

# **Ανοικτό Πανεπιστήμιο Κύπρου**

**Σχολή Θετικών και Εφαρμοσμένων Επιστημών**

**Μεταπτυχιακό Πρόγραμμα Σπουδών**

***Εφαρμοσμένη Πληροφορική της Υγείας & Τηλεϊατρική***

## **Μεταπτυχιακή Διατριβή**



**Αναγνώριση Δραστηριοτήτων Ηλικιωμένων Ανθρώπων  
με τη Βοήθεια Φορετών Αισθητήρων Χωρίς Μπαταρίες**

**Ανδρέας Δράκος**

**Επιβλέπων Καθηγητής**

**Θεοδόσιος Γούδας**

**Νοέμβριος 2019**

# **Ανοικτό Πανεπιστήμιο Κύπρου**

**Σχολή Θετικών και Εφαρμοσμένων Επιστημών**

**Μεταπτυχιακό Πρόγραμμα Σπουδών**

***Εφαρμοσμένη Πληροφορική της Υγείας & Τηλεϊατρική***

## **Μεταπτυχιακή Διατριβή**

**Αναγνώριση Δραστηριοτήτων Ηλικιωμένων Ανθρώπων  
με τη Βοήθεια Φορετών Αισθητήρων Χωρίς Μπαταρίες**

**Ανδρέας Δράκος**

**Επιβλέπων Καθηγητής  
Θεοδόσιος Γούδας**

Η παρούσα μεταπτυχιακή διατριβή υποβλήθηκε προς μερική εκπλήρωση των απαιτήσεων για απόκτηση μεταπτυχιακού τίτλου σπουδών στο Μ.Π.Σ. "Εφαρμοσμένη Πληροφορική της Υγείας & Τηλεϊατρική" από τη Σχολή Θετικών και Εφαρμοσμένων Επιστημών του Ανοικτού Πανεπιστημίου Κύπρου.

**Νοέμβριος 2019**

ΛΕΥΚΗ ΣΕΛΙΔΑ

## Περίληψη

Η νοσηλεία ηλικιωμένων χωρίς παρακολούθηση προκαλεί πτώσεις ασθενών, οι οποίες θεωρούνται βασική αιτία σοβαρών τραυματισμών. Εκτός από τους σωματικούς τραυματισμούς, έχουν επίσης ψυχολογικές συνέπειες, καθώς επίσης συνδέονται και με ιατρικές δαπάνες. Η επιτήρηση, με φυσική παρουσία ανθρώπων, που είναι η κύρια λύση για την αποφυγή πτώσεων, είναι δαπανηρή. Για το λόγο αυτό, πολλές προσπάθειες ερευνητών, με διάφορες τεχνολογικές λύσεις, επικεντρώθηκαν στον τομέα της ανίχνευσης και πρόληψης πτώσης. Παραδείγματα τέτοιων τεχνολογικών λύσεων αφορούν μια ποικιλία αισθητήρων που συνδέονται με το σώμα, το κρεβάτι ή το πάτωμα. Αυτή η διπλωματική διατριβή βασίστηκε στη χρήση ασύρματου, φορετού, χωρίς μπαταρίες, χαμηλής ισχύος και χαμηλού κόστους αισθητήρα (Wearable Wireless Identification and Sensing Platform, W<sup>2</sup>ISP). Τα σύνολα δεδομένων για την ερμηνεία, προκειμένου να αναγνωριστούν οι διάφορες δραστηριότητες, παράχθηκαν από ένα τρισδιάστατο επιταχυνσιόμετρο και τη μεταδιδόμενη ισχύ σήματος από το W<sup>2</sup>ISP. Τα δεδομένα επίσης αφορούσαν υγιείς ηλικιωμένους που φορούσαν το W<sup>2</sup>ISP, εφαρμοσμένο στα ρούχα τους, στο επίπεδο του στέρνου, αναλαμβάνοντας μια σειρά δραστηριοτήτων σε δύο κλινικές αίθουσες. Σε αυτή τη μεταπτυχιακή διατριβή, για την αξιολόγηση της προσέγγισής μας και την επιτυχή διάκριση της αναγνώρισης των δραστηριοτήτων, παρουσιάζεται μια σύγκριση επιδόσεων μεταξύ μερικών από τους πιο δημοφιλείς αλγόριθμους εποπτευόμενης μηχανικής μάθησης που χρησιμοποιήθηκαν σε συστήματα ανίχνευσης πτώσης. Αυτοί είναι οι: Random Forest (RF), Support Vector Machine (SVM), K nearest neighbor (k-NN) και neural network MultiLayer Perceptron (MLP). Για την ταξινόμηση δεδομένων χρησιμοποιήθηκε η μέθοδος αξιολόγησης k-fold cross validation με 10 folds. Χρησιμοποιήθηκαν διαφορετικές στατιστικές μετρήσεις για την αξιολόγηση των παραγόμενων μοντέλων, όπως η ακρίβεια, η ανάκληση, η F-measure και η Kappa Statistic. Τα ευρήματα δείχνουν ότι τα καλύτερα αποτελέσματα προέρχονται από τον αλγόριθμο RF. Το μοντέλο πέτυχε αποτελέσματα ακρίβειας (precision) πάνω από 98% (Room 1) και 93% (Room 2), η ανάκληση (Recall) ήταν > 96,5% και 90,9% αντίστοιχα, ενώ η F-measure ήταν >

97% και 91,9% αντίστοιχα. Τα υψηλά αποτελέσματα επιβεβαιώνουν την εγκυρότητα της προσέγγισής μας και η απόδοση της ξεπερνά τις προηγούμενες παρόμοιες μελέτες.

## Summary

Getting out of bed and ambulating without supervision in hospitals causes patient falls, which are considered as a basic cause of serious injuries among older adults. In addition to physically injuries, they also have psychological consequences, as well as being linked to an amount of medical expenses. The surveillance, with physical presence of people, which is the main solution to avoid falls, is costly. For this reason, many efforts of researchers with various technological solutions have focused on the field of fall detection and prevention. Examples of technology solutions relate to a variety of sensors that are connected to the body, the bed or the floor. This thesis was based on the use of a wireless, wearable, batteryless, low-power and low-cost sensor (Wearable Wireless Identification and Sensing Platform, W<sup>2</sup>ISP). The datasets for interpreting, in order to identify bed exit events, were produced from a three dimensional accelerometer and the transmitted signal strength from the W<sup>2</sup>ISP. The data also, concerned 14 healthy olders (66-86 years old) who wore the W<sup>2</sup>ISP, attached over their clothes, at sternum level and undertook a number of activities in two clinical rooms. In this thesis, for evaluating our approach and successfully distinguish activity recognition, presents an performance comparison between some the most popular supervised machine learning algorithms which have been used in fall detection systems. These are Random Forest (RF), Support Vector Machine (SVM), K nearest neighbor (k-NN) and neural network MultiLayer Perceptron (MLP). A 10-fold cross-validation evaluation method was used in data classification. Different statistical measures used, for evaluating the models which produced, such as precision, recall, F- measure and Kappa Statistic. The findings show that the best results are derived from the RF algorithm. The model succeeded Precision results above 98% (Room 1) and 93% (Room 2), the Recall was > 96,5% and 90,9% respectively, while F-score was > 97% and 91,9% respectively. The high results confirm the validity of our approach and the performance outperforms between previous similar studies.

## Περιεχόμενα

<b>1. Εισαγωγή</b> .....	<b>1</b>
<b>2. Βιβλιογραφική Επισκόπηση</b> .....	<b>6</b>
<b>3. Εργαλεία και μέθοδοι</b> .....	<b>10</b>
3.1 Συμμετέχοντες και τοποθεσία.....	10
3.2 Τεχνολογία.....	11
3.3 Περιγραφή Συνόλων Δεδομένων.....	12
3.4 Εργαλείο WEKA.....	14
3.5 Ταξινομητές (Classifiers).....	15
3.6 Μέθοδος k-fold cross-validation.....	20
3.7 Αξιολόγηση μετρήσεων.....	21
3.8 Επιλογή χαρακτηριστικών.....	25
3.9 Τεχνικές βελτίωσης της απόδοσης σε ταξινομητές που εφαρμόζονται σε μη ισορροπημένα δεδομένα.....	29
3.10 Διάγραμμα ροής του μοντέλου αναγνώρισης δραστηριοτήτων.....	31
<b>4. Αποτελέσματα πειραμάτων</b> .....	<b>32</b>
4.1 Παραμετροποίηση αλγορίθμων στο WEKA.....	32
4.2 Αποτελέσματα μετρήσεων των αλγορίθμων με χρήση διαφορετικού πλήθους χαρακτηριστικά.....	33
4.3 Αποτελέσματα μετρήσεων των αλγορίθμων χωρίς το χαρακτηριστικό του χρόνου.....	44
4.4 Αποτελέσματα μετρήσεων των αλγορίθμων με χρήση των τεχνικών SMOTE και Cost-sensitive.....	49
4.5 Σύγκριση αποτελεσμάτων.....	57
<b>5. Συμπεράσματα</b> .....	<b>59</b>
<b>6. Επίλογος</b> .....	<b>62</b>
<b>Βιβλιογραφία</b> .....	<b>64</b>

# 1. Εισαγωγή

Το προσδόκιμο της ζωής σε παγκόσμιο επίπεδο αυξάνεται συνεχώς και προβλέψεις αναφέρουν ότι ο πληθυσμός των ανθρώπων που θα ξεπερνούν τα 60 έτη ηλικίας το 2050 θα είναι περίπου 2 δισεκατομμύρια. Επομένως είναι επιτακτικό να ενταθούν οι προσπάθειες που ήδη γίνονται για την καλύτερη αντιμετώπιση, τόσο σε ποιοτικό όσο και οικονομικό επίπεδο, των προβλημάτων που σχετίζονται με τη γήρανση. Ένα από αυτά τα προβλήματα είναι ο κίνδυνος πτώσης των ηλικιωμένων στα δωμάτια των νοσοκομείων (Chesser et al. 2019).

Οι πτώσεις των ηλικιωμένων μέσα στα νοσοκομεία, ύστερα από έρευνες που έχουν διεξαχθεί, καταλήγουν σε ένα μεγάλο ποσοστό τραυματισμών, αποτελώντας ταυτόχρονα και ένα επιπλέον δαπανηρό γεγονός (Shinmoto Torres et al. 2017B). Εκτός από τον τραυματισμό και την πρόσθετη οικονομική επιβάρυνση για την αποκατάσταση, επηρεάζεται επιπλέον η ανεξαρτησία και η αυτοπεποίθηση του ασθενή, αφού προκαλούνται ψυχολογικά τραύματα όπως ο φόβος, η απώλεια εμπιστοσύνης, το άγχος κ.α. (Shinmoto Torres et al. 2017A).

Βασικός σκοπός ενός συστήματος υγείας είναι η ποιοτική παροχή φροντίδας στον ασθενή μέσα σε ένα οικονομικά βιώσιμο περιβάλλον. Για τον λόγο αυτό αναπτύχθηκαν διάφοροι μέθοδοι αναγνώρισης ανθρώπινης δραστηριότητας που αποσκοπούν στη μείωση του κινδύνου πτώσης των ηλικιωμένων, ενημερώνοντας το νοσηλευτικό προσωπικό (Ranasinghe et al. 2014).

Η ανάπτυξη μεθόδων αναγνώρισης ανθρώπινης δραστηριότητας με ακρίβεια είναι ένας τομέας μελέτης με διαρκή εξέλιξη. Η ακριβής, έγκαιρη και έγκυρη αναγνώριση σε πραγματικό χρόνο, συμβάλλει σημαντικά στην ελαχιστοποίηση ενός τέτοιου περιστατικού να λάβει μεγαλύτερες διαστάσεις (Shinmoto Torres et al. 2013B).



Τα πρότυπα που εφαρμόζονται, για την κατηγορία των ασθενών που κινδυνεύουν να πέσουν μέσα στα νοσοκομεία, ώστε να παρέχουν έγκαιρες προειδοποιήσεις στο ιατρικό και νοσηλευτικό προσωπικό για να τους προσφέρουν βοήθεια, περιλαμβάνουν διάφορες μεθόδους, όπως χρήση ασφαλών υποδημάτων, αναθεώρηση των φαρμάκων ή χρήση συστημάτων συναγερμού για την έξοδο από το κρεβάτι και την καρέκλα (Shinmoto Torres et al. 2017A).

Στην παρούσα μεταπτυχιακή διατριβή θα επικεντρωθούμε στα συστήματα συναγερμού για έξοδο από το κρεβάτι μέσω της αναγνώρισης των δραστηριοτήτων των ασθενών. Έρευνες που έχουν πραγματοποιηθεί για πρόληψη πτώσης κάνοντας χρήση αισθητήρων πίεσης σε κρεβάτια και καρέκλες, δεν έχουν αναφέρει μείωση του ρυθμού πτώσης, λόγω εμφάνισης μεγάλου βαθμού ψευδών συναγερμών. Επιπλέον οι αισθητήρες πίεσης απαιτούν συνεχή συντήρηση όπως καθαρισμό και απολύμανση, καθώς έρχονται σε επαφή με τα σωματικά υγρά των ασθενών και έτσι επιβαρύνεται ο εργασιακός φόρτος των νοσηλευτών. Παράγουν επίσης ηχητικούς συναγερμούς διαταράσσοντας την ηρεμία των ασθενών (Shinmoto Torres et al. 2017A).

Μελέτες επίσης που έχουν χρησιμοποιήσει βίντεο για την πρόληψη πτώσεων, έχουν δείξει την εκδήλωση ανησυχιών για την προστασία της ιδιωτικής ζωής των ασθενών (Shinmoto Torres et al. 2017A).

Η πλειονότητα των μελετών που έχουν γίνει για τα προαναφερθέντα συστήματα, βασίζονται σε πολλαπλούς φορετούς αισθητήρες, ογκώδες σε ορισμένες περιπτώσεις λόγω της μπαταρίας τους, που φοριούνται σε διάφορα σημεία του σώματος των ασθενών (Wickramasinghe et al. 2015B). Οι αισθητήρες, ανιχνεύουν την κίνηση, παρέχοντας παρακολούθηση των ασθενών, καθώς συλλέγονται συνεχώς δεδομένα κίνησης και αναλύονται σε πραγματικό χρόνο (Shinmoto Torres et al. 2017B).

Σε μελέτες αποδοχής από τους χρήστες που έχουν πραγματοποιηθεί, η διακριτικότητα επισημαίνεται ως ένα από τα βασικά κριτήρια αποδοχής, γεγονός που καταρρίπτει άμεσα την χρήση τέτοιων συστημάτων, λόγω των μεγάλων μπαταριών σε μέγεθος (Wickramasinghe et al. 2015B). Επιπλέον, οι αισθητήρες μπαταριών απαιτούν

επαναφόρτιση ή αλλαγή τους, αυξάνοντας το φόρτο εργασίας του νοσηλευτικού προσωπικού καθώς η διάρκεια παραμονής ορισμένων ασθενών μπορεί να διαρκέσει αρκετές εβδομάδες (Shinmoto Torres et al. 2017B).

Η συλλογή πληροφοριών ανθρώπινης κίνησης πραγματοποιούνταν με την τροφοδοσία ενός παραδοσιακού αισθητήρα MEMS (Micro-Electro-Mechanical Systems). Το γεγονός όμως της αντιστοίχισης της δραστηριότητας των ασθενών με τον τομέα των συχνοτήτων, που βρέθηκε ότι κυμαίνεται σε πολύ χαμηλές συχνότητες της τάξεως των 4 Hz και ίσως και μικρότερες, πρόσφερε τη δυνατότητα της χρήσης πληροφοριών επιτάχυνσης πολύ χαμηλής ανάλυσης χωρίς την ανάγκη ενός MEMS. Έτσι αναπτύχθηκε η παθητική μέθοδος ανίχνευσης RF (ραδιοσυχνοτήτων) με τεχνολογία RFID χωρίς μπαταρίες και με δυνατότητα εύκολης προσαρμογής σε νοσοκομειακά ρούχα (Chesser et al. 2019).

Οι αισθητήρες χωρίς μπαταρία με RFID (αναγνωριστικά ραδιοσυχνοτήτων) ή αλλιώς παθητικοί, έχουν συντελέσει στην ανάπτυξη νέων εφαρμογών που βασίζονται σε αυτούς. Σε αντίθεση με τους αισθητήρες που κάνουν χρήση μπαταρίας, οι παθητικοί είναι πιο ελαφριοί στο βάρος τους και μικρότεροι στο μέγεθός τους, καθιστώντας τους κατάλληλους για διακριτική παρακολούθηση. Επιπλέον, οι παθητικοί αισθητήρες δεν χρειάζονται συντήρηση, αφού λειτουργούν χωρίς μπαταρία, προσφέροντας μεγαλύτερη διάρκεια ζωής (Wickramasinghe et al. 2015B).

Επίσης, λόγω του μικρού τους μεγέθους, όπως προαναφέρθηκε, μπορούν να ενσωματωθούν σε ενδύματα, αφαιρώντας την αίσθηση παρακολούθησης, ειδικά από ασθενείς με διαταραχές διανοητικής ικανότητας μιας και η διακριτικότητα έχει αναγνωριστεί ως βασικό κριτήριο αποδοχής της τεχνολογίας στην καθημερινότητα τους (Wickramasinghe et al. 2015B).

Επιπλέον δίνει δυνατότητα διάκρισης των ασθενών, επιτρέποντας την εξατομίκευση των συναγερωμένων εξόδου από την κρεβάτι σύμφωνα με τις ανάγκες των ασθενών. Το κόστος τους είναι αρκετά χαμηλό και έχουν ανοχή στη δυνατότητα πλύσης τους σε πλυντήριο, αφού προσαρμόζονται στα ρούχα. Τέλος δεν απαιτεί συνεργασία των χρηστών για να εξασφαλίσει την επιτυχία της χρήσης τους (Chesser et al. 2019).

Αδιαμφισβήτητο γεγονός, είναι η ύπαρξη πληθώρας συστημάτων ανίχνευσης στην αγορά που συνδέονται με το σώμα, το κρεβάτι και το πάτωμα, δείχνοντας σε μεγάλο βαθμό την αναζήτηση από πλευράς επαγγελματιών υγείας, συστημάτων που θα τους προειδοποιούν για πιθανές πτώσεις ασθενών με την μεγαλύτερη ακρίβεια (Ranasinghe et al. 2014).

Η αυτόματη και σε πραγματικό χρόνο αναγνώριση της εξόδου των ασθενών από το κρεβάτι τους με τη χρήση παθητικών αισθητήρων, αντικείμενο της παρούσας μεταπτυχιακής διατριβής, σε συνδυασμό με τη χρήση αυτόματων συστημάτων συναγερμού, παρέχει τη δυνατότητα παρέμβασης και εποπτείας τους χωρίς παρακολούθηση.

Αυτή η μεταπτυχιακή διατριβή περιγράφει ορισμένες τεχνικές και παραμετροποιήσεις που εφαρμόστηκαν σε αλγορίθμους μηχανικής μάθησης για την πρόβλεψη ανθρώπινων δραστηριοτήτων μέσω ενός αισθητήρα, σε δεδομένα που προέρχονται από μια ασύρματη φορητή πλατφόρμα αναγνώρισης ραδιοσυχνοτήτων (RFID) χωρίς μπαταρίες γνωστή ως W<sup>2</sup>ISP.

Κύριος στόχος είναι η υλοποίηση και η αξιολόγηση της αποτελεσματικότητας διάφορων ταξινομητών για τον προσδιορισμό δραστηριοτήτων σε πραγματικό χρόνο βάσει ενός συνόλου δεδομένων.

Χρησιμοποιήθηκαν αρκετοί ταξινομητές στα πειράματα που πραγματοποιήθηκαν, αλλά κρίθηκε σκόπιμο να αναφερθούν τέσσερις από αυτούς, βάσει της αποτελεσματικότητάς τους και βάσει της δημοφιλίας τους σε αντίστοιχες προγενέστερες έρευνες.

Οπότε η σημασία της μεταπτυχιακής διατριβής έγκειται στην συνεισφορά της να αναπτύξει ένα μοντέλο που βασίζεται σε αλγορίθμους μηχανικής μάθησης για την αναγνώριση της δραστηριότητας σε πραγματικό χρόνο, με πειραματική επίδειξη της αποτελεσματικότητάς του, χρησιμοποιώντας δεδομένα που συλλέχθηκαν σε ένα κλινικό περιβάλλον από μια έρευνα που έχει ήδη προηγηθεί.

Το υπόλοιπο της μεταπτυχιακής διατριβής ακολουθεί της εξής δομή: το κεφάλαιο 2 παρουσιάζει μια σύντομη βιβλιογραφική ανασκόπηση συναφών εργασιών, το κεφάλαιο 3 αναλύει μεθόδους, τεχνικές και αλγορίθμους που χρησιμοποιήθηκαν, το κεφάλαιο 4 παρουσιάζει τα αποτελέσματα αξιολόγησης των πειραμάτων που έλαβαν χώρα και τελικώς στο κεφάλαιο 5, 6 αποδίδονται τα συμπεράσματα.

## 2. Βιβλιογραφική Επισκόπηση

Τις δύο τελευταίες δεκαετίες έχουν πραγματοποιηθεί αρκετές έρευνες, με ποικίλες προσεγγίσεις, στον τομέα της αναγνώρισης της ανθρώπινης δραστηριότητας. Οι προσεγγίσεις, άλλοτε αφορούσαν διαφορετικές τεχνολογικές επιλογές για την συλλογή των δεδομένων, δηλαδή τον τύπο του αισθητήρα ή την θέση τοποθέτησής τους, άλλοτε διαφορετικές τεχνικές που ακολουθούνταν για την αναγνώριση της δραστηριότητας και άλλοτε διαφορετικούς συνδυασμούς που αφορούσαν την τεχνολογική επιλογή και την τεχνική προσέγγιση μαζί.

Ορισμένες έρευνες επικεντρώθηκαν σε έναν ή περισσότερους αισθητήρες τοποθετημένους γύρω από το κρεβάτι κάνοντας χρήση αισθητήρων πίεσης σε διάφορα σημεία όπως το στρώμα κρεβατιού, τα πατάκια κ.α. Τα αποτελέσματά τους ποίκιλλανε, αλλά απαιτούσαν συντήρηση, καθαρισμό και ορισμένες φορές και αλλαγή, γεγονότα που δεν βοήθησαν την ευρεία χρήση τους (Ranasinghe et al. 2013, Shinmoto Torres et al. 2013A).

Άλλες έρευνες χρησιμοποίησαν εικόνες βίντεο για ανίχνευση πτώσης, αλλά γέννησαν ανησυχίες παραβίασης της προσωπικής ζωής λόγω της ύπαρξης καμερών (Shinmoto Torres et al. 2016A).

Εκτός από αισθητήρες περιβάλλοντος, οι ερευνητές ασχολήθηκαν αρκετά και με τους φορετούς αισθητήρες στο σώμα των ασθενών. Ο συνηθέστερος είναι το επιταχυνσιόμετρο και σε ορισμένες περιπτώσεις συνδυάζεται με άλλους αισθητήρες όπως γυροσκόπια, μαγνητόμετρα και βαρόμετρα (Shinmoto Torres et al. 2016A).

Αρκετές από τις έρευνες που βασίστηκαν στους φορετούς αισθητήρες κάνουν χρήση ή αισθητήρων που απαιτούν μπαταρία για την λειτουργία τους ή παθητικών αισθητήρων, που είναι αισθητήρες που λειτουργούν χωρίς ύπαρξη μπαταρίας (Ranasinghe et al. 2014,

Shinmoto Torres et al. 2013A, Shinmoto Torres et al. 2013B, Wickramasinghe et al. 2015B).

Διάφορες έρευνες, όπως αυτές των Wang et al. 2014, Mukhopadhyay 2015, Yuan et al. 2014, έχουν κάνει χρήση πολλαπλών αισθητήρων με βαριές μπαταρίες που είναι εφαρμοσμένοι στο σώμα του ασθενούς για την συλλογή πολλών και ποικίλων δεδομένων για την αναγνώριση δραστηριότητας (Wickramasinghe et al. 2017). Η αναγνώριση δραστηριοτήτων με χρήση φορετών αισθητήρων με μπαταρία έχει επομένως μελετηθεί επαρκώς, αλλά η εφαρμογή τους δεν βρήκε ευρεία χρήση λόγω της μη αποδοχή τους, αφού το μέγεθος και οι απαιτήσεις συντήρησής τους, αποτέλεσε τροχοπέδη στην εφαρμογή τους από ηλικιωμένους ασθενείς (Ranasinghe et al. 2013, Wickramasinghe et al. 2015A).

Μελέτες που ασχολήθηκαν με την αξιολόγηση της αποδοχής των φορετών αισθητήρων από ηλικιωμένους ασθενείς, έδειξε ότι προτιμούν τους μικρούς σε όγκο, ελαφριούς και χωρίς να απαιτούν συντήρηση. Η πολυπλοκότητα στη χρήση καθώς και η διακριτικότητα είναι από τα βασικότερα κριτήρια αποδοχής (Wickramasinghe et al. 2017).

Για το λόγο αυτό πολλές έρευνες όπως των Shinmoto Torres et al. 2013A, Wickramasinghe et al. 2017, Ranasinghe et al. 2014, Chesser et al. 2019, ασχολήθηκαν με αισθητήρες που ακολουθούν την τεχνολογία των ασύρματων φορετών RFID αισθητήρων που είναι διακριτικοί, ελαφριοί και μικροί σε μέγεθος λόγω της μη χρήσης μπαταριών.

Στην πλειονότητα των ερευνών δύο είναι οι βασικότερες προσεγγίσεις που αφορούν τις τεχνικές που ακολουθούν τα συστήματα για την ταξινόμηση. Αυτές είναι η προσέγγιση που βασίζεται στο κατώφλι (threshold) και η προσέγγιση που βασίζεται στη χρήση αλγορίθμων μηχανικής μάθησης (He et al. 2017, Pannurat et al. 2014, Ranasinghe et al. 2014, Shinmoto Torres et al. 2013A).

Οι προσεγγίσεις που βασίζονται στο κατώφλι (thresholds), κάνουν χρήση ενός ή περισσότερων κατωφλίων για την ανίχνευση των πτώσεων, συμπεραίνοντας ότι η επιτάχυνση στις πτώσεις μεταβάλλεται πιο απότομα από ότι σε μία φυσιολογική κίνηση (He et al. 2017).

Οι μέθοδοι που βασίζονται στην προσέγγιση του κατωφλίου, αναγνώριζαν την πτώση όταν οι μέγιστες τιμές ήταν κάτω ή πάνω από το όριο του κατωφλίου (Chia-Yeh et al. 2017). Τα πλεονεκτήματα αυτής της προσέγγισης ήταν το χαμηλό υπολογιστικό κόστος και η εύκολη εφαρμογή τους σε συστήματα με φορετούς αισθητήρες (Chia-Yeh et al. 2017, Igual et al. 2013, Lee et al. 2014, Putra et al. 2018). Παρόλο αυτά, δεν είναι αρκετά αποτελεσματικές αφού δημιουργούσαν μεγάλο αριθμό ψευδών συναγερμών και δεν μπορούν καλύψουν το πεδίο της αναγνώρισης διάφορων δραστηριοτήτων των ανθρώπων (Chia-Yeh et al. 2017, Putra et al. 2018).

Για την μείωση των ψευδών συναγερμών και ταυτόχρονα τη βελτίωση των συστημάτων, αρκετές έρευνες επικεντρώθηκαν στη χρήση αλγορίθμων μηχανικής μάθησης (Diep et al. 2013, Putra et al. 2018). Όσο αναφορά την μηχανική μάθηση, οι συνηθέστεροι αλγόριθμοι που χρησιμοποιούνται στην αναγνώριση δραστηριοτήτων είναι οι: Naïve Bayesian (NB), Support Vector Machine (SVM), k-Nearest Neighbors (kNN), Neural Networks (NN) και Decision Trees (DT) (Chia-Yeh et al. 2017, Putra et al. 2018).

Μελέτες που χρησιμοποίησαν τεχνικές μηχανικής μάθησης πέτυχαν υψηλού βαθμού αποτελέσματα. Όσες όμως συνδυάστηκαν με χρήση αισθητήρων μεγάλου όγκου ή η χρήση πολλαπλών αισθητήρων στο σώμα των ασθενών, αποδείχθηκαν απαγορευτικές στην εφαρμογή τους σε πραγματικές συνθήκες σε ηλικιωμένους ασθενείς (Ranasinghe et al. 2013).

Επίσης, μέσω τεχνικών μηχανικής μάθησης μειώθηκαν σε μεγάλο βαθμό και οι καθυστερήσεις στη δημιουργία συναγερμού κατά την ανίχνευση των δραστηριοτήτων μέσω εμπειρικών αλγορίθμων ταξινόμησης. Οι καθυστερήσεις οφείλονταν στην πολλαπλή επεξεργασία δεδομένων, που παράγονταν από αισθητήρες κίνησης, εφαρμοσμένους στο ανθρώπινο σώμα, για την καταγραφή βιομηχανικών χαρακτηριστικών από την κίνηση ενός ατόμου (Wickramasinghe et al. 2017).

Η ευρεία χρήση επίσης των έξυπνων κινητών τηλεφώνων και η ενσωμάτωση σε αυτά αισθητήρων όπως επιταχυνσιόμετρα, γυροσκόπια κ.α., ώθησαν τους ερευνητές στη χρήση

τους για την αναγνώριση των δραστηριοτήτων των ανθρώπων, πετυχαίνοντας πολύ υψηλά ποσοστά ακρίβειας (Aguiar et al. 2014, Albert et al. 2012). Έρευνες όμως όπως των Aguiar et al. 2014, Habib et al. 2014, απέδειξαν τη δυσκολία εφαρμογής τους, ειδικά σε ηλικιωμένους ασθενείς, με βασικότερα προβλήματα να είναι η τοποθέτηση του κινητού και η κατανάλωση της μπαταρίας.

Ένα γενικό συμπέρασμα που έχει εξαχθεί από την πληθώρα των ερευνών που έχουν γίνει με διαφορετικούς τύπους ή πλήθος αισθητήρων, είναι ότι η ακρίβεια (precision) κατά την αξιολόγηση των συστημάτων είναι συνήθως μικρότερη από την ανάκληση (recall). Η χαμηλή ακρίβεια μεταφράζεται σε μεγάλο αριθμό ψευδών συναγερμών και η χαμηλή ανάκληση στο γεγονός ότι το σύστημα δεν θα προκαλέσει ενεργοποίηση συναγερμού σε ένα σημαντικό γεγονός που δεν θα το αντιληφθεί. Οπότε η αποδοχή ενός συστήματος αναγνώρισης κίνησης στον πραγματικό κόσμο και ειδικά σε περιβάλλον ηλικιωμένων ασθενών, κρίνεται σε μεγάλο βαθμό από τον βαθμό της απόδοσης των τιμών της ακρίβειας και της ανάκλησης (Putra et al. 2018).

Σε σύγκριση με όλες τις έρευνες που προαναφέρθηκαν, τα συστήματα που βασίζονται σε αισθητήρες RFID χωρίς την χρήση μπαταριών για την αναγνώριση δραστηριοτήτων ηλικιωμένων ασθενών σε κλινικό περιβάλλον, έχουν πολλά πλεονεκτήματα, όπως το χαμηλό κόστος και η μη αναγκαιότητα συντήρησή τους. Η παρούσα μεταπτυχιακή διατριβή διαφέρει από τις προηγούμενες μελέτες, επειδή λόγω της ένωσης όλων των αρχείων που αποτελούσαν τα σύνολα δεδομένων των δύο δωματίων σε δύο ενιαία, δεν λήφθηκε υπόψη το χαρακτηριστικό του χρόνου. Επιπλέον, η εφαρμογή αρκετών πειραμάτων με διαφορετικές παραμέτρους των αλγορίθμων μηχανικής μάθησης και η χρήση τεχνικών όπως της SMOTE, από τις γνώσεις που αποκτήθηκαν μέσω της βιβλιογραφικής επισκόπησης, οδήγησαν στην επίτευξη καλύτερων αποτελεσμάτων στην αναγνώριση δραστηριοτήτων χρησιμοποιώντας παθητικούς αισθητήρες RFID, σε σχέση με παρόμοιες μελέτες που έχουν εκπονηθεί στο παρελθόν.




# 3. Εργαλεία και μέθοδοι

## 3.1 Συμμετέχοντες και τοποθεσία

Στην παρούσα μεταπτυχιακή διατριβή χρησιμοποιούμε δύο σύνολα δεδομένων που περιέχουν δεδομένα ορισμένων κινήσεων από 14 ηλικιωμένους ανθρώπους ηλικίας μεταξύ 66 και 86 ετών (Shinmoto Torres et al. 2013A). Κάθε συμμετέχων που βρισκόταν στα δωμάτια παρακολούθησης, πραγματοποίησε τυχαία, με το δικό του ρυθμό και όσο πιο άνετα επιθυμούσε ορισμένες από τις εξής δραστηριότητες: να είναι ξαπλωμένος στο κρεβάτι, να κάθεται στο κρεβάτι, να κάθεται στην καρέκλα και να περπατάει. Παράλληλα ένας ερευνητής σημείωνε τις δραστηριότητες που πραγματοποιούνταν (Shinmoto Torres et al. 2016A, Wickramasinghe et al. 2017, Wickramasinghe et al. 2015B).

Όλα τα δεδομένα συλλέχθηκαν σε δύο κλινικά δωμάτια με διαφορετική διαμόρφωση. Τα δωμάτια σχεδιάστηκαν με τέτοιο τρόπο ώστε να είναι παρόμοια με τα δωμάτια των νοσοκομείων όπου είναι διακοσμημένα με ένα κρεβάτι και μια καρέκλα (Shinmoto Torres et al. 2016A, Wickramasinghe et al. 2017, Wickramasinghe et al. 2015B).

Το πρώτο δωμάτιο είχε τέσσερις κεραίες ανάγνωσης RFID όπου η μία τοποθετήθηκε στην οροφή πάνω από το κρεβάτι και οι υπόλοιπες στους τοίχους, με τέτοιο τρόπο ώστε να καλύπτουν την περιοχή γύρω από το κρεβάτι και την καρέκλα. Στο δεύτερο δωμάτιο, τοποθετήθηκαν τρεις κεραίες, εκ των οποίων οι δύο στην οροφή πάνω από το κρεβάτι για καλύτερη κάλυψη της εξόδου του ασθενή από αυτό και η άλλη στον τοίχο που βρίσκεται μπροστά από την καρέκλα ([Εικόνα 1](#)) (Shinmoto Torres et al. 2016A, Wickramasinghe et al. 2017, Wickramasinghe et al. 2015B).




**Εικόνα 1.** Διαμόρφωση των δύο δωματίων. Το A αντιστοιχεί στο Room1 και το B στο Room2 (Shinmoto Torres et al. 2016A).

## 3.2 Τεχνολογία

Η ασύρματη πλατφόρμα παρακολούθησης RFID αποτελείται από ένα ασύρματο φορητό αισθητήρα  $W^2ISP$  που είναι ένας παθητικός RFID αισθητήρας και από μία υποδομή RFID.

Ο αισθητήρας  $W^2ISP$  ([Εικόνα 2](#)) βασίζεται στη λειτουργία του WISP με ορισμένες βέβαια βασικές διαφορές, όπως η φορητότητα, η βελτιωμένη ευέλικτη κεραία λόγω φορητότητας και ο αυξημένος ρυθμός ανάγνωσης. Τον φέρει ο ασθενής πάνω του, συνήθως στην περιοχή του στήθους, μέσω ενός αγωγίμου υφάσματος. Αποτελείται από ένα τριαξονικό επιταχυνσιόμετρο και έναν μικροεπεξεργαστή, όπου μέσω κεραιών RFID, εκπέμπεται ηλεκτρομαγνητική ενέργεια για να τον τροφοδοτήσει. Η ασύρματη τροφοδοσία του αισθητήρα απαιτεί συγκέντρωση επαρκούς ισχύς για την τροφοδοσία του κυκλώματος  $W^2ISP$ , ώστε να μπορούν να ληφθούν και να αποσταλούν οι πληροφορίες πίσω στον αναγνώστη RFID. Η ικανότητα λειτουργίας του επιταχυνσιόμετρου απαιτεί ελάχιστη ισχύ για να διαβάσει τον αισθητήρα αφού είναι χαμηλής κατανάλωσης. Είναι επίσης μικρός σε μέγεθος, ελαφρύς, φθηνός και χωρίς μπαταρίες (Shinmoto Torres et al. 2013A, Wickramasinghe et al. 2017).



**Εικόνα 2.** Αισθητήρας W<sup>2</sup>ISP ενσωματωμένος σε ύφασμα (Wickramasinghe et al. 2017)

Η υποδομή RFID αποτελείται από έναν αναγνώστη (reader) UHF RFID που λειτουργεί στην περιοχή συχνοτήτων 920- 926 MHz και κυκλικά πολωμένες κεραίες. Οι κεραίες, 3 και 4 στο πλήθος τους ανά δωμάτιο και στρατηγικά τοποθετημένες σε κομβικά σημεία, όπως κοντά στο κρεβάτι και στην καρέκλα ώστε να προσομοιώνουν ένα νοσοκομειακό δωμάτιο, είναι υπεύθυνες για την συλλογή των δεδομένων από τους αισθητήρες W<sup>2</sup>ISP. Η τροφοδοσία τους πραγματοποιείται από τον αναγνώστη (reader) (Shinmoto Torres et al. 2013A, Wickramasinghe et al. 2017).

### 3.3 Περιγραφή Συνόλων Δεδομένων

Περιγράφοντας τα datasets στα οποία γίνονται τα πειράματα, τα δεδομένα περιέχουν τιμές από ορισμένα χαρακτηριστικά τα οποία αναφέρονται και αναλύονται ως εξής: χρόνος (t),  $a_f$ ,  $a_v$ ,  $a_l$ , Id της κεραίας ανάγνωσης, RSSI, φάση ( $\varphi$ ), συχνότητα και κλάση.

Η  $a_f$  μετωπιαία επιτάχυνση, η  $a_v$  κατακόρυφη επιτάχυνση και η  $a_l$  πλευρική επιτάχυνση είναι μετρήσεις που προέρχονται από το τριαξονικό επιταχυνσιόμετρο, το οποίο είναι ενσωματωμένο στο W<sup>2</sup>ISP και μετρά την επιτάχυνση του ασθενή που προκύπτει από την κίνησή του και από τη βαρύτητα στους άξονες του επιταχυνσιόμετρου. Επομένως οι μετρήσεις αυτές μας φανερώνουν στοιχεία της κίνησης του σώματος που πραγματοποιεί ο συμμετέχοντας (Shinmoto Torres et al. 2017A, Wickramasinghe et al. 2017).

Το RSSI, δηλαδή ο δείκτης ισχύος του λαμβανόμενου σήματος στην κεραία RFID, είναι μία μέτρηση που δείχνει την διακύμανση της τιμής της απόστασης του ασθενή με την κεραία RFID που λαμβάνει τις ενδείξεις του αισθητήρα που φέρει ο ασθενής (Chesser et al. 2019, Shinmoto Torres et al. 2017A). Ο αναγνώστης της κεραίας RFID, ενεργοποιεί τον αισθητήρα του ασθενή και μετράει τη δύναμη του ασύρματου σήματος που γυρνάει πίσω από τον αισθητήρα W<sup>2</sup>ISP και στη συνέχεια σχετίζεται με την απόσταση μεταξύ της RFID κεραίας και του W<sup>2</sup>ISP. Έτσι προκύπτει η μέτρηση της δύναμης (Wickramasinghe et al. 2017). Οι αλλαγές τιμής του RSSI είναι πολύ σημαντικά δεδομένα που συντελούν στη διάκριση μεταξύ των κινήσεων του ασθενή, ειδικά σε περιπτώσεις που τα δεδομένα από το επιταχυνσιόμετρο δεν επαρκούν από μόνα τους να προβούν στη διάκριση. Αυτό γίνεται γιατί σε ορισμένες στάσεις του σώματος, οι μετρήσεις του επιταχυνσιόμετρου είναι όμοιες. Επίσης οι υψηλές τιμές του RSSI δείχνουν ότι ο αισθητήρας του ασθενή είναι πιο κοντά σε μια συγκεκριμένη κεραία (Chesser et al. 2019).

Το Id είναι μια πληροφορία του αισθητήρα της κεραίας ανάγνωσης (Chesser et al. 2019).

Η συχνότητα F που μετριέται σε MHz, αφορά την συχνότητα των καναλιών που χρησιμοποιεί ο αναγνώστης RFID για να ζητήσει δεδομένα από τον αισθητήρα (Chesser et al. 2019).

Η φάση ( $\varphi$ ) είναι μία μέτρηση της γωνίας μεταξύ του φορέα RF που μεταδίδεται από την RFID κεραία και του σήματος που επιστρέφει από τον αισθητήρα του ασθενή (Chesser et al. 2019). Χρησιμοποιείται για την ανάλυση των κινήσεων του ασθενή με την βοήθεια χωρικών πληροφοριών. Οι μετρήσεις της που υπολογίζονται από έναν RFID αναγνώστη βάσει του λαμβανόμενου σήματος του αναμεταδότη, παρέχουν πληροφορίες όπως η απόσταση του αισθητήρα του ασθενή από μια κεραία RFID και η ταχύτητα, οι λεγόμενες χωρικές πληροφορίες (Shinmoto Torres et al. 2017A). Η αλλαγή της απόστασης, ακόμη και οι μικρές, προκαλούν ευαισθησία στην πληροφορία της φάσης με αποτέλεσμα τα δεδομένα της φάσης να είναι σημαντικά στην αναγνώριση της μετάβασης από μια δραστηριότητα σε κάποια άλλη. Συγκρίνοντας το χαρακτηριστικό της φάσης ( $\varphi$ ) με την RSSI, η φάση

επιηρεάζεται ακόμη και από μικρές κινήσεις ενώ η RSSI από μεγαλύτερες (Chesser et al. 2019).

Επίσης, εκτός από όλες αυτές οι πληροφορίες που αναφέρθηκαν, χρησιμοποιούνται το φύλο του ασθενή και η χρονική στιγμή  $t$  που έγινε η λήψη των δεδομένων από τον αισθητήρα (Shinmoto Torres et al. 2017A).

Θεωρούμε ότι τα χαρακτηριστικά που εξάγονται από το  $W^2ISP$ , επιτάχυνση, χρόνος, φάση, συχνότητα και RSSI είναι χρονικά χαρακτηριστικά (Shinmoto Torres et al. 2016A).

### **3.4 Εργαλείο WEKA**

Το WEKA (Waikato Environment for Knowledge Analysis) είναι ένα ελεύθερο λογισμικό ανοιχτού κώδικα που αναπτύχθηκε στο πανεπιστήμιο του Waikato της Νέας Ζηλανδίας με σκοπό την ανάλυση της γνώσης. Ο στόχος του είναι να δημιουργήσει μία σύγχρονη και ισχυρή πλατφόρμα για να αναπτύσσει τεχνικές μηχανικής μάθησης, εφαρμόζοντας αυτές στον πραγματικό κόσμο. Έχει αναπτυχθεί σε γλώσσα προγραμματισμού Java και προσφέρει δυνατότητα χρήσης αρκετών αλγορίθμων μηχανικής μάθησης καθώς και εφαρμογή εξόρυξης δεδομένων. Περιλαμβάνει προεπεξεργασία δεδομένων, ταξινόμηση, παρεμβολή ή παλινδρόμηση (regression), ομαδοποίηση και συσχέτιση. Χρησιμοποιείται κυρίως για ερευνητικούς και ακαδημαϊκούς σκοπούς (Dhakate et al. 2014, Sharma et al. 2012).

Δεν απαιτεί κατοχή υψηλού βαθμού γνώσεων μηχανικής μάθησης από πλευράς των χρηστών αφού παρέχει εύχρηστο γραφικό περιβάλλον, γεγονός που το κάνει πολύ απλό στη χρήση του και επομένως δημοφιλές. Η μορφή των δεδομένων που υποστηρίζει είναι συνήθως ARFF (Μορφή Αρχείων Συσχετίσεων Χαρακτηριστικών), αλλά υποστηρίζει και άλλες μορφές όπως CSV. Η δομή των αρχείων ARFF που θα χρησιμοποιηθούν και στην παρούσα μεταπτυχιακή διατριβή αποτελείται από ειδικές ετικέτες που υποδηλώνουν στα δεδομένα εισόδου τα εξής: τα ονόματα των χαρακτηριστικών, τους τύπους των χαρακτηριστικών, τις τιμές των χαρακτηριστικών και εννοείται τα δεδομένα (Dhakate et al. 2014, Jagga & Gupta 2014, Sharma et al. 2012).

## 3.5 Ταξινομητές (Classifiers)

Οι δύο βασικότερες κατηγοριοποιήσεις της μηχανικής μάθησης είναι η εποπτευόμενη και η μη εποπτευόμενη μηχανική μάθηση. Η εποπτευόμενη που είναι και αυτή που θα χρησιμοποιηθεί στην μεταπτυχιακή διατριβή, πραγματοποιεί αρχικά το στάδιο της εκπαίδευσης από δεδομένα που η κλάση τους είναι ήδη γνωστή (Amendola et al. 2015). Στη συνέχεια προβλέπεται η κλάση για ένα σύνολο δεδομένων που υπόκεινται στη διαδικασία της δοκιμής και δεν περιέχουν κλάσεις, βάσει του συνόλου δεδομένων που έχει υποστεί εκπαίδευση. Οπότε δημιουργείται αρχικά το μοντέλο από τα δεδομένα εκπαίδευσης και στη συνέχεια το μοντέλο αυτό χρησιμοποιείται για να ταξινομήσει τα νέα δεδομένα που αποτελούν τα δεδομένα δοκιμής (Zerrouki et al. 2016).

Η μη εποπτευόμενη αντιθέτως, δεν υλοποιεί εκπαίδευση, αλλά προσπαθεί να αποκαλύψει κρυμμένα μοτίβα σε ένα σύνολο δεδομένων που δεν περιέχει εκ των προτέρων κλάσεις, ομαδοποιώντας τα δεδομένα βάσει κριτηρίων ομοιότητας (Amendola et al. 2015).

Και στις δύο περιπτώσεις, την διαδικασία κατηγοριοποίησης του συνόλου δεδομένων σε κλάσεις, την αναλαμβάνει ο ταξινομητής (classifier), δηλαδή οι αλγόριθμοι μηχανικής μάθησης. Αυτό το επιτυγχάνει μέσω των χαρακτηριστικών (features) του συνόλου δεδομένων. Στην εποπτευόμενη μηχανική μάθηση, στο στάδιο της εκπαίδευσης, οι αλγόριθμοι προσπαθούν να εντοπίσουν σχέσεις μεταξύ των features και των κλάσεων, με σκοπό τη δημιουργία μοντέλου πρόβλεψης που θα ταξινομήσει στη συνέχεια δεδομένα που δεν περιέχουν κλάσεις. Η απόδοση του μοντέλου που παράγεται, αξιολογείται από ορισμένες μετρήσεις (Amendola et al. 2015).

Σε αυτή την ενότητα περιγράφονται συνοπτικά οι αλγόριθμοι μηχανικής μάθησης που χρησιμοποιούνται στην παρούσα μεταπτυχιακή διατριβή (RF, SVM, NN, k-NN).

### **Random Forest (RF)**

Ο RF είναι ένας μη πιθανοτικός αλγόριθμος που βασίζεται σε δέντρα αποφάσεων (decision trees), αφού παράγει έναν αριθμό τέτοιων δέντρων. Ένα τυχαίο υποσύνολο από το σύνολο των δεδομένων λαμβάνεται υπόψη για κάθε ένα από τα δέντρα για την εκπαίδευσή τους.

Επίσης για τον διαχωρισμό, μόνο ένα τυχαίο υποσύνολο των χαρακτηριστικών (features) χρησιμοποιείται για να αποφασιστεί το feature που θα χρησιμοποιηθεί για τον διαχωρισμό του υποσυνόλου δεδομένων στον αντίστοιχο κόμβο. Από την άλλη πλευρά τα δέντρα αποφάσεων (DT) διαχωρίζουν το σύνολο των δεδομένων της κάθε διακλάδωσης του δέντρου, λαμβάνοντας υπόψη μόνο ένα feature, έως ότου όλα τα σημεία δεδομένων που προέκυψαν από τον διαχωρισμό να ανήκουν σε μία κλάση. Αυτή η διαδικασία διαφοροποιεί τον RF από την πλειοψηφία των ρυθμίσεων μάθησης των δέντρων αποφάσεων DT, όπου εκεί αξιολογείται ολόκληρο το σύνολο των features (Nef et al. 2015).

Για την ταξινόμηση νέων δεδομένων, τα δεδομένα μοιράζονται σε κάθε ένα από τα δέντρα που έχουν παραχθεί, με σκοπό η απόφαση ανάθεσης της κλάσης να είναι απόρροια την πλειοψηφίας των δέντρων. Ορισμένα από τα πλεονεκτήματά του συγκεκριμένου αλγορίθμου είναι η υψηλή απόδοση που επιτυγχάνει στην ταξινόμηση των νέων δεδομένων λόγω της χρήσης της πλειοψηφίας των δέντρων που έχουν παραχθεί, καθώς επίσης και η διασφάλιση της γενίκευσης των νέων δεδομένων, λόγω της καλής συμπεριφοράς του στο over-fitting (Nef et al. 2015, Wickramasinghe et al. 2015A).

Το over-fitting, δηλαδή η υπερφόρτωση είναι η κατάσταση όπου ένας ταξινομητής χάνει τη δυνατότητα γενικευμένης μάθησης και παράγει προβλέψεις που οδηγούν σε παραπλανητικά αποτελέσματα. Δηλαδή μπορεί να επιτύχει ορισμένες φορές καλά αποτελέσματα σε ένα υποσύνολο των δεδομένων εκπαίδευσης, αλλά δεν εγγυάται ότι θα έχει εξίσου καλά σε νέα δεδομένα δοκιμών. Μπορεί για παράδειγμα ένας αλγόριθμος να παγιδευτεί σε ένα ή λίγα διαγνωστικά μοτίβα για δεδομένα εισόδου και να παράγει εντελώς λάθος διαγνωστικά αποτελέσματα (Han & Jiang 2014).

## **SVM**

Είναι ένας μη πιθανοτικός ταξινομητής μηχανικής μάθησης για δυαδική ταξινόμηση. Η αρχή λειτουργίας του είναι ότι αφού τα δεδομένα από τον αρχικό χώρο χαρακτηριστικών που βρίσκονται δεν διαχωρίζονται γραμμικά, μέσω της επιλογής ενός πυρήνα, χαρτογραφεί σε ένα νέο χώρο τα δεδομένα εκπαίδευσης καθιστώντας τα κατά προσέγγιση γραμμικά, ώστε να μπορεί με μεγαλύτερη ασφάλεια να αποδώσει τις σωστές κλάσεις. Στο νέο αυτό χώρο γίνεται προσπάθεια να δημιουργηθεί η βέλτιστη διαχωριστική γραμμή

(hyperplane) που λειτουργεί ως όριο για την διάκριση των κλάσεων (Delahoz & Labrador 2018, Hsieh et al. 2016, Liu et al. 2018, Nef et al. 2015, Zerrouki et al. 2016).

Τα σημεία δεδομένων που προέρχονται από το στάδιο της εκπαίδευσης και που είναι πιο κοντά στο βέλτιστο διαχωριστικό, ονομάζονται διανύσματα υποστήριξης (support vectors). Τα σημεία αυτά αντιπροσωπεύουν το μέγιστο περιθώριο από το διαχωριστικό (hyperplane) για τα δεδομένα εκπαίδευσης. Όσο μεγαλύτερο είναι το περιθώριο τόσο μικρότερο είναι το σφάλμα γενίκευσης και επομένως το μοντέλο γίνεται αποδοτικότερο (Delahoz & Labrador 2018, Hsieh et al. 2016, Liu et al. 2018, Nef et al. 2015, Zerrouki et al. 2016).

Αρχικά ο SVM απαιτούσε γραμμικό διαχωρισμό των κλάσεων. Η πιο απλή περίπτωση ταξινόμησης είναι όταν τα σύνολα δεδομένων έχουν μόνο δύο κλάσεις και διαχωρίζονται γραμμικά, αφού μια ευθεία γραμμή χωρίζει τον χώρο σε δύο περιοχές που αντιστοιχούν ουσιαστικά στις δύο κλάσεις. Αν και ο SVM είναι ένας δυαδικός ταξινομητής όπως προαναφέρθηκε, έχει τη δυνατότητα να χρησιμοποιηθεί και σε προβλήματα πολλών κλάσεων (multi-class). Οι κυριότερες προσεγγίσεις για την χρήση του σε προβλήματα πολλών κλάσεων είναι οι one vs one και η one vs all (Delahoz & Labrador 2018, Hsieh et al. 2016, Liu et al. 2018, Nef et al. 2015, Zerrouki et al. 2016).

Η one-versus-all προσέγγιση δημιουργεί  $k$  διαφορετικούς δυαδικούς ταξινομητές για ένα multiclass πρόβλημα  $k$  κλάσεων, ενώ η one vs one παράγει  $k(k-1)/2$  επιμέρους δυαδικούς ταξινομητές. Στην one-versus-all ο πρώτος δυαδικός ταξινομητής εκπαιδεύεται χρησιμοποιώντας δεδομένα με ετικέτα της πρώτης τάξης ως θετικά παραδείγματα και για τις υπόλοιπες κλάσεις,  $k-1$  στο πλήθος, ως αρνητικά αποτελέσματα (Wang & Xue 2014).

Σημαντικό πρόβλημα της προσέγγισης one vs all είναι το μη ισορροπημένο σύνολο εκπαίδευσης, γιατί αν υποθέσουμε ότι έχουμε ένα σύνολο δεδομένων με 3 κλάσεις και 100 παραδείγματα για κάθε μία από αυτές, τότε παρατηρείται το εξής πρόβλημα ανισορροπίας. Από την μία πλευρά έχουμε 100 παραδείγματα με θετικό αποτέλεσμα και από την άλλη 200 με αρνητικό. Στην one vs one όμως, τα δεδομένα της κάθε κλάσης συγκρίνονται με τα δεδομένα μόνο μιας άλλης κλάσης κάθε φορά, με αποτέλεσμα η προσέγγιση αυτή να είναι



πιο συμμετρική. Δηλαδή τα 100 παραδείγματα της πρώτης κλάσης συγκρίνονται με τα 100 της δεύτερης κ.ο.κ. (Wang & Xue 2014).

Στη περίπτωση μας, το WEKA χρησιμοποιεί την προσέγγιση one vs one. Τέλος, κομβικό σημείο για την βελτιστοποίηση της απόδοσης του ταξινομητή είναι η επιλογή του πυρήνα, καθώς με την εξέλιξη του, έκανε χρήση πολλών διαφορετικών πυρήνων (γραμμικοί, πολυωνομικοί, Gaussian, Radial Basis Function RBF) που χρησιμοποιούνται για την ταξινόμηση (Hsieh et al. 2016, Liu et al. 2018, Nef et al. 2015).

### **k-nearest neighbor (k-NN)**


Ο K-πλησιέστερος ταξινομητής γειτόνων ανήκει στην κατηγορία των εποπτευόμενων αλγορίθμων μηχανικής μάθησης και ονομάζονται επίσης και τεμπέληδες (lazy) ταξινομητές. Ταξινομεί τα νέα δεδομένα, δηλαδή τα δεδομένα του σταδίου δοκιμής (test) βάσει των δεδομένων εκπαίδευσης. Πιο συγκεκριμένα παρατηρεί μέσω της απόστασης (Ευκλείδεια, Μανχάταν κ.α.), τα δεδομένα εκπαίδευσης που είναι πλησιέστερα στα δεδομένα δοκιμής για να αποφασίσει που θα τα κατατάξει. Σημαντικό ρόλο παίζει η τιμή k που είναι ένας ακέραιος αριθμός μεγαλύτερος του μηδενός που υποδηλώνει το πλήθος των πλησιέστερων δεδομένων εκπαίδευσης στα νέα δεδομένα. Το πλήθος αυτό θα αποφασίσει σε πια κλάση θα ανήκουν τα δεδομένα δοκιμής. Ο αλγόριθμος χρησιμοποιεί διάφορες τεχνικές για την ταξινόμηση, με τις κυριότερες να είναι η τυπική, η σταθμισμένη και αυτή που βασίζεται στην απόσταση (Delahoz & Labrador 2018, Liu et al. 2018, Zerrouki et al. 2016).

Ο αριθμός του k παίζει σημαντικό ρόλο, αφού μεγάλη τιμή του μπορεί να μεταφραστεί σε μείωση της ευαισθησίας (sensitivity), αυξάνοντας την μεροληψία και τα δεδομένα θορύβου, ενώ μία μικρή τιμή του μπορεί να αυξήσει τη διακύμανση, προκαλώντας ασταθή αποτελέσματα. Αρνητικό σημείο του συγκεκριμένου αλγορίθμου είναι η πολυπλοκότητά του στη διαδικασία αναζήτησης των πλησιέστερων γειτόνων για κάθε σύνολο δεδομένων που βρίσκεται στο στάδιο της εκπαίδευσης (Hsieh et al. 2016).

### **Neural network classification**

Ο αλγόριθμος νευρωνικών δικτύων (NN) ανήκει και αυτός στην εποπτευόμενη μηχανική μάθηση, χρησιμοποιώντας πολλαπλές εισόδους, εξόδους και κρυφά επίπεδα με αυθαίρετο αριθμό νευρώνων. Ο αλγόριθμος πολλαπλών στρώσεων Perceptron (MultiLayer Perceptron MLP), με εκμάθηση ανάδρομης διάδοσης (back-propagation BP) που συντελεί στην βελτιστοποίησή του, είναι ένας από τους πιο ευρέως χρησιμοποιημένους αλγορίθμους νευρωνικών δικτύων (Gayathri & Sudha 2014).

Η αρχιτεκτονική του αποτελείται από τρεις στρώσεις (Εικόνα 3), οι οποίες όπως προαναφέρθηκε είναι η είσοδος, τα κρυμμένα στρώματα και η έξοδος. Η είσοδος αφορά τα χαρακτηριστικά προς ταξινόμηση, τα κρυμμένα στρώματα καθορίζονται με εμπειρικό τρόπο σχετικά με την αναμενόμενη ακρίβεια ταξινόμησης και η έξοδος αφορά τις κλάσεις που έχουν αποδοθεί (Gayathri & Sudha 2014).



**Εικόνα 3.** Αρχιτεκτονική του MLP (Ramchoun et al. 2016)

Η αρχή λειτουργίας τους βασίζεται στην εκπαίδευσή τους για να μάθουν να μετασχηματίζουν τα δεδομένα εισόδου σε μια προτιμώμενη απάντηση. Στην αντίστροφη διάδοση (BP), η επιθυμητή έξοδος συγκρίνεται με τις πραγματικές τιμές εξόδου για να υπολογιστεί η τιμή του σφάλματος βάσει κάποιας συνάρτησης. Κατόπιν ρυθμίζονται τα

βάρη της κάθε σύνδεσης, προκειμένου να μειωθεί η τιμή του σφάλματος. Η διαδικασία αυτή επαναλαμβάνεται πολλές φορές και αποτελεί τη φάση της εκπαίδευσης η οποία σταματάει όταν ο υπολογισμός του σφάλματος είναι μικρός. Για την σωστή προσαρμογή των βαρέων, εφαρμόζεται η κατάταξη κλίσης που είναι μία μη γραμμική μέθοδος βελτιστοποίησης μέσω της οποίας υπολογίζεται το παράγωγο της συνάρτησης σφάλματος σε σχέση με τα βάρη του δικτύου. Στη συνέχεια τα βάρη αλλάζουν έτσι ώστε το σφάλμα να μειώνεται. Η τετραγωνική ευκλείδεια απόσταση ανάμεσα στην πραγματική έξοδο του δικτύου και την επιθυμητή έξοδο είναι το σφάλμα που υπολογίζεται (Gayathri & Sudha 2014).

Οι κόμβοι στην έξοδο αντιστοιχίζονται με κάθε κλάση. Η τιμή του κάθε κόμβου στην έξοδο θα πρέπει να παρέχει την ανάλογη κλάση για τα δεδομένα εισόδου. Για παράδειγμα, ένας κόμβος εξόδου με σωστή κλάση αναμένεται να έχει υψηλή τιμή, ενώ αναμένεται να έχει χαμηλή για όλες τις υπόλοιπες κλάσεις (Zerrouki et al. 2016).

### **3.6 Μέθοδος k-fold cross-validation**

Η μέθοδος k-fold cross-validation χρησιμοποιείται για τη συλλογή αποτελεσμάτων της αξιολόγησης της απόδοσης των αλγορίθμων. Η διασταυρωμένη επικύρωση είναι μία διαδικασία κατά την οποία πραγματοποιείται επαναδειγματοληψία σε ένα σύνολο δεδομένων για την αξιολόγηση αλγορίθμων μηχανικής μάθησης. Η μέθοδος αυτή οδηγεί σε λιγότερο μεροληπτική εκτίμηση σε σχέση με άλλες μεθόδους, όπως ο απλός διαχωρισμός ενός συνόλου δεδομένων σε δεδομένα εκπαίδευσης και δοκιμής και για το λόγο αυτό χρησιμοποιείται ευρέως (Amendola et al. 2015).

Η τεχνική k-fold χωρίζει τυχαία το σύνολο δεδομένων σε k υποσύνολα που ονομάζονται folds. Στη συνέχεια τα (k-1) υποσύνολα χρησιμοποιούνται στο στάδιο της εκπαίδευσης (train) και το εναπομείναν υποσύνολο χρησιμοποιείται στη εξέταση (test). Η διαδικασία αυτή επαναλαμβάνεται k φορές ώστε κάθε υποσύνολο να χρησιμοποιηθεί στο στάδιο της εξέτασης (Amendola et al. 2015).

### 3.7 Αξιολόγηση μετρήσεων

Η ενότητα της αξιολόγησης αλγορίθμων μηχανικής μάθησης αποτελεί κομβικής σημασίας διαδικασία, προσφέροντας επίσης και τη δυνατότητα σύγκρισή τους μεταξύ τους. Για την διαδικασία αξιολόγησής τους δεν υπάρχει κάποιος προκαθορισμένος κανόνας αφού κάθε περίπτωση είναι διαφορετική και επίσης ο τρόπος αξιολόγησης δεν είναι μοναδικός. Για το λόγο αυτό αναφέρεται ότι η αξιολόγηση των αλγορίθμων ταξινόμησης με εποπτεία πρέπει να αιτιολογείται. Επομένως απαιτείται ανάλυση και κατανόηση των χαρακτηριστικών των αλγορίθμων για να αποτελέσουν γνώμονα για την επιλογή του τρόπου αξιολόγησης. Η ποιότητα της αξιολόγησης είναι πολύπλευρο ζήτημα το οποίο αντιμετωπίζεται με την χρήση των βαθμολογιών (Scores). Οι βαθμολογίες απεικονίζουν ποσοτικά την συμπεριφορά ενός ταξινομητή κατά την εφαρμογή του σε ένα πρόβλημα που απαιτεί ταξινόμηση (Santafe et al. 2015).


Το WEKA που είναι το εργαλείο το οποίο θα χρησιμοποιήσουμε για την εφαρμογή των αλγορίθμων, παράγει αρκετές βαθμολογίες, με πιο συνηθισμένες τις Accuracy, Recall, Precision, F-Measure, Kappa statistic κ.α. Οι πλειοψηφία αυτών των βαθμολογιών υπολογίζονται από ένα πίνακα που παράγεται και ονομάζεται confusion matrix ([Εικόνα 4](#))

		Classifier decision	
		$\hat{c}^+$	$\hat{c}^-$
Actual class	$c^+$	$TP$ (True Positive)	$FN$ (False Negative)
	$c^-$	$FP$ (False Positive)	$TN$ (True Negative)

**Εικόνα 4.** Απεικόνιση ενός Confusion Matrix δύο κλάσεων (Santafe et al. 2015)

Η ακρίβεια (accuracy) είναι μία μέτρηση που χρησιμοποιείται ευρέως σε προβλήματα ταξινόμησης, αλλά δεν αποτελεί πάντα την κατάλληλη μέτρηση για την αξιολόγηση ενός ταξινομητή, ιδιαίτερα σε σύνολα δεδομένων ταξινόμησης που δεν περιέχουν το ίδιο πλήθος περιστατικών (instances) για κάθε μία κλάση. Αυτά τα σύνολα χαρακτηρίζονται ως μη ισορροπημένα δεδομένα. Σε αυτού του είδους τα σύνολα δεδομένων, όπως είναι και αυτά της παρούσας μεταπτυχιακή διατριβή ([Εικόνα 5](#)), υπάρχει μεγάλη πιθανότητα να

επιτύχουμε υψηλή τιμή ακρίβειας χωρίς να κάνουμε πραγματικά χρήσιμες προβλέψεις. Οπότε η ακρίβεια ως μέτρηση αξιολόγησης, έχει νόημα μόνο αν τα instances του συνόλου δεδομένων είναι ομοιόμορφα κατανομημένα. Σε αντίθετη περίπτωση, η ακρίβεια δεν αρκεί ως μοναδική τεχνική αξιολόγησης της απόδοσης ενός αλγορίθμου (Santafe et al. 2015).



**Εικόνα 5.** Ποσοστό κλάσεων ανά δραστηριότητα ασθενή επί του συνόλου δεδομένων, ανά δωμάτιο.

Τα αποτελέσματα του ταξινομητή αποθηκεύονται όπως προαναφέρθηκε, σε ένα πίνακα που είναι γνωστός ως confusion matrix. Παράδειγμα ενός τέτοιου πίνακα που ταιριάζει με την παρούσα μεταπτυχιακή διατριβή είναι ο παρακάτω (Εικόνα 6).

		Predicted class			
		class 1	class 2	class 3	class 4
Actual class	class 1	TP1	E <sub>1-2</sub>	E <sub>1-3</sub>	E <sub>1-4</sub>
	class 2	E <sub>2-1</sub>	TP2	E <sub>2-3</sub>	E <sub>2-4</sub>
	class 3	E <sub>3-1</sub>	E <sub>3-2</sub>	TP3	E <sub>3-4</sub>
	class 4	E <sub>4-1</sub>	E <sub>4-2</sub>	E <sub>4-3</sub>	TP4

**Εικόνα 6.** Απεικόνιση Confusion Matrix 4 κλάσεων

Ο πίνακας αποτελείται από τιμές που αφορούν τις εξής καταστάσεις (Delahoz & Labrador 2018).

- True Positives (TP), αναφέρονται στα instances που έχουν ταξινομηθεί σωστά

- True Negatives (TN), αναφέρονται στα instances που έχουν ταξινομηθεί σωστά ως κάποια άλλη κλάση σε σχέση με μία συγκεκριμένη κλάση.
- False Positives (FP), αναφέρονται στα instances που ταξινομήθηκαν λανθασμένα σε μια συγκεκριμένη κλάση ενώ ανήκαν σε διαφορετικές
- False Negatives (FN), αναφέρονται στα instances που έπρεπε να ταξινομηθούν σε μία συγκεκριμένη κλάση, αλλά ταξινομήθηκαν λανθασμένα σε διαφορετικές

Αντιστοιχίζοντας τις παραπάνω τιμές του confusion matrix, ο συνολικός αριθμός των TP's αποτελείται από τιμές της διαγωνίου της [Εικόνας 6](#) που είναι με γκρι χρώμα. Ο συνολικός αριθμός των FP's για μία συγκεκριμένη κλάση αποτελείται από το άθροισμα όλων των τιμών της συγκεκριμένης στήλης που βρίσκεται η κλάση, εκτός από την τιμή του TP. Ο συνολικός αριθμός των FN's για μία συγκεκριμένη κλάση αποτελείται από το άθροισμα όλων των τιμών της συγκεκριμένης γραμμής που βρίσκεται η κλάση, εκτός από την τιμή του TP. Ο συνολικός αριθμός των TN's για μία συγκεκριμένη κλάση αποτελείται από το άθροισμα όλων των τιμών από όλες τις γραμμές και στήλες του confusion matrix, εκτός από τη γραμμή και στήλη της συγκεκριμένης κλάσης ([Εικόνα 7](#))

		TN for Class 2			
		Predicted class			
		class 1	class 2	class 3	class 4
Actual class	class 1	TP1		E <sub>1-3</sub>	E <sub>1-4</sub>
	class 2				
	class 3	E <sub>3-1</sub>		TP3	E <sub>3-4</sub>
	class 4	E <sub>4-1</sub>		E <sub>4-3</sub>	TP4

**Εικόνα 7.** Απεικόνιση Confusion Matrix 4 κλάσεων

Έχοντας ολοκληρωθεί η ανάλυση του confusion matrix και των τιμών του, παρατίθενται οι δείκτες απόδοσης για την αξιολόγηση των αλγορίθμων που θα χρησιμοποιηθούν. Αν και το εργαλείο WEKA εμφανίζει τα αποτελέσματα αυτόματα, κρίνεται σκόπιμο να γίνει αναφορά των τύπων που υπολογίζουν τους δείκτες απόδοσης.

Η ακρίβεια (Accuracy) ενός ταξινομητή ορίζεται από τον κάτωθι τύπο (Delahoz & Labrador 2018):

$$\text{Accuracy} = \text{TN} + \text{TP} / (\text{TP} + \text{TN} + \text{FP} + \text{FN})$$

Η ανάκληση (Recall) ή αλλιώς η ευαισθησία (sensitivity) ή αλλιώς η αναλογία των σωστά ταξινομημένων θετικών instances (TP's) σε ολόκληρο το σύνολο των θετικών instances, ορίζεται από τον κάτωθι τύπο (Delahoz & Labrador 2018):

$$\text{Recall} = \text{TP} / (\text{TP} + \text{FN})$$

Η ακρίβεια (Precision) είναι η αναλογία του αριθμού των σωστά ταξινομημένων θετικών instances προς ολόκληρο το σύνολο των instances που ταξινομήθηκαν ως θετικά και ορίζεται από το κάτωθι τύπο (Delahoz & Labrador 2018):

$$\text{Precision} = \text{TP} / (\text{TP} + \text{FP})$$

Ενδεικτικά οι τύποι της ανάκλησης (Recall) και της ακρίβειας (Precision) για τον confusion matrix ([Εικόνα 6](#)) της μεταπτυχιακής διατριβής μας είναι οι εξής:

$$\text{Recall 1} = \text{TP1} / (\text{TP1} + \text{E1-2} + \text{E1-3} + \text{E1-4})$$

$$\text{Recall 2} = \text{TP2} / (\text{TP2} + \text{E2-1} + \text{E2-3} + \text{E2-4})$$

$$\text{Precision 1} = \text{TP1} / (\text{TP1} + \text{E2-1} + \text{E3-1} + \text{E4-1})$$

$$\text{Precision 2} = \text{TP2} / (\text{TP2} + \text{E1-2} + \text{E3-2} + \text{E4-2})$$

Η Recall 1 αφορά το αποτέλεσμα της πρώτης κλάσης, Recall 2 της δεύτερης κλάσης κ.ο.κ. για τις υπόλοιπες κλάσεις και μετρήσεις.

Μια ακόμη μέτρηση, είναι η F-Measure η οποία προκύπτει από των συνδυασμό των Precision και Recall και ο τύπος του είναι ο κάτωθι (Delahoz & Labrador 2018):

$$\text{F-measure} = 2 * ((\text{Precision} * \text{Recall}) / (\text{Precision} + \text{Recall}))$$

Η μέτρηση F-measure χρησιμοποιήθηκε ως η βασική μέτρηση για την αξιολόγηση και σύγκριση των αλγορίθμων που θα λάβουν χώρα στα πειράματα που θα ακολουθήσουν, αφού αποτελεί έναν αρμονικό μέσο όρο των μετρήσεων της ακρίβειας (precision) και της ανάκλησης (recall) και δεν λειτουργεί με προκατάληψη σε περιπτώσεις που η πλειοψηφία

των δεδομένων ανήκουν σε μία συγκεκριμένη κλάση. Ως επακόλουθο των πλεονεκτημάτων της, καθίσταται η καταλληλότερη μέτρηση μιας και το σύνολο των δεδομένων μας παρουσιάζει μη ισορροπημένες κατανομές κλάσεων (Wickramasinghe et al. 2015B).

Επειδή όπως προαναφέρθηκε, η ακρίβεια ως μέτρηση της απόδοσης προβλημάτων με πολλές κλάσεις και μη ισορροπημένα δεδομένα δεν είναι κατάλληλη από μόνη της ως αξιολόγηση του συστήματος, σημαντική μέτρηση που συμβάλει στην καλύτερη αξιολόγηση είναι και η Kappa statistic. Η μέτρηση αυτή αντισταθμίζει τυχαίες επιτυχημένες προβλέψεις, αποτελώντας χρήσιμη μέτρηση σε προβλήματα πολλών κλάσεων. Η διαφορά της με την ακρίβεια (Accuracy) είναι στην βαθμολόγηση των σωστών ταξινομήσεων. Η ακρίβεια αποτυπώνει ως βαθμολογία της, όλες τις σωστές ταξινομήσεις από όλες τις κλάσεις, ενώ η Kappa statistic βαθμολογεί τις σωστές ταξινομήσεις ξεχωριστά για κάθε κλάση και μετά τις αθροίζει. Οπότε είναι λιγότερο ευαίσθητη στις τυχαίες προβλέψεις που προκαλούνται από τον διαφορετικό αριθμό των instances σε κάθε κλάση. Το εύρος αυτής της μέτρησης κυμαίνεται από -1 έως 1. Η μεγαλύτερη τιμή της, δηλαδή κοντά στο 1 υποδηλώνει υψηλό βαθμό απόδοσης του ταξινομητή (Galar, M et al. 2015, Ozcift & Gulden 2012, Santafe et al. 2015, Wahid et al. 2016).

### **3.8 Επιλογή χαρακτηριστικών**

Η επιλογή των χαρακτηριστικών σε ένα dataset είναι μία πολύ σημαντική και βασική διαδικασία στην μηχανική μάθηση αφού διαδραματίζει μεγάλη επίδραση και επηρεάζει αρκετές φορές την απόδοση του μοντέλου. Για τον λόγο αυτό η επιλογή χαρακτηριστικών και ο καθαρισμός ορισμένων δεδομένων πρέπει να είναι σημαντικό βήμα στον σχεδιασμό ενός μοντέλου.

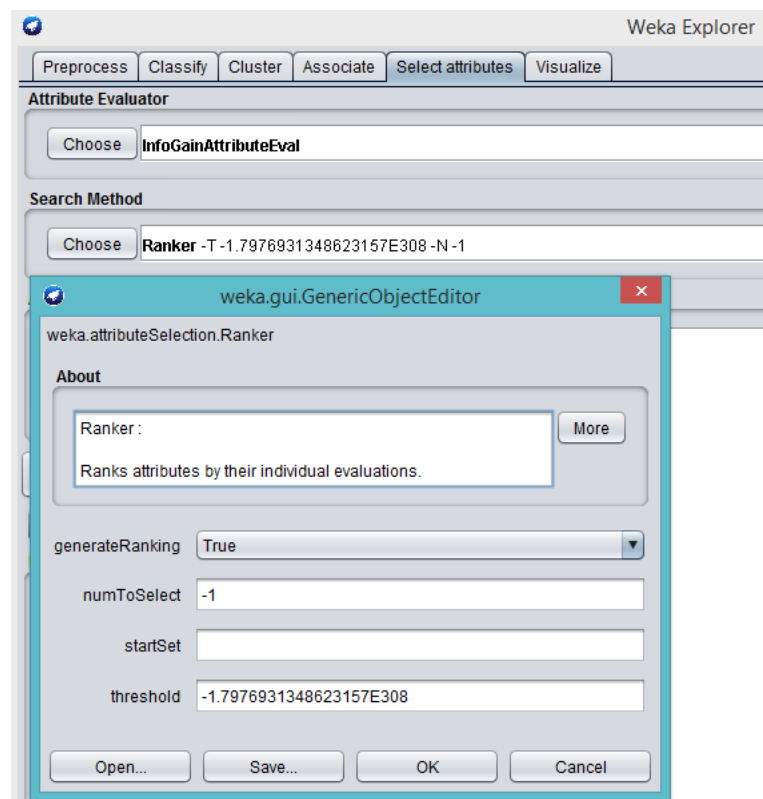
Σκοπός της είναι η μείωση των δεδομένων αφαιρώντας τα χαρακτηριστικά που περισσεύουν όντας μη σχετικά σε ένα σύνολο δεδομένων. Το μέτρο αξιολόγησης χαρακτηριστικών κατηγοριοποιεί της μεθόδους επιλογής, ανάλογα με τον τύπο του φίλτρου (filter) και του περιτυλίγματος (wrapper). Λόγω της ταχύτητας και της καταλληλότητας σε δεδομένα μεγάλου μεγέθους, η μέθοδος του φίλτρου (filter) είναι αυτή που χρησιμοποιείται στην παρούσα μεταπτυχιακή διατριβή (Al Janabi & Kadhim 2018).



Η επιλογή ενός υποσυνόλου χαρακτηριστικών και η αξιολόγηση της ποιότητάς τους στη χρήση των μεθόδων φιλτραρίσματος που βασίζονται στα χαρακτηριστικά των δεδομένων, είναι ανεξάρτητη από τον αλγόριθμο ταξινόμησης. Οι μέθοδοι επιλογής χαρακτηριστικών κατηγοριοποιούνται στην αξιολόγηση ενός μόνο χαρακτηριστικού ή ενός υποσυνόλου, αναλόγως του τρόπου που γίνεται η εκτίμησή τους. Στην αξιολόγηση ενός μόνο χαρακτηριστικού, βαθμονομείται μεμονωμένα κάθε ένα από αυτά, μέσω της απόδοσης του ειδικής βαρύτητας (weight) σύμφωνα με το βαθμό συνάφειας και η μέθοδος αυτή ονομάζεται κατάταξη (ranking) ή βαρύτητα (weighting) χαρακτηριστικών. Η δεύτερη μέθοδος, δηλαδή η αξιολόγηση υποσυνόλου όπως αναφέρει και το όνομα της αξιολογεί περισσότερα από ένα χαρακτηριστικά (Al Janabi & Kadhim 2018).

#### **Μέθοδος αναζήτησης Ranker**

Οι μέθοδοι κατάταξης (Rankers) αξιολογούν αυτόνομα χαρακτηριστικά, ταξινομώντας τα σύμφωνα με το σκορ τους και χρησιμοποιούνται πάντα μαζί με τους αξιολογητές χαρακτηριστικών (OneR, GainRatio, ReliefF κ.α.). Όπως φαίνεται και στην [Εικόνα 8](#) οι μέθοδοι κατάταξης συνοδεύονται με ορισμένες βασικές παραμέτρους όπως η τιμή του κατωφλίου (threshold) βάσει του οποίου απορρίπτονται χαρακτηριστικά και ο αριθμός επιλογής (number to select) που δηλώνει το πλήθος των χαρακτηριστικών, τα οποία είναι ταξινομημένα με φθίνουσα διάταξη ως προς την βαρύτητά τους, που θέλουμε να κρατήσουμε στο σύνολο δεδομένων (Dinakaran & Thangaiah 2013).



**Εικόνα 8.** Παράμετροι των μεθόδων Rankers στο WEKA

Επομένως η επιλογή χαρακτηριστικών είναι μία διαδικασία που προσφέρει πλεονεκτήματα όπως την ευκολότερη κατανόηση της σημαντικότητας των δεδομένων, την μείωση του χρόνου δημιουργίας του μοντέλου και τη βελτίωση της απόδοσης των αλγορίθμων λόγω της μείωσης των διαστάσεων.

### **Μέθοδοι επιλογής χαρακτηριστικών**

Αρκετές είναι οι τεχνικές για την επιλογή χαρακτηριστικών με την ανάλυση ορισμένων από τις οποίες εφαρμόστηκαν στη παρούσα μεταπτυχιακή διατριβή να ακολουθεί.

### **Correlation based Feature Selection(CFS)**

Αυτή τεχνική υλοποιεί επιλογή ενός υποσυνόλου χαρακτηριστικών από το σύνολο των δεδομένων του εκάστοτε προβλήματος. Η λειτουργία του βασίζεται στον υπολογισμό της συσχέτισης μεταξύ όλων των χαρακτηριστικών και της κλάσης με τη χρήση ευρετικής αξιολόγησης. Το καλύτερο υποσύνολο είναι αυτό που τα χαρακτηριστικά του εξαρτώνται

σε υψηλό βαθμό με την κλάση και σχετίζονται ελάχιστα με άλλα χαρακτηριστικά (Al Janabi & Kadhim 2018).

### **Information Gain (IG)**

Η τεχνική αυτή δημιουργεί ένα δέντρο αποφάσεων (ID3) όπου σε κάθε κόμβο επιλέγεται ένα χαρακτηριστικό μετά από δοκιμή. Δηλαδή σε κάθε κόμβο βάσει του υπολογισμού του IG αποφασίζεται το χαρακτηριστικό που θα επιλέξει τον διαχωρισμό που θα γίνει στον συγκεκριμένο κόμβο. Οπότε το χαρακτηριστικό με τη μεγαλύτερη τιμή IG αυτομάτως ελαχιστοποιεί τα δεδομένα που καλούνται να ταξινομηθούν μετά τη διάσπαση και μειώνει την τυχαία ταξινόμησή τους (Al Janabi & Kadhim 2018).

### **Gain Ratio(GR) attribute evaluations**

Αυτή η τεχνική είναι μια επέκταση της μέτρησης IG και πιο συγκεκριμένα ξεπερνά τη μεροληψία της μέτρησης IG εφαρμόζοντας κανονικοποίηση στα χαρακτηριστικά με μεγάλο αριθμό τιμών (Al Janabi & Kadhim 2018).

### **One-R (One Rule)**

Σε αυτό την τεχνική το ποσοστό σφάλματος είναι ο βασικός παράγοντας για την αξιολόγηση των χαρακτηριστικών. Αναλυτικότερα, η λογική βασίζεται στη δημιουργία ορισμένων κανόνων για τα χαρακτηριστικά, και πιο συγκεκριμένα ένας κανόνας για κάθε ένα και στη συνέχεια ο αλγόριθμος επιλέγει τον κανόνα με την μικρότερη αναλογία σφάλματος (Al Janabi & Kadhim 2018).

### **Relief-F**

Είναι μία τεχνική που επιλέγει τυχαία ένα στιγμιότυπο και στη συνέχεια αναζητά ένα ή περισσότερα (k) γειτονικά στιγμιότυπα δεδομένων από κάθε κλάση. Στη συνέχεια ενημερώνει την βαθμονόμηση της βαρύτητας όλων των χαρακτηριστικών αναλόγως από τις τιμές του στιγμιότυπου, των πλησιέστερων γειτόνων της ίδιας κλάσης και των πλησιέστερων γειτόνων διαφορετικών κλάσεων. Αναλόγως αν το γειτονικό ζευγάρι στιγμιότυπων είναι της ίδιας κλάσης ή διαφορετικής, η βαθμολογία των χαρακτηριστικών αυξάνεται ή μειώνεται. Η τεχνική αυτή λειτουργεί καλά σε προβλήματα πολλαπλών κλάσεων (Al Janabi & Kadhim 2018, Durgabai 2014).

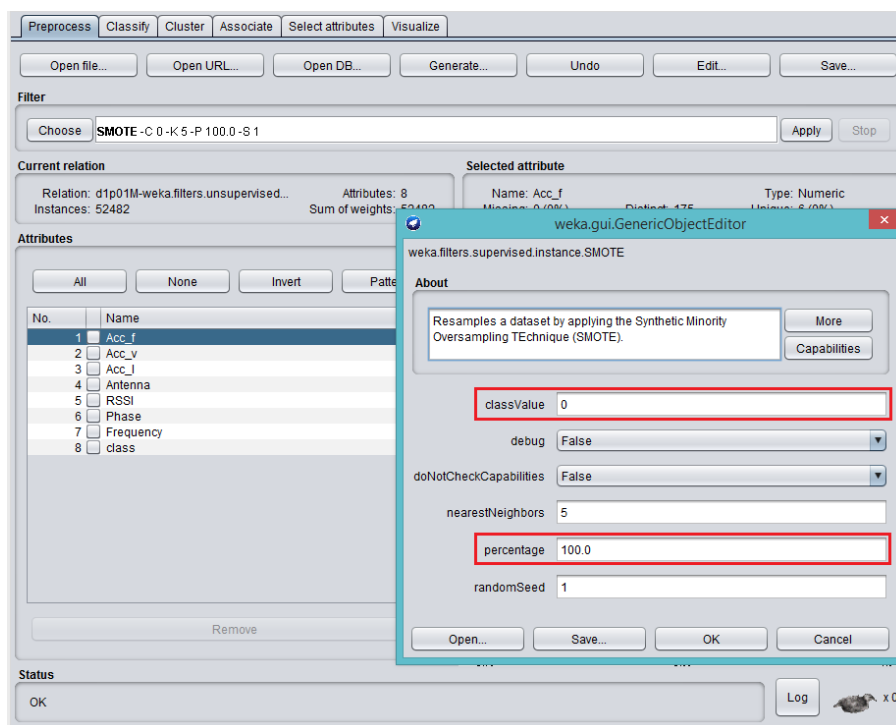
### 3.9 Τεχνικές βελτίωσης της απόδοσης σε ταξινομητές που εφαρμόζονται σε μη ισορροπημένα δεδομένα

Οι τεχνικές της υποδειγματοληψίας (undersampling) και της υπερδειγματοληψίας (oversampling), είναι τεχνικές που χρησιμοποιούνται συχνά στο χειρισμό μη ισορροπημένων συνόλων δεδομένων. Η υπερδειγματοληψία αναπαράγει τις περιπτώσεις των κλάσεων που είναι σε μειοψηφία ενώ η υποδειγματοληψία απορρίπτει περιπτώσεις κλάσεων που είναι σε πλειοψηφία. Και οι δύο τεχνικές έχουν μειονεκτήματα, αφού με την υποδειγματοληψία απορρίπτονται πιθανώς χρήσιμα δεδομένα και με την υπερδειγματοληψία δημιουργούνται αντίγραφα υπάρχουσών στιγμιότυπων (instances), καθιστώντας ενδεχομένως την εμφάνιση του φαινομένου της υπερφόρτωση (over-fitting). Λόγω του γεγονότος ότι οι μέθοδοι υπερδειγματοληψίας παρέχουν ακριβέστερα αποτελέσματα από ότι οι μέθοδοι υποδειγματοληψία θα γίνει χρήση του αλγορίθμου υπερδειγματοληψίας SMOTE (Synthetic Minority Oversampling TEchnique), ο οποίος, βάσει ερευνών, μπορεί να επιτύχει καλύτερη απόδοση ταξινομητή από την υποδειγματοληψία (Shi, D et al. 2015).

Η τεχνική SMOTE όπως αναφέρει και η ονομασία της βασίζεται στη συνθετική υπερδειγματοληψία της κλάσης που αφορά την μειονότητα του συνόλου δεδομένων ώστε να ωθήσει τον ταξινομητή να δημιουργήσει μεγαλύτερες περιοχές αποφάσεων. Με αυτό τον τρόπο οι περιοχές θα περιέχουν περισσότερα στιγμιότυπα στην κλάση που μειοψηφεί, επομένως η μεγαλύτερη κάλυψη της συγκεκριμένης κλάσης θα συντελέσει στην καλύτερη εκμάθηση (Shi, D et al. 2015).

Η τεχνική αυτή στο εργαλείο WEKA, έχοντας την τιμή 0 στην παράμετρο classValue ([Εικόνα 9](#)), αναγνωρίζει την κλάση που μειοψηφεί και προσθέτει τόσα νέα στιγμιότυπα σε ποσοστό επί της μειοψηφούσας κλάσης, όσα αναφέρει η τιμή της παραμέτρου Percentage ([Εικόνα 9](#)). Αλλάζοντας την τιμή της παραμέτρου classValue, δίνεται η δυνατότητα καθορισμού της κλάσης, βάσει της οποίας θα δημιουργηθούν τα νέα στιγμιότυπα. Τα νέα στιγμιότυπα προστίθενται στο τέλος των δεδομένων ενός συνόλου δεδομένων, με

αποτέλεσμα να υπάρχει ο κίνδυνος εμφάνισης του εξής προβλήματος. Χρησιμοποιώντας την μέθοδο k-fold cross validation και ειδικά αν τα νέα στιγμιότυπα είναι αρκετά σε πλήθος, υπάρχει η πιθανότητα κάποιο από τα υποσύνολα που χρησιμοποιεί η μέθοδος, να περιέχει μόνο στιγμιότυπα της ίδιας κλάσης, γεγονός που πρέπει να αποφεύγεται. Για το λόγο αυτό κρίνεται σκόπιμο μετά την εφαρμογή της SMOTE, να εφαρμόζεται η τεχνική Randomize, η οποία ανακατεύει τυχαία τα στιγμιότυπα του συνόλου δεδομένων.

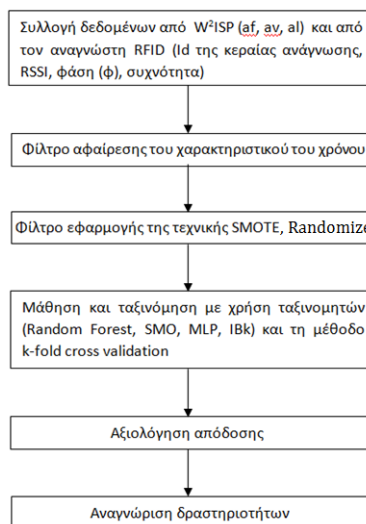


**Εικόνα 9.** Παράμετροι της τεχνικής SMOTE

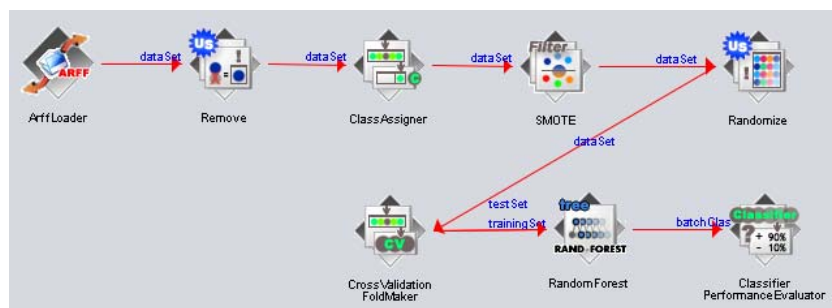
Μία ακόμη τεχνική είναι η τεχνική Cost-Sensitive. Στο WEKA υλοποιείται μέσω του ταξινομητή CostSensitiveClassifier που ανήκει στους meta ταξινομητές και η αρχή λειτουργίας του βασίζεται σε δύο μεθόδους. Η πρώτη είναι ο επανυπολογισμός των δεδομένων εκπαίδευσης όσο αναφορά το συνολικό κόστος που έχει ανατεθεί σε κάθε κλάση και η δεύτερη είναι η πρόβλεψη της κλάσης με το μικρότερο αναμενόμενο κόστος λανθασμένης πρόβλεψης (Shi, D et al. 2015).

### 3.10 Διάγραμμα ροής του μοντέλου αναγνώρισης δραστηριοτήτων

Σύμφωνα με τις Εικόνες [10](#), [11](#) που ακολουθούν, συλλέγονται τα δεδομένα από το τρισδιάστατο επιταχυνσιόμετρο και από τον αναγνώστη RFID. Το σύνολο δεδομένων υπόκειται σε φίλτρο αφαίρεσης χαρακτηριστικών, για την αφαίρεση του χαρακτηριστικού του χρόνου και στη συνέχεια εφαρμόζονται τα φίλτρα SMOTE και Randomize για να προβεί στην υπερδειγματοληψία της κλάσης που αφορά την μειονότητα. Ακολουθεί η χρήση διάφορων αλγορίθμων που κάνουν χρήση της μεθόδου k-fold cross validation για τη δημιουργία του μοντέλου πρόβλεψης των δραστηριοτήτων των ασθενών.



Εικόνα 10. Διάγραμμα ροής του μοντέλου ανίχνευσης δραστηριοτήτων



Εικόνα 11. Απεικόνιση του μοντέλου ανίχνευσης δραστηριοτήτων στο περιβάλλον KnowledgeFlow του WEKA

# 4. Αποτελέσματα πειραμάτων

Σε αυτή την ενότητα θα εξεταστούν και θα συγκριθούν οι επιδόσεις των διάφορων αλγορίθμων εποπτευόμενης μηχανικής μάθησης για την αναγνώριση συγκεκριμένων δραστηριοτήτων των ασθενών. Μέσω της σύγκρισης θα επισημανθούν οι διαφορετικές επιδόσεις των αλγορίθμων που χρησιμοποιήθηκαν βάσει ορισμένων μετρήσεων αξιολόγησης που προαναφέρθηκαν, όπως η F-measure, η ανάκληση (recall), η ακρίβεια (precision) και η Kappa Statistic.

Στην παρούσα μεταπτυχιακή διατριβή εφαρμόστηκε για όλα τα πειράματα που διεξήχθησαν η μέθοδος k-fold cross validation με την τιμή του k να είναι 10, ως εκ τούτου εκτελέστηκε 10 φορές η εξής διαδικασία. Το σύνολο δεδομένων διαχωριζόταν σε 10 τμήματα, εκ των οποίων τα 9 από αυτά αποτελέσουν δεδομένα εκπαίδευσης και το ένα που απέμενε ήταν τα δεδομένα δοκιμής. Η τιμή 10 για το k ήταν η βέλτιστη επιλογή, συγκρίνοντας τα αποτελέσματα που προέκυψαν με το k να παίρνει τις τιμές 5, 10, 15.

## 4.1 Παραμετροποίηση αλγορίθμων στο WEKA

Για την επιλογή των τιμών των παραμέτρων διεξήχθησαν αρκετές δοκιμές με αλλαγές τιμών σε διάφορες παραμέτρους και επιλέχθηκαν αυτές που συντέλεσαν στην καλύτερη απόδοση των αλγορίθμων.

Στον αλγόριθμο Random Forest (RF) παρόλο τις διάφορες δοκιμές που πραγματοποιήθηκαν με τις αλλαγές σε διάφορες παραμέτρους του, όπως η παράμετρος numFeatures που δηλώνει τον αριθμό των χαρακτηριστικών που πρέπει να ληφθούν υπόψη σε κάθε σημείο διάσπασης, η μέγιστη απόδοση επιτεύχθηκε με τις προεπιλεγμένες παραμέτρους στα αρχεία δεδομένων και στα δύο δωμάτια.

Στον αλγόριθμο Support Vector Machine (SMO) ύστερα από δοκιμές, οι παράμετροι που επηρέασαν θετικά την απόδοσή του στα σύνολα δεδομένων και στα δύο δωμάτια είναι η παράμετρος  $c$  και η  $kernel$ . Η παράμετρος  $c$  μεταφράζεται στην πολυπλοκότητα που χρησιμοποιεί ο SMO για να κατασκευάσει τη διαχωριστική γραμμή (hyperplane). Στο Room1 η τιμή 5 συντέλεσε για την καλύτερη απόδοση, ενώ στο Room2 η τιμή αυτή είναι η τιμή 10. Η επιλογή του  $kernel$  PUK στις δοκιμές που αφορούσαν και τα δύο δωμάτια, σε σχέση με τους υπόλοιπους γνωστούς πυρήνες όπως οι PolyKernel, RBF κ.α. υπερίσχυσε, βελτιώνοντας τις τιμές των μετρήσεων αξιολόγησης του αλγορίθμου.

Στον αλγόριθμο k-nearest neighbor (1Bk), τα πειράματα βασίστηκαν στις αλλαγές της τιμής  $k$ , δηλαδή του αριθμού των πλησιέστερων γειτόνων που χρησιμοποιούνται για την πρόβλεψη της απόδοσης τάξης. Η παράμετρος αυτή αναλόγως της τιμής της, ήταν κομβική στο βαθμό μεταβολής της απόδοσης του αλγορίθμου. Στο Room1 ο αλγόριθμος κατέλαβε τον μεγαλύτερο βαθμό αποτελεσματικότητας με την τιμή του  $k$  να είναι 1, που είναι και η προεπιλεγμένη τιμή, ενώ στο Room2 ο αλγόριθμος πέτυχε την υψηλότερη απόδοσή του με την τιμή του  $k$  να είναι 3.

Στον αλγόριθμο MultilayerPerceptron (MLP) η απόδοση του παρουσίαζε μεταβολές κατά κύριο λόγο στην αλλαγή της παραμέτρου  $hiddenLayers$ . Η παράμετρος αυτή που πρέπει να είναι πάντα θετικός ακέραιος αριθμός ή 0, υποδηλώνει το αριθμό των κρυμμένων στρωμάτων ( $hidden\ layers$ ) του νευρωνικού δικτύου και το αριθμό των κόμβων - νευρώνων ( $neurons$ ) για κάθε επίπεδο. Εκτός από τους ακέραιους αριθμούς υπάρχουν και κάποιες άλλες τιμές όπως η προεπιλεγμένη τιμή που έχει ο αλγόριθμος 'a' που ισούται με  $(\text{παράμετροι} + \text{κλάσεις})/2$ , η τιμή 'o' που ισούται με το αριθμό των κλάσεων, η τιμή 'i' που ισούται με τον αριθμό των παραμέτρων και η τιμή 't' που ισούται με το άθροισμα των παραμέτρων και των κλάσεων. Στα πειράματα που πραγματοποιήθηκαν, η τιμή  $t$  συντέλεσε της αποδοτικότερη λειτουργία του αλγορίθμου και στα δύο δωμάτια.

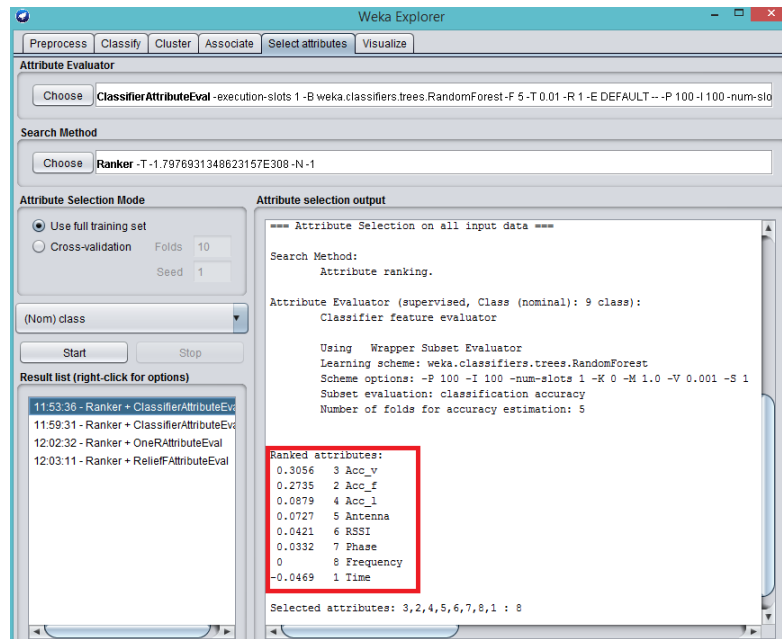
## **4.2 Αποτελέσματα μετρήσεων των αλγορίθμων με χρήση διαφορετικού πλήθους χαρακτηριστικά.**



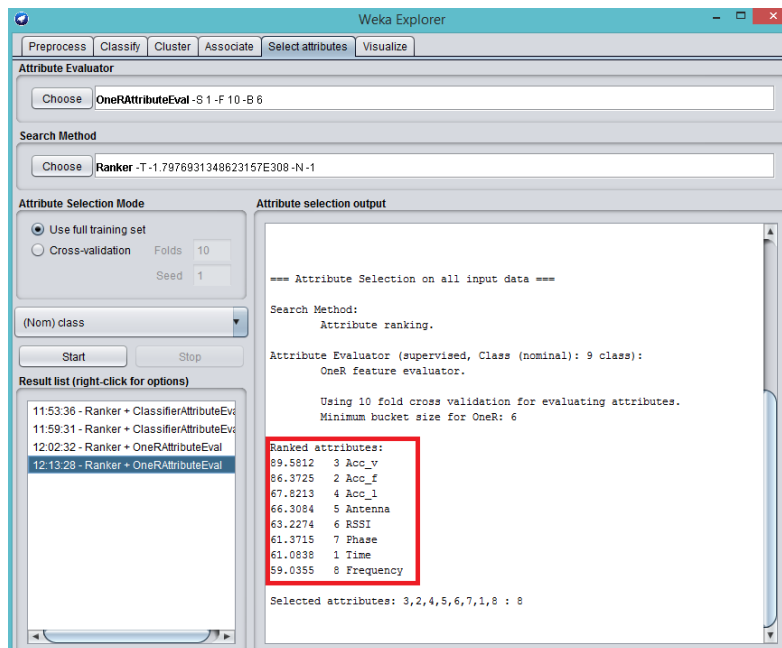
Στην παρούσα μεταπτυχιακή διατριβή πραγματοποιήθηκε συνδυασμός όλων των αρχείων για κάθε ένα από τα datasets των δύο δωματίων. Ως αποτέλεσμα έχουμε για το Room1, μόνο ένα αρχείο που περιέχει τα instances και των 60 αρχείων, οπότε και τα δεδομένα από όλους τους ασθενείς. Παρομοίως για το Room2 έχουμε άλλο ένα αρχείο που περιέχει όλα τα instances των 27 αρχείων. Η λογική αυτή ακολουθήθηκε για να έχουμε ένα πληρέστερο και πιο ανταγωνιστικό σύνολο δεδομένων από την οπτική γωνία ότι θα καλύπτει αρκετά περισσότερες περιπτώσεις.

Ο χρόνος που αποτελεί το πρώτο χαρακτηριστικό του συνόλου δεδομένων, είναι άμεσα συνδεδεμένο με τον εκάστοτε ασθενή που έγιναν οι μετρήσεις και πιθανώς να είναι ένα σημαντικό χαρακτηριστικό σε ένα σύνολο δεδομένων που αφορούν έναν μόνο ασθενή ή σε περιπτώσεις που κάθε ένα από τα αρχεία του dataset εξετάζοταν ξεχωριστά. Επίσης σίγουρα αποτελεί σημαντικό χαρακτηριστικό σε περιπτώσεις που η χρήση ορισμένων αλγορίθμων απαιτούν και λαμβάνουν υπόψη την προηγούμενη κατάσταση για να προβούν στην ταξινόμηση νέων δεδομένων. Σε αυτή την περίπτωση η κατάσταση για την χρονική στιγμή  $t-1$  είναι χρήσιμη πληροφορία για την αξιολόγηση της κατάστασης την χρονική στιγμή  $t$ .

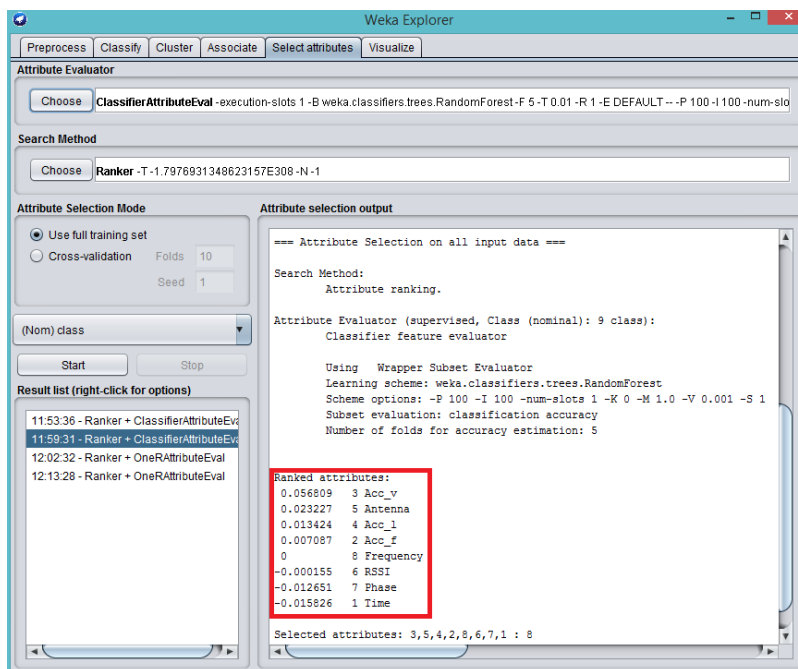
Στην μεταπτυχιακή διατριβή όμως επειδή τα αρχεία είναι ενιαία και δεν αφορούν ένα μόνο ασθενή, καθώς επίσης και οι αλγόριθμοι που χρησιμοποιήθηκαν δεν ακολουθούν τον τρόπο λειτουργίας αλγορίθμων που απαιτούν την προηγούμενη κατάσταση, κρίθηκε σκόπιμο το χαρακτηριστικό του χρόνου να αφαιρεθεί από τα σύνολα δεδομένων. Για την επικύρωση της ενέργειας αυτής πραγματοποιήθηκε και επιλογή χαρακτηριστικών μέσω διάφορων μεθόδων κατάταξης (rankers) του WEKA, η οποία επιβεβαίωσε την επιλογή αυτή, αφού στις περισσότερες περιπτώσεις το χαρακτηριστικό του χρόνου αξιολογήθηκε ως τελευταίο ή από τα τελευταία στην κατάταξη, όπως φαίνεται και στις Εικόνες [12](#), [13](#), [14](#), [15](#) που ακολουθούν.



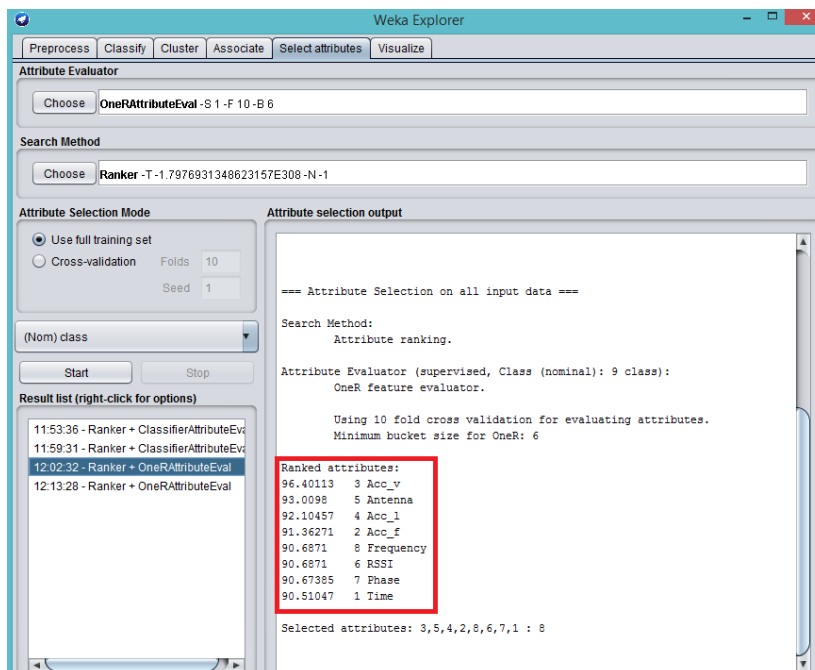
Εικόνα 12. Κατάταξη χαρακτηριστικών για το dataset του 1ου δωματίου με ClassifierAttributeEvaluator



Εικόνα 13. Κατάταξη χαρακτηριστικών για το dataset του 1ου δωματίου με OneRAttributeEvaluator



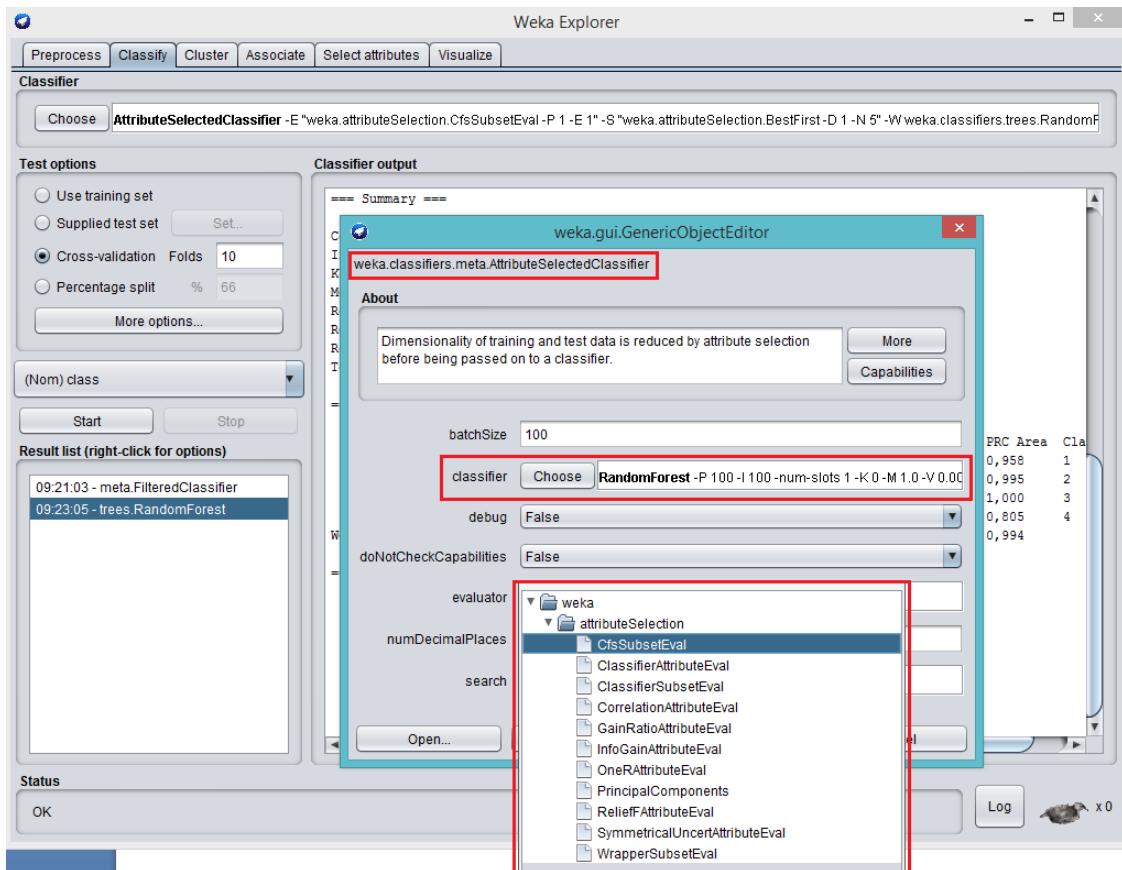
Εικόνα 14. Κατάταξη χαρακτηριστικών για το dataset του 2ου δωματίου με ClassifierAttributeEvaluator



Εικόνα 15. Κατάταξη χαρακτηριστικών για το dataset του 2ου δωματίου με OneRAttributeEvaluator

Λόγω της αφαίρεσης ενός χαρακτηριστικού από τα σύνολα δεδομένων των δωματίων, δηλαδή αυτό του χρόνου, πραγματοποιήθηκαν δοκιμές ταξινόμησης με τον αλγόριθμο AttributeSelectedClassifier. Ο αλγόριθμος αυτός, που είναι ένας meta ταξινομητής, ενσωματώνει τη διαδικασία επιλογής παραμέτρων με τη διαδικασία της ταξινόμησης ([Εικόνα 16](#)). Επίσης ο αλγόριθμος αυτός επιλέγει παραμέτρους που βασίζονται μόνο στο σύνολο δεδομένων που αφορά το στάδιο της εκπαίδευσης, ακόμη και στις περιπτώσεις που εφαρμόζεται η μέθοδος cross validation. Η υλοποίηση αυτή είχε ως στόχο να δημιουργηθούν μοντέλα που θα χρησιμοποιούν δεδομένα με διαφορετικό πλήθος παραμέτρων. Το πλήθος θα είναι 3, 4, 5 και 8 παράμετροι. Έτσι θα έχουμε μία πιο ολοκληρωμένη εικόνα με αποτελέσματα, για να μπορέσει να γίνει σύγκριση των μοντέλων που θα δημιουργηθούν, με αυτά της βασικής μας υπόθεσης όπου το σύνολο δεδομένων περιέχει 7 παραμέτρους. Στον αριθμό του πλήθους των χαρακτηριστικών που αναφέρθηκαν δεν περιλαμβάνεται η παράμετρος της κλάσης.

Η τεχνική AttributeSelectedClassifier χρησιμοποιήθηκε με πέντε τεχνικές αξιολόγησης και δύο μεθόδους αναζήτησης, όπου CFSSubsetEval, Information Gain, GainRatio, One-R και Relief-F είναι οι τεχνικές αξιολόγησης και ο Best First και ο Ranker οι μέθοδοι αναζήτησης. Η ανάλυσή τους έχει ήδη προηγηθεί. Οι ρυθμίσεις για τους αλγορίθμους ταξινόμησης δεν αναφέρονται, γιατί είναι ίδιες με τις ρυθμίσεις των αλγορίθμων του βασικού πειράματος όπου τα δεδομένα θα περιέχουν 7 παραμέτρους και έχουν ήδη παρουσιαστεί.



**Εικόνα 16.** Χρήση του αλγορίθμου AttributeSelectedClassifier στο περιβάλλον WEKA

Στις εικόνες [17](#), [18](#) που ακολουθούν παρουσιάζονται ορισμένες μετρήσεις της απόδοσης των τεσσάρων αλγορίθμων και ο αριθμός των χαρακτηριστικών που επιλέχθηκαν από τις μεθόδους επιλογής παραμέτρων. Πιο συγκεκριμένα η [Εικόνα 17](#) αφορά το σύνολο δεδομένων του Room1 και η [Εικόνα 18](#) το σύνολο δεδομένων του Room2. Μέσω της τεχνικής αξιολόγησης CFS έγινε επιλογή 4 χαρακτηριστικών για τα δεδομένα του Room1 και 3 χαρακτηριστικών για το Room2. Για τις τεχνικές Information Gain, GainRatio, One-R και Relief-F που χρησιμοποιούν την μέθοδο αναζήτησης Ranker, μέσω της παραμέτρου "numToSelect" επιλέχθηκε αρχικά ο αριθμός των 5 χαρακτηριστικών και στη συνέχεια επιλέχθηκαν όλα τα χαρακτηριστικά, δηλαδή 8.

ROOM1					
Algorithm	Selection method	No of features	Precision	Recall	F-measure
RandomForest	CFS Subset Evaluator	4	0,924	0,904	0,914
	Information Gain Ranking	5	0,982	0,966	0,974
	GainRatioAttributeEval	5	0,98	0,965	0,972
	OneR feature evaluator	5	0,981	0,965	0,973
	ReliefFAttributeEval	5	0,983	0,967	<b>0,975</b>
	Information Gain Ranking	8	0,985	0,964	0,974
	GainRatioAttributeEval	8	0,985	0,964	0,974
	OneR feature evaluator	8	0,985	0,964	0,974
	ReliefFAttributeEval	8	0,985	0,964	0,974
SMO	CFS Subset Evaluator	4	0,863	0,747	0,801
	Information Gain Ranking	5	0,953	0,866	0,907
	GainRatioAttributeEval	5	0,96	0,878	0,917
	OneR feature evaluator	5	0,96	0,878	0,917
	ReliefFAttributeEval	5	0,962	0,887	0,923
	Information Gain Ranking	8	0,972	0,912	<b>0,941</b>
	GainRatioAttributeEval	8	0,972	0,912	0,941
	OneR feature evaluator	8	0,972	0,912	0,941
	ReliefFAttributeEval	8	0,972	0,912	0,941
MultilayerPerceptron	CFS Subset Evaluator	4	0,865	0,775	0,818
	Information Gain Ranking	5	0,94	0,88	0,909
	GainRatioAttributeEval	5	0,947	0,891	0,918
	OneR feature evaluator	5	0,947	0,893	0,919
	ReliefFAttributeEval	5	0,952	0,897	0,924
	Information Gain Ranking	8	0,956	0,908	<b>0,931</b>
	GainRatioAttributeEval	8	0,956	0,908	0,931
	OneR feature evaluator	8	0,956	0,908	0,931
	ReliefFAttributeEval	8	0,956	0,908	0,931
IBK	CFS Subset Evaluator	4	0,911	0,893	0,902
	Information Gain Ranking	5	0,973	0,964	0,968
	GainRatioAttributeEval	5	0,971	0,962	0,966
	OneR feature evaluator	5	0,971	0,962	0,966
	ReliefFAttributeEval	5	0,973	0,964	<b>0,968</b>
	Information Gain Ranking	8	0,968	0,95	0,959
	GainRatioAttributeEval	8	0,968	0,95	0,959
	OneR feature evaluator	8	0,968	0,95	0,959
	ReliefFAttributeEval	8	0,968	0,95	0,959

**Εικόνα 17.** Αποτελέσματα τεσσάρων αλγορίθμων ύστερα από την εφαρμογή διάφορων μεθόδων επιλογής παραμέτρων στο Room1


ROOM2					
Algorithm	Selection method	No of features	Precision	Recall	F-measure
RandomForest	CFS Subset Evaluator	3	0,851	0,833	0,842
	Information Gain Ranking	5	0,918	0,901	<b>0,909</b>
	GainRatioAttributeEval	5	0,915	0,877	0,896
	OneR feature evaluator	5	0,892	0,871	0,881
	ReliefFAttributeEval	5	0,915	0,886	0,900
	Information Gain Ranking	8	0,919	0,883	0,901
	GainRatioAttributeEval	8	0,919	0,883	0,901
	OneR feature evaluator	8	0,919	0,883	0,901
	ReliefFAttributeEval	8	0,919	0,883	0,901
SMO	CFS Subset Evaluator	3	0,831	0,795	0,813
	Information Gain Ranking	5	0,868	0,831	0,849
	GainRatioAttributeEval	5	0,911	0,839	<b>0,874</b>
	OneR feature evaluator	5	0,843	0,812	0,827
	ReliefFAttributeEval	5	0,9	0,839	0,868
	Information Gain Ranking	8	0,88	0,844	0,862
	GainRatioAttributeEval	8	0,88	0,844	0,862
	OneR feature evaluator	8	0,88	0,844	0,862
	ReliefFAttributeEval	8	0,88	0,844	0,862
MultilayerPerceptron	CFS Subset Evaluator	3	0,829	0,803	0,816
	Information Gain Ranking	5	0,844	0,817	0,830
	GainRatioAttributeEval	5	0,887	0,832	0,859
	OneR feature evaluator	5	0,834	0,811	0,822
	ReliefFAttributeEval	5	0,879	0,83	0,854
	Information Gain Ranking	8	0,907	0,85	<b>0,878</b>
	GainRatioAttributeEval	8	0,907	0,85	0,878
	OneR feature evaluator	8	0,907	0,85	0,878
	ReliefFAttributeEval	8	0,907	0,85	0,878
IBK	CFS Subset Evaluator	3	0,815	0,79	0,802
	Information Gain Ranking	5	0,874	0,848	0,861
	GainRatioAttributeEval	5	0,898	0,854	<b>0,875</b>
	OneR feature evaluator	5	0,836	0,792	0,813
	ReliefFAttributeEval	5	0,888	0,851	0,869
	Information Gain Ranking	8	0,88	0,823	0,851
	GainRatioAttributeEval	8	0,88	0,823	0,851
	OneR feature evaluator	8	0,88	0,823	0,851
	ReliefFAttributeEval	8	0,88	0,823	0,851

**Εικόνα 18.** Αποτελέσματα τεσσάρων αλγορίθμων ύστερα από την εφαρμογή διάφορων μεθόδων επιλογής παραμέτρων στο Room2


Σύμφωνα με την [Εικόνα 17](#), στο Room1 η υψηλότερη τιμή ακρίβειας (precision) επιτεύχθηκε με τον ταξινομητή Random Forest, τις τεχνικές Information Gain, GainRatio, One-R, Relief-F και με την χρήση και των 8 παραμέτρων και είναι 0,985. Η μεγαλύτερη τιμή της μέτρησης Recall είναι η 0,967 η οποία πραγματοποιήθηκε από τον ταξινομητή RandomForest, την τεχνική ReliefF και με την χρήση 5 παραμέτρων.

Ακολουθώντας, στο Room 2 και πάντα με τα αποτελέσματα της [Εικόνα 18](#), η υψηλότερη τιμή ακρίβειας (precision) βρίσκεται στο ταξινομητή RandomForest με τεχνικές Information Gain, GainRatio, One-R, Relief-F και με την χρήση και των 8 παραμέτρων και είναι 0,919. Η μέτρηση Recall καταλαμβάνει την μέγιστη τιμή της 0,901 με τον ταξινομητή RandomForest, την τεχνική Information Gain και με την χρήση 5 παραμέτρων.


Στις εικόνες [19-26](#) που ακολουθούν απεικονίζονται οι τιμές της μέτρησης F-measure σε συνάρτηση με το αριθμό των χαρακτηριστικών. Ο κατακόρυφος άξονας y έχει τις τιμές της μέτρησης F-measure και ο οριζόντιος άξονας x το πλήθος των παραμέτρων. Ξεχωριστές εικόνες υπάρχουν για κάθε ταξινομητή και για τα δύο δωμάτια.




Εικόνα 19




Εικόνα 20




Εικόνα 21



Εικόνα 22




Εικόνα 23




Εικόνα 24





Εικόνα 25



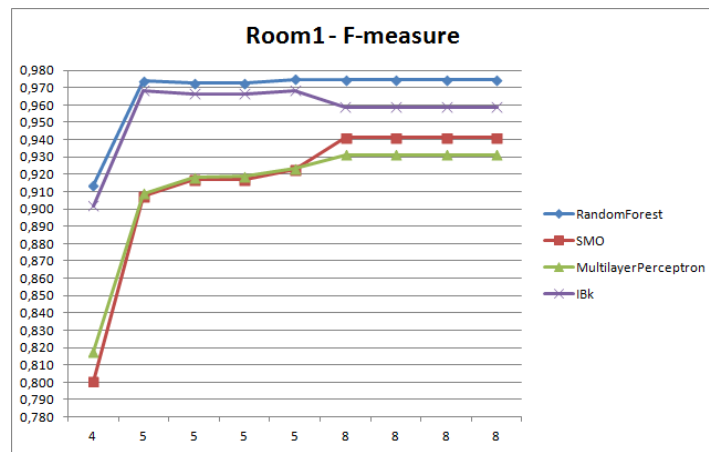
Εικόνα 26

Παρατηρώντας τη τιμή της μέτρησης F-measure για τους αλγορίθμους που εφαρμόστηκαν στα δεδομένα του Room1, βλέπουμε ότι οι τιμές της συγκεκριμένης μέτρησης είτε αναφερόμαστε σε χρήση δεδομένων που περιέχουν 5 παραμέτρους είτε σε 8, είναι σχεδόν ίδιες. Με τον RandomForest και τον IBk, οι μέγιστες τιμές έχουν επιτευχθεί με δεδομένα 5 παραμέτρων, ενώ με το SMO και τον MultilayerPerceptron οι μέγιστες τιμές αντιστοιχούν σε δεδομένα 8 παραμέτρων. Η τιμές που έκαναν χρήση 4 παραμέτρων για όλους τους αλγορίθμους είναι αισθητά μειωμένη σε σχέση με τις μέγιστες τιμές ανά αλγόριθμο, γεγονός που υποδηλώνει την αναγκαιότητα χρήσης περισσότερων παραμέτρων. Συνολικά στο Room1 η μέγιστη τιμή της F-measure σε σχέση με όλους του αλγορίθμους είναι η 0,975 και είναι αποτέλεσμα του ταξινομητή RandomForest και της χρήσης δεδομένων 5 παραμέτρων που επιλέχθηκαν βάσει του αξιολογητή παραμέτρων ReliefF. Η διαφορά βέβαια από τη δεύτερη μεγαλύτερη τιμή που επιτυγχάνεται με την χρήση 5 και 8 παραμέτρων από το RandomForest ξανά, είναι πάρα πολύ μικρή και η τιμή της είναι 0,974.

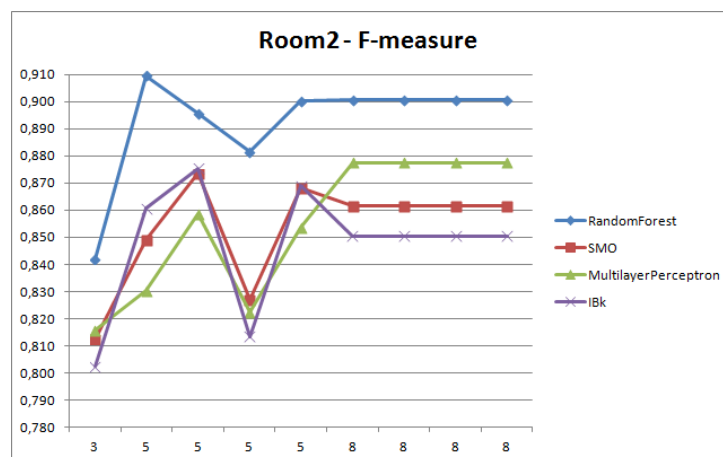
Παρομοίως και στα δεδομένα του Room2, η τιμή της F-measure για τους τρεις από τους τέσσερις αλγορίθμους (RandomForest, SMO, IBk) ήταν σχετικά σε κοντινά επίπεδα είτε έκαναν χρήση 5 είτε 8 παραμέτρων. Στον RandomForest, στον SMO και στον IBk οι μέγιστες τιμές παρουσιάστηκαν με δεδομένα 5 παραμέτρων, ενώ στον MultilayerPerceptron οι μέγιστες τιμές παρατηρούνται στην χρήση 8 παραμέτρων. Και στο Room2 όπως στο Room1, οι τιμές που ήταν αποτελέσματα από δεδομένα λιγότερων παραμέτρων, 3 στην προκειμένη περίπτωση, ήταν οι μικρότερες που επετεύχθησαν στο σύνολο όλων των τιμών από τις δοκιμές που πραγματοποιήθηκαν. Ο αλγόριθμος RandomForest και σε αυτό το δωμάτιο είναι ο αλγόριθμος ταξινόμησης με την μεγαλύτερη τιμή F-measure σε σύγκριση με όλους τους υπόλοιπους αλγορίθμους με την τιμή του να

είναι 0,909 και είναι αποτέλεσμα του ταξινομητή RandomForest και της χρήσης δεδομένων 5 παραμέτρων που επιλέχθηκαν βάσει του αξιολογητή παραμέτρων Information Gain. Αξίζει να σημειωθεί και η μικρή διαφορά με τη δεύτερη μεγαλύτερη τιμή 0,901 η οποία προέρχεται πάλι από τον RandomForest αλλά με χρήση 8 παραμέτρων μέσω όλων των αξιολογητών παραμέτρων.

Την ανάλυση των ξεχωριστών εικόνων για κάθε ταξινομητή και για τα δύο δωμάτια που προηγήθηκε, ακολουθούν δύο εικόνες, [Εικόνα 27](#) και [Εικόνα 28](#) που παρουσιάζουν συγκεντρωτικά τους αλγορίθμους ανά δωμάτιο για την ευκολότερη σύγκρισή τους.



**Εικόνα 27.** Συγκεντρωτική απεικόνιση της απόδοσης όλων των αλγορίθμων με χρήση διαφόρων αριθμών χαρακτηριστικών στο Room1



**Εικόνα 28.** Συγκεντρωτική απεικόνιση της απόδοσης όλων των αλγορίθμων με χρήση διαφόρων αριθμών χαρακτηριστικών στο Room2

### 4.3 Αποτελέσματα μετρήσεων των αλγορίθμων χωρίς το χαρακτηριστικό του χρόνου.

Τα αποτελέσματα των πειραμάτων που ακολουθούν, αφορούν τα αρχεία δεδομένων των δύο δωματίων χωρίς το χαρακτηριστικό του χρόνου, δηλαδή με την χρήση 7 παραμέτρων, εξαιρουμένης του χαρακτηριστικού που αφορά την ετικέτα της κλάσης

Οι Εικόνες [29](#), [30](#) με τους πίνακες που ακολουθούν παρουσιάζουν την απόδοση για κάθε μία από τις κινήσεις των ασθενών ή διαφορετικά για κάθε μία από τις κλάσεις των δεδομένων, χρησιμοποιώντας τους αλγορίθμους RandomForest (RF), Support Vector Machine (SMO), MultiLayerPerceptron (MLP) και K Nearest Neighbor (IBk) και για τα δύο δωμάτια. Η προσέγγιση του αλγορίθμου RF παρέχει την υψηλότερη βαθμολογία F-measure για όλων των ειδών τις κινήσεις και στα δύο δωμάτια, αν και ο αλγόριθμος MLP στο Room1 και ο SMO στο Room2 είχαν την ίδια βαθμολογία με τον RF στην κατάσταση που ο ασθενής είναι ξαπλωμένος.

Οι υψηλότερες τιμές ακρίβειας (precision) του RF (>0,97) για κάθε κίνηση στο Room1 μεταφράζεται σε μικρό αριθμό False Positives και επομένως σε δημιουργία χαμηλού αριθμού ψευδών συναγερμών, γεγονός σημαντικό για την αποδοχή ενός συστήματος. Η τοπολογία του Room2 με τις 3 κεραίες υστερεί στην αποφυγή ψευδών συναγερμών σε σχέση με αυτή του Room1, μιας και η ακρίβεια (precision) ειδικά στις κλάσεις 1 και 4 καταλαμβάνουν σκορ μικρότερα του 0,89.

Υπολογίζοντας το μέσο όρο της μέτρησης Recall για όλες τις κινήσεις ανά αλγόριθμο, ξεκινώντας από το Room1, παρατηρούμε ότι ο αλγόριθμος RF πιάνει την υψηλότερη τιμή 0,959, που αποκωδικοποιείται στην σωστή αντίληψη των διάφορων κινήσεων σε ποσοστό περίπου 96% και στην λανθασμένη αναγνώριση τους σε ποσοστό 4%. Και σε αυτή την περίπτωση τα αποτελέσματα που παράχθηκαν στο Room1 είναι καλύτερα από το Room2, μιας και η μέγιστη μέση τιμή της μέτρησης Recall που επετεύχθη με τον αλγόριθμο RF είναι 0,864 στο Room2 σε σχέση με το 0,959 του Room1.

	ROOM 1															
	sit on bed (class1)				sit on chair (class2)				lying (class3)				ambulating (class4)			
	RF	SMO	MLP	IBK	RF	SMO	MLP	IBK	RF	SMO	MLP	IBK	RF	SMO	MLP	IBK
recall	0,996	0,994	0,988	0,985	0,992	0,993	0,989	0,987	0,999	0,999	0,999	0,999	0,851	0,6	0,621	0,82
precision	0,984	0,956	0,959	0,982	0,979	0,969	0,962	0,973	1	0,997	0,999	0,997	0,97	0,958	0,885	0,901
F-measure	0,99	0,975	0,973	0,983	0,986	0,981	0,975	0,98	0,999	0,998	0,999	0,998	0,907	0,738	0,73	0,858


**Εικόνα 29.** Παρουσίαση αποτελεσμάτων ορισμένων μετρήσεων για όλους τους αλγορίθμους ανά δραστηριότητα ασθενούς στο Room1

	ROOM 2															
	sit on bed (class1)				sit on chair (class2)				lying (class3)				ambulating (class4)			
	RF	SMO	MLP	IBK	RF	SMO	MLP	IBK	RF	SMO	MLP	IBK	RF	SMO	MLP	IBK
recall	0,943	0,917	0,915	0,891	0,974	0,974	0,989	0,972	0,999	0,999	0,998	0,999	0,54	0,49	0,484	0,469
precision	0,889	0,876	0,874	0,871	0,957	0,943	0,929	0,936	0,997	0,997	0,996	0,995	0,862	0,756	0,806	0,781
F-measure	0,915	0,896	0,894	0,881	0,965	0,958	0,958	0,954	0,998	0,998	0,997	0,997	0,664	0,594	0,604	0,586

**Εικόνα 30.** Παρουσίαση αποτελεσμάτων ορισμένων μετρήσεων για όλους τους αλγορίθμους ανά δραστηριότητα ασθενούς στο Room2

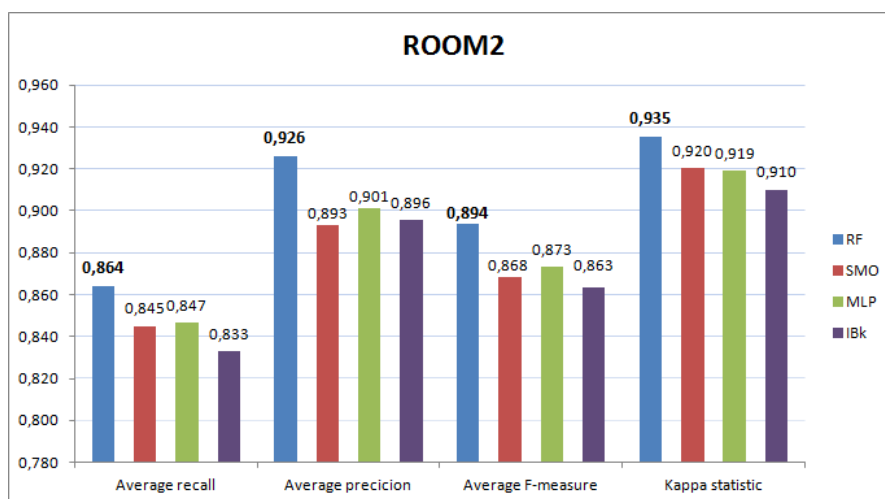
Αφού προηγήθηκε η παρουσίαση ορισμένων αποτελεσμάτων ανά μέτρηση, ανά αλγόριθμο ανά κλάση των συνόλων δεδομένων και ανά δωμάτιο, στη συνέχεια παρουσιάζονται αποτελέσματα που προέρχονται από την εφαρμογή των τεσσάρων αλγορίθμων ανά δωμάτιο και ανά μέσο όρο των μετρήσεων για όλες τις δραστηριότητες. Επομένως η τιμή του Average Recall και Average Precision ισούται με το άθροισμα της κάθε μία μέτρησης ανά δραστηριότητα διά τέσσερα, που είναι και το πλήθος των κλάσεων. Η τιμή της Average F-measure προκύπτει από τον τύπο  $F\text{-measure} = 2 * ((Precision * Recall) / (Precision + Recall))$  που έχει αναφερθεί και στο [κεφάλαιο 3](#), με την διαφορά της αντικατάστασης των Precision και Recall από τις τιμές των Average Precision και Average Recall. Η τιμή της μέτρησης Kappa Statistic αφορά την απόδοση συνολικά του κάθε μοντέλου που δημιουργείται από κάθε αλγόριθμο.

Τα αποτελέσματα που παρουσιάζονται στην [Εικόνα 31](#) καταδεικνύουν την επίτευξη της καλύτερης αξιολόγησης του ταξινομητή RF έναντι της ανίχνευσης των δραστηριοτήτων από τους υπόλοιπους ταξινομητές για το Room1. Μπορούμε επίσης να σημειώσουμε ότι ο RF υπερτερεί σε όλες τις μετρήσεις, με βασικότερες τις F-measure και Kappa statistic, με τιμές αρκετά ικανοποιητικές (>0,97). Παρόλα αυτά, και οι υπόλοιποι ταξινομητές πετυχαίνουν υψηλές βαθμολογίες στις μετρήσεις, αφού για παράδειγμα στον ταξινομητή IBK οι βαθμολογίες είναι της τάξεως >0,95.



**Εικόνα 31.** Απεικόνιση του μέσου όρου των μετρήσεων για τις δραστηριότητες ανά αλγόριθμο στο Room1. Η τιμή της μέτρησης Kappa statistic δεν αφορά μέσο όρο.


Τα αποτελέσματα που αφορούν την ταξινόμηση των δεδομένων του Room2 και αποτυπώνονται στην [Εικόνα 32](#) φανερώνουν ότι ο RF, είναι ο αλγόριθμος με τις υψηλότερες επιδόσεις, με διαφορά της κλίμακας 2% έως 3% στις μετρήσεις F-measure και Kappa statistic, σε σύγκριση με τους υπόλοιπους αλγορίθμους. Συγκεκριμένα η τιμή της μέτρησης F-measure είναι 0,894 και της Kappa statistic 0,935.



**Εικόνα 32.** Απεικόνιση του μέσου όρου των μετρήσεων για τις δραστηριότητες ανά αλγόριθμο στο Room2. Η τιμή της μέτρησης Kappa statistic δεν αφορά μέσο όρο.

Συγκρίνοντας τα αποτελέσματα των επιδόσεων των δύο δωματίων για κάθε μία κλάση, για τον αλγόριθμο RandomForest, μιας και στις συγκρίσεις που προηγήθηκαν κατέλαβε τις υψηλότερες επιδόσεις σε σύγκριση με τους υπόλοιπους αλγορίθμους, παρατηρούμε όπως φαίνεται και στην [Εικόνα 33](#) ότι τα αποτελέσματα που προέκυψαν στο Room1 υπερτερούν σε όλες τις κλάσεις από αυτά του Room2. Παρόλο την υπεροχή της απόδοσης του αλγορίθμου στα δεδομένα του Room1, ιδιαίτερη εντύπωση παρουσιάζει η μεγάλη απόκλιση της πρόβλεψης της κλάσης με ετικέτα περπάτημα τόσο απέναντι στο ποσοστό πρόβλεψης των άλλων κλάσεων του ίδιου δωματίου, όσο και απέναντι στις προβλέψεις της ίδιας κλάσης του Room1. Οι λόγοι που παρατηρείται αυτή η διαφορά προφανώς μπορεί να είναι περισσότεροι από ένας, αλλά στην παρούσα μεταπτυχιακή διατριβή, θα επικεντρωθούμε στην ανισορροπία των κλάσεων στα σύνολα δεδομένων.

Random Forest			
		Room1	Room2
sit on bed (class1)	recall	0,996	0,943
	precision	0,984	0,889
	F-measure	0,99	0,915
sit on chair (class2)	recall	0,992	0,974
	precision	0,979	0,957
	F-measure	0,986	0,965
lying (class3)	recall	0,999	0,999
	precision	1	0,997
	F-measure	0,999	0,998
ambulating (class4)	recall	0,851	0,54
	precision	0,97	0,862
	F-measure	0,907	0,664



**Εικόνα 33.** Σύγκριση των μετρήσεων Recall, Precision και F-measure του αλγορίθμου RF και στα δύο δωμάτια για κάθε μία κλάση

Η ανισορροπία των κλάσεων που χαρακτηρίζουν τις διάφορες δραστηριότητες [Εικόνα 5](#), όπως η δραστηριότητα ξαπλωμένη στο κρεβάτι και η δραστηριότητα που ο ασθενής περπατάει, επηρεάζουν το μαθησιακό μοντέλο του ταξινομητή, αφού ο ταξινομητής δεν μπορεί να κατηγοριοποιήσει σωστά τα νέα δεδομένα που αφορούν κλάσεις με μικρό πλήθος στιγμιότυπων στο στάδιο της εκπαίδευσης. Αυτό είναι ευδιάκριτο στις [Εικόνες 34, 35](#) που απεικονίζουν σε ποσοστό %, τα Confusion Matrix για τα δεδομένα των δύο δωματίων του αλγορίθμου RandomForest. Επιλέχτηκε και σε αυτή την περίπτωση ο

συγκεκριμένος αλγόριθμος διότι στις συγκρίσεις που προηγήθηκαν, κατέλαβε τις υψηλότερες επιδόσεις σε σύγκριση με τους υπόλοιπους.

Όσο αναφορά το Room1 παρατηρούμε ότι το 85% των δεδομένων που αφορούν την δραστηριότητα περπάτημα προβλέφθηκαν σωστά, ποσοστό όχι ιδιαίτερα χαμηλό αν το αντιμετωπίζαμε μεμονωμένα, αλλά με αισθητή διαφορά σε σχέση με τις υπόλοιπες δραστηριότητες που το ποσοστό των επιτυχημένων προβλέψεων είναι >99%. Η μη σωστή πρόβλεψη της δραστηριότητας που αφορά το περπάτημα είχε ως αποτέλεσμα την εσφαλμένη ταξινόμηση στις δραστηριότητες 'sit on bed' και 'sit on chair' σε ποσοστά περίπου 11% και 3% αντίστοιχα. Ως υπενθύμιση το ποσοστό των δεδομένων με τη συγκεκριμένη δραστηριότητα επί του συνόλου, είναι 4% ([Εικόνα 5](#)).

Στο Room2 η σωστή πρόβλεψη της δραστηριότητας περπάτημα κυμαίνεται σε πολύ χαμηλά επίπεδα αφού το ποσοστό είναι 54%, ενδεικτικό σε μεγάλο βαθμό του γεγονότος ότι το ποσοστό των δεδομένων της συγκεκριμένης δραστηριότητας επί του συνόλου, είναι 1%. 39% και 6% είναι τα ποσοστά της εσφαλμένης αναγνώρισης της δραστηριότητας περπάτημα στις δραστηριότητες 'sit on bed' και 'sit on chair' αντίστοιχα. Χαμηλό είναι και το ποσοστό των δεδομένων των δραστηριοτήτων 'sit on bed' και 'sit on chair' επί του συνόλου, με ποσοστά 6% και 2% αντίστοιχα ([Εικόνα 5](#)). Για τον λόγο αυτό παρατηρείται μείωση του ποσοστού σωστής αναγνώρισης των δύο δραστηριοτήτων. Αντιθέτως, η πρόβλεψη της δραστηριότητας που ο ασθενής είναι ξαπλωμένος αγγίζει την απόλυτη τιμή, 99,9%, ποσοστό που ευθύνεται στο 91% που καταλαμβάνουν τα δεδομένα με την συγκεκριμένη κλάση επί του συνόλου.

ROOM1 - RF Confusion Matrix					
		class1	class2	class3	class4
sit on bed	class1	99,62	0,16	0,06	0,16
sit on chair	class2	0,16	99,22	0,00	0,62
lying	class3	0,06	0,00	99,94	0,00
ambulating	class4	11,35	3,43	0,10	85,12

**Εικόνα 34**

ROOM2 - RF Confusion Matrix					
		class1	class2	class3	class4
sit on bed	class1	94,29	0,16	4,34	1,21
sit on chair	class2	0,19	97,36	0,00	2,45
lying	class3	0,06	0,00	99,93	0,00
ambulating	class4	39,40	6,27	0,30	54,03

**Εικόνα 35**

## 4.4 Αποτελέσματα μετρήσεων των αλγορίθμων με χρήση των τεχνικών SMOTE και Cost-sensitive

Λόγω του χαμηλού ποσοστού πρόβλεψης της δραστηριότητας περπάτημα, ειδικά στο Room2, εφαρμόστηκαν οι τεχνικές SMOTE σε συνδυασμό με την τεχνική Randomize και η cost-sensitive, που αναλύθηκαν στο κεφάλαιο 3, για την βελτίωσή του, χωρίς βέβαια να επηρεάζεται αρνητικά η συνολική απόδοση του μοντέλου πρόβλεψης. Και σε αυτή την περίπτωση, οι τεχνικές είχαν ως βασικό αλγόριθμο τον RandomForest που είναι ο αποδοτικότερος όλων. Οι Εικόνες [36](#), [40](#), [41](#), [44](#), [45](#), [46](#) που ακολουθούν, αποτυπώνουν με τη βοήθεια των Confusion Matrix, την βελτίωση της πρόβλεψης της συγκεκριμένης δραστηριότητας μετά την εφαρμογή των προαναφερθέντων τεχνικών.

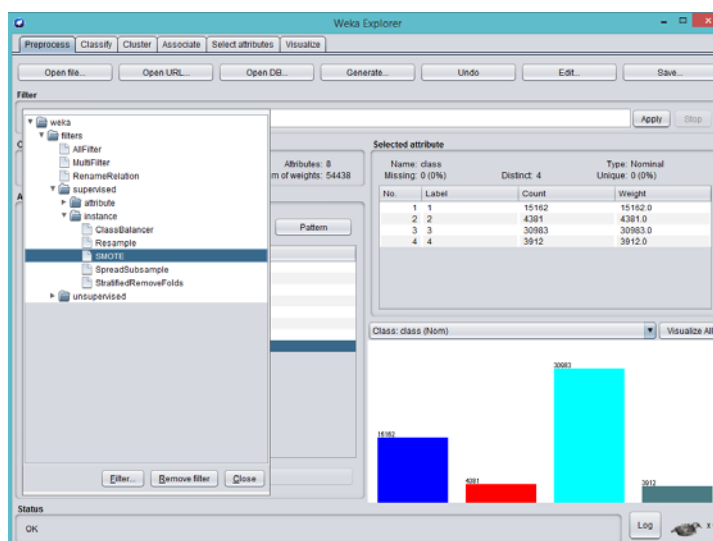
Όσο αναφορά το Room1, στην [Εικόνα 36](#) πετύχαμε τα καλύτερα αποτελέσματα μετά την εφαρμογή της τεχνικής SMOTE,

ROOM1 - RF Confusion Matrix - SMOTE - Randomize					
		class1	class2	class3	class4
sit on bed	class1	99,47	0,16	0,07	0,31
sit on chair	class2	0,16	99,09	0,00	0,75
lying	class3	0,06	0,00	99,94	0,00
ambulating	class4	9,84	2,48	0,08	87,60

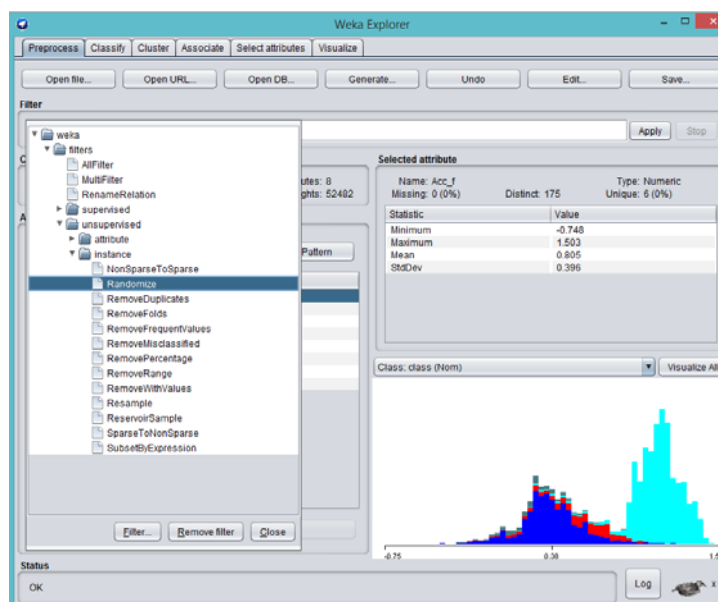
**Εικόνα 36**

Για την υλοποίησή της, όπως φαίνεται και στην [Εικόνα 37](#), σε πρώτο στάδιο, από τα φίλτρα του WEKA εφαρμόζεται η τεχνική SMOTE στο σύνολο δεδομένων. Στη συνέχεια, το νέο σύνολο δεδομένων υπόκειται στο φίλτρο Randomize ([Εικόνα 38](#)) και κατόπιν ο αλγόριθμος το χρησιμοποιεί για τη δημιουργία του μοντέλου πρόβλεψης.



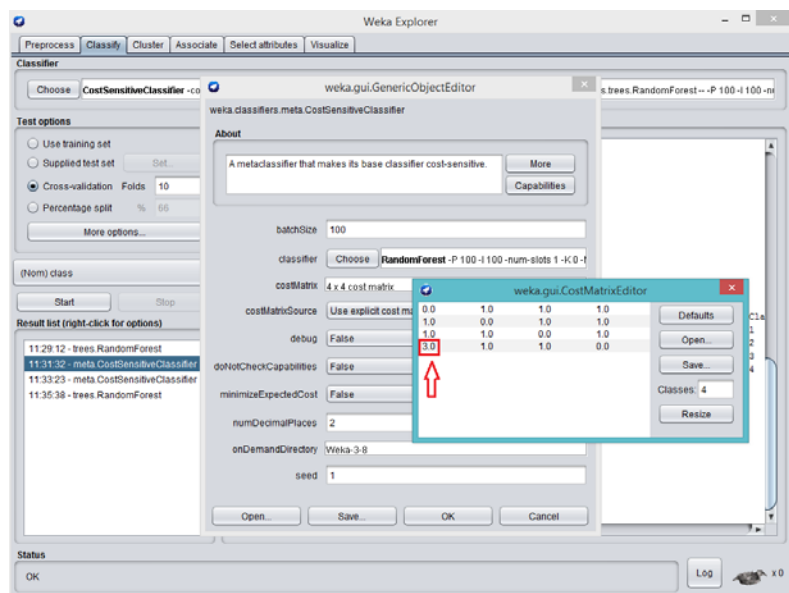


Εικόνα 37. Φίλτρο SMOTE στο WEKA

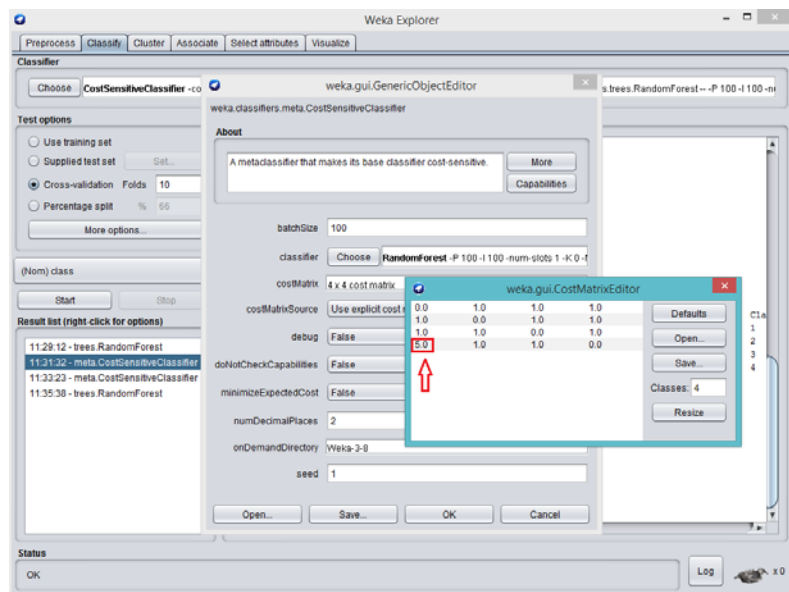


Εικόνα 38. Φίλτρο Randomize στο WEKA

Κατά την εφαρμογή της τεχνικής cost-sensitive, πραγματοποιήθηκαν πειράματα τροποποιώντας την τιμή του κόστους για την κλάση με ετικέτα περπάτημα (κλάση 4) που προβλέφθηκε ως κάθισμα του ασθενή στο κρεβάτι (κλάση 1). Η επιλογή για την αλλαγή της τιμής του κόστους της συγκεκριμένης κλάσης, έγινε με γνώμονα ότι κατέλαβε το μεγαλύτερο ποσοστό από την εσφαλμένη ταξινόμηση της κλάσης με ετικέτα περπάτημα. Στην τιμή του κόστους στην [Εικόνα 39](#) δόθηκε η τιμή 3 και στην [Εικόνα 40](#) η τιμή 5.



Εικόνα 39. Αλλαγή της τιμής κόστους σε τιμή 3 μέσω της τεχνικής cost-sensitive



Εικόνα 40. Αλλαγή της τιμής κόστους σε τιμή 5 μέσω της τεχνικής cost-sensitive

Τα αποτελέσματα αλλαγής της τιμής κόστους παρατίθενται στις [Εικόνες 41, 42](#) που ακολουθούν. Να επισημανθεί ότι πραγματοποιήθηκαν πειράματα με διάφορες τιμές κόστους, για να καταλήξουμε στις τιμές που προαναφέρθηκαν και που συνδράμουν στα καλύτερα αποτελέσματα.

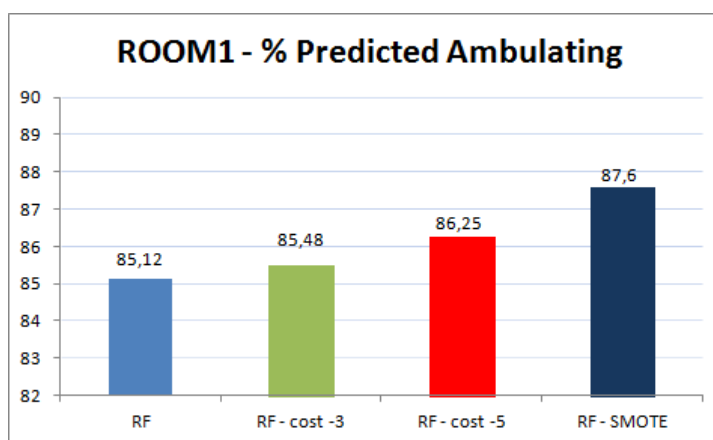
ROOM1 - RF Confusion Matrix - Cost '3'					
		class1	class2	class3	class4
sit on bed	class1	99,58	0,15	0,05	0,21
sit on chair	class2	0,16	99,22	0,00	0,62
lying	class3	0,06	0,00	99,94	0,00
ambulating	class4	11,15	3,27	0,10	85,48

**Εικόνα 41**

ROOM1 - RF Confusion Matrix - Cost '5'					
		class1	class2	class3	class4
sit on bed	class1	99,51	0,15	0,07	0,27
sit on chair	class2	0,16	99,16	0,00	0,68
lying	class3	0,06	0,00	99,94	0,00
ambulating	class4	10,63	3,02	0,10	86,25

**Εικόνα 42**


Οπότε συγκρίνοντας τα αποτελέσματα των πειραμάτων που πραγματοποιήθηκαν για την βελτίωση του ποσοστού πρόβλεψης της δραστηριότητας περπάτημα στο Room1, παρατηρούμε ότι με την τεχνική cost-sensitive, η τιμή του κόστους 5 είναι αποδοτικότερη από την τιμή κόστους 3, αλλά η τεχνική SMOTE υπερτερεί της τεχνικής cost-sensitive. Παρόλα αυτά, η μέγιστη βελτίωση που παρουσιάζεται είναι της τάξης του 2,5%, ποσοστό όχι ιδιαίτερα μεγάλο ([Εικόνα 43](#)). Η πρώτη στήλη με ονομασία RF της [Εικόνας 43](#) απεικονίζει την πρόβλεψη πριν την εφαρμογή των τεχνικών.



**Εικόνα 43.** Σύγκριση του ποσοστού % πρόβλεψης της 4ης κλάσης πριν την εφαρμογή και μετά την εφαρμογή των τεχνικών SMOTE & Cost-sensitive με τον αλγόριθμο RF στο Room1

Επιπλέον στην [Εικόνα 44](#) που ακολουθεί, παρουσιάζεται η τιμή της μέτρησης F-measure πριν και μετά την εφαρμογή των τεχνικών SMOTE και cost-sensitive. Και εδώ παρατηρείται ότι η μέγιστη τιμή της μέτρησης F-measure επιτυγχάνεται με την τεχνική SMOTE, αν και η βελτίωση είναι ανεπαίσθητη. Σκοπός όμως της παρουσίασης της συγκεκριμένης μέτρησης, που αποτελεί και τη βασική μέτρηση για την αξιολόγηση της απόδοσης των μοντέλων που δημιουργούνται στη παρούσα μεταπτυχιακή διατριβή, είναι

για να επισημανθεί ότι με την χρήση των τεχνικών που εφαρμόστηκαν, δεν μειώθηκε η απόδοση των μοντέλων.



**Εικόνα 44.** Σύγκριση της μέτρησης F-measure πριν την εφαρμογή και μετά την εφαρμογή των τεχνικών SMOTE & Cost-sensitive με τον αλγόριθμο RF στο Room1

Όσο αναφορά το Room2, οι Εικόνες [45](#), [46](#), [47](#) παρουσιάζουν τα αποτελέσματα μετά την εφαρμογή της τεχνικής SMOTE και cost-sensitive

		class1	class2	class3	class4
sit on bed	class1	91,56	0,16	4,34	3,94
sit on chair	class2	0,00	96,98	0,00	3,02
lying	class3	0,06	0,00	99,93	0,00
ambulating	class4	21,79	2,84	0,00	75,37

**Εικόνα 45**


		class1	class2	class3	class4
sit on bed	class1	92,68	0,24	4,50	2,57
sit on chair	class2	0,00	96,79	0,00	3,21
lying	class3	0,07	0,00	99,93	0,00
ambulating	class4	33,73	5,07	0,00	61,19

**Εικόνα 46**

		class1	class2	class3	class4
sit on bed	class1	91,56	0,16	4,42	3,86
sit on chair	class2	0,00	96,79	0,00	3,21
lying	class3	0,07	0,00	99,92	0,00
ambulating	class4	31,04	4,78	0,30	63,88


**Εικόνα 47**

Παρατηρώντας και συγκρίνοντας τα αποτελέσματα των πειραμάτων που πραγματοποιήθηκαν για την βελτίωση του ποσοστού πρόβλεψης της δραστηριότητας περπάτημα στο Room2, παρατηρούμε ότι με την τεχνική cost-sensitive, η βελτίωση του ποσοστού κυμαίνεται μεταξύ 7% και περίπου 10%, με μεγαλύτερο ποσοστό να επιτυγχάνεται με την τιμή κόστους 5. Παρομοίως με το Room1, η εφαρμογή της τεχνικής SMOTE στα δεδομένα από αφορούν το Room2 είναι αποδοτικότερη. Η βελτίωσή του όμως σε αυτή την περίπτωση είναι αρκετά μεγαλύτερη. Η αύξηση του ποσοστού όπως φαίνεται και στην [Εικόνα 48](#) είναι 25% μεγαλύτερη από την αρχική κατάσταση, δηλαδή πριν την εφαρμογή των διάφορων τεχνικών βελτίωσης και 11,5% μεγαλύτερη από το αποτέλεσμα που σημειώθηκε με την τεχνική cost-sensitive.



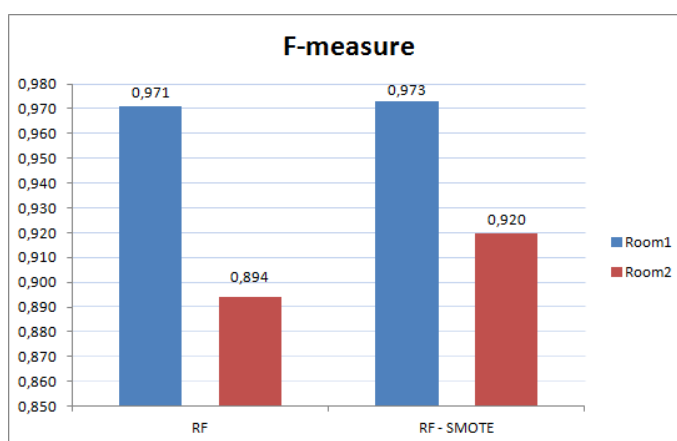
**Εικόνα 48.** Σύγκριση του ποσοστού % πρόβλεψης της 4ης κλάσης πριν την εφαρμογή και μετά την εφαρμογή των τεχνικών SMOTE & Cost-sensitive με τον αλγόριθμο RF στο Room2

Όπως πραγματοποιήθηκε στο Room1, έτσι και για το Room2 η [Εικόνα 49](#) που ακολουθεί, παρουσιάζει την τιμή της μέτρησης F-measure πριν και μετά την εφαρμογή των τεχνικών SMOTE και cost-sensitive. Παρατηρείται ότι η μέγιστη τιμή της μέτρησης F-measure επιτυγχάνεται με την τεχνική SMOTE και στο δωμάτιο αυτό, με τη βελτίωση να είναι ικανοποιητική με αύξηση λίγο περισσότερο από 2,5%. Η τεχνική cost-sensitive αν και βελτιώνει το ποσοστό πρόβλεψης της κλάσης με ετικέτα περπάτημα περίπου 10%, δεν βελτιώνει καθόλου την μέτρηση F-measure.




**Εικόνα 49.** Σύγκριση της μέτρησης F-measure πριν την εφαρμογή και μετά την εφαρμογή των τεχνικών SMOTE & Cost-sensitive με τον αλγόριθμο RF στο Room2

Παρατηρώντας την [Εικόνα 50](#) που απεικονίζει την απόδοση της μέτρησης F-measure για κάθε δωμάτιο με τη χρήση και μη χρήση της τεχνικής SMOTE στο αλγόριθμο Random Forest, συμπεραίνεται ότι με τη χρήση της τεχνικής SMOTE, οι τιμές F-measure 0,973 και 0,92 του Room1 και Room2 αντίστοιχα είναι οι υψηλότερες τιμές που επετεύχθησαν ύστερα από ένα κύκλο πειραμάτων που πραγματοποιήθηκαν και παρουσιάστηκαν με γνώμονα πάντα ότι το χαρακτηριστικό του χρόνου έχει αφαιρεθεί από τα σύνολα δεδομένων των δωματίων. Επίσης η τοπολογία του Room1 με τις 4 κεραιές είναι καταλληλότερη από αυτή των 3 κεραιών του Room2 στην καλύτερη πρόγνωση των διάφορων δραστηριοτήτων των ασθενών.




**Εικόνα 50** - Τιμή της μέτρησης F-measure του RF ανά δωμάτιο με και χωρίς τη χρήση της τεχνικής SMOTE

Καταλήγοντας, στην [Εικόνα 51](#) παρουσιάζονται συγκεντρωτικά τα αποτελέσματα των μέσων όρων των μετρήσεων Precision, Recall και F-measure του αλγορίθμου RF για τα δύο δωμάτια για όλες τις δραστηριότητες, ύστερα από την εφαρμογή των τεχνικών SMOTE και Randomize.



**Εικόνα 51** - Αποτελέσματα μέσου όρου μετρήσεων Recall, Precision και F-measure του αλγορίθμου RF και στα δύο δωμάτια

Με το πέρας της ολοκλήρωσης των διάφορων πειραμάτων, ακολουθεί η σύγκριση των αποτελεσμάτων της μέτρησης F-measure του Random Forest που είναι ο αποδοτικότερος αλγόριθμος και για τα δύο δωμάτια, με τα σύνολα δεδομένων και να περιέχουν (No of features 8) και να μην περιέχουν (No of features 7) το χαρακτηριστικό του χρόνου ([Εικόνα 52](#)). Οι τιμές που περιέχουν 7 χαρακτηριστικά, είναι τιμές χωρίς την εφαρμογή της τεχνικής SMOTE, μιας και η συγκεκριμένη τεχνική δεν είχε εφαρμοστεί ούτε στις τιμές που είναι αποτελέσματα 8 χαρακτηριστικών. Στη συγκεκριμένη εικόνα παρατηρείται ότι η απόδοση των μοντέλων με τη χρήση 7 χαρακτηριστικών είναι ελάχιστα μικρότερη από αυτή του αρχικού συνόλου δεδομένων (8 χαρακτηριστικά)



**Εικόνα 52.** Τιμή της μέτρησης F-measure του RF ανά δωμάτιο με χρήση του συνόλου δεδομένων με και χωρίς το χαρακτηριστικό του χρόνου.

## 4.5 Σύγκριση αποτελεσμάτων

Κλείνοντας την ενότητα των πειραμάτων κρίνεται σκόπιμο να παραθέσουμε κι ορισμένα αποτελέσματα προηγούμενων ερευνών για να τα συγκρίνουμε με αυτά της παρούσας μεταπτυχιακής διατριβής. Για τη δίκαιη σύγκριση όμως των αποτελεσμάτων μας με άλλες μελέτες, θα πρέπει να πληρούνται ορισμένες προϋποθέσεις. Εξαιρώντας το βασικό στόχο των ερευνών, που θεωρείται αυτονόητο ότι πρέπει να είναι ο ίδιος, μία από τις βασικότερες προϋποθέσεις είναι τα κοινά σύνολα δεδομένων, αφού όπως είναι ευκόλως κατανοητό αποτελούν τη βασική πηγή μέσω της οποίας εξάγονται τα προς σύγκριση αποτελέσματα. Οι ομάδες των συμμετεχόντων είναι επίσης κρίσιμος παράγοντας μιας και η συμπεριφορά και οι αντιδράσεις τους ποικίλουν σε μεγάλο βαθμό ανάλογα με την ηλικία τους. Ακόμη και η διαφορετικότητα στο περιβάλλον που εκτελούνται τα πειράματα μπορεί να είναι ένας λόγος που καθιστά μη δίκαιη μία σύγκριση αποτελεσμάτων. Τέλος, απαιτείται να υπάρχουν κοινές μετρήσεις αξιολόγησης για να επιτευχθεί μία σωστή σύγκριση.

Για τους λόγους που μόλις προαναφέρθηκαν και καλύπτοντας όλες τις ανωτέρω προϋποθέσεις, στην [Εικόνα 53](#) παρουσιάζεται η σύγκριση των αποτελεσμάτων της παρούσας μεταπτυχιακής διατριβής με παρόμοιες έρευνες που έχουν ήδη πραγματοποιηθεί. Έχοντας υπόψη ότι η F-measure είναι η βασική μέτρηση για την αξιολόγηση της απόδοσης των αλγορίθμων, παρατηρείται ότι η υψηλότερη τιμή της και στα δύο σύνολα δεδομένων που αφορούν τα δύο δωμάτια, επιτυγχάνεται στη δική μας



μεταπτυχιακής διατριβής. Οι τιμές των μετρήσεων precision και recall της μεταπτυχιακής διατριβής μας υπερτερούν επίσης σε σχέση με τις υπόλοιπες, με μοναδική εξαίρεση την τιμή της μέτρησης recall στο Room2 της έρευνας του Shinmoto Torres et al. 2016A που είναι μεγαλύτερη κατά 2 περίπου ποσοστιαίες μονάδες.

Συγγραφείς ερευνών	ROOM1				ROOM2				Classifier
	Precision	Recall	F-measure	Accuracy	Precision	Recall	F-measure	Accuracy	
Wickramasinghe, A. et.al (2017)	85.1	48.8			84.9	86.5			SVM
Shinmoto Torres, R. L. et.al (2016 A)	67	94	77		78	93	84		CRF
Wickramasinghe, A. et.al (2015 B)	90	87	88		90	83	85		SVM with RBF kernel
Shinmoto Torres, R. L. et.al (2013 B)			65				71		CRF
Shinmoto Torres, R. L. et.al (2013 A)		93,4		96		82,75		94	CRF
Shinmoto Torres, R. L. et.al (2016 B)			90				81		dWCRF
<b>Μεταπτυχιακή Διατριβή</b>	<b>98,07</b>	<b>96,52</b>	<b>97,29</b>		<b>93</b>	<b>90,97</b>	<b>91,97</b>		Random Forest

**Εικόνα 53.** Σύγκριση αποτελεσμάτων της μεταπτυχιακής διατριβής μας με παρόμοιες έρευνες

Στην [Εικόνα 54](#) παρουσιάζονται επίσης ενδεικτικά, ορισμένα αποτελέσματα ερευνών με στόχο την αναγνώριση ανθρώπινης δραστηριότητας, τα οποία όμως δεν παράχθηκαν σύμφωνα με τα δεδομένα και τις συνθήκες της παρούσας μεταπτυχιακής διατριβής. Κριτήριο της επιλογής τους ήταν η χρήση αλγορίθμων μηχανικής μάθησης, μιας και αποτελεί βασικό θεματικό πεδίο της μεταπτυχιακής διατριβής. Σε αυτή την περίπτωση, στο βαθμό που επιτρέπεται να γίνει μία σύγκριση, τα αποτελέσματα της μεταπτυχιακής διατριβής, ειδικά αυτά που αφορούν το Room1 που είναι και τα ψηλότερα, υστερούν σε σύγκριση με τα αποτελέσματα άλλων ερευνών, όπως των Ozdemir & Barshan 2014 και Chia-Yeh et al. 2017, αλλά σε μικρό βαθμό.

Συγγραφείς ερευνών	Precision	Recall	F-measure	Accuracy	Classifier	Πηγή δεδομένων
Wickramasinghe, A. et.al (2015 A)			94		Random Forest	WISP - RFID
Shinmoto Torres, R. L. et.al (2017 A)	66,8	81,4	72,4		WSVM	W2ISP - RFID
Ozdemir, A.T. et.al (2014)		100		99,91	k-NN	6 ασύρματοι αισθητήρες σε διάφορα σημεία του σώματος
Awais, M. et.al (2019)			93		WSVM	Smartphone
Awais, M. et.al (2019)			88,4		Random Forest	WISP - RFID
Chia-Yeh, H. et.al (2017)	98,81	99,24		98,88	SVM	tri-axial accelerometer

**Εικόνα 54.** Παρουσίαση αποτελεσμάτων από έρευνες που έκαναν χρήση διαφόρων αλγορίθμων μηχανικής μάθησης

# 5. Συμπεράσματα

Σε αυτή την μεταπτυχιακή διατριβή παρουσιάστηκε μία προσέγγιση για την αναγνώριση δραστηριοτήτων ηλικιωμένων ανθρώπων ώστε να μειωθεί ο κίνδυνος πτώσης. Προτείνουμε τέσσερις αλγορίθμους που βασίζονται στη μηχανική μάθηση και έχουν χρησιμοποιηθεί στο παρελθόν σε αντίστοιχες έρευνες, τον Random Forest, τον k-Nearest Neighbor, τον SVM και τον MultiLayer Perceptron, για την σωστή πρόβλεψη και ταξινόμηση της κλάσης για στιγμιότυπα που προέρχονται από δύο σύνολα δεδομένων, ένα για κάθε δωμάτιο.

Συγκρίνοντας τις επιδόσεις των αλγορίθμων, επιτεύχθηκαν υψηλές μετρήσεις και στα δυο δωμάτια. Η επαναληψιμότητα των αποτελεσμάτων λόγω της μεθόδου k-fold cross validation επικυρώνει την ισχύ των ταξινομητών.

Η σύγκριση μεταξύ των αλγορίθμων βασίστηκε σε διάφορες μετρήσεις απόδοσης. Τα πειράματα που διεξήχθησαν μέσω αυτών των μετρήσεων κατέδειξαν την υπεροχή της προσέγγισης του ταξινομητή Random Forest και στα δύο δωμάτια, στη διάκριση των διάφορων δραστηριοτήτων

Τα αποτελέσματα της αξιολόγησης, με συνολικές επιδόσεις της ακρίβειας (precision), της ανάκλησης (recall) και της F-measure ήταν 96,52%, 98,07% και 97,29% αντίστοιχα για το Room1, ενώ για το Room2 ήταν 90,97%, 93 % και 91,97%.

Ειδικότερα, η αρχιτεκτονική του Room1 έδειξε ότι μπορεί να επιτύχει σημαντικά υψηλότερη βαθμολογία στη μέτρηση F-measure (98,4%) για την δραστηριότητα που ο ασθενής κάθεται στο κρεβάτι και για την δραστηριότητα που περπατάει (92,4%) σε σύγκριση με το Room2, που οι τιμές είναι 89,6% και 81,4% αντίστοιχα.

Αξίζει να επισημανθεί ότι η διαφορά της βαθμολογίας στη μέτρηση F-measure μεταξύ των δύο δωματίων για τη δραστηριότητα που ο ασθενής περπατάει, μειώθηκε αρκετά λόγω της

χρήσης της τεχνικής SMOTE, αφού χωρίς την εφαρμογή της, η τιμή στο Room2 ήταν 66,4%, δηλαδή 26% μικρότερη από αυτή του Room1.

Παρόλο τη μεγάλη βελτίωση του ποσοστού πρόβλεψης που επιτεύχθηκε με την τεχνική SMOTE στο Room2 σε σχέση με το Room1, το ποσοστό στο Room2 παραμένει μικρότερο από αυτό του Room1, αφού και για τις δύο συγκεκριμένες δραστηριότητες, το μοντέλο που δημιουργήθηκε για το Room1 υπερτερεί περίπου κατά 10 ποσοστιαίες μονάδες από αυτό του Room2.

Όσο αναφορά τις άλλες δύο δραστηριότητες, δηλαδή αυτές που ασθενής είναι ξαπλωμένος και κάθετα στην καρέκλα, η διαφορά της μέτρησης F-measure και στα δύο δωμάτια είναι μικρότερη, αφού στο Room1 η τιμή της είναι 99,9% και 98,2%, ενώ στο Room2 είναι 99,8% και 96,5%

Το γεγονός ότι η πρόβλεψη της κατάστασης που ο ασθενής κάθετα στο κρεβάτι είναι λίγο μεγαλύτερη του 99% στο Room1 και περίπου 97% στο Room2, είναι αρκετά ικανοποιητικό, γιατί ειδικά κατά τη διάρκεια της νύχτας όπου υποτίθεται ορισμένοι ασθενείς δεν πρέπει να σηκώνονται από το κρεβάτι χωρίς επίβλεψη, δηλώνει ότι πιθανώς ο ασθενής επιχειρεί να σηκωθεί και επομένως το νοσηλευτικό προσωπικό μπορεί να ενημερωθεί με την ενεργοποίηση ενός συναγερμού για να αποφευχθεί μία ενδεχόμενη πτώση.

Ο κύριος λόγος που ο ταξινομητής RF υπερέχει μεταξύ των άλλων στην καλύτερη αναγνώριση των δραστηριοτήτων (AR) χρησιμοποιώντας δεδομένα από τον αισθητήρα επιτάχυνσης, οφείλεται στο γεγονός ότι χρησιμοποιεί εσωτερικά έναν αριθμό αποσυνδεδεμένων δέντρων αποφάσεων (DT) και ως εκ τούτου είναι πιο ανθεκτικός στα θορυβώδη χαρακτηριστικά που παράγονται από τη ροή δεδομένων του W<sup>2</sup>ISP (Wickramasinghe et al. 2015A).

Στο πρόσφατο παρελθόν έχουν αναπτυχθεί αρκετά συστήματα αναγνώρισης δραστηριοτήτων ή εξόδου από το κρεβάτι. Οι Εικόνες [53](#), [54](#) που συνοψίζουν τα αποτελέσματα των προηγούμενων προσεγγίσεων μαζί με τα αποτελέσματα της μελέτης

μας, επέδειξαν ότι η απόδοση του μοντέλου της παρούσας μεταπτυχιακής διατριβής υπερτερεί σε σχέση με τα αποτελέσματα παρόμοιων εργασιών που χρησιμοποίησαν τα ίδια σύνολα δεδομένων και είναι ικανοποιητικά συγκρίσιμη με άλλες μελέτες, που αφενός είχαν ως στόχο την αναγνώριση δραστηριοτήτων με αλγορίθμους μηχανικής μάθησης, αλλά αφετέρου είχαν και αρκετές διαφορές.

Εκτός από το γεγονός ότι ο αισθητήρας W<sup>2</sup>ISP είναι αρκετά ελαφρύς, χωρίς μπαταρίες, χαμηλού κόστους και χωρίς συντήρηση, το σημαντικότερο πλεονεκτήματα της παρούσας μεταπτυχιακής διατριβής για την αποδοχή της, είναι η εξαιρετικά ακριβής αναγνώριση των δραστηριοτήτων, ειδικά στο Room1, με πολύ χαμηλές απώλειες και ψευδείς συναγερμούς.

Η ορθή αναγνώριση επομένως σε μεγάλο βαθμό των δραστηριοτήτων, θα προσφέρει ένα ικανοποιητικό και αξιόπιστο σύστημα πρόληψης των πτώσεων και θα βοηθήσει τους επαγγελματίες υγείας να παρακολουθούν τους ηλικιωμένους ασθενείς μέσω της δημιουργίας συναγερμών.

# 6. Επίλογος

Η αδιαμφισβήτητη ύπαρξη πτώσεων αποτελεί σημαντικό ζήτημα σε μια κοινωνία που το προσδόκιμο ζωής των ανθρώπων έχει αυξηθεί, προκαλώντας σημαντικά προβλήματα. Οπότε η μείωση των πτώσεων σε μεγάλο βαθμό, εκτός από την αποφυγή των τραυματισμών, συμβάλει ακόμη περισσότερο στην αύξηση της εμπιστοσύνης των ηλικιωμένων να εκτελούν βασικές δραστηριότητες της καθημερινότητάς τους.

Η ύπαρξη πληθώρας ερευνών και η δημιουργία νέων ερευνών που ασχολούνται με την αναγνώριση δραστηριότητας, αποτυπώνει την σοβαρότητα του προβλήματος. Συνεχής είναι η αναζήτηση διαφορετικών προσεγγίσεων, που προσπαθούν να εκμεταλλευτούν στο έπακρο την εξέλιξη της τεχνολογίας και της επιστήμης.

Η χρήση των ασύρματων αισθητήρων RFID που αποτελούσε μία από τις βασικότερες πηγές παραγωγής δεδομένων στο πρόσφατο παρελθόν για την αναγνώριση της ανθρώπινης δραστηριότητας, παρατηρείται ότι υποχωρεί και ολοένα και περισσότερες έρευνες χρησιμοποιούν προσεγγίσεις που κάνουν χρήση έξυπνων κινητών τηλεφώνων. Ο λόγος που συμβαίνει αυτό οφείλεται στη συγχώνευση επιπλέον δεδομένων που παράγονται από πρόσθετους αισθητήρες, με σκοπό την αύξηση του ποσοστού ανίχνευσης. Έρευνες που έκαναν χρήση του επιταχυνσιόμετρου σε συνδυασμό με γυροσκόπιο ή βαρόμετρο, πέτυχαν πολύ καλά αποτελέσματα, αφού το γυροσκόπιο συμβάλει στη βελτιστοποίηση ανίχνευσης της περιστροφής που είναι πιθανό σύμπτωμα μιας πτώσης και το βαρόμετρο υπολογίζει την υψομετρική διαφορά κατά τη διάρκεια μιας πτώσης.

Λόγω της ευρείας χρήσης των έξυπνων κινητών τηλεφώνων, ακόμη και από ανθρώπους μεγαλύτερης ηλικίας, και για τους λόγους που μόλις προαναφέρθηκαν, θεωρούμε ότι τα κινητά αποτελούν την καλύτερη επιλογή για έρευνες που στοχεύουν στην αναγνώριση δραστηριοτήτων στην καθημερινότητα υγιών ηλικιωμένων ανθρώπων στο σπίτι τους.

Όσο αναφορά όμως την αναγνώριση δραστηριοτήτων σε ηλικιωμένους που βρίσκονται είτε στο σπίτι είτε στο νοσοκομείο, με προβλήματα υγείας όπως η άνοια κ.α., θεωρούμε ότι η χρήση ασύρματων φορητών RFID αισθητήρων είναι η καλύτερη λύση, αφού ο ασθενής λόγω του μικρού βάρους και της ελάχιστης απαίτησης για συντήρηση του αισθητήρα, σχεδόν αγνοεί την ύπαρξή του.

Οπότε, παρόλο τη μείωση χρήσης ασύρματων φορητών αισθητήρων RFID στα συστήματα ανίχνευσης πτώσης, πιστεύουμε στην αναγκαιότητα της βελτίωσης αυτών των συστημάτων. Επομένως αυτή η μεταπτυχιακή διατριβή αποτελεί μία εξέλιξη στα συστήματα ανίχνευσης πτώσης που κάνουν χρήση RFID αισθητήρων, λόγω της υψηλής απόδοσης των μοντέλων που δημιουργήθηκαν.

Η χρήση αλγορίθμων βαθιάς μάθησης (deep learning), για περαιτέρω εξέλιξη των συστημάτων ανίχνευσης δραστηριοτήτων μέσω ταξινόμησης, διαφαίνεται να αποτελεί βασικό κομμάτι σε μελλοντικές έρευνες, όπου η διερεύνηση νέων μεθόδων βασισμένων στη deep learning, υπόσχεται βελτίωση της ακρίβειας στην ανίχνευση των πτώσεων.

# Βιβλιογραφία

1. Aguiar, B., Rocha, T., Silva, J., Inês Sousa, I. (2014) Accelerometer-based fall detection for smartphones. *2014 IEEE International Symposium on Medical Measurements and Applications*. <https://ieeexplore.ieee.org/document/6860110> [Πρόσβαση: 1/11/2019]
2. Al Janabi, K.B.S., Kadhim, R. (2018) Data Reduction Techniques: A Comparative Study for Attribute Selection Methods. *International Journal of Advanced Computer Science and Technology*. 8(1). [https://www.ripublication.com/ijacst18/ijacstv8n1\\_01.pdf](https://www.ripublication.com/ijacst18/ijacstv8n1_01.pdf) [Πρόσβαση: 1/9/2019]
3. Albert, M. V., Kording, K., Herrmann, M., Jayaraman, A. (2012) Fall Classification by Machine Learning Using Mobile Phones. *PLOS ONE*. 7(5). <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0036556> [Πρόσβαση: 1/11/2019]
4. Amendola, S., Bianchi, L., Marrocco, G. (2015) Movement Detection of Human Body Segments: Passive radio-frequency identification and machine-learning technologies. *IEEE Antennas and Propagation Magazine*. 57(3). <https://ieeexplore.ieee.org/document/7163526> [Πρόσβαση: 1/11/2019]
5. Awais, M., Raza, M., Ali, K., Ali, Z., Irfan, M., Chughtai, O., Khan, I., Kim, S., Ur Rehman, M. (2019) An Internet of Things Based Bed-Egress Alerting Paradigm Using Wearable Sensors in Elderly Care Environment. *Sensors* 2019. <https://www.mdpi.com/1424-8220/19/11/2498> [Πρόσβαση: 1/11/2019]
6. Chesser, M., Jayatilaka, A., Visvanathan, R., Fumeaux, C., Sample, A., Ranasinghe, D.C (2019) Super Low Resolution RF Powered Accelerometers for Alerting on Hospitalized Patient Bed Exits. *2019 IEEE International Conference on Pervasive Computing and Communications*. <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8767398> [Πρόσβαση: 1/9/2019]

7. Chia-Yeh, H., Kai-Chun, L., Chih-Ning, H., Woei-Chyn, C. & Chia-Tai, C. (2017) Novel Hierarchical Fall Detection Algorithm Using a Multiphase Fall Model. *Sensors* 2017. 17(2). <https://www.mdpi.com/1424-8220/17/2/307> [Πρόσβαση: 1/9/2019]
8. Delahoz, Y.S., Labrador, M.A. (2014) Survey on Fall Detection and Fall Prevention Using Wearable and External Sensors. *Sensors* 2014. 14(10). <https://www.mdpi.com/1424-8220/14/10/19806> [Πρόσβαση: 1/11/2019]
9. Dhakate, P. P., Patil, S., Rajeswari, K., Abin, D. (2014) Preprocessing and Classification in WEKA Using Different Classifiers. *Int. Journal of Engineering Research and Applications*. 4(8). <https://pdfs.semanticscholar.org/0789/9afe30164eea03245a5f05c4b47c1a50bfa7.pdf> [Πρόσβαση: 1/9/2019]
10. Diep, N.N., Pham, C., Phuong, T.M. (2013) A classifier based approach to real-time fall detection using low-cost wearable sensors. *2013 International Conference on Soft Computing and Pattern Recognition*. <https://ieeexplore.ieee.org/document/7054110> [Πρόσβαση: 1/9/2019]
11. Dinakaran, S., Thangaiah, P.R.J. (2013) Role of Attribute Selection in Classification Algorithms. *International Journal of Scientific & Engineering Research*. 4(6). <https://www.ijser.org/researchpaper/Role-of-Attribute-Selection-in-Classification-Algorithms.pdf> [Πρόσβαση: 1/9/2019]
12. Durgabai, R.P.L. (2014) Feature Selection using ReliefF Algorithm. *International Journal of Advanced Research in Computer and Communication Engineering*. 3(10). <https://pdfs.semanticscholar.org/f683/29dcfa2d2f915abc814288001f8e39653c2a.pdf> [Πρόσβαση: 1/9/2019]
13. Galar, M., Fernández, A., Barrenechea, E., Herrera, F. (2015) DRCW-OVO: Distance-based relative competence weighting combination for One-vs-One strategy in multi-class problems. *Pattern Recognition*. 48(1). <https://www.sciencedirect.com/science/article/abs/pii/S0031320314002829> [Πρόσβαση: 1/9/2019]
14. Gayathri, M., Sudha, A. (2014) Software Defect Prediction System using Multilayer Perceptron Neural Network with Data Mining. *International Journal of Recent Technology and Engineering*. 3(2).



- <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.675.7633&rep=rep1&type=pdf> [Πρόσβαση: 1/11/2019]
15. Habib, M. A., Mohktar, M. S., Kamaruzzaman, S. B., Lim, K. S., Pin, T. M., Ibrahim, F. (2014) Smartphone-based solutions for fall detection and prevention: challenges and open issues. *Sensors* 2014. 14(4). <https://www.mdpi.com/1424-8220/14/4/7181> [Πρόσβαση: 1/11/2019]
  16. Han, H., Jiang, X. (2014) Overcome support vector machine diagnosis overfitting. *Cancer Inform.* 13. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4264614/> [Πρόσβαση: 1/11/2019]
  17. He, J., Bai, S., Wang, X. (2017) An Unobtrusive Fall Detection and Alerting System Based on Kalman Filter and Bayes Network Classifier. *Sensors* 2017. 17(6). <https://www.mdpi.com/1424-8220/17/6/1393> [Πρόσβαση: 1/9/2019]
  18. Hsieh, C.Y., Huang, C.N., Liu, K.C., Chu, W.C., Chan, C.T. (2016) A machine learning approach to fall detection algorithm using wearable sensor. *2016 International Conference on Advanced Materials for Science and Engineering*. <https://ieeexplore.ieee.org/document/7840209> [Πρόσβαση: 1/11/2019]
  19. Huang, C.N., Chan, C.T. (2014) A ZigBee-Based Location-Aware Fall Detection System for Improving Elderly Telecare. *Int. J. Environ. Res. Public Health* 2014. 11(4). <https://www.mdpi.com/1660-4601/11/4/4233/htm> [Πρόσβαση: 1/9/2019]
  20. Igual, R., Medrano, C., Plaza, I. (2013) Challenges, issues and trends in fall detection systems. *BioMedical Engineering OnLine*. 12. <https://biomedical-engineering-online.biomedcentral.com/articles/10.1186/1475-925X-12-66> [Πρόσβαση: 1/9/2019]
  21. Jagga, Z., Gupta, D. (2014) Supervised learning classification models for prediction of plant virus encoded RNA silencing suppressors. *PLoS One*. 9(5). <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0097446>. [Πρόσβαση: 1/9/2019]
  22. Lee, J.K., Robinovitch, S.N., Park, E.J. (2014) Inertial Sensing-Based Pre-Impact Detection of Falls Involving Near-Fall Scenarios. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*. 23(2). <https://ieeexplore.ieee.org/document/6905812> [Πρόσβαση: 1/9/2019]

23. Liu, K.C., Hsieh, C.Y., Ping Hsu, S.J., Chan, C.T. (2018) Impact of Sampling Rate on Wearable-Based Fall Detection Systems Based on Machine Learning Models. *IEEE Sensors Journal*. 18(23).  
<https://ieeexplore.ieee.org/document/8478181> [Πρόσβαση: 1/11/2019]
24. Mukhopadhyay, S. C. (2015) Wearable Sensors for Human Activity Monitoring: A Review. *IEEE Sensors Journal*. 15(3).  
<https://ieeexplore.ieee.org/document/6974987/authors#authors> [Πρόσβαση: 1/9/2019]
25. Nef, T., Urwyler, P., Büchler, M., Tarnanas, I., Stucki, R., Cazzoli, D., Müri, R., Mosimann, U. (2015) Evaluation of Three State-of-the-Art Classifiers for Recognition of Activities of Daily Living from Smart Home Ambient Data. *Sensors 2015*. 15(5).  
<https://www.mdpi.com/1424-8220/15/5/11725> [Πρόσβαση: 1/11/2019]
26. Ozdemir, A.T., Barshan, B. (2014) Detecting Falls with Wearable Sensors Using Machine Learning Techniques. *Sensors 2014*. 14(6). <https://www.mdpi.com/1424-8220/14/6/10691> [Πρόσβαση: 1/9/2019]
27. Ozcift, A., Gulden, A. (2012) A Robust Multi-Class Feature Selection Strategy Based on Rotation Forest Ensemble Algorithm for Diagnosis of Erythematous Diseases. *Journal of Medical Systems*. 36(2).  
<https://link.springer.com/article/10.1007%2Fs10916-010-9558-0>  
[Πρόσβαση: 1/9/2019]
28. Pannurat, N., Thiemjarus, S., Nantajeewarawat, E. (2014) Automatic Fall Monitoring: A Review. *Sensors 2014*. 14(7). <https://www.mdpi.com/1424-8220/14/7/12900>  
[Πρόσβαση: 1/9/2019]
29. Putra, I.P.E.S., Brusey, J., Gaura, E., Vesilo, R. (2018) An Event-Triggered Machine Learning Approach for Accelerometer-Based Fall Detection. *Sensors 2018*. 18(1).  
<https://www.mdpi.com/1424-8220/18/1/20> [Πρόσβαση: 1/9/2019]
30. Ramchoun, H., Idrissi, M. A. J., Ghanou, Y., Ettaouil, M. (2016) Multilayer Perceptron: Architecture Optimization and Training. *International Journal of Interactive Multimedia and Artificial Intelligence*. 4(1).  
<https://www.ijimai.org/JOURNAL/node/907> [Πρόσβαση: 1/9/2019]
31. Ranasinghe, D. C., Roberto L. Shinmoto Torres, Hill, K., Visvanathan, R. (2014) Low cost and batteryless sensor-enabled radio frequency identification tag based

- approaches to identify patient bed entry and exit posture transitions. *Gait & Posture*. 39(1).  
<https://www.sciencedirect.com/science/article/pii/S0966636213002749?via%3Dihub> [Πρόσβαση: 1/9/2019]
32. Ranasinghe, D. C., Roberto L. Shinmoto Torres, Wickramasinghe, A. (2013) Automated Activity Recognition and Monitoring of Elderly Using Wireless Sensors: Research Challenges. *5th IEEE International Workshop on Advances in Sensors and Interfaces*. <https://ieeexplore.ieee.org/document/6576067> [Πρόσβαση: 1/9/2019]
33. Santafe, G., Inza, I., Lozano, J.A. (2015) Dealing with the evaluation of supervised classification algorithms. *Artificial Intelligence Review*. 44(4).  
<https://link.springer.com/article/10.1007%2Fs10462-015-9433-y>  
[Πρόσβαση:1/9/2019]
34. Sharma, N., Bajpai, A., Litoriya, R. (2012) Comparison the various clustering algorithms of weka. *International Journal of Emerging Technology and Advanced Engineering*. 2(5).  
<https://pdfs.semanticscholar.org/eca2/5eb78be04ffe09b029dd1d36f5ba66749f29.pdf> [Πρόσβαση: 1/9/2019]
35. Shi, D., Guan, J., Zurada, J. (2015) Cost-Sensitive Learning for Imbalanced Bad Debt Datasets in Healthcare Industry. *IEEE, 2015 Asia-Pacific Conference on Computer Aided System Engineering*. <https://ieeexplore.ieee.org/document/7286989>  
[Πρόσβαση: 1/9/2019]
36. Shinmoto Torres, R. L., Visvanathan, R., Abbott, D., Hill, K. D., Ranasinghe, D. C. (2017A) A battery-less and wireless wearable sensor system for identifying bed and chair exits in a pilot trial in hospitalized older people. *PLoS One*. 12(10).  
<https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0185670>  
[Πρόσβαση: 1/9/2019]
37. Shinmoto Torres, R. L., Shi, Q., Van den Hengel, A., Ranasinghe, D. C. (2017B) A hierarchical model for recognizing alarming states in a batteryless sensor alarm intervention for preventing falls in older people. *Pervasive and Mobile Computing*. 40.  
<https://www.sciencedirect.com/science/article/pii/S1574119216302206>  
[Πρόσβαση: 1/9/2019]

38. Shinmoto Torres, R. L., Visvanathan, R., Hoskins, S., Anton Van den Hengel, A., Ranasinghe, D. (2016A) Effectiveness of a Batteryless and Wireless Wearable Sensor System for Identifying Bed and Chair Exits in Healthy Older People. *Sensors* 2016. 16(4). <https://www.mdpi.com/1424-8220/16/4/546/htm> [Πρόσβαση: 1/9/2019]
39. Shinmoto Torres, R. L., Ranasinghe, D. C., Shi, Q., Anton Van den Hengel (2016B) Learning from Imbalanced Multiclass Sequential Data Streams Using Dynamically Weighted Conditional Random Fields. *ArXiv* 2016. <https://arxiv.org/abs/1603.03627> [Πρόσβαση: 1/9/2019]
40. Shinmoto Torres, R. L., Ranasinghe, D. C., Shi, Q., Sample, A. P (2013A) Sensor enabled wearable RFID technology for mitigating the risk of falls near beds. *2013 IEEE International Conference on RFID*. <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=6548154> [Πρόσβαση: 1/9/2019]
41. Shinmoto Torres, R. L., Ranasinghe, D. C., Shi, Q. (2013B) Evaluation of Wearable Sensor Tag Data Segmentation Approaches for Real Time Activity Classification in Elderly. In: Stojmenovic I., Cheng Z., Guo S. (eds) *Mobile and Ubiquitous Systems: Computing, Networking, and Services. MobiQuitous 2013. Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering*, vol 131. *Springer*. <http://autoidlab.cs.adelaide.edu.au/node/102> [Πρόσβαση: 1/9/2019]
42. Wahid, N.S.A., Saad, P., Hariharan, M. (2016) Automatic infant cry pattern classification for a multiclass problem. *Journal of Telecommunication, Electronic and Computer Engineering*. 8. <http://journal.utem.edu.my/index.php/jtec/article/view/838> [Πρόσβαση:1/9/2019]
43. Wang Z., Xue X. (2014) Multi-Class Support Vector Machine. In: Ma Y., Guo G. (eds) *Support Vector Machines Applications*. *Springer*. [https://link.springer.com/chapter/10.1007/978-3-319-02300-7\\_2](https://link.springer.com/chapter/10.1007/978-3-319-02300-7_2) [Πρόσβαση: 1/11/2019]
44. Wickramasinghe, A., Ranasinghe, D.C., Fumeaux, C., Hill, K. D, & Visvanathan, R. (2017) Sequence Learning with Passive RFID Sensors for Real-Time Bed-Egress Recognition in Older People. *IEEE Journal of Biomedical and Health Informatics*.

- 21(4). <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=7484257>  
[Πρόσβαση: 1/9/2019]
45. Wickramasinghe, A., Ranasinghe, D.C. (2015 A) Ambulatory Monitoring Using Passive Computational RFID Sensors. *IEEE Sensors Journal*. 15{10}.  
<https://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=7134710> [Πρόσβαση: 1/9/2019]
46. Wickramasinghe, A., Ranasinghe, D.C. (2015 B) Recognizing Activities in Real Time Using Body Worn Passive Sensors With Sparse Data Streams: To Interpolate or Not To Interpolate?. *12th EAI International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services*.  
<https://pdfs.semanticscholar.org/30a2/79341828429fc3bda284a429faee31ba802f.pdf> [Πρόσβαση: 1/9/2019]
47. Wang, J., Zhang, Z., Li, B., Lee, S., Sherratt, R.S. (2014) An enhanced fall detection system for elderly person monitoring using consumer home networks. *IEEE Transactions on Consumer Electronics*. 60(1).  
<https://ieeexplore.ieee.org/document/6780921> [Πρόσβαση: 1/9/2019]
48. Yuan, J., Tan, K. K., Lee, T. H., Huat Koh, G. C. (2014) Power-Efficient Interrupt-Driven Algorithms for Fall Detection and Classification of Activities of Daily Living. *IEEE Sensors Journal*. 15(3).  
<https://ieeexplore.ieee.org/document/6902765/authors#authors> [Πρόσβαση: 1/9/2019]
49. Zerrouki, N., Harrou, F., Houacine, A., Sun, Y. (2016) Fall detection using supervised machine learning algorithms: A comparative study. *2016 8th International Conference on Modelling, Identification and Control*.  
<https://ieeexplore.ieee.org/document/7804195/citations#citations> [Πρόσβαση: 1/11/2019]