	0.8391	0.4246	0.6863
	Kernel Naive Bayes	67.1	0.7955	0.5833	0.6715	0.7931	0.3759	0.6731
QDA	Quadratic Discriminant	68.6	0.8235	0.5833	0.6860	0.8276	0.4123	0.6829

ANOVA

Cross Validation

Πίνακας Σ.5 : Αποτελέσματα ταξινόμησης σε 2 κλάσεις με 14 χαρακτηριστικά με τη μέθοδο Cross Validation και εφαρμογή ANOVA

		%	PREC	REC	ACC	SPEC	MCC	F1
Trees	Fine Tree	68.7	0.7307	0.7289	0.6869	0.6289	0.3576	0.7298
	Medium Tree	73.3	0.7304	0.8557	0.7330	0.5636	0.4435	0.7881
	Coarse Tree	72.3	0.7293	0.8308	0.7229	0.5739	0.4219	0.7767
SVM	Linear SVM	74.7	0.7462	0.8557	0.7475	0.5979	0.4745	0.7972
	Quadratic SVM	74.2	0.7408	0.8532	0.7417	0.5876	0.4621	0.7931
	Cubic SVM	75	0.7772	0.7985	0.7504	0.6838	0.4851	0.7877
	Fine Gaussian SVM	74	0.7362	0.8607	0.7403	0.5739	0.4591	0.7936
	Medium Gaussian SVM	74.9	0.7426	0.8682	0.7489	0.5842	0.4779	0.8005
	Coarse Gaussian SVM	73.7	0.7391	0.8458	0.7374	0.5876	0.4528	0.7889
	Weighted KNN	73	0.7483	0.8060	0.7302	0.6254	0.4398	0.7760
KNN	Fine KNN	67.8	0.7254	0.7164	0.6782	0.6254	0.3411	0.7209
	Medium KNN	73.3	0.7333	0.8483	0.7330	0.5739	0.4434	0.7866
	Coarse KNN	72.3	0.7178	0.8607	0.7229	0.5326	0.4219	0.7828
	Cosine KNN	74.3	0.7534	0.8284	0.7431	0.6254	0.4660	0.7891
	Cubic KNN	72.6	0.7284	0.8408	0.7258	0.5670	0.4279	0.7806
	Weighted KNN	73	0.7483	0.8060	0.7302	0.6254	0.4398	0.7760
Ensemble	Boosted Trees	76.6	0.7620	0.8682	0.7662	0.6254	0.5146	0.8116
	Bagged Trees	74.6	0.7568	0.8284	0.7460	0.6323	0.4722	0.7910
	Subspace Discriminant	74.2	0.7528	0.8259	0.7417	0.6254	0.4630	0.7877
	Subspace KNN	70.3	0.7356	0.7612	0.7027	0.6220	0.3861	0.7482
	RUSBoosted Trees	74.7	0.7845	0.7786	0.7475	0.7045	0.4824	0.7815
Neural Networks	Narrow Neural Network	72.2	0.7646	0.7512	0.7215	0.6804	0.4303	0.7578
	Medium Neural Network	68.7	0.7262	0.7388	0.6869	0.6151	0.3552	0.7324
	Wide Neural Network	67.5	0.7174	0.7264	0.6753	0.6048	0.3320	0.7219
	Bilayered Neural Network	68	0.7296	0.7114	0.6797	0.6357	0.3457	0.7204
	Trilayered Neural Network	70	0.7389	0.7463	0.6999	0.6357	0.3828	0.7426
Naive Bayes	Gaussian Naive Bayes	70.7	0.7884	0.6766	0.7071	0.7491	0.4203	0.7282
	Kernel Naive Bayes	71	0.7410	0.7687	0.7100	0.6289	0.4008	0.7546
QDA	Quadratic Discriminant	70.3	0.7800	0.6791	0.7027	0.7354	0.4092	0.7261

Holdout Validation**Πίνακας Σ.6 :** Αποτελέσματα ταξινόμησης σε 2 κλάσεις με 14 χαρακτηριστικά με τη μέθοδο Holdout Validation και εφαρμογή ANOVA

		%	PREC	REC	ACC	SPEC	MCC	F1
Trees	Fine Tree	68.1	0.7328	0.7083	0.6812	0.6437	0.3501	0.7203
	Medium Tree	71.5	0.7163	0.8417	0.7150	0.5402	0.4045	0.7739
	Coarse Tree	71.5	0.8020	0.6750	0.7150	0.7701	0.4396	0.7330
SVM	Linear SVM	75.4	0.7634	0.8333	0.7536	0.6437	0.4885	0.7968
	Quadratic SVM	73.4	0.7372	0.8417	0.7343	0.5862	0.4464	0.7860
	Cubic SVM	69.6	0.7436	0.7250	0.6957	0.6552	0.3785	0.7342
	Fine Gaussian SVM	76.3	0.7752	0.8333	0.7633	0.6667	0.5093	0.8032

	Medium Gaussian SVM	74.9	0.7394	0.8750	0.7488	0.5747	0.4783	0.8015
	Coarse Gaussian SVM	77.3	0.7744	0.8583	0.7729	0.6552	0.5289	0.8142
KNN	Fine KNN	71.5	0.7607	0.7417	0.7150	0.6782	0.4180	0.7511
	Medium KNN	74.9	0.7537	0.8417	0.7488	0.6207	0.4777	0.7953
	Coarse KNN	72.9	0.7254	0.8583	0.7295	0.5517	0.4361	0.7863
	Cosine KNN	73.9	0.7578	0.8083	0.7391	0.6437	0.4593	0.7823
	Cubic KNN	75.4	0.7594	0.8417	0.7536	0.6322	0.4880	0.7984
	Weighted KNN	76.3	0.7983	0.7917	0.7633	0.7241	0.5150	0.7950
Ensemble	Boosted Trees	72.9	0.7581	0.7833	0.7295	0.6552	0.4416	0.7705
	Bagged Trees	78.7	0.8115	0.8250	0.7874	0.7356	0.5625	0.8182
	Subspace Discriminant	77.8	0.7984	0.8250	0.7778	0.7126	0.5415	0.8115
	Subspace KNN	70.5	0.7521	0.7333	0.7053	0.6667	0.3983	0.7426
	RUSBoosted Trees	76.8	0.8103	0.7833	0.7681	0.7471	0.5275	0.7966
Neural Networks	Narrow Neural Network	73.9	0.7895	0.7500	0.7391	0.7241	0.4705	0.7692
	Medium Neural Network	65.7	0.7025	0.7083	0.6570	0.5862	0.2950	0.7054
	Wide Neural Network	66.7	0.7179	0.7000	0.6667	0.6207	0.3193	0.7089
	Bilayered Neural Network	69.6	0.7664	0.6833	0.6957	0.7126	0.3911	0.7225
	Trilayered Neural Network	68.1	0.7596	0.6583	0.6812	0.7126	0.3662	0.7054
Naive Bayes	Gaussian Naive Bayes	72	0.8163	0.6667	0.7198	0.7931	0.4545	0.7339
	Kernel Naive Bayes	73.4	0.7778	0.7583	0.7343	0.7011	0.4575	0.7679
QDA	Quadratic Discriminant	72	0.8100	0.6750	0.7198	0.7816	0.4510	0.7364

Kruskal Wallis

Cross Validation

Πίνακας Σ.7 : Αποτελέσματα ταξινόμησης σε 2 κλάσεις με 15 χαρακτηριστικά με τη μέθοδο Cross Validation και εφαρμογή Kruskal Wallis

		%	PREC	REC	ACC	SPEC	MCC	F1
Trees	Fine Tree	69.3	0.7345	0.7363	0.6926	0.6323	0.3688	0.7354
	Medium Tree	72.3	0.7283	0.8333	0.7229	0.5704	0.4218	0.7773
	Coarse Tree	70.3	0.7279	0.7786	0.7027	0.5979	0.3830	0.7524
SVM	Linear SVM	74.9	0.7603	0.8284	0.7489	0.6392	0.4785	0.7929
	Quadratic SVM	75.3	0.7561	0.8483	0.7532	0.6220	0.4868	0.7995
	Cubic SVM	71.7	0.7488	0.7711	0.7172	0.6426	0.4164	0.7598
	Fine Gaussian SVM	74.7	0.7506	0.8458	0.7475	0.6117	0.4745	0.7953
	Medium Gaussian SVM	74.7	0.7551	0.8358	0.7475	0.6254	0.4749	0.7934
	Coarse Gaussian SVM	74.6	0.7457	0.8532	0.7460	0.5979	0.4714	0.7958
KNN	Fine KNN	69.4	0.7500	0.7090	0.6941	0.6735	0.3793	0.7289
	Medium KNN	74.3	0.7456	0.8458	0.7431	0.6014	0.4652	0.7925
	Coarse KNN	72.3	0.7225	0.8483	0.7229	0.5498	0.4216	0.7803
	Cosine KNN	75	0.7669	0.8184	0.7504	0.6564	0.4825	0.7918

	Cubic KNN	74.5	0.7506	0.8383	0.7446	0.6151	0.4685	0.7920
	Weighted KNN	74.7	0.7789	0.7886	0.7475	0.6907	0.4805	0.7837
Ensemble	Boosted Trees	75.3	0.7584	0.8433	0.7532	0.6289	0.4870	0.7986
	Bagged Trees	74	0.7534	0.8209	0.7403	0.6289	0.4603	0.7857
	Subspace Discriminant	74.7	0.7585	0.8284	0.7475	0.6357	0.4754	0.7919
	Subspace KNN	71	0.7481	0.7537	0.7100	0.6495	0.4038	0.7509
	RUSBoosted Trees	73.4	0.7646	0.7836	0.7345	0.6667	0.4526	0.7740
Neural Networks	Narrow Neural Network	71.6	0.7649	0.7363	0.7157	0.6873	0.4210	0.7503
	Medium Neural Network	66.7	0.7165	0.7040	0.6667	0.6151	0.3181	0.7102
	Wide Neural Network	69.6	0.7406	0.7313	0.6955	0.6460	0.3765	0.7359
	Bilayered Neural Network	73.3	0.7602	0.7886	0.7330	0.6564	0.4486	0.7741
	Trilayered Neural Network	70.4	0.7506	0.7338	0.7042	0.6632	0.3955	0.7421
Naive Bayes	Gaussian Naive Bayes	71.1	0.7902	0.6841	0.7114	0.7491	0.4276	0.7333
	Kernel Naive Bayes	73	0.7578	0.7861	0.7302	0.6529	0.4426	0.7717
QDA	Quadratic Discriminant	71.1	0.7902	0.6841	0.7114	0.7491	0.4276	0.7333

Holdout Validation

Πίνακας Σ.8 : Αποτελέσματα ταξινόμησης σε 2 κλάσεις με 15 χαρακτηριστικά με τη μέθοδο Holdout Validation και εφαρμογή Kruskal Wallis

		%	PREC	REC	ACC	SPEC	MCC	F1
Trees	Fine Tree	74.9	0.8036	0.7500	0.7488	0.7471	0.4924	0.7759
	Medium Tree	72	0.7541	0.7667	0.7198	0.6552	0.4233	0.7603
	Coarse Tree	71.5	0.7652	0.7333	0.7150	0.6897	0.4202	0.7489
SVM	Linear SVM	78.3	0.8000	0.8333	0.7826	0.7126	0.5510	0.8163
	Quadratic SVM	73.9	0.7895	0.7500	0.7391	0.7241	0.4705	0.7692
	Cubic SVM	71.5	0.7563	0.7500	0.7150	0.6667	0.4160	0.7531
	Fine Gaussian SVM	75.4	0.7594	0.8417	0.7536	0.6322	0.4880	0.7984
	Medium Gaussian SVM	77.3	0.7967	0.8167	0.7729	0.7126	0.5321	0.8066
	Coarse Gaussian SVM	72.5	0.7203	0.8583	0.7246	0.5402	0.4257	0.7833
KNN	Fine KNN	68.6	0.7523	0.6833	0.6860	0.6897	0.3687	0.7162
	Medium KNN	74.4	0.7519	0.8333	0.7440	0.6207	0.4676	0.7905
	Coarse KNN	70.5	0.7218	0.8000	0.7053	0.5747	0.3859	0.7589
	Cosine KNN	74.9	0.7698	0.8083	0.7488	0.6667	0.4804	0.7886
	Cubic KNN	74.9	0.7500	0.8500	0.7488	0.6092	0.4775	0.7969
	Weighted KNN	72.9	0.7581	0.7833	0.7295	0.6552	0.4416	0.7705
Ensemble	Boosted Trees	76.3	0.7886	0.8083	0.7633	0.7011	0.5121	0.7984
	Bagged Trees	73.9	0.7619	0.8000	0.7391	0.6552	0.4604	0.7805
	Subspace Discriminant	75.8	0.7778	0.8167	0.7585	0.6782	0.5005	0.7967
	Subspace KNN	72	0.7627	0.7500	0.7198	0.6782	0.4269	0.7563
	RUSBoosted Trees	72.9	0.7857	0.7333	0.7295	0.7241	0.4532	0.7586
Neural Networks	Narrow Neural Network	69.1	0.7500	0.7000	0.6908	0.6782	0.3746	0.7241
	Medium Neural Network	69.6	0.7568	0.7000	0.6957	0.6897	0.3857	0.7273

	Wide Neural Network	67.1	0.7281	0.6917	0.6715	0.6437	0.3328	0.7094
	Bilayered Neural Network	72.5	0.7442	0.8000	0.7246	0.6207	0.4285	0.7711
	Trilayered Neural Network	79.2	0.8031	0.8500	0.7923	0.7126	0.5703	0.8259
Naive Bayes	Gaussian Naive Bayes	71	0.7885	0.6833	0.7101	0.7471	0.4250	0.7321
	Kernel Naive Bayes	70.5	0.7398	0.7583	0.7053	0.6322	0.3926	0.7490
QDA	Quadratic Discriminant	71	0.7885	0.6833	0.7101	0.7471	0.4250	0.7321

Ταξινόμηση δεδομένων σε τρεις κλάσεις με τρία χαρακτηριστικά

Cross Validation

Πίνακας Σ.9 : Αποτελέσματα ταξινόμησης σε 3 κλάσεις με 3 χαρακτηριστικά με τη μέθοδο Cross Validation

		Class	%	PREC	REC	ACC	SPEC	MCC	F1
Trees	Fine Tree	Control	60.1	0.7198	0.7413	0.6765	0.5827	0.3264	0.7304
		Bipolar II		0.333	0.3474	0.8118	0.8872	0.2306	0.3402
		Unipolar Depressive		0.4671	0.4262	0.7147	0.8209	0.2547	0.4457
	Medium Tree	Control	65.4	0.7093	0.8682	0.7118	0.4856	0.3889	0.7808
		Bipolar II		0.5349	0.2421	0.8647	0.9658	0.2962	0.333
		Unipolar Depressive		0.5034	0.3989	0.7324	0.8551	0.2751	0.4451
	Coarse Tree	Control	64.3	0.6805	0.8955	0.6897	0.3921	0.3402	0.7734
		Bipolar II		0.5	0.1263	0.8603	0.9795	0.1988	0.2017
		Unipolar Depressive		0.5118	0.3552	0.7353	0.8753	0.2622	0.4194
SVM	Linear SVM	Control	65.6	0.669	0.9552	0.6941	0.3165	0.3683	0.7869
		Bipolar II		-	0	0.8603	1	-	-
		Unipolar Depressive		0.5849	0.3388	0.7574	0.9115	0.306	0.4291
	Quadratic SVM	Control	65.7	0.675	0.9353	0.6956	0.3489	0.363	0.7842
		Bipolar II		0.5	0.0842	0.8603	0.9863	0.1613	0.1441
		Unipolar Depressive		0.5888	0.3443	0.7588	0.9115	0.3115	0.4345
	Cubic SVM	Control	41.5	0.6255	0.4279	0.5103	0.6295	0.0575	0.5081
		Bipolar II		0.2542	0.1579	0.8176	0.9248	0.1018	0.1948
		Unipolar Depressive		0.2746	0.5191	0.5015	0.495	0.0125	0.3592
	Fine Gaussian SVM	Control	68.7	0.7096	0.9055	0.725	0.464	0.422	0.7956
		Bipolar II		0.7308	0.2	0.8779	0.988	0.3399	0.314
		Unipolar Depressive		0.5957	0.459	0.7706	0.8853	0.3767	0.5185
	Medium Gaussian SVM	Control	65.9	0.6846	0.9179	0.7015	0.3885	0.3716	0.7843
		Bipolar II		0.8	0.0842	0.8691	0.9966	0.2327	0.1524
		Unipolar Depressive		0.542	0.388	0.7471	0.8793	0.3005	0.4522
	Coarse Gaussian SVM	Control	64.9	0.6592	0.9577	0.6824	0.2842	0.3415	0.7809
		Bipolar II		-	0	0.8603	1	-	-
		Unipolar Depressive		0.5833	0.306	0.7544	0.9195	0.2873	0.4014
KNN	Fine KNN	Control	60.1	0.7366	0.7164	0.6809	0.6295	0.344	0.7264
		Bipolar II		0.3486	0.4	0.8118	0.8786	0.2633	0.3725
		Unipolar Depressive		0.4611	0.4536	0.7103	0.8048	0.2597	0.4573
	Medium KNN	Control	68.7	0.7304	0.903	0.7418	0.5	0.4511	0.8076
		Bipolar II		0.575	0.2421	0.8672	0.9704	0.3129	0.3407
		Unipolar Depressive		0.609	0.4682	0.7851	0.8954	0.3989	0.5294
	Coarse KNN	Control	65.9	0.6882	0.9279	0.7088	0.3921	0.3911	0.7903
		Bipolar II		-	0	0.8603	1	-	-

	Cosine KNN	Unipolar Depressive	63.2	0.5435	0.4098	0.7485	0.8732	0.3122	0.4673
		Control		0.6955	0.8408	0.6882	0.4676	0.3358	0.7613
		Bipolar II		0.3448	0.2105	0.8338	0.935	0.1807	0.2614
	Cubic KNN	Unipolar Depressive	69	0.5294	0.3934	0.7426	0.8712	0.2935	0.4514
		Control		0.7179	0.9055	0.7338	0.4856	0.4414	0.8009
		Bipolar II		0.575	0.2421	0.8691	0.9709	0.3139	0.3407
	Weighted KNN	Unipolar Depressive	67.9	0.6165	0.4481	0.7765	0.8974	0.3863	0.519
		Control		0.7562	0.8408	0.7456	0.6079	0.4648	0.7962
		Bipolar II		0.4512	0.3895	0.8485	0.9231	0.3327	0.4181
	Ensemble	Boosted Trees	Unipolar Depressive	66.2	0.5762	0.4754	0.7647	0.8712	0.3699
Control			0.7246		0.8507	0.7206	0.5324	0.4088	0.7826
Bipolar II			0.55		0.2316	0.8662	0.9692	0.2959	0.3259
Bagged Trees		Unipolar Depressive	64.4	0.4938	0.4372	0.7279	0.835	0.2833	0.4638
		Control		0.7345	0.8259	0.7206	0.5683	0.4105	0.7775
		Bipolar II		0.3939	0.2737	0.8397	0.9316	0.2404	0.323
Subspace Discriminant		Unipolar Depressive	66.6	0.5606	0.4044	0.7544	0.8833	0.3226	0.4698
		Control		0.6924	0.9353	0.7162	0.3993	0.4101	0.7958
		Bipolar II		0.6	0.0316	0.8618	0.9966	0.1143	0.06
Subspace KNN		Unipolar Depressive	63.1	0.7143	0.8209	0.7	0.5252	0.3645	0.7639
		Control		0.3429	0.2526	0.8279	0.9214	0.1985	0.2909
		Bipolar II		0.5068	0.4098	0.7338	0.8531	0.2826	0.4532
RUSBoosted Trees	Unipolar Depressive	60.1	0.8018	0.6741	0.7088	0.759	0.4259	0.7324	
	Control		0.3099	0.4632	0.7809	0.8325	0.2522	0.3713	
	Bipolar II		0.47	0.5137	0.7132	0.7867	0.2924	0.4909	
Neural Networks	Narrow Neural Network	Unipolar Depressive	65.7	0.7114	0.8706	0.7147	0.4892	0.3956	0.783
		Control		0.4615	0.2526	0.8544	0.9521	0.2671	0.3265
		Bipolar II		0.5368	0.3989	0.7456	0.8732	0.3017	0.4577
	Medium Neural Network	Unipolar Depressive	65	0.7122	0.8308	0.7015	0.5144	0.3669	0.7669
		Control		0.4833	0.3053	0.8574	0.947	0.3083	0.3742
		Bipolar II		0.5232	0.4317	0.7412	0.8551	0.3061	0.4731
	Wide Neural Network	Unipolar Depressive	62.5	0.7426	0.7463	0.6971	0.6259	0.3726	0.7444
		Control		0.4157	0.3895	0.8382	0.9111	0.309	0.4022
		Bipolar II		0.4706	0.4809	0.7147	0.8008	0.2798	0.4757
	Bilayered Neural Network	Unipolar Depressive	64	0.7187	0.8134	0.7015	0.5396	0.3688	0.7631
		Control		0.4444	0.2526	0.8515	0.9487	0.2582	0.3221
		Bipolar II		0.4912	0.459	0.7265	0.8249	0.2903	0.4746
Trilayered Neural Network	Unipolar Depressive	64.3	0.7231	0.8184	0.7074	0.5468	0.3815	0.7678	
	Control		0.4154	0.2842	0.8441	0.935	0.2585	0.3375	
	Bipolar II		0.5062	0.4426	0.7338	0.841	0.2966	0.4723	
Naive Bayes	Gaussian Naive Bayes	Unipolar Depressive	64.6	0.7449	0.8134	0.725	0.5971	0.422	0.7776
		Control		0.3333	0.1263	0.8426	0.959	0.1321	0.1832
		Bipolar II		0.4878	0.5464	0.7235	0.7887	0.3239	0.5155
	Kernel Naive Bayes	Unipolar Depressive	65.7	0.7222	0.8731	0.7265	0.5144	0.4219	0.7905
		Control		0.4286	0.0316	0.8588	0.9932	0.085	0.0588
		Bipolar II		0.4973	0.5082	0.7294	0.8109	0.3169	0.5027
QDA	Quadratic Discriminant	Unipolar Depressive	64.3	0.7477	0.796	0.7206	0.6115	0.4148	0.7711
		Control		0.3333	0.1895	0.8338	0.9385	0.164	0.2416
		Bipolar II		0.5	0.541	0.7309	0.8008	0.3337	0.5197

Holdout Validation

Πίνακας Σ.10 : Αποτελέσματα ταξινόμησης σε 3 κλάσεις με 3 χαρακτηριστικά με τη μέθοδο Holdout Validation

		Class	%	PREC	REC	ACC	SPEC	MCC	F1
Trees	Fine Tree	Control	56.4	0.6714	0.7833	0.6471	0.4524	0.25	0.7231
		Bipolar II		0.2632	0.1724	0.8137	0.92	0.111	0.2083
		Unipolar Depressive		0.3556	0.2909	0.6667	0.8054	0.103	0.32
	Medium Tree	Control	60.8	0.6757	0.8333	0.6667	0.4286	0.2888	0.7463
		Bipolar II		0.4	0.1379	0.848	0.9657	0.1676	0.2051
		Unipolar Depressive		0.4348	0.3636	0.701	0.8255	0.2008	0.396
	Coarse Tree	Control	60.3	0.6196	0.95	0.6275	0.1667	0.1931	0.75
		Bipolar II		0.6667	0.069	0.8627	0.9943	0.1835	0.125
		Unipolar Depressive		0.4118	0.1273	0.7157	0.9329	0.0966	0.1944
SVM	Linear SVM	Control	61.8	0.6384	0.9417	0.652	0.2381	0.2611	0.7609
		Bipolar II		-	0	0.8578	1	-	-
		Unipolar Depressive		0.4815	0.2364	0.7255	0.906	0.1865	0.3171
	Quadratic SVM	Control	63.2	0.6588	0.9333	0.6765	0.3095	0.3207	0.7724
		Bipolar II		0.5	0.069	0.8578	0.9886	0.1449	0.1212
		Unipolar Depressive		0.5	0.2727	0.7304	0.8993	0.2156	0.3529
	Cubic SVM	Control	37.3	0.5093	0.4583	0.4216	0.369	-0.1702	0.4825
		Bipolar II		0.5	0.1034	0.8578	0.9829	0.1784	0.1714
		Unipolar Depressive		0.2	0.3273	0.4657	0.5168	-0.1394	0.2483
	Fine Gaussian SVM	Control	62.7	0.6774	0.875	0.6814	0.4048	0.3223	0.7636
		Bipolar II		0.2857	0.069	0.8431	0.9714	0.0775	0.1111
		Unipolar Depressive		0.5	0.3818	0.7304	0.8591	0.2644	0.433
	Medium Gaussian SVM	Control	64.2	0.6607	0.925	0.6765	0.3214	0.3181	0.7708
		Bipolar II		0.6	0.1034	0.8627	0.9886	0.2078	0.1765
		Unipolar Depressive		0.5484	0.3091	0.7451	0.906	0.2659	0.3953
Coarse Gaussian SVM	Control	63.2	0.6477	0.95	0.6667	0.2619	0.3031	0.7703	
	Bipolar II		-	0	0.8578	1	-	-	
	Unipolar Depressive		0.5357	0.2727	0.7402	0.9128	0.2392	0.3614	
KNN	Fine KNN	Control	59.8	0.7281	0.6917	0.6667	0.631	0.3198	0.7094
		Bipolar II		0.3793	0.3793	0.8235	0.8971	0.2765	0.3793
		Unipolar Depressive		0.459	0.5091	0.7059	0.7785	0.2788	0.4828
	Medium KNN	Control	64.2	0.6908	0.875	0.6961	0.4405	0.3563	0.7721
		Bipolar II		0.5	0.2069	0.8578	0.9657	0.2562	0.2927
		Unipolar Depressive		0.5	0.3636	0.7304	0.8658	0.2564	0.4211
	Coarse KNN	Control	63.7	0.6514	0.95	0.6716	0.2738	0.3154	0.7729
		Bipolar II		-	0	0.8578	1	-	-
		Unipolar Depressive		0.5517	0.2909	0.7451	0.9128	0.2588	0.381
	Cosine KNN	Control	60.3	0.6667	0.8333	0.6569	0.4048	0.2656	0.7407
		Bipolar II		0.3333	0.1379	0.8382	0.9543	0.1369	0.1951
		Unipolar Depressive		0.4524	0.3455	0.7108	0.8456	0.2097	0.3918
	Cubic KNN	Control	63.2	0.6842	0.8667	0.6863	0.4286	0.3334	0.7647
		Bipolar II		0.5556	0.1724	0.8627	0.9771	0.2543	0.2632
		Unipolar Depressive		0.4651	0.3636	0.7157	0.8456	0.2277	0.4082
Weighted KNN	Control	65.7	0.7266	0.8417	0.7206	0.5476	0.4112	0.7799	
	Bipolar II		0.4286	0.3103	0.8431	0.9314	0.2778	0.36	
	Unipolar Depressive		0.5455	0.4364	0.75	0.8658	0.326	0.4848	
Ensemble	Boosted Trees	Control	58.3	0.6667	0.8333	0.6569	0.4048	0.2656	0.7407
		Bipolar II		0.1429	0.0345	0.8333	0.9657	0.0004	0.0556
		Unipolar Depressive		0.383	0.3273	0.6765	0.8054	0.1398	0.3529
	Bagged	Control	61.8	0.7293	0.8083	0.7108	0.5714	0.3924	0.7668
Bipolar II		0.3333		0.2414	0.8235	0.92	0.1855	0.28	

	Trees	Unipolar Depressive		0.44	0.4	0.701	0.8121	0.2188	0.419	
	Subspace Discriminant	Control	65.7	0.6832	0.9167	0.701	0.3929	0.3735	0.7829	
		Bipolar II		0.5	0.069	0.8578	0.9886	0.1449	0.1212	
		Unipolar Depressive		0.5641	0.4	0.7549	0.8859	0.3226	0.4681	
	Subspace KNN	Control	58.3	0.7258	0.75	0.6863	0.5952	0.348	0.7377	
		Bipolar II		0.2333	0.2414	0.7794	0.8686	0.1084	0.2373	
		Unipolar Depressive		0.44	0.4	0.701	0.8121	0.2188	0.419	
	RUSBoosted Trees	Control	58.3	0.837	0.6417	0.7157	0.8214	0.458	0.7264	
		Bipolar II		0.2245	0.3793	0.7255	0.7829	0.1326	0.2821	
		Unipolar Depressive		0.4921	0.5636	0.7255	0.7852	0.3351	0.5254	
	Neural Networks	Narrow Neural Network	Control	66.2	0.7114	0.8833	0.7206	0.4881	0.4119	0.7881
			Bipolar II		0.3636	0.1379	0.8431	0.96	0.1514	0.2
Unipolar Depressive			0.5682		0.4545	0.7598	0.8725	0.3528	0.5051	
Medium Neural Network		Control	62.7	0.7344	0.7833	0.7059	0.5952	0.3854	0.7581	
		Bipolar II		0.4737	0.3103	0.8529	0.9429	0.3042	0.375	
		Unipolar Depressive		0.4386	0.4545	0.6961	0.7852	0.2371	0.4464	
Wide Neural Network		Control	55.9	0.6777	0.6833	0.6225	0.5357	0.2195	0.6805	
		Bipolar II		0.32	0.2759	0.8137	0.9029	0.1903	0.2963	
		Unipolar Depressive		0.4138	0.4364	0.6814	0.7718	0.2048	0.4248	
Bilayered Neural Network		Control	64.2	0.7153	0.8583	0.7157	0.5119	0.3999	0.7803	
		Bipolar II		0.25	0.1724	0.8088	0.9143	0.1018	0.2041	
		Unipolar Depressive		0.575	0.4182	0.7598	0.8859	0.3399	0.4842	
Trilayered Neural Network	Control	66.7	0.7752	0.8333	0.7598	0.6548	0.4982	0.8032		
	Bipolar II		0.4091	0.3103	0.8382	0.9257	0.2658	0.3529		
	Unipolar Depressive		0.5094	0.4909	0.7353	0.8255	0.3202	0.5		
Naive Bayes	Gaussian Naive Bayes	Control	59.8	0.72	0.75	0.6814	0.5833	0.3368	0.7347	
		Bipolar II		0.1818	0.069	0.8235	0.9486	0.0271	0.1	
		Unipolar Depressive		0.4412	0.5455	0.6912	0.745	0.2734	0.4878	
	Kernel Naive Bayes	Control	64.2	0.7113	0.8417	0.7059	0.5119	0.3783	0.771	
		Bipolar II		0.4	0.069	0.8529	0.9829	0.117	0.1176	
		Unipolar Depressive		0.4912	0.5091	0.7255	0.8054	0.311	0.5	
QDA	Quadratic Discriminant	Control	63.2	0.7308	0.7917	0.7059	0.5833	0.3839	0.76	
		Bipolar II		0.2667	0.1379	0.8235	0.9371	0.1004	0.1818	
		Unipolar Depressive		0.5085	0.5455	0.7353	0.8054	0.3434	0.5263	

Ταξινόμηση δεδομένων σε τρεις κλάσεις με δεκαεπτά χαρακτηριστικά

Cross Validation

Πίνακας Σ.11 : Αποτελέσματα ταξινόμησης σε 3 κλάσεις με 17 χαρακτηριστικά με τη μέθοδο Cross Validation

		Class	ACC	PREC	REC	ACC	SPEC	MCC	F1
Trees	Fine Tree	Control	58.8	0.7233	0.7413	0.6794	0.5899	0.3332	0.7322
		Bipolar II		0.325	0.2737	0.8191	0.9077	0.1952	0.2971
		Unipolar Depressive		0.4043	0.4153	0.6779	0.7746	0.1884	0.4097
	Medium Tree	Control	65.3	0.7329	0.8532	0.7294	0.5504	0.4283	0.7885
		Bipolar II		0.4630	0.2632	0.8544	0.9504	0.2739	0.3356
		Unipolar Depressive		0.4810	0.4153	0.7221	0.8350	0.2629	0.4457
	Coarse Tree	Control	65.7	0.6944	0.9328	0.7176	0.4065	0.4125	0.7962
		Bipolar II		0.4615	0.0632	0.8588	0.9880	0.1296	0.1111
		Unipolar Depressive		0.5197	0.3607	0.7382	0.8773	0.2708	0.4258
SVM	Linear SVM	Control	66.2	0.7084	0.9005	0.7221	0.4640	0.4147	0.7930
		Bipolar II		0.4865	0.1895	0.8588	0.9675	0.2399	0.2727
		Unipolar Depressive		0.5303	0.3825	0.7426	0.8753	0.2890	0.4444
	Quadratic SVM	Control	67.2	0.7191	0.8980	0.7324	0.4928	0.4371	0.7987
		Bipolar II		0.5179	0.3053	0.8632	0.9538	0.3268	0.3841
		Unipolar Depressive		0.5492	0.3661	0.7485	0.8893	0.2953	0.4393
	Cubic SVM	Control	62.9	0.7215	0.7861	0.6941	0.5612	0.3565	0.7524
		Bipolar II		0.4324	0.3368	0.8456	0.9282	0.2951	0.3787
		Unipolar Depressive		0.4762	0.4372	0.7191	0.8229	0.2675	0.4558
	Fine Gaussian SVM	Control	66.8	0.6955	0.9204	0.7147	0.4173	0.4023	0.7923
		Bipolar II		0.7222	0.1368	0.8721	0.9915	0.2771	0.2301
		Unipolar Depressive		0.5462	0.3880	0.7485	0.8813	0.3037	0.4537
	Medium Gaussian SVM	Control	66.8	0.7140	0.9129	0.7324	0.4712	0.4397	0.8013
		Bipolar II		0.6154	0.1684	0.8691	0.9829	0.2736	0.2645
		Unipolar Depressive		0.5071	0.3880	0.7338	0.8612	0.2733	0.4396
	Coarse Gaussian SVM	Control	63.4	0.6574	0.9453	0.6765	0.2878	0.3209	0.7755
		Bipolar II		-	0	0.8603	1	-	-
		Unipolar Depressive		0.5000	0.2787	0.7309	0.8974	0.2187	0.3579
KNN	Fine KNN	Control	58.7	0.7308	0.7090	0.6735	0.6223	0.3293	0.7197
		Bipolar II		0.3578	0.4105	0.8147	0.8803	0.2749	0.3824
		Unipolar Depressive		0.4144	0.4098	0.6853	0.7867	0.1972	0.4121
	Medium KNN	Control	65.6	0.7169	0.8881	0.7265	0.4928	0.4229	0.7933
		Bipolar II		0.3889	0.2211	0.8426	0.9436	0.2111	0.2819
		Unipolar Depressive		0.5312	0.3716	0.7426	0.8793	0.2846	0.4373
	Coarse KNN	Control	64.3	0.6702	0.9403	0.6916	0.3333	0.3567	0.7826
		Bipolar II		1	0.0105	0.8620	1	0.0952	0.0208
		Unipolar Depressive		0.5086	0.3207	0.7327	0.8853	0.2433	0.3933
	Cosine KNN	Control	67.8	0.7400	0.8706	0.7426	0.5576	0.4575	0.8000
		Bipolar II		0.4918	0.3158	0.8588	0.9470	0.3188	0.3846
		Unipolar Depressive		0.5548	0.4426	0.7544	0.8692	0.3368	0.4924
	Cubic KNN	Control	65.3	0.7134	0.8856	0.7221	0.4856	0.4129	0.7902
		Bipolar II		0.4200	0.2211	0.8485	0.9504	0.2278	0.2897
		Unipolar Depressive		0.5115	0.3661	0.7353	0.8712	0.2669	0.4268
	Weighted KNN	Control	66.3	0.7304	0.8557	0.7279	0.5432	0.4250	0.7881
		Bipolar II		0.4677	0.3053	0.8544	0.9436	0.2997	0.3694
		Unipolar Depressive		0.5306	0.4262	0.7441	0.8612	0.3096	0.4727
Ensemble	Boosted Trees	Control	68.1	0.7249	0.8980	0.7382	0.5072	0.4499	0.8022
		Bipolar II		0.5946	0.2316	0.8706	0.9744	0.3148	0.3333
		Unipolar Depressive		0.5517	0.4372	0.7529	0.8692	0.3317	0.4878
	Bagged Trees	Control	67.2	0.7332	0.8682	0.7353	0.5432	0.4413	0.7950
		Bipolar II		0.5000	0.2947	0.8603	0.9521	0.3113	0.3709
		Unipolar Depressive		0.5405	0.4372	0.7485	0.8632	0.3228	0.4834
	Subspace Discriminant	Control	67.9	0.7154	0.9129	0.7338	0.4748	0.4429	0.8022
		Bipolar II		0.5000	0.1684	0.8603	0.9726	0.2309	0.2520
		Unipolar Depressive		0.5852	0.4317	0.7647	0.8873	0.3547	0.4969
	Subspace KNN	Control	62.6	0.7335	0.7736	0.7000	0.5935	0.3725	0.7530
		Bipolar II		0.4023	0.3684	0.8353	0.9111	0.2901	0.3846
		Unipolar Depressive		0.4734	0.4372	0.7176	0.8209	0.2649	0.4545
RUSBoost	Control	59.1	0.7861	0.6493	0.6882	0.7446	0.3874	0.7112	
	Bipolar II		0.3308	0.4632	0.7941	0.8479	0.2718	0.3860	

	ed Trees	Unipolar Depressive		0.4512	0.5301	0.7000	0.7626	0.2791	0.4874
Neural Networks	Narrow Neural Network	Control	64.1	0.7454	0.8010	0.7206	0.6043	0.4140	0.7722
		Bipolar II		0.4247	0.3263	0.8441	0.9282	0.2850	0.3690
		Unipolar Depressive		0.4743	0.4536	0.7176	0.8149	0.2723	0.4637
	Medium Neural Network	Control	62.6	0.7494	0.7512	0.7044	0.6367	0.3882	0.7503
		Bipolar II		0.4175	0.4526	0.8353	0.8974	0.3385	0.4343
		Unipolar Depressive		0.4655	0.4426	0.7132	0.8129	0.2597	0.4538
	Wide Neural Network	Control	56.6	0.7168	0.6990	0.6588	0.6007	0.2982	0.7078
		Bipolar II		0.3267	0.3474	0.8088	0.8838	0.2253	0.3367
		Unipolar Depressive		0.3797	0.3880	0.6647	0.7666	0.1535	0.3838
	Bilayered Neural Network	Control	61.8	0.7327	0.7637	0.6956	0.5971	0.3647	0.7479
		Bipolar II		0.4062	0.4105	0.8338	0.9026	0.3117	0.4084
		Unipolar Depressive		0.4485	0.4044	0.7059	0.8169	0.2289	0.4253
Trilayered Neural Network	Control	61.6	0.7243	0.7711	0.6912	0.5755	0.3529	0.7470	
	Bipolar II		0.3750	0.3474	0.8279	0.9060	0.2617	0.3607	
	Unipolar Depressive		0.4634	0.4153	0.7132	0.8229	0.2470	0.4380	
Naive Bayes	Gaussian Naive Bayes	Control	52.2	0.8081	0.5970	0.6779	0.7950	0.3885	0.6867
		Bipolar II		0.2182	0.6316	0.6324	0.6325	0.1865	0.3243
		Unipolar Depressive		0.5093	0.3005	0.7338	0.8934	0.2353	0.3780
	Kernel Naive Bayes	Control	52.9	0.7762	0.6642	0.6882	0.7230	0.3807	0.7158
		Bipolar II		0.2169	0.6211	0.6338	0.6359	0.1818	0.3215
		Unipolar Depressive		0.5312	0.1858	0.7368	0.9396	0.1905	0.2753
QDA	Quadratic Discriminant	Control	51.8	0.7980	0.5995	0.6735	0.7806	0.3761	0.6847
		Bipolar II		0.2182	0.6316	0.6324	0.6325	0.1865	0.3243
		Unipolar Depressive		0.4951	0.2787	0.7294	0.8954	0.2153	0.3566

Holdout Validation

Πίνακας Σ.12 : Αποτελέσματα ταξινόμησης σε 3 κλάσεις με 17 χαρακτηριστικά με τη μέθοδο Holdout Validation

		Class	%	PREC	REC	ACC	SPEC	MCC	F1
Trees	Fine Tree	Control	57.8	0.6923	0.7500	0.6569	0.5238	0.2803	0.7200
		Bipolar II		0.2500	0.1379	0.8186	0.9314	0.0901	0.1778
		Unipolar Depressive		0.4138	0.4364	0.6814	0.7718	0.2048	0.4248
	Medium Tree	Control	63.7	0.7234	0.8500	0.7206	0.5357	0.4109	0.7816
		Bipolar II		0.3333	0.1034	0.8431	0.9657	0.1176	0.1579
		Unipolar Depressive		0.4630	0.4545	0.7108	0.8054	0.2614	0.4587
	Coarse Tree	Control	62.3	0.7273	0.8000	0.7059	0.5714	0.3825	0.7619
		Bipolar II		0.4286	0.1034	0.8529	0.9771	0.1546	0.1667
		Unipolar Depressive		0.4308	0.5091	0.6863	0.7517	0.2484	0.4667
SVM	Linear SVM	Control	63.7	0.6647	0.9417	0.6863	0.3214	0.3474	0.7793
		Bipolar II		0.6667	0.0690	0.8627	0.9943	0.1835	0.1250
		Unipolar Depressive		0.4839	0.2727	0.7255	0.8926	0.2044	0.3488
	Quadratic SVM	Control	64.7	0.6954	0.8750	0.7010	0.4524	0.3674	0.7749
		Bipolar II		0.7143	0.1724	0.8725	0.9886	0.3088	0.2778
		Unipolar Depressive		0.4783	0.4000	0.7206	0.8389	0.2537	0.4356
	Cubic SVM	Control	62.3	0.7063	0.8417	0.7010	0.5000	0.3673	0.7681
		Bipolar II		0.3529	0.2069	0.8333	0.9371	0.1820	0.2609
		Unipolar Depressive		0.4545	0.3636	0.7108	0.8389	0.2185	0.4040
	Fine Gaussian	Control	62.7	0.6667	0.9167	0.6814	0.3452	0.3278	0.7719

Χρήση Αλγορίθμων Μηχανικής Μάθησης για την ταξινόμηση καταθλιπτικών καταστάσεων

	SVM	Bipolar II	64.7	0.7500	0.1034	0.8676	0.9943	0.2462	0.1818	
		Unipolar Depressive		0.4286	0.2727	0.7059	0.8658	0.1630	0.3333	
	Medium Gaussian SVM	Bipolar II		0.6894	0.9250	0.7108	0.4048	0.3979	0.7900	
		Unipolar Depressive		0.3333	0.0690	0.8480	0.9771	0.0953	0.1143	
	Coarse Gaussian SVM	Control		61.3	0.5135	0.3455	0.7353	0.8792	0.2587	0.4130
		Bipolar II			0.6333	0.9500	0.6471	0.2143	0.2510	0.7600
KNN	Fine KNN	Control	62.3	-	0	0.8578	1	-	-	
		Bipolar II		0.4583	0.2000	0.7206	0.9128	0.1553	0.2785	
		Unipolar Depressive		0.7583	0.7583	0.7157	0.6548	0.4131	0.7583	
	Medium KNN	Bipolar II	64.7	0.4194	0.4483	0.8333	0.8971	0.3360	0.4333	
		Unipolar Depressive		0.4340	0.4182	0.6961	0.7987	0.2194	0.4259	
		Control		0.7086	0.8917	0.7206	0.4762	0.4128	0.7897	
	Coarse KNN	Bipolar II	62.7	0.4000	0.2069	0.8431	0.9486	0.2080	0.2727	
		Unipolar Depressive		0.5000	0.3455	0.7304	0.8725	0.2484	0.4086	
		Control		0.6497	0.9583	0.6716	0.2619	0.3199	0.7744	
	Cosine KNN	Bipolar II	66.7	-	0	0.8578	1	-	-	
		Unipolar Depressive		0.4815	0.2364	0.7255	0.9060	0.1865	0.3171	
		Control		0.7329	0.8917	0.7451	0.5357	0.4663	0.8045	
	Cubic KNN	Bipolar II	64.2	0.4706	0.2759	0.8529	0.9486	0.2836	0.3478	
		Unipolar Depressive		0.5122	0.3818	0.7353	0.8658	0.2742	0.4375	
		Control		0.7032	0.9083	0.7206	0.4524	0.4156	0.7927	
	Weighted KNN	Bipolar II	67.6	0.3571	0.1724	0.8382	0.9486	0.1671	0.2326	
		Unipolar Depressive		0.4857	0.3091	0.7255	0.8792	0.2216	0.3778	
		Control		0.7647	0.8667	0.7647	0.6190	0.5071	0.8125	
Ensemble	Boosted Trees	Bipolar II	62.7	0.4444	0.2759	0.8480	0.9429	0.2693	0.3404	
		Unipolar Depressive		0.5200	0.4727	0.7402	0.8389	0.3215	0.4952	
		Control		0.7047	0.8750	0.7108	0.4762	0.3895	0.7807	
	Bagged Trees	Bipolar II	66.7	0.2500	0.0690	0.8382	0.9657	0.0624	0.1081	
		Unipolar Depressive		0.4468	0.3818	0.7059	0.8255	0.2185	0.4118	
		Control		0.7536	0.8667	0.7549	0.5952	0.4859	0.8062	
	Subspace Discriminant	Bipolar II	65.2	0.3333	0.1379	0.8382	0.9543	0.1369	0.1951	
		Unipolar Depressive		0.5185	0.5091	0.7402	0.8255	0.3366	0.5138	
		Control		0.6855	0.9083	0.7010	0.4048	0.3716	0.7814	
	Subspace KNN	Bipolar II	64.2	0.4000	0.1379	0.8480	0.9657	0.1676	0.2051	
		Unipolar Depressive		0.5714	0.3636	0.7549	0.8993	0.3095	0.4444	
		Control		0.7581	0.7833	0.7255	0.6429	0.4296	0.7705	
	RUSBoosted Trees	Bipolar II	57.4	0.4444	0.4138	0.8431	0.9143	0.3381	0.4286	
		Unipolar Depressive		0.4717	0.4545	0.7157	0.8121	0.2698	0.4630	
		Control		0.7835	0.6333	0.6814	0.7500	0.3778	0.7005	
	Neural Networks	Narrow Neural Network	Bipolar II	65.2	0.3261	0.5172	0.7794	0.8229	0.2842	0.4000
			Unipolar Depressive		0.4262	0.4727	0.6863	0.7651	0.2305	0.4483
			Control		0.7661	0.7917	0.7353	0.6548	0.4500	0.7787
Medium Neural Network		Bipolar II	56.9	0.4286	0.2069	0.8480	0.9543	0.2226	0.2791	
		Unipolar Depressive		0.4848	0.5818	0.7206	0.7718	0.3354	0.5289	
		Control		0.7551	0.6167	0.6569	0.7143	0.3260	0.6789	
Wide Neural Network		Bipolar II	57.4	0.3333	0.3448	0.8088	0.8857	0.2273	0.3390	
		Unipolar Depressive		0.4211	0.5818	0.6716	0.7047	0.2630	0.4885	
		Control		0.7107	0.7167	0.6618	0.5833	0.3006	0.7137	
Bilayered		Bipolar II	56.9	0.4167	0.3448	0.8382	0.9200	0.2870	0.3774	
		Unipolar Depressive		0.3559	0.3818	0.6471	0.7450	0.1241	0.3684	
			Control		0.6875	0.7333	0.6471	0.5238	0.2618	0.7097
		Bipolar II		0.3333	0.2414	0.8235	0.9200	0.1855	0.2800	

	Neural Network	Unipolar Depressive		0.3818	0.3818	0.6667	0.7718	0.1536	0.3818
	Trilayered Neural Network	Control	59.8	0.7323	0.7750	0.7010	0.5952	0.3759	0.7530
		Bipolar II		0.3478	0.2759	0.8235	0.9143	0.2099	0.3077
Unipolar Depressive	0.3889	0.3818		0.6716	0.7785	0.1613	0.3853		
Naive Bayes	Gaussian Naive Bayes	Control	55.9	0.7810	0.6833	0.7010	0.7262	0.4033	0.7289
		Bipolar II		0.2444	0.3793	0.7451	0.8057	0.1558	0.2973
		Unipolar Depressive		0.3889	0.3818	0.6716	0.7785	0.1613	0.3853
	Kernel Naive Bayes	Control	57.4	0.7417	0.7417	0.6961	0.6310	0.3726	0.7417
		Bipolar II		0.2340	0.3793	0.7353	0.7943	0.1440	0.2895
		Unipolar Depressive		0.4595	0.3091	0.7157	0.8658	0.2014	0.3696
QDA	Quadratic Discriminant	Control	55.4	0.7736	0.6833	0.6961	0.7143	0.3917	0.7257
		Bipolar II		0.2444	0.3793	0.7451	0.8057	0.1558	0.2973
		Unipolar Depressive		0.3774	0.3636	0.6667	0.7785	0.1439	0.3704

ANOVACross Validation

Πίνακας Σ.13 : Αποτελέσματα ταξινόμησης σε 3 κλάσεις με 14 χαρακτηριστικά με τη μέθοδο Cross Validation και εφαρμογή ANOVA

		Class	%	PREC	REC	ACC	SPEC	MCC	F1
Trees	Fine Tree	Control	61.5	0.7306	0.7488	0.6882	0.6007	0.3516	0.7396
		Bipolar II		0.3820	0.3579	0.8294	0.9060	0.2712	0.3696
		Unipolar Depressive		0.4637	0.4536	0.7118	0.8068	0.2622	0.4586
	Medium Tree	Control	66.3	0.7275	0.8632	0.7279	0.5324	0.4250	0.7895
		Bipolar II		0.5200	0.2737	0.8632	0.9590	0.3090	0.3586
		Unipolar Depressive		0.5098	0.4262	0.7353	0.8491	0.2924	0.4643
	Coarse Tree	Control	63.8	0.6777	0.9204	0.6941	0.3669	0.3551	0.7806
		Bipolar II		0.2778	0.0526	0.8485	0.9778	0.0657	0.0885
		Unipolar Depressive		0.5086	0.3224	0.7338	0.8853	0.2449	0.3946
SVM	Linear SVM	Control	66.9	0.7191	0.8980	0.7324	0.4928	0.4371	0.7987
		Bipolar II		0.3889	0.1474	0.8485	0.9624	0.1699	0.2137
		Unipolar Depressive		0.5634	0.4372	0.7574	0.8753	0.3409	0.4923
	Quadratic SVM	Control	69.1	0.7352	0.8980	0.7485	0.5324	0.4723	0.8085
		Bipolar II		0.5102	0.2632	0.8618	0.9590	0.2978	0.3472
		Unipolar Depressive		0.6000	0.4590	0.7721	0.8873	0.3799	0.5201
	Cubic SVM	Control	66.8	0.7380	0.8408	0.7294	0.5683	0.4289	0.7860
		Bipolar II		0.4810	0.4000	0.8559	0.9299	0.3569	0.4368
		Unipolar Depressive		0.5455	0.4262	0.7500	0.8692	0.3215	0.4785
	Fine Gaussian SVM	Control	67.2	0.7021	0.9204	0.7221	0.4353	0.4187	0.7966
		Bipolar II		0.6667	0.1263	0.8691	0.9897	0.2506	0.2124
		Unipolar Depressive		0.5556	0.4098	0.7529	0.8793	0.3214	0.4717
	Medium Gaussian SVM	Control	65.6	0.7104	0.9030	0.7250	0.4676	0.4216	0.7952
		Bipolar II		0.5217	0.1263	0.8618	0.9812	0.2062	0.2034
		Unipolar Depressive		0.4863	0.3880	0.7250	0.8491	0.2561	0.4316
Coarse Gaussian SVM	Control	63.7	0.6626	0.9478	0.6838	0.3022	0.3400	0.7799	
	Bipolar II		0	0	0.8559	0.9949	0.0268	-	
	Unipolar		0.5098	0.2842	0.7338	0.8994	0.2280	0.3649	

KNN	Fine KNN	Depressive	61							
		Control		0.7424	0.7313	0.6912	0.6331	0.3633	0.7368	
		Bipolar II		0.3738	0.4211	0.8206	0.8855	0.2918	0.3960	
		Unipolar Depressive		0.4576	0.4426	0.7088	0.8068	0.2521	0.4500	
	Medium KNN	Control	64.6	0.7080	0.8806	0.7147	0.4748	0.3961	0.7849	
		Bipolar II		0.3729	0.2316	0.8382	0.9368	0.2073	0.2857	
		Unipolar Depressive		0.5207	0.3443	0.7382	0.8833	0.2639	0.4145	
	Coarse KNN	Control	64.9	0.6787	0.9353	0.7000	0.3597	0.3733	0.7866	
		Bipolar II		1.0000	0.0105	0.8618	1.0000	0.0952	0.0208	
		Unipolar Depressive		0.5120	0.3497	0.7353	0.8773	0.2599	0.4156	
	Cosine KNN	Control	66.6	0.7404	0.8657	0.7412	0.5612	0.4542	0.7982	
		Bipolar II		0.4127	0.2737	0.8441	0.9368	0.2516	0.3291	
		Unipolar Depressive		0.5374	0.4317	0.7471	0.8632	0.3177	0.4788	
	Cubic KNN	Control	64.9	0.7126	0.8756	0.7176	0.4892	0.4024	0.7857	
		Bipolar II		0.3929	0.2316	0.8426	0.9419	0.2188	0.2914	
		Unipolar Depressive		0.5154	0.3661	0.7368	0.8732	0.2700	0.4281	
	Weighted KNN	Control	66.8	0.7387	0.8507	0.7338	0.5647	0.4382	0.7908	
		Bipolar II		0.4333	0.2737	0.8485	0.9419	0.2635	0.3355	
		Unipolar Depressive		0.5478	0.4699	0.7529	0.8571	0.3442	0.5059	
	Ensemble	Boosted Trees	Control	67.8	0.7291	0.8905	0.7397	0.5216	0.4523	0.8018
			Bipolar II		0.5435	0.2632	0.8662	0.9641	0.3137	0.3546
Unipolar Depressive			0.5455		0.4262	0.7500	0.8692	0.3215	0.4785	
Bagged Trees		Control	69.1	0.7495	0.8706	0.7515	0.5791	0.4767	0.8055	
		Bipolar II		0.5439	0.3263	0.8676	0.9556	0.3526	0.4079	
		Unipolar Depressive		0.5705	0.4863	0.7632	0.8652	0.3708	0.5251	
Subspace Discriminant		Control	66.9	0.7157	0.9080	0.7324	0.4784	0.4387	0.8004	
		Bipolar II		0.4118	0.1474	0.8515	0.9658	0.1800	0.2171	
		Unipolar Depressive		0.5588	0.4153	0.7544	0.8793	0.3266	0.4765	
Subspace KNN		Control	62.5	0.7371	0.7811	0.7059	0.5971	0.3844	0.7585	
		Bipolar II		0.3673	0.3789	0.8221	0.8940	0.2694	0.3731	
		Unipolar Depressive		0.4808	0.4098	0.7221	0.8370	0.2604	0.4425	
RUSBoosted Trees		Control	58.1	0.7932	0.6393	0.6882	0.7590	0.3921	0.7080	
		Bipolar II		0.3188	0.4632	0.7868	0.8393	0.2607	0.3777	
		Unipolar Depressive		0.4312	0.5137	0.6868	0.7505	0.2510	0.4688	
Neural Networks	Narrow Neural Network	Control	64	0.7401	0.7935	0.7132	0.5971	0.3986	0.7659	
		Bipolar II		0.4235	0.3789	0.8412	0.9162	0.3094	0.4000	
		Unipolar Depressive		0.4878	0.4372	0.7250	0.8310	0.2780	0.4611	
	Medium Neural Network	Control	61.8	0.7438	0.7438	0.6971	0.6295	0.3733	0.7438	
		Bipolar II		0.3814	0.3895	0.8265	0.8974	0.2844	0.3854	
		Unipolar Depressive		0.4641	0.4590	0.7118	0.8048	0.2648	0.4615	
	Wide Neural Network	Control	58.7	0.7230	0.7338	0.6765	0.5935	0.3285	0.7284	
		Bipolar II		0.2929	0.3053	0.8000	0.8803	0.1824	0.2990	
		Unipolar Depressive		0.4335	0.4098	0.6971	0.8028	0.2165	0.4213	
	Bilayered Neural Network	Control	60.4	0.7402	0.7512	0.6971	0.6187	0.3712	0.7457	
		Bipolar II		0.3789	0.3789	0.8265	0.8991	0.2781	0.3789	
		Unipolar Depressive		0.4124	0.3989	0.6853	0.7907	0.1917	0.4056	
	Trilayered Neural Network	Control	62.2	0.7481	0.7537	0.7044	0.6331	0.3875	0.7509	
		Bipolar II		0.4085	0.3053	0.8412	0.9282	0.2647	0.3494	
		Unipolar Depressive		0.4461	0.4973	0.6985	0.7726	0.2612	0.4703	
Naive Bayes	Gaussian Naive Bayes	Control	57.8	0.7914	0.6891	0.7088	0.7374	0.4195	0.7367	
		Bipolar II		0.2711	0.4737	0.7485	0.7932	0.2154	0.3448	
		Unipolar Depressive		0.4329	0.3880	0.6985	0.8129	0.2082	0.4092	

	Kernel Naive Bayes	Control	63.7	0.7512	0.7811	0.7176	0.6259	0.4111	0.7659
		Bipolar II		0.3857	0.2842	0.8368	0.9265	0.2404	0.3273
		Unipolar Depressive		0.4792	0.5027	0.7191	0.7988	0.2971	0.4907
QDA	Quadratic Discriminant	Control	57.8	0.7914	0.6891	0.7088	0.7374	0.4195	0.7367
		Bipolar II		0.2711	0.4737	0.7485	0.7932	0.2154	0.3448
		Unipolar Depressive		0.4329	0.3880	0.6985	0.8129	0.2082	0.4092

Holdout Validation

Πίνακας Σ.14 : Αποτελέσματα ταξινόμησης σε 3 κλάσεις με 14 χαρακτηριστικά με τη μέθοδο Holdout Validation και εφαρμογή ANOVA

		Class	%	PREC	REC	ACC	SPEC	MCC	F1
Trees	Fine Tree	Control	60.3	0.7054	0.7583	0.6716	0.5476	0.3123	0.7309
		Bipolar II		0.3750	0.3103	0.8284	0.9143	0.2435	0.3396
		Unipolar Depressive		0.4510	0.4182	0.7059	0.8121	0.2360	0.4340
	Medium Tree	Control	62.3	0.6625	0.8833	0.6667	0.3571	0.2878	0.7571
		Bipolar II		0.4000	0.2069	0.8431	0.9486	0.2080	0.2727
		Unipolar Depressive		0.5172	0.2727	0.7353	0.9060	0.2272	0.3571
	Coarse Tree	Control	61.8	0.6328	0.9333	0.6422	0.2262	0.2317	0.7542
		Bipolar II		0	0	0.8529	0.9943	-0.0286	-
		Unipolar Depressive		0.5385	0.2545	0.7402	0.9195	0.2316	0.3457
SVM	Linear SVM	Control	65.7	0.6667	0.9167	0.6814	0.3452	0.3278	0.7719
		Bipolar II		0.6667	0.1379	0.8676	0.9886	0.2615	0.2286
		Unipolar Depressive		0.6061	0.3636	0.7647	0.9128	0.3331	0.4545
	Quadratic SVM	Control	67.2	0.6968	0.9000	0.7108	0.4405	0.3922	0.7855
		Bipolar II		0.5000	0.2069	0.8578	0.9657	0.2562	0.2927
		Unipolar Depressive		0.6216	0.4182	0.7745	0.9060	0.3734	0.5000
	Cubic SVM	Control	58.3	0.6690	0.7917	0.6471	0.4405	0.2484	0.7252
		Bipolar II		0.3750	0.2069	0.8382	0.9429	0.1945	0.2667
		Unipolar Depressive		0.3913	0.3273	0.6814	0.8121	0.1480	0.3564
	Fine Gaussian SVM	Control	64.7	0.6453	0.9250	0.6569	0.2738	0.2690	0.7603
		Bipolar II		1.0000	0.0690	0.8676	1.0000	0.2444	0.1290
		Unipolar Depressive		0.6333	0.3455	0.7696	0.9262	0.3403	0.4471
	Medium Gaussian SVM	Control	64.7	0.6627	0.9167	0.6765	0.3333	0.3160	0.7692
		Bipolar II		0.7500	0.1034	0.8676	0.9943	0.2462	0.1818
		Unipolar Depressive		0.5588	0.3455	0.7500	0.8993	0.2915	0.4270
Coarse Gaussian SVM	Control	63.2	0.6491	0.9250	0.6618	0.2857	0.2816	0.7629	
	Bipolar II		0	0	0.8529	0.9943	-0.0286	-	
	Unipolar Depressive		0.5625	0.3273	0.7500	0.9060	0.2847	0.4138	
KNN	Fine KNN	Control	62.7	0.7568	0.7000	0.6912	0.6786	0.3741	0.7273
		Bipolar II		0.4167	0.5172	0.8284	0.8800	0.3639	0.4615
		Unipolar Depressive		0.5088	0.5273	0.7353	0.8121	0.3356	0.5179
	Medium KNN	Control	62.3	0.6752	0.8833	0.6814	0.3929	0.3228	0.7653
		Bipolar II		0.3636	0.1379	0.8431	0.9600	0.1514	0.2000
		Unipolar Depressive		0.4722	0.3091	0.7206	0.8725	0.2114	0.3736
	Coarse KNN	Control	62.7	0.6506	0.9000	0.6569	0.3095	0.2649	0.7552
		Bipolar II		-	0	0.8578	1.0000	-	-
		Unipolar Depressive		0.5263	0.3636	0.7402	0.8792	0.2768	0.4301

Χρήση Αλγορίθμων Μηχανικής Μάθησης για την ταξινόμηση καταθλιπτικών καταστάσεων

Ensemble	Cosine KNN	Control	59.8	0.6733	0.8417	0.6667	0.4167	0.2882	0.7481
		Bipolar II		0.2727	0.1034	0.8333	0.9543	0.0893	0.1500
		Unipolar Depressive		0.4186	0.3273	0.6961	0.8322	0.1735	0.3673
	Cubic KNN	Control	64.7	0.6768	0.9250	0.6961	0.3690	0.3645	0.7817
		Bipolar II		0.4167	0.1724	0.8480	0.9600	0.1965	0.2439
		Unipolar Depressive		0.5714	0.2909	0.7500	0.9195	0.2713	0.3855
	Weighted KNN	Control	66.2	0.7083	0.8500	0.7059	0.5000	0.3780	0.7727
		Bipolar II		0.5000	0.2759	0.8578	0.9543	0.2989	0.3556
		Unipolar Depressive		0.5682	0.4545	0.7598	0.8725	0.3528	0.5051
Ensemble	Boosted Trees	Control	63.7	0.7027	0.8667	0.7059	0.4762	0.3781	0.7761
		Bipolar II		0.5000	0.2759	0.8578	0.9543	0.2989	0.3556
		Unipolar Depressive		0.4500	0.3273	0.7108	0.8523	0.2008	0.3789
	Bagged Trees	Control	63.7	0.6887	0.8667	0.6912	0.4405	0.3447	0.7675
		Bipolar II		0.4375	0.2414	0.8480	0.9486	0.2467	0.3111
		Unipolar Depressive		0.5135	0.3455	0.7353	0.8792	0.2587	0.4130
	Subspace Discriminant	Control	65.2	0.6835	0.9000	0.6961	0.4048	0.3589	0.7770
		Bipolar II		0.5000	0.1724	0.8578	0.9714	0.2327	0.2564
		Unipolar Depressive		0.5556	0.3636	0.7500	0.8926	0.2983	0.4396
	Subspace KNN	Control	61.3	0.7063	0.7417	0.6667	0.5595	0.3050	0.7236
		Bipolar II		0.4643	0.4483	0.8480	0.9143	0.3679	0.4561
		Unipolar Depressive		0.4600	0.4182	0.7108	0.8188	0.2445	0.4381
	RUSBoosted Trees	Control	54.4	0.7955	0.5833	0.6667	0.7857	0.3667	0.6731
		Bipolar II		0.2833	0.5862	0.7304	0.7543	0.2610	0.3820
		Unipolar Depressive		0.4286	0.4364	0.6912	0.7852	0.2204	0.4324
Neural Networks	Narrow Neural Network	Control	62.3	0.7302	0.7667	0.6961	0.5952	0.3665	0.7480
		Bipolar II		0.4000	0.2069	0.8431	0.9486	0.2080	0.2727
		Unipolar Depressive		0.4603	0.5273	0.7059	0.7718	0.2873	0.4915
	Medium Neural Network	Control	63.7	0.7615	0.6917	0.6912	0.6905	0.3770	0.7249
		Bipolar II		0.4242	0.4828	0.8333	0.8914	0.3549	0.4516
		Unipolar Depressive		0.5323	0.6000	0.7500	0.8054	0.3911	0.5641
	Wide Neural Network	Control	58.8	0.7500	0.7250	0.6961	0.6548	0.3774	0.7373
		Bipolar II		0.2750	0.3793	0.7696	0.8343	0.1879	0.3188
		Unipolar Depressive		0.4583	0.4000	0.7108	0.8255	0.2359	0.4272
	Bilayered Neural Network	Control	60.3	0.7073	0.7250	0.6618	0.5714	0.2982	0.7160
		Bipolar II		0.5200	0.4483	0.8627	0.9314	0.4044	0.4815
		Unipolar Depressive		0.4107	0.4182	0.6814	0.7785	0.1956	0.4144
	Trilayered Neural Network	Control	50	0.6818	0.6250	0.6078	0.5833	0.2057	0.6522
		Bipolar II		0.2941	0.3448	0.7892	0.8629	0.1946	0.3175
		Unipolar Depressive		0.2833	0.3091	0.6029	0.7114	0.0200	0.2957
Naive Bayes	Gaussian Naive Bayes	Control	57.4	0.7455	0.6833	0.6765	0.6667	0.3456	0.7130
		Bipolar II		0.3846	0.5172	0.8137	0.8629	0.3376	0.4412
		Unipolar Depressive		0.3636	0.3636	0.6569	0.7651	0.1287	0.3636
	Kernel Naive Bayes	Control	60.8	0.7015	0.7833	0.6765	0.5238	0.3184	0.7402
		Bipolar II		0.3636	0.1379	0.8431	0.9600	0.1514	0.2000
		Unipolar Depressive		0.4407	0.4727	0.6961	0.7785	0.2459	0.4561
QDA	Quadratic Discriminant	Control	57.4	0.7455	0.6833	0.6765	0.6667	0.3456	0.7130
		Bipolar II		0.3846	0.5172	0.8137	0.8629	0.3376	0.4412
		Unipolar Depressive		0.3636	0.3636	0.6569	0.7651	0.1287	0.3636

Kruskal Wallis

Cross Validation

Πίνακας Σ.15 : Αποτελέσματα ταξινόμησης σε 3 κλάσεις με 15 χαρακτηριστικά με τη μέθοδο Cross Validation και εφαρμογή Kruskal Wallis

		Class	%	PREC	REC	ACC	SPEC	MC C	F1
Trees	Fine Tree	Control	61.2	0.7506	0.7413	0.7015	0.6439	0.3842	0.7459
		Bipolar II		0.3814	0.3895	0.8265	0.8974	0.2844	0.3854
		Unipolar Depressive		0.4355	0.4426	0.6956	0.7887	0.2302	0.4390
	Medium Tree	Control	66.3	0.7219	0.8781	0.7279	0.5108	0.4254	0.7924
		Bipolar II		0.5185	0.2947	0.8632	0.9556	0.3209	0.3758
		Unipolar Depressive		0.5109	0.3825	0.7353	0.8652	0.2739	0.4375
	Coarse Tree	Control	64.7	0.6750	0.9353	0.6956	0.3489	0.3630	0.7842
		Bipolar II		0.3571	0.1053	0.8485	0.9692	0.1300	0.1626
		Unipolar Depressive		0.5684	0.2951	0.7500	0.9175	0.2720	0.3885
SVM	Linear SVM	Control	66.5	0.7123	0.8930	0.7235	0.4784	0.4169	0.7925
		Bipolar II		0.4286	0.1579	0.8529	0.9658	0.1941	0.2308
		Unipolar Depressive		0.5532	0.4262	0.7529	0.8732	0.3276	0.4815
	Quadratic SVM	Control	69.1	0.7320	0.9104	0.7500	0.5180	0.4774	0.8115
		Bipolar II		0.5200	0.2737	0.8632	0.9590	0.3090	0.3586
		Unipolar Depressive		0.6000	0.4262	0.7691	0.8954	0.3627	0.4984
	Cubic SVM	Control	64.6	0.7263	0.8383	0.7176	0.5432	0.4028	0.7783
		Bipolar II		0.4384	0.3368	0.8471	0.9299	0.2987	0.3810
		Unipolar Depressive		0.4895	0.3825	0.7265	0.8531	0.2564	0.4294
	Fine Gaussian SVM	Control	65.9	0.6898	0.9129	0.7059	0.4065	0.3805	0.7859
		Bipolar II		0.6875	0.1158	0.8691	0.9915	0.2453	0.1982
		Unipolar Depressive		0.5303	0.3825	0.7426	0.8753	0.2890	0.4444
	Medium Gaussian SVM	Control	66.6	0.7174	0.9030	0.7324	0.4856	0.4378	0.7996
		Bipolar II		0.5185	0.1474	0.8618	0.9778	0.2222	0.2295
		Unipolar Depressive		0.5170	0.4153	0.7382	0.8571	0.2935	0.4606
Coarse Gaussian SVM	Control	63.8	0.6609	0.9502	0.6824	0.2950	0.3376	0.7796	
	Bipolar II		0	0	0.8588	0.9983	0.0155	-	
	Unipolar Depressive		0.5149	0.2842	0.7353	0.9014	0.2314	0.3662	
KNN	Fine KNN	Control	60.1	0.7410	0.7189	0.6853	0.6367	0.3535	0.7298
		Bipolar II		0.3636	0.3789	0.8206	0.8923	0.2666	0.3711
		Unipolar Depressive		0.4398	0.4590	0.6971	0.7847	0.2405	0.4492
	Medium KNN	Control	66.2	0.7229	0.8955	0.7353	0.5036	0.4432	0.8000
		Bipolar II		0.4314	0.2316	0.8500	0.9504	0.2396	0.3014
		Unipolar Depressive		0.5191	0.3716	0.7382	0.8732	0.2753	0.4331
	Coarse KNN	Control	65.3	0.6836	0.9353	0.7059	0.3741	0.3868	0.7899
		Bipolar II		1.0000	0.0105	0.8618	1.0000	0.0952	0.0208
		Unipolar Depressive		0.5194	0.3661	0.7382	0.8753	0.2730	0.4295
	Cosine KNN	Control	67.2	0.7500	0.8657	0.7500	0.5827	0.4735	0.8037
		Bipolar II		0.4576	0.2842	0.8529	0.9453	0.2827	0.3506
		Unipolar Depressive		0.5223	0.4481	0.7412	0.8491	0.3128	0.4824

	Cubic KNN	Control	66.3	0.7123	0.8930	0.7235	0.4784	0.4169	0.7925
		Bipolar II		0.4615	0.2526	0.8544	0.9521	0.2671	0.3265
		Unipolar Depressive		0.5484	0.3716	0.7485	0.8873	0.2974	0.4430
	Weighted KNN	Control	68.1	0.7616	0.8582	0.7574	0.6115	0.4897	0.8070
		Bipolar II		0.4355	0.2842	0.8485	0.9402	0.2702	0.3439
		Unipolar Depressive		0.5515	0.4973	0.7559	0.8511	0.3604	0.5230
Ensemble	Boosted Trees	Control	68.7	0.7311	0.9129	0.7500	0.5144	0.4779	0.8119
		Bipolar II		0.5208	0.2632	0.8632	0.9607	0.3030	0.3497
		Unipolar Depressive		0.5769	0.4098	0.7603	0.8893	0.3374	0.4792
	Bagged Trees	Control	69.6	0.7495	0.8856	0.7574	0.5719	0.4901	0.8119
		Bipolar II		0.5577	0.3053	0.8691	0.9607	0.3469	0.3946
		Unipolar Depressive		0.5752	0.4809	0.7647	0.8692	0.3718	0.5238
	Subspace Discriminant	Control	67.4	0.7171	0.9080	0.7338	0.4820	0.4419	0.8013
		Bipolar II		0.4667	0.1474	0.8574	0.9726	0.2026	0.2240
		Unipolar Depressive		0.5603	0.4317	0.7559	0.8753	0.3358	0.4877
	Subspace KNN	Control	62.4	0.7269	0.7811	0.6971	0.5755	0.3642	0.7530
		Bipolar II		0.3902	0.3368	0.8338	0.9145	0.2676	0.3616
		Unipolar Depressive		0.4699	0.4262	0.7162	0.8229	0.2573	0.4470
	RUSBoosted Trees	Control	60.1	0.8108	0.6716	0.7132	0.7734	0.4377	0.7347
		Bipolar II		0.3358	0.4737	0.7956	0.8479	0.2802	0.3930
		Unipolar Depressive		0.4413	0.5137	0.6941	0.7606	0.2622	0.4747
Neural Networks	Narrow Neural Network	Control	64.7	0.7517	0.8060	0.7279	0.6151	0.4297	0.7779
		Bipolar II		0.4268	0.3684	0.8426	0.9197	0.3067	0.3955
		Unipolar Depressive		0.4850	0.4426	0.7235	0.8270	0.2778	0.4629
	Medium Neural Network	Control	61.8	0.7494	0.7363	0.6985	0.6439	0.3788	0.7428
		Bipolar II		0.3579	0.3579	0.8206	0.8957	0.2536	0.3579
		Unipolar Depressive		0.4737	0.4918	0.7162	0.7988	0.2872	0.4826
	Wide Neural Network	Control	61.9	0.7482	0.7612	0.7074	0.6295	0.3923	0.7546
		Bipolar II		0.3765	0.3368	0.8294	0.9094	0.2581	0.3556
		Unipolar Depressive		0.4462	0.4536	0.7015	0.7928	0.2451	0.4499
	Bilayered Neural Network	Control	61.3	0.7382	0.7786	0.7059	0.6007	0.3849	0.7579
		Bipolar II		0.3778	0.3579	0.8279	0.9043	0.2682	0.3676
		Unipolar Depressive		0.4217	0.3825	0.6926	0.8068	0.1955	0.4011
	Trilayered Neural Network	Control	60.7	0.7409	0.7612	0.7015	0.6151	0.3788	0.7509
		Bipolar II		0.3647	0.3263	0.8265	0.9077	0.2453	0.3444
		Unipolar Depressive		0.4176	0.4153	0.6868	0.7867	0.2024	0.4164
Naive Bayes	Gaussian Naive Bayes	Control	58.7	0.7904	0.6940	0.7103	0.7338	0.4210	0.7391
		Bipolar II		0.2733	0.4947	0.7456	0.7863	0.2242	0.3521
		Unipolar Depressive		0.4710	0.3989	0.7176	0.8350	0.2473	0.4320
	Kernel Naive Bayes	Control	62.9	0.7524	0.7935	0.7235	0.6223	0.4219	0.7724
		Bipolar II		0.3385	0.2316	0.8294	0.9265	0.1864	0.2750
		Unipolar Depressive		0.4555	0.4754	0.7059	0.7907	0.2626	0.4652
QDA	Quadratic Discriminant	Control	58.7	0.7904	0.6940	0.7103	0.7338	0.4210	0.7391
		Bipolar II		0.2733	0.4947	0.7456	0.7863	0.2242	0.3521
		Unipolar Depressive		0.4710	0.3989	0.7176	0.8350	0.2473	0.4320

Holdout Validation

Πίνακας Σ.16 : Αποτελέσματα ταξινόμησης σε 3 κλάσεις με 15 χαρακτηριστικά με τη μέθοδο Holdout Validation και εφαρμογή Kruskal Wallis

		Class	%	PREC	REC	ACC	SPEC	MCC	F1
Trees	Fine Tree	Control	60.3	0.7120	0.7355	0.6667	0.5663	0.3044	0.7236
		Bipolar II		0.4167	0.3448	0.8382	0.9200	0.2870	0.3774
		Unipolar Depressive		0.4364	0.4444	0.7010	0.7933	0.2364	0.4404
	Medium Tree	Control	63.2	0.6867	0.8512	0.6814	0.4337	0.3173	0.7601
		Bipolar II		0.5000	0.2414	0.8578	0.9600	0.2782	0.3256
		Unipolar Depressive		0.4750	0.3519	0.7255	0.8600	0.2354	0.4043
	Coarse Tree	Control	64.2	0.7183	0.8430	0.7108	0.5181	0.3856	0.7757
		Bipolar II		NaN	0	0.8578	1.0000	NaN	NaN
		Unipolar Depressive		0.4677	0.5370	0.7157	0.7800	0.3041	0.5000
SVM	Linear SVM	Control	66.7	0.7248	0.8926	0.7353	0.5060	0.4412	0.8000
		Bipolar II		NaN	0	0.8578	1.0000	NaN	NaN
		Unipolar Depressive		0.5091	0.5185	0.7402	0.8200	0.3366	0.5138
	Quadratic SVM	Control	67.2	0.7310	0.8760	0.7353	0.5301	0.4401	0.7970
		Bipolar II		0.4545	0.1724	0.8529	0.9657	0.2136	0.2500
		Unipolar Depressive		0.5417	0.4815	0.7549	0.8533	0.3482	0.5098
	Cubic SVM	Control	62.7	0.7481	0.8099	0.7255	0.6024	0.4225	0.7778
		Bipolar II		0.3500	0.2414	0.8284	0.9257	0.1962	0.2857
		Unipolar Depressive		0.4340	0.4259	0.7010	0.8000	0.2273	0.4299
	Fine Gaussian SVM	Control	65.7	0.7059	0.8926	0.7157	0.4578	0.3975	0.7883
		Bipolar II		0.5000	0.0690	0.8578	0.9886	0.1449	0.1212
		Unipolar Depressive		0.5106	0.4444	0.7402	0.8467	0.3050	0.4752
	Medium Gaussian SVM	Control	64.7	0.7219	0.9008	0.7353	0.4940	0.4423	0.8015
		Bipolar II		NaN	0	0.8578	1.0000	NaN	NaN
		Unipolar Depressive		0.4340	0.4259	0.7010	0.8000	0.2273	0.4299
Coarse Gaussian SVM	Control	63.2	0.6534	0.9504	0.6716	0.2651	0.3076	0.7744	
	Bipolar II		NaN	0	0.8578	1.0000	NaN	NaN	
	Unipolar Depressive		0.5000	0.2593	0.7353	0.9067	0.2127	0.3415	
KNN	Fine KNN	Control	59.3	0.7479	0.7355	0.6961	0.6386	0.3728	0.7417
		Bipolar II		0.2414	0.2414	0.7843	0.8743	0.1157	0.2414
		Unipolar Depressive		0.4464	0.4630	0.7059	0.7933	0.2534	0.4545
	Medium KNN	Control	65.2	0.6855	0.9008	0.6961	0.3976	0.3535	0.7786
		Bipolar II		0.4545	0.1724	0.8529	0.9657	0.2136	0.2500
		Unipolar Depressive		0.5588	0.3519	0.7549	0.9000	0.2981	0.4318
	Coarse KNN	Control	64.7	0.6647	0.9504	0.6863	0.3012	0.3443	0.7823
		Bipolar II		NaN	0	0.8578	1.0000	NaN	NaN
		Unipolar Depressive		0.5484	0.3148	0.7500	0.9067	0.2722	0.4000
	Cosine KNN	Control	68.1	0.7365	0.9008	0.7500	0.5301	0.4744	0.8104
		Bipolar II		0.5385	0.2414	0.8627	0.9657	0.2961	0.3333
		Unipolar Depressive		0.5349	0.4259	0.7500	0.8667	0.3165	0.4742
	Cubic KNN	Control	66.2	0.6987	0.9008	0.7108	0.4337	0.3875	0.7870
		Bipolar II		0.6250	0.1724	0.8676	0.9829	0.2793	0.2703
		Unipolar Depressive		0.5250	0.3889	0.7451	0.8733	0.2914	0.4468
Weighted KNN	Control	68.6	0.7681	0.8760	0.7696	0.6145	0.5151	0.8185	
	Bipolar II		0.4167	0.1724	0.8480	0.9600	0.1965	0.2439	
	Unipolar Depressive		0.5370	0.5370	0.7549	0.8333	0.3704	0.5370	
Ensemble	Boosted Trees	Control	65.2	0.7133	0.8430	0.7059	0.5060	0.3745	0.7727
		Bipolar II		0.7000	0.2414	0.8775	0.9829	0.3627	0.3590
		Unipolar Depressive		0.4706	0.4444	0.7206	0.8200	0.2694	0.4571
	Bagged	Control	64.7	0.7153	0.8512	0.7108	0.5060	0.3852	0.7774
		Bipolar II		0.3333	0.2069	0.8284	0.9314	0.1703	0.2553

	Trees	Unipolar Depressive		0.5476	0.4259	0.7549	0.8733	0.3265	0.4792	
	Subspace Discriminant	Control	67.2	0.7171	0.9008	0.7304	0.4819	0.4314	0.7985	
		Bipolar II		0.7143	0.1724	0.8725	0.9886	0.3088	0.2778	
		Unipolar Depressive		0.5111	0.4259	0.7402	0.8533	0.2971	0.4646	
	Subspace KNN	Control	61.8	0.7520	0.7769	0.7157	0.6265	0.4068	0.7642	
		Bipolar II		0.2692	0.2414	0.7990	0.8914	0.1391	0.2545	
		Unipolar Depressive		0.4717	0.4630	0.7206	0.8133	0.2780	0.4673	
	RUSBoosted Trees	Control	63.2	0.8300	0.6860	0.7304	0.7952	0.4728	0.7511	
		Bipolar II		0.3333	0.5862	0.7745	0.8057	0.3161	0.4250	
		Unipolar Depressive		0.5472	0.5370	0.7598	0.8400	0.3793	0.5421	
	Neural Networks	Narrow Neural Network	Control	65.2	0.7642	0.7769	0.7255	0.6506	0.4292	0.7705
			Bipolar II		0.4375	0.2414	0.8480	0.9486	0.2467	0.3111
Unipolar Depressive			0.4923		0.5926	0.7304	0.7800	0.3528	0.5378	
Medium Neural Network		Control	47.5	0.6792	0.5950	0.5931	0.5904	0.1823	0.6344	
		Bipolar II		0.2069	0.2069	0.7745	0.8686	0.0755	0.2069	
		Unipolar Depressive		0.2754	0.3519	0.5833	0.6667	0.0173	0.3089	
Wide Neural Network		Control	60.3	0.7479	0.7355	0.6961	0.6386	0.3728	0.7417	
		Bipolar II		0.3636	0.2759	0.8284	0.9200	0.2205	0.3137	
		Unipolar Depressive		0.4127	0.4815	0.6814	0.7533	0.2242	0.4444	
Bilayered Neural Network		Control	57.8	0.7333	0.7273	0.6814	0.6145	0.3411	0.7303	
		Bipolar II		0.2400	0.2069	0.7941	0.8914	0.1047	0.2222	
		Unipolar Depressive		0.4068	0.4444	0.6814	0.7667	0.2054	0.4248	
Trilayered Neural Network		Control	56.9	0.7500	0.7190	0.6912	0.6506	0.3666	0.7342	
		Bipolar II		0.2414	0.2414	0.7843	0.8743	0.1157	0.2414	
		Unipolar Depressive		0.3729	0.4074	0.6618	0.7533	0.1564	0.3894	
Naive Bayes		Gaussian Naive Bayes	Control	64.7	0.8416	0.7025	0.7451	0.8072	0.5008	0.7658
			Bipolar II		0.4783	0.3793	0.8529	0.9314	0.3431	0.4231
			Unipolar Depressive		0.4500	0.6667	0.6961	0.7067	0.3374	0.5373
	Kernel Naive Bayes	Control	63.2	0.7742	0.7934	0.7402	0.6627	0.4589	0.7837	
		Bipolar II		0.3077	0.1379	0.8333	0.9486	0.1237	0.1905	
		Unipolar Depressive		0.4328	0.5370	0.6912	0.7467	0.2665	0.4793	
QDA	Quadratic Discriminant	Control	64.7	0.8416	0.7025	0.7451	0.8072	0.5008	0.7658	
		Bipolar II		0.4783	0.3793	0.8529	0.9314	0.3431	0.4231	
		Unipolar Depressive		0.4500	0.6667	0.6961	0.7067	0.3374	0.5373	