



# ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

ΤΟΜΕΑΣ ΗΛΕΚΤΡΙΚΩΝ ΒΙΟΜΗΧΑΝΙΚΩΝ ΔΙΑΤΑΞΕΩΝ ΚΑΙ ΣΥΣΤΗΜΑΤΩΝ

ΑΠΟΦΑΣΕΩΝ

## Εντοπισμός θορύβου σε σήματα ηλεκτροδερματικής δραστηριότητας με χρήση τεχνικών μηχανικής μάθησης

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΒΑΣΙΛΕΙΟΣ Ε. ΚΑΒΑΡΔΙΝΑΣ

Επιβλέπων: Δημήτριος Ασκούνης  
Καθηγητής Ε.Μ.Π.

Αθήνα, Ιούλιος 2021





ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ  
ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

ΤΟΜΕΑΣ ΗΛΕΚΤΡΙΚΩΝ ΒΙΟΜΗΧΑΝΙΚΩΝ ΔΙΑΤΑΞΕΩΝ  
ΚΑΙ ΣΥΣΤΗΜΑΤΩΝ ΑΠΟΦΑΣΕΩΝ

# Εντοπισμός θορύβου σε σήματα ηλεκτροδερματικής δραστηριότητας με χρήση τεχνικών μηχανικής μάθησης

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

**ΒΑΣΙΛΕΙΟΣ Ε. ΚΑΒΑΡΔΙΝΑΣ**

**Επιβλέπων:** Δημήτριος Ασκούνης  
Καθηγητής Ε.Μ.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 16<sup>η</sup> Ιουλίου 2021.

.....  
Δημήτριος Ασκούνης  
Καθηγητής Ε.Μ.Π.

.....  
Ιωάννης Ψαρράς  
Καθηγητής Ε.Μ.Π.

.....  
Χρυσόστομος Δούκας  
Αναπλ. Καθηγητής Ε.Μ.Π.

Αθήνα, Ιούλιος 2021

.....  
**ΚΑΒΑΡΔΙΝΑΣ ΒΑΣΙΛΕΙΟΣ**

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

Copyright © Βασίλειος Ε. Καβαρδίνας, 2021

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

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

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



## Περίληψη

Η παρούσα διπλωματική εργασία επιδιώκει να ερευνήσει τη δυνατότητα εφαρμογής της επιστήμης της μηχανικής μάθησης πάνω σε βιομετρικά δεδομένα, τα οποία αξιοποιούνται στον χώρο της ψυχικής υγείας και της αναγνώρισης συναισθημάτων. Κίνητρο αποτέλεσε η ανάγκη συστηματικής και σε πραγματικό χρόνο παρακολούθησης της ψυχικής υγείας, η οποία στην εποχή μας αντιμετωπίζεται ως ένα σημαντικό κοινωνικό ζήτημα. Η ραγδαία πρόοδος της τεχνολογίας και η ευρεία διάδοση και χρήση των φορετών (wearable) συσκευών μπορεί πλέον να παρέχει υποστηρικτικό ρόλο στη διαδικασία αυτή. Πιο συγκεκριμένα, μέσω της διαρκούς συλλογής δεδομένων στην καθημερινή ζωή ενός χρήστη, του προσφέρεται η δυνατότητα να παρακολουθεί ο ίδιος τον εαυτό του. Αυτό επιτυγχάνεται, καθώς οι wearable συσκευές συλλέγουν με μη παρεμβατικό τρόπο βιοσήματα από τον χρήστη, τα οποία με την επεξεργασία από τους κατάλληλους αλγορίθμους και τη χρήση κάποιας εφαρμογής στο κινητό του, μπορούν να τον βοηθήσουν να αποκτήσει καλύτερη γνώση για την ψυχολογική του κατάσταση και τις διακυμάνσεις αυτής. Η χρήση των νέων τεχνολογιών σε συνδυασμό με τις παραδοσιακές υπηρεσίες ψυχικής υγείας έχουν ανοίξει μια νέα αγορά, η οποία προσελκύει διαρκώς όλο και περισσότερες εταιρείες να επενδύσουν σε αυτήν, τη λεγόμενη «Επαυξημένη Ψυχική Υγεία, Augmented Mental Health». Η καταγραφή, ωστόσο, σημάτων στο καθημερινό περιβάλλον του χρήστη έχει μια θεμελιώδη πρόκληση, τον θόρυβο που εισάγεται στα καταγραφόμενα σήματα.

Η εκπόνηση της διπλωματικής εργασίας έγινε σε συνεργασία με την εταιρεία Sentio Solutions, η οποία δραστηριοποιείται στον τομέα της επαυξημένης ψυχικής υγείας, κατασκευάζοντας και διαθέτοντας το wearable προϊόν της, ένα βραχιόλι αναγνώρισης συναισθημάτων Feel. Αντικείμενο της εργασίας είναι η αναζήτηση και ανάπτυξη μιας μεθόδου, η οποία να βασίζεται σε τεχνικές μηχανικής μάθησης, για τον εντοπισμό του θορύβου στο βιοσήμα της ηλεκτροδερματικής δραστηριότητας, το οποίο συλλέγεται από το βραχιόλι Feel. Η ηλεκτροδερματική δραστηριότητα είναι ένα βιομετρικό σήμα που ποσοτικοποιεί τα ηλεκτρικά χαρακτηριστικά του δέρματος και έχει χρησιμοποιηθεί εκτενώς για την αναγνώριση συναισθημάτων, καθώς και τη διάγνωση ψυχικών διαταραχών.

Στο πλαίσιο της εργασίας ακολουθούνται δύο προσεγγίσεις. Η πρώτη αξιοποιεί αλγορίθμους επιβλεπόμενης μάθησης, ενώ η δεύτερη αλγορίθμους μη επιβλεπόμενης μάθησης. Η επιβλεπόμενη μάθηση παρουσίασε ικανοποιητικά αποτελέσματα όσον αφορά στον διαχωρισμό των τμημάτων του σήματος που είναι καθαρά από αυτά που περιέχουν θόρυβο, ενώ η μη επιβλεπόμενη μάθηση δεν παρουσίασε εξίσου καλά αποτελέσματα. Επομένως, η μέθοδος της επιβλεπόμενης μάθησης συνιστάται για περαιτέρω έρευνα και δοκιμή σε πραγματικές συνθήκες παραγωγής.

## Λέξεις κλειδιά

Ψυχική υγεία, εντοπισμός θορύβου, εντοπισμός artifacts, ηλεκτροδερματική δραστηριότητα, μηχανική μάθηση, wearable συσκευές



## *Abstract*

This thesis seeks to investigate the applicability of machine learning to biometric data, which are utilized in the field of mental health and emotion recognition. The motivation was the need for systematic and real-time monitoring of mental health, which in our time is treated as an important social issue. The rapid advancement of technology and the widespread use of wearable devices can now provide a supportive role in this process. More specifically, through the continuous collection of ambulatory data during the daily life of a user, he/she is offered the opportunity to monitor himself. This is achieved as wearable devices collect biosignals in a non-invasive way from the user, which by processing by appropriate algorithms and using an application on his mobile phone, can help him gain better knowledge of his psychological state and its fluctuations. The use of new technologies in combination with traditional mental health services has opened a new market, which is constantly attracting more and more companies to invest in it, the so-called "Augmented Mental Health". However, recording signals in the user's everyday environment has a significant challenge, the noise that is introduced into the recorded signals.

The present thesis was made in collaboration with the company Sentio Solutions, which is active in the field of augmented mental health by manufacturing and distributing its wearable product, the emotion recognition wristband Feel. The purpose of this dissertation is the search and development of a method, based on machine learning techniques, for the detection of noise in the biosignal of electrodermal activity, which is collected from the Feel wristband. The electrodermal activity is a biometric signal that quantifies the electrical characteristics of the skin and has been extensively used in emotion recognition research as well as mental disorders diagnosis.

For the development of the suggested method, two approaches are followed. The first utilizes supervised learning algorithms, while the second utilizes unsupervised learning algorithms. Supervised learning demonstrated satisfactory results in separating the parts of the signal that are clear from those that contain noise, while unsupervised learning did not produce as good results. Therefore, the supervised learning method is recommended for further research and testing in real production conditions.

## *Keywords*

Mental health, noise detection, artifact detection, electrodermal activity, machine learning, wearable devices





# Πίνακας περιεχομένων

<b>Πίνακας περιεχομένων.....</b>	<b>1</b>
<b>Πίνακας Σχημάτων &amp; Πινάκων .....</b>	<b>3</b>
<b>1. Εισαγωγή .....</b>	<b>4</b>
1.1. Ψυχική υγεία και προκλήσεις .....	4
1.2 Σκοπός της διπλωματικής .....	7
1.3 Οργάνωση κειμένου .....	9
<b>2. Η ψυχική υγεία και ο ρόλος των δεδομένων.....</b>	<b>10</b>
2.1 Η ψυχική υγεία και η ανάγκη για βιομετρικά δεδομένα.....	10
2.1.1. Οι συμβατικές μέθοδοι διάγνωσης .....	10
2.1.2. Ανάγκη στήριξης σε αντικειμενικά δεδομένα .....	13
2.1.3. Βιοσήματα και ψυχική υγεία .....	14
2.2 Μέθοδοι και περιβάλλοντα συλλογής βιολογικών δεδομένων.....	16
2.2.1 Το εργαστηριακό περιβάλλον.....	16
2.2.2. Το καθημερινό περιβάλλον .....	18
2.3 Προκλήσεις κατά τη συλλογή δεδομένων στο καθημερινό περιβάλλον .....	20
<b>3. Το πρόβλημα του θορύβου στο σήμα της Ηλεκτροδερματικής Δραστηριότητας .....</b>	<b>22</b>
3.1 Το σήμα της ηλεκτροδερματικής δραστηριότητας .....	22
3.1.1 Ορισμός και ιστορική αναδρομή .....	22
3.1.2 Τα χαρακτηριστικά του σήματος .....	23
3.1.3 Σύνδεση του σήματος με την ψυχολογία .....	24
3.2 Θόρυβος σε EDA δεδομένα.....	25
3.3 Σχετικές εργασίες για τον εντοπισμό και την απομάκρυνση του θορύβου .....	28
3.3.1 Τεχνικές που βασίζονται στη γνώση για το σήμα.....	28
3.3.2 Τεχνικές που βασίζονται στη μηχανική μάθηση .....	29
<b>4. Θεωρητικό υπόβαθρο στη Μηχανική Μάθηση .....</b>	<b>31</b>
4.1. Εισαγωγή στη μηχανική μάθηση.....	31
4.2. Επιβλεπόμενη Μάθηση .....	32
4.2.1. Θεωρία Επιβλεπόμενης Μάθησης .....	32
4.2.2. Αλγόριθμοι Επιβλεπόμενης Μάθησης .....	33
4.3. Μη Επιβλεπόμενη Μάθηση .....	37
4.3.1. Θεωρία μη Επιβλεπόμενης Μάθησης .....	37
4.3.2. Αλγόριθμοι μη Επιβλεπόμενης Μάθησης .....	37
4.4. Μετρικές αξιολόγησης.....	38
<b>5. Ανάπτυξη μεθόδου εντοπισμού θορύβου .....</b>	<b>41</b>

<b>5.1. Συλλογή των δεδομένων ηλεκτροδερματικής δραστηριότητας.....</b>	<b>41</b>
5.1.1. Συσκευή καταγραφής .....	41
5.1.2. Διαδικασία καταγραφής.....	41
<b>5.2 Δημιουργία μεθόδου βασισμένης στην Επιβλεπόμενη Μάθηση.....</b>	<b>42</b>
5.2.1 Προετοιμασία των δεδομένων εισόδου.....	43
5.2.2 Προετοιμασία των μοντέλων και αξιολόγηση των από αποτελεσμάτων .....	45
<b>5.3 Δημιουργία μεθόδου βασισμένης στη μη Επιβλεπόμενη Μάθηση.....</b>	<b>47</b>
5.3.1 Προετοιμασία των δεδομένων εισόδου.....	48
5.3.2 Προετοιμασία των μοντέλων και αξιολόγηση των από αποτελεσμάτων .....	48
<b>6. Επίλογος.....</b>	<b>51</b>
6.1. Συμπεράσματα.....	51
6.2. Μελλοντικές Επεκτάσεις.....	52
<b>7. Βιβλιογραφία.....</b>	<b>53</b>

## Πίνακας Σχημάτων & Πινάκων

Σχήμα 1.1: Συχνότητες εμφάνισης ψυχολογικών διαταραχών.....	5
Σχήμα 1.2: Η ψηφιοποίηση της ιατροφαρμακευτικής φροντίδας.....	6
Σχήμα 1.3: Το βραχιόλι Feel.....	8
Σχήμα 3.1: Χαρακτηριστικά απόκρισηςαγωγιμότητας δέρματος.....	23
Σχήμα 3.2: Artifacts υψηλής συχνότητας.....	26
Σχήμα 3.3: Motion artifacts, αποσύνδεση ηλεκτροδίων.....	26
Σχήμα 3.4: Motion artifacts, πίεση ή τριβή με τα ηλεκτρόδια.....	27
Σχήμα 4.1: Παράδειγμα Κατηγοριοποίησης και Παλινδρόμησης.....	32
Σχήμα 4.2: Γράφημα της λογιστικής συνάρτησης.....	33
Σχήμα 4.3: Παράδειγμα κατηγοριοποίησης με χρήση SVM.....	34
Σχήμα 4.4: Αναπαράσταση μοντέλου τυχαίων δασών.....	35
Σχήμα 4.5: Παράδειγμα κατηγοριοποίησης με χρήση K κοντινότερων γειτόνων.....	36
Σχήμα 4.6.α: Διαχωρισμός κανονικού δεδομένου με χρήση δασών απομόνωσης.....	38
Σχήμα 4.6.β: Διαχωρισμός μη κανονικού δεδομένου με χρήση δασών απομόνωσης.....	38
Σχήμα 5.1: Τα στάδια του pipeline μηχανικής μάθησης.....	42
Πίνακας 5.1: Υποσύνολα χαρακτηριστικών που επιλέχθηκαν από τις μεθόδους επιλογής χαρακτηριστικών.....	45
Πίνακας 5.2: Υποσύνολα χαρακτηριστικών που επιλέχθηκαν για κάθε μοντέλο.....	46
Πίνακας 5.3: Μετρικές αξιολόγησης μη επιβλεπόμενης μάθησης.....	46
Σχήμα 5.2: Οι Receiver Operating Characteristic καμπύλες των μοντέλων επιβλεπόμενης μάθησης.....	47
Πίνακας 5.4: Μετρικές αξιολόγησης μη επιβλεπόμενης μάθησης.....	49
Σχήμα 5.3: Οι Receiver Operating Characteristic καμπύλες των μοντέλων μη επιβλεπόμενης μάθησης.....	49

# Κεφάλαιο 1

## 1. Εισαγωγή

### 1.1. Ψυχική υγεία και προκλήσεις


Η ψυχική υγεία δεν συνιστά απλώς την απουσία κάποιας ψυχικής διαταραχής, αλλά και το επίπεδο της ψυχικής ευημερίας ενός ατόμου. Πιο συγκεκριμένα, μπορεί να οριστεί ως “η ψυχολογική κατάσταση κάποιου, ο οποίος λειτουργεί σε ικανοποιητικό επίπεδο συναισθηματικής και συμπεριφοριστικής προσαρμογής, αντιμετωπίζοντας τα καθημερινά άγχη της ζωής”. Σύμφωνα με τον Παγκόσμιο Οργανισμό Υγείας (Π.Ο.Υ.), μολονότι η ψυχική υγεία είναι αδύνατο να οριστεί πλήρως, περιλαμβάνει μεταξύ άλλων, την υποκειμενική ευεξία, την αντιληπτή αυτοαποτελεσματικότητα, την αυτονομία ενός ατόμου, καθώς και την αυτοπραγμάτωση των διανοητικών και συναισθηματικών του δυνατοτήτων (Organization, 2001). Η αδυναμία απόδοσης αυστηρού ορισμού πηγάζει από τις διαφοροποιήσεις μεταξύ των εκάστοτε τοπικών αντιλήψεων, οι οποίες διαφοροποιούνται ανάλογα με τα πολιτισμικά, θρησκευτικά και κοινωνικά γνωρίσματα. Ενδεικτικά, αξίζει να αναφερθεί ότι το ευρύ φάσμα των προβλημάτων ψυχικής υγείας περιλαμβάνει τόσο ψυχικές διαταραχές, όπως σχιζοφρένεια, κατάθλιψη, διπολική και αγχώδη διαταραχή, κρίσεις πανικού, όσο και κατάχρηση ουσιών και αλκοόλ.

Το μέγεθος και η πολυπλοκότητα που ενέχει το φαινόμενο της ψυχικής υγείας, καθώς και η οικονομική του υπόσταση αναδεικνύουν την αξία μελέτης αυτού. Πολλές έρευνες έχουν προσπαθήσει να αποτυπώσουν την έκταση των περιπτώσεων ψυχικών διαταραχών στον παγκόσμιο πληθυσμό. Θεωρείται, ωστόσο, ότι τα καταγεγραμμένα δεδομένα υπολείπονται της πραγματικότητας. Αυτό συμβαίνει διότι η συλλογή τους κρίνεται ιδιαίτερα δύσκολη, κυρίως σε χώρες με χαμηλό βιοτικό επίπεδο, αφού υπάρχουν περιπτώσεις που δεν καταγράφονται είτε λόγω έλλειψης υποδομών, είτε λόγω απουσίας ενδιαφέροντος του γενικού πληθυσμού, ο οποίος δίνει προτεραιότητα στις βιοτικές και όχι στις ψυχικές ανάγκες. Σύμφωνα με έρευνες του Ινστιτούτου Μέτρησης και Αξιολόγησης της Υγείας, καθώς και του Παγκόσμιου Οργανισμού Υγείας, το 2017 ένας στους επτά (15%) ανθρώπους κατά μέσο όρο παγκοσμίως έπασχε από μία ή περισσότερες ψυχικές διαταραχές, με κορυφαίες την αγχώδη διαταραχή (3.76%) και την κατάθλιψη (3.44%) (Richie & Roser, 2018). Ακόμα και σε ανεπτυγμένες χώρες όπως οι Ηνωμένες Πολιτείες το ποσοστό εμφάνισης οποιασδήποτε ψυχικής ασθένειας στον ενήλικο πληθυσμό αγγίζει το 20.6% (Mental Illness, 2021).

## Prevalence by mental and substance use disorder, World, 2017

Share of the total population with a given mental health or substance use disorder. Figures attempt to provide a true estimate (going beyond reported diagnosis) of disorder prevalence based on medical, epidemiological data, surveys and meta-regression modelling.

Our World  
in Data



Source: IHME, Global Burden of Disease

CC BY

**Σχήμα 1.1: Συχνότητες εμφάνισης ψυχολογικών διαταραχών (Richie & Roser, 2018)**

Επιπρόσθετα, κίνδυνο για επιδείνωση της ψυχικής κατάστασης των ανθρώπων αποτελούν και οι γενικευμένες κρίσεις, είτε αφορούν κάποια ανθρώπινη (τρομοκρατικές επιθέσεις) ή φυσική (σεισμοί, επιδημίες/ασθένειες) καταστροφή είτε την ύφεση της παγκόσμιας ή τοπικής οικονομίας. Χαρακτηριστικό παράδειγμα αποτελεί η τρέχουσα πανδημία του κορονοϊού, καθώς οι άνθρωποι ανησυχούν ιδιαίτερα για την υγεία τους, καθώς και την υγεία των κοντινών τους προσώπων, όπως και για τις οικονομικές συνέπειες που αναμένονται. Πιο συγκεκριμένα, έρευνα που διεξήχθη στο Ηνωμένο Βασίλειο συνέκρινε αποτελέσματα από τα ίδια ερωτηματολόγια, που απαντήθηκαν κατά τον Απρίλιο του 2020 και τα δύο προηγούμενα χρόνια. Τα συμπεράσματα έδειξαν αύξηση της συχνότητας εμφάνισης ψυχικής δυσφορίας στο γενικό πληθυσμό από 18.9% σε 27.3%. Ειδικότερα, παρατηρήθηκε εντονότερη αύξηση σε συγκεκριμένες πληθυσμιακές ομάδες, όπως στις γυναίκες, στις ηλικίες 18-24 και 25-34 και στις οικογένειες που έχουν παιδιά προσχολικής ηλικίας (Pierce, et al., 2020). Νέα έρευνα, ως συνέχεια της προηγούμενης, στον Βρετανικό πληθυσμό, που συνέκρινε δεδομένα του διαστήματος Ιουνίου του 2019 και Μαρτίου 2020 με δεδομένα του Ιουνίου του 2020, παρατήρησε ότι το ποσοστό των ανθρώπων που είχαν πιθανότητα να παρουσιάσουν κατάθλιψη αυξήθηκε από 9.7% σε 19.2%, δηλαδή σχεδόν ένας στους πέντε (Vizard, Davis, White, & Beynon, 2020).

Η προαναφερθείσα διάσταση του φαινομένου υπογραμμίζει την ανάγκη που υπάρχει σήμερα για πρόληψη, έγκαιρη διάγνωση και συστηματική παρακολούθηση της ψυχικής υγείας των ανθρώπων. Η τεχνολογία μπορεί να έχει υποστηρικτικό ρόλο στην αντιμετώπιση των ψυχικών διαταραχών, τόσο σε επίπεδο πρόληψης και διάγνωσης όσο και σε επίπεδο αντιμετώπισης και θεραπείας. Ένα απλό παράδειγμα μπορεί να είναι η διευκόλυνση επικοινωνίας και επαφής με κάποιον ειδικό σε ένα κέντρο υποστήριξης ψυχικής υγείας μέσω της χρήσης ενός κινητού τηλεφώνου ή η εύκολη πρόσβαση σε πληροφορίες και ασκήσεις για την ψυχική ευημερία. Τα τελευταία χρόνια, ωστόσο, η ανάπτυξη της τεχνολογίας καθιστά όλο και πιο συχνή τη χρήση συσκευών, τις οποίες ο χρήστης μπορεί να φοράει (wearable devices) χωρίς να εμποδίζουν την καθημερινότητά του. Οι συσκευές αυτές έχουν τη δυνατότητα να συλλέγουν πληροφορίες σε πραγματικό χρόνο και θα μπορούσαν να χρησιμοποιηθούν σε συνδυασμό με κάποια εφαρμογή στο κινητό, ώστε να εξασφαλίσουν στον χρήστη τη δυνατότητα να παρακολουθεί ο ίδιος την ψυχική του υγεία και να τη βελτιώνει σε καθημερινή βάση. Επομένως, γίνεται πλέον λόγος για επαυξημένη ψυχική υγεία, καθώς οι κλασικές μέθοδοι διάγνωσης και ψυχοθεραπείας εμπλουτίζονται από τα αντικειμενικά δεδομένα που συλλέγονται από τις wearable συσκευές. Ο αναδυόμενος τομέας της επαυξημένης ψυχικής υγείας προσελκύει διαρκώς νέες εταιρείες, οι οποίες προσπαθούν να εμπορευματοποιήσουν τη δυνατότητα συλλογής και επεξεργασίας δεδομένων στο πλαίσιο των καθημερινών δραστηριοτήτων του χρήστη.



**Σχήμα 1.2: Η ψηφιοποίηση της ιατροφαρμακευτικής φροντίδας**

Σημαντική πηγή αντικειμενικών δεδομένων αποτελούν τα βιοσήματα, δηλαδή σήματα που ποσοτικοποιούν τις μεταβολές της φυσιολογίας του ανθρώπινου σώματος, οι οποίες μπορεί να προέρχονται από τις συναισθηματικές διακυμάνσεις ενός ατόμου. Χαρακτηριστικά παραδείγματα βιοσημάτων αποτελούν οι καρδιακοί παλμοί, η αγωγιμότητα του δέρματος και η θερμοκρασία του σώματος. Λαμβάνοντάς τα υπόψη κατά την εκτίμηση της ψυχικής κατάστασης ενός ανθρώπου μπορεί να διαγνωστεί ευκολότερα μια ψυχική διαταραχή και να παρακολουθείται συνεχώς η εξέλιξή της. Τα τελευταία χρόνια είναι, επίσης, δυνατός και ο αυτοματοποιημένος έλεγχος των ψυχικών διακυμάνσεων ενός ανθρώπου από υπολογιστικά συστήματα. Σύμφωνα με την επιστήμη της συναισθηματικής υπολογιστικής, με την παροχή

των κατάλληλων βιολογικών δεδομένων ένα σύστημα μπορεί να αναγνωρίσει και να ερμηνεύσει τα ανθρώπινα συναισθήματα ( (Haag, Goronzy, Schaich, & Williams, 2004), (Quazi, Mukhopadhyay, Suryadevara, & Huang, 2012)).

Προκειμένου να επιτευχθεί ο στόχος της αυτόματης αναγνώρισης της συναισθηματικής κατάστασης ενός χρήστη σε εμπορικό πλαίσιο, απαιτείται, όπως προαναφέρθηκε, η συλλογή των βιοσημάτων στο καθημερινό του περιβάλλον. Η διαδικασία αυτή ενέχει τον κίνδυνο της εισαγωγής θορύβου στα σήματα που καταγράφονται. Αιτία της ύπαρξης θορύβου αποτελεί το γεγονός ότι ο χρήστης δεν βρίσκεται πλέον στο ελεγχόμενο περιβάλλον ενός εργαστηρίου, φορώντας κάποια σταθερή συσκευή, αλλά στο χώρο του σπιτιού του, της εργασίας του, των κοινωνικών ή άλλων συναναστροφών του φορώντας μια φορητή wearable συσκευή (Wilhelm & Grossman, 2010). Ο χρήστης δεν είναι περιορισμένος, όπως στο εργαστήριο, αλλά η καταγραφή των δεδομένων πραγματοποιείται ενώ κινείται και συμμετέχει σε δραστηριότητες. Ο θόρυβος που εισάγεται στο σήμα μπορεί να το παραμορφώσει και να το καταστήσει ακατάλληλο προς επεξεργασία, ούτως ώστε να μην είναι δυνατόν να εξαχθεί πληροφορία από αυτό. Επιπλέον, ενδέχεται να αλλοιώσει τη μορφολογία του σήματος οδηγώντας σε επισφαλή συμπεράσματα για τη συναισθηματική κατάσταση του χρήστη, όπως για παράδειγμα τον λανθασμένο εντοπισμό ενός συναισθήματος. Επομένως, για να είναι ασφαλή τα συμπεράσματα της διαδικασίας αναγνώρισης των συναισθημάτων, κρίνεται πολύ σημαντική η προεπεξεργασία του σήματος και η αφαίρεση του θορύβου από αυτό.

Για να πραγματοποιηθεί επιτυχώς η αφαίρεση του θορύβου, απαιτείται να προηγηθεί ο ακριβής εντοπισμός των περιοχών του σήματος που είναι θορυβώδη. Παραδοσιακά και σε συνθήκες εργαστηρίου, όπου τα δεδομένα δεν είναι πολλά, την εργασία αυτή αναλάμβανε κάποιος ειδικός, ο οποίος εντόπιζε και όριζε τα θορυβώδη τμήματα. Η μέθοδος, όμως, αυτή, του εντοπισμού από τον άνθρωπο δεν μπορεί να εφαρμοστεί στην περίπτωση που ο όγκος των δεδομένων είναι πολύ μεγάλος. Αυτό συμβαίνει όταν τα δεδομένα προέρχονται από κάποια συσκευή που προορίζεται για χρήση από το ευρύ καταναλωτικό κοινό. Απαιτείται, επομένως, η χρήση μιας αυτόματης μεθόδου, που θα χρησιμοποιεί κάποιον αλγόριθμο και θα εκτελείται από ένα υπολογιστικό σύστημα, ενώ παράλληλα θα ελαχιστοποιείται η ανθρώπινη παρέμβαση.

## **1.2 Σκοπός της διπλωματικής**

Αντικείμενο της παρούσας εργασίας είναι η δημιουργία μιας μεθόδου εντοπισμού και αναγνώριση θορύβου στο βιομετρικό σήμα της ηλεκτροδερματικής δραστηριότητας (electrodermal activity). Για την ανάπτυξη της μεθόδου αυτής γίνεται χρήση τεχνικών μηχανικής μάθησης, προκειμένου το σύστημα που θα τη χρησιμοποιεί να αξιοποιεί και να μαθαίνει από τα ίδια τα δεδομένα. Έτσι, το υπολογιστικό σύστημα δεν θα απαιτεί τη συνεχή



ανθρώπινη παρέμβαση, η οποία θα αποτελούσε μια ιδιαίτερα χρονοβόρα και επίπονη διαδικασία, ενώ παράλληλα δεν θα καθίσταται αναγκαία προϋπόθεση η κατάρτιση του ερευνητή πάνω στα βιοσήματα. Ακολουθώντας το δρόμο της μηχανικής μάθησης, υπάρχουν δύο επιλογές, η επιβλεπόμενη και η μη επιβλεπόμενη μάθηση. Στη συγκεκριμένη εργασία ελέγχονται και οι δύο για τη δημιουργία μιας αποτελεσματικής μεθόδου.

Η εργασία πραγματοποιείται στο πλαίσιο συνεργασίας του Εργαστηρίου Συστημάτων Αποφάσεων και Διοίκησης με τη Sentio Solutions. Τα δεδομένα που χρησιμοποιούνται αποτελούν μέρος των πραγματικών δεδομένων τα οποία η εταιρεία αξιοποιεί στο πρόγραμμά της με στόχο τον εντοπισμό και την αναγνώριση συναισθημάτων σε πραγματικούς χρήστες των προϊόντων της. Συγκεκριμένα, τα σήματα που παραχωρήθηκαν για την υλοποίηση της εργασίας έχουν συλλεχθεί από το βραχιόλι Feel που κατασκευάζει και διαθέτει η εν λόγω εταιρεία. Ο σκοπός επομένως της εργασίας αφορά στη δημιουργία μιας μεθόδου βασισμένης στη μηχανική μάθηση η οποία να μπορεί να παρέχει αξιόπιστα αποτελέσματα, ώστε δυνητικά να ενσωματωθεί στη γραμμή παραγωγής της εταιρείας.



**Σχήμα 1.3: Το βραχιόλι Feel**

### *1.3 Οργάνωση κειμένου*

2<sup>ο</sup> Κεφάλαιο: Αξιοποίηση δεδομένων στον τομέα της ψυχικής υγείας για τον έλεγχο και την πρόληψη ψυχικών και συναισθηματικών διαταραχών. Διαδικασίες και μέσα συλλογής δεδομένων. Κινητή συλλογή δεδομένων και τα προβλήματα που προκύπτουν.

3<sup>ο</sup> Κεφάλαιο: Ορισμός και μοντελοποίηση των EDA σημάτων. Θόρυβος σε σήματα ηλεκτροδερματικής δραστηριότητας. Προγενέστερες προσπάθειες αποθορυβοποίησης του σήματος.

4<sup>ο</sup> Κεφάλαιο: Θεωρητικό υπόβαθρο. Εισαγωγή στη Μηχανική Μάθηση και επεξήγηση των μοντέλων που χρησιμοποιούνται.

5<sup>ο</sup> Κεφάλαιο: Προτεινόμενη μεθοδολογία και εκτέλεση. Δοκιμές μοντέλων επιβλεπόμενης και μη επιβλεπόμενης μάθησης. Παράθεση αποτελεσμάτων και σύγκριση.

6<sup>ο</sup> Κεφάλαιο: Συμπεράσματα και μελλοντικές επεκτάσεις.

## Κεφάλαιο 2

### 2. Η ψυχική υγεία και ο ρόλος των δεδομένων

Η ψυχική υγεία και η ποιότητα αυτής αποτελούν ένα ζήτημα το οποίο απασχολεί ενεργά τις ανθρώπινες κοινωνίες τους τελευταίους δύο αιώνες. Η επίσημη αναγνώρισή της έγινε από τον William Sweetzer το 1843, οπότε και της αποδόθηκε ο όρος “ψυχική υγιεινή” (mental hygiene). Αργότερα ο Isaac Ray όρισε την ψυχική υγιεινή ως “την τέχνη της διατήρησης του νου ενάντια σε όλα τα περιστατικά και τις επιρροές που εκτιμώνται να επιδεινώσουν τις ιδιότητές του, να βλάψουν τις ενέργειές του ή να διαταράξουν τις κινήσεις του” (Mandell, 1995). Παρά την προσέγγιση αυτή, λίγη σημασία και φροντίδα παρεχόταν στα ψυχικά ασθενή άτομα, τα οποία περιθωριοποιούνταν και κατέληγαν να ζουν υπό χειρίστες συνθήκες είτε απομονωμένα, είτε σε κάποιο άσυλο. Ένα βήμα προς τη βελτίωση της κατάστασης αυτής προσπάθησε να πραγματοποιήσει η Dorothea Dix στα τέλη του 19ου αιώνα, αναδεικνύοντας την αμέλεια με την οποία αντιμετώπιζονταν οι ψυχικά ασθενείς και ιδρύοντας περισσότερες από 30 κρατικές ψυχιατρικές κλινικές σε ΗΠΑ και Καναδά. Η υποστελέχωση τους και η έλλειψη πόρων, ωστόσο, οδήγησε σύντομα στον κορεσμό τους. Παρά την κατάληξη αυτή, η συγκεκριμένη κίνηση έδωσε έναυσμα στο να ξεκινήσει το “κίνημα ψυχικής υγιεινής” (Mental Hygiene Movement) από τον πρώην ψυχικά ασθενή Clifford Beers, το οποίο συνέβαλε στη συστηματοποίηση μιας πιο επιστημονικής αντιμετώπισης του προβλήματος στα τέλη του 19ου αιώνα (Farreras, 2019).

Στην αρχή του 20ου αιώνα θεσμοθετήθηκαν οι πρώτες ψυχιατρικές κλινικές, που στόχο πλέον είχαν τη μελέτη και την αντιμετώπιση των ψυχικών ασθενειών και όχι απλώς την περίθαλψη των ασθενών. Η σύγχρονη ονομασία “ψυχική υγεία” (Mental Health) υιοθετήθηκε μετά τον Β΄ Παγκόσμιο Πόλεμο προσδίδοντας θετική διάσταση στον όρο, που παραπέμπει στην πρόληψη, την ίαση και την προώθηση της φροντίδας της υγείας. Τα τελευταία χρόνια η ψυχική υγεία αποτελεί ξεχωριστό επιστημονικό κλάδο, στον οποίο έχει πραγματοποιηθεί εκτενής έρευνα και εξακολουθεί να πραγματοποιείται έως και σήμερα. Η σύνδεση του παραπάνω κλάδου με τη συνεχή τεχνολογική εξέλιξη έχει εισάγει τον έλεγχο και την παρακολούθηση της ατομικής ψυχικής υγείας στην καθημερινή ζωή του ανθρώπου.

#### 2.1 Η ψυχική υγεία και η ανάγκη για βιομετρικά δεδομένα

##### 2.1.1. Οι συμβατικές μέθοδοι διάγνωσης

Αδιαμφισβήτητα, η διατήρηση της καλής ψυχικής υγείας στηρίζεται πρωτίστως στην έγκαιρη και σωστή διάγνωση και κατά δεύτερον, στην επιτυχημένη θεραπεία σε περίπτωση ύπαρξης

μιας ψυχικής ασθένειας. Το κομμάτι της διάγνωσης έχει γνωρίσει σταδιακή ανάπτυξη τους τελευταίους δύο αιώνες (Farreras, 2019). Αρχικά, στα τέλη του 19ου αιώνα έγινε μια πρώτη προσπάθεια περιγραφής ενός συστήματος ψυχικών διαταραχών με επίκεντρο τα συμπτώματα τους. Το γεγονός ότι προτεινόταν πολλά διαφορετικά τέτοια συστήματα κατά τα επόμενα χρόνια, ανέδειξε την ανάγκη για ένα ενοποιημένο και κοινώς αποδεκτό σύστημα, και τελικά οδήγησε στην έκδοση του Diagnostic and Statistical Manual (DSM) από την Αμερικανική Ψυχιατρική Ένωση. Στο εγχειρίδιο αυτό πραγματοποιούνται διαρκώς αναθεωρήσεις, προκειμένου αυτό να συμβαδίζει με τα αποτελέσματα των νέων ερευνών. Συγκεκριμένα από το 2013, βρίσκεται στην 5η έκδοση (Diagnostic and Statistical Manual of Mental Disorders, 2013). Ο ρόλος του DSM εντοπίζεται στο να βοηθά τους ειδικούς στη διαδικασία τόσο της διάγνωσης όσο και της θεραπείας. Παρέχει μια ενοποιημένη βάση για τα χαρακτηριστικά και τις μορφές των ψυχικών διαταραχών, στηριζόμενο σε ερευνητικά δεδομένα.

Εμβαθύνοντας στη διαδικασία εκτίμησης της ψυχικής κατάστασης και αξιολόγησης της ψυχικής υγείας ενός ατόμου, αυτή μπορεί να χαρακτηριστεί ως πολύπλοκη και χρονοβόρα. Αυτό συμβαίνει, διότι αποτελείται από ένα πλήθος βημάτων, το οποίο μάλιστα δεν είναι σταθερό ή προκαθορισμένο, αλλά ποικίλει και μεταβάλλεται ανάλογα με την εκάστοτε κλινική. Ο πιο διαδεδομένος και ευρέως χρησιμοποιούμενος τρόπος για τη διάγνωση και την εκτίμηση μιας ψυχικής διαταραχής είναι η πραγματοποίηση ατομικών συνεδριών και η συμπλήρωση ενδεδειγμένων ερωτηματολογίων (Assessments and evaluations for mental illness treatment, 2015), (Mental health: What's normal, what's not, 2019)).

Κατά κύριο λόγο, η πρώτη επαφή με κάποιον ειδικό γίνεται υπό τη μορφή συνεδρίας, διάρκειας μιας έως δύο ωρών. Ο εν δυνάμει ασθενής, αρχικά, παρουσιάζει τους προβληματισμούς και τις σκέψεις του, καθώς και ό,τι τον απασχολεί σχετικά με τα συμπτώματα που παρατηρεί. Στη συνέχεια, ο ψυχίατρος ή ψυχολόγος πραγματοποιεί συγκεκριμένες ερωτήσεις με σκοπό να αντλήσει τις κατάλληλες πληροφορίες που θα τον οδηγήσουν σε μια πρώτη διάγνωση. Οι ερωτήσεις αυτές μπορεί να αφορούν το ιστορικό τόσο του ίδιου του εξεταζόμενου όσο και της οικογένειάς του, καθώς και τυχόν φαρμακευτικές αγωγές που λάμβανε ή εξακολουθεί να λαμβάνει ο ίδιος. Κατά τη διάρκεια της συνεδρίας ο εξετάζων παρατηρεί προσεκτικά τον τρόπο με τον οποίο ο ασθενής δρα, συμπεριφέρεται και απαντά, προκειμένου να εντοπίσει κάποιο συγκεκριμένο, πιθανώς κρυμμένο, χαρακτηριστικό που να συνδέεται με τα συμπτώματα. Συνήθως, ζητείται η συμπλήρωση ενός εγκεκριμένου ερωτηματολογίου ή φόρμας εκτίμησης, ώστε μέσω μιας πληθώρας ερωτήσεων να εξαχθούν με εγκυρότητα τα απαραίτητα στοιχεία.

Μετά το πέρας της πρώτης συνεδρίας, στην πλειονότητα των περιπτώσεων ζητείται από τον ασθενή να πραγματοποιήσει ορισμένες παθολογικές εξετάσεις. Οι εξετάσεις αυτές μπορεί να έχουν τη μορφή εξετάσεων αίματος, εγκεφαλογραφήματος, μαγνητικής τομογραφίας και άλλων, ανάλογα με τα συμπτώματα. Ο λόγος για τον οποίο κρίνονται απαραίτητες, είναι για να αποκλειστεί το ενδεχόμενο κάποιας ασθένειας παθολογικής φύσεως, καθώς έχει

παρατηρηθεί πως πολλά συμπτώματα που πηγάζουν από παθολογικές νόσους μπορεί να παραπέμπουν και σε ψυχικές ασθένειες.

Εκτός από τον ίδιο τον ασθενή, ο ειδικός πραγματοποιεί συνεδρίες και με πρόσωπα που βρίσκονται στο στενό κύκλο του εξεταζόμενου, όπως για παράδειγμα μέλη της οικογένειάς του ή φίλους. Αυτό έχει ως σκοπό την άντληση πληροφοριών, που πιθανώς να μην έχουν δοθεί από τον ίδιο τον ασθενή, ή λεπτομερειών για την κατάστασή του υπό ένα διαφορετικό πρίσμα. Επιτυγχάνεται με αυτόν τον τρόπο μια βαθύτερη μελέτη της περίπτωσης του εξεταζόμενου ατόμου, η οποία με τη σειρά της θα οδηγήσει σε μια πιο σαφή και πλήρη εικόνα για την ψυχική κατάστασή του.

Αν μετά την ολοκλήρωση των παραπάνω βημάτων, θεωρηθεί ότι ο εξεταζόμενος διαθέτει κάποια ψυχική διαταραχή, τότε ακολουθεί η διαδικασία θεραπείας αυτής. Συγκεκριμένα, όσον αφορά τον τρόπο θεραπείας μιας ψυχικής ασθένειας πιο συχνά επιλέγεται η ψυχοθεραπεία, είτε αυτή συνοδεύεται από κάποια φαρμακευτική αγωγή είτε όχι (What is Psychotherapy?, 2019). Η ψυχοθεραπεία προϋποθέτει τη συνεχή και ανά τακτά χρονικά διαστήματα παρακολούθηση από κάποιον ψυχοθεραπευτή ή ψυχίατρο. Η παρακολούθηση αυτή έχει τη μορφή συνεδριών, όπου κάθε φορά πραγματοποιείται εκ νέου η εκτίμηση της ψυχικής υγείας του ασθενή, ώστε να εντοπίζεται κάθε αλλαγή και να αποτυπώνεται η βελτίωση αυτής. Κατά την ψυχοθεραπεία ο ασθενής έχει εξίσου ενεργό ρόλο με τον ψυχοθεραπευτή καθώς πρέπει να έχει επίγνωση, όσο αυτό είναι δυνατό, των συναισθηματικών καταστάσεων και των εμπειριών που βιώνει και εν συνεχεία να μπορεί να τις μεταφέρει με τη μικρότερη δυνατή απόκλιση από την πραγματικότητα στον ψυχοθεραπευτή του.

Πιο συγκεκριμένα, αξίζει να γίνει αναφορά σε μια εκ των διαφόρων τύπων ψυχοθεραπείας, την γνωσιακή συμπεριφορική ψυχοθεραπεία (cognitive behavioural therapy, CBT). Η μέθοδος αυτή εστιάζει στον εντοπισμό αρνητικών συμπεριφορών και συναισθημάτων και στόχο έχει την αντιμετώπιση και αντικατάσταση αυτών με νέες αντικειμενικές και θετικές σκέψεις. Αποτελεί μια ψυχοθεραπευτική μέθοδο με υψηλά ποσοστά επιτυχίας σε ψυχικές ασθένειες σχετιζόμενες με άγχος, αδυναμία διαχείρισης θυμού, διατροφικές διαταραχές, κατάθλιψη και άλλα (Hofmann, Asnaani, Vonk, Sawyer, & Fang, 2012). Η αποτελεσματικότητα της CBT μεθόδου έχει αποδειχθεί τόσο στη συμβατική της μορφή, δηλαδή όταν ψυχοθεραπευτής και ασθενής βρίσκονται στον ίδιο φυσικό χώρο, όσο και εξ αποστάσεως, με τη βοήθεια του ίντερνετ και της τεχνολογίας (Kumar, Sattar, Bseiso, Khan, & Rutkofsky, 2017). Η εφαρμογή της ICBT (Internet-based CBT) μάλιστα έχει ιδιαίτερη αξία την περίοδο που διανύουμε, δεδομένης της ευρείας χρήσης του ίντερνετ και της ευκολίας που αυτό παρέχει στον ασθενή για θεραπεία από την ασφάλεια του σπιτιού του.

Κατά τη CBT ο ασθενής αποκτά ενεργό ρόλο στη θεραπεία του και πέραν του πλαισίου των συνεδριών. Συγκεκριμένα μπορεί να κληθεί να πραγματοποιεί καθημερινά ασκήσεις, όπως ασκήσεις ηρεμίας, διατήρηση ημερολογίου καθώς και να καταγράφει και να αναγνωρίζει την ύπαρξη δυσλειτουργικών συναισθημάτων και σκέψεων (Tsitsas & Paschali, 2014).

Απαραίτητη προϋπόθεση για τις παραπάνω ενέργειες αποτελεί η δυνατότητα του ασθενή να μπορεί να παρακολουθεί ο ίδιος τον εαυτό του, να έχει επίγνωση των συναισθηματικών του διακυμάνσεων και ιδανικά να μπορεί να τις αναγνωρίσει, ώστε να τις καταγράψει επιτυχώς.

### 2.1.2. Ανάγκη στήριξης σε αντικειμενικά δεδομένα

Τόσο στη διαδικασία της διάγνωσης, όσο και σε αυτή της θεραπείας εντοπίζονται ορισμένοι παράγοντες, οι οποίοι ενδέχεται να αποτελέσουν πηγές κινδύνων για τη επιτυχή ολοκλήρωση των διαδικασιών (Wilhelm & Grossman, 2010). Όπως προαναφέρθηκε, κύριο χαρακτηριστικό της διάγνωσης, εξαιρώντας τις παθολογικές εξετάσεις, αποτελεί η επαφή του γιατρού με τον ασθενή και η εις βάθος συζήτηση για την εξαγωγή πληροφοριών από αυτόν. Αντίστοιχα, κατά τη διαδικασία της θεραπείας, εκτός από τις συζητήσεις μεταξύ ειδικού και ασθενή, ο τελευταίος καλείται να πραγματοποιεί συνεχή ενδοσκόπηση προκειμένου να μπορεί να αντιλαμβάνεται και να καταγράφει την ψυχική του κατάσταση και τα συναισθήματά του.

Η προσέγγιση αυτή, ωστόσο, ενέχει κάποιους σημαντικούς κινδύνους, που είναι πιθανό να φθείρουν την αξιοπιστία των δεδομένων και κατά συνέπεια των συμπερασμάτων.

- Η οπτική γωνία υπό την οποία δίνονται οι πληροφορίες αποτελεί την πρώτη και ίσως σημαντικότερη μορφή κινδύνου (Oswald & Grosjean, 2004):
  - Ο ασθενής καλείται να διηγηθεί περιστατικά που του συνέβησαν, καθώς και συμπτώματα τα οποία παρατηρεί και αισθάνεται. Στη διαδικασία αυτή παρεμβάλλεται ο παράγοντας της προσωπικής αντίληψης, που ενδέχεται να αλλοιώσει σε σημαντικό βαθμό την αντικειμενικότητα στην αφήγηση των γεγονότων. Έτσι, υπάρχει η πιθανότητα ο γιατρός να οδηγηθεί σε εσφαλμένα συμπεράσματα, κρίνοντας, για παράδειγμα, ότι ο εξεταζόμενος δεν χρήζει κάποιας βοήθειας, ενώ στην πραγματικότητα αυτή καθίσταται αναγκαία.
  - Το συγκεκριμένο πρόβλημα εντοπίζεται και στην περίπτωση των πληροφοριών που παρέχουν τα κοντινά πρόσωπα του ασθενή, καθώς αυτοί μπορεί να υπάρξουν μεροληπτικοί. Για παράδειγμα, μπορεί να φανούν ιδιαίτερα επιεικείς ή επικριτικοί με την κατάστασή του, παρουσιάζοντας διαστρεβλωμένα ορισμένα στοιχεία, καθότι τα θεωρούν ανούσια ή σημαντικά, αντίστοιχα. Ακόμη, ενδέχεται να μη θεωρούν τους εαυτούς τους ως παράγοντες επιρροής για τον ασθενή και την ψυχική του διάθεση, με αποτέλεσμα να αποκρύπτουν στοιχεία της καθημερινής επαφής μαζί του ή άθελά τους να τα παραποιούν.
- Μια δεύτερη πηγή κινδύνου, που μπορεί να οδηγήσει σε αλλοιώσεις, είναι η ανάγκη για αναδρομική ανάκληση των γεγονότων από τον εξεταζόμενο (Bradburn, Rips, & Shevell, 1987). Ο τελευταίος καλείται, στο πλαίσιο της διαδικασίας των συνεδριών και της συμπλήρωσης ερωτηματολογίων, να διηγηθεί και να περιγράψει συμβάντα και

καταστάσεις που έχουν λάβει χώρα στο παρελθόν. Ενδέχεται, επομένως, να επηρεαστεί από διάφορους παράγοντες, όπως πιο πρόσφατα γεγονότα, υποκειμενικές αντιλήψεις και κοινωνικά στερεότυπα, και να παραποιήσει το τι πραγματικά συνέβη. Επίσης, υπάρχει και η πιθανότητα αδυναμίας πλήρους ανάκλησης των γεγονότων στη μνήμη του ασθενή. Για παράδειγμα, μπορεί να μη θυμάται πλήθος λεπτομερειών ή και ολόκληρα μέρη ενός περιστατικού, με αποτέλεσμα να αποκρύπτει ακούσια σημαντικές πληροφορίες.

- Ο τελευταίος κίνδυνος εντοπίζεται στην περίπτωση, κατά την οποία ο υπό εξέταση ασθενής πάσχει από περισσότερες από μία, και συχνά πολύπλοκης φύσεως, παθήσεις. Συγκεκριμένα, καθίσταται ιδιαίτερα δύσκολη η προσέγγιση και η μελέτη περιπτώσεων ατόμων, που παρουσιάζουν δυσκολίες στην επικοινωνία και στην αποτύπωση των σκέψεων και των συναισθημάτων τους. Χαρακτηριστικό παράδειγμα αποτελούν άτομα που αναγνωρίζονται με κάποια μορφή αυτιστικής διαταραχής, τα οποία αδυνατούν να επικοινωνήσουν τα συναισθήματά τους και να συμμετάσχουν σε έναν παραγωγικό διάλογο με τον ψυχοθεραπευτή. Άλλη μια περίπλοκη και ιδιαίτερη περίπτωση συνιστούν τα άτομα που διακρίνονται από περιορισμένη νοητική ικανότητα, καθώς υπολείπονται της δυνατότητας να εκφράσουν αποδοτικά σκέψεις και να ανακαλέσουν συμβάντα. Υπό αυτές τις συνθήκες τα δεδομένα που λαμβάνονται είναι περιορισμένης αξίας και απαιτείται αυξημένος κόπος και προσπάθεια για την εξαγωγή ασφαλών συμπερασμάτων που θα οδηγήσουν στη σωστή διάγνωση και μετέπειτα θεραπεία.

Η αβεβαιότητα που προκύπτει από τους παραπάνω παράγοντες δυσχεραίνει την παρακολούθηση του ασθενή τόσο από τον ψυχοθεραπευτή όσο και από τον ίδιο του τον εαυτό. Ο πρώτος πρέπει να μπορεί να φτάνει σε ασφαλή συμπεράσματα για την ψυχική κατάσταση του ασθενή και ο δεύτερος πρέπει να έχει τη δυνατότητα να αντιλαμβάνεται αν βιώνει κάποιο συναίσθημα και να μπορεί να το αναγνωρίσει. Προκειμένου να ελαχιστοποιηθεί αυτή η αβεβαιότητα κρίνεται απαραίτητη η υποβοήθηση από αντικειμενικά δεδομένα, πηγή των οποίων, όπως θα αναλυθεί παρακάτω αποτελούν τα βιοσήματα.

### **2.1.3. Βιοσήματα και ψυχική υγεία**

Για την παράκαμψη των κινδύνων που προαναφέρθηκαν είναι αναγκαία η αξιοποίηση αντικειμενικών δεδομένων, που είναι δύσκολο έως αδύνατο να παρερμηνευτούν. Δεδομένα τέτοιας φύσεως αποτελούν τα βιοσήματα, που μπορούν να προκύψουν από τη φυσιολογία του ατόμου και τον τρόπο που αυτή μεταβάλλεται κατά τις ψυχικές και συναισθηματικές διακυμάνσεις του. Λόγω του ότι αποτελούν αντιδράσεις του αυτόνομου νευρικού συστήματος απέναντι σε ερεθίσματα, ο άνθρωπος δεν έχει τη δυνατότητα να τα ελέγξει και να τα παραποιήσει κατά βούληση. Έχοντας ο ψυχοθεραπευτής στα χέρια του τα δεδομένα αυτά, έχει τη δυνατότητα να τα αντιπαραβάλλει με τις μαρτυρίες που έχει συλλέξει από τον

ίδιο τον εξεταζόμενο και το στενό του περιβάλλον, εξετάζοντας με αυτόν τον τρόπο την εγκυρότητά τους, ώστε να καταλήξει σε πιο ακριβή συμπεράσματα. Επιπρόσθετη βοήθεια, ωστόσο, που θα ενίσχυε την εγκυρότητα ενός πορίσματος, θα μπορούσε να αντληθεί μέσω ενός έξυπνου συστήματος. Εισάγοντας αυτά τα δεδομένα σε ένα υπολογιστικό σύστημα, αυτό θα μπορούσε να πραγματοποιήσει μια επιπλέον διάγνωση, ώστε να υποβοηθήσει αυτή του ψυχοθεραπευτή, βελτιώνοντας έτσι την αξιοπιστία του τελικού συμπεράσματος (Valenza & Scilingo, 2017).

Παρακάτω αναφέρονται κάποια από τα πολύ βασικά βιοσήματα, τα οποία έχουν συνδεθεί με ορισμένες ψυχικές καταστάσεις. Τα δεδομένα που προκύπτουν από τις αντιδράσεις του ανθρώπινου σώματος έχουν αξιοποιηθεί για την αναγνώριση συναισθημάτων σε πληθώρα ερευνών.

- Δραστηριότητα των ματιών (EOG): Πρόκειται για ένα από τα κυριότερα χαρακτηριστικά στα οποία εστιάζουν και οι ίδιοι οι άνθρωποι από τη φύση τους, όταν προσπαθούν να εκτιμήσουν τη συναισθηματική κατάσταση κάποιου άλλου (Schurgin, et al., 2014). Στη δραστηριότητα των ματιών περιλαμβάνονται τόσο οι κινήσεις του βολβού, όσο και οι εκφράσεις του προσώπου στην περιοχή γύρω από αυτά. Καθότι, όμως, οι κινήσεις αυτές μπορεί να υποκινηθούν ή να περιοριστούν συνειδητά, ως ένα βαθμό, από το υποκείμενο μελέτης, οι μελετητές έχουν στρέψει την προσοχή τους προς τις αντιδράσεις της κόρης του ματιού. Η αλλαγή του μεγέθους της προέρχεται από την αντίδραση του αυτόνομου νευρικού συστήματος του ατόμου, με αποτέλεσμα να μην μπορεί να ελεγχθεί συνειδητά. Οι μεταβολές της κόρης του ματιού έχουν συνδεθεί με τη συναισθηματική διέγερση και πιο συγκεκριμένα, η διαστολή υποδηλώνει αυξημένη διέγερση, είτε πρόκειται για αρνητικό είτε για θετικό συναίσθημα (Bradley, Miccoli, Escrig, & Lang, 2008).
- Ηλεκτροδερματική δραστηριότητα (EDA): Το σήμα αυτό ποσοτικοποιεί την ηλεκτρική δραστηριότητα του δέρματος και απαντάται στη βιβλιογραφία και με την ονομασία γαλβανική απόκριση δέρματος (GSR). Μεταβολές στο σήμα προκύπτουν λόγω της εφίδρωσης του ανθρώπινου σώματος και υποδεικνύουν την ένταση της συναισθηματικής κατάστασης στην οποία αυτό βρίσκεται. Σε ερευνητικό επίπεδο, η ηλεκτροδερματική δραστηριότητα έχει συνδεθεί με πληθώρα ψυχικών διαταραχών, καθώς η επιρρέπεια ενός ατόμου στη μεταβολή του σήματος εξαρτάται σημαντικά από την ψυχική του κατάσταση (Öhman, 1981), (Greco, Valenza, Lanata, Rota, & Scilingo, 2014)). Ενδεικτικά, έχει αξιοποιηθεί εκτεταμένα σε έρευνες για τον εντοπισμό και την αναγνώριση άγχους (Anusha, et al., 2019). Το συγκεκριμένο βιολογικό σήμα αναλύεται εκτενέστερα στο 3ο Κεφάλαιο.
- Ηλεκτροεγκεφαλογράφημα: Μια πολύ σημαντική πηγή βιολογικών σημάτων αποτελεί η ηλεκτρική δραστηριότητα του εγκεφάλου. Παρόλο που δεν μπορεί να θεωρηθεί ως αντίδραση του σώματος απέναντι σε ερεθίσματα, όπως ακριβώς τα προηγούμενα βιοσήματα, η εγκεφαλική λειτουργία προσφέρει τη δυνατότητα αποκωδικοποίησης της κατάστασης της φυσιολογίας του υποκειμένου μελέτης. Η συλλογή αυτών των



βιοσημάτων γίνεται μέσω της διαδικασίας της ηλεκτροεγκεφαλογραφίας και έχει χρησιμοποιηθεί σε πολλές περιπτώσεις για να βοηθήσει έναν υπολογιστή να κατανοήσει τη συναισθηματική κατάσταση του χρήστη του. Η ικανότητά του ηλεκτροεγκεφαλογραφήματος να προσφέρει την απαραίτητη πληροφορία για την αναγνώριση συναισθημάτων έχει φανεί από πλήθος σχετικών ερευνών ( (Wang, Nie, & Lu, 2014), (Nie, Wang, Shi, & Lu, 2011)).

- Εκφράσεις προσώπου, Αναγνώριση φωνής: Τέλος, αξίζει να αναφερθούν δύο χαρακτηριστικά, τα οποία έχει αποδειχθεί ότι σχετίζονται σε μεγάλο βαθμό με συναισθηματικές καταστάσεις αλλά είναι επιρρεπή στην ικανότητα του υποκειμένου μελέτης να τα ελέγχει. Πρόκειται για τις εκφράσεις του προσώπου και την αναγνώριση μεταβολών στη φωνή.
  - Όσον αφορά τις εκφράσεις του προσώπου, οι Ekman και Friesen ανέπτυξαν το Facial Action Coding System (FACS) (Ekman & Friesen, 1978) για τη μέτρηση και τη μοντελοποίηση της δραστηριότητας του προσώπου. Το σύστημα αυτό αξιοποιείται ώστε να συνδέονται αυτόματα ορισμένα μοτίβα των κινήσεων του προσώπου με συναισθηματικές καταστάσεις (Calvo & D'Mello, 2010).
  - Η αναγνώριση μεταβολών στη φωνή και την ομιλία προσφέρει, επίσης, τη δυνατότητα εξαγωγής συμπερασμάτων για τη διάθεση ενός ανθρώπου. Η χρησιμότερη πληροφορία περιέχεται στα παραγλωσσικά χαρακτηριστικά της ομιλίας, δηλαδή στον τρόπο με τον οποίο λέγεται κάτι. Πιο συγκεκριμένα, ο τόνος της φωνής έχει αποδειχθεί ότι επηρεάζεται από τη συναισθηματική διέγερση του ατόμου και την ένταση του συναισθήματος (Calvo & D'Mello, 2010).

Αξίζει να σημειωθεί ότι στη συντριπτική πλειοψηφία των διαθέσιμων ερευνών με αντικείμενο την αναγνώριση συναισθημάτων ή την εκτίμηση ψυχικών διαταραχών, συλλέγονται δεδομένα από περισσότερα του ενός βιοσήματα. Αυτό συμβαίνει διότι η βίωση ενός συναισθήματος επιφέρει μεταβολές σε πλήθος παραγόντων της φυσιολογίας του ανθρώπινου σώματος, προκειμένου αυτό να αντιμετωπίσει κατάλληλα την αιτία που το προκάλεσε (Ekman P. , 1992). Έτσι, η χρήση πολλαπλών πηγών βιολογικών δεδομένων εγγυάται μεγαλύτερη ακρίβεια στην αναγνώριση ενός συναισθήματος.

## ***2.2 Μέθοδοι και περιβάλλοντα συλλογής βιολογικών δεδομένων***

### ***2.2.1 Το εργαστηριακό περιβάλλον***

Παραδοσιακά και ειδικά στα πλαίσια ερευνών, ακόμα και σήμερα, η συλλογή βιολογικών δεδομένων πραγματοποιείται σε κλειστούς ελεγχόμενους χώρους, όπως εργαστήρια ή ιατρεία. Αυτή η συλλογή δεδομένων μπορεί να αξιοποιηθεί σε δύο περιπτώσεις. Η πρώτη, πιο απλή, περίπτωση, είναι η προσπάθεια διάγνωσης κάποιας ψυχικής ασθένειας, οπότε και

υποκείμενο μελέτης είναι ο ίδιος ο εν δυνάμει ασθενής. Η δεύτερη περίπτωση είναι η διεξαγωγή έρευνας, όπου μελετάται κάποια ψυχική διαταραχή καθώς και οι επιπτώσεις που έχει στον άνθρωπο. Για να πραγματοποιηθεί η έρευνα συλλέγονται τα βιοσήματα από ένα προκαθορισμένο αριθμό εξεταζόμενων, που συνήθως βρίσκονται σε παρόμοια ψυχική κατάσταση. Εάν η έρευνα έχει στόχο τη μελέτη διαφορών αυτού του δείγματος με τα υγιή επίπεδα, τότε επιλέγεται μια επιπλέον ομάδα ατόμων που έχει κριθεί ως υγιής και ονομάζεται “control group”. Έτσι, επιδιώκεται η σύγκριση και η επισήμανση διαφορών στις συναισθηματικές αντιδράσεις απέναντι σε ποικιλία ερεθισμάτων.

Στο πλαίσιο του εργαστηριακού περιβάλλοντος, για την πρόκληση συναισθημάτων σε ένα άτομο και για τον έλεγχο των συναισθηματικών του μεταβολών ακολουθείται πάντα κάποια εμπειριστατωμένη και προκαθορισμένη διαδικασία. Κατά τη διαδικασία αυτή υπάρχει η δυνατότητα αξιοποίησης πλήθους μορφών ερεθισμάτων, προκειμένου να επηρεαστεί η ψυχική διάθεση του εξεταζόμενου. Η πιο χαρακτηριστική μορφή οπτικών ερεθισμάτων που χρησιμοποιείται είναι μια εξαιρετικά μεγάλη συλλογή εικόνων, επιλεγμένων κατάλληλα για τη δυνατότητά τους να προκαλούν συγκεκριμένα συναισθήματα. Η συλλογή αυτή ονομάζεται International Affective Picture System (IAPS) (Lang, Bradley, Cuthbert, & others, 1997) και οι εικόνες που περιέχει διαθέτουν τιμές για τα επίπεδα “συναισθηματικής δραστηριότητας” (emotional valence), από δυσάρεστο έως ευχάριστο, και “διέγερσης” (arousal), από ηρεμία έως ενθουσιασμό. Ομοίως με τη συλλογή εικόνων, μπορεί να επιλεγθεί και μια συλλογή από ήχους, γνωστή ως International Affective Digital Sounds (IADS) (Bradley & Lang, Affective reactions to acoustic stimuli, 2000), που βάσει έρευνας έχει διαπιστωθεί ότι οδηγούν στην πρόκληση προκαθορισμένων συναισθημάτων. Επιπρόσθετα, ως μέσο πρόκλησης συναισθημάτων μπορούν να χρησιμοποιηθούν και κάποια συγκεκριμένα αποσπάσματα εμπορικών ταινιών. Τέλος, μπορεί να επιλεγούν ορισμένα τεστ άγχους, που ως στόχο τους έχουν να δημιουργήσουν ψυχική πίεση, προσομοιώνοντας ερεθίσματα που μπορεί να βιώσει ο εξεταζόμενος στην καθημερινή του ζωή. Χαρακτηριστικά, το άτομο μπορεί να κληθεί να επιλύσει τεστ λογικής ή να συμμετάσχει σε κάποια άβολη ή έντονη κοινωνική αλληλεπίδραση.

Μέχρι πρόσφατα ήταν ιδιαίτερα δύσκολη η συλλογή σημάτων εκτός του περιβάλλοντος ενός εργαστηρίου καθώς δεν το επέτρεπε η τεχνολογία. Οι συσκευές δεν ήταν αρκετά μικρές και εύχρηστες ώστε να μην εμποδίζουν τον χρήστη στην καθημερινότητά του. Το πρόβλημα αυτό πλέον λύνεται με την ανάπτυξη της τεχνολογίας και των wearable συσκευών. Έτσι, ο βασικός λόγος για τον οποίο τέτοιες διαδικασίες συνεχίζουν να πραγματοποιούνται κυρίως στον κλειστό χώρο ενός εργαστηρίου ή ενός ιατρείου, είναι η ασφάλεια και ο έλεγχος που παρέχει το περιβάλλον αυτό. Αυτό οφείλεται στην ύπαρξη πλήρους εποπτείας των διαδικασιών από τον μελετητή ή το γιατρό. Οι επιβλέποντες μπορούν να επιβεβαιώνουν ανά πάσα στιγμή την ομαλή και επιτυχημένη διεξαγωγή της εξέτασης. Έτσι, έχουν τη δυνατότητα να ελέγχουν τόσο την τήρηση των κανονισμών που έχουν συμφωνηθεί, όσο και να διορθώνουν τυχόν αποκλίσεις από αυτούς.

### 2.2.2. Το καθημερινό περιβάλλον


Με την πάροδο των χρόνων εντοπίστηκε η ανάγκη για παρακολούθηση και συλλογή δεδομένων εκτός περιβάλλοντος εργαστηρίου, σε συνθήκες καθημερινής ζωής (Wilhelm & Grossman, 2010). Οι πρώτες προσπάθειες έγιναν για την παρακολούθηση προβλημάτων σωματικής υγείας, ενώ ακολούθησε η εκμετάλλευση των δεδομένων αυτών για ζητήματα ψυχικής υγείας. Η επιτακτικότητα της ανάγκης για τέτοιου είδους κινητά (ambulatory) δεδομένα έχει οδηγήσει στην πραγματοποίηση πολλών προσπαθειών προς αυτή την κατεύθυνση. Σημαντικά έχουν ωφελήσει και οι τεχνολογικές εξελίξεις, λόγω χάρη η βελτίωση της ακρίβειας των αισθητήρων και η μείωση του μεγέθους των συσκευών αυτών για πιο άνετη καθημερινή χρήση.



Εικόνα 2.2: Οι διαφορετικοί τύποι wearable συσκευών

Η καταγραφή των περισσότερων από τα βιολογικά σήματα που αναφέρθηκαν στην υποενότητα 2.1.3 είναι πλέον εφικτή και στο φυσικό περιβάλλον. Η συλλογή τους πραγματοποιείται μέσω εύχρηστων φορητών συσκευών, τις οποίες φοράει ο χρήστης στο σώμα του καθόλη τη διάρκεια της ημέρας, χωρίς να εμποδίζονται οι δραστηριότητες της καθημερινότητάς του (Haghi, Thurow, & Stoll, 2017). Οι φορητές wearable συσκευές καταγράφουν συνεχώς δεδομένα που απεικονίζουν τα ερεθίσματα και τις αντιδράσεις του ατόμου, όπως εμφανίζονται στη φυσιολογική του ζωή. Η πιο χαρακτηριστική και συχνά χρησιμοποιούμενη συσκευή κινητής καταγραφής βιολογικών δεδομένων είναι το βραχιόλι.

Ενδεικτικά, το βραχιόλι έχει αξιοποιηθεί για τη μέτρηση καρδιακών παλμών και πίεσης, μέσω φωτοπληθυσμογραφίας, ηλεκτροδερματικής δραστηριότητας και θερμοκρασίας σώματος. Ένα, επίσης, αξιοσημείωτο σύστημα κινητής καταγραφής είναι το σύστημα LifeShirt (Grossman, 2004), το οποίο έχει δημιουργηθεί για την παρακολούθηση του καρδιαγγειακού και αναπνευστικού συστήματος.



**Εικόνα 2.3: Το παράδειγμα του Lifeshirt**

Υπάρχουν, ωστόσο, ακόμα δυσκολίες στην καταγραφή κάποιων βιοσημάτων και γενικότερα ενδείξεων του ανθρώπινου σώματος εκτός του εργαστηριακού περιβάλλοντος. Ορισμένοι αισθητήρες συλλογής δεδομένων είναι πολύ δύσκολο έως αδύνατο να ενσωματωθούν μέσα σε φορητές συσκευές και να μεταφερθούν σε φυσικό, καθημερινό περιβάλλον. Για παράδειγμα έχουν πραγματοποιηθεί προσπάθειες για την παρακολούθηση των κινήσεων των ματιών, μέσω ειδικών συσκευών, χωρίς όμως απόλυτη επιτυχία, καθώς η συσκευή δεν περνά απαρατήρητη από τον περίγυρο του χρήστη και το μέγεθός της δεν την καθιστά εύχρηστη (Vidal, Turner, Bulling, & Gellersen, 2012).

Στις περιπτώσεις ερευνών, όπου τα απαιτούμενα δεδομένα είναι εφικτό να συλλεχθούν από το καθημερινό περιβάλλον των υποκειμένων μελέτης, εξαλείφονται διάφοροι αρνητικοί παράγοντες που σχετίζονται με το περιβάλλον του εργαστηρίου (Wilhelm & Grossman, 2010). Αρχικά, ο πιο βασικός από τους παράγοντες σχετίζεται με τη φυσικότητα των αιτιών, τα οποία προκαλούν τις συναισθηματικές διακυμάνσεις που αναμένεται να παρατηρηθούν. Πιο συγκεκριμένα, τα τεχνητά ερεθίσματα στα οποία υποβάλλεται το υποκείμενο μελέτης στο εργαστήριο δεν συνάδουν σε απόλυτο βαθμό με εκείνα που συναντά στην καθημερινότητα. Έτσι, θα μπορούσε να θεωρηθεί πως ορισμένες ψυχικές καταστάσεις εκβιάζονται, με αποτέλεσμα αυτές να μην αποτυπώνονται σωστά στα βιολογικά δεδομένα

που συλλέγονται. Αυτό δύναται να οδηγήσει σε παρερμηνείες και λανθασμένες εκτιμήσεις σχετικά με τις αντιδράσεις του εξεταζόμενου. Επιπλέον, διαφορά υπάρχει και στη χρονική διάρκεια των δεδομένων που καταγράφονται. Οι πληροφορίες για τις διακυμάνσεις της ψυχικής διάθεσης του εξεταζόμενου δεν περιορίζονται στο συγκεκριμένο χρονικό πλαίσιο της επίσκεψής του στο εργαστήριο ή το ιατρείο, αλλά το διάστημα καταγραφής τους κυμαίνεται από κάποιες ώρες έως και πολλές ημέρες. Επιτυγχάνεται κατ' αυτόν τον τρόπο η συλλογή λεπτομερειών σε βάθος χρόνου, περιλαμβάνοντας πιθανώς μια ποικιλία συμβάντων που δύναται να αποτυπώσει με μεγαλύτερη αξιοπιστία την ψυχογραφία του υποκειμένου. Τέλος, το περιβάλλον του εργαστηρίου, όντας άγνωστο στον ασθενή και σε κάποιες περιπτώσεις αφιλόξενο, ενδέχεται να τον προδιαθέσει αρνητικά. Για παράδειγμα, εάν η μελέτη πραγματοποιείται σε ασθενείς που παρουσιάζουν αγχώδεις διαταραχές είναι πιθανό η ίδια η διαδικασία που ακολουθείται να προκαλέσει ανησυχία, οδηγώντας σε μετρήσεις αυξημένου επιπέδου άγχους, ακόμα και αν το υποκείμενο θεωρείται ότι βρίσκεται σε κατάσταση ηρεμίας. Παράγοντες που μπορεί να επιφέρουν τέτοια προδιάθεση είναι ο χώρος διεξαγωγής της μελέτης ή εξέτασης, οι μελετητές, ο εξοπλισμός καταγραφής και η γνώση όσων πρόκειται να συμβούν, οι οποίοι εκλείπουν από τη φύση της καθημερινότητας.

### ***2.3 Προκλήσεις κατά τη συλλογή δεδομένων στο καθημερινό περιβάλλον***

Η έξοδος από τον κλειστό και απομονωμένο χώρο του εργαστηρίου επιβαρύνει τις μετρήσεις με θόρυβο και τις καθιστά, ως ένα βαθμό, αναξιόπιστες. Η συλλογή των δεδομένων ενέχει μια σειρά προκλήσεων, όπως αυτές συνοψίζονται από τους Wilhelm και Grossman (Wilhelm & Grossman, 2010).

Αν και δεν αποκλείεται να έχουν τεθεί ορισμένοι κανόνες για τη διαδικασία των μετρήσεων, η φύση της καθημερινότητας του εξεταζόμενου, εν μέσω της οποίας αυτός λειτουργεί και παράγει δεδομένα, δεν μπορεί να ελεγχθεί απόλυτα. Επομένως, υπάρχει το ενδεχόμενο ο εξεταζόμενος να παρεκκλίνει απ' τις συμφωνηθείσες κατευθυντήριες γραμμές και να μη συμμορφωθεί σε συγκεκριμένες υποδείξεις, υποβαθμίζοντας έτσι την ποιότητα των δεδομένων. Ενδεικτικά, ενέργειες, όπως η κατανάλωση αλκοόλ ή άλλων ουσιών και η έντονη σωματική άσκηση, μπορεί να φέρουν τη φυσιολογία του σε καταστάσεις που δεν αναμένονταν, παραπλανώντας έτσι τους μελετητές. Ο κίνδυνος που περιεγράφηκε οξύνεται στην περίπτωση που το άτομο αποφύγει να ενημερώσει τον μελετητή, ακόμα και εκ των υστέρων, για τις πράξεις αυτές.

Κατά την κινητή συλλογή δεδομένων εισάγεται θόρυβος στο βιοσήμα, που προέρχεται κυρίως από την κίνηση της συσκευής πάνω στο υπό μελέτη άτομο. Ενώ ορισμένες μετρήσεις από το ανθρώπινο σώμα είναι εύκολο να γίνουν σε μη επιβλεπόμενο περιβάλλον, όπως το ηλεκτροκαρδιογράφημα, άλλες είναι ιδιαίτερα επιρρεπείς σε θορύβους, όπως το ηλεκτροεγκεφαλογράφημα και η ηλεκτροδερματική δραστηριότητα. Οι θόρυβοι αυτοί

μπορεί να οφείλονται σε παρεμβολές στο μετρούμενο σήμα που προέρχονται είτε από την ίδια τη συσκευή είτε από τις κινήσεις του ατόμου που τη χρησιμοποιεί. Η συνεχής κίνηση είναι αναπόσπαστο στοιχείο της καθημερινής ζωής ενός ανθρώπου και αυξάνεται σημαντικά σε περιπτώσεις έντονης σωματικής άσκησης. Τα όρια που επιβάλλονται ως προς τη δυνατότητα κίνησης του υπό εξέταση ατόμου όταν βρίσκεται σε συνθήκες εργαστηρίου δεν υφίστανται στην καθημερινότητά του. Έτσι, τα παραγόμενα δεδομένα εμφανίζουν θορύβους, λόγω περιστασιακής αποσύνδεσης της συσκευής με το σώμα ή έντονης τριβής της με αυτό.

Ένα επιπλέον ζήτημα, που τίθεται κατά τη συλλογή δεδομένων σε συνθήκες καθημερινότητας, είναι η συχνότητα εμφάνισης των γεγονότων που αναζητά ο ερευνητής. Στο πλαίσιο του εργαστηρίου η παροχή ερεθισμάτων είναι δεδομένη και η συχνότητά τους εκ των προτέρων γνωστή, οπότε αναμένεται και η πρόκληση της επιθυμητής αντίδρασης του υποκειμένου μελέτης. Στην καθημερινή ζωή, ωστόσο, είναι πιθανό τα ερεθίσματα αυτά να εμφανίζονται αρκετά σπάνια, έως και καθόλου, με αποτέλεσμα να εκλείπουν και οι επιθυμητές παρατηρήσεις. Χαρακτηριστικό παράδειγμα αποτελούν οι κρίσεις πανικού. Ο εν δυνάμει ασθενής μπορεί ακόμα και για ημέρες να μην έρθει σε επαφή με κάποιον στρεσογόνο παράγοντα, ο οποίος να του προκαλέσει κάποια κρίση, που αποτελεί και τον λόγο για τον οποίο γίνεται εξ αρχής η παρακολούθηση. Η σποραδικότητα ή ακόμα και απουσία παρατηρήσεων στο διάστημα εντός του οποίου πραγματοποιούνται οι μετρήσεις, μπορεί να οδηγήσουν εσφαλμένα στο συμπέρασμα ότι ο εξεταζόμενος δεν χαρακτηρίζεται από κάποια ψυχική διαταραχή.

Τέλος, κατά τη διάρκεια καταγραφής δεδομένων εκτός του περιβάλλοντος του εργαστηρίου κρίνεται εξαιρετικά επιζήμια για την αξιοπιστία της μελέτης η άγνοια του πλαισίου και των όσων συμβαίνουν στο περιβάλλον του υποκειμένου της έρευνας. Λόγω του ότι δεν είναι εκ των προτέρων γνωστές η στιγμή και η διάρκεια εμφάνισης ερεθισμάτων, είναι αμφιλεγόμενο το αν μια μέτρηση συνιστά πράγματι συναισθηματική διέγερση. Για παράδειγμα, μπορεί να παρατηρηθεί αύξηση παλμών, θερμοκρασίας δέρματος και ηλεκτροδερματικής δραστηριότητας, στοιχεία που παραπέμπουν σε κατάσταση άγχους, ενώ όμως το άτομο βρίσκεται σε κατάσταση έντονης σωματικής άσκησης, για την οποία έχει παραλήψει να ενημερώσει. Φαίνεται, επομένως, ότι τα εν κινήσει δεδομένα είναι ιδιαίτερα επιρρεπή σε παρερμηνεία, η οποία μπορεί τελικά να οδηγήσει και σε λανθασμένη διάγνωση.

## Κεφάλαιο 3

### 3. Το πρόβλημα του θορύβου στο σήμα της Ηλεκτροδερματικής Δραστηριότητας

#### 3.1 Το σήμα της ηλεκτροδερματικής δραστηριότητας

##### 3.1.1 Ορισμός και ιστορική αναδρομή

Ο όρος ηλεκτροδερματική δραστηριότητα (Electrodermal Activity - EDA) έχει εδραιωθεί για να περιγράφει τις ηλεκτρικές ιδιότητες του δέρματος. Στις περισσότερες περιπτώσεις τίθεται για να αναπαραστήσει την αγωγιμότητα του δέρματος και γι' αυτόν τον λόγο συναντάται στη βιβλιογραφία και ως Skin Conductance. Ένας επιπλέον όρος που χρησιμοποιείται ευρέως για την περιγραφή του μεγέθους αυτού είναι η γαλβανική απόκριση δέρματος (Galvanic Skin Response - GSR). Ωστόσο, σύμφωνα με τον Boucsein (Boucsein, 2012) ο όρος αυτός ενδέχεται να είναι παραπλανητικός, καθώς υπονοεί ότι το μέγεθος αυτό μετρά αποκλειστικά κάποιου είδους αντίδραση σε ερεθίσματα, ενώ στην πραγματικότητα είναι πιο σύνθετο, όπως θα αναλυθεί παρακάτω.


Οι μεταβολές που παρατηρούνται στις μετρήσεις της ηλεκτροδερματικής δραστηριότητας προέρχονται από την ενεργοποίηση των ιδρωτοποιών αδένων, η λειτουργία των οποίων έχει συνδεθεί με το “συμπαθητικό” τμήμα του αυτόνομου νευρικού συστήματος. Πιο συγκεκριμένα, διέγερση του τμήματος αυτού από κάποιο συναισθηματικό ή ψυχολογικό ερέθισμα συνεπάγεται ενεργοποίηση των ιδρωτοποιών αδένων και, κατ' επέκταση, αύξηση της αγωγιμότητας του δέρματος. Η τελευταία παρατήρηση οδήγησε στην ιδέα ότι υπάρχει δυνατότητα μέσω της ηλεκτροδερματικής δραστηριότητας να εκτιμήσουμε τις ψυχολογικές και συναισθηματικές αντιδράσεις ενός ατόμου (Ellaway, Kuppuswamy, Nicotra, & Mathias, 2010).

Σύμφωνα με την ιστορική αναδρομή, όπως αυτή περιγράφεται στο βιβλίο του Wolfram Boucsein (Boucsein, 2012), η πρώτη παρατήρηση της ηλεκτρικής ιδιότητας του δέρματος χρονολογείται στα 1849 σε ένα πείραμα που πραγματοποιήθηκε από τον Dubois-Reymond. Κατά το πείραμα αυτό παρατηρήθηκε ροή ρεύματος από ένα ακίνητο ανθρώπινο άκρο σε ένα άλλο το οποίο κινούνταν ηθελημένα από το υποκείμενο μελέτης. Το συγκεκριμένο πείραμα, ωστόσο, συσχέτισε λανθασμένα την ηλεκτρική αυτή δραστηριότητα με τη μυϊκή δραστηριότητα, δεδομένου ότι αυτή ήταν και η άποψη που κυριαρχούσε εκείνη την εποχή. Η ορθή συσχέτιση με τη λειτουργία των ιδρωτοποιών αδένων καθυστέρησε μέχρι το 1878, οπότε και τελικά επετεύχθη από τους Hermann και Luchsinger. Έπειτα, η συσχέτιση αυτή ισχυροποιήθηκε με την επανάληψη του προγενέστερου πειράματος του Dubois-Reymond, από τον Hermann το 1882, το οποίο φανέρωσε αυξημένη δραστηριότητα στην παλάμη και

τα δάχτυλα, μέρη τα οποία έχουν ως χαρακτηριστικό τους τον αυξημένο βαθμό εφίδρωσης. Η ανακάλυψη των ηλεκτροδερματικών φαινομένων, καθώς και η σχέση της ηλεκτροδερματικής δραστηριότητας με ψυχολογικούς παράγοντες αποδόθηκε σε δύο ανεξάρτητους ερευνητές, τους Féré και Tarchanoff. Ο πρώτος, χρησιμοποιώντας εξωτερικό ρεύμα για τις μετρήσεις, δηλαδή εξωσωματική μέθοδο, παρατήρησε μεταβολές στην αντίσταση του δέρματος κατά τη διάρκεια συναισθηματικών ερεθισμάτων. Ο δεύτερος, χρησιμοποιώντας την ενδοσωματική μέθοδο, κατέγραψε τις ηλεκτροδερματικές μεταβολές που ακολουθούσαν κάποιο ερέθισμα. Τέλος, η δημοσίευση του Ελβετού νευρολόγου Veraguth, “Das psychogalvanische Reflex-phänomen”, δημιούργησε μεγάλο ενδιαφέρον σε ψυχολόγους και ψυχιάτρους για τη συσχέτιση ψυχολογίας και ηλεκτρικών μετρήσεων του δέρματος και οδήγησε σε πλήθος ερευνών και δημοσιεύσεων πάνω στο φαινόμενο αυτό.

### 3.1.2 Τα χαρακτηριστικά του σήματος

Από τη μέτρηση και την ποσοτικοποίηση της ηλεκτροδερματικής δραστηριότητας προκύπτει ένα συνεχές σήμα. Το σήμα αυτό αποτελείται από την υπέρθεση μιας τονικής και μιας φασικής συνιστώσας, γεγονός που επιτρέπει το διαχωρισμό του, ώστε να μελετηθούν ξεχωριστά τα δύο αυτά συστατικά (Benedek & Kaernbach, 2010). Η τονική συνιστώσα ονομάζεται επίπεδο αγωγιμότητας δέρματος (Skin Conductance Level – SCL) και αποτελεί ένα αργά μεταβαλλόμενο σήμα. Το πλάτος του διαφέρει ανάλογα με τον άνθρωπο και το σημείο στο οποίο πραγματοποιείται η μέτρηση και μπορεί να λάβει τιμές στο διάστημα 2-20  $\mu\text{S}$ . Η φασική συνιστώσα ονομάζεται απόκριση αγωγιμότητας δέρματος (Skin Conductance Response – SCR), παρουσιάζει μεγαλύτερο ρυθμό μεταβολής από το επίπεδο αγωγιμότητας δέρματος και λαμβάνει χαρακτηριστική μορφή, όπως αναπαρίσταται στο Σχήμα 3.1. Τυπικά μεγέθη της είναι ο χρόνος ανόδου 1-3 sec, ο χρόνος ημι-ανάρρωσης 2-10 sec και το πλάτος 0.1-1  $\mu\text{S}$  (Dawson, Schell, & Fillion, 2007).



Σχήμα 3.1: Χαρακτηριστικά απόκρισης αγωγιμότητας δέρματος (Dawson, Schell, & Fillion, 2007).



Οι αποκρίσεις αγωγιμότητας δέρματος (SCRs), όπως φαίνονται στο παραπάνω σχήμα, μπορούν με τη σειρά τους να χωριστούν σε δύο επιμέρους κατηγορίες, τις “ειδικές” (Specific-SCRs) και τις “αόριστες” (NonSpecific-SCRs). Και οι δύο, όμως, κατηγορίες διέπονται από τα ίδια προαναφερθέντα χαρακτηριστικά. Η ειδοποιός διαφορά που τις διακρίνει εντοπίζεται στην αιτία και τη στιγμή που αυτές συμβαίνουν. Οι Specific-SCRs είναι αντιδράσεις του σώματος μέσω του αυτόνομου νευρικού συστήματος, οι οποίες πυροδοτούνται από κάποιο ερέθισμα και ακολουθούν αυτό με μια μικρή καθυστέρηση, περίπου 1-3 sec. Το ερέθισμα μπορεί να προέρχεται είτε από το εξωτερικό περιβάλλον είτε από ενδογενείς σκέψεις. Η δυνατότητα τεχνητής πρόκλησης Specific-SCRs έχει αποδειχθεί εξαιρετικά χρήσιμη, καθώς προσφέρει πληροφορίες για τη σύνδεση της ψυχολογικής και συναισθηματικής κατάστασης ενός ατόμου με τη φυσική του κατάσταση. Οι NonSpecific-SCRs προκύπτουν χωρίς την επίδραση κάποιου εξωτερικού ερεθίσματος και παρατηρούνται ανά τακτά χρονικά διαστήματα, ενδεικτικά 1-3 αποκρίσεις ανά λεπτό, ανάλογα με την ψυχοφυσιολογία του ατόμου.

### *3.1.3 Σύνδεση του σήματος με την ψυχολογία*

Το σήμα της ηλεκτροδερματικής δραστηριότητας έχει χρησιμοποιηθεί εκτεταμένα σε έρευνες που βασίζονται στη χρήση ερεθισμάτων και που ως στόχο τους έχουν την καταγραφή των αποκρίσεων του αυτόνομου νευρικού συστήματος. Έχει παρατηρηθεί ότι διαφορετικά χαρακτηριστικά του σήματος έχουν τη δυνατότητα να ποσοτικοποιήσουν αυτή τη διέγερση. Πιο συγκεκριμένα, έχει φανεί ότι οι αποκρίσεις του δέρματος (SCR), δηλαδή η φασική συνιστώσα, είναι καλύτερος δείκτης της διέγερσης που δημιουργείται από στιγμιαία ερεθίσματα, ενώ το επίπεδο της αγωγιμότητας του δέρματος (SCL) αντικατοπτρίζει καλύτερα τη γενικευμένη διέγερση, όπως μια συναισθηματική κατάσταση, το άγχος ή ακόμα και τον ύπνο.

Ένας επιπλέον ερευνητικός τομέας στον οποίο έχει προσφέρει αξία η ηλεκτροδερματική δραστηριότητα είναι αυτός της έρευνας γύρω από τα συναισθήματα και κυρίως το άγχος, τόσο το θετικό όσο και το αρνητικό. Η σημαντικότητα του βιοσήματος αυτού εντοπίζεται στο γεγονός ότι πηγάζει αποκλειστικά από το συμπαθητικό τμήμα του αυτόνομου νευρικού συστήματος, το οποίο είναι υπεύθυνο για τις καταστάσεις "φυγής ή μάχης" (flight or fight), χωρίς να επηρεάζεται από το παρασυμπαθητικό τμήμα όπως άλλα βιοσήματα. Παρότι έχει γίνει εκτεταμένη έρευνα γύρω από τα συναισθήματα και την ηλεκτροδερματική δραστηριότητα, έχει φανεί ότι η περιγραφή της φύσης των συναισθημάτων απαιτεί τον συνδυασμό και με άλλα βιοσήματα για να πραγματοποιηθεί επιτυχώς. Ωστόσο κάποια χαρακτηριστικά του ηλεκτροδερματικού σήματος έχουν δείξει ότι μπορούν να περιγράψουν με εγκυρότητα την ένταση, κυρίως αρνητικών, συναισθημάτων, όπως το ψυχολογικό άγχος καθώς και τη δυνατότητα ένα άτομο να ανταπεξέρχεται σε αυτό.

Αξίζει, ολοκληρώνοντας, να γίνει αναφορά στη συμβολή της ηλεκτροδερματικής δραστηριότητας στην έρευνα της κλινικής ψυχοφυσιολογίας. Πιο συγκεκριμένα, το βιοσήμα έχει συσχετιστεί με διάφορες ψυχικές διαταραχές. Πρωτίστως, λόγω της σύνδεσης με το ψυχολογικό άγχος όπως και ειπώθηκε παραπάνω, η καταγραφή του βιοσήματος έχει ιδιαίτερη αξία στο πλαίσιο αξιολόγησης και θεραπείας ασθενών με αγχώδεις διαταραχές. Η ηλεκτροδερματική δραστηριότητα, επίσης, έχει δείξει ιδιαίτερη χρησιμότητα ως δείκτης στη διαδικασία πρόβλεψης της εμφάνισης ψυχοπάθειας, σχιζοφρένειας ή κάποιας αντικοινωνικής διαταραχής. Τέλος, έχει αποδειχθεί ότι η EDA μπορεί να αποτελέσει σημαντικό δείκτη στη διαδικασία της διάγνωσης της διπολικής διαταραχής. Χαρακτηριστικό παράδειγμα αποτελεί έρευνα που διεξήχθη σε ασθενείς που έπασχαν από διπολική διαταραχή, κατά την οποία πραγματοποιήθηκε σύγκριση των αντιδράσεών τους με αυτές υγιών ατόμων σε συναισθηματικά ερεθίσματα. Τα αποτελέσματα έδειξαν ότι οι ασθενείς εμφάνισαν σημαντικά χαμηλότερες μετρήσεις από τα υγιή άτομα, καθώς και ότι ακόμα και μεταξύ τους οι μετρήσεις διέφεραν ανάλογα με την κατάστασή τους τη δεδομένη στιγμή (καταθλιπτική - ανάμεικτη - μανιακή) (Greco, Valenza, Lanata, Rota, & Scilingo, 2014).


### **3.2 Θόρυβος σε EDA δεδομένα**

Όπως αναφέρθηκε στο δεύτερο κεφάλαιο, η χρήση συσκευών που μπορούν να φορεθούν για τη συλλογή των βιοσημάτων έξω από το εργαστηριακό περιβάλλον έχει ως αποτέλεσμα την εισαγωγή σημαντικής ποσότητας θορύβου στα σήματα που καταγράφονται. Ο θόρυβος αυτός δυσχεραίνει αφενός τη διαδικασία επεξεργασίας του σήματος και αφετέρου την εξαγωγή συμπερασμάτων από αυτό, τόσο για έναν μελετητή όσο και για ένα αυτόματο υπολογιστικό σύστημα.

Με τον όρο “θόρυβο” μέσα σε ένα σήμα αποκαλούμε οποιαδήποτε ανεπιθύμητη ή και άγνωστη παραμόρφωση σε αυτό. Πιο συγκεκριμένα, και στο πλαίσιο της εργασίας θα γίνεται λόγος για artifacts μέσα στο σήμα. Με τον όρο artifact χαρακτηρίζεται οποιαδήποτε μεταβολή στο μετρούμενο σήμα, η οποία δεν έχει ως πηγή της κάποια πραγματική μεταβολή της αγωγιμότητας του δέρματος. Τα artifacts αυτά αποτελούν το κυριότερο και σημαντικότερο πρόβλημα παραμόρφωσης του σήματος. Συγκεκριμένα, οι δομημένες μορφές που λαμβάνουν τα artifacts και ο τρόπος με τον οποίο αλλοιώνουν το σήμα εισάγει ψεύτικη πληροφορία και παραπλανητικά χαρακτηριστικά σε αυτό. Ως αποτέλεσμα, μπορούν να οδηγήσουν στην εξαγωγή λανθασμένων συμπερασμάτων κατά την επεξεργασία του σήματος.

Πρωτίστως, ο θόρυβος στα σήματα ηλεκτροδερματικής δραστηριότητας, τα οποία θα μας απασχολήσουν, μπορεί να προέρχεται από το μέσο το οποίο καταγράφει το σήμα. Στην περίπτωση, για παράδειγμα, που η συσκευή είναι συνδεδεμένη στο ηλεκτρικό δίκτυο ενδέχεται να εμφανιστεί μέσα στο σήμα μια συνιστώσα με υψηλότερη συχνότητα όπως αυτή του δικτύου στο Σχήμα 3.2. Ωστόσο, το πρόβλημα αυτό παύει να υφίσταται όταν τα

δεδομένα προέρχονται από φορητή συσκευή με μπαταρία, καθώς δεν γίνεται καταγραφή κατά τη διάρκεια της φόρτισης.



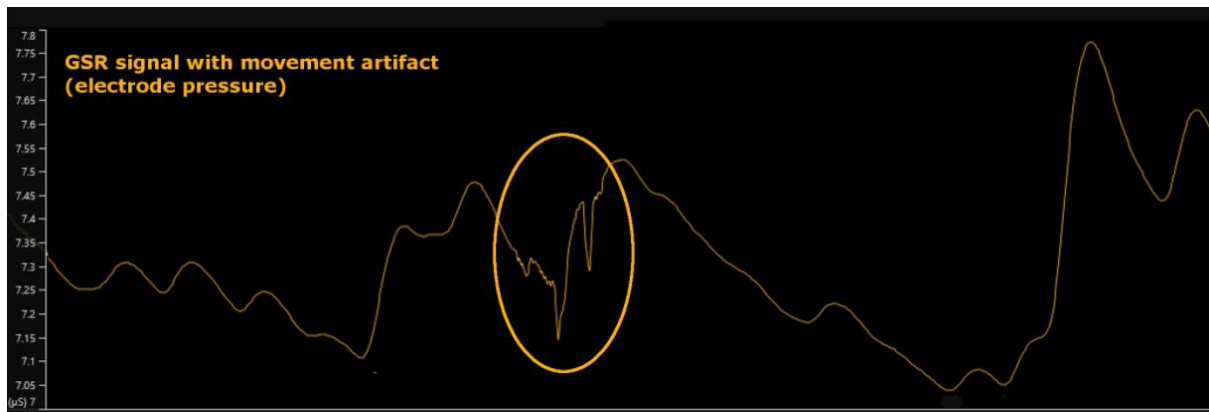
Σχήμα 3.2: Artifacts υψηλής συχνότητας (GSR artifacts, n.d.)

Δευτερευόντως, πλήθος artifacts προκύπτουν και κατά τη διαδικασία καταγραφής των δεδομένων από τις κινήσεις του υποκειμένου μελέτης. Γι' αυτόν τον λόγο τους αποδίδεται και το όνομα "motion artifacts". Η απλούστερη μορφή που συναντάται εντοπίζεται στις μερικές ή ολικές αποσυνδέσεις της συσκευής από την περιοχή μέτρησης. Συγκεκριμένα, αρκετές φορές η επαφή με τα ηλεκτρόδια χάνεται, με αποτέλεσμα να παρατηρούνται μεγάλες και απότομες πτώσεις στις τιμές του σήματος στο Σχήμα 3.3.



Σχήμα 3.3: Motion artifacts, αποσύνδεση ηλεκτροδίων (GSR artifacts, n.d.)

Οι περιπτώσεις motion artifacts που συναντώνται πιο συχνά και είναι πιο δύσκολο να εντοπιστούν και να αφαιρεθούν από το σήμα, είναι η τριβή και η εφαρμογή υπερβολικής πίεσης πάνω στα ηλεκτρόδια. Αποτέλεσμα αυτών των δύο ενδεχομένων είναι η παρατήρηση απότομων αυξομειώσεων της μετρούμενης ηλεκτροδερματικής δραστηριότητας, οι οποίες παραμορφώνουν το σήμα και μάλιστα μπορεί να παρερμηνευτούν ως αξιόπιστες αποκρίσεις του δέρματος (Σχήμα 3.4).



**Σχήμα 3.4: Motion artifacts, πίεση ή τριβή με τα ηλεκτρόδια (GSR artifacts, n.d.)**

Επιπρόσθετα, οι κινήσεις του χρήστη ενδέχεται να μετακινήσουν τη συσκευή, αλλάζοντας την περιοχή επαφής της με το δέρμα. Τότε, εμφανίζονται artifacts εάν η νέα περιοχή μετρήσεων παρουσιάζει μικρότερη ή μεγαλύτερη εφίδρωση, καθώς παρατηρούνται απότομες αλλαγές επιπέδου στην αγωγιμότητα του δέρματος. Τέλος, υπάρχει η πιθανότητα παρεμβολές στο σήμα να προέρχονται από έντονη μυϊκή δραστηριότητα, ακόμα και μακριά από την περιοχή από όπου λαμβάνονται οι μετρήσεις.

Αξίζει, επίσης, να γίνει αναφορά και σε μια ομάδα artifacts τα οποία, ωστόσο, δεν έχουν κάποια χαρακτηριστικά που να τα ξεχωρίζουν και, επομένως, δεν είναι εύκολο να εντοπιστούν, παρά μόνο με την ανατροφοδότηση, δηλαδή την ενημέρωση από την πλευρά του χρήστη. Βασικότερες αιτίες εμφάνισής τους αποτελούν οι περιβαλλοντικές συνθήκες, καθώς και η δραστηριότητα του χρήστη κατά την περίοδο καταγραφής των μετρήσεων. Για παράδειγμα, υψηλή θερμοκρασία, υγρασία, ή κάποια έντονη σωματική άσκηση, όπως η γυμναστική, οδηγούν συνήθως το ανθρώπινο σώμα σε αυξημένη εφίδρωση. Υπό τις συνθήκες αυτές, μπορεί να καταγραφεί έντονη σταδιακή αύξηση του επιπέδου ηλεκτροδερματικής δραστηριότητας και παραμονή στο επίπεδο αυτό για μεγάλο χρονικό διάστημα. Μια τέτοια παρατήρηση ενδέχεται να παρερμηνευθεί ως περίοδος έντονης συναισθηματικής φόρτισης με ασυνήθιστα μεγάλη διάρκεια και να παραπέμψει επί παραδείγματι σε μια κατάσταση υψηλού παρατεταμένου άγχους.

Από τα παραπάνω συμπεραίνεται ότι τα artifacts επηρεάζουν σημαντικά τη μορφολογία του σήματος, είτε εισάγοντας ψεύτικη πληροφορία, είτε αλλοιώνοντας αυτήν που περιέχεται στο σήμα. Είναι σημαντικό επομένως να εντοπίζονται και είτε να αφαιρούνται είτε να διορθώνονται, όπου αυτό είναι δυνατό. Στο πλαίσιο της παρούσας εργασίας βαρύτητα δίνεται εξολοκλήρου στον επιτυχή εντοπισμό και την αναγνώριση αυτών των προβληματικών τμημάτων του σήματος.

### 3.3 Σχετικές εργασίες για τον εντοπισμό και την απομάκρυνση του θορύβου

#### 3.3.1 Τεχνικές που βασίζονται στη γνώση για το σήμα

Πολλές έρευνες και τεχνικές που αναπτύχθηκαν για να προσεγγίσουν το πρόβλημα των artifacts αξιοποιούν τη γνώση που υπάρχει γύρω από το πεδίο των σημάτων, καθώς η ηλεκτροδερματική δραστηριότητα αποτελεί ένα συνεχές σήμα. Στηρίζονται, επομένως, είτε σε αλγόριθμους που αντιλαμβάνονται το σήμα ως μια χρονοσειρά, είτε σε αλγόριθμους ψηφιακής επεξεργασίας σήματος (Digital Signal Processing).

Μια πρώτη προσέγγιση αφορά την απευθείας διόρθωση του σήματος χωρίς να γίνεται πρώτα εντοπισμός των τμημάτων που περιέχουν artifacts. Χαρακτηριστικό παράδειγμα αποτελεί η χρήση εκθετικής εξομάλυνσης (exponential smoothing). Η συγκεκριμένη μέθοδος εφαρμόστηκε στην έρευνα του Hernandez et al., προκειμένου να απομακρυνθεί ο θόρυβος από τα σήματα που είχαν συλλέξει από εργαζόμενους τηλεφωνικών κέντρων. Στη συνέχεια, τα σήματα αυτά, εφόσον θεωρήθηκαν πλέον καθαρά, χρησιμοποιήθηκαν για τον εντοπισμό χρονικών διαστημάτων άγχους στους συγκεκριμένους εργαζόμενους (Hernandez J. a., 2011). Σε αυτήν την περίπτωση εμφανίζεται η πιθανότητα, ο αλγόριθμος να μεταβάλλει αδιάκριτα τις τιμές του σήματος. Αυτό έχει ως αποτέλεσμα να υπάρχει ο κίνδυνος να παραλειφθούν ορισμένα artifacts, τα οποία έρχονταν διόρθωσης, ή να παραμορφωθούν τμήματα του σήματος που περιέχουν μεταβολές, οι οποίες οφείλονται στην ύπαρξη συναισθήματος.

Επιπλέον, πληθώρα ερευνών έχει επιστρατεύσει τεχνικές ψηφιακής επεξεργασίας σήματος, προκειμένου να πετύχει ένα ικανοποιητικά καθαρό σήμα. Η πιο συνήθης χρήση επεξεργασίας σήματος γίνεται μέσω φίλτρων, όπως τα Hanning filters (Hernandez, Riobo, Rozga, Abowd, & Picard, 2014), τα Hamming filters (Poh, Swenson, & Picard, 2010) και moving median filtering (Kocielnik, Sidorova, Maggi, Ouwerkerk, & Westerink, 2013). Ωστόσο, το φιλτράρισμα που παρέχουν υπόκειται σε ορισμένους περιορισμούς. Πιο συγκεκριμένα, ενώ εξομαλύνουν με επιτυχία μικρής κλίμακας artifacts, αδυνατούν να κάνουν το ίδιο και στον έντονο θόρυβο που προκύπτει από τις κινήσεις της συσκευής πάνω στο χέρι του χρήστη, όταν πραγματοποιείται κινητή (ambulatory) συλλογή δεδομένων.

Πιο πρόσφατα έχουν προταθεί και πιο εξεζητημένες τεχνικές που αξιοποιούν την αποσύνθεση του σήματος της ηλεκτροδερματικής δραστηριότητας, προκειμένου να απομονώσουν τις συνιστώσες που περιέχουν θόρυβο. Η αποσύνθεση του σήματος πραγματοποιείται με τη χρήση ορισμένων μητρικών κυματομορφών (mother wavelets). Για το συγκεκριμένο πρόβλημα, του εντοπισμού δηλαδή των artifacts σε σήμα ηλεκτροδερματικής δραστηριότητας, το καλύτερο αποτέλεσμα έχει αποδειχθεί ότι παρέχει η κυματομορφή Haar (db1), καθώς ενδείκνυται για την δυνατότητά της να προσαρμόζεται σε απότομες αυξομειώσεις του σήματος, όπως είναι ο θόρυβος. Κατά τη διαδικασία της αποσύνθεσης του σήματος, αρχικά το σήμα χωρίζεται σε συνιστώσες συγκεκριμένων

διαστημάτων συχνοτήτων, περνώντας από τόσα φίλτρα όσα και τα διαστήματα που έχουν επιλεχθεί. Στη συνέχεια, σε κάθε συνιστώσα ξεχωριστά εφαρμόζεται η μητρική κυματομορφή Haar και προκύπτει μία ακολουθία από συντελεστές, που περιγράφει τη μορφή του σήματος στη συγκεκριμένη συνιστώσα. Μετά την αποσύνθεση του σήματος, οι ακολουθίες των συντελεστών μοντελοποιούνται βάσει κάποιας κατανομής πιθανότητας, όπως για παράδειγμα Gaussian Mixture (Chen, et al., 2015) και Laplace (Shukla, Barreda-Ángeles, Oliver, & Puig, 2018). Τέλος, υπολογίζεται ένα όριο κάτω από το οποίο θεωρείται ότι παίρνουν τιμές μόνο οι συντελεστές που προκύπτουν από τμήματα καθαρού σήματος και έτσι απορρίπτονται οι συντελεστές που παραπέμπουν σε κάποιας μορφής artifact. Το όριο αυτό μπορεί να επανυπολογίζεται διαρκώς ανάλογα με τις τοπικές τιμές του σήματος, ώστε να μην επηρεάζεται το αποτέλεσμα από το επίπεδο της αγωγιμότητας του δέρματος (SCL), αλλά μόνο από τις μεταβολές της απόκρισης αγωγιμότητας (SCR). Για τη διόρθωση του σήματος και την εξάλειψη του θορύβου, το σήμα ανακατασκευάζεται από τους συντελεστές που διατηρήθηκαν. Η τεχνική αυτή, παρότι έχει δείξει πολύ καλά αποτελέσματα, έχει το μειονέκτημα της υψηλής υπολογιστικής πολυπλοκότητας, όπως, επίσης, και της ελαφριάς παραμόρφωσης του σήματος ακόμα και σε τμήματα που δεν περιέχουν artifacts.

Κρίνοντας από τα παραπάνω φαίνεται πως οι αναφερθείσες μέθοδοι και τεχνικές που εκμεταλλεύονται τη γνώση για το σήμα φέρουν ικανοποιητικά αποτελέσματα όσον αφορά τον εντοπισμό και την απομάκρυνση των artifacts. Ωστόσο, αφενός τεχνικές όπως η εκθετική εξομάλυνση και τα φίλτρα επηρεάζουν όλο το σήμα και όχι τα σημεία εκείνα που χρήζουν διόρθωσης, δηλαδή τα artifacts και αφετέρου η αποσύνθεση και η στατιστική μοντελοποίηση του σήματος χαρακτηρίζονται από υψηλή υπολογιστική πολυπλοκότητα. Επομένως αναζητήθηκε λύση σε έναν τομέα που έχει γνωρίσει ιδιαίτερη ανάπτυξη και χρήση τα τελευταία χρόνια, στον τομέα της μηχανικής μάθησης.

### *3.3.2 Τεχνικές που βασίζονται στη μηχανική μάθηση*

Παρότι στο επόμενο κεφάλαιο θα γίνει εκτενής αναφορά στη θεωρία της μηχανικής μάθησης και στις επιμέρους διαδικασίες που πραγματοποιούνται για την επίλυση ενός προβλήματος χρησιμοποιώντας τέτοιες τεχνικές, αξίζει να γίνει συνοπτική αναφορά σε προγενέστερες προσπάθειες που κινήθηκαν προς αυτή την κατεύθυνση.

Η πρώτη προσπάθεια αξιοποίησης των δυνατοτήτων της μηχανικής μάθησης πραγματοποιήθηκε από τους (Taylor, et al., 2015). Ο εντοπισμός θορύβου σε αυτό το παράδειγμα προσεγγίστηκε ως ένα πρόβλημα επιβλεπόμενης μάθησης. Στο πλαίσιο της συγκεκριμένης έρευνας έγινε συλλογή EDA σημάτων από 32 συμμετέχοντες, τα οποία χωρίστηκαν σε τμήματα των 5 δευτερολέπτων. Από το κάθε τμήμα υπολογίστηκε πλήθος χαρακτηριστικών, από τα οποία επιλέχθηκαν τα πλέον κατάλληλα για την επίλυση του προβλήματος. Μετά από δοκιμή διάφορων αλγορίθμων κατηγοριοποίησης, την καλύτερη επίδοση είχαν οι πίνακες διανυσμάτων υποστήριξης (Support Vector Machine) με σχεδόν 97% ακρίβεια. Συμπεραίνεται, λοιπόν, ότι με την κατάλληλη μοντελοποίηση του

προβλήματος αναγνώρισης του θορύβου, αυτό μπορεί να επιλυθεί με μεγάλη επιτυχία από ένα αυτόματο σύστημα, χωρίς να έχει προγραμματιστεί αυστηρώς ο τρόπος.

Η επιβλεπόμενη μάθηση, ωστόσο, απαιτεί κόπο και χρόνο από τους ερευνητές για την παραγωγή των επιθυμητών εξόδων για τα δεδομένα εισόδου, ώστε αυτά να μπορούν να δοθούν σε ένα σύστημα. Γι' αυτό το λόγο η έρευνα των (Zhang, Haghdan, & Xu, 2017) κινήθηκε προς την κατεύθυνση της μη επιβλεπόμενης μάθησης, όπου απαιτείται μόνο η κατάλληλη προετοιμασία των δεδομένων εισόδου. Στο πλαίσιο αυτής εκπαιδεύτηκαν και αξιολογήθηκαν πέντε αλγοριθμικά μοντέλα επιβλεπόμενης και τρία μη επιβλεπόμενης μάθησης. Το αποτέλεσμα ήταν να επιβεβαιωθεί η αποδοτικότητα που είχε παρατηρηθεί από τους αλγορίθμους επιβλεπόμενης μάθησης. Το σημαντικότερο συμπέρασμα, ωστόσο, ήταν ότι ακόμα και χωρίς τη γνώση ετικετών για τα τμήματα και, επομένως, με χρήση μη επιβλεπόμενης μάθησης, είναι δυνατόν να επιτευχθούν εξίσου καλής ποιότητας αποτελέσματα.

Τα τελευταία χρόνια έχει αρχίσει να γίνεται δημοφιλής και μια επιπλέον μορφή μηχανικής μάθησης, η ενεργός μάθηση. Η ενεργός μάθηση είναι μια μορφή ημι-επιβλεπόμενης μάθησης, δηλαδή το μοντέλο λαμβάνει δεδομένα εκπαίδευσης, μόνο για ένα μέρος των οποίων είναι γνωστή η επιθυμητή έξοδος. Πιο συγκεκριμένα, ο αλγόριθμος ξεκινά με ένα πολύ μικρό πλήθος δεδομένων με ετικέτες και σταδιακά ζητάει από τον χρήστη ετικέτες για δεδομένα, τα οποία ο αλγόριθμος κρίνει ως πιο σημαντικά για την επιτυχία της κατηγοριοποίησης. Οι (Xia, Jaques, Taylor, Fedor, & Picard, 2015) βασίστηκαν στο ότι τα SVM (Support Vector Machine) αποτελούν μια πολύ καλή επιλογή αλγορίθμου τόσο για το συγκεκριμένο πρόβλημα όσο και για τη δημιουργία ενός αλγορίθμου ενεργούς μάθησης. Η μέθοδος που ανέπτυξαν περιορίζει τη συμβολή του ανθρώπου στη διαδικασία της μάθησης, καθώς δεν υποχρεούται να δαπανήσει πολύ χρόνο στην παραγωγή ετικετών για όλα τα διαθέσιμα δεδομένα, παρά μόνο για όσα κρίνει ο αλγόριθμος απαραίτητα. Ωστόσο, αξίζει να σημειωθεί πως για έναν αλγόριθμο ενεργούς μάθησης, το ανώτατο όριο της αποδοτικότητάς του είναι αυτό που θα έδινε ο αντίστοιχος αλγόριθμος επιβλεπόμενης μάθησης αν του παρέχονταν όλα τα δεδομένα με ετικέτες. Έτσι, με τη χρήση της ενεργούς μάθησης, αφενός μειώνεται ο χρόνος και ο κόπος που απαιτείται από τον ανθρώπινο παράγοντα, αφετέρου, όμως, δεν επιτυγχάνεται πάντα η βέλτιστη απόδοση του αλγορίθμου.

Στην παρούσα εργασία δοκιμάζονται τεχνικές παρόμοιες με τις παραπάνω έρευνες για την ανάπτυξη μιας ολοκληρωμένης μεθόδου, η οποία να ανταποκρίνεται βέλτιστα στα δεδομένα που συλλέγει η εταιρεία Sentio Solutions με το βραχιόλι Feel. Η ιδιαιτερότητα σε σχέση με τις προαναφερθείσες εργασίες βρίσκεται στα δεδομένα, καθώς αυτά προέρχονται από έναν αισθητήρα ίδιας κατασκευής της εταιρείας και συλλέγονται κατά τις συνθήκες της καθημερινής ζωής των χρηστών του βραχιολιού.

## Κεφάλαιο 4

### 4. Θεωρητικό υπόβαθρο στη Μηχανική Μάθηση

#### 4.1. Εισαγωγή στη μηχανική μάθηση

Η μηχανική μάθηση αποτελεί έναν επιστημονικό τομέα που υπάρχει και εξερευνάται από τις αρχές της δεκαετίας του 1960. Τα τελευταία χρόνια ωστόσο γνωρίζει τη μεγαλύτερη της ανάπτυξη. Αφενός ο όγκος των διαθέσιμων δεδομένων που δημιουργούνται καθημερινά έχει αναδείξει τόσο τη χρησιμότητα αλλά και την αναγκαιότητά της. Αφετέρου η αυξημένη υπολογιστική πολυπλοκότητα των υπολογιστικών συστημάτων έχει καταστήσει τη χρήση της πιο εύκολη στις μέρες μας. Η χρήση της μηχανικής μάθησης συναντάται πλέον σε διάφορους τομείς όπως είναι η ρομποτική, η βιοϊατρική, ο τομέας των επιχειρήσεων και πολλοί άλλοι.

Με τον όρο Μηχανική Μάθηση ορίζεται το επιστημονικό πεδίο μελέτης αλγορίθμων και στατιστικών μοντέλων, με τη βοήθεια των οποίων ένα υπολογιστικό σύστημα μπορεί να εκτελεί διεργασίες χωρίς να είναι αυστηρώς προγραμματισμένο. Με τη βοήθεια της μηχανικής μάθησης ένας υπολογιστής προγραμματίζεται να συλλέγει δεδομένα, να “μαθαίνει” από αυτά και σύμφωνα με αυτή τη γνώση να κάνει προβλέψεις και να λαμβάνει αποφάσεις.

Προκειμένου να αξιοποιηθούν αλγόριθμοι μηχανικής μάθησης, πρέπει πρώτα το πρόβλημα να μοντελοποιηθεί κατάλληλα. Για να γίνει αυτό, παρεμβάλλεται ένα στάδιο κατά το οποίο εξαγονται χαρακτηριστικά από τα διαθέσιμα δεδομένα του προβλήματος, τα οποία θα μπορούν να χρησιμοποιηθούν για την εκπαίδευση του μοντέλου. Συγκεκριμένα, το στάδιο αυτό ονομάζεται εξαγωγή χαρακτηριστικών (Feature extraction) και κατά τη διάρκειά του, από το αρχικό σετ δεδομένων παράγεται ένα πλήθος μεταβλητών, τα χαρακτηριστικά, τα οποία χρησιμοποιούνται ως είσοδοι στους διάφορους αλγόριθμους μηχανικής μάθησης. Η χρησιμότητα της εξαγωγής χαρακτηριστικών έγκειται στη μετατροπή των αρχικών δεδομένων σε χαρακτηριστικά μεστά από πληροφορία, η οποία μπορεί να ερμηνευτεί ευκολότερα από τον ανθρώπινο παράγοντα και να αξιοποιηθεί για την εκπαίδευση μαθηματικών μοντέλων.

Επιπρόσθετα, υπάρχει η περίπτωση να κριθεί ότι το πλήθος των χαρακτηριστικών είναι πολύ μεγάλο και πιθανώς περιέχει και περιττές πληροφορίες. Τότε πραγματοποιείται επιλογή χαρακτηριστικών (Feature selection), όπου επιλέγεται ένας εκ των πολλών δυνατών συνδυασμών από αυτά. Η διαδικασία αυτή πραγματοποιείται με κάποια αυτοματοποιημένη μέθοδο και συμβάλλει στη μείωση των τυχαίων μεταβλητών του προβλήματος, που αλλιώς ονομάζεται μείωση διαστάσεων (Dimensionality Reduction). Έτσι, μειώνεται το υπολογιστικό κόστος της λύσης του προβλήματος, τόσο σε μνήμη όσο και σε χρόνο εκτέλεσης. Τέλος, ο αλγόριθμος ενδέχεται να δώσει καλύτερα αποτελέσματα, καθώς επιλέγονται εκείνα τα



χαρακτηριστικά που είναι πλέον κατάλληλα και περιέχουν την πληροφορία που απαιτείται για τη λύση του συγκεκριμένου προβλήματος.


Στη συγκεκριμένη εργασία θα μας απασχολήσουν δυο μορφές τις οποίες μπορεί να πάρει η μηχανική μάθηση. Ο διαχωρισμός τους γίνεται με βάση τον τρόπο με τον οποίο κατασκευάζεται το μοντέλο μάθησης και τα δεδομένα εκπαίδευσης. Αυτές αφορούν στην επιβλεπόμενη και τη μη επιβλεπόμενη μάθηση που αναλύονται στη συνέχεια.

## 4.2. Επιβλεπόμενη Μάθηση

### 4.2.1. Θεωρία Επιβλεπόμενης Μάθησης

Ως προβλήματα επιβλεπόμενης μάθησης (Supervised learning) ορίζονται αυτά στα οποία τα δεδομένα εκπαίδευσης περιέχουν τόσο τις εισόδους όσο και τις αντίστοιχες επιθυμητές εξόδους. Τα μοντέλα που ανήκουν σε αυτή την ομάδα χρησιμοποιούν τη γνώση που υπάρχει από παλαιότερα δεδομένα, προκειμένου να πραγματοποιήσουν προβλέψεις για τα νεότερα.

Τα προβλήματα επιβλεπόμενης μάθησης μπορούν να χωριστούν εκ νέου σε δύο άλλες κατηγορίες, ανάλογα με τη μορφή της επιθυμητής εξόδου. Στην περίπτωση που στόχος του μοντέλου είναι να κατατάξει την είσοδο σε μία από ένα πεπερασμένο πλήθος κατηγοριών, τότε αυτό θεωρείται πρόβλημα κατηγοριοποίησης (Classification). Αντίθετα, αν η επιθυμητή έξοδος αποτελείται από μία ή περισσότερες συνεχείς μεταβλητές, τότε αυτό συνιστά πρόβλημα παλινδρόμησης (Regression). Σχηματικά η διαφορά των δύο προβλημάτων φαίνεται στο Σχήμα 4.1.



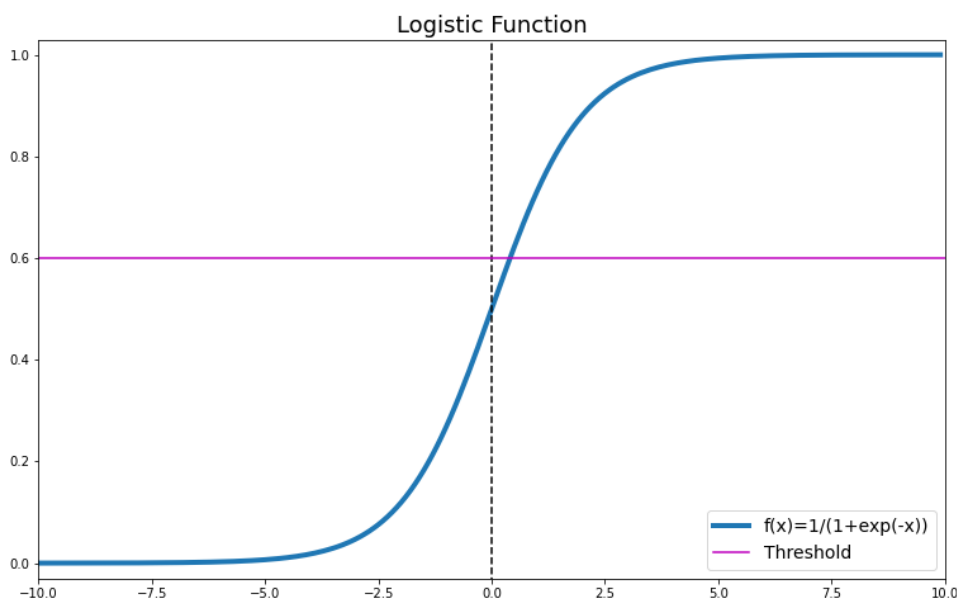
Σχήμα 4.1: Παράδειγμα Κατηγοριοποίησης και Παλινδρόμησης.

## 4.2.2. Αλγόριθμοι Επιβλεπόμενης Μάθησης

Όσον αφορά στους αλγόριθμους επιβλεπόμενης μάθησης που χρησιμοποιούνται στο πλαίσιο της εργασίας, αυτοί αναλύονται ως εξής.

### 4.2.2.1 Λογιστική παλινδρόμηση (Logistic Regression)


Πρόκειται για ένα μοντέλο μηχανικής μάθησης το οποίο χρησιμοποιείται για κατηγοριοποίηση (classification). Πιο συγκεκριμένα, ως στατιστικό μοντέλο αντιστοιχίζει το γραμμικό συνδυασμό των χαρακτηριστικών (features) των δεδομένων εισόδου σε τιμές πιθανοτήτων, από το 0 ως το 1, συμπεριλαμβανομένων και των ακραίων τιμών. Για να πραγματοποιήσει αυτή την αντιστοίχιση χρησιμοποιεί τη λογιστική συνάρτηση, όπως φαίνεται στο σχήμα 4.2, η οποία είναι μια σιγμοειδής συνάρτηση και αντιστοιχεί στην εξίσωση  $f(x)=1/(1+\exp(-x))$ . Αφού υπολογιστεί η πιθανότητα για κάθε δείγμα, χρησιμοποιείται ένα κατώφλι (threshold) ώστε τα δείγματα να χωριστούν σε κατηγορίες, ανάλογα με την τιμή της πιθανότητας που έλαβαν. Το κατώφλι δεν έχει μια προκαθορισμένη τιμή αλλά επιλέγεται αυθαίρετα από τον αλγόριθμο με στόχο τη βέλτιστη απόδοση του μοντέλου κατά την εκπαίδευση. Για παράδειγμα, όπως παρουσιάζεται στο κάτωθι σχήμα (4.2), το κατώφλι έχει οριστεί στην τιμή 0.6 και δεδομένα που λαμβάνουν πιθανότητα μεγαλύτερη του 0.6 αντιστοιχίζονται στην κατηγορία 1, ενώ τα υπόλοιπα στην κατηγορία 0.



Σχήμα 4.2: Γράφημα της λογιστικής συνάρτησης

#### 4.2.2.2 Μηχανές Διανυσμάτων Υποστήριξης (Support Vector Machines - SVM):

Οι Μηχανές Διανυσμάτων Υποστήριξης αποτελούν έναν αλγόριθμο επιβλεπόμενης μάθησης, ο οποίος μπορεί να χρησιμοποιηθεί είτε για κατηγοριοποίηση είτε για παλινδρόμηση. Στις SVM τα δεδομένα εκπαίδευσης αναπαρίστανται σε ένα χώρο χαρακτηριστικών έτσι ώστε να διαχωρίζονται με το μέγιστο δυνατό περιθώριο, ανάλογα με την κατηγορία στην οποία ανήκουν. Ο αλγόριθμος προσπαθεί να βρει και να κατασκευάσει ένα υπερ-επίπεδο (hyperplane) στον χώρο αυτόν που να διαχωρίζει βέλτιστα τα δεδομένα που ανήκουν σε διαφορετικές κλάσεις. Βέλτιστο θεωρείται το επίπεδο που απέχει κατά το μέγιστο από οποιοδήποτε δείγμα των δεδομένων ανεξάρτητα από την κλάση στην οποία ανήκει (Σχήμα 4.3). Μετά την εκπαίδευση του μοντέλου, τα δεδομένα για τα οποία καλείται να πάρει κάποια απόφαση αναπαρίστανται στον ίδιο χώρο και κατατάσσονται σε μια κατηγορία ανάλογα με την πλευρά στην οποία βρίσκονται.



Σχήμα 4.3: Παράδειγμα κατηγοριοποίησης με χρήση SVM (Cortes & Vapnik, 1995)

Γενικά, οι SVM είναι κατηγοριοποιητές δύο κλάσεων και αρχικά χρησιμοποιήθηκαν για το γραμμικό διαχωρισμό δεδομένων. Ωστόσο, πλέον, έχουν αναπτυχθεί μέθοδοι για τη χρήση των ΜΔΥ σε προβλήματα με περισσότερες των δύο κλάσεων. Με τη χρήση πυρήνων, όπως οι rbf, poly, κ.α. επιτρέπεται και ο μη γραμμικός διαχωρισμός δεδομένων

#### 4.2.2.3 Τυχαία Δάση (Random Forest):

Τα Τυχαία Δάση ανήκουν στην ευρύτερη κατηγορία των μεθόδων συνόλου (Ensemble methods). Στόχος των τεχνικών αυτών είναι να συνδυάζουν τις προβλέψεις πιο βασικών και απλών μοντέλων προκειμένου να βελτιώνουν τη γενίκευση και τη σταθερότητα των

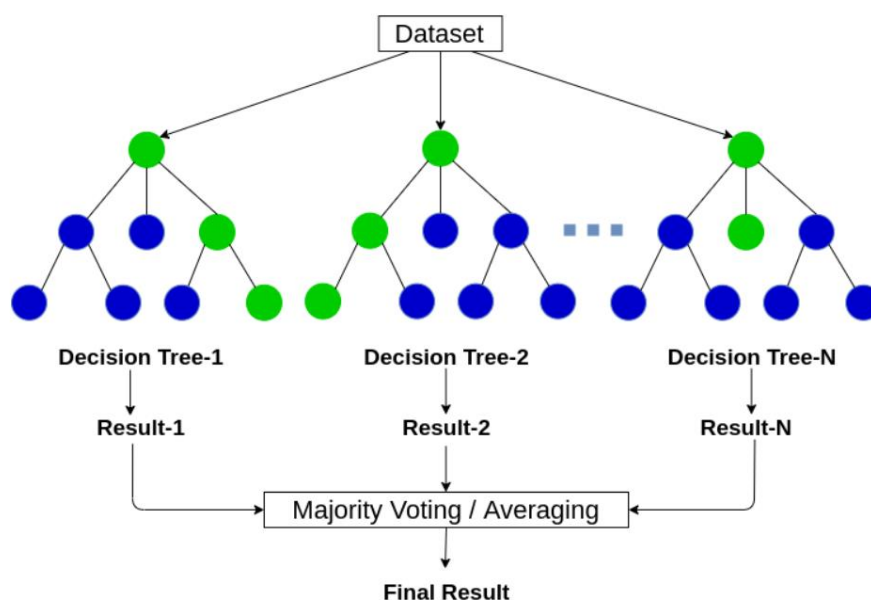
αποτελεσμάτων σε σχέση με ένα μεμονωμένο μοντέλο. Η βασική αρχή αυτών των μεθόδων είναι η κατασκευή διάφορων ανεξάρτητων απλών μοντέλων και στη συνέχεια η εύρεση του μέσου όρου των προβλέψεών τους, καθώς θεωρείται ότι το συνδυαστικό αποτέλεσμα είναι συνήθως καλύτερο από τα επιμέρους ξεχωριστά.

Τα τυχαία δάση αποτελούν μια μέθοδο συνόλου η οποία λειτουργεί κατασκευάζοντας ένα σύνολο δέντρων αποφάσεων κατά τη διαδικασία της εκπαίδευσης του μοντέλου. Κάθε νέο δεδομένο το οποίο καλείται ο αλγόριθμος να κατηγοριοποιήσει περνά από τα ήδη κατασκευασμένα δέντρα αποφάσεων. Το αποτέλεσμα σχετικά με την κατηγορία στην οποία ανήκει επιλέγεται από την πλειοψηφία των δέντρων απόφασης.

Ένα πρόβλημα που παρουσιάζει ο μοντέλο είναι η υψηλή συσχέτιση μεταξύ των δέντρων απόφασης, από τη στιγμή που χρησιμοποιούνται τα ίδια δεδομένα και τα ίδια χαρακτηριστικά για την κατασκευή τους. Υπάρχει ακόμα και η πιθανότητα να δημιουργηθεί το ίδιο δέντρο πολλαπλές φορές. Προκειμένου να ξεπεραστεί αδυναμία αυτή έχουν υπάρξει δύο τροποποιήσεις στον πρωταρχικό αλγόριθμο.

Πρώτον, για κάθε δέντρο απόφασης επιλέγεται κάθε φορά ένα νέο υποσύνολο των δεδομένων εκπαίδευσης. Τα υποσύνολα αυτά δημιουργούνται με δειγματοληψία με επανατοποθέτηση. Η γενικότερη αυτή μέθοδος ονομάζεται bootstrap aggregating (bagging).

Δεύτερον, η μέθοδος bagging αξιοποιείται και για την επιλογή των χαρακτηριστικών που θα χρησιμοποιηθούν για την κατασκευή των δέντρων. Για κάθε δέντρο επομένως επιλέγεται ένα νέο υποσύνολο των χαρακτηριστικών για τον χωρισμό των δεδομένων. Κατά αυτόν τον τρόπο αποφεύγεται η χρήση μόνο των ισχυρότερων χαρακτηριστικών σε κάθε δέντρο και άρα μειώνεται η συσχέτιση μεταξύ τους.



**Σχήμα 4.4: Αναπαράσταση μοντέλου τυχαίων δασών**


#### 4.2.2.4 K Κοντινότεροι Γείτονες (K nearest neighbors – KNN):

Το μοντέλο των K Κοντινότερων Γειτόνων βασίζεται στη λογική, ότι τα παρόμοια δεδομένα βρίσκονται κοντά στον χώρο των χαρακτηριστικών (feature space). Πιο συγκεκριμένα, σε ένα πρόβλημα κατηγοριοποίησης αυτό σημαίνει ότι δεδομένα που ανήκουν στην ίδια κατηγορία έχουν μικρή απόσταση μεταξύ τους.

Κατά την εκπαίδευση του μοντέλου αυτό αποθηκεύει απλά τα δεδομένα εκπαίδευσης που του παρέχονται, δηλαδή τις τιμές των χαρακτηριστικών τους και τις ετικέτες που δηλώνουν την κατηγορία στην οποία ανήκουν. Για κάθε νέο δεδομένο, το οποίο καλείται το μοντέλο να κατηγοριοποιήσει, υπολογίζεται η απόσταση του από όλα τα δεδομένα εκπαίδευσης. Στη συνέχεια, επιλέγεται η κατηγορία στην οποία ανήκει η πλειοψηφία από τους K κοντινότερους γείτονές του.

Το K είναι ένας θετικός φυσικός αριθμός και αποτελεί τη βασική παράμετρο του μοντέλου. Η επιλογή της πραγματοποιείται από τον χρήστη πριν την κατασκευή του μοντέλου. Γενικά η βέλτιστη επιλογή του εξαρτάται από τα δεδομένα εισόδου. Επιλέγοντας πολύ χαμηλές τιμές για το K αυξάνεται η επιρροή του θορύβου και των artifacts στο μοντέλο, ενώ οι υψηλές τιμές καθιστούν τα όρια των κατηγοριών λιγότερο διακριτά.

Μια επιπλέον σημαντική παράμετρος του μοντέλου είναι η συνάρτηση που υπολογίζει τις αποστάσεις μεταξύ των δειγμάτων των δεδομένων. Η επιλογή της κατάλληλης συνάρτησης εξαρτάται από τη φύση των δεδομένων. Αν για παράδειγμα τα χαρακτηριστικά έχουν τη μορφή συνεχών μεταβλητών, τότε συνήθως επιλέγεται η Ευκλείδεια απόσταση.



Σχήμα 4.5: Παράδειγμα κατηγοριοποίησης με χρήση K κοντινότερων γειτόνων

## 4.3. Μη Επιβλεπόμενη Μάθηση

### 4.3.1. Θεωρία μη Επιβλεπόμενης Μάθησης

Ως προβλήματα μη επιβλεπόμενης μάθησης (Unsupervised learning) ορίζονται αυτά στα οποία δεν είναι γνωστή η επιθυμητή έξοδος για τα δεδομένα εισόδου. Επομένως, στόχος των διαφόρων αλγορίθμων είναι η εξαγωγή κρυμμένων μοτίβων ή πληροφοριών για τη δομή και την κατανομή των συγκεκριμένων δεδομένων. Χαρακτηριστικά παραδείγματα αυτής της κατηγορίας συνιστούν η ομαδοποίηση δεδομένων (Clustering), ο καθορισμός της κατανομής των δεδομένων ως προς το χώρο εισόδου (εκτίμηση πυκνότητας ή Density Estimation), καθώς και η προβολή των δεδομένων από ένα πολυδιάστατο χώρο σε δύο ή τρεις διαστάσεις (Dimensionality Reduction) για το σκοπό της αναπαράστασης τους (Visualization).

### 4.3.2. Αλγόριθμοι μη Επιβλεπόμενης Μάθησης

Όσον αφορά στους αλγόριθμους επιβλεπόμενης μάθησης που χρησιμοποιούνται στο πλαίσιο της εργασίας, αυτοί αναλύονται ως εξής.

#### 4.3.2.1 Μηχανές Διανυσμάτων Υποστήριξης Μιας Κατηγορίας (One-class SVM):


Θέτοντας ως βάση το SVM, όπως αναφέρθηκε στην υποενότητα 4.2.2, που χρησιμοποιείται για την το διαχωρισμό των δεδομένων σε δύο κατηγορίες, το One-class SVM προσπαθεί να ξεχωρίσει μία κατηγορία από τα δεδομένα εισόδου, αυτή των κανονικών-αποδεκτών δεδομένων. Στόχος του αλγορίθμου είναι η εύρεση και η κατασκευή ενός υπέρ-επιπέδου το οποίο να περικλείει τα κανονικά δεδομένα και να έχει τη μέγιστη απόσταση από την αρχή των αξόνων του χώρου στον οποίο απεικονίζονται τα δεδομένα. Με τον δεύτερο περιορισμό επιτυγχάνεται το να είναι όσο πιο στενό το υπέρ-επίπεδο πάνω στα δεδομένα. Με την κατασκευή αυτού του βέλτιστου υπέρ-επιπέδου, το μοντέλο χαρακτηρίζει τα δεδομένα που βρίσκονται έξω από αυτό ως ανωμαλίες/outliers.

#### 4.3.2.2 Δάση Απομόνωσης (Isolation Forest):


Τα Δάση Απομόνωσης είναι μια μέθοδος η οποία αξιοποιείται για τον εντοπισμό ανωμαλιών μέσα σε ένα μεγάλο πλήθος δεδομένων. Το χαρακτηριστικό της συγκεκριμένης τεχνικής, που τη διακρίνει από άλλες, είναι ότι εστιάζει στην αναγνώριση και απομόνωση των μη τυπικών δεδομένων. Αντίθετα, οι υπόλοιπες τεχνικές εντοπισμού ανωμαλιών μοντελοποιούν τα κανονικά δεδομένα και στη συνέχεια αναγνωρίζουν όσα δεν ταιριάζουν στο μοντέλο αυτό, όπως για παράδειγμα το One-class SVM. Το πλεονέκτημα των Δασών Απομόνωσης πηγάζει από δύο χαρακτηριστικά των μη τυπικών δεδομένων. Αφενός από το γεγονός ότι αυτά έχουν

μικρότερη συχνότητα εμφάνισης από τα κανονικά και αφετέρου από το ότι οι τιμές των χαρακτηριστικών τους διαφέρουν αισθητά από αυτές που διέπουν τα χαρακτηριστικά των κανονικών δεδομένων.

Το συγκεκριμένο μοντέλο ανήκει στις τεχνικές συνόλου όπως και το Random Forest και επομένως χρησιμοποιεί επίσης Δέντρα Απόφασης για τον διαχωρισμό των δεδομένων. Αρχικά οι παρατηρήσεις περνάνε μέσα από τα δέντρα αποφάσεων, στη συνέχεια υπολογίζεται ο μέσος όρος των αποτελεσμάτων των δέντρων και, τέλος, αποδίδεται ένας βαθμός ανωμαλίας για κάθε δεδομένο. Ο βαθμός αυτός εξαρτάται άμεσα από το μήκος του μονοπατιού το οποίο ακολουθεί μέσα σε ένα δέντρο απόφασης ένα δεδομένο μέχρι να απομονωθεί, δηλαδή να γίνει φύλλο. Η βασική ιδέα βρίσκεται στο ότι τα μη τυπικά δεδομένα ακολουθούν πολύ μικρότερα μονοπάτια προκειμένου να απομονωθούν σε σχέση με τα κανονικά. Χαρακτηριστικό παράδειγμα φαίνεται στο ΣΧΗΜΑ.



**Σχήμα 4.6.α: Διαχωρισμός κανονικού δεδομένου με χρήση δασών απομόνωσης (Liu, Ting, & Zhou, 2008)**



**Σχήμα 4.6.β: Διαχωρισμός μη κανονικού δεδομένου με χρήση δασών απομόνωσης (Liu, Ting, & Zhou, 2008)**

#### 4.4. Μετρικές αξιολόγησης

Για την εκτίμηση των αποτελεσμάτων των αλγορίθμων επιβλεπόμενης και μη επιβλεπόμενης μάθησης που δοκιμάζονται στο πλαίσιο της εργασίας χρησιμοποιείται ένα σύνολο μετρικών αξιολόγησης. Οι συγκεκριμένες μετρικές χρησιμοποιούνται κυρίως σε προβλήματα κατηγοριοποίησης. Για τη δυαδική κατηγοριοποίηση, για παράδειγμα για τις κατηγορίες 0 και 1, ισχύει ότι True Positive (TP) είναι τα δεδομένα που χαρακτηρίζονται σωστά ως 1, True Negative (TN) τα δεδομένα που χαρακτηρίζονται σωστά ως 0, False Positive (FP) τα δεδομένα

που χαρακτηρίζονται εσφαλμένα ως 1 και False Negative (FN) τα δεδομένα που χαρακτηρίζονται εσφαλμένα ως 0.

- Ακρίβεια (Accuracy): Το accuracy δείχνει την απόδοση ενός κατηγοριοποιητή υπολογίζοντας το κλάσμα μεταξύ των δεδομένων τα οποία κατηγοριοποίησε σωστά και του συνόλου των δεδομένων.

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

- Ευαισθησία (Sensitivity/Recall): Το Recall μετράει το ποσοστό των δεδομένων που ανήκουν στην κατηγορία 1 και κατηγοριοποιήθηκαν σωστά.

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

- Precision: Το precision δείχνει το πόσα από τα δεδομένα που τοποθετήθηκαν στην κατηγορία 1 είναι σωστά.

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

- F1-σκορ (F1-score): Το F1-σκορ αποτελεί τον αρμονικό μέσο των μετρικών recall και precision.

$$F1 - score = \frac{2}{recall^{-1} + precision^{-1}} = \frac{2TP}{2TP + FP + FN}$$

- Εμβαδόν κάτω από την Receiver Operating Characteristic καμπύλη (ROC AUC): Η Receiver Operating Characteristic καμπύλη κατασκευάζεται σχεδιάζοντας το True Positive Rate (TN/(TP+FN)) ως συνάρτηση του False Positive Rate (FP/(FP+TN)). Πιο αναλυτικά, ένας κατηγοριοποιητής, για κάθε δεδομένο το οποίο καλείται να κατατάξει σε μια κατηγορία, υπολογίζει την πιθανότητα να ανήκει στην κατηγορία 1. Συγκρίνοντας την τιμή αυτή με ένα επιλεγμένο κατώφλι πραγματοποιεί την κατάταξη του δεδομένου. Δηλαδή, αν η πιθανότητα είναι μεγαλύτερη από το κατώφλι επιλέγεται κατηγορία 1, ενώ στην αντίθετη περίπτωση η κατηγορία 0. Οι διάφορες τιμές που χρειάζονται για τις μεταβλητές TPR και FPR ώστε να σχεδιαστεί η καμπύλη, λαμβάνονται ελέγχοντας τα αποτελέσματα ενός κατηγοριοποιητή χρησιμοποιώντας διαφορετικά κατώφλια διάκρισης μεταξύ των κατηγοριών. Το



εμβαδόν κάτω από αυτή την καμπύλη δείχνει την αποδοτικότητα του μοντέλου, με μέγιστη και βέλτιστη τιμή το 1 και ελάχιστη το 0.

## Κεφάλαιο 5

### 5. Ανάπτυξη μεθόδου εντοπισμού θορύβου

#### 5.1. Συλλογή των δεδομένων ηλεκτροδερματικής δραστηριότητας

##### 5.1.1. Συσκευή καταγραφής

Αρχικό στάδιο προς την ανάπτυξη της μεθόδου αποτέλεσε η συλλογή ενός συνόλου δεδομένων ηλεκτροδερματικής δραστηριότητας. Ως μέσο καταγραφής των δεδομένων χρησιμοποιήθηκε το βραχιόλι Feel της Sentio Solutions. Το βραχιόλι αυτό περιλαμβάνει, εκτός του αισθητήρα για το σήμα ηλεκτροδερματικής δραστηριότητας (EDA), αισθητήρες για τη θερμοκρασία του δέρματος, τη θερμοκρασία και την υγρασία του περιβάλλοντος, φωτοπληθυσμογράφο, επιταχυνσιόμετρο και γυροσκόπιο, τα οποία όμως δεν λαμβάνονται υπόψη στην εργασία. Αξίζει να σημειωθεί πως το εν λόγω βραχιόλι δεν αποτελεί συσκευή για αποκλειστική χρήση εντός εργαστηρίου ή και γενικότερα για πραγματοποίηση ερευνών. Αντιθέτως, πρόκειται για ένα εμπορικό προϊόν, το οποίο έχει σχεδιαστεί για να χρησιμοποιείται σε καθημερινή βάση από το χρήστη, χωρίς να τον επιβαρύνει στις δραστηριότητές του. Το γεγονός αυτό υποδεικνύει ότι ορισμένα χαρακτηριστικά του διαφέρουν από τον αντίστοιχο τυπικό εξοπλισμό που συναντάται σε ένα εργαστήριο. Τέτοια χαρακτηριστικά είναι το μικρό μέγεθος και βάρος του βραχιολιού, το γεγονός ότι είναι κατασκευασμένο από υποαλλεργικά υλικά, καθώς και η κατασκευή των εσωτερικών του κυκλωμάτων ώστε να επιτυγχάνεται η μέγιστη δυνατή διάρκεια της μπαταρίας του.

Προκειμένου να επιτευχθούν τα παραπάνω χαρακτηριστικά, ο αισθητήρας της ηλεκτροδερματικής δραστηριότητας σχεδιάστηκε από την ίδια την εταιρεία. Το στοιχείο εκείνο που επηρεάστηκε κατά το σχεδιασμό του αισθητήρα είναι τα ηλεκτρόδιά του. Συγκεκριμένα, το μικρότερο, σχετικά με άλλες παρόμοιες συσκευές, μέγεθός τους, καθώς και το υλικό κατασκευής και η απόσταση μεταξύ τους, ορίζει την κλίμακα των τιμών του σήματος να είναι χαμηλότερη από αυτή που συναντάται στη βιβλιογραφία και αναφέρεται στην υποενότητα 3.1.2. Τέλος, όπως ειπώθηκε παραπάνω, το βραχιόλι προορίζεται για συνεχή καθημερινή χρήση, έχει δηλαδή κατασκευαστεί με γνώμονα την άνεση του χρήστη. Αυτό σημαίνει ότι είναι στην ευχέρεια του χρήστη να μην το φοράει αρκετά σφιχτά. Ως αποτέλεσμα αυτό μπορεί να κινείται πάνω στο χέρι του, δημιουργώντας τριβές ή κενά στην επαφή του αισθητήρα με το δέρμα, γεγονός που εισάγει θόρυβο και artifacts στο σήμα.

##### 5.1.2. Διαδικασία καταγραφής

Για το σκοπό της εργασίας συλλέχθηκαν σήματα ηλεκτροδερματικής δραστηριότητας από 9 άτομα, και συγκεκριμένα μέλη της εταιρείας. Τα άτομα αυτά κλήθηκαν να φορέσουν το βραχιόλι στη διάρκεια της καθημερινότητάς τους. Το βραχιόλι φορέθηκε στον καρπό του κυρίαρχου-καλού χεριού του εκάστοτε ατόμου, με τα ηλεκτρόδια να βρίσκονται στην

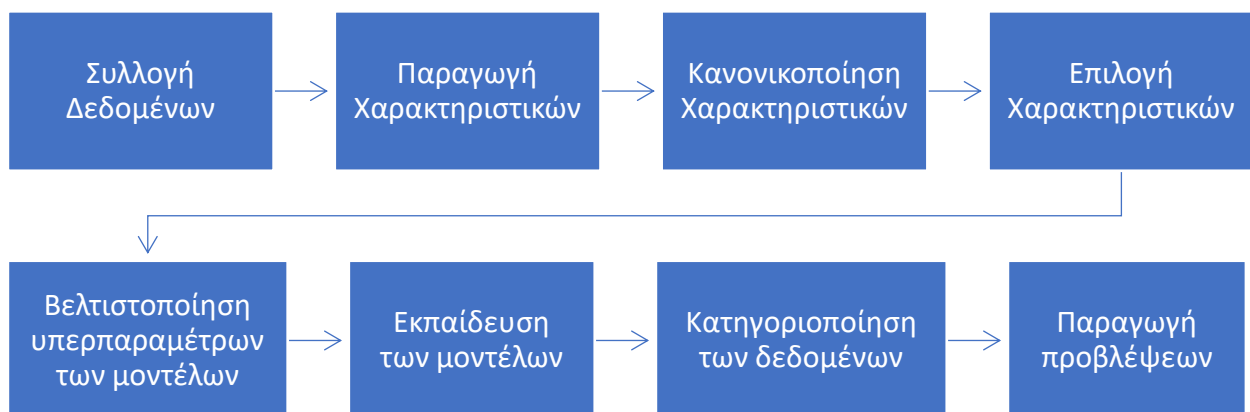
εσωτερική πλευρά του χεριού. Ιδιαίτερα σημαντικό είναι το γεγονός πως δεν επιβλήθηκε κανένας περιορισμός ως προς την κινητικότητα των υποκειμένων μελέτης καθόλη τη διάρκεια της πειραματικής περιόδου, κάτι που κατέστησε και τα ληφθέντα δεδομένα αντίστοιχα της πραγματικότητας.

## 5.2 Δημιουργία μεθόδου βασισμένης στην Επιβλεπόμενη Μάθηση

Για την προσέγγιση που παρουσιάζεται στην παρούσα υποενότητα καθώς και στην επόμενη χρησιμοποιήθηκε κώδικας γραμμένος στη γλώσσα προγραμματισμού Python. Πιο συγκεκριμένα οι ορισμοί για τα μοντέλα και τις τεχνικές που αξιοποιούνται προέρχονται από τη βιβλιοθήκη ανοιχτού λογισμικού Scikit-learn.

Αρχικά, ο εντοπισμός θορύβου προσεγγίστηκε σαν πρόβλημα επιβλεπόμενης μάθησης. Στο υπό εξέταση πρόβλημα στόχος του αλγόριθμου είναι να αποκτήσει τη γνώση ώστε να μπορεί να κατατάξει τα τμήματα του σήματος σε μία εκ των δύο κατηγοριών. Μια κατηγορία που να περιέχει τα artifacts και μια που να περιέχει τα τμήματα του καθαρού σήματος. Πρόκειται, επομένως για ένα πρόβλημα κατηγοριοποίησης (Classification).

Η ροή που ακολουθείται για την ανάπτυξη της μεθόδου, καθώς και τα επιμέρους στάδια που υλοποιούνται φαίνονται χαρακτηριστικά στο σχήμα 5.1. Πρόκειται για ένα τυπικό pipeline μηχανικής μάθησης, από τη συλλογή των δεδομένων ως την παραγωγή προβλέψεων.



Σχήμα 5.1: Τα στάδια του pipeline μηχανικής μάθησης

### 5.2.1 Προετοιμασία των δεδομένων εισόδου

Πρώτο βήμα προκειμένου να μπορούν να χρησιμοποιηθούν τεχνικές μηχανικής μάθησης ήταν η κατάλληλη μοντελοποίηση του προβλήματος. Πιο συγκεκριμένα, τα σήματα τμηματοποιήθηκαν σε δείγματα προκειμένου να μπορούν να εξαχθούν από αυτά χαρακτηριστικά, τα οποία έπειτα θα δίνονταν ως είσοδοι στους αλγόριθμους μηχανικής μάθησης. Για τον σκοπό αυτόν τα σήματα χωρίστηκαν σε παράθυρα των 5 δευτερολέπτων με 1 δευτερόλεπτο επικάλυψη, για να μην χαθεί πληροφορία στα όρια των παραθύρων.

Αξίζει να σημειωθεί πως τα σήματα που αντλήθηκαν, διατηρήθηκαν ακριβώς όπως είχαν παραχθεί από το βραχιόλι. Δεν υπέστησαν δηλαδή κάποιας μορφής φιλτράρισμα ή αποθορυβοποίηση (denoising). Από αυτά, προκειμένου να δοκιμαστούν αλγόριθμοι επιβλεπόμενης μάθησης, επιλέχθηκαν τυχαία δύο σήματα, συνολικής διάρκειας 4.6 ωρών ή αλλιώς 4,146 παραθύρων, στα οποία έγινε labeling. Παρήχθησαν, δηλαδή, ετικέτες (labels) σχετικά με την ύπαρξη θορύβου μέσα σε κάθε παράθυρο. Σε κάθε παράθυρο των 5 δευτερολέπτων δόθηκε μία ετικέτα, 0 ή 1. Η ετικέτα 1 όριζε ότι το σήμα στο παράθυρο περιείχε θόρυβο και η ετικέτα 0 ότι ήταν καθαρό. Η διαδικασία αυτή ήταν απαραίτητη προκειμένου να μπορέσουμε να προσεγγίσουμε το πρόβλημα αξιοποιώντας αλγόριθμους κατηγοριοποίησης. Τη διαδικασία του labeling ανέλαβε και πραγματοποίησε μέλος της ομάδας του data science τμήματος της εταιρείας όντας εξοικειωμένος με το σήμα της ηλεκτροδερματικής δραστηριότητας.

Ακολούθως, πραγματοποιήθηκε η εξαγωγή χαρακτηριστικών από τα δείγματα/παράθυρα. Για το κάθε παράθυρο δημιουργήθηκαν 7 παράγωγα σήματα. Πιο συγκεκριμένα, τα σήματα αυτά ήταν το αρχικό σήμα, η πρώτη και δεύτερη παράγωγος, καθώς και τρία επίπεδα και τα κατάλοιπα της αποσύνθεσης του σήματος με τη χρήση της κυματομορφής Haar. Για τα 7 παράγωγα σήματα υπολογίστηκαν ορισμένα μεγέθη-χαρακτηριστικά για κάθε παράθυρο, κάποια στατιστικά και κάποια φυσικά μεγέθη. Τα μεγέθη αυτά ήταν η μέγιστη, ελάχιστη και μέση τιμή, η τυπική απόκλιση και η ενέργεια του σήματος σε 4 διαστήματα συχνοτήτων. Σε αυτά τα χαρακτηριστικά προστέθηκαν δύο ακόμα λογικές μεταβλητές. Η μία όριζε αν το σήμα στο κάθε παράθυρο ήταν μόνιμα σταθερό και η άλλη αν ήταν μόνιμα αρνητικό. Προέκυψαν, επομένως, 58 χαρακτηριστικά. Στη συνέχεια έγινε κανονικοποίηση του κάθε παραθύρου στο διάστημα 0-1, δηλαδή άλλαξε η κλίμακα των τιμών του σήματος ώστε η ελάχιστη και η μέγιστη τιμή να είναι 0 και 1 αντίστοιχα, και υπολογίστηκαν εκ νέου τα ίδια χαρακτηριστικά για τα νέα παράθυρα. Συνολικά, επομένως, παρήχθησαν 116 χαρακτηριστικά.

Το σύνολο των 116 αυτών χαρακτηριστικών θεωρήθηκε αρκετά μεγάλο, καθώς με το πλήθος τους αυξανόταν και η υπολογιστική πολυπλοκότητα του προβλήματος. Κρίθηκε, επομένως, απαραίτητο να επιλεγθούν τα χαρακτηριστικά εκείνα τα οποία προσέφεραν τη μέγιστη πληροφορία στους αλγόριθμους μηχανικής μάθησης που θα δοκιμάζονταν. Η διαδικασία αυτή πραγματοποιήθηκε σε δύο βήματα.

Αρχικά, ελέγχθηκε η συσχέτιση μεταξύ των χαρακτηριστικών, ώστε να κρατηθούν αυτά που δεν συσχετίζονται ισχυρά μεταξύ τους προκειμένου να μην υπάρξει επανάληψη δεδομένων. Για το σκοπό αυτό υπολογίστηκε ο συντελεστής συσχέτισης Pearson μεταξύ όλων των χαρακτηριστικών ανά δύο. Στη συνέχεια για κάθε ζεύγος χαρακτηριστικών που είχε συντελεστή συσχέτισης μεγαλύτερο ή ίσο του 0.98 αφαιρούνταν το ένα από τα δυο χαρακτηριστικά. Τα χαρακτηριστικά που παρέμειναν ήταν 67.

Δευτερευόντως ακολούθησε η επιλογή χαρακτηριστικών (feature selection), μια διαδικασία που περιγράφεται στην υποενότητα 4.1. Για να ακολουθηθεί αυτή η διαδικασία, όμως, έπρεπε να προηγηθούν ορισμένοι μετασχηματισμοί στα δεδομένα.

Πιο συγκεκριμένα, αρχικά τα δεδομένα χωρίστηκαν σε δυο υποσύνολα, ένα υποσύνολο για την εκπαίδευση των μοντέλων και ένα για τον έλεγχο της απόδοσής τους, train και test sets, με ποσοστά 75% και 25% του συνόλου των δεδομένων αντίστοιχα. Ο λόγος που έγινε αυτό το βήμα είναι διότι κατά τη δημιουργία και αξιολόγηση ενός μοντέλου μηχανικής μάθησης, αυτό πρέπει να αξιολογείται σε δεδομένα που δεν έχει συναντήσει κατά την εκπαίδευσή του, προκειμένου να εγγυάται η αξιοπιστία των αποτελεσμάτων του.

Έπειτα από τον διαχωρισμό των δεδομένων και χρησιμοποιώντας μόνο το σύνολο εκπαίδευσης, έγινε κανονικοποίηση των χαρακτηριστικών. Η κανονικοποίηση που επιλέχθηκε να εφαρμοστεί ήταν η αλλαγή της κλίμακας των δεδομένων, έτσι ώστε οι τιμές του κάθε χαρακτηριστικού να κυμαίνονται πλέον μέσα στο διάστημα 0-1. Ο μετασχηματισμός αυτός των δεδομένων έγινε προκειμένου όλες οι τιμές να βρίσκονται στην ίδια κλίμακα. Αυτό συνέβαλε τόσο στην ευκολότερη οπτική ανάλυση των δεδομένων όσο και την επεξεργασία τους από ορισμένους αλγόριθμους μηχανικής μάθησης.

Αφότου έγινε η κανονικοποίηση των δεδομένων, επιλέχθηκαν να δοκιμαστούν οι κάτωθι τρεις μέθοδοι για την επιλογή των χαρακτηριστικών:

- SelectKBest χρησιμοποιώντας το Mutual information value μεταξύ των τιμών του κάθε χαρακτηριστικού και των ετικετών (labels). Πιο συγκεκριμένα, η μέθοδος αυτή ελέγχει και κρατά τα χαρακτηριστικά που έχουν την πιο ισχυρή συσχέτιση με τις ετικέτες.
- Recursive Feature Elimination (RFECV). Πρόκειται για μια άπληστη μέθοδο που επιδιώκει να βρει το σύνολο των χαρακτηριστικών που μεγιστοποιεί την απόδοση ενός δοθέντος μοντέλου. Συγκεκριμένα, χρησιμοποιήθηκε το μοντέλο Logistic Regression. Ξεκινώντας από όλα τα χαρακτηριστικά, η μέθοδος αφαιρούσε κάθε φορά εκείνο το χαρακτηριστικό που κρίνονταν απ' το μοντέλο ως το λιγότερο σημαντικό. Μετά τη δοκιμή όλων των υποσυνόλων διατηρούνταν αυτό που βελτιστοποιούσε την απόδοση του μοντέλου.
- Feature importance με το μοντέλο Random Forest. Εν προκειμένω, η μέθοδος εκπαιδεύει ένα μοντέλο random forest στα δεδομένα με σκοπό να διαλέξει αυτά τα οποία το μοντέλο έκρινε ως πιο χρήσιμα.

Η μέθοδος SelectKBest επέλεξε 33 χαρακτηριστικά, η μέθοδος RFECV επέλεξε 28 χαρακτηριστικά και η μέθοδος Feature importance επέλεξε 23 χαρακτηριστικά, όπως φαίνονται αναλυτικά στον ακόλουθο πίνακα.

Μέθοδος	Σύνολο χαρακτηριστικών
SelectKBest with Mutual information	8, 16, 17, 18, 23, 26, 27, 33, 34, 35, 39, 41, 42, 45, 47, 49, 50, 53, 55, 66, 68, 74, 75, 76, 81, 82, 91, 92, 99, 100, 105, 107, 108
RFECV with Logistic Regression	8, 9, 16, 17, 18, 26, 33, 34, 35, 41, 42, 49, 50, 67, 76, 81, 82, 90, 91, 93, 98, 99, 103, 107, 108, 111, 113, 114
Feature importance with Random Forest	8, 16, 17, 18, 27, 31, 41, 42, 49, 50, 60, 66, 68, 74, 75, 76, 82, 84, 95, 99, 103, 108, 111

**Πίνακας 5.1: Υποσύνολα χαρακτηριστικών που επιλέχθηκαν από τις μεθόδους επιλογής χαρακτηριστικών**

Τα κοινά χαρακτηριστικά που επέλεξαν οι παραπάνω μέθοδοι είναι 11, κάτι που υποδεικνύει πως τα υποσύνολα διαφέρουν μεταξύ τους. Δε θα μπορούσε, λοιπόν, να εξαχθεί ένα μοναδικό υποσύνολο χαρακτηριστικών. Έτσι, κρίθηκε απαραίτητο να δοκιμαστούν όλα τα παραπάνω υποσύνολα με τους αλγόριθμους μηχανικής μάθησης που επιλέχθηκαν, προκειμένου να αναδειχθεί το πλέον κατάλληλο υποσύνολο για τον κάθε αλγόριθμο.

### 5.2.2 Προετοιμασία των μοντέλων και αξιολόγηση των από αποτελεσμάτων

Όσον αφορά στα μοντέλα μηχανικής μάθησης που αποφασίστηκε να δοκιμαστούν ως προς την κατηγοριοποίηση των τμημάτων του σήματος, αυτά είναι τα ακόλουθα.

- Logistic Regression
- Support Vector Machines (SVM)
- Random Forest
- K-Nearest Neighbors

Για την επιλογή των κατάλληλων χαρακτηριστικών για κάθε ένα από τα προτεινόμενα μοντέλα, δοκιμάστηκαν εξαντλητικά όλα τα υποσύνολα που προέκυψαν από τη διαδικασία επιλογής χαρακτηριστικών. Για να γίνει ο έλεγχος πραγματοποιήθηκε cross validation 5

διπλωμάτων (5-fold) χρησιμοποιώντας το σετ δεδομένων εκπαίδευσης. Τα υποσύνολα χαρακτηριστικών που έδωσαν τα βέλτιστα αποτελέσματα για το κάθε μοντέλο παρουσιάζονται στον πίνακα 5.2.

Μοντέλο	Μέθοδος επιλεγμένων χαρακτηριστικών
K-Nearest Neighbors	Λίστα χαρακτηριστικών από SelectKBest
SVM	Λίστα χαρακτηριστικών από RFECV
Logistic Regression	Λίστα χαρακτηριστικών από RFECV
Random Forest	Λίστα χαρακτηριστικών από Feature Importance

**Πίνακας 5.2: Υποσύνολα χαρακτηριστικών που επιλέχθηκαν για κάθε μοντέλο**

Στη συνέχεια πραγματοποιήθηκε βελτιστοποίηση των υπερπαραμέτρων (hyperparameter tuning) των παραπάνω τεσσάρων αλγορίθμων χρησιμοποιώντας Grid Search. Πιο συγκεκριμένα για κάθε μοντέλο επιλέχθηκε ένα σύνολο από τις διαθέσιμες υπερπαραμέτρους τους και ελέγχθηκαν εξαντλητικά όλοι οι συνδυασμοί από ένα σύνολο τιμών που θα μπορούσαν αυτές να πάρουν ώστε να βρεθεί ο βέλτιστος.

Αφότου επιλέχθηκαν και οι συνδυασμοί των υπερπαραμέτρων για κάθε μοντέλο, ολοκληρώθηκαν όλα τα βήματα πριν την αξιολόγηση των κατηγοριοποιητών. Τα μοντέλα μηχανικής μάθησης εκπαιδεύτηκαν στο σύνολο εκπαίδευσης και εφαρμόστηκαν πάνω στο σύνολο ελέγχου (test set). Για την αξιολόγηση της απόδοσης της κατηγοριοποίησης υπολογίστηκε ένα πλήθος μετρικών. Οι τιμές που προέκυψαν αναγράφονται στον πίνακα 5.3

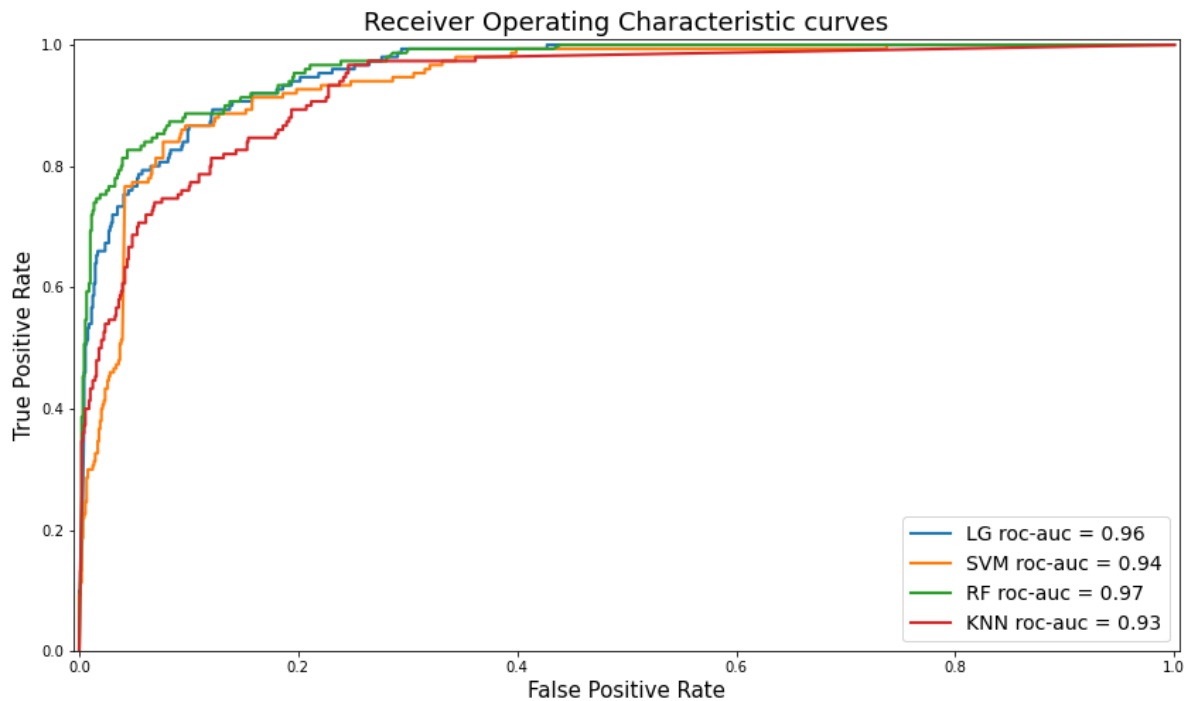
Μοντέλα	Μετρικές αξιολόγησης				
	accuracy	recall	precision	f1_score	roc_auc
Logistic Regression	0.895	<b>0.867</b>	0.594	0.705	0.958
Support Vector Machines	0.889	0.84	0.581	0.687	0.940
Random Forest	<b>0.939</b>	0.72	<b>0.837</b>	<b>0.774</b>	<b>0.964</b>
K-Nearest Neighbors	0.909	0.42	0.9	0.573	0.915

**Πίνακας 5.3: Μετρικές αξιολόγησης επιβλεπόμενης μάθησης**

Από τον παραπάνω πίνακα φαίνεται ότι το μοντέλο Random Forest έχει τα καλύτερα αποτελέσματα σε σχέση με τα υπόλοιπα. Το συγκεκριμένο μοντέλο πετυχαίνει υψηλότερα νούμερα σε όλες σχεδόν τις μετρικές που ελέγχονται. Αντίστοιχα, το λιγότερο αποδοτικό μοντέλο φαίνεται πως είναι το K-Nearest Neighbors, το οποίο παρουσιάζει πολύ χαμηλό

recall, δηλαδή αδυνατεί να κατηγοριοποιήσει σωστά πολλά από τα τμήματα του σήματος που περιέχουν θόρυβο.

Προκειμένου να γίνει πιο ξεκάθαρη η τελευταία μετρική του πίνακα 5.3, η οποία αποτελεί το εμβαδόν κάτω από την Receiver Operating Characteristic καμπύλη, παρατίθεται το σχήμα 5.2, στο οποίο φαίνονται οι εν λόγω καμπύλες για τα τέσσερα μοντέλα.



Σχήμα 5.2: Οι Receiver Operating Characteristic καμπύλες των μοντέλων επιβλεπόμενης μάθησης

### 5.3 Δημιουργία μεθόδου βασισμένης στη μη Επιβλεπόμενη Μάθηση

Εν συνεχεία της προηγούμενης ενότητας ο εντοπισμός θορύβου προσεγγίστηκε και σαν πρόβλημα μη επιβλεπόμενης μάθησης. Στο υπό εξέταση πρόβλημα στόχος του αλγόριθμου είναι να αποκτήσει τη δυνατότητα να διακρίνει τα τμήματα του σήματος που περιέχουν θόρυβο ως μη κανονικό σήμα και επομένως να τα αναγνωρίζει ως artifacts.

Για την ανάπτυξη μιας μεθόδου που να βασίζεται σε τεχνικές μη επιβλεπόμενης μάθησης δεν είναι απαραίτητες οι ετικέτες (labels) για τα δεδομένα εισόδου. Έτσι, τα δεδομένα που χρησιμοποιήθηκαν προηγουμένως για την επιβλεπόμενη κατηγοριοποίηση αξιοποιήθηκαν στην παρούσα ενότητα μόνο για την αξιολόγηση της απόδοσης των μοντέλων και δε συνέβαλαν στην εκπαίδευσή τους.



### *5.3.1 Προετοιμασία των δεδομένων εισόδου*

Για την προσέγγιση ως πρόβλημα μη επιβλεπόμενης μάθησης αξιοποιήθηκαν τα εναπομείναντα διαθέσιμα σήματα, δηλαδή τα 7 σήματα τα οποία δεν πέρασαν από τη διαδικασία του labeling. Τα σήματα αυτά, διάρκειας 17.7 ωρών χωρίστηκαν σε 9,780 παράθυρα των 5 δευτερολέπτων. Για το σύνολο αυτό των δεδομένων παρήχθησαν τα ίδια 116 χαρακτηριστικά, όπως αυτά περιγράφονται στην υποενότητα 5.2.1.

Μετά το στάδιο της παραγωγής χαρακτηριστικών, ακολουθήθηκε και πάλι η διαδικασία ελέγχου και αφαίρεσης των έντονα συσχετιζόμενων χαρακτηριστικών, προκειμένου να μην υπάρχει περιττή πληροφορία στο σύνολο των δεδομένων εκπαίδευσης. Για το σκοπό αυτό, διαγράφηκε ένα χαρακτηριστικό από κάθε ζευγάρι με συντελεστή συσχέτισης Pearson μεγαλύτερο ή ίσο του 0.98. Τα χαρακτηριστικά που παρέμειναν ήταν 53.

Το επόμενο βήμα που πραγματοποιήθηκε ήταν η κανονικοποίηση των μη συσχετιζόμενων χαρακτηριστικών. Συγκεκριμένα, η κανονικοποίηση που επιλέχθηκε να εφαρμοστεί ήταν και εδώ η αλλαγή της κλίμακας των δεδομένων, προκειμένου οι τιμές του κάθε χαρακτηριστικού να κυμαίνονται μέσα στο διάστημα 0-1.

Το γεγονός ότι κατά τη μη επιβλεπόμενη μάθηση δεν υπήρχαν ετικέτες για τα δεδομένα εκπαίδευσης κατέστησε αδύνατο το να ακολουθηθούν τα επόμενα βήματα που υλοποιούνται στην υποενότητα 5.2.1. Πιο συγκεκριμένα, δεν ήταν εφικτό να γίνει επιλογή χαρακτηριστικών. Ως αποτέλεσμα, χρησιμοποιήθηκαν και τα 53 χαρακτηριστικά για την εκπαίδευση και την αξιολόγηση των μοντέλων μη επιβλεπόμενη μάθησης.

### *5.3.2 Προετοιμασία των μοντέλων και αξιολόγηση των από αποτελεσμάτων*

Όσον αφορά στα μοντέλα μη επιβλεπόμενης μάθησης που αποφασίστηκε να δοκιμαστούν για τον εντοπισμό των θορυβωδών τμημάτων του σήματος, αυτά είναι τα ακόλουθα.

- Isolation Forest
- One-class SVM

Η έλλειψη ετικετών στα δεδομένα εκπαίδευσης δεν επέτρεψε την πραγματοποίηση της διαδικασίας της βελτιστοποίησης των υπερπαραμέτρων (hyperparameter tuning) των μοντέλων. Συνεπώς, οι αλγόριθμοι που επιλέχθηκαν δοκιμάστηκαν μόνο με τις προεπιλεγμένες τιμές για τις παραμέτρους τους, όπως αυτές ορίζονται στη βιβλιοθήκη που χρησιμοποιείται.


Ως τελικό στάδιο έγινε η εκπαίδευση των μοντέλων πάνω στα 7 σήματα που αποτελούσαν τα δεδομένα εκπαίδευσης και η εφαρμογή αυτών στα 2 σήματα για τα οποία υπήρχαν

ετικέτες και αποτέλεσαν τα δεδομένα αξιολόγησης. Για την εκτίμηση της απόδοσης των δύο μοντέλων υπολογίστηκε ένα πλήθος μετρικών. Οι τιμές που προέκυψαν παρουσιάζονται χαρακτηριστικά στον πίνακα 5.4.

Μοντέλα	Μετρικές αξιολόγησης				
	accuracy	recall	precision	f1_score	roc_auc
Isolation Forest	<b>0.781</b>	<b>0.818</b>	0.917	<b>0.865</b>	<b>0.833</b>
One-class SVM	0.553	0.492	<b>0.971</b>	0.653	0.824

Πίνακας 5.4: Μετρικές αξιολόγησης μη επιβλεπόμενης μάθησης

Βάσει των τιμών που αναγράφονται, συμπεραίνεται ότι το αποδοτικότερο εκ των δύο μοντέλων, είναι αυτό του Isolation Forest. Πιο συγκεκριμένα, το μοντέλο υπερτερεί στην πλειοψηφία των μετρικών που λαμβάνονται υπόψη. Για τη μεγαλύτερη κατανόηση της τιμής που παρουσιάζεται στην τελευταία στήλη του πίνακα, η οποία δείχνει το εμβαδό κάτω από τη Receiver Operating Characteristic καμπύλη, απεικονίζονται οι καμπύλες των δύο μοντέλων που δοκιμάστηκαν στο σχήμα 5.3.



Σχήμα 5.3: Οι Receiver Operating Characteristic καμπύλες των μοντέλων μη επιβλεπόμενης μάθησης

Συγκρίνοντας τα αποτελέσματα των πινάκων 5.3 και 5.4, φαίνεται ότι οι αποδόσεις των δύο μεθόδων δεν απέχουν πολύ. Ωστόσο, είναι ευδιάκριτο ότι η μέθοδος που βασίζεται στην

επιβλεπόμενη μάθηση προσεγγίζει σε κάθε περίπτωση με μεγαλύτερη επιτυχία τη λύση στο πρόβλημα του εντοπισμού των τμημάτων του σήματος που περιέχουν θόρυβο.

# Κεφάλαιο 6

## 6. Επίλογος

### 6.1. Συμπεράσματα

Στην παρούσα εργασία επιτυγχάνεται η ανάπτυξη μιας ολοκληρωμένης μεθόδου, η οποία βασίζεται σε τεχνικές μηχανικής μάθησης. Πιο συγκεκριμένα, περιγράφονται τα στάδια που απαιτούνται για την κατασκευή της μεθόδου, όπως η συλλογή των δεδομένων, η προεπεξεργασία τους, η παραγωγή χαρακτηριστικών και η επιλογή των πλέον κατάλληλων, η χρήση των μοντέλων μηχανικής μάθησης και τέλος η αξιολόγηση των αποτελεσμάτων τους. Αποδεικνύεται ότι υπάρχει μέθοδος η οποία παρέχει μια αποδοτική λύση στο πρόβλημα του εντοπισμού θορύβου στο βιοσήμα της ηλεκτροδερματικής δραστηριότητας, στο διαχωρισμό δηλαδή των τμημάτων του σήματος με θόρυβο από τα καθαρά.

Αναλύοντας τα αποτελέσματα φτάνουμε σε ορισμένα βασικά συμπεράσματα:

- Αρχικά, συνάγεται το συμπέρασμα ότι είναι εφικτή η χρήση της μηχανικής μάθησης σε ένα πρόβλημα επεξεργασίας σήματος. Με την κατάλληλη μοντελοποίηση του προβλήματος δεν είναι απαραίτητη η βαθιά γνώση του επιστημονικού πεδίου των σημάτων, προκειμένου να επιτευχθεί το επιδιωκόμενο αποτέλεσμα.
- Η χρήση επιβλεπόμενης μάθησης δίνει ικανοποιητικά αποτελέσματα, με το μοντέλο random forest να είναι το αποδοτικότερο ανάμεσα σε αυτά που δοκιμάστηκαν. Αυτά τα αποτελέσματα δείχνουν ότι η ολοκληρωμένη μέθοδος που παρουσιάστηκε ενθαρρύνει την περαιτέρω έρευνα πάνω στις συγκεκριμένες τεχνικές. Επίσης, φαίνεται ότι αξίζει να συγκριθεί η συγκεκριμένη μέθοδος με τους αλγορίθμους που χρησιμοποιεί η εταιρεία στο παραγωγικό λογισμικό της για τον εντοπισμό του θορύβου, καθώς και να ελεγχθεί η γενίκευση των αποτελεσμάτων της στα δεδομένα μεγάλης κλίμακας, τα οποία διαχειρίζεται στο παραγωγικό της περιβάλλον.
- Η μη επιβλεπόμενη μάθηση δεν προσφέρει την αποδοτικότητα που παρατηρείται στην επιβλεπόμενη. Επομένως, δεν συνιστάται η χρήση αυτής της μεθόδου έτσι όπως παρουσιάζεται στη συγκεκριμένη εργασία. Θα πρέπει να δοκιμαστούν διαφορετικά μοντέλα μη επιβλεπόμενης μάθησης και να επανασχεδιαστούν τα χαρακτηριστικά που αναπαριστούν τα δεδομένα.
- Τέλος, οδηγούμαστε στο συμπέρασμα ότι ο χρόνος που δαπανάται για την παραγωγή ετικετών (labels), προκειμένου να χρησιμοποιηθεί επιβλεπόμενη μάθηση, συμβάλλει σημαντικά στην ανάπτυξη ενός συστήματος που επιλύει αποδοτικά το πρόβλημα εντοπισμού του θορύβου. Αν στόχος είναι η κατασκευή ενός μοντέλου που προσφέρει αξιόπιστα αποτελέσματα, τότε είναι απαραίτητες οι εργατώρες που θα δαπανηθούν για

την κατάλληλη προετοιμασία των δεδομένων που θα χρησιμοποιηθούν για την εκπαίδευση του μοντέλου.

## 6.2. Μελλοντικές Επεκτάσεις

Η παρούσα διπλωματική εργασία προσεγγίζει το πρόβλημα του εντοπισμού του θορύβου με δύο θεμελιώδεις ομάδες μοντέλων μηχανικής μάθησης. Το γεγονός αυτό δείχνει ότι υπάρχουν ακόμα επιλογές τεχνικών μηχανικής μάθησης που μπορούν να εξερευνηθούν, όπως είναι οι αλγόριθμοι που αξιοποιούν δίκτυα. Χαρακτηριστικό παράδειγμα αποτελούν τα νευρωνικά δίκτυα, τα οποία έχουν δοκιμαστεί ξανά ερευνητικά για τον εντοπισμό θορύβου σε άλλα βιοσήματα (Nejedly, et al., 2019).

Επιπλέον, θα μπορούσε να γίνει επέκταση και σε τεχνικές deep learning. Προκειμένου, ωστόσο, να είναι αποδοτικοί τέτοιοι αλγόριθμοι θα πρέπει να ικανοποιούνται ορισμένες προϋποθέσεις, οι οποίες δεν είχαν εξασφαλιστεί στο πλαίσιο της συγκεκριμένης εργασίας. Πρώτον, απαιτούνται σημαντικοί υπολογιστικοί πόροι για την κατασκευή του νευρωνικού δικτύου και την παραγωγή αποτελεσμάτων σε εύλογο χρονικό διάστημα. Δεύτερον, για να μπορέσει το δίκτυο να εκπαιδευτεί σωστά και να δώσει ικανοποιητικά αποτελέσματα χρειάζεται ένα μεγάλο όγκο δεδομένων. Ιδανικά σε αυτή την περίπτωση θα ήταν Δεδομένα Μεγάλης Κλίμακας (Big Data), τόσο ως προς το πλήθος, όσο και ως προς την ποικιλομορφία τους.

Τέλος, όπως επισημάνθηκε, τα αποτελέσματα που παρουσίασε η προσέγγιση της μη επιβλεπόμενης μηχανικής μάθησης δεν ήταν ικανοποιητικά. Αντί, όμως, να απορριφθούν πλήρως οι τεχνικές μη επιβλεπόμενης μάθησης, θα άξιζε να εξεταστούν και να επανασχεδιαστούν κάποια από τα πρώτα στάδια αυτής της μεθόδου. Πιο συγκεκριμένα, υπάρχουν μεγάλα περιθώρια για εξερεύνηση στο στάδιο της παραγωγής των χαρακτηριστικών, όπου θα μπορούσε να ωφελήσει η περαιτέρω εξοικείωση με το σήμα της ηλεκτροδερματικής δραστηριότητας, αλλά και γενικότερα των βιοσημάτων. Έχοντας καλύτερη γνώση του σήματος είναι δυνατό να παραχθεί πλήθος χαρακτηριστικών που εμπεριέχουν πληροφορία για τη μορφολογία του θορύβου και του καθαρού σήματος, ώστε να βοηθά τα μοντέλα μηχανικής μάθησης στο καλύτερο διαχωρισμό τους. Ενδεχομένως, να ήταν χρήσιμο να εξερευνηθεί και η χρήση αυτόματων κωδικοποιητών (autoencoders) για την αυτοματοποιημένη παραγωγή κωδικοποιήσεων-χαρακτηριστικών από το σήμα, χωρίς να έχουν οριστεί εκ των προτέρων από κάποιον. Η σύγκριση με τα χαρακτηριστικά που παρουσιάζονται στην εργασία θα μπορούσε να προσφέρει μια καλύτερη εικόνα ως προς την ποιότητα της πληροφορίας που περιέχουν τα χαρακτηριστικά που χρησιμοποιήθηκαν.

## Κεφάλαιο 7

### 7. Βιβλιογραφία

- Anusha, A., Sukumaran, P., Sarveswaran, V., Shyam, A., Akl, T. J., Preejith, S., . . . others. (2019). Electrodermal activity based pre-surgery stress detection using a wrist wearable. *IEEE journal of biomedical and health informatics*, 92-100.
- Assessments and evaluations for mental illness treatment*. (2015, 09). Retrieved from <https://www.betterhealth.vic.gov.au/health/ServicesAndSupport/assessments-and-evaluations-for-mental-illness-treatment>
- Benedek, M., & Kaernbach, C. (2010). A continuous measure of phasic electrodermal activity. *Journal of neuroscience methods*, 80-91.
- Boucsein, W. (2012). *Electrodermal activity*. Springer Science & Business Media.
- Bradburn, N. M., Rips, L. J., & Shevell, S. K. (1987). Answering autobiographical questions: The impact of memory and inference on surveys. *Science*, 157-161.
- Bradley, M. M., & Lang, P. J. (2000). Affective reactions to acoustic stimuli. *Psychophysiology*, 204-215.
- Bradley, M. M., Miccoli, L., Escrig, M. A., & Lang, P. J. (2008). The pupil as a measure of emotional arousal and autonomic activation. *Psychophysiology*, 602-607.
- Calvo, R. A., & D'Mello, S. (2010). Affect detection: An interdisciplinary review of models, methods, and their applications. *IEEE Transactions on affective computing*, 18-37.
- Chen, W., Jaques, N., Taylor, S., Sano, A., Fedor, S., & Picard, R. W. (2015). Wavelet-based motion artifact removal for electrodermal activity. *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* (pp. 6223-6226). IEEE.
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine learning*, 273-297.
- Dawson, M. E., Schell, A. M., & Filion, D. L. (2007). The electrodermal system. In J. T. Cacioppo, L. G. Tassinary, & G. Berntson, *Handbook of psychophysiology* (pp. 159-181). Cambridge university press.
- Diagnostic and Statistical Manual of Mental Disorders* (5th ed.). (2013). American Psychiatric Association.
- Ekman, P. (1992). An argument for basic emotions. *Cognition & emotion*, 169-200.
- Ekman, P., & Friesen, W. V. (1978). *Facial Action Coding System: A Technique for the Measurement of Facial Movement*. Palo Alto: Consulting Psychologists Press.
- Ellaway, P. H., Kuppaswamy, A., Nicotra, A., & Mathias, C. J. (2010). Sweat production and the sympathetic skin response: Improving the clinical assessment of autonomic function. *Autonomic Neuroscience*, 109-114.
- Farreras, I. G. (2019). History of mental illness. Noba Project Champaign.
- Greco, A., Valenza, G., Lanata, A., Rota, G., & Scilingo, E. P. (2014). Electrodermal activity in bipolar patients during affective elicitation. *IEEE journal of biomedical and health informatics*, 1865-1873.
- Grossman, P. (2004). The LifeShirt: a multi-function ambulatory system monitoring health, disease, and medical intervention in the real world. *Stud Health Technol Inform*, 133-141.
- GSR artifacts*. (n.d.). Retrieved from <https://www.tobiipro.com/learn-and-support/learn/GSR-essentials/gsr-artifacts/>

- Haag, A., Goronzy, S., Schaich, P., & Williams, J. (2004). Emotion recognition using bio-sensors: First steps towards an automatic system. In *Tutorial and research workshop on affective dialogue systems* (pp. 36-48).
- Haghi, M., Thurow, K., & Stoll, R. (2017). Wearable devices in medical internet of things: scientific research and commercially available devices. *Healthcare informatics research*, 4-15.
- Hernandez, J. a. (2011). Call center stress recognition with person-specific models. *International Conference on Affective Computing and Intelligent Interaction*, (pp. 125-134).
- Hernandez, J., Riobo, I., Rozga, A., Abowd, G. D., & Picard, R. W. (2014). Using electrodermal activity to recognize ease of engagement in children during social interactions. *Proceedings of the 2014 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, (pp. 307-317).
- Hofmann, S. G., Asnaani, A., Vonk, I. J., Sawyer, A. T., & Fang, A. (2012). The efficacy of cognitive behavioral therapy: A review of meta-analyses. *Cognitive therapy and research*, 427-440.
- Kocielnik, R., Sidorova, N., Maggi, F. M., Ouwerkerk, M., & Westerink, J. H. (2013). Smart technologies for long-term stress monitoring at work. *Proceedings of the 26th IEEE international symposium on computer-based medical systems*, (pp. 53-58).
- Kumar, V., Sattar, Y., Bseiso, A., Khan, S., & Rutkofsky, I. H. (2017). The effectiveness of internet-based cognitive behavioral therapy in treatment of psychiatric disorders. *Cureus*.
- Lang, P. J., Bradley, M. M., Cuthbert, B. N., & others. (1997). International affective picture system (IAPS): Technical manual and affective ratings. *NIMH Center for the Study of Emotion and Attention*.
- Liu, F. T., Ting, K. M., & Zhou, Z.-H. (2008). Isolation forest. *2008 eighth IEEE international conference on data mining* (pp. 413-422). IEEE.
- Mandell, W. (1995). *Origins of Mental Health*. Retrieved from <https://www.jhsph.edu/departments/mental-health/about-us/origins-of-mental-health.html>
- Mental health: What's normal, what's not.* (2019). Retrieved from <https://www.mayoclinic.org/healthy-lifestyle/adult-health/in-depth/mental-health/art-20044098>
- Mental Illness.* (2021, January). Retrieved from <https://www.nimh.nih.gov/health/statistics/mental-illness>
- Nejedly, P., Cimbalnik, J., Klimes, P., Plesinger, F., Halamek, J., Kremen, V., . . . others. (2019). Intracerebral EEG artifact identification using convolutional neural networks. *Neuroinformatics*, 225-234.
- Nie, D., Wang, X.-W., Shi, L.-C., & Lu, B.-L. (2011). EEG-based emotion recognition during watching movies. 667--670.
- Öhman, A. (1981). Electrodermal activity and vulnerability to schizophrenia: A review. *Biological Psychology*, 87-145.
- Organization, W. H. (2001). *The World Health Report 2001: Mental health: new understanding, new hope*. World Health Organization.
- Oswald, M. E., & Grosjean, S. (2004). Confirmation bias. *Cognitive illusions: A handbook on fallacies and biases in thinking, judgement and memory*.

- Pierce, M., Hope, H., Ford, T., Hatch, S., Hotopf, M., John, A., . . . Abel, K. (2020). Mental health before and during the COVID-19 pandemic: a longitudinal probability sample survey of the UK population. *The Lancet Psychiatry*, 883-892.
- Poh, M.-Z., Swenson, N. C., & Picard, R. W. (2010). A wearable sensor for unobtrusive, long-term assessment of electrodermal activity. *IEEE transactions on Biomedical engineering*, 1243-1252.
- Quazi, M., Mukhopadhyay, S., Suryadevara, N., & Huang, Y.-M. (2012). Towards the smart sensors based human emotion recognition. *2012 IEEE International Instrumentation and Measurement Technology Conference Proceedings*, (pp. 2365-2370).
- Richie, H., & Roser, M. (2018). *Mental Health*. Retrieved from <https://ourworldindata.org/mental-health>
- Schurgin, M., Nelson, J., Iida, S., Ohira, H., Chiao, J., & Franconeri, S. (2014). Eye movements during emotion recognition in faces. *Journal of vision*.
- Shukla, J., Barreda-Ángeles, M., Oliver, J., & Puig, D. (2018). Efficient wavelet-based artifact removal for electrodermal activity in real-world applications. *Biomedical Signal Processing and Control*, 45-52.
- Taylor, S., Jaques, N., Chen, W., Fedor, S., Sano, A., & Picard, R. (2015). Automatic identification of artifacts in electrodermal activity data. *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* (pp. 1934-1937). IEEE.
- Tsitsas, G. D., & Paschali, A. A. (2014). A cognitive-behavior therapy applied to a social anxiety disorder and a specific phobia, case study. *Health psychology research*.
- Valenza, G., & Scilingo, E. P. (2017). Exploiting physiological sensors and biosignal processing to enhance monitoring care in mental health. In *Handbook of Large-Scale Distributed Computing in Smart Healthcare* (pp. 515-550). Springer.
- Vidal, M., Turner, J., Bulling, A., & Gellersen, H. (2012). Wearable eye tracking for mental health monitoring. *Computer Communications*, 1306-1311.
- Vizard, T., Davis, J., White, E., & Beynon, B. (2020). Coronavirus and depression in adults, Great Britain: June 2020. *London: Office for National Statistics*.
- Wang, X.-W., Nie, D., & Lu, B.-L. (2014). Emotional state classification from EEG data using machine learning approach. *Neurocomputing*, 94-106.
- What is Psychotherapy?* (2019). Retrieved from <https://www.psychiatry.org/patients-families/psychotherapy>
- Wilhelm, F. H., & Grossman, P. (2010). Emotions beyond the laboratory: Theoretical fundamentals, study design, and analytic strategies for advanced ambulatory assessment. *Biological psychology*, 552-569.
- Xia, V., Jaques, N., Taylor, S., Fedor, S., & Picard, R. (2015). Active learning for electrodermal activity classification. *2015 IEEE signal processing in medicine and biology symposium (spmb)* (pp. 1-6). IEEE.
- Zhang, Y., Haghdan, M., & Xu, K. S. (2017). Unsupervised motion artifact detection in wrist-measured electrodermal activity data. *Proceedings of the 2017 ACM International Symposium on Wearable Computers*, (pp. 54-57).