

Μέθοδοι Εντοπισμού Σημείων Αλλαγής σε
Πολυδιάστατες Χρονοσειρές για Ανίχνευση Μεταβολών
Κινητικής Δραστηριότητας

Η Μεταπτυχιακή Εργασία Ειδίκευσης

υποβάλλεται στην ορισθείσα
από την Γενική Συνέλευση Ειδικής Σύθεσης
του Τμήματος Μηχανικών Η/Υ και Πληροφορικής
Εξεταστική Επιτροπή

από τον

Ιωάννη Φωτόπουλο

ως μέρος των υποχρεώσεων για την απόκτηση του

ΜΕΤΑΠΤΥΧΙΑΚΟΥ ΔΙΠΛΩΜΑΤΟΣ ΣΤΗΝ ΠΛΗΡΟΦΟΡΙΚΗ
ΜΕ ΕΙΔΙΚΕΥΣΗ
ΣΤΙΣ ΤΕΧΝΟΛΟΓΙΕΣ-ΕΦΑΡΜΟΓΕΣ

Πανεπιστήμιο Ιωαννίνων

Φεβρουάριος 2020

Εξεταστική Επιτροπή:

- **Αριστείδης Λύκας**, Καθηγητής, Τμήμα Μηχανικών Η/Υ & Πληροφορικής, Πανεπιστήμιο Ιωαννίνων
- **Κωνσταντίνος Μπλέκας**, Αναπληρωτής Καθηγητής, Τμήμα Μηχανικών Η/Υ & Πληροφορικής, Πανεπιστήμιο Ιωαννίνων
- **Κωνσταντίνος Βλάχος**, Επίκουρος Καθηγητής, Τμήμα Μηχανικών Η/Υ & Πληροφορικής, Πανεπιστήμιο Ιωαννίνων

ΑΦΙΕΡΩΣΗ

Αφιερώνω την εργασία στην οικογένεια μου, την Έφη και τους φίλους μου, οι οποίοι με στήριξαν καθ' όλη την διάρκεια των μεταπτυχιακών μου σπουδών.

ΕΥΧΑΡΙΣΤΙΕΣ

Θα ήθελα να ευχαριστήσω τον επιβλέποντα Κ. Αριστείδη Λύκα για την στήριξη του, χωρίς τις σημαντικές παρατηρήσεις, καθοδηγήσεις και διορθώσεις δεν θα προέκυπτε το επιθυμητό αποτέλεσμα της εργασίας.

ΠΕΡΙΕΧΟΜΕΝΑ

ΠΕΡΙΕΧΟΜΕΝΑ	iv
ΚΑΤΑΛΟΓΟΣ ΣΧΗΜΑΤΩΝ	vii
ΚΑΤΑΛΟΓΟΣ ΠΙΝΑΚΩΝ	x
ΠΕΡΙΛΗΨΗ	xiii
EXTENDED ABSTRACT IN ENGLISH	xv
1.ΕΙΣΑΓΩΓΗ	1
1.1 Ορισμός Προβλήματος.....	2
1.2 Κατηγοριοποίηση Μεθόδων	3
1.3 Κύριες Μέθοδοι Εντοπισμού	4
1.4 Πεδίο Εφαρμογής.....	7
1.5 Ανοιχτά Προβλήματα.....	8
1.6 Δομή Διατριβής.....	9
2.ΣΤΑΤΙΣΤΙΚΟ-ΑΛΓΟΡΙΘΜΙΚΟ ΥΠΟΒΑΘΡΟ	11
2.1 Συναρτήσεις Κόστους	12
2.1.1 Παραμετρικά Μοντέλα	13
2.1.1.1 Εκτίμηση Μέγιστης Πιθανοφάνειας (ML Estimation)	13
2.1.1.2 Γραμμικά Αυτοπαλινδρομικά Μοντέλα.....	16
2.1.2 Μη Παραμετρικά Μοντέλα	17
2.1.2.1 Εκτίμηση Μέγιστης μη Παραμετρικής Πιθανοφάνειας.....	18
2.1.2.2 Στατιστικό Βαθμίδα.....	19
2.1.2.3 Μετασχηματισμοί Πυρήνα.....	20
2.2 Αλγόριθμοι Εντοπισμού Σημείων Αλλαγής.....	21
2.2.1 Εξαντλητικοί Αλγόριθμοι	22
2.2.2 Προσεγγιστικοί Αλγόριθμοι	24
2.2.2.1 Δυαδική κατάτμηση (Binary Segmentation).....	24
2.2.2.2 Bottom Up κατάτμηση	25
2.2.2.3 Κυλιόμενο Παράθυρο (Sliding Window)	26
3.ΚΥΛΙΟΜΕΝΟ ΠΑΡΑΘΥΡΟ ΣΤΑΘΕΡΟΥ ΜΕΓΕΘΟΥΣ	29

3.1	Άθροισμα Αποστάσεων.....	30
3.2	Διαφορά Εξωτερικής και Εσωτερικής Απόστασης.....	31
3.3	Διαφορά Στατιστικού Μέσου Όρου	33
3.4	Εφαρμογή του Dip Test.....	34
3.4.1	Πίνακας αποστάσεων μεταξύ σημείων.....	36
3.4.2	Πίνακας αποστάσεων μεταξύ μέσων όρων και σημείων.....	37
3.5	Σφάλμα Ανακατασκευής Μέσω PCA.....	37
3.6	Γενική Περιγραφή Αλγορίθμου Κυλιόμενου Παραθύρου.....	39
4.	ΑΛΓΟΡΙΘΜΟΣ ΑΥΞΑΝΟΜΕΝΟΥ ΠΑΡΑΘΥΡΟΥ	42
4.1	Περιγραφή Αλγορίθμου	42
4.1.1	Έλεγχος Πολυτροπικότητας του Παραθύρου	43
4.1.2	Κριτήριο Βέλτιστης Κατάτμησης	44
4.1.3	Εύρεση Μονοτροπικού Παραθύρου	45
5.	ΕΦΑΡΜΟΓΗ ΣΕ ΡΟΕΣ ΔΕΔΟΜΕΝΩΝ ΑΠΟ ΑΙΣΘΗΤΗΡΕΣ ΚΙΝΗΣΗΣ ...	48
5.1	Προεπεξεργασία Σημάτων	49
5.1.1	Εξαγωγή Χαρακτηριστικών Μέσω Αυτοκωδικοποιητών	50
5.1.2	Εξαγωγή Ενέργειας Σημάτων Μέσω DFT Μετασχηματισμών.....	53
5.1.3	Κανονικοποίηση Z.....	53
5.2	Τρόπος Αξιολόγησης	55
5.2.1	Μετρικές Αξιολόγησης.....	56
5.3	Πειραματική Μελέτη.....	57
5.3.1	Περιγραφή Συνόλων Δεδομένων	58
5.3.1.1	CrowdSignals	58
5.3.1.2	HHAR.....	59
5.3.1.3	MHealth.....	61
5.3.2	Αποτελέσματα Αλγορίθμου Κυλιόμενου Παραθύρου	62
5.3.2.1	Crowdsignals.....	63
5.3.2.2	HHAR Phone.....	68
5.3.2.3	HHAR Watch	73
5.3.2.4	MHealth.....	78
5.3.3	Αποτελέσματα Αλγορίθμου Αυξανόμενου Παραθύρου.....	83
5.3.3.1	Crowdsignals.....	83
5.3.3.2	HHAR Phone.....	84
5.3.3.3	HHAR Watch	85
5.3.3.4	MHealth.....	86

5.4	Συμπεράσματα	87
5.4.1	Αλγόριθμος Κυλιόμενου Παραθύρου	87
5.4.2	Αλγόριθμος Αυξανόμενου Παραθύρου	89
5.4.3	Μετά-Ανάλυση Σφάλματος Ανακατασκευής PCA	91
6.ΣΥΝΟΨΗ-ΜΕΛΛΟΝΤΙΚΗ ΕΡΓΑΣΙΑ	98
6.1	Σύνοψη	98
6.2	Μελλοντική Εργασία	99
ΑΝΑΦΟΡΕΣ	100

ΚΑΤΑΛΟΓΟΣ ΣΧΗΜΑΤΩΝ

Σχήμα 1.1 Δείγμα σημάτων 3 αισθητήρων που καταγράφουν ανθρώπινες δραστηριότητες χαμηλού επιπέδου.....	8
Σχήμα 2.1 Διαχωρισμός των κύριων αλγορίθμων εντοπισμού.....	23
Σχήμα 2.2 Σχηματική αναπαράσταση του Bin Seg αλγορίθμου.	25
Σχήμα 2.3 Σχηματική αναπαράσταση του αλγορίθμου Bottom Up.	26
Σχήμα 2.4 Σχηματική αναπαράσταση του αλγορίθμου Win Sliding.....	27
Σχήμα 3.1 Σχηματική αναπαράσταση της μετρικής (3.1).	31
Σχήμα 3.2 Σχηματική αναπαράσταση της μετρικής (3.4)	33
Σχήμα 3.3 Σχηματική αναπαράσταση της μετρικής (3.5).	34
Σχήμα 3.4 Περίπτωση πολυτροπικής κατανομής.	35
Σχήμα 3.5 Περίπτωση μονοτροπικής κατανομής	35
Σχήμα 3.6 Σχηματική αναπαράσταση του αλγορίθμου του κυλιόμενου παραθύρου..	40
Σχήμα 3.7 Βήματα εξαγωγής των σημείων αλλαγής μέσω του αλγορίθμου του κυλιόμενου παραθύρου.....	41
Σχήμα 4.1 Απεικόνιση των περιπτώσεων πολυτροπικότητας του βήματος 4 του αλγορίθμου αυξανόμενου παραθύρου.	46
Σχήμα 4.2 Σχηματική αναπαράσταση του αλγορίθμου του αυξανόμενου παραθύρου.	47
Σχήμα 5.1 Αρχιτεκτονική αυτοκωδικοποιητών με 3 κρυμμένα επίπεδα.....	51
Σχήμα 5.2 Εύρος τιμών του Z-statistic	54
Σχήμα 5.3 Διάγραμμα προεπεξεργασίας	55
Σχήμα 5.4 Σχηματική αναπαράσταση τοποθέτησης συσκευών αισθητήρων στον χρήστη και δείγμα των δραστηριοτήτων που εκτελεί.....	57
Σχήμα 5.5 Αναπαράσταση ροής σημάτων ενός χρήστη απ' το Crowdsignals σύνολο.	59
Σχήμα 5.6 Αναπαράσταση ροής σημάτων της συσκευής έξυπνου τηλεφώνου (Phone) ενός χρήστη απ' το σύνολο HHAR.	60
Σχήμα 5.7 Αναπαράσταση ροής σημάτων της συσκευής έξυπνου ρολογιού (Watch) ενός χρήστη απ' το σύνολο HHAR.	60
Σχήμα 5.8 Αναπαράσταση ροής σημάτων ενός χρήστη απ' το σύνολο MHealth.....	61
Σχήμα 5.9 α) Ροή ανομοιογένειας β) σωστά εντοπισμένα σημεία αλλαγής της μετρικής (3.1) για τον χρήστη 1 (περίπτωση Normalization προεπεξεργασίας).....	63
Σχήμα 5.10 α) Ροή ανομοιογένειας β) σωστά εντοπισμένα σημεία αλλαγής της μετρικής (3.4) για τον χρήστη 1 (περίπτωση Normalization προεπεξεργασίας).....	64

Σχήμα 5.33 Μέση απόδοση σε κάθε σύνολο για κάθε περίπτωση μετρικής και προεπ. (κάθετες στήλες μέθοδος προεπ.) α) άθρ. αποστ. (3.1) β) διαφ. εξ. εσωτ. αποστ. (3.4) γ) διαφ. μέσων (3.5) δ) dip test (3.7) ε) PCA (3.10)	88
Σχήμα 5.34 Αναπαράσταση των μέσων αποδόσεων όλων των συνόλων του αλγορίθμου του αυξανόμενου παραθύρου για κάθε σύνολο και κάθε περίπτωση προεπεξεργασίας.....	90
Σχήμα 5.35 α) Ροή ανομοιογένειας β) σωστά εντοπισμένα σημεία αλλαγής της μετά-επεξεργασίας για τον χρήστη 1 (περίπτωση προεπεξεργασίας: καμία).....	92
Σχήμα 5.36 α) Ροή ανομοιογένειας β) σωστά εντοπισμένα σημεία αλλαγής της μετά-επεξεργασίας για τον χρήστη 5 (περίπτωση προεπεξεργασίας: κανονικοποίησης)	93
Σχήμα 5.37 α) Ροή ανομοιογένειας β) σωστά εντοπισμένα σημεία αλλαγής της μετά-επεξεργασίας για τον χρήστη 7 (περίπτωση προεπεξεργασίας: κανονικοποίησης)	94
Σχήμα 5.38 α) Ροή ανομοιογένειας β) σωστά εντοπισμένα σημεία αλλαγής της μετά-επεξεργασίας για τον χρήστη 10 (περίπτωση προεπεξεργασίας: κανονικοποίησης) ..	95
Σχήμα 5.39 Αναπαράσταση των μέσων αποδόσεων όλων των συνόλων του αλγορίθμου του κυλιόμενου παραθύρου με την μετρική της διαφ. μέσων όρων (3.7) και της κανονικοποίησης στην ροή $d(t)$ που προκύπτει από την μετρική (3.10) για όλα τα σύνολα.....	96

ΚΑΤΑΛΟΓΟΣ ΠΙΝΑΚΩΝ

Πίνακας 5.1 Αποτελέσματα της 3.1 μετρικής (άθροισμα αποστάσεων) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του CrowdSignal συνόλου δεδομένων.....	63
Πίνακας 5.2 Αποτελέσματα της 3.4 μετρικής (διαφ. εξ. εσωτ. αποστάσεων) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του CrowdSignal συνόλου δεδομένων.....	64
Πίνακας 5.3 Αποτελέσματα της 3.5 μετρικής (διαφ. μέσωσ όρων) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του CrowdSignal συνόλου δεδομένων...	65
Πίνακας 5.4 Αποτελέσματα της 3.7 μετρικής (dip test) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του CrowdSignal συνόλου δεδομένων.....	66
Πίνακας 5.5 Αποτελέσματα της 3.10 μετρικής (σφάλμα ανακ. PCA) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του CrowdSignal συνόλου δεδομένων.....	67
Πίνακας 5.6 Αποτελέσματα της 3.1 μετρικής (άθροισμα αποστάσεων) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του HHAR Phone συνόλου δεδομένων.....	68
Πίνακας 5.7 Αποτελέσματα της 3.4 μετρικής (διαφ. εξ. εσωτ. αποστάσεων) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του HHAR Phone συνόλου δεδομένων.....	69
Πίνακας 5.8 Αποτελέσματα της 3.5 μετρικής (διαφ. μέσωσ όρων) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του HHAR Phone συνόλου δεδομένων..	70
Πίνακας 5.9 Αποτελέσματα της 3.7 μετρικής (dip test) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του HHAR Phone συνόλου δεδομένων.....	71
Πίνακας 5.10 Αποτελέσματα της 3.10 μετρικής (σφάλμα ανακ. PCA) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του HHAR Phone συνόλου δεδομένων.....	72
Πίνακας 5.11 Αποτελέσματα της 3.1 μετρικής (άθροισμα αποστάσεων) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του HHAR Watch συνόλου δεδομένων.....	73
Πίνακας 5.12 Αποτελέσματα της 3.4 μετρικής (διαφ. εξ. εσωτ. αποστάσεων) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του HHAR Watch συνόλου δεδομένων.....	74
Πίνακας 5.13 Αποτελέσματα της 3.5 μετρικής (διαφ. μέσωσ όρων) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του HHAR Watch συνόλου δεδομένων.....	75

Πίνακας 5.14 Αποτελέσματα της 3.7 μετρικής (dip test) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του HHAR Watch συνόλου δεδομένων .	76
Πίνακας 5.15 Αποτελέσματα της 3.10 μετρικής (σφάλμα ανακ. PCA) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του HHAR Watch συνόλου δεδομένων	77
Πίνακας 5.16 Αποτελέσματα της 3.1 μετρικής (άθροισμα αποστάσεων) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του MHealth συνόλου δεδομένων	78
Πίνακας 5.17 Αποτελέσματα της 3.4 μετρικής (διαφ. εξ. εσωτ. αποστάσεων) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του MHealth συνόλου δεδομένων	79
Πίνακας 5.18 Αποτελέσματα της 3.5 μετρικής (διαφ. μέσωσ όρων) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του MHealth συνόλου δεδομένων.....	80
Πίνακας 5.19 Αποτελέσματα της 3.7 μετρικής (dip test) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του MHealth συνόλου δεδομένων.....	81
Πίνακας 5.20 Αποτελέσματα της 3.10 μετρικής (σφάλμα ανακ. PCA) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του MHealth συνόλου δεδομένων	82
Πίνακας 5.21 Αποτελέσματα του αλγορίθμου αυξανόμενου παραθύρου για την περίπτωση του Crowsignals συνόλου δεδομένων	83
Πίνακας 5.22 Αποτελέσματα του αλγορίθμου αυξανόμενου παραθύρου για την περίπτωση του HHAR Phone συνόλου δεδομένων	84
Πίνακας 5.23 Αποτελέσματα του αλγορίθμου αυξανόμενου παραθύρου για την περίπτωση του HHAR Watch συνόλου δεδομένων	85
Πίνακας 5.24 Αποτελέσματα του αλγορίθμου αυξανόμενου παραθύρου για την περίπτωση του MHealth συνόλου δεδομένων	86
Πίνακας 5.25 Σύνολα ροών με τις καλύτερες και χειρότερες αποδόσεις για κάθε περίπτωση μετρικής και προεπ. όπου C (Crowdsignals), M (MHealth), HW (HHAR Watch), HP (HHAR Phone).....	88
Πίνακας 5.26 Μέση απόδοση σε όλα τα σύνολα για κάθε περίπτωση μετρικής και προεπεξεργασίας.....	89
Πίνακας 5.27 Σύνολα ροών με τις καλύτερες και χειρότερες αποδόσεις για τον αλγόριθμο του αυξανόμενου παραθύρου και για κάθε μέθοδο προεπεξεργασίας. όπου C (Crowdsignals), M (MHealth), HW (HHAR Watch).....	90
Πίνακας 5.28 Μέση απόδοση σε όλα τα σύνολα για τον αλγόριθμο αυξανόμενου παραθύρου για κάθε περίπτωση προεπεξεργασίας.....	91
Πίνακας 5.29 Αποτελέσματα του αλγορίθμου του κυλιόμενου παραθύρου ($s = 50$) με την μετρική της διαφ. μέσωσ όρων και της κανονικοποίησης στην ροή $d(t)$ για την περίπτωση του συνόλου δεδομένων Crowsignals	92
Πίνακας 5.30 Αποτελέσματα του αλγορίθμου του κυλιόμενου παραθύρου ($s = 350$) με την μετρική της διαφ. μέσωσ όρων και της κανονικοποίησης στην ροή $d(t)$ για την περίπτωση του συνόλου δεδομένων HHAR Phone	93

Πίνακας 5.31 Αποτελέσματα του αλγορίθμου του κυλιόμενου παραθύρου ($s = 550$) με την μετρική της διαφ. μέσω των όρων και της κανονικοποίησης στην ροή $d(t)$ για την περίπτωση του συνόλου δεδομένων HHAR Watch.....	94
Πίνακας 5.32 Αποτελέσματα του αλγορίθμου του κυλιόμενου παραθύρου ($s = 240$) με την μετρική της διαφ. μέσω των όρων και της κανονικοποίησης στην ροή $d(t)$ για την περίπτωση του συνόλου δεδομένων MHealth	95
Πίνακας 5.33 Μέση απόδοση της μεταεπεξεργασίας της ροής $d(t)$ που προκύπτει απ' την μετρική (5.10) σε όλα τα σύνολα	95
Πίνακας 5.34 Αναπαράσταση των διαφορών των επιδόσεων πριν και μετά την επεξεργασία της ροής $d(t)$ που προκύπτει από την μετρική (3.10) για κάθε προεπεξεργασία και για κάθε σύνολο ροών	96
Πίνακας 5.35 Αναπαράσταση των διαφορών των μέσων επιδόσεων πριν και μετά την επεξεργασία της ροής $d(t)$ που προκύπτει από την μετρική (3.10) για όλα τα σύνολα ροών.....	97

ΠΕΡΙΛΗΨΗ

Ιωάννης Φωτόπουλος

Μ.Δ.Ε. Τμήμα Μηχανικών Η/Υ & Πληροφορικής Πανεπιστημίου Ιωαννίνων,

Φεβρουάριος 2020

Μέθοδοι Εντοπισμού Σημείων Αλλαγής σε Πολυδιάστατες Χρονοσειρές για Ανίχνευση Μεταβολών Κινητικής Δραστηριότητας.

Επιβλέπων: Αριστείδης Λύκας

Ο αυτόματος εντοπισμός σημείων αλλαγής (unsupervised change point detection) σε πολυδιάστατες ροές δεδομένων είναι σημαντικό πρόβλημα στην ανάλυση δεδομένων που προέρχονται από συστήματα αισθητήρων (sensors). Η πλειοψηφία των μεθόδων βασίζεται στην επεξεργασία των δεδομένων εντός ενός χρονικού παραθύρου και στην εξαγωγή μετρικών που ποσοτικοποιούν την ανομοιογένεια των δεδομένων του παραθύρου.

Η εργασία καταρχήν επικεντρώνεται στην τεχνική του ολισθαίνοντος παραθύρου (sliding window) σταθερού μήκους και συγκρίνονται διάφορες μετρικές ανομοιογένειας, καθώς και εναλλακτικές μέθοδοι προεπεξεργασίας των δεδομένων (κανονικοποίηση, ανάλυση Fourier, νευρωνικοί αυτοκωδικοποιητές βαθιάς μάθησης). Επιπλέον προτείνονται και αξιολογούνται δύο νέες μετρικές, η πρώτη βασίζεται στο στατιστικό dip test για ανίχνευση μονοτροπικότητας και η δεύτερη στο σφάλμα ανακατασκευής της μεθόδου PCA. Οι παραπάνω προσεγγίσεις θεωρούν εκ των προτέρων γνωστό τον αριθμό των αλλαγών. Για να ξεπεραστεί αυτός ο περιορισμός, στη συνέχεια προτείνεται η μέθοδος του αυξανόμενου παραθύρου που εντοπίζει σε πραγματικό χρόνο τα σημεία αλλαγής. Η κύρια ιδέα είναι ότι το παράθυρο αυξάνεται κατά μήκος της ροής μέχρι ένα μέγιστο μήκος και σε κάθε βήμα ελέγχεται μονοτροπικότητα των δεδομένων (προεπεξεργασμένων ή όχι) εντός του παραθύρου.

Οι ανωτέρω μεθοδολογίες εντοπισμού αλλαγών εφαρμόστηκαν και αξιολογήθηκαν σε πολυδιάστατες ροές δεδομένων από συστήματα αισθητήρων που καταγράφουν ανθρώπινες δραστηριότητες.

EXTENDED ABSTRACT IN ENGLISH

Ioannis Fotopoulos

M. Sc. Department of Computer Science and Engineering,

University of Ioannina, February 2020

Change Point Detection Methods Evaluated On Multidimensional Timeseries for
Detecting Motion Based Activities

Supervisor: Aristidis Likas

The aim of this thesis is the study, development and implementation of methods for unsupervised detection of change points on multidimensional signal streams that are produced by a human tracking sensor system. The main categories of change point detection methods are two: in the first category the detection procedure is performed off-line, utilizing the whole data stream, while in the second category detection is performed in real-time.

The first part of the thesis is devoted to the Sliding Window method which belongs to the offline category. The technique relies on window of fixed length that slides over the data stream. At each step the data content inside a window is tested for homogeneity using several criteria. We have considered several such criteria and proposed two new ones: the first that is based on the statistical dip test and the second that is based on the PCA reconstruction error. Moreover, we have considered several data preprocessing options such normalization, Fourier Transform and deep neural autoencoders.

In the second part of the thesis, the Increasing Window method is proposed that overcomes the offline constraint and detects the change points at real time. The core idea is that the window is increasing along the stream and at each iteration, the unimodality of the window data sample is checked using the statistical dip test.

All the processes are evaluated on real multidimensional signal streams that are produced by a system of sensors that record human activities. The experimental results indicate that reasonable accuracy in the unsupervised detection of activity changes can

be obtained when the data stream is produced by a sufficiently structured system of sensors.

ΚΕΦΑΛΑΙΟ 1.

ΕΙΣΑΓΩΓΗ

- 1.1 Ορισμός Προβλήματος**
 - 1.2 Κατηγοριοποίηση Μεθόδων**
 - 1.3 Κύριες Μέθοδοι Εντοπισμού**
 - 1.4 Πεδίο Εφαρμογής**
 - 1.5 Ανοιχτά Προβλήματα**
 - 1.6 Δομή Διατριβής**
-

Στην μεταπτυχιακή διατριβή μελετήθηκαν offline και online μέθοδοι εντοπισμού σημείων αλλαγής σε πολυδιάστατες ροές δεδομένων που προέρχονται από σήματα αισθητήρων (sensor data). Σκοπός της εργασίας είναι η ανάπτυξη αλγορίθμων και τεχνικών στατιστικής αλλά και μηχανικής μάθησης για τον ακριβέστερο εντοπισμό τέτοιων σημείων. Το ερευνητικό ενδιαφέρον του προβλήματος κατά καιρούς έχει αποσπάσει την προσοχή ερευνητών από διάφορους κλάδους και τομείς όπως επεξεργασία εικονοσειρών, κειμενοσειρών (video/signal natural language processing), μετεωρολογία (climate change detection), βιοστατιστική (healthcare monitoring) και οικονομετρία (stock markets). Στην δική μας περίπτωση η εφαρμογή του θεωρητικού υπόβαθρου βρίσκει έδαφος στην επεξεργασία σημάτων που προέρχονται από αισθητήρες (sensors) οι οποίοι καταγραφούν δραστηριότητες (activities) και κινήσεις (motion) ανθρώπων.

1.1 Ορισμός Προβλήματος

Το πρόβλημα εντοπισμού σημείων αλλαγών καταστάσεων σε πολυδιάστατες ροές δεδομένων (streams) είχε διατυπωθεί πρωτίστως το 1954 [1], όπου διαπιστώθηκε η ανάγκη εύρεσης σημείων αλλαγής. Η γενική περιγραφή που μπορεί να δοθεί για αυτού το είδος προβλήματος είναι η εξής:

- Εντόπισε εκείνα τα σημεία μέσα στην ροή και κατέτμησε την ροή στα σημεία αυτά έτσι ώστε να ικανοποιείται ένα κριτήριο ομοιομορφίας σε κάθε τμήμα (segment) που προκύπτει απ' την κατάτμηση (segmentation).

Στόχος είναι να διαμορφωθούν τμήματα στην ροή έτσι ώστε να συγκλίνουν στην πραγματική κατάσταση σε περίπτωση που δίνεται. Με λίγα λόγια τα όρια (change points) κάθε τμήματος να είναι 'κοντά' στα πραγματικά σημεία αλλαγής κατάστασης.

Οπότε το πρόβλημα εντοπισμού σημείων όπου παρατηρείται αλλαγή κατάστασης, είναι ισοδύναμο με το πρόβλημα της κατάτμησης ροών. Η διαδικασία απόφασης της κατάτμησης δηλαδή ποια σημεία είναι σημεία αλλαγής βασίζεται στην εξαγωγή εκ των προτέρων στατιστικής πληροφορίας των καταστάσεων. Ο ορισμός της κατάστασης εξαρτάται απ' το είδος των δεδομένων που έχουμε στην διάθεση μας, π.χ αν οι ακολουθιακές ενδείξεις καιρικών φαινομένων (ατμοσφαιρική πίεση, θερμοκρασία) για μια χρονική περίοδο δείχνουν ηλιοφάνεια βρισκόμαστε στην κατάσταση 'ηλιοφάνειας' για το συγκεκριμένο χρονικό διάστημα. Το πρόβλημα έχει ευρέως αποτυπωθεί σε δεδομένα όπου υπάρχει χρονική διάταξη ή χρονική εξάρτηση δηλαδή σε χρονικά ακολουθιακές ροές δεδομένων και οι κύριες μέθοδοι βασίζονται σ' αυτού του είδους την ιδιότητα. Συγκεκριμένα εκμεταλλεύονται αυτή την ιδιότητα για να εντοπίσουν απότομες αλλαγές του συστήματος που επεξεργάζονται. Οπότε έχει ιδιαίτερη σημασία η επεξεργασία να σέβεται την σειρά εμφάνισης των δειγμάτων ως προς τον χρόνο. Με βάση τον ορισμό του προβλήματος φαίνεται πως το πρόβλημα ανάγεται σε πρόβλημα διακριτής βελτιστοποίησης, όπου οι υπάρχοντες εξαντλητικοί αλγόριθμοι προσπαθούν να εντοπίσουν ακριβή λύση. Στην δική μας έρευνα προσπαθήσαμε με προσεγγιστικές μεθόδους να λύσουμε το πρόβλημα όσο ακριβέστερα γίνεται χρησιμοποιώντας εργαλεία μηχανικής και στατιστικής μάθησης.

1.2 Κατηγοριοποίηση Μεθόδων

Για τον εντοπισμό των σημείων αλλαγής υπάρχουν πολλές μέθοδοι που έχουν εφαρμοσθεί σε διάφορων ειδών προβλήματα, (Audio Speech Recognition)[2], (Health Monitoring) [3], με διαφορετικές θεωρητικές και πρακτικές προσεγγίσεις για κάθε περίπτωση. Μια κύρια διαφοροποίηση μεταξύ των αλγορίθμων που επιλύουν το πρόβλημα γίνεται με βάση τον τρόπο επεξεργασίας των δεδομένων. Πιο συγκεκριμένα δύο κατηγορίες υπάρχουν με βάση αυτό το κριτήριο.

- Offline επεξεργασία δηλαδή ο αλγόριθμος εντοπισμού εφαρμόζεται εφόσον συλλεχθούν τα δείγματα της ροής (offline detection) που περιγράφουν ένα φαινόμενο για συγκεκριμένο χρονικό διάστημα.
- Online επεξεργασία όπου γίνεται εξαγωγή των σημείων αλλαγής σε πραγματικό χρόνο (online detection). Τέτοιου είδους αλγόριθμοι έχουν μικρότερη υπολογιστική πολυπλοκότητα και εντοπίζουν σε πραγματικό χρόνο τυχόν σημεία αλλαγής καθώς εισέρχονται στον αλγόριθμο δείγματα της χρονοσειράς.

Αλγόριθμοι που εφαρμόζονται στην περίπτωση της online διαδικασίας, συνήθως είναι προσεγγιστικοί και δεν ψάχνουν εξαντλητικά την ακριβή λύση. Μια σημαντική διαφοροποίηση των μεθόδων βασίζεται στην πληροφορία η οποία είναι διαθέσιμη για τον αριθμό και την θέση των πραγματικών σημείων αλλαγής μέσα στο δείγμα. Στην περίπτωση που υπάρχει αυτή η βάση αλήθειας για το πλήθος και την θέση των πραγματικών σημείων αλλαγής K , μπορεί να αναπτυχθεί ένα σύστημα επιβλεπόμενης μάθησης (supervised learning) που θα εντοπίζει τα σημεία εκμεταλλευόμενο την εκ των προτέρων γνώση. Οπότε στην περίπτωση που γνωρίζουμε ποια είναι τα πραγματικά σημεία αλλαγής μπορούμε να κατασκευάσουμε έναν δυαδικό ταξινομητή (binary classifier) όπως μηχανές διανυσμάτων υποστήριξης (SVM) [4] που θα προβλέπει αν ένα σημείο είναι ή όχι σημείο αλλαγής. Λόγω του ότι τα θετικά σημεία (αλλαγής) συνήθως είναι λίγα στο πλήθος μπορεί να υπάρξει ανισορροπία κλάσεων (class imbalance) μεταξύ θετικών και αρνητικών δειγμάτων κάτι που πρέπει να ληφθεί υπόψιν για να αντιμετωπιστεί με κατάλληλους τρόπους δειγματοληψίας. Στην περίπτωση που δίνεται η ετικέτα της κατάστασης στην οποία ανήκει ένα δείγμα κάθε

χρονική στιγμή το πρόβλημα ανάγεται σε πρόβλημα ταξινόμησης πολλών κλάσεων (multilabel classification) όπου σημεία αλλαγής είναι εκείνα τα σημεία που γίνεται μετάβαση από μια κατάσταση σε μία άλλη και αυτό μπορεί να το εντοπίσει ένας ισχυρός ταξινομητής όπως SVM, Deep Neural Networks, Convolutional Neural Networks, Naïve Bayes. Η επιβλεπόμενη μέθοδος εντοπισμού των σημείων αλλαγής δεν στοχεύει να ανακαλύψει κρυφές ιδιότητες των δεδομένων, αλλά εκμεταλλεύεται την βάση αλήθειας (ground truth) που παρέχεται και δίνει αυστηρή λύση στο πρόβλημα εντοπισμού όταν το σφάλμα ταξινόμησης (categorical cross entropy loss) γίνει πολύ μικρό στο σύνολο εκπαίδευσης και ελέγχου για την αποφυγή υπερεκπαίδευσης (overfitting) και υποεκπαίδευσης (underfitting). Αντιθέτως η μη επιβλεπόμενη (unsupervised) διαδικασία εντοπισμού προσπαθεί να εξάγει στατιστική πληροφορία απ' τα δεδομένα ώστε να αποφανθεί, κάτι το οποίο προφανώς είναι σχετικά πιο δύσκολη διαδικασία. Όπως αναφέρθηκε το πρόβλημα μπορεί να μεταφραστεί σε πρόβλημα διακριτής βελτιστοποίησης ελαχιστοποιώντας ένα κριτήριο ομοιομορφίας βρίσκοντας ακριβή λύση. Αυτή η προσέγγιση προφανώς γίνεται offline και είναι ένα είδος μη επιβλεπόμενης διαδικασίας. Στην παρούσα εργασία ασχοληθήκαμε με προσεγγιστικές (approximations) μη επιβλεπόμενες offline και online μεθόδους. Τα δεδομένα τα οποία επεξεργαστήκαμε παρείχαν επιπλέον το πλήθος και την θέση των πραγματικών σημείων αλλαγής K κάτι που μας διευκόλυνε στην αξιολόγηση των μεθόδων που αναπτύξαμε. Η πληροφορία αυτή δεν χρησιμοποιείται απ' τους αλγόριθμους κατάτμησης παρά μόνο στην φάση της αξιολόγησης.

1.3 Κύριες Μέθοδοι Εντοπισμού

Στο πλαίσιο εύρεσης της κατάλληλης προσεγγιστικής μεθόδου εντοπισμού σημείων αλλαγής δοκιμάσαμε διάφορες τεχνικές που συνδύαζαν προεπεξεργασία των δεδομένων με σκοπό την εξαγωγή χαρακτηριστικών (feature extraction) με την εφαρμογή κάποιων μετρικών ομοιογένειας καθώς και του στατιστικού τεστ dip test [5]. Οι δύο τεχνικές εντοπισμού που αναπτύξαμε βασίζονται στον αλγόριθμο του κυλιόμενου παραθύρου σταθερού μήκους $Win_{sliding}$ (Window Sliding) και στον αλγόριθμο αυξανόμενου παραθύρου Win_{inc} (Increasing Window). Οι δύο προσεγγίσεις διαφέρουν ως προς τον τρόπο επεξεργασίας και τον τρόπο εξαγωγής των

υποψήφια σημείων αλλαγής \hat{K} . Η κύρια μεθοδολογία του αλγορίθμου του κυλιόμενου παραθύρου (Sliding Window) βασίζεται στην τμηματική επεξεργασία της πολυδιάστατης ροής $\{y_i\}_i^T$ όπου επεξεργάζεται κάθε τμήμα $[a, b]$ ξεχωριστά σε κάθε επανάληψη.

$$Win_{sliding}(y_{a..b}) \quad (1.1)$$

όπου $y_i \in \mathbb{R}^d, i = 0 \dots T, a = 0, \dots T - s, b = s \dots T, s = b - a$ μήκος, $Win_{sliding}$ και a, b αριστερό και δεξί άκρο του παραθύρου $Win_{sliding}$ αντίστοιχα.

Περιγραφικά μπορούμε να πούμε πως η συνάρτηση $Win_{sliding}$ ολισθαίνει πάνω στην πολυδιάστατη ροή και εφαρμόζει κάποια μετρική ομοιογένειας ή το στατιστικό τεστ dip test και κατασκευάζει μια ροή ανομοιογένειας με βάση την οποία εξάγουμε το σύνολο των υποψήφια σημείων αλλαγής \hat{K} για διάφορες τιμές του μεγέθους του παραθύρου $size$, το οποίο ορίζεται αναγκαστικά απ' τον χρήστη.

$$d(t) = Win_{sliding}(y_{a..b}) \quad (1.2)$$

όπου $t = a + \frac{s}{2}$ κέντρο του παραθύρου $Win_{sliding}$.

Το υποψήφια σημεία είναι εκείνα τα σημεία για τα οποία η αντίστοιχη τιμή της ροής ανομοιογένειας $d(t)$ είναι μεγαλύτερη ενός κατωφλίου μ_0 . Αμέσως προκύπτει το ερώτημα ποιο θα είναι το κατώφλι το οποίο θα δώσει ο χρήστης. Ο ορισμός του κατωφλίου απ' τον χρήστη θα είχε νόημα αν η διαδικασία γινόταν online. Στις περιπτώσεις των δειγμάτων που εξετάσαμε θεωρήσαμε την διαδικασία offline. Επιπλέον για τον υπολογισμό της ροής ανομοιογένειας $d(t)$ χρησιμοποιήθηκε το σφάλμα ανακατασκευής της μεθόδου κυρίων συνιστωσών (PCA) των ανακατασκευασμένων δειγμάτων το οποίο έδωσε αξιόλογα αποτελέσματα. Πρέπει να σημειωθεί ότι η τεχνική της ανακατασκευής της PCA δεν έχει εφαρμοσθεί ως κριτήριο για τον εντοπισμό σημείων αλλαγής στην βιβλιογραφία. Στα δείγματα των πειραμάτων είχαμε την θέση και το πλήθος των πραγματικών σημείων K κάτι που μας διευκόλυνε στην αξιολόγηση και των δύο μεθόδων. Οπότε για να βρούμε τα υποψήφια σημεία \hat{K} θεωρούμε ότι το πλήθος τους είναι σταθερό, έπειτα εντοπίζουμε τα $|\hat{K}|$ μεγαλύτερα σημεία ως προς την $d(t)$, όπου $|\hat{K}| \geq |K|$ και διερευνούμε κατά πόσο αυτά τα σημεία είναι μακριά απ' τα πραγματικά με ένα σφάλμα ανοχής περίπου της τάξης των 3.0

δευτερολέπτων των υποψηφίων \hat{t} απ' τα πραγματικά t^* . Όπως αντιλαμβάνεται κάποιος η μέθοδος του κυλιόμενου παραθύρου έχει κάποια μειονεκτήματα που αφορούν την επιλογή υπερπαραμέτρων. Αυτό το πρόβλημα προσπαθούμε να λύσουμε με την μέθοδο του αυξανόμενου παραθύρου (Increasing Window) όπου υπολογίζουμε ένα κριτήριο πολυτροπικότητας (dip test) σε παράθυρο το οποίο αυξάνεται και εντοπίζουμε εκείνο το σημείο αλλαγής στο δείγμα εντός του παραθύρου το οποίο δημιουργεί την καλύτερη κατάτμηση στο παράθυρο ικανοποιώντας ένα κριτήριο ομαδοποίησης. Ο αλγόριθμος θεωρεί αυστηρά αυτό το σημείο υποψήφιο σημείο αλλαγής οπότε δεν χρειάζεται να επεξεργαστεί ολόκληρη την χρονοσειρά για να αποφανθεί σε αντίθεση με τον αλγόριθμο του κυλιόμενου παραθύρου *WinSliding* όπως θα δούμε παρακάτω (Κεφ. 4). Σε επόμενη ενότητα (Κεφ. 3) θα συζητήσουμε όλες τις μετρικές που χρησιμοποιήθηκαν και την διαδικασία εφαρμογής του στατιστικού dip test στο κυλιόμενο παράθυρο.

Το ζητούμενο είναι πόσο κατάλληλα είναι αυτά τα μοντέλα για τον ακριβέστερο εντοπισμό των σημείων αλλαγής και αν είναι υπάρχει καλή επιτυχία στην ακρίβεια πόσο κατάλληλο είναι το μοντέλο για online υπολογισμούς. Τα παραπάνω ερωτήματα προσπαθούμε να καλύψουμε σ' αυτή την εργασία εφαρμόζοντας την κύρια ιδέα σε δείγματα σημάτων που εκπέμπονται από αισθητήρες (gyroscope, accelerometer, magnetometer) οι οποίοι καταγράφουν χαμηλού επιπέδου ανθρώπινες δραστηριότητες που βασίζονται κυρίως σε αλλαγές κίνησης, τοποθεσίας και κατεύθυνσης στον χώρο. Η διαδικασία είναι μη επιβλεπόμενη, γρήγορη και προσεγγιστική, και προσπαθεί να κατατμήσει την πολυδιάστατη ροή σημάτων όσο το δυνατόν πιο ακριβέστερα.

Όπως θα δούμε σε επόμενη ενότητα (Κεφ. 5) η μέθοδος του κυλιόμενου παραθύρου μπορεί να συνδυαστεί με την εξαγωγή υψηλού επιπέδου χαρακτηριστικών μέσω της μεθόδου αυτοαποκωδικοποιητών (Autoencoders) και μετασχηματισμών Φουριέρ (Discrete Fourier Transformations). Γενικά σε πολλά προβλήματα μηχανικής μάθησης το στάδιο της προεπεξεργασίας δεδομένων μπορεί να συμβάλει θετικά σε καλύτερη απόδοση του μοντέλου. Τα δείγματα που προκύπτουν απ' την τεχνητή ανακατασκευή του χαρακτηριστικού χώρου αντικαθιστούν τα αρχικά δείγματα της ροής και εφαρμόζεται ένα απ' τα μοντέλα που εντοπίζουν τα σημεία αλλαγής όπως αναφέρθηκε πιο πριν. Επίσης έχουν εφαρμοσθεί και οι μετασχηματισμοί Φουριέρ (Discret Fourier Transformations) στα ανακατασκευασμένα δείγματα για τον υπολογισμό του μέτρου της ισχύς κάθε μονοδιάστατου σήματος όπως και η διαδικασία κανονικοποίησης σε κάθε μονοδιάστατο σήμα.

1.4 Πεδίο Εφαρμογής

Πρακτικό ενδιαφέρον των μεθόδων εντοπισμού σημείων αλλαγής σε πολυδιάστατα σήματα βρίσκει έδαφος σε HAR συστήματα (Human Activity Recognition) που βασίζονται σε ένα σύνολο αισθητήρων. Πλέον σ' αυτού του είδους συστήματα έχουν ενσωματωθεί εργαλεία και μέθοδοι από τον χώρο της στατιστικής μηχανικής και βαθιάς μάθησης [6] που προσπαθούν είτε να εξάγουν υψηλού επιπέδου χαρακτηριστικά είτε να εντοπίσουν τα σημεία αλλαγής με επίβλεψη ή χωρίς επίβλεψη όπως αναφέρθηκε.

Για την περιγραφή των δραστηριοτήτων χρησιμοποιούνται αισθητήρες που καταγράφουν χαμηλού επιπέδου δραστηριότητες (low level activities) που αφορούν την κίνηση ενός ανθρώπου στον χώρο (body-worn sensors). Αυτού του είδους οι αισθητήρες είναι οι πιο κατάλληλοι για να περιγράψουν τις δραστηριότητες ανθρώπων και συνήθως βρίσκονται σε έξυπνες συσκευές τηλεφώνων και ρολογιών χειριού (smartphones, handwatches). Πιο συγκεκριμένα υπάρχουν (βλ. Σχήμα 1.1) αισθητήρες που καταγράφουν την ταχύτητα ή την επιτάχυνση στον χώρο, όπως το επιταχυνσιόμετρο (accelerometer), την μετατόπιση στον χώρο όπως το γυροσκόπιο (gyroscope) και τις βαρυτικές δυνάμεις στον χώρο το μαγνητόμετρο (magnetometer). Καθένα απ' αυτά τα χαρακτηριστικά περιγράφονται στον τρισδιάστατο χώρο οπότε κάθε αισθητήρας εκπέμπει ένα τρισδιάστατο σήμα σε κάθε χρονική στιγμή.

Στην παρούσα εργασία ασχοληθήκαμε με δείγματα που περιγράφουν τις δραστηριότητες διάφορων χρηστών όπως περπάτημα, τρέξιμο, ποδηλασία, χρήση μέσων μαζικής μεταφοράς, ανεβοκατέβασμα σκαλιών, όρθια στάση, καθιστική στάση. Οπότε οι μέθοδοι που αναπτύξαμε προσπαθούν να εντοπίσουν σημεία αλλαγής δραστηριοτήτων.

Για λόγους αξιολόγησης των μεθόδων επεξεργαστήκαμε δεδομένα με ετικέτα δηλαδή ο χρήστης κάθε χρονική στιγμή δίνει την πληροφορία της δραστηριότητας που εκτελεί (ground truth). Τα πειράματα των ανθρώπων διαρκούν από 20 έως 45 λεπτά.



Σχήμα 1.1 Δείγμα σημάτων 3 αισθητήρων που καταγράφουν ανθρώπινες δραστηριότητες χαμηλού επιπέδου.

1.5 Ανοιχτά Προβλήματα

Παρότι έχουν προταθεί και αναπτυχθεί αρκετά εργαλεία για HAR συστήματα υπάρχουν αρκετά ζητήματα που δεν έχουν λυθεί. Προφανώς είναι ένα πρόβλημα που αποκτά ολοένα περισσότερο ερευνητικό ενδιαφέρον αλλά και πρακτικό διότι αφορά την καθημερινότητα των ανθρώπων, οπότε γίνεται όλο και πιο αναγκαία η επεξεργασία των δεδομένων που καταγράφουν τις δραστηριότητες.

A. Ανάπτυξη πιο ακριβέστερων μη επιβλεπόμενων μοντέλων.

Προφανώς είναι πολυτέλεια να έχουμε ετικέτες κάθε χρονική στιγμή. Δεν είναι εφικτό να συλλεχθούν ετικέτες για τεράστιο αριθμό δειγμάτων. Οπότε προκύπτει άμεσα η ανάγκη εύρεσης αλγορίθμων που να εντοπίζουν όσο πιο ακριβέστερα σημεία αλλαγής, οι οποίοι θα είναι ικανοί να εκμεταλλεύονται την στατιστική πληροφορία των ροών και να ανακαλύπτουν πρότυπα και μοτίβα.

B. Ανάπτυξη πιο γρήγορων μοντέλων για online εντοπισμό αλλαγών (online detection).

Είναι το δεύτερο ζήτημα που προκύπτει λόγω του ότι ένας τέτοιος αλγόριθμος μπορεί να χρησιμοποιηθεί σε μια φορητή συσκευή θα ήταν επιτακτικό να υπάρξουν χαμηλού

υπολογιστικού κόστους μέθοδοι λόγω περιορισμένων πόρων. Προφανώς η χαμηλή καθυστέρηση εντοπισμού θα βοηθούσε στην έγκαιρη ερμηνεία ενός φαινομένου απ' τον αναλυτή.

Γ. Ανίχνευση περιττών αισθητήρων.

Υπάρχει περίπτωση να υπάρχουν περιττά σήματα τα οποία να δυσκολεύουν τον εντοπισμό των σημείων αλλαγής και να μπερδεύουν την μέθοδο. Αυτό βέβαια εξαρτάται με το φαινόμενο και το πρόβλημα που καλούμαστε να αντιμετωπίσουμε. Για παράδειγμα αν η μέθοδος προσπαθεί να εντοπίσει χαμηλού επιπέδου δραστηριότητες και λαμβάνει πολλά σήματα από ίδιους αισθητήρες αλλά από διαφορετικές συσκευές (Smartwatch, Smartphone) είναι κάτι το οποίο προκαλεί μεγάλη δυσκολία και υψηλή πολυπλοκότητα συστήματος. Βέβαια αυτό μπορεί να συμβεί και σε περιπτώσεις αλλοίωσης του σήματος που εκπέμπεται από μία συσκευή (noisy signals).

Δ. Υψηλή απόδοση σε περιπτώσεις έλλειψης αισθητήρων.

Αντιθέτως σε κάποια πειράματα υπάρχουν ένας η δύο αισθητήρες που περιγράφουν τις δραστηριότητες κάτι το οποίο μπορεί να μην βοηθάει στον εντοπισμό των σημείων αλλαγής. Θα ήταν χρήσιμο να υλοποιηθούν κατάλληλες τεχνικές προεπεξεργασίας των σημάτων για την εξαγωγή χρήσιμων και σημασιολογικών χαρακτηριστικών που θα συνέβαλαν στην αύξηση των επιδόσεων.

1.6 Δομή Διατριβής

Στο Κεφ. 2 γίνεται περιληπτική αναφορά των υπαρχόντων αλγορίθμων και μεθόδων. Επίσης στο Κεφ. 2 αναφέρονται οι συναρτήσεις κόστους που υπολογίζουν την ομοιομορφία μεταξύ των συγκρινόμενων τμημάτων και η εφαρμογή τους στις κατηγορίες των αλγορίθμων που αναφέρονται.

Στο Κεφ. 3 γίνεται εκτενής αναφορά των μετρικών και των κριτηρίων κατάτμησης της ροής που εφαρμόστηκαν στον αλγόριθμο του κυλιόμενου παραθύρου (Win Sliding). Επίσης σ' αυτό το κεφάλαιο, αναφέρονται τα μειονεκτήματα και πλεονεκτήματα της μεθόδου.

Στο Κεφ. 4 παρουσιάζουμε τον αλγόριθμο αυξανόμενου παραθύρου ο οποίος λειτουργεί online προσπαθώντας να λύσουμε προβλήματα επιλογής υπερπαραμέτρων και ταχύτητας υπολογισμών.

Στο Κεφ. 5 αναφέρονται οι προεπεξεργασίες και τα αποτελέσματα των δύο μεθόδων σε σύνολα δεδομένων που σχετίζονται με τις δραστηριότητες διαφόρων χρηστών.

Τέλος τα συμπεράσματα της εργασίας παρουσιάζονται στο Κεφ. 6.

ΚΕΦΑΛΑΙΟ 2.

ΣΤΑΤΙΣΤΙΚΟ-ΑΛΓΟΡΙΘΜΙΚΟ ΥΠΟΒΑΘΡΟ

2.1 Συναρτήσεις Κόστους

2.2 Αλγόριθμοι Εντοπισμού Σημείων Αλλαγής

Σ' αυτό το κεφάλαιο θα γίνει περιληπτική ανασκόπηση των μοντέλων και μεθόδων που έχουν μελετηθεί για το πρόβλημα εύρεσης σημείων αλλαγής [28]. Οι πρώτες προσεγγίσεις [1] στον πρόβλημα βασίζονται στον ορισμό του προβλήματος που δόθηκε στην υποενότητα (1.1), και αφορούν την κατάτμηση της πολυδιάστατης ροής $\{y_i\}_i^T, y_i \in \mathbb{R}^d$ προκειμένου να ελαχιστοποιηθεί η αντικειμενική συνάρτηση κόστους:

$$C(\hat{K}, y) := \sum_{k=0}^{\hat{K}} c(y_{\hat{t}_k \dots \hat{t}_{k+1}}) \quad (2.1)$$

όπου $\hat{K} = \{\hat{t}_1, \hat{t}_2, \dots, \hat{t}_{\hat{K}}\}$ σύνολο θέσεων των εκτιμώμενων σημείων αλλαγής και $\hat{t}_0 = 0, \hat{t}_{\hat{K}+1} = T$.

Θεωρούμε την $y = \{y_0 \dots y_T\}, y_i \in \mathbb{R}^d, (d \geq 1)$, πολυδιάστατη ροή μήκους T . Η συνάρτηση κόστους $c(y_{\hat{t}_k \dots \hat{t}_{k+1}}), k = 0, \dots, \hat{K}$ χαρακτηρίζει την ομοιομορφία ενός τμήματος $[\hat{t}_k \dots \hat{t}_{k+1}]$. Προφανώς αυτό το κριτήριο πρέπει να ελαχιστοποιείται σε κάθε τμήμα, για να εκτιμηθεί η κατάλληλη κατάτμηση δηλαδή να εντοπιστούν εκείνα τα τμήματα $[\hat{t}_k \dots \hat{t}_{k+1}]$ στην ροή όπου τα δείγματα τους είναι όσο το δυνατόν ομοιόμορφα

μεταξύ τους. Γενικά το πρόβλημα χωρίζεται σε δύο περιπτώσεις ανάλογα με το εάν το πλήθος $|\hat{K}|$ των υποψήφιων σημείων αλλαγής που θέλουμε να εντοπίσει ο αλγόριθμος δίνεται ως δεδομένο. Εάν δίνεται η πληροφορία χρησιμοποιείται ως κριτήριο τερματισμού της κατάτμησης και δίνεται ως είσοδος στους αλγόριθμους. Αντιθέτως υπάρχουν και αλγόριθμοι που εκτιμούν τον αριθμό των υποψήφιων σημείων αλλαγής \hat{K} θεωρώντας τροποποιημένη την αντικειμενική συνάρτηση κόστους (2.1) προσθέτοντας έναν όρο εξομάλυνσης. Σ' αυτή την υποενότητα (2.1) θα περιγράψουμε κάποιες συναρτήσεις κόστους και τα μοντέλα που έχουν προταθεί στην βιβλιογραφία [28]. Επίσης θα αναφερθούν οι εξαντλητικοί αλγόριθμοι που βρίσκουν την ακριβή λύση για δεδομένο $|\hat{K}|$ και συνάρτηση κόστους c , αλλά και οι προσεγγιστικοί πάνω στους οποίους έχουμε στηρίξει τις μεθόδους μας όπως και τα πλεονεκτήματα και μειονεκτήματα ως προς την πολυπλοκότητα και την επίδοση τους.

2.1 Συναρτήσεις Κόστους

Για να αναπτυχθεί ένα ισχυρό σύστημα εντοπισμού σημείων αλλαγής [28] είναι αναγκαίος ο συνδυασμός του κατάλληλου αλγορίθμου και της συνάρτησης κόστους. Η επιλογή της κατάλληλης συνάρτησης που θα περιγράφει την ομοιογένεια κάθε τμήματος (segment), δηλαδή πόσο 'καλά' ταιριάζουν τα δεδομένα (fitting) του τμήματος στο μοντέλο, καθορίζει σημαντικά την απόδοση. Όπως έχει αναφερθεί το πρόβλημα εντοπισμού σημείων αλλαγής μπορεί να μεταφραστεί ως ένα πρόβλημα διακριτής βελτιστοποίησης.

- Στην πρώτη περίπτωση όπου δίνεται το πλήθος των σημείων \hat{K} που θέλουμε να εντοπιστούν.

$$\min_{|\hat{K}|=constant} C(\hat{K}, y) \quad (2.2)$$

- Γενικά στο πρόβλημα μπορεί να μην δίνεται το πλήθος των υποψήφιων σημείων $|\hat{K}|$. Μία προσέγγιση είναι η προσθήκη ενός όρου εξομάλυνσης $pen(\hat{K})$ στην (2.2) σχέση που περιγράφει πόσο πολύπλοκη θα είναι η κατάτμηση \hat{K} . Ορίζοντας μεγάλες τιμές του όρου

εξομάλυνσης $pen(\hat{K})$ επιτρέπουμε στο μοντέλο να εντοπίζει τις πιο σημαντικές αλλαγές.

$$\min_{\hat{K}} [C(\hat{K}, y) + pen(\hat{K})] \quad (2.3)$$

Ο ορισμός (2.3) χρησιμοποιείται για την εκτίμηση του πλήθους των υποψήφιων σημείων \hat{K} . Στο πρώτο σκέλος της εργασίας (Κεφ. 3) όπου ασχοληθήκαμε με την προσεγγιστική πλευρά του προβλήματος δεν μας επιτρεπόταν τόσο εύκολα να αποφανθούμε για το πρόβλημα (2.3) αν και είναι ένα ανοιχτό πρόβλημα προς περαιτέρω συζήτηση. Στο Κεφ. 4 ο αλγόριθμος του αυξανόμενου παραθύρου είναι πιο ισχυρός και μπορεί να μας δώσει και το πλήθος των υποψήφιων σημείων \hat{K} όπως θα δούμε παρακάτω. Τμήματα που έχουν μικρή συνάρτηση κόστους είναι ομοιογενή και πιθανόν να μην περιέχουν σημείο αλλαγής.

Παρακάτω θα αναφερθούν τα γενικά μοντέλα και οι αντίστοιχες συναρτήσεις κόστους που χρησιμοποιούνται ευρέως για το πρόβλημα και χωρίζονται σε δύο κατηγορίες τα παραμετρικά μοντέλα και τα μη παραμετρικά.

2.1.1 Παραμετρικά Μοντέλα

Αυτού του είδους τα μοντέλα είναι το θεμέλιο για την κατασκευή μεθόδων εντοπισμού σημείων αλλαγής και βασίζονται στην εκτίμηση των απότομων αλλαγών των διανυσματικών παραμέτρων των μοντέλων που περιγράφουν στατιστικά τα δείγματα των υπακολουθιών των σημάτων $y_{\hat{t}_k \dots \hat{t}_{k+1}}$ $0 \leq \hat{t}_k < \hat{t}_{k+1} < T$.

2.1.1.1 Εκτίμηση Μέγιστης Πιθανοφάνειας (ML Estimation)

Οι διαδικασίες εκτίμησης μέγιστης πιθανοφάνειας είναι ευρέως γνωστές και καλύπτουν σημαντικό αριθμό περιπτώσεων. Ο ορισμός της κατάλληλης συνάρτησης πυκνότητας πιθανότητας (pdf) παίζει σημαντικό ρόλο για την εκτίμηση των σημείων αλλαγής $\hat{t}_1, \hat{t}_2, \dots, \hat{t}_R$ που ορίζουν τα ομοιογενή τμήματα. Οπότε θεωρούμε γενικά ότι τα δείγματα είναι τυχαία και ανεξάρτητα και ακολουθούν μια κατανομή.

$$y_i \sim f(\cdot | \theta_k) \quad (2.4)$$

όπου $f(\cdot | \theta_k)$ είναι η συνάρτηση πυκνότητας πιθανότητας παραμετροποιημένη απ' το διάνυσμα παραμέτρων θ_k για κάθε k -οστο τμήμα (segment) που προκύπτει στην ροή σημάτων. Η πιο γνωστή και ευρέως χρησιμοποιούμενη κατανομή είναι η κανονική (Gaussian Distribution) με παραμέτρους $\theta_k = \{\mu_k, \Sigma_k\}$ τις οποίες υπολογίζουμε για κάθε τμήμα $[\hat{t}_k, \hat{t}_{k+1}]$. Οι διαφορετικές παράμετροι θ_k μπορούν να αποτυπώσουν τις αλλαγές των μέσων και διακυμάνσεων στην κατανομή των δειγμάτων οπότε μπορούμε να εκτιμήσουμε τις θέσεις των σημείων ώστε να μεγιστοποιείται η λογαριθμική πιθανοφάνεια.

$$c_{LogML}(y_{\hat{t}_k \dots \hat{t}_{k+1}}) = \max_{\theta_k} \sum_{i=\hat{t}_{k+1}}^{\hat{t}_k} \log(f(y_i | \theta_k)) \quad (2.5)$$

$$0 \leq \hat{t}_k < \hat{t}_{k+1} < T, k = 0, \dots, |\hat{K}| + 1.$$

Ο συνδυασμός του μοντέλου (2.4) και της συνάρτησης κόστους (2.5) έχει χρησιμοποιηθεί σε αρκετές μεθόδους στην βιβλιογραφία [9] [10], είναι φανερό ότι καλύπτει την γενική των περιπτώσεων. Η σχέση (2.5) με συνάρτηση πυκνότητας πιθανότητας την κανονική $f(y_i | \theta_k) \sim N(\mu = \bar{y}_k, \Sigma = \hat{\Sigma}_k)$ είναι τυπικό μοντέλο εντοπισμού απότομων αλλαγών και μετατοπίσεων των μέσων και διακυμάνσεων των τμημάτων. Πρέπει να αναφερθεί ότι μοντέλα που βασίζονται στις μετατοπίσεις ως προς το μέσο (mean shifts), δηλαδή θεωρώντας ότι τα δεδομένα είναι τυχαία και ανεξάρτητα και ακολουθούν κανονική κατανομή με σταθερή διακύμανση, είναι τα πιο γνωστά και ευρέως εφαρμοσμένα. Συγκεκριμένα το άθροισμα των τετραγωνικών ή απόλυτων διαφορών των δειγμάτων ενός τμήματος $y_{\hat{t}_k \dots \hat{t}_{k+1}}$ $0 \leq \hat{t}_k < \hat{t}_{k+1} < T$ από το εμπειρικό μέσο $\bar{y}_{\hat{t}_k \dots \hat{t}_{k+1}}$ είναι μια υποπερίπτωση του πιθανοτικού μοντέλου (2.4) που προσπαθεί να αποτυπώσει της μεταβολές των μέσων. Οπότε προκύπτει ένα κριτήριο ομοιομορφίας ενός τμήματος που μπορεί να περιγραφεί συναρτήσει των τετραγωνικών ή απόλυτων διαφορών των δειγμάτων απ' τον στατιστικό μέσο. Σημσιολογικά δείγματα που 'μοιάζουν' είναι λογικό να βρίσκονται 'κοντά' στην αντιπροσωπευτική τιμή του τμήματος δηλαδή τον μέσο.

$$c_{L\rho}(y_{\hat{t}_k \dots \hat{t}_{k+1}}) = \sum_{i=\hat{t}_k}^{\hat{t}_{k+1}} \|y_i - \bar{y}_{\hat{t}_k \dots \hat{t}_{k+1}}\|_\rho \quad (2.6)$$

Προφανώς μια επέκταση της συνάρτησης κόστους (2.6) είναι η μοντελοποίηση των αλλαγών της δεύτερης τάξης στατιστικών τιμών όπως της διακύμανσης των τυχαίων και ανεξάρτητων δειγμάτων που πάλι μπορούμε να πούμε πώς αποτελεί υποπερίπτωση του (2.4) αλλά όχι μόνο για την κανονική κατανομή αλλά και για άλλες εκθετικές [11].

Η συνάρτηση κόστους που προκύπτει είναι η εξής:

$$\begin{aligned} c_\Sigma(y_{\hat{t}_k \dots \hat{t}_{k+1}}) &= (\hat{t}_{k+1} - \hat{t}_k) * \log \det \hat{\Sigma}_{\hat{t}_k \dots \hat{t}_{k+1}} \\ &+ \sum_{i=\hat{t}_k}^{\hat{t}_{k+1}} (y_i - \bar{y}_{\hat{t}_k \dots \hat{t}_{k+1}})' \hat{\Sigma}_{\hat{t}_k \dots \hat{t}_{k+1}}^{-1} (y_i - \bar{y}_{\hat{t}_k \dots \hat{t}_{k+1}}) \end{aligned} \quad (2.7)$$

Όπου $\hat{\Sigma}_{\hat{t}_k \dots \hat{t}_{k+1}}$ είναι ο εμπειρικός πίνακας των συνδιακυμάνσεων της υπακολουθίας $y_{\hat{t}_k \dots \hat{t}_{k+1}}$.

Στην βιβλιογραφία [28] αναφέρεται ότι μέθοδοι εντοπισμού σημείων αλλαγής έχουν εφαρμοσθεί σε δεδομένα μετρήσεων γεγονότων (π.χ μετρήσεις πωλήσεων) τα οποία περιγράφονται από Poisson κατανομή με σταθερό ρυθμό άφιξης. Η συνάρτηση κόστους που προκύπτει για αυτή την μοντελοποίηση είναι η εξής

$$c_{Poisson}(y_{\hat{t}_k \dots \hat{t}_{k+1}}) = -(\hat{t}_{k+1} - \hat{t}_k) \bar{y}_{\hat{t}_k \dots \hat{t}_{k+1}} \log \bar{y}_{\hat{t}_k \dots \hat{t}_{k+1}} \quad (2.8)$$

Μια παρόμοια συνάρτηση κόστους με την $c_{L\rho}$ (2.6) η οποία βασίζεται στην Mahalanobis νόρμα εντοπίζει τις αλλαγές του μέσου του γραμμικού μετασχηματισμού των δεδομένων μέσω του πίνακα $M \in \mathbb{R}^{d \times d}$ συμμετρικό και θετικά ημιορισμένο όπου d διάσταση σημάτων. Στην περίπτωση μας είναι ο αντίστροφος πίνακας συνδιακύμανσης $\hat{\Sigma}_{\hat{t}_k \dots \hat{t}_{k+1}}^{-1}$. Ο τύπος της Mahalanobis νόρμας είναι ο εξής

$$\|y_i\|_M = y_i' M y_i \quad (2.9)$$

Η συνάρτηση κόστους που παραμετροποιείται μέσω της Mahalanobis μετρικής είναι η εξής:

$$c_M(y_{\hat{t}_k \dots \hat{t}_{k+1}}) = \sum_{i=a}^b \|y_i - \bar{y}_{\hat{t}_k \dots \hat{t}_{k+1}}\|_M \quad (2.10)$$

Ο υπολογισμός της νόρμας (2.9) είναι ισοδύναμος με την εφαρμογή γραμμικών μετασχηματισμών στα δείγματα οπότε μετά την αποσύνθεση του πίνακα $M = \hat{\Sigma}_{\hat{t}_k \dots \hat{t}_{k+1}}^{-1} = U'U$ προκύπτει η τροποποιημένη συνάρτηση κόστους:

$$c_M(y_{\hat{t}_k \dots \hat{t}_{k+1}}) = \sum_{i=a}^b \|Uy_i - U\bar{y}_{\hat{t}_k \dots \hat{t}_{k+1}}\|_2 \quad (2.11)$$

Οι αλλαγές του μέσου που θα εντοπιστούν στο μετασχηματισμένο σήμα Uy αντιστοιχίζονται στις πραγματικές αλλαγές του αρχικού σήματος y . Γενικά μπορούν να εφαρμοσθούν και άλλες μετατροπές στα αρχικά σήματα όπως γραμμική μείωση διάστασης μέσω της μεθόδου των κυρίων συνιστωσών (PCA) κάτι το οποίο χρησιμοποιήθηκε στην παρούσα εργασία. Γενικά στην βιβλιογραφία υπάρχουν τεχνικές μάθησης που προσπαθούν να εκτιμήσουν τον πίνακα M [13], και μετά να εφαρμόσουν τον γραμμικό μετασχηματισμό μέσω της (2.11), όμως δεν δίνει καλή απόδοση όταν τα δεδομένα είναι μη γραμμικά εξαρτημένα.

2.1.1.2 Γραμμικά Αυτοπαλινδρομικά Μοντέλα

Μια άλλη προσέγγιση στο πρόβλημα θεωρεί γραμμικές εξαρτήσεις των δειγμάτων ως προς τον χρόνο. Πιο συγκεκριμένα υποθέτουμε πως κάθε δείγμα είναι γραμμικός συνδυασμός των p προηγούμενων δειγμάτων συν κάποιου είδους σφάλματος προσέγγισης που ανεχόμαστε. Τα πιο γνωστά μοντέλα [14] που συνήθως χρησιμοποιούνται στην οικονομετρία είναι τα αυτοπαλινδρομικά μετατοπισμένου μέσου μοντέλα (ARMA) p, q τάξης όπου κάθε δείγμα γράφεται ως γραμμικός συνδιασμός των p προηγούμενων του ως εξής:

$$y_i = x_i u + z_i v + e_t \quad (2.12)$$

όπου $x_i = [y_{i-1}, y_{i-2}, \dots, y_{i-p}]$, $z_i \sim N(0, \sigma(y_{i-1 \dots i-p}))$ και u, v εκτιμητές. Η φιλοσοφία των γραμμικών μοντέλων βασίζεται στην εκτίμηση της αλλαγής προτύπων στην ροή με την βοήθεια των γραμμικών εκτιμητών u, v οπότε η συνάρτηση κόστους είναι η εξής:

$$c_{Linear}(y_{\hat{t}_k \dots \hat{t}_{k+1}}) = \min_{u \in \mathbb{R}^p, v \in \mathbb{R}^q} \sum_{i=\hat{t}_k}^{\hat{t}_{k+1}} \|y_i - (x_i u + z_i v)\|_\rho \quad (2.13)$$

Προφανώς προηγείται το στάδιο της εκτίμησης των παραμέτρων u, v μέσω της μεθόδου των ελαχίστων τετραγώνων (least squares) όπου αντλούμε αναλυτική λύση του γραμμικού μοντέλου για $\rho = 2$ (2.12), ενώ για $\rho = 1$ προκύπτει ένα πρόβλημα γραμμικού προγραμματισμού. Για να εντοπιστούν καθαρές αλλαγές στην δομή της ροής y συνήθως αφαιρείται ο όρος $z_i v$ και προκύπτει το πολλαπλό αυτοπαλινδρομικό μοντέλο (AR) το οποίο αποτελεί ειδική περίπτωση του (2.13) και δεν λαμβάνεται υπόψιν ο θόρυβος που παράγουν τα δεδομένα σε κάθε τμήμα $y_{\hat{t}_k \dots \hat{t}_{k+1}}$

$$c_{Linear}(y_{\hat{t}_k \dots \hat{t}_{k+1}}) = \min_{u \in \mathbb{R}^p, v \in \mathbb{R}^q} \sum_{t=\hat{t}_k}^{\hat{t}_{k+1}} \|y_t - x_t u\|_\rho \quad (2.14)$$

Μια διαφορετική ερμηνεία των γραμμικών μοντέλων που μπορεί να δοθεί είναι ότι έχουν ως στόχο να εντοπίσουν την αλλαγή της στασιμότητας (stationary) των τμημάτων ως προς τον εκτιμητή u . Το πιο δημοφιλές στατιστικό τεστ που χρησιμοποιείται για αυτό τον σκοπό είναι το στατιστικό τεστ Dickey-Fuller [15].

2.1.2 Μη Παραμετρικά Μοντέλα

Σ' αυτή την υποενότητα (2.1.2) θα αναφερθούν τα μη παραμετρικά μοντέλα και οι αντίστοιχες συναρτήσεις κόστους που προκύπτουν. Τρεις βασικές προσεγγίσεις παρουσιάζονται, οι οποίες συντελούν στην εξαγωγή μη παραμετρικών στατιστικών τιμών και είναι: η εκτίμηση μέγιστης μη παραμετρικής πιθανοφάνειας μέσω υπολογισμών εμπειρικών αθροιστικών συναρτήσεων κατανομών, οι μετατροπές

πυρήνων (kernel transformations) και τα μοντέλα που βασίζονται στην στατιστική βαθμίδα (rank statistic). Σε αντίθεση με τα προηγούμενα μοντέλα όπου είχαμε να υπολογίσουμε τις παραμέτρους των μοντέλων, στα μη παραμετρικά μοντέλα θέλουμε εξαγάγουμε στατιστικές τιμές που ποσοτικοποιούν το μέτρο της ομοιογένειας ενός τμήματος $y_{\hat{t}_k \dots \hat{t}_{k+1}}$.

2.1.2.1 Εκτίμηση Μέγιστης μη Παραμετρικής Πιθανοφάνειας.

Όπως και πριν θεωρούμε ότι τα δείγματα είναι ανεξάρτητα και ακολουθούν μια μη-παραμετρική κατανομή $F(\circ)$.

$$y_i \sim \sum_{k=0}^{\bar{K}} \hat{F}_{\hat{t}_k \dots \hat{t}_{k+1}}(\circ) \quad (2.15)$$

Με την $\hat{F}(\circ)$ να είναι η αθροιστική συνάρτηση πυκνότητας πιθανότητας μη παραμετρικής κατανομής την οποία πρέπει να γνωρίζουμε γνωρίζουμε εκ των προτέρων, η σχέση (2.15) μπορεί να μεταφραστεί ως η εκτίμηση μη παραμετρικής πιθανοφάνειας (parameter free Maximum Likelihood). Η πρώτη προσέγγιση [16] μη παραμετρικών μεθόδων για το πρόβλημα που μελετάμε ορίζει ως αθροιστική πυκνότητα πιθανότητας την εξής:

$$\hat{F}_{\hat{t}_k \dots \hat{t}_{k+1}}(u) := \frac{1}{\hat{t}_{k+1} - \hat{t}_k} \left[\sum_{i=\hat{t}_k}^{\hat{t}_{k+1}} \#(y_i < u) + 0.5 * \#(y_i = u) \right] \quad (2.16)$$

$$0 \leq \hat{t}_k < \hat{t}_{k+1} < T, k = 0, \dots, |\bar{K}| + 1.$$

Όπου $\#(y_i \circ u)$ δηλώνει το πλήθος σημείων που ικανοποιούν την συνθήκη της $<$ ή $=$ και $u \in \mathbb{R}$. Για σταθερό u , n ανεξάρτητα δείγματα και θεωρώντας ότι η αθροιστική συνάρτηση κατανομής παραμένει αμετάβλητη γίνεται η διαπίστωση ότι $nF(u) \sim \text{Binomial}(n, F(u))$ οπότε επιτρέπεται να πούμε πως έχουμε μη παραμετρική εκτίμηση μέγιστης πιθανοφάνειας και προκύπτει αυτόματα η επόμενη συνάρτηση κόστους.

$$c_{\hat{F}}(y_{\hat{t}_k \dots \hat{t}_{k+1}}) = -(\hat{t}_{k+1} - \hat{t}_k) * \sum_{u=1}^T \frac{\hat{F}_{\hat{t}_k \dots \hat{t}_{k+1}}(u) \log \hat{F}_{\hat{t}_k \dots \hat{t}_{k+1}}(u) + (1 - \hat{F}_{\hat{t}_k \dots \hat{t}_{k+1}}(u)) \log(1 - \hat{F}_{\hat{t}_k \dots \hat{t}_{k+1}}(u))}{(u - 0.5)(T - u + 0.5)} \quad (2.17)$$

Ο υπολογισμός της συνάρτησης κόστους (2.17) είναι σχετικά ακριβή διαδικασία και απαιτεί $O(T^3)$ υπολογισμούς όπου T το μήκος του σήματος y . Βέβαια σ' αυτή την περίπτωση η συνάρτηση (2.17) έχει τον περιορισμό ότι μπορεί να εφαρμοσθεί σε μονοδιάστατα σήματα. Στην περίπτωση που έχουμε μεγαλύτερη διάσταση η διαδικασία περιπλέκεται με $O(d * T^3)$ παραπάνω υπολογισμούς.

2.1.2.2 Στατιστικό Βαθμίδας.

Το στατιστικό βαθμίδας είναι η πολυδιάστατη τιμή \mathbb{R}^d που ορίζεται για κάθε δείγμα της ροής $y = \{y_i\}_1^T$ και δηλώνει το άθροισμα του πλήθους των δειγμάτων που ικανοποιούν την $y_{s,j} \leq y_{i,j}$ για κάθε διάσταση $j \in [1, d]$ και έχει τον ακόλουθο τύπο:

$$r_{i,j} = \sum_{s=1}^T \#(y_{s,j} \leq y_{i,j}) - \frac{T+1}{2} \quad (2.18)$$

όπου $1 \leq s \leq T, 1 \leq j \leq d$.

Η ροή r περιγράφει την στατιστική βαθμίδα (ranking) κάθε δείγματος για κάθε διάσταση, η κατασκευή της αντίστοιχης αντικειμενικής απαιτεί την αντικατάσταση της αρχικής ροής y από την r οπότε έχουμε:

$$c_{rank}(y_{\hat{t}_k \dots \hat{t}_{k+1}}) = -(\hat{t}_{k+1} - \hat{t}_k) \bar{r}'_{\hat{t}_k \dots \hat{t}_{k+1}} \hat{\Sigma}'_r r_{\hat{t}_k \dots \hat{t}_{k+1}} \quad (2.19)$$

όπου $\hat{\Sigma}'_r = \frac{1}{T} \sum_{i=1}^T (r_i + 1/2)'(r_i + 1/2)$.

Πάνω στην στατιστική βαθμίδα έχουν βασιστεί αρκετά στατιστικά τεστ όπως Wilcoxon-Mann-Witney Friedman και Kruskal-Wallis. Ένα βασικό πλεονέκτημα της (2.19) είναι ότι οι μετασχηματισμοί του σήματος σε βαθμίδες είναι αμετάβλητοι σε

μονοτονικές μετατροπές. Ο υπολογισμός της (2.19) απαιτεί $O(d * T \log(T))$ υπολογισμούς ενώ του πίνακα $\hat{\Sigma}_r \in \mathbb{R}^{d \times d}$, $O(d^2 + d^3)$.

2.1.2.3 Μετασχηματισμοί Πυρήνα

Μια απ' τις γνωστότερες διαδικασίες μετασχηματισμού των δεδομένων στην κοινότητα της μηχανικής μάθησης είναι ο μετασχηματισμός πυρήνα όπου τα δεδομένα στην περίπτωση μας το πολυδιάστατο σήμα $\{y_i\}_{i=1}^T$ προβάλλονται στον Hilbert χώρο \mathcal{H} μέσω της συνάρτησης πυρήνα $k(\cdot, \cdot): \mathbb{R}^d \times \mathbb{R}^d \rightarrow \mathbb{R}$ και της συνάρτησης προβολής $\varphi(y_i): \mathcal{H} \rightarrow \mathbb{R}$, η οποία ορίζεται ως $\varphi(y_i) = k(y_i, \cdot) \in \mathcal{H}$ οπότε ορίζουμε το γραμμικό Hilbert πυρήνα:

$$\langle \varphi(y_i), \varphi(y_s) \rangle_{\mathcal{H}} = k(y_i, y_s), \|\varphi(y_i)\|_{\mathcal{H}}^2 = k(y_i, y_i) \quad (2.20)$$

για οποιαδήποτε δείγματα y_i, y_s .

Η τεχνική χρησιμοποιείται σε διαδικασίες ομαδοποίησης και κατηγοριοποίησης μέσω SVM (Support Vector Machines). Η μη παραμετρική συνάρτηση κόστους προκύπτει απ' το γνωστό kernel trick εφόσον εφαρμόσουμε την c_{L2} (2.6) στα μετασχηματισμένα $\varphi(y_i)$:

$$c_{kernel}(y_{\hat{t}_k \dots \hat{t}_{k+1}}) = \sum_{i=\hat{t}_k}^{\hat{t}_{k+1}} \|\varphi(y_i) - \bar{\mu}_{\hat{t}_k \dots \hat{t}_{k+1}}\|_{\mathcal{H}}^2 \quad (2.21)$$

όπου $\bar{\mu}_{\hat{t}_k \dots \hat{t}_{k+1}} \in \mathcal{H}$ ο μέσος όρος των $\{\varphi(y_i)\}_{i=1}^T$ μετασχηματισμένων σημάτων και $\|\cdot\|_{\mathcal{H}}^2$ όπως ορίστηκε στη σχέση (2.20). Μετά από αλγεβρικές πράξεις (kernel trick) στην (2.21) προκύπτει η μη παραμετρική συνάρτηση κόστους.

$$c_{kernel}(y_{\hat{t}_k \dots \hat{t}_{k+1}}) = \sum_{i=\hat{t}_k}^{\hat{t}_{k+1}} k(y_i, y_i) - \frac{1}{\hat{t}_{k+1} - \hat{t}_k} \sum_{s,i=\hat{t}_k}^{\hat{t}_{k+1}} k(y_i, y_s) \quad (2.22)$$

Η σχέση (2.21) είναι ισοδύναμη με την σχέση (2.22) και εντοπίζει αλλαγές στους μέσους των μετασχηματισμένων δεδομένων.

Η πιο γνωστή συνάρτηση πυρήνα εκτός της γραμμικής είναι η rbf (Gaussian) η οποία ορίζεται ως $\exp(-\gamma \|y_i - y_s\|_2) = k(y_i, y_s)$ όπου γ είναι η παράμετρος εύρους ή κλίμακας. Οπότε αν εφαρμόσουμε την rbf συνάρτηση πυρήνα στη σχέση (2.22) προκύπτει:

$$c_{rbf}(y_{\hat{t}_k \dots \hat{t}_{k+1}}) = (\hat{t}_{k+1} - \hat{t}_k) - \frac{1}{\hat{t}_{k+1} - \hat{t}_k} \sum_{s, \hat{t}=\hat{t}_k}^{\hat{t}_{k+1}} \exp(-\gamma \|y_i - y_s\|_2) \quad (2.23)$$

Επιπλέον στην (2.21) μπορεί να ενσωματωθεί η Mahalanobis μετρική η οποία ορίζεται ως:

$$\|\varphi(y_i) - \varphi(y_s)\|_{M, \mathcal{H}}^2 = (\varphi(y_i) - \varphi(y_s))' M (\varphi(y_i) - \varphi(y_s)) \quad (2.24)$$

Μέσω της (2.24) εφαρμόζεται μη γραμμική προβολή στα δεδομένα όπως και στην rbf περίπτωση και έπειτα η Mahalanobis εφαρμόζεται στα μετασχηματισμένα σήματα του Hilbert χώρου με οποιοδήποτε πυρήνα ενεργοποίησης. Οπότε προκύπτει και η αντίστοιχη συνάρτηση με την νόρμα $\|\cdot\|_{\mathcal{H}, M}^2$ όπως ορίστηκε στο (2.24):

$$c_{kernel}(y_{\hat{t}_k \dots \hat{t}_{k+1}}) = \sum_{i=\hat{t}_k}^{\hat{t}_{k+1}} \|\varphi(y_i) - \bar{\mu}_{\hat{t}_k \dots \hat{t}_{k+1}}\|_{\mathcal{H}, M}^2 \quad (2.25)$$

2.2 Αλγόριθμοι Εντοπισμού Σημείων Αλλαγής

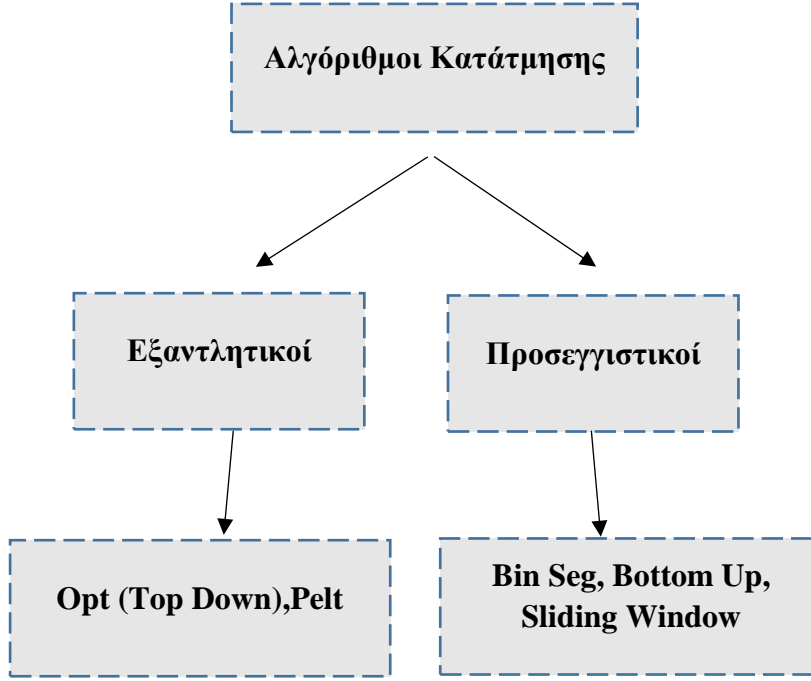
Σ' αυτή την υποενότητα (2.2) θα μελετήσουμε τους κύριους αλγορίθμους εύρεσης των σημείων αλλαγής στην πολυδιάστατη ροή σημάτων y που υπάρχουν στην βιβλιογραφία. Η κύρια διαφοροποίηση των μεθόδων αυτών εξαρτάται από τον τρόπο εξαγωγής των σημείων αλλαγής, δηλαδή αν είναι ακριβής ή προσεγγιστικός. Οι αλγόριθμοι που υπολογίζουν ακριβή μορφή λύσης δέχονται σαν είσοδο ολόκληρο το σήμα που περιγράφει ένα φαινόμενο (offline detection) και προσπαθούν να εντοπίσουν τα σημεία αλλαγής εξαντλητικά χρησιμοποιώντας μια από τις συναρτήσεις κόστους

που περιγράψαμε στην υποενότητα (2.1). Η δεύτερη κατηγορία αλγορίθμων είναι οι προσεγγιστικοί οι οποίοι είναι προφανώς πιο γρήγοροι λόγω του ότι επεξεργάζονται την ροή τμηματικά και μπορούν να εντοπίζουν τα σημεία αλλαγής και online, χρησιμοποιούν επίσης τις ίδιες συναρτήσεις κόστους με κάποιες παραλλαγές. Προφανώς η πολυπλοκότητα κάθε αλγορίθμου εξαρτάται απ' την συνάρτηση κόστους που θα χρησιμοποιηθεί. Θα θεωρηθεί ότι η πολυπλοκότητα εφαρμογής κάθε συνάρτησης θα είναι $O(1)$ για σκοπούς διευκόλυνσης στην ανάλυση μας. Όλοι οι αλγόριθμοι είναι ικανοί να εκτιμήσουν και το πλήθος των σημείων αλλαγής \hat{K} λύνοντας το πρόβλημα με τον επιπλέον όρο εξομάλυνσης (2.3) όπως θα δούμε παρακάτω.

2.2.1 Εξαντλητικοί Αλγόριθμοι

Οι δύο βασικοί αλγόριθμοι που λύνουν το πρόβλημα διακριτής βελτιστοποίησης με γνωστό το πλήθος των υποψήφιων σημείων αλλαγής $|\hat{K}|$ για το πρόβλημα (2.2) αλλά και εκτιμούν το πλήθος $|\hat{K}|$ όταν δεν δίνεται για το πρόβλημα (2.3) είναι οι Opt και Pelt αντίστοιχα. Ο Opt (Optimal) αλγόριθμος βρίσκει την ακριβή λύση χρησιμοποιώντας δυναμικό προγραμματισμό, παίρνοντας ως είσοδο το πλήθος των υποψήφιων σημείων αλλαγής $|\hat{K}|$. Περιγραφικά εντοπίζει εξαντλητικά σ' ολόκληρη την ροή σημάτων το πρώτο σημείο αλλαγής ή κατάτμησης όπου ελαχιστοποιείται το $C(\hat{K}, y)$ της σχέσης (2.1). Έπειτα επαναληπτικά προσπαθεί να εντοπίσει αμέσως το επόμενο σημείο που ελαχιστοποιεί την ίδια συνάρτηση $C(\hat{K}, y)$ κρατώντας ως δεδομένη την προηγούμενη τμηματοποίηση, ο αλγόριθμος τερματίζει ωστόσο το πλήθος των εντοπισμένων σημείων αλλαγής $|\hat{K}|$ γίνει ίσο με μια δοθέν τιμή απ' τον χρήστη. Η ασυμπτωτική πολυπλοκότητα του Opt είναι $O(|\hat{K}|T^2)$ όπου T το μήκος του σήματος. Η αναδρομική σχέση που χρησιμοποιείται μπορεί να περιγραφεί με τον ακόλουθο τύπο:

$$\begin{aligned}
& \min_{|\hat{R}|=\text{constant}} C(\hat{R}, y_{0..T}) = \\
& \min_{\hat{t} \in T \setminus \hat{R}, \hat{R} = \hat{R} \cup \{\hat{t}^1\}, 0 = \hat{t}_0 < \hat{t}_1 < \hat{t}_2 \dots < \hat{t}_R < \hat{t}_{R+1} = T} \sum_{k=0}^{|\hat{R}|} c(y_{\hat{t}_k \dots \hat{t}_{k+1}}) = \\
& \min_{\hat{t} \in T \setminus \hat{R}, \hat{R} = \hat{R} \cup \{\hat{t}^1\}} C(\hat{R}, y_{0..T})
\end{aligned} \tag{2.26}$$



Σχήμα 2.1 Διαχωρισμός των κύριων αλγορίθμων εντοπισμού.

Ο εξαντλητικός αλγόριθμος που λύνει το πρόβλημα (2.3) είναι ο Pelt ο οποίος εκτιμά το πλήθος των υπονήφιων σημείων αλλαγής \hat{R} . Ο Pelt αλγόριθμος προσπαθεί να εντοπίσει τα σημεία τα οποία δεν είναι πιθανά σημεία αλλαγής εξετάζοντας αν ικανοποιούν την εξής συνθήκη.

$$[\min_{\hat{R}} C(\hat{R}, y_{0..t}) + \text{pen}(T)] + c(y_{t..l}) \geq [\min_{\hat{R}} C(\hat{R}, y_{0..l}) + \text{pen}(T)] \tag{2.27}$$

για $\hat{t} < l < T$ και l ένας τυχαία ομοιόμορφα επιλεγμένος αριθμός. Με λίγα λόγια ο αλγόριθμος σε ένα πέρασμα εντοπίζει τα y_t σημεία τα οποία δεν μπορεί να είναι σημεία αλλαγής λόγω ότι ικανοποιούν την παραπάνω συνθήκη για ομοιόμορφα τυχαία επιλεγμένο $l \in (\hat{t}, T]$. Τα σημεία που δεν ικανοποιούν την συνθήκη προφανώς είναι

υποψήφια σημεία και σχηματίζουν την κατάτμηση. Ο πέναλτι όρος συνήθως είναι γραμμικός $pen(T) = \beta|T|$ όπου $\beta > 0$ είναι συντελεστής εξομάλυνσης και ορίζεται απ' τον χρήστη. Η ασυμπτωτική πολυπλοκότητα του Pelt αλγορίθμου είναι $O\left(\frac{T^2}{2}\right)$. Να σημειωθεί ότι εκτός απ' το γραμμικό όρο τιμωρίας υπάρχουν και οι AIC και BIC όροι τιμωρίας:

$$pen_{BIC,L_2} = \det \hat{\Sigma} \log(T) |T| \text{ και } pen_{AIC,L_2} = \det \hat{\Sigma} |T| \quad (2.28)$$

όπου $\hat{\Sigma}$ πίνακας συνδιακύμανση της ροής.

2.2.2 Προσεγγιστικοί Αλγόριθμοι

Μια εναλλακτική λύση των προβλημάτων (2.2),(2.3) προκύπτει μέσω των προσεγγιστικών αλγορίθμων οι οποίοι επεξεργάζονται τα δεδομένα με μικρότερη προφανώς πολυπλοκότητα σε σχέση με τους ακριβείς αλγορίθμους. Ο κύριος κορμός της εργασίας βασίζεται στην προσεγγιστική επίλυση του προβλήματος (2.2). Σ' αυτή την υποενότητα (2.2.2) θα ασχοληθούμε με τους προσεγγιστικούς αλγορίθμους Bin Seg, Bottom Up, Sliding Window.


2.2.2.1 Δυαδική κατάτμηση (Binary Segmentation)

Ο αλγόριθμος Bin Seg είναι η προσεγγιστική εκδοχή του αλγορίθμου Opt και μπορεί να λύσει και το πρόβλημα (2.3), κάτι που δεν θα μελετήσουμε σ' αυτή την ενότητα. Ο Bin Seg στην πρώτη επανάληψη εντοπίζει εξαντλητικά όπως και ο Opt το πρώτο σημείο αλλαγής, δηλαδή το πρώτο σημείο y_t που ελαχιστοποιεί την επιλεγμένη συνάρτηση κόστους.

$$\hat{t}_1 = \operatorname{argmin}_{1 \leq t < T} c(y_1 \dots y_t) + c(y_{t+1} \dots y_T) \quad (2.29)$$

Μόλις εντοπίσει το πρώτο σημείο αλλαγής \hat{t}_1 διαχωρίζει την ροή και επαναλαμβάνει την ίδια διαδικασία (2.29) στα δύο υποτμήματα που προέκυψαν (βλ. Σχήμα 2.2). Ο

αλγόριθμος συνεχίζει την ίδια διαδικασία δυναμικά μέχρι το πλήθος των εντοπισμένων αλλαγών γίνει ίσο με το δοθέν πλήθος $|\hat{K}|$ το οποίο ορίζεται απ' τον χρήστη για την λύση του προβλήματος (2.2). Η πολυπλοκότητα του αλγορίθμου είναι $O(T \log(T))$. Μια παραλλαγή του Bin Seg είναι ο αλγόριθμος Wild Bin Seg [17]. Ο αλγόριθμος αυτός σε κάθε επανάληψη δειγματοληπτεί I τυχαία διαστήματα στην ροή και σε καθένα εφαρμόζει την δυαδική κατάτμηση (Bin Seg) επιλέγοντας ως σημείο αλλαγής το σημείο που προκύπτει απ' το τμήμα που έχει το ελάχιστο κόστος κατάτμησης. Η συνθήκες τερματισμού είναι ίδιες με αυτές του Bin Seg.




Σχήμα 2.2 Σχηματική αναπαράσταση του Bin Seg αλγορίθμου.

2.2.2.2 Bottom Up κατάτμηση

Η Bottom Up κατάτμηση είναι συμπληρωματική διαδικασία της Bin Seg. Η κύρια διαφορά είναι ότι δειγματοληπτεί τυχαία και ομοιόμορφα ένα μεγάλο πλήθος σημείων P , ($P \gg |\hat{K}|$) για την περίπτωση του προβλήματος (2.2), τα οποία διαμορφώνουν $P + 1$ διαστήματα. Ο αλγόριθμος σε κάθε επανάληψη ενώνει δοκιμαστικά όλα τα γειτονικά διαστήματα της ροής (βλ Σχήμα 2.3) και κρατάει την ένωση που ελαχιστοποιεί το άθροισμα κόστους κάθε διαστήματος που προκύπτει απ' τις P ενώσεις.

$$\min_{\hat{t}_k} \sum_{k=1}^P c(y_{\hat{t}_k \dots \hat{t}_{k+1}}) \quad (2.30)$$

Η ίδια διαδικασία συνεχίζεται μέχρι ωστόσο το $P = |\hat{K}|$ για την περίπτωση του προβλήματος (2.2) ή όταν ικανοποιηθεί ένα κριτήριο τερματισμού για το (2.3) πρόβλημα αντίστοιχα θεωρώντας τον κατάλληλο πέναλτι όρο. Η πολυπλοκότητα είναι γραμμική ως προς το μέγεθος της ροής T .



Σχήμα 2.3 Σχηματική αναπαράσταση του αλγορίθμου Bottom Up.

2.2.2.3 Κυλιόμενο Παράθυρο (Sliding Window)

Η μέθοδος του κυλιόμενου παραθύρου σταθερού μήκους είναι μια ακραία μορφή προσέγγισης στο πρόβλημα (2.2) αλλά πλέον κατάλληλη για γρήγορο εντοπισμό των σημείων αλλαγής διότι η διαδικασία είναι καθαρά ακολουθιακή. Πάνω σ' αυτό το μοντέλο και σε παραλλαγές βασίστηκε η συγκεκριμένη εργασία όπως θα δούμε σε επόμενα κεφάλαια (Κεφ.3, Κεφ. 4). Η ιδέα είναι σχετικά απλή το παράθυρο $Win_{sliding}$ ολισθαίνει κατά μήκος της ροής και σε κάθε χρονική στιγμή t συγκρίνει την ομοιομορφία των δειγμάτων εκατέρωθεν του σημείου t (κέντρο του παραθύρου) μέσω μίας συνάρτησης κόστους ή κάποιας μετρικής. Το αποτέλεσμα της μετρικής ή συνάρτησης κόστους $d(t)$ αντιστοιχεί στο κέντρο του παραθύρου t όπως έχει περιγραφεί στην σχέση (1.1).


Συνήθως θεωρούμε τα δυο ημιπαράθυρα δεξιά και αριστερά του κέντρου t (βλ. Σχήμα 2.4) και υπολογίζουμε την συνάρτηση κόστους του παραθύρου από το οποίο

αφαιρούνται τα αντίστοιχα κόστη των ημιπαραθύρων χρησιμοποιώντας μια απ' τις γνωστές συναρτήσεις κόστους:

$$d(t) = Win_{sliding}(y_{a..b}) = c(y_{a..b}) - (c(y_{a..t}) + c(y_{t..b})) \quad (2.31)$$

όπου t κέντρο του παραθύρου $Win_{sliding}$.

Η τιμή $d(t)$ που προκύπτει απ' την σχέση (2.31) αναπαριστά την διαφορά μεταξύ εξωτερικής και εσωτερικής ομοιομορφίας του παραθύρου και χρησιμοποιείται για τον εντοπισμό των σημείων αλλαγής. Η ευρέως διαδεδομένη συνάρτηση που χρησιμοποιείται είναι η σχέση (2.6) για $\rho = 1,2$ η οποία μπορεί να παρομοιαστεί με το t-test όπου ελέγχεται ο διαφορά των μέσων μεταξύ δύο πληθυσμών στην περίπτωση μας δεξιού και αριστερού ημιπαραθύρου.



Σχήμα 2.4 Σχηματική αναπαράσταση του αλγορίθμου Win Sliding.

Το t-test όμως δεν λειτουργεί για πολυδιάστατα δεδομένα. Εκτός απ' την σχέση (2.31) δηλαδή τον υπολογισμό συναρτήσεων κόστους μπορούμε να υποθέσουμε το γενικό στατιστικό τεστ δύο πληθυσμών στο οποίο η μηδενική υπόθεση θεωρεί τις δύο κατανομές των δειγμάτων στο δεξιό και αριστερό ημιπαραθύρο όμοιες δηλαδή την διαφορά τους ως προς κάποια στατιστική μετρική να είναι μικρή.

$$\begin{aligned} H_0: \mathbb{P}_{a..t} &\approx \mathbb{P}_{t..b} \\ H_1: \mathbb{P}_{a..t} &\neq \mathbb{P}_{t..b} \end{aligned} \quad (2.32)$$

Προφανώς σημεία t των οποίων η διαφορά των κατανομών ως προς μία στατιστική μετρική των δυο πληθυσμών δεξιά και αριστερά είναι μεγάλη (δηλαδή απορρίπτεται η μηδενική υπόθεση H_0) είναι υποψήφια σημεία αλλαγής. Η ιδέα (να χρησιμοποιηθεί η (2.31) σχέση ή κάποιο απ' τα γνωστά στατιστικά τεστ όπως Kolmogorov-Smirnoff επιτυγχάνει τον ίδιο σκοπό: να εντοπιστούν οι διαφορές στις κατανομές $d(\mathbb{P}_{a...t}, \mathbb{P}_{t...b})$. Πρέπει να επισυμανθεί ότι εφαρμόζοντας τις συναρτήσεις κόστους $c_{L_2}, c_{LogML}, c_{kernel}$ στην σχέση (2.31) είναι ισοδύναμο με το να χρησιμοποιηθούν τα στατιστικά τεστ Student t-test [18], Generalize Likelihood Ratio [19] και Kernel Maximum Discrepancy [20] αντίστοιχα. Στην δική μας εργασία θα δούμε τις τροποποιήσεις της σχέσης (2.31) και πως εφαρμόζουμε το στατιστικό τεστ dip test [5] για να υπολογίσουμε διαφορές στις κατανομές των αποστάσεων των δειγμάτων του παραθύρου αλλά και πώς χρησιμοποιούμε την διαδικασία του παραθύρου $Win_{sliding}$ για προεπεξεργασία και μετασχηματισμό της ροής. Τα δύο βασικά και ανοιχτά προβλήματα αυτής της μεθόδου βασίζονται στον προσδιορισμό των κατάλληλων υπερπαραμέτρων δηλαδή του μεγέθους του παραθύρου $size$ και του κατωφλίου μ_0 που προσδιορίζει πότε ένα σημείο είναι σημείο αλλαγής. Σημεία των οποίων η διαφορά των κατανομών $d(\mathbb{P}_{a...t}, \mathbb{P}_{t...b})$, των ημιπαραθύρων δεξιά και αριστερά είναι μεγαλύτερη απ' το μ_0 τότε αποτελούν σημεία αλλαγής και απορρίπτεται η μηδενική υπόθεση H_0 , αντίστοιχα όταν η τιμή ανομοιογένειας $d(t)$ είναι μεγαλύτερη απ' το μ_0 . Προφανώς ο σωστός καθορισμός του κατωφλίου λύνει και το πρόβλημα (2.3) και λειτουργεί για την online διαδικασία εντοπισμού (online detection). Παρότι η μέθοδος λειτουργεί για το πρόβλημα (2.2) δεν δέχεται ως είσοδο το πλήθος των εκτιμώμενων σημείων αλλαγής \hat{K} όπως στις προηγούμενες μεθόδους σαν συνθήκη τερματισμού. Οπότε για να βρούμε τα υποψήφια σημεία στην ροή ψάχνουμε τα μέγιστα $d(t)$ ή $d(\mathbb{P}_{<t}, \mathbb{P}_{t>})$.

$$\hat{K} = \operatorname{argmax}_{|\hat{K}|=\text{constant}, t} (d(\mathbb{P}_{<t}, \mathbb{P}_{t>})) \quad (2.33)$$

όπου $\hat{K} = \{\hat{t}_1, \hat{t}_2, \dots, \hat{t}_{\hat{K}}\}$.

ΚΕΦΑΛΑΙΟ 3.

ΚΥΛΙΟΜΕΝΟ ΠΑΡΑΘΥΡΟ ΣΤΑΘΕΡΟΥ ΜΕΓΕΘΟΥΣ

3.1 Άθροισμα Αποστάσεων

3.2 Διαφορά Εξωτερικής και Εσωτερικής Απόστασης

3.3 Διαφορά Στατιστικού Μέσου Όρου

3.4 Εφαρμογή του Dip Test

3.5 Σφάλμα Ανακατασκευής Μέσω PCA

3.6 Γενική Περιγραφή Αλγορίθμου Κυλιόμενου Παραθύρου

Όπως αναφέρθηκε στο προηγούμενο κεφάλαιο (Κεφ. 2) ο αλγόριθμος του κυλιόμενου παραθύρου Win Sliding (2.31) εντοπίζει προσεγγιστικά τα σημεία αλλαγής \hat{t} υπολογίζοντας μια τιμή ανομοιογένειας $d(t)$ για καθένα στιγμιότυπο y_t . Έπειτα θεωρούμε το σύνολο των υποψήφιων σημείων αλλαγής \hat{K} με δοθέν $|\hat{K}|$, το οποίο περιέχει τα σημεία της ροής \hat{t} που αντιστοιχούν στις $|\hat{K}|$ μεγαλύτερες τιμές ανομοιογένειας $d(t)$. Για να αξιολογηθεί η μέθοδος εντοπίζονται ποιες από τις $|\hat{K}|$ μεγαλύτερες τιμές $d(t)$ είναι ‘κοντά’ στα πραγματικά σημεία αλλαγής K όταν είναι γνωστή η θέση τους t^* και το πλήθος τους $|K|$. Στην συγκεκριμένη εργασία δεν έχουμε ασχοληθεί με τις συναρτήσεις κόστους όπως έχουν χρησιμοποιηθεί στην βιβλιογραφία αλλά με διάφορες μετρικές, τεχνικές και το στατιστικό τεστ dip test [5] που προσπαθούν να αποτυπώσουν τις απότομες αλλαγές σ’ ένα παράθυρο και κατ’ επέκταση σ’ όλη την ροή σημάτων. Στόχος μας είναι να υλοποιήσουμε τεχνικές οι

οποίες θα μπορούν να εκτελούνται με μικρή σχετικά πολυπλοκότητα έτσι ώστε να μπορούν να ενσωματωθούν σε διαδικασίες online εντοπισμού αλλά και να έχουν όσον το δυνατό καλύτερη ακρίβεια. Το γενικό σχήμα του αλγορίθμου παραμένει ίδιο δηλαδή έχουμε ένα παράθυρο $Win_{sliding}$ με μέγεθος s που ολισθαίνει πάνω στην ροή. Για να εντοπιστούν οι αλλαγές όσο το δυνατό πιο ακριβέστερα οι μετρικές που εφαρμόζονται στο παράθυρο πρέπει να σέβονται την φύση του προβλήματος δηλαδή την διάταξη των σημείων του παραθύρου ως προς τον χρόνο κάτι το οποίο παίζει σημαντικό ρόλο απ' την στιγμή που θέλουμε να εντοπίσουμε αλλαγές καταστάσεων που εμφανίζονται με μια χρονική σειρά. Οι δικές μας παραλλαγές αφορούν τον τρόπο υπολογισμού των τιμών ανομοιογένειας $d(t)$. Όλες οι μεθοδολογίες έχουν ως στόχο να εντοπίσουν τις απότομες αλλαγές όπως και οι ήδη υπάρχουσες μέθοδοι της βιβλιογραφίας όπως αναφέρθηκε στο προηγούμενο Κεφ. 2. Παρακάτω θα παρουσιαστούν τρεις μετρικές και οι πολυπλοκότητες τους, ο τρόπος υλοποίησης του dip test [5] με κάποια προεπεξεργασία που εφαρμόζεται στο παράθυρο και τέλος θα δούμε πώς η τεχνική της ανακατασκευής των δειγμάτων της ροής μέσω γραμμικής μείωσης διάστασης (όπως PCA) μπορεί να δουλέψει ως κατάλληλο κριτήριο το πρόβλημα.

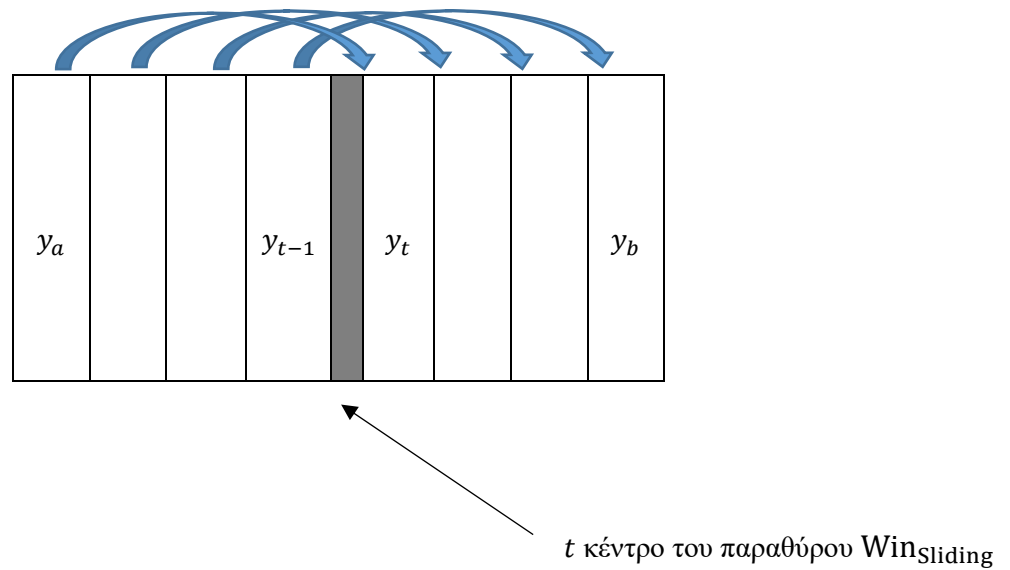
3.1 Άθροισμα Αποστάσεων

Όπως έχει αναφερθεί, κάθε δείγμα y_i $0 \leq i \leq T$ περιγράφεται ως ένα στιγμιότυπο στην ροή το οποίο στις περιπτώσεις που έχουμε εξετάσει είναι πολυδιάστατο $y_i \in \mathbb{R}^d$, επομένως είναι λογικό σημεία τα οποία βρίσκονται στην ίδια κατάσταση να έχουν μικρή απόσταση μεταξύ τους δηλαδή να υπακούν σ' ένα κανόνα ομοιομορφίας. Επομένως το άθροισμα των αποστάσεων συμμετρικών δειγμάτων του δεξιού και αριστερού ημιπαραθύρου μπορεί εντοπίσει απότομες αλλαγές μεταξύ των σημείων και να παράγει την τιμή ανομοιογένειας $d(t)$ για το κεντρικό σημείο t σε κάθε βήμα εφαρμογής του παραθύρου. Η βασική υπόθεση που μπορεί να γίνει είναι ότι εφόσον τα δείγματα του παραθύρου βρίσκονται στην ίδια κατάσταση το άθροισμα των συμμετρικών αποστάσεων είναι μικρό, αντιθέτως όταν το παράθυρο πλησιάζει σε σημεία που γίνεται αλλαγή κατάστασης το άθροισμα αυξάνεται λόγω ανομοιομορφίας. Κάποια στιγμή τα δείγματα δεξιού και αριστερού ημιπαραθύρου θα αντιστοιχούν σε

διαφορετικές καταστάσεις οπότε εκεί προσδοκείται η τιμή $d(t)$ της μετρικής να παίρνει μέγιστες τιμές.

$$Sum_{dist} (Win_{sliding}(y_{a...b})) = \sum_{i=a}^t \|y_i - y_{t+i}\|_1 \quad (3.1)$$

Προφανώς η ασυμπτωτική πολυπλοκότητα της συνολικής διαδικασίας είναι $O(T * size)$ και παραμένει σταθερή ως προς το μήκος της ροής T .



Σχήμα 3.1 Σχηματική αναπαράσταση της μετρικής (3.1).

Η επόμενη μετρική έχει χρησιμοποιηθεί για κατάτμηση κειμένων και αφορά τον υπολογισμό ομοιοτήτων μεταξύ κείμενων [20]. Στην δική μας περίπτωση χρησιμοποιήσαμε την μετρική με την παραλλαγή ότι υπολογίζει αποστάσεις και όχι ομοιότητες.

3.2 Διαφορά Εξωτερικής και Εσωτερικής Απόστασης

Γενικά μπορούμε να θεωρήσουμε το παράθυρο $Win_{sliding}$ σαν ένα σύνολο δειγμάτων όπου εμπεριέχονται δύο υποσύνολα του το δεξί και αριστερό ημιπαράθυρο των οποίων

θέλουμε να συγκρίνουμε την εξωτερική και εσωτερική απόσταση. Θεωρούμε την εξωτερική απόσταση των ημιπαραθύρων ως το διπλό άθροισμα αποστάσεων μεταξύ κάθε δείγματος του αριστερού ημιπαραθύρου με καθένα από τα δείγματα του δεξιού.

$$Outer_{dist} \left(Win_{sliding}(y_{a...b}) \right) = \sum_{i=a}^t \sum_{j=t+1}^b \|y_i - y_j\|_1 \quad (3.2)$$


Εφόσον υπολογιστεί η εξωτερική απόσταση, επόμενο βήμα είναι να συγκριθεί με την εσωτερική απόσταση $Inner_{dist}$ του παραθύρου η οποία ορίζεται ως ο μέσος όρος των διπλών αθροισμάτων αποστάσεων μεταξύ κάθε δείγματος των 2 ημιπαραθύρων με καθένα απ' τα επόμενα δείγματα στον χρόνο.

$$Inner_{dist} \left(Win_{sliding}(y_{a...b}) \right) = \frac{\sum_{i=a}^t \sum_{j=i+1}^t \|y_i - y_j\|_1 + \sum_{i=t+1}^b \sum_{j=i+1}^b \|y_i - y_j\|_1}{2} \quad (3.3)$$

Για να συγκριθούν δύο μετρικές υπολογίζεται η διαφορά τους οπότε για παράθυρο $Win_{sliding}$ επιστρέφουμε την τιμή ανομοιογένειας ως:

$$d(t) = Outer_{dist} \left(Win_{sliding}(y_{a...b}) \right) - Inner_{dist} \left(Win_{sliding}(y_{a...b}) \right) \quad (3.4)$$

Η μετρική διαφοράς εξωτερικής και εσωτερικής απόστασης έχει ως στόχο να εξάγει ποσοτική πληροφορία ως προς τις αποστάσεις σημείων του υπερσυνόλου δηλαδή ολόκληρου του παράθυρο και των δυο υποσυνόλων του. Προφανώς όταν το παράθυρο βρίσκεται σε σημείο αλλαγής η διαφορά αυτή θα είναι μεγάλη δεδομένου ότι τα σημεία εκατέρωθεν του κέντρου θα διαφέρουν ως προς τις αποστάσεις τους. Η πολυπλοκότητα υπολογισμού της μετρικής είναι $O\left(\frac{s^2}{2}\right)$ λόγω των διπλών αθροισμάτων οπότε και η συνολική πολυπλοκότητα του $Win_{sliding}$ αλγορίθμου είναι $O\left(T * \frac{s^2}{2}\right)$ τάξης. Οι μετρικές (3.1) και (3.4) δεν λαμβάνουν υπόψιν στατιστικής σημασίας χαρακτηριστικά των δειγμάτων, κάτι το οποίο απασχολεί τις επόμενες τεχνικές όπου αναφερόμαστε στην στατιστική επεξεργασία σημάτων.



Σχήμα 3.2 Σχηματική αναπαράσταση της μετρικής (3.4)

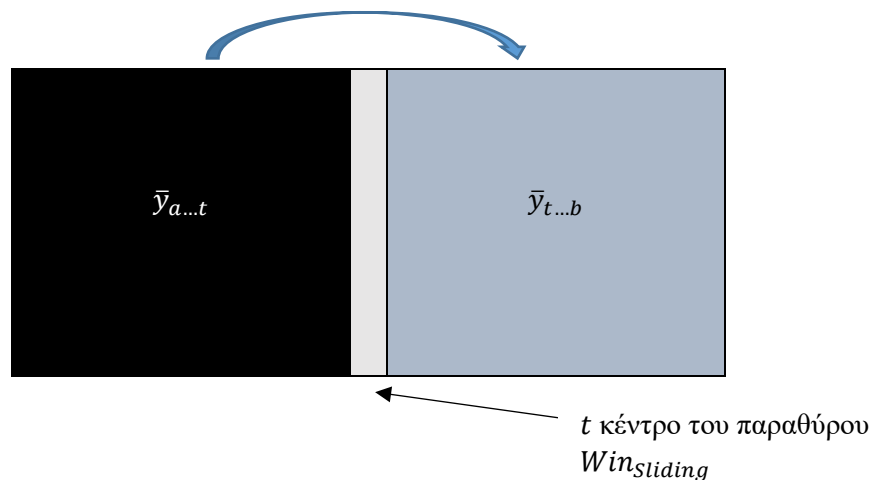
3.3 Διαφορά Στατιστικού Μέσου Όρου

Εκτός από την σύγκριση αποστάσεων μεταξύ δύο συνόλων στην περίπτωση μας των δειγμάτων των δυο ημιπαραθύρων, το επόμενο βήμα θα ήταν να επεξεργαστούμε την στατιστική πληροφορία των δυο συνόλων και να τα συγκρίνουμε ως προς την κατανομή τους. Θεωρώντας ότι τα δείγματα είναι ανεξάρτητα και ακολουθούν κανονική πολυδιάστατη κατανομή μπορούμε να συγκρίνουμε τους μέσους όρους των δύο δειγμάτων $d(\bar{y}_{a...s}, \bar{y}_{s...b})$ υπολογίζοντας την απόσταση τους.

$$Diff_{mean}(Win_{sliding}(y_{a...b})) = \|\bar{y}_{a...t} - \bar{y}_{t+1...b}\|_1 \quad (3.5)$$

Η διαφορά μέσων όρων σε μονοδιάστατα δεδομένα μπορεί να αποτυπωθεί μέσω του στατιστικού Student's t-test, στην περίπτωση μας δεν υπάρχει αντίστοιχο τεστ για πολυδιάστατα δεδομένα. Το t-test μπορεί να εφαρμοσθεί σε πολυδιάστατα δεδομένα υπολογίζοντας την τιμή t-statistic για καθεμία διάσταση j , $1 \leq j \leq d$ οπότε θα προκύψουν d t-statistics, με λίγα λόγια μπορούμε να συγκρίνουμε τους μέσους όρους d μονοδιάστατων σημάτων μεταξύ των ημιπαραθύρων. Για κάθε παράθυρο μπορούμε

να παίρνουμε την μεγαλύτερη τιμή που προκύπτει απ' τα t-tests, δηλαδή η τιμή ανομοιογένειας $d(t)$ θα παίρνει το μεγαλύτερο t-statistic που προκύπτει απ' το μονοδιάστατο σήμα με την μεγαλύτερη διαφορά μέσω των αγνοώντας τα υπόλοιπα σήματα κάτι που δημιουργεί ένα πολύπλοκο τρόπο απόφασης για το αν ένα σημείο είναι ή όχι σημείο αλλαγής. Στην συγκεκριμένη εργασία δεν μας απασχόλησε το συγκεκριμένο ζήτημα εφόσον επεξεργαζόμαστε την ροή ως πολυδιάστατα δείγματα. Η απόσταση των μέσων όρων για την πολυδιάστατη περίπτωση δεν μπορεί να θεωρηθεί ως στατιστικό τεστ δεδομένου ότι δεν υπάρχει κριτήριο απόφασης.

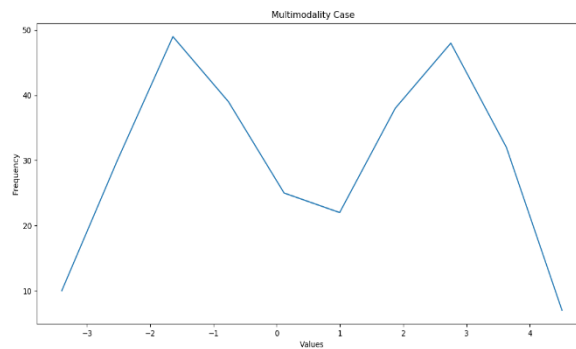


Σχήμα 3.3 Σχηματική αναπαράσταση της μετρικής (3.5).

3.4 Εφαρμογή του Dip Test

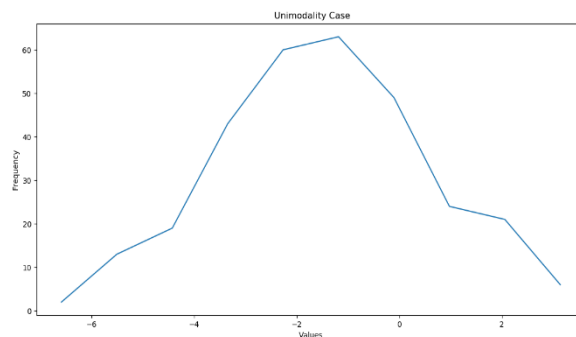
Επεκτείνοντας την ιδέα της εξαγωγής στατιστικών που χαρακτηρίζουν διαφορές δύο δειγμάτων ως προς τις κατανομές εφαρμόσαμε το στατιστικό τεστ dip test [5] το οποίο εκτιμά την πιθανότητα ύπαρξης πολυτροπικότητας (multimodality) σε μονοδιάστατα δεδομένα υπολογίζοντας το στατιστικό dip value. Η διαδικασία για την οποία θα αναφερθούμε σ' αυτή την υποενότητα έχει εφαρμοσθεί σε εικονοσειρές (video) [21] με σκοπό την περίληψη τους. Πιο συγκεκριμένα η διαδικασία που υλοποιείται είναι ίδια με αυτή του κυλιόμενου παραθύρου και εφαρμόζεται πάνω σε ροή από εικόνες και εντοπίζει τα κύρια στιγμιότυπα εικόνων με βάση την πολυτροπικότητα των αποστάσεων των διανυσμάτων κίνησης στο παράθυρο. Το dip test υπολογίζει την πιθανότητα ύπαρξης πολυτροπικότητας σε μονοδιάστατα σύνολα δεδομένων. Γενικά

μεγάλος βαθμός πολυτροπικότητας εμφανίζεται όταν υπάρχουν δύο ή και περισσότερες κατανομές που σχηματίζουν δύο ή και περισσότερες κορυφές (βλ. Σχήμα 3.4). Στις περιπτώσεις αυτές αναμένουμε το στατιστικό dip value που δηλώνει την πιθανότητα ύπαρξης πολυτροπικότητας να έχει υψηλές τιμές.



Σχήμα 3.4 Περίπτωση πολυτροπικής κατανομής.

Το αντίθετο της πολυτροπικότητας είναι η μονοτροπικότητα (unimodality) όπου θεωρούμε τα δεδομένα ότι ακολουθούν μία κατανομή με κορυφή όπως η Student-t η οποία είναι μια κατανομή υψηλού βαθμού μονοτροπικότητας και η ομοιόμορφη U χαμηλού βαθμού (βλ. Σχήμα 3.5). Με άλλα λόγια η στατιστική τιμή του dip test (dip value) δηλώνει την απόσταση από την μονοτροπικότητα και παίρνει μέγιστες τιμές όταν τα δεδομένα ακολουθούν κατανομή υψηλής πολυτροπικότητας.



Σχήμα 3.5 Περίπτωση μονοτροπικής κατανομής

Το ζήτημα με την εφαρμογή του dip test είναι ότι θεωρεί μονοδιάστατα δείγματα. Θα ήταν λογικό να εφαρμοστεί σε κάθε σήμα $j, 1 \leq j < d, d$ η διάσταση ροής οπότε προκύπτουν d dip values.

3.4.1 Πίνακας αποστάσεων μεταξύ σημείων

Για να μην χαθεί η πληροφορία των διατεταγμένων σημείων ως προς τον χρόνο μπορεί να εφαρμοστεί το dip test στον πίνακα αποστάσεων μεταξύ των σημείων του παραθύρου $D \in \mathbb{R}^{s \times s}$, s μέγεθος παραθύρου.

$$D_{i,j} = \|y_i - y_j\|_1 \quad (3.5)$$

$i, j = a \dots b$.

Η στρατηγική έχει εφαρμοστεί στο [21] και είναι η εξής εφαρμόζουμε το dip test σε κάθε γραμμή D_i του πίνακα D και παίρνουμε την μεγαλύτερη απ' τις s dip values που προκύπτουν. Με λίγα λόγια εξετάζουμε την πιθανότητα πολυτροπικότητας στα διανύσματα αποστάσεων των σημείων του παραθύρου δηλαδή στις γραμμές του πίνακα D . Η ιδέα είναι πως αν οι κατανομές των αποστάσεων εμφανίζουν υψηλή πολυτροπικότητα, η dip value προσδοκάται να είναι μεγάλη οπότε υπάρχει πιθανή αλλαγή κατάστασης στην περιοχή του παραθύρου. Στο [21] περιγράφεται η συνολική διαδικασία του τεστ όπου η μηδενική υπόθεση H_0 είναι η ύπαρξη μονοτροπικότητας και η εναλλακτική H_1 ύπαρξη πολυτροπικότητας. Η μηδενική υπόθεση απορρίπτεται όταν τουλάχιστον ένα από τα διανύσματα αποστάσεων παρουσιάζουν πολυτροπικότητα. Ο ισχυρισμός για τον αν υπάρχει πολυτροπικότητα, δηλαδή απορρίπτεται η H_0 με βαθμό σημαντικότητας του τεστ α , είναι να ισχύει $p_{value} \geq \alpha$ όπου p_{value} δηλώνει το ποσοστό σημαντικότητας του τεστ και υπολογίζεται ως $p_{value} = \#[\max_i(\text{dip}(D_i)) \leq \text{dip}(U_r)]/m, r = 1 \dots m, U_r \sim U(0,1)$. Στην πράξη ελέγχουμε αν $\text{dip} \geq \max_r(\text{dip}(U^r))$ όπου απορρίπτεται η μηδενική υπόθεση H_0 .

3.4.2 Πίνακας αποστάσεων μεταξύ μέσων όρων και σημείων

Λόγω του ότι η εφαρμογή του dip test στον πίνακα αποστάσεων μεταξύ των σημείων του παραθύρου είναι ακριβή διαδικασία για μεγάλο μήκος παραθύρου εφαρμόσαμε μια παραλλαγή της παραπάνω στρατηγικής. Συγκεκριμένα σε κάθε παράθυρο υπολογίζουμε τον πίνακα αποστάσεων μεταξύ των μέσων όρων των δειγμάτων των ημιπαραθύρων και των σημείων του συνολικού παραθύρου.

$$D_{i,j} = \|\bar{y}_i - y_j\|_2 \quad (3.6)$$

$$i = 1,2, j = a \dots b, \bar{y}_1 = \bar{y}_{a \dots t}, \bar{y}_2 = \bar{y}_{t+1 \dots b}$$

Οπότε εφαρμόζεται το dip test για δύο μόνο διανύσματα αποστάσεων και δεχόμαστε την μεγαλύτερη από τις δύο dip value, η διαδικασία έχει τον ίδιο στόχο με την προηγούμενη στρατηγική μόνο που η πολυπλοκότητα είναι προφανώς μικρότερη.

$$d(t) = \max(dip(D_1^t), dip(D_2^t)) \quad (3.7)$$

t κέντρο του παραθύρου.

3.5 Σφάλμα Ανακατασκευής Μέσω PCA

Σ' αυτή την υποενότητα θα συζητηθεί μια τεχνική που βασίζεται στο κυλιόμενο παράθυρο και προσπαθεί να εντοπίσει σημεία αλλαγής ανακατασκευάζοντας την ροή y_i $i = 0 \dots T$ $y_i \in \mathbb{R}^d$. Μια διαφορετική ερμηνεία στο πρόβλημα είναι ο εντοπισμός σημείων που βρίσκονται σε 'περιοχή' της ροής με μεγάλη ανομοιομοφία το οποίο μπορεί να μεταφραστεί στο ότι τα δείγματα στην 'περιοχή' αυτή δεν είναι γραμμικά εξαρτημένα και υπάρχει αλλαγή κατάστασης. Οπότε ένας μηχανισμός που θα εντοπίζει αυτού του είδους τις 'περιοχές' αυτόματα θα εντοπίζει και τα πιθανά σημεία αλλαγής. Ένας συνδυασμός της SVD μεθόδου με το Bottom-Up αλγόριθμο για τον εντοπισμό των σημείων αλλαγής [22] μειώνει την διάσταση της ροής και κατασκευάζει μια μετρική με βάση την SVD ανάλυση την οποία θεωρεί ως κριτήριο συνένωσης δυο

τμημάτων. Γενικώς η γραμμική μείωση διάστασης αφαιρεί τον θόρυβο των δειγμάτων των τμημάτων κάτι το οποίο βοηθάει στην σύγκριση δυο τμημάτων ως προς την ομοιογένεια τους. Παρόμοια στρατηγική ακολουθήθηκε και στην δική μας εργασία με την διαφορά ότι χρησιμοποιήσαμε PCA ανάλυση σε συνδιασμό με την μέθοδο του κυλιόμενου παραθύρου. Η τεχνική εξάγει ανωμαλίες σε ένα σύνολο θεωρώντας γραμμικές εξαρτήσεις μεταξύ σημείων που ανήκουν στην ίδια κατάσταση της ροής. Η ιδέα είναι η εξής θεωρούμε την ανακατασκευή της ροής χρησιμοποιώντας την τεχνική του κυλιόμενου παραθύρου σταθερού μήκους.

$$Y_t = Win_{Stack}(y_{a..b}) \quad (3.8)$$

$Y_t \in \mathbb{R}^{d*s}$, d διάσταση αρχική ροής, s μέγεθος παραθύρου Win_{Stack} .

Οπότε η ροή ανακατασκευάζεται στον Y χώρο όπου κάθε Y_t δείγμα αποτελείται από τα δείγματα του παραθύρου $y_{a..b}$ σε μορφή διανύσματος στην θέση t . Το παράθυρο Win_{Stack} λειτουργεί ως συνάρτηση δειγματοληψίας για την κατασκευή του χαρακτηριστικού χώρου Y . Επομένως εφαρμόζοντας γραμμική μείωση διάστασης (PCA) προβάλλοντας τα δείγματα στον υπόχωρο που παράγεται από τα ιδιοδιανύσματα που αντιστοιχούν στις k μεγαλύτερες ιδιοτιμές όπου $k = \lfloor \frac{d*s}{10} \rfloor$. Με άλλα λόγια μειώνουμε την διάσταση των Y_t δειγμάτων στο 10% της αρχικής τους $D = d * s$.

$$\max_{w,\lambda} ((C^T C) * w - \lambda * w) \Rightarrow Eigen(C^T C) \Rightarrow \lambda_1 \dots \lambda_k, w_1 \dots w_k \quad (3.9)$$

όπου $C = (Y - \bar{Y})'(Y - \bar{Y})$ και $Z = Y * W, Z_t \in \mathbb{R}^k$.

Στην συνέχεια προβάλλουμε τα Z στα $\tilde{Y}, \tilde{Y} = Z * W^T$ ανακατασκευάζοντας τα αρχικά διανύσματα Y . Η PCA ανάλυση έχει καλύτερα αποτελέσματα σε σύνολα όπου τα δεδομένα είναι γραμμικά εξαρτημένα μεταξύ τους. Για να δούμε πόσο καλή είναι η ανάλυση υπολογίζουμε το σφάλμα ανακατασκευής της PCA υπολογίζοντας την $\|\cdot\|_p$ μεταξύ των ανακατασκευασμένων \tilde{Y}_t και των αρχικών δειγμάτων Y_t .

$$d(t) = \|Y_t - \tilde{Y}_t\|_2 \quad (3.10)$$

Με τον παραπάνω τρόπο κατασκευάζουμε τη χρονοσειρά ανομοιογένειας $d(t)$ βασιζόμενη στα σφάλματα ανακατασκευής της PCA. Προφανώς το σφάλμα θα είναι μεγάλο όταν στο παράθυρο χαθούν οι γραμμικές εξαρτήσεις μεταξύ των σημείων και υπάρξει ανομοιομορφία ή και κάποιου είδους θόρυβος. Πρέπει να τονιστεί ότι η μετρική αυτή εφαρμόζεται για πρώτη φορά για τον εντοπισμό των σημείων αλλαγής. Ένας άλλος τρόπος εκτίμησης του βαθμού γραμμικής εξάρτησης των δεδομένων της ροής είναι να εφαρμόσουμε τα γραμμικά αυτοπαλινδρομικά μοντέλα μέσω Least Squares αναλυτικής λύσης όπου για κάθε μονοδιάστατο σήμα έχουμε την πρόβλεψη $\hat{y}_{t,j} = b_0 + \sum_{i=1}^m b_i y_{t-i,j} + \varepsilon_t, \forall j = 1 \dots d$, όπου d διάσταση αρχικής ροής. Σε περιοχές όπου το σφάλμα $\|y_t - \hat{y}_t\|_p$ των προβλέψεων από τα πραγματικά σημεία είναι μεγάλο προφανώς θα υπάρχει απότομη αλλαγή.

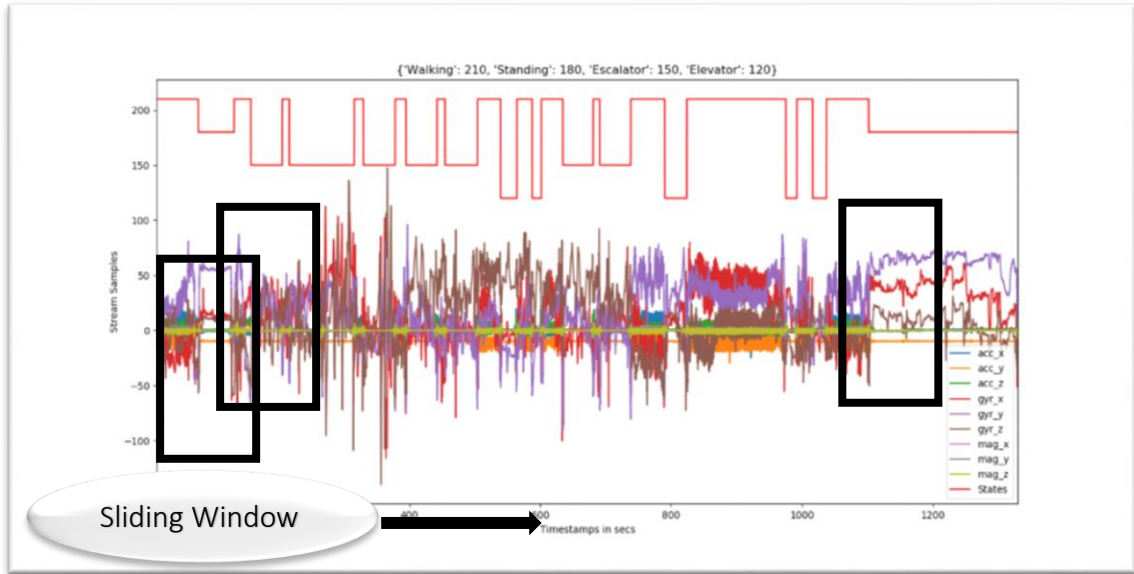
3.6 Γενική Περιγραφή Αλγορίθμου Κυλιόμενου Παραθύρου

Είσοδος: $y_i, i = 0 \dots T$, μέγεθος κυλιόμενου παραθύρου s , $step$ βήμα ολίσθησης

Έξοδος: ροή ανομοιογένειας $d(t)$

1. Αρχικοποίηση των ορίων του αρχικού παραθύρου $a = 0, b = s, t = \frac{s}{2}$
2. Εφόσον $b < T$ κάνε
3. $d(t) = Win_{sliding}(y_{a..b})$
4. $a = a + step, b = b + step, t = a + \frac{s}{2}$
5. Πήγαινε βήμα 2 εφόσον ισχύει η συνθήκη

Στα δείγματα που εφαρμόστηκε ο αλγόριθμος το βήμα ολίσθησης $step$ είναι 1 και το εύρος τιμών του μήκους του κυλιόμενου παραθύρου s είναι [26,2000].



Σχήμα 3.6 Σχηματική αναπαράσταση του αλγορίθμου του κυλιόμενου παραθύρου.

Εφόσον γνωρίζουμε τον αριθμό των σημείων \hat{K} και έχουμε υπολογίσει την ροή ανομοιογένειας $d(t)$ στην συνέχεια εντοπίζουμε τα σημεία \hat{t} που αντιστοιχούν στις $|\hat{K}|$ μεγαλύτερες τιμές της ροής ανομοιογένειας d ,

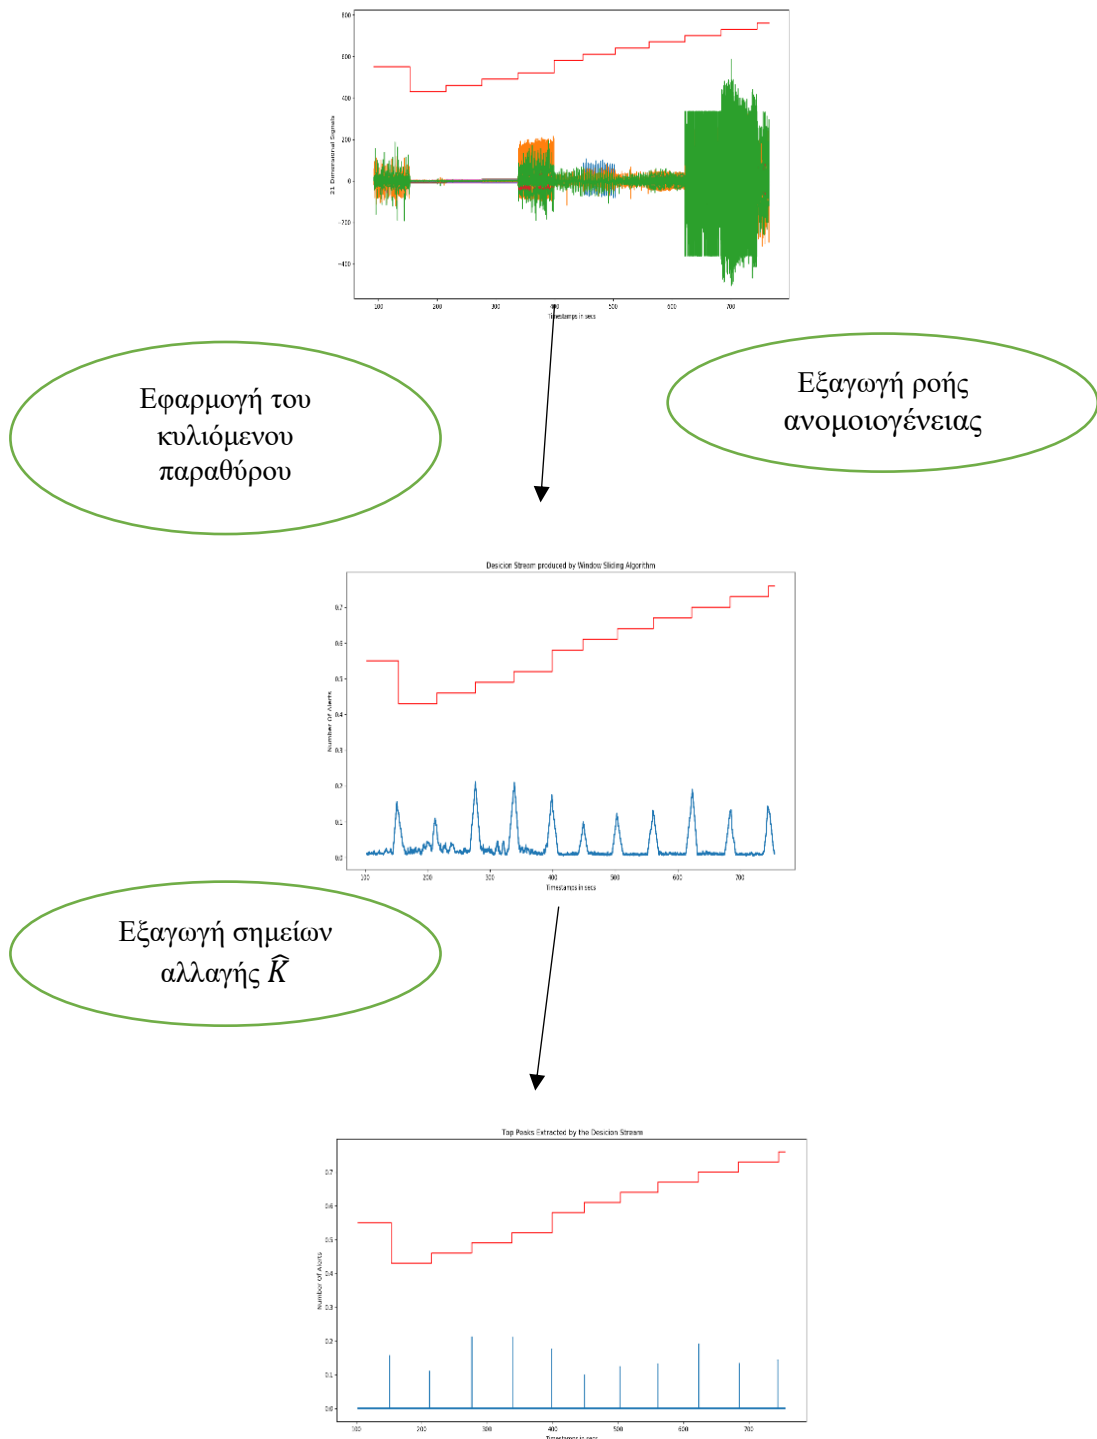
$$\hat{K} = \underset{|\hat{R}|, t}{\operatorname{argmax}}(d(t)) \quad (3.11)$$

Λαμβάνουμε υπόψιν ότι τα σημεία $\{\hat{t}_1 \dots, \hat{t}_{|\hat{R}|}\}$ απέχουν μεταξύ τους τουλάχιστον 6.5 secs. Σε περίπτωση έλλειψης κατωφλίου μ_0 η μέθοδος δεν μπορεί να λύσει το πρόβλημα (2.3), δηλαδή όταν το πλήθος των υποψήφιων σημείων αλλαγής \hat{K} δεν δίνεται.

Το βασικό πλεονέκτημα της μεθόδου του κυλιόμενου παραθύρου είναι η υψηλή ταχύτητα ως προς την κύρια διαδικασία, την ολίσθηση του παραθύρου, που είναι γραμμική ως προς το πλήθος της ροής $O(T)$. Προφανώς η επιλογή της κατάλληλης μετρικής παίζει σημαντικό ρόλο στην ταχύτητα και επίδοση.

Το κύριο χαρακτηριστικό του αλγορίθμου είναι ότι προσπαθεί να δώσει μια εκτίμηση για τα πιθανά σημεία αλλαγής επικεντρώνοντας στην περιοχή κάθε σημείου t ανεξάρτητα στην ροή αγνοώντας την κατανομή προηγούμενων σημείων από το τρέχον. Κύριο μειονέκτημα είναι η εξάρτηση από την παράμετρο s (μέγεθος του παραθύρου)

που πρέπει να ρυθμιστεί απ' τον χρήστη σε κάθε περίπτωση όπως επίσης και ο καθορισμός του πλήθους του συνόλου των εκτιμώμενων σημείων αλλαγής \hat{K} . Αυτό δημιουργεί προβλήματα γενίκευσης της μεθόδου σε διαφορετικές ροές.



Σχήμα 3.7 Βήματα εξαγωγής των σημείων αλλαγής μέσω του αλγορίθμου του κυλιόμενου παραθύρου

ΚΕΦΑΛΑΙΟ 4.

ΑΛΓΟΡΙΘΜΟΣ ΑΥΞΑΝΟΜΕΝΟΥ ΠΑΡΑΘΥΡΟΥ

4.1 Περιγραφή Αλγορίθμου

Δοθέντων των μειονεκτημάτων του αλγορίθμου του κυλιόμενου παραθύρου σταθερού μήκους στην παρούσα εργασία προσπαθήσαμε να εκμεταλλευτούμε τις ιδιότητες του στατιστικού *dip test* [5] και να αλλάξουμε τα κριτήρια εντοπισμού των σημείων αλλαγής. Παρόμοια εφαρμογή έγινε για την στατιστική επεξεργασία εικονοσειρών [21] όπου παράθυρο σταθερού μήκους ολισθάνει σε μια ροή εικόνων και με βάση το κριτήριο πολυτροπικότητας των αποστάσεων των διανυσμάτων χρώματος του παραθύρου εκτιμούσε τις εικόνες κλειδιά της ροής (*key frames*) με στόχο την κατασκευή μιας περίληψης του βίντεο. Στην δική μας περίπτωση η ιδέα είναι ίδια με την παραλλαγή ότι το παράθυρο δεν ολισθαίνει αλλά μετακινεί το δεξί του άκρο b . Η ιδέα είναι ο αλγόριθμος να εντοπίζει τα σημεία *online* αξιοποιώντας τις ιδιότητες του στατιστικού *dip test* και την δομή του προβλήματος.

4.1 Περιγραφή Αλγορίθμου

Ο αλγόριθμος ξεκινάει απ' την αρχή της ροής και αρχικοποιεί τα αρχικά όρια $[a, b]$ $a = 0, b = s_0$ του αυξανόμενου παραθύρου Win_{inc} με μήκος $s_0 = b - a$, οπότε

αμέσως προκύπτει η πρώτη παράμετρος που πρέπει να ρυθμιστεί, το αρχικό μέγεθος s_0 του παραθύρου.

4.1.1 Έλεγχος Πολυτροπικότητας του Παραθύρου

Αφού γίνει η αρχικοποίηση, στο παράθυρο εφαρμόζεται το στατιστικό τεστ *dip test* που ελέγχει αν ισχύει η μηδενική υπόθεση H_0 που δηλώνει την ύπαρξη μονοτροπικότητας ή η εναλλακτική υπόθεση H_a ύπαρξη πολυτροπικότητας στα διανύσματα αποστάσεων του παραθύρου. Το πρώτο βήμα του ελέγχου είναι ο υπολογισμός της στατιστικής τιμής *dip value* που δηλώνει την πιθανότητα πολυτροπικότητας στο δείγμα. Η διαδικασία είναι ίδια με αυτή που περιγράφηκε στην υποενότητα 3.4 όπου υπολογιζόταν οι δύο *dip values* των γραμμών του πίνακα αποστάσεων $D \in \mathbb{R}^{2 \times size}$ μεταξύ των μέσων όρων των ημιπαραθύρων και των δειγμάτων του παραθύρου (3.4.2) σταθερού μήκους όπου δεχόμαστε την μεγαλύτερη τιμή

$$dip_{val} = \max(dip(D_1), dip(D_2)) \quad (4.1)$$

Εφόσον υπολογιστεί η τιμή dip_{val} του τρέχοντος παραθύρου Win_{inc} εφαρμόζεται η διαδικασία ελέγχου της πολυτροπικότητας στο σύνολο των δειγμάτων του παραθύρου. Η μηδενική υπόθεση H_0 απορρίπτεται σε περίπτωση που η τιμή dip_{val} είναι μεγαλύτερη απ' τις *dip values* 1000 τυχαίων και ομοιόμορφα κατανομημένων δειγμάτων U^r (μεγέθους ίδιου με του τρέχον παραθύρου Win_{inc}) στο διάστημα (0,1), ($r = 1 \dots 1000$), που προκύπτουν από διαδικασία προσομοίωσης. Όπως αναφέρθηκε στην υποενότητα (3.4) η ακραία μορφή μονοτροπικότητας των δεδομένων είναι η ομοιόμορφη. Οπότε τιμές του dip_{val} που ξεπερνούν την μεγαλύτερη *dip value* των 1000 ομοιόμορφων δειγμάτων υποδεικνύουν πολυτροπικότητα με 100% ποσοστό εμπιστοσύνης.

$$H_0: \text{απορρίπτεται για } dip_{val} \geq \max_r(dip(U^r)) \quad (4.2)$$

όπου $r = 1 \dots 1000$.

Για υπολογιστικούς λόγους και λόγους συμφωνίας των ελέγχων το αποτέλεσμα του μεγαλύτερου απ' τα dip values της προσομοίωσης για όλα τα πιθανά μεγέθη παραθύρου s που προκύπτουν στην διαδικασία αποθηκεύεται για χρήση σε κάθε στατιστικό έλεγχο.

4.1.2 Κριτήριο Βέλτιστης Κατάτμησης

Εφόσον γίνει ο έλεγχος πολυτροπικότητας του τρέχοντος παραθύρου Win_{Inc} ξεκινάει το δεύτερο βήμα της διαδικασίας. Αν η μηδενική υπόθεση H_0 απορριφθεί ο αλγόριθμος θεωρεί ότι μέσα στο τρέχον αυξανόμενο παράθυρο Win_{Inc} υπάρχει πιθανό σημείο αλλαγής j . Σ' αυτή την περίπτωση εφαρμόζουμε το κριτήριο επιλογής του κατάλληλου εκείνου σημείου το οποίο θεωρείται σημείο αλλαγής \hat{t} . Για να βρεθεί αυτό το σημείο στο τρέχον δείγμα του τρέχοντος παραθύρου εντοπίζουμε εξαντλητικά στο δείγμα το σημείο j για το οποίο αν διαχωριστεί το δείγμα σε δύο τμήματα $y_{a...j}$ και $y_{j+1...b}$ θα ελαχιστοποιείται το σφάλμα ομαδοποίησης των αντίστοιχων τμημάτων που προκύπτουν

$$\hat{t} = \min_j \left(\sum_{i=a}^j \|\bar{y}_{a...i} - y_i\|_2 + \sum_{k=j+1}^b \|\bar{y}_{k...b} - y_k\|_2 \right) \quad (4.3)$$

όπου a, b άκρα του παραθύρου Win_{Inc} , $j = a + 1, \dots, b - 1$.

Με άλλα λόγια επιλέγουμε το υποψήφιο σημείο αλλαγής το οποίο διαχωρίζει το παράθυρο σε δύο ομοιόμορφα τμήματα. Η διαδικασία είναι ίδια με αυτή του Top Down αλγορίθμου για την εύρεση του πρώτου σημείου αλλαγής στην ροή. Σε περίπτωση που δεν απορριφθεί η μηδενική υπόθεση, το παράθυρο Win_{Inc} αυξάνεται κρατώντας το αριστερό άκρο a σταθερό και αυξάνοντας το δεξί άκρο b κατά s_0 , $b = b + s_0$.

Όσο στο δείγμα του τρέχοντος αυξανόμενου παραθύρου Win_{Inc} δεν υπάρχει πολυτροπικότητα και το μήκος του $s_{current}$ ξεπεράσει ένα κατώφλι s_{max} όπου $s_{max} = 10 * s_0$, το παράθυρο συνεχίζει ολισθαίνοντας στην ροή με σταθερό μήκος οπότε μετακινούνται και το δεξί και το αριστερό άκρο a, b κατά s_0 : $a = a + s_0$ και $b = b +$

s_0 . Με αυτό τον τρόπο το παράθυρο σταματάει να εξαρτάται από δείγματα που είναι πολύ πίσω στο παρελθόν της ροής.

4.1.3 Εύρεση Μονοτροπικού Παραθύρου

Εφόσον ο αλγόριθμος έχει εντοπίσει το καλύτερο σημείο κατάτμησης j στο πολυτροπικό δείγμα εντός του αυξανόμενου παραθύρου (το οποίο j θεωρείται σημείο αλλαγής) ξεκινάει καινούργιο παράθυρο με μήκος s_0 και αρχή a το σημείο κατάτμησης j . Το παράθυρο ολισθαίνει μέχρι να εντοπιστεί το επόμενο μονοτροπικό δείγμα. Εφόσον εντοπιστεί μονοτροπικό δείγμα το παράθυρο (βήμα 1) αρχίζει να αυξάνεται εφαρμόζοντας τους αντίστοιχους στατιστικούς ελέγχους που περιγράψαμε παραπάνω. Η τεχνική αυτή επίσης εφαρμόστηκε στην περίληψη βίντεο [21] με την ιδέα ότι εφόσον εντοπισθεί το σημείο αλλαγής δείγματα που βρίσκονται μετέπειτα του σημείου αλλαγής j να είναι πιθανώς πολυτροπικά διότι το σύστημα μπορεί να μην έχει ακόμα επέλθει σε κατάσταση ‘ηρεμίας’. Ο αλγόριθμος αυξανόμενου παραθύρου έχει ως εξής:

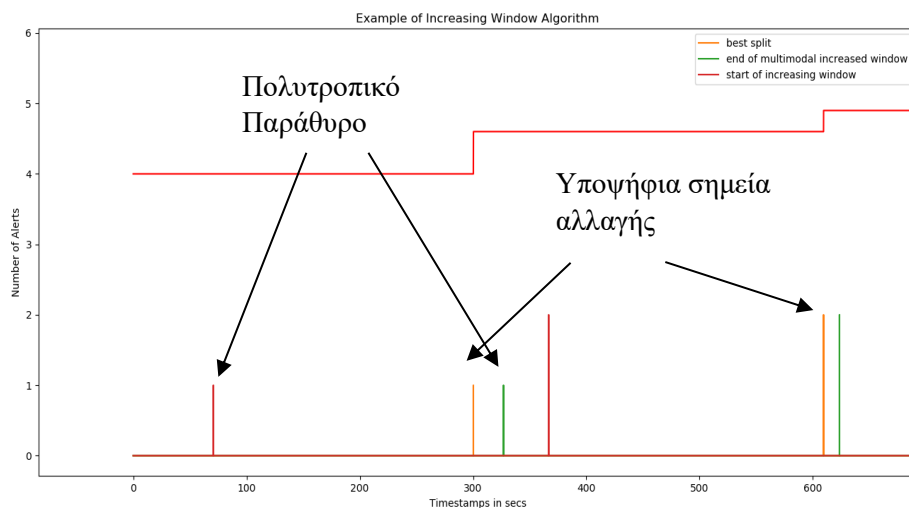
Είσοδος: y_i , $i = 0 \dots T$, αρχικό μήκος αυξανόμενου παραθύρου s_0 , βήμα αύξησης παραθύρου $step$, μέγιστο μήκος αυξανόμενου παραθύρου s_{max} .

Έξοδος: σύνολο υποψήφιων σημείων αλλαγής $\hat{K} = \{\hat{t}_1, \hat{t}_2, \dots, \hat{t}_R\}$.

1. Αρχικοποίηση των ορίων του παραθύρου Win_{Inc} $a = 0, b = s_0$,
 $\hat{K} = \{\}, s_{current} = s_0$.
2. Εφόσον $b < T$:
3. Έλεγχος της H_0 υπόθεσης (ύπαρξη μονοτροπικότητας) στο $y_{a\dots b}$.
4. Αν H_0 απορριφθεί κάνε
 - a. $\hat{t} = \min_j (\sum_{i=a}^j \|\bar{y}_{a\dots i} - y_i\|_\rho + \sum_{k=i+1}^b \|\bar{y}_{k\dots b} - y_i\|_\rho)$, $\hat{K} = \hat{K} \cup \{\hat{t}\}$.
 - b. $a = a + j, b = a + s_0$
 - c. Όσο η μηδενική υπόθεση H_0 του $y_{a\dots b}$ απορρίπτεται κάνε:
Ολίσθηση παραθύρου $a = a + step, b = b + step$.
 - d. Αλλιώς:
 $b = b + step$ και πήγαινε βήμα 3

5. Αν η υπόθεση H_0 δεν απορριφθεί έλεγξε
 - a. Αν $s_{current} \geq s_{max}$ κάνε
Ολίσθηση παραθύρου $a = a + step, b = b + step$.
 - b. Αλλιώς
Αύξηση παραθύρου $b = b + step$
6. $s_{current} = b - a$
7. Πήγαινε στο βήμα 3 εφόσον ισχύει η συνθήκη του βήματος 2.


Στα πειράματα που υλοποιήσαμε τον αλγόριθμο η παράμετρος του βήματος $step$ είναι ίση με το αρχικό μήκος του παραθύρου s_0 , και το μέγιστο παράθυρο s_{max} είναι 10 φορές μεγαλύτερο του αρχικού μήκους s_0 .



Σχήμα 4.1 Απεικόνιση των περιπτώσεων πολυτροπικότητας του βήματος 4 του αλγορίθμου αυξανόμενου παραθύρου.

Ο αλγόριθμος λειτουργεί online και εντοπίζει τα υποψήφια σημεία αλλαγής σε πραγματικό χρόνο το οποίο είναι το κύριο πλεονέκτημα του. Ο κύριος κορμός του αλγορίθμου βασίζεται στον έλεγχο της πολυτροπικότητας των αποστάσεων των δειγμάτων του παραθύρου μέσω του στατιστικού dip test κάτι το οποίο δίνει την ικανότητα στον αλγόριθμο να γενικευτεί για οποιοδήποτε δείγμα σημάτων. Το μόνο

μειονέκτημα είναι ότι υπάρχει περιορισμός σε ότι αφορά την υλοποίηση μεθόδων προεπεξεργασίας των σημάτων όπως DFT και Autoencoders (βλ. Κεφ 5). Η μόνη προεπεξεργασία που υλοποιήσαμε στα πειράματα ήταν αυτής της Z κανονικοποίησης στα δείγματα κάθε παραθύρου Win_{Inc} πριν τον έλεγχο της H_0 υπόθεσης. Οι διαδικασίες προεπεξεργασίας για κάθε αλγόριθμο θα αναφερθούν εκτενώς στο επόμενο κεφάλαιο (Κεφ.5 υποενότητα, 5.1).



Σχήμα 4.2 Σχηματική αναπαράσταση του αλγορίθμου του αυξανόμενου παραθύρου.

ΚΕΦΑΛΑΙΟ 5.

ΕΦΑΡΜΟΓΗ ΣΕ ΡΟΕΣ ΔΕΔΟΜΕΝΩΝ ΑΠΟ ΑΙΣΘΗΤΗΡΕΣ ΚΙΝΗΣΗΣ

5.1 Προεπεξεργασία Σημάτων

5.2 Τρόπος Αξιολόγησης

5.3 Πειραματική Μελέτη

5.4 Συμπερασματολογία

Στην ενότητα αυτή θα αναφέρουμε τα αποτελέσματα των δύο αλγορίθμων (Κεφ. 3,4) που εφαρμόστηκαν σε διάφορες ροές. Μια απ' τις κύριες εφαρμογές των μεθόδων εντοπισμού σημείων αλλαγής σε μια ροή είναι και ο εντοπισμός σημείων αλλαγής κατάστασης ανθρώπινων δραστηριοτήτων (HAR; η κάθε κατάσταση περιγράφεται από μια ή περισσότερες συσκευές όπου κάθε συσκευή είναι ενσωματωμένη με αισθητήρες οι οποίοι παράγουν πολυδιάστατα σήματα. Στα παραδείγματα που μελετήσαμε συνήθως η διάσταση κάθε σήματος που παράγεται απ' τους αισθητήρες είναι 3 (3-D). Οι ροές κατηγοριοποιήθηκαν με βάση τα χαρακτηριστικά των συσκευών που έχουν ενσωματωθεί σε κάθε χρήστη. Επίσης σε κάθε διαφορετική συσκευή υπάρχει διαφορετική ποσότητα και ποικιλία αισθητήρων. Στην διάθεση μας είχαμε τρεις κατηγορίες συνόλων με διαφορετικό πλήθος και ποικιλία αισθητήρων που κατέγραφαν τις δραστηριότητες διάφορων χρηστών. Σε κάποιες έρευνες τίθεται το ζήτημα της σωστής τοποθέτησης των συσκευών καταγραφής [23] με στόχο την βέλτιστη καταγραφή, κάτι το οποίο παίζει ρόλο στην απόδοση των αλγορίθμων.

5.1 Προεπεξεργασία Σημάτων

Η δειγματοληψία των σημάτων γίνεται με σταθερό μέσο ρυθμό των 57,5 Hz (0.023 secs) για όλα τα σύνολα δεδομένων δηλαδή η μέση χρονική διαδοχική άφιξη των στιγμιοτύπων είναι 0.023 sec. Σε κάποιες περιπτώσεις ο ρυθμός δειγματοληψίας ήταν μεγαλύτερος από 500 Hz οπότε προέκυπταν τεράστιες ροές (μεγέθους $1.5 \cdot 10^6$) κάτι το οποίο δυσκόλυνε την μελέτη. Το πρόβλημα λύθηκε με μεθόδους υπολογίζοντας τον μέσο όρο ανά 10 δείγματα.

$$y_j = \bar{y}_{i \dots i+10} \quad (5.1)$$

$$i = 0 \dots T - 10, j = i + 5.$$

ώστε να προκύπτουν δείγματα με ρυθμό άφιξης 50 Hz. Η σχέση (5.1) εφαρμόζεται σε περιπτώσεις ροών μήκους $T \gg 10^6$. Λόγω της ανομοιομορφίας των ροών ως προς τα χαρακτηριστικά τους είναι λογικό τα αποτελέσματα των μεθόδων να διαφέρουν. Όπως θα δούμε ο εντοπισμός σημείων αλλαγής καταστάσεων ανθρώπινων δραστηριοτήτων στην περίπτωση που η καταγραφή των κινήσεων γίνεται από πολλούς αισθητήρες είναι προφανώς πιο επιτυχημένη σε σχέση με την καταγραφή απ' σχετικό μικρό πλήθος αισθητήρων λόγω ότι υπάρχει περισσότερη πληροφορία προς επεξεργασία. Επίσης παίζει σημαντικό ρόλο στην απόδοση των μεθόδων και ο θόρυβος που ενδεχομένως προέρχεται απ' τους αισθητήρες. Για τους λόγους αυτούς εφαρμόσαμε διάφορες τεχνικές προεπεξεργασίας των σημάτων και έπειτα τροφοδοτήσαμε τις μεθόδους με τα επεξεργασμένα δείγματα. Θα παρουσιαστούν τα αποτελέσματα και η απόδοση κάθε μετρικής, που αναφέρθηκε στο Κεφ. 3, για καθεμία απ' τις περιπτώσεις προεπεξεργασίας. Θα εξεταστεί και η περίπτωση που δεν έγινε καμία προεπεξεργασία στα αρχικά δείγματα. Επίσης θα παρουσιαστούν και τα αποτελέσματα του αλγορίθμου του αυξανόμενου παραθύρου (Κεφ 4) που εφαρμόστηκε στα μη επεξεργασμένα αλλά και κανονικοποιημένα δείγματα των παραθύρων που δημιουργούνται.

Για την εφαρμογή του αλγορίθμου κυλιόμενου παραθύρου σταθερού μήκους ο οποίος επεξεργάζεται την ροή offline θεωρήσαμε τρία είδη προεπεξεργασίας: την Z κανονικοποίηση (Z Normalization) σε κάθε μονοδιάστατο σήμα, Fourier μετασχηματισμούς στον χρόνο (DFT), και εξαγωγή χαρακτηριστικών μέσω

αυτοκωδικοποιητών (Autoencoders) στα δειγματικά παράθυρα. Μέσω των μεθόδων προεπεξεργασίας που οδηγούν στην εξαγωγή χαρακτηριστικών (Autoencoders και DFT) η μέθοδος θα είναι σε θέση να επεξεργαστεί ποιοτικότερη πληροφορία σε ποσοτικό και ποιοτικό επίπεδο. Η εφαρμογή της κανονικοποίησης έγινε για να επιτευχθεί ισορροπία κλίμακας στις τιμές των δειγμάτων, διότι το εύρος των τιμών μεταξύ των αισθητήρων διαφέρει κατά πολύ.

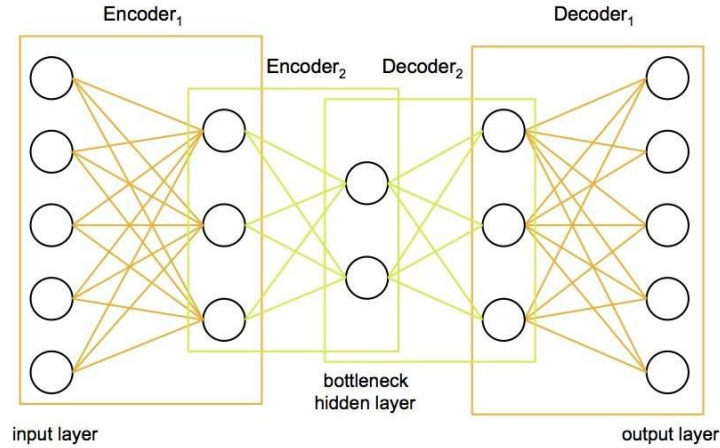
5.1.1 Εξαγωγή Χαρακτηριστικών Μέσω Αυτοκωδικοποιητών

Η εξαγωγή χαρακτηριστικών μέσω της μεθόδου των αυτοκωδικοποιητών (Autoencoders) από τα παραθυρικά δείγματα της ροής στον χρόνο έχει χρησιμοποιηθεί για τον εντοπισμό αλλαγών [24] χρησιμοποιώντας τον αλγόριθμο του κυλιόμενου παραθύρου σταθερού μήκους. Πρόκειται για μια τεχνική μη επιβλεπόμενης μάθησης που επιτυγχάνει μη γραμμικής μείωση διάστασης του χαρακτηριστικού χώρου της ροής που ορίσαμε στη υποενότητα 3.5.

$$Y_t = Win_{Stack}(y_{a..b}) \quad (5.2)$$

όπου $a = 0, \dots, T - s$, $b = s \dots T$, $Y_t \in \mathbb{R}^{d \times s}$, t κέντρο του παραθύρου.

Ο λόγος που δεν χρησιμοποιήθηκε η μέθοδος των κυρίων συνιστωσών (PCA) είναι ότι με την εφαρμογή μιας ισχυρής μεθόδου μη γραμμικής μείωσης διάστασης εξάγουμε χώρο μειωμένης διάστασης Z κρατώντας μεγαλύτερα ποσοστά ενέργειας του αρχικού χώρου Y συγκριτικά με την γραμμική μείωση διάστασης. Οπότε εξάγουμε τον διανυσματικό χώρο Z που περιγράφει κρυμμένες μεταβλητές της περιοχής κάθε κεντρικού σημείου t του παραθύρου δεξιά και αριστερά. Το πρόβλημα της υπερεκπαίδευσης μπορεί να παρουσιαστεί σ' αυτή την προσέγγιση. Η κύρια ιδιότητα αυτού του τύπου των νευρωνικών δικτύων είναι ότι μπορεί να εξάγει μια συμπαγή αναπαράσταση του αρχικού διανυσματικού χώρου Y σε ένα χώρο μειωμένης διάστασης όπου διατηρείται η αρχική πληροφορία των δεδομένων ειδικά στην περίπτωση μη γραμμικών συσχετίσεων.



Σχήμα 5.1 Αρχιτεκτονική αυτοκωδικοποιητών με 3 κρυμμένα επίπεδα.

Η αρχιτεκτονική αυτού του τύπου τεχνητών νευρωνικών δικτύων βασίζεται σε δυο στάδια την κωδικοποίηση και την αποκωδικοποίηση. Λόγω συμμετρίας και τα δύο στάδια αποτελούνται από ίδιο πλήθος στρωμάτων (layers) εκτός του κεντρικού στρώματος όπου βρίσκεται η χαρακτηριστική βάση Z και είναι το μεσαίο στρώμα. Συνήθως επιλέγεται κάθε συμμετρικό στρώμα να έχει ίδιο πλήθος κόμβων με συναρτήσεις ενεργοποίησης μη γραμμικές. Τα στρώματα εισόδου και εξόδου έχουν ίδιο πλήθος κόμβων με συνάρτηση ενεργοποίησης την ταυτοτική $f(x) = x$ απ' την στιγμή που θέλουμε να ελαχιστοποιήσουμε σφάλμα ανακατασκευής δεδομένων. Η κοινή χαρακτηριστική βάση βρίσκεται στο πρώτο στάδιο κωδικοποίησης εφόσον εφαρμοστούν τα πρώτα $k/2$ κρυμμένα επίπεδα στρώματα όπου $k = 7$.

$$E_{nc}(Y) = g(Y, W^{(1)\dots(lk/2)}, b^{(1)\dots(lk/2)}, h) \quad (5.3)$$

όπου, $Y \in \mathbb{R}^{(T-s)xs*d}$, $h(r) = \frac{1}{1+e^{-r}}$ ή $\frac{e^r - e^{-r}}{e^r + e^{-r}}$, $W^{(1)}$ (initialized weighted matrix), $b^{(1)}$ (initialized bias vector).

Όπως και στην περίπτωση της μείωσης διάστασης των κύριων συνιστωσών που αναφέρθηκε στην υποενότητα 3.5 (περίπτωση PCA) επιδιώκουμε η μειωμένη διάσταση να είναι στο 10% της αρχικής, αυτό μπορεί να επιτευχθεί ρυθμίζοντας το πλήθος των κόμβων του μεσαίου στρώματος σε $\lfloor \frac{s*d}{10} \rfloor$. Για να ερμηνεύσουμε όσο καλύτερα και αποδοτικότερα την αρχική δομή στον μειωμένο χώρο, πρέπει να ελαχιστοποιήσουμε το σφάλμα ανακατασκευής

$$\begin{aligned} & \min_{W, W', b, b'} J(W, W', b, b') \\ & = \sum_{i=1}^{n-s} L(Y_i, D_{enc}(E_{nc}(Y_i))) + \lambda \left(\sum_i b_i^2 + \sum_i b_i'^2 \right) \end{aligned} \quad (5.4)$$

όπου $\tilde{Y} = D_{enc}(Z) = g(Y, W^{(\lfloor k/2 \rfloor) \dots (k+1)}, b^{(\lfloor k/2 \rfloor) \dots (k+1)}, h, f), Z = E_{nc}(Y)$.

Η συνάρτηση κόστους ελαχιστοποίησης που χρησιμοποιήθηκε ήταν το μέσο τετραγωνικό σφάλμα (mean square loss) μεταξύ αρχικού Y και ανακατασκευασμένου χώρου \tilde{Y} .

$$L = \sum_{i=1}^{T-s} \frac{\|Y_i - \tilde{Y}_i\|_2}{T-s} \quad (5.5)$$

Ο δεύτερος όρος στην (5.4) είναι ο όρος εξομάλυνσης και συμβάλει στην αποφυγή υπερεκπαίδευσης (overfitting) και η παράμετρος εξομάλυνσης λ , ($\lambda = 10^{-3}$) που ρυθμίζεται απ' τον χρήστη. Οι μέθοδοι ελαχιστοποίησης που εφαρμόστηκαν είναι η στοχαστική βελτιστοποίηση της μεθόδου απότομης καθόδου (Gradient Descent) ή της παραλλαγής της αλγόριθμος Adam. Εφόσον η αντικειμενική συνάρτηση (5.4) μειωθεί κάτω απ' ένα επιθυμητό κατώφλι στην περίπτωση των πειραμάτων 0.005 η διαδικασία τερματίζει. Στην συνέχεια τα βάρη W, b που προκύπτουν απ' την εκπαίδευση στα αρχικά δεδομένα Y , βρίσκουμε την προεπεξεργασμένη ροή

$$Z_t = E_{nc}(Y_t) \quad (5.6)$$

όπου $Z \in \mathbb{R}^{(T-s) \times \lfloor \frac{s+d}{10} \rfloor}$: κέντρο του παραθύρου ανακατασκευής Win_{Stack} .

Πρέπει να σημειωθεί ότι το μέγεθος s του παραθύρου δειγματοληψίας Win_{Stack} της αρχικής ροής είναι $s = 200$ για όλα τα πειράματα.

5.1.2 Εξαγωγή Ενέργειας Σημάτων Μέσω DFT Μετασχηματισμών

Στόχος αυτής της προεπεξεργασίας είναι να εξάγει την ισχύ των συντελεστών Fourier για κάθε μονοδιάστατο σήμα y_i $i = 0 \dots T$, στην ροή για κάθε παράθυρο. Η εφαρμογή του μετασχηματισμού πρέπει να ικανοποιεί την διάταξη των δειγμάτων στον χρόνο. Για τον σκοπό αυτό υπολογίσαμε την ισχύ των συντελεστών Fourier σε κάθε γραμμή του του πίνακα-παραθύρου $Win_{Sample_DFT_Magnitude}(y_{a..b})$, $y_{a..b} \in \mathbb{R}^{s \times d}$ μεγέθους $s = 64$. Η τεχνική είναι παρόμοια με αυτή των Short Discrete Fourier μετασχηματισμών μόνο που στην δική μας εφαρμογή δεν συμβάλουν συντελεστές εξομάλυνσης, όπως παράθυρο Hamming, στον μετασχηματισμό. Οπότε έχουμε την εξής μετατροπή

$$Y_t = Win_{Sample_DFT_Magnitude}(y_{a..b}) = [F * (y_{a..b})]_{Magnitude \text{ per row } i} \quad (5.7)$$

Όπου $a = 0, \dots, T - s$, $b = s \dots T$, $Y_t \in \mathbb{R}^{d \times s}$, $i = 1 \dots d$, $F \in \mathbb{C}^{s \times s}$ πίνακας συντελεστών Fourier, $s = 64$ και t κέντρο του παραθύρου.


Πρέπει να σημειωθεί ότι το μέγεθος του παραθύρου $Win_{Sample_DFT_Magnitude}$, s είναι 64 για όλα τα πειράματα. Μ' αυτή την τεχνική μετασχηματισμού καταφέρνουμε να μην χαθεί η διάταξη των σημείων ως προς τον χρόνο και ο μετασχηματισμένος χώρος Y να περιέχει την ενέργεια του κάθε σήματος του παραθύρου οπότε η διάσταση του Y είναι $\mathbb{R}^{T \times (s \times d)}$.

Οι δύο προηγούμενες τεχνικές προεπεξεργασίας (Autoencoder, DFT) έχουν ως κοινό το ότι βασίζονται στον αλγόριθμο του κυλιόμενου παραθύρου σταθερού μήκους και προσπαθούν να εξάγουν χαρακτηριστικά των σημάτων που θα συμβάλουν στην υψηλότερη απόδοση των μεθόδων εντοπισμού που εφαρμόζονται offline.

5.1.3 Κανονικοποίηση Z

Η τρίτη και τελευταία τεχνική προεπεξεργασίας αφορά την κανονικοποίηση μέσω του Z-statistic κάθε σήματος σ' ολόκληρη την ροή στην περίπτωση του κυλιόμενου παραθύρου και σε κάθε παράθυρο που διαμορφώνεται στον αλγόριθμο του

αυξανόμενου παραθύρου. Η τεχνική έχει νόημα όταν το εύρος των τιμών των σημάτων είναι διαφορετικό μεταξύ τους και δημιουργούνται προβλήματα κλίμακας στην μέθοδο εντοπισμού.



Σχήμα 5.2 Εύρος τιμών του Z-statistic

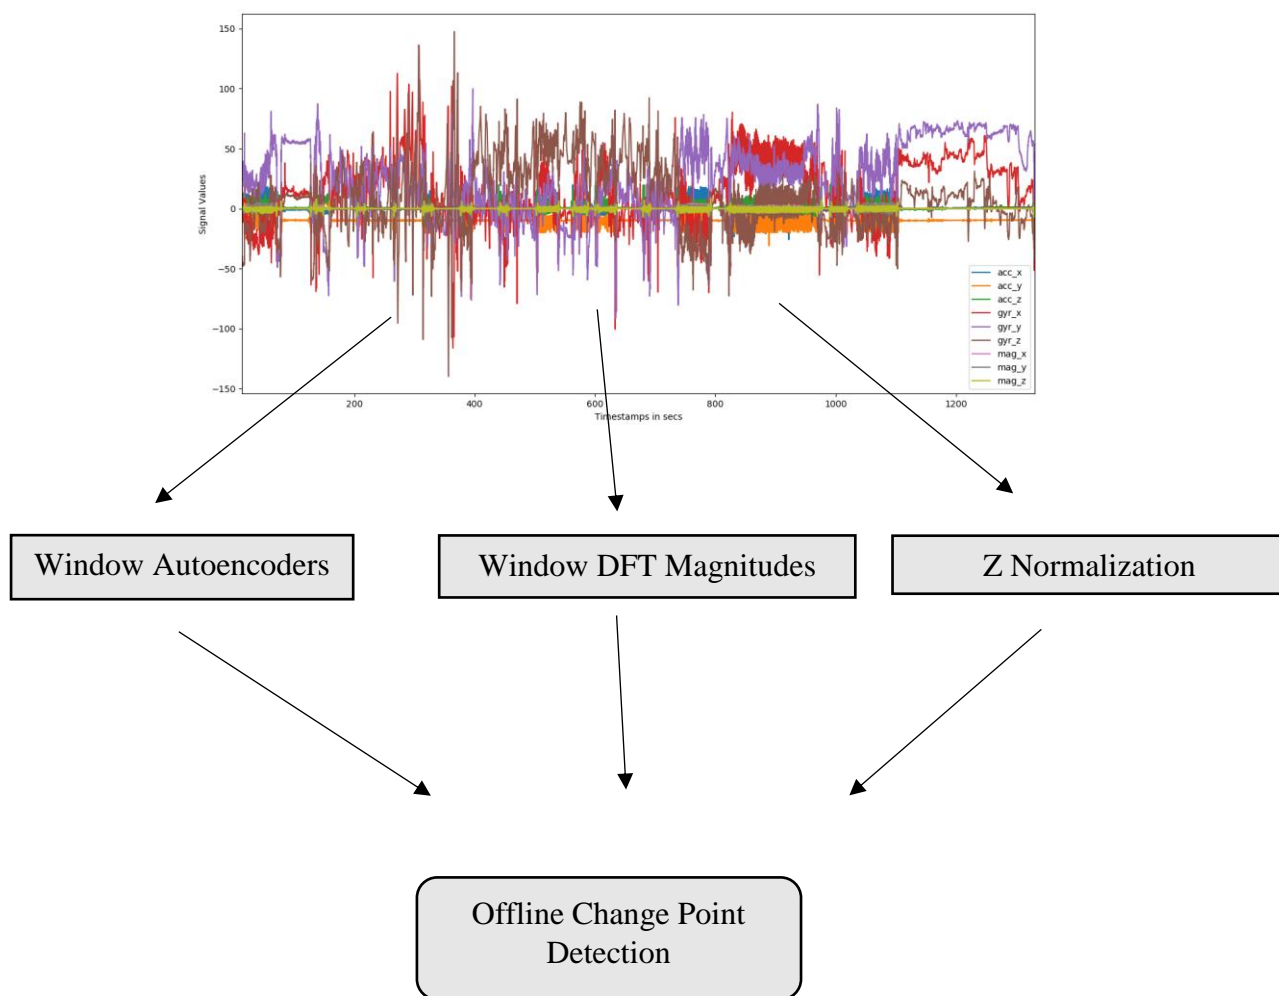
Υπάρχουν περιπτώσεις δειγμάτων όπου αισθητήρες με μεγάλο εύρος τιμών, μπορεί λόγω θορύβου, συγκριτικά με τους υπόλοιπους, ενδεχομένως να ‘καλύπτουν’ την πληροφορία των υπολοίπων και να μην εντοπίζονται σημεία αλλαγής που βασίζονται στις απότομες αλλαγές στις τιμές των αισθητήρων χαμηλού εύρους τιμών. Η Z κανονικοποίηση φέρνει τις τιμές όλων των σημάτων περίπου στο διάστημα [-3,3].

$$Z_{i,l} = \frac{y_{i,l} - \bar{y}_l}{Std(y_l)} \quad (5.8)$$

όπου $l = 1 \dots d, i = 0 \dots T$.

Εφαρμόζοντας την κανονικοποίηση Z σ’ ολόκληρη την ροή έχουμε καλύτερη εικόνα των δεδομένων λαμβάνοντας υπόψιν ολόκληρη την στατιστική κατανομή των δειγμάτων στον χώρο οπότε επιτυγχάνεται πιο ακριβής κανονικοποίηση.

Οι παραπάνω τεχνικές (εκτός της Z κανονικοποίησης) δεν εφαρμόστηκαν για τον αλγόριθμο του δυναμικά αυξανόμενου παράθυρου διότι η μέθοδος εντοπίζει online τα πιθανά σημεία αλλαγής οπότε οι τεχνικές προεπεξεργασίας θα καθυστερούσαν σε υψηλό βαθμό την διαδικασία.



Σχήμα 5.3 Διάγραμμα προεπεξεργασίας

5.2 Τρόπος Αξιολόγησης

Η αξιολόγηση για τον εκάστοτε αλγόριθμο είναι διαφορετική διαδικασία. Στην περίπτωση του κυλιόμενου παραθύρου (Window Sliding) αξιολογούμε την ροή ανομοιογένειας $d(t)$ που παράγεται απ' την εφαρμογή της εκάστοτε μετρικής που αναφέρθηκε στο Κεφ. 3. Για την αξιολόγηση σ' αυτή την περίπτωση θεωρούμε το σύνολο των υποψήφιων σημείων αλλαγής \hat{K} με σταθερό πλήθος $|\hat{K}| = constant$ το οποίο πλήθος δίνεται απ' τον χρήστη. Επομένως εξάγονται τα σημεία που αντιστοιχούν στις $|\hat{K}|$ μεγαλύτερες τιμές της $d(t)$ ροής:

$$\hat{K} = \operatorname{argmax}_{|\hat{K}|=\text{constant}, \hat{t}}(d(\hat{t})) \quad (5.9)$$

όπου $\hat{K} = \{\hat{t}_1, \hat{t}_2, \dots, \hat{t}_{|\hat{K}|}\}$.

και ελέγχουμε το ποσοστό των \hat{K} σημείων που απέχουν στον χρόνο το πολύ 3 secs από κάποιο πραγματικό σημείο t^* : $|t^* - \hat{t}| < \frac{3}{r_{arrival}}$ όπου $r_{arrival}$ είναι ο μέσος ρυθμός άφιξης των στιγμιοτύπων της ροής του δείγματος σε δευτερόλεπτα (secs). Απ' την στιγμή που οι ροές που έχουμε στην διάθεση μάς παρέχουν και το σύνολο των πραγματικών σημείων αλλαγής K και την θέση τους t^* διευκολύνεται η αξιολόγηση. Συνήθως θεωρούμε ότι το πλήθος του συνόλου των υποψήφιων σημείων είναι μεγαλύτερο ίσο του συνόλου των πραγματικών σημείων αλλαγής $|\hat{K}| \geq |K|$.

Όσο αφορά τον αλγόριθμο του αυξανόμενου παραθύρου το σύνολο των υποψήφιων σημείων \hat{K} εκτιμάται αυτόματα απ' την διαδικασία αυτόματα όπως έχει αναφερθεί. Η διαδικασία αξιολόγησης είναι παρόμοια.

5.2.1 Μετρικές Αξιολόγησης

Οπότε και στις δύο περιπτώσεις μεθόδων έχουμε το σύνολο \hat{K} που περιέχει τις θέσεις των υποψήφιων σημείων, επομένως το σύνολο των σωστά εντοπισμένων (*Corrected Detected*) προκύπτει από το υποσύνολο των \hat{K} για τα οποία ισχύει $Corrected\ Detected = \{|t^* - \hat{t}| < \frac{3}{r_{arrival}}: \hat{t} \in \hat{K}, \exists \text{ μοναδικό } t^* \in K\}$ (*CD*). Οι δύο μετρικές [24] που χρησιμοποιήθηκαν για την αξιολόγηση της απόδοσης των αλγορίθμων είναι

$$TPR = \frac{|CD|}{|K|}, \text{ και } FPR = \frac{|\hat{K}| - |CD|}{|\hat{K}|} \quad (5.10)$$

οι οποίες δηλώνουν το ποσοστό των σωστά εντοπισμένων σημείων προς των πραγματικών και το ποσοστό των λανθασμένα εντοπισμένων σημείων. Χρησιμοποιώντας τις μετρικές (5.10) αξιολογούμε κάθε μέθοδο που εφαρμόζεται για κάθε περίπτωση προεπεξεργασίας.

5.3 Πειραματική Μελέτη

Στην πειραματική μελέτη μας επεξεργαστήκαμε ροές με διαφορετική ποικιλομορφία ως προς το σύστημα των αισθητήρων που κατέγραφαν τις ανθρώπινες δραστηριότητες αλλά και τις δραστηριότητες σε κάθε περίπτωση δειγμάτων. Στην διάθεση μας είχαμε τρία σύνολα ροών δεδομένων το CrowdSignals [29] της AlgoSnap, MHealth [26] και HHAR [27]. Τα χαρακτηριστικά των ροών είναι το πλήθος και η ποικιλία των αισθητήρων που χρησιμοποιούνται και η τοποθέτηση τους πάνω στους χρήστες. Πιθανά σημεία τοποθέτησης είναι ο κορμός και τα άκρα του ανθρώπου.



Σχήμα 5.4 Σχηματική αναπαράσταση τοποθέτησης συσκευών αισθητήρων στον χρήστη και δείγμα των δραστηριοτήτων που εκτελεί.

Επίσης οι δραστηριότητες που καταγράφονται διαφέρουν σε κάθε σύνολο, πρέπει να σημειωθεί ότι οι δραστηριότητες είναι ‘χαμηλού’ επιπέδου όπως ‘τρέξιμο, περπάτημα, καθιστική όρθια στάση, ποδηλασία, ορειβασία, ανεβοκατέβασμα σκαλιών’ κλπ. Οι κύριοι αισθητήρες που καταγράφουν ανθρώπινες κινήσεις είναι τρεις το αξελερόμετρο (accelerometer) που καταγράφει κίνηση ως προς τους τρεις άξονες του χώρου x, y, z το γυροσκόπιο (gyroscope) που καταγράφει τις κατευθύνσεις στον χώρο δηλαδή τον προσανατολισμό του ανθρώπου και τέλος το μαγνητόμετρο (magnetometer) το οποίο καταγράφει τις μαγνητικές-βαρυτικές δυνάμεις που δέχεται ο άνθρωπος στον τρισδιάστατο σύστημα. Όλοι οι αισθητήρες έχουν ως σημείο αναφοράς την θέση στην οποία έχουν τοποθετηθεί πάνω στον χρήστη. Στις ροές εφαρμόστηκαν οι αλγόριθμοι

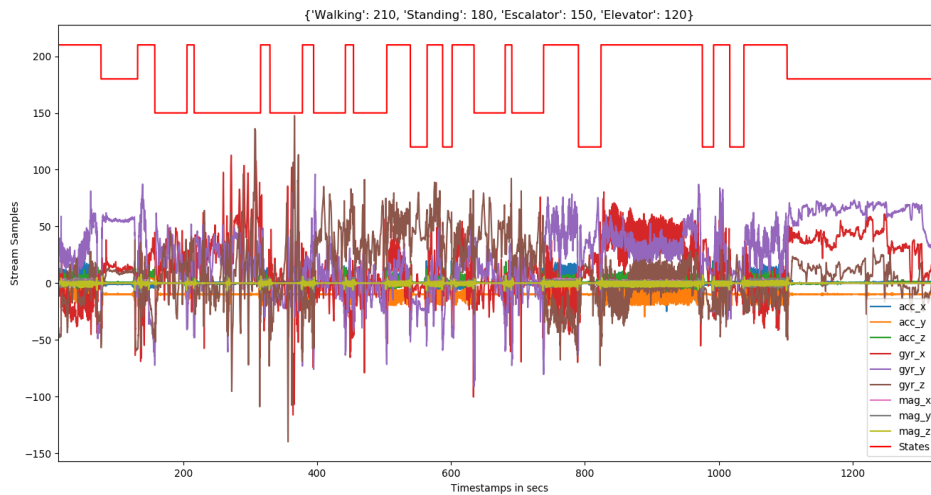
και οι μετρικές που προαναφέρθηκαν στα προηγούμενα κεφάλαια για κάθε πιθανό είδος προεπεξεργασίας.

5.3.1 Περιγραφή Συνόλων Δεδομένων

Στην συνέχεια παρουσιάζεται μια συνοπτική περιγραφή των ροών δεδομένων που εξετάστηκαν. Όπως θα δούμε η απόδοση των μεθόδων εξαρτάται απ' το σύστημα καταγραφής των δραστηριοτήτων.

5.3.1.1 CrowdSignals


Το συγκεκριμένο σύνολο δεδομένων περιέχει καταγραφές (δυο ροές δεδομένων) των δραστηριοτήτων 2 χρηστών. Το σύστημα καταγραφής αποτελείται από μια συσκευή έξυπνου τηλεφώνου (smartphone) ενσωματωμένη σε κάθε χρήστη η οποία εμπεριέχει τριών ειδών αισθητήρες ένα αξελερόμετρο (accelerometer) ένα μαγνητόμετρο (magnetometer) και ένα γυροσκόπιο (gyroscope) δηλαδή η αρχική διάσταση της ροής y_i είναι $d = 9$. Ο μέσος ρυθμός άφιξης $\bar{r}_{arrival}$ μεταξύ δύο καταγραφών είναι 0.01916 secs (47.5 Hz) και το μέσο πλήθος των στιγμιοτύπων των ροών \bar{T} είναι 137655. Το σύνολο των δραστηριοτήτων που εκτελεί ο πρώτος χρήστης είναι 'περπάτημα καθιστική στάση ανεβοκατέβασμα ανελκυστήρα, κυλιόμενων σκαλιών' ενώ ο δεύτερος χρησιμοποιεί μέσα μαζικής μεταφοράς όπως τρένο και λεωφορείου. Πρέπει να σημειωθεί ότι οι δραστηριότητες του δεύτερου χρήστη μπορεί να θεωρηθούν υψηλού επιπέδου.



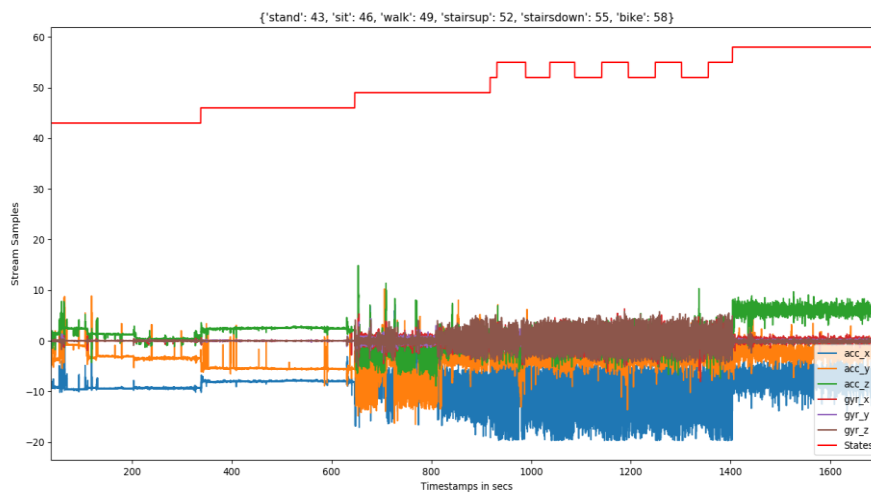
Σχήμα 5.5 Αναπαράσταση ροής σημάτων ενός χρήστη απ’ το Crowdsignals σύνολο.

5.3.1.2 HHAR

Για το συγκεκριμένο σύνολο ροών οι συσκευές καταγραφής των δραστηριοτήτων είναι ένα έξυπνο τηλέφωνο (smartphone) και ένα έξυπνο ρολόι (smartwatch) και το πλήθος των χρηστών που εκτελούν τις δραστηριότητες είναι 9. Η ανάλυση και εφαρμογή των μεθόδων έγινε ξεχωριστά για κάθε συσκευή οπότε προκύπτουν δύο υποσύνολα που αντιστοιχούν σε καθεμία συσκευή η οποία καταγράφει τις δραστηριότητες των 9 χρηστών. Ο διαχωρισμός έγινε για να δοκιμαστούν οι μέθοδοι σε ροές που δεν υπάρχει μεγάλος όγκος διαθέσιμης πληροφορίας από πολλές συσκευές. Κάθε συσκευή είναι ενσωματωμένη με ένα αξελερόμετρο (accelerometer) και ένα γυροσκόπιο (gyroscope) οπότε η διάσταση για κάθε δείγμα y_i είναι $d = 6$. Ο μέσος χρόνος άφιξης μεταξύ δύο καταγραφών $\bar{r}_{arrival}$ είναι 0.0267 secs (65 Hz) και το μέσο πλήθος \bar{T} των ροών είναι 82348. Το σύνολο των δραστηριοτήτων που εκτελούνται είναι ‘ποδηλασία, περπάτημα, τρέξιμο, καθιστική στάση, όρθια στάση, ανέβασμα κατέβασμα σκαλιών’ και είναι ίδιο για όλους τους χρήστες.



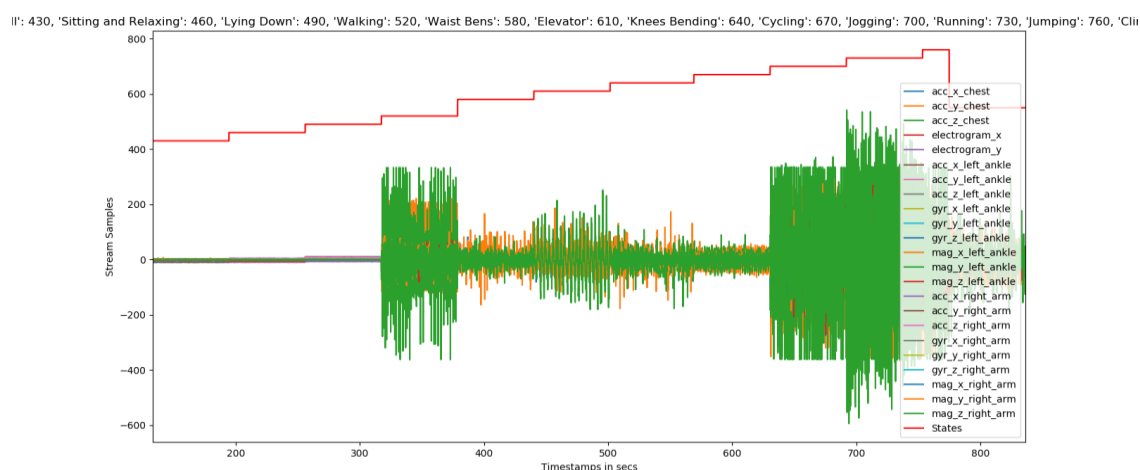
Σχήμα 5.6 Αναπαράσταση ροής σημάτων της συσκευής έξυπνου τηλεφώνου (Phone) ενός χρήστη απ' το σύνολο HHAR.



Σχήμα 5.7 Αναπαράσταση ροής σημάτων της συσκευής έξυπνου ρολογιού (Watch) ενός χρήστη απ' το σύνολο HHAR.

5.3.1.3 MHealth

Η περίπτωση αυτού του συνόλου ροών είναι διαφορετική διότι οι καταγραφές γίνονται από πολλές συσκευές και ποικίλους αισθητήρες σε κάθε συσκευή. Συγκεκριμένα το σύστημα καταγραφής περιέχει i) μια συσκευή ενσωματωμένη στο στήθος κάθε χρήστη που εμπεριέχει ένα αξελερόμετρο και ένα ηλεκτροκαρδιογράφο που εκπέμπει 2D σήματα, ii) μια συσκευή ενσωματωμένη στο αριστερό αστράγαλο με ένα αξελερόμετρο ένα μαγνητόμετρο και ένα γυροσκόπιο, και iii) μία συσκευή στο δεξί μπράτσο με ένα αξελερόμετρο ένα μαγνητόμετρο και ένα γυροσκόπιο. Το πλήθος των χρηστών είναι 10 και η διάσταση για κάθε δείγμα της ροής y_i είναι $d = 23$. Ο μέσος χρόνος άφιξης $\bar{T}_{arrival}$ μεταξύ δυο καταγραφών είναι 0.0208 secs (52 Hz) και το μέσο πλήθος \bar{T} των ροών είναι 34319. Όπως είναι φανερό το σύστημα καταγραφής σ' αυτή την περίπτωση περιέχει ποιοτική πληροφορία μεγάλου όγκου. Το σύνολο των δραστηριοτήτων που εκτελούνται είναι 'όρθια στάση, καθιστική στάση, στάση σώματος στο πάτωμα, περπάτημα, ανέβασμα σκαλιών, σκύψιμο μέσης προς τα εμπρός, μετωπική ανύψωση των χεριών, γονάτισμα, ποδηλασία, τζόκινγκ, τρέξιμο, άλμα εμπρός-πίσω' και είναι ίδιο για όλους τους χρήστες.



Σχήμα 5.8 Αναπαράσταση ροής σημάτων ενός χρήστη απ' το σύνολο MHealth

5.3.2 Αποτελέσματα Αλγορίθμου Κυλιόμενου Παραθύρου


Σ' όλες τις περιπτώσεις δεδομένων εφαρμόστηκε ο αλγόριθμος κυλιόμενου παραθύρου για τις μετρικές που παρουσιάστηκαν στο Κεφ. 3 Εξ (3.1, .3.4, 3.5, 3.7) και για όλες τις περιπτώσεις προεπεξεργασίας. Για την περίπτωση της μετρικής του σφάλματος ανακατασκευής PCA (3.10) εφαρμόστηκαν μόνο οι προεπεξεργασίες των DFT (3.7) και Z-normalization (3.8). Η εφαρμογή της μετρικής (3.10) στις κρυμμένες μεταβλητές Z των αυτοκωδικοποιητών ενδέχεται φαινόμενα εκφυλισμού των δεδομένων και δεν χρησιμοποιήθηκε. Λόγω περιορισμού υπολογιστικών πόρων η μετρική (3.10) εφαρμόστηκε στην ροή των DFT μετασχηματισμών μόνο για μέγεθος παραθύρου $s = 26$. Όπως αναφέρθηκε για την αξιολόγηση του αλγορίθμου χρησιμοποιήθηκαν οι μετρικές (5.10) θεωρώντας ως K το σύνολο των πραγματικών σημείων αλλαγής και \hat{K} το σύνολο των εντοπισμένων σημείων αλλαγής όπου το πλήθος $|\hat{K}|$ προσδιορίζεται απ' τον χρήστη και τα στοιχεία του προκύπτουν απ' την σχέση (5.9). Πρέπει να σημειωθεί ότι τα κελιά των γραμμών του πρώτου υποπίνακα αναπαριστούν την δυάδα $(TPR\%, FPR\%)$ των μετρικών αξιολόγησης (5.10). Ενώ στα κελιά των τελευταίων υποπινάκων αναγράφονται οι μέση απόδοση των μετρικών (5.10) για όλους τους χρήστες και το καλύτερο μέγεθος παραθύρου s , ($s \in [26, 2000]$) για κάθε εφαρμογή των μετρικών και των αντίστοιχων προεπεξεργασιών αντίστοιχα.

5.3.2.1 Crowdsignals

Προε/σία Χρήστες	Καμία (<i>TPR, FPR</i>)	Κανο/ση (<i>TPR, FPR</i>)	DFT (<i>TPR, FPR</i>)	Auto/er (<i>TPR, FPR</i>)	$ K $	$ \hat{K} $
1	(51.9,48.2)	(77.7,22.2)	(55.5,44.4)	(29.6,70.4)	27	27
2	(55.5,81.9)	(44.4,85.2)	(22.2,92.6)	(0,100)	9	27
($\overline{TPR}, \overline{FPR}$)	(53.8,64.8)	(61.1,53.7)	(38.4,68.5)	(14.8,85.2)		

Μήκος Παραθύρου s Μετρική (3.1)	500	26	26	1000

Πίνακας 5.1 Αποτελέσματα της 3.1 μετρικής (άθροισμα αποστάσεων) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του CrowdSignal συνόλου δεδομένων.




Σχήμα 5.9 α) Ροή ανομοιογένειας β) σωστά εντοπισμένα σημεία αλλαγής της μετρικής (3.1) για τον χρήστη 1 (περίπτωση Normalization προεπεξεργασίας)

Προε/σία Χρήστες	Καμία (<i>TPR, FPR</i>)	Κανο/ση (<i>TPR, FPR</i>)	DFT (<i>TPR, FPR</i>)	Auto/er (<i>TPR, FPR</i>)	$ K $	$ \hat{K} $
1	(62.9,37)	(62.9,37)	(44.4,55.5)	(37,62.9)	27	27
2	(44.4,85.9)	(55.5,81.5)	(44.4,85.2)	(0,100)	9	27
($\overline{TPR}, \overline{FPR}$)	(53.7,61.1)	(59.3,59.3)	(44.4,70.3)	(18.5,81.5)		

Μήκος Παραθύρου s Μετρική (3.4)	500	500	50	1500
--	-----	-----	----	------

Πίνακας 5.2 Αποτελέσματα της 3.4 μετρικής (διαφ. εξ. εσωτ. αποστάσεων) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του CrowdSignal συνόλου δεδομένων.




Σχήμα 5.10 α) Ροή ανομοιογένειας β) σωστά εντοπισμένα σημεία αλλαγής της μετρικής (3.4) για τον χρήστη 1 (περίπτωση Normalization προεπεξεργασίας)

Προε/σία Χρήστες	Καμία (<i>TPR, FPR</i>)	Κανο/ση (<i>TPR, FPR</i>)	DFT (<i>TPR, FPR</i>)	Auto/er (<i>TPR, FPR</i>)	$ K $	$ \hat{K} $
1	(59.3,40.7)	(77.7,22.2)	(55.5,44.4)	(33.3,66.6)	27	27
2	(44.4,85.2)	(44.4,85.2)	(22.2,92.5)	(0,100)	9	27
($\overline{TPR}, \overline{FPR}$)	(51.9,63)	(61.1,53.7)	(38.8,68.5)	(16.6,83.3)		

Μήκος Παραθύρου s Μετρική (3.5)	250	250	26	1500
--	-----	-----	----	------

Πίνακας 5.3 Αποτελέσματα της 3.5 μετρικής (διαφ. μέσω των όρων) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του CrowdSignal συνόλου δεδομένων.




Σχήμα 5.11 α) Ροή ανομοιογένειας β) σωστά εντοπισμένα σημεία αλλαγής της μετρικής (3.5) για τον χρήστη 1 (περίπτωση Normalization προεπεξεργασίας)

Προε/σία Χρήστες	Καμία (<i>TPR, FPR</i>)	Κανο/ση (<i>TPR, FPR</i>)	DFT (<i>TPR, FPR</i>)	Auto/er (<i>TPR, FPR</i>)	<i>K</i>	<i>K̂</i>
1	(70.4,29.6)	(33.3,66.6)	(44.5,55.5)	(14.8,85.2)	27	27
2	(55.5,81.5)	(22.2,92.6)	(44.4,85.2)	(11.1,96.3)	9	27
(<i>TPR, FPR</i>)	(63,55.5)	(27.8,79.6)	(44.4,70.4)	(12.5,90.7)		

Μήκος Παραθύρου <i>s</i> Μετρική (3.7)	26	50	1500	250
---	----	----	------	-----

Πίνακας 5.4 Αποτελέσματα της 3.7 μετρικής (dip test) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του CrowdSignal συνόλου δεδομένων.




Σχήμα 5.12 α) Ροή ανομοιογένειας β) σωστά εντοπισμένα σημεία αλλαγής της μετρικής (3.7) για τον χρήστη 1 (περίπτωση καμίας προεπεξεργασίας)

Προε/σία Χρήστες	Καμία (<i>TPR, FPR</i>)	Κανο/ση (<i>TPR, FPR</i>)	DFT (<i>TPR, FPR</i>)	Auto/er (<i>TPR, FPR</i>)	$ K $	$ \hat{K} $
1	(63,37)	(63,37)	(74.1,25.9)	-	27	27
2	(44.4,85.2)	(66.6,77.7)	(22.2,92.6)	-	9	27
($\overline{TPR}, \overline{FPR}$)	(53.7,61.1)	(64.8,57.4)	(48.2,59.3)	-		

Μήκος Παραθύρου s Μετρική (3.10)	26	50	26	-
---	----	----	----	---

Πίνακας 5.5 Αποτελέσματα της 3.10 μετρικής (σφάλμα ανακ. PCA) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του CrowdSignal συνόλου δεδομένων.




Σχήμα 5.13 α) Ροή ανομοιογένειας β) σωστά εντοπισμένα σημεία αλλαγής της μετρικής (3.10) για τον χρήστη 1 (περίπτωση DFT προεπεξεργασίας)

5.3.2.2 HHAR Phone

Προε/σία Χρήστες	Καμία (<i>TPR, FPR</i>)	Κανο/ση (<i>TPR, FPR</i>)	DFT (<i>TPR, FPR</i>)	Auto/er (<i>TPR, FPR</i>)	$ K $	$ \hat{K} $
1	(30.1,73.3)	(15.4,86.6)	(53.9,53.3)	(61.5,46.6)	13	15
2	(14.3,86.6)	(7.1,93.3)	(50.5,3.3)	(14.3,86.6)	14	15
3	(25,80)	(16.7,86.6)	(16.6,86.6)	(0,100)	12	15
4	(20,80)	(40,60)	(26.6,73.3)	(13.4,86.6)	15	15
5	(20,80)	(33.3,66.6)	(13.3,86.6)	(20,86.6)	15	15
6	(15.4,86.6)	(23.1,36.4)	(61.5,46.6)	(84.6,26.6)	13	15
7	(36.4,73.3)	(36.6,73.3)	(27.3,80)	(27.3,80)	11	15
8	(33.3,66.6)	(46.6,53.3)	(33.3,66.6)	(6.6,93.3)	15	15
9	(53.8,53.3)	(53.8,53.3)	(84.6,26.6)	(76.9,33.3)	13	15
($\overline{TPR}, \overline{FPR}$)	(27.6,75.5)	(30.3,67.7)	(40.8, 57)	(33.9,71.1)		

Μήκος Παραθύρου s Μετρική (3.1)	1500	1500	1000	1000
--	------	------	------	------

Πίνακας 5.6 Αποτελέσματα της 3.1 μετρικής (άθροισμα αποστάσεων) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του HHAR Phone συνόλου δεδομένων




Σχήμα 5.14 α) Ροή ανομοιογένειας β) σωστά εντοπισμένα σημεία αλλαγής της μετρικής (3.1) για τον χρήστη 9 (περίπτωση DFT προεπεξεργασίας)

Προε/σία Χρήστες	Καμία (<i>TPR, FPR</i>)	Κανο/ση (<i>TPR, FPR</i>)	DFT (<i>TPR, FPR</i>)	Auto/er (<i>TPR, FPR</i>)	<i>K</i>	<i>K̂</i>
1	(46.15,60)	(46.19,60)	(38.5,33.3)	(30.7,73.3)	13	15
2	(35.7,66.7)	(35.71,66.7)	(64.3,40)	(21.4,80)	14	15
3	(66.6,46.6)	(66.7,46.7)	(25,80)	(8.3,93.3)	12	15
4	(73.3,26.6)	(73.3,26.6)	(46.6,53.3)	(13.3,86.6)	15	15
5	(66.6,33.3)	(66.6,33.3)	(46.6,53.3)	(20,80)	15	15
6	(76.9,33.3)	(76.9,33.3)	(76.9,33.3)	(84.6,26.6)	13	15
7	(81.9,40)	(81.81,40)	(27.3,80)	(45.5,66.6)	11	15
8	(80,20)	(80,20)	(60,40)	(6.6,93.3)	15	15
9	(69.2,40)	(69.23,40)	(76.9,33.3)	(84.6,26.6)	13	15
(<i>TPR, FPR</i>)	(66.3, 40.7)	(66.3,40.7)	(51.4,49.6)	(35, 69.6)		

Μήκος Παραθύρου <i>s</i> Μετρική (3.4)	1500	1500	500	1500
---	------	------	-----	------

Πίνακας 5.7 Αποτελέσματα της 3.4 μετρικής (διαφ. εξ. εσωτ. αποστάσεων) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του HHAR Phone συνόλου δεδομένων




Σχήμα 5.15 α) Ροή ανομοιογένειας β) σωστά εντοπισμένα σημεία αλλαγής της μετρικής (3.4) για τον χρήστη 7 (περίπτωση Normalization προεπεξεργασίας)

Προε/σία Χρήστες	Καμία (<i>TPR, FPR</i>)	Κανο/ση (<i>TPR, FPR</i>)	DFT (<i>TPR, FPR</i>)	Auto/er (<i>TPR, FPR</i>)	<i>K</i>	<i>K̂</i>
1	(38.46,66.6)	(61.5,46.6)	(38.5,66.6)	(61.5,46.6)	13	15
2	(42.85,60)	(64.3,40)	(50,53.3)	(21.4,80)	14	15
3	(16.6,86.6)	(50,60)	(41.6,66.6)	(16.6,86.6)	12	15
4	(53.3,46.6)	(66.6,33.3)	(40,60)	(13.3,86.6)	15	15
5	(53.3,40)	(66.6,33.3)	(53.3,46.6)	(20,80)	15	15
6	(84.6,26.6)	(76.9,33.3)	(92.3,20)	(69.2,40)	13	15
7	(27.3,80)	(81.81,40)	(27.3,80)	(36.3,73.3)	11	15
8	(73.3,26.6)	(73.3,26.6)	(60,40)	(6.6,93.3)	15	15
9	(76.9,33.3)	(76.9,33.3)	(84.6,26.6)	(76.9,33.3)	13	15
(<i>TPR, FPR</i>)	(52.6,51.8)	(68.7, 38.5)	(54.2,51.1)	(35.8,68.9)		

Μήκος Παραθύρου <i>s</i> Μετρική (3.5)	500	1500	1000	1500
---	-----	------	------	------

Πίνακας 5.8 Αποτελέσματα της 3.5 μετρικής (διαφ. μέσωσ όρων) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του HHAR Phone συνόλου δεδομένων




Σχήμα 5.16 α) Ροή ανομοιογένειας β) σωστά εντοπισμένα σημεία αλλαγής της μετρικής (3.5) για τον χρήστη 6 (περίπτωση DFT προεπεξεργασίας)

Προε/σία Χρήστες	Καμία (<i>TPR, FPR</i>)	Κανο/ση (<i>TPR, FPR</i>)	DFT (<i>TPR, FPR</i>)	Auto/er (<i>TPR, FPR</i>)	$ K $	$ \hat{K} $
1	(15.4,86.6)	(38.5,66.6)	(15.4,86.6)	(30.7,73.3)	13	15
2	(14.3,86.6)	(28.6,73.3)	(21.4,80)	(28.6,73.3)	14	15
3	(16.6,86.6)	(16.6,86.6)	(41.6,66.6)	(33.3,73.3)	12	15
4	(20,80)	(40,60)	(26.6,66.6)	(20,80)	15	15
5	(26.6,73.3)	(26.6,73.3)	(26.6,73.3)	(20,80)	15	15
6	(38.5,6.66)	(15.4,86.6)	(61.5,46.6)	(53.9,53.3)	13	15
7	(27.3,80)	(72.7,46.6)	(27.3,80)	(27.3,80)	11	15
8	(33.3,66.6)	(40,60)	(33.3,66.6)	(20,80)	15	15
9	(46.2,60)	(46,60)	(30.7,73.3)	(69.2,40)	13	15
($\overline{TPR}, \overline{FPR}$)	(26.5,76.3)	(36.1,68.14)	(31.6,71.9)	(33.6,70.3)		

Μήκος Παραθύρου s Μετρική (3.7)	250	250	500	1000
--	-----	-----	-----	------

Πίνακας 5.9 Αποτελέσματα της 3.7 μετρικής (dip test) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του HHAR Phone συνόλου δεδομένων




Σχήμα 5.17 α) Ροή ανομοιογένειας β) σωστά εντοπισμένα σημεία αλλαγής της μετρικής (3.7) για τον χρήστη 7 (περίπτωση Normalization προεπεξεργασίας)

Προε/σία Χρήστες	Καμία (<i>TPR, FPR</i>)	Κανο/ση (<i>TPR, FPR</i>)	DFT (<i>TPR, FPR</i>)	Auto/er (<i>TPR, FPR</i>)	$ K $	$ \hat{K} $
1	(23.07,80)	(23,80)	(23,07,80)	-	13	15
2	(28.6,73.3)	(35.7,66.6)	(21.42,80)	-	14	15
3	(16.6,86.6)	(8.3,93.3)	(16.6,86.6)	-	12	15
4	(33.3,66.6)	(33.3,66.6)	(20,80)	-	15	15
5	(26.6,73.3)	(33.3,66.6)	(20,80)	-	15	15
6	(7.6,93.3)	(7.6,93.3)	(7.6,93.3)	-	13	15
7	(9,93.3)	(9,93.3)	(0,100)	-	11	15
8	(13.3,86.6)	(13.3,86.6)	(13.3,86.6)	-	15	15
9	(0,100)	(0,100)	(0,100)	-	13	15
($\overline{TPR}, \overline{FPR}$)	(17.6,83.7)	(18.2,82.7)	(13.6,87.4)	-		

Μήκος Παραθύρου s Μετρική (3.10)	50	100	26	-
---	----	-----	----	---

Πίνακας 5.10 Αποτελέσματα της 3.10 μετρικής (σφάλμα ανακ. PCA) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του HHAR Phone συνόλου δεδομένων




Σχήμα 5.18 α) Ροή ανομοιογένειας β) σωστά εντοπισμένα σημεία αλλαγής της μετρικής (3.10) για τον χρήστη 2 (περίπτωση Normalization προεπεξεργασίας)

5.3.2.3 HHAR Watch

Προε/σία Χρήστες	Καμία (TPR, FPR)	Κανο/ση (TPR, FPR)	DFT (TPR, FPR)	Auto/er (TPR, FPR)	K	K̂
1	(15.4,86.6)	(23.07,80)	(15.4,86.6)	(7.6,93.3)	13	15
2	(21.4,80)	(14.3,86.6)	(14.3,86.6)	(14.3,86.6)	14	15
3	(33.3,73.3)	(8.3,93.3)	(25,80)	(33.3,73.3)	12	15
4	(33.3,66.6)	(26.6,73.3)	(33.3,66.6)	(20,80)	15	15
5	(13.3,86.6)	(13.3,86.6)	(33.3,66.6)	(26.6,73.3)	15	15
6	(15.4,86.6)	(23.07,80)	(23.07,80)	(30.7,73.3)	13	15
7	(30,80)	(30,80)	(36.4,73.3)	(54.54,60)	11	15
8	(16.6,86.6)	(15.4,86.6)	(23.07,80)	(23.07,80)	13	15
9	(23.07,80)	(23.07,80)	(30.,73.3)	(38.5,66.6)	13	15
(TPR, FPR)	(22.4,80.6)	(19.7, 83)	(25.9,77)	(27.6 76.2)		

Μήκος Παραθύρου s Μετρική (3.1)	2000	1500	500	2000
--	------	------	-----	------

Πίνακας 5.11 Αποτελέσματα της 3.1 μετρικής (άθροισμα αποστάσεων) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του HHAR Watch συνόλου δεδομένων




Σχήμα 5.19 α) Ροή ανομοιογένειας β) σωστά εντοπισμένα σημεία αλλαγής της μετρικής (3.1) για τον χρήστη 7 (περίπτωση Autoencoder προεπεξεργασίας)

Προε/σία Χρήστες	Καμία (<i>TPR, FPR</i>)	Κανο/ση (<i>TPR, FPR</i>)	DFT (<i>TPR, FPR</i>)	Auto/er (<i>TPR, FPR</i>)	<i>K</i>	<i>K̂</i>
1	(23.7,80)	(23.7,80)	(15.4,86.6)	(7.7,93.3)	13	15
2	(21.5,80)	(21.4,80)	(7.1,93.3)	(14.3,86.6)	14	15
3	(25,80)	(25,80)	(33.3,73.3)	(25,80)	12	15
4	(20,80)	(20,80)	(20,80)	(20,80)	15	15
5	(20,80)	(20,80)	(20,80)	(20,80)	15	15
6	(23.7,80)	(23.7,80)	(23.1,80)	(30.8,73.3)	13	15
7	(36.4,73.3)	(36.4,73.3)	(54.6,60)	(54.6,60)	11	15
8	(30.7,73.3)	(30.7,73.3)	(7.6,93.3)	(7.7,93.3)	13	15
9	(30.7,73.3)	(30.7,73.3)	(46.2,60)	(30.7,73.3)	13	15
(<i>TPR, FPR</i>)	(25.7, 77.7)	(25.7, 77.7)	(25.3, 78.5)	(23.4, 79.9)		

Μήκος Παραθύρου <i>s</i> Μετρική (3.4)	1500	1500	500	1500
---	------	------	-----	------

Πίνακας 5.12 Αποτελέσματα της 3.4 μετρικής (διαφ. εξ. εσωτ. αποστάσεων) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του HHAR Watch συνόλου δεδομένων




Σχήμα 5.20 α) Ροή ανομοιογένειας β) σωστά εντοπισμένα σημεία αλλαγής της μετρικής (3.4) για τον χρήστη 7 (περίπτωση Autoencoder προεπεξεργασίας)

Προε/σία Χρήστες	Καμία (<i>TPR, FPR</i>)	Κανο/ση (<i>TPR, FPR</i>)	DFT (<i>TPR, FPR</i>)	Auto/er (<i>TPR, FPR</i>)	<i>K</i>	<i>K̂</i>
1	(15.4,86.6)	(23.1,80)	(14.3,86.6)	(7.6,93.3)	13	15
2	(13.4,86.6)	(42.9,60)	(33.3,73.3)	(14.3,86.6)	14	15
3	(33.3,73.3)	(41.6,66.6)	(14.3,86.6)	(25,80)	12	15
4	(26.6,73.3)	(46.6,53.3)	(33.3,73.3)	(20,80)	15	15
5	(20,80)	(46.6,53.3)	(20,80)	(20,80)	15	15
6	(15.4,86.6)	(15.4,86.6)	(33.3,86.6)	(30.7,73.3)	13	15
7	(45.5,66.6)	(18.2,86.6)	(54.6,60)	(45.5,66.6)	11	15
8	(15.4,86.6)	(14.3,86.6)	(7.6,93.3)	(15.4,86.6)	13	15
9	(30.7,86.6)	(38.5,66.6)	(46.2,60)	(38.5,66.6)	13	15
(<i>TPR, FPR</i>)	(23.9,80.7)	(31.9,71.1)	(28.5,77.7)	(24.1,79.2)		

Μήκος Παραθύρου <i>s</i> Μετρική (3.5)	1500	500	500	2000
---	------	-----	-----	------

Πίνακας 5.13 Αποτελέσματα της 3.5 μετρικής (διαφ. μέσω των όρων) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του HHAR Watch συνόλου δεδομένων




Σχήμα 5.21 α) Ροή ανομοιογένειας β) σωστά εντοπισμένα σημεία αλλαγής της μετρικής (3.5) για τον χρήστη 7 (περίπτωση DFT προεπεξεργασίας)

Προε/σία Χρήστες	Καμία (<i>TPR, FPR</i>)	Κανο/ση (<i>TPR, FPR</i>)	DFT (<i>TPR, FPR</i>)	Auto/er (<i>TPR, FPR</i>)	$ K $	$ \hat{K} $
1	(15.4,86.6)	(15.4,86.6)	(23.1,80)	(15.4,86.6)	13	15
2	(7.2,93.3)	(7.2,93.3)	(14.3,86.6)	(0,100)	14	15
3	(25,80)	(25,80)	(41.6,66.6)	(25,80)	12	15
4	(20,80)	(13.3,86.6)	(6.6,93.3)	(13.3,86.6)	15	15
5	(13.3,86.6)	(13.3,86.6)	(13.3,86.6)	(13.3,86.6)	15	15
6	(15.4,86.6)	(7.7,93.3)	(15.4,86.6)	(15.4,86.6)	13	15
7	(18.2,86.6)	(27.3,80)	(36.4,73.3)	(27.3,80)	11	15
8	(21.4,80)	(15.4,86.6)	(15.4,86.6)	(15.4,86.6)	13	15
9	(15.4,86.6)	(23.1,80)	(38.4,73.3)	(23.1,80)	13	15
($\overline{TPR}, \overline{FPR}$)	(16.1,85.14)	(16.4, 85.9)	(22.7,81.4)	(16.4,85.9)		

Μήκος Παραθύρου s Μετρική (3.7)	500	1000	1000	1000
--	-----	------	------	------

Πίνακας 5.14 Αποτελέσματα της 3.7 μετρικής (dip test) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του HHAR Watch συνόλου δεδομένων




Σχήμα 5.22 α) Ροή ανομοιογένειας β) σωστά εντοπισμένα σημεία αλλαγής της μετρικής (3.7) για τον χρήστη 3 (περίπτωση DFT προεπεξεργασίας)

Προε/σία Χρήστες	Καμία (<i>TPR, FPR</i>)	Κανο/ση (<i>TPR, FPR</i>)	DFT (<i>TPR, FPR</i>)	Auto/er (<i>TPR, FPR</i>)	<i>K</i>	<i>K̂</i>
1	(0,100)	(30.8,73.3)	(7.7,93.3)	-	13	15
2	(7.2,93.3)	(14.3,86.6)	(14.3,86.6)	-	14	15
3	(16.6,86.6)	(8.4,93.3)	(8.4,93.3)	-	12	15
4	(0,100)	(6.6,93.3)	(0,100)	-	15	15
5	(20,80)	(0,100)	(0,100)	-	15	15
6	(7.7,93.3)	(15.4,86.6)	(0,100)	-	13	15
7	(54.5,60)	(27.3,80)	(36.4,73.3)	-	11	15
8	(28.6,73.3)	(23.1,80)	(13.3,86.6)	-	13	15
9	(46.2,69.2)	(23.1,80)	(30.7,80)	-	13	15
(<i>TPR, FPR</i>)	(20.01,83.9)	(16.5,85.90)	(12.3,90.3)	-		

Μήκος Παραθύρου <i>s</i> Μετρική (3.10)	500	100	26	-
--	-----	-----	----	---

Πίνακας 5.15 Αποτελέσματα της 3.10 μετρικής (σφάλμα ανακ. PCA) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του HHAR Watch συνόλου δεδομένων




Σχήμα 5.23 α) Ροή ανομοιογένειας β) σωστά εντοπισμένα σημεία αλλαγής της μετρικής (3.10) για τον χρήστη 7 (περίπτωση DFT προεπεξεργασίας)

5.3.2.4 MHealth

Προε/σία Χρήστες	Καμία (<i>TPR, FPR</i>)	Κανο/ση (<i>TPR, FPR</i>)	DFT (<i>TPR, FPR</i>)	Auto/er (<i>TPR, FPR</i>)	<i>K</i>	<i>K̂</i>
1	(9.1,90.1)	(18.2,81.9)	(36.4,63.3)	(9.1,90.9)	11	11
2	(9.1,90.1)	(9.1,90.1)	(45.5,54.5)	(9.1,90.9)	11	11
3	(18.2,81.9)	(27.2,72.8)	(45.5,54.5)	(27.3,72.8)	11	11
4	(18.2,81.9)	(27.2,72.8)	(36.4,63.3)	(0,100)	11	11
5	(9.1,90.1)	(18.2,81.9)	(45.5,54.5)	(45.5,54.5)	11	11
6	(18.2,81.9)	(18.2,81.9)	(54.5,45.5)	(9.1,90.9)	11	11
7	(18.2,81.9)	(18.2,81.9)	(36.4,63.3)	(18.2,81.9)	11	11
8	(18.2,81.9)	(18.2,81.9)	(27.7,72.7)	(18.2,81.9)	11	11
9	(18.2,81.9)	(27.2,72.8)	(45.5,54.5)	(9.1,90.9)	11	11
10	(18.2,81.9)	(0,100)	(27.7,72.7)	(27.3,72.8)	11	11
(<i>TPR, FPR</i>)	(15.5,84.5)	(18.2,81.9)	(40,60)	(17.2,82.8)		

Μήκος Παραθύρου <i>s</i> Μετρική (3.1)	1500	250	500	26

Πίνακας 5.16 Αποτελέσματα της 3.1 μετρικής (άθροισμα αποστάσεων) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του MHealth συνόλου δεδομένων




Σχήμα 5.24 α) Ροή ανομοιογένειας β) σωστά εντοπισμένα σημεία αλλαγής της μετρικής (3.1) για τον χρήστη 5 (περίπτωση DFT προεπεξεργασίας)

Προε/σία Χρήστες	Καμία (<i>TPR, FPR</i>)	Κανο/ση (<i>TPR, FPR</i>)	DFT (<i>TPR, FPR</i>)	Auto/er (<i>TPR, FPR</i>)	$ K $	$ \hat{K} $
1	(81.8,18.2)	(81.8,18.2)	(63.6,36.4)	(54.5,45.5)	11	11
2	(81.8,18.2)	(81.8,18.2)	(54.5,45.5)	(36.4,63.4)	11	11
3	(81.8,18.2)	(81.8,18.2)	(54.5,45.5)	(81.8,18.2)	11	11
4	(81.8,18.2)	(81.8,18.2)	(72.7,27.3)	(27.3,72.7)	11	11
5	(90.9,9.1)	(90.9,9.1)	(72.7,27.3)	(72.7,27.3)	11	11
6	(90.9,9.1)	(90.9,9.1)	(72.7,27.3)	(9.1,90.9)	11	11
7	(90.9,9.1)	(90.9,9.1)	(72.7,27.3)	(54.5,45.5)	11	11
8	(81.8,18.2)	(81.8,18.2)	(72.7,27.3)	(54.5,45.5)	11	11
9	(90.9,9.1)	(90.9,9.1)	(63.6,36.4)	(27.3,72.3)	11	11
10	(90.9,9.1)	(90.9,9.1)	(72.7,27.3)	(27.3,72.8)	11	11
(<i>TPR, FPR</i>)	(86.4,13.6)	(81.8,18.2)	(67.3,32.7)	(44.5,55.5)		

Μήκος Παραθύρου s Μετρική (3.4)	500	500	250	500
--	-----	-----	-----	-----

Πίνακας 5.17 Αποτελέσματα της 3.4 μετρικής (διαφ. εξ. εσωτ. αποστάσεων) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του MHealth συνόλου δεδομένων




Σχήμα 5.25 α) Ροή ανομοιογένειας β) σωστά εντοπισμένα σημεία αλλαγής της μετρικής (3.4) για τον χρήστη 10 (περίπτωση καμιάς προεπεξεργασίας)

Προε/σία Χρήστες	Καμία (<i>TPR, FPR</i>)	Κανο/ση (<i>TPR, FPR</i>)	DFT (<i>TPR, FPR</i>)	Auto/er (<i>TPR, FPR</i>)	<i>K</i>	<i>K̂</i>
1	(54.5,45.5)	(54.5,45.5)	(63.6,36.4)	(54.5,45.5)	11	11
2	(54.5,45.5)	(81.8,18.2)	(54.5,45.5)	(36.4,63.6)	11	11
3	(54.5,45.5)	(90.9,9.1)	(54.5,45.5)	(63.6,36.4)	11	11
4	(54.5,45.5)	(81.8,18.2)	(72.7,27.3)	(27.3,72.7)	11	11
5	(45.5,55.5)	(90.9,9.1)	(72.7,27.3)	(63.6,36.4)	11	11
6	(72.7,27.3)	(90.9,9.1)	(72.7,27.3)	(9.1,90.9)	11	11
7	(63.6,36.4)	(90.9,9.1)	(72.7,27.3)	(54.5,45.5)	11	11
8	(54.5,45.5)	(81.8,18.2)	(54.5,45.5)	(36.4,63.6)	11	11
9	(72.7,27.3)	(72.7,27.3)	(63.6,36.4)	(27.3,72.7)	11	11
10	(63.6,36.4)	(81.8,18.2)	(54.5,45.5)	(27.3,72.7)	11	11
(<i>TPR, FPR</i>)	(59.1,40.9)	(81.8,18.2)	(63.6,36.4)	(40,60)		

Μήκος Παραθύρου <i>s</i> Μετρική (3.5)	1000	1000	500	1000
---	------	------	-----	------

Πίνακας 5.18 Αποτελέσματα της 3.5 μετρικής (διαφ. μέσω των όρων) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του MHealth συνόλου δεδομένων




Σχήμα 5.26 α) Ροή ανομοιογένειας β) σωστά εντοπισμένα σημεία αλλαγής της μετρικής (3.5) για τον χρήστη 5 (περίπτωση Normalization προεπεξεργασίας)

Προε/σία Χρήστες	Καμία (<i>TPR, FPR</i>)	Κανο/ση (<i>TPR, FPR</i>)	DFT (<i>TPR, FPR</i>)	Auto/er (<i>TPR, FPR</i>)	$ K $	$ \hat{K} $
1	(36.4,64.6)	(72.7,27.3)	(81.8,18.2)	(18.2,81.8)	11	11
2	(54.5,45.5)	(72.7,27.3)	(63.6,36.4)	(27.3,72.7)	11	11
3	(54.5,45.5)	(72.7,27.3)	(90.9,9.1)	(36.4,63.6)	11	11
4	(36.4,64.6)	(81.8,18.2)	(90.9,9.1)	(18.2,81.8)	11	11
5	(63.6,36.4)	(72.7,27.3)	(81.8,18.2)	(27.3,72.7)	11	11
6	(36.4,64.6)	(72.7,27.3)	(90.9,9.1)	(9.1,90.9)	11	11
7	(54.5,45.5)	(72.7,27.3)	(90.9,9.1)	(18.2,81.8)	11	11
8	(54.5,45.5)	(54.5,45.5)	(90.9,9.1)	(27.3,72.7)	11	11
9	(54.5,45.5)	(81.8,18.2)	(90.9,9.1)	(27.3,72.7)	11	11
10	(36.4,64.6)	(72.7,27.3)	(100,0)	(0,100)	11	11
($\overline{TPR}, \overline{FPR}$)	(48.2,51.8)	(72.7,27.3)	(87.3,12.7)	(20.9,79.1)		

Μήκος Παραθύρου s Μετρική (3.7)	250	500	1000	1000

Πίνακας 5.19 Αποτελέσματα της 3.7 μετρικής (dip test) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του MHealth συνόλου δεδομένων




Σχήμα 5.27 α) Ροή ανομοιογένειας β) σωστά εντοπισμένα σημεία αλλαγής της μετρικής (3.7) για τον χρήστη 10 (περίπτωση DFT προεπεξεργασίας)

Προε/σία Χρήστες	Καμία (<i>TPR, FPR</i>)	Κανο/ση (<i>TPR, FPR</i>)	DFT (<i>TPR, FPR</i>)	Auto/er (<i>TPR, FPR</i>)	$ K $	$ \hat{K} $
1	(18.2,81.8)	(27.3,72.7)	(18.2,81.8)	-	11	11
2	(27.3,72.7)	(27.3,72.7)	(18.2,81.8)	-	11	11
3	(18.2,81.8)	(18.2,81.8)	(27.3,72.7)	-	11	11
4	(27.3,72.7)	(27.3,72.7)	(27.3,72.7)	-	11	11
5	(27.3,72.7)	(36.4,63.6)	(36.4,63.6)	-	11	11
6	(27.3,72.7)	(27.3,72.7)	(36.4,63.6)	-	11	11
7	(27.3,72.7)	(27.3,72.7)	(27.3,72.7)	-	11	11
8	(27.3,72.7)	(27.3,72.7)	(27.3,72.7)	-	11	11
9	(36.4,63.6)	(27.3,72.7)	(27.3,72.7)	-	11	11
10	(18.2,81.8)	(27.3,72.7)	(18.2,81.8)	-	11	11
(<i>TPR, FPR</i>)	(18.2,81.8)	(27.3,72.7)	(26.4,73.6)	-		

Μήκος Παραθύρου s Μετρική (3.10)	250	100	26	-
---	-----	-----	----	---

Πίνακας 5.20 Αποτελέσματα της 3.10 μετρικής (σφάλμα ανακ. PCA) για τον αλγόριθμο κυλιόμενου παραθύρου και την περίπτωση του MHealth συνόλου δεδομένων



Σχήμα 5.28 α) Ροή ανομοιογένειας β) σωστά εντοπισμένα σημεία αλλαγής της μετρικής (3.10) για τον χρήστη 5 (περίπτωση Normalization προεπεξεργασίας)


5.3.3 Αποτελέσματα Αλγορίθμου Αυξανόμενου Παραθύρου

Τα κελιά του μεσαίου πρώτου υποπίνακα αντιστοιχούν στις μετρικές αξιολόγησης (5.10). Τα κελιά του δεξιού υποπίνακα δηλώνουν το πλήθος των πραγματικών σημείων αλλαγής $|K|$ και το πλήθος των εντοπισμένων σημείων αλλαγής $|\hat{K}|$ που εκτιμά ο αλγόριθμος του αυξανόμενου παραθύρου για κάθε χρήστη και περίπτωση προεπεξεργασίας (στα δείγματα του τρέχοντος παραθύρου πριν τον έλεγχο της πολυτροπικότητας) αντίστοιχα. Τα κελιά του τελευταίου υποπίνακα αντιστοιχούν στο μέγεθος του αρχικού παραθύρου s_0 .

5.3.3.1 Crowdsignals

Προε/σία Χρήστες	Καμία (TPR, FPR)	$ \hat{K} $	Κανο/ση (TPR, FPR)	$ \hat{K} $	$ K $
1	(88.9,81.6)	131	(81.5,69.5)	72	27
2	(55.5,98.5)	334	(44.4,97.7)	177	9
($\overline{TPR}, \overline{FPR}$)	(72.2,90.1)	(62.9,83.6)			
Μήκος Αρχ. Παρ. s_0	26	26			

Πίνακας 5.21 Αποτελέσματα του αλγορίθμου αυξανόμενου παραθύρου για την περίπτωση του Crowdsignals συνόλου δεδομένων




Σχήμα 5.29 Σωστά εντοπισμένα σημεία αλλαγής του αλγορίθμου αυξ. παρ. για τον χρήστη 1 (περίπτωση Normalization προεπεξεργασίας)

5.3.3.2 HHAR Phone

Προε/σία Χρήστες	Καμία (<i>TPR, FPR</i>)	$ \hat{K} $	Κανο/ση (<i>TPR, FPR</i>)	$ \hat{K} $	$ K $
1	(15.4,0)	2	(15.4,0)	2	13
2	(14.3,80)	10	(14.3,75)	8	14
3	(16.6,0)	2	(16.6,0)	2	12
4	(20,50)	6	(13.3,0)	2	15
5	(20,40)	5	(13.3,33)	3	15
6	(15,4,0)	2	(15.4,0)	2	13
7	(27.3,0)	3	(27.3,0)	3	11
8	(20,4,0)	5	(13.3,50)	4	15
9	(15.4,0)	2	(15.4,0)	2	13
($\overline{TPR}, \overline{FPR}$)	(18.3,23.3)	(16,17.6)			
Μήκος Αρχ. Παρ. s_0	1250	1000			

Πίνακας 5.22 Αποτελέσματα του αλγορίθμου αυξανόμενου παραθύρου για την περίπτωση του HHAR Phone συνόλου δεδομένων

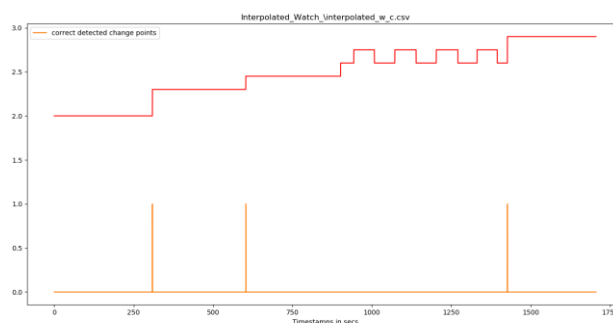


Σχήμα 5.30 Σωστά εντοπισμένα σημεία αλλαγής του αλγορίθμου αυξ. παρ. για τον χρήστη 7 (περίπτωση Normalization προεπεξεργασίας)

5.3.3.3 HHAR Watch

Προε/σία Χρήστες	Καμία (<i>TPR, FPR</i>)	$ \hat{K} $	Κανο/ση (<i>TPR, FPR</i>)	$ \hat{K} $	$ K $
1	(23.1,66.6)	9	(23.1,50)	6	13
2	(7.2,93.3)	15	(14.3,80)	10	14
3	(25,40)	5	(25,0)	3	12
4	(13.3,71.4)	7	(13.3,0)	2	15
5	(13.3,75)	8	(13.3,50)	4	15
6	(7.7,80)	5	(15.4,60)	5	13
7	(9.1,50)	2	(9.1,0)	1	11
8	(7.6,0)	1	(7.7,0)	1	13
9	(15.4,0)	2	(7.7,0)	1	13
($\overline{TPR}, \overline{FPR}$)	(13.7,53)	(14.4,26.6)			
Μήκος Αρχ. Παρ. s_0	500	750			

Πίνακας 5.23 Αποτελέσματα του αλγορίθμου αυξανόμενου παραθύρου για την περίπτωση του HHAR Watch συνόλου δεδομένων

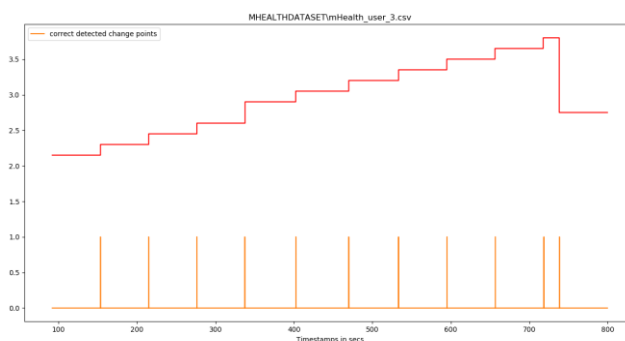


Σχήμα 5.31 Σωστά εντοπισμένα σημεία αλλαγής του αλγορίθμου αυξ. παρ. για τον χρήστη 3 (περίπτωση Normalization προεπεξεργασίας)

5.3.3.4 MHealth

Προε/σία Χρήστες	Καμία (TPR, FPR)	$ \hat{K} $	Κανο/ση (TPR, FPR)	$ \hat{K} $	$ K $
1	(36.4,0)	4	(81.9,0)	9	11
2	(54.5,0)	6	(81.9,0)	9	11
3	(72.7,0)	8	(100,8.3)	12	11
4	(63.6,12.5)	8	(90.1,0)	10	11
5	(45.5,0)	5	(90.1,0)	10	11
6	(63.6,12.5)	8	(100,8.3)	12	11
7	(45.5,0)	5	(81.9,0)	9	11
8	(63.5,0)	7	(81.9,0)	9	11
9	(81.9,0)	10	(90.1,0)	10	11
10	(45.5,0)	5	(90.1,0)	10	11
($\overline{TPR}, \overline{FPR}$)	(57.3,3.5)	(89.1,1.6)			
Μήκος Αρχ. Παρ. s_0	500	500			

Πίνακας 5.24 Αποτελέσματα του αλγορίθμου αυξανόμενου παραθύρου για την περίπτωση του MHealth συνόλου δεδομένων



Σχήμα 5.32 Σωστά εντοπισμένα σημεία αλλαγής του αλγορίθμου αυξ. παρ. για τον χρήστη 3 (περίπτωση Normalization προεπεξεργασίας).

5.4 Συμπεράσματα

Στόχος της ανάλυσης ήταν να εφαρμόσουμε τους αλγορίθμους σε διάφορα είδη ροών σημάτων κίνησης έτσι ώστε να εκτιμήσουμε την επίδοση των αλγορίθμων. Παρακάτω θα γίνει λεπτομερής αναφορά για κάθε σύνολο δεδομένων έτσι ώστε να σχηματισθεί μια συνολική εικόνα για την αποδοτικότητα κάθε μεθόδου.

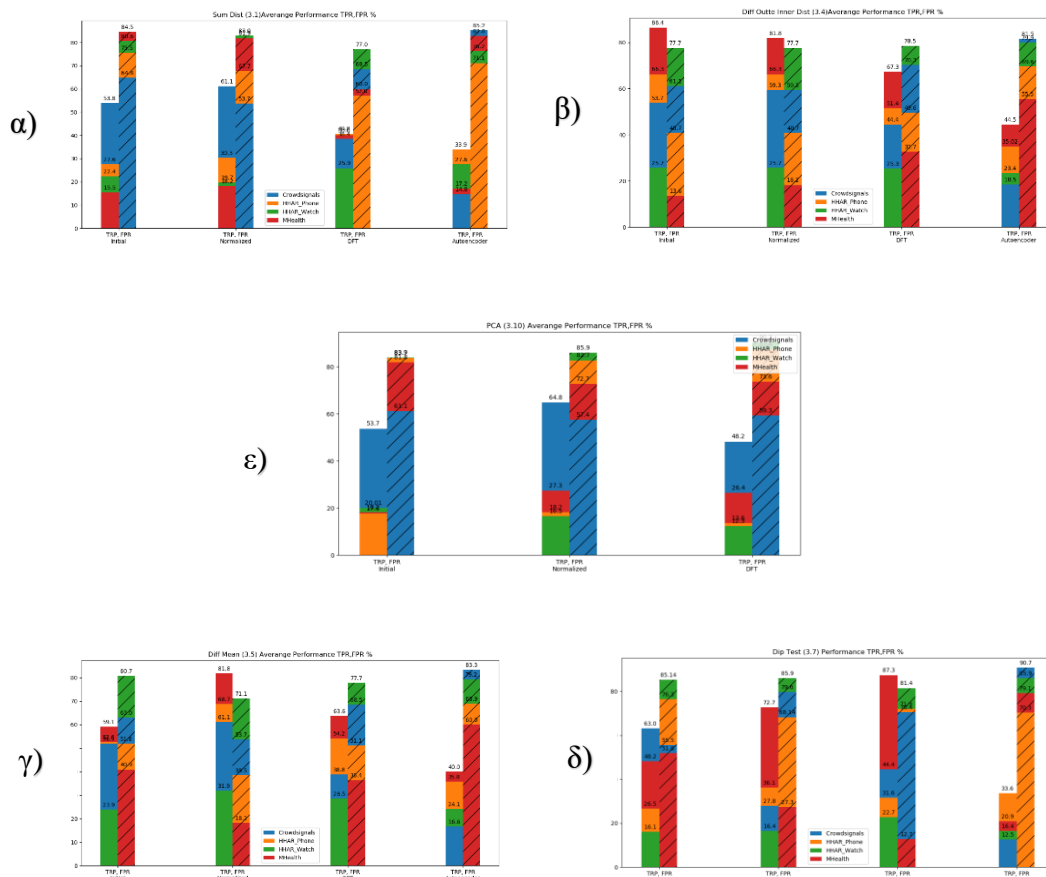
5.4.1 Αλγόριθμος Κυλιόμενου Παραθύρου

Μια βασική παρατήρηση είναι ότι η επίδοση του αλγορίθμου του κυλιόμενου παραθύρου για κάθε χρήστη και για κάθε περίπτωση μετρικής και προεπεξεργασίας εξαρτάται απ' τον σωστό καθορισμό του μήκους του παραθύρου s . Ο αλγόριθμος έχει πρόβλημα όσο αφορά την ρύθμιση του μήκους του παραθύρου όπως διαπιστώθηκε απ' τα πειράματα με το s να κυμαίνεται μεταξύ [26,2000]. Πριν παρουσιαστούν οι μέσες αποδόσεις (\overline{TPR} , \overline{FPR}) όλων των χρηστών όλων των συνόλων για κάθε περίπτωση (μετρικής, προεπεξεργασίας) είναι σημαντικό να σημειωθεί ότι η απόδοση των μεθόδων εξαρτάται απ' τα χαρακτηριστικά των δεδομένων της κάθε ροής σημάτων όπως το πλήθος και η ποικιλία αισθητήρων που καταγράφουν τις ανθρώπινες κινήσεις. Όπως φαίνεται παρακάτω (Πίνακας. 5.25) για κάθε περίπτωση εφαρμογής των μετρικών και αντίστοιχων μεθόδων προεπεξεργασίας προκύπτει ότι οι καλύτερες αποδόσεις παρατηρούνται στα σύνολα ροών MHealth, Crowdsignals, και HHAR Phone με αντίστοιχα ποσοστά 52.9%, 31.6%, 15.7% των 19 περιπτώσεων (μετρικής και προεπ). Ενώ οι χειρότερες αποδόσεις παρατηρούνται στα HHAR Watch, Crowdsignals, MHealth και HHAR Phone με αντίστοιχα ποσοστά 63.15%, 21.1%, 10.5%, 5.3% των 19 περιπτώσεων. Να υπενθυμίσουμε (βλ. υποενότητα 5.3.1) ότι οι ροές $y_i \in \mathbb{R}^{23}$ του MHealth συνόλου παράγονται από 8 αισθητήρες ενώ οι ροές $y_i \in \mathbb{R}^6$ του HHAR Watch από 2 αισθητήρες. Το συμπέρασμα που προκύπτει είναι ότι το μεγαλύτερο ποσοστό (52.9%), μετρικών και αντίστοιχων μεθόδων προεπεξεργασίας εκτιμούν με μεγαλύτερη ακρίβεια τα σημεία αλλαγής όταν έχουν να επεξεργαστούν σήματα που προέρχονται από πολλούς και ποικίλους αισθητήρες κίνησης. Επίσης το

μεγαλύτερο ποσοστό (63.15%), μετρικών και αντίστοιχων προεπεξεργασιών αποδίδει χαμηλά όταν το πολυδιάστατο σήμα προέρχεται από λίγους αισθητήρες.

Προε/σία	Καμία	Κανο/ση	DFT	Auto/er
Μετρικές Κυλ. Παρ.	<i>Best/Worst Performance</i>	<i>Best/Worst Performance</i>	<i>Best/Worst Performance</i>	<i>Best/Worst Performance</i>
(3.1)	C/M	C/M	HP/HW	HP/C
(3.4)	M/HW	M/HW	M/HW	M/C
(3.5)	M/HW	M/HW	M/HW	M/C
(3.7)	C/HW	M/HW	M/HW	HP/C
(3.10)	C/HP	C/HW	C/HW	-

Πίνακας 5.25 Σύνολα ροών με τις καλύτερες και χειρότερες αποδόσεις για κάθε περίπτωση μετρικής και προεπ. όπου C (Crowdsignals), M (MHealth), HW (HHAR Watch), HP (HHAR Phone)



Σχήμα 5.33 Μέση απόδοση σε κάθε σύνολο για κάθε περίπτωση μετρικής και προεπ. (κάθετες στήλες μέθοδος προεπ.) α) άθρ. αποστ. (3.1) β) διαφ. εξ. εσωτ. αποστ. (3.4) γ) διαφ. μέσων (3.5) δ) dip test (3.7) ε) PCA (3.10)

Η συνολική εικόνα των μέσων αποδόσεων για τους χρήστες όλων των συνόλων παρουσιάζεται παρακάτω (Πίνακα 5.26) όπου παρατηρείται ότι ο συνδιασμός της μετρικής (3.5) της διαφοράς των μέσων των ημιπαραθύρων με την μέθοδο προεπεξεργασίας της κανονικοποίησης έχει την καλύτερη μέση απόδοση ($\overline{TPR} = 60.9\%$, $\overline{FPR} = 45.3\%$) ενώ ο χειρότερος συνδιασμός μετρικής και προεπεξεργασίας είναι η μετρική (3.7) του dip test με την προεπεξεργασία των αυτοκωδικοποιητών ($\overline{TPR} = 20.9\%$, $\overline{FPR} = 81.5\%$).

Προε/σία Μετρικές Κυλ. Παρ.	Καμία ($\overline{TPR}, \overline{FPR}$)	Κανο/ση ($\overline{TPR}, \overline{FPR}$)	DFT ($\overline{TPR}, \overline{FPR}$)	Auto/er ($\overline{TPR}, \overline{FPR}$)
(3.1)	29.8 76.3	32.4 71.5	36.3 65.6	23.4 78.8
(3.4)	58.0 48.3	58.3 48.9	47.1 57.8	30.4 71.6
(3.5)	46.9 59.1	60.9 45.3	46.3 58.5	29.1 72.9
(3.7)	38.5 67.2	38.3 65.2	46.5 59.1	20.9 81.5
(3.10)	27.4 77.6	31.7 74.6	25.1 77.7	-

Πίνακας 5.26 Μέση απόδοση σε όλα τα σύνολα για κάθε περίπτωση μετρικής και προεπεξεργασίας

5.4.2 Αλγόριθμος Αυξανόμενου Παραθύρου


Η τιμή του κατάλληλου μήκους του αρχικού παραθύρου s_0 για τα σύνολα ροών MHHAR Phone, HHAR Watch, MHealth κυμαίνεται μεταξύ [500,1250] ενώ για το Crowdsignals $s_0 = 26$. Η απόδοση του αλγορίθμου μπορούμε να πούμε ότι έχει μικρότερη εξάρτηση απ' το μέγεθος του παραθύρου s_0 απ' ότι ο αλγόριθμος του κυλιόμενου παραθύρου απ' την στιγμή που το εύρος τιμών του είναι σχετικά μικρό για τα περισσότερα σύνολα ροών.

Η ανάλυση των αποτελεσμάτων του αλγορίθμου του αυξανόμενου παραθύρου είναι παρόμοια. Σ' αυτή την περίπτωση έχουμε να εξετάσουμε την απόδοση του αλγορίθμου για δύο περιπτώσεις προεπεξεργασίας. Η καλύτερη απόδοση παρατηρείται στο MHealth και στις δύο περιπτώσεις προεπεξεργασίας (καμία: $\overline{TPR} = 57.3\%$, $\overline{FPR} =$

3.5%, κανονικοποίηση: $\overline{TPR} = 89.1\%$, $\overline{FPR} = 1.6\%$). Ενώ η χειρότερη απόδοση για την περίπτωση της μηδενικής προεπεξεργασίας παρατηρείται στο HHAR Watch ($\overline{TPR} = 13.7\%$, $\overline{FPR} = 53\%$) και για την περίπτωση της κανονικοποίησης παρατηρείται στο Crowdsignals ($\overline{TPR} = 62.9\%$, $\overline{FPR} = 83.6\%$). Το συμπέρασμα είναι το ίδιο όπως και στον αλγόριθμο του κυλιόμενου παραθύρου. Ο αλγόριθμος αυξανόμενου παραθύρου αποδίδει καλύτερα σε ροές πολυδιάστατων σημάτων που προέρχονται από ποικίλους και πολλούς αισθητήρες, ενώ δεν αποδίδει σε ροές σημάτων με λίγη πληροφορία όπως το Crowdsignal και το HHAR Watch όπου η ροή των σημάτων παράγεται από 3 ($y_i \in \mathbb{R}^9$) και 2 ($y_i \in \mathbb{R}^6$) αισθητήρες κίνησης αντίστοιχα.

	Προε/σία	Καμία	Κανο/ση
		<i>Best/Worst Performance</i>	<i>Best/Worst Performance</i>
Αλγ. Αυξ Παρ.		M/HW	M/C

Πίνακας 5.27 Σύνολα ροών με τις καλύτερες και χειρότερες αποδόσεις για τον αλγόριθμο του αυξανόμενου παραθύρου και για κάθε μέθοδο προεπεξεργασίας, όπου C (Crowdsignals), M (MHealth), HW (HHAR Watch).



Σχήμα 5.34 Αναπαράσταση των μέσων αποδόσεων όλων των συνόλων του αλγορίθμου του αυξανόμενου παραθύρου για κάθε σύνολο και κάθε περίπτωση προεπεξεργασίας

Συνολικά η καλύτερη μέση απόδοση του αλγορίθμου για τους χρήστες όλων των συνόλων παρατηρείται στην περίπτωση της κανονικοποίησης (βλ. Πίνακα 5.28).

Προε/σία	Καμία ($\overline{TPR}, \overline{FPR}$)	Κανο/ση ($\overline{TPR}, \overline{FPR}$)
Αυξαν. Παρ	40.4 42.5	45.6 32.3


Πίνακας 5.28 Μέση απόδοση σε όλα τα σύνολα για τον αλγόριθμο αυξανόμενου παραθύρου για κάθε περίπτωση προεπεξεργασίας

5.4.3 Μετά-Ανάλυση Σφάλματος Ανακατασκευής PCA

Παρατηρώντας τα αποτελέσματα της μετρικής (3.10) του σφάλματος ανακατασκευής του παραθύρου μέσω της PCA για τον αλγόριθμο του κυλιόμενου παραθύρου. Διαπιστώθηκε ότι οι μονοδιάστατες ροές $d(t)$ έχουν μη γραμμική δομή δηλαδή παρατηρούνται κάθετες τμηματικές μετατοπίσεις των τιμών ανομοιογένειας (βλ. Σχήμα 5.13α), 5.18α), 5.23α), 5.28α)). Σκοπός της μετά-ανάλυσης είναι η επεξεργασία αυτών των ροών έτσι ώστε να αυξηθεί η απόδοση. Επίσης παρατηρήθηκε ότι ο συνδιασμός της μετρικής της διαφοράς των μέσων όρων (3.5) με την προεπεξεργασία της κανονικοποίησης έδωσε την καλύτερη μέση επίδοση ($\overline{TPR} = 60.9\%$, $\overline{FPR} = 45.3\%$) για όλα τα σύνολα πολυδιάστατων ροών δεδομένων. Όπως είναι αντιληπτό η εφαρμογή αυτού του συνδιασμού στην μονοδιάστατη μη στατική ροή $d(t)$ που προκύπτει απ' την μετρική (3.10) πιθανώς να συμβάλλει στην αύξηση της απόδοσης. Παρακάτω παρουσιάζονται τα αποτελέσματα την μετά-επεξεργασίας των ροών ανομοιογένειας $d(t)$ της μετρικής (3.10) για κάθε περίπτωση προεπεξεργασίας και για κάθε χρήστη των συνόλων που επεξεργαστήκαμε.

Προε/σία Χρήστες	Καμία (<i>TPR, FPR</i>)	Κανο/ση (<i>TPR, FPR</i>)	DFT (<i>TPR, FPR</i>)	Auto/er (<i>TPR, FPR</i>)	$ K $	$ \hat{K} $
1	(74.1,25.9)	(62.9,37)	(62.9,37)	-	27	27
2	(44.4,85.2)	(55.5,81,5)	(11.1,96.2)	-	9	27
($\overline{TPR}, \overline{FPR}$)	(59.3,55.5)	(59.3,59.3)	(37,66.6)	-		


Πίνακας 5.29 Αποτελέσματα του αλγορίθμου του κυλιόμενου παραθύρου ($s = 50$) με την μετρική της διαφ. μέσω των όρων και της κανονικοποίησης στην ροή $d(t)$ για την περίπτωση του συνόλου δεδομένων Crowsignals



Σχήμα 5.35 α) Ροή ανομοιογένειας β) σωστά εντοπισμένα σημεία αλλαγής της μεταεπεξεργασίας για τον χρήστη 1 (περίπτωση προεπεξεργασίας: καμία)

Προε/σία Χρήστες	Καμία (<i>TPR, FPR</i>)	Κανο/ση (<i>TPR, FPR</i>)	DFT (<i>TPR, FPR</i>)	Auto/er (<i>TPR, FPR</i>)	<i>K</i>	<i>K̂</i>
1	(30.7,73.3)	(30.7,73.3)	(23.1,80)	-	13	15
2	(42.9,60)	(42.9,60)	(35.7,66.6)	-	14	15
3	(25,80)	(25,80)	(25,80)	-	12	15
4	(46.6,53.3)	(40,60)	(46.6,53.4)	-	15	15
5	(60,40)	(53.3,46.6)	(60,40)	-	15	15
6	(53.9,53.3)	(38.5,66.6)	(30.7,73.3)	-	13	15
7	(9.1,93.3)	(9.1,93.3)	(9.1,93.3)	-	11	15
8	(40,60)	(40,60)	(33.3,66.6)	-	15	15
9	(46.1,60)	(30.7,73.3)	(30.7,73.3)	-	13	15
(<i>TPR, FPR</i>)	(39.4,63.6)	(34.5,68.2)	(32.7,69.6)	-		


Πίνακας 5.30 Αποτελέσματα του αλγορίθμου του κυλιόμενου παραθύρου ($s = 350$) με την μετρική της διαφ. μέσω των όρων και της κανονικοποίησης στην ροή $d(t)$ για την περίπτωση του συνόλου δεδομένων HHAR Phone



Σχήμα 5.36 α) Ροή ανομοιογένειας β) σωστά εντοπισμένα σημεία αλλαγής της μετά-επεξεργασίας για τον χρήστη 5 (περίπτωση προεπεξεργασίας: κανονικοποίησης)

Προε/σία Χρήστες	Καμία (<i>TPR, FPR</i>)	Κανο/ση (<i>TPR, FPR</i>)	DFT (<i>TPR, FPR</i>)	Auto/er (<i>TPR, FPR</i>)	<i>K</i>	<i>K̂</i>
1	(15.4,86.6)	(15.4,86.6)	(23.1,80)	-	13	15
2	(7.1,93.3)	(14.3,86.6)	(7.1,93.3)	-	14	15
3	(33.3,73.3)	(25,80)	(33.3,73.3)	-	12	15
4	(20,80)	(26.7,73.3)	(26.6,73.3)	-	15	15
5	(20,80)	(20,80)	(20,80)	-	15	15
6	(7.7,93.3)	(30.7,73.3)	(0,100)	-	13	15
7	(18.2,86.6)	(36.4,73.3)	(27.3,80)	-	11	15
8	(26.6,73.3)	(13.3,86.6)	(20,80)	-	13	15
9	(30.7,73.3)	(30.7,73.3)	(23.1,80)	-	13	15
(<i>TPR, FPR</i>)	(19.9,82.2)	(23.61,79.2)	(20,82.2)	-		


Πίνακας 5.31 Αποτελέσματα του αλγορίθμου του κυλιόμενου παραθύρου ($s = 550$) με την μετρική της διαφ. μέσω των όρων και της κανονικοποίησης στην ροή $d(t)$ για την περίπτωση του συνόλου δεδομένων HHAR Watch



Σχήμα 5.37 α) Ροή ανομοιογένειας β) σωστά εντοπισμένα σημεία αλλαγής της μετά-επεξεργασίας για τον χρήστη 7 (περίπτωση προεπεξεργασίας: κανονικοποίησης)

Προε/σία Χρήστες	Καμία (<i>TPR, FPR</i>)	Κανο/ση (<i>TPR, FPR</i>)	DFT (<i>TPR, FPR</i>)	Auto/er (<i>TPR, FPR</i>)	<i>K</i>	<i>K̂</i>
1	(63.6,36.4)	(63.6,36.4)	(54.5,45.5)	-	11	11
2	(90.1,9.9)	(72.7,27.3)	(72.7,27.3)	-	11	11
3	(63.6,36.4)	(72.7,27.3)	(81.8,18.2)	-	11	11
4	(81.8,18.2)	(81.8,18.2)	(81.8,18.2)	-	11	11
5	(54.5,45.5)	(72.7,27.3)	(63.6,36.4)	-	11	11
6	(72.7,27.3)	(90.9,9.1)	(90.9,9.1)	-	11	11
7	(72.7,27.3)	(90.9,9.1)	(81.8,18.2)	-	11	11
8	(72.7,27.3)	(81.8,18.2)	(81.8,18.2)	-	11	11
9	(63.6,36.4)	(90.9,9.1)	(81.8,18.2)	-	11	11
10	(72.7,27.3)	(90.9,9.1)	(81.8,18.2)	-	11	11
(<i>TPR, FPR</i>)	(70.9,29.1)	(80.9,19.1)	(77.3,22.7)	-		


Πίνακας 5.32 Αποτελέσματα του αλγορίθμου του κυλιόμενου παραθύρου ($s = 240$) με την μετρική της διαφ. μέσω των όρων και της κανονικοποίησης στην ροή $d(t)$ για την περίπτωση του συνόλου δεδομένων MHealth



Σχήμα 5.38 α) Ροή ανομοιογένειας β) σωστά εντοπισμένα σημεία αλλαγής της μετα-επεξεργασίας για τον χρήστη 10 (περίπτωση προεπεξεργασίας: κανονικοποίησης)

Προε/σία	Καμία (<i>TPR, FPR</i>)	Κανο/ση (<i>TPR, FPR</i>)	DFT (<i>TPR, FPR</i>)	Auto/er (<i>TPR, FPR</i>)
Μετ. επεξ. PCA	47.4 57.6	49.6 56.5	41.7 60.3	-

Πίνακας 5.33 Μέση απόδοση της μεταεπεξεργασίας της ροής $d(t)$ που προκύπτει από την μετρική (5.10) σε όλα τα σύνολα



Σχήμα 5.39 Αναπαράσταση των μέσων αποδόσεων όλων των συνόλων του αλγορίθμου του κυλιόμενου παραθύρου με την μετρική της διαφ. μέσων όρων (3.7) και της κανονικοποίησης στην ροή $d(t)$ που προκύπτει από την μετρική (3.10) για όλα τα σύνολα

Προφανώς παρατηρείται αύξηση των αποδόσεων για τα σύνολα ροών MHealth HHAR Phone, HHAR Watch και Crowdsignals μετά την επεξεργασία της $d(t)$ ροής που προκύπτει από την μετρική (3.10) για την πλειονότητα (75%) των περιπτώσεων προεπεξεργασίας (βλ. Πίνακα 5.34) όπως επίσης η μέση απόδοση όλων των συνόλων έχει αυξηθεί για όλες τις περιπτώσεις προεπεξεργασίας (βλ Πίνακα 5.35).

Προε/σία	Καμία	Κανο/ση	DFT	Auto/er
	$\pm(TPR, FPR)$	$\pm(TPR, FPR)$	$\pm(TPR, FPR)$	$\pm(TPR, FPR)$
C	+5.6 -5.6	-5.5 +4.6	-11.2 +7.3	-
HP	+21.8 -20.1	+16.3 -14.5	+19.1 -17.8	-
HW	-0.2 -1.7	+7.1 -6.7	+7.7 -8.1	-
M	+52.7 -52.7	+53.6 -53.6	+50.9 -50.9	-

Πίνακας 5.34 Αναπαράσταση των διαφορών των επιδόσεων πριν και μετά την επεξεργασία της ροής $d(t)$ που προκύπτει από την μετρική (3.10) για κάθε προεπεξεργασία και για κάθε σύνολο ροών

Προε/σία	Καμία	Κανο/ση	DFT	Auto/er
.	$\pm(\overline{TPR}, \overline{FPR})$	$\pm(\overline{TPR}, \overline{FPR})$	$\pm(\overline{TPR}, \overline{FPR})$	$\pm(\overline{TPR}, \overline{FPR})$
Διαφορά Πριν-Μετ. επεξ. PCA	+20 -20	+17.6 -18.1	+16.6 -17.4	-

Πίνακας 5.35 Αναπαράσταση των διαφορών των μέσων επιδόσεων πριν και μετά την επεξεργασία της ροής $d(t)$ που προκύπτει από την μετρική (3.10) για όλα τα σύνολα ροών.

ΚΕΦΑΛΑΙΟ 6.

ΣΥΝΟΨΗ-ΜΕΛΛΟΝΤΙΚΗ ΕΡΓΑΣΙΑ

6.1 Σύνοψη

6.2 Μελλοντική Εργασία

6.1 Σύνοψη

Στην παρούσα εργασία μελετήθηκε το πρόβλημα εντοπισμού σημείων αλλαγής σε πολυδιάστατες ροές σημάτων με εφαρμογή σε ροές που προέρχονται από σύστημα αισθητήρων που καταγράφουν ανθρώπινες δραστηριότητες. Η μελέτη εστιάστηκε στις μεθόδους του κυλιόμενου και αυξανόμενου παραθύρου. Εξετάστηκαν μετρικές που ενσωματώθηκαν στον αλγόριθμο κυλιόμενου παραθύρου με σκοπό την αποτύπωση των αλλαγών των κατανομών των δειγμάτων στο παράθυρο. Κάποιες απ' τις μετρικές που χρησιμοποιήθηκαν όπως η διαφορά των μέσων όρων έχουν εφαρμοσθεί στην βιβλιογραφία για την κατάτμηση ροών από σήματα ενώ οι μετρικές των αθροισμάτων αποστάσεων, της σύγκρισης των εξωτερικών και εσωτερικών αποστάσεων του παραθύρου έχουν χρησιμοποιηθεί για κατάτμηση κειμένων. Επίσης εφαρμόστηκε και το dip test για τον εκτίμηση του βαθμού πολυτροπικότητας των διανυσμάτων απόστασης μεταξύ των μέσων των ημιπαραθύρων και των δειγμάτων του κυλιόμενου παραθύρου. Η μετρική που προτείνουμε σ' αυτή την εργασία είναι το σφάλμα ανακατασκευής των δειγμάτων του παραθύρου μέσω της ανάλυσης των κυρίων συνιστωσών (PCA).

Στο δεύτερο σκέλος της εργασίας προτείνουμε τον αλγόριθμο του αυξανόμενου παραθύρου που εντοπίζει σε πραγματικό χρόνο (online) τα υποψήφια σημεία αλλαγής και βασίζεται στον εντοπισμό πολυτροπικών δειγμάτων στο παράθυρο της ροής μέσω του στατιστικού τεστ dip test.

6.2 Μελλοντική Εργασία

Για την περίπτωση του αλγορίθμου του κυλιόμενου παραθύρου θα μπορούσε να εφαρμοσθεί η προεπεξεργασία Wavelet στα σήματα για πιθανή εξαγωγή καλύτερων χαρακτηριστικών. Επίσης δεν ερευνήθηκε η εκτίμηση ενός κατωφλίου μ_0 με το οποίο ο αλγόριθμος του κυλιόμενου παραθύρου εντοπίζει σε πραγματικό χρόνο τα σημεία αλλαγής. Γενικά στην βιβλιογραφία έχουν αναπτυχθεί HAR συστήματα για τον εντοπισμό υψηλού επιπέδου δραστηριοτήτων, διεπαφών μεταξύ ανθρώπων [7] αλλά και ανθρώπων με το περιβάλλον. Για παράδειγμα η δραστηριότητα ‘πίνω καφέ’ είναι υψηλού επιπέδου και χρειάζεται διαφορετική προσέγγιση όσον αφορά την επιλογή των κατάλληλων αισθητήρων, το πλήθος τους, και την σωστή τοποθέτηση τους ώστε να επιτευχθεί η καλύτερη δυνατή περιγραφή του φαινομένου. Σ’ αυτή την περίπτωση χρειάζονται αισθητήρες που να καταγράφουν την κίνηση και των αντικειμένων (object sensors), για παράδειγμα για να εντοπιστεί η δραστηριότητα ‘πίνω καφέ’ χρειάζονται αισθητήρες που καταγράφουν την κίνηση της κούπας του καφέ σε συνδυασμό με αυτούς που καταγράφουν την κίνηση του χρήστη. Αισθητήρες που καταγράφουν περιβαντολογικές ενδείξεις [8] πχ, θερμοκρασία ατμοσφαιρική πίεση (ambient sensors) είναι χρήσιμοι για να αποτυπώσουν πληροφορίες που αφορούν διεπαφή χρήστη με το περιβάλλον. Σε γενικές γραμμές ο εντοπισμός τέτοιων σχετικά δύσκολων φαινομένων απαιτεί υψηλή τεχνική υποστήριξη και κατάλληλη συλλογή δεδομένων ώστε να τροφοδοτηθούν στο μοντέλο εντοπισμού αλλαγών δραστηριοτήτων. Επομένως είναι ανοιχτή πρόκληση η ανάπτυξη μεθόδων που θα εντοπίζουν αλλαγές υψηλού επιπέδου δραστηριοτήτων για διάφορες καταστάσεις.

ΑΝΑΦΟΡΕΣ

- [1] Ewan S Page. ‘Continuous inspection schemes’. *Biometrika* 41.(1/2/1954), pp. 100–115. 1954.
- [2] David Rybach et al. ‘Audio segmentation for speech recognition using segment features’. *Proc ICASSP 2009*. pp. 4197–4200, 2009.
- [3] Ping Yang, Guy Dumont, and John Mark Ansermino, ‘Adaptive change detection in heart rate trend monitoring in anesthetized children’. *IEEE Transactions on Biomedical Engineering* 53.(11), pp. 2211–2219, 2006.
- [4] Sasank Reddy et al. ‘Using mobile phones to determine transportation modes’. *ACM Transactions on Sensor Networks (TOSN)* 6.(2), 2010.
- [5] J. A. Hartigan and P. M. Hartigan, ‘The dip test of unimodality’ *The Annals of Statistics*, vol. 13, no. 1, pp. 70–84, 1985.
- [6] Jindong Wang, Yiqiang Chen, Shuji Hao, Xiaohui Peng, Lisha HU, ‘Deep Learning for sensor-based activity recognition: A survey’. *Pattern Recognition Letters*, pp 1-9, 2018.
- [7] Y. Kim Toumajian, ‘Hand gesture recognition using micro-doppler signatures with CNN’, *IEEE Access*, 2016.
- [8] A. Wang, G. Chen, C. Shang, M. Zhang, L. Liu, ‘Human activity recognition in a smart home environment with stacked denoising autoencoders’ *International Conference on Web-Age Information Management*, pp 29-40, 2016.
- [9] M. Lavielle, and E. Moulines, ‘Least-squares estimation of an unknown number of shifts ’ in a time series’. *Journal of Time Series Analysis*, 21(1):33–59, 2000.

- [10] A. Sen and M. S. Srivastava, ‘On tests for detecting change in mean’. *The Annals of Statistics*, 3(1):98–108, 1975.
- [11] S. I. M. Ko, T. T. L. Chong, and P. Ghosh, ‘Dirichlet process hidden Markov multiple change-point model’. *Bayesian Analysis*, 10(2):275–296, 2015.
- [12] P. C. Mahalanobis, ‘On the generalised distance in statistics’. *Proceedings of the National Institute of Sciences of India*, 2(1):49–55, 1936.
- [13] J. V. Davis, B. Kulis, P. Jain, S. Sra, and I. S. Dhillon. ‘Information-theoretic metric learning’. *24th International Conference on Machine Learning (ICML)*, pages 209–216, Corvallis, Oregon, USA, 2007.
- [14] J. Bai. ‘Least squares estimation of a shift in linear processes’. *Journal of Time Series Analysis*, 15(5):453–472, 1994.
- [15] J. Bai, R. L. Lumsdaine, and J. H. Stock, ‘Testing for and dating common breaks in multivariate time series’. *Review of Economic Studies*, 65(3):395–432, 1998.
- [16] J. H. J. Einmahl and I. W. McKeague, ‘Empirical likelihood based hypothesis testing’. *Bernoulli*, 9(2):267–290, 2003.
- [17] Piotr Fryzlewicz, ‘Wild binary segmentation for multiple change-point detection’. *Annals of Statistics*, 42(6):2243–2281, 2014.
- [18] M. Basseville and I. Nikiforov, ‘Detection of abrupt changes: theory and application’, Prentice Hall Englewood Cliffs, 1993.
- [19] Jie Chen and Arjun K. Gupta, ‘Parametric Statistical Change Point Analysis’. *Birkh’auser Boston*, 2011. doi: 10.1007/978-0-8176-4801-5.
- [20] Roman Kern and Michael Granitzer ‘Efficient Linear Text Segmentation Based on Information Retrieval Techniques’ at Conference: MEDES '09 International ACM Conference on Management of Emergent Digital EcoSystems, Lyon, France, October 27-30, 2009.
- [21] Vasileios T. Chasanis, Antonis I. Ioannidis and Aristidis C. Likas ‘Efficient Key-frame Extraction Based on Unimodality of Frame Sequences’ at Proc. ICSP, China 2014.

- [22] Stephan Spiegel, Ernesto William De Luca 'Pattern Recognition and Classification for Multivariate Time Series' at DOI: 10.1145/2003653.200365 SensorKDD, August 2011.
- [23] Adriana G. Wilde 'An Overview of Human Activity Detection Technologies for Pervasive Systems' Seminar paper, 2010.
- [24] Wei-Han Lee Jorge Ortiz Bongjun Ko Ruby Lee 'Time Series Segmentation through Automatic Feature Learning' at arXiv: 1801.05394, 2018.
- [25] M. Zeng L.T Nguyen, B, Yu O.J Mengshoel, J. Zhu P. Wu, J. Zhang, 'Convolutional Neural Networks For Human Activity Recognition Using Mobile Sensors in Mobile Computing Applications and Services (MobiCase), 6th International Conference on IEEE 2014 pp, 192-197.
- [26] Banos, O., Garcia, R., Holgado, J. A., Damas, M., Pomares, H., Rojas, I., Saez, A., Villalonga, C. mHealthDroid: a novel framework for agile development of mobile health applications. Proc. of the 6th International Work-conference on Ambient Assisted Living an Active Ageing (IWAAL 2014), Belfast, Northern Ireland, December 2-5, 2014.
- [27] Allan Stisen, Henrik Blunck, Sourav Bhattacharya, Thor Siiger Prentow, Mikkel Baun Kjærgaard, Anind Dey, Tobias Sonne, and Mads Møller Jensen "Smart Devices are Different: Assessing and Mitigating Mobile Sensing Heterogeneities for Activity Recognition", Proc. 13th ACM Conference on Embedded Networked Sensor Systems (SenSys 2015), Seoul, Korea, 2015].
- [28] Charles Truonga, Laurent Oudre, Nicolas Vayatis, 'Selective review of offline change point detection methods' at CMLA, CNRS, ENS Paris Saclay bL2TI, University Paris 13.
- [29] <http://algorithmsnap.com/>

ΣΥΝΤΟΜΟ ΒΙΟΓΡΑΦΙΚΟ

Ο Ιωάννης Φωτόπουλος γεννήθηκε στην Κοζάνη εν έτη 1993. Ολοκλήρωσε το προπτυχιακό πρόγραμμα σπουδών του Τμήματος Μαθηματικών του Πανεπιστημίου Ιωαννίνων τον Γενάρη του 2017, και απ' τον Φεβρουάριο του 2018 ξεκίνησε να φοιτά στο μεταπτυχιακό πρόγραμμα σπουδών του Τμήματος Μηχανικών Η/Υ και Πληροφορικής του Πανεπιστημίου Ιωαννίνων. Τα κύρια ενδιαφέροντα του επικεντρώνονται στους τομείς της μηχανικής μάθησης, εφαρμοσμένης στατιστικής, επεξεργασίας σήματος/εικόνας, αλγορίθμων βελτιστοποίησης και των εφαρμογών τους.