



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

**Ανάλυση μεταβλητότητας καρδιακού ρυθμού για την αναγνώριση
επιπέδων προσήλωσης χρήστη σε παιχνίδια σοβαρού σκοπού για την
υγεία**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Κανέλλος Ε. Θεόδωρος - Φανούριος

Επιβλέπουσα: Κωνσταντίνα Σ. Νικήτα
Καθηγήτρια Ε.Μ.Π.



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

**Ανάλυση μεταβλητότητας καρδιακού ρυθμού για την αναγνώριση
επιπέδων προσήλωσης χρήστη σε παιχνίδια σοβαρού σκοπού για την
υγεία**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Κανέλλος Ε. Θεόδωρος - Φανούριος

Επιβλέπουσα: Κωνσταντίνα Σ. Νικήτα
Καθηγήτρια Ε.Μ.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 13^η Σεπτεμβρίου 2023.

Κωνσταντίνα Σ. Νικήτα	Γεώργιος Στάμου	Αθανάσιος Βουλόδημος
Καθηγήτρια Ε.Μ.Π.	Καθηγητής Ε.Μ.Π.	Επίκουρος Καθηγητής Ε.Μ.Π.

Ιούνιος 2023

Κανέλλος Ε. Θεόδωρος – Φανούριος

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

Copyright © Κανέλλος Θεόδωρος – Φανούριος

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

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

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

**Στην Βασιλική, στον Στάθη, στις Σοφίες, στην Μαρία
και στον πολυαγαπημένο μου παππού...**

Περίληψη

Η παρούσα Διπλωματική Εργασία διερευνά τη σχέση μεταξύ της μεταβλητότητας του καρδιακού ρυθμού (ΜΚΡ) που καταγράφεται κατά την αλληλεπίδραση χρήστη με παιχνίδια σοβαρού σκοπού για την υγεία (ΠΣΣΥ), με τα επίπεδα προσήλωσής του στην παρέμβαση. Ανώτερος στόχος της έρευνας αυτής ορίζεται η επιβλεπόμενη εκπαίδευση μοντέλων μηχανικής μάθησης με είσοδο χαρακτηριστικών που προκύπτουν από την καταγραφή ΜΚΡ για την πρόβλεψη των επιπέδων προσήλωσης χρήστη και την ενίσχυση της παρέμβασης που παρέχει το ΠΣΣΥ μέσω δυναμικής προσαρμογής του.

Για τις ανάγκες της παρούσας Διπλωματικής Εργασίας, αρχικά διενεργείται θεωρητική πλαισίωση και εισαγωγή στις βασικές έννοιες που αναφέρονται στην έρευνα, ενώ αξιοποιούνται δεδομένα αλληλεπίδρασης συμμετεχόντων με ΠΣΣΥ που ενισχύει τις διατροφικές γνώσεις του χρήστη. Πραγματοποιείται επεξεργασία και ανάλυση των δεδομένων που συλλέγονται από αισθητήρα καρδιακού παλμού αλλά και δεδομένων εκτίμησης προσήλωσης που επισημειώνουν οι συμμετέχοντες παρακολουθώντας καταγραφές της αλληλεπίδρασής τους με το ΠΣΣΥ. Στη συνέχεια τα δεδομένα εισάγονται σε ρηγά μοντέλα μηχανικής μάθησης, με σκοπό την κατάλληλη εκπαίδευση και την παραγωγή μετρικών, που υποδεικνύουν την ικανότητα των μοντέλων στην πρόβλεψη των επιπέδων προσήλωσης.

Από την ανάλυση των αρχικών αποτελεσμάτων που εξάγονται, για την παρούσα έρευνα, κατά την εκπαίδευση των μοντέλων στο σύνολο των συμμετεχόντων με τη μεθοδολογία «leave-one-participant-out», προκύπτει πως τα μοντέλα μηχανικής μάθησης δεν αποκτούν ικανοποιητική ικανότητα πρόβλεψης. Για την περαιτέρω διερεύνηση εκπαιδεύονται τα ρηγά μοντέλα σε κάθε συμμετέχοντα και αναλύονται τα αποτελέσματα. Στη συνέχεια επαναλαμβάνεται η τεχνική «leave-one-participant-out» με επιλογή συμμετεχόντων στους οποίους τα μοντέλα επέδειξαν ικανότητα διάκρισης. Τέλος πραγματοποιείται σύγκριση ανάμεσα στα δύο σύνολα εκπαίδευσης και διερευνώνται ζητήματα που αφορούν την ποιότητα επισημείωσης των επιπέδων προσήλωσης. Η βελτίωση που παρατηρείται στην ικανότητα πρόβλεψης με το μειωμένο σύνολο εκπαίδευσης δίνει το έναυσμα σε περαιτέρω μελλοντική έρευνα για βελτίωση των καταγραφών των δεδομένων.

Λέξεις Κλειδιά: παιχνίδια σοβαρού σκοπού, συναισθηματική υπολογιστική, μεταβλητότητα καρδιακού ρυθμού, επίπεδα προσήλωσης, μηχανική μάθηση

Abstract

The present Diploma Thesis investigates the relationship between heart rate variability (HRV), monitored during user interaction with a serious game for health (SGH), and user perceived levels of engagement. The main goal of this research is defined as the supervised training of machine learning models, using features extracted from the HRV analysis as input to predict user engagement and enhance the intervention provided by the SGH through its dynamic content adaptation.

For the needs of this Diploma Thesis, an introduction to basic related concepts is carried out, while participant interaction data with a SGH which enhances the user's nutrition knowledge are employed. Data collected from a heart rate sensor as well as engagement data, annotated by participants while watching recordings of their interaction with the SGH, are being processed and analyzed. Followingly, the extracted features are imported into shallow machine learning models to produce metrics that indicate the models' ability to predict engagement levels.

Analysis of the preliminary results indicate that the training of the machine learning models based on data collected from all participants, using with the "leave-one-participant-out" methodology, does not achieve satisfactory predictive capabilities. In the next step, the shallow machine learning models are trained on each participant separately and the results are analyzed. The leave-one-participant-out technique is then repeated, selecting participants for whom the models demonstrated adequate discrimination capabilities. Finally, a comparison is conducted between the two training samples and issues related to the quality of annotation of engagement levels provided by the participants are investigated. The observed improvement in predictive capability with the reduced training set prompts further future research to improve the quality of annotated engagement.

Keywords: serious games, affective computing, heart rate variability, machine learning, engagement levels

Πίνακας περιεχομένων

<i>Περίληψη</i>	6
<i>Abstract</i>	7
<i>Ευρετήριο Εικόνων</i>	13
<i>Ευρετήριο Πινάκων</i>	17
<i>Ευρετήριο Διαγραμμάτων</i>	18
Κεφάλαιο 1: Εισαγωγή	19
1.1 Εισαγωγή στο αντικείμενο της Διπλωματικής Εργασίας	19
1.2 Στόχος της Διπλωματικής Εργασίας	19
1.3 Οργάνωση της Διπλωματικής Εργασίας	20
Κεφάλαιο 2: Θεωρητικό Υπόβαθρο	21
2.1 Παιχνίδια σοβαρού ως παρεμβάσεις για την υγεία	21
2.1.1 Παιχνίδια σοβαρού σκοπού (ΠΣΣ)	21
2.1.2 Εφαρμογές ΠΣΣ στον τομέα της υγείας	22
2.1.3 Αξιολόγηση ΠΣΣ	25
2.1.4 Μελλοντικές προκλήσεις των παιχνιδιών ΠΣΣΥ	27
2.2 Συναισθηματική Υπολογιστική και Νοημοσύνη	29
2.2.1 Τεχνητή νοημοσύνη και συναισθήματα	29
2.2.2 Ορισμοί και εφαρμογές ΣΥΝ	30
2.2.3 Μέθοδοι τεχνητής νοημοσύνης για ΠΣΣ	32
2.2.4 ΣΥΝ και ΠΣΣ	34
2.2.5 Μέθοδοι αναγνώρισης συναισθήματος	35
2.3 Μεταβλητότητα Καρδιακού Ρυθμού	37
2.3.1 Ανάλυση ΜΚΡ	37
2.3.2 Εφαρμογές ΜΚΡ	39
2.3.3 ΜΚΡ και επίπεδα προσήλωσης	40
Κεφάλαιο 3: Μεθοδολογία	42
3.1 Περιγραφή πειραματικής διαδικασίας	42
3.1.1 Το ΠΣΣΥ	42
3.1.2 Ο αισθητήρας καταγραφής του καρδιακού ρυθμού	42
3.1.3 Τρόπος καταγραφής των επιπέδων προσήλωσης μέσω υποκειμενικής επισημείωσης του χρήστη	42
3.1.4 Οι συμμετέχοντες	43
3.2 Δομή των δεδομένων	43
3.2.1 Δεδομένα καρδιακού ρυθμού	43
3.2.2 Δεδομένα επιπέδων προσήλωσης από την επισημείωση των χρηστών	44
3.3 Επεξεργασία των δεδομένων καρδιακού ρυθμού	45
3.3.1 Εκκαθάριση και προεπεξεργασία δεδομένων καρδιακού ρυθμού	45
3.3.2 Χωρισμός των καταγραφών HRV σε χρονικά διαστήματα, με την χρήση επικαλυπτόμενων χρονικών παραθύρων παρακολούθησης	46
3.4 Ανάλυση δεδομένων καρδιακού ρυθμού	47
3.4.1 Χαρακτηριστικά στον τομέα του χρόνου	47

3.4.2 Χαρακτηριστικά στον τομέα της συχνότητας	48
3.5 Επεξεργασία και ανάλυση των δεδομένων επισημείωσης χρήστη	50
3.5.1 Προεπεξεργασία και χωρισμός των δεδομένων προσήλωσης του χρήστη σε χρονικά διαστήματα, με την χρήση επικαλυπτόμενων χρονικών παραθύρων παρακολούθησης	50
3.5.2 Ανάλυση δεδομένων προσήλωσης του χρήστη	50
3.5.3 Προετοιμασία δεδομένων προσήλωσης για δυαδική ταξινόμηση	51
3.6 Συσχέτιση εισόδου – εξόδου για τα μοντέλα μηχανικής μάθησης	51
Κεφάλαιο 4: Μέθοδοι Μηχανικής Μάθησης	53
4.1 Επιλογή και δημιουργία αλγορίθμου leave-one-out για cross validation	53
4.2 Επιλογή και χρήση αλγορίθμων μηχανικής μάθησης	54
Κεφάλαιο 5: Αποτελέσματα	61
5.1 Αποτελέσματα από την εκπαίδευση των μοντέλων μηχανικής μάθησης με όλους τους συμμετέχοντες	61
5.1.1 Αποτελέσματα με την χρήση της Μέσης Τιμής (Mean Value) των δεδομένων προσήλωσης, ως μετρικής εξόδου για χρονικά διαστήματα παρακολούθησης 10sec για όλους τους συμμετέχοντες	61
5.1.2 Αποτελέσματα με την χρήση της Περιοχής του Ίχνους (Area of the Annotation Trace) των δεδομένων προσήλωσης ως μετρικής εξόδου για χρονικά διαστήματα παρακολούθησης 10 sec για όλους τους συμμετέχοντες	64
5.1.3 Αποτελέσματα με την χρήση του Πλάτους (Amplitude) των δεδομένων προσήλωσης ως μετρικής εξόδου για χρονικά διαστήματα παρακολούθησης 30 sec, με 10 sec χρονική επικάλυψη για όλους τους συμμετέχοντες	68
5.2 Αποτελέσματα από την εκπαίδευση με επιλεγμένους συμμετέχοντες	71
5.2.1 Αποτελέσματα με την χρήση της Μέσης Τιμής (Mean Value) των δεδομένων προσήλωσης ως μετρικής εξόδου για χρονικά διαστήματα παρακολούθησης 10 sec στους επιλεγμένους συμμετέχοντες	71
5.2.2 Αποτελέσματα με την χρήση της Περιοχής του Ίχνους (Area of the Annotation Trace) των δεδομένων προσήλωσης ως μετρικής εξόδου για χρονικά διαστήματα παρακολούθησης 10 sec για τους επιλεγμένους συμμετέχοντες	75
5.2.3 Αποτελέσματα με την χρήση του Πλάτους (Amplitude) των δεδομένων προσήλωσης ως μετρικής εξόδου για χρονικά διαστήματα παρακολούθησης 30 sec, με 10 sec χρονική επικάλυψη, στους επιλεγμένους συμμετέχοντες	78
5.3 Σύγκριση των αποτελεσμάτων μεταξύ της εκπαίδευσης για όλους τους συμμετέχοντες και της εκπαίδευσης για επιλεγμένους συμμετέχοντες	82
Κεφάλαιο 6: Συζήτηση	84
6.1 Προβλήματα που παρουσιάστηκαν	84
6.2 Τρόποι επίλυσης των προβλημάτων που προέκυψαν κατά την πειραματική διαδικασία	85
6.3 Αναζήτηση μίας κοινής αρχής που να διέπει τα δεδομένα προσήλωσης των συμμετεχόντων που επιλέχθηκαν για εκπαίδευση, σε σύγκριση με αυτά των συμμετεχόντων που δεν επιλέχθηκαν	90
Κεφάλαιο 7: Επίλογος	92
7.1 Σύνοψη	92
7.2 Όρια και περιορισμοί	92

7.3 Μελλοντικές Προκλήσεις	93
<i>Κεφάλαιο 8: Βιβλιογραφία</i>	<i>94</i>

Ευρετήριο Εικόνων

Εικόνα 1: Γραφική αναπαράσταση της έννοιας ΠΣΣ.	21
Εικόνα 2: Σχέση τεχνολογίας-στοιχείων παιχνιδιού. Το βέλος υποδεικνύει την τεχνολογία που χρησιμοποιεί ο παίκτης για να αλληλοεπιδράσει με τα στοιχεία του παιχνιδιού.	23
Εικόνα 3: Τα ΠΣΣΥ «Express Cooking Train» (αριστερά) και «Wake Up for the Future!» (δεξιά).	25
Εικόνα 4: Στιγμιότυπα από το περιβάλλον εικονικής πραγματικότητας του παιχνιδιού «Pulse».	25
Εικόνα 5: Απεικόνιση της πολυπλοκότητας των ΠΣΣ.	27
Εικόνα 6: Παιχνιδοποίηση και Τεχνητή Νοημοσύνη.	28
Εικόνα 7: Οι εκφραστικοί AUs που εμπλέκονται στο συναίσθημα της χαράς, [15].	30
Εικόνα 8: Συναισθηματική Υπολογιστική και Νοημοσύνη.	31
Εικόνα 9: ΠΣΣ και Τεχνητή Νοημοσύνη: Προκλήσεις και Ευκαιρίες για την Υπολογιστική Κοινωνική Επιστήμη.	33
Εικόνα 10: Natural Language Processing με τη χρήση της Python για sentiment analysis.	36
Εικόνα 11: MKP ως μέσω αλληλεπίδρασης του συμπαθητικού με το ΠΝΣ.	38
Εικόνα 12: Ανάλυση MKP, μη επεμβατική μέθοδος αναγνώρισης παθήσεων.	40
Εικόνα 13: Σχηματική απεικόνιση της μεθόδου του διαχωρισμού σε χρονικά παράθυρα με την χρήση κυλιόμενων παραθύρων. Στο συγκεκριμένο παράδειγμα χρησιμοποιούνται χρονικά διαστήματα των 5 λεπτών με 1 λεπτό επικάλυψη.	47
Εικόνα 14: Γραφική απεικόνιση του τρόπου λειτουργίας του KNN Classifier.	54
Εικόνα 15: Γραφική αναπαράσταση του τρόπου λειτουργίας του Gaussian Naive Bayes Classifier.	55
Εικόνα 16: Γραφική αναπαράσταση της λειτουργίας της Logistic Regression Classifier.	55
Εικόνα 17: Γραφική αναπαράσταση του Decision Tree Classifier.	56
Εικόνα 18: Γραφική αναπαράσταση του τρόπου λειτουργίας του Random Forest Classifier.	56
Εικόνα 19: Γραφική αναπαράσταση του τρόπου λειτουργίας του SVM Classifier.	57
Εικόνα 20: Σχηματική αναπαράσταση της λειτουργίας του XGBoost Classifier.	57
Εικόνα 21: Σχηματική αναπαράσταση της λειτουργίας του MLP Classifier.	58
Εικόνα 22: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο KNN Classifier, με μετρική προσήλωσης την μέση τιμή των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec.	62
Εικόνα 23: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο GaussianNB Classifier, με μετρική προσήλωσης την μέση τιμή των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec.	62
Εικόνα 24: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο Logistic Regression Classifier, με μετρική προσήλωσης την μέση τιμή των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec.	62
Εικόνα 25: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο Decision Tree Classifier, με μετρική προσήλωσης την μέση τιμή των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec.	63
Εικόνα 26: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο Random Forest Classifier, με μετρική προσήλωσης την μέση τιμή των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec.	63
Εικόνα 27: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο SVM Classifier, με μετρική προσήλωσης την μέση τιμή των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec.	63

Ευρετήριο Πινάκων

Πίνακας 1: Παράδειγμα ανεπεξέργαστων δεδομένων καρδιακού ρυθμού.	44
Πίνακας 2: Παράδειγμα δεδομένων σχετικά με τα επίπεδα προσήλωσης από την επισημείωση των συμμετεχόντων στο παιχνίδι.	45
Πίνακας 3: Πίνακας αντιστοίχισης συναρτήσεων πρακτικού μέρους και αλγόριθμων μηχανικής μάθησης.	60
Πίνακας 4: Τιμές μετρικών όλων των μοντέλων μηχανικής μάθησης, με μετρική προσήλωσης την μέση τιμή των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec.	61
Πίνακας 5: Τιμές μετρικών όλων των μοντέλων μηχανικής μάθησης, με μετρική προσήλωσης την περιοχή του ίχνους των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec.	64
Πίνακας 6: Τιμές μετρικών όλων των μοντέλων μηχανικής μάθησης, με μετρική προσήλωσης το πλάτος των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 30 sec με χρονική επικάλυψη 10 sec.	68
Πίνακας 7: Τιμές τελικών μετρικών όλων των μοντέλων μηχανικής μάθησης, με μετρική προσήλωσης την μέση τιμή των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec στους επιλεγμένους συμμετέχοντες.	71
Πίνακας 8: Τιμές τελικών μετρικών όλων των μοντέλων μηχανικής μάθησης, με μετρική προσήλωσης την περιοχή του ίχνους των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec, στους επιλεγμένους συμμετέχοντες.	75
Πίνακας 9: Τιμές τελικών μετρικών όλων των μοντέλων μηχανικής μάθησης, με μετρική προσήλωσης το πλάτος των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 30 sec με χρονική επικάλυψη 10 sec στους επιλεγμένους συμμετέχοντες.	78
Πίνακας 10: Πίνακας αποτύπωσης της σύγκρισης μεταξύ της εκπαίδευσης για όλους τους συμμετέχοντες και της εκπαίδευσης ειδικά για τους επιλεγμένους με μετρική προσήλωσης την Μέση Τιμή των επισημειωμένων δεδομένων, για χρονικά διαστήματα παρακολούθησης 10 sec.	82
Πίνακας 11: Πίνακας αποτύπωσης της σύγκρισης μεταξύ της εκπαίδευσης για όλους τους συμμετέχοντες και της εκπαίδευσης ειδικά για του επιλεγμένους με μετρική προσήλωσης την Περιοχή του Ίχνους των επισημειωμένων δεδομένων, για χρονικά διαστήματα παρακολούθησης 10 sec.	82
Πίνακας 12: Πίνακας αποτύπωσης της σύγκρισης μεταξύ της εκπαίδευσης για όλους τους συμμετέχοντες και της εκπαίδευσης ειδικά για του επιλεγμένους με μετρική προσήλωσης το Πλάτος των επισημειωμένων δεδομένων, για χρονικά διαστήματα παρακολούθησης 30 sec, με χρονική επικάλυψη 10 sec.	83
Πίνακας 7: Πίνακας σύγκρισης μεταξύ των αλγορίθμων μηχανικής μάθησης για όλες τις μετρικές των μοντέλων, δειγματοληπτικά για τον συμμετέχοντα 4.	86
Πίνακας 8: Τιμές AUC παραγόμενες από τον XGBoost Classifier, για τους επιλεγμένους συμμετέχοντες.	87

Ευρετήριο Διαγραμμάτων

Διάγραμμα 1: Γραφική Αναπαράσταση της ανάπτυξης των ΠΣΣ στον ερευνητικό τομέα σύμφωνα με τις δημοσιεύσεις των ACM digital library and IEEE Xplore.	23
Διάγραμμα 2: Καμπύλες προσήλωσης για τους συμμετέχοντες που επιλέχθηκαν με τις καλύτερες τιμές AUC.	88
Διάγραμμα 3: Καμπύλες προσήλωσης για τους συμμετέχοντες που δεν επιλέχθηκαν διότι οι τιμές AUC ήταν μικρότερες του 0.55.	90

Κεφάλαιο 1: Εισαγωγή

1.1 Εισαγωγή στο αντικείμενο της Διπλωματικής Εργασίας

Βρισκόμαστε στο κατώφλι του 21^{ου} αιώνα, η επιστήμη της υγείας στρέφεται προς έναν πιο ανθρωποκεντρικό χαρακτήρα με γνώμονα την πρόγνωση, την πρόληψη και την εξατομικευμένη και συμμετοχική φροντίδα των ασθενών (P4 medicine) [1]. Σε αυτή την τεχνολογική εξέλιξη οι επαγγελματίες στον τομέα της υγείας και οι ασθενείς καλούνται να αλληλοεπιδράσουν με σύγχρονες τεχνολογίες που στοχεύουν στην μοναδικότητα του κάθε ατόμου και στην εξειδίκευση ή στη σε βάθος ίαση. Η παραπάνω προσέγγιση εισάγει από την μία πλευρά την συνεχή κατάρτιση και εκπαίδευση των επαγγελματιών και από την άλλη πλευρά την βελτίωση της ποιότητας ζωής των ατόμων υιοθετώντας καλύτερες καθημερινές συνήθειες. Σημαντική προσθήκη στην τεχνολογική εξέλιξη στον τομέα της υγείας αποτελεί και η χρήση σύγχρονων τεχνολογιών, για την αποκατάσταση χρόνιων ασθενειών και παθήσεων.

Όλα τα παραπάνω μπορούν να πραγματοποιηθούν με εργαλεία όπως είναι η συλλογή και η διαχείριση πληροφοριών υγείας, ο ψηφιακός φάκελος ασθενούς, η παρακολούθηση ασθενειών καθώς και οι έξυπνες συσκευές τηλεϊατρικής [2], σε συνδυασμό με παρεμβάσεις όπως τα ΠΣΣΥ και τεχνολογίες αιχμής όπως η συναισθηματική υπολογιστική νοημοσύνη (ΣΥΝ). Η ΣΥΝ αφορά ένα διεπιστημονικό γνωστικό υπόβαθρο ψυχολογίας, γνωστικής, φυσιολογίας και επιστημών υπολογιστών [3]. Στην παρούσα Διπλωματική Εργασία αξιοποιούνται εργαλεία και καινοτόμες τεχνολογίες, όπως είναι η χρήση ΠΣΣΥ, η καταγραφή δεδομένων μέσω αισθητήρων που αφορούν την ΜΚΡ, καθώς και η παρακολούθηση και ανάλυση επιπέδων προσήλωσης, μέσω ΣΥΝ. Η αναζήτηση της αρχής που διέπει την ΜΚΡ με τα επίπεδα προσήλωσης πραγματοποιείται μέσω εκπαίδευσης μοντέλων μηχανικής μάθησης.

Η παρούσα Διπλωματική Εργασία και η συλλογή των δεδομένων που αξιοποιούνται στην παρούσα έρευνα πραγματοποιήθηκαν και συλλέχθηκαν στο Εθνικό Μετσόβιο Πολυτεχνείο και συγκεκριμένα στο Εργαστήριο Βιοϊατρικών Προσομοιώσεων και Απεικονιστικής Τεχνολογίας (BioSim Laboratory), με την πολύτιμη επίβλεψη και βοήθεια του Διδάκτορα Κωνσταντίνου Μήτση και της Καθηγήτριας Κωνσταντίνας Νικήτα, τους οποίους και ευχαριστώ από καρδιάς.

1.2 Στόχος της Διπλωματικής Εργασίας

Στόχος της παρούσας Διπλωματικής Εργασίας είναι η κατανόηση και επεξεργασία των δεδομένων που προκύπτουν από την καταγραφή του αισθητήρα καρδιάς Pulse, αλλά και των δεδομένων προσήλωσης των συμμετεχόντων μέσω της υποκειμενικής επισημείωσής τους, όπως επίσης και η εκτενής βιβλιογραφική έρευνα

σε έννοιες που αφορούν τα ΠΣΣΥ, τη ΣΥΝ και την Τεχνητή Νοημοσύνη, τη ΜΚΡ, ως παρεμβάσεις για την υγεία. Τα δεδομένα συλλέγονται, μέσω της αλληλεπίδρασης των συμμετεχόντων με ΠΣΣΥ, εισάγοντας την ΣΥΝ ως μέσω παρέμβασης στον τομέα της υγείας. Εν συνεχεία ως κύριος σκοπός της παρούσας έρευνας αναδεικνύεται η ενασχόληση και η εκπαίδευση αλγορίθμων μηχανικής μάθησης, καθώς και η ανεύρεση τρόπων βελτιστοποίησης των μετρικών των μοντέλων για την εξαγωγή πιο αξιόπιστων αποτελεσμάτων. Σημαντικό ενδιαφέρον παρουσιάζει, η κατανόηση και η ανάλυση των δεδομένων που προκύπτουν από τα μοντέλα για την επεξήγηση και την ανεύρεση μίας αρχής που να διέπει τη ΜΚΡ με τα επίπεδα προσήλωσης ενός ατόμου. Στο Κεφάλαιο 7 της Διπλωματικής Εργασίας παρουσιάζονται μελλοντικές επεκτάσεις των θεμάτων που πραγματεύονται, καθώς και περιορισμοί που πιθανώς να προκύπτουν.

1.3 Οργάνωση της Διπλωματικής Εργασίας

Η παρούσα Διπλωματική Εργασία οργανώνεται, σε πέντε βασικούς πυλώνες που είναι τα Κεφάλαια 2, 3, 4, 5 και 6, στο Κεφάλαιο 7 που αποτελεί τον επίλογο και στο Κεφάλαιο 8 που συνοψίζεται η βιβλιογραφία που χρησιμοποιήθηκε κατά την βιβλιογραφική έρευνα.

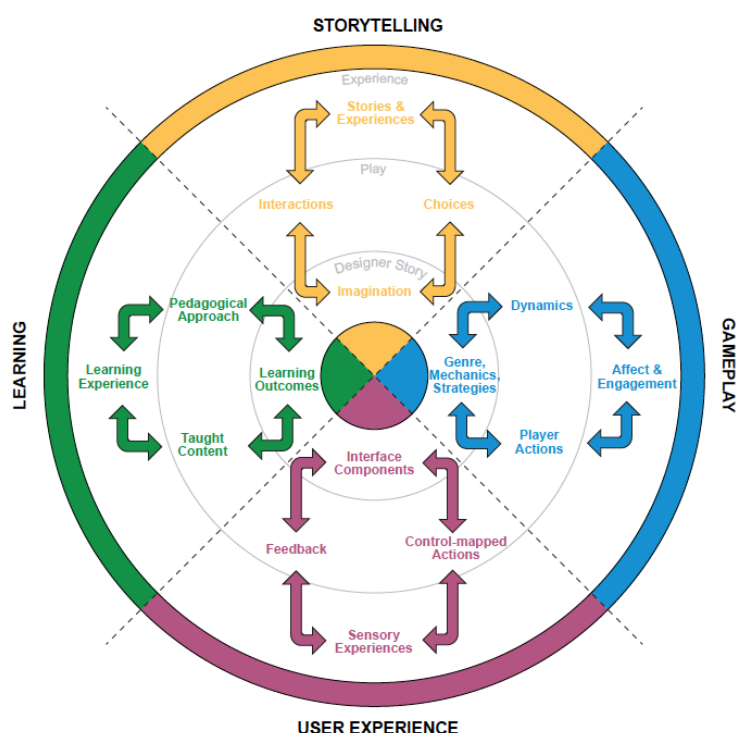
- **Κεφάλαιο 2 – Θεωρητικό Υπόβαθρο:** Θεωρητική ανάλυση των εννοιών: ΠΣΣΥ, ΣΥΝ και Τεχνητή Νοημοσύνη, ΜΚΡ, ως παρεμβάσεις για την υγεία.
- **Κεφάλαιο 3 – Μεθοδολογία:** Εισαγωγή στο πρακτικό μέρος της παρούσας Διπλωματικής Εργασίας, αναλύεται η μεθοδολογία που ακολουθήθηκε για την επεξεργασία, ανάλυση και προετοιμασία των δεδομένων ΜΚΡ, καθώς και των δεδομένων που επισημαίνουν οι συμμετέχοντες για την προσήλωσή τους.
- **Κεφάλαιο 4 – Μέθοδοι Μηχανικής Μάθησης:** Κεντρικό μέρος του πρακτικού μέρους της Διπλωματικής Εργασίας, παρουσίαση αλγορίθμων μηχανικής μάθησης, εξαγωγή μετρικών των αλγορίθμων που χρησιμοποιήθηκαν.
- **Κεφάλαιο 5 – Αποτελέσματα:** Παρουσίαση των τελικών αποτελεσμάτων με αντίστοιχους πίνακες και γραφήματα.
- **Κεφάλαιο 6 – Συζήτηση:** Σύνοψη, επεξήγηση και ανάλυση των αποτελεσμάτων που ελήφθησαν από την πειραματική διαδικασία, παρουσίαση προβλημάτων που παρουσιάστηκαν και τρόπων επίλυσής τους.
- **Κεφάλαιο 7 - Επίλογος:** Παρουσίαση μελλοντικών προκλήσεων και αναφορά των περιορισμών της παρούσας έρευνας.
- **Κεφάλαιο 8 – Βιβλιογραφία:** Σύνοψη της βιβλιογραφίας που μελετήθηκε και χρησιμοποιήθηκε στην παρούσα έρευνα της Διπλωματικής Εργασίας.

Κεφάλαιο 2: Θεωρητικό Υπόβαθρο

2.1 Παιχνίδια σοβαρού ως παρεμβάσεις για την υγεία

2.1.1 Παιχνίδια σοβαρού σκοπού (ΠΣΣ)

Τι είδους παιχνίδια μπορούν να θεωρηθούν ΠΣΣΥ; Ο Παγκόσμιος Οργανισμός Υγείας, όρισε την υγεία με την ευρύτερη έννοιά της ως μια κατάσταση πλήρους σωματικής, ψυχικής και κοινωνικής ευεξίας και όχι απλώς ως την απουσία ασθένειας ή αναπηρίας. Άλλοι ορισμοί απαιτούν απλώς την απαλλαγή από την ασθένεια ή τον τραυματισμό. Εάν χρησιμοποιήσουμε τον πιο αυστηρό ορισμό, μπορούμε να εξετάσουμε μόνο παιχνίδια που αφορούν τις διάφορες φάσεις ανάπτυξης της ασθένειας, τόσο για την εκπαίδευση των επαγγελματιών υγείας, όσο και για την εξοικείωσή του ασθενούς με την ασθένειά του [4]. Με τον όρο ΠΣΣ, ορίζεται το σύνολο των παιχνιδιών τα οποία είναι κατασκευασμένα για ποικίλους σκοπούς που δεν αφορούν αποκλειστικά την ψυχαγωγία και την εκτόνωση των χρηστών. Πιο συγκεκριμένα, τα ΠΣΣ υιοθετούν πολλά χαρακτηριστικά και λειτουργίες των ηλεκτρονικών παιχνιδιών, ωστόσο ο κύριος σκοπός αυτών, αφορά την επιστημονική εξερεύνηση, την διαχείριση έκτακτης ανάγκης, την εκπαίδευση επαγγελματιών, την ευαισθητοποίηση, την αποκατάσταση, την παρακολούθηση και την διάγνωση ασθενειών, την προώθηση αλλαγών συμπεριφοράς στον τρόπο ζωής αλλά και την διαχείριση της ψυχικής υγείας [5].



Εικόνα 1: Γραφική αναπαράσταση της έννοιας ΠΣΣ.


Τα ΠΣΣ αποτελούν μια ειδική κατηγορία ενός αφηγηματικού περιεχομένου, στο οποίο η αφήγηση βασίζεται στην ακολουθία μοτίβων υψηλής ποιότητας, αποτελώντας μέρος μιας στοχαστικής διαδικασίας εκτός από το πλαίσιο της ψυχαγωγίας. Η ιδέα πίσω από την δημιουργία ενός τέτοιου παιχνιδιού στηρίζεται κυρίως στην προσομοίωση και την εισαγωγή του χρήστη σε ένα σενάριο της καθημερινότητας, κάνοντας αισθητή την παιδαγωγική αξία της διασκέδασης και του ανταγωνισμού [6]. Η προσέγγιση πως μέσω ενός παιχνιδιού γίνεται άντληση ποικίλων πληροφοριών αλλά και εκμάθηση σε διάφορες κατευθύνσεις, ανάλογα τον χρήστη που αλληλοεπιδρά με το εκάστοτε παιχνίδι, δίνει έναν πιο ανθρωποκεντρικό χαρακτήρα στα ηλεκτρονικά παιχνίδια. Ειδικότερα, το παιχνίδι είναι δυναμικό και παραμετροποιήσιμο στα μέτρα και τις ικανότητες του εκάστοτε χρήστη, πρωταγωνιστής είναι το άτομο και το παιχνίδι προσαρμόζεται σε δυσκολία με βάση τα ερεθίσματα που λαμβάνει από το χρήστη. Τα ερεθίσματα λαμβάνονται από το παιχνίδι κατά την αλληλεπίδραση του συμμετέχοντα με αυτό, η δυσκολία των επιπέδων είναι κλιμακούμενη και η διαδοχή των επιπέδων γίνεται ομαλά, βελτιστοποιώντας με αυτό τον τρόπο την εμπειρία, την αποδοτικότητα και την συμμετοχή του ατόμου στο παιχνίδι. Αποτέλεσμα επομένως, ενός καλοφτιαγμένου ΠΣΣ με έμφαση στη λεπτομέρεια αλλά και στους μηχανισμούς αλληλεπίδρασης με το άτομο, είναι η δημιουργία ενός περιβάλλοντος στο οποίο ο χρήστης εξοικειώνεται εύκολα με τους μηχανισμούς, αυξάνοντας με τον τρόπο αυτό, τα επίπεδα προσήλωσης και αποδοτικότητας του συμμετέχοντα.

Στο πλαίσιο αυτής της διπλωματικής εργασίας, θα γίνει μια σε βάθος ανάλυση για την συμβολή των ΠΣΣΥ στον τομέα της υγείας ως μέσο εκπαίδευσης, ευαισθητοποίησης, παρακολούθησης, πρόληψης αλλά και αποκατάστασης ασθενειών.

2.1.2 Εφαρμογές ΠΣΣ στον τομέα της υγείας


Η είσοδος των ΠΣΣ στο τομέα της υγειονομικής περίθαλψης, παρουσιάζει ιδιαίτερο ενδιαφέρον, καθώς αποτελεί ένα νέο εκπαιδευτικό εργαλείο και όχι μόνο, με ποικίλα πλεονεκτήματα. Χαρακτηριστικά θα αναφερθεί ότι η διαδραστική μάθηση μέσω παιχνιδιών, είναι πιο εύληπτη και διασκεδαστική για τους επαγγελματίες της υγείας, σε σύγκριση με τον παραδοσιακό τρόπο εκμάθησης, αποδεσμεύοντας τους από τον κίνδυνο του λάθους και ενισχύοντας την διαρκή εξάσκηση σε πραγματικά σενάρια.

Τα ΠΣΣΥ μπορούν να διακριθούν σε δύο μεγάλες κατηγορίες. Σε αυτά που αφορούν τους ασθενείς (serious games for patients) και αυτά που αφορούν τους όχι ασθενείς (serious games for non-patients) [4].



Διάγραμμα 1: Γραφική Αναπαράσταση της ανάπτυξης των ΠΣΣ στον ερευνητικό τομέα σύμφωνα με τις δημοσιεύσεις των ACM digital library and IEEE Xplore.

Στην πρώτη κατηγορία διακρίνουμε πέντε υποκατηγορίες, βασισμένες στη χρήση του κάθε παιχνιδιού: α) Η παρακολούθηση της υγείας: τα παιχνίδια αυτά στοχεύουν στην παρακολούθηση των βίο-σημάτων του ασθενούς, όπως είναι το σύστημα τηλε-διαχείρισης καρδιακής ανεπάρκειας. β) Η ανίχνευση: αφορά την εστίαση στην ανάλυση και τον εντοπισμό συμπτωμάτων τους ασθενούς, για παράδειγμα το «Unobtrusive Health», σοβαρό παιχνίδι που βασίζεται σε EEG, και το «PlayWithEyes». γ) Η μεταχείριση και η θεραπεία ενός προβλήματος υγείας, όπως είναι η διάγνωση και η διαχείριση του Parkinson και των διαταραχών που σχετίζονται με τις κοινωνικές δεξιότητες και τον λόγο. δ) Η αποκατάσταση της υγείας και των καθημερινών δεξιοτήτων μετά από ασθένειες, όπως είναι η νευρο-ψυχολογική αποκατάσταση, η αποκατάσταση χρόνιου πόνου και η αποκατάσταση άνω άκρου μετά από εγκεφαλικό. ε) Η εκπαίδευση και η αυτοκατευθυνόμενη φροντίδα: αφορά την αύξηση της κατανόησης της ασθένειας ή του προβλήματος υγείας και την εκμάθηση της αποκατάστασης μέσω του παιχνιδιού. Μερικά παραδείγματα παιχνιδιών, είναι το «Re-Mission», ένα ΠΣΣΥ που αφορά τον διαβήτη. Η εκπαίδευση μπορεί να αφορά και την εκμάθηση πρώτων βοηθειών για άτομα που βρίσκονται στο φάσμα του αυτισμού ή γνωστική εξάσκηση για την νόσο του Alzheimer [4].



Εικόνα 2: Σχέση τεχνολογίας-στοιχείων παιχνιδιού. Το βέλος υποδεικνύει την τεχνολογία που χρησιμοποιεί ο παίκτης για να αλληλοεπιδράσει με τα στοιχεία του παιχνιδιού.

Στην δεύτερη κατηγορία, βρίσκονται τα ΠΣΣΥ που αφορούν τους όχι ασθενείς, τα παιχνίδια αυτά θα μπορούσαν να ονομαστούν και παιχνίδια υγείας και ευεξίας, καθώς επικεντρώνονται κυρίως σε θέματα τρόπου ζωής και στις σχέσεις με την λειτουργική υγεία. Σύμφωνα με τη μελέτη που διεξήχθη στην Alameda, προτάθηκαν λύσεις που μπορούν να βελτιώσουν την ποιότητα ζωής μέσω της άσκησης, του ύπνου, της διατήρησης υγιούς σωματικού βάρους, του περιορισμού του αλκοόλ, και της αποφυγής του καπνίσματος. Μερικά παραδείγματα παιχνιδιών που πραγματεύονται τις παραπάνω έννοιες είναι: το παιχνίδι «Sensory gate-ball», το «Dancing in the streets», το «Virku» και το «Mo-Fun Circus» [4].

Οι υποκατηγορίες που δομούν τη δεύτερη κατηγορία, είναι οι εξής: α) Τα παιχνίδια εκπαίδευσης και προσομοίωσης, δηλαδή ΠΣΣΥ που χρησιμοποιούνται ως εργαλεία μάθησης και εξάσκησης για επαγγελματίες υγείας. Μερικά παραδείγματα είναι το «HumanSim» ένα εικονικό πρόγραμμα προσομοίωσης οδοντικών εμφυτευμάτων, το παιχνίδι «Pulse» ένα εικονικό εργαστήριο κλινικής εκμάθησης και ιατρικών υπηρεσιών έκτακτης ανάγκης για άτομα με ειδικές ανάγκες και το «Play&Care» για εκπαίδευση φοιτητών ιατρικής με μεθόδους διαφορικής διάγνωσης. β) Παιχνίδια εκπαίδευσης και προσομοίωσης για μη επαγγελματίες, δηλαδή παιχνίδια που χρησιμοποιούνται από άτομα, όχι άμεσα εμπλεκόμενα με το χώρο της υγείας, για να μάθουν και να βελτιωθούν στην υγειονομική περιθάλψη. Σε αυτή την ομάδα ανήκουν παιχνίδια όπως το «Fatworld», το «The food detectives fight Back!», το «Nutri-trainer» για την σωστή και υγιεινή στάση απέναντι στο φαγητό αλλά ακόμα και παιχνίδια εκπαίδευσης για την υγιεινή των χεριών [4].

Σχετικά με την δεύτερη κατηγορία που αναφέρθηκε παραπάνω αξίζει να γίνει αναφορά σε δύο ακόμα ΠΣΣΥ, που έχουν αναπτυχθεί στο Εργαστήριο Βιοϊατρικών Προσομοιώσεων και Απεικονιστικής Τεχνολογία του Εθνικού Μετσοβίου Πολυτεχνείου (BioSim, NTUA) τα οποία είναι τα «Wake Up for the Future!» και το «Express Cooking Train». Όσον αφορά το πρώτο, πρόκειται για ένα ΠΣΣΥ που απευθύνεται σε ενήλικες, το οποίο στοχεύει στην ευαισθητοποίηση και την προώθηση της διαχείρισης αυτοασθενειών σχετιζόμενες με την αποφρακτική άπνοια ύπνου (ΑΑΥ). Η ΑΑΥ αποτελεί την πιο διαδεδομένη διαταραχή της αναπνοής που σχετίζεται με τον ύπνο [7]. Όσον αφορά το δεύτερο ΠΣΣΥ με όνομα «Express Cooking Train», ο χρήστης αναλαμβάνει τον έλεγχο ενός τρένου που ταξιδεύει σε μετα-αποκαλυπτικό περιβάλλον. Το ταξίδι του τρένου χαρακτηρίζεται επικίνδυνο εξαιτίας της παρουσίας τεράτων τα οποία βασίζονται αποκλειστικά σε μία κακή διατροφή γεμάτη επεξεργασμένα, «άχρηστα» τρόφιμα. Το παιχνίδι πραγματεύεται την υιοθέτηση πιο υγιεινών συνηθειών που αφορούν το φαγητό και την διατροφή, προσομοιώνοντας το περιβάλλον μιας κουζίνας [8]. Το ΠΣΣΥ «Express Cooking Train» χρησιμοποιείται ως παιχνίδι αλληλοεπίδρασης για του συμμετέχοντες στο πρακτικό μέρος της παρούσας Διπλωματικής Εργασίας.



Εικόνα 3: Τα ΠΣΣΥ «Express Cooking Train» (αριστερά) και «Wake Up for the Future!» (δεξιά).



Εικόνα 4: Στιγμιότυπα από το περιβάλλον εικονικής πραγματικότητας του παιχνιδιού «Pulse».

Γίνεται κατανοητό επομένως, πως τα ΠΣΣ αποτελούν ένα εν δυνάμει ικανότατο εργαλείο, το οποίο μπορεί να προσφέρει τεράστια εξέλιξη στον τομέα της εξ αποστάσεως μάθησης, εκπαίδευσης και εξειδίκευσης. Ακόμα αποτελούν ικανό εργαλείο για την πρόληψη, ανίχνευση, ίαση και αποκατάσταση ασθενειών. Τα πλεονεκτήματα που προκύπτουν από την εφαρμογή νέας τεχνολογίας, σε διάφορους τομείς όπως είναι ο τομέας της ιατρικής περίθαλψης, είναι αντιληπτά τόσο στους επαγγελματίες της υγείας όσο και στους ασθενείς. Το ενδιαφέρον όλο και περισσότερων ατόμων να εμπλακούν με τον κλάδο των ΠΣΣ, είναι συνεχώς αυξανόμενο και μπορεί να επιφέρει ακόμα περισσότερα θετικά αποτελέσματα, πάντοτε με επίκεντρο τον άνθρωπο.

Κρίνεται ωστόσο απαραίτητη η σωστή αξιολόγηση, η διαρκής αναβάθμιση και η συνεχής ενασχόληση τόσο με τον τομέα της ανάπτυξης του παιχνιδιού όσο και του σχεδιασμού του, έτσι ώστε να μπορεί να γίνει λόγος για ποιοτική μάθηση, εξειδίκευση και πρόληψη.

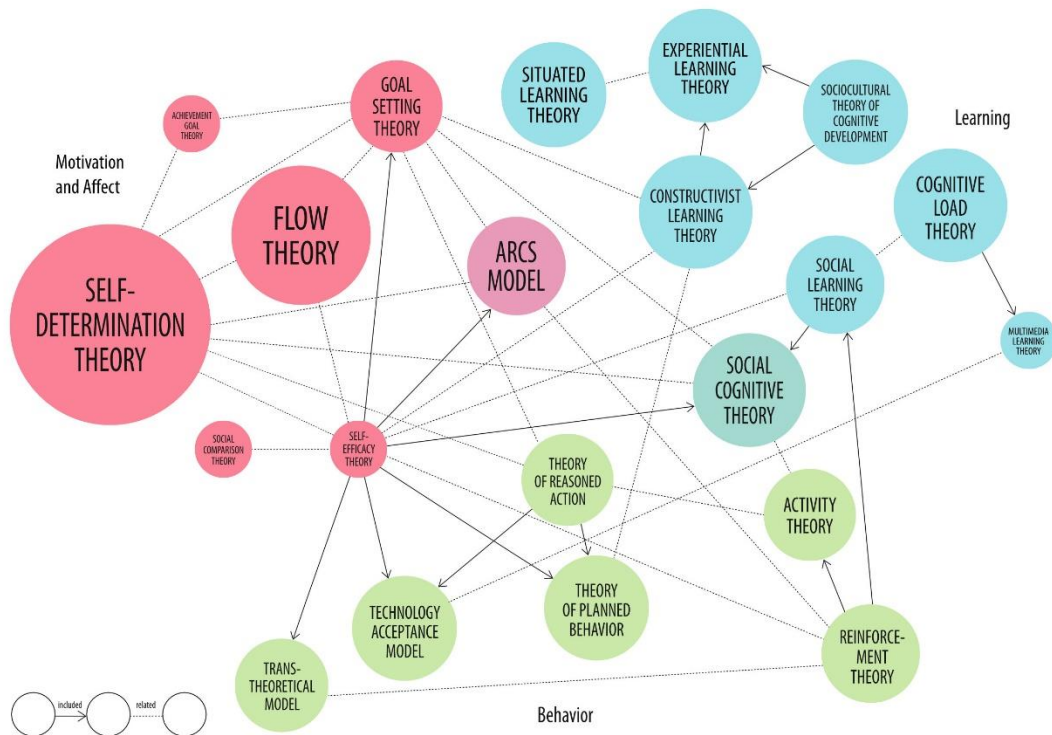
2.1.3 Αξιολόγηση ΠΣΣ

Τα ΠΣΣ έχουν αναγνωριστεί ως αποτελεσματικά μέσα εκπαίδευσης, αύξησης της ευαισθητοποίησης και σωματικής αποκατάστασης, οδηγώντας σε αλλαγές στον τρόπο ζωής, ενώ ταυτόχρονα προσελκύουν και διασκεδάζουν τον χρήστη. Με βάση

τα ευρήματα μιας πρόσφατα δημοσιευμένης βιβλιογραφικής ανασκόπησης, η αποτελεσματικότητα των ΠΣΣ βασίζεται σε έναν σχεδιασμό που βασίζεται στη θεωρία. Η πιο συχνά χρησιμοποιούμενη θεωρητική βάση είναι η Κοινωνική Γνωσιακή Θεωρία (ΚΓΘ). Πρέπει να τονιστεί ότι μόνο ένας μικρός αριθμός (5%) των παρεμβάσεων απευθύνεται σε ενήλικες. Αν και τα περισσότερα ΠΣΣ (68%) διαθέτουν κάποια μορφή αφήγησης, τα είδη παιχνιδιών διαφέρουν πολύ. Ο σχεδιασμός του παιχνιδιού, θα πρέπει να δομηθεί με βάση ένα εννοιολογικό πλαίσιο που λαμβάνει υπόψη την εμπειρία και την αλληλοεπίδραση του χρήστη[8].

Τα ΠΣΣ, αναπτύσσονται με στόχο να έχουν κάποιο αντίκτυπο στους εμπλεκόμενους στο παιχνίδι, πέρα της απλής ψυχαγωγίας. Η εκπαίδευση των επαγγελματιών υγείας είναι πρωταρχικής σημασίας για την ασφάλεια των ασθενών. Σε ορισμένα επαγγέλματα που σχετίζονται με την υγεία, η εκπαίδευση και η κατάρτιση πρέπει να ασκούνται καθ' όλη τη διάρκεια της εργασιακής περιόδου και όχι να περιορίζονται στα σχολεία και τα πανεπιστήμια. Η χρήση νέας τεχνολογίας όπως είναι η εικονική ή η επαυξημένη πραγματικότητα και η μηχανική μάθηση, φέρνει νέες δυνατότητες βελτίωσης στα μαθησιακά αποτελέσματα. Η είσοδος των ΠΣΣ, στον τομέα της υγειονομικής περίθαλψης, εισάγει μια τεχνολογία που μπορεί να εκπαιδεύσει ενώ ψυχαγωγεί τους χρήστες. Αυτός ο τύπος εκπαίδευσης μπορεί να είναι πολύ χρήσιμος για τα επαγγέλματα υγείας, καθώς βελτιώνει τα μαθησιακά αποτελέσματα δημιουργώντας μια προσέγγιση προσανατολισμένη στον μαθητή [9].

Για την βέλτιστη αξιολόγηση και κριτική των ΠΣΣ σχετικά με το μαθησιακό αποτύπωμά τους, προτείνεται να γίνει χρήση του μοντέλου του Kirkpatrick. Το συγκεκριμένο μοντέλο κινείται σε τέσσερις βασικούς πυλώνες οι οποίοι είναι: α) ο βαθμός θετικής αντίδρασης των συμμετεχόντων στη μάθηση, β) ο βαθμός της επιδιωκόμενης γνώσης και των δεξιοτήτων των συμμετεχόντων, γ) η συμπεριφορά του διδασκόμενου και δ) ο βαθμός των στοχευμένων αποτελεσμάτων που προκύπτουν ως αποτέλεσμα της μάθησης. Για την μέτρηση της αντίδρασης των συμμετεχόντων στο παιχνίδι, προτείνεται, μετά το πέρας του παιχνιδιού η κατάθεση υποκειμενικής αναφοράς σχετικά με δεδομένα που αφορούν τον βαθμό προσήλωσης του εμπλεκόμενου, την συμμετοχικότητα του και το αίσθημα διασκέδασης και ψυχαγωγίας. Όσον αφορά στα επίπεδα μόρφωσης και εκπαίδευσης, αρκεί μία σύντομη εξέταση γνώσεων πριν και μετά το πέρας του παιχνιδιού, έτσι ώστε να γίνει αντιληπτό πού το παιχνίδι είναι εύληπτο και πού χρειάζεται βελτίωση. Η συμπεριφορά των συμμετεχόντων κατά τη διάρκεια του παιχνιδιού, μπορεί να εκτιμηθεί από ειδικούς με απλή παρατήρηση, με στόχο την βελτίωση του παιχνιδιού για την αύξηση των επιπέδων προσήλωσης. Σχετικά με τα αποτελέσματα, οι συμμετέχοντες μπορούν να δώσουν μια αρκετά ικανοποιητική εικόνα για την επιδοσή τους και για το αίσθημα σιγουριάς που αποπνέει το παιχνίδι λαμβάνοντας υπόψη τις δεξιότητές τους.



Εικόνα 5: Απεικόνιση της πολυπλοκότητας των ΠΣΣ.

Γίνεται κατανοητό επομένως, πως η σωστή και σαφής αξιολόγηση είναι απαραίτητη για την δημιουργία ενός ΠΣΣΥ. Το παιχνίδι χρήζει άριστης λεπτομέρειας και σχεδίασης, χωρίς αυτό να καθιστά υποχρεωτική την πολύπλοκη κατασκευή του. Απαραίτητο για την σωστή αξιολόγηση του παιχνιδιού είναι ο συμμετέχων δηλαδή, ο παίχτης, ο ασθενής ή ο επαγγελματίας υγείας, που θα δώσει σωστή ανατροφοδότηση και κριτική για τους μηχανισμούς, το γνωσιακό εύρος που καλύπτει το παιχνίδι καθώς και τα αποτελέσματα που έχει στον εμπλεκόμενο μετά από κάποιο χρονικό όριο αλληλεπίδρασης με αυτό. Επιπρόσθετα, καλό είναι να αναφερθεί πως τα ΠΣΣ εκτός από τον εύληπτο χαρακτήρα που θα πρέπει να διαθέτουν, σημαντικό είναι να προκαλούν το άτομο να παίζει και να μην δημιουργούν το αίσθημα της πλήξης.

2.1.4 Μελλοντικές προκλήσεις των παιχνιδιών ΠΣΣΥ

Παρατηρήθηκε ότι οι τομείς υγείας που ωφελούνται περισσότερο από τη χρήση των ΠΣΣΥ, ως εργαλείο μάθησης και εκπαίδευσης, είναι συνήθως εκείνοι στους οποίους οι διαδικασίες είναι απλούστερες και οι παιχνιδοποιημένες εφαρμογές μπορούν να κατασκευαστούν χωρίς υψηλές ανάγκες σχεδιασμού. Οι διαδικασίες αποκατάστασης από παθήσεις, τραυματισμούς και μακροχρόνιες ασθένειες είναι ένα γόνιμο πεδίο για την ανάπτυξη των σοβαρών παιχνιδιών, καθώς ορισμένα πρωτόκολλα εύκολα αναπτύσσονται και δεν απαιτούν πολύπλοκες διεργασίες. Ωστόσο άλλες διαδικασίες στον τομέα της υγείας, όπως οι χειρουργικές επεμβάσεις και οι επεμβατικές διαδικασίες, είναι εργασίες που χαρακτηρίζονται από μια σειρά ενεργειών που απαιτούν ακριβή εκτέλεση και για το λόγο αυτό, δεν έχουν διερευνηθεί περαιτέρω από τη βιβλιογραφία. Για να υπάρξει αποτελεσματικότητα, απαιτείται

υψηλός βαθμός ρεαλισμού, σε συνδυασμό με τη χρήση συσκευών ικανών να παρέχουν απτικές αισθήσεις όμοιες με αυτές που παρατηρούνται σε πραγματικές διαδικασίες. Οι περισσότερες γενικές συσκευές απτικής εικονικής πραγματικότητας, δεν παρέχουν ρεαλισμό, καθώς η προσομοίωση αυτών των διαδικασιών απαιτεί μοντελοποίηση αντικειμένων και αλγορίθμων για τον ακριβή εντοπισμό των ενεργειών. Επιπρόσθετα, απαίτηση για τα ΠΣΣΥ αποτελεί και η υψηλή ισχύς επεξεργασίας. Αυτά τα θέματα, αποτελούν προκλήσεις που δεν έχουν ξεπεραστεί ακόμα, αποτελώντας ενδιαφέρουσες ερευνητικές πτυχές [10].



Εικόνα 6: Παιγνιδοποίηση και Τεχνητή Νοημοσύνη.

Τα ΠΣΣΥ, μαζί με την καινοτόμα τεχνολογία που διαθέτουν, χαρακτηρίζονται και από γεγονότα τα οποία κρίνουν τον τομέα αυτόν ως όχι πλήρως λειτουργικό ακόμα. Οι περισσότερες μελέτες, δεν έχουν σαφώς καθορισμένες ομάδες ελέγχου και δεν εφάρμοσαν ή/και στερούνταν θεωρίας για την κατανόηση των υποκείμενων διεργασιών, όπως αναφέρεται και σε σχετική έρευνα για τις ελλείψεις που παρουσιάζονται σε εφαρμογές για την υγεία [11]. Η μελλοντική έρευνα γύρω από τα ΠΣΣΥ, θα πρέπει να αποσαφηνίσει πλήρως τους μηχανισμούς που διέπουν τις παιγνιδοποιημένες εκπαιδευτικές παρεμβάσεις και να διερευνήσει τη θεωρία που θα μπορούσε να εξηγεί τα αποτελέσματα των μαθησιακών και όχι μόνο παρεμβάσεων, μέσω των παιχνιδιών. Οι καλά καθορισμένες ομάδες ελέγχου, καθώς και η πλαισίωση των μηχανισμών των ΠΣΣΥ από καλά τεκμηριωμένη θεωρία, θα μπορέσουν να δώσουν μια πιο ολοκληρωμένη κατανόηση του τρόπου επιλογής των βέλτιστων στοιχείων κάθε παιχνιδιού, για το σωστό εκπαιδευτικό πλαίσιο και για τον σωστό τύπο μαθητευόμενου [12].

2.2 Συναισθηματική Υπολογιστική και Νοημοσύνη

2.2.1 Τεχνητή νοημοσύνη και συναισθήματα

Στο υποκεφάλαιο αυτό θα γίνει έρευνα αλλά και ανάλυση του κλάδου που ονομάζεται ΣΥΝ, της σχέσης που έχει ο τομέας αυτός με την τεχνητή νοημοσύνη, των εφαρμογών της στο χώρο της υγείας αλλά και το πώς οι παραπάνω έννοιες συνδέονται με τα ΠΣΣΥ.

Είναι γεγονός πως η τεχνητή νοημοσύνη παρουσιάζει ραγδαία ανάπτυξη τον τελευταίο καιρό. Εφαρμογές τεχνητής νοημοσύνης παρατηρούνται σε διάφορες πτυχές της καθημερινότητας και περιλαμβάνουν ένα εκτενές πλήθος ενεργειών που εκτελούνται με μεγαλύτερη ευκολία όπως είναι η αναζήτηση στο διαδίκτυο, τα αυτοκινούμενα οχήματα, η αναγνώριση φωνητικών εντολών και άλλα [13].

Οι περισσότερες μελέτες σχετικά με την έρευνα συναισθημάτων και συμπεριφορών, που εστιάζουν κυρίως στην εκπαίδευση, έχουν συλλέξει δεδομένα χρησιμοποιώντας παρατηρητική (βάσει αναλύσεων ειδικών), δηλωτική (με βάση την επισημείωση των χρηστών) ή και συνδυασμό των δύο αυτών μεθόδων. Οι στρατηγικές αυτές, παρουσιάζουν ορισμένα πλεονεκτήματα όπως το χαμηλό κόστος και η ευέλικτη εφαρμογή τους, στη διδασκαλία και τη μάθηση, ωστόσο παρουσιάζουν και σημαντικούς περιορισμούς. Όσον αφορά στις μεθόδους παρατήρησης, η παρατήρηση της έντασης των συναισθημάτων απαιτεί εκπαίδευση, με σκοπό τον προσδιορισμό των «εκφραστικών μονάδων δράσης» (expressive Action Units, eAU), που χαρακτηρίζουν τις κινήσεις του προσώπου. Με σκοπό να γίνει σωστή επισήμανση των eAUs, είναι απαραίτητο να έχει προηγηθεί εκτενής εκπαίδευση και εξάσκηση. Όσον αφορά στις δηλωτικές μεθόδους, παραμένει ασαφές εάν οι συμμετέχοντες είναι σε θέση να αντιληφθούν σωστά τα συναισθήματά τους ή εάν βασίζονται οι απαντήσεις τους στην «κοινωνική επιθυμία» [14].

Με στόχο να ξεπεραστούν οι περιορισμοί που αντιμετωπίζει η παρατήρηση και οι δηλωτικές μέθοδοι, υιοθετήθηκε μια ποικιλία στρατηγικών για την μέτρηση νευροβιολογικών και συμπεριφορικών παραμέτρων που ενσωματώνονται στην εκπαιδευτική έρευνα. Σημαντικό είναι ότι η έρευνα έχει δείξει πως υπάρχουν ισχυρές επικαλύψεις, μεταξύ του τρόπου αναπαράστασης της διαδικασίας που βιώνονται τα συναισθήματα στην περιοχή του εγκεφάλου και της έκφρασής τους. Επομένως τόσο οι νευροβιολογικές συμπεριφορές όσο και οι συμπεριφορικές μέθοδοι, παρέχουν αναμφισβήτητα αξιόπιστη και συνεπή πρόσβαση σε συναισθηματικά δεδομένα. Ωστόσο σε σενάρια πραγματικής ζωής, οι στρατηγικές που προαναφέρθηκαν, φαίνεται να μην δίνουν τα αναμενόμενα αποτελέσματα καθώς οι παράμετροι της έκφρασης του ατόμου στην πραγματική ζωή είναι πολυπληθείς [14].

Για τον σωστότερο προσδιορισμό σεναρίων πραγματικής ζωής, υιοθετούνται μέθοδοι τεχνητής νοημοσύνης, ειδικότερα αλγόριθμοι που εξάγουν συμπεράσματα συσχετισμένα με μοτίβα. Στην επιστημονική έρευνα, συστήματα παρακολούθησης της ίριδας του ματιού, ανίχνευσης προσώπου με όραση υπολογιστών και φωνητικής αναγνώρισης, αποτελούν εργαλεία βέλτιστων στρατηγικών που αφορούν την αναγνώριση και την ερμηνεία των ανθρωπίνων συναισθημάτων [14].


Η ανίχνευση προσώπων πραγματοποιείται κυρίως με αλγόριθμους ταξινόμησης, όπως είναι ο αλγόριθμος «Viola Jones cascade Classifier». Μέσω της εικόνας του προσώπου, γίνεται ανάθεση σημείων αναφοράς με τη χρήση διαφορετικών αλγορίθμων, που εκχωρούν δείκτες προσώπου (στην μύτη, στα φρύδια, στα χείλη κ.λ.π.). Οι δείκτες αυτοί στη συνέχεια συγκρίνονται με προϋπάρχοντα μοτίβα αναφοράς που ορίζει κάθε eAU, για παράδειγμα η απόσταση μεταξύ των φρυδιών που καθορίζει την ένταση της έκφρασης του συνοφρυώματος. Κάθε eAU αντιστοιχεί σε έναν αριθμό και αντιπροσωπεύει την συστολή ενός μύος ή μυϊκής ομάδας του προσώπου [14].



Εικόνα 7: Οι εκφραστικοί AUs που εμπλέκονται στο συναίσθημα της χαράς, [15].

2.2.2 Ορισμοί και εφαρμογές ΣΥΝ

Ο όρος ΣΥΝ προτάθηκε για πρώτη φορά από τη Rosalind W. Picard το 1985 στο MIT Media Lab. Ως ΣΥΝ, ορίζεται η αλληλεπίδραση με μηχανές (συστήματα τεχνητής νοημοσύνης) που αντιλαμβάνονται, αναγνωρίζουν, ανταποκρίνονται και επηρεάζουν τα ανθρώπινα συναισθήματα. Ο κλάδος αυτός, εκτείνεται σε ένα ευρύ φάσμα ερευνητικών πεδίων όπως η ψυχολογία, η μηχανική, η κοινωνιολογία, τα μαθηματικά, η επιστήμη των υπολογιστών, η εκπαίδευση και η γλωσσολογία. Η συναισθηματική τεχνητή νοημοσύνη (Artificial Emotional Intelligence, AEI), και η τεχνητή νοημοσύνη αναπτύσσονται πέρα από το στάδιο της αναγνώρισης και της ερμηνείας των ανθρώπινων συναισθημάτων, στην προσομοίωση ανθρώπινων συναισθημάτων, στην τόνωση των ανθρώπινων συναισθημάτων και στη συμμετοχή σε συναισθηματική αλληλεπίδραση [16].



Εικόνα 8: Συναισθηματική Υπολογιστική και Νοημοσύνη.

Η τεχνητή συναισθηματική νοημοσύνη είναι ένας συνδυασμός τεχνητής και συναισθηματικής νοημοσύνης. Η συναισθηματική νοημοσύνη είναι η ικανότητα των ατόμων να αναγνωρίζουν τα δικά τους συναισθήματα καθώς και τα συναισθήματα των άλλων και να τα εκφράζουν κατάλληλα [17]. Η τεχνητή συναισθηματική νοημοσύνη, εκτός των παραπάνω, «αντιλαμβάνεται» τα συναισθήματα χρησιμοποιώντας συναισθηματικές πληροφορίες ή χρησιμοποιείται ως εργαλείο λήψης αποφάσεων. Με άλλα λόγια, η τεχνητή συναισθηματική νοημοσύνη αντλεί μια συναισθηματική βάση δεδομένων, για τη διάκριση των συναισθημάτων και τον προσδιορισμό νέων σκέψεων και ενεργειών όπως οι άνθρωποι, αλλά με την συνδρομή της μηχανικής μάθησης. Με την αίσθηση και την αναγνώριση των ανθρώπινων συναισθημάτων μέσω τεχνητής νοημοσύνης, οι εμπλεκόμενοι μπορούν να αντιλαμβάνονται τη συναισθηματική τους κατάσταση και να λαμβάνουν νέα συναισθηματική διέγερση. Η τεχνητή συναισθηματική νοημοσύνη, έχει την ικανότητα να αξιοποιεί τα συναισθήματα για την επίτευξη στόχων και την χρησιμοποίησή τους, για την επίλυση προβλημάτων. Η τεχνητή συναισθηματική νοημοσύνη, είναι επίσης χρήσιμη για την παροχή υπηρεσιών προσαρμοσμένων στο Web 3.0, μια έξυπνη τεχνολογία web που μπορεί να παρέχει εξατομικευμένες πληροφορίες κατανοώντας τι περιέχεται σε ιστοσελίδες χρησιμοποιώντας σημασιολογική τεχνολογία ιστού. Με αυτόν τον τρόπο, πραγματοποιείται αλληλοεπίδραση σε πραγματικό χρόνο για την αναγνώριση και ανταπόκριση των ανθρώπινων συναισθημάτων, καθώς και για την κατανόηση των ατομικών χαρακτηριστικών και προτιμήσεων. Οι τεχνολογίες που σχετίζονται με την ΣΥΝ, περιλαμβάνουν το Affect (Emotion) Sensing, δηλαδή την αναγνώριση ανθρώπινων συναισθημάτων και το Affect Generation, όπου η τεχνητή νοημοσύνη δημιουργεί άμεσες και αυτόματες συναισθηματικές αντιδράσεις για συγκεκριμένα μοτίβα εξωτερικών ερεθισμάτων. Η τεχνητή συναισθηματική νοημοσύνη προσθέτει μια τεχνολογία Affect (Emotion) Augmentation που ασχολείται με συναισθήματα που

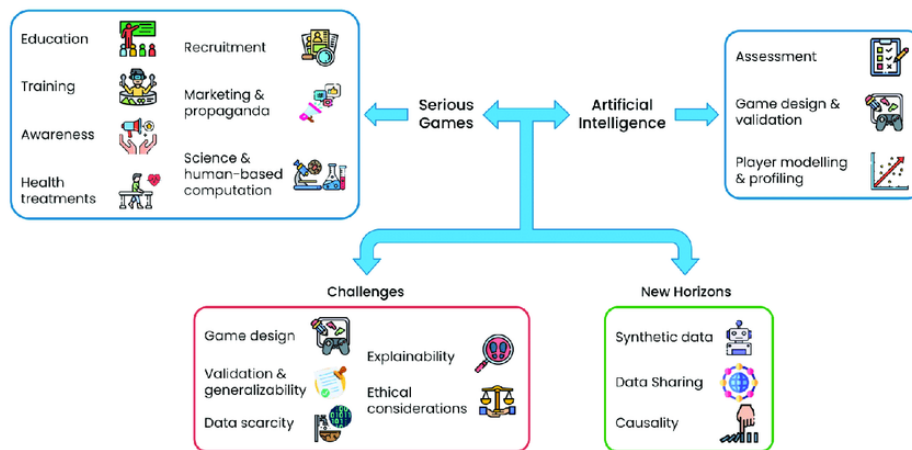
δημιουργούνται μέσω του σχεδιασμού και της συλλογιστικής τεχνητής νοημοσύνης [16].

Αν και η ανάπτυξη της τεχνολογίας από τη συναισθηματική πληροφορική στην τεχνητή συναισθηματική νοημοσύνη είναι ραγδαία, η τρέχουσα τεχνολογία εξακολουθεί να επικεντρώνεται στην αναγνώριση και ταξινόμηση των ανθρωπίνων συναισθημάτων. Τα προβλήματα και τα ζητήματα που έθεσε η Rosalind W. Picard στην εργασία «Affective Computing Challenges», εξακολουθούν να ισχύουν για την τεχνητή συναισθηματική νοημοσύνη καθώς και για την ΣΥΝ [16].

2.2.3 Μέθοδοι τεχνητής νοημοσύνης για ΠΣΣ

Ακολουθώντας την τάση των ψηφιακών εφαρμογών υγείας, που εφαρμόζονται κατά τη διάρκεια και της πανδημίας COVID-19, δημιουργήθηκε μία καινοτόμος ολοκληρωμένη πλατφόρμα για την υποστήριξη της λήψης κλινικών αποφάσεων και τηλεϊατρικής σε παιδιά με Σακχαρώδη Διαβήτη Τύπου 1 (T1DM, Type 1 Diabetes Mellitus), το ελληνικό χρηματοδοτούμενο έργο με ονομασία «Endorse». Η πλατφόρμα «Endorse», αξιοποιεί την δύναμη της εξηγήσιμης τεχνητής νοημοσύνης μαζί με τεχνολογίες κινητής υγείας και παιχνιδοποίησης. Η πλατφόρμα χρησιμοποιεί διάφορες πηγές δεδομένων, όπως αισθητήρες γλυκόζης, έξυπνα στυλό ινσουλίνης, ανιχνευτές δραστηριότητας, εφαρμογές για κινητά, Ηλεκτρονικά Μητρώα Υγείας και ΠΣΣΥ [18]. Στην «Endorse» εντάσσεται μία νέα μέθοδος Δημιουργίας Διαδικαστικού Περιεχομένου (ΔΔΠ) με στόχο την επίτευξη εξατομίκευσης και προσαρμογής σε ΠΠΣΥ. Η μέθοδος ΔΔΠ βασίζεται σε ένα γενετικό αλγόριθμο (ΓΑ) και παρέχει εξατομικευμένο περιεχόμενο με τη μορφή προσαρμοσμένων μηνυμάτων και αποστολών σε ΠΣΣΥ, λαμβάνοντας υπόψη δεδομένα που συλλέγονται από αισθητήρες που σχετίζονται με την υγεία και την αλληλεπίδραση του χρήστη με τα παιχνίδια [19].

Η τεχνητή νοημοσύνη όσον αφορά στα ΠΣΣ κινείται σε δύο πυλώνες: α) στην προσαρμογή εντός του παιχνιδιού μέσω πρακτόρων (agents) και β) στην προσαρμογή του παιχνιδιού μέσω προσαρμοστικότητας. Οι πράκτορες παιχνιδιών λειτουργούν είτε ως reflex (αντανεκλαστικοί) agents είτε ως goal-directed (στοχευμένοι) agents. Οι reflex agents είναι προγραμματισμένοι να αντιδρούν σε στιγμιαίες ενέργειες των παικτών, ενώ οι goal-directed agents στοχεύουν να χειραγωγούν το παιχνίδι προς την προκαθορισμένη κατάσταση στόχου τους. Η προσαρμοστικότητα δεν ανταποκρίνεται σε μια μεμονωμένη ενέργεια, αλλά δημιουργεί προφίλ χρηστών για αντιστοίχιση της παρουσίασης του παιχνιδιού με τα χαρακτηριστικά του παίχτη [20].



Εικόνα 9: ΠΣΣ και Τεχνητή Νοημοσύνη: Προκλήσεις και Ευκαιρίες για την Υπολογιστική Κοινωνική Επιστήμη.

Η τεχνητή νοημοσύνη στον τομέα των σοβαρών παιχνιδιών πραγματεύεται και την παρακολούθηση της προόδου του χρήστη κατά την αλληλοεπίδραση του με το παιχνίδι. Πιο συγκεκριμένα, η παρακολούθηση της προόδου του χρήστη πραγματοποιείται είτε μέσω καταγραφής της δραστηριότητας του παίκτη σε μία βάση δεδομένων, ή μέσω ενεργοποίησης προγραμματιστικών σημαίων που αποτελεί τον πυρήνα των αντανακλαστικών παραγόντων και της προσαρμοστικότητας. Οι προγραμματιστικές σημαίες είναι για παράδειγμα: α) αργοπορία στην απάντηση κάποιας ερώτησης, β) επαναλαμβανόμενα λάθη, γ) άσκοπη περιήγηση στο περιβάλλον του παιχνιδιού. Οι reflex agents ενεργοποιούνται σε αυτή την περίπτωση παρέχοντας στον χρήστη την κατάλληλη ανατροφοδότηση. Συχνά οι πράκτορες ενεργούν υπό την εμφάνιση ενός Non-Playable Character (NPC) καθιστώντας την παρέμβαση τους διακριτική αλλά έγκαιρη [20].

Η αλληλοεπίδραση με χαρακτήρες NPC, είναι ζωτικής σημασίας για τα ΠΣΣ, καθώς αναδεικνύουν έντονα την παρουσία της τεχνητής νοημοσύνης στον τομέα των ηλεκτρονικών παιχνιδιών με έμφαση στα σοβαρά παιχνίδια. Οι πράκτορες ή NPC, διατηρούν το ενδιαφέρον στο παιχνίδι συντροφεύοντας τον παίκτη, είτε με τον χαρακτήρα των ομότιμων παιχτών, ή ελεγχόμενων από το παιχνίδι χαρακτήρων με ρόλους που ποικίλλουν μεταξύ καθοδήγησης του παιχνιδιού, μεταφοράς/επεξήγησης, εκπαιδευτικού υλικού ή χιουμοριστικών περισπασμών. Δεδομένων αυτών των ρόλων, η επικοινωνία μεταξύ παικτών και πρακτόρων είναι ένα ηχηρό επίκεντρο λειτουργικής ποιότητας. Οι κύριοι τρόποι επικοινωνίας NPC-to-player, είναι μέσω κειμένου ή φωνητικών εντολών, ενώ το player-to-NPC, παραμένει μέσω κειμένου [20]. Στο σημείο αυτό αξίζει να σημειωθεί πως οι φωνητικές εντολές κατά τη διάρκεια του παιχνιδιού, αποτελούν ένα εργαλείο τεχνητής νοημοσύνης με όνομα speech recognition, κατά το οποίο μέσω και άλλων μεθόδων όπως είναι η Natural Language Processing (NLP), γίνεται μετατροπή της φωνής του παίκτη σε κείμενο, για να λάβει χώρα μια πιο ρεαλιστική αλληλοεπίδραση με το παιχνίδι. Γίνεται επομένως κατανοητό πως οι παίκτες προτιμούν να επικοινωνούν με τα NPC, μέσω φωνής, προσδίδοντας στο παιχνίδι, κατά την αλληλεπίδραση με αυτό, το στοιχείο του ρεαλισμού. Η δυνατότητα φωνητικής επικοινωνίας με το παιχνίδι συμβάλλει στην

αύξηση των συναισθημάτων, διατηρώντας τον παίκτη σε εγρήγορση και αυξάνοντας το επίπεδο ενασχόλησης με αυτό.

Η ΣΥΝ όπως φαίνεται, είναι ένα διευρυμένο πεδίο που λαμβάνει νέες μορφές με την ανάπτυξη ισχυρότερων υπολογιστικών συσκευών. Ωστόσο τα περισσότερα σύνολα δεδομένων περιορίζονται σε βασικούς τρόπους (ομιλία, κείμενο και βίντεο). Επιπλέον η έλλειψη επισημασμένων συναισθηματικών δεδομένων, έχει αποτελέσει εμπόδιο στην περαιτέρω ανάπτυξη στην ΣΥΝ. Επιπλέον οι συναισθηματικές εκφράσεις μπορεί να είναι εγγενώς διαιρούμενες, οδηγώντας έτσι σε πολλαπλές εξίσου έγκυρες αναπαραστάσεις στην έκφραση και την αντίληψη. Η ασάφεια αυτή δημιουργεί προκλήσεις για τους τρόπους που απαιτούνται για την αποτύπωση της συναισθηματικής έκφρασης και την αντιληπτών συναισθηματικών καταστάσεων [21].

2.2.4 ΣΥΝ και ΠΣΣ

Τις τελευταίες δεκαετίες, η προσαρμογή και η εξατομίκευση σε ΠΣΣ έχουν αποδειχθεί ως μέθοδοι που βελτιώνουν τα κίνητρα των παικτών για μάθηση, για συμμετοχή στη διαδικασία μάθησης και ως εκ τούτου τη συνολική μαθησιακή πρόοδο. Όλες οι προτεινόμενες προσεγγίσεις προσαρμογής και εξατομίκευσης, βασίζονται στη μοντελοποίηση παικτών, η οποία μπορεί να περιλαμβάνει τρεις κύριες ομάδες ατομικών χαρακτηριστικών:

- **Συναισθηματική (affective) κατάσταση του παίκτη:** Παρέχει ατομική διέγερση συναισθημάτων και ως εκ τούτου μπορεί να εφαρμοστεί για προσαρμογή παιχνιδιού με επίκεντρο τον παίκτη και στόχο να κρατήσει τον παίκτη σε ροή, ενώ ταυτόχρονα ενεργοποιεί τα εγγενή του κίνητρα.
- **Αποτελέσματα και αποτελεσματικότητα του παιχνιδιού:** Τέτοιες μετρήσεις μπορούν εύκολα να παρακολουθούνται κατά τη διάρκεια των περιόδων παιχνιδιού για την παροχή πληροφοριών σχετικά με τη βελτίωση των γνώσεων, των δεξιοτήτων του παίκτη και τη συνολική πρόοδο στο παιχνίδι.
- **Ο χαρακτήρας του παιχνιδιού και/ή της μάθησης:** Αποκαλύπτει την προσωπικότητα ενός μεμονωμένου παίκτη και μπορεί να εξαχθεί με υποκειμενικές αναφορές, χρησιμοποιώντας συγκεκριμένα ερωτηματολόγια ή με γραμμική παλινδρόμηση χρησιμοποιώντας κατάλληλες μετρικές παιχνιδιού [22].

Από τις τρεις παραπάνω ομάδες ατομικών χαρακτηριστικών, η συναισθηματική κατάσταση του παίκτη τείνει να είναι η πιο δύσκολη για να αναγνωριστεί. Ως βασικό συστατικό των αλληλεπιδράσεων συναισθήματος-γνώσης, το συναίσθημα είναι μια νευροβιολογική δραστηριότητα και μπορεί να αναγνωριστεί από υποκειμενικές αναφορές, παρατήρησης των κινήσεων του σώματος ή της συμπεριφοράς του προσώπου και από τις ψυχοφυσιολογικές μετρήσεις ενδεικτικά της Ηλεκτρο-Δερμαρικής Δραστηριότητας (EDA), του Όγκου του Καρδιακού Παλμού (BVP), του ηλεκτροκαρδιογραφήματος (ECG) και του ηλεκτροεγκεφαλογραφήματος (EEG) [22].


Για την εφαρμογή της συναισθηματικής κατάστασης, ως βάσης για τη συναισθηματική προσαρμογή του παιχνιδιού, θα πρέπει να παρέχονται διάφορα

στάδια μέτρησης και επεξεργασίας ψυχοφυσιολογικών σημάτων. Οι ψυχοφυσιολογικές αντιδράσεις που παράγονται από το παιχνίδι πρέπει να μετρώνται και να καταγράφονται. Στη συνέχεια επιλεγμένα σχετικά χαρακτηριστικά εξάγονται από τα μετρούμενα σήματα και τελικά κανονικοποιούνται. Το σύνολο των δεδομένων χαρακτηριστικών, επεξεργάζεται με ταξινόμηση ή εκτίμηση, για την ανάθεση ψυχολογικών ετικετών σε δεδομένα χαρακτηριστικά. Για τα συναισθηματικά δεδομένα που εξάγονται κατά την αλληλοεπίδραση με ΠΣΣΥ, χρησιμοποιούνται αρκετοί ταξινομητές (classifiers) όπως είναι: k-nearest neighbour (KNN), Bayesian Networks (BNT), decision trees (DT), linear discriminant analysis (LDA), support vector machines (SVM) και πολλοί άλλοι, που συγκρίνονται ως προς την ακρίβειά τους, με την χρήση αλγορίθμων «cross-validation» στο σύνολο των δεδομένων εκπαίδευσης [22].

2.2.5 Μέθοδοι αναγνώρισης συναισθήματος

Το συναίσθημα διαδραματίζει σημαντικό ρόλο σε κάθε τρόπο επικοινωνίας μεταξύ ανθρώπων ή μεταξύ ανθρώπου και υπολογιστή. Η ομιλία είναι το πιο φυσικό μέσο στην ανθρώπινη επικοινωνία και επίσης ένας εύκολος τρόπος μετάδοσης συναισθημάτων. Στην αναπτυσσόμενη εποχή της τεχνητής νοημοσύνης, το συναίσθημα έχει συγκεκριμένο ρόλο στην αλληλεπίδραση ανθρώπου – υπολογιστή, ή γενικότερα στην αλληλεπίδραση ανθρώπου – μηχανής. Η κατανόηση της ανθρώπινης συμπεριφοράς επιτρέπει στα συστήματα συναισθηματικής επίγνωσης να παρέχουν συνεχή επαφή χωρίς καθυστερήσεις. Επομένως η αναγνώριση συναισθημάτων που βασίζεται στην ομιλία, διαδραματίζει ουσιαστικό ρόλο στο HCI (Αλληλεπίδραση ανθρώπου – υπολογιστή) ή στο HMI (Διεπαφή ανθρώπου – μηχανής) [23].

Η αναγνώριση συναισθημάτων ομιλίας (Speech Emotion Recognition, SER) στοχεύει σε μια φυσική επαφή με τη μηχανή, χρησιμοποιώντας την άμεση φωνητική αλληλεπίδραση αντί για οποιαδήποτε άλλη συσκευή, ως είσοδο για την κατανόηση λεκτικού περιεχομένου και την απλοποίηση των αντιδράσεων του ανθρώπινου ακροατή. Συστήματα διαλόγου για ομιλούμενες γλώσσες, όπως η χρήση μοτίβων συναισθημάτων από σήματα ομιλίας σε ιατρικές εφαρμογές, που χρησιμοποιούνται ως διαγνωστικά και προγνωστικά εργαλεία για παθήσεις ψυχικής υγείας, αποτελούν χαρακτηριστικά παραδείγματα εφαρμογών αναγνώρισης συναισθημάτων [23].



Εικόνα 10: Natural Language Processing με τη χρήση της Python για sentiment analysis.

Την περίοδο 1964 με 1966 ο Joseph Weizenbaum έκανε τα πρώτα βήματα στην δημιουργία ενός υπολογιστικού προγράμματος επεξεργασίας φυσικής γλώσσας, με όνομα «Eliza». Το «Eliza» ασχολήθηκε και προσομοίωσε συνομιλίες με τους χρήστες, που τους έδινε την ψευδαίσθηση ότι γίνονταν κατανοητοί, χωρίς στην πραγματικότητα να υπάρχει ενσωματωμένο πλαίσιο για να γίνει αυτό. Ένα από τα πιο διάσημα σενάρια του «Eliza» είναι το «Doctor», το οποίο προσομοίωνε τη μέθοδο της προσωποκεντρικής θεραπείας, απαντώντας με μη κατευθυντικές ερωτήσεις στην είσοδο που έδινε ο χρήστης. Ο Weizenbaum εξεπλήγη, από τον αριθμό ατόμων που απέδωσαν ανθρώπινα συναισθήματα στο πρόγραμμα του υπολογιστή [24].

Σήμερα ένα συναισθηματικό πρόγραμμα που κατανοεί πραγματικά έναν χρήστη φαίνεται πιο ρεαλιστικό από ποτέ. Αυτή η υπηρεσία θα μπορούσε να ενεργοποιηθεί με τη χρήση της ηλεκτροεγκεφαλογραφικής (EEG) αναγνώρισης συναισθημάτων ομιλίας, που χρησιμοποιεί ομιλία και εγκεφαλικά κύματα για τον εντοπισμό και την ανάλυση συναισθηματικού περιεχομένου [24].

Το EEG, αποτελεί μέθοδο παρακολούθησης ηλεκτρικής εγκεφαλικής δραστηριότητας και πρωτοεμφανίστηκε στον τομέα της Νευροεπιστήμης για τη διάγνωση της επιληψίας ή των διαταραχών ύπνου. Σε πρόσφατη έρευνα, φάνηκε ότι τα σήματα ηλεκτροεγκεφαλογραφικής δραστηριότητας έχουν χρησιμοποιηθεί σε πολλές μελέτες για την ανίχνευση της συναισθηματικής απόκρισης ενός ατόμου σε ορισμένα ερεθίσματα, καθώς δημιουργούν μια άμεση διαδρομή μεταξύ του εγκεφάλου του χρήστη και του υπολογιστή. Τα καταγεγραμμένα σήματα παράγονται στο τμήμα κίνησης και συναισθημάτων του εγκεφάλου και αποτελούνται από πέντε κύριες ζώνες συχνότητας: i) Delta (δ , έως 4 Hz) waves, ii) Theta (θ , 4 – 8 Hz) waves, iii) Alpha (α , 8 – 15 Hz) waves, iv) Beta (β , 15 – 32 Hz) waves και v) Gamma (γ , \geq 32 Hz) waves, όπου κάθε κύμα μπορεί να δώσει διαφορετικές ενδείξεις συναισθηματικής κατάστασης. Τα κύματα alpha, για παράδειγμα, μπορεί να υποδηλώνουν μία χαλαρή αντανακλαστική κατάσταση του νου και της συνείδησης, ενώ τα κύματα beta μπορεί να δείξουν διαφορετικό εύρος από έντονο στρες έως ήπια εμμονή. Τα κύματα gamma,

μπορούν να βρεθούν κατά τη βραχυπρόθεσμη αντιστοίχιση μνήμης αναγνωρισμένων αντικειμένων, ήχων ή απτικών αισθήσεων και είναι υπεύθυνα για τη γνωστική λειτουργία, τη μάθηση, τις εργασίες επίλυσης προβλημάτων και την επεξεργασία πληροφοριών. Επιπλέον, η κυρίαρχη δύναμη ενός συναισθήματος μπορεί να βρεθεί ως αύξηση της αναλογίας alpha / beta δραστηριότητας, καθώς και ως αύξησης της beta δραστηριότητας [24].

Το πιο συχνά χρησιμοποιούμενο μοντέλο για τον εντοπισμό και την ταξινόμηση συναισθημάτων, είναι το μοντέλο διέγερσης / σθένους, που προτάθηκε από τον James A. Russel. Αυτό το μοντέλο υποδηλώνει ότι τα συναισθήματα κατανέμονται σε έναν δισδιάστατο χώρο που περιέχει διαστάσεις διέγερσης και σθένους. Το εύρος του άξονα διέγερσης κυμαίνεται από το ήρεμο έως το διεγερμένο, ενώ το εύρος του άξονα σθένους από το θετικό έως το αρνητικό. Ένα αρνητικό επίπεδο σθένους και διέγερσης αντιπροσωπεύει μια καταθλιπτική συναισθηματική κατάσταση, ενώ μια θετική τιμή και στους δύο άξονες υποδηλώνει συναισθήματα ενθουσιασμού. Ο Plutchik, ανέφερε ότι υπάρχουν ορισμένα πρωταρχικά συναισθήματα ενώ όλα τα υπόλοιπα είναι συνδυασμός αυτών. Τα πρωταρχικά συναισθήματα χρησιμοποιούνται για την ερμηνεία του EEG και είναι τα εξής: φόβος, θυμός, λύπη, χαρά, αηδία, αποδοχή, προσμονή και έκπληξη [24].


Ο σχεδιασμός μιας συναισθηματικής υπηρεσίας, που χρησιμοποιεί SER και EEG enabled Emotion Recognition, για την κατανόηση της περίπλοκης εσωτερικής κατάστασης ενός ατόμου, θα μπορούσε να ανοίξει το δρόμο για μία νέα εποχή αλληλεπίδρασης ανθρώπου – υπολογιστή. Ειδικά σε ότι αφορά την ψυχοθεραπεία, απαιτείται ένα σύστημα που να μπορεί να ανιχνεύει συναισθήματα, όχι μόνο κατά τη διάρκεια μιας συνομιλίας με ένα άτομο, αλλά και σε φάσεις αυτοστοχασμού και εσωτερικής σκέψης. Τα δεδομένα εγκεφαλικών κυμάτων πρέπει να εξετάζονται στο πλαίσιο συνομιλίας, καθώς η ομιλία πρέπει να ανιχνεύεται σε σχέση με τα σήματα EEG [24].

2.3 Μεταβλητότητα Καρδιακού Ρυθμού

2.3.1 Ανάλυση MKP

MKP (Heart Rate Variability (HRV)), ορίζεται η διακύμανση του καρδιακού ρυθμού, στα χρονικά διαστήματα μεταξύ γειτονικών καρδιακών παλμών. Αποτελεί έναν από τους πολλούς δείκτες παθολογικών καταστάσεων που σχετίζονται με την υγεία και παρέχει αξιόπιστες πληροφορίες σχετικά με την αλληλεπίδραση του συμπαθητικού (ΣΝΣ) και του παρασυμπαθητικού νευρικού συστήματος (ΠΝΣ). Συγκεκριμένα το HRV δημιουργείται από αλληλεπιδράσεις καρδιάς – εγκεφάλου και δυναμικές μη γραμμικές διεγέρσεις του αυτόνομου νευρικού συστήματος (ΑΝΣ). Η ανάλυση της διακύμανσης του καρδιακού ρυθμού είναι μία πολύ γνωστή μη επεμβατική τεχνική για τον εντοπισμό της λειτουργίας του ΑΝΣ. Η MKP αποτελεί μια αναδυόμενη ιδιότητα αλληλεξαρτώμενων ρυθμιστικών συστημάτων που λειτουργούν σε διαφορετικές χρονικές κλίμακες, με σκοπό την προσαρμογή σε περιβαλλοντικές και ψυχολογικές προκλήσεις. Το HRV, αντανακλά τη ρύθμιση της αυτόνομης ισορροπίας, της αρτηριακής πίεσης (BP), της ανταλλαγής αερίων του

εντέρου, της καρδιάς και του αγγειακού τόνου ο οποίος αναφέρεται στη διάμετρο των αιμοφόρων αγγείων που ρυθμίζουν την αρτηριακή πίεση και πιθανώς τους μύες του προσώπου [25]. Διαπιστώθηκε ότι η καρδιακή φυσιολογική μεταβλητότητα εξαρτάται από τη διέγερση του φλεβοκομβικού κόμβου (βηματοδότη), η οποία μπορεί να αξιολογηθεί με την ανάλυση του HRV. Σε μελέτες που βασίζονται σε ανθρώπους, έχει βρεθεί ότι ένα χαμηλό επίπεδο της μεταβλητότητας, είναι μία από τις κύριες αιτίες του ποσοστού θανάτου μεταξύ των ενηλίκων, ως εκ τούτου η MKP βοηθά στον εντοπισμό του κινδύνου καρδιακών παθήσεων και της κατάστασης του ANΣ [26].



Εικόνα 11: MKP ως μέσω αλληλεπίδρασης του συμπαθητικού με το ΠΝΣ.

Η υγιής καρδιά δεν είναι μετρονόμος. Οι ταλαντώσεις μιας υγιούς καρδιάς είναι πολύπλοκες και μη γραμμικές. Οι διακυμάνσεις μεταξύ των διαστημάτων των παλμών μιας υγιούς καρδιάς περιγράφονται καλύτερα από το μαθηματικό χάος. Η μεταβλητότητα των μη γραμμικών συστημάτων, παρέχει ευελιξία για την ταχεία αντιμετώπιση ενός αβέβαιου και μεταβαλλόμενου περιβάλλοντος. Ενώ τα υγιή βιολογικά συστήματα παρουσιάζουν χωρική και χρονική πολυπλοκότητα, η ασθένεια μπορεί να περιλαμβάνει είτε απώλεια είτε αύξηση πολυπλοκότητας [25].

Το HRV μπορεί να ποικίλει ανάλογα τη χρονική καταγραφή του σε: α) short – term HRV, β) σε ultra short-term HRV και γ) long – term ή Twenty-Four-Hour HRV [27]. Σε αυτή την ενότητα θα γίνει μία αναφορά στο short – term HRV και στο ultra short-term HRV, τα οποία δεν θα αναλυθούν ξεχωριστά, και στο Twenty-Four-Hour HRV.


Όσον αφορά στις βραχυπρόθεσμες καταγραφές MKP, δύο διακριτές αλλά επικαλυπτόμενες διαδικασίες δημιουργούν βραχυπρόθεσμες μετρήσεις HRV. Η πρώτη πηγή είναι μια σύνθετη και δυναμική σχέση μεταξύ του συμπαθητικού και του παρασυμπαθητικού κλάδου. Η δεύτερη πηγή περιλαμβάνει τους ρυθμιστικούς μηχανισμούς που ελέγχουν τον ρυθμό της καρδιάς μέσω της αναπνευστικής φλεβοκομβικής αρρυθμίας (RSA), του αντανακλαστικού βαροϋποδοχέα (έλεγχος αρνητικής αντίδρασης της αρτηριακής πίεσης του αίματος (BP)) και ρυθμικές αλλαγές στον αγγειακό τόνο. Το RSA, αναφέρεται στην επιτάχυνση και επιβράδυνση της καρδιάς λόγω της αναπνοής μέσω του πνευμονογαστρικού νεύρου [25].

Ενώ όσον αφορά στις μακροπρόθεσμες καταγραφές MKP, το Twenty-Four-Hour HRV, οι κικράδιοι ρυθμοί, η θερμοκρασία του πυρήνα του σώματος, ο μεταβολισμός, ο κύκλος ύπνου και το σύστημα ρενίνης – αγγειοτενσίνης συμβάλλουν στις καταγραφές HRV 24 ωρών, που αντιπροσωπεύουν το «χρυσό πρότυπο» για την κλινική αξιολόγηση του HRV. Αυτές οι εγγραφές επιτυγχάνουν μεγαλύτερη προγνωστική ισχύ από τις βραχυπρόθεσμες μετρήσεις. Αν υπολογίζουμε 24 ώρες και βραχυπρόθεσμες μετρήσεις HRV χρησιμοποιώντας τους ίδιους μαθηματικούς τύπους, δεν μπορούν να υποκαταστήσουν η μία την άλλη και η φυσιολογική τους σημασία μπορεί να διαφέρει βαθιά [25].

Οι δείκτες MKP στον τομέα του χρόνου, ποσοτικοποιούν το HRV που παρατηρείται κατά τις περιόδους παρακολούθησης, που μπορεί να κυμαίνονται από < 1 λεπτού έως > 24 ωρών. Αυτές οι μετρήσεις περιλαμβάνουν το SDNN, SDRR, SDANN, SDNN Index, RMSSD, NN50, pNN50, HR Max – HR Min, τον τριγωνικό δείκτη HRV (HTI) και την Τριγωνική Παρεμβολή του Ιστογράμματος των Διαστημάτων NN (TINN) [25]. Αναλυτικότερα η επεξήγηση των παραπάνω και μια εκτενέστερη ανάλυση του HRV θα γίνει στο Κεφάλαιο 3.

2.3.2 Εφαρμογές MKP

Το HRV ενός ατόμου είναι ένας εξαιρετικός δείκτης της αυτόνομης δραστηριότητάς του. Διάφορες σωματικές και ψυχικές καταστάσεις επηρεάζουν το ANΣ συμπεριλαμβανομένων των αυτόνομων νευροπαθειών, όπως η διαβητική νευροπάθεια, η κατάθλιψη, η διαταραχή μετατραυματικού στρες (PTSD), το άγχος και η καρδιακή υγεία. Τα δεδομένα HRV βοηθούν στην σωστή υπόδειξη των επιπέδων άγχους και της σοβαρότητας καταστάσεων υγείας, δείχνοντας την ικανότητα του σώματος να ανταπεξέρχεται. Ειδικότερα η αντίληψη μίας «απειλής» δημιουργεί έναν «καταράκτη» φυσιολογικών διεργασιών που ονομάζεται «stress response». Η καρδιακή δραστηριότητα ρυθμίζεται από δύο τύπου νευροτροποποιητικούς υποδοχείς (ακετυλοχολίνη και νορεπινεφρίνη) των καρδιακών κυττάρων που αντιστοιχούν στο ΠΝΣ και στο ΣΝΣ αντίστοιχα. Το άγχος αυξάνει τον καρδιακό παλμό και την δύναμη συστολής του, ως εκ τούτου η ποσότητα του αίματος κυκλοφορεί γρηγορότερα προκειμένου να παραδοθεί περισσότερο οξυγόνο στα όργανα ως μια προσπάθεια εξάλειψης του στρεσογόνου παράγοντα [28]. Τα δεδομένα HRV μπορούν στη συνέχεια να χρησιμοποιηθούν για να «ποσοτικοποιηθεί» η συνολική υγεία και να προσδιορισθεί εάν απαιτούνται περαιτέρω παρεμβάσεις για την αντιμετώπιση συγκεκριμένων παθολογικών καταστάσεων, όπως η καρδιακή νόσος και η κατάθλιψη.



Εικόνα 12: Ανάλυση MKP, μη επεμβατική μέθοδος αναγνώρισης παθήσεων.

Αξίζει να αναφερθεί πως το HRV, έχει αποδειχθεί αρκετά ικανοποιητική μέθοδος για την αναγνώριση των συμπτωμάτων πολλών παθήσεων. Τέτοια πάθηση αποτελεί το Σύνδρομο Αποφρακτικής Άπνοιας Ύπνου, ΣΑΑΥ (Obstructive Sleep Apnea Syndrome, OSAS) που παρατηρείται σε περίπου 2% των παιδιών. Η MKP είναι ένα δυνητικά απλό, μη επεμβατικό εργαλείο προσυμπτωματικού ελέγχου ΣΑΑΥ. Τα αποτελέσματα δείχνουν ότι η ένταση χάους του καρδιακού ρυθμού, όπως μετράται από το όριο θορύβου στην αριθμητική τιτλοδότηση, είναι σημαντικά υψηλότερη κατά τον ύπνο REM, από τον ύπνο NREM, σε όλες τις ομάδες ασθενών. Με τη χρήση της ανάλυσης χαρακτηριστικών λειτουργίας δέκτη, η ανίχνευση του ΣΑΑΥ, έδωσε specificity 72.2% και sensitivity 81.3%, χρησιμοποιώντας την τεχνική της αριθμητικής τιτλοδότησης. Τα ευρήματα υποδηλώνουν ότι η κατάσταση του ύπνου και η διαταραχή της αναπνοής είναι σημαντικοί καθοριστικοί παράγοντες του καρδιακού αυτόνομου ελέγχου. Μη γραμμικές τεχνικές όπως η αριθμητική ογκομέτρηση, όταν χρησιμοποιούνται σε συνδυασμό με τη φασματική ανάλυση του HRV, θα μπορούσαν να αποτελέσουν ένα αποτελεσματικό εργαλείο διαλογής για το παιδιατρικό ΣΑΑΥ [29].

2.3.3 MKP και επίπεδα προσήλωσης

Οι μετρήσεις της MKP παρέχουν, κατά θεωρητική προσέγγιση, δείκτες νοητικής προσήλωσης (mental engagement, ME). Η διανοητική προσήλωση ήταν ανέκαθεν ένα κεντρικό επεξηγηματικό κατασκεύασμα σε μια σειρά από θεωρίες της ανθρώπινης απόδοσης, της ανάπτυξης του παιδιού και της γήρανσης. Σε αυτούς τους ερευνητικούς τομείς, η νοητική προσήλωση θεωρείται ως κινητήρια μεταβλητή που επηρεάζει την προθυμία ενός ατόμου να καταλείψει προσπάθεια και πόρους, για να αποκτήσει εννοιολογικές ιδέες ή δεξιότητες [30]. Οι μετρήσεις της φυσιολογικής δραστηριότητας και των επιπέδων προσήλωσης, χρησιμοποιούνται συχνά ως συγκλίνουσες για τον αντίκτυπο συγκεκριμένων συνθηκών στη νοητική προσήλωση ενός ατόμου με την εργασία, την ψυχαγωγία, την άθληση, την αλληλεπίδραση με παιχνίδια κ.α.

Για περισσότερο από έναν αιώνα, οι ερευνητές έχουν μελετήσει αλλαγές στη δραστηριότητα του ΑΝΣ που συμβαίνουν όταν τα άτομα επηρεάζονται από περιβαλλοντικούς παράγοντες ή κατά την εκτέλεση εργασιών. Οι δείκτες ΜΚΡ, λόγω της ικανότητάς τους να περιγράφουν την αλληλεπίδραση μεταξύ συμπαθητικής και παρασυμπαθητικής ενεργοποίησης, έχουν θεωρηθεί ως μέτρο της ολοκλήρωσης εγκεφάλου – καρδιάς, που βασίζεται στη συμπεριφορά. Μια αυξανόμενη βιβλιογραφία συνδέει αμφίδρομες νευρολογικές οδούς από τον μετωπιαίο φλοιό του εγκεφάλου με συμπαθητικά και παρασυμπαθητικά τμήματα του ΑΝΣ. Το Κεντρικό Αυτόνομο Δίκτυο (CAN) παρέχει ένα μοντέλο που εξηγεί πως οι στοχευμένες συμπεριφορές διέπονται α) από φθίνουσες προβολές του προμετωπιαίου φλοιού σε υποφλοιώδεις πυρήνες που ρυθμίζουν την καρδιαγγειακή δραστηριότητα και β) από ανιούσες προβολές αυτόνομων δομών του εγκεφαλικού στελέχους που επηρεάζουν υποφλοιώδεις και φλοιώδεις δομές. Το μοντέλο CAN και τα στοιχεία της σχέσης μεταξύ πολλαπλών νευρωνικών δικτύων, οδήγησαν τους J. F. Thayer, A. L. Hansen, E. Saus-Rose, and B. H. Johnsen [31] και άλλους όπως ο T. M. Hess [32] να προτείνουν ότι τα μέτρα ενεργοποίησης HRV και ANS μπορούν να χρησιμεύσουν ως δείκτες αλλαγών, στη νοητική επεξεργασία που συντελείται όταν τα άτομα εκτελούν εργασίες που περιλαμβάνουν την κατανομή της προσοχής και της πνευματικής προσήλωσης [30].

Σε έρευνες που εκπονήθηκαν ανά τα χρόνια, οι N. Hjortskov, A. K. Blangsted, N. Fallentin, U. Lundberg [33] ασχολήθηκαν με την μείωση της συνιστώσας HRV υψηλής συχνότητας, σε νεαρές γυναίκες που εκτελούσαν μια εργασία υπολογιστή σε σχέση με την περίοδο ανάπαυσης. Πιο πρόσφατα οι J. Taelman, S. Vandeput, E. Vlemincx, A. Spaepen, S. Van Huffel [34] παρείχαν στοιχεία σχετικά με το μέγεθος της αντίδρασης του ΑΝΣ, το οποίο αυξάνεται καθώς αυξάνεται η διανοητική απαίτηση. Αξιολόγησαν εγγραφές HRV έξι λεπτών σε νεαρούς ενήλικους υπό συνθήκες ηρεμίας, ανίχνευση οπτικού ερεθίσματος (χαμηλή ζήτηση) και μια εργασία μαθηματικού υπολογισμού (υψηλή ζήτηση). Η επίδραση ήταν σημαντικά μεγαλύτερη υπό συνθήκες υψηλής ζήτησης. Αυτά τα ευρήματα, υποδηλώνουν ότι η σχέση μεταξύ HRV και διανοητικής προσήλωσης μπορεί να είναι συγκεκριμένη για το κάθε έργο και να καθοδηγείται από το επίπεδο των νοητικών απαιτήσεων της εκάστοτε εργασίας [35].

Κεφάλαιο 3: Μεθοδολογία

Στο παρόν κεφάλαιο παρουσιάζεται το πρακτικό μέρος της παρούσας Διπλωματικής Εργασίας. Θα γίνει μια εκτενής ανάλυση της δομής της πειραματικής διαδικασίας, από το ξεκίνημα που αφορά την συλλογή των δεδομένων μέχρι την εισαγωγή τους σε μοντέλα μηχανικής μάθησης, για την ανάλυση και την ερμηνεία των αποτελεσμάτων των μοντέλων.

3.1 Περιγραφή πειραματικής διαδικασίας

3.1.1 Το ΠΣΣΥ

Το παιχνίδι που χρησιμοποιήθηκε με σκοπό την αλληλεπίδραση των συμμετεχόντων με αυτό ως «case study», ονομάζεται «Express Cooking Train» (ECT) και είναι ένα ΠΣΣΥ το οποίο είναι φτιαγμένο για λειτουργικό Microsoft Windows. Το ECT διαθέτει ένα εικονικό περιβάλλον κουζίνας που συνδέεται οντολογικά με τρόφιμα και συνταγές παρέχοντας στον χρήστη ένα ασφαλές περιβάλλον προσομοίωσης μαγειρέματος. Ο πειραματισμός στην κουζίνα είναι ζωτικής σημασίας για την ανακάλυψη πιο υγιεινών υλικών και τεχνικών μαγειρέματος. Το περιεχόμενο του ECT βασίζεται σε οδηγίες και ενημερωτικά δελτία από τον Παγκόσμιο Οργανισμό Υγείας (ΠΟΥ) και την Αμερικανική Καρδιολογική Εταιρεία (ΑΚΑ) για να διασφαλίσει την αξιοπιστία [36].

3.1.2 Ο αισθητήρας καταγραφής του καρδιακού ρυθμού

Ο αισθητήρας που χρησιμοποιήθηκε για την καταγραφή του καρδιακού ρυθμού στο πλαίσιο της πειραματικής διαδικασίας είναι ο αισθητήρας Pulse από την World Famous Electronics LLC. Ο PulseSensor αποτελεί έναν προσιτό αισθητήρα που μπορεί να τοποθετηθεί γύρω από το δάχτυλο ή στο λοβό του αυτιού χωρίς να ενοχλεί τον χρήστη. Για την καταγραφή των παρόντων δεδομένων, ο αισθητήρας τοποθετήθηκε στο λοβό του αυτιού των συμμετεχόντων, για να αποφευχθεί πιθανή ενόχληση που μπορούσε να προκληθεί από την τοποθέτησή του στο δάχτυλο, κατά τη διάρκεια της αλληλεπίδρασης με το ΠΣΣΥ. Ο συγκεκριμένος αισθητήρας ανιχνεύει παλμούς μέσω μιας διόδου εκπομπής φωτός που δημιουργεί φωτοπληθυσμογραφία (PPG) [5].

3.1.3 Τρόπος καταγραφής των επιπέδων προσήλωσης μέσω υποκειμενικής επισημείωσης του χρήστη

Για την καταγραφή των δεδομένων επισημείωσης του χρήστη σχετικά με τα επίπεδα προσήλωσης του κατά τη διάρκεια του παιχνιδιού, χρησιμοποιήθηκε ένα «annotation tool». Συγκεκριμένα πραγματοποιήθηκε με προσομοίωση του εργαλείου RankTrace, το οποίο επιτρέπει στους συμμετέχοντες να σχολιάσουν την συναισθηματική τους εμπειρία σε πραγματικό χρόνο καθώς παρακολουθούν το

«playthrough» της αλληλοεπίδρασής τους με το ΠΣΣΥ. Μέσω αυτής της προσέγγισης, οι παίκτες δημιουργούν ένα συνεχές ίχνος της αντιληπτής προσήλωσης αμέσως μετά την αλληλεπίδρασή τους με το παιχνίδι. Οι τιμές παρήχθησαν μέσω του τροχού του ποντικιού, με δειγματοληψία διαστημάτων ενός δευτερόλεπτου. Τα δεδομένα υποκειμενικής επισημείωσης των συμμετεχόντων εξήχθησαν σε μορφή αρχείου κειμένου μετά το πέρας του παιχνιδιού [5].

3.1.4 Οι συμμετέχοντες

Επιλέχθηκαν συνολικά 26 συμμετέχοντες, 19 άνδρες και 7 γυναίκες, ως επί το πλείστον προπτυχιακοί και μεταπτυχιακοί φοιτητές του Εθνικού Μετσόβιου Πολυτεχνείου (ΕΜΠ). Κανένας συμμετέχων δεν είχε εμφανή κινητική ή οπτική αναπηρία και οι περισσότεροι συμμετέχοντες είχαν φυσιολογική βαθμολογία BMI (18,5 – 25), εκτός από δύο ελαφρώς υπέρβαρους (25 – 27) και δύο ελαφρώς παχύσαρκους (30 – 35). Αφού οι συμμετέχοντες κάθισαν άνετα, τους τοποθετήθηκε ο αισθητήρας Pulse στο λοβό του αυτιού της επιλογής τους, έτσι ώστε να μην εμποδίζει με κανέναν τρόπο. Το ΠΣΣΥ με το οποίο αλληλοεπίδρασαν, όπως προαναφέρθηκε πραγματευόταν τις μαγειρικές συνήθειες [5].

3.2 Δομή των δεδομένων

Τα δεδομένα σχετικά με τον καρδιακό ρυθμό και τα επίπεδα προσήλωσης των χρηστών, συλλέγονται και αποθηκεύονται σε μορφή αρχείου κειμένου (Text Document).

3.2.1 Δεδομένα καρδιακού ρυθμού

Τα δεδομένα του καρδιακού ρυθμού όπως παρήχθησαν από τον αισθητήρα PulseSensor, δεν είχαν την απαιτούμενη μορφή για να μπορέσουν να χρησιμοποιηθούν, καθώς ιδανικά θα έπρεπε σε κάθε καταγραφή να έχουμε μία διαφορετική τιμή ΜΚΡ από την προηγούμενη. Στον Πίνακα 1, παρουσιάζεται ένα παράδειγμα της μορφής που είχαν τα δεδομένα πριν γίνει επεξεργασία.

Ανεπεξέργαστα Δεδομένα Καρδιακού Ρυθμού

HR	R-R	H	time	=	date	time
65	924	392	t	=	2019-07-09	14:52:18.852424
65	924	385	t	=	2019-07-09	14:52:18.872649
65	924	384	t	=	2019-07-09	14:52:18.892832
...	t	=
74	1000	646	t	=	2019-07-09	14:59:22.760747
74	1000	686	t	=	2019-07-09	14:59:22.780984
...	t	=

Πίνακας 1: Παράδειγμα ανεπεξέργαστων δεδομένων καρδιακού ρυθμού.

Από τον παραπάνω πίνακα μπορούμε να αντλήσουμε τις παρακάτω πληροφορίες:

- i. Τιμές σχετικά με τον καρδιακό ρυθμό, δηλαδή τους χτύπους της καρδιάς ανά λεπτό (bpm).
- ii. Τιμές σχετικά με τη ΜΚΡ, μετρώντας διαστήματα R – R, δηλαδή διαστήματα μεταξύ δύο διαδοχικών χτύπων.
- iii. Ημερομηνία κάθε μέτρησης.
- iv. Ακριβή χρονική στιγμή κάθε μέτρησης (timestamp).

3.2.2 Δεδομένα επιπέδων προσήλωσης από την επισημείωση των χρηστών

Τα δεδομένα επιπέδων προσήλωσης που επισημαίνουν οι χρήστες, δεν χρειάστηκαν κάποια επεξεργασία για να αξιοποιηθούν, καθώς κάθε ένα δευτερόλεπτο πραγματοποιούταν καταγραφή μίας νέας τιμής προσήλωσης, από τον ίδιο τον χρήστη που παρακολουθούσε το «playthrough» του, μετά το πέρας της αλληλοεπίδρασης με το παιχνίδι. Στον Πίνακα 2 παρουσιάζεται ένα παράδειγμα της μορφής του αρχείου που περιείχε τις τιμές επιπέδου προσήλωσης των χρηστών.

Δεδομένα επιπέδων προσήλωσης των συμμετεχόντων

Engagement Values	time	:	time
4	time	:	15:36.34
4	time	:	15:36.35
...	time	:	...
-5	time	:	15:37.1
-5	time	:	15:37.2
-5	time	:	15:37.3
...	time	:	...

Πίνακας 2: Παράδειγμα δεδομένων σχετικά με τα επίπεδα προσήλωσης από την επισημείωση των συμμετεχόντων στο παιχνίδι.

Από τον παραπάνω πίνακα μπορούμε να αντλήσουμε τις παρακάτω πληροφορίες:

- i. Τιμές σχετικά με τα επίπεδα προσήλωσης των χρηστών κατά την αλληλεπίδρασή τους με το ΠΣΣΥ.
- ii. Ακριβή χρονική στιγμή κάθε μέτρησης (timestamp).

3.3 Επεξεργασία των δεδομένων καρδιακού ρυθμού

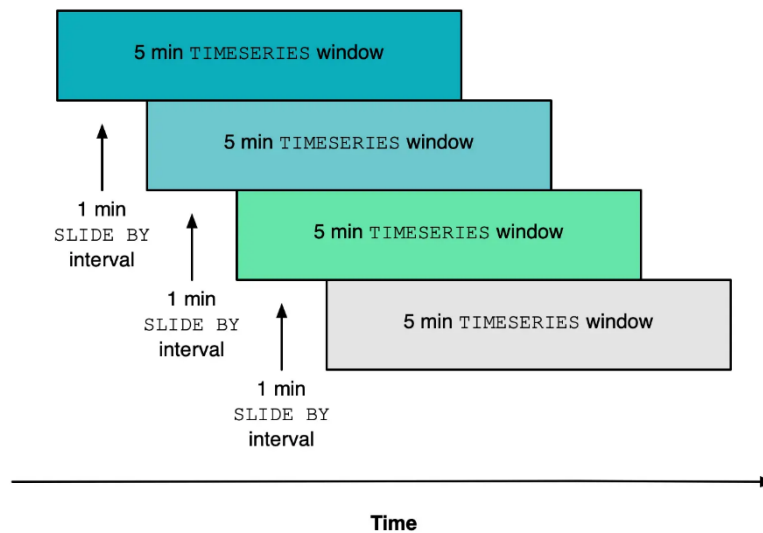
3.3.1 Εκκαθάριση και προεπεξεργασία δεδομένων καρδιακού ρυθμού

Για την επεξεργασία των δεδομένων που ελήφθησαν από τον αισθητήρα PulseSensor, αρχικά χρειάστηκε εκκαθάριση των τιμών που είχαν καταγραφεί περισσότερο της μίας φοράς, σε διάστημα λιγότερο του ενός δευτερολέπτου, γεγονός που αποτελούσε σφάλμα στη μέτρηση. Ιδανικά θα θέλαμε κάθε ένα δευτερόλεπτο να υπάρχει μία καινούργια καταγραφή ΜΚΡ. Για τον σκοπό αυτό τα δεδομένα εισήχθησαν στην Python και με την χρήση της βιβλιοθήκης Pandas, πραγματοποιήθηκε ανάγνωση και αποθήκευση των προς επεξεργασία στηλών σε λίστες. Εξαιτίας της ιδιομορφίας των δεδομένων του καρδιακού ρυθμού σε αντίθεση με τα δεδομένα προσήλωσης του χρήστη, κρίνεται σημαντική τόσο η εκκαθάριση των δεδομένων της ΜΚΡ από τις επαναλαμβανόμενες καταγραφές, όσο και η κατάλληλη επεξεργασία και απομόνωση των χρονικών στιγμών έτσι ώστε κάθε ξεχωριστή

καταγραφή να συνοδεύεται με την ακριβή χρονική στιγμή που έγινε. Για την υλοποίηση των παραπάνω, δημιουργήθηκαν τρεις λίστες που περιείχαν: η πρώτη (dt1) τις τιμές της MKP, η δεύτερη (dt1_time_min) το λεπτό της καταγραφής και η τρίτη (dt1_time_sec) το δευτερόλεπτο της καταγραφής. Εν συνεχεία δημιουργήθηκε η συνάρτηση «clearing()» η οποία λαμβάνει τρία ορίσματα, τις τρεις παραπάνω λίστες δηλαδή την dt1[i], dt1_time_min[i] και την dt1_time_sec[i], όπου i ο κάθε συμμετέχων. Με την χρήση της dt1, γίνεται εκκαθάριση των επαναλαμβανόμενων τιμών στην διάρκεια ενός δευτερολέπτου για κάθε συμμετέχοντα και με την χρήση της dt1_time_min, γίνεται μετατροπή των λεπτών σε δευτερόλεπτα και άθροιση με την dt1_time_sec, έτσι ώστε να δημιουργηθούν χρονικές ετικέτες για κάθε τιμή HRV, μετρημένες σε δευτερόλεπτα, για την διευκόλυνση στον ορισμό διαστημάτων, στη συνέχεια του πρακτικού μέρους. Η συνάρτηση «clearing()» επιστρέφει δύο λίστες, την rr_intervals_list που περιέχει τις «καθαρισμένες» τιμές της MKP και την time_list που περιλαμβάνει τις χρονικές ετικέτες της κάθε καταγραφής σε δευτερόλεπτα για κάθε συμμετέχοντα.

3.3.2 Χωρισμός των καταγραφών HRV σε χρονικά διαστήματα, με την χρήση επικαλυπτόμενων χρονικών παραθύρων παρακολούθησης

Με στόχο την αύξηση των δεδομένων για την μελλοντική τους χρήση ως είσοδο σε μοντέλα μηχανικής μάθησης, γίνεται χρήση μίας καινούργια συνάρτησης, της «f()», η οποία λαμβάνει τέσσερα ορίσματα, τις δύο λίστες που επιστρέφει η συνάρτηση «clearing()» δηλαδή τις rr_intervals_list και την time_list, τη χρονική διάρκεια σε δευτερόλεπτα που θα διαρκέσουν τα χρονικά διαστήματα παρακολούθησης και την χρονική διάρκεια σε δευτερόλεπτα της επικάλυψης. Η παραπάνω συνάρτηση επιστρέφει μία λίστα με όνομα rr_final, με υπό-λίστες για κάθε συμμετέχοντα, όπου κάθε υπό-λίστα περιλαμβάνει τα χρονικά διαστήματα που ορίσαμε για παρακολούθηση με την ανάλογη επικάλυψη.



Εικόνα 13: Σχηματική απεικόνιση της μεθόδου του διαχωρισμού σε χρονικά παράθυρα με την χρήση κυλιόμενων παραθύρων. Στο συγκεκριμένο παράδειγμα χρησιμοποιούνται χρονικά διαστήματα των 5 λεπτών με 1 λεπτό επικάλυψη.

3.4 Ανάλυση δεδομένων καρδιακού ρυθμού

3.4.1 Χαρακτηριστικά στον τομέα του χρόνου

Αφού γίνεται η απαραίτητη επεξεργασία στα δεδομένα MKP, ακολουθεί η ανάλυση των χρονικών μετρικών του HRV. Για τον σκοπό αυτό χρησιμοποιήθηκε η βιβλιοθήκη της python, «hrv-analysis» ως βάση για την επεξεργασία των δεδομένων των συμμετεχόντων. Πιο συγκεκριμένα δημιουργήθηκε στην python μια συνάρτηση με όνομα «hrv()», η οποία λαμβάνει ως ορίσματα την λίστα `rr_final` που αναφέρθηκε παραπάνω, καθώς και την ελάχιστη και την μέγιστη τιμή των R – R κορυφών του κάθε συμμετέχοντα. Η συνάρτηση «hrv()» εκτελεί τις παρακάτω διεργασίες σε κάθε υπό-λίστα της `rr_final` του κάθε συμμετέχοντα:

1. Αφαίρεση των ακραίων τιμών από το σήμα, μέσω της συνάρτησης «`remove_outliers`» της βιβλιοθήκης `hrv-analysis`.
2. Αντικατάσταση των ακραίων τιμών «nan» με την χρήση γραμμικής παρεμβολής, μέσω της συνάρτησης «`interpolate_nan_values`» της βιβλιοθήκης `hrv-analysis`.
3. Αφαίρεση των έκτοπων παλμών από το σήμα, μέσω της συνάρτησης «`remove_ectopic_beats`» της βιβλιοθήκης `hrv-analysis`, έτσι ώστε να λάβουμε μια καινούργια λίστα που περιέχει τις κανονικοποιημένες τιμές των R – R κορυφών, που είναι οι κορυφές N – N.
4. Αντικατάσταση των τιμών «nan» των έκτοπων παλμών με την χρήση γραμμικής παρεμβολής, μέσω της συνάρτησης «`interpolate_nan_values`» της βιβλιοθήκης `hrv-analysis`.

5. Εξαγωγή των χαρακτηριστικών στον τομέα του χρόνου μέσω της συνάρτησης «get_time_domain_features» της βιβλιοθήκης hrv-analysis.

Όσων αφορά τα χαρακτηριστικά στον τομέα του χρόνου λαμβάνουμε τις παρακάτω μετρικές:

- **Mean_NNI:** Ο Μέσος όρος των γειτονικών κανονικοποιημένων διαστημάτων N – N.
- **SDNN:** Η τυπική απόκλιση των διαστημάτων μεταξύ κανονικοποιημένων παλμών N – N και μετριέται σε ms. Αντανακλά τη συνολική MKP για την περίοδο ενδιαφέροντος.
- **SDSD:** Η τυπική απόκλιση των διαδοχικών διαφορών μεταξύ γειτονικών διαστημάτων N – N.
- **NN50:** Ο αριθμός των γειτονικών διαστημάτων N – N που διαφέρουν μεταξύ τους κατά περισσότερο από 50 ms.
- **pNN50:** Το ποσοστό των γειτονικών διαστημάτων N – N που διαφέρουν μεταξύ τους κατά περισσότερο από 50 ms.
- **NN20:** Ο αριθμός των γειτονικών διαστημάτων N – N που διαφέρουν μεταξύ τους κατά περισσότερο από 20 ms.
- **pNN20:** Το ποσοστό των γειτονικών διαστημάτων N – N που διαφέρουν μεταξύ τους κατά περισσότερο από 20 ms.
- **RMSSD:** Η τετραγωνική ρίζα του μέσου όρου των τετραγώνων διαδοχικών διαφορών μεταξύ γειτονικών διαστημάτων N – N.
- **Median_NN:** Ο μέσος όρος των απόλυτων τιμών των διαδοχικών διαφορών μεταξύ γειτονικών διαστημάτων N -N.
- **Range_NN:** Το εύρος των γειτονικών διαστημάτων N - N
- **CVSD:** Ο συντελεστής διακύμανσης των διαδοχικών διαφορών και προκύπτει εάν διαιρέσουμε το RMSSD με τον μέσο όρο των διαστημάτων N – N.
- **CV_NNI:** Ο συντελεστής διακύμανσης των γειτονικών διαστημάτων N – N, δηλαδή ο λόγος του SDNN προς τον μέσο όρο των διαστημάτων N – N.
- **Mean_HR:** Ο μέσος όρος του καρδιακού ρυθμού.
- **Max_HR:** Η μέγιστη τιμή του καρδιακού ρυθμού.
- **Min_HR:** Η ελάχιστη τιμή του καρδιακού ρυθμού.
- **STD_HR:** Η τυπική απόκλιση του καρδιακού ρυθμού.

3.4.2 Χαρακτηριστικά στον τομέα της συχνότητας

Το αντικείμενο έρευνας της παρούσας Διπλωματικής, επεξεργάζεται αποκλειστικά τα δεδομένα της MKP στον τομέα του χρόνου. Ωστόσο θα γίνει μία αναφορά στα χαρακτηριστικά και στις μετρικές που μπορούν να αντληθούν στον τομέα της συχνότητας, ως αφορμή περαιτέρω έρευνας.

Οι μετρήσεις στον τομέα της συχνότητας περιγράφουν την κατανομή της απόλυτης ή της σχετικής ισχύος σε τέσσερις ζώνες συχνότητας. Η φασματική

ανάλυση της MKP χρησιμοποιείται ευρέως ως μη επεμβατική τεχνική για την αξιολόγηση: α) της δραστηριότητας του ΑΝΣ στην καρδιά και β) της ισορροπίας μεταξύ των δύο κύριων κλάδων του, του συμπαθητικού και του παρασυμπαθητικού συστήματος [37]. Η «Task Force» της Ευρωπαϊκής Εταιρείας Καρδιολογίας και Βορειοαμερικανικής Εταιρείας Βηματοδότησης και Ηλεκτροφυσιολογίας, χώρισε τις ταλαντώσεις του καρδιακού παλμού σε ζώνες εξαιρετικά χαμηλής συχνότητας (ULF, ≤ 0.003 Hz), πολύ χαμηλής συχνότητας (VLF, 0.003 – 0.04 Hz), χαμηλής συχνότητας (LF, 0.04 – 0.15 Hz) και υψηλής συχνότητας (HF, 0.15 – 0.40 Hz) [38]. Τα χαρακτηριστικά στον τομέα της συχνότητας είναι τα παρακάτω:

- **LF:** Η ζώνη LF (0.04 – 0.15 Hz), καταγράφεται τυπικά σε ελάχιστη περίοδο 2 λεπτών. Αυτή η περιοχή ονομαζόταν παλαιότερα εύρος βαροϋποδοχέων, επειδή αντανακλούσε κυρίως τη δραστηριότητα του βαροϋποδοχέα κατά τη διάρκεια συνθηκών ηρεμίας. Κατά τη διάρκεια περιόδων με αργούς ρυθμούς αναπνοής, η πνευμονογαστρική δραστηριότητα μπορεί εύκολα να δημιουργήσει ταλαντώσεις στους καρδιακούς ρυθμούς που περνούν στη ζώνη LF. Οι σχετιζόμενες με το αναπνευστικό απαγωγές, είναι ιδιαίτερα παρούσες στη ζώνη LF, όταν οι ρυθμοί αναπνοής είναι κάτω από 8.5 bpm, ή περιόδων 7sec, ή όταν κάποιος αναστενάζει, ή παίρνει βαθιά αναπνοή [38].
- **HF:** Η αναπνευστική ζώνη (0.15 – 0.40 Hz), όπως αλλιώς ονομάζεται η περιοχή υψηλής συχνότητας, καταγράφεται συμβατικά σε μία ελάχιστη περίοδο 1 λεπτού. Η ζώνη HF αντανακλά την παρασυμπαθητική δραστηριότητα και ονομάζεται αναπνευστική ζώνη επειδή αντιστοιχεί στις διακυμάνσεις του καρδιακού ρυθμού που σχετίζονται με τον αναπνευστικό κύκλο. Η ισχύς υψηλής συχνότητας σχετίζεται σε μεγάλο βαθμό με τις μετρικές του χρονικού τομέα pNN50 και RMSSD. Η ισχύς της ζώνης μπορεί να αυξηθεί τη νύχτα και να μειωθεί κατά τη διάρκεια της ημέρας. Η χαμηλότερη ισχύς HF συσχετίζεται με άγχος, πανικό, άγχος ή ανησυχία. Η ρύθμιση του πνευμονογαστρικού τόνου βοηθά στην διατήρηση της δυναμικής αυτόνομης ρύθμισης, που είναι σημαντική για την καρδιαγγειακή υγεία. Η ελλιπής αναστολή του πνευμονογαστρικού τόνου, εμπλέκεται σε αυξημένη νοσηρότητα [38].
- **VLF:** Η ζώνη πολύ χαμηλής συχνότητας (0.003 – 0.04 Hz) καταγράφεται σε περιόδους μεταξύ 25 – 300 δευτερόλεπτα. Συσχετίζεται με θερμικό και ορμονικό έλεγχο σε συνδυασμό με αγγειοκινητική δραστηριότητα.
- **LF / HF ratio:** Η αναλογία ισχύος LF προς HF βασίζεται σε εγγραφές 24 ωρών, κατά τις οποίες τόσο η παρασυμπαθητική όσο και η συμπαθητική νευρική δραστηριότητα συμβάλλουν στην ισχύ της ζώνης LF. Ο λόγος LF / HF θεωρείται πως συσχετίζεται με την αναλογία μεταξύ της δραστηριότητας ΣΝΣ και ΠΝΣ. Μια χαμηλή αναλογία LF / HF αντανακλά την παρασυμπαθητική κυριαρχία, δηλαδή την εξοικονόμηση ενέργειας. Αντίθετα ένας υψηλός λόγος LF / HF υποδηλώνει κυριαρχία συμπαθητικής λειτουργίας σε καταστάσεις έντασης ή φυγής.

- **LFnu:** Η ζώνη χαμηλής συχνότητας σε κανονικοποιημένες μονάδες. Πρόκειται για τον λόγο της χαμηλής συχνότητας προς το άθροισμα της χαμηλής και της υψηλής συχνότητας.
- **HFnu:** Η ζώνη υψηλής συχνότητας σε κανονικοποιημένες μονάδες. Πρόκειται για τον λόγο της υψηλής συχνότητας προς το άθροισμα της χαμηλής και της υψηλής συχνότητας.
- **Total_Power:** Η συνολική διακύμανση των κανονικοποιημένων κορυφών $N - N$, πρόκειται για το άθροισμα όλων των φασματικών ζωνών.

3.5 Επεξεργασία και ανάλυση των δεδομένων επισημείωσης χρήστη

3.5.1 Προεπεξεργασία και χωρισμός των δεδομένων προσήλωσης του χρήστη σε χρονικά διαστήματα, με την χρήση επικαλυπτόμενων χρονικών παραθύρων παρακολούθησης

Για την ανάγνωση των δεδομένων της προσήλωσης του χρήστη, έγινε χρήση της βιβλιοθήκης Pandas της Python. Πιο συγκεκριμένα δημιουργήθηκε μια λίστα με όνομα `dt2`, η οποία περιλάμβανε τα δεδομένα προσήλωσης των χρηστών. Δεν χρειάστηκε η αποθήκευση των χρονικών στιγμών κάθε καταγραφής καθώς τα δεδομένα ήταν οργανωμένα ανά 1 δευτερόλεπτο. Για τον χωρισμό των δεδομένων επισημείωσης του χρήστη σε χρονικά διαστήματα, με τη χρήση επικαλυπτόμενων χρονικών παραθύρων παρακολούθησης, δημιουργήθηκε η συνάρτηση `<func()>` στην ίδια φιλοσοφία με την συνάρτηση `<f()>` που αφορά την διαχείριση των διαστημάτων του καρδιακού ρυθμού. Η συνάρτηση δέχεται τρία ορίσματα, το πρώτο είναι το `dt2[i]` όπου i ο κάθε συμμετέχων, το δεύτερο είναι το μέγεθος σε δευτερόλεπτα για τα διαστήματα και το τρίτο η χρονική επικάλυψη. Η `<func()>` επιστρέφει μία λίστα από υπολίστες με όνομα `result`, που περιέχει τα χρονικά διαστήματα που ορίστηκαν παραπάνω για κάθε συμμετέχοντα.

3.5.2 Ανάλυση δεδομένων προσήλωσης του χρήστη

Για την αξιοποίηση και την καλύτερη ερμηνεία των δεδομένων προσήλωσης κάθε συμμετέχοντα, αφού γίνεται ο διαχωρισμός σε χρονικά διαστήματα, ακολουθείται η εξαγωγή στατιστικών στοιχείων από κάθε υπολίστα. Για την πραγματοποίηση της εξαγωγής στατιστικών στοιχείων και την σύγκριση των δεδομένων προσήλωσης, χρησιμοποιήθηκαν τέσσερις μετρικές:

- **Η Μέση τιμή των δεδομένων επισημείωσης (Mean annotation value, μA):** Εκφράζει την κεντρική τιμή ενός συνόλου δεδομένων, δηλαδή το άθροισμα των δεδομένων με το πλήθος τους στο σύνολο. Για τον υπολογισμό της μέσης τιμής σχολιασμού δημιουργήθηκε η συνάρτηση `<find_mean_value()>` που λαμβάνει ως όρισμα την λίστα της οποίας θέλουμε τη μέση τιμή σχολιασμού.

- **Η Περιοχή του ίχνους των δεδομένων επισημείωσης (Area of the annotation trace, $\int A$):** Υπολογίζεται από το σύνθετο τραπεζοειδές ολοκλήρωμα και κανονικοποιείται κατά τη χρονική διάρκεια. Για τον υπολογισμό του τραπεζοειδούς ολοκληρώματος δημιουργήθηκε η συνάρτηση «find_trapezoid_area», που λαμβάνει ως όρισμα τη λίστα της οποίας θέλουμε το τραπεζοειδές ολοκλήρωμα.
- **Το Πλάτος (Amplitude, \hat{A}):** Υπολογίζεται από την διαφορά μέγιστης και ελάχιστης τιμής. Για τον υπολογισμό του πλάτους δημιουργήθηκε η συνάρτηση «find_amplitude», που λαμβάνει ως όρισμα τη λίστα της οποίας θέλουμε να υπολογίσουμε το πλάτος.
- **Η Μέση κλίση του ίχνους των δεδομένων επισημείωσης (Mean Value of the annotation trace, ΔA):** Ο λόγος της κάθετης διαφοράς ύψους προς την οριζόντια απόσταση. Για τον υπολογισμό της μέσης κλίσης δημιουργήθηκε η συνάρτηση «find_average_gradient», που λαμβάνει ως όρισμα τη λίστα της οποίας θέλουμε να υπολογίσουμε τη μέση κλίση.

3.5.3 Προετοιμασία δεδομένων προσήλωσης για δυαδική ταξινόμηση

Σε συνέχεια της πειραματικής έρευνας της παρούσας Διπλωματικής, θα γίνει εκπαίδευση μοντέλων μηχανικής μάθησης χρησιμοποιώντας δυαδική ταξινόμηση στην έξοδο των μοντέλων. Με σκοπό να μπορέσουμε να εισάγουμε τα δεδομένα της επισημείωσης των συμμετεχόντων σχετικά με την προσήλωση τους, ως έξοδο στην εκπαίδευση των μοντέλων μηχανικής μάθησης, χρειάζεται στα δεδομένα που λάβαμε, αφού επεξεργάστηκαν, να εξαχθούν κατάλληλες μετρικές, όπως αναφέρθηκαν παραπάνω. Πιο συγκεκριμένα, κάθε υπολίστα με δεδομένα προσήλωσης, που διαιρείται από τα χρονικά διαστήματα που έχουμε ορίσει, να εξάγει μία τιμή για την μετρική επισημείωσης που δίνουμε ως όρισμα, κάθε φορά. Δημιουργούμε μία συνάρτηση με όνομα «couple()», η οποία παίρνει ως όρισμα μία λίστα και χωρίζει τα στοιχεία της, όπου κάθε στοιχείο αντιπροσωπεύει μία τιμή μετρικής επισημείωσης, σε ζεύγη (το 1^ο με το 2^ο, το 2^ο με το 3^ο κ.ο.κ.). Εν συνέχεια τα ζεύγη συγκρίνονται μεταξύ τους και εάν το πρώτο είναι μεγαλύτερο του δευτέρου, τότε αφού έχουμε δημιουργήσει μία κενή λίστα με όνομα output, μπαίνει ως πρώτο στοιχείο της η τιμή 1, ενώ αν ισχύει το αντίθετο μπαίνει η τιμή 0 και έτσι συνεχίζεται η διαδικασία για τα διαστήματα του κάθε συμμετέχοντα, μέχρι να δημιουργηθεί μία λίστα με 0 και 1 για τον καθένα.

3.6 Συσχέτιση εισόδου – εξόδου για τα μοντέλα μηχανικής μάθησης

Όπως φαίνεται παραπάνω, για κάθε 2 υπολίστες που αφορούν τα δεδομένα προσήλωσης του χρήστη λαμβάνουμε μία δυαδική τιμή. Για τον λόγο αυτό κρίνεται απαραίτητο να γίνει συσχέτιση εισόδου – εξόδου για τα μοντέλα μηχανικής μάθησης που θα ακολουθήσουν, έτσι ώστε για κάθε συμμετέχοντα κάθε υπολίστα με δεδομένα καρδιακού ρυθμού να αντιστοιχεί σε μία τιμή 0 ή 1. Δηλαδή θα πρέπει η χρονική

παρατήρηση στα διαστήματα παρακολούθησης, να είναι μικρότερη από το μέγεθος ολόκληρης της καταγραφής των δεδομένων για να υπάρχει αντιστοιχία εισόδου – εξόδου. Χρειάζεται επομένως για κάθε συμμετέχοντα, τα δεδομένα ΜΚΡ να είναι μία λίστα που να περιέχει υπολίστες με δεδομένα HRV και τα επεξεργασμένα δεδομένα προσήλωσης του χρήστη να είναι μία λίστα που να περιέχει τιμές 0 ή 1, όπου οι δύο λίστες που αναφέραμε να είναι αντιστοιχισμένες στοιχείο προς στοιχείο και συνεπακόλουθα να έχουν το ίδιο μέγεθος.

Κεφάλαιο 4: Μέθοδοι Μηχανικής Μάθησης

Το κεφάλαιο αυτό αποτελεί το κυρίως μέρος του ερευνητικού πρακτικού τμήματος της παρούσας Διπλωματικής. Στο κεφάλαιο αυτό, θα γίνει αναφορά στους αλγόριθμους μηχανικής μάθησης που χρησιμοποιήθηκαν για εκπαίδευση, στη διαδικασία που ακολουθήθηκε για τον διαχωρισμό των δεδομένων σε δεδομένα εκπαίδευσης και δεδομένα ελέγχου, στα προβλήματα που παρουσιάστηκαν κατά την ανάπτυξη των μοντέλων αυτών, καθώς και στους τρόπους επίλυσης που χρησιμοποιήθηκαν για να γίνουν τα μοντέλα πιο αξιόπιστα και να έχουν μεγαλύτερη ικανότητα πρόβλεψης.

Αρχικά αφαιρέθηκε ο συμμετέχων 3 επειδή η μορφή που είχαν τα ακατέργαστα δεδομένα κειμένου δεν ήταν αναγνώσιμη από τον κώδικα, αλλά και ο συμμετέχων 22 από τα επισημειωμένα δεδομένα, καθώς δεν βρισκόταν στην λίστα με τους συμμετέχοντες για τα δεδομένα καρδιακού ρυθμού. Για την εκπαίδευση των μοντέλων χρησιμοποιήθηκε επιβλεπόμενη μάθηση με την χρήση δυαδικής ταξινόμησης, όπου ως είσοδος ορίστηκαν οι μετρικές στον τομέα του χρόνου που προκύπτουν από την επεξεργασία των δεδομένων καρδιακού ρυθμού, ενώ ως έξοδος ορίστηκαν οι δυαδικές τιμές 0 ή 1 που προκύπτουν από την σύγκριση των μετρικών επισημείωσης μεταξύ δύο διαδοχικών χρονικών διαστημάτων παρακολούθησης.

4.1 Επιλογή και δημιουργία αλγόριθμου *leave-one-out* για *cross validation*

Για να δημιουργήσουμε ένα *training – test set* για την εκπαίδευση των μοντέλων μηχανικής μάθησης, χρειάζεται η κατάλληλη επιλογή ενός αλγόριθμου *cross validation* έτσι ώστε να περιοριστεί όσο το δυνατόν περισσότερο ο παράγοντας υποκειμενισμού. Για τον λόγο αυτό δεν επιλέχθηκε η συνάρτηση `<train_test_split()>` της βιβλιοθήκης `<sklearn>` της Python, αλλά προτιμήθηκε η χρήση του αλγόριθμου `<leave-one-out>`. Σκοπός της χρήσης του αλγόριθμου `<leave-one-out>`, είναι να εκπαιδεύεται το μοντέλο με δεδομένα από όλους τους συμμετέχοντες εκτός ενός, του οποίου τα δεδομένα χρησιμεύουν για έλεγχο (*testing*) και η λογική αυτή επαναλαμβάνεται τόσες φορές όσες το πλήθος των συμμετεχόντων. Για την πραγμάτωση των παραπάνω δημιουργήθηκε ένας κώδικας βασισμένος στην ιδέα του αλγόριθμου `<leave-one-out>` και ειδικότερα του `<leave-one-participant-out>`. Πρόκειται για ένα `<for-loop>` του οποίου το πλήθος των επαναλήψεων ταυτίζεται με αυτό των συμμετεχόντων, διαχωρίζει τις τιμές `test_x`, `test_y`, `train_x` και `train_y` δηλαδή οι πρώτες δύο αφορούν το κομμάτι του ελέγχου, ενώ οι δύο επόμενες το κομμάτι της εκπαίδευσης, όπου με `x` συμβολίζουμε την είσοδο του μοντέλου δηλαδή τα δεδομένα HRV, ενώ με `y` την έξοδο του μοντέλου δηλαδή το σύνολο των 0 και 1 που αφορούν δεδομένα προσήλωσης.


Για την πραγματοποίηση όλων των παραπάνω, δημιουργήθηκε η συνάρτηση `<ml_loo()>`. Η συνάρτηση αυτή, λαμβάνει ως ορίσματα την λίστα που περιέχει όλες

τις υπολίστες για όλους τους συμμετέχοντες με όνομα «res1», την λίστα που περιέχει τις τιμές 0 και 1 για όλους τους συμμετέχοντες με όνομα «res2», το μοντέλο με το οποίο θα γίνει η εκπαίδευση, καθώς και μία λίστα με όνομα «length_final». Όσον αφορά στη λίστα «length_final», τα στοιχεία της είναι τα μεγέθη των λιστών τόσο του καρδιακού ρυθμού όσο και της προσήλωσης κάθε συμμετέχοντα, για να μπορεί να γίνει σωστή οριοθέτηση μεταξύ των υπολιστών αλλά και του συνόλου 0 και 1 για τον κάθε συμμετέχοντα. Η συνάρτηση «ml_loo()» επιστρέφει δύο λίστες με ονόματα «predicted_targets» και «actual_targets», όπου η «actual_targets» είναι το σύνολο των δεδομένων ελέγχου (testing) της εξόδου και η «predicted_targets» είναι το σύνολο των προβλέψεων εξόδου του μοντέλου.

4.2 Επιλογή και χρήση αλγορίθμων μηχανικής μάθησης

Έγινε επιλογή 8 αλγορίθμων / ταξινομητών (classifiers) μηχανικής μάθησης που ήταν συμβατοί με την δυαδική ταξινόμηση, για την διενέργεια επιβλεπόμενης μάθησης στα δεδομένα μας, που είναι οι παρακάτω:


- **K-Nearest Neighbour:** Αντιπροσωπεύει κάθε σημείο δεδομένων σε ένα χώρο n διαστάσεων, ο οποίος ορίζεται από n χαρακτηριστικά. Υπολογίζει την απόσταση μεταξύ ενός σημείου από ένα άλλο και στη συνέχεια εκχωρεί την ετικέτα των μη παρατηρηθέντων δεδομένων με βάση τις ετικέτες των πλησιέστερων παρατηρούμενων σημείων δεδομένων.



Εικόνα 14: Γραφική απεικόνιση του τρόπου λειτουργίας του KNN Classifier.

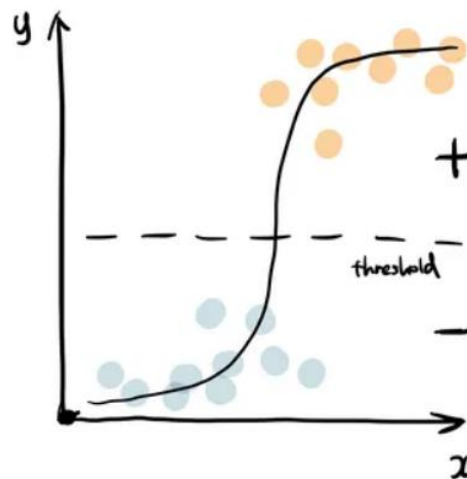
- **Gaussian Naive Bayes:** Βασισμένος στο θεώρημα του Bayes, μία προσέγγιση για τον υπολογισμό της πιθανότητας υπό όρους που βασίζεται σε προηγούμενες γνώσεις και στην «αφελή» υπόθεση ότι κάθε χαρακτηριστικό είναι ανεξάρτητο το ένα από το άλλο. Το μεγαλύτερο πλεονέκτημα αυτού του ταξινομητή είναι, ότι ενώ οι

περισσότεροι αλγόριθμοι μηχανικής μάθησης βασίζονται σε μεγάλο όγκο δεδομένων εκπαίδευσης, αποδίδει σχετικά καλά ακόμα και όταν το μέγεθος των δεδομένων εκπαίδευσης είναι μικρό. Ο Gaussian Naive Bayes ακολουθεί την κανονική κατανομή.



Εικόνα 15: Γραφική αναπαράσταση του τρόπου λειτουργίας του Gaussian Naive Bayes Classifier.

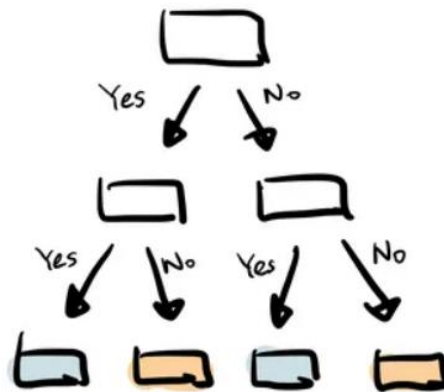
- **Logistic Regression:** Χρησιμοποιεί τη σιγμοειδή συνάρτηση για να επιστρέψει την πιθανότητα μίας ετικέτας. Χρησιμοποιείται ευρέως όταν το πρόβλημα ταξινόμησης είναι δυαδικό. Η σιγμοειδής συνάρτηση δημιουργεί μία έξοδο πιθανότητας, συγκρίνοντας την πιθανότητα με ένα προκαθορισμένο όριο και το αντικείμενο αντιστοιχίζεται σε μία ετικέτα ανάλογα.



Εικόνα 16: Γραφική αναπαράσταση της λειτουργίας της Logistic Regression Classifier.

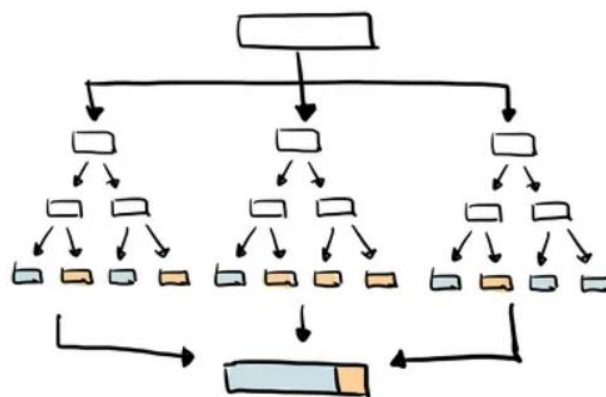
- **Decision Tree:** Δημιουργεί κλαδιά δέντρων σε μία προσέγγιση ιεραρχίας και κάθε κλαδί μπορεί να θεωρηθεί ως δήλωση if – else. Τα κλαδιά αναπτύσσονται διαμερίζοντας το σύνολο δεδομένων σε

υποσύνολα, με βάση τα πιο σημαντικά χαρακτηριστικά. Η τελική ταξινόμηση γίνεται στα φύλλα του δέντρου απόφασης.




Εικόνα 17: Γραφική αναπαράσταση του Decision Tree Classifier.

- **Random Forest:** Όπως υποδηλώνει το όνομά του, ο ταξινομητής αποτελείται από μία συλλογή δέντρων απόφασης. Είναι ένας κοινός τύπος μεθόδων συνόλου που συγκεντρώνουν αποτελέσματα από πολλαπλούς προγνωστικούς παράγοντες. Χρησιμοποιεί την τεχνική που επιτρέπει σε κάθε δέντρο να εκπαιδεύεται σε μία τυχαία δειγματοληψία του αρχικού συνόλου δεδομένων και παίρνει την πλειοψηφία των ψήφων από τα δέντρα. Σε σύγκριση με το δέντρο αποφάσεων έχει καλύτερη γενίκευση αλλά λιγότερο ερμηνεύσιμη, λόγω των περισσότερων επιπέδων που προστέθηκαν στο μοντέλο.



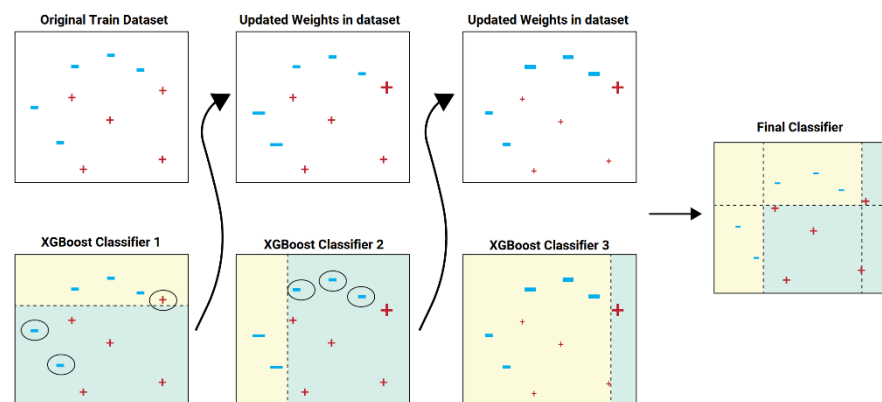
Εικόνα 18: Γραφική αναπαράσταση του τρόπου λειτουργίας του Random Forest Classifier.

- **Support Vector Machine:** Ο SVM βρίσκει τον καλύτερο τρόπο ταξινόμησης των δεδομένων, με βάση τη θέση σε σχέση με ένα όριο μεταξύ θετικής και αρνητικής κλάσης. Αυτό το περίγραμμα είναι γνωστό ως υπερεπίπεδο που μεγιστοποιεί την απόσταση μεταξύ σημείων δεδομένων από διαφορετικές κλάσεις.




Εικόνα 19: Γραφική αναπαράσταση του τρόπου λειτουργίας του SVM Classifier.

- **XGBoost:** Είναι μία βελτιστοποιημένη καταναμημένη βιβλιοθήκη ενισχυμένης διαβάθμισης, σχεδιασμένη για αποτελεσματική και επεκτάσιμη εκπαίδευση μοντέλων μηχανικής μάθησης. Είναι μία μέθοδος εκμάθησης συνόλου που συνδυάζει τις προβλέψεις πολλών «αδύναμων» μοντέλων, για να παράγει μία ισχυρή πρόβλεψη. Το XGBoost σημαίνει Extreme Gradient Boosting και έχει γίνει ένας από τους πιο δημοφιλείς και ευρέως χρησιμοποιούμενους αλγόριθμους μηχανικής μάθησης, λόγω της ικανότητάς του να διαχειρίζεται μεγάλα σύνολα δεδομένων και την ικανότητά του να επιτυγχάνει κορυφαίες επιδόσεις σε πολλές εργασίες μηχανικής μάθησης.



Εικόνα 20: Σχηματική αναπαράσταση της λειτουργίας του XGBoost Classifier.

- **Multi-Layer Perceptron (MLP):** Είναι μία πλήρως συνδεδεμένη κατηγορία τεχνητού νευρωνικού δικτύου. Ένα MLP αποτελείται από τουλάχιστον τρία επίπεδα κόμβων: ένα στρώμα εισόδου, ένα κρυφό στρώμα και ένα στρώμα εξόδου. Εκτός από τους κόμβους εισόδου, κάθε κόμβος είναι ένας νευρώνας που χρησιμοποιεί μία μη γραμμική συνάρτηση ενεργοποίησης. Το MLP χρησιμοποιεί μία εποπτευόμενη τεχνική εκμάθησης, που βασίζεται σε κανόνες που ονομάζονται backpropagation δηλαδή αντίστροφη λειτουργία αυτόματης διαφοροποίησης για εκπαίδευση. Τα πολλαπλά στρώματα και η μη γραμμική ενεργοποίηση, διακρίνουν το MLP από ένα γραμμικό perceptron.



Εικόνα 21: Σχηματική αναπαράσταση της λειτουργίας του MLP Classifier.

Για την αξιοποίηση των παραπάνω αλγορίθμων μηχανικής μάθησης, για κάθε αλγόριθμο δημιουργήθηκε μία συνάρτηση, η οποία διενεργεί τις εξής λειτουργίες:

1. Την κλήση της συνάρτησης «ml_loo()» με παραμέτρους την είσοδο, την έξοδο, τον εκάστοτε αλγόριθμο μηχανικής μάθησης και την λίστα «length_final».
2. Την κατασκευή του «confusion matrix» δηλαδή του πίνακα που συνοψίζει την απόδοση του μοντέλου μηχανικής μάθησης σε ένα σύνολο δεδομένων δοκιμής. Ο πίνακας εμφανίζει: α) τον αριθμό των αληθώς θετικών (true positive, TP), β) τον αριθμό των αληθώς αρνητικών (true negative, TN), γ) τον αριθμό των ψευδώς θετικών (false positive, FP) και δ) τον αριθμό των ψευδώς αρνητικών (false negative, FN) που παράγονται από το μοντέλο στα δεδομένα δοκιμής.
3. Τον υπολογισμό της μετρικής Accuracy. Χρησιμοποιείται για την μέτρηση της απόδοσης του μοντέλου. Ορίζεται ως ο λόγος του συνόλου των αληθώς θετικών και αληθώς αρνητικών, προς όλο το σύνολο.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN}$$

4. Τον υπολογισμό της μετρικής Precision. Εκφράζει το πόσο ακριβείς είναι οι θετικές προβλέψεις ενός μοντέλου. Ορίζεται ως ο λόγος των αληθώς θετικών προβλέψεων προς τον συνολικό αριθμό των θετικών προβλέψεων που γίνονται από το μοντέλο.

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

5. Τον υπολογισμό της μετρικής Recall / Sensitivity. Εκφράζει την αποτελεσματικότητα ενός μοντέλου ταξινόμησης στον εντοπισμό όλων των σχετικών περιπτώσεων από ένα σύνολο δεδομένων. Ορίζεται ως ο λόγος των αληθώς θετικών περιπτώσεων προς το άθροισμα των αληθώς θετικών και των ψευδώς αρνητικών προβλέψεων.

$$Recall = \frac{TP}{TP+FN}$$

6. Τον υπολογισμό της μετρικής Specificity. Εκφράζει την αναλογία των αληθώς αρνητικών που προσδιορίζονται σωστά από το μοντέλο. Ορίζεται ως ο λόγος των αληθώς αρνητικών περιπτώσεων προς το άθροισμα των αληθώς αρνητικών και των ψευδώς θετικών προβλέψεων.

$$Specificity = \frac{TN}{TN+FP}$$

7. Τον υπολογισμό της μετρικής F1 Score. Συνδυάζει τις μετρικές precision και recall, χρησιμοποιώντας τον αρμονικό μέσο όρο τους.
8. Τον υπολογισμό και την σχεδίαση της μετρικής area under curve (AUC). Εκφράζει την μέτρηση απόδοσης για τα προβλήματα ταξινόμησης σε διάφορες τιμές και ρυθμίσεις κατωφλίου. Αντιπροσωπεύει το βαθμό ή το μέτρο της διαχωρισιμότητας, δηλαδή την ικανότητα του μοντέλου να διακρίνει μεταξύ των τάξεων. Όσο υψηλότερες είναι οι τιμές της AUC, τόσο καλύτερο είναι το μοντέλο στην πρόβλεψη. Οι τιμές της AUC κυμαίνονται από 0 έως και 1.

Αναφέρεται παρακάτω η αντιστοιχία των ονομάτων των συναρτήσεων που χρησιμοποιήθηκαν στον κώδικα, με τους αλγόριθμους μηχανικής μάθησης:

Αντιστοίχιση συναρτήσεων πρακτικού μέρους – αλγορίθμων μηχανικής μάθησης

Συνάρτηση	Αλγόριθμος Μηχανικής Μάθησης
KNN()	KNNClassifier()
Gaussian()	GaussianNB()
Logistic()	LogisticRegression()
DecissionTree()	DecissionTreeClassifier()
RandomForest()	RandomForestClassifier()
SupportVectorMachine()	SVC(C = 1.0, kernel = "rbf", probability = False)
XG()	XGBClassifier()
mlp()	MLPClassifier()

Πίνακας 3: Πίνακας αντιστοίχισης συναρτήσεων πρακτικού μέρους και αλγορίθμων μηχανικής μάθησης.

Κεφάλαιο 5: Αποτελέσματα

Στο παρακάτω κεφάλαιο παρουσιάζονται τα αποτελέσματα που παράγει ο κώδικας που κατασκευάστηκε για την υλοποίηση του πρακτικού μέρους της παρούσας Διπλωματικής Εργασίας. Πιο συγκεκριμένα παρουσιάζονται οι πίνακες και τα διαγράμματα που παράγει ο κώδικας: α) κατά την εκπαίδευση με όλους τους συμμετέχοντες, β) κατά την εκπαίδευση με περιορισμένο αριθμό συμμετεχόντων που επιλέχθηκαν, μετά από την επίλυση των προβλημάτων που παρουσιάστηκαν εξαιτίας αρκετών συμμετεχόντων που χαρακτηρίστηκαν ως «outliers». Είναι εμφανές στους πίνακες και τα στιγμιότυπα που ακολουθούν, πως για αλγόριθμους όπως ο KNN, ο Decision Tree, ο Random Forest και ο XGBoost λαμβάνουμε αρκετά ικανοποιητικά δεδομένα. Οι λόγοι που τα αποτελέσματα βελτιώθηκαν αρκετά για τους παραπάνω αλγόριθμους και για επιλεγμένους συμμετέχοντες, αλλά και αναλυτικά τα προβλήματα που παρουσιάστηκαν καθώς και οι τρόποι επίλυσής τους θα αναλυθούν στο Κεφάλαιο 6.

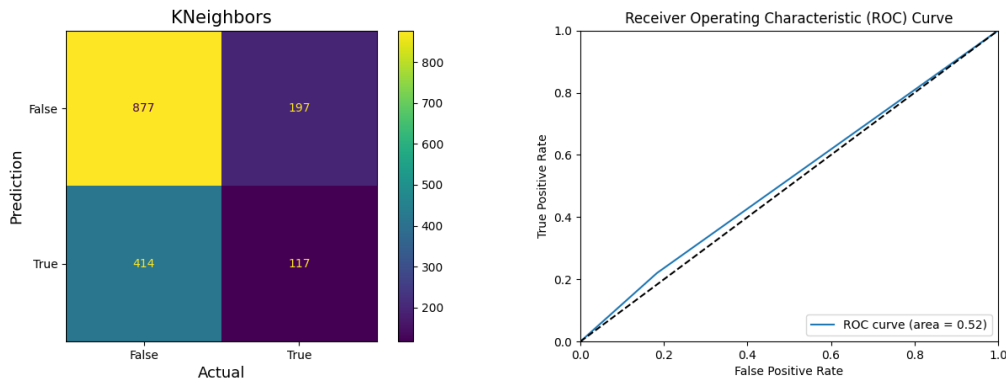
5.1 Αποτελέσματα από την εκπαίδευση των μοντέλων μηχανικής μάθησης με όλους τους συμμετέχοντες

5.1.1 Αποτελέσματα με την χρήση της Μέσης Τιμής (Mean Value) των δεδομένων προσήλωσης, ως μετρικής εξόδου για χρονικά διαστήματα παρακολούθησης 10sec για όλους τους συμμετέχοντες


Μετρικές όλων των μοντέλων μηχανικής μάθησης με χρήση μετρικής προσήλωσης την μέση τιμή των επισημειωμένων δεδομένων και για χρονικά διαστήματα 10sec

	KNN Classifier	GaussianNB Classifier	Logistic Regression Classifier	Decision Tree Classifier	Random Forest Classifier	SVM Classifier	XGBoost Classifier	MLP Classifier
Accuracy	0.6193	0.6647	0.6691	0.5831	0.6523	0.6691	0.6404	0.6492
Precision	0.3726	0.2941	1.0	0.3740	0.4415	1.0	0.4315	0.2777
Sensitivity	0.2203	0.0094	0.0	0.3860	0.1920	0.0	0.2730	0.0376
Specificity	0.8165	0.9888	1.0	0.6806	0.8798	1.0	0.8221	0.9515
F1 Score	0.2769	0.0182	0.0	0.3799	0.2677	0.0	0.3344	0.0663
AUC	0.5184	0.4991	0.5	0.5333	0.5359	0.5	0.5476	0.4946

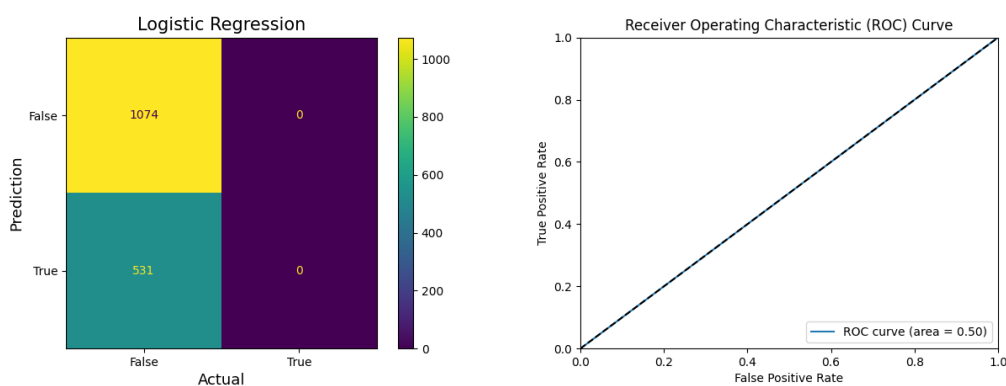
Πίνακας 4: Τιμές μετρικών όλων των μοντέλων μηχανικής μάθησης, με μετρική προσήλωσης την μέση τιμή των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec.



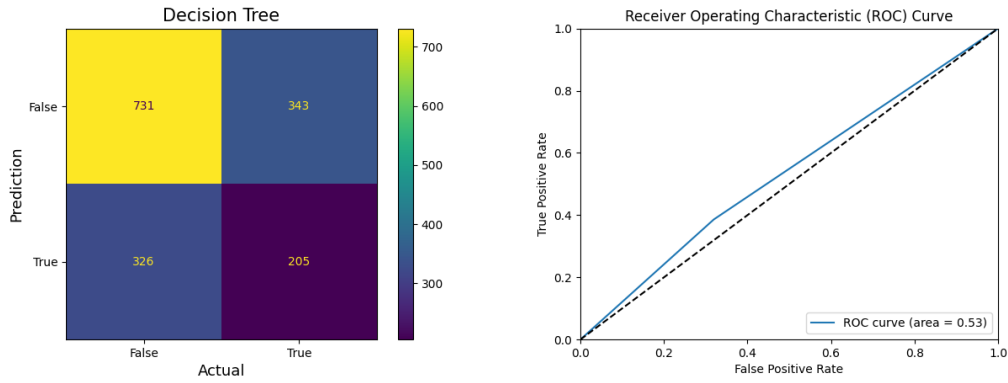
Εικόνα 22: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο KNN Classifier, με μετρική προσήλωσης την μέση τιμή των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec.




Εικόνα 23: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο GaussianNB Classifier, με μετρική προσήλωσης την μέση τιμή των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec.




Εικόνα 24: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο Logistic Regression Classifier, με μετρική προσήλωσης την μέση τιμή των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec.



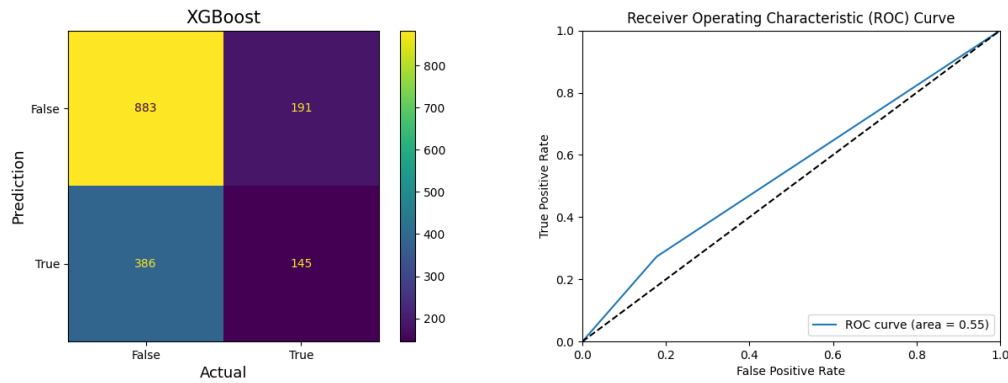
Εικόνα 25: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο Decision Tree Classifier, με μετρική προσήλωσης την μέση τιμή των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec.



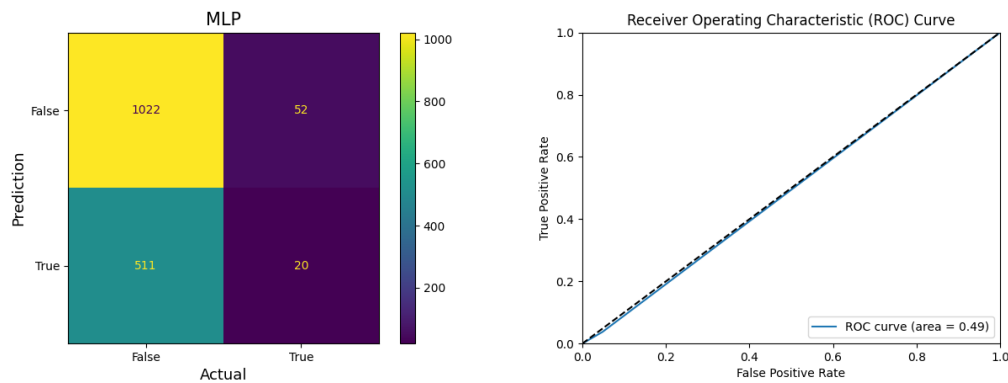
Εικόνα 26: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο Random Forest Classifier, με μετρική προσήλωσης την μέση τιμή των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec.



Εικόνα 27: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο SVM Classifier, με μετρική προσήλωσης την μέση τιμή των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec.



Εικόνα 28: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο XGBoost Classifier, με μετρική προσήλωσης την μέση τιμή των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec.




Εικόνα 29: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο MLP Classifier, με μετρική προσήλωσης την μέση τιμή των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec.

5.1.2 Αποτελέσματα με την χρήση της Περιοχής του Ίχνους (Area of the Annotation Trace) των δεδομένων προσήλωσης ως μετρικής εξόδου για χρονικά διαστήματα παρακολούθησης 10 sec για όλους τους συμμετέχοντες


Μετρικές όλων των μοντέλων μηχανικής μάθησης για μετρική προσήλωσης την περιοχή του ίχνους των δεδομένων προσήλωσης για χρονικά διαστήματα 10sec

	KNN Classifier	GaussianNB Classifier	Logistic Regression Classifier	Decision Tree Classifier	Random Forest Classifier	SVM Classifier	XGBoost Classifier	MLP Classifier
Accuracy	0.6137	0.6629	0.6666	0.5856	0.6573	0.6666	0.6398	0.6485
Precision	0.3676	0.3500	1.0	0.3805	0.4675	1.0	0.4334	0.2769
Sensitivity	0.2205	0.0130	0.0	0.3869	0.2018	0.0	0.2616	0.0336
Specificity	0.8102	0.9878	1.0	0.6850	0.8850	1.0	0.8289	0.9560
F1 Score	0.2757	0.2522	0.0	0.3836	0.2819	0.0	0.3263	0.0600
AUC	0.5154	0.5004	0.5	0.5359	0.5434	0.5	0.5453	0.4948


Πίνακας 5: Τιμές μετρικών όλων των μοντέλων μηχανικής μάθησης, με μετρική προσήλωσης την περιοχή του ίχνους των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec.



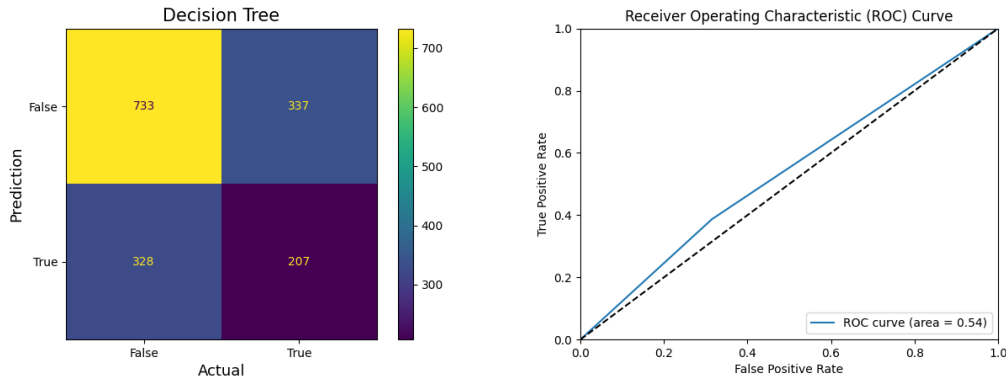
Εικόνα 30: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο KNN Classifier, με μετρική προσήλωσης την περιοχή του ίχνους των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec.




Εικόνα 31: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο GaussianNB Classifier, με μετρική προσήλωσης την περιοχή του ίχνους των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec.




Εικόνα 32: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο Logistic Regression Classifier, με μετρική προσήλωσης την περιοχή του ίχνους των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec.



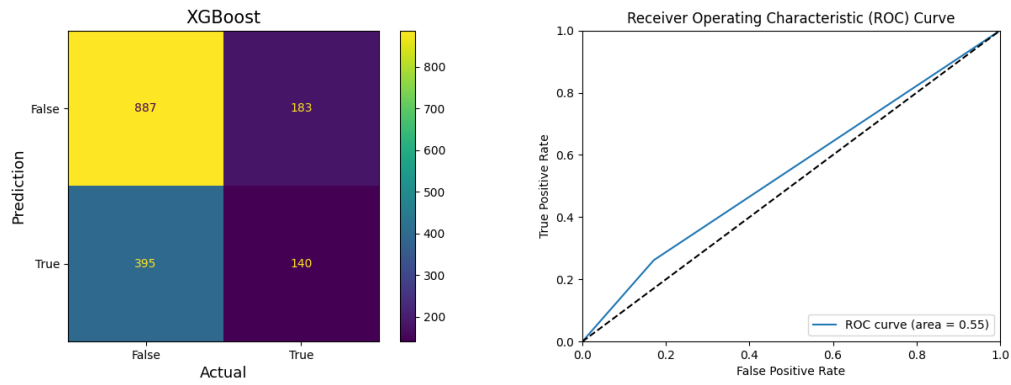
Εικόνα 33: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο Decision Tree Classifier, με μετρική προσήλωσης την περιοχή του ίχνους των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec.




Εικόνα 34: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο Random Forest Classifier, με μετρική προσήλωσης την περιοχή του ίχνους των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec.



Εικόνα 35: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο SVM Classifier, με μετρική προσήλωσης την περιοχή του ίχνους των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec.



Εικόνα 36: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο XGBoost Classifier, με μετρική προσηλωσης την περιοχή του ίχνους των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec.




Εικόνα 37: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο MLP Classifier, με μετρική προσηλωσης την περιοχή του ίχνους των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec.

5.1.3 Αποτελέσματα με την χρήση του Πλάτους (Amplitude) των δεδομένων προσήλωσης ως μετρικής εξόδου για χρονικά διαστήματα παρακολούθησης 30 sec, με 10 sec χρονική επικάλυψη για όλους τους συμμετέχοντες

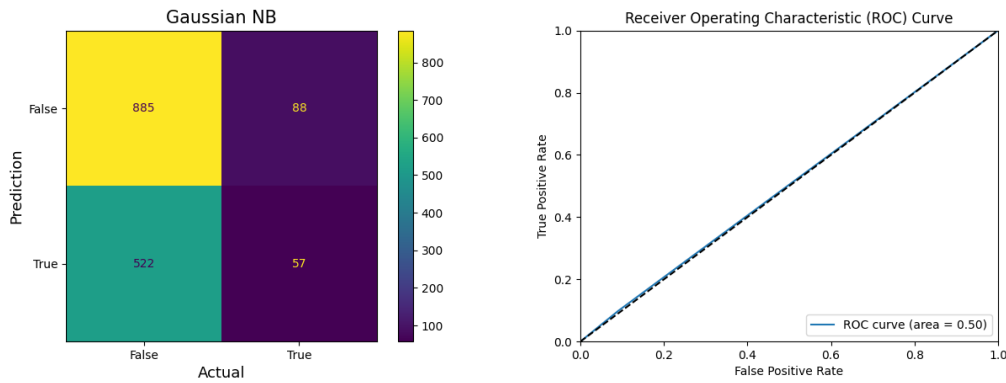
Μετρικές όλων των μοντέλων μηχανικής μάθησης για μετρική προσήλωσης το πλάτος των δεδομένων προσήλωσης για χρονικά διαστήματα 30sec με επικάλυψη 10sec

	KNN Classifier	GaussianNB Classifier	Logistic Regression Classifier	Decision Tree Classifier	Random Forest Classifier	SVM Classifier	XGBoost Classifier	MLP Classifier
Accuracy	0.5773	0.6069	0.6275	0.5560	0.5908	0.6269	0.5966	0.6204
Precision	0.4123	0.3931	0.5454	0.4095	0.4247	0.5	0.4474	0.4683
Sensitivity	0.3126	0.0984	0.0103	0.4300	0.2728	0.0051	0.3454	0.1278
Specificity	0.7348	0.9095	0.9948	0.6310	0.7800	0.9969	0.7461	0.9136
F1 Score	0.3555	0.1574	0.0203	0.4195	0.3322	0.0102	0.3898	0.2008
AUC	0.5237	0.5040	0.5026	0.5305	0.5264	0.5010	0.5457	0.5207

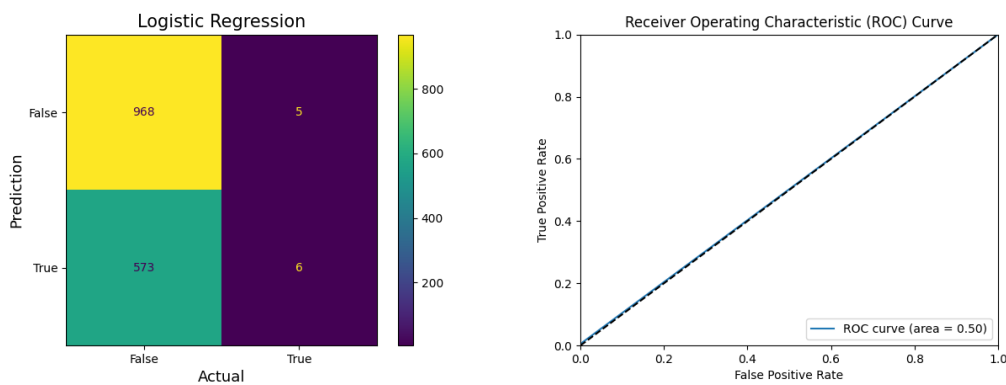
Πίνακας 6: Τιμές μετρικών όλων των μοντέλων μηχανικής μάθησης, με μετρική προσήλωσης το πλάτος των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 30 sec με χρονική επικάλυψη 10 sec.



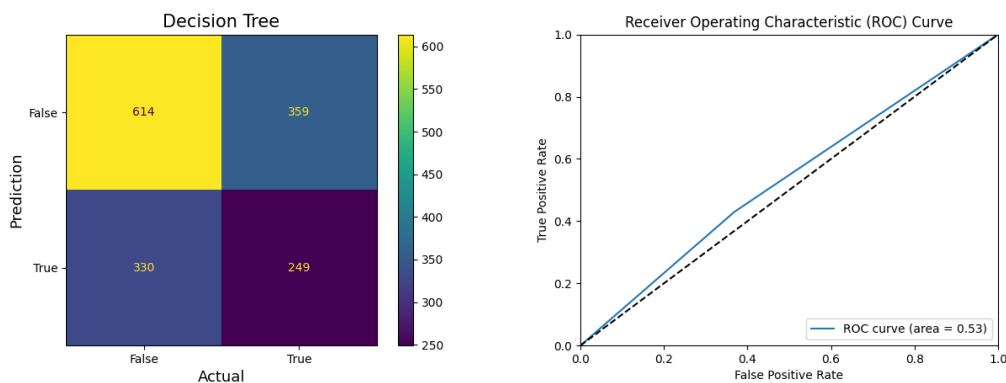
Εικόνα 38: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο KNN Classifier, με μετρική προσήλωσης το πλάτος των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 30 sec με χρονική επικάλυψη 10 sec.




Εικόνα 39: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο GaussianNB Classifier, με μετρική προσήλωσης το πλάτος των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 30 sec με χρονική επικάλυψη 10 sec.



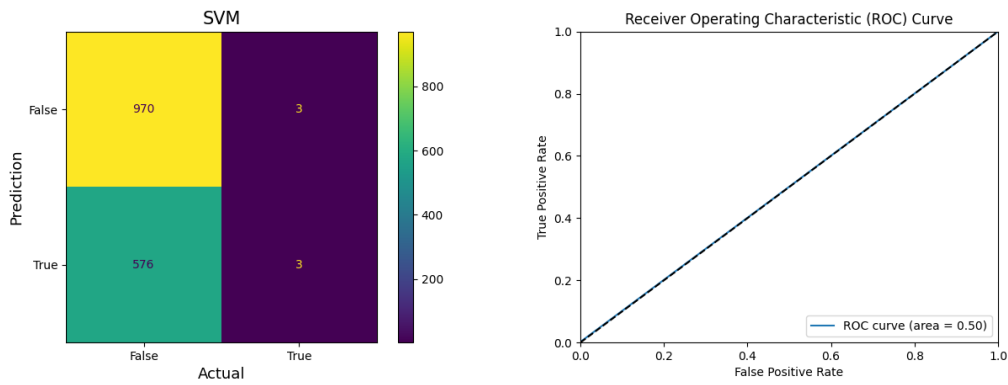
Εικόνα 40: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο Logistic Regression Classifier, με μετρική προσήλωσης το πλάτος των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 30 sec με χρονική επικάλυψη 10 sec.



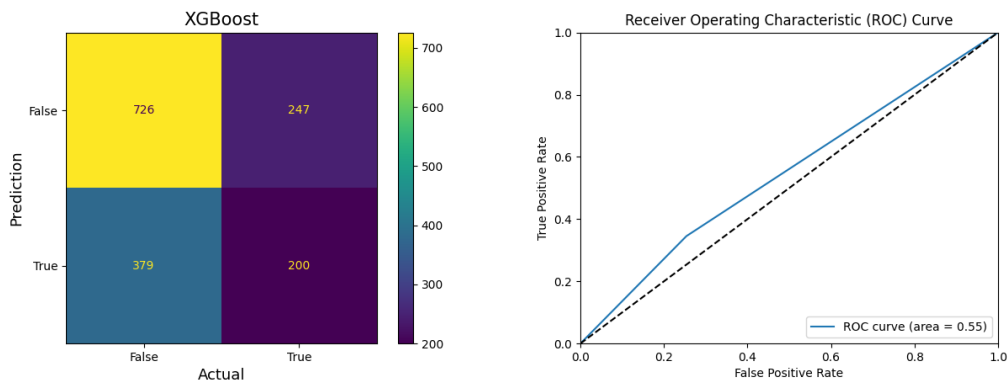
Εικόνα 41: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο Decision Tree Classifier, με μετρική προσήλωσης το πλάτος των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 30 sec με χρονική επικάλυψη 10 sec.



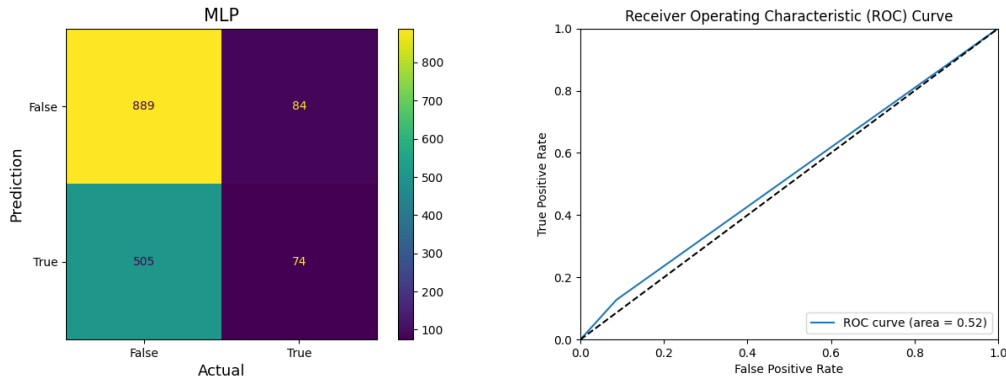
Εικόνα 42: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο Random Forest Classifier, με μετρική προσήλωσης το πλάτος των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 30 sec με χρονική επικάλυψη 10 sec.



Εικόνα 43: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο SVM Classifier, με μετρική προσήλωσης το πλάτος των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 30 sec με χρονική επικάλυψη 10 sec.



Εικόνα 44: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο XGBoost Classifier, με μετρική προσήλωσης το πλάτος των των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 30 sec με χρονική επικάλυψη 10 sec.



Εικόνα 45: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο MLP Classifier, με μετρική προσήλωσης το πλάτος των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 30 sec με χρονική επικάλυψη 10 sec.

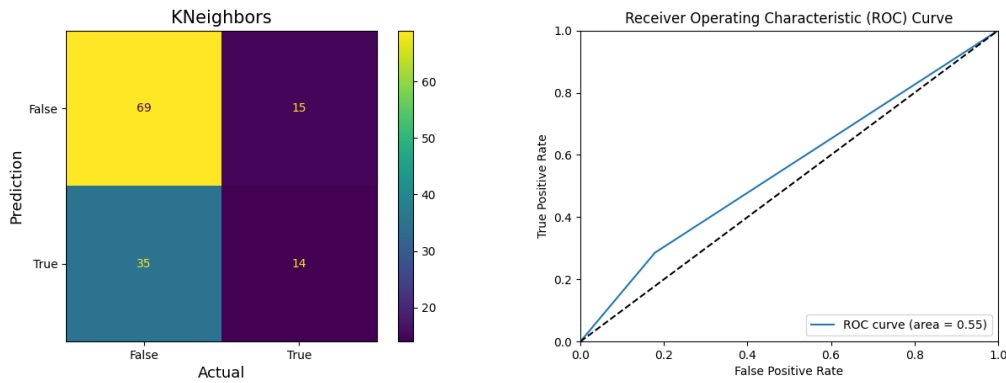
5.2 Αποτελέσματα από την εκπαίδευση με επιλεγμένους συμμετέχοντες

5.2.1 Αποτελέσματα με την χρήση της Μέσης Τιμής (Mean Value) των δεδομένων προσήλωσης ως μετρικής εξόδου για χρονικά διαστήματα παρακολούθησης 10 sec στους επιλεγμένους συμμετέχοντες

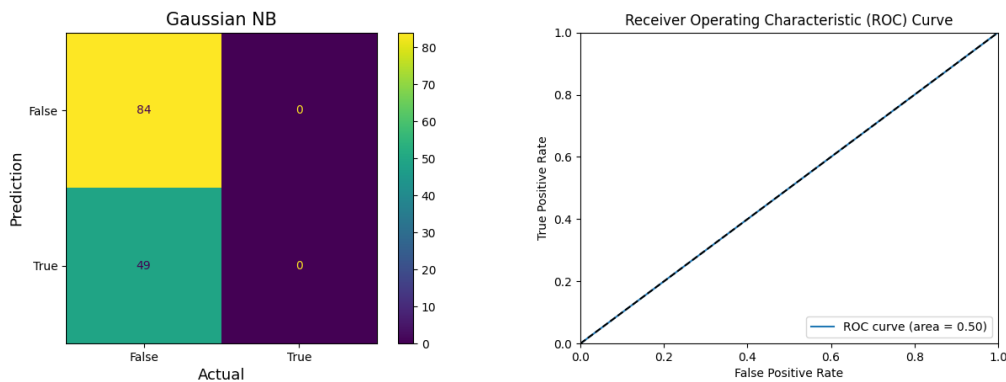
Μετρικές όλων των μοντέλων μηχανικής μάθησης για μετρική προσήλωσης την μέση τιμή των δεδομένων προσήλωσης για χρονικά διαστήματα 10sec, στους επιλεγμένους συμμετέχοντες

	KNN Classifier	GaussianNB Classifier	Logistic Regression Classifier	Decision Tree Classifier	Random Forest Classifier	SVM Classifier	XGBoost Classifier	MLP Classifier
Accuracy	0.6240	0.6315	0.6315	0.8421	0.8421	0.6315	0.8571	0.6315
Precision	0.4827	1.0	1.0	0.85	0.9375	1.0	0.8571	0.5
Sensitivity	0.2857	0.0	0.0	0.6938	0.6122	0.0	0.7346	0.0204
Specificity	0.8214	1.0	1.0	0.9285	0.9761	1.0	0.9285	0.9880
F1 Score	0.3589	0.0	0.0	0.7640	0.7407	0.0	0.7912	0.0392
AUC	0.5535	0.5	0.5	0.8112	0.7942	0.5	0.8316	0.5042

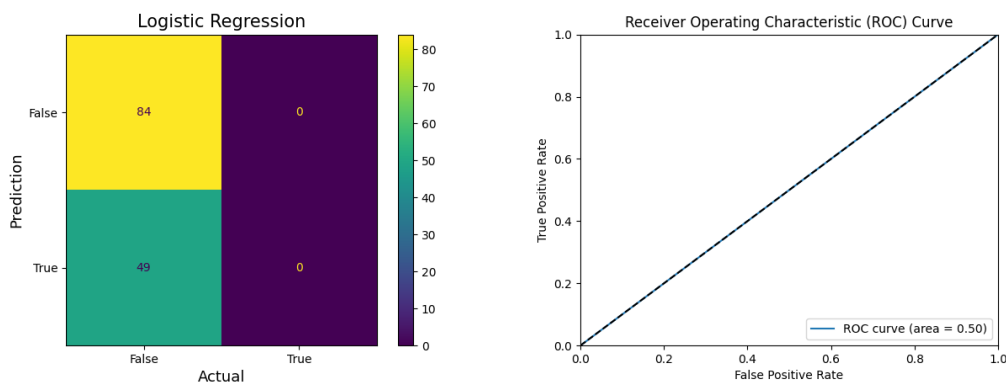
Πίνακας 7: Τιμές τελικών μετρικών όλων των μοντέλων μηχανικής μάθησης, με μετρική προσήλωσης την μέση τιμή των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec στους επιλεγμένους συμμετέχοντες.



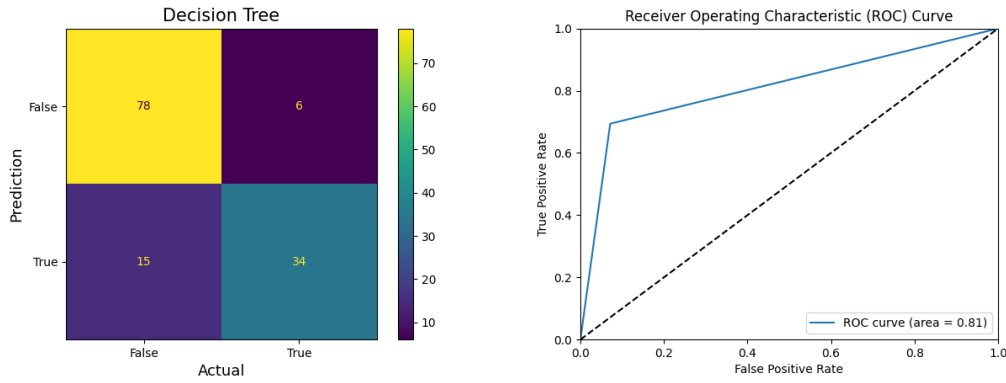
Εικόνα 46: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο KNN Classifier, με μετρική προσηλωσης την μέση τιμή των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec, για τους επιλεγμένους συμμετέχοντες.



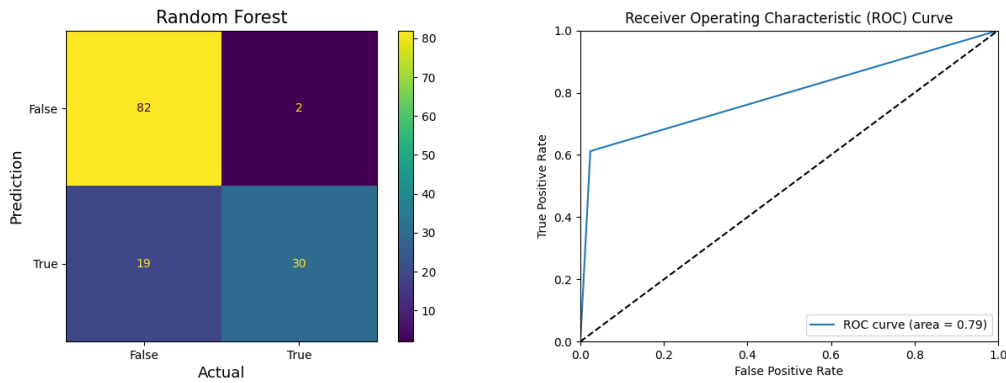
Εικόνα 47: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο GaussianNB Classifier, με μετρική προσηλωσης την μέση τιμή των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec, για τους επιλεγμένους συμμετέχοντες.




Εικόνα 48: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο Logistic Regression Classifier, με μετρική προσηλωσης την μέση τιμή των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec, για τους επιλεγμένους συμμετέχοντες.



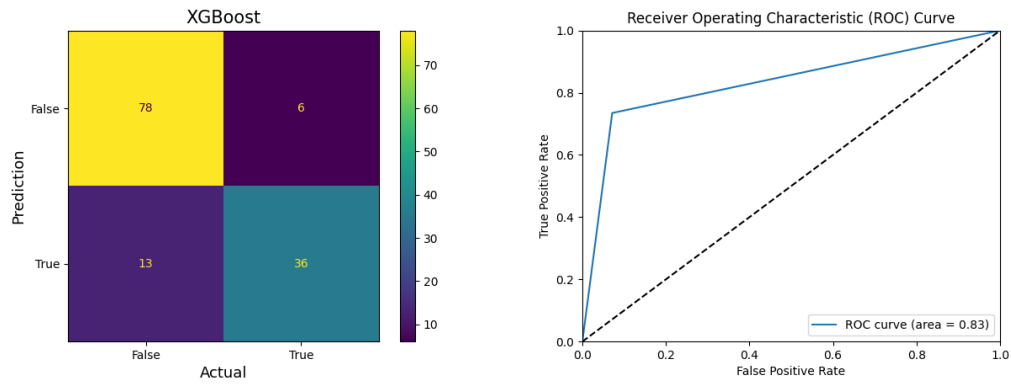
Εικόνα 49: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο *Decision Tree Classifier*, με μετρική προσήλωσης την μέση τιμή των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec, για τους επιλεγμένους συμμετέχοντες.



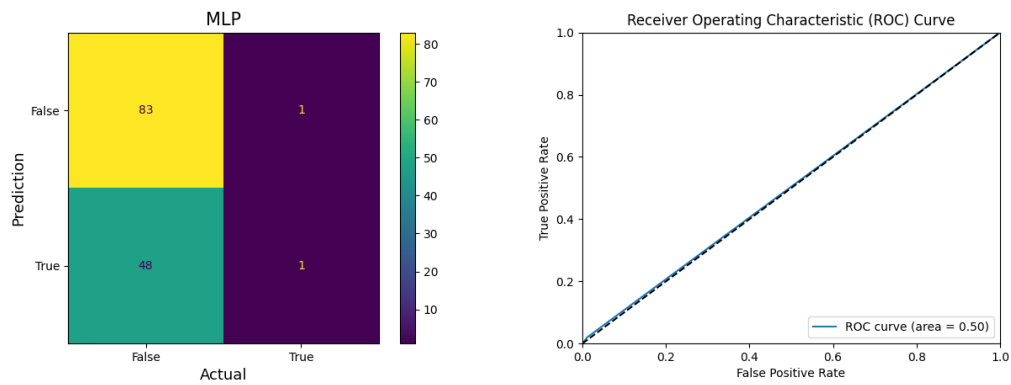
Εικόνα 50: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο *Random Forest Classifier*, με μετρική προσήλωσης την μέση τιμή των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec, για τους επιλεγμένους συμμετέχοντες.



Εικόνα 51: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο *SVM Classifier*, με μετρική προσήλωσης την μέση τιμή των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec, για τους επιλεγμένους συμμετέχοντες.



Εικόνα 52: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο XGBoost Classifier, με μετρική προσήλωσης την μέση τιμή των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec, για τους επιλεγμένους συμμετέχοντες.



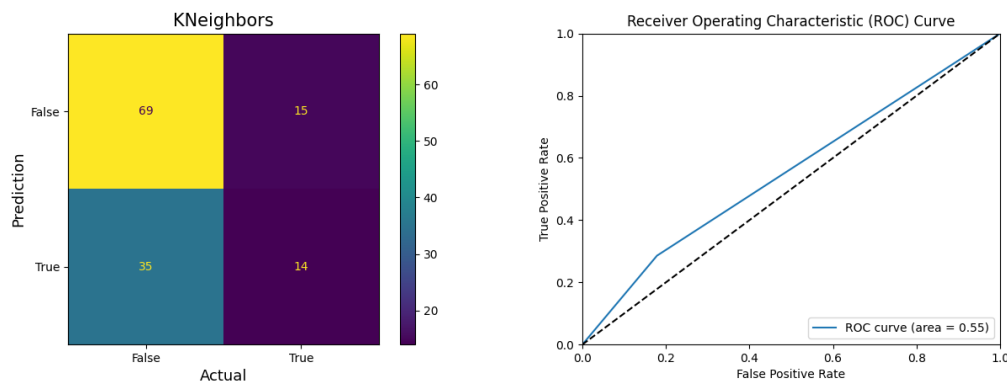
Εικόνα 53: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο MLP Classifier, με μετρική προσήλωσης την μέση τιμή των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec, για τους επιλεγμένους συμμετέχοντες.

5.2.2 Αποτελέσματα με την χρήση της Περιοχής του Ίχνους (Area of the Annotation Trace) των δεδομένων προσήλωσης ως μετρικής εξόδου για χρονικά διαστήματα παρακολούθησης 10 sec για τους επιλεγμένους συμμετέχοντες

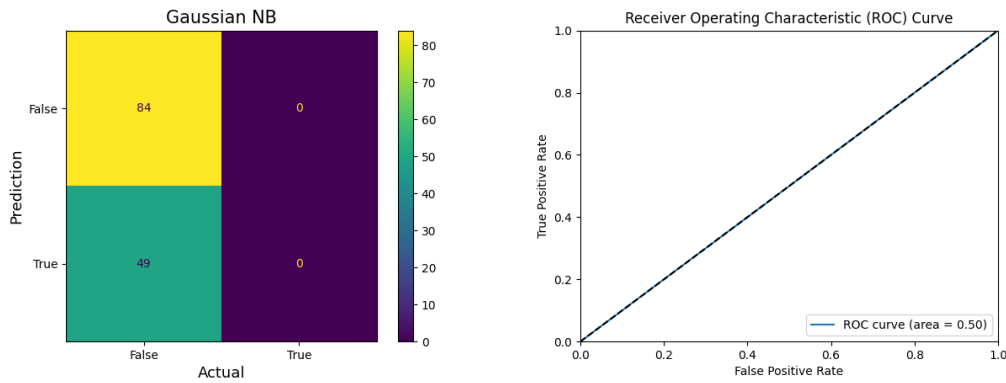
Μετρικές όλων των μοντέλων μηχανικής μάθησης για μετρική προσήλωσης την περιοχή του ίχνους των τιμών των δεδομένων προσήλωσης για χρονικά διαστήματα 10sec, στους επιλεγμένους συμμετέχοντες

	KNN Classifier	GaussianNB Classifier	Logistic Regression Classifier	Decision Tree Classifier	Random Forest Classifier	SVM Classifier	XGBoost Classifier	MLP Classifier
Accuracy	0.6240	0.6315	0.6315	0.8571	0.8345	0.6315	0.8345	0.6240
Precision	0.4827	1.0	1.0	0.8571	0.9354	1.0	0.8292	0.3333
Sensitivity	0.2857	0.0	0.0	0.7346	0.5918	0.0	0.6938	0.0204
Specificity	0.8214	1.0	1.0	0.9285	0.9761	1.0	0.9166	0.9761
F1 Score	0.3589	0.0	0.0	0.7912	0.7249	0.0	0.7555	0.0384
AUC	0.5535	0.5	0.5	0.8316	0.7840	0.5	0.8052	0.4982

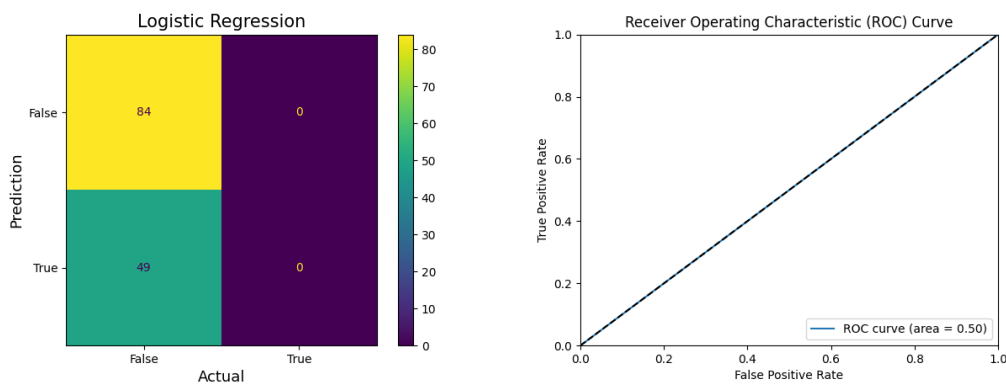
Πίνακας 8: Τιμές τελικών μετρικών όλων των μοντέλων μηχανικής μάθησης, με μετρική προσήλωσης την περιοχή του ίχνους των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec, στους επιλεγμένους συμμετέχοντες.



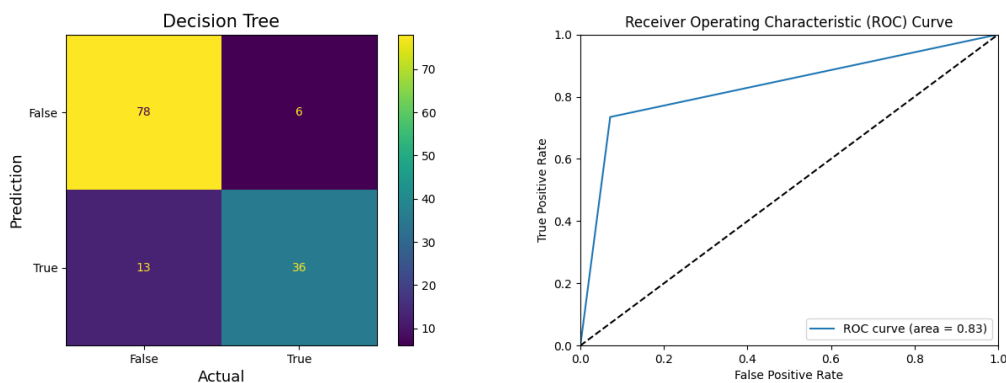
Εικόνα 54: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο KNN Classifier, με μετρική προσήλωσης την περιοχή του ίχνους των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec, για τους επιλεγμένους συμμετέχοντες.



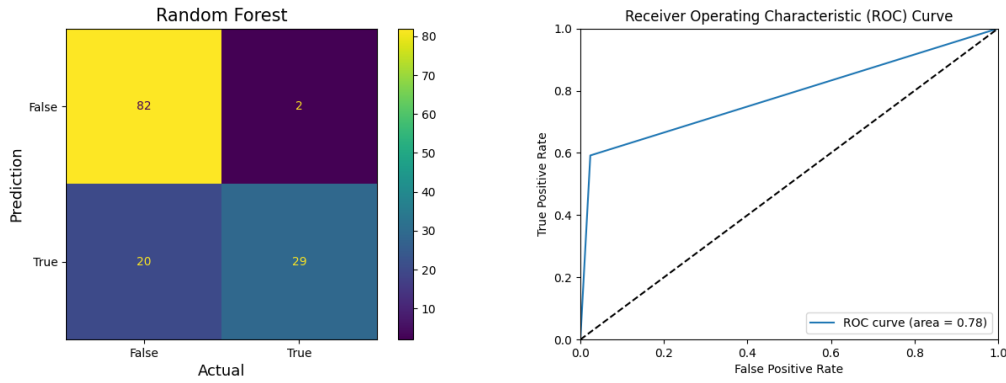
Εικόνα 55: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο GaussianNB Classifier, με μετρική προσήλωσης την περιοχή του ίχνους των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec, για τους επιλεγμένους συμμετέχοντες.



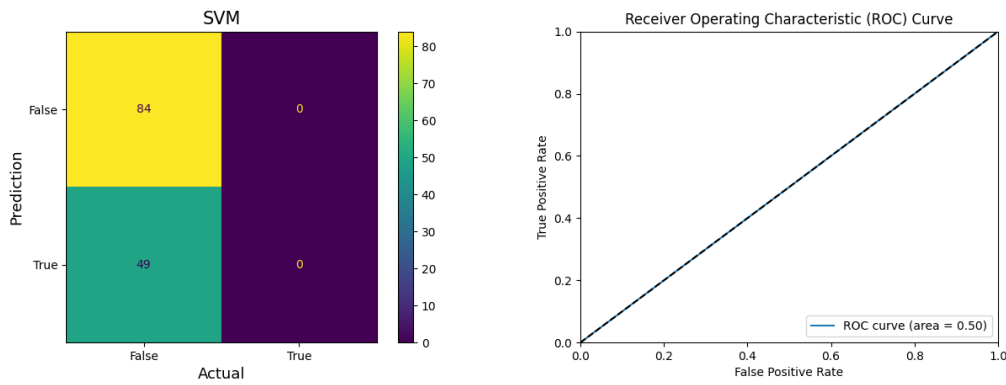
Εικόνα 56: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο Logistic Regression Classifier, με μετρική προσήλωσης την περιοχή του ίχνους των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec, για τους επιλεγμένους συμμετέχοντες.



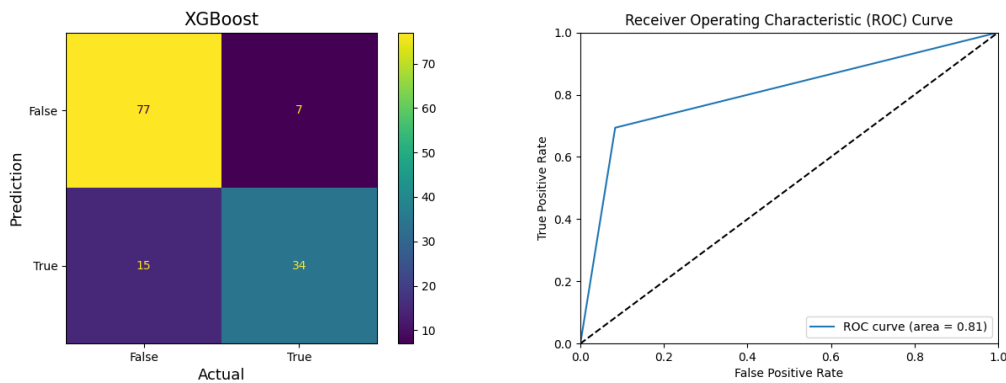
Εικόνα 57: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο Decision Tree Classifier, με μετρική προσήλωσης την περιοχή του ίχνους των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec, για τους επιλεγμένους συμμετέχοντες.




Εικόνα 58: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο Random Forest Classifier, με μετρική προσήλωσης την περιοχή του ίχνους των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec, για τους επιλεγμένους συμμετέχοντες.



Εικόνα 59: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο SVM Classifier, με μετρική προσήλωσης την περιοχή του ίχνους των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec, για τους επιλεγμένους συμμετέχοντες.



Εικόνα 60: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο XGBoost Classifier, με μετρική προσήλωσης την περιοχή του ίχνους των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec, για τους επιλεγμένους συμμετέχοντες.



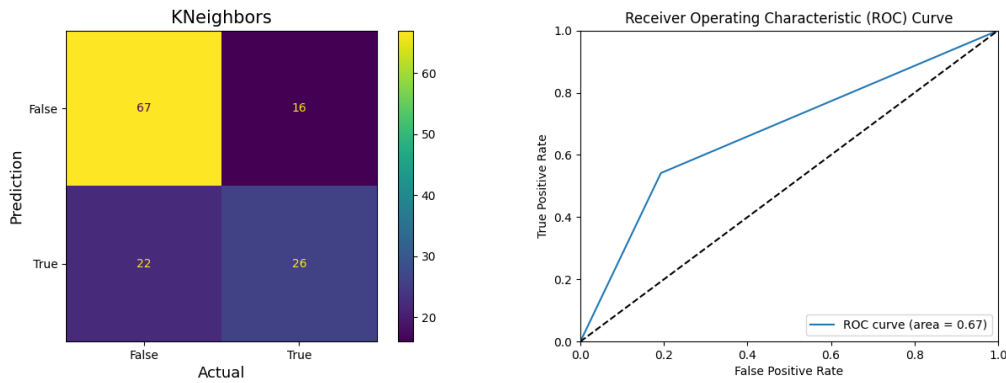
Εικόνα 61: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο MLP Classifier, με μετρική προσήλωσης την περιοχή του ίχνους των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 10 sec, για τους επιλεγμένους συμμετέχοντες.

5.2.3 Αποτελέσματα με την χρήση του Πλάτους (Amplitude) των δεδομένων προσήλωσης ως μετρικής εξόδου για χρονικά διαστήματα παρακολούθησης 30 sec, με 10 sec χρονική επικάλυψη, στους επιλεγμένους συμμετέχοντες

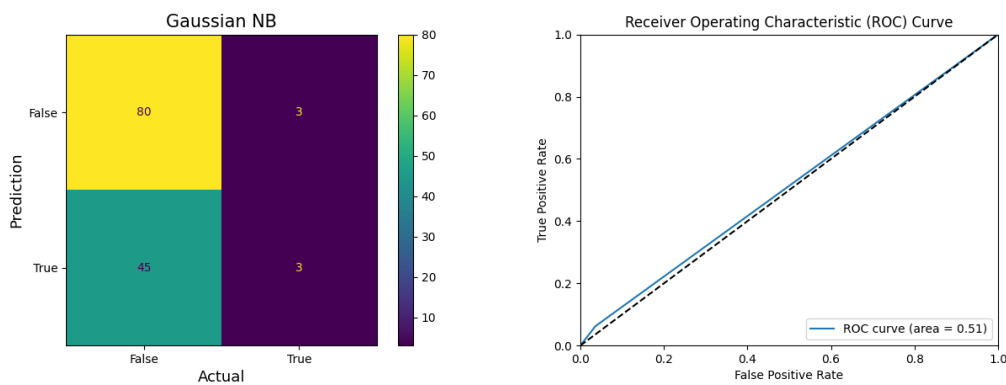
Μετρικές όλων των μοντέλων μηχανικής μάθησης για μετρική προσήλωσης το πλάτος των δεδομένων προσήλωσης για χρονικά διαστήματα 30sec με χρονική επικάλυψη 10sec, στους επιλεγμένους συμμετέχοντες

	KNN Classifier	GaussianNB Classifier	Logistic Regression Classifier	Decision Tree Classifier	Random Forest Classifier	SVM Classifier	XGBoost Classifier	MLP Classifier
Accuracy	0.7099	0.6335	0.6183	0.8625	0.8854	0.6259	0.8702	0.6488
Precision	0.6190	0.5	0.0	0.8	0.8666	0.3333	0.8163	0.5454
Sensitivity	0.5416	0.0625	0.0	0.8333	0.8125	0.0200	0.8333	0.25
Specificity	0.8072	0.9638	0.9759	0.8795	0.9277	0.9759	0.8915	0.8795
F1 Score	0.5777	0.1111	0.0	0.8163	0.8387	0.0392	0.8247	0.3428
AUC	0.6744	0.5131	0.4879	0.8564	0.8701	0.4983	0.8624	0.5647


Πίνακας 9: Τιμές τελικών μετρικών όλων των μοντέλων μηχανικής μάθησης, με μετρική προσήλωσης το πλάτος των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 30 sec με χρονική επικάλυψη 10 sec στους επιλεγμένους συμμετέχοντες.



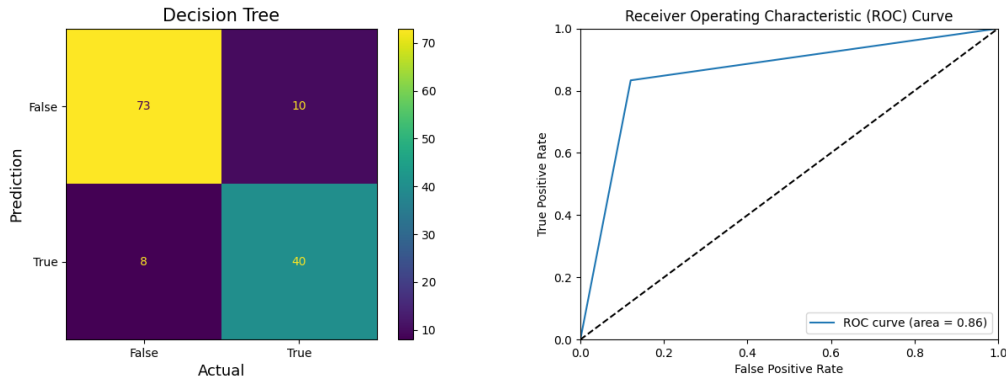
Εικόνα 62: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο KNN Classifier, με μετρική προσήλωσης το πλάτους των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 30 sec με χρονική επικάλυψη 10 sec, για τους επιλεγμένους συμμετέχοντες.



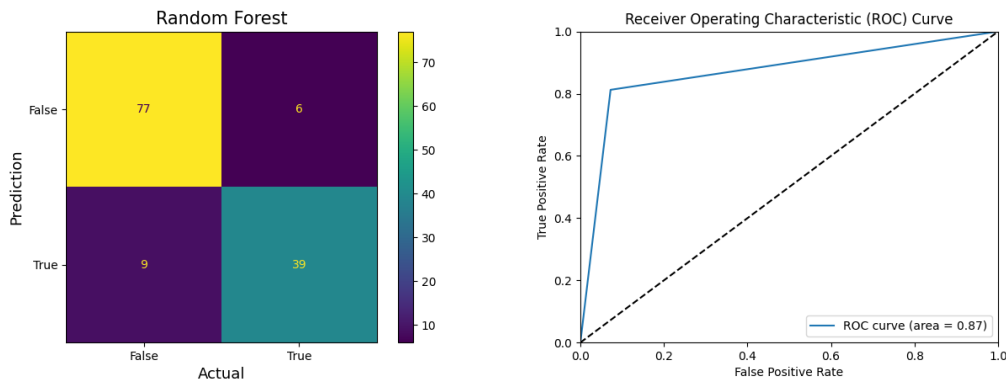
Εικόνα 63: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο GaussianNB Classifier, με μετρική προσήλωσης το πλάτους των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 30 sec με χρονική επικάλυψη 10 sec, για τους επιλεγμένους συμμετέχοντες.



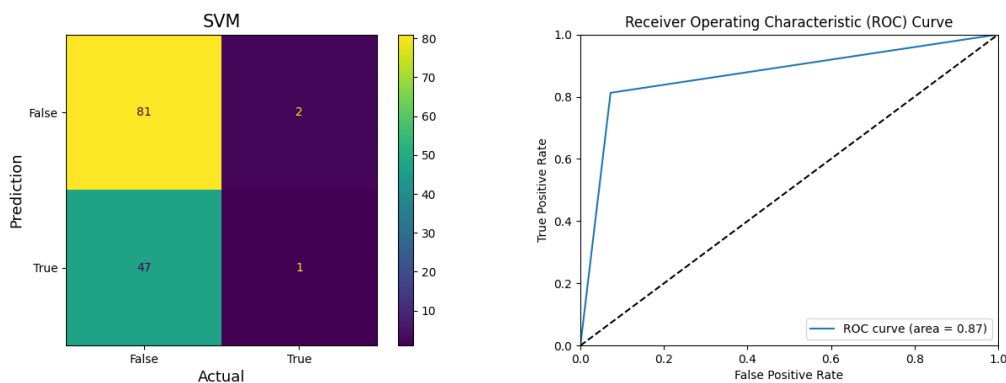
Εικόνα 64: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο Logistic Regression Classifier, με μετρική προσήλωσης το πλάτους των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 30 sec με χρονική επικάλυψη 10 sec, για τους επιλεγμένους συμμετέχοντες.



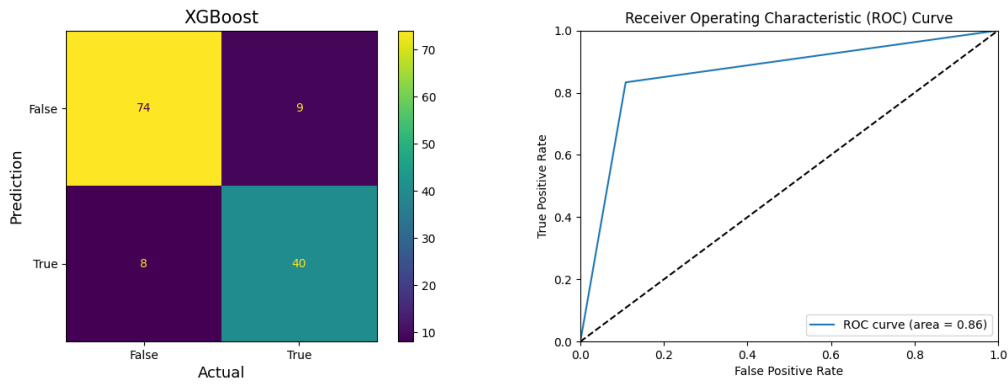
Εικόνα 65: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο Decision Tree Classifier, με μετρική προσήλωσης το πλάτους των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 30 sec με χρονική επικάλυψη 10 sec, για τους επιλεγμένους συμμετέχοντες.



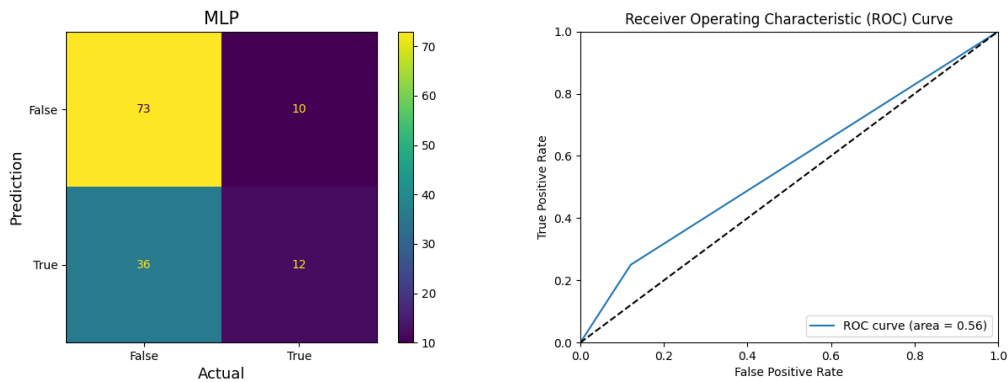
Εικόνα 66: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο Random Forest Classifier, με μετρική προσήλωσης το πλάτους των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 30 sec με χρονική επικάλυψη 10 sec, για τους επιλεγμένους συμμετέχοντες.



Εικόνα 67: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο SVM Classifier, με μετρική προσήλωσης το πλάτους των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 30 sec με χρονική επικάλυψη 10 sec, για τους επιλεγμένους συμμετέχοντες.



Εικόνα 68: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο XGBoost Classifier, με μετρική προσήλωσης το πλάτους των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 30 sec με χρονική επικάλυψη 10 sec, για τους επιλεγμένους συμμετέχοντες.



Εικόνα 69: Confusion matrix (αριστερά) και διάγραμμα AUC (δεξιά) για το μοντέλο MLP Classifier, με μετρική προσήλωσης το πλάτους των επισημειωμένων δεδομένων και για χρονικά διαστήματα παρακολούθησης 30 sec με χρονική επικάλυψη 10 sec, για τους επιλεγμένους συμμετέχοντες.

5.3 Σύγκριση των αποτελεσμάτων μεταξύ της εκπαίδευσης για όλους τους συμμετέχοντες και της εκπαίδευσης για επιλεγμένους συμμετέχοντες

Οι αλγόριθμοι μηχανικής μάθησης με τις βέλτιστες επιδόσεις έχουν σημειωθεί με κίτρινο χρώμα.

Σύγκριση μεταξύ της εκπαίδευσης πριν και μετά την επιλογή συμμετεχόντων για χρονικά διαστήματα παρακολούθησης 10sec και για μετρική προσήλωσης την μέση τιμή των επισημειωμένων δεδομένων

	Πριν			Μετά		
	Decision Tree Classifier	Random Forest Classifier	XGBoost Classifier	Decision Tree Classifier	Random Forest Classifier	XGBoost Classifier
Accuracy	0.5831	0.6523	0.6404	0.8421	0.8421	0.8571
Precision	0.3740	0.4415	0.4315	0.85	0.9375	0.8571
Sensitivity	0.3860	0.1920	0.2730	0.6938	0.6122	0.7346
Specificity	0.6806	0.8798	0.8221	0.9285	0.9761	0.9285
F1 Score	0.3799	0.2677	0.3344	0.7640	0.7407	0.7912
AUC	0.5333	0.5359	0.5476	0.8112	0.7942	0.8316

Πίνακας 10: Πίνακας αποτύπωσης της σύγκρισης μεταξύ της εκπαίδευσης για όλους τους συμμετέχοντες και της εκπαίδευσης ειδικά για τους επιλεγμένους με μετρική προσήλωσης την Μέση Τιμή των επισημειωμένων δεδομένων, για χρονικά διαστήματα παρακολούθησης 10 sec.

Σύγκριση μεταξύ της εκπαίδευσης πριν και μετά την επιλογή συμμετεχόντων για χρονικά διαστήματα παρακολούθησης 10sec και για μετρική προσήλωσης την περιοχή του ίχνους των επισημειωμένων δεδομένων

	Πριν			Μετά		
	Decision Tree Classifier	Random Forest Classifier	XGBoost Classifier	Decision Tree Classifier	Random Forest Classifier	XGBoost Classifier
Accuracy	0.5856	0.6573	0.6398	0.8571	0.8345	0.8345
Precision	0.3805	0.4675	0.4334	0.8571	0.9354	0.8292
Sensitivity	0.3869	0.2018	0.2616	0.7346	0.5918	0.6938
Specificity	0.6850	0.8850	0.8289	0.9285	0.9761	0.9166
F1 Score	0.3836	0.2819	0.3263	0.7912	0.7249	0.7555
AUC	0.5359	0.5434	0.5453	0.8316	0.7840	0.8052

Πίνακας 11: Πίνακας αποτύπωσης της σύγκρισης μεταξύ της εκπαίδευσης για όλους τους συμμετέχοντες και της εκπαίδευσης ειδικά για τον επιλεγμένους με μετρική προσήλωσης την Περιοχή του Ίχνους των επισημειωμένων δεδομένων, για χρονικά διαστήματα παρακολούθησης 10 sec.

Σύγκριση μεταξύ της εκπαίδευσης πριν και μετά την επιλογή συμμετεχόντων για χρονικά διαστήματα παρακολούθησης 30sec με χρονική επικάλυψη 10sec και για μετρική προσήλωσης το πλάτος των επισημειωμένων δεδομένων

	Πριν			Μετά		
	Decision Tree Classifier	Random Forest Classifier	XGBoost Classifier	Decision Tree Classifier	Random Forest Classifier	XGBoost Classifier
Accuracy	0.5560	0.5908	0.5966	0.8625	0.8854	0.8702
Precision	0.4095	0.4247	0.4474	0.8	0.8666	0.8163
Sensitivity	0.4300	0.2728	0.3454	0.8333	0.8125	0.8333
Specificity	0.6310	0.7800	0.7461	0.8795	0.9277	0.8915
F1 Score	0.4195	0.3322	0.3898	0.8163	0.8387	0.8247
AUC	0.5305	0.5264	0.5457	0.8564	0.8701	0.8624

Πίνακας 12: Πίνακας αποτύπωσης της σύγκρισης μεταξύ της εκπαίδευσης για όλους τους συμμετέχοντες και της εκπαίδευσης ειδικά για του επιλεγμένους με μετρική προσήλωσης το Πλάτος των επισημειωμένων δεδομένων, για χρονικά διαστήματα παρακολούθησης 30 sec, με χρονική επικάλυψη 10 sec.

Κεφάλαιο 6: Συζήτηση

Στο παρόν κεφάλαιο ακολουθεί η ανακεφαλαίωση της παρούσας Διπλωματικής Εργασίας. Στο πλαίσιο της παρούσας Διπλωματικής Εργασίας, αρχικά πραγματοποιήθηκε θεωρητική πλαισίωση της εργασίας, μέσω βιβλιογραφικής έρευνας με σκοπό την εκτενή ανάλυση και παρουσίαση σύγχρονων τεχνολογικά εννοιών, που είναι τα ΠΣΣΥ, ο κλάδος της τεχνητής νοημοσύνης που αφορά την ΣΥΝ, καθώς και η σύγχρονη μελέτη των ιατρικών παρεμβάσεων που βασίζονται στην έννοια της ΜΚΡ. Αναλύθηκε επίσης, πώς οι παραπάνω έννοιες μπορούν να συνδυαστούν μεταξύ τους και αναζητήθηκε η δυνατότητα αξιοποίησης των δεδομένων του καρδιακού ρυθμού σε συνδυασμό με τα επίπεδα προσήλωσης χρηστών που αλληλοεπιδρούν με ΠΣΣΥ.

Το πρακτικό μέρος της παρούσας έρευνας, πραγματεύεται την αξιοποίηση των θεωρητικών εννοιών που προαναφέρθηκαν, εισάγοντας αλγορίθμους μηχανικής μάθησης, την αξιοποίηση σύγχρονων γλωσσών προγραμματισμού για ανάπτυξη κώδικα που θα ικανοποιεί τις ανάγκες της εκκαθάρισης, ερμηνείας και ανάλυσης των δεδομένων, καθώς και την εξαγωγή πινάκων, γραφικών παραστάσεων και μετρικών μηχανικής μάθησης. Με την πρόοδο της μελέτης της Διπλωματικής Εργασίας, α) έγινε επεξεργασία και ανάλυση των δεδομένων που συλλέγονται από αισθητήρα καρδιακού παλμού αλλά και δεδομένων εκτίμησης προσήλωσης που επισημειώνουν οι συμμετέχοντες παρακολουθώντας καταγραφές της αλληλεπίδρασής τους με το ΠΣΣΥ και β) έγινε εισαγωγή των δεδομένων σε ρητά μοντέλα μηχανικής μάθησης, με σκοπό την κατάλληλη εκπαίδευση και την παραγωγή μετρικών, που υποδεικνύουν την ικανότητα των μοντέλων στην πρόβλεψη των επιπέδων προσήλωσης. Ακόμα αναζητήθηκαν τρόποι βελτίωσης και αύξησης των επιδόσεων των μοντέλων, χρησιμοποιώντας ως κριτήριο τον αλγόριθμο μηχανικής μάθησης XGBoost και εκπαιδύοντας στα δεδομένα κάθε συμμετέχοντα ξεχωριστά για την ανεύρεση των συμμετεχόντων με τις βέλτιστες μετρικές. Με τον τρόπο αυτό, ορίστηκαν αρκετοί συμμετέχοντες ως «outliers», χωρίς αυτό να περιορίζει τον αριθμό των συμμετεχόντων που θα λαμβάνουν μέρος στην εκπαίδευση των μοντέλων.

6.1 Προβλήματα που παρουσιάστηκαν

Στον τομέα της εκπαίδευσης των μοντέλων, παρουσιάστηκαν προβλήματα τα οποία αφορούσαν την μετρική AUC, όταν επιχειρούσαμε να τρέξουμε τον κώδικα για όλους τους συμμετέχοντες χρησιμοποιώντας τον αλγόριθμο ταξινόμησης leave-one-participant-out. Χαρακτηριστικά οι τιμές της μετρικής AUC, ήταν σχεδόν 0.5 γεγονός που υποδηλώνει πως τα μοντέλα δεν είχαν καμία ικανότητα διαχωρισμότητας, ασχέτως με τις μετρικές των δεδομένων προσήλωσης που ορίζονταν ως έξοδος και τα χρονικά παράθυρα που επιλέγονταν. Στο Κεφάλαιο 5 παρουσιάστηκαν τα στιγμιότυπα από την εκτέλεση του κώδικα, για όλες τις μετρικές των δεδομένων προσήλωσης και για χρονικά παράθυρα α) 10 sec και β) 30 sec με επικάλυψη 10 sec. Πιο συγκεκριμένα παρουσιάζονται οι τιμές των Accuracy, Precision, Recall,

Specificity, F1 Score, AUC, ο confusion matrix και η γραφική παράσταση της AUC, για κάθε μοντέλο μηχανικής μάθησης.

Τα πιθανά αίτια που μπορεί να οφείλονται στην όχι καλή απόδοση των μοντέλων μηχανικής μάθησης, όταν προσπαθούμε να εκπαιδεύσουμε σε όλους τους συμμετέχοντες θα αναλυθούν παρακάτω.

Σε έρευνα που έγινε σχετικά με την εξαγωγή βέλτιστων αποτελεσμάτων, παρατηρήθηκε ότι για χρονικά διαστήματα παρακολούθησης 10 sec, τα καλύτερα αποτελέσματα λαμβάνονται εάν ορίσουμε ως μετρική των δεδομένων προσήλωσης είτε την μέση τιμή (Mean Value) ή την περιοχή του ίχνους (Area of the annotation trace) των επισημειωμένων δεδομένων. Ενώ για τα χρονικά διαστήματα παρακολούθησης 30 sec λαμβάνουμε βέλτιστα αποτελέσματα, εάν ορίσουμε ως μετρική των δεδομένων προσήλωσης το πλάτος (Amplitude) [5]. Όλα τα παραπάνω επιβεβαιώνονται και στην πειραματική διαδικασία της παρούσας Διπλωματικής από τα αποτελέσματα που εξάγουμε.

6.2 Τρόποι επίλυσης των προβλημάτων που προέκυψαν κατά την πειραματική διαδικασία

Όπως φαίνεται από τα στιγμιότυπα του Κεφαλαίου 5, της ενότητας 5.1, τα μοντέλα μηχανικής μάθησης δεν παρουσιάζουν ικανότητα διάκρισης κατά την διαδικασία της δυαδικής ταξινόμησης. Οι τρόποι επίλυσης που χρησιμοποιήθηκαν, αφορούν την διενέργεια «principal component analysis» (PCA), την αναζήτηση μορφών ανισορροπιών στις εξόδους των μοντέλων που αφορούν άνιση κατανομή των 0 και 1, καθώς και τον χαρακτηρισμό κάποιων συμμετεχόντων ως «outliers». Κατά την πειραματική διαδικασία της αλληλοεπίδρασης των συμμετεχόντων με το ΠΣΣΥ, κάποιοι συμμετέχοντες δεν έδωσαν τόσο σαφή εικόνα κατά την διαδικασία της υποκειμενικής αναφοράς τους, ώστε να βρίσκεται σε άμεση συσχέτιση με τα δεδομένα του καρδιακού τους ρυθμού. Αυτό εισάγει κάποιας μορφής ανισορροπία κατά την εκπαίδευση με αποτέλεσμα οι αλγόριθμοι να μην έχουν την ικανότητα να διακρίνουν με σαφή τρόπο.

Η διενέργεια PCA αφορά μια στατιστική διαδικασία για τη μείωση του συνόλου των χαρακτηριστικών που αντιπροσωπεύουν τα αρχικά δεδομένα, σε έναν υπόχωρο χαμηλότερης διάστασης με ελάχιστη απώλεια πληροφοριών [39]. Στην παρούσα διαδικασία, επιλέχθηκαν μετά την ανάλυση τα πρώτα 3 κύρια στοιχεία που είχαν τη μέγιστη διακύμανση από ένα σύνολο 16 κύριων στοιχείων. Τα αποτελέσματα που λήφθηκαν ήταν καλύτερα από πριν, ωστόσο όχι θεαματικά, αφού ακόμα η τιμή της μετρικής AUC ήταν κοντά στο 0.5.

Η αναζήτηση ανισορροπιών στις εξόδους των μοντέλων δεν ήταν λύση, καθώς τα δεδομένα δεν παρουσίαζαν τόσο έντονη ανισορροπία ώστε να μπορεί καθολικά μια μέθοδος να χρησιμοποιηθεί για να επιλύσει το πρόβλημα. Στην περίπτωση που κάποιοι συμμετέχοντες παρουσίαζαν έντονη ανισορροπία, χρησιμοποιήθηκαν οι μέθοδοι α) Random undersampling, β) Oversampling with SMOTE (Synthetic

Minority Over-sampling Technique) και γ) Undersampling and Oversampling, ωστόσο όπως προαναφέρθηκε δεν προέκυψε μία μέθοδος που να μπορεί να εφαρμοστεί καθολικά σε όλους τους συμμετέχοντες.

Στη συνέχεια χρησιμοποιήθηκαν οι αλγόριθμοι Z-Score και Turkey's Fence για τον χαρακτηρισμό κάποιων συμμετεχόντων ως «outliers», ωστόσο το πρόβλημα ήταν πιο σύνθετο και οι παραπάνω μέθοδοι δεν όρισαν με σαφή τρόπο κάποιους συμμετέχοντες ως «outliers».

Για την σωστή προσέγγιση του τρόπου επίλυσης του προβλήματος, που ήταν ο χαρακτηρισμός κάποιων συμμετεχόντων ως «outliers», έγινε εκπαίδευση των μοντέλων στα δεδομένα του κάθε συμμετέχοντα. Η εκπαίδευση έγινε με είσοδο τις λίστες που προέκυπταν από τη χρονική διαίρεση των καταγραφών κάθε συμμετέχοντα σε διαστήματα μη επικαλυπτόμενα, δηλαδή χρονικά διαστήματα 10 sec χωρίς επικαλυπτόμενα παράθυρα, για τον μηδενισμό του παράγοντα προκατάληψης και με έξοδο τις μετρικές προσήλωσης των επισημειωμένων δεδομένα του κάθε συμμετέχοντα. Για την εκπαίδευση των μοντέλων, χρησιμοποιήθηκε η μέθοδος «train_test_split()» με ποσοστό 70% των δεδομένων κάθε συμμετέχοντα για εκπαίδευση και 30% για έλεγχο. Εξήχθησαν μετρικές για κάθε μοντέλο μηχανικής μάθησης, για κάθε συμμετέχοντα και αποθηκεύτηκαν σε μορφή πινάκων, για να γίνει σωστή σύγκριση μεταξύ των συμμετεχόντων στους οποίους τα μοντέλα ανταποκρίνονται βέλτιστα. Ο SVM Classifier δεν παρουσίασε ικανότητα διαχωρισιμότητας κατά την εκπαίδευση με τα δεδομένα του κάθε συμμετέχοντα, αλλά και μεταξύ συμμετεχόντων όπως φαίνεται στα παραπάνω στιγμιότυπα, οπότε δεν συμπεριλήφθηκε στους πίνακες σύγκρισης. Δειγματοληπτικά παρουσιάζεται για τον τέταρτο συμμετέχοντα ο πίνακας με όλες τις μετρικές για κάθε αλγόριθμο μηχανικής μάθησης.

Σύγκριση επιδόσεων μεταξύ όλων των αλγορίθμων μηχανικής μάθησης για τον συμμετέχοντα 4

	KNN Classifier	GaussianNB Classifier	Logistic Regression Classifier	Decision Tree Classifier	Random Forest Classifier	XGBoost Classifier	MLP Classifier
Accuracy	0.5909	0.6363	0.4090	0.7272	0.6818	0.7727	0.6363
Precision	0.2	0.3333	0.0	0.5	0.3333	0.6	0.375
Sensitivity	0.1666	0.3333	0.0	0.3333	0.1666	0.5	0.5
Specificity	0.75	0.75	0.5625	0.875	0.875	0.875	0.6875
F1 Score	0.1818	0.3333	0.0	0.4	0.2222	0.5454	0.4285
AUC	0.4583	0.5416	0.2812	0.6041	0.5208	0.6875	0.5937

Πίνακας 13: Πίνακας σύγκρισης μεταξύ των αλγορίθμων μηχανικής μάθησης για όλες τις μετρικές των μοντέλων, δειγματοληπτικά για τον συμμετέχοντα 4.

Για την ολοκλήρωση της σύγκρισης μεταξύ των συμμετεχόντων ορίστηκε το μοντέλο XGBoost Classifier ως ικανότερο να δώσει μια πιο αντιπροσωπευτική εικόνα, όσον αφορά στη δυαδική ταξινόμηση που διενεργήθηκε στην παρούσα Διπλωματική Εργασία. Λαμβάνοντας υπόψη πως η εικόνα που λάβαμε από την



εκπαίδευση στα δεδομένα του κάθε συμμετέχοντα, αντιπροσωπεύεται σε μεγάλο βαθμό από τον πίνακα του συμμετέχοντα 4, δηλαδή πως ο XGBoost παρουσιάζει τις υψηλότερες τιμές στην μετρική AUC, ορίστηκε ως κατώφλι επιλογής των «outliers» συμμετεχόντων η τιμή της AUC να είναι μεγαλύτερη ή ίση με 0.55. Ως εκ τούτου επιλέχθηκαν οι συμμετέχοντες: 0, 3, 4, 9, 10, 12, 15, 16 και 19. Στον παρακάτω πίνακα παρουσιάζονται οι τιμές της μετρικής AUC για συμμετέχοντες που επιλέχθηκαν.








Τιμές AUC για του επιλεγμένους συμμετέχοντες

Συμμετέχων 0	0.5777
Συμμετέχων 3	0.5750
Συμμετέχων 4	0.6875
Συμμετέχων 9	0.6477
Συμμετέχων 10	0.6615
Συμμετέχων 12	0.5735
Συμμετέχων 15	0.5833
Συμμετέχων 16	0.5892
Συμμετέχων 19	0.5535









Πίνακας 14: Τιμές AUC παραγόμενες από τον XGBoost Classifier, για τους επιλεγμένους συμμετέχοντες.

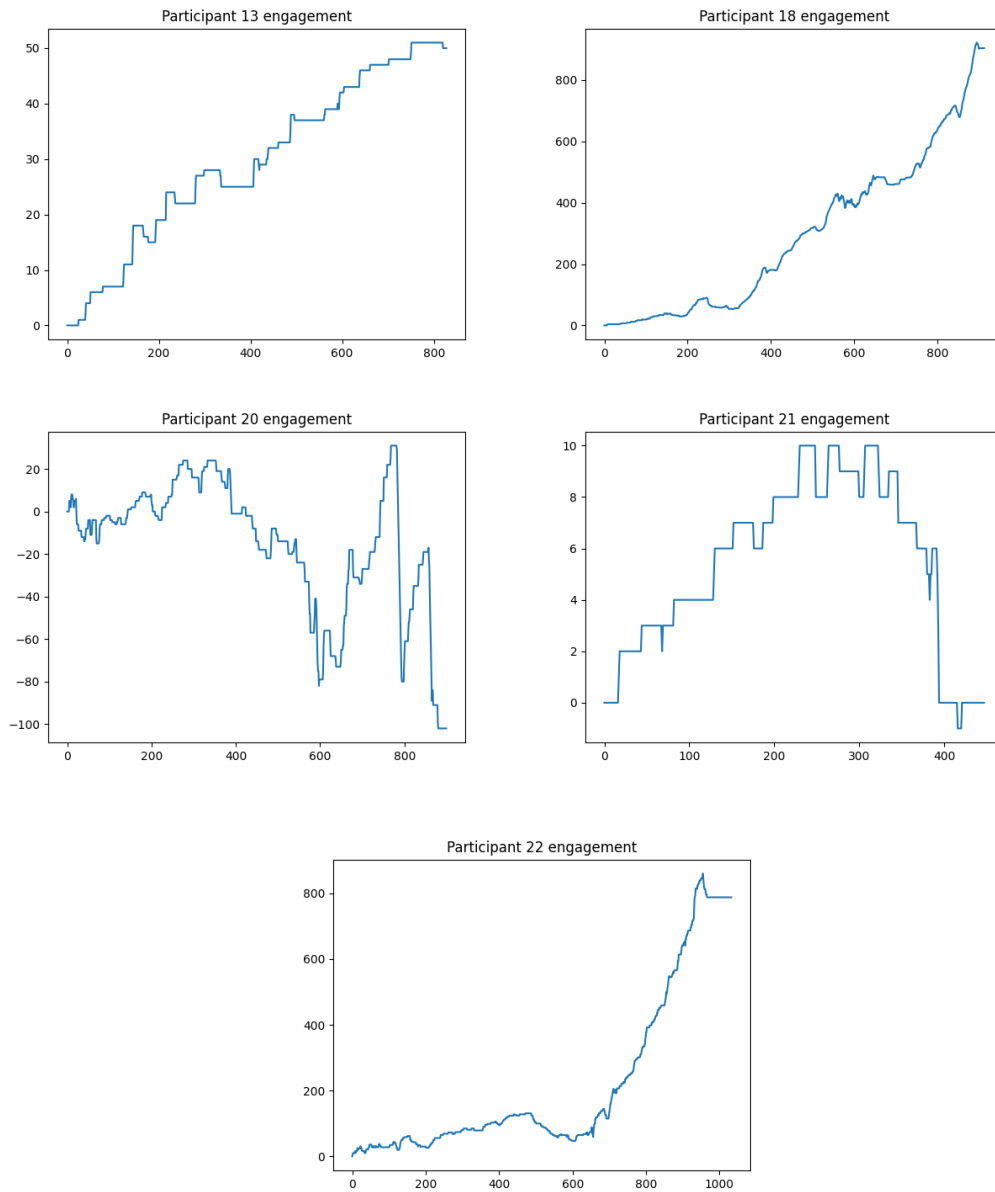
Στο Κεφάλαιο 5, στην ενότητα 5.2 παρουσιάζονται τα τελικά βέλτιστα αποτελέσματα για τους επιλεγμένους συμμετέχοντες. Γίνεται εμφανές πως η διακριτική ικανότητα των συγκεκριμένων μοντέλων που αναγράφονται στους πίνακες αυξήθηκε, όταν η εκπαίδευση αφορούσε τους συμμετέχοντες με τις βέλτιστες επιδόσεις από το δεύτερο σύνολο εκπαίδευσης. Επισυνάπτονται οι καμπύλες των τιμών προσήλωσης για τους επιλεγμένους συμμετέχοντες και για αυτούς που δεν επιλέχθηκαν. Στην ενότητα 6.3 θα αναζητηθεί εάν υπάρχει κάποιο συγκεκριμένο μοτίβο μεταξύ των καμπυλών προσήλωσης των επιλεγμένων, σε σύγκριση με τους μη επιλεγμένους συμμετέχοντες και τι συμπεράσματα μπορούν να προκύψουν από αυτό.





Διάγραμμα 2: Καμπύλες προσήλωσης για τους συμμετέχοντες που επιλέχθηκαν με τις καλύτερες τιμές AUC.





Διάγραμμα 3: Καμπύλες προσήλωσης για τους συμμετέχοντες που δεν επιλέχθηκαν διότι οι τιμές AUC ήταν μικρότερες του 0.55.

6.3 Αναζήτηση μίας κοινής αρχής που να διέπει τα δεδομένα προσήλωσης των συμμετεχόντων που επιλέχθηκαν για εκπαίδευση, σε σύγκριση με αυτά των συμμετεχόντων που δεν επιλέχθηκαν

Αναλύοντας τα παραπάνω δεδομένα, πραγματοποιήθηκε εκτενής έρευνα για την αναζήτηση μίας κοινής αρχής που να διέπει τα δεδομένα προσήλωσης των συμμετεχόντων που επιλέχθηκαν για εκπαίδευση, σε σύγκριση με αυτά των συμμετεχόντων που δεν επιλέχθηκαν. Πιο συγκεκριμένα α) εξήχθησαν γραφήματα που αφορούν δεδομένα κατανομών των τιμών προσήλωσης με τη χρήση της

συνάρτησης «distplot()» της βιβλιοθήκης «Seaborn» της Python, που είναι εξειδικευμένη για την αποτύπωση δεδομένων μηχανικής μάθησης, β) παρήχθησαν ιστογράμματα από τα οποία λάβαμε τις μετρικές «Skewness» και «Kurtosis» και γ) εξήχθησαν στατιστικές μετρικές για τα δεδομένα, που είναι η «Mean-Average», η «Variance» και «Standard Deviation». Από την ανάλυση των παραπάνω δεν προέκυψε κάποιο εμφανές μοτίβο το οποίο να διέπει τους συμμετέχοντες που επιλέχθηκαν, σε αντίθεση με αυτούς που δεν επιλέχθηκαν, παρά μόνο πως η επιλογή βασίστηκε σε υποκειμενικά κριτήρια και συγκεκριμένα στον ορισμό ενός ελάχιστου ορίου της τιμής AUC στο 0.55.

Ανεξαρτήτως των παραπάνω, η έρευνα για την σύνδεση των χρονικών χαρακτηριστικών της MKP με τα επισημειωμένα δεδομένα του χρήστη, για τα επίπεδα προσήλωσης του, κατά την αλληλοεπίδραση με το ΠΣΣΥ, οδήγησε στο συμπέρασμα πως υπάρχει ικανότητα στα μοντέλα μηχανικής μάθησης να προβλέψουν ικανοποιητικά και άρα υπάρχει σχέση μεταξύ HRV και Engagement. Συγκεκριμένα εάν υπάρξουν αρκετά δεδομένα που με κατάλληλη επεξεργασία να χρησιμοποιούνται ως είσοδος και η έξοδος να έχει άμεση συνάφεια με την είσοδο, σύγχρονοι αλγόριθμοι όπως ο XGBoost, ο Decision Tree και ο Random Forest, μπορούν να εκπαιδευτούν και να δώσουν αρκετά ικανοποιητικά αποτελέσματα. Ταυτόχρονα η αναζήτηση νέων αλγορίθμων με υψηλότερη πολυπλοκότητα, συνεχίζει να αποτελεί πρόκληση.

Κεφάλαιο 7: Επίλογος

7.1 Σύνοψη

Συνοψίζοντας, η παρούσα Διπλωματική Εργασία κυμαίνεται σε δύο βασικούς άξονες έρευνας. Ο πρώτος βασικός άξονας αφορά την θεωρητική πλαισίωση και την εισαγωγή στις βασικές έννοιες που αναφέρονται στην έρευνα της παρούσας Διπλωματικής Εργασίας. Ο δεύτερος βασικός άξονας αφορά το πρακτικό μέρος της παρούσας έρευνας, δηλαδή την συγγραφή του κώδικα που θα επιτελεί την πειραματική έρευνα. Πιο συγκεκριμένα πραγματοποιήθηκε εκκαθάριση και επεξεργασία των δεδομένων της ΜΚΡ, αλλά και των επισημειωμένων δεδομένων των συμμετεχόντων για την προσήλωσή τους. Εν συνεχεία τα δεδομένα εισάγονται σε ρηγά μοντέλα μηχανικής μάθησης, με σκοπό την κατάλληλη εκπαίδευση και την παραγωγή μετρικών, που υποδεικνύουν την ικανότητα των μοντέλων στην πρόβλεψη των επιπέδων προσήλωσής. Ως είσοδος των μοντέλων μηχανικής μάθησης ορίστηκαν τα χρονικά διαστήματα που περιλαμβάνουν την χρονική ανάλυση των δεδομένων του καρδιακού ρυθμού και ως έξοδος τα χρονικά διαστήματα που περιλαμβάνουν τιμές 0 και 1 παραγόμενες από τις μετρικές προσήλωσης. Ακολούθησε η επίλυση των προβλημάτων που παρουσιάστηκαν εξαιτίας σφάλματος στην υποκειμενική καταγραφή των δεδομένων προσήλωσης των συμμετεχόντων, μέσω εκπαίδευσης των μοντέλων στα δεδομένα κάθε χρήστη και την επιλογή των συμμετεχόντων με τις καλύτερες μετρικές για την παραγωγή των τελικών αποτελεσμάτων. Τέλος πραγματοποιείται σύγκριση ανάμεσα στα δύο σύνολα εκπαίδευσης και διερευνώνται ζητήματα που αφορούν την ποιότητα επισημείωσης των επιπέδων προσήλωσης.

7.2 Όρια και περιορισμοί

Σημαντικός περιορισμός για την ανάλυση των δεδομένων τόσο του καρδιακού ρυθμού όσο και της προσήλωσης των συμμετεχόντων, αποτελεί ο μικρός αριθμός δειγμάτων σε συνδυασμό με την ασάφεια που παρουσιάζουν τα δεδομένα προσήλωσης κάποιων χρηστών. Πιο συγκεκριμένα κατά την διενέργεια του πειράματος, παρουσιάζονται για την μετρική AUC, αρκετά χαμηλές τιμές υποδηλώνοντας έλλειψη ικανότητας διαχωρισιμότητας των μοντέλων. Η έλλειψη συμμετεχόντων αλλά και η παρουσίαση σφαλμάτων επηρεάζουν αρκετά την εγγύτητα και τον παράγοντα μεροληψίας των μοντέλων. Επιπρόσθετα, για κάποιους συμμετέχοντες παρουσιάζεται ανισορροπία στην κατανομή των τιμών 0 και 1, όσον αφορά στις μετρικές προσήλωσης, γεγονός που χρειάζεται περαιτέρω ανάλυση και διερεύνηση τρόπων επίλυσης, καθώς υπάρχει πιθανότητα αλλοίωσης των αποτελεσμάτων.

Παράλληλα αρκετά σημαντικό περιορισμό αποτελεί και ο εξοπλισμός που χρησιμοποιήθηκε στη διενέργεια του πειράματος. Συγκεκριμένα, ο αισθητήρας που χρησιμοποιήθηκε χαρακτηρίζεται χαμηλού κόστους, με αποτέλεσμα να εισάγει

φαινόμενα θορύβου και ασταθειών στην δειγματοληψία του πειράματος. Αποτέλεσμα των παραπάνω είναι όπως προαναφέρθηκε η μείωση της εγγύτητας των προς ανάλυση δεδομένων.

Ακόμα η δήλωση των επιπέδων προσήλωσης από τους συμμετέχοντες, εισάγει έντονο υποκειμενισμό και αβεβαιότητα καθώς υποδηλώνονται μετά το πέρας της αλληλοεπίδρασης με το ΠΣΣΥ. Πιο συγκεκριμένα η χρήση εργαλείων ανίχνευσης επιδράσεων και συναισθημάτων, θα μπορούσε να βελτιώσει αισθητά τα δεδομένα της προσήλωσης των συμμετεχόντων, χωρίς να υπάρχουν αμφιβολίες για την αποτύπωση της πραγματικής κατάστασης που περιγράφεται μέσω της μνήμης.

7.3 Μελλοντικές Προκλήσεις

Η παρούσα Διπλωματική Εργασία, θα μπορούσε να επεκταθεί μελλοντικά με τη συλλογή περισσότερων δεδομένων, είτε με την αύξηση των συμμετεχόντων ή με την καταγραφή των δεδομένων προσήλωσης περισσότερες της μίας φορές για την αποφυγή «θορύβου», έτσι ώστε τα δεδομένα σχεδόν όλων των συμμετεχόντων να μπορούν να αξιοποιηθούν στην εκπαίδευση των μοντέλων.

Ακόμα μελλοντική πρόκληση αποτελεί και η εξέλιξη και αναβάθμιση του εξοπλισμού καταγραφής του καρδιακού ρυθμού. Πιο συγκεκριμένα, ο αισθητήρας καταγραφής για την παρούσα έρευνα, άφησε περιθώρια για αστάθειες στην καταγραφή της ΜΚΡ κατά τα διαστήματα αλληλεπίδρασης με το ΠΣΣΥ εισάγοντας πολλές φορές θόρυβο. Η ταυτόχρονη, υποκειμενική, δήλωση του χρήστη, σχετικά με τα επίπεδα προσήλωσής του, κατά την αλληλοεπίδραση με το ΠΣΣΥ, θα βοηθούσε αρκετά στην ανάλυση και ερμηνεία των δεδομένων, καθώς ο συμμετέχων θα έδινε πιο σωστά αποτελέσματα δυναμικά. Επιπλέον η ανάπτυξη ενός παράλληλου ΠΣΣΥ πιο εξελιγμένου, στο οποίο ο χρήστης θα καλείται να αλληλοεπιδράσει αφού ολοκληρώσει το πρώτο, θα οδηγούσε πιθανώς στην αύξηση των δεδομένων προς ανάλυση, αλλά και του ενδιαφέροντος, της προσήλωσης και της ενασχόλησης των συμμετεχόντων.

Ακόμα μια σημαντική μελλοντική πρόταση, αποτελεί και ο συνδυασμός αλλά και η διασταύρωση των δεδομένων εκπαίδευσης με δεδομένα άλλων αισθητήρων, όπως ενός ηλεκτροεγκεφαλογραφήματος ή (και) ηλεκτρομυογραφήματος. Τα δεδομένα αυτά μπορούν να παρέχουν ένα αρκετά μεγάλο εύρος συνόλου εκπαίδευσης που θα βοηθούσε στην βελτίωση της διακριτικής ικανότητας των μοντέλων μηχανικής μάθησης.

Μελλοντική πρόκληση αποτελεί και η αναζήτηση (ή και η ανάπτυξη) πιο σύγχρονων αλγορίθμων μηχανικής μάθησης, οι οποίοι θα παρουσιάζουν πιο έντονη πολυπλοκότητα απέναντι σε προβλήματα με «ασυμβίβαστα» δεδομένα ή (και) με έντονη ανισορροπία των δεδομένων κατά την εκπαίδευση.

Κεφάλαιο 8: Βιβλιογραφία

- [1] M. Flores, G. Glusman, K. Brogaard, N. D. Price, and L. Hood, "P4 medicine: how systems medicine will transform the healthcare sector and society," *Per Med*, vol. 10, no. 6, pp. 565–576, Aug. 2013, doi: 10.2217/pme.13.57.
- [2] C Lee Ventola, "Mobile devices and apps for health care professionals: uses and benefits".
- [3] J. Tao and T. Tan, "Affective Computing: A Review," 2005, pp. 981–995. doi: 10.1007/11573548_125.
- [4] V. Wattanasoontorn, I. Boada, R. García, and M. Sbert, "Serious games for health," *Entertain Comput*, vol. 4, no. 4, pp. 231–247, Dec. 2013, doi: 10.1016/J.ENTCOM.2013.09.002.
- [5] K. Mitsis *et al.*, "A Multimodal Approach for Real Time Recognition of Engagement towards Adaptive Serious Games for Health," *Sensors*, vol. 22, no. 7, p. 2472, Mar. 2022, doi: 10.3390/s22072472.
- [6] "Wikipedia contributors. 'Serious game.' Wikipedia, The Free Encyclopedia. Wikipedia, The Free Encyclopedia, 16 Mar. 2023. Web. 13 Jun. 2023.", Accessed: Jun. 13, 2023. [Online]. Available: https://en.wikipedia.org/wiki/Serious_game
- [7] K. Mitsis, E. Kalafatis, K. Zarkogianni, G. Mourkousis, and K. S. Nikita, "Procedural content generation based on a genetic algorithm in a serious game for obstructive sleep apnea," in *2020 IEEE Conference on Games (CoG)*, IEEE, Aug. 2020, pp. 694–697. doi: 10.1109/CoG47356.2020.9231785.
- [8] K. Mitsis, K. Zarkogianni, N. Bountouni, M. Athanasiou, and K. S. Nikita, "An Ontology-Based Serious Game Design for the Development of Nutrition and Food Literacy Skills," in *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, IEEE, Jul. 2019, pp. 1405–1408. doi: 10.1109/EMBC.2019.8856604.
- [9] F. Ricciardi and L. T. De Paolis, "A Comprehensive Review of Serious Games in Health Professions," *International Journal of Computer Games Technology*, vol. 2014, pp. 1–11, 2014, doi: 10.1155/2014/787968.
- [10] A. A. Tori, R. Tori, and F. de L. dos S. Nunes, "Serious Game Design in Health Education: A Systematic Review," *IEEE Transactions on Learning Technologies*, vol. 15, no. 6, pp. 827–846, Dec. 2022, doi: 10.1109/TLT.2022.3200583.
- [11] C. Lister, J. H. West, B. Cannon, T. Sax, and D. Brodegard, "Just a Fad? Gamification in Health and Fitness Apps," *JMIR Serious Games*, vol. 2, no. 2, p. e9, Aug. 2014, doi: 10.2196/games.3413.
- [12] A. E. J. van Gaalen, J. Brouwer, J. Schönrock-Adema, T. Bouwkamp-Timmer, A. D. C. Jaarsma, and J. R. Georgiadis, "Gamification of health professions education: a systematic review," *Advances in Health Sciences Education*, vol. 26, no. 2, pp. 683–711, May 2021, doi: 10.1007/s10459-020-10000-3.

- [13] G. N. Yannakakis and J. Togelius, *Artificial Intelligence and Games*. Cham: Springer International Publishing, 2018. doi: 10.1007/978-3-319-63519-4.
- [14] A. Ezquerra, F. Agen, I. Rodríguez-Arteche, and I. Ezquerra-Romano, "Integrating Artificial Intelligence into Research on Emotions and Behaviors in Science Education," *Eurasia Journal of Mathematics, Science and Technology Education*, vol. 18, no. 4, p. em2099, Mar. 2022, doi: 10.29333/ejmste/11927.
- [15] L. F. Barrett, R. Adolphs, S. Marsella, A. M. Martinez, and S. D. Pollak, "Emotional Expressions Reconsidered: Challenges to Inferring Emotion From Human Facial Movements," *Psychological Science in the Public Interest*, vol. 20, no. 1, pp. 1–68, Jul. 2019, doi: 10.1177/1529100619832930.
- [16] J. Lee, S. Lee, and D. Kim, "Problems and Issues of Emotional Computing and Artificial Emotional Intelligence: A Review of Rosalind W. Picard's thesis 'Affective Computing: Challenges,'" in *2022 IEEE/ACIS 7th International Conference on Big Data, Cloud Computing, and Data Science (BCD)*, IEEE, Aug. 2022, pp. 360–364. doi: 10.1109/BCD54882.2022.9900683.
- [17] *A Dictionary of Psychology*. Oxford University Press, 2008. doi: 10.1093/acref/9780199534067.001.0001.
- [18] I. A. Vasilakis *et al.*, "THE ENDORSE FEASIBILITY PILOT TRIAL: ASSESSING THE IMPLEMENTATION OF SERIOUS GAMES STRATEGY AND ARTIFICIAL INTELLIGENCE-BASED TELEMEDICINE IN GLYCEMIC CONTROL IMPROVEMENT," *Diabetes Technol Ther*, p. A218-A219, 2022.
- [19] E. Kalafatis *et al.*, "Artificial Intelligence Based Procedural Content Generation in Serious Games for Health: The Case of Childhood Obesity," 2023, pp. 207–219. doi: 10.1007/978-3-031-32029-3_19.
- [20] W. S. Ravyse, A. Seugnet Blignaut, V. Leendertz, and A. Woolner, "Success factors for serious games to enhance learning: a systematic review," *Virtual Real*, vol. 21, no. 1, pp. 31–58, Mar. 2017, doi: 10.1007/s10055-016-0298-4.
- [21] R. Titung, "Interactive Machine Learning for Multimodal Affective Computing," in *2022 10th International Conference on Affective Computing and Intelligent Interaction Workshops and Demos (ACIIW)*, IEEE, Oct. 2022, pp. 1–4. doi: 10.1109/ACIIW57231.2022.10085996.
- [22] B. Bontchev, I. Naydenov, and I. Adamov, "Controlling Adaptation in Affective Serious Games," in *2021 International Conference Automatics and Informatics (ICAI)*, IEEE, Sep. 2021, pp. 159–162. doi: 10.1109/ICAI52893.2021.9639656.
- [23] M. S. Nair and D. P. Gopinath, "Transfer learning for Speech Based Emotion Recognition," in *2022 IEEE International Conference on Signal Processing, Informatics, Communication and Energy Systems (SPICES)*, IEEE, Mar. 2022, pp. 559–564. doi: 10.1109/SPICES52834.2022.9774103.
- [24] D. S. Moschona, "An Affective Service based on Multi-Modal Emotion Recognition, using EEG enabled Emotion Tracking and Speech Emotion Recognition," in *2020 IEEE International Conference on Consumer Electronics - Asia (ICCE-Asia)*, IEEE, Nov. 2020, pp. 1–3. doi: 10.1109/ICCE-Asia49877.2020.9277291.

- [25] F. Shaffer and J. P. Ginsberg, "An Overview of Heart Rate Variability Metrics and Norms," *Front Public Health*, vol. 5, Sep. 2017, doi: 10.3389/fpubh.2017.00258.
- [26] R. Tiwari, R. Kumar, S. Malik, T. Raj, and P. Kumar, "Analysis of Heart Rate Variability and Implication of Different Factors on Heart Rate Variability," *Curr Cardiol Rev*, vol. 17, no. 5, Sep. 2021, doi: 10.2174/1573403X16999201231203854.
- [27] F. Shaffer, Z. M. Meehan, and C. L. Zerr, "A Critical Review of Ultra-Short-Term Heart Rate Variability Norms Research," *Front Neurosci*, vol. 14, Nov. 2020, doi: 10.3389/fnins.2020.594880.
- [28] G. Giannakakis, K. Marias, and M. Tsiknakis, "A stress recognition system using HRV parameters and machine learning techniques," in *2019 8th International Conference on Affective Computing and Intelligent Interaction Workshops and Demos (ACIIW)*, IEEE, Sep. 2019, pp. 269–272. doi: 10.1109/ACIIW.2019.8925142.
- [29] Z.-D. Deng, C.-S. Poon, N. M. Arzeno, and E. S. Katz, "Heart Rate Variability in Pediatric Obstructive Sleep Apnea," in *2006 International Conference of the IEEE Engineering in Medicine and Biology Society*, IEEE, Aug. 2006, pp. 3565–3568. doi: 10.1109/IEMBS.2006.260139.
- [30] D. M. Pendleton, M. L. Sakalik, M. L. Moore, and P. D. Tomporowski, "Mental engagement during cognitive and psychomotor tasks: Effects of task type, processing demands, and practice," *International Journal of Psychophysiology*, vol. 109, pp. 124–131, Nov. 2016, doi: 10.1016/j.ijpsycho.2016.08.012.
- [31] J. F. Thayer, A. L. Hansen, E. Saus-Rose, and B. H. Johnsen, "Heart Rate Variability, Prefrontal Neural Function, and Cognitive Performance: The Neurovisceral Integration Perspective on Self-regulation, Adaptation, and Health," *Annals of Behavioral Medicine*, vol. 37, no. 2, pp. 141–153, Apr. 2009, doi: 10.1007/s12160-009-9101-z.
- [32] T. M. Hess, "Selective Engagement of Cognitive Resources," *Perspectives on Psychological Science*, vol. 9, no. 4, pp. 388–407, Jul. 2014, doi: 10.1177/1745691614527465.
- [33] N. Hjortskov, D. Rissén, A. K. Blangsted, N. Fallentin, U. Lundberg, and K. Søgaard, "The effect of mental stress on heart rate variability and blood pressure during computer work," *Eur J Appl Physiol*, vol. 92, no. 1–2, pp. 84–89, Jun. 2004, doi: 10.1007/s00421-004-1055-z.
- [34] J. Taelman, S. Vandeput, E. Vlemincx, A. Spaepen, and S. Van Huffel, "Instantaneous changes in heart rate regulation due to mental load in simulated office work," *Eur J Appl Physiol*, vol. 111, no. 7, pp. 1497–1505, Jul. 2011, doi: 10.1007/s00421-010-1776-0.
- [35] D. M. Pendleton, M. L. Sakalik, M. L. Moore, and P. D. Tomporowski, "Mental engagement during cognitive and psychomotor tasks: Effects of task type, processing demands, and practice," *International Journal of Psychophysiology*, vol. 109, pp. 124–131, Nov. 2016, doi: 10.1016/j.ijpsycho.2016.08.012.
- [36] K. Mitsis, K. Zarkogianni, K. Dalakleidi, G. Mourkousis, and K. S. Nikita, "Evaluation of a Serious Game Promoting Nutrition and Food Literacy: Experiment Design and Preliminary Results," in *2019 IEEE 19th International Conference on Bioinformatics*

- and Bioengineering (BIBE)*, IEEE, Oct. 2019, pp. 497–502. doi: 10.1109/BIBE.2019.00096.
- [37] R. Bailon, P. Laguna, L. Mainardi, and L. Sornmo, “Analysis of Heart Rate Variability Using Time-Varying Frequency Bands Based on Respiratory Frequency,” in *2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, IEEE, Aug. 2007, pp. 6674–6677. doi: 10.1109/IEMBS.2007.4353891.
- [38] F. Shaffer and J. P. Ginsberg, “An Overview of Heart Rate Variability Metrics and Norms,” *Front Public Health*, vol. 5, Sep. 2017, doi: 10.3389/fpubh.2017.00258.
- [39] F. Kherif and A. Latypova, “Principal component analysis,” in *Machine Learning*, Elsevier, 2020, pp. 209–225. doi: 10.1016/B978-0-12-815739-8.00012-2.