



ΠΡΟΓΡΑΜΜΑ ΜΕΤΑΠΤΥΧΙΑΚΩΝ ΣΠΟΥΔΩΝ
ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΔΙΚΤΥΩΝ
ΠΑΝΕΠΙΣΤΗΜΙΟ ΙΩΑΝΝΙΝΩΝ




ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ & ΤΗΛΕΠΙΚΟΙΝΩΝΙΩΝ
ΣΧΟΛΗ ΠΛΗΡΟΦΟΡΙΚΗΣ & ΤΗΛΕΠΙΚΟΙΝΩΝΙΩΝ
ΠΑΝΕΠΙΣΤΗΜΙΟ ΙΩΑΝΝΙΝΩΝ

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ ΜΕΤΑΠΤΥΧΑΙΚΟΥ ΠΡΟΓΡΑΜΜΑΤΟΣ

**«Αναγνώριση Ανθρώπινης Δραστηριότητας μέσω Ανάλυσης Δεδομένων
από Φορέσιμους Αισθητήρες με Αλγορίθμους Μηχανικής Μάθησης»**

Παναγιώτα Βίννη

A.M. : 170



Επιβλέπων: Τζάλλας Αλέξανδρος

Άρτα, Μάρτιος, 2025



**Πρόγραμμα Μεταπτυχιακών Σπουδών «Πληροφορικής και
Δικτύων» Τμήμα Πληροφορικής και Τηλεπικοινωνιών
Πανεπιστήμιο Ιωαννίνων**

**«Αναγνώριση Ανθρώπινης Δραστηριότητας μέσω
Ανάλυσης Δεδομένων από Φορέσιμους
Αισθητήρες με Αλγορίθμους Μηχανικής
Μάθησης»**

Παναγιώτα Βίννη

A.M. : 170

Επιβλέπων: Τζάλλας Αλέξανδρος

Άρτα, Μάρτιος, 2025



**“Human Activity Recognition Using Wearable Sensor
Data and Machine Learning Algorithms”**



Εγκρίθηκε από τριμελή εξεταστική επιτροπή

Άρτα, 28 /03 /2025

ΕΠΙΤΡΟΠΗ ΑΞΙΟΛΟΓΗΣΗΣ

1. Επιβλέπων καθηγητής
Αλέξανδρος Τζάλλας
2. Μέλος επιτροπής
Νικόλαος Γιαννακέας
3. Μέλος επιτροπής
Ιωάννης Τσούλος



© Βίννη, Παναγιώτα, 2025.

Με επιφύλαξη παντός δικαιώματος. All rights reserved.



Δήλωση μη λογοκλοπής

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

Βίννη, Παναγιώτα



Ευχαριστίες

Θα ήθελα να ευχαριστήσω τον επιβλέποντα καθηγητή μου κ. Τζάλλα Αλέξανδρο (Καθηγητή), για την καθοδήγηση που μου προσέφερε και το χρόνο που διέθεσε δίνοντάς μου χρήσιμες συμβουλές και οδηγίες για την ολοκλήρωση της διπλωματικής μου εργασίας. Στο ίδιο πλαίσιο ευγνωμοσύνης, θα ήθελα να ευχαριστήσω την οικογένεια και τους φίλους μου, οι οποίοι στάθηκαν σημαντικοί αρωγοί στην προσπάθειά μου και μου προσέφεραν αμέριστη υποστήριξη και καθοδήγηση σε κάθε φάση της πορείας μου.



Περίληψη

Η Αναγνώριση Αθρώπινης Δραστηριότητας (HAR) είναι ένας ταχέως εξελισσόμενος τομέας που αξιοποιεί δεδομένα αισθητήρων και αλγορίθμους μηχανικής μάθησης για την ταξινόμηση και ανάλυση ανθρώπινων κινήσεων. Με την εξάπλωση των φορητών αισθητήρων και των έξυπνων συσκευών, η HAR έχει βρει εκτεταμένες εφαρμογές στην υγειονομική περίθαλψη, την παρακολούθηση της φυσικής κατάστασης, τη φροντίδα ηλικιωμένων και την αλληλεπίδραση ανθρώπου-υπολογιστή. Η παρούσα διατριβή διερευνά το HAR χρησιμοποιώντας δεδομένα που συλλέγονται από φορητούς αισθητήρες και εφαρμόζει διάφορους αλγορίθμους μηχανικής μάθησης για την ταξινόμηση ανθρώπινων δραστηριοτήτων. Συγκεκριμένα, χρησιμοποιήθηκαν τα σύνολα δεδομένων MHEALTH και WISDM, τα οποία υποβλήθηκαν σε ενδελεχή προεπεξεργασία, εξαγωγή χαρακτηριστικών και ταξινόμηση στο περιβάλλον Weka. Έξι μοντέλα μηχανικής μάθησης - το Δέντρο Αποφάσεων, το Τυχαίο Δάσος, η Μηχανή Διανυσμάτων Υποστήριξης (SVM), οι k-κοντινότεροι γείτονες (k-NN), ο Naive Bayes και τα Συνελικτικά Νευρωνικά Δίκτυα (CNN) - αξιολογήθηκαν με τη χρήση 10 Fold Cross Validation. Οι επιδόσεις ταξινόμησης αξιολογήθηκαν μέσω πολλαπλών μετρικών αξιολόγησης, ενώ τα αποτελέσματα απεικονίστηκαν περαιτέρω μέσω heatmaps, Precision – Recall Curves, ROC Curves και Learning Curves για να αποκτήσουν εικόνα της απόδοσης του μοντέλου. Πραγματοποιήθηκε συγκριτική ανάλυση μεταξύ των δύο συνόλων δεδομένων για τον προσδιορισμό του πιο αποτελεσματικού ταξινομητή για το HAR. Τα ευρήματα δείχνουν ότι το Random Forest και το CNN παρουσίασαν ανώτερες επιδόσεις όσον αφορά την ακρίβεια και την ανθεκτικότητα. Τα αποτελέσματα αυτά συμβάλλουν στην πρόοδο των μεθοδολογιών HAR και αναδεικνύουν τις δυνατότητες της μηχανικής μάθησης στην ανάλυση δεδομένων φορητών αισθητήρων.

Λέξεις-κλειδιά: Αναγνώριση Ανθρώπινης Δραστηριότητας, Φορέσιμοι Αισθητήρες, Ανάλυση Δεδομένων, Αλγόριθμοι Μηχανικής Μάθησης



Abstract

Human activity recognition (HAR) is a rapidly evolving field that leverages sensor data and machine learning algorithms to classify and analyse human movements. With the proliferation of wearable sensors and smart devices, HAR has found extensive applications in healthcare, fitness monitoring, elderly care, and human-computer interaction. This thesis explores HAR using data collected from wearable sensors and applies various machine learning algorithms to classify human activities. Specifically, the MHEALTH and WISDM datasets were used, which were subjected to thorough pre-processing, feature extraction and classification in the Weka environment. Six machine learning models - Decision Tree, Random Forest, Support Vector Machine (SVM), k-Nearest Neighbors (k-NN), Naive Bayes and Convolutional Neural Networks (CNN) - were evaluated using 10 Fold Cross Validation. Classification performance was evaluated through multiple evaluation metrics, and the results were further visualized through heatmaps, Precision - Recall Curves, ROC Curves and Learning Curves to gain insight into model performance. A comparative analysis was performed between the two datasets to determine the most effective classifier for HAR. The findings show that Random Forest and CNN performed superior in terms of accuracy and robustness. These results contribute to the advancement of HAR methodologies and highlight the potential of machine learning in wearable sensor data analysis.

Keywords: Human Activity Recognition, Wearable Sensors, Data Analysis, Machine Learning Algorithms

Πίνακας Περιεχομένων

Ευχαριστίες.....	7
Περίληψη	8
Abstract.....	9
Πίνακας Περιεχομένων	10
Κατάλογος Εικόνων	14
Κατάλογος Πινάκων	17
Πίνακας Συντομογραφιών	18
Εισαγωγή	19
1. Αναγνώριση Ανθρώπινης Δραστηριότητας (HAR).....	20
1.1. Ορισμός και Σημασία της HAR	20
1.2. Ιστορική Εξέλιξη της HAR	22
1.3. Εφαρμογές της HAR στην υγεία και στην καθημερινή ζωή	25
1.4. Τεχνολογίες – Μέσα – Συσκευές της HAR.....	33
2. Τεχνολογίες Φορέσιμων Αισθητήρων	36
2.1 Φορέσιμοι Αισθητήρες: Είδη και Χρήσεις.....	36
2.2.1 Επιταχυνσίόμετρα (Accelerometers).....	37
2.2.2 Γυροσκόπια (Gyroscopes).....	39
2.2.3 Καταγραφείς ζωτικών σημάτων (ΗΚΓ κ.λπ.) {Vital Sign Recorders (e.g., ECG) }	41
2.2 Επισκόπηση των Δεδομένων που Συλλέγονται από Φορέσιμους Αισθητήρες...	42
2.3 Προκλήσεις στη Συλλογή και Επεξεργασία Δεδομένων από Φορέσιμους Αισθητήρες	45
3. Βιβλιογραφική Ανασκόπηση (Literature Review).....	48
3.1 Μηχανές και Ερώτημα Αναζήτησης	48



3.2	Διάγραμμα PRISMA	48
3.3	Εξαγωγή Αποτελεσμάτων	51
4.	Μηχανική Μάθηση για Αναγνώριση Ανθρώπινης Δραστηριότητας	56
4.1	Θεωρητικό Υπόβαθρο Αλγορίθμων Μηχανικής Μάθησης	56
4.1.1	Στατιστική Μοντελοποίηση και Μηχανική Μάθηση (Statistical Modeling) ..	57
4.1.2	Υπερβλεπόμενη και Μη Ελεγχόμενη Μάθηση (Supervised and Unsupervised Learning).....	58
4.2	Επιλογή Αλγορίθμων για την Αναγνώριση Δραστηριότητας	60
4.2.1	Decision Tree	61
4.2.2	Random Forest	62
4.2.3	SVM	64
4.2.4	K-Nearest Neighbors (K-NN)	66
4.2.5	Naive Bayes.....	68
4.2.6	Neural Networks – CNN	70
4.3	Εξάσκηση και Αξιολόγηση των Μοντέλων (Training and Evaluation of the Models).....	72
4.3.1	Τεχνικές Διασταύρωσης (Cross-validation).....	73
4.3.2	Μετρικές Αξιολόγησης (Accuracy, Precision, Recall, F1 Score).....	75
4.3.2.1	Accuracy.....	75
4.3.2.2	Precision	77
4.3.2.3	Recall.....	78
4.3.2.4	F1 Score.....	79
4.3.2.5	Confusion Matrix	80
5.	Ανάλυση Δεδομένων και Προεπεξεργασία	83
5.1	Σύνολα Δεδομένων που χρησιμοποιήθηκαν	83
5.1.1	MHEALTH Dataset	84
5.1.2	WISDM Dataset	85



5.2	Προεπεξεργασία Δεδομένων	87
5.2.1	Καθαρισμός δεδομένων (Data Cleaning)	88
5.2.2	Τεχνικές Εξόρυξης Χαρακτηριστικών	89
5.2.3	Επεξήγηση της πλατφόρμας WEKA	89
5.2.4	Διαχωρισμός Training και Test Set Δεδομένων στο WEKA	91
5.3	Διαδικασία ταξινόμησης στο WEKA (Classification Process)	94
5.3.1	Εισαγωγή του συνόλου δεδομένων στο Weka	94
5.3.2	Προετοιμασία για την Διαδικασία της Ταξινόμησης	94
5.3.3	Εκπαίδευση και Αξιολόγηση των Μοντέλων	96
5.3.4	Αποτελέσματα Ταξινόμησης για το mHealth	98
5.5.5	Αποτελέσματα Ταξινόμησης για το WISDM	104
5.5.6	Εξαγωγή Αποτελεσμάτων για Οπτικοποίηση	110
6.	Αποτελέσματα, Σύγκριση και Συζήτηση	112
6.1	Οπτικοποίηση Αποτελεσμάτων για το mHEALTH	112
6.1.1	Heatmaps Πινάκων Σύγκρισης όλων των μοντέλων	112
6.1.2	Precision- Recall και ROC Curves όλων των μοντέλων	115
6.1.3	Οπτικοποίηση της Απόδοσης των Μετρικών όλων των μοντέλων	119
6.1.4	Συγκριτική ανάλυση ROC Curve όλων των μοντέλων	119
6.1.5	Καμπύλες Εκμάθησης (Learning Curves) όλων των μοντέλων	120
6.1.6	Συγκριτική ανάλυση των επιδόσεων των μοντέλων του mHealth	122
6.1.7	Συζήτηση και συμπέρασμα σχετικά με το καλύτερο μοντέλο για το mHealth	122
6.2	Οπτικοποίηση Αποτελεσμάτων για το WISDM	123
6.2.1	Heatmaps Πινάκων Σύγκρισης όλων των μοντέλων	123
6.2.2	Precision- Recall και ROC Curves όλων των μοντέλων	126
6.2.3	Οπτικοποίηση της Απόδοσης των Μετρικών όλων των μοντέλων	130
6.2.4	Συγκριτική ανάλυση ROC Curve όλων των μοντέλων	131



6.2.5	Καμπύλες Εκμάθησης (Learning Curves) όλων των μοντέλων.....	132
6.2.6	Συζήτηση και συμπέρασμα σχετικά με το καλύτερο μοντέλο για το mHealth	134
6.3	Συγκριτική Ανάλυση των Επιδόσεων των Μοντέλων και για τα δύο Datasets	134
6.3.1	Heatmap των Μετρικών για το mHealth Dataset.....	135
6.3.2	Heatmap των Μετρικών για το WISDM Dataset.....	136
6.3.3	Σύγκριση χρόνου εκπαίδευσης μοντέλου (Training Time Model) και για τα δύο Datasets	137
6.4	Συμπέρασμα σχετικά με την απόδοση του μοντέλου και για τα δύο Datasets .	139
7.	Συμπεράσματα	140
	Βιβλιογραφία.....	142
	Πηγές Εικόνων	151



Κατάλογος Εικόνων

Εικόνα 1: Η εξέλιξη της HAR στον χρόνο (2008-2020).....	25
Εικόνα 2: Εξατομικευμένη Παρακολούθηση της Υγείας	26
Εικόνα 3: Παρακολούθηση Φυσικής Κατάστασης	27
Εικόνα 4: Ανίχνευση Πτώσης	28
Εικόνα 5: Αλληλεπίδραση Ανθρώπου - Υπολογιστή (HCI)	29
Εικόνα 6: Ανάλυση Αθλητικών Επιδόσεων	30
Εικόνα 7: Ψυχολογία και Τηλεϊατρική.....	30
Εικόνα 8: Παιχνίδια – Gaming	31
Εικόνα 9: Internet of Things (IoT)	32
Εικόνα 10: Self- Driving Αυτοκίνητα	32
Εικόνα 11: Οι Αισθητήρες του HAR.....	34
Εικόνα 12: Συσκευές της HAR	35
Εικόνα 13: Ταξινόμηση των Φορητών Αισθητήρων για την Παρακολούθηση Δραστηριοτήτων.....	37
Εικόνα 14: Άξονες Επιταχυνσιόμετρων	38
Εικόνα 15: Γυροσκόπιο	40
Εικόνα 16: Holter Monitor με ECG καταγραφή	42
Εικόνα 17: Φορητές συσκευές και οι θέσεις τους στο ανθρώπινο σώμα.....	44
Εικόνα 18: Προκλήσεις Φορέσιμων Αισθητήρων	47
Εικόνα 19: Διάγραμμα PRISMA για την Βιβλιογραφική Ανασκόπηση.....	50
Εικόνα 20: Στατιστική Μοντελοποίηση και Μηχανική Μάθηση	57
Εικόνα 21: Διαφορά Unsupervised / Supervised Μάθησης.....	59
Εικόνα 22: Σχεδιασμός ενός Decision Tree	61
Εικόνα 23: Σχεδιασμός ενός Random Forest	63
Εικόνα 24: Διάγραμμα Απεικόνισης SVM.....	66
Εικόνα 25: Διάγραμμα Απεικόνισης K-NN	67
Εικόνα 26: Σχεδιασμός Naive Bayes.....	69
Εικόνα 27: Απεικόνιση Νευρωνικών Δικτύων (CNN)	70
Εικόνα 28: Αρχιτεκτονική της k Fold Cross Validation	73
Εικόνα 29: Ανάλυση ενός Πίνακα Σύγκρισης.....	82



Εικόνα 30: To Framework της HAR.....	83
Εικόνα 31: Confusion Matrix Heatmap for Decision Tree Model	Εικόνα 32:
Confusion Matrix Heatmap for Random Forest Model	113
Εικόνα 33: Confusion Matrix Heatmap for SVM Model	Εικόνα 34:
Confusion Matrix Heatmap for k-NN Model.....	113
Εικόνα 35: Confusion Matrix Heatmap for Naive Bayes Model	Εικόνα
36: Confusion Matrix Heatmap for CNN Model	113
Εικόνα 37: Precision-Recall Curve and ROC Curve for Decision Tree Model.....	115
Εικόνα 38: Precision-Recall Curve and ROC Curve for Random Forest Model.....	116
Εικόνα 39: Precision-Recall Curve and ROC Curve for SVM Model.....	116
Εικόνα 40: Precision-Recall Curve and ROC Curve for k-NN Model	117
Εικόνα 41: Precision-Recall Curve and ROC Curve for Naive Bayes Model	117
Εικόνα 42: Precision-Recall Curve and ROC Curve for CNN Model	117
Εικόνα 43: Metrics Values for all Models (Accuracy, Precision, Recall, F1Score)	119
Εικόνα 44: ROC Curve for all the 6 Models.....	120
Εικόνα 45: Learning Curve for Decision Tree Model	Εικόνα 46:
Learning Curve for Random Forest Model	121
Εικόνα 47: Learning Curve for SVM Model	Εικόνα 48:
Learning Curve for k-NN Model	121
Εικόνα 49: Learning Curve for Naive Bayes Model	Εικόνα 50:
Learning Curve for CNN Model	122
Εικόνα 51: Confusion Matrix Heatmap for Decision Tree Model	Εικόνα 52:
Confusion Matrix Heatmap for Random Forest Model	124
Εικόνα 53: Confusion Matrix Heatmap for SVM Model	Εικόνα 54:
Confusion Matrix Heatmap for k-NN Model.....	124
Εικόνα 55: Confusion Matrix Heatmap for Naive Bayes Model	Εικόνα 56: Confusion
Matrix Heatmap for CNN Model	125
Εικόνα 57: Precision-Recall Curve and ROC Curve for Decision Tree Model.....	127
Εικόνα 58: Precision-Recall Curve and ROC Curve for Random Forest Model.....	127
Εικόνα 59: Precision-Recall Curve and ROC Curve for SVM Model.....	128
Εικόνα 60: Precision-Recall Curve and ROC Curve for k-NN Model	128
Εικόνα 61: Precision-Recall Curve and ROC Curve for Naive Bayes Model	129
Εικόνα 62: Precision-Recall Curve and ROC Curve for CNN Model	129



Εικόνα 63: Metrics Values for all Models (Accuracy, Precision, Recall, F1Score)	131
Εικόνα 64: ROC Curve for all the 6 Models	132
Εικόνα 65: Learning Curve for Decision Tree Model	Εικόνα 66: Learning Curve for Random Forest Model
Εικόνα 67: Learning Curve for SVM Model	Εικόνα 68: Learning Curve for k-NN Model.....
Εικόνα 69: Learning Curve for Naive Bayes Model	Εικόνα 70: Learning Curve for CNN Model
Εικόνα 71: Heatmap Classification Metrics for all Model	136
Εικόνα 72: Heatmap Classification Metrics for all Models WISDM Dataset.....	137
Εικόνα 73: Time Taken Comparison.....	138



Κατάλογος Πινάκων

Πίνακας 1: Πίνακας Λεπτομερειών Βιβλιογραφικής Ανασκόπησης.....	51
Πίνακας 2: Σύνοψη των διαφόρων datasets για τις τάξεις τους, τους συμμετέχοντες και το καταγεγραμμένο σύνολο δραστηριοτήτων.	87
Πίνακας 3: Πλεονεκτήματα και Μειονεκτήματα Μεθόδων Διαχωρισμού Δεδομένων.....	93
Πίνακας 4: Αποτελέσματα Decision Tree για το mHealth Dataset	98
Πίνακας 5: Αποτελέσματα Random Forest για το mHealth Dataset	99
Πίνακας 6: Αποτελέσματα SVM για το mHealth Dataset	100
Πίνακας 7: Αποτελέσματα kNN για το mHealth Dataset	100
Πίνακας 8: Αποτελέσματα Naive Bayes για το mHealth Dataset.....	101
Πίνακας 9: Αποτελέσματα Neural Networks για το mHealth Dataset.....	101
Πίνακας 10: Αποτελέσματα Decision Tree για το WISDM Dataset	105
Πίνακας 11: Αποτελέσματα Random Forest για το WISDM Dataset	105
Πίνακας 13: Αποτελέσματα SVM για το WISDM Dataset	106
Πίνακας 14: Αποτελέσματα k-NN για το WISDM Dataset.....	107
Πίνακας 15: Αποτελέσματα Naive Bayes για το WISDM Dataset.....	107
Πίνακας 16: Αποτελέσματα CNN για το WISDM Dataset.....	108



Πίνακας Συντομογραφιών

AI:		Artificial Intelligence
DL:		Deep Learning
ML:		Machine Learning
CNN:		Convolutional Neural Network
RNN:		Convolutional Neural Network
HAR:		Human Activity Recognition
NN:		Neural Network
RF:		Random Forrest
SVM:		Support Vector Machine
NB:		Naïve Bayes
K-NN:		K Nearest Neighbors
ADL:		Activities Daily Living
WISDM:		Wireless Sensor Data Mining
mHealth:		mobile Health
ECG:		Electrocardiogram
PCA:		Principal Component Analysis
ROC:		Receiver operating characteristic
TP:		True Positive
TN:		True Negative
FP:		False Positive
FN:		False Negative



Εισαγωγή

Η ταχεία ανάπτυξη των έξυπνων φορητών συσκευών και αισθητήρων έχει οδηγήσει σε σημαντικές εξελίξεις στον τομέα της Αναγνώρισης Ανθρώπινης Δραστηριότητας (HAR). Η HAR περιλαμβάνει την αυτόματη ανίχνευση και ταξινόμηση ανθρώπινων δραστηριοτήτων με βάση δεδομένα αισθητήρων που συλλέγονται από φορητές συσκευές. Η ικανότητα ακριβούς ταξινόμησης των δραστηριοτήτων έχει πολυάριθμες εφαρμογές στην υγειονομική περίθαλψη, την παρακολούθηση της φυσικής κατάστασης, την αποκατάσταση και την αλληλεπίδραση ανθρώπου-υπολογιστή.

Η παρούσα διατριβή διερευνά την εφαρμογή των αλγορίθμων μηχανικής μάθησης στη HAR αναλύοντας δύο γνωστά σύνολα δεδομένων: MHEALTH και WISDM. Η μελέτη επικεντρώνεται στην επεξεργασία ακατέργαστων δεδομένων αισθητήρων, στην εξαγωγή σημαντικών χαρακτηριστικών και στην εφαρμογή διαφόρων μοντέλων ταξινόμησης για τον προσδιορισμό της πιο αποτελεσματικής τεχνικής μηχανικής μάθησης για το HAR. Η διαδικασία ταξινόμησης πραγματοποιήθηκε με τη χρήση του Weka, ενός ευρέως χρησιμοποιούμενου λογισμικού μηχανικής μάθησης, ώστε να εξασφαλιστεί μια συνεπής και συστηματική αξιολόγηση των διαφόρων μοντέλων.

Οι πρωταρχικοί στόχοι αυτής της έρευνας είναι: (1) η προεπεξεργασία και ο καθαρισμός των συνόλων δεδομένων HAR για την εξασφάλιση υψηλής ποιότητας δεδομένων εισόδου, (2) η εξαγωγή σχετικών χαρακτηριστικών που συμβάλλουν στην ακριβή ταξινόμηση, (3) να εφαρμοστούν και να συγκριθούν έξι ταξινομητές μηχανικής μάθησης -Δέντρο Αποφάσεων, Τυχαίο Δάσος, SVM, k-NN, Naïve Bayes και CNN- για να εκτιμηθεί η απόδοσή τους, και (4) να οπτικοποιηθεί και να ερμηνεύσει τα αποτελέσματα χρησιμοποιώντας μετρικές αξιολόγησης και γραφικές αναπαραστάσεις. Πραγματοποιώντας συγκριτική ανάλυση μεταξύ των δύο συνόλων δεδομένων, η παρούσα έρευνα αποσκοπεί στον εντοπισμό του πιο αποτελεσματικού μοντέλου για το HAR και στην παροχή πληροφοριών σχετικά με τα πλεονεκτήματα και τους περιορισμούς των διαφόρων προσεγγίσεων ταξινόμησης.



1. Αναγνώριση Ανθρώπινης Δραστηριότητας (HAR)

Η Αναγνώριση Ανθρώπινης Δραστηριότητας (HAR) είναι ένας ταχέως εξελισσόμενος τομέας που επικεντρώνεται στον εντοπισμό και την ταξινόμηση ανθρώπινων κινήσεων με βάση δεδομένα που συλλέγονται από διάφορους αισθητήρες. Αξιοποιώντας φορητές συσκευές, smartphones και αισθητήρες περιβάλλοντος, τα συστήματα HAR μπορούν να παρακολουθούν και να αναλύουν δραστηριότητες όπως το περπάτημα, το τρέξιμο, το κάθισμα ή πιο σύνθετες κινήσεις. Η τεχνολογία αυτή διαδραματίζει κρίσιμο ρόλο στην παρακολούθηση της υγείας, στην ανάλυση αθλητικών επιδόσεων, στη φροντίδα ηλικιωμένων και στον αυτοματισμό έξυπνων σπιτιών, επιτρέποντας πιο εξατομικευμένη και έξυπνη αλληλεπίδραση μεταξύ ανθρώπων και μηχανών.

Πώς όμως εξελίχθηκε η HAR με την πάροδο του χρόνου και ποιες είναι οι σημαντικότερες εφαρμογές της στην καθημερινή ζωή και την υγειονομική περίθαλψη; Ποιες είναι οι βασικές τεχνολογίες και συσκευές που επιτρέπουν την ακριβή αναγνώριση δραστηριοτήτων; Οι ακόλουθες ενότητες θα διερευνήσουν αυτές τις πτυχές, παρέχοντας μια βαθύτερη κατανόηση της εξέλιξης της HAR, των εφαρμογών και των τεχνολογικών εξελίξεων που οδηγούν στην επιτυχία της.

1.1. Ορισμός και Σημασία της HAR

Η αναγνώριση ανθρώπινης δραστηριότητας (HAR) αναφέρεται στη διαδικασία ταξινόμησης χειρονομιών, κινήσεων του σώματος ή συμπεριφορών και πρόβλεψης καταστάσεων δραστηριότητας μέσω υπολογιστικών τεχνικών. Η HAR επιτυγχάνεται με την ανάλυση δεδομένων που παράγονται από αισθητήρες που φοριούνται, όπως επιταχυνσιόμετρα, γυροσκόπια και μαγνητόμετρα. Αυτοί οι αισθητήρες καταγράφουν αδρανειακά δεδομένα που μπορούν να χρησιμοποιηθούν για τον προσδιορισμό των δραστηριοτήτων καθημερινής διαβίωσης, οι οποίες επικεντρώνονται κυρίως στην κινητικότητα και την αλληλεπίδραση ενός ατόμου με το περιβάλλον του.

Τα τελευταία χρόνια, η HAR με βάση τους αισθητήρες έχει αποκτήσει εξέχουσα θέση στην έρευνα λόγω των αυξανόμενων δυνατοτήτων συγχώνευσης αισθητήρων. Η συγχώνευση



αισθητήρων συνδυάζει δεδομένα από πολλαπλές πηγές για να ενισχύσει την αξιοπιστία, την ακρίβεια και την πληρότητα της αναγνώρισης δραστηριοτήτων. Αυτό έχει καταστήσει την HAR ακρογωνιαίο λίθο για την ανάπτυξη καινοτόμων εφαρμογών στην υγειονομική περίθαλψη, τα έξυπνα σπίτια και τις υποστηρικτικές τεχνολογίες.

Η HAR λειτουργεί ως υποσύνολο της αναγνώρισης προτύπων, όπου οι αλγόριθμοι επεξεργάζονται ακατέργαστα δεδομένα για να ανιχνεύσουν πρότυπα και να κατηγοριοποιήσουν τις ανθρώπινες δραστηριότητες. Παρά τις πολλά υποσχόμενες δυνατότητές της, η HAR παραμένει ένα δύσκολο πρόβλημα λόγω των ατομικών παραλλαγών στην εκτέλεση της ίδιας δραστηριότητας. Οι διαφορές στα στυλ κίνησης μεταξύ των ατόμων μπορούν να περιπλέξουν τα μοντέλα πρόβλεψης, καθιστώντας αναγκαίες ισχυρές και γενικευμένες λύσεις [1].

Η σημασία του HAR επεκτείνεται πέρα από τις τεχνικές προκλήσεις. Η ικανότητά της να παρακολουθεί, να αναλύει και να προβλέπει την ανθρώπινη κίνηση έχει οδηγήσει σε εξελίξεις σε διάφορους τομείς. Για παράδειγμα, στην υγειονομική περίθαλψη, η HAR υποστηρίζει την εξ αποστάσεως παρακολούθηση ασθενών, την αποκατάσταση και την ανίχνευση πτώσεων για ηλικιωμένους. Στην καθημερινή ζωή, βοηθά στην παρακολούθηση της φυσικής κατάστασης, στην ανάλυση του τρόπου ζωής και στην ανάπτυξη έξυπνων περιβαλλόντων. Ερμηνεύοντας την ανθρώπινη συμπεριφορά και μεταφράζοντάς την σε αξιοποιήσιμες γνώσεις, το HAR έχει γίνει αναπόσπαστο μέρος της δημιουργίας ευφών συστημάτων που βελτιώνουν την ανθρώπινη ζωή.

Τα συστήματα HAR βασίζονται γενικά σε δύο κύριες προσεγγίσεις: αναγνώριση με βάση αισθητήρες και αναγνώριση με βάση την όραση. Η αναγνώριση βάσει αισθητήρων απαιτεί από τα άτομα να φορούν συσκευές που συλλέγουν δεδομένα κίνησης, ενώ η αναγνώριση βάσει όρασης βασίζεται στην ανάλυση βίντεο ή εικόνας για την ερμηνεία των δραστηριοτήτων. Και οι δύο προσεγγίσεις παράγουν δεδομένα που επεξεργάζονται με αλγόριθμους μηχανικής μάθησης για τον εντοπισμό και την κατηγοριοποίηση των ανθρώπινων ενεργειών.

Η αναγνώριση ανθρώπινων δραστηριοτήτων συνίσταται στην ερμηνεία ανθρώπινων χειρονομιών ή κινήσεων μέσω αισθητήρων για τον προσδιορισμό της ανθρώπινης δράσης ή δραστηριότητας. Για παράδειγμα, ένα σύστημα HAR μπορεί να αναφέρει δραστηριότητες που εκτελούνται από ασθενείς εκτός νοσοκομειακών εγκαταστάσεων, γεγονός που το



καθιστά χρήσιμο εργαλείο για την αξιολόγηση των παρεμβάσεων υγείας και της προόδου της θεραπείας, καθώς και για τη λήψη κλινικών αποφάσεων. Το HAR μπορεί να είναι εποπτευόμενο (supervised) ή μη εποπτευόμενο (unsupervised). Το εποπτευόμενο σύστημα HAR απαιτεί προηγούμενη εκπαίδευση με ένα σύνολο δεδομένων με ετικέτες, αντίθετα, το σύστημα χωρίς εποπτεία δεν απαιτεί εκπαίδευση αλλά διαθέτει ένα σύνολο κανόνων που διαμορφώνονται κατά την ανάπτυξη. Στη συγκεκριμένη εργασία, έγινε εστίαση σε ένα σύστημα HAR εποπτευόμενου τύπου για την αναγνώριση των ακόλουθων έξι ανθρώπινων δραστηριοτήτων: περπάτημα (WK), ανέβασμα σκάλας (WU), κατέβασμα σκάλας (WD), ορθοστασία (ST), ξάπλωμα (LD) και κάθισμα (SD). Περισσότερες λεπτομέρειες θα αναλυθούν σε μετέπειτα κεφάλαια [2].

1.2. Ιστορική Εξέλιξη της HAR

Η εξέλιξη της HAR έχει διαμορφωθεί από τις εξελίξεις στην πληροφορική, την τεχνολογία αισθητήρων και τη μηχανική μάθηση. Αρχικά, τα συστήματα HAR βασίζονταν σε παραδοσιακές τεχνικές επεξεργασίας εικόνας, χρησιμοποιώντας κάμερες και όραση υπολογιστή (computer vision) για την ταξινόμηση δραστηριοτήτων με βάση οπτικά στοιχεία. Αυτές οι μέθοδοι, ενώ ήταν αποτελεσματικές σε ελεγχόμενα περιβάλλοντα, αντιμετώπιζαν προκλήσεις σε δυναμικές, πραγματικές συνθήκες λόγω αποκρύψεων, συνθηκών φωτισμού και ανησυχιών για την προστασία της ιδιωτικής ζωής.

Η έλευση της φορητής τεχνολογίας (wearable technology) σηματοδότησε μια αλλαγή παραδείγματος στην έρευνα HAR. Τα επιταχυνσιόμετρα, τα γυροσκόπια και τα μαγνητόμετρα, τα οποία έγιναν συμπαγή και προσιτά, επέτρεψαν τη συλλογή δεδομένων κίνησης σε ποικίλα περιβάλλοντα. Οι πρώτες φορητές συσκευές χρησιμοποιήθηκαν κυρίως για ερευνητικούς σκοπούς, αλλά η επιτυχία τους έδωσε ώθηση στην εμπορική ανάπτυξη, οδηγώντας σε πανταχού παρόντα καταναλωτικά προϊόντα, όπως ζώνες γυμναστικής και έξυπνα ρολόγια.

Σημαντικό ορόσημο στο HAR ήταν η ενσωμάτωση αλγορίθμων μηχανικής μάθησης, οι οποίοι βελτίωσαν την ακρίβεια και την προσαρμοστικότητα των συστημάτων αναγνώρισης δραστηριοτήτων. Τεχνικές όπως τα δέντρα αποφάσεων, οι μηχανές διανυσμάτων υποστήριξης (SVM) και τα νευρωνικά δίκτυα επέτρεψαν στα μοντέλα HAR να



επεξεργάζονται μεγάλα σύνολα δεδομένων και να ταξινομούν δραστηριότητες με μεγάλη ακρίβεια. Πιο πρόσφατα, οι εξελίξεις στη βαθιά μάθηση, ιδίως τα συνελκτικά νευρωνικά δίκτυα (CNN) και τα επαναλαμβανόμενα νευρωνικά δίκτυα (RNN), βελτίωσαν περαιτέρω το HAR, επιτρέποντας τη μάθηση από άκρο σε άκρο και την καταγραφή των χρονικών εξαρτήσεων στα δεδομένα αισθητήρων [3].


Καθώς η τεχνολογική πρόοδος είχε βαθιά επίδραση σε διάφορους τομείς, το Σχήμα 5 απεικονίζει την εξέλιξη των στρατηγικών HAR με την πάροδο του χρόνου, δίνοντας έμφαση σε σημαντικά ορόσημα στον τομέα.

Πιο συγκεκριμένα,

- *Silhouette Sequences (2008)*: Οι Silhouette Sequences σηματοδότησαν μια από τις πρώτες προσεγγίσεις στο HAR, αξιοποιώντας τις 2D μορφές σε συνδυασμό με την εκτίμηση της 3D σκελετικής στάσης για την εξαγωγή χαρακτηριστικών χαμηλής διάστασης. Αυτές οι μέθοδοι αποτύπωναν δυναμικά τις ανθρώπινες ενέργειες ενσωματώνοντας τον χρόνο ως τρίτη χωρική διάσταση, βελτιώνοντας την αναγνώριση σύνθετων κινήσεων. Η πρώιμη έρευνα σε αυτόν τον τομέα έθεσε τις βάσεις για την ενσωμάτωση χωρικών και χρονικών χαρακτηριστικών στο HAR.
- *Εκτίμηση τρισδιάστατης ροής (3D Flow) (2013)*: Η έλευση της 3D εκτίμησης ροής προώθησε σημαντικά την HAR βελτιώνοντας τη σύλληψη κίνησης σε πολλαπλά σημεία θέασης. Αυτή η τεχνική ήταν ιδιαίτερα αποτελεσματική για τον χειρισμό σεναρίων πολλαπλών οπτικών γωνιών, επιτρέποντας μεγαλύτερη ακρίβεια στην αναγνώριση ενεργειών από διαφορετικές οπτικές γωνίες. Η κανονικοποίηση της Silhouette και οι μέθοδοι που βασίζονται στην εντροπία βελτίωσαν περαιτέρω την υπολογιστική αποδοτικότητα και την ευρωστία αυτής της προσέγγισης.
- *Αρθρώσεις Eigen (Eigen Joints) (2014)*: Οι αρθρώσεις Eigen εισήγαγαν μια σκελετική αναπαράσταση για την ανάλυση κίνησης, εστιάζοντας στις κρίσιμες κινήσεις των αρθρώσεων στις ανθρώπινες δράσεις. Προσδιορίζοντας τις βασικές αρθρώσεις και τις σχέσεις τους, η μέθοδος αυτή επέτρεψε μια πιο συμπαγή αλλά και ουσιαστική αναπαράσταση της ανθρώπινης κίνησης, επιτρέποντας βελτιωμένη ακρίβεια αναγνώρισης και μειωμένη υπολογιστική επιβάρυνση.



- *Χάρτες κίνησης βάθους (Depth Motion Maps) (2014)*: Οι χάρτες κίνησης βάθους αξιοποίησαν δεδομένα βάθους για την καταγραφή τρισδιάστατων μοτίβων κίνησης, αντιμετωπίζοντας τις προκλήσεις που σχετίζονται με την απόκρυψη και τον θόρυβο του φόντου. Η προσέγγιση αυτή παρείχε βελτιωμένη ανάλυση κίνησης με την ενσωμάτωση χωρικών ενδείξεων βάθους, καθιστώντας την ισχυρή τεχνική για την αναγνώριση ανθρώπινων ενεργειών σε ακατάστατα ή δυναμικά περιβάλλοντα.
- *Κοινά χωρικά γραφήματα (Joint Spatial Graphs) (2019)*: Τα κοινά χωρικά γραφήματα εισήγαγαν μια αναπαράσταση χωροχρονικών δεδομένων με βάση γραφήματα, όπου τα σημεία του ανθρώπινου σκελετού μοντελοποιήθηκαν ως κόμβοι και οι σχέσεις τους αποτυπώθηκαν ως ακμές. Αυτή η μέθοδος αναπαρήγαγε αποτελεσματικά τις ανθρώπινες ενέργειες στον τρισδιάστατο χώρο, επιτρέποντας τη βελτιωμένη ανάλυση σύνθετων μοτίβων κίνησης. Σηματοδότησε τη μετάβαση στα νευρωνικά δίκτυα γραφημάτων για την HAR με βάση τον σκελετό.
- *Δομημένα δεντρικά νευρωνικά δίκτυα (Structured Tree Neural Networks) (2020)*: Τα νευρωνικά δίκτυα δομημένων δέντρων συνδύασαν την ιεραρχική αναπαράσταση των δομών δέντρων με τεχνικές βαθιάς μάθησης για την αποτελεσματική μοντελοποίηση της αναγνώρισης τρισδιάστατων ενεργειών. Δομώντας τα δεδομένα σε κατευθυνόμενους γράφους και δενδροειδή μοντέλα, η προσέγγιση αυτή βελτίωσε την κατανόηση της ανθρώπινης κίνησης, ιδίως σε μεγάλα και ποικίλα σύνολα δεδομένων. Αυτή η καινοτομία ανέδειξε τη δύναμη των μεθόδων που βασίζονται σε γράφους και ιεραρχικές μεθόδους για την αντιμετώπιση των προκλήσεων της HAR [4].



Εικόνα 1: Η εξέλιξη της HAR στον χρόνο (2008-2020)

Το ιστορικό χρονοδιάγραμμα και οι σχετικές αρχιτεκτονικές αποκαλύπτουν τη μετασχηματιστική πορεία των τεχνολογιών HAR με την πάροδο των ετών. Κάθε στάδιο, από τις ακολουθίες σιλουέτας έως τα δομημένα νευρωνικά δίκτυα δέντρων, αντανακλά μια σημαντική πρόοδο στην ικανότητα ανάλυσης και ερμηνείας των ανθρώπινων ενεργειών σε διάφορα πλαίσια. Με την απεικόνιση της εξέλιξης των μεθοδολογιών και των εφαρμογών τους στον πραγματικό κόσμο, αυτό το κεφάλαιο θέτει τις βάσεις για τη μετέπειτα συζήτηση των προσεγγίσεων αιχμής και των νέων συνεισφορών της παρούσας έρευνας. Η κατανόηση αυτών των βασικών ορόσημων παρέχει πολύτιμες γνώσεις σχετικά με τις προκλήσεις και τις ευκαιρίες που εξακολουθούν να διαμορφώνουν τον τομέα της HAR.

1.3. Εφαρμογές της HAR στην υγεία και στην καθημερινή ζωή

Η αναγνώριση της ανθρώπινης δραστηριότητας είναι ένας σημαντικός τομέας έρευνας στον τομέα των πανταχού παρόντων υπολογιστών, της ανάλυσης της ανθρώπινης συμπεριφοράς και της αλληλεπίδρασης ανθρώπου-υπολογιστή. Η έρευνα σε αυτούς τους τομείς χρησιμοποιεί διάφορους αλγορίθμους μηχανικής μάθησης για την αναγνώριση απλών και σύνθετων δραστηριοτήτων, όπως το περπάτημα, το τρέξιμο, το μαγείρεμα κ.λπ. Ειδικότερα, η αναγνώριση των καθημερινών δραστηριοτήτων είναι απαραίτητη για τη διατήρηση ενός υγιεινού τρόπου ζωής, την αποκατάσταση ασθενών και την αλλαγή δραστηριοτήτων μεταξύ



των ηλικιωμένων πολιτών που μπορεί να βοηθήσει στην ανίχνευση και διάγνωση σοβαρών ασθενειών. Ως εκ τούτου, το πλαίσιο αναγνώρισης ανθρώπινων δραστηριοτήτων παρέχει μηχανισμό για την ανίχνευση τόσο των δραστηριοτήτων στάσης όσο και των περιπατητικών δραστηριοτήτων, των κινήσεων του σώματος και των ενεργειών των χρηστών, χρησιμοποιώντας διαφορετικά πολυτροπικά δεδομένα που παράγονται από ποικιλία αισθητήρων [5]. Παρακάτω παρουσιάζονται ορισμένες από τις πιο σημαντικές περιπτώσεις χρήσης:

- **Εξατομικευμένη παρακολούθηση της υγείας**

Η HAR συμβάλλει στην εξατομικευμένη υγειονομική περίθαλψη με τη συνεχή παρακολούθηση των επιπέδων δραστηριότητας και των ζωτικών σημείων των ασθενών. Για παράδειγμα, οι φορητοί αισθητήρες μπορούν να ανιχνεύσουν την καθιστική συμπεριφορά σε ασθενείς που αναρρώνουν από χειρουργική επέμβαση και να τους προτρέψουν να κινηθούν, μειώνοντας τον κίνδυνο επιπλοκών όπως η φλεβική θρόμβωση. Ομοίως, τα συστήματα HAR διαδραματίζουν κρίσιμο ρόλο στη διαχείριση χρόνιων ασθενειών όπως ο διαβήτης, συσχετίζοντας τη σωματική δραστηριότητα με τα επίπεδα γλυκόζης στο αίμα.



Εικόνα 2: Εξατομικευμένη Παρακολούθηση της Υγείας

- **Παρακολούθηση φυσικής κατάστασης**

Στον τομέα της φυσικής κατάστασης και της ευεξίας, τα συστήματα HAR δίνουν τη δυνατότητα στους χρήστες να παρακολουθούν σωματικές δραστηριότητες όπως το



περπάτημα, το τρέξιμο και η ποδηλασία. Οι φορητές συσκευές που είναι εξοπλισμένες με επιταχυνσιόμετρα και γυροσκόπια μπορούν να εκτιμήσουν την ενεργειακή δαπάνη, να προσδιορίσουν την ένταση της άσκησης και να παρέχουν ανατροφοδότηση σχετικά με τη στάση του σώματος ή τη βάδιση. Αυτές οι γνώσεις βοηθούν τα άτομα να θέσουν και να επιτύχουν αποτελεσματικά τους στόχους γυμναστικής [6].



Εικόνα 3: Παρακολούθηση Φυσικής Κατάστασης

- **Ανίχνευση πτώσης**

Τα συστήματα HAR χρησιμοποιούνται ευρέως για την ανίχνευση πτώσεων σε ηλικιωμένους πληθυσμούς, μια κρίσιμη εφαρμογή δεδομένων των κινδύνων που συνδέονται με τις πτώσεις. Αναλύοντας μοτίβα κίνησης από φορητούς αισθητήρες, τα συστήματα αυτά μπορούν να ανιχνεύουν απότομες αλλαγές στη στάση του σώματος και να στέλνουν ειδοποιήσεις στους φροντιστές ή στις υπηρεσίες έκτακτης ανάγκης. Τέτοιες τεχνολογίες είναι ιδιαίτερα επωφελείς σε εγκαταστάσεις υποστηριζόμενης διαβίωσης και για άτομα με κινητικές δυσκολίες [7].



Εικόνα 4: Ανίχνευση Πτώσης

- **Αλληλεπίδραση ανθρώπου/υπολογιστή**

Για την αλληλεπίδραση ανθρώπου-υπολογιστή, η HAR είναι καθοριστική για τον προσδιορισμό και την κατηγοριοποίηση των ανθρώπινων χειρονομιών και κινήσεων, βελτιώνοντας έτσι τη χρηστικότητα και την προσβασιμότητα των υπολογιστικών συστημάτων. Ως εκ τούτου, οι εντολές που βασίζονται σε χειρονομίες για ηλεκτρονικές συσκευές όπως τα έξυπνα τηλέφωνα και οι έξυπνες τηλεοράσεις γίνονται πιο διαισθητικές με το HAR. Επιπλέον, το HAR επιτρέπει την αυτοματοποίηση των συστημάτων υπολογιστών με βάση τη φωνή, βελτιώνοντας την αλληλεπίδραση με εικονικούς προσωπικούς βοηθούς και chatbots. Επιπλέον, παρακολουθώντας τις φυσικές κινήσεις και συμπεριφορές των χρηστών, το HAR συμβάλλει στη διατήρηση της υγείας και της ευεξίας των χρηστών, μετριάζοντας τις δυσμενείς επιπτώσεις της παρατεταμένης χρήσης υπολογιστή, όπως η καταπόνηση των ματιών και ο πόνος στην πλάτη.



Εικόνα 5: Αλληλεπίδραση Ανθρώπου - Υπολογιστή (HCI)

- **Ανάλυση αθλητικών επιδόσεων**

Η ανάλυση αθλητικών επιδόσεων επωφελείται σε μεγάλο βαθμό από το HAR. Βοηθά στην παρακολούθηση και ανάλυση των κινήσεων των αθλητών κατά τη διάρκεια τόσο των αγώνων όσο και των προπονήσεων, στον εντοπισμό πιθανών κινδύνων τραυματισμού, στην αξιολόγηση της αποτελεσματικότητας του προγράμματος προπόνησης, στην παρακολούθηση της προόδου του κάθε αθλητή και στην ανάλυση των τακτικών και στρατηγικών πτυχών των ομαδικών αθλημάτων. Για παράδειγμα, το HAR μπορεί να αναλύσει τις κινήσεις των παικτών του μπάσκετ κατά τη διάρκεια των χτυπημάτων, να παρακολουθήσει τους δρομείς για ενδείξεις τραυματισμών υπερβολικής χρήσης και να αξιολογήσει την απόδοση των ποδοσφαιριστών κατά τη διάρκεια των αγώνων. Παρακολουθεί επίσης την κίνηση των ποδιών και την τοποθέτηση των παικτών του τένις ή αξιολογεί τις ενέργειες των παικτών του μπάσκετ για την ενίσχυση της ομαδικής άμυνας και της κίνησης της μπάλας. Επιπλέον, η παρακολούθηση της στάσης σε εφαρμογές γυμναστικής με τεχνητή νοημοσύνη διασφαλίζει ότι οι χρήστες τηρούν τις οδηγίες ασφαλείας και λαμβάνουν ανατροφοδότηση σε πραγματικό χρόνο κατά τη διάρκεια της οικιακής προπόνησης.



Εικόνα 6: Ανάλυση Αθλητικών Επιδόσεων

- **Ψυχολογία**

Στον τομέα της ψυχολογίας, το HAR υπόσχεται πολλά για εφαρμογές τηλεϊατρικής. Η χρήση τρισδιάστατων πόζων του ανθρώπινου σώματος επιτρέπει την εξ αποστάσεως ποσοτική κινητική αξιολόγηση, διευκολύνοντας την παροχή υγειονομικής περίθαλψης απευθείας στα σπίτια των ασθενών. Το HAR βοηθά επίσης στην ανίχνευση του αυτισμού με την ανίχνευση άτυπων συμπεριφορών, αναδεικνύοντας τη σημασία της έγκαιρης παρέμβασης για τη βελτίωση της ποιότητας ζωής. Επιπλέον, η παρακολούθηση της ανθρώπινης κίνησης συμβάλλει στην αξιολόγηση της ψυχικής κατάστασης και της συναισθηματικής ευεξίας των ατόμων, αναδεικνύοντας τις δυνατότητες του HAR στην κατανόηση της ανθρώπινης ψυχολογίας [8].



Εικόνα 7: Ψυχολογία και Τηλεϊατρική



- **Παιχνίδι**

Στο gaming, το HAR προσφέρει πολλά οφέλη. Η αναγνώριση και η ταξινόμηση των ενεργειών και των χειρονομιών των παικτών καθιστά τις εμπειρίες πιο καθηλωτικές και διαδραστικές. Το παιχνίδι με έλεγχο κίνησης είναι μια χαρακτηριστική περίπτωση. Χρησιμοποιεί το HAR για να μεταφράσει τις κινήσεις των παικτών σε διασκεδαστικές ενέργειες εντός του παιχνιδιού, όπως το κούνημα ενός σπαθιού ή η ρίψη μιας μπάλας. Επίσης, ο χειρισμός των διεπαφών εντός του παιχνιδιού με χειρονομίες βελτιώνει την πλοήγηση, εξασφαλίζοντας μια απρόσκοπτη εμπειρία παιχνιδιού για τους παίκτες. Επιπλέον, το HAR μπορεί να παρακολουθεί τη σωματική άσκηση των χρηστών κατά τη διάρκεια του παιχνιδιού. Τα παιχνίδια μπορούν να δώσουν κίνητρα για σωματική δραστηριότητα, ανταμείβοντας τους παίκτες για την ολοκλήρωση βημάτων ή τη συμμετοχή σε συγκεκριμένες προπονήσεις.



Εικόνα 8: Παιχνίδια – Gaming

- **IoT**

Το HAR έχει ενσωματωθεί σε έξυπνα σπίτια και οικοσυστήματα IoT για τη βελτίωση της ποιότητας ζωής. Τα συστήματα έξυπνων σπιτιών χρησιμοποιούν το HAR για την αυτοματοποίηση εργασιών με βάση τα πρότυπα δραστηριότητας των κατοίκων, όπως η προσαρμογή του φωτισμού ή του κλιματισμού όταν εντοπίζονται άτομα σε συγκεκριμένα δωμάτια [9].



Εικόνα 9: Internet of Things (IoT)

- **Αυτοκινούμενα αυτοκίνητα**

Όσον αφορά τα αυτοκινούμενα αυτοκίνητα, το HAR συμβάλλει στην ενίσχυση της ασφάλειας και της αποτελεσματικότητας. Ανιχνεύοντας πεζούς, ποδηλάτες και άλλα οχήματα στο δρόμο, το HAR επιτρέπει στα αυτόνομα αυτοκίνητα να προβλέπουν και να αποτρέπουν συγκρούσεις. Επιπλέον, το HAR εντοπίζει συμπεριφορές οδηγών, όπως σήματα χεριών και κινήσεις του κεφαλιού, διευκολύνοντας την επικοινωνία μεταξύ των αυτοκινούμενων οχημάτων και των ανθρώπινων οδηγών [10].



Εικόνα 10: Self-Driving Αυτοκίνητα




1.4. Τεχνολογίες – Μέσα – Συσκευές της HAR

Η ραγδαία εξέλιξη της τεχνολογίας έχει επηρεάσει σημαντικά την ανάπτυξη της Αναγνώρισης Ανθρώπινης Δραστηριότητας (HAR). Τα σύγχρονα συστήματα αξιοποιούν έναν συνδυασμό υλικού και λογισμικού για τη συλλογή, επεξεργασία και ανάλυση δεδομένων για την ακριβή ταξινόμηση δραστηριοτήτων. Παρακάτω, ακολουθεί επισκόπηση των βασικών τεχνολογικών στοιχείων και τάσεων της HAR.

- **Έξυπνες συσκευές και ενσωματωμένοι αισθητήρες (Smart Devices and Embedded Sensors)**

Τα smartphones και άλλες έξυπνες συσκευές έχουν αναδειχθεί σε πανταχού παρόντα εργαλεία στη HAR, χρησιμοποιώντας ενσωματωμένους αισθητήρες για τη συλλογή δεδομένων και την παροχή ανατροφοδότησης σε πραγματικό χρόνο. Αυτές οι συσκευές καθιστούν το HAR προσιτό σε ευρύτερο πληθυσμό και εφαρμόσιμο σε διάφορους τομείς, όπως η υγειονομική περίθαλψη, η ρομποτική και η περιβαλλοντική προσαρμογή. Ειδικότερα, τα συστήματα αυτά βασίζονται συχνά σε σήματα και δεδομένα από αισθητήρες που μπορεί να είναι είτε σταθεροί, τοποθετημένοι σε συγκεκριμένους χώρους όπως δωμάτια, είτε κινητοί, ενσωματωμένοι σε φορητές συσκευές όπως smartphones ή smartwatches. Για παράδειγμα, τα smartphones είναι εξοπλισμένα με πολλαπλές λειτουργίες, όπως ενσωματωμένες κάμερες, λογισμικό πολυμέσων ικανό να αναπαράγει μουσική και να προβάλλει εικόνες ή βίντεο, καθώς και εφαρμογές πλοήγησης. Αυτές οι λειτουργίες ενισχύουν τις δυνατότητες HAR παρέχοντας δεδομένα τόσο από το πλαίσιο όσο και από τη συμπεριφορά [11].



Εικόνα 11: Οι Αισθητήρες του HAR

- **Φορητή τεχνολογία (Wearable Technology)**

Οι φορητές συσκευές διαδραματίζουν κεντρικό ρόλο στην HAR, επιτρέποντας τη συλλογή λεπτομερών δεδομένων κίνησης και φυσιολογικών δεδομένων. Οι βασικές πτυχές περιλαμβάνουν:

- *Φορέσιμοι αισθητήρες* (επιταχυνσιόμετρα, γυροσκόπια και φυσιολογικές οθόνες): Καταγράφουν ένα ευρύ φάσμα δεδομένων δραστηριότητας και ζωτικών σημείων και διευκολύνουν την ανίχνευση των σωματικών δραστηριοτήτων, καθιστώντας τους απαραίτητους για εφαρμογές όπως η παρακολούθηση της φυσικής κατάστασης και η παρακολούθηση της υγείας.
- *Έξυπνες συσκευές*: Τα έξυπνα κινητά τηλέφωνα αποτελούν απαραίτητα εργαλεία για την HAR λόγω των ενσωματωμένων αισθητήρων κίνησης και των υπολογιστικών δυνατοτήτων τους. Οι εφαρμογές που εκτελούνται σε smartphones μπορούν να ταξινομήσουν δραστηριότητες όπως το περπάτημα, το τρέξιμο και η μετακίνηση αναλύοντας δεδομένα επιταχυνσιόμετρου και GPS [12].

- **Τάσεις στη φορητή τεχνολογία**

Οι πρόσφατες εξελίξεις στη φορητή τεχνολογία έχουν βελτιώσει περαιτέρω τις δυνατότητες των συστημάτων HAR. Αρχικά, οι φορητές συσκευές γίνονται μικρότερες



και πιο διακριτικές, βελτιώνοντας την άνεση του χρήστη και επιτρέποντας τη συνεχή παρακολούθηση χωρίς παρενόχληση. Ακόμη, οι μπαταρίες μεγαλύτερης διάρκειας εξασφαλίζουν ότι οι συσκευές μπορούν να λειτουργούν για μεγάλα χρονικά διαστήματα, υποστηρίζοντας την παρακολούθηση σε πραγματικό χρόνο σε εφαρμογές όπως η υγειονομική περίθαλψη και ο αθλητισμός. Είναι σημαντικό να τονιστεί ότι, οι εξελίξεις στην τεχνολογία αισθητήρων έχουν αυξήσει την ακρίβεια της συλλογής δεδομένων, επιτρέποντας πιο αξιόπιστη αναγνώριση δραστηριοτήτων. Παράλληλα, οι σύγχρονες φορητές συσκευές συχνά υποστηρίζουν επεξεργασία δεδομένων σε πραγματικό χρόνο και συνδεσιμότητα στο cloud, επιτρέποντας την απρόσκοπτη ανταλλαγή δεδομένων και προηγμένες αναλύσεις. Ενώ τέλος, καινοτομίες όπως τα έξυπνα υφάσματα και οι εμφυτεύσιμες συσκευές υπόσχονται την επέκταση των εφαρμογών HAR [13]. Για παράδειγμα, τα έξυπνα υφάσματα που ενσωματώνουν αισθητήρες μπορούν να παρακολουθούν τις κινήσεις κατά τη διάρκεια της αθλητικής απόδοσης, ενώ οι εμφυτεύσιμες συσκευές μπορούν να παρέχουν συνεχή, μακροπρόθεσμη παρακολούθηση της υγείας [14].



Εικόνα 12: Συσκευές της HAR

- **Επιπτώσεις στην προσβασιμότητα και τις εφαρμογές**

Η εξάπλωση της φορητής τεχνολογίας έχει όχι μόνο βελτιώσει την ακρίβεια των συστημάτων HAR, αλλά και διευρύνει την προσβασιμότητα και τη χρησιμότητά τους. Καθώς οι φορητές συσκευές γίνονται όλο και πιο προσιτές και φιλικές προς τον χρήστη,



η HAR έχει αναδειχθεί σε αναπόσπαστο στοιχείο της εξατομικευμένης και προληπτικής υγειονομικής περίθαλψης. Αξιοποιώντας δεδομένα σε πραγματικό χρόνο και προηγμένες αναλύσεις, τα συστήματα HAR υποστηρίζουν την παρακολούθηση της υγείας, την παρακολούθηση της φυσικής κατάστασης και τα προσαρμοστικά περιβάλλοντα διαβίωσης, καλύπτοντας ένα ευρύ φάσμα κοινωνικών αναγκών [15].

Αυτές οι τεχνολογικές εξελίξεις όχι μόνο βελτίωσαν την ακρίβεια των συστημάτων HAR, αλλά και διεύρυναν την προσβασιμότητα και τη χρηστικότητα τους. Με τη διάδοση των φορητών συσκευών, το HAR έχει γίνει αναπόσπαστο μέρος της ευρύτερης κίνησης προς την εξατομικευμένη και προληπτική υγειονομική περίθαλψη.

2. Τεχνολογίες Φορέσιμων Αισθητήρων


Οι τεχνολογίες φορητών αισθητήρων έχουν μεταμορφώσει τον τομέα της αναγνώρισης ανθρώπινης δραστηριότητας (HAR), επιτρέποντας την απρόσκοπτη συλλογή φυσιολογικών δεδομένων και δεδομένων κίνησης σε πραγματικό χρόνο. Αυτοί οι αισθητήρες, ενσωματωμένοι σε συσκευές όπως έξυπνα ρολόγια, συσκευές παρακολούθησης φυσικής κατάστασης και εξειδικευμένο ιατρικό εξοπλισμό, παρέχουν ένα μέσο παρακολούθησης της ανθρώπινης δραστηριότητας και υγείας με πρωτοφανή ακρίβεια [16]. Το παρόν κεφάλαιο παρέχει μια επισκόπηση των τύπων των φορητών αισθητήρων, των δεδομένων που συλλέγουν και των προκλήσεων που σχετίζονται με την εφαρμογή τους σε συστήματα HAR.

2.1 Φορέσιμοι Αισθητήρες: Είδη και Χρήσεις

Οι φορητοί αισθητήρες έχουν γίνει απαραίτητα εργαλεία για την παρακολούθηση και την ανάλυση της ανθρώπινης δραστηριότητας και υγείας. Αυτές οι συσκευές συλλέγουν δεδομένα σε πραγματικό χρόνο για φυσιολογικές και φυσικές παραμέτρους, παρέχοντας πληροφορίες για την κίνηση, τα ζωτικά σημεία και τις περιβαλλοντικές αλληλεπιδράσεις. Η ευελιξία τους επιτρέπει την ενσωμάτωσή τους σε διάφορες μορφές, όπως έξυπνα ρολόγια,



ζώνες γυμναστικής, επιθέματα και υφάσματα, καθιστώντας τους αναπόσπαστο κομμάτι τόσο της καθημερινής χρήσης όσο και εξειδικευμένων εφαρμογών [17].



Εικόνα 13: Ταξινόμηση των Φορητών Αισθητήρων για την Παρακολούθηση Δραστηριότητας

Οι εξελίξεις στα υλικά και την τεχνολογία αισθητήρων έχουν βελτιώσει την ακρίβεια, την ευαισθησία και την ευελιξία των φορητών αισθητήρων, επιτρέποντας την ελάχιστη επεμβατική ή μη επεμβατική παρακολούθηση. Αυτές οι καινοτομίες έχουν επεκτείνει το ρόλο τους από την παρακολούθηση της φυσικής κατάστασης στην υγειονομική περίθαλψη, την πλοήγηση και την ψυχαγωγία, διαμορφώνοντας ένα μέλλον όπου οι φορητοί αισθητήρες θα ενσωματώνονται απρόσκοπτα στην καθημερινή ζωή [18]. Οι ακόλουθες ενότητες διερευνούν συγκεκριμένους τύπους φορητών αισθητήρων και τις ποικίλες χρήσεις τους.


2.2.1 Επιταχυνσιόμετρα (Accelerometers)

Υπάρχουν διάφοροι τύποι αισθητήρων για τη μέτρηση σημάτων που μπορούν να χρησιμοποιηθούν από τα συστήματα HAR. Δύο από τους πλέον χρησιμοποιούμενους είναι το επιταχυνσιόμετρο και το γυροσκόπιο.

Τα επιταχυνσιόμετρα είναι ευρέως χρησιμοποιούμενοι αισθητήρες για τη μέτρηση της επιτάχυνσης και της κίνησης σε συστήματα αναγνώρισης ανθρώπινης δραστηριότητας (HAR). Αυτοί οι αισθητήρες ανιχνεύουν την επιτάχυνση (μετρούμενη σε μέτρα ανά δευτερόλεπτο στο τετράγωνο, m/s^2) καταγράφοντας τις μεταβολές της χωρητικότητας μέσα στα μικροηλεκτρομηχανικά τους συστήματα (MEMS). Η τεχνολογία MEMS, η οποία



αποτελείται από αιωρούμενα σωματίδια πυριτίου που κινούνται σε απόκριση στην επιτάχυνση, επιτρέπει στα επιταχυνσιόμετρα να μετρούν την κίνηση κατά μήκος συγκεκριμένων αξόνων αναφοράς. Όταν συμβαίνει επιτάχυνση, τα σωματίδια μετατοπίζονται, δημιουργώντας αλλαγές στη χωρητικότητα που ερμηνεύονται για να παρέχουν δεδομένα κίνησης [19].



Εικόνα 14: Άξονες Επιταχυνσιόμετρων

Τα επιταχυνσιόμετρα είναι πολύτιμα στις φορητές συσκευές λόγω της ικανότητάς τους να μετρούν τη βαρύτητα και τη γραμμική επιτάχυνση, επιτρέποντας ποικίλες εφαρμογές. Για παράδειγμα, μπορούν να παρακολουθούν τη σωματική δραστηριότητα καταγράφοντας την ένταση και τη συχνότητα της κίνησης, να αξιολογούν την ταχύτητα και τη μετατόπιση μέσω της ενσωμάτωσης δεδομένων και να παρέχουν ανίχνευση κλίσης για τον προσδιορισμό της στάσης του σώματος. Αυτά τα χαρακτηριστικά επιτρέπουν στα επιταχυνσιόμετρα να ταξινομούν τις ανθρώπινες δραστηριότητες και στάσεις, καθιστώντας τα απαραίτητα εργαλεία για την παρακολούθηση της φυσικής δραστηριότητας σε κλινικά και εργαστηριακά περιβάλλοντα.

Ιστορικά, τα επιταχυνσιόμετρα διερευνήθηκαν για πρώτη φορά τη δεκαετία του 1950 για τη μέτρηση της ταχύτητας και της επιτάχυνσης της βάρδιας, ενώ λεπτομερείς μελέτες εμφανίστηκαν τη δεκαετία του 1970 καθώς η τεχνολογία εξελισσόταν. Η εισαγωγή των επιταχυνσιόμετρων MEMS το 1979 αποτέλεσε σημαντικό ορόσημο, μειώνοντας το κόστος,



βελτιώνοντας τις επιδόσεις και επιτρέποντας την ευρεία χρήση σε φορητά συστήματα [20]. Οι εφαρμογές περιλαμβάνουν την ανάλυση βάδισης, όπου τα επιταχυνσιόμετρα προσαρμόζονται στα κάτω άκρα ή στην πλάτη για την ανάλυση των φάσεων κίνησης κατά τη διάρκεια του βαδίσματος.

Σε σύγκριση με απλούστερους αισθητήρες κίνησης, όπως τα βηματόμετρα, τα επιταχυνσιόμετρα προσφέρουν ανώτερες δυνατότητες. Ενώ τα βηματόμετρα είναι οικονομικά αποδοτικά και μετρούν τον αριθμό των βημάτων, δεν μπορούν να καταγράψουν την ένταση της κίνησης ή να παρέχουν ακριβείς εκτιμήσεις ενεργειακής δαπάνης. Αντίθετα, τα επιταχυνσιόμετρα παρέχουν ολοκληρωμένα δεδομένα για την ανθρώπινη κίνηση, υποστηρίζοντας την ακριβή και αξιόπιστη εκτίμηση της ΠΑ σε διάφορα περιβάλλοντα. Ο μικρός παράγοντας μορφής τους, η χαμηλή κατανάλωση ενέργειας και η ευελιξία τους τα καθιστούν απαραίτητα στη σύγχρονη τεχνολογία φορητών συσκευών [21].


2.2.2 Γυροσκόπια (Gyroscopes)

Τα γυροσκόπια είναι βασικοί αισθητήρες που μετρούν τη γωνιακή ταχύτητα και ανιχνεύουν την περιστροφή και τον προσανατολισμό. Συμπληρώνουν τα επιταχυνσιόμετρα παρέχοντας πληροφορίες σχετικά με τη γωνιακή κίνηση, επιτρέποντας την ανίχνευση πολύπλοκων κινήσεων όπως κλίσεις, στροφές και περιστροφές. Μαζί με τα επιταχυνσιόμετρα, τα γυροσκόπια επιτρέπουν την ολοκληρωμένη παρακολούθηση τόσο της γραμμικής όσο και της γωνιακής κίνησης, με αποτέλεσμα την ακριβέστερη παρακολούθηση της δραστηριότητας και τη μείωση των στρεβλώσεων βαθμονόμησης [22].

Τα γυροσκόπια ενσωματώνονται ευρέως σε καταναλωτικά wearables, όπως smartwatches και smartphones, καθώς και σε εξειδικευμένες συσκευές για κλινικές εφαρμογές. Για παράδειγμα, χρησιμοποιούνται για την ποσοτικοποίηση του τρόμου και της βραδυκινησίας στη νόσο του Πάρκινσον και για την καταγραφή γωνιακών κινήσεων με το χέρι. Στις εφαρμογές υγειονομικής περίθαλψης, ο συνδυασμός γυροσκοπίων με άλλους αισθητήρες - όπως επιταχυνσιόμετρα, ηλεκτροκαρδιογραφήματα ή μικρόφωνα - έχει αποδειχθεί αποτελεσματικός για την πολυτροπική παρακολούθηση της δραστηριότητας. Αυτή η ενσωμάτωση προσφέρει ακριβή παρακολούθηση δυναμικών κινήσεων, συμπεριλαμβανομένων αθλητικών ενεργειών όπως το μπόουλινγκ ή το μπέιζμπολ, οι οποίες



περιλαμβάνουν γρήγορες και περιστροφικές κινήσεις πέρα από τα συνήθη πρότυπα περπατήματος ή τρεξίματος [23].



Εικόνα 15: Γυροσκόπιο

Τα γυροσκόπια διαθέτουν πρόσθετες λειτουργίες που ενισχύουν τις δυνατότητες των φορητών συσκευών. Για παράδειγμα, βελτιώνουν την ανίχνευση πτώσεων με τη λήψη της γωνιακής ταχύτητας και την ενσωμάτωση δεδομένων από επιταχυνσιόμετρα και βαρόμετρα για τον εντοπισμό πτώσεων. Συσκευές όπως το Apple Watch αξιοποιούν αυτή την τεχνολογία, ειδοποιώντας τους χρήστες όταν ανιχνεύεται πτώση και επικοινωνώντας αυτόματα με τις υπηρεσίες έκτακτης ανάγκης εάν ανιχνευθεί ακινησία για παρατεταμένο χρονικό διάστημα. Στον αθλητισμό και τη γυμναστική, τα γυροσκόπια βελτιώνουν την καταμέτρηση επαναλήψεων κατά τη διάρκεια των προπονήσεων και βελτιώνουν τους υπολογισμούς απόστασης και κατεύθυνσης όταν το GPS δεν είναι διαθέσιμο [22].

Τεχνολογικά, τα γυροσκόπια λειτουργούν με βάση τη δύναμη Coriolis για τη μέτρηση του γωνιακού ρυθμού και της διακύμανσης με δυναμική απόκριση υψηλής ταχύτητας. Οι πρώτες εφαρμογές βασίζονταν σε μεμονωμένα γυροσκόπια για τη μέτρηση της γωνιακής επιτάχυνσης, αλλά ο συνδυασμός τους με επιταχυνσιόμετρα έχει βελτιώσει την ακρίβεια της παρακολούθησης μετριάζοντας τα σφάλματα. Τα σύγχρονα γυροσκόπια, όπως αυτά που προέρχονται από κατασκευαστές όπως η STMicroelectronics και η Honeywell, είναι συμπαγή και αποδοτικά. Για παράδειγμα, ο αισθητήρας ISM330DHCX της STMicroelectronics έχει διαστάσεις μικρότερες από 3 mm και υποστηρίζει ένα ευρύ φάσμα μετρήσεων έως και 4000 μοίρες ανά δευτερόλεπτο (dps) με τυπικό ρυθμό δειγματοληψίας



100 Hz. Αυτά τα χαρακτηριστικά καθιστούν τα γυροσκόπια κατάλληλα για την παρακολούθηση της γωνιακής επιτάχυνσης σε κινήσεις των άνω άκρων και του κορμού [24].

Ενώ τα γυροσκόπια προσφέρουν στιβαρές επιδόσεις, η μακροχρόνια χρήση μπορεί να οδηγήσει σε τυχαία ολίσθηση, η οποία εισάγει σφάλματα. Παρ' όλα αυτά, η ικανότητά τους να καταγράφουν τη δυναμική της περιστροφής τα καθιστά ανεκτίμητα στη φορητή τεχνολογία για εφαρμογές που κυμαίνονται από την κλινική παρακολούθηση έως την παρακολούθηση της φυσικής κατάστασης και τα συστήματα πλοήγησης.

2.2.3 Καταγραφείς ζωτικών σημείων (ΗΚΓ κ.λπ.) {Vital Sign Recorders (e.g., ECG) }


Οι καταγραφείς ζωτικών σημείων έχουν φέρει επανάσταση στην παρακολούθηση της υγείας, επιτρέποντας τη συνεχή και ακριβή παρακολούθηση των φυσιολογικών παραμέτρων σε περιβάλλοντα πραγματικού κόσμου. Οι φορητοί ιατρικοί αισθητήρες μεταδίδουν σε πραγματικό χρόνο δεδομένα για παραμέτρους όπως ο αναπνευστικός ρυθμός, η αρτηριακή πίεση, η θερμοκρασία σώματος και τα πρότυπα ύπνου σε κεντρικά ιατρικά συστήματα. Αυτό επιτρέπει στους επαγγελματίες υγείας να παρατηρούν και να αναλύουν εξ αποστάσεως τις συνθήκες των ασθενών, επιτρέποντας έγκαιρες παρεμβάσεις και εξατομικευμένη φροντίδα [25]. Τα συστήματα απομακρυσμένης παρακολούθησης έχουν σημαντική πρακτική αξία, ιδίως στη φροντίδα ηλικιωμένων και τη διαχείριση χρόνιων ασθενειών, βελτιώνοντας την πρόσβαση στις υπηρεσίες υγειονομικής περίθαλψης και μειώνοντας τους χρόνους απόκρισης κατά τη διάρκεια έκτακτων περιστατικών [26].

Οι σύγχρονοι φορητοί αισθητήρες ζωτικών σημείων είναι υψηλής ακρίβειας και ευέλικτοι, καθώς εμφανίζονται σε συσκευές όπως συσκευές παρακολούθησης φυσικής κατάστασης, έξυπνα ρολόγια, ακουστικά, αλλά ακόμη και αυτοκόλλητα επιθέματα. Αυτές οι συσκευές ενσωματώνονται απρόσκοπτα στην καθημερινή ζωή, δίνοντας τη δυνατότητα στους χρήστες να παρακολουθούν την υγεία τους με ελάχιστη διαταραχή.

Μεταξύ αυτών των τεχνολογιών, το ηλεκτροκαρδιογράφημα (ΗΚΓ - ECG) είναι μια από τις πιο ευρέως υιοθετημένες μεθόδους καταγραφής ζωτικών σημείων, ιδίως στην



παρακολούθηση της καρδιαγγειακής υγείας. Το ECG μετρά την ηλεκτρική δραστηριότητα της καρδιάς μέσω συγκεκριμένων κυματομορφών (P, Q, R, S, T, U), οι οποίες παρέχουν κρίσιμες πληροφορίες σχετικά με τον ρυθμό και τη λειτουργία της καρδιάς. Οι φορητές συσκευές ECG, όπως αυτές που ενσωματώνονται σε έξυπνα ρολόγια και συσκευές παρακολούθησης φυσικής κατάστασης, διαθέτουν συνήθως αισθητήρες ΗΚΓ μίας απαγωγής. Παρόλο που αυτά είναι λιγότερο ολοκληρωμένα από τα τυπικά ΗΚΓ 12 απαγωγών που χρησιμοποιούνται σε κλινικές ρυθμίσεις, προσφέρουν το πλεονέκτημα της συνεχούς παρακολούθησης και της προσβασιμότητας [27].



Εικόνα 16: Holter Monitor με ECG καταγραφή

2.2 Επισκόπηση των Δεδομένων που Συλλέγονται από Φορέσιμους Αισθητήρες

Όπως έχει γίνει γνωστό, οι φορητοί αισθητήρες συλλέγουν και αναλύουν συνεχώς φυσιολογικά δεδομένα καθώς και δεδομένα κίνησης (εμβιομηχανική), επιτρέποντας την παρακολούθηση της υγείας σε πραγματικό χρόνο, την παρακολούθηση της δραστηριότητας και την αξιολόγηση των επιδόσεων. Αυτοί οι αισθητήρες παράγουν τεράστιες ποσότητες δεδομένων που παρέχουν πολύτιμες πληροφορίες για την ανθρώπινη συμπεριφορά, τη σωματική δραστηριότητα και τη συνολική ευημερία. Τα δεδομένα που συλλέγονται



μπορούν να χρησιμοποιηθούν στην υγειονομική περίθαλψη, στην αθλητική επιστήμη και σε διάφορους άλλους τομείς, διαδραματίζοντας καθοριστικό ρόλο στην προληπτική ιατρική, την αποκατάσταση και την εξατομικευμένη φυσική κατάσταση [28].

Οι φορητοί αισθητήρες έχουν σχεδιαστεί για να συλλέγουν μια σειρά δεδομένων, ανάλογα με τον τύπο του αισθητήρα και την προβλεπόμενη εφαρμογή του. Οι κύριες κατηγορίες δεδομένων που συλλέγονται περιλαμβάνουν:

- **Φυσιολογικά δεδομένα**

- *Καρδιακός ρυθμός και HRV (Heart Rate Variability):* Τα δεδομένα καρδιακού ρυθμού που μετρώνται με τη χρήση αισθητήρων φωτοπληθυσμογραφίας (PPG) ή ηλεκτροκαρδιογραφίας (ECG) παρέχουν πληροφορίες για την καρδιαγγειακή υγεία, τα επίπεδα στρες και τη συνολική φυσική κατάσταση.
- *Αναπνευστικός ρυθμός:* Οι αισθητήρες ανιχνεύουν αλλαγές στη διαστολή του θώρακα ή τη ροή του αέρα για τη μέτρηση της αναπνοής, που είναι απαραίτητα για την αξιολόγηση των αναπνευστικών καταστάσεων ή της απόδοσης κατά την άσκηση.
- *Θερμοκρασία σώματος:* Παρακολουθούνται με τη χρήση θερμόμετρου ή αισθητήρων υπερύθρων, και είναι σημαντικό να τονιστεί ότι τα δεδομένα θερμοκρασίας βοηθούν στην ανίχνευση πυρετού, λοιμώξεων ή θερμικού στρες.
- *Κορεσμός οξυγόνου στο αίμα (SpO_2):* Τα παλμικά οξύμετρα που ενσωματώνονται στα wearables αξιολογούν τα επίπεδα οξυγόνου στο αίμα, τα οποία είναι ζωτικής σημασίας για την παρακολούθηση της αναπνευστικής απόδοσης και την ανίχνευση καταστάσεων όπως η άπνοια στον ύπνο ή η υποξία [29].


- **Δεδομένα εμβιομηχανικής και κίνησης (Biomechanical and Motion Data)**

- *Επιτάχυνση και γωνιακή ταχύτητα (Acceleration and angular velocity):* Τα δεδομένα αυτά χρησιμοποιούνται για την ανάλυση της κίνησης, της στάσης και της βάρδισης, καθώς και για την ανίχνευση πτώσεων.
- *Καταμέτρηση βημάτων και διανυθείσα απόσταση (Step count and distance traveled):* Τα βηματόμετρα και τα επιταχυνσιόμετρα παρακολουθούν τα



επίπεδα σωματικής δραστηριότητας, προσφέροντας πληροφορίες για τα καθημερινά πρότυπα κίνησης.

- *Ανάλυση στάσης και βάδισης (Postural and gait analysis)*: Οι αισθητήρες κίνησης βοηθούν στην ανίχνευση ανωμαλιών στα πρότυπα βάδισης, τα οποία μπορεί να είναι χρήσιμα για την παρακολούθηση νευρολογικών ασθενειών (π.χ. νόσος του Πάρκινσον) [30].



Εικόνα 17: Φορητές συσκευές και οι θέσεις τους στο ανθρώπινο σώμα

Παρά τις προκλήσεις που σχετίζονται με την ακρίβεια, την προστασία της ιδιωτικής ζωής και τη διαχείριση δεδομένων, οι συνεχείς εξελίξεις στην τεχνολογία αισθητήρων και στις λύσεις ψηφιακής υγείας ανοίγουν το δρόμο για πιο αποτελεσματικές και αξιόπιστες εφαρμογές. Τελικά, οι φορητοί αισθητήρες διαδραματίζουν καθοριστικό ρόλο στη διαμόρφωση του μέλλοντος της υγειονομικής περίθαλψης, της φυσικής κατάστασης και της παρακολούθησης της ανθρώπινης απόδοσης [31].



2.3 Προκλήσεις στη Συλλογή και Επεξεργασία Δεδομένων από Φορέσιμους Αισθητήρες


Η ενσωμάτωση των φορητών αισθητήρων σε εφαρμογές υγειονομικής περίθαλψης, φυσικής κατάστασης και τρόπου ζωής έχει προωθήσει σημαντικά την παρακολούθηση σε πραγματικό χρόνο και τη λήψη αποφάσεων βάσει δεδομένων. Ωστόσο, παρά την αυξανόμενη υιοθέτησή τους, εξακολουθούν να υπάρχουν αρκετές προκλήσεις στη συλλογή και επεξεργασία δεδομένων από αυτές τις συσκευές [32]. Οι προκλήσεις αυτές κυμαίνονται από τεχνικούς περιορισμούς και ανησυχίες για την ακρίβεια των δεδομένων μέχρι ζητήματα προστασίας της ιδιωτικής ζωής και ηθικά ζητήματα.

- **Ακρίβεια και αξιοπιστία των δεδομένων.** Οι φορητοί αισθητήρες αντιμετωπίζουν συχνά προβλήματα ακρίβειας λόγω εξωτερικών παραγόντων, όπως αντικείμενα κίνησης, ακατάλληλη τοποθέτηση και περιβαλλοντικές παρεμβολές. Για παράδειγμα, ένα επιταχυνσιόμετρο μπορεί να παρερμηνεύσει ορισμένες κινήσεις ή ένας αισθητήρας φωτοπλεθυσμογραφίας (PPG) μπορεί να επηρεαστεί από τον τόνο του δέρματος, τα τατουάζ ή τον φωτισμό του περιβάλλοντος, οδηγώντας σε ασυνεπείς ή λανθασμένες μετρήσεις. Η βαθμονόμηση και η επικύρωση με όργανα ιατρικής ποιότητας παραμένουν κρίσιμες για τη διασφάλιση αξιόπιστων μετρήσεων.
- **Κατανάλωση ενέργειας και διάρκεια ζωής της μπαταρίας.** Δεδομένου ότι οι περισσότερες φορητές συσκευές έχουν σχεδιαστεί για να είναι συμπαγείς και ελαφριές, έχουν περιορισμένη χωρητικότητα μπαταρίας. Η συνεχής συλλογή δεδομένων, η ασύρματη μετάδοση και η ενσωματωμένη επεξεργασία μπορούν να εξαντλήσουν γρήγορα την ισχύ, οδηγώντας σε μικρότερους χρόνους χρήσης και διακοπές στην παρακολούθηση. Η βελτιστοποίηση της ενεργειακής απόδοσης με ταυτόχρονη διατήρηση υψηλών επιδόσεων αποτελεί βασική πρόκληση στην τεχνολογία των φορητών αισθητήρων [33].
- **Υπερφόρτωση δεδομένων και προβλήματα αποθήκευσης.** Οι φορητοί αισθητήρες παράγουν μεγάλο όγκο συνεχών δεδομένων, ιδίως σε συστήματα πολλαπλών αισθητήρων που παρακολουθούν ταυτόχρονα πολλές παραμέτρους (π.χ. καρδιακός ρυθμός, κίνηση, θερμοκρασία). Για τη διαχείριση αυτής της εισροής πληροφοριών



απαιτείται αποτελεσματική αποθήκευση, συμπίεση και μετάδοση δεδομένων. Χωρίς κατάλληλες τεχνικές φιλτραρίσματος και επεξεργασίας, τα ακατέργαστα δεδομένα μπορεί να είναι συντριπτικά, καθιστώντας δύσκολη την εξαγωγή ουσιαστικών πληροφοριών.

- **Επεξεργασία σε πραγματικό χρόνο και καθυστέρηση.** Σε εφαρμογές όπως η απομακρυσμένη παρακολούθηση ασθενών ή η ανάλυση αθλητικών επιδόσεων, η επεξεργασία δεδομένων σε πραγματικό χρόνο είναι ζωτικής σημασίας. Ωστόσο, οι καθυστερήσεις στη μετάδοση δεδομένων λόγω καθυστέρησης δικτύου, περιορισμών εύρους ζώνης ή υπολογιστικών περιορισμών μπορεί να εμποδίσουν την έγκαιρη ανίχνευση κρίσιμων συμβάντων (π.χ. καρδιακή αρρυθμία). Διερευνάται η επεξεργασία δεδομένων μέσω υπολογιστών ακμής και τεχνητής νοημοσύνης για τη μείωση της καθυστέρησης και την ενίσχυση της λήψης αποφάσεων σε πραγματικό χρόνο [34].
- **Ανησυχίες για το απόρρητο και την ασφάλεια.** Η συλλογή ευαίσθητων δεδομένων υγείας και βιομετρικών δεδομένων εγείρει σοβαρές ανησυχίες για την προστασία της ιδιωτικής ζωής. Οι φορητές συσκευές μεταδίδουν δεδομένα μέσω ασύρματων δικτύων, γεγονός που τις καθιστά ευάλωτες σε κυβερνοεπιθέσεις, πειρατεία ή μη εξουσιοδοτημένη πρόσβαση. Η διασφάλιση της κρυπτογράφησης δεδομένων, του ασφαλούς ελέγχου ταυτότητας και της συμμόρφωσης με τους κανονισμούς (π.χ. GDPR, HIPAA) είναι απαραίτητη για την προστασία της ιδιωτικής ζωής των χρηστών και την αποτροπή παραβιάσεων δεδομένων.
- **Συμμόρφωση των χρηστών και φορεσιμότητα.** Για να είναι αποτελεσματικοί οι φορητοί αισθητήρες, οι χρήστες πρέπει να τους φορούν και να τους χρησιμοποιούν με συνέπεια και σωστά. Η δυσφορία, ο ερεθισμός του δέρματος, ο όγκος της συσκευής ή η έλλειψη αντιλαμβανόμενης χρησιμότητας μπορεί να οδηγήσουν σε μη συμμόρφωση, επηρεάζοντας τη συλλογή δεδομένων. Ο σχεδιασμός ελαφρών, διακριτικών και φιλικών προς τον χρήστη φορητών συσκευών που ενσωματώνονται απρόσκοπτα στην καθημερινή ζωή είναι ζωτικής σημασίας για τη μακροπρόθεσμη συμμόρφωση [35].



Εικόνα 18: Προκλήσεις Φορέσιμων Αισθητήρων

Παρά τις προκλήσεις αυτές, οι συνεχείς εξελίξεις στην τεχνολογία των αισθητήρων, την τεχνητή νοημοσύνη και την ασύρματη επικοινωνία βελτιώνουν συνεχώς την αποτελεσματικότητα και την αξιοπιστία της συλλογής και της επεξεργασίας δεδομένων που φοριούνται. Η αντιμετώπιση αυτών των περιορισμών θα είναι το κλειδί για την πλήρη αξιοποίηση των δυνατοτήτων των φορητών αισθητήρων στην υγειονομική περίθαλψη, τη γυμναστική και όχι μόνο, καθιστώντας τους πιο ακριβείς, ασφαλείς και φιλικούς προς τον χρήστη για ευρεία υιοθέτηση.



3. Βιβλιογραφική Ανασκόπηση (Literature Review)

Σκοπός της βιβλιογραφικής ανασκόπησης που πραγματοποιήθηκε για την παρούσα διπλωματική εργασία είναι η διερεύνηση της υφιστάμενης ερευνητικής δραστηριότητας σχετικά με την αναγνώριση ανθρώπινης δραστηριότητας (HAR) μέσω δεδομένων από φορέσιμους αισθητήρες και την εφαρμογή αλγορίθμων μηχανικής μάθησης. Η ανασκόπηση αυτή είχε σαν στόχο να εντοπίσει τα κύρια ερευνητικά άρθρα που συνδυάζουν αυτούς τους τρεις τομείς, εξετάζοντας τη μεθοδολογία, τις εφαρμογές και τα αποτελέσματα που παρουσιάζουν.

3.1 Μηχανές και Ερώτημα Αναζήτησης

Για την αναζήτηση των σχετικών άρθρων χρησιμοποιήθηκαν οι εξής επιστημονικές μηχανές αναζήτησης:

- *IEEE Xplore*, με επίκεντρο ερευνητικές εργασίες τεχνολογικής φύσεως.
- *PubMed*, που ειδικεύεται σε άρθρα με επίκεντρο τη βιοϊατρική.
- *ScienceDirect* και *Scopus*, που καλύπτουν ένα ευρύ φάσμα επιστημονικών τομέων.


Οι λέξεις-κλειδιά που χρησιμοποιήθηκαν στις αναζητήσεις αποτελούνταν από τον συνδυασμό: **"HAR AND WEARABLE SENSORS DATA AND MACHINE LEARNING ALGORITHMS"**.

3.2 Διάγραμμα PRISMA

Από τα συνολικά 820 άρθρα που εντοπίστηκαν, επιλέχθηκαν 12 papers βάσει κριτηρίων όπως η συνάφεια με το θέμα, η σαφήνεια των μεθόδων και η πρακτική εφαρμογή των αποτελεσμάτων. Στη μελέτη αυτών των papers παρατηρήθηκε ότι, ενώ όλα περιλάμβαναν μοντέλα μηχανικής μάθησης και δεδομένα από φορέσιμους αισθητήρες, υπήρχαν ελλείψεις, όπως ο περιορισμένος αριθμός αλγορίθμων και η ανεπαρκής ανάλυση των αποτελεσμάτων.



Επιπλέον, κανένα από τα άρθρα δεν συνδύαζε δύο μεγάλα και δημοφιλή datasets, όπως τα **mHealth** και **WISDM**, ούτε εφαρμόζε αλγορίθμους μηχανικής μάθησης ταυτόχρονα και στα δύο. Η απουσία αυτή αφήνει σημαντικά κενά όσον αφορά τη γενικευσιμότητα και τη συγκριτική ανάλυση διαφορετικών μοντέλων σε ετερογενή δεδομένα. Επιπλέον, παρατηρήθηκε περιορισμένη ποικιλία φορέσιμων αισθητήρων, καθώς πολλά papers εστιάζουν αποκλειστικά σε επιταχυνσιόμετρα ή γυροσκόπια, χωρίς να εξετάζουν τη δυνατότητα συνδυαστικής χρήσης δεδομένων από διαφορετικούς αισθητήρες. Για παράδειγμα, αισθητήρες καρδιακού ρυθμού που εφαρμόστηκαν στη δική μας μελέτη μπορούν να προσφέρουν μια πιο ολοκληρωμένη κατανόηση της ανθρώπινης δραστηριότητας.



Εικόνα 19: Διάγραμμα PRISMA για την Βιβλιογραφική Ανασκόπηση



3.3 Εξαγωγή Αποτελεσμάτων

Η διαπίστωση αυτών των ελλείψεων αναδεικνύει την ανάγκη για τη συγγραφή της παρούσας διπλωματικής εργασίας. Στόχος είναι να προσφέρει μια πιο ολοκληρωμένη προσέγγιση, ενσωματώνοντας μεγαλύτερο εύρος αλγορίθμων μηχανικής μάθησης, τη συνδυαστική χρήση δεδομένων από διαφορετικούς αισθητήρες, λεπτομερέστερη ανάλυση αποτελεσμάτων και να προτείνει βελτιστοποιημένες μεθόδους για την αναγνώριση ανθρώπινης δραστηριότητας μέσω δεδομένων από φορέσιμους αισθητήρες.

Πίνακας 1: Πίνακας Λεπτομερειών Βιβλιογραφικής Ανασκόπησης

Συγγραφείς	Χρονιά	Τίτλος	Μέθοδοι	Αποτελέσματα
M. S. H. Bhuiyan, N. S. Patwary, P. K. Saha, M. T. Hossain.	01-01-2020	Sensor-Based Human Activity Recognition: A Comparative Study of Machine Learning Techniques	Χρησιμοποιήθηκε το WISDM Dataset και οι αλγόριθμοι μηχανικής μάθησης που δοκιμάστηκαν ήταν οι αλγόριθμοι Random Forest (RF), K-Nearest Neighbors (KNN), Long Short-Term Memory (LSTM), Support Vector Machine (SVM) και Multilayer Perceptron (MLP).	Η μελέτη διαπίστωσε ότι η PCA σε συνδυασμό με RF πέτυχε την καλύτερη απόδοση, ειδικά σε δεδομένα επιταχυνσιόμετρου τηλεφώνου, με ακρίβεια 87,5%.
C. -T. Yen, J. -X. Liao, Y. -K. Huang	01-01-2020	Human Daily Activity Recognition Performed Using Wearable Inertial Sensors Combined With Deep Learning Algorithms	Για την αυτόματη εξαγωγή και ταξινόμηση των χαρακτηριστικών χρησιμοποιήθηκε ένα 1D Convolutional Neural Network (CNN), με τροποποιημένη δομή, εξαιρουμένων των στρωμάτων συγκέντρωσης για τη διατήρηση λεπτομερών χαρακτηριστικών. Χρησιμοποιήθηκε ο βελτιστοποιητής Adam με ρυθμό μάθησης 0,00001 και ως συνάρτηση απώλειας χρησίμευσε η κατηγορική διασταυρούμενη εντροπία.	Για το προσαρμοσμένο σύνολο δεδομένων, οι ακρίβειες εκπαίδευσης και δοκιμής ήταν 97,19% και 93,77%, αντίστοιχα. Τα αποτελέσματα αυτά κατέδειξαν την αποτελεσματικότητα της προτεινόμενης δομής CNN για την ακριβή αναγνώριση ανθρώπινων δραστηριοτήτων.
N. Tufek, M. Yalcin, M. Altintas, F. Kalaoglu, Y. Li, S. K. Bahadir	01-01-2020	Human Action Recognition Using Deep Learning Methods on Limited Sensory Data	Χρησιμοποιήθηκαν δύο σύνολα δεδομένων: το σύνολο δεδομένων UCI Human Activity Recognition (HAR) και ένα προσαρμοσμένο σύνολο δεδομένων που ονομάζεται ETEXWELD. Υλοποιήθηκαν διάφορα μοντέλα βαθιάς μάθησης: 1D CNN, 2D	Το μοντέλο LSTM 3 επιπέδων πέτυχε την καλύτερη απόδοση, επιτυγχάνοντας νέα κορυφαία ακρίβεια 97,4% στο σύνολο δεδομένων UCI HAR, όταν χρησιμοποιήθηκαν μόνο δεδομένα



			CNN, LSTM 2 επιπέδων, LSTM 3 επιπέδων, αμφίδρομο LSTM και ένα υβριδικό μοντέλο CNN-LSTM. Επιπλέον, δοκιμάστηκε η δυναμική χρονική στρέβλωση (DTW) με k-κοντινότερους γείτονες (kNN). Η εκπαίδευση περιελάμβανε 10πλό cross-validation και οι τεχνικές επαύξησης δεδομένων προσέθεσαν θόρυβο και μετατοπισμένα δεδομένα για να δημιουργήσουν πιο ισχυρά δείγματα εκπαίδευσης.	επιταχυνσιόμετρου και γυροσκοπίου. Για το σύνολο δεδομένων ETEXWELD, το ίδιο μοντέλο πέτυχε ακρίβεια 99,0%. Αξιολογήθηκαν μετρικές επιδόσεων για κάθε μοντέλο, αποκαλύπτοντας ότι οι προσεγγίσεις βαθιάς μάθησης, ιδίως οι αρχιτεκτονικές LSTM, υπερέβησαν τους παραδοσιακούς αλγόριθμους μηχανικής μάθησης, όπως ο kNN, όσον αφορά την ακρίβεια και το υπολογιστικό κόστος.
R. Khan, M. Abbas, R. Anjum, F. Waheed, S. Ahmed, F. Bangash	01-01-2020	Evaluating Machine Learning Techniques on Human Activity Recognition Using Accelerometer Data	Για τη μείωση των χαρακτηριστικών χρησιμοποιήθηκε η ανάλυση κύριων συνιστωσών (PCA). Η μελέτη εξέτασε διάφορους ταξινομητές μηχανικής μάθησης, όπως Random Forest (RF), k-Nearest Neighbors (KNN), Support Vector Machine (SVM) και Multilayer Perceptron (MLP). Το σύνολο δεδομένων που χρησιμοποιήθηκε προήλθε από μια δημόσια διαθέσιμη πηγή που περιελάμβανε συμμετέχοντες που εκτελούσαν πολλαπλές δραστηριότητες.	Η καλύτερη απόδοση επιτεύχθηκε από τον αλγόριθμο Random Forest (RF), ο οποίος πέτυχε ακρίβεια (accuracy) 86,35% σε δεδομένα επιταχυνσιόμετρου από smartphones. Άλλοι αλγόριθμοι, όπως ο LSTM, παρουσίασαν ανταγωνιστική ακρίβεια με 77,24%, ενώ οι KNN και SVM πέτυχαν χαμηλότερες ακρίβειες 59,65% και 60,59%, αντίστοιχα.
Alarfaj M, Al Madini A, Alsafran A, Farag M, Chtourou S, Afifi A, Ahmad A, Al Rubayyi O, Al Harbi A, Al Thunai M	01-01-2024	Wearable sensors based on artificial intelligence models for human activity recognition.	Η έρευνα χρησιμοποίησε συνελκτικά νευρωνικά δίκτυα (CNN) προσαρμοσμένα για διαφορετικούς τύπους αισθητήρων, συμπεριλαμβανομένων επιταχυνσιόμετρων, γυροσκοπίων και βαρομέτρων. Τα CNN εκπαιδεύτηκαν χρησιμοποιώντας το σύνολο δεδομένων FallAID, το οποίο περιλαμβάνει ποικίλα πρότυπα κίνησης και δραστηριότητες. Η προεπεξεργασία των δεδομένων περιελάμβανε την εξαγωγή χαρακτηριστικών για την εξαγωγή στατιστικών ιδιοτήτων όπως ο μέσος όρος και η τυπική απόκλιση, καθώς και τον καθαρισμό των δεδομένων για λόγους συνοχής.	Το προτεινόμενο μοντέλο late-fusion CNN επέδειξε ανώτερες επιδόσεις σε εργασίες HAR σε σύγκριση με έναν τυπικό ταξινομητή διανυσματικής μηχανής υποστήριξης (SVM). Το μοντέλο CNN πέτυχε ακρίβεια δοκιμής 94,83%, ξεπερνώντας σημαντικά την ακρίβεια δοκιμής 83,10% του SVM. Μετρικές επικύρωσης όπως ακρίβεια, ανάκληση και F1-score, επιβεβαίωσαν την ανθεκτικότητα της προσέγγισης CNN σε διάφορες κατηγορίες δραστηριοτήτων.
Fridriksdottir E, Bonomi AG	10-11-2020	Accelerometer-Based Human Activity Recognition for Patient	Αναπτύχθηκε ένα βαθύ νευρωνικό δίκτυο (DNN), το οποίο αποτελείται από τρία στρώματα συνελκτικού τύπου ακολουθούμενα από ένα στρώμα LSTM για την εξαγωγή χρονικών χαρακτηριστικών, με	Το DNN πέτυχε συνολική ακρίβεια δοκιμής 94,52%, ξεπερνώντας το 83,35% του SVM. Ενώ και τα δύο μοντέλα δυσκολεύτηκαν με τη διαφοροποίηση δραστηριοτήτων



Ku Abd Rahim KN, Elamvazuthi I, Izhar LI, Capi G		Monitoring Using a Deep Neural Network.	ενεργοποίηση ReLU. Το μοντέλο συγκρίθηκε με έναν ταξινομητή SVM, ενώ η τμηματοποίηση των δεδομένων πραγματοποιήθηκε με τη χρήση συρόμενου παραθύρου σταθερού μήκους (διαστήματα 6 δευτερολέπτων, 50% επικάλυψη).	όπως η άνοδος/κατέβασμα σκαλοπατιών, το DNN επέδειξε πιο ισορροπημένη και υψηλότερη απόδοση, όπως φαίνεται από μετρικές όπως η ακρίβεια, η ανάκληση και το F1-score.
	26-11-2018	Classification of Human Daily Activities Using Ensemble Methods Based on Smartphone Inertial Sensors.	Η προεπεξεργασία των δεδομένων περιελάμβανε τμηματοποίηση του σήματος (με χρήση ολισθαίνοντος παραθύρου) και φιλτράρισμα (διάμεσο και ζωνοπερατό φίλτρο Butterworth). Στη μελέτη χρησιμοποιήθηκαν πέντε μέθοδοι μάθησης συνόλου: Bagging, Adaboost, Rotation Forest, Ensembles of Nested Dichotomies (END) και Random Subspace, με SVM και Random Forest (RF) ως βασικούς εκπαιδευτές. Η απόδοση του μοντέλου αξιολογήθηκε με τη χρήση τόσο του holdout (διαχωρισμός 70/30) όσο και της 10 fold cross validation.	Το σύνολο Random Subspace με SVM πέτυχε την υψηλότερη ακρίβεια, φθάνοντας το 99,22% με 10-πλό cross-validation και το 98,74% με τη μέθοδο holdout. Τα μοντέλα με βάση το SVM ξεπέρασαν σταθερά το RF ως βασικό μαθητή σε όλες τις μετρικές αξιολόγησης, συμπεριλαμβανομένων της ακρίβειας, της ανάκλησης, του F-measure και του ROC. Η μελέτη έδειξε ότι οι μέθοδοι ensemble, ιδιαίτερα οι μέθοδοι Random Subspace, βελτίωσαν σημαντικά την ακρίβεια ταξινόμησης.
	09-05-2024	Human Activity Recognition Algorithm with Physiological and Inertial Signals Fusion: Photoplethysmography, Electrodermal Activity, and Accelerometry.	Τα δεδομένα συλλέχθηκαν από 23 άτομα με τις δραστηριότητες να ομαδοποιούνται με βάση την ένταση: χαμηλή, μεσαία και υψηλή. Η προεπεξεργασία των δεδομένων περιελάμβανε τμηματοποίηση με συρόμενο παράθυρο 10 δευτερολέπτων (50% επικάλυψη) και φιλτράρισμα. Εφαρμόστηκαν δύο μοντέλα: ένας ταξινομητής Random Forest (RF) και ένα προ-εκπαιδευμένο νευρωνικό δίκτυο συνέλιξης ResNet-18 (CNN) που εκπαιδεύτηκε σε εικόνες φασματογραφημάτων που δημιουργήθηκαν από τα σήματα.	Ο ταξινομητής RF πέτυχε υψηλές επιδόσεις ταξινόμησης χρησιμοποιώντας δεδομένα ACC-only, επιτυγχάνοντας βαθμολογία F1 77,42% για μεμονωμένες δραστηριότητες και 92,52% για ομαδοποιημένες δραστηριότητες. Ωστόσο, η προσθήκη σημάτων EDA και BVP βελτίωσε την ακρίβεια του CNN, επιτυγχάνοντας βαθμολογία F1 69,89% για μεμονωμένες δραστηριότητες και 87,51% για ομαδοποιημένες δραστηριότητες.
Sun, Yujie, Xu, Xiaolong, Tian, Xincheng, Zhou, Lelai, Li, Yibin	01-09-2024	Efficient human activity recognition: A deep convolutional transformer-based contrastive self-supervised approach using wearable sensors	Νέα μέθοδος για την HAR με τη χρήση βαθιών συνελκτικών μετασχηματιστών (DCT) και μια αντιθετική προσέγγιση αυτοεπιβλεπόμενης μάθησης. Η μέθοδος αξιοποιεί το πλαίσιο Bootstrap Your Own Latent (BYOL), όπου ένα μοντέλο DCT χρησιμεύει ως ραχοκοκαλιά για την εξαγωγή χαρακτηριστικών. Στο στάδιο της	Το μοντέλο DCTCSS πέτυχε κορυφαία αποτελέσματα, επιδεικνύοντας μέση βαθμολογία F1 95,64% στο UCI-HAR, 88,39% στο Skoda και 98,40% στο Mhealth, ακόμη και όταν εκπαιδεύτηκε μόνο με το 10% των επισημασμένων δεδομένων. Τα αποτελέσματα



Qu, Yuxun, Tang, Yongqiang, Yang, Xuebing, Wen, Yanlong, Zhang, Wensheng			τελειοποίησης, ένας γραμμικός ταξινομητής εκπαιδεύεται μόνο με ένα μικρό υποσύνολο (1-10%) επισημασμένων δεδομένων.	επιβεβαίωσαν την αποτελεσματικότητα του μοντέλου στην αναγνώριση δραστηριοτήτων με ελάχιστα επισημειωμένα δεδομένα.
	01-06-2023	Context-aware mutual learning for semi-supervised human activity recognition using wearable sensors	Η μέθοδος αυτή αξιοποιεί δύο κύρια δίκτυα που εκπαιδεύονται παράλληλα, ανταλλάσσοντας εποπτευόμενες πληροφορίες μέσω ψευδοετικετών για τον μετριασμό της υπερπροσαρμογής. Το πλαίσιο ενσωμάτωσε μια απώλεια διατήρησης της κατανομής (DPL) για την ευθυγράμμιση της κατανομής των κλάσεων των ψευδο-ετικετοποιημένων δεδομένων με τα επισημασμένα δεδομένα, μειώνοντας τα προβλήματα απόκλισης. Επιπλέον, στο βοηθητικό δίκτυο χρησιμοποιήθηκε μια μονάδα συνάθροισης με επίγνωση του πλαισίου (CAA) για την ενίσχυση της εκμάθησης χαρακτηριστικών με την ενσωμάτωση πληροφοριών πλαισίου από γειτονικές ακολουθίες.	Η προτεινόμενη μέθοδος ξεπέρασε τις επιδόσεις των παραδοσιακών μεθόδων με ημι-επίβλεψη, όπως η Pseudo Label, το Temporal Ensemble και ο Auto Encoder. Πέτυχε μέση βελτίωση του F1-score έως και 9,4% στο UCI-HAR, 10,4% στο WISDM, 17,5% στο PAMAP2 και 4,9% στο mHealth, όταν χρησιμοποιεί μόνο 0,5% δεδομένων με ετικέτες. Η συμπερίληψη των DPL και CAA οδήγησε σε πιο αξιόπιστες ψευδοετικέτες και καλύτερη γενίκευση, βελτιώνοντας σημαντικά την ακρίβεια ταξινόμησης σε όλα τα σύνολα δεδομένων.
	20-06-2024	Coupling Analysis of Multiple Machine Learning Models for Human Activity Recognition	Η εργασία εισήγαγε ένα πλαίσιο που συνδυάζει μοντέλα μηχανικής μάθησης (ML) και βαθιάς μάθησης (DL) για την HAR. Τα μοντέλα που βασίστηκαν στο ML περιλάμβαναν τις μηχανές διανυσμάτων υποστήριξης (SVM), Random Forest (RF) και Adaptive Neuro-Fuzzy Inference System (ANFIS), ενώ η προσέγγιση DL χρησιμοποίησε ένα υβριδικό 1D Convolutional Neural Network (1dCNN). Η επιλογή των χαρακτηριστικών βελτιστοποιήθηκε με τη χρήση Recursive Feature Elimination (RFE) με εκτιμητή SVM για την εξάλειψη των περιττών χαρακτηριστικών. Τα μοντέλα εκπαιδεύτηκαν και επικυρώθηκαν χρησιμοποιώντας έναν τυπικό διαχωρισμό 70/30 εκπαίδευσης-δοκιμής.	Το μοντέλο SVM πέτυχε την υψηλότερη συνολική ακρίβεια 95,8% στο σύνολο δεδομένων UCI-HAR, ξεπερνώντας το RF (91,7%) και το ANFIS (91,4% με επιλεγμένα χαρακτηριστικά). Το μοντέλο 1dCNN πέτυχε ακρίβεια 93% στο UCI-HAR και είχε άριστη απόδοση (100% ακρίβεια) στο MHEALTH χρησιμοποιώντας ανάλυση προσανατολισμένη στις ετικέτες. Για το σύνολο δεδομένων WISDM, τα μοντέλα 1dCNN και RF πέτυχαν ακρίβεια 91,4% και 87,3% αντίστοιχα.
Essa, Ehab, Abdelmaksoud, Islam R.	25-10-2023	Temporal-channel convolution with self-attention network for human activity	Η μελέτη εισήγαγε δύο νέες αρχιτεκτονικές: CSNet (Convolution with Self-Attention Network) και TCCSNet (Temporal-Channel Convolution with Self-Attention Network).	Το μοντέλο TCCSNet πέτυχε τις υψηλότερες επιδόσεις στα περισσότερα σύνολα δεδομένων, με ακρίβεια 98,6% στο MHEALTH,



		recognition using wearable sensors	Τα μοντέλα ενσωματώνουν 1D στρώματα συνέλιξης και έναν μηχανισμό αυτοπροσοχής για να συλλάβουν τόσο τις τοπικές όσο και τις παγκόσμιες εξαρτήσεις στα δεδομένα των αισθητήρων. Το CSNet επικεντρώνεται στην εξαγωγή χρονικών χαρακτηριστικών με τη χρήση συνέλιξης ακολουθούμενη από μπλοκ αυτοπροσοχής. Το TCCSNet επεκτείνει αυτή την προσέγγιση χρησιμοποιώντας δύο κλάδους: έναν κλάδο με βάση το χρόνο και έναν κλάδο με βάση το κανάλι, για τη σύλληψη των χρονικών και διακαναλικών εξαρτήσεων, αντίστοιχα.	89,1% στο PAMAP2 και 92,5% στο WISDM, ξεπερνώντας τα βασικά μοντέλα όπως το LSTM και το Transformer. Το CSNet παρουσίασε επίσης ισχυρές επιδόσεις, ιδίως στην καταγραφή των χρονικών εξαρτήσεων, φτάνοντας σε ακρίβεια 97,66% στο MHEALTH. Η ενσωμάτωση της αυτοπροσοχής βελτίωσε σημαντικά τις δυνατότητες γενίκευσης και των δύο μοντέλων, καθιστώντας τα ανθεκτικά σε σύνολα δεδομένων με διαφορετικές ρυθμίσεις αισθητήρων και πολυπλοκότητα δραστηριοτήτων.
--	--	------------------------------------	---	---



4. Μηχανική Μάθηση για Αναγνώριση Ανθρώπινης Δραστηριότητας

Η Αναγνώριση Ανθρώπινης Δραστηριότητας (HAR) είναι ένας κρίσιμος τομέας έρευνας στην τεχνητή νοημοσύνη και την πανταχού παρούσα πληροφορική, με εφαρμογές στην παρακολούθηση της υγείας, την παρακολούθηση της φυσικής κατάστασης και την αποκατάσταση. Η HAR περιλαμβάνει τον εντοπισμό και την ταξινόμηση των ανθρώπινων κινήσεων με βάση δεδομένα που συλλέγονται από αισθητήρες που φοριούνται, βιντεοσκοπήσεις ή αισθητήρες smartphone. Οι τεχνικές μηχανικής μάθησης (ML) διαδραματίζουν θεμελιώδη ρόλο στην επεξεργασία αυτών των δεδομένων αισθητήρων και στην ακριβή ταξινόμηση των διαφόρων δραστηριοτήτων. Αυτό το κεφάλαιο διερευνά τα θεωρητικά θεμέλια των αλγορίθμων μηχανικής μάθησης, συζητά διάφορες μεθόδους ταξινόμησης κατάλληλες για την HAR και εξηγεί πώς αυτά τα μοντέλα εκπαιδεύονται και αξιολογούνται για την αποτελεσματική αναγνώριση δραστηριοτήτων.


4.1 Θεωρητικό Υπόβαθρο Αλγορίθμων Μηχανικής Μάθησης

Στο πλαίσιο της αναγνώρισης ανθρώπινης δραστηριότητας (HAR), η Μηχανική Μάθηση διαδραματίζει κρίσιμο ρόλο στη μετατροπή των ακατέργαστων σημάτων αισθητήρων σε σημαντικές πληροφορίες, ανιχνεύοντας μοτίβα ή αλλιώς πρότυπα, ταξινομώντας δραστηριότητες και προβλέποντας ακόμη και μελλοντική συμπεριφορά. Οι φορητοί αισθητήρες, όπως τα επιταχυνσιόμετρα, τα γυροσκόπια και οι μετρητές καρδιακού ρυθμού, παράγουν τεράστιες ποσότητες δεδομένων χρονοσειράς, που καταγράφουν διάφορες πτυχές της ανθρώπινης κίνησης. Ωστόσο, αυτά τα ακατέργαστα δεδομένα (raw data) είναι συχνά θορυβώδη και πολύπλοκα, γεγονός που καθιστά δύσκολη την άμεση ερμηνεία τους. Οι αλγόριθμοι ML αντιμετωπίζουν αυτή την πρόκληση μαθαίνοντας πρότυπα από επισημασμένα δεδομένα με ετικέτες (μάθηση με επίβλεψη - supervised learning) ή ανακαλύπτοντας κρυφές δομές σε μη επισημασμένα δεδομένα (μάθηση χωρίς επίβλεψη - unsupervised learning) [36].



4.1.1 Στατιστική Μοντελοποίηση και Μηχανική Μάθηση (Statistical Modeling)

Η στατιστική μοντελοποίηση και η μηχανική μάθηση είναι στενά συνδεδεμένα πεδία, και τα δύο παίζουν σημαντικό ρόλο στην Αναγνώριση Ανθρώπινης Δραστηριότητας. Ενώ η στατιστική μοντελοποίηση επικεντρώνεται κυρίως στον καθορισμό μαθηματικών σχέσεων μεταξύ μεταβλητών, η μηχανική μάθηση δίνει έμφαση στη μάθηση από μεγάλα σύνολα δεδομένων για τη βελτίωση της απόδοσης με την πάροδο του χρόνου. Η βασική διαφορά μεταξύ αυτών των δύο προσεγγίσεων είναι ότι τα στατιστικά μοντέλα συνήθως υποθέτουν μια συγκεκριμένη κατανομή δεδομένων και βασίζονται στη θεωρία πιθανοτήτων για την εξαγωγή συμπερασμάτων, ενώ τα μοντέλα μηχανικής μάθησης βασίζονται σε υπολογιστικές τεχνικές για τον εντοπισμό μοτίβων χωρίς να κάνουν ισχυρές υποθέσεις σχετικά με την υποκείμενη κατανομή δεδομένων [37].



Εικόνα 20: Στατιστική Μοντελοποίηση και Μηχανική Μάθηση

Στο πλαίσιο της HAR, παραδοσιακά χρησιμοποιούνται στατιστικά μοντέλα όπως τα μοντέλα Hidden Markov Models (HMMs) και τα μοντέλα μίξης Gaussian Mixture Models (GMMs). Τα HMM είναι ιδιαίτερα αποτελεσματικά για διαδοχικά δεδομένα αισθητήρων, καθώς μοντελοποιούν τις δραστηριότητες ως μεταβάσεις μεταξύ κρυφών καταστάσεων.




Ομοίως, τα GMM βοηθούν στη μοντελοποίηση της κατανομής πιθανότητας των διαφόρων καταστάσεων δραστηριότητας, καθιστώντας τα χρήσιμα για εφαρμογές HAR όπου οι δραστηριότητες παρουσιάζουν διακριτές στατιστικές ιδιότητες. Ωστόσο, με την αυξανόμενη διαθεσιμότητα μεγάλων συνόλων δεδομένων αισθητήρων, οι τεχνικές μηχανικής μάθησης έχουν γίνει η προτιμώμενη επιλογή για HAR. Οι κλασικοί αλγόριθμοι μηχανικής μάθησης, όπως τα δέντρα αποφάσεων, οι μηχανές διανυσμάτων υποστήριξης (SVM) και τα τυχαία δάση, έχουν εφαρμοστεί με επιτυχία για την ταξινόμηση των ανθρώπινων δραστηριοτήτων με βάση τις μετρήσεις του επιταχυνσιόμετρου και του γυροσκοπίου. Πιο πρόσφατα, οι προσεγγίσεις βαθιάς μάθησης έχουν αποκτήσει ευρεία δημοτικότητα λόγω της ικανότητάς τους να μαθαίνουν αυτόματα πολύπλοκα χαρακτηριστικά από ακατέργαστα δεδομένα αισθητήρων, εξαλείφοντας την ανάγκη για χειροκίνητη εξαγωγή χαρακτηριστικών [38]. Είναι απαραίτητο να τονιστεί ότι, τα νευρωνικά δίκτυα, ιδίως τα συνεπαγωγικά νευρωνικά δίκτυα (CNN) και τα επαναλαμβανόμενα νευρωνικά δίκτυα (RNN), έχουν επιδείξει σημαντική βελτίωση της ακρίβειας των HAR.

4.1.2 Υπερβλεπόμενη και Μη Ελεγχόμενη Μάθηση (Supervised and Unsupervised Learning)

Οι αλγόριθμοι μηχανικής μάθησης που χρησιμοποιούνται στην HAR μπορούν γενικά να κατηγοριοποιηθούν σε δύο κύριους τύπους: μάθηση με επίβλεψη και μάθηση χωρίς επίβλεψη. Η μάθηση με επίβλεψη περιλαμβάνει την εκπαίδευση μοντέλων σε σύνολα δεδομένων με ετικέτες, όπου κάθε δείγμα εισόδου (π.χ. μετρήσεις επιταχυνσιόμετρου και γυροσκοπίου) συνδέεται με μια γνωστή ετικέτα δραστηριότητας (π.χ. περπάτημα, τρέξιμο ή καθιστή θέση). Το μοντέλο μαθαίνει μοτίβα από αυτά τα παραδείγματα και τα γενικεύει για να ταξινομήσει νέα, άγνωστα δεδομένα. Αυτή η προσέγγιση χρησιμοποιείται ευρέως στο HAR, δεδομένου ότι πολλά δημόσια διαθέσιμα σύνολα δεδομένων, όπως το σύνολο δεδομένων WISDM, περιέχουν δεδομένα δραστηριότητας με υπάρχουσες ετικέτες. Ορισμένοι από τους πιο συνηθισμένους αλγορίθμους μάθησης με επίβλεψη που χρησιμοποιούνται στο HAR περιλαμβάνουν τα δέντρα αποφάσεων, τα τυχαία δάση, τις μηχανές διανυσμάτων υποστήριξης (SVM) και τα νευρωνικά δίκτυα. Τα Δέντρα Αποφάσεων και τα Τυχαία Δάση λειτουργούν με τη μάθηση ιεραρχικών κανόνων απόφασης με βάση τα χαρακτηριστικά του αισθητήρα, καθιστώντας τα ιδιαίτερα ερμηνεύσιμα. Τα



SVM ταξινομούν τις δραστηριότητες βρίσκοντας το βέλτιστο όριο (υπερεπίπεδο) μεταξύ διαφορετικών κατηγοριών δραστηριοτήτων, ενώ τα μοντέλα βαθιάς μάθησης, όπως τα CNN και τα δίκτυα μακράς βραχυπρόθεσμης μνήμης (LSTM), εξάγουν αυτόματα τα σχετικά χαρακτηριστικά, καθιστώντας τα ιδιαίτερα αποτελεσματικά για εργασίες HAR που περιλαμβάνουν δεδομένα χρονοσειρών [39].



Εικόνα 21: Διαφορά Unsupervised / Supervised Μάθησης

Η μάθηση χωρίς επίβλεψη, αντίθετα, ασχολείται με δεδομένα χωρίς ετικέτες, δηλαδή ο αλγόριθμος πρέπει να ανακαλύψει μοτίβα και σχέσεις χωρίς σαφείς ετικέτες δραστηριότητας. Αυτή η προσέγγιση είναι χρήσιμη σε HAR όταν τα δεδομένα με ετικέτες είναι σπάνια ή ακριβά για να αποκτηθούν. Αντί να μαθαίνουν από προκαθορισμένες ετικέτες δραστηριότητας, οι αλγόριθμοι μάθησης χωρίς επίβλεψη βρίσκουν κρυφές δομές στα δεδομένα ομαδοποιώντας παρόμοιες ενδείξεις αισθητήρων. Μια από τις πιο συχνά χρησιμοποιούμενες τεχνικές μάθησης χωρίς επίβλεψη στην HAR είναι η ομαδοποίηση k-Means, η οποία χωρίζει τα δεδομένα αισθητήρων σε ομάδες με βάση την ομοιότητα, επιτρέποντας τον εντοπισμό διαφορετικών δραστηριοτήτων χωρίς προηγούμενη επισήμανση. Μια άλλη χρήσιμη τεχνική είναι η ανάλυση κύριων συνιστωσών (PCA), η οποία μειώνει τη διαστατικότητα των δεδομένων αισθητήρων, διατηρώντας παράλληλα τις πιο σημαντικές πληροφορίες, καθιστώντας τα μοντέλα πιο αποδοτικά [40].



Παρόλο που η μάθηση με επίβλεψη είναι η κυρίαρχη προσέγγιση στο HAR λόγω της διαθεσιμότητας συνόλων δεδομένων με ετικέτες, η μάθηση χωρίς επίβλεψη παίζει καθοριστικό ρόλο στην ανακάλυψη νέων μοτίβων δραστηριότητας και στη βελτίωση των μοντέλων όταν τα δεδομένα με ετικέτες είναι περιορισμένα. Σε ορισμένες περιπτώσεις, οι ερευνητές χρησιμοποιούν μάθηση με ημι-επίβλεψη (semi-supervised learning), η οποία συνδυάζει και τις δύο προσεγγίσεις για να αξιοποιήσει ένα μικρό όγκο δεδομένων με ετικέτες μαζί με μια μεγαλύτερη δεξαμενή δεδομένων χωρίς ετικέτες. Αυτή η υβριδική προσέγγιση συμβάλλει στη βελτίωση της γενίκευσης των μοντέλων HAR, μειώνοντας παράλληλα την εξάρτηση από εκτεταμένα σύνολα δεδομένων με ετικέτες. Καθώς τα συστήματα HAR συνεχίζουν να εξελίσσονται, ο συνδυασμός επιβλεπόντων, μη επιβλεπόντων και ημι- επιβλεπόντων τεχνικών μάθησης είναι πιθανό να διαδραματίσει κρίσιμο ρόλο στην ανάπτυξη ισχυρών και προσαρμόσιμων συστημάτων αναγνώρισης δραστηριοτήτων [41].

4.2 Επιλογή Αλγορίθμων για την Αναγνώριση Δραστηριότητας

Η αναγνώριση ανθρώπινων δραστηριοτήτων βασίζεται σε αλγορίθμους μηχανικής μάθησης για την ταξινόμηση διαφορετικών φυσικών δραστηριοτήτων με βάση δεδομένα αισθητήρων που συλλέγονται από φορητές συσκευές. Η επιλογή ενός κατάλληλου αλγορίθμου είναι ζωτικής σημασίας για την επίτευξη υψηλής ακρίβειας και αποτελεσματικότητας στην αναγνώριση διαφόρων δραστηριοτήτων. Στο HAR, τα δεδομένα αισθητήρων - όπως η επιτάχυνση, η γωνιακή ταχύτητα, ο καρδιακός ρυθμός και άλλα φυσιολογικά σήματα - υποβάλλονται σε επεξεργασία για την εξαγωγή σημαντικών χαρακτηριστικών που βοηθούν στην ταξινόμηση. Διαφορετικοί αλγόριθμοι χειρίζονται αυτά τα δεδομένα με διαφορετικούς τρόπους, που κυμαίνονται από απλά μοντέλα βασισμένα σε κανόνες έως σύνθετα δίκτυα βαθιάς μάθησης. Η επιλογή του αλγορίθμου εξαρτάται από παράγοντες όπως το μέγεθος του συνόλου δεδομένων, η υπολογιστική απόδοση και η πολυπλοκότητα των προτύπων δραστηριότητας. Ποιοι είναι όμως κάποιοι από τους βασικότερους αλγορίθμους που εφαρμόζονται στην HAR;




4.2.1 Decision Tree

Το Δέντρο Αποφάσεων (DT) είναι ένας αλγόριθμος μάθησης με επίβλεψη που χρησιμοποιείται ευρέως στην Αναγνώριση Ανθρώπινης Δραστηριότητας λόγω της απλότητας, της ερμηνευσιμότητας και της αποτελεσματικότητάς του. Λειτουργεί με αναδρομική κατάτμηση του συνόλου δεδομένων σε υποσύνολα με βάση τις τιμές των χαρακτηριστικών, σχηματίζοντας μια δενδροειδή δομή όπου κάθε εσωτερικός κόμβος αντιπροσωπεύει έναν κανόνα απόφασης και κάθε κόμβος φύλλου αντιστοιχεί σε μια ετικέτα κλάσης (δηλ. μια αναγνωρισμένη δραστηριότητα). Αυτή η μέθοδος επιτρέπει τη λήψη δομημένων και ιεραρχικών αποφάσεων, καθιστώντας την κατάλληλη για την αναγνώριση διαφόρων ανθρώπινων δραστηριοτήτων με βάση δεδομένα αισθητήρων [42].

Μερικά από τα πλεονεκτήματα των δένδρων απόφασης στο HAR είναι τα κάτωθι:

- *Ερμηνευσιμότητα:* Τα DT παρέχουν μια σαφή διαδικασία λήψης αποφάσεων, γεγονός που τα καθιστά χρήσιμα για εφαρμογές πραγματικού χρόνου.
- *Ελάχιστη προεπεξεργασία δεδομένων:* Χειρίζονται αποτελεσματικά τόσο αριθμητικά όσο και κατηγορικά δεδομένα.
- *Ιεραρχική ταξινόμηση:* Η δομημένη προσέγγιση επιτρέπει τη διαφοροποίηση μεταξύ σύνθετων δραστηριοτήτων.
- *Υπολογιστική αποδοτικότητα:* Σε σύγκριση με τα μοντέλα βαθιάς μάθησης, τα DT απαιτούν λιγότερη επεξεργαστική ισχύ, καθιστώντας τα κατάλληλα για φορητές συσκευές [43].



Εικόνα 22: Σχεδιασμός ενός Decision Tree




Στις εφαρμογές HAR, τα δέντρα αποφάσεων ταξινομούν τις ανθρώπινες δραστηριότητες με βάση δεδομένα αισθητήρων που συλλέγονται από συσκευές όπως επιταχυνσιόμετρα, γυροσκόπια και μαγνητόμετρα. Ο αλγόριθμος δέντρων απόφασης επεξεργάζεται αυτά τα δεδομένα εντοπίζοντας μοτίβα στην κίνηση και επιλέγοντας τα πιο σχετικά χαρακτηριστικά για τη διαφοροποίηση μεταξύ δραστηριοτήτων όπως το περπάτημα, το τρέξιμο, το κάθισμα ή το άλμα. Η διαδικασία τυπικά περιλαμβάνει:

- *Συλλογή και προεπεξεργασία δεδομένων:* Συγκέντρωση επισημασμένων δεδομένων αισθητήρα, χειρισμός ελλιπών τιμών και κανονικοποίηση χαρακτηριστικών.
- *Εξαγωγή χαρακτηριστικών:* Προσδιορισμός βασικών στατιστικών και βασισμένων στη συχνότητα χαρακτηριστικών.
- *Εκπαίδευση και δοκιμή μοντέλων:* Εκπαίδευση ενός DT σε επισημασμένα δεδομένα και αξιολόγηση της απόδοσής του με χρήση της ακρίβειας, της ακρίβειας, της ανάκλησης και του F1-score.
- *Πρόβλεψη:* Ανάπτυξη του εκπαιδευμένου μοντέλου για την ταξινόμηση δραστηριοτήτων σε πραγματικό χρόνο [44].

Παρά τα πλεονεκτήματά τους, τα Δέντρα Αποφάσεων είναι επιρρεπείς στην υπερπροσαρμογή (overfitting) και δυσκολεύονται με δεδομένα υψηλών διαστάσεων (high-dimensional data). Για την ενίσχυση της απόδοσης, οι μέθοδοι συνόλου, όπως τα τυχαία δάση και οι τεχνικές ενίσχυσης, μπορούν να βελτιώσουν την ακρίβεια και τη γενίκευση.

4.2.2 Random Forest

Το Random Forest (RF) είναι ένας ευρέως χρησιμοποιούμενος αλγόριθμος Μηχανικής Μάθησης που δημιουργεί πολλαπλά δέντρα αποφάσεων και συγκεντρώνει τις προβλέψεις τους για να βελτιώσει την ακρίβεια, την ανθεκτικότητα και τη γενίκευση. Αντί να βασίζεται σε ένα μόνο δέντρο απόφασης, ο RF κατασκευάζει ένα «δάσος» από δέντρα απόφασης, καθένα από τα οποία εκπαιδεύεται σε ένα τυχαίο υποσύνολο των δεδομένων εκπαίδευσης και ένα τυχαία επιλεγμένο υποσύνολο χαρακτηριστικών. Αυτή η τυχειότητα μειώνει τον κίνδυνο υπερπροσαρμογής (overfitting) και ενισχύει την ικανότητα του μοντέλου να γενικεύει σε άγνωστα δεδομένα, καθιστώντας το έναν αποτελεσματικό αλγόριθμο για την αναγνώριση ανθρώπινης δραστηριότητας (HAR).



Εικόνα 23: Σχεδιασμός ενός Random Forest

Όσον αφορά τα πλεονεκτήματα του συγκεκριμένου αλγορίθμου στο πεδίο του HAR είναι σημαντικό να τονιστούν τα κάτωθι:

- *Υψηλή ακρίβεια και ανθεκτικότητα:* Επιτυγχάνει υψηλή ακρίβεια ταξινόμησης και αποδίδει καλά ακόμη και με θορυβώδη ή ελλιπή δεδομένα αισθητήρων.
- *Πρόληψη του overfitting:* Σε αντίθεση με τα μεμονωμένα δέντρα απόφασης, το RF μειώνει την υπερπροσαρμογή με τη μέση τιμή πολλαπλών προβλέψεων, καθιστώντας το πιο γενικεύσιμο σε νέα δεδομένα.
- *Ευελιξία:* Μπορεί να χειριστεί τόσο εργασίες ταξινόμησης όσο και παλινδρόμησης, καθιστώντας το ευέλικτη επιλογή για διάφορες εφαρμογές HAR.
- *Ανάλυση σημασίας χαρακτηριστικών:* Παρέχει πληροφορίες σχετικά με το ποια χαρακτηριστικά συμβάλλουν περισσότερο στην ταξινόμηση, βοηθώντας στη βελτίωση της επιλογής αισθητήρων και στη βελτίωση της αποδοτικότητας του μοντέλου [45].

Από την άλλη πλευρά, όπως υπάρχουν θετικά χαρακτηριστικά, έτσι ακριβώς υπάρχουν και περιορισμοί του Random Forest στο αντικείμενο του HAR, μερικοί από τους οποίους είναι:

- *Υπολογιστική πολυπλοκότητα:* Καθώς αυξάνεται ο αριθμός των δέντρων, το μοντέλο γίνεται πιο απαιτητικό σε μνήμη και απαιτεί περισσότερο χρόνο επεξεργασίας, γεγονός που μπορεί να αποτελέσει περιορισμό για εφαρμογές HAR πραγματικού χρόνου.



- *Αργός χρόνος πρόβλεψης:* Ενώ το RF εκπαιδεύεται γρήγορα, η παραγωγή προβλέψεων μπορεί να είναι πιο αργή σε σύγκριση με απλούστερα μοντέλα, καθιστώντας το λιγότερο ιδανικό για εφαρμογές που απαιτούν άμεσα αποτελέσματα ταξινόμησης.
- *Έλλειψη ερμηνευσιμότητας:* Ενώ τα δέντρα απόφασης είναι ερμηνεύσιμα, ένα σύνολο πολλών δέντρων καθιστά το RF πιο δύσκολο να αναλυθεί και να εξηγηθεί σε σύγκριση με τα μεμονωμένα δέντρα.

Στο HAR, όπου τα δεδομένα αισθητήρων συχνά περιλαμβάνουν μετρήσεις επιταχυνσιόμετρου, γυροσκοπίου και μαγνητόμετρου, το RF μπορεί να διακρίνει αποτελεσματικά μεταξύ διαφορετικών δραστηριοτήτων, όπως το περπάτημα, το τρέξιμο και το κάθισμα. Η ικανότητα χειρισμού τόσο αριθμητικών όσο και κατηγορικών μεταβλητών, σε συνδυασμό με την ανθεκτικότητά της σε ελλείποντα ή θορυβώδη δεδομένα, την καθιστά ιδιαίτερα κατάλληλη για εφαρμογές με φορητούς αισθητήρες. Επιπλέον, το RF εκτελεί ενσωματωμένη επιλογή χαρακτηριστικών, που σημαίνει ότι μπορεί να κατατάξει τη σημασία των χαρακτηριστικών του αισθητήρα, συμβάλλοντας στη βελτιστοποίηση της απόδοσης του μοντέλου με τη μείωση των άσχετων εισόδων [46].

4.2.3 SVM

Τα Support Vector Machines (SVM) είναι ένας ευρέως χρησιμοποιούμενος αλγόριθμος μάθησης με επίβλεψη, γνωστός για την ανθεκτικότητά και την αποτελεσματικότητά του σε εργασίες ταξινόμησης, συμπεριλαμβανομένης της Αναγνώρισης Ανθρώπινης Δραστηριότητας (HAR). Το SVM είναι ιδιαίτερα χρήσιμο στο HAR επειδή μπορεί να χειριστεί αποτελεσματικά χαρακτηριστικά υψηλών διαστάσεων. Ο αλγόριθμος είναι ικανός να μαθαίνει από μικρά σύνολα δεδομένων, διατηρώντας παράλληλα ισχυρές επιδόσεις ταξινόμησης. Κατά τη διάρκεια της εκπαίδευσης, ο SVM κατασκευάζει υπερεπίπεδα για τον διαχωρισμό των σημείων δεδομένων με βάση τις ενδείξεις αισθητήρων, όπως οι μετρήσεις του επιταχυνσιόμετρου και του γυροσκοπίου. Εάν τα δεδομένα δεν είναι γραμμικά διαχωρίσιμα, εφαρμόζεται μια συνάρτηση πυρήνα (όπως πολυώνυμο, συνάρτηση ακτινικής βάσης (RBF) ή σιγμοειδής) για να μετασχηματίσει τα δεδομένα σε έναν χώρο υψηλότερων διαστάσεων όπου καθίσταται δυνατός ο γραμμικός διαχωρισμός [47].




Η χρήση του συγκεκριμένου αλγορίθμου στη HAR προσφέρει αξιολογικά πλεονεκτήματα, όπως:

- *Αποτελεσματικό σε χώρους υψηλών διαστάσεων:* Τα SVM αποδίδουν καλά ακόμη και όταν το σύνολο των χαρακτηριστικών είναι μεγάλο, καθιστώντας τα κατάλληλα για σύνθετες εφαρμογές HAR που περιλαμβάνουν πολλαπλές ενδείξεις αισθητήρων.
- *Ευσταθής με μικρά σύνολα δεδομένων:* Σε αντίθεση με τις μεθόδους βαθιάς μάθησης που απαιτούν μεγάλες ποσότητες δεδομένων, τα SVM μπορούν να επιτύχουν υψηλή ακρίβεια με σχετικά μικρά σύνολα δεδομένων εκπαίδευσης.
- *Ικανότητα γενίκευσης:* Τα SVM είναι λιγότερο επιρρεπή σε υπερπροσαρμογή, ιδίως όταν εφαρμόζεται κατάλληλη ρύθμιση των υπερπαραμέτρων - hyperparameter (όπως η επιλογή του σωστού πυρήνα (kernel) και της παραμέτρου κανονικοποίησης - regularization).

Βέβαια, υπάρχουν και μερικά μειονεκτήματα κατά την εφαρμογή των SVM στην HAR και αυτό έχει να κάνει με:

- *Υψηλό υπολογιστικό κόστος για μεγάλα σύνολα δεδομένων:* Το μοντέλο SVM γίνεται αργό και απαιτεί πολύ μνήμη καθώς αυξάνεται ο αριθμός των δειγμάτων εκπαίδευσης, καθιστώντας το λιγότερο αποδοτικό για εφαρμογές HAR σε πραγματικό χρόνο.
- *Η επιλογή των παραμέτρων είναι ζωτικής σημασίας:* Η επιλογή της συνάρτησης πυρήνα και των υπερπαραμέτρων επηρεάζει σημαντικά την απόδοση, απαιτώντας εκτεταμένη ρύθμιση για την επίτευξη βέλτιστων αποτελεσμάτων.
- *Δεν είναι ιδανικό για εφαρμογές HAR σε πραγματικό χρόνο:* Λόγω του υψηλού υπολογιστικού κόστους και της βραδύτερης ταχύτητας εξαγωγής συμπερασμάτων, το SVM μπορεί να μην είναι η καλύτερη επιλογή για εργασίες αναγνώρισης δραστηριότητας σε πραγματικό χρόνο σε συσκευές με περιορισμένους πόρους [48].



Εικόνα 24: Διάγραμμα Απεικόνισης SVM


Το SVM έχει χρησιμοποιηθεί με επιτυχία σε εργασίες HAR, όπως η αναγνώριση του περπατήματος, του τρεξίματος, του καθίσματος και άλλων φυσικών δραστηριοτήτων, με βάση δεδομένα αισθητήρων χρονοσειράς που συλλέγονται από wearables. Είναι ιδιαίτερα αποτελεσματική σε εργασίες δυαδικής ταξινόμησης, αλλά μπορεί να επεκταθεί σε προβλήματα πολλαπλών κατηγοριών.

4.2.4 K-Nearest Neighbors (K-NN)

Ο αλγόριθμος k-Nearest Neighbors (k-NN) είναι μια απλή αλλά αποτελεσματική μέθοδος μηχανικής μάθησης που βασίζεται σε περιπτώσεις και χρησιμοποιείται για εργασίες ταξινόμησης, συμπεριλαμβανομένης της αναγνώρισης ανθρώπινης δραστηριότητας (HAR). Σε αντίθεση με τα παραμετρικά μοντέλα, ο k-NN δεν υποθέτει μια υποκείμενη κατανομή δεδομένων- αντίθετα, ταξινομεί τα νέα σημεία δεδομένων με βάση την ετικέτα πλειοψηφίας μεταξύ των k πλησιέστερων γειτόνων τους στο χώρο χαρακτηριστικών. Στο πλαίσιο του HAR, το k-NN έχει επιδείξει μεγάλες δυνατότητες για τη βελτίωση της ακρίβειας ταξινόμησης, ιδίως στην αναγνώριση δραστηριοτήτων όπως το περπάτημα, το τρέξιμο, το κάθισμα και το ανέβασμα σκαλοπατιών. Ο αλγόριθμος λειτουργεί με τον υπολογισμό των αποστάσεων (συνήθως με τη χρήση της ευκλείδειας απόστασης) μεταξύ ενός test δοκιμής



και των αποθηκευμένων test εκπαίδευσης, και στη συνέχεια αναθέτει στο test δοκιμής την ετικέτα της πλειοψηφίας των k πλησιέστερων γειτόνων του. Η επιλογή του k παίζει καθοριστικό ρόλο στον καθορισμό της απόδοσης του ταξινομητή - ένα μικρότερο k μπορεί να οδηγήσει σε υπερβολική προσαρμογή (overfitting), ενώ ένα μεγαλύτερο k μπορεί να μειώσει το θόρυβο αλλά μπορεί να προκαλέσει υπερβολική γενίκευση του μοντέλου. Επιπλέον, το φιλτράρισμα του θορύβου στα ακατέργαστα δεδομένα αισθητήρων μπορεί να ενισχύσει την αξιοπιστία του k -NN σε πραγματικές εφαρμογές HAR [49].



Εικόνα 25: Διάγραμμα Απεικόνισης K-NN

Τα θετικά που μπορεί να προσφέρει ο k -NN αλγόριθμος στα συστήματα HAR είναι τα εξής:

- *Απλότητα και ερμηνευσιμότητα:* Το k -NN είναι διαισθητικό, εύκολο στην εφαρμογή και δεν απαιτεί εκτεταμένη εκπαίδευση του μοντέλου.
- *Αποτελεσματικότητα στην ταξινόμηση πολλαπλών κατηγοριών:* Το k -NN λειτουργεί καλά για τη διάκριση μεταξύ πολλαπλών τύπων δραστηριότητας όταν είναι διαθέσιμα επαρκή επισημασμένα δεδομένα.
- *Προσαρμοστικότητα:* Μπορεί να ενισχυθεί με στάθμιση απόστασης, δυναμική επιλογή του k και μεθόδους επιλογής χαρακτηριστικών για τη βελτίωση της ακρίβειας.

Ενώ από την αντίθετη πλευρά, οι περιορισμοί που εμφανίζονται κατά την χρήση τους είναι:




- *Υπολογιστική πολυπλοκότητα:* Καθώς το k-NN απαιτεί την αποθήκευση και τη σύγκριση όλων των δειγμάτων εκπαίδευσης, καθίσταται υπολογιστικά δαπανηρό για μεγάλα σύνολα δεδομένων HAR.
- *Εντατική μνήμη:* Ο αλγόριθμος πρέπει να διατηρεί ολόκληρο το σύνολο δεδομένων, γεγονός που οδηγεί σε υψηλή κατανάλωση μνήμης.
- *Ευαίσθητος σε θορυβώδη και μη ισορροπημένα δεδομένα:* Εάν τα δεδομένα αισθητήρων περιέχουν θόρυβο ή εάν ορισμένες κλάσεις δραστηριότητας υποεκπροσωπούνται (underrepresented), το k-NN μπορεί να δυσκολευτεί με εσφαλμένη ταξινόμηση [50].

4.2.5 Naive Bayes

Ο Naive Bayes (NB) είναι ένας πιθανοτικός αλγόριθμος ταξινόμησης που βασίζεται στο θεώρημα του Bayes, ο οποίος υπολογίζει την πιθανότητα μιας κλάσης δεδομένων των παρατηρούμενων χαρακτηριστικών. Υποθέτει ότι όλα τα χαρακτηριστικά είναι υπό όρους ανεξάρτητα, δηλαδή ότι η παρουσία ενός χαρακτηριστικού δεν επηρεάζει την παρουσία ενός άλλου. Αυτή η απλουστευτική υπόθεση, αν και συχνά μη ρεαλιστική, καθιστά το μοντέλο υπολογιστικά αποδοτικό και εύκολο στην εκπαίδευση, ιδίως σε μικρά σύνολα δεδομένων. Ο ταξινομητής υπολογίζει τις εκ των υστέρων πιθανότητες με βάση τη συνάρτηση πιθανότητας και την εκ των προτέρων πιθανότητα, επιλέγοντας την κλάση με την υψηλότερη πιθανότητα [51].

Στο HAR, χρησιμοποιείται για την ταξινόμηση των δραστηριοτήτων με βάση τις ενδείξεις αισθητήρων. Το μοντέλο μαθαίνει την κατανομή των χαρακτηριστικών των αισθητήρων για διαφορετικές κατηγορίες δραστηριοτήτων και προβλέπει την πιο πιθανή δραστηριότητα για ένα δεδομένο σύνολο ενδείξεων αισθητήρων. Δεδομένου ότι το HAR συχνά περιλαμβάνει δεδομένα υψηλής διάστασης, ο αλγόριθμος μπορεί να είναι αποτελεσματικός λόγω της ικανότητάς του να κλιμακώνεται καλά και να επεξεργάζεται δεδομένα γρήγορα. Ωστόσο, η παραδοχή της ανεξαρτησίας των χαρακτηριστικών μπορεί να είναι περιοριστική, καθώς οι ενδείξεις των αισθητήρων συχνά συσχετίζονται στις εφαρμογές του πραγματικού κόσμου.



Εικόνα 26: Σχεδιασμός Naive Bayes

Για αυτόν τον λόγο υπάρχουν και παρακάτω περιορισμοί του αλγορίθμου:

- *Υπόθεση ανεξαρτησίας των χαρακτηριστικών:* Αυτό παραβιάζει τη βασική υπόθεση του μοντέλου και μπορεί να μειώσει την ακρίβεια.
- *Πρόβλημα μηδενικής συχνότητας:* Εάν μια τιμή χαρακτηριστικού αισθητήρα λείπει από τα δεδομένα εκπαίδευσης για μια συγκεκριμένη κλάση, η πιθανότητα αυτής της κλάσης μπορεί να γίνει μηδενική. Η εξομάλυνση Laplace χρησιμοποιείται συνήθως για τον μετριασμό αυτού του προβλήματος.
- *Περιορισμένη ικανότητα σύλληψης πολύπλοκων σχέσεων:* Δεδομένου ότι ο Naive Bayes δεν μοντελοποιεί αλληλεπιδράσεις μεταξύ χαρακτηριστικών, μπορεί να δυσκολευτεί με πιο σύνθετα σενάρια HAR.

Είναι σημαντικό όμως να τονιστούν και τα θετικά χαρακτηριστικά της εφαρμογής του, όπως:

- *Γρήγορα και αποτελεσματικά:* Ο Naive Bayes είναι υπολογιστικά αποδοτικός, καθιστώντας τον κατάλληλο για εφαρμογές HAR σε πραγματικό χρόνο.
- *Χειρίζεται καλά δεδομένα υψηλών διαστάσεων:* Μπορεί να ταξινομήσει δραστηριότητες με τη χρήση μεγάλου αριθμού χαρακτηριστικών αισθητήρων χωρίς σημαντική πτώση των επιδόσεων.




- Απαιτεί λίγα δεδομένα εκπαίδευσης: Σε αντίθεση με πιο σύνθετα μοντέλα, το Naive Bayes μπορεί να αποδώσει καλά ακόμη και με μικρά σύνολα δεδομένων εκπαίδευσης [52].

4.2.6 Neural Networks – CNN

Τα νευρωνικά δίκτυα έχουν αναδειχθεί ως ένα ισχυρό εργαλείο στην αναγνώριση ανθρώπινης δραστηριότητας λόγω της ικανότητάς τους να εξάγουν αυτόματα μοτίβα από ακατέργαστα δεδομένα αισθητήρων (raw sensor data). Μεταξύ των διαφορετικών αρχιτεκτονικών νευρωνικών δικτύων, τα συνεπαγωγικά νευρωνικά δίκτυα (CNN) και τα ανακυκλούμενα νευρωνικά δίκτυα (RNN) είναι τα πιο ευρέως χρησιμοποιούμενα για εφαρμογές HAR [53].

Τα CNN υπερέχουν στη καταγραφή χωρικών εξαρτήσεων σε δομημένα δεδομένα και έχουν αποδειχθεί ιδιαίτερα αποτελεσματικά στην ανάλυση σημάτων αισθητήρων, όπως να επεξεργάζονται εικόνες σε εργασίες computer vision. Από την άλλη πλευρά, τα RNNs, ιδίως τα δίκτυα μακράς βραχυπρόθεσμης μνήμης (LSTM), έχουν σχεδιαστεί για να μοντελοποιούν τις χρονικές εξαρτήσεις σε διαδοχικά δεδομένα, καθιστώντας τα κατάλληλα για εργασίες HAR όπου οι δραστηριότητες εξελίσσονται με την πάροδο του χρόνου.



Εικόνα 27: Απεικόνιση Νευρωνικών Δικτύων (CNN)



Τα CNNs έχουν επιδείξει ισχυρές επιδόσεις στο HAR μαθαίνοντας αυτόματα αναπαραστάσεις χαρακτηριστικών από ακατέργαστα δεδομένα αισθητήρων, όπως οι μετρήσεις του επιταχυνσιόμετρου και του γυροσκοπίου. Δεδομένου ότι τα δεδομένα αισθητήρων μπορούν να δομηθούν ως σήματα χρονοσειρών (time-series), τα CNN εφαρμόζουν φίλτρα συνελίξεων 1D για την εξαγωγή σημαντικών χωρικών χαρακτηριστικών, μειώνοντας την ανάγκη για χειροκίνητη μηχανική των χαρακτηριστικών. Αυτή η προσέγγιση επιτρέπει στα CNN να καταγράφουν τις τοπικές εξαρτήσεις στα σήματα αισθητήρων, κάτι που είναι ζωτικής σημασίας για τη διάκριση διαφορετικών ανθρώπινων δραστηριοτήτων [54].

Τα μοντέλα βαθιάς μάθησης, ιδίως τα CNN, έχουν κερδίσει δημοτικότητα λόγω της ανθεκτικότητάς τους στην ταξινόμηση δραστηριοτήτων σε πραγματικό χρόνο. Ωστόσο, απαιτούν μεγάλα μαρκαρισμένα σύνολα δεδομένων και εκτεταμένη ρύθμιση των υπερπαραμέτρων για βέλτιστη απόδοση. Τα μοντέλα HAR που βασίζονται σε CNN μπορούν να αναπτυχθούν σε κινητές συσκευές, αλλά η υπολογιστική πολυπλοκότητά τους δημιουργεί προκλήσεις για την εξαγωγή συμπερασμάτων σε πραγματικό χρόνο, ιδίως σε συσκευές με περιορισμένους πόρους, όπως τα smartphones και τα smartwatches.

Υβριδικά μοντέλα που συνδυάζουν CNNs και LSTMs έχουν επίσης διερευνηθεί στην HAR, αξιοποιώντας την ικανότητα εξαγωγής χωρικών χαρακτηριστικών των CNNs και την ικανότητα διαδοχικής μοντελοποίησης των LSTMs. Αυτά τα μοντέλα βελτιώνουν την ακρίβεια ταξινόμησης καταγράφοντας τόσο τις τοπικές όσο και τις χρονικές εξαρτήσεις [55].

Μερικά από τα πλεονεκτήματα των νευρωνικών δικτύων στο HAR είναι τα εξής:

- *Αυτόματη εξαγωγή χαρακτηριστικών:* Σε αντίθεση με τις παραδοσιακές προσεγγίσεις μηχανικής μάθησης που βασίζονται σε χειροποίητα χαρακτηριστικά, τα CNN και τα RNN μαθαίνουν αυτόματα τα σχετικά μοτίβα από τα ακατέργαστα δεδομένα αισθητήρων, μειώνοντας την ανάγκη για εκτεταμένη προεπεξεργασία.
- *Υψηλή ακρίβεια:* Τα μοντέλα βαθιάς μάθησης, ιδίως τα CNNs και τα LSTMs, επιτυγχάνουν ανώτερη ακρίβεια ταξινόμησης σε σύγκριση με τους παραδοσιακούς αλγόριθμους, ιδίως όταν εκπαιδεύονται σε σύνολα δεδομένων μεγάλης κλίμακας.



- *Χειρισμός σύνθετων και θορυβωδών δεδομένων:* Τα CNNs αντιμετωπίζουν αποτελεσματικά το θόρυβο των αισθητήρων και τις ελλείπουσες τιμές, καθιστώντας τα ανθεκτικά στις πραγματικές διακυμάνσεις των δεδομένων HAR.
- *Επεκτασιμότητα:* Τα CNNs και τα RNNs μπορούν να εκπαιδευτούν σε μεγάλα σύνολα δεδομένων και να ρυθμιστούν λεπτομερώς για να βελτιώσουν τη γενίκευση σε διάφορες δραστηριότητες και θέματα.

Ενώ, τα μειονεκτήματα που μπορεί να εμφανιστούν κατά την εφαρμογή τους είναι τα:

- *Υψηλό υπολογιστικό κόστος:* Τα μοντέλα βαθιάς μάθησης απαιτούν σημαντική υπολογιστική ισχύ, γεγονός που καθιστά δύσκολη την ανάπτυξή τους σε συσκευές χαμηλής ισχύος, όπως τα smartwatches. Τα CNN και τα LSTM συχνά απαιτούν εξειδικευμένο υλικό (GPUs/TPUs) για αποτελεσματική εκπαίδευση και εξαγωγή συμπερασμάτων.
- *Μεγάλη απαίτηση δεδομένων εκπαίδευσης:* Σε αντίθεση με τους παραδοσιακούς αλγόριθμους όπως ο k-NN ή ο SVM, τα νευρωνικά δίκτυα απαιτούν μεγάλα σύνολα δεδομένων με ετικέτες για αποτελεσματική μάθηση. Τα περιορισμένα δεδομένα εκπαίδευσης μπορεί να οδηγήσουν σε υπερπροσαρμογή, μειώνοντας τη γενίκευση του μοντέλου.
- *Περιορισμένη απόδοση σε πραγματικό χρόνο:* Η ανάπτυξη μοντέλων βαθιάς μάθησης για HAR σε ενσωματωμένες συσκευές απαιτεί τεχνικές βελτιστοποίησης, όπως συμπίεση μοντέλου και κλάδεμα για τη μείωση της μνήμης και του υπολογιστικού αποτυπώματος [56].

4.3 Εξάσκηση και Αξιολόγηση των Μοντέλων (Training and Evaluation of the Models)


Μετά την επιλογή ενός κατάλληλου μοντέλου μηχανικής μάθησης για την αναγνώριση ανθρώπινης δραστηριότητας, είναι ζωτικής σημασίας να διασφαλιστεί η αξιοπιστία και η γενίκευσή του μέσω μιας καλά δομημένης διαδικασίας εκπαίδευσης και αξιολόγησης. Αυτό περιλαμβάνει τον διαχωρισμό του συνόλου δεδομένων σε σύνολα εκπαίδευσης, επικύρωσης και δοκιμής, τη λεπτομερή ρύθμιση των υπερπαραμέτρων και την αξιολόγηση της απόδοσης με τη χρήση αντικειμενικών μετρικών. Για να επιτευχθούν αξιόπιστα και αμερόληπτα



αποτελέσματα, χρησιμοποιούνται τεχνικές διασταυρούμενης επικύρωσης για να αξιολογηθεί πόσο καλά το μοντέλο γενικεύεται σε αθέατα και καινούρια δεδομένα. Επιπλέον, διάφορες μετρικές αξιολόγησης, όπως η ακρίβεια (συνολική ορθότητα - accuracy), η ακρίβεια (precision), η ανάκληση (recall) και το F1-score, παρέχουν πληροφορίες σχετικά με την αποτελεσματικότητα κάθε μοντέλου στην ορθή ταξινόμηση των ανθρώπινων δραστηριοτήτων [57]. Τα ακόλουθα υποκεφάλαια θα διερευνήσουν λεπτομερώς αυτές τις πτυχές, καλύπτοντας τη σημασία των στρατηγικών διασταυρούμενης επικύρωσης και τις βασικές μετρικές απόδοσης που χρησιμοποιούνται για την αξιολόγηση των μοντέλων HAR.

4.3.1 Τεχνικές Διασταύρωσης (Cross-validation)

Για να διασφαλιστεί η αξιοπιστία και η ευρωστία ενός μοντέλου μηχανικής μάθησης, είναι απαραίτητο να χρησιμοποιούνται τεχνικές επικύρωσης που παρέχουν μια αμερόληπτη εκτίμηση της απόδοσής του. Μεταξύ των διαφόρων μεθόδων επικύρωσης, η k-Fold Cross-Validation (k-CV) υιοθετείται ευρέως λόγω της ικανότητάς της να αξιοποιεί αποτελεσματικά τα δεδομένα, μειώνοντας παράλληλα τους κινδύνους υπερπροσαρμογής. Αυτή η τεχνική είναι ιδιαίτερα χρήσιμη όταν πρόκειται για σύνολα δεδομένων μικρού ή μεσαίου μεγέθους, καθώς διασφαλίζει ότι όλα τα σημεία δεδομένων (data points) χρησιμοποιούνται τόσο για την εκπαίδευση όσο και για τη δοκιμή σε διαφορετικά στάδια [58].



Εικόνα 28: Αρχιτεκτονική της k Fold Cross Validation



Στην k-Fold Cross-Validation, το σύνολο δεδομένων χωρίζεται τυχαία σε k υποσύνολα ίσου μεγέθους (πτυχές). Το μοντέλο εκπαιδεύεται σε (k-1) αναδιπλώσεις (folds) και δοκιμάζεται στις υπόλοιπες αναδιπλώσεις. Αυτή η διαδικασία επαναλαμβάνεται k φορές, με κάθε αναδίπλωση να χρησιμεύει ως σύνολο δοκιμών (test set) μία φορά, και η τελική απόδοση του μοντέλου καθορίζεται από το μέσο όρο των αποτελεσμάτων και των k επαναλήψεων. Το κύριο πλεονέκτημα του k-CV είναι ότι μειώνει τη διακύμανση που σχετίζεται με ένα μόνο διαχωρισμό εκπαίδευσης-δοκιμής (train - test) και παρέχει μια πιο αξιόπιστη εκτίμηση της γενικευσιμότητας του μοντέλου. Ωστόσο, υποθέτει ότι τα δείγματα δεδομένων είναι ανεξάρτητα και ταυτόσημα κατανομημένα, δηλαδή προέρχονται από την ίδια στατιστική κατανομή και δεν παρουσιάζουν εξαρτήσεις.

Στην Αναγνώριση Ανθρώπινης Δραστηριότητας, η υπόθεση αυτή συχνά παραβιάζεται, επειδή τα δεδομένα που συλλέγονται από το ίδιο άτομο τείνουν να συσχετίζονται λόγω βιολογικών, περιβαλλοντικών και συμπεριφορικών παραγόντων. Επιπλέον, τα συστήματα HAR που βασίζονται σε αισθητήρες χρησιμοποιούν συχνά επικαλυπτόμενα συρόμενα παράθυρα (overlapping sliding windows) για την κατάτμηση δεδομένων χρονοσειρών (time-series data), οδηγώντας σε πιθανή διαρροή πληροφοριών εάν διαδοχικά δείγματα από το ίδιο άτομο εμφανίζονται τόσο στα σύνολα εκπαίδευσης όσο και στα σύνολα δοκιμής. Ως αποτέλεσμα, το k-CV μπορεί να υπερεκτιμήσει την ακρίβεια του μοντέλου, καθώς τα πρότυπα που μαθαίνονται από ένα τμήμα των δεδομένων ενός ατόμου μπορεί να επηρεάσουν άδικα τις προβλέψεις σε ένα άλλο τμήμα από το ίδιο άτομο [59].

Παρά τις προκλήσεις αυτές, η k-Fold Cross Validation παραμένει μια πολύτιμη τεχνική αξιολόγησης στο HAR, ιδίως όταν εφαρμόζεται με προσεκτική διαμέριση του συνόλου δεδομένων για την ελαχιστοποίηση της μεροληψίας. Εξασφαλίζοντας ότι ο διαχωρισμός των δεδομένων δεν εισάγει εξαρτήσεις, οι ερευνητές μπορούν να ενισχύσουν τη γενίκευση του μοντέλου και να αποκτήσουν μια πιο ακριβή αξιολόγηση της απόδοσής του στον πραγματικό κόσμο. Ωστόσο, όταν εργάζονται με σύνολα δεδομένων HAR που περιέχουν παραλλαγές ειδικά για το υποκείμενο, εναλλακτικές στρατηγικές επικύρωσης, όπως η διασταυρούμενη επικύρωση Leave-One-Subject-Out (LOSO), μπορεί μερικές φορές να είναι πιο κατάλληλη [60].

Με την προσεκτική εφαρμογή της k-Fold Cross Validation, οι ερευνητές της HAR μπορούν να εξισορροπήσουν την αξιολόγηση της απόδοσης του μοντέλου με την υπολογιστική



αποδοτικότητα, βελτιώνοντας τελικά την ακρίβεια και την ανθεκτικότητα των συστημάτων αναγνώρισης δραστηριοτήτων.

4.3.2 Μετρικές Αξιολόγησης (Accuracy, Precision, Recall, F1 Score)

Για την αξιολόγηση της αποτελεσματικότητας των μοντέλων αναγνώρισης ανθρώπινης δραστηριότητας, είναι ζωτικής σημασίας η χρήση καθιερωμένων μετρικών αξιολόγησης που παρέχουν εικόνα της απόδοσης του μοντέλου. Αυτές οι μετρικές βοηθούν να προσδιοριστεί πόσο καλά το μοντέλο ταξινομεί τις δραστηριότητες και αν γενικεύει αποτελεσματικά σε άγνωστα δεδομένα. Μεταξύ των πιο συχνά χρησιμοποιούμενων μετρικών στο HAR είναι το Accuracy, το Precision, το Recall και το F1 Score, κάθε μία από τις οποίες προσφέρει μια μοναδική προοπτική για την απόδοση της ταξινόμησης. Το Accuracy παρέχει ένα συνολικό μέτρο της ορθότητας, ενώ το Precision εστιάζει στην ελαχιστοποίηση των ψευδώς θετικών αποτελεσμάτων. Το Recall δίνει έμφαση στον ορθό εντοπισμό πραγματικών περιπτώσεων δραστηριότητας, κάτι που είναι ιδιαίτερα σημαντικό στις ιατρικές εφαρμογές και στις εφαρμογές με κρίσιμη σημασία για την ασφάλεια. Τέλος, το F1 Score εξισορροπεί το Precision και το Recall, εξασφαλίζοντας μια ισχυρή αξιολόγηση όταν πρόκειται για μη ισορροπημένα σύνολα δεδομένων [61]. Στις υποενότητες που ακολουθούν γίνεται έμφαση σε κάθε μετρική, εξηγώντας τη σημασία και τον ρόλο τους στην αξιολόγηση μοντέλων HAR.

4.3.2.1 Accuracy

Η ακρίβεια είναι μία από τις πιο συχνά χρησιμοποιούμενες μετρικές αξιολόγησης στην HAR και παρέχει ένα γενικό μέτρο του πόσο καλά ένα μοντέλο ταξινομεί σωστά τις δραστηριότητες. Ορίζεται ως ο λόγος των σωστά προβλεπόμενων περιπτώσεων -τόσο των Αληθώς Θετικών (TP) όσο και των Αληθώς Αρνητικών (TN)- προς τον συνολικό αριθμό των περιπτώσεων, συμπεριλαμβανομένων των Ψευδώς Θετικών (FP) και των Ψευδώς Αρνητικών (FN) . Μαθηματικά, εκφράζεται ως εξής:



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

Μια υψηλή τιμή Accuracy υποδηλώνει ότι το μοντέλο πραγματοποιεί σημαντικό αριθμό σωστών προβλέψεων, αλλά είναι σημαντικό να ερμηνεύεται αυτή η μέτρηση μαζί με άλλες, ιδίως όταν πρόκειται για ανισόρροπα σύνολα δεδομένων όπου ορισμένες δραστηριότητες μπορεί να είναι συχνότερες από άλλες. Διάφοροι παράγοντες επηρεάζουν την ακρίβεια των μοντέλων HAR, συμπεριλαμβανομένης της τοποθέτησης αισθητήρων, της ποιότητας των δεδομένων, της πολυπλοκότητας των δραστηριοτήτων και της ακρίβειας χειροκίνητης επισήμανσης. Η θέση των φορητών αισθητήρων επηρεάζει σημαντικά το Accuracy, καθώς οι αισθητήρες που τοποθετούνται στον καρπό ή τον αστράγαλο καταγράφουν περισσότερες κινήσεις αλλά εισάγουν υψηλότερο θόρυβο, ενώ εκείνοι που βρίσκονται στη μέση ή το ισχίο παρέχουν πιο σταθερές μετρήσεις για την αναγνώριση κινήσεων ολόκληρου του σώματος. Επιπλέον, ο ασυνεπής προσανατολισμός των αισθητήρων μπορεί να εισάγει σφάλματα εάν δεν ληφθεί υπόψη στο μοντέλο. Δεδομένου ότι τα μοντέλα HAR βασίζονται σε δεδομένα χρονοσειρών, ο ρυθμός δειγματοληψίας παίζει επίσης κρίσιμο ρόλο στην απόδοση ταξινόμησης. Οι συσκευές αισθητήρων με χαμηλή ισχύ μπορεί να μειώσουν τον ρυθμό δειγματοληψίας για να εξοικονομήσουν ενέργεια, δημιουργώντας ένα συμβιβασμό μεταξύ υπολογιστικής απόδοσης και ακρίβειας ταξινόμησης. Οι αποτυχίες του δικτύου σε συστήματα που βασίζονται σε αισθητήρες μπορεί να οδηγήσουν περαιτέρω σε έλλειψη δεδομένων, επηρεάζοντας αρνητικά την απόδοση [62].

Ένας άλλος σημαντικός παράγοντας είναι η πολυπλοκότητα της δραστηριότητας, καθώς η αναγνώριση απλών δραστηριοτήτων όπως το περπάτημα ή το κάθισμα είναι συνήθως ευκολότερη από την ανίχνευση σύνθετων δραστηριοτήτων όπως το μαγείρεμα ή η άσκηση. Πολλές μελέτες επικεντρώνονται σε απλές δραστηριότητες λόγω των σαφέστερων μοτίβων τους, αλλά οι εφαρμογές στον πραγματικό κόσμο απαιτούν το χειρισμό επικαλυπτόμενων ή σταδιακών δραστηριοτήτων, οι οποίες θέτουν πρόσθετες προκλήσεις. Ενώ η ακρίβεια είναι μια χρήσιμη βασική μετρική, δεν παρέχει πάντα μια πλήρη εικόνα της απόδοσης του μοντέλου. Εάν ορισμένες δραστηριότητες είναι σημαντικά πιο συχνές από άλλες, ένα μοντέλο μπορεί να επιτύχει υψηλή ακρίβεια ευνοώντας την κυρίαρχη δραστηριότητα, ενώ



έχει κακή απόδοση στις σπανιότερες δραστηριότητες [63]. Ως εκ τούτου, είναι σημαντικό να συμπληρώνεται με τις υπόλοιπες μετρικές, οι οποίες παρέχουν βαθύτερη εικόνα της απόδοσης του μοντέλου, ιδίως σε πραγματικές εφαρμογές HAR.

4.3.2.2 Precision

Το Precision είναι μια σημαντική μετρική αξιολόγησης στην Αναγνώριση Ανθρώπινης Δραστηριότητας που μετρά το ποσοστό των σωστά προβλεπόμενων θετικών περιπτώσεων μεταξύ όλων των περιπτώσεων που ταξινομούνται ως θετικές. Με άλλα λόγια, ποσοτικοποιεί πόσες από τις δραστηριότητες που το μοντέλο αναγνωρίζει ως μια συγκεκριμένη κατηγορία είναι πράγματι σωστές. Μαθηματικά, η ακρίβεια ορίζεται ως εξής:

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

,όπου το TP (True Positives) αντιπροσωπεύει σωστά ταξινομημένες περιπτώσεις μιας δεδομένης δραστηριότητας και το FP (False Positives) αντιπροσωπεύει περιπτώσεις που ταξινομήθηκαν εσφαλμένα ως η εν λόγω δραστηριότητα [64]. Μια υψηλή τιμή Precision υποδηλώνει ότι το μοντέλο κάνει λιγότερες ψευδώς θετικές προβλέψεις, πράγμα που σημαίνει ότι έχει μεγάλη αυτοπεποίθηση όταν αποδίδει μια περίπτωση σε μια συγκεκριμένη κλάση.

Το Precision είναι ιδιαίτερα χρήσιμη σε σύνολα δεδομένων με ανισορροπία, όπου ορισμένες δραστηριότητες είναι πιο συχνές από άλλες. Σε τέτοιες περιπτώσεις, ένας ταξινομητής μπορεί να ευνοήσει την πλειοψηφούσα κλάση, οδηγώντας σε παραπλανητικές βαθμολογίες ακρίβειας. Για παράδειγμα, σε ένα σύστημα ανίχνευσης πτώσεων, εάν ένα μοντέλο ταξινομεί λανθασμένα τις συνήθεις δραστηριότητες ως πτώσεις (υψηλό ποσοστό ψευδώς θετικών), θα οδηγούσε σε περιττούς συναγερμούς, μειώνοντας την αξιοπιστία του συστήματος. Με τη βελτιστοποίηση για υψηλότερη ακρίβεια, το μοντέλο εξασφαλίζει ότι όταν προβλέπει μια πτώση, είναι πιο πιθανό να είναι σωστό, μειώνοντας τους ψευδείς συναγερμούς [65].



Ωστόσο, η εστίαση μόνο στο Precision μπορεί να έχει μειονεκτήματα. Σε εφαρμογές όπου η έλλειψη μιας δραστηριότητας είναι πιο κρίσιμη από έναν ψευδή συναγερμό, όπως η ιατρική διάγνωση ή η ανίχνευση έκτακτων περιστατικών, η στήριξη αποκλειστικά στην ακρίβεια θα μπορούσε να είναι προβληματική [66]. Ως εκ τούτου, η ακρίβεια είναι καλύτερο να ερμηνεύεται μαζί με το Recall και το F1 Score, το οποίο εξισορροπεί και τις δύο μετρικές.

4.3.2.3 Recall

Η ανάκληση, επίσης γνωστή ως ευαισθησία ή αληθώς θετικό ποσοστό (TPR), είναι μια θεμελιώδης μετρική αξιολόγησης στην HAR. Μετρά την ικανότητα του μοντέλου να αναγνωρίζει σωστά όλες τις σχετικές περιπτώσεις μιας συγκεκριμένης δραστηριότητας. Μαθηματικά, το Recall ορίζεται ως εξής:

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

όπου το TP (True Positives) αντιπροσωπεύει τις σωστά ταξινομημένες περιπτώσεις μιας δραστηριότητας και το FN (False Negatives) αντιπροσωπεύει τις περιπτώσεις που το μοντέλο απέτυχε να αναγνωρίσει ότι ανήκουν στη συγκεκριμένη δραστηριότητα [67]. Ένα υψηλότερο Recall σκορ σημαίνει ότι το μοντέλο εντοπίζει τις περισσότερες από τις πραγματικές θετικές περιπτώσεις, ελαχιστοποιώντας τον αριθμό των ψευδώς αρνητικών.

Το Recall είναι ιδιαίτερα κρίσιμο σε εφαρμογές όπου η απώλεια μιας περίπτωσης δραστηριότητας έχει σοβαρές συνέπειες. Για παράδειγμα, σε ένα σύστημα ανίχνευσης πτώσης, εάν το μοντέλο αποτύχει να αναγνωρίσει μια πραγματική πτώση (υψηλό ποσοστό ψευδώς αρνητικών αποτελεσμάτων), αυτό θα μπορούσε να οδηγήσει σε καθυστερημένη ιατρική παρέμβαση, θέτοντας σοβαρό κίνδυνο για τον χρήστη. Ομοίως, σε ιατρικές εφαρμογές, η αποτυχία εντοπισμού μιας κρίσιμης κατάστασης, όπως η καρδιακή αρρυθμία ή οι επιληπτικές κρίσεις, θα μπορούσε να έχει απειλητικές για τη ζωή συνέπειες. Ωστόσο, ένα μοντέλο βελτιστοποιημένο για υψηλή ανάκληση μπορεί να θυσιάσει το precision, οδηγώντας σε περισσότερα ψευδώς θετικά αποτελέσματα. Αυτό σημαίνει ότι ενώ το



μοντέλο ανιχνεύει με επιτυχία τις περισσότερες αληθείς περιπτώσεις, μπορεί επίσης να ταξινομήσει λανθασμένα τις κανονικές δραστηριότητες ως κρίσιμα συμβάντα [68]. Στην HAR, αυτό θα μπορούσε να οδηγήσει σε περιττές ειδοποιήσεις, ψευδείς συναγερμούς ή μειωμένη εμπιστοσύνη στο σύστημα. Ως εκ τούτου, η ανάκληση θα πρέπει να αναλύεται παράλληλα με το precision, ώστε να διασφαλίζεται μια ισορροπημένη αξιολόγηση.

Παρόλο που η επίτευξη ανάκλησης 100% είναι σπάνια, τα συστήματα HAR θα πρέπει να στοχεύουν στη μεγιστοποίηση της ανάκλησης χωρίς συμβιβασμούς στην ακρίβεια, ανάλογα με τις ειδικές απαιτήσεις της εφαρμογής. Για την εύρεση της καλύτερης ισορροπίας μεταξύ αυτών των δύο μετρικών, χρησιμοποιείται συχνά η βαθμολογία F1 - ένας αρμονικός μέσος όρος της ακρίβειας και της ανάκλησης, ο οποίος θα συζητηθεί στην επόμενη ενότητα.

4.3.2.4 F1 Score

Το F1 Score είναι μια βασική μετρική αξιολόγησης στην Αναγνώριση Ανθρώπινης Δραστηριότητας, ιδιαίτερα σε περιπτώσεις όπου το σύνολο δεδομένων είναι ανισόρροπο ή όταν τόσο το Precision όσο και το Recall είναι εξίσου σημαντικές. Παρέχει μια ενιαία αριθμητική τιμή που εξισορροπεί τον συμβιβασμό μεταξύ της precision, η οποία μετρά πόσες από τις προβλεπόμενες θετικές περιπτώσεις είναι πραγματικά σωστές, και της ανάκλησης, η οποία ποσοτικοποιεί πόσες από τις πραγματικές θετικές περιπτώσεις αναγνωρίστηκαν με επιτυχία. Το F1 Score υπολογίζεται ως ο αρμονικός μέσος όρος της precision και της ανάκλησης χρησιμοποιώντας τον τύπο:

$$F1\ Score = \frac{2 * TP}{2 * TP + FP + FN}$$

ή

$$F1\ Score = \frac{2 * Precision * Recall}{Precision + Recall}$$



Δεδομένου ότι λαμβάνει υπόψη τόσο την Precision όσο και την Recall, διασφαλίζει ότι ένα μοντέλο δεν έχει καλή απόδοση στη μία πτυχή ενώ αποτυγχάνει στην άλλη. Ένα υψηλό σκορ F1 υποδηλώνει ένα καλά ισορροπημένο μοντέλο, ενώ ένα χαμηλό σκορ υποδηλώνει ότι είτε η ακρίβεια είτε η ανάκληση είναι ανεπαρκείς, μειώνοντας τη συνολική αποτελεσματικότητα [69]. Αυτό καθιστά το F1 Score ιδιαίτερα χρήσιμο για εφαρμογές HAR, όπου οι λανθασμένες ταξινομήσεις μπορεί να έχουν σημαντικές συνέπειες.

Στο HAR, η F1 Score είναι ιδιαίτερα πολύτιμη όταν πρόκειται για ανισορροπία τάξης, καθώς ορισμένες δραστηριότητες, όπως το περπάτημα ή η ορθοστασία, παρατηρούνται συχνότερα από άλλες, όπως η πτώση ή το τρέξιμο. Ένα μοντέλο που επιτυγχάνει υψηλή ακρίβεια μπορεί να εξακολουθεί να έχει κακή απόδοση στις κλάσεις μειοψηφίας, και το F1 Score συμβάλλει, διασφαλίζοντας ότι τόσο η ακρίβεια όσο και η ανάκληση συμβάλλουν στην αξιολόγηση. Επιπλέον, είναι ζωτικής σημασίας σε εφαρμογές όπου τα ψευδώς θετικά και τα ψευδώς αρνητικά αποτελέσματα έχουν διαφορετικές επιπτώσεις. Για παράδειγμα, στην ανίχνευση πτώσης, ένα ψευδώς αρνητικό -αποτυγχάνοντας να ανιχνεύσει μια πραγματική πτώση- μπορεί να απειλήσει τη ζωή, ενώ ένα ψευδώς θετικό -που εκλαμβάνει την κανονική κίνηση ως πτώση- μπορεί να προκαλέσει περιττές ειδοποιήσεις, αλλά είναι λιγότερο επιβλαβές. Η βαθμολογία F1 βοηθά στην επίτευξη ισορροπίας μεταξύ αυτών των σφαλμάτων, καθιστώντας την προτιμώμενη μετρική σε τέτοια κρίσιμα σενάρια [70].

Ένα άλλο πλεονέκτημα της είναι ότι επιτρέπει άμεσες συγκρίσεις μεταξύ διαφορετικών μοντέλων HAR. Δεδομένου ότι συνδυάζει την ακρίβεια και την ανάκληση σε μια ενιαία τιμή, απλοποιεί τη διαδικασία αξιολόγησης και βοηθά τους ερευνητές και τους προγραμματιστές να αξιολογούν τις βελτιώσεις μεταξύ των διαφόρων μοντέλων. Ωστόσο, είναι σημαντικό να σημειωθεί ότι, ενώ το F1 Score παρέχει μια χρήσιμη συνοπτική μετρική, θα πρέπει πάντα να εξετάζεται μαζί με την ακρίβεια, την ανάκληση και την ανάκληση για να επιτευχθεί μια ολοκληρωμένη κατανόηση της απόδοσης ενός μοντέλου.

4.3.2.5 Confusion Matrix

Ο πίνακας σύγχυσης είναι ένα θεμελιώδες εργαλείο για την αξιολόγηση της απόδοσης των μοντέλων μηχανικής μάθησης, ιδίως σε εργασίες ταξινόμησης όπως η αναγνώριση ανθρώπινης δραστηριότητας (HAR). Παρέχει μια λεπτομερή ανάλυση του πόσο καλά ένα



μοντέλο ταξινομεί κάθε δραστηριότητα, επισημαίνοντας τόσο τις σωστές όσο και τις λανθασμένες προβλέψεις. Σε αντίθεση με μετρικές επιδόσεων μίας τιμής, όπως η ακρίβεια, ο πίνακας σύγχυσης προσφέρει μια πιο λεπτομερή άποψη της απόδοσης του μοντέλου, επιτρέποντας την καλύτερη ανάλυση των σφαλμάτων ταξινόμησης.

Ο πίνακας σύγχυσης είναι ένας τετραγωνικός πίνακας όπου οι γραμμές αντιπροσωπεύουν τις πραγματικές κλάσεις δραστηριοτήτων και οι στήλες τις προβλεπόμενες κλάσεις δραστηριοτήτων. Κάθε κελί του πίνακα αντιστοιχεί στον αριθμό των περιπτώσεων που ταξινομούνται σε μια συγκεκριμένη κατηγορία. Τα διαγώνια στοιχεία υποδεικνύουν σωστά ταξινομημένες δραστηριότητες, ενώ τα στοιχεία εκτός διαγωνίου αντιπροσωπεύουν λανθασμένα ταξινομημένες περιπτώσεις. Σε αυτή τη δομή, τα True Positives (TP) αντιπροσωπεύουν τον αριθμό των σωστά ταξινομημένων περιπτώσεων δραστηριότητας, ενώ τα True Negatives (TN) υποδηλώνουν τον αριθμό των περιπτώσεων που αναγνωρίστηκαν σωστά ότι δεν ανήκουν σε μια συγκεκριμένη δραστηριότητα. Τα ψευδώς θετικά (FP) προκύπτουν όταν μια περίπτωση ταξινομείται εσφαλμένα ως μια συγκεκριμένη δραστηριότητα (σφάλμα τύπου I), ενώ τα ψευδώς αρνητικά (FN) προκύπτουν όταν μια περίπτωση ταξινομείται εσφαλμένα ως μια άλλη δραστηριότητα (σφάλμα τύπου II). Ένας τέλειος ταξινομητής θα παρήγαγε έναν πίνακα σύγχυσης με μη μηδενικές τιμές μόνο κατά μήκος της διαγωνίου, υποδεικνύοντας ότι όλες οι δραστηριότητες αναγνωρίστηκαν σωστά [71].

Για την ταξινόμηση HAR, ο πίνακας σύγχυσης βοηθά στον εντοπισμό λανθασμένων ταξινομήσεων, στην ανάλυση των επιπτώσεων της ανισορροπίας των κλάσεων και στην κατανόηση της αξιοπιστίας του μοντέλου. Εάν μια δραστηριότητα όπως το περπάτημα ταξινομείται συχνά λανθασμένα ως τρέξιμο, αυτό υποδηλώνει ότι το μοντέλο δυσκολεύεται να διακρίνει μεταξύ αυτών των δύο κινήσεων. Ομοίως, εάν ο πίνακας σύγχυσης αποκαλύπτει συνεχείς λανθασμένες ταξινομήσεις σε πολλαπλές δραστηριότητες, αυτό μπορεί να υποδεικνύει ότι η διαδικασία εξαγωγής χαρακτηριστικών απαιτεί βελτίωση. Ορισμένες δραστηριότητες μπορεί επίσης να έχουν περισσότερα δείγματα εκπαίδευσης, γεγονός που μπορεί να μεροληπτεί στην απόδοση ταξινόμησης, καθιστώντας τον πίνακα σύγχυσης χρήσιμο για την κατανόηση τέτοιων ζητημάτων.




		Predicted Class		
		Positive	Negative	
Actual Class	Positive	True Positive (TP)	False Negative (FN) Type II Error	Sensitivity $\frac{TP}{(TP + FN)}$
	Negative	False Positive (FP) Type I Error	True Negative (TN)	Specificity $\frac{TN}{(TN + FP)}$
		Precision $\frac{TP}{(TP + FP)}$	Negative Predictive Value $\frac{TN}{(TN + FN)}$	Accuracy $\frac{TP + TN}{(TP + TN + FP + FN)}$

Εικόνα 29: Ανάλυση ενός Πίνακα Σύγχυσης

Στις εφαρμογές HAR, ορισμένες δραστηριότητες παρουσιάζουν παρόμοια μοτίβα κίνησης, καθιστώντας δύσκολη τη διαφοροποίηση μεταξύ τους από τα μοντέλα μηχανικής μάθησης. Για παράδειγμα, δραστηριότητες όπως η ορθοστασία και το κάθισμα περιλαμβάνουν ελάχιστη κίνηση, οδηγώντας σε αυξημένα ποσοστά λανθασμένης ταξινόμησης μεταξύ αυτών των κατηγοριών. Ομοίως, τα μοντέλα μπορεί να δυσκολεύονται να διακρίνουν μεταξύ τζόκινγκ και τρεξίματος λόγω της ομοιότητας στη δυναμική της κίνησης. Ο πίνακας σύγχυσης παρέχει ουσιαστική εικόνα αυτών των ζητημάτων, βοηθώντας στον εντοπισμό των δραστηριοτήτων που το μοντέλο συγχέει συχνότερα, στην αξιολόγηση της αποτελεσματικότητας των διαφόρων ταξινομητών και στη βελτίωση της μηχανικής των χαρακτηριστικών ή των υπερπαραμέτρων του μοντέλου για τη βελτίωση της ακρίβειας ταξινόμησης.

5. Ανάλυση Δεδομένων και Προεπεξεργασία

Στα προηγούμενα κεφάλαια, διερευνήθηκαν τα θεωρητικά θεμέλια της Αναγνώρισης Ανθρώπινης Δραστηριότητας, συμπεριλαμβανομένου του ρόλου των δεδομένων των φορέσιμων αισθητήρων και των τεχνικών μηχανικής μάθησης που χρησιμοποιούνται για την ταξινόμηση των ανθρώπινων δραστηριοτήτων. Τώρα, είναι το σημείο στο οποίο γίνεται η μετάβαση από τη θεωρία στην πράξη, εστιάζοντας στα σύνολα δεδομένων, τις τεχνικές προεπεξεργασίας και τις μεθόδους εξαγωγής χαρακτηριστικών που αποτελούν τον πυρήνα αυτής της έρευνας. Αυτό το κεφάλαιο χρησιμεύει ως γέφυρα μεταξύ της εννοιολογικής κατανόησης και της πρακτικής εφαρμογής, θέτοντας τις βάσεις για τα μοντέλα ταξινόμησης και την οπτικοποίηση τους που θα αναπτυχθούν παρακάτω.



Εικόνα 30: Το Framework της HAR

5.1 Σύνολα Δεδομένων που χρησιμοποιήθηκαν

Η αποτελεσματικότητα οποιουδήποτε συστήματος Αναγνώρισης Ανθρώπινης Δραστηριότητας εξαρτάται σε μεγάλο βαθμό από την ποιότητα και την ποικιλομορφία των συνόλων δεδομένων που χρησιμοποιούνται για την εκπαίδευση και την αξιολόγηση. Στην παρούσα εργασία, επιλέχθηκαν δύο καθιερωμένα σύνολα δεδομένων, το MHEALTH και το WISDM, για την ανάπτυξη και αξιολόγηση μοντέλων μηχανικής μάθησης για την ταξινόμηση δραστηριοτήτων. Αυτά τα σύνολα δεδομένων περιέχουν μετρήσεις αισθητήρων που συλλέγονται από φορέσιμες συσκευές, όπως επιταχυνσιόμετρα και γυροσκόπια, τα οποία χρησιμοποιούνται ευρέως σε εφαρμογές HAR.



Χρησιμοποιώντας αυτά τα δύο σύνολα δεδομένων, η παρούσα έρευνα στοχεύει στη διερεύνηση διαφορετικών αισθητήρων και χαρακτηριστικών δεδομένων, διασφαλίζοντας ότι τα μοντέλα που αναπτύσσονται είναι εύρωστα και προσαρμόσιμα σε διάφορα σενάρια HAR [72]. Τα ακόλουθα υποκεφάλαια παρέχουν μια λεπτομερή επισκόπηση κάθε συνόλου δεδομένων, συμπεριλαμβανομένων των διαδικασιών συλλογής δεδομένων, των τοποθετήσεων των αισθητήρων, των καταγεγραμμένων δραστηριοτήτων και των προδιαγραφών του συνόλου δεδομένων.

5.1.1 MHEALTH Dataset

Το σύνολο δεδομένων mHEALTH (Mobile HEALTH) είναι ένα δημόσια διαθέσιμο σύνολο δεδομένων που χρησιμοποιείται ευρέως στην έρευνα για την αναγνώριση ανθρώπινης δραστηριότητας. Παρέχει υψηλής ανάλυσης φυσιολογικά δεδομένα και δεδομένα κίνησης που συλλέγονται από πολλαπλούς αισθητήρες που φοριούνται στο σώμα, γεγονός που το καθιστά ιδιαίτερα πολύτιμο για τη μελέτη σύνθετων ανθρώπινων δραστηριοτήτων. Το σύνολο δεδομένων δημιουργήθηκε για να διευκολύνει την έρευνα σε εφαρμογές κινητής υγείας, την αναγνώριση δραστηριοτήτων και την ανίχνευση πτώσεων, προσφέροντας λεπτομερείς μετρήσεις αισθητήρων από πολλαπλές θέσεις του σώματος.

Το σύνολο δεδομένων αποτελείται από καταγραφές δέκα εθελοντών διαφορετικού προφίλ, οι οποίοι εκτελούσαν δώδεκα διαφορετικές σωματικές δραστηριότητες, όπως ορθοστασία, κάθισμα, ξάπλωμα, περπάτημα, τρέξιμο, τρέξιμο και άλμα. Οι δραστηριότητες αυτές καταγράφηκαν με τη χρήση φορέσιμων αισθητήρων Shimmer2, οι οποίοι ήταν προσαρτημένοι σε τρία βασικά σημεία του σώματος: στο στήθος, στον δεξιό καρπό και στον αριστερό αστράγαλο. Η τοποθέτηση σε αυτά τα σημεία επιτρέπει την ολοκληρωμένη καταγραφή των κινήσεων, καθώς διαφορετικά μέρη του σώματος συμβάλλουν μοναδικά σε διάφορες σωματικές δραστηριότητες [73].

Οι αισθητήρες που χρησιμοποιούνται στο σύνολο δεδομένων mHEALTH μετρούν πολλαπλές παραμέτρους που σχετίζονται με την κίνηση και φυσιολογικές παραμέτρους, όπως επιταχυνσιόμετρο, γυροσκόπιο, μαγνητόμετρο και μετρήσεις ηλεκτροκαρδιογραφήματος (EEG). Όπως αναφέρθηκε και προηγουμένως, το επιταχυνσιόμετρο καταγράφει τις δυνάμεις επιτάχυνσης που ασκούνται στο σώμα, το



γυροσκόπιο μετρά τη γωνιακή ταχύτητα και το μαγνητόμετρο καταγράφει τον προσανατολισμό σε σχέση με το μαγνητικό πεδίο της Γης. Επιπλέον, ο αισθητήρας που είναι τοποθετημένος στο στήθος πρόκειται για ένα EEG 2 απαγωγών, το οποίο, παρέχει πολύτιμα φυσιολογικά δεδομένα που μπορούν να εξεταστούν για μελλοντικές εφαρμογές όπως η παρακολούθηση της καρδιάς και η ανάλυση των επιπτώσεων της άσκησης.

Το σύνολο δεδομένων συλλέχθηκε με ρυθμό δειγματοληψίας 50 Hz, ο οποίος είναι επαρκής για την ακριβή καταγραφή της δυναμικής της ανθρώπινης κίνησης. Τα δεδομένα κάθε συμμετέχοντα αποθηκεύονται σε ξεχωριστά αρχεία καταγραφής, με κάθε γραμμή να αντιπροσωπεύει μια ένδειξη αισθητήρα σε ένα συγκεκριμένο χρονικό βήμα και στήλες που αντιστοιχούν σε διαφορετικές μορφές αισθητήρων. Οι καταγεγραμμένες δραστηριότητες περιλαμβάνουν τόσο σταθερές στάσεις (π.χ. ορθοστασία, κάθισμα, ξάπλωμα) όσο και δυναμικές κινήσεις (π.χ. περπάτημα, τρέξιμο, άλμα), διασφαλίζοντας ότι το σύνολο δεδομένων καλύπτει ένα ευρύ φάσμα καθημερινών ανθρώπινων δραστηριοτήτων [74].

Ένα βασικό πλεονέκτημα του συνόλου δεδομένων MHEALTH είναι η δυνατότητά του να εφαρμοστεί σε εργασίες αναγνώρισης ανθρώπινης δραστηριότητας στον πραγματικό κόσμο. Οι δραστηριότητες εκτελέστηκαν σε ένα σχετικά απεριόριστο περιβάλλον, επιτρέποντας τη μεταβλητότητα των στυλ εκτέλεσης και των εντάσεων. Αυτό καθιστά το σύνολο δεδομένων κατάλληλο για την εκπαίδευση μοντέλων μηχανικής μάθησης που πρέπει να χειρίζονται ποικίλα μοτίβα κίνησης [75]. Στην παρούσα μελέτη, το σύνολο δεδομένων mHEALTH χρησιμοποιείται για την εκπαίδευση και τη δοκιμή μοντέλων μηχανικής μάθησης για την ταξινόμηση δραστηριοτήτων, αξιοποιώντας τα ολοκληρωμένα σήματα κίνησης και φυσιολογίας που περιέχει για την ενίσχυση των επιδόσεων αναγνώρισης.

5.1.2 WISDM Dataset

Το σύνολο δεδομένων Wireless Sensor Data Mining (WISDM) είναι ένα ευρέως χρησιμοποιούμενο δημόσιο σύνολο δεδομένων για την αναγνώριση ανθρώπινης δραστηριότητας (HAR), το οποίο έχει σχεδιαστεί για να διευκολύνει την ανάπτυξη και την αξιολόγηση μοντέλων μηχανικής μάθησης για την ταξινόμηση δραστηριοτήτων με τη χρήση κινητών συσκευών. Σε αντίθεση με τα σύνολα δεδομένων που βασίζονται σε πολλαπλούς ειδικούς αισθητήρες που φοριούνται, το σύνολο δεδομένων WISDM



χρησιμοποιεί κυρίως μετρήσεις επιταχυνσιόμετρου και γυροσκοπίου από καταναλωτικά smartphones και smartwatches. Αυτό το χαρακτηριστικό το καθιστά ιδιαίτερα σημαντικό για εφαρμογές στον πραγματικό κόσμο, καθώς αποδεικνύει τη δυνατότητα υλοποίησης του HAR με τη χρήση ευρέως διαθέσιμων εμπορικών συσκευών [76].

Το σύνολο δεδομένων συλλέχθηκε από μια ομάδα 51 συμμετεχόντων, από τους οποίους ο καθένας κλήθηκε να εκτελέσει 18 διαφορετικές δραστηριότητες, ενώ είχε ένα smartphone στην μπροστινή τσέπη του και φορούσε ένα έξυπνο ρολόι στον καρπό του. Οι δραστηριότητες περιλαμβάνουν κοινές καθημερινές ενέργειες όπως περπάτημα, τρέξιμο, άνοδος και κάθοδος από σκάλες, κάθισμα, ορθοστασία, πληκτρολόγηση, βούρτσισμα δοντιών, κατανάλωση διαφόρων τροφίμων, άθληση, γράψιμο, χειροκρότημα και δίπλωμα ρούχων. Οι δραστηριότητες αυτές καταγράφηκαν σε φυσικές συνθήκες για να διασφαλιστεί η δυνατότητα εφαρμογής του συνόλου δεδομένων σε πραγματικές συνθήκες.

Η διαδικασία συλλογής δεδομένων ελέγχθηκε με τη χρήση μιας προσαρμοσμένης εφαρμογής για κινητά που εκτελείται σε smartphones και smartwatches με βάση το Android. Τα smartphones που χρησιμοποιήθηκαν στη μελέτη περιλάμβαναν συσκευές Google Nexus 5/5X και Samsung Galaxy S5 που έτρεχαν με Android 6.0, ενώ τα smartwatches αποτελούνταν από LG G Watches που λειτουργούσαν με Android Wear 1.5. Τα δεδομένα αισθητήρων καταγράφηκαν από τα επιταχυνσιόμετρα και τα γυροσκόπια που ήταν ενσωματωμένα και στις δύο συσκευές, με αποτέλεσμα να προκύπτουν τέσσερις διαφορετικές ροές αισθητήρων: επιταχυνσιόμετρο τηλεφώνου, γυροσκόπιο τηλεφώνου, επιταχυνσιόμετρο ρολογιού και γυροσκόπιο ρολογιού. Τα δεδομένα καταγράφηκαν με σταθερό ρυθμό δειγματοληψίας 20 Hz, πράγμα που σημαίνει ότι οι μετρήσεις των αισθητήρων καταγράφονταν κάθε 50 χιλιοστά του δευτερολέπτου [77].

Η δομή του συνόλου δεδομένων WISDM επιτρέπει την ανάλυση μοτίβων δραστηριότητας σε διάφορες μορφές αισθητήρων, καθιστώντας το βασικό πόρο για τους ερευνητές που διερευνούν την αποτελεσματικότητα διαφόρων αλγορίθμων ταξινόμησης. Ένα από τα βασικά πλεονεκτήματα του WISDM είναι η δυνατότητα εφαρμογής του σε πρακτικές λύσεις HAR που βασίζονται σε smartphone. Δεδομένου ότι τα έξυπνα τηλέφωνα χρησιμοποιούνται ευρέως και είναι εξοπλισμένα με ενσωματωμένους αισθητήρες, αυτό το σύνολο δεδομένων παρέχει πολύτιμες πληροφορίες σχετικά με τον τρόπο με τον οποίο τα μοντέλα HAR μπορούν να ενσωματωθούν σε κινητές εφαρμογές για την παρακολούθηση δραστηριοτήτων σε πραγματικό χρόνο. Επιπλέον, με τη συμπερίληψη δεδομένων αισθητήρων τόσο από



smartphone όσο και από smartwatch, το σύνολο δεδομένων επιτρέπει στους ερευνητές να συγκρίνουν την αποτελεσματικότητα διαφορετικών συσκευών σε εργασίες αναγνώρισης δραστηριότητας [78].

Πίνακας 2: Σύνοψη των διαφόρων datasets για τις τάξεις τους, τους συμμετέχοντες και το καταγεγραμμένο σύνολο δραστηριοτήτων.

Dataset	Subjects	Classes	Sensors	Activities
mHealth	10	12	Shimmer2 wearable sensor which comprises an Accelerometer, Gyroscope, and Magnetometer	ADL (Standing, Sitting, Lying, Walking, Jogging, Running, Jumping, Cycling, etc.)
WISDM	29	6	Accelerometer and Gyroscope sensors in the Smartphone.	ADL (Walking, Jogging, Standing, Sitting, Upstairs, Downstairs, etc.)

5.2 Προεπεξεργασία Δεδομένων

Η προεπεξεργασία δεδομένων είναι ένα κρίσιμο βήμα στην Αναγνώριση Ανθρώπινης Δραστηριότητας, καθώς εξασφαλίζει ότι τα ακατέργαστα δεδομένα αισθητήρων καθαρίζονται, δομούνται και μετατρέπονται σε κατάλληλη μορφή για να εφαρμοστούν στην συνέχεια οι αλγόριθμοι μηχανικής μάθησης. Ο πρωταρχικός στόχος της προεπεξεργασίας είναι η βελτίωση της ποιότητας των δεδομένων με την αφαίρεση των ασυνεπειών, τον χειρισμό των ελλিপών τιμών και την εξαγωγή σχετικών χαρακτηριστικών που συμβάλλουν στην ακριβή ταξινόμηση των δραστηριοτήτων. Όσον αφορά την HAR, η προεπεξεργασία περιλαμβάνει γενικά τον καθαρισμό των δεδομένων, την τμηματοποίηση, την εξαγωγή χαρακτηριστικών και τον μετασχηματισμό. Στο παρόν υποκεφάλαιο περιγράφονται



λεπτομερώς τόσο οι θεωρητικές πτυχές της προεπεξεργασίας όσο και η συγκεκριμένη μεθοδολογία που εφαρμόζεται στην παρούσα διατριβή με τη χρήση του λογισμικού Weka.

5.2.1 Καθαρισμός δεδομένων (Data Cleaning)

Τα ακατέργαστα δεδομένα αισθητήρων συχνά περιέχουν θόρυβο, ελλειπείς τιμές ή ασυνεπείς ενδείξεις λόγω περιορισμών της συσκευής, κακής ευθυγράμμισης του αισθητήρα ή κάποιου ανθρώπινου σφάλματος κατά τη συλλογή των δεδομένων. Ο καθαρισμός των δεδομένων εξασφαλίζει ότι το σύνολο δεδομένων τελειοποιείται πριν από την εξαγωγή χαρακτηριστικών και την ταξινόμηση. Τα βασικά βήματα που εμπλέκονται στον καθαρισμό δεδομένων περιλαμβάνουν τα εξής:

- *Χειρισμός ελλειπόν τιμών:* Οι ελλείπουσες τιμές στα σύνολα δεδομένων HAR μπορεί να προκύψουν από βλάβες υλικού ή δυσλειτουργίες αισθητήρων. Στο Weka, οι ελλείπουσες τιμές μπορούν να αντιμετωπιστούν είτε αφαιρώντας τις επηρεαζόμενες περιπτώσεις είτε υποκαθιστώντας τις ελλείπουσες τιμές χρησιμοποιώντας στατιστικές μεθόδους όπως η αντικατάσταση του μέσου όρου, της διάμεσου ή του τρόπου λειτουργίας.
- *Αφαίρεση αντιγράφων και ακραίων τιμών:* Οι διπλές εγγραφές μπορεί να εισάγουν πλεονασμό, ενώ οι ακραίες τιμές μπορεί να στρεβλώσουν την απόδοση του μοντέλου. Το Weka επιτρέπει στους χρήστες να οπτικοποιούν τις κατανομές των χαρακτηριστικών και να αφαιρούν ακραίες τιμές ή να εφαρμόζουν τεχνικές εξομάλυνσης για να μετριάσουν τις επιπτώσεις τους.
- *Συνέπεια των ετικετών (Label Consistency):* Η διασφάλιση ότι όλες οι ετικέτες δραστηριοτήτων έχουν αποδοθεί σωστά είναι απαραίτητη για την ταξινόμηση. Τυχόν ασυνέπειες στην επισήμανση διορθώνονται για να διατηρηθεί η ομοιομορφία σε όλο το σύνολο δεδομένων [79].



5.2.2 Τεχνικές Εξόρυξης Χαρακτηριστικών

Αφού γίνει ο καθαρισμός των δεδομένων, πραγματοποιείται η εξαγωγή χαρακτηριστικών για τα σημαντικά χαρακτηριστικά που αντιπροσωπεύουν διαφορετικές δραστηριότητες. Στην HAR, οι μετρήσεις αισθητήρων, όπως τα δεδομένα επιταχυνσιόμετρου και γυροσκοπίου, υποβάλλονται σε επεξεργασία για τον υπολογισμό στατιστικών, χρονικών και συχνοτικών χαρακτηριστικών. Τα βασικά βήματα που εμπλέκονται στην εξαγωγή χαρακτηριστικών με τη χρήση του Weka περιλαμβάνουν:

- *Επιλογή και μετασχηματισμός χαρακτηριστικών:* Τα σύνολα δεδομένων που χρησιμοποιούνται στην παρούσα εργασία (MHEALTH και WISDM) περιέχουν πολλαπλές μετρήσεις αισθητήρων που καταγράφονται με την πάροδο του χρόνου. Το Weka παρέχει επιλογές για τον μετασχηματισμό των ακατέργαστων δεδομένων αισθητήρων σε σημαντικά χαρακτηριστικά, όπως η μέση τιμή, η τυπική απόκλιση και η συσχέτιση μεταξύ των αξόνων.
- *Τμηματοποίηση με χρήση συρόμενων παραθύρων:* Οι εργασίες HAR απαιτούν συχνά την τμηματοποίηση συνεχών ροών αισθητήρων σε μικρότερα χρονικά παράθυρα. Το Weka επιτρέπει τεχνικές παραθύρων, οι οποίες βοηθούν στην εξαγωγή χρονικών μοτίβων εντός ενός σταθερού μεγέθους πλαισίου, διασφαλίζοντας ότι διατηρούνται οι διαδοχικές εξαρτήσεις.
- *Κανονικοποίηση και κλιμάκωση:* Οι τιμές των χαρακτηριστικών μπορεί να έχουν διαφορετικά εύρη, γεγονός που μπορεί να επηρεάσει αρνητικά τους αλγορίθμους μηχανικής μάθησης. Έτσι, εφαρμόζονται μέθοδοι κανονικοποίησης, όπως η κλιμάκωση Min-Max ή η κανονικοποίηση Z-score, για να διασφαλιστεί η ομοιομορφία στις κατανομές των χαρακτηριστικών [73].

5.2.3 Επεξήγηση της πλατφόρμας WEKA

Η ροή προεπεξεργασίας που υλοποιήθηκε στην παρούσα μελέτη πραγματοποιήθηκε με τη χρήση της διεπαφής Explorer του Weka. Τα ακόλουθα βήματα εφαρμόστηκαν και στα δύο σύνολα δεδομένων πριν από την ταξινόμηση:



Το πρώτο βήμα περιελάμβανε την εισαγωγή του συνόλου δεδομένων στο Weka. Η Weka υποστηρίζει πολλαπλές μορφές αρχείων, συμπεριλαμβανομένων των ARFF και CSV. Τα σύνολα δεδομένων MHEALTH και WISDM φορτώθηκαν στο λογισμικό, όπου όλα τα διαθέσιμα χαρακτηριστικά που αντιπροσωπεύουν μετρήσεις αισθητήρων, συμπεριλαμβανομένων των δεδομένων επιταχυνσιόμετρου, γυροσκοπίου και μαγνητομέτρου, εμφανίστηκαν στην καρτέλα «Preprocess». Στη συνέχεια, πραγματοποιήθηκε επιλογή και φιλτράρισμα χαρακτηριστικών για την αφαίρεση άσχετων ή περιττών χαρακτηριστικών. Προσδιορίστηκαν και απορρίφθηκαν τα χαρακτηριστικά που δεν συνέβαλαν σημαντικά στην ταξινόμηση των δραστηριοτήτων. Οι τεχνικές επιλογής χαρακτηριστικών της Weka βοήθησαν στην τελειοποίηση του συνόλου δεδομένων, διατηρώντας μόνο τα πιο κατατοπιστικά χαρακτηριστικά, εξασφαλίζοντας καλύτερη απόδοση ταξινόμησης [80].

Στη συνέχεια εξετάστηκαν οι ετικέτες κλάσεων και στα δύο σύνολα δεδομένων. Το σύνολο δεδομένων MHEALTH περιείχε 12 διαφορετικές ετικέτες δραστηριότητας, ενώ το σύνολο δεδομένων WISDM είχε έξι κατηγορίες, όπως περπάτημα, τρέξιμο και καθιστή θέση. Τα εργαλεία οπτικοποίησης της Weka χρησιμοποιήθηκαν για την επιθεώρηση της κατανομής των ετικετών κλάσεων, διασφαλίζοντας ότι το σύνολο δεδομένων ήταν επαρκώς ισορροπημένο ή ότι μπορούσαν να ληφθούν τα κατάλληλα μέτρα εάν υπήρχαν ανισορροπίες κλάσεων. Για να μειωθεί ο θόρυβος στο σύνολο δεδομένων, εφαρμόστηκαν διάφορες τεχνικές φιλτραρίσματος. Χρησιμοποιήθηκε το φίλτρο «Remove Useless» του Weka για την απόρριψη χαρακτηριστικών με σταθερές τιμές, ενώ χρησιμοποιήθηκαν πρόσθετες τεχνικές επιλογής χαρακτηριστικών για τη διατήρηση μόνο των πιο σχετικών χαρακτηριστικών. Αυτό το βήμα βοήθησε στην εξάλειψη του ανεπιθύμητου θορύβου και στη βελτίωση της συνολικής ποιότητας του συνόλου δεδομένων.

Μετά τη μείωση του θορύβου, εφαρμόστηκαν κανονικοποίηση και τυποποίηση για να εξασφαλιστεί ότι όλες οι μετρήσεις των αισθητήρων ήταν σε συγκρίσιμη κλίμακα. Το φίλτρο «Κανονικοποίηση» της Weka χρησιμοποιήθηκε για να φέρει τις τιμές των χαρακτηριστικών σε ένα ομοιόμορφο εύρος, αποτρέποντας ζητήματα όπου ορισμένα χαρακτηριστικά θα μπορούσαν να έχουν κυρίαρχη επιρροή στην ταξινόμηση λόγω μεγαλύτερων αριθμητικών μεγεθών. Αυτό το βήμα ήταν ζωτικής σημασίας για τη διασφάλιση δίκαιης μεταχείρισης όλων των χαρακτηριστικών στα μοντέλα μηχανικής μάθησης.



Τέλος, μετά την ολοκλήρωση όλων των βημάτων προεπεξεργασίας, το επεξεργασμένο σύνολο δεδομένων αποθηκεύτηκε σε μορφή ARFF για την επακόλουθη ταξινόμηση. Το βήμα αυτό εξασφάλισε ότι τα καθαρισμένα και μετασχηματισμένα δεδομένα ήταν κατάλληλα δομημένα για χρήση σε αλγορίθμους μηχανικής μάθησης. Τα προεπεξεργασμένα σύνολα δεδομένων ήταν στη συνέχεια έτοιμα για ταξινόμηση, επιτρέποντας την αποτελεσματικότερη αναγνώριση δραστηριοτήτων [81].

Με τη συστηματική εφαρμογή αυτών των βημάτων προεπεξεργασίας στο Weka, τα σύνολα δεδομένων μετατράπηκαν σε δομημένη μορφή, διευκολύνοντας την ακριβέστερη και πιο αξιόπιστη ταξινόμηση HAR. Στην επόμενη ενότητα θα περιγραφούν λεπτομερώς οι τεχνικές ταξινόμησης που εφαρμόστηκαν στα προεπεξεργασμένα δεδομένα.

5.2.4 Διαχωρισμός Training και Test Set Δεδομένων στο WEKA

Στη μηχανική μάθηση, ο διαχωρισμός των δεδομένων σε σύνολα εκπαίδευσης και δοκιμών είναι απαραίτητος για να διασφαλιστεί ότι τα μοντέλα γενικεύονται καλά σε νέα, αθέατα δεδομένα. Στο Weka, υπάρχουν πολλαπλοί τρόποι διαχωρισμού των συνόλων δεδομένων για ταξινόμηση, με την 10πλάσια διασταυρούμενη επικύρωση να είναι η κύρια μέθοδος που χρησιμοποιήθηκε σε αυτή τη μελέτη. Ωστόσο, είναι επίσης δυνατή η εκτέλεση μιας μεθόδου αναμονής, όπου ένα ποσοστό δεδομένων διατίθεται για εκπαίδευση, ενώ το υπόλοιπο προορίζεται για δοκιμή.

A) 10-Fold Cross-Validation

Στην παρούσα μελέτη, επιλέχθηκε η 10-Fold Cross-Validation ως η κύρια μέθοδος αξιολόγησης για να διασφαλιστούν αξιόπιστες μετρήσεις επιδόσεων. Αυτή η τεχνική διαιρεί το σύνολο δεδομένων σε 10 υποσύνολα ίσου μεγέθους (ή «αναδιπλώσεις»). Κάθε αναδίπλωση λειτουργεί ως σύνολο δοκιμής μία φορά, ενώ οι υπόλοιπες εννέα αναδιπλώσεις χρησιμοποιούνται για την εκπαίδευση. Αυτή η διαδικασία επαναλαμβάνεται 10 φορές και τα αποτελέσματα από κάθε επανάληψη υπολογίζονται κατά μέσο όρο για να προκύψει η τελική απόδοση ταξινόμησης.



Τα κύρια πλεονεκτήματα της 10-Fold Cross-Validation περιλαμβάνουν:

- *Καλύτερη αξιοποίηση των δεδομένων:* Κάθε περίπτωση στο σύνολο δεδομένων χρησιμοποιείται τόσο για εκπαίδευση όσο και για δοκιμή, μειώνοντας τη μεροληψία.
- *Μείωση της υπερπροσαρμογής:* Με τη δοκιμή σε πολλαπλά υποσύνολα, τα μοντέλα είναι λιγότερο πιθανό να απομνημονεύσουν συγκεκριμένα σημεία δεδομένων και είναι πιο πιθανό να γενικεύσουν καλά σε αθέατα δεδομένα.
- *Πιο αξιόπιστη αξιολόγηση:* Μετρήσεις επιδόσεων όπως η ακρίβεια, η ακρίβεια, η ανάκληση και το F1-score υπολογίζονται σε πολλαπλές επαναλήψεις, οδηγώντας σε πιο σταθερά αποτελέσματα.

Στο Weka, η 10-Fold Cross-Validation υλοποιήθηκε ως εξής:

- Πλοήγηση στην καρτέλα Classify (Ταξινόμηση).
- Επιλογή ενός ταξινομητή (π.χ. Decision Tree, SVM, CNN).
- Επιλέγοντας Cross-validation (διασταυρούμενη επικύρωση) και ορίζοντας τον αριθμό των αναδιπλώσεων σε 10.
- Εκτέλεση του ταξινομητή για να ληφθούν μέσες μετρικές αξιολόγησης.

B) Hold-Out Method (Training-Test Split in Weka)

Αν και η 10-Fold Cross-Validation ήταν η κύρια μέθοδος που χρησιμοποιήθηκε, μια άλλη κοινή προσέγγιση στη μηχανική μάθηση είναι η μέθοδος hold-out, όπου το σύνολο δεδομένων χωρίζεται ρητά σε ξεχωριστά σύνολα εκπαίδευσης και δοκιμής. Αυτή η μέθοδος ακολουθεί συνήθως έναν διαχωρισμό 70-30 ή 80-20, όπου:

- Το 70-80% των δεδομένων χρησιμοποιείται για εκπαίδευση.
- Το 20-30% των δεδομένων χρησιμοποιείται για δοκιμή.

Στη Weka, αυτό γίνεται με τους εξής τρόπους:

- Επιλέγοντας την επιλογή Percentage Split (Διαχωρισμός σε ποσοστό) στην καρτέλα Classify (Ταξινόμηση).
- Ορισμός του ποσοστού διαχωρισμού (π.χ. 70% για εκπαίδευση, 30% για δοκιμή).



- Εκτέλεση του ταξινομητή στο σύνολο εκπαίδευσης και αξιολόγηση στο σύνολο δοκιμής.

Αυτή η προσέγγιση είναι χρήσιμη όταν εργάζεστε με μεγάλα σύνολα δεδομένων όπου η διασταυρούμενη επικύρωση μπορεί να είναι υπολογιστικά δαπανηρή. Ωστόσο, μπορεί να οδηγήσει σε μεροληπτικά αποτελέσματα εάν τα σύνολα εκπαίδευσης και δοκιμής δεν είναι αντιπροσωπευτικά ολόκληρου του συνόλου δεδομένων.

Πίνακας 3: Πλεονεκτήματα και Μειονεκτήματα Μεθόδων Διαχωρισμού Δεδομένων

Μέθοδος	Πλεονεκτήματα	Μειονεκτήματα
10-Fold Cross-Validation	Διασφαλίζει ότι κάθε περίπτωση χρησιμοποιείται για εκπαίδευση και δοκιμή- Μειώνει τη διακύμανση στην αξιολόγηση- Παρέχει σταθερά αποτελέσματα.	Πιο δαπανηρή υπολογιστικά.
Hold-Out Method (Train-Test Split)	Πιο γρήγορο και αποτελεσματικό για μεγάλα σύνολα δεδομένων- Χρήσιμο όταν τα μοντέλα πρέπει να δοκιμαστούν σε πραγματικά αθέατα δεδομένα.	Οι επιδόσεις μπορεί να εξαρτώνται από τον τρόπο διαχωρισμού των δεδομένων- Υψηλότερος κίνδυνος μεροληπτικών αποτελεσμάτων.

Δεδομένου ότι η 10-Fold Cross-Validation παρέχει μια πιο αξιόπιστη εκτίμηση της απόδοσης του μοντέλου, επιλέχθηκε ως η κύρια μέθοδος για την εκπαίδευση και την αξιολόγηση των ταξινομητών σε αυτή την εργασία. Με τη χρήση αυτής της προσέγγισης, τα μοντέλα δοκιμάστηκαν σε διαφορετικά υποσύνολα των δεδομένων, εξασφαλίζοντας μια πιο ακριβή απεικόνιση των επιδόσεων του πραγματικού κόσμου.



5.3 Διαδικασία ταξινόμησης στο WEKA (Classification Process)

Μετά την προεπεξεργασία, τα εκλεπτυσμένα σύνολα δεδομένων υποβλήθηκαν σε ταξινόμηση χρησιμοποιώντας τις δυνατότητες μηχανικής μάθησης του Weka. Η ταξινόμηση είναι ένα βασικό βήμα στην αναγνώριση ανθρώπινων δραστηριοτήτων (HAR), όπου επισημασμένα δεδομένα αισθητήρων τροφοδοτούνται σε αλγορίθμους μηχανικής μάθησης για την αναγνώριση και κατηγοριοποίηση διαφορετικών δραστηριοτήτων. Στην παρούσα διατριβή εφαρμόστηκαν έξι μοντέλα μηχανικής μάθησης: Δένδρο απόφασης (J48), τυχαίο δάσος, μηχανή διανυσμάτων υποστήριξης (SVM), k-κοντινότεροι γείτονες (kNN), Naive Bayes και νευρωνικά δίκτυα συνελίξεων (CNN). Αυτή η ενότητα περιγράφει λεπτομερώς τη διαδικασία ταξινόμησης στο Weka, εστιάζοντας στα πρακτικά βήματα και τα αποτελέσματα για κάθε μοντέλο. Είναι σημαντικό να τονιστεί ότι η διαδικασία αυτή εφαρμόστηκε τόσο στα σύνολα δεδομένων MHEALTH όσο και στα σύνολα δεδομένων WISDM, εξασφαλίζοντας μια συνεπή μεθοδολογία για τη σύγκριση [82].

5.3.1 Εισαγωγή του συνόλου δεδομένων στο Weka

Πριν από την ταξινόμηση, τα αρχεία του συνόλου δεδομένων μετατράπηκαν σε μορφή .arff, η οποία είναι συμβατή με το Weka. Η μετατροπή αυτή ήταν απαραίτητη για να διευκολυνθεί ο απρόσκοπτος χειρισμός των δεδομένων εντός του λογισμικού. Μετά τη μετατροπή, το σύνολο δεδομένων φορτώθηκε στο Weka με πλοήγηση στην καρτέλα Preprocess και επιλογή του αντίστοιχου αρχείου .arff.

5.3.2 Προετοιμασία για την Διαδικασία της Ταξινόμησης

Στις εργασίες αναγνώρισης ανθρώπινης δραστηριότητας, η επιλογή των κατάλληλων ταξινομητών μηχανικής μάθησης είναι κρίσιμη, καθώς τα κάθε διαφορετικό μοντέλο έχει μοναδικά πλεονεκτήματα και αδυναμίες στο χειρισμό δεδομένων αισθητήρων χρονοσειρών. Οι επιλεγμένοι ταξινομητές αντιπροσωπεύουν ένα ευρύ φάσμα παραδειγμάτων μηχανικής μάθησης. Κάθε μοντέλο προσφέρει διακριτά πλεονεκτήματα όσον αφορά την ακρίβεια, την



υπολογιστική αποδοτικότητα, τη γενίκευση και την ερμηνευσιμότητα, τα οποία αποτελούν βασικά κριτήρια στις εφαρμογές HAR.

Η διαδικασία ταξινόμησης πραγματοποιήθηκε στην καρτέλα Classify, όπου εφαρμόστηκαν διάφορα μοντέλα μηχανικής μάθησης στο σύνολο δεδομένων. Χρησιμοποιήθηκαν τα ακόλουθα έξι μοντέλα:

- **Decision Tree (J48):** Τα Δέντρα Αποφάσεων χρησιμοποιούνται ευρέως στο HAR λόγω της ικανότητάς τους να δημιουργούν διαφανή και ερμηνεύσιμα μοντέλα. Ο αλγόριθμος J48, ο οποίος είναι μια υλοποίηση του αλγορίθμου C4.5, δημιουργεί μια δομή που μοιάζει με δέντρο, όπου κάθε κόμβος αντιπροσωπεύει μια απόφαση βάσει ενός χαρακτηριστικού και οι κλάδοι αντιπροσωπεύουν πιθανές τιμές του εν λόγω χαρακτηριστικού. Οι τελικοί κόμβοι των φύλλων υποδηλώνουν την προβλεπόμενη κλάση δραστηριότητας.
- **Random Forest (RandomForest):** Το Random Forest είναι μια μέθοδος μάθησης συνόλου που κατασκευάζει πολλαπλά δέντρα απόφασης και συγκεντρώνει τις προβλέψεις τους. Αυτό βελτιώνει την ακρίβεια ταξινόμησης και μειώνει την υπερπροσαρμογή σε σύγκριση με ένα μόνο Δέντρο Απόφασης. Το μοντέλο επιλέγει τυχαία υποσύνολα χαρακτηριστικών για κάθε δέντρο, εξασφαλίζοντας ποικιλομορφία μεταξύ των δέντρων.
- **Support Vector Machine (SVM - SMO):** Οι SVM είναι ισχυροί ταξινομητές που λειτουργούν καλά για εργασίες HAR λόγω της ικανότητάς τους να βρίσκουν το βέλτιστο υπερεπίπεδο που διαχωρίζει τις διαφορετικές κατηγορίες δραστηριοτήτων. Το μοντέλο απεικονίζει τα σημεία δεδομένων σε έναν χώρο υψηλών διαστάσεων και μεγιστοποιεί το περιθώριο μεταξύ διαφορετικών κλάσεων.
- **K- Nearest Neighbors (k-NN, k=1):** Ο k-NN είναι ένας μη παραμετρικός, βασισμένος σε περιπτώσεις ταξινομητής που αποδίδει ετικέτες κλάσης με βάση την πλειοψηφική ψήφο των k πλησιέστερων δειγμάτων εκπαίδευσης. Εδώ, k=1 σημαίνει ότι η ταξινόμηση καθορίζεται αποκλειστικά από τον πλησιέστερο γείτονα.
- **Naive Bayes:** Ο Naive Bayes είναι ένας πιθανοτικός ταξινομητής που βασίζεται στο θεώρημα του Bayes, υποθέτοντας ότι τα χαρακτηριστικά είναι ανεξάρτητα δεδομένης της ετικέτας κλάσης. Παρά την ισχυρή αυτή υπόθεση, συχνά αποδίδει εκπληκτικά καλά σε εργασίες HAR.



- **Συνελικτικό νευρωνικό δίκτυο (CNN):** Τα CNN είναι μοντέλα βαθιάς μάθησης ιδιαίτερα αποτελεσματικά για την ανάλυση διαδοχικών δεδομένων. Σε αντίθεση με τα παραδοσιακά μοντέλα μηχανικής μάθησης, τα CNN εξάγουν αυτόματα τα σχετικά χαρακτηριστικά από τα ακατέργαστα σήματα αισθητήρων, καθιστώντας τα ιδιαίτερα κατάλληλα για εργασίες HAR [83].

Όλα τα προαναφερθείσα μοντέλα Μηχανικής Μάθησης είναι εξίσου σημαντικά και έχουν σημαντικό αντίκτυπο στην ταξινόμηση μεγάλων συνόλων δεδομένων, αλλά καθώς η μελέτη συγκεκριμενοποιείται στα δεδομένα Αναγνώρισης Ανθρώπινης Δραστηριότητας, δημιουργείται το εξής ερώτημα: Γιατί επιλέχθηκαν αυτά τα μοντέλα ταξινόμησης για τα HAR δεδομένα; Η επιλογή αυτών των έξι ταξινομητών εξασφαλίζει μια ολοκληρωμένη αξιολόγηση των διαφόρων προσεγγίσεων μηχανικής μάθησης για το HAR:

- Τα Decision Tree και Random Forest αντιπροσωπεύουν ερμηνεύσιμα και αποδοτικά μοντέλα που βασίζονται σε δέντρα.
- Το SVM αποτυπώνει πολύπλοκα όρια αποφάσεων και είναι ανθεκτικό σε μικρά μεγέθη δείγματος.
- Το k-NN παρέχει μια απλή, βασισμένη σε παραδείγματα προσέγγιση που δεν απαιτεί εκπαίδευση του μοντέλου.
- Το Naive Bayes χρησιμεύει ως ένα γρήγορο, πιθανοτικό βασικό μοντέλο.
- Το CNN αντιπροσωπεύει μια προσέγγιση βαθιάς μάθησης ικανή για αυτόματη εξαγωγή χαρακτηριστικών.

Με την εφαρμογή και των έξι ταξινομητών στα σύνολα δεδομένων MHEALTH και WISDM, η παρούσα μελέτη παρέχει μια ισχυρή σύγκριση των παραδοσιακών μεθόδων και των μεθόδων βαθιάς μάθησης για το HAR, αναδεικνύοντας τους συμβιβασμούς μεταξύ ακρίβειας, υπολογιστικής απόδοσης και ερμηνευσιμότητας. Κάθε μοντέλο εκτελέστηκε χρησιμοποιώντας τις ενσωματωμένες λειτουργίες ταξινόμησης του Weka [84].

5.3.3 Εκπαίδευση και Αξιολόγηση των Μοντέλων



Για να διασφαλιστεί η αξιοπιστία των αποτελεσμάτων ταξινόμησης, χρησιμοποιήθηκε 10-Fold Cross-Validation. Η μέθοδος αυτή διαιρεί το σύνολο δεδομένων σε δέκα ίσα υποσύνολα, όπου εννέα υποσύνολα χρησιμοποιούνται για εκπαίδευση και το υπόλοιπο υποσύνολο χρησιμοποιείται για δοκιμή. Η διαδικασία επαναλαμβάνεται δέκα φορές, διασφαλίζοντας ότι κάθε υποσύνολο χρησιμοποιείται για δοκιμή ακριβώς μία φορά. Η προσέγγιση αυτή αποτρέπει την υπερπροσαρμογή και παρέχει μια ισχυρή αξιολόγηση της απόδοσης του μοντέλου.

Στο Weka, η διαδικασία διασταυρούμενης επικύρωσης διαμορφώθηκε ως εξής:

- Επιλογές δοκιμής: «Cross-validation» (Διασταυρούμενη επικύρωση)
- Αριθμός αναδιπλώσεων: 10
- Τυχαίος σπόρος: Προεπιλεγμένες ρυθμίσεις

Cross-Validation and Dataset Splitting

Για να διασφαλιστεί η αξιόπιστη και αμερόληπτη αξιολόγηση των μοντέλων, χρησιμοποιήθηκε 10 fold cross-validation. Η τεχνική αυτή διαιρεί το σύνολο δεδομένων σε 10 ίσα υποσύνολα, όπου κάθε υποσύνολο χρησιμεύει ως σύνολο δοκιμής μία φορά, ενώ τα υπόλοιπα εννέα υποσύνολα χρησιμοποιούνται για εκπαίδευση. Η διαδικασία αυτή επαναλαμβάνεται 10 φορές και τα αποτελέσματα υπολογίζονται κατά μέσο όρο για να παρέχουν μια αξιόπιστη εκτίμηση της απόδοσης.

Η χρήση του 10 fold cross validation αποτρέπει την υπερπροσαρμογή, διασφαλίζοντας ότι κάθε περίπτωση δεδομένων χρησιμοποιείται τόσο για εκπαίδευση όσο και για δοκιμή σε διαφορετικές επαναλήψεις. Επιτρέπει επίσης στα μοντέλα να γενικεύονται καλύτερα σε αφανή δεδομένα, καθιστώντας τη διαδικασία ταξινόμησης πιο αξιόπιστη.

Οι βασικές μετρικές αξιολόγησης που λαμβάνονται από το Weka περιλαμβάνουν:

- *Accuracy*: Το ποσοστό των σωστά ταξινομημένων περιπτώσεων.
- *Precision*: Το ποσοστό των σωστά προβλεπόμενων θετικών παρατηρήσεων προς το σύνολο των προβλεπόμενων θετικών παρατηρήσεων.
- *Recall*: Το ποσοστό των σωστά προβλεπόμενων θετικών παρατηρήσεων προς το σύνολο των πραγματικών θετικών παρατηρήσεων.



- *F1-score*: Ο αρμονικός μέσος όρος της ακρίβειας και της ανάκλησης, εξισορροπώντας και τα δύο μέτρα.
- *Πίνακας σύγχυσης (Confusion Matrix)*: Ένας πίνακας που δείχνει τις σωστές και λανθασμένες ταξινομήσεις για κάθε κατηγορία δραστηριότητας.

5.3.4 Αποτελέσματα Ταξινόμησης για το mHealth

Έπειτα από τη διαδικασία της προεπεξεργασίας των δεδομένων του συγκεκριμένου dataset, τα δεδομένα είναι έτοιμα να περάσουν στο επόμενο στάδιο, αυτό της ταξινόμησής τους με την εφαρμογή συγκεκριμένων ταξινομητών. Αυτό γίνεται με τη χρήση Αλγορίθμων Μηχανικής Μάθησης, όπου στην προκειμένη περίπτωση εφαρμόστηκαν έξι στο σύνολο, και παρακάτω παρουσιάζονται τα αποτελέσματα τα οποία εμφανίστηκαν κατά την εκτέλεσή τους.

- **Decision Tree**

Πρώτα εκτελέστηκε ο ταξινομητής J48 Decision Tree. Η δομή του δέντρου απόφασης επέτρεψε την εύκολη ερμηνευσιμότητα, καθιστώντας το ένα πολύτιμο μοντέλο παρά την πιθανή υπερπροσαρμογή σε ορισμένες περιπτώσεις. Η Weka εμφάνισε τα ακόλουθα αποτελέσματα:

Πίνακας 4: Αποτελέσματα Decision Tree για το mHealth Dataset

Decision Tree	35174 All Instances
Correctly Classified Instances	34608 (98.3909 %)
Incorrectly Classified Instances	566 (1.6091 %)
Accuracy	98.4 %
Precision	98.4 %
Recall	98.4 %
TP	98.4 %
FP	0.1 %
F1-Score	98.4 %
Time Taken	1.61 sec



- **Random Forest:**

Στη συνέχεια εκτελέστηκε ο ταξινομητής Random Forest, ο οποίος εμφάνισε τα κάτωθι αποτελέσματα. Το Random Forest πέτυχε την υψηλότερη απόδοση ταξινόμησης μεταξύ όλων των μοντέλων. Η προσέγγιση του συνόλου μείωσε αποτελεσματικά την υπερπροσαρμογή, οδηγώντας σε ισχυρή γενίκευση. Ωστόσο, απαιτούσε περισσότερους υπολογιστικούς πόρους σε σύγκριση με απλούστερα μοντέλα όπως το Naïve Bayes.

Πίνακας 5: Αποτελέσματα Random Forest για το mHealth Dataset

Random Forest	35174 All Instances
Correctly Classified Instances	35088 (99.7555 %)
Incorrectly Classified Instances	86 (0.2445 %)
Accuracy	98.4 %
Precision	98.4 %
Recall	98.4 %
TP	99.8 %
FP	0.001 %
F1-Score	98.4 %
Time Taken	13.99 sec

- **Support Vector Machine (SVM)**

Έπειτα, έγινε η εκτέλεση του SVM ταξινομητή στα δεδομένα, όπου βγήκαν τα εξής αποτελέσματα που φαίνονται στον πίνακα. Το SVM δυσκολεύτηκε με τα δεδομένα HAR, πιθανότατα λόγω της υψηλής διαστατικότητας και των επικαλυπτόμενων κατανομών κλάσεων. Είχε μέτριες επιδόσεις, αλλά υστερούσε σε σύγκριση με τις προσεγγίσεις που βασίζονται σε σύνολα.



Πίνακας 6: Αποτελέσματα SVM για το mHealth Dataset

SVM	35174 All Instances
Correctly Classified Instances	26081 (74.1485 %)
Incorrectly Classified Instances	9093 (25.8515 %)
Accuracy	74.1 %
Precision	74.8 %
Recall	74.1 %
TP	74.1 %
FP	2.5 %
F1-Score	73.4 %
Time Taken	11.34 sec

- **K – Nearest Neighbors**

Στη συνέχεια, εφαρμόστηκε ο ταξινομητής k-NN, με αριθμό γειτόνων $k=1$ και λήφθηκαν τα αποτελέσματα του παρακάτω πίνακα. Αυτός ο ταξινομητής είχε καλή απόδοση, αλλά ήταν υπολογιστικά δαπανηρός για μεγάλα σύνολα δεδομένων λόγω των υπολογισμών απόστασης.

Πίνακας 7: Αποτελέσματα kNN για το mHealth Dataset

kNN	35174 All Instances
Correctly Classified Instances	30056 (85.4495 %)
Incorrectly Classified Instances	5118 (14.5505 %)
Accuracy	85.4 %
Precision	85.3 %
Recall	85.4 %
TP	85.4 %
FP	1.4 %
F1-Score	85.2 %
Time Taken	0.02 sec



- **Naïve Bayes**

Ακολούθως, εκτελέστηκε ο ταξινομητής Naïve Bayes, ο οποίος έδωσε τα κάτωθι αποτελέσματα. Ο Naïve Bayes ήταν ο ταχύτερος ταξινομητής αλλά είχε χαμηλότερη ακρίβεια. Η απόδοσή του ήταν περιορισμένη λόγω της παραδοχής της ανεξαρτησίας των χαρακτηριστικών, η οποία σπάνια ισχύει στα δεδομένα HAR.

Πίνακας 8: Αποτελέσματα Naïve Bayes για το mHealth Dataset

Naïve Bayes	35174 All Instances
Correctly Classified Instances	21867 (62.1681 %)
Incorrectly Classified Instances	13307 (37.8319 %)
Accuracy	62.2 %
Precision	81.6 %
Recall	62.2 %
TP	62.2 %
FP	3.2 %
F1-Score	61.7 %
Time Taken	0.24 sec

- **Neural Networks – CNN**

Τέλος, εφαρμόστηκε και ο αλγόριθμος των Νευρωνικών Δικτύων, ο οποίος εμφάνισε τα παρακάτω αποτελέσματα του πίνακα. Το CNN είχε καλές επιδόσεις, επωφελούμενο από την εξαγωγή χαρακτηριστικών μέσω βαθιάς μάθησης. Ωστόσο, ήταν υπολογιστικά δαπανηρή, απαιτώντας τον μεγαλύτερο χρόνο εκπαίδευσης.

Πίνακας 9: Αποτελέσματα Neural Networks για το mHealth Dataset

CNN	35174 All Instances
Correctly Classified Instances	29722 (84.4999 %)
Incorrectly Classified Instances	5452 (15.5001 %)
Accuracy	84.5 %



Precision	84.1 %
Recall	84.5 %
TP	84.5 %
FP	1.5 %
F1-Score	84.1 %
Time Taken	117.08 sec

Έπειτα από την παρουσίαση όλων των αποτελεσμάτων και των έξι μοντέλων Μηχανικής Μάθησης, ήρθε η ώρα, με βάση τους συγκεκριμένους αριθμούς, να γίνει μια ανάλυση και να απαντηθεί η ερώτηση: Ποιος είναι ο καλύτερος αλγόριθμος ταξινόμησης για το mHealth dataset;

Με βάση τα αποτελέσματα ταξινόμησης που προέκυψαν από το Weka, ο ταξινομητής Random Forest αναδείχθηκε ως το μοντέλο με τις καλύτερες επιδόσεις για το σύνολο δεδομένων MHEALTH HAR. Πέτυχε την υψηλότερη ακρίβεια 99,8%, δηλαδή έκανε τις λιγότερες λανθασμένες ταξινομήσεις μεταξύ όλων των μοντέλων που δοκιμάστηκαν. Επιπλέον, επέδειξε ένα πολύ χαμηλό ποσοστό ψευδώς θετικών αποτελεσμάτων, μόλις 0,001%, καθιστώντας το ιδιαίτερα αξιόπιστο για τη διάκριση μεταξύ διαφορετικών ανθρώπινων δραστηριοτήτων. Η ακρίβεια, η ανάκληση και το F1-score για το Random Forest ήταν όλα 98,4%, υποδεικνύοντας ισχυρές και ισορροπημένες επιδόσεις ταξινόμησης σε όλες τις κατηγορίες δραστηριοτήτων. Παρόλο που ο χρόνος υπολογισμού του ήταν 13,99 δευτερόλεπτα, ο οποίος είναι υψηλότερος από ορισμένα άλλα μοντέλα, αυτό το αντιστάθμισμα είναι λογικό δεδομένης της ανώτερης απόδοσής του. Συνολικά, το Random Forest είναι ο πιο αποτελεσματικός ταξινομητής για αυτό το σύνολο δεδομένων, προσφέροντας τόσο υψηλή ακρίβεια όσο και ισχυρή γενίκευση.

Ο ταξινομητής Δέντρου Αποφάσεων (J48) κατέλαβε τη δεύτερη καλύτερη θέση. Πέτυχε ακρίβεια 98,4%, η οποία είναι ελαφρώς χαμηλότερη από την Random Forest, αλλά εξακολουθεί να είναι εξαιρετικά υψηλή. Η ακρίβεια, η ανάκληση και το F1-score ήταν επίσης 98,4%, καθιστώντας τον μια ανταγωνιστική εναλλακτική λύση. Ένα από τα βασικά



πλεονεκτήματά του είναι η υπολογιστική του απόδοση, καθώς ολοκλήρωσε την ταξινόμηση σε μόλις 1,61 δευτερόλεπτα, σημαντικά ταχύτερα από το Random Forest. Ωστόσο, είχε ελαφρώς υψηλότερο ποσοστό ψευδώς θετικών αποτελεσμάτων (0,1%), πράγμα που σημαίνει ότι παρήγαγε ελαφρώς περισσότερες λανθασμένες ταξινομήσεις από το Random Forest. Παρά αυτό το μικρό μειονέκτημα, το Decision Tree παραμένει μια ισχυρή επιλογή, ειδικά όταν ο ταχύτερος χρόνος εκτέλεσης αποτελεί προτεραιότητα.

Στο μεσαίο εύρος επιδόσεων, οι ταξινομητές k-Nearest Neighbors (k-NN) και Convolutional Neural Network (CNN) επέδειξαν μέτριες δυνατότητες ταξινόμησης. Το μοντέλο k-NN (k=1) πέτυχε ακρίβεια 85,4%, με ακρίβεια 85,3% και βαθμολογία F1 85,2%. Ενώ αυτές οι μετρήσεις είναι αξιοσέβαστες, υπολείπονται εκείνων των Random Forest και Decision Tree. Ωστόσο, το k-NN είχε ένα αξιοσημείωτο πλεονέκτημα όσον αφορά το χρόνο υπολογισμού, καθώς χρειάστηκε μόλις 0,02 δευτερόλεπτα για να ολοκληρώσει την ταξινόμηση, καθιστώντας το ταχύτερο μοντέλο σε αυτή τη σύγκριση. Από την άλλη πλευρά, το CNN πέτυχε ακρίβεια 84,5%, με παρόμοιες βαθμολογίες ακρίβειας και ανάκλησης. Ενώ τα μοντέλα βαθιάς μάθησης, όπως το CNN, συχνά απαιτούν σημαντικούς υπολογιστικούς πόρους, ο χρόνος επεξεργασίας των 117,08 δευτερολέπτων σε αυτό το πείραμα είναι σημαντικά υψηλότερος από οποιονδήποτε άλλο ταξινομητή, καθιστώντας το μη εφαρμόσιμο για εφαρμογές HAR σε πραγματικό χρόνο. Έτσι, το k-NN είναι μια αξιοπρεπής επιλογή για γρήγορη ταξινόμηση, ενώ το CNN παραμένει μια επιλογή εάν προτιμώνται προσεγγίσεις βαθιάς μάθησης, παρά το υψηλό υπολογιστικό κόστος του.

Στο κατώτερο άκρο των επιδόσεων, οι ταξινομητές Μηχανή Διανυσμάτων Υποστήριξης (SVM) και Naïve Bayes παρουσίασαν τα πιο αδύναμα αποτελέσματα. Η SVM πέτυχε ακρίβεια 74,1%, με βαθμολογίες ακρίβειας και ανάκλησης γύρω στο 74%, γεγονός που υποδηλώνει ότι δυσκολεύτηκε να διακρίνει αποτελεσματικά μεταξύ των κλάσεων δραστηριότητας. Είχε επίσης ποσοστό ψευδώς θετικών αποτελεσμάτων 2,5%, το οποίο είναι σημαντικά υψηλότερο από τα μοντέλα με καλύτερες επιδόσεις. Ενώ ολοκλήρωσε την ταξινόμηση σε 11,34 δευτερόλεπτα, η ακρίβειά του δεν ήταν αρκετά ανταγωνιστική ώστε να δικαιολογεί τη χρήση του έναντι άλλων μοντέλων. Εν τω μεταξύ, ο Naïve Bayes είχε τη χειρότερη επίδοση από όλους τους ταξινομητές, επιτυγχάνοντας ακρίβεια μόλις 62,2%. Παρά το γεγονός ότι είχε την υψηλότερη ακρίβεια με 81,6%, η ανάκληση και το F1-score του ήταν χαμηλά, υποδεικνύοντας ότι ενώ έκανε σχετικά λίγα ψευδώς θετικά αποτελέσματα, έχασε μεγάλο αριθμό πραγματικών ταξινομήσεων δραστηριοτήτων. Ωστόσο, το



σημαντικότερο πλεονέκτημά του ήταν η ταχύτητά του, καθώς χρειάστηκε μόλις 0,24 δευτερόλεπτα για την ταξινόμηση. Ενώ αυτό την καθιστά υπολογιστικά αποδοτική, η χαμηλή ακρίβειά της την καθιστά ακατάλληλη για την αναγνώριση ανθρώπινων δραστηριοτήτων.

Συμπερασματικά, το Random Forest είναι ο καλύτερος ταξινομητής για το σύνολο δεδομένων MHEALTH HAR, παρέχοντας την υψηλότερη ακρίβεια με ελάχιστα ψευδώς θετικά αποτελέσματα. Το Decision Tree είναι μια ισχυρή εναλλακτική λύση, προσφέροντας σχεδόν πανομοιότυπες επιδόσεις με ταχύτερη εκτέλεση. Το k-NN είναι χρήσιμο για γρήγορες ταξινομήσεις, αλλά η ακρίβειά του είναι χαμηλότερη, ενώ το CNN έχει δυνατότητες αλλά είναι υπολογιστικά ακριβό. Οι SVM και Naïve Bayes είναι οι πιο αδύναμοι ταξινομητές, με σημαντικά χαμηλότερη ακρίβεια και αξιοπιστία. Ως εκ τούτου, ο καλύτερος ταξινομητής για αυτό το σύνολο δεδομένων είναι ο Random Forest, ενώ ο χειρότερος ταξινομητής είναι ο Naïve Bayes.

5.5.5 Αποτελέσματα Ταξινόμησης για το WISDM

Ακριβώς η ίδια διαδικασία που ακολουθήθηκε στο mHealth Dataset, εφαρμόστηκε και στο WISDM Dataset. Τα αποτελέσματα της εκτέλεσης των έξι Αλγορίθμων Μηχανικής Μάθησης παρουσιάζονται παρακάτω:

- **Decision Tree**

Πρώτα εκτελέστηκε ο ταξινομητής J48 Decision Tree. Η δομή του δέντρου απόφασης επέτρεψε την εύκολη ερμηνευσιμότητα, καθιστώντας το ένα πολύτιμο μοντέλο παρά την πιθανή υπερπροσαρμογή σε ορισμένες περιπτώσεις. Ο ταξινομητής Δέντρου Αποφάσεων παρείχε ισχυρή και αξιόπιστη απόδοση, προσφέροντας μια καλή ισορροπία μεταξύ ακρίβειας και ερμηνευσιμότητας. Ταξινόμησε σωστά τις περισσότερες δραστηριότητες, διατηρώντας παράλληλα την αποδοτικότητα, καθιστώντας τον μια σταθερή επιλογή για εφαρμογές πραγματικού χρόνου. Ωστόσο, υπερείχε ελαφρώς από πιο σύνθετα μοντέλα. Η Weka εμφάνισε τα ακόλουθα αποτελέσματα:



Πίνακας 10: Αποτελέσματα Decision Tree για το WISDM Dataset

Decision Tree	5418 All Instances
Correctly Classified Instances	4847 (89.4611 %)
Incorrectly Classified Instances	571 (10.5389 %)
Accuracy	98.4 %
Precision	89.2 %
Recall	89.5 %
TP	89.5 %
FP	2.9 %
F1-Score	89.3 %
Time Taken	0.62 sec

- **Random Forest**

Ο ταξινομητής Random Forest ήταν ο ταξινομητής με τις καλύτερες επιδόσεις για το σύνολο δεδομένων WISDM, επιδεικνύοντας υψηλή ακρίβεια και ανθεκτικότητα. Η προσέγγιση του συνόλου βοήθησε στη μείωση των λανθασμένων ταξινομήσεων, διατηρώντας παράλληλα τη συνοχή μεταξύ των διαφόρων κατηγοριών δραστηριοτήτων. Αν και απαιτούσε περισσότερους υπολογισμούς από το Δέντρο Αποφάσεων, η αξιοπιστία του το κατέστησε το πιο αποτελεσματικό μοντέλο συνολικά. Η Weka εμφάνισε τα ακόλουθα αποτελέσματα:

Πίνακας 11: Αποτελέσματα Random Forest για το WISDM Dataset

Random Forest	5418 All Instances
Correctly Classified Instances	5130 (94.6844 %)
Incorrectly Classified Instances	288 (5.3156 %)
Accuracy	94.7 %
Precision	94.7 %
Recall	94.7 %



TP	94.7 %
FP	1.1 %
F1-Score	94.7 %
Time Taken	2.2 sec

- **Support Vector Machine (SVM)**

Το SVM έδειξε αξιοπρεπή ικανότητα ταξινόμησης, αλλά δυσκολεύτηκε ελαφρώς στη διάκριση μεταξύ ορισμένων δραστηριοτήτων. Ενώ είχε καλύτερες επιδόσεις από το Naïve Bayes, ήταν λιγότερο αποτελεσματικό από το Random Forest και το CNN. Το υπολογιστικό του κόστος ήταν μέτριο, καθιστώντας το μια λογική επιλογή για το HAR, αλλά όχι την πλέον βέλτιστη.

Πίνακας 12: Αποτελέσματα SVM για το WISDM Dataset

SVM	5418 All Instances
Correctly Classified Instances	4622 (85.3082 %)
Incorrectly Classified Instances	796 (14.6918 %)
Accuracy	85.3 %
Precision	83.4 %
Recall	85.3 %
TP	85.3 %
FP	5.3 %
F1-Score	83.7 %
Time Taken	2.54 sec

- **K – Nearest Neighbors (K- NN)**

Στη συνέχεια, εφαρμόστηκε ο ταξινομητής k-NN για αριθμό γειτόνων k=1. Ο ταξινομητής k-NN είχε παρόμοιες επιδόσεις με τον SVM, αλλά με ελαφρώς καλύτερη ακρίβεια. Ήταν εξαιρετικά γρήγορος στον υπολογισμό και παρείχε λογικά αποτελέσματα ταξινόμησης. Ωστόσο, οι επιδόσεις του δεν ήταν τόσο ισχυρές όσο του Random Forest ή του CNN,



καθιστώντας τον πιο κατάλληλο για σενάρια όπου η ταχύτητα αποτελεί προτεραιότητα έναντι της ακρίβειας.

Πίνακας 13: Αποτελέσματα k -NN για το WISDM Dataset

kNN	5418 All Instances
Correctly Classified Instances	4656 (85.9358 %)
Incorrectly Classified Instances	762 (14.0642 %)
Accuracy	85.4 %
Precision	86.5 %
Recall	85.9 %
TP	85.9 %
FP	3.8 %
F1-Score	85.6 %
Time Taken	0.0002 sec

- **Naïve Bayes**

Η μέθοδος Naïve Bayes δυσκολεύτηκε περισσότερο με την ταξινόμηση στο σύνολο δεδομένων WISDM, πιθανότατα λόγω των ισχυρών υποθέσεων ανεξαρτησίας της, οι οποίες δεν ευθυγραμμίζονται καλά με πολύπλοκα δεδομένα αισθητήρων. Παρόλο που ήταν πολύ γρήγορο, η χαμηλότερη ακρίβειά του το κατέστησε λιγότερο αξιόπιστη επιλογή για εργασίες HAR.

Πίνακας 14: Αποτελέσματα Naïve Bayes για το WISDM Dataset

Naïve Bayes	5418 All Instances
Correctly Classified Instances	4099 (75.6552 %)
Incorrectly Classified Instances	1319 (24.3448 %)
Accuracy	75.7 %
Precision	71.9 %
Recall	75.7 %
TP	75.7 %



FP	1.03 %
F1-Score	72.6 %
Time Taken	0.07 sec

- **Neural Networks - CNN**

Το CNN είχε εξαιρετικά καλές επιδόσεις, σχεδόν ισοδυναμώντας με το Random Forest στην ποιότητα ταξινόμησης. Οι δυνατότητες βαθιάς μάθησης που διέθετε το βοήθησαν να συλλάβει πολύπλοκα μοτίβα στα δεδομένα. Ωστόσο, το μεγαλύτερο μειονέκτημά του ήταν ο μεγάλος χρόνος υπολογισμού, γεγονός που το καθιστά λιγότερο κατάλληλο για εφαρμογές πραγματικού χρόνου παρά την ισχυρή προβλεπτική του ικανότητα.

Πίνακας 15: Αποτελέσματα CNN για το WISDM Dataset

CNN	5418 All Instances
Correctly Classified Instances	5020 (92.6541 %)
Incorrectly Classified Instances	398 (7.3459 %)
Accuracy	92.6 %
Precision	92.7 %
Recall	92.7 %
TP	92.7 %
FP	1.3 %
F1-Score	92.6 %
Time Taken	149.82 sec

Όπως ακριβώς και στο mHealth Dataset, έτσι και στο WISDM, αφότου παρουσιάστηκαν όλα τα αποτελέσματα και των έξι μοντέλων Μηχανικής Μάθησης, ήρθε η στιγμή, με βάση τους συγκεκριμένους αριθμούς, να γίνει μια ανάλυση και να απαντηθεί η ερώτηση: Ποιος είναι ο καλύτερος αλγόριθμος ταξινόμησης για το mHealth dataset;



Για το σύνολο δεδομένων WISDM, ο ταξινομητής με τις καλύτερες επιδόσεις ήταν ο Random Forest, ενώ ο ταξινομητής με τις χειρότερες επιδόσεις ήταν ο Naïve Bayes.

Το Random Forest ξεπέρασε όλα τα άλλα μοντέλα όσον αφορά την ακρίβεια, την ακρίβεια, την ανάκληση και το F1-score. Η προσέγγιση μάθησης συνόλου, η οποία συγκεντρώνει πολλαπλά δέντρα απόφασης, συνέβαλε στην ισχυρή προγνωστική του απόδοση και την ανθεκτικότητά του σε διαφορετικές κατηγορίες δραστηριοτήτων. Αυτή η μέθοδος χειρίστηκε αποτελεσματικά τις διακυμάνσεις στα δεδομένα των αισθητήρων και απέφυγε την υπερβολική προσαρμογή, διατηρώντας παράλληλα υψηλή αξιοπιστία. Παρόλο που απαιτούσε περισσότερους υπολογισμούς από απλούστερα μοντέλα όπως το Δέντρο Αποφάσεων ή το k-NN, η ανώτερη ακρίβεια ταξινόμησής του την κατέστησε την καλύτερη επιλογή για το HAR σε αυτό το σύνολο δεδομένων.

Από την άλλη πλευρά, το Naïve Bayes είχε την πιο αδύναμη απόδοση ταξινόμησης. Αυτό πιθανώς οφείλεται στην υπόθεση του αλγορίθμου για ανεξαρτησία των χαρακτηριστικών, η οποία δεν ισχύει καλά σε πολύπλοκα δεδομένα δραστηριότητας που βασίζονται σε αισθητήρες. Ως αποτέλεσμα, δυσκολευόταν να διακρίνει μεταξύ διαφορετικών δραστηριοτήτων, οδηγώντας σε υψηλότερο ποσοστό λανθασμένης ταξινόμησης. Παρόλο που ήταν υπολογιστικά αποδοτικός και γρήγορος, η χαμηλότερη ακρίβεια και η βαθμολογία F1 τον κατέστησαν το λιγότερο αποτελεσματικό μοντέλο για αυτό το σύνολο δεδομένων.

Συνοψίζοντας, το Random Forest είναι ο πιο αξιόπιστος ταξινομητής για το HAR χρησιμοποιώντας το σύνολο δεδομένων WISDM, εξισορροπώντας την ακρίβεια και την αποτελεσματικότητα, ενώ το Naïve Bayes είναι ο λιγότερο κατάλληλος λόγω των υπεραπλουστευμένων πιθανολογικών υποθέσεων που κάνει και οι οποίες αποτυγχάνουν να αποτυπώσουν τις πολύπλοκες σχέσεις στα δεδομένα αναγνώρισης δραστηριοτήτων.



5.5.6 Εξαγωγή Αποτελεσμάτων για Οπτικοποίηση

Για να διευκολυνθεί μια ολοκληρωμένη σύγκριση, οι μετρικές που εξήχθησαν από την πλατφόρμα Weka επεξεργάστηκαν με τη χρήση σεναρίων Python. Με την οπτικοποίηση των αποτελεσμάτων, επιτεύχθηκε σαφέστερη ερμηνεία της αποτελεσματικότητας των μοντέλων, καθοδηγώντας τελικά την επιλογή του καλύτερου μοντέλου ταξινόμησης για την Αναγνώριση Ανθρώπινης Δραστηριότητας (HAR). Αφού προέκυψαν τα αποτελέσματα της ταξινόμησης, εξήχθησαν και αναλύθηκαν μετρικές απόδοσης με τη χρήση της Python για να βελτιωθεί η ερμηνευσιμότητα. Δημιουργήθηκαν οι ακόλουθες οπτικοποιήσεις:

A) Καμπύλες ROC

Οι καμπύλες λειτουργικού χαρακτηριστικού δέκτη (ROC) σχεδιάστηκαν για κάθε ταξινομητή για να μετρηθεί ο συμβιβασμός μεταξύ ευαισθησίας (ανάκληση) και ειδικότητας. Η περιοχή κάτω από την καμπύλη (AUC) χρησιμοποιήθηκε ως ποσοτικό μέτρο, όπου μια υψηλότερη AUC υποδηλώνει καλύτερη απόδοση του μοντέλου. Αυτά τα διαγράμματα παρέχουν μια σαφή οπτική αναπαράσταση του πόσο καλά κάθε ταξινομητής διακρίνει μεταξύ των κατηγοριών δραστηριότητας.

B) Καμπύλες ακρίβειας-ανάκλησης (Precision – Recall Curves)

Οι καμπύλες ακρίβειας-ανάκλησης χρησιμοποιήθηκαν για την αξιολόγηση των επιδόσεων των ταξινομητών στο χειρισμό ανισοβαρών δεδομένων. Οι καμπύλες αυτές καταδεικνύουν την ισορροπία μεταξύ ακρίβειας και ανάκλησης για διαφορετικά κατώτατα όρια ταξινόμησης. Μια υψηλή περιοχή κάτω από την καμπύλη ακρίβειας-ανάκλησης υποδηλώνει καλύτερη απόδοση στη διάκριση μεταξύ δραστηριοτήτων.

Γ) Χάρτες θερμότητας του πίνακα σύγχυσης (Confusion Matrix Heatmaps)

Οι πίνακες σύγχυσης εξήχθησαν και μετατράπηκαν σε θερμικούς χάρτες για την απεικόνιση των προτύπων λανθασμένης ταξινόμησης. Κάθε γραμμή αντιπροσωπεύει την πραγματική κλάση, ενώ κάθε στήλη αντιπροσωπεύει την προβλεπόμενη κλάση. Ένας ταξινομητής με



άριστη απόδοση θα είχε ένα έντονο διαγώνιο μοτίβο, υποδεικνύοντας υψηλά ποσοστά ορθής ταξινόμησης. Τα Heatmaps βοηθούν στον εντοπισμό συγκεκριμένων δραστηριοτήτων που ταξινομούνται συχνά λανθασμένα, παρέχοντας πληροφορίες για πιθανές βελτιώσεις του μοντέλου.

Δ) Διαγράμματα σύγκρισης (Comparison Plots)

Για τη σύγκριση των επιδόσεων των ταξινομητών, δημιουργήθηκαν ραβδογράμματα και γραμμικά διαγράμματα χρησιμοποιώντας τις εξαγόμενες μετρικές:

- Σύγκριση ακρίβειας μεταξύ ταξινομητών.
- Αξιολόγηση F1-score για την εξισορρόπηση της ακρίβειας και της ανάκλησης.
- Συμβιβασμοί επιδόσεων συγκεκριμένων μοντέλων.

Αυτές οι οπτικοποιήσεις επέτρεψαν συλλογικά τον προσδιορισμό του πιο αποτελεσματικού ταξινομητή για τις εργασίες HAR. Οι γνώσεις που αποκτήθηκαν από αυτά τα διαγράμματα θα συζητηθούν στο επόμενο κεφάλαιο, όπου παρέχεται μια βαθύτερη ανάλυση των επιδόσεων των μοντέλων και των πιθανών βελτιώσεων [85].



6. Αποτελέσματα, Σύγκριση και Συζήτηση


Στο παρόν κεφάλαιο παρουσιάζονται τα αποτελέσματα των πειραμάτων ταξινόμησης που πραγματοποιήθηκαν στα σύνολα δεδομένων mHealth και WISDM, και ακολουθεί μια εμπεριστατωμένη σύγκριση και συζήτηση των επιδόσεων των μοντέλων. Στόχος αυτής της ενότητας είναι να αξιολογηθεί η αποτελεσματικότητα των έξι επιλεγμένων ταξινομητών μηχανικής μάθησης στην αναγνώριση ανθρώπινων δραστηριοτήτων από δεδομένα αισθητήρων.

6.1 Οπτικοποίηση Αποτελεσμάτων για το mHEALTH


Η οπτικοποίηση των αποτελεσμάτων ταξινόμησης είναι απαραίτητη για την ερμηνεία της απόδοσης των μοντέλων μηχανικής μάθησης που εφαρμόζονται στο σύνολο δεδομένων mHealth. Η αξιολόγηση διεξήχθη με τη χρήση πολλαπλών γραφικών παραστάσεων, συμπεριλαμβανομένων των πινάκων σύγχυσης σε μορφή Heatmaps, των καμπυλών ακρίβειας-ανάκλησης (Precision – Recall), των καμπυλών ROC, των γραφικών παραστάσεων μετρήσεων απόδοσης και των καμπυλών μάθησης (Learning Curves). Αυτές οι απεικονίσεις παρέχουν κρίσιμες πληροφορίες σχετικά με το πόσο καλά απέδωσε κάθε ταξινομητής στην αναγνώριση ανθρώπινων δραστηριοτήτων με βάση τα δεδομένα φορητών αισθητήρων.

6.1.1 Heatmaps Πινάκων Σύγχυσης όλων των μοντέλων


Ο πίνακας σύγχυσης είναι ένα θεμελιώδες εργαλείο στην ανάλυση ταξινόμησης, καθώς απεικονίζει πόσο καλά οι προβλεπόμενες ετικέτες ταιριάζουν με τις πραγματικές ετικέτες για διάφορες κατηγορίες δραστηριοτήτων. Κάθε πίνακας σύγχυσης, που παρουσιάζεται σε μορφή θερμικού χάρτη, αντιπροσωπεύει την απόδοση ταξινόμησης ενός συγκεκριμένου μοντέλου μηχανικής μάθησης.




Εικόνα 31: Confusion Matrix Heatmap for Decision Tree Model




Εικόνα 32: Confusion Matrix Heatmap for Random Forest Model




Εικόνα 33: Confusion Matrix Heatmap for SVM Model



Εικόνα 34: Confusion Matrix Heatmap for k-NN Model



Εικόνα 35: Confusion Matrix Heatmap for Naive Bayes Model



Εικόνα 36: Confusion Matrix Heatmap for CNN Model



Ο ταξινομητής Decision Tree επέδειξε υψηλή ακρίβεια, ταξινομώντας σωστά την πλειονότητα των περιπτώσεων δραστηριότητας με ελάχιστες λανθασμένες ταξινομήσεις. Ωστόσο, παρουσίασε ορισμένα σφάλματα στη διάκριση μεταξύ δραστηριοτήτων με παρόμοια μοτίβα κίνησης, όπως το περπάτημα και το τρέξιμο, όπου μικρές διαφορές στην κίνηση μπορεί να οδηγήσουν σε σύγχυση ταξινόμησης. Παρά το γεγονός αυτό, η συνολική απόδοση ήταν ισχυρή, καθιστώντας το ένα από τα πιο ερμηνεύσιμα και αξιόπιστα μοντέλα ταξινόμησης.

Ο ταξινομητής Random Forest πέτυχε την καλύτερη απόδοση μεταξύ όλων των μοντέλων. Παρουσίασε το χαμηλότερο ποσοστό λανθασμένης ταξινόμησης, αποδεικνύοντας την ικανότητά του να γενικεύει καλά σε διάφορες κατηγορίες δραστηριοτήτων. Ο πίνακας σύγκρισης έδειξε ότι αυτό το μοντέλο έκανε σημαντικά λιγότερα σφάλματα ταξινόμησης σε σύγκριση με το μοντέλο Decision Tree, ενισχύοντας το πλεονέκτημα των τεχνικών μάθησης συνόλου σε εργασίες HAR.

Από την άλλη πλευρά, το Support Vector Machine (SVM) δυσκολεύτηκε με τις αλληλεπικαλυπτόμενες δραστηριότητες, οδηγώντας σε περισσότερες λανθασμένες ταξινομήσεις από ό,τι τα μοντέλα που βασίζονται σε δέντρα. Ο πίνακας σύγκρισης για το SVM έδειξε ότι ήταν λιγότερο αποτελεσματικό στη διαφοροποίηση μεταξύ δραστηριοτήτων με παρόμοια χαρακτηριστικά κίνησης, επηρεάζοντας την αξιοπιστία της ταξινόμησής του.

Ο ταξινομητής k-Nearest Neighbors (k-NN) παρουσίασε επίπεδο απόδοσης παρόμοιο με το SVM. Είχε αρκετά καλές επιδόσεις, αλλά δυσκολευόταν με δεδομένα υψηλής διάστασης, οδηγώντας σε σφάλματα όταν οι δραστηριότητες ήταν στενά συνδεδεμένες μεταξύ τους. Παρόλο που ο k-NN είχε ανταγωνιστική ακρίβεια, ο πίνακας σύγκρισης αποκάλυψε αξιοσημείωτα σφάλματα ταξινόμησης, ιδίως στη διάκριση μεταξύ λεπτών μεταβάσεων δραστηριοτήτων.

Ο ταξινομητής Naïve Bayes παράγαγε τα χειρότερα αποτελέσματα, με μεγάλο αριθμό λανθασμένων ταξινομήσεων σε πολλές κατηγορίες δραστηριοτήτων. Ο πίνακας σύγκρισης έδειξε σαφώς ότι ο Naïve Bayes δυσκολευόταν να μοντελοποιήσει τις πολύπλοκες κατανομές των δεδομένων ανθρώπινης δραστηριότητας, οδηγώντας σε σημαντικά σφάλματα ταξινόμησης.


Το Συνελικτικό Νευρωνικό Δίκτυο (CNN) απέδωσε καλά στην καταγραφή σύνθετων μοτίβων, όπως αποδεικνύεται από τον πίνακα σύγκρισης. Ωστόσο, ενίοτε δυσκολευόταν να




διακρίνει μεταξύ παρόμοιων δραστηριοτήτων, ιδίως όταν επρόκειτο για λεπτές διαφορές στην κίνηση. Ενώ η ακρίβεια ταξινόμησής του ήταν υψηλή, υπήρχαν ακόμη κάποιες λανθασμένες ταξινομήσεις.

6.1.2 Precision- Recall και ROC Curves όλων των μοντέλων


Οι καμπύλες Precision-Recall και ROC (Receiver Operating Characteristic) παρέχουν μια βαθύτερη κατανόηση του τρόπου με τον οποίο κάθε ταξινομητής αποδίδει στη διάκριση μεταξύ των κατηγοριών δραστηριοτήτων. Η καμπύλη Precision-Recall αξιολογεί την ικανότητα του μοντέλου να ελαχιστοποιεί τα ψευδώς θετικά αποτελέσματα, ενώ η καμπύλη ROC αντιπροσωπεύει τον συμβιβασμό μεταξύ ευαισθησίας (Recall) και ειδικότητας (1 - False Positive Rate).




Εικόνα 37: Precision-Recall Curve and ROC Curve for Decision Tree Model




Εικόνα 38: Precision-Recall Curve and ROC Curve for Random Forest Model




Εικόνα 39: Precision-Recall Curve and ROC Curve for SVM Model



Εικόνα 40: Precision-Recall Curve and ROC Curve for k-NN Model



Εικόνα 41: Precision-Recall Curve and ROC Curve for Naive Bayes Model



Εικόνα 42: Precision-Recall Curve and ROC Curve for CNN Model



Ο ταξινομητής Decision Tree επέδειξε ισχυρή ικανότητα ταξινόμησης με υψηλή περιοχή κάτω από την καμπύλη (AUC) τόσο στις καμπύλες Precision-Recall όσο και στις καμπύλες ROC. Αυτό έδειξε ότι το μοντέλο ήταν ικανό να διακρίνει αποτελεσματικά τις δραστηριότητες με ελάχιστα ψευδώς θετικά αποτελέσματα.

Ο ταξινομητής Random Forest είχε τις υψηλότερες τιμές AUC, επιβεβαιώνοντας την ανώτερη απόδοση ταξινόμησης. Οι υψηλές τιμές ακρίβειας και ανάκλησης σε πολλαπλές κατηγορίες δραστηριοτήτων κατέδειξαν την ανθεκτικότητα αυτού του μοντέλου, καθιστώντας το ως το μοντέλο με τις καλύτερες επιδόσεις στην ταξινόμηση HAR.

Αντίθετα, ο ταξινομητής SVM παρουσίασε ασθενέστερες καμπύλες ROC και Precision-Recall σε σύγκριση με τα μοντέλα που βασίζονται σε δέντρα. Αυτό υποδηλώνει ότι το SVM αντιμετώπισε προκλήσεις στο διαχωρισμό επικαλυπτόμενων κλάσεων δραστηριότητας, οδηγώντας σε χαμηλότερη ικανότητα διάκρισης μεταξύ πραγματικών και προβλεπόμενων ετικετών δραστηριότητας.

Το μοντέλο k-NN παρουσίασε μέτρια απόδοση, με την καμπύλη ROC να δείχνει μια ελαφρώς ασθενέστερη ικανότητα ταξινόμησης από το Random Forest και το Decision Tree. Η καμπύλη ακρίβειας-ανάκλησης έδειξε ότι το k-NN δυσκολευόταν να διατηρήσει την ισορροπία μεταξύ ψευδώς θετικών και ψευδώς αρνητικών αποτελεσμάτων, επηρεάζοντας τη συνολική απόδοσή του.


Ο ταξινομητής Naïve Bayes είχε τις φτωχότερες καμπύλες Precision-Recall και ROC, γεγονός που αναδεικνύει την αναποτελεσματικότητά του στο χειρισμό σύνθετων δεδομένων HAR. Οι χαμηλές τιμές AUC έδειξαν ότι το μοντέλο δυσκολευόταν σημαντικά στη διαφοροποίηση μεταξύ των κατηγοριών δραστηριότητας, καθιστώντας το ακατάλληλο για ακριβή ταξινόμηση HAR.

Ο ταξινομητής CNN επέδειξε ανταγωνιστικές επιδόσεις στις καμπύλες ROC και Precision-Recall, αλλά δεν ξεπέρασε τον ταξινομητή Random Forest. Ενώ το CNN είχε καλές επιδόσεις στη σύλληψη σύνθετων χρονικών και χωρικών μοτίβων στα δεδομένα HAR, παρουσίασε κάποιες ασυνέπειες στην ταξινόμηση δραστηριοτήτων, ιδίως για δραστηριότητες με λεπτές παραλλαγές.



6.1.3 Οπτικοποίηση της Απόδοσης των Μετρικών όλων των μοντέλων

Ένα ειδικό διάγραμμα που συγκρίνει την Ακρίβεια, την Ακρίβεια, την Ανάκληση και το F1-Score για όλους τους ταξινομητές παρείχε μια συνολική σύνοψη της απόδοσης του μοντέλου. Τα αποτελέσματα επιβεβαίωσαν ότι το Random Forest πέτυχε τις υψηλότερες τιμές σε όλες τις μετρήσεις, εδραιώνοντας τη θέση του ως ταξινομητή με τις καλύτερες επιδόσεις. Τα μοντέλα Decision Tree και CNN ακολούθησαν από κοντά, ενώ τα μοντέλα Naïve Bayes είχαν τη χαμηλότερη απόδοση, επιβεβαιώνοντας την κακή ικανότητα γενίκευσης στην ταξινόμηση HAR.




Εικόνα 43: Metrics Values for all Models (Accuracy, Precision, Recall, F1Score)

6.1.4 Συγκριτική ανάλυση ROC Curve όλων των μοντέλων

Μια ενιαία καμπύλη ROC που συνέκρινε όλους τους ταξινομητές παρείχε μια άμεση οπτική αναπαράσταση της ικανότητας κάθε μοντέλου να ταξινομεί δραστηριότητες. Το μοντέλο Random Forest παρουσίασε την καλύτερη καμπύλη ROC, ενισχύοντας περαιτέρω την κατάστασή του ως κορυφαίο. Αντίθετα, το μοντέλο Naïve Bayes είχε την πιο αδύναμη



καμπύλη ROC, επιβεβαιώνοντας την ανεπαρκή ικανότητά του να διαχωρίζει αποτελεσματικά τις κατηγορίες δραστηριοτήτων.



Εικόνα 44: ROC Curve for all the 6 Models


6.1.5 Καμπύλες Εκμάθησης (Learning Curves) όλων των μοντέλων

Οι καμπύλες μάθησης για κάθε ταξινομητή αποκάλυψαν πρόσθετες πληροφορίες σχετικά με τις ικανότητες γενίκευσής τους:


- Το Random Forest είχε την καλύτερη καμπύλη μάθησης, επιδεικνύοντας σταθερή απόδοση με την αύξηση των δεδομένων εκπαίδευσης.
- Το δένδρο αποφάσεων παρουσίασε μικρή υπερπροσαρμογή, αλλά διατήρησε υψηλή ακρίβεια ταξινόμησης.
- Το SVM παρουσίασε υψηλό σφάλμα εκπαίδευσης, υποδεικνύοντας δυσκολίες στο χειρισμό πολύπλοκων δεδομένων HAR.




- Το k-NN παρουσίασε αργή βελτίωση καθώς χρησιμοποιούνταν περισσότερα δεδομένα εκπαίδευσης, περιορίζοντας την ικανότητά του να γενικεύει αποτελεσματικά.
- Το Naïve Bayes είχε τη χειρότερη καμπύλη μάθησης, επιβεβαιώνοντας ότι δεν κατάφερε να γενικεύσει καλά.
- Το CNN απαιτούσε σημαντικά δεδομένα εκπαίδευσης για να επιτύχει τη βέλτιστη απόδοση, καθιστώντας το υπολογιστικά δαπανηρό.




Εικόνα 45: Learning Curve for Decision Tree Model




Εικόνα 46: Learning Curve for Random Forest Model




Εικόνα 47: Learning Curve for SVM Model



Εικόνα 48: Learning Curve for k-NN Model



Εικόνα 49: Learning Curve for Naive Bayes Model



Εικόνα 50: Learning Curve for CNN Model

6.1.6 Συγκριτική ανάλυση των επιδόσεων των μοντέλων του mHealth

Με βάση τα αποτελέσματα ταξινόμησης και τις οπτικοποιήσεις, **το μοντέλο Random Forest** υπερέχει σαφώς όλων των άλλων ταξινομητών όσον αφορά την ακρίβεια, την ακρίβεια, την ανάκληση και τη συνολική ικανότητα γενίκευσης. Τα μοντέλα Decision Tree και CNN είχαν καλές επιδόσεις, αλλά το Decision Tree υπέφερε από μια ελαφρά υπερπροσαρμογή και το CNN απαιτούσε εκτεταμένα δεδομένα εκπαίδευσης. Τα μοντέλα SVM και k-NN είχαν μέτριες επιδόσεις, αλλά δυσκολεύτηκαν με την επικάλυψη δραστηριοτήτων. Το μοντέλο Naïve Bayes είχε τη χαμηλότερη απόδοση, καθιστώντας το τη λιγότερο κατάλληλη επιλογή για την ταξινόμηση HAR.

6.1.7 Συζήτηση και συμπέρασμα σχετικά με το καλύτερο μοντέλο για το mHealth

Μετά την ανάλυση όλων των οπτικοποιήσεων και των μετρικών επιδόσεων, είναι προφανές ότι **ο ταξινομητής Random Forest** είναι το καλύτερο μοντέλο για το mHealth dataset. Πέτυχε σταθερά την υψηλότερη ακρίβεια, επέδειξε ισχυρή γενίκευση και διατήρησε χαμηλά



ποσοστά λανθασμένης ταξινόμησης σε όλες τις κατηγορίες δραστηριοτήτων. Το μοντέλο Decision Tree είχε επίσης καλές επιδόσεις, αλλά παρουσίασε μικρή υπερπροσαρμογή, ενώ το μοντέλο CNN ήταν υπολογιστικά δαπανηρό παρά την επίτευξη υψηλής ακρίβειας. Οι ταξινομητές SVM και k-NN είχαν μέτριες επιδόσεις, ενώ το μοντέλο Naïve Bayes είχε κακές επιδόσεις, καθιστώντας το τον λιγότερο αποτελεσματικό ταξινομητή.

Έτσι, για την Αναγνώριση Ανθρώπινης Δραστηριότητας (HAR) με τη χρήση δεδομένων φορέσιμων αισθητήρων από το mHealth dataset, το μοντέλο Random Forest είναι το πιο αξιόπιστο και αποτελεσματικό μοντέλο μηχανικής μάθησης, προσφέροντας υψηλή ακρίβεια ταξινόμησης, ισχυρή ικανότητα γενίκευσης και ελάχιστα σφάλματα λανθασμένης ταξινόμησης.

6.2 Οπτικοποίηση Αποτελεσμάτων για το WISDM


Η οπτικοποίηση των αποτελεσμάτων ταξινόμησης είναι απαραίτητη για την ερμηνεία της απόδοσης των μοντέλων μηχανικής μάθησης που εφαρμόζονται στο σύνολο δεδομένων mHealth. Η αξιολόγηση διεξήχθη με τη χρήση πολλαπλών γραφικών παραστάσεων, συμπεριλαμβανομένων των πινάκων σύγχυσης σε μορφή Heatmaps, των καμπυλών ακρίβειας-ανάκλησης (Precision – Recall), των καμπυλών ROC, των γραφικών παραστάσεων μετρήσεων απόδοσης και των καμπυλών μάθησης (Learning Curves). Αυτές οι απεικονίσεις παρέχουν κρίσιμες πληροφορίες σχετικά με το πόσο καλά απέδωσε κάθε ταξινομητής στην αναγνώριση ανθρώπινων δραστηριοτήτων με βάση τα δεδομένα φορητών αισθητήρων.

6.2.1 Heatmaps Πινάκων Σύγχυσης όλων των μοντέλων


Η οπτικοποίηση των αποτελεσμάτων ταξινόμησης για το σύνολο δεδομένων WISDM είναι απαραίτητη για την αξιολόγηση της απόδοσης των διαφόρων μοντέλων μηχανικής μάθησης. Διάφορα διαγράμματα, όπως πίνακες σύγχυσης (Heatmaps), καμπύλες ακρίβειας-ανάκλησης, καμπύλες ROC, μετρικές επιδόσεων και καμπύλες μάθησης, παρέχουν




πληροφορίες σχετικά με το πόσο καλά κάθε μοντέλο αναγνωρίζει τις ανθρώπινες δραστηριότητες με βάση τα δεδομένα φορητών αισθητήρων.




Εικόνα 51: Confusion Matrix Heatmap for Decision Tree Model




Εικόνα 52: Confusion Matrix Heatmap for Random Forest Model




Εικόνα 53: Confusion Matrix Heatmap for SVM Model



Εικόνα 54: Confusion Matrix Heatmap for k-NN Model



Εικόνα 55: Confusion Matrix Heatmap for Naive Bayes Model



Εικόνα 56: Confusion Matrix Heatmap for CNN Model

Οι πίνακες σύγχυσης σε μορφή θερμικού χάρτη αναπαριστούν οπτικά την ακρίβεια ταξινόμησης κάθε μοντέλου, δείχνοντας τις σωστές και τις λανθασμένες ταξινομημένες περιπτώσεις δραστηριοτήτων.

Ο ταξινομητής Δέντρου Αποφάσεων είχε καλή απόδοση, ταξινομώντας σωστά μεγάλο αριθμό περιπτώσεων. Ωστόσο, δυσκολεύτηκε με δραστηριότητες που είχαν επικαλυπτόμενα χαρακτηριστικά, όπως το περπάτημα και το τρέξιμο, οδηγώντας σε ορισμένες λανθασμένες ταξινομήσεις. Αυτό το ζήτημα είναι σύνηθες σε σύνολα δεδομένων HAR, όπου οι ομοιότητες κίνησης μπορεί να προκαλέσουν σύγχυση.

Ο ταξινομητής Random Forest αναδείχθηκε ως ο ταξινομητής με τις καλύτερες επιδόσεις, παρουσιάζοντας ελάχιστα σφάλματα ταξινόμησης. Ο πίνακας σύγχυσης του αναδεικνύει την ικανότητά του να διακρίνει μεταξύ διαφορετικών δραστηριοτήτων με μεγάλη ακρίβεια. Ο συνδυαστικός χαρακτήρας του Random Forest του επιτρέπει να καταγράφει πολύπλοκα μοτίβα πιο αποτελεσματικά από ό,τι ένα μεμονωμένο Δέντρο Αποφάσεων, με αποτέλεσμα τη βελτίωση της γενίκευσης.

Ο ταξινομητής SVM επέδειξε μέτρια απόδοση, παρουσιάζοντας σημαντικά σφάλματα ταξινόμησης για δραστηριότητες με υψηλή μεταβλητότητα. Ο πίνακας σύγχυσης δείχνει ότι το SVM δυσκολεύτηκε με δραστηριότητες που έχουν μη γραμμικά όρια απόφασης, καθιστώντας το λιγότερο αποτελεσματικό από τα μοντέλα που βασίζονται σε δέντρα.




Ο ταξινομητής k-NN παρουσίασε παρόμοιο επίπεδο επιδόσεων με τον SVM. Παρόλο που πέτυχε σχετικά υψηλή ακρίβεια, ο πίνακας σύγχυσης υποδηλώνει ότι αντιμετώπισε προκλήσεις κατά την ταξινόμηση δραστηριοτήτων με επικαλυπτόμενα χαρακτηριστικά κίνησης, ιδίως λόγω της εξάρτησής του από την ταξινόμηση με βάση την απόσταση.

Ο ταξινομητής Naïve Bayes παρήγαγε τα φτωχότερα αποτελέσματα ταξινόμησης, με υψηλό αριθμό λανθασμένων ταξινομημένων περιπτώσεων. Ο πίνακας σύγχυσής του αναδεικνύει την αδυναμία του να μοντελοποιήσει αποτελεσματικά πολύπλοκες κατανομές, ενισχύοντας την ιδιότητά του ως του λιγότερο κατάλληλου ταξινομητή για εφαρμογές HAR.


Το μοντέλο CNN, αν και υπολογιστικά δαπανηρό, παρείχε υψηλή ακρίβεια ταξινόμησης, όπως αντικατοπτρίζεται στον πίνακα σύγχυσης. Ωστόσο, παρουσίασε περιστασιακές λανθασμένες ταξινομήσεις σε δραστηριότητες με λεπτές μεταβολές της κίνησης. Τα CNN είναι γνωστά για τις ισχυρές ικανότητες εξαγωγής χαρακτηριστικών, οι οποίες συνέβαλαν στην ισχυρή απόδοσή τους.

6.2.2 Precision- Recall και ROC Curves όλων των μοντέλων


Οι καμπύλες Precision-Recall και ROC (Receiver Operating Characteristic) είναι κρίσιμες για την αξιολόγηση της αποτελεσματικότητας κάθε ταξινομητή στη διάκριση μεταξύ των κατηγοριών δραστηριότητας. Ενώ η καμπύλη Precision-Recall μετρά πόσο καλά το μοντέλο ελαχιστοποιεί τα ψευδώς θετικά αποτελέσματα, ενώ η καμπύλη ROC αξιολογεί το συμβιβασμό μεταξύ ευαισθησίας (Recall) και ειδικότητας (1 - False Positive Rate).




Εικόνα 57: Precision-Recall Curve and ROC Curve for Decision Tree Model




Εικόνα 58: Precision-Recall Curve and ROC Curve for Random Forest Model




Εικόνα 59: Precision-Recall Curve and ROC Curve for SVM Model



Εικόνα 60: Precision-Recall Curve and ROC Curve for k-NN Model



Εικόνα 61: Precision-Recall Curve and ROC Curve for Naive Bayes Model



Εικόνα 62: Precision-Recall Curve and ROC Curve for CNN Model

Το μοντέλο Δέντρου Αποφάσεων πέτυχε υψηλές τιμές AUC, υποδεικνύοντας ότι ήταν αποτελεσματικό στη διάκριση μεταξύ κλάσεων δραστηριοτήτων, αλλά υπέφερε από ελαφρά υπερπροσαρμογή.

Ο ταξινομητής Random Forest αποδείχθηκε και πάλι ο καλύτερος, επιτυγχάνοντας τις υψηλότερες τιμές AUC τόσο στις καμπύλες Precision-Recall όσο και στις καμπύλες ROC. Αυτό υποδηλώνει ότι ο Random Forest είχε τον καλύτερο συμβιβασμό μεταξύ των σωστά ταξινομημένων δραστηριοτήτων και της ελαχιστοποίησης των λανθασμένων ταξινομήσεων.



Ο ταξινομητής SVM εμφάνισε ασθενέστερες καμπύλες ROC και Precision-Recall σε σύγκριση με τα μοντέλα που βασίζονται σε δέντρα, ενισχύοντας τον αγώνα του με τα επικαλυπτόμενα μοτίβα δραστηριοτήτων.


Το μοντέλο k-NN είχε μέτρια απόδοση, με την καμπύλη ROC να αποκαλύπτει ότι ήταν λιγότερο αποτελεσματικό στη διάκριση μεταξύ ορισμένων δραστηριοτήτων σε σύγκριση με το Random Forest και το Decision Tree.

Το μοντέλο Naïve Bayes είχε τις πιο αδύναμες καμπύλες, επιβεβαιώνοντας ότι δεν ήταν κατάλληλο για την ταξινόμηση HAR λόγω της μη ρεαλιστικής παραδοχής ανεξαρτησίας των χαρακτηριστικών του.

Ο ταξινομητής CNN, αν και υπολογιστικά απαιτητικός, επέδειξε ισχυρή απόδοση τόσο στις καμπύλες Precision-Recall όσο και στις καμπύλες ROC, καθιστώντας το ένα από τα καλύτερα μοντέλα μαζί με το Random Forest.

6.2.3 Οπτικοποίηση της Απόδοσης των Μετρικών όλων των μοντέλων


Η οπτικοποίηση των μετρήσεων απόδοσης συγκρίνει την Ακρίβεια, την Ανάκληση και το F1-Score σε όλους τους ταξινομητές. Το μοντέλο Random Forest πέτυχε τις υψηλότερες τιμές σε όλες τις μετρικές, εδραιώνοντας περαιτέρω την ιδιότητά του ως ο πιο αξιόπιστος ταξινομητής. Τα μοντέλα Decision Tree και CNN είχαν καλές επιδόσεις, αλλά το Decision Tree παρουσίασε ελαφρά υπερπροσαρμογή και το CNN είχε υψηλό υπολογιστικό κόστος. Οι ταξινομητές SVM και k-NN είχαν μέτριες επιδόσεις, ενώ το μοντέλο Naïve Bayes είχε τις χειρότερες επιδόσεις, επιβεβαιώνοντας την αδυναμία του να χειριστεί αποτελεσματικά πολύπλοκα δεδομένα HAR.



Εικόνα 63: Metrics Values for all Models (Accuracy, Precision, Recall, F1Score)

6.2.4 Συγκριτική ανάλυση ROC Curve όλων των μοντέλων

Μια ενιαία καμπύλη ROC που συνέκρινε όλους τους ταξινομητές παρείχε μια σαφή απεικόνιση της ικανότητας ταξινόμησης κάθε μοντέλου. Το μοντέλο Random Forest είχε την καλύτερη καμπύλη ROC, υποδεικνύοντας ανώτερη απόδοση ταξινόμησης. Το μοντέλο Naïve Bayes είχε την ασθενέστερη καμπύλη ROC, επιβεβαιώνοντας την αδυναμία του να διαχωρίσει αποτελεσματικά τις κατηγορίες δραστηριοτήτων. Τα μοντέλα Decision Tree και CNN παρουσίασαν ανταγωνιστικές καμπύλες ROC, αλλά το CNN απαιτούσε σημαντικά περισσότερο χρόνο εκπαίδευσης.



Εικόνα 64: ROC Curve for all the 6 Models


6.2.5 Καμπύλες Εκμάθησης (Learning Curves) όλων των μοντέλων

Οι καμπύλες μάθησης για κάθε ταξινομητή παρέχουν πληροφορίες σχετικά με τις ικανότητες γενίκευσής τους:


- Το Random Forest είχε την πιο σταθερή καμπύλη μάθησης, επιδεικνύοντας σταθερή απόδοση με την αύξηση των δεδομένων εκπαίδευσης.
- Το Decision Tree παρουσίασε ελαφρά υπερπροσαρμογή, όπως αποδεικνύεται από τη μείωση του σφάλματος εκπαίδευσης με την πάροδο του χρόνου.
- Το SVM παρουσίασε υψηλό σφάλμα εκπαίδευσης, υποδεικνύοντας ότι δυσκολευόταν να χειριστεί αποτελεσματικά τα δεδομένα HAR.
- Το k-NN παρουσίασε αργή βελτίωση, αναδεικνύοντας την ευαισθησία του στο μέγεθος του συνόλου δεδομένων.
- Ο Naïve Bayes είχε τη χειρότερη καμπύλη μάθησης, επιβεβαιώνοντας ότι απέτυχε να γενικεύσει αποτελεσματικά.




- Το CNN απαιτούσε εκτεταμένα δεδομένα εκπαίδευσης, καθιστώντας το υπολογιστικά δαπανηρό παρά την υψηλή ακρίβειά του.




Εικόνα 65: Learning Curve for Decision Tree Model




Εικόνα 66: Learning Curve for Random Forest Model




Εικόνα 67: Learning Curve for SVM Model



Εικόνα 68: Learning Curve for k-NN Model



Εικόνα 69: Learning Curve for Naive Bayes Model



Εικόνα 70: Learning Curve for CNN Model



6.2.6 Συζήτηση και συμπέρασμα σχετικά με το καλύτερο μοντέλο για το mHealth

Μετά την ανάλυση των αποτελεσμάτων ταξινόμησης και των οπτικοποιήσεων, ο ταξινομητής Random Forest υπερείχε σταθερά έναντι όλων των άλλων μοντέλων. Πέτυχε την υψηλότερη ακρίβεια, ακρίβεια, ανάκληση και βαθμολογία F1, επιδεικνύοντας ισχυρή γενίκευση και χαμηλά ποσοστά λανθασμένης ταξινόμησης. Το μοντέλο Decision Tree είχε καλές επιδόσεις, αλλά υπέφερε από ελαφρά υπερπροσαρμογή. Το μοντέλο CNN είχε επίσης ισχυρές επιδόσεις, αλλά το υψηλό υπολογιστικό του κόστος το κατέστησε λιγότερο πρακτικό για εφαρμογές πραγματικού χρόνου. Οι ταξινομητές SVM και k-NN έδειξαν μέτριες επιδόσεις, αντιμετωπίζοντας προβλήματα με την επικάλυψη δραστηριοτήτων και την υπολογιστική απόδοση. Το μοντέλο Naïve Bayes είχε τη χειρότερη επίδοση, ενισχύοντας ότι η υπόθεση ανεξαρτησίας των χαρακτηριστικών του δεν ισχύει για σύνολα δεδομένων HAR.

Έτσι, για την Αναγνώριση Ανθρώπινης Δραστηριότητας (HAR) με χρήση δεδομένων φορητών αισθητήρων από το σύνολο δεδομένων WISDM, **το μοντέλο Random Forest** είναι το πιο αποτελεσματικό μοντέλο μηχανικής μάθησης, προσφέροντας τον καλύτερο συμβιβασμό μεταξύ ακρίβειας, υπολογιστικής απόδοσης και ικανότητας γενίκευσης.

6.3 Συγκριτική Ανάλυση των Επιδόσεων των Μοντέλων και για τα δύο Datasets

Σε αυτή την ενότητα, αναλύουμε και συγκρίνουμε τις επιδόσεις ταξινόμησης των έξι μοντέλων μηχανικής μάθησης στα σύνολα δεδομένων mHealth και WISDM, χρησιμοποιώντας heatmaps των μετρικών ταξινόμησης και ένα ραβδόγραμμα που συγκρίνει το χρόνο εκπαίδευσης μεταξύ των μοντέλων. Αυτές οι απεικονίσεις επιτρέπουν μια σε βάθος κατανόηση του τρόπου με τον οποίο τα μοντέλα αποδίδουν σε διαφορετικά σύνολα δεδομένων, αποκαλύπτοντας βασικές πληροφορίες σχετικά με τη γενικευσιμότητα και την αποτελεσματικότητά τους.



6.3.1 Heatmap των Μετρικών για το mHealth Dataset

Ο χάρτης θερμότητας για το σύνολο δεδομένων mHealth παρουσιάζει μια λεπτομερή επισκόπηση των τεσσάρων βασικών μετρικών ταξινόμησης - ακρίβεια, ακρίβεια, ανάκληση και βαθμολογία F1 - και για τα έξι μοντέλα μηχανικής μάθησης. Αυτή η απεικόνιση επιτρέπει την άμεση σύγκριση των επιδόσεων των ταξινομητών.


Το μοντέλο Random Forest ξεχωρίζει ως ο αλγόριθμος με τις καλύτερες επιδόσεις, επιτυγχάνοντας την υψηλότερη ακρίβεια, ακρίβεια, ανάκληση και F1-score μεταξύ όλων των μοντέλων. Αυτό ευθυγραμμίζεται με τα προηγούμενα ευρήματά μας, καθώς το Random Forest είναι ιδιαίτερα εύρωστο λόγω της προσέγγισης μάθησης συνόλου, η οποία μειώνει τη διακύμανση και την υπερπροσαρμογή, διατηρώντας παράλληλα υψηλή προβλεπτική ικανότητα.

Το μοντέλο Δέντρου Αποφάσεων ακολουθεί από κοντά, επιδεικνύοντας ισχυρή απόδοση ταξινόμησης. Ωστόσο, είναι ελαφρώς πιο επιρρεπές στην υπερπροσαρμογή σε σύγκριση με το Random Forest λόγω της δομής του με ένα δέντρο.

Το μοντέλο CNN παρουσιάζει επίσης υψηλές μετρικές ταξινόμησης, υπερέχοντας ιδιαίτερα στην καταγραφή σύνθετων μοτίβων δραστηριότητας. Ωστόσο, η απόδοσή του συνοδεύεται από υψηλό υπολογιστικό κόστος, απαιτώντας σημαντικό χρόνο εκπαίδευσης.

Τα μοντέλα SVM και k-NN εμφανίζουν μέτριες επιδόσεις, με το SVM να δυσκολεύεται με τις επικαλυπτόμενες κλάσεις δραστηριότητας και το k-NN να είναι υπολογιστικά ακριβό για μεγαλύτερα σύνολα δεδομένων.

Ο ταξινομητής Naïve Bayes παρουσιάζει σταθερά χαμηλότερες επιδόσεις, επιτυγχάνοντας τη χαμηλότερη ακρίβεια και βαθμολογία F1. Αυτό είναι αναμενόμενο, καθώς ο Naïve Bay υποθέτει την ανεξαρτησία των χαρακτηριστικών, η οποία δεν είναι ρεαλιστική στα σύνολα δεδομένων HAR, οδηγώντας σε υψηλά ποσοστά λανθασμένης ταξινόμησης.



Εικόνα 71: Heatmap Classification Metrics for all Model

6.3.2 Heatmap των Μετρικών για το WISDM Dataset

Ο θερμικός χάρτης για το σύνολο δεδομένων WISDM παρέχει μια παρόμοια σύγκριση της απόδοσης του μοντέλου χρησιμοποιώντας τις ίδιες τέσσερις μετρικές ταξινόμησης.

Σε σύγκριση με το σύνολο δεδομένων mHealth, το Random Forest παραμένει το μοντέλο με τις καλύτερες επιδόσεις, επιτυγχάνοντας την υψηλότερη ακρίβεια ταξινόμησης και ικανότητα γενίκευσης. Ωστόσο, το περιθώριο υπεροχής του είναι ελαφρώς μειωμένο, γεγονός που υποδηλώνει ότι τα χαρακτηριστικά του συνόλου δεδομένων επηρεάζουν την απόδοση ταξινόμησης.


Το CNN αποδίδει εξαιρετικά καλά στο σύνολο δεδομένων WISDM, παρουσιάζοντας ανταγωνιστικά αποτελέσματα κοντά στο Random Forest. Αυτό υποδηλώνει ότι το CNN επωφελείται από τη δομημένη φύση των δεδομένων αισθητήρων σε αυτό το σύνολο δεδομένων.

Το μοντέλο Decision Tree συνεχίζει να παρουσιάζει ισχυρά αποτελέσματα ταξινόμησης, αλλά παραμένει ελαφρώς λιγότερο γενικεύσιμο από το Random Forest.



Το SVM και το k-NN διατηρούν μέτριες επιδόσεις ταξινόμησης, με το k-NN να έχει σχετικά υψηλότερη βαθμολογία ανάκλησης σε σύγκριση με την ακρίβειά του, υποδεικνύοντας ότι καταγράφει περισσότερες θετικές περιπτώσεις, αλλά με κόστος τα αυξημένα ψευδώς θετικά αποτελέσματα.

Για άλλη μια φορά, το μοντέλο Naïve Bayes έχει τη χειρότερη επίδοση, επιβεβαιώνοντας ότι οι απλουστευτικές πιθανοτικές υποθέσεις του δεν ισχύουν καλά στην ταξινόμηση δεδομένων HAR.



Εικόνα 72: Heatmap Classification Metrics for all Models WISDM Dataset

6.3.3 Σύγκριση χρόνου εκπαίδευσης μοντέλου (Training Time Model) και για τα δύο Datasets

Το ραβδόγραμμα που συγκρίνει τους χρόνους εκπαίδευσης και για τα έξι μοντέλα και για τα δύο σύνολα δεδομένων παρέχει κρίσιμες πληροφορίες σχετικά με την υπολογιστική αποδοτικότητα.

Το μοντέλο CNN απαιτεί τον μεγαλύτερο χρόνο εκπαίδευσης με σημαντική διαφορά, ιδίως στο σύνολο δεδομένων WISDM. Αυτό είναι αναμενόμενο, καθώς τα μοντέλα βαθιάς



μάθησης απαιτούν εκτεταμένους υπολογιστικούς πόρους για την εκπαίδευση, γεγονός που τα καθιστά λιγότερο κατάλληλα για εφαρμογές πραγματικού χρόνου.


Το μοντέλο Random Forest, παρά το γεγονός ότι έχει την καλύτερη επίδοση όσον αφορά την ακρίβεια ταξινόμησης, έχει λογικό χρόνο εκπαίδευσης, καθιστώντας το εξαιρετική επιλογή για εφαρμογές HAR όπου τόσο η απόδοση όσο και η αποδοτικότητα είναι σημαντικές.

Ο ταξινομητής Δέντρου Αποφάσεων είναι ένα από τα ταχύτερα μοντέλα που εκπαιδεύονται, καθιστώντας το πρακτική επιλογή όταν απαιτείται ερμηνευσιμότητα και γρήγορη ανάπτυξη.

Ο k-NN, παρά το γεγονός ότι είναι ένας απλός αλγόριθμος, είναι υπολογιστικά δαπανηρός όταν εργάζεται με μεγαλύτερα σύνολα δεδομένων, επειδή βασίζεται σε υπολογισμούς απόστασης κατά την ταξινόμηση και όχι στην εκπαίδευση. Ωστόσο, ο χρόνος εκπαίδευσης του είναι σημαντικά χαμηλότερος για το WISDM σε σύγκριση με το mHealth, γεγονός που υποδεικνύει ότι το μέγεθος του συνόλου δεδομένων επηρεάζει την αποδοτικότητά του.

Το SVM παρουσιάζει μέτριο χρόνο εκπαίδευσης, αλλά η απόδοση ταξινόμησής του δεν δικαιολογεί το υπολογιστικό του κόστος, καθιστώντας το λιγότερο ευνοϊκή επιλογή σε σύγκριση με το Random Forest και το CNN.

Το Naïve Bayes, παρά το γεγονός ότι είναι το μοντέλο με τις χειρότερες επιδόσεις στην ταξινόμηση, είναι το ταχύτερο στην εκπαίδευση, αναδεικνύοντας την αποτελεσματικότητά του αλλά την έλλειψη προβλεπτικής ισχύος.



Εικόνα 73: Time Taken Comparison



6.4 Συμπέρασμα σχετικά με την απόδοση του μοντέλου και για τα δύο Datasets

Με βάση τις επιδόσεις ταξινόμησης και την υπολογιστική αποδοτικότητα, το μοντέλο Random Forest παραμένει ο καλύτερος συνολικός ταξινομητής και στα δύο σύνολα δεδομένων. Προσφέρει την καλύτερη ισορροπία μεταξύ υψηλής ακρίβειας και λογικού χρόνου εκπαίδευσης, καθιστώντας το καταλληλότερο μοντέλο μηχανικής μάθησης για εφαρμογές HAR.

Το μοντέλο CNN έχει ανταγωνιστικές επιδόσεις, ιδίως στο WISDM, αλλά το υψηλό υπολογιστικό του κόστος το καθιστά λιγότερο πρακτικό για εφαρμογές πραγματικού χρόνου. Το Decision Tree παραμένει μια ισχυρή εναλλακτική λύση, ιδίως για ερμηνεύσιμα μοντέλα που απαιτούν γρήγορη εκπαίδευση.

Από την άλλη πλευρά, τα SVM και k-NN παρέχουν μέτρια αποτελέσματα αλλά είναι λιγότερο βέλτιστα από το Random Forest, ενώ το Naïve Bayes κατατάσσεται σταθερά ως το πιο αδύναμο μοντέλο.

Αυτά τα ευρήματα επιβεβαιώνουν ότι το Random Forest είναι ο πιο αποτελεσματικός και ακριβής ταξινομητής για εργασίες HAR που χρησιμοποιούν δεδομένα φορητών αισθητήρων, καθιστώντας το τον καλύτερο υποψήφιο για ανάπτυξη στον πραγματικό κόσμο.



7. Συμπεράσματα

Συνοψίζοντας, η παρούσα διατριβή διερευνήσε την εφαρμογή αλγορίθμων μηχανικής μάθησης στην αναγνώριση ανθρώπινης δραστηριότητας (HAR) με τη χρήση δεδομένων αισθητήρων που φοριούνται. Μέσω της ανάλυσης των συνόλων δεδομένων MHEALTH και WISDM, χρησιμοποιήθηκαν διάφορες τεχνικές προεπεξεργασίας, εξαγωγής χαρακτηριστικών και ταξινόμησης για την αξιολόγηση της απόδοσης έξι διαφορετικών μοντέλων μηχανικής μάθησης.

Τα αποτελέσματα έδειξαν ότι οι ταξινομητές Random Forest και CNN ήταν οι πιο αποτελεσματικοί ταξινομητές, επιτυγχάνοντας υψηλή ακρίβεια και ισχυρή απόδοση και στα δύο σύνολα δεδομένων. Το Random Forest επέδειξε ισχυρές δυνατότητες ταξινόμησης λόγω της προσέγγισης μάθησης συνόλου, ενώ το CNN αξιοποίησε την εξαγωγή βαθιών χαρακτηριστικών για την καταγραφή σύνθετων μοτίβων δραστηριότητας. Αντίθετα, οι Naive Bayes και SVM παρουσίασαν συγκριτικά χαμηλότερη ακρίβεια ταξινόμησης, υποδεικνύοντας ότι μπορεί να μην είναι τόσο κατάλληλοι για εργασίες HAR με δεδομένα φορητών αισθητήρων.

Ένα βασικό συμπέρασμα από τη συγκριτική ανάλυση των δύο συνόλων δεδομένων ήταν ότι το σύνολο δεδομένων MHEALTH είχε γενικά μεγαλύτερη ακρίβεια ταξινόμησης από το WISDM, πιθανότατα λόγω των διαφορών στην τοποθέτηση των αισθητήρων και των πρωτοκόλλων συλλογής δεδομένων. Επιπλέον, οι τεχνικές οπτικοποίησης που χρησιμοποιήθηκαν, συμπεριλαμβανομένων των πινάκων σύγχυσης, των καμπυλών ROC, των καμπυλών ακρίβειας-ανάκλησης και των καμπυλών μάθησης, παρείχαν πολύτιμες πληροφορίες σχετικά με την απόδοση του μοντέλου και την αξιοπιστία της ταξινόμησης.

Συνολικά, αυτή η έρευνα υπογραμμίζει τη σημασία της επιλογής των κατάλληλων αλγορίθμων μηχανικής μάθησης για το HAR και δείχνει πώς η προεπεξεργασία δεδομένων και η εξαγωγή χαρακτηριστικών επηρεάζουν την απόδοση ταξινόμησης. Η μελέτη συμβάλλει στον αναπτυσσόμενο τομέα της HAR παρέχοντας μια συστηματική αξιολόγηση διαφορετικών ταξινομητών και τονίζοντας τη σημασία της επιλογής μοντέλου σε πραγματικές εφαρμογές. Η μελλοντική έρευνα θα μπορούσε να διερευνήσει υβριδικά μοντέλα που συνδυάζουν βαθιά μάθηση με παραδοσιακές τεχνικές μηχανικής μάθησης ή να



διερευνήσει υλοποιήσεις HAR σε πραγματικό χρόνο με χρήση ενσωματωμένων συστημάτων και τεχνολογιών υπολογισμού ακμών.

Η παρούσα μελέτη πέτυχε με επιτυχία τους στόχους της, προσφέροντας μια ολοκληρωμένη ανάλυση των μεθοδολογιών HAR και συμβάλλοντας στις συνεχιζόμενες προσπάθειες για τη βελτίωση της ταξινόμησης της ανθρώπινης δραστηριότητας μέσω της μηχανικής μάθησης και των τεχνολογιών φορητών αισθητήρων.



Βιβλιογραφία

- [1] M. Vrigkas, C. Nikou, and I. A. Kakadiaris, “A review of human activity recognition methods,” *Front. Robot. AI*, vol. 2, no. NOV, pp. 1–28, 2015, doi: 10.3389/frobt.2015.00028.
- [2] Deval Shah, “Human Activity Recognition (HAR): Fundamentals, Models, Datasets,” 2023. <https://www.v7labs.com/blog/human-activity-recognition> (accessed Mar. 27, 2023).
- [3] Hiral Atha, “Wearable Technology: Trendspotting Of This New Age Tech,” 2016. <https://www.moveoapps.com/blog/wearable-technology-trendspotting-of-this-new-age-tech/> (accessed Mar. 05, 2016).
- [4] P. P. Ariza-Colpas *et al.*, “Human Activity Recognition Data Analysis: History, Evolutions, and New Trends,” *Sensors*, vol. 22, no. 9, 2022, doi: 10.3390/s22093401.
- [5] F. Kulsoom, S. Narejo, Z. Mehmood, H. N. Chaudhry, A. Butt, and A. K. Bashir, *A review of machine learning-based human activity recognition for diverse applications*, vol. 34, no. 21. Springer London, 2022. doi: 10.1007/s00521-022-07665-9.
- [6] “Health and Fitness Apps: Workout Guide in the Palm.” <https://www.nickelfox.com/industries/healthtech/health-and-fitness-app-development/>
- [7] L. OZ, “Automatic Fall Detection Using Computer Vision,” 2022. <https://alwaysai.co/blog/automatic-fall-detection-using-computer-vision> (accessed Jun. 07, 2022).
- [8] T. Nguyen, “Human Activity Recognition: Everything You Should Know About,” 2024. <https://www.neurond.com/blog/human-activity-recognition>
- [9] K. Chhablani, “The Evolving Landscape of IoT: Smart Home Devices and Their Impact on Daily Life,” 2023. <https://medium.com/@kunalchhablani14/the-evolving-landscape-of-iot-smart-home-devices-and-their-impact-on-daily-life-9a7ce599d93b> (accessed Nov. 05, 2023).
- [10] SuzukiFortMotors, “Future of Self-Driving Cars,” 2024. <https://suzukifortmotors.com/staging/future-of-self-driving-cars/> (accessed Jan. 08,



- 2024).
- [11] M. Straczekiewicz, P. James, and J. P. Onnela, “A systematic review of smartphone-based human activity recognition methods for health research,” *npj Digit. Med.*, vol. 4, no. 1, pp. 1–15, 2021, doi: 10.1038/s41746-021-00514-4.
 - [12] S. Mekruksavanich and A. Jitpattanakul, “Device Position-Independent Human Activity Recognition with Wearable Sensors Using Deep Neural Networks,” *Appl. Sci.*, vol. 14, no. 5, 2024, doi: 10.3390/app14052107.
 - [13] P. H. N. Gonçalves, H. Bragança, and E. Souto, “Efficient Human Activity Recognition on Wearable Devices Using Knowledge Distillation Techniques,” *Electronics*, vol. 13, no. 18, p. 3612, 2024.
 - [14] “Wearable Technology Development Services.” <https://sirinsoftware.com/wearables-solutions>
 - [15] T. Stampfler, M. Elgendi, R. R. Fletcher, and C. Menon, “The use of deep learning for smartphone-based human activity recognition,” *Front. Public Heal.*, vol. 11, no. 7, 2023, doi: 10.3389/fpubh.2023.1086671.
 - [16] D. Sethi, S. Bharti, and C. Prakash, “A comprehensive survey on gait analysis: History, parameters, approaches, pose estimation, and future work,” *Artif. Intell. Med.*, vol. 129, no. May, p. 102314, 2022, doi: 10.1016/j.artmed.2022.102314.
 - [17] K. Yasar, “wearable technology DEFINITION.” <https://www.techtarget.com/searchmobilecomputing/definition/wearable-technology>
 - [18] V. Vijayan, J. Connolly, J. Condell, N. McKelvey, and P. Gardiner, “Review of wearable devices and data collection considerations for connected health,” *Sensors*, vol. 21, no. 16, pp. 1–31, 2021, doi: 10.3390/s21165589.
 - [19] “Accelerometer Guide.” https://www.phidgets.com/docs/Accelerometer_Guide
 - [20] C. C. Yang and Y. L. Hsu, “A review of accelerometry-based wearable motion detectors for physical activity monitoring,” *Sensors*, vol. 10, no. 8, pp. 7772–7788, 2010, doi: 10.3390/s100807772.
 - [21] J. Vitrià, J. Sanches, and M. Hernández, “Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics): Preface,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 6669 LNCS, no. June, 2011, doi: 10.1007/978-3-642-21257-4.



- [22] S. M. Ali *et al.*, “Wearable Accelerometer and Gyroscope Sensors for Estimating the Severity of Essential Tremor,” *IEEE J. Transl. Eng. Heal. Med.*, vol. 12, no. June 2023, pp. 194–203, 2024, doi: 10.1109/JTEHM.2023.3329344.
- [23] “Gyroscope Sensor Working and Its Applications.” <https://www.elprocus.com/gyroscope-sensor/>
- [24] “How Do Wearable Motion Sensors Work?,” 2024. <https://dorsavi.com/how-do-wearable-motion-sensors-work/>
- [25] D. Dias and J. P. S. Cunha, “Wearable health devices—vital sign monitoring, systems and technologies,” *Sensors (Switzerland)*, vol. 18, no. 8, 2018, doi: 10.3390/s18082414.
- [26] Z. Lv and Y. Li, “Wearable Sensors for Vital Signs Measurement: A Survey,” *J. Sens. Actuator Networks*, vol. 11, no. 1, 2022, doi: 10.3390/jsan11010019.
- [27] O. In, “COMMUNICATIONS IN UBIQUITOUS HEALTHCARE A Wireless Wearable ECG Sensor for Long-Term Applications,” *IEEE Commun. Mag.*, no. January, pp. 36–43, 2012.
- [28] “How can you collect data more efficiently with wearable technology?,” 2024. <https://www.linkedin.com/advice/3/youre-working-research-project-how-can-s0cfc>
- [29] J. Barzola-Monteses, R. Caicedo-Quiroz, F. Parrales-Bravo, A. Aroni-Mera, and J. Zambrano-Navarrete, “Data Collection Techniques in Wearable Devices for Patient Tracking in Medical Centers,” *Proc. LACCEI Int. Multi-conference Eng. Educ. Technol.*, pp. 1–6, 2024, doi: 10.18687/LACCEI2024.1.1.1655.
- [30] F. de Arriba-Pérez, M. Caeiro-Rodríguez, and J. M. Santos-Gago, “Collection and processing of data from wrist wearable devices in heterogeneous and multiple-user scenarios,” *Sensors (Switzerland)*, vol. 16, no. 9, 2016, doi: 10.3390/s16091538.
- [31] S. Qadir, N. S. Khan, G. Anjum, and N. Uddin, “A wearable sensors dataset for stress & boredom associated activity recognition,” *Data Br.*, vol. 54, p. 110550, 2024, doi: 10.1016/j.dib.2024.110550.
- [32] N. D. Robert Cronin Yung Peng, Rose Khavari and G. O. D. P. J. S. J. M. C. F. R. N. Kate Shannon ., “Wearable Sensors -Modalities, Challenges, and Prospects,” *Physiol. Behav.*, vol. 176, no. 1, pp. 139–148, 2016, doi: 10.1039/c7lc00914c.Wearable.
- [33] E. McAdams, C. Gehin, B. Massot, and J. McLaughlin, “The challenges facing wearable sensor systems,” *Stud. Health Technol. Inform.*, vol. 177, no. September,



- pp. 196–202, 2012, doi: 10.3233/978-1-61499-069-7-196.
- [34] S. Canali, V. Schiaffonati, and A. Aliverti, “Challenges and recommendations for wearable devices in digital health: Data quality, interoperability, health equity, fairness,” *PLOS Digit. Heal.*, vol. 1, no. 10, pp. 1–13, 2022, doi: 10.1371/journal.pdig.0000104.
- [35] I. Azodo, R. Williams, A. Sheikh, and K. Cresswell, “Opportunities and Challenges Surrounding the Use of Data from Wearable Sensor Devices in Health Care: Qualitative Interview Study,” *J. Med. Internet Res.*, vol. 22, no. 10, 2020, doi: 10.2196/19542.
- [36] U. Oleh, R. Obermaisser, and A. S. Ahammed, “A Review of Recent Techniques for Human Activity Recognition: Multimodality, Reinforcement Learning, and Language Models,” *Algorithms*, vol. 17, no. 10, 2024, doi: 10.3390/a17100434.
- [37] S. Gupta, “Deep learning based human activity recognition (HAR) using wearable sensor data,” *Int. J. Inf. Manag. Data Insights*, vol. 1, no. 2, p. 100046, 2021, doi: 10.1016/j.jjime.2021.100046.
- [38] M. Zago, A. F. R. Kleiner, and P. A. Federolf, “Editorial: Machine Learning Approaches to Human Movement Analysis,” *Front. Bioeng. Biotechnol.*, vol. 8, no. January, pp. 2020–2022, 2021, doi: 10.3389/fbioe.2020.638793.
- [39] G. Aquino, M. G. F. Costa, and C. F. F. Costa Filho, “Explaining One-Dimensional Convolutional Models in Human Activity Recognition and Biometric Identification Tasks,” *Sensors*, vol. 22, no. 15, 2022, doi: 10.3390/s22155644.
- [40] R. K. Athota and D. Sumathi, “Human activity recognition based on hybrid learning algorithm for wearable sensor data,” *Meas. Sensors*, vol. 24, no. July, p. 100512, 2022, doi: 10.1016/j.measen.2022.100512.
- [41] A. I. Alexan, A. R. Alexan, and S. Oniga, “Real-Time Machine Learning for Human Activities Recognition Based on Wrist-Worn Wearable Devices,” *Appl. Sci.*, vol. 14, no. 1, 2024, doi: 10.3390/app14010329.
- [42] S. K. Chaurasia and S. R. N. Reddy, “Ai assisted human activity recognition (HAR),” *Int. J. Eng. Adv. Technol.*, vol. 8, no. 6, pp. 2143–2148, 2019, doi: 10.35940/ijeat.F8575.088619.
- [43] V. G. Sánchez and N.-O. Skeie, “Decision Trees for Human Activity Recognition in Smart House Environments,” *Proc. 59th Conf. Simulation Model. (SIMS 59)*, 26-28



- Sept. 2018, *Oslo Metrop. Univ. Norw.*, vol. 153, no. May, pp. 222–229, 2018, doi: 10.3384/ecp18153222.
- [44] D. Sharma, U. Chauhan, and H. Khan, “International Journal of INTELLIGENT SYSTEMS AND APPLICATIONS IN ENGINEERING Human Activity Recognition using Extremely Fast Decision Tree Classifier,” *Orig. Res. Pap. Int. J. Intell. Syst. Appl. Eng. IJISAE*, vol. 2024, no. 16s, pp. 664–671, 2024, [Online]. Available: www.ijisae.org
- [45] Niklas Donges, “Random Forest: A Complete Guide for Machine Learning,” 2024. <https://builtin.com/data-science/random-forest-algorithm> (accessed Nov. 26, 2024).
- [46] D. Thakur and S. Biswas, “Guided regularized random forest feature selection for smartphone based human activity recognition,” *J. Ambient Intell. Humaniz. Comput.*, vol. 14, no. 7, pp. 9767–9779, 2023, doi: 10.1007/s12652-022-03862-5.
- [47] K. G. Manosha Chathuramali and R. Rodrigo, “Faster human activity recognition with SVM,” *Int. Conf. Adv. ICT Emerg. Reg. ICTer 2012 - Conf. Proc.*, no. September, pp. 197–203, 2012, doi: 10.1109/ICTer.2012.6421415.
- [48] D. Lamani *et al.*, “SVM directed machine learning classifier for human action recognition network,” *Sci. Rep.*, vol. 15, no. 1, pp. 1–18, 2025, doi: 10.1038/s41598-024-83529-7.
- [49] S. Mohsen, A. Elkaseer, and S. G. Scholz, *Human Activity Recognition Using K-Nearest Neighbor Machine Learning Algorithm*, vol. 262 SIST, no. November. Springer Singapore, 2022. doi: 10.1007/978-981-16-6128-0_29.
- [50] P. J. S. Ferreira, J. M. P. Cardoso, and J. Mendes-Moreira, “KNN prototyping schemes for embedded human activity recognition with online learning,” *Computers*, vol. 9, no. 4, pp. 1–20, 2020, doi: 10.3390/computers9040096.
- [51] “What are Naïve Bayes classifiers?” <https://www.ibm.com/think/topics/naive-bayes>
- [52] D. P. Ismi, S. Panchoo, and Murinto, “K-means clustering based filter feature selection on high dimensional data,” *Int. J. Adv. Intell. Informatics*, vol. 2, no. 1, pp. 38–45, 2016, doi: 10.26555/ijain.v2i1.54.
- [53] M. M. Islam, S. Nooruddin, F. Karray, and G. Muhammad, “Human activity recognition using tools of convolutional neural networks: A state of the art review, data sets, challenges, and future prospects,” *Comput. Biol. Med.*, vol. 149, no. September, p. 106060, 2022, doi: 10.1016/j.combiomed.2022.106060.



- [54] C. Xu, D. Chai, J. He, X. Zhang, and S. Duan, “InnoHAR: A deep neural network for complex human activity recognition,” *IEEE Access*, vol. 7, no. January, pp. 9893–9902, 2019, doi: 10.1109/ACCESS.2018.2890675.
- [55] M. R. Azhar, “Training CNN on Signal Data for Human Activity Recognition,” 2023. <https://medium.com/@rehanmb1/training-cnn-on-signal-data-for-human-activity-recognition-ca1eaddeac8f> (accessed Oct. 21, 2023).
- [56] E. Abdellatef, R. M. Al-Makhlasy, and W. A. Shalaby, “Detection of human activities using multi-layer convolutional neural network,” *Sci. Rep.*, vol. 15, no. 1, 2025, doi: 10.1038/s41598-025-90307-6.
- [57] “Understanding the 8 Best Cross-Validation Techniques that Elevate Your Data Analysis,” 2023. <https://www.bigdatalearning.com/blog/8-best-cross-validation-techniques> (accessed Nov. 30, 2023).
- [58] H. Bragança, J. G. Colonna, H. A. B. F. Oliveira, and E. Souto, “How Validation Methodology Influences Human Activity Recognition Mobile Systems,” *Sensors*, vol. 22, no. 6, 2022, doi: 10.3390/s22062360.
- [59] S. U. Rehman, A. Ali, A. M. Khan, and C. Okpala, “Human Activity Recognition: A Comparative Study of Validation Methods and Impact of Feature Extraction in Wearable Sensors,” *Algorithms*, vol. 17, no. 12, 2024, doi: 10.3390/a17120556.
- [60] A. Dehghani, T. Glatard, and E. Shihab, “Subject Cross Validation in Human Activity Recognition,” 2019, [Online]. Available: <http://arxiv.org/abs/1904.02666>
- [61] Drew Banks, “Decoding Human Activity Recognition (HAR): Exploring Fundamentals, Models, and Datasets,” 2022. <https://www.data-labelify.com/en/human-activity-recognition-har/> (accessed Jun. 19, 2022).
- [62] Z. Fu, X. He, E. Wang, J. Huo, J. Huang, and D. Wu, “Personalized human activity recognition based on integrated wearable sensor and transfer learning,” *Sensors (Switzerland)*, vol. 21, no. 3, pp. 1–23, 2021, doi: 10.3390/s21030885.
- [63] D.-A. Nguyen and N.-A. Le-Khac, “SoK: Behind the Accuracy of Complex Human Activity Recognition Using Deep Learning,” pp. 1–8, 2024, doi: 10.1109/ijcnn60899.2024.10650322.
- [64] P. Gao, “Development of YOLO-based Model for Fall Detection in IoT Smart Home Applications,” *Int. J. Adv. Comput. Sci. Appl.*, vol. 14, no. 10, pp. 1118–1125, 2023,



doi: 10.14569/IJACSA.2023.01410117.

- [65] B. A. Mohammed Hashim and R. Amutha, “Human activity recognition based on smartphone using fast feature dimensionality reduction technique,” *J. Ambient Intell. Humaniz. Comput.*, vol. 12, no. 2, pp. 2365–2374, 2021, doi: 10.1007/s12652-020-02351-x.
- [66] L. Trivedi and R. Vij, “Performance of different machine learning methods on activity recognition and pose estimation datasets”.
- [67] H. Smolic, “Precision Versus Recall — Essential Metrics in Machine Learning,” 2022. <https://medium.com/geekculture/precision-versus-recall-essential-metrics-in-machine-learning-8b0d66dd5cff> (accessed Sep. 17, 2022).
- [68] L. Team, “Precision and Recall,” 2024. <https://www.lyzr.ai/glossaries/precision-and-recall/> (accessed Nov. 25, 2024).
- [69] P. J. Wolf, “Understanding and Applying the F1 Score,” 2024. <https://www.linkedin.com/pulse/understanding-applying-f1-score-dr-patrick-j-wolf-ye7nc/> (accessed Mar. 28, 2024).
- [70] C. Fan and F. Gao, “A New Approach for Smoking Event Detection Using a Variational Autoencoder and Neural Decision Forest,” *IEEE Access*, vol. 8, pp. 120835–120849, 2020, doi: 10.1109/ACCESS.2020.3006163.
- [71] H. Cho and S. M. Yoon, “Divide and conquer-based 1D CNN human activity recognition using test data sharpening,” *Sensors (Switzerland)*, vol. 18, no. 4, pp. 1–24, 2018, doi: 10.3390/s18041055.
- [72] N. A. Choudhury and B. Soni, “In-depth analysis of design & development for sensor-based human activity recognition system,” *Multimed. Tools Appl.*, vol. 83, no. 29, pp. 73233–73272, 2024, doi: 10.1007/s11042-023-16423-5.
- [73] M. A. Kutlay and S. Gagula-Palalic, “Application Of Machine Learning In Healthcare: Analysis On MHEALTH Dataset,” *Southeast Eur. J. Soft Comput.*, vol. 4, no. 2, 2016, doi: 10.21533/scjournal.v4i2.97.
- [74] “MHEALTH DATASET,” 2014. <https://archive.ics.uci.edu/dataset/319/mhealth+dataset>
- [75] M. H. Khan, H. Shafiq, M. S. Farid, and M. Grzegorzec, “Encoding human activities using multimodal wearable sensory data,” *Expert Syst. Appl.*, vol. 261, no. March 2024, p. 125564, 2025, doi: 10.1016/j.eswa.2024.125564.



- [76] M. Heydarian and T. E. Doyle, “rWISDM: Repaired WISDM, a Public Dataset for Human Activity Recognition,” pp. 1–13, 2023, [Online]. Available: <http://arxiv.org/abs/2305.10222>
- [77] G. M. Weiss, “WISDM Smartphone and Smartwatch Activity and Biometrics Dataset,” *UCI Mach. Learn. Repos. WISDM Smartphone Smartwatch Act. Biometrics Dataset Data Set*, vol. 7, pp. 133190–133202, 2019, [Online]. Available: <https://archive.ics.uci.edu/ml/machine-learning-databases/00507/WISDM-dataset-description.pdf>
- [78] “WISDM: WiReless Sensor Data Mining,” 2012. <https://www.cis.fordham.edu/wisdm/dataset.php>
- [79] X. Zheng, M. Wang, and J. Ordieres-Meré, “Comparison of data preprocessing approaches for applying deep learning to human activity recognition in the context of industry 4.0,” *Sensors (Switzerland)*, vol. 18, no. 7, 2018, doi: 10.3390/s18072146.
- [80] A. Vaughn, P. Biocco, Y. Liu, and M. Anwar, “Activity detection and analysis using smartphone sensors,” *Proc. - 2018 IEEE 19th Int. Conf. Inf. Reuse Integr. Data Sci. IRI 2018*, no. July, pp. 102–107, 2018, doi: 10.1109/IRI.2018.00022.
- [81] S. Karim, S. M. A. Burney, and N. Mahmood, “An Analysis of Human Activities Recognition using Smartwatches Dataset,” *Int. J. Adv. Comput. Sci. Appl.*, vol. 11, no. 12, pp. 334–339, 2020, doi: 10.14569/IJACSA.2020.0111241.
- [82] A. G. Fataniya and H. P. Modi, “Comprehensive Analysis of Deep Learning-based Human Activity Recognition approaches based on Accuracy,” *Int. J. Comput. Digit. Syst.*, vol. 12, no. 4, pp. 1097–1118, 2022, doi: 10.12785/ijcds/120188.
- [83] . H., “Comprehensive Analysis of Data Mining Classifiers Using Weka,” *Int. J. Adv. Res. Comput. Sci.*, vol. 9, no. 2, pp. 718–723, 2018, doi: 10.26483/ijarcs.v9i2.5900.
- [84] C. Knorowski, “A Guide to Time-Series Sensor Data Classification Using UCI HAR Data,” 20225. <https://medium.com/towards-data-science/a-guide-to-time-series-sensor-data-classification-using-uci-har-data-b7ac4f6ad251> (accessed Jan. 27, 2025).
- [85] P. Chanda *et al.*, “Decision Tree Classifiers for Incident Call Data Sets Plagiarism Declaration,” *J. Chem. Inf. Model.*, vol. 53, no. July, pp. 1–82, 2014, doi: 10.13140/RG.2.2.34230.86082.





Εικόνα 1: Η εξέλιξη της HAR στον χρόνο (2008-2020)

Εικόνα 2: Εξατομικευμένη Παρακολούθηση της Υγείας

<https://www.frontiersin.org/journals/robotics-and-ai/articles/10.3389/frobt.2015.00028/full>

Εικόνα 3: Παρακολούθηση Φυσικής Κατάστασης

<https://www.nickelfox.com/industries/healthtech/health-and-fitness-app-development/>

Εικόνα 4: Ανίχνευση Πτώσης <https://alwaysai.co/blog/automatic-fall-detection-using-computer-vision>

Εικόνα 5: Αλληλεπίδραση Ανθρώπου - Υπολογιστή (HCI)

Εικόνα 6: Ανάλυση Αθλητικών Επιδόσεων <https://www.tes.com/teaching-resource/ocr-cambridge-technicals-level-3-unit-5-performance-analysis-in-sport-and-exercise-12466364>

Εικόνα 7: Ψυχολογία και Τηλεϊατρική <https://psychedtraining.com.au/technology-transforms-psychological-assessments-a-modern-guide/>

Εικόνα 8: Παιχνίδια – Gaming

Εικόνα 9: Internet of Things (IoT) <https://medium.com/@kunalchhablani14/the-evolving-landscape-of-iot-smart-home-devices-and-their-impact-on-daily-life-9a7ce599d93b>

Εικόνα 10: Self- Driving Αυτοκίνητα <https://suzukifortmotors.com/staging/future-of-self-driving-cars/>

Εικόνα 11: Οι Αισθητήρες του HAR

https://www.researchgate.net/publication/368635925_Human_Activity_Recognition_Data_Analysis_History_Evolutions_and_New_Trends

Εικόνα 12: Συσκευές της HAR



Εικόνα 13: Ταξινόμηση των Φορητών Αισθητήρων για την Παρακολούθηση Δραστηριοτήτων

https://www.sciencedirect.com/science/article/pii/S0933365722000793?ref=cra_js_challenge&fr=RR-1

Εικόνα 14: Άξονες Επιταχυνσιόμετρων

https://www.phidgets.com/docs/Accelerometer_Guide

Εικόνα 15: Γυροσκόπιο <https://www.elprocus.com/gyroscope-sensor/>

Εικόνα 16: Holter Monitor με ECG καταγραφή

<https://www.hopkinsmedicine.org/health/treatment-tests-and-therapies/holter-monitor>

Εικόνα 17: Φορητές συσκευές και οι θέσεις τους στο ανθρώπινο σώμα

https://www.researchgate.net/publication/354016694_Review_of_Wearable_Devices_and_Data_Collection_Considerations_for_Connected_Health

Εικόνα 18: Προκλήσεις Φορέσιμων Αισθητήρων

<https://www.sciencedirect.com/science/article/pii/S002192902300283X>

Εικόνα 19: Διάγραμμα PRISMA

Εικόνα 20: Statical ML https://esupervs.click/product_tag/94722429_.html

Εικόνα 21: Supervised / Unsupervised <https://lawtomated.com/supervised-vs-unsupervised-learning-which-is-better/>

Εικόνα 22: DS <https://www.explorium.ai/machine-learning/the-complete-guide-to-decision-trees/>

Εικόνα 23: RF <https://www.sciencedirect.com/science/article/abs/pii/S095741742402431X>

Εικόνα 24: SVM <https://www.kdnuggets.com/2023/07/gentle-introduction-support-vector-machines.html>

Εικόνα 25: KNN <https://www.tpointtech.com/k-nearest-neighbor-algorithm-for-machine-learning>

Εικόνα 26: NB <https://databasecamp.de/en/ml/naive-bayes-algorithm>



Εικόνα 27: CNN

https://doc.comsol.com/6.2/doc/com.comsol.help.comsol/comsol_ref_definitions.19.050.html

Εικόνα 28: K fold CV <https://www.mdpi.com/1424-8220/23/1/125>

Εικόνα 29: Confusion matrix <https://encord.com/glossary/confusion-matrix/>