



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ

ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

ΤΟΜΕΑΣ ΣΥΣΤΗΜΑΤΩΝ ΜΕΤΑΔΟΣΗΣ ΠΛΗΡΟΦΟΡΙΑΣ

ΚΑΙ ΤΕΧΝΟΛΟΓΙΑΣ ΥΛΙΚΩΝ

**Αναγνώριση επιπέδων προσήλωσης σε πραγματικό χρόνο με τεχνικές
βαθιάς μάθησης που αξιοποιούν δεδομένα αισθητήρων**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Μυρτώ Ι. Κοκμοτού

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

Αθήνα, Οκτώβριος 2024



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ

ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

ΤΟΜΕΑΣ ΣΥΣΤΗΜΑΤΩΝ ΜΕΤΑΔΟΣΗΣ ΠΛΗΡΟΦΟΡΙΑΣ

ΚΑΙ ΤΕΧΝΟΛΟΓΙΑΣ ΥΛΙΚΩΝ

**Αναγνώριση επιπέδων προσήλωσης σε πραγματικό χρόνο με τεχνικές
βαθιάς μάθησης που αξιοποιούν δεδομένα αισθητήρων**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Μυρτώ Ι. Κοκμοτού

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

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 14^η Οκτωβρίου 2024.

.....

Κωνσταντίνα Σ. Νικήτα

Καθηγήτρια Ε.Μ.Π.

.....

Γεώργιος Στάμου

Καθηγητής Ε.Μ.Π.

.....

Αθανάσιος Βουλόδημος

Επίκουρος Καθηγητής Ε.Μ.Π.

Αθήνα, Οκτώβριος 2024

.....

Μυρτώ Ι. Κοκμοτού

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

Copyright © Μυρτώ Ι. Κοκμοτού, 2024

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.

Περίληψη

Η παρούσα διπλωματική εργασία εξετάζει τη συσχέτιση μεταξύ της μεταβλητότητας του καρδιακού ρυθμού (ΜΚΡ) και των επιπέδων προσήλωσης κατά την αλληλεπίδραση ενός χρήστη με Παιχνίδι Σοβαρού Σκοπού (ΠΣΣ), που στοχεύει στην προώθηση υγιεινών διατροφικών συνηθειών. Ο βασικός στόχος της έρευνας είναι να αναπτυχθεί μοντέλο επιβλεπόμενης βαθιάς μάθησης, το οποίο να αξιοποιεί εξαγόμενα χαρακτηριστικά από τις καταγραφές του καρδιακού παλμού για να προβλέπει τα επίπεδα προσήλωσης των συμμετεχόντων.

Τμηματικά, η παρούσα εργασία, αναζητά λύσεις στην ανάγκη θεωρητικής θεμελίωσης και πειραματικής πλαισίωσης του παρόντος σεναρίου. Αρχικά, μελετώνται και αναλύονται βιβλιογραφικά οι θεμελιώδεις έννοιες της έρευνας. Στη συνέχεια, πραγματοποιείται ανάλυση και προεπεξεργασία των συλλεγόμενων δεδομένων, τόσο των καταγραφών καρδιακού παλμού όσο και των υποκειμενικών αναφορών με τη μορφή επισημειώσεων της προσήλωσης των συμμετεχόντων. Για τη διερεύνηση της σχέσης μεταξύ των δεδομένων εισόδου – εξόδου, εκπαιδεύεται μοντέλο βαθιάς μάθησης με τη μέθοδο Leave One (Participant) Out και αξιολογείται με βάση μετρικές που υποδεικνύουν την ικανότητα του στην πρόβλεψη των επιπέδων προσήλωσης.

Η διαδικασία της εκπαίδευσης με τη μέθοδο παλινδρόμησης (regression) μετατρέπεται σε δυαδική ταξινόμηση (binary classification), με την εισαγωγή μετρικών που αποτυπώνουν την αύξουσα και φθίνουσα τάση των επιπέδων προσήλωσης. Τα αποτελέσματα της αξιολόγησης του νέου αυτού προβλήματος, υποδεικνύουν την ύπαρξη ανισορροπίας των κλάσεων (*class imbalance*). Συνολικά, διαπιστώνεται ότι το προτεινόμενο μοντέλο δεν επιτυγχάνει ικανοποιητική ικανότητα πρόβλεψης. Παράλληλα, αναδεικνύεται η ανάγκη περαιτέρω διερεύνησης σε μεγαλύτερα σύνολα δεδομένων, καθώς και η μείωση του θορύβου και της προκατάληψης (bias) που εισάγονται κατά τη διαδικασία καταγραφής των δεδομένων. Μελλοντικά, η παρούσα μελέτη θα μπορούσε να αξιοποιηθεί για την ενίσχυση της παρέμβασης που προσφέρει το ΠΣΣ μέσω κατάλληλου μηχανισμού δυναμικής αναπροσαρμογής για την εξατομίκευση.

Λέξεις Κλειδιά: Συναισθηματική Υπολογιστική Νοημοσύνη, Ανάλυση συναισθήματος, Παιχνίδια Σοβαρού Σκοπού, Μεταβλητότητα Καρδιακού Ρυθμού, Προσήλωση, Βαθιά Μάθηση

Abstract

This thesis examines the association between heart rate variability (HRV) and perceived levels of engagement during a user's interaction with a Serious Game (SG) as an intervention to promote healthy nutrition habits. The main objective of the research is to develop a supervised deep learning model that utilizes extracted features from pulse recordings to predict participants' engagement levels.

Segmentally, this paper seeks solutions to the need for theoretical foundation and experimental framing of this scenario. Firstly, the fundamental concepts of the research are studied and analysed in the literature. Then, analysis and pre-processing of the collected data, both heart rate recordings and self-reports in the form of participants' engagement annotations, is performed. To investigate the relationship between the input-output data, a deep learning model is trained using the Leave One (Participant) Out method and evaluated against metrics indicating its ability to predict engagement levels.

The regression training process is transformed into a binary classification by introducing metrics that capture the increasing and decreasing trend of engagement levels. The results of the evaluation of this new problem indicate the existence of a class imbalance. Overall, it is found that the proposed model does not achieve a satisfactory predictive ability. At the same time, the need for further investigation on larger datasets is highlighted, as well as the need to reduce the noise and bias introduced during the data recording process. In the future, this study could be used to enhance the intervention offered by the SG through an appropriate dynamic adaption mechanism for personalisation.

Keywords: Affective Computing, Sentiment Analysis, Serious Games, Heart Rate Variability, Engagement, Deep Learning

Πίνακας περιεχομένων

1. Εισαγωγή.....	12
1.1 Εισαγωγή στο αντικείμενο της διπλωματικής εργασίας.....	12
1.2 Στόχος διπλωματικής εργασίας.....	13
1.3 Οργάνωση διπλωματικής εργασίας.....	13
2. Θεωρητικό πλαίσιο.....	15
2.1 Ανθρώπινο συναίσθημα ως αντικείμενο έρευνας.....	15
2.1.1 Θεωρητικά μοντέλα συναισθήματος.....	15
2.1.2 Συναισθηματική υπολογιστική και νοημοσύνη.....	16
2.1.3 Τεχνικές βαθιάς μάθησης για την πρόβλεψη συναισθήματος.....	20
2.1.4 Εφαρμογές και προκλήσεις στην αναγνώριση συναισθήματος.....	21
2.2 Παιχνίδια Σοβαρού Σκοπού (Serious Games).....	22
2.2.1 Ορισμός και χαρακτηριστικά.....	22
2.2.2 ΣΥΝ και ΠΣΣ.....	24
2.2.3 Εφαρμογές και προκλήσεις.....	26
2.3 Μεταβλητότητα καρδιακού ρυθμού.....	27
2.3.1 Βιολογικοί μηχανισμοί του καρδιακού ρυθμού.....	27
2.3.2 Σημασία και χρήση των δεδομένων ΜΚΡ.....	29
2.4 Προσήλωση.....	30
2.4.1 Μέτρηση της προσήλωσης.....	30
2.4.2 Προσήλωση και ΜΚΡ.....	31
3. Μεθοδολογία.....	33
3.1 Περιγραφή πειραματικής διάταξης.....	33
3.2.1 ΠΣΣ.....	33
3.2.2 Καταγραφή των επιπέδων προσήλωσης.....	34
3.2.3 Συλλογή δεδομένων από αισθητήρες.....	34
3.2.4 Συμμετέχοντες.....	34
3.2 Προεπεξεργασία δεδομένων.....	35
3.2.1 Δομή και εκκαθάριση δεδομένων.....	35
3.2.1.1 Εκκαθάριση δεδομένων καρδιακού ρυθμού.....	35
3.2.1.2 Εκκαθάριση δεδομένων επισημειώσεων των επιπέδων προσήλωσης.....	36
3.2.2 Προετοιμασία Δεδομένων.....	36
3.2.2.1 Προεπεξεργασία δεδομένων καρδιακού ρυθμού.....	37
3.2.2.2 Χωρισμός χρονικών παραθύρων παρατήρησης και εφαρμογή επικάλυψης.....	40
3.2.2.3 Προετοιμασία δεδομένων προσήλωσης.....	41
3.2.2.4 Αντιστοίχιση δεδομένων εισόδου – εξόδου.....	41
4. Προτεινόμενο μοντέλο βαθιάς μάθησης.....	43
4.1 Leave-One(Participant)-Out Cross Validation (LO(P)OCV).....	43
4.2 Εξαγωγή χαρακτηριστικών.....	44
4.3 Αρχιτεκτονική μοντέλου.....	44
4.3.1 Ορισμός Convolutional-Neural-Network (CNN).....	45
4.3.2 Δομή και εκπαίδευση του μοντέλου.....	47
4.4 Φιλτράρισμα Διάμεσης Τιμής (Median Filtering).....	49
4.5 Μέθοδος αξιολόγησης των προβλέψεων.....	49
5. Αποτελέσματα.....	52
5.1 Αποτελέσματα για παράθυρα 10 sec.....	52
5.2 Αποτελέσματα για παράθυρα 30 sec.....	54
5.3 Γραφικές παραστάσεις επιπέδων προσήλωσης.....	56
6. Συζήτηση και συμπεράσματα.....	60

6.1 Ερμηνεία των αποτελεσμάτων και προκλήσεις.....	61
6.2 Προτάσεις βελτίωσης.....	64
7. Επίλογος.....	66
7.1 Σύνοψη.....	66
7.2 Περιορισμοί και προκλήσεις.....	66
7.3 Μελλοντικές κατευθύνσεις.....	67
Βιβλιογραφία.....	69

Ευρετήριο Εικόνων

Εικόνα 1: Russell's Circumplex Model of Emotions.....	16
Εικόνα 2: Εφαρμογές της Συναισθηματικής Υπολογιστικής Νοημοσύνης.....	17
Εικόνα 3: Δεδομένα εισόδου για συστήματα αναγνώρισης συναισθήματος [16].....	20
Εικόνα 4: Δυναμική αλληλεπίδραση των χαρακτηριστικών ΠΣΣ [22].....	23
Εικόνα 5: Γραφική απεικόνιση των βασικότερων περιοχών εφαρμογής ΠΣΣ [23].....	26
Εικόνα 6: Τομείς εφαρμογής της ανάλυσης της ΜΚΡ [33].....	30
Εικόνα 7: Ενδεικτικά δεδομένα από αρχείο μετρήσεων καρδιακού ρυθμού.....	35
Εικόνα 8: Ενδεικτικά δεδομένα από αρχείο επισημειώσεων επιπέδων προσήλωσης.....	36
Εικόνα 9: Εποπτικό παράδειγμα διαστημάτων N-N από σήμα PPG.....	37
Εικόνα 10: Αποτελέσματα συσχέτισης Pearson των ΜΚΡ - διέγερσης/σθένους [42].....	38
Εικόνα 11: Εποπτικό παράδειγμα χρονικά επικαλυπτόμενων παραθύρων.....	40
Εικόνα 12: Η δομή ενός CNN.....	45
Εικόνα 13: Δομή Fully-connected layer σε ένα Νευρωνικό Δίκτυο.....	47
Εικόνα 14: Πίνακας σύγχυσης της μετρικής της αύξουσας τάσης για μέθοδο χωρίς validation σε χρονικά παράθυρα παρατήρησης 10 sec και αντίστοιχη ROC καμπύλη.....	53
Εικόνα 15: Πίνακας σύγχυσης της μετρικής της φθίνουσας τάσης για μέθοδο χωρίς validation σε χρονικά παράθυρα παρατήρησης 10 sec και αντίστοιχη ROC καμπύλη.....	53
Εικόνα 16: Πίνακας σύγχυσης της μετρικής της αύξουσας τάσης για μέθοδο με validation σε χρονικά παράθυρα παρατήρησης 10 sec και αντίστοιχη ROC καμπύλη.....	53
Εικόνα 17: Πίνακας σύγχυσης της μετρικής της φθίνουσας τάσης για μέθοδο με validation σε χρονικά παράθυρα παρατήρησης 10 sec και αντίστοιχη ROC καμπύλη.....	54
Εικόνα 18: Πίνακας σύγχυσης της μετρικής της αύξουσας τάσης για μέθοδο χωρίς validation σε χρονικά παράθυρα παρατήρησης 30 sec και αντίστοιχη ROC καμπύλη.....	55
Εικόνα 19: Πίνακας σύγχυσης της μετρικής της φθίνουσας τάσης για μέθοδο χωρίς validation σε χρονικά παράθυρα παρατήρησης 30 sec και αντίστοιχη ROC καμπύλη.....	55
Εικόνα 20: Πίνακας σύγχυσης της μετρικής της αύξουσας τάσης για μέθοδο με validation σε χρονικά παράθυρα παρατήρησης 30 sec και αντίστοιχη ROC καμπύλη.....	55
Εικόνα 21: Πίνακας σύγχυσης της μετρικής της φθίνουσας τάσης για μέθοδο με validation σε χρονικά παράθυρα παρατήρησης 30 sec και αντίστοιχη ROC καμπύλη.....	56

Ευρετήριο Πινάκων

Πίνακας 1: Τιμές μετρικών προσήλωσης για χρονικά παράθυρα παρατήρησης 10 sec.....	52
Πίνακας 2: Τιμές μετρικών προσήλωσης για χρονικά παράθυρα παρατήρησης 30 sec.....	54

Ευρετήριο Διαγραμμάτων

Διάγραμμα 1: Συμμετέχων 12784.....	56
Διάγραμμα 2: Συμμετέχων 32281.....	56
Διάγραμμα 3: Συμμετέχων 64463.....	57
Διάγραμμα 4: Συμμετέχων 25690.....	57
Διάγραμμα 5: Συμμετέχων 33980.....	57
Διάγραμμα 6: Συμμετέχων 64404.....	57
Διάγραμμα 7: Συμμετέχων 84548.....	57
Διάγραμμα 8: Συμμετέχων 33999.....	57
Διάγραμμα 9: Συμμετέχων 32578.....	58
Διάγραμμα 10: Συμμετέχων 37381.....	58

Διάγραμμα 11: Συμμετέχων 28587.....	58
Διάγραμμα 12: Συμμετέχων 23416.....	58
Διάγραμμα 13: Συμμετέχων 65673.....	58
Διάγραμμα 14: Συμμετέχων 13477.....	58
Διάγραμμα 15: Συμμετέχων 51317.....	59

1. Εισαγωγή

1.1 Εισαγωγή στο αντικείμενο της διπλωματικής εργασίας

Ιστορικά, οι θετικές επιστήμες πορεύονται παράλληλα, επιδρούν και αλληλοεπηρεάζονται από τις ανθρωπιστικές επιστήμες, όπως η Κοινωνιολογία και η Ψυχολογία και από την πολιτισμική έκφραση όπως συναντάται στην Τέχνη, θέτοντας το επίκεντρο της έρευνας στη διάθεση των κοινωνικών αναγκών και της διαρκούς ανθρώπινης εξέλιξης. Στη σύγχρονη εποχή, αναδεικνύεται κυρίαρχος ο ρόλος της Επιστήμης των Υπολογιστών, παράλληλα με την ανάδυση της Τεχνητής Νοημοσύνης ως κυρίαρχου μέσου στην ερμηνεία και τη διαμόρφωση ποικίλων εκφάνσεων της καθημερινής ζωής. Αυτή η ραγδαία επάνοδος του ρόλου της μηχανής στη ζωή του ανθρώπου, συντελεί πλέον παράγοντα καθοριστικής επιρροής στο σύνολο των επιστημονικών αναλύσεων και μελετών. Ταυτόχρονα, η εγκαθίδρυση μιας προσέγγισης που τοποθετεί τον άνθρωπο στο επίκεντρο, ως εκφραστή και ταυτόχρονα αποδέκτη ενός πολυπαραγοντικού περιβάλλοντος, αναδεικνύει την αξία της μοναδικότητας του ατόμου. Δημιουργείται, λοιπόν, η ανάγκη εναρμόνισης των βασικών αρχών και προσεγγίσεων των Επιστημών Υγείας με τις αξίες της συμμετοχικότητας και της διάδρασης. Έτσι, η σύγχρονη αντίληψη για την υγεία, αφορά παρεμβάσεις που λαμβάνουν υπόψη τα μοναδικά χαρακτηριστικά του κάθε ατόμου και στοχεύουν στην εξατομικευμένη παροχή θεραπείας και ολιστικής φροντίδας.

Ταυτόχρονα με τις νέες εξελίξεις, μετασχηματίζεται και ο τομέας της ανάλυσης συναισθήματος. Κατ' εξοχήν, αυτή βασίζεται στη μοντελοποίηση των ανθρώπινων συναισθημάτων μέσω συστηματικών μεθόδων ανάλυσης και ερμηνείας των υποκείμενων βιολογικών μηχανισμών, και των αλληλεπιδράσεων με το περιβάλλον του ανθρώπου. Στις εφαρμογές της Συναισθηματικής Υπολογιστικής Νοημοσύνης (ΣΥΝ), ο βρόχος ανάδρασης από αυτές τις αλληλεπιδράσεις παρέχει σημαντικές πληροφορίες για τη συναισθηματική κατάσταση του ατόμου κι επιτρέπει την προσαρμογή και εξατομίκευση των παρεμβάσεων και υπηρεσιών υγείας, με τη χρήση μηχανισμών επανατροφοδότησης. Η είσοδος της Τεχνητής Νοημοσύνης και η ανάπτυξη μοντέλων μηχανικής και βαθιάς μάθησης που επεξεργάζονται δεδομένα από ιατρικές αναφορές, ψηφιακούς φακέλους υγείας, φορητές συσκευές ανίχνευσης βιοσημάτων, την τηλεϊατρική και το διαδίκτυο των πραγμάτων (IoT), ενισχύει συνολικά την ερευνητική προσπάθεια, αλλά και πιο πρακτικές εφαρμογές στο χώρο των επιστημών υγείας. Με αυτόν τον τρόπο, υποβοηθάται η λήψη ιατρικών αποφάσεων, η παροχή στοχευμένων παρεμβάσεων υγείας, η πρόβλεψη της πιθανότητας εμφάνισης ψυχικών ασθενειών ή κλινικών αποτελεσμάτων, η προώθηση ενός πιο υγιεινού τρόπου ζωής.

Η παρούσα εργασία αφορμάται από τη νέα αυτή κατεύθυνση της ΣΥΝ για την εισαγωγή εξατομίκευσης σε δυναμικά περιβάλλοντα με την αξιοποίηση καινοτόμων τεχνολογιών. Συγκεκριμένα, λειτουργεί ως ένα case study για τη διερεύνηση της ικανότητας αξιοποίησης δεδομένων Μεταβλητότητας Καρδιακού Ρυθμού (ΜΚΡ) στην εκτίμηση των επιπέδων προσήλωσης, αξιολογώντας τη δυνατότητα πρόβλεψης σε πραγματικό χρόνο. Τα δεδομένα αυτά, συλλέχθηκαν κατά τη διεξαγωγή πειράματος το οποίο αφορά το παιχνίδι σοβαρού σκοπού “Express Cooking Train” για την προώθηση υγιεινών διατροφικών συνηθειών και πραγματοποιήθηκε στο Εθνικό Μετσόβιο Πολυτεχνείο. Κατά τη διάρκεια του παιχνιδιού καταγράφηκαν δεδομένα σχετικά με τη

ΜΚΡ του κάθε συμμετέχοντα, καθώς και η καταγραφή, με τη μορφή αυτοαναφοράς, για τα επίπεδα προσήλωσής του.

1.2 Στόχος διπλωματικής εργασίας

Η παρούσα διπλωματική εργασία αποσκοπεί στην μελέτη της συσχέτισης της προσήλωσης και των δεδομένων καρδιακού ρυθμού των συμμετεχόντων της προαναφερθείσας πειραματικής διαδικασίας, κατά διάρκεια αλληλεπίδρασής τους με το παιχνίδι σοβαρού σκοπού για την υγεία. Πιο συγκεκριμένα, η εργασία καταπιάνεται, σε πρώτο χρόνο, με μία βιβλιογραφική ανασκόπηση σχετικά με τις δυνατότητες αξιοποίησης της Συναισθηματικής Υπολογιστικής Νοημοσύνης (ΣΥΝ) στον σχεδιασμό συστημάτων δυναμικής ανατροφοδότησης για Παιχνίδια Σοβαρού Σκοπού (ΠΣΣ) μέσω της χρήσης δεδομένων Μεταβλητότητας Καρδιακού Ρυθμού (ΜΚΡ). Σε δεύτερο επίπεδο, η μελέτη εστιάζει στην ανάπτυξη μοντέλου βαθιάς μάθησης, ως μίας από τις δημοφιλέστερες προσεγγίσεις για την ανάλυση δεδομένων χρονοσειρών στο πεδίο της αναγνώρισης συναισθήματος. Επιδιώκεται μία ενδελεχής ανάλυση πάνω στα ευρήματα που προκύπτουν από την διαδικασία εκπαίδευσης και αξιολόγησης του μοντέλου, καθώς και η εξαγωγή συνολικών συμπερασμάτων που αφορούν αφενός την ικανότητά του να προβλέπει τα επίπεδα προσήλωσης και αφετέρου μία συγκεντρωτική εικόνα για το σύνολο των προκλήσεων που παρουσιάζονται στο τεχνικό κομμάτι της εργασίας.

Ο βασικός σκοπός της Διπλωματικής Εργασίας είναι να επεκτείνει την υπάρχουσα γνώση που αφορά τη χρήση βιοσημάτων και συγκεκριμένα των δεδομένων καρδιακού ρυθμού για την αναγνώριση των επιπέδων προσήλωσης των χρηστών σε δυναμικά περιβάλλοντα ΠΣΣ. Επιδιώκει να εμπλουτίσει τα ευρήματα προηγούμενων εργασιών, οι οποίες βασίστηκαν σε απλούστερους αλγορίθμους μηχανικής μάθησης, μέσω της εφαρμογής πιο πολύπλοκων μοντέλων βαθιάς μάθησης. Στο πλαίσιο αυτό, εξετάζεται η ακρίβεια, η απόδοση και η γενική δυνατότητα του προτεινόμενου μοντέλου να αναγνωρίζει με αξιοπιστία τα επίπεδα προσήλωσης των συμμετεχόντων με βάση δεδομένα ΜΚΡ. Τέλος, λειτουργεί ως σημείο αναφοράς για μελλοντικές εξελίξεις και προεκτάσεις του παρόντος εγχειρήματος.

1.3 Οργάνωση διπλωματικής εργασίας

Η παρούσα διπλωματική εργασία οργανώνεται σε έξι βασικούς άξονες. Το πρώτο κομμάτι αφορά το θεωρητικό υπόβαθρο των βασικών εννοιών που μελετώνται. Στο δεύτερο, παρουσιάζεται η διαδικασία επεξεργασίας και προετοιμασίας των διαθέσιμων δεδομένων. Στο τρίτο αναλύεται η προτεινόμενη αρχιτεκτονική καθώς και οι παραδοχές και τεχνικές που χρησιμοποιούνται για την εκπαίδευση του μοντέλου βαθιάς μάθησης. Το τέταρτο και το πέμπτο μέρος αφορούν την παρουσίαση των αποτελεσμάτων και τον σχολιασμό τους, αντίστοιχα. Η τελευταία ενότητα αποτελεί μια σύνοψη της συνολικής μελέτης και την παρουσίαση μελλοντικών κατευθύνσεων. Πιο συγκεκριμένα:

- **Κεφάλαιο 2: Θεωρητικό πλαίσιο**
Γίνεται ανασκόπηση στις έννοιες της Συναισθηματικής Υπολογιστικής Νοημοσύνης (ΣΥΝ), των Παιχνιδιών Σοβαρού Σκοπού (ΠΣΣ), της Μεταβλητότητας Καρδιακού Ρυθμού (ΜΚΡ) και της προσήλωσης
- **Κεφάλαιο 3: Μεθοδολογία**
Αναλύεται δομή των διαθέσιμων δεδομένων και η διαδικασία προεπεξεργασίας τους.
- **Κεφάλαιο 4: Προτεινόμενο μοντέλο βαθιάς μάθησης**
Περιγράφεται το μοντέλο βαθιάς μάθησης και οι μέθοδοι αξιολόγησης που χρησιμοποιήθηκαν.
- **Κεφάλαιο 5: Αποτελέσματα**
Παρουσιάζονται τα αποτελέσματα των πειραμάτων που διενεργήθηκαν.
- **Κεφάλαιο 6: Συζήτηση και συμπεράσματα**
Συζητούνται τα ευρήματα της έρευνας και οι προκλήσεις που προέκυψαν.
- **Κεφάλαιο 7: Επίλογος**
Παρουσιάζεται η σύνοψη της Διπλωματικής Εργασίας και προτάσεις για μελλοντική έρευνα.

2. Θεωρητικό πλαίσιο

2.1 Ανθρώπινο συναίσθημα ως αντικείμενο έρευνας

Το κεφάλαιο αυτό προσπαθεί να διερευνήσει τη σημασία της έρευνας σχετικά με το ανθρώπινο συναίσθημα ως μιας συνοπτικής σκιαγράφησης των μηχανισμών που το διέπουν καθώς και της ενσωμάτωσης των επιστημονικών ευρημάτων που προκύπτουν από τη μελέτη του, στην κοινωνική ζωή. Η προσέγγιση αυτή, επιδιώκεται μέσα από το πρίσμα της Συναισθηματικής Υπολογιστικής Νοημοσύνης, της Επιστήμης των Υπολογιστών και της Τεχνητής Νοημοσύνης. Παράλληλα με την παρουσίαση ορισμένων βασικών σημείων για την ιστορική σημασία της σχέσης μηχανής – ανθρώπινου συναισθήματος, γίνεται μια προσπάθεια προσέγγισης της πορείας αυτής της σχέσης στο χρόνο, από την ανάδυση των θεωρητικών μοντέλων περιγραφής, ερμηνείας και ποσοτικοποίησής του ανθρώπινου συναισθήματος με υπολογιστικές μεθόδους, έως τις σύγχρονες εξελίξεις της κατασκευής μοντέλων Τεχνητής Νοημοσύνης για την πρόβλεψη, ανάλυση και προσομοίωση συναισθηματικών καταστάσεων.


2.1.1 Θεωρητικά μοντέλα συναισθήματος

Το ανθρώπινο συναίσθημα μπορεί να θεωρηθεί ως ένας σύνθετος μηχανισμός που περιλαμβάνει πολλές διαφορετικές συνιστώσες όπως η βιωμένη εμπειρία, οι γνωστικές διεργασίες και οι ψυχοφυσιολογικές μεταβολές. Επηρεάζει σημαντικά την έκφραση και τη συμπεριφορά του ανθρώπου, την ψυχική του υγεία, την κοινωνική του αλληλεπίδραση, τις σκέψεις και τον τρόπο που αντιλαμβάνεται τον εαυτό του και το περιβάλλον του [1]. Τα συναισθήματα έχουν μεταβλητό και πολυσύνθετο χαρακτήρα και διαφοροποιούνται ανάμεσα στις διάφορες κοινωνικές, πολιτισμικές και πολιτικές ομάδες [2]. Επομένως, η φύση και η σημασία του ανθρώπινου συναισθήματος αποτελεί συνεχές αντικείμενο ανάλυσης και συζήτησης σε πολυάριθμα ακαδημαϊκά πεδία, όπως η Ψυχολογία, η Βιολογία, η Ιατρική, η Ιστορία, η Κοινωνιολογία, η Επιστήμη των υπολογιστών και η Τεχνητή Νοημοσύνη. Η επιστημονική κοινότητα δεν έχει υιοθετήσει καθολικά κάποιον επίσημο ορισμό για το ανθρώπινο συναίσθημα και υπάρχει πληθώρα θεωριών που το προσεγγίζουν και το μελετούν. Ταυτόχρονα, δεδομένου ότι τα συναισθήματα είναι δυναμικές ψυχοφυσιολογικές διεργασίες που συμβαίνουν μη λεκτικά [3], η αναγνώριση τους καθίσταται ιδιαίτερα σύνθετη .

Σημαντικός αλλά και απαιτητικός, λοιπόν, στόχος αποτελεί η κατανόηση και αναγνώριση του ανθρώπινου συναισθήματος, αφού αφορά σε πληθώρα πτυχών της καθημερινής και κοινωνικής ζωής του ατόμου, αλλά και μιας τεχνολογικής εξέλιξης εναρμονισμένης με τις ανθρώπινες ανάγκες και αξίες. Στο πλαίσιο αυτό, στην πορεία της ιστορικής εξέλιξης της επιστήμης, έχει παρατηρηθεί εκτενής προσπάθεια της επιστημονικής κοινότητας να αντιμετωπίσει συστηματικά αυτό το πρόβλημα, σύμφωνα με τις νέες μεθόδους και προκλήσεις που ανακύπτουν. Συνεπώς, στην έρευνα σχετικά με το ανθρώπινο συναίσθημα καθοριστική πρόκληση αποτελεί η ανάπτυξη μοντέλων για τον προσδιορισμό των συναισθημάτων, τις διαστάσεις που τα διέπουν και μεθόδους για την ποσοτικοποίησή τους. Η δημιουργία τέτοιων μοντέλων αποτελεί σημαντική πτυχή της εξέλιξης

στην ανάλυση του συναισθήματος, διότι επιτρέπει ακριβέστερες εκτιμήσεις των συναισθηματικών καταστάσεων.

Μία από τις κυρίαρχες θεωρητικές προσεγγίσεις πάνω στις οποίες θα βασιστούν μοντέλα αναγνώρισης συναισθήματος, θεωρεί το συναίσθημα ως διακριτές, θεμελιώδεις καταστάσεις όπως η χαρά, η έκπληξη, η θλίψη, ο θυμός κ.ά. Το μοντέλο αυτό αναφέρεται ως το κατηγορικό μοντέλο συναισθημάτων και προτάθηκε από τον P. Ekman, το 1992. Από την άλλη, σύμφωνα με τις διαστασιακές προσεγγίσεις, τα συναισθήματα μπορούν να αναπαρασταθούν με έναν μικρό αριθμό συνεχών διαστάσεων, όπου η μία διάσταση αντιπροσωπεύει το επίπεδο "ενεργοποίησης" ή "διέγερσης" και η δεύτερη την "τιμή σθένους", θετική ή αρνητική, του συναισθήματος [4].



Εικόνα 1: Russell's Circumplex Model of Emotions


Διαφορετικά μοντέλα συναισθημάτων τα οποία έχουν προταθεί, συμπεριλαμβανομένων των προσαρμοστικών, της αξιολόγησης, των κονστρουκτιβιστικών και των μοντέλων που βασίζονται στα κίνητρα, αξιοποιούν και περιγράφουν συγκεκριμένες συναισθηματικές καταστάσεις, ωστόσο μπορούν να λειτουργήσουν και συμπληρωματικά. Για παράδειγμα, η διέγερση και το σθένος στο διαστατικό χώρο μπορούν να αναπαρασταθούν ως διακριτά συναισθήματα [7].

2.1.2 Συναισθηματική υπολογιστική και νοημοσύνη

Σύμφωνα με βιβλιογραφικές αναφορές, οι μέθοδοι αναγνώρισης συναισθήματος μπορούν να ταξινομηθούν σε δύο βασικές κατηγορίες. Μεθόδους που βασίζονται σε τεχνικές αυτοαξιολόγησης, για παράδειγμα με τη μορφή ερωτηματολογίων και σε αυτοματοποιημένες υπολογιστικές τεχνικές αξιολόγησης που βασίζονται σε μετρήσεις διαφόρων παραμέτρων που σχετίζονται με το ανθρώπινο σώμα [6]. Στο παρελθόν, στην έρευνα της ανάλυσης των συναισθημάτων, σημαντικό ρόλο διαδραμάτισε τόσο η επιστημονική γνώση όσο και η εμπειρία του ειδικού. Ωστόσο, επειδή η εξαγωγή συμπερασμάτων από υποκειμενικές αναφορές εισαγάγει μεγάλο βαθμό μεροληψίας, αυξάνει την πιθανότητα σφάλματος. Επιπλέον, η αναγνώριση των συναισθημάτων είναι μια δυναμική διαδικασία που διαφοροποιείται για κάθε άτομο [7]. Ακόμη, δεδομένου ότι η υποκειμενική αναφορά, ως μέθοδος αυτοαξιολόγησης ή ως ανάλυση του ειδικού, παραβλέπει τους σύνθετους νευροβιολογικούς μηχανισμούς που καθορίζουν τη συναισθηματική έκφραση, για την

ακριβέστερη εκτίμηση της ανθρώπινης συναισθηματικής κατάστασης σημαντικός αναδεικνύεται και ο ρόλος της μηχανής. Έτσι, παράλληλα με τις επιστημονικές και τεχνολογικές εξελίξεις που πραγματοποιούνται ήδη από τα τέλη του προηγούμενου αιώνα, δίνεται η δυνατότητα, πέρα από τις κλασσικές μεθόδους αναγνώρισης του συναισθήματος, να αναπτυχθούν νέα υπολογιστικά μοντέλα βασισμένα στην Επιστήμη των Υπολογιστών και πλέον την Τεχνητή Νοημοσύνη.

Το 1985, η Rosalind W. Picard, επινοεί τον όρο *affective computing* ως μίας "υπολογιστικής μεθόδου που σχετίζεται με τα συναισθήματα, προκύπτει από αυτά ή τα επηρεάζει σκοπίμως". Λίγα χρόνια αργότερα, η ίδια αναφέρει ότι "η συναισθηματική υπολογιστική νοημοσύνη (ΣΥΝ) ήταν ένας τομέας έρευνας που δημιουργήθηκε για να προσδώσει στην τεχνολογία τις δεξιότητες της συναισθηματικής νοημοσύνης. Για παράδειγμα, ένας υπολογιστής μπορεί να διδαχθεί πώς να διακρίνει αν το άτομο με το οποίο αλληλεπιδρά βαριέται, είναι ταραγμένο ή χαλαρό" [8]. Γενικότερα, η ΣΥΝ έχει υιοθετήσει έννοιες από πολλούς ανεξάρτητους αλλά ταυτόχρονα αλληλοεξαρτώμενους ερευνητικούς τομείς, όπως η ψυχολογία, η κοινωνιολογία, τα μαθηματικά, η εκπαίδευση, η επιστήμη των υπολογιστών, οι οποίοι συμβάλλουν από κοινού στην ανάπτυξή της [1].



Εικόνα 2: Εφαρμογές της Συναισθηματικής Υπολογιστικής Νοημοσύνης

Η ΣΥΝ περιλαμβάνει δύο βασικούς άξονες: την αναγνώριση συναισθημάτων και την ανάλυση συναισθήματος. Από τη μία, η αναγνώριση συναισθήματος στοχεύει στην ανίχνευση της συναισθηματικής κατάστασης των ανθρώπων και αξιοποιεί συνήθως το διαστατικό ή το διακριτό μοντέλο συναισθημάτων. Βασίζεται κυρίως στην αναγνώριση συναισθημάτων μέσω οπτικών δεδομένων (VER), μέσω ήχου/ομιλίας (AER/SER) και μέσω φυσιολογικών σημάτων (PER). Από την άλλη, η ανάλυση συναισθήματος επικεντρώνεται κυρίως σε αξιολογήσεις δεδομένων που προέρχονται από γραπτό λόγο, όπως κείμενα και συνομιλίες και στην εξόρυξη δεδομένων που προέρχονται από προσωπικές προτιμήσεις χρηστών στα κοινωνικά δίκτυα, καμπάνιες μάρκετινγκ και αξιολογήσεις προϊόντων. Η πρόβλεψη στην ανάλυση συναισθήματος κατηγοριοποιείται συνήθως ως θετική, αρνητική ή ουδέτερη. Σε αντιστοιχία με τα διαφορετικά μοντέλα ταξινόμησης

συναισθημάτων, η αναγνώριση συναισθημάτων και η ανάλυση συναισθήματος μπορούν να συσχετίζονται [9].

Γίνεται άμεσα φανερό το γεγονός ότι υπό το πρίσμα της ΣΥΝ, οι ήδη υπάρχουσες θεωρίες των συναισθημάτων βρήκαν πρόσφορο έδαφος για να αναπτυχθούν και να αποτελέσουν χρήσιμα εργαλεία για τα νέα υπολογιστικά μοντέλα. Συγκεκριμένα, τα δύο βασικά μοντέλα ταξινόμησης συναισθημάτων, το διακριτό και το διαστατικό, χρησιμοποιούνται κατά κόρον από τους ερευνητές της ΣΥΝ. Ωστόσο, έχει παρατηρηθεί, ότι η διακριτή θεώρηση των συναισθημάτων, εισαγάγει μεγάλο βαθμό μεροληψίας (bias) στα υπολογιστικά μοντέλα που χρησιμοποιούνται και δυσχεραίνει την ερμηνεία περιορισμένων συνόλων συναισθημάτων [1]. Επιπλέον, σε αντίθεση με τον άνθρωπο, που αντιλαμβάνεται τα οπτικά και ακουστικά ερεθίσματα διαισθητικά, για τα μοντέλα μηχανικής μάθησης, τα υποκειμενικά χαρακτηριστικά που διέπουν αυτές τις συναισθηματικές εκφράσεις, τις καθιστούν δύσκολες ως προς την επίλυση προβλήματος. Το γεγονός αυτό οφείλεται στο ότι χαρακτηρίζονται από έντονα μεταβαλλόμενες, ως προς την είσοδο, συναρτήσεις, αλλά και από υψηλή διαστατικότητα ως αρχείων εικόνων και ήχου [6]. Ως εκ τούτου, η διαστατική θεώρηση, η οποία χρησιμοποιεί τον διδιάστατο χώρο για την επισήμανση των σχετικών συναισθηματικών καταστάσεων, χρησιμοποιείται ως επί το πλείστον στην ανάλυση συναισθημάτων στο χώρο της ΣΥΝ [4]. Στην πράξη, δεν έχει υιοθετηθεί καθολικά μία συγκεκριμένη μέθοδος. Αντίθετα, ο τύπος των επισημάνσεων των συναισθημάτων που είναι διαθέσιμος στις βάσεις δεδομένων καθορίζει τη μέθοδο που θα ακολουθηθεί, ώστε να συνάδει με τα διαθέσιμα δεδομένα: κατηγορικός εαν υπάρχουν εικόνες ή ακολουθίες, οι οποίες πρέπει να αντιστοιχιστούν με μία μόνο συναισθηματική κατάσταση και διαστατικός για συνεχή πρόβλεψη συναισθημάτων [3]. Επίσης, η μεθοδολογία που ακολουθείται βασίζεται εκτός από το είδος των δεδομένων που λήφθηκαν για την αξιολόγηση των συναισθημάτων και στις μεθόδους που χρησιμοποιήθηκαν για την ανάλυσή τους.


Όσον αφορά τη συλλογή των συναισθηματικών δεδομένων που χρησιμοποιούνται για την πρόβλεψη συναισθημάτων, οι παραδοσιακές προσεγγίσεις, όπως αναφέρθηκε προηγουμένως, στηρίχθηκαν κυρίως σε χειροποίητα χαρακτηριστικά (handcrafted features) και μαθηματικά μοντέλα βασισμένα σε κανόνες, τα οποία δυσκολεύονταν να συλλάβουν τη λεπτή και πολύπλοκη φύση των ανθρώπινων συναισθημάτων. Τις τελευταίες δεκαετίες, ταυτόχρονα με τη ραγδαία εξέλιξη της Τεχνητής Νοημοσύνης ξαναέρχεται στο προσκήνιο το ερώτημα σχετικά με το βαθμό στον οποίο μπορεί η μηχανή να αναγνωρίσει και να αποκριθεί στην συναισθηματική κατάσταση ενός ανθρώπου. Αναδύεται, έτσι, η τεχνητή συναισθηματική νοημοσύνη (Artificial Emotional Intelligence), η οποία αποτελεί ένα σημαντικό πεδίο έρευνας για την ανάπτυξη συστημάτων που μπορούν αυτόματα όχι μόνο να αναγνωρίζουν και να μοντελοποιούν αλλά και να εκφράζουν και να προσομοιώνουν συναισθήματα [8]. Τα συστήματα τεχνητής συναισθηματικής νοημοσύνης, αποσκοπούν στην παροχή φυσικής αλληλεπίδρασης μεταξύ ανθρώπου και υπολογιστή [1]. Η τεχνητή συναισθηματική νοημοσύνη ενσωματώνει διάφορες τεχνικές και προσεγγίσεις που αξιοποιούν τα συλλεγμένα και αναλυμένα δεδομένα για την ανίχνευση συναισθημάτων με πολλαπλούς τρόπους, μιμούμενη την ανθρώπινη αντίληψη [10]. Στο πεδίο της τεχνητής συναισθηματικής νοημοσύνης, έχουν αναπτυχθεί τεχνικές όπως αλγόριθμοι επεξεργασίας φυσικής γλώσσας (Natural Language Processing – NLP), υπολογιστικής όρασης (Computer Vision) και τεχνητών νευρωνικών δικτύων (ANN) για την ερμηνεία και την πρόβλεψη συναισθημάτων. Οι τεχνικές μηχανικής και βαθιάς μάθησης επιτρέπουν την αυτόματη εξαγωγή σύνθετων μοτίβων και χαρακτηριστικών από δεδομένα, όπως τις εκφράσεις του προσώπου, την προσωδία της φωνής (π.χ.

τόνος, τονισμός και μοτίβο) και τα φυσιολογικά σήματα. Η βαθιά μάθηση, ιδίως τα συνελκτικά νευρωνικά δίκτυα (CNN) και τα αναδρομικά νευρωνικά δίκτυα (RNN), υπερέχουν στην εκμάθηση ιεραρχικών αναπαραστάσεων και χρονικών εξαρτήσεων εντός των δεδομένων, επιτρέποντας την ακριβέστερη αναγνώριση συναισθημάτων [10, 11], με δυνατότητα γενίκευσης (generalization) σε διαφορετικές περιπτώσεις συναισθημάτων. Επιπλέον, τα τελευταία χρόνια, σημαντική συνεισφορά στην προώθηση της τεχνητής αναγνώρισης συναισθήματος αποτελεί και η συνεχής αύξηση των διαθέσιμων βάσεων δεδομένων αλλά και οι ισχυρότεροι υπολογιστικοί πόροι.

Στα υπάρχοντα μοντέλα μηχανικής και βαθιάς μάθησης, οι μέθοδοι συλλογής δεδομένων βασίζονται στο γεγονός ότι ανθρώπινη συναισθηματική έκφραση μπορεί να γίνει αντιληπτή τόσο σε νευροβιολογικό όσο και σε συμπεριφορικό επίπεδο. Έτσι, μέσω της συλλογής και ανάλυσης δεδομένων έκφρασης και δεδομένων από αισθητήρες βιοσημάτων, μπορεί να αποκαλυφθεί η σχέση μεταξύ συμπεριφοράς και νευροφυσιολογικής δραστηριότητας και να κατασκευαστούν μοντέλα που χαρτογραφούν το συναίσθημα, τη συμπεριφορά και την εγκεφαλική δραστηριότητα. Ως εκ τούτου, όπως αναφέρθηκε παραπάνω, η αναγνώριση συναισθημάτων μπορεί να βασίζεται σε εικόνες, φωνή, κείμενο αλλά και διάφορα, εύκολα συλλεγόμενα, φυσιολογικά σήματα (π.χ. δερματική αντίσταση, μεταβλητότητα καρδιακού ρυθμού και αρτηριακή πίεση) [10].

Σε ερευνητικό επίπεδο παρατηρείται ότι οι δημοφιλέστερες μέθοδοι για την αναγνώριση συναισθήματος βασίζονται σε συμπεριφορικά δεδομένα, όπως οι εκφράσεις του προσώπου, το κείμενο, η φωνή, οι χειρονομίες και η στάση του σώματος ενός ανθρώπου, τα οποία μπορούν εύκολα να συλλεχθούν. Το γεγονός όμως η αξιοπιστία των πληροφοριών που προέρχονται από συμπεριφορικά δεδομένα εξαρτάται σε μεγάλο βαθμό από το κοινωνικό περιβάλλον, το πολιτισμικό υπόβαθρο, καθώς και από την προσωπικότητα των συμμετεχόντων, εισαγάγει μεγάλο βαθμό μεροληψίας. Από την άλλη, οι μεταβολές στα φυσιολογικά σήματα αντικατοπτρίζουν άμεσα τις αλλαγές στα ανθρώπινα συναισθήματα, γεγονός που μπορεί να συμβάλλει στην αναγνώριση, ερμηνεία και προσομείωση συναισθηματικών καταστάσεων [9].

Τα τελευταία χρόνια, σημαντικός αριθμός ερευνητικών προσπαθειών που ασχολείται με τα συστήματα αναγνώρισης συναισθήματος (ERS), έχει στραφεί σε μη επεμβατικές μεθόδους συλλογής δεδομένων, όπως το ηλεκτροεγκεφαλογράφημα (EEG), το ηλεκτροκαρδιογράφημα (ECG), η ηλεκτροδερμική δραστηριότητα (EDA), η φωτοπληθυσμογραφία (PPG) [13]. Κάτι τέτοιο επιτυγχάνεται μέσω φορητών συσκευών και συσκευών χαμηλού κόστους, αποδίδοντας πολλά υποσχόμενα ευρήματα στη συναισθηματική υπολογιστική [14]. Ακόμη, ένα πλεονέκτημα που προσφέρουν τα φυσιολογικά σήματα, αποτελεί το γεγονός ότι παρέχουν πληροφορίες σχετικά με υποκείμενες μεταβολές του συναισθήματος που δεν γίνονται άμεσα εμφανείς σε συμπεριφορικές εκφράσεις, με αμεσότητα και δυνατότητα ανάλυσης για αρκετά μικρά χρονικά παράθυρα παρατήρησης [15].



Εικόνα 3: Δεδομένα εισόδου για συστήματα αναγνώρισης συναισθήματος [16]

2.1.3 Τεχνικές βαθιάς μάθησης για την πρόβλεψη συναισθήματος

Η αναγνώριση συναισθηματικών καταστάσεων βασίζεται σε δύο τύπους δεδομένων: αυτοαναφορικούς, σχετικούς με το ίδιο το άτομο (γνωστικούς και συναισθηματικούς) και εξωτερικούς παρατηρήσιμους παράγοντες, όπως οι αντιληπτές εκφράσεις του προσώπου, η στάση του σώματος, η ομιλία και οι κινήσεις. Μεθοδολογικά, όπως συνηθίζεται σε πολλές εφαρμογές τεχνητής συναισθηματικής νοημοσύνης, η μελέτη των συναισθημάτων και ειδικότερα της προσήλωσης απαιτεί τη συγκέντρωση δεδομένων που προκύπτουν από ένα συνδυασμό παρατηρήσεων (π.χ. εκφράσεις προσώπου, ομιλία) και δηλωτικών δεδομένων (π.χ. ερωτηματολόγια) [8]. Έτσι, η ποικιλία των δεδομένων που χρησιμοποιείται για το χαρακτηρισμό και την κατηγοριοποίηση των συναισθηματικών δεδομένων που χρησιμοποιούνται ως είσοδοι στα μοντέλα TN, οδηγεί στην ανάγκη σχεδιασμού και υλοποίησης διαφορετικών μεθόδων ανάλυσης του συναισθήματος. Οι περισσότερες από τις προσπάθειες ανίχνευσης συναισθημάτων χρησιμοποιούν δεδομένα με επισημειώσεις ή δεδομένα που προέρχονται από μεθόδους crowdsourcing και τη γλωσσολογία για να εκπαιδεύσουν μοντέλα ανίχνευσης συναισθημάτων. Στην πρόσφατη έρευνα, έχουν χρησιμοποιηθεί προηγμένα μοντέλα βαθιάς μάθησης, όπως μοντέλα ενσωμάτωσης λέξεων, συνελκτικά νευρωνικά δίκτυα και αναδρομικά νευρωνικά δίκτυα για την ταξινόμηση συναισθημάτων. Επιπλέον, έχει επιχειρηθεί και η ανίχνευση της έντασης των συναισθημάτων με τη χρήση επισημειωμένων δεδομένων [17].

Από τις τεχνικές βαθιάς μάθησης, τα τεχνητά νευρωνικά δίκτυα (ANN) αποτελούν μία από τις δημοφιλέστερες επιλογές για την ανάλυση και την επεξεργασία δεδομένων για την αναγνώριση συναισθημάτων. Μία από τις πλέον διαδεδομένες μεθόδους είναι η χρήση Συνελικτικών Νευρωνικών Δικτύων (CNNs), ιδιαίτερα αποτελεσματικά στην επεξεργασία και αναγνώριση προτύπων από οπτικά δεδομένα, όπως εκφράσεις του προσώπου. Επιπλέον, τα Αναδρομικά Νευρωνικά Δίκτυα (RNNs) και ιδιαίτερα τα LSTM (Long Short-Term Memory) είναι ευρέως χρησιμοποιούμενα για την ανάλυση χρονοσειρών σε φωνητικά δεδομένα ή στην επεξεργασία κειμένου, καθώς μπορούν να εντοπίσουν και να αναλύσουν συναισθηματικές αλλαγές πάνω σε διαδοχικά χρονικά παράθυρα παρατήρησης. Τα τελευταία χρόνια, το πεδίο εφαρμογής των ANN έχει διευρυνθεί ακόμη περισσότερο, ειδικότερα όσον αφορά την χρήση τους για την ανάλυση χρονοσειρών από δεδομένα αισθητήρων βιοσημάτων. Συγκεκριμένα, στη βιβλιογραφία συναντώνται μελέτες που χρησιμοποιούν τεχνικές εποπτευόμενης μάθησης όπως CNN, LSTM, Autoencoders αλλά και μη εποπτευόμενης μάθησης όπως τα Deep Belief Networks (DBN).

2.1.4 Εφαρμογές και προκλήσεις στην αναγνώριση συναισθήματος

Στην εποχή του Web 2.0, η αφθονία των δεδομένων (big data) στον ψηφιακό κόσμο έχει ανοίξει νέους δρόμους για τον από κοινού σχεδιασμό, τη συμμετοχή και υλοποίηση νέων τεχνολογιών και υπηρεσιών σε μία παγκόσμια κοινότητα. Σε αυτό το παγκοσμιοποιημένο περιβάλλον, τις τελευταίες δεκαετίες, αναδεικνύεται η σημασία της Τεχνητής Συναισθηματικής Νοημοσύνης, με ολοένα αυξανόμενο ερευνητικό ενδιαφέρον για τις εφαρμογές της, οι οποίες εκτείνονται από τους τομείς της εκπαίδευσης και της υγείας, έως αυτούς της μηχανοκίνησης, της ψυχαγωγίας και της οικονομίας [5]. Εξελίσσεται διαρκώς και αλληλοεπηρεάζεται από την επιστήμη των υπολογιστών και την Τεχνητή Νοημοσύνη σε εφαρμογές πάνω στις υποστηρικτικές τεχνολογίες, τη διεπαφή εγκεφάλου-υπολογιστή, την αλληλεπίδραση ανθρώπου-υπολογιστή, την εικονική και επαυξημένη πραγματικότητα και την ανάπτυξη γνωστικών πρακτόρων και ψηφιακών “βοηθών” που μπορούν να εκδηλώνουν αποδεκτές, σύμφωνα με τα κοινωνικά πρότυπα, συμπεριφορές κατά την αλληλεπίδραση με άλλα συστήματα ή ανθρώπους [7, 9]. Η τεχνητή συναισθηματική νοημοσύνη έχει ως στόχο να δώσει στα συστήματα ή τους έξυπνους πράκτορες την ικανότητα να μαθαίνουν, να αντιλαμβάνονται, να αναγνωρίζουν, να σχεδιάζουν, να σκέφτονται και να ενεργούν. Σαν αποτέλεσμα, η αναγνώριση των συναισθηματικών καταστάσεων σε διαφορετικές περιπτώσεις αλληλεπίδρασης, μπορεί να έχει σημαντικό αντίκτυπο από την ενίσχυση της γνωστικής λειτουργίας του ατόμου στην εκπαίδευση, μία καίρια παρέμβαση υγείας ψυχικής υγείας, ή ένα αποτελεσματικό σύστημα συστάσεων για εφαρμογές που το εύρος και η χρησιμότητά τους εκτείνεται σε διάφορους κοινωνικούς χώρους.

Παρά τη ραγδαία εξέλιξη της ΣΥΝ και την ανάπτυξη της Τεχνητής Συναισθηματικής Νοημοσύνης τις τελευταίες δεκαετίες, τίθενται ορισμένες καίριες προκλήσεις για τα μοντέλα μηχανικής και βαθιάς μάθησης που αναπτύσσονται, οι οποίες προκύπτουν από τα εγγενή χαρακτηριστικά και λειτουργίες των ανθρώπινων συναισθημάτων. Τα συναισθήματα είναι δυναμικοί μηχανισμοί που εκτυλίσσονται και μεταβάλλονται δυναμικά με το χρόνο, επηρεάζονται από τη δυναμική της αλληλεπίδρασης, τη σημασιολογία των λεκτικών εκφράσεων, το περιβάλλον και το κοινωνικό και πολιτισμικό πλαίσιο αλλά και από την προσωπικότητα του ίδιου του ατόμου. Επιπλέον, η εμπειρία μας από τον κόσμο, συμπεριλαμβανομένης τόσο της αντίληψης όσο και της

σύνθεσης ή διέγερσης των συναισθημάτων, είναι εγγενώς πολυτροπική. Σημαντικό παράγοντα αποτελεί, επίσης, η προστασία της ιδιωτικότητας των δεδομένων και η παροχή υψηλής διαφάνειας στις μεθόδους συλλογής και ανάλυσής τους. Συμπερασματικά, η ανάπτυξη μοντέλων αναγνώρισης συναισθήματος καθίσταται ένα πολυσύνθετο πρόβλημα, το οποίο εξαρτάται από πολλούς διαφορετικούς παράγοντες. Έτσι, η ανάλυση συναισθημάτων με βάση πολλαπλές πηγές, η ανάλυση σε πραγματικό χρόνο διατηρώντας τη χρονική αλληλουχία των συναισθηματικών δεδομένων, η ανάλυση με βάση τις συνθήκες και το πλαίσιο των διαθέσιμων δεδομένων και οι υποκειμενικοί παράγοντες αποτελούν πληροφορίες που θα πρέπει να συμπεριλαμβάνονται, όσο είναι δυνατόν, στο σχεδιασμό και ερμηνεία μοντέλων αναγνώρισης συναισθήματος [18].

Τελικά, μπορεί κανείς να συμπεράνει ότι η ΣΥΝ και η Τεχνητή Συναισθηματική Νοημοσύνη παρέχουν πολυάριθμες ερευνητικές ευκαιρίες στο πεδίο της αναγνώρισης συναισθημάτων αλλά ταυτόχρονα και προκλήσεις. Αν και ο άνθρωπος έχει περιορισμένη ικανότητα στην αναγνώριση συναισθημάτων σε σύγκριση με τα υπολογιστικά συστήματα ΤΝ, η ανθρώπινη παρέμβαση αποτελεί, ακόμη, κρίσιμο παράγοντα στην αποτελεσματικότητα αυτών των υπολογιστικών μοντέλων, όσον αφορά την ακρίβεια στην αναγνώριση συναισθημάτων. Το γεγονός αυτό επαναφέρει τον ανοιχτό προβληματισμό σχετικά με την αποτελεσματικότητα της μηχανής στο να αντιλαμβάνεται και να “μιμείται” τις ανθρώπινες συναισθηματικές καταστάσεις και ταυτόχρονα θέτει προκλήσεις για τη μελλοντική έρευνα.


2.2 Παιχνίδια Σοβαρού Σκοπού (Serious Games)

Το παιχνίδι αποτελεί μία σημαντική πτυχή της κοινωνικής ζωής και του ανθρώπινου πολιτισμού. Έχει παρατηρηθεί, ότι οι μηχανισμοί των παιχνιδιών μπορούν να αξιοποιηθούν πέραν της απλής ψυχαγωγίας σε τομείς όπως η εκπαίδευση, η υγειονομική περίθαλψη ή η φυσική κατάσταση [19]. Πάνω σε αυτήν την παρατήρηση θα βασιστεί η δημιουργία των παιχνιδιών σοβαρού σκοπού, παιχνιδιών ιδιαίτερα σχεδιασμένων για να αξιοποιηθούν σε διαφορετικά περιβάλλοντα, στοχεύοντας ετερόκλητες ομάδες ανθρώπων. Στις παρακάτω ενότητες παρουσιάζεται μία θεωρητική πλαισίωση των παιχνιδιών σοβαρού σκοπού, ο ρόλος της ΣΥΝ στην ανάπτυξη και τον σχεδιασμό τους, καθώς και ορισμένες πρακτικές εφαρμογές τους στην υγεία και την εκπαίδευση.

2.2.1 Ορισμός και χαρακτηριστικά

Ένα παιχνίδι σοβαρού σκοπού (ΠΣΣ) ορίζεται ως ένα σύστημα λογισμικού που χαρακτηρίζεται από στοιχεία που αφορούν τα παραδοσιακά παιχνίδια, όχι όμως καθαρά από ψυχαγωγική σκοπιά. Με άλλα λόγια, η ανάπτυξη των παιχνιδιών σοβαρού σκοπού εκμεταλλεύεται και εξερευνά τις δυνατότητες χρήσης παιχνιδιών με στόχους πέρα από την απλή ψυχαγωγία. Σε

γενικές γραμμές, βασικό ρόλο ενός τέτοιου παιχνιδιού αποτελεί η δυνατότητά του να παρακινεί τον παίκτη ώστε να επιτύχει έναν ή περισσότερους στόχους, μέσω κατάλληλων μηχανισμών, μιας ελκυστικής εμπειρίας παιχνιδιού και της χρήσης της κατάλληλης τεχνολογίας αλληλεπίδρασης [20]. Οι στόχοι αυτοί μπορεί να ποικίλουν, από την εκπαίδευση των παικτών, τη βελτίωση συγκεκριμένων πτυχών της κατάρτισης και των δεξιοτήτων τους, μέχρι την ευαισθητοποίησή τους γύρω από διάφορα θέματα, όπως κοινωνικά θέματα και θέματα υγείας [21]. Παράλληλα με την επίτευξη αυτών των στόχων, βασικό ρόλο στην αποτελεσματικότητα των παιχνιδιών σοβαρού σκοπού παίζει η διατήρηση μιας συνολικά αναλλοίωτης εμπειρίας παιχνιδιού (εμπειρίας του παίκτη), με άλλα λόγια η διατήρηση μιας ισορροπίας ανάμεσα στα “σοβαρά” τους χαρακτηριστικά και την ψυχαγωγική πλευρά τους [20], ώστε να καλλιεργείται η αποδοχή των παικτών ως προς το παιχνίδι. Τα είδη, η πολυπλοκότητα και οι πλατφόρμες τους ποικίλλουν σε πολύ μεγάλο βαθμό. Επιπλέον, τόσο η έρευνα όσο και η βιομηχανία των παιχνιδιών σοβαρού σκοπού αναπτύσσονται ραγδαία τα τελευταία χρόνια, με ολοένα αυξανόμενο ενδιαφέρον ως προς τις δυνατότητες και τις εφαρμογές τους.



Εικόνα 4: Δυναμική αλληλεπίδραση των χαρακτηριστικών ΠΣΣ [22]

Τα παιχνίδια σοβαρού σκοπού εμφανίζουν αρκετές φορές πλεονέκτημα έναντι των κλασικών μεθόδων εκπαίδευσης, όπως διαπιστώνεται από έρευνες που έχουν πραγματοποιηθεί [19]. Για παράδειγμα, μπορούν να βελτιώσουν την ακαδημαϊκή επίδοση, την προσήλωση και γενικότερα τη διαδικασία της μάθησης, επιδρώντας στις γνωστικές και συμπεριφορικές διεργασίες [17]. Μερικά από τα βασικά χαρακτηριστικά τους, που τα διαφοροποιούν σε σχέση με τις παραδοσιακές εκπαιδευτικές μεθόδους, είναι πως προωθούν την ενεργητική έναντι της παθητικής μάθησης, ενθαρρύνουν τον παίκτη να αναλάβει κινδύνους “επιτρέποντάς” του να κάνει λάθη και προωθούν την αμοιβαία συνεργασία για την επίλυση ενός κοινού προβλήματος (συνεργατικά ΠΣΣ). Επίσης, παρέχουν διάφορα σενάρια που επιτρέπουν στους εκπαιδευόμενους να αντιμετωπίσουν καταστάσεις προτού συμβούν πραγματικά, αλλά και καταστάσεις που δεν εμπύπτουν στον πραγματικό κόσμο [23]. Συχνά, οι παίκτες είναι πρόθυμοι να επενδύσουν περισσότερο χρόνο και ενέργεια στο παιχνίδι, επειδή το ίδιο το παιχνίδι τους ανταμείβει. Τα ΠΣΣ, διακρίνονται, επίσης, από προσαρμοστικότητα, επιτρέποντας επιπλέον βαθμούς εξατομίκευσης, ώστε να χρησιμοποιούνται αποτελεσματικά από άτομα που παρακολουθούν κάποια θεραπεία και ειδικότερα από άτομα με αναπηρία. Ένα ΠΣΣ μπορεί να αναπροσαρμόζει τη μαθησιακή δραστηριότητα με δυναμικό τρόπο [24]. Έτσι, δίνεται στους παίκτες η ευκαιρία να αξιολογήσουν και να

αμφισβητήσουν οι ίδιοι τις αποφάσεις τους, θέτοντάς τους στο επίκεντρο της εκπαιδευτικής διαδικασίας [20].

2.2.2 ΣΥΝ και ΠΣΣ

Γίνεται ήδη φανερό ότι η ΣΥΝ μπορεί να αποτελέσει ένα ισχυρό εργαλείο στην ανάπτυξη ΠΣΣ. Τα ΠΣΣ παρέχουν μια δυναμική συναισθηματική εμπειρία, η οποία με τη σειρά της θέτει νέες προκλήσεις για την αυτόματη αναγνώρισή των συναισθηματικών καταστάσεων που τη χαρακτηρίζουν. Επιπλέον, η διαδικασία του ηλεκτρονικού παιχνιδιού είναι μια κατεξοχήν συναισθηματική και όχι ορθολογική διαδικασία [25]. Έτσι, με την ενσωμάτωση των μεθόδων της ΣΥΝ στο σχεδιασμό και την ανάπτυξη ΠΣΣ, δίνεται η δυνατότητα δημιουργίας εξατομικευμένων σεναρίων που ανταποκρίνονται δυναμικά στις συναισθηματικές καταστάσεις και συμπεριφορές των παικτών. Η περαιτέρω ανάπτυξη των στρατηγικών σχεδιασμού και υλοποίησης ΠΣΣ που βασίζονται σε υπολογιστικές μεθόδους αντιπροσωπεύεται από τα συστήματα τεχνητής νοημοσύνης. Η τεχνητή νοημοσύνη ως ένας ταχέως εξελισσόμενος τομέας προσφέρει ένα ευρύ φάσμα τεχνικών και μεθόδων, καθεμία από τις οποίες έχει τις δικές της πιθανές εφαρμογές στο πεδίο των ΠΣΣ [26]. Μέσω της χρήσης συναισθηματικών δεδομένων και τεχνικών μηχανικής και βαθιάς μάθησης, τα παιχνίδια αυτά μπορούν να αντιλαμβάνονται, να ερμηνεύουν και να προσαρμόζονται στις συναισθηματικές αντιδράσεις των χρηστών σε πραγματικό χρόνο, προωθώντας βαθύτερα επίπεδα προσήλωσης και βελτιώνοντας την εμπειρία του παιχνιδιού [27].

Το πλαίσιο της ΣΥΝ σε ένα ΠΣΣ μπορεί να εφαρμοστεί με διάφορες μεθόδους: συλλογή και αναγνώριση, επεξεργασία και μετάδοση των συναισθημάτων. Για παράδειγμα, η επεξεργασία και η αναγνώριση των συναισθημάτων μπορεί να γίνει με τη χρήση υπολογιστικών μοντέλων συναισθημάτων [21]. Ωστόσο, τα υπολογιστικά μοντέλα που χρησιμοποιούνται συνήθως στο πλαίσιο της ΣΥΝ συχνά αποδεικνύονται μη κατάλληλα για την ανάπτυξη ΠΣΣ. Μια σειρά από πρόσφατες μελέτες έχουν αποδείξει ότι τα βασικά συναισθήματα που προτείνει το κατηγορικό μοντέλο συναισθημάτων, δεν παίζουν σημαντικό ρόλο στη μάθηση μέσω ενός υπολογιστή. Στις διαδικασίες ηλεκτρονικής μάθησης, πιο συχνά μελετάται ένα υποσύνολο γνωστικών-συναισθηματικών καταστάσεων που είναι πιο χαρακτηριστικές σε αυτό το είδος μάθησης. Αυτές οι συναισθηματικές καταστάσεις είναι ένας συνδυασμός βασικών συναισθημάτων και περιλαμβάνουν τη ροή/προσήλωση, την απογοήτευση, τη σύγχυση και την πλήξη. Για το λόγο αυτό στα ΠΣΣ χρησιμοποιείται, κατά κύριο λόγο, η θεωρία της Ροής που διερευνά τη δυναμική των συναισθηματικών καταστάσεων με την πάροδο του χρόνου κατά τη διάρκεια μαθησιακών δραστηριοτήτων [23]. Έχει παρατηρηθεί πως οι μετρήσεις της προσήλωσης είναι αντικειμενικές, έγκυρες και εύκολα εφαρμόσιμες σε διάφορα πλαίσια και με διαφορετικούς χρήστες. Επιπλέον, αποτελούν σημαντικό εργαλείο στην έρευνα για τα ΠΣΣ [21], διότι επιτρέπει στους ερευνητές να κατανοήσουν ποιες αποφάσεις την προωθούν ή την αναστέλουν. Ειδικότερα, όταν η ενίσχυση της προσήλωσης βασίζεται σε εσωτερικά κίνητρα, όπως η πρόκληση, η περιέργεια και η συνεργασία, είναι πιθανό να διαρκέσει περισσότερο και να βοηθήσει το άτομο να φτάσει στην κατάσταση ροής, κατά την οποία βυθίζεται πλήρως στην εμπειρία του παιχνιδιού [25].

Όσον αφορά την προσομοίωση και τη μετάδοση συναισθημάτων, τα ΠΣΣ αξιοποιούν μηχανισμούς προσαρμοστικότητας και δυναμικής ανατροφοδότησης. Μάλιστα, η αποτελεσματικότητά των ΠΣΣ μπορεί να βελτιωθεί όταν εφαρμόζονται συγκεκριμένοι μηχανισμοί, όπως η παροχή ανατροφοδότησης με εκπαιδευτικό περιεχόμενο, η επιβράβευση και ο μηχανισμός της παιχνιδοποίησης (gamification) [24, 26]. Η χρήση τέτοιων μηχανισμών συνδέεται με επιδράσεις στις συναισθηματικές καταστάσεις, τα κίνητρα και τη συμπεριφορά του παίκτη. Η προσαρμοστικότητα στα ΠΣΣ, έχει δημιουργηθεί ώστε να προσαρμόζει πτυχές του παιχνιδιού με βάση παρατηρήσεις ή εισόδους που προκύπτουν από τον παίκτη και το περιβάλλον του, για παράδειγμα, μέσω της συλλογής και επεξεργασίας πληροφοριών, από την επίδοση, τη συμπεριφορά, τις προσωπικές προτιμήσεις, την εξωτερική πραγματικότητα, αλλά και από βιοσήματα που μπορεί να συλλέγονται κατά τη διάρκεια του παιχνιδιού [29]. Ο τελικός στόχος αυτής της προσαρμοστικότητας είναι η μεγιστοποίηση μιας ή περισσότερων πτυχών της εμπειρίας του παίκτη, με τα παιχνίδια να εστιάζουν συνήθως στην προσήλωση του χρήστη ή και στην αποτελεσματικότητα της μάθησης. Σε σύγκριση με άλλες προσαρμοστικές εκπαιδευτικές τεχνολογίες, τα ΠΣΣ υπερέχουν όσον αφορά την κινητοποίηση και την προσήλωση των χρηστών. Λόγω της φύσης αυτών των παιχνιδιών, οποιαδήποτε πληροφορία σχετικά με τις ενέργειες του παίκτη ή το περιβάλλον του παιχνιδιού είναι άμεσα διαθέσιμη, καθιστώντας εύκολη τη συλλογή και αξιοποίησή της. Αυτά τα παιχνίδια επιτρέπουν, επίσης, μεγάλη ευελιξία όσον αφορά το δημιουργικό τους περιεχόμενο και του κατάλληλου σχεδιασμού, βελτίωσης και δοκιμής του.


Μέσω ενός μηχανισμού δυναμικής δημιουργίας περιεχομένου, ένα ΠΣΣ έχει τη δυνατότητα να προσαρμόζει το περιεχόμενο και τη δυσκολία του, βάσει δεδομένων τα οποία αφορούν την επίδοση, τη συμπεριφορά και τη συναισθηματική κατάσταση των συμμετεχόντων. Τα δεδομένα αυτά μπορεί να συλλέγονται μέσα από ίδιο το παιχνίδι, από την αλληλεπίδραση του χρήστη με το παιχνίδι (π.χ. χρόνους απόκρισης) αλλά και δεδομένων συλλεγμένων από βιοαισθητήρες. Επίσης, ο μηχανισμός αυτός μπορεί να χρησιμοποιεί τα δεδομένα αυτά για την επαλήθευση και βαθμονόμηση των εργασιών του παιχνιδιού και της δυσκολίας τους. Στο κομμάτι του σχεδιασμού και της ανάπτυξης τέτοιων μηχανισμών στα ΠΣΣ χρησιμοποιούνται πολλές διαφορετικές τεχνικές, από απλές μεθόδους περιγραφικής στατιστικής και συσχετίσεις έως αλγορίθμους επιβλεπόμενης μηχανικής μάθησης, όπως Γραμμική Παλινδρόμηση, Δένδρα Αποφάσεων, Naive Bayes, Γενετικοί Αλγόριθμοι [24, 29], Νευρωνικά Δίκτυα [26]. Επιπλέον, η εφαρμογή της TN στην ανάπτυξη ΠΣΣ έχει αρχίσει να εμφανίζεται όλο και περισσότερο σε ερευνητικό πλαίσιο, συμβάλλοντας στη δημιουργία δυναμικά αναπροσαρμόσιμων και εξατομικευμένων ΠΣΣ.

Ακόμη, στο πλαίσιο των ΠΣΣ, έχουν αναπτυχθεί διαφορετικές μέθοδοι μοντελοποίησης των παικτών. Από αυτές, η συναισθηματική μοντελοποίηση, δεν ασχολείται άμεσα με μετρήσεις των επιδόσεων ενός παίκτη, αλλά με φυσιολογικά δεδομένα που συλλέγονται ή συνάγονται μέσω αισθητήρων. Αντλεί κυρίως δεδομένα από την παρακολούθηση των κινήσεων της ίριδας των ματιών, την αναγνώριση της στάσης ή των εκφράσεων του προσώπου, την αναγνώριση φωνής ή ακόμη και παρατηρήσεις που βασίζονται σε μεθόδους crowdsourcing, όπως οι έρευνες γνώμης των παικτών. Συχνά, οι μέθοδοι μοντελοποίησης συναισθημάτων κάνουν χρήση εξωτερικών συσκευών υλικού για την πραγματοποίηση ακριβών μετρήσεων [31]. Σύμφωνα με τη βιβλιογραφία, οι περισσότερες εφαρμογές ΠΣΣ, βασίζονται σε μεθόδους συλλογής δεδομένων όπου τα συναισθήματα καταγράφονται μέσω εκφράσεων του προσώπου, αλλαγές στον τόνο της φωνής ή

τους συνδυασμούς αυτών και μέσω της επεξεργασίας φυσικής γλώσσας (NLP). Ωστόσο, υπάρχουν και αρκετές πρόσφατες μελέτες που ασχολούνται με την αναγνώριση συναισθημάτων μέσω φορητής τεχνολογίας και αισθητήρων βιοσημάτων [4, 25, 28].

2.2.3 Εφαρμογές και προκλήσεις

Τα τελευταία χρόνια, υπάρχει αυξανόμενο ενδιαφέρον για τα παιχνίδια σοβαρού σκοπού στους τομείς της εκπαίδευσης και της υγείας και την αποτελεσματικότητά τους στην προώθηση θετικών αποτελεσμάτων στην μάθηση. Η εκπαίδευση αποτελεί έναν από τους κύριους τομείς ανάπτυξης ΠΣΣ. Σύμφωνα με τη θεωρία της ροής, η αντίληψη της πρόκλησης, η επίτευξη στόχων και η λήψη ανατροφοδότησης σχετικά με την πρόοδο της μάθησης μπορούν να βοηθήσουν τον μαθητή να φτάσει υψηλότερα επίπεδα προσήλωσης και να αποκτήσει αίσθηση ελέγχου της εκπαιδευτικής διαδικασίας, η οποία είναι θεμελιώδης για τη μάθηση [22]. Έτσι, η εκπαιδευτική διαδικασία γίνεται πιο πλούσια και πιο ενδιαφέρουσα μέσα από τα ΠΣΣ [26]. Εκτός από το χώρο της εκπαίδευσης, ορισμένες μελέτες έχουν δείξει ότι τα ΠΣΣ και οι τεχνικές παιχνιδιοποίησης μπορούν να λειτουργήσουν αποτελεσματικά στην προώθηση θετικών αποτελεσμάτων για την υγεία, όπως η βελτίωση της σωματικής δραστηριότητας, η υγιεινή διατροφή [27], καθώς και της ψυχικής υγείας, ενώ συμβάλλουν και στη διαχείριση της κατάθλιψης και του άγχους [33]. Μάλιστα, σε ένα ερευνητικό πρόγραμμα σχετικό με τις διατροφικές συνήθειες, οι ερευνητές κατέληξαν στο συμπέρασμα ότι η χρήση ενός ΠΣΣ, συνέβαλε, εκτός από την ενθάρρυνση της υγιεινής διατροφής και στην ανάπτυξη νέων γνώσεων [22]. Η εγγενής ψυχαγωγία και τα κίνητρα που δημιουργούν τα ΠΣΣ σε συνδυασμό με μία επαρκή ενημέρωση και την συμβολή ειδικών ψυχικής υγείας, δημιουργούν νέες προοπτικές στην βελτίωση των διατροφικών συνηθειών και την πρόληψη της παχυσαρκίας [32, 33].



Εικόνα 5: Γραφική απεικόνιση των βασικότερων περιοχών εφαρμογής ΠΣΣ [23]

Παρ' όλ' αυτά, σε αντίθεση με την εφαρμογή της ΣΥΝ σε τομείς όπως η υγεία, η εφαρμογή της στο χώρο των ΠΣΣ βρίσκεται ακόμη σε πρώιμο στάδιο. Δεδομένου ότι ο υπολογιστής δεν γνωρίζει, αλλά καλείται να προσομοιώσει τις κοινωνικές δεξιότητες, καθίσταται ακόμη πιο δύσκολο έργο η εφαρμογή της συναισθηματικής υπολογιστικής σε ένα παιχνίδι το οποίο πραγματοποιεί αλληλεπίδραση σε πραγματικό χρόνο. Έτσι, η έρευνα στον τομέα της ΣΥΝ για τα ΠΣΣ αποτελεί μία πρόκληση για τον πραγματικό κόσμο. Υπάρχουν αρκετές μεταβλητές και πτυχές των συναισθηματικών μηχανισμών που είναι ακόμη άγνωστες για την επίδρασή τους στις εμπειρίες των παικτών [35]. Επειδή, λοιπόν, η ανάπτυξη παιχνιδιών σοβαρού σκοπού απαιτεί θεωρητική γνώση αυτών των μέχρι τώρα ανεξερεύνητων γνωστικών, συναισθηματικών μηχανισμών και μηχανισμών κινήτρων, απαραίτητων ώστε να επιλεγθούν με επιτυχία για οι κατάλληλες δομές, αρχές και μηχανισμοί που θα χρησιμοποιηθούν [17], συχνά η εφαρμογή της ΣΥΝ στα ΠΣΣ γίνεται επι τούτου με την επιλογή κατάλληλων μεταβλητών οι οποίες εμφανίζουν καλύτερη απόδοση μόνο σε συγκεκριμένα σενάρια του παιχνιδιού. Ένα ακόμη καίριο ερώτημα που τίθεται συχνά από τους ερευνητές είναι το κατά πόσο τα ΠΣΣ είναι ικανά να διατηρήσουν τα επίπεδα προσήλωσης των παικτών κατά τη διάρκεια της χρήσης τους. Για να απαντηθεί αυτό το ερώτημα απαιτούνται σύνθετα πειράματα και μακροπρόθεσμη μελέτη, με τη συμβολή πολλών συμμετεχόντων με διαφορετικά προφίλ, ώστε η προσαρμοστικότητα να συγχρονίζεται με το προφίλ του κάθε συμμετέχοντα [22].

2.3 Μεταβλητότητα καρδιακού ρυθμού

Η μελέτη για την κατανόηση των παραγόντων που τροφοδοτούν αλλά και επηρεάζουν το ανθρώπινο συναίσθημα, επικεντρώνεται τόσο στα εξωτερικά ερεθίσματα, τις μεταβολές των ψυχικών και γνωστικών καταστάσεων, ωστόσο η αλληλένδετη φύση ψυχολογικών – φυσιολογικών μεταβολών καταδεικνύει, επίσης, τη συμμετοχή των βιολογικών μηχανισμών στην διαμόρφωση των συναισθηματικών καταστάσεων. Παρακάτω παρουσιάζεται τόσο μια σύντομη περιγραφή του καρδιακού ρυθμού και των βιολογικών διεργασιών με τις οποίες σχετίζεται, όσο και η πληροφορία που μπορεί να “υποδηλώνει” σχετικά με ποικίλες ψυχοφυσιολογικές καταστάσεις. Στο τέλος της υποενότητας, γίνεται μια προσπάθεια θεωρητικής προσέγγισης της συσχέτισης του καρδιακού ρυθμού με την προσήλωση.

2.3.1 Βιολογικοί μηχανισμοί του καρδιακού ρυθμού

Ο καρδιακός ρυθμός (ΚΡ) ορίζεται ως ο αριθμός των καρδιακών παλμών ανά λεπτό. Οι περιοδικές διακυμάνσεις στο μήκος του διαστήματος μεταξύ δύο διαδοχικών καρδιακών παλμών ενός ατόμου ορίζεται ως η μεταβλητότητα του καρδιακού παλμού (ΜΚΡ). Ένας σύνθετος και συνεχώς μεταβαλλόμενος ΚΡ φανερώνει την ικανότητα ενός οργανισμού να προσαρμόζεται άμεσα και αποτελεσματικά σε περιβαλλοντικές και ψυχικές μεταβολές. Από την άλλη, η μειωμένη ΜΚΡ έχει συσχετιστεί με καρδιαγγειακές παθήσεις αλλά και με διάφορες ψυχικές και γνωστικές διαταραχές [36].

Ο φυσιολογικός μηχανισμός που διέπει την MKP αποτελεί παράδειγμα της άμεσης και ταυτόχρονα πολύπλοκης αλληλεπίδρασης μεταξύ εγκεφαλικής και σωματικής δραστηριότητας. Οι καρδιακοί παλμοί εκκινούν από την διέγερση του φλεβοκομβικού κόμβου. Στη συνέχεια, οι μεταβολές μεταξύ των διαδοχικών παλμών αποτελούν χαρακτηριστική απόκριση στους υποκείμενους φυσιολογικούς μηχανισμούς που συμβάλλουν στην ρύθμιση του ΚΡ, όπως το αυτόνομο νευρικό σύστημα (ΑΝΣ) [13]. Συγκεκριμένα, το ΑΣΝ, το οποίο επηρεάζει τον ΚΡ εντός σύντομων χρονικών διαστημάτων, αποτελείται από δύο διακριτά συστήματα, το συμπαθητικό (ΣΝΣ) και το παρασυμπαθητικό νευρικό σύστημα (ΠΝΣ). Το ΣΝΣ το οποίο είναι υπεύθυνο για τις “άμεσες” αποκρίσεις, κυριαρχεί κατά τη διάρκεια έντονης δραστηριότητας και το αποτέλεσμα της λειτουργίας του αυξάνει τον ΚΡ. Το ΠΝΣ, κυριαρχεί σε ήρεμες καταστάσεις και συνδέεται με μείωση του ΚΡ. Υπό φυσιολογικές συνθήκες, τα δύο συστήματα λειτουργούν συμπληρωματικά για τη ρύθμιση της ισορροπίας στη λειτουργία του ΑΝΣ.

Εκτός από το ΑΝΣ, ένας ακόμη παράγοντας που επηρεάζει τις βραχυπρόθεσμες περιοδικές μεταβολές στον ΚΡ αποτελεί η κυκλική ενεργοποίηση των νευρικών αποδεκτών πίεσης (ΝΑΠ), οι οποίοι ρυθμίζουν τα επίπεδα της αρτηριακής πίεσης. Για παράδειγμα, με την αύξηση της αρτηριακής πίεσης, οι ΝΑΠ ενεργοποιούνται για να μειωθεί ο ΚΡ και να διασταλούν οι αρτηρίες, με στόχο την επαναφορά της αρτηριακής πίεσης στα φυσιολογικά επίπεδα. Όσο συχνότερα ενεργοποιείται αυτός ο μηχανισμός, τόσο συχνότερα προσαρμόζεται ο ΚΡ στις μεταβολές, επηρεάζοντας την MKP. Ο μηχανισμός αυτός συσχετίζεται επίσης με την αλληλεπίδραση ανάμεσα στο κυκλοφορικό και αναπνευστικό σύστημα, οπότε η αναπνοή αποτελεί με τη σειρά της παράγοντα που επηρεάζει την MKP.


Το σύμπλεγμα QRS στο ΗΚΓ αντιπροσωπεύει την έναρξη της αποπόλωσης του καρδιακού μυός και η χρονική διάρκεια από μία κορυφή του κύματος R έως την επόμενη κορυφή R αποτελεί το διάστημα από παλμό σε παλμό (διάστημα RR) ή το χρόνο που μεσολαβεί μεταξύ δύο διαδοχικών καρδιακών παλμών. Το τελευταίο μπορεί να καταγραφεί ως ένα απλό μονοδιάστατο διάνυσμα όπου κάθε εγγραφή αντιπροσωπεύει ένα διάστημα RR του ΗΚΓ [37]. Η MKP μπορεί να ποσοτικοποιηθεί με τη μέτρηση της απόστασης μεταξύ διαδοχικών διαστημάτων RR σε ΗΚΓ διαφορετικών χρονικών παραθύρων, μεταβλητού μήκους και εφαρμόζοντας διαφορετικούς δείκτες χρόνου, συχνότητας και μη γραμμικές μεθόδους. Επειδή καθένα από τα αναφερθέντα συστήματα που εμπλέκονται στην διαμόρφωση της MKP έχουν διαφορετικές χρονικές κλίμακες και συχνότητες, η παρακολούθηση και καταγραφή της καρδιακής λειτουργίας συχνά αδυνατεί να ποσοτικοποιήσει το σύνολο της MKP. Συνήθως οι βραχυπρόθεσμες καταγραφές (short-term HRV analysis), μικρότερες των πέντε λεπτών, παρέχουν σημαντική πληροφορία για την MKP υψηλής συχνότητας, ενώ οι μακροπρόθεσμες καταγραφές (long-term HRV analysis), τουλάχιστον 24 ωρών, είναι χρήσιμες για τις χαμηλές συχνότητες MKP. Αν και οι μακροπρόθεσμες καταγραφές περιέχουν πληροφορίες από πολλά διαφορετικά στιγμιότυπα της MKP και συνεπώς θεωρούνται πιο αξιόπιστες για την πρόβλεψη αποτελεσμάτων υγείας, το ερευνητικό ενδιαφέρον στρέφεται συχνότερα στις βραχυπρόθεσμες καταγραφές. Η ανάλυση MKP σε πολύ μικρά χρονικά διαστήματα (ultra-short-term HRV analysis) μελετά την αξιοπιστία και εγκυρότητα των δεικτών της MKP που υπολογίζονται σε σχέση με χρονικά σύντομες καταγραφές MKP. Μάλιστα, έχει παρατηρηθεί ότι σε παράθυρα τόσο σύντομα όσο των 10-30 δευτερόλεπτων, η δυνατότητα εξαγωγής χαρακτηριστικών είναι εξίσου αξιόπιστη με μεγαλύτερες καταγραφές (>5 λεπτών). Ωστόσο, κάτι τέτοιο αφορά

κυρίως τα χρονικά χαρακτηριστικά της ΜΚΡ και λιγότερο τα χαρακτηριστικά συχνότητας, τα οποία εξάγονται από παράθυρα παρατήρησης μεγαλύτερα του 1 λεπτού [36].

2.3.2 Σημασία και χρήση των δεδομένων ΜΚΡ

Το ΗΚΓ και η φωτοπληθυσμογραφία (PPG) αφορούν δύο φυσιολογικά σήματα που σχετίζονται με την καρδιά, τα οποία συλλέγονται εύκολα από φορητές συσκευές και μπορούν να ωφελήσουν στην ενσωμάτωση της ERS στην καθημερινή ζωή [14] με πολλά υποσχόμενα ευρήματα στη ΣΥΝ. Συγκεκριμένα, δεδομένα βιοαισθητήρων, όπως η PPG για τη μέτρηση του παλμού του όγκου του αίματος, του ΚΡ και της ΜΚΡ, καθιστούν δυνατή την παρακολούθηση της ανθρώπινης κίνησης αλλά και την παρακολούθηση άλλων πτυχών της ανθρώπινης συμπεριφοράς και των συναισθηματικών καταστάσεων. Δεδομένου ότι η ΜΚΡ αποτελεί ένα φυσιολογικό ποσοδείκτη της υγείας και της καθημερινής δραστηριότητας, σημαντική πτυχή αποτελεί η παρακολούθησή της με στόχο την ενίσχυση ενός πιο υγιεινού τρόπου ζωής, με ελαχιστοποίηση της αίσθησης της παρέμβασης. Επιπλέον, ευρήματα ερευνών έχουν δείξει θετικά αποτελέσματα για την ανίχνευση του άγχους [38] και την αναγνώριση συναισθηματικών καταστάσεων με βάση αντίστοιχα δεδομένα που παρέχουν βιοαισθητήρες [4].

Τόσο τα γραμμικά όσο και τα μη γραμμικά χαρακτηριστικά που αφορούν την ΜΚΡ, αποτελούν ένα ισχυρό εργαλείο για την εφαρμογή διαφορετικών μεθόδων που στοχεύουν στην ποσοτικοποίηση και αναπαράσταση των πληροφοριών που εξάγονται από τα σήματα ΚΡ. Με τις μεθόδους ανάλυσης που βασίζονται και σε δείκτες της ΜΚΡ καθίσταται δυνατή η ανάπτυξη συστημάτων παρακολούθησης διαφορετικών ασθενειών για κλινικές εφαρμογές. Με βάση την παρατήρηση ότι μια ασθένεια συσχετίζεται με ένα συγκεκριμένο μοτίβο τιμών δεικτών ΜΚΡ, γίνεται δυνατή η χαρτογράφηση των ασθενειών στο φάσμα των δεικτών ΜΚΡ. Μάλιστα, έχει βρεθεί πως ασθένειες όπως για παράδειγμα η καρδιακή ανεπάρκεια, η κολπική μαρμαρυγή, οι καρδιαγγειακές δυσλειτουργίες, η αρρυθμία, συσχετίζονται σε μεγάλο βαθμό με μεταβολές στον ΚΡ. Προκύπτει, λοιπόν, το συμπέρασμα πως η αυτοματοποιημένη ανάλυση της HRV μπορεί να ενισχύσει τα συστήματα υποστήριξης ιατρικών αποφάσεων για ένα ευρύ φάσμα εφαρμογών. Τα συστήματα αυτά είναι δυνατό να καλύπτουν συγκεκριμένες ιατρικές ανάγκες παρέχοντας αντικειμενικές πληροφορίες που προέρχονται από τη ΜΚΡ. Πιο συγκεκριμένα, τα μοντέλα τεχνητής νοημοσύνης μπορούν να χρησιμοποιηθούν σε πληθώρα εφαρμογών για να εξάγουν αντικειμενικές πληροφορίες. Στη συνέχεια οι πληροφορίες αυτές γίνεται να χρησιμοποιηθούν σε συστήματα υποστήριξης ιατρικών αποφάσεων [37] και τελικά στη βελτίωση της παροχής υγειονομικής περίθαλψης.



Εικόνα 6: Τομείς εφαρμογής της ανάλυσης της MKP [33]

Η ανάλυση MKP μπορεί να παρέχει πρόσθετες, εύκολα προσβάσιμες πληροφορίες σε πραγματικό χρόνο για την παρακολούθηση της εξέλιξης μιας νόσου, τη θεραπευτική ανταπόκριση και την πρόγνωση. Μπορεί να αποδειχθεί πολύτιμο εργαλείο στην παρακολούθηση θεραπειών για ασθένειες όπως ο καρκίνος και ο διαβήτης και για την πρόβλεψη επιληπτικών επεισοδίων. Επιπλέον, ο χαμηλός ρυθμός λήψης δεδομένων του μονοκάναλου ΗΚΓ διευκολύνει την απομακρυσμένη ασύρματη παρακολούθηση του ΚΡ και την αυτόματη ανάλυση της MKP σε πραγματικό χρόνο, γεγονός το οποίο μπορεί να αποτελέσει χρήσιμο εργαλείο για άτομα που ζουν σε απομακρυσμένες περιοχές, ηλικιωμένους, άτομα με δυσκολίες στη μετακίνηση. Στην περίπτωση αυτή, ακόμη ένα πλεονέκτημα αποτελεί η ικανότητα της ανάλυσης MKP να παρακολουθεί ένα ευρύ φάσμα καταστάσεων, οι οποίες δεν είναι όλες αμοιβαία αποκλειόμενες. Για παράδειγμα, είναι δυνατή η ταυτόχρονη παρακολούθηση του ύπνου και η ανίχνευση της κοιλιακής μαρμαρυγής [37].

2.4 Προσήλωση

2.4.1 Μέτρηση της προσήλωσης

Η προσήλωση αφορά συμπεριφορικές, συναισθηματικές και γνωστικές διεργασίες κατά τη διαδικασία της μάθησης. Η συναισθηματική προσήλωση επικεντρώνεται σε καταστάσεις που σχετίζονται με τη συναισθηματική εμπλοκή των ατόμων κατά τη διάρκεια μαθησιακών δραστηριοτήτων, είτε αυτή αφορά θετικά είτε αρνητικά συναισθήματα. Οι θεωρίες των κινήτρων, τονίζουν το ρόλο τόσο των θετικών όσο και των αρνητικών συναισθημάτων, καθώς, η δυναμική των συναισθηματικών καταστάσεων μπορεί να ενισχύσει ή να μειώσει την προσήλωση και να επηρεάσει τη μαθησιακή διαδικασία. Με δεδομένο ότι οι παραδοσιακές μέθοδοι μάθησης και η

μάθηση με τη βοήθεια της τεχνολογίας μοιράζονται παρόμοιους συναισθηματικούς μηχανισμούς, τα ΠΣΣ μπορούν να αποτελέσουν χρήσιμο εργαλείο για την διερεύνηση της σχέσης προσήλωσης – μαθησιακής δραστηριότητας. Επιπλέον, η παρακολούθηση με μη παρεμβατικό τρόπο του γνωστικού φόρτου εργασίας των χρηστών, κατά τη διάρκεια αλληλεπίδρασής τους με τη “Μηχανή”, είναι ζωτικής σημασίας για την αξιολόγηση των επιπέδων προσήλωσής τους. Κάτι τέτοιο μπορεί να ωφελήσει ποικίλες εφαρμογές συμπεριλαμβανομένης της υγείας της διατροφής, της αυτοκίνησης και της Αλληλεπίδρασης Ανθρώπου – Μηχανής και εν τέλει την βελτίωση του τρόπου ζωής [39].

Η γνωστική διάσταση της προσήλωσης περιλαμβάνει τον νοητικό προσανατολισμό και τις γνωστικές προσπάθειες που καταβάλλονται κατά τη διάρκεια των μαθησιακών δραστηριοτήτων, καθώς και τις σκέψεις που προκαλούνται ή την συγκέντρωση. Έχει παρατηρηθεί ότι μπορεί να επηρεάσει θετικά τα κινήτρα και τα μαθησιακά αποτελέσματα. Παρά τις σημαντικές προόδους στην εννοιολόγηση της προσήλωσης, ορισμένες σημαντικές πτυχές στην σχετική έρευνα δεν έχουν ακόμα αναπτυχθεί. Συγκεκριμένα, μέχρι τώρα, οι περισσότεροι ερευνητές χρησιμοποιούσαν αυτοαναφορικές καταγραφές ή παρατηρήσεις για τη μέτρηση της προσήλωσης. Πλεον χρησιμοποιούνται κατά κόρον ψυχοφυσιολογικά δεδομένα, είτε ως μεμονωμένες εισόδοι δεδομένων σε μοντέλα μηχανικής και βαθιάς μάθησης, είτε ως συνδυασμός δεδομένων εισόδου που προέρχονται από πολλαπλές πηγές [40].

Η προσήλωση μπορεί να μετρηθεί από διάφορα συμπεριφορικά χαρακτηριστικά: κινήσεις της ίριδας του ματιού, εκφράσεις του προσώπου, χειρονομίες κ.ο.κ. Επίσης, κεντρικά και περιφερειακά φυσιολογικά σήματα έχουν χρησιμοποιηθεί συχνά για την αναγνώριση της προσήλωσης. Οι περισσότερες από τις προτεινόμενες μεθόδους για τη μέτρηση των φυσιολογικών δεδομένων επιχειρούν να καταγράψουν και να επεξεργαστούν τα ηλεκτρικά σήματα που παράγονται από την καρδιά, τον εγκέφαλο, τους μύες και το δέρμα. Τα κύρια όργανα που χρησιμοποιούνται για την παρακολούθηση των φυσιολογικών σημάτων περιλαμβάνουν το ηλεκτροκαρδιογράφημα (ΗΚΓ), το ηλεκτρομυογράφημα (ΗΜΓ), τη γαλβανική απόκριση του δέρματος (GSR) και την αναπνοή (RSP).

2.4.2 Προσήλωση και MKP

Η MKP αποτελεί έναν βιοδείκτη που μελετάται ευρέως στην ψυχοφυσιολογία και τις νευροεπιστήμες για την ικανότητά του να αντανακλά τη δυναμική αλληλεπίδραση μεταξύ του συμπαθητικού και του παρασυμπαθητικού κλάδου του αυτόνομου νευρικού συστήματος, όπως αναφέρθηκε. Οι διαφορετικοί δείκτες MKP θεωρείται πως σχετίζονται με διαφορετικούς φυσιολογικούς μηχανισμούς. Με βάση το *neurovisceral integration model*, οι νευρώνες που εμπλέκονται στη ρύθμιση των ψυχολογικών διεργασιών, δηλαδή τη συναισθηματική και γνωστική αυτορρύθμιση, σχετίζονται επίσης με τη ρύθμιση της καρδιακής αυτόνομης δραστηριότητας. Η ικανότητα του ΑΝΣ να μεταβάλλει τις φυσιολογικές καταστάσεις και η οποία, όπως αναφέρθηκε παραπάνω, περιγράφεται από διαφορετικούς δείκτες της MKP, συνδέεται με την προσαρμογή μεταξύ καταστάσεων υψηλής και χαμηλής διέγερσης. Ως εκ τούτου, έχει θεωρείται ότι παίζει ρόλο στη ρύθμιση των συναισθηματικών καταστάσεων και των γνωστικών διεργασιών.

Φαίνεται, λοιπόν, ότι μπορεί να υπάρχει συσχέτιση της MKP με τον γνωστικό έλεγχο και τη συναισθηματική ρύθμιση. Για παράδειγμα, σε μελέτες που διερεύνησαν τις συναισθηματικές αντιδράσεις στο άγχος, τα άτομα με υψηλότερο RSA (δείκτης ποσοτικοποίησης της επίδρασης της αναπνοής στην MKP) είχαν χαμηλότερη, αντιληπτή, αρνητική συναισθηματική διέγερση, ενώ βίωναν πιο θετικές διαθέσεις. Αυτή η συσχέτιση θεωρήθηκε ότι οφείλεται στην ικανότητα ρύθμισης των συναισθημάτων, όπως η ικανότητα προγραμματισμού, επαναπροσδιορισμού και επανεκτίμησης. Επίσης, μελέτες που διερεύνησαν τη σχέση μεταξύ της MKP και της λειτουργικότητας ενός ατόμου, έδειξαν ότι συμμετέχοντες με υψηλότερη MKP, με ιδιαίτερα βραχυπρόθεσμες μεταβολές, είχαν καλύτερες επιδόσεις στην διατήρηση της συγκέντρωσης, την μνημονική διαδικασία, την αυτοπειθαρχία και τη γνωστική ευελιξία [36].

Ερευνητικά έχει μελετηθεί η συσχέτιση ορισμένων χαρακτηριστικών της MKP με συναισθηματικές διεργασίες, όπως αυτές περιγράφονται από το διαστατικό μοντέλο συναισθημάτων [14, 33, 35, 37]. Το σθένος, δηλαδή το πόσο θετική ή αρνητική μπορεί να είναι μια συναισθηματική εμπειρία και η διέγερση, δηλαδή η ένταση της συναισθηματικής εμπειρίας σχετίζονται με γνωστικές και συναισθηματικές καταστάσεις όπως η προσήλωση. Προκύπτει, λοιπόν, η παρατήρηση πως η MKP μπορεί να συσχετίζεται με τις μεταβολές της συναισθηματικής και γνωστικής προσήλωσης, καθιστώντας την έναν δυνητικά χρήσιμο παράγοντα πρόβλεψής της.

3. Μεθοδολογία

Η ενότητα αυτή αποτελεί μια αναλυτική καταγραφή τόσο της δομής των διαθέσιμων δεδομένων όσο και των μεθόδων που ακολουθήθηκαν για το προπαρασκευαστικό στάδιο, όσον αφορά το πρακτικό κομμάτι της παρούσας εργασίας. Αρχικά, παρουσιάζεται η πλαισίωση της διαδικασίας συλλογής και καταγραφής των δεδομένων και στη συνέχεια τα στάδια της εκκαθάρισης και προεπεξεργασίας τους, ώστε να έρθουν στη κατάλληλη μορφή για χρησιμοποιηθούν ως είσοδοι στο προτεινόμενο μοντέλο βαθιάς μάθησης. Επίσης, αναλύονται επιλογές που πραγματοποιήθηκαν με βάση το σύνολο των διαθέσιμων δεδομένων και της φύσης του παρόντος προβλήματος αναγνώρισης των επιπέδων προσήλωσης.

3.1 Περιγραφή πειραματικής διάταξης

Η παρούσα εργασία αξιοποιεί δεδομένα τα οποία συλλέχθηκαν με τη βοήθεια αισθητήρων, κατά την εφαρμογή ερευνητικού πειράματος, με στόχο την αναγνώριση επιπέδων προσήλωσης σε πραγματικό χρόνο. Η ερευνητική διαδικασία που πραγματοποιήθηκε περιλαμβάνει δύο βασικές συνιστώσες. Η πρώτη αφορά την συμμετοχή σε παιχνίδι σοβαρού σκοπού, το οποίο αποτελεί παρέμβαση για την υγεία και συγκεκριμένα για τις διατροφικές συνήθειες. Η δεύτερη αφορά την μέτρηση διαφόρων παραμέτρων σχετικών με την φυσιολογική κατάσταση του κάθε συμμετέχοντα κατά τη διάρκεια της πειραματικής διαδικασίας αυτής, καθώς και μετρικές μέσα από το ίδιο το παιχνίδι. Στις παρακάτω υποενότητες παρουσιάζεται το περίγραμμα της διαδικασίας λήψης και καταγραφής των διαθέσιμων δεδομένων, καθώς το πλαίσιο της πειραματικής διάταξης.

3.2.1 ΠΣΣ

Το “Express Cooking Train” [41] αποτελεί ΠΣΣ το οποίο δημιουργήθηκε με στόχο την ενθάρρυνση της υιοθέτησης υγιεινών διατροφικών συνηθειών και μαγειρικών πρακτικών. Οργανώνεται σε διαφορετικές αποστολές όπου ο παίκτης καλείται να “μαγειρέψει εικονικά”, υγιεινά γεύματα για να αντιμετωπίσει τα τέρατα που τον κυνηγούν σε ένα περιβάλλον προσομοίωσης κουζίνας. Η κάθε αποστολή περιλαμβάνει τρία στάδια: το στάδιο εκπαίδευσης και προετοιμασίας, το κυρίως “Gameplay” και ένα επιπλέον στάδιο αξιολόγησης. Υπάρχουν συνολικά τρεις αποστολές από τις οποίες οι δύο τελευταίες είναι προαιρετικές. Το ίδιο το παιχνίδι θέτει τον συμμετέχοντα στο επίκεντρο της διαδικασίας μαγειρέματος, καθώς του δίνει την ευκαιρία να πειραμαστεί δημιουργικά, μειώνοντας την αίσθηση της παρέμβασης. Ως προς τα “σοβαρά” χαρακτηριστικά του, το παιχνίδι ενσωματώνει ένα μηχανισμό δυναμικής παραγωγής περιεχομένου (PCG) και αξιοποιεί τεχνικές ανατροφοδότησης και αναπροσαρμογής που έχουν ως άμεσο στόχο να κινητοποιήσουν το ενδιαφέρον του παίκτη και τελικά να τον ευαισθητοποιήσουν και να ενισχύσουν την επίγνωσή του ως προς έναν πιο υγιεινό τρόπο ζωής. Παράλληλα διερευνώνται οι δυνατότητες της PCG σε προσαρμοστικές παρεμβάσεις ΠΣΣ για χρόνιες ασθένειες [29].

3.2.2 Καταγραφή των επιπέδων προσήλωσης

Η καταγραφή της προσήλωσης κατά τη διάρκεια του παιχνιδιού πραγματοποιήθηκε με τη βοήθεια ενός εργαλείου συνεχούς επισημείωσης (annotation tool) συναισθημάτων, το οποίο βασίστηκε στο αντίστοιχο εργαλείο RankTrace. Το σύστημα καταγραφής χρησιμοποιεί τον τον τροχό του ποντικιού ως φυσικό μέσο που αντιστοιχίζει την την αντιληπτή προσήλωση του παίκτη κατά τη διάρκεια του παιχνιδιού σε ένα συνεχές ίχνος στην οθόνη του υπολογιστή. Συγκεκριμένα, κάθε συμμετέχοντας παρακολουθεί στην οθόνη την καταγραφή του “playthrough” μετά από τη συμμετοχή του στο παιχνίδι και ταυτόχρονα δημιουργεί ένα συνεχές ίχνος επισημειώσεων ανάλογα με την υποκειμενική του αντίληψη για τα επίπεδα προσήλωσής του κατά τη διάρκεια του παιχνιδιού. Τα δεδομένα επισημείωσης της προσήλωσης δειγματοληπτούνται ανά δευτερόλεπτο [29].

3.2.3 Συλλογή δεδομένων από αισθητήρες

Η πειραματική διάταξη που χρησιμοποιήθηκε περιλαμβάνει αισθητήρες που καταγράφουν δεδομένα από διαφορετικές πηγές. Συγκεκριμένα, χρησιμοποιήθηκε μία διάταξη αισθητήρων πίεσης για την αναγνώριση της θέσης του σώματος και αισθητήρας που ανιχνεύει τον καρδιακό ρυθμό. Στην παρούσα εργασία χρησιμοποιήθηκαν ως αρχική πηγή δεδομένων μόνο οι μετρήσεις του αισθητήρα καρδιακού ρυθμού. Εστιάζει, επομένως, στην διερεύνηση της περίπτωσης χρήσης δεδομένων εισόδου από μία μόνο πηγή. Ο αισθητήρας καρδιακού ρυθμού που χρησιμοποιήθηκε είναι ο PulseSensor της World Famous Electronics LLC. Ο PulseSensor αποτελεί έναν χαμηλού κόστους αισθητήρα, ο οποίος ελαχιστοποιεί την αίσθηση της παρέμβασης αφού μπορεί να τοποθετηθεί γύρω από το δάχτυλο ή στο λοβό του αυτιού. Ο αισθητήρας αυτός έχει τη δυνατότητα να ανιχνεύει τους παλμούς μέσω μιας διόδου εκπομπής φωτός που παράγει μια φωτοπληθυσμογραφία (PPG). Η δειγματοληψία για τον αισθητήρα PulseSensor ήταν περίπου 25 Hz [29].

3.2.4 Συμμετέχοντες

Στην πειραματική διαδικασία πήραν μέρος συνολικά 26 συμμετέχοντες, από τους οποίους 19 ήταν άνδρες και 7 γυναίκες, ηλικίας περίπου 26 ετών. 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). Καθώς το ΠΣΣ έχει σχεδιαστεί στα Αγγλικά, όλοι οι συμμετέχοντες είχαν καλή κατανόηση της αγγλικής γλώσσας. Για την διεξαγωγή του πειράματος, ο αισθητήρας παλμού τοποθετήθηκε στο λοβό του αυτιού κάθε συμμετέχοντα για να μην παρεμποδίζει τη διαδικασία του παιχνιδιού. Στην πρώτη αποστολή συμμετείχαν όλοι οι συμμετέχοντες, ενώ στην δεύτερη και τρίτη αποστολή συμμετείχαν 14 και 3 συμμετέχοντες, αντίστοιχα. Μετά το πέρας του παιχνιδιού, δώθηκαν σε κάθε συμμετέχοντα οδηγίες για τη χρήση του εργαλείου επισημείωσης [29].

3.2 Προεπεξεργασία δεδομένων

3.2.1 Δομή και εκκαθάριση δεδομένων

Τόσο τα δεδομένα από τον αισθητήρα καρδιακού ρυθμού όσο και τα δεδομένα επισημειώσεων της προσήλωσης έχουν αποθηκευτεί σε αρχεία `.txt`. Τα αρχεία αυτά οργανώνονται ανά συμμετέχοντα. Όσον αφορά την αντιστοίχιση των δεδομένων, η αρχή του κάθε αρχείου με τις μετρήσεις του καρδιακού ρυθμού συμπίπτει με την αρχή κάθε αντίστοιχου αρχείου επισημειώσεων προσήλωσης. Δηλαδή, η χρονική αλληλουχία των δύο συνόλων δεδομένων εξελίσσεται παράλληλα με το χρόνο του παιχνιδιού, ξεκινώντας από το αρχικό του στάδιο.

3.2.1.1 Εκκαθάριση δεδομένων καρδιακού ρυθμού

Τα αρχικά δεδομένα του καρδιακού ρυθμού οργανώνονται σε στήλες οι οποίες περιέχουν τις εξής μεταβλητές:

- Καρδιακός ρυθμός, οι παλμοί της καρδιάς ανά λεπτό (bpm) – 1η στήλη
- MKP μέτρηση, κανονικά-προς-κανονικά N-N διαστήματα (κανονικοποιημένα R-R διαστήματα) – 2η στήλη
- Ακριβής χρονική στιγμή καταγραφής – 3η στήλη, όπου t είναι το timestamp

65	822376	$t = 2019-07-09\ 14:52:09.009658$
65	822389	$t = 2019-07-09\ 14:52:09.029901$
65	822422	$t = 2019-07-09\ 14:52:09.051091$

Εικόνα 7: Ενδεικτικά δεδομένα από αρχείο μετρήσεων καρδιακού ρυθμού

Πάνω στα δεδομένα είχε ήδη εφαρμοστεί εκκαθάριση όσον αφορά έκτοπες τιμές (outliers) για τα διαστήματα R-R και κενές τιμές. Πραγματοποιήθηκε επιπλέον έλεγχος για την εύρεση NaN τιμών πάνω στα διαθέσιμα δεδομένα, ή τυχόν δεδομένων που βρίσκονταν σε ακατάλληλη μορφή. Συγκεκριμένα, για τα timestamps πραγματοποιήθηκε έλεγχος ότι βρίσκονται σε μορφή *datetime* και δεν βρέθηκε κάποια λανθασμένη τιμή στο σύνολο των δεδομένων. Επίσης δεν βρέθηκαν κενές τιμές. Όσον αφορά την ορθότητα της αλληλουχίας των χρονικών καταγραφών, για έναν συμμετέχοντα παρατηρήθηκε ένα χρονικό “άλμα” στο διάστημα των μετρήσεων. Ως εκ τούτου, επειδή θεωρήθηκε ότι μέθοδοι όπως η συμπλήρωση των κενών δεδομένων με γραμμική παρεμβολή (extrapolation) ή με επανάληψη δεδομένων θα εισήγαγε bias, τα δεδομένα μετά από το διάστημα που παρατηρήθηκε το χρονικό κενό αγνοήθηκαν.

Δεδομένου ότι η δειγματοληψία του αισθητήρα παλμού είναι περίπου 25 Hz ~ 0,04 sec, παρατηρείται ότι κάθε παλμός έχει καταμετρηθεί παραπάνω από μία φορές. Γι' αυτό το λόγο ακολουθήθηκε μέθοδος η οποία “αφαιρεί” τα πλεονάζοντα δεδομένα (duplicates), διατηρώντας τα μοναδικά διαδοχικά N-N διαστήματα. Πιο συγκεκριμένα, η μέθοδος εκκαθάρισης που εφαρμόστηκε αρχικοποιεί μία μεταβλητή χρόνου στη χρονική στιγμή της έναρξης της καταγραφής του αισθητήρα παλμού για τον κάθε συμμετέχοντα, στην οποία αντιστοιχεί το πρώτο καταγεγραμμένο διάστημα N-N. Έπειτα, με βάση αυτή τη μεταβλητή, κάθε N-N διάστημα “επεκτείνεται” μέχρι την επομενη μέτρηση της οποίας η χρονική στιγμή καταγραφής συμπίπτει ή ξεπερνά το N-N διάστημα αυτό. Αυτό επιτυγχάνεται μέσω μιας επαναληπτικής διαδικασίας σύγκρισης των μετρήσεων με το τρέχον timestamp εκφρασμένο σε millisecond (ms), εφόσον τα διαστήματα N-N καταγράφονται σε ms.

Γι' αυτό το σκοπό έχει δημιουργηθεί συνάρτηση `calculate_nn_intervals`, η οποία παίρνει σαν όρισμα ένα πίνακα, με στήλες την τιμή των N-N διαστημάτων, το timestamp και την παραγόμενη από το timestamp στήλη, `time_in_ms`. Η συνάρτηση αυτή επιστρέφει το αρχικό dataframe χωρίς τα διπλότυπα, δηλαδή μόνο με τα πραγματικά N-N διαστήματα και τον αντίστοιχο χρόνο καταγραφής τους, ως timestamp και ως χρόνο σε ms. Το διάβασμα και η επεξεργασία των δεδομένων για τα αρχεία των μετρήσεων γίνεται με τη βοήθεια της βιβλιοθήκης *pandas* της *python*.

3.2.1.2 Εκκαθάριση δεδομένων επισημειώσεων των επιπέδων προσήλωσης

Τα δεδομένα των επισημειώσεων των επιπέδων προσήλωσης οργανώνονται ανάλογα με τα δεδομένα καρδιακού ρυθμού σε στήλες και αποθηκεύεται η τιμή της προσήλωσης και ο αντίστοιχος χρόνος καταγραφής της επισημείωσης.

14 time:	15:38.2
13 time:	15:38.3
8 time:	15:38.4
8 time:	15:38.5

Εικόνα 8: Ενδεικτικά δεδομένα από αρχείο επισημειώσεων επιπέδων προσήλωσης

Η δειγματοληψία των δεδομένων αυτών είναι 1 sec και αποθηκεύονται σειριακά. Μετά από έλεγχο ορθότητας των δεδομένων, δεν βρέθηκε κάποιο σφάλμα.

3.2.2 Προετοιμασία Δεδομένων


Στο στάδιο της προεπεξεργασίας, ο τελικός στόχος είναι να δημιουργηθεί μία δομή δεδομένων στη μορφή που θα χρησιμοποιηθεί για την εκπαίδευση του μοντέλου. Η προετοιμασία των δεδομένων που ακολουθήθηκε για την εκπαίδευση του μοντέλου αποτελείται από τα εξής βήματα:

1. Προεπεξεργασία δεδομένων καρδιακού ρυθμού

2. Χωρισμός των δεδομένων σε χρονικά παράθυρα παρατήρησης.
3. Χρήση επικάλυψης μεταξύ των χρονικών παραθύρων με στόχο των εμπλουτισμό των δεδομένων.
4. Αντιστοίχιση δεδομένων εισόδου – εξόδου.

3.2.2.1 Προεπεξεργασία δεδομένων καρδιακού ρυθμού

Για την εκπαίδευση θα χρησιμοποιηθούν τόσο ακατέργαστες οι ακολουθίες από τα επιλεγμένα διαστήματα N-N όσο και handcrafted features, δηλαδή ορισμένα στατιστικά χαρακτηριστικά της ΜΚΡ στο πεδίο του χρόνου. Η επιλογή αυτή βασίστηκε σε αντίστοιχο πρόβλημα αναγνώρισης συναισθήματος με χρήση δεδομένων από φωτοπληθυσμογραφία [42] και θα τεκμηριωθεί στην *Ενότητα 4* όπου παρουσιάζεται αναλυτικά η δομή του μοντέλου βαθιάς μάθησης και η διαδικασία εξαγωγής χαρακτηριστικών.




Εικόνα 9: Εποπτικό παράδειγμα διαστημάτων N-N από σήμα PPG

Γενικά, ως handcrafted features επιλέγονται χαρακτηριστικά, τα οποία βασίζονται σε στατιστικές πληροφορίες όπως η Μέση Τιμή, η Διακύμανση και το Πλάτος. Η ανάλυση ενός φυσιολογικού σήματος μπορεί να πραγματοποιηθεί σε δύο τομείς: τον τομέα του χρόνου και τον τομέα της συχνότητας. Η μέθοδος που χρησιμοποιήθηκε εξήγαγε τα χαρακτηριστικά στο πεδίο του χρόνου χρησιμοποιώντας τα διαστήματα N-N. Για τον τομέα της συχνότητας, δεν είναι εφικτή η χρήση των διαστημάτων N-N για την αναγνώριση συναισθημάτων σε πολύ μικρά χρονικά διαστήματα, δηλαδή κάτω του ενός λεπτού. Ως εκ τούτου, υπολογίστηκαν και χρησιμοποιήθηκαν μόνο χαρακτηριστικά από το πεδίο του χρόνου.

Η σχέση ανάμεσα στην καρδιακή δραστηριότητα την συναισθηματική διέγερση και σθένος είναι σύνθετη και μπορεί να επηρεάζεται από έναν συνδυασμό παραμέτρων της ΜΚΡ και της λειτουργίας του αυτόνομου νευρικού συστήματος [43]. Με βάση την ανάλυση που πραγματοποιήθηκε από τους Lee et al. [42], παρατηρήθηκε ότι δεν συσχετίζονται όλοι οι δείκτες της ΜΚΡ με το συναίσθημα. Επομένως, τα χαρακτηριστικά που δεν συσχετίζονται με το σθένος και τη διέγερση του συναισθήματος θα μπορούσαν να παρεμποδίσουν την διαδικασία εκπαίδευσης

στην αναγνώριση συναισθημάτων. Γι' αυτό το λόγο, η επιλογή των στατιστικών χαρακτηριστικών MKP για την εκπαίδευση του μοντέλου βαθιάς μάθησης βασίστηκε στον *συντελεστή συσχέτισης Pearson*, ο οποίος μετρά τη γραμμική συσχέτιση μεταξύ δύο μεταβλητών.



Εικόνα 10: Αποτελέσματα συσχέτισης Pearson των MKP - διέγερσης/σθένους [42]

Στην παρούσα εργασία, η αναγνώριση δεν πραγματοποιείται στο διδιάστατο χώρο της διέγερσης – σθένους, αλλά μελετώνται τα επίπεδα προσήλωσης. Ωστόσο, όπως αναφέρθηκε, το διαστατικό μοντέλο συναισθημάτων ορίζει συναισθηματικές καταστάσεις οι οποίες σχετίζονται με τη συναισθηματική και γνωστική προσήλωση. Συγκεκριμένα, καταστάσεις υψηλότερης διέγερσης συνήθως υποδεικνύουν υψηλότερη γνωστική προσήλωση, χωρίς αυτή απαραίτητα να είναι θετική. Για παράδειγμα, μία συναισθηματική κατάσταση υψηλής διέγερσης μπορεί να σχετίζεται με άγχος ή ενθουσιασμό. Αντίστοιχα, ο υψηλός δείκτης σθένους αφορά καταστάσεις υψηλής συναισθηματικής ισορροπίας, όπως χαλάρωσης και ηρεμίας, με αυξημένα επίπεδα προσήλωσης [36].

Μία περιγραφή των ποσοδεικτών MKP στο πεδίο του χρόνου που βρέθηκε ότι επηρεάζουν σημαντικά τα επίπεδα συναισθήματος [42] και αξιοποιήθηκαν στην παρούσα εργασία παρουσιάζεται παρακάτω:

- **MeanNN:**

- Αποτελεί τη μέση τιμή μεταξύ των διαδοχικών καρδιακών παλμών, δηλαδή τη μέση τιμή του συνόλου των N-N διαστημάτων.
- Η αύξηση του καρδιακού ρυθμού και μείωση της MeanNN, συχνά συνδέεται με αυξημένα επίπεδα διέγερσης, αλλά αυτό δεν σχετίζεται άμεσα με τη διάσταση του σθένους της συναισθηματικής κατάστασης. Η ένταση της διέγερσης μπορεί να υποδεικνύει αυξημένη γνωστική λειτουργία και ενεργοποίηση του οργανισμού, χωρίς απαραίτητα να συνεπάγεται θετική συναισθηματική κατάσταση [43].

- **MedianNN:**

- Αποτελεί τη διάμεση τιμή του χρόνου μεταξύ διαδοχικών διαστημάτων N-N.
- Η μετρική αυτή, επίσης, παρέχει πληροφορίες για τη δραστηριότητα του παρασυμπαθητικού νευρικού συστήματος.

- **RMSSD:**

- Αποτελεί την τετραγωνική ρίζα της μέσης τιμής του τετραγώνου διαδοχικών διαφορών μεταξύ των διαδοχικών διαστημάτων N-N.
- Η RMSSD σχετίζεται, επίσης, με την παρασυμπαθητική δραστηριότητα του ANΣ. Οι χαμηλές τιμές RMSSD αφορούν καταστάσεις υψηλής διέγερσης, όπως άγχους ή ενθουσιασμού. Παράλληλα, υψηλότερες τιμές RMSSD αφορούν καταστάσεις ηρεμίας και ισορροπίας του παρασυμπαθητικού νευρικού συστήματος, οι οποίες συμβάλλουν στη ενίσχυση της γνωστικής λειτουργίας [43].

- **SDNN:**

- Αντιπροσωπεύει την τυπική απόκλιση στο σύνολο των διαστημάτων N-N και εκφράζεται σε ms.
- Η SDNN θεωρείται ένας καθολικός ποσοδείκτης της MKP και σχετίζεται τόσο με το άγχος όσο και με την προσήλωση. Θα μπορούσε να χρησιμοποιηθεί ως δείκτης προσαρμοστικότητας σε συνθήκες άγχους [43].

- **PNN50:**

- Εκφράζει το ποσοστό των διαστημάτων N-N που διαφέρουν περισσότερο από 50 ms από το προηγούμενο N-N διάστημα.
- Υψηλές τιμές PNN50 συνήθως υποδεικνύουν μεγαλύτερη MKP και καλύτερη προσαρμοστικότητα του παρασυμπαθητικού συστήματος.

- **NN50:**

- Εκφράζει τον αριθμό των διαστημάτων N-N που διαφέρουν μεταξύ τους κατά περισσότερο από 50 ms.
- Παρόμοια με τη μετρική PNN50, υψηλές τιμές NN50 υποδεικνύουν υψηλή MKP και ενεργοποίηση του παρασυμπαθητικού νευρικού συστήματος.


3.2.2.2 Χωρισμός χρονικών παραθύρων παρατήρησης και εφαρμογή επικάλυψης

Εφόσον έχουμε να κάνουμε με πρόβλημα χρονοσειρών, παραδοσιακά τα χρονικά παράθυρα παρατήρησης δημιουργούνται με κυλιόμενο τρόπο πάνω στο σύνολο των δεδομένων. Ωστόσο, η εγγενής μεταβλητότητα των δεδομένων MKP απαιτεί ιδιαίτερη διαχείριση. Συγκεκριμένα, για κάθε n -δευτερόλεπτα παρατηρείται διαφοροποίηση στο πλήθος των παλμών. Για τη δημιουργία σταθερού μήκους εισόδου για το μοντέλο, αρχικά, σε κάθε παράθυρο επιλέγονται μόνο τα διαστήματα N-N εκείνα, τα οποία περιέχονται στο χρονικό διάστημα του παραθύρου παρατήρησης. Στη συνέχεια, για κάθε τέτοιο *bin* εφαρμόζεται η συνάρτηση *resample* ανά δευτερόλεπτο και για κάθε δευτερόλεπτο αποθηκεύεται η μέση τιμή των διαστημάτων N-N, εαν υπάρχουν παραπάνω από μία παρατηρήσεις. Διαφορετικά, σε περίπτωση που στο διάστημα του δευτερολέπτου δεν αντιστοιχεί κάποιο διάστημα, συμπληρώνεται με την τιμή 0, ώστε να διατηρηθεί η χρονική αλληλουχία των δεδομένων. Αντίστοιχα, εαν στο διάστημα παρατήρησης υπάρχουν λιγότερα από n διαστήματα, όπου n η χρονική διάρκεια του παραθύρου, εφαρμόζεται τεχνική συμπλήρωσης των δεδομένων *zero padding*. Πριν συμπληρωθούν οι ‘κενές’ τιμές, γίνεται η εξαγωγή των επιλεγμένων στατιστικών χαρακτηριστικών MKR από τα πραγματικά διαστήματα N-N. Για τον υπολογισμό των μετρικών της MKP χρησιμοποιήθηκε η βιβλιοθήκη *hrv_analysis* της *python* και συγκεκριμένα η συνάρτηση *get_time_domain_features*.

Η εργασία επικεντρώθηκε στην αναγνώριση σύντομων μεταβολών, όπου το διάστημα αναγνώρισης ήταν μικρό. Στην πειροψηφία τους, οι υπάρχουσες έρευνες για την αναγνώριση συναισθημάτων χρησιμοποιούν διαστήματα αναγνώρισης μεταξύ 30 δευτερολέπτων και 1 λεπτού, γεγονός που καθιστά δύσκολη την ανίχνευση συναισθημάτων που μεταβάλλονται γρήγορα. Ως εκ τούτου, τα χρονικά παράθυρα που επιλέχθηκαν ήταν διάρκειας 10 ή 30 δευτερολέπτων.

Ακόμη, επειδή τα διαθέσιμα δεδομένα είναι λίγα, χρησιμοποιήθηκε η μέθοδος της επικάλυψης μεταξύ των διαδοχικών παραθύρων παρατήρησης (*overlapping time windows*). Αυτό σημαίνει ότι, για παράδειγμα, ανά χρονικό παράθυρο διάρκειας *window_size* (χρονική διάρκεια παραθύρου παρατήρησης) τα δεδομένα που περιέχονται στο χρονικό διάστημα ($i, i + \text{window_size} - \text{overlap}$), όπου i ο αύξων αριθμός του τρέχοντος παραθύρου, επαναλαμβάνονται σε σχέση με το αμέσως προηγούμενο παράθυρο παρατήρησης.

Η επικάλυψη, προστίθεται στη διαδικασία της προετοιμασίας των δεδομένων με τη βοήθεια της επιπλέον μεταβλητής *overlap* στην επαναληπτική διαδικασία δημιουργίας παραθύρων, η οποία καθορίζει το “βήμα” της επανάληψης.



Εικόνα 11: Εποπτικό παράδειγμα χρονικά επικαλυπτόμενων παραθύρων

3.2.2.3 Προετοιμασία δεδομένων προσήλωσης

Το παρόν πρόβλημα αναγνώρισης των επιπέδων προσήλωσης αντιμετωπίστηκε ως πρόβλημα παλινδρόμησης (regression). Ως εκ τούτου, χρησιμοποιήθηκε η τεχνική της παλινδρόμησης Νευρωνικών Δικτύων η οποία αποτελεί μια τεχνική μηχανικής μάθησης στην οποία ο στόχος είναι να προβλεφθεί μια συνεχής αριθμητική τιμή, με βάση τα δεδομένα εισόδου. Τα Νευρωνικά Δίκτυα αποτελούν ένα τύπο μοντέλων βαθιάς μάθησης, τα οποία μπορούν να χρησιμοποιηθούν για regression με την εκμάθηση μιας απεικόνισης από τα χαρακτηριστικά εισόδου στην έξοδο – στόχο (target).

Κατά την προετοιμασία των δεδομένων προσήλωσης για regression, χρησιμοποιήθηκε η μέθοδος κανονικοποίησης Min – Max Scaling. Η μέθοδος αυτή είναι μια τεχνική κανονικοποίησης που μετασχηματίζει τα δεδομένα ώστε όλες οι τιμές να βρίσκονται εντός ενός συγκεκριμένου διαστήματος, σύμφωνα με τον τύπο:

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}}$$

Αναλυτικότερα, αφαιρείται η ελάχιστη τιμή του επιλεγμένου χαρακτηριστικού από κάθε δεδομένο του συνόλου προς κανονικοποίηση και στη συνέχεια διαιρείται με τη διαφορά της μέγιστης από την ελάχιστη τιμή. Με τη συγκεκριμένη μέθοδο, εξασφαλίζεται ότι οι τιμές του κανονικοποιημένου χαρακτηριστικού θα κυμαίνονται μέσα στο επιθυμητό διάστημα, καθιστώντας το συγκρίσιμο και καταλληλότερο στη χρήση για αλγόριθμους μηχανικής και βαθιάς μάθησης.

Σύμφωνα με αυτή τη μέθοδο, οι τιμές της προσήλωσης κανονικοποιήθηκαν για τον κάθε συμμετέχοντα ξεχωριστά, ώστε να υπάρχει κοινή κλίμακα αναφοράς για τα δεδομένα εξόδου, συγκεκριμένα στο διάστημα [0,1]. Η ανά συμμετέχοντα κανονικοποίηση πραγματοποιήθηκε ώστε να αποτυπωθούν οι εγγενείς διαφορές στα δεδομένα που οφείλονται στην ετερόκλητη φύση αλλά και τον υποκειμενισμό στις καταγραφές των επισημειώσεων.

3.2.2.4 Αντιστοίχιση δεδομένων εισόδου – εξόδου

Για τη διαδικασία αντιστοίχισης δεδομένων εισόδου - εξόδου, δημιουργούνται δύο διαφορετικές δομές με τα δεδομένα ΜΚΡ και προσήλωσης ανά συμμετέχοντα, αντίστοιχα. Στη συνέχεια αποθηκεύονται σε δύο ξεχωριστά αρχεία '.pkl' μέσω της βιβλιοθήκης *pickle* της *python*, με στόχο την ευκολότερη διαχείρισή τους και μείωση του 'overhead' του σταδίου προετοιμασίας για την αυτοματοποίηση της διαδικασίας της εκπαίδευσης.

Τα επεξεργασμένα δεδομένα που αφορούν την ΜΚΡ αποθηκεύονται, συγκεντρωτικά για όλους τους συμμετέχοντες, σε ένα αντικείμενο *dictionary* όπου κάθε εγγραφή αντιστοιχεί στα δεδομένα ενός συμμετέχοντα. Η τιμή (value) της κάθε εγγραφής είναι ένα *pandas dataframe* με τις εξής πληροφορίες:

nn_intervals: Στήλη με τα διαστήματα N-N αφού έχουν εκκαθαριστεί και οργανωθεί σε χρονικά παράθυρα ορισμένης χρονικής διάρκειας.

time_features: Έξι στήλες με τα αντίστοιχα χρονικά χαρακτηριστικά της MKP, όπως αυτά έχουν εξαχθεί από τα διαστήματα N-N, με μία εγγραφή ανά χαρακτηριστικό για κάθε χρονικό παράθυρο παρατήρησης.

group_id: Μοναδικός ακέραιος αριθμός, ως αναγνωριστικό για κάθε ξεχωριστό παράθυρο με σκοπό τη διατήρηση της χρονικής αλληλουχίας των δεδομένων. Η επιλογή one-hot-encoding της στήλης του χρόνου γίνεται με το σκεπτικό ότι το timestamp δεν θα χρησιμοποιηθεί στην διαδικασία εκπαίδευσης.

participant_id: Μοναδικό αναγνωριστικό για κάθε συμμετέχοντα. Βοηθάει στην ομαδοποίηση των δεδομένων ανα συμμετέχοντα.

Με ανάλογο τρόπο, τα δεδομένα της προσήλωσης αποθηκεύονται σε ένα ξεχωριστό αρχείο με ένα συνολικό dataframe, που περιέχει την αντίστοιχη στήλη *participant_id*, για κάθε συμμετέχοντα, όπως και στα δεδομένα εισόδου, ώστε να είναι εύκολο να γίνει η μετέπειτα αντιστοίχιση. Οι εγγραφές είναι αποθηκευμένες σε χρονικά αύξουσα σειρά, το οποίο σημαίνει ότι για κάθε συμμετέχοντα κάθε γραμμή αντιστοιχεί στο “επόμενο” χρονικά δευτερόλεπτο, όπως και η αντίστοιχη μέτρηση. Η αντιστοιχία των δεδομένων που αφορούν τα διαστήματα N-N και των αντίστοιχων τιμών προσήλωσης είναι 1-1, σύμφωνα με τη διαδικασία προετοιμασίας.

4. Προτεινόμενο μοντέλο βαθιάς μάθησης

4.1 Leave-One(Participant)-Out Cross Validation (LO(P)OCV)

Η επιλογή της κατάλληλης συνάρτησης χωρισμού των δεδομένων σε σύνολα train και test, επιλέχθηκε με βάση ένα συνδυασμό παραγόντων που λαμβάνουν υπόψη την ιδιαιτερότητα του προβλήματος και της φύσης των δεδομένων. Αρχικά, το περιορισμένο πλήθος διαθέσιμων δεδομένων αποτελεί μία πρόκληση στη χρήση τεχνικών βαθιάς μάθησης, όπου συνήθως αξιοποιούνται αρκετά μεγάλα dataset. Επίσης, το γεγονός ότι η κατανομή των επισημειώσεων είναι ετερογενής, λόγω υποκειμενικών διαφορών που προκύπτουν από τη διαδικασία καταγραφής, καθιστά τη χρήση συναρτήσεων της λογικής `train_test_split()` για την εκπαίδευση στο σύνολο των δεδομένων λιγότερο κατάλληλη. Το ίδιο γεγονός οδηγεί, επίσης, στην παρατήρηση πως τα δεδομένα ενός συμμετέχοντα δεν έχει νόημα να χρησιμοποιούνται και στα δύο σύνολα, εκτός αν η εκπαίδευση εφαρμοστεί ανά συμμετέχοντα. Στην περίπτωση αυτή, τα δεδομένα που επαναλαμβάνονται λόγω επικάλυψης εισαγάγουν προκατάληψη (bias) στην πρόβλεψη, εφόσον υπάρχουν κοινά δεδομένα στα σύνολα train - test. Από την άλλη, δεν βρέθηκε κάποιο τέχνασμα ώστε να απομονωθούν διαφορετικά στιγμιότυπα των δεδομένων για μία per - participant μέθοδο εκπαίδευσης χωρίς να χρειαστεί να αγνοείται σημαντικός αριθμός των “επικαλυπτόμενων” δεδομένων.

Με βάση τις παραπάνω παρατηρήσεις, θεωρήθηκε ως καταλληλότερη μία Cross Validation μέθοδος, καθώς ταυτόχρονα παρέχει μια λεπτομερή εικόνα της ικανότητας του μοντέλου να γενικεύει σε νέα δεδομένα. Η μέθοδος Leave-One-Out Cross-Validation (LOOCV) είναι μια τεχνική αξιολόγησης μοντέλων που χρησιμοποιείται για τη δημιουργία συνόλων train και test σε περιβάλλοντα μηχανικής και βαθιάς μάθησης. Στην LOOCV, το σύνολο δεδομένων χωρίζεται σε n υποσύνολα, όπου το n αντιπροσωπεύει τον αριθμό των παρατηρήσεων, ενώ στο παρόν σενάριο, των διαφορετικών συμμετεχόντων. Σε κάθε επανάληψη της διαδικασίας, ένας μόνο συμμετέχων χρησιμοποιείται ως σύνολο test, ενώ τα υπόλοιπα $n-1$ δείγματα συνθέτουν το σύνολο train. Η διαδικασία επαναλαμβάνεται n φορές, και το μοντέλο αξιολογείται με βάση τη συνολική απόδοση κατά τη διάρκεια όλων των επαναλήψεων. Η LO(P)OCV εξασφαλίζει ότι όλα τα δείγματα χρησιμοποιούνται τόσο για training όσο και για testing, προσφέροντας έτσι μια αξιόπιστη εκτίμηση της ικανότητας γενίκευσης του μοντέλου πάνω στο σύνολο των ετερογενών δεδομένων.

Η μέθοδος LO(P)OCV υλοποιήθηκε με τη χρήση επαναληπτικής μεθόδου πάνω στα αποθηκευμένα dictionaries. Αρχικά, πραγματοποιήθηκε διάβασμα των δεδομένων από τα υπάρχοντα dataframes. Έπειτα, σε κάθε επανάληψη, τα δεδομένα “ομαδοποιήθηκαν”, έτσι ώστε το τρέχον “αρχείο” να δημιουργεί το σύνολο test και τα υπόλοιπα τα σύνολα train-validation. Πριν την εκπαίδευση, τα δεδομένα οριοθετούνται ώστε να υπάρχει 1-1 αντιστοίχιση στους πίνακες με τα διαστήματα N-N, τα στατιστικά χαρακτηριστικά και τις κανονικοποιημένες μετρήσεις προσήλωσης.

Αξιοποιήθηκαν δύο διαφορετικές παραλλαγές της μεθόδου LO(P)OCV:

1. Κλασική μέθοδος LO(P)OCV

Δεν χρησιμοποιείται ξεχωριστό σύνολο validation, δηλαδή τα δεδομένα χωρίζονται σε train-test σύνολα όπως περιγράφηκε παραπάνω.

2. Randomized μέθοδος χωρισμού σε train – validation σύνολα

Πραγματοποιείται χωρισμός των δεδομένων σε σύνολα train-validation. Εδώ αξίζει να σημειωθεί, πως στην περίπτωση αυτή, εμφανίζεται το πρόβλημα των κοινών στιγμιοτύπων λόγω επικάλυψης. Χρησιμοποιήθηκε, γι' αυτό το λόγο, μία τυχαιοποιημένη (randomized) τεχνική διαμοιρασμού των δεδομένων σε σύνολα train και validation, ώστε ελαχιστοποιείται η επικάλυψη των διαδοχικών παραθύρων. Συγκεκριμένα, από το σύνολο των δεδομένων εκπαίδευσης επιλέγεται με τυχαίο τρόπο ένα υποσύνολο, το μέγεθος του οποίου προσεγγίζει μια προκαθορισμένη αναλογία, για να χρησιμοποιηθεί ως σύνολο validation. Στη συνέχεια, ορίζεται μια σταθερά *gap*, βάσει της οποίας εξαιρούνται τα παράθυρα που βρίσκονται σε απόσταση $\pm gap$ από κάθε παρατήρηση του συνόλου validation. Με αυτόν τον τρόπο, διασφαλίζεται ότι τα δεδομένα αυτά δεν συμπεριλαμβάνονται στο σύνολο train. Ακολούθως, τα παραγόμενα σύνολα ανακατεύονται τυχαία, για τη μείωση της πιθανότητας bias και την καλύτερη γενίκευση του μοντέλου.

4.2 Εξαγωγή χαρακτηριστικών


Η διαδικασία εξαγωγής χαρακτηριστικών είναι απαραίτητη για την αναγνώριση συναισθημάτων. Αυτό οφείλεται στο γεγονός ότι το συναίσθημα δεν αποκαλύπτεται στις ίδιες τις ακατέργαστες μετρήσεις και, ως εκ τούτου, θα πρέπει να εξαχθούν σημαντικά χαρακτηριστικά που σχετίζονται με το συναίσθημα, για την ανίχνευσή του. Υπάρχουν δύο τρόποι εξαγωγής χαρακτηριστικών από βιοσήματα. Ο πρώτος είναι μια μέθοδος που χρησιμοποιεί handcrafted features, δηλαδή στατιστικές μετρικές, όπως ο μέσος όρος, η τυπική απόκλιση, το πλάτος και το εμβαδό. Η δεύτερη μέθοδος εξαγωγής χαρακτηριστικών βασίζεται στη βαθιά μάθηση, όπου τα χαρακτηριστικά εξάγονται χρησιμοποιώντας διάφορα μοντέλα Νευρωνικών Δικτύων. Στην παρούσα εργασία, αξιοποιούνται τα πλεονεκτήματα και των δύο μεθόδων, με τη συγχώνευση στατιστικών χαρακτηριστικών και χαρακτηριστικών βαθιάς μάθησης. Όσον αφορά την πρώτη μέθοδο, λαμβάνονται έξι χαρακτηριστικά στο πεδίο του χρόνου. Για τα χαρακτηριστικά βαθιάς μάθησης, τα χρονικά παράθυρα των N-N διαστημάτων χρησιμοποιούνται ως είσοδοι ενός μοντέλου CNN. Ως αποτέλεσμα, τόσο τα στατιστικά χαρακτηριστικά όσο και τα εξαγόμενα χαρακτηριστικά του Νευρωνικού Δικτύου χρησιμοποιούνται για την αναγνώριση των επιπέδων προσήλωσης.

4.3 Αρχιτεκτονική μοντέλου

Η υλοποίηση του προτεινόμενου μοντέλου βασίστηκε σε μια τροποποιημένη εκδοχή του μοντέλου των Lee et al. [42], αξιοποιώντας την εξαγωγή χαρακτηριστικών όπως περιγράφεται στην παραπάνω υποενότητα. Συγκεκριμένα, για κάθε συμμετεχόντα δημιουργήθηκε ένα μοντέλο Convolutional-Neural-Network (CNN), το οποίο μπορεί να προβλέπει σε πραγματικό χρόνο τα επίπεδα προσήλωσης ενός συμμετέχοντα με βάση τα δεδομένα της ανάλυσης ΜΚΡ. Παρακάτω γίνεται μια συνοπτική παρουσίαση των Συνελκτικών Νευρωνικών Δικτύων και των βασικών τους χαρακτηριστικών. Στη συνέχεια περιγράφεται η αρχιτεκτονική του τελικού προτεινόμενου μοντέλου.

4.3.1 Ορισμός Convolutional-Neural-Network (CNN)

Τα Συνελικτικά Νευρωνικά Δίκτυα (Convolutional Neural Networks - CNNs) είναι μοντέλα βαθιάς μάθησης που χρησιμοποιούνται ευρέως στον τομέα της επεξεργασίας εικόνας και βίντεο, ενώ τα τελευταία χρόνια έχει αυξηθεί το ενδιαφέρον γύρω από την πραγματοποίηση προβλέψεων βάσει δεδομένων χρονοσειρών. Η βασική διαφορά των CNNs από τα πλήρως συνδεδεμένα Νευρωνικά Δίκτυα είναι η χρήση συνελικτικών (convolutional) φίλτρων, τα οποία επιτρέπουν στα CNNs να ανιχνεύουν τοπικά μοτίβα και χωρικές συσχετίσεις στα δεδομένα. Ένα CNN αποτελείται από πολλαπλά επίπεδα (layers). Συνοπτικά, αποτελείται από ένα *input layer*, έναν αριθμό από *hidden layers* και ένα *output layer*. Σε ένα CNN, τα *hidden layers* περιλαμβάνουν ένα ή περισσότερα *convolutional layers*. Συνήθως σε ένα *convolutional layer* πραγματοποιείται ένα dot product του *convolution-kernel* με τον πίνακα εισόδου του layer. Καθώς ο *convolution-kernel* ολισθαίνει κατά μήκος του πίνακα εισόδου του layer, η λειτουργία συνέλιξης παράγει έναν *features map*, ο οποίος με τη σειρά του λειτουργεί ως είσοδος του επόμενου layer. Με άλλα λόγια, ο *convolution-kernel* εφαρμόζει συνέλιξη πάνω στην είσοδο, ανιχνεύοντας τοπικά μοτίβα ή χαρακτηριστικά. Ακολουθούν άλλα layers, όπως τα *pooling layers*, τα *fully-connected* (πλήρως συνδεδεμένα) layers και τα *normalization layers* (κανονικοποίησης). Τα *pooling layers* (συνήθως max pooling) μειώνουν τη διάσταση των δεδομένων, διατηρώντας τα σημαντικότερα χαρακτηριστικά, και τέλος, τα *fully-connected layers* χρησιμοποιούνται για την τελική ταξινόμηση ή πρόβλεψη. Συνοπτικά, όπως φαίνεται στην παρακάτω εικόνα, μια τυπική αρχιτεκτονική βασισμένη σε CNN δομείται από ένα ή περισσότερα *convolutional layers* και ακολουθείται από *pooling layers* και τελικά *fully-connected layers*.



Εικόνα 12: Η δομή ενός CNN

Τα Μονοδιάστατα Συνελικτικά Νευρωνικά Δίκτυα (1D Convolutional Neural Networks - 1D CNNs) χρησιμοποιούνται για την επεξεργασία ακολουθιακών δεδομένων, όπως τα σήματα, οι χρονοσειρές και η επεξεργασία κειμένου. Σε αντίθεση με τα 2D CNNs που λειτουργούν σε εικόνες ή δεδομένα με δύο χωρικές διαστάσεις (π.χ. μήκος και πλάτος), τα 1D CNNs εφαρμόζουν συνέλιξη σε δεδομένα μίας διάστασης, δηλαδή σε σειρές από χαρακτηριστικά ή χρονικά διατεταγμένα δεδομένα.

Η μαθηματική περιγραφή ενός μονοδιάστατου CNN παρουσιάζεται παρακάτω:

4. Convolutional(Συνελικτικό) layer:

$$H_{l+1} = \text{ReLU}(H_l * W_l + b_l)$$

- H_l : Έξοδος στο layer l, η οποία είναι μια ακολουθία δεδομένων διαστάσεων [n,t,c], όπου:
 - n: Το μέγεθος παρτίδας (batch size)
 - t: Το μήκος της ακολουθίας (sequence length)
 - c: Ο αριθμός των χαρακτηριστικών
- W_l : Τα βάρη του φίλτρου διαστάσεων [k,c], όπου:
 - k: Το μήκος του φίλτρου (kernel size)
 - c: Ο αριθμός των χαρακτηριστικών
- $*$: Σύμβολο της μονοδιάστατης συνέλιξης
- b_l : bias του επιπέδου l
- ReLU : Συνάρτηση ενεργοποίησης *Rectified Linear Unit*. Ο πρωταρχικός στόχος μιας συνάρτησης ενεργοποίησης είναι να εισαγάγει μη-γραμμικότητα στο δίκτυο, επιτρέποντάς του να μοντελοποιεί σύνθετα μοτίβα και συσχετίσεις στα δεδομένα.

4. Pooling layer:


$$P_l = \text{Max Pool}(H_{l+1})$$

- Η διαδικασία του *Max Pooling*, αποτελεί μια λειτουργία μείωσης των διαστάσεων που επιλέγει το μέγιστο στοιχείο της συνέλιξης, από την περιοχή του feature map που καλύπτεται από το φίλτρο. Η χρήση του *Max Pooling* στοχεύει στη διατήρηση των πιο σημαντικών πληροφοριών, μειώνοντας παράλληλα την υπολογιστική πολυπλοκότητα των επόμενων layers.

4. Fully-connected (πλήρως συνδεδεμένο) layer:

$$F_l = P_l W_f + b_f$$

- F_l : η έξοδος του fully-connected layer
- W_f : τα βάρη του πλήρως συνδεδεμένου επιπέδου
- b_f : bias
- Ένα πλήρως συνδεδεμένο Νευρωνικό Δίκτυο, γνωστό ως Multi-Layer Perceptron (MLP), αποτελείται από πολλαπλά πλήρως συνδεδεμένα layers. Κάθε πλήρως συνδεδεμένο layer αποτελεί μια συνάρτηση από το $\mathbb{R}^m$ στο $\mathbb{R}^n$, με τη διάσταση της εξόδου να εξαρτάται από τη διάσταση της εισόδου. Στον MLP, οι νευρώνες συνήθως χρησιμοποιούν μη γραμμικές συναρτήσεις ενεργοποίησης, επιτρέποντας στο δίκτυο να μαθαίνει πολύπλοκα μοτίβα στα δεδομένα.



Εικόνα 13: Δομή Fully-connected layer σε ένα Νευρωνικό Δίκτυο

4. Layer εξόδου (output layer):

Για τα προβλήματα παλινδρόμησης (regression) στην έξοδο εφαρμόζεται συνήθως ένα *fully-connected layer* με Γραμμική(linear) συνάρτηση ενεργοποίησης, όπου:

Linear(F_l): Η συνάρτηση linear εφαρμόζει έναν γραμμικό μετασχηματισμό στην έξοδο του fully-connected layer. Η έξοδος (**Y**) είναι μια συνεχής αριθμητική τιμή ή ένα διάνυσμα συνεχών τιμών.

- Ο μαθηματικός τύπος για τη γραμμική συνάρτηση είναι:

$$Y = F_l W + b$$

Όπου:

- **W** : βάρη του γραμμικού μετασχηματισμού,
- **b** : bias

4.3.2 Δομή και εκπαίδευση του μοντέλου

Η συνολική αρχιτεκτονική χρησιμοποιεί στατιστικά χαρακτηριστικά MKP στο πεδίο του χρόνου αλλά και χαρακτηριστικά εξαγόμενα από CNN για την αναγνώριση των επιπέδων προσήλωσης. Συγκεκριμένα, η δομή του μοντέλου συνδυάζει τα παρακάτω δύο επίπεδα:

1. CNN που λαμβάνει ως είσοδο τα διαστήματα N-N

Το CNN χρησιμοποιεί ως είσοδο το χρονικό παράθυρο με διαστήματα N-N. Όπως αναφέρθηκε παραπάνω, η μεταβλητή φύση των N-N διαστημάτων χρειάστηκε ιδιαίτερη διαχείριση, καθώς τα μοντέλα CNN πρέπει να έχουν σταθερό μήκος εισόδου. Έτσι ακολουθήθηκε η μέθοδος που περιγράφεται στην *Ενότητα 3* σχετικά με τη διαδικασία δημιουργίας χρονικών παραθύρων παρατήρησης. Το CNN αποτελείται από δύο επίπεδα συνέλιξης (Conv1_NN και Conv2_NN). Το κάθε Convolutional Layer αποτελείται από ένα Batch Normalization layer και ένα Max Pooling layer. Υπάρχουν συνολικά $input_sequence_size$ (= χρονική διάρκεια παραθύρου παρατήρησης) + 1 φίλτρα, για κάθε Convolutional Layer, με βήμα (strides) ίσο με 1, επιτρέποντας padding μεγέθους 1 και χρησιμοποιείται η *ReLU* ως συνάρτηση ενεργοποίησης.

2. Στατιστικά χαρακτηριστικά MKP

Το δεύτερο επίπεδο του μοντέλου αποτελείται από στατιστικά χαρακτηριστικά που επιλέχθηκαν με βάση τη συσχέτιση Pearson. Έχουν επιλεγεί έξι στατιστικά χαρακτηριστικά τα οποία εισάγονται απευθείας στο επόμενο layer.

Τα συνολικά εξαγόμενα χαρακτηριστικά, δηλαδή τα χαρακτηριστικά που εξήχθησαν τόσο από το CNN όσο και από τη στατιστική μέθοδο, συγχωνεύονται στο επίπεδο *Concatenate layer*. Στη συνέχεια, εισάγονται σε ένα *fully-connected* layer με 32 units. Τέλος, εφαρμόζεται το layer εξόδου με γραμμική συνάρτηση ενεργοποίησης. Για την αποφυγή overfitting, μετά το δεύτερο *cnl layer* και πριν το *layer* εξόδου, εφαρμόζονται και επιπλέον *Dropout layers*, με dropout rate ίσο με 0,05.

Η εκπαίδευση του μοντέλου έγινε με χρήση της μετρικής *Mean Squared Error* (MSE) ως συνάρτηση απώλειας (loss function). Το MSE είναι μια κοινή μετρική που χρησιμοποιείται σε προβλήματα πρόβλεψης, και υπολογίζει το μέσο τετραγωνικό σφάλμα μεταξύ των πραγματικών και των προβλεπόμενων τιμών. Το MSE αξιολογεί την απόδοση του μοντέλου, επιβεβαιώνοντας πόσο κοντά είναι οι προβλεπόμενες τιμές στις πραγματικές. Ο μαθηματικός τύπος για τον υπολογισμό του είναι ο παρακάτω:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

όπου n είναι ο αριθμός των δεδομένων/δειγμάτων, y_i οι πραγματικές τους τιμές και $\hat{y}_i$ οι προβλεπόμενες. Επιπλέον, είναι χρήσιμη για την εφαρμογή του *early stopping*. Το *early stopping* αποτελεί μια τεχνική που στοχεύει στο να σταματήσει την εκπαίδευση του μοντέλου όταν η απώλεια (loss) στο σύνολο validation αρχίζει να αυξάνεται ξανά, δηλαδή όταν το μοντέλο αρχίζει να υπερπροσαρμόζεται στα δεδομένα εκπαίδευσης (training dataset). Με τον τρόπο αυτό, βοηθάει στο να αποφεύγεται το overfitting του μοντέλου και αυτό να επιτυγχάνει καλύτερη γενίκευση σε νέα δεδομένα.

4.4 Φιλτράρισμα Διάμεσης Τιμής (Median Filtering)

Για την αξιολόγηση του μοντέλου, χρησιμοποιήθηκε εξομάλυνση των προβλέψεων με την τεχνική του φιλτραρίσματος διάμεσης τιμής (*median filtering*). Η τεχνική αυτή επιλέχθηκε με στόχο τη βελτίωση της σταθερότητας και της ακρίβειας του μοντέλου.

Ως προς τη βελτίωση της σταθερότητας, το φιλτράρισμα μπορεί να συμβάλλει στη μείωση των διακυμάνσεων και του θορύβου στα δεδομένα προβλέψεων, εξασφαλίζοντας πιο ομαλή μετάβαση μεταξύ των διαδοχικών προβλέψεων. Επιπλέον, όταν υπάρχει έντονο *time-shifting*, όπου τα δεδομένα εισόδου δεν αντανακλούν άμεσα τις μεταβολές της προσήλωσης, οι προβλέψεις μπορεί να είναι υπερβολικά "θορυβώδεις" και να παρουσιάζουν απότομες διακυμάνσεις που δεν ανταποκρίνονται σε πραγματικές αλλαγές της τάσης. Το φιλτράρισμα με διάμεση τιμή μειώνει αυτή την επίδραση, διατηρώντας τη βασική τάση της χρονοσειράς, γεγονός που μπορεί να μειώσει τη χρονική υστέρηση στην αντίδραση του μοντέλου σε αυτές τις μεταβολές. Συγκεκριμένα, το φιλτράρισμα διάμεσης τιμής αποτελεί μια μέθοδο εξομάλυνσης που χρησιμοποιείται ευρέως για την μείωση του θορύβου στις προβλέψεις ενός μοντέλου. Αντίθετα με την απλή μέση τιμή, η διάμεσος είναι πιο ανθεκτική σε ακραίες τιμές, αφού επιλέγει τη μεσαία τιμή ενός συνόλου δεδομένων και όχι το μέσο όρο τους.

Η τεχνική του φιλτραρίσματος με διάμεση τιμή εφαρμόζεται μέσω ενός *sliding window* (κυλιόμενου παραθύρου), το οποίο μετατοπίζεται κατά ένα βήμα τη φορά πάνω στα δεδομένα των προβλέψεων. Σε κάθε βήμα υπολογίζεται η διάμεσος των προβλέψεων που περιέχονται στο επιλεγμένο χρονικό παράθυρο. Δηλαδή, για ένα παράθυρο διάρκειας *window*, η μέθοδος υπολογίζει τη διάμεση τιμή των προβλέψεων από τη θέση i έως $i + window$. Για την εφαρμογή της μεθόδου χρησιμοποιήθηκε συνάρτηση *extract_median*, με τις εξής παραμέτρους:

- **predictions:** Ένας πίνακας που περιλαμβάνει τις προβλέψεις του μοντέλου βαθιάς μάθησης.
- **window:** Το μέγεθος του παραθύρου για το φιλτράρισμα, δηλαδή το πλήθος των προβλέψεων που λαμβάνονται υπόψη για τον υπολογισμό της διάμεσης τιμής.

Κατά την επιλογή κατάλληλου μεγέθους παραθύρου, παρατηρείται ένα *trade-off* μεταξύ της αποτελεσματικότητας στη μείωση του θορύβου και ελαχιστοποίησης της καθυστέρησης πρόβλεψης (*lagging*). Ενώ ένα μικρότερο παράθυρο επιτρέπει την ταχύτερη προσαρμογή στις μεταβολές της χρονοσειράς, μειώνοντας το *lagging*, ενδέχεται να μην είναι τόσο αποτελεσματικό στη μείωση του θορύβου. Αντίθετα, ένα μεγαλύτερο παράθυρο αυξάνει την εξομάλυνση, αλλά μπορεί να εισαγάγει καθυστέρηση στην προσαρμογή σε απότομες μεταβολές.

4.5 Μέθοδος αξιολόγησης των προβλέψεων

Έχουν γίνει ορισμένες παραδοχές ως προς την αξιολόγηση των αποτελεσμάτων και την εκτίμηση της ικανότητας πρόβλεψης του προτεινόμενου μοντέλου. Για παράδειγμα, η παρατήρηση σχετικά με την υποκειμενικότητα της μεθόδου δημιουργίας των επισημειώσεων για τα επίπεδα

προσήλωσης σε συνδυασμό με το γεγονός ότι χρησιμοποιήθηκε μέθοδος παλινδρόμησης, οδήγησε στην ανάγκη εισαγωγής μίας κατάλληλης μετρικής που να ακολουθεί την “τάση” κι όχι απαραίτητα την ακριβή τιμή των επιπέδων της προσήλωσης. Η τάση αναφέρεται σε οποιαδήποτε συστηματική αλλαγή στο επίπεδο μιας χρονοσειράς, δηλαδή στη μακροπρόθεσμη κατεύθυνσή της. Τόσο η κατεύθυνση όσο και η κλίση (ρυθμός μεταβολής) μιας τάσης μπορεί να παραμένουν σταθερές ή να μεταβάλλονται κατά τη διάρκεια της χρονοσειράς.

Για το σκοπό αυτό δημιουργήθηκαν δύο συναρτήσεις:

- **upward_trend_similarity:** Η συνάρτηση αυτή αξιολογεί τη αύξουσα τάση μεταξύ των πραγματικών τιμών (y_{true}) και των προβλεπόμενων τιμών (y_{pred}). Χρησιμοποιεί τις διαφορές μεταξύ διαδοχικών τιμών για να προσδιορίσει αν η κάθε ακολουθία (πραγματική και προβλεπόμενη) παρουσιάζει αύξηση.
- **downward_trend_similarity:** Η συνάρτηση αυτή αξιολογεί τη φθίνουσα τάση μεταξύ των πραγματικών τιμών (y_{true}) και των προβλεπόμενων τιμών (y_{pred}). Αντίστοιχα, συγκρίνεται αν οι καθοδικές ή μη τάσεις είναι οι ίδιες για τις πραγματικές και τις προβλεπόμενες τιμές.

Για την αξιολόγηση της απόδοσης του μοντέλου σχετικά με τις δύο μετρικές, αύξουσας και φθίνουσας τάσης, δημιουργήθηκε πίνακας σύγχυσης (confusion matrix) και εξήχθησαν οι εξής μετρικές:

- **Accuracy:** Αποτελεί το ποσοστό των αληθών προβλέψεων σε σχέση με το σύνολο των παρατηρήσεων. Υπολογίζεται ως

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

όπου TP είναι τα αληθώς θετικά (True Positives) , TN τα αληθώς αρνητικά (True Negatives), FP τα ψευδώς θετικά (False Positives) και FN τα ψευδώς αρνητικά (False Negatives).

- **Precision:** Δηλώνει την ακρίβεια του μοντέλου σχετικά με την θετική κλάση. Εκφράζει το ποσοστό αληθώς θετικών προβλέψεων σε σχέση με το σύνολο των θετικών προβλέψεων. Υπολογίζεται ως :

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

- **Specificity:** Αντιπροσωπεύει το ποσοστό των αρνητικών παρατηρήσεων που αναγνωρίστηκαν αληθώς. Υπολογίζεται ως :

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

- **Sensitivity (or Recall):** Αντιπροσωπεύει το ποσοστό των θετικών παρατηρήσεων που αναγνωρίστηκαν αληθώς. Υπολογίζεται ως :

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

- **F1 Score:** Είναι ο αρμονικός μέσος όρος των μετρικών precision και sensitivity. Υπολογίζεται ως :

$$2 * \frac{Precision * Recall}{Precision+Recall}$$

- **AUC (Area Under Curve):** Δίνει μια συνολική εκτίμηση της ικανότητας του μοντέλου να διακρίνει μεταξύ θετικών και αρνητικών κλάσεων. Αποτελεί μία τιμή μεταξύ του 0 και του 1, όπου υψηλότερες τιμές υποδηλώνουν μεγαλύτερη ικανότητα πρόβλεψης.

Για την αξιολόγηση της απόδοσης του μοντέλου, εκτός από τις μετρικές “αύξουσας – φθίνουσας” τάσης των προβλέψεων – πραγματικών τιμών, χρησιμοποιήθηκε, επίσης, η μετρική Root Mean Squared Error (RMSE). Η RMSE υπολογίζεται ως η τετραγωνική ρίζα του μέσου όρου των τετραγώνων του σφάλματος της διαφοράς μεταξύ της πραγματικής τιμής και της προβλεπόμενης τιμής. Η χρησιμότητά της έναντι άλλων μετρικών, είναι ότι δίνει μεγαλύτερη βαρύτητα σε μεγάλα σφάλματα, καθιστώντας την αποτελεσματική για την ανάδειξη σημαντικών αποκλίσεων στις προβλέψεις και την αξιολόγηση της ακρίβειας του μοντέλου.

Επιπλέον, για τον εποπτικό έλεγχο της εγκυρότητας των προβλέψεων, μετά από κάθε επανάληψη εκπαίδευσης εξάγονται γραφικές παραστάσεις που αναπαριστούν από κοινού τις προβλέψεις και τα πραγματικά δεδομένα προσήλωσης για κάθε συμμετέχοντα. Τα γραφήματα δεδομένων χρονοσειρών μπορούν συχνά να απεικονίσουν τάσεις ή μοτίβα με έναν πιο προσιτό, διαισθητικό τρόπο.


5. Αποτελέσματα

Για την εκπαίδευση του μοντέλου, πραγματοποιήθηκαν δοκιμές για χρονικά παράθυρα παρατήρησης 10 και 30 sec, με επικαλύψεις 1, 5 sec και 5, 10 sec, αντίστοιχα. Η επίδοση του μοντέλου αξιολογείται με βάση τις μετρικές που παρουσιάστηκαν στην *Ενότητα 4*. Για την μελέτη των δύο περιπτώσεων, πραγματοποιήθηκε ρύθμιση υπερπαραμέτρων (hyperparameter tuning) όσον αφορά τον αριθμό των εποχών, το μέγεθος επικάλυψης, το *batch size*, το *gap size* (για την μέθοδο χωρισμού συνόλων train - validation) και παρουσιάζονται τα βέλτιστα αποτελέσματα.


5.1 Αποτελέσματα για παράθυρα 10 sec

	Μέθοδος χωρίς validation set		Μέθοδος με validation set	
	Αύξουσα τάση	Φθίνουσα τάση	Αύξουσα τάση	Φθίνουσα τάση
Accuracy	0.6918	0.709	0.6939	0.7053
Precision	0.1407	0.1127	0.1454	0.1207
F1 Score	0.1735	0.15	0.1794	0.1628
Specificity	0.7695	0.7718	0.7707	0.7642
Sensitivity	0.2262	0.2241	0.2339	0.2501
AUC	0.4978	0.4979	0.5023	0.5072


Πίνακας 1: Τιμές μετρικών προσήλωσης για χρονικά παράθυρα παρατήρησης 10 sec




Εικόνα 14: Πίνακας σύγκρισης της μετρικής της αύξουσας τάσης για μέθοδο χωρίς validation σε χρονικά παράθυρα παρατήρησης 10 sec και αντίστοιχη ROC καμπύλη



Εικόνα 15: Πίνακας σύγκρισης της μετρικής της φθίνουσας τάσης για μέθοδο χωρίς validation σε χρονικά παράθυρα παρατήρησης 10 sec και αντίστοιχη ROC καμπύλη



Εικόνα 16: Πίνακας σύγκρισης της μετρικής της αύξουσας τάσης για μέθοδο με validation σε χρονικά παράθυρα παρατήρησης 10 sec και αντίστοιχη ROC καμπύλη




Εικόνα 17: Πίνακας σύγχυσης της μετρικής της φθίνουσας τάσης για μέθοδο με validation σε χρονικά παράθυρα παρατήρησης 10 sec και αντίστοιχη ROC καμπύλη


5.2 Αποτελέσματα για παράθυρα 30 sec

	Μέθοδος χωρίς validation set		Μέθοδος με validation set	
	Αύξουσα τάση	Φθίνουσα τάση	Αύξουσα τάση	Φθίνουσα τάση
Accuracy	0.7188	0.7375	0.7226	0.7376
Precision	0.1566	0.125	0.1569	0.1284
F1 Score	0.1814	0.157	0.1797	0.1616
Specificity	0.8038	0.8066	0.8091	0.8058
Sensitivity	0.215	0.2108	0.2107	0.2182
AUC	0.5097	0.5087	0.5098	0.512


Πίνακας 2: Τιμές μετρικών προσήλωσης για χρονικά παράθυρα παρατήρησης 30 sec




Εικόνα 18: Πίνακας σύγκρισης της μετρικής της αύξουσας τάσης για μέθοδο χωρίς validation σε χρονικά παράθυρα παρατήρησης 30 sec και αντίστοιχη ROC καμπύλη



Εικόνα 19: Πίνακας σύγκρισης της μετρικής της φθίνουσας τάσης για μέθοδο χωρίς validation σε χρονικά παράθυρα παρατήρησης 30 sec και αντίστοιχη ROC καμπύλη




Εικόνα 20: Πίνακας σύγκρισης της μετρικής της αύξουσας τάσης για μέθοδο με validation σε χρονικά παράθυρα παρατήρησης 30 sec και αντίστοιχη ROC καμπύλη




Εικόνα 21: Πίνακας σύγκρισης της μετρικής της φθίνουσας τάσης για μέθοδο με validation σε χρονικά παράθυρα παρατήρησης 30 sec και αντίστοιχη ROC καμπύλη

5.3 Γραφικές παραστάσεις επιπέδων προσήλωσης


Παρακάτω παρουσιάζονται γραφικές παραστάσεις των συμμετεχόντων, που έχουν επιλεγεί από το σύνολο των δοκιμών. Με μπλε χρώμα απεικονίζονται τα πραγματικά δεδομένα, ενώ οι προβλέψεις με πορτοκαλί χρώμα.




Διάγραμμα 1: Συμμετέχων 12784




Διάγραμμα 2: Συμμετέχων 32281




Διάγραμμα 3: Συμμετέχων 64463




Διάγραμμα 4: Συμμετέχων 25690




Διάγραμμα 5: Συμμετέχων 33980




Διάγραμμα 6: Συμμετέχων 64404




Διάγραμμα 7: Συμμετέχων 84548




Διάγραμμα 8: Συμμετέχων 33999




Διάγραμμα 9: Συμμετέχων 32578




Διάγραμμα 10: Συμμετέχων 37381




Διάγραμμα 11: Συμμετέχων 28587




Διάγραμμα 12: Συμμετέχων 23416



Διάγραμμα 13: Συμμετέχων 65673



Διάγραμμα 14: Συμμετέχων 13477



Διάγραμμα 15: Συμμετέχων 51317

6. Συζήτηση και συμπεράσματα

Η ενότητα αυτή αποτελεί μία ανασκόπηση της συνολικής δομής της Διπλωματικής Εργασίας. Επίσης, παρουσιάζεται η ανάλυση και ο σχολιασμός των αποτελεσμάτων. Το θεωρητικό υπόβαθρο, δηλαδή η βιβλιογραφική πλαισίωση των εννοιών και βασικών αρχών που διέπουν την πειραματική διαδικασία, διαστασιολογεί το παρόν πρόβλημα. Αναλύονται οι έννοιες των ΠΣΣ και της ΣΥΝ, ενώ παρουσιάζονται θεωρητικές και πειραματικές μελέτες οι οποίες αναδεικνύουν το σύγχρονο ερευνητικό ενδιαφέρον στους συγκεκριμένους τομείς. Αφαιρετικά, το παρόν σενάριο αποτελεί ένα πρόβλημα αναγνώρισης συναισθήματος. Πιο συγκεκριμένα, πραγματοποιείται ένα case study για την μελέτη της συσχέτισης της ΜΚΡ με τα επίπεδα προσήλωσης χρηστών που αλληλεπιδρούν με ένα ΠΣΣ για την υγεία. Το προτεινόμενο μοντέλο βαθιάς μάθησης, θα μπορούσε σε επόμενο χρόνο να αξιοποιηθεί για την δυναμική παραγωγή περιεχομένου σε ΠΣΣ με επίκεντρο τις παρεμβάσεις υγείας [24, 27].

Η υπόθεση της προβλεπτικής ικανότητας των διαθέσιμων δεδομένων βασίζεται σε στατιστική ανάλυση που πραγματοποιήθηκε με την αξιοποίηση δεδομένων εισόδου είτε μιας μόνο πηγής, είτε συνδυασμού πολλαπλών πηγών, καθώς βρέθηκαν σημαντικές συσχετίσεις μεταξύ των δεδομένων από αισθητήρες όσο και μετρικών του παιχνιδιού με την τιμή των επιπέδων της προσήλωσης [29]. Επιπλέον, όπως αναφέρθηκε, βιβλιογραφικά υπάρχουν θεωρητικές και πειραματικές απόπειρες που προσεγγίζουν και αναλύουν αυτή την συσχέτιση. Έτσι, με τεχνικές επιβλεπόμενης βαθιάς Μάθησης επιχειρήθηκε να διερευνηθεί περαιτέρω αυτή η σχέση μεταξύ των δεδομένων, δηλαδή να αξιολογηθεί η δυνατότητα των εξαγόμενων χαρακτηριστικών να αναγνωρίζουν με ακρίβεια τα επίπεδα προσήλωσης με μη γραμμικό τρόπο. Τέτοιες μέθοδοι θα μπορούσαν να ενσωματωθούν στο PCG του ΠΣΣ, ως μέρος ενός συνεχούς βρόχου ανατροφοδότησης του παραγόμενου περιεχομένου του παιχνιδιού για τη μεγιστοποίηση της προσήλωσης των παικτών.

Κατά την πειραματική διαδικασία, αρχικά, πραγματοποιήθηκε ανάλυση και επεξεργασία των δεδομένων του καρδιακού ρυθμού και της προσήλωσης, ώστε να αξιοποιηθούν στο προτεινόμενο μοντέλο βαθιάς μάθησης. Η αρχιτεκτονική που αναπτύχθηκε βασίστηκε σε συνδυαστική τεχνική εξαγωγής χαρακτηριστικών από τα δεδομένα ΜΚΡ, ενώ υλοποιήθηκε μέθοδος regression. Στη συνέχεια, με την εισαγωγή δύο μετρικών “τάσης”, τα δεδομένα της προσήλωσης, δηλαδή τα αληθή δεδομένα και οι προβλέψεις της αρχικής διαδικασίας regression, μετασχηματίστηκαν σε μορφή για δυαδική ταξινόμηση (binary classification). Η τελική αξιολόγηση του μοντέλου πραγματοποιήθηκε με βάση τις μετρικές που προέκυψαν από τη δυαδική ταξινόμηση, ενώ παράλληλα, εξήχθησαν γραφικές παραστάσεις, όσον αφορά τα συνεχή αληθή δεδομένα – προβλέψεις.

Η περίπτωση που μελετάται αφορά τη μετατροπή ενός προβλήματος παλινδρόμησης σε ένα ισοδύναμο πρόβλημα δυαδικής ταξινόμησης για την αξιολόγηση των προβλέψεων. Έτσι, η προσήλωση, μελετάται σε δύο διακριτές κατηγορίες, αντί για τα συνεχή μεγέθη που προκύπτουν από την παλινδρόμηση. Αυτή η μέθοδος επιτρέπει μια ποιοτική ανάλυση της απόδοσης του μοντέλου, ειδικά στην περίπτωση θορύβου ή ασυνέπειας των δεδομένων. Επιπλέον, θεωρήθηκε

πως η δυαδική ταξινόμηση μπορεί να οδηγήσει σε πιο σταθερά και γενικεύσιμα αποτελέσματα. Συγκεκριμένα, η δυαδική ταξινόμηση μπορεί να παρέχει μια αξιόπιστη προσέγγιση για την ικανότητα πρόβλεψης, σε αντίθεση με την ποσοτικοποίηση του συναισθήματος ως μιας συνεχούς τιμής, η οποία μπορεί να μην είναι εύκολα ερμηνεύσιμη. Όπως θα αναλυθεί παρακάτω, η επιλογή αυτή θέτει ορισμένες προκλήσεις.

6.1 Ερμηνεία των αποτελεσμάτων και προκλήσεις

Η ερμηνεία της επίδοσης του μοντέλου βασίζεται σε μια συνδυαστική μελέτη των αποτελεσμάτων, η οποία προκύπτει από την ιδιαιτερότητα της συνολικής πειραματικής μεθόδου. Από τη μία, το regression δεν ενδείκνυται να αξιολογηθεί αποκλειστικά με τις συνηθισμένες μετρικές, για παράδειγμα RMSE, MAE, R^2 , λόγω του υποκειμενισμού που εισάγεται κατά την καταγραφή των επισημειώσεων της μεταβλητής – στόχου. Ταυτόχρονα, η εύρεση μιας κατάλληλης μετρικής για την αξιολόγηση της ικανότητας πρόβλεψης παρουσιάζει την εξής ιδιομορφία, όπου οι συνεχείς τιμές της προσήλωσης μετασχηματίζονται σε δυαδικές κλάσεις. Στην περίπτωση αυτή, η πρόβλεψη εστιάζεται πλέον αντί για το μέγεθος – ένταση των μεταβολών στα επίπεδα προσήλωσης, στην ικανότητα αναγνώρισης της στιγμιαίας αλλαγής στην “κλίση” της καμπύλης της, ως αύξουσας και φθίνουσας τάσης.

Για την αξιολόγηση των προβλέψεων του μοντέλου βαθιάς μάθησης αξιοποιούνται οι μετρικές που προκύπτουν από τον πίνακα σύγχυσης (confusion matrix), όπως εξάγεται από τα δυαδικά δεδομένα της προσήλωσης. Τα αποτελέσματα συγκρίνονται ως προς τις διαφορετικές μεθόδους χωρισμού των δεδομένων και τις διαφορετικές χρονικές διάρκειες των παραθύρων παρατήρησης, ενώ δεν φαίνεται κάποια περίπτωση να υπερτερεί συνολικά έναντι των υπολοίπων. Η παρατηρούμενη συνθήκη οδηγεί άμεσα στο συμπέρασμα ότι το σύνολο των δεδομένων παρουσιάζει ανισορροπία (*imbalance*). Αυτό σημαίνει πως υπάρχει ανισοκατανομή στις δύο κλάσεις ταξινόμησης, είτε αυτό αφορά την μετρικής της “αύξουσας τάσης” είτε της “φθίνουσας τάσης”. Συγκεκριμένα, στο σύνολο των διαφορετικών σεναρίων, η κλάση στην οποία εστιάζει η εκάστοτε μετρική (θετική κλάση) είναι υποβαθμισμένη σε σχέση με την ευρύτερη κλάση (αρνητική κλάση). Ταυτόχρονα, η πλειοψηφία των προβλέψεων ταξινομείται στην αρνητική κλάση.

Με μία πρώτη ματιά, παρατηρείται υψηλή ακρίβεια, όπου περίπου το 70% των συνολικών προβλέψεων ταξινομείται σωστά, με μικρές διαφοροποιήσεις για τα διαφορετικά σεναρία εκπαίδευσης. Ωστόσο, το αποτέλεσμα αυτό αποδίδεται κυρίως στην επιτυχημένη ταξινόμηση της αρνητικής - ευρύτερης κλάσης, ενώ η ταξινόμηση της θετικής – παρατηρούμενης κλάσης παραμένει ανεπαρκής. Αναλυτικότερα, οι τιμές της μετρικής precision, η οποία αντικατοπτρίζει την ικανότητα του μοντέλου να προβλέπει την εκάστοτε παρατηρούμενη, αύξουσα ή φθίνουσα τάση, καθώς και της μετρικής sensitivity, είναι αρκετά χαμηλές. Το γεγονός αυτό υποδεικνύει ότι το μοντέλο αδυνατεί πολύ συχνά να προβλέψει σωστά την θετική κλάση. Έτσι, η αυξημένη ακρίβεια φαίνεται πως συνδέεται, ως επί το πλείστον, με το υψηλό precision, ενώ παράλληλα, οι χαμηλές τιμές της μετρικής F1 score επιβεβαιώνουν την ύπαρξη του προβλήματος *imbalance*. Η συνολική εικόνα της ικανότητας πρόβλεψης, όπως περιγράφεται από τη μετρική του AUC score δεν βελτιώνει, ουσιαστικά, την τυχαία πρόβλεψη για καμία από τις δύο μετρικές της τάσης των

επιπέδων προσήλωσης. Πιο συγκεκριμένα, τα αποτελέσματα για τη μετρική AUC στο σύνολο των περιπτώσεων είναι πολύ κοντά στο 0,5. Συνοψίζοντας, η ολοκληρωμένη εικόνα που προσφέρει ο πίνακας σύγχυσης και η συνδυαστική ανάγνωση των αποτελεσμάτων που προκύπτουν, δείχνουν ότι η αυξημένη ακρίβεια (accuracy) αποτελεί πλασματικό μέτρο για την αξιολόγηση της αξιοπιστίας των προβλέψεων εξαιτίας του αυξημένου *imbalance*. Αναζητείται, στη συνέχεια, μία θεωρητική τεκμηρίωση των παραπάνω συμπερασμάτων.

Με βάση τον ορισμό του *imbalance*, σε ένα περιβάλλον δυαδικής ταξινόμησης υπάρχει ανισορροπία κλάσεων εάν μια κλάση αντιπροσωπεύεται από την πλειοψηφία των περιπτώσεων και η άλλη αντιπροσωπεύεται μόνο από μια μειοψηφία περιπτώσεων πάνω στο σύνολο των δεδομένων. Σύμφωνα με μελέτες σχετικά με το πρόβλημα του *imbalance* στις προβλέψεις μοντέλων βαθιάς μάθησης, έχει βρεθεί πως το η ανισορροπία των δεδομένων επεκτείνεται και, στην πραγματικότητα, μεγεθύνεται στην περίπτωση πολλαπλών κλάσεων, πολλαπλών επισημάνσεων, πολλαπλών περιπτώσεων μάθησης, όπως και σε προβλήματα regression. Ένας καίριος, λοιπόν, προβληματισμός που προκύπτει είναι το κατά πόσο η επιλογή της συγκεκριμένης αρχιτεκτονικής, σχεδιασμένης για regression, μπορεί να ενισχύει εξ αρχής το παρατηρούμενο πρόβλημα της ανισορροπίας των δεδομένων. Εκτός από τη μέθοδο εκπαίδευσης, σημαντικό ρόλο φαίνεται να διαδραματίζει και η επιλογή τεχνικής της ταξινόμησης. Συγκεκριμένα, στην παραπάνω μελέτη, παρατηρήθηκε ότι η ισοκατανομή στις δημιουργούμενες κλάσεις αποτελεί καθοριστικό παράγοντα για την απόδοση των μοντέλων. Αντίθετα, η ανισοκατανομή, η οποία προκύπτει όταν οι κλάσεις ταξινόμησης διαφέρουν σε πλήθος παρατηρήσεων, οδηγεί σε αυξημένο *imbalance* [44]. Το γεγονός ότι στην προτεινόμενη μέθοδο ταξινόμησης η γνησίως μονότονη κατεύθυνση ταξινομείται στη θετική κλάση και οι άλλες δύο περιπτώσεις στην αρνητική, δημιουργεί ανισοκατανομή και διαφορά στο πλήθος των δεδομένων μεταξύ πολυπληθέστερης (majority) και μειονοτικής (minority) κλάσης. Αυτή η διαφοροποίηση, λοιπόν, μπορεί να αποτελεί παράγοντα εμφάνισης αυξημένου *imbalance*.

Επιπλέον, όσον αφορά τις τεχνικές βαθιάς μάθησης, σύμφωνα με ερευνητική μελέτη πάνω στο *imbalance* σε μεθόδους αξιολόγησης για MLP και CNN, παρουσιάζονται ορισμένοι παράγοντες, καθοριστικοί για το συγκεκριμένο ζήτημα. Σχετικά με τους MLP, οι αρκετά ρηχές αρχιτεκτονικές με πλήρως-διασυνδεδεμένα layers, συσχετίζονται με υψηλότερο βαθμό *imbalance* στα δεδομένα των προβλέψεων. Όπως αναφέρθηκε και προηγουμένως, προκειμένου να αποφευχθεί η μεγάλη πολυπλοκότητα και το *overfitting*, χρησιμοποιήθηκε μόνο ένα *fully connected layer* στην προτεινόμενη αρχιτεκτονική. Κάτι τέτοιο, ενδεχομένως να δυσχεραίνει την αποτελεσματική πρόβλεψη. Ενώ αυτό αποτελεί μία καίρια παρατήρηση όσον αφορά μοντέλα σχεδιασμένα για δυαδική ταξινόμηση, μπορεί να μην μεταφέρεται ισοδύναμα στην περίπτωση regression που εξετάζεται. Αξίζει, ωστόσο, να σημειωθεί. Σε ένα δεύτερο επίπεδο, έχει προταθεί πως η ύπαρξη αραιών δεδομένων (*sparsity*) για την εκπαίδευση CNN, συσχετίζεται επίσης με υψηλά επίπεδα *imbalance* [42]. Βάσει αυτής της πρότασης, είναι κρίσιμο το γεγονός πως τα διαθέσιμα δεδομένα εκπαίδευσης είναι αρκετά ευάριθμα.

Στη συνέχεια, για μια συνολικότερη εποπτεία των αποτελεσμάτων, εξετάζονται οι γραφικές παραστάσεις των συνεχών προβλέψεων του αρχικού regression σε συνδυασμό με τα αληθή δεδομένα προσήλωσης. Παρ' όλο που οι γραφικές παραστάσεις δεν αποτελούν συστηματική μέθοδο αξιολόγησης, παρέχουν διαισθητική πληροφορία για την ικανότητα πρόβλεψης του μοντέλου. Συγκεκριμένα, παρατηρείται ότι στις περισσότερες γραφικές παραστάσεις παρατηρείται, αν όχι στο σύνολο της χρονοσειράς, τουλάχιστον σε ορισμένα διαστήματα, ακολούθηση της

καμπύλης των πραγματικών δεδομένων σχετικά με αυτήν των προβλέψεων. Λόγω του ότι η ταύτιση αποτελεί ένα σπάνιο και σύνθετο σενάριο, εξαιτίας της υποκειμενικότητας και της ετερόκλητης φύσης των παρατηρήσεων, η παρατηρούμενη ομοιότητα προσδίδει θετική ένδειξη για την προβλεπτική ικανότητα του μοντέλου. Παράλληλα, φαίνεται πως οι προβλέψεις περιέχουν αρκετό θόρυβο, γεγονός το οποίο μπορεί να οδηγήσει σε ορισμένα συμπεράσματα. Για παράδειγμα, ακόμη και με την εφαρμογή τεχνικής εξομάλυνσης του θορύβου, το trade-off ανάμεσα στην εισαγωγή καθυστέρησης και τη μείωση του θορύβου αποτέλεσε bottleneck στην απόδοση του μοντέλου. Με άλλα λόγια, η εφαρμογή του φίλτρου διάμεσης τιμής σε μεγαλύτερα χρονικά παράθυρα ή με διαφορετική μέθοδο εξομάλυνσης, όπως η μέση τιμή, θα εισήγαγε καθυστέρηση ή/και θα παρέβλεπε τις πιο απότομες μεταβολές της προσήλωσης. Ένα δεύτερο συμπέρασμα, είναι πως η επιλογή μιας αρχιτεκτονικής με μειωμένη πολυπλοκότητα, δεδομένου του μικρού πλήθους δεδομένων, έρχεται να αντισταθμίσει την ικανότητα πρόβλεψης. Δηλαδή, η προτεινόμενη αρχιτεκτονική του μοντέλου είναι σχετικά απλή, γεγονός που μπορεί να περιορίσει την ικανότητά του να εντοπίζει υποκείμενους συσχετισμούς στα δεδομένα κατά την εκπαίδευση.

Ένας πρόσθετος προβληματισμός προκύπτει από την πιθανότητα παραμόρφωσης των πραγματικών σχέσεων μεταξύ των μεταβλητών κατά τη μετατροπή των συνεχών δεδομένων σε δυαδικά, γεγονός που μπορεί να επηρεάσει την ακρίβεια των προβλέψεων. Παρ' όλο που το μοντέλο βελτιστοποιείται για την αντιμετώπιση αυτής της πρόκλησης μέσω επαναπροσαρμογής της διαδικασίας εκπαίδευσης για regression, η τελική αξιολόγηση στηρίζεται σε έναν μετασχηματισμό αυτής της διαδικασίας. Η μετατροπή των συνεχών σε δυαδικά δεδομένα ενδέχεται να εισάγει μια απλοϊκή προσέγγιση, η οποία δεν αντικατοπτρίζει πλήρως τη συνεχή φύση των αρχικών παρατηρήσεων. Παράλληλα, η διατήρηση των συνεχών τιμών θα μπορούσε να προσφέρει μια πιο ακριβή εικόνα της απόδοσης του μοντέλου, ειδικά δεδομένου ότι η αρχιτεκτονική του είναι σχεδιασμένη για regression. Ωστόσο, τα αποτελέσματα που αναφέρονται σε κοινά σενάρια εκπαίδευσης υποδεικνύουν ότι το βέλτιστο RMSE παραμένει σχετικά υψηλό (περίπου 0.3) για το διάστημα κανονικοποίησης $[0,1]$. Το γεγονός αυτό υποδηλώνει περιθώριο περαιτέρω βελτιστοποίησης του μοντέλου.

Τέλος, μια γενικότερη παρατήρηση είναι πως η ανομοιογένεια των δεδομένων καθιστά δύσκολη την ανάπτυξη ενός μοντέλου ώστε να είναι εξίσου αποτελεσματικό για όλους τους συμμετέχοντες. Επίσης, κάθε σενάριο συλλογής τους μπορεί να περιλαμβάνει ποικιλία παραγόντων, όπως οι διαφορετικές περιβαλλοντικές συνθήκες, οι οποίες εν γένει επηρεάζουν την προσήλωση, η ποικιλομορφία στην κατανομή των δεδομένων και η διαφοροποίηση μεταξύ των ατόμων. Αυτές οι διαφορές καθιστούν την προσαρμογή του μοντέλου για την εκάστοτε περίπτωση, έναν επιπλέον συντελεστή πολυπλοκότητας στη διαδικασία εκπαίδευσης. Σαν συμπέρασμα, η αδυναμία εύρεσης ενός γενικευμένου μοντέλου ενδέχεται να μην δίνει μια σαφή, συγκεντρωτική εικόνα για την ακρίβεια και την αξιοπιστία των προβλέψεων. Ακόμη ένας προβληματισμός αφορά το κατά πόσο το μοντέλο θα μπορέσει να επιτύχει να αποδώσει ικανοποιητικά σε σενάρια που δεν έχουν συμπεριληφθεί στην αρχική εκπαίδευση, ακόμη και για μεγαλύτερα σύνολα δεδομένων. Έτσι, είναι σημαντικό να εξεταστεί η διαφοροποίηση της αποτελεσματικότητας της διαδικασίας εκπαίδευσης και αξιολόγησης ανάλογα με τις εκάστοτε συνθήκες.

6.2 Προτάσεις βελτίωσης

Τα αποτελέσματα, αν και μη βέλτιστα, αναδεικνύουν την δυνατότητα συσχέτισης των δεδομένων MKP με τα επίπεδα προσήλωσης των συμμετεχόντων κατά την αλληλεπίδρασή τους με το ΠΣΣ. Τα ευρήματα αφορούν εξίσου σημαντικές προκλήσεις που μένει να μελετηθούν για την σταθεροποίηση των συμπερασμάτων. Με βάση τις παρατηρήσεις που προκύπτουν από την ανάλυση των αποτελεσμάτων της προτεινόμενης μεθόδου βαθιάς μάθησης, παρατίθενται ορισμένες προτάσεις για τη βελτίωσή της.

Σχετικά με τη μεθοδολογία regression που ακολουθήθηκε οι κυρίαρχες προκλήσεις αφορούν δύο επίπεδα. Το πρώτο πρόβλημα που αντιμετωπίζεται είναι τόσο η εισαγωγή θορύβου όσο και η ύπαρξη καθυστέρησης. Εν προκειμένω, η διαδικασία της εκπαίδευσης είναι ευάλωτη και στις δύο παραμέτρους. Τα CNN παρουσιάζουν αυξημένη ευαισθησία στο data tuning, δηλαδή τη δομή και την επεξεργασία των δεδομένων. Έτσι, για την αύξηση της ικανότητας προσαρμογής των προβλέψεων στις μεταβολές των επιπέδων προσήλωσης προτείνεται η διερεύνηση διαφορετικών μεθόδων ομαδοποίησης των δεδομένων MKP και βελτιστοποίηση στις μεθόδους εξαγωγής χαρακτηριστικών. Δεδομένου ότι η ερμηνευσιμότητα των συγκεκριμένων μοντέλων είναι αρκετά περιορισμένη, θα μπορούσε να πραγματοποιηθεί μια στατιστική ανάλυση, είτε εφαρμογή ρηχών μοντέλων μηχανικής μάθησης για την εύρεση των πιο κατάλληλων χαρακτηριστικών της MKP για το δεδομένο πρόβλημα.

Το δεύτερο επίπεδο βελτίωσης αφορά τη μείωση του *imbalance*. Θα ήταν σκόπιμη η αναζήτηση μιας νέας αρχής για τη δυαδική ταξινόμηση, δηλαδή την δημιουργία των κλάσεων προσήλωσης σε έναν κοινό “χώρο”. Συγκεκριμένα, προτείνεται η ανάπτυξη ενός προσαρμοσμένου Δείκτη Προσήλωσης (Engagement Index - EI), όπου η συνεχής τιμή της προσήλωσης θα ταξινομείται σε δύο κατηγορίες, για παράδειγμα, “προσήλωση” και “μη προσήλωση” ή “υψηλή” και “χαμηλή” προσήλωση. Αυτή η προσέγγιση έχει ως στόχο τη μείωση της προκατάληψης που δημιουργεί η ανισοκατανομή των προτεινόμενων μετρικών. Για τη μετατροπή της συνεχούς τιμής προσήλωσης σε δυαδική, θα μπορούσαν να χρησιμοποιηθούν διάφοροι μέθοδοι, όπως:

1. Ταξινόμηση βάσει μιας τιμής κατωφλίου (threshold-based classification)
2. Στατιστικό μέτρο z-score
3. Συσταδοποίηση (clustering)
4. Αλγόριθμοι ταξινόμησης, όπως logistic regression ή support vector machines (SVM)

Παρατηρήθηκαν, επίσης, διαφοροποιήσεις στην διακριτική ικανότητα του μοντέλου ανάμεσα στους διαφορετικούς συμμετέχοντες. Χαρακτηριστικά, ο πειραματισμός με τροποποιήσεις της αρχιτεκτονικής που προτείνεται, και η ρύθμιση των υπερπαραμέτρων, δεν οδήγησαν σε ενιαία βελτίωση ή χειροτέρευση των αποτελεσμάτων. Το γεγονός αυτό θα μπορούσε περαιτέρω να επαληθευτεί με μια per - participant μέθοδο εκπαίδευσης, ώστε να ληφθούν συμπεράσματα για κάθε συμμετέχοντα ξεχωριστά. Μία αρκετά παίει λύση θα ήταν η εκπαίδευση μοντέλων εξειδικευμένων για κάθε συμμετέχοντα αντί ενός γενικού μοντέλου, γεγονός που ενδεχομένως να αύξανε την ακρίβεια των προβλέψεων αλλά θα απαιτούσε σημαντικά περισσότερους

υπολογιστικούς πόρους. Αυτή η προσέγγιση, ουσιαστικά, θα ωφελούσε αποκλειστικά την περίπτωση της μελέτης και αξιολόγησης της ικανότητας πρόβλεψης των μοντέλων, ενώ δεν φαίνεται χρήσιμη για τη γενίκευση των αποτελεσμάτων και για μια πιο πρακτική εφαρμογή. Ωστόσο, η εφαρμογή αλγορίθμων συσταδοποίησης, όπως η δημοφιλής μέθοδος K-means clustering, για την δημιουργία γενικευμένων προφίλ συμμετεχόντων πιθανόν να μπορούσε να ενισχύσει την διαδικασία εκπαίδευσης.

7. Επίλογος

7.1 Σύνοψη

Συνοπτικά, η παρούσα Διπλωματική Εργασία αποτελεί μία θεωρητική και πειραματική μελέτη, η οποία εστιάζει στην αναζήτηση συσχετίσεων μεταξύ της μεταβλητότητας του καρδιακού παλμού και των επιπέδων προσήλωσης. Στο πρώτο κομμάτι της, επικεντρώνεται στην θεωρητική πλαisiώση των βασικών αρχών και εννοιών που σχετίζονται με το συγκεκριμένο πρόβλημα. Η κατανόηση του θεωρητικού πλαισίου και των θεμελιωδών εννοιών της ΣΥΝ, των ΠΣΣ και της ΜΚΡ, στη συνέχεια, αξιοποιείται για την εύρεση κατάλληλης μεθόδου βαθιάς μάθησης με στόχο μία πρακτική διερεύνηση της παραπάνω συσχέτισης. Αναπτύσσεται κώδικας για την προετοιμασία και επεξεργασία των δεδομένων ΜΚΡ και αλγόριθμος βαθιάς μάθησης βασισμένος σε Συνελικτικά Νευρωνικά Δίκτυα. Όσον αφορά τα δεδομένα εισόδου, προτείνεται συνδυαστική μέθοδος εξαγωγής χαρακτηριστικών από τα επεξεργασμένα διαστήματα N-N και έξι διαφορετικά στατιστικά χαρακτηριστικά της ΜΚΡ στο πεδίο του χρόνου. Η μεταβλητή εξόδου αποτελείται από τις χρονικά αντιστοιχισμένες συνεχείς τιμές της προσήλωσης. Αρχικά, εφαρμόζεται μέθοδος παλινδρόμησης. Στη συνέχεια τα δεδομένα της πρόβλεψης όπως και τα αληθή δεδομένα των επιπέδων προσήλωσης μετατρέπονται σε μορφή για δυαδική ταξινόμηση με βάση δύο μετρικές, αύξουσας και φθίνουσας τάσης. Η διαδικασία της εκπαίδευσης και αξιολόγησης κυμαίνεται σε δύο επίπεδα. Στο πρώτο επίπεδο, η διαδικασία της εκπαίδευσης ρυθμίζεται και επαναπροσαρμόζεται με την εποπτική βοήθεια γραφικών παραστάσεων των προβλέψεων και των αληθών τιμών. Κατά δεύτερον, εξάγονται μετρικές για την αξιολόγηση της ικανότητας του μοντέλου στην πρόβλεψη των δυαδικών επιπέδων προσήλωσης. Τέλος, πραγματοποιείται ερμηνεία των αποτελεσμάτων, όπως αυτά προκύπτουν από τον συνδυασμό των εφαρμοζόμενων μεθόδων και προτείνονται ορισμένες κατευθύνσεις για την βελτίωση και επέκταση της πειραματικής διαδικασίας.

7.2 Περιορισμοί και προκλήσεις

Η αναγνώριση συναισθήματος αποτελεί ένα πολυπαραγοντικό πρόβλημα. Βασίζεται τόσο στην εγκυρότητα των δεδομένων που αξιοποιούνται όσο και στην καταλληλότητα των μεθόδων που χρησιμοποιούνται όσον αφορά τα εγγενή χαρακτηριστικά και την ιδιαιτερότητα κάθε τέτοιου προβλήματος.

Όσον αφορά το παρόν εγχείρημα, σημαντικό περιορισμό αποτελεί η απουσία μιας ενιαίας και συστηματικής μεθόδου συλλογής των δεδομένων προσήλωσης. Η επισημείωση των επιπέδων προσήλωσης από τους συμμετέχοντες πραγματοποιείται μετά το πέρας της αλληλεπίδρασής τους με το ΠΣΣ. Το γεγονός ότι οι επισημειώσεις των επιπέδων προσήλωσης εξαρτώνται από την προσωπική αναδρομή των συμμετεχόντων εισάγει υποκειμενικότητα και ασάφεια στα δεδομένα, καθώς οι συμμετέχοντες μπορεί να θυμούνται ή να αξιολογούν την εμπειρία τους διαφορετικά από

την πραγματικότητα. Αντίθετα, η υιοθέτηση πιο αντικειμενικών μεθόδων μέτρησης της προσήλωσης, όπως η χρήση εργαλείων ανίχνευσης συναισθημάτων και φυσιολογικών αντιδράσεων σε πραγματικό χρόνο [45] θα μπορούσε να επηρεάσει θετικά τη συνολική αποτελεσματικότητα της ανάλυσης.

Επιπρόσθετα, όσον αφορά τη διεξαγωγή της πειραματικής διαδικασίας προκύπτει προβληματισμός σχετικά με τον εξοπλισμό που χρησιμοποιήθηκε και συγκεκριμένα του αισθητήρα καρδιακού παλμού. Η επιλογή ενός χαμηλού κόστους αισθητήρα, οποίος μπορεί να εισάγει θόρυβο και αστάθεια στη διαδικασία δειγματοληψίας, επηρεάζει την ποιότητα και την ακρίβεια των συλλεγόμενων δεδομένων. Συνεπώς, η χρήση υψηλότερης ποιότητας εξοπλισμού θα μπορούσε να βελτιώσει σημαντικά την ακρίβεια των παρατηρήσεων.

Τέλος, σύμφωνα με τα βασικά ευρήματα, παρατηρείται αυξημένο *imbalance* μεταξύ των προβλεπόμενων κλάσεων και συνολικά, χαμηλή ικανότητα πρόβλεψης. Η ικανότητα πρόβλεψης του μοντέλου καθώς και εισαγωγή *bias* στη διαδικασία της εκπαίδευσης, επηρεάζεται κατά κόρον από την ύπαρξη σφαλμάτων και από το μικρό πλήθος δειγμάτων. Αυτό το πρόβλημα μεγενθύνεται στην περίπτωση της βαθιάς μάθησης και των συνελκτικών νευρωνικών δικτύων, δεδομένης της υψηλής ευαισθησίας που παρουσιάζουν τα συγκεκριμένα μοντέλα. Επιπλέον, η εισαγωγή θορύβου και καθυστέρησης καθώς και ανισορροπία στην κατανομή των τιμών 0 και 1 στις μετρικές προσήλωσης μετά την μετατροπή τους σε δυαδικές, επηρεάζουν σημαντικά το αποτέλεσμα. Συγκεκριμένα, η ασυμμετρία στην κατανομή των κλάσεων, καθώς η μια κλάση είναι υπερεκπροσωπημένη, μειώνει την απόδοση του μοντέλου, καθιστώντας δύσκολη την ακριβή πρόβλεψη, ειδικά για την μεινοτική κλάση. Αυτοί οι παράγοντες μπορούν να επηρεάσουν τα αποτελέσματα της ανάλυσης και απαιτούν πιο λεπτομερή ανάλυση και ενδεχόμενες προσαρμογές για να βελτιωθεί η ικανότητα πρόβλεψης του μοντέλου.

7.3 Μελλοντικές κατευθύνσεις

Ορισμένες μελλοντικές κατευθύνσεις για την διεύρυνση της μελέτης που πραγματοποιήθηκε στην παρούσα Διπλωματική Εργασία αφορούν τόσο τη βελτιστοποίηση της προτεινόμενης μεθόδου όσο και την αναζήτηση ευρύτερων λύσεων.

Μια επέκταση της παρούσας προσπάθειας, θα ήταν η ανάπτυξη μιας *multimodal* προσέγγισης, βασισμένης στο πλήθος των διαθέσιμων πηγών δεδομένων αλληλεπίδρασης με το ΠΣΣ. Οι *multimodal* προσεγγίσεις για την αναγνώριση συναισθηματικών δεδομένων αποτελούν μια πολλά υποσχόμενη μέθοδο στον τομέα της ΣΥΝ και της Τεχνητής Συναισθηματικής Νοημοσύνης [15]. Στο πλαίσιο αυτό, οι *multimodal* μέθοδοι εκμεταλλεύονται το γεγονός ότι τα ανθρώπινα συναισθήματα μπορούν να εκφραστούν με πολλαπλούς τρόπους και μέσω διαφορετικών καναλιών επικοινωνίας. Σε αυτή την περίπτωση, τα δεδομένα από πολλαπλές πηγές οργάνωνται μέσω της επεξεργασίας και του συνδυασμού τους σε ένα γενικό σύνολο ώστε να εισαχθούν σε ένα ενιαίο μοντέλο. Η μελέτη αυτή θα μπορούσε να επιτευχθεί με την ανάπτυξη σύνθετων αλγορίθμων για την αντιμετώπιση της ετερογένειας και του συγχρονισμού των δεδομένων.

Γενικότερα, τα μοντέλα βαθιάς μάθησης εμφανίζουν υψηλή πολυπλοκότητα και η επίδοσή τους συχνά βελτιώνεται για πολυπληθέστερα σύνολα δεδομένων. Έτσι, η ανάλυση που πραγματοποιήθηκε θα ήταν ωφέλιμο να εξεταστεί πάνω σε τέτοια σύνολα δεδομένων, για την εξαγωγή πιο στέρεων συμπερασμάτων. Από την άλλη, θα μπορούσε να ωφεληθεί η εφαρμογή μιας μεθόδου Transfer Learning. Η μέθοδος αυτή επιτρέπει τη χρήση μοντέλων, προεκπαιδευμένων πάνω σε μεγάλα σύνολα δεδομένων και την προσαρμογή τους σε ένα πιο εξειδικευμένο πρόβλημα. Με αυτόν τον τρόπο, τα μοντέλα μπορούν να αξιοποιήσουν τις γνώσεις που έχουν αποκτήσει από την προ-εκπαίδευσή τους σε σύνολα δεδομένων, τα οποία είναι συνήθως πολυπληθέστερα και πιο ποικίλα. Έτσι, περιορίζεται ανάγκη για την εκ νέου εκπαίδευση του μελετούμενου μοντέλου σε μεγάλο όγκο δεδομένων, καθώς αυτό είναι ήδη εξοικειωμένο με θεμελιώδη χαρακτηριστικά τα οποία είναι κοινά ή σημαντικά για την κατηγορία των δεδομένων που μελετάται.

Τέλος, μια επέκταση της παρούσας ανάλυσης θα μπορούσε να πραγματοποιηθεί μέσω του πειραματισμού πάνω σε διαφορετικά μοντέλα βαθιάς μάθησης (π.χ. LSTMs, Variational Autoencoders, GRUs). Για παράδειγμα, τα LSTMs εμφανίζουν αυξημένη ικανότητα στη διαχείριση σύνθετων εξαρτήσεων στο πεδίο του χρόνου σε δεδομένα χρονοσειρών, ενώ τα GRUs εμφανίζουν μικρότερη πολυπλοκότητα και συχνά, απαιτούν συντομότερο χρόνο εκπαίδευσης. Έτσι, η ανάπτυξη νέων αλγορίθμων βασισμένων σε διαφορετικά μοντέλα ή συνδυασμούς αυτών θα επέτρεπε τη σύγκριση διαφορετικών τεχνικών βαθιάς μάθησης και θα έδινε μια πιο σφαιρική εικόνα πάνω στις δυνατότητές τους για το παρόν σενάριο.

Βιβλιογραφία

- [1] R. Arya, J. Singh, and A. Kumar, “A survey of multidisciplinary domains contributing to affective computing,” *Comput. Sci. Rev.*, vol. 40, p. 100399, May 2021, doi: 10.1016/j.cosrev.2021.100399.
- [2] C. Ratner, “A Macro Cultural-Psychological Theory of Emotions,” in *Emotion in Education*, Elsevier, 2007, pp. 89–104. doi: 10.1016/B978-012372545-5/50007-1.
- [3] P. V. Rouast, M. T. P. Adam, and R. Chiong, “Deep Learning for Human Affect Recognition: Insights and New Developments,” *IEEE Trans. Affect. Comput.*, vol. 12, no. 2, pp. 524–543, Apr. 2021, doi: 10.1109/TAFFC.2018.2890471.
- [4] P. Siirtola, S. Tamminen, G. Chandra, A. Ihalapathirana, and J. Rönning, “Predicting Emotion with Biosignals: A Comparison of Classification and Regression Models for Estimating Valence and Arousal Level Using Wearable Sensors,” *Sensors*, vol. 23, no. 3, p. 1598, Feb. 2023, doi: 10.3390/s23031598.
- [5] R. Zall and M. R. Kangavari, “Comparative Analytical Survey on Cognitive Agents with Emotional Intelligence,” *Cogn. Comput.*, vol. 14, no. 4, pp. 1223–1246, Jul. 2022, doi: 10.1007/s12559-022-10007-5.
- [6] A. Dziedzickis, A. Kaklauskas, and V. Bucinskas, “Human Emotion Recognition: Review of Sensors and Methods,” *Sensors*, vol. 20, no. 3, Art. no. 3, Jan. 2020, doi: 10.3390/s20030592.
- [7] S. M. S. A. Abdullah, S. Y. A. Ameen, M. A. M. Sadeeq, and S. Zeebaree, “Multimodal Emotion Recognition using Deep Learning,” *J. Appl. Sci. Technol. Trends*, vol. 2, no. 02, pp. 52–58, Apr. 2021, doi: 10.38094/jastt20291.
- [8] P. Weichbroth and W. Sroka, “A note on the affective computing systems and machines: a classification and appraisal,” *Procedia Comput. Sci.*, vol. 207, pp. 3798–3807, 2022, doi: 10.1016/j.procs.2022.09.441.
- [9] Y. Wang *et al.*, “A Systematic Review on Affective Computing: Emotion Models, Databases, and Recent Advances,” Mar. 20, 2022, *arXiv*: arXiv:2203.06935. Accessed: Jun. 10, 2024. [Online]. Available: <http://arxiv.org/abs/2203.06935>
- [10] H. Kumar and A. Martin, “Artificial Emotional Intelligence: Conventional and deep learning approach,” *Expert Syst. Appl.*, vol. 212, p. 118651, Feb. 2023, doi: 10.1016/j.eswa.2022.118651.
- [11] S. Zhang, Y. Yang, C. Chen, X. Zhang, Q. Leng, and X. Zhao, “Deep learning-based multimodal emotion recognition from audio, visual, and text modalities: A systematic review of recent advancements and future prospects,” *Expert Syst. Appl.*, vol. 237, p. 121692, Mar. 2024, doi: 10.1016/j.eswa.2023.121692.
- [12] Z. He *et al.*, “Advances in Multimodal Emotion Recognition Based on Brain–Computer Interfaces,” *Brain Sci.*, vol. 10, no. 10, Art. no. 10, Oct. 2020, doi: 10.3390/brainsci10100687.
- [13] Y. Haque *et al.*, “State-of-the-Art of Stress Prediction from Heart Rate Variability Using Artificial Intelligence,” *Cogn. Comput.*, vol. 16, no. 2, pp. 455–481, Mar. 2024, doi: 10.1007/s12559-023-10200-0.
- [14] S. N. M. Sayed Ismail, N. A. Ab. Aziz, S. Z. Ibrahim, and M. S. Mohamad, “A systematic review of emotion recognition using cardio-based signals,” *ICT Express*, p. S2405959523001157, Sep. 2023, doi: 10.1016/j.icte.2023.09.001.
- [15] B. Nakisa, M. N. Rastgoo, A. Rakotonirainy, F. Maire, and V. Chandran, “Automatic Emotion Recognition Using Temporal Multimodal Deep Learning,” *IEEE Access*, vol. 8, pp. 225463–225474, 2020, doi: 10.1109/ACCESS.2020.3027026.

- [16] H. Monkaresi, N. Bosch, R. A. Calvo, and S. K. D'Mello, "Automated Detection of Engagement Using Video-Based Estimation of Facial Expressions and Heart Rate," *IEEE Trans. Affect. Comput.*, vol. 8, no. 1, pp. 15–28, Jan. 2017, doi: 10.1109/TAFFC.2016.2515084.
- [17] A. Adikari, G. Gamage, D. de Silva, N. Mills, S.-M. J. Wong, and D. Alahakoon, "A self structuring artificial intelligence framework for deep emotions modeling and analysis on the social web," *Future Gener. Comput. Syst.*, vol. 116, pp. 302–315, Mar. 2021, doi: 10.1016/j.future.2020.10.028.
- [18] K. Cortiñas-Lorenzo and G. Lacey, "Toward Explainable Affective Computing: A Review," *IEEE Trans. Neural Netw. Learn. Syst.*, pp. 1–0, 2023, doi: 10.1109/TNNLS.2023.3270027.
- [19] J. Krath, L. Schürmann, and H. F. O. Von Korflesch, "Revealing the theoretical basis of gamification: A systematic review and analysis of theory in research on gamification, serious games and game-based learning," *Comput. Hum. Behav.*, vol. 125, p. 106963, Dec. 2021, doi: 10.1016/j.chb.2021.106963.
- [20] P. Caserman *et al.*, "Quality Criteria for Serious Games: Serious Part, Game Part, and Balance," *JMIR Serious Games*, vol. 8, no. 3, p. e19037, Jul. 2020, doi: 10.2196/19037.
- [21] M. Urgo, W. Terkaj, M. Mondellini, and G. Colombo, "Design of serious games in engineering education: An application to the configuration and analysis of manufacturing systems," *CIRP J. Manuf. Sci. Technol.*, vol. 36, pp. 172–184, Jan. 2022, doi: 10.1016/j.cirpj.2021.11.006.
- [22] A. A. Tori, R. Tori, and F. D. L. D. S. Nunes, "Serious Game Design in Health Education: A Systematic Review," *IEEE Trans. Learn. Technol.*, vol. 15, no. 6, pp. 827–846, Dec. 2022, doi: 10.1109/TLT.2022.3200583.
- [23] I. Daoudi, R. Chebil, E. Tranvouez, W. Lejouad Chaari, and B. Espinasse, "Improving Learners' Assessment and Evaluation in Crisis Management Serious Games: An Emotion-based Educational Data Mining Approach," *Entertain. Comput.*, vol. 38, p. 100428, May 2021, doi: 10.1016/j.entcom.2021.100428.
- [24] E. Kalafatis *et al.*, "Artificial Intelligence Based Procedural Content Generation in Serious Games for Health: The Case of Childhood Obesity," in *Wireless Mobile Communication and Healthcare*, A. Cunha, N. M. Garcia, J. Marx Gómez, and S. Pereira, Eds., Cham: Springer Nature Switzerland, 2023, pp. 207–219. doi: 10.1007/978-3-031-32029-3_19.
- [25] D. J. Diaz-Romero, A. M. R. Rincon, A. Miguel-Cruz, N. Yee, and E. Stroulia, "Recognizing Emotional States With Wearables While Playing a Serious Game," *IEEE Trans. Instrum. Meas.*, vol. 70, pp. 1–12, 2021, doi: 10.1109/TIM.2021.3059467.
- [26] J. Pérez, M. Castro, and G. López, "Serious Games and AI: Challenges and Opportunities for Computational Social Science," *IEEE Access*, vol. 11, pp. 62051–62061, 2023, doi: 10.1109/ACCESS.2023.3286695.
- [27] 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)*, Athens, Greece: IEEE, Oct. 2019, pp. 497–502. doi: 10.1109/BIBE.2019.00096.
- [28] T. H. Laine and R. S. N. Lindberg, "Designing Engaging Games for Education: A Systematic Literature Review on Game Motivators and Design Principles," *IEEE Trans. Learn. Technol.*, vol. 13, no. 4, pp. 804–821, Oct. 2020, doi: 10.1109/TLT.2020.3018503.
- [29] 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.
- [30] 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)*, Aug. 2020, pp. 694–697. doi: 10.1109/CoG47356.2020.9231785.

- [31] R. Hare and Y. Tang, "Player Modelling and Adaptation Methods within Adaptive Serious Games," in *2021 International Conference on Cyber-Physical Social Intelligence (ICCSI)*, Beijing, China: IEEE, Dec. 2021, pp. 1–6. doi: 10.1109/ICCSI53130.2021.9736213.
- [32] X. Qin, D. Yang, S. Pan, and Q. Yuan, "Research on emotion recognition of bimodal bioelectrical features based on D-S evidence theory," *Biomed. Signal Process. Control*, vol. 87, p. 105538, Jan. 2024, doi: 10.1016/j.bspc.2023.105538.
- [33] R. Damaševičius, R. Maskeliūnas, and T. Blažauskas, "Serious Games and Gamification in Healthcare: A Meta-Review," *Information*, vol. 14, no. 2, p. 105, Feb. 2023, doi: 10.3390/info14020105.
- [34] K. Zarkogianni *et al.*, "The ENDORSE Feasibility Study: Exploring the Use of M-Health, Artificial Intelligence and Serious Games for the Management of Childhood Obesity," *Nutrients*, vol. 15, no. 6, p. 1451, Mar. 2023, doi: 10.3390/nu15061451.
- [35] D. Setiono, D. Saputra, K. Putra, J. V. Moniaga, and A. Chowanda, "Enhancing Player Experience in Game With Affective Computing," *Procedia Comput. Sci.*, vol. 179, pp. 781–788, Jan. 2021, doi: 10.1016/j.procs.2021.01.066.
- [36] T. Pham, Z. J. Lau, S. H. A. Chen, and D. Makowski, "Heart Rate Variability in Psychology: A Review of HRV Indices and an Analysis Tutorial," *Sensors*, vol. 21, no. 12, p. 3998, Jun. 2021, doi: 10.3390/s21123998.
- [37] O. Faust *et al.*, "Heart rate variability for medical decision support systems: A review," *Comput. Biol. Med.*, vol. 145, p. 105407, Jun. 2022, doi: 10.1016/j.compbimed.2022.105407.
- [38] L. V. Coutts, D. Plans, A. W. Brown, and J. Collomosse, "Deep learning with wearable based heart rate variability for prediction of mental and general health," *J. Biomed. Inform.*, vol. 112, p. 103610, Dec. 2020, doi: 10.1016/j.jbi.2020.103610.
- [39] S. Iarlori *et al.*, "An Overview of Approaches and Methods for the Cognitive Workload Estimation in Human–Machine Interaction Scenarios through Wearables Sensors," *BioMedInformatics*, vol. 4, no. 2, pp. 1155–1173, May 2024, doi: 10.3390/biomedinformatics4020064.
- [40] I. Dubovi, "Cognitive and emotional engagement while learning with VR: The perspective of multimodal methodology," *Comput. Educ.*, vol. 183, p. 104495, Jul. 2022, doi: 10.1016/j.compedu.2022.104495.
- [41] 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)*, Berlin, Germany: IEEE, Jul. 2019, pp. 1405–1408. doi: 10.1109/EMBC.2019.8856604.
- [42] M. Lee, Y. K. Lee, M.-T. Lim, and T.-K. Kang, "Emotion Recognition Using Convolutional Neural Network with Selected Statistical Photoplethysmogram Features," *Appl. Sci.*, vol. 10, no. 10, p. 3501, May 2020, doi: 10.3390/app10103501.
- [43] K. Hilgarter, K. Schmid-Zalaudek, R. Csanády-Leitner, M. Mörtl, A. Rössler, and H. K. Lackner, "Phasic heart rate variability and the association with cognitive performance: A cross-sectional study in a healthy population setting," *PLOS ONE*, vol. 16, no. 3, p. e0246968, Mar. 2021, doi: 10.1371/journal.pone.0246968.
- [44] K. Ghosh, C. Bellinger, R. Corizzo, P. Branco, B. Krawczyk, and N. Japkowicz, "The class imbalance problem in deep learning," *Mach. Learn.*, vol. 113, no. 7, pp. 4845–4901, Jul. 2024, doi: 10.1007/s10994-022-06268-8.
- [45] N. Sevchenko, M. Ninaus, F. Wortha, K. Moeller, and P. Gerjets, "Measuring Cognitive Load Using In-Game Metrics of a Serious Simulation Game," *Front. Psychol.*, vol. 12, p. 572437, Mar. 2021, doi: 10.3389/fpsyg.2021.572437.