



*ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ*

*ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ*

*ΤΜΗΜΑ ΒΙΟΜΗΧΑΝΙΚΗΣ ΣΧΕΔΙΑΣΗΣ ΚΑΙ ΠΑΡΑΓΩΓΗΣ*

**ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ**

**ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ ΣΕ ΙΑΤΡΙΚΑ ΔΕΔΟΜΕΝΑ**

**ΣΥΓΓΡΑΦΕΑΣ:  
ΚΟΥΤΣΗΣ ΧΑΡΙΛΑΟΣ  
ΑΜ: 71446633**

**ΕΠΙΒΛΕΠΩΝ ΚΑΘΗΓΗΤΗΣ:  
ΝΙΚΟΛΑΟΥ ΓΡΗΓΟΡΙΟΣ**

**ΑΘΗΝΑ, ΦΕΒΡΟΥΑΡΙΟΣ 2022**



*ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ*

*ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ*

*ΤΜΗΜΑ ΒΙΟΜΗΧΑΝΙΚΗΣ ΣΧΕΔΙΑΣΗΣ ΚΑΙ ΠΑΡΑΓΩΓΗΣ*

**DIPLOMA THESIS**

**MACHINE LEARNING ON MEDICAL DATA**

**AUTHOR:**

**KOUTSIS CHARILAOS**

**REGISTRATION NUMBER: 71446633**

**SUPERVISOR TEACHER:**

**NIKOLAOU GRIGORIOS**

**ATHENS, FEBRUARY 2022**



*ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ*

*ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ*

*ΤΜΗΜΑ ΒΙΟΜΗΧΑΝΙΚΗΣ ΣΧΕΔΙΑΣΗΣ ΚΑΙ ΠΑΡΑΓΩΓΗΣ*

## **ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ ΣΕ ΙΑΤΡΙΚΑ ΔΕΔΟΜΕΝΑ**

Η Διπλωματική/Πτυχιακή Εργασία εξετάστηκε από την κάτωθι Εξεταστική Επιτροπή:

<b>ΟΝΟΜΑ ΕΠΩΝΥΜΟ</b>	<b>ΒΑΘΜΙΔΑ</b>	<b>ΨΗΦΙΑΚΗ ΥΠΟΓΡΑΦΗ</b>
<b>ΝΙΚΟΛΑΟΥ Γ.</b>	ΛΕΚΤΟΡΑΣ	
<b>ΒΑΣΙΛΕΙΑΔΟΥ Σ.</b>	ΕΠΙΚΟΥΡΗ ΚΑΘΗΓΗΤΡΙΑ	
<b>ΔΡΟΣΟΣ Χ.</b>	ΕΔΙΠ	

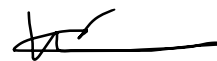
## **ΔΗΛΩΣΗ ΣΥΓΓΡΑΦΕΑ ΠΤΥΧΙΑΚΗΣ/ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ**

Ο/η κάτωθι υπογεγραμμένος/η Κούτσης Χαρίλαος του Χρήστου, με αριθμό μητρώου 71446633 φοιτητής/τρια του Πανεπιστημίου Δυτικής Αττικής της Σχολής Μηχανικών του Τμήματος Βιομηχανικής Σχεδίασης και Παραγωγής, δηλώνω υπεύθυνα ότι:

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

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

Ο/Η Δηλών/ούσα



## **Ευχαριστίες**

Αρχικά, θα ήθελα να ευχαριστήσω τον επιβλέποντα καθηγητή μου Νικολάου Γρηγόριο, που μέσω των διδαγμάτων του με ώθησε να ασχοληθώ με τον τομέα της Μηχανικής Μάθησης. Επίσης, δίνοντας μου τα κατάλληλα εφόδια και συμβουλές με βοήθησε στην υλοποίηση της παρούσας διπλωματικής εργασίας.

Έπειτα, θα ήθελα να ευχαριστήσω και τους δικούς μου ανθρώπους, για τη βοήθεια και τη στήριξη που μου έχουν δώσει.

## Περίληψη

Το στρες θεωρείται βασικός παράγοντας στην επιρροή και επίδραση της λήψης αποφάσεων. Εκτός όμως του στρες, υπάρχει και άλλοι παράγοντες που εμπλέκονται στη διαδικασία λήψη αποφάσεων, όπως είναι ο φόρτος εργασίας, η σωματική και ψυχική προσπάθεια και η προσοχή. Όμως, οι ασάφειες των παραπάνω εννοιών οδηγούν πολλές φορές σε σύγχυση.

Η μεταβλητότητα του καρδιακού ρυθμού (Heart Rate Variability) αποτελεί μια κοινή μέθοδο μέτρησης του στρες. Μέσω της διερεύνησης της σχέσης του στρες και της μεταβλητότητας του καρδιακού ρυθμού, μπορεί να σημειωθεί με πλήρη σιγουριά πως η μεταβλητότητα του καρδιακού ρυθμού ανταποκρίνεται στις όποιες μεταβολές του στρες. Επίσης, με σκοπό την βέλτιστη αξιολόγηση της μεταξύ τους σχέση, γίνεται χρήση των χαρακτηριστικών της μεταβλητότητας του καρδιακού ρυθμού. Όμως, συχνά αντιμετωπίζεται πρόβλημα υπολογιστικής πολυπλοκότητας, λόγω της ποσότητας των χαρακτηριστικών που φθάνουν στα όρια πλεονασμού.

Έναν από τους στόχους της παρούσας διπλωματικής εργασίας αποτελεί η ανίχνευση του ψυχικού στρες, για την οποία χρησιμοποιείται ένα σύνολο δεδομένων ανοικτού κώδικα, το οποίο ονομάζεται SWELL-KW, στο οποίο αποδίδονται τρεις διαφορετικές ετικέτες. Επιπλέον, πραγματοποιείται μελέτη σε πέντε διαφορετικούς αλγορίθμους μηχανικής μάθησης με επίβλεψη, έχοντας ως σκοπό την επίδοση εκείνου του μοντέλου με την υψηλότερη ακρίβεια για τελική χρήση.

Ωστόσο, σημαντικό παράγοντα στη φυσιολογική λειτουργία της καρδιάς αποτελεί και ο έλεγχος των καρδιακών παλμών μέσω ηλεκτροκαρδιογραφήματος (ECG). Το συγκεκριμένο γεγονός έχει ως αποτέλεσμα το δεύτερο στόχο της διπλωματικής εργασίας, ο οποίος αφορά την ανίχνευση της καρδιακής κατάστασης, για την οποία χρησιμοποιείται ο συνδυασμός δύο βάσεων δεδομένων ανοικτού κώδικα, της IT-BIH Arrhythmia Database και της PTB Diagnostic ECG Database, στον οποίο αποδίδονται πέντε διαφορετικές ετικέτες. Για την επιλογή του ιδανικότερου μοντέλου προς χρήση στη συγκεκριμένη εφαρμογή, πραγματοποιείται μελέτη δύο αλγορίθμων βαθιάς μάθησης με επίβλεψη.

### Λέξεις - Κλειδιά

Μεταβλητότητα του καρδιακού ρυθμού, Στρες, Καρδιακός παλμός, Ηλεκτροκαρδιογράφημα, Μηχανική μάθηση, Βαθιά μάθηση

## **Abstract**

Stress is considered as an essential element in influencing and affecting decision-making. But apart from stress, there are other elements involved in the decision making process, such as workload, physical and mental effort and attention. However, the ambiguities of them often lead to confusion.

Heart Rate Variability (HRV) is a common method of measuring stress. By investigating the correlation between stress and heart rate variability, it can be noted that heart rate variability responds to any stress changes. Also, in order to optimally evaluate the correlation between them, the characteristics of heart rate variability are used. Nevertheless, some problem of computational complexity is often encountered due to the amount of features reaching redundancy limits.

One of the objectives of this thesis is the detection of mental stress, for which an open source dataset called SWELL-KW is used, in which three different labels are assigned. In addition, five different supervised machine learning algorithms are studied, aiming at the performance of the model with the highest accuracy for end use.

However, an important factor of the normal functioning of the heart is the monitoring of the heartbeat by an electrocardiogram (ECG). The second objective of this thesis is the detection of cardiac status, for which the combination of two open source databases, the IT-BIH Arrhythmia Database and the PTB Diagnostic ECG Database, are used, in which five different labels are assigned. For selecting of the most ideal model in this application, a study of two supervised deep learning algorithms is performed.

## **Keywords**

Heart Rate Variability, Stress, Heartbeat, Electrocardiogram, Machine learning, Deep learning

# Περιεχόμενα

Ευχαριστίες.....	2
Περίληψη .....	3
Λέξεις - Κλειδιά.....	3
Abstract.....	4
Keywords.....	4
Εισαγωγή .....	7
Κεφάλαιο 1.....	9
1.1 Μηχανική Μάθηση.....	9
1.1.1 Μηχανική Μάθηση με επίβλεψη.....	10
1.1.1.1 Αλγόριθμοι Μηχανικής Μάθησης με επίβλεψη – Ταξινόμηση.....	10
1.2 Βαθιά Μάθηση .....	13
1.2.1 Βαθιά Μάθηση με επίβλεψη .....	14
1.2.1.1 Αλγόριθμοι Βαθιάς Μάθησης με επίβλεψη.....	14
1.3 Πολυπλοκότητα μοντέλων.....	15
Κεφάλαιο 2.....	18
2.1 Μεταβλητότητα του καρδιακού ρυθμού (Heart Rate Variability).....	18
2.2 Η ανατομία της καρδιάς.....	18
2.3 Η ηλεκτρική δραστηριότητα της καρδιάς.....	19
2.4 Μέτρηση μεταβλητότητας του καρδιακού ρυθμού (HRV).....	20
2.5 Μεταβλητότητα του καρδιακού ρυθμού και στρες.....	22
2.5.1 Φυσιολογικές και γνωστικές αντιδράσεις σχετιζόμενες με το στρες .....	23
2.5.2 Διαφορετικές μέθοδοι μέτρησης του ψυχικού στρες.....	24
2.6 Μεταβλητότητα του καρδιακού ρυθμού και εφαρμογές.....	25
Κεφάλαιο 3.....	27
3.1 Εφαρμογή Μηχανικής Μάθησης - Ανίχνευση ψυχικού στρες .....	27
3.1.1 Το σύνολο δεδομένων SWELL-KW .....	27
3.1.2 Συμμετέχοντες και σχεδιασμός .....	27
3.1.3 Δεδομένα και χαρακτηριστικά .....	27
3.1.4 Επιλογή χαρακτηριστικών.....	29
3.1.5 Παράμετρος συντονισμού (Tuning) .....	30
3.1.6 Μοντέλα και συγκρίσεις.....	31
3.1.7 Σύνοψη .....	36
3.1.8 Δοκιμή μοντέλου.....	37
3.2 Εφαρμογή Βαθιάς Μάθησης - Ανίχνευση καρδιακής κατάστασης .....	38
3.2.1 Η βάση δεδομένων MIT-BIH Arrhythmia .....	38
3.2.2 Η βάση δεδομένων PTB Diagnostic ECG.....	38
3.2.3 Δεδομένα και χαρακτηριστικά .....	38
3.2.4 Μοντέλα και συγκρίσεις.....	43
3.2.5 Σύνοψη .....	47
3.2.6 Δοκιμή μοντέλου.....	47
Κεφάλαιο 4.....	48
4.1 Συμπεράσματα.....	48
4.2 Μελλοντικές εργασίες .....	48
Βιβλιογραφία .....	49
Παράρτημα Α - Κώδικας Python εφαρμογής ανίχνευσης ψυχικού στρες.....	52
Παράρτημα Β - Κώδικας Python εφαρμογής ανίχνευσης καρδιακής κατάστασης.....	54





## Εισαγωγή

Είναι ευρέως γνωστό πως το στρες αποτελεί έναν από τους κυριότερους παράγοντες της καθημερινότητας και συγκεκριμένα παίζει σημαντικό ρόλο στη λήψη αποφάσεων. Κατά τη διάρκεια της οδήγησης, της επικοινωνίας ή ακόμα και κάποιας διάλεξης τίθεται αναγκαία η συνεχής εξισορρόπηση των απαιτήσεων με διάφορες παραμέτρους, όπως είναι η πίεση του χρόνου. Βάσει ποιοτικής έρευνας και πειραμάτων, βγαίνει το συμπέρασμα πως το στρες επηρεάζει, κατά κύριο λόγο, αρνητικά τη διαδικασία λήψης αποφάσεων. Μελέτες δείχνουν πως η σχέση μεταξύ της απόδοσης και του στρες είναι μια καμπύλη έχοντας σχήμα καμπάνας. Οι Nguyen T.A. και Zeng Y. [1] έθεσαν ένα θεωρητικό πλαίσιο, στο οποίο προσδιορίζεται το στρες από το φόρτο εργασίας και τη νοητική ικανότητα, ενώ από την πλευρά της νοητικής ικανότητας, καθορίζεται από τις δεξιότητες, τις επιρροές και τις γνώσεις. Συμπεραίνεται πως η αύξηση του φόρτου εργασίας προκαλεί περισσότερο στρες και μειώνει την ατομική απόδοση. Η μελέτη και η αξιολόγηση του στρες θεωρείται απαραίτητη και μειώνοντας τις συνέπειες που προκαλούνται, επιτυγχάνεται μεγαλύτερη απόδοση.

Το στρες περιλαμβάνει εσωτερικούς και εξωτερικούς στρεσογόνους παράγοντες. Η μέτρηση, όμως, των φυσιολογικών παραμέτρων δε μπορεί να είναι ακριβής στις αντιδράσεις από το στρες και δεν αντιπροσωπεύεται απολύτως ως ψυχικό στρες. Ωστόσο, ο Nguyen T.A. συμπέρανε πως η μεταβλητότητα του καρδιακού ρυθμού συσχετίζεται με το ψυχικό στρες, το ηλεκτροεγκεφαλογράφημα (EEG) συσχετίζεται με τη νοητική προσπάθεια.

Γενικά επικρατεί σύγχυση σχετικά με το στρες, το γνωστικό φόρτο εργασίας, το φόρτο εργασίας, την προσοχή και τη νοητική προσπάθεια. Συνήθως αυτές οι έννοιες χρησιμοποιούνται για να περιγράψουν την ίδια κατάσταση, ενώ στην πραγματικότητα υπάρχουν διαφορές μεταξύ τους. Κάποιοι ερευνητές θεωρούν πως για την αξιολόγηση του γνωστικού φόρτου εργασίας χρησιμοποιείται η ανάλυση της μεταβλητότητας του καρδιακού ρυθμού, ενώ άλλοι ερευνητές υποστηρίζουν πως το ψυχικό στρες επηρεάζει τη μεταβλητότητα του καρδιακού ρυθμού. Επιπλέον, σημειώνεται πως η νοητική προσπάθεια μετριέται τόσο με το δείκτη φόρτου εργασίας της NASA (NASA-TLX) όσο και με ηλεκτροεγκεφαλογράφημα.

Ο Nguyen T.A. απέδειξε επίσης πως η αναλογία της χαμηλής και υψηλής συχνότητας (LF / HF) μπορεί να χρησιμοποιηθεί ως μέσον αξιολόγησης του ψυχικού στρες. Η μεταβλητότητα του καρδιακού ρυθμού και το ηλεκτροεγκεφαλογράφημα θεωρούνται αρκετά αξιόπιστες μέθοδοι για την αξιολόγηση του ψυχικού στρες. Δεδομένου όμως ότι διάφορες μέθοδοι χρησιμοποιούνται για τη μέτρηση του στρες, επικρατεί ένα αρκετά μεγάλο φάσμα απόψεων σχετικά με το συγκεκριμένο θέμα. Ωστόσο, προκύπτει ένα πρόβλημα και συγκεκριμένα αφορά την επιλογή των κατάλληλων χαρακτηριστικών. Στην παρούσα διπλωματική εργασία, διερευνάται το ψυχικό στρες βάσει της μεταβλητότητας του καρδιακού ρυθμού.

Το σύνολο δεδομένων μεταβλητότητας του καρδιακού ρυθμού (HRV) που χρησιμοποιήθηκε στην παρούσα διπλωματική εργασία, βασίζεται στο σύνολο δεδομένων SWELL Knowledge Work (SWELL-KW). Στο συγκεκριμένο σύνολο δεδομένων πραγματοποιήθηκε έρευνα για το στρες και τη μοντελοποίηση του χρήστη. Υπήρξαν τυπικές εργασιακές πιέσεις στους συμμετέχοντες, όπως η πίεση να τελειώνουν την εργασία τους στην ώρα που έπρεπε και οι απρόσμενες διακοπές ηλεκτρονικών ταχυδρομείων (e-mails). Για το σύνολο δεδομένων SWELL-KW συμμετείχαν 25 άτομα, στα οποία λήφθηκαν δεδομένα μεταβλητότητας καρδιακού ρυθμού. Τα χαρακτηριστικά που χρησιμοποιήθηκαν, περιλάμβαναν το πεδίο χρόνου και συχνότητας, την τυπική απόκλιση των RR διαστημάτων και το μέσο τετράγωνο των διαδοχικών διαφορών της καρδιακής δραστηριότητας. Το συγκεκριμένο σύνολο

δεδομένων αποτελείται από 35 χαρακτηριστικά και 3 ετικέτες. Επιπλέον, χρησιμοποιήθηκαν 5 αλγόριθμοι μηχανικής μάθησης με επίβλεψη για ταξινόμηση, δηλαδή ο αλγόριθμος Decision Tree, ο αλγόριθμος Random Forest, ο αλγόριθμος Logistic Regression, ο αλγόριθμος K-Nearest Neighbors και ο αλγόριθμος Gradient Boosted Decision Trees, με σκοπό την επιλογή του καταλληλότερου μοντέλου για την εύρεση καταστάσεων ψυχικού στρες.

Όσον αφορά τον τομέα της καρδιακής κατάστασης, ο έλεγχος των καρδιακών παλμών με τη χρήση ηλεκτροκαρδιογραφήματος (ECG), το οποίο αποτελεί μία από τις ταχύτερες και απλούστερες μεθόδους που χρησιμοποιούνται για την αξιολόγηση της καρδιάς. Ένα ηλεκτροκαρδιογράφημα καταγράφει τα ερεθίσματα της καρδιάς με σκοπό να δείξει την ταχύτητα που χτυπάει, τον ρυθμό των καρδιακών παλμών, εάν είναι σταθερός ή ανώμαλος, καθώς και το συγχρονισμό των ηλεκτρικών παλμών κατά τη διάρκεια που κινούνται μέσω των τμημάτων της καρδιάς. Το ηλεκτροκαρδιογράφημα (ECG) και οι μεταβολές που μπορούν να υπάρξουν σε αυτό μπορούν να αποτελέσουν ένδειξη για παθήσεις που σχετίζονται με την καρδιά.

Το σύνολο δεδομένων που χρησιμοποιήθηκε στην ανίχνευση της καρδιακής κατάστασης αποτελεί συνδυασμό δύο βάσεων δεδομένων της IT-BIH Arrhythmia και της PTB Diagnostic ECG. Για τις βάσεις δεδομένων IT-BIH Arrhythmia και PTB Diagnostic ECG χρησιμοποιήθηκαν 109446 δείγματα με συχνότητα δείγματος τα 125Hz (Hertz) και 14552 δείγματα με συχνότητα δείγματος τα 125Hz αντίστοιχα ως έξοδο ταξινόμησης 5 ετικετών. Τέλος, μελετήθηκαν και χρησιμοποιήθηκαν 2 αλγόριθμοι βαθιάς μάθησης με επίβλεψη για ταξινόμηση, και συγκεκριμένα ο αλγόριθμος Convolutional Neural Network και ο αλγόριθμος Long Short-Term Memory Network, με σκοπό την επιλογή του ιδανικότερου μοντέλου για την ανίχνευση της καρδιακής κατάστασης.

# Κεφάλαιο 1

## 1.1 Μηχανική Μάθηση


Η μηχανική μάθηση αφορά τη γνώση του υπολογιστή μέσω κάποιων δεδομένων. Αποτελείται από ένα ερευνητικό πεδίο της τεχνητής νοημοσύνης, της στατιστικής και της επιστήμης των υπολογιστών και είναι γνωστή ως στατιστική μάθηση ή προγνωστική ανάλυση. Μπορεί να σημειωθεί πως η εφαρμογή της μηχανικής μάθησης είναι πανταχού παρούσα στην καθημερινότητα τα τελευταία χρόνια, όπως οι αυτόματες προτάσεις για ταινίες, προτάσεις παραγγελιών φαγητού και διάφορων προϊόντων για αγορά, αναγνώριση προσώπων σε ψηφιακές φωτογραφίες, κα. Αρκετοί σύγχρονοι ιστότοποι χρησιμοποιούν κατά κύριο λόγο αλγόριθμους μηχανικής μάθησης. Πέρα των εμπορικών εφαρμογών, η μηχανική μάθηση αποτελεί ένα ισχυρό εργαλείο διάφορων επιστημονικών προβλημάτων, όπως η εύρεση μακρινών πλανητών, η κατανόηση του σύμπαντος, η ανάλυση του DNA, η θεραπεία καρκίνου, κα. Στη μηχανική μάθηση, η αυτοματοποίηση της διαδικασίας λήψης αποφάσεων *απαρτίζεται από τα πιο επιτυχημένα είδη αλγορίθμων*. Οι αλγόριθμοι αυτοί αναλύονται στις παρακάτω κατηγορίες:

**Μηχανική Μάθηση με επίβλεψη (Supervised).** Οι αλγόριθμοι σε αυτήν την κατηγορία έχουν τη δυνατότητα να εφαρμόσουν οτιδήποτε έχουν εκπαιδευτεί στο παρελθόν σε καινούργια δεδομένα. Αρχίζοντας με την ανάλυση ενός γνωστού συνόλου δεδομένων, ο αλγόριθμος παράγει μια συνάρτηση με σκοπό την πρόβλεψη σχετική των τιμών εξόδου. Ο αλγόριθμος επίσης, είναι ικανός να συγκρίνει την έξοδο του με την αντίστοιχα σωστή και να βρίσκει τα σφάλματα με στόχο την τροποποίηση του μοντέλου ανάλογα.

**Μηχανική Μάθηση χωρίς επίβλεψη (Unsupervised).** Η μηχανική μάθηση χωρίς επίβλεψη χρησιμοποιείται σε συστήματα που μπορούν να συμπεράνουν μια συνάρτηση, με αποτέλεσμα την περιγραφή μίας κρυφής δομής, έχοντας χρησιμοποιήσει δεδομένα χωρίς ετικέτα. Τα συστήματα αυτά δε μπορούν να βρουν τη σωστή έξοδο, όμως εξερευνώντας τα δεδομένα έχουν τη δυνατότητα να βγάλουν συμπεράσματα από το σύνολο δεδομένων.

**Ημι-επιβλεπόμενη Μηχανική Μάθηση (Semi-Supervised).** Η συγκεκριμένη κατηγορία εμπίπτει μεταξύ της μηχανικής μάθησης με επίβλεψη και της μηχανικής μάθησης χωρίς επίβλεψη, καθώς χρησιμοποιούνται δεδομένα με και χωρίς ετικέτα για την εκπαίδευση του μοντέλου. Τα συστήματα που χρησιμοποιούν την ημι-επιβλεπόμενη μηχανική μάθηση έχουν τη δυνατότητα βελτίωσης της ακρίβειας μάθησης.

**Ενισχυτική Μάθηση (Reinforcement).** Η ενισχυτική μηχανική μάθηση είναι μια μέθοδος που αλληλοεπιδρά με το περιβάλλον κάνοντας διάφορες απροσδιόριστες ενέργειες, με αποτέλεσμα την ανταμοιβή ή το σφάλμα. Η μέθοδος αυτή επιτρέπει τον αυτόματο προσδιορισμό των ιδανικών συμπεριφορών προκειμένου να μεγιστοποιηθεί η απόδοση του αλγορίθμου μέσω την ανατροφοδότησης (feedback). [2] [3]



Εικόνα 1.1: Κατηγορίες Μηχανικής Μάθησης

### 1.1.1 Μηχανική Μάθηση με επίβλεψη


Σε ένα απλό μοντέλο μηχανικής μάθησης, η διαδικασία μάθησης χωρίζεται στην εκπαίδευση και στη δοκιμή. Στη διαδικασία της εκπαίδευσης, τα δεδομένα χρησιμοποιούνται ως εισοδοί, τα οποία εκπαιδεύει ο αλγόριθμος μάθησης και δημιουργούν το εκάστοτε μοντέλο. Στη διαδικασία της δοκιμής, χρησιμοποιείται το μοντέλο μάθησης για τα δεδομένα δοκιμής, με στόχο την πρόβλεψη.

Η μηχανική μάθηση με επίβλεψη θεωρείται η πιο κοινή τεχνική για την ταξινόμηση προβλημάτων, δεδομένου ότι ο σκοπός της μηχανής είναι να μάθει ένα σύστημα ταξινόμησης. Κύριο καθήκον της συγκεκριμένης μεθόδου είναι η δημιουργία ενός ικανού μοντέλου πρόβλεψης της ετικέτας ενός αντικειμένου που παρέχεται από ένα ανάλογο σύνολο χαρακτηριστικών. Έπειτα, ο αλγόριθμος λαμβάνει, ως εισόδους, ένα σύνολο χαρακτηριστικών σε συνάρτηση με τις σωστές αντίστοιχες εξόδους και μαθαίνει συγκρίνοντας τες με τις διορθωμένες εξόδους, με αποτέλεσμα να βρει σφάλματα. Στη συνέχεια, το μοντέλο τροποποιείται αναλόγως.

Η μηχανική μάθηση με επίβλεψη αποτελεί την πιο κοινή τεχνική εκπαίδευσης για νευρωνικά δίκτυα και δέντρα απόφασης. Και οι δύο αυτές μέθοδοι εξαρτώνται από πληροφορίες οι οποίες δίνονται από την προκαθορισμένη ταξινόμηση. Επιπλέον χρησιμοποιείται σε εφαρμογές για την πρόβλεψη μελλοντικών γεγονότων από ιστορικά δεδομένα, όπως η πρόβλεψη του είδους ενός φυτού από το σύνολο των μετρήσεων του άνθους του.

Ο συγκεκριμένος τρόπος μάθησης χωρίζεται σε δύο κατηγορίες, την ταξινόμηση και την παλινδρόμηση. Στην ταξινόμηση, η ετικέτα της εξόδου είναι διακριτή, ενώ στην παλινδρόμηση, είναι συνεχής. Ο αλγόριθμος πραγματοποιεί διακρίσεις μεταξύ των δεδομένων  $X$ , τα οποία χρησιμοποιούνται για την εκπαίδευση του μοντέλου και συνήθως αποτελούν δομημένα δεδομένα που δίνονται κατά τη διάρκεια διαδικασίας της εκπαίδευσης. Ο αλγόριθμος, κατά τη διαδικασία αυτή, δημιουργεί το μοντέλο πρόβλεψης. Έπειτα, το αντίστοιχο μοντέλο δύναται να προβλέψει τις πιθανές ετικέτες για ένα συγκεκριμένο σύνολο δεδομένων. Ανάλογα με τη φύση της εξόδου  $y$ , η μηχανική μάθηση με επίβλεψη ταξινομείται ως:

- Ταξινόμηση (Classification), εάν η έξοδος  $y$  έχει σταθερές διακριτές τιμές.
- Παλινδρόμηση (Regression), εάν η έξοδος  $y$  έχει εναλλασσόμενες αριθμητικές τιμές. [4]

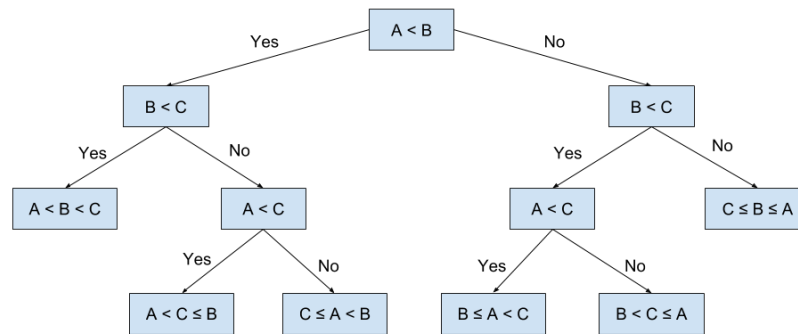


Εικόνα 1.2: Μηχανική Μάθηση με επίβλεψη

#### 1.1.1.1 Αλγόριθμοι Μηχανικής Μάθησης με επίβλεψη – Ταξινόμηση Decision tree

Ένα δέντρο απόφασης, ή αλλιώς Decision Tree, αποτελεί ένα εργαλείο λήψης αποφάσεων στο οποίο χρησιμοποιείται ένα δενδροειδές μοντέλο. Το συγκεκριμένο είδος είναι ένας τρόπος απεικόνισης αλγορίθμου που εμπεριέχει ένα σύστημα ελέγχου καταστάσεων. Η μορφή του δέντρου απόφασης απαρτίζεται από αρχικούς κόμβους, εσωτερικούς κόμβους και κόμβους φύλλου. Οι αρχικοί κόμβοι αναπαριστούν την αφετηρία του δέντρου, οι εσωτερικοί κόμβοι αντιπροσωπεύουν κάποια χαρακτηριστικά και οι κόμβοι φύλλου αντιπροσωπεύουν τις κλάσεις του συνόλου δεδομένων.

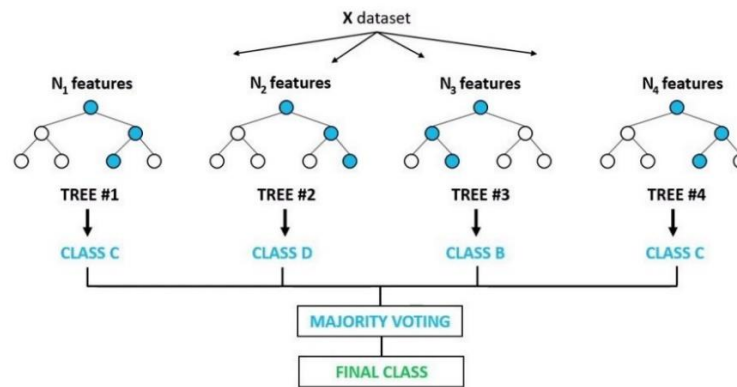
Ουσιαστικά η δομή ενός δέντρου απόφασης είναι παρεμφερής με αυτή του διαγράμματος ροής.



Εικόνα 1.3: Ταξινόμηση αριθμών χρησιμοποιώντας δέντρο απόφασης

### Random Forest

Ο αλγόριθμος Random Forest βασίζεται στην έννοια των δέντρων απόφασης και πιο συγκεκριμένα στην ανάπτυξη πολλαπλών δέντρων από τη τυχαία δειγματοληψία χαρακτηριστικών εισόδου. Στη συνέχεια, τα αποτελέσματα συνδυάζονται με ψηφοφορία ή με την έξοδο του κανόνα μεγίστου. Αποτελεί έναν αλγόριθμο εκμάθησης, ο οποίος δημιουργεί ένα σύνολο ταξινόμησης. Επίσης, απαρτίζεται από διαφορετικά και ανεξάρτητα δέντρα απόφασης και κάθε ένα δημιουργείται και ταξινομείται με την εισαγωγή νέου δείγματος εισόδου. Κάθε δέντρο απόφασης κατέχει το δικό του αποτέλεσμα και ο αλγόριθμος είναι εκείνος που θα επιλέξει αυτό με τη μεγαλύτερη ψηφοφορία ως τελικό αποτέλεσμα. Τα δείγματα, τα οποία λαμβάνονται από τη διαδικασία εκπαίδευσης, μπορούν να συμβάλουν στη δημιουργία νέων διαφορετικών δέντρων απόφασης. Έπειτα, όλα τα δέντρα απόφασης που έχουν δημιουργηθεί, χρησιμοποιούνται στο τελικό στάδιο που αφορά την πρόβλεψη, με τη χρήση, συνήθως, ενός συνόλου δεδομένων για τη δοκιμή και εξέταση του αλγορίθμου.




Εικόνα 1.4: Δομή αλγορίθμου Random Forest

### Logistic Regression

Η λογιστική παλινδρόμηση, ή αλλιώς Logistic Regression, αποτελεί ένα στατιστικό μοντέλο για ταξινόμηση και σε αντίθεση με τη γραμμική παλινδρόμηση, τα αποτελέσματα της κατηγοριοποιούνται στην πιθανότητα να είναι θετικά ή αρνητικά. Πιο συγκεκριμένα, για κάποιο  $x_i \in R^P$ , του οποίου η έξοδος συμβολίζεται με  $y_i$ , η πιθανότητα να είναι θετική η έξοδος προβλέπεται ως  $P\{y_i = +1\} = \frac{1}{1+e^{-\beta^T x_i}}$ , δεδομένης της παραμέτρου  $\beta$  του μοντέλου. Με σκοπό να χρησιμοποιείται μία παράμετρος που αποδίδει με τον καλύτερο τρόπο, συχνά ένα σύνολο δειγμάτων ταξινόμησης συλλέγεται για την


εκμάθηση της παραμέτρου  $\beta$ . Στην πράξη όμως, τα δείγματα που χρησιμοποιούνται για την εκπαίδευση, μπορούν να επιφέρουν σφάλματα στο μοντέλο και πιο συγκεκριμένα τα δείγματα με ακραίες τιμές διαστρεβλώνουν την εκτίμηση των παραμέτρων, με συνέπεια τη μείωση της απόδοσης του μοντέλου.



Εικόνα 1.5: Απεικόνιση λογιστικής παλινδρόμησης

### K-Nearest Neighbors (KNN)

Ο αλγόριθμος K-Nearest Neighbors είναι ένας από τους απλούστερους αλγορίθμους για ταξινόμηση και χρησιμοποιείται αρκετά συχνά για πολλές εφαρμογές. Αποτελεί μια μη παραμετρική στατιστική μέθοδο τόσο για ταξινόμηση όσο και για παλινδρόμηση. Η λογική με την οποία λειτουργεί ο συγκεκριμένο αλγόριθμος είναι η αναζήτηση των  $k$ -κοντινότερων γειτόνων αναζητώντας τους μεταξύ των προ-ταξινομημένων δειγμάτων εκπαίδευσης και τους κατατάσσει βάσει της ομοιότητάς τους. Οι κατηγορίες αυτών χρησιμοποιούνται για πρόβλεψη και εάν περισσότεροι από ένας γείτονας ανήκουν στην εκάστοτε κατηγορία, τότε χρησιμοποιείται το άθροισμα αυτών σαν βάρος για την ταξινόμηση. Για παράδειγμα, όπως φαίνεται στην παρακάτω εικόνα, εάν  $k$ -κοντινότεροι γείτονες = 3, τα τρία πλησιέστερα σημεία του κόκκινου κύκλου είναι δύο μωβ κύκλοι και ένας κίτρινος. Βάσει των στατιστικών μεθόδων, ο κόκκινος κύκλος ανήκει στην κατηγορία των μωβ κύκλων. Ωστόσο, εάν  $k$ -κοντινότεροι γείτονες = 6, τα έξι πλησιέστερα σημεία του κόκκινου κύκλου είναι δύο μωβ κύκλοι και τέσσερεις κίτρινοι. Τότε, ο κόκκινος κύκλος ανήκει στην κατηγορία των κίτρινων κύκλων.

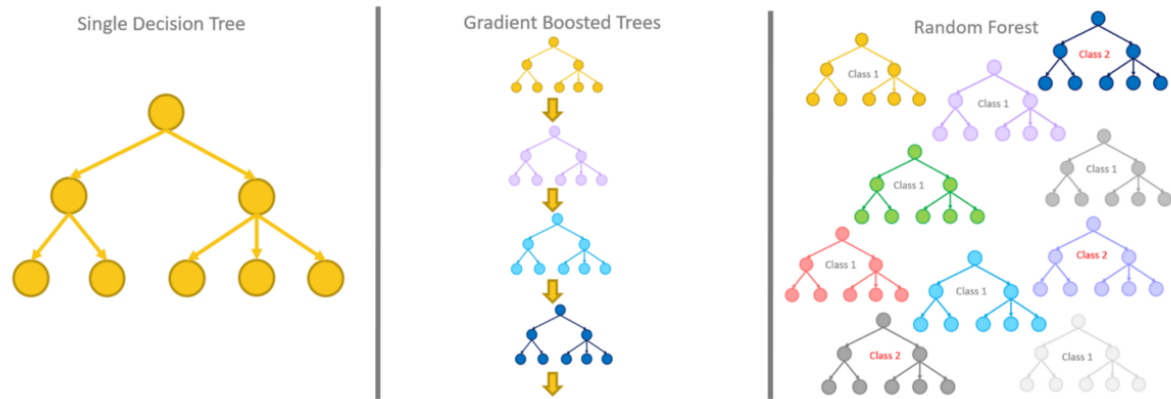


Εικόνα 1.6: Παράδειγμα KNN αλγορίθμου

### Gradient Boosted Decision Trees (GBDT)

Μια ακόμη μέθοδος στον κλάδο των δέντρων αποφάσεων είναι ο αλγόριθμος Gradient Boosted Decision Trees ή αλλιώς GBDT, ο οποίος έχει εφαρμοστεί σε αρκετές εφαρμογές με μεγάλη επιτυχία

και το κύριο πλεονέκτημά του είναι η εύρεση μη γραμμικών αλληλεπιδράσεων κατά τη διαρκεία εκπαίδευσης των δέντρων αποφάσεων με το μικρότερο σφάλμα. Σε κάθε επανάληψη δημιουργείται ένας ασθενής ταξινομητής και ο καθένας εκπαιδεύεται με βάση τους προηγούμενους. Πιο συγκεκριμένα, ο συγκεκριμένος αλγόριθμος σε κάθε επανάληψη δημιουργείται ένα νέο δέντρο απόφασης, πριν όμως το ξεκίνημα κάθε επανάληψης, υπολογίζεται η πρώτη και η δεύτερη παράγωγος συνάρτησης απωλειών. Έπειτα, δημιουργείται ένα νέο δέντρο απόφασης και υπολογίζεται η προβλεπόμενη τιμή και τέλος, προστίθεται το νέο δέντρο απόφασης στο υπάρχον μοντέλο.



Εικόνα 1.7: Δομές των αλγορίθμων Decision Tree, Gradient Boosted Decision Trees και Random Forest

## 1.2 Βαθιά Μάθηση

Η βαθιά μάθηση αποτελεί ένα υποσύνολο της μηχανικής μάθησης και πιο συγκεκριμένα, είναι ένα νευρωνικό δίκτυο έχοντας τρία ή περισσότερα επίπεδα. Ωστόσο, αν και ένα νευρωνικό δίκτυο με μόνο ένα στρώμα έχει τη δυνατότητα να κάνει προβλέψεις, τα επιπλέον κρυφά στρώματα βοηθούν στη βελτιστοποίηση των επιδόσεων. Η τεχνολογία της βαθιάς μάθησης χρησιμοποιείται πίσω από αρκετά καθημερινά προϊόντα και υπηρεσίες, όπως είναι τα αυτοκινούμενα οχήματα, οι ψηφιακοί βοηθοί, κα. Τα νευρωνικά δίκτυα βαθιάς μάθησης, προσπαθούν, μέσω ενός συνδυασμού δεδομένων εισόδου, βαρών και κατωφλίου, να μιμηθούν τον ανθρώπινο εγκέφαλο και τρόπο σκέψης. Επιπλέον, αποτελούνται από πολλαπλά στρώματα συνδεδεμένων μεταξύ τους κόμβων, από τα οποία το κάθε ένα στρώμα βασίζεται στο προηγούμενό του, με σκοπό τη βελτίωση της ταξινόμησης και τη βελτιστοποίηση της πρόβλεψης. Η εξέλιξη αυτή των υπολογισμών του νευρωνικού δικτύου ορίζεται ως «forward propagation».

Τα στρώματα της εισόδου και της εξόδου ονομάζονται ορατά στρώματα. Στην περίπτωση του στρώματος εισόδου, εισάγονται τα δεδομένα για επεξεργασία στο μοντέλο βαθιάς μάθησης και στην περίπτωση του στρώματος εξόδου, πραγματοποιείται η ταξινόμηση ή πρόβλεψη.

Για τον υπολογισμό των σφαλμάτων στις προβλέψεις χρησιμοποιούνται αλγόριθμοι πραγματοποιώντας μια διαδικασία που ονομάζεται «back propagation» και στη συνέχεια, ρυθμίζονται κατάλληλα τα βάρη και κατώφλια κινούμενη προς τα πίσω μέσω των στρωμάτων, με σκοπό την εκπαίδευση του μοντέλου. Σε συνεργασία των δύο διαδικασιών, forward propagation και back propagation, το νευρωνικό δίκτυο μπορεί να κάνει προβλέψεις και να διορθώνει τυχόν σφάλματα. Επίσης, με την πάροδο του χρόνου, το μοντέλο γίνεται πιο ακριβές.


Ωστόσο, τα παραπάνω αναπαριστούν τον απλούστερο τύπο νευρωνικού δικτύου βαθιάς μάθησης. Οι αλγόριθμοι βαθιάς μάθησης είναι αρκετά πιο πολύπλοκοι και για την αντιμετώπιση συγκεκριμένων προβλημάτων υπάρχουν διαφορετικοί τύποι νευρωνικών δικτύων.

Όπως οι αλγόριθμοι στη μηχανική μάθηση, έτσι και οι αλγόριθμοι στη βαθιά μάθηση χωρίζονται σε κάποιες κατηγορίες. Οι κατηγορίες αυτές αναλύονται ως:



**Βαθιά Μάθηση με επίβλεψη (Supervised).** Η βαθιά μάθηση με επίβλεψη αναφέρεται στο στόχο που πρέπει να προβλεφθεί, έχοντας την ανάλογη ετικέτα εντός των δεδομένων που έχουν χρησιμοποιηθεί για εκπαίδευση.

**Βαθιά Μάθηση χωρίς επίβλεψη (Unsupervised).** Η βαθιά μάθηση χωρίς επίβλεψη αναφέρεται στο στόχο που πρέπει να προβλεφθεί, όμως μη έχοντας κάποια ετικέτα εντός των δεδομένων που έχουν χρησιμοποιηθεί για εκπαίδευση. [5]




Εικόνα 1.8: Κατηγορίες Βαθιάς Μάθησης

### 1.2.1 Βαθιά Μάθηση με επίβλεψη

Στη βαθιά μάθηση με επίβλεψη απαρτίζονται δύο από τις πιο δημοφιλείς αρχιτεκτονικές, τα Νευρωνικά Δίκτυα Συνελίξεων ή αλλιώς Convolutional Neural Networks (CNN) και τα Αναδρομικά νευρωνικά δίκτυα, ή αλλιώς Recurrent Neural Networks (RNN), τα οποία αποτελούνται από ένα μεγάλο σύνολο αρχιτεκτονικών, όπως είναι τα δίκτυα Long Short-Term Memory (LSTM Networks).

#### 1.2.1.1 Αλγόριθμοι Βαθιάς Μάθησης με επίβλεψη Convolutional Neural Networks

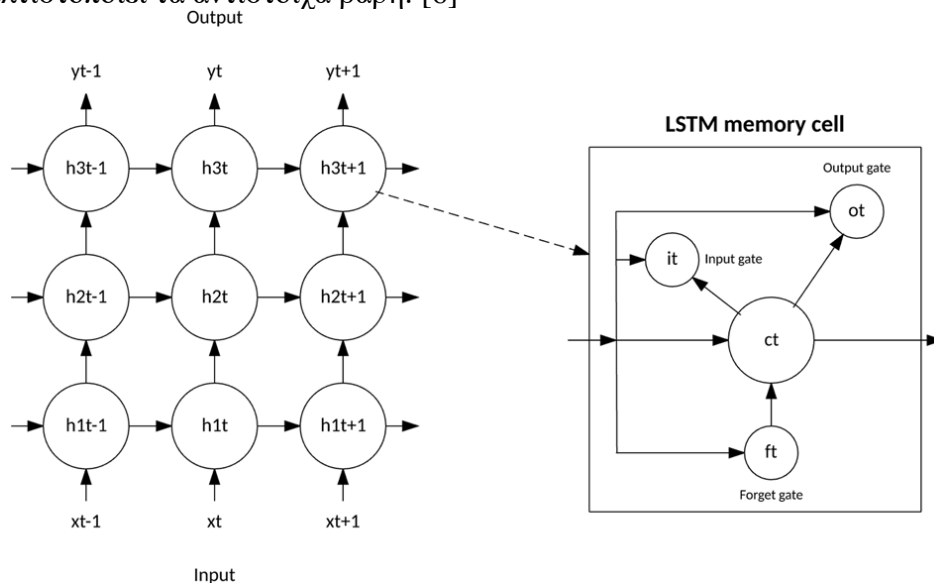
Το Convolutional Neural Network αποτελεί ένα πολυστρωματικό νευρωνικό δίκτυο, του οποίου η αρχιτεκτονική είναι αρκετά χρήσιμη σε εφαρμογές που αφορούν την επεξεργασία εικόνας. Ο Yann LeCun δημιούργησε το πρώτο Convolutional Neural Network, το οποίο ήταν επικεντρωμένο στην αναγνώριση χειρόγραφων χαρακτήρων. Τα αρχικά στρώματα του συγκεκριμένου δικτύου αναγνωρίζουν χαρακτηριστικά και τα επόμενα στρώματα πραγματοποιούν ανασυνδυασμούς των χαρακτηριστικών αυτών σε χαρακτηριστικά μεγαλύτερου επιπέδου. Η αρχιτεκτονική του Convolutional Neural Network απαρτίζεται από διάφορα επίπεδα στα οποία υλοποιείται η εξαγωγή χαρακτηριστικών και η ταξινόμηση. Η χρήση βαθιών στρωμάτων, συγκέντρωσης, συνελίξεων και ενός ολοκληρωμένου συνδεδεμένου στρώματος ταξινόμησης οδήγησε τη χρήση των νευρωνικών δικτύων βαθιάς μάθησης σε αρκετές νέες εφαρμογές. Το Convolutional Neural Network, εκτός της επεξεργασίας εικόνας, έχει εφαρμοστεί με επιτυχία τόσο στην αναγνώριση βίντεο όσο και σε διάφορες εφαρμογές επεξεργασίας της φυσικής γλώσσας. [6]



Εικόνα 1.9: Παράδειγμα CNN αρχιτεκτονικής

## LSTM Networks


Το LSTM Network διαφοροποιείται από τις τυπικές αρχιτεκτονικές νευρωνικών δικτύων, οι οποίες βασίζονται σε νευρώνες, και στη θέση τους εισήγαγε τα κελιά μνήμης. Το κύτταρο μνήμης έχει τη δυνατότητα να διατηρεί την τιμή του ως συνάρτηση των εισόδων του για μικρό ή και μεγάλο χρονικό διάστημα. Το γεγονός αυτό επιτρέπει στο κύτταρο να γνωρίζει και να θυμάται τι είναι σημαντικό και να μη βασίζεται μόνο στην τελευταία υπολογισμένη τιμή. Οι πληροφορίες που εισέρχονται ή εξέρχονται από το κύτταρο ελέγχονται από τρεις (3) πύλες που περιέχει το κύτταρο μνήμης. Η πρώτη πύλη ή αλλιώς πύλη εισόδου, ελέγχει πότε μπορούν οι νέες πληροφορίες να εισέλθουν στη μνήμη. Η δεύτερη πύλη, ή αλλιώς πύλη forget, ελέγχει πότε ξεχνιέται μια υπάρχουσα πληροφορία, δίνοντας τη δυνατότητα στο κύτταρο να θυμάται νέα δεδομένα. Τέλος, η τρίτη πύλη, ή αλλιώς πύλη εξόδου, ελέγχει πότε χρησιμοποιούνται οι πληροφορίες στην έξοδο από το κύτταρο. Επίσης, το κύτταρο περιέχει βάρη που ελέγχουν κάθε πύλη. Βάσει του σφάλματος εξόδου που προκύπτει, ο αλγόριθμος εκπαίδευσης δύναται να βελτιστοποιεί τα αντίστοιχα βάρη. [6]



Εικόνα 1.10: Παράδειγμα LSTM αρχιτεκτονικής

### 1.3 Πολυπλοκότητα μοντέλων

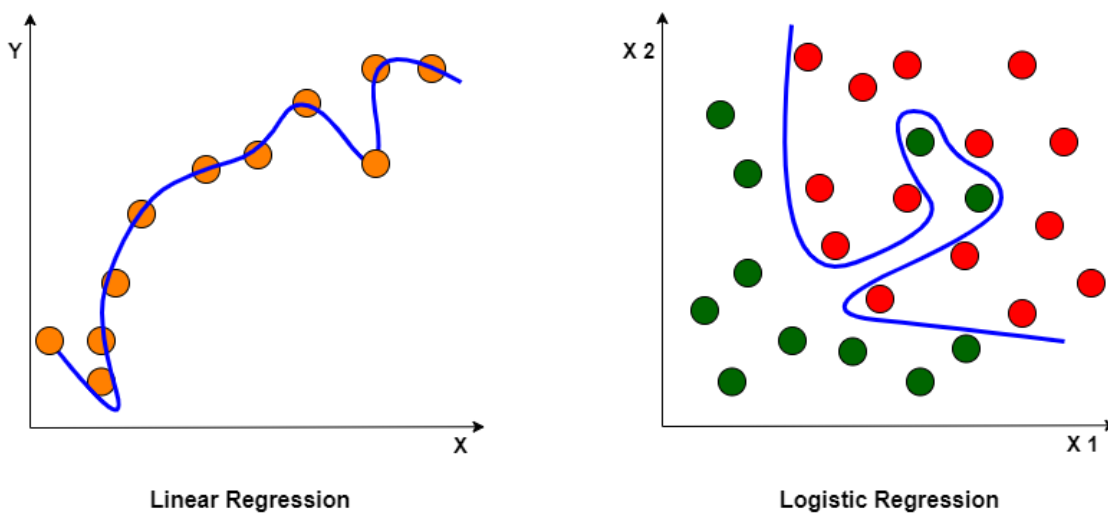
Καλό μοντέλο μηχανικής μάθησης ή αντίστοιχα βαθιάς μάθησης θεωρείται το μοντέλο που γενικεύει οποιαδήποτε δεδομένα εισόδου με κατάλληλο τρόπο. Συγκεκριμένα, το μοντέλο να προβλέπει σωστά μελλοντικά δεδομένα, τα οποία δεν τα έχει δει και επεξεργαστεί ποτέ. Για το σκοπό αυτό, υπάρχει η υπερ-μοντελοποίηση (overfitting) και η υπο-μοντελοποίηση (underfitting), οι οποίες είναι υπεύθυνες για τις κακές και ανακριβείς επιδόσεις των μοντέλων των αλγορίθμων μηχανικής μάθησης.



Εικόνα 1.11: Αποτελέσματα μοντέλων με ικανοποιητική ακρίβεια

### Υπερ-μοντελοποίηση

Ένα μοντέλο θεωρείται πως είναι υπερ-μοντελοποιημένο όταν εκπαιδεύεται με τόσα πολλά δεδομένα που μαθαίνει από τις ανακριβείς καταχωρήσεις δεδομένων και το θόρυβο. Το γεγονός αυτό έχει ως αποτέλεσμα το μοντέλο να μην κατηγοριοποιεί σωστά τα δεδομένα, εξαιτίας του θορύβου και των πολλών λεπτομερειών. Οι αιτίες της υπερ-μοντελοποίησης αποτελούν οι μη γραμμικές και οι μη παραμετρικές μέθοδοι, επειδή μπορούν να δημιουργήσουν μη ρεαλιστικά μοντέλα λόγω της μεγάλης ελευθερίας που τους παρέχεται για τη δημιουργία ενός μοντέλου. Για την αποφυγή της υπερ-μοντελοποίησης δίνεται η χρήση ενός γραμμικού αλγορίθμου, εάν πρόκειται για γραμμικά δεδομένα, ή η χρήση παραμέτρων, όπως είναι το κριτήριο διαχωρισμού στον αλγόριθμο Decision Tree.




Εικόνα 1.12: Αποτελέσματα μοντέλων με υπερ-μοντελοποίηση


### Υπο-μοντελοποίηση

Ένας αλγόριθμος μηχανικής μάθησης λέγεται πως έχει υπο-μοντελοποίηση (underfitting) όταν το μοντέλο του δε μπορεί να προσαρμοστεί καλά στα δεδομένα, με αποτέλεσμα να καταστρέφεται η ακρίβεια του. Συνήθως, υπο-μοντελοποίηση συμβαίνει όταν έχουν χρησιμοποιηθεί λίγα δεδομένα για την εκπαίδευση ενός ακριβές μοντέλου και επιπλέον, όταν δημιουργείται ένα γραμμικό μοντέλο με λιγότερα μη γραμμικά δεδομένα. Στις περιπτώσεις αυτές, το μοντέλο εφαρμόζεται πού εύκολα σε τόσα λίγα δεδομένα και έχει ως επίπτωση τις λανθασμένες προβλέψεις. Για την αποφυγή της υπο-

μοντελοποίησης συνιστάται η χρήση περισσότερων δεδομένων και η επιλογή των κατάλληλων χαρακτηριστικών.



Linear Regression



Logistic Regression

Εικόνα 1.13: Αποτελέσματα μοντέλων με υπο-μοντελοποίηση

## Κεφάλαιο 2

### 2.1 Μεταβλητότητα του καρδιακού ρυθμού (Heart Rate Variability)

Στα μέσα του 20ου αιώνα, αναγνωρίστηκε μια σημαντική επίδραση του Αυτόνομου Νευρικού Συστήματος, συμπεριλαμβανομένου του απρόσμενου θανάτου λόγω καρδιακής ανεπάρκειας. Ο καρδιακός ρυθμός αποτελεί ένα δείκτη ανωμαλιών του Αυτόνομου Νευρικού Συστήματος και κάποια αλλαγή στη μεταβλητότητα του καρδιακού ρυθμού (Heart Rate Variability - HRV) είναι από τους πρώτους παράγοντες πολλών ασθενειών. Επιπλέον, το αυτόνομο νευρικό σύστημα απαρτίζει τον πρωταρχικό μηχανισμό ελέγχου του καρδιακού ρυθμού και τη ρύθμιση αυτού, με αποτέλεσμα να επηρεάζει την ανάπτυξη δεικτών, συμπεριλαμβανομένου ενός από τους πιο δυναμικούς δείκτες, τη μεταβλητότητα του καρδιακού ρυθμού (HRV). Για πρώτη φορά, το 1965, εντοπίστηκε η κλινική σημασία της μεταβλητότητας του καρδιακού ρυθμού από τους Hon και Lee [1], και πιο συγκεκριμένα σημείωσαν πως οι αλλαγές στον καρδιακό ρυθμό προηγήθηκαν των αλλαγών μεταξύ των καρδιακών διαστημάτων και ανακάλυψαν την αποτροπή της παρούσας παθολογικής κατάστασης. Έκτοτε, αρκετές μελέτες και διάφορα ερευνητικά έργα, που αφορούν τη μεταβλητότητα του καρδιακού ρυθμού, έχουν πραγματοποιηθεί. Η μεταβλητότητα του καρδιακού ρυθμού έχει τη δυνατότητα να παρέχει αρκετές και πολύτιμες πληροφορίες που αφορούν τις φυσιολογικές και παθολογικές καταστάσεις, έχοντας και ως αποτέλεσμα την πρόληψη κινδύνου. Στην πράξη, η χρήση της μεταβλητότητας του καρδιακού ρυθμού αυξάνεται συνεχώς, λόγω της υψηλής πρόγνωσης και της απλοϊκής ανάλυσής της. [7]

### 2.2 Η ανατομία της καρδιάς


Η καρδιά αποτελεί μια μυϊκή αντλία έχοντας ρυθμικές συσπάσεις και επιτρέπει μια συνεχόμενη ροή του αίματος διασφαλίζοντας την ανταλλαγή αερίων και θρεπτικών ουσιών. Η καρδιά είναι τυλιγμένη με μια αρκετά λεπτή μεμβράνη, η οποία ονομάζεται περικάρδιο. Βρίσκεται πάνω από το διάφραγμα και πιο συγκεκριμένα στο κεντρικό τμήμα του θώρακα. Το βάρος της καρδιάς κυμαίνεται από 300-350 γραμμάρια για τους άνδρες και 250-300 γραμμάρια για τις γυναίκες. Η καρδιά απαρτίζεται από δύο κόλπους, οι οποίοι λαμβάνουν αίμα, και δύο κοιλίες, στις οποίες μεταφέρεται το αίμα.

Οι κόλποι και οι κοιλίες χωρίζονται από ένα τοίχωμα, του οποίου ο ρόλος είναι να εμποδίζει την ανάμειξη του αίματος της δεξιάς και της αριστερής πλευράς της καρδιάς. Ο δεξιός κόλπος παρέχει το αποξυγονωμένο αίμα στη δεξιά κοιλία, ωθώντας το στους πνεύμονες. Μετά την απελευθέρωση του διοξειδίου του άνθρακα, το οξυγονωμένο αίμα έρχεται στον αριστερό κόλπο. Έπειτα, η αριστερή κοιλία δέχεται το οξυγονωμένο αίμα από τον αριστερό κόλπο και το ωθεί στο υπόλοιπο σώμα.

Ο παλμός της καρδιάς αποτελεί προϊόν ρυθμικών συσπάσεων του καρδιακού μυ, που ονομάζεται μυοκάρδιο. Κατά τη διάρκεια της συστολής, η κοιλία ή ο κόλπος συσπάται, αυξάνοντας έτσι την πίεση μέσα στην καρδιά, με αποτέλεσμα την εκτόξευση αίματος. Στη συνέχεια, η κοιλία ή ο κόλπος χαλαρώνουν και είναι έτοιμοι να λάβουν νέα ποσότητα αίματος.

Το Αυτόνομο Νευρικό Σύστημα (Autonomic Nervous System - ANS) ελέγχει τις συσπάσεις της καρδιάς. Το Αυτόνομο Νευρικό Σύστημα διαιρείται στο Συμπαθητικό Νευρικό Σύστημα (Sympathetic Nervous System - SNS) και στο Παρασυμπαθητικό Νευρικό Σύστημα (Parasympathetic Nervous System - PNS). Το Συμπαθητικό Νευρικό Σύστημα και το Παρασυμπαθητικό Νευρικό Σύστημα λειτουργούν ανταγωνιστικά. Το Συμπαθητικό Νευρικό Σύστημα προετοιμάζει το ανθρώπινο σώμα με σκοπό να ανταποκριθεί σε στρεσογόνες καταστάσεις. Ταυτόχρονα, το Παρασυμπαθητικό Νευρικό Σύστημα ελέγχει τις ελεύθερες λειτουργίες του ανθρώπινου σώματος όταν βρίσκεται σε φυσιολογική κατάσταση. Τα πιο κοινά χαρακτηριστικά που σχετίζονται με το Συμπαθητικό Νευρικό Σύστημα είναι τα εξής:

1. Οι παλμοί της καρδιάς μπορούν να αυξηθούν από 70 σε 150 bpm (beats per minute) μέσα σε 3 δευτερόλεπτα.
2. Η αρτηριακή πίεση μπορεί να διπλασιαστεί μέσα σε 10 δευτερόλεπτα. [7]




Εικόνα 2.1: Η ανατομία της καρδιάς

### 2.3 Η ηλεκτρική δραστηριότητα της καρδιάς

Το ηλεκτροκαρδιογράφημα (Electrocardiogram - ECG) καταγράφει την ηλεκτρική δραστηριότητα της καρδιάς, στην οποία οι καρδιακοί παλμοί εμφανίζονται ως πολλαπλές επαναλαμβανόμενες που χαρακτηρίζονται από τις κορυφές και τις κοιλάδες. Το εύρος συχνοτήτων του ηλεκτροκαρδιογραφήματος κυμαίνεται από 0,05 Hz έως 100 Hz και το δυναμικό εύρος από 1mV έως 10mV.

Το ηλεκτροκαρδιογράφημα χαρακτηρίζεται από πέντε κορυφές και κοιλάδες, οι οποίες επισημαίνονται με τα γράμματα P, Q, R, S, T. Επιπλέον, το ηλεκτροκαρδιογράφημα αποτελεί μια σύνθετη καταγραφή όλων των ενεργειών που παράγονται από το μυοκάρδιο. Στο σύστημα ηλεκτροκαρδιογραφήματος, το κύμα P αναπαριστά την ενεργοποίηση του κόλπου και του άνω θαλάμου της καρδιάς, ενώ το κύμα QRS και το κύμα T αντιπροσωπεύουν τη διέγερση του κάτω θαλάμου της καρδιάς ή της κοιλίας. Το σύμπλεγμα QRS εκφράζει την κοιλιακή συστολή και το κύμα T αντανακλά την επαναπόλωση των κοιλιών. Η ανίχνευση του QRS αποτελεί μία από τις πιο κρίσιμες ενέργειες στην ανάλυση ηλεκτροκαρδιογραφήματος. Μόλις εντοπιστεί το σύμπλεγμα QRS, μπορούν να ληφθούν πιο λεπτομερείς πληροφορίες, όπως είναι ο καρδιακός ρυθμός (HR) και η μεταβλητότητα καρδιακού ρυθμού (HRV).

Το διάστημα RR (RR-interval) είναι το χρονικό διάστημα μεταξύ δύο διαδοχικών QRS συμπλεγμάτων και μπορεί να υπολογιστεί ο στιγμιαίος καρδιακός ρυθμός. Επίσης, το διάστημα RR φανερώνει τη σύνδεση μεταξύ του νευρικού συστήματος και της ισχύος του HRV και διαφέρει από τον καρδιακό ρυθμό, ο οποίος είναι ο μέσος όρος των παλμών ανά λεπτό. [8]



Εικόνα 2.2: Μια τυπική φυσιολογική κυματομορφή ηλεκτροκαρδιογραφήματος

## 2.4 Μέτρηση μεταβλητότητας του καρδιακού ρυθμού (HRV)

Η μεταβλητότητα του καρδιακού ρυθμού είναι ένας γενικός όρος αποτελούμενος από μια σειρά χαρακτηριστικών που προέρχονται από το χρονικό διάστημα μεταξύ δύο διαδοχικών καρδιακών παλμών, τα οποία αναφέρονται ως διαστήματα RR. Η μεταβλητότητα καρδιακού ρυθμού μετριέται με ηλεκτροκαρδιογράφημα κλινικού επιπέδου (electrocardiogram - ECG), αλλά χάρη στην πρόοδο της τεχνολογίας μπορεί πλέον να μετρηθεί και με φορητές συσκευές, όπως είναι οι ιμάντες καρδιακών παλμών.

Το διάστημα RR είναι το χρονικό διάστημα σε χιλιοστά του δευτερολέπτου μεταξύ δύο διαδοχικών καρδιακών παλμών και χρησιμοποιείται για συμπεράσματα της μεταβλητότητας του καρδιακού ρυθμού. Η μεταβλητότητα καρδιακού ρυθμού μπορεί να υπολογιστεί μέσω του χρόνου και της συχνότητας μεταξύ διαδοχικών δειγμάτων RR.

Οι υπολογισμοί με χρήση συχνοτήτων προέρχονται συνήθως από το Lomb-Scaglie, μια παραλλαγή του Μετασχηματισμού Fourier (Fourier Transform). Ο αλγόριθμος Lomb είναι κατάλληλος για δεδομένα με ανομοιόμορφα δείγματα, τα οποία είναι όμοια με αυτά των διαστημάτων RR. Η γενικευμένη μορφή της εξίσωσης Lomb-Scaglie δίνεται από την παρακάτω εξίσωση, όπου τα A, B και T είναι αυθαίρετες συναρτήσεις της συχνότητας  $f$  και των χρόνων παρατήρησης  $t$ . [1]

$$(1) \quad P(f) = \frac{A^2}{2} (\sum_n g_n \cos(2\pi f[t_n - T]))^2 + \frac{B^2}{2} (\sum_n g_n \sin(2\pi f[t_n - T]))^2$$

Η φωτοπληθυσμογραφία (photoplethysmography - PPG) είναι ένας ευρέως χρησιμοποιούμενος αισθητήρας που αφορά τη μέτρηση του καρδιακού ρυθμού και της μεταβλητότητας του καρδιακού ρυθμού. Πιο συγκεκριμένα μετρούνται ηλεκτρικά σήματα, κυρίως το φως, το οποίο ανακλάται από τις αλλαγές της ροής του αίματος. Μελέτες έχουν δείξει πως η φωτοπληθυσμογραφία δεν είναι τόσο ακριβής όσο το ηλεκτροκαρδιογράφημα, το οποίο θεωρείται άριστο εργαλείο για τη μέτρηση της καρδιάς, δίνοντας επίσης και ικανοποιητικά αποτελέσματα των μετρήσεων της μεταβλητότητας του καρδιακού ρυθμού.

Πίνακας 2.1: Μετρήσεις στο φάσμα του χρόνου

SDNN	Standard deviation of normal RR intervals
SDRR	Standard deviation of RR intervals
pNN50	Percentage of successive RR intervals that differ by more than 50 milliseconds
RMSSD	Root mean square of successive RR interval differences

Το SDNN και το SDRR μπορούν να μετρήσουν τα διαστήματα RR, από την άλλη πλευρά το pNN50 και το RMSSD μετρούν τις διαφορές μεταξύ των διαστημάτων RR. Τα χαρακτηριστικά αυτά μπορούν να υπολογιστούν με τους εξής τύπους:

$$(2) \quad SDNN = \sqrt{\frac{1}{N-1} \sum_i (RR_i - RR_m)^2}$$

$$(3) \quad pNN50 = \frac{\sum_{i=1}^N (|R_i - R_{i+1}| > 50ms)}{N-1}$$

$$(4) \quad RMSSD = \sqrt{\frac{1}{N-1} \sum_{i=1}^{N-1} (RR_{i+1} - RR_i)^2}$$

Το  $RR_i$  αντιπροσωπεύει το  $i$ -οστό διάστημα RR, όπου το  $N$  αποτελεί τον συνολικό αριθμό των καρδιακών παλμών και το  $RR_m$  τον μέσο όρο των διαστημάτων RR. Όπως το SDNN, έτσι και το SDRR μπορεί να μετρήσει πως τα διαστήματα αλλάζουν με την πάροδο του χρόνου, περιλαμβανομένων όμως φυσιολογικών ή και μη παλμών.

Πίνακας 2.2: Μετρήσεις στο φάσμα της συχνότητας

ULF power	Absolute power of the ultra-low-frequency band (0.003 Hz)
VLF power	Absolute power of the very-low-frequency band (0.0033–0.04 Hz)
LF peak	Peak frequency of the low-frequency band (0.04–0.15 Hz)
LF power	Absolute power of the low-frequency band (0.04–0.15 Hz)
HF peak	Peak frequency of the high-frequency band (0.15–0.4 Hz)
HF power	Absolute power of the high-frequency band (0.15–0.4 Hz)
LF/HF	Ratio of LF-to-HF power




## 2.5 Μεταβλητότητα του καρδιακού ρυθμού και στρες

Το στρες συναντάται συχνά στην καθημερινότητα ως ένα κοινό ψυχολογικό φαινόμενο. Όσον αφορά τον ορισμό του στρες, περιλαμβάνονται τόσο εσωτερικοί όσο και εξωτερικοί στρεσογόνοι παράγοντες, η αντίληψη της διέγερσης του οργανισμού και η φυσιολογική απόκριση. Επίσης, το στρες απαρτίζουν εκείνο που βασίζεται σε ερεθίσματα και εκείνο που βασίζεται σε αντιδράσεις. Σχετικά με την πρώτη περίπτωση, προκαλείται από ορισμένες περιβαλλοντικές καταστάσεις ή εξωτερικά γεγονότα, τα οποία θεωρούνται στρεσογόνοι παράγοντες. Στη δεύτερη περίπτωση, το στρες αποτελεί ένα πρότυπο αντίδρασης αλλαγών των σωματικών λειτουργιών υπό των στρεσογόνων παραγόντων.

Το ψυχικό στρες διακρίνεται σε οξύ και χρόνιο στρες, ανάλογα την ένταση και τη διάρκεια λειτουργίας των στρεσογόνων παραγόντων. Οι προκλήσεις και η επίδραση που προκύπτουν από έναν στρεσογόνο παράγοντα θεωρούνται προσωρινές και διαρκούν από μερικά λεπτά έως και κάποιες ώρες. Αντίθετα, εάν λειτουργεί ο χρόνιος στρεσογόνος παράγοντας, η διάρκεια του κυμαίνεται από μερικές ώρες κάθε μέρα έως και εβδομάδες, ή ακόμα και μήνες, ο οποίος θεωρείται επαναλαμβανόμενος, επίμονος ή υψηλής έντασης.

Βάσει του νόμου των Yerkes-Dodson [9], φαίνεται η σχέση μεταξύ του στρες και της απόδοσης, η οποία μπορεί να αυξηθεί με τη ψυχική καταπόνηση, έως ότου ενός σημείου, διότι στη συνέχεια, εάν αυξηθεί το στρες, παρουσιάζεται η φθίνουσα πορεία της.



Εικόνα 2.3: Σχέση απόδοσης και ψυχικού στρες

Σύμφωνα με το συγκεκριμένο νόμο, το ψυχικό στρες αποτελεί σημαντικό ρόλο στην ατομική απόδοση. Ωστόσο, δεν παρουσιάζονται οι παράγοντες που επηρεάζουν με τη σειρά τους το ψυχικό στρες. Για το λόγο αυτό, δόθηκε από τους Nguyen T. A. και Zeng Y. το θεωρητικό πλαίσιο που αφορά το ψυχικό στρες:

$$(5) \quad \sigma = \frac{Wp}{(K+S)*\alpha}$$

,όπου το  $Wp$  αφορά το ψυχικό φόρτο εργασίας, το  $K$  αφορά τη γνώση, το  $S$  την ικανότητα, το  $\alpha$  το συναίσθημα και το  $\sigma$  το ψυχικό στρες. Από την εξίσωση (5) μπορεί να διευκρινιστεί πως η ατομική ψυχική ικανότητα καθορίζεται από τις δεξιότητες, τις γνώσεις και τα συναισθήματα. Επομένως, ο ψυχικός φόρτος εργασίας και η ψυχική ικανότητα έχουν τη δυνατότητα να καθορίσουν το ψυχικό στρες.

Το σήμα HRV είναι ένα μη σταθερό σήμα που περιγράφει τις διαφοροποιήσεις μεταξύ διαδοχικών παλμών της καρδιάς. Οι αλλαγές αυτές μπορούν να ερμηνευθούν ως τρέχουσα ή επερχόμενη ψυχολογική ασθένεια. Το αυτόνομο νευρικό σύστημα μπορεί να δημιουργήσει σημαντικές αποκρίσεις στρες στη φυσιολογική κατάσταση του ατόμου. Επίσης, θα δημιουργήσει φυσιολογικές αποκρίσεις όπως καρδιακοί παλμοί, μεταβλητότητα του καρδιακού ρυθμού, αρτηριακή πίεση, κα. Η

μεταβλητότητα του καρδιακού ρυθμού είναι μία μέθοδος μέτρησης, η οποία μπορεί να χρησιμοποιηθεί για τη μέτρηση του ψυχολογικού στρες. Επιπλέον, αποτελεί μια διακύμανση στο διάστημα του καρδιακού παλμού που ελέγχεται από το αυτόνομο νευρικό σύστημα. Έχει τη δυνατότητα να ρυθμίσει την αρτηριακή πίεση, τον καρδιακό ρυθμό, την πέψη και την αναπνοή. Έχει διαπιστωθεί πως το αυξημένο ψυχολογικό στρες συσχετίζεται με μειωμένη μεταβλητότητα του καρδιακού ρυθμού, ειδικά με μειωμένη παρασυμπαθητική ενεργοποίηση, και πιο συγκεκριμένα ως αύξηση του λόγου LF/HF και μείωση της ισχύος RMSSD και HF.

Η πρόκληση του ψυχικού στρες χωρίζεται σε πέντε διαφορετικούς τομείς, οι οποίοι βασίζονται σε στρεσογόνους παράγοντες.

1. **Λειτουργική μνήμη.** Η Λειτουργική μνήμη απαρτίζει την προσωρινή αποθήκευση και χειρισμό των απαραίτητων πληροφοριών που έχουν ως αντικείμενο τις γνωστικές εργασίες. Τα άτομα που έχουν υψηλότερη λειτουργική μνήμη χρησιμοποιούν κυρίως απλούστερες μεθοδολογίες επίλυσης προβλημάτων υπό των υψηλών συνθηκών πίεσης.
2. **Χρόνος αντίδρασης.** Ο χρόνος αντίδρασης μπορεί, σε κάποιο βαθμό, να υποδηλώνει στρες. Επομένως, για την αξιολόγηση του ψυχικού στρες, η μέτρηση του χρόνου αντίδρασης αποτελεί έναν ζωτικής σημασίας παράγοντα. Σε καταστάσεις ηρεμίας και ψυχικής πίεσης και συγκρίνοντας την αρτηριακή πίεση παρατηρούνται κατά τη διάρκεια υπέρτασης διαταραχές του παρασυμπαθητικού και συμπαθητικού καρδιακού ελέγχου.
3. **Επιλεκτική προσοχή.** Η επιλεκτική προσοχή οδηγεί τη συνείδηση σε σχετικά ερεθίσματα και ταυτόχρονα αγνοεί τα ερεθίσματα του περιβάλλοντος. Επομένως, δίνεται κύρια προσοχή σε συγκεκριμένες διαδικασίες, ενώ αγνοούνται άσχετα αντικείμενα του περιβάλλοντος για μια συγκεκριμένη περίοδο.
4. **Φυσική πίεση.** Η κλασική περίπτωση φυσικής πίεσης είναι η ψυχρή πίεση, η οποία απαιτεί την υποδοχή ενός χεριού σε ένα δοχείο με παγωμένο νερό, με αποτέλεσμα των αλλαγών της αρτηριακής πίεσης και του καρδιακού ρυθμού.
5. **Κοινωνικό άγχος.** Ένας επιπλέον σημαντικός παράγοντας για τη μέτρηση του ψυχικού στρες απαρτίζει το κοινωνικό άγχος. Μια δημόσια ομιλία μπορεί να αποτελέσει περίπτωση κοινωνικού άγχους και πιο συγκεκριμένα στη μεταβλητότητα του καρδιακού ρυθμού (HRV), οι τυπικές αποκλίσεις των διαδοχικών διαστημάτων RR παρουσιάζουν αυξήσεις λόγω του αργού ρυθμού αναπνοής. [10]

### 2.5.1 Φυσιολογικές και γνωστικές αντιδράσεις σχετιζόμενες με το στρες

Θεωρείται ευρέως γνωστό πως το ψυχικό στρες βασίζεται από αρκετούς παράγοντες και διάφορα συστήματα του σώματος. Συγκεκριμένα, μελέτες έχουν δείξει πως ο εγκέφαλος εμπλέκεται σημαντικά στην αντίδραση των στρεσογόνων παραγόντων. Λόγω της εξέλιξης της τεχνολογίας και της άμεσης απεικόνισης του εγκεφάλου, έχει αποκτηθεί μια νέα κατανόηση των δικτύων στρες τα τελευταία χρόνια. Τα δίκτυα στρες αποτελούν ένα σύνολο συνδεδεμένων εγκεφαλικών δομών, οι οποίοι τίθενται σε λειτουργία όταν εκτίθενται σε στρεσογόνα γεγονότα στο εξωτερικό τους περιβάλλον. Επίσης, αξίζει να σημειωθεί, πως διάφοροι τύποι στρες, όπως το οξύ και το χρόνια στρες, επιφέρουν διάφορες επιπτώσεις στη μνήμη, στη λήψη αποφάσεων και γενικών στην υγεία.

Οι φυσιολογικές και γνωστικές αντιδράσεις έχουν την ικανότητα να παρακολουθούν και να μετρούν το ψυχικό στρες. Η ενεργοποίηση δύο συστημάτων αντιδράσεως του στρες, της άμεσης δράσης του Συμπαθητικού Νευρικού Συστήματος (SNS) και της βραδύτερης του συστήματος HPA (Hypothalamic–Pituitary–Adrenal), αποτελεί ένα σαφή νευροβιολογικό δείκτη του στρες. Επίσης, μέσω της ενεργοποίησης του συστήματος HPA μπορεί να προκληθεί αυξημένη παραγωγή κορτιζόλης, γνωστή ως ορμόνη του στρες. Συγκεκριμένα, υπό συνθήκες στρες, ενισχύει τη χρήση γλυκόζης στο εγκέφαλο, αυξάνοντας τα επίπεδα σακχάρου στο αίμα.

## 2.5.2 Διαφορετικές μέθοδοι μέτρησης του ψυχικού στρες

Εκτός από τη μεταβλητότητα του καρδιακού ρυθμού, υπάρχουν και άλλες μέθοδοι που μπορούν να χρησιμοποιηθούν για τη μέτρηση του ψυχικού στρες, όπως το ηλεκτροεγκεφαλογράφημα (Electroencephalogram - EEG), η κορτιζόλη και ο δείκτης φόρτου εργασίας της NASA (NASA Task Load Index - NASA-TLX).

**Ηλεκτροεγκεφαλογράφημα.** Τα σήματα του ηλεκτροεγκεφαλογραφήματος παρουσιάζουν ποικίλα χαρακτηριστικά σε διαφορετικά εγκεφαλικά κύματα. Αποτελούν μη σταθερά σήματα με διαφορετικές συχνότητες σε διαφορετικά χρονικά διαστήματα. Επίσης, μέσω του ηλεκτροεγκεφαλογραφήματος αντανακλάται η εγκεφαλική δραστηριότητα και μπορεί να διαγνωστεί το ψυχικό στρες. Βάσει του εύρους συχνοτήτων, τα σήματα ταξινομούνται σε τέσσερις διαφορετικές ζώνες: Delta (1-4 Hz), Theta (4-8 Hz), Alpha (8-13 Hz) και Beta (13-30 Hz). Κάθε ζώνη αντιπροσωπεύει και από έναν διαφορετικό τρόπο λειτουργίας. [10]

Πίνακας 2.3: Λειτουργίες των εγκεφαλικών κυμάτων

Εγκεφαλικά κύματα	Εγκεφαλικά κύματα Χαρακτηριστικά
Delta (1-4Hz)	Κυρίαρχο κατά τη διάρκεια του ύπνου
Theta (4-8Hz)	Κατάσταση αφύπνισης
Alpha (8-13Hz)	Κατάσταση αφύπνισης με κλειστά μάτια
Beta (13-30Hz)	Κυριαρχεί κατά τη διάρκεια της νοητικής δραστηριότητας

Τέλος, σημειώνεται πως το αριστερό ημισφαίριο του εγκεφάλου εμπλέκεται κυρίως στο χειρισμό των θετικών συναισθημάτων και συμπεριφορών, σε αντίθεση με το δεξιό ημισφαίριο το οποίο εμπλέκεται περισσότερο στο χειρισμό των αρνητικών συναισθημάτων και συμπεριφορών.

**Κορτιζόλη.** Η κορτιζόλη είναι ένας από τους πιο δημοφιλείς και κοινούς βιο-δείκτες του στρες. Επιπλέον, κατά τη διάρκεια του ψυχικού στρες, η ενεργοποίηση του συστήματος HPA προκαλεί την έκκριση ορμονών, όπως είναι οι στεροειδείς ορμόνες και η ορμόνη απελευθέρωσης κορτικοτροφίνης. Όμως, αντιμετωπίζονται αρκετές δυσκολίες στη μέτρηση και στην αξιολόγηση του στρες με τη χρήση κορτιζόλης. Αρχικά, δεν είναι εφικτό όλοι οι τύποι αρνητικών στρεσογόνων παραγόντων να ενεργοποιούν το σύστημα HPA με σταθερότητα, με στόχο την πρόκληση μεταβολών της κορτιζόλης. Δεύτερον, ακόμη και αν απελευθερωθεί η κορτιζόλη στην κυκλοφορία του αίματος, τα επίπεδά της μπορούν να επηρεαστούν από αρκετούς παράγοντες, όπως είναι η καφεΐνη, το φύλο και η ηλικία.

**Δείκτης φόρτου εργασίας της NASA.** Ο δείκτης φόρτου εργασίας της NASA χρησιμοποιείται ευρέως στη μέτρηση του στρες. Έχει σχεδιαστεί με σκοπό να λαμβάνει εκτιμήσεις του φόρτου εργασίας αμέσως ή μετά από μία εργασία. Πιο συγκεκριμένα, ο δείκτης φόρτου εργασίας της NASA υπολογίζει το στρες έχοντας λάβει υπόψιν έξι διαφορετικές διαστάσεις:

1. διανοητικές απαιτήσεις
2. σωματικές απαιτήσεις
3. χρονικές απαιτήσεις
4. προσωπικές επιδόσεις
5. προσπάθεια
6. απογοήτευση

7. Μέσω της αξιολόγησης των τιμών δύο από τους έξι παράγοντες, τίθεται δυνατή η ποσοτικοποίηση του ψυχικού στρες. Επίσης, ο συγκεκριμένος δείκτης θεωρείται πιο ευαίσθητος σε χαμηλό ψυχικό φόρτο εργασίας.

## **2.6 Μεταβλητότητα του καρδιακού ρυθμού και εφαρμογές**

### **DeStress: Deep Learning for Unsupervised Identification of Mental Stress in Firefighters from Heart-rate Variability (HRV) Data**

Στη συγκεκριμένα έρευνα γίνεται μελέτη ανίχνευσης άγχους με χρήση μηχανικής μάθησης χωρίς επίβλεψη σε 100 εκπαιδευόμενους πυροσβέστες μέσω των δεδομένων, συγκεκριμένα των παλμών της μεταβλητότητας του καρδιακού ρυθμού (Heart Rate Variability), που συλλέγονται από την εκπαίδευσή τους. Διαπιστώνεται ότι τρεις μέθοδοι είναι οι κατάλληλες για την ανίχνευση του στρες στα συγκεκριμένα δεδομένα:

- K-Means clustering
- Convolutional autoencoders
- Long short-term memory (LSTM) autoencoders

Παρατηρήθηκε ότι η χρήση K-Means clustering δεν είναι σε θέση να αποδώσει σημαντικά στα δεδομένα. Από την άλλη πλευρά, οι χρήσεις convolutional and LSTM autoencoders παρουσιάζονται πιο αποτελεσματικές χρησιμοποιώντας τους δείκτες HRV του ψυχικού στρες, με υψηλή ακρίβεια σε σύγκριση με τους καθιερωμένους δείκτες φυσιολογικού στρες, όπως RMSSD (η τετραγωνική ρίζα του μέσου όρου των τετραγώνων των διαφορών μεταξύ διαδοχικών διαστημάτων RR), Max-HR (μέγιστο διάστημα RR), Mean-HR (μέσος όρος διαδοχικών καρδιακών παλμών) και LF-HF (αναλογία χαμηλής συχνότητας προς υψηλή συχνότητα). [11]

### **Drowsiness detection using heart rate variability**

Έχει παρατηρηθεί πως το 10-30% των θανάτων από τροχαία είναι σχετιζόμενα με την υπνηλία. Η ανίχνευση υπνηλίας του οδηγού είναι βασισμένη σε βιολογικά σήματα και σήματα του οχήματος, η οποία μελετάται στην πρόληψη και ασφάλεια του οχήματος. Η δραστηριότητα του αυτόνομου νευρικού συστήματος του κάθε ανθρώπου, η οποία μπορεί να μετρηθεί από τη μεταβλητότητα του καρδιακού ρυθμού (HRV) με χρήση ενός ηλεκτροκαρδιογραφήματος (ECG), παρουσιάζει διαφοροποιήσεις κατά τη διάρκεια καταστάσεων όπως στρες, ακραίας κόπωσης και υπνηλίας. Οι συγκριμένες αλλαγές εκδηλώνονται στη μεταβλητότητα του καρδιακού ρυθμού και επομένως θα μπορούσαν τα συγκεκριμένα δεδομένα να χρησιμοποιηθούν με σκοπό την ανίχνευση υπνηλίας του οδηγού. Πραγματοποιήθηκε ανάλυση σε τρεις βάσεις δεδομένων, στις οποίες οι οδηγοί παρουσίαζαν επίπεδα στέρησης ύπνου και για κάθε λεπτό δινόταν σαν αποτέλεσμα η κατάσταση του οδηγού ως νυσταγμένο ή ξύπνιο. Αναπτύχθηκαν δύο διαφορετικοί τρόποι ανίχνευσης υπνηλίας με βάση της μεταβλητότητας του καρδιακού ρυθμού. Ενώ γινόταν αξιολόγηση από τον ανιχνευτή υπνηλίας για κάθε λεπτό οδήγησης ως "ξύπνιο" ή "νυσταγμένο" χρησιμοποιώντας επτά χαρακτηριστικά που προέρχονταν από τη μεταβλητότητα του καρδιακού ρυθμού, ο ανιχνευτής στέρησης ύπνου, από την αρχή, διέκρινε εάν ο οδηγός θα μπορούσε να οδηγήσει ή όχι. Η χρήση των συστημάτων αξιολόγησης της υπνηλίας με βάση τα σήματα HRV μπορεί να επιφέρει σημαντικές βελτιώσεις στα ήδη υπάρχοντα συστήματα ασφαλείας οχημάτων. [12]

### **Wearable and Automotive Systems for Affect Recognition from Physiology**

Στην παρούσα έρευνα αναπτύχθηκαν και δοκιμάστηκαν συστήματα τα οποία δείχνουν πως μπορούν να αναγνωριστούν δεκαεννέα συναισθήματα μέσω της φυσιολογίας, παρέχοντας μια καινούργια μέθοδο αλληλεπίδρασης, μέσω της οποίας μπορεί να εμπλουτιστεί η αποτελεσματικότητα της αλληλεπίδρασης ανθρώπου-μηχανής. Στα συστήματα αυτά χρησιμοποιούνται μέθοδοι, όπως είναι οι φυσιολογικοί αισθητήρες, δηλαδή, η επισκόπηση των μοντέλων συναισθημάτων που εφαρμόζονται

για την κατηγοριοποίηση και την περιγραφή αυτών, τα πειράματα Sentic, τα οποία έχουν σχεδιαστεί με τέτοιο τρόπο ώστε να αναγνωρίζουν οκτώ συγκεκριμένα συναισθήματα σε περιβάλλοντα εσωτερικού χώρου. Αξίζει να σημειωθεί πως το ποσοστό αναγνώρισης των οκτώ συναισθημάτων άγγιζε το 81%. Επιπλέον συστήματα που χρησιμοποιήθηκαν αποτελούν τα συστήματα που ενσωματώνουν κάμερες και ασύρματες συσκευές παρακολούθησης, τα οποία φάνηκαν χρήσιμα για τη μέτρηση των φυσικών καταστάσεων. Παρουσιάζεται ακόμη το πείραμα ανίχνευσης της πίεσης του οδηγού μέσω της μεταβλητότητας του καρδιακού ρυθμού με χρήση ενός ηλεκτροκαρδιογραφήματος (ECG). Τα αποτελέσματα του συγκεκριμένου πειράματος απέδειξαν πως το άγχος του οδηγού μπορεί να αναγνωριστεί με ποσοστό ακριβείας 96% χρησιμοποιώντας δεδομένα πέντε λεπτών και με ποσοστό ακριβείας 89% για δεδομένα ενός λεπτού. [13]

### **Resolving Ambiguities in the LF/HF Ratio: LF-HF Scatter Plots for the Categorization of Mental and Physical Stress from HRV**

Η συγκεκριμένη μελέτη έδειξε πως η δραστηριότητα της ζώνης χαμηλής συχνότητας (Low Frequency - LF) και της ζώνης υψηλής συχνότητας (High Frequency - HF) στη μεταβλητότητα του καρδιακού ρυθμού μέσω ενός δυσδιάστατου διαγράμματος βελτιώνει την ικανότητα διάκρισης του σωματικού και ψυχικού άγχους, σε σχέση με τις τυπικές μετρήσεις του λόγου χαμηλής συχνότητας προς υψηλή συχνότητα (LF/HF). Η ταχύτητα εισροής ιόντων που εκπέμπουν τα κύτταρα, καθοδηγείται από το αυτόνομο νευρικό σύστημα (ANS). Το συμπαθητικό νευρικό σύστημα (Sympathetic Nervous System - SNS) αυξάνει την αγωγιμότητα της κυτταρικής μεμβράνης, οδηγώντας σε πιο μικρά διαστήματα μεταξύ δύο διαδοχικών καρδιακών παλμών, με αποτέλεσμα τον υψηλότερο καρδιακό ρυθμό, ενώ από την άλλη πλευρά, το παρασυμπαθητικό νευρικό σύστημα (Parasympathetic Nervous System - PNS) έχει το αντίθετο αποτέλεσμα, τον χαμηλότερο καρδιακό ρυθμό. Ο βαθμός ελευθερίας που λαμβάνεται μέσω του δυσδιάστατου διαγράμματος κατέκτησε τόσο την ακριβή διάκριση μεταξύ των καταστάσεων άγχους όσο και παρατηρήθηκε περιττή η γραμμική σχέση μεταξύ της δραστηριότητας των νευρικών συστημάτων και της ισχύος συχνότητας, ή αλλιώς της αλληλεπίδρασης μεταξύ της ισχύος χαμηλής συχνότητας και της ισχύος υψηλής συχνότητας. [14]

## Κεφάλαιο 3

### 3.1 Εφαρμογή Μηχανικής Μάθησης - Ανίχνευση ψυχικού στρες

Στη συγκεκριμένη εφαρμογή χρησιμοποιείται το σύνολο δεδομένων SWELL-KW με σκοπό την ανίχνευση του ψυχικού στρες, με βάση τα χαρακτηριστικά της μεταβλητότητας του καρδιακού ρυθμού (HRV). Επιπλέον, για την εύρεση της υψηλότερης απόδοσης πραγματοποιείται χρήση των αλγορίθμων Decision Tree, Random Forest, Logistic Regression, K-Nearest Neighbors, Gradient Boosted Decision Trees. Τα προαναφερθέντα δεδομένα εισάγονται σε ένα πρόγραμμα βασισμένα στη γλώσσα Python.

#### 3.1.1 Το σύνολο δεδομένων SWELL-KW

Το συγκεκριμένο σύνολο δεδομένων αποτελείται από δείκτες μεταβλητότητας καρδιακού ρυθμού (Heart Rate Variability - HRV), οι οποίοι υπολογίζονται από το σύνολο δεδομένων SWELL (SWELL-KW) για έρευνα σχετικά με το άγχος [15]. Το σύνολο δεδομένων αυτό συλλέχτηκε από ερευνητές του Ινστιτούτου Υπολογιστικών και Πληροφοριακών Επιστημών του Πανεπιστημίου Radboud. Πρόκειται για μία μελέτη η οποία βασίζεται σε δεδομένα του πραγματικού κόσμου.

#### 3.1.2 Συμμετέχοντες και σχεδιασμός

Πραγματοποιήθηκαν πειράματα που διεξήχθησαν σε 25 άτομα (δεκαεπτά άνδρες και οκτώ γυναίκες) με μέσο όρο ηλικίας τα 25 έτη, τα οποία έκαναν τυπικές εργασίες γραφείου, όπως για παράδειγμα είναι η δημιουργία αναφορών, η πραγματοποίηση παρουσιάσεων, η ανάγνωση ηλεκτρονικού ταχυδρομείου (e-mail) και η αναζήτηση πληροφοριών. Κάθε άτομο πέρασε από τυπικούς εργασιακούς παράγοντες άγχους, όπως η απροσδόκητη διακοπή λειτουργίας του ηλεκτρονικού υπολογιστή και η πίεση που δεχόταν ώστε να ολοκληρώσει την εργασία του εγκαίρως.

Στο πείραμα καταγράφηκαν διάφορα δεδομένα, όπως η έκφραση του προσώπου, η στάση του σώματος, το σήμα από ηλεκτροκαρδιογράφημα (ECG signal) και η αγωγιμότητα του δέρματος. Οι ερευνητές κατέγραψαν επίσης την εμπειρία του κάθε ατόμου σχετικά με το φόρτο εργασίας του, τα συναισθήματα και το πως αντιλαμβάνεται το άγχος.

Κάθε συμμετέχων πέρασε από τρεις διαφορετικές συνθήκες εργασίας:

- **no stress:** Ο συμμετέχων επιτρεπόταν να εργαστεί για όσο διάστημα χρειαζόταν, έως 45 λεπτά το μέγιστο, αλλά χωρίς να γνωρίζει τη μέγιστη διάρκεια της εργασίας του.
- **time pressure :** Κατά τη διάρκεια αυτής της περιόδου, ο χρόνος για την ολοκλήρωση της εργασίας μειώθηκε στα 2/3 του χρόνου που χρειάστηκε ο συμμετέχων στην πρώτη περίπτωση.
- **interruption :** Οι συμμετέχοντες έλαβαν οκτώ μηνύματα ηλεκτρονικού ταχυδρομείου στη μέση των εργασιών που τους είχαν ανατεθεί. Ορισμένα μηνύματα ηλεκτρονικού ταχυδρομείου ήταν σχετικά με τα καθήκοντά τους και ζητήθηκε από το συμμετέχων να προβεί σε συγκεκριμένες ενέργειες, ενώ άλλα δεν είχαν κάποια ουδέτερη σχέση με τα καθήκοντά τους.

#### 3.1.3 Δεδομένα και χαρακτηριστικά

Το σύνολο δεδομένων SWELL-KW εμπεριέχει τόσο δεδομένα εκπαίδευσης, όσο και δεδομένα δοκιμής, που απαρτίζονται από 35 χαρακτηριστικά και τρεις διαφορετικές συνθήκες. Τα δεδομένα εκπαίδευσης αποτελούνται από 369289 δείγματα και τα δεδομένα δοκιμής από 41033 δείγματα. Τα 35 χαρακτηριστικά του συνόλου δεδομένων που εντοπίζονται, παρατίθενται στον πίνακα 3.1 για την ταξινόμηση.

Πίνακας 3.1: Τα χαρακτηριστικά του συνόλου δεδομένων SWELL-KW

1	Mean RR	Mean R-R interval
2	Median RR	Median R-R interval
3	SDRR	Standard deviation of R-R interval
4	RMSSD	Root mean square of successive difference in distance
5	SDSD	Standard deviation of all interval of differences between adjacent RR intervals
6	SDRR_RMSSD	Ratio of SDRR over RMSSD
7	HR	Heart rate
8	pNN25	Percentage of number of adjacent RR intervals differing by more than 25 ms
9	pNN50	The ratio of NN50 to the total number of NNs
10	SD1	Short-term poincare plot descriptor of the heart rate variability
11	SD2	Long-term poincare plot descriptor of the heart rate variability
12	KURT	Kurtosis of all RR intervals
13	SKEW	Skewness of all RR intervals
14	MEAN_REL_RR	Mean of the relative RR
15	MEDIAN_REL_RR	Median of the relative RR
16	SDRR_REL_RR	Standard Deviation of the relative RR
17	RMSSD_REL_RR	Root mean square of successive difference in distance of the relative RR
18	SDSD_REL_RR	Short and long-term poincare plot descriptor of the relative RR
19	SDRR_RMSSD_REL_RR	Ratio of SDRR over RMSSD of the relative RR
20	KURT_REL_RR	Kurtosis of all relative RR intervals
21	SKEW_REL_RR	Skewness of all relative RR intervals
22	VLF	Very low frequency power from 0.003 HZ to 0.04Hz
23	VLF_PCT	VLF as a percentage of total
24	LF Low	Low frequency power from 0.04 HZ to 0.15Hz
25	LF_PCT	LF as a percentage of total
26	LF_NU	Low frequency of HRV in normalized unit
27	HF	High frequency power from 0.15 HZ to 0.4 Hz
28	HF_PCT	HF as a percentage of total
29	HF_NU	High frequency of HRV in normalized unit
30	TP	Total HRV power spectrum
31	LF/HF	Ratio of LF to HF
32	HF/LF	Ratio of HF to LF
33	sampen	A modification of approximate entropy
34	higuci	An approximate value of the graph of a real-valued function
35	datasetld	A standard value for every sample

Ορισμένα χαρακτηριστικά ορίζονται από μαθηματικές εξισώσεις, όπως:

$$(1) \quad REL\_RR_i = 2 \frac{REL\_RR_i - REL\_RR_{i-1}}{REL\_RR_i + REL\_RR_{i-1}}$$

$$(2) \quad RMSSD = \sqrt{\frac{1}{N-1} \sum_{i=1}^{N-1} (RR_{i+1} - RR_i)^2}$$

$$(3) \quad HF\_NU = \frac{HF}{HF+LF}$$

$$(4) \quad LF\_NU = \frac{LF}{HF+LF}$$

Κατά τη διαδικασία ανάλυσης των δεδομένων, απεικόνισης και εκπαίδευσης αυτών, χρησιμοποιήθηκαν διάφορα εργαλεία, όπως Pandas, Numpy, Scikit-learn, Seaborn και Matplotlib. Συγκεκριμένα, η scikit-learn εμπεριέχει αρκετούς αλγορίθμους μηχανικής μάθησης, όπως Decision Tree, Random Forest, Logistic Regression, K-Nearest Neighbors, Gradient Boosted Decision Trees, οι οποίοι χρησιμοποιήθηκαν για την εκπαίδευση μοντέλων στο συγκεκριμένο σύνολο δεδομένων. Όμως, πριν από τη χρήση των παραπάνω αλγορίθμων χρειάστηκε η επιλογή των κατάλληλων χαρακτηριστικών για την βέλτιστη εκπαίδευση των μοντέλων και η παράμετρος συντονισμού (tuning) σε κάθε αλγόριθμο ξεχωριστά, με σκοπό τις υψηλότερες αποδόσεις των μοντέλων.


### 3.1.4 Επιλογή χαρακτηριστικών

Όπως προαναφέρθηκε, ο στόχος των μοντέλων εκπαίδευσης είναι η υψηλή ακρίβεια τους. Η επιτυχία του μοντέλου υπολογίζεται βάση του βαθμού πρόγνωσης στην αντίστοιχη ετικέτα εξόδου του συνόλου δεδομένων δοκιμής. Η ακρίβεια αντιπροσωπεύει τη συνολική σωστή πρόβλεψη και υπολογίζεται με τον εξής τύπο:

$$(5) \quad Accuracy = \frac{TP}{TP+FP}$$

,όπου TP (True Positive) εννοούνται οι θετικές σωστές προβλέψεις και FP (False Positive) οι λανθασμένες θετικές προβλέψεις.

Το σύνολο δεδομένων εκπαίδευσης επισημαίνει τα δείγματα με βάση τριών συνθηκών ψυχικού στρες και πιο συγκεκριμένα, όπως φαίνεται στην Εικόνα 3.1, 200082 δείγματα σε κατάσταση χωρίς άγχος, 105150 δείγματα σε κατάσταση διακοπής και 64057 δείγματα σε κατάσταση πίεσης χρόνου.



Εικόνα 3.1: Ιστόγραμμα με τις τρεις ετικέτες του συνόλου δεδομένων εκπαίδευσης

Μπορεί να σημειωθεί πως σχεδόν το μισό του συνόλου δεδομένων εκπαίδευσης αποτελείται από ετικέτες κατάστασης χωρίς άγχος. Από την άλλη πλευρά, το σύνολο δοκιμών απαρτίζεται από 22158




δείγματα κατάστασης χωρίς άγχος, 11782 δείγματα σε κατάσταση διακοπής και 7093 δείγματα σε κατάσταση πίεσης χρόνου.

Τα 35 χαρακτηριστικά των δειγμάτων παρουσιάζονται στον παρακάτω πίνακα συσχέτισης Pearson και εν συνεχεία πραγματοποιείται επιλογή των κατάλληλων χαρακτηριστικών έχοντας ως βαθμό καταφλίου συσχέτισης (correlation threshold) ίσο με 0.1, με στόχο τα βέλτιστα αποτελέσματα.

Τα χαρακτηριστικά που επιλέχθηκαν ως τα καταλληλότερα είναι:

1. MEAN\_RR
2. MEDIAN\_RR
3. SDRR\_RMSSD
4. MEDIAN\_REL\_RR
5. SDRR\_RMSSD\_REL\_RR
6. VLF
7. VLF\_PCT



Εικόνα 3.2: Πίνακας συσχέτισης Pearson

### 3.1.5 Παράμετρος συντονισμού (Tuning)

Οι παράμετροι κάθε αλγορίθμου παίζουν σημαντικό στην επίδραση και στην απόδοση του αποτελέσματος κάθε μοντέλου. Η βελτιστοποίηση των παραμέτρων των αλγορίθμων που χρησιμοποιήθηκαν παρουσιάζονται ως εξής:

- Στην περίπτωση του αλγορίθμου Decision Tree, χρησιμοποιήθηκε ως κριτήριο διαχωρισμού ο δείκτης Gini, δίνοντας ελάχιστη διαφορά στην απόδοση από το κριτήριο διαχωρισμού Entropy.

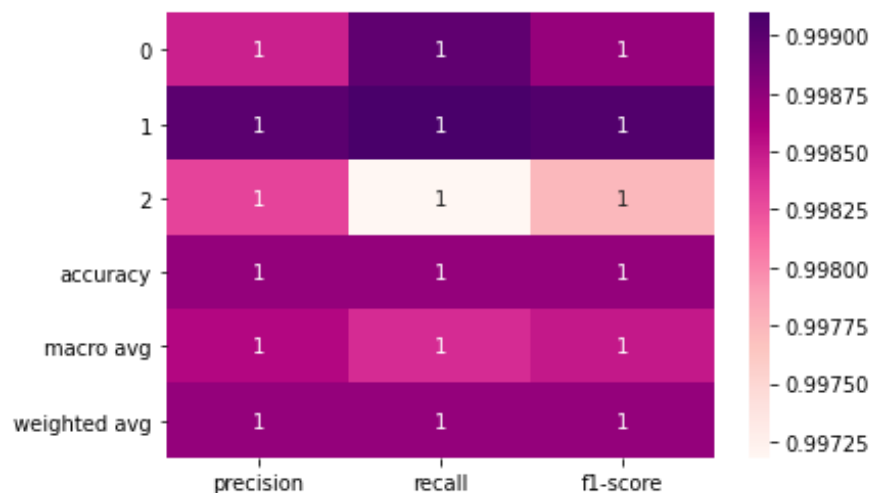
- Στην περίπτωση του αλγορίθμου Random Forest, ο αριθμός των δέντρων που χρησιμοποιήθηκαν κατά την εκπαίδευση του μοντέλου είναι 2, δίνοντας τη βέλτιστη απόδοση σε σχέση με χαμηλούς ή και πολύ υψηλούς αριθμούς δέντρων.
- Στην περίπτωση του αλγορίθμου Logistic Regression, η τιμή της παραμέτρου C που χρησιμοποιήθηκε επιφέροντας τα βέλτιστα αποτελέσματα είναι 0,001.
- Στην περίπτωση του αλγορίθμου K\_Nearest Neighbors, ο αριθμός γειτόνων που χρειάστηκε για τη βέλτιστη απόδοση είναι ίσος με 1.
- Στην περίπτωση του αλγορίθμου Gradient Boosted Decision Trees, ο αριθμός των δέντρων που χρησιμοποιήθηκαν κατά την εκπαίδευση είναι 10 και το βάθος του κάθε δέντρου είναι εξίσου 10.

### 3.1.6 Μοντέλα και συγκρίσεις


Η χρήση και των πέντε αλγορίθμων επιφέρει διάφορα και διαφορετικά αποτελέσματα. Παρακάτω θα πραγματοποιηθεί ανάλυση των αποτελεσμάτων για κάθε αλγόριθμο ξεχωριστά.

#### Decision Tree

Πιο συγκεκριμένα, για τον αλγόριθμο Decision Tree παρατηρείται υπερ-μοντελοποίηση (overfitting), έχοντας ως επίδοση ακρίβειας ίση περίπου με 100%, κάνοντας το συγκεκριμένο μοντέλο αναξιόπιστο. Τόσο στον παρακάτω πίνακα σύγκρισης όσο και στην παρακάτω αναφορά ταξινόμησης παρουσιάζεται ειδικότερα η αιτία της υπερ-μοντελοποίησης.



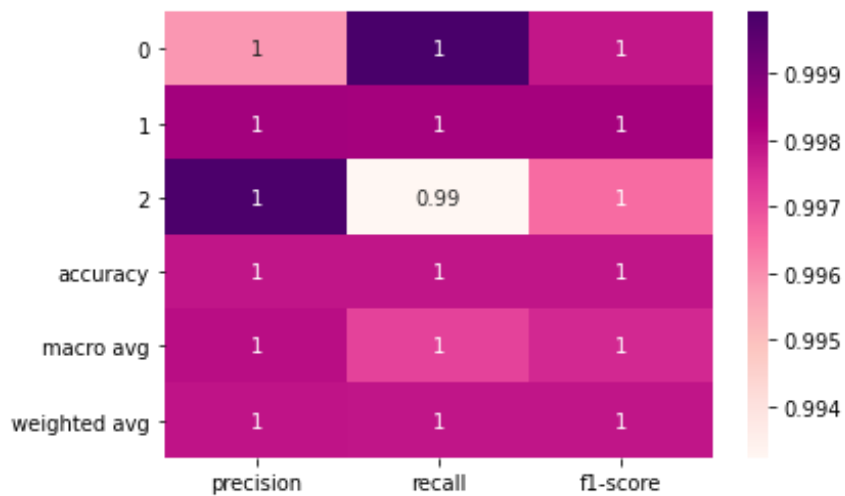
Εικόνα 3.3: Αναφορά ταξινόμησης του αλγορίθμου Decision Tree




Εικόνα 3.4: Πίνακας σύγκρισης του αλγορίθμου Decision Tree

### Random Forest

Σχετικά με το μοντέλο του αλγορίθμου Random Forest, τα αποτελέσματα είναι σχεδόν παρόμοια με του αλγορίθμου Decision Tree, δηλαδή και στην περίπτωση αυτή παρατηρείται υπερ-μοντελοποίηση (overfitting). Οποιαδήποτε αλλαγή των παραμέτρων και μετατροπή του μοντέλου δε δίνει τη λύση στην αποφυγή της κατάστασης της υπερ-μοντελοποίησης. Παρακάτω δίνονται αναλυτικότεροι οι τιμές του παρόντος μοντέλου.



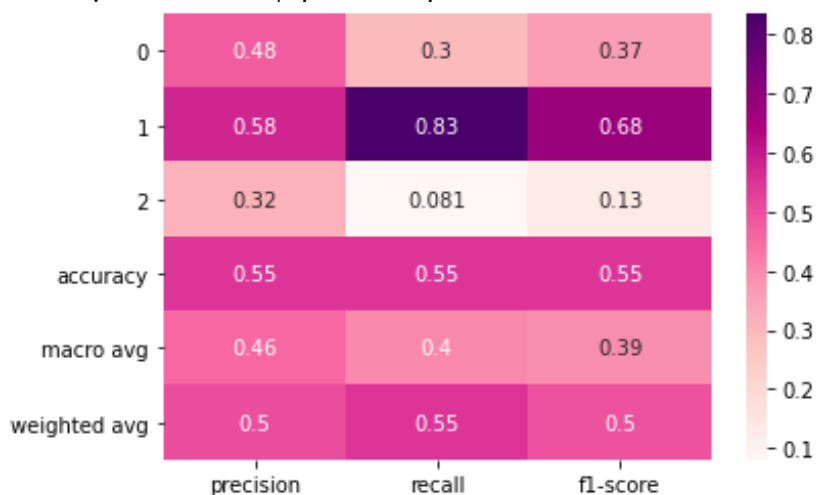
Εικόνα 3.5: Αναφορά ταξινόμησης του αλγορίθμου Random Forest




Εικόνα 3.6: Πίνακας σύγχυσης του αλγορίθμου Random Forest

### Logistic Regression

Στην περίπτωση του αλγορίθμου Logistic Regression, παρατηρείται το ακριβώς αντίθετο αποτέλεσμα σε σύγκριση με τους δύο προηγούμενους αλγορίθμους. Το μοντέλο με τη χρήση των ιδανικότερων παραμέτρων επιφέρει επιδόσεις ακριβείας ίση με 55%, με αποτέλεσμα την υπομοντελοποίηση. Το μοντέλο δυσκολεύεται να διακρίνει τις ετικέτες των δεδομένων δοκιμής και να τις συγκρίνει σωστά με εκείνες των δεδομένων δοκιμής. Πιο συγκεκριμένα οι χαμηλές αυτές τιμές και τα αποτελέσματα του μοντέλου αναφέρονται παρακάτω.



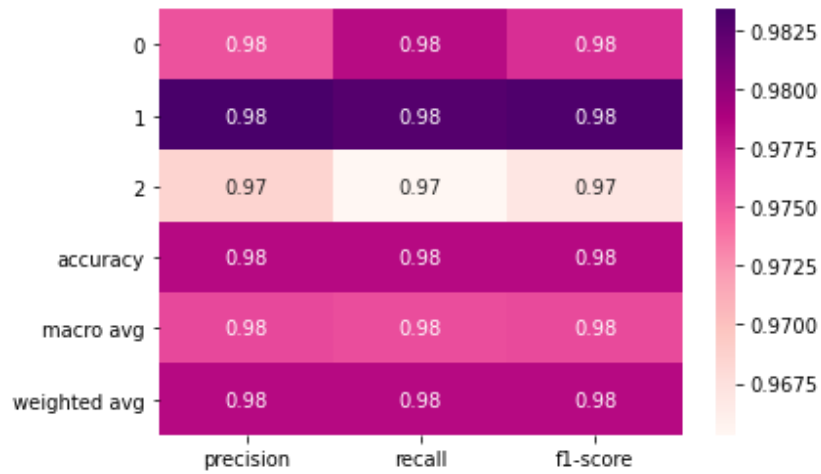
Εικόνα 3.7: Αναφορά ταξινόμησης του αλγορίθμου Logistic Regression




Εικόνα 3.8: Πίνακας σύγκρισης του αλγορίθμου Logistic Regression

### **K-Nearest Neighbors**

Όσον αφορά τον αλγόριθμο K-Nearest Neighbors, το μοντέλο έχοντας ως k-κοντινότερο γείτονα ίσο με 1, δίνει ως αποτέλεσμα ακριβείας 98%, κάνοντας το ένα αρκετά αξιόπιστο μοντέλο και έτοιμο για χρήση. Αυτό φαίνεται στην Εικόνα 3.9 και Εικόνα 3.10.



Εικόνα 3.9: Αναφορά ταξινόμησης του αλγορίθμου K-Nearest Neighbors




Εικόνα 3.10: Πίνακας σύγκρισης του αλγορίθμου K-Nearest Neighbors

### Gradient Boosted Decision Trees

Τέλος, ο αλγόριθμος Gradient Boosted Decision Trees δίνει και αυτό με τη σειρά του υψηλής ακριβείας μοντέλο με ποσοστό επίδοσης 97%, ανταγωνίζοντας το προηγούμενο μοντέλο του αλγορίθμου K-Nearest Neighbors. Τα αποτελέσματα του συγκεκριμένου μοντέλου δίνονται παρακάτω.



Εικόνα 3.11: Αναφορά ταξινόμησης του αλγορίθμου Gradient Boosted Decision Trees



Εικόνα 3.12: Πίνακας σύγκρισης του αλγορίθμου Gradient Boosted Decision Trees

### 3.1.7 Σύνοψη


Η μείωση των χαρακτηριστικών του συνόλου δεδομένων εκπαίδευσης έχει τη δυνατότητα να μειώσει τόσο το χρόνο εκπαίδευσης όσο και να αυξήσει τις επιδόσεις των μοντέλων. Η ακρίβεια που επιφέρει κάθε μοντέλο ξεχωριστά συλλέγεται, εξετάζεται και αναλύεται μέσω του ελέγχου του ποσοστού των ετικετών.

Επιπλέον, παρατηρείται πως στην κατηγορία ταξινόμησης με χρήση δέντρων, ο αλγόριθμος Gradient Boosted Decision Trees επιφέρει πιο ικανοποιητικό μοντέλο, σε αντίθεση με τα μοντέλα των αλγορίθμων Decision Tree και Random Forest.

Έχοντας αναλύσει συνολικά τα μοντέλα των αλγορίθμων στο συγκεκριμένο σύνολο δεδομένων, προκύπτει πως το καταλληλότερο μοντέλο χρήσης αποτελεί εκείνο του αλγορίθμου K-Nearest Neighbors με αριθμό γειτόνων ίσο με 1.

Πίνακας 3.2: Τα αποτελέσματα των μοντέλων των αλγορίθμων

Decision Tree	0.998733
Random Forest	0.997928
Logistic Regression	0.553847
K-Nearest Neighbors	0.978505
Gradient Boosted Decision Trees	0.969293



Εικόνα 3.13: Τα αποτελέσματα των μοντέλων των αλγορίθμων

Αξίζει να σημειωθεί πως η μελέτη της συσχέτισης των εννοιών, οι οποίες αφορούν το άγχος, δείχνει τη μεταβλητότητα του καρδιακού ρυθμού να ανταποκρίνεται στις εναλλαγές του ψυχικού στρες, με αποτέλεσμα να επικυρώνεται η συσχέτιση μεταξύ της μεταβλητότητας του καρδιακού ρυθμού και του ψυχικού στρες.

Θεωρείται απαραίτητο το βέλτιστο υποσύνολο χαρακτηριστικών μεταβλητότητας του καρδιακού ρυθμού για την ποσοτικοποίηση του ψυχικού στρες, με σκοπό να αποδίδεται με μεγαλύτερη σημασία σε σύγκριση με άλλα χαρακτηριστικά. Επιπλέον, η χρήση μειωμένων χαρακτηριστικών έχει τη δυνατότητα να μειώσει το κόστος συλλογής δεδομένων. Πέραν αυτού, ο χρόνος εκπαίδευσης και πρόβλεψης του εκάστοτε μοντέλου μπορεί να ελαττωθεί σημαντικά. Τέλος, αποδεικνύεται πως η επιλογή των κατάλληλων χαρακτηριστικών αποτελεί μεγάλη αναγκαιότητα σε εφαρμογές του πραγματικού κόσμου.

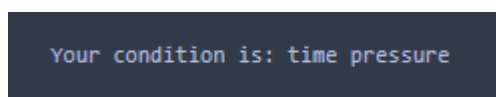
### 3.1.8 Δοκιμή μοντέλου

Πραγματοποιείται δοκιμή του μοντέλου K-Nearest Neighbors, ως το καταλληλότερο, σε ένα τυχαίο δείγμα από το σύνολο δεδομένων δοκιμών, όπως φαίνεται στον Πίνακα 3.3, αναμένοντας να δίνεται το αντίστοιχο αποτέλεσμα και στη συγκεκριμένη περίπτωση "time pressure".

Πίνακας 3.3: Τυχαίο δείγμα από το σύνολο δεδομένων δοκιμών

	MEAN_RR	MEDIAN_RR	SDRR	RMSSD	SDSD	...	condition
41028	1118.406543	1117.85705	113.955632	18.592177	18.592071	...	time pressure

Έπειτα από τη διαδικασία δοκιμής του προαναφερθέντος δείγματος, παρατηρείται στην Εικόνα 3.14 πως το συγκεκριμένο μοντέλο προέβλεψε την ετικέτα του δείγματος με ακρίβεια.



Εικόνα 3.14: Αποτέλεσμα εφαρμογής του μοντέλου



### 3.2 Εφαρμογή Βαθιάς Μάθησης - Ανίχνευση καρδιακής κατάστασης

Στην εφαρμογή αυτή χρησιμοποιείται ένα σύνολο δεδομένων, το οποίο αποτελείται από το συνδυασμό δύο διαφορετικών βάσεων δεδομένων, της MIT-BIH Arrhythmia Database και της PTB Diagnostic ECG Database. Οι δύο αυτές βάσεις δεδομένων αφορούν τις συλλογές σημάτων καρδιακών παλμών με τη χρήση ηλεκτροκαρδιογραφήματος. Το τελικό σύνολο δεδομένων χρησιμοποιήθηκε με σκοπό την ανίχνευση των καρδιακών καταστάσεων από τους καρδιακούς παλμούς με τη χρήση βαθιάς μάθησης.

Επίσης, για την εύρεση της υψηλότερης απόδοσης πραγματοποιείται χρήση των αλγορίθμων βαθιάς μάθησης, όπως ο αλγόριθμος Convolutional Neural Network και ο αλγόριθμος Long Short-Term Memory Network. Όπως και στην εφαρμογή ανίχνευσης ψυχικού στρες, έτσι και στην παρούσα περίπτωση πραγματοποιείται χρήση της γλώσσας Python.

#### 3.2.1 Η βάση δεδομένων MIT-BIH Arrhythmia

Στη συγκεκριμένη βάση δεδομένων περιέχονται 48 μισάωρα αποσπάσματα καταγραφών ηλεκτροκαρδιογραφήματος που μετρήθηκαν από 47 άτομα και μελετήθηκαν από το BIH Arrhythmia Laboratory τις χρονολογίες 1975 έως 1979. Επιλέχθηκαν 23 τυχαίες καταγραφές ηλεκτροκαρδιογραφήματος από ένα σύνολο 4000 καταγραφών, οι οποίες συλλέχθηκαν από τυχαίους ασθενείς στο νοσοκομείο Beth Israel της Βοστώνης, και οι υπόλοιπες 24 καταγραφές επιλέχθηκαν από τους ίδιους ερευνητές. Τέλος, όλες οι καταγραφές μετατράπηκαν από αναλογικές σε ψηφιακές σε 360 δείγματα ανά δευτερόλεπτο. [16]

#### 3.2.2 Η βάση δεδομένων PTB Diagnostic ECG

Σε αυτή τη βάση δεδομένων εμπεριέχονται καταγραφές ηλεκτροκαρδιογραφήματος από διακόσια ενενήντα (290) άτομα, ηλικίας 17 έως 87 ετών, ανάμεσα σε 209 άνδρες και 81 γυναίκες. Επιπλέον, κάθε σήμα ηλεκτροκαρδιογραφήματος μετατρέπεται από αναλογικό σε ψηφιακό σήμα σε 1000 δείγματα ανά δευτερόλεπτο. [17]


#### 3.2.3 Δεδομένα και χαρακτηριστικά

Το σύνολο δεδομένων που σχηματίστηκε με τη χρήση των προαναφερθέντων βάσεων δεδομένων, εμπεριέχει τόσο δεδομένα εκπαίδευσης, όσο και δεδομένα δοκιμής, που απαρτίζονται από 187 δείγματα καρδιακών παλμών σε χρονοσειρά και 5 διαφορετικές συνθήκες. Τα δεδομένα εκπαίδευσης αποτελούνται από 87554 δείγματα και τα δεδομένα δοκιμής από 21892 δείγματα. Οι συνθήκες καρδιακών καταστάσεων χωρίζονται ως εξής:


- **Normal Beats:** Οι καρδιακοί παλμοί και η καρδιακή κατάσταση του συμμετέχοντος βρίσκονται σε φυσιολογική κατάσταση.
- **Supraventricular Ectopic Beats:** Οι καρδιακοί παλμοί του συμμετέχοντος είναι ασυνήθιστα γρήγοροι.
- **Ventricular Ectopic Beats:** Ο καρδιακός ρυθμός του συμμετέχοντος θεωρείται ανώμαλος, όμως εάν είναι περιστασιακός δεν αποτελεί πρόβλημα.
- **Fusion Beats:** Στη συγκεκριμένη καρδιακή κατάσταση του συμμετέχοντος υποδηλώνεται πως υπάρχουν δύο εστίες βηματοδοτικών κυττάρων, οι οποίες πυροδοτούνται ταυτόχρονα, με αποτέλεσμα τη μεγαλύτερη συχνότητα των καρδιακών παλμών.
- **Unknown Beats:** Στην περίπτωση αυτή δε μπορεί να αναγνωριστεί και να αξιολογηθεί σωστά η καρδιακή κατάσταση του συμμετέχοντος.

Το σύνολο δεδομένων εκπαίδευσης επισημαίνει τα δείγματα με βάση πέντε καρδιακών καταστάσεων και πιο συγκεκριμένα, όπως φαίνεται στην Εικόνα 3.15, 72469 δείγματα Normal Beats, 2224 δείγματα Supraventricular Ectopic Beats, 5787 δείγματα Ventricular Ectopic Beats, 639 δείγματα Fusion Beats

και 6435 δείγματα Unknown Beats.



Εικόνα 3.15: Ιστόγραμμα με τις πέντε ετικέτες του συνόλου δεδομένων εκπαίδευσης




Εικόνα 3.16: Κυκλικό διάγραμμα με τις πέντε ετικέτες του συνόλου δεδομένων εκπαίδευσης


Παρατηρείται πως σχεδόν τα 4/5 του συνόλου δεδομένων εκπαίδευσης αποτελείται από ετικέτες με Normal Beats. Από την άλλη πλευρά, το σύνολο δοκιμών απαρτίζεται από 18118 δείγματα Normal

Beats, 556 δείγματα Supraventricular Ectopic Beats, 1447 δείγματα Ventricular Ectopic Beats, 162 δείγματα Fusion Beats και 1609 δείγματα Unknown Beats.

Με σκοπό τη βέλτιστη εκπαίδευση των μοντέλων και λόγω της μεγάλης ανισορροπίας που επικρατεί μεταξύ των 5 διαφορετικών καρδιακών καταστάσεων, δύναται η επεξεργασία του συνόλου δεδομένων εκπαίδευσης, δηλαδή η δημιουργία νέου συνόλου δεδομένων εκπαίδευσης αποτελούμενη από ισάξια δείγματα. Στην παρούσα κατάσταση επιλέχθηκαν 20000 δείγματα για κάθε συνθήκη.




Εικόνα 3.17: Ιστόγραμμα με τις πέντε ετικέτες του νέου συνόλου δεδομένων εκπαίδευσης

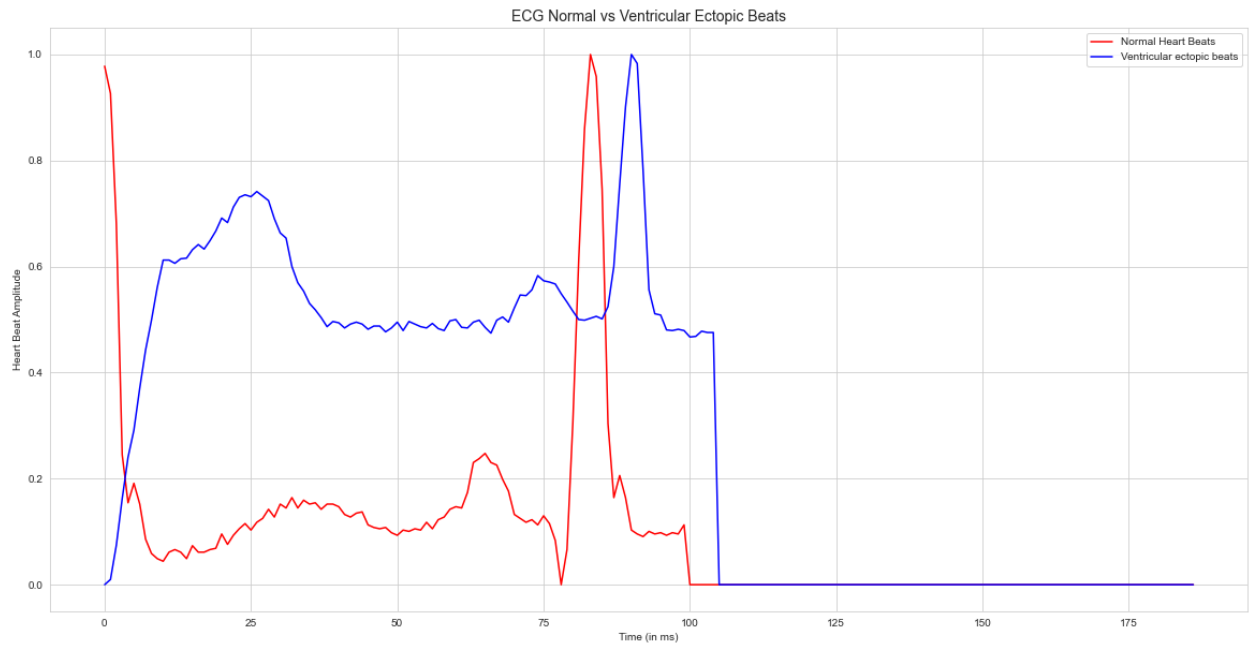


Εικόνα 3.18: Κυκλικό διάγραμμα με τις πέντε ετικέτες του νέου συνόλου δεδομένων εκπαίδευσης


Με τη χρήση τυχαίας δειγματοληψίας, δίνονται παρακάτω παραδείγματα σύγκρισης των δειγμάτων Normal Beats με τις υπόλοιπες 4 καταστάσεις.



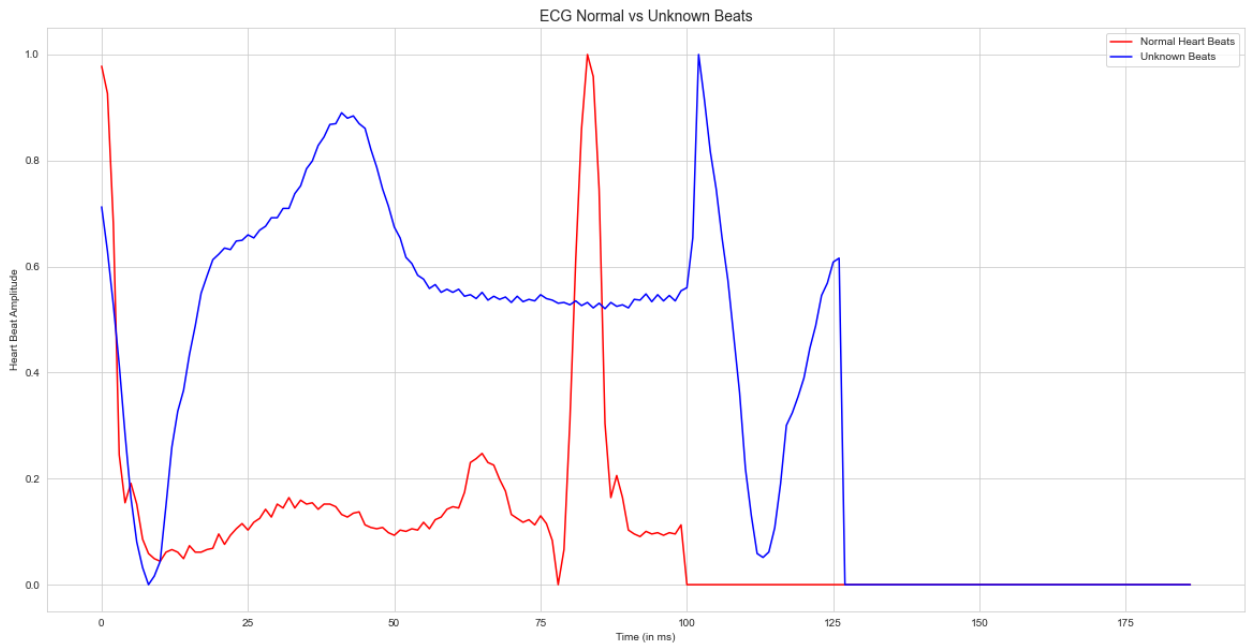
Εικόνα 3.19: Normal Beats και Supraventricular Ectopic Beats



Εικόνα 3.20: Normal Beats και Ventricular Ectopic Beats



Εικόνα 3.21: Normal Beats και Fusion Beats



Εικόνα 3.22: Normal Beats και Unknown Beats

Κατά τη διαδικασία ανάλυσης των δεδομένων, απεικόνισης και εκπαίδευσης αυτών, χρησιμοποιήθηκαν διάφορα εργαλεία, όπως Pandas, Numpy, Scikit-learn, Seaborn, Matplotlib, TensorFlow και Keras. Συγκεκριμένα οι δομές TensorFlow και Keras εμπεριέχουν εργαλεία για τη δημιουργία αλγορίθμων βαθιάς μάθησης, όπως ο αλγόριθμος Convolutional Neural Network και ο αλγόριθμος Long Short-Term Memory Network, οι οποίοι χρησιμοποιήθηκαν για την εκπαίδευση μοντέλων στο συγκεκριμένο σύνολο δεδομένων.

### 3.2.4 Μοντέλα και συγκρίσεις

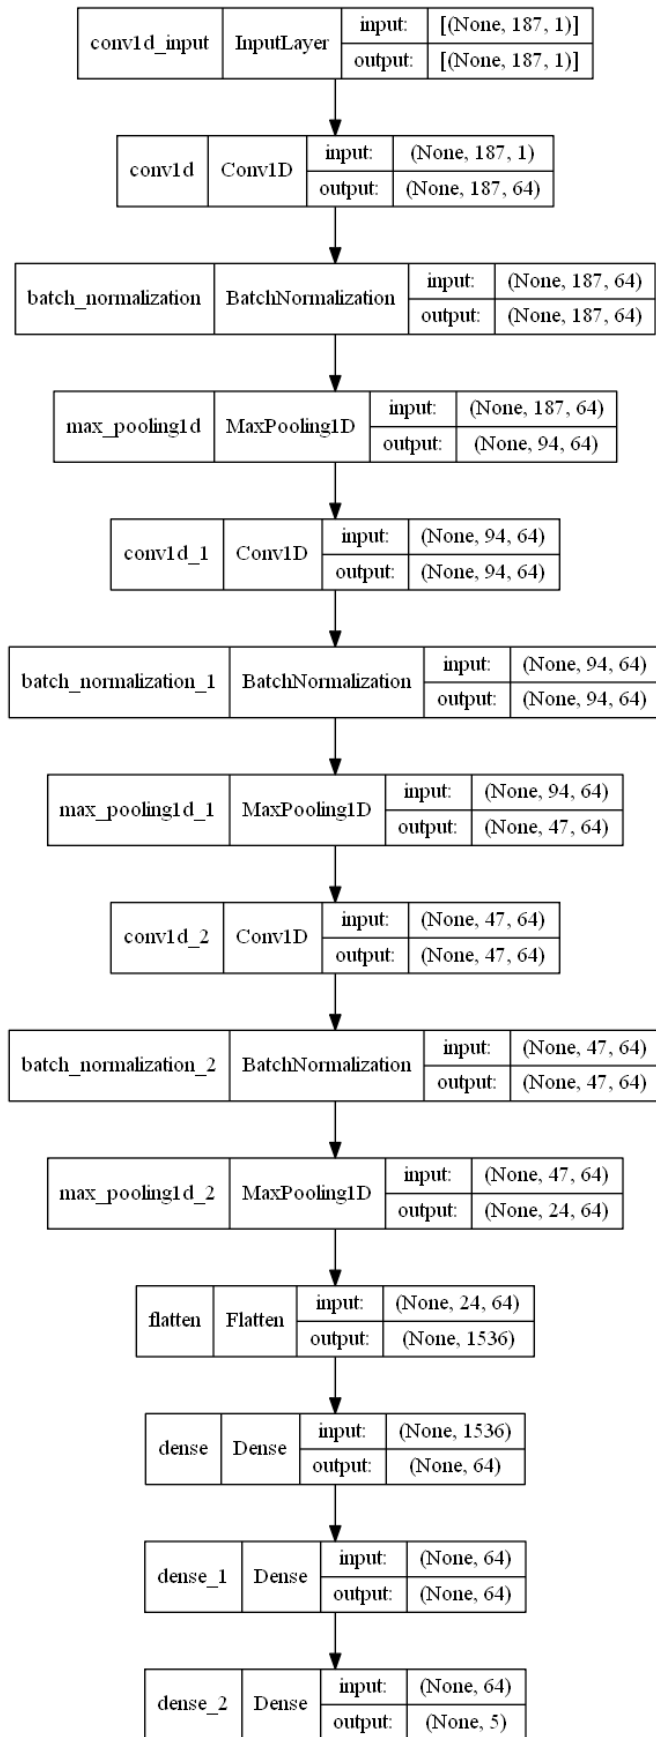
Όταν εκπαιδεύεται το μοντέλο, η ακρίβεια και η απώλεια του μοντέλου μπορούν να ποικίλλουν. Συνήθως, η ακρίβεια θα πρέπει να αυξάνεται και η απώλεια να μειώνεται με την αύξηση κάθε εποχής. Με τις τιμές ακρίβειας "val\_accuracy" και τις τιμές απώλειας "val\_loss", οι περιπτώσεις είναι:

- Το μοντέλο παραγεμίζει τιμές και δε μαθαίνει, όταν το val\_loss αυξάνεται και το val\_accuracy μειώνεται.
- Το μοντέλο παρουσιάζει φαινόμενο υπερ-μοντελοποίησης, όταν και το val\_loss και το val\_accuracy αυξάνονται.
- Το μοντέλο μαθαίνει και λειτουργεί σωστά, όταν το val\_loss μειώνεται και το val\_accuracy αυξάνεται.

### Convolutional Neural Network


Ο αλγόριθμος Convolutional Neural Network ή αλλιώς CNN χρησιμοποιήθηκε ως πρώτη μέθοδος για την απόκτηση μοντέλου που θα επιφέρει το επιθυμητό αποτέλεσμα. Συγκεκριμένα στην αρχιτεκτονική του παρουσιάζεται στην είσοδο το συνελκτικό στρώμα μίας διάστασης Conv1D με μέγεθος πυρήνα (kernel size) ίσο με 6 και συνάρτηση ενεργοποίησης ReLU. Στη συνέχεια προστέθηκε ένα ακόμα στρώμα Batch Normalization, με σκοπό την αποφυγή της υπερποσαρμογής και ένα στρώμα MaxPooling1D, μειώνοντας τις αναπαραστάσεις εισόδου και λαμβάνοντας τη τιμή pool\_size ίση με 3. Έπειτα αναπαράγονται τα προηγούμενα τρία βήματα δύο επιπλέον φορές και οδηγείται στο στρώμα Flatten, το οποίο συμπιέζει τις διαστάσεις εισόδου και οδηγεί τις εξόδους σε ένα ολοκληρωμένο συνδεδεμένο στρώμα, με στρώμα εισόδου Dense με 64 μονάδες και συνάρτηση ενεργοποίησης ReLU, κρυφό στρώμα Dense με 64 μονάδες και συνάρτηση ενεργοποίησης ReLU και στρώμα εξόδου Dense με 5 μονάδες και συνάρτηση ενεργοποίησης Softmax. Επίσης, να σημειωθεί πως ως βελτιστοποιητής

χρησιμοποιήθηκε ο (optimizer) Adam.




Εικόνα 3:22: Αρχιτεκτονική CNN αλγορίθμου

Το μοντέλο εκπαιδεύτηκε με επιτυχία για 50 εποχές και batch size ίσο με 32, φέρνοντας την επίδοση του μοντέλου να ισούται με 84% και απώλεια ίση με 0,41.



Εικόνα 3.23: Ακρίβεια μοντέλου CNN



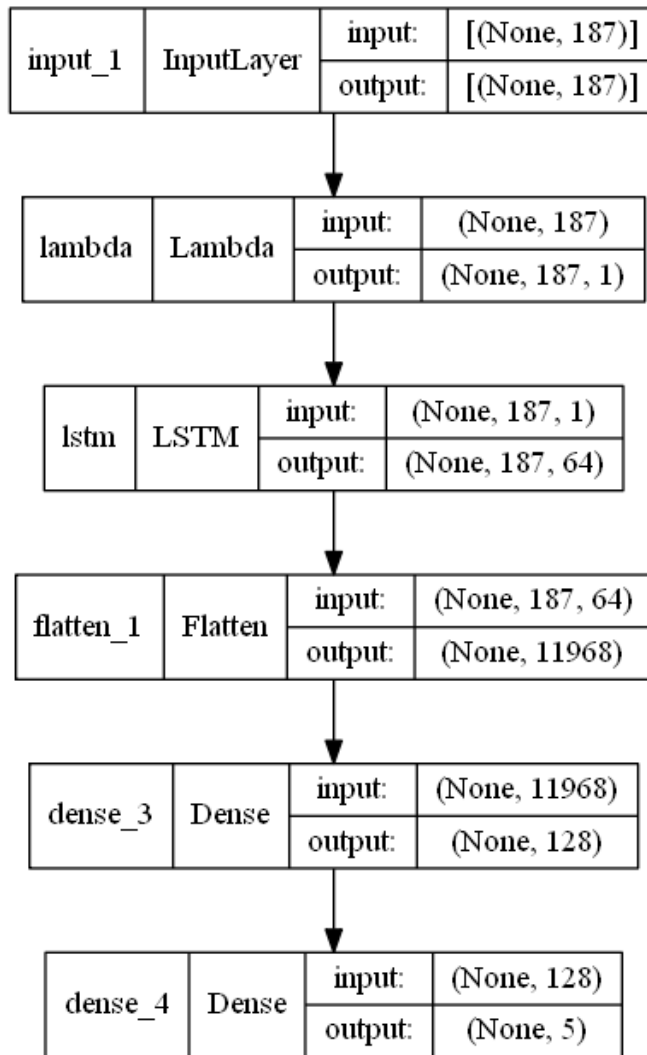
Εικόνα 3.24: Απώλεια μοντέλου CNN

Από τα παραπάνω γραφήματα παρατηρείται πως το CNN μοντέλο αποτελεί ένα ικανοποιητικό μοντέλο για χρήση αποφεύγοντας είτε την υπερ-μοντελοποίηση είτε την υπο-μοντελοποίηση.

### **LSTM Network**


Η άλλη μέθοδος που χρησιμοποιήθηκε είναι ο αλγόριθμος βαθιάς μάθησης Long Short-Term Memory Network ή αλλιώς LSTM Network. Στην αρχιτεκτονική του παρουσιάζεται στην είσοδο στρώμα με τα μεγέθη εισόδου του συνόλου δεδομένων που οδηγείται στο στρώμα Lambda, που χρησιμοποιείται για τον μετασχηματισμό των δεδομένων εισόδου. Έπειτα, το επόμενο στρώμα στη σειρά είναι το στρώμα LSTM με 64 μονάδες, του οποίου οι έξοδοι οδηγούνται στο στρώμα Flatten, με σκοπό τη συμπίεση των διαστάσεων εισόδου του. Τέλος, καταλήγουν σε ένα ολοκληρωμένο συνδεδεμένο στρώμα, με στρώμα εισόδου Dense με 128 μονάδες και συνάρτηση ενεργοποίησης ReLU και στρώμα εξόδου Dense με 5 μονάδες και συνάρτηση ενεργοποίησης Sigmoid. Επίσης και το συγκεκριμένο μοντέλο χρησιμοποίησε ως βελτιστοποιητή τον (optimizer) Adam.






Εικόνα 3.25: Αρχιτεκτονική LSTM Network αλγορίθμου

Το μοντέλο εκπαιδεύτηκε με επιτυχία για 20 εποχές, φέρνοντας την επίδοση του μοντέλου να ισούται με 99% και απώλεια ίση με 0,03, γεγονός που σημαίνει πως έχει δημιουργηθεί υπερ-μοντελοποίηση. Το φαινόμενο αυτό παρατηρείται και στην Εικόνα 3.26 και 3.27.



Εικόνα 3.26: Ακρίβεια μοντέλου LSTM Network



Εικόνα 3.27: Απόλεια μοντέλου LSTM Network

### 3.2.5 Σύνοψη

Με τη χρήση των αλγορίθμων CNN και LSTM Network και την κατασκευή των βέλτιστων αρχιτεκτονικών για κάθε περίπτωση, πραγματοποιήθηκε εκπαίδευση στο επεξεργασμένο σύνολο δεδομένων, με σκοπό τη δημιουργία των ιδανικότερων μοντέλων. Όπως φαίνεται στον Πίνακα 3.4 και στα γραφήματα ακριβείας και απώλειας κάθε μοντέλου αντίστοιχα, βγαίνει το συμπέρασμα πως το ιδανικότερο μοντέλο για χρήση στην παρούσα εφαρμογή αποτελεί το μοντέλο του αλγορίθμου CNN.

Πίνακας 3.4: Τα αποτελέσματα των μοντέλων των αλγορίθμων

Μέθοδος	Ακρίβεια	Απόλεια
Convolutional Neural Network	0.843249	0.411508
LSTM Network	0.994374	0.029345


### 3.2.6 Δοκιμή μοντέλου

Πραγματοποιείται δοκιμή του μοντέλου CNN, ως το καταλληλότερο, σε ένα τυχαίο δείγμα από το σύνολο δεδομένων δοκιμών, όπως φαίνεται στον Πίνακα 3.5, αναμένοντας να δίνεται το αντίστοιχο αποτέλεσμα και στη συγκεκριμένη περίπτωση "Normal Beats" ή αλλιώς 0.0 όπως παρουσιάζεται στο σύνολο δεδομένων.

Πίνακας 3.5: Τυχαίο δείγμα από το σύνολο δεδομένων δοκιμών

	0	1	2	3	4	...	187
14504	0.936242	0.949664	0.694631	0.42953	0.090604	...	0.0

Έπειτα από τη διαδικασία δοκιμής του προαναφερθέντος δείγματος, παρατηρείται στην Εικόνα 3.26 πως το συγκεκριμένο μοντέλο πρόβλεψε την ετικέτα του δείγματος με ακρίβεια.



Εικόνα 3.28: Αποτέλεσμα εφαρμογής του μοντέλου

## Κεφάλαιο 4

### 4.1 Συμπεράσματα

Στην παρούσα διπλωματική εργασία, πραγματοποιήθηκε μια ολοκληρωμένη ανασκόπηση του στρες, της μεταβλητότητας του καρδιακού ρυθμού, της καρδιακής κατάστασης και των μεθόδων μηχανικής και βαθιάς μάθησης. Βάσει αυτού, προέκυψε και παρατηρήθηκε μια σχέση μεταξύ του στρες και της απόδοσης. Επίσης, προτείνονται μηχανισμοί για τη αξιολόγηση του στρες, της νοητικής προσπάθειας, της προσοχής και του φόρτου εργασίας κατά τη διάρκεια λήψης αποφάσεων. Πραγματοποιήθηκαν δύο εφαρμογές τόσο για την ανίχνευση του ψυχικού στρες όσο και για την ανίχνευση της καρδιακής κατάστασης.

Για την πρώτη εφαρμογή, τη συσχέτιση μεταξύ του ψυχικού στρες και της μεταβλητότητας του καρδιακού ρυθμού, προσδιορίστηκε μια σειρά παραμέτρων της μεταβλητότητας του καρδιακού ρυθμού, οι οποίες ενδέχεται να επηρεάζονται άμεσα από το ψυχικό στρες. Μία ανάλυση της σχέσης μεταξύ των χαρακτηριστικών και του ψυχικού στρες πραγματοποιήθηκε με δεδομένα μεταβλητότητας του καρδιακού ρυθμού από το σύνολο δεδομένων SWELL-KW, με τη χρήση αλγορίθμων μηχανικής μάθησης με επίβλεψη. Η μελέτη των εννοιών που συσχετίζονται με το στρες, παρουσιάζει τη μεταβλητότητα του καρδιακού ρυθμού να ανταποκρίνεται στις μεταβολές του στρες έναντι άλλων εννοιών, με αποτέλεσμα να επικυρώνεται η συσχέτιση του στρες με τη μεταβλητότητα του καρδιακού ρυθμού. Επιπλέον, η χρήση των κατάλληλων χαρακτηριστικών για την εκπαίδευση των μοντέλων που χρησιμοποιήθηκαν και των κατάλληλων παραμέτρων για κάθε ένα εξ' αυτών, έβγαλαν σε συμπεράσματα πως το ιδανικότερο μοντέλο προς χρήση είναι του αλγορίθμου K-Nearest Neighbors, με μία αρκετά ικανοποιητική επίδοση.

Όσον αφορά την κατάσταση της καρδιάς και την περίπτωση της δεύτερης εφαρμογής, πραγματοποιήθηκε ανάλυση των καρδιακών παλμών σε χρονοσειρά, με δεδομένα καρδιακών παλμών από τη συγχώνευση δύο βάσεων δεδομένων, τη MIT-BIH Arrhythmia Database και τη PTB Diagnostic ECG Database, με τη χρήση αλγορίθμων βαθιάς μάθησης με επίβλεψη. Για τη δημιουργία των βέλτιστων μοντέλων, δημιουργήθηκαν κατάλληλες αρχιτεκτονικές αντίστοιχα για κάθε αλγόριθμο και σε συνδυασμό με το επεξεργασμένο σύνολο δεδομένων, απέφεραν το μοντέλο του LSTM Network ως το ικανότερο για χρήση. Ωστόσο, αξίζει να σημειωθεί πως υπάρχει δυνατότητα βελτιστοποίησης της αρχιτεκτονικής του συγκεκριμένου αλγορίθμου με σκοπό να επιφέρει μεγαλύτερες επιδόσεις.

### 4.2 Μελλοντικές εργασίες

Η μηχανική μάθηση εξαρτάται από μεγάλες ποσότητες δεδομένων, κάνοντας την ανάλυσή τους αρκετά σημαντική. Να σημειωθεί, επίσης, πως η συλλογή μαζικών δεδομένων κοστίζει τόσο σε κόπο όσο και σε χρήμα. Η παρούσα διπλωματική εργασία μπορεί να διευκολύνει την αποτελεσματικότητα εφαρμογών των παρόμοιων ερευνών σε προβλήματα του πραγματικού κόσμου. Επιπλέον, στόχο της εργασίας αυτής αποτελεί η χρήση των δύο εφαρμογών (η ανίχνευση του ψυχικού στρες και η ανίχνευση της καρδιακής κατάστασης) σε συνδυασμό με τα αυτόνομα οχήματα, με σκοπό την πρόβλεψη και αποφυγή τροχαίων ατυχημάτων.

## Βιβλιογραφία

- [1] C. Su, Heart Rate Variability Feature Selection using Random Forest for Mental Stress Quantification, 2020.
- [2] Andreas C. Müller και Sarah Guido, Introduction to Machine Learning with Python.
- [3] Κ. Διαμαντάρας και Δ. Μπότσης, Μηχανική Μάθηση, ΕΚΔΟΣΕΙΣ ΚΛΕΙΔΑΡΙΘΜΟΣ.
- [4] V. Nasteski, «An overview of the supervised machine learning,» *Research Gate*, 2018.
- [5] I. C. Education, «Deep Learning,» 2020. [Ηλεκτρονικό]. Available: <https://www.ibm.com/cloud/learn/deep-learning>.
- [6] Samaya Madhavan και M. Tim Jones, «Deep learning architectures,» 2017. [Ηλεκτρονικό]. Available: [https://developer.ibm.com/articles/cc-machine-learning-deep-learning-architectures/?mhsrc=ibmsearch\\_a&mhq=lstm](https://developer.ibm.com/articles/cc-machine-learning-deep-learning-architectures/?mhsrc=ibmsearch_a&mhq=lstm).
- [7] M. Ashtiyani, S. Navaei Lavasani, M.R. Deevband και A. Asgharzadeh Alvar, «Heart Rate Variability Classification using Support Vector Machine and Genetic Algorithm,» *US National Library of Medicine*, 2018.
- [8] J. H. M. Team, «Electrocardiogram,» [Ηλεκτρονικό]. Available: <https://www.hopkinsmedicine.org/health/treatment-tests-and-therapies/electrocardiogram>.
- [9] P. Marney A. White, «What the Yerkes-Dodson Law Says About Stress and Performance,» healthline, 2020. [Ηλεκτρονικό]. Available: <https://www.healthline.com/health/yerkes-dodson-law>.
- [10] G. Giannakakis, K. Marias και M. Tsiknakis, «A stress recognition system using HRV parameters,» *8th International Conference on Affective Computing and Intelligent Interaction Workshops and Demos (ACIIW)*, 2019.
- [11] Ali Oskooei, Sophie Mai Chau, Jonas Weiss, Jonas Weiss, María Rodríguez Martínez και Bruno Michel, «DeStress: Deep Learning for Unsupervised Identification of Mental Stress in Firefighters from Heart-rate Variability (HRV) Data,» *Cornell University*, 2019.
- [12] José Vicente, Pablo Laguna, Pablo Laguna και Pablo Laguna, «Drowsiness detection using heart rate variability,» *Medical & Biological Engineering & Computing*, 2016.
- [13] R. W. Picard, Wearable and automotive systems for affect recognition from physiology, Massachusetts Institute of Technology. Department of Electrical Engineering and Computer Science, 2000.
- [14] Wilhelm von Rosenberg, Theerasak Chanwimalueang, Tricia Adjei, Usman Jaffer, Usman Jaffer και Danilo P. Mandic, «Resolving Ambiguities in the LF/HF Ratio: LF-HF Scatter Plots for the Categorization of Mental and Physical Stress from HRV,» 2017. [Ηλεκτρονικό]. Available: <https://www.frontiersin.org/articles/10.3389/fphys.2017.00360/full#h2>.
- [15] Koldijk, S, Sappelli, M, Verberne, S., Verberne, S και Kraaij, W., «The SWELL Knowledge Work Dataset for Stress and User Modeling Research,» 2014. [Ηλεκτρονικό]. Available: <http://cs.ru.nl/~skoldijk/SWELL-KW/Dataset.html>.
- [16] George Moody και Roger Mark, «MIT-BIH Arrhythmia Database,» 2015. [Ηλεκτρονικό]. Available: <https://www.physionet.org/content/mitdb/1.0.0/>.
- [17] R.-D. Boussejot, «PTB Diagnostic ECG Database,» 2004. [Ηλεκτρονικό]. Available: <https://www.physionet.org/content/ptbdb/1.0.0/>.
- [18] Sun Hee Shim, MD, Sun-Young Park, MD, Se Na Moon, MD, Jin Hee Oh, MD, PhD, Jae Young Lee, MD, PhD, Hyun Hee Kim, MD, PhD, Ji Whan Han, MD, PhD και Ji Whan Han, MD, PhD, «Baseline heart rate variability in children and adolescents with vasovagal syncope,» 2014. [Ηλεκτρονικό]. Available: <https://www.e-cep.org/journal/view.php?number=2013600075>.
- [19] Gatha Tanwar, Ritu Chauhan, Madhusudan Singh και Dhananjay Singh, «Pre-Emption of Affliction Severity Using HRV Measurements from a Smart Wearable; Case-Study on SARS-Cov-2 Symptoms,» *US National Library of Medicine*, 2020.
- [20] C. Ottesen, «Tutorial: Stress detection with wearable devices and Machine Learning,» 2019. [Ηλεκτρονικό]. Available: <https://dataespresso.com/en/2019/01/30/stress-detection-with-wearable-devices-and-machine-learning/>.

- [21] M. Dr. Payal Kohli, «The heart: All you need to know,» 2020. [Ηλεκτρονικό]. Available: <https://www.medicalnewstoday.com/articles/320565>.
- [22] C. Kariuki, «Retitling Stress: A Look at the Yerkes-Dodson Law,» 2021. [Ηλεκτρονικό]. Available: <https://sites.dartmouth.edu/dujs/2021/02/07/retitling-stress-a-look-at-the-yerkes-dodson-law/>.
- [23] E. Team, «What is Machine Learning? A Definition.,» 2020. [Ηλεκτρονικό]. Available: <https://www.expert.ai/blog/machine-learning-definition/>.
- [24] Iqbal Muhammad και Zhu Yan, SUPERVISED MACHINE LEARNING APPROACHES: A SURVEY, School of Information Sciences and Technology, Southwest Jiaotong University, China.
- [25] Jiashi Feng, Huan Xu, Shie Mannor και Shuicheng Yan, «School of Information Sciences and Technology, Southwest Jiaotong University, China,» [Ηλεκτρονικό]. Available: <https://proceedings.neurips.cc/paper/2014/file/6cdd60ea0045eb7a6ec44c54d29ed402-Paper.pdf>.
- [26] S. Fazeli, «ECG Heartbeat Categorization Dataset,» 2018. [Ηλεκτρονικό]. Available: <https://www.kaggle.com/shayanfazeli/heartbeat>.
- [27] M. C. Staff, «Supraventricular tachycardia,» [Ηλεκτρονικό]. Available: <https://www.mayoclinic.org/diseases-conditions/supraventricular-tachycardia/symptoms-causes/syc-20355243>.
- [28] «Normal sinus rhythm with ventricular ectopics,» 2020. [Ηλεκτρονικό]. Available: <https://www.gosh.nhs.uk/conditions-and-treatments/conditions-we-treat/normal-sinus-rhythm-ventricular-ectopics/>.
- [29] George B. Moody και Roger G. Mark, «The Impact of the MIT-BIH Arrhythmia Database,» 2001. [Ηλεκτρονικό]. Available: <http://ecg.mit.edu/george/publications/mitdb-embs-2001.pdf>.
- [30] Upasana, «Difference between Loss, Accuracy, Validation loss, Validation accuracy in Keras,» 2019. [Ηλεκτρονικό]. Available: <https://www.javacodemonk.com/difference-between-loss-accuracy-validation-loss-validation-accuracy-in-keras-ff358faa>.
- [31] P. M. MALIK. M.D., «Electrophysiology, Pacing, and Arrhythmia,» 1990. [Ηλεκτρονικό].
- [32] «Εικόνα 1.1: Κατηγορίες Μηχανικής Μάθησης,» [Ηλεκτρονικό]. Available: <https://www.geeksforgeeks.org/ml-types-learning-supervised-learning/>.
- [33] «Εικόνα 1.2: Μηχανική Μάθηση με επίβλεψη,» [Ηλεκτρονικό]. Available: <https://www.geeksforgeeks.org/ml-types-learning-supervised-learning/>.
- [34] «Εικόνα 1.3: Ταξινόμηση αριθμών χρησιμοποιώντας δέντρο απόφασης,» [Ηλεκτρονικό]. Available: <https://elf11.github.io/2018/07/01/python-decision-trees-acm.html>.
- [35] «Εικόνα 1.4: Δομή αλγορίθμου Random Forest,» [Ηλεκτρονικό]. Available: <https://medium.com/analytics-vidhya/random-forest-classifier-and-its-hyperparameters-8467bec755f6>.
- [36] «Εικόνα 1.5: Απεικόνιση λογιστικής παλινδρόμησης,» [Ηλεκτρονικό]. Available: [http://www.masteringdatascience.co.uk/CaseStudy\\_LogisticRegression.html](http://www.masteringdatascience.co.uk/CaseStudy_LogisticRegression.html).
- [37] «Εικόνα 1.6: Παράδειγμα KNN αλγορίθμου,» [Ηλεκτρονικό]. Available: <https://medium.com/analytics-vidhya/k-nearest-neighbors-knn-8f027ae1228f>.
- [38] «Εικόνα 1.7: Δομείς των αλγορίθμων Decision Tree, Gradient Boosted Decision Trees και Random Forest,» [Ηλεκτρονικό]. Available: <https://medium.com/analytics-vidhya/ensemble-models-bagging-boosting-c33706db0b0b>.
- [39] «Εικόνα 1.8: Κατηγορίες Βαθιάς Μάθησης,» [Ηλεκτρονικό]. Available: [https://developer.ibm.com/articles/cc-machine-learning-deep-learning-architectures/?mhsr=ibmsearch\\_a&mhq=lstm](https://developer.ibm.com/articles/cc-machine-learning-deep-learning-architectures/?mhsr=ibmsearch_a&mhq=lstm).
- [40] «Εικόνα 1.9: Παράδειγμα CNN αρχιτεκτονικής,» [Ηλεκτρονικό]. Available: [https://developer.ibm.com/articles/cc-machine-learning-deep-learning-architectures/?mhsr=ibmsearch\\_a&mhq=lstm](https://developer.ibm.com/articles/cc-machine-learning-deep-learning-architectures/?mhsr=ibmsearch_a&mhq=lstm).
- [41] «Εικόνα 1.10: Παράδειγμα LSTM αρχιτεκτονικής,» [Ηλεκτρονικό]. Available: [https://developer.ibm.com/articles/cc-machine-learning-deep-learning-architectures/?mhsr=ibmsearch\\_a&mhq=lstm](https://developer.ibm.com/articles/cc-machine-learning-deep-learning-architectures/?mhsr=ibmsearch_a&mhq=lstm).

- [42] «Εικόνα 1.11: Αποτελέσματα μοντέλων με ικανοποιητική ακρίβεια,» [Ηλεκτρονικό]. Available: [https://satishgunjal.com/underfitting\\_overfitting/](https://satishgunjal.com/underfitting_overfitting/).
- [43] «Εικόνα 1.12: Αποτελέσματα μοντέλων με υπερ-μοντελοποίηση,» [Ηλεκτρονικό]. Available: [https://satishgunjal.com/underfitting\\_overfitting/](https://satishgunjal.com/underfitting_overfitting/).
- [44] «Εικόνα 1.13: Αποτελέσματα μοντέλων με υπο-μοντελοποίηση,» [Ηλεκτρονικό]. Available: [https://satishgunjal.com/underfitting\\_overfitting/](https://satishgunjal.com/underfitting_overfitting/).
- [45] «Εικόνα 2.1: Η ανατομία της καρδιάς,» [Ηλεκτρονικό]. Available: <https://www.texasheart.org/heart-health/heart-information-center/topics/heart-anatomy/>.
- [46] «Εικόνα 2.2: Μια τυπική φυσιολογική κυματομορφή ηλεκτροκαρδιογραφήματος,» [Ηλεκτρονικό]. Available: [https://www.researchgate.net/figure/Normal-healthy-ECG-waveform-Where-P-wave-QRS-complex-and-T-wave-represent-the\\_fig1\\_321812830](https://www.researchgate.net/figure/Normal-healthy-ECG-waveform-Where-P-wave-QRS-complex-and-T-wave-represent-the_fig1_321812830).
- [47] «Εικόνα 2.3: Σχέση απόδοσης και ψυχικού στρες,» [Ηλεκτρονικό]. Available: <https://www.pngegg.com/en/png-cs1px>.

## Παράρτημα Α - Κώδικας Python εφαρμογής ανίχνευσης ψυχικού στρες

0. Εισαγωγή βιβλιοθηκών

```
import pandas as pd
import numpy as np
import pandas_profiling as pp
import matplotlib
import matplotlib.pyplot as plt
%matplotlib inline
import seaborn as sns
from sklearn import preprocessing
from sklearn.metrics import classification_report, accuracy_score, confusion_matrix
from sklearn.ensemble import RandomForestClassifier
from sklearn import linear_model
from sklearn.linear_model import LogisticRegression
from sklearn.neighbors import KNeighborsClassifier
from sklearn.tree import DecisionTreeClassifier
from sklearn.ensemble import GradientBoostingClassifier
```

1. Ανάγνωση δεδομένων

```
train = pd.read_csv("train.csv")
```

2. Απεικόνιση ετικετών

```
conditions = dict(train['condition'].value_counts())
labels = list(conditions.keys())
counts = list(conditions.values())
plt.bar(labels, counts, color='blueviolet', width = 0.6)
```

3. Κωδικοποίηση ετικετών

```
le = preprocessing.LabelEncoder()
le.fit(train['condition'])
train['condition'] = le.transform(train['condition'])
```

4. Απεικόνιση του πίνακα συσχέτισης Pearson

```
plt.figure(figsize=(12,10))
corr = train.corr()
sns.heatmap(corr, annot=False, cmap=plt.cm.Reds)
plt.show()
```

5. Ορισμός συνάρτησης επιλογής χαρακτηριστικών

```
def feature_selection(correlation,threshold):
```

```
    selected_features = []
    for i in range(corr.shape[0]):
        if corr.iloc[i,35] > threshold:
            selected_features.append(train.iloc[:,i])
    return pd.DataFrame(selected_features).T
```

```
CORRELATION_THRESHOLD = 0.1
```

```
reduced_train = feature_selection(corr,CORRELATION_THRESHOLD)
```

6. Διαχωρισμός των δεδομένων

```
X_train = reduced_train.iloc[:, :-1]
```

```
y_train = reduced_train.iloc[:, -1]
```

7. Δημιουργία και εκτέλεση α Random Forest μοντέλου

```
rf = RandomForestClassifier(n_estimators=2)
rf.fit(X_train,y_train)
y_pred = rf.predict(X_test)
rf_accuracy = accuracy_score(y_test,y_pred)
clf_report = classification_report(y_test, y_pred, output_dict=True)
sns.heatmap(pd.DataFrame(clf_report).iloc[:,-1, :].T, annot=True, cmap= 'RdPu')
plt.figure(figsize=(8,6))
sns.heatmap(confusion_matrix(y_test,y_pred), annot = True, fmt = '0.0f', cmap= 'RdPu')
```

8. Δημιουργία και εκτέλεση Logistic Regression μοντέλου

```
log_reg = linear_model.LogisticRegression(C = 0.001)
log_reg.fit(X_train, y_train)
LogisticRegression(C=0.001)
y_pred = log_reg.predict(X_test)
log_reg_accuracy = accuracy_score(y_test,y_pred)
clf_report = classification_report(y_test, y_pred, output_dict=True)
sns.heatmap(pd.DataFrame(clf_report).iloc[:-1, :].T, annot=True, cmap= 'RdPu')
plt.figure(figsize=(8,6))
sns.heatmap(confusion_matrix(y_test,y_pred), annot = True, fmt = '0.0f', cmap= 'RdPu')
```

9. Δημιουργία και εκτέλεση KNN μοντέλου

```
knn = KNeighborsClassifier(n_neighbors=1)
knn.fit(X_train, y_train)
y_pred = knn.predict(X_test)
knn_accuracy = accuracy_score(y_test,y_pred)
clf_report = classification_report(y_test, y_pred, output_dict=True)
sns.heatmap(pd.DataFrame(clf_report).iloc[:-1, :].T, annot=True, cmap= 'RdPu')
plt.figure(figsize=(8,6))
sns.heatmap(confusion_matrix(y_test,y_pred), annot = True, fmt = '0.0f', cmap= 'RdPu')
```

10. Δημιουργία και εκτέλεση Decision Tree μοντέλου

```
dtree =DecisionTreeClassifier("gini")
dtree.fit(X_train, y_train)
DecisionTreeClassifier()
y_pred = dtree.predict(X_test)
dtree_accuracy = accuracy_score(y_test,y_pred)
clf_report = classification_report(y_test, y_pred, output_dict=True)
sns.heatmap(pd.DataFrame(clf_report).iloc[:-1, :].T, annot=True, cmap= 'RdPu')
plt.figure(figsize=(8,6))
sns.heatmap(confusion_matrix(y_test,y_pred), annot = True, fmt = '0.0f', cmap= 'RdPu')
```

11. Δημιουργία και εκτέλεση GBDT μοντέλου

```
gbdt = GradientBoostingClassifier(n_estimators=10, max_depth=10)
gbdt.fit(X_train, y_train)
y_pred = gbdt.predict(X_test)
gbdt_accuracy = accuracy_score(y_test,y_pred)
clf_report = classification_report(y_test, y_pred, output_dict=True)
sns.heatmap(pd.DataFrame(clf_report).iloc[:-1, :].T, annot=True, cmap= 'RdPu')
plt.figure(figsize=(8,6))
sns.heatmap(confusion_matrix(y_test,y_pred), annot = True, fmt = '0.0f', cmap= 'RdPu')
```

12. Αποτελέσματα ακριβείας

```
Summary = {'Method':['Decision Tree', 'Random Forest', 'Logistic Regression', 'K-Nearest Neighbors', 'Gradient Boosted Decision Trees'],
           'Accuracy':[dtree_accuracy, rf_accuracy, log_reg_accuracy, knn_accuracy, gbdt_accuracy]}
```

```
Summary = pd.DataFrame(Summary)
Summary.set_index('Method', inplace=True)
Summary.plot.bar()
```

13. Δοκιμή τυχαίου δείγματος

```
test = pd.read_csv("test.csv")
X_test = test[X_train.columns]
y_test = test['condition']
def final_result(result):
```

```
    if result == 0:
        x = 'interruption'
    elif result == 1:
        x = 'no stress'
    else:
```



```

    x = 'time pressure'
    return (x)
X_test_sample = X_test.sample()
result = loaded_model.predict(X_test_sample)
final_result(result))

```

## Παράρτημα Β - Κώδικας Python εφαρμογής ανίχνευσης καρδιακής κατάστασης

0. Εισαγωγή βιβλιοθηκών

```

import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns
sns.set_style("whitegrid")
from sklearn.utils import resample
from tensorflow.keras.utils import to_categorical
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Conv1D, MaxPooling1D, Flatten, LSTM, Lambda
from tensorflow.keras.optimizers import Adam
from tensorflow.keras.layers import BatchNormalization
from tensorflow.keras.utils import plot_model
from keras.preprocessing import sequence

```

1. Ανάγνωση δεδομένων

```

train_data = pd.read_csv("mitbih_train.csv", header = None)
test_data = pd.read_csv("mitbih_test.csv", header = None)

```

2. Απεικόνιση ετικετών

```

train_data[187] = train_data[187].astype('int')
test_data[187] = test_data[187].astype('int')
sns.catplot(x = 187, kind = 'count', data = train_data)
plt.figure(figsize= (10,10))
my_circle = plt.Circle((0,0), 0.7, color = 'white')
plt.pie(train_data[187].value_counts(), labels=['Normal Beats','Unknown Beats', 'Ventricular Ectopic Beats','Supraventricular Ectopic Beats', 'Fusion Beats'],autopct = '%0.2f%%',colors = ['blue','orchid','olive','orange','tomato'])
p = plt.gcf()
p.gca().add_artist(my_circle)
plt.show()

```

3. Διαχωρισμός των ετικετών σε επιμέρους και σύγκριση αυτών

```

df_1 = train_data[train_data[187] == 1]
df_2 = train_data[train_data[187] == 2]
df_3 = train_data[train_data[187] == 3]
df_4 = train_data[train_data[187] == 4]
plt.figure(figsize=(20,10))
plt.plot(train_data.iloc[0, 0:187], color = 'red', label = 'Normal Heart Beats')
plt.plot(df_1.iloc[0, 0:187], color = 'blue', label = 'Supraventricular ectopic beats')
plt.title("ECG Normal vs Supraventricular Ectopic Beats", fontsize = 14)
plt.xlabel("Time (in ms)")
plt.ylabel("Heart Beat Amplitude")
plt.legend()
plt.show()
plt.figure(figsize=(20,10))
plt.plot(train_data.iloc[0, 0:187], color = 'red', label = 'Normal Heart Beats')
plt.plot(df_2.iloc[0, 0:187], color = 'blue', label = 'Ventricular ectopic beats')
plt.title("ECG Normal vs Ventricular Ectopic Beats", fontsize = 14)
plt.xlabel("Time (in ms)")

```

```

plt.ylabel("Heart Beat Amplitude")
plt.legend()
plt.show()
plt.figure(figsize=(20,10))
plt.plot(train_data.iloc[0, 0:187], color = 'red', label = 'Normal Heart Beats')
plt.plot(df_3.iloc[0, 0:187], color = 'blue', label = 'Fusion Beats')
plt.title("ECG Normal vs Fusion Beats", fontsize = 14)
plt.xlabel("Time (in ms)")
plt.ylabel("Heart Beat Amplitude")
plt.legend()
plt.show()
plt.figure(figsize=(20,10))
plt.plot(train_data.iloc[0, 0:187], color = 'red', label = 'Normal Heart Beats')
plt.plot(df_4.iloc[0, 0:187], color = 'blue', label = 'Unknown Beats')
plt.title("ECG Normal vs Unknown Beats", fontsize = 14)
plt.xlabel("Time (in ms)")
plt.ylabel("Heart Beat Amplitude")
plt.legend()
plt.show()
4. Δημιουργία νέου συνόλου δεδομένων με ίδιο αριθμό δειγμάτων
df_0 = train_data[train_data[187]==0].sample(n=20000, random_state=123)
df_1_upsample = resample(df_1, n_samples = 20000, replace = True, random_state = 123)
df_2_upsample = resample(df_2, n_samples = 20000, replace = True, random_state = 123)
df_3_upsample = resample(df_3, n_samples = 20000, replace = True, random_state = 123)
df_4_upsample = resample(df_4, n_samples = 20000, replace = True, random_state = 123)
train_df = pd.concat([df_0, df_1_upsample, df_2_upsample, df_3_upsample, df_4_upsample])
5. Απεικόνιση του νέου συνόλου δεδομένων
sns.catplot(x = 187, kind = 'count', data = train_df)
plt.figure(figsize= (10,10))
my_circle = plt.Circle((0,0), 0.7, color = 'white')
plt.pie(train_df[187].value_counts(), labels=['Normal Beats','Unknown Beats', 'Ventricular Ectopic Beats','Supraventricular
Ectopic Beats', 'Fusion Beats'],autopct = '%0.2f%%',colors = ['blue','orchid','olive','orange','tomato'])
p = plt.gcf()
p.gca().add_artist(my_circle)
plt.show()
6. Προετοιμασία δεδομένων για εκπαίδευση
target_train = train_df[187]
target_test = test_data[187]
X_train = train_df.iloc[:, :-1].values
X_test = test_data.iloc[:, :-1].values
y_train = to_categorical(target_train)
y_test = to_categorical(target_test)
6.1 Μετατροπή του μεγέθους των εισόδων
X_train = X_train.reshape(len(X_train),X_train.shape[1],1)
X_test = X_test.reshape(len(X_test),X_test.shape[1],1)
7. Δημιουργία και εκτέλεση CNN μοντέλου
def build_model():
    model = Sequential()
    model.add(Conv1D(filters = 64, kernel_size = 6, activation='relu', padding = 'same', input_shape = (187, 1)))
    model.add(BatchNormalization())
    model.add(MaxPooling1D(pool_size=(3), strides = (2), padding = 'same'))
    model.add(Conv1D(filters = 64, kernel_size = 6, activation='relu', padding = 'same'))
    model.add(BatchNormalization())
    model.add(MaxPooling1D(pool_size=(3), strides = (2), padding = 'same'))
    model.add(Conv1D( filters = 64, kernel_size = 6, activation='relu', padding = 'same'))

```

```

model.add(BatchNormalization())
model.add(MaxPooling1D(pool_size=(3), strides = (2), padding = 'same'))
model.add(Flatten())
model.add(Dense(units = 64, activation='relu'))
model.add(Dense(units = 64, activation='relu'))
model.add(Dense(units = 5, activation='softmax'))
model.compile(optimizer = 'Adam', loss = 'categorical_crossentropy', metrics = ['accuracy'])
return model

model = build_model()
plot_model(model, show_shapes=True, show_layer_names=True)
history = model.fit(X_train, y_train, epochs = 50, batch_size = 32, validation_data=(X_test, y_test))
model.evaluate(X_test, y_test)
pd.DataFrame(history.history)
pd.DataFrame(history.history)[['accuracy', 'val_accuracy']].plot()
pd.DataFrame(history.history)[['loss', 'val_loss']].plot()

```

8. Δημιουργία και εκτέλεση LSTM μοντέλου

```

def build_model_2():
    model = tf.keras.models.Sequential([
        tf.keras.layers.Input(shape=(187,)),
        tf.keras.layers.Lambda(lambda x : tf.expand_dims(x,axis=-1)),
        tf.keras.layers.LSTM(64,return_sequences=True),
        tf.keras.layers.Flatten(),
        tf.keras.layers.Dense(128,activation='relu'),
        tf.keras.layers.Dense(5,activation='sigmoid')
    ])
    model.compile(optimizer = 'Adam', loss = 'categorical_crossentropy', metrics = ['accuracy'])
    return model

model_2 = build_model_2()
plot_model(model_2, show_shapes=True, show_layer_names=True)
history_2 = model_2.fit(X_train, y_train, epochs = 20, validation_data=(X_test, y_test))
model_2.evaluate(X_test, y_test)
pd.DataFrame(history_2.history)
pd.DataFrame(history_2.history)[['accuracy', 'val_accuracy']].plot()
pd.DataFrame(history_2.history)[['loss', 'val_loss']].plot()

```

9. Δοκιμή τυχαίου δείγματος

```

def final_result(result):
    if result == 0:
        x = 'Normal Beats'
    elif result == 1:
        x = 'Supraventricular Ectopic Beats'
    elif result == 2:
        x = 'Ventricular Ectopic Beats'
    elif result == 3:
        x = 'Fusion Beats'
    else:
        x = 'Unknown Beats'
    return (x)

X_test_sample = test_data.sample()
X_test_sample = X_test_sample.iloc[:, :-1].values
X_test_sample = X_test_sample.reshape(len(X_test_sample),X_test_sample.shape[1],1)
result = model.predict(X_test_sample)
result = np.argmax(result, axis = 1)
print('Your heartbeat signal is:', final_result(result[0]))

```