



ΟΙΚΟΝΟΜΙΚΟ ΠΑΝΕΠΙΣΤΗΜΙΟ ΑΘΗΝΩΝ

**ΠΡΟΓΡΑΜΜΑ ΜΕΤΑΠΤΥΧΙΑΚΩΝ ΣΠΟΥΔΩΝ
ΣΤΗΝ ΕΠΙΣΤΗΜΗ ΤΩΝ ΥΠΟΛΟΓΙΣΤΩΝ**

**Διπλωματική Εργασία
Μεταπτυχιακού Διπλώματος Ειδίκευσης**

«Αναγνώριση Δραστηριοτήτων από Ενδείξεις Αισθητήρων»

ΝΙΚΟΛΑΟΣ ΠΑΠΑΝΕΛΟΠΟΥΛΟΣ

Επιβλέπων: ΙΩΝ ΑΝΔΡΟΥΤΣΟΠΟΥΛΟΣ

ΑΘΗΝΑ, ΙΟΥΝΙΟΣ 2010

ΠΕΡΙΕΧΟΜΕΝΑ

ΚΕΦΑΛΑΙΟ 1: Εισαγωγή

1.1 Αντικείμενο της εργασίας.....	4
1.2 Διάρθρωση του υπόλοιπου κειμένου.....	4

ΚΕΦΑΛΑΙΟ 2: Προηγούμενες μέθοδοι αναγνώρισης

δραστηριοτήτων

2.1 Μέθοδοι βασισμένες σε Κρυμμένα Μαρκοβιανά Μοντέλα.....	7
2.2 Μέθοδοι βασισμένες σε αφελείς ταξινομητές Bayes.....	15
2.3 Μέθοδοι που χρησιμοποιούν κανόνες συσχέτισης.....	16
2.4 Μέθοδοι που χρησιμοποιούν υπό συνθήκη τυχαία πεδία.....	22
2.5 Μέθοδοι που χρησιμοποιούν δέντρα απόφασης.....	22
2.6 Σχετικές εργασίες.....	23

ΚΕΦΑΛΑΙΟ 3: Το σύστημα της εργασίας

3.1 Εισαγωγή.....	26
3.2 Γενική περιγραφή του συστήματος.....	26
3.3 Ο αλγόριθμος AdaBoost.....	31
3.4 Ταξινομητές λογιστικής παλινδρόμησης.....	32

ΚΕΦΑΛΑΙΟ 4: Πειραματικά αποτελέσματα

4.1 Εισαγωγή.....	34
4.2 Σύνολα δεδομένων.....	34
4.3 Αποτελέσματα με τον AdaBoost.....	36
4.4 Αποτελέσματα με λογιστική παλινδρόμηση.....	46

ΚΕΦΑΛΑΙΟ 5: Συμπεράσματα

5.1 Σύνοψη αποτελεσμάτων.....	49
5.2 Πιθανές μελλοντικές επεκτάσεις.....	50
Αναφορές.....	51

ΚΕΦΑΛΑΙΟ 1

ΕΙΣΑΓΩΓΗ

1.1 Αντικείμενο της εργασίας

Σκοπός της εργασίας αυτής ήταν η ανάπτυξη ενός συστήματος ικανού να αναγνωρίζει τις δραστηριότητες (π.χ. προετοιμασία γεύματος, προετοιμασία για ύπνο) ενός ανθρώπου που κατοικεί σε ένα σπίτι με αισθητήρες. Το εγχείρημα αυτό είναι σημαντικό, διότι θα μπορούσε να βοηθήσει ανθρώπους που ζουν μόνοι τους και ιδιαίτερα ηλικιωμένους. Για παράδειγμα, ένας ηλικιωμένος ενδέχεται να λαμβάνει φαρμακευτική αγωγή για την καρδιά του, συγκεκριμένες ώρες κάθε ημέρα. Αν ξεχάσει μία ημέρα να λάβει τα φάρμακά του τη σωστή ώρα, ένα σύστημα αναγνώρισης δραστηριοτήτων θα μπορούσε να τον ειδοποιήσει. Επίσης, ένας άνθρωπος που κοιμάται για λίγες ώρες κάθε μεσημέρι ενδέχεται να ξυπνάει συνήθως περίπου στις 4:00 μ.μ. Αν κάποια ημέρα, ενώ έχει κοιμηθεί, δεν έχει ξυπνήσει μέχρι εκείνη την ώρα, τότε ίσως χρειάζεται ιατρική βοήθεια. Ένα σύστημα αναγνώρισης δραστηριοτήτων θα μπορούσε να ειδοποιήσει τους συγγενείς ή αρμόδιους γιατρούς. Ακόμη, απότομες αλλαγές στις συνήθειες ενός ανθρώπου ενδέχεται να σηματοδοτούν κατάθλιψη, άνοια ή άλλα ιατρικά προβλήματα.

Η αυτόματη παρακολούθηση ηλικιωμένων ή άλλων ανθρώπων που χρειάζονται επίβλεψη στα σπίτια τους παρέχει διπλό όφελος. Αφενός δεν απαιτείται η προσαγωγή τους σε νοσοκομεία ή άλλα κέντρα, αποφεύγοντας τη συμφορήσή τους και το κόστος νοσηλείας, αφετέρου οι άνθρωποι αυτοί μπορούν να συνεχίσουν να ζουν στο οικείο περιβάλλον τους. Επίσης, η αναγνώριση δραστηριοτήτων μέσω αισθητήρων παρουσιάζει πλεονεκτήματα, όπως το μικρό κόστος των αισθητήρων και η διακριτική παρουσία τους στα σπίτια, αντίθετα από τη χρήση καμερών, που πιθανότατα θα ενοχλούσαν περισσότερο τους παρακολουθούμενους.

Το σύστημα της εργασίας αξιοποιεί ενδείξεις αισθητήρων και αλγορίθμους μηχανικής μάθησης. Δοκιμάστηκε πειραματικά, σε δεδομένα άλλων ερευνητών, με δύο αλγόριθμους επιβλεπόμενης μάθησης, τον AdaBoost και έναν ταξινομητή λογιστικής παλινδρόμησης (logistic regression). Τα πειραματικά αποτελέσματα με τον AdaBoost ήταν καλύτερα. Προσπαθήσαμε να αναγνωρίσουμε έξι είδη δραστηριοτήτων ενός κατοίκου σπιτιού, αλλά και τότε ακριβώς συνέβησαν. Στα αποτελέσματα των πειραμάτων μας επιτύχαμε μεγάλα ποσοστά ορθότητας (accuracy), πάνω από 90% για τις περισσότερες δραστηριότητες.

1.2 Διάρθρωση του υπόλοιπου κειμένου

Το δεύτερο κεφάλαιο της εργασίας αποτελεί βιβλιογραφική επισκόπηση σχετικών μεθόδων που έχουν προταθεί από άλλους ερευνητές. Το τρίτο κεφάλαιο περιγράφει το σύστημα αναγνώρισης δραστηριοτήτων της παρούσας εργασίας. Το τέταρτο κεφάλαιο

περιγράφει τα πειράματα που πραγματοποιήθηκαν στη διάρκεια της εργασίας και τα αποτελέσματά τους. Το πέμπτο κεφάλαιο συνοψίζει τα αποτελέσματα της εργασίας και προτείνει μελλοντικές επεκτάσεις.

ΚΕΦΑΛΑΙΟ 2

ΠΡΟΗΓΟΥΜΕΝΕΣ ΜΕΘΟΔΟΙ ΑΝΑΓΝΩΡΙΣΗΣ ΔΡΑΣΤΗΡΙΟΤΗΤΩΝ

Σε αυτό το κεφάλαιο αναλύουμε τις σημαντικότερες προηγούμενες μεθόδους για την αναγνώριση δραστηριοτήτων μέσα σε ένα σπίτι.

2.1 Μέθοδοι βασισμένες σε Κρυμμένα Μαρκοβιανά Μοντέλα

Το Μαρκοβιανό μοντέλο είναι ένας γράφος. Οι κόμβοι του γράφου, αντιπροσωπεύουν το σύνολο των καταστάσεων όπου μπορεί να βρεθεί ένας άνθρωπος, ένα σύστημα, ένα φυσικό φαινόμενο κλπ. Οι ακμές του γράφου αντιπροσωπεύουν την πιθανότητα μετάβασης από μία κατάσταση-κόμβο σε κάποια άλλη. Στη συνέχεια παρουσιάζουμε τους ορισμούς για το Μαρκοβιανό μοντέλο.

ΟΡΙΣΜΟΙ ΣΤΟ ΜΑΡΚΟΒΙΑΝΟ ΜΟΝΤΕΛΟ

$$Q = q_1, q_2, \dots, q_N$$

Q είναι το σύνολο των N πιθανών καταστάσεων.

$$A = a_{00}, a_{0,1}, \dots, a_{n1}, \dots, a_{nn}$$

A είναι ο πίνακας πιθανοτήτων μεταβάσεων. Κάθε a_{ij} είναι η πιθανότητα μετάβασης από τον κόμβο i στον κόμβο j . Επίσης ισχύει ότι $\sum_{j=1}^n a_{ij} = 1, \forall i$.

$$\pi = \pi_1, \pi_2, \dots, \pi_N$$

π_i είναι η πιθανότητα εκκίνησης από την κατάσταση q_i . Ισχύει ότι $\sum_{i=1}^N \pi_i = 1$.


$$P(q_i | q_1, q_2, \dots, q_{i-1}) = P(q_i | q_{i-1}) \\ = a_{(i-1),i}$$

Υπόθεση Μαρκόφ περιορισμένου ορίζοντα. (Για Μαρκοβιανό μοντέλο 1^{ης} τάξης).

Υποθέτουμε επίσης ότι το σύστημα είναι στάσιμο, δηλαδή ότι οι πιθανότητες των μεταβάσεων $a_{i,j}$ παραμένουν χρονικά αμετάβλητες.

ΠΑΡΑΔΕΙΓΜΑ 1

Υποθέτουμε ότι θέλουμε να δημιουργήσουμε ένα Μαρκοβιανό μοντέλο του καιρού. Οι πιθανές καταστάσεις όπου μπορεί να βρεθεί ο καιρός είναι οι καταστάσεις 1-Βροχή, 2-Ζέστη, 3-Κρύο και οι πιθανότητες μετάβασης από μία κατάσταση σε άλλη φαίνονται στο Σχήμα 1 που αποτελεί το γράφο του Μαρκοβιανού μοντέλου.



Σχήμα 1

Σύμφωνα με το Σχήμα 1, αν ο καιρός βρίσκεται στην κατάσταση «Βροχή», τότε η πιθανότητα ο καιρός να βρεθεί στην κατάσταση «Βροχή» την επόμενη ημέρα είναι 0.4, η πιθανότητα να βρεθεί στην κατάσταση «Ζέστη» είναι 0.2 και στην κατάσταση «Κρύο» 0.4. Μία σημαντική ιδιότητα του Μαρκοβιανού μοντέλου 1^{ης} τάξης είναι ότι η μετάβαση από μία κατάσταση σε μία άλλη εξαρτάται μόνο από την παρούσα κατάσταση και όχι από τις μεταβάσεις του παρελθόντος. Δηλαδή, στο ΠΑΡΑΔΕΙΓΜΑ 1 αν υποθέσουμε ότι ο καιρός μία δεδομένη ημέρα π.χ. τη Δευτέρα βρίσκεται στην κατάσταση «Βροχή», τότε η πιθανότητα να βρίσκεται στην κατάσταση «Ζέστη» την Τρίτη είναι 0.2, ανεξάρτητα από τις καταστάσεις όπου βρισκόταν τις προηγούμενες ημέρες. Όλες οι καταστάσεις φέρουν κάποιες πιθανότητες εκκίνησης, που δείχνουν πόσο πιθανό είναι το μοντέλο να βρεθεί αρχικά σε αυτές. Οι πιθανότητες εκκίνησης για κάποιους κόμβους μπορεί να είναι μηδέν.

Αντίθετα από το απλό Μαρκοβιανό μοντέλο, στο Κρυμμένο Μαρκοβιανό μοντέλο (Hidden Markov Model, HMM) οι καταστάσεις δεν είναι άμεσα παρατηρήσιμες. Μπορούμε μόνο να εκτιμήσουμε έμμεσα πόσο πιθανό είναι το HMM να βρίσκεται σε κάποια

κατάσταση, παρατηρώντας γεγονότα που λαμβάνουν χώρα όταν το HMM βρίσκεται στις διάφορες καταστάσεις.

Για παράδειγμα, ένας κλιματολόγος το έτος 2010 μελετά το φαινόμενο του θερμοκηπίου και θέλει να συγκρίνει τη συμπεριφορά που είχε ο καιρός το καλοκαίρι του 2010 με το καλοκαίρι του 1995. Ο κλιματολόγος όμως δεν έχει στη διάθεσή του δεδομένα για τον καιρό του 1995, εκτός από το ημερολόγιο ενός μικρού παιδιού, του Γιώργου, που περιγράφει πόσα παγωτά έφαγε κάθε μία ημέρα του καλοκαιριού.¹ Χάριν ευκολίας θεωρούμε ότι υπάρχουν μόνο δύο καταστάσεις καιρού: 1-Κρύο, 2-Ζέστη. Στόχος λοιπόν του κλιματολόγου είναι να συμπεράνει, με βάση τα παγωτά που έφαγε ο Γιώργος, ποια ήταν η κατάσταση του καιρού σε κάθε μία ημέρα του καλοκαιριού του 1995. Τα παγωτά στη συγκεκριμένη περίπτωση είναι τα γεγονότα, από τα οποία προσπαθούμε να συμπεράνουμε σε ποιες καταστάσεις βρέθηκε διαδοχικά το μοντέλο. Παρακάτω παρουσιάζουμε τους ορισμούς για το HMM.

ΟΡΙΣΜΟΙ ΣΤΟ ΚΡΥΜΜΕΝΟ ΜΑΡΚΟΒΙΑΝΟ ΜΟΝΤΕΛΟ

$$Q = q_1, q_2, \dots, q_N$$

Q είναι το σύνολο των N πιθανών καταστάσεων.

$$A = a_{00}, a_{0,1}, \dots, a_{n1}, \dots, a_{nn}$$

A είναι ο πίνακας πιθανοτήτων μεταβάσεων. $\sum_{j=1}^n a_{ij} = 1, \forall i$.

$$O = o_1, o_2, \dots, o_T$$

O είναι το σύνολο των δυνατών παρατηρήσεων-γεγονότων.

$$B = b_i(o_i)$$

Κάθε $b_i(o_i)$ εκφράζει την πιθανότητα να παραχθεί o_i όταν βρισκόμαστε στην κατάσταση q_i .

$$\pi = \pi_1, \pi_2, \dots, \pi_N$$

π είναι το σύνολο των πιθανοτήτων εκκίνησης. $\sum_{i=1}^N \pi_i = 1$.

$$P(q_i | q_1, q_2, \dots, q_{i-1}) = P(q_i | q_{i-1})$$

Υπόθεση Μαρκόφ περιορισμένου ορίζοντα. (Για Μαρκοβιανό μοντέλο 1^{ης} τάξης.)

$$P(o_i | q_1, \dots, q_T, o_1, \dots, o_T) = P(o_i | q_i)$$

Υπόθεση ανεξαρτησίας εξόδου. (Για Μαρκοβιανό μοντέλο 1^{ης} τάξης.)

Υποθέτουμε επίσης ότι το σύστημα είναι στάσιμο, δηλαδή ότι οι πιθανότητες των μεταβάσεων $a_{i,j}$ παραμένουν χρονικά αμετάβλητες.

¹ Παράδειγμα βασισμένο σε αντίστοιχο παράδειγμα των Jurafsky και Martin (2006).

ΠΑΡΑΔΕΙΓΜΑ 2


Κατανομή πιθανοτήτων των γεγονότων (αριθμός παγωτών)
δεδομένων των καταστάσεων Κρύο-Ζέστη:

$$\begin{aligned} P(1|Κρύο) &= 0.7 \\ P(2|Κρύο) &= 0.2 \\ P(3|Κρύο) &= 0.1 \end{aligned}$$

$$\begin{aligned} P(1|Ζέστη) &= 0.1 \\ P(2|Ζέστη) &= 0.4 \\ P(3|Ζέστη) &= 0.5 \end{aligned}$$

Κατανομή πιθανοτήτων κόμβων εκκίνησης:

$$\begin{aligned} P(\text{Ζέστη} | \text{αρχή}) &= 0.7 \\ P(\text{Κρύο} | \text{αρχή}) &= 0.3 \end{aligned}$$



Σχήμα 2

Στο ΠΑΡΑΔΕΙΓΜΑ 2, υποθέτουμε ότι ο κλιματολόγος παρατήρησε στο ημερολόγιο του Γιώργου τα γεγονότα 3, 1, 3 (δηλαδή ότι έφαγε σε μία ημέρα 3 παγωτά, την επόμενη 1 και τη μεθεπόμενη 3) και θέλει να υπολογίσει την πιθανότητα ο καιρός να βρέθηκε στις καταστάσεις Ζέστη-Κρύο-Ζέστη. Ο αλγόριθμος Viterbi (μία μορφή δυναμικού προγραμματισμού) μπορεί να χρησιμοποιηθεί για να υπολογιστεί η πιθανότερη ακολουθία καταστάσεων δεδομένης μιας ακολουθίας παρατηρήσεων γεγονότων.

Όπως και στο Μαρκοβιανό μοντέλο, έτσι και στο Κρυμμένο Μαρκοβιανό μοντέλο δεχόμαστε την υπόθεση του Μαρκόφ. Επιπροσθέτως, το Κρυμμένο Μαρκοβιανό μοντέλο κάνει μία ακόμα υπόθεση: Η πιθανότητα να παραχθεί ένα γεγονός, εξαρτάται μόνο από την κατάσταση στην οποία βρισκόμαστε, όχι από άλλες καταστάσεις ή γεγονότα. Η πιθανότητα

αυτή καλείται «υπόθεση ανεξαρτησίας εξόδου». Για παράδειγμα, η πιθανότητα ο κλιματολόγος να παρατηρήσει ότι ο Γιώργος έφαγε 3 παγωτά εξαρτάται μόνο από την κατάσταση όπου βρισκόταν ο καιρός εκείνη τη συγκεκριμένη μέρα και όχι από καταστάσεις όπου βρέθηκε άλλες ημέρες ή από γεγονότα άλλων ημερών.

Οι Kasteren κ.ά. (2008) χρησιμοποίησαν ένα HMM για την αναγνώριση των δραστηριοτήτων σε ένα σπίτι. Θεώρησαν ότι οι μη ορατές καταστάσεις είναι οι δραστηριότητες που εκτελούνται σε ένα σπίτι, ενώ οι παρατηρήσεις είναι διανύσματα που αποτελούνται από δεδομένα αισθητήρων. Χώρισαν το χρόνο σε διαστήματα σταθερού μήκους των 60 δευτερολέπτων. Για κάθε χρονικό διάστημα t , όρισαν μία μεταβλητή y_t που αντιπροσωπεύει τη δραστηριότητα που εκτελείται σε αυτό το χρονικό διάστημα. Το διάνυσμα $\vec{y} = \langle y_1, y_2, \dots, y_T \rangle$ παριστάνει τις δραστηριότητες που εκτελέστηκαν στα επιμέρους χρονικά διαστήματα $t_i, i = 1, \dots, T$. Ως x_t^i όρισαν μία μεταβλητή που παίρνει την τιμή 0 αν ο αισθητήρας i ενεργοποιήθηκε στο χρονικό διάστημα t και 1 διαφορετικά. Η παρατήρηση σε κάθε χρονικό διάστημα t είναι ένα διάνυσμα $\vec{x}_t = \langle x_t^1, x_t^2, \dots, x_t^N \rangle$ (όπου N είναι το πλήθος των αισθητήρων που εγκαταστάθηκαν στο σπίτι), ενώ το διάνυσμα $\vec{x} = \langle \vec{x}_1, \vec{x}_2, \dots, \vec{x}_T \rangle$ αντιπροσωπεύει το σύνολο των παρατηρήσεων για όλα τα χρονικά διαστήματα t_i . Ακριβέστερα, ως τιμές x_t^i χρησιμοποίησαν τα ακόλουθα δεδομένα (διαφορετικά σε κάθε ένα από τρία πειράματα):

1. **«ωμή» αναπαράσταση του αισθητήρα:** $x_t^i = 1$ όταν ο αισθητήρας i είναι ενεργοποιημένος και 0 διαφορετικά..
2. **αναπαράσταση αλλαγής σημείου:** $x_t^i = 1$, αν στο διάστημα t άλλαξε η τιμή του αισθητήρα, διαφορετικά 0. Για παράδειγμα, αν ο δεύτερος αισθητήρας ήταν ενεργοποιημένος για τα χρονικά διαστήματα t_1, t_2, t_3 και στο χρονικό διάστημα t_4 απενεργοποιήθηκε, τότε $x_{t_4}^2 = 1$.
3. **ενεργοποίηση τελευταίου αισθητήρα:** $x_t^i = 1$, αν στο διάστημα t ο i -στός αισθητήρας ήταν εκείνος που είχε ενεργοποιηθεί πιο πρόσφατα, διαφορετικά 0.

Τα πειράματα που πραγματοποιήσαν ήταν τρία. Εκτός από τη μέθοδο του HMM χρησιμοποιήσαν και τη μέθοδο των Υπό Συνθήκη Τυχαίων Πεδίων (Conditional Random Fields, CRFs), η οποία αναλύεται παρακάτω. Στα πειράματά τους, έλεγξαν την ακρίβεια των δύο μοντέλων σε **συνθήκες πραγματικού χρόνου** και σε **συνθήκες μη πραγματικού χρόνου**. Ο όρος **συνθήκες πραγματικού χρόνου** σημαίνει ότι για την αναγνώριση των δραστηριοτήτων χρησιμοποιούνταν ανά πάσα στιγμή μόνο παρατηρήσεις του παρελθόντος, ενώ ο όρος **συνθήκες μη πραγματικού χρόνου** σημαίνει ότι, χρησιμοποιούνταν και παρατηρήσεις του μέλλοντος.

Την ακρίβεια των δύο μοντέλων την προσδιόρισαν χρησιμοποιώντας δύο διαφορετικά μέτρα επίδοσης. Ο λόγος είναι ότι η συλλογή των δεδομένων των αισθητήρων (γεγονότα) είναι μη ισορροπημένη (δηλαδή υπάρχουν δραστηριότητες που εμφανίζονται πιο συχνά από άλλες).

1. **Ποσοστό ορθότητας (accuracy):** Το ποσοστό των χρονικών διαστημάτων t που ταξινομήθηκε στη σωστή δραστηριότητα ή στη «μη-δραστηριότητα», θεωρώντας ότι το πολύ μία δραστηριότητα εξελίσσεται ανά πάσα στιγμή. Στη μη-δραστηριότητα κατατάσσονται τα χρονικά διαστήματα t όπου δεν εκτελέστηκε καμία δραστηριότητα.
2. **Μακροσκοπική ακρίβεια (macro-average precision):** Ορίζεται ως εξής:

$$\frac{1}{C} \sum_{c=1}^C P_c$$

όπου C είναι το πλήθος των ειδών δραστηριοτήτων και $P_c = \frac{TP_c}{TP_c + FP_c}$. TP_c (true positives) είναι ο αριθμός των διαστημάτων όπου το σύστημα θεώρησε σωστά ότι συμβαίνει η δραστηριότητα c και FP_c (false positives) ο αριθμός των διαστημάτων όπου το σύστημα θεώρησε λανθασμένα ότι συμβαίνει η δραστηριότητα c .

ΠΑΡΑΔΕΙΓΜΑ 3 (ΠΟΣΟΣΤΟ ΟΡΘΟΤΗΤΑΣ)

Υποθέτουμε ότι κάποιος άνθρωπος που κατοικεί σε ένα σπίτι πραγματοποίησε 3 δραστηριότητες, τις 1, 2, 3 στα χρονικά διαστήματα t_2 , t_4 , t_6 αντίστοιχα. Τα διαστήματα t_1 , t_3 , t_5 , t_7 είναι διαστήματα όπου δεν εκτελέστηκε καμία δραστηριότητα. Το σύστημα που κατασκευάστηκε, όμως, συμπέρανε ότι στο χρονικό διάστημα t_2 και t_5 πραγματοποιήθηκε η δραστηριότητα 2, στο χρονικό διάστημα t_4 πραγματοποιήθηκε η δραστηριότητα 1 και στο χρονικό διάστημα t_6 πραγματοποιήθηκε η δραστηριότητα 3. Επίσης συμπέρανε ότι στα διαστήματα t_1 , t_3 , t_7 δεν πραγματοποιήθηκε καμία δραστηριότητα. Τότε, το ποσοστό ορθότητας του συστήματος είναι $4/7$ ή 57.14% .

ΠΑΡΑΔΕΙΓΜΑ 4 (ΜΑΚΡΟΣΚΟΠΙΚΗ ΑΚΡΙΒΕΙΑ)

Υποθέτουμε ότι κάποιος άνθρωπος που κατοικεί σε ένα σπίτι πραγματοποίησε 3 δραστηριότητες, τις 1, 2, 3 στα χρονικά διαστήματα t_1 , t_2 , t_3 αντίστοιχα. Τα διαστήματα t_4 , t_5 , t_6 αντιστοιχούν στη μη-δραστηριότητα. Το σύστημα που κατασκευάστηκε, όμως, συμπέρανε ότι στα χρονικά διαστήματα t_2 , t_4 , πραγματοποιήθηκε η δραστηριότητα 1, στο χρονικό διάστημα t_1 πραγματοποιήθηκε η δραστηριότητα 2 και στο χρονικό διάστημα t_3 πραγματοποιήθηκε η δραστηριότητα 3. Τα διαστήματα t_5 , t_6 κατετάγησαν στη μη-δραστηριότητα. Τότε για τη δραστηριότητα 1, η ακρίβεια τάξης είναι 0, για τη δραστηριότητα 2 η ακρίβεια τάξης είναι 0, για την 3 η ακρίβεια τάξης είναι 1 και για τη μη-δραστηριότητα η ακρίβεια τάξης είναι $2/3$. Τότε η μακροσκοπική ακρίβεια είναι $(0+0+1+2/3)/6=1/3$ ή 27.77% .

ΠΑΡΑΔΕΙΓΜΑ 5 (ΜΑΚΡΟΣΚΟΠΙΚΗ ΑΚΡΙΒΕΙΑ)

Ας υποθέσουμε ότι έχουμε ένα άλλο παράδειγμα, όπου ο συνολικός χρόνος του πειράματος ήταν $T=t_1+t_2+t_3+t_4+t_5+t_6+t_7$, όπου κάθε χρονικό διάστημα t_i έχει σταθερό μήκος 60 δευτερολέπτων. Ένας άνθρωπος πραγματοποίησε τη δραστηριότητα 1 στα χρονικά διαστήματα t_1 , t_4 , t_6 , τη δραστηριότητα 2 στο χρονικό διάστημα t_2 , t_3 και τη δραστηριότητα 3 στα χρονικά διαστήματα t_1 , t_3 , t_4 . Στα διαστήματα t_5 , t_7 δεν πραγματοποιήθηκε κάποια δραστηριότητα. Το σύστημα θεώρησε ότι η δραστηριότητα 1 συνέβη στα διαστήματα t_1 , t_6 , η δραστηριότητα 2 στο t_2 και η δραστηριότητα 3 στο t_4 . Τα διαστήματα t_5 , t_7 κατετάγησαν στη μη-δραστηριότητα. Τότε η ακρίβεια τάξης για τη δραστηριότητα 1 είναι $2/3$, για τη δραστηριότητα 2 είναι $1/2$, για τη δραστηριότητα 3 είναι $1/3$ και για τη μη-δραστηριότητα $2/2=1$. Οπότε η μακροσκοπική ακρίβεια του συστήματος είναι $(2/3+1/2+1/3+1)/7=(5/2)/7=0.35$ ή 35.71% .

Στο 1^ο πείραμα σύγκριναν την ακρίβεια των μεθόδων που χρησιμοποίησαν. Δοκίμασαν και τους τρεις εναλλακτικούς ορισμούς των x_t^i , καθώς και συνδυασμό του 2^{ου} και 3^{ου} ορισμού των x_t^i . Στην περίπτωση του συνδυασμού, τα διανύσματα-παρατηρήσεις περιέχουν τα x_t^i υπολογισμένα και με τους δύο τρόπους. Το 1^ο πείραμα πραγματοποιήθηκε σε συνθήκες μη πραγματικού χρόνου. Σε όλες τις περιπτώσεις, το μοντέλο CRF πέτυχε μεγαλύτερο ποσοστό ορθότητας. Αντίθετα το μοντέλο HMM πέτυχε μεγαλύτερη μακροσκοπική ακρίβεια.

Στο 2^ο πείραμα εξέτασαν το ποσοστό ορθότητας και τη μακροσκοπική ακρίβεια σε συνάρτηση με τον αριθμό των ημερών που χρησιμοποίησαν για την εκπαίδευση του συστήματος. Όσο αναφορά το ποσοστό ορθότητας, το μοντέλο CRF πέτυχε καλύτερα αποτελέσματα σε σχέση με το HMM. Αντίθετα, το μοντέλο HMM πέτυχε καλύτερη μακροσκοπική ακρίβεια. Και τα δύο μοντέλα τείνουν να σταθεροποιήσουν τα δύο μέτρα επίδοσης σχεδόν στον ίδιο αριθμό ημερών εκπαίδευσης.

Στο 3^ο πείραμα αξιολογήθηκαν τα δύο μοντέλα σε συνθήκες πραγματικού χρόνου και σε συνθήκες μη πραγματικού χρόνου. Από τα αποτελέσματα του πειράματος συμπεράναν ότι σε συνθήκες μη πραγματικού χρόνου το μοντέλο CRF υπερτερεί όσον αναφορά τη μακροσκοπική ακρίβεια, ενώ το μοντέλο HMM υπερτερεί όσο αναφορά το ποσοστό ορθότητας. Σε συνθήκες πραγματικού χρόνου, το μοντέλο HMM υπερτερεί και με τα δύο μέτρα.

Οι Singla κ.ά. (2008) χρησιμοποίησαν επίσης ένα HMM, στο οποίο όμως οι καταστάσεις αντιστοιχούσαν στα γεγονότα των αισθητήρων.

2.2 Μέθοδοι βασισμένοι σε αφελείς ταξινομητές Bayes

Ο Παπαματθαϊάκης (2008) χρησιμοποίησε έναν «αφελή ταξινομητή Bayes» (Naïve Bayes, NB). Οι ταξινομητές αυτοί περιγράφονται στα περισσότερα εισαγωγικά βιβλία τεχνητής νοημοσύνης (π.χ. Russel και Norvig, 2003). Στόχος του Παπαματθαϊάκη φαίνεται πως ήταν να κατασκευάσει ένα σύστημα που να αποφαινεται αν μία δραστηριότητα (και ποια) εκτελέστηκε (οποιαδήποτε στιγμή) στη διάρκεια ενός δεδομένου διαστήματος, όχι να αποκρίνεται από πότε ως πότε εκτελέστηκε κάθε δραστηριότητα. Ως χαρακτηριστικά (features) του ταξινομητή χρησιμοποίησε τη συχνότητα ενεργοποίησης κάθε αισθητήρα εντός του διαστήματος. Στο πείραμα που πραγματοποίησε, προσπάθησε να αναγνωρίσει συνολικά 158 δραστηριότητες που εκτέλεσε κάποιος άνθρωπος σε χρονικό διάστημα δύο εβδομάδων. Ο ταξινομητής συνολικά κατάταξε σωστά 105 από τις 158 δραστηριότητες, ενώ κατέταξε λανθασμένα 53 δραστηριότητες. Ο Παπαματθαϊάκης κατέληξε στο συμπέρασμα ότι ο ταξινομητής NB δεν ανταποκρίθηκε καλά σε σχέση με άλλες μεθόδους αναγνώρισης δραστηριοτήτων (όπως δέντρα απόφασης, κανόνες συσχέτισης), τις οποίες εξέτασε επίσης.

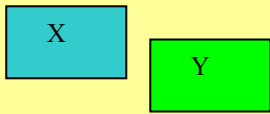
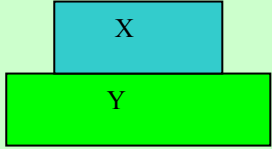
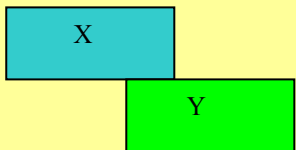
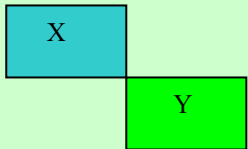
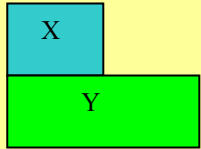
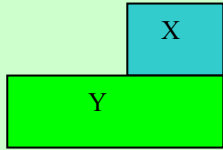
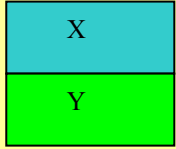
Οι Crandall κ.ά. (2008) χρησιμοποίησαν έναν ταξινομητή NB για να μπορέσουν να αναγνωρίσουν ποια γεγονότα προκαλούνται από κάθε ένα από τρία άτομα που επισκέπτονται καθημερινά ένα εργαστήριο. Αντίθετα, στην παρούσα εργασία θεωρούμε ότι όλα τα γεγονότα προκαλούνται από το ίδιο άτομο.

Οι Cook κ.ά. (2007, 2008) χρησιμοποίησαν επίσης έναν ταξινομητή NB για να συσχετίσουν γεγονότα αισθητήρων με δραστηριότητες που πραγματοποιούνταν από δύο ανθρώπους που κατοικούσαν σε ένα σπίτι. Οι κάτοικοι αυτοί ήταν φοιτητές που ο καθένας είχε το δικό του δωμάτιο. Ο μόνος χώρος που μοιράζονταν ήταν ο κάτω όροφος του σπιτιού.

2.3 Μέθοδοι που χρησιμοποιούν κανόνες συσχέτισης

Άλλες μέθοδοι αναγνώρισης χρησιμοποιούν τις χρονικές σχέσεις του Άλεν, που φαίνονται στον Πίνακα 1. Οι μεταβλητές X και Y του πίνακα μπορούν να αντιπροσωπεύουν γεγονότα αισθητήρων ή ακόμα και δραστηριότητες που πραγματοποιήθηκαν σε ένα σπίτι.

Πίνακας 1

Χρονικές σχέσεις	Γράφημα	Περιορισμοί
X πριν το Y Y μετά το X		εκκίνηση (X) < εκκίνηση (Y) τερματισμός(X) < εκκίνηση (Y)
X κατά τη διάρκεια του Y Y περιέχει το X		εκκίνηση(X) > εκκίνηση(Y) τερματισμός (X) < τερματισμός (Y)
X επικαλύπτει το Y Y επικαλύπτεται από το X		εκκίνηση(X) < εκκίνηση(Y) εκκίνηση(Y) < τερματισμός(X) τερματισμός(X) < τερματισμός(Y)
X συναντά το Y Y συναντιέται από το X		εκκίνηση(Y) = τερματισμός(X)
X εκκινεί το Y Y εκκινείται από το X		εκκίνηση(X) = εκκίνηση(Y) τερματισμός(X) ≠ τερματισμός(Y)
X τερματίζει το Y Y τερματίζεται από το X		εκκίνηση(X) ≠ εκκίνηση(Y) τερματισμός(X) = τερματισμός(Y)
X ίσο με το Y		εκκίνηση(X) = εκκίνηση(Y) τερματισμός(X) = τερματισμός(Y)

ΠΑΡΑΔΕΙΓΜΑ 7

Έστω ότι η δραστηριότητα X είναι η «προετοιμασία μεσημεριανού», ενώ η δραστηριότητα Y είναι η «τρώει μεσημεριανό φαγητό». Αν οι δραστηριότητες X και Y συνδέονται με τη σχέση «X πριν το Y» σύμφωνα με τον Πίνακα 1, τότε αυτό σημαίνει ότι πρώτα εκτελέστηκε η δραστηριότητα X και κατόπιν η Y, χωρίς οι δραστηριότητες να επικαλύπτονται.

Παρόμοιες σχέσεις μπορούμε να μάθουμε για όλες τις δραστηριότητες και να εξεταστούν τυχόν ασυνήθιστες συμπεριφορές (π.χ. η δραστηριότητα X συνήθως εκτελείται πριν την Y, αλλά μία συγκεκριμένη ημέρα εκτελέστηκε μετά την Y). Επίσης, όπως αναφέραμε οι μεταβλητές X και Y μπορούν να αποτελούν και γεγονότα αισθητήρων. Ένα σύνολο τέτοιων σχέσεων μεταξύ γεγονότων μπορεί να χρησιμοποιηθεί προκειμένου να αναγνωρισθεί η δραστηριότητα η οποία εκτελείται.

Οι κανόνες συσχέτισης έχουν τη μορφή $\{x_1, x_2, \dots, x_n\} \rightarrow y$, που σημαίνει ότι όταν σε ένα σύνολο έχουμε τα στοιχεία x_1, x_2, \dots, x_n τότε υπάρχει μεγάλη πιθανότητα να εντοπίσουμε το y. Η πιθανότητα αυτή καλείται εμπιστοσύνη του κανόνα. Αναζητούμε κανόνες που η εμπιστοσύνη τους είναι πάνω από κάποιο «κατώφλι» (κατώτατη τιμή). Παρακάτω έχουμε τον Πίνακα 2, που αποτελείται από διάφορα αριθμημένα σύνολα:

Πίνακας 2

Αριθμός Συνόλου	Στοιχεία Συνόλων
1	ντομάτα, ελιές
2	ντομάτα, τυρί, γάλα, αυγά
3	ψωμί, κρασί, ελιές, ζάχαρη, αλάτι
4	αλάτι, πιπέρι, κρασί, γάλα, αυγά
5	αλάτι, πιπέρι, κρασί, γάλα, ψωμί

Θεωρούμε ένα σύνολο στοιχείων $I = \{\text{ντομάτα, ελιές, τυρί, γάλα, αυγά, ψωμί, κρασί, ζάχαρη, αλάτι, πιπέρι}\}$.

ΟΡΙΣΜΟΙ

στοιχειοσύνολο I_i : ένα σύνολο τέτοιο ώστε το I_i να είναι υποσύνολο του συνόλου I , $I_i \subseteq I$.

κ-στοιχειοσύνολο: είναι ένα στοιχειοσύνολο το οποίο περιέχει κ-στοιχεία.

υποστήριξη s: ενός στοιχειοσυνόλου ορίζουμε τη συχνότητα εμφάνισης (ποσοστό) όλων των στοιχείων του στοιχειοσυνόλου.

συχνό στοιχειοσύνολο: ονομάζουμε ένα στοιχειοσύνολο του οποίου η υποστήριξη είναι μεγαλύτερη από μία κατώτατη τιμή («κατώφλι»).

ΠΑΡΑΔΕΙΓΜΑ 8

Έστω ότι έχουμε το στοιχειοσύνολο $I_i = \{\text{αλάτι, πιπέρι, κρασί, γάλα}\}$. Τότε η υποστήριξη αυτού του στοιχειοσυνόλου s στο Πίνακα 2 είναι $2/5$, διότι τα στοιχεία του στοιχειοσυνόλου αλάτι, πιπέρι, κρασί, γάλα, εμφανίζονται **όλα μαζί** στα 2 από τα συνολικά 5 σύνολα του πίνακα. Συγκεκριμένα εμφανίζονται στα σύνολα 4 και 5.

Οι ορισμοί του κανόνα συσχέτισης, υποστήριξη του κανόνα και εμπιστοσύνη του κανόνα είναι οι εξής:

ΟΡΙΣΜΟΙ

1-Κανόνας συσχέτισης

Έχει τη μορφή $X \rightarrow Y$, με X και Y να αποτελούν στοιχειοσύνολα.

$$X \subseteq I, Y \subseteq I, X \cap Y = \text{κενό}$$

2-Υποστήριξη του κανόνα

Το ποσοστό των περιπτώσεων (π.χ. γραμμών του Πίνακα 2) που περιέχουν το $X \cap Y$.

$\frac{\sigma(X \cap Y)}{T}$, με T να είναι το πλήθος των δοσοληψιών και $\sigma(\circ)$ να είναι ο αριθμός των περιπτώσεων.

3-Εμπιστοσύνη του κανόνα

Το ποσοστό των περιπτώσεων που περιέχουν και το X και το Y .

$$\frac{\sigma(X \cap Y)}{\sigma(X)}$$

Ο Παπαματθαϊάκης (2008) και ο Συρίγος (2009) χρησιμοποίησαν κανόνες συσχέτισης για την αναγνώριση των δραστηριοτήτων, καθώς και τον αλγόριθμο Apriori για να μαθαίνουν τους κανόνες συσχέτισης.

Στις παραπάνω εργασίες, οι σχέσεις μεταξύ των γεγονότων των αισθητήρων παράγονται σύμφωνα με τον παρακάτω αλγόριθμο.

Είσοδος: γεγονότα αισθητήρων, ώρα έναρξης, ώρα λήξης των γεγονότων

Επανάλαβε όσο υπάρχει (γεγονός && γεγονός +1)

- Βρες την ώρα έναρξης και λήξης 2 διαδοχικών γεγονότων
- Σύγκρινε τις ώρες έναρξης και λήξης των γεγονότων
- Αναγνώρισε τη χρονική σχέση των γεγονότων (σύμφωνα με τον Πίνακα)
- Κατέγραψε τους αισθητήρες που παρήγαγαν τα γεγονότα και δημιούργησε το χρονικό κανόνα
- Πήγαινε στο επόμενο γεγονός (αυξάνεται ο δείκτης των γεγονότων)

Τέλος επανάληψης

Τέλος

ΠΑΡΑΔΕΙΓΜΑ 9

Ένα παράδειγμα του παραπάνω αλγορίθμου είναι το παρακάτω:

Είσοδος:

Ημερομηνία	Ώρα έναρξης	Ώρα λήξης	Αισθητήρας	Αντικείμενο	Δωμάτιο
23/02/2010	13:28:30	14:15:10	25	πόρτα	κουζίνα
23/02/2010	13:30:05	14:10:50	50	ψυγείο	κουζίνα

Εξοδος:

Η χρονική σχέση που θα παραχθεί είναι η «50 κατά τη διάρκεια 25» (Η παραπάνω χρονική σχέση προέκυψε με βάση τις σχέσεις του Άλεν που φαίνονται στον Πίνακα 1).

Προκειμένου να γίνει κατανοητός ο τρόπος δημιουργίας των χρονικών κανόνων, ας υποθέσουμε ότι ο παρακάτω πίνακας (Πίνακας 3) περιέχει δεδομένα εκπαίδευσης από περιπτώσεις του παρελθόντος στις οποίες έλαβε χώρα μια συγκεκριμένη δραστηριότητα. Η 2^η και 3^η στήλη περιέχουν την ταυτότητα του αισθητήρα X και Y αντίστοιχα. Η 4^η στήλη περιέχει τη σχέση με την οποία συνδέονται τα 2 γεγονότα μεταξύ τους. Η 5^η στήλη περιέχει τη συχνότητα εμφάνισης της σχέσης της 4^{ης} στήλης στο σύνολο όλων των περιπτώσεων όπου

συνεμφανίζονται τα γεγονότα στηλών 2 και 3. Η 6^η στήλη περιέχει το ποσοστό εμπιστοσύνης της σχέσης της 4^{ης} στήλης. Η εμπιστοσύνη ορίζεται ως ο λόγος της συχνότητας εμφάνισης της σχέσης της 4^{ης} στήλης, προς το πλήθος των εμφανίσεων κάποιας σχέσης μεταξύ των δύο γεγονότων.

Πίνακας 3

Κανόνας	Αισθητήρας X	Αισθητήρας Y	Σχέση	Συχνότητα Εμφάνισης Σχέσης	Εμπιστοσύνη
1	35	50	35 μετά το 50	30	1
2	20	10	20 πριν το 10	25	1
3	12	39	12 επικαλύπτει το 39	20	0.8
4	17	21	21 συναντά το 17	32	0.9
5	11	18	11 εκκινεί το 18	19	1

ΠΑΡΑΔΕΙΓΜΑ 10

Έστω ότι οι αισθητήρες 35 και 50 εμφανίζονται να έχουν 10 φορές κάποια σχέση μεταξύ τους, η 4^η στήλη περιέχει τη σχέση «35 κατά τη διάρκεια του 50» και η συχνότητα εμφάνισης της συγκεκριμένης σχέσης μεταξύ των δύο αισθητήρων είναι 7. Τότε η εμπιστοσύνη του κανόνα της πρώτης γραμμής του Πίνακα 3 θα είναι 0.7.

Οι Παπαματθαϊάκης και Συρίγος προσπαθούν να εντοπίσουν ποια δραστηριότητα έλαβε χώρα σε ένα συγκεκριμένο χρονικό διάστημα (όχι από πότε ως πότε έλαβε χώρα)

Για να δούμε πώς χρησιμοποιούν τους κανόνες συσχέτισης για αυτό το σκοπό, ας υποθέσουμε ότι στο διάστημα που εξετάζουμε οι κανόνες μίας συγκεκριμένης δραστηριότητας που ικανοποιούνται είναι οι: ο κανόνας 1 (3 φορές), ο κανόνας 3 (1 φορά) και ο κανόνας 4 (5 φορές). Τότε ο συντελεστής βάρους (ΣΒ) της δραστηριότητας ο οποίος ορίζεται ως:

$$\Sigma B = \sum_{i=1}^N \text{εμπιστοσύνη_κάνονα}_i * \text{φορές_εμφάνισης_κάνονα}_i,$$

(όπου N είναι το πλήθος των κανόνων).

γίνεται:

$$3*1 + 0.8 + 0.9*5 = 8.3$$

Αφού υπολογιστεί ο συντελεστή βάρους όλων των δραστηριοτήτων, επιλέγεται η δραστηριότητα που επιτυγχάνει το μεγαλύτερο συντελεστή βάρους. Οπότε το σύστημα αναγνώρισης των δραστηριοτήτων αποκρίνεται ότι στο συγκεκριμένο διάστημα εκτελέστηκε η δραστηριότητα με το μεγαλύτερο συντελεστή βάρους. Προφανώς γίνεται η παραδοχή ότι ποτέ δεν εκτελούνται παράλληλα περισσότερες από μία δραστηριότητες.

Στα πειράματά τους, οι Παπαματαθαιάκης και Συρίγος προσπάθησαν να αναγνωρίσουν τις δραστηριότητες που πραγματοποιήθηκαν σε δύο διαφορετικά σπίτια. Για τα δύο σπίτια είχαν στη διάθεσή τους σύνολα δεδομένων για τα γεγονότα που πραγματοποιήθηκαν σε συνολική χρονική διάρκεια δύο εβδομάδων.

Οι Jakulla κ.ά. (2008) χρησιμοποίησαν επίσης κανόνες συσχέτισης, για να εντοπίσουν κάποια ασυνήθιστη συμπεριφορά στις δραστηριότητες κάποιου ανθρώπου. Για παράδειγμα, ένας άνθρωπος που κατοικεί ένα σπίτι ίσως συνηθίζει να εκτελεί πρώτα τη δραστηριότητα «άνοιγμα τηλεόρασης» και κατόπιν τη δραστηριότητα «κάθεται στον καναπέ». Οι δύο αυτές δραστηριότητες συνδέονται με τη σχέση «X πριν το Y». Όταν για κάποιο λόγο αυτή η σχέση παραβιαστεί, τότε σημειώνεται μία ασυνήθιστη συμπεριφορά. Για την εξόρυξη των πιο συχνών χρονικών σχέσεων χρησιμοποίησαν και αυτοί τον αλγόριθμο Apriori. Τα πειράματά τους έγιναν σε δύο συλλογές δεδομένων. Η μία περιλαμβάνει γεγονότα χρονικής διάρκειας 59 ημερών. Η δεύτερη συλλογή δεδομένων είναι συνθετική και περιλαμβάνει περίπου 4000 δραστηριότητες. Στη συνθετική συλλογή το μοντέλο ανίχνευσης ασυνήθιστων συμπεριφορών τα πήγε αρκετά καλά (ανίχνευσε όλες τις προβλεπόμενες ασυνήθιστες συμπεριφορές και δε σημειώθηκαν σφάλματα), ενώ αντίθετα στην πραγματική συλλογή δε σημειώθηκε καμία ανίχνευση ασυνήθιστης συμπεριφοράς. Όπως υποστηρίζουν, αυτό οφείλεται στη φύση των δεδομένων της πρώτης συλλογής, αφού δεν περιέχει καμία ασυνήθιστη συμπεριφορά.

Οι ίδιοι ερευνητές, εκτός από την ανίχνευση των ασυνήθιστων συμπεριφορών, ασχολήθηκαν και με την πρόβλεψη μελλοντικών δραστηριοτήτων (Jakulla κ.ά., 2007).

2.4 Μέθοδοι που χρησιμοποιούν υπό συνθήκη τυχαία πεδία

Οι Kasteren κ.ά. (2008) χρησιμοποίησαν υπό συνθήκη τυχαία πεδία (Conditional Random Fields, CRFs) για την αναγνώριση δραστηριοτήτων σε ένα σπίτι και σύγκριναν τα αποτελέσματά τους με τη μέθοδο HMM. Τα αποτελέσματα της εργασίας αυτής φαίνονται αναφέρονται παραπάνω στην ενότητα 2.1. Για εισαγωγή στα CRFs, ο αναγνώστης παραπέμπεται στην εργασία των Sutton και McCallum (2006).

2.5 Μέθοδοι που χρησιμοποιούν δέντρα απόφασης

Οι γνωστότεροι αλγόριθμοι μάθησης δέντρων απόφασης είναι ο ID3 και η επέκτασή του, ο C4.5. Οι αλγόριθμοι αυτοί περιγράφονται στα περισσότερα εισαγωγικά εγχειρίδια τεχνητής νοημοσύνης (π.χ. Russel και Norvig, 2003).

Οι Παπαματθαϊάκης (2008) και Maurer κ.ά. (2005) στις εργασίες τους συμπέραναν ότι τα δέντρα απόφασης δεν ανταποκρίνονται τόσο καλά όσο οι ταξινομητές NB κατά την αναγνώριση δραστηριοτήτων. Οι Maurer κ.ά. χρησιμοποίησαν όμως δέντρα απόφασης, διότι όπως υποστηρίζουν αποτελούν μία καλή ισορροπία μεταξύ ακρίβειας στην αναγνώριση δραστηριοτήτων και υπολογιστικού κόστους. Χρησιμοποίησαν αισθητήρες σε διάφορα μέρη του ανθρωπίνου σώματος. Εκτίμησαν ποιο είναι το καταλληλότερο σημείο του ανθρωπίνου σώματος όπου πρέπει να τοποθετηθούν οι αισθητήρες, καθώς και το υπολογιστικό κόστος που απαιτείται όταν κάποιοι αισθητήρες είναι τοποθετημένοι στα συγκεκριμένα σημεία. Στην αναγνώριση των δραστηριοτήτων τους χρησιμοποίησαν δύο είδη αισθητήρων: επιταχυνσιόμετρα και αισθητήρες φωτός. Εκτίμησαν την ακρίβεια του συστήματός τους με τα χαρακτηριστικά που προκύπτουν ξεχωριστά από τα επιταχυνσιόμετρα και από τους αισθητήρες φωτός, καθώς και από το συνδυασμό των χαρακτηριστικών αυτών.

Από τα αποτελέσματα των πειραμάτων τους, συμπέραναν ότι το καλύτερο σημείο τοποθέτησης των αισθητήρων είναι ο καρπός του χεριού. Κάποιες δραστηριότητες σημείωσαν μεγάλα ποσοστά ακρίβειας, ενώ αντίθετα κάποιες άλλες δε σημείωσαν τόσο καλά αποτελέσματα και αυτό διότι οι δραστηριότητες αυτές έμοιαζαν αρκετά μεταξύ τους. Αυτές οι δραστηριότητες ήταν οι «περπάτημα», «ανεβαίνω μία σκάλα», «κατεβαίνω μία σκάλα», όπου το σύστημα δεν μπορούσε να διαχωρίσει με μεγάλη ακρίβεια τις δύο τελευταίες από τη δραστηριότητα «περπάτημα».

Αντίθετα οι Logan κ.ά. (2007) συμπέραναν ότι τα δέντρα απόφασης είναι καλύτερη μέθοδος από τους ταξινομητές NB. Για την αναγνώριση των δραστηριοτήτων

χρησιμοποίησαν δεδομένα από τρία κύρια είδη αισθητήρων: αισθητήρες RFID, αισθητήρες που χρησιμοποιούν καλώδια, αισθητήρες κίνησης. Από τα πειράματα που πραγματοποίησαν συμπεράναν ότι οι αισθητήρες κίνησης είναι αυτοί που συνεισφέρουν αποτελεσματικότερα στην αναγνώριση των δραστηριοτήτων.

2.6 Σχετικές εργασίες

Παρακάτω παρουσιάζουμε σύντομα άλλες λιγότερα άμεσα σχετικές εργασίες.

Ο Δασούλας (2009) ασχολήθηκε με την ανάπτυξη ενός συστήματος που καταγράφει τις δραστηριότητες κάποιου ανθρώπου σε εξωτερικούς χώρους.

Η Τρούβα (2009) ασχολήθηκε με τον εντοπισμό της θέσης κάποιου ανθρώπου σε ένα σπίτι, μέσω της συλλογής φωτογραφιών χρησιμοποιώντας PDA και έξυπνα κινητά τηλέφωνα.

Οι Riedel κ.ά. (2008) ασχολήθηκαν με μεθόδους εξάλειψης θορύβων σε βίντεο, όταν η αναγνώριση δραστηριοτήτων γίνεται μέσω βίντεο.

Οι Ζούμπα κ.ά. (2004) προσπαθούν να αναγνωρίσουν τις δραστηριότητες που πραγματοποιούνται μέσα σε ένα σπίτι, χρησιμοποιώντας βίντεο.

Οι Yacoob κ.ά. (1999) μελετούν την αναγνώριση ανθρώπινων δραστηριοτήτων που σχετίζονται με την κίνηση των διαφόρων μελών του ανθρώπινου σώματος μέσω εικόνας. Επίσης αναγνώριση δραστηριοτήτων μέσω εικόνας επιχείρησαν και οι Hongeng κ.ά. (2000).

Οι Reiter κ.ά. (2009) παρουσιάζουν ένα σύστημα το οποίο αλληλεπιδρά με ανθρώπους (και ειδικά με παιδιά) που έχουν ειδικές ανάγκες και τους βοηθά να επικοινωνήσουν με το περιβάλλον τους. Οι χρήστες ενημερώνουν το σύστημα για το αν τα διάφορα γεγονότα που συμβαίνουν γύρω τους, τους ικανοποιούν ή όχι. Το σύστημα εκπαιδεύεται ξεχωριστά για τον κάθε χρήστη και αποφασίζει ποιες δραστηριότητες τον ικανοποιούν και ποιες όχι. Ωστόσο στην εργασία αυτή δεν παρουσιάζεται κάποια μέθοδος αναγνώρισης δραστηριοτήτων.

Τέλος, παραπέμπουμε τον αναγνώστη στην εργασία του Tapia (2003) για μία γενικότερη και σε βάθος ανάλυση της αναγνώρισης δραστηριοτήτων σε ένα σπίτι. Σε αυτήν την εργασία αναλύεται ο σχεδιασμός ενός συστήματος αναγνώρισης δραστηριοτήτων, καθώς και όλοι οι παράμετροι που ένας σχεδιαστής ενός τέτοιου συστήματος πρέπει να λάβει υπ'

όψιν του. Περιγράφονται οι διάφοροι τρόποι αναγνώρισης δραστηριοτήτων, όπως π.χ. μέσα από τη συλλογή δεδομένων από απλούς αισθητήρες, από εικόνες, καθώς και από βίντεο. Επίσης αναλύονται αλγόριθμοι αναγνώρισης δραστηριοτήτων, καθώς και η υλοποίηση αυτών των αλγορίθμων. Τέλος αναλύεται ο σχεδιασμός του τρόπου συλλογής των δεδομένων από τα διάφορα είδη αισθητήρων.

ΚΕΦΑΛΑΙΟ 3

ΤΟ ΣΥΣΤΗΜΑ ΤΗΣ ΕΡΓΑΣΙΑΣ

3.1 Εισαγωγή

Το κεφάλαιο αυτό περιγράφει το σύστημα αναγνώρισης δραστηριοτήτων που αναπτύχθηκε στη διάρκεια της παρούσας εργασίας. Η ενότητα 3.2 παρέχει μια γενική περιγραφή του συστήματος, ενώ η ενότητα 3.3 περιγράφει τους αλγορίθμους μηχανικής μάθησης τους οποίους χρησιμοποιεί το σύστημα.

3.2 Γενική περιγραφή του συστήματος

Το σύστημα χρησιμοποιεί εναλλακτικά δύο αλγορίθμους επιβλεπόμενης μηχανικής μάθησης, τον AdaBoost και έναν ταξινομητή λογιστικής παλινδρόμησης (logistic regression). Πριν όμως περιγράψουμε συνοπτικά τους αλγορίθμους αυτούς, παρουσιάζουμε την προσέγγισή μας στο πρόβλημα της αναγνώρισης δραστηριοτήτων, στην οποία βασίζεται το σύστημα.

Έστω n το πλήθος των ειδών των δραστηριοτήτων που θέλουμε να αναγνωρίζουμε (π.χ. προετοιμασία γεύματος, προετοιμασία εξόδου, ύπνος κλπ.). Για κάθε είδος δραστηριοτήτων, εκπαιδεύουμε έναν ξεχωριστό ταξινομητή (classifier), ο οποίος αποφασίζει σε κάθε χρονική στιγμή (για την ακρίβεια σε κάθε γεγονός, βλ. παρακάτω) αν εκτελείται η αντίστοιχη δραστηριότητα ή όχι. Η προσέγγιση αυτή επιτρέπει την παράλληλη εκτέλεση πολλών δραστηριοτήτων. Επίσης, επιτρέπει την εύκολη επέκταση του συστήματος, όποτε θέλουμε να προσθέσουμε ένα νέο είδος δραστηριοτήτων, επέκταση που μπορεί να γίνει εκπαιδεύοντας και προσθέτοντας ένα νέο ταξινομητή. Πιο συγκεκριμένα, οι ταξινομητές κατατάσσουν γεγονότα, τα οποία προκύπτουν όποτε αλλάζει η ένδειξη τουλάχιστον ενός αισθητήρα. Κάθε γεγονός (χρονική στιγμή κατά την οποία άλλαξε ένδειξη ένας αισθητήρας) παριστάνεται από ένα διάνυσμα \vec{x} , το οποίο περιέχει τιμές που προκύπτουν από τις τρέχουσες αλλά και προηγούμενες ενδείξεις όλων των αισθητήρων, όπως εξηγείται παρακάτω. Τα γεγονότα κατατάσσονται σε τρεις αμοιβαία αποκλειόμενες κατηγορίες, τις B, I, O, οι οποίες έχουν τις ακόλουθες σημασίες:

Κατηγορία	Περιγραφή
B	Η δραστηριότητα αρχίζει να εκτελείται στο γεγονός αυτό.
I	Η δραστηριότητα βρίσκεται σε εξέλιξη (ή ενδεχομένως τελειώνει) στο γεγονός αυτό, αλλά δεν ξεκινά στο γεγονός αυτό.
O	Η δραστηριότητα δεν εκτελείται στο γεγονός αυτό.

Ο συγκεκριμένος τρόπος κατάταξης σειριακών γεγονότων σε τρεις κατηγορίες (B, I, O) προέρχεται από την επεξεργασία φυσικής γλώσσας, όπου χρησιμοποιείται π.χ. κατά την επισημείωση λέξεων που αποτελούν ή όχι μέρη κυρίων ονομάτων, χρονικών εκφράσεων κλπ. Σε ορισμένα από τα πειράματα της παρούσας εργασίας, οι κατηγορίες B και I συνενώθηκαν, οπότε η ενιαία κατηγορία που προέκυψε σήμαινε ότι η δραστηριότητα βρισκόταν σε εξέλιξη.

Παρακάτω περιγράφουμε τις ιδιότητες (attributes) των οποίων οι τιμές (χαρακτηριστικά, features) περιλαμβάνονται στα διανύσματα που περιγράφουν τα γεγονότα. Χρησιμοποιούνται συνολικά 19 είδη ιδιοτήτων. Κατά την εκπαίδευση του συστήματος, μια πρόσθετη τιμή εντός κάθε διανύσματος δείχνει τη σωστή κατηγορία του διανύσματος (του αντίστοιχου γεγονότος). Κατά τη χρήση (και την αξιολόγηση) του συστήματος, μετά την εκπαίδευση, η σωστή κατηγορία είναι άγνωστη και το σύστημα πρέπει να τη μαντέψει.

ΕΙΔΗ ΙΔΙΟΤΗΤΩΝ (τιμών στο εσωτερικό κάθε διανύσματος, κάθε διάνυσμα περιγράφει σε ένα γεγονός)

<p>1- Η τιμή που έχει ο κάθε αισθητήρας τη στιγμή του περιγραφόμενου γεγονότος (μία ιδιότητα για κάθε αισθητήρα, με τιμή 0 όταν είναι μη ενεργοποιημένος και 1 διαφορετικά).</p>
<p>2- Η χρονική διάρκεια (σε δευτερόλεπτα) που έχει παρέλθει από τότε που ο κάθε αισθητήρας πήρε την τιμή που έχει στο περιγραφόμενο γεγονός, δηλαδή επί πόσο χρόνο (σε δευτερόλεπτα) έχει ο κάθε αισθητήρας την τρέχουσα τιμή του (μία ιδιότητα για κάθε αισθητήρα).</p>
<p>3- Η χρονική διάρκεια (σε γεγονότα) που έχει παρέλθει από τότε που ο κάθε αισθητήρας πήρε την τιμή που έχει στο περιγραφόμενο γεγονός, δηλαδή επί πόσο χρόνο (σε γεγονότα) έχει ο κάθε αισθητήρας την τρέχουσα τιμή του (μία ιδιότητα για κάθε αισθητήρα).</p>
<p>4- Επί πόσο χρόνο (διάρκεια, σε δευτερόλεπτα) ο κάθε αισθητήρας είχε την προηγούμενη τιμή του, πριν πάρει την τιμή που έχει στο περιγραφόμενο γεγονός, δηλαδή επί πόσο χρόνο (σε δευτερόλεπτα) είχε ο κάθε αισθητήρας την προηγούμενη τιμή του (μία ιδιότητα ανά αισθητήρα).</p>
<p>5- Επί πόσο χρόνο (χρονική διάρκεια, σε γεγονότα) ο κάθε αισθητήρας είχε την προηγούμενη τιμή του, πριν πάρει την τιμή που έχει στο περιγραφόμενο γεγονός, δηλαδή επί πόσο χρόνο (σε γεγονότα) είχε ο κάθε αισθητήρας την προηγούμενη τιμή του (μία ιδιότητα ανά αισθητήρα).</p>
<p>6- Πόσα γεγονότα κατηγορίας B έχουν υπάρξει κατά την τρέχουσα ημέρα, πριν το περιγραφόμενο γεγονός, δηλαδή πόσες φορές έχει ήδη ξεκινήσει η δραστηριότητα στην τρέχουσα ημέρα.</p>
<p>7- Πόσα γεγονότα κατηγορίας B και I έχουν υπάρξει από το πιο πρόσφατο γεγονός κατηγορίας B ως το περιγραφόμενο γεγονός. Με άλλα λόγια, επί πόσο χρόνο (σε γεγονότα) βρίσκεται σε εξέλιξη η δραστηριότητα (αν βρίσκεται σε εξέλιξη) ή πόσο χρόνο (σε γεγονότα) διήρκεσε η δραστηριότητα την πιο πρόσφατη φορά που εκτελέστηκε (αν δεν βρίσκεται τώρα σε εξέλιξη).</p>
<p>8- Πόσα γεγονότα κατηγορίας O έχουν υπάρξει από το πιο πρόσφατο γεγονός κατηγορίας B ή I ως το περιγραφόμενο γεγονός. Με άλλα λόγια, επί πόσο χρόνο (σε γεγονότα) <u>δεν</u> βρίσκεται σε εξέλιξη η δραστηριότητα (αν δεν βρίσκεται σε εξέλιξη). Αν το αμέσως προηγούμενο γεγονός ήταν B ή I, η ιδιότητα αυτή έχει την τιμή 0.</p>

9- Η χρονική διάρκεια (σε δευτερόλεπτα) από το πιο πρόσφατο γεγονός B ως το πιο πρόσφατο γεγονός I. Με άλλα λόγια, επί πόσο χρόνο (σε δευτερόλεπτα) βρισκόταν (την πιο πρόσφατη φορά που συνέβη) ή βρίσκεται σε εξέλιξη η δραστηριότητα. Αν το προηγούμενο γεγονός ήταν B, τότε η τιμή της ιδιότητας είναι 0.

10- Η χρονική διάρκεια (σε δευτερόλεπτα) από το πρώτο γεγονός O αμέσως μετά το πιο πρόσφατο γεγονός B ή I (που ακολουθείται από γεγονός O) ως το πιο πρόσφατο γεγονός O. Με άλλα λόγια, ποια ήταν η διάρκεια (σε δευτερόλεπτα) του πιο πρόσφατου διαστήματος όπου δεν βρισκόταν σε εξέλιξη η δραστηριότητα.

11- Η ώρα της ημέρας (1–24) μέσα στην οποία περιέχεται το γεγονός. Δηλαδή, αν το γεγονός προέκυψε μεταξύ 00:00:00-00:59:59, η τιμή της ιδιότητας είναι 1. Αν προέκυψε μεταξύ 01:00:00-01:59:59, η τιμή είναι 2 κ.ο.κ.

12- Πόσα γεγονότα κατηγορίας B εντός της ίδιας ημέρας που περιλαμβάνει το περιγραφόμενο γεγονός είχαν προκληθεί από τον κάθε αισθητήρα (μία ιδιότητα ανά αισθητήρα).

13- Πόσα γεγονότα κατηγορίας B και I εντός του διαστήματος από το πιο πρόσφατο O ως το περιγραφόμενο γεγονός είχαν προκληθεί από τον κάθε αισθητήρα (μία ιδιότητα ανά αισθητήρα).

14- Πόσα γεγονότα κατηγορίας O εντός του διαστήματος από το πιο πρόσφατο B ή I ως το περιγραφόμενο γεγονός είχαν προκληθεί από τον κάθε αισθητήρα (μία ιδιότητα ανά αισθητήρα).

15- Αν το προηγούμενο γεγονός είναι B ή I, τότε οι ιδιότητες αυτές (μία ανά αισθητήρα) δείχνουν επί πόσο χρόνο (σε δευτερόλεπτα) ο κάθε αισθητήρας έχει την τωρινή του τιμή (αυτή που έχει στο περιγραφόμενο γεγονός). Αν το προηγούμενο γεγονός είναι O, τότε οι ιδιότητες αυτές (μία ανά αισθητήρα) δείχνουν επί πόσο χρόνο (σε δευτερόλεπτα) ο κάθε αισθητήρας είχε διατηρήσει (συνεχώς) την τιμή που είχε στο πιο πρόσφατο γεγονός B ή I.

16- Αν το προηγούμενο γεγονός είναι O, τότε οι ιδιότητες αυτές (μία ανά αισθητήρα) δείχνουν επί πόσο χρόνο (σε δευτερόλεπτα) ο κάθε αισθητήρας έχει την τωρινή του τιμή (αυτή που έχει στο περιγραφόμενο γεγονός). Αν το προηγούμενο γεγονός είναι B ή I, τότε οι ιδιότητες αυτές (μία ανά αισθητήρα) δείχνουν επί πόσο χρόνο (σε δευτερόλεπτα) ο κάθε αισθητήρας είχε διατηρήσει (συνεχώς) την τιμή που είχε στο πιο πρόσφατο γεγονός O.

17- Η σειρά με την οποία ο κάθε αισθητήρας δημιούργησε γεγονός (ή ακολουθία συνεχόμενων γεγονότων) κατά τη διάρκεια της πιο πρόσφατης εκτέλεσης (ακολουθία γεγονότων B και I) της δραστηριότητας (μία ιδιότητα ανά αισθητήρα). Για παράδειγμα, ας υποθέσουμε ότι κατά τη διάρκεια της πιο πρόσφατης εκτέλεσης της δραστηριότητας, ο αισθητήρας με ταυτότητα id=10 και ο αισθητήρας με ταυτότητα id=20 είναι οι μόνοι που παράγουν γεγονότα. Αν ο αισθητήρας 10 ήταν ο πρώτος που παρήγαγε κάποιο γεγονός και κατόπιν ο αισθητήρας 20 και κατόπιν πάλι ο 20 και μετά ο αισθητήρας 10, τότε η ιδιότητα θα έπαιρνε για τον 10 την τιμή 3 και για τον 20 την τιμή 2. Αν κάποιος αισθητήρας κατά τη διάρκεια της πιο πρόσφατης εκτέλεσης της δραστηριότητας δεν έχει δημιουργήσει κανένα γεγονός, τότε η τιμή της ιδιότητας αυτής είναι 0.

18- Η σειρά με την οποία ο κάθε αισθητήρας δημιούργησε γεγονός (ή ακολουθία συνεχόμενων γεγονότων) κατά τη διάρκεια της πιο πρόσφατης μη εκτέλεσης (ακολουθία γεγονότων O) της δραστηριότητας (μία ιδιότητα ανά αισθητήρα).

19- Πόσα (ποσοστό) γεγονότα εκπαίδευσης κατηγορίας B ή I προκλήθηκαν από αλλαγή της ένδειξης του ίδιου αισθητήρα που προκάλεσε το περιγραφόμενο γεγονός. Δηλαδή ποια είναι η πιθανότητα αν βρισκόμαστε σε γεγονός B ή I, αυτό το γεγονός να έχει προκληθεί από τον ίδιο αισθητήρα που προκάλεσε το περιγραφόμενο γεγονός. Αν η εκτίμηση αυτής της πιθανότητας κυμαίνεται μεταξύ 0%-10%, τότε η τιμή της ιδιότητας είναι 1, αν είναι μεταξύ 10%-20% είναι 2 κ.ο.κ.

20- Η ορθή κατηγορία διανύσματος (B, I ή O), η οποία είναι γνωστή μόνο στα γεγονότα εκπαίδευσης.

Κάθε ταξινομητής, λοιπόν, καλείται να κατατάξει τα γεγονότα (τα διανύσματα που τα περιγράφουν) στις κατηγορίες B, I ή O, ανάλογα με το αν η δραστηριότητα που αντιστοιχεί στον ταξινομητή ξεκινά, βρίσκεται σε εξέλιξη ή δεν εκτελείται στα αντίστοιχα γεγονότα. Για την αξιολόγηση κάθε ταξινομητή (άρα για κάθε δραστηριότητα ξεχωριστά), χρησιμοποιήσαμε τα παρακάτω μέτρα:

Precision (ακρίβεια) = [πόσα γεγονότα που στην πραγματικότητα ανήκαν στην κατηγορία B ή I τα κατέταξε ο ταξινομητής ως B ή I] / [πόσα γεγονότα κατέταξε ο ταξινομητής ως B ή I].

Recall (ανάκληση) = [πόσα γεγονότα που στην πραγματικότητα ανήκαν στην κατηγορία B ή I τα κατέταξε ο ταξινομητής ως B ή I] / [πόσα γεγονότα ανήκαν πραγματικά στην κατηγορία B ή I].

Error Rate (ποσοστό λάθους) = [πόσα γεγονότα κατέταξε ο ταξινομητής σε λάθος κατηγορία] / [πλήθος όλων των γεγονότων]

F-Measure = $\frac{(1 + \beta) \cdot Precision \cdot Recall}{((\beta \cdot Precision) + Recall)}$. Χρησιμοποιούμε $\beta = 1$, που δίνει ίσο βάρος στην ακρίβεια και την ανάκληση.

3.3 Ο αλγόριθμος AdaBoost

Ο αλγόριθμος AdaBoost (Freund και Schapire 1996, Schapire 1999) είναι ένας αλγόριθμος επιβλεπόμενης μηχανικής μάθησης ο οποίος εκπαιδεύεται με n επαναληπτικές κλήσεις ενός βασικού (base) αλγορίθμου μάθησης. Κατά την εκπαίδευση, ο αλγόριθμος δέχεται ως εισόδους το n , παραδείγματα εκπαίδευσης (διανύσματα χαρακτηριστικών, μαζί με τις ορθές αντίστοιχες αποκρίσεις), καθώς και το βασικό αλγόριθμο μάθησης. Στο δικό μας πρόβλημα, τα παραδείγματα εκπαίδευσης είναι διανύσματα που περιγράφουν γεγονότα και οι ορθές αποκρίσεις είναι οι κατηγορίες B, I ή O. Κάθε παράδειγμα εκπαίδευσης φέρει και ένα βάρος (βαθμό σπουδαιότητας). Αρχικά όλα τα παραδείγματα έχουν το ίδιο βάρος w_i που είναι ίσο με:

$$w_i = \frac{1}{N}, \quad \text{όπου } N \text{ είναι το πλήθος των παραδειγμάτων εκπαίδευσης}$$

Σε κάθε επαναληπτικό βήμα εκπαίδευσης, ο AdaBoost εκπαιδεύει το βασικό αλγόριθμο μάθησης στα παραδείγματα εκπαίδευσης με τα τρέχοντα βάρη τους. Προκύπτει έτσι ένας διαφορετικός βασικός ταξινομητής από κάθε επαναληπτικό βήμα εκπαίδευσης. Στο τέλος κάθε επανάληψης, ο AdaBoost αυξάνει το βάρος των παραδειγμάτων που ο βασικός ταξινομητής της επανάληψης δεν κατάφερε να κατατάξει σωστά και μειώνει το βάρος εκείνων που ο βασικός ταξινομητής κατέταξε ορθά. Με τον τρόπο αυτό, δίνεται έμφαση στα παραδείγματα που κατετάγησαν λανθασμένα, ώστε οι βασικοί ταξινομητές που θα προκύψουν από τις επόμενες επαναλήψεις να είναι πιθανότερο να τα κατατάξουν σωστά.

Ο βασικός ταξινομητής που προκύπτει από κάθε επανάληψη φέρει ένα βάρος ψήφου:

z_j , για $j=1, \dots, n$, όπου n το πλήθος των επαναλήψεων εκπαίδευσης

Το βάρος z_j είναι μεγάλο αν ο βασικός ταξινομητής της j -οστής επανάληψης είχε κατατάξει σωστά μεγάλο ποσοστό των N παραδειγμάτων εκπαίδευσης, διαφορετικά είναι μικρό.

Μετά την εκπαίδευση, δηλαδή μετά την περάτωση των n επαναλήψεων, οι βασικοί ταξινομητές που έχουν προκύψει από τις επαναλήψεις χρησιμοποιούνται ως συνδυασμός (ensemble), προκειμένου να κατατάσσονται νέες περιπτώσεις (γεγονότα στην περίπτωσή μας) των οποίων είναι άγνωστες οι ορθές κατηγορίες. Η κατάταξη νέων περιπτώσεων γίνεται με ψηφοφορία μεταξύ των βασικών ταξινομητών που έχουν προκύψει. Η ψήφος κάθε βασικού ταξινομητή ζυγίζεται με το βάρος του.

Ως βασικό αλγόριθμο μάθησης χρησιμοποιήσαμε εκφυλισμένα δέντρα απόφασης βάθους 1 (decision stumps), που αποτελούν συχνή επιλογή βασικού αλγορίθμου στον AdaBoost. Ένα decision stump κατατάσσει τις περιπτώσεις εξετάζοντας μόνο μία ιδιότητα, εκείνη που παρέχει το μεγαλύτερο κέρδος πληροφορίας (information gain) στα παραδείγματα εκπαίδευσης. Το κέρδος πληροφορίας επηρεάζεται από τα βάρη των παραδειγμάτων εκπαίδευσης, με αποτέλεσμα τα decision stumps που προκύπτουν ως βασικοί ταξινομητές από τις επαναλήψεις εκπαίδευσης να εξετάζουν εν γένει διαφορετικές ιδιότητες.

3.4 Ταξινομητές λογιστικής παλινδρόμησης

Σε ορισμένα από τα πειράματα της εργασίας χρησιμοποιήθηκε επίσης ένας ταξινομητής λογιστικής παλινδρόμησης (logistic regression). Οι ταξινομητές αυτοί περιγράφονται αναλυτικά, για παράδειγμα, από τους Jurafsky και Martin (2006). Τα πειραματικά αποτελέσματα, όμως, του συστήματος της εργασίας ήταν σαφώς χειρότερα με τη χρήση του ταξινομητή λογιστικής παλινδρόμησης, συγκρινόμενα με τα αποτελέσματα που λάβαμε χρησιμοποιώντας τον AdaBoost.

ΚΕΦΑΛΑΙΟ 4

ΠΕΙΡΑΜΑΤΙΚΑ ΑΠΟΤΕΛΕΣΜΑΤΑ

4.1 Εισαγωγή

Αυτό το κεφάλαιο περιγράφει τα πειράματα που πραγματοποιήθηκαν στη διάρκεια της εργασίας και τα αποτελέσματά τους.

4.2 Σύνολα δεδομένων

Στα πειράματά μας χρησιμοποιήσαμε ένα σύνολο δεδομένων που κατασκευάστηκε από τους Kasteren κ.ά. (2008) και αποτελείται από δύο αρχεία.² Το πρώτο αρχείο περιέχει τα είδη δραστηριοτήτων που θέλουμε να αναγνωρίσουμε, καθώς και τις χρονικές στιγμές (ώρα, ημέρα, μήνα και χρονιά) που αυτές οι δραστηριότητες ξεκίνησαν και σταμάτησαν να εκτελούνται. Η κάθε μία δραστηριότητα χαρακτηρίζεται από μία ταυτότητα (id, ένας ακεραίος αριθμός). Συγκεκριμένα, το πρώτο αρχείο περιλαμβάνει σε κάθε γραμμή του τη χρονική στιγμή εκκίνησης και τερματισμού της δραστηριότητας και την ταυτότητα id της. Για παράδειγμα, αν μία δραστηριότητα με ταυτότητα 10 ξεκίνησε να εκτελείται στις 25/02/2010 την ώρα 08:32:25 και σταμάτησε να εκτελείται στις 25/02/2010 την ώρα 08:53:50, τότε η αντίστοιχη γραμμή στο πρώτο αρχείο θα είναι:

25-Feb-2010 08:32:25 25-Feb-2010 08:53:50 10

Στα πειράματά μας ασχοληθήκαμε με τις δραστηριότητες: 1-«χρησιμοποίηση τουαλέτας» (id=4), 2-«κάνει μπάνιο» (id=5), 3-«πηγαίνει για ύπνο» (id=10), 4-«προετοιμασία πρωινού» (id=13), 5-«προετοιμασία δείπνου» (id=15), 6-«πίνει ποτό» (id=17).

Το δεύτερο αρχείο περιγράφει τις ενεργοποιήσεις των αισθητήρων που πραγματοποιήθηκαν κατά τη διάρκεια εκτέλεσης των δραστηριοτήτων. Συγκεκριμένα σε κάθε γραμμή του περιλαμβάνει τη χρονική στιγμή (ώρα, ημέρα, μήνα και χρονιά) εκκίνησης και τερματισμού της ενεργοποίησης (δηλαδή πότε ενεργοποιήθηκε και πότε απενεργοποιήθηκε ο κάθε αισθητήρας), την ταυτότητα id του αισθητήρα και την τιμή του (που είναι πάντα 1 και μπορεί να αγνοηθεί). Για παράδειγμα, αν ένας αισθητήρας ενεργοποιήθηκε στις 26/03/2010 την ώρα 19:01:40 και απενεργοποιήθηκε στις 26/03/2010 την ώρα 19:48:02 και η ταυτότητα του αισθητήρα είναι 20, τότε η αντίστοιχη γραμμή στο δεύτερο αρχείο θα είναι:

26-Mar-2010 19:01:40 26-Mar-2010 19:48:02 20 1

². Το σύνολο δεδομένων διατίθεται από τη διεύθυνση: <http://sites.google.com/site/tim0306/datasets>.

Με κατάλληλο κώδικα, που υλοποιήσαμε σε Java, δημιουργήσαμε τα διανύσματα όλων των γεγονότων (στιγμών όπου τουλάχιστον ένας αισθητήρας άλλαξε τιμή, βλ. κεφάλαιο 3) και εκπαιδεύσαμε τους ταξινομητές, έναν για κάθε μία δραστηριότητα.³ Από αυτά τα διανύσματα, χρησιμοποιήσαμε το 70% για την εκπαίδευση του συστήματός μας (training set) και το 30% για έλεγχο (αξιολόγηση, testing set). Επειδή ο AdaBoost δεν μπορεί να χειριστεί καλά ιδιότητες που έχουν πραγματικές τιμές ή τιμές από πολύ μεγάλα πεπερασμένα σύνολα, διακριτοποιήσαμε όλες τις ιδιότητες. Υπολογίσαμε για κάθε μία ιδιότητα, τη μέγιστη τιμή που λαμβάνει στα δεδομένα εκπαίδευσης του συστήματος. Κατόπιν διαιρέσαμε το διάστημα των πραγματικών αριθμών από την ελάχιστη τιμή (που θεωρήσαμε ότι είναι πάντα μηδέν) ως τη μέγιστη τιμή σε 24 ίσα υποδιαστήματα (διαφορετικά για κάθε μία ιδιότητα). Αν η τιμή της ιδιότητας ανήκει στο πρώτο υποδιάστημα, τότε μετά τη διακριτοποίηση η ιδιότητα θα έχει την τιμή 0. Αν ανήκει στο δεύτερο υποδιάστημα, τότε θα έχει την τιμή 1 κ.ο.κ. Τέλος, αν η τιμή είναι μεγαλύτερη από τη μέγιστη τιμή που είχε παρατηρηθεί στα δεδομένα εκπαίδευσης, τότε η ιδιότητα θα έχει μετά τη διακριτοποίηση την τιμή 24. Με βάση τον παραπάνω τρόπο καθορίζονται οι τιμές των ιδιοτήτων όλων των διανυσμάτων του συνόλου δεδομένων. Το πλήθος των υποδιαστημάτων (24) επελέγη εμπειρικά, βάσει προκαταρκτικών δοκιμών.

Πραγματοποιήσαμε δύο ειδών πειράματα. Στο πρώτο είδος, θεωρήσαμε γνωστές όλες τις ορθές κατηγορίες (B, I, O) των προηγούμενων γεγονότων (που επηρεάζουν τις τιμές των ιδιοτήτων μετέπειτα γεγονότων) του συνόλου ελέγχου. Αντίθετα, στο δεύτερο είδος πειραμάτων θεωρήσαμε ότι οι κατηγορίες των προηγούμενων γεγονότων του συνόλου ελέγχου ήταν αυτές στις οποίες τα είχε κατατάξει ο ταξινομητής της δραστηριότητας (κατατάσσουμε τα γεγονότα σειριακά από τα παλαιότερα προς τα νεότερα). Το δεύτερο είδος πειραμάτων είναι πιο ρεαλιστικό, αφού στην πράξη δεν γνωρίζουμε τις ορθές κατηγορίες των προηγούμενων γεγονότων, αλλά μόνο τις αποφάσεις που είχε πάρει ο κάθε ταξινομητής για αυτά. Το πρώτο είδος πειραμάτων, όμως, παρέχει μια ένδειξη του πόσο επηρεάζονται τα αποτελέσματα από τις λανθασμένες προηγούμενες αποφάσεις των ταξινομητών.

Τέλος, εκτός από το παραπάνω σύνολο δεδομένων, διαθέτουμε και ένα ακόμα, που κατασκευάστηκε στο MIT⁴. Ωστόσο, δεν πραγματοποιήσαμε εκτενή πειράματα με το σύνολο

³ Δοκιμάσαμε την υλοποίηση του AdaBoost που περιλαμβάνεται στο Weka (http://www.cs.waikato.ac.nz/~ml/weka/index_downloading.html), καθώς και δική μας υλοποίηση του AdaBoost. Τα πειραματικά αποτελέσματα που αναφέρουμε παρήχθησαν με την υλοποίηση του Weka. Δοκιμάσαμε επίσης τις υλοποιήσεις λογιστικής παλινδρόμησης (και της παραλλαγής της που είναι γνωστή ως ταξινομητής μεγίστης εντροπίας) του Machine Learning Group του National University of Taiwan (<http://www.csie.ntu.edu.tw/~cjlin/liblinear/>) και του Natural Language Processing Group του Πανεπιστημίου Stanford (<http://nlp.stanford.edu/>). Τα πειραματικά αποτελέσματα λογιστικής παλινδρόμησης που αναφέρουμε παρήχθησαν με την υλοποίηση του Stanford.

⁴ Διατίθεται από τη διεύθυνση: <http://courses.media.mit.edu/2004fall/mas622j/04.projects/home/>.

αυτό, διότι φαίνεται να περιέχει λάθη και ασυνέπειες που επηρεάζουν την επίδοση του συστήματός μας.

4.3 Αποτελέσματα με τον AdaBoost

Στα πειράματα αυτή της ενότητας χρησιμοποιήσαμε τον αλγόριθμο μάθησης AdaBoost (βλ. κεφάλαιο 3).⁵ Αρχικά πραγματοποιήσαμε πειράματα για 50 ως 300 επαναλήψεις εκπαίδευσης, με βήμα 50. Σε κάθε περίπτωση, εκπαιδεύσαμε το σύστημα στο σύνολο εκπαίδευσης και το αξιολογήσαμε στο σύνολο ελέγχου. Σε μερικά διαγράμματα, όμως, δείχνουμε και το ποσοστό σφάλματος (error rate) που επιτυγχάνει το σύστημα όταν αξιολογείται στο ίδιο σύνολο δεδομένων στο οποίο εκπαιδεύτηκε, γιατί το ποσοστό αυτό αποτελεί χονδρικά ένα κάτω (καλύτερο) φράγμα του αντίστοιχου ποσοστού που είναι δυνατόν να επιτύχει το σύστημα όταν αξιολογείται σε διαφορετικά δεδομένα από εκείνα στα οποία εκπαιδεύτηκε.

Στον Πίνακα 1 βλέπουμε τα αποτελέσματα για το πρώτο είδος πειραμάτων, όπου είναι γνωστές οι ορθές κατηγορίες των προηγούμενων γεγονότων ελέγχου. Τα αποτελέσματα του δεύτερου είδος πειραμάτων, όπου οι ορθές κατηγορίες των προηγούμενων γεγονότων είναι άγνωστες, είναι πανομοιότυπα με εκείνα του πρώτου. Η δεύτερη στήλη του Πίνακα 1 δείχνει τον αριθμό επαναλήψεων εκπαίδευσης που οδήγησε στο καλύτερο F-Measure. Οι επιδόσεις των υπολοίπων στηλών αντιστοιχούν στους καλύτερους αυτούς αριθμούς επαναλήψεων. Παρατηρούμε ότι για κάποιες δραστηριότητες το σύστημα είχε σχετικά καλά αποτελέσματα, ωστόσο για άλλες δραστηριότητες, όπως οι 15 και 17, τα αποτελέσματα ήταν πολύ χειρότερα.

Πίνακας 1: Αποτελέσματα κατάταξης σε B, I, O για το 1^ο είδος πειραμάτων

Δραστηριότητα (id)	Επαναλήψεις	Error rate (%)	Precision (%)	Recall (%)	F-Measure (%)
4	50-300	8,58	85,44	88,76	87,07
10	50-300	3,91	82,73	94,26	88,12
13	50-300	2,40	82,05	92,75	87,07
15	50-300	10,60	29,06	97,14	44,74
17	50-300	9,22	13,58	78,57	23,16
5	50-300	1,76	82,05	82,05	82,05

⁵ Πιο συγκεκριμένα, χρησιμοποιήσαμε την παραλλαγή AdaBoostM1, υλοποίηση της οποίας περιλαμβάνεται στο Weka.

Πίνακας 2: Πίνακας σύγκρισης δραστηριότητας id=13

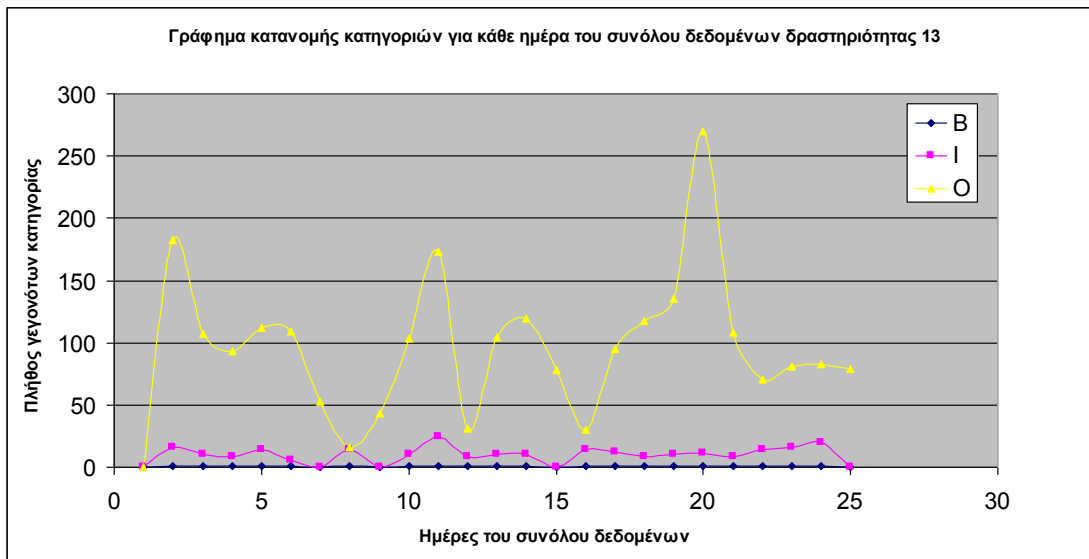
Δραστηριότητα id=13	B	I	O
B	0	0	29
I	0	229	0
O	0	39	495

Ο Πίνακας 2 δείχνει αναλυτικότερα πώς έγινε η ταξινόμηση των γεγονότων της δραστηριότητας 13. Για παράδειγμα, το στοιχείο O-O (γραμμή-στήλη) του πίνακα έχει την τιμή 495. Αυτό σημαίνει ότι 495 γεγονότα που ανήκαν στην πραγματικότητα στην κατηγορία O κατετάγησαν σε αυτήν. Το στοιχείο O-I έχει την τιμή 39. Αυτό σημαίνει ότι 39 γεγονότα που ανήκαν στην κατηγορία O κατετάγησαν στην I. Από τον Πίνακα 2 βλέπουμε ότι ο ταξινομητής έμαθε να ταξινομεί σωστά τα γεγονότα της κατηγορίας I, ενώ στην κατηγορία O πραγματοποιεί αρκετά λάθη. Επίσης, δεν κατατάσσει ποτέ γεγονότα στην κατηγορία B. Αντίστοιχη συμπεριφορά παρατηρήσαμε σε όλες τις δραστηριότητες.

Στο παρακάτω γράφημα παρουσιάζουμε την κατανομή των κατηγοριών για κάθε μία ημέρα στα γεγονότα του συνόλου δεδομένων.

Γράφημα 1

Κατανομή κατηγοριών στα γεγονότα του συνόλου δεδομένων για κάθε ημέρα



Η μπλε γραμμή μάς δείχνει την κατανομή της κατηγορίας B, η ροζ της I και η κίτρινη της O. Όπως φαίνεται στο διάγραμμα, τα γεγονότα O είναι πολύ περισσότερα, ενώ τα γεγονότα B εξαιρετικά λίγα. Παρόμοιες είναι οι κατανομές των γεγονότων και στις άλλες δραστηριότητες. Ως εκ τούτου, οι ταξινομητές μαθαίνουν να μην κατατάσσουν ποτέ (ή να κατατάσσουν πολύ σπάνια) τα γεγονότα στην κατηγορία B. Καταλήξαμε, λοιπόν, στο

συμπέρασμα ότι είναι προτιμότερο να αφαιρέσουμε την κατηγορία Β, διότι μπερδεύει τους ταξινομητές, και όλα τα γεγονότα που ανήκουν στην κατηγορία αυτή να κατατάσσονται στην κατηγορία Ι. Έτσι αυξάνεται ελαφρά και ο αριθμός των γεγονότων της κατηγορίας Ι. Παρακάτω, παρουσιάζουμε τα πειραματικά αποτελέσματα μετά την ενοποίηση των κατηγοριών Β και Ι. Συγκρίνοντας του πίνακες 1, 3 και 4 βλέπουμε ότι τα αποτελέσματα βελτιώθηκαν με την ενοποίηση των κατηγοριών Β και Ι, για αυτό στα επόμενα πειράματα χρησιμοποιήσαμε μόνο τις κατηγορίες Ι και Ο. Σημειώνουμε ότι κατά τον υπολογισμό των τιμών των ιδιοτήτων (κεφάλαιο 3), όπου αναφέρεται γεγονός κατηγορίας Β εννοείται πλέον γεγονός κατηγορίας Ι που ακολουθεί (αμέσως) ένα γεγονός Ο.

Πίνακας 3: Αποτελέσματα κατάταξης σε Ι, Ο για το 1^ο είδος πειραμάτων

Δραστηριότητα (id)	Επαναλήψεις	Error rate (%)	Precision (%)	Recall (%)	F-Measure (%)
4	50	8,59	85,71	88,37	87,02
10	50	2,52	91,13	92,62	91,87
13	50	1,64	86,84	95,67	91,03
15	50	1,52	75,56	97,14	85,00
17	50	2,27	40,91	64,29	50,00
5	50	1,01	96,97	82,05	88,89

Πίνακας 4: Αποτελέσματα κατάταξης σε Ι, Ο για το 2^ο είδος πειραμάτων

Δραστηριότητα (id)	Επαναλήψεις	Error rate (%)	Precision (%)	Recall (%)	F-Measure (%)
4	50	9,22	86,00	85,66	85,83
10	200	1,77	98,21	90,16	94,02
13	200	6,44	57,76	97,10	72,43
15	200,300	7,07	38,20	97,14	54,84
17	150	1,26	62,50	71,42	66,67
5	50	1,01	91,89	87,18	89,47

Επίσης, προκειμένου να μειώσουμε περαιτέρω την ανισοροπία του αριθμού γεγονότων των κατηγοριών Ι και Ο (τα Ο είναι πολύ περισσότερα), δοκιμάσαμε τρεις διαφορετικούς τρόπους «ψαλιδίσματος» (αφαίρεσης) γεγονότων, οι οποίοι αφαιρούν κυρίως γεγονότα Ο:

ΤΡΟΠΟΙ ΨΑΛΙΔΙΣΜΑΤΟΣ

- 1- Ψαλίδισε τα γεγονότα που προκαλούνται από αισθητήρες οι οποίοι δεν ενεργοποιούνται ούτε απενεργοποιούνται κατά τη διάρκεια εκτέλεσης της δραστηριότητας (που προσπαθούμε να μάθουμε να αναγνωρίζουμε) στα δεδομένα εκπαίδευσης.
- 2- Ψαλίδισε τα γεγονότα που προέρχονται από αισθητήρες οι οποίοι προκαλούν λιγότερα από 2% των γεγονότων εκπαίδευσης της δραστηριότητας.
- 3- Ψαλίδισε τα γεγονότα που προέρχονται από αισθητήρες οι οποίοι προκαλούν λιγότερα από 3% των γεγονότων εκπαίδευσης της δραστηριότητας.

Οι παρακάτω πίνακες δείχνουν τα πειραματικά αποτελέσματα με τον πρώτο τρόπο ψαλιδίσματος.

Πίνακας 5: Αποτελέσματα κατάταξης σε I, O με ψαλίδισμα 1^ο τρόπου για το 1^ο είδος πειραμάτων

Δραστηριότητα (id)	Επαναλήψεις	Error rate (%)	Precision (%)	Recall (%)	F-Measure (%)
4	80-100	7,08	95,88	90,31	93,01
10	55,65,70,75	1,42	97,52	96,72	97,12
13	95	2,59	89,47	98,55	93,79
15	80	3,02	70,45	93,94	80,52
17	15,20,25	7,69	68,75	78,57	73,33
5	10	3,45	80,43	94,87	87,06

Πίνακας 6: Αποτελέσματα κατάταξης σε I, O με ψαλίδισμα 1^ο τρόπου για το 2^ο είδος πειραμάτων

Δραστηριότητα (id)	Επαναλήψεις	Error rate (%)	Precision (%)	Recall (%)	F-Measure (%)
4	5,10	7,29	96,64	89,15	92,74
10	25	2,63	100,00	89,34	94,37
13	60	6,05	80,77	91,30	85,71
15	40,50	5,44	55,17	96,97	70,32
17	15	2,88	100,00	78,57	88,00
5	10	3,45	80,43	94,87	87,06

Συγκρίνοντας τους πίνακες 3, 4 και 5, 6 παρατηρούμε ότι υπάρχει σημαντική βελτίωση της αναγνώρισης όλων των δραστηριοτήτων, με εξαίρεση τη δραστηριότητα 5,

διαφορά που ίσως οφείλεται στο ότι με τη δραστηριότητα 5 σχετίζονται μόνο 2 αισθητήρες, αντί 4-5 για τις υπόλοιπες δραστηριότητες. Σημειώνουμε ότι μας ενδιαφέρει περισσότερο το F-Measure (συνδυασμός Precision και Recall) και όχι το ποσοστό σφάλματος (Error Rate), γιατί ένας ταξινομητής που κατατάσσει σωστά τα γεγονότα O (που είναι πολύ περισσότερα) επιτυγχάνει χαμηλό (καλό) ποσοστό σφάλματος, ακόμα και αν δεν εντοπίζει καλά πότε εκτελούνται οι διαδικασίες.

Οι επιδόσεις των ταξινομητών με τους άλλους δύο τρόπους ψαλιδίσματος είναι παρόμοιες, ωστόσο μεγαλύτερη βελτίωση σημειώνεται με τον τρίτο τρόπο ψαλιδίσματος. Για το λόγο αυτό παρακάτω παρουσιάζουμε τους πίνακες των αποτελεσμάτων για τον τρίτο τρόπο ψαλιδίσματος. Οι επαναλήψεις του AdaBoost που χρησιμοποιήσαμε ήταν από 5 ως 100, με βήμα 5.

Πίνακας 7: Αποτελέσματα κατάταξης σε I, O με ψαλίδισμα 3^{ου} τρόπου για το 1^ο είδος πειραμάτων

Δραστηριότητα (id)	Επαναλήψεις	Error rate (%)	Precision (%)	Recall (%)	F-Measure (%)
4	80-100	7,08	95,88	90,31	93,01
10	55,65,70,75	1,42	97,52	96,72	97,12
13	5,10	0,00	100,00	100,00	100,00
15	10	1,43	92,85	96,30	94,54
17	25	9,18	63,16	85,71	72,73
5	15	9,16	84,62	84,62	84,62

Πίνακας 8: Αποτελέσματα κατάταξης σε I, O με ψαλίδισμα 3^{ου} τρόπου για το 2^ο είδος πειραμάτων

Δραστηριότητα (id)	Επαναλήψεις	Error rate (%)	Precision (%)	Recall (%)	F-Measure (%)
4	5,10	7,29	96,64	89,15	92,74
10	25	2,63	100,00	89,34	94,37
13	55-65,75	2,35	94,37	100,00	97,10
15	15-30,50-60,70,80	1,43	92,86	96,30	94,55
17	20,25	5,10	84,62	78,57	81,48
5	15	32,82	46,43	66,67	54,74

Καταλήγουμε στο συμπέρασμα ότι οι ταξινομητές κάποιων δραστηριοτήτων επιτυγχάνουν καλύτερες επιδόσεις με τον πρώτο τρόπο ψαλιδίσματος, ενώ άλλοι με το δεύτερο τρόπο. Ωστόσο ο ταξινομητής της δραστηριότητας 5 φαίνεται ότι ανταποκρίνεται


καλύτερα όταν δε χρησιμοποιείται κανένας τρόπος ψαλιδίσματος, ενώ οι επιδόσεις του χειροτερεύουν αισθητά με τον τρίτο τρόπο ψαλιδίσματος, που είναι εν γένει ο καλύτερος για τις υπόλοιπες δραστηριότητες.

Για τη σύγκριση των αποτελεσμάτων μας, υλοποιήσαμε ακόμα δύο βασικές μεθόδους (baseline 1 και baseline 2). Η baseline 1 κατατάσσει κάθε ένα γεγονός στην κατηγορία η οποία εμφανίζεται συχνότερα στα δεδομένα εκπαίδευσης. Η baseline 2 χρησιμοποιεί μόνο μία επανάληψη εκπαίδευσης του AdaBoost, επομένως εξετάζει μόνο μία ιδιότητα.

Τα παρακάτω γραφήματα δείχνουν ενδεικτικά, για δύο δραστηριότητες, το ποσοστό σφάλματος των μεθόδων, αυξάνοντας σταδιακά τον αριθμό των γεγονότων του συνόλου εκπαίδευσης που χρησιμοποιούνται για την εκπαίδευση του συστήματος (καμπύλες μάθησης). Δείχνουμε τόσο το ποσοστό σφάλματος στα δεδομένα ελέγχου (διαφορετικά από τα δεδομένα εκπαίδευσης) όσο και στα δεδομένα εκπαίδευσης (ίδια δεδομένα εκπαίδευσης και ελέγχου), για τους λόγους που προαναφέραμε. Τα κατακόρυφα διαστήματα (error bars) αντιστοιχούν σε διαστήματα εμπιστοσύνης 95%.


Γράφημα 2

Καμπύλες μάθησης Adaboost (15 επαναλήψεις), baseline 1, baseline 2 για τη δραστηριότητα 17 στο 1^ο είδος πειραμάτων




Γράφημα 3

Καμπύλες μάθησης Adaboost (15 επαναλήψεις), baseline 1, baseline 2 για τη δραστηριότητα 17 στο 2^ο είδος πειραμάτων




Γράφημα 4

Καμπύλες μάθησης Adaboost (5 επαναλήψεις), baseline 1, baseline 2 για τη δραστηριότητα 13 στο 1^ο είδος πειραμάτων



Γράφημα 5

Καμπύλες μάθησης μεθόδων Adaboost (55 επαναλήψεις), baseline 1, baseline 2 για τη δραστηριότητα 13 στο 2^ο είδος πειραμάτων



Συνοψίζοντας, στους παρακάτω πίνακες παρουσιάζουμε τις καλύτερες επιδόσεις (αντιστοιχούν στα καλύτερα F-Measure) των ταξινομητών για τα δύο είδη πειραμάτων.

Πίνακας 9α: Αποτελέσματα καλύτερων επιδόσεων AdaBoost για το 1ο είδος πειραμάτων

Δραστηριότητα (id)	Συνθήκη ψαλιδίσματος	Επαναλήψεις AdaBoost	Error rate (%)	Precision (%)	Recall (%)	F-Measure (%)
4	1,2,3	80-100	7,08	95,88	90,31	93,01
10	1,2,3	55,65,70,75	1,42	97,52	96,72	97,12
13	3	5,10	0,00	100,00	100,00	100,00
15	3	10	1,43	92,85	96,30	94,54
17	1	15,20,25	7,69	68,75	78,57	73,33
5	καμία	50	1,01	96,97	82,05	88,89

Πίνακας 9β: Αποτελέσματα καλύτερων επιδόσεων baseline 1 για το 1^ο είδος πειραμάτων

Δραστηριότητα (id)	Συνθήκη ψαλιδίσματος	Error rate (%)	Precision (%)	Recall (%)	F-Measure (%)
4	1,2,3	47,77	52,22	100,00	68,62
10	Καμία	15,40	NaN	0,00	NaN
13	Καμία	8,71	NaN	0,00	NaN
15	Καμία	4,42	NaN	0,00	NaN
17	Καμία	1,77	NaN	0,00	NaN
5	Καμία	4,92	NaN	0,00	NaN

Πίνακας 9γ: Αποτελέσματα καλύτερων επιδόσεων baseline 2 για το 1^ο είδος πειραμάτων

Δραστηριότητα (id)	Συνθήκη ψαλιδίσματος	Error rate (%)	Precision (%)	Recall (%)	F-Measure (%)
4	1,2,3	10,12	90,31	90,31	90,31
10	1,2,3	4,45	88,46	94,26	91,26
13	3	6,47	85,90	100,00	92,41
15	3	16,19	44,07	92,30	60,47
17	1	9,62	61,11	78,57	68,75
5	1	4,08	82,50	84,62	83,54

Πίνακας 10α: Αποτελέσματα καλύτερων επιδόσεων για το 2ο είδος πειραμάτων

Δραστηριότητα (id)	Συνθήκη ψαλιδίσματος	Επαναλήψεις AdaBoost	Error rate (%)	Precision (%)	Recall (%)	F-Measure (%)
4	1,2,3	5,10	7,29	96,64	89,15	92,74
10	1,2,3	25	2,63	100,00	89,34	94,37
13	3	55-65,75	2,35	94,37	100,00	97,10
15	3	15-30,50-60,70,80	1,43	92,86	96,30	94,55
17	1	15	2,88	100,00	78,57	88,00
5	καμία	50	1,01	91,89	87,18	89,47

Πίνακας 10β: Αποτελέσματα καλύτερων επιδόσεων baseline 1 για το 2^ο είδος πειραμάτων

Δραστηριότητα (id)	Συνθήκη ψαλιδίσματος	Error rate (%)	Precision (%)	Recall (%)	F-Measure (%)
4	1,2,3	47,77	52,22	100,00	68,62
10	καμία	15,40	NaN	0,00	NaN
13	καμία	8,71	NaN	0,00	NaN
15	καμία	4,42	NaN	0,00	NaN
17	καμία	1,77	NaN	0,00	NaN
5	καμία	4,92	NaN	0,00	NaN

Πίνακας 10γ: Αποτελέσματα καλύτερων επιδόσεων baseline 2 για το 2^ο είδος πειραμάτων

Δραστηριότητα (id)	Συνθήκη ψαλιδίσματος	Error rate (%)	Precision (%)	Recall (%)	F-Measure (%)
4	1,2,3	10,12	90,31	90,31	90,31
10	1,2,3	4,45	88,46	94,26	91,26
13	3	6,47	85,90	100,00	92,41
15	3	16,19	44,07	96,30	60,47
17	1	9,62	61,11	78,57	68,75
5	1	4,08	82,50	84,61	83,54

Από τους παραπάνω πίνακες βλέπουμε ότι τα αποτελέσματα με τον AdaBoost είναι εν γένει σαφώς καλύτερα από τα αντίστοιχα αποτελέσματα των baseline 1 και baseline 2. Ο αριθμός επαναλήψεων εκπαίδευσης, όμως, του AdaBoost που οδηγεί στα καλύτερα αποτελέσματα διαφέρει από δραστηριότητα σε δραστηριότητα. Τα αποτελέσματα ποικίλλουν επίσης ανάλογα με τον τρόπο ψαλιδίσματος. Συμπεραίνουμε λοιπόν, ότι για κάποιες δραστηριότητες οι αισθητήρες που έχουν μικρή συχνότητα εμφάνισης είναι σημαντικοί, αντίθετα για κάποιες άλλες δραστηριότητες οι αισθητήρες αυτοί μπερδεύουν τους ταξινομητές.

4.4 Αποτελέσματα με λογιστική παλινδρόμηση

Με βάση τις παρατηρήσεις που κάναμε προηγουμένως, στα πειράματα με τον ταξινομητή λογιστικής παλινδρόμησης χρησιμοποιήσαμε μόνο τις κατηγορίες I και O. Δοκιμάσαμε πάλι και τους τρεις τρόπους «ψαλιδίσματος» γεγονότων. Οι καλύτερες επιδόσεις σημειώθηκαν με τον πρώτο τρόπο ψαλιδίσματος, για τον οποίο τα αποτελέσματα παρουσιάζονται παρακάτω:

Πίνακας 11: Αποτελέσματα κατάταξης σε I, O με ψαλίδισμα 1^ο τρόπου για το 1^ο είδος πειραμάτων

Δραστηριότητα (id)	Error rate (%)	Precision (%)	Recall (%)	F-Measure (%)
4	8,10	95,04	89,15	92,00
10	3,85	94,01	90,16	92,04
13	9,22	79,37	72,46	75,76
15	0,60	94,11	96,97	95,52
17	5,77	78,57	78,57	78,57
5	3,45	88,89	82,05	85,33


Πίνακας 12: Αποτελέσματα κατάταξης σε I, O με ψαλίδισμα 1^ο τρόπου για το 2^ο είδος πειραμάτων

Δραστηριότητα (id)	Error rate (%)	Precision (%)	Recall (%)	F-Measure (%)
4	47,77	52,22	100,00	68,61
10	75,10	24,75	100,00	39,68
13	68,01	22,62	100,00	36,89
15	48,39	11,81	96,97	21,06
17	50,96	20,00	92,86	32,91
5	82,46	12,91	100,00	22,87

Στους πίνακες 11 και 12 παρατηρούμε ότι στο πρώτο είδος πειραμάτων ο ταξινομητής λογιστικής παλινδρόμησης πέτυχε σχετικά καλά αποτελέσματα σε κάποιες δραστηριότητες, ενώ σε κάποιες άλλες δεν τα πήγε και τόσο καλά. Ωστόσο, στο δεύτερο είδος πειραμάτων, τα αποτελέσματα ήταν απογοητευτικά. Στα παρακάτω γραφήματα φαίνεται ενδεικτικά το ποσοστό σφάλματος του ταξινομητή για τη δραστηριότητα με ταυτότητα 13, για το πρώτο και δεύτερο είδος πειραμάτων. Τα διαγράμματα των υπολοίπων δραστηριοτήτων είναι παρόμοια.


Γράφημα 6

Καμπύλες μάθησης μεθόδου Λογιστικής Παλινδρόμησης, για τη δραστηριότητα id=13
1^ο είδος πειραμάτων



Γράφημα 7

Καμπύλες μάθησης μεθόδου Λογιστικής Παλινδρόμησης, για τη δραστηριότητα id=13
2^ο είδος πειραμάτων



ΚΕΦΑΛΑΙΟ 5

ΣΥΜΠΕΡΑΣΜΑΤΑ

5.1 Σύνοψη των αποτελεσμάτων

Στη διάρκεια της παρούσας εργασίας αναπτύχθηκε ένα σύστημα αναγνώρισης των δραστηριοτήτων που εκτελεί ένας άνθρωπος μέσα σε ένα σπίτι. Η μέθοδος αξιοποιεί ενδείξεις αισθητήρων και αλγορίθμους μηχανικής μάθησης. Δοκιμάστηκαν πειραματικά, σε δεδομένα άλλων ερευνητών, δύο αλγόριθμοι επιβλεπόμενης μάθησης, ο AdaBoost και ένας ταξινομητής λογιστικής παλινδρόμησης. Τα πειραματικά αποτελέσματα με τον AdaBoost ήταν σαφώς καλύτερα.

Τα περισσότερα συστήματα αναγνώρισης δραστηριοτήτων χρησιμοποιούν ένα μόνο ταξινομητή, ο οποίος προσπαθεί να αναγνωρίσει όλες τις δραστηριότητες. Αντίθετα, στο σύστημά μας χρησιμοποιήσαμε πολλούς ταξινομητές, έναν διαφορετικό για κάθε δραστηριότητα. Η χρήση διαφορετικού ταξινομητή ανά δραστηριότητα επιτρέπει την εύκολη προσθήκη νέων δραστηριοτήτων, κάτι που μπορεί να γίνει με την εκπαίδευση και προσθήκη νέων ταξινομητών για τις νέες δραστηριότητες. Επίσης, επιτρέπει οι δραστηριότητες να επικαλύπτονται. Σημειώνουμε, επίσης, ότι αντίθετα από μερικά προηγούμενα συστήματα, το σύστημά μας δεν αποφασίζει μόνο ποιες δραστηριότητες εκτελέστηκαν σε ένα δεδομένο χρονικό διάστημα, αλλά και πότε ακριβώς εκτελέστηκαν. Επίσης, μπορεί να αναγνωρίζει δραστηριότητες τη στιγμή που εκτελούνται, σε συνθήκες πραγματικού χρόνου (real-time).

Το σύστημά μας θεωρεί ως γεγονότα προς κατάταξη τις χρονικές στιγμές όπου αλλάζει ένδειξη τουλάχιστον ένας αισθητήρας. Διαπιστώσαμε ότι τα αποτελέσματα είναι καλύτερα όταν «ψαλιδίζονται» γεγονότα που προκαλούνται από αισθητήρες οι οποίοι δεν φαίνεται (από τα δεδομένα εκπαίδευσης) να σχετίζονται με γεγονότα στα οποία εκτελούνται οι δραστηριότητες. Επίσης, τα αποτελέσματα ήταν καλύτερα χρησιμοποιώντας μόνο δύο κατηγορίες ανά δραστηριότητα (εκτελείται ή όχι η δραστηριότητα), σε σχέση με τα αποτελέσματα με δύο κατηγορίες (αρχίζει να εκτελείται, συνεχίζει να εκτελείται, δεν εκτελείται η δραστηριότητα).

5.2 Πιθανές μελλοντικές επεκτάσεις

Θα ήταν ενδιαφέρον να διερευνηθεί στο μέλλον η πιθανότητα ενσωμάτωσης του συστήματος της παρούσας εργασίας σε ένα μεγαλύτερο σύστημα, για παράδειγμα ένα σύστημα που θα παρακολουθεί τις δραστηριότητες ηλικιωμένων ή άλλων ατόμων που χρειάζονται επίβλεψη και θα εντοπίζει ασυνήθιστες δραστηριότητες, που ενδεχομένως να σηματοδοτούν την ανάγκη ιατρικής φροντίδας.

Θα ήταν επίσης ενδιαφέρον να διερευνηθεί το ενδεχόμενο συνδυασμού του συστήματος της εργασίας με ένα σύστημα παραγωγής κειμένων φυσικής γλώσσας, το οποίο θα παράγει περιλήψεις, σε μορφή κειμένων, που θα συνοψίζουν τις δραστηριότητες ενός ατόμου. Έχουν ήδη αναπτυχθεί συστήματα αυτού του είδους που βοηθούν παιδιά με γλωσσικές δυσκολίες να αφηγηθούν τι έκαναν στη διάρκεια της ημέρας (Reiter κ.ά. 2009, Black κ.ά. 2010).

Αναφορές

Δασούλας Κ., *Μελέτη και Υλοποίηση Ολοκληρωμένου Συστήματος Καταγραφής Ενεργειών Ατόμων σε Εξωτερικούς Χώρους*, Διπλωματική Εργασία, Τμήμα Πληροφορικής, Οικονομικό Πανεπιστήμιο Αθηνών, 2009.

Παπαματθαϊάκης Γ., *Σχεδίαση και Υλοποίηση Έξυπνου Συστήματος για Ανάλυσης και Αξιολόγησης Δεδομένων από Αισθητήρες Χώρου*, Διπλωματική Εργασία, Τμήμα Πληροφορικής, Οικονομικό Πανεπιστήμιο Αθηνών, 2008.

Συρίγος Μ., *Σχεδιασμός & Υλοποίηση Συστήματος Καταγραφής & Αναγνώρισης Καθημερινών Δραστηριοτήτων*, Διπλωματική Εργασία, Τμήμα Πληροφορικής, Οικονομικό Πανεπιστήμιο Αθηνών, 2009.

Τρούβα Ε., *The Mobile Phone as a Platform Assisting the Independent Living of Aging People*, Διπλωματική εργασία, Τμήμα Πληροφορικής, Οικονομικό Πανεπιστήμιο Αθηνών, 2009.

Black R., Reiter E., Reddington J., Tintarev n. and Waller A., *Using NLG and Sensors to Support Narrative for Children with Complex Communication Needs*, Proceedings of NAACL-10 Workshop on Speech and Language Processing for Assistive Technology, California, USA, 2010

Crandall A. and Cook D.J., *Attributing to Individuals in Multi-Inhabitant Environments*, Proceedings of the Fourth International Conference on Intelligent Environments, Seattle, USA, 2008.

Freund Y. and Schapire R.E., *Experiments with a New Boosting Algorithm*, Machine Learning: Proceedings of the Thirteenth International Conference, Bari, Italy, 1996.

Hongeng S., Bremond F. and Nevatia R., *Representation and Optimal Recognition of Human Activities*, Proceedings of the Conference on Computer Vision and Pattern Recognition, South Carolina, USA, 2000.

Huynh T. and Schiele B., *Analyzing Features for Activity Recognition*, Proceedings of the Joint Conference on Smart Objects and Ambient Intelligence, Grenoble, France, 2005.

Jakulla V. and Cook D.J., *Anomaly Detection Using Temporal Mining in a Smart Home Environment*, International Journal in Methods of Information in Medicine, Smart Homes and Ambient Assisted Living special issue, 2008.

Jakulla V. and Cook D.J., *Mining Sensor in Smart Environment for Temporal Activity Prediction*, In Proceedings of the First International Workshop on Knowledge Discovery from Sensor Data, California, USA, 2007.

Jurafski D. and Martin H., *Speech and language processing: An introduction to natural processing computational linguistics and speech recognition*, Pearson, 2006.

Kasteren T., Noulas A., Englebienne G. and Krose B., *Accurate Activity Recognition in a Home Setting*, Proceedings of the Tenth International Conference on Ubiquitous Computing, Seoul, Korea, 2008.

Logan B., Healey J., Philipose M., Tapia E. and Intille S., *A Long-Term Evaluation of Sensing Modalities for Activity Recognition*, Proceedings of the Ninth International Conference on Ubiquitous Computing, Innsbruck, Austria, 2007.

Maurer U., Smailagic A., Siewiorek D. and Deisher M., *Activity Recognition and Monitoring Using Multiple Sensors on Different Body Positions*, Proceedings of the International Workshop on Wearable and Implantable Body Sensor Networks, Massachusetts, USA, 2006.

Reiter E., Turner R., Alm N., Black R., Dempster M. and Waller A., *Using NLG to Help Language-Impaired Users Tell Stories and Participate in Social Dialogues*, Proceedings of Twelfth European Workshop on Natural Language Generation, Athens, Greece, 2009.

Riedel D., Venkatesh S. and Liu V., *Spatial activity recognition in a smart home environment using a chemotactic model*, Proceedings of the Fifth International Conference on Intelligent Sensors, Sensor Networks and Information Processing, Melbourne, Australia, 2005.

Rusel S. and Norvig P., *Artificial Intelligence a Modern Approach Second Edition*, Pearson Education, Inc, 2003.

Schapire R.E., *Theoretical Views of Boosting and Applications*, Algorithm Learning Theory: Proceedings of the Tenth International Conference, Berlin, Germany, 1999.

Singla G., Cook D.J. and Schmitter-Edgecombe M., *Incorporating Temporal Reasoning Into Activity Recognition for Smart Home Residents*, Proceedings of the AAAI Workshop on Spatial and Temporal Reasoning, Illinois, USA, 2008.

Sutton C. and McCallum A., *An Introduction to Conditional Random Fields for Relational Learning*, MIT Press, Massachusetts, USA, 2006.

Szewczyk S., Dwan K., Minor B., Swedlove B. and Cook D.J., *Annotating Smart Environment Sensor Data for Activity Recognition*, International Journal Technology and Health Care, special issue on Smart Environments: Technology to support health care, 2009.

Tapia E., *Activity Recognition in the Home Setting Using Simple and Ubiquitous Sensors*, MSc thesis, Massachusetts Institute of Technology, USA, 2003.

Yacoob Y., Black M., *Parameterized Modeling and Recognition of Activities*, International Journal Computer Vision and Image Understanding, 1999.

Zouba N., Bremond F., Thonnat M. and Thinh V., *Multi-Sensors Analysis for Everyday Activity Monitoring*, In Proceedings of the Fourth International Conference: Sciences of Electronic, Technologies of Information and Telecommunications, Hammamet, Tunisia, 2007.