



**ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΙΑΣ**

**ΣΧΟΛΗ ΘΕΤΙΚΩΝ ΕΠΙΣΤΗΜΩΝ  
ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ ΜΕ ΕΦΑΡΜΟΓΕΣ ΣΤΗΝ ΒΙΟΙΑΤΡΙΚΗ**

**ΠΡΟΠΤΥΧΙΑΚΟ ΠΡΟΓΡΑΜΜΑ ΣΠΟΥΔΩΝ**

**ΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ**

**Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη  
συστήματος αυθεντικοποίησης μέσω δεδομένων  
ηλεκτροκαρδιογραφήματος**

**Ηλίας Χ. Χαματίδης**

**ΛΑΜΙΑ**

**ΜΑΪΟΣ 2018**



## **ΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ**

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης  
μέσω δεδομένων ηλεκτροκαρδιογραφήματος

**Ηλίας Χ. Χαματίδης**

### **ΕΠΙΒΛΕΠΩΝ ΚΑΘΗΓΗΤΗΣ**

**Γεώργιος Σπαθούλας**

Μέλος ΕΔΙΠ

Πανεπιστήμιο Θεσσαλίας

### **ΤΡΙΜΕΛΗΣ ΕΠΙΤΡΟΠΗ ΠΑΡΑΚΟΛΟΥΘΗΣΗΣ**

**Γεώργιος Σπαθούλας**

Μέλος ΕΔΙΠ

Πανεπιστήμιο Θεσσαλίας

**Μαρία Αδάμ**

Αναπληρωτής Καθηγητής

Πανεπιστήμιο Θεσσαλίας

**Κωνσταντίνος Δελήμπασης**

Επίκουρος Καθηγητής

Πανεπιστήμιο Θεσσαλίας

**Ημερομηνία Εξέτασης: 23 Μαΐου 2018**



## ΠΕΡΙΛΗΨΗ

Η παρούσα εργασία πραγματεύεται την χρήση του ηλεκτροκαρδιογραφήματος ως βιομετρικό χαρακτηριστικό για την αυθεντικοποίηση των χρηστών ενός συστήματος. Τα τελευταία χρόνια έχει διαπιστωθεί ότι πληροφορία που προκύπτει από το σήμα της καρδιάς είναι μοναδική για κάθε άνθρωπο και συνεπώς μπορεί να χρησιμοποιηθεί ως βιομετρικό χαρακτηριστικό.

Βασική δυσκολία στην υλοποίηση ενός έγκυρου πειράματος στην αρχή της συγγραφής αποτέλεσε η ανομοιομορφία των πειραμάτων της βιβλιογραφίας. Το κάθε πείραμα από την βιβλιογραφία είχε διαφορετικό αριθμό ατόμων, διαφορετικές μεθόδους εξαγωγής χαρακτηριστικών και αλγορίθμους ταξινόμησης. Έτσι πρώτο βήμα ήταν η διενέργεια ενός μεγάλου πειράματος με μεθόδους της βιβλιογραφίας ώστε να βρεθεί ο καλύτερος συνδυασμός μεθόδων.

Αρχικά έγινε λήψη του data set της Physionet ECG diagnostic database και δημιουργήθηκε ένα σύνολο από 50 άτομα που αποτέλεσε την κοινή βάση για τα πειράματα στην συνέχεια. Κατά το πρώτο στάδιο γίνεται προεπεξεργασία σε αυτά, εφαρμόζεται ένα φίλτρο Butterworth για την εξάλειψη του θορύβου καθώς γίνεται και κατάτμηση σε τμήματα.

Στην συνέχεια εφαρμόζονται μετασχηματισμοί σε αυτά τα σήματα ώστε να πάρουμε τα χαρακτηριστικά που θα χρησιμοποιηθούν. Οι μετασχηματισμοί που εφαρμόζονται είναι Discrete Fourier Transform, Discrete Cosine Transform, Wavelet Transform και η ανάλυση σε κύριες συνιστώσες (PCA).

Τελευταίο στάδιο αποτελεί η ταξινόμηση των χαρακτηριστικών αυτών ώστε να διαπιστωθεί η αποτελεσματικότητα της κάθε μεθόδου. Αυτό γίνεται με του αλγορίθμους K-Means, Multi-layer perceptron, Radial basis function, Random forest, RBF Network. Τέλος έγινε και η υλοποίηση ενός deep learning neural network για να ελεγχθεί η απόδοσή του όσον αφορά τη βιομετρική αυθεντικοποίηση.

**ΘΕΜΑΤΙΚΗ ΠΕΡΙΟΧΗ:** Ασφάλεια υπολογιστών

**ΛΕΞΕΙΣ ΚΛΕΙΔΙΑ:** Ασφάλεια, βιομετρική αυθεντικοποίηση, καρδιογράφημα, μηχανική μάθηση



## **ABSTRACT**

The present thesis is relevant to the use of the electrocardiogram as a biometric for authentication purposes. Electrocardiogram is used vastly for medical diagnosis because it can give signs for many diseases just from a doctor interpreting the waveform of the signal. But recently it is known that information from these heart signal is unique for every human and can be used as a biometric trait.

The difficulty starting a valid experiment was that in the relative bibliography there were many different opposed frames of doing the authentication. So it was hard to distinguish the best method. There were variations among the size of test set, feature extraction methods and classification techniques. Firstly we had to establish a common base to test the methods proposed in bibliography and find the best pair of feature extraction-classification method.

A data set of 50 people was created which was then used for every experiment. Every signal is pre-processed to eliminate noise, so every signal is filtered with a Butterworth filter. The filtered signals were separated into pieces and every piece was transformed with various approaches. These transformations are: Discrete Fourier Transform, Discrete Cosine Transform, Wavelet Transform and Principal component analysis(PCA).

Last step was to classify those feature that were extracted to find the accuracy of each method. The algorithms that are tested are: K-Means, Multi-layer perceptron, Radial basis function, Random forest, RBF Network. Also a deep learning neural network was created to test if it is possible to perform biometric authentication.

**SUBJECT AREA:** Computer security

**KEYWORDS:** Security, biometric authentication, electrocardiogram, machine learning





**ΕΥΧΑΡΙΣΤΙΕΣ**



## ΠΕΡΙΕΧΟΜΕΝΑ

<b>1</b>	<b>Εισαγωγή</b>	<b>19</b>
<b>2</b>	<b>Βιομετρική αυθεντικοποίηση</b>	<b>21</b>
2.1	Εισαγωγή . . . . .	21
2.2	Βιομετρική αυθεντικοποίηση . . . . .	21
2.3	Κριτήρια επιλογής βιομετρικών χαρακτηριστικών . . . . .	23
2.4	Βασικά είδη βιομετρικών χαρακτηριστικών . . . . .	24
2.4.1	Βασικά βιομετρικά χαρακτηριστικά . . . . .	25
2.4.2	Το σήμα της καρδιάς . . . . .	30
2.4.2.1	Η ανατομία της καρδιάς . . . . .	30
2.4.2.2	Το σήμα της καρδιάς . . . . .	30
2.4.2.3	Το σήμα της καρδιάς ως βιομετρικό χαρακτηριστικό . . . . .	31
<b>3</b>	<b>Βιβλιογραφική έρευνα</b>	<b>35</b>
<b>4</b>	<b>Μέθοδοι</b>	<b>41</b>
4.1	Προεπεξεργασία . . . . .	41
4.1.1	Φίλτρο Butterworth . . . . .	41
4.2	Εξαγωγή χαρακτηριστικών . . . . .	42
4.2.1	Μετασχηματισμός Fourier . . . . .	42
4.2.1.1	Σειρά Fourier . . . . .	42
4.2.1.2	Συνεχής μετασχηματισμός Fourier . . . . .	43
4.2.1.3	Μετασχηματισμός Fourier Διακριτού Χρόνου . . . . .	44
4.2.1.4	Διακριτός μετασχηματισμός Fourier . . . . .	44

4.2.2	Διακριτός μετασχηματισμός συνημιτόνων . . . . .	45
4.2.3	Wavelet . . . . .	46
4.2.3.1	Συνεχής μετασχηματισμός Wavelet . . . . .	47
4.2.3.2	Διακριτός μετασχηματισμός Wavelet . . . . .	48
4.2.4	Βασικές συναρτήσεις κυματιδίων . . . . .	48
4.2.4.1	Haar Wavelet . . . . .	48
4.2.4.2	Meyer Wavelet . . . . .	49
4.2.4.3	Morlet Wavelet: . . . . .	49
4.2.4.4	Daubechies Wavelet . . . . .	50
4.2.5	PCA . . . . .	51
4.3	Classification . . . . .	52
4.3.1	Multilayer Perceptron . . . . .	53
4.3.1.1	Συναρτήσεις ενεργοποίησης . . . . .	54
4.3.2	K-Means . . . . .	55
4.3.3	Radial Basis Function . . . . .	55
4.3.4	Random Forest . . . . .	56
4.3.5	RBF Classifier . . . . .	57
4.3.6	Deep Neural Networks . . . . .	57
<b>5</b>	<b>Προτεινόμενη μεθοδολογία</b>	<b>61</b>
5.1	Non-Fiducial feature extraction και machine learning . . . . .	61
5.1.1	Preprocess . . . . .	61
5.1.2	Feature extraction . . . . .	62
5.1.3	Classification . . . . .	63
5.2	Non-Fiducial feature extraction και deep learning . . . . .	63
5.2.1	Preprocess . . . . .	63
5.2.2	Feature extraction . . . . .	64

5.2.3	Classification	65
5.3	Non-Fiducial feature extraction με PCA	65
5.3.1	Preprocess	65
5.3.2	Feature extraction με PCA	68
5.3.3	Classification	72
5.3.3.1	Classification με MLP σε όλα τα άτομα	72
5.3.3.2	Classification με MLP σε όλα τα άτομα με εφαρμογή cost-sensitive εκπαίδευσης	72
5.3.3.3	Classification με MLP σε άτομα εκτός του διανυσματικού χώρου	73
<b>6</b>	<b>Πειράματα και αποτελέσματα</b>	<b>75</b>
6.1	Συλλογή δεδομένων	75
6.2	Feature extraction	76
6.2.1	Non-Fiducial feature extraction με χρήση Fourier, Cosine και Wavelet	76
6.2.1.1	Διακριτός μετασχηματισμός Fourier	76
6.2.1.2	Discrete Cosine Transformation	77
6.2.1.3	Wavelet decomposition	77
6.2.2	PCA	78
6.3	Classification	78
6.3.1	Machine learning	78
6.3.2	Deep learning	80
6.3.2.1	ECGSyn	80
6.3.3	Machine learning στις συνιστώσες PCA	82
6.3.4	Απόσταση	82
6.3.5	Machine learning και PCA	83
6.3.5.1	Cost-sensitive εκπαίδευση	84

6.3.5.2	Training με μικρότερο διανυσματικό χώρο . . . . .	85
---------	---	----

<b>7</b>	<b>Συμπεράσματα</b>	<b>87</b>
----------	---------------------	-----------

## ΛΙΣΤΑ ΣΧΗΜΑΤΩΝ

2.1	Σχηματική αναπαράσταση της αναγνώρισης(identification) ενός ατόμου . . .	23
2.2	Ανατομία της καρδιάς . . . . .	31
2.3	Δυναμικό στην φλεβόκομβο της καρδιάς, φαίνονται οι διαφορές δυναμικού λόγω της μεταφοράς ιόντων . . . . .	32
2.4	Ηλεκτροκαρδιογράφημα που προκύπτει από το ηλεκτρόδιο V7 . . . . .	33
4.1	Οι απόκρίσεις συχνότητας για διάφορες τάξεις φίλτρων Butterworth . . . . .	41
4.2	Ανάλυση κυρίων συνιστωσών στο κλασσικό παράδειγμα των ανθών(IRIS Dataset) . . . . .	53
4.3	Οι δύο συνηθέστερες συναρτήσεις ενεργοποίησης που συναντάμε στα νευρωνικά δίκτυα . . . . .	54
4.4	Νευρώνας που δέχεται $m$ εισόδους και παράγει 1 έξοδο . . . . .	58
4.5	δίκτυο Multi-layer Perceptron με ένα κρυφό επίπεδο . . . . .	59
4.6	Deep neural network με 1 επίπεδο εισόδου, 3 κρυφά επίπεδα και 1 επίπεδο εξόδου . . . . .	59
4.7	Διαφορετικά κρυφά επίπεδα συνδυάζουν πληροφορία από προηγούμενα επίπεδα . . . . .	60
5.1	Η μορφολογία ενός καρδιακού παλμού, διακρίνονται οι κορυφές P, Q, R, S και T καθώς και απόστάσεις μεταξύ αυτών . . . . .	66
5.2	Διαφορετικοί παλμοί που εξήχθησαν από ένα άτομο, διακρίνονται ξεκάθαρα οι κορυφές R, P και T . . . . .	67
5.3	Οι 5 κύριες συνιστώσες ενός καρδιακού παλμού . . . . .	69
6.1	Καρδιακό σήμα μετά από το φιλτράρισμα με το φίλτρο Butterworth . . . . .	76
6.2	Σήμα της καρδιάς στο πεδίο του χρόνου και στο πεδίο της συχνότητας . . .	77
6.3	Μετασχηματισμός συνημίτονων σε καρδιακό σήμα . . . . .	78

6.4	Τρία επίπεδα διάσπασης Wavelet . . . . .	79
6.5	Οι κύριες συνιστώσες δύο καρδιακών παλμών από διαφορετικά άτομα. . .	80
6.6	Δομή του deep neural network . . . . .	82
6.7	Η ακρίβεια του δικτύου κατά την διάρκεια της εκπαίδευσης . . . . .	83
6.8	Η λογιστική συνάρτηση ενεργοποίησης σε κάθε κύκλο εκπαίδευσης . . . .	84
6.9	ποστάσεις Manhattan μεταξύ κυρίων συνιστοσών ενός ατόμου . . . . .	85
6.10	Αριθμός ατόμων που εκπαιδεύτηκε με κάθε ποινή . . . . .	86



## ΛΙΣΤΑ ΠΙΝΑΚΩΝ

- 6.1 Αποτελέσματα διαφορετικών μετασχηματισμών και αλγορίθμων ταξινόμησης 81
- 6.2 Αποτελέσματα 5 διαφορετικών αλγορίθμων με τα ίδια training και test set . 86
- 6.3 Αποτελέσματα cost-sensitive εκπαίδευσης στον αλγόριθμο Random Forest 86



## 1. ΕΙΣΑΓΩΓΗ

Η ασφάλεια των προσωπικών μας δεδομένων γίνεται όλο και πιο καίριο ζήτημα καθώς οι απειλές στην ασφάλεια των υπολογιστών αυξάνονται αλλά και οι χρήστες εκθέτουν όλο και μεγαλύτερο ποσοστό των προσωπικών τους δεδομένων στο διαδίκτυο καθιστώντας τα ευάλωτα στο να πέσουν σε λάθος χέρια με συνέπειες καταστροφικές. Κανείς δεν θα ήθελε οι προσωπικές του συζητήσεις ή φωτογραφίες να διαρρεύσουν στο διαδίκτυο. Έτσι η όλο και πιο έντονη χρήση των υπολογιστών και του διαδικτύου δημιουργεί την επιτακτική ανάγκη για μεγαλύτερη ασφάλεια στους χρήστες.

Η πρωταρχική μορφή ασφάλειας που είχαν οι υπολογιστές ήταν η χρήση ενός κωδικού είτε 4-ψήφιου είτε ενός αλφαριθμητικού συγκεκριμένου μήκους. Η χρήση τους όμως ενέχει δύο βασικούς κινδύνους. Αρχικά ο χρήστης θα έχει αρκετούς κωδικούς για κάθε υπηρεσία που χρησιμοποιεί με αποτέλεσμα να τους ξεχνάει. Αυτό έχει ως συνέπεια ο χρήστης να χρησιμοποιεί εύκολους κωδικούς που όμως είναι ευάλωτοι σε αρκετές επιθέσεις. Η χρήση κωδικών για την ασφάλεια των χρηστών αποτελεί την μέση λύση καθώς είναι η πιο εύκολη μέθοδος για αυθεντικοποίηση ενός ατόμου. Ενέχει όμως μεγάλο κίνδυνο για την ασφάλεια των προσωπικών δεδομένων του.

Τα τελευταία χρόνια οι επιθέσεις κλοπής δεδομένων γίνονται όλο και πιο εξεζητημένες, έτσι και οι μέθοδοι προστασίας πρέπει να εξελιχθούν. Πιο συγκεκριμένα το τελευταίο εξάμηνο του 2017 οι επιθέσεις αυξήθηκαν κατά 8500%. Αυτή η αύξηση οφείλεται εν μέρη στην όλο και μεγαλύτερη αξία των κρυπτονομισμάτων που πυροδότησε μία φρενίτιδα στο διαδίκτυο. Πολλές από τις επιθέσεις αυτές αποσκοπούν στην απόκτηση ενός κομματιού της ισχύος των χρηστών ώστε να κάνουν πιο εύκολα mine. Ακόμα το 71% της απώλειας των προσωπικών δεδομένων την περασμένη χρονιά προέρχεται από επιθέσεις τύπου phishing.

Το πρόβλημα ασφαλείας που αναλύθηκε υπόσχεται να λύσει η βιομετρική αυθεντικοποίηση. Βιομετρικά είναι όλα αυτά τα χαρακτηριστικά που προκύπτουν από την φυσιολογία ή την συμπεριφορά του ανθρώπου. Βασικό πλεονέκτημα των βιομετρικών χαρακτηριστικών είναι ακριβώς ότι δεν έχουν οι παραδοσιακές μορφές αυθεντικοποίησης, δηλαδή δεν μπορείς να τα ξεχάσεις γιατί τα έχεις πάντα μαζί σου και για τον ίδιο λόγο τα καθιστά και πιο δύσκολα να κλαπούν. Τα τελευταία χρόνια υπάρχει συνεχής άνοδος της χρήσης βιομετρικών μεθόδων αυθεντικοποίησης, ιδιαίτερα στις κινητές συσκευές που λόγω του hardware που έχουν είναι εύκολο να υλοποιηθούν συστήματα ανάγνωσης αρκετών βιο-

μετρικών χαρακτηριστικών.

Επίσης με την χρήση βιομετρικών χαρακτηριστικών μπορούν να αντιμετωπιστούν δύο πολύ σημαντικά προβλήματα. Το πρόβλημα της αυθεντικοποίησης, που αφορά της σύγκριση των βιομετρικών μου χαρακτηριστικών με κάποιο πρότυπο που υπάρχει στην βάση δεδομένων για να μπορέσει να καταλάβει το σύστημα αν όντως είμαστε αυτός που ισχυριζόμαστε ή όχι. Επίσης μπορούμε να απαντήσουμε και στο πρόβλημα της αναγνώρισης, που συγκρίνει τα βιομετρικά χαρακτηριστικά μας με όλα τα υπάρχοντα πρότυπα στην βάση και να βρει ποιο από όλα ανήκει σε εμάς και ουσιαστικά να απαντήσει στο ερώτημα "ποιος είμαστε" χωρίς να του έχουμε δώσει κάποιο στοιχείο.

Στόχος αυτής της πτυχιακής είναι να διερευνηθεί η αυθεντικοποίηση με το ηλεκτροκαρδιογράφημα των ανθρώπων. Πιο συγκεκριμένα η αυθεντικοποίηση του ατόμου με την επεξεργασία του σήματος που παράγεται από την καρδιά και διαβάζεται από την επιφάνεια του δέρματος. Είναι από τις τελευταίες και πιο σύγχρονες εξελίξεις στο χώρο των βιομετρικών χαρακτηριστικών. Η διαδικασία που ακολουθείται στην παρούσα εργασία αποτελείται από 3 διακριτά στάδια που το καθένα μπορεί να διαφοροποιείται από τα άλλα.

Πρώτο στάδιο αποτελεί η προεπεξεργασία του καρδιακού σήματος. Εδώ τα σήματα αρχικά φιλτράρονται για να εξαλείψουμε θόρυβο, παρεμβολές που προέρχονται από την δειγματοληψία. Το στάδιο της προεπεξεργασίας ετοιμάζει τα σήματα για το επόμενο στάδιο, το οποίο είναι η εξαγωγή των χαρακτηριστικών από την κυματομορφή του σήματος. Υπάρχουν πολλοί τρόποι να πάρει κάποιος χαρακτηριστικά από το σήμα. Τελευταίο στάδιο στην διαδικασία είναι η ταξινόμηση αυτών μέσω μηχανικής γνώσης ή κάποιου στατιστικού μέτρου για να διαπιστώσουμε αν τα χαρακτηριστικά που εξήχθησαν είναι ικανά να αποτελέσουν βιομετρικό χαρακτηριστικό αυθεντικοποίησης.

Συγκεκριμένα σε αυτή την εργασία τα στάδια που γίνεται η μεγαλύτερη διαφοροποίηση είναι τα δύο τελευταία, καθώς η βασική ιδέα ήταν να έχουμε μία κοινή βάση σε όλα τα πειράματα ώστε να πάρουμε έγκυρο αποτέλεσμα για το ποια διαδικασία είναι πιο αποδοτική. Έτσι στο στάδιο της εξαγωγής χαρακτηριστικών δοκιμάζονται διάφορες μέθοδοι. Όμοια και στο στάδιο της ταξινόμησης αυτών γίνεται έλεγχος της κάθε μεθόδου από το προηγούμενο στάδιο με διάφορους αλγορίθμους μηχανικής γνώσης ή και στατιστικών μέτρων για να διαπιστωθεί πιο ζευγάρι μετασχηματισμού-αλγορίθμου ταξινόμησης δίνει τα καλύτερα αποτελέσματα.

## 2. ΒΙΟΜΕΤΡΙΚΗ ΑΥΘΕΝΤΙΚΟΠΟΙΗΣΗ

### 2.1 Εισαγωγή

Οι ηλεκτρονικοί υπολογιστές αποτελούν πια αναπόσπαστο κομμάτι της καθημερινότητας των ανθρώπων. Η χρήση τους είναι ευρεία, από την δημόσια διοίκηση και τα τραπεζικά συστήματα μέχρι την εκπαίδευση και το εμπόριο. Τα οφέλη της χρήσης υπολογιστών σε όλους τους τομείς είναι αδιαμφισβήτητα, όμως η αυξανόμενη χρήση τους έδωσε έναυσμα σε νέους κινδύνους. Ο βασικότερος από αυτούς είναι η κλοπή προσωπικών δεδομένων και η παραποίηση ταυτότητας. Τα τελευταία χρόνια για να αντιμετωπιστούν οι αυξανόμενες ανάγκες των χρηστών στο διαδίκτυο σχετικά με την αυθεντικοποίησή τους έχει προταθεί η βιομετρική αυθεντικοποίηση. Ο βαθμός χρήσης και η απόδοσή της ιδιαίτερα σε φορητές συσκευές καταδεικνύει ότι θα αποτελέσει την κύρια επιλογή αυθεντικοποίησης στο προσεχές διάστημα.

### 2.2 Βιομετρική αυθεντικοποίηση

Οι παραδοσιακές μορφές αυθεντικοποίησης δεν μπορούν πια να ανταποκριθούν στις σύγχρονες ανάγκες των ατόμων στο διαδίκτυο, καθώς το κάθε άτομο έχει πληθώρα κωδικών που πρέπει να θυμάται. Συνήθως οι κωδικοί αυτοί είναι εύκολοι για πρακτικούς λόγους, με αποτέλεσμα τα προσωπικά δεδομένα των χρηστών να είναι ευάλωτα σε επιθέσεις από τρίτα μη εξουσιοδοτημένα πρόσωπα. Την λύση σε αυτό το ζήτημα προσπαθεί να δώσει τις τελευταίες δεκαετίες η χρήση μεθόδων αυθεντικοποίησης βάσει των βιομετρικών χαρακτηριστικών του ανθρώπου. Οι προτεινόμενες μέθοδοι βασίζονται στην μέτρηση χαρακτηριστικών του ανθρώπινου σώματος και την χρήση αυτών για αυθεντικοποίηση. Λόγω της φύσης του ανθρώπινου σώματος πολλά φυσικά χαρακτηριστικά χαρακτηρίζουν μοναδικά τους ανθρώπους. Επίσης υπάρχουν βιομετρικά χαρακτηριστικά που προκύπτουν από την συμπεριφορά του ανθρώπου και θεωρούνται και αυτά μοναδικά.

Έτσι τα βιομετρικά χαρακτηριστικά δίνουν την δυνατότητα σε ένα άτομο να αναγνωριστεί με βάση ενός συνόλου χαρακτηριστικών που συλλέγονται από αυτόν και είναι μοναδικά για κάθε άτομο.

Υπάρχουν δύο διαφορετικές προσεγγίσεις:

- **Βιομετρική αυθεντικοποίηση:** Είναι η διαδικασία σύγκρισης δεδομένων των χα-

ρακτηριστικών ενός ατόμου ενάντια στα σε ένα template αυτού του ατόμου που βρίσκεται σε μια βάση δεδομένων ώστε να καθορισθεί η ομοιότητα μεταξύ των δύο συνόλων. Το template αυτό βρίσκεται απόθηκευμένο σε μια ασφαλή βάση δεδομένων ή σε κάποια φορητή συσκευή όπως οι smart cards και δημιουργείται όταν το άτομο κάνει enroll στο σύστημα. Η αυθεντικοποίηση απαντά στο ερώτημα αν το άτομο που ισχυρίζεται ότι είναι το άτομο "X", είναι όντως αυτός που ισχυρίζεται ότι είναι είτε όχι.

- **Βιομετρική αναγνώριση:** Είναι η διαδικασία κατά την οποία αναγνωρίζεται ένα άτομο. Το σύστημα λαμβάνει ένα δείγμα βιομετρικών χαρακτηριστικών από το άτομο και το συγκρίνει με όλα τα καταγεγραμμένα template προσπαθώντας να βρει το καλύτερο ταίριασμα και να απαντήσει στην ερώτηση "Ποιο άτομο είναι αυτό?".

Στο Σχήμα 2.1 φαίνονται τα στάδια που απαιτούνται για την αναγνώριση ενός ατόμου. Στο στάδιο της εγγραφής διακρίνονται τα εξής βασικά στάδια:

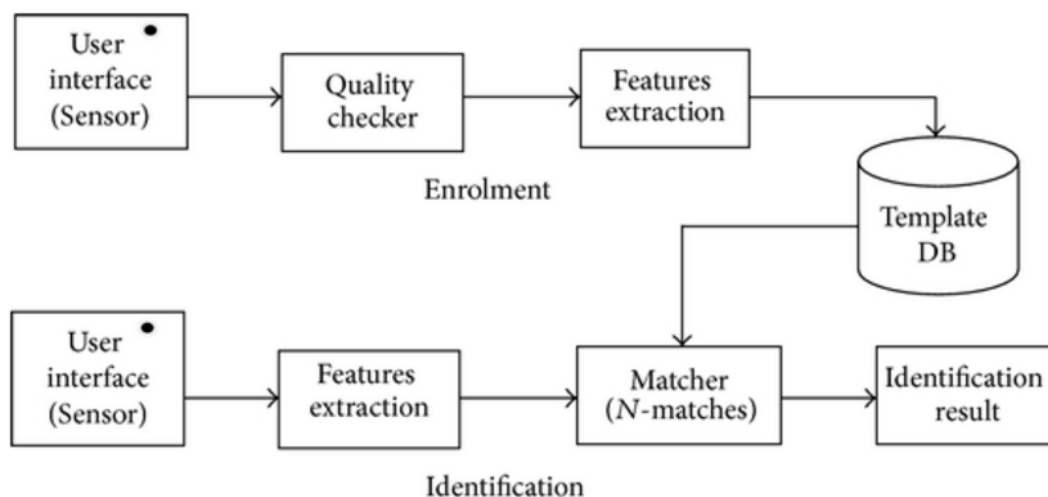
- Ο χρήστης εισάγει τα βιομετρικά χαρακτηριστικά στον αισθητήρα του συστήματος.
- Ένας ελεγκτής ελέγχει αν τα δεδομένα τηρούν τα προβλεπόμενα κριτήρια αλλιώς ο χρήστης θα χρειαστεί να τα ξανά εισάγει.
- Επόμενο στάδιο είναι η εξαγωγή των βιομετρικών χαρακτηριστικών. Ανάλογα με το βιομετρικό χαρακτηριστικό που χρησιμοποιεί το σύστημα και την τεχνική που χρησιμοποιείται ποικίλουν και τα χαρακτηριστικά που εξάγονται σε αυτό το στάδιο.

Αφού ο χρήστης κάνει εγγραφή μια φορά το σύστημα, μπορεί στην συνέχεια να κάνει χρήση της δυνατότητας αυθεντικοποίησης. Όταν ο χρήστης εισάγει τα βιομετρικά του χαρακτηριστικά για αναγνώριση ακολουθείται η εξής διαδικασία:

- Ο χρήστης εισάγει τα βιομετρικά χαρακτηριστικά στον αισθητήρα του συστήματος
- Γίνεται εξαγωγή των χαρακτηριστικών από τα δεδομένα που εισήγαγε ο χρήστης
- Στην συνέχεια γίνεται ταίριασμα των χαρακτηριστικών αυτών με των χαρακτηριστικών που βρίσκονται στα template της βάσης από τις εγγραφές των χρηστών
- Επιλέγεται για αναγνώριση το ταίριασμα με τη μεγαλύτερη ομοιότητα με τα στοιχεία που εισήγαγε ο χρήστης

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος

Όμοια και στην διαδικασία της αυθεντικοποίησης το μόνο που αλλάζει είναι τα δύο τελευταία στάδια καθώς τα χαρακτηριστικά του χρήστη συγκρίνονται μόνο με τα χαρακτηριστικά του template στην βάση και απαντάται αν είναι ή όχι αυτός που ισχυρίζεται.



Σχήμα 2.1: Σχηματική αναπαράσταση της αναγνώρισης(identification) ενός ατόμου

### 2.3 Κριτήρια επιλογής βιομετρικών χαρακτηριστικών

Υπάρχει πληθώρα βιομετρικών χαρακτηριστικών που χρησιμοποιούνται ευρέως πια. Η επιλογή αυτού εξαρτάται από το είδος της εφαρμογής, το επίπεδο ασφαλείας, το κόστος και την επίδοση του συστήματος. Έτσι ορίζονται οι εξής 7 παράγοντες που πρέπει να ληφθούν υπόψη στην κατασκευή ενός συστήματος βιομετρικής αυθεντικοποίησης:

- **Καθολικότητα (Universality):** Οποιοσδήποτε άνθρωπος επιδιώκει να κάνει αυθεντικοποίηση πρέπει να κατέχει αυτό το βιομετρικό χαρακτηριστικό. Αυτός ο παράγοντας μετράται με τον όρο FTE (failure to enroll).
- **Μοναδικότητα (Uniqueness):** Το χαρακτηριστικό που θα επιλεγεί πρέπει να είναι αρκετά μοναδικό ανάμεσα στους ανθρώπους, έτσι ώστε το False Positive Rate να είναι σε απόδεκτά επίπεδα.
- **Μονιμότητα (Permanence):** Το βιομετρικό χαρακτηριστικό που θα επιλεγεί πρέπει να είναι αδιάλλακτο στην πορεία του χρόνου, δηλαδή να μην αλλάζει υπερβολικά

κατά την γήρανση του ατόμου με τα αποτελέσματα να μην μπορεί να γίνει απόδεκτό από τον αλγόριθμο.

- **Μετρησιμότητα (Measurability):** Το χαρακτηριστικό που θα επιλεγεί πρέπει να είναι δυνατό να ληφθεί και να ψηφιοποιηθεί από ένα άτομο χωρίς να προκαλεί δυσφορία/ενόχληση. Επίσης τα δεδομένα που θα ληφθούν πρέπει να είναι εφικτό να υποστούν την απαραίτητη επεξεργασία.
- **Επίδοση (Performance):** Το βιομετρικό χαρακτηριστικό που θα επιλέξουμε πρέπει να πληρεί 2 δείκτες σε απόδεκτό επίπεδο. Ο πρώτος είναι η ακρίβεια αναγνώρισης, όπου μετριέται το ποσοστό με το οποίο αναγνωρίζει σωστά τα άτομα. Ο δεύτερος είναι η ταχύτητα δηλαδή πόσες αυθεντικοποιήσεις μπορεί να διεξάγει σε ένα δεδομένο χρονικό διάστημα.
- **απόδεκτό (Acceptability):** Τα άτομα που θα χρησιμοποιούν την εφαρμογή πρέπει να είναι πρόθυμα να παρουσιάσουν και να δώσουν το χαρακτηριστικό τους στο σύστημα.
- **Παραβίαση (Circumvention):** Αυτή η έννοια αφορά την ευκολία με την οποία μπορεί ένα χαρακτηριστικό να κλαπεί ή να αναπαρασταθεί από κάποιον τρίτο (π. χ κλοπή δακτυλικού απότυπώματος από ποτήρι ή ψεύτικα δάκτυλα). Σε αυτό τον παράγοντα ανήκει και η έννοια της συσκοτίσις όπου ένα άτομο αλλάζει κάποιο φυσικό του χαρακτηριστικό ώστε να αποφύγει την αυθεντικοποίηση (π. χ. κόψιμο ή κάψιμο των ακροδάχτυλων).

Κανένα βιομετρικό χαρακτηριστικό δεν πληρεί βέλτιστα όλες τις κατηγορίες (ακρίβεια, κόστος, πρακτικότητα κ. τ. λ). Κανένα από αυτά δεν αποτελεί ιδανικό αλλά τα περισσότερα από αυτά είναι απόδεκτά για εφαρμογές στην καθημερινή ζωή. Όπως αναφέρθηκε και παραπάνω η επιλογή του κατάλληλου βιομετρικού χαρακτηριστικού εξαρτάται από την φύση της εφαρμογής που θέλουμε να υλοποιήσουμε καθώς και τις λειτουργικές απαιτήσεις της εφαρμογής και του συστήματος.

## 2.4 Βασικά είδη βιομετρικών χαρακτηριστικών

Υπάρχουν πληθώρα βιομετρικών χαρακτηριστικών, τα οποία συνήθως πληρούν τα περισσότερα από τα κριτήρια της προηγούμενης ενότητας. Η επιλογή εξαρτάται από τον



σχεδιαστή της εφαρμογής και του λειτουργικούς σκοπούς αυτής. Υπάρχουν δύο κατηγορίες βιομετρικών χαρακτηριστικών:

- **Φυσιολογικά (Physiological):** Προέρχονται από τα φυσικά σωματικά χαρακτηριστικά του ανθρώπου
- **Συμπεριφοράς(Behavioral):** Είναι τα βιομετρικά χαρακτηριστικά που προκύπτουν από την συμπεριφορά του ανθρώπου

#### 2.4.1 Βασικά βιομετρικά χαρακτηριστικά

Στην συνέχεια παρουσιάζονται τα βασικότερα βιομετρικά χαρακτηριστικά που υλοποιούνται σε σύγχρονες εφαρμογές :

- **Δακτυλικό απότύπωμα:** Αποτελεί ένα από τα πιο διαδεδομένα βιομετρικά χαρακτηριστικά καθώς και το παλιότερο. Η χρήση αυτού γινόταν πολύ πριν την διάδοση των υπολογιστών, με την σύγκριση απότυπων τυπωμένων με μελάνι σε χαρτί. Η επιφάνεια του δακτύλου αποτελείται από “όροι” και “κοιλιάδες” και η μορφολογία του καθορίζεται κατά τους πρώτους 7 μήνες της κύησης. Η ευκολία της λήψης τους σε συνδυασμό με το χαμηλό κόστος των συσκευών λήψης είναι ο κύριος λόγος που χρησιμοποιούνται σε πολλές εφαρμογές σήμερα (ακόμα και στα κινητά). Σε εφαρμογές που απαιτείται μεγαλύτερη ασφάλεια και ακρίβεια χρησιμοποιείται το δακτυλικό απότύπωμα και από τα 10 δάκτυλα των χεριών. Τέλος υπάρχουν κατηγορίες ανθρώπων που δεν ενδείκνυται η αυθεντικοποίηση με δακτυλικό απότύπωμα, όπως άτομα με κάποιο γενετικό πρόβλημα ή άτομα που επιρρεπή σε τραυματισμούς (άτομα που κάνουν χειρωνακτική εργασία συνήθως έχουν κοψίματα, μελανιές στα χέρια).[27]
- **Αποτύπωμα της παλάμης:** Όπως τα ακροδάχτυλα έτσι και οι παλάμες του ανθρώπου περιέχουν μοναδικά χαρακτηριστικά όπως “όροι”, “κοιλιάδες”. Λόγω της μεγαλύτερης επιφάνειας η παλάμη είναι αναμενόμενο να έχει και μεγαλύτερη ακρίβεια από το δακτυλικό απότύπωμα. Αντίθετα όμως ο εξοπλισμός που απαιτείται για την λήψη αυτού του απότυπώματος είναι πιο ακριβός και πιο μεγάλος σε μέγεθος. Οι παλάμες όμως εκτός από “όροι”, “κοιλιάδες” περιέχουν και ακανόνιστες γραμμές και ρυτίδες, τα οποία μπορούν να ληφθούν και με πιο φθινό εξοπλισμό. Το ολοκληρωμένο μοντέλο του αποτυπώματος της παλάμης συνδυάζει “όροι”, “κοιλιάδες”, γραμμές του χεριού, ρυτίδες καθώς και την γεωμετρία του χεριού ώστε να έχει την μέγιστη δυνατή ακρίβεια.[10]

- **Ίριδα:** Η ίριδα είναι το μέρος του ματιού που βρίσκεται ανάμεσα στην κόρη του ματιού και το άσπρο του οφθαλμού. Η οπτική δομή της ίριδας σχηματίζεται κατά την διάρκεια της κύησης και σταθεροποιείται στα πρώτα 2 χρόνια της ζωής (το χρώμα της ίριδας παρ' όλα αυτά αλλάζει κατά την διάρκεια της ζωής του ανθρώπου και δεν επηρεάζει την δομή της). Η περίπλοκη ακτινωτή δομή της ίριδας την καθιστά ικανή για να εξαχθούν πληροφορίες μοναδικές για κάθε άτομο και ικανές για αυθεντικοποίηση. Αν και δεν αποτελεί ένα από τα διαδεδομένα χαρακτηριστικά που χρησιμοποιούνται για αυθεντικοποίηση, τα τελευταία χρόνια η μείωση κόστους του εξοπλισμού λήψης και επεξεργασίας, καθιστά την ίριδα ένα από τα πλέον υποσχόμενα βιομετρικά χαρακτηριστικά.[5]
- **Πρόσωπο:** αποτελεί μία από τις μεθόδους όπου το άτομο δεν χρειάζεται να έρθει σε επαφή με κάποια συσκευή λήψης και αποτελεί ένα από τα πιο φυσικά χαρακτηριστικά για τον άνθρωπο καθώς είναι το βασικό στοιχείο που χρησιμοποιεί ο εγκέφαλος για την αναγνώριση άλλων ατόμων. Σε αυτή την περίπτωση γίνεται σύγκριση κάποιων βασικών χαρακτηριστικών του προσώπου, όπως αποστάσεις ματιών-μύτης-ζηγωματικών. Υπάρχει πληθώρα εφαρμογών που εφαρμόζουν την αναγνώριση προσώπου. Από αναγνώριση σταθερής εικόνας σε λευκό φόντο μέχρι αναγνώριση προσώπων μέσα σε κινούμενο πλήθος σε βίντεο. Στην αναγνώριση προσώπου εμφανίζονται κάποια από τα βασικά προβλήματα επεξεργασίας εικόνας, όπως το πρόβλημα του φωτισμού όπου το σύστημα δεν μπορεί να αναγνωρίσει 2 ίδιες εικόνες που έχουν ληφθεί με διαφορετικό φωτισμό, καθώς και το πρόβλημα όπου το σύστημα αδυνατεί να αναγνωρίσει 2 εικόνες του ίδιου ατόμου που έχουν ληφθεί από διαφορετική οπτική γωνία.[35]
- **Σχήμα παλάμης:** Αυτό το είδος βιομετρικού χαρακτηριστικού αφορά μόνο τα γεωμετρικά χαρακτηριστικά της παλάμης όπως το μέγεθός της, το σχήμα, το μήκος και το πλάτος των δακτύλων. Ανωμαλίες που μπορεί να εμφανίζει το δέρμα της παλάμης όπως γρατσουниές, ουλές, ξηρότητα του δέρματος δεν επηρεάζουν την ακρίβεια των συστημάτων αυτών. Όμως τα γεωμετρικά χαρακτηριστικά δεν είναι τόσο μοναδικά ώστε να γίνει χρήση αυτών σε εφαρμογές που απαιτούν αναγνώριση του ατόμου ανάμεσα σε άλλα, αντίθετα με τα προβλήματα αυθεντικοποίησης που απαιτούν απλά αν το άτομο είναι ή δεν είναι αυτό στο οποίο ανήκει το απόθηκευμένο template που υπάρχει στη βάση. Επίσης η γεωμετρία του χεριού αλλάζει ανάλογα με την ηλικία του ανθρώπου, έτσι παραβιάζεται το κριτήριο της μονιμότητας. Ακόμα οι συσκευές λήψης του σχήματος της παλάμης είναι αρκετά μεγάλες σε μέγεθος και

δεν μπορούν να ενσωματωθούν σε Laptop και κινητά.[17]

- **Βάδισμα:** Ένα από τα πιο παράξενα βιομετρικά χαρακτηριστικά αποτελεί ο τρόπος που βαδίζει κάποιος. Ανήκει στην ίδια κατηγορία με την αναγνώριση προσώπου όπου μπορούμε να αναγνωρίσουμε ένα άτομο από απόσταση. Χρησιμοποιείται κυρίως σε εφαρμογές παρακολούθησης από κάμερες ασφαλείας. Βασική τεχνική αποτελεί η αναγνώριση του σχήματος του ανθρώπινου σώματος σε μία εικόνα και η εξαγωγή συγκεκριμένων μετρικών χαρακτηριστικών σε διαφορετικές χρονικές στιγμές (θέση και τροχιά αγκώνων, γονάτων, κεφαλιού, μήκος διασκελισμού). Βέβαια αποτελεί μία δύσκολη διαδικασία καθώς ο βηματισμός επηρεάζεται από πολλούς παράγοντες όπως είδος παπουτσιού, ρουχισμός, επιφάνεια βηματισμού. [3]
- **Αυτί:** Ένα ακόμα από τα λιγότερο δημοφιλή βιομετρικά χαρακτηριστικά είναι το αυτί. Συγκεκριμένα ο χονδροειδής ιστός του λοβού του αυτιού έχει ξεχωριστή κατασκευή ανάμεσα στα διαφορετικά άτομα. Υπάρχουν δύο τεχνικές επεξεργασίας του σχήματος του αυτιού. Είτε εξαγωγή απόστάσεων από συγκεκριμένα σημεία του λοβού και σύγκριση αυτών, είτε σύγκριση αυτούσιας της εικόνας του σχήματος του λοβού. Η αναγνώριση ενός ατόμου από το σχήμα του αυτιού εμφανίζει χρησιμότητα σε περιπτώσεις που έχουμε φωτογραφία προφίλ ενός ατόμου και δεν μπορούμε να κάνουμε αναγνώριση του προσώπου αυτού.[8]
- **Φωνή:** Η φωνή αποτελεί ένα ξεχωριστό φυσικό χαρακτηριστικό που χρησιμοποιούν και οι άνθρωποι για να αναγνωρίζουν ο ένας τον άλλο. Εξαρτάται από συνδυασμό αρκετών φυσικών χαρακτηριστικών όπως τη μορφή των φωνητικών χορδών, το σχήμα της φωνητικής οδού και του οισοφάγου, την ρινική κοιλότητα και το σχήμα των χειλιών και του στόματος. Πέραν των προαναφερθέντων φυσικών χαρακτηριστικών η φωνή εξαρτάται και από παράγοντες όπως η υγεία (το συνάχι αλλάζει τον τόνο της φωνής), την ψυχική κατάσταση και την ηλικία. Επίσης η φωνή δεν έχει τόσο μοναδικά χαρακτηριστικά ανάμεσα στους ανθρώπους και δεν μπορεί να χρησιμοποιηθεί σε εφαρμογές που απαιτούν αναγνώριση ατόμων ανάμεσα σε άλλα. Η κύρια χρήση τέτοιων συστημάτων είναι αναγνώριση μέσω τηλεφώνου, αν και δεν είναι και τόσο αξιόπιστη καθώς η υπάρχει αρκετός θόρυβος από το κανάλι που μεταφέρεται η φωνή.[23]
- **Τρόπος γραφής:** Ο τρόπος γραφής σε κάθε άτομο φέρει ένα βαθμό κατά τον οποίο είναι ξεχωριστός. Αυτό το βιομετρικό χαρακτηριστικό δεν είναι μοναδικό και δεν μπορεί να αποτέλεσει μέτρο για την αυθεντικοποίηση ενός ατόμου. Μπορεί όμως με την

συνεχή παρακολούθηση του τρόπου γραφής ενός χρήστη να διαβεβαιωθεί το σύστημα ότι ο χρήστης που πληκτρολογεί είναι όντως ο σωστός, με βάση τα μοτίβα τα οποία πληκτρολογεί (ταχύτητα-ρυθμός γραφής, συνδιασμοί πλήκτρων). Όμως ακόμα και σε ένα άτομο ο τρόπος με τον οποίο γράφει διαφέρει ανάλογα με την στάση του σώματος, είδος πληκτρολογίου και συναισθηματική κατάσταση.

- **Υπογραφή:** Ο τρόπος με τον οποίο υπογράφει κάποιος θεωρείται χαρακτηριστικός για κάθε άτομο. Είναι ένα από τα παλαιότερα βιομετρικά χαρακτηριστικά. Επίσης είναι από τις πιο διαδεδομένες μορφές αυθεντικοποίησης καθώς είναι απόδεκτές σε κυβερνητικά, νομικά και εμπορικά έγγραφα. Ωστόσο δεν αποτελεί μοναδικό χαρακτηριστικό ούτε και για το ίδιο το άτομο καθώς ακόμα και δύο συνεχόμενες υπογραφές του ίδιου ατόμου θα διαφέρουν αρκετά μεταξύ τους. Ακόμα η υπογραφή είναι ένα από τα βιομετρικά χαρακτηριστικά που είναι πάρα πολύ εύκολο να πλαστογραφηθεί. Επαγγελματίες μπορούν να πλαστογραφήσουν υπογραφές εάν έρθουν σε οπτική επαφή με αυτές για λίγα δευτερόλεπτα.[1]
- **DNA:** Το γνωστό σε όλους δεσοξυριβονουκλεϊκό οξύ που περιέχει τις γενετικές πληροφορίες απαραίτητες για την ζωή ενός οργανισμού. Ο γενετικός κώδικας είναι μοναδικός για κάθε άνθρωπο εκτός από τους ομοζυγωτικούς διδύμους. Χρησιμοποιείται ευρέως στην εγκληματολογία για την ταυτοποίηση θύματος και δράστη. Η ταυτοποίηση μέσω του DNA έχει 3 βασικά μειονεκτήματα.
  - Είναι αρκετά εύκολο να κλαπεί ένα δείγμα DNA από ένα ανυποψίαστο θύμα και να χρησιμοποιηθεί για άνομους σκοπούς.
  - Δεν έχει άμεση αναγνώριση/αυθεντικοποίηση όπως τα άλλα βιομετρικά καθώς χρειάζεται χημική επεξεργασία από ειδικούς.
  - Η επεξεργασία του DNA φέρει κινδύνους της προστασίας των προσωπικών δεδομένων, καθώς πολλές ασθένιες μπορούν να ανιχνευθούν από την εξέταση της αλληλουχίας του DNA, και αυτά τα δεδομένα θα μπορούσαν να χρησιμοποιηθούν εναντίον του ατόμου αυτού (κοινωνικός εξοστρακισμός, εύρεση εργασίας).
- **Θερμική εικόνα προσώπου, χεριού και αγγείων χεριού:** Η θερμότητα που εκπέμπει το ανθρώπινο σώμα παράγει μια χαρακτηριστική εικόνα για κάθε άτομο. Αυτή η εικόνα μπορεί να ληφθεί μέσω υπέρυθρων καμερών χωρίς το άτομο να έρθει σε επαφή με την συσκευή λήψης (όπως η λήψη μίας απλής φωτογραφίας). Αντίθετα

όμως με την απλή φωτογραφία, με την υπέρυθρη μπορούμε να αναγνωρίσουμε άτομα που είναι μεταμφιεσμένα. Η σωστή λήψη της θερμικής εικόνας είναι ένα δύσκολο έργο καθώς είναι ιδιαίτερα ευαίσθητη στις συνθήκες του δωματίου (παρουσία θέρμανσης) και ακόμα πιο δύσκολο σε εξωτερικούς χώρους που οι πηγές θερμότητας είναι ακόμα περισσότερες (αυτοκίνητα, σωλήνες). Επίσης η χρήση αισθητήρων κοντινών υπέρυθρων (NIR) χρησιμοποιείται για την ανίχνευση των αγγείων της παλάμης. Όμως το υψηλό κόστος των αισθητήρων αυτών τα καθιστά μη διαδεδομένες αυτές τις τεχνικές αυθεντικοποίησης.[34]

- **Οσμή:** Κάθε αντικείμενο εκπέμπει μοναδική μυρωδιά ανάλογα με την χημική του σύσταση. Έτσι μπορεί να χρησιμοποιηθεί για την αναγνώριση του. Αέρας που περιβάλλει το αντικείμενο εισάγεται σε μία συστοιχία χημικών αισθητήρων. Καθένας αισθητήρας αντιστοιχεί σε μία ομάδα αρωματικών χημικών ενώσεων. Κάθε άτομο εκπέμπει μία ξεχωριστή οσμή, αλλά η ταυτοποίηση των ατόμων είναι δύσκολη καθώς επεμβαίνουν πρόσθετες μυρωδιές όπως απόσμητικά, κολόνιες καθώς και εξωτερικές μυρωδιές από το περιβάλλον.[26]
- **Σάρωση αμφιβληστροειδούς:** Τα αγγεία του αμφιβληστροειδούς έχουν πλούσια και σύνθετη δομή, ξεχωριστή για κάθε άνθρωπο ακόμα και για κάθε μάτι. Θεωρείται ένα από τα πιο ασφαλή βιομετρικά χαρακτηριστικά καθώς είναι δύσκολο να κλαπεί ή να πλαστογραφηθεί από τρίτους. Η λήψη της εικόνας των αγγείων γίνεται με το άτομο να κοιτάει μέσα σε ένα όργανο το οποίο προτρέπει το άτομο να κοιτάξει σε ένα συγκεκριμένο σημείο ώστε να έρθει σε συγκεκριμένη θέση ο αμφιβληστροειδής. Η σάρωση αμφιβληστροειδούς αν και είναι από τις πιο ασφαλείς μεθόδους, δεν είναι διαδεδομένη καθώς απαιτεί προσπάθεια από την μεριά του χρήστη, ώστε να γίνει σωστά η σάρωση των αγγείων. Επίσης μέσω της σάρωσης μπορούν να φανερωθούν ασθένειες, όπως την υπέρταση, και έτσι τίθεται θέμα της προστασίας των προσωπικών δεδομένων.[18]
- **Ηλεκτροκαρδιογράφημα:** Το σήμα που προέρχεται από την λειτουργία της φλεβοκόμβου της καρδιάς και καταγράφεται από ηλεκτρόδια στο δέρμα των ανθρώπων είναι μοναδικό για κάθε άτομο. Η μοναδικότητα του σήματος προκύπτει από την ξεχωριστή κατασκευή της καρδιάς του κάθε ανθρώπου. Τα τελευταία χρόνια είναι ένα ανερχόμενο βιομετρικό χαρακτηριστικό με μεγάλο βαθμό ασφαλείας και δυσκολία στη πλαστογράφηση και την κλοπή. [21]

Το συνηθέστερο και πιο διαδεδομένο βιομετρικό χαρακτηριστικό αποτελεί το δακτυ-

λικό απότύπωμα καθώς είναι εύκολη η συλλογή του και η επεξεργασία του. Επίσης οι συσκευές αναγνώρισης δαχτυλικού απότυπώματος είναι αρκετά χαμηλές σε κόστος, έτσι το καθιστά σήμερα ως μία από τις πιο διαδεδομένες τεχνικές αυθεντικοποίησης η οποία εφαρμόζεται σχεδόν σε όλες τις συσκευές κινητής τηλεφωνίας. Επίσης τα βιομετρικά χαρακτηριστικά που σχετίζονται με την συμπεριφορά του ατόμου όπως το περπάτημα, η φωνή και ο ρυθμός πληκτρολογεί είναι ακόμα πολλά υποσχόμενα καθώς δεν προσδίδουν την σταθερότητα των φυσιολογικών χαρακτηριστικών αλλά έχουν άλλα πλεονεκτήματα.

## **2.4.2 Το σήμα της καρδιάς**

### **2.4.2.1 Η ανατομία της καρδιάς**

Η καρδιά είναι ένα μυώδες όργανο το οποίο αντλεί το αίμα στο κυκλοφορικό σύστημα το ανθρώπου. Η κυκλοφορία του αίματος στο σώμα το τροφοδοτεί με οξυγόνο και θρεπτικά συστατικά απαραίτητα για την λειτουργία του. Όπως φαίνεται και στο Σχήμα 2.2 η καρδιά χωρίζεται σε 4 διακριτούς τομείς.


- Άνω αριστερός και άνω δεξιός κόλπος
- Κάτω αριστερή και κάτω δεξιά κοιλία

Σε μία υγιή καρδιά η ροή του αίματος είναι μονόδρομη καθώς υπάρχουν οι βαλβίδες που αποτρέπουν την οπισθοδρόμηση της ροής. Η καρδιά βρίσκεται μέσα σε ένα "σακίδιο" με υγρό το περικάρδιο το οποίο την προστατεύει. Ο ρυθμός με τον οποίο αντλεί αίμα καθορίζεται από ειδικά κύτταρα που βρίσκονται στον δεξιό κόλπο. Αυτά τα κύτταρα έχουν την δυνατότητα να παράγουν ηλεκτρικό φορτίο ταυτόχρονα, το οποίο ταξιδεύει στα τοιχώματα της καρδιάς προκαλώντας την συστολή της. Τα κύτταρα του φλεβόκομβου της καρδιάς έχουν αρνητικό φορτίο αρχικά και με την είσοδο ιόντων νατρίου το φορτίο αυτό γίνεται θετικό. Όταν το δυναμικό αυτό φτάσει σε υψηλό επίπεδο τα κανάλια αυτά κλείνουν και εισέρχονται στο κύτταρο ιόντα ασβεστίου, καθώς και βγαίνουν από το κύτταρο ιόντα καλίου. Αυτές οι μετακινήσεις δυναμικού είναι ανιχνεύσιμες και φαίνονται στο Σχήμα 2.3 ως πολώσεις και εκ πολώσεις.

### **2.4.2.2 Το σήμα της καρδιάς**

Το σήμα της καρδιάς λαμβάνεται από το ανθρώπινο σώμα με την διαδικασία του Ηλεκτροκαρδιογραφήματος (Electrocardiogram, ECG). Αποτελεί την καταγραφή της ηλε-

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος




Σχήμα 2.2: Ανατομία της καρδιάς

κτρικής δραστηριότητας της καρδιάς σε μία δεδομένη χρονική περίοδο τοποθετώντας ηλεκτρόδια στο δέρμα σε διάφορα σημεία. Τα ηλεκτρόδια αυτά καταγράφουν μικρές αλλαγές στο δυναμικό του δέρματος, οι οποίες προκύπτουν από τις αλλαγές στο δυναμικό της φλεβοκόμβου. Για την καταγραφή του σήματος αυτού τοποθετούνται στο ανθρώπινο σώμα 12 ηλεκτρόδια στο στήθος καθώς και στα άκρα του ατόμου. Το ηλεκτροκαρδιογράφημα είναι η αναπαράσταση αυτού του σήματος όπου στον άξονα X υπάρχει ο χρόνος και στον άξονα Y η τάση. Το σήμα περιέχει μεγάλη πληροφορία για την κατασκευή και τη δομή της καρδιάς καθώς και για το σύστημα των ηλεκτρικών πολώσεων Σχήμα 6.1.

#### 2.4.2.3 Το σήμα της καρδιάς ως βιομετρικό χαρακτηριστικό

Ένα από τα φυσικά βιομετρικά χαρακτηριστικά του ανθρώπου είναι και το σήμα που παράγεται από την καρδιά. Αποτελεί μία από τις τελευταίες εφαρμογές στον χώρο της βιομετρικής αυθεντικοποίησης και είναι πολλά υποσχόμενη καθώς έχει ιδιότητες που δεν έχουν τα άλλα χαρακτηριστικά, λόγω της μοναδικής κατασκευής της καρδιάς που προέρχεται σαφώς από την μοναδικότητα του DNA του κάθε ατόμου. Έτσι η μοναδική κατασκευή της κάθε καρδιάς παράγει ένα μοναδικό σήμα το οποίο επηρεάζεται από το μέγεθος της καρδιάς, το μέγεθος των κόλπων και των κοιλιών, το πλάτος των βαλβίδων, τα επίπεδα stress και την φυσική κατάσταση του ατόμου. Η δειγματοληψία είναι πιο δύσκολη σε

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος




Σχήμα 2.3: Δυναμικό στην φλεβόκομβο της καρδιάς, φαίνονται οι διαφορές δυναμικού λόγω της μεταφοράς ιόντων

σχέση με άλλα βιομετρικά σήματα αλλά το σήμα της καρδιάς προσφέρει άλλα πλεονεκτήματα. Αρχικά είναι πολύ δύσκολο να κλαπεί ή να πλαστογραφηθεί, αντίθετα με το δακτυλικό απότύπωμα που μπορεί εύκολα να παρθεί ακόμα και από ένα ποτήρι που έχει μία δαχτυλιά ή στην περίπτωση του σχήματος του προσώπου είναι δυνατόν να γίνει παραποίηση ταυτότητας ακόμα και με την τοποθέτηση μίας φωτογραφίας στο σύστημα ταυτοποίησης. Επίσης η χρήση του σήματος από την καρδιά αποτελεί απόδειξη ότι το άτομο είναι ζωντανό αντίθετα με τα υπόλοιπα χαρακτηριστικά που δεν παρέχουν τέτοια στοιχεία (proof of liveness). Η βασική ιδέα είναι να εξάγουμε από το σήμα της καρδιάς κάποια χαρακτηριστικά και να δούμε κατά πόσο αυτό το σήμα είναι μοναδικό. Τέλος το σήμα της καρδιάς πληρεί τα περισσότερα από τα 7 κριτήρια που διατυπώθηκαν παραπάνω.

- **Καθολικότητα:** Κάθε άτομο διαθέτει καρδιακό παλμό, και αντίθετα σε σχέση με τα παραπάνω χαρακτηριστικά μας αποδεικνύει ότι το άτομο είναι και ζωντανό, ενώ σχεδόν όλα τα παραπάνω βιομετρικά χαρακτηριστικά που παρουσιάστηκαν μπορούν να κλαπούν και από κάποιον που δεν είναι ζωντανός.
- **Μοναδικότητα:** Λόγω της μοναδικής κατασκευής της καρδιάς το σήμα του κάθε ατόμου έχει μοναδικά χαρακτηριστικά.
- **Μονιμότητα:** Το σήμα της καρδιάς φαίνεται να είναι ανεπηρέαστο από την ηλικία των ατόμων. Παρ' όλο που αλλάζει το μέγεθος της καρδιάς και ο ρυθμός με την κατάσταση, την ηλικία και τα επίπεδα stress του ατόμου δεν φαίνεται να επηρεάζει άμεσα τα αποτελέσματα.



Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος



Σχήμα 2.4: Ηλεκτροκαρδιογράφημα που προκύπτει από το ηλεκτρόδιο V7

- **Μετρησιμότητα:** Η μετρησιμότητα αποτελεί το μόνο παράγοντα που το σήμα της καρδιάς υστερεί σε σχέση με τα άλλα. Καθώς για την λήψη ενός καθαρού σήματος απαιτείται ακριβός εξοπλισμός καθώς και εκπαιδευμένο προσωπικό να τοποθετήσει τα ηλεκτρόδια. Επίσης μπορεί να χρησιμοποιηθεί σήμα που λαμβάνεται από το βραχίονα του ατόμου με αισθητήρα τύπου βραχιολάκι, αλλά το σήμα που προκύπτει είναι αρκετά πιο θορυβώδες. Σε μία τέτοια περίπτωση βέβαια δεν είναι άβολη η όλη διαδικασία για το άτομο.
- **Επίδοση:** Όπως θα δειχθεί και παρακάτω το σήμα της καρδιάς παράγει εξίσου ικανοποιητικές επιδόσεις με το δακτυλικό απότύπωμα, και απαιτεί πόρους από το σύστημα μόνο κατά το στάδιο της εκπαίδευσης του μοντέλου, καθώς κατά την πιστοποίηση επιτελείται μόνο μια απλή σύγκριση.
- **Αποδεκτό:** Ακόμα μία κατηγορία που το σήμα της καρδιάς υστερεί, καθώς όπως η σάρωση αμφιβληστροειδούς και το DNA, έτσι και η καρδιά μπορεί να φανερώσει ασθένειες που πιθανώς να έχει το άτομο. Έτσι τίθεται κίνδυνος για τα προσωπικά δεδομένα του ατόμου.

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος

- **Παραβίαση:** Είναι σχεδόν αδύνατο να κλαπεί καθώς θα πρέπει να ληφθεί με παλμογράφο σήμα από το άτομο αυτό. Εξίσου δύσκολο είναι κάποιος να πλαστογραφήσει το σήμα της καρδιάς κάποιου άλλου επειδή το καρδιακό σήμα είναι αρκετά περίπλοκο σήμα και μοναδικό για κάθε άτομο αποτελεί απίθανο ενδεχόμενο να αναπαραχθεί από κάποιον τρίτο.

### 3. ΒΙΒΛΙΟΓΡΑΦΙΚΗ ΕΡΕΥΝΑ

Στην εργασία του Biel [2] γίνεται εξαγωγή σημάτων με καρδιογράφο 12 καναλιών, από τους οποίους 6 είναι στο στήθος και 6 στα άκρα του ατόμου. Και σύμφωνα με αυτά υπολογίζεται ο πίνακας αυτοσυσχέτισης μεταξύ των ηλεκτροδίων, από το οποίο προκύπτει ότι υπάρχει άμεση σύνδεση μεταξύ των ηλεκτροδίων και των εξαγόμενων χαρακτηριστικών που προκύπτουν από το καρδιογράφημα. Επιλέγεται η χρήση του ηλεκτροδίου του χεριού λόγω της ευκολίας εφαρμογής του καθώς και της μείωσης των χαρακτηριστικών κατά 180 σε σχέση με τα υπόλοιπα. Η μέθοδος που χρησιμοποιήθηκε για την ταξινόμηση των ατόμων είναι η Soft Independent Modeling of Class Analogy (SIMCA), όπου αρχικά 85 μετρήσεις χρησιμοποιούνται για την κατασκευή 20 κλάσεων και στην συνέχεια σκοπός του μοντέλου είναι να βρεθούν ομοιότητες μεταξύ δεδομένων και κλάσεων σε αντίθεση με συνηθισμένα μοντέλα που ψάχνουν συγκεκριμένες συμπεριφορές.

Τα σήματα στην εργασία του Boumbaron [4] λαμβάνονται από το κανάλι RA-LA (Δεξί ή αριστερό χέρι) με συχνότητα δειγματοληψίας 128Hz. Και στην συνέχεια φιλτράρονται με υπερηγερατό φίλτρο στα 0.5Hz ώστε να εξαλειφθεί πιθανή ύπαρξη θορύβου. Για την ανίχνευση των καρδιακών κύκλων χρησιμοποιείται ένα Hidden Markov Model πρώτης τάξης. Η εξαγωγή των χαρακτηριστικών γίνεται με PCA ώστε να μειωθούν οι διαστάσεις σε ένα σύνολο λίγων συντεταγμένων και στην συνέχεια στο σύνολο των συντελεστών που προκύπτουν από το PCA εφαρμόζεται ο αλγόριθμος LDA ώστε να μειώσουμε περαιτέρω την διάσταση του χώρου. Τέλος γίνεται ταξινόμηση αυτών των συντελεστών με την χρήση ενός RBF Neural Network. Η ταξινόμηση γίνεται σε 9 άτομα που το καθένα έχει 20 καρδιακούς κύκλους. Τα αποτελέσματα που προκύπτουν είναι στο διάστημα 62-94%

Ο Gahi [12] εφαρμόζει την εξής διαδικασία. Στα δεδομένα που έχουν ληφθεί εφαρμόζεται χαμηλοπερατό φίλτρο 4ης τάξης Bessel με συχνότητα απόκοπής τα 30Hz ώστε να εξαλειφθεί πιθανώς θόρυβος που υπάρχει στο σήμα. Και στην συνέχεια εξαγονται από το σήμα 24 βασικά χαρακτηριστικά P, PQ, QRS, QT, T και RR χρονικές διάρκειες καθώς και τα πλάτη P, R και T και στην συνέχεια επιλέγονται ένα κατώφλι και απόβρονται τα σήματα που δεν είναι ικανά για εκπαίδευση. Στην ταυτοποίηση επιλέγεται η απόσταση Mahalanobis και συγκρίνεται το λαμβανόμενο σήμα με αυτό που είναι απόθηκευμένο στην βάση. Το δείγμα που θα έχει την μικρότερη απόσταση με αυτά που είναι απόθηκευμένα στην βάση είναι αυτό που ανήκει στο άτομο. Στην βάση απόθηκεύονται οι πίνακες απόστασεων καθώς και ο πίνακας συνδιακύμανσης που υπολογίζονται όταν εγγράφεται το άτομο στο σύστημα.

Ο Wang [33] εφαρμόζει την εξής διαδικασία στα σήματα. Αρχικά τα σήματα φιλτράρονται για να εξαλειφθεί θόρυβος που προκαλείται από το baseline wander καθώς και θόρυβος που ευθύνεται στις γραμμές τροφοδοσίας του ρεύματος. Έτσι εφαρμόζετε στο σήμα φίλτρο Butterworth, ζωνοπερατό στην ζώνη 1-40 Hz καθώς και κατώφλι για να απορριφθούν οι παλμοί που δεν είναι ικανοί για ταξινόμηση. από τους καρδιακούς παλμούς εξάγονται τα βασικά χαρακτηριστικά: κορυφές R και τα σημεία με εντοπισμό τοπικών ελαχίστων Q, S, P, T καθώς και το L', P', S', T', X και Z. Στα δεδομένα αυτά εφαρμόζονται οι αλγόριθμοι PCA και LDA ώστε να μειωθεί η διάσταση των δεδομένων. Το ECG είναι μη-περιοδικό σήμα, αλλά εμφανίζει υψηλή επανάληψη έτσι δοκιμάστηκε και τεχνική εξαγωγής μη-βασικών χαρακτηριστικών όπου εφαρμόζεται αυτοσυσχέτιση για να βρεθούν ομοιότητες σε σημεία και στην συνέχεια διακριτός μετασχηματισμός συνημιτόνων στους συντελεστές της αυτοσυσχέτισης ώστε να μειωθεί η διάσταση το χώρου. Τα αποτελέσματα είναι 92.48% για την τράπεζα PTB και 94.88% για την MIT για το PCA/LDA και 98.90%, 99.43% για το AC/DCT αντίστοιχα.

Στην εργασία του Vuksanovic [31] ακολουθείται η εξής διαδικασία. Αρχικά τα σήματα δειγματοληπτούνται με την χαμηλότερη συχνότητα ώστε να έχουν όλα την ίδια συχνότητα δειγματοληψίας, αυτή η συχνότητα είναι στην συγκεκριμένη περίπτωση τα 1000Hz. Στην συνέχεια φιλτράρονται με ένα φίλτρο Butterworth 6ης τάξης. Η έξοδος από αυτό το φίλτρο εισέρχεται σε ένα φίλτρο για την εξουδετέρωση του θορύβου από τις γραμμές τροφοδοσίας. Τέλος τα σήματα φιλτράρονται με ένα χαμηλοπερατό φίλτρο Butterworth 10ης τάξης για να κόψει τον θόρυβο υψηλών συχνοτήτων. Η βασική τεχνική που ακολουθείται στην συνέχεια είναι ο κατάτμηση σε παράθυρα του καρδιακού παλμού όπου κάθε παράθυρο περιέχει ένα καρδιακό παλμό. Αμέσως μετά το φιλτράρισμα παίρνουμε τον μέσο όρο από 5 παλμούς για να εξαλειφθούν τυχόν ανωμαλίες στους παλμούς, καθώς και εφαρμόζεται κατώφλι για να εξαλειφθούν παλμοί που δεν είναι ικανοί για περαιτέρω επεξεργασία. Η ανίχνευση των περιοχών QRS γίνεται με την εφαρμογή του Short time Fourier transform αμέσως μετά το φιλτράρισμα τα οποία βρίσκονται στην περιοχή 10-25 Hz, η ανίχνευση των περιοχών QRS έχει καθοριστικό ρόλο στην διαδικασία καθώς με την εύρεση των σημείων αυτών γίνεται εκτίμηση και εξαγωγή όλου του παλμού. από τους παλμούς εξάγονται χαρακτηριστικά πλάτους, μήκους και διάρκειας μεταξύ των σημείων. Η ταξινόμηση αυτών των χαρακτηριστικών έγινε με τον αλγόριθμο KNN του Matlab. Τα χαρακτηριστικά μήκους δίνουν 55. 56% με 33% το ποσοστό negative test, οι παράγοντες πλάτους 98. 89% με 86% negative test score και όλα τα χαρακτηριστικά μαζί δίνουν 100% με 17% negative test score. Το πείραμα έγινε σε 13 ασθενείς και σε κάποια πειράματα χρησιμοποιήθηκε

υποσύνολο αυτών.

Στην εργασία του Israel [15] εφαρμόζεται η εξής διαδικασία. Σε αυτή την διαδικασία δείγματα από άντρες και γυναίκες ηλικίας 22 με 48 χρόνων τα οποία έχουν ληφθεί από 41 δειγματοληψίες με 12 επαναλήψεις την φορά. Σε κάθε δειγματοληψία δόθηκαν στα άτομα διαφορετικές εργασίες ώστε να αναπαραχθούν επίπεδα stress σε διαφορετικές καθημερινές εργασίες. Αρχικά παρατηρήθηκε ότι οπτικά οι διαφορές μεταξύ ατόμων είναι μεγαλύτερες από ότι οι διαφορές μεταξύ των δοθέντων διεργασιών. Στην συνέχεια με την ανάλυση του πεδίου συχνοτήτων προκύπτουν 2 συχνότητες οι οποίες πρέπει να αφαιρεθούν, τα 60 Hz όπου είναι η συχνότητα της γραμμής ρεύματος και στα 0.06Hz όπου είναι το baseline δυναμικό. Έτσι εφαρμόζεται ζωνοπερατό φίλτρο στην ζώνη των 2Hz έως 40Hz. Η εξαγωγή των βασικών χαρακτηριστικών έγινε από τα P, R και T συμπλέγματα καθώς και απόστάσεις μεταξύ αυτών. από τα 15 χαρακτηριστικά που εξήχθησαν 12 επιλέχθηκαν για ταξινόμηση σύμφωνα με τις εκφράσεις Λάμδα του Wilkes ως μέτρο σύγκλισης. Η ταξινόμηση αυτών έγινε με γραμμική διακριτή ανάλυση και χρήση του κανόνα της "ψήφου πλειοψηφίας" όπου οι στήλες είναι τα δεδομένα εισόδου και γραμμές τα αποτελέσματα από διάφορους αλγορίθμους ταξινόμησης. Οι συναισθηματικές αλλαγές και το stress προκαλούν αλλαγές στην κυματομορφή της καρδιάς, συνεπώς στην συνέχεια δοκιμάζεται κατά πόσο οι καρδιακοί παλμοί είναι ανεξάρτητοι σε κάθε άτομο.

Έτσι εκπαιδεύονται οι 4 πίνακες διακριτής ανάλυσης:

- Εκπαίδευση με low-stress για αναγνώριση low-stress ατόμων
- Εκπαίδευση με high-stress για αναγνώριση low-stress ατόμων
- Εκπαίδευση με low-stress για αναγνώριση high-stress ατόμων
- Εκπαίδευση με high-stress για αναγνώριση high-stress ατόμων

Τα αποτελέσματα που προέκυψαν ταξινόμησαν το 97% των ατόμων σωστά και στις 4 περιπτώσεις αποδεικνύοντας ότι η αναγνώριση του ατόμου μέσω του καρδιακού του παλμού είναι ανεξάρτητη των επιπέδων stress και των εργασιών που επιτελεί την στιγμή της λήψης.

Στην εργασία του Saechia [29] η καρδιά αντιμετωπίζεται ως ένα μοναδικό σύστημα για κάθε άνθρωπο και το σήμα αυτής αποτελεί την κρουστική απόκριση αυτού του συστήματος. Έτσι οι χαρακτηριστικοί συντελεστές του σήματος αυτού λαμβάνονται παίρνοντας τον μετασχηματισμό Fourier του σήματος αυτού. Επίσης επειδή οι δειγματοληψίες είναι

από διαφορετικά άτομα σε διαφορετικές χρονικές στιγμές τα σήματα κανονικοποιούνται όλα, ώστε να έχουν τον ίδιο καρδιακό ρυθμό. Στη διαδικασία της επεξεργασίας εκτός από τη περίοδο PQRSΤ εξετάζονται μεμονωμένα τα P, QRS και T κομμάτια του σήματος. Για την αυθεντικοποίηση γίνεται χρήση νευρωνικών δικτύων και διαπιστώνεται ότι η χρήση των μεμονωμένων κομματιών του σήματος είναι πιο απόδοτική από την χρήση ολόκληρης της περιόδου.

Ο Plataniotis [25] στην εργασία αυτή με γνώμονα ότι τα fiducial features δεν επαρκούν για την επεξεργασία του καρδιογραφήματος καθώς δεν είναι πάντα εύκολο να εντοπιστούν οι καρδιακοί παλμοί. Έτσι εξάγονται οι συντελεστές του καρδιογραφήματος από κομμάτια του καρδιογραφήματος που αρχικά υπολογίζεται η αυτοσυσχέτησή τους και στην συνέχεια υπολογίζετε ο διακριτός μετασχηματισμός συνημιτόνων(DCT) αυτής. Το ποσοστό σωστής αναγνώρισης είναι 100% καθώς και τα επίπεδα false positive είναι αρκετά χαμηλά για άτομα βρίσκονται στην βάση που χρησιμοποιήθηκε.

Στην εργασία του Fatemian [11] γίνεται χρήση σήματος που λαμβάνεται από ένα ηλεκτρόδιο(1-κανάλι). Αρχικά γίνεται προεπεξεργασία του σήματος ώστε να εξαλειφθεί θόρυβος και πιθανόν λάθη δειγματοληψίας. Στην συνέχεια εφαρμόζεται στα σήματα ο μετασχηματισμός Wavelet καθώς και η δημιουργία ενός προτύπου για κάθε ασθενή ώστε να αποθηκεύεται στην βάση μόνο ένας παλμός για κάθε ασθενή, μειώνοντας έτσι τον απαιτούμενο χώρο. Με την χρήση 2 παλμών για κάθε ασθενή επιτευχθεί ποσοστό ορθής αυθεντικοποίησης 99. 61%.

Στην εργασία του Chan [9] χρησιμοποιήθηκαν δειγματοληψίες από 50 άτομα από 3 διαφορές καταγραφές. Η λήψη των σημάτων έγινε με 2 ηλεκτρόδια στις παλάμες των ατόμων. Τα σήματα από την πρώτη καταγραφή χρησιμοποιήθηκαν ως πρότυπα για το κάθε άτομο σε μια βάση δεδομένων και τα υπόλοιπα σήματα για τεστ. Ως μέτρα συγκρίσεις μεταξύ των ατόμων χρησιμοποιούνται οι 3 μέθοδοι:ποσοστιαία διαφορά καταλοίπων, συντελεστές συσχέτισης και την απόσταση μεταξύ των συντελεστών του μετασχηματισμού Wavelet. Από τις τρεις παραπάνω μεθόδους η τελευταία δίνει τα καλύτερα αποτελέσματα, ξεπερνώντας τις άλλες δύο κατά 10%.

Στη εργασία του Li [19] αρχικά γίνεται μια προεπεξεργασία στα σήματα και εξάγονται οι καρδιακοί παλμοί από τα σήματα καθώς και το φιλτράρισμα αυτών για την εξάλειψη του θορύβου. Στην συνέχεια ο κάθε παλμός μοντελοποιείται με ένα Ερμιτιανό πολυώνυμο και ένα support vector machine(SVM). Επίσης στο ομομορφικό πεδίο μοντελοποιούνται με το Gaussian mixture modeling(GMM). Το GMM σε συνδυασμό με την ετεροσκεδαστική

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος

γραμμική ανάλυση χρησιμοποιείται για την μείωση της διάστασης του σήματος και διακριτής μοντελοποίησης αυτών. Τέλος ο συνδυασμός των score από τα δύο αυτά πεδία λαμβάνεται ώστε να αυξηθεί η απόδοση. Ο συνδυασμός και των δύο αυτών δίνει 98.3%.

Στην εργασία του Biel [2] ερευνά τον αριθμό ηλεκτροδίων που απαιτείται κατά την διάρκεια της δειγματοληψίας. Στη επεξεργασία των σημάτων χρησιμοποιείται πληθώρα τεχνικών και διαπιστώνεται ότι και με 1 από τα 12 ηλεκτρόδια είναι ικανή η δειγματοληψία για σήμα ικανό για αυθεντικοποίηση. Ωστόσο το ιδανικό είναι τουλάχιστον 3 ηλεκτρόδια.

Στην εργασία του Odínaka [24] είναι μία συγκριτική ανάλυση μεταξύ των τεχνικών βιομετρικής αυθεντικοποίησης που αναπτύχθηκαν τα τελευταία 13 χρόνια στην βιβλιογραφία. Οι τεχνικές κατηγοριοποιούνται με βάση τα χαρακτηριστικά που εξάγονται από τον παλμό και την τεχνική που χρησιμοποιείται για την ταξινόμηση αυτού. Όλοι οι αλγόριθμοι απέδωσαν καλύτερα όταν το training και test σετ προέρχονταν από την ίδια δειγματοληψία. Και οι 3 αλγόριθμοι που χρησιμοποιήθηκαν έδωσαν equal error rates(EER) μικρότερο του 5.5%.

Στην εργασία του Zoakee [36] προτείνεται η μέθοδος του συνδυασμού του καρδιακού παλμού με το απότύπωμα της παλάμης. Τα χαρακτηριστικά από τον καρδιακό παλμό εξάγονται με την μέθοδο MFCC και από την παλάμη με την μέθοδο PCA. Τα χαρακτηριστικά αυτά ταξινομούνται με τον αλγόριθμο KNN και απόδίδουν 94.7% ποσοστό ορθής αυθεντικοποίησης. Τα δεδομένα που χρησιμοποιήθηκαν προέρχονται από 50 άντρες ηλικίας μεταξύ 18-54 ετών.

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος



## 4. ΜΕΘΟΔΟΙ

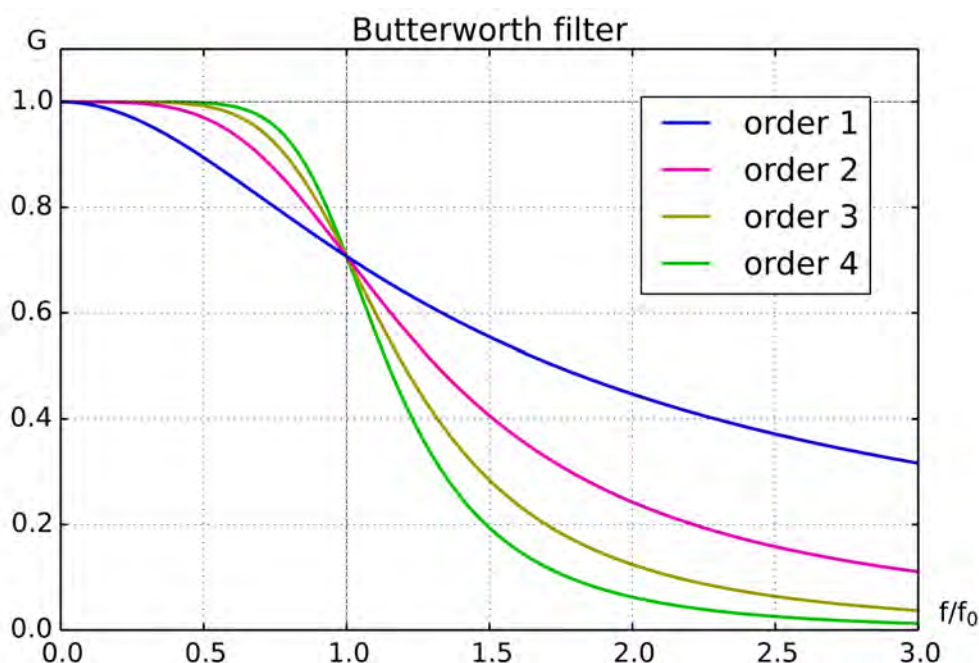
### 4.1 Προεπεξεργασία

#### 4.1.1 Φίλτρο Butterworth

Το φίλτρο Butterworth είναι ένα φίλτρο επεξεργασίας σήματος σχεδιασμένο να έχει όσο το δυνατόν πιο επίπεδη απόκριση συχνότητας στην ζώνη που επιτρέπει τα σήματα να περνάνε [30]. Η απόκριση συχνότητας ενός χαμηλοπερατού φίλτρου είναι:

$$G(\omega) = \frac{1}{\sqrt{1 + \omega^{2n}}}$$

Όπου  $\omega$  είναι η γωνιακή συχνότητα και  $n$  ο αριθμός των πόλων στο φίλτρο. Παρατηρείται



Σχήμα 4.1: Οι απόκρισεις συχνότητας για διάφορες τάξεις φίλτρων Butterworth

στο Σχήμα 4.1 ότι όσο μεγαλύτερη είναι η τάξη του φίλτρου, τόσο πιο απότομη είναι η μετάβαση από την ζώνη μετάβασης στην ζώνη απόρριψης. Συνεπώς το φίλτρο Butterworth είναι ιδανικό για την επεξεργασία του καρδιακού σήματος, καθώς μία πολύ συγκεκριμένη ζώνη είναι αυτή που βρίσκεται η πληροφορία (0. 5Hz - 40Hz). Οι περιοχές έξω από αυτή την ζώνη αποτελούν θόρυβο από τις γραμμές του τροφοδοσίας, κίνηση μυών, κίνηση αναπνευστικού, παρεμβολές.

## 4.2 Εξαγωγή χαρακτηριστικών

Σε αυτή την ενότητα περιγράφονται τα εργαλεία που χρησιμοποιήθηκαν για την εξαγωγή χαρακτηριστικών από το καρδιακό σήμα. Η εξαγωγή των χαρακτηριστικών είναι το σημαντικότερο στάδιο στην διαδικασία καθώς στην συνέχεια η ταξινόμηση και η αυθεντικοποίηση γίνεται με βάση αυτούς του συντελεστές.

### 4.2.1 Μετασχηματισμός Fourier

Κατά την μετάδοση του σήματος μέσα από ένα κανάλι επικοινωνίας η μορφή του σήματος αλλάζει λόγω του καναλιού και διάφορων πηγών θορύβου που επιδρούν σε αυτό. Αυτό έχει ως συνέπεια το σήμα που εκπέμπεται από την πηγή να μην είναι ακριβώς ίδιο με αυτό που λαμβάνετε από τον πομπό. Πολλές φορές η επίδραση αυτού του θορύβου καθιστά δύσκολη την επεξεργασία του σήματος στο πεδίο του χρόνου, έτσι συνηθίζεται η μελέτη στο πεδίο των συχνοτήτων [6].

Η ανάλυση Fourier ως ευρύτερο πεδίο των μαθηματικών αποτελεί την ανάλυση ενός σήματος σε άθροισμα απλούστερων περιοδικών τριγωνομετρικών συναρτήσεων (απόσύνθεση), καθώς και την αντίστροφη διαδικασία, δηλαδή την σύνθεση μιας συναρτησης από σύνολο γνωστών συναρτήσεων.

Υπάρχουν διάφορες παραλλαγές της ανάλυσης Fourier και επιλέγεται η καταλληλότερη ανάλογα με την περιοδικότητα ή μη του σήματος καθώς και με το πεδίο ορισμού αυτού (συνεχές ή διακριτό).

Η ανάλυση των σημάτων στο πεδίο της συχνότητας βασίζεται στην αναπαράσταση των σημάτων ως μεταβλητή. Ο μετασχηματισμός Fourier καθώς και η σειρά Fourier αποτελεί ένα από τα βασικά εργαλεία της ανάλυσης σήματος. Η ευκολία καθώς και η ταχύτητα του αλγορίθμου στην μεταφορά του σήματος από το πεδίο του χρόνου στο πεδίο της συχνότητας τον καθιστά έναν από τους πιο δημοφιλείς αλγορίθμους στην βιομετρική αυθεντικοποίηση.

#### 4.2.1.1 Σειρά Fourier

Η Σειρά Fourier εφαρμόζεται σε περιοδικά σήματα συνεχούς χρόνου και εκφράζει το σήμα ως άπειρο άθροισμα ημίτονων και συνημίτονων. Έστω  $T$  η περίοδος της συνάρ-

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος

τησης  $f$ , η σειρά Fourier είναι η εξής:

$$f(t) = \frac{a_0}{2} + \sum_{n=1}^{\infty} (a_n \cos(n\omega t) + b_n \sin(n\omega t))$$

Όπου:

$$a_0 = \frac{2}{T} \int_0^T f(t) dt$$

$$a_n = \frac{2}{T} \int_0^T f(t) \cos(n\omega t) dt$$

$$b_n = \frac{2}{T} \int_0^T f(t) \sin(n\omega t) dt$$

Χρησιμοποιώντας την σχέση του Euler:

$$e^{in\omega t} = \cos(n\omega t) + i \sin(n\omega t), \text{ με } \omega = \frac{2\pi}{T}$$

η σειρά Fourier μπορεί να γραφεί ως εξής:

$$f(t) = \sum_{n=-\infty}^{\infty} c_n e^{2\pi n t / T}$$

$$\text{όπου: } c_n = \frac{1}{T} \int_0^T f(t) e^{-2\pi n t / T} dt$$

#### 4.2.1.2 Συνεχής μετασχηματισμός Fourier

Όταν το πεδίο ορισμού της συνάρτησης πραγματικός αριθμός, όπως είναι ο χρόνος ( $t$ ), τότε ορίζεται ο παρακάτω αντιστρέψιμος μετασχηματισμός:

$$S(f) = \int_{-\infty}^{\infty} s(t) e^{-2\pi f t} dt$$

Η παραπάνω σχέση δίνει το συνεχές φάσμα του σήματος στο πεδίο της συχνότητας, όπου πια το σήμα είναι ανεξάρτητο του χρόνου και αναπαριστάται από την συμμετοχή της κάθε συχνότητας στο σύνολο του φάσματός του. Ο συνεχής μετασχηματισμός Fourier εφαρμόζεται σε περιοδικά και μη-περιοδικά σήματα.

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος

### 4.2.1.3 Μετασχηματισμός Fourier Διακριτού Χρόνου

Όπως η Σειρές Fourier αποτελούν εργαλείο για την έκφραση περιοδικών σημάτων συνεχούς χρόνου ως άθροισμα τριγωνομετρικών/μιγαδικών συναρτήσεων έτσι και ο Μετασχηματισμός Fourier Διακριτού Χρόνου αποτελεί το αντίστοιχο εργαλείο για περιοδικά σήματα διακριτού χρόνου.

$$S_{1/T}(f) = \sum_{n=-\infty}^{\infty} s[n]e^{-i2\pi fnT}$$

και ο αντίστροφος μετασχηματισμός ορίζεται ως:

$$s[n] = T \int_{1/T} S_{1/T}(f)e^{i2\pi fnT} df$$

### 4.2.1.4 Διακριτός μετασχηματισμός Fourier

Έστω η ακολουθία:

$$S_N = \frac{1}{NT} \sum_N s_N[n]e^{-i2\pi n \frac{k}{N}}$$

Η ακολουθία:

$$S_k = \sum_{n=0}^{N-1} s_N[n]e^{-2\pi in \frac{k}{N}}$$

είναι ο διακριτός μετασχηματισμός Fourier της  $s_N$ .  
Όμοια ορίζεται και ο αντίστροφος μετασχηματισμός της

$$S_k : s_N[n] = \frac{1}{N} \sum_N S_k e^{2\pi in \frac{k}{N}}$$

Το  $N$  επιλέγεται ως το μήκος του μη-μηδενικού τμήματος της  $s[n]$ . Στην περίπτωση του Διακριτού μετασχηματισμού Fourier (Discrete Fourier Transform, DFT) η απόσύνθεση

σε ημιτονοειδή διαφορετικών συχνοτήτων, τα οποία είναι αρμονικές της θεμελιώδους συχνότητας.  $f_0$ , οι συχνότητες των μιγαδικών εκθετικών σημάτων είναι πολλαπλάσια της θεμελιώδους αυτής συχνότητας. Επιλέχθηκε ο Διακριτός Μετασχηματισμός Fourier καθώς τα σήματα που έχουμε είναι διακριτά σήματα δειγματοληπτούμενα με  $F_s = 1000Hz$ .

#### 4.2.2 Διακριτός μετασχηματισμός συνημιτόνων

Ο διακριτός μετασχηματισμός συνημιτόνων (Discrete Cosine Transformation, DCT) εκφράζει μία πεπερασμένη ακολουθία σημείων ως άθροισμα συνημιτόνων διαφορετικών συχνοτήτων και πλάτους. Είναι όμοιος με τον DFT με την διαφορά ότι ο πρώτος χρησιμοποιεί μόνο πραγματικούς αριθμούς ενώ ο DFT χρησιμοποιεί ημίτονα και συνημίτονα σε μορφή μιγαδικών εκθετικών. Ο DCT λόγω της χρήσης συνημιτόνων, που είναι άρτια συνάρτηση, αποτελεί άρτια επέκταση της αρχικής συνάρτησης. Ακόμα πλεονέκτημα του DCT έναντι του DFT είναι ότι ο DCT χρησιμοποιεί μόνο συνημίτονα έναντι του DFT που χρησιμοποιεί και τα δύο και για αυτό προτιμάτε σε εφαρμογές συμπίεσης εικόνας και ήχου. Επειδή ο DCT εφαρμόζεται σε διακριτές πεπερασμένες ακολουθίες προκύπτουν τα εξής 2 ζητήματα. Πρώτον πρέπει να καθοριστεί αν η συνάρτηση  $f(x)$  είναι άρτια ή περιττή και στα δύο άκρα του πεδίου ορισμού της. Δεύτερον να καθοριστεί γύρω από πιο σημείο η συνάρτηση είναι άρτια ή περιττή.

Οι παραπάνω 2 επιλογές μας δίνουν τις 8 βασικές παραλλαγές του DCT καθώς και τις 8 παραλλαγές του DST (Διακριτός μετασχηματισμός Ημιτόνων). Συνολικά προκύπτουν 16 παραλλαγές, 2 για κάθε 2 από τα όρια του πεδίου ορισμού, αν δηλαδή επιλέξουμε τα όρια να είναι άρτια ή περιττά. Επίσης πρέπει να επιλέξουμε αν θα είναι συμμετρικά ως προς ένα σημείο ή ως προς ένα σημείο ανάμεσα σε αυτό (έχει ως αποτέλεσμα το σημείο αυτό να εμφανίζεται 2 φορές λόγω συμμετρίας). Συνεπώς προκύπτουν  $2*2*2*2=16$  συνδυασμοί από τους οποίους οι μισοί είναι DCT και οι άλλοι μισοί είναι DST.

Αυτές οι επιλογές προφανώς επηρεάζουν άμεσα τον μετασχηματισμό και προσδίδουν σε κάθε ένα από αυτούς μοναδικές ιδιότητες που εκμεταλλευόμαστε ανάλογα με την εφαρμογή. Για παράδειγμα οι οριακές συνθήκες του DCT είναι υπεύθυνες για την “συμπίεση ενέργειας” που προκύπτει από τις ιδιότητες του DCT και τον καθιστά χρήσιμο για εφαρμογές συμπίεσης εικόνας και ήχου. Αυτό οφείλεται στην σωστή επιλογή των ορίων που επηρεάζουν τον ρυθμό σύγκλισης των Σειρών Fourier.

Γενικά όσο περισσότερες ασυνέχειες έχει μία εξίσωση τόσο μειώνεται ο ρυθμός

σύγκλησης της σειράς Fourier αυτής, και έτσι χρειάζεται περισσότερα συνημίτονα για να την αναπαραστήσουμε με συγκεκριμένη ακρίβεια. Λόγω της περιοδικότητας των DFT σημαίνει ότι ασυνέχειες εμφανίζονται στα άκρα καθώς κανένα κομμάτι της ακολουθίας του σήματος δεν θα έχει ίσα τα δεξιά και τα αριστερά του όρια(ασυνέχειες άκρων). Ακόμα ο DST, ο οποίος είναι περιττός, θα εμφανίζει ασυνέχεια για κάθε συνάρτηση της οποίας το αριστερό όριο είναι διάφορο του μηδενός. Σε αντίθεση με τα παραπάνω ο DCT, ο οποίος είναι άρτιος, δεν εμφανίζει συνέχειες στα όρια καθώς και τα δύο όρια είναι άρτια. Για αυτό και οι παραλλαγές των διακριτών μετασχηματισμών συνημιτόνων οι οποίες έχουν και τα δύο όρια τους άρτια προτιμούνται για εφαρμογές σε επεξεργασία σήματος (τυπος I, II, V και VI).

Αυτός που υλοποιείται από το Matlab είναι ο DCT-II:

$$y(k) = w(k) \sum_{n=1}^N x(n) \cos\left(\frac{\pi}{2N}(2n-1)k\right) \text{ για } k=1, 2, \dots, N$$

όπου:

$$w(k) = \begin{cases} \frac{1}{\sqrt{N}} & , \text{ αν } k = 1 \\ \sqrt{\frac{2}{N}} & , \text{ αν } 2 \leq k \leq N \end{cases}$$

### 4.2.3 Wavelet

Η ανάλυση Wavelet [22] χρησιμοποιείται σε πολλά πεδία όπως ανάλυση σήματος, ανάλυση εικόνας και συστήματα επικοινωνίας. Όπως και οι προηγούμενοι 2 μετασχηματισμοί έχουν ως βασική ιδέα την ανάλυση μία συνάρτησης ως ένα σύνολο βασικών συναρτήσεων έτσι και ο διακριτός μετασχηματισμός κυματιδίου αναλύει μία συνάρτηση σε κυματίδια που αποτελούν συστολές και διαστολές ενός μητρικού κυματιδίου. Τα κυματίδια που προέρχονται από το μητρικό κυματίδιο έχουν ειδικές ιδιότητες κλιμάκωσης, είναι περιορισμένα στο χρόνο και στην συχνότητα και έτσι συνδέονται πιο άμεσα με το σήμα το οποίο θέλουμε να αναλύσουμε.

Όπως ο μετασχηματισμός Fourier “μετακινεί” ένα σήμα στο πεδίο των συχνοτήτων έτσι και ο μετασχηματισμός Wavelet “μετακινεί” ένα σήμα στο πεδίο των κυματιδίων. Ο μετασχηματισμός Wavelet προτιμάται για μη-στατικά σήματα στην ανάλυση σημάτων. Για να ορίσουμε το μετασχηματισμό κυματιδίου πρέπει αρχικά να ορίσουμε το μητρικό κυματίδιο, το οποίο ορίζεται ως εξής:

Έστω μιγαδική συνάρτηση  $\psi$  για την οποία ισχύουν οι ακόλουθες συνθήκες:

$$\int_{-\infty}^{\infty} |\psi(t)|^2 dt < \infty (1)$$

$$c_{\Psi} = 2\pi \int_{-\infty}^{\infty} \frac{|\Psi(\omega)|^2}{|\omega|} d\omega < \infty (2)$$

όπου  $\Psi$  είναι ο μετασχηματισμός Fourier της  $\psi$ . Η πρώτη εξίσωση (1) μας εξασφαλίζει ότι η συνάρτηση  $\psi$  έχει πεπερασμένη ενέργεια. Και η δεύτερη ότι αν η  $\Psi(\omega)$  είναι συνεχής, τότε  $\Psi(0) = 0$ .

#### 4.2.3.1 Συνεχής μετασχηματισμός Wavelet

Αν η  $\psi$  ικανοποιεί τις δύο παραπάνω συνθήκες τότε ορίζεται ο μετασχηματισμός wavelet για ένα πραγματικό σήμα ως εξής:

$$S(b, a) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} \bar{\psi}\left(\frac{t-b}{a}\right) s(t) dt (3)$$

Η παράμετρος  $b$  είναι η παράμετρος της χρονικής μετατόπισης και η παράμετρος  $a$  είναι η παράμετρος της κλιμάκωσης του κυματιδίου που αναλύουμε και  $\bar{\psi}$  το μιγαδικό συζυγές του κυματιδίου που ορίστηκε παραπάνω. Αν ορίσουμε το  $\psi$  ως εξής:

$$\psi_{a,b}(t) = a^{-1/2} \psi\left(\frac{t-b}{a}\right) (4)$$

που αποτελεί την κλιμάκωση και την χρονική μετατόπιση της  $\psi$  που ορίστηκε παραπάνω, τότε η εξίσωση που ορίστηκε στην (3) μπορεί να γραφεί ως το εσωτερικό γινόμενο της  $\psi_{a,b}(t)$  με ένα πραγματικό σήμα  $s(t)$ .

$$S(b, a) = \int_{-\infty}^{\infty} \bar{\Psi}_{a,b} s(t) dt (5)$$

Και τέλος όταν η  $\psi(t)$  ικανοποιεί τη συνθήκη (2) που απαιτείται, τότε ορίζεται και ο αντίστροφος μετασχηματισμός Wavelet, όπου μπορούμε να πάρουμε το αρχικό σήμα  $s(t)$  από τον μετασχηματισμό του  $S(b, a)$ . Ο οποίος ορίζεται ως εξής:

$$s(t) = \frac{1}{c_{\Psi}} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} S(b, a) \psi_{a,b}(t) \frac{da db}{a^2}$$

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος

### 4.2.3.2 Διακριτός μετασχηματισμός Wavelet

Όταν το σήμα που πρέπει να αναλύσουμε είναι διακριτό τότε ορίζεται ο διακριτός μετασχηματισμός wavelet. Αρχικά οι παράμετροι κλιμάκωσης και μετατόπισης  $a, b$  αντίστοιχα, κβαντίζονται ως εξής:

$$a = a_0^m \text{ και } b = nb_0$$

καθώς και το κυματίδιο πρέπει να οριστεί για να ισχύει για διακριτά σήματα ως εξής:

$$\psi_{m,n}(t) = a_0^{-m/2} \psi\left(\frac{t - nb_0}{a_0^m}\right)$$

όπου  $m, n$  ακέραιοι.

Και τέλος ο μετασχηματισμός κυματιδίου ορίζεται ως εξής:

$$S_{m,n} = \int_{-\infty}^{\infty} \bar{\psi}_{m,n} s(t) dt$$

όμοια με τον συνεχή μετασχηματισμό κυματιδίου και στον διακριτό ορίζεται ο αντίστροφος μετασχηματισμός:

$$s(t) = k_\psi \sum_m \sum_n S_{m,n} \psi_{m,n}$$

με  $k_\psi$  σταθερά για λόγους κανονικοποίησης συνάρτηση  $\psi_{m,n}(t)$  παρέχει σημεία δειγματοληψίας στο πεδίο κλίμακας-χρόνου. Γίνεται γραμμική δειγματοληψία στο άξονα του χρόνου (άξονας  $b$ ) και λογαριθμική στον άξονα της κλιμάκωσης (άξονας  $a$ ). Οι παραπάνω σχέσεις εξαρτώνται από την επιλογή του μητρικού κυματιδίου  $\psi$ . Για να πάρουμε τις πλήρεις πληροφορίες από τον μετασχηματισμό πρέπει συνεπώς να ξέρουμε τον τύπο του κυματιδίου που χρησιμοποιήθηκε. Όμως υπάρχουν και ιδιότητες του σήματος που είναι ανεξάρτητες από την επιλογή του κυματιδίου  $\psi$ , όπως η φάση της μιγαδικής συνάρτησης που αναλύουμε.

## 4.2.4 Βασικές συναρτήσεις κυματιδίων

### 4.2.4.1 Haar Wavelet

Η πιο απλή συνάρτηση κυματιδίου, έχει την μορφή τετραγωνικού παλμού και ορίζεται ως εξής.



Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος

Αρχικά ορίζουμε την συνάρτηση κλιμάκωσης:

$$\psi(t) = \begin{cases} 1 & , \text{αν } 0 \leq t \leq 1 \\ 0 & , \text{αλλιώς} \end{cases}$$

και το κυματίδιο ορίζεται ως εξής:

$$\psi(t) = \begin{cases} 1 & , \text{αν } 0 < t \leq \frac{1}{2} \\ -1 & , \text{αν } \frac{1}{2} < t \leq 1 \\ 0 & , \text{αλλού} \end{cases}$$

#### 4.2.4.2 Meyer Wavelet

Αποτελεί ένα συνεχές ορθοκανονικό κυματίδιο. Η συνάρτηση κλιμάκωσης ορίζεται ως εξής:

$$\Phi(\omega) = \begin{cases} 1 & , \text{αν } \omega \leq \frac{2}{4}\pi \\ \cos\left(\frac{\pi}{2}\nu\left(\frac{3}{4\pi}|\omega| - 1\right)\right) & , \text{αν } \frac{2}{3}\pi \leq |\omega| \leq \frac{4}{3} \\ 0 & , \text{αλλού} \end{cases}$$

με  $\nu(t)$  συνεχή συνάρτηση που ορίζεται:

$$\nu(t) = \begin{cases} 0 & , \text{αν } t \leq 0 \\ 1 & , \text{αν } t \geq 1 \end{cases}$$

Συνεπώς η συνάρτηση κυματιδίου  $\psi$  δίνεται από τον υπολογισμό του μετασχηματισμού Fourier μέσω της  $\Phi$ .

$$\Psi(\omega) = e^{i\omega/2} \sum_{l \in \mathbb{Z}} \Phi(\omega + 2\pi(2l + 1))\Phi\left(\frac{\omega}{2}\right)$$

Επειδή η  $\Psi$  έχει πεπερασμένη και μη μηδενική διάρκεια, η συνάρτηση κυματιδίου  $\psi$  προκύπτει παίρνοντας τον αντίστροφο μετασχηματισμό Fourier της παραπάνω σχέσης.

#### 4.2.4.3 Morlet Wavelet:

Η παρακάτω εξίσωση κυματιδίου ορίζεται έτσι ώστε ο μετασχηματισμός Fourier,  $\Psi(\omega)$ , να είναι μία μετατοπισμένη Gaussian συνάρτηση μετατοπισμένη έτσι ώστε να ισχύει  $\Psi(0) = 0$ .

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος

$$\Psi(\omega) = e^{-\frac{\omega-\omega_0}{2}} - e^{-\frac{\omega^2}{2}} e^{-\frac{t^2}{2}}$$

και η συνάρτηση προκύπτει από τον αντίστροφο μετασχηματισμό Fourier όπως και προηγουμένως:

$$\psi(t) = (e^{-i\omega_0 t} - e^{-\frac{\omega^2}{2}}) e^{-\frac{t^2}{2}}$$

#### 4.2.4.4 Daubechies Wavelet

Εκτός από την βάση του Haar προηγούμενες βάσεις που αναφέρθηκαν αποτελούνται από άπειρες συναρτήσεις που έχουν μη-κλειστό φορέα. Στην περίπτωση του κυματιδίου Daubechies κατασκευάζεται ορθοκανονικό κυματίδιο το οποίο είναι κλειστός φορέας. Για να έχει η  $\psi$  κλειστό φορέα επιλέγεται φη οποία έχει και αυτή κλειστό φορέα. Αρχικά πρέπει να ικανοποιούνται οι ακόλουθες 4 συνθήκες.

Έστω ακολουθία  $a_k$  με  $k \in \mathbb{Z}$  ικανοποιεί για κάθε  $N > 2$ :

$$a_k = 0, \text{ αν } k < 0 \text{ ή } k > 2N(1)$$

$$\sum_{k=-\infty}^{\infty} a_k a_{k+2m} = \delta_{0m}, \text{ για κάθε } m \in \mathbb{Z}(2)$$

$$\sum_{k=-\infty}^{\infty} a_k = \sqrt{2}(3)$$

$$\sum_{k=-\infty}^{\infty} \beta^k k^m = 0, \text{ με } 0 \leq m \leq N - 1(4)$$

$$\text{με } \beta_k = (-1)^k a_{-k+1}.$$

Επίσης για  $N=1$ , έχουμε  $a_0=a_1=1$  προκύπτει η βάση του Haar.

Από την παραπάνω ακολουθία,  $a_k$ , υπολογίζεται η εξής συνάρτηση κλιμάκωσης με κλειστό φορέα.

$$\phi(t) = \sum_{k=-\infty}^{\infty} a_k \sqrt{2} \phi(2t - k)$$

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος

είναι συνεχής με κλειστό φορέα και ικανοποιεί την σχέση:

$$\int \phi(t) dt = 1$$

Ακόμα αν το  $\beta_k$  ορίζεται όπως στην σχέση (4), τότε η  $\psi$  είναι:

$$\psi(t) = \sum_{k=-\infty}^{\infty} \beta_k \phi(2t - k)$$

Στο Matlab έγινε χρήση της συνάρτησης `wavedec` και του κυματιδίου `Daubechies` ώστε να διασπάσουμε το σήμα σε 9 επίπεδα. Η `wavedec` υλοποιεί πολυεπίπεδη μονοδιάστατη ανάλυση `wavelet`. Από τα επίπεδα επιλέχθηκαν οι συντελεστές επιπέδου 3 καθώς δίνουν τα καλύτερα αποτελέσματα όταν έγιναν δοκιμές με διάφορα επίπεδα που προέκυψαν από την ανάλυση `Wavelet`.

#### 4.2.5 PCA

Η ανάλυση κυρίων συνιστωσών PCA [16] αποτελεί μία γραμμική μέθοδο συμπίεσης δεδομένων στην οποία μεταφέρουμε τα δεδομένα από ένα χώρο  $n$  διαστάσεων σε ένα μικρότερο χώρο  $m$  διαστάσεων και καταλληλότερο για την επικείμενη επεξεργασία που θα υποστούν τα δεδομένα. Οι νέες συντεταγμένες που προκύπτουν είναι το αποτέλεσμα γραμμικού συνδυασμού των αρχικών συντεταγμένων σε νέο ορθογώνιο άξονα, ενώ ταυτόχρονα διατηρείται φθίνουσα σειρά στις διακυμάνσεις των δεδομένων.

Έτσι λόγω των δύο παραπάνω συνθηκών η πρώτη κύρια συνιστώσα έχει περισσότερη πληροφορία από την δεύτερη και επίσης η δεύτερη δεν έχει πληροφορίες που έχει η πρώτη. Ακόμα λόγω της ορθογωνιότητας των κυρίων συνιστωσών δεν συσχετίζονται μεταξύ τους. Ο αριθμός των κυρίων συνιστωσών είναι ίσος με τον αριθμό των αρχικών μεταβλητών, αλλά οι πρώτες κύριες συνιστώσες έχουν το 90% της συνολικής πληροφορίας. Έτσι επιτυγχάνεται να μειωθούν οι διαστάσεις των δεδομένων, διατηρώντας το μεγαλύτερο ποσοστό της πληροφορίας. Λόγω αυτής της ιδιότητας ο αλγόριθμος PCA χρησιμοποιείται ευρέως στην συμπίεση εικόνας.

Τα βήματα που ακολουθεί ο αλγόριθμος PCA είναι τα εξής:

1. Αφαίρεση από τα αρχικά δεδομένα του μέσου όρου, έτσι παράγονται νέα δεδομένα με μέσο όρο ίσο με το μηδέν
2. Υπολογισμός του πίνακα συν-διακύμανσης

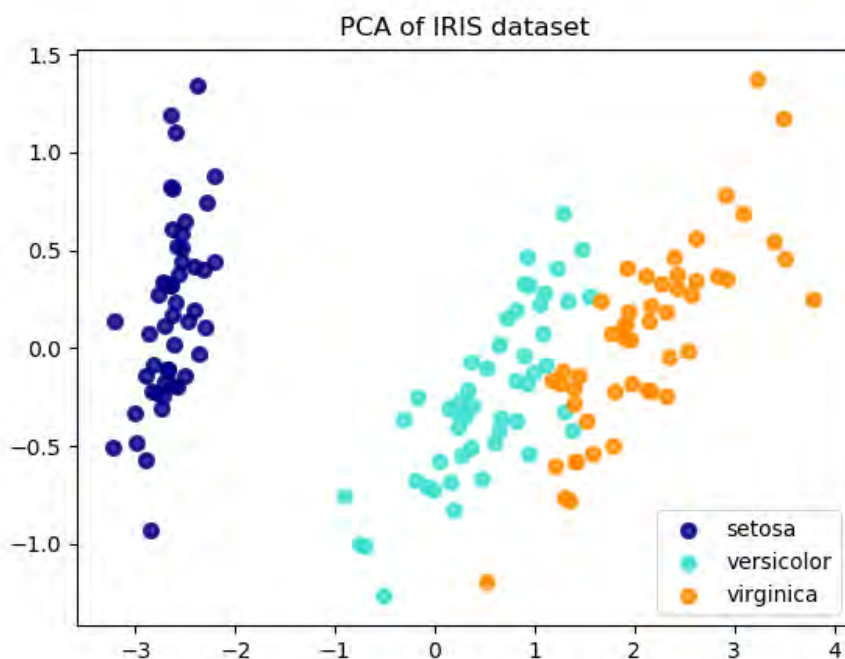
3. Με βάση τον πίνακα συν-διακύμανσης υπολογίζονται οι ιδιοτιμές και τα ιδιοδιανύσματα αυτού
4. Επιλογή των στοιχείων που θα αποτελέσουν το χαρακτηριστικό διάνυσμα, σύμφωνα με αυτά δημιουργείται το χαρακτηριστικό διάνυσμα καθώς και ο νέος διανυσματικός χώρος όπου εκφράζονται τα δεδομένα
5. Συλλογή νέων δεδομένων, όπου σύμφωνα με τον πίνακα που δημιουργήθηκε στο προηγούμενο βήμα πολλαπλασιάζεται με τον εαυτό του ανεστραμμένο και δημιουργείται ο τελικός διανυσματικός χώρος.
6. Επαναφορά των αρχικών δεδομένων. Καθώς δεν έχουμε πάρει όλα τα δεδομένα θα υπάρχει ένα σφάλμα συμπίεσης. Για τον υπολογισμό των αρχικών διανυσμάτων πολλαπλασιάζουμε τον παραπάνω πίνακα με τον αντίστροφο του πίνακα των συνιστωσών καθώς και προσθέτουμε τον μέσο όρο τον οποίο αφαιρέσαμε στο πρώτο βήμα.

Τα στοιχεία που βρίσκονται εκτός της κύριας διαγωνίου στον πίνακα συν-διακύμανσης μας δείχνουν την σχέση μεταξύ των δεδομένων. Θετική τιμή σε αυτή δηλώνει ότι αυξάνονται ταυτόχρονα και αρνητική το αντίθετο. Επίσης σύμφωνα με τις τιμές του πίνακα αυτού τοποθετημένες σε φθίνουσα σειρά επιλέγεται ο αριθμός των κυρίων συνιστωσών. Έτσι τα διανύσματα που επιλέχτηκαν παραπάνω τοποθετούνται σε στήλες πίνακα από τον οποίο υπολογίζεται ο πίνακας του διανυσματικού χώρου στο βήμα 6. Τα διανύσματα που προκύπτουν από τον αλγόριθμο PCA αποτελούν μία ορθογώνια βάση και είναι μεταξύ τους ασυσχέτιστα.

### 4.3 Classification

Σε αυτή την ενότητα αναλύονται οι μέθοδοι που χρησιμοποιήθηκαν για την ταξινόμηση των data set που παρήχθησαν στην προηγούμενη ενότητα. Σε όλες τις περιπτώσεις τα data set επό την προηγούμενη ενότητα έχουμε δυο κλάσεις, μία είναι τα δεδομένα που ανήκουν στο άτομο που θέλει να κάνει αυθεντικοποίηση και η δεύτερη ανήκει στα υπόλοιπα άτομα που προφανώς δεν πρέπει να εισέλθουν στο σύστημα.

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος



Σχήμα 4.2: Ανάλυση κυρίων συνιστωσών στο κλασσικό παράδειγμα των ανθών(IRIS Dataset)

#### 4.3.1 Multilayer Perceptron

Είναι το πιο κλασσικό παράδειγμα ενός feedforward νευρωνικού δικτύου [28] και είναι αρκετά ισχυρό για να επιλύσει αρκετά γραμμικά και μη προβλήματα. Αποτελείται συνήθως από 3 επίπεδα νευρώνων, το επίπεδο εισόδου, το κρυφό επίπεδο και το επίπεδο εξόδου. Το κρυφό επίπεδο και το επίπεδο εξόδου χρησιμοποιούν μια μη-γραμμική συνάρτηση ενεργοποίησης και αυτό είναι και το χαρακτηριστικό που μαζί με το γεγονός ότι υπάρχει κρυφό επίπεδο τα καθιστά ικανά να επιλύσουν προβλήματα που δεν είναι γραμμικά διαχωρίσιμα. Αυτή είναι και η διαφορά που τα διαχωρίζει από τα γραμμικά perceptron. Η τεχνική που χρησιμοποιείται για την εκπαίδευση αυτού του δικτύου είναι η πίσω διάδοση λάθους (backward propagation of errors), στην οποία υπολογίζεται το λάθος στην έξοδο, στο επίπεδο εξόδου, και διαδίδεται στα υπόλοιπα επίπεδα ώστε να διαμορφωθούν αντίστοιχα τα βάρη του κάθε νευρώνα.

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος

#### 4.3.1.1 Συναρτήσεις ενεργοποίησης

Οι δύο συνηθέστερες συναρτήσεις ενεργοποίησης είναι η λογιστική συνάρτηση και η υπερβολική εφαπτομένη οι οποίες παρουσιάζονται στην συνέχεια στο Σχήμα 4.3.

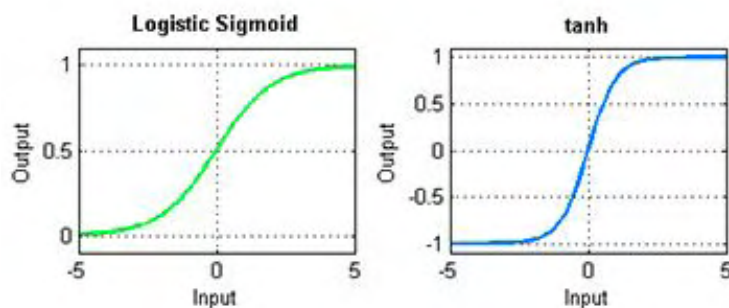
Η λογιστική συνάρτηση:

$$f(s) = \frac{1}{1 + e^{-s}}$$

Και η υπερβολική εφαπτομένη:

$$f(s) = \frac{1 - e^{-as}}{1 + e^{-as}}$$

Οι 2 αυτές συναρτήσεις δρουν ως κατώφλι για μεγάλες τιμές και τις περιορίζουν στα δια-



Σχήμα 4.3: Οι δύο συνηθέστερες συναρτήσεις ενεργοποίησης που συναντάμε στα νευρωνικά δίκτυα

στήματα  $[0, 1]$  και  $[-1, 1]$  αντίστοιχα.

Τέλος έχειδειχθεί ότι ένα δίκτυο με ένα κρυφό επίπεδο (και πιθανώς άπειρους νευρώνες) μπορεί να προσεγγίσει οποιαδήποτε συνεχή συνάρτηση. Το μέγεθος του επιπέδου εισόδου εξαρτάται από το μέγεθος της εισόδου. Στην παρούσα περίπτωση χρησιμοποιήθηκαν 20 νευρώνες για τους 20 συντελεστές που προκύπτουν από τους μετασχηματισμούς την προηγούμενης ενότητας. Το επίπεδο εξόδου εξαρτάται από τον αριθμό των κλάσεων που θέλουμε να διαχωρίσουμε τα δεδομένα. Στην περίπτωση μας έχουμε 2 κλάσεις οι οποίες σχετίζονται με το αν το καρδιογράφημα ανήκει σε ένα συγκεκριμένο άτομο ή όχι. Ο αριθμός των κρυφών νευρώνων δεν καθορίζεται από κάποια σχέση και συνήθως

απαιτεί πειραματισμούς για την εύρεση του ιδανικού μεγέθους. Ένας πειραματικός κανόνας ορίζει ότι ο αριθμός των νευρώνων του κρυφού επιπέδου είναι ίσος με το ημίθροισμα του αριθμού των νευρώνων εισόδου και εξόδου. Τέλος πρέπει να δοθεί ιδιαίτερη προσοχή ώστε το δίκτυο να μην υπερ-εκπαιδευτεί. Δηλαδή να μην προσαρμοστεί υπερβολικά στα δεδομένα εκπαίδευσης και να μην μπορεί να αναγνωρίσει δεδομένα εκτός αυτών. Μία τεχνική για να αντιμετωπιστεί αυτό είναι να χρησιμοποιήσουμε 2 διαφορετικά σετ, ένα για την εκπαίδευση και ένα για το τεστ του δικτύου. Συνήθως αυτή η σχετική αναλογία είναι 60/40.

### 4.3.2 K-Means

Αποτελεί έναν από τους βασικούς αλγορίθμους ομαδοποίησης [32] και το K στην ονομασία αφορά τον αριθμό των ομάδων που αρχικά δώσαμε στον αλγόριθμο ώστε να τις δημιουργήσει. Ο αλγόριθμος αποτελείται από 2 βασικά βήματα. Αρχικά ορίζονται K ομάδες τυχαία, και όλα τα δείγματα του χώρου ανατίθενται σε μία ομάδα. Στην συνέχεια για κάθε δείγμα υπολογίζεται η απόσταση από το κέντρο της ομάδας που ανήκει καθώς και από τα κέντρα των υπόλοιπων ομάδων. Αν η απόσταση είναι πιο μικρή στην ομάδα που ανήκει, μένει σε αυτή την ομάδα. Αλλιώς το βάζουμε σε άλλη ομάδα. Η διαδικασία αυτή συνεχίζεται μέχρι σε μία επανάληψη να μην υπάρχουν αλλαγές κάποιου δείγματος σε κάποια άλλη ομάδα. Τα πιο συνηθισμένα μέτρα απόστασης είναι η Ευκλείδεια απόσταση και η απόσταση Manhattan.

Ευκλείδεια:

$$d = \sqrt{\sum_{i=1}^N (x_i - y_i)^2}$$

Manhattan:

$$d = \sum_{i=1}^N (|x_i - y_i|)$$

### 4.3.3 Radial Basis Function

Αποτελεί υλοποίηση νευρωνικού δικτύου [7] όπου χρησιμοποιείται ως συνάρτηση ενεργοποίησης μία συνάρτηση ακτινικής βάσης (radial basis function). Οι συναρτήσεις

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος

αυτές παίρνουν πραγματικές τιμές και οι τιμές τους εξαρτώνται μόνο από την απόσταση τους από την αρχή των αξόνων

$$\phi(x) = \phi(\|x\|)$$

Όπως αναφέρθηκε και προηγουμένως ένα δίκτυο MLP με ένα κρυφό επίπεδο μπορεί να προσεγγίσει οποιαδήποτε συνάρτηση, έτσι και τα δίκτυα ακτινικής βάσης μπορούν να προσεγγίσουν συναρτήσεις αξιοποιώντας τις ιδιότητες των συναρτήσεων ακτινικής βάσης. Για παράδειγμα:

$$y_k = \sum_{i=1}^N w_i \phi(\|x - c_i\|)$$

Όπου  $\|x\|$  συνήθως η Ευκλείδεια απόσταση.

Στην παραπάνω σχέση η συνάρτηση  $y$  προσεγγίζεται ως άθροισμα  $N$  συναρτήσεων ακτινικής βάσης. Η κάθε μία από αυτές έχει διαφορετικό κέντρο  $c_i$  και βάρος  $w_i$ . Η συνάρτηση ακτινικής βάσης που χρησιμοποιήθηκε είναι η Gaussian:

$$\phi = e^{-\beta r^2}, \text{ με } \beta > 0$$

Τα δίκτυα RBF μπορούν να προσεγγίσουν οποιαδήποτε συνάρτηση του χώρου  $R_n$ , δεδομένου συγκεκριμένων συνθηκών στο σχήμα της συνάρτησης ενεργοποίησης. Η δομή του δικτύου είναι όπως και στο δίκτυο MLP με 3 επίπεδα. Ένα επίπεδο εισόδου χωρίς συνάρτηση ενεργοποίησης, ένα κρυφό επίπεδο που έχει μη γραμμικές ακτινικές συναρτήσεις ενεργοποίησης και ένα κρυφό επίπεδο που έχει γραμμικές συναρτήσεις ενεργοποίησης.

#### 4.3.4 Random Forest

Τα τυχαία δάση [20] αποτελούν αλγόριθμο συνδυαστικής γνώσης και συνδυάζουν πολλά δέντρα απόφασης (decision trees). Η έννοια της συνδυαστικής γνώσης είναι ότι κατασκευάζονται πολλαπλές υποθέσεις και υλοποιούνται από διαφορετικά μοντέλα. Στην συνέχεια τα αποτελέσματα από αυτές τις υποθέσεις συνδυάζονται με βάση την αρχή των πολλαπλών επεξηγήσεων σε μία τελική υπόθεση. Υπάρχουν διαφορετικές τεχνικές ψηφοφορίας, μερικές από αυτές είναι voting, weighted voting, reliability weighted voting.

Τα δέντρα απόφασης αποτελούν δέντρα τα οποία τα φύλλα τους είναι τα labels των δεδομένων και τα κλαδιά αποτελούν τις λογικές ενώσεις των χαρακτηριστικών που



οδηγούν σε αυτά, από την ρίζα του δέντρου έως τα φύλλα. Στα φύλλα συνήθως ανατίθενται κλάσεις ή πιθανότητες το δείγμα να ανήκει σε κάποια κλάση.

Το τυχαίο δάσος συνεπώς συνδυάζει πολλά δέντρα απόφασης την ώρα της εκπαίδευσης και επιλέγει την απάντηση που εμφανίστηκε περισσότερες φορές στα διάφορα μοντέλα που εκπαιδεύτηκαν. Τα τυχαία δάση έχουν την ιδιότητα να διορθώνουν το ελάττωμα που έχουν τα δέντρα απόφασης που είναι η υπέρ-εκπαίδευση σε σχέση με το training set. Δένδρα που έχουν μεγάλο βάθος μπορούν να μάθουν με μεγάλη λεπτομέρεια patterns και έτσι είναι ευάλωτα να υπέρ-εκπαιδευτούν πάνω στα δεδομένα εκπαίδευσης. Στα τυχαία δάση τα δεδομένα εκπαίδευσης μοιράζονται στα διάφορα μοντέλα και στο τελικό μοντέλο επιλέγεται ο μέσος όρος από όλα τα μοντέλα. Έτσι επιτυγχάνεται η αύξηση της απόδοσης με κόστος μικρή αύξηση στο bias.

#### 4.3.5 RBF Classifier

Όμοια με το RBF Δίκτυο, ο RBF ταξινομητής αποτελεί παραλλαγή του RBF Network. Η εκπαίδευση αυτού γίνεται υπό πλήρη επίβλεψη και σκοπός είναι να ελαχιστοποιήσουμε το τετραγωνικό σφάλμα. Τα κέντρα των ακτινικών Gaussian συναρτήσεων βρίσκονται με την χρήση του αλγορίθμου ομαδοποίησης K-means. Η μόνη διαφορά που έχει το RBFNetwork με τον RBFClassifier είναι ότι ο πρώτος εκπαιδεύει το κρυφό επίπεδο χωρίς επίβλεψη ενώ ο δεύτερος με επίβλεψη.

#### 4.3.6 Deep Neural Networks

Τα νευρωνικά δίκτυα είναι ένα σύνολο από αλγορίθμους που παρομοιάζουν την λειτουργία του ανθρώπινου εγκεφάλου στην δομή και κατά κάποιο τρόπο στην λειτουργία. Επεξεργάζονται δεδομένα μέσω μηχανικής όρασης, σεσημασμένων δεδομένων (labeling) και ομαδοποίησης των δεδομένων εισόδου. Η είσοδος στα δίκτυα αυτά είναι ένα διάνυσμα και πρέπει οποιαδήποτε δεδομένα να μετατραπούν σε διάνυσμα πρώτου εισαχθούν (εικόνες, ηχητικά σήματα, κείμενο κ.τ.λ) στο νευρωνικό δίκτυο.


Τα δίκτυα ομαδοποιούν τα δεδομένα όταν δεν υπάρχουν ετικέτες σε αυτά με βάση ομοιότητες στα δεδομένα εισόδου. Αν τα δεδομένα έχουν και ετικέτες τότε το δίκτυο ταξινομεί τα δεδομένα εισόδου, δεδομένου ότι έχει εκπαιδευτεί πάνω σε αυτά τα δεδομένα αρχικά. Τα deep neural networks είναι νευρωνικά δίκτυα με τεράστιο αριθμό νευρώνων εισόδου και κρυφών νευρώνων. Τέτοιου είδους δίκτυα λέγονται "universal approximators"

καθώς "μαθαίνουν" να αντιστοιχίζουν συγκεκριμένη είσοδο σε συγκεκριμένη έξοδο.

Έστω μία άγνωστη συνάρτηση  $f(x) = y$  όπου  $x$  τα δεδομένα εισόδου και  $y$  τα δεδομένα εξόδου. Κατά την διαδικασία της εκπαίδευσης του δικτύου, το δίκτυο βρίσκει την σωστή συνάρτηση  $f$  ώστε να συσχετίσει την είσοδο  $x$  με την έξοδο  $y$ .

Στην περίπτωση της ταξινόμησης ετικέτες πρέπει να δοθούν στο δίκτυο κατά την διάρκεια της εκπαίδευσης και για αυτό το λόγο ονομάζεται εκπαίδευση με επίβλεψη (supervised learning). Σε αντίθεση με την ταξινόμηση τα deep neural networks δεν χρειάζονται ετικέτες για να εντοπίσουν ομοιότητες ανάμεσα στα δεδομένα. Η εκπαίδευση χωρίς ετικέτες στα δεδομένα ονομάζεται εκπαίδευση χωρίς επίβλεψη (unsupervised learning). Σε αντίθεση με την ταξινόμηση που θεωρείται μία στατική πρόβλεψη, τα deep neural networks μπορούν με την κατάλληλη είσοδο να κάνουν πρόβλεψη για μελλοντικά δεδομένα.

Βασική δομή του νερωνικού δικτύου αποτελεί ο νευρώνας (Σχήμα 4.4) ο οποίος δέχεται είσοδο μαζί με κάποια βάρη, αθροίζει αυτήν την είσοδο και στην συνέχεια την εισάγει σε μία συνάρτηση ενεργοποίησης. Οι μόνοι νευρώνες που δεν έχουν κάποιο βάρος είναι οι νευρώνες εισόδου που παίρνουν κατευθείαν τα δεδομένα του χρήστη. Πολλοί νευρώνες μαζί σχηματίζουν ένα επίπεδο, οι νευρώνες που ανήκουν στο ίδιο επίπεδο δέχονται είσοδο και παράγουν έξοδο ταυτόχρονα.




Σχήμα 4.4: Νευρώνας που δέχεται  $m$  εισόδους και παράγει 1 έξοδο


Στην βιβλιογραφία τα δίκτυα με ένα κρυφό επίπεδο είναι τα Multi-layer Perceptron (Σχήμα 4.5) παρουσιάστηκαν στην προηγούμενη ενότητα και οποιοδήποτε δίκτυο έχει πάνω από ένα κρυφό επίπεδο ανήκει στην κατηγορία των deep neural networks (Σχήμα 4.6). Το πλεονέκτημα των deep neural networks[13] είναι ότι κάθε επίπεδο εκπαιδεύεται σε μοναδικά δεδομένα που προκύπτουν από το προηγούμενο επίπεδο, έτσι μπορεί να ανα-

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος

γνωρίζει όλο και μεγαλύτερες λεπτομέρειες πάνω στα δεδομένα. Όσο πιο πολλά επίπεδα έχει ένα δίκτυο τόσο μεγαλύτερη λεπτομέρεια μπορεί να αναγνωρίσει καθώς συναθροίζει και εκπαιδεύεται με πληροφορία από τα προηγούμενα επίπεδα (Σχήμα 4.7).



Σχήμα 4.5: δίκτυο Multi-layer Perceptron με ένα κρυφό επίπεδο




Σχήμα 4.6: Deep neural network με 1 επίπεδο εισόδου, 3 κρυφά επίπεδα και 1 επίπεδο εξόδου

Η ιεραρχία αυτή μεταξύ των επιπέδων προσδίδει στο δίκτυο αφαιρετικότητα και πολυπλοκότητα. Έτσι τα δίκτυα αυτά είναι ικανά να χειριστούν πολυδιάστατα δεδομένα μεγάλου όγκου. Τα δίκτυα αυτά μπορούν να βρουν ομοιότητες σε δεδομένα χωρίς ετικέτες και χωρίς κάποια προφανή δομή, όπως είναι τα περισσότερα δεδομένα που παράγει ο άνθρωπος (εικόνες, ήχοι, κείμενο, βίντεο). Τα deep neural networks έχουν την δυνατότητα

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος

να κάνουν εξαγωγή των χαρακτηριστικών από τα δεδομένα εισόδου χωρίς να ανθρώπινη παρέμβαση, μειώνοντας έτσι το χρονοβόρο έργο της εξαγωγής και τοποθέτησης ετικετών στα δεδομένα.

Όταν η εκπαίδευση γίνεται σε δεδομένα χωρίς ετικέτες κάθε επίπεδο στο deep network μαθαίνει τα χαρακτηριστικά αυτόματα προσπαθώντας επανειλημμένα να ανακατασκευάσει την είσοδο που δέχεται, αυτό επιτυγχάνεται ελαχιστοποιώντας την διαφορά μεταξύ της "μαντεψιάς" του δικτύου και της κατανομής πιθανότητας της πραγματικής εισόδου.



Σχήμα 4.7: Διαφορετικά κρυφά επίπεδα συνδυάζουν πληροφορία από προηγούμενα επίπεδα

Ένα deep-learning δίκτυο το οποίο εκπαιδεύεται με δεδομένα με ετικέτες αφού γίνει η εκπαίδευση μπορεί στη συνέχεια να εφαρμοστεί σε μη δομημένα δεδομένα, δίνοντας έτσι την ευκαιρία να εκπαιδευτεί σε πολύ μεγαλύτερο όγκο δεδομένων σε σχέση με άλλα μοντέλα μηχανικής γνώσης. Όσο περισσότερα δεδομένα έχει ένα deep-learning δίκτυο για να εκπαιδευτεί τόσο πιο ακριβές είναι. Γενικά ισχύει στην βιβλιογραφία ότι "κακοί" αλγόριθμοι που εκπαιδεύονται σε μεγάλο όγκο δεδομένων ξεπερνάνε σε απόδοση "καλούς" αλγόριθμους που εκπαιδεύονται σε μικρό όγκο δεδομένων. Και αυτός είναι ένα από τα μεγάλα προτερήματα των δικτύων αυτών, η ικανότητα εκπαίδευσης σε μη-σημασμένα δεδομένα. Τέλος η έννοια της εκπαίδευσης στα deep learning networks δεν είναι τίποτα παραπάνω από την αλλαγή των βαρών του δικτύου με βάση το παραγόμενο λάθος, μέχρις ότου να μην μειώνεται άλλο το λάθος.

## 5. ΠΡΟΤΕΙΝΟΜΕΝΗ ΜΕΘΟΔΟΛΟΓΙΑ

Σε αυτό το κεφάλαιο παρουσιάζονται οι τρεις διαφορετικές προσεγγίσεις που χρησιμοποιήθηκαν για την επίτευξη της αυθεντικοποίησης χρηστών βάσει των δεδομένων που προκύπτουν από το καρδιογράφημά τους. Κάθε προσέγγιση αποτελείται από τρεις υποενότητες, οι οποίες αποτελούν και διακριτά στάδια της διαδικασίας:

- **Προεπεξεργασία:** Σε αυτό το στάδιο γίνεται επεξεργασία στο σήμα που λαμβάνεται από τον χρήστη, ώστε να είναι δυνατή η επεξεργασία του στο επόμενο βήμα
- **Εξαγωγή χαρακτηριστικών:** Εφαρμογή μετασχηματισμού για την εξαγωγή των απαραίτητων χαρακτηριστικών από το σήμα
- **Ταξινόμηση:** Στα χαρακτηριστικά που εξήχθησαν εφαρμόζεται κάποιος αλγόριθμος μηχανικής μάθησης ή εισάγονται σε κάποιο νευρωνικό δίκτυο

### 5.1 Non-Fiducial feature extraction και machine learning

Η πρώτη μεθοδολογία που ακολουθείται είναι η επεξεργασία και η εξαγωγή των χαρακτηριστικών του σήματος στο πεδίο της συχνότητας και στην συνέχεια αυτά τα χαρακτηριστικά δοκιμάζονται με διάφορους αλγόριθμους μηχανικής γνώσης.

#### 5.1.1 Preprocess

Αρχικά ορίζουμε ένα σύνολο με τα καρδιογραφήματα των 50 ατόμων:

$$\mathbf{P}_i, \text{ για } i = 1, 2, \dots, 50$$

Όπου το κάθε άτομο έχει 4 δειγματοληψίες:

$$\mathbf{S}_{i,j}, \text{ για } i = 1, 2, \dots, 50 \text{ και } j = 1, 2, \dots, 4$$

Όπου  $i$  δηλώνει το άτομο στο οποίο ανήκει η δειγματοληψία  $j$ .

Αρχικά για κάθε άτομο και για κάθε δειγματοληψία το σήμα φιλτράρεται με ένα ζωνοπερατό φίλτρο Butterworth στην ζώνη συχνοτήτων 0. 5Hz έως 40Hz για να απορριφθούν

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος

πηγές θορύβου που υπάρχουν στο σήμα όπως Baseline wander σε περιοχές μικρότερες των 0.5Hz και θόρυβος από τις γραμμές του ρεύματος που βρίσκεται στα 50Hz ή 60Hz (ανάλογα με την χώρα).

$$\mathbf{F}_{i,j} = \mathcal{B}\{\mathbf{S}_{i,j}\}, \text{ για } i = 1, 2, \dots, 50 \text{ και } j = 1, 2, \dots, 4$$

Κάθε σήμα  $\mathbf{S}_{i,j}$  στην συνέχεια χωρίζεται σε επιμέρους τμήματα των 5 δευτερολέπτων, ώστε σε κάθε τμήμα να έχουμε αρκετούς παλμούς. Για λόγους απλότητας το κάθε δείγμα θα συμβολίζεται  $\mathbf{S}_{i,j}$  και μετά την κατάτμιση.

### 5.1.2 Feature extraction

Σε αυτή την υποενότητα χρησιμοποιώντας τα τμήματα που παρήχθησαν στην προηγούμενη εφαρμόζονται τρεις μετασχηματισμοί από τους οποίους θα γίνει εξαγωγή των χαρακτηριστικών που θα χρησιμοποιηθούν για την ταξινόμηση.

Τα κατατμημένα αυτά τμήματα μετασχηματίζονται με τους εξής μετασχηματισμούς Fourier, Cosine, Wavelet:

- $y_{1,i} = \mathcal{F}\{\mathbf{F}_{i,j}\}$
- $y_{2,i} = \mathcal{C}\{\mathbf{F}_{i,j}\}$
- $y_{3,i} = \mathcal{W}\{\mathbf{F}_{i,j}\}$

Μετά τον μετασχηματισμό γίνεται λήψη των συντελεστών που θα χρησιμοποιηθούν στην αυθεντικοποίηση. Λαμβάνονται οι 20 μεγαλύτεροι συντελεστές αγνοώντας την συνιστώσα DC(θέση μηδέν) στους μετασχηματισμούς Fourier, Cosine ενώ στο Wavelet λαμβάνονται οι συντελεστές από το τρίτο επίπεδο απόσύνθεσης του πεδίου των κυματιδίων Wavelet.

- $coef_{1,i} = sort\{y_1[1 : 20]\}$
- $coef_{2,i} = sort\{y_2[1 : 20]\}$
- $coef_{3,i} = sort\{y_{3,level3}[1 : 20]\}$

Οι παραπάνω μεταβλητές περιέχουν τους 20 σημαντικότερους συντελεστές που προκύπτουν από τον κάθε μετασχηματισμό.

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος

### 5.1.3 Classification

Σε αυτή την ενότητα δημιουργούνται τα αρχεία εκπαίδευσης σύμφωνα με τους παραπάνω συντελεστές. Για κάθε ασθενή  $\mathbf{P}_i$ , για  $i = 1, 2, \dots, 50$  δημιουργούνται 2 σετ αρχείων, τα αρχεία αυτά είναι τα  $train_i$  και  $test_i$ . Οι συντελεστές του ασθενή  $\mathbf{P}_i$  χωρίζονται σε 2 μέρη, το 60% αυτών εισάγεται στο αρχείο  $train_i$  και χαρακτηρίζεται από την ετικέτα 0 και το υπόλοιπο 40% των συντελεστών αυτών εισάγεται στο αρχείο  $test_i$  και σηματοδοτείται με την ετικέτα 0 όμοια με το αρχείο  $train_i$ .

Το αρχείο  $train_i$  συμπληρώνεται με το 60% των συντελεστών των  $\mathbf{P}_k$ , με  $k \neq i$  ώστε να έχουμε ισάριθμους συντελεστές που ανήκουν στο άτομο  $i$  και που δεν ανήκουν στο άτομο  $i$ , οι συντελεστές αυτοί σηματοδοτούνται με την ετικέτα 1. Όμοια στο αρχείο  $test_i$  εισάγονται το 40% των συντελεστών των ατόμων  $\mathbf{P}_k$ , με  $k \neq i$ , έτσι ώστε και εδώ να έχει ισάριθμο αριθμό συντελεστών που ανήκουν στο άτομο  $i$  και που δεν ανήκουν σε αυτό.

Η εκπαίδευση αυτών γίνεται με τους αλγορίθμους K-Means, MLP, RBFNetwork, Random Forest στο περιβάλλον Weka, όπου εισάγονται τα αρχεία  $train$  και  $test$  για κάθε ασθενή που δημιουργήθηκαν παραπάνω.

## 5.2 Non-Fiducial feature extraction και deep learning

Με αυτή την μέθοδο τα δύο πρώτα στάδια είναι ίδια με την προηγούμενη υποενότητα, η διαφοροποίηση προκύπτει στο στάδιο της ταξινόμησης καθώς γίνεται χρήση ενός deep neural network.

### 5.2.1 Preprocess

Αρχικά ορίζουμε ένα σύνολο με τα καρδιογραφήματα των 50 ατόμων:

$$\mathbf{P}_i, \text{ για } i = 1, 2, \dots, 50$$

Όπου το κάθε άτομο έχει 4 δειγματοληψίες:

$$\mathbf{S}_{i,j}, \text{ για } i = 1, 2, \dots, 50 \text{ και } j = 1, 2, \dots, 4$$

Όπου  $i$  δηλώνει το άτομο στο οποίο ανήκει δειγματοληψία  $j$ .

Αρχικά για κάθε άτομο και για κάθε δειγματοληψία το σήμα φιλτράρεται με ένα ζωνοπερατό

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος

φίλτρο Butterworth στην ζώνη συχνοτήτων 0.5Hz έως 40Hz για να απορριφθούν πηγές θορύβου που υπάρχουν στο σήμα όπως Baseline wander σε περιοχές μικρότερες των 0.5Hz και θόρυβος από τις γραμμές του ρεύματος που βρίσκεται σε 50Hz ή 60 (ανάλογα με την χώρα).

$$\mathbf{F}_{i,j} = \mathcal{B}\{\mathbf{S}_{i,j}\}, \text{ για } i = 1, 2, \dots, 50 \text{ και } j = 1, 2, \dots, 4$$

Κάθε σήμα  $\mathbf{S}_{i,j}$  στην συνέχεια κόβεται σε κομμάτια των 5 δευτερολέπτων ώστε σε κάθε κομμάτι των 5 δευτερολέπτων να έχουμε τουλάχιστον έναν ολόκληρο παλμό, για λόγους απλότητας θα συμβολίζεται  $\mathbf{S}_{i,j}$  και μετά την κατάτμιση.

### 5.2.2 Feature extraction

Σε αυτή την υποενότητα χρησιμοποιώντας τα κομμάτια που παρήχθησαν στην προηγούμενη εφαρμόζονται 3 μετασχηματισμοί από τους οποίους θα γίνει εξαγωγή των χαρακτηριστικών που θα χρησιμοποιηθούν για την ταξινόμηση.

Τα κατατμημένα αυτά κομμάτια μετασχηματίζονται με τους εξής 3 μετασχηματισμούς Fourier, Cosine, Wavelet:

- $y_{1,i} = \mathcal{F}\{\mathbf{F}_{i,j}\}$
- $y_{2,i} = \mathcal{C}\{\mathbf{F}_{i,j}\}$
- $y_{3,i} = \mathcal{W}\{\mathbf{F}_{i,j}\}$

Μετά τον μετασχηματισμό γίνεται λήψη των συντελεστών που θα χρησιμοποιηθούν στην αυθεντικοποίηση, λαμβάνονται οι 20 μεγαλύτεροι συντελεστές αγνοώντας την συνιστώσα Dc(θέση μηδέν) στους μετασχηματισμούς Fourier, Cosine και στο Wavelet λαμβάνονται οι συντελεστές από το τρίτο επίπεδο αποσύνθεσης του πεδίου των κυματιδίων Wavelet.

- $coef_{1,i} = \text{sort}\{y_1[1 : 20]\}$
- $coef_{2,i} = \text{sort}\{y_2[1 : 20]\}$
- $coef_{3,i} = \text{sort}\{y_{3,level3}[1 : 20]\}$

Οι παραπάνω μεταβλητές περιέχουν τους 20 μεγαλύτερους συντελεστές που προκύπτουν από τον κάθε μετασχηματισμό.



### 5.2.3 Classification

Για την δημιουργία των αρχείων που απαιτούνται για την εκπαίδευση του νευρωνικού δικτύου συνενώνονται τα 3 αρχεία που δημιουργήθηκαν στην προηγούμενη ενότητα έτσι ώστε σε μια σειρά του αρχείου να περιέχει τα *coefficients* και από τους 3 μετασχηματισμούς του κάθε τμήματος του παλμού ώστε να υπάρχουν αρκετές μεταβλητές για να εκμεταλλευτούμε τον μεγάλο βαθμό ελευθερίας του νευρωνικού δικτύου.

Το δίκτυο κατασκευάζεται με 60 νευρώνες ως είσοδο, 3 κρυφά επίπεδα με [100, 200, 100] νευρώνες το κάθε κρυφό επίπεδο και 2 νευρώνες εξόδου που υποδηλώνουν με 0 αν ο παλμός αναγνωρίστηκε ότι ανήκει στο άτομο  $i$  (δηλαδή έγινε σωστά η αυθεντικοποίηση) και με 1 αν δεν ανήκει στο σωστό άτομο  $i$  και ανήκει σε οποιαδήποτε από τα άλλα  $k \neq i$  (απότυχημένη αυθεντικοποίηση).

## 5.3 Non-Fiducial feature extraction με PCA

Σε αυτή την ενότητα θα γίνει εξαγωγή των χαρακτηριστικών του καρδιακού σήματος με ανάλυση των κυρίων συστωσών(PCA) ενός καρδιακού παλμού. Οι συντελεστές που προκύπτουν από την ανάλυση αυτή στην συνέχεια θα χρησιμοποιηθούν για ταξινόμηση.

### 5.3.1 Preprocess

Αρχικά ορίζουμε ένα σύνολο με τα καρδιογραφήματα των 50 ατόμων:

$$\mathbf{P}_i, \text{ για } i = 1, 2, \dots, 50$$


Όπου το κάθε άτομο έχει 4 δειγματοληψίες:

$$\mathbf{S}_{i,j}, \text{ για } i = 1, 2, \dots, 50 \text{ και } j = 1, 2, \dots, 4$$

Όπου  $i$  δηλώνει το άτομο στο οποίο ανήκει δειγματοληψία  $j$ .

Όπως και στις προηγούμενες ενότητες πρώτο στάδιο αποτελεί το φιλτράρισμα του σήματος. Έτσι για κάθε άτομο και για κάθε δειγματοληψία το σήμα φιλτράρεται με ένα ζωνοπερατό φίλτρο Butterworth 8ης τάξης στην ζώνη συχνοτήτων 0. 5Hz έως 40Hz για να απορριφθούν πηγές θορύβου που υπάρχουν στο σήμα όπως Baseline wander σε περιοχές μικρότερες των 0. 5Hz και θόρυβος από τις γραμμές του ρεύματος που βρίσκεται σε 50Hz ή 60Hz (ανάλογα με την χώρα).

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος



Σχήμα 5.1: Η μορφολογία ενός καρδιακού παλμού, διακρίνονται οι κορυφές P, Q, R, S και T καθώς και απόστάσεις μεταξύ αυτών

$$F_{i,j} = \mathcal{B}\{S_{i,j}\}, \text{ για } i = 1, 2, \dots, 50 \text{ και } j = 1, 2, \dots, 4$$

Αφότου γίνει το φιλτράρισμα του σήματος χρειάζεται να εξάγουμε τους καρδιακούς παλμούς από την κάθε δειγματοληψία των ατόμων. Έτσι δημιουργείται ένας πίνακας με όλους τους καρδιακούς παλμούς από όλα τα άτομα. Για την δημιουργία του πίνακα ακολουθείται η εξής διαδικασία:

- Ο εντοπισμός των καρδιακών παλμών, δηλαδή μιας περιόδου PQRST γίνεται με την χρήση της πρώτης παραγώγου για τον εντοπισμό της κορυφής R
- Με αφετηρία το σημείο R εντοπίζουμε αριστερά και δεξιά από αυτό τα τοπικά μέγιστα που είναι οι κορυφές P και T αντίστοιχα


Βασικό στοιχείο για την επιτυχία του αλγορίθμου PCA είναι οι παλμοί να έχουν ίσο μέγεθος καθώς στην συνέχεια απαιτείται πολλαπλασιασμός πινάκων. Έτσι επιλέγεται ως μέγεθος για όλους τους παλμούς τα 900 σημεία ώστε οι καρδιακοί παλμοί να είναι

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος

ομοιόμορφοι. Στην θέση 450 της κάθε γραμμής του πίνακα συνεπώς βρίσκεται η κορυφή R του καρδιακού παλμού.

Οι καρδιακοί παλμοί που εξήχθησαν τοποθετούνται σε έναν πίνακα καθώς και με μία ετικέτα η οποία συμβολίζει σε ποιο άτομο ανήκουν.

$$All\_Data = Peak\{\mathbf{S}_i\}$$
$$All\_Position = i, \text{ για } i = 1, 2, \dots, 50$$



Σχήμα 5.2: Διαφορετικοί παλμοί που εξήχθησαν από ένα άτομο, διακρίνονται ξεκάθαρα οι κορυφές R, P και T

Στον πίνακα *All\_Data* βρίσκονται όλοι οι καρδιακοί παλμοί από όλα τα άτομα και στον πίνακα *All\_Position* διατηρεί σε αντιστοιχεία σε ποιον ανήκει ο καρδιακός παλμός. Η διάσταση του πίνακα *All\_Data* είναι  $(\sum_{i=1}^{50} N_i, 900)$  όπου  $N_i$  ο αριθμός των καρδιακών παλμών του ατόμου  $\mathbf{F}_i$ . Τέλος η συνάρτηση *Peak* υπολογίζει την πρώτη παράγωγο, βρίσκει το τοπικό μέγιστο και χησιμεύει στον εντοπισμό της κορυφής R.

Ακόμα δημιουργείται ο πίνακας *Data*, αυτός ο πίνακας περιέχει λίγους παλμούς από κάθε ασθενή και θα χρησιμοποιηθεί για την κατασκευή του διανυσματικού χώρου που περιέχει σε κάθε γραμμή του καρδιακούς παλμούς από κάθε ασθενή. Ο πίνακας *Data*

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος

περιέχει για κάθε άτομο  $F_i$  το 10% του συνολικού αριθμού των καρδιακών παλμών από τον πίνακα *All\_Data*.

Η των καρδιακών παλμών που συμμετέχουν στον πίνακα *Data* γίνεται τυχαία καθώς δύο συνεχόμενοι παλμοί του ίδιου ατόμου θα έχουν μεγαλύτερη συσχέτιση από δύο καρδιακούς παλμούς του ίδιου ατόμου που προέρχονται από διαφορετικές δειγματοληψίες.

### 5.3.2 Feature extraction με PCA

Για την κατασκευή του διανυσματικού χώρου των κυρίων συνιστωσών αρχικά ο πίνακας *Data* πολλαπλασιάζεται με τον ανάστροφο *Data'* για να υπολογιστεί ο πίνακας συσχέτισης:

$$A = Data' * Data$$

Και στην συνέχεια ο πίνακας *A* χρησιμοποιείται για την κατασκευή του διανυσματικού χώρου όπου θα εκφραστούν όλα τα σήματα:

$$[V, D] = eigs(A)$$

Όπου *V* ο πίνακας ιδιοδιανυσμάτων και *D* ο πίνακας ιδιοτιμών, από τον οποίο επιλέγονται οι 20 μεγαλύτερες 20 συνιστώσες.


Έτσι με την κατασκευή του διανυσματικού χώρου *V* θα γίνει προβολή στο χώρο των σημάτων και θα πάρουμε τις κύριες συνιστώσες των σημάτων τις οποίες θα χρησιμοποιήσουμε για αυθεντικοποίηση.

Για κάθε άτομο  $F_i$  προβάλλουμε τους καρδιακούς παλμούς αυτού στον διανυσματικό χώρο *V*:

$$coefficients_i = simata_i * V, \text{ για } i = 1, 2, \dots, 50$$

Όπου *simata<sub>i</sub>* είναι όλα τα σήματα του ατόμου *i* που ανήκουν στο πίνακα *All\_Data*. Και κατασκευάζεται και ο πίνακας:

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος



Σχήμα 5.3: Οι 5 κύριες συνιστώσες ενός καρδιακού παλμού

$$not\_coefficients_i = simata_{k \neq i} * V, \text{ για } i, k = 1, 2, \dots, 50$$

Με  $not\_coefficients_i$  συμβολίζονται οι συνιστώσες όλων των ατόμων εκτός από το άτομο  $i$  που ανήκουν στον πίνακα  $All\_Data$ . Ο δεύτερος πίνακας περιέχει σήματα από τα υπόλοιπα 49 άτομα εκτός του  $i$ , έτσι είναι λογικό να είναι και μεγαλύτερος σε μέγεθος. Όμως στην εκπαίδευση που θα ακολουθήσει θέλουμε οι δύο κλάσεις να είναι ισομεγέθης, για αυτό το λόγο από τους υπόλοιπους 49 παίρνουμε όσους καρδιακούς παλμούς έχει το άτομο  $F_i$  ώστε οι δύο παραπάνω πίνακες να είναι ισομεγέθεις.

Τέλος για κάθε άτομο δημιουργείται και ένας πίνακας με όλους τους καρδιακούς του παλμούς εκφρασμένους στο χώρο  $V$ , που δεν ανήκουν όμως στους δύο παραπάνω πίνακες και σκοπό έχει το testing:

$$person\_coefficients_i = all\_simata_i * V, \text{ για } i = 1, 2, \dots, 50$$

Πρώτη δοκιμή για την αυθεντικοποίηση των ατόμων γίνεται με την χρήση της απόστασης ως μέτρο με την εξής διαδικασία:

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος

- Για τους πίνακες  $coefficients_i, not\_coefficients_i, person\_coefficients_i$  υπολογίζεται το average ανά 5 παλμούς.
- Υπολογίζονται οι εξής απόστάσεις πινάκων
  - Υπολογίζεται η απόσταση Manhattan μεταξύ των πινάκων  $average\_coefficients_i$  και  $average\_person\_coefficients_i$
  - Υπολογίζεται η απόσταση Manhattan μεταξύ των πινάκων  $average\_not\_coefficients_i$  και  $average\_person\_coefficients_i$

$$diff1 = \sum |average\_coefficients_i - average\_person\_coefficients_i|$$

$$diff2 = \sum |average\_not\_coefficients_i - average\_person\_coefficients_i|$$

- Υπολογίζεται το ελάχιστο, το μέγιστο και η μέση τιμή για τους 2 αυτούς πίνακες  $diff1, diff2$
- Η μέτρηση του ποσοστού επιτυχίας γίνεται με την καταμέτρηση των στοιχείων του  $diff1 < \min(diff2)$ , δηλαδή οι απόστάσεις μεταξύ των σημάτων του ατόμου με τα σήματα του που ανήκουν στο διανισματικό χώρο να είναι μικρότερες από την μικρότερη απόσταση των σημάτων του ατόμου με τα σήματα των υπολοίπων ανήκουν στο χώρο.

Εκτός από την απόσταση ως κριτήριο για την αυθεντικοποίηση έγινε χρήση και αλγορίθμων τεχνητής νοημοσύνης.

Για την δημιουργία των αρχείων εκπαίδευσης ακολουθήθηκε η εξής διαδικασία:

- Το αρχείο εκπαίδευσης  $train_i$  αποτελείται από τους πίνακες  $coefficients_i$  που έχουν την ετικέτα 0 και  $not\_coefficients$  που έχουν την ετικέτα 1 αφήνοντας εκτός το 40% από τον κάθε πίνακα
- Το αρχείο  $test_i$  έχει τα στοιχεία που αφέθηκαν εκτός προηγουμένως, ώστε να αποτελούν στοιχεία που το δίκτυο δεν έχει εκπαιδευτεί και έτσι θα δώσει μια πιο εγκυρη απάντηση.

Πάνω σε αυτά τα αρχεία εκπαίδευσης δοκιμάζονται οι 5 αλγόριθμοι ταξινόμησης που αναφέρθηκαν στην προηγούμενη ενότητα και αυτός που δίνει τα μεγαλύτερα αποτελέσματα επιλέγεται για εκπαίδευση με cost sensitive τεχνικές. Η λογική στην cost sensitive

εκπαίδευση είναι να μειώσουμε τα false positive κρατώντας τα true positive πάνω από ένα συγκεκριμένο όριο. Όπου στην περίπτωση μας false positive είναι όταν ένα άτομο αναγνωρίζετε ως  $i$  χωρίς να είναι το άτομο  $i$ . Ιδανικά θα θέλαμε αυτό το νούμερο να είναι 0 αλλά σε κανένα σχεδόν σύστημα δεν είναι. Ακόμα και σε ένα σύστημα με 4-ψήφιο κωδικό πρόσβασης η πιθανότητα να μπει κάποιος κατά τύχη είναι 1/10000. Στη περίπτωση των cost sensitive τεχνικών επιβάλουμε μεγάλες "ποινές" κατά την εκπαίδευση όταν εμφανίζεται ένα false positive έτσι ώστε το δίκτυο να απόφεύγει να ταξινομεί δεδομένα σε αυτή την κατηγορία. Τέλος σε αυτή την τεχνική διαπιστώνετε ότι δεν είναι το βέλτιστο να εκπαιδεύσουμε το δίκτυο για κάθε άτομο με την ίδια ποινή. Έτσι για κάθε άτομο θέτουμε ένα όριο των true positive να είναι πάνω από 90% και των false positive να είναι μικρότερα από 10%. Συνεπώς να γίνει διαδοχική εκπαίδευση με αυξανόμενη ποινή και θα επιλέγεται ως ιδανική ποινή για κάθε άτομο η μικρότερη που ικανοποιεί την παραπάνω συνθήκη.

Στην συνέχεια για να διαπιστωθεί αν η συμμετοχή συγκεκριμένων σημάτων παίζει κάποιο ρόλο στα αποτελέσματα δημιουργείται ένας νέος διανυσματικός χώρος  $V_2$  ο οποίος περιέχει μόνο τα πρώτα 30 άτομα αφήνοντας τα υπόλοιπα 20 απ' έξω. Έτσι δοκιμάζεται η αυθεντικοποίηση μεταξύ σημάτων που δεν ανήκουν στον διανυσματικό χώρο.

$$\begin{aligned} coefficients_{2_i} &= simata_i * V_2, \text{ για } i = 31, 2, \dots, 41 \\ not\_coefficients_{2_j} &= simata_j * V_2, \text{ για } j = 42, 43, \dots, 50 \end{aligned}$$

Σε αυτή την μεθοδολογία θα γίνει αυθεντικοποίηση του κάθε ασθενή  $i$  με σύνολο συντελεστών  $coefficients_{2_i}$  ενάντια στο σύνολο των συντελεστών  $not\_coefficients_{2_j}$ . Έτσι διασφαλίζεται ότι πρώτον δεν υπάρχει μέσα στον διανυσματικό χώρο  $V_2$  κανένα από τα σήματα που χρησιμοποιείται για εκπαίδευση και δεύτερον τα σήματα  $not\_coefficients_{2_j}$  δεν υπάρχουν ούτε στο διανυσματικό χώρο, ούτε στα αρχεία των  $coefficients_{2_i}$  διασφαλίζεται ότι ο MLP τα βλέπει πρώτη φορά και δεν τίθεται θέμα overtrain. Έτσι όμοια δημιουργούνται 2 ομάδες αρχείων. Στο αρχείο train2 θα περιέχεται το 60% του συνολικού αριθμών των συντελεστών και στο test2 το υπόλοιπο 40%.

- Το αρχείο εκπαίδευσης  $train_{2_i}$  αποτελείται από τους πίνακες  $coefficients_{2_i}$  που έχουν την ετικέτα 0 και  $not\_coefficients_{2_j}$  που έχουν την ετικέτα 1
- Το αρχείο  $test_{2_i}$  έχει το 40% των στοιχείων που δεν χρησιμοποιήθηκαν για εκπαίδευση, ώστε να αποτελούν στοιχεία που το δίκτυο δεν έχει εκπαιδευτεί και έτσι θα δώσει έγκυρη απάντηση.

### 5.3.3 Classification

Σύμφωνα με τα αρχεία εκπαίδευσης της παραπάνω ενότητας θα γίνει η ταξινόμηση για να παρατηρηθεί αν είναι δυνατή η αυθεντικοποίηση μέσω αυτής της διαδικασίας. Η διαδικασία της ταξινόμησης έγινε με τον αλγόριθμο Multi-Layer Perceptron. Ο λόγος που επιλέχθηκε αυτός ο αλγόριθμος σε σχέση με τους υπόλοιπους αλγόριθμους που χρησιμοποιήθηκαν προηγουμένως είναι ότι ο MLP δίνει τα καλύτερα αποτελέσματα και αναλύεται στην επόμενη ενότητα.

Χρησιμοποιώντας τον αλγόριθμο MLP εφαρμόζονται 3 διαδικασίες στα δεδομένα.

#### 5.3.3.1 Classification με MLP σε όλα τα άτομα

Γίνεται εφαρμογή του αλγόριθμου MLP στα αρχεία  $train_i$  και  $test_i$  της προηγούμενης υποενότητας. Τα αρχεία αυτά εισάγονται στο λογισμικό Weka. Γίνεται χρήση διαφορετικών αρχείων για train και για test ώστε το δίκτυο να μην κάνει overtrain πάνω στα δεδομένα αυτά. Τα αποτελέσματα όπως θα δούμε και παρακάτω ήταν άκρως ικανοποιητικά.

#### 5.3.3.2 Classification με MLP σε όλα τα άτομα με εφαρμογή cost-sensitive εκπαίδευσης

Αν και τα αποτελέσματα της προηγούμενης υποενότητας ήταν αρκετά υψηλά, βασικό στοιχείο των συστημάτων αυθεντικοποίησης είναι η διατήρηση ενός χαμηλού επιπέδου false positive, ώστε να μην μπορούν να κάνουν αυθεντικοποίηση άτομα στα οποία δεν ανήκει το καρδιογράφημα. Έτσι σε αυτή την υποενότητα εφαρμόζεται ο cost-sensitive MLP αλγόριθμος που υλοποιεί το Weka, στον οποίο μπορούμε να εισάγουμε έναν πίνακα με ποινές τις οποίες επιβάλλει ο αλγόριθμος κατά την διάρκεια της εκπαίδευσης. Αυτή η διαδικασία εφαρμόζεται για να βρούμε για κάθε ασθενή την βέλτιστη ποιότητα που πρέπει να εφαρμοστεί στην εκπαίδευση του κάθε ασθενή ώστε να ελαχιστοποιηθεί το false positive rate (FPR) διατηρώντας το true positive rate (TPR) πάνω από 90%. Αυτό σημαίνει ότι ελαχιστοποιείται ο κίνδυνος να εισέλθει στο σύστημα κάποιος μη εξουσιοδοτημένος με τίμημα στην χειρότερη περίπτωση 1 στις 10 φορές να ζητηθεί από τον έγκυρο χρήστη να επανατοποθετήσει τα στοιχεία του για δεύτερη αυθεντικοποίηση.

Έτσι εφαρμόζεται η εξής διαδικασία:



Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος

- Στα αρχεία  $train_i$  και  $test_i$  εφαρμόζεται εκπαίδευση με τον αλγόριθμο cost-sensitive MLP και τις ποινές [0, 5, 10, 15, 20, 25, 30, 35, 40, 45, 50]
- από τα αποτελέσματα που προκύπτουν λαμβάνονται οι πίνακες TPR, FPR και συνδιάζονται ώστε να έχουμε για κάθε άτομο τα αποτελέσματα από την εκπαίδευση με διαφορετικές ποινές.
- Για κάθε ασθενή γίνεται επεξεργασία των 2 πινάκων FPR, TPR ώστε να βρεθεί το ελάχιστο FPR δεδομένου ότι το TPR πρέπει να είναι μεγαλύτερο του 90%. Συνθήκη τερματισμού αποτελεί επίσης όταν το FPR είναι ίσο σε δύο διαδοχικές εκπαιδεύσεις (διαδοχικές είναι οι εκπαιδεύσεις που η διαφορά της ποινής των δύο εκπαιδεύσεων είναι ίση με 5).
- Για κάθε άτομο επιλέγεται η ποινή η οποία θα πληρεί τουλάχιστον μία από τις παραπάνω συνθήκες.

Η εκπαίδευση με αυτόν τον τρόπο μεγιστοποιεί την ασφάλεια του συστήματος προκαλώντας την ελάχιστη δυνατή ενόχληση όσον αφορά την εμπειρία χρήσης. Διατηρώντας το  $TPR > 90\%$  ο χρήστης θα χρειαστεί μόνο 1 φορά στις 10 να εισάγει ξανά τα στοιχεία του. Με αυτό το μικρό τίμημα όπως παρουσιάζεται και παρακάτω η ασφάλεια του συστήματος αυξάνεται δραματικά.

### 5.3.3.3 Classification με MLP σε άτομα εκτός του διανυσματικού χώρου

Σε αυτή την ενότητα γίνεται χρήση των  $train2_i$  και  $test2_i$  που δημιουργήθηκαν στην προηγούμενη ενότητα. Αυτά τα αρχεία περιέχουν άτομα που δεν συμμετέχουν στην δημιουργία του διανυσματικού χώρου και των κυρίων συνιστωσών. Όμοια και η αυθεντικοποίηση του κάθε ατόμου γίνεται ενάντια σε άτομα που δεν συμμετέχουν ούτε στην κατασκευή του διανυσματικού χώρου ούτε και την διαδικασία της εκπαίδευσης. Η διενέργεια αυτού του πειράματος είναι άκρως σημαντική καθώς βλέπουμε ότι 30 άτομα είναι αρκετά για την δημιουργία του διανυσματικού χώρου και των κυρίων συνιστωσών που χρειάζονται για να εκφράσουμε τα υπόλοιπα άτομα. Επίσης συμπεραίνεται ότι η συμμετοχή ενός ατόμου είναι ανεξάρτητη του αποτελέσματος της αυθεντικοποίησης αυτού του ατόμου με την χρήση του χώρου που συμμετείχε, καθώς σύμφωνα με τις προηγούμενες ενότητες θα μπορούσε να προκύψει ότι τα υψηλά αποτελέσματα προκύπτουν επειδή τα σήματα συμμετέχουν στην κατασκευή του διανυσματικού χώρου. Αυτό όμως αποδεικνύεται εδώ ότι δεν ισχύει.

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος

## 6. ΠΕΙΡΑΜΑΤΑ ΚΑΙ ΑΠΟΤΕΛΕΣΜΑΤΑ

### 6.1 Συλλογή δεδομένων

Αρχικά έγινε λήψη από την Βάση Δεδομένων **Physionet** ή **Diagnostic ECG Database** [14]. Η βάση αυτή κατά κύριο λόγο χρησιμοποιείται για ανίχνευση παθήσεων της καρδιάς και αποτελεί την μεγαλύτερη δωρεάν διαθέσιμη βάση ηλεκτροκαρδιογραφημάτων (ECG). Στο σύνολο αυτό περιέχονται 294 ασθενείς με τα εξής χαρακτηριστικά:

- 16 κανάλια εισόδου, (14 για ECGs, 1 για αναπνοή, 1 για τροφοδοσία ρεύματος)
- Τάση εισόδου:  $\pm 16$  mV, compensated offset voltage up to  $\pm 300$  mV
- Αντίσταση εισόδου: 100  $\Omega$  (DC)
- Ανάλυση: 16 bit με 0.5  $\mu\text{V}/\text{LSB}$  (2000 A/D μονάδες ανά mV)
- Εύρος: 0 - 1 kHz (σύγχρονη δειγματοληψία σε όλα τα κανάλια)
- Θόρυβος τάσης: max. 10  $\mu\text{V}$  (pp), αντίστοιχα 3  $\mu\text{V}$  (RMS) με βραχυκυκλωμένη την είσοδο
- Online καταγραφή αντίστασης του δέρματος
- Καταγραφή επιπέδων θορύβου κατά την διάρκεια της συλλογής των σημάτων

Η βάση περιέχει 549 ασθενής από 290 άτομα (ηλικίας 17 με 87, μέση τιμή 57.2, 209 άνδρες, μέση ηλικία 55.5, και 81 γυναίκες, μέσης ηλικίας 61.6). Κάθε άτομο έχει από 1 έως 5 δειγματοληψίες. Κάθε δειγματοληψία αποτελείται από 15 σήματα τα οποία καταγράφονται ταυτόχρονα: τα συμβατικά 12 ηλεκτρόδια (i, ii, iii, avr, avl, avf, v1, v2, v3, v4, v5, v6) μαζί με τα 3 Frank ηλεκτρόδια ECGs (vx, vy, vz). Κάθε σήμα ψηφιοποιείται με συχνότητα δειγματοληψίας 1000 δείγματα ανά δευτερόλεπτο, με ανάλυση 16 bit σε ένα εύρος  $\pm 16.384$  mV.

Στην συνέχεια για να υπάρχει ομοιομορφία καθώς και πληθώρα εγγραφών στο Data Set έγινε επιλογή μόνο αυτών των ατόμων οι οποίοι έχουν 4 δειγματοληψίες, διότι οι ήταν οι μόνοι που μπορούσαν να δημιουργήσουν ένα αρκετά μεγάλο Data Set με επαρκή αριθμό σημάτων ανά ασθενή. Επόμενο βήμα στην διαδικασία ήταν να μετατραπούν τα σήματα, με το toolbox που προσφέρει η Physiobank(wfdb2mat), από δυαδικά αρχεία που περιέχουν


Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος

δείγματα του ψηφιοποιημένου σήματος (.dat) σε αρχεία κατάλληλα για επεξεργασία στο Matlab (.mat). Συνεπώς το Data-set αποτελείται από 50 άτομα που έχουν 4 δειγματοληψίες του 115 δευτερολέπτων ο καθένας.

## 6.2 Feature extraction

### 6.2.1 Non-Fiducial feature extraction με χρήση Fourier, Cosine και Wavelet

Όπως ορίστηκε στην προηγούμενη ενότητα τα σήματα φιλτράρονται και στην συνέχεια γίνεται κατάτμιση αυτών σε τμήματα των 5 δευτερολέπτων. Έτσι είναι έτοιμα για την ανάλυσή τους με τους μετασχηματισμούς Fourier, Cosine και Wavelet.

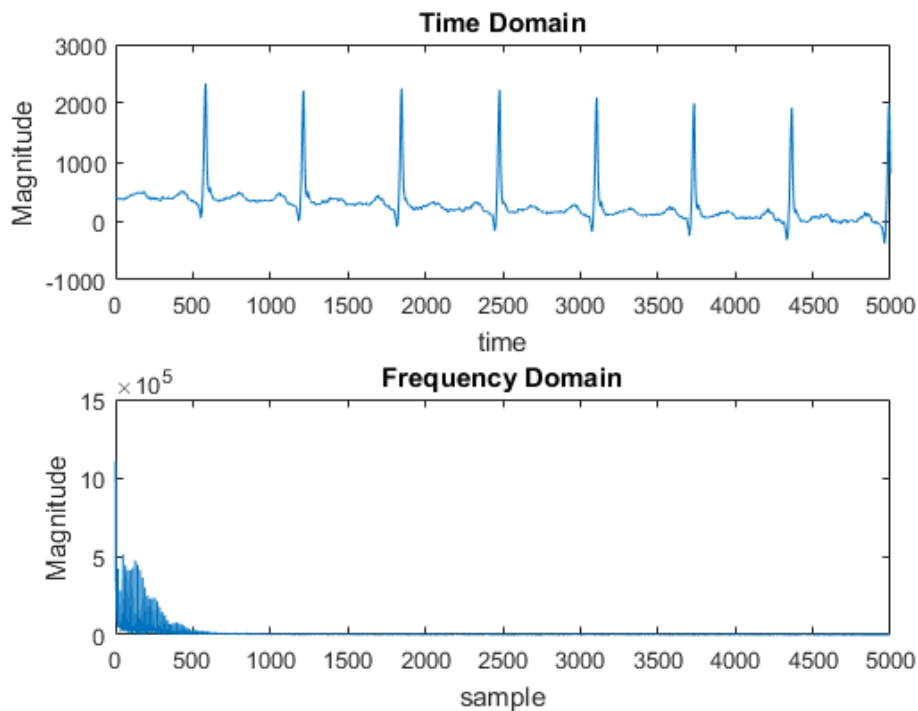


Σχήμα 6.1: Καρδιακό σήμα μετά από το φιλτράρισμα με το φίλτρο Butterworth

#### 6.2.1.1 Διακριτός μετασχηματισμός Fourier

Σε κάθε κομμάτι των 5 δευτερολέπτων εφαρμόζεται ο διακριτός μετασχηματισμός Fourier(DFT). Όπως βλέπουμε στο Σχήμα 6.2 η πληροφορία συγκεντρώνεται στις χαμηλές συχνότητες. Στην συνέχεια μετά το μετασχηματισμό οι 20 μεγαλύτεροι συντελεστές από κάθε τμήμα, εκτός από το συντελεστή στην θέση  $a_0$  που είναι η συνιστώσα DC, εισάγονται σε αρχεία Weka για την εκπαίδευση αλγορίθμων μηχανικής γνώσης.

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος



Σχήμα 6.2: Σήμα της καρδιάς στο πεδίο του χρόνου και στο πεδίο της συχνότητας

### 6.2.1.2 Discrete Cosine Transformation

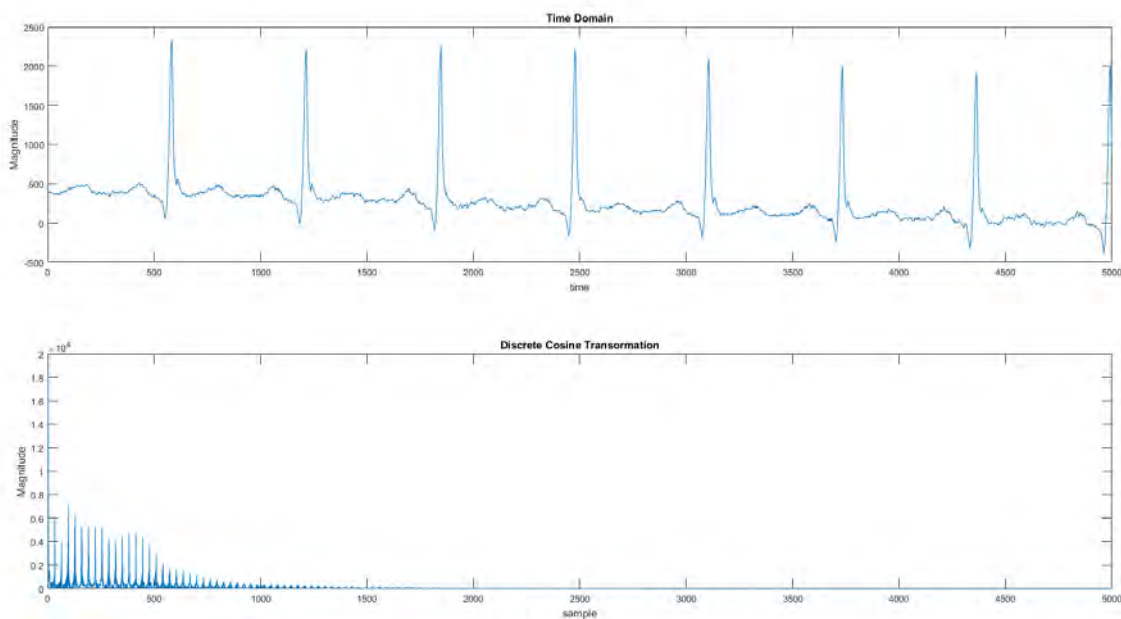
Όμοια με το διακριτό μετασχηματισμό Fourier τα φιλτραρισμένα τμήματα των 5 δευτερολέπτων υπόκεινται διακριτό μετασχηματισμό συνημίτονων (DCT). Στο Σχήμα 6.3 εικονίζεται ένα σήμα στο πεδίο του χρόνου καθώς και ο διακριτός μετασχηματισμός συνημίτονων αυτού.

Στην συνέχεια επιλέγονται οι 20 μεγαλύτεροι συντελεστές πλην την συνιστώσας  $a_0$  και εισάγονται σε αρχεία κατάλληλα για εκπαίδευση στο Weka.

### 6.2.1.3 Wavelet decomposition

Τρίτος μετασχηματισμός που εφαρμόζεται στα τμήματα είναι ο μετασχηματισμός Wavelet. Το κυματίδιο που επιλέχθηκε είναι το κυματίδιο Daubechies 9ης τάξης. από την απόσύνθεση κρατήσαμε μόνο το τρίτο επίπεδο, από το οποίο χρησιμοποιήθηκαν όμοια με πριν οι 20 μεγαλύτεροι συντελεστές. Αυτοί οι συντελεστές εισάγονται σε αρχεία Weka για να γίνει η εκπαίδευση.

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος



Σχήμα 6.3: Μετασχηματισμός συνημίτονων σε καρδιακό σήμα

## 6.2.2 PCA

Σύμφωνα με την διαδικασία που αναλύθηκε στην προηγούμενη ενότητα τα χαρακτηριστικά που θα εξάγουμε για να κάνουμε το machine learning προκύπτουν από τις κύριες συνιστώσες των καρδιακών παλμών. Έτσι προβάλλοντας κάθε καρδικό παλμό πάνω στον ιδιοχώρο που κατασκευάστηκε λαμβάνεται ένα μοναδικό σύνολο από συντελεστές που θα χρησιμοποιηθούν.


Στο Σχήμα 6.5 φαίνονται δύο παλμοί από διαφορετικά άτομα και ακόμα και οπτικά φαίνεται η διαφορά στις συνιστώσες τους.

## 6.3 Classification

### 6.3.1 Machine learning

Σύμφωνα με τους συντελεστές της προηγούμενης ενότητας δημιουργούνται τα αρχεία εκπαίδευσης για το Weka. Η ταξινόμηση θα γίνει σε 2 κλάσεις, είτε το άτομο θα αυθεντικοποιείται ορθά είτε θα απορρίπτεται. Για να είναι συνεπής η εκπαίδευση θέλουμε τα δεδομένα από τις δύο κλάσεις να είναι ισομεγέθη. Για παράδειγμα αν παίρνουμε από ένα

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος



Σχήμα 6.4: Τρία επίπεδα διάσπασης Wavelet

άτομο 90 συντελεστές, από του υπόλοιπους 49 θα πάρουμε από 2 συντελεστές από τον καθένα ώστε να είναι σχεδόν ίσα σε μέγεθος.


Η εκπαίδευση στο Weka γίνεται με τους αλγορίθμους:

- Multi-Layer-Perceptron
- K-means
- RBFNetwork
- RandomForest

Τα αποτελέσματα φαίνονται στον παρακάτω πίνακα για κάθε μετασχηματισμό σε συνδυασμό με κάθε αλγόριθμο.

Τα καλύτερα αποτελέσματα προέρχονται από τον συνδυασμό Wavelet και Random Forest και είναι **88.447%**

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος



Σχήμα 6.5: Οι κύριες συνιστώσες δύο καρδιακών παλμών από διαφορετικά άτομα.

### 6.3.2 Deep learning

Σε αυτή την ενότητα παρουσιάζεται η δημιουργία και η εκπαίδευση ενός deep neural network. Η υλοποίηση του έγινε στην βιβλιοθήκη της Python Tensorflow που ανήκει στη Google. Επειδή τα deep learning δίκτυα έχουν την δυνατότητα για μεγάλο αριθμό εισόδων γίνεται ένωση και των τριών αρχείων της προηγούμενης ενότητας (Fourier, Cosine, Wavelet). Συνεπώς έχουμε 60 συντελεστές για κάθε τμήμα των 5 δευτερολέπτων. Στο Σχήμα 6.6 φαίνεται η δομή του δικτύου. Έχει 60 νευρώνες εισόδου για τους συντελεστές από τους 3 μετασχηματισμούς, 3 κρυφά επίπεδα με [100, 200, 100] κρυφούς νευρώνες αντίστοιχα και 2 νευρώνες εξόδου για τις 2 κλάσεις που έχουμε ορίσει.

Το αποτέλεσμα που δίνει το δίκτυο όταν λαμβάνει ως είσοδο το ίδιο training και test set που είχαν και οι προηγούμενοι machine learning αλγόριθμοι είναι: **Accuracy: 0.8016%**

#### 6.3.2.1 ECGSyn

Λόγω της μικρής ποσότητας δεδομένων και του μεγάλου βαθμού ελευθερίας τα αποτελέσματα ήταν μικρότερα από το αναμενόμενο. Έτσι με το εργαλείο της Physionet ECGSyn, που είναι μια γεννήτρια τεχνητών ηλεκτροκαρδιογραφήματων παράγουμε πε-



Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος

Transformation	Classification	Correct %	TP rate	FP rate	ROC Area
Cosine	KNN	81.616	0.832	0.199	0.817
Cosine	MLP	81.409	0.86	0.233	0.871
Cosine	RBFN	80.233	0.912	0.301	0.855
Cosine	RandForest	83.993	0.881	0.199	0.903
Fourier	KNN	82.53	0.867	0.214	0.827
Fourier	MLP	82.601	0.87	0.215	0.886
Fourier	RBFN	81.076	0.911	0.284	0.871
Fourier	RandForest	85.204	0.89	0.183	0.914
Wavelet	KNN	86.974	0.908	0.166	0.871
Wavelet	MLP	85.753	0.887	0.17	0.918
Wavelet	RBFN	85.873	0.919	0.198	0.909
Wavelet	RandForest	88.447	0.917	0.146	0.952

Πίνακας 6.1: Αποτελέσματα διαφορετικών μετασχηματισμών και αλγορίθμων ταξινόμησης

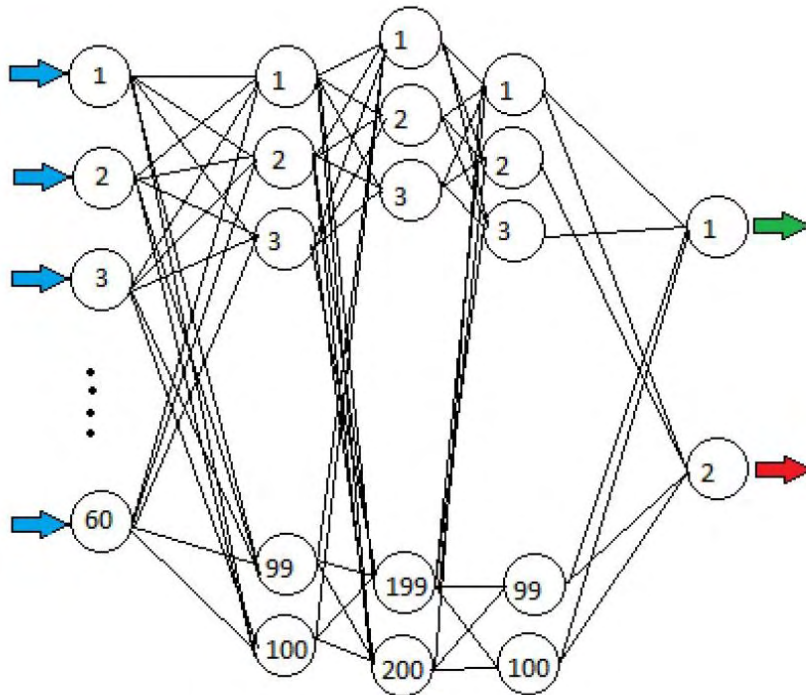
ρισσότερα δεδομένα για δοκιμή στο deep neural network. ECGSYN παράγει συνθετικά ECG σήματα με μέσο καρδιακό ρυθμό ορισμένο από το χρήστη, αριθμό καρδιακών ρυθμών, συχνότητα δειγματοληψίας, μορφολογία της κυματομορφής (P, Q, R, S, και T χρόνο εμφάνισης, πλάτος και διάρκεια), τυπική απόκλιση της RR διάρκειας και του LF/HF λόγου (ένα μέτρο της σχετικής συνεισφοράς των χαμηλών και υψηλών συστατικών των συχνοτήτων της ακολουθίας RR στην συνολική μεταβλητότητα του καρδιακού ρυθμού).

Αξιοποιώντας 3 ζεύγη διαφορικών εξισώσεων, το ECGSYN αναπαράγει πολλά από τα χαρακτηριστικά του ανθρώπινου ECG, περιλαμβάνοντας χτύπο-με-χτύπο διαφοροποίηση σε μορφολογία και διάρκεια, αρρυθμία λόγω του αναπνευστικού συστήματος, της εξάρτησης του QT στον καρδιακό ρυθμό, και διαμόρφωση πλάτους της R-κορυφής. Η έξοδος από το ECGSYN μπορεί να χρησιμοποιηθεί με βιοϊατρικές τεχνικές επεξεργασίας σήματος οι οποίες χρησιμοποιούνται για τον υπολογισμό κλινικών στατιστικών από ECG σήματα.

Έτσι παρήχθησαν για 10 άτομα 1000 δειγματοληψίες των 5 δευτερολέπτων για τον καθένα ώστε να είναι αρκετά για να εκπαιδεύσουν το δίκτυο. Όμοια χωρίσαμε τα αρχεία για την εκπαίδευση του δικτύου 60/40 για train και test. Έτσι κάθε αρχείο είχε 1000 δειγματοληψίες που ανήκουν στο άτομο που εξετάζουμε και άλλες 1000 από τους άλλους 9. Τα αποτελέσματα με την χρήση του νέου σετ δεδομένων είναι: **Accuracy:0.857678%**

Αν και τα αποτελέσματα του deep learning δικτύου είναι μικρότερα από τους machine learning αλγορίθμους παρατηρείται ότι οι δέκα καλύτεροι ασθενείς από το deep learning δίκτυο έχουν καλύτερα ποσοστά από τους 10 καλύτερους από τους machine learning αλ-

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος



Σχήμα 6.6: Δομή του deep neural network

γορίθμους.

### 6.3.3 Machine learning στις συνιστώσες PCA

### 6.3.4 Απόσταση

Αρχικά λόγω της εμφανούς οπτικής διαφοράς των συνιστωσών έγινε δοκιμή με κριτήριο την Manhattan απόσταση μεταξύ αυτών.

Στο Σχήμα 6.9 εικονίζεται η απόσταση μεταξύ της απόστασης των κυρίων συνιστωσών ενός ατόμου ενάντια στο template αυτού του ατόμου στη βάση (πράσινο) καθώς και ενάντια σε άλλα άτομα της βάσης(κόκκινο).Είναι εμφανές ότι οι δύο αυτές περιοχές επικαλύπτονται και για αυτό το λόγο η τεχνική αυτή έδωσε **Accuracy: 35.65%**. Καθόλου ικανοποιητικό αποτέλεσμα καθώς στην αυθεντικοποίηση ιδανικά θέλουμε το μεγαλύτερο πράσινο στο Σχήμα 6.9 να είναι μικρότερο από το μικρότερο κόκκινο.

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος



Σχήμα 6.7: Η ακρίβεια του δικτύου κατά την διάρκεια της εκπαίδευσης

### 6.3.5 Machine learning και PCA


Έτσι στην συνέχεια δημιουργούνται τα training και test set για κάθε άτομο προβάλλοντας κάθε καρδιακό παλμό στο διανυσματικό χώρο που δημιουργήσαμε. Κάθε αρχείο περιέχει τους 20 κύριες συνιστώσες που προκύπτουν από την προβολή στον διανυσματικό χώρο. Τα αρχεία περιείχαν τους 20 συντελεστές των πινάκων *coef fecients, not\_coef fecients* συνπώς έχουμε 2 κλάσεις σηματοδοτημένες με 0 και 1 αντίστοιχα. Καθώς και το αρχείο *train<sub>i</sub>,test<sub>i</sub>* που περιέχει σήματα του ατόμου έναντι σημάτων των υπολοίπων 49 ατόμων. Η εκπαίδευση στο Weka γίνεται με τους εξής αλγορίθμους.

Αρχικά έγινε δοκιμή με 5 αλγορίθμους :

- Multi-Layer-Perceptron
- K-Means
- RBFNetwork
- RandomForest
- RBFClassifier

Τα αποτελέσματα που παίρνουμε εικονίζονται στον Πίνακα 6.2. Οι δύο καλύτεροι αλγόριθμοι είναι MLP και PCA και για αυτό επιλέγονται για cost-sensitive εκπαίδευση.

dnn/logits\_activation




Σχήμα 6.8: Η λογιστική συνάρτηση ενεργοποίησης σε κάθε κύκλο εκπαίδευσης

### 6.3.5.1 Cost-sensitive εκπαίδευση

Πραγματοποιώντας εκπαίδευση με τις ποινές που ορίστηκαν στην προηγούμενη ενότητα ο αλγόριθμος Random Forest δίνει πολύ χαμηλότερα αποτελέσματα από τον MLP. Τα αποτελέσματα του Random Forest εικονίζονται στον Πίνακα 6.3. Έτσι επιλέγεται η εκπαίδευση με ποινές να γίνει με τον MLP. Εφαρμόζοντας τις ποινές που ορίστηκαν και το κριτήριο το true positive rate να είναι μεγαλύτερο του 90% με σκοπό να μειώσουμε το false negative rate, να κάνουμε δηλαδή το σύστημα μας πιο ασφαλές.

Στο Σχήμα 6.10 βλέπουμε ότι 37 άτομα δεν χρειάστηκαν κάποια ποινή για να ικανοποιήσουν τα κριτήρια που ορίστηκαν. Και για αυτό τα αποτελέσματα ήταν άκρως ικανοποιητικά καθώς μειώσαμε το **False positive rate** κατά 50% της αρχικής τιμής του (από **0.02** σε **0.01**) και μειώνοντας την απόδοση **Accuracy: 98.7607%**, δηλαδή ούτε 2% από την αρχική επίδοση του MLP. Έτσι καταφέραμε να κάνουμε το σύστημα κατά 50% πιο ασφαλές με ένα μικρό τίμημα να χρειαστεί κάποια φορά ο χρήστης να εισάγει δεύτερη φορά τα δεδομένα του.

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος



Σχήμα 6.9: ποστάσεις Manhattan μεταξύ κυρίων συνιστοσών ενώς ατόμου

### 6.3.5.2 Training με μικρότερο διανυσματικό χώρο

Όπως ορίσαμε στην προηγούμενη ενότητα έναν μικρότερο χώρο από το σύνολο των ατόμων, προβάλουμε πάνω σε αυτόν άτομα που δεν συμμετείχαν στην κατασκευή του για να διαπιστώσουμε αν έπαιζε κάποιο ρόλο στα υψηλά αποτελέσματα. Τα αποτελέσματα ήταν και σε αυτήν την περίπτωση **Accuracy: 99.1466%**, που σημαίνει ότι ακόμα και 30 άτομα είναι ικανά να δημιουργήσουν έναν διανυσματικό χώρο ικανό να εντοπίσει την διαφοροποίηση ανάμεσα στους παλμούς.

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος

Transformation	Classification	Correct
KNN	99.0620	0.9680
MLP	99.2746	0.9795
RBFN	98.0540	0.9552
RandForest	99.4103	0.9734
RBF Classifier	96.5988	0.9599


Πίνακας 6.2: Αποτελέσματα 5 διαφορετικών αλγορίθμων με τα ίδια training και test set

Penalty	Classification
Penalty_0	0.9680
Penalty_10	0.7556
Penalty_30	0.2898
Penalty_50	0.0167

Πίνακας 6.3: Αποτελέσματα cost-sensitive εκπαίδευσης στον αλγόριθμο Random Forest

Σύνολο ποινών σε όλα τα άτομα

- Ποινή 0
- Ποινή 5
- Ποινή 10
- Ποινή 15
- Ποινή 30
- Ποινή 35
- Ποινή 45



Σχήμα 6.10: Αριθμός ατόμων που εκπαιδεύτηκε με κάθε ποινή

## 7. ΣΥΜΠΕΡΑΣΜΑΤΑ

Αυτή η πτυχιακή εργασία αφορά την βιομετρική αυθεντικοποίηση με βάση το ηλεκτροκαρδιογράφημα. Υπήρχε κάποιο ερευνητικό υπόβαθρο που ήταν ανομοιόρφο ως προς τις τεχνικές που χρησιμοποιούσε στην προεπεξεργασία, εξαγωγή χαρακτηριστικών και ταξινόμηση. Οπότε αρχικά δημιουργήσαμε μία κοινή βάση για να γίνει πείραμα και να διαπιστωθεί ποια μεθοδολογία από την βιβλιογραφία παράγει τα πιο έμπιστα αποτελέσματα.

Για να υπάρχει μία κοινή βάση ώστε το πείραμα να είναι αξιόπιστο όλα τα πειράματα έγιναν στο ίδιο Data Set, το ECG της Physionet, ώστε να υπάρχει πλήρης ομοιότητα ανάμεσα στα παράλληλα πειράματα και τα μόνα στάδια διαφοροποίησης να είναι αυτά που αναφέρονται παρακάτω. Το σύνολο ατόμων που δημιουργήσαμε περιέχει 50 άτομα, που το καθένα έχει 4 δειγματοληψίες του 1:55 λεπτών. Αρχικά έγινε δοκιμή τριών μετασχηματισμών οι οποίοι ήταν οι πιο δημοφιλείς στην βιβλιογραφία: Discrete Fourier Transformation, Discrete Cosine Transformation και Wavelet Decomposition. Από αυτούς τους μετασχηματισμούς χρησιμοποιήθηκαν οι 20 σημαντικότεροι συντελεστές, ως είσοδος στο επόμενο στάδιο του πειράματος, την ταξινόμηση των δειγμάτων.

Και για αυτό το στάδιο υπήρχε στην βιβλιογραφία πληθώρα αλγορίθμων και στατιστικών τεχνικών οπότε επελέχθηκαν οι 4 πιο δημοφιλείς: K-Means, Multi-Layer Perceptron, Random Forest και Radial Basis Function Network. Και στους 4 αλγορίθμους εισήχθησαν ακριβώς τα ίδια σετ εκπαίδευσης ώστε να δούμε ποιος συνδυασμός μετασχηματισμού-αλγόριθμου μηχανικής γνώσης είναι ο καλύτερος με βάση την υπάρχουσα βιβλιογραφία. Τα καλύτερα αποτελέσματα τα έδωσε το ζεύγος Wavelet-Random Forest με **Accuracy: 88.447%**. Τα αποτελέσματα είναι χαμηλότερα από την αντίστοιχη βιβλιογραφία καθώς οι εργασίες με τις αντίστοιχες τεχνικές χρησιμοποιούν πολύ μικρότερα data set (της τάξεως των 10 ατόμων).

Στην συνέχεια έγινε δοκιμή αυθεντικοποίησης με χρήση deep neural network. Λόγω του μεγάλου αριθμού εισόδων καθώς και κρυφών νευρώνων που έχουν αυτά τα δίκτυα θεωρήσαμε ότι θα είχαν καλύτερη απόδοση. Έτσι δώσαμε ως είσοδο τους 20 συντελεστές και από τους 3 μετασχηματισμούς, δηλαδή 60 στοιχεία ως είσοδο. Αναμέναμε λόγω της μεγαλύτερης πληροφορίας που είχε ως είσοδο να πέραμε μεγαλύτερα αποτελέσματα σε σχέση με τους αλγόριθμους μηχανικής γνώσης που δοκιμάστηκαν στα ίδια δεδομένα. Όμως τα αποτελέσματα ήταν **Accuracy: 0.8016%**, πολύ χειρότερα από το μικρότερο αλ-

γόριθμο μηχανικής γνώσης. Αυτό οφείλεται στον μικρό αριθμό δεδομένων ανά άτομο, αφού το deep network δεν είχε αρκετά δεδομένα ώστε να εκπαιδευτεί σωστά λόγω του υψηλού βαθμού ελευθερίας που έχει. Για να διαπιστωθεί όμως αν τα deep networks είναι κατάλληλα για προβλήματα βιομετρικής αυθεντικοποίησης παράξαμε τεχνητά ηλεκτροκαρδιογραφήματα με το ECGsyn της Physionet. Παράγοντας 1000 δειγματοληψίες ανά άτομο πετυχαίνουμε **Accuracy: 0.857678%**, που είναι ένα σχετικά πιο ικανοποιητικό ποσοστό.

Τελευταία τεχνική που υλοποιήσαμε ήταν η εξαγωγή των χαρακτηριστικών του σήματος με την χρήση του αλγορίθμου PCA και στη συνέχεια εκπαίδευση με machine learning αλγορίθμους. Αρχικά το διαφορετικό σε σχέση με τις προηγούμενες τεχνικές αυτής της εργασίας είναι ότι δεν έγινε κατάτμηση σε παράθυρα των 5 δευτερολέπτων αλλά αυτούσια εξαγωγή των καρδιακών παλμών με τον εντοπισμό των κορυφών R. Στην συνέχεια κατασκευάζοντας τον διανυσματικό χώρο με ένα ποσοστό των καρδιακών παλμών όλων των ατόμων τον χρησιμοποιούμε για να προβάσουμε πάνω σε αυτό τους καρδιακούς παλμούς ώστε να πάρουμε τις κύριες συνιστώσες για κάθε άτομο. Αυτές τις κύριες συνιστώσες τις χρησιμοποιούμε για την δημιουργία αρχείων εκπαίδευσης για machine learning. Τα αποτελέσματα ήταν πέρα από κάθε προσδοκία καθώς ο αλγόριθμος MLP έδωσε τα καλύτερα αποτελέσματα με **Accuracy: 99.2746%**.

Επόμενο βήμα ήταν να αυξήσουμε την ασφάλεια του συστήματος αυθεντικοποίησης. Για να γίνει αυτό εφαρμόζουμε πάνω στον αλγόριθμο MLP cost-sensitive τεχνικές εκπαίδευσης. Που σημαίνει όταν συναντάει κατά την εκπαίδευση μία περίπτωση false positive να δίνει μία μεγάλη ποινή το δίκτυο ώστε να "αποφεύγει" να ταξινομεί περιπτώσεις στις false negative περιπτώσεις. Έτσι επιτύχαμε με μείωση του συνολικού accuracy του συστήματος περίπου 2% να αυξήσουμε την ασφάλεια του συστήματος κατά 50%.

Επίσης έπρεπε να διαπιστωθεί αν η συμμετοχή όλων των ατόμων στην κατασκευή του διανυσματικού χώρου παίζει ρόλο στα υψηλά ποσοστά ορθής αυθεντικοποίησης που έχει το σύστημα. Συνεπώς δημιουργήθηκε νέος διανυσματικός χώρος που περιείχε μόνο τα 30 από τα 50 άτομα. Οπότε με τα 20 άτομα που δεν υπάρχουν στον ιδιοχώρο προβάλλονται σε αυτόν και η εκπαίδευση στο MLP δίκτυο γίνεται με αυτούς τους νέους συντελεστές. Τα αποτελέσματα ήταν εξίσου υψηλά **Accuracy: 99.1466%**. Η διαφορά με το αρχικό πείραμα όπου συμμετέχουν και τα 50 άτομα είναι πολύ μικρή και θεωρείται στατιστικά ασήμαντη.

Κλείνοντας συμπαιραίνουμε ότι με τις κατάλληλες τεχνικές προεπεξεργασίας το



Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος

ηλεκτροκαρδιογράφημα είναι ένα πολύ ισχυρό βιομετρικό χαρακτηριστικό με ασφάλεια όμοια με τα πιο δημοφιλή χαρακτηριστικά. Τέλος πρέπει να αντιμετωπιστεί το ζήτημα της προστασίας των προσωπικών δεδομένων, καθώς δεν γίνεται να αποθηκεύεται αυτούσιος ο καρδιακός παλμός του ασθενή ούτε και οι συντελεστές από τους μετασχηματισμούς που δοκιμάστηκαν. Από το σήμα της καρδιάς μπορούν να εξαχθούν πληροφορίες για την υγεία του ατόμου το οποίο θα έχει επιπτώσεις στην προσωπική και επαγγελματική του ζωή. Επόμενος στόχος αποτελεί να υλοποιήσουμε πάνω στο σύστημα που αναπτύξαμε το επιπλέον στάδιο των cancelable βιομετρικών. Δηλαδή την εφαρμογή ενός μη αντιστεπτού μετασχηματισμού στους συντελεστές που θα αποθηκεύονται ώστε να μην μπορεί να συσχετιστούν με το αρχικό σήμα αλλά ταυτόχρονα μπορούν να χρησιμοποιηθούν για μαθηματικές πράξεις.

Χρήση μεθόδων μηχανικής μάθησης για την ανάπτυξη συστήματος αυθεντικοποίησης μέσω δεδομένων ηλεκτροκαρδιογραφήματος

## ΒΙΒΛΙΟΓΡΑΦΙΑ

- [1] Gonzalo Bailador, Carmen Sanchez-Avila, Javier Guerra-Casanova, and Alberto de Santos Sierra. Analysis of pattern recognition techniques for in-air signature biometrics. *Pattern Recognition*, 44(10-11):2468–2478, 2011.
- [2] Lena Biel, Ola Pettersson, Lennart Philipson, and Peter Wide. Ecg analysis: a new approach in human identification. *IEEE Transactions on Instrumentation and Measurement*, 50(3):808–812, 2001.
- [3] Cheng Bo, Lan Zhang, Xiang-Yang Li, Qiuyuan Huang, and Yu Wang. Silentsense: silent user identification via touch and movement behavioral biometrics. In *Proceedings of the 19th annual international conference on Mobile computing & networking*, pages 187–190. ACM, 2013.
- [4] Ognian Boumbarov, Yuliyana Velchev, and Strahil Sokolov. Ecg personal identification in subspaces using radial basis neural networks. In *Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications, 2009. IDAACS 2009. IEEE International Workshop on*, pages 446–451. IEEE, 2009.
- [5] Kevin W Bowyer, Karen P Hollingsworth, and Patrick J Flynn. A survey of iris biometrics research: 2008–2010. In *Handbook of iris recognition*, pages 23–61. Springer, 2016.
- [6] Ronald Newbold Bracewell and Ronald N Bracewell. *The Fourier transform and its applications*, volume 31999. McGraw-Hill New York, 1986.
- [7] Martin D Buhmann. Radial basis functions. *Acta numerica*, 9:1–38, 2000.
- [8] Mark Burge and Wilhelm Burger. Ear biometrics. In *Biometrics*, pages 273–285. Springer, 1996.
- [9] Adrian DC Chan, Mohyeldin M Hamdy, Armin Badre, and Vesal Badee. Wavelet distance measure for person identification using electrocardiograms. *IEEE transactions on instrumentation and measurement*, 57(2):248–253, 2008.
- [10] Yong Jian Chin, Thian Song Ong, Michael KO Goh, and Bee Yan Hiew. Integrating palmprint and fingerprint for identity verification. In *Network and System Security, 2009. NSS'09. Third International Conference on*, pages 437–442. IEEE, 2009.

- [11] S Zahra Fatemian and Dimitrios Hatzinakos. A new ecg feature extractor for biometric recognition. In *Digital Signal Processing, 2009 16th International Conference on*, pages 1–6. IEEE, 2009.
- [12] Youssef Gahi, Meryem Lamrani, Abdelhak Zoglat, Mouhcine Guennoun, Bill Kapralos, and Khalil El-Khatib. Biometric identification system based on electrocardiogram data. In *New Technologies, Mobility and Security, 2008. NTMS'08.*, pages 1–5. IEEE, 2008.
- [13] Xavier Glorot and Yoshua Bengio. Understanding the difficulty of training deep feedforward neural networks. In *Proceedings of the thirteenth international conference on artificial intelligence and statistics*, pages 249–256, 2010.
- [14] A. L. Goldberger, L. A. N. Amaral, L. Glass, J. M. Hausdorff, P. Ch. Ivanov, R. G. Mark, J. E. Mietus, G. B. Moody, C.-K. Peng, and H. E. Stanley. PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals. *Circulation*, 101(23):e215–e220, 2000 (June 13). Circulation Electronic Pages: <http://circ.ahajournals.org/content/101/23/e215.full> PMID:1085218; doi: 10.1161/01.CIR.101.23.e215.
- [15] Steven A Israel, John M Irvine, Andrew Cheng, Mark D Wiederhold, and Brenda K Wiederhold. Ecg to identify individuals. *Pattern recognition*, 38(1):133–142, 2005.
- [16] Ian T Jolliffe. Principal component analysis and factor analysis. In *Principal component analysis*, pages 115–128. Springer, 1986.
- [17] Ajay Kumar, David CM Wong, Helen C Shen, and Anil K Jain. Personal verification using palmprint and hand geometry biometric. In *International Conference on Audio- and Video-Based Biometric Person Authentication*, pages 668–678. Springer, 2003.
- [18] Seyed Mehdi Lajevardi, Arathi Arakala, Stephen A Davis, and Kathy J Horadam. Retina verification system based on biometric graph matching. *IEEE transactions on image processing*, 22(9):3625–3635, 2013.
- [19] Ming Li and Shrikanth Narayanan. Robust ecg biometrics by fusing temporal and cepstral information. In *Pattern recognition (icpr), 2010 20th international conference on*, pages 1326–1329. IEEE, 2010.
- [20] Andy Liaw, Matthew Wiener, et al. Classification and regression by randomforest. *R news*, 2(3):18–22, 2002.

- [21] Vu Mai, Ibrahim Khalil, and Christopher Meli. Ecg biometric using multilayer perceptron and radial basis function neural networks. In *Engineering in Medicine and Biology Society, EMBC, 2011 Annual International Conference of the IEEE*, pages 2745–2748. IEEE, 2011.
- [22] Stephane G Mallat. A theory for multiresolution signal decomposition: the wavelet representation. *IEEE transactions on pattern analysis and machine intelligence*, 11(7):674–693, 1989.
- [23] Judith A Markowitz. Voice biometrics. *Communications of the ACM*, 43(9):66–73, 2000.
- [24] Ikenna Odinaka, Po-Hsiang Lai, Alan D Kaplan, Joseph A O’Sullivan, Erik J Sirevaag, and John W Rohrbaugh. Ecg biometric recognition: A comparative analysis. *IEEE Transactions on Information Forensics and Security*, 7(6):1812–1824, 2012.
- [25] Konstantinos N Plataniotis, Dimitrios Hatzinakos, and Jimmy KM Lee. Ecg biometric recognition without fiducial detection. In *Biometric Consortium Conference, 2006 Biometrics Symposium: Special Session on Research at the*, pages 1–6. IEEE, 2006.
- [26] Irene Rodriguez-Lujan, Gonzalo Bailador, Carmen Sanchez-Avila, Ana Herrero, and Guillermo Vidal-De-Miguel. Analysis of pattern recognition and dimensionality reduction techniques for odor biometrics. *Knowledge-Based Systems*, 52:279–289, 2013.
- [27] Robert K Rowe, Kristin A Nixon, and Stephen P Corcoran. Multispectral fingerprint biometrics. In *Information Assurance Workshop, 2005. IAW’05. Proceedings from the Sixth Annual IEEE SMC*, pages 14–20. IEEE, 2005.
- [28] Dennis W Ruck, Steven K Rogers, Matthew Kabrisky, Mark E Oxley, and Bruce W Suter. The multilayer perceptron as an approximation to a bayes optimal discriminant function. *IEEE Transactions on Neural Networks*, 1(4):296–298, 1990.
- [29] Sukkharak Saechia, Jeerasuda Koseeyaporn, and Paramote Wardkein. Human identification system based ecg signal. In *TENCON 2005 2005 IEEE Region 10*, pages 1–4. IEEE, 2005.
- [30] Ivan W Selesnick and C Sidney Burrus. Generalized digital butterworth filter design. *IEEE Transactions on signal processing*, 46(6):1688–1694, 1998.

- [31] B Vuksanovic and M Alhamdi. Analysis of human electrocardiogram for biometric recognition using analytic and ar modeling extracted parameters. *International Journal of Information and Electronics Engineering*, 4(6):428, 2014.
- [32] Kiri Wagstaff, Claire Cardie, Seth Rogers, Stefan Schrödl, et al. Constrained k-means clustering with background knowledge. In *ICML*, volume 1, pages 577–584, 2001.
- [33] Yongjin Wang, Foteini Agrafioti, Dimitrios Hatzinakos, and Konstantinos N Plataniotis. Analysis of human electrocardiogram for biometric recognition. *EURASIP journal on Advances in Signal Processing*, 2008(1):148658, 2007.
- [34] Yasunari Yoshitomi, Sung-Il Kim, Takako Kawano, and Tetsuro Kilazoe. Effect of sensor fusion for recognition of emotional states using voice, face image and thermal image of face. In *Robot and Human Interactive Communication, 2000. RO-MAN 2000. Proceedings. 9th IEEE International Workshop on*, pages 178–183. IEEE, 2000.
- [35] Wenyi Zhao, Arvinth Krishnaswamy, Rama Chellappa, Daniel L Swets, and John Weng. Discriminant analysis of principal components for face recognition. In *Face Recognition*, pages 73–85. Springer, 1998.
- [36] Sara Zokaee and Karim Faez. Human identification based on ecg and palmprint. *International Journal of Electrical and Computer Engineering*, 2(2):261, 2012.