

ΑΝΑΓΝΩΡΙΣΗ ΑΝΘΡΩΠΙΝΗΣ ΚΙΝΗΣΗΣ
ΜΕ ΧΡΗΣΗ ΔΕΔΟΜΕΝΩΝ
ΑΠΟ ΦΟΡΕΣΙΜΟΥΣ ΑΙΣΘΗΤΗΡΕΣ ΚΑΙ
ΕΦΑΡΜΟΓΗ ΑΛΓΟΡΙΘΜΩΝ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

της

ΜΑΡΙΑΣ ΤΡΙΑΝΤΑΦΥΛΛΟΥ

ΕΠΙΒΛΕΠΟΥΣΑ ΚΑΘΗΓΗΤΡΙΑ

ΚΑΤΕΡΙΝΑ ΤΖΗΜΟΥΡΤΑ

ΚΟΖΑΝΗ, ΟΚΤΩΒΡΙΟΣ 2024

(αυτή η σελίδα είναι σκόπιμα λευκή)

ΑΝΑΓΝΩΡΙΣΗ ΑΝΘΡΩΠΙΝΗΣ ΚΙΝΗΣΗΣ
ΜΕ ΧΡΗΣΗ ΔΕΔΟΜΕΝΩΝ
ΑΠΟ ΦΟΡΕΣΙΜΟΥΣ ΑΙΣΘΗΤΗΡΕΣ ΚΑΙ
ΕΦΑΡΜΟΓΗ ΑΛΓΟΡΙΘΜΩΝ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

της

ΜΑΡΙΑΣ ΤΡΙΑΝΤΑΦΥΛΛΟΥ

ΕΠΙΒΛΕΠΟΥΣΑ ΚΑΘΗΓΗΤΡΙΑ

ΚΑΤΕΡΙΝΑ ΤΖΗΜΟΥΡΤΑ

ΚΟΖΑΝΗ, ΟΚΤΩΒΡΙΟΣ 2024

(αυτή η σελίδα είναι σκόπιμα λευκή)

Περίληψη

Η αναγνώριση ανθρώπινης κίνησης (Human Activity Recognition - HAR) αποτελεί ένα ραγδαία αναπτυσσόμενο πεδίο της υπολογιστικής επιστήμης και της μηχανικής, με ευρεία εφαρμογή στην υγεία, τον αθλητισμό, και την ασφάλεια. Η αναγνώριση δραστηριοτήτων μέσω της καταγραφής της κίνησης ενός ατόμου χρησιμοποιεί φορέσιμους αισθητήρες, όπως επιταχυνσιόμετρα και γυροσκόπια, που τοποθετούνται στο σώμα και καταγράφουν δεδομένα για τη θέση, την ταχύτητα και την επιτάχυνση. Τα δεδομένα αυτά χρησιμοποιούνται για την ανάλυση και αναγνώριση των δραστηριοτήτων μέσω αλγορίθμων μηχανικής μάθησης.

Η παρούσα διπλωματική εργασία επικεντρώνεται στην ανάπτυξη ενός συστήματος για την αναγνώριση ανθρώπινης κίνησης με τη χρήση δεδομένων από φορέσιμους αισθητήρες. Η αναγνώριση της ανθρώπινης κίνησης είναι σημαντική γιατί επιτρέπει την αυτόματη κατηγοριοποίηση καθημερινών δραστηριοτήτων, όπως το περπάτημα και το τρέξιμο, και συμβάλλει στην παρακολούθηση της υγείας και της φυσικής κατάστασης. Η μεθοδολογία της εργασίας περιλαμβάνει την επεξεργασία δεδομένων από το MHEALTH dataset, ένα σύνολο δεδομένων που περιέχει καταγραφές κίνησης από 10 άτομα κατά την εκτέλεση 12 φυσικών δραστηριοτήτων. Αλγόριθμοι μηχανικής μάθησης, όπως τα Decision Trees, Random Forest, Support Vector Machine (SVM), Multilayer Perceptron (MLP) και k-Nearest Neighbor (k-NN), εκπαιδεύτηκαν για την αναγνώριση αυτών των δραστηριοτήτων. Οι αλγόριθμοι αυτοί μπορούν να κατηγοριοποιήσουν αυτόματα τις κινήσεις του ανθρώπου, παρέχοντας χρήσιμες πληροφορίες για την υγεία και τη φυσική του κατάσταση.

Τα αποτελέσματα της μελέτης δείχνουν ότι οι αλγόριθμοι μηχανικής μάθησης, όταν εκπαιδευτούν σωστά, μπορούν να προσφέρουν υψηλή ακρίβεια στην αναγνώριση και κατηγοριοποίηση της ανθρώπινης κίνησης. Συγκεκριμένα, αλγόριθμοι όπως ο k-Nearest Neighbor (k-NN) και το Random Forests είχαν τις καλύτερες επιδόσεις. Η μεθοδολογία αυτή μπορεί να αξιοποιηθεί σε συστήματα παρακολούθησης ασθενών, αθλητικών δραστηριοτήτων και ακόμα και στη φροντίδα ηλικιωμένων, βελτιώνοντας σημαντικά την ποιότητα ζωής. Τέλος, η εργασία επισημαίνει τις προκλήσεις που σχετίζονται με την ανάλυση των δεδομένων από φορέσιμους αισθητήρες, όπως η πολυπλοκότητα των αλγορίθμων και η ανάγκη για μεγάλες ποσότητες δεδομένων για την εκπαίδευση των μοντέλων. Προτείνονται επίσης κατευθύνσεις για μελλοντική έρευνα, όπως η περαιτέρω βελτίωση της ακρίβειας των αλγορίθμων και η ανάπτυξη φορητών συσκευών για την παρακολούθηση σε πραγματικό χρόνο.

Λέξεις - Κλειδιά

Αναγνώριση Ανθρώπινης Κίνησης (HAR), Φορέσιμοι Αισθητήρες, Μηχανική Μάθηση, Επιταχυνσιόμετρο, Γυροσκόπιο, Απόδοση Αλγορίθμων, Παρακολούθηση Υγείας, Πρόληψη Ατυχημάτων

Abstract

Human Activity Recognition (HAR) is a rapidly growing field in computing and engineering, characterized by the automatic identification of physical activities using wearable sensors. These sensors, such as accelerometers and gyroscopes, record data related to body movement, including position, speed, and acceleration. HAR has wide-ranging applications in healthcare, sports, and safety, offering potential solutions for monitoring health, enhancing athletic performance, and improving security.

This thesis focuses on the development of a method for automatic human activity recognition using wearable sensor data and machine learning (ML) algorithms. HAR is particularly important for monitoring daily activities, such as walking or running, and plays a crucial role in healthcare by enabling the automatic detection of abnormal movements. This is especially beneficial for elderly or vulnerable populations, where activity monitoring can prevent accidents and ensure timely health interventions. The methodology of this study involves the use of data from the MHEALTH dataset, which includes recordings from 10 individuals performing 12 different physical activities. Various ML algorithms, including Decision Trees, Random Forest, Support Vector Machine (SVM), Multilayer Perceptron (MLP), and k-Nearest Neighbor (k-NN), were trained to classify these activities. These algorithms can automatically categorize human movements, providing valuable insights into an individual's health and physical condition.

The results show that when properly trained, ML algorithms can offer high accuracy in recognizing and classifying human activities. Algorithms such as k-Nearest Neighbor (k-NN) and Random Forests demonstrated the best performance in this context. The application of HAR technologies in systems for patient monitoring, sports activity tracking, and elderly care could significantly enhance quality of life. Finally, the thesis discusses the challenges of analyzing wearable sensor data, such as the complexity of algorithms and the need for large datasets for training. It also proposes future research directions, including improving algorithmic accuracy and developing portable devices for real-time activity monitoring.

Keywords

Human Activity Recognition (HAR), Wearable Sensors, Machine Learning, Accelerometer, Gyroscope, Algorithm Performance, Health Monitoring, Accident Prevention

Δήλωση Πνευματικών Δικαιωμάτων

Δηλώνω ρητά ότι, σύμφωνα με το άρθρο 8 του Ν. 1599/1986 και τα άρθρα 2,4,6 παρ. 3 του Ν. 1256/1982, η παρούσα Διπλωματική Εργασία με τίτλο

«ΑΝΑΓΝΩΡΙΣΗ ΑΝΘΡΩΠΙΝΗΣ ΚΙΝΗΣΗΣ ΜΕ ΧΡΗΣΗ ΔΕΔΟΜΕΝΩΝ ΑΠΟ ΦΟΡΕΣΙΜΟΥΣ ΑΙΣΘΗΤΗΡΕΣ ΚΑΙ ΕΦΑΡΜΟΓΗ ΑΛΓΟΡΙΘΜΩΝ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ

» καθώς και τα ηλεκτρονικά αρχεία και πηγαίοι κώδικες που αναπτύχθηκαν ή τροποποιήθηκαν στα πλαίσια αυτής της εργασίας και αναφέρονται ρητώς μέσα στο κείμενο που συνοδεύουν, και η οποία έχει εκπονηθεί στο Διατμηματικό Πρόγραμμα Μεταπτυχιακών Σπουδών «Ψηφιακή Υγεία και Διοίκηση Υπηρεσιών Υγείας» των Τμημάτων Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών και Μαιευτικής του Πανεπιστημίου Δυτικής Μακεδονίας, υπό την επίβλεψη της κ. **Κατερίνας Τζημούρτα**

αποτελεί αποκλειστικά προϊόν προσωπικής εργασίας και δεν προσβάλλει κάθε μορφής πνευματικά δικαιώματα τρίτων και δεν είναι προϊόν μερικής ή ολικής αντιγραφής, οι πηγές δε που χρησιμοποιήθηκαν περιορίζονται στις βιβλιογραφικές αναφορές και μόνον. Τα σημεία όπου έχω χρησιμοποιήσει ιδέες, κείμενο, αρχεία ή / και πηγές άλλων συγγραφέων, αναφέρονται ευδιάκριτα στο κείμενο με την κατάλληλη παραπομπή και η σχετική αναφορά περιλαμβάνεται στο τμήμα των βιβλιογραφικών αναφορών με πλήρη περιγραφή.

Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας, εξ ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για σκοπό μη κερδοσκοπικό, εκπαιδευτικής ή ερευνητικής φύσης, υπό την προϋπόθεση να αναφέρεται η πηγή προέλευσης και να διατηρείται το παρόν μήνυμα. Ερωτήματα που αφορούν τη χρήση της εργασίας για κερδοσκοπικό σκοπό πρέπει να απευθύνονται προς τον συγγραφέα. Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον συγγραφέα και μόνο.

Copyright (C) Μαρία Τριανταφύλλου & Κατερίνα Τζημούρτα, 2024, Κοζάνη

Copyright (C).....Μαρία Τριανταφύλλου & Κατερίνα Τζημούρτα, 2024, Κοζάνη

Ευχαριστίες

Περιεχόμενα

ΠΕΡΙΛΗΨΗ	v
ABSTRACT	vi
ΔΗΛΩΣΗ ΠΝΕΥΜΑΤΙΚΩΝ ΔΙΚΑΙΩΜΑΤΩΝ	vii
ΕΥΧΑΡΙΣΤΙΕΣ	viii
ΠΕΡΙΕΧΟΜΕΝΑ.....	ix
ΚΑΤΑΛΟΓΟΣ ΕΙΚΟΝΩΝ	xi
ΚΕΦΑΛΑΙΟ 1: ΕΙΣΑΓΩΓΗ	12
1.1 Αντικείμενο της διπλωματικής	12
1.2 Οργάνωση της διπλωματικής.....	13
ΚΕΦΑΛΑΙΟ 2: ΒΙΒΛΙΟΓΡΑΦΙΚΗ ΑΝΑΣΚΟΠΗΣΗ	15
2.1 Ανθρώπινη κίνηση	15
2.1.1 Η ιστορία της κίνησης.....	15
2.1.2 Κίνηση και υγεία.....	17
2.2 Αναγνώριση Ανθρώπινης Κίνησης (Human Activity Recognition)	18
2.2.1 Τι είναι η αναγνώριση της ανθρώπινης κίνησης.....	18
2.2.2 Κατηγοριοποίηση	20
2.2.3 Χρησιμότητα.....	24
2.2.4 Εφαρμογές τεχνολογίας φορέσιμων αισθητήρων	25
2.3 Σχετικές Εργασίες	30
ΚΕΦΑΛΑΙΟ 3: ΜΕΘΟΔΟΛΟΓΙΑ	38
3.1 Περιγραφή της βάσης δεδομένων	38
3.2 Προπεξεργασία δεδομένων.....	42
3.3 Εκπαίδευση μοντέλων μηχανικής μάθησης.....	44
3.4 Επιλογή αλγορίθμων Μηχανικής Μάθησης.....	46
3.4.1 Decision Trees	46
3.4.2 Random Forests	47
3.4.3 Support Vector Machine.....	47
3.4.4 Multilayer Perceptron.....	48
3.4.5 k- Nearest Neighbor.....	48
ΚΕΦΑΛΑΙΟ 4: ΑΠΟΤΕΛΕΣΜΑΤΑ	49
ΚΕΦΑΛΑΙΟ 5: ΣΥΜΠΕΡΑΣΜΑΤΑ.....	58
5.1 Συμπεράσματα μεθοδολογίας	58

5.2 Μελλοντικές έρευνες	60
Βιβλιογραφία.....	63

ΚΑΤΑΛΟΓΟΣ ΕΙΚΟΝΩΝ

Εικόνα 1: Λεονάρντο ντα Βίντσι (Φαφούτη, 2013)	16
Εικόνα 2: Ανάλυση της ανθρώπινης κίνησης (Michalis Vrigkas, 2015)	20
Εικόνα 3: Ποσοστά σωστών και λάθος τοποθετημένων δεδομένων.....	49
Εικόνα 4: Πίνακας λεπτομερούς ακρίβειας με βάση την κλάση	50
Εικόνα 5: Πίνακας Confusion Matrix	50
Εικόνα 6: Ποσοστά σωστών και λάθος τοποθετημένων δεδομένων.....	50
Εικόνα 7: Πίνακας λεπτομερούς ακρίβειας με βάση την κλάση	51
Εικόνα 8: Πίνακας Confusion Matrix	51
Εικόνα 9: Ποσοστά σωστών και λάθος τοποθετημένων δεδομένων.....	52
Εικόνα 10: Πίνακας λεπτομερούς ακρίβειας με βάση την κλάση	52
Εικόνα 11: Πίνακας Confusion Matrix	53
Εικόνα 12: Ποσοστά σωστών και λάθος τοποθετημένων δεδομένων.....	53
Εικόνα 13: Πίνακας λεπτομερούς ακρίβειας με βάση την κλάση	54
Εικόνα 14: Πίνακας Confusion Matrix	54
Εικόνα 15: Ποσοστά σωστών και λάθος τοποθετημένων δεδομένων.....	54
Εικόνα 16: Πίνακας λεπτομερούς ακρίβειας με βάση την κλάση	55

ΚΕΦΑΛΑΙΟ 1: ΕΙΣΑΓΩΓΗ

1.1 Αντικείμενο της διπλωματικής

Η φυσική κίνηση ενός ατόμου είναι απόλυτα συνδεδεμένη με την κατάσταση υγείας και τον τρόπο ζωής του. Ο τρόπος με τον οποίο κινείται κάποιος μπορεί να υποδεικνύει προβλήματα υγείας που μπορεί να έχει, ψυχική ανισορροπία και γενικότερα μη φυσιολογικές δραστηριότητες. Για αυτό τον λόγο οι ερευνητές έκριναν απαραίτητο να βρουν έναν τρόπο με τον οποίο να μπορούν να καταγράψουν και να μελετήσουν την φυσική κίνηση των ανθρώπων και αυτή η διαδικασία ονομάστηκε Αναγνώριση Ανθρώπινης Κίνησης (Human Activity Recognition - HAR). (Abdul Kadar Masum, 2019)

Η αναγνώριση ανθρώπινης κίνησης αποτελεί ένα ταχέως αναπτυσσόμενο πεδίο έρευνας με ευρύ φάσμα εφαρμογών, από την ιατρική και τον αθλητισμό μέχρι την καθημερινή τεχνολογία και την ασφάλεια. Η χρήση φορέσιμων αισθητήρων έχει αναδειχθεί ως μια από τις πιο αξιόπιστες και αποτελεσματικές μεθόδους συλλογής δεδομένων για την ανάλυση της ανθρώπινης κίνησης. Οι αισθητήρες αυτοί, όπως είναι τα επιταχυνσιόμετρα και τα γυροσκόπια, μπορούν να καταγράφουν λεπτομερείς πληροφορίες σχετικά με τη θέση, την ταχύτητα και την επιτάχυνση του σώματος σε πραγματικό χρόνο.

Η ενσωμάτωση αυτών των δεδομένων σε αλγορίθμους μηχανικής μάθησης επιτρέπει την αυτοματοποιημένη και ακριβή αναγνώριση διαφόρων τύπων κίνησης. Οι αλγόριθμοι μηχανικής μάθησης μπορούν να εκπαιδευτούν, ώστε να αναγνωρίζουν συγκεκριμένες δραστηριότητες όπως είναι το περπάτημα, το τρέξιμο, το ανέβασμα σκάλας και άλλες καθημερινές δραστηριότητες. Επιπλέον, μπορούν να χρησιμοποιηθούν για την παρακολούθηση της υγείας και της φυσικής κατάστασης, την πρόληψη ατυχημάτων και την υποστήριξη της αποκατάστασης τραυματισμών.

Σκοπός αυτής της εργασίας είναι η αναγνώριση ανθρώπινης κίνησης μέσω της χρήσης δεδομένων από φορέσιμους αισθητήρες και η εφαρμογή αλγορίθμων μηχανικής μάθησης. Για το σκοπό αυτό, χρησιμοποιούνται δεδομένα που είναι διαθέσιμα στο διαδίκτυο με τίτλο MHEALTH, τα οποία περιλαμβάνουν καταγραφές κινήσεων σώματος από φορέσιμους αισθητήρες, όπως επιταχυνσιόμετρα και γυροσκόπια και

σημάτων ζωτικών λειτουργιών (ΕΚΓ) από 10 άτομα κατά τη διάρκεια της εκτέλεσης 12 φυσικών δραστηριοτήτων (περπάτημα, τρέξιμο, ποδηλασία, κ.ά.). Σε αυτό το πλαίσιο, η εργασία μελετά διαφορετικές μεθόδους μηχανικής μάθησης για τη βελτίωση της ακρίβειας και της αποδοτικότητας των αλγορίθμων στην αυτόματη ανίχνευση της ανθρώπινης κίνησης.

Η δυνατότητα των αλγορίθμων να αναγνωρίζουν και να ταξινομούν αυτόματα τις ανθρώπινες δραστηριότητες από τα δεδομένα των αισθητήρων έχει επιδείξει τεράστιες δυνατότητες, καθώς οι τεχνολογίες αυτές συνεχίζουν να βελτιώνονται και να εξελίσσονται. Η παρούσα εργασία φιλοδοξεί να συμβάλει στην ανάπτυξη προηγμένων μεθόδων αναγνώρισης ανθρώπινης κίνησης προσφέροντας νέες δυνατότητες για την αξιοποίηση των φορέσιμων αισθητήρων σε διάφορους τομείς της καθημερινής ζωής και της επιστήμης. Στο πρώτο κομμάτι αυτής της εργασίας γίνεται εκτενέστερη αναφορά στην Αναγνώριση της Ανθρώπινης Κίνησης (Human Activity Recognition – HAR), αναλύοντας λεπτομερέστερα τι είναι, πως λειτουργεί και σε ποιους τομείς χρησιμεύει. Στη συνέχεια, αναφέρονται κάποιες μελέτες που έχουν ήδη γίνει από ερευνητές πάνω στο συγκεκριμένο πεδίο και παρουσιάζονται αναλυτικά οι μέθοδοι και οι τεχνικές που χρησιμοποιήθηκαν για την ανάλυση και επεξεργασία των δεδομένων, καθώς και οι στρατηγικές που εφαρμόστηκαν για την εκπαίδευση των αλγορίθμων μηχανικής μάθησης. Τέλος, η εργασία ολοκληρώνεται με τη συζήτηση για τις δυνατότητες αυτών των τεχνολογιών να βελτιώσουν την ποιότητα ζωής των ανθρώπων και την ασφάλεια τους στο καθημερινό περιβάλλον. Εξετάζονται τα οφέλη και οι προκλήσεις που συνεπάγεται η ενσωμάτωση της HAR σε διάφορες εφαρμογές, καθώς και οι προοπτικές για μελλοντική έρευνα και ανάπτυξη στον τομέα. Ιδιαίτερη έμφαση δίνεται στην αξιοποίηση των δεδομένων από φορέσιμους αισθητήρες για την αυτόματη ανίχνευση και πρόβλεψη υγειονομικών καταστάσεων, την ανάπτυξη πιο προσωπικών προσεγγίσεων στη φροντίδα της υγείας και την αναβάθμιση των αθλητικών επιδόσεων.

1.2 Οργάνωση της διπλωματικής

Το *Κεφάλαιο 2* αναλύει γενικά στοιχεία που αφορούν την Αναγνώριση της Ανθρώπινης Κίνησης (HAR). Ξεκινά με μια επισκόπηση της ιστορίας της ανθρώπινης κίνησης, από τις πρώτες μελέτες μέχρι σήμερα, και εξετάζει τη σύνδεση της κίνησης με την υγεία και την ευημερία των ανθρώπων. Στη συνέχεια, παρουσιάζεται η HAR ως κλάδος της υπολογιστικής επιστήμης και μηχανικής, περιγράφοντας τις κατηγορίες στις οποίες

χωρίζεται, τη χρησιμότητά της, και τις εφαρμογές της τεχνολογίας φορέσιμων αισθητήρων τόσο στην επιστήμη όσο και στην καθημερινή ζωή.

Το *Κεφάλαιο 3* περιγράφει τη μεθοδολογία της εργασίας. Αναλύει τη βάση δεδομένων που χρησιμοποιήθηκε για τη λήψη των αποτελεσμάτων, τις μεθόδους προεπεξεργασίας των δεδομένων και τη διαδικασία εκπαίδευσης των αλγορίθμων μηχανικής μάθησης. Επιπλέον, περιγράφονται οι τεχνικές που χρησιμοποιήθηκαν για την επιλογή των αλγορίθμων, όπως τα Decision Trees, Random Forests, και Support Vector Machines, μεταξύ άλλων.

Το *Κεφάλαιο 4* παρουσιάζει τα αποτελέσματα της εφαρμογής των αλγορίθμων μηχανικής μάθησης. Καταγράφονται τα αποτελέσματα για κάθε αλγόριθμο, με ειδική αναφορά στην απόδοσή τους σε διαφορετικές μετρήσεις, όπως η ακρίβεια και η ταχύτητα. Γίνεται σύγκριση μεταξύ των αλγορίθμων και επισημαίνονται οι δυνατές και αδύναμες πλευρές του καθενός.

Το *Κεφάλαιο 5* περιλαμβάνει τα συμπεράσματα της εργασίας. Αναλύονται τα γενικά συμπεράσματα από τα αποτελέσματα των αλγορίθμων και οι επιπτώσεις τους στον τομέα της Αναγνώρισης Ανθρώπινης Κίνησης. Συζητούνται επίσης οι περιορισμοί της μελέτης και προτείνονται τρόποι βελτίωσης για μελλοντικές έρευνες σε μεγαλύτερα σύνολα δεδομένων, τη χρήση πιο προηγμένων αλγορίθμων μηχανικής μάθησης, και την ενσωμάτωσή τους σε συστήματα που λειτουργούν σε πραγματικό χρόνο για την παρακολούθηση της υγείας και την πρόληψη ατυχημάτων.

ΚΕΦΑΛΑΙΟ 2: ΒΙΒΛΙΟΓΡΑΦΙΚΗ ΑΝΑΣΚΟΠΗΣΗ


2.1 Ανθρώπινη κίνηση

2.1.1 Η ιστορία της κίνησης

Το ενδιαφέρον για την ανθρώπινη κίνηση έχει ξεκινήσει από τα πολύ παλιά χρόνια της ανθρώπινης ιστορίας. Η ανθρώπινη περιέργεια και οι ανάγκες που γεννιούνταν οδήγησαν τους ανθρώπους στο να μελετήσουν την ανθρώπινη κίνηση. Ακόμα και οι ανάγκες της επιστήμης ή των τεχνών οδήγησαν στη μελέτη του ανθρώπινου σώματος και της κίνησης που αυτό έχει.

Ο αρχαίος φιλόσοφος Αριστοτέλης (383 π.Χ. με 321 π. Χ.) είχε γράψει βιβλίο και είχε μελετήσει το βάδισμα των ζώων και ποια μέρη αυτού χρειάζονται για να παραχθεί κίνηση. Ακόμα και τα αγάλματα της εποχής υποδεικνύουν το επίπεδο γνώσης που κατείχαν οι άνθρωποι της εποχής σύμφωνα με τις πόζες και τις στάσεις που έδιναν σε αυτά.

Κατά την περίοδο της αναγέννησης ο Leonardo Da Vinci (1452- 1519) δήλωνε μέσα από τα σκίτσα του τη σημασία που έδινε στην ανατομία του σώματος και την εξοικείωση που είχε με λεπτομέρειες όπως τα νεύρα, τα οστά και οι μύες καθώς είχαν σημασία γιατί ανάλογα με τις δυνάμεις που αναπτύσσονται κάθε φορά με την κάθε κίνηση έπρεπε να αντικατοπτριστεί στο σκίτσο όσο πιο ρεαλιστικά γινόταν και η αντίδραση του σώματος στην κάθε δύναμη. Για παράδειγμα σε ένα σκίτσο του φαίνεται ένας άντρας να ανεβαίνει μια σκάλα. Στο τετράδιο του βρέθηκαν σημειώσεις που ανέλυν την κίνηση αυτή όπως είναι το γεγονός πως για να σηκώσει κάποιος το ένα του πόδι όλο του το βάρος πηγαίνει στο άλλο πόδι. Ένας άνθρωπος που ανεβαίνει μία σκάλα ρίχνει το βάρος του μπροστά και στο πόδι που στηρίζεται. Στην παρακάτω εικόνα (Εικόνα 1) επίσης φαίνεται με πόση λεπτομέρεια σχεδίαζε το ανθρώπινο σώμα πράγμα που υποδεικνύει τις γνώσεις του και τη μελέτη που είχε κάνει πάνω σε αυτό.



Εικόνα 1: Λεονάρντο ντα Βίντσι (Φαφούτη, 2013)

Φτάνοντας στην εποχή του διαφωτισμού δεν βλέπουμε μεγάλη εξέλιξη στη μελέτη της κίνησης πέρα από αυτό όμως εκείνη την περίοδο έχουμε την ανακάλυψη του Issac Newton (1642- 1727) που ήταν οι τρεις νόμοι της κίνησης που επίσης έπαιξαν τον ρόλο τους στην κατανόηση της ανθρώπινης κίνησης.

Έτσι ερχόμαστε στο 1874 όπου ο Γάλλος αστρονόμος Pierre Janssen (1824- 1907) κατάφερε να καταγράψει με μία κάμερα δικής του εφεύρεσης την Αφροδίτη που διέσχισε τον ήλιο. Η κάμερά του κατέγραψε σαράντα οκτώ λήψεις μέσα σε εβδομήντα δύο λεπτά σε έναν δίσκο. Αυτό ενέπνευσε και άλλους επιστήμονες όπως την Etienne-Jules Marey (1830- 1904) να μελετήσουν με αυτό τον τρόπο την κίνηση ανθρώπων και ζώων. Το ενδιαφέρον του Jassen για τη μελέτη της κίνησης τον οδήγησε στη σχεδίαση και άλλων ειδικών καμερών που του επέτρεπαν την καταγραφή μιας κίνησης σε φάσεις σε μία φωτογραφία.

Προς τα τέλη του 19^{ου} αιώνα ο Christian Wilhelm Braune (1831–1892) και ο Otto Fischer (1861–1917) ξεκίνησαν τις πειραματικές μελέτες πάνω στην ανθρώπινη βάδιση. Έτσι τον 20^ο αιώνα η βιομηχανική εξελίχθηκε σε κλάδο της επιστήμης αναλαμβάνοντας τα δικά τους προγράμματα και τις δικές τους μελέτες. (B. Rosenhahn, 2008)

2.1.2 Κίνηση και υγεία

Η κίνηση είναι θεμελιώδης και αναγκαία λειτουργία του ανθρώπινου σώματος. Δεν είναι συνώνυμο της άσκησης και είναι κάτι που γίνεται αυτόματα, χωρίς ιδιαίτερη προσπάθεια και σκέψη αλλά απαιτεί ενέργεια και δράση. Ως κίνηση ή φυσική δραστηριότητα ορίζεται οποιαδήποτε κίνηση παράγεται από το ανθρώπινο σώμα με τη συμμετοχή μυών και ενέργειας. (WHO, 2022)

Η κίνηση έχει θετικό αντίκτυπο στον ανθρώπινο οργανισμό. Επιγραμματικά, βοηθά στην διατήρηση της σωματικής υγείας και στην ενίσχυση διαφόρων συστημάτων όπως είναι το αναπνευστικό σύστημα, το κυκλοφορικό και το γαστρεντερικό σύστημα, ενισχύει το ανοσοποιητικό σύστημα του οργανισμού, αυξάνει την οστική πυκνότητα και διατηρεί το μυϊκό σύστημα σε καλή κατάσταση. Επίσης συνεισφέρει στην συναισθηματική υγεία του ατόμου καθώς μέσω της κίνησης εκκρίνονται διάφορες ορμόνες όπως είναι οι ενδορφίνες και η ντοπαμίνη οι οποίες βελτιώνουν την διάθεση και επιπλέον παρέχει την χαρά και ικανοποίηση της αυτοεξυπηρέτησης και προσωπικής φροντίδας. Τέλος ενισχύει και την ψυχική υγεία ενός ατόμου καθώς μειώνει το στρες και το άγχος.

Μέσα από πολλές έρευνες και μελέτες έχει αποδειχθεί πως η κίνηση και η φυσική δραστηριότητα ενισχύει τη μακροζωία και καθυστερεί την ανάπτυξη διαφόρων παθήσεων. Ακόμα και άτομα που πάσχουν από συγκεκριμένες ασθένειες έχει παρατηρηθεί ότι έχουν καλύτερη ποιότητα ζωής, καλύτερη έκβαση και ταχύτερη βελτίωση όταν υπάρχει η κίνηση στη ζωή τους.

Σύμφωνα με τον Παγκόσμιο Οργανισμό Υγείας, στο άρθρο που αναρτήθηκε το 2024 στην επίσημη σελίδα τους με θέμα «Φυσική Δραστηριότητα» (Tessa Strain, 2024) (Regina Guthhold, 2020) αναφέρεται πως παιδιά ηλικίας 5 έως 17 ετών θα πρέπει να ασκούνται για τουλάχιστον 60 λεπτά την ημέρα με άσκηση μέτριας ή έντονης έντασης. Ενήλικες ηλικίας από 18 έως 64 ετών θα πρέπει να κάνουν τουλάχιστον 150-300 λεπτά μέτριας έντασης αερόβια άσκηση εβδομαδιαίως ή διαφορετικά 75-150 λεπτά έντονης άσκησης εβδομαδιαίως ενώ άτομα άνω των 65 ετών θα πρέπει να κάνουν ότι και οι υπόλοιποι ενήλικες δίνοντας μια παραπάνω βάση σε δραστηριότητες που ενισχύουν τη σωματική δύναμη και την ισορροπία. (WHO, 2022)

Επιπρόσθετα η κίνηση ενός ατόμου μπορεί να μαρτυρά πολλά για τη φυσική του κατάσταση και τον τρόπο ζωής του. Ο τρόπος με τον οποίο κινείται κάποιος θα

Με σχόλια [ΚΤ1]: Να μπει αναφορά

μπορούσε να σχετίζεται με διάφορους παράγοντες υγείας που μπορεί να υπάρχουν όπως είναι για παράδειγμα κάποια καρδιακή νόσος, κάποια ψυχική νόσος και άλλα. (Abdul Kadar Masum, 2019) (C J Caspersen, 1985)

2.2 Αναγνώριση Ανθρώπινης Κίνησης (Human Activity Recognition)

2.2.1 Τι είναι η αναγνώριση της ανθρώπινης κίνησης

Αναγνώριση Ανθρώπινης Κίνησης (Human Activity Recognition- HAR) είναι η διαδικασία αναγνώρισης και μελέτης δραστηριοτήτων της καθημερινής ζωής χρησιμοποιώντας ένα σύνολο αισθητήρων και του κατάλληλου αλγορίθμου. Η ανθρώπινη κίνηση μπορεί να εκδηλωθεί μέσα από μια δραστηριότητα, από μία χειρονομία ή ακόμα και μέσα από μία συμπεριφορά και αυτά καταγράφονται από αισθητήρες. Στη συνέχεια τα δεδομένα κίνησης που θα συλλεχθούν μεταφράζονται από τον υπολογιστή και αναλύονται με τους κατάλληλους κώδικες. (Isakava, 2022)

Είναι ένας κλάδος της υπολογιστικής επιστήμης και της μηχανικής που δημιουργεί συστήματα και τεχνικές οι οποίες είναι ικανές να αναγνωρίσουν και να κατηγοριοποιήσουν αυτόματα τις ανθρώπινες ενέργειες με βάση δεδομένα που λαμβάνουν από αισθητήρες. Στις δραστηριότητες αυτές συμπεριλαμβάνονται το τρέξιμο, το κάθισμα, η έγερση, το περπάτημα όπως και οι πτώσεις. Συχνά καταγράφονται μέσω των καθημερινών εργασιών που γίνονται όπως είναι το να πάει κάποιος στη δουλειά του, μέσα από την άθληση κ.α.

Η φυσική κίνηση ενός ατόμου αποτελεί ένα πολύ σημαντικό στοιχείο για τον τρόπο ζωής κάποιου, επηρεάζει την αλληλεπίδραση μεταξύ δύο ατόμων αλλά και γενικότερα τις διαπροσωπικές σχέσεις των ανθρώπων. Ένας άνθρωπος με καρδιαγγειακές παθήσεις, για παράδειγμα, έχει διαφορετικό τρόπο ζωής από κάποιον που πάσχει από παθήσεις του αναπνευστικού συστήματος. Η έρευνα πάνω σε αυτές τις παθήσεις απαιτούν και την αναγνώριση της φυσικής δραστηριότητας που εκτελείται από τον άνθρωπο. Με την ανάδειξη και εξέλιξη αυτής της διαδικασίας, που ονομάζεται αναγνώριση ανθρώπινης κίνησης, η ανακάλυψη των παραγόντων που σχετίζονται με την ανθρώπινη κίνηση μπορούν να γίνουν ένα πολύ χρήσιμο εργαλείο. (Abdul Kadar Masum, 2019)

Σύμφωνα με τον Παγκόσμιο Οργανισμό Υγείας (<https://www.who.int/news-room/factsheets/detail/physical-activity>) η ανθρώπινη δραστηριότητα χωρίζεται σε δύο

κατηγορίες και είναι οι μέτριας έντασης δραστηριότητες και οι έντονης έντασης δραστηριότητες. Οι μέτριας έντασης δραστηριότητες απαιτούν λιγότερη ανθρώπινη ενέργεια για να εκτελεστούν όπως είναι το περπάτημα και η σίτιση σε αντίθεση με τις άλλες που απαιτούν μεγάλα ποσά ενέργειας όπως είναι το τρέξιμο.

Στόχος της Αναγνώρισης της Ανθρώπινης Κίνησης είναι να εξετάζει δραστηριότητες μέσα από βίντεο είτε εικόνες. Για τον λόγο αυτό οι κινήσεις είναι χωρισμένες σε κατηγορίες και τα συστήματα αναγνώρισης της ανθρώπινης δραστηριότητας έχουν σαν στόχο τη σωστή ταξινόμηση των δεδομένων που λαμβάνουν στην υποκείμενη κατηγορία. Ανάλογα με την πολυπλοκότητά τους οι ανθρώπινες κινήσεις χωρίζονται σε (Εικόνα 2):

- Χειρονομίες
- Ατομικές δραστηριότητες
- Δραστηριότητες ανάμεσα σε άνθρωπο με αντικείμενο ή άνθρωπο με άνθρωπο
- Ομαδικές δραστηριότητες
- Συμπεριφορές
- Εκδηλώσεις



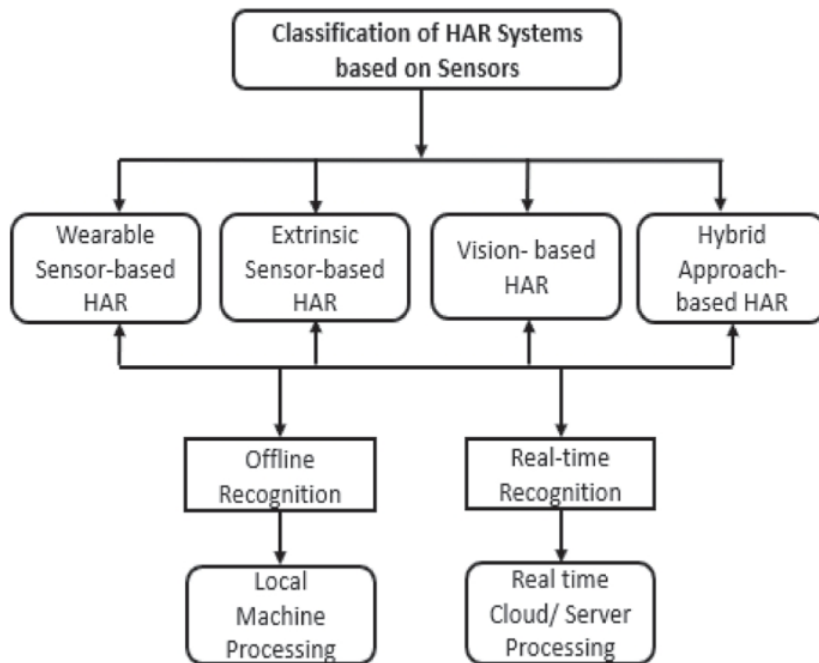
Εικόνα 2: Ανάλυση της ανθρώπινης κίνησης (Michalis Vrigkas, 2015)

Οι χειρονομίες αντιστοιχούν σε πρωτόγονες κινήσεις του σώματος που μπορεί να συνοδεύουν συγκεκριμένη ενέργεια, ατομικές δραστηριότητες είναι κινήσεις που κάνει ένα άτομο σαν μέρος μιας γενικότερης δραστηριότητας, δραστηριότητες ανάμεσα σε άνθρωπο με αντικείμενο ή άνθρωπο με άνθρωπο είναι όταν μέσα στην δραστηριότητα συμπεριλαμβάνεται κάποιο αντικείμενο ή κάποιο ακόμα άτομο και ομαδικές δραστηριότητες είναι όταν συμμετέχουν πολλά άτομα ταυτόχρονα. Οι συμπεριφορές αναφέρονται σε φυσικές κινήσεις που κάνει ένα άτομο και σχετίζονται με την προσωπικότητά του, την συναισθηματική και ψυχική του κατάσταση ενώ τα συμβάντα αντιστοιχούν σε καταστάσεις που περιγράφουν κοινωνικές ενέργειες μεταξύ ατόμων και αντιστοιχούν στον κοινωνικό ρόλο ενός ατόμου. (Michalis Vrigkas, 2015)

2.2.2 Κατηγοριοποίηση

Η HAR μπορεί να χωριστεί σε κατηγορίες ανάλογα τον τύπο του αισθητήρα και τον αλγόριθμο που χρησιμοποιεί (Εικόνα 3)

Ταξινόμηση με βάση τους αισθητήρες που χρησιμοποιούνται



Εικόνα 3: Κατηγοριοποίηση της HAR με βάση τους αισθητήρες (Nurul Amin Choudhury, 2023)

Ανάλογα με τους αισθητήρες που χρησιμοποιούνται κάθε φορά μπορούν να σχηματιστούν τέσσερις κατηγορίες HAR:

Στην πρώτη κατηγορία συμπεριλαμβάνεται η Αναγνώριση της Ανθρώπινης Κίνησης μέσω φορέσιμων αισθητήρων. Το σύστημα αυτό είναι το πιο διαδεδομένο και πολυχρησιμοποιημένο. Σε αυτή την περίπτωση τα δεδομένα συλλέγονται μέσω φορέσιμων αισθητήρων όπως είναι ένα γυροσκόπιο ή ένα επιταχυνσιόμετρο. Οι αισθητήρες αυτοί τοποθετούνται σε ένα ή περισσότερα σημεία πάνω στο ανθρώπινο σώμα με τη βοήθεια των κατάλληλων αξεσουάρ. Είναι από τις πιο συνηθισμένες μεθόδους καταγραφής δεδομένων και λόγω της καλής απόδοσής τους και λόγω της προσβασιμότητάς τους. Επίσης τα δεδομένα που συλλέγονται είναι αριθμητικά και δεν επηρεάζονται τα προσωπικά δεδομένα του ατόμου.

Στην επόμενη κατηγορία κατατάσσονται τα συστήματα που χρησιμοποιούν εξωτερικούς αισθητήρες. Μία άλλη μέθοδος καταγραφής της ανθρώπινης κίνησης είναι η λήψη δεδομένων με τη χρήση αισθητήρων εξωτερικού περιβάλλοντος και την κατηγοριοποίησή τους με τη βοήθεια αλγορίθμων μηχανικής μάθησης. Οι ερευνητές

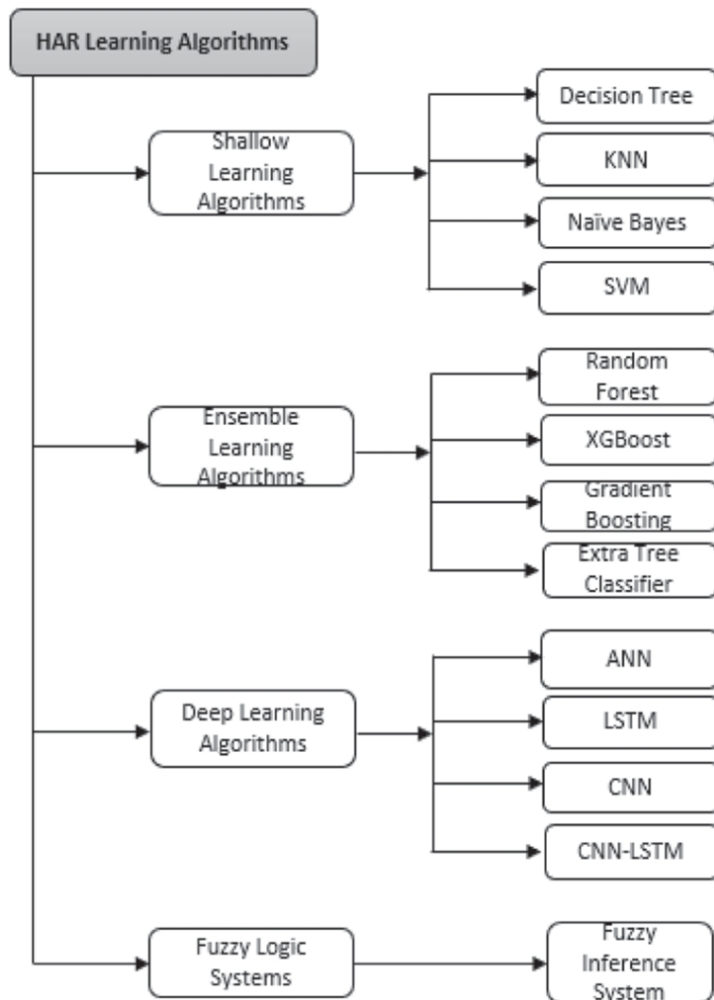
παρ' όλα αυτά δεν προτιμούν την συγκεκριμένη τακτική γιατί είναι αυτή με τα λιγότερο καλά αποτελέσματα.

Στην τρίτη κατηγορία είναι ανήκουν όσα βασίζονται σε οπτικά δεδομένα. Η κεντρική ιδέα είναι η λήψη πολλών εικόνων από μια δραστηριότητα μέσω κάμερας και η αποθήκευσή αυτών σε ένα σετ δεδομένων. Έτσι τα δεδομένα κατηγοριοποιούνται ανάλογα με τη δραστηριότητα που απεικονίζουν, αποθηκεύονται και είναι πάντα διαθέσιμα και μελέτη. Αυτά τα συστήματα είναι κατάλληλα για καταγραφή κίνησης όταν οι δραστηριότητες επιτυγχάνονται κυρίως σε μικρούς χώρους, όπως είναι το περιβάλλον ενός γραφείου ή σπιτιού. Η αναγνώριση βέβαια της ανθρώπινης κίνησης μέσω βίντεο ή καμερών όχι μόνο απαιτούν ακριβό εξοπλισμό και ιδιαίτερες συνθήκες που αν δεν υπάρχουν μπορεί να επιφέρουν δυσκολίες Επίσης και αυτή η μέθοδος δεν είναι πολύ διαδεδομένη λόγω του ότι δεν είναι ιδιαίτερα πρακτική.

Τέλος σε αυτή την κατηγορία συναντάμε τον συνδυασμό των προηγούμενων τεχνικών και ονομάζεται υβριδική προσέγγιση. Σε αυτό λοιπόν τον τελευταίο τρόπο λήψης στοιχείων για την ανθρώπινη κίνηση έχουμε συνδυασμό των φορέσιμων, του εξωτερικού περιβάλλοντος και τους οπτικούς αισθητήρες. Πολλοί προτιμούν αυτό τον τρόπο γιατί έχει πολύ καλά αποτελέσματα και μπορεί να ανταποκριθεί πολύ καλά στην καταγραφή ομαδικών δραστηριοτήτων.

Όλα αυτά τα συστήματα μπορούν να χρησιμοποιηθούν και σε πραγματικό χρόνο με τη χρήση δεδομένων σε πραγματικό χρόνο (online) αλλά και με δεδομένα εργαστηρίου (offline) καθώς έχουν τη δυνατότητα συλλογής και αποθήκευσης των δεδομένων. (Nurul Amin Choudhury, 2023)

Ταξινόμηση με βάση τους αλγορίθμους



Εικόνα 4: Αλγόριθμοι που χρησιμοποιούνται συχνά σε συστήματα HAR (Nurul Amin Choudhury, 2023)

Ανάλογα με τους αλγόριθμους που χρησιμοποιεί το κάθε σύστημα και πάλι έχουμε τέσσερις κατηγορίες αναγνώρισης της ανθρώπινης δραστηριότητας (Εικόνα 4).

Στην πρώτη κατηγορία ανήκουν οι αλγόριθμοι ρηχής μάθησης. Σε αυτή την κατηγορία ανήκουν οι αλγόριθμοι που βοηθούν στο να βρεθούν μοτίβα και σχέσεις σε συγκεκριμένα δεδομένα ώστε να έχουμε προβλέψεις και αποφάσεις. Βασίζονται συχνά σε δεδομένα που έχουν εξαχθεί από μια βάση και έχουν καταχωρηθεί χειροκίνητα χρησιμοποιώντας απλά μαθηματικά μοντέλα μάθησης. Συνήθως οι αλγόριθμοι αυτοί

είναι υπολογιστικά πιο αποτελεσματικοί σε σχέση με άλλες προσεγγίσεις εξαιτίας του απλού μοντέλου εκπαίδευσης που δεν απαιτεί ιδιαίτερες μαθηματικές δυνατότητες.

Στην δεύτερη κατηγορία ανήκουν οι αλγόριθμοι εκμάθησης συνόλου. Στην ουσία είναι η επέκταση των ρηχών αλγορίθμων. Αυτοί αποδίδουν καλύτερα από την άποψη των συνολικών πινάκων απόδοσης και λόγω των πολλαπλών βασικών μοντέλων και των πολλαπλών δοκιμών τους.

Στη συνέχεια είναι οι αλγόριθμοι βαθιάς μάθησης. Οι αλγόριθμοι αυτοί είναι ευρέως γνωστοί στη χρήση τους σε συστήματα που έχουν να κάνουν με την HAR γιατί είναι αποτελεσματικοί και έχουν την τάση να εξάγουν αυτόματα χαρακτηριστικά. Ο ανθρώπινος παράγοντας στη διαμόρφωση των χαρακτηριστικών δεν είναι απαραίτητος καθώς είναι έτσι φτιαγμένα ώστε να εξάγουν τα χαρακτηριστικά αυτόματα από μόνα τους. Το βασικό τους μειονέκτημα είναι ότι χρήζουν πολύωρης ενασχόλησης με τον υπολογιστή και έχουν σύνθετες παραμέτρους, εμπόδια που είναι δύσκολο να ξεπεραστούν. Ακόμα αυτά τα μοντέλα χρειάζονται μεγάλο πλήθος δεδομένων για να εκπαιδευτούν και να βγάλουν τα σωστά αποτελέσματα.

Τελευταία κατηγορία είναι τα συστήματα ασαφούς συμπεράσματος. Είναι ένα σύστημα που βασίζεται σε κανόνες και όπου σε μία καθαρή είσοδο δίνονται ασαφή χαρακτηριστικά και επεξεργάζεται μία καθαρή έξοδος από αυτή. Αυτή η μέθοδος είναι γρήγορη αλλά δεν αποδίδει καλύτερα από άλλες νεότερες μεθόδους. (Nurul Amin Choudhury, 2023)

2.2.3 Χρησιμότητα

Όπως αναφέραμε και παραπάνω η Ανάλυση της Ανθρώπινης Κίνησης μελετάται πολύ τα τελευταία χρόνια γιατί μπορεί να φανεί χρήσιμη σε διάφορους κλάδους και μπορεί να βρει εφαρμογή σε πολλά πεδία. Τα κύρια πεδία εφαρμογής της είναι:

- στα συστήματα παρακολούθησης ασθενών
- στην παρακολούθηση ασυνήθιστων περιστατικών και πτώσεων
- στην φροντίδα των ηλικιωμένων
- στην καθημερινή καταγραφή και παρακολούθηση της ρουτίνας ενός αθλητή
- στον βιομετρικό έλεγχο ταυτότητας
- στην ανάλυση της βάρδισης και

- στην πρόβλεψη ενεργειακής κατανάλωσης.

Ακόμα το περιβάλλον ενός έξυπνου σπιτιού μπορεί να βελτιωθεί μέσω της καθημερινής παρακολούθησης όπως επίσης και η δραστηριότητα της οδήγησης μπορεί να βελτιωθεί και να γίνεται με μεγαλύτερη ασφάλεια. Ένας ακόμη κλάδος που μπορεί να έχει εφαρμογή είναι οι στρατιωτικές δραστηριότητες και μπορεί να συμβάλει στον έλεγχο της εγκληματικότητας μέσω της παρακολούθησης. (N. C. Sri Harsha, 2021)

2.2.4 Εφαρμογές τεχνολογίας φορέσιμων αισθητήρων

Η υγειονομική περίθαλψη αποτελεί ένα από τα πιο θεμελιώδη αγαθά για την ανθρώπινη κοινωνία, διασφαλίζοντας την ευημερία και την ποιότητα ζωής των πολιτών. Ωστόσο, η ραγδαία ανάπτυξη των κοινωνιών έχει δημιουργήσει νέες προκλήσεις, καθώς οι ανάγκες για υγειονομικές υπηρεσίες συχνά υπερβαίνουν τις διαθέσιμες και προσβάσιμες παροχές. Η συνεχής αύξηση των απαιτήσεων για ποιοτική υγειονομική περίθαλψη καθιστά την ενίσχυση και αναβάθμιση των συστημάτων υγείας απόλυτη προτεραιότητα για τους επαγγελματίες του τομέα.

Η δομή και η αποτελεσματικότητα ενός συστήματος υγείας διαφέρει σημαντικά από χώρα σε χώρα, επηρεαζόμενη από τον πληθυσμό, το επίπεδο πολιτιστικής ανάπτυξης, τους φυσικούς πόρους και το κοινωνικοοικονομικό πλαίσιο κάθε χώρας. Σε αυτό το πλαίσιο, η προσαρμογή των συστημάτων υγείας στις ιδιαίτερες ανάγκες και συνθήκες κάθε κοινωνίας αποτελεί πρόκληση και απαιτεί στρατηγικό σχεδιασμό και προσαρμοστικότητα.

Η αυξημένη έμφαση που δίνεται στην υγεία και στην βελτίωση του ποιοτικού επιπέδου των υγειονομικών υπηρεσιών συμβάλλει στην ενίσχυση του ανταγωνισμού μεταξύ των υγειονομικών οργανισμών. Αυτός ο ανταγωνισμός, αν και απαιτητικός, λειτουργεί ως κινητήριος δύναμη για την καινοτομία και την ανάπτυξη του κλάδου. Οι υγειονομικοί οργανισμοί επιδιώκουν να προσφέρουν ανώτερες υπηρεσίες και να ανταποκρίνονται στις υψηλές προσδοκίες των ασθενών, ενισχύοντας έτσι τη συνολική ποιότητα της υγειονομικής περίθαλψης.

Συνολικά, η ανάπτυξη ενός επαρκούς και αποτελεσματικού συστήματος υγείας απαιτεί συνεργασία, επένδυση σε πόρους και συνεχή αναπροσαρμογή στις νέες ανάγκες και προκλήσεις. Μόνο έτσι μπορεί να διασφαλιστεί η παροχή υψηλού επιπέδου υγειονομικής φροντίδας που θα ανταποκρίνεται στις ανάγκες όλων των πολιτών, ανεξαρτήτως κοινωνικοοικονομικού ή πολιτισμικού υπόβαθρου.

Η αύξηση του προσδόκιμου ζωής και η γήρανση του παγκόσμιου πληθυσμού αποτελούν φαινόμενα που παρατηρούνται τα τελευταία χρόνια, αποτέλεσμα των σημαντικών προόδων που έχουν συντελεστεί στον τομέα της υγείας και της φαρμακευτικής αγωγής. Οι βελτιώσεις αυτές έχουν συμβάλει στην παράταση της ζωής και στην βελτίωση της ποιότητας ζωής των ηλικιωμένων. Ωστόσο, αυτή η εξέλιξη συνοδεύεται από νέες κοινωνικές και οικονομικές προκλήσεις, καθώς η ενεργός συμμετοχή των ηλικιωμένων στην κοινωνία καθίσταται ολοένα και πιο σημαντική.

Την τελευταία δεκαετία, πολλές χώρες βρίσκονται αντιμέτωπες με το ζήτημα της γήρανσης του πληθυσμού, το οποίο αποτελεί πηγή ανησυχίας για την κοινωνική συνοχή όσο και για την οικονομική σταθερότητα. Η ενίσχυση της υποστήριξης των ηλικιωμένων στις καθημερινές τους δραστηριότητες καθώς και η αύξηση της ασφάλειας, της ευημερίας και της αυτονομίας τους, αναδεικνύονται ως βασικές προτεραιότητες.

Επιπλέον, από έρευνες που έχουν διεξαχθεί στην Ευρώπη και την Αμερική και σύμφωνα με τον Παγκόσμιο Οργανισμό Υγείας, οι ηλικιωμένοι προτιμούν να λαμβάνουν την απαραίτητη φροντίδα στο οικιακό τους περιβάλλον παρά σε νοσοκομειακές μονάδες. Αυτή η προτίμηση υπογραμμίζει την ανάγκη για ανάπτυξη υπηρεσιών κατ' οίκον φροντίδας, οι οποίες θα επιτρέπουν στους ηλικιωμένους να διατηρούν την αυτονομία και την αξιοπρέπειά τους, παραμένοντας στο οικείο περιβάλλον τους. (WHO, 2015) (Mu- Hsing Kuo, 2016)

Η αυξημένη ανάγκη για υποστήριξη των ηλικιωμένων δημιουργεί νέες απαιτήσεις και ευκαιρίες στον τομέα της υγειονομικής περίθαλψης. Οι κυβερνήσεις και οι κοινωνικοί φορείς καλούνται να σχεδιάσουν και να εφαρμόσουν πολιτικές που θα ανταποκρίνονται στις μεταβαλλόμενες δημογραφικές συνθήκες, ενισχύοντας την κοινωνική ένταξη και την οικονομική συμμετοχή των ηλικιωμένων.

Η παροχή απομακρυσμένης φροντίδας στο σπίτι αποτελεί μια καινοτόμο προσέγγιση που επιτρέπει στα άτομα να παραμένουν στο οικείο και άνετο περιβάλλον τους αποφεύγοντας την ανάγκη νοσηλείας σε νοσοκομειακούς χώρους που συχνά συνεπάγεται υψηλό κόστος. Αυτή η προσέγγιση όχι μόνο μειώνει τα έξοδα αλλά και βελτιώνει την ποιότητα ζωής των ασθενών, επιτρέποντάς τους να διατηρούν την αυτονομία και την αξιοπρέπειά τους. (Ananda Mohon Ghosh, 2016)

Για την υποστήριξη αυτής της μεθόδου φροντίδας, έχουν αναπτυχθεί καινοτόμα συστήματα αισθητήρων που είναι οικονομικά προσιτά και εύκολα στη χρήση. Αυτά τα συστήματα μπορούν να εγκατασταθούν στο σπίτι του ασθενή και να καταγράφουν την ημερήσια κατάσταση της υγείας του, συμβάλλοντας στη διατήρηση της ασφάλειάς του. Οι συσκευές αυτές, που συχνά είναι φορέσιμες, έχουν τη δυνατότητα να συλλέγουν δεδομένα σε πραγματικό χρόνο παρέχοντας αξιόπιστες πληροφορίες τόσο για τους ζωτικούς δείκτες του ασθενή όσο και για την φυσική του δραστηριότητα.



Εικόνα 5: Απομακρυσμένη παρακολούθηση ασθενών (mTelehealth, 2020)

Πιο συγκεκριμένα, οι φορέσιμες συσκευές καταγράφουν σημαντικούς ζωτικούς δείκτες όπως η καρδιακή συχνότητα, η αρτηριακή πίεση, τα επίπεδα οξυγόνου στο αίμα και η θερμοκρασία του σώματος. Επιπλέον, παρακολουθούν την καθημερινή φυσική δραστηριότητα του ασθενή, όπως τα βήματα που κάνει, τις ώρες που είναι ενεργός και τις ώρες που ξεκουράζεται. Αυτά τα δεδομένα είναι εξαιρετικά χρήσιμα για την παροχή προληπτικής ιατρικής φροντίδας καθώς επιτρέπουν στους επαγγελματίες υγείας να εντοπίζουν έγκαιρα τυχόν ανωμαλίες και να λαμβάνουν τα απαραίτητα μέτρα.

Η ενσωμάτωση αυτών των τεχνολογιών στην καθημερινή ζωή των ασθενών προσφέρει πολλαπλά οφέλη. Οι ασθενείς αισθάνονται πιο ασφαλείς και προστατευμένοι, καθώς γνωρίζουν ότι η υγεία τους παρακολουθείτε συνεχώς. Οι οικογένειες των ασθενών είναι πιο ήρεμες γνωρίζοντας ότι οι αγαπημένοι τους λαμβάνουν την κατάλληλη φροντίδα χωρίς να χρειάζεται να εγκαταλείψουν το σπίτι τους.

Η τεχνολογία των αισθητήρων έχει σημειώσει αξιοσημείωτες βελτιώσεις τα τελευταία χρόνια, με σημαντικές προόδους όσον αφορά το σχήμα, το μέγεθος, το κόστος και τη γενικότερη παρουσία τους. Αυτές οι βελτιώσεις αντανακλούν την αυξημένη ανάγκη

και ζήτηση που παρατηρείτε σε διάφορους βιομηχανικούς κλάδους. Σε συνδυασμό με την ταχεία ανάπτυξη του Internet of Things (IoT) η εξέλιξη στην τεχνολογία των αισθητήρων είναι απαραίτητη για να καλύψει την αυξανόμενη ζήτηση και να ανταποκριθεί στις απαιτήσεις της αγοράς. (Sumit Majumder, 2017)

Οι αισθητήρες που συγκεντρώνουν τη μεγαλύτερη ζήτηση είναι οι φορέσιμοι και εκείνοι που σχετίζονται με την παρακολούθηση του περιβάλλοντος. Αυτοί οι αισθητήρες χρησιμοποιούνται από ερευνητές για διάφορες εφαρμογές όπως είναι η ανάλυση της βιάδισης, η αναγνώριση κίνησης και πολλές άλλες. Η ικανότητά τους να συλλέγουν ακριβή δεδομένα σε πραγματικό χρόνο καθιστά τους αισθητήρες αυτούς απαραίτητους σε πλήθος τομέων.

Ένα από τα πρωταρχικά μελήματα όταν πρόκειται για εφαρμογές που βασίζονται σε αισθητήρα είναι όπως ξανά είπαμε η ρύθμιση της τιμής τους στην αγορά καθώς και η διασφάλιση της ακρίβειας στη συλλογή των δεδομένων. Η βελτίωση της τεχνολογίας των αισθητήρων και η μείωση του θορύβου κατά τη συλλογή δεδομένων έχουν οδηγήσει σε σημαντικές επενδύσεις στον κλάδο της υγείας και του αθλητισμού.

Αισθητήρες όπως είναι οι αισθητήρες αδράνειας αρχικά είχαν χρησιμοποιηθεί σε εφαρμογές όπως είναι η πλοήγηση αεροσκαφών, πλοίων, χερσαίων οχημάτων και ρομπότ καθώς και σε διάφορες βιομηχανίες για την ανάλυση των κραδασμών. Η γρήγορη ανάπτυξη όμως της τεχνολογίας των μικρό- ηλεκτρομηχανικών συστημάτων οδήγησε στην ανάπτυξη αισθητήρων μικρού μεγέθους, ελαφριού τύπου και φθηνών σε κόστος. Έτσι πλέον πολλοί κατασκευαστές έχουν να προτείνουν αισθητήρες αδράνειας που είναι εύκολο να αποκτηθούν και να τοποθετηθούν. (Ferhat Attal, 2015)

Οι φορέσιμοι αισθητήρες που σκοπό έχουν την καταγραφή της υγείας κάποιου μπορεί να είναι σε διάφορες μορφές και ευέλικτοι στη χρήση τους, ενσωματώνονται ακόμα και στα ρούχα και είναι εύκολοι στην τοποθέτησή τους. Οι αισθητήρες που ήδη υπάρχουν πέρα από τις ζωτικές λειτουργίες που μπορούν να καταγράψουν μπορούν να λαμβάνουν τιμές ηλεκτροκαρδιογραφήματος και ηλεκτρομυογραφήματος. Για την καταγραφή της κίνησης χρησιμοποιούνται γυροσκόπια, επιταχυνσιόμετρα και αισθητήρες που καταγράφουν το μαγνητικό πεδίο.

Η συνεχής καταγραφή των φυσιολογικών παραμέτρων ενός ατόμου αποτελεί ένα εξαιρετικά πολύτιμο εργαλείο για την πρόγνωση και έγκαιρη διάγνωση ποικίλων καρδιαγγειακών, νευρολογικών και πνευμονολογικών παθήσεων σε πρώιμο στάδιο. Η

παρακολούθηση και ανάλυση της κίνησης σε πραγματικό χρόνο, παράλληλα, προσφέρει πολύτιμες πληροφορίες που μπορούν να συμβάλουν στην πρόληψη πτώσεων, την αξιολόγηση της βάδισης και τη λεπτομερή ανάλυση του ύπνου. Τα δεδομένα που συλλέγονται από αυτούς τους αισθητήρες έχουν τη δυνατότητα είτε να αποθηκεύονται για προσωπική χρήση του ατόμου είτε να αποστέλλονται στον προσωπικό του ιατρό για περαιτέρω ανάλυση και αξιολόγηση. Με αυτόν τον τρόπο εξασφαλίζεται μια ολοκληρωμένη και ακριβής παρακολούθηση της υγείας του ατόμου επιτρέποντας άμεσες και στοχευμένες ιατρικές παρεμβάσεις όταν κρίνεται απαραίτητο. (Sumit Majumder, 2017)

Η ιατρική διάγνωση και τα συστήματα παρακολούθησης των ασθενών αποτελούν έναν ακόμη τομέα όπου η αναγνώριση ανθρώπινης δραστηριότητας (HAR) μπορεί να βρει σημαντικές εφαρμογές. Η HAR προσφέρει αποτελεσματικές λύσεις που μπορούν να υποστηρίξουν τόσο τους κλινικούς ιατρούς όσο και τους επαγγελματίες υγείας στην απομακρυσμένη θεραπεία και παρακολούθηση ασθενών ή ατόμων που χρειάζονται συνεχή φροντίδα. Όπως αναφέρθηκε προηγουμένως, η HAR μπορεί να λειτουργήσει τόσο ως εργαλείο θεραπείας όσο και πρόγνωσης, με τη δυνατότητα να προλάβει ακόμη και θανάτους.

Η απομακρυσμένη παρακολούθηση ασθενών μέσω της HAR συμβάλλει σημαντικά στην αποφόρτιση των νοσοκομείων, μειώνοντας έτσι το φόρτο εργασίας των εργαζομένων και βελτιώνοντας τις παρεχόμενες υπηρεσίες υγείας. Παράλληλα, ενισχύεται η ικανότητα των μονάδων υγείας να παρέχουν επείγουσα φροντίδα και το σύστημα μπορεί να χρησιμοποιηθεί ακόμα και για την αντιμετώπιση αυτοκινητιστικών ατυχημάτων. (Ananda Mohon Ghosh, 2016) (Mohammed Al- khafajiy, 2019)

Με την ενσωμάτωση της HAR στην κλινική πρακτική διασφαλίζεται η άμεση και ακριβής παρακολούθηση των ασθενών επιτρέποντας στοχευμένες παρεμβάσεις όταν απαιτείται. Η χρήση τέτοιων τεχνολογιών όχι μόνο ενισχύει την ποιότητα της φροντίδας αλλά και βελτιώνει την αποδοτικότητα του υγειονομικού συστήματος συνολικά, παράγοντας μια πιο βιώσιμη και αποτελεσματική παροχή υπηρεσιών.

Η εξ αποστάσεως επίβλεψη μπορεί να εξυπηρετήσει μια ποικιλία ασθενών συμπεριλαμβανομένων εκείνων με χρόνιες παθήσεις, κινητικά προβλήματα και εκείνων που χουν σε απομακρυσμένες ή δυσπρόσιτες περιοχές, μακριά από αστικά κέντρα. Επιπλέον, μπορεί να υποστηρίξει ασθενείς που αναρρώνουν από χειρουργικές

επεμβάσεις καθώς και νεογνά που απαιτούν ειδική φροντίδα. Τα δεδομένα που συλλέγονται μέσω αυτής της παρακολούθησης μπορούν να αποθηκεύονται σε βάσεις δεδομένων παρέχοντας πολύτιμες πληροφορίες για μελλοντική χρήση, την προσαρμογή θεραπειών αλλά και για ερευνητικούς σκοπούς. Με αυτόν τον τρόπο βελτιώνεται επίσης η σχέση μεταξύ ασθενούς και γιατρού, καθώς επιτρέπεται η συνεχής παρακολούθηση και η εξατομικευμένη προσέγγιση στη φροντίδα του ασθενούς. (Mohammed Al- khafajiy, 2019)

Συνοψίζοντας σημειώνεται πως, χωρίς καμία αμφιβολία, ένας σημαντικός παράγοντας που διαμορφώνει τον τομέα της υγείας είναι η ραγδαία ανάπτυξη και εξέλιξη της τεχνολογίας. Παρά την ταχύτατη πρόοδο των κοινωνιών οι ανάγκες για ιατρική περίθαλψη αυξάνονται συνεχώς και η τεχνολογία διαδραματίζει καθοριστικό ρόλο στην ικανοποίηση αυτών των αναγκών. Στη σύγχρονη εποχή προηγμένα τεχνολογικά συστήματα υγείας είναι πλέον διαθέσιμα προσφέροντας υποστήριξη από τη λήψη αποφάσεων έως τη συλλογή πολύτιμων πληροφοριών.

Για να ενισχυθεί η ψηφιοποίηση αυτής της διαδικασίας έχει αναπτυχθεί μια πληθώρα αισθητήρων. Αυτοί οι αισθητήρες έχουν σχεδιαστεί για να διευκολύνουν το έργο των επαγγελματιών υγείας και να βελτιώσουν συνολικά τις τεχνολογικές διαδικασίες στον τομέα της υγείας. Οι αισθητήρες αυτοί επιτρέπουν τη συνεχή παρακολούθηση των ασθενών, την άμεση καταγραφή και ανάλυση δεδομένων και την υποστήριξη της λήψης κλινικών αποφάσεων συμβάλλοντας έτσι στην παροχή υψηλής ποιότητας φροντίδας και στην αποτελεσματική διαχείριση των πόρων υγείας. (Muhammed Ali Kutlay, 2015)

2.3 Σχετικές Εργασίες

Η αναγνώριση της ανθρώπινης κίνησης μέσω φορέσιμων αισθητήρων όπως έχει ήδη αναφερθεί είναι ένας τομέας που παρουσιάζει πολύ μεγάλο ενδιαφέρον τα τελευταία χρόνια και μελετάται από πολλούς ερευνητές. Οι φορέσιμοι αισθητήρες, όπως επιταχυνσιόμετρα, γυροσκόπια και μαγνητόμετρα, έχουν τη δυνατότητα να καταγράφουν λεπτομερείς πληροφορίες για τη σωματική δραστηριότητα σε πραγματικό χρόνο, επιτρέποντας την ανάπτυξη εφαρμογών που μπορούν να αναγνωρίζουν και να κατηγοριοποιούν τις κινήσεις του ανθρώπου με μεγάλη ακρίβεια. Η ανάπτυξη αυτών των συστημάτων αναγνώρισης ανθρώπινης κίνησης προσφέρει

πολλαπλά οφέλη, όπως η παρακολούθηση της υγείας, η ανίχνευση πτώσεων, η βελτίωση της φυσικής κατάστασης, και η υποστήριξη σε ιατρικές διαδικασίες. Επιπλέον, οι δυνατότητες χρήσης των δεδομένων που προέρχονται από φορέσιμους αισθητήρες επεκτείνονται και σε άλλους τομείς, όπως η ασφάλεια και η αθλητική απόδοση. Με τη χρήση αλγορίθμων μηχανικής μάθησης, τα δεδομένα αυτά μπορούν να μετατραπούν σε χρήσιμες πληροφορίες που προσφέρουν ουσιαστική γνώση για την ανθρώπινη κίνηση.

Οι μελέτες πάνω σε αυτόν τον τομέα (Jamie o' Halloran, 2019) επικεντρώνονται στην ανάπτυξη αλγορίθμων που μπορούν να αναλύσουν δεδομένα από αισθητήρες και να προσφέρουν ακριβή αποτελέσματα σχετικά με τις δραστηριότητες που εκτελεί ένα άτομο. Οι αλγόριθμοι μηχανικής μάθησης εκπαιδεύονται χρησιμοποιώντας σύνολα δεδομένων που περιλαμβάνουν καταγραφές φυσικών δραστηριοτήτων και εφαρμόζονται σε διάφορες ερευνητικές προσπάθειες για να αξιολογηθεί η ακρίβεια και η αποτελεσματικότητά τους. Στη βιβλιογραφία, εμφανίζονται διάφορα σύνολα δεδομένων που χρησιμοποιούνται από τους ερευνητές για να εκπαιδεύσουν τους αλγορίθμους τους. Παρακάτω αναλύονται κάποιες μελέτες που έχουν γίνει με τη χρήση των δεδομένων που είναι διαθέσιμα στο διαδίκτυο με τίτλο **MHEALTH**, το οποίο περιλαμβάνει καταγραφές κινήσεων σώματος από φορέσιμους αισθητήρες, όπως επιταχυνσιόμετρα και γυροσκόπια και σημάτων ζωτικών λειτουργιών (EKG) από 10 άτομα κατά τη διάρκεια της εκτέλεσης 12 φυσικών δραστηριοτήτων (περπάτημα, τρέξιμο, ποδηλασία, κ.ά.).

Οι Jamie O' και Halloran Edward Curry (Jamie o' Halloran, 2019) εξέτασαν διάφορες σωματικές δραστηριότητες με φορέσιμους αισθητήρες αδράνειας. Ο στόχος τους ήταν αρχικά να διερευνήσουν κατά πόσο η ανθρώπινη κίνηση και οι ζωτικοί δείκτες μπορούν να καταγραφούν και να επεξεργαστούν με τέτοιο τρόπο ώστε να τροφοδοτήσουν μοντέλα μηχανικής μάθησης. Επιπλέον, σύγκριναν διάφορα μοντέλα μηχανικής μάθησης για να διαπιστώσουν πιο από αυτά αποδίδει καλύτερα στην ανάλυση των δεδομένων. Τα μοντέλα που χρησιμοποιήθηκαν περιλάμβαναν τα μοντέλα Extreme Gradient Boosting (XGBoost), Multilayer Perceptron (MLP), Convolutional Neural Network (CNN), Long Short- Term Memory Network (LSTM), CNN+ LSTM Hybrid (ConvLSTM) Autoencoder Random Forests(AE w/RF). Για την προσαρμογή εισόδου των σημάτων στα νευρωνικά δίκτυα (Muhammed Ali Kutlay, 2015), τον διαχωρισμό σετ εκπαίδευσης και δοκιμής, τη ρύθμιση των υπερπαραμέτρων, τη συλλογή του

Με σχόλια [ΚΤ2]: Να μπει αναφορά

μοντέλου και την αξιολόγησή του χρησιμοποιήθηκε η μεθοδολογία που πρότειναν οι Muhammed Ali Kutlay και Sadina Gagula- Palalic. Από τα αποτελέσματα που παρουσιάζουν φαίνεται ότι τα μοντέλα MLP και XGBoost παράγουν καλύτερες τιμές στην επεξεργασία σε σχέση με τα άλλα μοντέλα όπως φαίνεται και παρακάτω στον Πίνακα 1 καθώς και οι δύο μοντέλα επιδεικνύουν την ικανότητα να διακρίνουν επιτυχώς παρόμοιες δραστηριότητες όπως το χαλαρό τρέξιμο (jogging) από το κανονικό τρέξιμο.

Αρχιτεκτονική (Architecture)	Ακρίβεια (Accuracy)	Ακρίβεια (Precision)	Ανάκληση (Recall)
MLP	90.55%	91.66%	90.55%
XGBoost	89.97%	90.09%	89.97%
CNN	83.91%	83.47%	83.91%
ConvLSTM	83.89%	83.69%	83.89%
AE w/RF	83.27%	82.59%	83.25%
LSTM	78.09%	74.86%	78.09%

Πίνακας 1: Σύγκριση accuracy, precision και recall για τη μελέτη των Jamie o' Halloran, 2019

Οι Muhammed Ali Kutlay και Sadina Gagula- Palalic (Muhammed Ali Kutlay, 2015) στην μελέτη που διεξήγαγαν είχαν σαν στόχο τον προσδιορισμό μη κανονικών διαδικασιών χρησιμοποιώντας δεδομένα μέσα από την ανθρώπινη κίνηση και τους ζωτικούς δείκτες εθελοντών. Σκοπός τους ήταν αυτά να χρησιμοποιηθούν αυτά τα δεδομένα για τη διάγνωση συγκεκριμένων παθήσεων πριν εμφανιστούν καθώς και για την αποφυγή τους. Επιπλέον, τα αποτελέσματα της έρευνας μπορούν να εφαρμοστούν στην παρακολούθηση των κινήσεων ασθενών ή ηλικιωμένων ατόμων με στόχο την καταγραφή οποιαδήποτε ανεπιθύμητης κίνησης εκτελούν που μπορεί να οδηγήσει σε τραυματισμό ή πτώση.

Για την ανάλυση των δεδομένων χρησιμοποιήθηκαν δύο είδη αλγορίθμων: ο Multilayer Perceptron (MLP) και ο Support Vector Machines (SVM). Τα αποτελέσματα αυτών των αλγορίθμων συγκρίθηκαν μεταξύ τους ώστε να καθοριστεί ποιος είναι πιο κατάλληλος για την ανάλυση τέτοιου είδους δεδομένων.

Από τα αποτελέσματα που παρουσίασαν φαίνεται ότι ο Multilayer Perceptron (MLP) παράγει καλύτερες τιμές ακρίβειας, παρόλο που είναι πιο αργός σε ρυθμό επεξεργασίας. Αντίθετα, ο αλγόριθμος Support Vector Machine (SVM) είναι πιο γρήγορος αλλά έχει μικρότερη ακρίβεια (Πίνακας 2). Όπως αναφέρουν και οι ίδιοι αυτή η έρευνα αποτελεί ένα σημείο εκκίνησης για μελλοντικές έρευνες που στόχο θα έχουν τη βελτίωση των αλγορίθμων μηχανικής μάθησης με απώτερο σκοπό την ακόμη πιο ενεργό χρήση τους στον τομέα της υγείας.

Αρχιτεκτονική (Architecture)	Ακρίβεια (Accuracy)	Ακρίβεια (Precision)	Ανάκληση (Recall)
Multilayer Perceptron	91.70%	95.5%	94.2%
Support Vector Machine	83.21%	84.6%	96.3%

Πίνακας 2: Σύγκριση του accuracy, precision και recall για τα προτεινόμενα μοντέλα μηχανικής μάθησης για τη μελέτη των Muhammed Ali Kutlay, 2015

Οι Loknath Sai Ambati και Omar El-Gayar (Loknath Sai Ambati, 2021) στην δική τους εργασία είχαν σαν μοναδικό στόχο να μελετήσουν την επίδοση διαφόρων τεχνικών μηχανικής μάθησης που χρησιμοποιούνται στην Αναγνώριση της Ανθρώπινης Κίνησης. Οι αλγόριθμοι και μέθοδοι που μελέτησαν ήταν οι Naïve Bayes, Support Vector Machine, K- Nearest Neighbor, Logistic Regression, Stochastic Gradient Descent, Decision Tree, Decision Tree with entropy, Random Forest, Gradient Boosting Decision Tree και NG Boost. Η μελέτη έγινε σε τρία διαφορετικά σύνολα δεδομένων, το Pamap2, το SWELL και το MHealth όπου και στα τρία σύνολα τα δεδομένα υποβλήθηκαν στην ελάχιστη προ επεξεργασία για την αντιμετώπιση των τιμών που έλειπαν και την εξαίρεση δεδομένων κατά τη διάρκεια του μεταβατικού σταδίου. Στον παρακάτω πίνακα (Πίνακας 3) θα παρατεθούν τα αποτελέσματα από το σύνολο δεδομένων MHealth όπως αυτά παρουσιάστηκαν από τους μελετητές.

Αρχιτεκτονική (Architecture)	Ακρίβεια (Accuracy)	Ακρίβεια (Precision)	Ανάκληση (Recall)
Naïve Bayes	52.1%	52%	52%
Support Vector Machines	96.5%	97%	97%
k-Nearest Neighbor	99.1%	99%	99%

SGD	62.9%	63%	63%
Logistic Regression	73.8%	72%	74%
Decision Tree	91.1%	91%	91%
Decision Tree with Entropy	91.8%	92%	92%
Random Forests	93.9%	94%	94%
XGBoost	93.4%	94%	93%
NGBoost	87.5%	87%	87%

Πίνακας 3: Οι τιμές accuracy, precision και recall που απέδωσε ο κάθε αλγόριθμος για τη μελέτη των Loknath Sai Ambati, 2021

Το αποτέλεσμα στο οποίο κατέληξαν οι μελετητές ήταν ότι την καλύτερη απόδοση για τα MHealth δεδομένα είχε ο αλγόριθμος KNN παρόλο που είναι αυτός που χρειάζεται περισσότερο χρόνο από τους υπόλοιπους κατά την εκτέλεσή του. Επίσης τόνισαν τη σημασία προσαρμογής του κατάλληλου αλγορίθμου ανάλογα τα δεδομένα τα οποία πρόκειται να μελετηθούν και τα αντίστοιχα χαρακτηριστικά τους.

Στη συνέχεια ακολουθεί ένας συγκεντρωτικός πίνακας (Πίνακας 4) με τα αποτελέσματα από την επεξεργασία των δεδομένων που εξετάστηκαν στις παραπάνω έρευνες. Παρόλο που κάποιοι ερευνητές χρησιμοποίησαν τους ίδιους αλγορίθμους για τα ίδια δεδομένα τα αποτελέσματα που έλαβαν διαφέρουν. Αυτό οφείλεται στη διαφορετικές παραμέτρους που επέλεξε κάθε ερευνητής κατά την εκτέλεση των αλγορίθμων.

Αρχιτεκτονική (Architecture)	Ακρίβεια (Accuracy)	Ακρίβεια (Precision)	Ανάκληση (Recall)
Multilayer Perceptron	90.55%/ 91.70%	91.66%/ 95.5%	90.55%/94.2%
XGBoost	89.97%/ 93.4%	90.09%/ 94%	89.97%/ 93%
CNN	83.91%	83.47%	83.91%
ConvLSTM	83.89%	83.69%	83.89%

<i>AE w/RF</i>	83.27%	82.59%	83.25%
<i>LSTM</i>	78.09%	74.86%	78.09%
<i>Support Vector Machine</i>	83.21%/ 96.5%	84.6%/97%	96.3%/97%
<i>Naïve Bayes</i>	52.1%	52%	52%
<i>KNN</i>	99.1%	99%	99%
<i>SGD</i>	62.9%	63%	63%
<i>Logistic Progression</i>	73.8%	72%	74%
<i>Decision Tree</i>	91.1%	91%	91%
<i>DT with entropy</i>	91.8%	92%	92%
<i>Random Forest</i>	93.9%	94%	93%
<i>NGBoost</i>	87.5%	87%	87%

Πίνακας 4: Συγκριτικός πίνακας αποτελεσμάτων από τις έρευνες που μελετήθηκαν

Συγκρίνοντας τους αλγορίθμους που μελετήθηκαν στις παραπάνω έρευνες, τα αποτελέσματα καταδεικνύουν ότι ο αλγόριθμος K- Nearest Neighbor προσφέρει τις καλύτερες επιδόσεις κατά τη χρήση του. Τα αμέσως καλύτερα αποτελέσματα προσφέρει ο αλγόριθμος Random Forests.

Άλλοι ερευνητές έχουν επικεντρωθεί στην προεπεξεργασία και ανάλυση των δεδομένων με σκοπό τη βελτίωση των αποτελεσμάτων τους. Οι Abdul Kadar Muhammad Masum et al., για παράδειγμα (Abdul Kadar Masum, 2019), διεξήγαγαν μια έρευνα για να μελετήσουν δύο διαφορετικές μεθόδους επεξεργασίας δεδομένων με τη χρήση πέντε αλγορίθμων. Οι αλγόριθμοι αυτοί είναι οι Random Forests (RF), Support Vector Machines (SVM), Naïve Bayes (NB), Multilayer Perceptron (MLP) και Deep Convolutional Neural Network (CNN).

Στην πρώτη μέθοδο απομακρύνθηκαν όλες οι μηδενικές τιμές (null label) που εμφανίστηκαν κατά την επεξεργασία των δεδομένων. Αυτές οι τιμές δεν αντιπροσωπεύουν καμία φυσική δραστηριότητα και η απομάκρυνσή τους δεν θα είχε κανένα αντίκτυπο στην αναγνώριση των υπόλοιπων φυσικών δραστηριοτήτων.

Παρακάτω παρουσιάζονται τα αποτελέσματα μετά την εφαρμογή της πρώτης μεθόδου, όπως φαίνεται στον Πίνακα 5.

	Classifiers	Accuracy	Precision	Recall
Base Level Classifier	Native Bayes	90.26%	87.32%	89.72%
	Random Forest	91.63%	91.9%	92.1%
	SVM	94.69%	94.2%	94.2%
Deep Level Classifier	MLP	96.66%	96.31%	96.48%
	Deep CNN	99.8%	99.3%	99.67%

Πίνακας 5: Παρουσίαση αποτελεσμάτων μετά την αφαίρεση των μηδενικών τιμών

Στη δεύτερη προσπάθεια για μείωση της δυσαναλογίας των αποτελεσμάτων η μέθοδος που ακολουθήθηκε ήταν η χρήση ενός συγκεκριμένου φίλτρου στο πρόγραμμα WEKA. Το φίλτρο αυτό ρυθμίζει την ανισορροπία των τιμών σε κάθε κλάση. Ακολουθεί ο Πίνακας 6 με τα αποτελέσματα μετά την εφαρμογή της δεύτερης μεθόδου και του φίλτρου ισορροπίας.

	Classifiers	Accuracy	Precision	Recall
Base Level Classifier	Native Bayes	71.46%	69.70%	71.50%
	Random Forest	89.28%	91.40%	89.60%
	SVM	78.46%	77.70%	78.50%
Deep Level Classifier	MLP	91.69%	91.40%	91.70%
	Deep CNN	98.48%	98.50%	98.50%

Πίνακας 6: Παρουσίαση αποτελεσμάτων μετά την εφαρμογή του φίλτρου ισορροπίας

Από τα αποτελέσματα που παρουσίασαν κατέληξαν στο συμπέρασμα ότι μεταξύ των δύο μεθόδων υπερισχύει η τεχνική αφαίρεσης των μηδενικών τιμών καθώς δίνει καλύτερα αποτελέσματα σε όλες τις κατηγορίες (accuracy, precision, recall). Ένα ακόμα συμπέρασμα στο οποίο καταλήγουν οι ερευνητές, όπως φαίνεται και από τον Πίνακα 4, είναι ότι καλύτερη απόδοση έχουν οι Deep Level Classifiers και ότι μεταξύ

των δύο αλγορίθμων που αποτελούν την κατηγορία αυτή, την βέλτιστη απόδοση, έχει ο αλγόριθμος Deep CNN.

Επίσης και οι Abdul Kadar Muhammad Masum et al. (Abdul Kadar Muhammad Masum, 2019) ακολούθησαν μια διαδικασία προ επεξεργασίας των δεδομένων πριν προχωρήσουν στην τελική ανάλυσή τους για τη εξαγωγή αποτελεσμάτων. Αρχικά αφαιρέθηκαν οι άκυρες περιπτώσεις που δεν επηρέαζαν με κάποιον τρόπο τις υπόλοιπες που ήταν προς μελέτη. Η μείωση της δυσαναλογίας λόγω της ποικιλίας των διαφορετικών κατηγοριών ήταν μια ακόμα διαδικασία που πραγματοποιήθηκε μέσω της χρήσης συγκεκριμένου φίλτρου, προκειμένου να επιτευχθεί ισορροπία στα δεδομένα. Επιπλέον, εφαρμόστηκε ένα επιπρόσθετο φίλτρο το οποίο ρυθμίζει τη συχνότητα του δείγματος και έτσι ανωμαλίες που μπορεί να υπάρχουν στο δείγμα εξαιτίας των κυμάτων του εδάφους και άλλων σχετικών παραγόντων περιορίζονται.

Οι αλγόριθμοι που χρησιμοποιήθηκαν για την επεξεργασία των δεδομένων ήταν τρεις βασικοί ταξινομητές: οι Naïve Bayes, Random Forests και Support Vector Machine και τρεις εξελεγμένους ταξινομητές: οι Multi-Layer Perceptron, Convolutional Neural Network και Long- Short Term Memory. Τα συμπεράσματα των ερευνητών καταδεικνύουν ότι οι εξελεγμένοι ταξινομητές (deep- level classifiers) υπερτερούν στην επεξεργασία των δεδομένων σε σύγκριση με τους βασικούς ταξινομητές (base-level classifiers). Επιπροσθέτως, από τους χρησιμοποιούμενους αλγόριθμους, ο αλγόριθμος Convolutional Neural Network (CNN) παρουσίασε την καλύτερη απόδοση.

ΚΕΦΑΛΑΙΟ 3: ΜΕΘΟΔΟΛΟΓΙΑ

3.1 Περιγραφή της βάσης δεδομένων

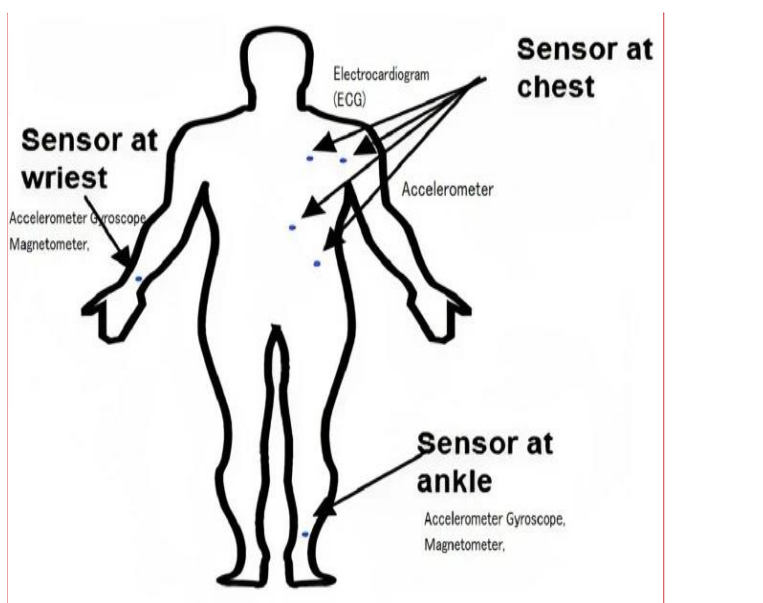
Στην παρούσα διπλωματική εργασία χρησιμοποιείται ένα σύνολο δεδομένων που έχει συλλεχθεί από τους Oresti Banos, Rafael Garcia και Alejandro Saez, το οποίο είναι ελεύθερα διαθέσιμο από το Αποθετήριο Μηχανικής Μάθησης του UCI (MHealth Dataset, 2014) (Oresti Banos, 2014). Το σύνολο δεδομένων MHEALTH αποτελείται από καταγραφές κίνησης του σώματος και ζωτικών σημείων από δέκα εθελοντές (υποκειμένα), ο καθένας με διαφορετικά χαρακτηριστικά. Οι καταγραφές έγιναν ενώ το κάθε υποκείμενο εκτελούσε 12 διαφορετικούς τύπους δραστηριοτήτων. Οι αισθητήρες επιταχυνσιόμετρο, γυροσκόπιο και μαγνητόμετρο τοποθετημένοι στο σώμα των υποκειμένων μετρούν την επιτάχυνση, τον ρυθμό περιστροφής, τον προσανατολισμό του μαγνητικού πεδίου και συνεπώς, το εύρος της κίνησης που βιώνουν τα διάφορα μέρη του σώματος των υποκειμένων. Το συλλεχθέν σύνολο δεδομένων περιλαμβάνει καταγραφές κίνησης του σώματος και ζωτικών σημείων των δέκα υποκειμένων κατά τη διάρκεια της εκτέλεσης των φυσικών δραστηριοτήτων που αναφέρθηκαν παραπάνω. Το σύνολο αυτό των δεδομένων, όπως φαίνεται και στον Πίνακα 7, περιλαμβάνει καταγραφές κινήσεων του σώματος και ζωτικών σημείων από δέκα εθελοντές με διαφορετικά προφίλ ο καθένας, ενώ εκτελούσαν διάφορες σωματικές δραστηριότητες.

	Άτομα	Δραστηριότητες	Συσκευές αισθητήρων	Τύπος αισθητήρα	Θέσεις τοποθέτησης
mHealth	10	12	Τέσσερις συσκευές: επιταχυνσιόμετρο, γυροσκόπιο, μαγνητόμετρο, ηλεκτροκαρδιογράφημα	Φορέσιμος	Στήθος, καρπός και αστράγαλος

Πίνακας 7: Περιγραφή του συνόλου δεδομένων mHealth

Οι αισθητήρες τοποθετήθηκαν στο στήθος, στον δεξιό καρπό και στον αριστερό αστράγαλο του κάθε ατόμου όπως φαίνεται στην Εικόνα 6. Οι ενδείξεις που καταγράφηκαν σχετίζονταν με τις κινήσεις που γίνεται στο κάθε σημείο του σώματος

περιλαμβάνοντας πληροφορίες όπως την επιτάχυνση, το ρυθμό στροφής και τον προσανατολισμό του μαγνητικού πεδίου. Ο αισθητήρας που είναι τοποθετημένος στο στήθος πραγματοποίησε μετρήσεις ηλεκτροκαρδιογραφήματος, που μπορούν να χρησιμοποιηθούν για την παρακολούθηση της καρδιακής λειτουργίας, την ανίχνευση τυχόν αρρυθμιών ή για την παρουσίαση των αποτελεσμάτων και των επιπτώσεων της άσκησης (MHealth Dataset, 2014) (Oresti Banos, 2014).




Με σχόλια [ΚΤ3]: Αν δεν έχει κάποια διαφορά από την Εικόνα 7, μπορεί να αφαιρεθεί.

Εικόνα 6: Τα σημεία τοποθέτησης των αισθητήρων για τη συλλογή των δεδομένων (Ehab El-Adawi, 2024)

Όπως αναφέρθηκε και προηγουμένως, το σύνολο των δεδομένων περιλαμβάνει καταγραφές κινήσεων του σώματος και ζωτικών σημείων από 10 εθελοντές με διαφορετικά προφίλ καθώς εκτελούσαν 12 φυσικές δραστηριότητες. Για την καταγραφή χρησιμοποιήθηκαν φορέσιμοι αισθητήρες Shimmer2 (BUR10) οι οποίοι τοποθετήθηκαν στο στήθος, στον δεξιό καρπό και τον αριστερό αστράγαλο με τη βοήθεια ελαστικών επιδέσμων (Εικόνα 7). Η χρήση των πολλαπλών αισθητήρων επιτρέπει ακριβέστερες μετρήσεις των κινήσεων κάθε μέλους, της επιτάχυνσης, του ρυθμού στροφής και του προσανατολισμού του μαγνητικού πεδίου αποτυπώνοντας έτσι καλύτερα τη δυναμική του σώματος με μεγαλύτερη ακρίβεια. Η συχνότητα δειγματοληψίας ήταν στα 50Hz, η οποία θεωρείται επαρκής για την καταγραφή της ανθρώπινης δραστηριότητας. Κάθε συνεδρία καταγράφηκε χρησιμοποιώντας βιντεοκάμερα. Αυτό το σύνολο δεδομένων φαίνεται να αντικατοπτρίζει κοινές

δραστηριότητες της καθημερινότητας δεδομένης της ποικιλίας των μελών του σώματος που εμπλέκονται σε κάθε μία, της ταχύτητας εκτέλεσης τους και της δυναμικής τους. Οι δραστηριότητες δεν εκτελέστηκαν σε ελεγχόμενο εργαστηριακό περιβάλλον και οι συμμετέχοντες κλήθηκαν απλώς να καταβάλουν την καλύτερη προσπάθειά τους κατά την εκτέλεσή τους. (MHealth Dataset, 2014)



Εικόνα 7: Τα σημεία τοποθέτησης των αισθητήρων με τη βοήθεια ελαστικών επιδέσμων (Abdu Gumaei, 2019)

Οι δραστηριότητες που εκτελέστηκαν ήταν:

1. Παραμένω ακίνητος (1 λεπτό)
2. Κάθισμα και χαλάρωση (1 λεπτό)
3. Ξαπλώνω (1 λεπτό)
4. Βάδιση (1 λεπτό)
5. Ανέβασμα σκάλας (1 λεπτό)
6. Πρόσθια επίκρυψη (20 φορές)
7. Ανύψωση των χεριών μπροστά (20 φορές)
8. Κάμψη γονάτων (σκύψιμο) (20 φορές)
9. Ποδήλατο (1 λεπτό)

10. Χαλαρό τρέξιμο (jogging) (1 λεπτό)

11. Γρήγορο τρέξιμο (1 λεπτό)

12. Άλματα μπρος και πίσω (20 φορές)

Σημειώνεται πως μέσα στις παρενθέσεις βρίσκεται το νούμερο των επαναλήψεων ή της διάρκειας της κάθε άσκησης. (MHealth Dataset, 2014)

Κωδικός Δραστηριότητας	Δραστηριότητα Όνομα με διάρκεια ή επαναλήψεις	Αριθμός περιπτώσεων
L1	Παραμένω ακίνητος (1 λεπτό)	3072
L2	Κάθισμα και χαλάρωση (1 λεπτό)	3072
L3	Ξαπλώνω (1 λεπτό)	3072
L4	Βάδιση (1 λεπτό)	3072
L5	Ανέβασμα σκάλας (1 λεπτό)	3072
L6	Πρόσθια επίκλυση (1 λεπτό)	3072
L7	Ανύψωση των χεριών μπροστά (20 επαναλήψεις)	3072
L8	Κάμψη γονάτων (20 επαναλήψεις)	3072
L9	Ποδήλατο (1 λεπτό)	3072
L10	Χαλαρό τρέξιμο (1 λεπτό)	3072
L11	Γρήγορο τρέξιμο (1 λεπτό)	3072
L12	Άλματα μπρος και πίσω (20 επαναλήψεις)	3072
Total		35174

Πίνακας : Ο αριθμός των επαναλήψεων για κάθε δραστηριότητα (Abdu Gumaei, 2019)

3.2 Προεπεξεργασία δεδομένων

Στη φάση της προεπεξεργασίας των δεδομένων, που αποτελεί κρίσιμο βήμα πριν την ανάλυση και εφαρμογή των αλγορίθμων μηχανικής μάθησης, δίνεται ιδιαίτερη προσοχή στην καθαριότητα και την ακρίβεια του συνόλου δεδομένων. Το σύνολο δεδομένων MHEALTH περιλαμβάνει λεπτομερείς καταγραφές από 10 διαφορετικούς εθελοντές, οι οποίοι κλήθηκαν να εκτελέσουν 12 διαφορετικούς τύπους δραστηριοτήτων. Τα δεδομένα που συλλέχθηκαν για κάθε υποκείμενο αποθηκεύονται σε ξεχωριστό αρχείο καταγραφής: 'mHealth_subject.log'. Κάθε αρχείο περιέχει τα δείγματα (ανά γραμμή) που έχουν καταγραφεί από όλους τους αισθητήρες (ανά στήλη). Οι ετικέτες που χρησιμοποιούνται για την αναγνώριση των δραστηριοτήτων είναι παρόμοιες με αυτές που αναφέρθηκαν παραπάνω (π.χ., η ετικέτα για το περπάτημα είναι η '4'). Συνεπώς, κάθε αρχείο καταγραφής περιλαμβάνει τις παρακάτω στήλες:

1. Επιταχυνσιόμετρο στήθους X (acceleration_chest_x)
2. Επιταχυνσιόμετρο στήθους Y (acceleration_chest_y)
3. Επιταχυνσιόμετρο στήθους Z (acceleration_chest_z)
4. Ηλεκτροκαρδιογράφημα οδηγού 1 (ecg_lead_1)
5. Ηλεκτροκαρδιογράφημα οδηγού 2 (ecg_lead_2)
6. Επιταχυνσιόμετρο αστραγάλου X (acceleration_ankle_x)
7. Επιταχυνσιόμετρο αστραγάλου Y (acceleration_ankle_y)
8. Επιταχυνσιόμετρο αστραγάλου Z (acceleration_ankle_z)
9. Γυροσκόπιο αστραγάλου X (gyro_ankle_x)
10. Γυροσκόπιο αστραγάλου Y (gyro_ankle_y)
11. Γυροσκόπιο αστραγάλου Z (gyro_ankle_z)
12. Μαγνητόμετρο αστραγάλου X (magnetometer_ankle_x)
13. Μαγνητόμετρο αστραγάλου Y (magnetometer_ankle_y)
14. Μαγνητόμετρο αστραγάλου Z (magnetometer_ankle_z)
15. Επιταχυνσιόμετρο καρπού X (acceleration_wrist_x)
16. Επιταχυνσιόμετρο καρπού Y (acceleration_wrist_y)

17. Επιταχυνσιόμετρο καρπού Z (acceleration_wrist_z)
18. Γυροσκόπιο καρπού X (gyro_wrist_x)
19. Γυροσκόπιο καρπού Y (gyro_wrist_y)
20. Γυροσκόπιο καρπού Z (gyro_wrist_z)
21. Μαγνητόμετρο καρπού X (magnetometer_wrist_x)
22. Μαγνητόμετρο καρπού Y (magnetometer_wrist_y)
23. Μαγνητόμετρο καρπού Z (magnetometer_wrist_z)

και την 24^η στήλη με την ετικέτα κλάσης που παίρνει τιμές από 0 έως 12. Κάθε δραστηριότητα στο σύνολο δεδομένων αντιστοιχίζεται σε μια από τις κατηγορίες από το 1 έως το 12, ενώ η κατάσταση 'null', η οποία αντιπροσωπεύει περιόδους κατά τις οποίες δεν πραγματοποιείται καμία από τις καθορισμένες δραστηριότητες, έχει ανατεθεί την τιμή 0. Η κατηγορία 'null' αποτελεί μια σημαντική πρόκληση στην ανάλυση καθώς είχε τα περισσότερα δεδομένα μέσα στο σύνολο δεδομένων, αντιπροσωπεύοντας μεγάλο μέρος της ροής των δεδομένων (περίπου το 73% των δεδομένων), πράγμα που θα μπορούσε να προκαλέσει σύγχυση και να επηρεάσει την απόδοση των αλγορίθμων μηχανικής μάθησης. Για το λόγο αυτό, η κατηγορία 'null' έχει αφαιρεθεί από την ανάλυση για να εξασφαλιστεί ότι τα μοτίβα και τα αποτελέσματα που εξάγονται είναι συνεπή και αξιόπιστα.

Ο παρακάτω πίνακας παρουσιάζει μια αναλυτική επισκόπηση των δεδομένων που καταγράφονται στο σύνολο δεδομένων MHEALTH για κάθε ένα από τα δέκα υποκείμενα. Συγκεκριμένα, καταγράφει το συνολικό αριθμό δεδομένων που συλλέχθηκαν αρχικά και τον αριθμό δεδομένων που παρέμειναν μετά την αφαίρεση των τιμών που χαρακτηρίζονται ως 'null'. Οι τιμές 'null' αναφέρονται σε δεδομένα που δεν αντιστοιχούν σε κάποια από τις συγκεκριμένες δραστηριότητες που είχαν οριστεί για την καταγραφή και για το λόγο αυτό αποκλείστηκαν από την τελική ανάλυση. Παράλληλα, στο συγκεκριμένο σύνολο δεδομένων δεν υπήρχαν τιμές που να λείπουν και όλες οι καταγραφές από τους αισθητήρες ήταν πλήρεις. Επομένως, δεν απαιτήθηκε η εφαρμογή τεχνικών για την αντιμετώπιση κενών τιμών.

Ο αριθμός των δεδομένων 'null' υποδεικνύει ότι ένα σημαντικό μέρος των δεδομένων που συλλέχθηκαν αρχικά δεν συμπεριλαμβάνεται στην τελική ανάλυση. Στον Πίνακα παρουσιάζεται και η συνολική διάρκεια της βάσης που είναι 473,57 λεπτά (7,89 ώρες)

αλλά και η συνολική διάρκεια των δεδομένων που τελικά χρησιμοποιήθηκαν για την εκπαίδευση των αλγορίθμων που είναι 114,40 λεπτά (1,61 ώρες)

Υποκείμενο	Σύνολο δεδομένων (δείγματα)	Σύνολο δεδομένων (χωρίς τα null)	Συνολική διάρκεια (λεπτά)	Συνολική διάρκεια (χωρίς τα null)
1	161280	35175	53,76	11,73
2	130561	35533	43,52	11,84
3	122112	35381	40,70	11,79
4	116736	35329	38,91	11,78
5	119808	33948	39,94	11,32
6	196865	32206	65,62	10,74
7	210843	34254	70,28	11,42
8	129024	33333	43,01	11,11
9	135168	34355	45,06	11,45
10	98304	33691	32,77	11,23
Σύνολο	1420701	343205	473,57 λεπτά	114,40 λεπτά
			7,89 ώρες	1,61 ώρες

3.3 Εκπαίδευση μοντέλων μηχανικής μάθησης

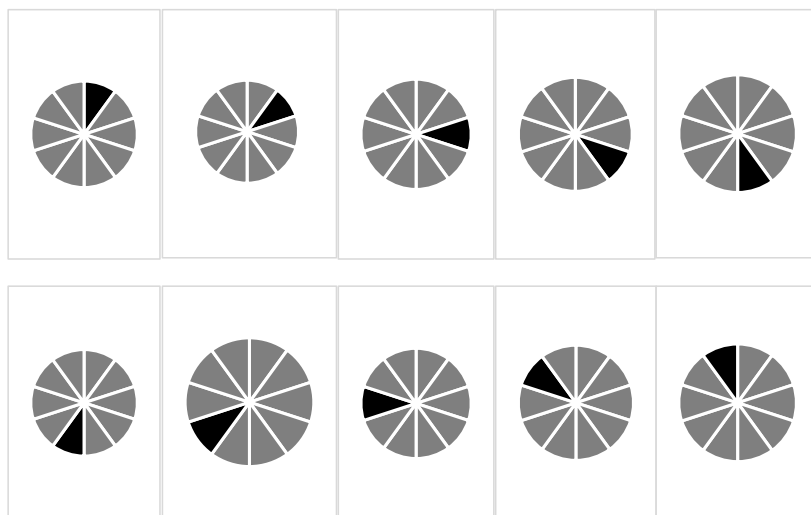
Για την λήψη καλύτερων αποτελεσμάτων με τη χρήση μοντέλων μηχανικής μάθησης μέρος των διαθέσιμων δεδομένων χρησιμοποιείται για την εκπαίδευση των αλγορίθμων και το υπόλοιπο μέρος του δείγματος για την έλεγχο. Ένας τρόπος για να συμβεί αυτό είναι να γίνει διαμοιρασμός του δείγματος σε τρία κομμάτια και έτσι τα δύο τρίτα (66%) να χρησιμοποιηθούν για την εκπαίδευση των μοντέλων και το ένα τρίτο (33%) για τον έλεγχο του δείγματος.

Είναι μια μέθοδος που χρησιμοποιείται αρκετά συχνά παρόλα αυτά το δείγμα που χρησιμοποιείται για την εκπαίδευση ή τον έλεγχο δεν είναι γνωστό αν είναι αρκετό και ενδεικτικό σε σχέση με το σύνολο των δεδομένων. Σε γενικές γραμμές με αυτό τον τρόπο δεν μπορεί να οριστεί με κάποιον τρόπο ένα το μέρος των δειγμάτων που

χρησιμοποιείται είναι αρκετό. Ειδικά σε περιπτώσεις που υπάρχουν πολλά χαμένα δεδομένα, ο αλγόριθμος δεν θα μπορέσει να διαχειριστεί σωστά το σύνολο των δεδομένων και τα αποτελέσματα που θα δώσει δεν είναι σωστά.

Από την άλλη, υπάρχει μια σημαντική στατιστική τεχνική που ονομάζεται διασταυρούμενη επικύρωση (cross validation). Στην τεχνική αυτή, ορίζεται ένας σταθερός αριθμός αναδίπλωσης ή διαχωρισμού για τα δεδομένα, για να γίνει πιο κατανοητό θα οριστεί ο αριθμός 3. Τα δεδομένα λοιπόν στο σημείο αυτό θα χωριστούν σε τρία ίσα κομμάτια και το καθένα από αυτά χρησιμοποιείται για τον έλεγχο του δείγματος ενώ τα υπόλοιπα δύο που υπολείπονται χρησιμοποιούνται για την εκπαίδευση. Τα δύο τρίτα λοιπόν των δεδομένων χρησιμοποιούνται για εκπαίδευση και το ένα τρίτο για έλεγχο. Η διαδικασία επαναλαμβάνεται για κάθε τρίτο του δείγματος.

Στην συγκεκριμένη εργασία γίνεται χρήση της διασταυρούμενης επικύρωσης χωρίζοντας το δείγμα σε 10 μέρη (10-fold cross validation) (Σχήμα 1). Το δείγμα χωρίζεται σε δέκα ίσα ή σχεδόν ίσα τμήματα. Το ένα κομμάτι χρησιμοποιείται για επικύρωση ενώ τα άλλα 9 για εκπαίδευση. Η διαδικασία αυτή επαναλαμβάνεται 10 φορές. Το πλεονέκτημα αυτής της μεθόδου είναι ότι αποδίδει αξιόπιστες και αμερόληπτες δοκιμές σε μικρότερο δείγμα δεδομένων καθώς απαιτεί περισσότερη υπολογιστική προσπάθεια από μια απλή διαδικασία. (Gurjeet Singh, 2011) (Gokhan Aksu, 2019) (Seyed Matin Malakouti, 2023)



Σχήμα 1: Σχηματική αναπαράσταση του 10-fold cross validation

3.4 Επιλογή αλγορίθμων Μηχανικής Μάθησης

Στη σημερινή εποχή τα δεδομένα που υπάρχουν και χρησιμοποιούνται στις βάσεις δεδομένων είναι τεράστια σε όγκο και αριθμό. Η μεγάλη εξέλιξη στον τομέα των δεδομένων και των βάσεων δεδομένων έχει δημιουργήσει την ανάγκη για νέες τεχνικές και καινούρια εργαλεία τα οποία θα μπορούν αυτόματα και με ευφυΐα να μετατρέψουν τα επεξεργαζόμενα δεδομένα σε χρήσιμες πληροφορίες και γνώση. (Brijain R Patel, 2016)

Μία ευρέως χρησιμοποιούμενη τεχνική στα συστήματα εξόρυξης δεδομένων είναι η δημιουργία ταξινομητών. Στην εξόρυξη δεδομένων, οι αλγόριθμοι που χρησιμοποιούνται ως ταξινομητές, έχουν την ικανότητα να διαχειριστούν μεγάλο όγκο πληροφοριών και δεδομένων. Μπορούν να κάνουν υποθέσεις σχετικά με τα ονόματα των κατηγοριών, να ταξινομήσουν τα δεδομένα με βάση τα σετ εκπαίδευσης και τις ετικέτες και να ταξινομήσουν πρόσφατα δεδομένα. (Bahzad Taha Jijo, 2021)

Οι αλγόριθμοι που χρησιμεύουν ως ταξινομητές στη Μηχανική μάθηση είναι πολλοί σε αριθμό παρόλα αυτά παρακάτω θα εξεταστούν συγκεκριμένοι αλγόριθμοι και αυτοί είναι: ο Random Forests(RF), ο αλγόριθμος Decision Trees (DT), ο αλγόριθμος Support Vector Machines (SVM), ο Multilayer Perceptron (MP) και ο αλγόριθμος k- Nearest Neighbor (KNN).

3.4.1 Decision Trees

Ο αλγόριθμος Decision Trees (DT) ή Δέντρα Απόφασης, όπως αλλιώς λέγονται, είναι μία από τις πιο ισχυρές και συχνές μεθόδους που χρησιμοποιείται στην μηχανική μάθηση, στην επεξεργασία φωτογραφιών και στην αναγνώριση προτύπων. Το DT είναι ένα διαδοχικό μοντέλο που ενώνει με αποτελεσματικό τρόπο μια σειρά βασικών τεστ όπου ένα αριθμητικό χαρακτηριστικό συγκρίνεται με μία τιμή σε κάθε τεστ. Χρησιμοποιείται κυρίως για ομαδοποίηση και είναι ένα συχνά χρησιμοποιούμενο μοντέλο στην εξόρυξη δεδομένων. Το κάθε δέντρο αποτελείται από κόμβους και κλαδιά. Κάθε κόμβος αντιπροσωπεύει τα χαρακτηριστικά προς ταξινόμησης μίας κατηγορίας και κάθε υποσύνολο ορίζει μία τιμή που μπορεί να ληφθεί από τον κόμβο. Εξαιτίας της απλής μορφής τους και της ακρίβειάς τους τα DT έχουν βρει εφαρμογή σε πολλά πεδία. (Bahzad Taha Jijo, 2021)

Πιο συγκεκριμένα είναι πολλοί οι τομείς της καθημερινής ζωής που συναντάται η εφαρμογή των DT. Κάποιοι από αυτούς του τομείς είναι:

- Στον τομέα των επιχειρήσεων
- Στην ηλεκτρονική διαφήμιση
- Στην επεξεργασία εικόνων
- Στη φαρμακολογία
- Στη βιομηχανία (Brijain R Patel, 2016)

3.4.2 Random Forests

Ο ταξινομητής Random Forests (RF) ή τυχαία δάση είναι ένας συνδυασμός προγνωστικών δέντρων έτσι ώστε κάθε δέντρο να εξαρτάται από τις τιμές του τυχαίου διανύσματος δειγματοληψίας ανεξάρτητα με την κατανομή. (Breiman, 2001) Είναι ένας ταξινομητής συνόλου που χρησιμοποιεί ένα σύνολο από CARTs για να κάνει μία πρόβλεψη. Τα δέντρα δημιουργούνται σχεδιάζοντας ένα υποσύνολο δειγμάτων εκπαίδευσης μέσω αντικατάστασης. Αυτό σημαίνει ότι το ίδιο δείγμα μπορεί να επιλεγεί πολλές φορές ενώ άλλα μπορεί να μην χρησιμοποιηθούν καθόλου. Τα δύο τρίτα του δείγματος χρησιμοποιούνται για να εκπαιδεύσουν τα δέντρα ενώ το υπόλοιπο ένα τρίτο χρησιμοποιείται για τη διασταυρούμενη επικύρωση του δείγματος με σκοπό τον υπολογισμό της απόδοσής του. (Mariana Belgiu, 2016)

3.4.3 Support Vector Machine

Ο ταξινομητής Support Vector Machine (SVM) ή δίκτυα διανυσμάτων υποστήριξης είναι εποπτευόμενα μοντέλα μέγιστου περιθωρίου με σχετικούς αλγορίθμους εκμάθησης που αναλύουν δεδομένα. Είναι ένα σύνολο εποπτευόμενων μεθόδων εκμάθησης που χρησιμοποιούνται για ταξινόμηση, παλινδρόμηση και ανίχνευση ακραίων τιμών. Εξαιτίας της απλότητας και της ευελιξίας του για την αντιμετώπιση μιας σειράς προβλημάτων γαταξινόμησης, ο SVM προσφέρει ευδιάκριτα ισορροπημένη προγνωστική απόδοση ακόμη και σε μελέτες που το μέγεθος του δείγματος μπορεί να είναι περιορισμένο. (Derek A. Pisner, 2020)

Τα πλεονεκτήματα του συγκεκριμένου ταξινομητή είναι ότι είναι:

- Αποτελεσματικός σε δεδομένα με μεγάλο μέγεθος
- Χρησιμοποιεί ένα υποσύνολο σημείων στη συνάρτηση απόφασης (που ονομάζονται διανύσματα υποστήριξης) επομένως είναι επίσης αποδοτικό στη μνήμη
- Ευέλικτο, μπορούν να καθοριστούν διαφορετικές συναρτήσεις για τη συνάρτηση απόφασης

Τα μειονεκτήματα του ταξινομητή είναι:

- Δεν παρέχουν άμεσα εκτιμήσεις πιθανοτήτων, αυτές υπολογίζονται χρησιμοποιώντας μια ακριβή πενταπλάσια διασταυρούμενη επικύρωση. (Υποστήριξη Vector Machines, n.d.) (Guangxin Huang, 2011)

3.4.4 Multilayer Perceptron

Ο Multilayer Perceptron (MLP) είναι ένας τύπος νευρωνικού δικτύου που αποτελείται από πολλαπλά στρώματα νευρώνων. Οι νευρώνες συνήθως χρησιμοποιούν μη γραμμικές συναρτήσεις ενεργοποίησης επιτρέποντας στο δίκτυο να μάθει πολύπλοκα μοτίβα σε δεδομένα. Είναι το πιο γνωστό και το πιο συχνά χρησιμοποιούμενο από τα νευρωνικά δίκτυα. Στις περισσότερες περιπτώσεις τα σήματα μεταδίδονται εντός του δικτύου προς μία κατεύθυνση, από την είσοδο στην έξοδο. Η έξοδος κάθε νευρώνα δεν επηρεάζει τον ίδιο τον νευρώνα. Η μέθοδος αυτή ονομάζεται τροφοδότηση προς τα εμπρός. Τα στρώματα (layers) που δεν συνδέονται άμεσα με το περιβάλλον ονομάζονται κρυφά. (Marius- Constantin Popescu, 2009)

3.4.5 k- Nearest Neighbor

Ο αλγόριθμος k- Nearest Neighbor είναι ένας μη παραμετρικός, εποπτευόμενος ταξινομητής εκμάθησης, ο οποίος χρησιμοποιεί την εγγύτητα για να κάνει ταξινομήσεις ή προβλέψεις σχετικά με την ομαδοποίηση ενός μεμονωμένου σημείου δεδομένων. Ο συγκεκριμένος τύπος ταξινόμησης αναπτύχθηκε λόγω της ανάγκης να πραγματοποιηθεί ανάλυση όταν οι αξιόπιστες παραμετρικές εκτιμήσεις των πυκνοτήτων πιθανότητας είναι άγνωστες ή δύσκολο να προσδιοριστούν. (Peterson, 2009) (E. A. Patrick, 1970)

ΚΕΦΑΛΑΙΟ 4: ΑΠΟΤΕΛΕΣΜΑΤΑ

Στο Κεφάλαιο 4 παρουσιάζονται τα αποτελέσματα της εφαρμογής των αλγορίθμων μηχανικής μάθησης που χρησιμοποιήθηκαν για την Αναγνώριση Ανθρώπινης Κίνησης (HAR). Οι αλγόριθμοι που εξετάστηκαν είναι οι Decision Trees, Random Forests, Support Vector Machine (SVM), Multilayer Perceptron (MLP) και k-Nearest Neighbor (k-NN). Για κάθε έναν από αυτούς, παρατίθενται τα ποσοστά ακρίβειας, ο δείκτης True Positive Rate (TPR), False Positive Rate (FPR), καθώς και η συνολική απόδοση τους με βάση τον πίνακα Confusion Matrix. Στόχος του κεφαλαίου είναι η αξιολόγηση των αποτελεσμάτων, ώστε να αναδειχθεί ο καλύτερος ταξινομητής για την παρούσα εφαρμογή.

Decision Trees

Στον πρώτο αλγόριθμο, από το σύνολο των 34608 περιπτώσεων, όπως φαίνεται και στις εικόνες 3 και 4, έχουμε ποσοστό σωστά ταξινομημένων περιπτώσεων 98,39%, TP Rate Avg 0,98, FP Rate 0,001 και Ακρίβεια (Precision) 0,984.

Correctly Classified Instances	34608	98.3909 %
Incorrectly Classified Instances	566	1.6091 %

Εικόνα 3: Ποσοστά σωστών και λάθος τοποθετημένων δεδομένων

=== Detailed Accuracy By Class ===

	TP Rate	FP Rate	Precision	Recall
	1,000	0,000	1,000	1,000
	1,000	0,000	1,000	1,000
	1,000	0,000	1,000	1,000
	0,998	0,000	0,996	0,998
	0,996	0,000	0,996	0,996
	1,000	0,000	0,999	1,000
	0,993	0,001	0,994	0,993
	0,995	0,001	0,992	0,995
	1,000	0,000	1,000	1,000
	0,957	0,005	0,949	0,957
	0,926	0,007	0,931	0,926
	0,862	0,004	0,878	0,862
Weighted Avg.	0,984	0,001	0,984	0,984

Εικόνα 4: Πίνακας λεπτομερούς ακρίβειας με βάση την κλάση

Από τον πίνακα Confusion Matrix φαίνεται (Εικόνα 5) ότι στα δεδομένα ελέγχου είχαμε 3072 σωστά τοποθετημένες περιπτώσεις στην πρώτη κατηγορία, που είναι η κατηγορία «στέκομαι ακίνητος για ένα λεπτό», όπως και στην δεύτερη, Τρίτη, έκτη και ένατη κατηγορία τα αποτελέσματα είναι σωστά τοποθετημένα. Στην τέταρτη κατηγορία μέχρι και την όγδοη παρατηρούμε κάποιες λανθασμένα τοποθετημένες τιμές. Για παράδειγμα στην πέμπτη κατηγορία που είναι η κατηγορία « ανέβασμα σκάλας» υπάρχουν 3059 σωστά τοποθετημένες περιπτώσεις και 13 λανθασμένα τοποθετημένες περιπτώσεις με αυτές να μοιράζονται 4 στην τέταρτη κατηγορία (περπάτημα), 2 στην έκτη κατηγορία (πρόσθια επίκουση), 1 στην έβδομη κατηγορία (ανύψωση των χεριών μπροστά), 5 στην όγδοη κατηγορία (κάμψη γονάτων) και μία περίπτωση στην δέκατη κατηγορία (χαλαρό τρέξιμο).

```
=== Confusion Matrix ===
      a   b   c   d   e   f   g   h   i   j   k   l  <-- classified as
3072   0   0   0   0   0   0   0   0   0   0   0 |  a = 1
  0 3072   0   0   0   0   0   0   0   0   0   0 |  b = 2
  0   0 3072   0   0   0   0   0   0   0   0   0 |  c = 3
  0   0   0 3065   3   0   0   0   0   0   4   0 |  d = 4
  0   0   0   4 3059   2   1   5   0   1   0   0 |  e = 5
  0   0   0   0   0 3072   0   0   0   0   0   0 |  f = 6
  0   0   0   0   0   0 3051  21   0   0   0   0 |  g = 7
  0   0   0   0   2   0  16 3361   0   0   0   0 |  h = 8
  0   0   0   0   0   0   0   0 3072   0   0   0 |  i = 9
  0   0   0   0   0   0   0   0   0 2939 101  32 |  j = 10
  0   0   0   8   7   0   0   0   0  114 2846  97 |  k = 11
  0   0   0   0   0   0   0   0   0   43  105  927 |  l = 12
```

Εικόνα 5: Πίνακας Confusion Matrix

Random Forests

Στον επόμενο αλγόριθμο, από το σύνολο των 35174 περιπτώσεων, όπως φαίνεται και στις εικόνες 6 και 7, έχουμε 99,75% ποσοστό σωστά τοποθετημένων περιπτώσεων με TP Rate Avg 0,99, FP Rate Avg 0 και Ακρίβεια (Precision) 0,99.

```
Correctly Classified Instances      35088          99.7555 %
Incorrectly Classified Instances      86            0.2445 %
```

Εικόνα 6: Ποσοστά σωστών και λάθος τοποθετημένων δεδομένων

=== Detailed Accuracy By Class ===

	TP Rate	FP Rate	Precision	Recall
	1,000	0,000	1,000	1,000
	1,000	0,000	1,000	1,000
	1,000	0,000	1,000	1,000
	1,000	0,000	0,999	1,000
	0,999	0,000	1,000	0,999
	1,000	0,000	1,000	1,000
	1,000	0,000	0,999	1,000
	0,999	0,000	0,999	0,999
	1,000	0,000	1,000	1,000
	0,998	0,001	0,987	0,998
	0,985	0,001	0,991	0,985
	0,974	0,000	0,991	0,974
Weighted Avg.	0,998	0,000	0,998	0,998

Εικόνα 7: Πίνακας λεπτομερούς ακρίβειας με βάση την κλάση

Από τον Confusion Matrix παρατηρείται (Εικόνα 8) ότι υπάρχουν 3072 σωστά τοποθετημένες περιπτώσεις στην πρώτη, δεύτερη, τρίτη και τέταρτη κατηγορία, στην έκτη και στην έβδομη όπως και στην ένατη κατηγορία. Στις υπόλοιπες παρατηρούμε να υπάρχουν και λανθασμένα τοποθετημένες περιπτώσεις όπως συμβαίνει για παράδειγμα στην δωδέκατη κατηγορία, που είναι η κατηγορία «άλματα μπρος και πίσω», υπάρχουν 1047 περιπτώσεις σωστά τοποθετημένες και οι υπόλοιπες 20 είναι λάθος τοποθετημένες στην εντέκατη κατηγορία (γρήγορο τρέξιμο) και οι 8 στην δέκατη κατηγορία (χαλαρό τρέξιμο).

```

=== Confusion Matrix ===
  a  b  c  d  e  f  g  h  i  j  k  l  <-- classified as
3072  0  0  0  0  0  0  0  0  0  0  0 |  a = 1
  0 3072  0  0  0  0  0  0  0  0  0  0 |  b = 2
  0  0 3072  0  0  0  0  0  0  0  0  0 |  c = 3
  0  0  0 3072  0  0  0  0  0  0  0  0 |  d = 4
  0  0  0  0 3069  0  0  3  0  0  0  0 |  e = 5
  0  0  0  0  0 3072  0  0  0  0  0  0 |  f = 6
  0  0  0  0  0  0 3072  0  0  0  0  0 |  g = 7
  0  0  0  0  0  0  2 3377  0  0  0  0 |  h = 8
  0  0  0  0  0  0  0  0 3072  0  0  0 |  i = 9
  0  0  0  0  0  0  0  0  0 3065  7  0 |  j = 10
  0  0  0  4  1  0  0  0  0  32 3026  9 |  k = 11
  0  0  0  0  0  0  0  0  0  8  20 1047 |  l = 12
    
```

Εικόνα 8: Πίνακας Confusion Matrix

Support Vector Machines

Σε αυτήν την προσπάθεια, από το σύνολο των 35174 περιπτώσεων, όπως φαίνεται στις εικόνες 9 και 10, έχουμε 74,14% ποσοστό σωστά καταναμημένων περιπτώσεων με TP Rate Avg 0,74, FP Rate Avg 0,025 και Ακρίβεια (Precision) 0,74.

Correctly Classified Instances	26081	74.1485 %
Incorrectly Classified Instances	9093	25.8515 %

Εικόνα 9: Ποσοστά σωστών και λάθος τοποθετημένων δεδομένων

=== Detailed Accuracy By Class ===

	TP Rate	FP Rate	Precision	Recall
	0,859	0,036	0,697	0,859
	0,916	0,017	0,837	0,916
	0,998	0,001	0,990	0,998
	0,672	0,038	0,631	0,672
	0,549	0,018	0,744	0,549
	0,784	0,037	0,672	0,784
	0,782	0,006	0,921	0,782
	0,604	0,037	0,635	0,604
	0,960	0,005	0,950	0,960
	0,641	0,052	0,542	0,641
	0,632	0,036	0,624	0,632
	0,091	0,001	0,721	0,091
Weighted Avg.	0,741	0,025	0,748	0,741

Εικόνα 10: Πίνακας λεπτομερούς ακρίβειας με βάση την κλάση

Στη συνέχεια από τον Confusion Matrix (Εικόνα 11) παρατηρείται ότι σε καμία κατηγορία τα δεδομένα δεν είναι απόλυτα σωστά τοποθετημένα και σε όλες τις περιπτώσεις υπάρχουν και λάθος τοποθετημένα δεδομένα. Η καλύτερα καταναμημένη κατηγορία είναι η τρίτη κατηγορία (ξαπλώνω) όπου οι 3067 περιπτώσεις είναι σωστά τοποθετημένες ενώ η κατηγορία με τα λιγότερα σωστά τοποθετημένα δεδομένα είναι η δωδέκατη (άλμα μπρος και πίσω) με μόνο 98 σωστά τοποθετημένες περιπτώσεις.

```

=== Confusion Matrix ===
      a   b   c   d   e   f   g   h   i   j   k   l  <-- classified as
2640    6    0  121    0  263  27  13    0    2    0    0 |   a = 1
    2 2815    0   56    0  198    0    0    0    1    0    0 |   b = 2
    0    0 3067    0    0    0    0    0    0    3    2    0 |   c = 3
  200   30    0 2064   57  312   55  82    0  157  115    0 |   d = 4
  108    2    0  106 1687   77    2  848    5  179   58    0 |   e = 5
    21  317    0  138   37 2407    1  24    0   94   33    0 |   f = 6
  308  150    0  150    0  27 2402    4    1  25    5    0 |   g = 7
  501  11    0  259  239  131   88 2041    5   79   22    3 |   h = 8
    0    1    0    4    5    6    1  43 2948   59    5    0 |   i = 9
    6    9    2  171  107   66    9  84   78 1970  567    3 |   j = 10
    4   21   23  165   71   63   21  51   32  647 1942   32 |   k = 11
    0    0    6   37   63   30    1  24   35  419  362   98 |   l = 12

```

Εικόνα 11: Πίνακας Confusion Matrix

Multilayer Perceptron

Στον παρακάτω αλγόριθμο, από το δείγμα των 35174 περιπτώσεων, όπως φαίνεται και στις εικόνες 12 και 13, προκύπτει πως το 84,49% των περιπτώσεων είναι τοποθετημένο στη σωστή κατηγορία με TP Rate Avg 0,84, FT Rate Avg 0,015 και Ακρίβεια (Precision) 0,841.

```

Correctly Classified Instances      29722          84.4999 %
Incorrectly Classified Instances    5452           15.5001 %

```

Εικόνα 12: Ποσοστά σωστών και λάθος τοποθετημένων δεδομένων

```

=== Detailed Accuracy By Class ===

```

	TP Rate	FP Rate	Precision	Recall
	0,976	0,003	0,966	0,976
	0,993	0,002	0,979	0,993
	0,998	0,001	0,994	0,998
	0,826	0,028	0,741	0,826
	0,782	0,022	0,772	0,782
	0,904	0,011	0,889	0,904
	0,918	0,008	0,913	0,918
	0,667	0,027	0,727	0,667
	0,957	0,004	0,957	0,957
	0,738	0,029	0,710	0,738
	0,755	0,027	0,725	0,755
	0,269	0,008	0,516	0,269
Weighted Avg.	0,845	0,015	0,841	0,845

Εικόνα 13: Πίνακας λεπτομερούς ακρίβειας με βάση την κλάση

Και σε αυτή την περίπτωση παρατηρούμε από τον πίνακα Confusion Matrix (Εικόνα 14) ότι σε καμία κατηγορία οι περιπτώσεις δεν είναι ολοκληρωτικά σωστά τοποθετημένες παρατηρώντας πως σε κάθε κατηγορία υπάρχουν λανθασμένα τοποθετημένες περιπτώσεις. Η καλύτερα κατανοημένη κατηγορία είναι η τρίτη κατηγορία (ξαπλώνω) με 3066 σωστά τοποθετημένες περιπτώσεις και μόνο 6 λάθος στην δέκατη κατηγορία (χαλαρό τρέξιμο) ενώ η κατηγορία με τις λιγότερες σωστά τοποθετημένες περιπτώσεις είναι η δωδέκατη κατηγορία (άλματα μπρος και πίσω) με μόλις 289 σωστά τοποθετημένες περιπτώσεις.

```
=== Confusion Matrix ===
  a  b  c  d  e  f  g  h  i  j  k  l  <-- classified as
2997  4  0  9  0  3  12  47  0  0  0  0 |  a = 1
  4 3052  0  3  0  11  0  0  0  1  0  1 |  b = 2
  0  0 3066  0  0  0  0  0  0  6  0  0 |  c = 3
 10  8  1 2538 103 120  41 147  2  83 16  3 |  d = 4
  6  1  0 148 2402  34  4 368 15  66 22  6 |  e = 5
  4 40  2 120  16 2778  17  46  0  25 16  8 |  f = 6
 23  7  2  73  3  45 2819  68  1  12 16  3 |  g = 7
 58  3  0 308 402  69 159 2255 16  39 45 25 |  h = 8
  0  0  0  0 17  7  0  41 2940  63  1  3 |  i = 9
  1  3  2 125  97 27 18  63  76 2267 325 68 |  j = 10
  0  1 10  59 32 17 16  32  8 424 2319 154 |  k = 11
  0  0  0  40 39 15  2  33 15 205 437 289 |  l = 12
```

Εικόνα 14: Πίνακας Confusion Matrix

k-Nearest Neighbor

Στην τελευταία δοκιμή από το δείγμα των 35174 περιπτώσεων (Εικόνα 15 και 16) προέκυψε ποσοστό 88,44% σωστά τοποθετημένων περιπτώσεων με TP Rate Avg 0,85, FP Rate Avg 0,014 και Ακρίβεια (Precision) 0,853.

```
Correctly Classified Instances      30056      85.4495 %
Incorrectly Classified Instances     5118      14.5505 %
```

Εικόνα 15: Ποσοστά σωστών και λάθος τοποθετημένων δεδομένων

=== Detailed Accuracy By Class ===

	TP Rate	FP Rate	Precision	Recall
	0,998	0,005	0,950	0,998
	0,999	0,001	0,986	0,999
	1,000	0,000	0,998	1,000
	0,859	0,024	0,773	0,859
	0,756	0,023	0,759	0,756
	0,855	0,015	0,843	0,855
	0,933	0,011	0,893	0,933
	0,714	0,029	0,723	0,714
	0,951	0,005	0,945	0,951
	0,785	0,026	0,740	0,785
	0,708	0,013	0,840	0,708
	0,438	0,006	0,694	0,438
Weighted Avg.	0,854	0,014	0,853	0,854

Εικόνα 16: Πίνακας λεπτομερούς ακρίβειας με βάση την κλάση

Από τον Confusion Matrix προκύπτει το συμπέρασμα πως σε καμία κατηγορία οι περιπτώσεις δεν είναι απόλυτα σωστά τοποθετημένες. Σε όλες τις κατηγορίες υπάρχουν λάθος κατανεμημένες περιπτώσεις. Για παράδειγμα στην πρώτη κατηγορία οι 3066 περιπτώσεις είναι σωστά τοποθετημένες στην πρώτη κατηγορία, 1 περίπτωση λάθος κατανεμημένη στην τέταρτη κατηγορία (βάδιση), 1 στην έκτη κατηγορία (πρόσθια επίκυψη) και 4 στην έβδομη κατηγορία (ανύψωση των χεριών μπροστά). Αντίστοιχα με πολλές λανθασμένα τοποθετημένες περιπτώσεις κινούνται και οι υπόλοιπες κατηγορίες.

Συνολικά, στον παρακάτω πίνακα παρουσιάζονται τα αποτελέσματα από την εφαρμογή διαφόρων αλγορίθμων μηχανικής μάθησης για την Αναγνώριση Ανθρώπινης Κίνησης (HAR). Συγκρίνονται οι αλγόριθμοι Decision Trees, Random Forests, Support Vector Machine (SVM), Multilayer Perceptron (MLP), και k-Nearest Neighbor (k-NN) με βάση την ακρίβεια (Accuracy), τον δείκτη True Positive Rate (TP Rate), το False Positive Rate (FP Rate), και την ακρίβεια της ταξινόμησης (Precision), επιτρέποντας τη συνολική αξιολόγηση της απόδοσης κάθε αλγόριθμου και δείχνουν ότι οι Random Forests υπερέρχουν, ενώ ο SVM παρουσιάζει χαμηλότερη απόδοση σε σχέση με τους υπόλοιπους ταξινομητές.

Classifier	Accuracy	TP Rate	FP Rate	Precision
Decision Trees	98.39	0.98	0.001	0.984
Random Forests	99.75	0.99	0.0	0.99
SVM	74.14	0.74	0.025	0.74
MLP	84.49	0.84	0.015	0.841
kNN	88.44	0.85	0.014	0.853

Ο ταξινομητής Decision Trees έχει εξαιρετικά υψηλή ακρίβεια (98.39%) και TP Rate (0.98), που δείχνουν ότι ταξινομεί τις περιπτώσεις σωστά σχεδόν σε όλες τις κατηγορίες. Η τιμή του FP Rate (0.001) είναι πολύ χαμηλή, που σημαίνει ότι κάνει ελάχιστα λάθη κατά την ταξινόμηση των αρνητικών περιπτώσεων. Η ακρίβεια (Precision) 0.984 δείχνει ότι οι σωστά ταξινομημένες περιπτώσεις είναι πολύ κοντά στην πραγματικότητα, καθιστώντας αυτόν τον αλγόριθμο έναν από τους καλύτερους στην παρούσα μελέτη.

Ο Random Forests έχει την καλύτερη απόδοση από όλους τους ταξινομητές, με εξαιρετικά υψηλή ακρίβεια (99.75%) και TP Rate (0.99). Το FP Rate είναι ουσιαστικά μηδενικό (0.00), που σημαίνει ότι κάνει ελάχιστα λάθη ταξινόμησης. Η ακρίβεια 0.99 υποδεικνύει επίσης ότι η ποιότητα των ταξινομήσεων είναι πολύ υψηλή, καθιστώντας τον Random Forests τον πιο αξιόπιστο ταξινομητή για αυτό το σύνολο δεδομένων.

Ο SVM έχει χαμηλότερη απόδοση σε σύγκριση με τους προηγούμενους ταξινομητές, με 74.14% σωστά ταξινομημένες περιπτώσεις. Το TP Rate και η ακρίβεια είναι σχετικά χαμηλά (0.74), ενώ το FP Rate (0.025) είναι υψηλότερο, υποδεικνύοντας ότι κάνει περισσότερα λάθη κατά την ταξινόμηση αρνητικών περιπτώσεων. Επομένως, ο SVM δεν αποδίδει τόσο καλά σε αυτό το σύνολο δεδομένων όσο άλλοι ταξινομητές.

Το Multilayer Perceptron επιτυγχάνει καλύτερη απόδοση από τον SVM, με 84.49% σωστές ταξινομήσεις και TP Rate 0.84. Το FP Rate (0.015) είναι χαμηλότερο από αυτό του SVM, γεγονός που δείχνει λιγότερα λάθη κατά την ταξινόμηση αρνητικών περιπτώσεων. Η ακρίβεια (0.841) είναι ικανοποιητική, καθιστώντας το Multilayer Perceptron έναν αξιοπρεπή ταξινομητή για αυτό το σύνολο δεδομένων, αν και δεν είναι τόσο ακριβής όσο ο Random Forests ή το Decision Tree.

Ο k-NN έχει καλή απόδοση με 88.44% σωστές ταξινομήσεις και TP Rate 0.85. Το FP Rate (0.014) είναι χαμηλό, κάτι που υποδηλώνει ότι οι λανθασμένες ταξινομήσεις είναι περιορισμένες. Η ακρίβεια (0.853) είναι επίσης αρκετά καλή, καθιστώντας τον k-NN έναν αξιόλογο ταξινομητή για την Αναγνώριση Ανθρώπινης Κίνησης.

Συμπερασματικά, ο Random Forests είναι ο πιο αποτελεσματικός ταξινομητής, καθώς παρουσιάζει την υψηλότερη ακρίβεια και τον χαμηλότερο δείκτη λανθασμένων ταξινομήσεων. Από την άλλη, ο Decision Trees αποδίδει επίσης πολύ καλά, προσφέροντας υψηλή ακρίβεια και χαμηλό ποσοστό λάθους. Οι ταξινομητές Multilayer Perceptron και k-Nearest Neighbor παρέχουν ικανοποιητικές επιδόσεις, αν και είναι λιγότερο αποδοτικοί σε σύγκριση με τους Random Forests και Decision Trees. Ο Support Vector Machines (SVM), ωστόσο, αποδίδει χαμηλότερα σε σχέση με τους υπόλοιπους αλγόριθμους, κάνοντας περισσότερα λάθη κατά την ταξινόμηση.

ΚΕΦΑΛΑΙΟ 5: ΣΥΜΠΕΡΑΣΜΑΤΑ

Το πέμπτο και τελευταίο κεφάλαιο της παρούσας διπλωματικής εργασίας συνθέτει τα συμπεράσματα που προέκυψαν από την ανάλυση και την εφαρμογή αλγορίθμων μηχανικής μάθησης για την Αναγνώριση Ανθρώπινης Κίνησης (HAR). Σκοπός του κεφαλαίου είναι να παρέχει μια κριτική ανάλυση των ευρημάτων, να διατυπώσει σαφή συμπεράσματα σχετικά με την αποδοτικότητα των αλγορίθμων και να αναδείξει τις προκλήσεις και τους περιορισμούς που προέκυψαν κατά την υλοποίηση της μεθοδολογίας. Επιπλέον, θα συζητηθούν οι πιθανοί λόγοι πίσω από τις επιδόσεις των αλγορίθμων και θα εξεταστεί η δυνατότητα εφαρμογής τους σε πραγματικά σενάρια. Τέλος, θα προταθούν μελλοντικές κατευθύνσεις έρευνας, με στόχο την περαιτέρω βελτίωση των τεχνικών αναγνώρισης ανθρώπινης κίνησης και τη διεύρυνση των εφαρμογών τους σε διάφορους τομείς.

5.1 Συμπεράσματα μεθοδολογίας

Η παρούσα εργασία εστιάζει στην αναγνώριση ανθρώπινης κίνησης, ένα πεδίο της υπολογιστικής επιστήμης που χρησιμοποιείται για τη μελέτη και κατηγοριοποίηση καθημερινών δραστηριοτήτων μέσω αλγορίθμων μηχανικής μάθησης. Η συγκεκριμένη εργασία βασίζεται στη χρήση της βάσης δεδομένων MHealth, η οποία αποτελείται από καταγραφές κινήσεων και ζωτικών σημάτων που συλλέχθηκαν από φορέσιμους αισθητήρες τοποθετημένους σε 10 άτομα. Τα άτομα αυτά εκτέλεσαν 12 διαφορετικές φυσικές δραστηριότητες, όπως περπάτημα, τρέξιμο, ποδηλασία και άλλες καθημερινές κινήσεις, ενώ τα δεδομένα που συλλέχθηκαν περιλάμβαναν μετρήσεις όπως επιτάχυνση, γωνιακή ταχύτητα, καθώς και ηλεκτροκαρδιογραφήματα (ΕΚΓ).

Στο πλαίσιο της ανάλυσης των δεδομένων αυτών, δοκιμάστηκαν πέντε διαφορετικοί αλγόριθμοι μηχανικής μάθησης: οι **Decision Trees**, **Random Forest**, **Support Vector Machine (SVM)**, **Multilayer Perceptron (MLP)** και **k-Nearest Neighbor (k-NN)**.

1. **Decision Trees**: Πρόκειται για έναν αλγόριθμο που δημιουργεί ένα μοντέλο προβλέψεων μέσω της διαίρεσης των δεδομένων σε διαδοχικές "αποφάσεις", διακλαδώνοντας τα δεδομένα σε "δέντρα" βασισμένα στα χαρακτηριστικά τους. Ο αλγόριθμος αυτός είναι εύκολος στην ερμηνεία και χρησιμοποιείται συχνά λόγω της απλότητάς του.
2. **Random Forest**: Αποτελεί εξέλιξη των Decision Trees, καθώς δημιουργεί πολλαπλά δέντρα από τυχαία υποσύνολα δεδομένων και ενσωματώνει τις προβλέψεις τους για

να βελτιώσει την ακρίβεια και τη σταθερότητα του μοντέλου. Είναι ιδιαίτερα ισχυρός και μπορεί να αντιμετωπίσει το πρόβλημα της υπερεκπαίδευσης (overfitting), που είναι κοινό στα Decision Trees.

3. **Support Vector Machine (SVM)**: Αυτός ο αλγόριθμος προσπαθεί να βρει το καλύτερο όριο (υπερεπίπεδο) που διαχωρίζει διαφορετικές κατηγορίες δεδομένων. Χρησιμοποιείται συχνά σε προβλήματα ταξινόμησης και έχει υψηλή απόδοση σε μικρά και μεσαία σύνολα δεδομένων, αλλά η εκπαίδευσή του μπορεί να είναι πιο απαιτητική υπολογιστικά.
4. **Multilayer Perceptron (MLP)**: Πρόκειται για έναν τύπο τεχνητού νευρωνικού δικτύου, που αποτελείται από πολλαπλά επίπεδα νευρώνων. Είναι ένας αλγόριθμος βαθιάς μάθησης που χρησιμοποιείται σε πιο περίπλοκα προβλήματα ταξινόμησης και πρόβλεψης. Απαιτεί περισσότερη υπολογιστική ισχύ για την εκπαίδευσή του, αλλά μπορεί να αποδώσει εξαιρετικά σε δεδομένα υψηλής πολυπλοκότητας.
5. **k-Nearest Neighbor (k-NN)**: Ένας πιο απλός αλγόριθμος που ταξινομεί ένα δείγμα βάσει της εγγύτητάς του σε άλλα δείγματα. Είναι εύκολος στην εφαρμογή, αλλά δεν είναι πάντα αποτελεσματικός σε μεγάλα σύνολα δεδομένων ή σε περιπτώσεις όπου υπάρχει μεγάλη ποικιλία χαρακτηριστικών.

Η ανάλυση αυτών των αλγορίθμων μηχανικής μάθησης έχει ως στόχο να συγκριθούν οι επιδόσεις τους στην ακριβή ταξινόμηση των ανθρώπινων δραστηριοτήτων, ώστε να εντοπιστεί ποιος από αυτούς είναι ο πιο αποτελεσματικός για τη συγκεκριμένη βάση δεδομένων MHealth. Με τη σύγκριση των αλγορίθμων, είναι δυνατόν να αναδειχθούν τα ισχυρά και αδύναμα σημεία καθενός και να προσδιοριστεί ποιος είναι καταλληλότερος για την αναγνώριση πολύπλοκων κινήσεων, όπως οι δραστηριότητες που αφορούν λεπτές αλλαγές στην κίνηση και τη φυσική κατάσταση.

Το κύριο συμπέρασμα που προκύπτει από την σύγκριση των πέντε αυτών αλγορίθμων, του Decision Trees, Random Forest, Support Vector Machine, Multilayer Perceptron και k- Nearest Neighbor στην βάση δεδομένων MHealth είναι ότι το μεγαλύτερο ποσοστό ακρίβειας (Precision) πετυχαίνουν οι αλγόριθμοι Decision Trees (98,4%) και Random Forests(99,8%). Σε σχέση με τους υπόλοιπους αλγορίθμους είναι ξεκάθαρο πως οι δύο αυτοί αλγόριθμοι έχουν σημαντικά μεγαλύτερη ικανότητα στο να κάνουν διάκριση μεταξύ παρόμοιων δραστηριοτήτων (π.χ. χαλαρό τρέξιμο/ γρήγορο τρέξιμο και ανέβασμα σκάλας/ λύγισμα

γονάτων). Συμπληρωματικά, από τους δύο αλγόριθμους καλύτερα αποτελέσματα λαμβάνουμε από τον Random Forests.

Παράλληλα, παρατηρούμε ότι ενώ οι Decision Trees και Random Forests επιδεικνύουν εξαιρετική ακρίβεια, υπήρχαν ορισμένες κατηγορίες δραστηριοτήτων όπου και οι δύο αλγόριθμοι παρουσίασαν δυσκολίες στη διάκριση. Συγκεκριμένα, οι δραστηριότητες όπως το **χαλαρό τρέξιμο** και το **γρήγορο τρέξιμο** συχνά μπερδεύονταν, λόγω των παρόμοιων χαρακτηριστικών κίνησης που παρουσιάζουν. Επιπλέον, οι κατηγορίες **ανέβασμα σκάλας** και **λύγισμα γονάτων** αποτελούν άλλες δύο δραστηριότητες που συχνά ταξινομήθηκαν λανθασμένα, καθώς οι κινήσεις έχουν αρκετά κοινά στοιχεία, όπως η κίνηση των ποδιών και η αλλαγή ύψους του σώματος.

Από τους υπόλοιπους αλγόριθμους, οι **SVM** και **Multilayer Perceptron** παρουσίασαν μεγαλύτερη δυσκολία στις ίδιες κατηγορίες, με αρκετά μεγαλύτερο ποσοστό λανθασμένων ταξινομήσεων. Αυτό οφείλεται στο γεγονός ότι οι αλγόριθμοι αυτοί δεν διαχειρίστηκαν το ίδιο αποτελεσματικά τις διαφορές στα δεδομένα που αφορούν παρόμοιες δραστηριότητες, οδηγώντας σε περισσότερα σφάλματα. Αντίστοιχα, ο **k-Nearest Neighbor (k-NN)** αντιμετώπισε παρόμοιες προκλήσεις, με κύρια προβλήματα στις κατηγορίες όπως το **άλμα μπρος και πίσω**, όπου η κίνηση μπορεί να συγχέεται με άλλες δραστηριότητες που περιλαμβάνουν αλλαγή θέσης του σώματος.

Τα παραπάνω συμπεράσματα οδηγούν στο συμπέρασμα πως ο αλγόριθμος Random Forests λειτουργήσει αρκετά ικανοποιητικά στην επεξεργασία της βάσης δεδομένων MHealth για την πρόβλεψη των ανθρώπινων δραστηριοτήτων που ενεργοποιούνται από συγκεκριμένες δυνάμεις για την εκμάθηση χαρακτηριστικών δυνάμεων προσωρινής ενεργοποίησης και να κάνουν προβλέψεις στην ταξινόμηση των δεδομένων. Η αρχιτεκτονική του αλγόριθμου Random Forests προσφέρει καλύτερα χαρακτηριστικά ανάλυσης από τα άλλα πέντε μοντέλα ταξινόμησης. Ο αλγόριθμος αυτός επίσης προσδιορίζει τα ζωτικά σημεία και το εύρος κίνησης των δραστηριοτήτων με μεγαλύτερη ακρίβεια. Όλα αυτά τα ευρήματα λοιπόν οδηγούν στην υπόθεση ότι ο Random Forests είναι το μοντέλο με τις καλύτερες επιδόσεις και είναι εξαιρετικά κατάλληλο για την ανάλυση των δεδομένων MHealth.

5.2 Μελλοντικές έρευνες

Οι μελλοντικές επεκτάσεις της παρούσας εργασίας μπορούν να συμβάλλουν σημαντικά στην εξέλιξη της Αναγνώρισης Ανθρώπινης Κίνησης (HAR), ειδικά σε τομείς που σχετίζονται με την υγεία και την παρακολούθηση ασθενών. Η χρήση του αλγόριθμου Random Forests στην

επεξεργασία μεγάλων όγκων δεδομένων είναι εξαιρετικά χρήσιμη λόγω της ικανότητάς του να επιτυγχάνει υψηλή ακρίβεια στην ταξινόμηση ανθρώπινων δραστηριοτήτων. Ωστόσο, υπάρχουν αρκετές προκλήσεις και περιοχές που μπορούν να εξεταστούν περαιτέρω, προκειμένου να βελτιωθεί η απόδοση αυτών των συστημάτων.

Μια από τις βασικές κατευθύνσεις για μελλοντική έρευνα είναι η εφαρμογή της τεχνολογίας HAR σε πραγματικό χρόνο. Η επεξεργασία δεδομένων σε πραγματικό χρόνο είναι ζωτικής σημασίας για πολλές εφαρμογές στον τομέα της υγείας, όπως η παρακολούθηση ασθενών σε κρίσιμες καταστάσεις ή η πρόληψη ατυχημάτων σε ευπαθείς πληθυσμούς, όπως οι ηλικιωμένοι. Η ενσωμάτωση φορέσιμων συσκευών που συλλέγουν δεδομένα και τα αναλύουν σε πραγματικό χρόνο θα μπορούσε να ενισχύσει την ικανότητα των συστημάτων αυτών να προβλέπουν και να προλαμβάνουν επικίνδυνες καταστάσεις, όπως πτώσεις ή καρδιακά επεισόδια.

Μια ακόμη σημαντική επέκταση θα ήταν η αξιολόγηση της απόδοσης του Random Forests και άλλων αλγορίθμων σε πολυδιάστατα δεδομένα, που περιλαμβάνουν διαφορετικές πηγές πληροφορίας. Για παράδειγμα, η συνδυαστική χρήση αισθητήρων που καταγράφουν όχι μόνο κίνηση αλλά και ζωτικά σημεία, όπως καρδιακούς παλμούς ή επίπεδα οξυγόνου στο αίμα, θα μπορούσε να δώσει μια πιο ολοκληρωμένη εικόνα για την κατάσταση ενός ατόμου. Με αυτόν τον τρόπο, οι αλγόριθμοι θα μπορούσαν να χρησιμοποιηθούν για την πρόβλεψη κρίσιμων καταστάσεων υγείας με μεγαλύτερη ακρίβεια.

Μια ακόμη πιθανή κατεύθυνση θα ήταν η αξιολόγηση της απόδοσης του HAR σε διαφορετικά περιβάλλοντα και συνθήκες. Για παράδειγμα, οι αισθητήρες μπορεί να λειτουργούν με διαφορετική ακρίβεια ανάλογα με το περιβάλλον (εσωτερικός ή εξωτερικός χώρος), τις καιρικές συνθήκες ή την ενδυμασία του ατόμου. Η επέκταση της έρευνας σε τέτοιες συνθήκες θα μπορούσε να επιτρέψει την ανάπτυξη πιο ανθεκτικών και ευέλικτων συστημάτων που θα μπορούσαν να χρησιμοποιηθούν σε πραγματικές συνθήκες χωρίς περιορισμούς.

Η χρήση του HAR σε συνδυασμό με τεχνολογίες έξυπνων σπιτιών είναι επίσης μια προοπτική που μπορεί να εξεταστεί. Τα έξυπνα σπίτια, εξοπλισμένα με αισθητήρες που παρακολουθούν συνεχώς τις κινήσεις των κατοίκων, θα μπορούσαν να ενσωματώσουν την τεχνολογία HAR για την παρακολούθηση της υγείας και της ασφάλειας, ειδικά σε ηλικιωμένους ή άτομα με χρόνιες ασθένειες. Η χρήση αυτών των δεδομένων σε συνδυασμό με αλγόριθμους μηχανικής μάθησης θα μπορούσε να βοηθήσει στη βελτίωση της ποιότητας ζωής των ατόμων αυτών, μέσω της συνεχούς παρακολούθησης και της πρόληψης πιθανών επικίνδυνων καταστάσεων.

Τέλος, οι μελλοντικές επεκτάσεις θα μπορούσαν να εξετάσουν τη συνεργασία μεταξύ διαφορετικών τύπων αλγορίθμων. Ο Random Forests μπορεί να συνδυαστεί με άλλους αλγόριθμους, όπως τα νευρωνικά δίκτυα ή τα συστήματα βαθιάς μάθησης, προκειμένου να ενισχυθεί η ακρίβεια των προβλέψεων. Με τον συνδυασμό διαφορετικών μεθόδων, είναι πιθανό να επιτευχθούν καλύτερα αποτελέσματα, που θα ενισχύσουν περαιτέρω την ακρίβεια και την ταχύτητα της αναγνώρισης ανθρώπινης κίνησης σε πραγματικές συνθήκες.

Βιβλιογραφία

- Abdu Gumaei, M. M. (2019, August 7). A hybrid deep learning model for human activity recognition using multimodal body sensing data. *IEEE*.
- Abdul Kadar Masum, S. I. (2019, April 23-25). A statistical and deep learning approach for human activity recognition . *IEEE*.
- Abdul Kadar Muhammad Masum, E. H.-A.-A. (2019, July). Human Activity Recognition using accelerometer, gyroscope and magnetometer sensors: deep neural network approaches. *IEEE*.
- Ananda Mohon Ghosh, D. H. (2016). Remote health monitoring system through IoT. *IEEE Xplore*.
- Antonio Bevilacqua, K. M. (2019, January 18). Human activity recognition with convolutional neural networks. *SpringerLink*.
- B. Rosenhahn, R. K. (2008). *Human Motion*. Springer.
- Bahzad Taha Jijo, A. M. (2021). Classification based on decision tree algorithm for machine learning. *Journal of applied science and technology trends*.
- Breiman, L. (2001). Random Forest. Στο L. Breiman, *Machine Learning*.
- Brijain R Patel, K. K. (2016). A survey on decision tree algorithm for classification. *International Journal of Science and Research*.
- C J Caspersen, K. E. (1985). Physical activity, exercise and physical fitness definitions and distinctions for health- related research. *National Library of Medicine*.
- Derek A. Pisner, D. M. (2020). Support Vector Machine. *Science Direct*.
- E. A. Patrick, F. P. (1970). A generalized k- nearest neighbor rule. *Science Direct*.
- Ehab El-Adawi, E. E. (2024, February 1). Wireless body area sensor networks based human activity recognition using deep learning. *Scientific Reports*.
- Farhat Attal, S. M. (2015, December 11). Physical human activity recognition using wearable sensors. *MDPI*.
- Ferhat Attal, S. M. (2015, December 11). Physical human activity recognition using wearable sensors. *mdpi*.
- Gokhan Aksu, N. D. (2019). An analysis program used in data mining: WEKA. *Journal of Measurement and Evaluation in Education and Psychology*.
- Guangxin Huang, H. C. (2011). Two- class support vector data description. *Science Direct* .
- Gurjeet Singh, R. K. (2011, October). Daily sediment yield modeling with artificial neural network using 10- fold cross validation method: a small agricultural watershed, Kargari, India. *International Journal of Earth Sciences and Engineering*.
- Isakava, T. (2022, March 31). *A gentle introduction to human activity recognition*. Ανάκτηση από InData Labs: <https://indatalabs.com/blog/human-activity-recognition>
- Jamie o' Halloran, E. W. (2019). A comparison of deep learning models in human activity recognition and behavioural prediction on the MHEALTH Dataset. *Computer Science*.

- Lakmini P. Malasinghe, N. R. (2017, October 26). Remote patient monitoring: a comprehensive study. *Journal of ambient intelligence and humanized computing*.
- Loknath Sai Ambati, O. E.-G. (2021). Human Activity Recognition: A comparison of Machine Learning Approaches. *Journal of the Midwest Association for Information Systems*.
- Mariana Belgiu, L. D. (2016). Random Forestsin remote sensing: a review of applications and future directions. *Science Direct*.
- Marius- Constantin Popescu, V. E.-P. (2009). Multilayer Perceptron and Neural Networks. *WSEAS TRANSACTIONS on CIRCUITS and SYSTEMS*.
- MHealth Dataset*. (2014). Ανάκτηση από UC Irvine Machine Learning Repository: <https://archive.ics.uci.edu/dataset/319/mhealth+dataset>
- Michalis Vrigkas, C. N. (2015, November 16). A review of human activity recognition methods. *Frontiers*.
- Mohammed Al- Khafajiy, T. B. (2019, January 24). Remote health monitoring of elderly through wearable sensors. *Multimedia tools and applications*.
- Mohammed Al- khafajiy, T. B. (2019, January 24). Remote health monitoring of elderly through wearable sensors. *Springer Link*.
- mTelehealth*. (2020, March). Ανάκτηση από <https://mtelehealth.com/hospitals-turn-to-remote-monitoring-tools-to-free-up-beds-for-the-sickest-coronavirus-patients/>
- Mu- Hsing Kuo, S. L.-T. (2016). Using information and mobile technology improved elderly home care services. *SCIENCE DIRECT- ELSEVIER*.
- Muhammed Ali Kutlay, S. G.-P. (2015, September 2). Application of machine learning in healthcare: analysis on MHEALTH Dataset. *Southeast Europe Journal of Soft Computing*.
- N. C. Sri Harsha, Y. G. (2021, July 6). Performance analysis of machine learning algorithms for smartphone- based human activity recognition. *Springer*.
- Nurul Amin Choudhury, B. S. (2023, September 21). In- depth analysis of design and development for sensor- based human activity recognition system. *Springer*.
- Oresti Banos, R. G.-T. (2014). mHealthDroid: A novel Framework for Agile Development of Mobile Health Applications. *Springer International Publishing*.
- Peterson, L. E. (2009). *K- Nearest Neighbor*. Ανάκτηση από scholarpedia: http://scholarpedia.org/article/K-nearest_neighbor
- Regina Guthhold, G. A. (2020, January). Global trends in insufficient physical activity among adolescents: a pooled analysis of 298 population- based surveys with 1-6 million participants. *THE LANCET CHILD & ADOLESCENT HELTH*.
- Seyed Matin Malakouti, M. B. (2023, August). The usage of 10- fold cross- validation and grid search to enhance ML methods performance is solar farm power generation prediction. *Science Direct- Elsevier*.
- Sumit Majumder, T. M. (2017, January 12). Wearable sensors for remote health monitoring. *MDPI*.
- Tessa Strain, S. F. (2024, August). National, regional and global trends in insufficient physical activity among adults from 2000 to 2022: a pooled analysis of 507 population- based surveys with 5-7 million participants. *THE LANCET GLOBAL HEALTH*.

WHO. (2015). Ανάκτηση από iris.who.:
https://iris.who.int/bitstream/handle/10665/326801/EMROPUB_2015_EN_1901.pdf

WHO. (2022, October 5). Ανάκτηση από WORLD HEALTH ORGANIZATION:
<https://www.who.int/news-room/fact-sheets/detail/physical-activity>

Υποστήριξη *Vector Machines*. (χ.χ.). Ανάκτηση από scikit-learn: <https://scikit-learn.org/stable/modules/svm.html>

Φαφούτη, Λ. (2013). Η ιδιοφυής ανατομία του Λεονάρντο ντα Βίντσι . *ΤΟ ΒΗΜΑ*.