



ΠΑΝΕΠΙΣΤΗΜΙΟ
ΙΩΑΝΝΙΝΩΝ

ΣΧΟΛΗ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΤΗΛΕΠΙΚΟΙΝΩΝΙΩΝ
ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΤΗΛΕΠΙΚΟΙΝΩΝΙΩΝ
ΠΜΣ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΔΙΚΤΥΩΝ

ΜΕΤΑΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ

**«ΜΕΛΕΤΗ, ΣΧΕΔΙΑΣΗ ΚΑΙ ΕΦΑΡΜΟΓΗ ΤΕΧΝΙΚΩΝ
ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΓΙΑ ΑΝΑΛΥΣΗ ΣΗΜΑΤΩΝ ΓΙΑ ΤΗΝ
ΠΑΡΑΚΟΛΟΥΘΗΣΗ ΤΗΣ ΑΝΘΡΩΠΙΝΗΣ ΔΡΑΣΤΗΡΙΟΤΗΤΑΣ»**

Λαμπρινή Παππά

Επιβλέπων: Χρυσόστομος Στύλιος
Καθηγητής

Άρτα, Ιανουάριος, 2021

**«STUDY, DESIGN AND IMPLEMENTATION OF MACHINE
LEARNING TECHNIQUES FOR SIGNAL ANALYSIS FOR
HUMAN ACTIVITY MONITORING»**

Εγκρίθηκε από τριμελή εξεταστική επιτροπή

Άρτα, 18 Ιανουαρίου 2021

ΕΠΙΤΡΟΠΗ ΑΞΙΟΛΟΓΗΣΗΣ

1. Επιβλέπων καθηγητής
Χρυσόστομος Στύλιος
Καθηγητής
2. Μέλος επιτροπής
Χρήστος Γκόγκος
Αναπληρωτής Καθηγητής
3. Μέλος επιτροπής
Αλέξανδρος Τζάλλας
Επίκουρος Καθηγητής

© Παππά Λαμπρινή, 2021.

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

Δήλωση μη λογοκλοπής

Δηλώνω υπεύθυνα και γνωρίζοντας τις κυρώσεις του Ν. 2121/1993 περί Πνευματικής Ιδιοκτησίας, ότι η παρούσα μεταπτυχιακή εργασία είναι εξ ολοκλήρου αποτέλεσμα δικής μου ερευνητικής εργασίας, δεν αποτελεί προϊόν αντιγραφής ούτε προέρχεται από ανάθεση σε τρίτους. Όλες οι πηγές που χρησιμοποιήθηκαν (κάθε είδους, μορφής και προέλευσης) για τη συγγραφή της περιλαμβάνονται στη βιβλιογραφία.

Παπά Λαμπρινή



Υπογραφή

ΕΥΧΑΡΙΣΤΙΕΣ

Θα ήταν αδιανόητο να μην ευχαριστήσω πρωτίστως τον καθηγητή κ. Χρυσόστομο Στύλιο που πίστεψε σε εμένα και μου εμπιστεύτηκε το συγκεκριμένο εξαιρετικά ενδιαφέρον ερευνητικό θέμα. Οι συμβουλές του και η καθοδήγησή του, προϊόν της ακαδημαϊκής και ερευνητικής του εμπειρίας, λειτούργησαν ως πυξίδα και δικλείδα ασφαλείας για την επιτυχή περάτωση της εργασίας. Μέσα σε ένα τέτοιο κλίμα συνεργασίας και ασφάλειας κατέστη εφικτό να εκπονήσω με ηρεμία και ζήλο τη διπλωματική μου εργασία. Το αποτέλεσμα ελπίζω να τον ανταμείψει.

Θερμές ευχαριστίες στον Δρ. κ. Πέτρο Καρβέλη που ήταν ο άμεσος συνεργάτης μου. Η υπομονή του και η άμεση ανταπόκριση στις αμέτρητες απορίες μου είναι αξιομνημόνευτη. Μέσα από την φυσική του ικανότητα να μεταλαμπαδεύει γνώση και εμπειρίες, και να προκαλεί την επιστημονική/ερευνητική περιέργεια, αισθάνομαι ότι «έκλεψα» λίγο από τον προσωπικό του αγώνα και το επιστημονικό κεφάλαιο.

Θα ήταν τρομερή παράλειψη να μην αναφερθώ στους συμφοιτητές μου. Ένα τόσο ετερογενές σύνολο ανθρώπων κατάφερε να συνεργαστεί, να μοιραστεί άγχη και αγωνίες, να ανακουφίσει, να συλλυπηθεί, να χαρεί, να φτάσει μαζί στο τέλος του δρόμου... Ελπίζω κάποιους να τους αποκαλώ φίλους και μετά από χρόνια.

Ευχαριστώ και το σύνολο των καθηγητών του μεταπτυχιακού προγράμματος σπουδών. Ο καθένας από την σκοπιά του με πήγε ένα βήμα παραπέρα, έγειρε στη σκέψη μου επιστημονικά ερωτήματα και διάθεση για αναζήτηση.

Τέλος, θέλω να ευχαριστήσω τη μητέρα μου. Αυτή ξέρει...

ΠΕΡΙΛΗΨΗ

Η αυτοματοποιημένη αναγνώριση της ανθρώπινης δραστηριότητας αποτελεί ένα ταχέως εξελισσόμενο ερευνητικό πεδίο, που έχει συγκεντρώσει το ενδιαφέρον της επιστημονικής κοινότητας, έχει σημαντικά ερευνητικά αποτελέσματα και έχει οδηγήσει σε πλήθος εφαρμογών, που στοχεύει στον εντοπισμό, παρακολούθηση και ανίχνευση των επιτελούμενων σωματικών ενεργειών ενός ανθρώπου. Πρόκειται ουσιαστικά για καταγραφή και κατ' επέκταση μοντελοποίηση των κινήσεων και της συμπεριφοράς ενός ανθρώπου και μελετάται η επίδρασή τους στις σωματικές μετρήσεις (Καρδιακός Ρυθμός κ.α.) λαμβάνοντας υπόψιν ένα σύνολο παρατηρήσεων. Σήμερα, με την εξέλιξη της τεχνολογίας και τις νέες γενιές αισθητήρων για τη λήψη βιο-σημάτων, είναι εύκολη η καταγραφή τους και είναι εφικτό να σχεδιαστούν προηγμένα μοντέλα μηχανικής μάθησης που λαμβάνουν ως είσοδο τις μετρήσεις των αισθητήρων και μπορούν να αναγνωρίσουν την ανθρώπινη δραστηριότητα και να εκτιμήσουν την κατάσταση της υγείας του ανθρώπου και εξάγουν αυτοματοποιημένα συμπεράσματα και προειδοποιήσεις.

Στην παρούσα εργασία, πραγματοποιήθηκε εκτεταμένη βιβλιογραφική ανασκόπηση των διαφορετικών προσεγγίσεων μηχανικής μάθησης που χρησιμοποιούνται σε προβλήματα αναγνώρισης ανθρώπινης δραστηριότητας. Τα μοντέλα μηχανικής μάθησης βασισμένα σε συμβολικές αναπαραστάσεις παρουσιάζουν μεγάλο ερευνητικό ενδιαφέρον, ενώ δύνανται να υπερκεράσουν εγγενείς αδυναμίες των κλασικών μοντέλων μηχανικής μάθησης καθώς και των μοντέλων βαθιάς μάθησης. Προς τούτο, επιλέχθηκε προς περαιτέρω μελέτη, διερεύνηση, επέκταση, προσαρμογή και εφαρμογή μια τέτοια μεθοδολογία, βασισμένη στη μέθοδο της Συμβολικής Συναθροιστικής Προσέγγισης (Symbolic Aggregate Approximation – SAX), λόγω των πλεονεκτημάτων που παρουσιάζει. Η συγκεκριμένη μεθοδολογία προσαρμόστηκε, εφαρμόστηκε και δοκιμάστηκε σε σήματα προερχόμενα από αισθητήρες (επιταχυνσιόμετρο και γυροσκόπιο) που μετρούν την ανθρώπινη δραστηριότητα.

Η ερευνητική συνεισφορά της εργασίας έγκειται στην τροποποίηση, προσαρμογή και εξέλιξη της μεθοδολογίας SAX, ώστε να δύναται να χειριστεί αποδοτικότερα σήματα που αποτελούνται από περισσότερα του ενός κανάλια πληροφορίας, όπως το επιταχυνσιόμετρο (που καταγράφει ταυτόχρονα 3 σήματα). Οπότε, πραγματοποιήθηκε εισαγωγή και περιγραφή της καινοτόμου μεθοδολογίας: «Πολυκαναλικά Έξυπνα Εικονίδια Συμβολικής Συναθροιστικής Προσέγγισης» (Multichannel Symbolic Aggregate Approximation Intelligent Icons) και ακολούθησε ο σχεδιασμός και η υλοποίηση ενός μοντέλου μηχανικής

μάθησης και η εφαρμογή του για την αναγνώριση οκτώ ανθρώπινων δραστηριοτήτων με αξιοποίηση των μετρήσεων από το επιταχυνσιόμετρο και γυροσκόπιο. Ο αλγόριθμος ταξινόμησης που χρησιμοποιήθηκε είναι ο ταξινομητής 1-πλησιέστερου γείτονα, ενώ η ικανότητα ορθής πρόβλεψης του προτεινόμενου μοντέλου είναι ιδιαίτερος υψηλή. Για λόγους σύγκρισης, υλοποιήσαμε και εφαρμόσαμε στο ίδιο σύνολο δεδομένων, άλλα δύο μοντέλα μηχανικής μάθησης (ένα κλασικό και ένα βασισμένο στη μέθοδο SAX), με χρήση του ίδιου αλγορίθμου ταξινόμησης. Με βάση τα αποτελέσματα διαπιστώθηκε ότι η προτεινόμενη μέθοδος ξεπερνάει τις άλλες δύο σε οποιαδήποτε σύγκριση.

Λέξεις-κλειδιά: Αναγνώριση Ανθρώπινης Δραστηριότητας, Μηχανική Μάθηση, Συμβολική Συναθροιστική Προσέγγιση – SAX, Πολυκαναλικά Έξυπνα Εικονίδια

ABSTRACT

Automated recognition of human activity is a rapidly evolving field of research, which has attracted the interest of the scientific community. It has significant research results and has led to several applications aiming at monitoring and detecting the physical actions of a person. It is essentially the recording, and consequently, the modeling of a person's movements and behavior, while their effect on physical measurements (Heart Rate, etc.) is studied taking into account a set of observations. Today, with the development of technology and new generations of sensors for receiving bio-signals, it is easy to record them and it is possible to design advanced machine learning models that take sensor measurements as input and can recognize human activity and assess the state of human health and draw automated conclusions and warnings.

In the present work, an extensive literature review of the different machine learning approaches used in human activity identification problems was performed. Machine learning models based on symbolic representations are of great research interest, while they can overcome the inherent weaknesses of the classic machine learning models as well as the deep learning models. To this end, such a methodology, based on the method of Symbolic Aggregate Approximation (SAX), was selected for further study, investigation, extension, adaptation, and application, due to its advantages. This methodology was adapted, applied, and tested on signals from sensors (accelerometer and gyroscope) that measure the human activity.

The research contribution of the work lies in the modification, adaptation, and evolution of the SAX methodology so that it can more efficiently handle signals consisting of more than one information channel, such as the accelerometer (which records 3 signals simultaneously). Thus, the innovative methodology "Multichannel Symbolic Aggregate Approximation Intelligent Icons" was introduced and described, followed by the design and implementation of a machine learning model that was applied for the recognition of eight activities utilizing the measurements of an accelerometer and a gyroscope. The classification algorithm used is the 1-Nearest Neighbor classifier, while the model's prediction ability appeared to be particularly high. For comparison reasons, we implemented and applied to the same dataset, two other machine learning models (one classic and one based on the SAX method), using the same classification algorithm. Based on the results, it was found that our method surpasses the other two in any comparison.

Keywords: Human Activity Recognition, Machine Learning, Symbolic Aggregate Approximation - SAX, Multichannel Intelligent Icons

ΠΙΝΑΚΑΣ ΠΕΡΙΕΧΟΜΕΝΩΝ

ΕΥΧΑΡΙΣΤΙΕΣ.....	ix
ΠΕΡΙΛΗΨΗ.....	xi
ABSTRACT	xiii
ΠΙΝΑΚΑΣ ΠΕΡΙΕΧΟΜΕΝΩΝ	xv
ΚΑΤΑΛΟΓΟΣ ΠΙΝΑΚΩΝ	xvii
ΚΑΤΑΛΟΓΟΣ ΕΙΚΟΝΩΝ.....	xviii
1. Εισαγωγή	1
1.1. Στόχοι εργασίας και συνεισφορά	2
1.2. Ανθρώπινες δραστηριότητες.....	3
1.3. Αισθητήρες.....	4
2. Θεωρητικό πλαίσιο	7
2.1. Τεχνικές μηχανικής μάθησης.....	7
2.1.1. Εποπτευόμενη μάθηση	8
2.2. Εξαγωγή χαρακτηριστικών	11
2.3. Βαθιά Μάθηση.....	13
2.4. State-of-the-art προσεγγίσεις μηχανικής μάθησης συναφείς με το εξεταζόμενο θέμα 15	
3. Συμβολική αναπαράσταση χρονοσειρών	19
3.1. Συμβολική Συναθροιστική Προσέγγιση (Symbolic Aggregate Approximation - SAX) 20	
3.1.1. Τμηματική Συναθροιστική Προσέγγιση (Piecewise Aggregate Approximation - PAA) 21	
3.1.2. Διακριτοποίηση	22
3.1.3. Έξυπνα εικονίδια	24
3.2. Παραλλαγές.....	25
4. Δεδομένα.....	29
4.1. Περιγραφή βάσης δεδομένων	29
4.2. Συγχρονισμός.....	32
4.3. Φιλτράρισμα – αφαίρεση θορύβου	33
4.4. Τμηματοποίηση.....	36
5. Πολυκαναλικά Έξυπνα Εικονίδια Συμβολικής Συναθροιστικής Προσέγγισης (Multichannel Symbolic Aggregate Approximation Intelligent Icons).....	39
5.1. Τα βήματα τους μεθόδου	40
5.1.1. Εφαρμογή PAA για μείωση διαστατικότητας	41
5.1.2. Εφαρμογή διακριτοποίησης.....	41
5.1.3. Εξαγωγή χαρακτηριστικών – Έξυπνα εικονίδια.....	43
5.1.4. Ταξινόμηση.....	46

6.	Αποτελέσματα – Συγκρίσεις.....	51
6.1.	Μέτρα αξιολόγησης ενός μοντέλου.....	51
6.2.	Αποτελέσματα.....	52
6.3.	Αποτελέσματα άλλων μεθόδων για την βάση δεδομένων RealWorld (HAR).....	60
6.4.	Οπτικοποίηση δεδομένων μέσω μείωσης διάστασης.....	60
6.4.1.	Πολυδιάστατη κλιμάκωση (Multidimensional Scaling – MDS).....	61
7.	Συμπεράσματα.....	67
	ΔΗΜΟΣΙΕΥΣΕΙΣ.....	69
	ΒΙΒΛΙΟΓΡΑΦΙΑ.....	71
	ΠΑΡΑΡΤΗΜΑ.....	77

ΚΑΤΑΛΟΓΟΣ ΠΙΝΑΚΩΝ

Πίνακας 2-1: Ορισμένα από τα συνήθη χαρακτηριστικά που χρησιμοποιούνται σε προβλήματα αναγνώρισης της ανθρώπινης δραστηριότητας.	13
Πίνακας 3-1: Οι πιθανές λέξεις που σχηματίζονται για μέγεθος αλφαβήτου = 3 και μήκος λέξης = 2	24
Πίνακας 5-1: Όλες οι πιθανές λέξεις που σχηματίζονται για μέγεθος αλφαβήτου = 4 και μήκος λέξης = 3	44
Πίνακας 5-2: Πίνακας χαρακτηριστικών της προσέγγισης με μη επικαλυπτόμενα παράθυρα. Κάθε κελί περιέχει έναν υποπίνακα διαστάσεων 1x64 που αποτελεί ένα έξυπνο εικονίδιο.	47
Πίνακας 5-3: Πίνακας χαρακτηριστικών της προσέγγισης με 50% επικαλυπτόμενα παράθυρα. Κάθε κελί περιέχει έναν υποπίνακα διαστάσεων 1x64 που αποτελεί ένα έξυπνο εικονίδιο.	47
Πίνακας 6-1: Η μορφή ενός πίνακα σύγκρισης	51
Πίνακας 6-2: Εξαγωγή Χαρακτηριστικών	53
Πίνακας 6-3: Μέση ακρίβεια για το μοντέλο με την κλασική εξαγωγή χαρακτηριστικών, για την προσέγγιση με μη επικαλυπτόμενα και επικαλυπτόμενα κατά 50% παράθυρα, αντίστοιχα	55
Πίνακας 6-4: Μέση ακρίβεια για το μοντέλο με τα μονοκαναλικά έξυπνα εικονίδια, για την προσέγγιση με μη επικαλυπτόμενα και επικαλυπτόμενα κατά 50% παράθυρα, αντίστοιχα	56
Πίνακας 6-5: Μέση ακρίβεια για το μοντέλο με τα πολυκαναλικά έξυπνα εικονίδια, για την προσέγγιση με μη επικαλυπτόμενα και επικαλυπτόμενα κατά 50% παράθυρα, αντίστοιχα	58
Πίνακας 6-6: Συνολικός συγκριτικός πίνακας μεταξύ των τριών διαφορετικών μοντέλων που υλοποιήσαμε, με μέτρο σύγκρισης την ευαισθησία κάθε κλάσης/δραστηριότητας.	58

ΚΑΤΑΛΟΓΟΣ ΕΙΚΟΝΩΝ

Εικόνα 2-1: Η διαδικασία της εποπτευόμενης μηχανικής μάθησης	11
Εικόνα 2-2: Η βαθιά μάθηση ως υποσύνολο της μηχανικής μάθησης, η οποία είναι υποσύνολο της τεχνητής νοημοσύνης	15
Εικόνα 3-1: Πίνακας εύρεσης οριακών τιμών β_i	23
Εικόνα 3-2: Μετατροπή τους σήματος από τον χώρο των πραγματικών αριθμών στον συμβολικό χώρο.....	24
Εικόνα 3-3: Το έξυπνο εικονίδιο που εξήχθη από τη συμβολοσειρά ‘bbcaaacbbbb’. Κάθε αριθμός δείχνει τη συχνότητα εμφάνισης τους λέξης που βρίσκεται στο αντίστοιχο κελί του πίνακα 3-1.	25
Εικόνα 4-1: Τα κύρια στοιχεία της βάσης δεδομένων RealWorld (HAR) [73]	29
Εικόνα 4-2: Πληροφορίες υποκειμένων της βάσης δεδομένων RealWorld (HAR).....	30
Εικόνα 4-3: Καταγραφή σημάτων από τους αισθητήρες της συσκευής smartwatch στον τρισδιάστατο χώρο.....	31
Εικόνα 4-4: Η κατανομή και προέλευση των σημάτων που χρησιμοποιούμε.	32
Εικόνα 4-5: Σήματα επιτάχυνσης στον x, y, z άξονα, αντίστοιχα, προερχόμενα από τις καταγραφές του επιταχυνσιόμετρου.....	33
Εικόνα 4-6: Σήματα γωνιακής ταχύτητας στον x, y z, άξονα, αντίστοιχα, προερχόμενα από τις καταγραφές του γυροσκοπίου.	33
Εικόνα 4-7: Αρχή και τέλος του ακατέργαστου σήματος	34
Εικόνα 4-8: (α) Το σήμα πριν το φιλτράρισμα και (β) το σήμα μετά το φιλτράρισμα	35
Εικόνα 4-9: Το κανονικοποιημένο σήμα	36
Εικόνα 4-10: Τμηματοποίηση σε κυλιόμενα χρονικά παράθυρα των 128 σημείων	37
Εικόνα 5-1: Το κάθε κανάλι του πολυκαναλικού σήματος αναπαρίσταται ως μια συμβολοσειρά. Αναζητούμε λέξεις των οποίων το 1 ^ο σύμβολο προέρχεται από το 1 ^ο κανάλι, το 2 ^ο σύμβολο από το 2 ^ο κανάλι, κ.ο.κ.	40
Εικόνα 5-2: Τα βήματα τους μεθόδου τους.....	40

Εικόνα 5-3: Το αρχικό σήμα (μαύρη γραμμή) και η ΡΑΑ αναπαράσταση (κόκκινη γραμμή).	41
Εικόνα 5-4: Ο κάθε συντελεστής ΡΑΑ αντιστοιχίζεται σε ένα σύμβολο από τα διαθέσιμα του επιλεγμένου μεγέθους αλφαβήτου. Οι οριζόντιες μπλε γραμμές είναι οι γραμμές των οριακών τιμών που οριοθετούν τις 4 διαφορετικές περιοχές τιμών.	42
Εικόνα 5-5: Ολικό γράφημα μεθόδου SAX. Παρατηρούμε το αρχικό σήμα, τους συντελεστές ΡΑΑ, τις οριακές γραμμές και τα τελικά σύμβολα.	43
Εικόνα 5-6: Το μονοκαναλικό έξυπνο εικονίδιο που εξήχθη από τη συμβολοσειρά ‘c c d d d d b b a a b b c d d d c b b a a b b c d d d c b a a b’. Κάθε αριθμός δείχνει τη συχνότητα εμφάνισης της λέξης που βρίσκεται στο αντίστοιχο κελί του πίνακα 5-1.	44
Εικόνα 5-7: Οι λέξεις αποτελούνται από ένα σύμβολο από κάθε διάσταση για τον υπολογισμό του πολυκαναλικού έξυπνου εικονιδίου	45
Εικόνα 5-8: Το πολυκαναλικό έξυπνο εικονίδιο. Κάθε αριθμός δείχνει τη συχνότητα εμφάνισης της λέξης που βρίσκεται στο αντίστοιχο κελί.	46
Εικόνα 5-9: Σχηματικά η ταξινόμηση με τον αλγόριθμο KNN. Στο (α) βλέπουμε τα σημεία του εκπαιδευμένου σετ δεδομένων και με το μαύρο ερωτηματικό το προς ταξινόμηση νέο στιγμιότυπο. Το (β) δείχνει την πρόβλεψη του ταξινομητή 1-πλησιέστερου γείτονα, το (β) τον ταξινομητή 3-πλησιέστερων γειτόνων και το (γ) τον ταξινομητή 5-πλησιέστερων γειτόνων για το ίδιο σημείο πρόβλεψης. Όπως είναι φανερό ο αριθμός των γειτόνων που θα επιλεγθεί επηρεάζει τις προβλέψεις.	50
Εικόνα 6-1: Πίνακας σύγχυσης για το μοντέλο με την κλασική εξαγωγή χαρακτηριστικών, για την προσέγγιση με μη επικαλυπτόμενα παράθυρα. Η αριστερή εκ των δύο τελευταίων στηλών υποδηλώνει την ευαισθησία της αντίστοιχης κλάσης.	54
Εικόνα 6-2: Πίνακας σύγχυσης για το μοντέλο με την κλασική εξαγωγή χαρακτηριστικών, για την προσέγγιση με επικαλυπτόμενα κατά 50% παράθυρα. Η αριστερή εκ των δύο τελευταίων στηλών υποδηλώνει την ευαισθησία της αντίστοιχης κλάσης.	54
Εικόνα 6-3: Πίνακας σύγχυσης για το μοντέλο με τα μονοκαναλικά έξυπνα εικονίδια, για την προσέγγιση με μη επικαλυπτόμενα παράθυρα. Η αριστερή εκ των δύο τελευταίων στηλών υποδηλώνει την ευαισθησία της αντίστοιχης κλάσης.	55

Εικόνα 6-4: Πίνακας σύγκρισης για το μοντέλο με τα μονοκαναλικά έξυπνα εικονίδια, για την προσέγγιση με επικαλυπτόμενα κατά 50% παράθυρα. Η αριστερή εκ των δύο τελευταίων στηλών υποδηλώνει την ευαισθησία της αντίστοιχης κλάσης.	56
Εικόνα 6-5: Πίνακας σύγκρισης για το μοντέλο με τα πολυκαναλικά έξυπνα εικονίδια, για την προσέγγιση με μη επικαλυπτόμενα παράθυρα. Η αριστερή εκ των δύο τελευταίων στηλών υποδηλώνει την ευαισθησία της αντίστοιχης κλάσης.	57
Εικόνα 6-6: Πίνακας σύγκρισης για το μοντέλο με τα πολυκαναλικά έξυπνα εικονίδια, για την προσέγγιση με επικαλυπτόμενα κατά 50% παράθυρα. Η αριστερή εκ των δύο τελευταίων στηλών υποδηλώνει την ευαισθησία της αντίστοιχης κλάσης.	57
Εικόνα 6-7: Συγκριτικό διάγραμμα της επιτευχθείσας ακρίβειας σε σχέση με άλλα μοντέλα για τη βάση δεδομένων RealWorld (HAR) που χρησιμοποιήσαμε. Η μέθοδός μας απεικονίζεται στην τελευταία στήλη.	60
Εικόνα 6-8: Αποτύπωση πολυδιάστατης κλιμάκωσης στην προσέγγιση των μη επικαλυπτόμενων παραθύρων (κλασικό μοντέλο εξαγωγής χαρακτηριστικών).....	62
Εικόνα 6-9: Αποτύπωση πολυδιάστατης κλιμάκωσης στην προσέγγιση των επικαλυπτόμενων παραθύρων (κλασικό μοντέλο εξαγωγής χαρακτηριστικών).....	63
Εικόνα 6-10: Αποτύπωση πολυδιάστατης κλιμάκωσης στην προσέγγιση των μη επικαλυπτόμενων παραθύρων (μονοκαναλικά εικονίδια).....	63
Εικόνα 6-11: Αποτύπωση πολυδιάστατης κλιμάκωσης στην προσέγγιση των επικαλυπτόμενων παραθύρων (μονοκαναλικά εικονίδια).....	64
Εικόνα 6-12: Αποτύπωση πολυδιάστατης κλιμάκωσης στην προσέγγιση των μη επικαλυπτόμενων παραθύρων (πολυκαναλικά εικονίδια).....	64
Εικόνα 6-13: Αποτύπωση πολυδιάστατης κλιμάκωσης στην προσέγγιση των επικαλυπτόμενων παραθύρων (πολυκαναλικά εικονίδια).....	65

1. Εισαγωγή

Η αναγνώριση της ανθρώπινης δραστηριότητας (Human Activity Recognition - HAR) αποτελεί ένα ταχέως εξελισσόμενο ερευνητικό πεδίο που έχει ως στόχο την αναγνώριση των δραστηριοτήτων που επιτελεί ένα άτομο/υποκείμενο, λαμβάνοντας υπόψιν ένα σύνολο παρατηρήσεων. Με άλλα λόγια η αναγνώριση της ανθρώπινης δραστηριότητας είναι η μοντελοποίηση της ανθρώπινης συμπεριφοράς [1], ώστε να καταστεί πραγματικότητα η αυτόματη ανίχνευση των διαφορετικών ενεργειών ενός ατόμου. Το πεδίο έχει γνωρίσει μιας μεγάλης ανάπτυξης στην ερευνητική κοινότητα τα τελευταία χρόνια εξαιτίας του μεγάλου πλήθους εφαρμογών που παρουσιάζει, όπως στον τομέα παροχής υπηρεσιών υγείας, στα έξυπνα σπίτια, στη διάχυτη υπολογιστική, την αυτόνομη διαβίωση υποβοηθούμενη από το περιβάλλον, την παρακολούθηση, τις κατασκευές κ.α. [2].

Μεγάλο ενδιαφέρον παρουσιάζεται σε σχέση με την ανάλυση και παρακολούθηση των καθημερινών ανθρώπινων δραστηριοτήτων με σκοπό την καλύτερη κατανόηση της κατάστασης της υγείας τους, την παροχή ιατρικής βοήθειας σε καταστάσεις ανάγκης και στην πρόληψη σημαντικών ασθενειών [3]. Η προαγωγή περισσότερο υγιεινού τρόπου ζωής (π.χ. ενθαρρύνοντας την σωματική άσκηση), η αποφυγή αγχογόνων δραστηριοτήτων, η ανίχνευση επικίνδυνων καταστάσεων (π.χ. πτώσεις) ή η καταγραφή των συνθηκών υγείας (π.χ. επιδείνωση της κινητικότητας εξαιτίας της ηλικίας ή ασθενειών) είναι μερικοί από τους τομείς που επωφελούνται από την παρακολούθηση και ανάλυση της ανθρώπινης συμπεριφοράς [3]. Στον τομέα παροχής υγείας, η αναγνώριση της ανθρώπινης δραστηριότητας περιλαμβάνει έναν σημαντικό αριθμό εφαρμογών, από την αναγνώριση πτώσεων σε ασθενείς με κινητικές διαταραχές, όπως ακαθησία, χορεία και νόσος του Parkinson, μέχρι τη συλλογή πληροφοριών σχετικά με το βάδισμα και τη στάση του σώματος, τη μεταβολική κατανάλωση ενέργειας και την παρακολούθηση της σωματικής δραστηριότητας [2].

Η παρακολούθηση της δραστηριότητας του ατόμου και η δημιουργία ημερήσιων, εβδομαδιαίων και μηνιαίων αναφορών δραστηριοτήτων που δείχνουν το συνολικό επίπεδο σωματικής δραστηριότητας μπορεί να βοηθήσει στην πρόληψη ασθενειών. Μερικές από αυτές είναι οι κύριες αιτίες θανάτου στις ανεπτυγμένες χώρες όπως ο διαβήτης τύπου II, η παχυσαρκία, ο καρκίνος και το εγκεφαλικό επεισόδιο. Σημειώνεται ότι για την αντιμετώπιση των επιπτώσεων των προαναφερθέντων ασθενειών δαπανώνται τεράστια οικονομικά κεφάλαια.

Επιπλέον, σύμφωνα με εκθέσεις του Παγκόσμιου Οργανισμού Υγείας [4], έως το 2050 στις ανεπτυγμένες χώρες του κόσμου το ένα τέταρτο, ή και περισσότερο, του πληθυσμού τους θα είναι ηλικίας 60 ετών και άνω, και συνολικά θα υπάρχουν 2,1 δισεκατομμύρια ηλικιωμένοι σε όλο τον κόσμο. Μαζί με άλλα παγκόσμια προβλήματα, όπως η έλλειψη νοσηλευτικού προσωπικού και η οικονομική κρίση αναφέρεται η επείγουσα ανάγκη για εκτεταμένη χρήση αυτοματοποιημένων συστημάτων παρακολούθησης.

Τα έξυπνα σπίτια επιτρέπουν σε ηλικιωμένους και ανάπηρους ασθενείς να είναι υπό συνεχή επίβλεψη της υγείας και ευεξίας τους, ενώ εκτελούν καθημερινές δραστηριότητες. Τα συγκεκριμένα σπίτια ενσωματώνουν νέες τεχνολογίες, όπως αισθητήρες περιβάλλοντος, διεπαφές χρήστη, υπολογιστικές συσκευές και ενεργοποιητές που εγγυώνται μια ακριβή επίβλεψη και ταχεία απόκριση σε επικίνδυνες καταστάσεις. Η κατάλληλη απόκριση είναι ιδιαίτερα σημαντική κατά την παρακολούθηση ατόμων με αδυναμίες ή χρόνιες ασθένειες όπως η νόσος του Parkinson ή η νόσος του Alzheimer.

1.1. Στόχοι εργασίας και συνεισφορά

Η παρούσα εργασία μελετά τις διαφορετικές τεχνικές μηχανικής μάθησης που έχουν προταθεί και αναπτυχθεί. Πραγματοποιείται ενδελεχής έρευνα στη σχετική βιβλιογραφία εστιάζοντας στην αναγνώριση της ανθρώπινης δραστηριότητας. Περιγράφονται οι ειδοποιόι διαφορές μεταξύ τους, ενώ παρατίθενται οι state-of-the-art προσεγγίσεις.

Ιδιαίτερη έμφαση δόθηκε σε μεθόδους μηχανικής μάθησης που βασίζονται στην μετατροπή των σημάτων από χρονοσειρές που είναι κατ' ουσίαν, σε συμβολικές αναπαραστάσεις, αναλύοντας με σαφήνεια τα πλεονεκτήματα μιας τέτοιας διαδικασίας. Κατά την βιβλιογραφική μας ανασκόπηση διαπιστώσαμε ότι περιορισμένης έκτασης ανάλογες προσεγγίσεις απαντώνται στην ελληνική βιβλιογραφία.

Τέλος, η βασική μας συνεισφορά έγκειται στην εισαγωγή, διατύπωση και κατάλληλη προσαρμογή μιας καινοτόμου τεχνικής μηχανικής μάθησης -βασισμένης στη συμβολική αναπαράσταση χρονοσειρών- που βρίσκει εφαρμογή σε σήματα που αποτελούνται από περισσότερα του ενός κανάλια πληροφορίας τα οποία περιγράφουν το ίδιο μέγεθος (πολυκαναλικά σήματα). Σχεδιάστηκε και υλοποιήθηκε το αντίστοιχο μοντέλο μηχανικής μάθησης, εφαρμόζοντάς το σε ανοιχτή βάση δεδομένων που περιλαμβάνει σήματα για αναγνώριση ανθρώπινης δραστηριότητας, ενώ εξήγαμε αποτελέσματα σχετικά με την επίδοση και απόδοση του μοντέλου.

Για λόγους πληρότητας, σχεδιάσαμε και υλοποιήσαμε δύο διαφορετικά μοντέλα μηχανικής μάθησης βασισμένα σε παραδοσιακές τεχνικές (με εφαρμογή στο ίδιο ακριβώς σετ δεδομένων), τα αποτελέσματα των οποίων λειτούργησαν ως σημείο αναφοράς για σύγκριση με τα αποτελέσματα της μεθόδου μας.

1.2. Ανθρώπινες δραστηριότητες

Τα τελευταία χρόνια έχει παρουσιαστεί μεγάλο ενδιαφέρον για την ανάλυση των προτιμήσεων και των καθημερινών δραστηριοτήτων των ανθρώπων. Η ανάλυση της ανθρώπινης συμπεριφοράς έχει αποδειχθεί πως είναι το κλειδί για την καλύτερη κατανόηση των ανθρώπινων αναγκών και επιθυμιών, με τους τομείς που έχουν την μεγαλύτερη εφαρμογή να είναι αυτός της υγείας και εκείνος της παροχής βοήθειας σε περίπτωση ανάγκης. Λειτουργίες όπως η προαγωγή υγιεινών και η αποτροπή μη υγιεινών δραστηριοτήτων ή ακόμη και η αναγνώριση μια πτώσης είναι δυνατόν να μοντελοποιηθούν προσφέροντας πολλαπλά οφέλη στους ανθρώπους [3].

Η μοντελοποίηση της ανθρώπινης συμπεριφοράς είναι δυνατόν να πραγματοποιηθεί μέσα από την διαδικασία της αναγνώρισης της ανθρώπινης δραστηριότητας (HAR). Χρησιμοποιώντας αισθητήρες που παράγουν διάφορα σήματα, τα οποία προκύπτουν από μια κίνηση είναι δυνατή η αναγνώριση καθημερινών λειτουργιών όπως βάδισμα, τρέξιμο, κάθισμα, ανύψωση, ανάβαση και κατάβαση σκαλιών, ποδηλασία κ.α. [3].

Οι ερευνητές διαχωρίζουν τις δραστηριότητες σε στατικές (static), δυναμικές (dynamic) και μετάβασης (transition). Οι στατικές δραστηριότητες είναι αυτές όπου η στάση του σώματος είναι σταθερή για κάποιο διάστημα, όπως η όρθια στάση. Οι δυναμικές δραστηριότητες περιλαμβάνουν κίνηση, όπως το περπάτημα. Τέλος, οι δραστηριότητες μετάβασης περιορίζονται στην αλλαγή μεταξύ των στατικών κινήσεων, όπως η μετάβαση μεταξύ όρθιας στάσης και καθίσματος [5].

Ένας επιπλέον διαχωρισμός τοποθετεί τις δραστηριότητες σε κατηγορίες όπως πολύ χαμηλού επιπέδου κινητικές δραστηριότητες (κατάκλιση), χαμηλού επιπέδου κινητικές δραστηριότητες (ετοιμασία φαγητού, διάβασμα κ.ά.), μεσαίου επιπέδου κινητικές δραστηριότητες (καθαρισμός τραπεζιού κ.α.), υψηλού επιπέδου κινητικές δραστηριότητες (ποδηλασία κ.α.) και μεταβάσεις μεταξύ δραστηριοτήτων (κάθισμα και όρθια στάση, επίπεδη στάση και όρθια στάση) [6].

Οι καθημερινές δραστηριότητες όπως η βάδιση, το τρέξιμο, το κάθισμα, το σήκωμα αντικειμένων, το ανέβασμα ή κατέβασμα σκάλας, η ποδηλασία, κ.α. μπορούν εύκολα να ανιχνευτούν με τη χρήση αισθητήρων που συλλέγουν διάφορα σήματα που περιγράφουν την ανθρώπινη κίνηση [7].

1.3. Αισθητήρες

Η αναγνώριση της ανθρώπινης δραστηριότητας μπορεί να πραγματοποιηθεί χρησιμοποιώντας πληροφορίες που λαμβάνονται από διάφορους τύπους αισθητήρων, που ανάλογα με τη θέση του διακρίνονται: σε αισθητήρες σώματος, αντικειμένου ή περιβάλλοντος [2].

Οι αισθητήρες περιβάλλοντος, όπως οι βιντεοκάμερες, είναι μια παραδοσιακή μέθοδος που χρησιμοποιείται ευρέως και ουσιαστικά επεξεργάζεται και αναλύει τις ανθρώπινες κινήσεις μέσα από καταγραφές βίντεο [8]. Το κύριο πλεονέκτημά της είναι η καταγραφή όχι μόνο εικόνων αλλά και ακουστικών συμβάντων που βοηθούν στην ανίχνευση και περιγραφή της ανθρώπινης δραστηριότητας. Για παράδειγμα, σε νοσοκομειακό περιβάλλον, οι εν λόγω αισθητήρες μπορούν να προειδοποιήσουν το νοσηλευτικό προσωπικό σε περίπτωση μεταβολής της κατάστασης του νοσηλευομένου, ώστε να παρέμβει. Επίσης, είναι πολύ χρήσιμα σε ένα εργασιακό περιβάλλον, όπου μπορούν να παρακολουθούν τις δραστηριότητες του εργαζομένου και εάν αυτές εκτελούνται με ασφάλεια.

Παρόλα αυτά, αυτό το είδος αισθητήρων έχει πολλά μειονεκτήματα: εγείρουν ζητήματα προσωπικών δεδομένων, συχνά χρειάζονται υποστήριξη υποδομής, εξαρτώνται από τις συνθήκες φωτισμού ενώ απαιτείται το καταγραφόμενο άτομο να παραμένει εντός του οπτικού πεδίου της κάμερας. Επιπλέον, η εξαγωγή χαρακτηριστικών από τις εγγεγραμμένες εικόνες απαιτεί πολύπλοκο λογισμικό που χρειάζεται σημαντική υπολογιστική ισχύ (hardware).

Από την άλλη, η χρήση αισθητήρων σώματος, όπως επιταχυνσιόμετρο, γυροσκόπιο, αισθητήρας ήχου, κ.α. μπορεί να προσφέρει καλύτερα αποτελέσματα [7]. Οι φορέσιμοι αισθητήρες, όχι μόνο επιλύουν το πρόβλημα υποδομής των αισθητήρων περιβάλλοντος, αλλά επιτρέπουν επίσης τη μέτρηση των σημάτων του σώματος (βιοσήματα). Διαφορετικές προσεγγίσεις υπάρχουν με βάση τη θέση των αισθητήρων κίνησης σε σημεία του σώματος, όπως η μέση, ο καρπός, το στέρνο, το στήθος και οι μηροί.

Δυστυχώς, αυτό το είδος αναγνώρισης δραστηριότητας δεν καθίσταται εφικτό για μακροχρόνια παρακολούθηση λόγω της δυσφορίας του χρήστη, καθώς φοράει αρκετούς αισθητήρες και

καλώδια, ενώ υπάρχει και η ανάγκη επανατοποθέτησης του αισθητήρα μετά το ντύσιμο [2]. Επιπλέον, οι εν λόγω αισθητήρες παρουσιάζουν μειονεκτήματα για ηλικιωμένους ή ασθενείς με Alzheimer, καθώς μπορεί να ξεχάσουν να φορέσουν ή να επαναφορτίσουν την μπαταρία που είναι ενσωματωμένη σε αυτούς.

Η πραγματική επανάσταση στον τομέα της αναγνώρισης της ανθρώπινης δραστηριότητας δεν θα μπορούσε να καταστεί δυνατή χωρίς την διείσδυση των smartphones στο μεγαλύτερο μέρος του παγκόσμιου πληθυσμού. Αφενός, αυτές οι συσκευές επιτρέπουν τη μη επεμβατική ενσωμάτωση πολλών αισθητήρων - όπως διπλές κάμερες, μικρόφωνα, αισθητήρες GPS, αισθητήρες φωτός, επιταχυνσιόμετρα και γυροσκοπία - σε μία και μόνο συσκευή. Αυτό επιλύει τα προβλήματα που σχετίζονται με τις απαιτήσεις σε υποδομές ή σε σχέση με την ικανότητα του ασθενούς για συνεργασία. Επιπλέον, με τη χρήση smartphone η απόκτηση δεδομένων είναι ταχύτερη δεδομένου ότι η μονάδα επεξεργασίας και ο αισθητήρας βρίσκονται ενσωματωμένοι στην ίδια συσκευή. Από την άλλη πλευρά, η χρήση του smartphone αντί πολλών ανεξάρτητων αισθητήρων, μειώνει την οικονομική επιβάρυνση του χρήστη.

Επιπλέον, η σχετική υπολογιστική τους δύναμη, η ικανότητά τους να στέλνουν και να λαμβάνουν δεδομένα, οι απευθείας υπολογισμοί, το ευρύ φάσμα επιλογών συνδεσιμότητας και η σχεδόν πανταχού παρούσα χρήση στην κοινωνία μας, τους καθιστούν τον τέλειο υποψήφιο για αναγνώριση ανθρώπινης δραστηριότητας, φέρνοντας νέες ερευνητικές ευκαιρίες για ανθρωποκεντρικές εφαρμογές. Σε αυτές τις εφαρμογές, ο χρήστης είναι η κύρια πηγή πληροφοριών και το τηλέφωνο είναι το εργαλείο αντίχρευσσης.

2. Θεωρητικό πλαίσιο

2.1. Τεχνικές μηχανικής μάθησης

Η μηχανική μάθηση είναι η μελέτη των υπολογιστικών αλγορίθμων που έχουν την ιδιότητα να αυτοβελτιώνονται [9, 10]. Θεωρείται υποσύνολο της τεχνητής νοημοσύνης (Εικόνα 2-2). Οι αλγόριθμοι μηχανικής μάθησης δημιουργούν ένα μαθηματικό μοντέλο βασισμένο σε δειγματικά δεδομένα, γνωστά ως δεδομένα εκπαίδευσης, δηλαδή τα δεδομένα που θα χρησιμοποιηθούν για την εκπαίδευση του μοντέλου, με στόχο να μπορεί να πραγματοποιήσει προβλέψεις ή να λαμβάνει αποφάσεις χωρίς να έχει ρητά προγραμματιστεί για να κάνει κάτι τέτοιο. Το 1959, ο Arthur Samuel όρισε τη μηχανική μάθηση ως "Ο τομέας σπουδών που παρέχει στους υπολογιστές την ικανότητα να μαθαίνουν χωρίς να έχουν προγραμματιστεί ρητώς για αυτόν τον σκοπό" [11].

Οι αλγόριθμοι μηχανικής μάθησης χρησιμοποιούνται σε ένα ευρύ φάσμα εφαρμογών, όπως αναγνώριση κακόβουλων emails και στην υπολογιστική όραση, όπου είναι δύσκολη ή αδύνατη η ανάπτυξη συμβατικών αλγορίθμων για την εκτέλεση των απαιτούμενων εργασιών.

Η μηχανική μάθηση είναι στενά σχετιζόμενη με την υπολογιστική στατιστική, που εστιάζει στην πραγματοποίηση προβλέψεων χρησιμοποιώντας υπολογιστή. Η μηχανική μάθηση διερευνά τη μελέτη και την κατασκευή αλγορίθμων που μπορούν να μαθαίνουν από τα δεδομένα και να κάνουν προβλέψεις. Τέτοιοι αλγόριθμοι λειτουργούν κατασκευάζοντας μοντέλα από δεδομένα, προκειμένου να κάνουν προβλέψεις βασισμένες στα δεδομένα ή να εξάγουν αποφάσεις που εκφράζονται ως το αποτέλεσμα. Η εξόρυξη δεδομένων είναι επίσης ένας σχετιζόμενος τομέας έρευνας. Η μηχανική μάθηση όταν βρίσκει εφαρμογή σε προβλήματα επιχειρήσεων αναφέρεται επίσης με το όνομα "προγνωστική ανάλυση".

Υπάρχουν τρεις κύριες κατηγορίες στις οποίες διακρίνουμε τις μεθόδους μηχανικής μάθησης με βάση την ύπαρξη ή μη ετικετοποιημένων δεδομένων (δηλαδή τα δεδομένα να φέρουν ετικέτα/αναγνωριστικό της κατηγορίας στην οποία ανήκουν).

- Εποπτευόμενη μάθηση: το μοντέλο εκπαιδεύεται με ένα σύνολο δεδομένων και των αντίστοιχων ετικετών τους (labeled data). Στόχος είναι ο αλγόριθμος να τροποποιήσει κατάλληλα τις παραμέτρους του ώστε να δημιουργήσει έναν γενικό κανόνα που να αντιστοιχίζει με τον καλύτερο τρόπο τα δεδομένα εισόδου με τις αντίστοιχες ετικέτες [12].

- Μη εποπτευόμενη μάθηση: τα δεδομένα εισόδου δεν φέρουν ετικέτες (unlabeled data) συνεπώς ο αλγόριθμος εκπαίδευσης είναι επιφορτισμένος να ανακαλύψει μόνος του τη δομή που χαρακτηρίζει τα δεδομένα εισόδου [12].
- Ενισχυτική μάθηση: ένα πρόγραμμα υπολογιστή αλληλεπιδρά σε ένα δυναμικό περιβάλλον στο οποίο πρέπει να επιτελέσει έναν συγκεκριμένο στόχο (π.χ. να οδηγήσει ένα όχημα ή να παίξει ένα παιχνίδι εναντίον ενός παίκτη. Κατά την επίλυση του προβλήματος, παρέχεται στο πρόγραμμα ανατροφοδότηση-επιβραβεύσεις, τις οποίες και προσπαθεί να μεγιστοποιήσει [13].

2.1.1. Εποπτευόμενη μάθηση

Η εποπτευόμενη μάθηση είναι η διαδικασία μηχανικής μάθησης όπου το μοντέλο “μαθαίνει” (μέσω εκπαίδευσης) μια συνάρτηση που αντιστοιχίζει μια είσοδο σε μια έξοδο [14]. Η εποπτευόμενη μάθηση αναφέρεται στην εύρεση μιας συνάρτησης κατάλληλης για το υπό μελέτη πρόβλημα. Αυτή η συνάρτηση δέχεται μια είσοδο X και την αντιστοιχίζει σε μια έξοδο Y . Αν αναπαραστήσουμε τον παραπάνω ορισμό σε μια απλή εξίσωση, τότε προκύπτει το ακόλουθο:

$$Y = f(X) \tag{1}$$

Το σύνολο δεδομένων (dataset) που χρησιμοποιείται χωρίζεται σε δύο υποσύνολα: το σύνολο δεδομένων εκπαίδευσης (training dataset) και το σύνολο δεδομένων ελέγχου (testing dataset). Ο λόγος των παραπάνω ποικίλλει, αλλά συνήθως είναι κοντά στο 2:8 (δηλαδή 20% δεδομένα ελέγχου και 80% δεδομένα εκπαίδευσης, αντίστοιχα) [15].

Τα δεδομένα εισόδου φέρουν ετικέτες και χρησιμοποιούνται για τον σχεδιασμό ενός μαθηματικού μοντέλου που θα χρησιμοποιηθεί στην διαδικασία της εκπαίδευσης. Το μοντέλο αναλύει το σύνολο δεδομένων εκπαίδευσης και παράγει τη συνάρτηση που συνάγεται [16]. Η συνάρτηση αυτή χρησιμοποιείται για την αντιστοίχιση νέων παραδειγμάτων. Ένα βέλτιστο σενάριο θα επιτρέψει στον αλγόριθμο να καθορίσει σωστά τις ετικέτες κλάσης νέων εμφανίσεων. Αυτό απαιτεί ο αλγόριθμος εκμάθησης να γενικεύει από τα δεδομένα εκπαίδευσης σε καινούριες καταστάσεις.

Τα προβλήματα εποπτευόμενης μηχανικής μάθησης μπορούν επιπλέον να κατηγοριοποιηθούν σε προβλήματα ταξινόμησης και προβλήματα παλινδρόμησης. Στα προβλήματα ταξινόμησης

η έξοδος κατηγοριοποιείται σε μια συγκεκριμένη ομάδα, ενώ στα προβλήματα παλινδρόμησης η έξοδος είναι μια αριθμητική τιμή [15].

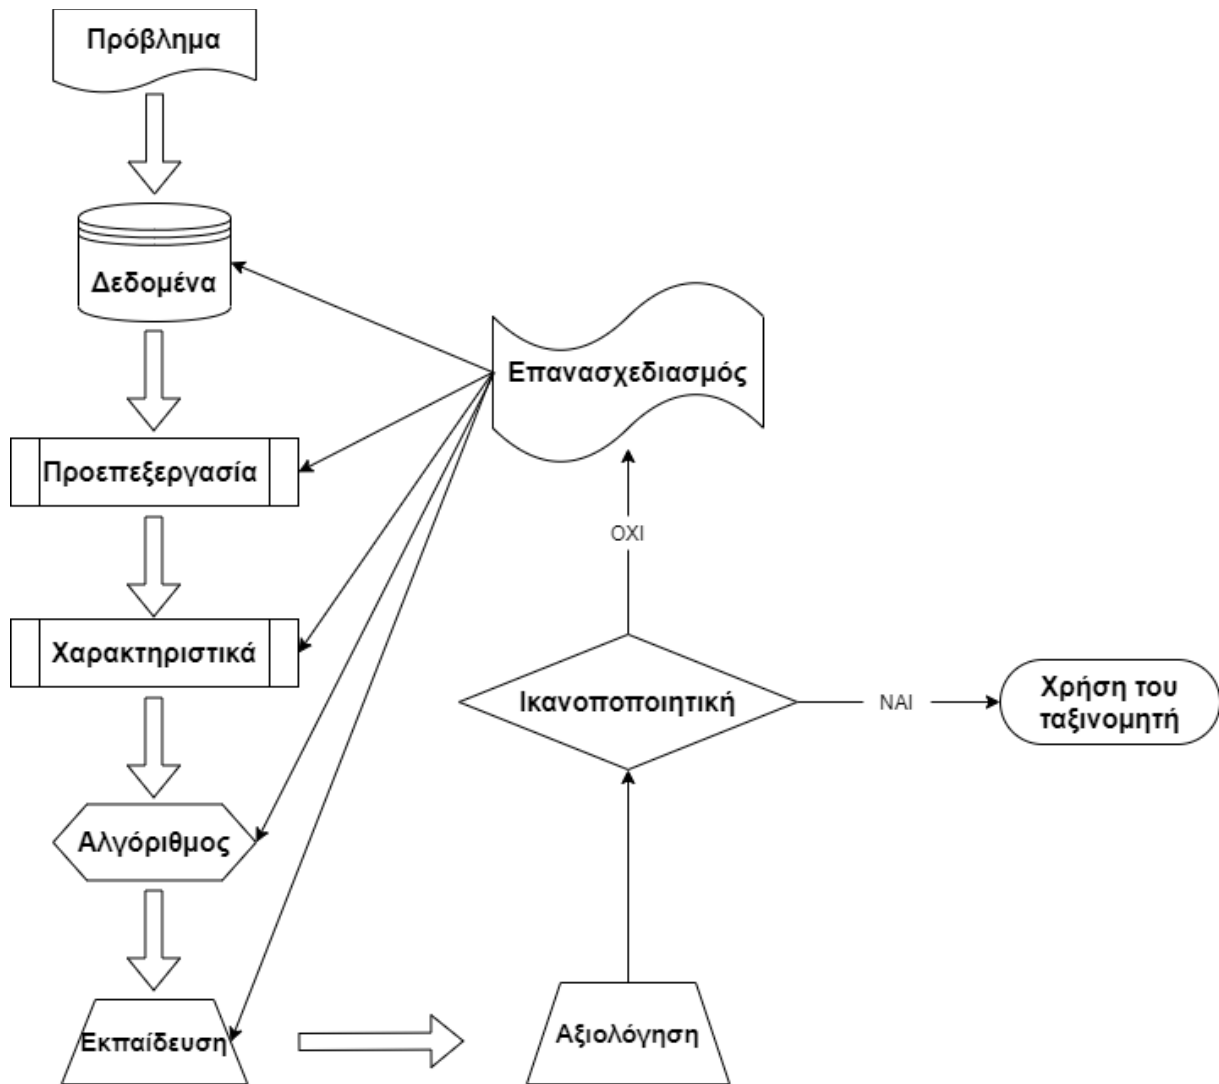
Οι περισσότερο ευρέως χρησιμοποιούμενοι αλγόριθμοι εποπτευόμενης μάθησης είναι: Μηχανές Διανυσμάτων Υποστήριξης (SVM), Γραμμική Παλινδρόμηση (Linear Regression), Λογιστική Παλινδρόμηση (Logistic Regression), Μπεϋζιανός Ταξινομητής (Naive Bayes), Δέντρα αποφάσεων (Decision Trees), ο Κ-πλησιέστεροι-γείτονες (K — Nearest Neighbour) και τα Νευρωνικά Δίκτυα [15]. Κατά το 2020, η βαθιά μάθηση κατέστη η κυρίαρχη προσέγγιση για μεγάλο μέρος εργασιών που πραγματοποιούνται στον τομέα της μηχανικής μάθησης [17].

Βήματα μεθόδου

Η παρακάτω γενική πορεία ακολουθείται στην περίπτωση που έχουμε να επιλύσουμε ένα πρόβλημα εποπτευόμενης μηχανικής μάθησης [18] και αποτυπώνεται σχηματικά στην Εικόνα 2-1.

1. Απόκτηση δεδομένων: Προσδιόρισε τον τύπο ή την φύση των δεδομένων προς εκπαίδευση. Πριν από οτιδήποτε άλλο, ο χρήστης πρέπει να αποφασίσει τι είδους δεδομένα πρόκειται να χρησιμοποιηθούν ως σύνολο δεδομένων εκπαίδευσης και πώς αυτά θα ληφθούν. Για παράδειγμα, στην περίπτωση ανάλυσης ενός χειρόγραφου, μπορεί να είναι ένας χειρόγραφος χαρακτήρας, μια ολόκληρη χειρόγραφη λέξη ή μια ολόκληρη γραμμή. Το σύνολο δεδομένων εκπαίδευσης πρέπει να είναι αντιπροσωπευτικό της πραγματικής χρήσης / λειτουργίας του υπό εξέταση φαινομένου/συστήματος. Έτσι, συλλέγεται ένα σύνολο δεδομένων εισόδου και συλλέγονται και οι αντίστοιχες έξοδοι, είτε από ειδικούς, είτε μέσω μετρήσεων.
2. Προεπεξεργασία και προετοιμασία δεδομένων: Το βήμα αυτό είναι από τα πιο σημαντικά στοιχεία της διαδικασίας μοντελοποίησης μηχανικής μάθησης. Επιπλέον, είναι μια αρκετά χρονοβόρα διαδικασία. Σε αυτό το βήμα προετοιμάζονται τα δεδομένα ώστε να καταστούν διαθέσιμα για περαιτέρω επεξεργασία και χρήση. Πρόκειται για την διαδικασία όπου αποκτούμε τα δειγματικά δεδομένα και τα χειριζόμαστε κατάλληλα, ώστε να παραχθούν ουσιαστικές (δηλαδή με νόημα) πληροφορίες. Αντιστοιχίζουμε τις παρατηρήσεις με τις αντίστοιχες ετικέτες τους, όπως απαιτεί η διαδικασία της εποπτευόμενης μηχανικής μάθησης.

3. Εξαγωγή χαρακτηριστικών: Προσδιόρισε την αναπαράσταση των χαρακτηριστικών (βλέπε ενότητα 2.2) που θα αποτελέσουν την είσοδο ώστε το σύστημα να “εκπαιδευτεί”. Η ακρίβεια της μαθημένης συνάρτησης εξαρτάται σε μεγάλο βαθμό από τον τρόπο αναπαράστασης της εισόδου. Κατά κανόνα, η είσοδος μετατρέπεται σε ένα διάνυσμα χαρακτηριστικών, το οποίο περιέχει ένα σύνολο χαρακτηριστικών που είναι περιγραφικά του αντικειμένου εισόδου. Ο αριθμός των χαρακτηριστικών δεν πρέπει να είναι πολύ μεγάλος, λόγω της “κατάρας της διαστατικότητας” (curse of dimensionality) [19], αλλά από την άλλη πρέπει να περιέχει αρκετές πληροφορίες για την ακριβή πρόβλεψη της εξόδου. Για ένα δεδομένο μέγεθος δείγματος, δηλαδή, υπάρχει ένας μέγιστος αριθμός χαρακτηριστικών πάνω από τον οποίο η απόδοση του ταξινομητή αντί να βελτιωθεί, μειώνεται.
4. Επιλογή αλγορίθμου: Προσδιόρισε τον αλγόριθμο εκμάθησης του μοντέλου. Για παράδειγμα, κάποιος μπορεί να επιλέξει να χρησιμοποιήσει Μηχανές Διανυσμάτων Υποστήριξης (SVM) ή Δέντρα αποφάσεων (Decision Trees).
5. Εκπαίδευση και αξιολόγηση: Ο σχεδιασμός ολοκληρώνεται. Τρέξε τον αλγόριθμο εκπαίδευσης στο σύνολο δεδομένων εκπαίδευσης (δηλαδή στον πίνακα των χαρακτηριστικών που έχουμε ήδη εξάγει σε προηγούμενο βήμα). Η αξιολόγηση του ταξινομητή (= της μαθημένης συνάρτησης) βασίζεται κυρίως στην ακρίβεια της πρόβλεψης που μπορεί να επιτύχει. Ένας από τους τρόπους που χρησιμοποιείται συχνά είναι η διασταυρούμενη επικύρωση (Cross-validation), όπου το σύνολο των χαρακτηριστικών χωρίζεται σε αμοιβαίως αποκλειόμενες ομάδες ίδιου μεγέθους. Κάθε φορά επιλέγουμε μία ομάδα πάνω στην οποία θα γίνει η αξιολόγηση και οι υπόλοιπες ομάδες χρησιμοποιούνται για την εκπαίδευση του ταξινομητή. Η ως άνω διαδικασία επαναλαμβάνεται τόσες φορές, όσες είναι και οι ομάδες στις οποίες διαιρέθηκε το σύνολο δεδομένων εκπαίδευσης. Ως τελικό αποτέλεσμα για την ακρίβεια του μοντέλου λαμβάνουμε τον μέσο όρο της ακρίβειας του μοντέλου στο σύνολο των επαναλήψεων.



Εικόνα 2-1: Η διαδικασία της εποπτευόμενης μηχανικής μάθησης

2.2. Εξαγωγή χαρακτηριστικών

Ο όρος «χαρακτηριστικά», χρησιμοποιείται για να υποδηλώσει ένα σύνολο (διάνυσμα) ποσοτικών δεικτών που εξάγονται ύστερα από κατάλληλη επεξεργασία των δεδομένων, με στόχο την κατηγοριοποίηση. Τα χαρακτηριστικά αυτά μπορεί να προέρχονται από μετασχηματισμούς των καταγεγραμμένων σημάτων, από στατιστική τους επεξεργασία κ.λπ.. Συχνά, είναι απαραίτητη η μείωση της διάστασης του διανύσματος των χαρακτηριστικών που έχουν εξαχθεί από τα δεδομένα [20]. Η επιλογή των καλύτερων χαρακτηριστικών αποσκοπεί αφενός στη μεγιστοποίηση της ακρίβειας ταξινόμησης και αφετέρου στην ελαχιστοποίηση της πολυπλοκότητας του συστήματος. Επειδή η εξέταση όλων των πιθανών συνδυασμών των χαρακτηριστικών μεγεθών (εξαντλητική αναζήτηση) είναι υπολογιστικά απαγορευτική, ακόμη και για μικρό πλήθος χαρακτηριστικών, έχουν αναπτυχθεί μέθοδοι αναζήτησης για την επιλογή

των καλύτερων χαρακτηριστικών. Οι μέθοδοι αυτές, εξισορροπούν την υπολογιστική πολυπλοκότητα με την ακρίβεια της ταξινόμησης, δηλαδή την εξαγωγή της μέγιστης δυνατής πληροφορίας στο μικρότερο δυνατό όγκο δεδομένων [21].

Τα χαρακτηριστικά που ως επί το πλείστον χρησιμοποιούνται στα προβλήματα αναγνώρισης ανθρώπινης δραστηριότητας χωρίζονται σε τρεις επιμέρους κατηγορίες: εκείνα που ανήκουν στο πεδίο του χρόνου, εκείνα που ανήκουν στον πεδίο των συχνοτήτων και εκείνα που συνδυάζουν τα δύο προαναφερόμενα πεδία και προέρχονται μετά από εφαρμογή του Διακριτού Μετασχηματισμού Κυματιδίων (Discrete Wavelet Transform – DWT). Στον Πίνακα 2-1 παρουσιάζονται κάποια από τα χαρακτηριστικά που χρησιμοποιούνται ευρέως σε προβλήματα αναγνώρισης ανθρώπινης δραστηριότητας [22, 23, 24, 25, 26, 27, 28, 29, 30, 5]. Ο αναγνώστης μπορεί να ανατρέξει στην παρεχόμενη βιβλιογραφία για περισσότερες πληροφορίες σχετικά με αυτά.

Πεδίο χρόνου
zero crossing rate
autocorrelation
variance
mean
standard deviation
Peak count
root mean square
interquartile range
median absolute deviation
pairwise correlation
temporal centroid
skewness
kurtosis
min
max
median
range maximum and minimum value
entropy
mean absolute deviation
cross correlation
median absolute deviation
Πεδίο συχνοτήτων
band power
power spectrum

log scale power bandwidth
maximum frequency
median frequency
fundamental frequency
power bandwidth
Fast Fourier Transform (FFT) coefficients
total energy
spectral centroid
spectral spread
spectral skewness
spectral kurtosis
spectral slope
spectral decrease
spectral roll-off point
spectral variation
spectral entropy
magnitude (a measure of the normalized value of the FFT coefficients)
maxinds (index of the frequency component with largest magnitude)
shannon spectral entropy
Πεδίο χρόνου - συχνοτήτων
Discrete Wavelet Transform
power of signal
squared coefficients
summations of the absolute values of detailed coefficients for each level

Πίνακας 2-1: Ορισμένα από τα συνήθη χαρακτηριστικά που χρησιμοποιούνται σε προβλήματα αναγνώρισης της ανθρώπινης δραστηριότητας.

2.3. Βαθιά Μάθηση

Η εξαγωγή χαρακτηριστικών είναι συνήθως αρκετά περίπλοκη διαδικασία και απαιτεί λεπτομερή γνώση της φύσης του προβλήματος. Το στάδιο προεπεξεργασίας πρέπει να προσαρμοστεί, να δοκιμαστεί και να τελειοποιηθεί μέσα από πολλές επαναλήψεις για βέλτιστα αποτελέσματα. Από τα μοντέλα βαθιάς μάθησης απουσιάζει το στάδιο εξαγωγής των χαρακτηριστικών χειροκίνητα, καθώς αυτά εξάγονται αυτόματα από το μοντέλο [31].

Η Βαθιά Μάθηση [10] αποτελεί υποσύνολο της Μηχανικής Μάθησης, που με τη σειρά της είναι υποσύνολο της Τεχνητής Νοημοσύνης (Εικόνα 2-2). Βασικό της χαρακτηριστικό είναι η εκμάθηση των υπολογιστών/μηχανών να λειτουργούν όπως δρουν φυσικά οι άνθρωποι, να

μαθαίνουν δηλαδή μέσα από τις εμπειρίες τους. Η βαθιά μάθηση χρησιμοποιεί νευρωνικά δίκτυα για να μάθει χρήσιμες αναπαραστάσεις χαρακτηριστικών απευθείας από τα δεδομένα. Τα νευρωνικά δίκτυα συνδυάζουν πολυεπίπεδα μη γραμμικά στρώματα επεξεργασίας, χρησιμοποιώντας απλά στοιχεία που λειτουργούν παράλληλα και έχουν εμπνευστεί από τα βιολογικά νευρικά συστήματα.

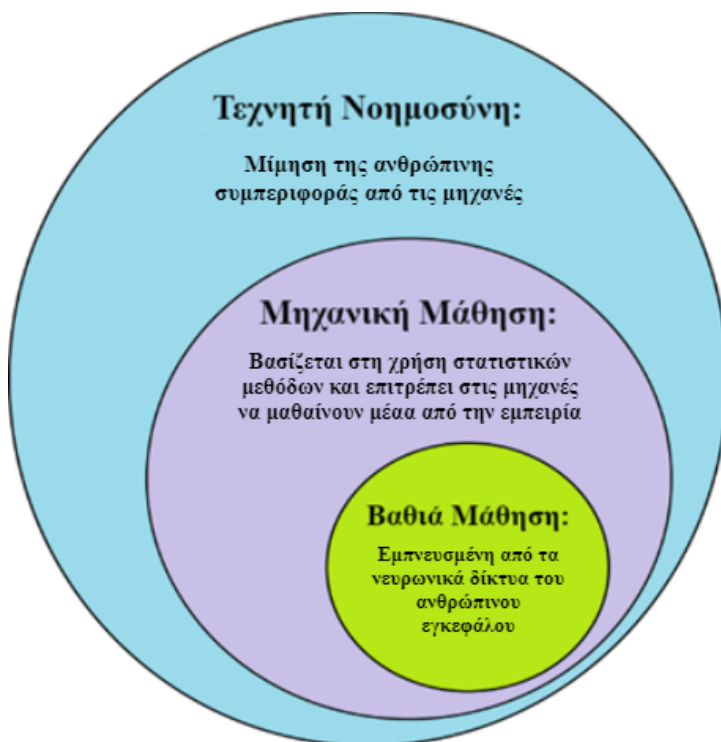
Η ανάπτυξη των μοντέλων βαθιάς μάθησης έγινε πραγματικότητα χάρη στην μεγάλη υπολογιστική ισχύ -και συνεπώς ταχύτητα- που απέκτησαν οι υπολογιστές τα τελευταία χρόνια, καθώς και στον μεγάλο όγκο δεδομένων που υπάρχουν πλέον διαθέσιμα για την εκπαίδευση μεγάλων νευρωνικών δικτύων (big data). Τα μοντέλα βαθιάς μάθησης τείνουν να αυξάνουν την ακρίβειά τους με τον αυξανόμενο αριθμό δεδομένων εκπαίδευσης, σε αντίθεση με τα παραδοσιακά μοντέλα μηχανικής μάθησης όπως ο ταξινομητής SVM και Naive Bayes που σταματούν να βελτιώνονται μετά από ένα σημείο κορεσμού [31].

Η εκπαίδευση των μοντέλων πραγματοποιείται χρησιμοποιώντας μια μεγάλη σειρά δεδομένων με ετικέτες και νευρωνικά δίκτυα που περιέχουν πολλά επίπεδα από στάδια επεξεργασίας πληροφορίας σε ιεραρχικές εποπτευόμενες αρχιτεκτονικές που χρησιμοποιούνται για μη εποπτευόμενη εκμάθηση χαρακτηριστικών για ανάλυση μοτίβων ή ταξινόμηση. Τα επίπεδα αυτά μπορούν να μάθουν μόνα τους μια εγγενή αναπαράσταση των ακατέργαστων δεδομένων απευθείας. Μια όλο και πιο αφηρημένη και συμπιεσμένη αναπαράσταση των ακατέργαστων δεδομένων παράγεται διαμέσου των πολλών επιπέδων των νευρικών δικτύων. Οι μέθοδοι βαθιάς μάθησης επιτρέπουν στα υπολογιστικά μοντέλα που συντίθενται από πολλαπλά επίπεδα μη γραμμικής επεξεργασίας πληροφορίας να μαθαίνουν ιεραρχικά αναπαραστάσεις δεδομένων με πολλαπλά επίπεδα αφαίρεσης, εξάγοντας σύνθετες σχέσεις μεταξύ των δεδομένων [32]. Αυτή η συμπιεσμένη αναπαράσταση των δεδομένων εισόδου χρησιμοποιείται στη συνέχεια για την παραγωγή του αποτελέσματος. Το αποτέλεσμα μπορεί να είναι, για παράδειγμα, η ταξινόμηση των δεδομένων εισόδου σε διαφορετικές κατηγορίες/κλάσεις.

Το βασικό σημείο πίσω από την φιλοσοφία των αρχιτεκτονικών βαθιάς μάθησης είναι ο υπολογισμός ιεραρχικών χαρακτηριστικών ή αναπαραστάσεων από τα παρατηρούμενα δεδομένα (δηλαδή τα ακατέργαστα δεδομένα), όπου τα χαρακτηριστικά υψηλότερου επιπέδου καθορίζονται από εκείνα των χαμηλότερων επιπέδων. Τα χαρακτηριστικά σε ένα μοντέλο βαθιάς μάθησης αναπαρίστανται αυτόματα από τα δεδομένα χρησιμοποιώντας μια γενικού σκοπού διαδικασία μάθησης [33], αντλώντας ιδέες και έμπνευση από τις θεωρίες πολυπλοκότητας βιολογικών και κυκλωματικών δικτύων.

Ορισμένα από τα μοντέλα βαθιάς μάθησης που έχουν αναπτυχθεί είναι τα Κλασικά Νευρωνικά Δίκτυα (Πολυεπίπεδα Perceptrons), τα Συνελκτικά Νευρωνικά Δίκτυα (CNNs), τα Επαναλαμβανόμενα Νευρωνικά Δίκτυα (RNNs), τα Δίκτυα Μακράς Βραχυπρόθεσμης Μνήμης (LSTMs), Γενετικά Ανταγωνιστικά Δίκτυα (GANs), τα Δίκτυα Βαθιάς Πίστης (DBNs), αυτοκωδικοποιητές (Autoencoders), κ.α.

Τα μοντέλα βαθιάς μάθησης βρίσκουν ευρεία εφαρμογή σε πλήθος πεδίων, όπως ταξινόμηση, ανάκτηση πληροφορίας, αναγνώριση εικόνας/φωνής, ρομποτική, κ.α.



Εικόνα 2-2: Η βαθιά μάθηση ως υποσύνολο της μηχανικής μάθησης, η οποία είναι υποσύνολο της τεχνητής νοημοσύνης

2.4. State-of-the-art προσεγγίσεις μηχανικής μάθησης συναφείς με το εξεταζόμενο θέμα

Η Μηχανική Μάθηση αποτελεί ίσως τον πιο ραγδαία αναπτυσσόμενο τομέα της Τεχνητής Νοημοσύνης, καθώς τα τελευταία χρόνια, ειδικά μετά την έλευση της βαθιάς μάθησης, έχει προσφέρει πληθώρα μεθόδων με πολύ καλά έως εντυπωσιακά αποτελέσματα σε όλες σχεδόν τις εφαρμογές που απαιτούν ευφυΐα. Συνεπώς, πληθώρα μελετών και ερευνών πραγματοποιούνται τα τελευταία χρόνια, ενώ συγκεκριμένα ο τομέας της αναγνώρισης της ανθρώπινης δραστηριότητας κεντρίζει σε μεγάλο βαθμό το ενδιαφέρον των ερευνητών. Στη

συνέχεια θα παρουσιάσουμε κάποιες από τις πιο πρόσφατες ερευνητικές μελέτες που έχουν πραγματοποιηθεί στον συγκεκριμένο τομέα.

Οι Kim et al. [34] προτείνουν ένα μοντέλο βαθιάς μάθησης βασισμένο στα Δίκτυα Μακράς Βραχυπρόθεσμης Μνήμης (LSTMs) για αναγνώριση δραστηριοτήτων σχετιζόμενες με την άσκηση βίας ανιχνεύοντας κατ' αυτό τον τρόπο πιθανές επικίνδυνες καταστάσεις. Χρήση της ίδιας μεθόδου βαθιάς μάθησης για αυτόματη αναγνώριση των κινήσεων των εργαζομένων στην κατασκευή αυτοκινητοδρόμων με χρήση αισθητήρων κίνησης προτείνουν οι Kim & Cho [35].

Οι Kanjilal και Uysal [36] σχεδίασαν ένα πειραματικό πλαίσιο εργασίας χρησιμοποιώντας τρεις διαφορετικούς αλγορίθμους βαθιάς μηχανικής μάθησης (Βαθιά Νευρωνικά Δίκτυα εμπρόσθιας τροφοδότησης, Επαναλαμβανόμενα Νευρωνικά Δίκτυα (RNNs) και μιας διάστασης συνελκτικά νευρωνικά δίκτυα (1D-CNN)) σε δεδομένα προερχόμενα από επιταχυνσιόμετρο για την αναγνώριση της ανθρώπινης δραστηριότητας παρουσιάζοντας υψηλά ποσοστά ακρίβειας.

Η μελέτη των Siirtola & Rönning [37] παρουσίασε μια νέα μέθοδο γνώσης και προσαρμογής σε διάφορα περιβάλλοντα για εξατομικευμένη αναγνώριση της ανθρώπινης δραστηριότητας μαθαίνοντας μέσα από ροές δεδομένων. Αυτό επιτυγχάνεται σταθμίζοντας τα πιο κατάλληλα πρότυπα βάσης ανάλογα με την απόδοσή τους στο τρέχον πλαίσιο. Έτσι, η στάθμιση διασφαλίζει ότι τα καλύτερα πρότυπα από το σύνολο των προτύπων για την τρέχουσα κατάσταση και περιβάλλον έχουν πάντα μεγαλύτερο βάρος στη διαδικασία πρόβλεψης από άλλα πρότυπα. Χρησιμοποίησαν στα πειράματά τους τρεις παρακάτω ταξινομητές: Γραμμική Διακριτική Ανάλυση (Linear Discriminant Analysis - LDA), Τετραγωνική Διακριτική Ανάλυση (Quadratic Discriminant Analysis – QDA) και Δέντρα παλινδρόμησης (regression tree).

Οι Pan και Wei [38] έκαναν χρήση των Μηχανών Διανυσμάτων Υποστήριξης (Support Vector Machines – SVMs) για αναγνώριση της ανθρώπινης δραστηριότητας σε εσωτερικούς χώρους. Δημιούργησαν μια βάση δεδομένων που περιέχει τον δείκτη ισχύος του λαμβανόμενου σήματος (RSSI) σε συγκεκριμένα σημεία αναφοράς. Συνεπώς, συνδύασαν για την εξαγωγή των χαρακτηριστικών πληροφορίες ισχύος του λαμβανόμενου σήματος, αλλά και επιτάχυνσης του υποκειμένου εντός του υπό μελέτη χώρου.

Στην μελέτη των Haroon και Premachand [39] γίνεται εξαγωγή χωρικών και χρονικών χαρακτηριστικών από δεδομένα που προέρχονται από βίντεο ή αλληλουχίες εικόνων από βαθιά

κάμερα τα οποία εκπαιδεύονται με τον αλγόριθμο ταξινόμησης K-πλησιέστεροι γείτονες (KNN) για αναγνώριση της ανθρώπινης δραστηριότητας.

Συνελικτικά νευρωνικά δίκτυα (CNNs) βασισμένα στην μεταφορά μάθησης (transfer learning) χρησιμοποίησαν οι Ramachandran και Pang [40] επιτυγχάνοντας αξιοσημείωτα αποτελέσματα και παράλληλα μειώνοντας το υπολογιστικό κόστος σε σύγκριση με μοντέλα βαθιάς μάθησης που υλοποίησαν, αλλά δεν βασίζονται στη μεταφορά μάθησης.

Οι Lewandowski et al. [41] ασχολούνται με τη χρήση ενσωματωμένων ταξινομητών στις φορέσιμες συσκευές (που φέρουν αισθητήρες), οι οποίες χρησιμοποιούνται για τη συλλογή σημάτων για αναγνώριση της ανθρώπινης δραστηριότητάς. Με τον τρόπο αυτό αποτρέπεται η μετάδοση δεδομένων που δεν είναι απαραίτητα ή χρήσιμα για την αναγνώριση της εκάστοτε δραστηριότητας. Έτσι, επιτυγχάνεται μείωση της κατανάλωσης ενέργειας και μακροπρόθεσμα μεγαλύτερη διάρκεια ζωής των φορέσιμων συσκευών. Στα πειράματά τους χρησιμοποίησαν πλήθος προσεγγίσεων ταξινόμησης: πιθανοτικά νευρωνικά δίκτυα (PNN), Μηχανές Διανυσμάτων Υποστήριξης (SVMs), K-πλησιέστεροι γείτονες (KNN), τυχαία δάση (RF), με τα τελευταία να επιδεικνύουν υψηλότερη απόδοση.

Οι Tian et al. [42] εξάγουν χαρακτηριστικά φασματικής ενέργειας κυματιδίου από δεδομένα επιταχυνσιόμετρο μεταξύ άλλων. Για την τελική επιλογή των χαρακτηριστικών χρησιμοποιούν συνδυαστικά φίλτρα, ενώ για την ταξινόμηση κάνουν χρήση του αλγορίθμου K-πλησιέστεροι γείτονες (KNN) και Μηχανές Διανυσμάτων Υποστήριξης (SVMs).

Ολοκληρώνουμε τη βιβλιογραφική ανασκόπηση των state-of-the-art προσεγγίσεων μηχανικής μάθησης με μια άλλη προσέγγιση που εφαρμόζεται συχνά τα τελευταία χρόνια και είναι αυτή της συνδυαστικής μάθησης (ensemble learning) που συνδυάζει τα αποτελέσματα πολλαπλών ταξινομητών για να παράγει ένα μοναδικό αποτέλεσμα εκτίμησης. Ένα τέτοιο μοντέλο σχεδίασαν οι Sekiguchi et al. [43] κάνοντας διαδοχικά χρήση Συνελικτικών Νευρωνικών Δικτύων (CNNs) και Ενίσχυση Κλίσης (Gradient boosting).

3. Συμβολική αναπαράσταση χρονοσειρών

Η πλειονότητα των δεδομένων που παράγονται στις μέρες μας (ιατρικά δεδομένα, μετεωρολογικά δεδομένα, αξία μετοχών, κ.λπ.) προέρχονται από ροές δεδομένων (streaming data) και είναι χρονοσειρές πραγματικών αριθμών. Για να καταστεί εφικτή η επεξεργασία τους είναι αναγκαία η μετατροπή τους σε προσεγγιστικές αναπαραστάσεις αυτών. Πολλές μέθοδοι έχουν προταθεί για την μείωση της διάστασής τους, οι περισσότερες εκ των οποίων είναι αριθμητικές, π.χ. ο διακριτός μετασχηματισμός Fourier (DFT), ο διακριτός μετασχηματισμός κυματιδίων (DWT), η αποσύνθεση μοναδικής τιμής (SVM), η ανάλυση στις κύριες συνιστώσες (PCA), η προσαρμοσμένη τμηματικά σταθερή προσέγγιση (APCA), η τμηματική συναθροιστική προσέγγιση (PAA), κ.α. [44, 45, 46].

Η προσπάθεια για αποτύπωση των χρονοσειρών ως συμβολοσειρές προέκυψε από το γεγονός πως η μετατροπή των πραγματικών σημάτων σε διακριτά δίνει την ευκαιρία στους ερευνητές για χρήση του μεγάλου πλούτου αλγορίθμων και δομών δεδομένων που έχουν υλοποιηθεί για χειρισμό αντίστοιχων αναπαραστάσεων. Τα μοντέλα συμβολικών αναπαραστάσεων εμφανίζουν εκτεταμένη χρήση πέραν της απλότητας, της αναγνωσιμότητας και της αποδοτικότητας στην αναπαράσταση χρονοσειρών που παρουσιάζουν, αλλά και εξαιτίας της δυνατότητας που παρέχουν για χρήση αλγορίθμων από άλλα πεδία, όπως από το πεδίο της επεξεργασίας κειμένου και ανάκτησης πληροφορίας, ή και από την βιοπληροφορική [44]. Μερικά παραδείγματα «εργαλείων» που δεν μπορούν να εφαρμοστούν σε ακολουθίες πραγματικών αριθμών, αλλά μπορούν σε συμβολικές αναπαραστάσεις περιλαμβάνουν τον κατακερματισμό (hashing), τα μαρκοβιανά μοντέλα, τα δέντρα επιθεμάτων, τα δέντρα αποφάσεων, κ.α. [46].

Με την ταχεία και ευρεία διάδοση των smartphones που διαθέτουν αισθητήρες, έχει επιτραπεί η ανάπτυξη στον τομέα της αναγνώρισης ανθρώπινων δραστηριοτήτων που με την σειρά του συνεισφέρει στην εξέλιξη και πρόοδο των υπηρεσιών υγείας, την καταγραφή των φυσικών δραστηριοτήτων, την ασφάλεια, κ.α. Πολλές προσεγγίσεις μηχανικής μάθησης έχουν προταθεί, από τεχνικές «ρηχής» μάθησης (π.χ. Support Vector Machines, Δέντρα αποφάσεων, Naive Bayes και K-Nearest Neighbours), έως τεχνικές «βαθιάς» μάθησης που βρίσκουν εφαρμογή και κερδίζουν έδαφος τα τελευταία χρόνια (π.χ. Convolutional Neural Networks (CNNs), Recurrent Neural Networks (RNNs), Restricted Boltzmann Machine (RBM), Sparse Autoencoder (SAE), Deep Feedforward Network (DFN) and Deep Boltzmann Machine (DBM)).

Παρά τις σημαντικές διαφορές που παρουσιάζουν και οι δύο αυτές προσεγγίσεις διαθέτουν ένα κοινό χαρακτηριστικό: αντιμετωπίζουν το πρόβλημα της υψηλής κατανάλωσης υπολογιστικών πόρων (μνήμης, υπολογιστικής ισχύος και κατ' επέκταση ενέργειας). Το προηγούμενο αποτελεί σημαντικό πρόβλημα συνυπολογίζοντας τους περιορισμένους πόρους που διαθέτουν τα smartphones και εν γένει οι φορέσιμες συσκευές. Οι αλγόριθμοι «βαθιάς» μάθησης συγκεκριμένα, έχουν αυξημένες απαιτήσεις σε υπολογιστικούς πόρους για online εφαρμογές και ανάγκη για σύνδεση σε εξυπηρετητή (server).

Σε αυτό ακριβώς το πρόβλημα έρχεται να δώσει λύση η τεχνική της συμβολικής αναπαράστασης των χρονοσειρών που περιγράφηκε παραπάνω. Τα βιοϊατρικά σήματα που λαμβάνονται για την αναγνώριση ανθρώπινων δραστηριοτήτων σχηματίζουν μεγάλα σε μέγεθος σύνολα δεδομένων, γεγονός που καθιστά δύσκολη την επεξεργασία τους και τη χρήση τους για σκοπούς ταξινόμησης. Εκμεταλλευόμενοι, ωστόσο, την ευελιξία και συμπίκνωση πληροφορίας που προσφέρουν οι συμβολικές αναπαραστάσεις, καθίσταται εφικτή η αναπαράσταση αυτού του μεγάλου όγκου δεδομένων με λογικό και αντιπροσωπευτικό πλήθος συμβόλων. Το τελευταίο έχει με τη σειρά του συνεισφορά στη μείωση της πολυπλοκότητας και του υπολογιστικού κόστους των διαφόρων προσεγγίσεων για αναγνώριση ανθρώπινων δραστηριοτήτων, ανοίγοντας νέους δρόμους για την υιοθέτηση νέων στρατηγικών αναγνώρισης ανθρώπινων δραστηριοτήτων σε συσκευές με περιορισμένες δυνατότητες σε μνήμη και υπολογιστική ισχύ.

3.1. Συμβολική Συναθροιστική Προσέγγιση (Symbolic Aggregate Approximation - SAX)

Η μέθοδος SAX αποτελεί μια προσέγγιση που επιτρέπει τη συμβολική αναπαράσταση χρονοσειρών. Με την συγκεκριμένη μεθοδολογία επιτυγχάνεται μείωση των διαστάσεων του προβλήματος, γεγονός πολύ σημαντικό που επιδρά στην ταχύτητα και αποδοτικότητα των χρησιμοποιούμενων αλγορίθμων. Επιπλέον, μπορούν να χρησιμοποιηθούν διάφορα μέτρα απόστασης (Ευκλείδεια, Manhattan, Minkowski) για σύγκριση των συμβολοσειρών (στο συμβολικό χώρο) που σχετίζονται με τα μέτρα απόστασης των αρχικών χρονοσειρών. Επίσης, με τα μέτρα απόστασης που εφαρμόζονται, υπάρχει εγγύηση για ύπαρξη κάτω φραγμάτων (lower bounding) [46]. Κατά συνέπεια, επιτυγχάνεται μείωση της πολυπλοκότητας και του απαιτούμενου χρόνου για υπολογισμό της απόστασης.

Επιπρόσθετα, η μέθοδος SAX μπορεί να εφαρμοστεί σε χρονοσειρές οποιουδήποτε μεγέθους ενώ μπορεί να υλοποιηθεί με ευκολία, με απαιτήσεις σε υπολογιστικούς πόρους και χωρητικότητα μνήμης περιορισμένες. Τέλος, να σημειωθεί ότι η εφαρμογή της δεν προϋποθέτει την πρόσβαση σε όλα τα δεδομένα της βάσης δεδομένων, γεγονός που την καθιστά ικανή επιλογή για επεξεργασία και διαχείριση των χρονοσειρών ως ροές δεδομένων (streaming data) [47].

Στη συνέχεια θα παρουσιάσουμε λεπτομερώς τα βήματα της μεθόδου SAX:

- Τμηματική Συναθροιστική Προσέγγιση (PAA)
- Διακριτοποίηση
- Έξυπνα εικονίδια

3.1.1. Τμηματική Συναθροιστική Προσέγγιση (Piecewise Aggregate Approximation - PAA)

Η Τμηματική Συναθροιστική Προσέγγιση είναι μια τεχνική που εφαρμόζεται κι έχει ως στόχο την μείωση των διαστάσεων του προβλήματος [48, 46]. Η κύρια ιδέα πίσω από την εφαρμογή της είναι ο υπολογισμός της μέσης τιμής ενός συνόλου σημείων που απαρτίζουν ένα τμήμα της χρονοσειράς και εν τέλει η αντικατάσταση αυτού του τμήματος με την υπολογισθείσα μέση τιμή. Με αυτό τον τρόπο επιτυγχάνεται η μείωση της διάστασης του προβλήματος και η μείωση του θορύβου ενώ ταυτόχρονα διατηρείται η τάση της χρονοσειράς.

Πιο συγκεκριμένα, με αυτή την τεχνική μετασχηματίστηκε μια χρονοσειρά X , μήκους n σε μια άλλη χρονοσειρά X' , μήκους m , όπου $m < n$.

$$X = \{x_1, x_2, x_3, \dots, x_n\} \quad \rightarrow \quad X' = \{x_1', x_2', x_3', \dots, x_m'\}, \quad m < n,$$

όπου κάθε x_i' υπολογίζεται από τον τύπο:

$$x_i' = \frac{m}{n} \sum_{j=\frac{n}{m}(i-1)+1}^{\frac{n}{m}i} x_j \quad (2)$$

Αν παρατηρήσουμε την παραπάνω σχέση διαπιστώνουμε ότι περιγράφει τον υπολογισμό μέσης τιμής. Με άλλα λόγια, με στόχο τη μείωση της διάστασης από n σε m , πρωταρχικά διαιρούμε την υπό διερεύνηση χρονοσειρά σε m ισομεγέθη τμήματα και δευτερευόντως υπολογίζουμε τη μέση τιμή των τιμών καθενός από τα τμήματα m , επιφέροντας έτσι συμπίεση στην αρχική

χρονοσειρά κατά έναν παράγοντα n/m . Η ακολουθία που προκύπτει από τις υπολογισθείσες μέσες τιμές (που ονομάζονται συντελεστές PAA) αποτελεί την Τμηματική Συναθροιστική Προσέγγιση της αρχικής χρονοσειράς.

Χρησιμοποιώντας το ακόλουθο μέτρο απόστασης που ουσιαστικά υποδηλώνει την Ευκλείδεια απόσταση μεταξύ δύο μετασχηματισμένων κατά PAA χρονοσειρών X', Y'

$$D_{PAA}(X', Y') \equiv \sqrt{\frac{n}{m} \sum_{i=1}^m (x'_i - y'_i)^2} \quad (3)$$

οι Yi & Faloutsos [49], και Keogh et al. [48] έχουν αποδείξει ότι η τεχνική PAA ικανοποιεί τη συνθήκη ύπαρξης κάτω φραγμάτων αποδεικνύοντας πως:

$$D_{PAA}(X', Y') \leq D(X, Y) \quad (4)$$

όπου $D(X, Y)$ η Ευκλείδεια απόσταση μεταξύ των αρχικών χρονοσειρών X, Y που δίνεται από τον τύπο:

$$D(X, Y) \equiv \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (5)$$

3.1.2. Διακριτοποίηση

Στο στάδιο της διακριτοποίησης, που αποτελεί και τον πυρήνα της μεθόδου SAX, κατ' ουσίαν αναθέτουμε ένα σύμβολο σε καθένα από τα m τμήματα όπου προηγουμένως υπολογίσαμε τη μέση τιμή (που είναι οι συντελεστές PAA).

$$X' = \{x'_1, x'_2, x'_3, \dots, x'_m\} \rightarrow S = \{s_1, s_2, s_3, \dots, s_m\},$$

όπου X' είναι η χρονοσειρά μήκους m όπως αυτή προέκυψε μετά την εφαρμογή της PAA, και S είναι η συμβολοσειρά μήκους m που θα προκύψει μετά την εφαρμογή του σταδίου της διακριτοποίησης.

Προς τούτο, αρχικά επιλέγουμε το μέγεθος του αλφαβήτου α . Με άλλα λόγια, επιλέγουμε πόσα σύμβολα θα είναι διαθέσιμα προς ανάθεση. Π.χ. αν $\alpha = 3$ (δηλαδή το μέγεθος του αλφαβήτου να ισούται με 3), τότε κάθε τμήμα μπορεί να αναπαρασταθεί με ένα εκ των 'a', 'b', 'c' συμβόλων.

Αν επιλέξουμε μέγεθος αλφαβήτου $\alpha = p$, τότε ας θεωρήσουμε το αλφάβητό μας A που θα αποτελείται από τα εξής σύμβολα:

$$A = \{\alpha_1, \alpha_2, \alpha_3, \dots, \alpha_p\}.$$

Κάθε σύμβολο θα πρέπει να παρουσιάζει ίση πιθανότητα εμφάνισης. Μια τέτοια συνθήκη εξασφαλίζεται από το γεγονός πως τα παράθυρα μετά την κανονικοποίηση ακολουθούν την κανονική κατανομή [46]. Με βάση το μέγεθος του αλφαβήτου ορίζουμε τόσες περιοχές τιμών όσες και το μέγεθος του αλφαβήτου που επιλέξαμε. Το εύρος τιμών μιας περιοχής καθορίζεται από τις οριακές τιμές (breakpoints) β_i , με $i = 1, 2, \dots, p - 1$, που λαμβάνονται από τον πίνακα της κανονικής κατανομής (Εικόνα 3-1), ώστε κάθε περιοχή να ικανοποιεί τη συνθήκη μια τιμή να εμφανίζει ίδια πιθανότητα να ανήκει σε μία από αυτές [50, 51]. Πιο συγκεκριμένα, το εμβαδόν κάθε περιοχής κάτω από την καμπύλη της κανονικής κατανομής μεταξύ των τιμών β_i και β_{i+1} ισούται με $1/\alpha$ [47].


$\beta_i \backslash a$	3	4	5	6	7	8
β_1	-0.43	-0.67	-0.84	-0.97	-1.07	-1.15
β_2	0.43	0	-0.25	-0.43	-0.57	-0.67
β_3		0.67	0.25	0	-0.18	-0.32
β_4			0.84	0.43	0.18	0
β_5				0.97	0.57	0.32
β_6					1.07	0.67
β_7						1.15

Εικόνα 3-1: Πίνακας εύρεσης οριακών τιμών β_i

Πλέον είμαστε σε θέση να προχωρήσουμε στην μετατροπή των πραγματικών τιμών σε σύμβολα με βάση την ακόλουθη σχέση:

$$s_i = \left\{ \begin{array}{l} a_1, \text{ εάν } \{x_i' \in (-\infty, \beta_1]\} \\ a_2, \text{ εάν } \{x_i' \in (\beta_1, \beta_2]\} \\ \vdots \\ a_p, \text{ εάν } \{x_i' \in (\beta_{p-1}, +\infty)\} \end{array} \right\}, \text{ όπου } i = 1, 2, 3, \dots, m \quad (6)$$

Με την διαδικασία που μόλις περιγράφηκε επιτύχαμε να μεταφέρουμε μια χρονοσειρά από τον χώρο των πραγματικών αριθμών στον συμβολικό χώρο (εφόσον μετατράπηκε σε συμβολοσειρά) γεγονός σημαντικό για την περαιτέρω εφαρμογή τεχνικών ανάλυσης δεδομένων, καθώς παρέχεται ευελιξία, χωρίς να χάνεται κρίσιμη πληροφορία. Η Εικόνα 3-2 αναπαριστά σχηματικά την μετατροπή που επιτεύχθηκε.



Εικόνα 3-2: Μετατροπή του σήματος από τον χώρο των πραγματικών αριθμών στον συμβολικό χώρο.

3.1.3. Έξυπνα εικονίδια

Τα έξυπνα εικονίδια είναι μια μέθοδος που απεικονίζει τα αποτελέσματα μετά την εφαρμογή της διακριτοποίησης [52]. Με αυτόν τον τρόπο, υπολογίζουμε τη συχνότητα εμφάνισης συμβόλου ή ομάδας συμβόλων (που λέγονται λέξεις) μέσα σε ένα παράθυρο δημιουργώντας προσεγγίσεις των υποκειμένων συναρτήσεων μάζας πιθανότητας [53]. Οι λέξεις μπορούν να λάβουν διάφορα μήκη και η επιλογή του μήκους επαφίεται στον σχεδιασμό, την διαθεσιμότητα σε πόρους και τις επιδιώξεις του ερευνητή. Σε κάθε περίπτωση, θα πρέπει να επιτευχθεί ισορροπία ανάμεσα στην ακρίβεια πρόβλεψης του μοντέλου και στο υπολογιστικό κόστος (και την συνεπακόλουθη ταχύτητα αναγνώρισης μιας κλάσης) που απαιτείται για τον υπολογισμό των έξυπνων εικονιδίων.

Τα βήματα που ακολουθούνται για την εύρεση των έξυπνων εικονιδίων είναι τα παρακάτω:

- Υπολογίζουμε όλους τους πιθανούς συνδυασμούς συμβόλων του αλφαβήτου που ορίζουν τις πιθανές λέξεις. Δηλαδή, οι συνδυασμοί που θα προκύψουν (με άλλα λόγια οι λέξεις που σχηματίζονται) θα έχουν πλήθος = $(\text{μέγεθος αλφαβήτου})^{(\text{μήκος λέξης})}$. Συνεπώς, αν επιλέξουμε $\text{μέγεθος αλφαβήτου} = 3$ και $\text{μήκος λέξης} = 2$, οι πιθανές λέξεις είναι $3^2 = 9$, οι οποίες και παρουσιάζονται στον Πίνακα 3-1.

aa	ba	ca
ab	bb	cb
ac	bc	cc

Πίνακας 3-1: Οι πιθανές λέξεις που σχηματίζονται για μέγεθος αλφαβήτου = 3 και μήκος λέξης = 2

- Με την ολοκλήρωση του σταδίου της διακριτοποίησης προέκυψε μια συμβολοσειρά από κάθε χρονικό παράθυρο. Για κάθε λέξη βρίσκουμε το πλήθος των εμφανίσεών της μέσα στη συμβολοσειρά που αναπαριστά ένα παράθυρο.
- Δημιουργούμε πίνακα που περιλαμβάνει στην αντίστοιχη θέση του Πίνακα 3-1 τη συχνότητα εμφάνισης κάθε λέξης, όπως φαίνεται στην Εικόνα 3-3. Βλέπουμε τη συχνότητα εμφάνισης κάθε λέξης η οποία βρίσκεται στο αντίστοιχο κελί του Πίνακα 3-1. Π.χ. το κελί {2, 3} αντιστοιχεί με βάση τον Πίνακα 3-1 στη λέξη *cb*. Άρα η

συγκεκριμένη λέξη εμφανίζεται μία φορά εντός της υπό μελέτη συμβολοσειράς 'bcaaacbbbbb'. Ο πίνακας που σχηματίστηκε αποτελεί το έξυπνο εικονίδιο του παραθύρου και αποτυπώνεται στην Εικόνα 3-3.

1	2	0	1
2	0	4	1
3	1	1	0
	1	2	3

Εικόνα 3-3: Το έξυπνο εικονίδιο που εξήχθη από τη συμβολοσειρά 'bcaaacbbbbb'. Κάθε αριθμός δείχνει τη συχνότητα εμφάνισης της λέξης που βρίσκεται στο αντίστοιχο κελί του πίνακα 3-1.

Το σύνολο των έξυπνων εικονιδίων που εξάγονται από όλα τα παράθυρα αποτελούν τον πίνακα των χαρακτηριστικών για το συγκεκριμένο μοντέλο.

3.2. Παραλλαγές

Η μέθοδος SAX έχει γνωρίσει ευρεία αποδοχή λόγω των συγκριτικών πλεονεκτημάτων που παρουσιάζει, αλλά και της διαισθητικής της φύσης, και πλήθος ερευνητών έχει ασχοληθεί διαχρονικά. Ως αποτέλεσμα έχουν αναπτυχθεί διάφορες παραλλαγές που παρουσιάζουν ενδιαφέρον και στοχεύουν στη βελτιστοποίηση της μεθόδου.

Είναι λογικό η μέθοδος SAX να παρουσιάζει και ορισμένα μειονεκτήματα με κυριότερα εκ των οποίων, αφενός την ανάγκη για καθορισμό αρκετών παραμέτρων που επηρεάζουν σημαντικά το τελικό αποτέλεσμα, αφετέρου την εγγενή αδυναμία της μεθόδου να παρέχει πληροφορία για απότομες μεταβολές στις τιμές των δεδομένων των αρχικών χρονοσειρών.

Το τελευταίο είναι εξαιρετικής σημασίας ειδικότερα σε περιπτώσεις όπου οι απότομες αυτές μεταβολές αντιστοιχούν σε πρότυπα συμπεριφοράς των δεδομένων που περιγράφουν κρίσιμη πληροφορία σχετικά με την υπό μελέτη χρονοσειρά. Με άλλα λόγια ο συμψηφισμός περιοχών τιμών υπό την έννοια του μέσου όρου επιφέρει σε ορισμένες περιπτώσεις την απώλεια της πραγματικής φύσης του χρονικά μεταβαλλόμενου μεγέθους που περιγράφει η χρονοσειρά.

Κάτι τέτοιο είναι ιδιαίτερα εμφανές σε χρονοσειρές που αναπαριστούν οικονομικά δεδομένα, τα οποία χαρακτηρίζονται από απότομες αυξομειώσεις που είναι μείζονος σημασίας για την ανάλυση αυτών των δεδομένων. Για το πρόβλημα αυτό προτάθηκε λύση με την εισαγωγή του ESAX [54, 55] όπου πέραν του συμβολισμού για την μέση τιμή προστίθενται δύο ακόμα σύμβολα που περιγράφουν την μέγιστη και την ελάχιστη, αντίστοιχα, τιμή ενός τμήματος. Για την αντιμετώπιση του ίδιου ζητήματος οι Li et al. [56] πρότειναν τον TSX που εισάγει άλλα τρία σύμβολα για την αναπαράσταση ενός τμήματος. Το πρώτο αφορά την κλίση της ευθείας που ενώνει το αρχικό με το τελικό σημείο, ενώ τα άλλα δύο την απόσταση από αυτή την ευθεία των σημείων άνω και κάτω της ευθείας που απέχουν το μέγιστο από αυτή. Η μέθοδος TFSAX [57] προσθέτει ένα επιπλέον σύμβολο που αναπαριστά την κλίση της ευθείας που ενώνει το αρχικό με το τελικό σημείο.

Ο iSAX [58] δεν αποτελεί ακριβώς παραλλαγή, αλλά μάλλον υπερσύνολο της μεθόδου SAX, καθώς αποτελεί μια αναπαράσταση που υποστηρίζει την ευρετηρίαση τεράστιων συνόλων δεδομένων και έχει αποδειχτεί ότι μπορεί να κάνει ευρετηρίαση σε έως και εκατό εκατομμύρια χρονοσειρές. Σε μεταγενέστερη μελέτη [59] οι συγγραφείς έδειξαν ότι μπορεί να γίνει ευρετηρίαση σε έως κι ένα δισεκατομμύριο χρονοσειρές.

Οι Pham et al. [60] πρότειναν τον *aSAX* και *iaSAX*. Ο πρώτος αποτελεί ένα συνδυασμό του αλγορίθμου SAX και του αλγορίθμου *k*-means και αντιμετωπίζει το ζήτημα της μεγάλης εξάρτησης του SAX από την ιδιότητα της γκαουσιανής κατανομής των χρονοσειρών. Από την άλλη, ο *iaSAX* δεν είναι τίποτε άλλο παρά ο αντίστοιχος με τον *iSAX* αλγόριθμος ευρετηρίασης ακολουθώντας την μέθοδο *aSAX*.

Ο SFA [61] βασίζεται στη διακριτοποίηση μέσω του διακριτού μετασχηματισμού Fourier καθώς αυτός παρέχει στατιστικά σημαντικό πιο σφιχτό κάτω φράγμα, πλέον της ικανότητας για πιο ολοκληρωμένη περιγραφή του σήματος εξαιτίας της μετάβασης στο πεδίο των συχνοτήτων.

Ο GASAX [62] προτάθηκε για τον προσδιορισμό των οριακών σημείων χρησιμοποιώντας ένα γενετικό αλγόριθμο. Ο στόχος του GASAX είναι να βρει την σχεδόν βέλτιστη κατανομή των οριακών τιμών που δίνει την καλύτερη αρμοστικότητα. Ο συγγραφέας υποστήριξε ότι η υπόθεση κανονικότητας υπερ-απλοποιεί το πρόβλημα των αναπαραστάσεων του SAX και ενδέχεται να οδηγήσει σε υψηλό σφάλμα κατά την εκτέλεση εργασιών εξόρυξης χρονοσειρών. Παρόλο που ο GASAX λειτουργεί καλά τόσο σε κανονικοποιημένα όσο και σε μη

κανονικοποιημένα δεδομένα χρονοσειρών, πρέπει να καθοριστούν κατάλληλες παράμετροι ελέγχου και αποτυγχάνει να συμπεριλάβει πληροφορίες σχετικά με την τάση της εκάστοτε χρονοσειράς.

Στη συνέχεια της βιβλιογραφικής ανασκόπησης εντοπίσαμε τον 1d-SAX [44]. Κατ' ουσίαν υπολογίζει την κλίση της ευθείας ελαχίστων τετραγώνων (γραμμική παλινδρόμηση) σε κάθε τμήμα και συνδυάζει αυτή την τιμή με την μέση τιμή του τμήματος, ώστε εν τέλει να προκύψει ένα και μόνο σύμβολο. Με αυτό τον τρόπο αποφεύγεται η αύξηση της πολυπλοκότητας του προτεινόμενου αλγορίθμου από την προσθήκη επιπλέον συμβόλων, όπως συμβαίνει σε άλλες παραλλαγές. Ο TrSAX [63] βασίζεται και αυτός στον υπολογισμό της κλίσης της ευθείας ελαχίστων τετραγώνων σε κάθε τμήμα, ωστόσο αντιστοιχίζει την τιμή αυτή σε ένα επιπλέον σύμβολο.

Στον αλγόριθμο SAX-EFG [64] γίνεται συνδυασμός του SAX με την τεχνική δημιουργίας χαρακτηριστικών βασισμένη σε εξελικτικό αλγόριθμο, τον EFG, που χρησιμοποιήθηκε για την δημιουργία επιλεκτικών χαρακτηριστικών για την ταξινόμηση ακολουθιών DNA. Κατ' αντιστοιχία, στον SAX-EFG χρησιμοποιούνται μοτίβα προερχόμενα από τον SAX ως δομικά στοιχεία για την κατασκευή πιο σύνθετων χαρακτηριστικών.

Ο SAX-TD [65] επιχειρεί κι αυτός να αντιμετωπίσει το πρόβλημα της απώλειας της τάσης της χρονοσειράς υπολογίζοντας τις αποκλίσεις των αποστάσεων των αρχικών και τελικών σημείων από την μέση τιμή, μεταξύ διαδοχικών τμημάτων της χρονοσειράς. Με την διατήρηση της τάσης ασχολείται και ο TSAX [66].

Ο TFSA [67] επικεντρώνεται στη διατήρηση των περισσότερων από τα χαρακτηριστικά της τάσης και των μοτίβων της πρωτότυπης χρονοσειράς, και αναπαριστά τις χρονοσειρές χρησιμοποιώντας σύμβολα τάσης που είναι επίσης κατάλληλα για ανακάλυψη γνώσης.

Οι Zan & Yamana [68] πρότειναν τον SAX_SD που προσθέτει ένα επιπλέον χαρακτηριστικό που είναι στατιστικό μέγεθος, την τυπική απόκλιση, και που εμφανίζει την κατανομή των σημείων σε κάθε τμήμα της χρονοσειράς.

Η μέθοδος APAA/ASAX [69] χρησιμοποιεί μη σταθερό μέγεθος τμημάτων, αλλά προσαρμοζόμενο στα γεγονότα ενδιαφέροντος της χρονοσειράς αποφεύγοντας την διακοπή ή την παρατεταμένη διάρκεια αυτών.

Ο SAX-BD [70] συνδυάζει τα πλεονεκτήματα των ESAX και SAX-TD χρησιμοποιώντας την σταθμισμένη οριακή απόσταση ως νέο μέτρο απόστασης για την λήψη της νέας αναπαράστασης χρονοσειρών. Τέλος, η πιο πρόσφατη βιβλιογραφική αναφορά είναι ο SAX-TM [71] που χρησιμοποιεί πίνακες μεταβάσεων για να διατηρήσει την πληροφορία που περιγράφει την τάση της χρονοσειράς.

4. Δεδομένα

Τα δεδομένα που χρησιμοποιήσαμε στην παρούσα εργασία είναι μέρος της βάσης δεδομένων RealWorld (HAR) που είναι διαθέσιμη από το πανεπιστήμιο του Μάνχαϊμ [72]. Συνοπτικά, τα κύρια στοιχεία της βάσης απεικονίζονται στην Εικόνα 4-1 που προέρχεται από τον ιστότοπο της βάσης [73].

RealWorld (HAR)	(2016)
• 15 Subjects	Walking
• 6 Sensors	Running
• 7 Body positions	Sitting
• Video recordings	Standing
	Lying
	Stairs Up
	Stairs Down
	Jumping

Εικόνα 4-1: Τα κύρια στοιχεία της βάσης δεδομένων RealWorld (HAR) [73]

4.1. Περιγραφή βάσης δεδομένων

Πιο αναλυτικά, η βάση καταρτίστηκε με την συμμετοχή δεκαπέντε ατόμων (αποκαλούμενα και υποκείμενα), οκτώ ανδρών και επτά γυναικών ώστε να υπάρχει ομοιόμορφη κατανομή. Τα χαρακτηριστικά τους κυμαίνονται ως εξής :

- Ηλικία: 31.9 ± 12.4 έτη
- Ύψος: 173.1 ± 6.9 εκατοστά
- Βάρος: 74.1 ± 13.8 κιλά

Στην βάση δεδομένων έχουν καταγραφεί για κάθε υποκείμενο οι εξής πληροφορίες: το αναγνωριστικό του, το φύλο του, η ηλικία του, το ύψος του, το βάρος του, το επάγγελμά του, στοιχεία που παρουσιάζονται στην Εικόνα 4-2.

Subjects	Gender	Age	Height (cm)	Weight (kg)	Occupation
1	Female	52	163 cm	48	Industrial Management Assistant
2	Male	26	179	70	Business Informatics
3	Male	27	176	81	Business Informatics
4	Male	26	183	82	Business Informatics
5	Male	62	170	70	Telecommunication Engineer
6	Female	26	174	65	Geriatric Nurse Assistant
7	Male	26	180	81	Business Informatics
8	Female	36	165	95	Nationally Certified Physical Therapist
9	Male	26	179	95	Plumbing and Heating Installer
10	Male	26	170	90	Chemical Laboratory Assistant
11	Female	48	175	71	Industrial Management Assistant
12	Female	16	164	54	Pupil
13	Female	27	170	65	Japanology
14	Male	26	183	78	Business Informatics
15	Female	30	165	66	Geologist

Εικόνα 4-2: Πληροφορίες υποκειμένων της βάσης δεδομένων RealWorld (HAR)

Οι δραστηριότητες στις οποίες υποβλήθηκε το κάθε άτομο ήταν οι οκτώ ακόλουθες:

- κατέβασμα σκάλας,
- ανέβασμα σκάλας,
- αναπήδηση,
- κατάκλιση,
- τρέξιμο,
- κάθισμα,
- όρθια στάση,
- βάδιση.

Το σύνολο των αισθητήρων που χρησιμοποιήθηκαν ήταν έξι και συγκεκριμένα επιταχυνσιόμετρο, συσκευή πλοήγησης GPS, γυροσκόπιο, φωτόμετρο, μαγνητόμετρο και ηχώμετρο. Η δειγματοληψία των αισθητήρων καταγράφεται σε Hz, δηλαδή σε δείγματα ανά δευτερόλεπτο, και καθορίζεται από την συσκευή καθώς και από το λογισμικό που δημιουργήθηκε για την συλλογή των δεδομένων. Οι ρυθμοί δειγματοληψίας για κάθε αισθητήρα παρουσιάζονται ακολούθως:

- Επιταχυνσιόμετρο: 50 Hz

- Συσκευή πλοήγησης GPS: 1/10 Hz
- Γυροσκόπιο: 50 Hz
- Φωτόμετρο: 50 Hz
- Μαγνητόμετρο: 50 Hz
- Ηχώμετρο: 1.5 Hz

Οι αισθητήρες ήταν ενσωματωμένοι σε φορέσιμες συσκευές, συγκεκριμένα σε smartphone (Samsung Galaxy S II) και σε smartwatch (LG G Watch R). Έξι από τα ως άνω smartphones και ένα smartwatch τοποθετήθηκαν σε επτά διαφορετικές θέσεις του σώματος των υποκειμένων: στήθος, πήχυς, κεφάλι, κνήμη, μηρός, μπράτσο, μέση και κατέγραφαν ταυτόχρονα τα αντίστοιχα σήματα, ενώ παράλληλα πραγματοποιούνταν και βιντεοσκόπηση των καταγραφών.

Κάθε άτομο πραγματοποίησε κάθε δραστηριότητα¹ περίπου 10 λεπτά, εκτός από τη σωματική άσκηση “αναπήδηση” που ήταν περίπου 1,7 λεπτά για λόγους σχετιζόμενους με ταχύτερη σωματική κόπωση λόγω μεγάλης έντασης της δραστηριότητας.

Για τους σκοπούς τους παρούσας εργασίας χρησιμοποιήθηκαν τα δεδομένα που προέρχονται μόνο από τον πήχυ, και πιο συγκεκριμένα δεδομένα επιταχυνσιόμετρου και γυροσκοπίου. Το επιταχυνσιόμετρο μετρά την επιτάχυνση (σε m/s^2), ενώ το γυροσκόπιο τη γωνιακή ταχύτητα (σε rad/s) τους κινούμενου σώματος.

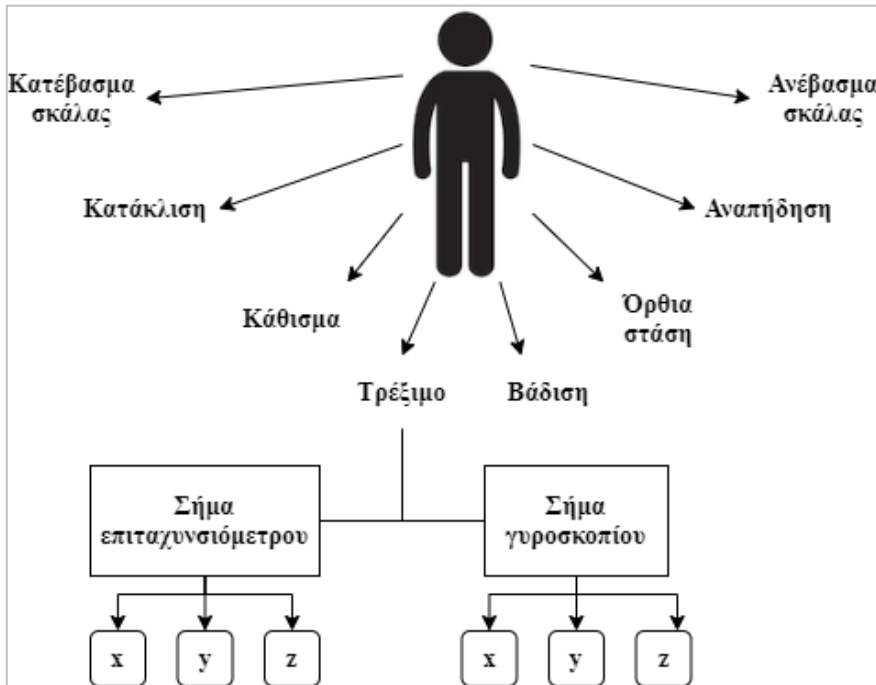
Το επιταχυνσιόμετρο και το γυροσκόπιο παρέχουν έκαστο από τρεις τιμές για κάθε χρονική στιγμή, μία για κάθε διάσταση του τρισδιάστατου χώρου (x, y, z αντίστοιχα) που ουσιαστικά περιγράφουν την κίνηση του υποκειμένου στον χώρο, όπως φαίνεται και στην Εικόνα 4-3.



Εικόνα 4-3: Καταγραφή σημάτων από τους αισθητήρες της συσκευής smartwatch στον τρισδιάστατο χώρο

¹ Από το δεύτερο άτομο απουσίαζαν δεδομένα για την δραστηριότητα ‘ανέβασμα σκάλας’ .

Ανακεφαλαιώνοντας, έχουμε στη διάθεσή μας για καθένα από τα 15 άτομα σήματα από επιταχυνσιόμετρο και γυροσκόπιο, για κάθε μία από τις 8 καταγεγραμμένες δραστηριότητες, και για τις τρεις διαστάσεις του χώρου x, y, z, όπως φαίνεται σχηματικά και στην Εικόνα 4-4.

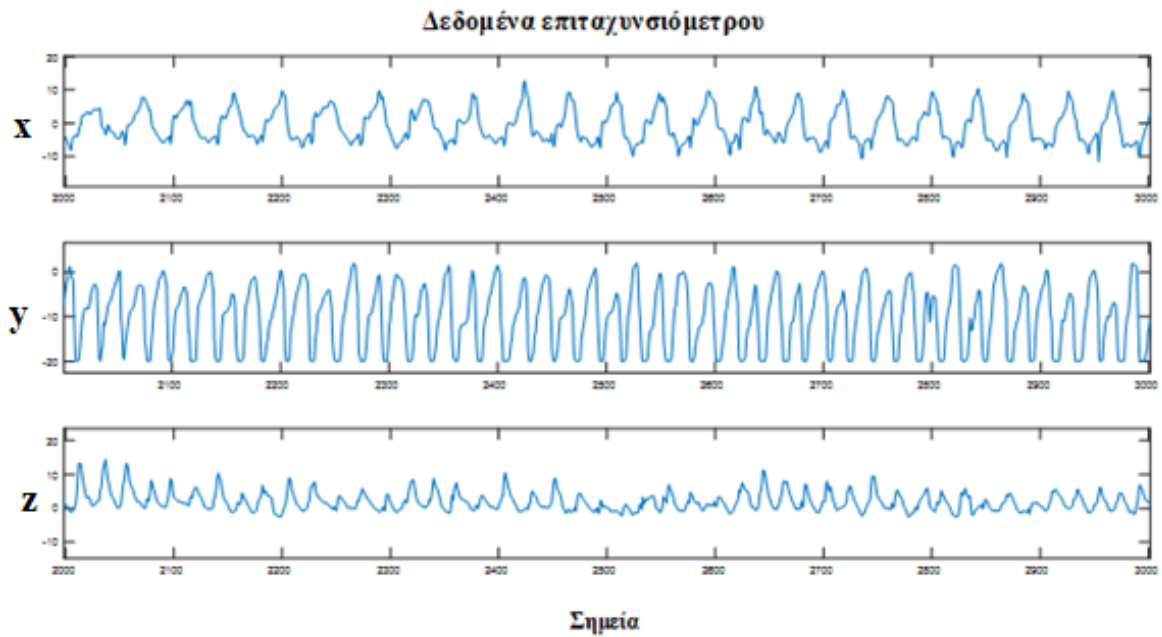


Εικόνα 4-4: Η κατανομή και προέλευση των σημάτων που χρησιμοποιούμε.

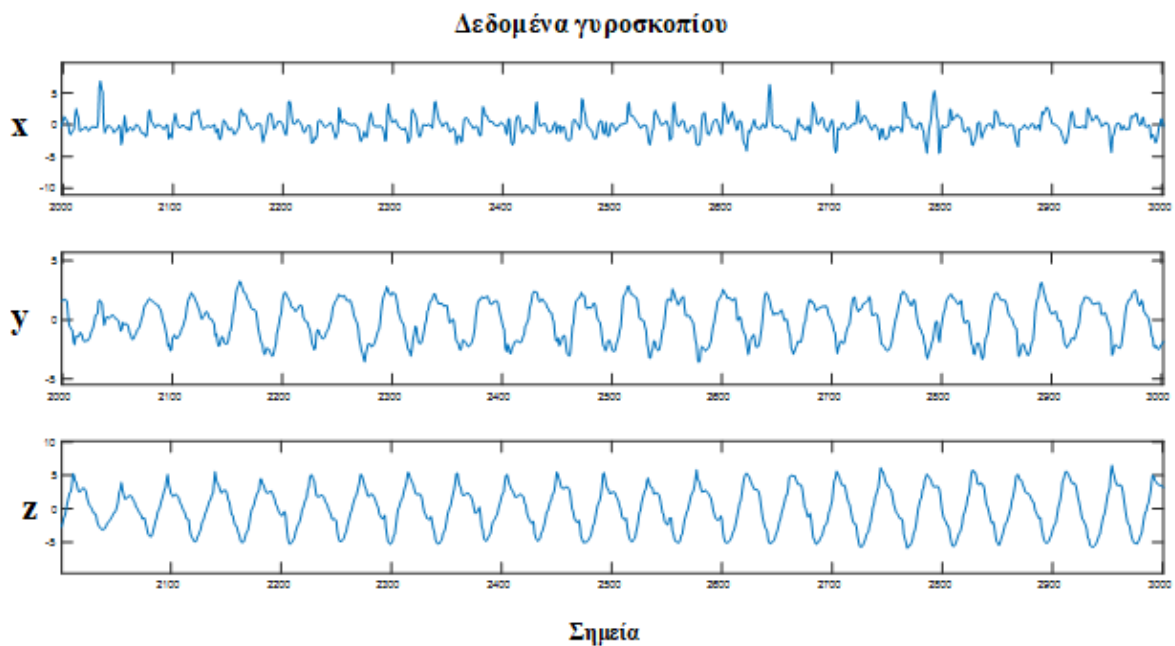
4.2. Συγχρονισμός

Το πρώτο βήμα στη φάση της προεπεξεργασίας των δεδομένων αποτελεί ο συγχρονισμός των δεδομένων από τους δύο αισθητήρες (επιταχυνσιόμετρο και γυροσκόπιο). Μια τέτοια διαδικασία είναι απαραίτητο να υλοποιηθεί στην περίπτωση που χρησιμοποιούνται δεδομένα από πολλαπλούς αισθητήρες τα οποία στέλνονται ασύρματα μέσω Bluetooth σε ένα κινητό τηλέφωνο, καθώς απαντώνται λάθη συγχρονισμού [74]. Αμέσως μετά τον συγχρονισμό δημιουργήθηκαν τεχνηέντως νέα σημεία με αποτέλεσμα να προκύψει ένας εικονικά αυξημένος ρυθμός δειγματοληψίας. Το πρόβλημα αυτό αντιμετωπίστηκε εφαρμόζοντας την τμηματικά κυβική παρεμβολή Hermite (PCHIP) [75] και κατ' αυτόν τον τρόπο καταφέραμε να επαναφέρουμε τη συχνότητα δειγματοληψίας στην αρχική τιμή, δηλαδή στα 50 Hz.

Τα σήματα που χειριζόμαστε, όπως έχει προαναφερθεί, προέρχονται από επιταχυνσιόμετρο και γυροσκόπιο το καθένα από τα οποία δίνει τρία ξεχωριστά σήματα για τις τρεις χωρικές διαστάσεις, x, y, z (άρα συνολικά έξι), τα οποία και απεικονίζονται στην **Error! Reference source not found.** και την **Error! Reference source not found.**, αντίστοιχα.



Εικόνα 4-5: Σήματα επιτάχυνσης στον x , y , z άξονα, αντίστοιχα, προερχόμενα από τις καταγραφές του επιταχυνσιόμετρου.




Εικόνα 4-6: Σήματα γωνιακής ταχύτητας στον x , y , z , άξονα, αντίστοιχα, προερχόμενα από τις καταγραφές του γυροσκοπίου.

4.3. Φιλτράρισμα – αφαίρεση θορύβου

Η διαδικασία που περιγράφεται στη συνέχεια ακολουθείται για καθένα από τρία σήματα του κάθε αισθητήρα. Το αρχικό ακατέργαστο σήμα έχει στην αρχή και στο τέλος του την ακόλουθη


μορφή. (Επιλέξαμε τυχαία να οπτικοποιήσουμε στις ακόλουθες εικόνες την καταγραφή από το 1^ο άτομο ενόσω επιτελεί την δραστηριότητα “τρέξιμο”).




Εικόνα 4-7: Αρχή και τέλος του ακατέργαστου σήματος

Παρατηρούμε στην Εικόνα 4-7 ότι υπάρχουν μικρές περιοχές που δεν ακολουθούν το ίδιο μοτίβο με όλο το υπόλοιπο σήμα. Πρόκειται για μεταβατικές περιοχές που περιγράφουν καταστάσεις όπου το υποκείμενο δεν έχει εισέλθει στον κανονικό ρυθμό εκτέλεσης της δραστηριότητας (π.χ. να έχει εκκινήσει την καταγραφή πριν ακόμα ξεκινήσει να τρέχει). Προς τούτο κρίθηκε χρήσιμο να αποκόψουμε 2% του σήματος από την αρχή και το τέλος του ακατέργαστου σήματος, αντίστοιχα, ώστε να εξαλείψουμε αυτές τις περιοχές.

Στη συνέχεια προχωρήσαμε με το φιλτράρισμα του σήματος (Εικόνα 4-8). Το σήμα υποβάλλεται σε φιλτράρισμα για αποκοπή του θορύβου, με χρήση φίλτρου διαμέσου 5^{ης} τάξης [76] και εν συνεχεία με βαθυπερατό φίλτρο Butterworth 5^{ης} τάξης και συχνότητα αποκοπής στα 20 Hz [1, 77].



(α)



(β)


Εικόνα 4-8: (α) Το σήμα πριν το φιλτράρισμα και (β) το σήμα μετά το φιλτράρισμα

Αμέσως μετά, υποβάλλουμε σε κανονικοποίηση z-score ολόκληρο το σήμα με στόχο να έχει μέση τιμή ίση με μηδέν και τυπική απόκλιση ίση με ένα, δεδομένου πως είναι άτοπο να συγκρίνουμε χρονοσειρές με διαφορετικά όφσσετ και πλάτη [51]. Πρόκειται για μια τυπική διαδικασία που εφαρμόζεται πάντα πριν την εφαρμογή του αλγορίθμου SAX, προκειμένου να αφαιρεθούν οι παραμορφώσεις, δηλαδή η μετατόπιση όφσσετ και η κλιμάκωση πλάτους, που έχουν αρνητικό αντίκτυπο στα αποτελέσματα των εργασιών αναγνώρισης δραστηριότητας [78].

Οι κανονικοποιημένες τιμές εξάγονται από το τύπο (7) [79]:

$$X_{norm,i} = \frac{X_i - \mu}{\sigma} \quad (7)$$

όπου: X_i οι τιμές της αρχικής χρονοσειράς σε κάθε σημείο i , μ η μέση τιμή όλων των τιμών της χρονοσειράς X_i και σ η τυπική απόκλιση που παρουσιάζουν οι τιμές της χρονοσειράς X_i . Στην Εικόνα 4-9 παρουσιάζεται το κανονικοποιημένο σήμα που είναι και το τελικό μετά από όλα τα στάδια επεξεργασίας που υποβλήθηκε το αρχικό ακατέργαστο σήμα.




Εικόνα 4-9: Το κανονικοποιημένο σήμα

4.4. Τμηματοποίηση

Πλέον το φιλτραρισμένο και κανονικοποιημένο σήμα θα χωριστεί σε παράθυρα ίσου μεγέθους είτε χωρίς επικάλυψη, είτε με επικάλυψη σε ποσοστό 50% επί του αρχικού παραθύρου. Η τεχνική τους τμηματοποίησης σε κυλιόμενα παράθυρα (Εικόνα 4-10) είναι η πιο ευρέως χρησιμοποιούμενη τεχνική τμηματοποίησης που χρησιμοποιείται σε προβλήματα αναγνώρισης δραστηριότητας, καθώς η απλότητα υλοποίησής τους την καθιστά ιδανική λύση για εφαρμογές πραγματικού χρόνου [3, 80]. Η εν λόγω τεχνική έχει αποδειχτεί ιδιαίτερος επωφελής για την αναγνώριση περιοδικών (π.χ. περπάτημα, τρέξιμο), αλλά και στατικών δραστηριοτήτων (π.χ. όρθια στάση, κάθισμα), ενώ είναι υπό αμφισβήτηση η χρησιμότητά της για την ανίχνευση σποραδικών δραστηριοτήτων. Οι τελευταίες απαιτούν μια πιο εξελιγμένη διαδικασία τμηματοποίησης, δεδομένης τους πολύπλοκης και διάσπαρτης φύσης τους [3]. Η προσέγγιση της τμηματοποίησης με επικάλυψη των παραθύρων, αφενός θα προσφέρει παραπάνω δεδομένα για εκπαίδευση του μοντέλου, αφετέρου θα σαρώσει πιο ομαλά τη χρονοσειρά, αποφεύγοντας έτσι την απώλεια κρίσιμων σημείων που χαρακτηρίζουν το σήμα μας [81].

Στη βιβλιογραφία έχει μελετηθεί εκτενώς το ζήτημα της επιλογής του μεγέθους του παραθύρου, καθώς επηρεάζει άμεσα την απόδοση κι επίδοση του υλοποιούμενου μοντέλου [82]. Επιλέξαμε το παράθυρό μας να έχει διάρκεια 2,56 sec, χρονικό διάστημα σύμφωνο με τα χρονικά διαστήματα που προτείνονται για προβλήματα αναγνώρισης ανθρώπινης δραστηριότητας [3], ώστε να υπάρχει ισορροπία μεταξύ του χρόνου που απαιτείται για αναγνώριση και της ακρίβειας του μοντέλου.

Δεδομένου ότι η συχνότητα δειγματοληψίας του σήματος είναι 50 Hz, εύκολα προκύπτει πως το μέγεθος του παραθύρου θα είναι $50 \text{ Hz} * 2,56 \text{ sec} = 128$ σημεία.



Εικόνα 4-10: Τμηματοποίηση σε κυλιόμενα χρονικά παράθυρα των 128 σημείων

5. Πολυκαναλικά Έξυπνα Εικονίδια Συμβολικής Συναθροιστικής Προσέγγισης (Multichannel Symbolic Aggregate Approximation Intelligent Icons)²

Η μέθοδός μας -τα πολυκαναλικά έξυπνα εικονίδια- αποτελεί επέκταση της αναπαράστασης των έξυπνων εικονιδίων σε μονοκαναλικά σήματα που έχει περιγραφεί από τους Keogh et al. [52]. Είναι μια καινοτόμος προσέγγιση που βρίσκει εφαρμογή σε σήματα που έχουν πέραν του ενός κανάλια, όπως είναι τα σήματα της βάσης δεδομένων που χρησιμοποιούμε τα οποία αποτελούνται από τρία κανάλια (τις διαστάσεις x, y, z). Η καινοτομία έγκειται στον τρόπο υπολογισμού των έξυπνων εικονιδίων που με τη μέθοδό μας σχηματίζονται βρίσκοντας όλες τις πιθανές λέξεις που προέρχονται από το συνδυασμό συμβόλων σε όλες τις διαστάσεις (δηλαδή τις x, y, z στην περίπτωση μας). Με άλλα λόγια, κατασκευάζουμε τα συσχετισμένα σε όλες τις διαστάσεις του σήματος έξυπνα εικονίδια, τα οποία και ονομάζονται πολυκαναλικά έξυπνα εικονίδια [83]. Στην βιβλιογραφική ανασκόπηση που πραγματοποιήσαμε στην Ενότητα 3.2 δεν βρήκαμε πουθενά κάποια παραλλαγή του SAX που να καταπιάνεται με την συμβολική αναπαράσταση πολυδιάστατων/πολυκαναλικών χρονοσειρών.

Ας θεωρήσουμε i το πλήθος συμβολοσειρές μήκους m έκαστη (που αναπαριστούν τα i κανάλια του σήματος, όπως προέκυψαν μετά την εφαρμογή της μεθόδου SAX), και ας τις συμβολίσουμε S_1, S_2, \dots, S_i .

$$S_1: S_1\{1\}, S_1\{2\}, S_1\{3\}, \dots, S_1\{m\}$$

$$S_2: S_2\{1\}, S_2\{2\}, S_2\{3\}, \dots, S_2\{m\}$$

...

...

$$S_i: S_i\{1\}, S_i\{2\}, S_i\{3\}, \dots, S_i\{m\}$$

Τότε, η k – **στη** λέξη σχηματίζεται από τον συνδυασμό των αντίστοιχων συμβόλων από όλα τα κανάλια ως εξής:

$$'S_1\{k\} S_2\{k\} S_3\{k\} \dots S_i\{k\}', \quad \text{όπου } 1 \leq k \leq m.$$

² L. Pappa, P. Karvelis, G. Georgoulas and C. Stylios, "Multichannel Symbolic Aggregate Approximation Intelligent Icons: Application for Activity Recognition," 2020 IEEE Symposium Series on Computational Intelligence (SSCI), Canberra, Australia, 2020, pp. 505-512, doi: 10.1109/SSCI47803.2020.9308497.

Είναι προφανές πως οι λέξεις που αναζητούνται με αυτό τον τρόπο θα έχουν μήκος i , όσα δηλαδή και τα κανάλια του σήματος.

Η παραπάνω διαδικασία θα μπορούσε να αποτυπωθεί σε ένα γενικό πλαίσιο όπως στην Εικόνα 5-1.




Εικόνα 5-1: Το κάθε κανάλι του πολυκαναλικού σήματος αναπαρίσταται ως μια συμβολοσειρά. Αναζητούμε λέξεις των οποίων το 1^ο σύμβολο προέρχεται από το 1^ο κανάλι, το 2^ο σύμβολο από το 2^ο κανάλι, κ.ο.κ.

Στην ενότητα 5.1.3 περιγράφεται με λεπτομέρεια η εξαγωγή των έξυπνων εικονιδίων από πολυκαναλικά σήματα μέσα από την εφαρμογή της μεθόδου στα σήματα που χειριζόμαστε.

5.1. Τα βήματα τους μεθόδου

Στα επόμενα επεξηγούμε αναλυτικά τα στάδια υλοποίησης της μεθόδου μας που βασίζεται στην εξαγωγή των πολυκαναλικών έξυπνων εικονιδίων, μέσα από την εφαρμογή της. Η Εικόνα 5-2 αναπαριστά σχηματικά όλα αυτά τα στάδια.



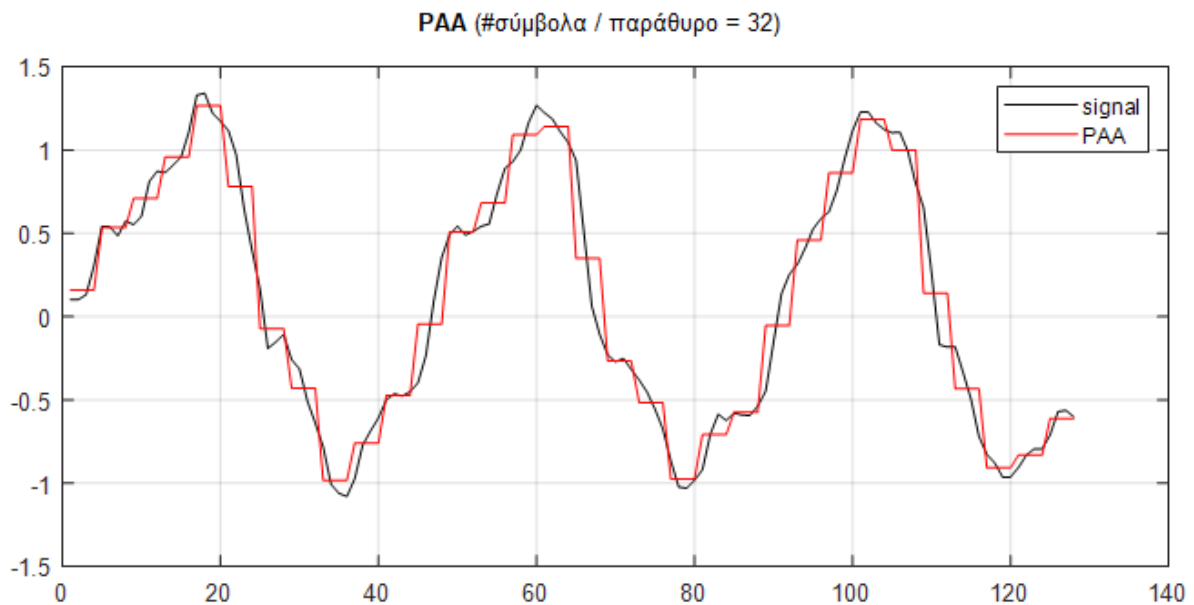
Εικόνα 5-2: Τα βήματα τους μεθόδου τους

Πρώτον, λαμβάνουμε τα δεδομένα και μετά τα επεξεργαζόμαστε (συγχρονισμός, φιλτράρισμα, κανονικοποίηση), όπως περιγράφηκε στην Ενότητα 4.2 και στην Ενότητα 4.3. Στη συνέχεια χωρίζουμε τα πολυκαναλικά σήματα σε παράθυρα (Ενότητα 4.4). Αμέσως μετά, λαμβάνει χώρα η τεχνική της Τμηματικής Συναθροιστικής Προσέγγισης (ΡΑΑ) για μείωση της διαστατικότητας του προβλήματος, που ακολουθείται από το στάδιο της διακριτοποίησης, και με αυτόν τον τρόπο ολοκληρώνεται η εφαρμογή της μεθόδου της Συμβολικής Συναθροιστικής Προσέγγισης (SAX). Συνεχίζουμε με το στάδιο τους εξαγωγής χαρακτηριστικών (μονοκαναλικά και πολυκαναλικά έξυπνα εικονίδια), και τέλος, η διαδικασία ολοκληρώνεται με το στάδιο της ταξινόμησης.

5.1.1. Εφαρμογή ΡΑΑ για μείωση διαστατικότητας

Η τεχνική ΡΑΑ έχει περιγραφεί σε θεωρητικό πλαίσιο στην ενότητα 3.1.1. Εδώ θα την εφαρμόσουμε στα σήματα της βάσης δεδομένων.

Στην ανάλυση που διεξάγουμε με μέγεθος κάθε παραθύρου ίσο με 128 σημεία, επιλέγουμε το κάθε παράθυρο να αναπαρίσταται από 32 σύμβολα. Άρα, το κάθε παράθυρο θα πρέπει να χωριστεί σε 32 τμήματα των τεσσάρων σημείων. Υπολογίζουμε τη μέση τιμή της κάθε τετράδας σημείων και πλέον το αντίστοιχο τμήμα λαμβάνει μία τιμή, την μόλις υπολογισθείσα μέση τιμή. Αυτοί είναι οι συντελεστές ΡΑΑ (32 το πλήθος). Εν τέλει, καταλήγουμε η διάσταση του προβλήματός μας να έχει μειωθεί κατά ένα παράγοντα 4. Η όλη διαδικασία απεικονίζεται στην Εικόνα 5-3.



Εικόνα 5-3: Το αρχικό σήμα (μαύρη γραμμή) και η ΡΑΑ αναπαράσταση (κόκκινη γραμμή).

5.1.2. Εφαρμογή διακριτοποίησης

Ακολουθεί η εφαρμογή της διακριτοποίησης, το θεωρητικό πλαίσιο της οποίας έχει αναλυθεί και περιγραφεί στην ενότητα 3.1.2.

Επιλέγουμε το μέγεθος του αλφαβήτου $\alpha = 4$, συνεπώς έχουμε στη διάθεσή μας τα σύμβολα 'a', 'b', 'c', 'd' για να αναπαραστήσουν τον κάθε συντελεστή ΡΑΑ. Οι οριακές τιμές $\beta_1 = -0.67$, $\beta_2 = 0$ και $\beta_3 = 0.67$ ορίζουν τις ακόλουθες τέσσερις περιοχές τιμών που αντιστοιχίζονται με τα σύμβολα του αλφαβήτου που προαναφέρθηκαν ως εξής:


$(-\infty, -0.67] \rightarrow \text{'a'}$

$(-0.67, 0] \rightarrow \text{'b'}$

$(0, 0.67] \rightarrow \text{'c'}$

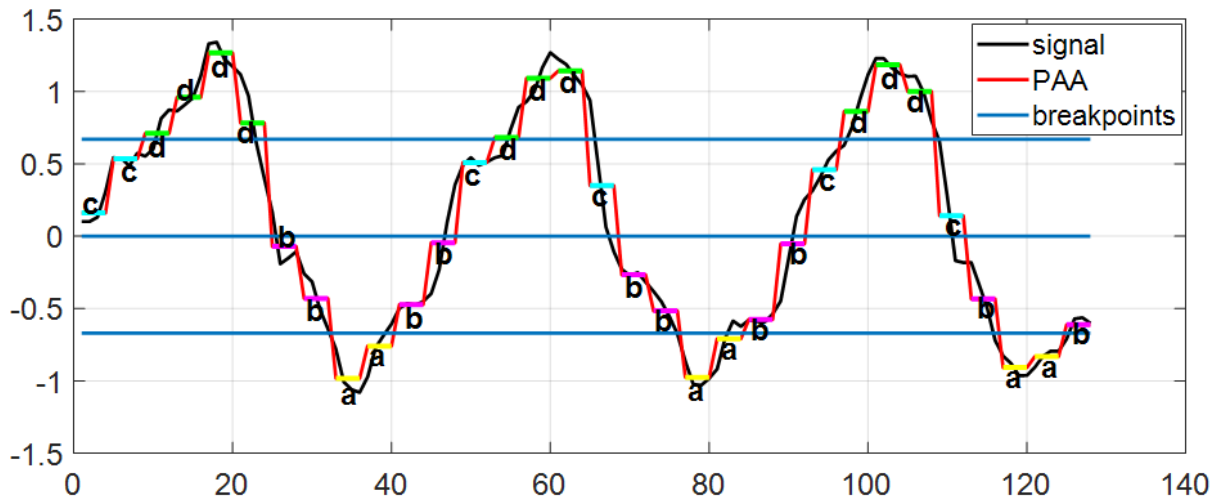
$(0.67, +\infty] \rightarrow \text{'d'}$

Η Εικόνα 5-4 αποτυπώνει γραφικά τη μετατροπή των συντελεστών PAA σε σύμβολα και τις τέσσερις περιοχές τιμών που ορίζονται από τις τρεις οριακές τιμές β_1 , β_2 και β_3 .



Εικόνα 5-4: Ο κάθε συντελεστής PAA αντιστοιχίζεται σε ένα σύμβολο από τα διαθέσιμα του επιλεγμένου μεγέθους αλφαβήτου. Οι οριζόντιες μπλε γραμμές είναι οι γραμμές των οριακών τιμών που οριοθετούν τις 4 διαφορετικές περιοχές τιμών.

Η Εικόνα 5-5 είναι ένα συγκεντρωτικό γράφημα όλης της διαδικασίας εφαρμογής της μεθόδου SAX που περιλαμβάνει το αρχικό σήμα, τους συντελεστές PAA και την τελική μετατροπή σε σύμβολα.



Εικόνα 5-5: Ολικό γράφημα μεθόδου SAX. Παρατηρούμε το αρχικό σήμα, τους συντελεστές PAA, τις οριακές γραμμές και τα τελικά σύμβολα.

Εν τέλει, η συμβολοσειρά που προκύπτει μετά από εφαρμογή όλης της διαδικασίας σε ένα παράθυρο είναι η ‘ccddd bbaabbcedddcbbaabbcedddcbbaab’ την οποία και παραθέτουμε και σε χρωματική μορφή ώστε να είναι πιο εύληπτη.

c c d d d d b b a a b b c d d d c b b a a b b c d d d c b a a b

5.1.3. Εξαγωγή χαρακτηριστικών – Έξυπνα εικονίδια

Παρακάτω θα δείξουμε την εφαρμογή τους σε μονοκαναλικά σήματα, αλλά και σε πολυκαναλικά που άλλωστε αποτελεί και την δική μας ερευνητική συνεισφορά.

5.1.3.1. Μονοκαναλικά έξυπνα εικονίδια


Υπενθυμίζουμε πως σκοπός της εξαγωγής των έξυπνων εικονιδίων είναι ο υπολογισμός της συχνότητας εμφάνισης κάθε λέξης εντός της υπό μελέτη συμβολοσειράς. Προς τούτο, αρχικά επιλέγουμε το μήκος που θα έχουν οι λέξεις που θα αναζητήσουμε να είναι ίσο με τρία. Δεδομένου πως το αλφάβητό μας έχει μέγεθος ίσο με τέσσερα, προκύπτει ότι οι πιθανές λέξεις θα είναι $4^3 = 64$ το πλήθος, όπως φαίνεται και στον Πίνακα 5-1.

aaa	aca	baa	bca	caa	cca	daa	dca
aab	acb	bab	bcb	cab	ccb	dab	dcb
aac	acc	bac	bcc	cac	ccc	dac	dcc
aad	acd	bad	bcd	cad	ccd	dad	dcd
aba	ada	bba	bda	cba	cda	dba	dda
abb	adb	bbb	bdb	cbb	cdb	dbb	ddb

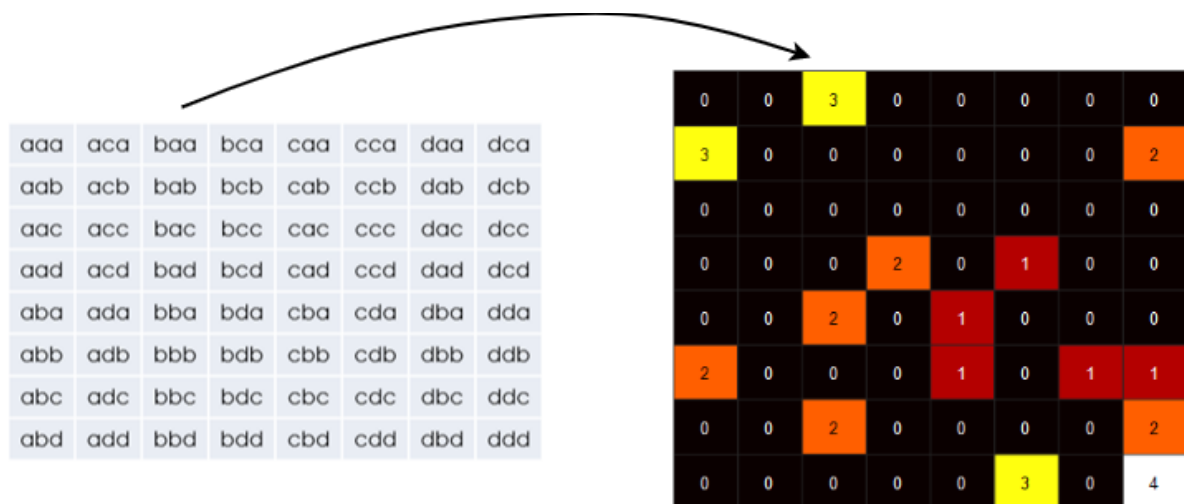
abc	adc	bbc	bdc	cbc	cdc	dbc	ddc
abd	add	bbd	bdd	cbd	cdd	dbd	ddd

Πίνακας 5-1: Όλες οι πιθανές λέξεις που σχηματίζονται για μέγεθος αλφαβήτου = 4 και μήκος λέξης = 3

Σε αυτό το σημείο θα αναζητήσουμε καθεμιά από τις παραπάνω πιθανές λέξεις εντός της συμβολοσειράς που αναπαριστά ένα παράθυρο και θα βρούμε εάν και πόσες φορές εμφανίζεται εντός αυτής. Για παράδειγμα, ας θεωρήσουμε τη λέξη ‘baa’. Παρατηρούμε ότι η συχνότητα εμφάνισής της είναι ίση με 3.



Δημιουργούμε πίνακα τιμών που σε κάθε κελί υπάρχει ο αριθμός των εμφανίσεων της λέξης που βρίσκεται στο αντίστοιχο κελί του Πίνακας 5-1. Συνεχίζοντας με το παράδειγμα με τη λέξη ‘baa’, παρατηρούμε ότι η θέση της στον Πίνακα 5-1 είναι το κελί {1, 3}. Συνεπώς, συμπληρώνουμε τον νέο πίνακα τιμών με τον αριθμό 3 στη θέση {1, 3} όπως φαίνεται και στην Εικόνα 5-6. Επαναλαμβάνοντας τη διαδικασία αυτή για όλες τις λέξεις και συμπληρώνοντας με τιμές όλα τα κελιά του πίνακα, προκύπτει το έξυπνο εικονίδιο για το συγκεκριμένο παράθυρο που μελετάμε.



Εικόνα 5-6: Το μονοκαναλικό έξυπνο εικονίδιο που εξήχθη από τη συμβολοσειρά ‘c c d d d d b b a a b b c d d d c b b a a b b c d d d c b a a b’. Κάθε αριθμός δείχνει τη συχνότητα εμφάνισης της λέξης που βρίσκεται στο αντίστοιχο κελί του πίνακα 5-1.

5.1.3.2. Πολυκαναλικά έξυπνα εικονίδια

Στην αρχή του παρόντος κεφαλαίου αναλύσαμε σε θεωρητικό πλαίσιο την εξαγωγή των έξυπνων εικονιδίων από πολυκαναλικά σήματα. Σε αυτή την ενότητα θα επιδείξουμε μέσα από

την εφαρμογή την ερευνητική μας συνεισφορά, τα πολυκαναλικά έξυπνα εικονίδια. Για την εξαγωγή τους είναι απαραίτητη η ενσωμάτωση πληροφορίας από τις τρεις διαστάσεις των σημάτων που χειριζόμαστε. Προς αυτή την κατεύθυνση, μετατρέπουμε τα αντίστοιχα παράθυρα και από τις τρεις διαστάσεις (x, y, z) σε συμβολοσειρές με τη μέθοδο SAX, και αναζητούμε λέξεις τέτοιες ώστε το 1^ο σύμβολο να προέρχεται από την αντίστοιχη θέση στην x-διάσταση, το 2^ο από την αντίστοιχη θέση στην y-διάσταση και το 3^ο από την αντίστοιχη θέση στην z-διάσταση, όπως δείχνουμε παρακάτω.

x:	c	c	d	d	d	d	b	b	a	a	b	b	c	d	d	d	c	b	b	a	a	b	b	c	d	d	d	c	b	a	a	b
y:	a	a	c	c	d	a	a	b	d	d	d	a	a	c	c	c	a	b	c	d	d	b	a	b	d	d	b	a	c	d	d	c
z:	c	b	a	a	a	b	c	b	b	a	b	d	b	b	a	a	b	c	b	b	b	c	d	c	b	a	b	b	b	a	b	c


1 ^η λέξη: 'cac'	14 ^η λέξη: 'dcb'	29 ^η λέξη: 'bcb'
-------------------------------	--------------------------------	--------------------------------

Εν τέλει, το σύνολο των λέξεων που προκύπτουν παρουσιάζεται στην Εικόνα 5-7 σε χρωματική μορφή ώστε να είναι πιο εύκολα κατανοητή. Σημειώνουμε ότι σε αντίθεση με την περίπτωση των μονοκαναλικών έξυπνων εικονιδίων, το μήκος τους λέξης δεν επιλέγεται, αλλά είναι de facto ίσο με το πλήθος των καναλιών του σήματος.



Εικόνα 5-7: Οι λέξεις αποτελούνται από ένα σύμβολο από κάθε διάσταση για τον υπολογισμό του πολυκαναλικού έξυπνου εικονιδίου

Πλέον, αυτό που απομένει για την εξαγωγή του πολυκαναλικού έξυπνου εικονιδίου είναι η εύρεση της συχνότητας εμφάνισης κάθε λέξης. Επαναλαμβάνουμε πως από την στιγμή που το μέγεθος του αλφαβήτου ισούται με τέσσερα και το μήκος των λέξεων ισούται με τρία, το πλήθος όλων των πιθανών λέξεων ισούται με 64.



Εικόνα 5-8: Το πολυκαναλικό έξυπνο εικονίδιο. Κάθε αριθμός δείχνει τη συχνότητα εμφάνισης της λέξης που βρίσκεται στο αντίστοιχο κελί.

Στην Εικόνα 5-7 παρατηρούμε ότι η λέξη ‘dca’ εμφανίζεται 4 φορές. Επομένως, με την ίδια λογική που ακολουθήσαμε και στα μονοκαναλικά έξυπνα εικονίδια, συμπληρώνουμε το αντίστοιχο κελί του πίνακα με την τιμή 4, όπως δείχνουμε στην Εικόνα 5-8. Συμπληρώνουμε τα αντίστοιχα κελιά για τις υπόλοιπες λέξεις, και με αυτόν τον τρόπο ολοκληρώνεται η εξαγωγή του πολυκαναλικού έξυπνου εικονιδίου για ένα παράθυρο.

5.1.4. Ταξινόμηση

Τα μονοκαναλικά και πολυκαναλικά έξυπνα εικονίδια, όπως αυτά προκύπτουν μετά από εφαρμογή της μεθόδου για κάθε παράθυρο των σημάτων, σχηματίζουν τον πίνακα των χαρακτηριστικών του μοντέλου εποπτευόμενης μηχανικής μάθησης που σχεδιάσαμε και υλοποιήσαμε και θα αποτελέσει την είσοδο του επιλεγμένου αλγορίθμου ταξινόμησης.

Για λόγους απλοποίησης στον χειρισμό του μεγάλου όγκου έξυπνων εικονιδίων που προέκυψαν από όλα τα σήματα, προχωρήσαμε στην ακόλουθη μετατροπή. Αλλάξαμε την μορφή των έξυπνων εικονιδίων από τετραγωνικό πίνακα διαστάσεων 8x8 που αρχικώς ήταν, σε πίνακα διαστάσεων 1x64. Κάτι τέτοιο μας βοηθάει στην κατανόηση του πίνακα των χαρακτηριστικών, έτσι ώστε κάθε γραμμή αυτού του πίνακα να ταυτίζεται με το έξυπνο εικονίδιο του παραθύρου. Ο τρόπος με τον οποίο παραθέσαμε τα έξυπνα εικονίδια αποτυπώνεται με σαφήνεια στους πίνακες που ακολουθούν. Ο Πίνακας 5-2 αφορά την προσέγγιση με μη επικαλυπτόμενα παράθυρα και ο Πίνακας 5-3 την προσέγγιση με επικάλυψη παραθύρων κατά 50%. Παρατηρώντας, βλέπουμε ότι η μοναδική μορφολογική διαφορά τους

έγκειται στο συνολικό πλήθος των παραθύρων και κατά συνέπεια και στον αριθμό των γραμμών του αντίστοιχου πίνακα χαρακτηριστικών.

# παρα- θύρου	ΠΙΝΑΚΑΣ ΧΑΡΑΚΤΗΡΙΣΤΙΚΩΝ							
	Μονοκαναλικά έξυπνα εικονίδια						Πολυκαναλικά έξυπνα εικονίδια	
	Επιταχυνσίμετρο			Γυροσκόπιο			Επιταχυνσίμετρο	Γυροσκόπιο
	x- άξονας	y- άξονας	z- άξονας	x- άξονας	y- άξονας	z- άξονας		
1	1x64	1x64	1x64	1x64	1x64	1x64	1x64	1x64
2	1x64	1x64	1x64	1x64	1x64	1x64	1x64	1x64
3	1x64	1x64	1x64	1x64	1x64	1x64	1x64	1x64
4	1x64	1x64	1x64	1x64	1x64	1x64	1x64	1x64
...
25133	1x64	1x64	1x64	1x64	1x64	1x64	1x64	1x64

Πίνακας 5-2: Πίνακας χαρακτηριστικών της προσέγγισης με μη επικαλυπτόμενα παράθυρα. Κάθε κελί περιέχει έναν υποπίνακα διαστάσεων 1x64 που αποτελεί ένα έξυπνο εικονίδιο.

# παρα- θύρου	ΠΙΝΑΚΑΣ ΧΑΡΑΚΤΗΡΙΣΤΙΚΩΝ							
	Μονοκαναλικά έξυπνα εικονίδια						Πολυκαναλικά έξυπνα εικονίδια	
	Επιταχυνσίμετρο			Γυροσκόπιο			Επιταχυνσίμετρο	Γυροσκόπιο
	x- άξονας	y- άξονας	z- άξονας	x- άξονας	y- άξονας	z- άξονας		
1	1x64	1x64	1x64	1x64	1x64	1x64	1x64	1x64
2	1x64	1x64	1x64	1x64	1x64	1x64	1x64	1x64
3	1x64	1x64	1x64	1x64	1x64	1x64	1x64	1x64
4	1x64	1x64	1x64	1x64	1x64	1x64	1x64	1x64
...
50081	1x64	1x64	1x64	1x64	1x64	1x64	1x64	1x64

Πίνακας 5-3: Πίνακας χαρακτηριστικών της προσέγγισης με 50% επικαλυπτόμενα παράθυρα. Κάθε κελί περιέχει έναν υποπίνακα διαστάσεων 1x64 που αποτελεί ένα έξυπνο εικονίδιο.

5.1.4.1. Διασταυρούμενη επικύρωση (Cross-validation)

Όπως έχει προαναφερθεί, οι πίνακες των χαρακτηριστικών θα αποτελέσουν την είσοδο του αλγορίθμου ταξινόμησης. Πριν όμως από αυτό το στάδιο θα πρέπει να προηγηθεί ο διαχωρισμός του πίνακα χαρακτηριστικών σε σετ εκπαίδευσης (training dataset) και σε σετ επικύρωσης (validation dataset) [84].

Προς αυτή την κατεύθυνση χωρίσαμε με τυχαίο τρόπο τον πίνακα των χαρακτηριστικών ως εξής:

- 80% των έξυπνων εικονιδίων από κάθε κλάση (= δραστηριότητα) → σετ εκπαίδευσης

- το εναπομείναν 20% των έξυπνων εικονιδίων από κάθε κλάση (= δραστηριότητα) → σετ επικύρωσης.

Το σετ εκπαίδευσης θα εκπαιδεύσει το μοντέλο ταξινόμησης, ενώ το σετ επικύρωσης θα ελέγξει ουσιαστικά την προβλεπτική ικανότητα του μοντέλου. Η διαδικασία που μόλις περιγράφηκε, δηλαδή “τυχαίος διαχωρισμός – εκπαίδευση – επικύρωση” επαναλήφθηκε δέκα φορές. Με αυτό τον τρόπο εξασφαλίζουμε την αμεροληψία του μοντέλου και τη συμμετοχή χαρακτηριστικών από όλα τα υποκείμενα στην εκπαίδευση.

Ο αλγόριθμος ταξινόμησης που χρησιμοποιήσαμε είναι ο αλγόριθμος *K-πλησιέστεροι-γείτονες*, οπότε κρίνεται σκόπιμο στο σημείο αυτό να κάνουμε μια σύντομη αναφορά σε αυτόν.

5.1.4.2. Αλγόριθμος ταξινόμησης *K-πλησιέστεροι-γείτονες* (k-Nearest-Neighbours – KNN)

Ο KNN αλγόριθμος ανήκει στους μη-παραμετρικούς, μη-γραμμικούς αλγορίθμους εποπτευόμενης μηχανικής μάθησης [13]. Επιπλέον, συγκαταλέγεται στους αλγορίθμους “τεμπέλικης μάθησης” (lazy learning), επειδή δεν μαθαίνει μια διακριτική συνάρτηση από τα δεδομένα εκπαίδευσης, αλλά απομνημονεύει το σύνολο δεδομένων εκπαίδευσης. Επιπλέον, βασίζεται στην λογική της πλειοψηφίας, καθώς οι K πιο κοντινοί γείτονες αποφασίζουν σε ποια κλάση ανήκει το υπό διερεύνηση σημείο/στιγμιότυπο, με χρήση κάποιου μέτρου απόστασης (π.χ. Ευκλείδεια απόσταση). Με άλλα λόγια, η πλειοψηφική κλάση των K πιο κοντινών γειτόνων είναι αυτή που καθορίζει και την κλάση του προς ταξινόμηση στιγμιότυπου. Επειδή όμως, βασίζεται σε μέτρα απόστασης, πριν την εφαρμογή του είναι απαραίτητη η κανονικοποίηση των τιμών των χαρακτηριστικών που εξήχθησαν, ώστε να έχουν μέση τιμή ίση με μηδέν και τυπική απόκλιση ίση με ένα [85]. Με αυτό τον τρόπο εξασφαλίζεται ώστε οι τιμές να αναφέρονται στην ίδια κλίμακα και να μην επηρεάζεται το τελικό αποτέλεσμα από εγγενείς διαφορές των τιμών [86, 87].

Ας δούμε τον αλγόριθμο KNN με περισσότερη λεπτομέρεια. Η κεντρική ιδέα είναι πως η τιμή της συνάρτησης-στόχου για ένα νέο στιγμιότυπο βασίζεται αποκλειστικά και μόνο στις αντίστοιχες τιμές των K πιο «κοντινών» στιγμιότυπων εκπαίδευσης, τα οποία αποτελούν τους «γείτονές» του.

Ο αλγόριθμος αυτός θεωρεί πως όλα τα στιγμιότυπα αντιστοιχούν σε σημεία του n -διάστασης χώρου πραγματικών αριθμών R^n . Ο πλησιέστερος γείτονας ενός στιγμιότυπου ορίζεται με

όρους Ευκλείδειας απόστασης. Πιο συγκεκριμένα, ας θεωρήσουμε ένα τυχαίο στιγμιότυπο x που περιγράφεται από το ακόλουθο διάνυσμα χαρακτηριστικών [9]:

$\langle \alpha_1(x), \alpha_2(x), \dots, \alpha_n(x) \rangle$, όπου το $\alpha_r(x)$ συμβολίζει την τιμή του r -στού χαρακτηριστικού του στιγμιότυπου x .

Τότε η απόσταση $d(x_i, x_j)$ μεταξύ δύο στιγμιότυπων x_i και x_j δίνεται από τον τύπο:

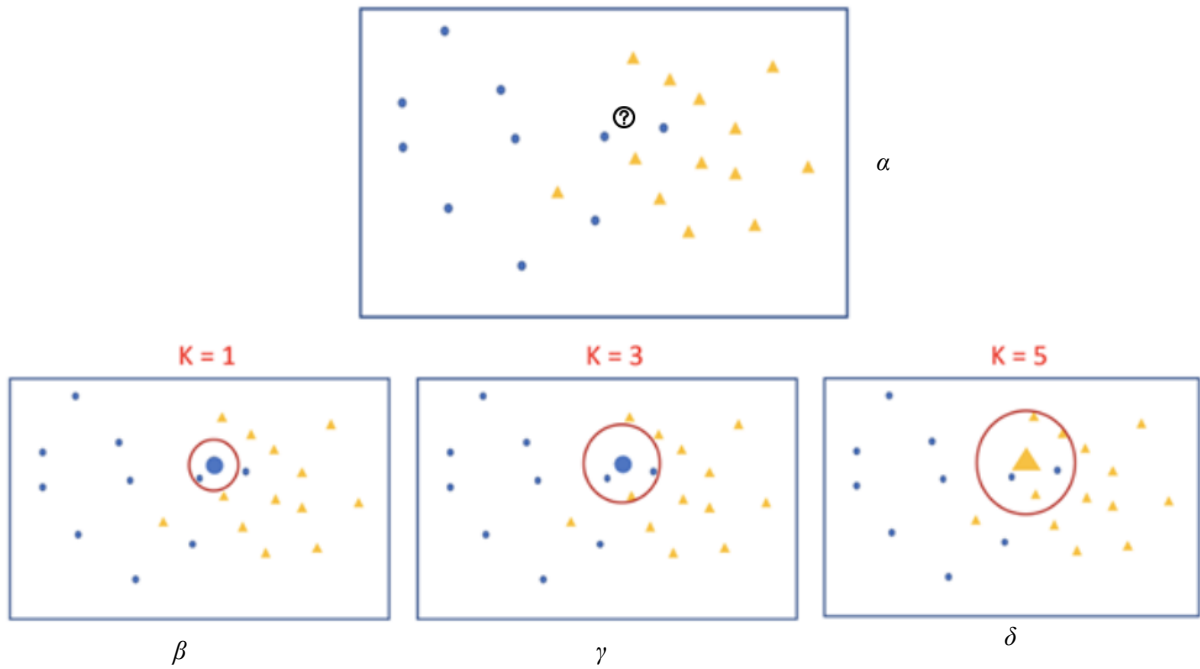
$$d(x_i, x_j) \equiv \sqrt{\sum_{r=1}^n (\alpha_r(x_i) - \alpha_r(x_j))^2} \quad (8)$$

Ας θεωρήσουμε διακριτών τιμών συναρτήσεις-στόχους της μορφής $f: R^n \rightarrow V$, όπου V είναι το πεπερασμένο σύνολο τιμών $\{v_1, v_2, \dots, v_s\}$. Προς απλούστευση η $f(x)$ υποδηλώνει την κλάση στην οποία ανήκει το στιγμιότυπο x , γίνεται δηλαδή μεταφορά από τον χώρο R^n σε ένα πεπερασμένο σύνολο διακριτών τιμών. Ο αλγόριθμος KNN για υπολογισμό διακριτών τιμών συνάρτησης-στόχου είναι ο εξής [9]:

- Πρόσθεσε όλα τα παραδείγματα εκπαίδευσης $\langle x, f(x) \rangle$ σε μια λίστα με όνομα π.χ. `training_examples`.
- Δοθέντος ενός στιγμιότυπου προς ταξινόμηση x_q
 - Ας θεωρήσουμε x_1, x_2, \dots, x_k τα k στιγμιότυπα από τη λίστα `training_examples` που είναι πιο κοντά στο x_q .
 - Τότε ο αλγόριθμος επιστρέφει
$$\hat{f}(x_q) \leftarrow \operatorname{argmax}_{v \in V} \sum_{i=1}^k \delta(v, f(x_i))$$
Όπου $\delta(a, b) = 1$ αν $a = b$ και $\delta(a, b) = 0$ σε διαφορετική περίπτωση.

Να σημειωθεί ότι ο αλγόριθμος KNN ποτέ δεν εξάγει μια γενική υπόθεση σχετικά με την συνάρτηση-στόχο, αλλά υπολογίζει κάθε φορά τις αποστάσεις γύρω από εκάστοτε προς ταξινόμηση στιγμιότυπο («τεμπέλκη μάθηση») [9].

Η παραπάνω διαδικασία αποτυπώνεται σχηματικά στην Εικόνα 5-9 στην οποία και παρατηρούμε ότι η επιλογή του K (των γειτόνων δηλαδή) παίζει σημαντικό ρόλο στην τελική πρόβλεψη.



Εικόνα 5-9: Σχηματικά η ταξινόμηση με τον αλγόριθμο KNN. Στο (α) βλέπουμε τα σημεία του εκπαιδευμένου σετ δεδομένων και με το μαύρο ερωτηματικό το προς ταξινόμηση νέο στιγμιότυπο. Το (β) δείχνει την πρόβλεψη του ταξινομητή 1-πλησιέστερου γείτονα, το (γ) τον ταξινομητή 3-πλησιέστερων γειτόνων και το (δ) τον ταξινομητή 5-πλησιέστερων γειτόνων για το ίδιο σημείο πρόβλεψης. Όπως είναι φανερό ο αριθμός των γειτόνων που θα επιλεγθεί επηρεάζει τις προβλέψεις.

6. Αποτελέσματα – Συγκρίσεις

Για την κατανόηση των αποτελεσμάτων θεωρείται χρήσιμο να εξηγήσουμε ορισμένους όρους (μέτρα αξιολόγησης) στους οποίους και θα αναφερθούμε στη συνέχεια με σκοπό την αξιολόγηση της απόδοσης της ικανότητας εκτίμησης του εκάστοτε μοντέλου ταξινόμησης που σχεδιάσαμε και υλοποιήσαμε.

6.1. Μέτρα αξιολόγησης ενός μοντέλου

Τα μέτρα αξιολόγησης που θα παρουσιάσουμε στην συνέχεια είναι ο *πίνακας σύγχυσης*, η *ακρίβεια* και η *ευαισθησία* [88, 89].

Πίνακας σύγχυσης (confusion matrix): είναι ένας πίνακας που δίνει τη συνολική εικόνα της απόδοσης του μοντέλου και μπορούμε να εξάγουμε χρήσιμες πληροφορίες. Για παράδειγμα ως παρατηρήσουμε τον ακόλουθο απλό πίνακα σύγχυσης (Πίνακας 6-1).

<i>n</i> = 165	Πρόβλεψη: OXI	Πρόβλεψη: <i>NAI</i>
	Πραγματικά: OXI	50
Πραγματικά: <i>NAI</i>	5	100

Πίνακας 6-1: Η μορφή ενός πίνακα σύγχυσης

Οι γραμμές αναπαριστούν την πραγματική κλάση (δραστηριότητα) στην οποία ανήκουν οι παρατηρήσεις, ενώ οι στήλες την κλάση που έχει προβλεφθεί από το μοντέλο. Πιο αναλυτικά:

- Το συνολικό πλήθος των παρατηρήσεων του μοντέλου με τον ως άνω πίνακα σύγχυσης είναι 165.
- Το σύνολο των παρατηρήσεων που ΠΡΑΓΜΑΤΙΚΑ είναι “OXI”, είναι 60 (= 50+10). Από αυτές:
 - Οι 50 έχουν **ορθώς** προβλεφθεί ως “OXI”.
 - Οι 10 έχουν **εσφαλμένα** προβλεφθεί ως “NAI”.

- Το σύνολο των παρατηρήσεων που ΠΡΑΓΜΑΤΙΚΑ είναι “ ΝΑΙ ”, είναι 105 (= 5+100). Από αυτές:
 - Οι 5 έχουν **εσφαλμένα** προβλεφθεί ως “ ΟΧΙ ”.
 - Οι 100 έχουν **ορθώς** προβλεφθεί ως “ ΝΑΙ ”.

Σημειώνεται πώς οι ορθές παρατηρήσεις βρίσκονται στην διαγώνιο ενός πίνακα σύγχυσης.

Ακρίβεια (*accuracy*): ορίζεται ως ο λόγος των ορθών προβλέψεων προς το σύνολο των προβλέψεων (ορθών και εσφαλμένων) που έκανε το μοντέλο.

$$\text{Ακρίβεια} = \frac{\# \text{ ορθών προβλέψεων}}{\# \text{ σύνολο προβλέψεων}}$$

Άρα με βάση το προηγούμενο παράδειγμα, $\text{ακρίβεια} = (50+100) / 165 = 90.1\%$.

Εναισθησία (*sensitivity*) ή *True Positive Rate - TPR* ή *ανάκληση - Recall*: εκφράζει την ικανότητα του μοντέλου να προβλέπει τις αληθώς θετικές παρατηρήσεις μιας κλάσης και ορίζεται ως ο λόγος των αληθώς θετικών παρατηρήσεων προς το άθροισμα των αληθώς θετικών με τις ψευδώς αρνητικές παρατηρήσεις.

$$\text{Εναισθησία} = \frac{\# \text{ αληθώς θετικές προβλέψεις}}{(\# \text{ αληθώς θετικές} + \# \text{ ψευδώς αρνητικές προβλέψεις})}$$

Άρα με βάση το προηγούμενο παράδειγμα, $\text{εναισθησία} = 100 / (100 + 5) = 95.2\%$.

6.2. Αποτελέσματα

Για λόγους σύγκρισης του μοντέλου μας με υπάρχουσες μεθόδους, υλοποιήσαμε πλέον της μεθόδου μας, δύο διαφορετικές προσεγγίσεις μηχανικής μάθησης χρησιμοποιώντας την ίδια βάση δεδομένων, με το ίδιο μέγεθος κυλιόμενου παραθύρου (128 σημεία), με ίδιες παραμέτρους (μέγεθος αλφαβήτου = 4, μήκος λέξης = 3) και εφαρμόζοντας τον ίδιο αλγόριθμο ταξινόμησης με ίδιες παραμέτρους (1 γείτονας).

Επιγραμματικά, υλοποιήσαμε τα ακόλουθα μοντέλα των οποίων τα αποτελέσματα θα παραθέσουμε στη συνέχεια με την ακόλουθη σειρά:

1. Κλασικό μοντέλο με εξαγωγή χαρακτηριστικών από το πεδίου του χρόνου και των συχνοτήτων
2. Μονοκαναλικά έξυπνα εικονίδια
3. Πολυκαναλικά έξυπνα εικονίδια (→ η μέθοδός μας)

Παραθέτουμε τους πίνακες σύγκρισης, τη μέση ακρίβεια του κάθε μοντέλου και την μέση ευαισθησία κάθε κλάσης για την προσέγγιση με μη-επικαλυπτόμενα και επικαλυπτόμενα παράθυρα, αντίστοιχα.

Σημειώνεται πως οι δύο τελευταίες στήλες του πίνακα σύγκρισης εμφανίζουν το ποσοστό των σωστών και εσφαλμένα ταξινομημένων παρατηρήσεων για κάθε προβλεπόμενη κλάση. Επομένως, η αριστερή εξ αυτών στήλη υποδηλώνει την ευαισθησία της αντίστοιχης κλάσης.

Για το 1^ο μοντέλο επιλέξαμε να συμπεριλάβουμε 16 χαρακτηριστικά που ανήκουν στο πεδίο του χρόνου ή της συχνότητας, μετά από βιβλιογραφική έρευνα που διεξήγαμε στην Ενότητα 2.2, και που περιγράφουν ουσιαστικά τη φύση των υπό μελέτη σημάτων. Τα χαρακτηριστικά αυτά παρατίθενται στον Πίνακα 6-2.

ΧΑΡΑΚΤΗΡΙΣΤΙΚΑ	ΠΕΡΙΓΡΑΦΗ
min	ελάχιστη τιμή
max	μέγιστη τιμή
mean	μέση τιμή
bandpower	μέση τιμή της ενέργειας του σήματος
zero-crossing rate	ρυθμός αλλαγής προσήμου
variance	διακύμανση
kurtosis	κύρτωση του σήματος
skewness	λοξότητα σήματος
root-mean-square	τετραγωνική ρίζα του μέσου όρου των τετραγώνων
median frequency	διάμεσος τιμή της συχνότητας
entropy	εντροπία του σήματος
euclidean norm	Ευκλείδεια νόρμα
mean abs	μέση τιμή των απόλυτων τιμών
sum	άθροισμα των τιμών
standard deviation	τυπική απόκλιση
total power	ολική ενέργεια του σήματος

Πίνακας 6-2: Εξαγωγή Χαρακτηριστικών

Τα αποτελέσματα απεικονίζονται ακολούθως. Στην Εικόνα 6-1 αποτυπώνεται ο πίνακας σύγκρισης για την προσέγγιση για μη επικαλυπτόμενα παράθυρα και στην Εικόνα 6-2 ο αντίστοιχος πίνακας για την προσέγγιση με επικαλυπτόμενα παράθυρα. Ο Πίνακας 6-3 παρουσιάζει την μέση τιμή της ακρίβειας για τις δύο περιπτώσεις (μη-επικαλυπτόμενα και επικαλυπτόμενα παράθυρα).

True Class	Climbing_down	3100	460	148	10	865	15	56	1006	54.8%	45.2%
	Climbing_up	578	4593	50	70	168	91	169	841	70.0%	30.0%
	Jumping	146	16	543	5	151	2	13	214	49.8%	50.2%
	Lying	24	54	7	6147	85	607	283	33	84.9%	15.1%
	Running	126	69	56	152	6902	106	80	319	88.4%	11.6%
	Sitting	75	97	23	718	107	5256	893	61	72.7%	27.3%
	Standing	154	357	32	398	124	918	4921	236	68.9%	31.1%
	Walking	676	454	174	16	556	6	43	5365	73.6%	26.4%
			63.5%	75.3%	52.6%	81.8%	77.0%	75.1%	76.2%	66.4%	
		36.5%	24.7%	47.4%	18.2%	23.0%	24.9%	23.8%	33.6%		
		Climbing_down	Climbing_up	Jumping	Lying	Running	Sitting	Standing	Walking		
		Predicted Class									

Εικόνα 6-1: Πίνακας σύγκρισης για το μοντέλο με την κλασική εξαγωγή χαρακτηριστικών, για την προσέγγιση με μη επικαλυπτόμενα παράθυρα. Η αριστερή εκ των δύο τελευταίων στηλών υποδηλώνει την ευαισθησία της αντίστοιχης κλάσης.

True Class	Climbing_down	6908	675	275	28	1611	20	57	1736	61.1%	38.9%
	Climbing_up	894	10166	127	94	245	127	268	1199	77.5%	22.5%
	Jumping	180	34	1436	4	182	2	16	306	66.5%	33.5%
	Lying	24	43	2	13254	69	708	330	30	91.7%	8.3%
	Running	154	87	116	192	14294	136	97	534	91.6%	8.4%
	Sitting	84	130	10	831	131	11931	1252	81	82.6%	17.4%
	Standing	191	401	55	480	176	1270	11496	201	80.6%	19.4%
	Walking	918	627	232	29	903	23	39	11789	81.0%	19.0%
			73.9%	83.6%	63.7%	88.9%	81.2%	83.9%	84.8%	74.3%	
		26.1%	16.4%	36.3%	11.1%	18.8%	16.1%	15.2%	25.7%		
		Climbing_down	Climbing_up	Jumping	Lying	Running	Sitting	Standing	Walking		
		Predicted Class									

Εικόνα 6-2: Πίνακας σύγκρισης για το μοντέλο με την κλασική εξαγωγή χαρακτηριστικών, για την προσέγγιση με επικαλυπτόμενα κατά 50% παράθυρα. Η αριστερή εκ των δύο τελευταίων στηλών υποδηλώνει την ευαισθησία της αντίστοιχης κλάσης.

True Class	Climbing down	10491	443	7	11	8	29	55	296	92.5%	7.5%
	Climbing up	291	12151	1	74	20	82	219	302	92.5%	7.5%
	Jumping	21	18	2100	5	11	5	12	18	95.9%	4.1%
	Lying	20	60	3	13029	35	968	346	29	89.9%	10.1%
	Running	22	37	5	58	15201	163	108	46	97.2%	2.8%
	Sitting	45	185	1	1203	186	11613	1188	59	80.2%	19.8%
	Standing	103	513	5	512	89	1199	11671	208	81.6%	18.4%
	Walking	167	253	3	5	13	19	107	14023	96.1%	3.9%
			94.0%	89.0%	98.8%	87.5%	97.7%	82.5%	85.2%	93.6%	
		6.0%	11.0%	1.2%	12.5%	2.3%	17.5%	14.8%	6.4%		
		Climbing down	Climbing up	Jumping	Lying	Running	Sitting	Standing	Walking		
		Predicted Class									

Εικόνα 6-4: Πίνακας σύγχυσης για το μοντέλο με τα μονοκαναλικά έξυπνα εικονίδια, για την προσέγγιση με επικαλυπτόμενα κατά 50% παράθυρα. Η αριστερή εκ των δύο τελευταίων στηλών υποδηλώνει την ευαισθησία της αντίστοιχης κλάσης.

ΑΚΡΙΒΕΙΑ (%)			
Μη επικαλυπτόμενα παράθυρα		50% επικαλυπτόμενα παράθυρα	
ΜΕΣΗ ΤΙΜΗ	ΤΥΠΙΚΗ ΑΠΟΚΛΙΣΗ	ΜΕΣΗ ΤΙΜΗ	ΤΥΠΙΚΗ ΑΠΟΚΛΙΣΗ
81.10	0.39	90.13	0.20

Πίνακας 6-4: Μέση ακρίβεια για το μοντέλο με τα μονοκαναλικά έξυπνα εικονίδια, για την προσέγγιση με μη επικαλυπτόμενα και επικαλυπτόμενα κατά 50% παράθυρα, αντίστοιχα

Για την 3^η προσέγγιση με τα πολυκαναλικά έξυπνα εικονίδια λάβαμε τα εξής αποτελέσματα. Στην Εικόνα 6-5 αποτυπώνεται ο πίνακας σύγχυσης για την προσέγγιση για μη επικαλυπτόμενα παράθυρα και στην Εικόνα 6-6 ο αντίστοιχος πίνακας για την προσέγγιση με επικαλυπτόμενα παράθυρα. Ο Πίνακας 6-5 παρουσιάζει την μέση τιμή της ακρίβειας για τις δύο περιπτώσεις (μη-επικαλυπτόμενα και επικαλυπτόμενα παράθυρα).

True Class	Climbing down	4554	575	10	5	10	16	47	473	80.0%	20.0%
	Climbing up	350	5601		42	9	62	163	363	85.0%	15.0%
	Jumping	106	21	938	4	1	2	14	34	83.8%	16.2%
	Lying	26	60	2	6294	35	584	245	24	86.6%	13.4%
	Running	20	37	2	50	7515	118	78	20	95.9%	4.1%
	Sitting	51	78	3	684	82	5532	797	33	76.2%	23.8%
	Standing	134	348	5	325	51	782	5366	159	74.8%	25.2%
	Walking	276	332		4	9	19	50	6630	90.6%	9.4%
		82.5%	79.4%	97.7%	85.0%	97.4%	77.8%	79.4%	85.7%		
		17.5%	20.6%	2.3%	15.0%	2.6%	22.2%	20.6%	14.3%		
		Climbing down	Climbing up	Jumping	Lying	Running	Sitting	Standing	Walking		
		Predicted Class									

Εικόνα 6-5: Πίνακας σύγκρισης για το μοντέλο με τα πολυκαναλικά έξυπνα εικονίδια, για την προσέγγιση με μη επικαλυπτόμενα παράθυρα. Η αριστερή εκ των δύο τελευταίων στηλών υποδηλώνει την ευαισθησία της αντίστοιχης κλάσης.

True Class	Climbing down	10852	248	5	1	3	18	46	167	95.7%	4.3%
	Climbing up	177	12443	1	46	11	72	162	228	94.7%	5.3%
	Jumping	17	11	2122	3	10	5	13	9	96.9%	3.1%
	Lying	20	54	1	13346	32	750	259	28	92.1%	7.9%
	Running	20	29	4	58	15278	132	97	22	97.7%	2.3%
	Sitting	61	136	1	947	180	12145	951	59	83.9%	16.1%
	Standing	105	410		364	77	984	12173	187	85.1%	14.9%
	Walking	114	176	3	7	5	22	79	14184	97.2%	2.8%
		95.5%	92.1%	99.3%	90.3%	98.0%	86.0%	88.3%	95.3%		
		4.5%	7.9%	0.7%	9.7%	2.0%	14.0%	11.7%	4.7%		
		Climbing down	Climbing up	Jumping	Lying	Running	Sitting	Standing	Walking		
		Predicted Class									

Εικόνα 6-6: Πίνακας σύγκρισης για το μοντέλο με τα πολυκαναλικά έξυπνα εικονίδια, για την προσέγγιση με επικαλυπτόμενα κατά 50% παράθυρα. Η αριστερή εκ των δύο τελευταίων στηλών υποδηλώνει την ευαισθησία της αντίστοιχης κλάσης.

ΑΚΡΙΒΕΙΑ (%)			
<i>Μη επικαλυπτόμενα παράθυρα</i>		<i>50% επικαλυπτόμενα παράθυρα</i>	
<i>ΜΕΣΗ ΤΙΜΗ</i>	<i>ΤΥΠΙΚΗ ΑΠΟΚΛΙΣΗ</i>	<i>ΜΕΣΗ ΤΙΜΗ</i>	<i>ΤΥΠΙΚΗ ΑΠΟΚΛΙΣΗ</i>
84.42	0.42	92.39	0.24

Πίνακας 6-5: Μέση ακρίβεια για το μοντέλο με τα πολυκαναλικά έξυπνα εικονίδια, για την προσέγγιση με μη επικαλυπτόμενα και επικαλυπτόμενα κατά 50% παράθυρα, αντίστοιχα

Ο Πίνακας 6-6 είναι συγκριτικός και απεικονίζει την ευαισθησία κάθε κλάσης για κάθε μοντέλο και προσέγγιση που υλοποιήσαμε.

ΔΡΑΣΤΗΡΙΟ- ΤΗΤΕΣ	ΕΥΑΙΣΘΗΣΙΑ (%)					
	ΚΛΑΣΙΚΟ ΜΟΝΤΕΛΟ		ΜΟΝΟΚΑΝΑΛΙΚΑ ΕΞΥΠΝΑ ΕΙΚΟΝΙΔΙΑ		ΠΟΛΥΚΑΝΑΛΙΚΑ ΕΞΥΠΝΑ ΕΙΚΟΝΙΔΙΑ	
	Μη επικαλυ- πτόμενα	Επικαλυ- πτόμενα 50%	Μη επικαλυ- πτόμενα	Επικαλυ- πτόμενα 50%	Μη επικαλυ- πτόμενα	Επικαλυ- πτόμενα 50%
Κατέβασμα σκάλας	53.97	61.53	72.06	91.45	79.09	94.97
Ανέβασμα σκάλας	70.08	77.88	81.18	93.15	85.43	94.82
Αναπήδηση	48.49	65.63	69.64	94.52	83.04	94.98
Κατάκλιση	84.98	91.58	82.94	90.13	85.01	92.27
Τρέξιμο	88.72	91.52	95.66	97.70	96.56	98.08
Κάθισμα	72.80	82.42	75.48	80.18	76.86	84.53
Όρθια στάση	68.92	80.65	71.69	81.33	75.03	86.01
Περπάτημα	73.71	81.28	85.11	95.41	90.30	96.71
ΜΕΣΗ ΤΙΜΗ	70.21	79.06	79.22	90.48	83.91	92.80

Πίνακας 6-6: Συνολικός συγκριτικός πίνακας μεταξύ των τριών διαφορετικών μοντέλων που υλοποιήσαμε, με μέτρο σύγκρισης την ευαισθησία κάθε κλάσης/δραστηριότητας.

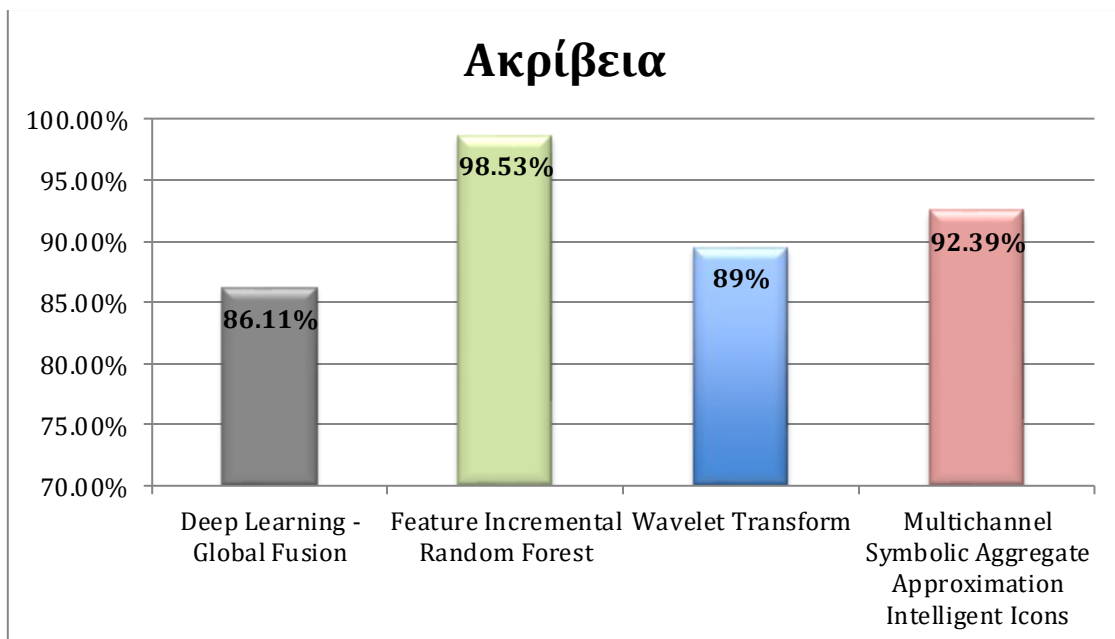
Εύκολα μπορεί κανείς να διαπιστώσει ότι η μέθοδός μας εμφανίζει τα καλύτερα αποτελέσματα σε όλες τις συγκρίσεις. Με βάση τα αποτελέσματα από τον παραπάνω πίνακα αλλά και τους πίνακες σύγχυσης που παραθέσαμε, συμπεραίνουμε τα παρακάτω:

- Το κλασικό μοντέλο με εξαγωγή χαρακτηριστικών από το πεδίο του χρόνου και της συχνότητας εμφανίζει τις πιο χαμηλές τιμές. Η υλοποίηση με την συμβολική αναπαράσταση χρονοσειρών (SAX) βελτιώνει σημαντικά τα εξαγόμενα αποτελέσματα, εμφανίζοντας μια μεσοσταθμική αύξηση της τάξης των 10 ποσοστιαίων μονάδων. Τέλος, η μέθοδός μας βελτιώνει περαιτέρω τις επιδόσεις παρουσιάζοντας αύξηση κατά περίπου 3% στις μέσες τιμές ευαισθησίας.
- Η προσέγγιση με τη χρήση επικαλυπτόμενων παραθύρων δίνει σαφώς καλύτερα προβλεπτικά αποτελέσματα και στις τρεις υλοποιήσεις. Η μεγαλύτερη αύξηση (και μάλιστα κατά περίπου 20 ποσοστιαίες μονάδες) παρατηρείται στη δραστηριότητα “αναπήδηση”. Κάτι τέτοιο ερμηνεύεται από το γεγονός πως η συγκεκριμένη δραστηριότητα αποτελείται από λιγότερα σημεία συγκριτικά με τις υπόλοιπες. Συνεπώς με την επικάλυψη των κυλιόμενων παραθύρων κατά 50% δημιουργήσαμε τεχνηέντως επιπλέον σημεία που περιγράφουν την εν λόγω δραστηριότητα. Συνεπώς, η τεχνική της επικάλυψης βοήθησε σε μεγάλο βαθμό την προβλεπτική ικανότητα του μοντέλου.
- Η δραστηριότητα “τρέξιμο” εμφανίζει τα υψηλότερα ποσοστά και στα τρία μοντέλα, τόσο με την τεχνική της επικάλυψης, όσο και χωρίς. Είναι μια δυναμική δραστηριότητα που παρουσιάζει εύκολα διακρίσιμα χαρακτηριστικά (π.χ. μεγαλύτερη συχνότητα μεταβάσεων) και επιπλέον τα διαθέσιμα σημεία που προέρχονται από το αντίστοιχο σήμα έχουν μεγάλο πλήθος.
- Αξιοσημείωτη αύξηση της προβλεπτικής ικανότητας παρουσιάζει η δραστηριότητα “κατέβασμα σκάλας” και στις δύο υλοποιήσεις με συμβολική αναπαράσταση (μονοκαναλικά και πολυκαναλικά έξυπνα εικονίδια) σε σχέση με το κλασικό μοντέλο. Επιπλέον, σε σύγκριση τώρα με τις προσεγγίσεις μη επικάλυψης και επικάλυψης, έχουμε κι εδώ σημαντική αύξηση για την δεύτερη εξ αυτών, καθώς η διαρροή που παρατηρείται κατά κύριο λόγο προς τις δραστηριότητες “ανέβασμα” και “βάδιση” μετριάζεται σημαντικά.
- Τα χαμηλότερα ποσοστά στα μοντέλα με τα μονοκαναλικά και τα πολυκαναλικά έξυπνα εικονίδια εμφανίζονται στις δραστηριότητες “κάθισμα” και “όρθια στάση” που εμφανίζουν και μεταξύ τους διαρροές, αλλά και προς άλλες δραστηριότητες (π.χ. “κατάκλιση”). Πρόκειται για σχεδόν αδρανείς δραστηριότητες οπότε παρουσιάζουν μια σχετική συσχέτιση των χαρακτηριστικών τους και συνεπώς είναι δυσκολότερη η

πρόβλεψή τους. Κι εδώ η τεχνική της επικάλυψης βελτιώνει την προβλεπτική ικανότητα.

6.3. Αποτελέσματα άλλων μεθόδων για την βάση δεδομένων RealWorld (HAR)

Ανατρέξαμε στη βιβλιογραφία με σκοπό να βρούμε αποτελέσματα διαφορετικών μεθόδων που εφαρμόστηκαν στη βάση δεδομένων που χρησιμοποιήσαμε στις υλοποιήσεις της παρούσας εργασίας, ώστε να έχουμε ένα μέτρο σύγκρισης. Παρατηρούμε στην Εικόνα 6-7 πως η μέθοδός μας παρουσιάζει αξιοσημείωτη τιμή ακρίβειας.



Εικόνα 6-7: Συγκριτικό διάγραμμα της επιτευχθείσας ακρίβειας σε σχέση με άλλα μοντέλα για τη βάση δεδομένων RealWorld (HAR) που χρησιμοποιήσαμε. Η μέθοδός μας απεικονίζεται στην τελευταία στήλη.

Η πρώτη στήλη παρουσιάζει μια υλοποίηση με μοντέλο βαθιάς μάθησης [90], η υλοποίηση της δεύτερης στήλης βασίζεται σε μεθόδους μάθησης αύξησης χαρακτηριστικών (Feature Incremental Learning Methods) [91], ενώ η τρίτη στήλη αναφέρεται σε μοντέλο που χρησιμοποιεί τον μετασχηματισμό κυματιδίων [92].

6.4. Οπτικοποίηση δεδομένων μέσω μείωσης διάστασης

Εξήγαμε τους πίνακες με το σύνολο των έξυπνων εικονιδίων για όλα τα παράθυρα (δηλαδή για ολόκληρο το τρισδιάστατο σήμα, προερχόμενο από επιταχυνσιόμετρο και γυροσκοπίο) στην Ενότητα 5.1.4. Εφαρμόζοντας τη μέθοδο της πολυδιάστατης κλιμάκωσης (Multidimensional

Scaling - MDS) υποβαθμίσαμε τις διαστάσεις στις τρεις, ώστε να μπορέσουμε να οπτικοποιήσουμε τα ευρήματά μας στον τρισδιάστατο χώρο.

Πριν παρουσιάσουμε τα αποτελέσματα, κρίνεται χρήσιμη μια σύντομη περιγραφή της μεθόδου της πολυδιάστατης κλιμάκωσης.

6.4.1. Πολυδιάστατη κλιμάκωση (Multidimensional Scaling – MDS)

Η πολυδιάστατη κλιμάκωση είναι μια οπτική αναπαράσταση αποστάσεων ή ανισοτήτων μεταξύ συνόλων αντικειμένων. Τα «αντικείμενα» μπορεί να είναι χρώματα, πρόσωπα, συντεταγμένες χαρτών, πολιτική πειθώ ή οποιοδήποτε είδος πραγματικών ή εννοιολογικών ερεθισμάτων [93].

Αποτελεί μια μεθοδολογία που ανήκει στη ευρύτερη κατηγορία της πολυμεταβλητής στατιστικής. Πρόκειται για μια διερευνητική τεχνική ανάλυσης των δεδομένων, όπου αναζητούμε σχέσεις μεταξύ μεταβλητών βασιζόμενοι σε αποστάσεις (ή συντελεστές ομοιότητας ή ανομοιότητας) παρουσιάζοντας ποσοτικά μια σαφή και κατά το δυνατόν ακριβή εικόνα των ομοιοτήτων και των διαφορών τους [94]. Συνοπτικά, είναι μια οπτικοποιημένη αναπαράσταση των αποστάσεων ή των (αν-)ομοιοτήτων μεταξύ συνόλων αντικειμένων. Αντικείμενα που είναι περισσότερο όμοια (ή έχουν μικρότερες αποστάσεις) βρίσκονται πιο κοντά μεταξύ τους στο γράφημα από ότι αντικείμενα λιγότερα όμοια (ή που έχουν μεγαλύτερες αποστάσεις). Πέρα από την αποτύπωση των (αν-)ομοιοτήτων ως αποστάσεων σε ένα γράφημα, η MDS μπορεί επιπλέον να χρησιμοποιηθεί ως τεχνική μείωσης διαστάσεων για δεδομένα με πολλές διαστάσεις [95].


Εν κατακλείδι, η τεχνική MDS λαμβάνοντας ως είσοδο τον (συμμετρικό) πίνακα αποστάσεων μεταξύ όλων των ζευγών σημείων, θα μας δώσει έναν πίνακα υποβαθμισμένο στις 2 ή 3 διαστάσεις όπου μεγαλύτερες αποστάσεις μεταξύ των ζευγών σημείων θα υποδηλώνει μεγαλύτερη ανομοιότητα, και το αντίστροφο. Ο υποβαθμισμένος αυτός πίνακας μπορεί να αναπαρασταθεί γραφικά (στις 2 ή 3 διαστάσεις) κι έτσι μπορούμε να εξάγουμε συμπεράσματα για το σύνολο των δεδομένων μας. Επιγραμματικά, τα βήματα της μεθόδου παρουσιάζονται ακολούθως:

- Ανάθεση των σημείων του αρχικού πίνακα δεδομένων σε τυχαίες συντεταγμένες του N υποβαθμισμένου χώρου.


- Υπολογισμός των αποστάσεων (π.χ. Ευκλείδειων) ανάμεσα σε όλα τα ζεύγη σημείων και εξαγωγή του συμμετρικού πίνακα ομοιότητας.
- Σύγκριση του πίνακα ομοιότητας με τον αρχικό πίνακα δεδομένων υπολογίζοντας την συνάρτηση σφάλματος (stress function). Μικρότερη τιμή αυτής συνεπάγεται καλύτερη προσαρμογή των αποστάσεων.
- Αναπροσαρμογή των συντεταγμένων κάθε σημείου προς την κατεύθυνση που ελαχιστοποιεί τη συνάρτηση σφάλματος.
- Επανάληψη των βημάτων 2 έως 4 μέχρις ότου η συνάρτηση σφάλματος δεν γίνεται μικρότερη.

Παρακάτω παρατίθενται επιλεκτικά για ένα άτομο (το 1^ο υποκείμενο της βάσης δεδομένων) γραφήματα που αναπαριστούν τα εξαγόμενα χαρακτηριστικά στον τρισδιάστατο χώρο όπως προέκυψαν για όλες τις δραστηριότητες. Ωστόσο, ανάλογα γραφήματα σε γενικές γραμμές προέκυψαν και για τα υπόλοιπα άτομα που συμμετείχαν.

Στην Εικόνα 6-8 και την Εικόνα 6-9 αποτυπώνεται η πολυδιάστατη κλιμάκωση για το κλασικό μοντέλο για την περίπτωση των μη επικαλυπτόμενων και των επικαλυπτόμενων παραθύρων αντίστοιχα.




Εικόνα 6-8: Αποτύπωση πολυδιάστατης κλιμάκωσης στην προσέγγιση των μη επικαλυπτόμενων παραθύρων (κλασικό μοντέλο εξαγωγής χαρακτηριστικών)




Εικόνα 6-9: Αποτύπωση πολυδιάστατης κλιμάκωσης στην προσέγγιση των επικαλυπτόμενων παραθύρων (κλασικό μοντέλο εξαγωγής χαρακτηριστικών)

Στην Εικόνα 6-10 και την Εικόνα 6-11 αποτυπώνεται η πολυδιάστατη κλιμάκωση για την περίπτωση του μοντέλου με τα μονοκαναλικά έξυπνα εικονίδια των μη επικαλυπτόμενων και των επικαλυπτόμενων παραθύρων αντίστοιχα.




Εικόνα 6-10: Αποτύπωση πολυδιάστατης κλιμάκωσης στην προσέγγιση των μη επικαλυπτόμενων παραθύρων (μονοκαναλικά εικονίδια)




Εικόνα 6-11: Αποτύπωση πολυδιάστατης κλιμάκωσης στην προσέγγιση των επικαλυπτόμενων παραθύρων (μονοκαναλικά εικονίδια)

Στην Εικόνα 6-12 και την Εικόνα 6-13 αποτυπώνεται η πολυδιάστατη κλιμάκωση για την περίπτωση του μοντέλου με τα πολυκαναλικά έξυπνα εικονίδια των μη επικαλυπτόμενων και των επικαλυπτόμενων παραθύρων αντίστοιχα.



Εικόνα 6-12: Αποτύπωση πολυδιάστατης κλιμάκωσης στην προσέγγιση των μη επικαλυπτόμενων παραθύρων (πολυκαναλικά εικονίδια)



Εικόνα 6-13: Αποτύπωση πολυδιάστατης κλιμάκωσης στην προσέγγιση των επικαλυπτόμενων παραθύρων (πολυκαναλικά εικονίδια)

Παρατηρώντας προσεκτικά (και περιστρέφοντας τα γραφήματά μας στο περιβάλλον που χρησιμοποιήσαμε για τη εξαγωγή τους) καταλήγουμε σε μια σειρά συμπερασμάτων:

- Στο κλασικό μοντέλο είναι αδύνατο να παρατηρηθεί κάποια ομαδοποίηση, καθώς οι παρατηρήσεις εμφανίζονται συγκεχυμένες. Ούτε η τεχνική της επικάλυψης βοηθάει στην εξαγωγή συμπερασμάτων μέσω της οπτικοποίησης των δεδομένων. Εν αντιθέσει, στα άλλα δύο μοντέλα εμφανίζονται ομαδοποιήσεις κλάσεων σε μικρό ή μεγαλύτερο βαθμό, κατά συνέπεια θα εστιάσουμε σε αυτές στη συνέχεια των συμπερασμάτων μας.
- Η δραστηριότητα “τρέξιμο” και “βόδιση” παρουσιάζονται να ομαδοποιούνται πολύ καλύτερα από όλες τις υπόλοιπες, καταλαμβάνοντας συγκεκριμένο χώρο, συγκροτημένα. Κάτι τέτοιο είναι αναμενόμενο καθώς πρόκειται για δυναμικές δραστηριότητες που παρουσιάζουν συγκεκριμένα χαρακτηριστικά ως προς το τρισδιάστατο σήμα της επιτάχυνσης και γωνιακής ταχύτητας που μελετάμε.
- Η δραστηριότητα “κατάκλιση” εμφανίζει μια κεντρική συστάδα σημείων και μια δεύτερη μικρότερη, αποκομμένη από την πρώτη.
- Η δραστηριότητα “αναπήδηση” εμφανίζεται να έχει λίγα σημεία γεγονός που οφείλεται στα λίγα δεδομένα που εξ αρχής παρέχονταν από τη βάση δεδομένων που χρησιμοποιήθηκε. Αυτή η ανισοκατανομή δεδομένων (και συνακόλουθα σημείων) έχει αποτυπωθεί ως πρόβλημα στο στάδιο της ταξινόμησης των δραστηριοτήτων.

- Οι δραστηριότητες “ανέβασμα σκάλας” και “κατέβασμα σκάλας” εμφανίζονται πεπλεγμένες μεταξύ τους στην περίπτωση των μονοκαναλικών έξυπνων εικονιδίων, καθώς παρουσιάζουν παρόμοια χαρακτηριστικά. Κάτι ανάλογο έχουμε διαβάσει σε ανάλογη μελέτη [7]. Ωστόσο, κάτι τέτοιο δεν παρατηρήθηκε στην περίπτωση των πολυκαναλικών έξυπνων εικονιδίων.
- Τέλος, οι δραστηριότητες “κάθισμα” και “όρθια στάση” παρουσιάζουν τον χαμηλότερο βαθμό ομαδοποίησης, καθώς τα σημεία τους είναι διασκορπισμένα στον χώρο. Το εύρημα αυτό σχετίζεται με τη δυσκολία στην αναγνώριση αυτών των δραστηριοτήτων από το μοντέλο ταξινόμησης, όπως έχουμε ήδη παρατηρήσει. Αξίζει να επισημάνουμε πως ανάλογες δυσκολίες αναγνώρισης αυτών των δραστηριοτήτων έχουν αναφερθεί και στη βιβλιογραφία [1, 96], λόγω της απεριοδικότητας αυτών των σημάτων και της συνακόλουθης δυσκολίας διάκρισής τους.

7. Συμπεράσματα

Η εργασία αυτή επικεντρώθηκε στις τεχνικές της μηχανικής μάθησης που χρησιμοποιούνται στον τομέα της αναγνώρισης των ανθρώπινων δραστηριοτήτων. Ιδιαίτερη έμφαση δόθηκε στις προσεγγίσεις που μεταφέρουν μια χρονοσειρά από τον χώρο των πραγματικών αριθμών στον συμβολικό χώρο. Οι συμβολικές αναπαραστάσεις παρέχουν ευελιξία στην χρήση, επεξεργασία και μεταξύ τους σύγκριση. Προς τούτο, επιλέχθηκε αυτή η τεχνική για εφαρμογή της σε πρόβλημα αναγνώρισης ανθρώπινης δραστηριότητας, κάνοντας χρήση μιας βάσης δεδομένων ελεύθερης πρόσβασης.

Η μελέτη αυτή εισάγει και περιγράφει μια υβριδική τεχνική εξαγωγής έξυπνων εικονιδίων, καθώς αυτά εξάγονται με τρόπο ώστε να συσχετίζεται η πληροφορία από όλα τα κανάλια του υπό διερεύνηση σήματος. Τα Πολυκαναλικά Έξυπνα Εικονίδια Συμβολικής Συναθροιστικής Προσέγγισης (Multichannel Symbolic Aggregate Approximation Intelligent Icons) αποτελούν την ερευνητική μας συνεισφορά. Τα πολυκαναλικά εικονίδια τοποθετούνται ως επιπλέον χαρακτηριστικά πέραν των μονοκαναλικών έξυπνων εικονιδίων σχηματίζοντας έναν ενιαίο πίνακα χαρακτηριστικών. Ο πίνακας αυτός αποτελεί την είσοδο σε ταξινομητή ενός πλησιέστερου γείτονα, από όπου και εξάγονται αποτελέσματα σχετικά με την επίδοση του μοντέλου. Για λόγους σύγκρισης σχεδιάσαμε και υλοποιήσαμε το μοντέλο των μονοκαναλικών έξυπνων εικονιδίων, καθώς και ένα κλασικό μοντέλο εξαγωγής χαρακτηριστικών από τον χώρο του χρόνου και των συχνοτήτων με εφαρμογή αυτών ακριβώς στο ίδιο σύνολο δεδομένων.

Αυτό που διαπιστώθηκε με σαφήνεια είναι η εξαιρετική επίδοση σε σχέση με το κλασικό μοντέλο, αλλά και η αξιοσημείωτη βελτίωση στα αποτελέσματα σε σύγκριση με το μοντέλο των μονοκαναλικών έξυπνων εικονιδίων. Επιπλέον, παρατηρήθηκε υπερκέρραση της δυσκολίας ταξινόμησης δραστηριοτήτων με όμοια χαρακτηριστικά. Η προτεινόμενη μέθοδος διαπρέπει στην πρόβλεψη και αναγνώριση δυναμικών ανθρώπινων δραστηριοτήτων. Τέλος, συμπεράναμε ότι η τεχνική των κυλιόμενων παραθύρων βελτιώνει τα πειραματικά αποτελέσματα και στα τρία μοντέλα που υλοποιήσαμε.

Αυτό, ωστόσο που θα μπορούσαμε να πούμε ότι αποτελεί «αδυναμία» της μεθόδου είναι η ανάγκη για προκαθορισμό παραμέτρων (μέγεθος παραθύρου, μέγεθος αλφαβήτου, μήκος λέξης, βαθμός συμπίεσης) που έχουν άμεσο αντίκτυπο στο τελικό αποτέλεσμα. Σε αυτή τη φάση ο καθορισμός τους έγινε μέσω διαδικασίας δοκιμής και σφάλματος (trial and error) για την εύρεση των βέλτιστων τιμών.

Συνεπώς, παραμένει ανοιχτό το πεδίο για βελτιώσεις της προτεινόμενης μεθόδου ξεκινώντας από την εύρεση τρόπου για αυτοματοποιημένο καθορισμό των βέλτιστων τιμών των παραμέτρων. Επιπλέον, ενδιαφέρον παρουσιάζει η προσπάθεια ταξινόμησης πιο σύνθετων ανθρώπινων δραστηριοτήτων που χαρακτηρίζονται από μεταβατικές κινήσεις. Σε επόμενο στάδιο σκοπεύουμε να προχωρήσουμε στην εφαρμογή της σε σύνολα δεδομένων διαφορετικής φύσης (δηλαδή, όχι για αναγνώριση ανθρώπινης δραστηριότητας), αλλά και σύνολα δεδομένων που εμφανίζουν ανισορροπία ως προς το πλήθος των τιμών κάθε κλάσης. Τέλος, βελτιώσεις θα μπορούσαν να πραγματοποιηθούν προς την κατεύθυνση της καλύτερης περιγραφής της τάσης της υπό μελέτης χρονοσειράς.

Συμπερασματικά, έχουμε προτείνει μια ημι-αυτόματη μέθοδο (η εξαγωγή των χαρακτηριστικών πραγματοποιείται αυτόματα) για την αναγνώριση ανθρώπινων δραστηριοτήτων, η οποία εμφανίζει εξαιρετικά υψηλή απόδοση υπό όρους ακρίβειας πρόβλεψης, κάνοντας χρήση δεδομένων από δύο μόνο αισθητήρες (επιταχυνσιόμετρο και γυροσκόπιο). Ο προτεινόμενος αλγόριθμος είναι απλός στην υλοποίηση και διαισθητικός, καθώς στοχεύει στη συμπερίληψη και συσχέτιση της πληροφορίας από όλα τα κανάλια ενός σήματος. Η απλότητά του έχει ως αντίκτυπο το σχετικά χαμηλό υπολογιστικό κόστος και κόστος πολυπλοκότητας, καθιστώντας τον μια δυνατή επιλογή για χρήση σε ροές δεδομένων.

ΔΗΜΟΣΙΕΥΣΕΙΣ

Οι παρακάτω δημοσιεύσεις έχουν προκύψει στα πλαίσια της παρούσας διπλωματικής εργασίας:

- I. L. Pappa, P. Karvelis, G. Georgoulas and C. Stylios, "Multichannel Symbolic Aggregate Approximation Intelligent Icons: Application for Activity Recognition," *2020 IEEE Symposium Series on Computational Intelligence (SSCI)*, Canberra, Australia, 2020, pp. 505-512, doi: 10.1109/SSCI47803.2020.9308497.
- II. L. Pappa, P. Karvelis, G. Georgoulas and C. Stylios "Theoretical justification and application opportunities for Multichannel Symbolic Aggregate Approximation Intelligent Icons" under preparation and submission for international journal.

ΒΙΒΛΙΟΓΡΑΦΙΑ

- [1] D. Anguita, A. Ghio, L. Oneto, X. Parra και J. L. Reyes-Ortiz, «A Public Domain Dataset for Human Activity Recognition using Smartphones,» σε *ESANN*, 2013.
- [2] A. M. Garcia, «HUMAN ACTIVITY RECOGNITION BY INERTIAL SIGNALS OBTAINED FROM A SMARTPHONE,» 2016.
- [3] O. Banos, J.-M. Galvez, M. Damas, H. Pomares και I. Rojas, «Window Size Impact in Human Activity Recognition,» *Sensors*, τόμ. 14, p. 6474–6499, 4 2014.
- [4] «Ageing and health,» 5 February 2018. [Ηλεκτρονικό]. Available: <https://www.who.int/news-room/fact-sheets/detail/ageing-and-health>.
- [5] L. Gao, A. K. Bourke και J. Nelson, «Evaluation of accelerometer based multi-sensor versus single-sensor activity recognition systems,» *Medical Engineering & Physics*, τόμ. 36, p. 779–785, 6 2014.
- [6] L. Atallah, B. Lo, R. King και G.-Z. Yang, «Sensor Positioning for Activity Recognition Using Wearable Accelerometers,» *IEEE Transactions on Biomedical Circuits and Systems*, τόμ. 5, p. 320–329, 8 2011.
- [7] C. Catal, S. Tufekci, E. Pirmitt και G. Kocabag, «On the use of ensemble of classifiers for accelerometer-based activity recognition,» *Applied Soft Computing*, τόμ. 37, p. 1018–1022, 12 2015.
- [8] D. Cook, K. D. Feuz και N. C. Krishnan, «Transfer learning for activity recognition: a survey,» *Knowledge and Information Systems*, τόμ. 36, p. 537–556, 6 2013.
- [9] T. Mitchell, *Machine Learning*, New York: McGraw-Hill, 1997.
- [10] I. Goodfellow, J. Bengio, A. Courville και F. Bach, *Deep Learning*, MIT Press Ltd, 2016.
- [11] M. Awad και R. Khanna, «Machine Learning,» σε *Efficient Learning Machines*, Apress, 2015, p. 1–18.
- [12] M. Talabis, R. Mcpherson και I. Miyamoto, *Information Security Analytics: Finding Security Insights, Patterns, and Anomalies in Big Data*, SYNGRESS MEDIA, 2014.
- [13] C. M. Bishop, *Pattern Recognition and Machine Learning*, Springer-Verlag New York Inc., 2006.
- [14] S. Russell, *Artificial intelligence : a modern approach*, Upper Saddle River, New Jersey: Prentice Hall, 2010.
- [15] B. Rokad, «Machine Learning Approaches and Its Applications,» 1 Αύγουστος 2019. [Ηλεκτρονικό]. Available: <https://medium.com/datadriveninvestor/machine-learning-approaches-and-its-applications-7bfbe782f4a8>. [Πρόσβαση 28 Δεκέμβριος 2020].
- [16] M. Mohri, *Foundations of machine learning*, Cambridge, MA: MIT Press, 2012.
- [17] E. Alpaydin, *Introduction to Machine Learning*, MIT Press Ltd, 2020.
- [18] S. Torfi, «A Meticulous Introduction to Supervised Learning in a Simple Way,» 17 Μάιος 2019. [Ηλεκτρονικό]. Available: <https://www.machinelearningmindset.com/powerful-supervised-learning/>. [Πρόσβαση 28 Δεκέμβριος 2020].
- [19] R. E. Bellman, *Adaptive control processes: a guided tour*, τόμ. 2045, Princeton university press, 2015.

-
-
- [20] A. S. Nsang, «An Empirical Study of Novel Approaches to Dimensionality Reduction and Applications,» 2011.
- [21] Α. Δημαράκη, «Εξαγωγή Χαρακτηριστικών και Ταξινόμηση Βιολογικών Σημάτων για χρήση στα Συστήματα Υποβοήθησης της Διάγνωσης,» 2017.
- [22] A. L. G. N. Gomes, «Human Activity Recognition with Accelerometry: Novel Time and Frequency Features,» 2014.
- [23] Ç. B. Erdaş, I. Atasoy, K. Açııcı και Η. Oğul, «Integrating Features for Accelerometer-based Activity Recognition,» *Procedia Computer Science*, τόμ. 98, p. 522–527, 2016.
- [24] L. Cao, Y. Wang, Q. Jin και J. Ma, «ActiRecognizer: Design and Implementation of a Real-Time Human Activity Recognition System,» σε *2017 International Conference on Cyber-Enabled Distributed Computing and Knowledge Discovery (CyberC)*, 2017.
- [25] S. Rosati, G. Balestra και M. Knaflitz, «Comparison of Different Sets of Features for Human Activity Recognition by Wearable Sensors,» *Sensors*, τόμ. 18, p. 4189, 11 2018.
- [26] S. J. Preece, J. Y. Goulermas, L. P. J. Kenney, D. Howard, K. Meijer και R. Crompton, «Activity identification using body-mounted sensors—a review of classification techniques,» *Physiological Measurement*, τόμ. 30, p. R1–R33, 4 2009.
- [27] L. Bao και S. S. Intille, «Activity Recognition from User-Annotated Acceleration Data,» σε *Lecture Notes in Computer Science*, Springer Berlin Heidelberg, 2004, p. 1–17.
- [28] A. Bulling, U. Blanke και B. Schiele, «A tutorial on human activity recognition using body-worn inertial sensors,» *ACM Computing Surveys*, τόμ. 46, p. 1–33, 1 2014.
- [29] M. Zhang και A. A. Sawchuk, «A Feature Selection-Based Framework for Human Activity Recognition Using Wearable Multimodal Sensors,» σε *Proceedings of the 6th International Conference on Body Area Networks*, Brussels, 2011.
- [30] M. H. M. Noor, Z. Salcic και K. I.-K. Wang, «Adaptive sliding window segmentation for physical activity recognition using a single tri-axial accelerometer,» *Pervasive and Mobile Computing*, τόμ. 38, p. 41–59, 7 2017.
- [31] A. Oppermann, «What is Deep Learning and How does it work? - Towards Data Science,» 11 August 2020. [Ηλεκτρονικό]. Available: <https://towardsdatascience.com/what-is-deep-learning-and-how-does-it-work-2ce44bb692ac>.
- [32] D. Y. Li Deng, *Deep Learning*, Now Publishers Inc, 2014.
- [33] Y. LeCun, Y. Bengio και G. Hinton, «Deep learning,» *Nature*, τόμ. 521, p. 436–444, 5 2015.
- [34] S. Kim, H. Nam, H. Park, Y.-T. Lee και Y. Yoon, «Activity-Recognition Model for Violence Behavior Using LSTM,» σε *Advances in Computer Science and Ubiquitous Computing*, Singapore, 2021.
- [35] K. Kim και Y. K. Cho, «Automatic Recognition of Workers' Motions in Highway Construction by Using Motion Sensors and Long Short-Term Memory Networks,» *Journal of Construction Engineering and Management*, τόμ. 147, p. 04020184, 3 2021.
- [36] R. Kanjilal και I. Uysal, «The Future of Human Activity Recognition: Deep Learning or Feature Engineering?,» *Neural Processing Letters*, 1 2021.
- [37] P. Siirtola και J. Rönning, «Context-aware incremental learning-based method for personalized human activity recognition,» *Journal of Ambient Intelligence and Humanized Computing*, 1 2021.
-
-

- [38] Z. Pan και C. Wei, «Human activity monitoring based on indoor map positioning,» *Microsystem Technologies*, 1 2021.
- [39] A. L. Haroon και D. R. Premachand, «Human Activity Recognition using Machine Learning Approach,» *Journal of Robotics and Control (JRC)*, τόμ. 2, 2021.
- [40] K. Ramachandran και J. Pang, «Transfer Learning Technique for Human Activity Recognition based on Smartphone Data,» *International Journal of Civil Engineering Research*, τόμ. 11, pp. 1-17, 2020.
- [41] M. Lewandowski, B. Płaczek και M. Bernas, «Classifier-Based Data Transmission Reduction in Wearable Sensor Network for Human Activity Monitoring,» *Sensors*, τόμ. 21, p. 85, 12 2020.
- [42] Y. Tian, J. Zhang, J. Wang, Y. Geng και X. Wang, «Robust human activity recognition using single accelerometer via wavelet energy spectrum features and ensemble feature selection,» *Systems Science & Control Engineering*, τόμ. 8, p. 83–96, 1 2020.
- [43] R. Sekiguchi, K. Abe, T. Yokoyama, M. Kumano και M. Kawakatsu, «Ensemble Learning for Human Activity Recognition,» σε *Adjunct Proceedings of the 2020 ACM International Joint Conference on Pervasive and Ubiquitous Computing and Proceedings of the 2020 ACM International Symposium on Wearable Computers*, New York, NY, USA, 2020.
- [44] S. Malinowski, T. Guyet, R. Quiniou και R. Tavenard, «1d-SAX: A Novel Symbolic Representation for Time Series,» σε *Advances in Intelligent Data Analysis XII*, Springer Berlin Heidelberg, 2013, p. 273–284.
- [45] P. Esling και C. Agon, «Time-Series Data Mining,» *ACM Comput. Surv.*, τόμ. 45, 12 2012.
- [46] J. Lin, E. Keogh, S. Lonardi και B. Chiu, «A symbolic representation of time series, with implications for streaming algorithms,» σε *Proceedings of the 8th ACM SIGMOD workshop on Research issues in data mining and knowledge discovery - DMKD* \textquotesingle03, 2003.
- [47] Α. Παπανίκου, «TIME SERIES DATA MINING,» 2008.
- [48] E. Keogh, K. Chakrabarti, M. Pazzani και S. Mehrotra, «Dimensionality Reduction for Fast Similarity Search in Large Time Series Databases,» *Knowledge and Information Systems*, τόμ. 3, p. 263–286, 8 2001.
- [49] B.-K. Yi και C. Faloutsos, «Fast Time Sequence Indexing for Arbitrary Lp Norms,» *Proceedings of the 26th International Conference on Very Large Data Bases, VLDB'00*, pp. 385-394, 1 2000.
- [50] E. Keogh, J. Lin και A. Fu, «HOT SAX: Efficiently Finding the Most Unusual Time Series Subsequence,» σε *Fifth IEEE International Conference on Data Mining (ICDM\textquotesingle05)*, 2005.
- [51] J. Lin, E. Keogh, L. Wei και S. Lonardi, «Experiencing SAX: a novel symbolic representation of time series,» *Data Mining and Knowledge Discovery*, τόμ. 15, p. 107–144, 4 2007.
- [52] E. Keogh, L. Wei, X. Xi, S. Lonardi, J. Shieh και S. Sirowy, «Intelligent Icons: Integrating Lite-Weight Data Mining and Visualization into GUI Operating Systems,» σε *Sixth International Conference on Data Mining (ICDM\textquotesingle06)*, 2006.
- [53] P. Karvelis, G. Georgoulas, I. P. Tsoumas, J. A. Antonino-Daviu, V. Climente-Alarcon και C. D. Stylios, «A Symbolic Representation Approach for the Diagnosis of Broken Rotor Bars in Induction Motors,» *IEEE Transactions on Industrial Informatics*, τόμ. 11, p. 1028–1037, 10 2015.
- [54] B. Lkhagva, Y. Suzuki και K. Kawagoe, «Extended SAX: Extension of Symbolic Aggregate Approximation for Financial Time Series Data Representation,» 2006.

-
-
- [55] B. Lkhagva, Y. Suzuki και K. Kawagoe, «New Time Series Data Representation ESAX for Financial Applications,» σε *22nd International Conference on Data Engineering Workshops (ICDEW\textquotesingle06)*, 2006.
- [56] G. Li, L. Zhang και L. Yang, «TSX: A Novel Symbolic Representation for Financial Time Series,» σε *Lecture Notes in Computer Science*, Springer Berlin Heidelberg, 2012, p. 262–273.
- [57] Y. Yu, Y. Zhu, D. Wan, H. Liu και Q. Zhao, «A Novel Symbolic Aggregate Approximation for Time Series,» σε *Advances in Intelligent Systems and Computing*, Springer International Publishing, 2019, p. 805–822.
- [58] J. Shieh και E. Keogh, «iSAX,» σε *Proceeding of the 14th ACM SIGKDD international conference on Knowledge discovery and data mining - KDD 08*, 2008.
- [59] A. Camerra, T. Palpanas, J. Shieh και E. Keogh, «iSAX 2.0: Indexing and Mining One Billion Time Series,» σε *2010 IEEE International Conference on Data Mining*, 2010.
- [60] N. D. Pham, Q. L. Le και T. K. Dang, «Two Novel Adaptive Symbolic Representations for Similarity Search in Time Series Databases,» σε *2010 12th International Asia-Pacific Web Conference*, 2010.
- [61] P. Schäfer και M. Höggqvist, «SFA,» σε *Proceedings of the 15th International Conference on Extending Database Technology - EDBT\textquotesingle12*, 2012.
- [62] M. M. M. Fuad, «Genetic Algorithms-Based Symbolic Aggregate Approximation,» σε *Data Warehousing and Knowledge Discovery*, Springer Berlin Heidelberg, 2012, p. 105–116.
- [63] H. Ruan, X. Hu, J. Xiao και G. Zhang, «TrSAX—An improved time series symbolic representation for classification,» *ISA Transactions*, τόμ. 100, p. 387–395, 5 2020.
- [64] U. Kamath, J. Lin και K. D. Jong, «SAX-EFG,» σε *Proceedings of the 2014 Annual Conference on Genetic and Evolutionary Computation*, 2014.
- [65] Y. Sun, J. Li, J. Liu, B. Sun και C. Chow, «An improvement of symbolic aggregate approximation distance measure for time series,» *Neurocomputing*, τόμ. 138, p. 189–198, 8 2014.
- [66] K. Zhang, Y. Li, Y. Chai και L. Huang, «Trend-based symbolic aggregate approximation for time series representation,» σε *2018 Chinese Control And Decision Conference (CCDC)*, 2018.
- [67] H. Yin, S.-q. Yang, X.-q. Zhu, S.-d. Ma και L.-m. Zhang, «Symbolic representation based on trend features for knowledge discovery in long time series,» *Frontiers of Information Technology & Electronic Engineering*, τόμ. 16, p. 744–758, 9 2015.
- [68] C. T. Zan και H. Yamana, «An improved symbolic aggregate approximation distance measure based on its statistical features,» σε *Proceedings of the 18th International Conference on Information Integration and Web-based Applications and Services*, 2016.
- [69] A. A. Ferreira, I. M. B. R. Barbosa, R. R. B. Aquino, H. Manuel, S. Natarajan, D. Fosas και D. Coley, «Adaptive Piecewise and Symbolic Aggregate Approximation as an Improved Representation Method for Heat Waves Detection,» σε *Advances in Intelligent Systems and Computing*, Springer International Publishing, 2018, p. 658–671.
- [70] Z. He, S. Long, X. Ma και H. Zhao, «A Boundary Distance-Based Symbolic Aggregate Approximation Method for Time Series Data,» *Algorithms*, τόμ. 13, p. 284, 11 2020.
- [71] K. Song, M. Ryu και K. Lee, «Transitional SAX Representation for Knowledge Discovery for Time Series,» *Applied Sciences*, τόμ. 10, p. 6980, 10 2020.
-
-

- [72] T. Szytler και H. Stuckenschmidt, «On-body Localization of Wearable Devices: An Investigation of Position-Aware Activity Recognition,» σε *2016 IEEE International Conference on Pervasive Computing and Communications (PerCom)*, 2016.
- [73] T. Szytler, «DataSet - RealWorld (HAR),» 2016. [Ηλεκτρονικό]. Available: https://sensor.informatik.uni-mannheim.de/index.html#dataset_realworld. [Πρόσβαση 02 January 2021].
- [74] J. Wåhslén, «Multi-Sensor Data Synchronization using Mobile Phones,» 2013.
- [75] C. Moler, *Numerical computing with MATLAB*, Philadelphia: Society for Industrial and Applied Mathematics, 2004.
- [76] I. Pitas και A. N. Venetsanopoulos, «Median Filters,» σε *Nonlinear Digital Filters*, Springer US, 1990, p. 63–116.
- [77] G. Bianchi, *Electronic filter simulation & design*, New York: McGraw-Hill, 2007.
- [78] I. N. Junejo και Z. A. Aghbari, «Using SAX representation for human action recognition,» *Journal of Visual Communication and Image Representation*, τόμ. 23, p. 853–861, 8 2012.
- [79] J. O. Bird, «The normal distribution,» σε *Engineering Mathematics*, Abingdon, Oxon New York, NY, Routledge, 2017, p. 726.
- [80] N. Yala, B. Fergani και A. Fleury, «Feature extraction for human activity recognition on streaming data,» σε *2015 International Symposium on Innovations in Intelligent Systems and Applications (INISTA)*, 2015.
- [81] S. Kozina, M. Lustrek και M. Gams, «Dynamic signal segmentation for activity recognition,» 2011.
- [82] L. Wang, T. Gu, X. Tao και J. Lu, «A hierarchical approach to real-time activity recognition in body sensor networks,» *Pervasive and Mobile Computing*, τόμ. 8, p. 115–130, 2 2012.
- [83] L. Pappa, P. Karvelis, G. Georgoulas και C. Stylios, «Multichannel Symbolic Aggregate Approximation Intelligent Icons: Application for Activity Recognition,» σε *2020 IEEE Symposium Series on Computational Intelligence (SSCI)*, 2020.
- [84] P. Refaeilzadeh, L. Tang και H. Liu, «Cross-Validation,» σε *Encyclopedia of Database Systems*, Springer US, 2009, p. 532–538.
- [85] T. Hastie, R. Tibshirani και J. Friedman, *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*, Second Edition, SPRINGER NATURE, 2009.
- [86] A. Pandey και A. Jain, «Comparative Analysis of KNN Algorithm using Various Normalization Techniques,» *International Journal of Computer Network and Information Security*, τόμ. 9, p. 36–42, 11 2017.
- [87] P. Sharma, «Why is scaling required in KNN and K-Means?,» 25 August 2019. [Ηλεκτρονικό]. Available: <https://medium.com/analytics-vidhya/why-is-scaling-required-in-knn-and-k-means-8129e4d88ed7>. [Πρόσβαση 02 January 2021].
- [88] A. Zheng, *Evaluating Machine Learning Models*, City: O'Reilly Media, Inc, 2015.
- [89] M. S. Nathalie Japkowicz, *Evaluating Learning Algorithms*, Cambridge University Press, 2013.
- [90] S. Liu, S. Yao, J. Li, D. Liu, T. Wang, H. Shao και T. Abdelzaher, «GlobalFusion: A Global Attentional Deep Learning Framework for Multisensor Information Fusion,» *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, τόμ. 4, p. 1–27, 3 2020.

- [91] C. Hu, Y. Chen, X. Peng, H. Yu, C. Gao και L. Hu, «A Novel Feature Incremental Learning Method for Sensor-Based Activity Recognition,» *IEEE Transactions on Knowledge and Data Engineering*, τόμ. 31, p. 1038–1050, 6 2019.
- [92] M. G. Abdu-Aguye και W. Gomaa, «Competitive Feature Extraction for Activity Recognition based on Wavelet Transforms and Adaptive Pooling,» σε *2019 International Joint Conference on Neural Networks (IJCNN)*, 2019.
- [93] J. Kruskal και M. Wish, *Multidimensional Scaling*, SAGE Publications, Inc., 1978.
- [94] I. Borg, P. J. F. Groenen και P. Mair, *Applied Multidimensional Scaling*, Springer-Verlag GmbH, 2012.
- [95] A. Buja, D. F. Swayne, M. L. Littman, N. Dean, H. Hofmann και L. Chen, «Data Visualization With Multidimensional Scaling,» *Journal of Computational and Graphical Statistics*, τόμ. 17, p. 444–472, 6 2008.
- [96] M. Milenkoski, K. Trivodaliev, S. Kalajdziski, M. Jovanov και B. R. Stojkoska, «Real time human activity recognition on smartphones using LSTM networks,» σε *2018 41st International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)*, 2018.

ΠΑΡΑΡΤΗΜΑ

Παρατίθενται οι κώδικες υλοποίησης όλων των μεθόδων σε περιβάλλον MATLAB.

```
clear all; clc;
```

```
s_acc='C:\Users\Lamprini\Desktop\track\synced_and_downsampled\acc_dbsubjects\  
s_gyro='C:\Users\Lamprini\Desktop\track\synced_and_downsampled\gyro_dbsubjects\'
```

```
for i = 1:15 %all subjects  
    for j = 1:8 % all activities  
        name = strcat(num2str(i), num2str(j));  
        acc = bring(s_acc, i, j);  
        gyro = bring(s_gyro, i, j);  
        if isempty(acc) && isempty(gyro)  
            continue;  
        else  
            sync_data = sync_and_downsample(acc,gyro);  
            dlmwrite([name '.csv'],sync_data,'precision',13);  
        end  
    end  
end  
end
```

```
function data = bring(directory, subject, activity)
```

```
    s = directory;  
  
    d1=dir(s);  
    d1(1:2) = [];  
  
    actcell = {'climbingdown', 'climbingup', 'jumping', 'lying', 'running', 'sitting', 'standing',  
'walking'};  
    N = length (d1);  
  
    s_name = strcat(s,d1(subject).name);  
    s_name = strcat(s_name,'\');  
    d2 = dir(s_name);  
    d2(1:2) = [];  
    actn=length (d2);  
    act_name = strcat(s_name,d2(activity).name);  
    activitynumber = find_class(d2(activity).name,actcell);  
    if (d2(activity).bytes) > 10  
        data = csvread(act_name, 1,1);  
  
    else  
        data=[];  
    end  
end
```

end

function TT = sync_and_downsample(acc,gyro)

t_gyro = datetime(gyro(:,1),'ConvertFrom','epochtime','TicksPerSecond',1e3,'Format','dd-
MMM-yyyy HH:mm:ss.SSS');
TG = array2timetable(gyro,'RowTimes',t_gyro);
TG(:, [1]) =[];

t_acc = datetime(acc(:,1),'ConvertFrom','epochtime','TicksPerSecond',1e3,'Format','dd-
MMM-yyyy HH:mm:ss.SSS');
TA = array2timetable(acc,'RowTimes',t_acc);
TA(:, [1]) =[];

TT = synchronize(TA,TG, 'union');
[F,TF] = fillmissing(TT,'pchip');
d = posixtime(F.Time); % convert to the original time form

d = d*1000;

F = F{:,}; % convert timetable to double array
F = [d F]; % first column the time

down_points = round((size(acc,1)+size(gyro,1))/2); % the number of points of the
downsampled timeseries
idx = [1:size(F,1)]; % Index
idxq = linspace(min(idx), max(idx), down_points); % Interpolation Vector
Vi = interp1(idx, F, idxq, 'pchip'); % Downsampled Vector

id = [1:size(Vi,1)];

TT = [id Vi];
end

clear all; clc;

s1='C:\Users\Lamprini\Desktop\track\synced_and_downsampled\db_synced_and_downsampled\'

d1=dir(s1);

d1=d1(~ismember({d1.name},{' ','..'}));

actcell = {'climbingdown', 'climbingup', 'jumping', 'lying', 'running', 'sitting', 'standing',
'walking'};

N = length (d1);

data = [];

ii=1;

icons_non{1}=[]; icons_non{2}=[];

icons_over{1}=[]; icons_over{2}=[];

for i=1:N % run through all subjects 1:N

s_name = strcat(s1,d1(i).name);

```
s_name = strcat(s_name,'\');
d2 = dir(s_name);
d2=d2(~ismember({d2.name},{' ','..'}));
actn=length (d2);
for j = 1:actn % run through all activities 1:actn
    act_name = strcat(s_name,d2(j).name);

    activitynumber = find_class(d2(j).name,actcell); %integer: 1-8
    if d2(j).bytes > 10
        d = csvread (act_name, 0,1);
        d_a = d(:,2:4); d_g = d(:, 5:7);
    else
        continue;
    end

    n = 3;
    % n = size(d,2)-1;
    for k=1:n % run through all dimensions 1:n
        signal{1}=d_a(:,k); % accelerometer signal
        signal{2}=d_g(:,k); % gyroscope signal
        tic
        for z = 1:2
            [i_non{z},i_over{z}] = sax_function(signal{z}, 50, 5, 20, 2.56, 32, 4, 3); %(raw data
x,y,z axis, sampling freq, order of butterworth filter, cutoff freq of butterworth, time/window,
symbols/window, alphabet size, word length)
            toc
            %t1=repmat(k,length(i_non), 1);
            %t2=repmat(i,length(i_non), 1);
            %t3=repmat(activitynumber,length(i_non), 1);
            i_non{z}=[i_non{z},repmat(k,size(i_non{z}, 1), 1), 1), 1),
repmat(activitynumber,size(i_non{z}, 1), 1), repmat(i,size(i_non{z}, 1), 1)];
            icons_non{z}=[icons_non{z};i_non{z}];
            i_over{z} = [i_over{z}, repmat(k,size(i_over{z}, 1), 1), 1), 1),
repmat(activitynumber,size(i_over{z}, 1), 1), repmat(i,size(i_over{z}, 1), 1)];
            icons_over{z} = [icons_over{z}; i_over{z}];
        end
    end
end
end
end

save ('synch_SAX_4_3.mat', 'icons_non', 'icons_over');

labels_non = icons_non{1}(:, (end-2):end);
labels_over = icons_over{1}(:, (end-2):end);
non = [icons_non{1}(:, 1:(end-3)) icons_non{2}(:, 1:(end-3)) labels_non];
over = [icons_over{1}(:, 1:(end-3)) icons_over{2}(:, 1:(end-3)) labels_over];
save('combined_SAX_4_3.mat', 'non', 'over');
```

```
function [all_icons_non, all_icons_over] = sax_function(signal, sample_frequency, butt_order,
f_co, time_window, symbols_window, alph_size, word_length)
```

```
% cut 2% signal from the beginning and the end to remove undesirable points
```

```
remove_points = round(size(signal,1)*2/100);
```

```
signal = signal(remove_points+1:end-remove_points);
```

```
data=filter_data_2 (signal, sample_frequency, butt_order, f_co);
```

```
sf = sample_frequency;
```

```
sec_windows = time_window;
```

```
N_points = round(sf*sec_windows);
```

```
SAX_array_non = timeseries2symbol_non_over(data, N_points, symbols_window, alph_size);
```

```
SAX_array_over = my_overlapping (data, N_points, symbols_window, alph_size);
```

```
% create the array of all intelligent icons, each in a row.
```

```
for i=1:size(SAX_array_non, 1)
```

```
    I_I_non = int_icon(SAX_array_non, word_length, alph_size, i);
```

```
    %figure(i);
```

```
    %heatmap(I_I_non,'Colormap',hot);
```

```
    I_I_non = reshape(I_I_non', [1, length(I_I_non)^2]);
```

```
    all_icons_non (i, :) = [I_I_non];
```

```
end
```

```
%save('intelligent_icons_non_3_8_x.mat','all_icons_non');
```

```
%the same for overlapping
```

```
for i=1:size(SAX_array_over, 1)
```

```
    I_I_over = int_icon(SAX_array_over, word_length, alph_size, i);
```

```
    %figure(i);
```

```
    %heatmap(I_I_over,'Colormap',hot);
```

```
    I_I_over = reshape(I_I_over', [1, length(I_I_over)^2]);
```

```
    all_icons_over (i, :) = [I_I_over];
```

```
end
```

```
%save('intelligent_icons_over_3_8_x.mat','all_icons_over');
```

```
%I_I_over = int_icon(SAX_array_over, 2, 4, 1);
```

```
end
```

```
function [filteredSignal] = filter_data_2(signal, f_sampling, b_filter_order, f_cutoff)
```

```
%function that filters data with median and butterworth filter
```

```
%INPUTS
```

```
%fileName: the file name
```

```
%dim: the direction x, y or z for which we want to apply sax
```

```
%f_co: cut frequency for butterworth filter
```

```
%f_s: sampling frequency for butterworth filter
```

```
%butt_order: the order of butterworth filter
```

```
data = signal; %export acceleration in one dimension as a vector
```

```
butt_order = b_filter_order;
```

```
f_co = f_cutoff;
f_s = f_sampling;

%Median Filtering in x_axis acceleration signal
filt_med = medfilt1(data, 5); % signal filtered with median filter 5th order

%Filtering Butterworth
[b,a] = butter(butt_order, f_co/(f_s/2), 'low'); %
filteredSignal = filter(b, a, filt_med); %signal after butterworth
%subplot(2,1,2);
%plot(time, filteredSignal);

%Save filtered signal in txt file
end
```

```
% a function that builds the SAX technique with non-overlapping windows.
% data : the filtered data as an input
% N : length of window as an input
% n : number of symbols in a window

function symbolic_data = timeseries2symbol(data, N, n, alphabet_size)

    subsec_size = floor(N/n); % length of subsection that form a symbol (in other words the
    number of data points that form a symbol)

    if alphabet_size > 20 % WARNING message. Restriction to alphabet_size
        disp('Currently alphabet_size cannot be larger than 20. Please update the breakpoint table
if you wish to do so');
        return;
    end

    data = (data - mean(data, 'omitnan'))./std(data, 'omitnan');

    normalized_windows = buffer (data, N); %Cut windows. Breaks data into segments of N
    points. Fills with zeros last column if length_data/N not an integer

    % normalized_windows = (windows - mean(windows, 'omitnan'))./std(windows, 'omitnan');
    %data broken in windows and after z-normalization
    [rows_norm, columns_norm] = size(normalized_windows);

    % take care of the special case where there is no dimensionality reduction
    if N == n
        PAA = mean(normalized_windows);
    else

        for i = 1:columns_norm
```

```

        sub_sections = buffer(normalized_windows(:,i), subsec_size); % divide every window
into n subsections
        PAA (i, :) = mean (sub_sections); %take the matrix of PAA approximation

    end
end

```

```

symbolic_data = map_to_symbol(PAA,alphabet_size); %take the final matrix of symbols
after calling a local function

```

```

% input: PAA matrix and the alphabet_size. Returns the SAX symbols

```

```

function symbol = map_to_symbol(PAA,alphabet_size)

```

```

    [rows_PAA, columns_PAA] = size(PAA);

```

```

    % define the breakpoints

```

```

    switch alphabet_size

```

```

        case 2, cut_points = [-inf 0];

```

```

        case 3, cut_points = [-inf -0.43 0.43];

```

```

        case 4, cut_points = [-inf -0.67 0 0.67];

```

```

        case 5, cut_points = [-inf -0.84 -0.25 0.25 0.84];

```

```

        case 6, cut_points = [-inf -0.97 -0.43 0 0.43 0.97];

```

```

        case 7, cut_points = [-inf -1.07 -0.57 -0.18 0.18 0.57 1.07];

```

```

        case 8, cut_points = [-inf -1.15 -0.67 -0.32 0 0.32 0.67 1.15];

```

```

        case 9, cut_points = [-inf -1.22 -0.76 -0.43 -0.14 0.14 0.43 0.76 1.22];

```

```

        case 10, cut_points = [-inf -1.28 -0.84 -0.52 -0.25 0 0.25 0.52 0.84 1.28];

```

```

        case 11, cut_points = [-inf -1.34 -0.91 -0.6 -0.35 -0.11 0.11 0.35 0.6 0.91 1.34];

```

```

        case 12, cut_points = [-inf -1.38 -0.97 -0.67 -0.43 -0.21 0 0.21 0.43 0.67 0.97 1.38];

```

```

        case 13, cut_points = [-inf -1.43 -1.02 -0.74 -0.5 -0.29 -0.1 0.1 0.29 0.5 0.74 1.02

```

```

1.43];

```

```

        case 14, cut_points = [-inf -1.47 -1.07 -0.79 -0.57 -0.37 -0.18 0 0.18 0.37 0.57 0.79

```

```

1.07 1.47];

```

```

        case 15, cut_points = [-inf -1.5 -1.11 -0.84 -0.62 -0.43 -0.25 -0.08 0.08 0.25 0.43

```

```

0.62 0.84 1.11 1.5];

```

```

        case 16, cut_points = [-inf -1.53 -1.15 -0.89 -0.67 -0.49 -0.32 -0.16 0 0.16 0.32

```

```

0.49 0.67 0.89 1.15 1.53];

```

```

        case 17, cut_points = [-inf -1.56 -1.19 -0.93 -0.72 -0.54 -0.38 -0.22 -0.07 0.07 0.22

```

```

0.38 0.54 0.72 0.93 1.19 1.56];

```

```

        case 18, cut_points = [-inf -1.59 -1.22 -0.97 -0.76 -0.59 -0.43 -0.28 -0.14 0 0.14

```

```

0.28 0.43 0.59 0.76 0.97 1.22 1.59];

```

```

        case 19, cut_points = [-inf -1.62 -1.25 -1 -0.8 -0.63 -0.48 -0.34 -0.2 -0.07 0.07 0.2

```

```

0.34 0.48 0.63 0.8 1 1.25 1.62];

```

```

        case 20, cut_points = [-inf -1.64 -1.28 -1.04 -0.84 -0.67 -0.52 -0.39 -0.25 -0.13 0

```

```

0.13 0.25 0.39 0.52 0.67 0.84 1.04 1.28 1.64];

```

```

        otherwise disp('Error! alphabet_size is too big');

```

```

    end

```

```

    for r = 1 : rows_PAA

```

```

        for c = 1 : columns_PAA

```



```
% cut_points <= PAA(r,c) returns ones or/and zeros.
% The sum of the above maps to the SAX symbols
symbol(r, c) = sum( cut_points <= PAA(r,c)); % order is now: a = 1, b = 2, c =
3..

    end
end

end
end

% A function that builds the SAX technique with overlapping windows.
% data : the filtered data as an input
% N : length of window as an input
% n : number of symbols in a window

function symbolic_data = my_overlapping(data, N, n, alphabet_size)

    subsec_size = floor(N/n); % length of subsection that form a symbol (in other words the
number of data points that form a symbol)

    if alphabet_size > 20 % WARNING message. Restriction to alphabet_size
        disp('Currently alphabet_size cannot be larger than 20. Please update the breakpoint table
if you wish to do so');
        return;
    end

    data = (data - mean(data, 'omitnan'))./std(data, 'omitnan');
    normalized_windows = buffer(data, N, round(1*N/2), 'nodelay'); % Cut windows. Breaks
data into segments of N points. Fills with zeros last column if length_data/N not an integer

% normalized_windows = (windows - mean(windows, 'omitnan'))./std(windows, 'omitnan');
% data broken in windows and after z-normalization
[rows_norm, columns_norm] = size(normalized_windows);

% take care of the special case where there is no dimensionality reduction
if N == n
    PAA = mean(normalized_windows);
else

    for i = 1:columns_norm
        sub_sections = buffer(normalized_windows(:,i), subsec_size); % divide every window
into n subsections
        PAA(i, :) = mean(sub_sections); % take the matrix of PAA approximation
    end
end

symbolic_data = map_to_symbol(PAA, alphabet_size); % take the final matrix of symbols
after calling a local function
```

```

% input: PAA matrix and the alphabet_size. Returns the
function symbol = map_to_symbol(PAA,alphabet_size)
[rows_PAA, columns_PAA] = size(PAA);

% define the breakpoints
switch alphabet_size
case 2, cut_points = [-inf 0];
case 3, cut_points = [-inf -0.43 0.43];
case 4, cut_points = [-inf -0.67 0 0.67];
case 5, cut_points = [-inf -0.84 -0.25 0.25 0.84];
case 6, cut_points = [-inf -0.97 -0.43 0 0.43 0.97];
case 7, cut_points = [-inf -1.07 -0.57 -0.18 0.18 0.57 1.07];
case 8, cut_points = [-inf -1.15 -0.67 -0.32 0 0.32 0.67 1.15];
case 9, cut_points = [-inf -1.22 -0.76 -0.43 -0.14 0.14 0.43 0.76 1.22];
case 10, cut_points = [-inf -1.28 -0.84 -0.52 -0.25 0 0.25 0.52 0.84 1.28];
case 11, cut_points = [-inf -1.34 -0.91 -0.6 -0.35 -0.11 0.11 0.35 0.6 0.91 1.34];
case 12, cut_points = [-inf -1.38 -0.97 -0.67 -0.43 -0.21 0 0.21 0.43 0.67 0.97 1.38];
case 13, cut_points = [-inf -1.43 -1.02 -0.74 -0.5 -0.29 -0.1 0.1 0.29 0.5 0.74 1.02
1.43];
case 14, cut_points = [-inf -1.47 -1.07 -0.79 -0.57 -0.37 -0.18 0 0.18 0.37 0.57 0.79
1.07 1.47];
case 15, cut_points = [-inf -1.5 -1.11 -0.84 -0.62 -0.43 -0.25 -0.08 0.08 0.25 0.43
0.62 0.84 1.11 1.5];
case 16, cut_points = [-inf -1.53 -1.15 -0.89 -0.67 -0.49 -0.32 -0.16 0 0.16 0.32
0.49 0.67 0.89 1.15 1.53];
case 17, cut_points = [-inf -1.56 -1.19 -0.93 -0.72 -0.54 -0.38 -0.22 -0.07 0.07 0.22
0.38 0.54 0.72 0.93 1.19 1.56];
case 18, cut_points = [-inf -1.59 -1.22 -0.97 -0.76 -0.59 -0.43 -0.28 -0.14 0 0.14
0.28 0.43 0.59 0.76 0.97 1.22 1.59];
case 19, cut_points = [-inf -1.62 -1.25 -1 -0.8 -0.63 -0.48 -0.34 -0.2 -0.07 0.07 0.2
0.34 0.48 0.63 0.8 1 1.25 1.62];
case 20, cut_points = [-inf -1.64 -1.28 -1.04 -0.84 -0.67 -0.52 -0.39 -0.25 -0.13 0
0.13 0.25 0.39 0.52 0.67 0.84 1.04 1.28 1.64];
otherwise disp('Error! alphabet_size is too big');
end

for r = 1 : rows_PAA
for c = 1 : columns_PAA

% cut_points <= PAA(r,c) returns ones or/and zeros.
% The sum of the above maps to the SAX symbols
symbol(r, c) = sum( cut_points <= PAA(r,c)); % order is now: a = 1, b = 2, c =
3..

end
end

end
end

```

```
% returns the intelligent icon of a specific window we choose from a SAX
% array

%INPUTS
%SAX_array: the array with sax symbols
%word_length: number of symbols that form a word e.g. a (=1), ba (=2), caa
%(=3), ... We will find the appearances of each word in a window
%alph_size: the number of letters available to characterize a PAA segment
>window_num: the number of window i want to calculate the intelligent icon

function ii = int_icon(SAX_array, word_length, alph_size, window_num)
    comb_num = permn([1:alph_size],word_length); % an array with all the combinations of
alphabet numbers

    str_comb = [""];
    %convert the array with all the combinations of alphabet numbers to string
    for i=1:length(comb_num)
        temp = mat2str(comb_num(i,:));
        temp = strrep(temp,['','']);
        temp = strrep(temp,[''],'');
        temp = strrep(temp,[' ','']);
        str_comb(i) = temp; % the array with string combinations of alphabet size
    end

    ii_array = [""]; %
    %convert the sax array to string array
    for i=1:size(SAX_array, 1)
        tt = mat2str(SAX_array(i,:));
        tt = strrep(tt,['','']);
        tt = strrep(tt,[''],'');
        window_string = strrep(tt,[''],'');
        ii_array(i,:) = window_string; %the sax array as string array
    end

    %find the appearances of every word within a window
    for j=1:length(comb_num)
        ii(j) = length(strfind(ii_array(window_num,:),str_comb(j)));
    end

    if rem(word_length, 2) == 0
        ii = reshape(ii, [alph_size^(word_length/2),alph_size^(word_length/2)]); %the
intelligent icon array
        ii = ii';
    else if (word_length==3 & (alph_size==4))
        ii = reshape(ii, [8, 8]); %the intelligent icon array
        ii = ii';
    else
end
```

```

    display ("These inputs can't form an intelligent icon");
end
end

```

```
end
```

```
function [M, I] = permn(V, N, K)
```

```
narginchk(2,3) ;
```

```
if fix(N) ~= N || N < 0 || numel(N) ~= 1 ;
```

```
    error('permn:negativeN','Second argument should be a positive integer') ;
```

```
end
```

```
nV = numel(V) ;
```

```
if nargin==2, % PERMN(V,N) - return all permutations
```

```
    if nV==0 || N == 0,
```

```
        M = zeros(nV,N) ;
```

```
        I = zeros(nV,N) ;
```

```
    elseif N == 1,
```

```
        % return column vectors
```

```
        M = V(:) ;
```

```
        I = (1:nV).';
```

```
    else
```

```
        % this is faster than the math trick used for the call with three
        % arguments.
```

```
        [Y {N:-1:1}] = ndgrid(1:nV) ;
```

```
        I = reshape(cat(N+1,Y{:}),[],N) ;
```

```
        M = V(I) ;
```

```
    end
```

```
else % PERMN(V,N,K) - return a subset of all permutations
```

```
    nK = numel(K) ;
```

```
    if nV == 0 || N == 0 || nK == 0
```

```
        M = zeros(numel(K), N) ;
```

```
        I = zeros(numel(K), N) ;
```

```
    elseif nK < 1 || any(K < 1) || any(K ~= fix(K))
```

```
        error('permn:InvalidIndex','Third argument should contain positive integers.') ;
```

```
    else
```

```
        V = reshape(V,1,[]) ; % v1.1 make input a row vector
```

```
        nV = numel(V) ;
```

```
        Npos = nV^N ;
```

```
        if any(K > Npos)
```

```
            warning('permn:IndexOverflow', ...
```

```
                'Values of K exceeding the total number of combinations are saturated.')
```

```
            K = min(K, Npos) ;
```

```
        end
```

```
% The engine is based on version 3.2 with the correction
% suggested by Roger Stafford. This approach uses a single matrix
% multiplication.
B = nV.^(1-N:0) ;
I = ((K(:)-.5) * B) ; % matrix multiplication
I = rem(floor(I),nV) + 1 ;
M = V(I) ;
end
end

clear all; clc;
s1='C:\Users\Lamprini\Desktop\track\multichannelling\db_synced_and_downsampled\'
d1=dir(s1);
d1=d1(~ismember({d1.name},{' ','..'}));
actcell = {'climbingdown', 'climbingup', 'jumping', 'lying', 'running', 'sitting', 'standing',
'walking'};
N = length (d1);
array_non{1}=[];    array_non{2}=[];
array_over{1}=[];  array_over{2}=[];
v_non{1} = [];     v_non{2} = [];
v_over{1}=[];     v_over{2}=[];
vertical_non{1} = [];  vertical_non{2} = [];
vertical_over{1} = []; vertical_over{2} = [];
tStart = tic;
for i=1:N % run through all subjects 1:N
    s_name = strcat(s1,d1(i).name);
    s_name = strcat(s_name,'\');
    d2 = dir(s_name);
    d2=d2(~ismember({d2.name},{' ','..'}));
    actn=length (d2);

    for j = 1:actn % run through all activities 1:actn
        act_name = strcat(s_name,d2(j).name);

        activitynumber = find_class(d2(j).name,actcell); %integer: 1-8
        if d2(j).bytes > 10
            d = csvread (act_name, 0,1);
            d_a = d(:,2:4); d_g = d(:, 5:7);
        else
            continue;
        end

        n = 3;
        % n = size(d,2)-1;
        tic
        for z = 1:2
            for k=1:n % run through all dimensions 1:n
                signal{1}=d_a(:,k); % accelerometer signal
                signal{2}=d_g(:,k); % gyroscope signal
            end
        end
    end
end
```

```

[symbols_non{z},symbols_over{z}] = sax_function(signal{z}, 50, 5, 20, 2.56, 32, 4,
3); %(raw data x,y,z axis, sampling freq, order of butterworth filter, cutoff freq of butterworth,
time/window, symbols/window, alphabet size, word length)

    array_non{z}=[array_non{z}; symbols_non{z}];

    array_over{z}=[array_over{z}; symbols_over{z}];
end
v_non{z} = vertical_icons(array_non{z}, 3, 4);
v_over{z} = vertical_icons(array_over{z}, 3, 4);
v_non{z} = [v_non{z} repmat(activitynumber,size(v_non{z}, 1), 1)
repmat(i,size(v_non{z}, 1), 1)];
v_over{z} = [v_over{z} repmat(activitynumber,size(v_over{z}, 1), 1)
repmat(i,size(v_over{z}, 1), 1)];
vertical_non{z}=[vertical_non{z}; v_non{z}];
vertical_over{z}=[vertical_over{z}; v_over{z}];
symbols_non{z} = [];
symbols_over{z} = [];
array_non{z} = [];
array_over{z} = [];

end
toc
disp(i)
disp(j)
tEnd = toc(tStart)
end
end

```

```

function vi = vertical_icons(array, word_length, alph_size)

```

```

    array = array';

    comb_num = permn([1:alph_size],word_length); % an array with all the combinations of
alphabet numbers
    step = size(array,2)/3;
    vi = [];
    for i=1:step
        xyz_window = [array(:, i) array(:, i+step) array(:, i+2*step)];
        for j=1:alph_size^word_length
            total(j) = length(find(ismember(xyz_window,comb_num(j,:), 'rows')));
        end
        vi = [vi; total];
    end
end
end

```

```

clear all; clc;
for j=1:2

```

```
non{j}=[]; over{j}= [];
end

a=load('SAX_4_3.mat');
b = load('vertical_icons.mat');
f1=fieldnames(a);
f2=fieldnames(b);
Data1=[a.(f1{1})];
Data2=[a.(f1{2})];
vert_non = [b.(f2{1})];
vert_over = [b.(f2{2})];

for j=1:2
    for n = 1:15
        for m = 1:8 % all activities
            d = bring (Data1 {j}, m, n); %call bring function for specific subject
            non{j} =[non{j}; d];
            e = bring (Data2 {j}, m, n);
            over{j} =[over{j}; e];
        end
    end
end
accxyz_gyrxyz_vert_non = [non{1}(:, 1:end-2) non{2}(:, 1:end-2) vert_non{1}(:,1:end-2)
vert_non{2}];
accxyz_gyrxyz_vert_over = [over{1}(:, 1:end-2) over{2}(:, 1:end-2) vert_over{1}(:, 1:end-2)
2) vert_over{2}];
save('multichannel_comparison_array.mat', 'accxyz_gyrxyz_vert_non',
'accxyz_gyrxyz_vert_over');
```

```
function b = bring(icon, activity, subject)
```

```
rows =size(icon,1);
columns = size (icon,2);
xs = []; ys = []; zs= [];

for i=1:rows
    if icon(i,(columns-1))==activity && icon(i,columns)==subject
        switch icon(i,(columns-2))
            case 1
                xs = [xs; icon(i, 1:(columns-3))];
            case 2
                ys = [ys; icon(i, 1:(columns-3))];
            case 3
                zs = [zs; icon(i, 1:(columns-3))];
        end
    end
end

end
activity = activity.*ones(size(xs,1),1);
```

```

    subject = subject.*ones(size(xs,1),1);
    b = [xs, ys, zs, activity, subject];
end

```

```
clear all; clc;
```

```

a=load('multichannel_comparison_array.mat');
f1=fieldnames(a);
Data1=[a.(f1{1})];
Data2=[a.(f1{2})];
mSAX_stats = cell(10,2); % 10 for 10 repetitions and 2 for non and over approach
simple_SAX_stats = cell(10,2); % 10 for 10 repetitions and 2 for non and over approach

```

```

array{1} = Data1;
array{2} = Data2;
class{1}=array{1}(:,(end-1));
class{2}=array{2}(:,(end-1));

```

```

for j = 1:2 %non and over data
    rep_ratios{j} = [];
    C_mSAX_all{j} = zeros(8); %mSAX confusion matrix
    C_simple_SAX_all{j} = zeros(8); %simple SAX confusion matrix
    for p = 1:10 %number of repetitions
        Train_data{j} = []; Test_data{j} = [];
        for i = 1:8
            S{j} = find(class{j} == i);
            L{j} = length(S{j});
            Temp{j} = S{j}(randperm(L{j}));
            Temp{j} = Temp{j}';
            tr{j} = round(0.8 * L{j});
            Train_ind{j} = Temp{j}(1:tr{j});
            Test_ind{j} = Temp{j}(tr{j}+1 : end);
            Train_data_act{j} = array{j}(Train_ind{j}, :);
            Test_data_act{j} = array{j}(Test_ind{j}, :);
            Train_data{j} = [Train_data{j}; Train_data_act{j}];
            Test_data{j} = [Test_data{j}; Test_data_act{j}];
        end
    end

```

```

class_train{j} = Train_data{j}(:,(end-1));
class_test{j} = Test_data{j}(:,(end-1));
% extract train and test dataset without mSAX icons to test the
% exact same dataset and compare models
train_simple_SAX{j} = Train_data{j}(:, 1:384);
test_simple_SAX{j} = Test_data{j}(:, 1:384);
neighbours = 1;

```

```

[pre_mSAX{j}, C_mSAX{j}] = just_knn(Train_data{j}(:, 1:end-2), Test_data{j}(:,
1:end-2), class_train{j}, class_test{j}, neighbours);

```

```
[pre_simple_SAX{j}, C_simple_SAX{j}] = just_knn(train_simple_SAX{j},  
test_simple_SAX{j}, class_train{j}, class_test{j}, neighbours);
```

```
C_mSAX_all{j} = C_mSAX_all{j} + C_mSAX{j};  
C_simple_SAX_all{j} = C_simple_SAX_all{j} + C_simple_SAX{j};
```

```
mSAX_stats{p,j} = confusionmatStats(C_mSAX{j});  
simple_SAX_stats{p,j} = confusionmatStats(C_simple_SAX{j});
```

```
T{j} =  
array2table(final_ratios{j}, 'VariableNames', {'Climbing_down', 'Climbing_up', 'Jumping',  
'Lying', 'Running', 'Sitting', 'Standing', 'Walking'});  
% T_all{j} = [T{j} array2table(final_all{j}, 'VariableNames', {'Overall_ratio'})];
```

```
end
```

```
classLabels = {'Climbing down'; 'Climbing up'; 'Jumping'; 'Lying'; 'Running'; 'Sitting';  
'Standing'; 'Walking'};  
classLabels = categorical(classLabels);  
figure('Name', 'mSAX');  
confusionchart(C_mSAX_all{j}, classLabels, 'RowSummary', 'row-normalized',  
'ColumnSummary', 'column-normalized');  
figure('Name', 'simpleSAX');  
confusionchart(C_simple_SAX_all{j}, classLabels, 'RowSummary', 'row-normalized',  
'ColumnSummary', 'column-normalized');  
all_mSAX{j} = sum(C_mSAX_all{j}, 'all');  
diag_mSAX{j} = trace(C_mSAX_all{j});  
accuracy_mSAX{j} = diag_mSAX{j} / all_mSAX{j};  
all_simple_SAX{j} = sum(C_simple_SAX_all{j}, 'all');  
diag_simple_SAX{j} = trace(C_simple_SAX_all{j});  
accuracy_simple_SAX{j} = diag_simple_SAX{j} / all_simple_SAX{j};  
end
```

```
function [pre, C] = just_knn(Train_data, Test_data, class_train, class_test, neighbours)  
    model = fitcknn(Train_data, class_train);  
    model.NumNeighbors = neighbours;  
    pre = predict(model, Test_data);
```

```
    C = confusionmat(class_test, pre);
```

```
end
```

```
function stats = confusionmatStats(group)  
field1 = 'confusionMat';  
if nargin < 2  
    value1 = group;  
else
```

```

    [value1,gorder] = confusionmat(group,grouphat);
end
numOfClasses = size(value1,1);
totalSamples = sum(sum(value1));
[TP,TN,FP,FN,accuracy,sensitivity,specificity,precision,f_score] =
deal(zeros(numOfClasses,1));
for class = 1:numOfClasses
    TP(class) = value1(class,class);
    tempMat = value1;
    tempMat(:,class) = []; % remove column
    tempMat(class,:) = []; % remove row
    TN(class) = sum(sum(tempMat));
    FP(class) = sum(value1(:,class))-TP(class);
    FN(class) = sum(value1(class,:))-TP(class);
end
for class = 1:numOfClasses
    accuracy(class) = trace(value1)/(totalSamples);
    sensitivity(class) = TP(class) / (TP(class) + FN(class));
    specificity(class) = TN(class) / (FP(class) + TN(class));
    precision(class) = TP(class) / (TP(class) + FP(class));
    f_score(class) = 2*TP(class)/(2*TP(class) + FP(class) + FN(class));
end
field2 = 'accuracy'; value2 = accuracy;
field3 = 'sensitivity'; value3 = sensitivity;
field4 = 'specificity'; value4 = specificity;
field5 = 'precision'; value5 = precision;
field6 = 'recall'; value6 = sensitivity;
field7 = 'Fscore'; value7 = f_score;
stats =
struct(field1,value1,field2,value2,field3,value3,field4,value4,field5,value5,field6,value6,field
7,value7);
if exist('gorder','var')
    stats =
struct(field1,value1,field2,value2,field3,value3,field4,value4,field5,value5,field6,value6,field
7,value7,'groupOrder',gorder);
end

```

```

clear all; clc;
s1='C:\Users\Lampri\l\Desktop\track\synced_and_downsampled\db_synced_and_downsampled\
ed\
d1=dir(s1);
d1(1:2) = [];
actcell = {'climbingdown', 'climbingup', 'jumping', 'lying', 'running', 'sitting', 'standing',
'walking'};
N = length (d1);
points = 128; %points for each window
data = [];
features_non{1}=[]; features_non{2}=[];
features_over{1}=[]; features_over{2}=[];

```

```

for i=1:N % run through all subjects 1:N
    s_name = strcat(s1,d1(i).name);
    s_name = strcat(s_name,'\');
    d2 = dir(s_name);
    d2=d2(~ismember({d2.name},{' ','..'}));
    actn=length (d2);
    for j = 1:actn % run through all activities 1:actn
        act_name = strcat(s_name,d2(j).name);

        activitynumber = find_class(d2(j).name,actcell); %integer: 1-8
        if d2(j).bytes > 10
            d = csvread (act_name, 1,1);
            d_a = d(:,1:3); d_g = d(:, 5:7);
        else
            continue;
        end

        n = 3;
    %    n = size(d,2)-1;
        for k=1:n % run through all dimensions 1:n
            signal{1}=d_a(:,k); % accelerometer signal
            signal{2}=d_g(:,k); % gyroscope signal
            tic
            for z = 1:2 % access the 2 cells of signal that contain acc and gyro
                data{z} = preprocess(signal{z}, 50, 5, 20);
                no_overlap_windows{z} = buffer (data{z}, points); %Cut windows.
                no_overlap_windows{z}(:, end)= []; % remove the last window as it conatians null
cells after buffering
                overlap_windows{z} = buffer (data{z}, points, round(1*points/2), 'nodelay');
                overlap_windows{z}(:, end)= []; % remove the last window as it conatians null cells
after buffering
                no_over_features{z} = feature_extraction(no_overlap_windows{z});
                overlap_features{z} = feature_extraction(overlap_windows{z});

                no_over_features{z}=[no_over_features{z}' repmat(k,size(no_over_features{z}', 1),
1)
repmat(i,size(no_over_features{z}', 1), 1),
repmat(i,size(no_over_features{z}', 1), 1)];
                features_non{z}=[features_non{z}; no_over_features{z}];
                overlap_features{z} = [overlap_features{z}' repmat(k,size(overlap_features{z}', 1),
1),
repmat(i,size(overlap_features{z}', 1), 1),
repmat(i,size(overlap_features{z}', 1), 1)];
                features_over{z} = [features_over{z}; overlap_features{z}];
            toc
        end
    end
end
end
end
end

```

```

function data = preprocess(signal, sample_frequency, butt_order, f_co)

    % cut 2% signal from the beginning and the end to remove undesirable points
    remove_points = round(size(signal,1)*2/100);
    signal = signal(remove_points+1:end-remove_points);
    filt_med = medfilt1(signal, 5);
    [b,a] = butter(butt_order, f_co/(sample_frequency/2), 'low'); % Returns the filter coefficients
    in length N+1. N = order of filter.
    filteredSignal = filter(b, a, filt_med);

    % z-normalization
    data = (signal - mean(signal, 'omitnan'))./std(signal, 'omitnan');

end

```

```

function features = feature_extraction(windows)
    elaxisto = min(windows);
    megisto = max(windows);
    mesos = mean(windows);
    p_power = bandpower(windows);
    ZCR = mean(abs(diff(sign(windows))));
    diakymansi = var(windows);
    kyrt = kurtosis(windows);
    assym = skewness(windows);
    root_mean_sq = rms(windows);
    med_freq = medfreq(windows);
    sh_entr = []; eucl_norm = []; mabs = []; sabs = [];
    for i=1:size(windows,2)
        entr = wentropy(windows(:,i),'shannon');
        sh_entr = [sh_entr entr];
        eucl = norm(windows(:,i));
        eucl_norm = [eucl_norm eucl];
        m = meanabs(windows(:,i));
        mabs = [mabs m];
        s = sumabs(windows(:,i));
        sabs = [sabs s];
    end
    athrisma = sum(windows);
    typikh = std(windows);
    F = fft(windows);
    pow = F.*conj(F);
    total_pow = sum(pow);
    % centr = spectralCentroid(windows,50);

    features = [elaxisto; megisto; mesos; p_power; ZCR; diakymansi; kyrt; assym;
    root_mean_sq; med_freq; sh_entr; eucl_norm; mabs; athrisma; typikh; total_pow];

end

```

```
clear all; clc;
array_1=[]; array_2 = [];

a1=load('SAX_non_50_2.56_32_4_3.mat');
f1=fieldnames(a1);
Data1=[a1.(f1{1})]; %export the 'non' data from .mat file

a2=load('SAX_over_50_2.56_32_4_3.mat');
f2=fieldnames(a2);
Data2=[a2.(f2{1})]; %export the 'over' data from .mat file

for m = 1:8 % run for all activities
    d = bring (Data1, m, 5); %call bring function for specific subject 'm'
    array_1 =[array_1; d]; %x, y, z horizontally for all activities and specific subject
    e = bring (Data2, m, 5); %call bring function for specific subject 'm'
    array_2 =[array_2; e]; %x, y, z horizontally for all activities and specific subject
end
class_1 = array_1(:,(end-1)); % the vector with all the classes = activities of array_1
class_2 = array_2(:,(end-1)); % the vector with all the classes = activities of array_2

D_1 = pdist(array_1(:,1:(end-2)),'Euclidean'); % one row-array with euclidian distances
between points
D_2 = pdist(array_2(:, 1:(end-2)),'Euclidean'); % one row-array with euclidian distances
between points

[Y_1, stress_1] = mdscale(D_1, 3,'criterion','metricstress', 'Start', 'random'); % apply mds for 3-
dimensions result
[Y_2, stress_2] = mdscale(D_2, 3,'criterion','metricstress', 'Start', 'random'); % apply md s for 3-
dimensions result
save('plots1.mat', 'Y_1', 'stress_1', 'Y_2', 'stress_2');

cmap = jet(8); % save colormap 'jet' for 8 colours
figure('Name',f1{1},'NumberTitle','off');
for m=1:8
    ind = find(class_1 == m); % indices of an activity
    plot3(Y_1(ind(1):ind(end),1),Y_1(ind(1):ind(end),2),Y_1(ind(1):ind(end),3), '!', 'color',
cmap(m,:), 'markersize',20);
    hold on;
end
legend('Climbing down','Climbing up', 'Jumping', 'Lying', 'Running', 'Sitting', 'Standing',
'Walking');
title('All activities, 5th subject');

figure('Name',f2{1},'NumberTitle','off');
for m=1:8
    ind = find(class_2 == m);
```

```
plot3(Y_2(ind(1):ind(end),1),Y_2(ind(1):ind(end),2),Y_2(ind(1):ind(end),3), '!', 'color',  
cmap(m,:), 'markersize',20);  
hold on;  
end  
legend('Climbing down','Climbing up', 'Jumping', 'Lying', 'Running', 'Sitting', 'Standing',  
'Walking');  
title('All activities, 5th subject');
```