



Παραδοτέο Π3.1: Προδιαγραφές αλγορίθμων μηχανικής μάθησης

Ενότητα Εργασίας 3 (ΕΕ3)

**ΔΡΑΣΗ ΕΘΝΙΚΗΣ ΕΜΒΕΛΕΙΑΣ:  
«ΕΡΕΥΝΩ-ΔΗΜΙΟΥΡΓΩ-ΚΑΙΝΟΤΟΜΩ»  
«ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ, ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ & ΚΑΙΝΟΤΟΜΙΑ» (ΕΠΑνεΚ)**

**ΤΙΤΛΟΣ: HEART - Έξυπνη συσκευή και λογισμικό για την ανάλυση δεδομένων  
κατανάλωσης ηλεκτρικής ενέργειας σε πραγματικό χρόνο  
ΑΚΡΩΝΥΜΙΟ: HEART  
ΚΩΔΙΚΟΣ ΕΡΓΟΥ: Τ2ΕΔΚ-03898**



Ευρωπαϊκή Ένωση  
Ευρωπαϊκό Ταμείο  
Περιφερειακής Ανάπτυξης



ΕΛΛΗΝΙΚΗ ΔΗΜΟΚΡΑΤΙΑ  
ΥΠΟΥΡΓΕΙΟ  
ΟΙΚΟΝΟΜΙΑΣ & ΑΝΑΠΤΥΞΗΣ  
ΕΙΔΙΚΗ ΓΡΑΜΜΑΤΕΙΑ ΕΠΑ & ΤΣ  
ΕΙΔΙΚΗ ΥΠΗΡΕΣΙΑ ΔΙΑΧΕΙΡΙΣΗΣ ΕΠΑνεΚ



ΕΛΛΗΝΙΚΗ ΔΗΜΟΚΡΑΤΙΑ  
Υπουργείο Παιδείας,  
Ερευνας και Θρησκευμάτων



ΓΕΝΙΚΗ ΓΡΑΜΜΑΤΕΙΑ  
ΕΡΕΥΝΑΣ ΚΑΙ ΤΕΧΝΟΛΟΓΙΑΣ



ΕΥΔΕ  
ΕΣΟΚ

ΕΠΑνεΚ 2014-2020  
ΕΠΙΧΕΙΡΗΣΙΑΚΟ ΠΡΟΓΡΑΜΜΑ  
ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ  
ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ  
ΚΑΙΝΟΤΟΜΙΑ



ΕΣΠΑ  
2014-2020  
ανάπτυξη - εργασία - αλληλεγγύη

Με τη συγχρηματοδότηση της Ελλάδας και της Ευρωπαϊκής Ένωσης

HEART - ΚΩΔΙΚΟΣ ΕΡΓΟΥ Τ2ΕΔΚ-03898  
«ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ,  
ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ & ΚΑΙΝΟΤΟΜΙΑ»  
(ΕΠΑνεΚ)

ΤΙΤΛΟΣ ΠΑΡΑΔΟΤΕΟΥ  
Υποδομή Αποθήκευσης και Διαχείρισης  
Δεδομένων

## Πνευματικά δικαιώματα

© Copyright 2020 Κοινοπραξία HEART

Αποτελούμενη από:

- NET2GRID HELLAS
- ΗΡΩΝ ΘΕΡΜΟΗΛΕΚΤΡΙΚΗ ΑΝΩΝΥΜΗ ΕΤΑΙΡΕΙΑ
- ΕΡΓΑΣΤΗΡΙΟ ΕΠΙΣΤΗΜΗΣ ΔΕΔΟΜΕΝΩΝ ΚΑΙ ΙΣΤΟΥ (DATA LAB) ΤΜΗΜΑΤΟΣ ΠΛΗΡΟΦΟΡΙΚΗΣ ΑΡΙΣΤΟΤΕΛΕΙΟΥ ΠΑΝΕΠΙΣΤΗΜΙΟΥ ΘΕΣΣΑΛΟΝΙΚΗΣ

Το παρακάτω έγγραφο δεν είναι προς αντιγραφή, επαναχρησιμοποίηση ή προς αλλαγή μέρους του ή ολόκληρου χωρίς την έγγραφη άδεια της κοινοπραξίας HEART. Επιπλέον, επιβάλλεται η αναγνώριση των συγγραφέων του εγγράφου. Όλες οι εφαρμοστέες μερίδες του σημειώματος των πνευματικών δικαιωμάτων πρέπει να αναφέρονται ξεκάθαρα.

Με επιφύλαξη παντός δικαιώματος

Το έγγραφο μπορεί να αλλάξει ανά πάσα στιγμή

HEART - ΚΩΔΙΚΟΣ ΕΡΓΟΥ Τ2ΕΔΚ-03898 «ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ, ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ & ΚΑΙΝΟΤΟΜΙΑ» (ΕΠΑνεΚ)	ΤΙΤΛΟΣ ΠΑΡΑΔΟΤΕΟΥ Υποδομή Αποθήκευσης και Διαχείρισης Δεδομένων
--	---

## Document Classification

<b>Τίτλος</b>	Προδιαγραφές αλγορίθμων μηχανικής μάθησης
<b>Παραδοτέο</b>	Π3.1
<b>Τύπος</b>	Έκθεση
<b>Πακέτο Εργασίας</b>	ΕΕ1
<b>Φορείς</b>	Α.Π.Θ.
<b>Συγγραφείς</b>	Δημητριάδης Ηλίας, Καρανάτσιου Δήμητρα, Ποιητής Μαρίνος
<b>Επίπεδο Διάδοσης</b>	ΔΗΜΟΣΙΟ

## Abstract

Η ενότητα εργασίας 3, επικεντρώνεται στην καταγραφή, μελέτη και την υλοποίηση των κατάλληλων αλγορίθμων μηχανικής μάθησης, βάσει των οποίων θα γίνει η εκπαίδευση των μοντέλων με απώτερο σκοπό την εξαγωγή γενικευμένων μοντέλων ανά συσκευή ενδιαφέροντος. Τα δεδομένα τα οποία θα χρησιμοποιηθούν προέρχονται από την αρχιτεκτονική συλλογής δεδομένων και μετρήσεων που τρέχει στις ενότητες εργασίας 1 και 2.

Στο συγκεκριμένο παραδοτέο παρουσιάζεται μια εκτενής βιβλιογραφική έρευνα που αφορά αλγόριθμους βασισμένους στην τεχνολογία της μη παρεμβατικής επιτήρησης φορτίων (Non intrusive load monitoring - NILM). Συγκεκριμένα αναλύονται διαφορετικές σύγχρονες μεθοδολογίες που έχουν διακριθεί για την αποτελεσματικότητά τους (state of the art), για τις οποίες παρουσιάζονται τα εκάστοτε πλεονεκτήματα και μειονεκτήματά τους. Πέρα από την ανάλυση αυτών, συστήνεται και η μεθοδολογία στην οποία τελικά θα

HEART - ΚΩΔΙΚΟΣ ΕΡΓΟΥ Τ2ΕΔΚ-03898 «ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ, ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ & ΚΑΙΝΟΤΟΜΙΑ» (ΕΠΑνεΚ)	ΤΙΤΛΟΣ ΠΑΡΑΔΟΤΕΟΥ Υποδομή Αποθήκευσης και Διαχείρισης Δεδομένων
--	---

επικεντρωθούμε στην προσπάθεια μας για εξαγωγή όσο το δυνατόν ακριβέστερων και αποτελεσματικών μοντέλων.

## Version Control

Version	Description	Name	Date
1.0	Αρχική Έκδοση	1.0	15/12/2020
2.0	Αναθεώρηση	2.0	15/1/2021
2.1	Αναθεώρηση	2.1	15/2/2021
3.0	Τελική έκδοση	3.0	25/2/2021

## Περιεχόμενα

### Κεφάλαιο 1: Εισαγωγή

HEART - ΚΩΔΙΚΟΣ ΕΡΓΟΥ Τ2ΕΔΚ-03898  
«ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ,  
ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ & ΚΑΙΝΟΤΟΜΙΑ»  
(ΕΠΑνεΚ)

ΤΙΤΛΟΣ ΠΑΡΑΔΟΤΕΟΥ  
Υποδομή Αποθήκευσης και Διαχείρισης  
Δεδομένων

Οι τεχνικές μη παρεμβατικής παρακολούθησης φορτίου (NILM) έχουν καταστεί μια από τις πιο σχετικές εναλλακτικές λύσεις για τον ενεργειακό διαχωρισμό, καθώς παρέχουν μια μέθοδο διαχωρισμού της ατομικής κατανάλωσης για συγκεκριμένες συσκευές, με σεβασμό στην ιδιωτικότητα των καταναλωτών και τη χρήση έξυπνων συσκευών. Η άνοδος των τεχνικών NILM (δες Εικόνα1) ενισχύθηκε επίσης από άνοδο ορισμένων αναδυόμενων τομέων, όπως το Internet of Things (IoT), τα Smart Grids (SG) ή τα Demand Response (DR) ενεργειακά προγράμματα, όπου οι πληροφορίες που παρέχονται από τη NILM μπορούν να είναι χρήσιμες για περαιτέρω λήψη αποφάσεων. Οι περισσότερες εφαρμογές που χρησιμοποιούν τεχνικές NILM επιδιώκουν ενεργειακή απόδοση, χρησιμοποιώντας πληροφορίες αναλυτικής ενέργειας για την παροχή ανατροφοδότησης στους τελικούς χρήστες, οι οποίοι μπορούν συνεπώς να λάβουν μέτρα για τη μείωση της κατανάλωσης ενέργειας μέσω της «ενεργειακής ευαισθητοποίησης».

Τα κύρια στάδια του NILM είναι:

1. Συλλογή δεδομένων: Τα ηλεκτρικά δεδομένα, συμπεριλαμβανομένων των δεδομένων ρεύματος, τάσης και ισχύος, λαμβάνονται από έξυπνους μετρητές, πίνακες απόκτησης ή χρησιμοποιώντας συγκεκριμένο υλικό
2. Ανίχνευση συμβάντος: ένα συμβάν είναι οποιαδήποτε αλλαγή στην κατάσταση μιας συσκευής με την πάροδο του χρόνου. Ένα γεγονός πρακτικά εντοπίζεται με διακυμάνσεις ισχύος και ρεύματος, οι οποίες μπορούν να ανιχνευθούν στα ηλεκτρικά δεδομένα που συλλέχθηκαν στην προηγούμενη φάση
3. Εξαγωγή χαρακτηριστικών: οι συσκευές παρέχουν πληροφορίες σημασμένου φορτίου ή διακριτών μεταξύ τους χαρακτηριστικών
4. Αναγνώριση φορτίου: χρησιμοποιώντας τις δυνατότητες που προσδιορίστηκαν προηγουμένως, πραγματοποιείται διαδικασία ταξινόμησης για να προσδιοριστεί ποιες συσκευές λειτουργούν σε μια καθορισμένη ώρα ή περίοδο, καθώς και οι καταστάσεις τους.

## Κεφάλαιο 2: Κατηγορίες μεθοδολογιών

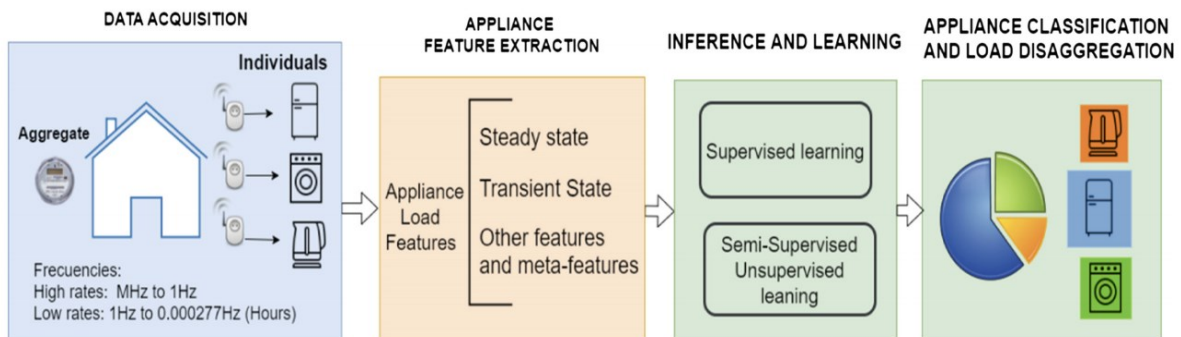
Με βάση το υπολογισθέν συνολικό φορτίο, βασικός στόχος των συστημάτων μη παρεμβατικής παρακολούθησης φορτίου είναι η ταξινόμηση του φορτίου, δηλαδή η ανίχνευση των συσκευών που λειτουργούν σε μια δεδομένη στιγμή. Αυτό μπορεί να

HEART - ΚΩΔΙΚΟΣ ΕΡΓΟΥ Τ2ΕΔΚ-03898  
«ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ,  
ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ & ΚΑΙΝΟΤΟΜΙΑ»  
(ΕΠΑνεΚ)

ΤΙΤΛΟΣ ΠΑΡΑΔΟΤΕΟΥ  
Υποδομή Αποθήκευσης και Διαχείρισης  
Δεδομένων

διατυπωθεί ως πρόβλημα βελτιστοποίησης ή ταξινόμησης, καθώς συνήθως εξετάζονται προς ανίχνευση τέσσερις τύποι (classes) συσκευών [1]:

- Τύπος I — Συσκευές ενεργοποίησης / απενεργοποίησης (On/Off): οι περισσότερες συσκευές σε νοικοκυριά, όπως λαμπτήρες και φρυγανιέρες.
- Τύπος II — Μηχανές πεπερασμένης κατάστασης (FSM): οι συσκευές σε αυτήν την κατηγορία παρουσιάζουν καταστάσεις, συνήθως σε περιοδική μορφή. Τέτοια παραδείγματα είναι το πλυντήριο / στεγνωτήριο, το ψυγείο και ούτω καθεξής.
- Τύπος III - Διαρκώς μεταβαλλόμενες συσκευές: η ισχύς αυτών των συσκευών ποικίλλει με την πάροδο του χρόνου, αλλά όχι με περιοδικό τρόπο. Παραδείγματα είναι τα dimmers και τα εργαλεία.
- Τύπος IV - Μόνιμες καταναλωτικές συσκευές: πρόκειται για συσκευές με σταθερή ισχύ που λειτουργούν 24 ώρες, όπως συναγερμοί και εξωτερικά τροφοδοτικά.



Εικόνα 1 (Non Intrusive Load Monitoring (NILM): A State of the Art)

Στη συνέχεια θα προσπαθήσουμε να περιγράψουμε συνοπτικά τις επικρατέστερες μεθόδους που έχουν παρουσιαστεί στην ευρύτερη βιβλιογραφία.

## 2.1 Προσεγγίσεις εποπτευόμενης μηχανικής μάθησης (Supervised Machine Learning)

Οι εποπτευόμενες τεχνικές χρησιμοποιούν εκπαίδευση εκτός σύνδεσης για την επίτευξη μιας βάσης δεδομένων πληροφοριών (ground truth) που χρησιμοποιείται για το σχεδιασμό του ταξινομητή. Το ground truth συλλέγεται είτε με την καταγραφή των λειτουργιών κάθε συσκευής με τη βοήθεια του τελικού χρήστη ή με την εγκατάσταση επιπλέον υπομέτρων μέσα το σπίτι. Μερικές κοινές τεχνικές εποπτευόμενης μάθησης

HEART - ΚΩΔΙΚΟΣ ΕΡΓΟΥ Τ2ΕΔΚ-03898  
«ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ,  
ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ & ΚΑΙΝΟΤΟΜΙΑ»  
(ΕΠΑνεΚ)

ΤΙΤΛΟΣ ΠΑΡΑΔΟΤΕΟΥ  
Υποδομή Αποθήκευσης και Διαχείρισης  
Δεδομένων

που έχουν εφαρμοστεί στο NILM είναι τα (ρηχά) Τεχνητά Νευρωνικά Δίκτυα, κυρίως τα Multilayer Perceptron (MLP) [2, 3], σε συνδυασμό με τα Convolutional Neural Networks (CNNs) [4], τα Deep Neural Networks [5-10], τα Support Vector Machines (SVM) [2], η μέθοδος K-Nearest Neighbours (k-NN) [11–13], οι naïve Bayes ταξινομητές [14, 13] και, πρόσφατα, τα τυχαία πεδία γραμμικής αλυσίδας (CRF), τα οποία λαμβάνουν υπόψη τον τρόπο με τον οποίο οι προηγούμενες καταστάσεις επηρεάζουν την τρέχουσα κατάσταση και μπορούν να αντιμετωπίσουν φορτία πολλαπλών καταστάσεων [15]. Όλα τα μοντέλα παρέχουν εξαιρετική απόδοση ταξινόμησης και μπορούν να ταυτοποιήσουν σωστά τις υπάρχουσες συσκευές, αποδεικνύοντας τη δυνατότητα εφαρμογής της προτεινόμενης προσέγγισης.

Επίσης, μια άλλη κατηγορία αλγορίθμων που έχουν χρησιμοποιηθεί στο NILM είναι οι αλγόριθμοι ταξινόμησης χρονικών σειρών, που μπορούν να κατηγοριοποιηθούν περαιτέρω σε τρεις ομάδες: ταξινόμηση βάσει απόστασης, ταξινόμηση βάσει χαρακτηριστικών, ταξινόμηση βάσει μοντέλου. Η ταξινόμηση βάσει απόστασης και χαρακτηριστικών λειτουργούν με τα πραγματικά δεδομένα χρονοσειρών [21- 23]. Οι μέθοδοι που βασίζονται σε χαρακτηριστικά χωρίζουν το σήμα σε μικρές ακολουθίες ή παράθυρα και στη συνέχεια εξάγουν χαρακτηριστικά για να ταξινομήσουν κάθε ακολουθία, ενώ οι μέθοδοι που βασίζονται σε απόσταση χρησιμοποιούν άμεσες ακολουθίες [24]. Οι μέθοδοι που βασίζονται σε μοντέλα, από την άλλη πλευρά, μετατρέπουν δεδομένα χρονοσειρών σε στατιστικά και πιθανολογικά μοντέλα, όπως τα μοντέλα Hidden και Semi-Markov, και στη συνέχεια αναγνωρίζουν τα σήματα της συσκευής από αυτά τα μοντέλα. Επιπλέον, και στις τρεις ομάδες, υπάρχουν δύο πιθανές προσεγγίσεις για την ανάπτυξη ενός αλγορίθμου ταξινόμησης: η πρώτη αφορά το σχεδιασμό ενός εντελώς νέου αλγορίθμου που λειτουργεί με μια σειρά ωρών, συνήθως δημιουργώντας ένα νέο μέτρο απόστασης για διαδοχικά δεδομένα και η άλλη προσέγγιση είναι ο σχεδιασμός ενός μετασχηματισμού που θα μετατρέπει τα διαδοχικά δεδομένα σε ένα σύνολο ανεξάρτητων διανυσμάτων χαρακτηριστικών (π.χ. καθυστερημένες εισόδους) τα οποία μπορούν στη συνέχεια να μεταφερθούν σε οποιαδήποτε τυπικό αλγόριθμο μηχανικής μάθησης.

Σε γενικές γραμμές, το NILM μπορεί να θεωρηθεί πρόβλημα πολλαπλών ετικετών. Σε κάθε στιγμιαίο δείγμα, η τροφοδοσία ρεύματος συνδέεται σχεδόν πάντα με ένα μείγμα συσκευών. Κάθε συσκευή είναι επιπλέον μια ανεξάρτητη «ιδέα» που μπορεί να λειτουργεί ταυτόχρονα με άλλες. Η μέθοδος ταξινόμησης πολλαπλών ετικετών διερευνήθηκε για πρώτη φορά στο NILM με την προσέγγιση των [Δ. 25], όπου η δειγματοληψία ισχύος

HEART - ΚΩΔΙΚΟΣ ΕΡΓΟΥ Τ2ΕΔΚ-03898 «ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ, ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ & ΚΑΙΝΟΤΟΜΙΑ» (ΕΠΑνεΚ)	ΤΙΤΛΟΣ ΠΑΡΑΔΟΤΕΟΥ Υποδομή Αποθήκευσης και Διαχείρισης Δεδομένων
--	---

κάθε στιγμή και η αλλαγή του σε κυλιόμενα παράθυρα, χρησιμοποιήθηκαν για να αναγνωριστούν τρεις συγκεκριμένες συσκευές.

## 2.2 Προσεγγίσεις μη εποπτευόμενης μηχανικής μάθησης (Unsupervised Machine Learning)

Οι μη εποπτευόμενες μέθοδοι δεν απαιτούν εκπαίδευση κάποιου μοντέλου πριν από την ταξινόμηση. Αυτό αποτελεί σημαντικό πλεονέκτημα αφού, με αυτόν τον τρόπο, απαιτείται ελάχιστη προσπάθεια από τον χρήστη και η παρεμβατικότητα στη δημιουργία μιας βάσης δεδομένων μειώνεται. Ωστόσο, η ακρίβεια των μη εποπτευόμενων μεθόδων είναι γενικά μικρότερη από τις εποπτευόμενες μεθόδους. Η ομαδοποίηση των χαρακτηριστικών και η μετέπειτα επισήμανση κάθε συμπλέγματος με τα ουσιαστικά ονόματα συσκευών έχουν εφαρμοστεί σε κάποιες προσεγγίσεις με ικανοποιητικά αποτελέσματα [16, 17]. Επιπλέον, ο συνδυασμός μιας εποπτευόμενης εκπαιδευτικής διαδικασίας σε διαθέσιμα σετ δεδομένων με ετικέτα με μια μη επιτηρούμενη μέθοδο κατάρτισης σε συγκεντρωτικά δεδομένα χωρίς ετικέτα προτείνεται στο [18].

Σε σενάρια πραγματικού κόσμου, αναμένεται ότι το ground truth είναι δύσκολο να βρεθεί. Οι μη εποπτευόμενες μέθοδοι μάθησης είναι σαφώς κατάλληλες για αυτήν την κατάσταση, αλλά είναι γενικά επιθυμητή η υψηλή ακρίβεια που επιτυγχάνουν τα μοντέλα εποπτευόμενης μάθησης. Η μέση λύση βρίσκεται μεταξύ των δύο, είναι η ημι-εποπτευόμενη μάθηση, η οποία αναφέρεται στη χρήση ενός μικρού αριθμού επισημασμένων παρατηρήσεων για τη βελτίωση της ταξινόμησης ενός πολύ μεγαλύτερο σύνολο δεδομένων χωρίς ετικέτα. Αυτή η ιδέα έχει διερευνηθεί με Hidden Markov Models [19, 20], τα οποία αναλύονται σε επόμενη ενότητα.

### 2.2.1 HMM

Όπως έχει ήδη αναφερθεί, αντίθετα με τις προσεγγίσεις εποπτευόμενης μηχανικής μάθησης (NILM) για την μη παρεμβατική επιτήρηση φορτίων, οι μη εποπτευόμενες δεν χρειάζονται προεκπαίδευση κάποιου μοντέλου και είναι πιο κατάλληλες σε πραγματικού χρόνου εφαρμογές. Οι συγκεκριμένες μέθοδοι δεν χρειάζονται δεδομένα για την κάθε συσκευή και οι παράμετροι των μοντέλων που προκύπτουν βασίζονται μόνο στο συνολικό καταγεγραμμένο φορτίο, χωρίς την ανάγκη παρέμβασης από τον εκάστοτε χρήστη. Οι μη εποπτευόμενες μεθοδολογίες έχουν συγκεντρώσει το ενδιαφέρον των



HEART - ΚΩΔΙΚΟΣ ΕΡΓΟΥ Τ2ΕΔΚ-03898  
«ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ,  
ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ & ΚΑΙΝΟΤΟΜΙΑ»  
(ΕΠΑνεΚ)

ΤΙΤΛΟΣ ΠΑΡΑΔΟΤΕΟΥ  
Υποδομή Αποθήκευσης και Διαχείρισης  
Δεδομένων

ερευνητών λόγω του χαμηλού υπολογιστικού και μή κόστους καθώς και λόγω της αξιοπιστίας τους [26].

Οι μη εποπτευόμενες μεθοδολογίες μπορούν να χωριστούν σε τρεις βασικές κατηγορίες: (α) Μέθοδοι που χρειάζονται δεδομένα χωρίς ετικέτα: Είναι συνήθως βασισμένες στην χρήση των Hidden Markov Models (HMM) και τα μοντέλα συσκευών προκύπτουν είτε χειροκίνητα [27], είτε αυτόματα κατά τη διάρκεια της εκπαίδευσης [28]. Το βασικό τους μειονέκτημα είναι ότι δεν αποδίδουν καλά σε δεδομένα τα οποία δεν έχουν ξαναδεί (περιπτώσεις που δεν υπήρχαν στη διάρκεια της εκπαίδευσης).

(β) Μέθοδοι που χρησιμοποιούν επισημασμένα δεδομένα: Χρησιμοποιούν αυτά τα δεδομένα για τη διάκριση συσκευών σε μέχρι τώρα άγνωστα δεδομένα. Αυτές οι μέθοδοι απαιτούν δεδομένα που έχουν συλλεχθεί από μετρήσεις σε γνωστές συσκευές βάσει των οποίων στην συνέχεια κατασκευάζονται μοντέλα τα οποία χρησιμοποιούνται για τη διάκριση συσκευών σε άγνωστα σπίτια. Σε αυτή την κατηγορία εμπίπτουν κυρίως μέθοδοι που χρησιμοποιούν βαθιά νευρωνικά δίκτυα που αναλύονται σε επόμενη ενότητα.

(γ) Μέθοδοι που δεν χρειάζονται να περάσουν τη διαδικασία της εκπαίδευσης σε κάποια δεδομένα για την διάκριση διαφορετικών συσκευών. Αυτές οι μέθοδοι δεν χρειάζονται ούτε συγκεκριμένα δεδομένα για κάθε συσκευή αλλά ούτε πρότερη γνώση των εκάστοτε σεναρίων [29][30].

Στη συγκεκριμένη ενότητα θα αναλύσουμε περαιτέρω τις μεθοδολογίες που χρησιμοποιούν HMMs αλλά και Graph Signal Processing (GSP), καθώς είναι αυτές που αποδίδουν καλύτερα και χρησιμοποιούνται ευρύτερα από την ερευνητική κοινότητα.

Τα HMMs χρησιμοποιούνται εκτενώς για την πιθανολογική μοντελοποίηση διαδοχικών δεδομένων κι έχουν εφαρμογές σε διάφορες περιοχές όπως την φωνητική αναγνώριση, βιοπληροφορική, κτλ. Ένα διακριτό χρόνου HMM μπορεί να εννοηθεί ως ένα Μαρκοβιανό μοντέλο του οποίου οι καταστάσεις/φάσεις δεν είναι άμεσα παρατηρήσιμες. Αντιθέτως, κάθε φάση χαρακτηρίζεται από μια συνάρτηση κατανομής πιθανοτήτων, που μοντελοποιεί τις παρατηρήσεις που αντιστοιχούν σε αυτή τη φάση. Στην περίπτωση του NILM, οι κρυμμένες (μη παρατηρήσιμες) φάσεις χρησιμοποιούνται για να μοντελοποιήσετε τις διακριτές καταστάσεις των ηλεκτρικών συσκευών [ON, OFF, Stand by].

Ένα τυπικό HMM χαρακτηρίζεται από τα ακόλουθα: (α) Το πεπερασμένο σύνολο κρυφών φάσεων (hidden states)  $S = \{S_1, S_2, \dots, S_N\}$  μιας συσκευής. (β) το πεπερασμένο σύνολο των παρατηρήσιμων τιμών  $Y = \{Y_1, Y_2, \dots, Y_t\}$  που αντιστοιχεί στην κατανάλωση ενέργειας για κάθε φάση. Οι τιμές αυτές μπορεί να είναι διακριτές ή συνεχείς. (γ) ο πίνακας


HEART - ΚΩΔΙΚΟΣ ΕΡΓΟΥ Τ2ΕΔΚ-03898  
«ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ,  
ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ & ΚΑΙΝΟΤΟΜΙΑ»  
(ΕΠΑνεΚ)

ΤΙΤΛΟΣ ΠΑΡΑΔΟΤΕΟΥ  
Υποδομή Αποθήκευσης και Διαχείρισης  
Δεδομένων

μετάβασης  $A = \{a_{ij}, 1 \leq i, j \leq N\}$  αναπαριστά την πιθανότητα μετάβασης από τη φάση  $S_i$  στην  $S_j$ , έτσι ώστε  $a_{ij} = P(q_{t+1} = S_j | q_t = S_i)$ ,  $a_{ij} \leq 1$  όπου  $q_t$  είναι η φάση την οποία καταλαμβάνει το σύστημα την χρονική στιγμή  $t$ . (δ) τον πίνακα εκπομπής  $B = P(y_t | S_j)$  που αναπαριστά την πιθανότητα “εκπομπής” της τιμής  $Y_t \in Y$  όταν η φάση του συστήματος είναι  $S_j$ . Η αρχική πιθανολογική κατανομή φάσεων είναι  $\pi = \{\pi_i\}$  που δείχνει την πιθανότητα της κάθε φάσης μιας κρυφής μεταβλητής τη χρονική στιγμή  $t=1$  έτσι ώστε,  $\pi = P(q_1 = S_i)$ ,  $1 \leq i \leq N$ . Το σύνολο όλων των παραμέτρων ενός HMM αναπαριστάται από το  $\lambda = \{\pi, A, B\}$ .

Όταν εφαρμόζεται ένα HMM σε ένα πραγματικό πρόβλημα, υπάρχουν δύο βασικά ερωτήματα που πρέπει να απαντηθούν. Το πρώτο αφορά το πώς θα μάθουμε την  $\lambda$  παράμετρο του μοντέλου γνωρίζοντας την αλληλουχία της μεταβλητής  $Y$  και το δεύτερο, γνωρίζοντας την παράμετρο  $\lambda$  και την αλληλουχία των τιμών της μεταβλητής  $Y$ , πώς θα εξαχθεί η βέλτιστη ακολουθία των κρυφών φάσεων  $S$ . Αυτά τα ερωτήματα είναι γνωστά κι ως προβλήματα μάθησης και εξαγωγής, για την επίλυση των οποίων έχουν προταθεί διάφοροι αλγόριθμοι όπως ο Baum-Welch κι ο Viterbi [31].

Το παραγοντικό HMM (Factorial Hidden Markov Model - FHMM) είναι μια επέκταση του HMM με πολλαπλές ανεξάρτητες ακολουθίες κρυφών φάσεων κι όπου κάθε παρατήρηση εξαρτάται από πολλαπλές κρυφές μεταβλητές [32]. Στα FHMM, αν θεωρήσουμε ότι  $Y = \{y_1, y_2, \dots, y_r\}$  είναι η παρατηρήσιμη ακολουθία, τότε η  $S = \{S^{(1)}, S^{(2)}, \dots, S^{(M)}\}$  αναπαριστά το σύνολο των κρυφών φάσεων όπου  $S^{(i)} = \{S_1^{(i)}, S_2^{(i)}, \dots, S_T^{(i)}\}$  είναι η κρυφή ακολουθία της αλυσίδας  $i$  όπως φαίνεται στην εικόνα 2.



Εικόνα 2

Τα FHMM προτιμώνται έναντι των κλασσικών HMM όταν σκοπός είναι η μοντελοποίηση χρονοσειρών που προκύπτουν από την αλληλεπίδραση πολλαπλών ανεξάρτητων διεργασιών. Παρόλα αυτά η υπολογιστική πολυπλοκότητα των προβλημάτων της μάθησης και της εξαγωγής είναι υψηλότερη στα FHMM σε σχέση με HMM. Επιπλέον, οι τεχνικές εξαγωγής για τα FHMM είναι υπερευαίσθητες στα τοπικά βέλτιστα[33].

Περνώντας τώρα στις διάφορες προσεγγίσεις των HMM για NILM, θα παρατηρήσει κανείς ότι υπάρχει μια πληθώρα διαφορετικών προτάσεων από τους εκάστοτε ερευνητές. Σε μια από αυτές [34], οι συγγραφείς προτείνουν τον συνδυασμό τεσσάρων παραλλαγών του FHMM. Χρησιμοποιούν χαμηλής συχνότητας μετρήσεις πραγματικής ενέργειας και υποθέτουν πως οι ηλεκτρικές συσκευές έχουν μόνο δύο διακριτές φάσεις (ON/OFF). Για την μάθηση των παραμέτρων του μοντέλου χρησιμοποιούν τον αλγόριθμο Expectation Maximization (EM) και για την εξαγωγή των φάσεων τον Maximum Likelihood Estimation (MLE) αλγόριθμο. Η απόδοση της συγκεκριμένης μεθοδολογίας είναι σχετικά περιορισμένη, λόγω του ότι εφαρμόζεται σε  $s'$  έναν μικρό αριθμό συσκευών, απαιτεί τον χειροκίνητο χαρακτηρισμό των συσκευών μετά τον διαχωρισμό τους και είναι υψηλής υπολογιστικής πολυπλοκότητας που το καθιστά μη κατάλληλη λύση για εφαρμογές πραγματικού χρόνου.

HEART - ΚΩΔΙΚΟΣ ΕΡΓΟΥ Τ2ΕΔΚ-03898  
«ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ,  
ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ & ΚΑΙΝΟΤΟΜΙΑ»  
(ΕΠΑνεΚ)

ΤΙΤΛΟΣ ΠΑΡΑΔΟΤΕΟΥ  
Υποδομή Αποθήκευσης και Διαχείρισης  
Δεδομένων

Μια μετέπειτα ερευνητική προσπάθεια ήταν η [35] όπου οι συγγραφείς πρότειναν ένα νέο αλγόριθμο για την εξαγωγή των κρυφών φάσεων, τον Additive Factorial Approximate MAP (AFMAP) που είναι χαμηλότερης πολυπλοκότητας και πιο αποδοτικός. Ο AFMAP χρησιμοποιείται για να εκτελέσει μια προσεγγιστική εξαγωγή στο σωρευτικό FHMM. Παρά τα πλεονεκτήματα που ήδη αναφέραμε όμως, κι αυτή η μέθοδος απαιτεί τον χειροκίνητο χαρακτηρισμό των συσκευών και παρουσιάζει χαμηλή απόδοση για εξοπλισμό κουζίνας και ηλεκτρονικές συσκευές.

Ο Parson [28], παρουσίασε μία διαφορετική μεθοδολογία όπου για το πρόβλημα της εξαγωγής χρησιμοποίησε μια επέκταση του αλγορίθμου Viterbi και μια διαδικασία εκπαίδευσης βασισμένη στον EM για να δημιουργήσει ένα πιο γενικευμένο μοντέλο για την μάθηση των παραμέτρων του HMM μοντέλου. Αυτό το γενικευμένο μοντέλο ρυθμίζεται στη συνέχεια για συγκεκριμένα μοντέλα συσκευών χρησιμοποιώντας μόνο συγκεντρωτικά δεδομένα από σπίτια όπου εφαρμόζονται τεχνικές NILM. Η ενεργή διεργασία ρύθμισης προϋποθέτει την ύπαρξη ενός “χρονικού παραθύρου” δεδομένων όπου καμία άλλη συσκευή δεν αλλάζει κατάσταση. Για συσκευές σαν τα ψυγεία, αυτό είναι κάτι σχετικά εύκολο, καθώς συνήθως είναι οι μόνες ενεργές κατά τη διάρκεια της νύχτας, αλλά γενικά είναι δύσκολο να επιτευχθεί για άλλου τύπου συσκευές.

Ένα ολοκληρωτικά μη εμποτευόμενης μάθησης NILM μοντέλο το οποίο βασίζεται σε μη παραμετρικά FHMM χρησιμοποιώντας χαμηλής συχνότητας μετρήσεις πραγματικής ενέργειας, παρουσιάζεται στο [30]. Σε αυτό, χρησιμοποιείται ένας συνδυασμός δειγματοληψιών (slice & Gibbs) για να μπορέσουν να εξάγουν ταυτόχρονα και των αριθμό των συσκευών αλλά και το εκάστοτε ενεργειακό φορτίο μέσα από το συνολικό. Ωστόσο, για προβλήματα με μεγάλες διαχωριστικές ανάγκες, ο αλγόριθμος εξαγωγής πιθανόν να κολλήσει σε περιοχές με τοπικά βέλτιστα κι επιπλέον οι υψηλές υπολογιστικές ανάγκες του τον καθιστούν μη βέλτιστη λύση για εφαρμογές πραγματικού χρόνου. Μία άλλη προσέγγιση παρουσιάστηκε στο [27], όπου εισάγεται ένας νέος NILM αλγόριθμος, για χαμηλής συχνότητας δειγματοληψία που χρησιμοποιεί μια υπερ-κατάσταση στα HMM, στα οποία ένας συνδυασμός καταστάσεων μοντέλων συσκευών παρουσιάζεται σαν μία υπερ-κατάσταση. Εδώ προτείνεται μία νέα παραλλαγή του αλγορίθμου Viterbi, ο αποκαλούμενος αραιός αλγόριθμος Viterbi (sparse). Πρόκειται για μία αποδοτική υπολογιστικά μέθοδο, η οποία, εν αντιθέσει με τα FHMM που εξάγουν προσεγγιστικά συμπεράσματα, οδηγεί σε ακριβή συμπεράσματα. Η προσέγγιση αυτή διατηρεί τις εξαρτήσεις μεταξύ των συσκευών, μπορεί να τρέχει σε πραγματικό χρόνο σε κάποιο

HEART - ΚΩΔΙΚΟΣ ΕΡΓΟΥ Τ2ΕΔΚ-03898  
«ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ,  
ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ & ΚΑΙΝΟΤΟΜΙΑ»  
(ΕΠΑνεΚ)

ΤΙΤΛΟΣ ΠΑΡΑΔΟΤΕΟΥ  
Υποδομή Αποθήκευσης και Διαχείρισης  
Δεδομένων

φθηνό ενσωματωμένο επεξεργαστή και μπορεί να διακρίνει το ενεργειακό αποτύπωμα των συσκευών με πολύπλοκες ενεργειακές υπογραφές. Παρά τα πλεονεκτήματα της, υπόκειται σε διάφορους περιορισμούς που αφορούν κυρίως τον χρόνο και τον χώρο καθώς ο αριθμός των υπερ-καταστάσεων αυξάνει εκθετικά με τον αριθμό των εμπλεκόμενων συσκευών.

Συμπερασματικά, παρά το γεγονός ότι τα HMM έχουν χρησιμοποιηθεί ευρέως σε εφαρμογές μη παρεμβατικής επιτήρησης φορτίου, η απόδοση τους είναι περιορισμένη κυρίως λόγω του ότι εξαρτώνται κατά μεγάλο βαθμό από τα μοντέλα πρότερης γνώσης που χρησιμοποιούνται για να καθορίσουν εκ των προτέρων τιμές για συγκεκριμένες φάσεις της κάθε συσκευής. Επίσης, ενώ έχουν καλή απόδοση όταν μιλάμε για συσκευές με ελεγχόμενες πολλαπλές καταστάσεις (όπως το ψυγείο), δεν ανταποκρίνονται στις προσδοκίες όταν έχουμε να κάνουμε με μεταβλητές ή συσκευές μη ελεγχόμενων πολλαπλών φάσεων [36].

## 2.2.2 Επεξεργασία σήματος γράφων (GSP: Graph Signal Processing)

Το GSP αναπαριστά ένα σύνολο δεδομένων χρησιμοποιώντας ένα σήμα γράφου που ορίζεται από ένα σύνολο κόμβων κι ενός σταθμισμένου πίνακα γειτνίασης (weighted adjacency matrix). Κάθε κόμβος στο γράφο αντιστοιχεί σε ένα στοιχείο στο σύνολο δεδομένων, ενώ ο πίνακας γειτνίασης ορίζει όλες τις κατευθυνόμενες ακμές και τα βάρη τους, όπου το βάρος αντιστοιχεί ουσιαστικά στο βαθμό ομοιότητας μεταξύ των κόμβων [37]. Η μέθοδος GSP είναι κατάλληλη για προβλήματα ταξινόμησης δεδομένων στις οποίες οι περίοδοι εκπαίδευσης είναι σύντομες και όχι τόσο αποτελεσματικές για τη δημιουργία αντίστοιχων μοντέλων. Συγκεκριμένα στην περιοχή του NILM, μπορούμε να θεωρήσουμε τα παρακάτω: Έχοντας ένα σύνολο μετρήσεων συνολικής ισχύος  $X$ , ορίζουμε ένα γράφο  $G=\{V,A\}$ , όπου  $V$  είναι το σύνολο των κόμβων το οποίο αντιστοιχεί στις μετρήσεις και  $A$  είναι ο σταθμισμένος πίνακας γειτνίασης που ορίζουν τις ακμές του γράφου. Κάθε στοιχείο  $x_i \in X$  αντιστοιχεί σε έναν κόμβο  $v_i$  του  $V$  και κάθε βάρος  $A_{ij}$  μεταξύ των αντίστοιχων ακμών δείχνει το βαθμό συσχέτισης των μετρήσεων  $x_i$ ,  $x_j$ . Το βάρος ενός κόμβου  $A_{ij}$  ορίζεται συνήθως χρησιμοποιώντας μιας Gaussian Kernel μεθόδου, με πιο κοινή την ακόλουθη:  $A_{i,j} = \exp \left[ -\frac{(x_i - x_j)^2}{\rho^2} \right]$  όπου το  $\rho$  είναι παράγοντας κλιμάκωσης (scaling factor). Οι γράφοι και τα σήματα γράφων, μπορούν να χρησιμοποιηθούν επιτυχώς για την αναπαράσταση διαφόρων δομών δεδομένων όπως χρονοσειρές, εικόνες, κοινωνικά δίκτυα, κτλ. Στον τομέα του διαχωρισμού ενεργειακών φορτίων, κάθε

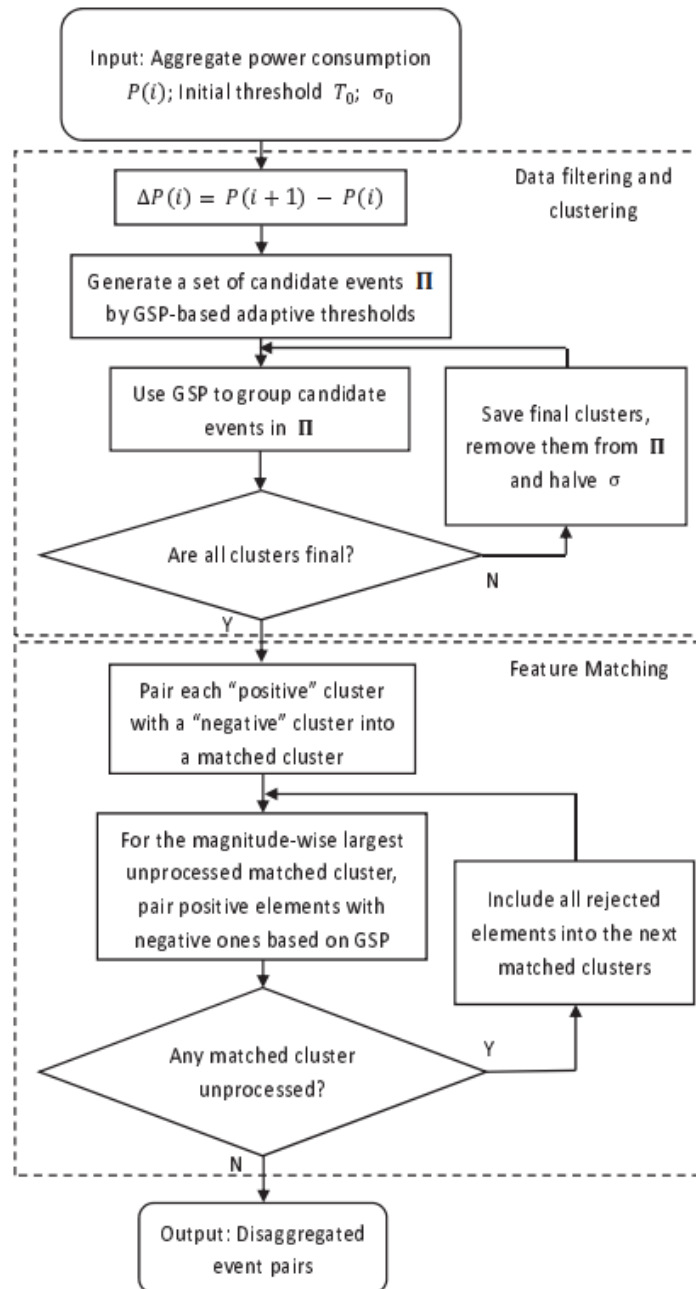
HEART - ΚΩΔΙΚΟΣ ΕΡΓΟΥ Τ2ΕΔΚ-03898  
«ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ,  
ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ & ΚΑΙΝΟΤΟΜΙΑ»  
(ΕΠΑνεΚ)

ΤΙΤΛΟΣ ΠΑΡΑΔΟΤΕΟΥ  
Υποδομή Αποθήκευσης και Διαχείρισης  
Δεδομένων

κόμβος έχει σχέση με τη συγκέντρωση του σήματος παραλλαγής ισχύος μεταξύ κοντινών μετρήσεων  $\Delta X_t$ , όπου  $\Delta X_t = X_{t+1} - X_t$ .

Η πρώτη ερευνητική προσπάθεια για NILM με την χρήση GSP παρουσιάστηκε σχετικά πρόσφατα [37], και δεν ήταν μια μέθοδος state-based ή event-based. Οι ερευνητές βασίστηκαν σε μια δουλειά που παρουσιάστηκε νωρίτερα και αφορούσε προβλήματα ταξινόμησης [38] σε γράφους, και κατάφεραν να εκτελέσουν χαμηλής πολυπλοκότητας ταξινόμηση πολλών κλάσεων στις μετρήσεις ενεργούς ισχύος χωρίς την ανάγκη να εντοπίσουν αλλαγές καταστάσεων στις συσκευές ως συμβάντα. Παρόλα αυτά, η προσέγγιση αυτή είναι επιβλεπόμενη και χρησιμοποιεί τα GSP μόνο για την ταξινόμηση των δεδομένων.

Στη συνέχεια οι ερευνητές Zhao et al [29, 39] προτείνουν μία “τυφλή” μεθοδολογία, σε δεδομένα χαμηλής συχνότητας για εντοπισμό συμβάντων αλλαγής κατάστασης με χρήση GSP χωρίς όμως την ανάγκη εκπαίδευσης. Στην συγκεκριμένη δουλειά, οι ερευνητές προχωρούν στη διάκριση των ενεργών ισχύων χωρίς να έχουν κάποια πρότερη γνώση, χρησιμοποιώντας GSP για την εύρεση προσαρμοσμένων τιμών κατωφλίου, για την ομαδοποίηση σημάτων και το ταίριασμα μοτίβων, βλέπε Εικόνα 3. Η προσέγγιση αυτή λειτουργεί καλά αν το μέσο φορτίο κάθε συσκευής είναι αρκετά διαφορετικό από αυτό άλλων συσκευών και εάν η ισχύς κάθε φορτίου δεν έχει πολλές διακυμάνσεις. Αυτό δεν είναι μια τυπική περίπτωση στα περισσότερα κτίρια, συνθήκη που περιορίζει την απόδοση αυτού του αλγορίθμου. Επιπλέον, η προτεινόμενη προσέγγιση απαιτεί την χειροκίνητη επισήμανση των συσκευών μετά την διεργασία διάκρισης τους, που επηρεάζεται ιδιαίτερα από τον θόρυβο που υπάρχει.



Εικόνα 3

HEART - ΚΩΔΙΚΟΣ ΕΡΓΟΥ Τ2ΕΔΚ-03898  
«ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ,  
ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ & ΚΑΙΝΟΤΟΜΙΑ»  
(ΕΠΑνεΚ)

ΤΙΤΛΟΣ ΠΑΡΑΔΟΤΕΟΥ  
Υποδομή Αποθήκευσης και Διαχείρισης  
Δεδομένων

### 2.3 Νευρωνικά Δίκτυα (Neural Networks)

Η μη παρεμβατική επιτήρηση φορτίων ξεκίνησε στα μέσα του 1980 με τη δουλειά του George Hart [40] ο οποίος περιγράφει μία ταξινόμια χαρακτηριστικών και επεξηγεί αναλυτικά τα χαρακτηριστικά αυτά, εστιάζοντας όμως μόνο σε μεταβάσεις σταθερών καταστάσεων. Στην περίπτωση των χαμηλών συχνοτήτων, πολλές τεχνικές ακολουθούν τη στρατηγική του Hart και εξάγουν περιορισμένα χαρακτηριστικά, παρ' όλα αυτά στις υψηλές συχνότητες υπάρχει πληθώρα ερευνών που εστιάζουν στην εξαγωγή μεγάλου όγκου δεδομένων [41].

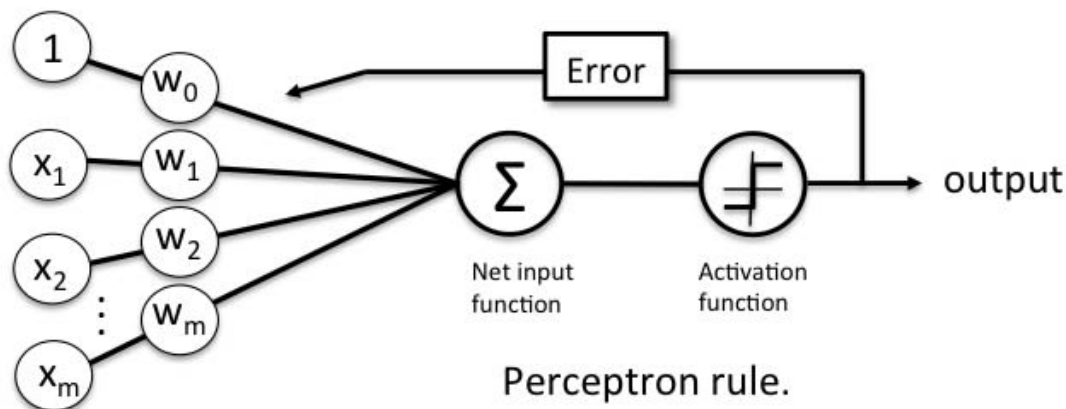
Η δημιουργία μεθόδων για την χειροκίνητη εξαγωγή των παραπάνω χαρακτηριστικών είναι μια πιθανή κατεύθυνση. Ωστόσο, εισάγει το πρόβλημα της μεγάλης υπολογιστικής πολυπλοκότητας, ενώ δεν εξασφαλίζει την ανθεκτικότητα των εξαγόμενων χαρακτηριστικών στο θόρυβο. Συνεπώς, το ερώτημα που προκύπτει είναι το εξής: Μπορεί να επιτευχθεί με κάποιον τρόπο αυτόματη και γρήγορη εξαγωγή ποιοτικών χαρακτηριστικών? Τα νευρωνικά δίκτυα είναι η απάντηση.

Τα νευρωνικά δίκτυα δεν αποτελούν καινούργια μεθοδολογία. Ωστόσο, απαιτούν μεγάλη υπολογιστική ισχύ για την εκπαίδευση τους. Με την εδραίωση των γραφικών μονάδων επεξεργασίας (GPU) οι απαιτήσεις αυτές μπορούν πλέον να καλυφθούν και να αναπτυχθούν βαθιά νευρωνικά δίκτυα με υψηλή περιγραφική δύναμη και ικανότητες πρόβλεψης. Όμως, τί είναι τα νευρωνικά δίκτυα? Στη βασική τους μορφή, πρόκειται για κατευθυνόμενους γράφους των οποίων οι κόμβοι αναπαριστούν τεχνητούς νευρώνες και οι ακμές επιτρέπουν την μετάδοση πληροφορίας ανάμεσα στους νευρώνες. Αυτοί οι νευρώνες οργανώνονται σε επίπεδα, ενώ συνδέσεις δημιουργούνται ανάμεσα στους νευρώνες δύο διαδοχικών επιπέδων. Ακόμη, οι συνδέσεις είναι ζυγισμένες και ο καθορισμός των συγκεκριμένων βαρών αποτελεί τη διαδικασία μέσω της οποίας τα νευρωνικά δίκτυα εκπαιδεύονται. Τέλος, βαθύ (deep) ονομάζεται ένα δίκτυο το οποίο αποτελείται από πολλαπλά επίπεδα νευρώνων.

Η διαδικασία της μάθησης διαφέρει ανάλογα με το είδος του νευρωνικού δικτύου. Το πρώτο στάδιο της μάθησης ονομάζεται εμπρόσθια τροφοδότηση (forward pass), στο οποίο οι είσοδοι του νευρωνικού δικτύου περνούν μέσω των συνάψεων από όλα τα επίπεδα νευρώνων και αποδίδουν τελικά μία ή περισσότερες εξόδους. Στην απλούστερη περίπτωση (Multilayer Perceptron, MLP), των βαθιών νευρωνικών δικτύων, κάθε νευρώνας δέχεται κάποιες εισόδους, έστω  $i$  σε πλήθος, οι οποίες αναπαριστώνται μέσω



ενός διανύσματος  $x_i$ . Επίσης, διαθέτει συνδέσεις με βάρη προς τους νευρώνες του επόμενου επιπέδου και αναπαριστά τα βάρη αυτά μέσω ενός πίνακα  $w_{ih}$ , που συνδέει τις εισόδους  $i$  με τον νευρώνα  $h$ . Ο νευρώνας παράγει έξοδο με βάση τον τύπο  $y = \sigma(\sum_{k=0}^i x_k * w_{ih})$ , όπου ως  $\sigma$  ορίζεται μια συνάρτηση ενεργοποίησης όπως η γραμμική  $\sigma(x) = x$  ή η ReLU  $\sigma(x) = \max(0, x)$ . Οι διαδοχικές, λοιπόν, έξοδοι των νευρώνων στα διάφορα επίπεδα οδηγούν στην τελική έξοδο του δικτύου.



Εικόνα 4: Μάθηση ενός νευρώνα με πολλαπλές εισόδους<sup>1</sup>

Η διαδικασία της μάθησης όμως απαιτεί την αξιολόγηση της εξόδου του νευρωνικού. Όσο πιο κοντά βρίσκεται η έξοδος στο επιθυμητό αποτέλεσμα τόσο καλύτερα εκπαιδευμένο είναι το δίκτυο. Αυτή η αξιολόγηση, συνεπώς επιτυγχάνεται μέσω μιας συνάρτησης κόστους που υπολογίζει την απόκλιση από την ιδανική τιμή. Προκειμένου να ολοκληρωθεί η εκπαίδευση, αυτή η απόκλιση μεταφέρεται από τους νευρώνες εξόδου, πίσω σε όλους τους νευρώνες μέχρι το πρώτο επίπεδο, υπολογίζοντας τις επιμέρους αποκλίσεις. Η παραπάνω διαδικασία ονομάζεται οπισθοδρόμηση (back propagation) και αποτελεί το δεύτερο στάδιο της εκπαίδευσης. Τέλος, το τρίτο στάδιο αποτελείται από την ενημέρωση των βαρών ώστε να ελαχιστοποιηθεί η παραγόμενη απόκλιση. Στην απλούστερη μορφή της, η διαδικασία της μάθησης για έναν νευρώνα φαίνεται στην Εικόνα 4.

Η έρευνα στα νευρωνικά δίκτυα έχει οδηγήσει σε πολλές διαφορετικές αρχιτεκτονικές και τύπους νευρώνων. Στον τομέα της μη παρεμβατικής επιτήρησης φορτίων έχει γίνει χρήση περιορισμένων τύπων και συγκεκριμένα των συνελκτικών (CNN) και LSTM (Long Short-

<sup>1</sup> "What is Perceptron | Simplilearn." <https://www.simplilearn.com/what-is-perceptron-tutorial>. Accessed 9 Feb. 2021.

HEART - ΚΩΔΙΚΟΣ ΕΡΓΟΥ Τ2ΕΔΚ-03898 «ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ, ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ & ΚΑΙΝΟΤΟΜΙΑ» (ΕΠΑνεΚ)	ΤΙΤΛΟΣ ΠΑΡΑΔΟΤΕΟΥ Υποδομή Αποθήκευσης και Διαχείρισης Δεδομένων
--	---

Term Memory) ανατροφοδοτικών δικτύων [42, 5] όπως και των αυτοκωδικοποιητών (AutoEncoders) [43]. Αποφεύγοντας τη διεξοδική ανάλυση αυτών των κατηγοριών για λόγους συντομίας, παρακάτω αναφέρεται η βασική διαφοροποίηση αυτών των τύπων από τα βαθιά νευρωνικά. Τα συνελκτικά δίκτυα χρησιμοποιούν την μαθηματική πράξη της συνέλιξης αντί του πολλαπλασιασμού στο εσωτερικό του νευρώνα. Ο λόγος έγκειται στο γεγονός ότι η συνέλιξη επιτρέπει τη χρήση γειτονικής πληροφορίας στον υπολογισμό της εξόδου, προσφέροντας μεγαλύτερη εκφραστικότητα στο μοντέλο. Τα LSTM νευρωνικά δίκτυα, δέχονται τμήμα μίας χρονοσειράς ως είσοδο και προβλέπουν τις επόμενες στιγμές αυτής της χρονοσειράς χρησιμοποιώντας πληροφορία από νευρώνες άλλων επιπέδων και δημιουργώντας έτσι μία μορφή μνήμης που ενισχύει την απόδοσή τους. Τέλος, οι αυτοκωδικοποιητές έχουν ως στόχο τον ανασχηματισμό της εισόδου συμπιέζοντας και επαναποσυμπιέζοντας την αρχική είσοδο. Έτσι προσφέρουν αναπαραστάσεις χαμηλής διάστασης για τις εισόδους τους και αποτελούν μοντέλα μη επιβλεπόμενης μάθησης καθώς οι τιμές σύγκρισης προκύπτουν από τα ίδια δεδομένα εισόδου και όχι από εξωτερικές ετικέτες.

Περνώντας στις ερευνητικές δουλειές στον τομέα της μη παρεμβατικής επιτήρησης φορτίων μέσω νευρωνικών δικτύων, αξιοσημείωτη είναι η εφαρμογή των LSTM ανατροφοδοτικών δικτύων και των αυτοκωδικοποιητών για το πρόβλημα του διαχωρισμού του ενεργειακού αποτυπώματος των διαφόρων οικιακών συσκευών [5]. Συγκεκριμένα, χρησιμοποιώντας το ευρέως γνωστό σύνολο δεδομένων UK-DALE [44] η εκπαίδευση βασίζεται τόσο σε πραγματικά όσο και σε συνθετικά δεδομένα, ενώ τρία μοντέλα συγκρίνονται. Χρησιμοποιώντας τις ενεργοποιήσεις της εκάστοτε συσκευής, το πρώτο μοντέλο, ένα LSTM, προβλέπει ενεργοποιήσεις για μελλοντικές χρονικές στιγμές. Από την άλλη, το δεύτερο μοντέλο, ένας αυτοκωδικοποιητής που επιπρόσθετα απομονώνει τον θόρυβο στο εισερχόμενο σήμα (denoising autoencoder), προβλέπει το φορτίο μιας συσκευής δεχόμενος ως είσοδο το συνολικό φορτίο από ένα πλήθος συσκευών, θεωρώντας ως θόρυβο τα φορτία των υπόλοιπων συσκευών. Τέλος, το τρίτο μοντέλο είναι ένα απλό νευρωνικό με στόχο την πρόβλεψη του χρόνου έναρξης και λήξης της λειτουργίας της συσκευής όπως και της μέσης κατανάλωσης της. Η συγκριτική αξιολόγηση των μοντέλων δείχνει ότι τόσο το LSTM όσο και ο αυτοκωδικοποιητής έχουν καλύτερη επίδοση από τα κλασικά Μαρκοβιανά μοντέλα, ενώ ο αυτοκωδικοποιητής αποτελεί την ισχυρότερη προσέγγιση και από τα τρία μοντέλα. Τέλος, θετικές ενδείξεις για την καταλληλότητα των LSTM δείχνει και έρευνα στα συνθετικά δεδομένα REDD με συσκευές δύο και πολλαπλών καταστάσεων [45] μέσω της οποίας διαπιστώθηκε και η

HEART - ΚΩΔΙΚΟΣ ΕΡΓΟΥ Τ2ΕΔΚ-03898 «ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ, ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ & ΚΑΙΝΟΤΟΜΙΑ» (ΕΠΑνεΚ)	ΤΙΤΛΟΣ ΠΑΡΑΔΟΤΕΟΥ Υποδομή Αποθήκευσης και Διαχείρισης Δεδομένων
--	---

δύναμη αυτών των νευρωνικών σε συσκευές των οποίων οι χρονοσειρές έχουν κάποια περιοδικότητα.

Τα συνελικτικά δίκτυα έχουν επίσης ευρεία διάδοση στο χώρο της μη παρεμβατικής επιτήρησης φορτίων, και μάλιστα οι καλύτερες επιδόσεις σήμερα επιτυγχάνονται μέσω αυτών των δικτύων, συγκεκριμένα με τη μέθοδο Seq2point [42]. Η ιδέα είναι να χρησιμοποιηθεί ένα παράθυρο των τιμών της εισόδου προκειμένου να γίνει πρόβλεψη μιας μοναδικής τιμής. Αυτό έρχεται σε αντιδιαστολή με τις προηγούμενες μεθόδους όπου η πρόβλεψη αφορούσε ένα ολόκληρο παράθυρο της ενεργειακής κατανάλωσης μιας συσκευής [5]. Εφαρμόζοντας, λοιπόν, το συνελικτικό δίκτυο στα δεδομένα UK-DALE και REDD, φαίνεται ότι οι επιδόσεις του είναι υψηλότερες από τις προηγούμενες μεθόδους αναφορικά με διάφορες μετρικές όπως το μέσο απόλυτο σφάλμα (Mean Absolute Error). Ακόμη, το συνελικτικό δίκτυο δείχνει να καταλαβαίνει καλύτερα τα δεδομένα καθώς παράγει χαρακτηριστικά που παλαιότερα εξάγονταν χειροκίνητα όπως η τυπική διάρκεια χρήσης και τα ενεργειακά επίπεδα των συσκευών [46]. Σε άλλη δουλειά [47], τα συνελικτικά δίκτυα βελτιώνουν ακόμη περισσότερο την απόδοση σε συσκευές πολλαπλών καταστάσεων απομακρύνοντας το θόρυβο από την επιρροή φορτίων άσχετων, με τη συσκευή υπό εξέταση, συσκευών. Αυτό επιτυγχάνεται με την ενοποίηση πολλαπλών συνελικτικών δικτύων που διαβάζουν και διαχωρίζουν τα διαφορετικά τμήματα ενός φασματογραφήματος, δίνοντας τελικά πολύ υψηλές επιδόσεις σε μετρικές όπως το μέσο απόλυτο σφάλμα και το F1-score.

Συνοψίζοντας, είναι προφανές ότι τα νευρωνικά δίκτυα αποτελούν μια αξιόπιστη και πολύ αποτελεσματική προσέγγιση στο πρόβλημα της μη παρεμβατικής επιτήρησης φορτίων. Μάλιστα, εξασφαλίζουν την αυτοματοποιημένη εξαγωγή χαρακτηριστικών και έτσι εξαλείφουν την ανάγκη για την κοστοβόρα χειροκίνητη δημιουργία τους. Η σωστή επιλογή του κατάλληλου νευρωνικού δικτύου δεν είναι τετριμμένη και αποτελεί ζήτημα προς διερεύνηση, τόσο λόγω της ποικιλομορφίας των συσκευών όσο και της διαφοροποίησης των δεδομένων και των αναγκών που προκύπτουν. Η σύνθεση όμως, της γνώσης από τα υπάρχοντα μοντέλα μπορεί να οδηγήσει στη δημιουργία νέων προσεγγίσεων που θα προτείνουν καθολικές και επεκτάσιμες λύσεις.

HEART - ΚΩΔΙΚΟΣ ΕΡΓΟΥ Τ2ΕΔΚ-03898  
«ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ,  
ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ & ΚΑΙΝΟΤΟΜΙΑ»  
(ΕΠΑνεΚ)

ΤΙΤΛΟΣ ΠΑΡΑΔΟΤΕΟΥ  
Υποδομή Αποθήκευσης και Διαχείρισης  
Δεδομένων

### Κεφάλαιο 3: Επιλογή χαρακτηριστικών

Ο διαχωρισμός του ενεργειακού αποτυπώματος επιτυγχάνεται με τον προσδιορισμό ενεργών συσκευών χρησιμοποιώντας μια διαδικασία κατηγοριοποίησης. Για το λόγο αυτό, πρέπει να είναι διαθέσιμο ένα σύνολο χαρακτηριστικών που σχετίζονται στενά, αφενός, με τη συλλογή δεδομένων και, αφετέρου, με τις μεθόδους που θα χρησιμοποιηθούν για την αναγνώριση της συσκευής. Τα χαρακτηριστικά της μη παρεμβατικής επιτήρησης φορτίων εξαρτώνται σε μεγάλο βαθμό από τον ρυθμό δειγματοληψίας που χρησιμοποιείται, ή αλλιώς το ρυθμό εξόδου δεδομένων από τη συσκευή μέτρησης που θα χρησιμοποιηθεί για τον διαχωρισμό, και όχι το ρυθμό δειγματοληψίας του ρεύματος και της τάσης που αποτελούν την είσοδο της συσκευής. Μια χονδρική διαίρεση που χρησιμοποιεί το κατώφλι του 1 δευτερολέπτου για την περίοδο δειγματοληψίας, επιτρέπει το διαχωρισμό των χαρακτηριστικών μεταξύ μακροσκοπικών ή χαμηλών συχνοτήτων και μικροσκοπικών ή υψηλών συχνοτήτων. Μια πιο διεξοδική κατηγοριοποίηση [48] διαιρεί το εύρος του ρυθμού δειγματοληψίας σε έξι κατηγορίες: **α)** πολύ αργό - βραδύτερο από 1 λεπτό, **β)** αργό - μεταξύ 1 λεπτού και 1 δευτερολέπτου, **γ)** μέτριο - ταχύτερο από 1 Hz αλλά πιο αργό από τη βασική συχνότητα, **δ)** υψηλό - από τη βασική συχνότητα έως 2 kHz, **ε)** πολύ υψηλό - συχνότητα δειγματοληψίας μεταξύ 2 και 40 kHz και **στ)** εξαιρετικά υψηλό - ταχύτερο από 40 kHz. Αυτή η κατηγοριοποίηση υιοθετείται και στο υπόλοιπο αυτής της αναφοράς.

Οι περισσότερες εφαρμογές χρησιμοποιούν πολύ αργή ή αργή δειγματοληψία με χαρακτηριστικά που λαμβάνονται από τη χρονοσειρά μεταβλητών ισχύος: τάση και ρεύμα, φαινόμενη (apparent), ενεργή και/ή άεργη ισχύς, γωνία φάσης ισχύος, συντελεστής ισχύος, κ.λπ. Θα υποθέσουμε στη συνέχεια ότι οι στιγμιαίες τιμές ρεύματος, τάσης και ισχύος υποδηλώνονται ως  $i$ ,  $v$  και  $p$ ; οι RMS τιμές τους ως IRMS και VRMS; η ενεργή, φαινόμενη και άεργη ισχύς ως  $P$ ,  $S$  και  $Q$ , αντίστοιχα; η συνολική αρμονική παραμόρφωση ως THD; και ο συντελεστής ισχύος ως PF. Το πιο χρησιμοποιούμενο χαρακτηριστικό είναι η φαινόμενη ισχύς  $S$  [49-50], ενώ η ενεργή και άεργη  $P$  και  $Q$  ακολουθούν [51, 5]. Σε μια πρόσφατη εργασία [52] χρησιμοποιήθηκαν μετρήσεις  $P$  και VRMS, με δειγματοληψία 1 Hz, επιτυγχάνοντας υψηλό επίπεδο ακρίβειας, ακόμη και με μεταβαλλόμενες τάσεις τροφοδοσίας.

Οι διάφορες χρονοσειρές μπορούν να χρησιμοποιηθούν με ποικίλους τρόπους. Σε πολλές περιπτώσεις εφαρμόζονται άμεσα [53], όπου χρησιμοποιείται η χρονοσειρά της  $P$  ισχύος του συνόλου δεδομένων Individual Household Electric Power Consumption

HEART - ΚΩΔΙΚΟΣ ΕΡΓΟΥ Τ2ΕΔΚ-03898  
«ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ,  
ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ & ΚΑΙΝΟΤΟΜΙΑ»  
(ΕΠΑνεΚ)

ΤΙΤΛΟΣ ΠΑΡΑΔΟΤΕΟΥ  
Υποδομή Αποθήκευσης και Διαχείρισης  
Δεδομένων

Dataset (IHEPCD) [54]. Αντίστοιχα υπάρχουν περιπτώσεις χρήσεων των ισχύων  $P$  και IRMS, που λαμβάνονται από το σύνολο δεδομένων Almanac of Minently Power (AMPds) [55]. και των  $S$  και IRMS, από τα σύνολα δεδομένων AMPds και REED [56]. Από την άλλη πλευρά, στο [57] οι χρονοσειρές ισχύος χωρίζονται σε υπο-ακολουθίες που χρησιμοποιούνται για τον υπολογισμό των στατιστικών στιγμών της κατανάλωσης φορτίου, και στο [58] το υψηλοσυχνοτικό σήμα ρεύματος υπόκειται σε μετασχηματισμούς τομέα-χρόνου.

Τα χρονικά χαρακτηριστικά χρησιμοποιούνται συνήθως σε αλγόριθμους NILM που δεν λαμβάνουν υπόψη περιστατικά (events). Συγκεκριμένα, αυτά που ανήκουν στην κατηγορία της **χαμηλής δειγματοληψίας** είναι τυπικά χαρακτηριστικά σταθερής κατάστασης (steady-state). Σε αυτήν την κατηγορία δειγματοληψίας, έχουν προταθεί επιπρόσθετα και άλλες προσεγγίσεις. Παράδειγμα αποτελεί ο διαχωρισμός ενός σήματος ισχύος σε «powerlets», την ελάχιστη ομάδα σύντομων ακολουθιών (που αντιπροσωπεύουν το σήμα), που λαμβάνονται από μοντέλα Auto-Regressive με εξωγενείς εισόδους (ARX) [59]. Ακόμη, με παρόμοια λογική γίνεται και χρήση των «Shapelets» [60] που αποτελούν μια μικρή υπο ομάδα της εκάστοτε χρονοσειράς.

Προχωρώντας στην επόμενη κατηγορία δειγματοληψίας, **το εύρος μεσαίου ρυθμού** επιτρέπει τον χαρακτηρισμό της παροδικής ηλεκτρικής συμπεριφοράς καθώς οι συσκευές αλλάζουν κατάσταση. Ενώ ορισμένες μεταβάσεις μπορεί να είναι ορατές μέσω της δειγματοληψίας χαμηλού ρυθμού, η δειγματοληψία μεσαίου ρυθμού επιτρέπει πολύ πιο λεπτομερείς πληροφορίες σχετικά με τα παροδικά σχήματα. Συγκεκριμένα έχει προταθεί η χρήση επτά χαρακτηριστικών, που εξάγονται από την τρέχουσα κυματομορφή: αριθμός αιχμών (spikes); αριθμός ημι-σταθερών καταστάσεων (σταθερότητα στην κατάσταση μεταξύ 1 και 5 δευτερολέπτων); αριθμός σταθερών καταστάσεων (σταθερότητα μεγαλύτερη των 5 δευτερολέπτων); συνολικός χρόνος σε ημι-σταθερές καταστάσεις / μήκος της κυματομορφής λειτουργίας; συνολικός χρόνος σε σταθερές καταστάσεις / μήκος της κυματομορφής λειτουργίας; αριθμός καταστάσεων ανά χρονικό παράθυρο; και ύπαρξη ή ανυπαρξία επαναλαμβανόμενων μοτίβων [61].

Καθώς οι χρονοσειρές παρέχουν συχνά υψηλό επίπεδο πλεονασμού, αυξάνοντας την πολυπλοκότητα του μοντέλου είναι πιθανή η κατάπτωση της επίδοσης του οδηγώντας το σε χαμηλή ακρίβεια. Για το λόγο αυτό, θα είχε νόημα η μετατροπή των χρονοσειρών στο πεδίο των συχνοτήτων, μετασχηματισμός που ωστόσο απαιτεί **υψηλούς ρυθμούς δειγματοληψίας**. Διάφορα χαρακτηριστικά μπορούν να εξαχθούν από πληροφορίες

HEART - ΚΩΔΙΚΟΣ ΕΡΓΟΥ Τ2ΕΔΚ-03898  
«ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ,  
ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ & ΚΑΙΝΟΤΟΜΙΑ»  
(ΕΠΑνεΚ)

ΤΙΤΛΟΣ ΠΑΡΑΔΟΤΕΟΥ  
Υποδομή Αποθήκευσης και Διαχείρισης  
Δεδομένων

συχνότητας, όπως αρμονικές [14] που λαμβάνονται με μετασχηματισμό Fourier και πολλαπλές ζώνες συχνοτήτων χρησιμοποιώντας την εντροπία της πληροφορίας [62]. Επιπρόσθετα, έχει παρατηρηθεί η χρήση του Discrete Wavelet Transform (DWT), λόγω της τοπικότητας των χρονικών συχνοτήτων όπως και της εφαρμογής του σε πολλαπλές αναλύσεις [74, 2]. Τέλος, στη βιβλιογραφία παρατηρούνται και άλλοι μετασχηματισμοί, όπως το Stockwell Transform [63], και έχουν προταθεί συνδυασμοί διαφορετικών τεχνικών, όπως του DWT και των αρμονικών [64].

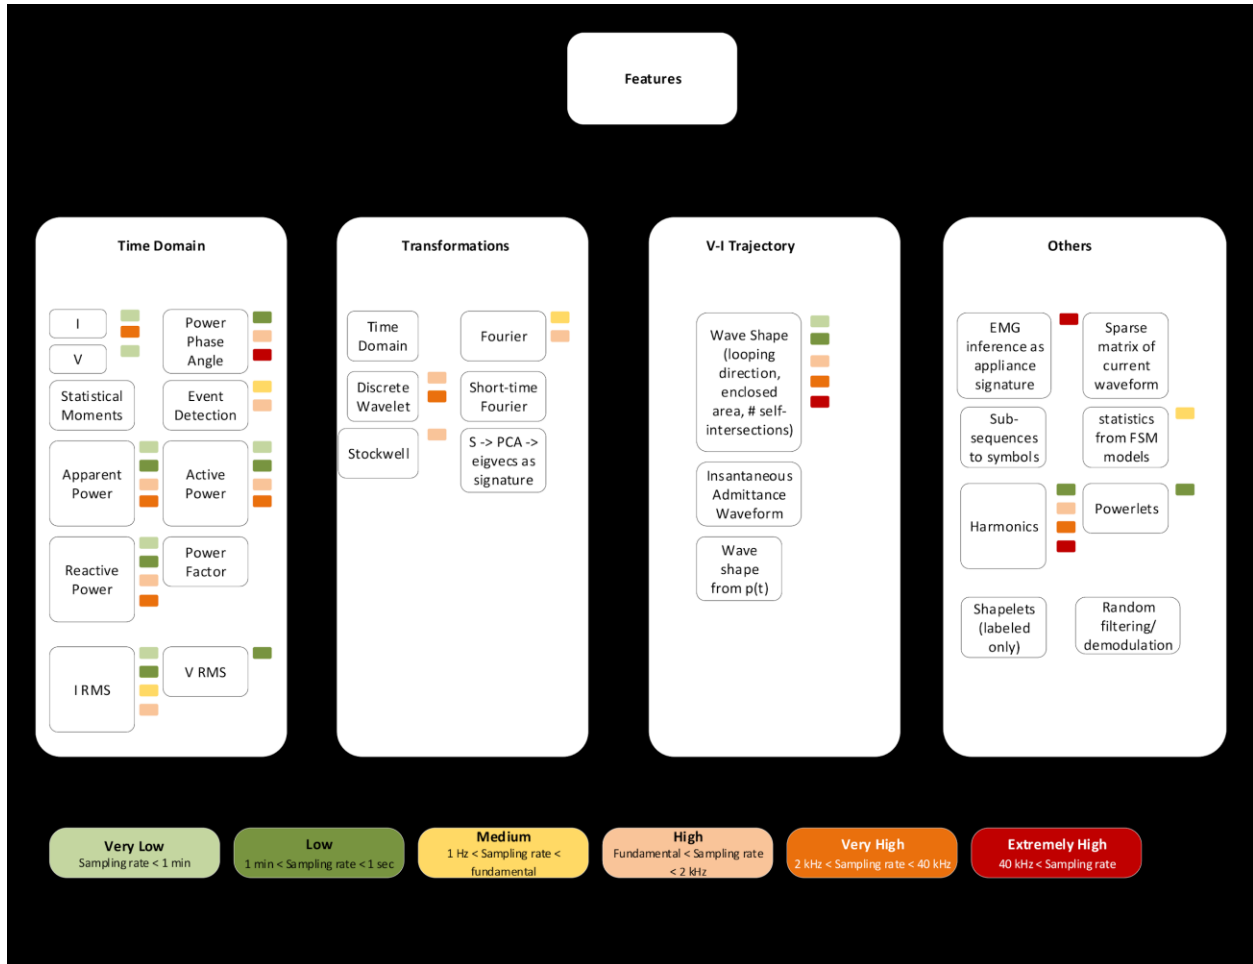
Τα **δεδομένα πολύ υψηλού ρυθμού** μας επιτρέπουν να λαμβάνουμε πολύ περισσότερες λεπτομέρειες σχετικά με τη κυματομορφή κάθε συσκευής, είτε από τις υψηλότερες αρμονικές είτε από το σχήμα των πρωτογενών κυματομορφών ρεύματος και τάσης. Οι δισδιάστατες τροχιές τάσης-ρεύματος ( $V-I$ ), που αντιστοιχούν στα κανονικοποιημένα σήματα τάσης και ρεύματος σταθερής κατάστασης κατά τη διάρκεια ενός κύκλου, έχουν ήδη θεωρηθεί ως μια πιθανή μέθοδος για τον προσδιορισμό των υπογραφών φορτίου από άποψη χαρακτηριστικών [65]. Σε γενικές γραμμές, η τροχιά  $V-I$  παρουσιάζει μοναδικά χαρακτηριστικά για συσκευές με διαφορετικές αρχές λειτουργίας (αντίσταση ή επαγωγή), και έτσι μπορεί να περιγράψει κατάλληλα την κυματομορφή ( $WS$ ) υπό εξέταση. Αναλυτικότερα, είναι δυνατόν να εξαχθούν χαρακτηριστικά, όπως η κατεύθυνση του βρόχου, η περιοχή που αυτά περικλείουν και ο αριθμός των αυτοδιασταυρώσεων. Οι πιο πρόσφατες εφαρμογές [75] χρησιμοποιούν επιπρόσθετα χαρακτηριστικά της  $V-I$  τροχιάς, ενώ άλλα χαρακτηριστικά που λαμβάνουν υπόψη το σχήμα των κυματομορφών και εξάγονται από το  $p(t)$  και το Instantaneous Admittance Waveform (IAW) έχουν επίσης εφαρμογή [66].

Χρησιμοποιώντας **εξαιρετικά υψηλό ρυθμό δειγματοληψίας** μπορεί να γίνει λήψη των αρμονικών υψηλότερης τάσης, επιτρέποντας επίσης τη σύλληψη ηλεκτρικού θορύβου. Για την ακρίβεια, έχει βρεθεί ότι η χρήση σημάτων υψηλής συχνότητας ηλεκτρομαγνητικών παρεμβολών (EMI) επιτρέπει τη διάκριση παρόμοιων φορτίων εναλλασσόμενου ρεύματος σε ένα σπίτι, κάτι που είναι αδύνατο με άλλες τεχνικές [67]. Αρμονικές υψηλότερης τάξης χρησιμοποιούνται σε διάφορες έρευνες [76–78]. Η πρώτη, αποτελεί επέκταση προηγούμενης δουλειάς [62] για την ταυτόχρονη λειτουργία διαφόρων συσκευών. Η τρίτη, προτείνει τη χρήση των αρμονικών φάσεων έναντι του πλάτους των αρμονικών του ρεύματος, με αποτελέσματα που δείχνουν σημαντικές βελτιώσεις στην απόδοση όταν λαμβάνονται υπόψη πολλοί συνδυασμοί συσκευών. Τέλος, η δεύτερη εργασία χρησιμοποιεί τον ίδιο τύπο χαρακτηριστικών, αν και εφαρμόζει διαφορετική διαδικασία αναγνώρισης. Επιτυγχάνει εξαιρετική απόδοση για διαφορετικούς

HEART - ΚΩΔΙΚΟΣ ΕΡΓΟΥ Τ2ΕΔΚ-03898 «ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ, ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ & ΚΑΙΝΟΤΟΜΙΑ» (ΕΠΑνεΚ)	ΤΙΤΛΟΣ ΠΑΡΑΔΟΤΕΟΥ Υποδομή Αποθήκευσης και Διαχείρισης Δεδομένων
--	---

συνδυασμούς μικρών μη γραμμικών φορτίων. Ωστόσο, καθώς τα δεδομένα που χρησιμοποιούνται είναι διαφορετικά και ιδιωτικά, η απόδοση των προσεγγίσεων [77, 87] δεν είναι συγκρίσιμη.

Τα χαρακτηριστικά που αναλύονται παραπάνω μπορούν να υπολογιστούν από την κύρια τροφοδοσία του σπιτιού. Ωστόσο, μπορούν να χρησιμοποιηθούν και άλλες πληροφορίες. Μεταβλητές όπως ο χρόνος και η διάρκεια χρήσης για ένα δεδομένο συμβάν μπορούν να συναχθούν μόνο από τον κύριο αισθητήρα ισχύος [68]. Η συχνότητα χρήσης μιας συσκευής, καθώς και ο συσχετισμός της χρήσης πολλαπλών συσκευών έχουν επίσης εφαρμοστεί [69–70]. Αυτές οι πληροφορίες μπορούν να επεκταθούν με τη συμπεριφορά των χρηστών για να εκφράσουν την αβεβαιότητα για κάθε κατάσταση κάθε συσκευής [71]. Τέλος, η χωρητικότητα, η οποία μπορεί να μετρηθεί ή να προβλεφθεί με διάφορους τρόπους, έχει χρησιμοποιηθεί για τη μείωση της πολυπλοκότητας των αλγορίθμων NILM [79], ενώ για συστήματα HVAC, έχουν χρησιμοποιηθεί επίσης εξωτερικές πληροφορίες καιρού [72].



Εικόνα 5: Κατηγοριοποίηση των χαρακτηριστικών με βάση το είδος και τη συχνότητα δειγματοληψίας

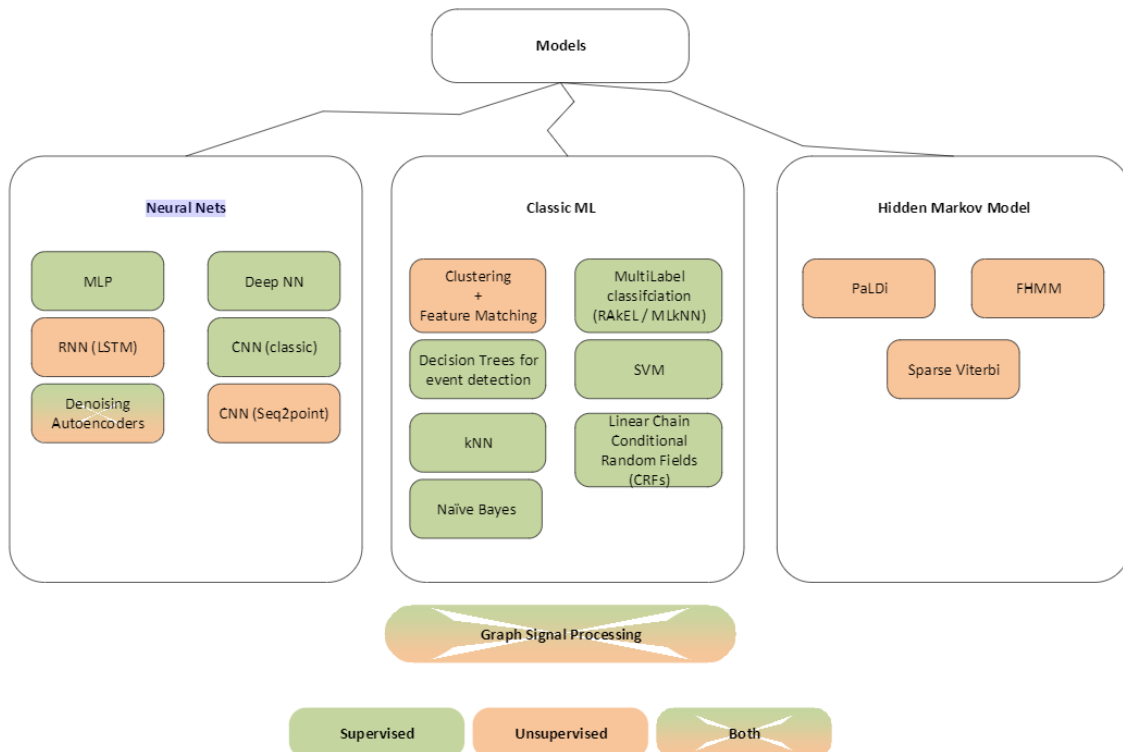
Δεν είναι ασυνήθιστο να χρησιμοποιούνται συνδυασμοί των χαρακτηριστικών που περιγράφονται παραπάνω, οδηγώντας κατ' αυτόν τον τρόπο σε υβριδικές προσεγγίσεις. Για παράδειγμα, οι τιμές των χαρακτηριστικών P, Q, IAW, και ρ, οι ιδιοτιμές και η κυματομορφή της μεταβατικότητας εναλλαγών (switching transient), έχουν εφαρμοστεί ως χαρακτηριστικά ενός "Committee Decision Mechanism" [66]. Ακόμη, πιο πρόσφατα, έχουν χρησιμοποιηθεί αλγόριθμοι επιλογής χαρακτηριστικών για τη μείωση του αρχικού συνόλου δεδομένων με χαρακτηριστικά 55 σταθερών και 23 μεταβατικών καταστάσεων στο αντίστοιχο που περιλαμβάνει μόνο τα 20 πιο σχετικά χαρακτηριστικά [73]. Τέλος, μια συνολική κατηγοριοποίηση των χαρακτηριστικών που περιγράφηκαν σε αυτήν την ενότητα επιχειρείται στην Εικόνα 5.



## Κεφάλαιο 4: Σύνοψη

Παρότι η τεχνολογία της μη παρεμβατικής επιτήρησης φορτίων δεν είναι καινούργια (παρουσιάστηκε περίπου πριν 30 χρόνια), μόλις πρόσφατα επανήλθε στο προσκήνιο και χρησιμοποιείται ευρέως λόγω κυρίως της ανάπτυξης των τεχνολογιών πληροφορικής και αισθητήρων. Στο παραδοτέο αυτό προσπαθήσαμε να καταγράψουμε τις πλέον σύγχρονες, αποτελεσματικές και υποσχόμενες μεθοδολογίες που έχουν επικρατήσει σε αυτόν τον τομέα τη τελευταία δεκαετία. Σκοπός αυτής της ανάλυσης, είναι η εξοικείωση με τους όρους και τις διάφορες μεθοδολογίες ώστε να είναι αποτελεσματικότερη η έρευνα που θα αναπτυχθεί στα πλαίσια του ερευνητικού έργου Heart.

Συνοψίζοντας, χωρίσαμε τις μεθοδολογίες σε δύο κύριες κατηγορίες (Supervised & Unsupervised) και προχωρήσαμε στην ανάλυση των πλέον υποσχόμενων κατηγοριών (Νευρωνικά δίκτυα, Hidden Markov Models, GSP), όπως φαίνεται και στην Εικόνα 6.



Εικόνα 6

HEART - ΚΩΔΙΚΟΣ ΕΡΓΟΥ Τ2ΕΔΚ-03898  
«ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ,  
ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ & ΚΑΙΝΟΤΟΜΙΑ»  
(ΕΠΑνεΚ)

ΤΙΤΛΟΣ ΠΑΡΑΔΟΤΕΟΥ  
Υποδομή Αποθήκευσης και Διαχείρισης  
Δεδομένων

Όπως είδαμε οι αποτελεσματικότερες μεθοδολογίες εμπεριέχουν υλοποιήσεις Νευρωνικών δικτύων ή επεξεργασία σήματος γράφων. Παρότι και οι δύο λύσεις έχουν ένα σχετικά υψηλό επίπεδο ωριμότητας, στα πλαίσια του έργου Heart θα πειραματιστούμε και με την ανάπτυξη μοντέλων που διαφοροποιούνται από τις ως τώρα τεχνολογίες αιχμής, χωρίς βέβαια να καθορίσουμε σε αυτό το στάδιο συγκεκριμένα το πώς θα γίνει αυτό. Βασιζόμενοι σε βασικές παραμέτρους και περιορισμούς που υπάρχουν λόγω hardware ή υποδομής (π.χ. Ρυθμός δειγματοληψίας), θα προχωρήσουμε στην ανάπτυξη μοντέλων που θα χρησιμοποιούν Νευρωνικά δίκτυα, Επεξεργασία σήματος γράφων ή και συνδυασμό αυτών των δύο (αν κι εφόσον αυτό είναι εφικτό).

## Κεφάλαιο 5: Βιβλιογραφία

- [1] Ruano, A., Hernandez, A., Ureña, J., Ruano, M., & Garcia, J. (2019). NILM techniques for intelligent home energy management and ambient assisted living: A review. *Energies*, 12(11), 2203.
- [2] Chang, H.; Lian, K.; Su, Y.; Lee, W. Power-Spectrum-Based Wavelet Transform for Nonintrusive Demand Monitoring and Load Identification. *IEEE Trans. Ind. Appl.* 2014, 50, 2081–2089.
- [3] Chang, H.-H. Non-Intrusive Demand Monitoring and Load Identification for Energy Management Systems Based on Transient Feature Analyses. *Energies* 2012, 5, 4569.
- [4] Wu, Q.; Wang, F. Concatenate Convolutional Neural Networks for Non-Intrusive Load Monitoring across Complex Background. *Energies* 2019, 12, 1572.
- [5] Kelly, J.; Knottenbelt, W. Neural NILM: Deep Neural Networks Applied to Energy Disaggregation. In Proceedings of the 2nd ACM International Conference on Embedded Systems for Energy-Efficient Built Environments, Seoul, Korea, 4–5 November 2015; pp. 55–64.
- [6] Kim, J.; Le, T.-T.-H.; Kim, H. Nonintrusive Load Monitoring Based on Advanced Deep Learning and Novel Signature. *Comput. Intell. Neurosci.* 2017, 2017, 4216281.



HEART - ΚΩΔΙΚΟΣ ΕΡΓΟΥ Τ2ΕΔΚ-03898 «ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ, ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ & ΚΑΙΝΟΤΟΜΙΑ» (ΕΠΑνεΚ)	ΤΙΤΛΟΣ ΠΑΡΑΔΟΤΕΟΥ Υποδομή Αποθήκευσης και Διαχείρισης Δεδομένων
--	---

[7] Devlin, M.; Hayes, B. Non-Intrusive Load Monitoring Using Electricity Smart Meter Data: A Deep Learning Approach. 2018. Available online: [https://www.researchgate.net/publication/328784204\\_Non-Intrusive\\_Load\\_Monitoring\\_using\\_Electricity\\_Smart\\_Meter\\_Data\\_A\\_Deep\\_Learning\\_Approach](https://www.researchgate.net/publication/328784204_Non-Intrusive_Load_Monitoring_using_Electricity_Smart_Meter_Data_A_Deep_Learning_Approach) (accessed on 1 March 2019).

[8] Singh, S.; Majumdar, A. Deep Sparse Coding for Non-Intrusive Load Monitoring. IEEE Trans. Smart Grid 2018, 9, 4669–4678.

[9] Fan, C.; Xiao, F.; Zhao, Y.; Wang, J. Analytical investigation of autoencoder-based methods for unsupervised anomaly detection in building energy data. Appl. Energy 2018, 211, 1123–1135.

[10] De Baets, L.; Ruyssinck, J.; Develder, C.; Dhaene, T.; Deschrijver, D. Appliance classification using VI trajectories and convolutional neural networks. Energy Build. 2018, 158, 32–36.

[11] Figueiredo, M.B.; de Almeida, A.; Ribeiro, B. An Experimental Study on Electrical Signature Identification of Non-Intrusive Load Monitoring (NILM) Systems. In Proceedings of the 10th ICANNGA, Ljubljana, Slovenia, 14–16 April 2011; pp. 31–40.

[12] Kramer, O.; Wilken, O.; Beenken, P.; Hein, A.; Hüwel, A.; Klingenberg, T.; Meinecke, C.; Raabe, T.; Sonnenschein, M. On Ensemble Classifiers for Nonintrusive Appliance Load Monitoring; Springer: Berlin/Heidelberg, Germany, 2012; pp. 322–331.

[13] Giri, S.; Bergés, M.; Rowe, A. Towards automated appliance recognition using an EMF sensor in NILM platforms. Adv. Eng. Inform. 2013, 27, 477–485.

[14] Meehan, P.; McArdle, C.; Daniels, S. An Efficient, Scalable Time-Frequency Method for Tracking Energy Usage of Domestic Appliances Using a Two-Step Classification Algorithm. Energies 2014, 7, 7041.

[15] He, H.; Liu, Z.; Jiao, R.; Yan, G. A Novel Nonintrusive Load Monitoring Approach based on Linear-Chain Conditional Random Fields. Energies 2019, 12, 1797.

HEART - ΚΩΔΙΚΟΣ ΕΡΓΟΥ Τ2ΕΔΚ-03898 «ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ, ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ & ΚΑΙΝΟΤΟΜΙΑ» (ΕΠΑνεΚ)	ΤΙΤΛΟΣ ΠΑΡΑΔΟΤΕΟΥ Υποδομή Αποθήκευσης και Διαχείρισης Δεδομένων
--	---

- [16] Wang, Z.; Zheng, G. Residential Appliances Identification and Monitoring by a Nonintrusive Method. *IEEE Trans. Smart Grid* 2012, 3, 80–92. [CrossRef]
- [17] Yang, C.C.; Soh, C.S.; Yap, V.V. A systematic approach to ON-OFF event detection and clustering analysis of non-intrusive appliance load monitoring. *Front. Energy* 2015, 9, 231–237.
- [18] Parson, O.; Ghosh, S.; Weal, M.; Rogers, A. An unsupervised training method for non-intrusive appliance load monitoring. *Artif. Intell.* 2014, 217, 1–19.
- [19] C. Beckel, W. Kleiminger, R. Cicchetti, T. Staake, and S. Santini, “The ECO data set and the performance of non-intrusive load monitoring algorithms,” presented at the ACM Conf. Embedded Syst. Energy Efficient Build., Memphis, TN, USA, 2014, pp. 80–89.
- [20] D. Li, K. Sawyer, and S. Dick, “Disaggregating household loads via semi-supervised multi-label classification,” presented at the Annu. Conf. North Amer. Fuzzy Inf. Process. Soc., Redmond, WA, USA, 2015, pp. 1–5.
- [21] Y. Kim, T. Schmid, Z. M. Charbiwala, and M. B. Srivastava, “ViridiScope: Design and implementation of a fine grained power monitoring system for homes,” in *Proc. 11th Int. Conf. Ubiquitous Comput.*, Orlando, FL, USA, 2009, pp. 245–254.
- [22] K. Suzuki, S. Inagaki, T. Suzuki, H. Nakamura, and K. Ito, “Nonintrusive appliance load monitoring based on integer programming,” in *Proc. SICE Annu. Conf.*, vols. 1–7. Tokyo, Japan, 2008, pp. 2742–2747.
- [23] Y.-X. Yu, P. Li, and C.-L. Zhao, “Non-intrusive method for online power load decomposition,” in *Proc. China Int. Conf. Electricity Distrib.*, Guangzhou, China, 2009, pp. 1–8.
- [24] C. Elbe and E. Schmutzner, “Appliance-specific energy consumption feedback for domestic consumers using load disaggregation methods,” presented at the *Int. Conf. Elect. Distrib.*, Stockholm, Sweden, 2013, pp. 1–4.

HEART - ΚΩΔΙΚΟΣ ΕΡΓΟΥ Τ2ΕΔΚ-03898 «ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ, ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ & ΚΑΙΝΟΤΟΜΙΑ» (ΕΠΑνεΚ)	ΤΙΤΛΟΣ ΠΑΡΑΔΟΤΕΟΥ Υποδομή Αποθήκευσης και Διαχείρισης Δεδομένων
--	---

[25] K. Basu, V. Debusschere, and S. Bacha, "Load identification from power recordings at meter panel in residential households," in Proc. 20th Int. Conf. Elect. Mach. (ICEM), Marseille, France, 2012, pp. 2098–2104.

[26] Bonfigli, R., Squartini, S., Fagiani, M., & Piazza, F. (2015, June). Unsupervised algorithms for non-intrusive load monitoring: An up-to-date overview. In 2015 IEEE 15th international conference on environment and electrical engineering (EEEIC) (pp. 1175-1180). IEEE.

[27] Makonin, S., Popowich, F., Bajić, I. V., Gill, B., & Bartram, L. (2015). Exploiting HMM sparsity to perform online real-time nonintrusive load monitoring. IEEE Transactions on smart grid, 7(6), 2575-2585.

[28] Parson, O., Ghosh, S., Weal, M., & Rogers, A. (2012, July). Non-intrusive load monitoring using prior models of general appliance types. In Proceedings of the AAAI Conference on Artificial Intelligence (Vol. 26, No. 1).

[29] Zhao, B., Stankovic, L., & Stankovic, V. (2016). On a training-less solution for non-intrusive appliance load monitoring using graph signal processing. IEEE Access, 4, 1784-1799.

[30] Jia, R., Gao, Y., & Spanos, C. J. (2015, November). A fully unsupervised non-intrusive load monitoring framework. In 2015 IEEE international conference on smart grid communications (SmartGridComm) (pp. 872-878). IEEE.

[31] Forney, G. D. (1973). The viterbi algorithm. Proceedings of the IEEE, 61(3), 268-278.

[32] Ghahramani, Z., & Jordan, M. I. (1997). Factorial hidden Markov models. Machine learning, 29(2), 245-273.

[33] Zoha, A., Gluhak, A., Imran, M. A., & Rajasegarar, S. (2012). Non-intrusive load monitoring approaches for disaggregated energy sensing: A survey. Sensors, 12(12), 16838-16866.

HEART - ΚΩΔΙΚΟΣ ΕΡΓΟΥ Τ2ΕΔΚ-03898 «ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ, ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ & ΚΑΙΝΟΤΟΜΙΑ» (ΕΠΑνεΚ)	ΤΙΤΛΟΣ ΠΑΡΑΔΟΤΕΟΥ Υποδομή Αποθήκευσης και Διαχείρισης Δεδομένων
--	---

[34] Kim, H., Marwah, M., Arlitt, M., Lyon, G., & Han, J. (2011, April). Unsupervised disaggregation of low frequency power measurements. In Proceedings of the 2011 SIAM international conference on data mining (pp. 747-758). Society for Industrial and Applied Mathematics.

[35] Kolter, J. Z., & Jaakkola, T. (2012, March). Approximate inference in additive factorial hmms with application to energy disaggregation. In Artificial intelligence and statistics (pp. 1472-1482). PMLR.

[36] Mauch, L., Barsim, K. S., & Yang, B. (2016, May). How well can HMM model load signals. In Proceeding of the 3rd international workshop on non-intrusive load monitoring (NILM 2016) (No. 6).

[37] Stankovic, V., Liao, J., & Stankovic, L. (2014, December). A graph-based signal processing approach for low-rate energy disaggregation. In 2014 IEEE symposium on computational intelligence for engineering solutions (CIES) (pp. 81-87). IEEE.

[38] Sandryhaila, A., & Moura, J. M. (2013, December). Classification via regularization on graphs. In 2013 IEEE global conference on signal and information processing (pp. 495-498). IEEE.

[39] Zhao, B., Stankovic, L., & Stankovic, V. (2015, December). Blind non-intrusive appliance load monitoring using graph-based signal processing. In 2015 IEEE global conference on signal and information processing (GlobalSIP) (pp. 68-72). IEEE.

[40] G. W. Hart. Prototype nonintrusive appliance load monitor. Technical report, MIT Energy Laboratory and Electric Power Research Institute, Sept. 1985.

[41] N. Amirach, B. Xerri, B. Borloz, and C. Jauffret. A new approach for event detection and feature extraction for nilm. In Electronics, Circuits and Systems (ICECS), 2014 21st IEEE International Conference on, pages 287–290. IEEE, 2014.

HEART - ΚΩΔΙΚΟΣ ΕΡΓΟΥ Τ2ΕΔΚ-03898 «ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ, ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ & ΚΑΙΝΟΤΟΜΙΑ» (ΕΠΑνεΚ)	ΤΙΤΛΟΣ ΠΑΡΑΔΟΤΕΟΥ Υποδομή Αποθήκευσης και Διαχείρισης Δεδομένων
--	---

[42] Zhang, C., Zhong, M., Wang, Z., Goddard, N., & Sutton, C. (2018, April). Sequence-to-point learning with neural networks for non-intrusive load monitoring. In Proceedings of the AAAI Conference on Artificial Intelligence (Vol. 32, No. 1).

[43] Bonfigli, R., Felicetti, A., Principi, E., Fagiani, M., Squartini, S., & Piazza, F. (2018). Denoising autoencoders for non-intrusive load monitoring: improvements and comparative evaluation. *Energy and Buildings*, 158, 1461-1474.

[44] Kelly J, Knottenbelt W (2015b) The UK-DALE dataset, domestic appliance-level electricity demand and whole-house demand from five UK homes

[45] Mauch L, Yang B (2015) A new approach for supervised power disaggregation by using a deep recurrent LSTM network. In proceedings of the 3 rd IEEE global conference on signal and information processing (GlobalSIP), pp 63–67

[46] Nalmpantis, C., & Vrakas, D. (2019). Machine learning approaches for non-intrusive load monitoring: from qualitative to quantitative comparison. *Artificial Intelligence Review*, 52(1), 217-243.

[47] Wu, Q., & Wang, F. (2019). Concatenate convolutional neural networks for non-intrusive load monitoring across complex backgrounds. *Energies*, 12(8), 1572.

[48] Clark, M. S. (2015). Improving the feasibility of energy disaggregation in very high- and low-rate sampling scenarios (Doctoral dissertation, University of British Columbia)

[49] Le, X. C., Vrigneau, B., & Sentieys, O. (2015, March). l1-Norm minimization based algorithm for non-intrusive load monitoring. In 2015 IEEE International Conference on Pervasive Computing and Communication Workshops (PerCom Workshops) (pp. 299-304). IEEE.

[50] Parson, O. (2014). *Unsupervised training methods for non-intrusive appliance load monitoring from smart meter data* (Doctoral dissertation, University of Southampton).

[51] Chang, H. H., Wiratha, P. W., & Chen, N. (2014). A non-intrusive load monitoring system using an embedded system for applications to unbalanced residential distribution systems. *Energy Procedia*, 61, 146-150.

HEART - ΚΩΔΙΚΟΣ ΕΡΓΟΥ Τ2ΕΔΚ-03898 «ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ, ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ & ΚΑΙΝΟΤΟΜΙΑ» (ΕΠΑνεΚ)	ΤΙΤΛΟΣ ΠΑΡΑΔΟΤΕΟΥ Υποδομή Αποθήκευσης και Διαχείρισης Δεδομένων
--	---

[52] Welikala, S., Thelasingha, N., Akram, M., Ekanayake, P. B., Godaliyadda, R. I., & Ekanayake, J. B. (2019). Implementation of a robust real-time non-intrusive load monitoring solution. *Applied energy*, 238, 1519-1529.

[53] Figueiredo, M., Ribeiro, B., & de Almeida, A. (2015). Analysis of trends in seasonal electrical energy consumption via non-negative tensor factorization. *Neurocomputing*, 170, 318-327.

[54] Bache, K.; Lichman, M. UCI Machine Learning Repository. Available online: <http://archive.ics.uci.edu/ml> (accessed on 20 April 2019)

[55] Makonin, S., Popowich, F., Bartram, L., Gill, B., & Bajić, I. V. (2013, August). AMPDs: A public dataset for load disaggregation and eco-feedback research. In *2013 IEEE electrical power & energy conference* (pp. 1-6). IEEE.

[56] Makonin, S. W. (2014). *Real-time embedded low-frequency load disaggregation* (Doctoral dissertation, Applied Sciences: School of Computing Science).

[57] Lu-Lulu, L. L., Park, S. W., & Wang, B. H. (2012). Electric load signature analysis for home energy monitoring system. *International Journal of Fuzzy Logic and Intelligent Systems*, 12(3), 193-197.

[58] Alshareef, S., & Morsi, W. G. (2015, October). Application of wavelet-based ensemble tree classifier for non-intrusive load monitoring. In *2015 IEEE Electrical Power and Energy Conference (EPEC)* (pp. 397-401). IEEE.

[59] Elhamifar, E., & Sastry, S. (2015, February). Energy disaggregation via learning powerlets and sparse coding. In *Proceedings of the AAAI Conference on Artificial Intelligence* (Vol. 29, No. 1).

[60] Patri, O. P., Panangadan, A. V., Chelmis, C., & Prasanna, V. K. (2014, July). Extracting discriminative features for event-based electricity disaggregation. In *2014 IEEE Conference on Technologies for Sustainability (SusTech)* (pp. 232-238). IEEE.



HEART - ΚΩΔΙΚΟΣ ΕΡΓΟΥ Τ2ΕΔΚ-03898 «ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ, ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ & ΚΑΙΝΟΤΟΜΙΑ» (ΕΠΑνεΚ)	ΤΙΤΛΟΣ ΠΑΡΑΔΟΤΕΟΥ Υποδομή Αποθήκευσης και Διαχείρισης Δεδομένων
--	---

[61] Du, L., Yang, Y., He, D., Harley, R. G., & Habetler, T. G. (2014). Feature extraction for load identification using long-term operating waveforms. *IEEE Transactions on Smart Grid*, 6(2), 819-826.

[62] Bouhouras, A. S., Milioudis, A. N., & Labridis, D. P. (2014). Development of distinct load signatures for higher efficiency of NILM algorithms. *Electric Power Systems Research*, 117, 163-171.

[63] Lin, Y. H., & Tsai, M. S. (2013). Development of an improved time–frequency analysis-based nonintrusive load monitor for load demand identification. *IEEE Transactions on Instrumentation and Measurement*, 63(6), 1470-1483.

[64] Nakajima, H., Nagasawa, K., Shishido, Y., Kagiya, Y., & Takagi, Y. (2014, September). The state estimation of existing home appliances using signal analysis technique. In *2014 Proceedings of the SICE Annual Conference (SICE)* (pp. 1247-1252). IEEE.

[65] Hassan, T., Javed, F., & Arshad, N. (2013). An empirical investigation of VI trajectory based load signatures for non-intrusive load monitoring. *IEEE Transactions on Smart Grid*, 5(2), 870-878.

[66] Liang, J., Ng, S. K., Kendall, G., & Cheng, J. W. (2009). Load signature study—Part I: Basic concept, structure, and methodology. *IEEE transactions on power Delivery*, 25(2), 551-560.

[67] Gupta, S., Reynolds, M. S., & Patel, S. N. (2010, September). ElectriSense: single-point sensing using EMI for electrical event detection and classification in the home. In *Proceedings of the 12th ACM international conference on Ubiquitous computing* (pp. 139-148).

[68] Elbe, C., & Schmutzner, E. (2013). Appliance-specific energy consumption feedback for domestic consumers using load disaggregation methods.

[69] Zeifman, M., & Roth, K. (2012, January). Disaggregation of home energy display data using probabilistic approach. In *2012 IEEE International Conference on Consumer Electronics (ICCE)* (pp. 630-631). IEEE.

HEART - ΚΩΔΙΚΟΣ ΕΡΓΟΥ Τ2ΕΔΚ-03898 «ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ, ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ & ΚΑΙΝΟΤΟΜΙΑ» (ΕΠΑνεΚ)	ΤΙΤΛΟΣ ΠΑΡΑΔΟΤΕΟΥ Υποδομή Αποθήκευσης και Διαχείρισης Δεδομένων
--	---

[70] Wang, H., & Yang, W. (2018). An iterative load disaggregation approach based on appliance consumption pattern. *Applied Sciences*, 8(4), 542.

[71] Zhai, S., Wang, Z., Yan, X., & He, G. (2018). Appliance flexibility analysis considering user behavior in home energy management system using smart plugs. *IEEE Transactions on Industrial Electronics*, 66(2), 1391-1401.

[72] Wytoczek, M.; Zico Kolter, J. Contextually Supervised Source Separation with Application to Energy Disaggregation. In Proceedings of the AAAI'14 Twenty-Eighth AAAI Conference on Artificial Intelligence, Québec, QC, Canada, 27–31 July 2013; pp. 486–492.

[73] Sadeghianpourhamami, N., Ruysinck, J., Deschrijver, D., Dhaene, T., & Develder, C. (2017). Comprehensive feature selection for appliance classification in NILM. *Energy and Buildings*, 151, 98-106.

[74] Tabatabaei, S. M., Dick, S., & Xu, W. (2016). Toward non-intrusive load monitoring via multi-label classification. *IEEE Transactions on Smart Grid*, 8(1), 26-40.

[75] Wang, A. L., Chen, B. X., Wang, C. G., & Hua, D. (2018). Non-intrusive load monitoring algorithm based on features of V–I trajectory. *Electric Power Systems Research*, 157, 134-144.

[76] Bouhouras, A. S., Gkaidatzis, P. A., Chatzisavvas, K. C., Panagiotou, E., Poulakis, N., & Christoforidis, G. C. (2017). Load signature formulation for non-intrusive load monitoring based on current measurements. *Energies*, 10(4), 538.

[77] Djordjevic, S., & Simic, M. (2018). Nonintrusive identification of residential appliances using harmonic analysis. *Turkish Journal of Electrical Engineering & Computer Sciences*, 26(2), 780-791.

[78] Bouhouras, A. S., Gkaidatzis, P. A., Panagiotou, E., Poulakis, N., & Christoforidis, G. C. (2019). A NILM algorithm with enhanced disaggregation scheme under harmonic current vectors. *Energy and Buildings*, 183, 392-407.

HEART - ΚΩΔΙΚΟΣ ΕΡΓΟΥ Τ2ΕΔΚ-03898 «ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ, ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ & ΚΑΙΝΟΤΟΜΙΑ» (ΕΠΑνεΚ)	ΤΙΤΛΟΣ ΠΑΡΑΔΟΤΕΟΥ Υποδομή Αποθήκευσης και Διαχείρισης Δεδομένων
--	---

[79] Uttama Nambi, A. S., Reyes Lua, A., & Prasad, V. R. (2015, November). Loced: Location-aware energy disaggregation framework. In *Proceedings of the 2nd acm international conference on embedded systems for energy-efficient built environments* (pp. 45-54).