



ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΜΑΚΕΔΟΝΙΑΣ

ΠΟΛΥΤΕΧΝΙΚΗ ΣΧΟΛΗ

ΤΜΗΜΑ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ Η/Υ

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

«Ανάπτυξη Αρχιτεκτονικής Συνελικτικού Νευρωνικού Δικτύου ως Μοντέλο
Αναγνώρισης Φορτίου μέσω Μη-παρεμβατικής Προσέγγισης»

Μυλωνά Δήμητρα

A.M.: 1521

Επιβλέπων Καθηγητής:

Μπουχουράς Άγγελος

ΙΟΥΛΙΟΣ 2023, ΚΟΖΑΝΗ

ΕΥΧΑΡΙΣΤΙΕΣ

Με την ολοκλήρωση της διπλωματικής μου εργασίας, θα ήθελα να εκφράσω τις ευχαριστίες μου σε όσους συνεισέφεραν στην εκπόνησή της.

Πρωτίστως, ευχαριστώ θερμά τον επιβλέποντα καθηγητή, κύριο Μπουχουρά Άγγελο, για την εμπιστοσύνη που μου έδειξε εξ' αρχής, την πολύτιμη καθοδήγησή του, την άψογη συνεργασία και τη διαρκή συμπαράσταση και υποστήριξη, προσφέροντας τις γνώσεις και τον προσωπικό του χρόνο.

Επιπλέον, ευχαριστώ τον υποψήφιο διδάκτορα Παπαγεωργίου Πέτρο, για τη γνωριμία μου με το πολύ ενδιαφέρον αντικείμενο του NILM και για τη συμβολή του στην περάτωση της εργασίας, μέσω των υποδείξεων και συμβουλών του.

Τέλος, θα ήθελα να εκφράσω την αμέριστη ευγνωμοσύνη μου στους γονείς μου, Νίκο και Στέλλα, και στην αδελφή μου Αγλαΐα, για την αμέτρητη στήριξη και κατανόηση, καθ' όλη τη διάρκεια των σπουδών μου.

ΠΕΡΙΛΗΨΗ

Ο τομέας της ενέργειας πλήττεται διαρκώς από σοβαρά ζητήματα, όπως είναι η αιχμή ζήτησης ή η ενεργειακή κρίση. Καθίσταται αναγκαία η εύρεση μεθόδων για τη διευκόλυνση των ζητημάτων αυτών, που θα επέλθει της αύξησης της ενεργειακής απόδοσης. Ένας τρόπος για να συμβεί αυτό, είναι η παροχή της δυνατότητας στον καταναλωτή για πλήρη έλεγχο της κατανάλωσής του, τόσο σε συνολικό επίπεδο, όσο και για τις επιμέρους συσκευές. Η παρούσα διπλωματική εργασία πραγματεύεται το θέμα της Μη-παρεμβατικής Παρακολούθησης Φορτίου (Non-Intrusive Load Monitoring - NILM), με στόχο την αναγνώριση και εκτίμηση της επιμέρους κατανάλωσης των συσκευών που συμμετέχουν στη συνολική κατανάλωση ενέργειας, μέσω της χρήσης μηχανικής μάθησης. Στην εργασία, αναλύονται έννοιες που σχετίζονται με την παρακολούθηση φορτίου, τόσο παρεμβατικά όσο και μη-παρεμβατικά, και εξηγείται λεπτομερώς η μέθοδος του NILM. Στη συνέχεια, γίνεται αναφορά στο μοντέλο μηχανικής μάθησης που έχει χρησιμοποιηθεί, το Συνελικτικό Νευρωνικό Δίκτυο (Convolutional Neural Network - CNN), και παρέχεται το απαραίτητο θεωρητικό υπόβαθρο για την πλήρη κατανόησή του. Τέλος, παρουσιάζεται η ανάπτυξη ενός μοντέλου CNN για NILM, με αναλυτική περιγραφή του σχεδιασμού και των αποτελεσμάτων του, μετά την εφαρμογή του σε πραγματικά δεδομένα μετρήσεων από -ανοιχτής πρόσβασης- βάση δεδομένων για αλγόριθμους NILM.

Λέξεις – κλειδιά: NILM, αναγνώριση φορτίου, Βαθιά Μάθηση, Συνελικτικό Νευρωνικό Δίκτυο (CNN)

ABSTRACT

The energy sector is constantly affected by serious issues, such as peak demand in power systems or the recent energy price crisis. It becomes necessary to find methods to alleviate these issues, which will be achieved by increasing energy efficiency. One way to make this happen is to enable consumers to have full control over their consumption, both at an overall level and for individual appliances. This thesis deals with the topic of Non-Intrusive Load Monitoring (NILM), aiming to identify properly appliances and combinations of appliances, based on measurements by only one main meter in the main feeding panel of residential installations. The proposed NILM is based on utilizing machine learning techniques. In this paper, concepts related to load monitoring, both intrusive and non-intrusive, are discussed, and the NILM method is explained in detail. Then, the machine learning model that is used, the Convolutional Neural Network (CNN), is being referenced, and the necessary theoretical background for its full understanding is provided. Finally, the development of a CNN model for NILM is presented, with a detailed description of its design and results.

Key – words: NILM, load identification, Deep Learning, Convolutional Neural Network (CNN)


ΔΗΛΩΣΗ ΠΝΕΥΜΑΤΙΚΩΝ ΔΙΚΑΙΩΜΑΤΩΝ

Δηλώνω ρητά ότι, σύμφωνα με το άρθρο 8 του Ν. 1599/1986 και τα άρθρα 2,4,6 παρ. 3 του Ν. 1256/1982, η παρούσα Διπλωματική Εργασία με τίτλο: «Ανάπτυξη Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου ως Μοντέλο Αναγνώρισης Φορτίου μέσω Μη-παρεμβατικής Προσέγγισης», καθώς και τα ηλεκτρονικά αρχεία και πηγαίοι κώδικες που αναπτύχθηκαν ή τροποποιήθηκαν στα πλαίσια αυτής της εργασίας και αναφέρονται ρητώς μέσα στο κείμενο που συνοδεύουν, και η οποία έχει εκπονηθεί στο Τμήμα Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών του Πανεπιστημίου Δυτικής Μακεδονίας, υπό την επίβλεψη του μέλους του Τμήματος κ. Μπουχουρά Άγγελου, αποτελεί αποκλειστικά προϊόν προσωπικής εργασίας και δεν προσβάλλει κάθε μορφής πνευματικά δικαιώματα τρίτων και δεν είναι προϊόν μερικής ή ολικής αντιγραφής, οι πηγές δε που χρησιμοποιήθηκαν περιορίζονται στις βιβλιογραφικές αναφορές και μόνον. Τα σημεία όπου έχω χρησιμοποιήσει ιδέες, κείμενο, αρχεία ή / και πηγές άλλων συγγραφέων, αναφέρονται ευδιάκριτα στο κείμενο με την κατάλληλη παραπομπή και η σχετική αναφορά περιλαμβάνεται στο τμήμα των βιβλιογραφικών αναφορών με πλήρη περιγραφή.

Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας, εξ ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για σκοπό μη κερδοσκοπικό, εκπαιδευτικής ή ερευνητικής φύσης, υπό την προϋπόθεση να αναφέρεται η πηγή προέλευσης και να διατηρείται το παρόν μήνυμα. Ερωτήματα που αφορούν τη χρήση της εργασίας για κερδοσκοπικό σκοπό πρέπει να απευθύνονται προς τον συγγραφέα. Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον συγγραφέα και μόνο.

Copyright (C) Δήμητρα Μυλωνά, Άγγελος Μπουχουράς, 2023, Κοζάνη

Υπογραφή Φοιτητή




ΠΕΡΙΕΧΟΜΕΝΑ

1. Εισαγωγή.....	8
1.1 Τι είναι το Έξυπνο Σπίτι – Δυνατότητες που παρέχει.....	8
1.2 Τι είναι ο Έξυπνος Μετρητής Ηλεκτρικής Ενέργειας και πώς χρησιμοποιείται.....	10
1.3 Ενεργειακή Κρίση	11
1.4 Peak Demand – Τι είναι και γιατί αποτελεί πρόβλημα	12
1.5 Μη-παρεμβατική παρακολούθηση φορτίου (NILM).....	13
1.5.1 Ορισμός	13
1.5.2 Τύποι συσκευών για ανίχνευση	14
1.5.3 Διαδικασία αποσύνθεσης του σήματος - Δυσκολίες.....	16
1.5.4 Γνωστές βάσεις δεδομένων ενεργειακής κατανάλωσης	20
1.5.5 Καινοτόμες λύσεις NILM	22
2. Θεωρητικό υπόβαθρο της αρχιτεκτονικής Συνελικτικού Νευρωνικού Δικτύου (Convolutional Neural Network - CNN).....	26
2.1 Τι είναι το CNN και πώς λειτουργεί.....	26
2.2 Σημαντικές παράμετροι του CNN.....	29
2.3 Είδη επιπέδων του CNN.....	31
2.4 Διαδικασία εκπαίδευσης του νευρωνικού δικτύου	37
2.5 Βελτιστοποίηση (Optimization).....	40
2.6 Κανονικοποίηση (Regularization).....	41
2.7 Δημοφιλείς αρχιτεκτονικές CNN	43
3. Ανάπτυξη του μοντέλου ενός Συνελικτικού Νευρωνικού Δικτύου.....	44
3.1 Προεπεξεργασία δεδομένων εισόδου.....	44
3.2 Σχεδιασμός του μοντέλου	48
3.3 Αποτελέσματα μοντέλου	59
4. Συμπεράσματα	65
4.1 Σύνοψη και συμπεράσματα	65
4.2 Περιορισμοί και μελλοντικές βελτιώσεις	65
Παράρτημα	67
Υλοποίηση CNN σε Python	67
Αναφορές.....	74

1. Εισαγωγή

1.1 Τι είναι το Έξυπνο Σπίτι – Δυνατότητες που παρέχει

Τα σύγχρονα τεχνολογικά επιτεύγματα επιτρέπουν στους ανθρώπους να προσθέτουν στα σπίτια τους «έξυπνα» χαρακτηριστικά, με στόχο την αναβάθμισή τους. Το έξυπνο σπίτι είναι αδιαμφισβήτητα το επόμενο βήμα στην εξέλιξη της σύγχρονης ζωής, αφού ήδη υπάρχουν 260 εκατομμύρια έξυπνα σπίτια παγκοσμίως. Ο όρος «έξυπνο σπίτι» αναφέρεται σε μια εγκατάσταση, με βασικά στοιχεία τις δυνατότητες διαχείρισης των συσκευών από απόσταση μέσω internet, και αυτόματης ενεργοποίησης συγκεκριμένων λειτουργιών (π.χ. απενεργοποίηση της θέρμανσης κατά την απουσία από το σπίτι). Η λειτουργία του βασίζεται στην κοινή σύνδεση όλων των συσκευών (τεχνολογία «Internet of Things»), οι οποίες μπορούν να γίνουν προσβάσιμες μέσω ενός κεντρικού σημείου –κινητού τηλεφώνου ή άλλης συνδεδεμένης στο δίκτυο συσκευής. Οι συσκευές ενός έξυπνου σπιτιού διαθέτουν ικανότητες αυτο-εκμάθησης, ώστε να μπορούν να παρακολουθούν τις συνήθειες του χρήστη και να πραγματοποιούν με δική τους πρωτοβουλία τις απαιτούμενες αλλαγές.



Σχήμα 1: Αναπαράσταση έξυπνου σπιτιού. Οι κύκλοι υποδηλώνουν τις πιθανές συνδεδεμένες συσκευές [1].

Παρουσιάζονται τουλάχιστον οκτώ διαφορετικοί τύποι πλεονεκτημάτων που προσφέρει ένα έξυπνο σπίτι, τόσο στο χρήστη, όσο και σε ολόκληρο το δίκτυο. Πρώτο και κυριότερο πλεονέκτημα αποτελεί η ικανότητα ενός έξυπνου σπιτιού να διαχειρίζεται καλύτερα την κατανάλωση ενέργειας και να

μειώνει τη χρήση της. Αυτό οφείλεται μερικώς, στο πόσο αναποτελεσματικά είναι δομημένα τα κτίρια, κυρίως στην Ευρώπη. Για παράδειγμα, στα πλαίσια μιας έρευνας στην Αγγλία [2], παρατηρήθηκε ότι το 98% των σπιτιών διέθεταν λέβητα αερίου για κεντρική θέρμανση, με σχεδόν αμελητέο έλεγχο (μόνο διακόπτης on/off ή χρονοδιακόπτης). Ταυτόχρονα, τα γραφήματα που αντιπροσωπεύουν την κατανάλωση έδειξαν ότι οι κάτοικοι είχαν τη θέρμανση ανοιχτή ακόμη και όταν απουσίαζαν. Έτσι, οδηγούμαστε στο συμπέρασμα ότι το 75% της οικιακής ενεργειακής κατανάλωσης στην Αγγλία δαπανάται στη θέρμανση. Η δυνατότητα ελέγχου και επίγνωσης του ποσού ενέργειας που καταναλώνει ένα σπίτι είναι πλεονέκτημα-κλειδί, αφού δημιουργεί ευκαιρίες για εξοικονόμηση ενέργειας.

Ένα εξίσου σημαντικό προνόμιο είναι η δημιουργία άνεσης. Παρόμοια με την Alexa/Siri (φωνητικός έλεγχος), η τεχνολογία καθιστά την καθημερινότητα ευκολότερη, πιο διασκεδαστική και πιο ενδιαφέρουσα. Μέσω του κινητού τηλεφώνου του, ο χρήστης μπορεί να ενεργοποιήσει ή να απενεργοποιήσει οποιαδήποτε συσκευή, αντικαθιστώντας τη χειροκίνητη λειτουργία. Ένας παράγοντας, που δε θα γινόταν να λείπει, είναι ο οικονομικός. Καλύτερη διαχείριση κατανάλωσης σημαίνει και καλύτερη διαχείριση χρημάτων, μέσω της άρσης της αλόγιστης σπατάλης ενέργειας. Επίσης, με δεδομένο ότι το σπίτι είναι σε θέση να καθορίσει τη χρήση της ενέργειας με όσο το δυνατόν πιο αποδοτικό τρόπο, οι καταναλωτές πλέον δε χρειάζεται να χρεώνονται για συσκευές που πριν θα ήταν διαρκώς ή άσκοπα ενεργοποιημένες [2].

Παράλληλα με το χρήστη, οφέλη προκύπτουν και για το ίδιο το δίκτυο ηλεκτρικής ενέργειας. Έχοντας την πληροφορία για το προφίλ κατανάλωσης του κάθε σπιτιού, ο διαχειριστής του δικτύου μπορεί, πιο εύκολα, να εξισορροπήσει αποτελεσματικότερα τη ζήτηση με την παροχή. Το «έξυπνο σπίτι» ταυτίζεται πολλές φορές με το «πράσινο σπίτι». Λόγω της υψηλής ενεργειακής επάρκειας και αυτονομίας του, η κατανάλωση ηλεκτρισμού και ορυκτών καυσίμων είναι μειωμένη, γεγονός που συντελεί στην προστασία του περιβάλλοντος και τη διαφύλαξη των μη ανανεώσιμων πηγών ενέργειας. Παράλληλα, τα έξυπνα σπίτια ενσωματώνουν τεχνολογίες, όπως τα ηλιακά πάνελ, που αποσκοπούν σε πρόσθετη ελάττωση των αναγκών για συμβατικές πηγές ενέργειας, όπως είναι τα ορυκτά καύσιμα.

Ένα ακόμη σημαντικό θετικό στοιχείο είναι η παροχή ασφάλειας. Το σπίτι θωρακίζεται με κάμερες, εσωτερικά και εξωτερικά, και ο χρήστης έχει τη δυνατότητα να παρακολουθεί και ζωντανά, όσο αυτές καταγράφουν. Μαζί, τοποθετούνται και αισθητήρες κίνησης, οι οποίοι, σε περίπτωση ανίχνευσης εισβολέα, καλούν άμεσα την αρμόδια αρχή, καθώς και ηλεκτρονικές κλειδαριές, οι οποίες απαιτούν προσωπικό κωδικό για να ξεκλειδώσουν. Τέλος, σημειώνονται οφέλη στους τομείς αισθητικής, χάρη στον ωραίο σχεδιασμό των «έξυπνων» συσκευών, και υγείας, αφού παρέχεται η δυνατότητα για άμεση κλήση της αρμόδιας υπηρεσίας σε έκτακτες περιπτώσεις [3]. Για παράδειγμα, σε περίπτωση που τα δεδομένα υποδεικνύουν παρατεταμένη χρήση της ηλεκτρικής κουζίνας στο σπίτι ενός καταναλωτή, μπορεί μια έξυπνη εφαρμογή να ειδοποιήσει αυτόματα κάποιον οικείο του, ώστε να προληφθεί πιθανός κίνδυνος πυρκαγιάς [4].

Παρατίθενται κάποιοι από τους πιο δημοφιλείς αυτοματισμούς ενός έξυπνου σπιτιού:

- 1) *Ασφάλειας σπιτιού*: παρακολούθηση χώρων και ενεργοποίηση σειρήνας όταν χρειαστεί.
- 2) *Φωτισμού*: ενεργοποίηση, απενεργοποίηση και ρύθμιση έντασης σε όλα τα φωτιστικά σώματα.
- 3) *Θερμοσίφωνα*: ενεργοποίηση, απενεργοποίηση από απόσταση.
- 4) *Θέρμανσης και ψύξης*: ρύθμιση από απόσταση, όχι απλά σαν λειτουργία on/off, αλλά με όλες τις λειτουργίες ρύθμισης που μπορεί να εκτελέσει ο τηλεχειρισμός του κλιματιστικού.


- 5) *Τεντών – Ρολών*: το σύστημα ανεβάζει και κατεβάζει τα ρολά και τις τέντες μεμονωμένα ή σε ομάδες με το πάτημα ενός διακόπτη. Η σκίαση τις κατάλληλες ώρες οδηγεί σε μειωμένες θερμοκρασίες στο εσωτερικό του σπιτιού, και άρα μείωση των αναγκών για ψύξη.
- 6) *Ήχου και εικόνας*: εύκολη και γρήγορη ρύθμιση των συσκευών αναπαραγωγής ήχου και εικόνας [5].

1.2 Τι είναι ο Έξυπνος Μετρητής Ηλεκτρικής Ενέργειας και πώς χρησιμοποιείται

Για τη δημιουργία ενός έξυπνου σπιτιού, κρίνονται καίριας σημασίας κάποιες τεχνολογίες. Μία από αυτές, είναι ο «έξυπνος μετρητής». Οι συγκεκριμένοι μετρητές είναι ασύρματες φορητές συσκευές, που μετρούν τη συνολική κατανάλωση ενέργειας σε πραγματικό χρόνο, ακριβώς όπως οι συμβατικοί μετρητές, με τη διαφορά ότι μπορούν να ενημερώνουν άμεσα τους χρήστες, τόσο για τη χρονική στιγμή που καταναλώθηκε η ενέργεια, όσο και για το κόστος της τη στιγμή αυτή. Εκτός από τους καταναλωτές, δίνεται η δυνατότητα ενημέρωσης και των παρόχων [4].

Είναι πολύ απλοί στην εγκατάσταση και τη χρήση τους. Ένας αισθητήρας μεταδίδει ασύρματα, μέσω του ειδικού πομπού ράγας, τις πληροφορίες σχετικά με την ποσότητα ηλεκτρικής ενέργειας που χρησιμοποιείται, απεικονίζοντας τα δεδομένα σε μια ασύρματη φορητή οθόνη. Η οθόνη μετατρέπει τη μετρήσιμη ενέργεια σε κιλοβατώρες, την τυπική μονάδα μέτρησης, που χρεώνει κάθε εταιρία ηλεκτρισμού. Οι αισθητήρες (αμπεροτσιμπίδες) κουμπώνουν γύρω από τα καλώδια τροφοδοσίας ρεύματος του κεντρικού ηλεκτρικού πίνακα του χώρου και συνδέονται με τον πομπό, ο οποίος συνήθως τοποθετείται εκτός του ηλεκτρολογικού πίνακα. Στη συνέχεια, ακολουθεί μια διαδικασία σύνδεσης μεταξύ πομπού και δέκτη (οθόνη). Μόλις η σύνδεση ολοκληρωθεί, ο μετρητής βρίσκεται σε πλήρη λειτουργία [6]. Στο Σχήμα 2, παρουσιάζεται ένας μονοφασικός έξυπνος μετρητής, με πομπό ράγας.

Η αξιοποίηση των συλλεγόμενων μετρήσεων είναι αυτή που οδηγεί σε καλύτερη διαχείριση της ενέργειας. Και αυτό γιατί, μέσω της σωστής ενημέρωσης, ο καταναλωτής αλλάζει συμπεριφορά χρήσης, αφού μπορεί να γνωρίζει το ποσό πληρωμής πριν σταλεί ο λογαριασμός του και το ποσό που καταναλώνει κάθε συσκευή του μεμονωμένα. Μέσω αυτής της δυνατότητας, εκτιμάται ότι μπορεί να παρατηρηθεί μείωση του λογαριασμού ρεύματος, έως και 20% [6]. Ωστόσο, καλό είναι να σημειωθεί, πως για μια βέλτιστη εφαρμογή θα πρέπει οι τεχνικές προδιαγραφές του μετρητή να εξασφαλίζουν ικανοποιητική συχνότητα καταγραφής δεδομένων (προτιμάται ανά δευτερόλεπτο). Επιπλέον, θα πρέπει να διασφαλίζεται στον καταναλωτή το δικαίωμα να συναλλάσσει τα δεδομένα του με φορείς της επιλογής του.



Σχήμα 2: Μονοφασικός έξυπνος μετρητής με πομπό ράγας [7].

1.3 Ενεργειακή Κρίση

Ταυτόχρονα με την ανάπτυξη και την εξέλιξη πρωτοποριακών τεχνολογιών στον τομέα της ενέργειας, παρατηρείται και η μεγαλύτερη ενεργειακή κρίση των τελευταίων ετών. Πιο συγκεκριμένα, οι τιμές της ενέργειας σημείωσαν πρωτοφανή άνοδο το 2022, κυρίως εξαιτίας της εισβολής της Ρωσίας στην Ουκρανία. Η χονδρική τιμή της ηλεκτρικής ενέργειας στην αγορά της Ευρωπαϊκής Ένωσης (E.E.) συνδέεται άμεσα με την τιμή του φυσικού αερίου, το οποίο είναι -κατά κύριο λόγο- εισαγόμενο. Η μείωση του εφοδιασμού αερίου αποτελεί τη βασική αιτία εκτίναξης των τιμών αερίου στα κράτη-μέλη της E.E., με αντίκτυπο την αύξηση και στην τιμή της ηλεκτρικής ενέργειας, η οποία παράγεται σε σταθμούς ηλεκτροπαραγωγής που λειτουργούν -σε μεγάλο βαθμό- με φυσικό αέριο.

Η τιμή της ενέργειας αναμένεται να παραμείνει υψηλή για μεγάλο -ακόμη- χρονικό διάστημα, καθώς χρειάζεται αρκετός χρόνος ώστε να επιτευχθεί αντικατάσταση των πηγών τροφοδοσίας. Έως τότε, οι χώρες της E.E. ενέκριναν κανονισμό έκτακτης ανάγκης για να αντιμετωπίσουν την κρίση και να βοηθήσουν πολίτες και επιχειρήσεις που πλήττονται από αυτή. Ο κανονισμός εφαρμόστηκε από την 1η Δεκεμβρίου 2022 έως τις 31 Μαρτίου 2023. Συμπληρώνει τις υφιστάμενες πρωτοβουλίες και νομοθετικές πράξεις της E.E. που θεσπίστηκαν για να κατοχυρωθεί η ασφάλεια του ενεργειακού εφοδιασμού, όπως ο κανονισμός για την αποθήκευση αερίου, ο κανονισμός για τη μείωση της ζήτησης αερίου, η δημιουργία μιας ενεργειακής πλατφόρμας και οι πρωτοβουλίες προβολής για τη διαφοροποίηση των πηγών εφοδιασμού.

Τα μέτρα που αναφέρονται για τη μείωση των λογαριασμών ενέργειας είναι τα εξής:

- 1) *Μείωση της χρήσης ηλεκτρικής ενέργειας:* συγκεκριμένα, υιοθετούνται εθελούσια μέτρα με στόχο τη μείωση της συνολικής χρήσης ηλεκτρικής ενέργειας κατά 10%, με υποχρεωτική όμως μείωση κατά τουλάχιστον 5% στις ώρες αιχμής. Έτσι, θα διατηρηθούν για μεγαλύτερο διάστημα τα αποθέματα καυσίμων και θα ελαχιστοποιηθεί η ζήτηση αερίου για ηλεκτροπαραγωγή.
- 2) *Ανώτατο όριο στα έσοδα των παραγωγών ηλεκτρικής ενέργειας:* όσοι παραγωγοί δε χρησιμοποιούσαν αέριο για την παραγωγή ενέργειας απέκτησαν απροσδόκητα υψηλά οικονομικά οφέλη. Το μέτρο αυτό θα καταστήσει δυνατή τη θέσπιση ανώτατου ορίου στα αγοραία έσοδα. Το ανώτατο αυτό όριο είναι 180€/MWh για εταιρίες που αξιοποιούν ανανεώσιμες πηγές, πυρηνική ενέργεια ή λιγνίτη. Με αυτόν τον τρόπο, θα «συγκρατηθούν» κέρδη από τους παραγωγούς ώστε να επωφεληθούν νοικοκυριά και επιχειρήσεις.
- 3) *Εξασφάλιση συνεισφοράς αλληλεγγύης από τις επιχειρήσεις ορυκτών καυσίμων:* οι εταιρίες ορυκτών καυσίμων έχουν αποκομίσει πρόσθετα κέρδη λόγω των υψηλών τιμών ενέργειας. Αφορά κέρδη που αυξήθηκαν κατά τουλάχιστον 20%. Με αυτό το μέτρο, επιδιώκεται η διασφάλιση της συνεισφοράς τους στο μερίδιο που τους αναλογεί, ώστε να επωφεληθούν τα νοικοκυριά και οι επιχειρήσεις [8].

1.4 Peak Demand – Τι είναι και γιατί αποτελεί πρόβλημα

«Peak Demand» ή στα ελληνικά «Αιχμή Ζήτησης» ονομάζεται η χρονική στιγμή στην οποία η ζήτηση ηλεκτρικής ενέργειας από τους καταναλωτές είναι μέγιστη. Οι περίοδοι αιχμής τείνουν να είναι οι μεσημεριανές-απογευματινές ώρες στη διάρκεια του χειμώνα, κατά τις οποίες λειτουργεί περισσότερο η θέρμανση, και οι απογευματινές ώρες στη διάρκεια του καλοκαιριού, κατά τις οποίες λειτουργεί περισσότερο η ψύξη [9]. Στην Ελλάδα, σαν ώρες αιχμής θεωρούνται οι 18.00-21.00, που οι περισσότεροι καταναλωτές βρίσκονται στο σπίτι [10].

Αν και η γενική ζήτηση ηλεκτρικής ενέργειας έχει μειωθεί με την πάροδο του χρόνου χάρη στις βελτιώσεις της τεχνολογίας, η αιχμή ζήτησης εξακολουθεί να δημιουργεί προβλήματα. Η αιχμή ζήτησης αποτελεί κρίσιμη ανησυχία για τους παρόχους ενέργειας, και ακόμη περισσότερο, για τους διαχειριστές των δικτύων ηλεκτρικής ενέργειας. Είναι αποτέλεσμα διαφόρων λόγων, όπως οι συμπεριφορές κατανάλωσης των χρηστών (πότε και πώς χρησιμοποιούν την ενέργεια) και η παραγωγή ενέργειας μέσω ανανεώσιμων πηγών (κυρίως ηλιακή και αιολική ενέργεια). Στο παρελθόν, οι πάροχοι ήταν σε θέση να μπορούν να διαχειριστούν καλύτερα το προφίλ της ενέργειας, εφόσον τα σπίτια και οι επιχειρήσεις ήταν μόνο καταναλωτές και όχι και παραγωγοί, όπως μπορεί να συμβεί σήμερα. Ταυτόχρονα, δημιουργείται αιχμή και από την εναλλαγή χρήσης ενέργειας από τις ανανεώσιμες πηγές στο δίκτυο. Για παράδειγμα, σε μια καλοκαιρινή ημέρα, ένας καταναλωτής που διαθέτει φωτοβολταϊκή εγκατάσταση και έχει αυτονομία τις πρωινές ώρες που παράγεται ηλιακή ενέργεια, θα αναγκαστεί τις βραδινές ώρες να χρησιμοποιήσει ενέργεια από το δίκτυο. Δηλαδή, μέσα σε πολύ σύντομο χρονικό διάστημα, η ζήτηση στο δίκτυο αυξάνεται απότομα.

Γενικά, αν η ζήτηση υπερβεί την ικανότητα παραγωγής, ο πάροχος θα πρέπει να αγοράσει ενέργεια από την αγορά, κάτι το οποίο είναι πολύ δαπανηρό. Εναλλακτικά, μπορεί να προτείνει τη δημιουργία νέων σταθμών παραγωγής, αλλά αυτή η προσέγγιση θα αυξήσει τα τέλη ηλεκτρικής ενέργειας και κατά συνέπεια, θα αποδειχθεί δαπανηρή για τους πελάτες. Για να αποφευχθούν, λοιπόν, αυτές οι καταστάσεις, οι προμηθευτές αναζητούν τρόπους μείωσης της ζήτησης σε περιόδους αιχμής [9].

Προκύπτει, λοιπόν, αβίαστα το συμπέρασμα ότι ο τομέας της ενέργειας αντιμετωπίζει έως και σήμερα σημαντικά προβλήματα. Καθίσταται αναγκαία η εύρεση λύσεων, ώστε η παροχή ενέργειας να είναι ασφαλής, οικονομική και αξιόπιστη. Τα τελευταία χρόνια γίνονται εντατικές προσπάθειες για αναβάθμιση των δικτύων ηλεκτρικής ενέργειας με την ενσωμάτωση εξελιγμένων μεθόδων. Ένας από τους βασικούς στόχους της αναβάθμισης αυτής είναι η μετατροπή του τελικού χρήστη από έναν παθητικό καταναλωτή, σε έναν ενεργό καταναλωτή, ο οποίος θα γνωρίζει επακριβώς το προφίλ της κατανάλωσής του. Η κατανάλωση κάθε ηλεκτρικής συσκευής θα πρέπει να καταγράφεται, και στη συνέχεια να επιλέγονται οι ενέργειες που θα εκτελεστούν [11]. Η πρόταση αυτή γίνεται εύκολα εφικτή με τη χρήση έξυπνων μετρητών και έξυπνων σπιτιών.

1.5 Μη-παρεμβατική παρακολούθηση φορτίου (NILM)

1.5.1 Ορισμός

Όπως έγινε αντιληπτό, υπάρχει ανάγκη για βελτιστοποίηση της χρήσης ενέργειας στον οικιακό και εμπορικό τομέα. Η σπατάλη ενέργειας μπορεί να αποφευχθεί με την παρακολούθηση της ενεργειακής κατανάλωσης και την αναφορά της σε καταναλωτές και παρόχους, για τη λήψη αποτελεσματικών μέτρων. Με την ανατροφοδότηση της συνολικής κατανάλωσής τους και πιο συγκεκριμένα, την ενημέρωση για την κατανάλωση της κάθε συσκευής ξεχωριστά, οι καταναλωτές είναι πιθανό να υιοθετήσουν διαφορετικές συνήθειες χρήσης. Τα οφέλη αυτά λειτούργησαν ως κίνητρο για την ανάπτυξη της «Παρακολούθησης Φορτίου».


Η παρακολούθηση φορτίου μπορεί εύκολα να υλοποιηθεί με την εγκατάσταση έξυπνων μετρητών. Ωστόσο, αυτή η πρόταση αποτελεί μια δαπανηρή και χρονοβόρα λύση, καθώς πρέπει να συνδεθεί ο κατάλληλος εξοπλισμός σε κάθε συσκευή. Το 1992, ο George W. Hart προτείνει μια προσέγγιση σύμφωνα με την οποία, γίνεται εφικτό να εξαχθεί το μοτίβο κατανάλωσης κάθε συσκευής μεμονωμένα μέσα από το συνολικό σήμα κατανάλωσης του σπιτιού, με τη χρήση ενός μόνο μετρητή. Η προσέγγιση αυτή είναι γνωστή ως «Μη-Παρεμβατική Παρακολούθηση Φορτίου» (Non-Intrusive Load Monitoring - NILM) [12]. Στο Σχήμα 3, παρουσιάζεται η διαφορά μεταξύ των δύο μεθόδων παρακολούθησης.

Το πρόβλημα της μη-παρεμβατικής παρακολούθησης φορτίου μπορεί να περιγραφεί από την εξίσωση (1).


$$X_t = \sum_{i=1}^N y_t^i + \sigma(t) \quad (1)$$

όπου X η δεδομένη ακολουθία της συνολικής κατανάλωσης ισχύος από N ενεργές συσκευές σε χρόνο $t = \{1, 2, \dots, T\}$. Στόχος του NILM είναι ο υπολογισμός της συνεισφοράς στη συνολική ισχύ y της συσκευής $i \in \{1, 2, \dots, N\}$ σε χρόνο t , έτσι ώστε κάθε χρονική στιγμή να ισχύει η εξίσωση. Ο όρος $\sigma(t)$ αντιπροσωπεύει τις συσκευές που δε λαμβάνονται υπόψη, καθώς και το θόρυβο υποβάθρου κατά τη μέτρηση [13]. Στο

Σχήμα 4, απεικονίζεται ένα πρόβλημα μη-παρεμβατικής παρακολούθησης, στο οποίο οι τρεις διαφορετικές βηματικές αλλαγές οδηγούν στις χαρακτηριστικές υπογραφές των τριών συσκευών.



Σχήμα 3: (a) Μη-παρεμβατική παρακολούθηση, (b) Παρεμβατική παρακολούθηση [14].




Σχήμα 4: Σχηματική απεικόνιση της μη-παρεμβατικής παρακολούθησης φορτίου [15].

1.5.2 Τύποι συσκευών για ανίχνευση

Η ενεργειακή κατανάλωση κάθε συσκευής είναι μοναδική και καλείται «υπογραφή» της συσκευής αυτής. Με βάση τις υπογραφές, οι συσκευές κατηγοριοποιούνται στους ακόλουθους τύπους:

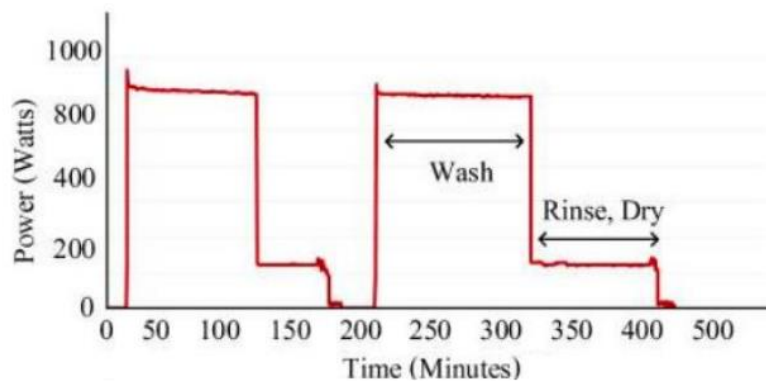
- 1) *Τύπος I (Συσκευές ON/OFF)*: συσκευές με δύο καταστάσεις λειτουργίας, ενεργή ή ανενεργή. Παρουσιάζουν ισχύ μόνο κατά τη διάρκεια της ενεργής λειτουργίας τους. Θεωρούνται

γραμμικές, αφού η λειτουργία τους είναι σταθερή. Παραδείγματα τέτοιων συσκευών είναι η τοστιέρα, ο βραστήρας, οι λάμπες. Μία τυπική καμπύλη κατανάλωσης, μίας συσκευής αυτής της κατηγορίας, παρουσιάζεται στο Σχήμα 5.



Σχήμα 5: Παράδειγμα υπογραφής συσκευής τύπου I [16].


- 2) *Τύπος II (Multi-state ή Finite State Machines-FSM)*: συσκευές με πεπερασμένο πλήθος καταστάσεων λειτουργίας. Κάθε κατάσταση έχει το δικό της αποτύπωμα, δημιουργώντας ένα μοτίβο στο σύνολο. Οι διαφορετικές καταστάσεις μπορούν να εντοπιστούν από τις πτώσεις/αυξήσεις του σήματος. Παραδείγματα τέτοιων συσκευών είναι το πλυντήριο, η εστία μαγειρέματος. Μία τυπική καμπύλη κατανάλωσης, μίας συσκευής αυτής της κατηγορίας, παρουσιάζεται στο Σχήμα 6.



Σχήμα 6: Παράδειγμα υπογραφής συσκευής τύπου II (πλυντήριο) [16].

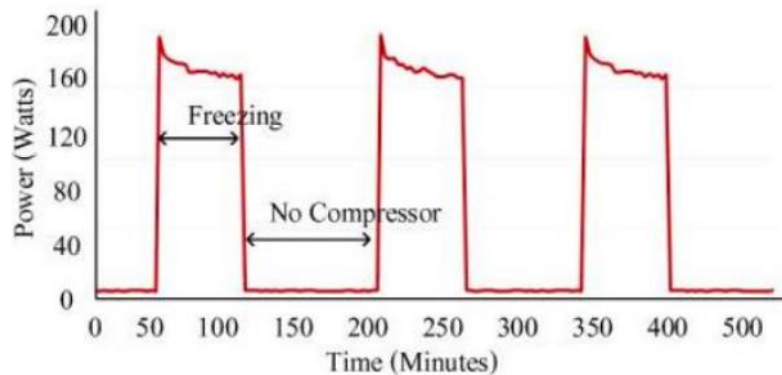
- 3) *Τύπος III (Continuously Variable Devices-CVD)*: συσκευές που δεν έχουν πεπερασμένο πλήθος καταστάσεων λειτουργίας και δε δημιουργούν μοτίβο, οι οποίες είναι δύσκολο να ανιχνευθούν. Παραδείγματα τέτοιων συσκευών είναι οι φορτιστές μπαταριών, οι φορητοί υπολογιστές. Μία

τυπική καμπύλη κατανάλωσης, μίας συσκευής αυτής της κατηγορίας, παρουσιάζεται στο Σχήμα 7.



Σχήμα 7: Παράδειγμα υπογραφής συσκευής τύπου III [16].

- 4) *Τύπος IV (Permanent Consumer Devices)*: συσκευές που λειτουργούν σταθερά σε ενεργή κατάσταση για μέρες/εβδομάδες. Παραδείγματα τέτοιων συσκευών είναι τα ψυγεία, τα ασύρματα τηλέφωνα [12]. Μία τυπική καμπύλη κατανάλωσης, μίας συσκευής αυτής της κατηγορίας, παρουσιάζεται στο Σχήμα 8.

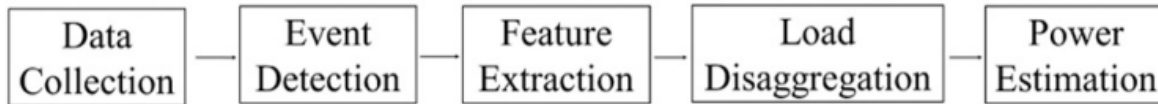


Σχήμα 8: Παράδειγμα υπογραφής συσκευής τύπου IV [16].

1.5.3 Διαδικασία αποσύνθεσης του σήματος - Δυσκολίες

Η «Ενεργειακή αποσύνθεση» (Energy Disaggregation) είναι μια τεχνική, η οποία υπολογίζει την κατανάλωση ενέργειας της κάθε συσκευής μεμονωμένα, από μια μόνο πηγή μέτρησης. Η διαδικασία

παρουσιάζεται στο Σχήμα 9 και αποτελείται από τη συλλογή δεδομένων, την ανίχνευση συμβάντων, την εξαγωγή χαρακτηριστικών, το διαχωρισμό φορτίου και την εκτίμηση ισχύος.



Σχήμα 9: Γενική μεθοδολογία NILM [17].

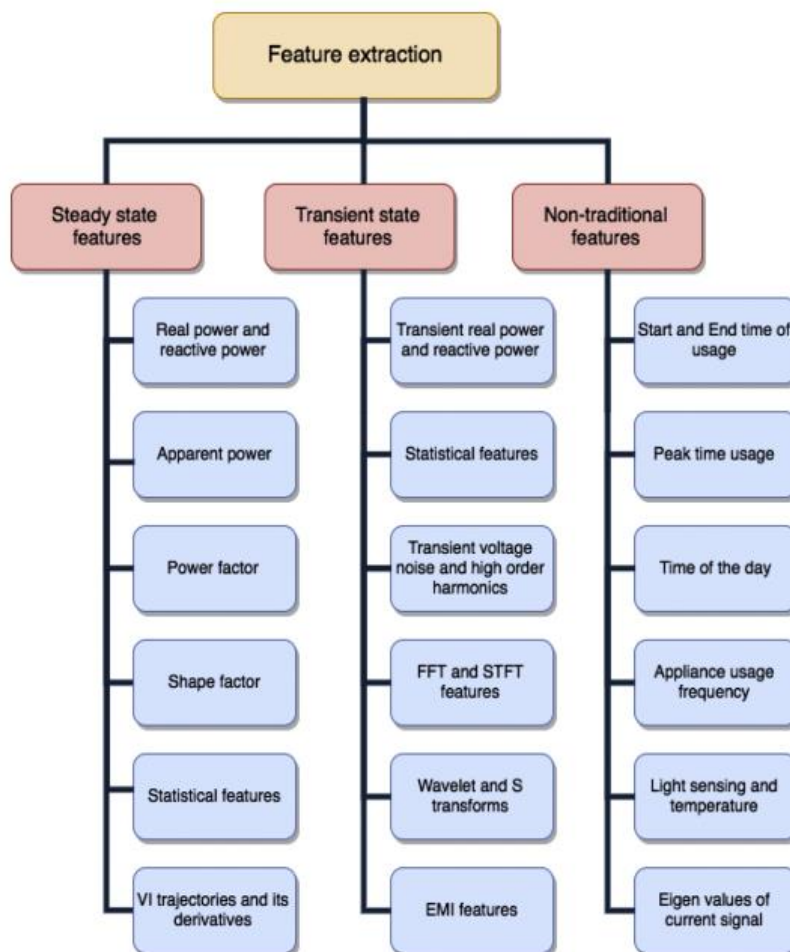
Συλλογή δεδομένων: η πρώτη πρόκληση που συναντάται στην ανάπτυξη ενός NILM αλγορίθμου είναι η επιλογή συχνότητας, με την οποία θα συλλέγονται δεδομένα οι έξυπνοι μετρητές, ώστε να επιτευχθεί η ταυτοποίηση συσκευών με όσο το δυνατόν μεγαλύτερη ακρίβεια. Αποδείχθηκε πως οι μετρήσεις με μεγαλύτερη συχνότητα είναι πιο αποτελεσματικές, καθώς εξάγουν πιο χρήσιμα χαρακτηριστικά. Για παράδειγμα, συχνότητα μεγαλύτερη από 1 Hz μπορεί να ταυτοποιήσει σωστά ακόμη και συσκευές με παρόμοια ισχύ, και αυτό γιατί, έχουν εξαχθεί χαρακτηριστικά, τα οποία χαρακτηρίζονται από μοναδικές κυματομορφές. Μια ακόμη δυσκολία που παρουσιάζεται σε αυτό το στάδιο είναι η ασφάλεια των δεδομένων του χρήστη, λόγω της αποστολής και επαναχρησιμοποίησης των μετρήσεων. Άρα, κρίνεται αναγκαίο να αναπτυχθούν τεχνικές που θα προστατεύουν την ιδιωτικότητα του χρήστη.

Ανίχνευση συμβάντων: σε αυτό το στάδιο, εξάγονται πληροφορίες για την αλλαγή κατάστασης της λειτουργίας των συσκευών, όπως: η ενεργοποίηση, η απενεργοποίηση και η συνεχής λειτουργία. Γενικά, οι προκλήσεις στην ανίχνευση συμβάντων προκύπτουν από τρία στοιχεία: τις υψηλές διακυμάνσεις, τη μακροχρόνια μετάβαση και το συγχρονισμό (ή σχεδόν-συγχρονισμό). Η υψηλή διακύμανση αναφέρεται στην ισχύ σε σταθερή κατάσταση με τυπική απόκλιση μεγαλύτερη από μια καθορισμένη τιμή. Η μακροχρόνια μετάβαση παρατηρείται όταν ένα γεγονός διαρκεί περισσότερο από το χρόνο που προσδοκεί η μέθοδος ανίχνευσης. Ο συγχρονισμός αφορά δύο παρακείμενα γεγονότα, που συμβαίνουν ταυτόχρονα ή με διαφορά ενός πολύ μικρού χρονικού διαστήματος. Στη βιβλιογραφία, παρουσιάζονται μέθοδοι που ανήκουν σε τρεις κατηγορίες: τους εξειδικευμένους ευριστικούς (expert heuristics), το μοντέλο πιθανοτήτων (probability model) και το προσαρμοσμένο φίλτρο (matched filter). Αν και η κάθε μέθοδος έχει τα δικά της πλεονεκτήματα, παραμένει δύσκολη η αντιμετώπιση όλων των προκλήσεων ταυτόχρονα.


Εξαγωγή χαρακτηριστικών: οι καλά-σχεδιασμένες μέθοδοι NILM απαιτούν μοναδικές υπογραφές που αποτυπώνουν τη συμπεριφορά της συσκευής, για τον εντοπισμό των διαφορετικών συσκευών στο συνολικό σήμα. Τέτοια χαρακτηριστικά, που σχετίζονται με τη συμπεριφορά, εξάγονται από τα μοναδικά μοτίβα κατανάλωσης της κάθε συσκευής, παρέχουν πληροφορίες σχετικά με τη λειτουργία ή την αλλαγή κατάστασης της λειτουργίας και εξαρτώνται από εσωτερικά μέρη των συσκευών, όπως οι αντιστάσεις ή οι κινητήρες. Εμφανίζονται δύο κύριες κατηγορίες χαρακτηριστικών που μπορούν να χρησιμοποιηθούν από το NILM: τα χαρακτηριστικά σταθερής κατάστασης (steady-state features) και τα χαρακτηριστικά μετάβασης (transient features). Τα πρώτα εξάγονται κατά την κατάσταση σταθερής λειτουργίας της συσκευής και σχετίζονται με την ισχύ και τη σχέση μεταξύ τάσης και ρεύματος (συντελεστής ισχύος), ενώ τα τελευταία κατά τις μεταβάσεις καταστάσεων λειτουργίας και προκύπτουν από το θόρυβο, ο οποίος

απορρέει από την εναλλαγή ON/OFF. Υπάρχουν μελέτες που χρησιμοποιούν και «μη-παραδοσιακά» χαρακτηριστικά σε συνδυασμό με τις δύο κύριες κατηγορίες. Αυτού του είδους τα χαρακτηριστικά αφορούν τη συμπεριφορά του χρήστη, με παραδείγματα την ώρα έναρξης, ώρα λήξης, ώρα αιχμής της χρήσης μιας συσκευής, τη συχνότητα χρήσης της και τη θερμοκρασία [17]. Στο Σχήμα 10, παρουσιάζονται αναλυτικά τα διάφορα είδη χαρακτηριστικών που αναφέρθηκαν.


Ταυτόχρονα με τα χαρακτηριστικά των συσκευών, στην αναγνώριση μη-γραμμικών φορτίων που απορροφούν μη-ημιτονοειδές ρεύμα κατά τη λειτουργία σταθερής κατάστασης, μπορούν να συμβάλλουν και οι αρμονικές ρεύματος ανώτερης τάξης, που παράγονται λόγω της μη-γραμμικότητας. «Αρμονικές» ονομάζονται οι συχνότητες που αποτελούν ακέραια πολλαπλάσια της θεμελιώδους συχνότητας (στην Ελλάδα ισούται με 50 Hz). Συνεπώς, αναφερόμαστε στη 3^η αρμονική, ίση με 150 Hz, και στην 5^η αρμονική, ίση με 250 Hz. Δημιουργούνται, κυρίως, σε συσκευές με διατάξεις ηλεκτρονικών ισχύος (ανορθωτές, αντιστροφείς κλπ.). Η εκμετάλλευση των αρμονικών, σε συνδυασμό με τις μετρήσεις ενεργού και άεργου ισχύος, μπορούν να βελτιώσουν την απόδοση του μοντέλου NILM. Στο Σχήμα 11, αποτυπώνονται οι διαφορές μεταξύ των αρμονικών σε έξι διαφορετικές συσκευές, ενώ στο Σχήμα 12, οι αντίστοιχες κυματομορφές τάσης-ρεύματος [18].



Σχήμα 10: Κατηγοριοποίηση χαρακτηριστικών [12].



Σχήμα 11: Περιεχόμενο αρμονικών για έξι διαφορετικές οικιακές συσκευές [18].



Σχήμα 12: Κυματομορφές τάσης-ρεύματος των έξι οικιακών συσκευών [18].

Εκμάθηση παραμέτρων: τα εξαγόμενα χαρακτηριστικά χρησιμοποιούνται σε αυτό το στάδιο, ώστε να αναγνωρίσουν τις συσκευές που λειτούργησαν, καθώς και τις καταστάσεις λειτουργίας τους, με τη βοήθεια παραμέτρων της κάθε συσκευής. Με βάση την πηγή των παραμέτρων, οι μέθοδοι εκπαίδευσης διαχωρίζονται σε εποπτευόμενες (supervised) και μη-εποπτευόμενες (unsupervised). Οι εποπτευόμενες μέθοδοι απαιτούν ένα πρόσθετο βήμα απόδοσης ετικέτας (labeling), στο οποίο τα δεδομένα κατανάλωσης της κάθε συσκευής, ή τμήμα των μετρήσεων, χρησιμοποιούνται για την

εκπαίδευση των παραμέτρων των συσκευών. Οι μη-εποπτευόμενες μέθοδοι δεν απαιτούν labeling- ανακτούν τις παραμέτρους από τις βάσεις δεδομένων των συσκευών. Γενικά, η απόδοση των εποπτευόμενων μεθόδων είναι υψηλότερη συγκριτικά με αυτή των μη-εποπτευόμενων [17]. Ωστόσο, ακολουθούνται από κάποιους περιορισμούς κατά την εφαρμογή τους σε πραγματικό χρόνο. Για παράδειγμα, δε διαθέτουν δυνατότητα προσαρμογής στις αλλαγές του περιβάλλοντος. Επομένως, οι υπογραφές της συσκευής θα πρέπει να ενημερώνονται με την εμφάνιση παραγόντων, όπως η γήρανση της συσκευής, η μείωση απόδοσης, η αντικατάσταση [12].

1.5.4 Γνωστές βάσεις δεδομένων ενεργειακής κατανάλωσης

Στον Πίνακα 1, παρουσιάζονται κάποιες από τις πιο δημοφιλείς βάσεις δεδομένων για το NILM. Έχουν δημιουργηθεί για ερευνητικούς σκοπούς και το πλεονέκτημά τους είναι ότι επιτρέπουν τη σύγκριση αποτελεσμάτων σε κοινά δεδομένα. Περιέχουν στοιχεία κατανάλωσης από οικίες χωρών με διαφορετικά χαρακτηριστικά, όπως η συχνότητα δικτύου, και από συσκευές με προδιαγραφές που ίσως να μη συμβαδίζουν με τις συσκευές που διαθέτει μια κατοικία. Ωστόσο, το γεγονός αυτό δημιουργεί την αμφιβολία για το εάν μπορούν να αξιοποιηθούν επιτυχώς στην ανάπτυξη μοντέλων αποσύνθεσης σήματος σε ουδέτερα σπίτια. Και αυτό γιατί, η ακρίβεια των αλγορίθμων θα κλονίζεται, λόγω του ότι η εκπαίδευσή τους δεν θα είναι προσαρμοσμένη στα χαρακτηριστικά των φορτίων της οικίας που μελετάται [13].

Πίνακας 1: Δημοφιλείς βάσεις δεδομένων για το NILM [13].

Βάση Δεδομένων	Τοποθεσία	Έτος δημιουργίας	Παράμετροι	Διάρκεια μετρήσεων	Πλήθος σπιτιών	Συχνότητα δειγμάτων
REDD	ΗΠΑ	2011	I, V, P	19 μέρες	6	15 kHz & 1 s (agg) – 3 s (app)
IAWE	Ινδία	2013	I, V, P, Q, S, f, EE	73 μέρες	1	1 s
UK-DALE	Μ. Βρετανία	2014	I, V, P, Q	2 χρόνια	5	16 kHz & 1 s (agg) – 6 s (app)
Dataport	ΗΠΑ	2018	P, S	4+ χρόνια	1.200+	60 s

όπου *I*: ένταση ρεύματος, *V*: τάση, *P*: ενεργός ισχύς, *Q*: άεργος ισχύς, *S*: φαινόμενη ισχύς, *f*: συχνότητα, *EE*: ηλεκτρική ενέργεια.

Η συχνότητα δειγματοληψίας παίζει σημαντικό ρόλο στην απόδοση του NILM. Αν και στις περισσότερες μελέτες γίνεται χρήση ενός μόνο ρυθμού δειγματοληψίας, σε ορισμένες παρατηρείται

χρήση διαφορετικών ρυθμών, σε ένα εύρος από πολύ χαμηλούς, της τάξης των Hz, έως πολύ υψηλούς, της τάξης των kHz/MHz [19]. Όπως αναφέρεται στο [20], η απόδοση που καταγράφεται για ένα μόνο ρυθμό μπορεί να μην επαρκεί για την ενδεδειγμένη αξιολόγηση του αλγορίθμου. Σημειώνεται ότι η απόδοση μειώνεται μη-γραμμικά με τη μείωση του ρυθμού, όμως μειώνεται και ο υπολογιστικός χρόνος. Συνεπώς, αναζητείται η «χρυσή τομή» μεταξύ απόδοσης και υπολογιστικού χρόνου, ώστε να βρεθεί ο ιδανικότερος ρυθμός δειγματοληψίας. Στο [19], αναλύεται μια προσέγγιση NILM σε διαφορετικούς ρυθμούς δειγματοληψίας, με σκοπό τον έλεγχο της αποτελεσματικότητάς τους. Η ανίχνευση των συσκευών υλοποιείται με: α) Μηχανή Διανυσμάτων Στήριξης (Support Vector Machine - SVM) και β) Βαθιά Νευρωνικά Δίκτυα (Deep Neural Networks - DNN). Στον Πίνακα 2, παρατηρούμε την αύξηση της απόδοσης με την αύξηση της συχνότητας των δειγμάτων.

Σύμφωνα με τα συμπεράσματα της έρευνας, μεταξύ των 3 συχνοτήτων, 10 kHz, 25 kHz και 50 kHz, η μεγαλύτερη ακρίβεια αναγνώρισης και η υψηλότερη απόδοση του αλγορίθμου επιτυγχάνονται στα 50 kHz, δηλαδή στη μεγαλύτερη συχνότητα. Στη συνέχεια, παρουσιάζονται κάποιες από τις πιο γνωστές βάσεις δεδομένων υψηλής συχνότητας (high sampling datasets).

- 1) *COOLL*: Αποτελείται από 840 περιπτώσεις στιγμιαίου ρεύματος και τάσης. Για αυτή τη βάση, χρησιμοποιήθηκαν 42 συσκευές που ανήκουν σε 12 διαφορετικούς τύπους. Οι μετρήσεις πραγματοποιήθηκαν στη Γαλλία, με ρυθμό δειγματοληψίας ίσο με 100 kHz [21].
- 2) *WHITED*: Περιέχει μετρήσεις μεταβατικής κατάστασης στιγμιαίου ρεύματος και τάσης για 134 συσκευές κατά την ενεργοποίησή τους. Οι διαφορετικοί τύποι συσκευών είναι 46. Οι μετρήσεις πάρθηκαν από 8 διαφορετικές περιοχές σε όλο τον κόσμο, με ρυθμό δειγματοληψίας ίσο με 44,1 kHz [22].
- 3) *MORED*: Αποτελείται από διάφορες βάσεις δεδομένων, με πιο σχετική με τη φύση της υψηλής δειγματοληψίας αυτή που περιέχει στιγμιαίες μετρήσεις ρεύματος και τάσης, με ρυθμό ίσο με 50 kHz. Χρησιμοποιήθηκαν 52 συσκευές, οι οποίες κατατάσσονται σε 37 διαφορετικούς τύπους. Οι μετρήσεις έχουν ληφθεί από 4 διαφορετικά νοικοκυριά και από 1 εργαστήριο στο Μαρόκο [23].

Πίνακας 2: Καταγραφή απόδοσης με τη χρήση διαφορετικών ρυθμών δειγματοληψίας [19].

Classifier	Parameters/ DNN layers	Overall Accuracy		
		10 kHz	25 kHz	50 kHz
SVM	Linear	41.63%	44.19%	72.26%
	RBF	46.40%	48.73%	62.23%
	Polynomial	43.56%	67.55%	60.60%
DNN	(512,256,64,16)	60.40%	69.32%	80.37%

1.5.5 Καινοτόμες λύσεις NILM

Έχουν αναφερθεί πολλές καινοτόμες λύσεις στην υπάρχουσα βιβλιογραφία, οι οποίες βασίζονται στη Μηχανική Μάθηση (Machine Learning). Παραδείγματα αυτών είναι οι διαφορετικές παραλλαγές του Κρυφού Μαρκοβιανού Μοντέλου (Hidden Markov Model - HMM) και μια υποκατηγορία της μηχανικής μάθησης, η Βαθιά Μάθηση (Deep Learning), η οποία μιμείται τον ανθρώπινο εγκέφαλο. Τα αποτελέσματα των μεθόδων μπορεί να διαφέρουν μεταξύ τους, όμως όλες οι μέθοδοι καλύπτουν τα βασικά βήματα της συλλογής δεδομένων, ανίχνευσης συμβάντων, εξαγωγής χαρακτηριστικών και εκμάθησης παραμέτρων. Ωστόσο, η εξέλιξη του Deep Learning και πιο συγκεκριμένα η ανάπτυξη της προσέγγισης των Νευρωνικών Δικτύων (Neural Networks), αποτελεί τη βάση για πρωτοποριακές σύγχρονες υλοποιήσεις, με καλύτερα αποτελέσματα συγκριτικά με προηγούμενες μελέτες [24].

- 1) *Κρυφά Μαρκοβιανά Μοντέλα (Hidden Markov Models)*: οι πρώτες μελέτες NILM βασίστηκαν κυρίως στα μοντέλα Hidden Markov, τα οποία χρησιμοποιούνται συνήθως για μοντελοποίηση χρονοσειρών. Μια σειρά από καταστάσεις, δηλαδή επίπεδα κατανάλωσης, ορίζεται τυπικά για κάθε συσκευή, με κάθε κατάσταση να έχει τη δική της πιθανολογική κατανομή [24]. Η κατάσταση του μοντέλου είναι κρυφή, όχι άμεσα ορατή στον παρατηρητή, αλλά η έξοδος είναι ορατή και εξαρτώμενη από την κρυφή κατάσταση. Για το NILM, η κρυφή κατάσταση είναι κάθε δυνατός συνδυασμός των καταστάσεων φορτίου των συσκευών, ενώ η έξοδος είναι το σήμα της συνολικής κατανάλωσης. Η ιδιότητα Markov επιβεβαιώνει ότι η υπό συνθήκη κατανομή πιθανότητας των κρυφών καταστάσεων εξαρτάται μόνο από την τιμή της αμέσως προηγούμενης κρυφής κατάστασης. Έχουν προταθεί διάφορες παραλλαγές, με πιο δημοφιλείς τα Factorial HMM, που γενικεύουν την αναπαράσταση των επιπέδων μέσω πολλαπλών μεταβλητών. Άλλες παραλλαγές είναι οι: Conditional FHMM (CFHMM), που χρησιμοποιείται σε περιπτώσεις προσθήκης περισσότερων του ενός χαρακτηριστικών για την αναπαράσταση των καταστάσεων, Factorial Hidden Semi Markov Models (FHSMM), που αποτελεί επέκταση του FHMM μέσω της χρήσης εναλλακτικής συνάρτησης πυκνότητας πιθανότητας για τη διάρκεια κατάληψης της κατάστασης της συσκευής, Conditional FHSMM, ως συνδυασμός των FHSMM και CFHMM [13].

Στο [25] χρησιμοποιήθηκαν παραλλαγές του HMM για αποσύνθεση του συνολικού σήματος. Η μελέτη έγινε σε 10 σπίτια, με το καθένα να διαθέτει διαφορετικό αριθμό συσκευών. Οι συγγραφείς βασίστηκαν σε χαρακτηριστικά χαμηλής συχνότητας δειγματοληψίας. Τα αποτελέσματα είχαν ποσοστό ακρίβειας ανίχνευσης από 68% έως και 98%, το οποίο μειωνόταν όσο αυξανόταν ο αριθμός των συσκευών για ανίχνευση.

Στο [26] χρησιμοποιήθηκε συνδυασμός δύο FHMM παραλλαγών, additive FHMM και difference FHMM. Οι συγγραφείς βασίστηκαν σε χαρακτηριστικά υψηλής συχνότητας δειγματοληψίας. Για τη δημιουργία του μοντέλου, ο αλγόριθμος εξάγει αποσπάσματα δεδομένων κατανάλωσης, που πιθανώς αντιστοιχούν στον κύκλο λειτουργίας μιας συσκευής. Έπειτα, προσπαθεί να αναγνωρίσει τα αποσπάσματα που ανήκουν στην ίδια συσκευή. Τα αποτελέσματα έδειξαν ότι επιτυγχάνεται μέτρια έως υψηλή ακρίβεια σε τέσσερα από τα επτά φορτία, και χαμηλή ακρίβεια σε ηλεκτρονικούς τύπους συσκευών.

Στο [27] αναπτύχθηκε μια προσέγγιση που βασίζεται σε κρυφά μοντέλα Markov (Bayesian HMM), με στόχο την αποσύνθεση δεδομένων ενεργού ισχύος. Οι συγγραφείς βασίστηκαν σε χαρακτηριστικά χαμηλής συχνότητας δειγματοληψίας. Η προσέγγιση θεωρείται ημι-επιβλεπόμενη (semi-supervised), καθώς προσπαθεί να εκπαιδεύσει το μοντέλο μέσω ενός γνωστού συνόλου δεδομένων.

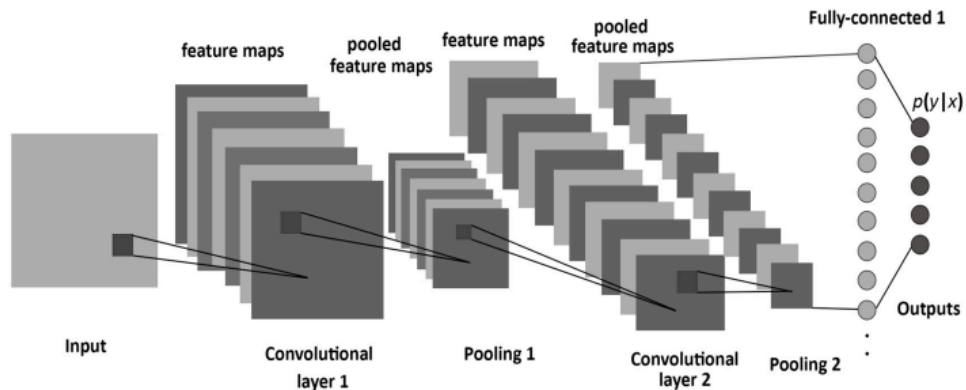
- 2) *Αλγόριθμοι Βελτιστοποίησης (Optimization methods)*: οι μέθοδοι βελτιστοποίησης παρέχουν μια διαφορετική προσέγγιση, με κύρια ιδέα την εύρεση του βέλτιστου συνδυασμού μεμονωμένων συσκευών που συνθέτουν το ολικό σήμα [24]. Στο [28], αναφέρεται ότι η αυξημένη πολυπλοκότητα που δημιουργείται από ένα μεγάλο αριθμό συσκευών και η απώλεια της χρονικής συνέχειας συνιστούν δύο σημαντικά μειονεκτήματα στη χρήση τεχνικών βελτιστοποίησης για το NILM. Μεταξύ των διαφόρων αλγορίθμων, οι Γενετικοί (Genetic Algorithms) φαίνεται να έχουν την καλύτερη απόδοση. Στο [29] προτείνεται μια μέθοδος επεξεργασίας (GSP), η οποία προσφέρει μια ανταγωνιστική λύση για μειωμένο υπολογιστικό φόρτο. Οι μέθοδοι που είναι εμπνευσμένες από την επεξεργασία εικόνας έχουν κερδίσει το ενδιαφέρον, καθώς επιτυγχάνουν καλύτερα αποτελέσματα από το μοντέλο FHMM [30,31].
- 3) *Ρηχή Μάθηση (Shallow Learning)*: περιλαμβάνει όλους τους παραδοσιακούς αλγόριθμους ταξινόμησης και παλινδρόμησης. Μέσω της ρηχής μάθησης, υπονοείται ότι ακολουθήθηκε μια «χειροποίητη» διαδικασία εξαγωγής χαρακτηριστικών, βασισμένη στη γνώση ειδικών σε αυτόν τον τομέα. Είναι ευκολότερη στην εφαρμογή, έχει μικρότερη υπολογιστική πολυπλοκότητα και σε ορισμένες περιπτώσεις έχει οδηγήσει σε θετικά αποτελέσματα. Οι υλοποιήσεις SVM προσπάθησαν να αντιμετωπίσουν το πρόβλημα με γραμμικές, αλλά και μη-γραμμικές προσεγγίσεις. Οι ταξινομητές Naive Bayes το αντιμετώπισαν υποθέτοντας ανεξαρτησία μεταξύ της κάθε κατάστασης της συσκευής, επιτυγχάνοντας ένα αξιοπρεπές ποσοστό ακρίβειας, αλλά με μικρό δείγμα εκπαίδευσης. Οι υλοποιήσεις που βασίζονται σε δέντρα αποφάσεων αποτελούν την καλύτερη προσέγγιση για ρηχή μάθηση, καθώς χρησιμοποιούνται συχνά και είναι σε θέση να αμφισβητήσουν την κυριαρχία των μεθόδων βαθιάς μάθησης [24]. Η εργασία που παρουσιάζεται στο [32] χρησιμοποιεί ένα σύνολο δέντρων αποφάσεων που βασίζεται στην τεχνική του bagging. Χρησιμοποιείται ένα νέο σύνολο χαρακτηριστικών συχνότητας και τα αποτελέσματα δείχνουν ότι οι συσκευές με παρόμοια κατανάλωση ανιχνεύονται με επιτυχία. Η τεχνική αυτή εφαρμόζεται στο [33], όπου ο αλγόριθμος XGBoost χρησιμοποιείται για την αποσύνθεση του σήματος. Ο XGBoost παρουσιάζει καλύτερα αποτελέσματα από τα Bayesian Δίκτυο (Bayesian Network), SVM, Τυχαίο Δάσος (Random Forest), Νευρωνικό Δίκτυο (Neural Network) και HMM, ενώ μειώνει το κόστος εκπαίδευσης του μοντέλου.
- 4) *Βαθιά Μάθηση (Deep Learning)*: η βαθιά μάθηση είναι ένας όρος που χρησιμοποιείται για να περιγράψει ένα σύνολο αλγορίθμων, το οποίο ανήκει στην ευρύτερη οικογένεια της μηχανικής μάθησης. Ένα μοντέλο βαθιάς μάθησης είναι τα Νευρωνικά Δίκτυα (Neural Networks). Είναι εμπνευσμένα από τη φύση, καθώς χαρακτηριστικό τους είναι ότι προσπαθούν να μιμηθούν τον ανθρώπινο εγκέφαλο. Οι τεχνητοί νευρώνες του δικτύου προσομοιάζουν τη λειτουργία των βιολογικών νευρώνων. Ο όρος «βαθιά» υποδηλώνει ότι τα δίκτυα αποτελούνται από πολλά επίπεδα (layers), που αποτελούνται από αλγορίθμους

και πραγματοποιούν αυτή τη μίμηση. Ο κύριος στόχος της συγκεκριμένης αρχιτεκτονικής είναι η εκμάθηση μιας ιεραρχίας χαρακτηριστικών, στην οποία κάθε επίπεδο επεξεργάζεται την είσοδο και δίνει μια καλύτερη αναπαράσταση των δεδομένων εισόδου στο επόμενο επίπεδο. Όσα περισσότερα είναι τα επίπεδα, τόσο καλύτερη γίνεται η αναπαράσταση.

Τα μοντέλα βαθιάς μάθησης είναι πολύ ελκυστικά, λόγω της ευελιξίας τους για χρήση σε ένα ευρύ φάσμα διαφορετικών προβλημάτων. Είναι σε θέση να μαθαίνουν αυτόματα νέες αναπαραστάσεις χαρακτηριστικών, οι οποίες προηγουμένως σχεδιάζονταν με το χέρι. Έχουν δοκιμαστεί για πολύ καιρό, όμως παλαιότερα δεν σημείωναν επιτυχία. Πιο συγκεκριμένα, η αρχή έγινε το 2006, με τους ερευνητές να έχουν τη δυνατότητα να εκπαιδεύουν βαθύτερα δίκτυα. Εξάριση πριν από αυτό, είναι το Συνελικτικό Νευρωνικό Δίκτυο (Convolutional Neural Network - CNN) που χρησιμοποιήθηκε από το LeCun [35]. Η επιτυχία ήρθε με την πρόσφατη υπέρβαση πολλών προβλημάτων, που εμπόδιζαν την πρόοδο αυτών των τεχνικών το προηγούμενο διάστημα. Μερικά από τα κύρια σημεία της επιτυχίας είναι η δημιουργία τεχνικών βελτιστοποίησης και ο μεγάλος όγκος δεδομένων που είναι διαθέσιμος σε διάφορες μορφές (εικόνες, ήχοι, κείμενα κλπ.). Στο [34], γίνεται αναφορά σε μια ασυνήθιστη νίκη του διαγωνισμού «ImageNet Large Scale Visual Recognition Challenge». Η πρώτη θέση είχε τεράστια διαφορά συγκριτικά με τη δεύτερη, και πιο συγκεκριμένα, 16,4% σφάλμα έναντι του 26,1%. Οι ερευνητές χρησιμοποίησαν ένα βαθύ CNN σε αντίθεση με τους χειροποίητους ανιχνευτές χαρακτηριστικών των υπόλοιπων προσεγγίσεων [35].


Κάποιες από τις κατηγορίες νευρωνικών δικτύων είναι:

- 1) *Συνελικτικά Νευρωνικά Δίκτυα (Convolutional Neural Networks - CNN)*: είναι κατάλληλα για την επεξεργασία δεδομένων με μοτίβο πλέγματος, όπως είναι οι εικόνες. Έχουν σχεδιαστεί, ώστε να μαθαίνουν αυτόματα και προσαρμοστικά χωρικές ιεραρχίες χαρακτηριστικών. Μπορεί να θεωρηθεί ότι χρησιμοποιούν πολλά πανομοιότυπα αντίγραφα του ίδιου νευρώνα. Έτσι, καθίσταται δυνατό για το δίκτυο να χειρίζεται μεγάλα υπολογιστικά μοντέλα διατηρώντας μικρό αριθμό παραμέτρων [13]. Στο Σχήμα 13, παρουσιάζεται η δομή ενός συνελικτικού νευρωνικού δικτύου.




Σχήμα 13: Αναπαράσταση συνελικτικού νευρωνικού δικτύου [36].

- 2) *Αναδρομικά Νευρωνικά Δίκτυα (Recurrent Neural Networks - RNN)*: χαρακτηρίζονται από ανατροφοδοτούμενες εσωτερικές συνδέσεις, δίνοντας τη δυνατότητα για επεξεργασία δεδομένων ακολουθίας. Η έξοδος του δικτύου είναι εξαρτημένη από την προηγούμενη είσοδο και από προηγούμενους υπολογισμούς. Το μοντέλο δημιουργεί ουσιαστικά μια εσωτερική μνήμη, την οποία χρησιμοποιεί για μελλοντικές προβλέψεις [13]. Στο Σχήμα 14, παρουσιάζεται η δομή ενός αναδρομικού νευρωνικού δικτύου.



Σχήμα 14: Αναπαράσταση αναδρομικού νευρωνικού δικτύου [37].

- 3) *Νευρώνες Μακράς Βραχυπρόθεσμης Μνήμης (Long Short Term Memory - LSTM)*: είναι ικανά να αντιμετωπίσουν το πρόβλημα της εξαφάνισης των κλίσεων. Σχεδιάστηκαν με τέτοιο τρόπο, ώστε να αποθηκεύουν πληροφορία για μεγάλα χρονικά διαστήματα, υιοθετώντας μια διαφορετική αρχιτεκτονική συγκριτικά με τα αναδρομικά δίκτυα. Τα RNN έχουν τη μορφή μιας αλυσίδας επαναλαμβανόμενων μονάδων. Αυτή η αλυσίδα έχει μια πολύ απλή δομή. Τα LSTM έχουν επίσης αυτή τη δομή που μοιάζει με αλυσίδα, αλλά με διαφορετική δομή επαναλαμβανόμενης μονάδας. Αντί να υπάρχει ένα μόνο επίπεδο νευρωνικού δικτύου, υπάρχουν τέσσερα, τα οποία αλληλεπιδρούν με έναν ιδιαίτερο τρόπο [38]. Στο Σχήμα 15, παρουσιάζεται η δομή ενός νευρώνα μακράς βραχυπρόθεσμης μνήμης.




Σχήμα 15: Αναπαράσταση νευρώνα μακράς βραχυπρόθεσμης μνήμης [39].

2. Θεωρητικό υπόβαθρο της αρχιτεκτονικής Συνελικτικού Νευρωνικού Δικτύου (Convolutional Neural Network - CNN)

2.1 Τι είναι το CNN και πώς λειτουργεί


Η βαθιά μάθηση είναι μια εφαρμογή τεχνητών νευρωνικών δικτύων με πολλαπλά κρυφά επίπεδα (hidden layers), τα οποία μιμούνται τις λειτουργίες του ανθρώπινου εγκεφάλου. Τα Συνελικτικά Νευρωνικά Δίκτυα (Convolutional Neural Networks - CNN) αποτελούν έναν ισχυρό αλγόριθμο μάθησης, ικανό να χειριστεί εκατομμύρια παραμέτρους, εξοικονομώντας το υπολογιστικό κόστος [40]. Τα CNN έχουν πρωτοποριακά αποτελέσματα την τελευταία δεκαετία, σε μια ποικιλία πεδίων, που σχετίζονται από την επεξεργασία εικόνας, έως και την αναγνώριση φωνής. Το πιο σημαντικό πλεονέκτημά τους είναι ότι τα χαρακτηριστικά τους δεν εξαρτώνται χωρικά. Για παράδειγμα, σε μια εφαρμογή ανίχνευσης προσώπου, δεν απαιτείται να δοθεί προσοχή στο σημείο της φωτογραφίας που βρίσκεται το πρόσωπο. Η ανίχνευση του αντικειμένου θα υλοποιηθεί ανεξάρτητα από τη θέση του. Μια ακόμη σημαντική πτυχή του CNN, είναι η απόκτηση χαρακτηριστικών όσο η είσοδος διαδίδεται προς τα κρυφά επίπεδα. Δηλαδή, στην περίπτωση ανίχνευσης προσώπων, οι ακμές μπορούν να ανιχνευθούν στα πρώτα επίπεδα, τα πιο απλά σχήματα στα δεύτερα επίπεδα και τα χαρακτηριστικά υψηλότερου επιπέδου (π.χ. πρόσωπα) στα τελευταία [41], όπως παρουσιάζεται στο Σχήμα 16.



Σχήμα 16: Παράδειγμα εξαγωγής χαρακτηριστικών από το κάθε επίπεδο σε ένα CNN [41].

Στην εικόνα εισόδου εφαρμόζεται ένα φίλτρο ή «πυρήνας» (kernel), για να παράγει μια καλύτερη έξοδο, που σταδιακά μετά από κάθε επίπεδο γίνεται και πιο λεπτομερής. Το φίλτρο είναι περιττού μεγέθους, ώστε όλα τα εικονοστοιχεία (pixels) του προηγούμενου επιπέδου να είναι συμμετρικά τοποθετημένα γύρω από το εικονοστοιχείο εξόδου, δημιουργώντας απλότητα στην υλοποίηση. Με τη χρήση μικρών μεγεθών, επιτρέπεται στο φίλτρο να υλοποιήσει συνελίξεις με την εικόνα εισόδου, πολλές φορές σε διαφορετικά σημεία. Το μέγεθος 1x1 αποφεύγεται, καθώς θα εξάγει χαρακτηριστικά χωρίς πληροφορίες από τα γειτονικά εικονοστοιχεία. Άρα, η καλύτερη επιλογή για το μέγεθος του φίλτρου είναι η 3x3 [42]. Το βάθος του εξαρτάται από τα κανάλια της εικόνας εισόδου. Για παράδειγμα, σε εικόνα που περιέχει τρία κανάλια Κόκκινο-Πράσινο-Μπλε (Red-Green-Blue - RGB) αντιστοιχεί φίλτρο με βάθος ίσο με τρία. Ο βηματισμός (stride) δηλώνει τον αριθμό των pixels, κατά τον οποίο μετακινείται το φίλτρο πάνω στην εικόνα μετά από κάθε επανάληψη. Όπως φαίνεται στο Σχήμα 17, για βηματισμό ίσο με ένα, το φίλτρο θα μετακινηθεί κατά ένα pixel ανά επανάληψη. Όσο ο βηματισμός μεγαλώνει, το μέγεθος της εικόνας εξόδου μικραίνει. Η εξίσωση (2) δίνει το μέγεθος που προκύπτει, με δεδομένα το μέγεθος της εικόνας εισόδου $N \times N$, το μέγεθος του φίλτρου $F \times F$ και το βηματισμό s . Με αυτόν τον τρόπο, μειώνονται οι παράμετροι ακόμη περισσότερο [41]. Τα φίλτρα γίνονται πιο πολύπλοκα, όσο τα επίπεδα προχωράνε προς την έξοδο. Στο τελευταίο επίπεδο, το CNN είναι πλέον σε θέση να αναγνωρίσει το αντικείμενο που του ζητήθηκε [43].

$$Output_{size} = \left[1 + \frac{N-F}{s}\right] \times \left[1 + \frac{N-F}{s}\right] \quad (2)$$



Σχήμα 17: Για βηματισμό ίσο με ένα, το φίλτρο μετακινείται κατά ένα pixel σε κάθε επανάληψη [41].

Ο όρος «συνελικτικό» σε ένα CNN υποδηλώνει τη μαθηματική πράξη της συνέλιξης, η οποία είναι μια γραμμική διαδικασία, κατά την οποία δύο συναρτήσεις πολλαπλασιάζονται, ώστε να παράγουν μια τρίτη συνάρτηση, η οποία εκφράζει το πώς τροποποιείται το σχήμα της μίας από την άλλη [44]. Με τη συνέλιξη, η εικόνα εισόδου περνά από ένα σύνολο φίλτρων. Κάθε φίλτρο ενεργοποιεί ορισμένα χαρακτηριστικά από την εικόνα και μεταβιβάζει την έξοδό του στο φίλτρο του επόμενου επιπέδου. Κάθε επίπεδο μαθαίνει να αναγνωρίζει διαφορετικά χαρακτηριστικά και οι λειτουργίες καταλήγουν να επαναλαμβάνονται για δεκάδες, εκατοντάδες ή και χιλιάδες επίπεδα. Στο τέλος, όλα τα δεδομένα της εικόνας που εξελίσσονται μέσω των πολλαπλών επιπέδων, επιτρέπουν στο CNN να αναγνωρίσει ολόκληρο το αντικείμενο [43]. Ένα από τα μειονεκτήματα της συνέλιξης, η οποία μειώνει το μέγεθος της εικόνας, είναι ότι δημιουργεί απώλεια ορισμένης πληροφορίας. Αυτό συμβαίνει για δύο λόγους: η εικόνα μικραίνει και δε δίνεται έμφαση στα στοιχεία που βρίσκονται στις γωνίες της. Μια αποτελεσματική και απλή μέθοδος για την επίλυση του προβλήματος είναι η μηδενική-συμπλήρωση (zero-padding). Αυτή η μέθοδος προσθέτει σειρές μηδενικών εξωτερικά από κάθε πλευρά της εικόνας εισόδου. Αν δε χρησιμοποιείται μηδενική-συμπλήρωση, η συνέλιξη ονομάζεται έγκυρη (valid convolution). Αν χρησιμοποιείται μηδενική-συμπλήρωση, έτσι ώστε το μέγεθος της εισόδου να διατηρηθεί και στην έξοδο, η συνέλιξη ονομάζεται ίδια (same convolution). Στο Σχήμα 18, απεικονίζεται η μορφή της εικόνας εισόδου μετά από τη χρήση μηδενικής-συμπλήρωσης, με αριθμό σειρών ίσο με ένα. Η εξίσωση (3) δίνει τον αριθμό των σειρών μηδενικών που πρέπει να προστεθούν, για να είναι η συνέλιξη ίδια, ενώ η (4) δίνει το μέγεθος της εικόνας που προκύπτει με τη χρήση μηδενικής-συμπλήρωσης [41].

$$P = \frac{F-1}{2} \quad (3)$$

$$Output_{size} = \left[1 + \frac{N+2*P-F}{S}\right] \times \left[1 + \frac{N+2*P-F}{S}\right] \quad (4)$$

0	0	0	0	0	0	0	0	0
0								0
0								0
0								0
0								0
0								0
0								0
0								0
0								0
0	0	0	0	0	0	0	0	0

Σχήμα 18: Χρήση μηδενικής-συμπλήρωσης με αριθμό σειρών ίσο με ένα [41].

2.2 Σημαντικές παράμετροι του CNN

Στη βαθιά μάθηση, ένα μοντέλο καθορίζεται από τις παραμέτρους του. Συναντώνται δύο όροι που σχετίζονται με τη μοντελοποίηση ενός CNN: οι παράμετροι (parameters) και οι υπερ-παράμετροι (hyperparameters).

- 1) *Παράμετροι (Parameters)*: μαθαίνονται ή εκτιμώνται από τα δεδομένα, κατά τη διάρκεια της εκπαίδευσης. Μπορούν να αλλάζουν τις τιμές τους στη διάρκεια αυτή, γι' αυτό αποκαλούνται και «εσωτερικές» προς το μοντέλο. Η εκπαίδευση του μοντέλου ξεκινά με την αρχικοποίηση των παραμέτρων σε κάποιες τιμές (τυχαίες ή μηδενικές). Όσο η διαδικασία εξελίσσεται, οι αρχικές τιμές ενημερώνονται μέσω ενός αλγορίθμου βελτιστοποίησης. Στο τέλος, οι παράμετροι που έχουν προκύψει αποτελούν το μοντέλο.
- 2) *Υπερ-παράμετροι (Hyperparameters)*: ελέγχουν τη διαδικασία μάθησης και καθορίζουν τις τιμές των παραμέτρων, που τελικά μαθαίνει ένας αλγόριθμος μάθησης. Το πρόθεμα «υπερ» υποδηλώνει ότι πρόκειται για παραμέτρους ανώτερου επιπέδου. Είναι σημαντικό να επιλέγονται όσο το δυνατόν καλύτερα, αφού επηρεάζουν άμεσα την απόδοση του μοντέλου που θα προκύψει. Η διαδικασία επιλογής τους ονομάζεται «Συντονισμός Υπερ-παραμέτρων» (Hyperparameter Tuning). Οι υπερ-παράμετροι που θα χρησιμοποιήσει ο αλγόριθμος μάθησης επιλέγονται πριν καν ξεκινήσει η εκπαίδευση του μοντέλου, γι' αυτό αποκαλούνται και «εξωτερικές» προς το μοντέλο, καθώς αυτό δε μπορεί να τις αλλάξει κατά τη διάρκεια της εκπαίδευσης. Δεν αποτελούν μέρος του τελικού μοντέλου που προκύπτει. Στο τέλος, που το μοντέλο απαρτίζεται από τις παραμέτρους, δεν είναι εφικτό μέσω αυτών να γίνουν γνωστές οι υπερ-παράμετροι που χρησιμοποιήθηκαν. Συνοπτικά, οποιαδήποτε τιμή που αποφασίζεται πριν την έναρξη της εκπαίδευσης και παραμένει ίδια έως το τέλος της είναι μια υπερ-παράμετρος [45].

Πίνακας 3: Παραδείγματα παραμέτρων και υπερ-παραμέτρων [45].

Παράμετροι	Υπερ-παραμέτροι
Βάρη του νευρωνικού δικτύου (weights)	Ρυθμός μάθησης σε αλγόριθμους βελτιστοποίησης (learning rate)
Κλίσεις του νευρωνικού δικτύου (biases)	Αριθμός κρυφών επιπέδων (hidden layers)
Βάρη (weights) του μοντέλου λογιστικής παλινδρόμησης (logistic regression)	Αριθμός μονάδων ενεργοποίησης σε κάθε επίπεδο (activation units)
	Αριθμός επαναλήψεων στην εκπαίδευση (epochs)
	Μέγεθος φίλτρου στα επίπεδα συνέλιξης

Τα βάρη (weights) και οι κλίσεις (biases) αναπτύσσουν τον τρόπο με τον οποίο το δίκτυο προωθεί τη ροή δεδομένων προς τα εμπρός (forward propagation). Μόλις ολοκληρώνεται η προς τα εμπρός διάδοση, το δίκτυο βελτιώνει τις συνδέσεις των νευρώνων, χρησιμοποιώντας τα σφάλματα που προέκυψαν σε αυτή. Στη συνέχεια, η ροή αντιστρέφεται για να περάσει από τα επίπεδα και να εντοπίσει τις συνδέσεις που απαιτούν προσαρμογή (backward propagation). Τα βάρη σχετίζονται με τη διαχείριση των συνδέσεων μεταξύ δύο βασικών νευρώνων. Για να μπορέσουν οι νευρώνες να εκπαιδευτούν, ώστε να υλοποιήσουν την προς τα εμπρός ροή, τα βάρη τους πρέπει να αυξηθούν ή να μειωθούν. Έπειτα, αυτές οι συνδέσεις θα αντιστραφούν και θα επαναληφθούν, έως ότου παραχθούν τα βέλτιστα αποτελέσματα. Οι κλίσεις είναι νευρώνες, που προστίθενται για να βοηθήσουν στην επιρροή του τελικού αποτελέσματος. Όπως και τα βάρη, ρυθμίζονται μέσω της αντιστροφής ροής. Όταν εμφανίζεται μια κλίση, ενεργοποιεί ένα σήμα και ωθεί τα δεδομένα προς τα εμπρός. Τόσο τα βάρη όσο και οι κλίσεις, διακρίνουν καλύτερα τους νευρώνες και τις συνδέσεις τους, για να δώσουν μια ακριβή έξοδο [46]. Στη συνέχεια, γίνεται μια αναφορά στον αριθμό των παραμέτρων που διαθέτει το κάθε επίπεδο.

- 1) *Επίπεδο εισόδου (Input Layer)*: το επίπεδο αυτό παρέχει απλώς το σχήμα της εικόνας εισόδου και δεν υπάρχουν εκπαιδευόμενες παράμετροι. Άρα, ο αριθμός παραμέτρων είναι ίσος με μηδέν.
- 2) *Επίπεδο συνέλιξης (CONV Layer)*: σε αυτό το επίπεδο, το CNN μαθαίνει, οπότε υπάρχουν πίνακες βαρών (weight matrices) και κλίσεις (bias) για το κάθε φίλτρο. Άρα, ο αριθμός παραμέτρων υπολογίζεται ως ((πλάτος φίλτρου * ύψος φίλτρου * αριθμός φίλτρων στο προηγούμενο επίπεδο) + 1) * αριθμός φίλτρων στο τρέχον επίπεδο).
- 3) *Επίπεδο συγκέντρωσης (POOL Layer)*: αυτό το επίπεδο δεν έχει εκπαιδευόμενες παραμέτρους, γιατί απλώς υλοποιεί έναν υπολογισμό. Άρα, ο αριθμός των παραμέτρων ισούται με μηδέν.
- 4) *Πλήρως συνδεδεμένο επίπεδο (FC Layer)*: αυτό το επίπεδο διαθέτει τον μεγαλύτερο αριθμό παραμέτρων, καθώς κάθε νευρώνας συνδέεται με άλλο νευρώνα. Άρα, ο αριθμός των παραμέτρων υπολογίζεται ως ((νευρώνες του τρέχοντος επιπέδου * νευρώνες του προηγούμενου επιπέδου) + 1 * νευρώνες του τρέχοντος επιπέδου) [47].


2.3 Είδη επιπέδων του CNN

Ένα CNN αποτελείται από τέσσερα είδη επιπέδων: επίπεδο συνέλιξης (convolutional layer), επίπεδο συγκέντρωσης (pooling layer), πλήρως συνδεδεμένο επίπεδο (fully connected layer - FC) και μη-γραμμικό επίπεδο (non-linearity layer). Το επίπεδο συνέλιξης είναι πάντα το πρώτο, ενώ το πλήρως συνδεδεμένο επίπεδο είναι πάντα το τελευταίο. Ενδιάμεσα συναντώνται τα επίπεδα συγκέντρωσης και τα μη-γραμμικά. Από το πρώτο επίπεδο έως το τελευταίο, η πολυπλοκότητα του δικτύου αυξάνεται.

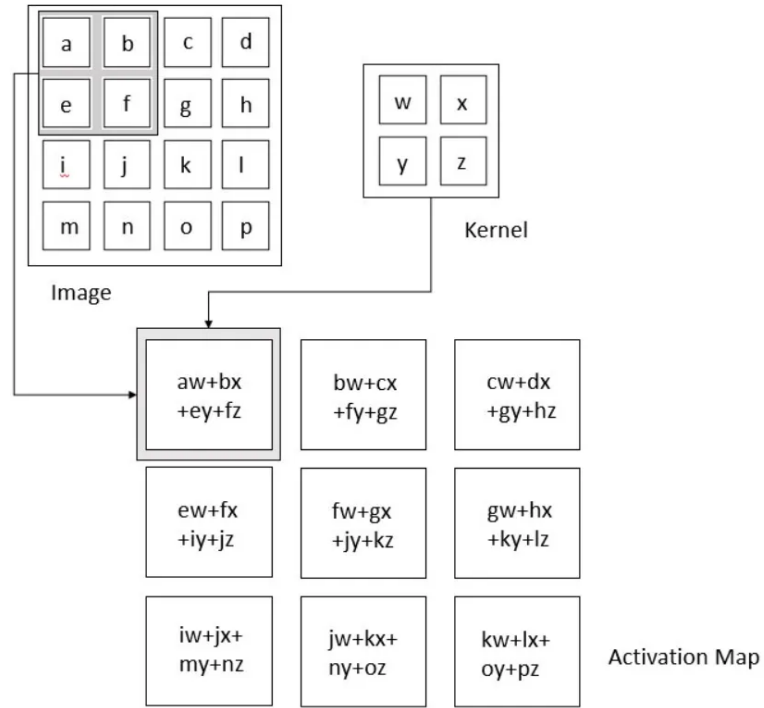
- 1) *Επίπεδο Συνέλιξης (Convolutional Layer)*: αποτελεί το βασικό δομικό στοιχείο ενός CNN. Οι περισσότεροι υπολογισμοί, και πιο συγκεκριμένα η πράξη της συνέλιξης, υλοποιούνται στο επίπεδο αυτό. Μαθηματικά, η πράξη δίνεται από την εξίσωση (5), και σχηματικά αναπαρίσταται στο Σχήμα 20. Μετά από το αρχικό επίπεδο, μπορεί να ακολουθήσει και ένα δεύτερο. Η διαδικασία της συνέλιξης περιλαμβάνει έναν πυρήνα (kernel) ή φίλτρο, το οποίο «μετακινείται» μέσα στην εικόνα ελέγχοντας αν υπάρχει κάποιο χαρακτηριστικό. Έπειτα από πολλές επαναλήψεις, το φίλτρο έχει περάσει από ολόκληρη την εικόνα. Μετά από κάθε επανάληψη υπολογίζεται ένα εσωτερικό γινόμενο μεταξύ των pixels της εικόνας εισόδου και του φίλτρου. Η τελική έξοδος είναι γνωστή ως χάρτης χαρακτηριστικών (feature map) ή χάρτης ενεργοποίησης (activation map) ή συνελκτικό χαρακτηριστικό (convolved feature), και παρέχει πληροφορίες για την εικόνα, όπως είναι οι πλευρές και οι γωνίες. Τελικά, σε αυτό το επίπεδο, η εικόνα μετατρέπεται σε αριθμητικές τιμές, επιτρέποντας στο CNN να την ερμηνεύσει και να εξάγει μοτίβα από αυτήν [43]. Στο Σχήμα 19, απεικονίζεται η μορφή του επιπέδου συνέλιξης. Το φίλτρο διασχίζει την εικόνα και η έξοδος προκύπτει από τα αποτελέσματα της συνέλιξης μεταξύ φίλτρου και εικόνας εισόδου.

$$(f * g)(i) = \sum_{j=1}^m g(i) \cdot f(i - j + m/2) \quad (5)$$

όπου f, g : συναρτήσεις, m : παραδείγματα εκπαίδευσης.




Σχήμα 19: Αναπαράσταση επιπέδου συνέλιξης [49].



Σχήμα 20: Πράξη της συνέλιξης [48].

- 2) *Επίπεδο Συγκέντρωσης (Pooling Layer)*: έπεται από το επίπεδο συνέλιξης, με στόχο να μειώσει το μέγεθος του χάρτη χαρακτηριστικών, ώστε να μειωθεί το υπολογιστικό κόστος. Αυτό πραγματοποιείται με την ελάττωση των συνδέσεων μεταξύ των επιπέδων. Ανάλογα με τη μέθοδο που χρησιμοποιείται, υπάρχουν διάφοροι τύποι επιπέδων συγκέντρωσης. Στο Μέγιστο Επίπεδο Συγκέντρωσης (Max Pooling), λαμβάνεται από το χάρτη χαρακτηριστικών το μέγιστο στοιχείο, ενώ στο Μέσο Επίπεδο Συγκέντρωσης (Average Pooling), υπολογίζεται ο μέσος όρος των στοιχείων [44], όπως φαίνεται στο Σχήμα 21.




Σχήμα 21: Παραδείγματα μέγιστου επιπέδου συγκέντρωσης και μέσου επιπέδου συγκέντρωσης [50].

- 3) *Πλήρως Συνδεδεμένο Επίπεδο (Fully Connected Layer - FC)*: χρησιμοποιείται για τη σύνδεση των νευρώνων δύο επιπέδων. Η εικόνα εισέρχεται στο επίπεδο ως «ισοπεδωμένη» (flattened), δηλαδή οι τιμές των pixels της δημιουργούν ένα διάνυσμα. Σε αυτό το επίπεδο, γίνεται η ταξινόμηση (classification) της εικόνας, με βάση τα χαρακτηριστικά που εξάγονται από τα προηγούμενα επίπεδα. «Πλήρως συνδεδεμένο» σημαίνει ότι όλες οι εισοδοί από ένα επίπεδο συνδέονται με κάθε μονάδα ενεργοποίησης (activation unit) του επόμενου επιπέδου [43]. Ο λόγος για τον οποίο πραγματοποιείται αυτή η σύνδεση, είναι ότι δύο συνδεδεμένα επίπεδα θα αποδώσουν καλύτερα από ότι μόνο ένα [44]. Τα επίπεδα του CNN δεν είναι όλα πλήρως συνδεδεμένα, καθώς αυτό θα οδηγούσε σε ένα περιττά πυκνό δίκτυο, αυξάνοντας τον υπολογιστικό φόρτο και μειώνοντας την ποιότητα της εξόδου [43].
- 4) *Μη-γραμμικά Επίπεδα (Non-Linearity Layers)*: δεδομένου ότι η συνέλιξη είναι μια γραμμική λειτουργία, ενώ οι εικόνες δεν είναι γραμμικές, τα μη-γραμμικά επίπεδα τοποθετούνται αμέσως μετά το στρώμα συνέλιξης, με σκοπό να εισάγουν μη-γραμμικότητα στο χάρτη ενεργοποίησης. Υπάρχουν διάφοροι τύποι μη-γραμμικών επιπέδων με πιο δημοφιλείς τους εξής:

1. *Σιγμοειδής Συνάρτηση (Sigmoid)*: με μαθηματικούς όρους, δίνεται από την εξίσωση (6) και γραφικά, αναπαρίσταται από το Σχήμα 22. Λαμβάνει έναν πραγματικό αριθμό και τον τοποθετεί σε μια περιοχή μεταξύ των τιμών 0 και 1, οι οποίες αποτελούν και τα δύο όριά της, και γι' αυτό, χρησιμοποιείται κυρίως για δυαδικά αποτελέσματα. Μια πολύ ανεπιθύμητη ιδιότητά της είναι ότι όταν η ενεργοποίηση βρίσκεται σε ένα από τα δύο όρια, η κλίση (gradient) γίνεται σχεδόν μηδενική. Όσο η τοπική κλίση μικραίνει, στην αντίστροφη ροή δεδομένων, η κλίση θα εξαφανιστεί και το δίκτυο δε θα μπορεί να εκπαιδευτεί. Επίσης, καθώς τα δεδομένα που εισάγονται στο νευρώνα είναι πάντα θετικά, η έξοδος της συνάρτησης θα είναι ή πάντα θετική ή πάντα αρνητική, οδηγώντας σε μια δυναμική ζιγκ-ζαγκ στις ενημερώσεις των βαρών.


$$\sigma(z) = \frac{1}{1+e^{-z}} \quad (6)$$



Σχήμα 22: Γραφική αναπαράσταση της σιγμοειδούς συνάρτησης [51].

- II. *Υπερβολική Εφαπτομένη (Tanh)*: με μαθηματικούς όρους, δίνεται από την εξίσωση (7) και γραφικά, αναπαρίσταται από το Σχήμα 23. Λαμβάνει έναν πραγματικό αριθμό και τον τοποθετεί σε μια περιοχή μεταξύ των τιμών -1 και 1. Εμφανίζει και αυτή το μειονέκτημα με τη σχεδόν μηδενική κλίση στα δύο όρια. Όμως, η διαφορά της είναι ότι το κέντρο της βρίσκεται στην τιμή 0, και όχι στην τιμή 0,5, και άρα αποφεύγεται το πρόβλημα της ζιγκ-ζαγκ δυναμικής στην ενημέρωση των βαρών.


$$\tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (7)$$



Σχήμα 23: Γραφική αναπαράσταση της υπερβολικής εφαπτομένης [51].

- III. *Διορθωμένη Γραμμική Μονάδα (Rectified Linear Unit – ReLU)*: είναι η πιο συχνά χρησιμοποιούμενη συνάρτηση. Μαθηματικά, προκύπτει από την εξίσωση (8) και γραφικά, αναπαρίσταται από το Σχήμα 24. Δίνει ως έξοδο αναλλοίωτη την τιμή της εισόδου, αν αυτή είναι θετική, αλλιώς δίνει την τιμή μηδέν. Συγκριτικά με τις άλλες δύο συναρτήσεις, είναι η πιο αξιόπιστη. Το μοναδικό μειονέκτημα που παρουσιάζει είναι ότι μπορεί να θεωρηθεί «εύθραυστη» κατά τη διάρκεια της εκπαίδευσης. Μια μεγάλη κλίση μπορεί να την ενημερώσει με τέτοιο τρόπο, ώστε ο νευρώνας να μην μπορεί να ενημερωθεί περαιτέρω. Ωστόσο, αυτό μπορεί να αντιμετωπιστεί με τη χρήση ενός κατάλληλου ρυθμού μάθησης (learning rate) [48].

$$a = \max(0, z) \quad (8)$$




Σχήμα 24: Γραφική αναπαράσταση της ReLU [51].

- IV. *Συνάρτηση Softmax*: αποτελεί μία δημοφιλή συνάρτηση, καθώς αντί για δύο μόνο όρια, και άρα δυαδική ταξινόμηση, μπορεί να περιέχει πολλαπλά όρια. Μαθηματικά, δίνεται από την εξίσωση (9). Συναντάται, συνήθως, στο επίπεδο εξόδου, χρησιμοποιείται σε εφαρμογές με πολλές κλάσεις ως εξόδους (multi-class) και επιστρέφει ως αποτέλεσμα την πιθανότητα κάθε κλάσης [52].


$$softmax(z_i) = \frac{e^{z_i}}{\sum_j e^{z_j}} \quad (9)$$

Στο Σχήμα 25, αναπαρίσταται η δομή ενός συνελκτικού νευρωνικού δικτύου, για την ταξινόμηση εικόνων με οχήματα. Ο αριθμός των επιπέδων ενός δικτύου, εξαιρουμένου του επιπέδου εισόδου, υποδηλώνει το βάθος (depth) του. Όσο πιο πολύπλοκη είναι η εικόνα, τόσο περισσότερα επίπεδα συνέλιξης, ακολουθούμενα από επίπεδα συγκέντρωσης, απαιτούνται. Σχετικά με την αρίθμηση των επιπέδων, πρώτο επίπεδο του δικτύου θεωρείται το πρώτο κρυφό επίπεδο, και όχι το επίπεδο εισόδου.



Σχήμα 25: Αναπαράσταση ενός CNN. Παράδειγμα αναγνώρισης εικόνας με όχημα [48].

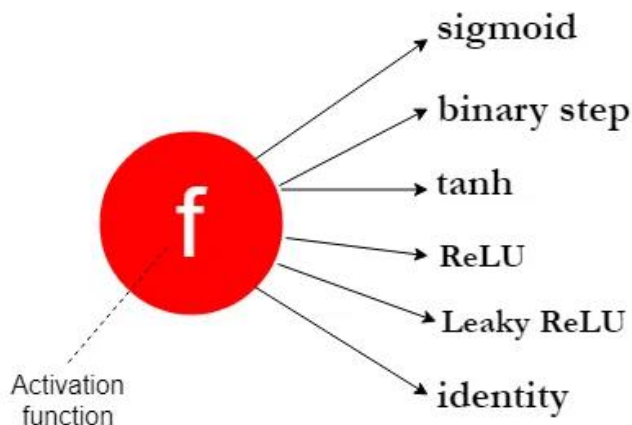
Κάθε επίπεδο αποτελείται από έναν αριθμό νευρώνων. Όπως αποκαλύπτει και το όνομα, η λειτουργία τους είναι παρόμοια με αυτή των ανθρώπινων νευρώνων, δηλαδή δέχονται κάποιες εισόδους και δίνουν μια έξοδο. Σε όρους μηχανικής μάθησης, ο νευρώνας είναι ένας φορέας μιας μαθηματικής συνάρτησης. Παρέχει μια έξοδο εφαρμόζοντας τη συνάρτηση στις εισόδους που του δίνονται [49]. Όπως ένας βιολογικός νευρώνας λαμβάνει σήματα εισόδου από άλλους νευρώνες μέσω δενδριτών, έτσι κι ένας τεχνητός νευρώνας (artificial neuron ή perceptron ή node) λαμβάνει τα δεδομένα από έναν άλλο, μέσω των νευρώνων εισόδου. Τα σημεία σύνδεσης μεταξύ δενδριτών και βιολογικών νευρώνων ονομάζονται συνάψεις, ενώ οι συνδέσεις ανάμεσα σε νευρώνες εισόδου και νευρώνες αποκαλούνται βάρη. Σε ένα βιολογικό νευρώνα, ο πυρήνας παράγει ένα σήμα εξόδου, με βάση τα σήματα που παρέχονται από τους δενδρίτες. Ομοίως, ο πυρήνας του τεχνητού νευρώνα εκτελεί ορισμένους υπολογισμούς, με βάση τις τιμές εισόδου, και παράγει μια έξοδο. Τέλος, στο βιολογικό νευρώνα, το σήμα εξόδου μεταφέρεται μέσω του άξονα. Στον τεχνητό νευρώνα, το ρόλο του άξονα έχει η τιμή εξόδου, που αποτελεί είσοδο για τους επόμενους νευρώνες.



Σχήμα 26: Αριστερά απεικονίζεται ένας βιολογικός νευρώνας και δεξιά ένας τεχνητός [53].

Στο Σχήμα 26, φαίνεται αναλυτικά η δομή και η λειτουργία ενός τεχνητού νευρώνα. Λαμβάνει τις εισόδους x_1, x_2, \dots, x_n , τις πολλαπλασιάζει με τα βάρη w_1, w_2, \dots, w_n και προσθέτει την κλίση b . Έπειτα, υπολογίζει τη γραμμική συνάρτηση z , στην οποία εφαρμόζει μια συνάρτηση ενεργοποίησης (activation function) f , για να προκύψει η έξοδος y . Τα διάφορα είδη συναρτήσεων ενεργοποίησης παρουσιάζονται στο Σχήμα 27. Η γραμμική συνάρτηση αποτελεί το γραμμικό στοιχείο ενός νευρώνα. Η έξοδος της υπολογίζεται από την εξίσωση (10). Τα x είναι εισόδοι και λαμβάνουν αριθμητικές τιμές. Τα w είναι βάρη και παίρνουν επίσης αριθμητικές τιμές, ελέγχοντας τη σημαντικότητα κάθε εισόδου. Όσο υψηλότερη η τιμή του w , τόσο σημαντικότερη η είσοδος. Το b είναι η κλίση, η οποία προστίθεται στο άθροισμα των γινομένων των εισόδων επί των βαρών, ώστε η συνάρτηση ενεργοποίησης να μην μπορεί να πάρει ως είσοδο μηδενική τιμή. Η συνάρτηση ενεργοποίησης αποτελεί το μη-γραμμικό στοιχείο του νευρώνα. Εφαρμόζεται στο z , με σκοπό να βγάλει μια έξοδο με βάση το είδος της συνάρτησης που χρησιμοποιείται [53].

$$z = (w_1 * x_1 + w_2 * x_2 + \dots + w_n * x_n) + b \quad (10)$$



Σχήμα 27: Είδη συναρτήσεων ενεργοποίησης [53].

Η επιλογή της συνάρτησης ενεργοποίησης για τα κρυφά επίπεδα είναι μια απλή διαδικασία και γίνεται με βάση το είδος του δικτύου. Για ένα CNN, επιλέγεται η ReLU, ενώ για ένα RNN, επιλέγεται η Tanh. Η επιλογή της συνάρτησης ενεργοποίησης για το επίπεδο εξόδου ακολουθεί διαφορετικό τρόπο και γίνεται με βάση το είδος του προβλήματος. Αν το πρόβλημα αφορά ταξινόμηση (classification), γίνεται μια επιπλέον κατηγοριοποίηση ανάλογα με το είδος της ταξινόμησης. Για δυαδική, χρησιμοποιείται η σιγμοειδής συνάρτηση. Για ταξινόμηση στην οποία κάθε είσοδος αντιστοιχεί σε μία μόνο έξοδο (multi-class), χρησιμοποιείται η Softmax. Για ταξινόμηση στην οποία κάθε είσοδος μπορεί να αντιστοιχεί σε πολλαπλές εξόδους (multi-label), χρησιμοποιείται η σιγμοειδής συνάρτηση. Αν το πρόβλημα αφορά παλινδρόμηση (regression), επιλέγεται η γραμμική συνάρτηση (linear activation) [54].

2.4 Διαδικασία εκπαίδευσης του νευρωνικού δικτύου

Η εκπαίδευση του νευρωνικού δικτύου, δηλαδή η εκμάθηση των τιμών των παραμέτρων (βάρη και κλίσεις), είναι το πιο κρίσιμο κομμάτι της βαθιάς μάθησης. Αποτελείται από τρία βασικά στάδια: τη διάδοση προς τα εμπρός (forward propagation), τον υπολογισμό της συνάρτησης κόστους (cost function) και τη διάδοση προς τα πίσω (backward propagation). Πρώτη γίνεται η διάδοση προς τα εμπρός, η οποία συμβαίνει όταν στο δίκτυο εισέρχονται δεδομένα εκπαίδευσης. Αυτά το διασχίζουν ολόκληρο, έτσι ώστε να υπολογιστούν οι προβλέψεις των ετικετών τους. Όσο τα δεδομένα περνάνε μέσα από τους νευρώνες, αυτοί εφαρμόζουν το μετασχηματισμό τους και τα στέλνουν στους νευρώνες του επόμενου επιπέδου. Όταν τα δεδομένα έχουν περάσει από όλα τα επίπεδα και όλοι οι νευρώνες έχουν υλοποιήσει τους υπολογισμούς τους, στο τελικό επίπεδο θα προκύψει το αποτέλεσμα της πρόβλεψης των ετικετών των εν λόγω παραδειγμάτων εισόδου.

Στη συνέχεια, χρησιμοποιείται η συνάρτηση κόστους, για να υπολογιστεί το σφάλμα και δηλαδή, να εκτιμηθεί το πόσο καλό ή κακό ήταν το αποτέλεσμα της πρόβλεψης συγκριτικά με το σωστό αποτέλεσμα. Σε αυτό το σημείο, χρειάζεται να σημειωθεί ότι το περιβάλλον μάθησης είναι εποπτευόμενο και άρα, υπάρχουν οι σωστές ετικέτες με τις αναμενόμενες τιμές. Ιδανικά, είναι επιθυμητό ένα μηδενικό κόστος, δηλαδή να μην εμφανίζεται απόκλιση μεταξύ εκτιμώμενης και αναμενόμενης τιμής. Κατά τη διάρκεια που το μοντέλο εκπαιδεύεται, τα βάρη προσαρμόζονται σταδιακά, με σκοπό να προκύψουν καλές προβλέψεις. Κάποιες από τις συναρτήσεις κόστους αναφέρονται στον Πίνακα 4.

Πίνακας 4: Συναρτήσεις κόστους [55].

$J(w, b) = \frac{1}{m} \sum_{i=1}^m a_i - y_i $	Mean Absolute Error για παλινδρόμηση
$J(w, b) = -\frac{1}{m} \sum_{i=1}^m [y_i * \log(a_i) + (1 - y_i) * \log(1 - a_i)]$	Binary Cross Entropy για δυαδική ταξινόμηση
$J(w, b) = -\sum_{j=0}^M \sum_{i=0}^N (y_{ij} * \log(a_{ij}))$	Categorical Cross Entropy για ταξινόμηση πολλαπλών κλάσεων


με m : αριθμός των παραδειγμάτων για εκπαίδευση (training examples), a : αναμενόμενο αποτέλεσμα, y : αποτέλεσμα πρόβλεψης, M : αριθμός προβλέψεων, N : αριθμός νευρώνων στο επίπεδο εξόδου

Μόλις υπολογιστεί το σφάλμα, η πληροφορία αυτή διαδίδεται προς τα πίσω. Ξεκινώντας από το επίπεδο της εξόδου, η πληροφορία του σφάλματος διαδίδεται σε όλους τους νευρώνες που συνέβαλλαν στο αποτέλεσμα της πρόβλεψης. Ωστόσο, κάθε νευρώνας λαμβάνει μόνο ένα τμήμα του σήματος για το σφάλμα, με βάση τη συμβολή του στην πρόβλεψη. Πλέον, μπορούν να ανανεωθούν τα βάρη και να επαναληφθεί η διαδικασία, έως ότου το σφάλμα να έχει τιμή κοντινή στο μηδέν. Για την αλλαγή των βαρών, χρησιμοποιείται μια τεχνική που αποκαλείται «Βαθμιαία Κάθοδος» (Gradient Descent). Σκοπός της μεθόδου αυτής είναι μέσω βημάτων να εντοπίσει το ολικό ελάχιστο, για το οποίο η συνάρτηση κόστους εμφανίζει τη χαμηλότερη τιμή [51]. Για να γίνει αυτό, απαιτούνται δύο στοιχεία που σχετίζονται με τα βήματα της μεθόδου: κατεύθυνση και ρυθμός μάθησης (learning rate ή α). Η κατεύθυνση μπορεί να βρεθεί με τη βοήθεια του υπολογισμού της παραγώγου, ή κλίσης, στο σημείο που βρίσκεται η τεχνική. Για την επίτευξη του ελαχίστου, η κίνηση γίνεται προς την αντίθετη κατεύθυνση από αυτή της κλίσης, όπως φαίνεται στο Σχήμα 28. Ο ρυθμός μάθησης υποδηλώνει το μέγεθος των βημάτων που γίνονται για την εύρεση του ολικού ελαχίστου. Πρόκειται συνήθως για μια μικρή τιμή, που ενημερώνεται με βάση τη συμπεριφορά της συνάρτησης απώλειας. Υψηλοί ρυθμοί μάθησης οδηγούν σε μεγαλύτερα βήματα, με

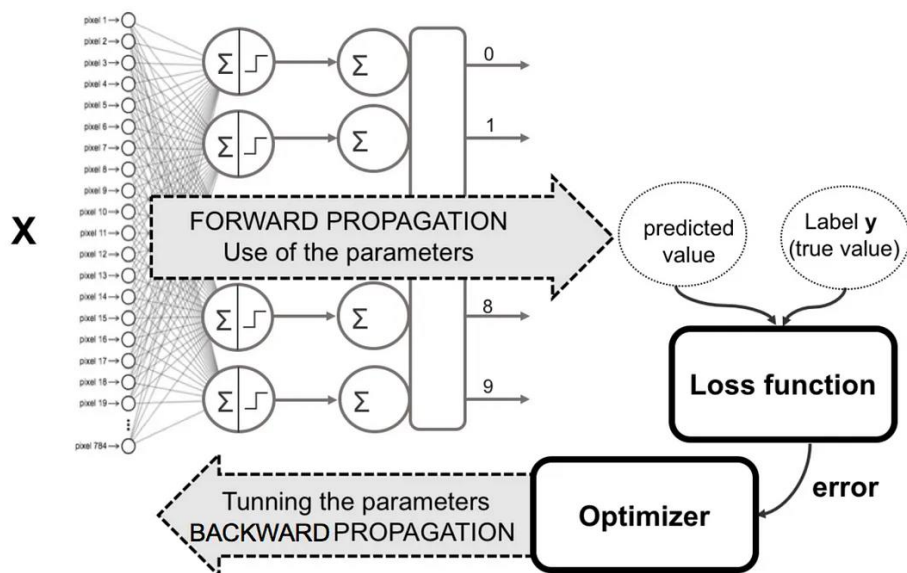
κίνδυνο την υπέρβαση του ελαχίστου. Αντίθετα, χαμηλός ρυθμός μάθησης οδηγεί σε μικρά βήματα, με αποτέλεσμα μεγαλύτερη ακρίβεια, όμως και περισσότερο υπολογιστικό χρόνο [56]. Οι παράμετροι αλλάζουν με βάση τις μαθηματικές εξισώσεις (11) και (12). Συνοπτικά, η συνολική διαδικασία της εκπαίδευσης παρουσιάζεται στο Σχήμα 29.

$$w = w - \alpha * \frac{dJ(w,b)}{w} \quad (11)$$

$$b = b - \alpha * \frac{dJ(w,b)}{db} \quad (12)$$



Σχήμα 28: Βαθμιαία Κάθοδος [57].



Σχήμα 29: Διαδικασία εκπαίδευσης του δικτύου [51].

2.5 Βελτιστοποίηση (Optimization)

Οι βελτιστοποιητές (optimizers) είναι αλγόριθμοι ή μέθοδοι που χρησιμοποιούνται για την ενημέρωση των παραμέτρων του δικτύου, όπως τα βάρη και ο ρυθμός μάθησης, με στόχο τη μείωση των απωλειών και την εξαγωγή αποτελεσμάτων με μεγαλύτερη ακρίβεια. Στη συνέχεια, αναφέρονται κάποιοι από τους πιο δημοφιλείς βελτιστοποιητές.

- 1) *Βαθμιαία Κάθοδος (Gradient Descent)*: είναι ο πιο συχνά χρησιμοποιούμενος αλγόριθμος βελτιστοποίησης, ο οποίος χρησιμοποιείται και από τη διάδοση δεδομένων προς τα πίσω. Ο αλγόριθμος αυτός εξαρτάται από την παράγωγο πρώτης τάξης της συνάρτησης κόστους. Υπολογίζει τον τρόπο με τον οποίο πρέπει να μεταβληθούν τα βάρη, ώστε η συνάρτηση κόστους να φτάσει στην ελάχιστη τιμή της. Μαθηματικά, δίνεται από την εξίσωση (13).

$$\vartheta = \vartheta - \alpha \cdot \nabla J(\vartheta) \quad (13)$$

- 2) *Στοχαστική Βαθμιαία Κάθοδος (Stochastic Gradient Descent)*: πρόκειται για παραλλαγή του αλγόριθμου βαθμιαίας καθόδου, με τη διαφορά ότι ενημερώνει τις παραμέτρους πιο συχνά, μετά από τον υπολογισμό της απώλειας κάθε παραδείγματος εκπαίδευσης. Έτσι, για χίλια παραδείγματα, οι παράμετροι ενημερώνονται χίλιες φορές, και όχι μόνο μία όπως στην προηγούμενη μέθοδο. Μαθηματικά, δίνεται από την εξίσωση (14), όπου $x(i)$, $y(i)$ τα παραδείγματα εκπαίδευσης.

$$\vartheta = \vartheta - \alpha \cdot \nabla J(\vartheta; x(i); y(i)) \quad (14)$$

- 3) *Mini-Batch Gradient Descent*: είναι ο καλύτερος αλγόριθμος μεταξύ όλων των παραλλαγών του αλγόριθμου βαθμιαίας καθόδου. Τα δεδομένα χωρίζονται σε μικρότερα τμήματα και ο αλγόριθμος ενημερώνει τις παραμέτρους μετά από κάθε τμήμα. Μαθηματικά, δίνεται από την εξίσωση (15), όπου $B(i)$ τα τμήματα των παραδειγμάτων εκπαίδευσης.

$$\vartheta = \vartheta - \alpha \cdot \nabla J(\vartheta; B(i)) \quad (15)$$

- 4) *«Ορμή» (Momentum)*: επινοήθηκε για τη μείωση της υψηλής διακύμανσης και ομαλοποιεί την ενημέρωση των παραμέτρων. Χρησιμοποιεί μια υπερ-παράμετρο, γνωστή ως «ορμή», που συμβολίζεται με γ και συνήθως έχει τιμή ίση με 0,9. Μαθηματικά, δίνεται από την εξίσωση (16) και οι παράμετροι ενημερώνονται με βάση την (17).

$$V(t) = \gamma \cdot V(t-1) + \alpha \cdot \nabla J(\vartheta) \quad (16)$$

$$\vartheta = \vartheta - V(t) \quad (17)$$

- 5) *Adam*: αποτελεί συντομογραφία του Adaptive Moment Estimation. Λειτουργεί με «ορμές» πρώτης και δεύτερης τάξης. Η βασική ιδέα του αλγορίθμου είναι ότι πρέπει να μειωθεί λίγο η

ταχύτητα, για μια πιο προσεκτική αναζήτηση του ελάχιστου κόστους. Υπολογίζει το μέσο όρο προηγούμενων κλίσεων και το αποθηκεύει στη μεταβλητή m_t , όπως φαίνεται στην εξίσωση (18), όπου το β_1 είναι ίσο με 0,9. Έπειτα, υπολογίζει το μέσο όρο των τετραγώνων των προηγούμενων κλίσεων και το αποθηκεύει στη μεταβλητή U_t , όπως φαίνεται στην εξίσωση (19), όπου το β_2 είναι ίσο με 0,999. Τελικά, οι παράμετροι ανανεώνονται με βάση την εξίσωση (20), όπου το ϵ είναι ίσο με $10 \cdot e^{-8}$ και το α είναι ίσο με το ρυθμό μάθησης [58].


$$\widehat{m}_t = \frac{m_t}{1 - (\beta_1)t} \quad (18)$$

$$\widehat{U}_t = \frac{U_t}{1 - (\beta_2)t} \quad (19)$$

$$\theta_{t+1} = \theta_t - \alpha * \frac{\widehat{m}_t}{\sqrt{\widehat{U}_t + \epsilon}} \quad (20)$$

2.6 Κανονικοποίηση (Regularization)


Είναι μια τεχνική που χρησιμοποιείται για την αποφυγή της υπερ-προσαρμογής και τη βελτίωση της απόδοσης του μοντέλου. Περιλαμβάνει την προσθήκη ενός όρου «ποινής» στη συνάρτηση κόστους, κατά τη διάρκεια της εκπαίδευσης. Αυτή η «ποινή» αποθαρρύνει το μοντέλο να γίνει υπερβολικά πολύπλοκο ή να δώσει μεγάλες τιμές στις παραμέτρους του, γεγονός που βοηθά στον έλεγχο της ικανότητάς του να προσαρμόζεται στο θόρυβο υποβάθρου. Στο Σχήμα 30, απεικονίζεται η κατάλληλη προσαρμογή δεδομένων, συγκριτικά με την υπερ-προσαρμογή, η οποία γίνεται εύκολα αντιληπτή από την πολυπλοκότητα που παρουσιάζει.



Σχήμα 30: Αριστερά απεικονίζεται η κατάλληλη προσαρμογή δεδομένων, ενώ δεξιά η υπερ-προσαρμογή [59].

- 1) *Dropout*: μία από τις πιο ενδιαφέρουσες τεχνικές κανονικοποίησης. Παράγει πολύ καλά αποτελέσματα και είναι η πιο συχνά χρησιμοποιούμενη τεχνική στον τομέα της βαθιάς μάθησης.

Σε κάθε επανάληψη, επιλέγει τυχαία κάποιους νευρώνες και τους αφαιρεί, μαζί με όλες τις εισερχόμενες και εξερχόμενες συνδέσεις τους, όπως φαίνεται στο Σχήμα 31. Έτσι, σε κάθε επανάληψη, υπάρχει ένα διαφορετικό σύνολο εξόδων. Το μοντέλο που προκύπτει αποδίδει καλύτερα, καθώς περιέχει περισσότερα τυχαία συμβάντα. Η πιθανότητα επιλογής των νευρώνων που θα αφαιρεθούν αποτελεί μια υπερ-παράμετρο. Η τεχνική μπορεί να εφαρμοστεί και στα κρυφά επίπεδα, αλλά και στα επίπεδα εισόδου. Για το λόγο αυτό, χρησιμοποιείται συνήθως όταν η δομή του δικτύου είναι μεγάλη.



Σχήμα 31: Αριστερά απεικονίζεται το δίκτυο πριν τη χρήση του dropout, ενώ δεξιά μετά τη χρήση του [59].


- 2) *Ενίσχυση Δεδομένων (Data Augmentation)*: ο πιο απλός τρόπος για τη μείωση της υπερπροσαρμογής είναι η αύξηση του μεγέθους των δεδομένων εκπαίδευσης. Στη μηχανική μάθηση, αυτό δε μπορεί να συμβεί, καθώς δεν είμαστε σε θέση να αυξήσουμε το μέγεθος των δεδομένων εκπαίδευσης, γιατί είναι πολύ δαπανηρά. Στην περίπτωση, όμως, της βαθιάς μάθησης, που τα δεδομένα είναι εικόνες, υπάρχουν τρόποι αύξησης του μεγέθους των δεδομένων εκπαίδευσης, όπως η περιστροφή της εικόνας, η αναστροφή, η κλιμάκωση, η μετατόπιση κλπ. Στο Σχήμα 32, έχει εφαρμοστεί η τεχνική αύξησης δεδομένων στο σύνολο δεδομένων των χειρόγραφων ψηφίων. Η αύξηση αυτή παρέχει μεγάλη βελτίωση στην ακρίβεια του μοντέλου [59].



Σχήμα 32: Διάφοροι τρόποι αύξησης δεδομένων [59].


2.7 Δημοφιλείς αρχιτεκτονικές CNN

- 1) *LeNet*: το εισήγαγε ο Yan LeCun [41] για αναγνώριση χειρόγραφων ψηφίων. Περιλαμβάνει πέντε επίπεδα συνέλιξης και ένα πλήρως συνδεδεμένο. Συνολικά, περιλαμβάνει 60.000 παραμέτρους. Στο Σχήμα 33, αναπαρίσταται η δομή ενός δικτύου αρχιτεκτονικής LeNet.




Σχήμα 33: Αρχιτεκτονική LeNet [41].

- 2) *AlexNet*: περιέχει πέντε επίπεδα συνέλιξης και δύο πλήρως συνδεδεμένα. Μετά από το πρώτο, δεύτερο και πέμπτο επίπεδο, είναι τοποθετημένο ένα επίπεδο μέγιστης συγκέντρωσης. Μοιάζει με το LeNet, αλλά είναι πολύ μεγαλύτερο. Συνολικά, διαθέτει 650.000 νευρώνες, 60.000.000 παραμέτρους και 630.000.000 συνδέσεις. Ήταν η αρχιτεκτονική που απέδειξε ότι η βαθιά μάθηση είναι αποτελεσματική στην υπολογιστική όραση (computer vision) [41]. Στο Σχήμα 34, αναπαρίσταται η δομή ενός δικτύου αρχιτεκτονικής AlexNet.




Σχήμα 34: Αρχιτεκτονική AlexNet [41].

- 3) *VGG-16*: είναι μια βελτιωμένη έκδοση του AlexNet, στην οποία αντί για φίλτρα μεγάλου μεγέθους, τοποθετούνται διαδοχικά πολλά φίλτρα μικρού μεγέθους. Το δίκτυο έχει 41 επίπεδα. Υπάρχουν 13 επίπεδα συνέλιξης και 3 πλήρως συνδεδεμένα επίπεδα. Επιτυγχάνει ακρίβεια με ποσοστό ίσο με 92,3% [60]. Στο Σχήμα 35, αναπαρίσταται η δομή ενός δικτύου αρχιτεκτονικής VGG-16.



Σχήμα 35: Αρχιτεκτονική VGG-16 [60].

- 4) *ResNet-50*: συντομογραφία του Residual Network. Είναι ένα κλασικό νευρωνικό δίκτυο, που χρησιμοποιείται για πολλές εφαρμογές υπολογιστικής όρασης. Έχει βάθος 50 επιπέδων. Η κύρια καινοτομία του είναι η παράλειψη, με την οποία η αρχική είσοδος προστίθεται στην έξοδο του μπλοκ παράλειψης, όπως απεικονίζεται στο Σχήμα 36 [61].



Σχήμα 36: Μπλοκ παράλειψης της αρχιτεκτονικής ResNet-50 [61].

3. Ανάπτυξη του μοντέλου ενός Συνελικτικού Νευρωνικού Δικτύου

3.1 Προεπεξεργασία δεδομένων εισόδου

Για να προκύψουν οι εικόνες εισόδου για το νευρωνικό δίκτυο, προηγήθηκε η ολοκλήρωση μιας διαφορετικής διαδικασίας, η οποία παρουσιάζεται συνοπτικά στο Σχήμα 37. Αρχικά, επιλέγεται μια δημόσια βάση δεδομένων (στην παρούσα εργασία η PLAID). Η PLAID (Plug-Load Appliance Identification Dataset) απαρτίζεται από μετρήσεις τάσης και ρεύματος διαφόρων οικιακών ηλεκτρικών συσκευών, με δειγματοληψία στα 30 kHz. Οι μετρήσεις αφορούν παρακολουθήσεις συσκευών είτε μεμονωμένα, είτε σε ταυτόχρονη λειτουργία (καινοτομία της έκδοσης του 2018). Επιπλέον, παρακολουθούνται και τα συμβάντα (events) που χαρακτηρίζονται από ενεργοποιήσεις και απενεργοποιήσεις συσκευών. Συνολικά, περιέχει 17 διαφορετικούς τύπους συσκευών που μετρώνται σε 65 διαφορετικές τοποθεσίες,


για τη συλλογή των υπο-μετρούμενων δεδομένων και στη συνέχεια, 13 από αυτούς μετρώνται σε μία μόνο τοποθεσία, για τη συλλογή των συγκεντρωτικών δεδομένων. Εφόσον η PLAID παρέχει τα μέσα για την ανίχνευση συμβάντων και την αναγνώριση φορτίων, συνιστά μια καλή επιλογή για εφαρμογές NILM. Ταυτόχρονα, διακρίνεται για την υψηλή δειγματοληψία των υπο-μετρούμενων και συγκεντρωτικών δεδομένων της [63].

Από την PLAID, πάρθηκαν οι χρονοσειρές του ρεύματος, είτε για μεμονωμένη λειτουργία συσκευών, είτε για ταυτόχρονη λειτουργία, είτε για μεταβάσεις, δηλαδή ενεργοποιήσεις/απενεργοποιήσεις. Στις χρονοσειρές αυτές, εφαρμόστηκε αλγόριθμος Fourier (FFT), ανά περίοδο ίση με 60 Hz (η περίοδος του ρεύματος). Ο μετασχηματισμός Fourier εμφάνισε το αρμονικό περιεχόμενο στο επίπεδο της συχνότητας. Καταγράφηκε η θεμελιώδης (1^η) αρμονική και από τις ανώτερες, οι 3^η και 5^η αρμονικές. Στη συνέχεια, εφαρμόστηκε αντίστροφος μετασχηματισμός Fourier, ώστε από το επίπεδο της συχνότητας, να γίνει μεταφορά στο επίπεδο του χρόνου. Από τις τρεις αρμονικές που προέκυψαν, υπολογίστηκαν οι τιμές μέσης τετραγωνικής ρίζας (root mean square – RMS), ανά 500 δείγματα, ώστε οι τιμές που θα προκύψουν να είναι ανά δευτερόλεπτο. Τέλος, υπολογίστηκαν τα ποσοστά μερικής παραμόρφωσης, σύμφωνα με τις εξισώσεις (21) και (22). Οι εικόνες σχηματίστηκαν ως γραφικές παραστάσεις (plots) των δύο αυτών ποσοστών, με το ποσοστό παραμόρφωσης της 3^{ης} αρμονικής να βρίσκεται στον οριζόντιο άξονα x και το ποσοστό παραμόρφωσης της 5^{ης} αρμονικής να βρίσκεται στον κάθετο άξονα y. Η διαδικασία επαναλαμβάνεται για 575 φορές, όσα είναι και τα διαθέσιμα sets που παρέχει η PLAID. Σε κάθε set, εμφανίζονται διαφορετικές συσκευές, έτσι ώστε να καλύπτεται ένα μεγάλο εύρος διαφορετικών συνδυασμών. Ένα παράδειγμα ενός set παρουσιάζεται στο Σχήμα 39, με συσκευές τις: φορητός υπολογιστής, λαμπτήρας φθορισμού, σίδηρο, πρέσα μαλλιών. Άρα, στο τέλος, προκύπτουν 575 φάκελοι με 10, 15, 20 ή 25 εικόνες, ανάλογα με τη διάρκεια του κάθε set. Για παράδειγμα, διάρκεια μετρήσεων ίση με 20 δευτερόλεπτα σημαίνει εξαγωγή 20 διαφορετικών εικόνων.

$$\%HD3 = \frac{HD3}{HD1} \quad (21)$$


$$\%HD5 = \frac{HD5}{HD1} \quad (22)$$

όπου $HD1$ η 1^η αρμονική, $HD3$ η 3^η αρμονική και $HD5$ η 5^η αρμονική.

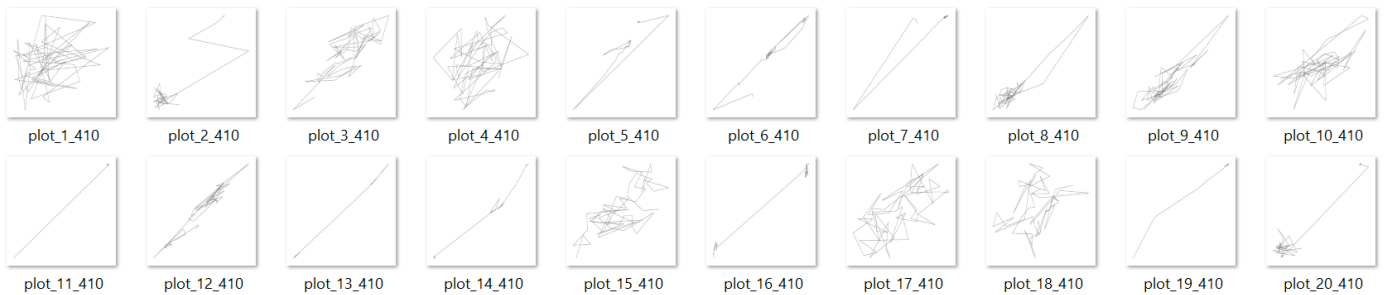


Σχήμα 37: Σχηματική αναπαράσταση της διαδικασίας δημιουργίας των εικόνων εισόδου.

Τα plots που δημιουργήθηκαν είχαν αρχικές διαστάσεις 1548 x 1168, άρα ήταν ορθογωνίου σχήματος. Για μεγαλύτερη ευκολία, στο νευρωνικό δίκτυο, προτιμάται η χρήση τετράγωνων εικόνων. Οπότε, στη συνέχεια, όλες οι εικόνες μετατράπηκαν σε τετράγωνα, με τελικές διαστάσεις 1548 x 1548, με τη βοήθεια ενός κώδικα σε γλώσσα python. Επίσης, πρέπει να σημειωθεί, ότι οι εικόνες παρουσιάζουν αποχρώσεις του γκρι χρώματος, δηλαδή αποχρώσεις μεταξύ άσπρου και μαύρου χρώματος, και άρα, είναι grayscale (ένα κανάλι). Το Σχήμα 38 αποτελεί ένα παράδειγμα μιας εικόνας εισόδου. Στη συγκεκριμένη, απεικονίζεται η μεμονωμένη λειτουργία του ανεμιστήρα.



Σχήμα 38: Παράδειγμα εικόνας εισόδου. Απεικονίζεται η μεμονωμένη λειτουργία του ανεμιστήρα.



Σχήμα 39: Το set νούμερο 410 με τις εικόνες που περιέχει (συσκευές: φορητός υπολογιστής, λαμπτήρας φθορισμού, σίδερο, πρέσα μαλλιών). Κάθε εικόνα αντιπροσωπεύει ένα δευτερόλεπτο.

Τελευταία διαδικασία που ακολουθήθηκε στο στάδιο της προεπεξεργασίας των δεδομένων, είναι η προσθήκη ετικετών (labeling) στα δεδομένα. Η επισήμανση των δεδομένων είναι ο τρόπος αναγνώρισής τους, ώστε να διευκρινιστεί το περιεχόμενό τους, επιτρέποντας στο νευρωνικό δίκτυο να κάνει προβλέψεις με μεγαλύτερη ακρίβεια. Οι ετικέτες προσδίδουν ουσιαστικά μια ταυτότητα σε κάθε εικόνα, και παρέχουν πληροφορίες σχετικά με αυτή. Εκπαιδεύοντας το μοντέλο μηχανικής μάθησης με δεδομένα που έχουν ετικέτες, γίνεται ευκολότερα και πιο σωστά η διαδικασία της πρόβλεψης. Σε

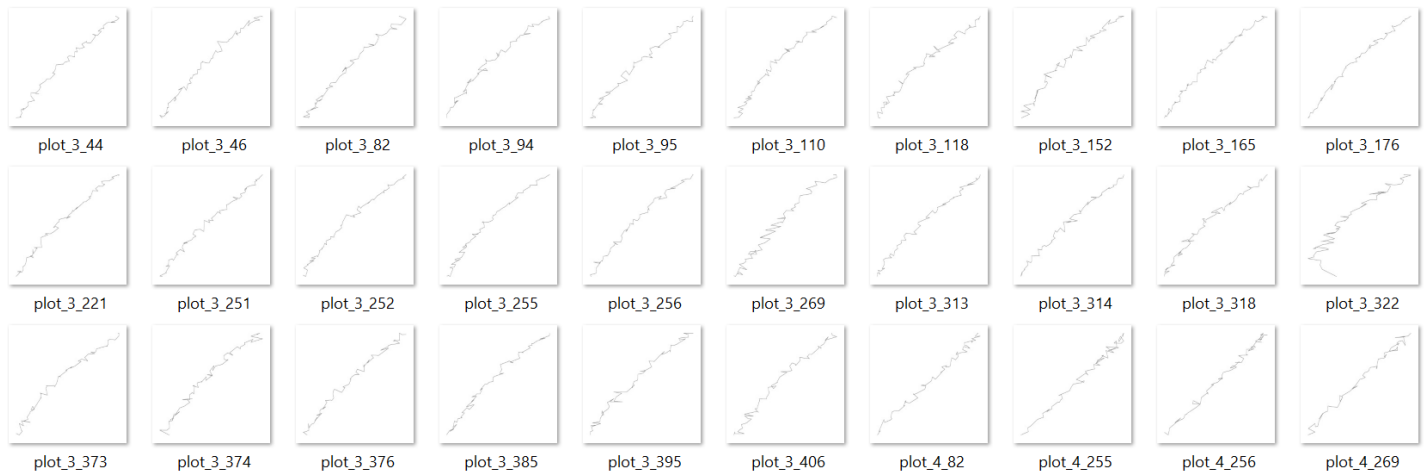
αντίθετη περίπτωση, αν είχαμε εισαγάγει στο μοντέλο έναν όγκο ακατέργαστων δεδομένων, το αποτέλεσμα θα ήταν βεβιασμένο και συνεπώς, ανακριβές. Το labeling είναι απαραίτητο στη μάθηση που γίνεται εποπτευόμενα. Πλέον, τα περισσότερα μοντέλα υιοθετούν τη μέθοδο της εποπτευόμενης μάθησης, αντιστοιχίζοντας μία είσοδο σε μία έξοδο, και κάνοντας προβλέψεις για την αντιστοίχιση αυτή. Η διαδικασία γίνεται με ανθρώπινη συμμετοχή (human-in-the-loop – HITL), όπου οι χρήστες καλούνται να κρίνουν τα δεδομένα και να τους προσδώσουν ετικέτες. Αν και αποτελεί μια χρονοβόρα -για το χρήστη- διαδικασία, που απαιτεί ιδιαίτερη προσοχή, καθώς είναι επιρρεπής σε ανθρώπινα σφάλματα, είναι ένα από τα πιο κρίσιμα βήματα της δημιουργίας ενός μοντέλου μηχανικής μάθησης, και φέρει το πολύ σημαντικό πλεονέκτημα της μεγάλης ακρίβειας [62]. Στην παρούσα εργασία, ήταν εφικτό με τη βοήθεια της PLAID, να είναι γνωστοί, σε κάθε set (Σχήμα 40), οι αριθμοί δειγμάτων που οι συσκευές του set αυτού ενεργοποιήθηκαν και απενεργοποιήθηκαν, όπως φαίνεται στο Σχήμα 41. Αυτοί οι αριθμοί, αντιστοιχούν σε χρονικές στιγμές. Γνωρίζοντας ότι το ένα δευτερόλεπτο έχει 30.000 δείγματα (αφού η συχνότητα δειγματοληψίας είναι 30kHz), διαιρούμε τον αριθμό του on/off με το 30.000 και βρίσκουμε το αντίστοιχο δευτερόλεπτο ενεργοποίησης/απενεργοποίησης. Εφόσον έχουμε τις χρονικές στιγμές των on/off κάθε συσκευής, μπορούμε να γνωρίζουμε τι γίνεται ανά δευτερόλεπτο. Έτσι, δημιουργήθηκαν φάκελοι, με ονομασίες τις διαφορετικές λειτουργίες ή μεταβάσεις που συναντήθηκαν, και κάθε εικόνα (που αντιστοιχεί σε κάθε δευτερόλεπτο) μεταφερόταν στον αντίστοιχο φάκελο, με βάση το είδος λειτουργίας που απεικονίζε. Στο Σχήμα 42, δίνεται ως παράδειγμα ο φάκελος που προέκυψε για τη μεμονωμένη λειτουργία του ανεμιστήρα.

Index	Type	Size	Value
0	dict	11	{'brand': 'Lasko cyclone', 'current': '1.1 A', 'load': 'I', 'manufacture_ ...
1	dict	11	{'brand': 'Dirt Devil', 'current': '10A', 'load': 'I', 'manufacture_year' ...

Σχήμα 40: Στο πρώτο set εμφανίζονται δύο συσκευές: ανεμιστήρας και σκούπα.

Key	Type	Size	Value
manufacture_year	str	0	
model_number	str	0	
notes	str	0	
off	str	8	[204316]
on	str	7	[37043]
type	str	3	Fan
voltage	str	4	120V
wattage	str	0	

Σχήμα 41: Αν ανοίξει η καρτέλα της κάθε συσκευής, γίνονται ορατοί οι αριθμοί on/off της.



Σχήμα 42: Κατά τη διαδικασία του labeling, προέκυψε ο φάκελος «Fan», ο οποίος περιέχει εικόνες από όλα τα sets, που αντιστοιχούν στη μεμονωμένη λειτουργία του ανεμιστήρα.

3.2 Σχεδιασμός του μοντέλου

Τα νευρωνικά δίκτυα έχουν χρησιμοποιηθεί σε διάφορες εφαρμογές. Αναφέρονται ενδεικτικά οι: πρόγνωση σεισμικών φαινομένων, υπολογιστική όραση, ασφάλεια στο διαδίκτυο. Στην παρούσα εργασία, παρουσιάζεται η περίπτωση της επίλυσης προβλημάτων μη-παρεμβατικής παρακολούθησης φορτίου. Πιο συγκεκριμένα, υλοποιείται μια προσπάθεια για αναγνώριση και ταξινόμηση δεδομένων, που σχετίζονται με τη λειτουργία οικιακών ηλεκτρικών συσκευών, μέσω της εκπαίδευσης ενός συνελκτικού νευρωνικού δικτύου. Τα δεδομένα ανήκουν σε κλάσεις, οι οποίες προέκυψαν από τη διαδικασία του labeling και κατηγοριοποιούνται σε: μεμονωμένη λειτουργία συσκευών, ταυτόχρονη λειτουργία συσκευών και μεταβάσεις, δηλαδή ενεργοποίηση/απενεργοποίηση συσκευών. Για την ταυτόχρονη λειτουργία, δημιουργούνται συνδυασμοί μεταξύ δύο, τριών ή τεσσάρων τυχαίων συσκευών, καλύπτοντας ένα μεγάλο φάσμα διαφορετικών επιλογών. Στο πείραμα της εργασίας, θα χρησιμοποιούνται σε κάθε σενάριο τέσσερις από αυτές τις κλάσεις. Πριν εισαχθούν τα δεδομένα στο μοντέλο, με τη βοήθεια ενός κώδικα σε γλώσσα python, ανακατατάσσονται μέσα στους φακέλους τους, ώστε στη συνέχεια, να μοιραστούν τυχαία στους φακέλους του training και testing, με αποτέλεσμα μια αποδοτικότερη εκπαίδευση. Ο διαχωρισμός γίνεται με τη μέθοδο 80 – 20, δηλαδή, το 80% των εικόνων τοποθετείται στον πρώτο φάκελο, ενώ το 20% στο δεύτερο. Ακολουθήθηκε αυτή η μέθοδος, καθώς ο όγκος των εικόνων είναι μικρός και έπρεπε να είναι περισσότερο εκμεταλλεύσιμος στο κομμάτι της εκπαίδευσης. Στη συνέχεια, αναφέρονται αναλυτικά τα σενάρια που έχουν δημιουργηθεί. Τα Σχήματα 43-62 παρουσιάζουν τις εικόνες των συσκευών που απαρτίζουν κάθε σενάριο.


- 1) Μεμονωμένες λειτουργίες φορητού υπολογιστή (laptop) (53 εικόνες) και πρέσας μαλλιών (hair iron) (59 εικόνες).
 Ταυτόχρονη λειτουργία ψυγείου (fridge) και πρέσας μαλλιών (32 εικόνες).
 Μεταβατική λειτουργία ενεργοποίησης του κλιματιστικού (none to air conditioner) (39 εικόνες).



Σχήμα 43: Παραδείγματα εικόνων για ταυτόχρονη λειτουργία ψυγείου και πρέσας μαλλιών.



Σχήμα 44: Παραδείγματα εικόνων για μεμονωμένη λειτουργία πρέσας μαλλιών.



Σχήμα 45: Παραδείγματα εικόνων για μεμονωμένη λειτουργία φορητού υπολογιστή.



Σχήμα 46: Παραδείγματα εικόνων για ενεργοποίηση του κλιματιστικού.


- 2) Μεμονωμένες λειτουργίες φορητού υπολογιστή (53 εικόνες) και κλιματιστικού (81 εικόνες).
Ταυτόχρονη λειτουργία φορητού υπολογιστή και κλιματιστικού (16 εικόνες).
Μεταβατική λειτουργία ενεργοποίησης του κλιματιστικού (39 εικόνες).



Σχήμα 47: Παραδείγματα εικόνων για ταυτόχρονη λειτουργία φορητού υπολογιστή και κλιματιστικού.



Σχήμα 48: Παραδείγματα εικόνων για μεμονωμένη λειτουργία κλιματιστικού.



Σχήμα 49: Παραδείγματα εικόνων για μεμονωμένη λειτουργία φορητού υπολογιστή.



Σχήμα 50: Παραδείγματα εικόνων για ενεργοποίηση του κλιματιστικού.

- 3) Μεμονωμένη λειτουργία κλιματιστικού (81 εικόνες).
- Ταυτόχρονη λειτουργία φορητού υπολογιστή και κλιματιστικού (16 εικόνες).
- Μεταβατικές λειτουργίες ενεργοποίησης (39 εικόνες) και απενεργοποίησης του κλιματιστικού (air conditioner to none) (37 εικόνες).



Σχήμα 51: Παραδείγματα εικόνων για ταυτόχρονη λειτουργία φορητού υπολογιστή και κλιματιστικού.



Σχήμα 52: Παραδείγματα εικόνων για μεμονωμένη λειτουργία κλιματιστικού.




Σχήμα 53: Παραδείγματα εικόνων για απενεργοποίηση του κλιματιστικού.



Σχήμα 54: Παραδείγματα εικόνων για ενεργοποίηση του κλιματιστικού.

- 4) Μεμονωμένες λειτουργίες φορητού υπολογιστή (53 εικόνες), πρέσας μαλλιών (59 εικόνες) και ανεμιστήρα (fan) (52 εικόνες).
Μεταβατική λειτουργία ενεργοποίησης του κλιματιστικού (39 εικόνες).



Σχήμα 55: Παραδείγματα εικόνων για μεμονωμένη λειτουργία φορητού υπολογιστή.



Σχήμα 56: Παραδείγματα εικόνων για μεμονωμένη λειτουργία κλιματιστικού.




Σχήμα 57: Παραδείγματα εικόνων για απενεργοποίηση του κλιματιστικού.



Σχήμα 58: Παραδείγματα εικόνων για μεμονωμένη λειτουργία πρέσας μαλλιών.

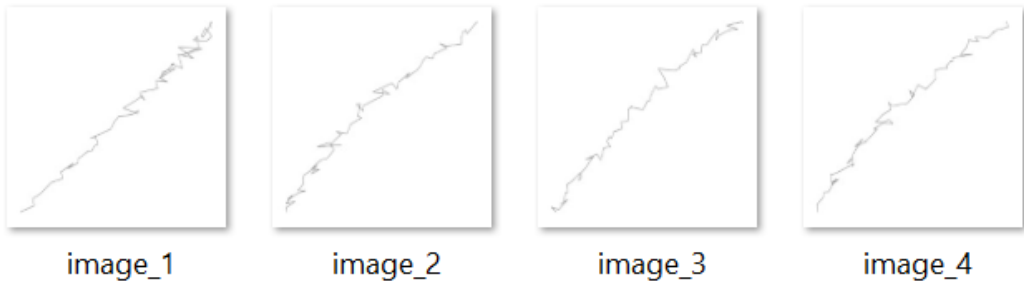
- 5) Μεμονωμένες λειτουργίες φορητού υπολογιστή (53 εικόνες), ψυγείου (107 εικόνες), ανεμιστήρα (52 εικόνες) και μηχανισμού απόψυξης ψυγείου (defroster) (75 εικόνες).



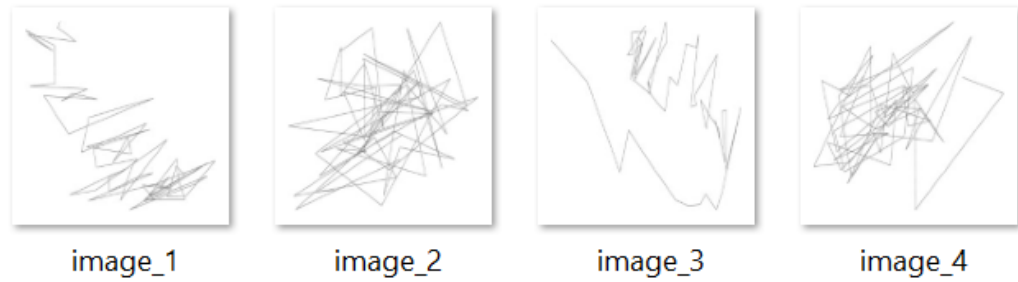
Σχήμα 59: Παραδείγματα εικόνων για μεμονωμένη λειτουργία φορητού υπολογιστή.



Σχήμα 60: Παραδείγματα εικόνων για μεμονωμένη λειτουργία ψυγείου.



Σχήμα 61: Παραδείγματα εικόνων για μεμονωμένη λειτουργία ανεμιστήρα.




Σχήμα 62: Παραδείγματα εικόνων για μεμονωμένη λειτουργία μηχανισμού απόψυξης ψυγείου.

Για να καθίσταται δυνατή η ακριβής μέτρηση της απόδοσης του μοντέλου, καθώς και η βελτίωση αυτής, η εκπαίδευση γίνεται εποπτευόμενα. Επιλέγεται μια γνωστή βάση δεδομένων, ώστε οι εικόνες να μπορούν να ταξινομηθούν στις κλάσεις σωστά και στη συνέχεια, να συγκριθούν με τις κλάσεις που θα προβλέψει το δίκτυο. Για την εφαρμογή του NILM, όπως έχει ήδη αναφερθεί, έχει επιλεγεί η βάση δεδομένων PLAID (Plug-Load Appliance Identification Dataset) στην έκδοση του 2018.

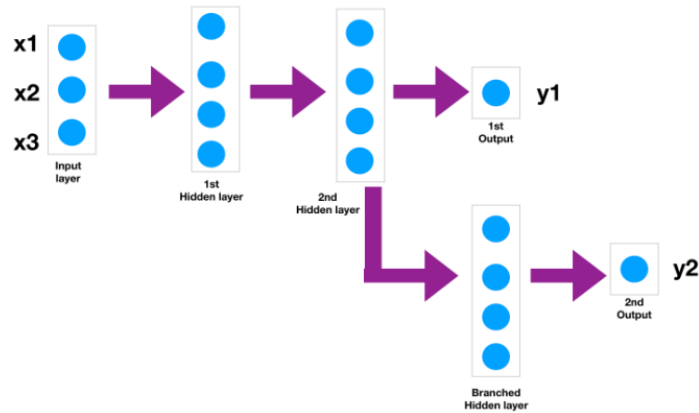
Για ένα σωστό σχεδιασμό ενός δικτύου, το σημαντικότερο βήμα είναι ο καθορισμός της αρχιτεκτονικής του μοντέλου, με βάση το είδος του προβλήματος. Στην παρούσα εργασία, επιλέγεται ως αρχιτεκτονική αυτή του συνελκτικού νευρωνικού δικτύου, καθώς το πρόβλημα αφορά την ταξινόμηση εικόνων. Παράλληλα, το παρόν πρόβλημα της μη-παρεμβατικής παρακολούθησης φορτίου απαιτεί ένα μοντέλο, στο οποίο κάθε εικόνα εισόδου αντιστοιχεί σε μία μόνο κλάση εξόδου (multi-class). Για να διευκολυνθεί η δημιουργία του δικτύου, χρησιμοποιείται μία -ανοιχτή στο κοινό- πλατφόρμα μηχανικής μάθησης (framework), ανεπτυγμένη από τη Google, η TensorFlow [64]. Η συγκεκριμένη πλατφόρμα διαθέτει μια υψηλού-επιπέδου διεπαφή προγραμματισμού εφαρμογών (application programming interface - API), γραμμένη σε γλώσσα python, την Keras. Τα πλεονεκτήματά της είναι ότι δημιουργήθηκε με τέτοιο τρόπο, ώστε να είναι απλή και εύκολα κατανοητή από τους χρήστες, καθώς και ότι μπορεί να υποστηρίξει τα περισσότερα μοντέλα δικτύων [65]. Η Keras διαθέτει δύο τρόπους για το σχεδιασμό ενός νευρωνικού δικτύου. Στο πρόβλημα που παρουσιάζεται, χρησιμοποιείται ο πρώτος τρόπος, διότι δεν απαιτείται κοινή χρήση των επιπέδων και δεν υπολογίζονται ταυτόχρονα διαφορετικές έξοδοι. Ωστόσο, στη συνέχεια, γίνεται μια αναφορά και στους δύο διαθέσιμους τρόπους.

- 1) *Ακολουθητική API (Sequential API)*: το μοντέλο χτίζεται ανά επίπεδο. Είναι πολύ εύκολη στην υλοποίησή της, όμως δεν επιτρέπει την κοινή χρήση επιπέδων και την ύπαρξη πολλαπλών εισόδων ή/και εξόδων. Στο Σχήμα 63, απεικονίζεται η δομή της ακολουθητικής διεπαφής.




Σχήμα 63: Sequential API [66].

- 2) *Λειτουργική API (Functional API)*: είναι πιο ευέλικτος τρόπος από ότι ο πρώτος. Θεωρείται μια πιο δυναμική προσέγγιση, καθώς επιτρέπει την κοινή χρήση επιπέδων και την ύπαρξη πολλαπλών εισόδων ή/και εξόδων. Μπορεί να χρησιμοποιηθεί σε πιο πολύπλοκα δίκτυα. Στο Σχήμα 64, απεικονίζεται η δομή της λειτουργικής API. Όπως γίνεται φανερό, επιτρέπεται η πρόβλεψη δύο εξόδων (y_1 , y_2) ταυτόχρονα από το ίδιο δίκτυο. Αντίθετα, στην περίπτωση της ακολουθητικής διεπαφής, θα ήταν απαραίτητη η δημιουργία δύο διαφορετικών δικτύων [66].



Σχήμα 64: Functional API [66].

Εφόσον έχουμε καταλήξει στην αρχιτεκτονική του μοντέλου, ξεκινάει η διαδικασία του «χτισίματός» του. Πρώτο βήμα είναι η «φόρτωση» (load) των δεδομένων εκπαίδευσης. Οι πραγματικές διαστάσεις των εικόνων είναι αρκετά μεγάλες, γεγονός που θα καθυστερεί το νευρωνικό δίκτυο και θα απαιτεί μεγάλη χωρητικότητα μνήμης. Για το λόγο αυτό, ανασχηματίζονται και οι τελικές διαστάσεις τους θα μετατραπούν σε 224 x 224. Γενικά, οι διαστάσεις πρέπει να μην είναι πολύ μικρές, καθώς θα χαθεί πληροφορία, αλλά ούτε και πολύ μεγάλες, καθώς θα απαιτείται μεγαλύτερος υπολογιστικός χρόνος και καλύτερος εξοπλισμός. Ωστόσο, η επιλογή διαστάσεων δεν επηρεάζει την απόδοση του μοντέλου σε σημαντικό βαθμό. Ένας ακόμη παράγοντας που επηρεάζει τον υπολογιστικό φόρτο, είναι η παράμετρος μεγέθους ομάδας (batch size), η οποία δηλώνει τον αριθμό των εικόνων που χρησιμοποιούνται για την εκπαίδευση στο forward/backward propagation. Συνήθως, επιλέγεται ίσο με 32, και γενικά προτιμάται να έχει μικρή τιμή (64, 32, 16, 8). Στο δίκτυο που αναπτύχθηκε, το batch size επιλέχθηκε ίσο με 16, γιατί σε αυτήν την τιμή παρουσίαζε το μοντέλο την καλύτερη απόδοση. Έπειτα, οι μικρότερες, πλέον, εικόνες υπόκεινται σε ανασχηματισμό (reshape), όπου μετατρέπονται σε διανύσματα διαστάσεων (224 x 224, 1), με τιμές τις τιμές των pixels τους. Ακολουθεί η τυποποίηση (standardize), η οποία είναι πρακτικά μια διαίρεση με το 255, δηλαδή με τον μέγιστο αριθμό pixels, εφόσον τα δεδομένα είναι εικόνες. Σκοπός της, είναι οι τιμές των διανυσμάτων να μετατραπούν σε μικρότερες τιμές, μεταξύ του μηδενός και του ένα, ώστε οι υπολογισμοί να υλοποιούνται ευκολότερα, σε μικρότερο χρόνο [67]. Συνοπτικά, η διαδικασία της επεξεργασίας των δεδομένων από το μοντέλο, απεικονίζεται στο Σχήμα 65.



Σχήμα 65: Σχηματική αναπαράσταση της επεξεργασίας των δεδομένων.

Επόμενο βήμα είναι η επιλογή των επιπέδων. Όπως αναφέρθηκε και στο δεύτερο κεφάλαιο, τα επίπεδα από τα οποία αποτελείται ένα μοντέλο συνελκτικού νευρωνικού δικτύου, σε σειρά με την οποία τοποθετούνται, είναι τα: επίπεδο συνέλιξης, επίπεδο συγκέντρωσης, επίπεδο «ισοπέδωσης» και πλήρως συνδεδεμένο επίπεδο. Στο σημείο αυτό, πρέπει να γίνει μια υπενθύμιση, σχετικά με το ότι το επίπεδο εισόδου δεν αναφέρεται, καθώς θεωρείται το επίπεδο «μηδέν». Ο χρήστης καλείται να αποφασίσει πόσα επίπεδα θα χρησιμοποιήσει για το μοντέλο του. Το συγκεκριμένο δίκτυο, όπως φαίνεται και στο Σχήμα 66, αποτελείται από επτά επίπεδα: δύο επίπεδα συνέλιξης, δύο επίπεδα συγκέντρωσης, ένα επίπεδο «ισοπέδωσης» και δύο πλήρως συνδεδεμένα επίπεδα. Η επιλογή των περισσότερων επιπέδων προσθέτει βελτίωση στην απόδοση του μοντέλου. Πιο αναλυτικά:

- 1) *Επίπεδο εισόδου*: αναμένει τα διανύσματα που αντιπροσωπεύουν τις grayscale εικόνες, μεγέθους (224,224,1).
- 2) *Convolutional layer 1*: αυτό το επίπεδο έχει 32 φίλτρα μεγέθους 3 x 3 και εφαρμόζει τη ReLU συνάρτηση ενεργοποίησης. Το μέγεθος των χαρτών χαρακτηριστικών που εξάγονται είναι (224, 224, 32). Οι διαστάσεις έχουν διατηρηθεί, εφόσον χρησιμοποιείται same padding.
- 3) *MaxPooling layer 1*: εκτελεί max pooling με μέγεθος ίσο με 2 x 2, μειώνοντας τις διαστάσεις των εξόδων του. Το μέγεθος pooling επιλέχθηκε ίσο με 2 x 2, ύστερα από δοκιμές, καθώς σημείωσε την καλύτερη απόδοση, όπως και το είδος (max έναντι average). Το μέγεθος των χαρτών χαρακτηριστικών που εξάγονται είναι (112, 112, 32), δηλαδή οι διαστάσεις έχουν διαιρεθεί με το μέγεθος του pooling.
- 4) *Convolutional layer 2*: αυτό το επίπεδο έχει 64 φίλτρα μεγέθους 3 x 3 και εφαρμόζει τη ReLU συνάρτηση ενεργοποίησης. Το μέγεθος των χαρτών χαρακτηριστικών που εξάγονται είναι (112, 112, 64). Οι διαστάσεις έχουν διατηρηθεί, εφόσον χρησιμοποιείται same padding.
- 5) *MaxPooling layer 2*: εκτελεί max pooling με μέγεθος ίσο με 2 x 2, μειώνοντας ακόμη περισσότερο τις διαστάσεις των εξόδων του. Το μέγεθος των χαρτών χαρακτηριστικών που εξάγονται είναι (56, 56, 64), δηλαδή οι διαστάσεις έχουν διαιρεθεί με το μέγεθος του pooling.
- 6) *Flatten layer*: αυτό το επίπεδο μετατρέπει την τρισδιάστατη έξοδο του προηγούμενου επιπέδου, σε μονοδιάστατο διάνυσμα, προετοιμάζοντάς το για τα fully connected layers. Δεν επηρεάζει τις διαστάσεις, απλώς κάνει την μετατροπή σε διάνυσμα.
- 7) *Fully connected layer 1*: διαθέτει 128 νευρώνες και εφαρμόζει τη ReLU συνάρτηση ενεργοποίησης. Το επίπεδο αυτό χρησιμοποιείται για την εισαγωγή μη-γραμμικότητας, μέσω της συνάρτησης ενεργοποίησης, και για την εκμάθηση χαρακτηριστικών υψηλότερου επιπέδου. Η τιμή των νευρώνων αποτελεί μια υπερ-παράμετρο και ρυθμίζεται με βάση την πολυπλοκότητα του δικτύου.
- 8) *Fully connected layer 2*: διαθέτει τέσσερις νευρώνες και εφαρμόζει τη Softmax συνάρτηση ενεργοποίησης, ώστε να προκύψει η πρόβλεψη της κλάσης. Ο αριθμός των νευρώνων, εδώ,


είναι ίσος με τον αριθμό των κλάσεων. Η συνάρτηση ενεργοποίησης κανονικοποιεί (normalize) τις τιμές εξόδου σε μια κατανομή πιθανότητας μεταξύ των κλάσεων, επιλέγοντας στο μοντέλο να κάνει τις προβλέψεις επιλέγοντας την κλάση με την υψηλότερη πιθανότητα.

Τελευταίο βήμα για την ολοκλήρωση του μοντέλου, είναι οι επιλογές για τις παραμέτρους, υπερ-παραμέτρους και συναρτήσεις ενεργοποίησης, με στόχο την επίτευξη της καλύτερης δυνατής απόδοσης. Ύστερα από διάφορες δοκιμές, εξηγούνται οι τιμές που χρησιμοποιήθηκαν, με στόχο την εύρεση μιας «χρυσής τομής» μεταξύ υψηλής απόδοσης και χαμηλής πολυπλοκότητας. Αναφορικά με το φίλτρο που χρησιμοποιήθηκε στα επίπεδα συνέλιξης, επιλέχθηκε ίσο με 3×3 , γιατί, όπως εξηγήθηκε στο δεύτερο κεφάλαιο, είναι η ιδανική επιλογή. Στην πραγματικότητα, το ακριβές μέγεθος του φίλτρου είναι $3 \times 3 \times 1$, και ο αριθμός «ένα» αναφέρεται στο μοναδικό κανάλι του grayscale. Το μέγεθος του φίλτρου εξαρτάται από παράγοντες, όπως η πολυπλοκότητα των δεδομένων και το επιθυμητό επίπεδο εξαγωγής χαρακτηριστικών. Ένα μικρό φίλτρο μπορεί να αποτυπώσει καλύτερα τις μικρές λεπτομέρειες. Οι αριθμοί των φίλτρων στα δύο επίπεδα συνέλιξης είναι 32 και 64, αντίστοιχα. Ο αριθμός των φίλτρων καθορίζει το βάθος των χαρτών χαρακτηριστικών της εξόδου σε κάθε επίπεδο. Η αύξηση των φίλτρων μπορεί να επιτρέψει στο δίκτυο να μάθει πιο σύνθετα χαρακτηριστικά. Ωστόσο, ταυτόχρονα αυξάνεται και η πολυπλοκότητα, και κατά συνέπεια οι απαιτήσεις σε μνήμη. Ο αριθμός των φίλτρων είναι μεγαλύτερος στο δεύτερο επίπεδο συνέλιξης, καθώς σε εκείνο γίνεται η εκμάθηση των χαρακτηριστικών υψηλότερου επιπέδου.

Στα επίπεδα συνέλιξης, έχει χρησιμοποιηθεί και padding, με στόχο την αποτροπή απώλειας πληροφορίας από τις άκρες της εικόνας εισόδου. Πιο συγκεκριμένα, στο μοντέλο προστέθηκε same padding, ώστε οι διαστάσεις της εισόδου να διατηρηθούν και στην έξοδο. Ως συναρτήσεις ενεργοποίησης, χρησιμοποιήθηκαν οι: ReLU και Softmax. Η πρώτη επιλέχθηκε λόγω της υψηλής απόδοσης που προσδίδει στο μοντέλο, συγκριτικά με τις υπόλοιπες διαθέσιμες συναρτήσεις. Η ReLU εξάγει την τιμή εισόδου, αν είναι θετική, ή την τιμή μηδέν, αν είναι αρνητική. Αυτή η απλότητα συμβάλλει σε ταχύτερους χρόνους εξαγωγής συμπερασμάτων. Ταυτόχρονα, ενεργοποιεί αραιά τους νευρώνες, αναγκάζοντάς τους να είναι πιο επιλεκτικοί στις ενεργοποιήσεις τους, ενθαρρύνοντας το δίκτυο να μάθει ποικίλες αναπαραστάσεις. Ένα ακόμη σημαντικό πλεονέκτημά της είναι η συμβολή της στον μετριασμό του προβλήματος της εξαφανιζόμενης κλίσης, που μπορεί να εμφανιστεί κατά τη διάδοση προς τα πίσω. Θέτοντας τις αρνητικές τιμές σε μηδέν, αποτρέπει η μεγάλη μείωση της κλίσης. Από την άλλη, η Softmax επιλέχθηκε, διότι το μοντέλο είναι multi-class.

Ο αριθμός των επαναλήψεων του μοντέλου (epochs) ανήκει στις υπερ-παραμέτρους και διαφέρει ανάλογα με τη βάση δεδομένων που χρησιμοποιείται και την πολυπλοκότητα του μοντέλου. Μια επανάληψη αναφέρεται σε ένα ολοκληρωμένο «πέρασμα» όλου του set εκπαίδευσης, με στόχο την αλλαγή των παραμέτρων για επίτευξη καλύτερης απόδοσης. Οι επαναλήψεις μπορούν να αυξηθούν σε περίπτωση που το μοντέλο δεν παρουσιάζει πρόοδο στην απόδοσή του με το πέρασμα των επαναλήψεων, και άρα κρίνεται αναγκαία η περαιτέρω εκπαίδευση. Στο μοντέλο της εργασίας, παρατηρήθηκε ότι στα σενάρια που υπάρχει ταυτόχρονη λειτουργία συσκευών, η βέλτιστη απόδοση δίνεται για αριθμό επαναλήψεων ίσο με 15, ενώ στα σενάρια που υπάρχει μεμονωμένη λειτουργία, για αριθμό ίσο με 10. Επαναλήψεις ίσες με 16 και 11, αντίστοιχα, οδηγούσαν το μοντέλο σε υπερ-προσαρμογή (overfitting). Σε αυτό το σημείο, έχουν ολοκληρωθεί τα βήματα για τη δημιουργία του

μοντέλου και μπορεί να αξιολογηθεί η απόδοσή του. Αν αυτή δεν είναι ικανοποιητική, συνεχίζονται οι δοκιμές στα διάφορα μεγέθη που αναφέρθηκαν.



Σχήμα 66: Σχηματική αναπαράσταση του μοντέλου συνελκτικού νευρωνικού δικτύου της παρούσας εργασίας.

3.3 Αποτελέσματα μοντέλου

Όταν το μοντέλο έχει ολοκληρωθεί, είναι έτοιμο προς αξιολόγηση. Για την αξιολόγησή του, σημειώνονται σε κάθε επανάληψη κάποια μεγέθη, που υποδηλώνουν την απόδοση. Τα μεγέθη, αυτά, παρουσιάζονται συνοπτικά στο Σχήμα 67. Η απόδοση θα πρέπει να εμφανίζει μια πρόοδο στην πάροδο των επαναλήψεων. Αν δε συμβαίνει αυτό, σημαίνει ότι το μοντέλο απαιτεί αλλαγές στις παραμέτρους, υπερ-παραμέτρους ή/και στα επίπεδα. Τα μεγέθη που λαμβάνονται υπόψη είναι τα εξής:

- 1) *Απώλεια (Loss)*: δηλώνει τη διαφορά μεταξύ πραγματικής και προβλεπόμενης τιμής εξόδου. Διακρίνεται σε απώλεια εκπαίδευσης (training loss) και απώλεια επικύρωσης (validation loss). Η διαφορά τους είναι ότι η πρώτη αναφέρεται στην προσαρμογή του μοντέλου στα δεδομένα εκπαίδευσης που του έχουν δοθεί, ενώ η δεύτερη αναφέρεται στην προσαρμογή του μοντέλου σε αθέατα, καινούρια δεδομένα, δηλαδή στο test set. Οι τιμές των απωλειών πρέπει να είναι όσο το δυνατόν χαμηλότερες. Στο συγκεκριμένο πείραμα, για τον υπολογισμό της απώλειας, χρησιμοποιείται η συνάρτηση κόστους «Κατηγορική διασταυρούμενη εντροπία» (Categorical Cross Entropy). Η συνάρτηση αυτή χρησιμοποιείται για multi-class ταξινόμηση και δίνεται από την εξίσωση (23). Να σημειωθεί, επίσης, ότι χρησιμοποιείται ο αλγόριθμος βελτιστοποίησης «Adam», για την ελαχιστοποίηση της απώλειας.

$$Loss = -\sum_x p(x) * \log(q(x)) \quad (23)$$

όπου x : αριθμός των κλάσεων (στο συγκεκριμένο πείραμα είναι ίσο με 4), $p(x)$: η πραγματική τιμή, $q(x)$: η προβλεπόμενη τιμή.

2) *Πίνακας αληθείας (Truth table)*: είναι μια ανάλυση όλων των πιθανών τιμών που μπορούν να επιστραφούν από το νευρωνικό δίκτυο. Βασίζονται στην Boolean λογική και χρησιμοποιούνται για να παρουσιάσουν τα πιθανά αποτελέσματα του δικτύου ως προς την αλήθεια ή το ψεύδος. Ισχύει ότι ένα αποτέλεσμα κρίνεται «θετικό» (positive), όταν έχει αναγνωρισθεί σωστά, ενώ κρίνεται «αρνητικό» (negative), όταν δεν ανήκει στην κλάση στην οποία ταξινομήθηκε από το δίκτυο. Πιο συγκεκριμένα, διακρίνονται τέσσερις κατηγορίες, οι: Αληθές Θετικό (True Positive - TP), Ψευδές Θετικό (False Positive - FP), Αληθές Αρνητικό (True Negative - TN) και Ψευδές Αρνητικό (False Negative - FN).

I. *Αληθές Θετικό*: το αντικείμενο προς αναγνώριση υπάρχει στην εικόνα και βρέθηκε σε αυτή από το νευρωνικό δίκτυο.

Πίνακας 5: Παράδειγμα αληθούς θετικού αποτελέσματος.

Πρόβλεψη	Πραγματική τιμή	Κατηγορία
Laptop	Laptop	True Positive

II. *Ψευδές Θετικό*: το αντικείμενο προς αναγνώριση δεν υπάρχει στην εικόνα, αλλά βρέθηκε σε αυτή από το νευρωνικό δίκτυο.

Πίνακας 6: Παράδειγμα ψευδούς θετικού αποτελέσματος.

Πρόβλεψη	Πραγματική τιμή	Κατηγορία
Laptop	No Laptop	False Positive

III. *Αληθές Αρνητικό*: το αντικείμενο προς αναγνώριση δεν υπάρχει στην εικόνα και δε βρέθηκε σε αυτή από το νευρωνικό δίκτυο.

Πίνακας 7: Παράδειγμα αληθούς αρνητικού αποτελέσματος.

Πρόβλεψη	Πραγματική τιμή	Κατηγορία
No Laptop	No Laptop	True Negative

IV. *Ψευδές Αρνητικό*: το αντικείμενο προς αναγνώριση υπάρχει στην εικόνα, αλλά δε βρέθηκε σε αυτή από το νευρωνικό δίκτυο [68].

Πίνακας 8: Παράδειγμα αληθούς αρνητικού αποτελέσματος.

Πρόβλεψη	Πραγματική τιμή	Κατηγορία
No Laptop	Laptop	False Negative

3) *Ακρίβεια (Accuracy)*: είναι το ποσοστό των σωστά ταξινομημένων δειγμάτων επί του συνολικού αριθμού δειγμάτων. Διακρίνεται, και αυτή, σε ακρίβεια εκπαίδευσης και ακρίβεια επικύρωσης, με βάση τη διαφορά που προαναφέρθηκε στο (1). Οι τιμές της ακρίβειας πρέπει να είναι όσο το δυνατόν υψηλότερες. Υπολογίζεται από την εξίσωση (24) [68].

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (24)$$

- 4) *Ανάκληση (Recall)*: δηλώνει πόσες θετικές περιπτώσεις προέβλεψε σωστά το δίκτυο, συγκριτικά με όλες τις θετικές περιπτώσεις που παρουσιάζονται στα δεδομένα. Υπολογίζεται από την εξίσωση (25).

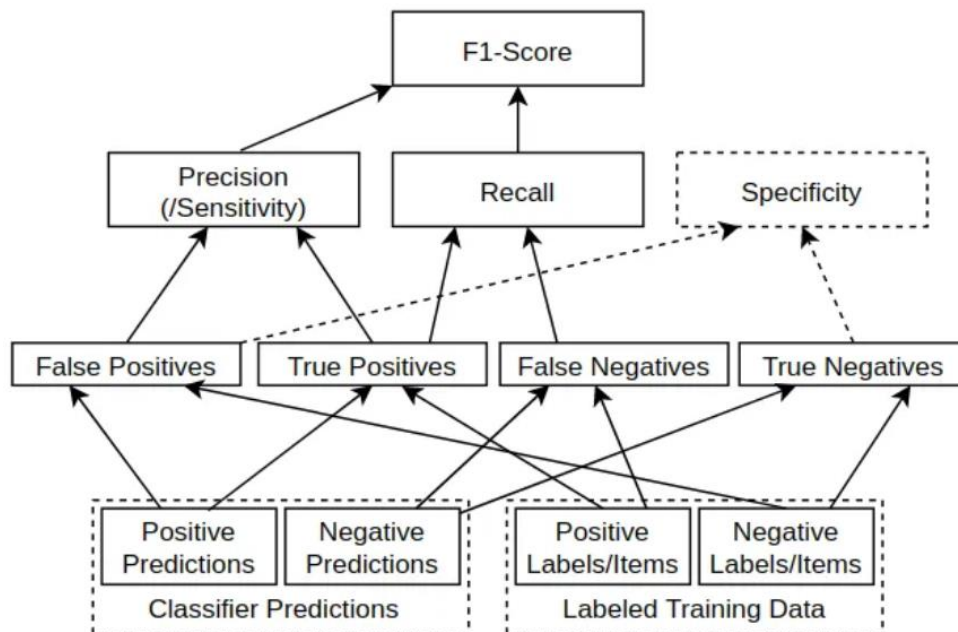
$$Recall = \frac{TP}{TP+FN} \quad (25)$$

- 5) *Ακρίβεια (Precision)*: δηλώνει πόσες από τις θετικές προβλέψεις είναι αληθείς (TP). Υπολογίζεται από την εξίσωση (26).

$$Precision = \frac{TP}{TP+FP} \quad (26)$$

- 6) *F1-score*: είναι ένα μέγεθος που συνδυάζει το recall με το precision, και αποτελεί έναν αρμονικό μέσο όρο των δύο. Ο αρμονικός μέσος όρος (harmonic mean) είναι ένας διαφορετικός τρόπος υπολογισμού του μέσου όρου, ο οποίος είναι καταλληλότερος για αναλογίες, όπως η ανάκληση και η ακρίβεια. Η ιδέα πίσω από το F1-score είναι η παροχή ενός μεγέθους, που θα σταθμίζει τα άλλα δύο μεγέθη, με ισορροπημένο τρόπο, απαιτώντας και από τα δύο να έχουν υψηλές τιμές, ώστε να αυξηθεί η τιμή του. Υπολογίζεται από την εξίσωση (27) [68].

$$F1 - Score = 2 * \frac{Precision * Recall}{Precision+Recall} \quad (27)$$



Σχήμα 67: Ιεραρχία των διαφόρων μεγεθών, από τα δεδομένα έως και το F1-Score [68].

Στα αποτελέσματα, όπως παρουσιάζονται στη συνέχεια, αναφέρονται, αρχικά, τα επιμέρους μετρητικά στοιχεία της κάθε κλάσης και στο τέλος, τα συνολικά αποτελέσματα του μοντέλου σε ολόκληρη τη βάση δεδομένων. Τα τελευταία προκύπτουν από τους μέσους όρους των αποτελεσμάτων των τεσσάρων κλάσεων.

- 1) Μεμονωμένες λειτουργίες φορητού υπολογιστή (laptop) (53 εικόνες) και πρέσας μαλλιών (hair iron) (59 εικόνες).
Ταυτόχρονη λειτουργία ψυγείου (fridge) και πρέσας μαλλιών (32 εικόνες).
Μεταβατική λειτουργία ενεργοποίησης του κλιματιστικού (none to air conditioner) (39 εικόνες).

Πίνακας 9: Πίνακας αληθείας και αποτελέσματα της κλάσης «hair iron».

True Positive	True Negative	False Positive	False Negative	Precision	Recall	F1-Score
11	20	1	0	0,92	1	0,96

Πίνακας 10: Πίνακας αληθείας και αποτελέσματα της κλάσης «laptop».

True Positive	True Negative	False Positive	False Negative	Precision	Recall	F1-Score
7	23	1	1	0,87	0,87	0,87

Πίνακας 11: Πίνακας αληθείας και αποτελέσματα της κλάσης «fridge and hair iron».

True Positive	True Negative	False Positive	False Negative	Precision	Recall	F1-Score
5	23	3	1	0,62	0,83	0,71

Πίνακας 12: Πίνακας αληθείας και αποτελέσματα της κλάσης «none to air conditioner».

True Positive	True Negative	False Positive	False Negative	Precision	Recall	F1-Score
4	25	0	3	1	0,57	0,73

Πίνακας 13: Συνολικά αποτελέσματα μοντέλου.

Test Loss	Test Accuracy	Precision	Recall	F1-Score
0,81	0,84	0,84	0,84	0,84

- 2) Μεμονωμένες λειτουργίες φορητού υπολογιστή (53 εικόνες) και κλιματιστικού (81 εικόνες).
Ταυτόχρονη λειτουργία φορητού υπολογιστή και κλιματιστικού (16 εικόνες).
Μεταβατική λειτουργία ενεργοποίησης του κλιματιστικού (39 εικόνες).

Πίνακας 14: Πίνακας αληθείας και αποτελέσματα της κλάσης «air conditioner».

True Positive	True Negative	False Positive	False Negative	Precision	Recall	F1-Score
15	14	4	1	0,79	0,94	0,86

Πίνακας 15: Πίνακας αληθείας και αποτελέσματα της κλάσης «laptop».

True Positive	True Negative	False Positive	False Negative	Precision	Recall	F1-Score
5	24	2	3	0,71	0,62	0,66

Πίνακας 16: Πίνακας αληθείας και αποτελέσματα της κλάσης «laptop and air conditioner».

True Positive	True Negative	False Positive	False Negative	Precision	Recall	F1-Score
2	31	0	1	1	0,66	0,79

Πίνακας 17: Πίνακας αληθείας και αποτελέσματα της κλάσης «none to air conditioner».

True Positive	True Negative	False Positive	False Negative	Precision	Recall	F1-Score
6	27	0	1	1	0,86	0,92

Πίνακας 18: Συνολικά αποτελέσματα μοντέλου.

Test Loss	Test Accuracy	Precision	Recall	F1-Score
1,42	0,82	0,82	0,79	0,81

- 3) Μεμονωμένη λειτουργία κλιματιστικού (81 εικόνες).
 Ταυτόχρονη λειτουργία φορητού υπολογιστή και κλιματιστικού (16 εικόνες).
 Μεταβατικές λειτουργίες ενεργοποίησης (39 εικόνες) και απενεργοποίησης του κλιματιστικού (air conditioner to none) (37 εικόνες).

Πίνακας 19: Πίνακας αληθείας και αποτελέσματα της κλάσης «air conditioner».

True Positive	True Negative	False Positive	False Negative	Precision	Recall	F1-Score
15	16	1	1	0,94	0,94	0,94

Πίνακας 20: Πίνακας αληθείας και αποτελέσματα της κλάσης «air conditioner and laptop».

True Positive	True Negative	False Positive	False Negative	Precision	Recall	F1-Score
3	29	1	0	0,75	1	0,86

Πίνακας 21: Πίνακας αληθείας και αποτελέσματα της κλάσης «air conditioner to none».

True Positive	True Negative	False Positive	False Negative	Precision	Recall	F1-Score
6	23	3	1	0,66	0,86	0,75

Πίνακας 22: Πίνακας αληθείας και αποτελέσματα της κλάσης «none to air conditioner».

True Positive	True Negative	False Positive	False Negative	Precision	Recall	F1-Score
4	26	0	3	1	0,57	0,73

Πίνακας 23: Συνολικά αποτελέσματα μοντέλου.

Test Loss	Test Accuracy	Precision	Recall	F1-Score
1,56	0,85	0,85	0,85	0,85

- 4) Μεμονωμένες λειτουργίες φορητού υπολογιστή (53 εικόνες), πρέσας μαλλιών (59 εικόνες) και ανεμιστήρα (fan) (52 εικόνες).
 Μεταβατική λειτουργία ενεργοποίησης του κλιματιστικού (39 εικόνες).

Πίνακας 24: Πίνακας αληθείας και αποτελέσματα της κλάσης «laptop».

True Positive	True Negative	False Positive	False Negative	Precision	Recall	F1-Score
6	25	0	2	1	0,75	0,86

Πίνακας 25: Πίνακας αληθείας και αποτελέσματα της κλάσης «hair iron».

True Positive	True Negative	False Positive	False Negative	Precision	Recall	F1-Score
11	19	3	0	0,78	1	0,88

Πίνακας 26: Πίνακας αληθείας και αποτελέσματα της κλάσης «fan».

True Positive	True Negative	False Positive	False Negative	Precision	Recall	F1-Score
5	26	0	2	1	0,71	0,83

Πίνακας 27: Πίνακας αληθείας και αποτελέσματα της κλάσης «none to air conditioner».

True Positive	True Negative	False Positive	False Negative	Precision	Recall	F1-Score
6	24	2	1	0,75	0,86	0,80

Πίνακας 28: Συνολικά αποτελέσματα μοντέλου.

Test Loss	Test Accuracy	Precision	Recall	F1-Score
0,45	0,85	0,85	0,85	0,85

- 5) Μεμονωμένες λειτουργίες φορητού υπολογιστή (53 εικόνες), ψυγείου (107 εικόνες), ανεμιστήρα (52 εικόνες) και μηχανισμού απόψυξης ψυγείου (defroster) (75 εικόνες).

Πίνακας 29: Πίνακας αληθείας και αποτελέσματα της κλάσης «laptop».

True Positive	True Negative	False Positive	False Negative	Precision	Recall	F1-Score
6	43	0	2	1	0,75	0,86

Πίνακας 30: Πίνακας αληθείας και αποτελέσματα της κλάσης «fridge».

True Positive	True Negative	False Positive	False Negative	Precision	Recall	F1-Score
19	21	9	2	0,68	0,90	0,77

Πίνακας 31: Πίνακας αληθείας και αποτελέσματα της κλάσης «fan».

True Positive	True Negative	False Positive	False Negative	Precision	Recall	F1-Score
6	43	1	1	0,86	0,86	0,86

Πίνακας 32: Πίνακας αληθείας και αποτελέσματα της κλάσης «defroster».

True Positive	True Negative	False Positive	False Negative	Precision	Recall	F1-Score
9	35	1	6	0,90	0,60	0,72

Πίνακας 33: Συνολικά αποτελέσματα μοντέλου.

Test Loss	Test Accuracy	Precision	Recall	F1-Score
0,91	0,78	0,78	0,76	0,77

Όπως προκύπτει, παρατηρείται αρκετά ικανοποιητική αναγνώριση και έχουν σημειωθεί καλά F1-Scores, για τον μικρό όγκο δεδομένων και για τις μικρές δυνατότητες του εξοπλισμού που χρησιμοποιήθηκε, σε όρους υπολογιστικής ισχύος. Από τα αποτελέσματα των διαφόρων δοκιμών, παρατηρήθηκε ότι συνδυασμοί που αποτελούνται από συσκευές με έντονο αρμονικό περιεχόμενο, όπως

το laptop και το κλιματιστικό, ήταν πιο επιτυχείς στην αναγνώριση. Αυτό οφείλεται στο γεγονός ότι, τέτοιες συσκευές παρουσιάζουν συχνότερα ανώτερες αρμονικές και άρα, οι εικόνες τους είναι περισσότερο αντιπροσωπευτικές στο πεδίο των αρμονικών. Επίσης, σε μια εικόνα που απεικονίζει την ταυτόχρονη λειτουργία δύο συσκευών, αν η μία από αυτές δεν εμφανίζει έντονο περιεχόμενο, υπάρχει ο κίνδυνος να «επικαλυφθεί» και να μην έχει το δικό της αποτύπωμα στην εικόνα. Ταυτόχρονα, συσκευές όπως το laptop και ο ανεμιστήρας, που δημιουργούν ένα μοτίβο στις εικόνες τους, είναι πιο εύκολα αναγνωρίσιμες από το νευρωνικό δίκτυο. Σε αυτό το σημείο, είναι σημαντικό να υπενθυμιστεί ότι η εκπαίδευση σε κάθε σενάριο γίνεται για τις τέσσερις κλάσεις του σεναρίου. Αυτό σημαίνει, ότι στα αποτελέσματα μπορούν να εμφανισθούν μόνο αυτές οι τέσσερις συγκεκριμένες συσκευές (ή πέντε στην περίπτωση κλάσης με ταυτόχρονη λειτουργία), καθώς αυτές γνωρίζει το δίκτυο.

Η διεξαγωγή όλων των πειραμάτων υλοποιήθηκε σε οικιακό φορητό υπολογιστή, με επεξεργαστή Intel Core i5 10th gen, μνήμη RAM 8 GB και λειτουργικό σύστημα Windows 10 pro x64. Ως περιβάλλον για ανάπτυξη κώδικα σε γλώσσα python, χρησιμοποιήθηκε το Spyder, στην έκδοση 5.4.1.

4. Συμπεράσματα

4.1 Σύνοψη και συμπεράσματα

Τα παραπάνω αποτελέσματα δείχνουν ότι η χρήση CNN αποτελεί ένα καλό εργαλείο για εφαρμογές NILM. Τα συνελικτικά νευρωνικά δίκτυα είναι ευρέως διαδεδομένα στο πεδίο της μη-παρεμβατικής παρακολούθησης, και ο λόγος είναι ότι μπορούν να αποδώσουν καλά στην αναγνώριση εικόνων/μοτίβων. Τα αρκετά καλά F1-Score που προέκυψαν, σε δίκτυο το οποίο εκπαιδεύτηκε με έναν πολύ μικρό όγκο εικόνων για τα δεδομένα του CNN, δηλώνουν ότι το μοντέλο μπορεί να είναι αποδοτικό, ακόμη και σε μια πολύ μικρότερη βάση δεδομένων από αυτή που απαιτεί ένα τέτοιο δίκτυο. Μεταξύ των δοκιμών που πραγματοποιήθηκαν, έγινε φανερό ότι για αυτόν τον μικρό όγκο δεδομένων, η μέθοδος 80-20 για το διαχωρισμό των εικόνων σε train και test ήταν η καταλληλότερη λύση, συγκριτικά με τις 60-40 και 70-30. Ταυτόχρονα, παρατηρήθηκε ότι συσκευές με χαμηλό αρμονικό περιεχόμενο δε γινόταν να αναγνωριστούν με επιτυχία, σε αντίθεση με τις συσκευές με πλούσιο περιεχόμενο, όπως το laptop και το κλιματιστικό. Επιπλέον, η εργασία προτείνει μια διαφορετική αντιμετώπιση στη δημιουργία των εικόνων. Πιο συγκεκριμένα, συνήθως παρατηρείται στο NILM να γίνεται χρήση V-I (τάση-ρεύμα) εικόνων. Ωστόσο, το μοντέλο που παρουσιάστηκε βασίστηκε στην απεικόνιση αρμονικών των συσκευών. Η πληροφορία για τις αρμονικές φάνηκε να είναι μια αποδοτική επιλογή για τη δημιουργία μιας βάσης δεδομένων.

4.2 Περιορισμοί και μελλοντικές βελτιώσεις

Όπως μπορεί να γίνει αντιληπτό από τα συμπεράσματα που αναφέρθηκαν, η μεθοδολογία που έχει προταθεί θα μπορούσε να δεχθεί βελτιώσεις. Σχετικά με την ανάπτυξη του μοντέλου νευρωνικού δικτύου, ένας καλύτερος εξοπλισμός (resources), με πιο δυνατό επεξεργαστή, θα επέτρεπε την

επιμήκυνση του μοντέλου (περισσότερα layers) και την αύξηση παραμέτρων, με συνέπεια την καλύτερη απόδοση, με ταυτόχρονη επεκτασιμότητα του μοντέλου. Ένας άλλος τρόπος για βελτίωση της απόδοσης, είναι η δημιουργία ενός υβριδικού μοντέλου, που θα χρησιμοποιούσε ένα μεταευριστικό αλγόριθμο για την εύρεση των ιδανικών παραμέτρων και υπερ-παραμέτρων. Αδιαμφισβήτητα, το πιο σημαντικό ζήτημα του μοντέλου που παρουσιάστηκε, είναι η πολύ μικρή βάση δεδομένων που χρησιμοποιήθηκε. Για να μπορέσει ένα CNN να θεωρηθεί εύρωστο, απαιτεί αρκετά μεγαλύτερο όγκο δεδομένων, της τάξης μεγέθους 10^3 ή και 10^4 . Μια πιθανή λύση, θα μπορούσε να είναι η δημιουργία εικόνων με βάση τις 1^{η} - 3^{η} και 1^{η} - 5^{η} αρμονικές. Στο πείραμα, οι εικόνες προέκυψαν από τις 3^{η} - 5^{η} αρμονικές. Αυτό οδηγεί σε ορισμένες περιπτώσεις σε απώλεια πληροφορίας. Σε συσκευές με χαμηλό έως και μηδενικό αρμονικό περιεχόμενο, όπως η πρέσα μαλλιών, η βασική πληροφορία έγκειται στη θεμελιώδη (1^{η}) αρμονική, η οποία στις συγκεκριμένες εικόνες δε λαμβάνεται υπόψη. Τέλος, στο μοντέλο της παρούσας εργασίας, υπάρχει περιορισμός στις κλάσεις εξόδου, οι οποίες έχουν οριστεί ίσες με τέσσερις σε κάθε σενάριο που μελετάται. Ένας πραγματικός αισθητήρας που θα τοποθετηθεί σε έναν ηλεκτρολογικό πίνακα, θα παρέχει πληροφορίες για όλες τις συσκευές που έχουν λειτουργήσει, γεγονός που θα απαιτεί ένα μοντέλο με περισσότερες κλάσεις. Συνεπώς, υπάρχουν πολλές προοπτικές για τη συνέχιση της παρούσας εργασίας στο μέλλον.

Παράρτημα

Υλοποίηση CNN σε Python

```
import os
import cv2
import numpy as np
import tensorflow as tf
from sklearn.model_selection import train_test_split
from tensorflow import keras
from tensorflow.keras import layers
from tensorflow.keras.preprocessing.image import img_to_array, load_img
from sklearn.preprocessing import LabelEncoder, OneHotEncoder

# Function to load and preprocess the images from the given directory
def load_images_from_folder(folder, target_size):
    images = []
    for filename in os.listdir(folder):
        img_path = os.path.join(folder, filename)
        img = load_img(img_path, target_size=target_size)
        img = img.convert('L') # Convert RGB to grayscale
        img = img_to_array(img)
        images.append(img)
    return np.array(images)

# Set the target image size for resizing
target_size = (224, 224)

# Load and preprocess the training data
```

```

train_folder = "train"
classes = ["Laptop", "Fan", "Fridge", "Defroster"]

train_images = []
train_labels = []

label_encoder = LabelEncoder()
integer_labels = label_encoder.fit_transform(classes)

for i, class_name in enumerate(classes):
    folder_path = os.path.join(train_folder, class_name)
    class_images = load_images_from_folder(folder_path, target_size)
    train_images.extend(class_images)
    train_labels.extend([i] * len(class_images))

train_images = np.array(train_images)
train_labels = np.array(train_labels)

# One-hot encode the labels
onehot_encoder = OneHotEncoder(sparse=False, categories='auto')
train_labels = onehot_encoder.fit_transform(train_labels.reshape(-1, 1))

# Split the training data into training and validation sets
train_images, val_images, train_labels, val_labels = train_test_split(
    train_images, train_labels, test_size=0.2, random_state=42
)

# Define custom F1-score metric
class F1Score(tf.keras.metrics.Metric):

```

```

def __init__(self, name='f1_score', **kwargs):
    super(F1Score, self).__init__(name=name, **kwargs)
    self.precision = tf.keras.metrics.Precision()
    self.recall = tf.keras.metrics.Recall()

def update_state(self, y_true, y_pred, sample_weight=None):
    self.precision.update_state(y_true, y_pred)
    self.recall.update_state(y_true, y_pred)

def result(self):
    precision = self.precision.result()
    recall = self.recall.result()
    f1_score = 2 * ((precision * recall) / (precision + recall + tf.keras.backend.epsilon()))
    return f1_score

def reset_state(self):
    self.precision.reset_state()
    self.recall.reset_state()

```

Define the CNN architecture

```

model = keras.Sequential([
    layers.Conv2D(32, kernel_size=(3, 3), activation="relu", padding='same', input_shape=(target_size[0],
target_size[1], 1)),
    layers.MaxPooling2D(pool_size=(2, 2)),
    layers.Conv2D(64, kernel_size=(3, 3), activation="relu", padding='same'),
    layers.MaxPooling2D(pool_size=(2, 2)),
    layers.Flatten(),
    layers.Dense(128, activation="relu"),

```

```
layers.Dense(4, activation="softmax")
])

# Compile the model
model.compile(
    loss=keras.losses.CategoricalCrossentropy(),
    optimizer=keras.optimizers.Adam(),
    metrics=['accuracy', tf.keras.metrics.Precision(), tf.keras.metrics.Recall(), F1Score()]
)

tf.random.set_seed(40) # Set a random seed for reproducibility

# Train the model
model.fit(
    train_images, train_labels,
    batch_size=16,
    epochs=10,
    validation_data=(val_images, val_labels)
)

# Load and predict the images from the test folder
test_folder = "test"

test_images = []
test_labels = []

for i, class_name in enumerate(classes):
    folder_path = os.path.join(test_folder, class_name)
    class_images = load_images_from_folder(folder_path, target_size)
```

```
test_images.extend(class_images)
test_labels.extend([i] * len(class_images))

test_images = np.array(test_images)
test_labels = np.array(test_labels)

# One-hot encode the test labels
test_labels = onehot_encoder.transform(test_labels.reshape(-1, 1))

# Evaluate the model on test dataset
test_loss, test_accuracy, precision, recall, f1_score = model.evaluate(test_images, test_labels)

# Evaluate the model on test dataset
test_predictions = model.predict(test_images)
predicted_labels = np.argmax(test_predictions, axis=1)
true_labels = np.argmax(test_labels, axis=1)

# Initialize dictionaries to store TP, TN, FP, FN values for each class
class_tp = {}
class_tn = {}
class_fp = {}
class_fn = {}

# Calculate TP, TN, FP, FN for each class
for class_index in range(len(classes)):
    class_name = classes[class_index]
    class_tp[class_name] = np.sum(np.logical_and(predicted_labels == class_index, true_labels ==
class_index))
```

```
class_tn[class_name] = np.sum(np.logical_and(predicted_labels != class_index, true_labels != class_index))
```

```
class_fp[class_name] = np.sum(np.logical_and(predicted_labels == class_index, true_labels != class_index))
```

```
class_fn[class_name] = np.sum(np.logical_and(predicted_labels != class_index, true_labels == class_index))
```

```
# Print TP, TN, FP, FN values for each class
```

```
for class_name in classes:
```

```
    print(f"Class: {class_name}")
```

```
    print('True Positive:', class_tp[class_name])
```

```
    print('True Negative:', class_tn[class_name])
```

```
    print('False Positive:', class_fp[class_name])
```

```
    print('False Negative:', class_fn[class_name])
```

```
    print()
```

```
# Print evaluation metrics
```

```
print('Test Loss:', test_loss)
```

```
print('Test Accuracy:', test_accuracy)
```

```
print('Precision:', precision)
```

```
print('Recall:', recall)
```

```
print('F1-Score:', f1_score)
```

```
for class_name in classes:
```

```
    folder_path = os.path.join(test_folder, class_name)
```

```
    test_images = load_images_from_folder(folder_path, target_size)
```

```
    predictions = model.predict(test_images)
```

```
    predicted_labels = np.argmax(predictions, axis=1)
```

```
    print(f"Predictions for class '{class_name}':")
```



```
for pred_label in predicted_labels:  
    print(classes[pred_label])
```

Αναφορές

- [1] Robles, Rosslin John, and Tai-hoon Kim. "Applications, systems and methods in smart home technology: A." *Int. Journal of Advanced Science And Technology* 15 (2010): 37-48.
- [2] Sovacool, Benjamin K., and Dylan D. Furszyfer Del Rio. "Smart home technologies in Europe: A critical review of concepts, benefits, risks and policies." *Renewable and sustainable energy reviews* 120 (2020): 109663.
- [3] [«Πλεονεκτήματα «Έξυπνου» Σπιτιού»](#) (Ημερομηνία τελευταίας προσπέλασης: 14/04/23)
- [4] [«Ανάπτυξη και έξυπνοι μετρητές»](#) (Ημερομηνία τελευταίας προσπέλασης: 13/04/23)
- [5] [«Πώς να κάνω το σπίτι μου έξυπνο; Τι κόστος έχουν οι αυτοματισμοί;»](#) (Ημερομηνία τελευταίας προσπέλασης: 13/04/23)
- [6] [«Έξυπνοι μετρητές ηλεκτρικής ενέργειας»](#) (Ημερομηνία τελευταίας προσπέλασης: 13/04/23)
- [7] [EFERGY EF01103 ασύρματος μετρητής ενέργειας E2 classic 3Φ με πομπό ράνας](#) (Ημερομηνία τελευταίας προσπέλασης: 13/04/23)
- [8] [«Ενημερωτικό γράφημα - Ενεργειακή κρίση: Τρία συντονισμένα μέτρα στην ΕΕ για να μειωθούν οι λογαριασμοί ενέργειας»](#) (Ημερομηνία τελευταίας προσπέλασης: 14/04/23)
- [9] [«Why is Peak Demand a Concern for Utilities?»](#) (Ημερομηνία τελευταίας προσπέλασης: 14/04/23)
- [10] [«Ηλεκτρικό ρεύμα: Ποιες είναι οι ώρες αιχμής – Έτσι θα μειώσετε την κατανάλωση»](#) (Ημερομηνία τελευταίας προσπέλασης: 14/04/23)
- [11] Τοπάλης, Ανδρέας Σ. (2020) «Μη παρεμβατική παρακολούθηση φορτίου και ανάλυση αλγορίθμων». Πτυχιακή εργασία, ΤΕΙ Δυτικής Μακεδονίας.
- [12] Gopinath, R., et al. "Energy management using non-intrusive load monitoring techniques—State-of-the-art and future research directions." *Sustainable Cities and Society* 62 (2020): 102411.
- [13] Δούμουρας, Νικόλαος Ι. (2021) «Μη παρεμβατική παρακολούθηση ηλεκτρικού φορτίου οικιακών εγκαταστάσεων με χρήση τεχνικών μηχανικής μάθησης». Διπλωματική εργασία, Εθνικό Μετσόβιο Πολυτεχνείο.
- [14] Shin, Changho, et al. "Data requirements for applying machine learning to energy disaggregation." *Energies* 12.9 (2019): 1696.
- [15] Hart, George William. "Nonintrusive appliance load monitoring." *Proceedings of the IEEE* 80.12 (1992): 1870-1891.
- [16] Desai, Sanket, et al. "Multi-state energy classifier to evaluate the performance of the nilm algorithm." *Sensors* 19.23 (2019): 5236.
- [17] Yan, Lei, et al. "Challenges for real-world applications of nonintrusive load monitoring and opportunities for machine learning approaches." *The Electricity Journal* 35.5 (2022): 107136.

- [18] Hassan, Taha, Fahad Javed, and Naveed Arshad. "An empirical investigation of VI trajectory based load signatures for non-intrusive load monitoring." *IEEE Transactions on Smart Grid* 5.2 (2013): 870-878.
- [19] Gopinath, R., et al. "Performance analysis of similar appliances identification using NILM technique under different data sampling rates." *Proceedings of the 5th International Workshop on Non-Intrusive Load Monitoring*. 2020.
- [20] Bohao Huang, Mary Knox, Kyle Bradbury, Leslie M Collins, and Richard G Newell. 2017. Non-intrusive load monitoring system performance over a range of low frequency sampling rates. In *2017 IEEE 6th International Conference on Renewable Energy Research and Applications (ICRERA)*. IEEE, 505–509.
- [21] Picon, Thomas, Mohamed Nait Meziane, Philippe Ravier, Guy Lamarque, Clarisse Novello, Jean-Charles Le Bunetel and Yves Raingeaud. "COOLL: Controlled On/Off Loads Library, a Public Dataset of High-Sampled Electrical Signals for Appliance Identification." *ArXiv abs/1611.05803* (2016): n. pag.
- [22] Kahl, Matthias, Anwar ul Haq, Thomas Kriechbaumer and Hans-Arno Jacobsen. "WHITED-A Worldwide Household and Industry Transient Energy Data Set." (2016).
- [23] M. A. Ahajjam, D. Bonilla Licea, C. Essayeh, M. Ghogho, and A. Kobbane, "Mored: A Moroccan buildings' electricity consumption dataset," *Energies*, vol. 13, no. 24, p. 6737, 2020.
- [24] Angelis, Georgios-Fotios, et al. "NILM applications: Literature review of learning approaches, recent developments and challenges." *Energy and Buildings* (2022): 111951.
- [25] Kim, Hyungsul, et al. "Unsupervised disaggregation of low frequency power measurements." *Proceedings of the 2011 SIAM international conference on data mining*. Society for Industrial and Applied Mathematics, 2011.
- [26] Kolter, J. Zico, and Tommi Jaakkola. "Approximate inference in additive factorial hmms with application to energy disaggregation." *Artificial intelligence and statistics*. PMLR, 2012.
- [27] Parson, Oliver, et al. "An unsupervised training method for non-intrusive appliance load monitoring." *Artificial Intelligence* 217 (2014): 1-19.
- [28] Z. Wang, G. Zheng, Residential appliances identification and monitoring by a nonintrusive method, *IEEE transactions on Smart Grid* 3 (2011) 80–92.
- [29] K. He, L. Stankovic, J. Liao, V. Stankovic, Non-intrusive load disaggregation using graph signal processing, *IEEE Transactions on Smart Grid* 9 (2016) 1739–1747.
- [30] E. Elhamifar, S. Sastry, Energy disaggregation via learning powerlets and sparse coding, in: *Twenty-Ninth AAAI Conference on Artificial Intelligence*, 2015.
- [31] D. Piga, A. Cominola, M. Giuliani, A. Castelletti, A. E. Rizzoli, Sparse optimization for automated energy end use disaggregation, *IEEE Transactions on Control Systems Technology* 24 (2015) 1044–1051.
- [32] H. Kang, H. Kim, et al., Household appliance classification using lower odd-numbered harmonics and the bagging decision tree, *IEEE Access* 8 (2020) 55937–55952.

- [33] Chen, Zhuo, et al. "Non-intrusive load monitoring based on feature extraction of change-point and XGBoost classifier." 2020 IEEE 4th Conference on Energy Internet and Energy System Integration (EI2). IEEE, 2020.
- [34] Krizhevsky, Alex, Ilya Sutskever, and Geoffrey E. Hinton. "Imagenet classification with deep convolutional neural networks." Communications of the ACM 60.6 (2017): 84-90.
- [35] do Nascimento, Pedro Paulo Marques. "Applications of deep learning techniques on NILM." Diss. Universidade Federal do Rio de Janeiro (2016).
- [36] Albelwi, Saleh, and Ausif Mahmood. "A framework for designing the architectures of deep convolutional neural networks." Entropy 19.6 (2017): 242.
- [37] ["Understanding the Mechanism and Types of Recurrent Neural Network"](#) (Ημερομηνία τελευταίας προσπέλασης: 04/05/23)
- [38] Δασκαλάκης, Ελευθέριος Ν. (2016) «Ανάλυση και Περιγραφή πολυμεσικών δεδομένων με χρήση συνελκτικών νευρωνικών δικτύων και νευρώνων μακράς βραχυπρόθεσμης μνήμης». Μεταπτυχιακή διατριβή, Αριστοτέλειο Πανεπιστήμιο Θεσσαλονίκης.
- [39] ["Deep Learning | Introduction to Long Short Term Memory"](#) (Ημερομηνία τελευταίας προσπέλασης: 04/05/23)
- [40] Chauhan, Rahul, Kamal Kumar Ghanshala, and R. C. Joshi. "Convolutional neural network (CNN) for image detection and recognition." 2018 first international conference on secure cyber computing and communication (ICSCCC). IEEE, 2018.
- [41] Albawi, Saad, Tareq Abed Mohammed, and Saad Al-Zawi. "Understanding of a convolutional neural network." 2017 international conference on engineering and technology (ICET). Ieee, 2017.
- [42] ["Deciding optimal kernel size for CNN"](#) (Ημερομηνία τελευταίας προσπέλασης: 19/05/23)
- [43] ["convolutional neural network \(cnn\)"](#) (Ημερομηνία τελευταίας προσπέλασης: 10/05/23)
- [44] ["Basic CNN Architecture: Explaining 5 Layers of Convolutional Neural Network"](#) (Ημερομηνία τελευταίας προσπέλασης: 10/05/23)
- [45] ["Parameters and Hyperparameters in Machine Learning and Deep Learning"](#) (Ημερομηνία τελευταίας προσπέλασης: 11/05/23)
- [46] ["What are Weights and Biases?"](#) (Ημερομηνία τελευταίας προσπέλασης: 15/05/23)
- [47] ["Understanding and Calculating the number of Parameters in Convolution Neural Networks \(CNNs\)"](#) (Ημερομηνία τελευταίας προσπέλασης: 13/05/23)
- [48] ["Convolutional Neural Networks, Explained"](#) (Ημερομηνία τελευταίας προσπέλασης: 16/05/23)
- [49] ["Understanding Neural Networks. From neuron to RNN, CNN, and Deep Learning"](#) (Ημερομηνία τελευταίας προσπέλασης: 16/05/23)

- [50] Yani, Muhamad. "Application of transfer learning using convolutional neural network method for early detection of terry's nail." Journal of Physics: Conference Series. Vol. 1201. No. 1. IOP Publishing, 2019.
- [51] ["Learning Process of a Deep Neural Network"](#) (Ημερομηνία τελευταίας προσπέλασης: 17/05/23)
- [52] ["Introduction to Softmax for Neural Network"](#) (Ημερομηνία τελευταίας προσπέλασης: 17/05/23)
- [53] ["The Concept of Artificial Neurons \(Perceptrons\) in Neural Networks"](#) (Ημερομηνία τελευταίας προσπέλασης: 16/05/23)
- [54] ["How to Choose an Activation Function for Deep Learning"](#) (Ημερομηνία τελευταίας προσπέλασης: 17/05/23)
- [55] ["Cost, Activation, Loss Function | | Neural Network | | Deep Learning. What are these?"](#) (Ημερομηνία τελευταίας προσπέλασης: 12/06/23)
- [56] ["What is gradient descent?"](#) (Ημερομηνία τελευταίας προσπέλασης: 17/05/23)
- [57] ["How Does the Gradient Descent Algorithm Work in Machine Learning?"](#) (Ημερομηνία τελευταίας προσπέλασης: 17/05/23)
- [58] ["Various Optimization Algorithms For Training Neural Network"](#) (Ημερομηνία τελευταίας προσπέλασης: 19/05/23)
- [59] ["An Overview of Regularization Techniques in Deep Learning \(with Python code\)"](#) (Ημερομηνία τελευταίας προσπέλασης: 20/05/23)
- [60] Chen, LeiYu, et al. "Review of image classification algorithms based on convolutional neural networks." Remote Sensing 13.22 (2021): 4712.
- [61] R. Poojary and A. Pai, "Comparative Study of Model Optimization Techniques in Fine-Tuned CNN Models," 2019 International Conference on Electrical and Computing Technologies and Applications (ICECTA), Ras Al Khaimah, United Arab Emirates, 2019, pp. 1-4, doi: 10.1109/ICECTA48151.2019.8959681.
- [62] ["Data Labelling in Machine Learning"](#) (Ημερομηνία τελευταίας προσπέλασης: 10/06/23)
- [63] Medico, R., De Baets, L., Gao, J. et al. A voltage and current measurement dataset for plug load appliance identification in households. Sci Data 7, 49 (2020). <https://doi.org/10.1038/s41597-020-0389-7>
- [64] ["TensorFlow"](#) (Ημερομηνία τελευταίας προσπέλασης: 09/06/23)
- [65] ["What Is Keras: The Best Introductory Guide To Keras"](#) (Ημερομηνία τελευταίας προσπέλασης: 09/06/23)
- [66] ["Understanding Sequential Vs Functional API in Keras"](#) (Ημερομηνία τελευταίας προσπέλασης: 09/06/23)
- [67] Andrew Ng, Kian Katanforoosh, Younes Bensouda Mourri, «Convolutional Neural Networks», [Coursera](#)
- [68] ["A Look at Precision, Recall, and F1-Score"](#) (Ημερομηνία τελευταίας προσπέλασης: 13/06/23)

