



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών

Διατμηματικό Πρόγραμμα Μεταπτυχιακών Σπουδών
«Παραγωγή και Διαχείριση Ενέργειας»

Ηρώων Πολυτεχνείου 9, 157 73, Ζωγράφου – 210-7723655 – erminfo@power.ece.ntua.gr

ΜΕΤΑΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ

***«ΕΦΑΡΜΟΓΕΣ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΣΕ
ΔΙΚΤΥΑ ΔΙΑΝΟΜΗΣ ΓΙΑ ΑΝΙΧΝΕΥΣΗ
ΤΟΠΟΛΟΓΙΑΣ»***

Του Μεταπτυχιακού Φοιτητή

Μοχιανάκη Καραμπατζάκη Αντώνη

Επιβλέπων

Άρης Ευάγγελος Δημέας, μέλος ΔΕΠ, ΗΜΜΥ ΕΜΠ

Αθήνα, Οκτώβριος 2024



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ
ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΗΛΕΚΤΡΙΚΗΣ ΙΣΧΥΟΣ

Εφαρμογές μηχανικής μάθησης σε δίκτυα διανομής για ανίχνευση τοπολογίας

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Μοχιανάκης Καραμπατζάκης Αντώνιος

Επιβλέπων: Άρης Ευάγγελος Δημέας
Καθηγητής ΗΜΜΥ ΕΜΠ

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 17^η Οκτωβρίου 2024.

Α.Δημέας
Καθηγητής Ε.Μ.Π.

Σ.Παπαθανασίου
Καθηγητής Ε.Μ.Π.

Γ.Κορρές
Καθηγητής Ε.Μ.Π.

Αθήνα, Οκτώβριος 2024

.....
Μοχιανάκης Καραμπατζάκης Αντώνιος

Διπλωματούχος Ηλεκτρολόγος Μηχανικός και Μηχανικός Υπολογιστών Ε.Μ.Π.

Copyright © Μοχιανάκης Καραμπατζάκης Αντώνιος
Με επιφύλαξη παντός δικαιώματος. All rights reserved.

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 δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις επίσημες θέσεις του Εθνικού Μετσόβιου Πολυτεχνείου.

Περίληψη

Η παρούσα διπλωματική εργασία πραγματεύεται μια μεθοδολογία ανίχνευσης τοπολογίας σε πραγματικό χρόνο (Topology Detection - TD) στα συστήματα διανομής ηλεκτρικής ενέργειας, έναν τομέα που έχει γίνει ολοένα και πιο κρίσιμος με την ένταξη διεσπαρμένων πηγών ενέργειας και δυναμικών αλλαγών φορτίου στο δίκτυο. Οι παραδοσιακές μέθοδοι ανίχνευσης τοπολογίας, που βασίζονται κυρίως σε εκτιμήσεις κατάστασης (state estimation) και ιστορικά δεδομένα παρουσιάζουν αδυναμίες στην παρακολούθηση γρήγορων εναλλαγών στις τοπολογίες των δικτύων. Η εργασία αξιοποιεί την διάδοση των μονάδων μέτρησης φασιθετών D-PMUs (Distribution - Phasor Measurement Units), που παρέχουν δεδομένα πραγματικού χρόνου, προσφέροντας ένα νέο πεδίο για την εφαρμογή τεχνικών βαθιάς μάθησης για τη βελτίωση της ακρίβειας και των χρόνων επίλυσης των μοντέλων ανίχνευσης τοπολογίας.

Ο κύριος στόχος της εργασίας είναι η ανάπτυξη ενός συνελκτικού νευρωνικού δικτύου (Convolution Neural Network – CNN) που βασίζεται στη μεθοδολογία αντιστοίχισης πυρήνα – κόμβου για τη δημιουργία του δικτύου (Kernel-Node-Map-Deep-Network - KNDN), μιας προσέγγισης του προβλήματος ανίχνευσης τοπολογίας που εντοπίστηκε στην βιβλιογραφική ανασκόπηση. Η προσέγγιση αυτή βασίζεται στην αντιστοίχιση της αρχιτεκτονικής του δικτύου με τη φυσική τοπολογία του συστήματος διανομής ηλεκτρικής ενέργειας. Αυτή η μέθοδος ουσιαστικά αντιστοιχίζει τα δεδομένα από τις μονάδες D-PMUs σε εκτιμήσεις για την τρέχουσα τοπολογία του δικτύου. Η μέθοδος αυτή χειρίζεται τα δεδομένα εισόδου δομώντας τα με τρόπο που τα αντιστοιχεί στη διάταξη του δικτύου, ενισχύοντας έτσι την ικανότητα του CNN να μαθαίνει από τα μοτίβα των ηλεκτρικών ροών του δικτύου.

Ο έλεγχος του μοντέλου που αναπτύχθηκε πραγματοποιήθηκε χρησιμοποιώντας το τροποποιημένο σύστημα διανομής IEEE 33-bus με 9 διακόπτες σε περιβάλλον προσομοίωσης Matlab. Για να επιτευχθεί αυτό, πρώτα προσδιορίστηκαν οι εφικτές τοπολογίες. Στη συνέχεια, επιλύθηκαν οι εξισώσεις ροής ισχύος χρησιμοποιώντας εργαλεία του MATPOWER. Τέλος, εισήχθη σφάλμα μέτρησης στις λύσεις των εξισώσεων ροής ισχύος για να προσομοιωθούν πραγματικές μετρήσεις των μονάδων D-PMUs. Επιπλέον, αναπτύχθηκε ένα νευρωνικό δίκτυο MLP (Multilayer Perceptron) και έγινε σύγκριση των αποτελεσμάτων των δύο μοντέλων.

Η εργασία δείχνει ότι το μοντέλο KNDN προσφέρει μια ακριβή και αποδοτική μεθοδολογία για την ανίχνευση τοπολογίας, γεγονός που ευθυγραμμίζεται με την βιβλιογραφία που μελετήθηκε. Αυτή η προσέγγιση όχι μόνο ενισχύει την αξιοπιστία και την ασφάλεια των δικτύων διανομής ηλεκτρικής ενέργειας αλλά υποστηρίζει επίσης τη συνεχιζόμενη μετάβαση προς πιο αποκεντρωμένα και δυναμικά ενεργειακά συστήματα. Μελλοντικές προεκτάσεις περιλαμβάνουν την εκπαίδευση του μοντέλου σε πραγματικά δεδομένα μονάδων D-PMUs για διαφορετικές τοπολογίες, την ανάπτυξη αλγορίθμου για αυτόματη αναδιάταξη δεδομένων εισόδου για την αξιοποίησή του σε μεγάλα δίκτυα διανομής καθώς και την διερεύνηση της χρήσης γραφικών νευρωνικών δικτύων (Graph Neural Networks).

Λέξεις κλειδιά: πρόβλημα ανίχνευσης τοπολογίας δικτύου σε πραγματικό χρόνο, μονάδες μέτρησης φασιθετών στα δίκτυα διανομής, βαθύ δίκτυο αντιστοίχισης πυρήνα – κόμβου, βαθιά συνελκτικά νευρωνικά δίκτυα

Abstract

This dissertation treats a methodology for real-time topology detection (TD) in power distribution systems, an area that has become increasingly critical with the integration of distributed energy resources and dynamic load changes. Traditional TD methods, largely reliant on state estimations and historical data, struggle to keep pace with the rapid transformations in power system configurations. This study capitalizes on the advent of distribution phasor measurement units (D-PMUs), which provide time-synchronized data, offering a new frontier for the application of deep learning techniques to improve TD accuracy and response times.

The main goal of this dissertation is the development of the Kernel-Node-Map Deep Network (KNDN), a TD approach found in the bibliography utilizing a deep convolutional neural network (CNN) framework. This approach lies in the kernel-node-map concept, which aligns the network's architecture with the physical topology of the power distribution system. KNDN effectively translates the data from D-PMUs into insights about the network's topology. The kernel-node-map concept redefines input data handling by structuring it in a way that mirrors the network's layout, thereby enhancing the CNN's ability to learn from patterns in electrical flows.

The validation of the KNDN developed were performed using modified IEEE 33-bus distribution system with 9 switches in Matlab simulation environment. To achieve that, the feasible topologies were first specified. Then, power flow equations were resolved using MATPOWER tools. In the end, measurement error was introduced to the power flow equations solutions to simulate actual D-PMUs measurements. Furthermore, a MLP neural network was also developed and the results from the two models were compared.

This dissertation shows that KNDN model shows better accuracy. By integrating deep learning with high-fidelity phasor measurement data, the KNDN method offers a powerful tool for real-time, accurate, and efficient topology detection. These results are aligned with the bibliography that was studied. This approach not only enhances the reliability and security of power distribution networks but also supports the ongoing transition towards more decentralized and dynamic power systems. Future work will focus on exploring the model's applicability to real-world datasets from D-PMUs across diverse grid configurations, the development of an optimal algorithm to automatically rearrange input elements for more practical use of the KNDN in a large distribution system as well as explore the utilization of graphical neural networks.

key words: real-time topology detection (TD) problem, distribution phasor measurement units (D-PMU), Kernel-Node-Map Deep Network (KNDN), deep convolutional neural network, kernel-node-map concept

Ευχαριστίες

Η παρούσα διπλωματική εργασία εκπονήθηκε κατά το ακαδημαϊκό έτος 2023-2024 στα πλαίσια του Τομέα Ηλεκτρικής Ισχύος της Σχολής Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών του Εθνικού Μετσόβιου Πολυτεχνείου κατά τη διάρκεια της φοίτησής μου στο Διατμηματικό Μεταπτυχιακό Πρόγραμμα του ΕΜΠ «Παραγωγή και Διαχείρισης Ενέργειας».

Αρχικά θα ήθελα να ευχαριστήσω τον επιβλέποντα καθηγητή κ. Άρη – Ευάγγελο Δημέα για την ανάθεση της διπλωματικής εργασίας. Ιδιαίτερα θα ήθελα να ευχαριστήσω τον Διδάκτορα στον Τομέα Ηλεκτρικής Ισχύος κ. Θεμιστοκλή Ξύγκη και τον υποψ. διδάκτορα Κυριάκο Ανδρεσάκη για την καθοδήγηση, τη βοήθεια και την υπομονή τους σε όλη τη διάρκεια εκπόνησης της διπλωματικής εργασίας.

Στήριγμά μου όλα αυτά τα χρόνια είναι βεβαίως η οικογένειά μου. Οι γονείς μου, Γιώργος και Δέσποινα, η αδερφή μου Μαριλένα. Είναι όλοι τους πάντα εκεί για μένα, έστω και αν μας χωρίζουν κάποια εκατοντάδες χιλιόμετρα την τελευταία δεκαετία. Μου πρόσφεραν αμέριστη, πολυεπίπεδη στήριξη όλα αυτά τα χρόνια του προπτυχιακού όσο και του μεταπτυχιακού προγράμματος.

Βεβαίως θα ήθελα να ευχαριστήσω την δεύτερη οικογένειά μου, τους φίλους μου, όλους όσοι διανύσαμε μαζί, δίπλα δίπλα, μέρα με τη μέρα, αυτά τα όμορφα φοιτητικά χρόνια, μοιραζόμενοι τις ίδιες αγωνίες και χαρές. Ιδιαίτερα θα ήθελα να αναφερθώ για την στήριξή τους το τελευταίο απαιτητικό δίχρονο του μεταπτυχιακού προγράμματος στους: Γιώργο Β. , Νίκο Κ., Μαρία Π.Μ., Μελίνα Ρ.

Καθώς αυτές οι ευχαριστίες γράφονται τις μέρες που υπηρετώ την στρατιωτική μου θητεία στον ακριτικό Έβρο, θα ήταν παράλειψη να μην αναφερθώ και σε όλους αυτούς με τους οποίους μοιράζομαι την καθημερινότητα μαζί τους αυτούς τους μήνες και την κάνουν να αξίζει. Ξέρουν αυτοί.

Αντώνης Μοχιανάκης Καραμπατζάκης

Οκτώβριος 2024

Περιεχόμενα

Περίληψη.....	5
Abstract.....	6
Κατάλογος σχημάτων	9
1. Εισαγωγή.....	11
1.1 Αντικείμενο της εργασίας.....	11
1.2 Δομή της εργασίας	11
2. Δίκτυα Διανομής Ενέργειας.....	13
2.1 Συστήματα Ηλεκτρικής Ενέργειας	13
2.2 Δίκτυο Διανομής Ενέργειας	14
2.3 Έξυπνα δίκτυα: «πράσινη μετάβαση» και «ψηφιακός μετασχηματισμός»	15
2.4 Ροή φορτίου.....	20
2.5 Εξοπλισμός δικτύου - PMUs.....	20
3. Τεχνητή Νοημοσύνη	23
3.1 Τεχνητή Νοημοσύνη	23
3.2 Μηχανική Μάθηση	24
3.3 Νευρωνικά Δίκτυα.....	28
3.4 Βασικές υπερπαράμετροι νευρωνικών δικτύων	30
3.5 Φαινόμενα Underfitting και Overfitting και η αντιμετώπισή τους.....	32
3.6 Διαχωρισμός Συνόλου Δεδομένων	33
3.7 Συνελκτικά Νευρωνικά Δίκτυα (Convolution Neural Networks)	35
3.7 Εφαρμογές Τεχνητής Νοημοσύνης στα «Έξυπνα Δίκτυα»	38
4. Ανίχνευση Τοπολογίας (Topology Detection)	43
4.1 Ορισμός προβλήματος – βιβλιογραφική ανασκόπηση.....	43
4.2. Η μέθοδος αντιστοίχισης πυρήνα – κόμβου (kernel – node mapping).....	45
5. Δημιουργία συνόλου δεδομένων.....	47
5.1 Εντοπισμός εφικτών τοπολογιών στο testbed modified IEEE 33 bus system	47
5.2 Προσομοίωση στο περιβάλλον Matlab	50
6. Υλοποίηση μοντέλων	59
6.1 Δεδομένα εισόδου-εξόδου	59
6.2 Κύριος κώδικας	62
6.3 Βασικές συναρτήσεις – υπερπαράμετροι	62
6.4 Κριτήρια ακριβείας μοντέλου	68

6.5. Αποτελέσματα μοντέλων	69
6.6 Σύγκριση - Συμπεράσματα	71
7. Μελλοντικές προεκτάσεις	73
Βιβλιογραφία	77

Κατάλογος σχημάτων

Figure 1 Το δίκτυο ηλεκτρισμού στην Ελλάδα όπως απεικονίζεται στην ιστοσελίδα του ΔΕΔΔΗΕ [4]	14
Figure 2 Ψηφιακά εργαλεία για τα έξυπνα δίκτυα, από την έκθεση του IEA [9].....	15
Figure 3 Σχηματικό διάγραμμα μιας PMU που συνδέεται στο ηλεκτρικό δίκτυο [22]	21
Figure 4 Σχέση Τεχνητής νοημοσύνης, Μηχανικής Μάθησης και Βαθιάς Μάθησης [28]	24
Figure 5 Τύποι μηχανικής μάθησης [32]	25
Figure 6 Δομή ενός τεχνητού νευρωνικού δικτύου	28
Figure 7 Δομή ενός MLP νευρωνικού [33]	29
Figure 8 Τεχνικές επιβλεπόμενης μάθησης που χρησιμοποιούνται ευρέως στα έξυπνα δίκτυα [35]	30
Figure 9 Γραφικές που αποτυπώνουν το φαινόμενο α)underfit β)επιτυχούς εκπαίδευσης γ)overfit [39]	33
Figure 10 Διαχωρισμός συνόλου δεδομένων και η χρήση του στο μοντέλο μηχανικής μάθησης [45]	35
Figure 11 Τυπική αρχιτεκτονική ενός CNN [48]	37
Figure 12 Σχήμα για την εφαρμογή της διαδικασίας εξαγωγής χαρακτηριστικών σε ένα σύνολο δεδομένων που τροφοδοτεί ένα μοντέλο ταξινόμησης [49]	38
Figure 13 Νέα καθήκοντα για τους διαχειριστές δικτύου. Το παράδειγμα της Γερμανίας [53] ..	40
Figure 14 Μεθοδολογία αντιστοίχισης πυρήνα – κόμβου [54].....	46
Figure 15 Σχεδιάγραμμα του modified IEEE 33 bus system.....	47
Figure 16 ο γράφος που αναπαριστά την τοπολογία 1.....	49
Figure 17 Στιγμιότυπα από τα αποτελέσματα της εκτέλεσης της εντολής runpf (1/3)	55
Figure 18 Στιγμιότυπα από τα αποτελέσματα της εκτέλεσης της εντολής runpf (2/3)	56
Figure 19 Στιγμιότυπα από τα αποτελέσματα της εκτέλεσης της εντολής runpf (3/3).....	57
Figure 20 Στιγμιότυπο από τον κώδικα σε προγραμματιστικό περιβάλλον Matlab για την δημιουργία του dataset.....	58
Figure 21 Ανακατανομή στοιχείων εισόδου με βάση την μεθοδολογία αντιστοίχισης πυρήνα – κόμβου [54].....	60
Figure 22 Δομή του KNDN αλγορίθμου [54]	60
Figure 23 Αντιστοίχιση δεδομένων εισόδου με υπογράφους του δικτύου [54]	61
Figure 24 Η συνάρτηση που πραγματοποιεί την εκπαίδευση του μοντέλου.....	62
Figure 25 Η συνάρτηση custom_stratified_split	64
Figure 26 Οι συναρτήσεις που υπολογίζουν την ακρίβεια πρόβλεψης κατάστασης διακόπτη και της ακριβείας πρόβλεψης του μοντέλου	65
Figure 27 Οι συναρτήσεις reduce_lr και EarlyStopping.....	65
Figure 28 Καμπύλη loss over epochs για το CNN.....	70
Figure 29 Καμπύλη loose accuracy over epochs για το CNN	70

[Αυτή η σελίδα είναι σκόπιμα λευκή]

1. Εισαγωγή

1.1 Αντικείμενο της εργασίας

Τα σύγχρονα δίκτυα διανομής έχουν να αντιμετωπίσουν πολλές προκλήσεις που θέτει η ενεργειακή μετάβαση, η κυριαρχία των διεσπαρμένων πηγών παραγωγής ενέργειας, η απαίτηση για υψηλή αξιοπιστία και ανθεκτικότητα των ενεργειακών υποδομών. Σε αυτά τα πλαίσια μετάβασης στα «έξυπνα δίκτυα» προκειμένου να επιτευχθούν αυτοί οι στόχοι, πολλαπλασιάζονται οι εφαρμογές της τεχνητής νοημοσύνης στα δίκτυα μεταφοράς και διανομής.

Η διπλωματική εργασία διερευνά το πρόβλημα ανίχνευσης τοπολογίας σε πραγματικό χρόνο στα συστήματα διανομής ηλεκτρικής ενέργειας, χρησιμοποιώντας τεχνολογία βαθιάς μάθησης. Επικεντρώνεται στην ανάπτυξη ενός συνελκτικού νευρωνικού δικτύου (CNN) που βασίζεται στη μεθοδολογία αντιστοίχισης πυρήνα-κόμβου, η οποία ενισχύει την ακρίβεια και την ταχύτητα ανίχνευσης τοπολογιών χρησιμοποιώντας δεδομένα από μονάδες μέτρησης φασιθετών (D-PMUs). Στα πλαίσια της εργασίας αξιοποιήθηκαν δεδομένα που παρήχθησαν από προσομοιώσεις σε προγραμματιστικό περιβάλλον Matlab. Η μεθοδολογία αυτή δοκιμάστηκε σε ένα τροποποιημένο σύστημα διανομής (modified IEEE 33 bus system) και αποδείχθηκε ότι προσφέρει βελτιωμένη εκτίμηση της τοπολογίας σε σχέση με ένα παραδοσιακό νευρωνικό MLP.

1.2 Δομή της εργασίας

Η εργασία δομείται σε 6 κεφάλαια:

- Στο **Κεφάλαιο 1** παρουσιάζεται το αντικείμενο και η δομή της εργασίας
- Στο **Κεφάλαιο 2** παρουσιάζονται συνοπτικά βασικά στοιχεία για τα σύγχρονα δίκτυα ηλεκτρικής ενέργειας και κάποιες από τις προκλήσεις που αντιμετωπίζουν οι διαχειριστές τους στα πλαίσια της πράσινης και ψηφιακής μετάβασης.
- Στο **Κεφάλαιο 3** παρουσιάζονται συνοπτικά βασικές γνώσεις που αφορούν την τεχνητή νοημοσύνη, τη μηχανική μάθηση και τα νευρωνικά δίκτυα. Ιδιαίτερο βάρος δίνεται στην περιγραφή των συνελκτικών νευρωνικών δικτύων, καθώς και εφαρμογών της τεχνητής νοημοσύνης στα ενεργειακά δίκτυα.
- Στο **Κεφάλαιο 4** παρουσιάζεται το πρόβλημα της ανίχνευσης τοπολογίας δικτύου, πραγματοποιείται βιβλιογραφική ανασκόπηση και περιγράφεται η μέθοδος της αντιστοίχισης πυρήνα – κόμβου.
- Στο **Κεφάλαιο 5** αναλύεται ο τρόπος επιλογής, ανάλυσης και επεξεργασίας των δεδομένων που χρησιμοποιήθηκαν για την εκπαίδευση και την επαλήθευση του

μοντέλου, μέσα από την πραγματοποίηση προσομοιώσεων στο περιβάλλον Matlab.

- Στο **Κεφάλαιο 6** παρουσιάζονται τα μοντέλα που υλοποιήθηκαν: ένα συνελκτικό νευρωνικό δίκτυο (CNN) και ένα νευρωνικό δίκτυο MLP. Γίνεται σύγκριση των αποτελεσμάτων τους.
- Στο **Κεφάλαιο 7** παρουσιάζονται τα συμπεράσματα της εργασίας και προτείνονται μελλοντικές προεκτάσεις.
- Τέλος, παρουσιάζεται η βιβλιογραφία που αξιοποιήθηκε για την συγγραφή της παρούσας εργασίας.

2. Δίκτυα Διανομής Ενέργειας

2.1 Συστήματα Ηλεκτρικής Ενέργειας

Ως **Σύστημα Ηλεκτρικής Ενέργειας** (ΣΗΕ) ορίζεται το σύστημα των εγκαταστάσεων και των μέσων που χρησιμοποιούνται για την παροχή ηλεκτρικής ενέργειας σε περιοχές εξυπηρέτησης. Βασικές προϋποθέσεις καλής λειτουργίας ενός ΣΗΕ είναι να παρέχει ηλεκτρική ενέργεια όπου υπάρχει ζήτηση με το ελάχιστο δυνατό κόστος και τις ελάχιστες επιπτώσεις στο περιβάλλον, εξασφαλίζοντας **σταθερή τάση, σταθερή συχνότητα και υψηλή αξιοπιστία τροφοδότησης**. [1]

Σε ένα ΣΗΕ διακρίνονται τρία επιμέρους συστήματα: το σύστημα παραγωγής, το δίκτυο Μεταφοράς και το δίκτυο διανομής. [2] Το **σύστημα παραγωγής** περιλαμβάνει τους σταθμούς παραγωγής ηλεκτρικού ρεύματος και τους μετασχηματιστές ανύψωσης τάσης για τη μεταφορά του ρεύματος υπό Υπερύψηλή ή Υψηλή Τάση. Το **σύστημα μεταφοράς** διασυνδέει όλους τους μεγάλους σταθμούς παραγωγής καθώς και διαφορετικά ΣΗΕ μεταξύ τους και μεταφέρει μεγάλες τιμές ισχύος σε μεγάλες αποστάσεις προς τα κέντρα κατανάλωσης. Περιλαμβάνει τις γραμμές υπερυψηλής και υψηλής τάσης, τους υποσταθμούς ζεύξης των δικτύων αυτών και τους υποσταθμούς μετασχηματισμού μεταξύ των διαφορετικών επιπέδων τάσης που αξιοποιούνται. Μπορεί να παρομοιαστεί ως η «σπονδυλική στήλη» του ΣΗΕ. Το **σύστημα διανομής** περιλαμβάνει τις γραμμές μέσης τάσης και χαμηλής τάσης, καθώς και τους υποσταθμούς που υποβιβάζουν την Μέση Τάση σε Χαμηλή Τάση. Μέσω αυτού του δικτύου η ηλεκτρική ενέργεια τροφοδοτεί καταναλωτές Μέσης και Χαμηλής Τάσης.

Ένα ΣΗΕ ενδέχεται να λειτουργεί απομονωμένο ή διασυνδεδεμένο με ένα ή περισσότερα γειτονικά συστήματα. Η διασύνδεση γίνεται τις περισσότερες φορές σε εθνικό επίπεδο αλλά υπάρχουν και διεθνείς διασυνδέσεις προσφέροντας τεχνικά και οικονομικά πλεονεκτήματα.

Τα τρία βασικά μεγέθη με βάση τα οποία σχεδιάζεται ένα ΣΗΕ είναι: η **τάση του δικτύου** (η μέγιστη τάση λειτουργίας των γραμμών), η **ισχύς βραχυκύκλωσης** του δικτύου (η συμβατική ισχύς που αντιστοιχεί στη μέγιστη ισχύ που αποδίδεται στο δίκτυο σε περίπτωση τριφασικού βραχυκυκλώματος σε κάποιο σημείο του) και η **στάθμη μόνωσης** του δικτύου (η τιμή της κρουστικής αντοχής του δικτύου, δηλαδή η διηλεκτρική αντοχή της μόνωσης του εξοπλισμού των υποσταθμών σε κρουστικές υπερτάσεις τυποποιημένης μορφής) [3].




Figure 1 Το δίκτυο ηλεκτρισμού στην Ελλάδα όπως απεικονίζεται στην ιστοσελίδα του ΔΕΔΔΗΕ [4]

2.2 Δίκτυο Διανομής Ενέργειας

Στην Ελλάδα, το Δίκτυο Διανομής απαρτίζεται από το δίκτυο Μέσης Τάσης και Χαμηλής Τάσης, τους Υποσταθμούς Μέσης Τάσης των 20 kV/0.4 kV, τις εναέριες γραμμές, τα καλώδια Μέσης Τάσης και Χαμηλής Τάσης, καθώς και το σχετικό εξοπλισμό προστασίας και ελέγχου. Στο Δίκτυο Διανομής συνδέονται οι καταναλωτές Μέσης Τάσης (20 kV) και οι καταναλωτές Χαμηλής Τάσης (230, 400 V). [5] [6]

Στα **ακτινικά Δίκτυα Διανομής** οι γραμμές των 20 kV αναχωρούν από τον κεντρικό υποσταθμό 150/20 kV και αναπτύσσονται ακτινικά. Κατά μήκος κάθε γραμμής συνδέονται μετασχηματιστές 20/0.4 kV των δικτύων Χαμηλής Τάσης ή καταναλωτές Μέσης Τάσης (πχ. μεγάλες ελληνικές επιχειρήσεις Βιομηχανικής και Εμπορικής χρήσης). Μια βασική πρόκληση για τα ακτινικά Δίκτυα Διανομής παρουσιάζεται όταν σε περίπτωση σφάλματος στο μήκος της γραμμής, ο διακόπτης ισχύος που υπάρχει στην αρχή της γραμμής ανοίγει με αποτέλεσμα όλοι οι μετασχηματιστές που βρίσκονται κατά μήκος της γραμμής να μένουν χωρίς τροφοδοσία. Συνήθως, κρίσιμα φορτία (ενδεικτικά πχ: βιομηχανίες, κρίσιμες υποδομές όπως στρατιωτικές εγκαταστάσεις, πολιτική προστασία, νοσοκομεία κτλ) τροφοδοτούνται με τοπικό ηλεκτροπαραγωγό ζεύγος (πχ ντιζελογεννήτρια).

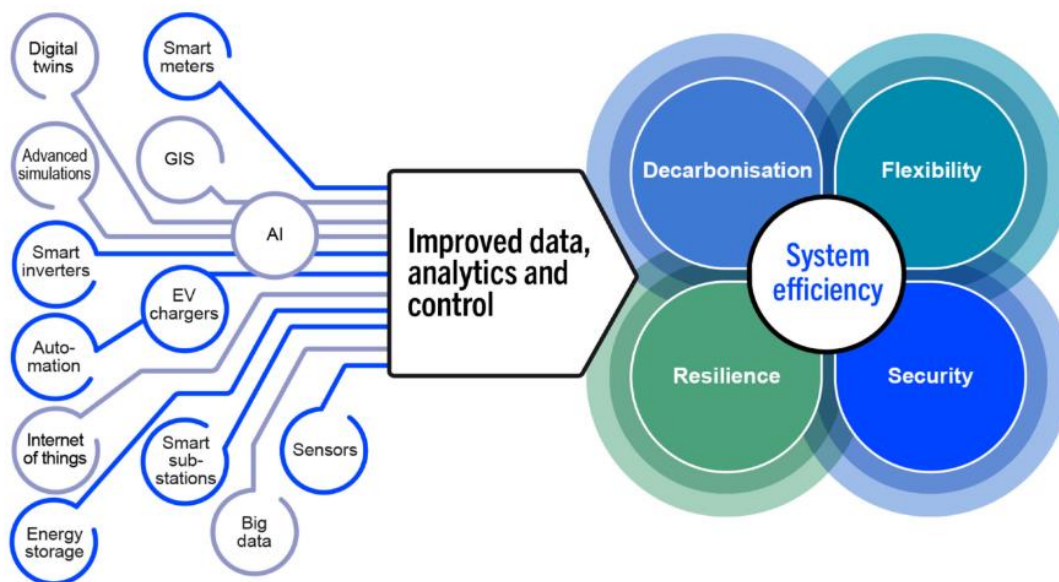
Με βάση τα στοιχεία του ΔΕΔΔΗΕ για το 2020 [6] το δίκτυο Μέσης Τάσης (ΜΤ) εκτείνεται **113.358 χλμ** ενώ το δίκτυο Χαμηλής Τάσης (ΧΤ) εκτείνεται **128.211 χλμ**. Επομένως το συνολικό μήκος του δικτύου διανομής ανέρχεται στα **241.569 χλμ**. Παράλληλα λειτουργούν **165.290** Υποσταθμοί Μέσης Τάσης προς Χαμηλή Τάση (Υ/Σ ΜΤ/ΧΤ), **993 χλμ**. Δίκτυο Υψηλής Τάσης (Υ.Τ.) εκ των οποίων **218 χλμ** στην Αττική και **775 χλμ** στα μη διασυνδεδεμένα νησιά, **241** Υποσταθμοί Υψηλής Τάσης προς Μέση Τάση (Υ/Σ ΥΤ/ΜΤ).

2.3 Έξυπνα δίκτυα: «πράσινη μετάβαση» και «ψηφιακός μετασχηματισμός»

Τα ΣΗΕ παίζουν ζωτικό ρόλο στις σύγχρονες κοινωνίες και οικονομίες. Μέσα από αυτά παράγεται, μεταφέρεται και διανέμεται η απαραίτητη ηλεκτρική ενέργεια για τη βιομηχανία, όλες τις παραγωγικές δραστηριότητες και την οικιακή κατανάλωση. Η ποικιλία των καθημερινών δραστηριοτήτων που απαιτούν τη χρήση ηλεκτρικής ενέργειας αρκεί για να γίνει αντιληπτή η σημασία τους. Η παροχή ηλεκτρικής ενέργειας συνδέεται άμεσα με το βιοτικό επίπεδο, την ποιότητα ζωής, όπως μαρτυρούν και οι συνθήκες ζωής 759 εκατομμυρίων ανθρώπων που ζουν χωρίς πρόσβαση στην ηλεκτρική ενέργεια [7]. Για όλους τους παραπάνω λόγους τα ενεργειακά δίκτυα εντάσσονται στις κρίσιμες υποδομές κάθε κράτους [8].

Είναι κοινώς αποδεκτό ότι οι προκλήσεις που καλούνται να διαχειριστούν σήμερα οι διαχειριστές των ενεργειακών δικτύων είναι άμεσα συνδεδεμένες με την ενεργειακή πολιτική που ασκείται [9]. Όπως τεκμηριώνεται συνοπτικά στη συνέχεια του κειμένου, η ταχεία τεχνολογική εξέλιξη, οι αυξημένες απαιτήσεις για αποδοτικότητα, αξιοπιστία, ανθεκτικότητα (resilience), η «πράσινη μετάβαση» και η διάδοση των διεσπαρμένων πηγών ενέργειας στο έδαφος της απελευθέρωσης του τομέα ηλεκτρικής ενέργειας και της ενίσχυσης της εμπορευματοποίησης της είναι οι κύριοι παράγοντες (“drivers”) που επιτάσσουν τον εκσυγχρονισμό των ηλεκτρικών δικτύων. Στην παράγραφο αυτή της διπλωματικής εργασίας εξετάζεται ο εκσυγχρονισμός αυτός, με επίκεντρο την ψηφιοποίηση και τα έξυπνα δίκτυα (smart grids).

Digital solutions for clean energy and system-wide efficiency



IEA. CC BY 4.0.

Figure 2 ψηφιακά εργαλεία για τα έξυπνα δίκτυα, από την έκθεση του IEA [9].

Συνοπτικά, η έννοια του «έξυπνου δικτύου» αναφέρεται στη μετάβαση από το παραδοσιακό ηλεκτρικό δίκτυο που ελέγχεται ηλεκτρολογικά-μηχανικά σε δίκτυο που ελέγχεται ηλεκτρονικά. Ο όρος Smart Grid εμφανίστηκε για πρώτη φορά στη νομοθεσία των ΗΠΑ το 2007 [10] όπου αναφερόταν (μετάφραση από τα αγγλικά):

«Η πολιτική των Ηνωμένων Πολιτειών είναι να υποστηρίξει την εκσυγχρονισμό του συστήματος μεταφοράς και διανομής ηλεκτρικής ενέργειας της χώρας για να διατηρήσει μια αξιόπιστη και ασφαλή υποδομή ηλεκτρικής ενέργειας που μπορεί να ανταποκριθεί στην αυξημένη ζήτηση στο μέλλον και να επιτύχει τα εξής, τα οποία μαζί χαρακτηρίζουν ένα Έξυπνο Δίκτυο:

- 1. Αυξημένη χρήση ψηφιακής πληροφορίας και τεχνολογίας ελέγχου για τη βελτίωση της αξιοπιστίας, της ασφάλειας και της αποδοτικότητας του ηλεκτρικού δικτύου.*
- 2. Δυναμική βελτιστοποίηση των λειτουργιών και των πόρων του δικτύου, με πλήρη κυβερνοασφάλεια.*
- 3. Ανάπτυξη και ενσωμάτωση διασκορπισμένων πόρων και παραγωγής, συμπεριλαμβανομένων των ανανεώσιμων πηγών.*
- 4. Ανάπτυξη και ενσωμάτωση πόρων απόκρισης της ζήτησης, πόρων στο πλευρό της ζήτησης και πόρων ενεργειακής απόδοσης.*
- 5. Ανάπτυξη τεχνολογιών «έξυπνων» (σε πραγματικό χρόνο, αυτοματοποιημένες, διαδραστικές τεχνολογίες που βελτιστοποιούν τη φυσική λειτουργία των συσκευών και των συσκευών καταναλωτών) για τη μέτρηση, την επικοινωνία σχετικά με τις λειτουργίες και την κατάσταση του δικτύου, και την αυτοματοποίηση της διανομής.*
- 6. Ενσωμάτωση «έξυπνων» συσκευών και συσκευών καταναλωτών.*
- 7. Ανάπτυξη και ενσωμάτωση προηγμένων τεχνολογιών αποθήκευσης ηλεκτρικής ενέργειας και τεχνολογιών εξομάλυνσης αιχμών, συμπεριλαμβανομένων των ηλεκτρικών και υβριδικών ηλεκτρικών οχημάτων και των κλιματιστικών με θερμική αποθήκευση.*
- 8. Παροχή έγκαιρων πληροφοριών και επιλογών ελέγχου στους καταναλωτές.*
- 9. Ανάπτυξη προτύπων για την επικοινωνία και τη διαλειτουργικότητα των συσκευών και των εξοπλισμών που συνδέονται με το ηλεκτρικό δίκτυο, συμπεριλαμβανομένης της υποδομής που υπηρετεί το δίκτυο.*
- 10. Αναγνώριση και μείωση των αδικαιολόγητων ή αναγκαίων εμποδίων στην υιοθέτηση τεχνολογιών, πρακτικών και υπηρεσιών έξυπνου δικτύου.»*

Από τότε μέχρι σήμερα βεβαίως οι εξελίξεις έχουν επιταχυνθεί. Για να κατανοηθεί το σύνθετο τοπίο στο οποίο καλούνται να δράσουν οι διαχειριστές δικτύων βοηθητικά είναι τα στοιχεία που συγκεντρώνει έκθεση της Deloitte [11] σύμφωνα με τα οποία μέχρι το 2030, θα έχουν συνδεθεί στο ευρωπαϊκό ενεργειακό δίκτυο: 40-50 εκατομμύρια αντλίες θερμότητας, 50-70 εκατομμύρια ηλεκτρικά αμάξια (από τα οποία το 50% θα πρέπει να μπορούν να φορτιστούν εκτός ορών αιχμής), +335 TWh επιπρόσθετης ζήτησης από τη βιομηχανία, +470 GW παραγωγής από ΑΠΕ (με το περίπου 70% να συνδέεται το δίκτυο διανομής), +40 GW αυτοκατανάλωση.

Αυτό που απασχολεί όλους τους εμπλεκόμενους στον τομέα της παραγωγής και μεταφοράς, διανομής ενέργειας, τις εταιρίες, διαχειριστές, τις Ρυθμιστικές Αρχές και τα νομοθετικά σώματα είναι ότι οι στόχοι της ενεργειακής μετάβασης, όπως η μείωση των εκπομπών CO₂ κατά 55% μέχρι το 2030, η αυξανόμενη ηλεκτροδότηση και η συμμετοχή των ανανεώσιμων πηγών ενέργειας πάνω από 40% απαιτούν ένα προσαρμοσμένο, οικονομικά προσιτό και ασφαλές δίκτυο ηλεκτρικής ενέργειας που προσαρμόζεται και αξιοποιεί τις καλύτερες διαθέσιμες τεχνολογίες.

Αυτές οι αναφορές μάλιστα έχουν ξεπεράσει τα πιο στενά όρια επιστημονικών συνεδριών ή των τεχνολογικών ιδρυμάτων και των πολυτεχνείων και έχουν βρει «χώρο» στο δημόσιο διάλογο, μέσα από παρεμβάσεις μεγάλων επιχειρηματιών και συγκροτημάτων τύπου που εκφράζουν και τα επιμέρους επιχειρηματικά συμφέροντα που δραστηριοποιούνται στην απελευθερωμένη αγορά ενέργειας. Σε αυτή την κατεύθυνση είναι χαρακτηριστική η παρέμβαση του ιδρυτή της Microsoft Bill Gates σε ένα άρθρο του που συζητήθηκε πολύ στο δημόσιο διάλογο [12] και ανέφερε emphaticά: «Το κλειδί – έκπληξη για ένα μέλλον καθαρής ενέργειας: Αν σε ενδιαφέρει η κλιματική αλλαγή, πρέπει να σε ενδιαφέρει η μεταφορά ενέργειας». Αντίστοιχα σε εξώφυλλο του τον Απρίλιο του 2023 το διάσημο περιοδικό Economist ανέφερε: «Αγκαλιάστε τους πυλώνες, όχι τα δέντρα» (Hug pylons, not trees) [13].

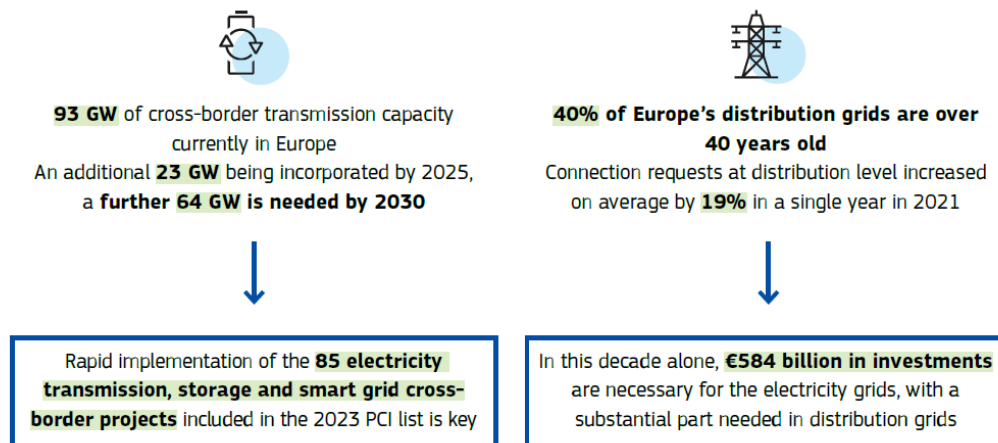
Σε αυτή τη συζήτηση τοποθετείται και η Ευρωπαϊκή Ένωση το 2023 διαμορφώνοντας σχέδιο δράσης («Grids, the missing link – An EU Action Plan for Grids») [14] που ανέφερε (οι υπογραμμίσεις του συγγραφέα):

*“Διασυνδεδεμένα και σταθερά δίκτυα ηλεκτρικής ενέργειας αποτελούν τη ραχοκοκαλιά μιας λειτουργικής αγοράς ενέργειας. Η Ευρωπαϊκή Ένωση διαθέτει ένα από τα πιο εκτεταμένα και ανθεκτικά δίκτυα ηλεκτρικής ενέργειας στον κόσμο, που εκτείνονται σε μήκος πάνω από **11 εκατομμύρια χιλιόμετρα** στην εσωτερική της αγορά και διασφαλίζοντας την παροχή ηλεκτρικής ενέργειας υψηλής ποιότητας στους καταναλωτές της καθημερινά.”*

«Παρά την πρόοδο αυτή, τα δίκτυα ηλεκτρικής ενέργειας της Ευρώπης αντιμετωπίζουν νέες και σημαντικές προκλήσεις. Θα πρέπει να ανταποκριθούν στην αυξανόμενη ζήτηση που συνδέεται με την «πράσινη» κινητικότητα, τη θέρμανση και ψύξη, την ηλεκτροκίνηση της βιομηχανίας και την έναρξη παραγωγής υδρογόνου χαμηλών εκπομπών. Αναμένεται να αυξηθεί η κατανάλωση ηλεκτρικής ενέργειας κατά περίπου 60% μεταξύ του παρόντος έτους και του 2030. Τα δίκτυα θα πρέπει επίσης να ενσωματώσουν ένα μεγάλο ποσοστό μεταβαλλόμενης ανανεώσιμης ενέργειας. Οι χωρητικότητες παραγωγής αιολικής και ηλιακής ενέργειας θα πρέπει να αυξηθούν από 400 GW το 2022 σε τουλάχιστον 1,000 GW έως το 2030, συμπεριλαμβανομένης μιας μεγάλης επέκτασης των ανανεώσιμων πηγών ενέργειας offshore έως 317 GW, που θα συνδεθούν στη στεριά. Επομένως, τα δίκτυα πρέπει να προσαρμοστούν σε ένα πιο αποκεντρωμένο, ψηφιοποιημένο και ευέλικτο σύστημα ηλεκτρικής ενέργειας με εκατομμύρια ηλιακά πάνελ σε στέγες και τοπικές ενεργειακές κοινότητες που μοιράζονται πόρους. (...)

Ειδικότερα, τα δίκτυα διανομής είναι προορισμένα να αναπτυχθούν και να αλλάξουν για να συνδέσουν μεγάλες ποσότητες αποκεντρωμένης ανανεώσιμης παραγωγής, καθώς

και νέα ευέλικτη ζήτηση ("φορτία"), όπως αντλίες θερμότητας και σταθμούς φόρτισης για ηλεκτρικά οχήματα. Αποκτούν νέους ρόλους, γίνονται διευκολυντές ("facilitators") μιας σειράς νέων λύσεων που απαιτεί το σύστημα. **Θα πρέπει να εξελιχθούν σε έξυπνα δίκτυα, να γίνουν ψηφιακά, να παρακολουθούνται σε πραγματικό χρόνο, να ελέγχονται απομακρυσμένα και να είναι κυβερνοασφαλή, με την έρευνα και την καινοτομία να διαδραματίζουν σημαντικό ρόλο.** Επιπλέον, περίπου το 40% των δικτύων διανομής στην Ευρώπη είναι πάνω από 40 χρόνια και χρειάζεται να εκσυγχρονιστεί. Οι εκτιμήσεις της βιομηχανίας υπολογίζουν ότι απαιτούνται περίπου 375-425 δισεκατομμύρια ευρώ επενδύσεις στα δίκτυα διανομής έως το 2030. **Συνολικά, η Επιτροπή εκτιμά ότι απαιτούνται 584 δισεκατομμύρια ευρώ επενδύσεις για τα ηλεκτρικά δίκτυα την τρέχουσα δεκαετία. Αυτό αντιπροσωπεύει σημαντικό μέρος των συνολικών επενδύσεων που απαιτούνται για την καθαρή μετάβαση στον τομέα της ηλεκτρικής ενέργειας.»**



Από φυλλάδιο της Ευρωπαϊκής Επιτροπής [15]

Στο ίδιο μήκος κύματος, ο **Διεθνής Οργανισμός Ενέργειας** (International Energy Agency – IEA) σε έκθεση της το 2023 αναφέρει [16]:

«Οι ψηφιακές τεχνολογίες και τα δεδομένα κρύβουν τεράστια δυναμική για την επιτάχυνση της μετάβασης προς καθαρή ενέργεια σε όλο τον ενεργειακό τομέα. Στα συστήματα ηλεκτρικής ενέργειας, οι ψηφιακές τεχνολογίες μπορούν να βοηθήσουν στην ένταξη αυξανόμενων ποσοστών ευμετάβλητων ανανεώσιμων πηγών και να βελτιώσουν την αξιοπιστία των δικτύων, ενώ στους τομείς των τελικών χρηστών μπορούν να βελτιώσουν την ενεργειακή απόδοση και την απόδοση των υλικών για να μειώσουν τις εκπομπές. (...) Οι πρόοδοι στις ψηφιακές τεχνολογίες και υπηρεσίες, η μείωση του κόστους και η πανταχού παρουσία συνδεσιμότητας έχουν επιταχύνει την ψηφιακή μετάβαση τα τελευταία χρόνια, ιδιαίτερα στα δίκτυα ηλεκτρικής ενέργειας. Η επένδυση σχετικά με το δίκτυο σε ψηφιακές τεχνολογίες έχει αυξηθεί κατά πάνω από

50% από το 2015 και αναμένεται να φτάσει το 19% της συνολικής επένδυσης στο δίκτυο το 2023. **Υπάρχει αυξανόμενη εστίαση στο δίκτυο διανομής, το οποίο τώρα αντιπροσωπεύει περισσότερο από το 75% των συνολικών ψηφιακών δαπανών.** Υπήρξε επίσης σημαντική αύξηση στην επένδυση σε υποδομή φόρτισης ηλεκτρικών οχημάτων, η οποία διπλασιάστηκε το 2022 σε σύγκριση με το προηγούμενο έτος. Ωστόσο, θα είναι απαραίτητες περαιτέρω προσπάθειες από τους πολιτικούς και τη βιομηχανία για να αξιοποιηθεί όλη η δυναμική της ψηφιοποίησης για την επιτάχυνση της μετάβασης σε καθαρή ενέργεια. Αυτό περιλαμβάνει την εφαρμογή επιτρεπτών προτύπων, πολιτικών και κανονισμών που προτεραιοποιούν την καινοτομία και τη διαλειτουργικότητα, ενώ αντιμετωπίζουν τους κινδύνους για την κυβερνοασφάλεια και την ιδιωτικότητα των δεδομένων».

Αντίστοιχα, σε πρόσφατη έκθεση του **ACER** (European Union Agency for the Cooperation of Energy Regulators) και του **CEER** (Council of European Energy Regulators) με τίτλο «Προκλήσεις των μελλοντικών ενεργειακών συστημάτων – Προτάσεις και δεσμεύσεις» (11 Ιουλίου 2024) αναφέρεται [17]:

«Τα δίκτυα διανομής είναι το εισιτήριο για την επίτευξη ενός ευέλικτου και απανθρακοποιημένου ενεργειακού συστήματος. Η απαλλαγή από τον άνθρακα και ο εξηλεκτρισμός θα οδηγήσουν σε σημαντικές αλλαγές στο επίπεδο της διανομής. Η πρόσθετη διεσπαρμένη παραγωγή και κατανάλωση θα δημιουργήσει περαιτέρω προκλήσεις για τα συστήματα διανομής ηλεκτρικής ενέργειας, τόσο σε ό,τι αφορά τη χωρητικότητα σύνδεσης όσο και στη διαχείριση των δυναμικών αμφίδρομων ροών ηλεκτρικής ενέργειας, ενώ ταυτόχρονα οφείλει να παραμένει ασφαλές και οικονομικά αποδοτικό. Όλο και περισσότερο, νέοι φορείς της αγοράς ενδέχεται να ζητήσουν δεδομένα δικτύου και κατανάλωσης για να παρέχουν υπηρεσίες διαχείρισης ενέργειας και ευελιξίας στους χρήστες του δικτύου και στους διαχειριστές συστημάτων. Οι διαχειριστές συστημάτων διανομής (DSO) θα αντιμετωπίσουν αρκετές προκλήσεις και διλήμματα, δηλαδή (i) επενδύοντας σε ενισχύσεις του δικτύου που απαιτούν μεγάλα κεφάλαια, όπως καλώδια/γραμμές και μετασχηματιστές· (ii) πραγματοποιώντας έξυπνες επενδύσεις για την αύξηση της χωρητικότητας και της ανθεκτικότητας του υπάρχοντος δικτύου· και (iii) ενθαρρύνοντας τους χρήστες του δικτύου να προσαρμόσουν τη ζήτηση ή την παραγωγή τους για να υποστηρίξουν το ηλεκτρικό σύστημα. Δύο μέτρα είναι απαραίτητα για την αντιμετώπιση αυτών των προκλήσεων. Πρώτον, οι ρυθμιστικές αρχές πρέπει να θεσπίσουν ένα κατάλληλο ρυθμιστικό πλαίσιο για τους DSO, ώστε να αναπτύξουν λύσεις για την αντιμετώπιση αυτών των προκλήσεων με οικονομικά αποδοτικό τρόπο. Δεύτερον, οι χονδρικές αγορές μπορούν να συμπληρωθούν με τοπικές αγορές για διεσπαρμένες υπηρεσίες ευελιξίας (distributed flexibility services).

Οι αλλαγές στα δίκτυα διανομής θα απαιτήσουν από τους DSO να αναλάβουν έναν πολύ πιο ενεργό ρόλο στη διευκόλυνση της αγοράς, παρέχοντας τα απαραίτητα δεδομένα/πληροφορίες αποδοτικά και ενεργοποιώντας διάφορες επικουρικές υπηρεσίες. Θα γίνει επομένως όλο και πιο σημαντικό οι DSO να είναι ανεξάρτητοι από οποιαδήποτε (κάθετα ολοκληρωμένα) περιουσιακά στοιχεία παραγωγής ή κατανάλωσης. Η διάσπαση της ιδιοκτησίας μεταξύ DSO και εταιρειών ενέργειας θα πρέπει να είναι ένας τρόπος για να επιτευχθεί αποτελεσματικά αυτή η ανεξάρτητη

παροχή δημόσιας υπηρεσίας. Όπου η διάσπαση της ιδιοκτησίας δεν είναι εφικτή ή κατάλληλη, θα πρέπει να αναπτυχθούν εναλλακτικές λύσεις για να διασφαλιστεί ότι οι DSO παρέχουν πλήρως ουδέτερη και μη διακριτική πρόσβαση τρίτων στο δίκτυό τους, να βελτιστοποιήσουν τις λειτουργίες, να εγγυηθούν την ουδετερότητα και να προωθήσουν τον ψηφιακό μετασχηματισμό.»

Σε αυτό το τοπίο εντάσσεται και η αξιοποίηση τεχνολογιών τεχνητής νοημοσύνης στα δίκτυα διανομής ενέργειας που απασχολεί και το θέμα της διπλωματικής εργασίας, όπως γίνεται αναφορά στην ενότητα 3.7 Εφαρμογές Τεχνητής Νοημοσύνης στα «Έξυπνα Δίκτυα».

2.4 Ροή φορτίου

Ροή φορτίου είναι η μελέτη της συμπεριφοράς ενός συστήματος ηλεκτρικής ενέργειας, που υφίσταται συγκεκριμένη φόρτιση, στη μόνιμη ημιτονοειδή κατάσταση λειτουργίας. Με βάση τη μελέτη ροής φορτίου υπολογίζονται οι τάσεις στους ζυγούς του ΣΗΕ, η ροή ισχύος στις γραμμές και τους μετασχηματιστές. Συνήθως πραγματοποιείται όταν σχεδιάζονται μεταβολές ή μελλοντικές επεκτάσεις σε ένα υπάρχον ΣΗΕ, όπως ανάπτυξη νέων μονάδων παραγωγής, η τροφοδοσία νέων φορτίων, όδευση νέων γραμμών μεταφοράς, η διασύνδεση με άλλα συστήματα. Ακόμα, πραγματοποιείται όταν χρειάζεται να καθοριστεί η βέλτιστη λειτουργία του συστήματος, να εκτιμηθεί η επίδραση που έχουν στο σύστημα διαφορετικές συνθήκες φόρτισης και για την εύρεση αρχικών τιμών που είναι απαραίτητες για άλλες μελέτες.

Για την επίλυση της ροής φορτίου απαιτείται η μαθηματική περιγραφή του προβλήματος και η εφαρμογή μιας αριθμητικής μεθόδου για την επίλυση των εξισώσεων που προκύπτουν. Η επίλυση των εξισώσεων χρειάζεται να ικανοποιεί περιορισμούς όπως το να μη γίνεται υπέρβαση των οριακών δυνατοτήτων των πηγών άεργου ισχύος, να μη γίνεται υπέρβαση των ορίων λήψης των μετασχηματιστών ελέγχου, να μην υπερφορτίζονται οι γραμμές και οι μετασχηματιστές, οι τάσεις των ζυγών να παραμένουν μέσα στα προδιαγεγραμμένα όρια [18]. Στις περισσότερες εφαρμογές αυτές οι εξισώσεις επιλύονται από αλγόριθμους σε περιβάλλοντα προσομοίωσης, όπως το MatPower της Matlab.

2.5 Εξοπλισμός δικτύου - PMUs

Κατά τη σταθερή κατάσταση σε ένα ηλεκτρικό σύστημα ισχύος, τα σήματα τάσης και ρεύματος διατηρούν σχεδόν ημιτονοειδείς μορφές κυμάτων. Ένας φασιθέτης ορίζεται ως το διάνυσμα που περιλαμβάνει τόσο το μέγεθος όσο και τη γωνία, αντανακλώντας μια ημιτονοειδή κυματομορφή. Για την παραγωγή του φασιθέτη από ένα σήμα, εφαρμόζονται μετασχηματισμοί Fourier χρησιμοποιώντας δείγματα δεδομένων που συλλέγονται εντός ενός συγκεκριμένου χρονικού διαστήματος. Σε σταθερή κατάσταση, το μέγεθος παραμένει σταθερό, ενώ η γωνία ποικίλλει ανάλογα με το σημείο έναρξης της δειγματοληψίας. Εφόσον η γωνία είναι σχετική μέτρηση, πρέπει να καθοριστεί ένα σημείο αναφοράς όπως αναφέρεται και στη συνέχεια [19] [20] [21].

Μια μονάδα μέτρησης φασιθέτη (phasor measurement units – εφεξής PMUs) είναι μια συσκευή που μετρά το μέγεθος και τη γωνία φάσης ενός ηλεκτρικού μεγέθους, όπως η τάση ή το ρεύμα, στο δίκτυο ηλεκτρικής ενέργειας. Οι συσκευές αυτές τοποθετούνται στρατηγικά σε όλο το ηλεκτρικό δίκτυο για να συλλέγουν τις κυματομορφές τάσης και ρεύματος. Αυτά τα δεδομένα χρησιμοποιούνται στη συνέχεια για τον υπολογισμό των φασιθετών. Ωστόσο, αν ο χρόνος των δειγμάτων που συλλέγονται από αυτές τις συσκευές δεν συγχρονιστεί με ένα κοινό σημείο αναφοράς, οι γωνίες των φασιθετών που υπολογίζονται σε διαφορετικές τοποθεσίες δεν θα είναι συγκρίσιμες, κάτι που εμποδίζει την ανάπτυξη προηγμένων εφαρμογών. Για να ξεπεραστεί αυτό το εμπόδιο, είναι κρίσιμο όλοι οι φασιθέτες που μετρούνται σε όλο το ηλεκτρικό δίκτυο να έχουν ένα κοινό χρονικό σημείο αναφοράς, ώστε να είναι δυνατή η άμεση σύγκριση. Αυτό συνήθως επιτυγχάνεται μέσω του δορυφορικού χρόνου αναφοράς GPS.

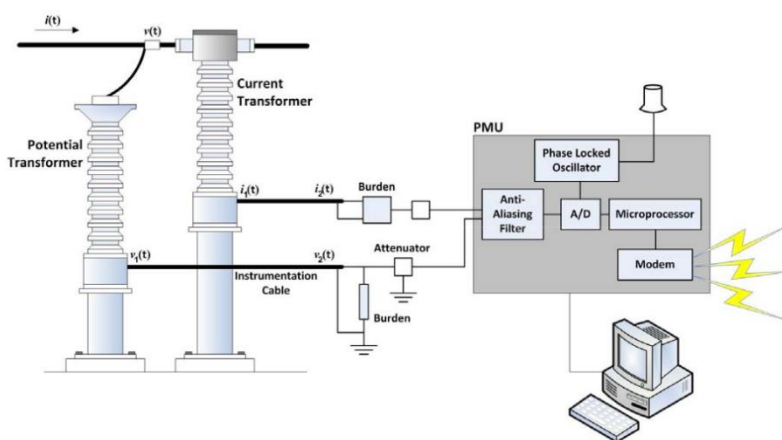


Figure 3 Σχηματικό διάγραμμα μιας PMU που συνδέεται στο ηλεκτρικό δίκτυο [22]

Η τεχνολογία των PMUs επιτρέπει να έχει ο διαχειριστής μια δυναμική εικόνα του δικτύου και θεωρείται πλέον από τα πιο σημαντικά εργαλεία για την επίβλεψη του συστήματος. Η ανάπτυξη προηγμένων συστημάτων μέτρησης και αυτοματισμών σε όλο το εύρος των ΣΗΕ αποτελεί προϋπόθεση για την μετάβαση στα ευφυή δίκτυα ηλεκτρισμού. Οι αυξημένες απαιτήσεις απομακρυσμένης εποπτείας και ελέγχου που επιτάσσει η διεσπαρμένη παραγωγή ηλεκτρικής ενέργειας εξυπηρετούνται από τον σταδιακό εκσυγχρονισμό του εξοπλισμού, αφού για να λειτουργούν σωστά τα ΣΗΕ χρειάζεται να εξασφαλίζεται σε επαρκή βαθμό η επίγνωση της κατάστασης του (situational awareness) κατά τη χρονική στιγμή μελέτης του. Δυστυχώς, τα δίκτυα διανομής έχουν περιορισμένο εξοπλισμό λόγω οικονομικών και τεχνικών περιορισμών που δεν επιτρέπουν την εγκατάσταση των D-PMUs (Distribution PMUs) σε κάθε ζυγό του δικτύου. Το πρόβλημα της βέλτιστης τοποθέτησής του εξοπλισμού μελετάται ερευνητικά [23] [24].

[Αυτή η σελίδα είναι σκόπιμα λευκή]

3. Τεχνητή Νοημοσύνη

3.1 Τεχνητή Νοημοσύνη

Η τεχνητή νοημοσύνη (TN) φαίνεται ότι είναι η τεχνολογία της εποχής μας και η ανάδειξή της σε οδηγό (“driver”) των τεχνολογικών εξελίξεων έχει οδηγήσει πολλούς να χαρακτηρίσουν την ανάπτυξη αυτών των τεχνολογιών συγκρίσιμη με την ανάπτυξη του ηλεκτρικού κινητήρα ή την εμφάνιση του διαδικτύου, μιλώντας για «4^η βιομηχανική επανάσταση».

Στις μέρες μας η TN είναι ήδη εδώ, ακόμα και αν στον καθημερινό πολίτη δεν είναι άμεσα προφανές. Ήδη πολλές εταιρίες, οργανισμοί και κράτη χρησιμοποιούν λογισμικά και εργαλεία που βασίζονται στην TN. Πρόσφατη έρευνα της PWC έδειξε ότι η TN θα συνεισφέρει έως το 2030 στην παγκόσμια οικονομία επιπλέον 15 τρισ. δολάρια [25].

Οι λόγοι για αυτή την γρήγορη ανάπτυξη είναι πολλοί. Συνοπτικά διακρίνονται δύο καταλυτικοί παράγοντες. Από τη μία πλευρά, το μέγεθος, η ποικιλία και οι ρυθμοί μεταφοράς των καταγεγραμμένων δεδομένων αυξάνονται κάθε χρόνο. Αυτό η τάση μας φέρνει στην εποχή των «**μεγάλων δεδομένων**» (**Big Data**) και ενθαρρύνει τη χρήση της τεχνητής νοημοσύνης, καθώς βασίζεται σε δεδομένα υψηλής ποιότητας και ακρίβειας. Από την άλλη πλευρά, η εκθετική πρόοδος στις **επιδόσεις υπολογισμού και αποθήκευσης** επιτρέπει όλο και περισσότερο την ευρεία χρήση της τεχνητής νοημοσύνης.

Ο όρος «τεχνητή νοημοσύνη» (TN) χρησιμοποιήθηκε για πρώτη φορά τη δεκαετία του 1950. Ωστόσο, υπάρχει μια μακρά και συνεχιζόμενη συζήτηση για το τι ακριβώς σημαίνει η τεχνητή νοημοσύνη. Συχνά η TN ορίζεται σε σύγκριση με την ανθρώπινη νοημοσύνη. Βεβαίως αυτή η προσέγγιση παρουσιάζει κινδύνους και αδυναμίες. Η ανθρώπινη νοημοσύνη σε άμεση συνάρτηση με την ανθρώπινη συνείδηση, δεν μπορεί να νοηθεί απλά ως ένα σύνολο υπολογιστικών ή γνωστικών ικανοτήτων, αλλά μπορεί να προσεγγιστεί μόνο ιστορικά – κοινωνικά, αφού ο εγκέφαλος του ανθρώπου ως όργανο σκέψης και διαμόρφωσης συνείδησης αναπτύσσεται και βελτιώνεται ιστορικά μέσα στη διαδικασία της κοινωνικής ζωής. Αυτό βέβαια αποτελεί φιλοσοφικό ζήτημα με πολλές προεκτάσεις, που δεν είναι στόχος της εργασίας να αναπτύξει και να διερευνήσει.

Ενδεικτικά αναφέρονται κάποιοι ορισμοί που δίνουν πολιτικοί οργανισμοί, όπως το Ευρωκοινοβούλιο, σύμφωνα με το οποίο η TN αναφέρεται στην ικανότητα μιας μηχανής να αναπαράγει τις γνωστικές λειτουργίες ενός ανθρώπου, όπως είναι η μάθηση, ο σχεδιασμός και η δημιουργικότητα [26]. Σύμφωνα με τεχνολογικά ινστιτούτα, η TN χρησιμοποιεί αυτοματισμούς για να αντικαταστήσει γνωστικές λειτουργίες που κανονικά θα έκαναν οι άνθρωποι [27]. Στην καρδιά αυτής της τεχνολογίας βρίσκεται η ιδέα της αυτοματοποίησης περίπλοκων τομέων γνωστικών εργασιών, χρησιμοποιώντας μηχανές που πλέον μπορούν να αναπτύξουν ικανότητες σε

τομείς όπως: η υπολογιστική όραση, η υπολογιστική ακοή, η γλωσσολογία, οι μαθηματικοί/λογικοί μηχανισμοί, οι διαπροσωπικά ευφυείς μηχανές, η κίνηση και η ρομποτική κ.α.

3.2 Μηχανική Μάθηση

Η ΤΝ είναι ένας συνολικός όρος που συνδυάζει πολλές διαφορετικές τεχνολογίες και υποκλάδους. Μεγάλο μέρος των προόδων στην ΤΝ βρίσκεται στη μηχανική μάθηση, σημαντικό υποκλάδο της ΤΝ. Η μηχανική μάθηση χρησιμοποιεί στατιστικές για να βρει μοτίβα σε μεγάλες ποσότητες δεδομένων και χρησιμοποιεί αυτά τα μοτίβα για να κάνει προβλέψεις. Οι τεχνικές ιδέες πίσω από τις περισσότερες εφαρμογές μηχανικής μάθησης υπάρχουν εδώ και πολλές δεκαετίες, αλλά τα τελευταία χρόνια η βελτίωση της υπολογιστικής ισχύος και η συγκέντρωση μεγάλων όγκων δεδομένων, όπως αναφέρθηκε και παραπάνω, επέτρεψε τη γιγάντωση εφαρμογών της.




Figure 4 Σχέση Τεχνητής νοημοσύνης, Μηχανικής Μάθησης και Βαθιάς Μάθησης [28]

Η μηχανική μάθηση μπορεί να οριστεί ευρέως ως μέθοδοι υπολογισμού χρησιμοποιώντας μαθηματικά μοντέλα και δεδομένα προκειμένου να γίνει μια ακριβής πρόβλεψη. Ο όρος πρωτοεμφανίστηκε με τον Arthur Samuel, ηλεκτρολόγο μηχανικό από το MIT, το 1959. Σύμφωνα με εκείνον, η μηχανική μάθηση ορίζεται ως «Το πεδίο μελέτης που δίνει στους υπολογιστές την ικανότητα να μαθαίνουν, χωρίς να έχουν ρητά προγραμματιστεί» [29]. Ζώντας στην εποχή των «Big Data», οι εφαρμογές Μηχανικής Μάθησης αυξάνονται, και πολλές μελέτες διενεργούνται από μαθηματικούς,

μηχανικούς και προγραμματιστές για την βελτιστοποίηση των χρησιμοποιούμενων αλγορίθμων, νέες εφαρμογές κτλ [30] [31].

Η Μηχανική Μάθηση βασίζεται σε διαφορετικούς αλγόριθμους για την επίλυση προβλημάτων δεδομένων, καθώς δεν υπάρχει ένας συγκεκριμένος ενιαίος τύπος αλγόριθμου που να είναι ο καλύτερος και να ταιριάζει σε οποιοδήποτε πρόβλημα. Αντιθέτως, το είδος του αλγορίθμου που χρησιμοποιείται εξαρτάται από το είδος του προβλήματος που καλείται να λύσει, τον αριθμό των μεταβλητών, το είδος του μοντέλου που θα του ταιριάζει καλύτερα και ούτω καθεξής.

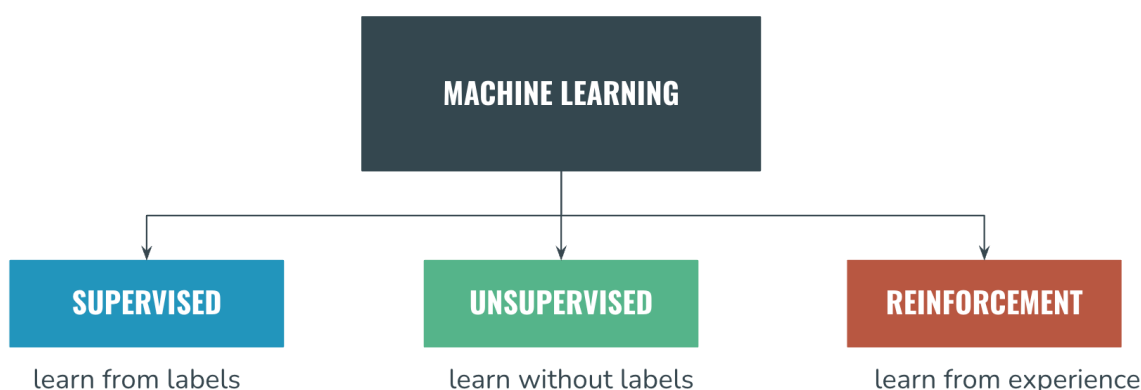


Figure 5 Τύποι μηχανικής μάθησης [32]

Με βάση τα παραπάνω ξεχωρίζουν οι παρακάτω τρεις πιο συχνές κατηγορίες αλγορίθμων:

- **Επιβλεπόμενη Μάθηση (Supervised Learning)**

Η επιβλεπόμενη μάθηση είναι μια κατηγορία μηχανικής μάθησης όπου μια συνάρτηση που σχετίζει μία είσοδο σε μία έξοδο, βασιζόμενη σε ζευγάρια εισόδου-εξόδου, χρησιμοποιεί ένα σύνολο μεγάλων δεδομένων εκπαίδευσης, το οποίο περιλαμβάνει εισόδους και σωστές εξόδους, οι οποίες επιτρέπουν στο μοντέλο να μαθαίνει με την πάροδο του χρόνου. Κατηγοριοποιείται σε δύο διαφορετικούς τύπους αλγορίθμων, την ταξινόμηση (classification), όπου οι αλγόριθμοι μαθαίνουν από τα δεδομένα προκειμένου να προβλέψουν ένα αποτέλεσμα και την παλινδρόμηση (regression), όπου οι αλγόριθμοι μαθαίνουν από τα δεδομένα προκειμένου να προβλέψουν συνεχείς τιμές.

Μερικοί από τους αλγορίθμους που χρησιμοποιούνται είναι: Μηχανές Διανυσμάτων Υποστήριξης (Support Vector Machines - SVM), Γραμμική Παλινδρόμηση (Linear Regression), Λογιστική Παλινδρόμηση (Logistic Regression), Δέντρα Αποφάσεων (Decision Trees), Νευρωνικά Δίκτυα (Neural Networks), ο αλγόριθμος Navie Bayes κ.α

Μια από τις πιο διαδεδομένες τεχνικές μηχανικής μάθησης είναι οι **Μηχανές Διανυσμάτων Υποστήριξης** (Support Vector Machines - SVM). Στην μηχανική μάθηση, οι SVMs είναι μοντέλα επιβλεπόμενης μάθησης με συναφείς αλγορίθμους μάθησης που αναλύουν δεδομένα που χρησιμοποιούνται για ταξινόμηση και ανάλυση παλινδρόμησης. Εκτός από την εκτέλεση γραμμικής ταξινόμησης, οι SVMs μπορούν να εκτελέσουν αποτελεσματικά μη γραμμική ταξινόμηση χρησιμοποιώντας αυτό που ονομάζεται “kernel trick”, αντιστοιχίζοντας αυτόματα τις εισόδους τους σε χώρους χαρακτηριστικών υψηλής διάστασης. Ουσιαστικά, οι SVMs δημιουργούν περιθώρια μεταξύ των κλάσεων. Τα περιθώρια σχεδιάζονται με τέτοιο τρόπο ώστε η απόσταση μεταξύ του περιθωρίου και των κλάσεων να είναι μέγιστη, μειώνοντας έτσι το σφάλμα ταξινόμησης.

Ένα **δέντρο απόφασης** είναι ένας γράφος που αναπαριστά επιλογές και τα αποτελέσματά τους σε μορφή δέντρου. Οι κόμβοι του γράφου αντιπροσωπεύουν γεγονότα ή επιλογές, και οι ακμές του διαγράμματος αντιπροσωπεύουν τους κανόνες ή τις συνθήκες λήψης αποφάσεων. Κάθε δέντρο αποτελείται από κόμβους και ακμές. Κάθε κόμβος αντιπροσωπεύει χαρακτηριστικά σε μια ομάδα που είναι προς ταξινόμηση, και κάθε ακμή αντιπροσωπεύει μια τιμή που μπορεί να λάβει ο κόμβος. Τα δέντρα αποφάσεων χρησιμοποιούνται ευρέως σε μη παραμετρικούς αλγορίθμους επιβλεπόμενης μάθησης για ταξινόμηση και πρόβλεψη. Είναι ιδιαίτερα χρήσιμα για την ανάλυση δεδομένων και τη λήψη αποφάσεων.

Ο αλγόριθμος **Navie Bayes** βασίζεται στο Θεώρημα του Bayes με την υπόθεση της ανεξαρτησίας μεταξύ των προβλεπτών. Ένας Naive Bayes ταξινομητής υποθέτει ότι η παρουσία ενός συγκεκριμένου χαρακτηριστικού σε μια κλάση δεν σχετίζεται με την παρουσία οποιουδήποτε άλλου χαρακτηριστικού. Ο Navie Bayes αξιοποιείται ευρέως στην ταξινόμηση κειμένου και χρησιμοποιείται κυρίως για την συσταδοποίηση (clustering) και την ταξινόμηση (classification).

Η **γραμμική παλινδρόμηση και η λογιστική παλινδρόμηση** είναι δύο βασικοί αλγόριθμοι επιβλεπόμενης μάθησης. Η γραμμική παλινδρόμηση είναι μια τεχνική πρόβλεψης που εξετάζει τη σχέση μεταξύ μιας εξαρτημένης μεταβλητής και μίας ή περισσότερων ανεξάρτητων μεταβλητών. Ο στόχος είναι να βρεθεί μια γραμμική σχέση που περιγράφει καλύτερα τα δεδομένα. Από την άλλη πλευρά, η λογιστική παλινδρόμηση χρησιμοποιείται για την πρόβλεψη δυαδικών αποτελεσμάτων (π.χ., ναι/όχι, 1/0). Αυτός ο αλγόριθμος εκτιμά την πιθανότητα που αντιστοιχεί στα αποτελέσματα. Εδώ, ο στόχος είναι να βρεθεί μια σχέση που περιγράφει την πιθανότητα ένα γεγονός να συμβεί ως αποτέλεσμα διαφόρων εισόδων.

- **Μη Επιβλεπόμενη Μάθηση (Unsupervised Learning).**

Στην μη επιβλεπόμενη μάθηση σε αντίθεση με την επιβλεπόμενη, δεν υπάρχουν σωστές απαντήσεις και δεν υπάρχει «δάσκαλος». Οι αλγόριθμοι μαθαίνουν λίγα χαρακτηριστικά από τα δεδομένα και όταν εισάγονται νέα δεδομένα, χρησιμοποιούν τα χαρακτηριστικά που έχουν ήδη μάθει για να αναγνωρίσουν την κλάση των δεδομένων. Ο αλγόριθμος εκπαιδεύεται χρησιμοποιώντας πληροφορίες που δεν είναι ταξινομημένες και επιτρέπουν στον αλγόριθμο να ενεργεί χωρίς καθοδήγηση. Η συγκεκριμένη τεχνική είναι ιδιαίτερα χρήσιμη στην επίλυση προβλημάτων clustering (συσταδοποίησης) και συσχέτισης (association), ειδικά αν δεν υπάρχει πρότερη γνώση για κοινά χαρακτηριστικά σε ένα σύνολο δεδομένων. Κάποιοι βασικοί αλγόριθμοι συσταδοποίησης είναι οι Hierarchica και οι K-Means.

Η ομαδοποίηση **K-means** είναι ένα από τους πιο απλούς αλγόριθμους μη επιβλεπόμενης μάθησης που λύνουν το πρόβλημα της ομαδοποίησης. Η διαδικασία ακολουθεί μια απλή και εύκολη μέθοδο για να ταξινομήσει ένα σύνολο δεδομένων μέσω ενός συγκεκριμένου αριθμού ομάδων (clusters). Η βασική ιδέα είναι ότι ορίζονται k κέντρα, ένα για κάθε ομάδα (cluster). Το επόμενο βήμα είναι κάθε σημείο που ανήκει σε ένα συγκεκριμένο σύνολο δεδομένων να συσχετιστεί με το πλησιέστερο κέντρο. Όταν κανένα σημείο δεν εκκρεμεί, ολοκληρώνεται το πρώτο βήμα και γίνεται μια πρώιμη ομαδοποίηση. Στη συνέχεια, απαιτείται να υπολογιστούν ξανά k νέα κέντρα, τα οποία θα αποτελούν το κέντρο βάρους για κάθε μία ομάδα (cluster) που προέκυψε από το προηγούμενο βήμα. Αφού λοιπόν οριστούν τα νέα k κέντρα, ακολουθεί και πάλι η ίδια διαδικασία ανάθεσης καθενός από τα στοιχεία του συνόλου δεδομένων στο κοντινότερο με αυτό, νέο πλέον κέντρο. Αποτέλεσμα αυτής της επανάληψης είναι ότι σε κάθε βήμα τα κέντρα αλλάζουν θέση (ορίζονται νέα) και τα στοιχεία ανατίθενται στη κατάλληλη ομάδα (cluster) κάθε φορά με βάση το κοντινότερο κέντρο.

Η **Ανάλυση Κύριων Συνιστωσών (Principal Component Analysis - PCA)** είναι μία από τις τεχνικές που αξιοποιούνται για τη μείωση του αριθμού των χαρακτηριστικών σε ένα σύνολο δεδομένων, διατηρώντας ταυτόχρονα όσο το δυνατόν περισσότερες πληροφορίες, μειώνοντας με αυτόν τον τρόπο τη πολυπλοκότητα των μοντέλων. Στην ανάλυση κυρίων συνιστωσών (PCA), η οποία είναι μία στατιστική διαδικασία, χρησιμοποιείται ένας ορθογώνιος μετασχηματισμός για την μετατροπή παρατηρήσεων πιθανώς συσχετισμένων μεταβλητών σε ένα σύνολο τιμών γραμμικά μη συσχετισμένων μεταβλητών, τις λεγόμενες κύριες συνιστώσες. Αυτό έχει σαν αποτέλεσμα την μείωση διαστάσεων των δεδομένων διατηρώντας την ίδια στιγμή τη διακύμανσή τους.

- **Ενισχυτική Μάθηση (Reinforcement Learning)**

Η Ενισχυτική Μάθηση (RL) είναι ένας βασικός κλάδος της μηχανικής μάθησης όπου ένας πράκτορας μαθαίνει να παίρνει αποφάσεις αλληλοεπιδρώντας με ένα περιβάλλον μεγιστοποιώντας κάποια έννοια συσσωρευτικής ανταμοιβής. Η διαδικασία μάθησης και λήψης αποφάσεων καθοδηγείται από την ανατροφοδότηση που λαμβάνεται από το περιβάλλον, η οποία μπορεί να είναι είτε θετική (ανταμοιβή) είτε αρνητική (τιμωρία).

3.3 Νευρωνικά Δίκτυα

Τα **νευρωνικά δίκτυα** είναι ένας τύπος αλγόριθμου μηχανικής μάθησης όπου διδάσκει στους υπολογιστές να επεξεργάζονται δεδομένα με τρόπο εμπνευσμένο από τη δομή και τη λειτουργία του ανθρώπινου εγκεφάλου. Ένα τεχνητό νευρωνικό δίκτυο λειτουργεί σε τρία επίπεδα: το επίπεδο εισόδου λαμβάνει την είσοδο, το κρυφό επίπεδο επεξεργάζεται την είσοδο και, τέλος, το επίπεδο εξόδου στέλνει τον υπολογισμένο αποτέλεσμα.

Στα **νευρωνικά δίκτυα** επιβλεπόμενης μάθησης η έξοδος της εισόδου είναι ήδη γνωστή στην διάρκεια της εκπαίδευσης. Η προβλεπόμενη έξοδος του νευρωνικού δικτύου συγκρίνεται με την πραγματική έξοδο. Με βάση το σφάλμα, οι παράμετροι αλλάζουν και στη συνέχεια τροφοδοτούνται ξανά στο νευρωνικό δίκτυο. Στο νευρωνικό δίκτυο πρόσθιας τροφοδότησης (feed forward neural network) όλοι οι υπολογισμοί γίνονται από την είσοδο προς την έξοδο. Στα πλαίσια της παρούσας διπλωματικής εργασίας έχει αναπτυχθεί ένα τέτοιο δίκτυο MLP (MultiLayer Perceptron): Οι νευρώνες είναι οργανωμένοι σε επίπεδα ή στρώματα (layers), ενώ δεν υπάρχουν συνδέσεις μεταξύ νευρώνων του ίδιου επιπέδου. Η διαστρωμάτωση διευκολύνει τη μαθηματική ανάλυση και επιπλέον προσφέρει δυνατότητα παράλληλης επεξεργασίας.




Figure 6 Δομή ενός τεχνητού νευρωνικού δικτύου

Ένα τυπικό νευρωνικό δίκτυο αποτελείται από τα εξής στοιχεία:

1. **Είσοδοι ($X_1, X_2, X_3, \dots, X_m$):** Αυτές είναι οι εισοδοί που προέρχονται από την είσοδο του δικτύου ή από το προηγούμενο επίπεδο στο νευρωνικό δίκτυο. Κάθε είσοδος είναι συνδεδεμένη με τον νευρώνα μέσω ενός βάρους.
2. **Βάρη ($W_1, W_2, W_3, \dots, W_m$):** Τα βάρη είναι παράμετροι του μοντέλου που προσαρμόζονται κατά τη διαδικασία εκπαίδευσης. Κάθε βάρος αντιστοιχεί σε μία είσοδο και πολλαπλασιάζει την τιμή της.
3. **Πόλωση (b):** Η πόλωση (ή bias) είναι ένας επιπλέον όρος που προστίθεται στη συνολική είσοδο του νευρώνα για να μετατοπίσει τη συνάρτηση ενεργοποίησης, ώστε να βελτιωθεί η ικανότητα του μοντέλου να μαθαίνει πιο περίπλοκες συσχετίσεις.
4. **Συνολική είσοδος (Σ):** Η συνολική είσοδος στον νευρώνα υπολογίζεται ως το άθροισμα των γινομένων των εισόδων με τα αντίστοιχα βάρη, συν την πόλωση.
5. **Συνάρτηση ενεργοποίησης (f):** Αφού υπολογιστεί η συνολική είσοδος, αυτή περνά μέσα από μια συνάρτηση ενεργοποίησης, η οποία μπορεί να είναι η σιγμοειδής ή άλλη. Η συνάρτηση ενεργοποίησης διαμορφώνει την τελική έξοδο του νευρώνα.
6. **Έξοδος (y):** Η τελική έξοδος του νευρώνα, η οποία μπορεί να χρησιμοποιηθεί ως είσοδος στο επόμενο επίπεδο του δικτύου ή ως μέρος της τελικής πρόβλεψης του μοντέλου.




Figure 7 Δομή ενός MLP νευρωνικού [33]

Η **Βαθιά Μάθηση (Deep learning)** είναι μια εξειδικευμένη μορφή μηχανικής μάθησης, η οποία διδάσκει στους υπολογιστές να πράττουν αυτό που στους ανθρώπους έρχεται φυσικά [34]. Προσθέτοντας περισσότερα επίπεδα και περισσότερες μονάδες εντός ενός επιπέδου, ένα βαθύ δίκτυο μπορεί να αναπαραστήσει λειτουργίες αυξανόμενης πολυπλοκότητας. Οι περισσότερες εργασίες, οι οποίες απαιτούν τη χαρτογράφηση ενός διανύσματος εισόδου σ' ένα διάνυσμα εξόδου μπορούν να επιτευχθούν μέσω βαθιάς μάθησης.

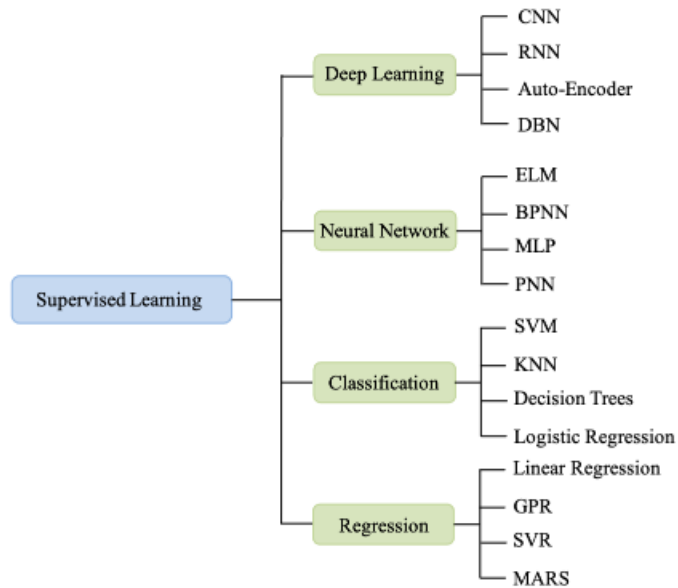


Figure 8 Τεχνικές επιβλεπόμενης μάθησης που χρησιμοποιούνται ευρέως στα έξυπνα δίκτυα [35]

3.4 Βασικές υπερπαραμέτροι νευρωνικών δικτύων

Τα νευρωνικά δίκτυα αποτελούν ένα δυνατό εργαλείο της μηχανικής μάθησης που έχει την ικανότητα να αναγνωρίζει περίπλοκα πρότυπα και σχέσεις μέσα στα δεδομένα. Παρ' όλα αυτά, χρειάζονται τη ρύθμιση πολλών υπερπαραμέτρων πριν την εκπαίδευση τους. Αυτές οι υπερπαραμέτροι είναι κρίσιμες για την ακρίβεια και την ικανότητα του μοντέλου να γενικεύει (generalize) τη γνώση που κατακτά κατά την εκπαίδευση. Σε αυτή την ενότητα γίνεται μια επισκόπηση των βασικών υπερπαραμέτρων για νευρωνικά δίκτυα και το πώς η ρύθμισή τους μπορεί να βελτιώσει τη λειτουργία του μοντέλου.

- **Ο αριθμός των κρυφών επιπέδων (hidden units)** σε ένα νευρωνικό δίκτυο αφορά το πλήθος των νευρώνων που βρίσκονται σε ένα κρυφό επίπεδο. Αυτά τα επίπεδα είναι τοποθετημένα μεταξύ του επιπέδου εισόδου και του επιπέδου εξόδου. Η ποσότητα των κρυφών επιπέδων που θα χρησιμοποιηθεί, επηρεάζει την πολυπλοκότητα και την αποτελεσματικότητα του δικτύου. Περισσότερα κρυφά επίπεδα μπορούν να βοηθήσουν το μοντέλο να αναγνωρίσει πιο περίπλοκες σχέσεις στα δεδομένα, αλλά υπάρχει και ο κίνδυνος υπερβολικής προσαρμογής (overfitting). Αντίθετα, λιγότερα κρυφά επίπεδα μπορεί να κάνουν το μοντέλο πιο απλό και αποδοτικό, αλλά μπορεί να μην είναι αρκετά για να αφήσουν το δίκτυο να «μάθει» σωστά από τα δεδομένα. Η σωστή επιλογή για τη

δημιουργία του ιδανικού αριθμού κρυφών επιπέδων είναι ένα σημαντικό στάδιο στη δημιουργία ενός νευρωνικού δικτύου.

- Ο **ρυθμός μάθησης** (learning rate) είναι παράμετρος που καθορίζει πόσο μεγάλα «βήματα» κάνει ένα νευρωνικό δίκτυο κατά την ρύθμιση των βαρών του. Ένας υψηλός ρυθμός μάθησης μπορεί να επιταχύνει τη σύγκλιση, αλλά υπάρχει κίνδυνος να προκληθούν αστάθειες και αποκλίσεις. Από την άλλη πλευρά, ένας χαμηλός ρυθμός μάθησης μπορεί να είναι πιο σταθερός αλλά να οδηγήσει σε πολύ αργή σύγκλιση, και να «κολλήσει» σε τοπικές βέλτιστες λύσεις. Η σωστή επιλογή του ρυθμού μάθησης είναι κρίσιμη για την αποδοτική εκπαίδευση του δικτύου.
- Ο **αριθμός των εποχών** (epochs) είναι μια κρίσιμη υπερπαράμετρος για τα νευρωνικά δίκτυα, καθώς καθορίζει πόσες φορές το μοντέλο θα επεξεργαστεί το σύνολο των δεδομένων κατά την εκπαίδευση. Η επιλογή του σωστού αριθμού εποχών εξαρτάται από πολλούς παράγοντες, όπως η πολυπλοκότητα του προβλήματος, το μέγεθος του συνόλου δεδομένων (dataset) και άλλες υπερπαραμέτρους. Συνήθως, για να βρεθεί ο βέλτιστος αριθμός, παρακολουθείται η απόδοση στο σύνολο εκπαίδευσης (training set) και η εκπαίδευση σταματά όταν αυτή αρχίζει να υποχωρεί.
- Η **συνάρτηση ενεργοποίησης** (activation function) σε ένα νευρωνικό δίκτυο λειτουργεί ως ένας διακόπτης που αποφασίζει εάν ο νευρώνας θα ενεργοποιηθεί, βάσει της σημασίας της εισόδου του για την πρόβλεψη. Χρησιμοποιώντας μαθηματικές συναρτήσεις όπως η σιγμοειδής και η υπερβολική εφασπτομένη, η συνάρτηση ενεργοποίησης μπορεί να μοντελοποιήσει διάφορους μη γραμμικούς συσχετισμούς. Η επιλογή της κατάλληλης συνάρτησης είναι κρίσιμη, καθώς επηρεάζει άμεσα την απόδοση του δικτύου.
- Το **μέγεθος παρτίδας (batch size)** σχετίζεται με την ποσότητα των δειγμάτων δεδομένων που χρησιμοποιούνται για κάθε επανάληψη εκπαίδευσης για την ανανέωση των βαρών στο νευρωνικό δίκτυο. Αυτή η μέθοδος επιτρέπει την εκπαίδευση σε μικρότερες ομάδες δεδομένων, αυξάνοντας την αποδοτικότητα σε υπολογιστικό χρόνο και χρήση μνήμης.
- Η **κανονικοποίηση (normalization)** είναι μια μέθοδος που βοηθά στην αποφυγή της υπερβολικής προσαρμογής ενός μοντέλου, προσθέτοντας έναν όρο στη συνάρτηση απώλειας (loss function) κατά την εκπαίδευση. Αυτό επιτυγχάνει μια πιο ισορροπημένη εκμάθηση, αποφεύγοντας την υπερβολική εξάρτηση από τα δεδομένα εκπαίδευσης και διασφαλίζοντας τη συνέπεια στις μετρήσεις και τις τιμές. Η εφαρμογή περιορισμών στα βάρη και τις πολώσεις των νευρώνων βοηθά στη δημιουργία ενός πιο αξιόπιστου μοντέλου. Η επιλογή του κατάλληλου τύπου

κανονικοποίησης εξαρτάται από τη φύση του προβλήματος και το μέγεθος των δεδομένων.

Η επιλογή των κατάλληλων υπερπαραμέτρων για ένα μοντέλο είναι μια κρίσιμη διαδικασία που ονομάζεται προσαρμογή/ρύθμιση υπερπαραμέτρων (hyperparameter tuning). Για το σκοπό αυτό, υπάρχουν διάφορες μέθοδοι, όπως η αναζήτηση πλέγματος (gridsearch), η τυχαία αναζήτηση (random search), και η βελτιστοποίηση κατά Bayes. Η αναζήτηση πλέγματος δοκιμάζει συστηματικά συνδυασμούς τιμών υπερπαραμέτρων, ενώ η τυχαία αναζήτηση εξερευνά τυχαίες τιμές μέσα σε ένα εύρος. Η βελτιστοποίηση κατά Bayes χρησιμοποιεί πιθανοτικά μοντέλα για να βρει τις πιθανότερες βέλτιστες υπερπαραμέτρους.

Είναι φανερό ότι η σωστή επιλογή υπερπαραμέτρων είναι απαραίτητη για τη δημιουργία αξιόπιστων και ευρέως εφαρμόσιμων νευρωνικών δικτύων. Ο συντονισμός αυτών των παραμέτρων μπορεί να απαιτεί σημαντικούς υπολογιστικούς πόρους και χρόνο, ειδικά σε μεγάλες βάσεις δεδομένων και περίπλοκα μοντέλα. Η έρευνα συνεχίζεται γύρω από τη βελτίωση της ρύθμισης υπερπαραμέτρων, με μελέτες να δείχνουν ότι οδηγεί σε καλύτερα και πιο αποδοτικά μοντέλα [36] [37] [38].

3.5 Φαινόμενα Underfitting και Overfitting και η αντιμετώπισή τους

Κατά τη διαδικασία εκπαίδευσης ενός νευρωνικού δικτύου και της εύρεσης του βέλτιστου μοντέλου, υπάρχουν τρεις πιθανότητες:

1. Το τελικό μοντέλο μπορεί να μην εκπαιδευτεί επαρκώς και οι προβλέψεις του να είναι ανακριβείς. Σε αυτή την περίπτωση, το νευρωνικό δίκτυο δεν παρουσιάζει καλή απόδοση στην πρόβλεψη των δεδομένων εκπαίδευσης (training dataset). Αυτό το φαινόμενο είναι γνωστό ως **underfitting**.
2. Το νευρωνικό δίκτυο μπορεί να εκπαιδευτεί επιτυχώς, παρουσιάζοντας μικρό συνολικό σφάλμα τόσο στα δεδομένα εκπαίδευσης (training dataset) όσο και στα νέα δεδομένα που βλέπει πρώτη φορά (test dataset).
3. Το μοντέλο μπορεί να κάνει ακριβείς προβλέψεις για τα δεδομένα εκπαίδευσης, αλλά να μην αποδίδει καλά σε νέα δεδομένα (test dataset). Αυτό το φαινόμενο είναι γνωστό ως **overfitting**.

Στην περίπτωση του underfitting (Figure 9 αριστερά), η συνάρτηση δεν προσεγγίζει τα δεδομένα με μεγάλη ακρίβεια, ενώ στην περίπτωση του overfitting (Figure 9 δεξιά), το μοντέλο δημιουργεί μια συνάρτηση που προβλέπει συγκεκριμένες τιμές χωρίς να έχει γενικευμένη ισχύ. Το overfitting περιγράφει το φαινόμενο κατά το οποίο το νευρωνικό δίκτυο απομνημονεύει το σύνολο δεδομένων εκπαίδευσης, με αποτέλεσμα να κάνει ακριβείς προβλέψεις μόνο για αυτά τα δεδομένα, ενώ οι προβλέψεις του για νέα δεδομένα παρουσιάζουν σημαντικά μεγαλύτερο σφάλμα. Στο κέντρο του Figure 9, παρουσιάζεται η επιθυμητή συμπεριφορά του μοντέλου, δηλαδή να είναι μια γενικευμένη συνάρτηση που μπορεί να αποδίδει καλά και σε νέα δεδομένα.




Figure 9 γραφικές που αποτυπώνουν το φαινόμενο α) underfit β) επιτυχούς εκπαίδευσης γ) overfit [39]

Το φαινόμενο του overfitting συμβαίνει συνήθως όταν το μοντέλο είναι υπερβολικά περίπλοκο, με αποτέλεσμα να προσαρμόζει τους συντελεστές βαρύτητας στα δεδομένα εκπαίδευσης. Έτσι, οι προβλέψεις για τα δεδομένα εκπαίδευσης είναι ακριβείς, καθώς το δίκτυο έχει σε μεγάλο βαθμό απομνημονεύσει τα δεδομένα αυτά. Για να μειωθεί το overfitting, χρησιμοποιούνται συνήθως τεχνικές που στοχεύουν στη μείωση της πολυπλοκότητας του δικτύου [40]. Μερικές από αυτές τις μεθόδους περιλαμβάνουν την αύξηση του κόστους με την προσθήκη ενός επιπλέον όρου (L1 & L2 Regularization) και την απενεργοποίηση ενός ποσοστού νευρώνων (Dropout).

Μία επιπλέον τεχνική για την αποφυγή του φαινομένου overfitting είναι η πρόωρη διακοπή της εκπαίδευσης του νευρωνικού δικτύου πριν από την εμφάνισή του (Early Stopping) [41]. Αυτή η μέθοδος διαφέρει από τις προηγούμενες, καθώς δεν επεμβαίνει στους συντελεστές βαρύτητας, αλλά εμποδίζει το δίκτυο από το να προσαρμόσει τις παραμέτρους του αποκλειστικά στα δεδομένα εκπαίδευσης. Ορίζεται ένας αριθμός επαναλήψεων ή εποχών (patience) κατά τη διάρκεια των οποίων το μοντέλο αναμένει να δει αν θα υπάρξει βελτίωση. Εάν μετά από αυτές τις επαναλήψεις το κόστος του συνόλου αξιολόγησης αυξάνεται ή παραμένει σταθερό, τότε η εκπαίδευση του μοντέλου διακόπτεται αμέσως.

3.6 Διαχωρισμός Συνόλου Δεδομένων

Κατά την εκπαίδευση ενός νευρωνικού δικτύου, είναι απαραίτητο η εκπαίδευση και η αξιολόγηση να γίνουν σε διαφορετικά δεδομένα. Γι' αυτό το αρχικό σύνολο δεδομένων χωρίζεται σε τουλάχιστον δύο μικρότερα: το σύνολο εκπαίδευσης (training set) και το σύνολο αξιολόγησης (testing set).

Το **σύνολο εκπαίδευσης** χρησιμοποιείται από το νευρωνικό δίκτυο κατά τη διάρκεια της εκπαίδευσης και πάνω σε αυτό πραγματοποιείται η βελτιστοποίηση του μοντέλου και ο υπολογισμός των συντελεστών βαρύτητας. Το **σύνολο αξιολόγησης** περιλαμβάνει δεδομένα που δεν έχουν χρησιμοποιηθεί κατά την εκπαίδευση, είναι άγνωστα στο δίκτυο και χρησιμοποιούνται για τη μέτρηση της απόδοσής του κατά την επιλογή των κατάλληλων υπερπαραμέτρων (hyperparameter tuning) [42]. Έτσι, για κάθε εποχή εκπαίδευσης, παρακολουθείται η απόδοση του μοντέλου τόσο σε γνωστά όσο και σε άγνωστα δεδομένα, ώστε να επιλεγούν οι υπερπαραμέτροι που βελτιώνουν τα αποτελέσματα και στα δύο σύνολα δεδομένων.

Ο στόχος είναι το τελικό μοντέλο να έχει γενικευμένη ικανότητα (generalization), δηλαδή να ελαχιστοποιηθεί το σφάλμα των προβλέψεων στο σύνολο αξιολόγησης. Για να είναι αντικειμενική η αξιολόγηση, τα δύο σύνολα δεν πρέπει να περιέχουν κοινά δεδομένα, ο διαχωρισμός τους πρέπει να γίνεται τυχαία και το σύνολο εκπαίδευσης δεν πρέπει να επηρεάζεται με κανέναν τρόπο από το σύνολο αξιολόγησης [43]. Βεβαίως χρειάζεται το σύνολο εκπαίδευσης να είναι αντιπροσωπευτικό του συνολικού συνόλου δεδομένων. Συνεπώς, χρειάζεται πάντα προσοχή στην επεξεργασία των δεδομένων. Για παράδειγμα, η κανονικοποίηση πρέπει να γίνεται και στα δύο σύνολα με βάση τα χαρακτηριστικά μόνο του συνόλου εκπαίδευσης (υπολογισμός μέσης τιμής και τυπικής απόκλισης ή μέγιστης και ελάχιστης τιμής) [44].

Το μέγεθος των υποσυνόλων εκπαίδευσης επιλέγεται ανάλογα με το πλήθος των διαθέσιμων δεδομένων. Τα δύο σύνολα, παρά τον τυχαίο διαχωρισμό τους, πρέπει να παραμείνουν αμετάβλητα κατά τη διάρκεια της επιλογής και δοκιμής υπερπαραμέτρων. Έτσι, η σύγκριση βασίζεται αποκλειστικά στην επίδραση των υπερπαραμέτρων, καθώς οποιεσδήποτε αλλαγές στα δεδομένα των δύο συνόλων δεν θα επέτρεπαν την αντικειμενική σύγκριση, επειδή οι δοκιμές θα γίνονταν κάθε φορά σε διαφορετικά δεδομένα.

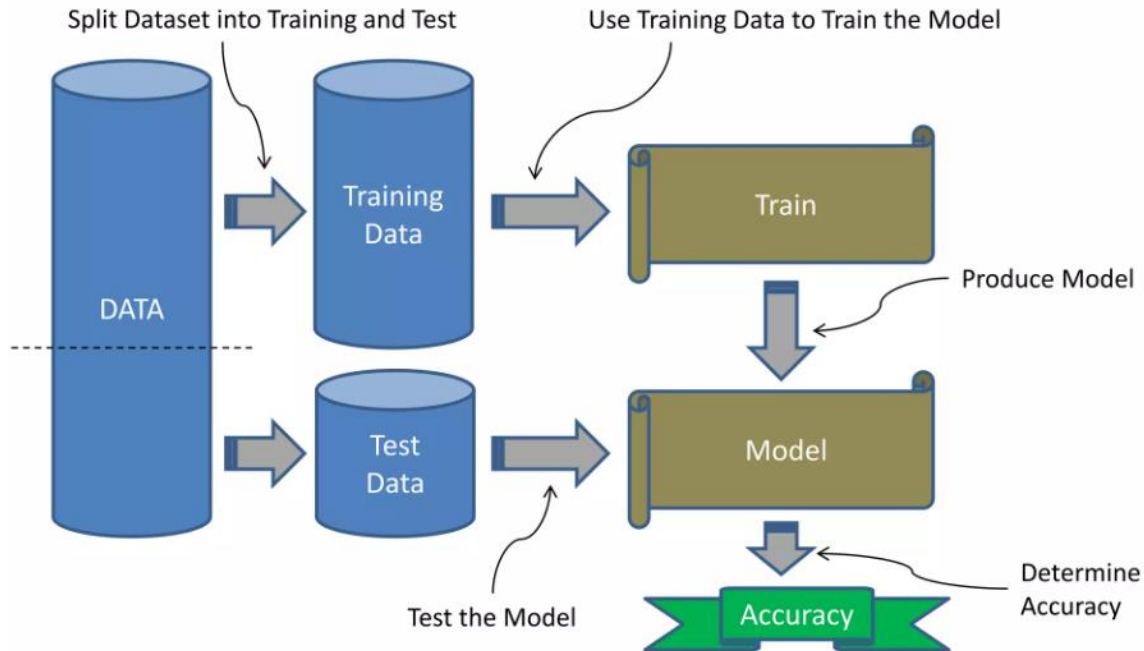


Figure 10 Διαχωρισμός συνόλου δεδομένων και η χρήση του στο μοντέλο μηχανικής μάθησης [45]

3.7 Συνελικτικά Νευρωνικά Δίκτυα (Convolution Neural Networks)

Τα συνελικτικά νευρωνικά δίκτυα (CNNs) είναι είδος νευρωνικού δικτύου. Πρόκειται για αρχιτεκτονικές πρόσθιας τροφοδότησης (feed-forward networks) οι οποίες χρησιμοποιούνται γενικότερα σε πολλά προβλήματα ταξινόμησης, αναγνώρισης εικόνας καθώς και επεξεργασίας φυσικής γλώσσας [46]. Τα CNNs αξιοποιούν τα ιεραρχικά μοτίβα που υπάρχουν στα δεδομένα και κατασκευάζουν περίπλοκα πρότυπα χρησιμοποιώντας μικρότερα και απλούστερα. Αυτός ο τύπος δικτύου είναι εμπνευσμένος από τον οπτικό φλοιό (visual cortex) του εγκεφάλου.

Τα CNNs παρουσιάζουν πολλές ομοιότητες με τα κλασσικά νευρωνικά δίκτυα. Αποτελούνται και αυτά από νευρώνες. Οι νευρώνες στην είσοδο και στην έξοδό τους συνδέονται με βάρη (συνδέσεις) των οποίων οι τιμές που αλλάζουν κατά τη διάρκεια της εκπαίδευσης. Κάθε νευρώνας δέχεται ένα σύνολο από εισόδους και υπολογίζει το εσωτερικό γινόμενο ανάμεσα στις εισόδους αυτές και τις τιμές των βαρών. Το αποτέλεσμα στη συνέχεια εισάγεται σε μία μη γραμμική συνάρτηση.

Παρ' όλες τις ομοιότητες με τα κλασσικά νευρωνικά δίκτυα, η βασική ιδιαιτερότητα των συνελικτικών δικτύων είναι ότι είναι πολύ πιο φιλικά στην υποδοχή εικόνων ως μεταβλητή εισόδου. Αυτό συμβαίνει διότι ως δεδομένο εισόδου δεν δέχονται ένα διάνυσμα μίας διάστασης αλλά ένα πολυδιάστατο πίνακα. Η βασική διαφορά επομένως των απλών νευρωνικών δικτύων και των συνελικτικών είναι ότι τα συνελικτικά δίκτυα έχουν τρισδιάστατη μορφή και από επίπεδο σε επίπεδο αλλάζει αυτή η τρισδιάστατη

μορφή. Κάθε επίπεδο ενός CNN μετασχηματίζει τον τρισδιάστατο όγκο εισόδου (input volume), σε έναν τρισδιάστατο όγκο εξόδου (output volume), που παράγεται από τις ενεργοποιήσεις των νευρώνων του.

Η λέξη «συνελικτικό» στην ονομασία του δικτύου υποδεικνύει ότι αξιοποιεί τη μαθηματική πράξη της συνέλιξης πινάκων. Η συνέλιξη είναι ένας ειδικός τύπος γραμμικού υπολογισμού. Τα CNN χρησιμοποιούν τη συνέλιξη στη θέση του πολλαπλασιασμού πινάκων, σε τουλάχιστον ένα από τα επίπεδά τους. Τα κρυφά επίπεδα ενός CNN, συνήθως, αποτελούνται από μια σειρά από συνελικτικά επίπεδα (convolutional layers) που πραγματοποιούν συνέλιξεις. Συνήθως, η συνάρτηση ενεργοποίησης αυτών των επιπέδων είναι ένα ReLu layer που ακολουθείται από επιπλέον επίπεδα, που ονομάζονται επίπεδα υπερδειγματοληψίας (pooling layers) [47].

Κατά τον σχεδιασμό ενός CNN, κάθε convolutional layer πρέπει να έχει τα παρακάτω γνωρίσματα:

- Η είσοδος του πρέπει να είναι ένα διάνυσμα ή ένας πίνακας με διαστάσεις (αριθμός εικόνων) x (πλάτος εικόνας) x (ύψος εικόνας) x (αριθμός χρωμάτων (image depth))
- Συνελικτικούς πυρήνες (convolutional kernels) το πλάτος και το ύψος των οποίων είναι υπερπαραμέτροι και το βάθος τους ίσο ή μικρότερο με το βάθος των εικόνων που επεξεργάζεται.

Υπάρχουν 4 βασικές λειτουργίες που εκτελούνται στα CNN:

- Συνέλιξη (Convolution)
- Συνάρτηση ενεργοποίησης (activation function)
- Συγκέντρωση ή Υπο-Δειγματοληψία (Pooling / Sub sampling)
- Κατηγοριοποίηση από πλήρως συνδεδεμένο επίπεδο (Fully Connected Layer for Classification)

Το **επίπεδο συνέλιξης** χρησιμοποιεί ένα σύνολο από φίλτρα τα οποία εντοπίζουν την παρουσία συγκεκριμένων χαρακτηριστικών ή μοτιβών που παρουσιάζονται στην αυθεντική εικόνα που δίνεται στην είσοδο (input). Συνήθως έχουν μικρότερες διαστάσεις από αυτές της αυθεντικής εικόνας, αλλά διατηρούν τη διάσταση του βάθους ίδια με αυτές. Το κάθε φίλτρο λοιπόν “γλιστρά” κατά πλάτος και κατά ύψος της εικόνας εισόδου, και ένα εσωτερικό γινόμενο υπολογίζεται για να δώσει ένα χάρτη ενεργοποίησης. Διαφορετικά φίλτρα τα οποία εντοπίζουν διαφορετικά χαρακτηριστικά περιστρέφονται στην εικόνα εισόδου και ένα σύνολο από χάρτες ενεργοποίησης προκύπτει ως έξοδος, το οποίο περνά στο επόμενο επίπεδο του CNN.

Η **συνάρτηση ενεργοποίησης** (activation function) είναι ο μη-γραμμικός μετασχηματισμός που εφαρμόζουμε στο σήμα εισόδου. Πρακτικά αποτελούν έναν κόμβο που βοηθά στο να παρθεί η απόφαση για το αν θα πυροδοτηθεί ένας νευρώνας ή όχι. Η μετασχηματισμένη έξοδος στέλνεται στο επόμενο επίπεδο, για το οποίο και αποτελεί σήμα εισόδου

Τα **επίπεδα συγκέντρωσης** (Pooling) συναντώνται ανάμεσα στα επίπεδα συνέλιξης των CNNs. Αυτό που κάνει αυτό το επίπεδο είναι να μειώνει το πλήθος των παραμέτρων

και κατα συνέπεια και τους υπολογισμούς ενός δικτύου, κρατώντας έτσι υπό έλεγχο ζητήματα υπερπροσαρμογής μέσω της μείωσης των διαστάσεων του. Οι πιο συνηθισμένες λειτουργίες αυτού του επιπέδου είναι η Μέση Συγκέντρωση (Average Pooling) και η Μέγιστη Συγκέντρωση (Max Pooling).

Στο **πλήρως συνδεδεμένο επίπεδο** οι νευρώνες έχουν πλήρεις συνδέσεις με όλες τις εξόδους των νευρώνων του προηγούμενου επιπέδου. Είναι ουσιαστικά ένα παραδοσιακό πολυεπίπεδο Perceptron (Multilayer Perceptron) που χρησιμοποιεί κάποια συνάρτηση απώλειας (loss function) για ενεργοποίηση. Οι έξοδοι των συνελικτικών επιπέδων και των συγκεντρωτικών επιπέδων αναπαριστούν υψηλού επιπέδου χαρακτηριστικά της αρχικής εικόνας εισόδου. Ο σκοπός αυτού του επιπέδου είναι να χρησιμοποιήσει αυτά τα χαρακτηριστικά για να κάνει ταξινόμηση της εικόνας εισόδου σε μία από τις διάφορες κλάσεις που θα υπάρχουν σαν επιλογή, με βάση το σύνολο εκπαίδευσης που χρησιμοποιήθηκε. Αυτό είναι και το τελευταίο επίπεδο ενός CNN πριν το αποτέλεσμα του δικτύου. Τα επίπεδα μπορούν να εντοπιστούν στο Figure 11.

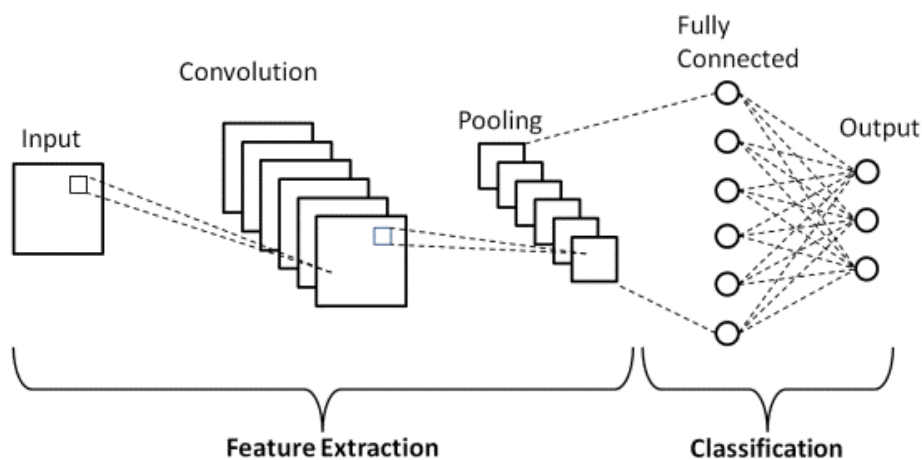


Figure 11 Τυπική αρχιτεκτονική ενός CNN [48]

Η **εξαγωγή χαρακτηριστικών (Feature extraction)** αναφέρεται στη διαδικασία μετατροπής των αρχικών δεδομένων σε αριθμητικά χαρακτηριστικά που μπορούν να γίνουν αντικείμενο επεξεργασίας, διατηρώντας τις πληροφορίες του αρχικού συνόλου δεδομένων. Αυτή η διαδικασία παρέχει καλύτερα αποτελέσματα σε σύγκριση με την εφαρμογή αλγορίθμων μηχανικής μάθησης απευθείας στα αρχικά δεδομένα.

Η αυτόματη εξαγωγή χαρακτηριστικών χρησιμοποιεί ειδικούς αλγόριθμους ή βαθιά δίκτυα για την αυτόματη εξαγωγή χαρακτηριστικών από σήματα ή εικόνες χωρίς την ανάγκη ανθρώπινης παρέμβασης. Αυτή η τεχνική μπορεί να είναι πολύ χρήσιμη για τη γρήγορη μετάβαση από τα ανεπεξέργαστα δεδομένα στην ανάπτυξη αλγορίθμων μηχανικής μάθησης. Με την διάδοσης της βαθιάς μάθησης, η εξαγωγή χαρακτηριστικών έχει εν πολλοίς αντικατασταθεί από τα πρώτα επίπεδα των βαθιών δικτύων.



Figure 12 Σχήμα για την εφαρμογή της διαδικασίας εξαγωγής χαρακτηριστικών σε ένα σύνολο δεδομένων που τροφοδοτεί ένα μοντέλο ταξινόμησης [49]

3.7 Εφαρμογές Τεχνητής Νοημοσύνης στα «Έξυπνα Δίκτυα»

Τα «έξυπνα δίκτυα» επιτρέπουν τη συλλογή τεράστιων ποσοτήτων δεδομένων πολλών διαστάσεων και πολλαπλών τύπων σχετικά με τις λειτουργίες του δικτύου ηλεκτρικής ενέργειας, ενσωματώνοντας προηγμένες υποδομές μέτρησης, τεχνολογίες ελέγχου και τεχνολογίες επικοινωνίας. Ωστόσο, οι παραδοσιακές τεχνολογίες μοντελοποίησης, βελτιστοποίησης και ελέγχου έχουν αρκετούς περιορισμούς στην επεξεργασία των δεδομένων. Οι εφαρμογές τεχνητής νοημοσύνης επεξεργάζονται μεγάλες ποσότητες δεδομένων με ταχύτερη ταχύτητα από τις αριθμητικές μεθόδους βελτιστοποίησης και με υψηλότερες ταχύτητες επεξεργασίας. Με αυτά τα χαρακτηριστικά, οι τεχνικές τεχνητής νοημοσύνης μπορούν να αυτοματοποιήσουν περαιτέρω και να αυξήσουν την απόδοση των συστημάτων ενέργειας. Έτσι, οι εφαρμογές τεχνικών τεχνητής νοημοσύνης στα «έξυπνα δίκτυα» γίνονται ολοένα και πιο διαδεδομένες και απαραίτητες με στόχο την ενίσχυση της αξιοπιστίας και της ανθεκτικότητας τους. Μερικές από τις εφαρμογές αφορούν εφαρμογές για την λειτουργία, τον έλεγχο και τον σχεδιασμό του ΣΗΕ, όπως για παράδειγμα την πρόβλεψη φορτίου, την αξιολόγηση της σταθερότητας του δικτύου, την ανίχνευση βλαβών, προβλήματα ασφαλείας κ.α [35] [50].

Σε αυτή τη βάση ενισχύεται και η ερευνητική δραστηριότητα σε αυτόν τον τομέα. **Μόνο τα τελευταία χρόνια οι αριθμοί των δημοσιεύσεων σχετικά με εφαρμογές τεχνητής νοημοσύνης σε ενεργειακά συστήματα έχει αυξηθεί κατά 40%** [51].

Συγκεκριμένα για τις εφαρμογές στα δίκτυα, που σχετίζονται με το θέμα της διπλωματικής εργασίας, μπορεί να γίνει μια σύντομη αναφορά ότι ως αποτέλεσμα της μετάβασης προς τη διεσπαρμένη παραγωγή, η μετρησιμότητα και η ελεγχιμότητα του

δικτύου διανομής γίνονται σημαντικά και κρίσιμα καθήκοντα. Λόγω της απουσίας πληροφοριών σχετικών με την τοπολογία και των συνήθως σπάνιων μετρήσεων και δεδομένων που συχνά παρατηρούνται στα συστήματα διανομής, οι συμβατικές προσεγγίσεις είναι δύσκολο να εφαρμοστούν. Ως εκ τούτου, η χρήση TN φαίνεται ως μονόδρομος, λόγω της ικανότητάς της να εξάγει πληροφορίες αποκλειστικά βασισμένες σε δεδομένα.

Αντίστοιχα, υπάρχουν βιβλιογραφικές ανασκοπήσεις για τις εφαρμογές συγκεκριμένα των βαθύ νευρωνικών δικτύων στην εκτίμηση και πρόβλεψη κατάστασης του δικτύου διανομής, η αναλυτική ανάπτυξη των οποίων ξεφεύγει από τους σκοπούς της παρούσας διπλωματικής [52]. Σύντομα να αναφερθεί ότι τα κλασικά νευρωνικά δίκτυα, όπως τα MLPs έχουν καθιερωθεί σε εφαρμογές όπως η στατική εκτίμηση κατάστασης στα συστήματα μεταφοράς ηλεκτρικής ενέργειας. Η δυναμική φύση της διασπασμένης παραγωγής (πχ ηλιακή και αιολική), η τεχνολογία οχήματος προς δίκτυο (Vehicle to Grid - V2G) και οι επιθέσεις εισαγωγής ψευδών δεδομένων (FDIAs – False Data Injection Attack), μπορεί να αποτελέσουν σημαντικές προκλήσεις για την εφαρμογή των κλασικών MLPs στην εκτίμηση κατάστασης (State Estimation) και στην πρόβλεψη κατάστασης (State Forecasting) στα συστήματα διανομής ηλεκτρικής ενέργειας. Για παράδειγμα, στη Γερμανία ο αριθμός των ηλεκτρικών αυτοκινήτων αναμένεται να ανέβει από το 2% στο 25% του συνολικού αριθμού αυτοκινήτων μέχρι το 2030, θέτοντας αντίστοιχες προκλήσεις για το δίκτυο διανομής [53].

Είναι κατανοητό ότι σε αυτό το τοπίο, ο ρόλος των διαχειριστών δικτύου στην ενεργειακή μετάβαση και η κερδοφορία τους σχετίζεται από τη διαθεσιμότητα μιας κατάλληλης υποδομής που διευκολύνει τη μετάβαση από τις ορυκτές σε ανανεώσιμες πηγές ενέργειας. Και σε αυτό τον στόχο δεν υποτάσσεται μόνο η φυσική υποδομή στη μορφή των ηλεκτρικών δικτύων αλλά και οι εσωτερικές δομές στον τομέα του σχεδιασμού, της διαχείρισης συστημάτων και της λειτουργίας του δικτύου. Αυτή η αλλαγή ρόλου συνδέεται με τις προκλήσεις της ενεργειακής πολιτικής μετάβασης και περιλαμβάνει συγκεκριμένα καθήκοντα που οι διαχειριστές δικτύου πρέπει να αντιμετωπίσουν, αξιοποιώντας και νέα εργαλεία, όπως αυτά της TN.

Είναι χαρακτηριστικό το Figure 13 που αναφέρεται στα νέα καθήκοντα των διαχειριστών δικτύου στη Γερμανία με βάση τους κεντρικούς στόχους της «απανθρακοποίησης», «αποκέντρωσης» και «ψηφιοποίησης».

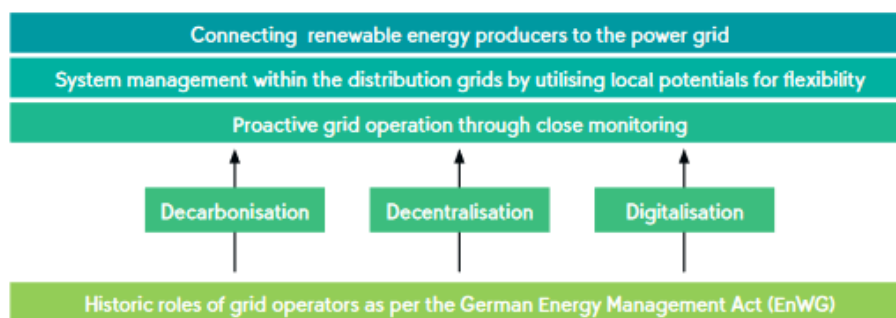


Figure 13 Νέα καθήκοντα για τους διαχειριστές δικτύου. Το παράδειγμα της Γερμανίας [53]

Κοιτώντας το από τη μεριά του διαχειριστή δικτύου, εάν μια στρατηγική ενσωμάτωσης τεχνικών τεχνητής νοημοσύνης ξεκινά αρχικά με τον εντοπισμό δυνατών εφαρμογών, αυτό θα πρέπει να ακολουθείται από τον έλεγχο της υφιστάμενης υποδομής και ποιότητας δεδομένων για το εάν είναι συμβατά για χρήση σε αυτές τις εφαρμογές. Εκτός από τις πηγές δεδομένων, είναι επίσης σημαντικό να ληφθεί υπόψη το νομικό πλαίσιο, το οποίο, χωρίς ένα σχέδιο συμμόρφωσης, μπορεί γρήγορα οδηγήσει σε αδιέξοδο.

Η ΤΝ προσφέρει στους διαχειριστές δικτύου διάφορους τρόπους πρόβλεψης των διακυμάνσεων των φορτίων ροής στο δίκτυο διανομής. Με τη βοήθεια της μηχανικής μάθησης, οι αλγόριθμοι μπορούν να συγκεντρώσουν και να αναλύσουν διάφορα δεδομένα προκειμένου να δημιουργήσουν ένα ευρύ φάσμα προβλέψεων. Τα δεδομένα που χρησιμοποιούνται περιλαμβάνουν ιστορικά δεδομένα, αριθμητικές προγνώσεις καιρού και τα βασικά χαρακτηριστικά των γραμμών από τους διαχειριστές δικτύου, αλλά συχνά και προβλέψεις τιμών που παρέχονται από τις ενεργειακές συναλλαγές, καθώς και ημερολογιακές πληροφορίες. Σε σύγκριση με τις κλασικές στατιστικές προβλέψεις, τα μοντέλα πρόβλεψης βασισμένα στην ΤΝ μπορούν να λάβουν υπόψη διάφορους παράγοντες σχετικούς με την παραγωγή, παράγοντας έτσι πιο ακριβείς πληροφορίες για την αναμενόμενη προσφορά. Οι ευέλικτοι καταναλωτές μπορούν επίσης να χρησιμοποιήσουν ΤΝ για να προβλέψουν το μέλλον, αναγνωρίζοντας μοτίβα κατανάλωσης. Ένα παράδειγμα εφαρμογής είναι η συμπεριφορά φόρτισης των ηλεκτρικών αυτοκινήτων, για τα οποία μπορούν να προετοιμαστούν σχετικά ακριβή και δυναμικά συγκεντρωτικά προφίλ φόρτισης χρησιμοποιώντας συσσωρευμένα μεταδεδομένα (όγκος κυκλοφορίας, ποσοστό ηλεκτρικών οχημάτων κ.λπ.). Η ΤΝ μπορεί επίσης να βοηθήσει στη συγκέντρωση των μεταβλητών καμπυλών παραγωγής και κατανάλωσης, συντονίζοντας μια ισορροπία κατανάλωσης και παραγωγής σε διάφορες χρονικές στιγμές, χώρους και τομείς. Η ικανότητα ανίχνευσης μοτίβων και εξαρτήσεων σε μεγάλους όγκους δεδομένων επιτρέπει τον εντοπισμό ελλείψεων και το σχεδιασμό βέλτιστων συνιστώμενων ενεργειών βάσει προηγούμενων δράσεων. Στο μέλλον, τα συστήματα βασισμένα στην ΤΝ θα μπορούσαν να χρησιμοποιήσουν αυτές τις

πληροφορίες σε τοπικά «έξυπνα δίκτυα» για να λαμβάνουν ανεξάρτητες αποφάσεις, επιτρέποντας μια μερικώς αυτοματοποιημένη διαχείριση του συστήματος. Ένα άλλο σημαντικό πεδίο εφαρμογής της TN βρίσκεται στον τομέα της πρόληψης βλαβών, ιδιαίτερα για την έξυπνη παρακολούθηση, επιθεώρηση και συντήρηση του συστήματος.

Οι αλγόριθμοι μπορούν να μάθουν τη λειτουργική συμπεριφορά των συστημάτων παραγωγής και διανομής και να εντοπίσουν ανωμαλίες από νωρίς. Αυτό μπορεί να γίνει είτε χρησιμοποιώντας ιστορικά δεδομένα είτε παρέχοντας στην TN μια συνεχή ροή λειτουργικών δεδομένων για την εκπαίδευση του αλγορίθμου. Η συντήρηση εξοπλισμού με δύσκολη πρόσβαση, όπως οι εναέριες γραμμές ή οι υποσταθμοί διανομής στην επαρχία, μπορεί έτσι να διατηρηθεί με τρόπο που βασίζεται στις ανάγκες, μειώνοντας σημαντικά τον χρόνο και το κόστος που απαιτείται. Η καταγραφή δεδομένων σε τέτοιες περιπτώσεις μπορεί να αυτοματοποιηθεί εν μέρει χρησιμοποιώντας για παράδειγμα drones.

Η TN μπορεί επίσης να βελτιώσει τις υποστηρικτικές διαδικασίες, με οπτικοακουστικά βοηθητικά συστήματα που επιτρέπουν στο προσωπικό τεχνικής υποστήριξης να ανακτούν εγχειρίδια συντήρησης, αρχεία ελέγχου και επιθεώρησης μέσω φωνητικών εντολών. Αυτού του είδους οι εφαρμογές είναι χρήσιμες για διαδικασίες συντήρησης ή δοκιμών με υψηλό κίνδυνο, όπως οι εργασίες που εκτελούνται σε συστήματα υψηλής τάσης, όπου είναι απαραίτητη η αυστηρή τήρηση συγκεκριμένων διαδικασιών.

Διαχωρίζοντας τους πιθανούς τομείς χρήσης στη μελλοντική δομή εργασιών των διαχειριστών δικτύου, μπορούν να καθοριστούν συγκεκριμένοι τομείς εφαρμογής με βάση τα δυνατά σημεία των διαφόρων μεθόδων TN:

- Έξυπνη επιτήρηση συστήματος
- Διαχείριση ροής φορτίου
- Τεκμηρίωση (documentation) συστήματος και υποδομής
- Ασφάλεια εργασίας
- Πρόβλεψη προσφοράς (παραγωγής) και ζήτησης (φορτίου)
- Επιτήρηση δικτύου
- Επιθεώρηση και συντήρηση
- Ανθρώπινοι πόροι – κατανομή προσωπικού
- Κυβερνοασφάλεια

Ιδιαίτερα για τον τομέα της επιτήρησης δικτύου, που γίνεται αναφορά και στη συνέχεια, η TN μπορεί να αξιοποιηθεί για να παράγει εκτιμήσεις της κατάστασης του δικτύου βασισμένη σε λίγους μετρητές, αυξάνοντας την παρατηρησιμότητα του δικτύου και αμβλύνοντας την ανάγκη εκτεταμένης εγκατάστασης εξοπλισμού (πχ μετρητών, αισθητήρων κτλ).

[Αυτή η σελίδα είναι σκόπιμα λευκή]

Ανίχνευση Τοπολογίας (Topology Detection)

4.1 Ορισμός προβλήματος – βιβλιογραφική ανασκόπηση

Διατύπωση προβλήματος

Με τον όρο **ανίχνευση τοπολογίας (topology detection – TD)** αναφερόμαστε στο πρόβλημα προσδιορισμού της φυσικής διάταξης (τοπολογίας) του δικτύου διανομής ενέργειας [54]. Για να αποσαφηνιστεί με μεγαλύτερη ακρίβεια, στη βιβλιογραφία γίνεται διάκριση μεταξύ των όρων topology detection και topology identification [55]. Στην ανίχνευση τοπολογίας (topology detection), ο διαχειριστής γνωρίζει την υπάρχουσα υποδομή των γραμμών και τις αντιστάσεις τους και καλείται να μάθει ποιες γραμμές έχουν ηλεκτριστεί. Στην ταυτοποίηση τοπολογίας (topology identification), ο διαχειριστής στοχεύει στην ταυτοποίηση τόσο της σύνδεσης των γραμμών όσο και των αντιστάσεών τους, διαμορφώνοντας έτσι ένα πιο σύνθετο πρόβλημα, που δεν απασχολεί στα πλαίσια της παρούσας διπλωματικής εργασίας.

Η ανίχνευση τοπολογίας είναι καίριο και επίκαιρο θέμα ερευνητικής δραστηριότητας, αφού παίζει σημαντικό ρόλο στη λειτουργία και τον έλεγχο των ενεργειακών δικτύων [24]. Τα τελευταία χρόνια, αρκετές διακοπές ρεύματος σε περιοχές παγκοσμίως έχουν προκαλέσει σημαντικές οικονομικές απώλειες και αρνητικές κοινωνικές επιπτώσεις. Η ραγδαία εξάπλωση των διεσπαρμένων πηγών παραγωγής ενέργειας και η επέκταση των δικτύων αποτελεί πρόκληση για τη λειτουργία τους, καλώντας για την ανάπτυξη προηγμένων λύσεων ελέγχου, βελτιστοποίησης και παρακολούθησης [56].

Τα υπάρχοντα συστήματα ασφαλείας για τα δίκτυα ηλεκτρικής ενέργειας, που επικεντρώνονται στη μοντελοποίηση, την προσομοίωση και την πρόβλεψη βλαβών, έχουν φτάσει στα όρια των δυνατοτήτων τους και αμφισβητούνται. Με την ταχεία ανάπτυξη των συστημάτων μέτρησης και την αυξανόμενη ωριμότητα της τεχνολογίας μεγάλων δεδομένων, η εκτίμηση κατάστασης και ο έλεγχος των λειτουργιών του δικτύου με βάση τις πληροφορίες για την πραγματική λειτουργία του δικτύου έχει αναδειχθεί ως το νέο μοντέλο για την ασφαλή λειτουργία τους [57]. Επιπλέον, οι αυξανόμενες αβεβαιότητες γύρω από τη χρήση της ανανεώσιμης ενέργειας έχουν θέσει πρωτοφανείς προκλήσεις για την εξασφάλιση της ασφαλούς και οικονομικής λειτουργίας των σύγχρονων συστημάτων ηλεκτρικής ενέργειας [58]. Η σύγχρονη πρακτική καταλήγει ότι αυτές οι εργασίες δεν μπορούν να εκτελεστούν χωρίς τη γνώση της τοπολογίας του δικτύου. Επιπλέον, η γνώση της τοπολογίας του δικτύου είναι θεμελιώδης κατά τη διαδικασία αποκατάστασης του δικτύου μετά από ένα καταστροφικό γεγονός [59].

Η κατάσταση ενός ΣΗΕ μπορεί να καθοριστεί πλήρως σε μια δεδομένη χρονική στιγμή εάν είναι γνωστό το μοντέλο του συστήματος, δηλαδή η διάταξη όλων των κόμβων και των κλάδων που το αποτελούν και οι τιμές των σχετικών τους παραμέτρων, καθώς και οι φασιθέτες (phasors) τάσης σε κάθε κόμβο του.

Φυσικά οι διαχειριστές των δικτύων γνωρίζουν τις γραμμές που συνδέουν τους κόμβους και τις παραμέτρους τους. Ωστόσο, εκτός από τις σταθερές γραμμές που είναι πάντα ενεργοποιημένες, υπάρχουν και γραμμές διακοπών (διακόπτες για συντομία στο εξής), οι οποίες, ανάλογα με το αν είναι ενεργοποιημένοι ή όχι, καθορίζουν την πραγματική τοπολογία του δικτύου.

Το 1970, οι Schweppe et al. έχοντας διαγνώσει την εγγενή αδυναμία των μετρητικών συστημάτων να συλλάβουν την πραγματική κατάσταση ενός ΣΗΕ, εισήγαγαν την εκτίμηση κατάστασης (State Estimation) στη μελέτη των ΣΗΕ με απώτερο στόχο το βέλτιστο έλεγχο της λειτουργίας τους σε πραγματικό χρόνο [60]. Η ανίχνευση της τοπολογίας αποτελεί απαραίτητη προϋπόθεση για την εκτίμηση κατάστασης [61] [62].

Στα δίκτυα μεταφοράς, οι μέθοδοι για την ανίχνευση τοπολογίας είναι πιο ώριμες λόγω της διαθεσιμότητας των δεδομένων των συστημάτων προστασίας και του συστήματος SCADA. Σε αντίθεση, το σύστημα διανομής ηλεκτρικής ενέργειας υστερεί σε σύγκριση με το δίκτυο μεταφοράς στη διαθεσιμότητα δεδομένων. Ταυτόχρονα όμως το σύστημα διανομής αντιμετωπίζει περισσότερες αλλαγές τοπολογίας σε σύγκριση με τα δίκτυα μεταφοράς λόγω της υψηλότερης δυναμικής των φορτίων, της αυξημένης συχνότητας βλαβών και της πρόσφατης υψηλής διείσδυσης των διανεμημένων πηγών ενέργειας (DERs), κάτι που αυξάνει την σημασία της εκτίμησης κατάστασης και της ανίχνευσης τοπολογίας. Επιπλέον, οι προσπάθειες βελτιστοποίησης volt-var μπορούν επίσης να αυξήσουν τις αλλαγές τοπολογίας στο σύστημα διανομής [63].

Η κατανόηση της τοπολογίας, της δομής ενός δικτύου ενέργειας και των νόμων που διέπουν τις αλλαγές της είναι το θεμέλιο για την υλοποίηση της λειτουργίας και του ελέγχου που βασίζεται στα δεδομένα (data-driven operation and control). Στη βιβλιογραφία υπάρχουν ανεπτυγμένες αρκετές μεθοδολογίες για την επίλυση του προβλήματος αναγνώρισης τοπολογίας [64].

Ορισμένες μελέτες έχουν χρησιμοποιήσει τον πίνακα συμβάντων (incidence matrix) και τον πίνακα γειτνίασης (adjacency matrix) που κατασκευάζονται με τη χρήση της κατάστασης διακοπών του συστήματος για να καθορίσουν τη συνδεσιμότητά του και να παρακολουθούν τις τοπολογικές αλλαγές [65] [66] [67]. Άλλες προηγούμενες εργασίες για την ανίχνευση τοπολογιών των δικτύων διανομής βασίζονται στα στατιστικά δεύτερης τάξης των δεδομένων του δικτύου [68]. Γραφικά μοντέλα έχουν χρησιμοποιηθεί για τη δημιουργία δέντρου επικάλυψης (spanning tree) βασισμένου στην αμοιβαία πληροφορία (mutual information) των δεδομένων τάσης [69]. Μέθοδοι ανάκτησης δέντρων που λειτουργούν τόσο από τα κάτω προς τα πάνω όσο και από τα πάνω προς τα κάτω έχουν σχεδιαστεί στις αναφορές [70] [71] [72]. Στην βιβλιογραφία επίσης η ανίχνευση τοπολογίας έχει θεωρηθεί ως ένα πρόβλημα μέγιστης πιθανοφάνειας (maximum likelihood problem) [73].

Από την αναζήτηση της σχετικής βιβλιογραφίας τεκμηριώνεται ότι η ανάπτυξη έξυπνων μετρητών και D-PMUs διευκολύνει λειτουργίες του δικτύου όπως οι εφαρμογές ανίχνευσης τοπολογίας. Τα πλεονεκτήματα των δεδομένων μέτρησης D-PMUs υψηλής ανάλυσης έχουν αποδειχθεί σε διάφορες εφαρμογές όπως η εκτίμηση κατάστασης [74] [75] [76], η ανίχνευση βλαβών [77] [78] [79], ο έλεγχος volt-var [80] [81] και η ανίχνευση τοπολογίας [63] [82] [83] [84] [85] [86] [87]. Οι κλασικές μέθοδοι

ανίχνευσης τοπολογίας βασίζονται κυρίως στην εκτίμηση κατάστασης με βάρη ελαχίστων τετραγώνων [88]. Σε αυτές τις μεθόδους, η κατάσταση του διακόπτη θεωρείται ως μια από τις μεταβλητές του εκτιμητή κατάστασης.

Στη βιβλιογραφία υπάρχουν πολλές προσεγγίσεις, όπως η θεωρία γραφημάτων και η γραφική μοντελοποίηση (graphical modelling) [89], τα πιθανοτικά γραφικά μοντέλα (probabilistic graphical model) [90] [91]. Στο [63] παρουσιάζεται μια συλλογή όλων των δυνατών τοπολογιών σε σύγκριση με τις χρονοσειρές πραγματικού χρόνου των μετρήσεων τάσης, αλλά μπορεί να υποστηριχθεί ότι οι παράμετροι των γραμμών δεν είναι διαθέσιμες συνέχεια. Ένας αναδρομικός αλγόριθμος ομαδοποίησης (recursive grouping algorithm) προτείνεται στο [92] για την επαλήθευση τοπολογίας βασισμένη στην εκτίμηση των παραμέτρων γραμμής. Σε μια άλλη ομάδα μελετών, η αναγνώριση τοπολογίας βασισμένη στη μετατροπή ενέργειας αναπτύσσεται χρησιμοποιώντας μόνο δεδομένα έξυπνων μετρητών [93].

Ωστόσο, τα δεδομένα που συλλέγονται κάθε ώρα μπορεί να μην είναι αρκετά γρήγορα για την ανίχνευση τοπολογίας λόγω της δυναμικής φορτίου-παραγωγής. Πρόσφατα, η προσέγγιση βαθιάς μάθησης έχει κερδίσει μεγάλη δημοτικότητα στην επιστήμη δεδομένων λόγω της βελτιωμένης απόδοσης και κλιμάκωσης. Στον τομέα του ηλεκτρικού συστήματος, οι μέθοδοι βαθιάς μάθησης έχουν χρησιμοποιηθεί εκτενώς για την ανίχνευση επιθέσεων εισαγωγής ψευδών δεδομένων [94] [95] [96], την πρόβλεψη φορτίου [97] [98] [99], τη μοντελοποίηση φορτίου [100] [101]. Οι εφαρμοσμένες μέθοδοι προσφέρουν γρήγορη σύγκλιση σε θέματα υψηλής υπολογιστικής πολυπλοκότητας.

4.2. Η μέθοδος αντιστοίχισης πυρήνα – κόμβου (kernel – node mapping)

Στα πλαίσια της παρούσας διπλωματικής, μελετήθηκε με βάση την βιβλιογραφία [54] ένας αλγόριθμος που βασίζεται στη βαθιά μάθηση και τις μονάδες D-PMU του δικτύου διανομής. Ο πυρήνας της προτεινόμενης μεθόδου είναι η διατύπωση του προβλήματος ανίχνευσης τοπολογίας ως διαδικασία αντιστοίχισης της συλλογής δεδομένων μέτρησης με το σύνολο εφικτών τοπολογιών μέσω συνελκτικών νευρωνικών δικτύων (CNNs). Σε αυτή τη βάση αναπτύσσεται το δίκτυο Kernel-node-map Deep Network (KNDN).

Είναι γνωστό ότι οι σχέσεις μεταξύ φασιθετών τάσεων και ρευμάτων, ενεργού και άεργου ισχύος είναι μη γραμμικές. Η επίλυση αυτών των περίπλοκων μη γραμμικών εξισώσεων είναι επίπονη, ειδικά σε ένα σύστημα διανομής του οποίου δεν είναι γνωστές όλες οι παράμετροι. Για την αντιμετώπιση της παραπάνω πρόκλησης, χρησιμοποιούνται μέθοδοι βαθιάς μάθησης (deep learning) για την ανίχνευση τοπολογίας.

Στο δίκτυο διανομής, τα CNN νευρωνικά έχουν ερευνηθεί εκτενώς λόγω της εξαιρετικής τους ικανότητας ανίχνευσης τοπικών χαρακτηριστικών (local sensing) και έχουν χρησιμοποιηθεί για τον εντοπισμό βλαβών [102], την αναγνώριση αλλαγής κατάστασης διακοπών (switch action identification) [103] και την ταξινόμηση διαταραχών

(distrurbance) [104]. Έτσι, το CNN επιλέγεται ως βάση για την υλοποίηση της διαδικασίας απεικόνισης των δεδομένων μέτρησης στην κατάσταση των διακοπών.

Όμως, λόγω της ποικιλίας των τοπολογιών των δικτύων διανομής, η κοινή χρήση βαρών στα CNN μπορεί να παρεμποδίσει την εφαρμογή τους για την αναγνώριση τοπολογίας. Σε τυπικές εφαρμογές επεξεργασίας εικόνων, ένας πίνακας κοινών βαρών μπορεί αποτελεσματικά να εξάγει χαρακτηριστικά σύροντας το φίλτρο σε όλη την εικόνα. Ωστόσο, στο πλαίσιο της αναγνώρισης τοπολογίας για τα συστήματα διανομής, ένας συγκεκριμένος πυρήνας CNN δεν μπορεί να γενικευτεί για να χειριστεί όλες τις εισόδους που σχετίζονται με μια δεδομένη τοπολογία. Ως εκ τούτου, ένας συγκεκριμένος πυρήνας CNN είναι αποτελεσματικός μόνο για μία τοπική είσοδο του μεγέθους του πυρήνα και όχι καθολικά για όλες τις εισόδους. Για να αντιμετωπιστούν αυτοί οι περιορισμοί, προτείνεται μια τροποποιημένη δομή CNN. Έτσι, διαμορφώνεται η μεθοδολογία KNDN, η οποία βασίζεται στην έννοια της αντιστοίχισης «πυρήνα-κόμβου» για να προσαρμοστεί πιο αποτελεσματικά στις προκλήσεις που παρουσιάζει η πολυπλοκότητα των συστημάτων διανομής [105].

Για να βελτιωθεί η εξαγωγή χαρακτηριστικών στη βάση της φυσικής τοπολογίας του δικτύου, προτείνεται μια μεθοδολογία αντιστοίχισης των κόμβων του δικτύου με τους πυρήνες του CNN. Με βάση αυτή τη μέθοδο ένα σύνολο πυρήνων αντιστοιχίζεται με πολλαπλούς υπογράφους που περιέχουν επιλεγμένους κόμβους.

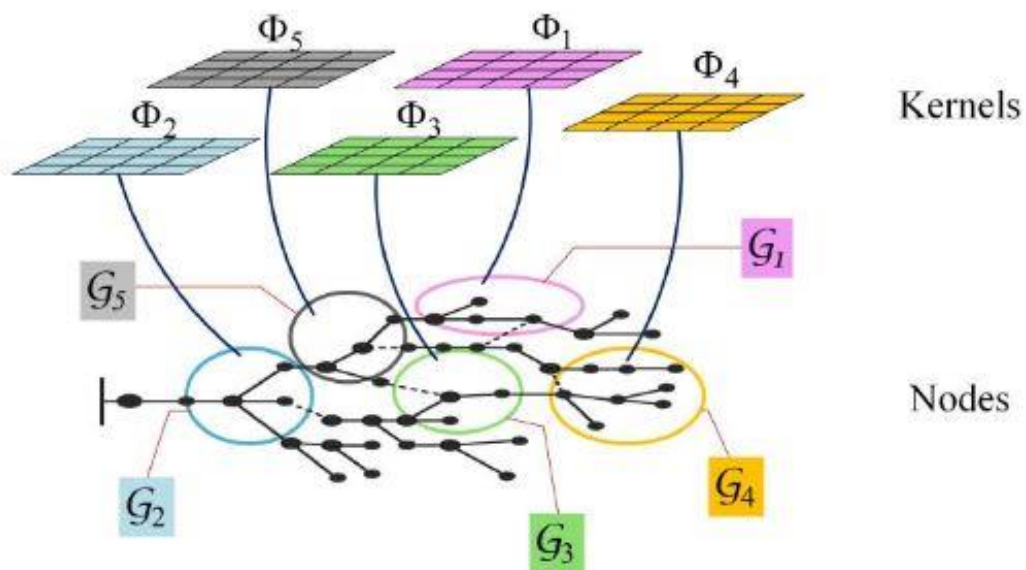


Figure 14 Μεθοδολογία αντιστοίχισης πυρήνα – κόμβου [54]

5. Δημιουργία συνόλου δεδομένων

5.1 Εντοπισμός εφικτών τοπολογιών στο testbed modified IEEE 33 bus system

Για την πραγματοποίηση προσομοιώσεων δικτύων ενέργειας στην ερευνητική βιβλιογραφία προτιμάται συχνά η χρήση συγκεκριμένων testbed της IEEE. Πρόκειται για πρότυπα συστήματα ηλεκτρικών δικτύων που έχουν αναπτυχθεί ακριβώς για την αξιολόγηση και δοκιμή αλγορίθμων και τεχνικών στην ανάλυση και τον έλεγχο των ηλεκτρικών δικτύων. Αυτά τα πρότυπα συστήματα προσομοιώνουν διαφορετικά μεγέθη και τύπους ηλεκτρικών δικτύων, από μικρά τοπικά δίκτυα έως μεγάλα διασυνδεδεμένα συστήματα και χρησιμοποιούνται ως κοινή βάση για τη σύγκριση και την αξιολόγηση της απόδοσης διαφόρων αλγορίθμων και μεθόδων. Διευκολύνουν έτσι την εκπαίδευση και την έρευνα στην ακαδημαϊκή κοινότητα, παρέχοντας ένα κοινό πλαίσιο αναφοράς.

Το σύστημα ηλεκτρικής ενέργειας που επιλέχθηκε για την εφαρμογή της διπλωματικής και την δημιουργία του συνόλου δεδομένων (dataset) είναι το τροποποιημένο πρότυπο 33 ζυγών της IEEE (modified IEEE 33-bus) [54]. Το σύστημα αυτό είναι μια παραλλαγή του αρχικού IEEE 33-bus distribution system, το οποίο είναι ένα από τα πιο συχνά χρησιμοποιούμενα πρότυπα συστήματα για τη μελέτη των δικτύων διανομής ηλεκτρικής ενέργειας. Το σύστημα αυτό αποτελείται από 33 ζυγούς (buses), 37 γραμμές (branches), 1 γεννήτρια στον ζυγό 1 (slack bus) [106] [107].

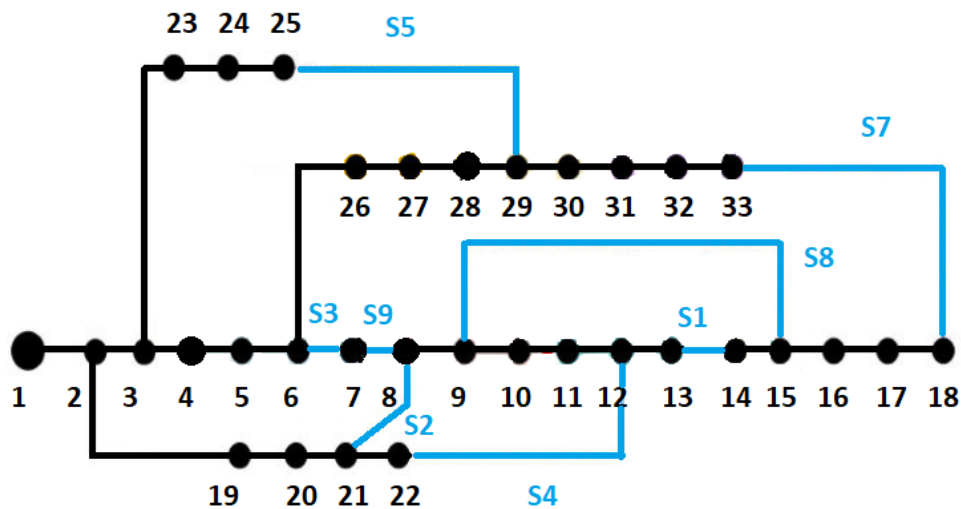


Figure 15 Σχεδιάγραμμα του modified IEEE 33 bus system

Το δίκτυο διαθέτει 9 διακόπτες. Ο κάθε διακόπτης μπορεί να είναι είτε ανοιχτός (0), είτε κλειστός (1). Κάθε φορά που αλλάζει η κατάσταση ενός διακόπτη, διαμορφώνεται μια διαφορετική τοπολογία στο δίκτυο. Αρχικά στόχος είναι η εύρεση των πιθανών τοπολογιών του δικτύου. Επομένως θεωρητικά υπάρχουν $2^9 = 512$ δυνατές πιθανές τοπολογίες. Όμως πρέπει να παρατηρηθεί ότι δεν έχουν όλες φυσικό νόημα ή με άλλα λόγια δεν είναι όλες εφικτές.

Οι εφικτές τοπολογίες ορίζονται ως εκείνες που διατηρούν το δίκτυο σε μια ακτινωτή και φυσικά συνδεδεμένη κατάσταση. Για να εντοπιστούν οι εφικτές τοπολογίες αξιοποιήθηκε η θεωρία γράφων. Κάθε δίκτυο διανομής μοντελοποιείται ως ένας γράφος, όπου οι κόμβοι του γράφου αποτελούν τους ζυγούς του δικτύου και οι ακμές του γράφου αποτελούν τις γραμμές διανομής ενέργειας.

Πραγματοποιήθηκε διερεύνηση για τις πιθανές επιτρεπτές τοπολογίες με βάση δύο κριτήρια [24]:

- **Συνδεδεσιμότητα:** Σε μια εφικτή τοπολογία το δίκτυο διατηρείται φυσικά συνδεδεμένο και δεν παρουσιάζονται αποκοπές. Δηλαδή κάθε εφικτή τοπολογία απαιτείται να είναι ακτινωτή. Αυτό σημαίνει ότι όλοι οι κόμβοι του γράφου πρέπει να μπορούν να συνδεθούν μεταξύ τους μέσω μιας διαδοχικής αλληλουχίας γραμμών.
- **Αποφυγή Βρόχων:** Ο γράφος που αναπαριστά το δίκτυο δεν πρέπει να περιέχει βρόχους.

Για να ελεγχθούν αυτά τα δύο βασικά κριτήρια στο σύνολο των πιθανών τοπολογιών αναπτύχθηκε κώδικας στη γλώσσα προγραμματισμού Python. Στο πρόγραμμα εισήχθησαν οι 512 πιθανοί γράφοι και η έξοδος του προγράμματος έβγαζε ως αποτέλεσμα αν σχηματίζονται βρόχοι στο γράφο και αν ο γράφος είναι συνδεδεμένος. Υπάρχουν σχετικές συναρτήσεις στις βιβλιοθήκες της python που υλοποιούν τα παραπάνω [108].

Με βάση τον έλεγχο που πραγματοποιήθηκε, οι γράφοι που ικανοποιούν ταυτόχρονα και τα δύο παραπάνω κριτήρια είναι 49. Επομένως η διερεύνηση καταλήγει στον εντοπισμό 49 εφικτών τοπολογιών.

Ως παράδειγμα παρατίθεται στο Figure 16 ο γράφος που παριστά μια εφικτή τοπολογία, την τοπολογία που ονομάστηκε «τοπολογία 1». Αντιστοίχως δημιουργήθηκε το σύνολο των εφικτών τοπολογιών με ένα σύνολο 49 γράφων.




Figure 16 ο γράφος που αναπαριστά την τοπολογία 1

5.2 Προσομοίωση στο περιβάλλον Matlab

Για την δημιουργία του συνόλου δεδομένων (dataset) για την εκπαίδευση του CNN δεν ήταν εφικτό να χρησιμοποιηθούν δεδομένα από πραγματικές εγκατεστημένες μονάδες D-PMUs λόγω διαφόρων παραγόντων. Πρώτον, η πρόσβαση σε τέτοια δεδομένα είναι συνήθως περιορισμένη λόγω της προστασίας προσωπικών δεδομένων λόγω της ιδιωτικότητας που σχετίζονται με τα ενεργειακά δίκτυα. Οι εταιρείες ηλεκτρισμού διστάζουν να διαθέσουν τα δεδομένα τους λόγω πιθανών κινδύνων ασφάλειας και εμπορικών συμφερόντων, διαδικασιών ανωνυμοποίησης που πρέπει να ακολουθηθούν κτλ. Σε περίπτωση που βρίσκονταν τέτοια δεδομένα, σημειώνεται επιπλέον ότι θα χρειαζόταν επιπρόσθετες διαδικασίες για την προεπεξεργασία, τον καθαρισμό και έλεγχο των δεδομένων. Με βάση τα παραπάνω, στα πλαίσια της παρούσας εργασίας επιλέχθηκε η λύση της προσομοίωσης στο MATLAB, η οποία προσφέρει μεγαλύτερη ευελιξία, επιτρέπει τον έλεγχο όλων των παραμέτρων του συστήματος, και παρέχει τη δυνατότητα αναπαράστασης διαφορετικών σεναρίων με ακρίβεια και αξιοπιστία χωρίς την ανάγκη πρόσβασης σε πραγματικά δεδομένα [109].

Το Matlab, ευρέως γνωστό ως ένα περιβάλλον προγραμματισμού και γλώσσα υψηλού επιπέδου, αποτελεί ένα χρήσιμο εργαλείο για τους μηχανικούς, τους επιστήμονες και τους ερευνητές σε διάφορους τομείς, κυρίως λόγω της ευκολίας και της αποδοτικότητας του στον χειρισμό αριθμητικών υπολογισμών, στην ανάλυση και οπτικοποίηση δεδομένων. Το Matlab προσφέρει μια πληθώρα ενσωματωμένων συναρτήσεων που καλύπτουν ένα ευρύ φάσμα εφαρμογών από την επεξεργασία σημάτων και την ανάλυση εικόνων μέχρι τη μηχανική μάθηση και τους αλγορίθμους ελέγχου.

Ειδικότερα στα πλαίσια της διπλωματικής εργασίας αξιοποιήθηκε το πακέτο MATPOWER, ένα εργαλείο ανοιχτού κώδικα για την προσομοίωση και οπτικοποίηση ΣΗΕ διαθέσιμο για το Matlab [110]. Το MATPOWER είναι ιδιαίτερα χρήσιμο για τη μοντελοποίηση διαδικασιών όπως η ανάλυση ροής ισχύος και η βέλτιστη ροή ισχύος, κρίσιμες για την ανάπτυξη αξιόπιστων και αποδοτικών συστημάτων ηλεκτρικής ενέργειας.

Ο default αλγόριθμος που χρησιμοποιείται από το MATPOWER για την επίλυση του προβλήματος ροής ισχύος είναι ο αλγόριθμος Newton-Raphson. Αυτός ο αλγόριθμος είναι ευρέως δημοφιλής λόγω της αποτελεσματικότητάς του στη γρήγορη σύγκλιση προς τη λύση, κυρίως σε συστήματα μεγάλης κλίμακας. Ο αλγόριθμος Newton-Raphson στο MATPOWER ξεκινά με την καθορισμό των αρχικών παραμέτρων του δικτύου, όπως τις τάσεις στους κόμβους, τις γωνίες των τάσεων, και τα φορτία σε κάθε κόμβο. Στην συνέχεια, ο αλγόριθμος αξιολογεί την αρχική κατανομή των φορτίων και ροών ισχύος στο δίκτυο. Χρησιμοποιώντας αυτές τις αρχικές τιμές, ο αλγόριθμος εφαρμόζει διαδοχικές διορθώσεις: υπολογίζει τα σφάλματα μεταξύ των πραγματικών τιμών και των επιθυμητών τιμών των ηλεκτρικών μεγεθών και προσαρμόζει τις τιμές για να μειώσει αυτά τα σφάλματα. Ο αλγόριθμος επαναλαμβάνεται μέχρι οι υπολογισμένες τιμές να συγκλίνουν προς μια σταθερή κατάσταση ισορροπίας που ικανοποιεί τις όλες τις λειτουργικές απαιτήσεις του δικτύου ικανοποιώντας τους περιορισμούς [111].

Βεβαίως το πρόβλημα ροής φορτίου μπορεί να επιλυθεί και με άλλους αλγόριθμους, όπως ο Gauss-Seidel και ο Fast Decoupled. Η επιλογή του κατάλληλου αλγόριθμου εξαρτάται από τη φύση του δικτύου και τις συγκεκριμένες απαιτήσεις της ανάλυσης. Στα πλαίσια της εργασίας χρησιμοποιήθηκε ο αλγόριθμος Newton-Raphson.

Αξιοποιήθηκε η εντολή “runpf” που εκτελεί την επίλυση της ροής ισχύος του κυκλώματος [112] [113]. Εκτός από την απεικόνιση των αποτελεσμάτων στην οθόνη, η οποία αποτελεί την προκαθορισμένη λειτουργία, η συνάρτηση runpf μπορεί επίσης να παρέχει τα αποτελέσματα σε μια δομή δεδομένων – αποτελεσμάτων (results structure). Αυτή η δομή αποτελεσμάτων παρέχει δεδομένα σχετικά με τη λύση της ροής ισχύος, συμπεριλαμβάνοντας στοιχεία όπως τις τάσεις στους ζυγούς, τις ροές ισχύος στους κλάδους και άλλες σχετικές παραμέτρους, επιτρέποντας έτσι στους χρήστες να ανακτούν και να αναλύουν τα δεδομένα της ανάλυσης ροής ισχύος.

Στη συνέχεια έγινε παρατήρηση των αποτελεσμάτων που προέκυψαν από την επίλυση της ροής ισχύος των 49 δικτύων. Με την παρατήρηση που έγινε, απορρίφθηκαν οι τοπολογίες στις οποίες οι μετρήσεις των τάσεων στους κόμβους ήταν χαμηλότερες από 0,95 pu (per unit – ανά μονάδα) για λόγους αξιοπιστίας και ασφάλειας του δικτύου. Οι τάσεις κάτω από το όριο αυτό υποδεικνύουν ότι το σύστημα λειτουργεί υπό συνθήκες αυξημένου φορτίου ή μειωμένης απόδοσης, γεγονός που μπορεί να οδηγήσει σε σοβαρά προβλήματα όπως η αστάθεια του συστήματος και η μειωμένη ποιότητα της παρεχόμενης ηλεκτρικής ενέργειας. Σε ακτινικά δίκτυα διανομής, όπως το υπό μελέτη σύστημα, η διατήρηση των τάσεων πάνω από το κατώτατο όριο των 0,95 pu είναι κρίσιμη για την εξασφάλιση της σωστής λειτουργίας και αποφυγής υπερβολικών απωλειών ή αποτυχίας σύγκλισης σε πιο απαιτητικές συνθήκες.

Επιπλέον, οι τοπολογίες με τάσεις κάτω από 0,95 pu υποδεικνύουν ότι αντί να μειώνουν το φορτίο του δικτύου, δημιουργούν συμφόρηση σε ορισμένες γραμμές, με αποτέλεσμα την περαιτέρω πτώση των τάσεων, η οποία σε ορισμένες περιπτώσεις μπορεί να είναι ακόμα και κάτω από 0,90 pu. Τέτοιες τοπολογίες κρίνονται ακατάλληλες για ανάλυση και περαιτέρω επεξεργασία, καθώς δεν επιτυγχάνουν τη βελτιστοποίηση του δικτύου και ενδέχεται να οδηγήσουν σε αποτυχία σύγκλισης των αλγορίθμων ανάλυσης, ιδιαίτερα όταν τα φορτία αυξομειώνονται. Για αυτούς τους λόγους, προτιμήθηκε να συνεχιστεί η ανάλυση μόνο με τις τοπολογίες στις οποίες οι τάσεις παραμένουν πάνω από το κατώτατο όριο των 0,95 pu, διασφαλίζοντας έτσι την αξιοπιστία και την αποδοτικότητα του συστήματος.

Με βάση αυτό το κριτήριο από τις 49 τοπολογίες τελικά διαμορφώνεται ένα σύνολο 26 εφικτών τοπολογιών. Η κάθε τοπολογία μπορεί να αναπαρασταθεί με βάση την κατάσταση των 9 διακοπών του δικτύου. Οι 26 τοπολογίες καταγράφονται στον πίνακα με την κατάσταση των διακοπών να αποτυπώνεται στον πίνακα 5.1.

Topology	S1	S2	S3	S4	S5	S6	S7	S8	S9
topology1	0	0	0	1	0	1	0	1	1
topology2	0	0	0	1	0	1	1	0	1
topology3	0	0	0	1	0	1	1	1	1
topology4	0	0	0	1	1	0	0	1	1
topology5	0	0	0	1	1	0	1	1	1
topology6	0	0	1	0	0	0	1	1	1
topology7	0	0	1	0	0	1	1	1	0
topology8	0	0	1	1	0	0	1	1	0
topology9	0	0	1	1	1	0	0	1	0
topology10	0	1	0	0	0	0	1	1	1
topology11	0	1	0	0	0	1	0	1	1
topology12	0	1	0	0	0	1	1	0	1
topology13	0	1	0	0	1	0	1	0	1
topology14	0	1	1	0	0	0	1	1	0
topology15	0	1	1	0	0	1	0	1	0
topology16	0	1	1	0	0	1	1	0	0
topology17	1	0	0	0	1	0	1	0	1
topology18	1	0	0	1	0	0	1	0	1
topology19	1	0	0	1	1	0	0	0	1
topology20	1	0	1	0	0	1	0	0	1
topology21	1	0	1	0	1	0	1	0	0
topology22	1	0	1	1	0	0	1	0	0
topology23	1	0	1	1	1	0	0	0	0
topology24	1	1	0	0	0	0	1	0	1
topology25	1	1	0	0	1	0	0	0	1
topology26	1	1	1	0	0	0	1	0	0

Table 1 Εφικτές τοπολογίες του modified IEEE 33 bus system

Για τη δημιουργία του τελικού συνόλου δεδομένων, εκτελέστηκε η εντολή «runpf» 1000 φορές για τις 26 εφικτές τοπολογίες του δικτύου modified IEEE 33-bus system. Η επαναληπτική εκτέλεση αυτής της εντολής ήταν απαραίτητη για να προκύψει ένα επαρκώς μεγάλο σύνολο δεδομένων που θα χρησιμοποιηθεί για την εκπαίδευση και τον έλεγχο των μοντέλων που θα αναπτυχθούν στη συνέχεια. Η διαδικασία αυτή εξασφαλίζει ότι το σύνολο των δεδομένων καλύπτει ένα ευρύ φάσμα πιθανών καταστάσεων λειτουργίας του δικτύου, προσδίδοντας στα μοντέλα τη δυνατότητα να αναγνωρίσουν και να προσαρμοστούν σε διάφορες συνθήκες λειτουργίας.

Για την επίτευξη της ποικιλίας αυτής, εφαρμόστηκε ομοιόμορφη κατανομή με τυπική απόκλιση $\sigma = 0.15$ στις τιμές των φορτίων του δικτύου. Η ομοιόμορφη κατανομή είναι μια από τις πιο βασικές και συχνά χρησιμοποιούμενες κατανομές στην στατιστική, ειδικά όταν είναι επιθυμητό να δημιουργηθούν τυχαίες μεταβλητές που έχουν ίση πιθανότητα εμφάνισης εντός ενός συγκεκριμένου εύρους τιμών. Στο πλαίσιο της δημιουργίας του συνόλου δεδομένων, η ομοιόμορφη κατανομή εφαρμόστηκε στα φορτία του δικτύου για να προσομοιωθούν διαφορετικές λειτουργικές συνθήκες, δημιουργώντας μια ποικιλία σεναρίων που αντιπροσωπεύουν τις δυνατές καταστάσεις που μπορεί να αντιμετωπιστούν σε πραγματικές συνθήκες.

Πιο συγκεκριμένα, η ομοιόμορφη κατανομή χαρακτηρίζεται από δύο παραμέτρους, το κατώτερο όριο και το ανώτερο όριο, μέσα στα οποία οι τιμές της μεταβλητής είναι ισοκατανεμημένες. Αυτό σημαίνει ότι κάθε τιμή εντός αυτού του εύρους έχει την ίδια πιθανότητα να επιλεγεί. Στην προσομοίωση των φορτίων του δικτύου, το εύρος τιμών επιλέγεται ώστε να καλύπτει τις πιθανές διακυμάνσεις στα φορτία που μπορεί να προκύψουν κατά τη διάρκεια της λειτουργίας του δικτύου. Η χρήση ομοιόμορφης κατανομής επιτρέπει την εκτίμηση της επίδρασης διαφορετικών επιπέδων ζήτησης ηλεκτρικής ενέργειας στο δίκτυο, διασφαλίζοντας ότι η προσομοίωση καλύπτει ένα ευρύ φάσμα πιθανών συνθηκών λειτουργίας.

Η απόφαση για την εφαρμογή της ομοιόμορφης κατανομής (με τυπική απόκλιση $\sigma = 0.15$) στα φορτία του δικτύου έχει ως στόχο να εξασφαλίσει ότι η προσομοίωση δεν επικεντρώνεται σε συγκεκριμένα σενάρια αλλά αντίθετα εξετάζει όλες τις πιθανές παραλλαγές λειτουργίας του συστήματος. Αυτό είναι ιδιαίτερα σημαντικό για την ανάπτυξη μοντέλων που πρέπει να είναι ευέλικτα και ικανά να ανταποκρίνονται σε ποικίλες καταστάσεις. Ενσωματώνοντας την ομοιόμορφη κατανομή, οι τιμές των φορτίων διαμορφώνονται έτσι ώστε να αντιπροσωπεύουν όχι μόνο τις συνήθεις λειτουργικές συνθήκες αλλά και τις ακραίες καταστάσεις, παρέχοντας έτσι μια ισχυρή βάση για την αξιολόγηση της απόδοσης και της αξιοπιστίας των μοντέλων που αναπτύσσονται. Η επιλογή αυτής της κατανομής επιτρέπει επίσης την αποφυγή της προκατάληψης που μπορεί να προκύψει από τη χρήση πιο εξειδικευμένων ή μη ισοκατανεμημένων προσεγγίσεων, οι οποίες ενδέχεται να δώσουν έμφαση μόνο σε ορισμένα σενάρια εις βάρος άλλων.

Επιπλέον, για να διασφαλιστεί ότι οι προσομοιώσεις είναι ρεαλιστικές και αντιπροσωπεύουν τις συνθήκες που θα προέκυπταν από μετρήσεις πραγματικών Phasor Measurement Units (D-PMUs), προστέθηκε γκαουσιανός θόρυβος στις τιμές των τάσεων και των ρευμάτων. Ο γκαουσιανός θόρυβος, γνωστός και ως κανονικός θόρυβος, είναι μια κοινή προσέγγιση για τη μοντελοποίηση τυχαίων διαταραχών και αβεβαιοτήτων σε διάφορα συστήματα, συμπεριλαμβανομένων των ηλεκτρικών δικτύων. Η κανονική κατανομή που τον χαρακτηρίζει περιγράφεται από δύο παραμέτρους: τη μέση τιμή (μέσος όρος) και την τυπική απόκλιση (σ). Ο γκαουσιανός θόρυβος έχει τη σημαντική ιδιότητα ότι οι τιμές του τείνουν να συγκεντρώνονται γύρω από τη μέση τιμή, με τις αποκλίσεις να ακολουθούν την τυπική κατανομή, κάτι που είναι χρήσιμο για τη μοντελοποίηση των σφαλμάτων μετρήσεων που τείνουν να κατανέμονται γύρω από την πραγματική τιμή με μικρές, αλλά όχι απίθανες, πιθανότητες για μεγαλύτερες αποκλίσεις.

Στο πλαίσιο της προσομοίωσης του τροποποιημένου συστήματος IEEE 33-bus, η προσθήκη γκαουσιανού θορύβου με τυπική απόκλιση $\sigma = 0.1\%$ στις τιμές των τάσεων και των ρευμάτων αποσκοπεί στην προσομοίωση των μικροδιακυμάνσεων που εμφανίζονται σε πραγματικές μετρήσεις, λόγω των ατελειών και των ορίων ακρίβειας των Phasor Measurement Units (D-PMUs). Αυτή η προσέγγιση οδηγεί στη δημιουργία ενός πιο ρεαλιστικού συνόλου δεδομένων, το οποίο δεν είναι ιδανικό, αλλά αντανακλά τις πραγματικές συνθήκες λειτουργίας όπου τα σφάλματα μέτρησης είναι αναπόφευκτα. Η ενσωμάτωση του γκαουσιανού θορύβου εξασφαλίζει ότι τα μοντέλα που θα εκπαιδευτούν και θα δοκιμαστούν με τα παραγόμενα δεδομένα θα είναι πιο ανθεκτικά και ικανά να αντιμετωπίσουν τις αβεβαιότητες των πραγματικών συστημάτων. Αντί να χρησιμοποιούνται "καθαρές" και ιδανικές τιμές, η προσθήκη αυτού του τύπου θορύβου επιτρέπει στα μοντέλα να εξοικειωθούν με τα σφάλματα και τις τυχαίες διακυμάνσεις, βελτιώνοντας έτσι την απόδοσή τους και την προσαρμοστικότητά τους σε περιβάλλοντα όπου οι μετρήσεις δεν είναι απολύτως ακριβείς.

Βεβαίως η δοκιμή των μοντέλων που αναπτύχθηκαν σε ένα σύνολο δεδομένων που αποτελείται από πραγματικές μετρήσεις από D-PMUs αποτελεί ζήτημα μελλοντικής διερεύνησης και δεν εξετάζεται στα πλαίσια της παρούσας εργασίας.

Η προσομοίωση έγινε αξιοποιώντας την έκδοση Matlab 2023b σε υπολογιστή με επεξεργαστή intel® Core™ i5-1035G1 CPU @1.00GHz, μνήμη RAM 8 GB και λειτουργικό σύστημα Windows 10. Στις σελίδες παρακάτω βλέπουμε στιγμιότυπα από τα αποτελέσματα της εκτέλεσης της προσομοίωσης για τη δημιουργία του συνόλου δεδομένων.

MATPOWER Version 7.0, 20-Jun-2019 -- AC Power Flow (Newton)

Newton's method power flow (power balance, polar) converged in 3 iterations.

Converged in 0.01 seconds

=====
 | System Summary |
 =====

How many?		How much?	P (MW)	Q (MVar)
Buses	33	Total Gen Capacity	800.0	-99999.0 to 99999.0
Generators	1	On-line Capacity	800.0	-99999.0 to 99999.0
Committed Gens	1	Generation (actual)	3.0	1.4
Loads	32	Load	2.9	2.3
Fixed	32	Fixed	2.9	2.3
Dispatchable	0	Dispatchable	-0.0 of -0.0	-0.0
Shunts	2	Shunt (inj)	-0.0	0.9
Branches	37	Losses (I ² * Z)	0.08	0.07
Transformers	0	Branch Charging (inj)	-	0.0
Inter-ties	0	Total Inter-tie Flow	0.0	0.0
Areas	1			

	Minimum	Maximum
Voltage Magnitude	0.951 p.u. @ bus 7	1.000 p.u. @ bus 1
Voltage Angle	-2.54 deg @ bus 18	0.02 deg @ bus 5
P Losses (I ² *R)	-	0.01 MW @ line 2-3
Q Losses (I ² *X)	-	0.01 MVar @ line 12-22

Figure 17 Στιγμιότυπα από τα αποτελέσματα της εκτέλεσης της εντολής runpf (1/3)

Bus Data						
Bus #	Voltage		Generation		Load	
	Mag (pu)	Ang (deg)	P (MW)	Q (MVar)	P (MW)	Q (MVar)
1	1.000	0.000*	3.00	1.43	-	-
2	0.998	-0.004	-	-	0.10	0.06
3	0.991	0.015	-	-	0.09	0.04
4	0.988	0.019	-	-	0.12	0.08
5	0.985	0.021	-	-	0.06	0.03
6	0.979	-0.060	-	-	0.06	0.02
7	0.951	-1.520	-	-	0.20	0.10
8	0.952	-1.530	-	-	0.20	0.10
9	0.956	-1.494	-	-	0.06	0.02
10	0.961	-1.315	-	-	0.06	0.02
11	0.962	-1.300	-	-	0.04	0.03
12	0.964	-1.275	-	-	0.06	0.04
13	0.963	-1.282	-	-	0.06	0.04
14	0.955	-2.266	-	-	0.12	0.08
15	0.956	-2.260	-	-	0.06	0.01
16	0.957	-2.347	-	-	0.06	0.02
17	0.961	-2.469	-	-	0.06	0.02
18	0.963	-2.538	-	-	-0.11	0.04
19	0.996	-0.045	-	-	0.09	0.04
20	0.985	-0.370	-	-	0.09	0.04
21	0.982	-0.489	-	-	0.09	0.04
22	0.977	-0.712	-	-	-0.11	0.04
23	0.988	0.007	-	-	0.09	0.05
24	0.982	-0.028	-	-	0.42	0.20

Figure 18 Στιγμιότυπα από τα αποτελέσματα της εκτέλεσης της εντολής runpf (2/3)

Branch Data								
Brnch #	From Bus	To Bus	From Bus Injection P (MW)	From Bus Injection Q (MVar)	To Bus Injection P (MW)	To Bus Injection Q (MVar)	Loss ($I^2 * Z$)	
							P (MW)	Q (MVar)
1	1	2	3.00	1.43	-2.99	-1.43	0.006	0.00
2	2	3	1.82	1.03	-1.81	-1.03	0.014	0.01
3	3	4	0.98	0.53	-0.98	-0.53	0.003	0.00
4	4	5	0.86	0.45	-0.85	-0.45	0.002	0.00
5	5	6	0.79	0.42	-0.79	-0.42	0.004	0.00
6	6	7	0.00	0.00	0.00	0.00	0.000	0.00
7	7	8	-0.20	-0.10	0.20	0.10	0.000	0.00
8	8	9	-0.40	-0.20	0.40	0.20	0.001	0.00
9	9	10	-0.66	-0.02	0.66	0.03	0.003	0.00
10	10	11	-0.72	-0.05	0.72	0.05	0.001	0.00
11	11	12	-0.77	-0.08	0.77	0.08	0.001	0.00
12	12	13	0.06	0.03	-0.06	-0.04	0.000	0.00
13	13	14	0.00	0.00	0.00	0.00	0.000	0.00
14	14	15	-0.12	-0.08	0.12	0.08	0.000	0.00
15	15	16	0.01	-0.29	-0.01	0.29	0.000	0.00
16	16	17	-0.05	-0.31	0.05	0.31	0.001	0.00
17	17	18	-0.11	-0.33	0.11	0.33	0.001	0.00
18	2	19	1.07	0.33	-1.07	-0.33	0.001	0.00
19	19	20	0.98	0.29	-0.97	-0.28	0.010	0.01
20	20	21	0.88	0.24	-0.88	-0.24	0.002	0.00
21	21	22	0.79	0.20	-0.79	-0.20	0.003	0.00
22	3	23	0.74	0.45	-0.73	-0.45	0.002	0.00
23	23	24	0.64	0.40	-0.64	-0.40	0.003	0.00
24	24	25	0.22	0.20	-0.22	-0.20	0.001	0.00

Figure 19 Στιγμιότυπα από τα αποτελέσματα της εκτέλεσης της εντολής runpf (3/3)

```
Editor - C:\Users\Antonis Mk\Desktop\diplomati\matpower7.0\script_for_measurement_sets_v2.m
script_for_measurement_sets_v2.m x +
14
15 numTopologies = 26;
16 for topologyIndex = 1:numTopologies
17     filename = sprintf('IEEE33basetopology_chosen%d.mat', topologyIndex);
18     load(filename);
19
20     N = 33; % total number of nodes
21
22     topology=mpc.branch(:,11);
23     PQ_base = mpc.bus(:,[2:3]); % Base load for each node - sos: MW, MVA
24     sigma_load = 0.15; % Load variability standard deviation
25     sigma_measurM = 0.1/100;
26     sigma_measurA = 0.1/100;
27     rng('shuffle');
28
29
30     for j=1:1000
31
32
33         % Uniform distribution to decide which loads to change (0 or 1, 50% chance)
34         change_indicator = randi([0, 1], N, 1);
35
36         % Loop over nodes
37         for i = 1:N
38             if change_indicator(i) == 1
39                 % If load is to be changed, use normal distribution around Pbase with specified sigma
40                 PQi = sigma_load * PQ_base(i,:) * randn;
41             else
42                 % If load does not change, no variation
43                 PQi = 0;
44             end
45
46             % Calculate the load profile for this node
47             PQ_var(i,:) = PQ_base(i,:) + PQi;
48         end
49         mpc.bus(:, [2, 3]) = PQ_var(:,:); % sos: MW, MVA
50         results=runpf(filename);
51
52
53
54
55
56
57
58
59
60
61
62
63
64
65
66
67
68
69
70
71
72
73
74
75
76
77
78
79
80
81
82
83
84
85
86
87
88
89
90
91
92
93
94
95
96
97
98
99
100
```

Figure 20 Στιγμιότυπο από τον κώδικα σε προγραμματιστικό περιβάλλον Matlab για την δημιουργία του dataset

6.Υλοποίηση μοντέλων

Στόχος αυτού του μέρους της εργασίας ήταν η υλοποίηση μοντέλων μηχανικής μάθησης που θα αξιοποιούν το σύνολο δεδομένων που αναπτύχθηκε και θα προχωρούν σε ανίχνευση τοπολογίας. Επιλέχθηκε η υλοποίηση ενός Συνελικτικού Νευρωνικού Δικτύου (CNN) που βασίζεται στη μεθοδολογία αντιστοίχισης πυρήνα – κόμβου, όπως περιγράφηκε πριν, και ενός νευρωνικού δικτύου (NN) τύπου MLPs (multilayer perceptrons). Η υλοποίηση και των δύο επιτρέπει την σύγκριση των δύο μοντέλων και την εξαγωγή κάποιων βασικών συμπερασμάτων, καθώς και την σκιαγράφηση ζητημάτων μελλοντικής διερεύνησης. Για την υλοποίηση των μοντέλων επιλέχτηκε η γλώσσα προγραμματισμού Python.

6.1 Δεδομένα εισόδου-εξόδου

Τα δεδομένα εισόδου και εξόδου χρησιμοποιούνται για την εκπαίδευση και την αξιολόγηση των μοντέλων πρόβλεψης της τοπολογίας του δικτύου. Συγκεκριμένα:

- **Δεδομένα εισόδου (X):** Αντιπροσωπεύουν την είσοδο του μοντέλου πρόβλεψης τοπολογίας. Είναι πίνακες με βάση τα αποτελέσματα της προσομοίωσης στο προγραμματιστικό περιβάλλον Matlab που αναπτύχθηκε στο προηγούμενο κεφάλαιο.

Πριν από την χρησιμοποίησή τους από το μοντέλο πρόβλεψης, χρειάζεται να προηγηθεί μια συγκεκριμένη προετοιμασία / επεξεργασία: Η είσοδος του KNDN νευρωνικού δικτύου πρέπει να επιλέγεται με κατάλληλο τρόπο, ώστε η τοπολογία του συστήματος διανομής να μπορεί να ανιχνευθεί επιτυχώς.

Η δομή του δικτύου KNDN λαμβάνει υπόψη τη δομή του δικτύου διανομής. Για αυτό το λόγο τα στοιχεία εισόδου του CNN διατάσσονται με συγκεκριμένο τρόπο ώστε να τροφοδοτούν καλύτερα το CNN για την εξαγωγή χαρακτηριστικών (βλ. υποενότητα 3.7 Συνελικτικά Νευρωνικά Δίκτυα (Convolution Neural Networks)). Η αναδιάταξη των τοποθεσιών των στοιχείων βασίζεται στην μέθοδο της αντιστοίχισης «πυρήνα- κόμβου», όπως απεικονίζεται στο Figure 21, Figure 23.

Η συνολική αρχιτεκτονική του αλγορίθμου KNDN απεικονίζεται στο Figure 22. Περιλαμβάνει το επίπεδο εισόδου (input layer), συνελικτικά επίπεδα (Conv layers) και επίπεδο εξόδου (output layers). Δεν υπάρχει επίπεδο συγκέντρωσης (pooling layer) μετά από κάθε συνελικτικό επίπεδο, για να διατηρούνται τα φυσικά χαρακτηριστικά της τοπολογίας των δεδομένων εισόδου.

Είναι καθιερωμένη πρακτική να κανονικοποιούνται και να προ-επεξεργάζονται οι επιλεγμένες εισοδοί πριν εφαρμοστούν στο νευρωνικό δίκτυο. Οι

μονοδιάστατοι (1D) πίνακες κανονικοποιούνται και μετασχηματίζονται σε διδιάστατους (2D) πίνακες. Στη συνέχεια, οι τοποθεσίες των στοιχείων εισόδου αναδιατάσσονται με βάση την μεθοδολογία αντιστοίχισης «πυρήνα-κόμβου». Η συνάρτηση ενεργοποίησης Rectified Linear Unit [114] χρησιμοποιείται ως συνάρτηση ενεργοποίησης για όλα τα συνελκτικά επίπεδα.




Figure 21 Ανακατανομή στοιχείων εισόδου με βάση την μεθοδολογία αντιστοίχισης πυρήνα – κόμβου [54]

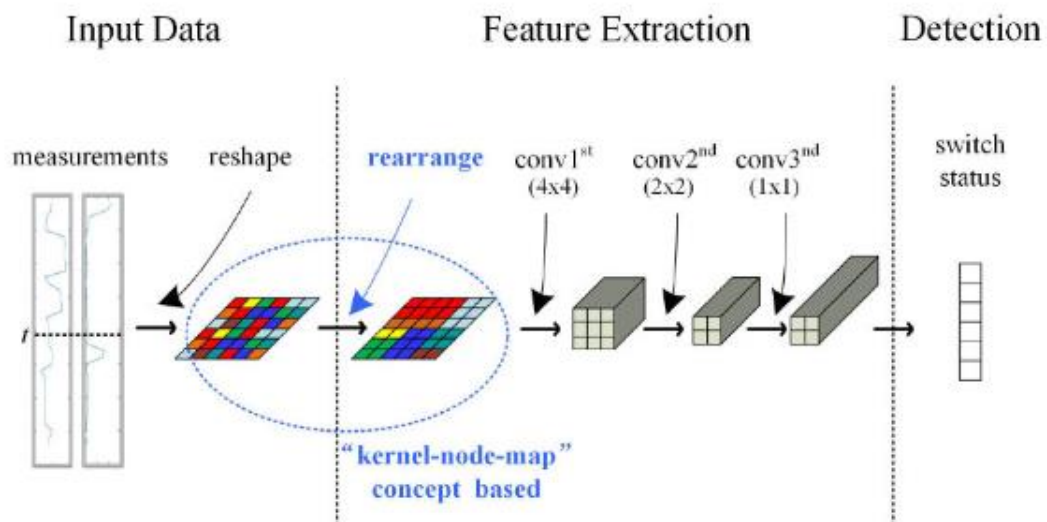


Figure 22 Δομή του KNDN αλγορίθμου [54]

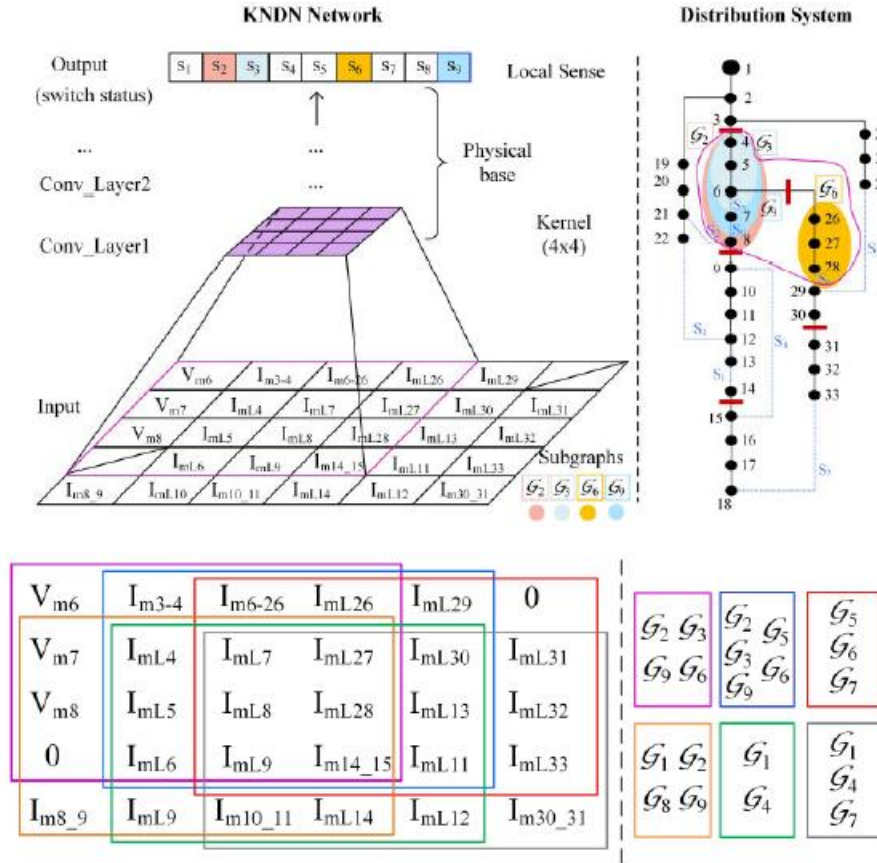


Figure 23 Αντιστοίχιση δεδομένων εισόδου με υπογράφους του δικτύου [54]

- **Δεδομένα εξόδου (Y):** Αντιπροσωπεύει την έξοδο του μοντέλου πρόβλεψης τοπολογίας. Είναι ένας πίνακας με 9 ψηφία (0 ή 1) που περιέχει την πρόβλεψη για την κατάσταση του κάθε διακόπτη (αν είναι ανοιχτός 0, αν είναι κλειστός 1).

6.2 Κύριος κώδικας

Το κύριο μέρος του κώδικα εκτελεί μια σειρά εργασιών για την εκπαίδευση και την πρόβλεψη τοπολογίας. Συγκεκριμένα:

- Ορίζονται οι βασικοί παράμετροι των μοντέλων. Με τεχνικές ρύθμισης παραμέτρων βελτιστοποιείται το αποτέλεσμα.
- Διαμορφώνεται συνάρτηση η οποία χωρίζει το dataset σε τρία υποσύνολα: training, validation, testing set.
- Εκπαιδεύονται τα μοντέλα CNN και NN χρησιμοποιώντας τα δεδομένα εισόδου και εξόδου που έχουν προετοιμαστεί (training set & validation set)
- Οι προβλέψεις γίνονται χρησιμοποιώντας τα εκπαιδευμένα μοντέλα των δεδομένων ελέγχου testing set)
- Υπολογίζονται οι μετρικές αξιολόγησης: όπως η ακρίβεια (accuracy) πρόβλεψης κατάστασης κάθε διακόπτη, RMSE, MAE (περισσότερα στην υποενότητα 6.4 Κριτήρια ακριβείας μοντέλου).

```
116 # Train the model
117 history = model.fit(
118     X_train, Y_train,
119     epochs=170,
120     batch_size=32,
121     validation_data=(X_val, Y_val),
122     callbacks=[callback, reduce_lr]
123 )
```

Figure 24 Η συνάρτηση που πραγματοποιεί την εκπαίδευση του μοντέλου

6.3 Βασικές συναρτήσεις – υπερπαραμέτροι

Παρακάτω αναλύονται οι βασικές συναρτήσεις που χρησιμοποιούνται και στα δύο μοντέλα που αναπτύχθηκαν:

- **custom_stratified_split** (X,Y, test_size, val_size, random_state): Αυτή η συνάρτηση είναι σχεδιασμένη για να διαχωρίζει το σύνολο δεδομένων σε τρία υποσύνολα: training, validation, testing, εξασφαλίζονται ότι θα γίνει ισοκατανομή των samples και από τις 26 τοπολογίες.

- **switch_accuracy** (y_true, y_pred): αυτή η συνάρτηση ορίζει την μετρική ακρίβειας για την πρόβλεψη της κατάστασης του κάθε διακόπτη. Η συνάρτηση εκτελεί τα εξής βήματα: Στρογγυλοποίηση των προβλέψεων και των πραγματικών τιμών για να μετατραπούν σε δυαδικές τιμές (0 ή 1). Σύγκριση των στρογγυλοποιημένων προβλέψεων με τις στρογγυλοποιημένες πραγματικές τιμές για να διαπιστωθεί εάν είναι ίδιες. Υπολογισμός της μέσης τιμής των σωστών προβλέψεων, μετατρέποντας τις boolean τιμές (True/False) σε αριθμητικές τιμές (1.0/0.0) και υπολογίζοντας το μέσο όρο τους. Αυτό επιτρέπει την αξιολόγηση της απόδοσης του μοντέλου για κάθε διακόπτη ξεχωριστά.
- **loose_accuracy** (y_true, y_pred): αυτή η συνάρτηση ορίζει την συνολική ακρίβεια του μοντέλου, μετρώντας πόσες φορές το μοντέλο προβλέπει σωστά την κατάσταση κάθε διακόπτη σε ένα δεδομένο sample και στη συνέχεια υπολογίζοντας το μέσο όρο της ακρίβειας σε όλα τα δείγματα.
- Συνάρτηση **ReduceROnPlateau**: αυτή η συνάρτηση προσαρμόζει τον ρυθμό μάθησης (learning rate) του μοντέλου κατά τη διάρκεια της εκπαίδευσης. Χρησιμοποιώντας αυτή τη συνάρτηση μπορεί να βοηθήσει στην αποφυγή του overfitting και στη βελτίωση της απόδοσης του μοντέλου.
 - **monitor='val_loss'**: Ορίζει τη μετρική που θα παρακολουθείται, σε αυτή την περίπτωση το loss του validation set.
 - **factor=0.2**: Ο παράγοντας με τον οποίο θα μειωθεί ο ρυθμός μάθησης αφού ενεργοποιηθεί η συνθήκη του plateau. π.χ., αν ο τρέχων ρυθμός μάθησης είναι 0.001, θα μειωθεί σε 0.0002.
 - **patience=5**: Αριθμός εποχών μετά την οποία, εάν δεν υπάρξει βελτίωση στην παρακολουθούμενη μετρική, θα μειωθεί ο ρυθμός μάθησης. Αυτό δίνει χρόνο στο μοντέλο να "εξερευνήσει" πριν προβεί σε μείωση του ρυθμού.
 - **min_lr=0.00001**: Ορίζει τον ελάχιστο ρυθμό μάθησης που μπορεί να επιτευχθεί μέσω της μείωσης. Αυτό εξασφαλίζει ότι ο ρυθμός μάθησης δεν θα γίνει πολύ χαμηλός, που μπορεί να οδηγήσει σε πολύ αργή εκπαίδευση ή στασιμότητα.
 - **verbose=1**: Επιτρέπει την εμφάνιση μηνυμάτων στην κονσόλα κατά την εκτέλεση της μείωσης του ρυθμού μάθησης, για να μπορεί ο χρήστης να παρακολουθεί την πρόοδο.
- Συνάρτηση **EarlyStopping**: Η συνάρτηση EarlyStopping στο TensorFlow και Keras είναι ένας τύπος callback που χρησιμοποιείται για να διακόψει την εκπαίδευση ενός μοντέλου όταν μια συγκεκριμένη μετρική σταματήσει να βελτιώνεται. Αυτό βοηθά στην αποφυγή της υπερπροσαρμογής (overfitting) και εξοικονομεί χρόνο, καθώς δεν συνεχίζει η εκπαίδευση εάν το μοντέλο δεν βελτιώνεται περαιτέρω. Ας εξετάσουμε τις παραμέτρους της EarlyStopping:
 - **monitor='val_loss'**: Αυτή η παράμετρος καθορίζει τη μετρική που θα παρακολουθείται, σε αυτή την περίπτωση την απώλεια επικύρωσης

(validation loss). Η εκπαίδευση θα διακοπεί εάν αυτή η τιμή δεν βελτιώνεται περαιτέρω.

- **min_delta=0.001:** Η ελάχιστη αλλαγή στη μετρική παρακολούθησης που θεωρείται ως βελτίωση. Δηλαδή, οι αλλαγές που είναι μικρότερες από αυτή την τιμή θα αγνοηθούν ως μη σημαντικές.
- **patience=10:** Ο αριθμός των εποχών να περάσουν χωρίς βελτίωση πριν διακοπεί η εκπαίδευση. Αυτό επιτρέπει στο μοντέλο να έχει κάποιο χρονικό περιθώριο για πιθανή βελτίωση πριν σταματήσει οριστικά η εκπαίδευση.
- **verbose=0:** Ρυθμίζει το επίπεδο λεπτομέρειας των μηνυμάτων που θα εμφανίζονται. Το 0 σημαίνει ότι δεν θα εμφανίζονται μηνύματα.
- **mode='auto':** Καθορίζει πώς θα αποφασίζεται εάν η εκπαίδευση βελτιώνεται (μειώνεται η απώλεια ή αυξάνεται η ακρίβεια).
- **baseline=None:** Ορίζει μια τιμή για την οποία, εάν η μετρική δεν την υπερβεί, θα διακοπεί η εκπαίδευση.
- **restore_best_weights=True:** Εάν είναι ενεργοποιημένο, μετά τη διακοπή της εκπαίδευσης, το μοντέλο θα επαναφέρει τα βάρη από την εποχή με την καλύτερη απόδοση, βοηθώντας έτσι στην αποφυγή της υπερπροσαρμογής.

```
28 # Custom stratified split
29 def custom_stratified_split(X, Y, test_size=0.2, val_size=0.1, random_state=42):
30     np.random.seed(random_state)
31     num_samples = len(Y)
32     test_indices = []
33     val_indices = []
34     train_indices = []
35
36     for i in range(num_samples):
37         if i % 10 < 2:
38             test_indices.append(i)
39         elif i % 10 < 3:
40             val_indices.append(i)
41         else:
42             train_indices.append(i)
43
44     test_indices = np.array(test_indices)
45     val_indices = np.array(val_indices)
46     train_indices = np.array(train_indices)
47
48     X_test = X[test_indices]
49     Y_test = Y[test_indices]
50     X_val = X[val_indices]
51     Y_val = Y[val_indices]
52     X_train = X[train_indices]
53     Y_train = Y[train_indices]
54
55     return X_train, X_val, X_test, Y_train, Y_val, Y_test
```

Figure 25 Η συνάρτηση custom_stratified_split


```

60 def accuracy_for_switch(index):
61     def switch_accuracy(y_true, y_pred):
62         rounded_predictions = tf.cast(tf.round(y_pred[:, index]), tf.float32)
63         rounded_true = tf.cast(tf.round(y_true[:, index]), tf.float32)
64         correct_predictions = tf.equal(rounded_true, rounded_predictions)
65         return tf.reduce_mean(tf.cast(correct_predictions, tf.float32))
66     switch_accuracy.__name__ = f'accuracy_switch_{index + 1}'
67     return switch_accuracy
68
69 # Create list of accuracy metrics for each switch
70 switch_accuracy_metrics = [accuracy_for_switch(i) for i in range(9)]
71
72 def strict_accuracy(y_true, y_pred):
73     y_pred_rounded = tf.round(y_pred)
74     y_pred_rounded = tf.cast(y_pred_rounded, tf.float32)
75     y_true = tf.cast(y_true, tf.float32)
76     correct_predictions = tf.reduce_all(tf.equal(y_true, y_pred_rounded), axis=1)
77     return tf.reduce_mean(tf.cast(correct_predictions, tf.float32))
78
79 def loose_accuracy(y_true, y_pred):
80     y_pred_rounded = tf.round(y_pred)
81     y_pred_rounded = tf.cast(y_pred_rounded, tf.float32)
82     y_true = tf.cast(y_true, tf.float32)
83     sample_accuracy = tf.reduce_sum(tf.cast(tf.equal(y_true, y_pred_rounded), tf.float32), axis=1) / tf.cast(tf.shape(y_true)[1], tf.float32)
84     return tf.reduce_mean(sample_accuracy)

```

Figure 26 Οι συναρτήσεις που υπολογίζουν την ακρίβεια πρόβλεψης κατάστασης διακόπτη και της ακριβείας πρόβλεψης του μοντέλου

```

103 reduce_lr = ReduceLROnPlateau(monitor='val_loss', factor=0.2, patience=5, min_lr=0.00001, verbose=1)
104
105 callback = tf.keras.callbacks.EarlyStopping(
106     monitor='val_loss',
107     min_delta=0.001,
108     patience=10, # isos na thelei mikrotero apo 20
109     verbose=0,
110     mode='auto',
111     baseline=None,
112     restore_best_weights=True,
113     start_from_epoch=0
114 )

```

Figure 27 Οι συναρτήσεις reduce_lr και EarlyStopping

Η δημιουργία του MLP - Multi-Layer Perceptron νευρωνικού δικτύου συγκεκριμένα έγινε ως εξής:

- Χρησιμοποιείται η κλάση “sequential” για τη δημιουργία μοντέλου σειριακής αρχιτεκτονικής, όπου τα επίπεδα (layers) προστίθενται το ένα μετά το άλλο. Αξιοποιείται δηλαδή η τυπική δομή για τη δημιουργία απλών feedforward νευρωνικών δικτύων.
- Αξιοποιούνται τα πυκνά συνδεδεμένα (fully-connected) νευρωνικά επίπεδα Dense. Κάθε νευρώνας σε ένα επίπεδο Dense συνδέεται με όλες τις εισόδους από το προηγούμενο επίπεδο.
 - **Πρώτο επίπεδο Dense:** Έχει 32 νευρώνες και χρησιμοποιεί τη συνάρτηση ενεργοποίησης ReLU (Rectified Linear Unit). Η συνάρτηση ReLU παρέχει ένα απλό μη γραμμικό κατώφλι, που επιτρέπει στα θετικά σήματα να περάσουν αμετάβλητα, ενώ τα αρνητικά τίθενται σε μηδέν.
 - **Δεύτερο επίπεδο Dense:** Ακριβώς όπως το πρώτο, αυτό το επίπεδο έχει επίσης 32 νευρώνες με συνάρτηση ενεργοποίησης ReLU.
 - Το **επίπεδο Flatten** μετατρέπει τα πολυδιάστατα δεδομένα εισόδου σε ένα επίπεδο διάνυσμα, προετοιμάζοντας τα για το πλήρως συνδεδεμένο επίπεδο Dense που ακολουθεί
 - **Τρίτο επίπεδο Dense:** αυτό το επίπεδο έχει 16 νευρώνες με συνάρτηση ενεργοποίησης ReLU.
 - Το **τελευταίο επίπεδο Dense** του δικτύου έχει 9 νευρώνες, με κάθε έναν να αντιστοιχεί σε έναν διακόπτη. Χρησιμοποιεί τη σιγμοειδής για συνάρτηση ενεργοποίησης (sigmoid activation function) για την παραγωγή πιθανοτήτων ανάμεσα στο 0 και 1, που αποτελεί μια κοινή πρακτική για μοντέλα ταξινόμησης πολλαπλών ετικετών.
 - Το δίκτυο εκπαιδεύεται αξιοποιώντας τον **Adam optimizer** με **learning_rate=0.0001**. Μικρότερη τιμή σημαίνει αργότερη σύγκλιση αλλά μπορεί να βοηθήσει στην αποφυγή προβλημάτων υπερβολικής προσαρμογής ή άλλων ασταθειών.

Η δημιουργία του CNN δικτύου έγινε συγκεκριμένα ως εξής:

- Το μοντέλο χρησιμοποιεί την κλάση Sequential της βιβλιοθήκης. Η δομή του δικτύου αποτελείται από επίπεδα συνέλιξης (Conv2D) που ακολουθούνται από επίπεδα πυκνής σύνδεσης (Dense).
- Σχετικά με τα **επίπεδα Συνέλιξης (Conv2D):**
 - **Πρώτο επίπεδο:** Το μοντέλο χρησιμοποιεί φίλτρα διαστάσεων 4x4 με 32 φίλτρα, ενεργοποιημένα με τη συνάρτηση ενεργοποίησης ReLU. Το επίπεδο αυτό χρησιμεύει για την εξαγωγή χαρακτηριστικών από την είσοδο.

- **Δεύτερο επίπεδο:** Το μοντέλο χρησιμοποιεί φίλτρα 2x2 με 32 φίλτρα, επίσης ενεργοποιημένα με ReLU. Συνεχίζει την επεξεργασία των χαρακτηριστικών που προκύπτουν από το προηγούμενο επίπεδο.
- **Επίπεδο Flatten:** Μετατρέπει τα πολυδιάστατα δεδομένα από τα συνελκτικά επίπεδα σε ένα επίπεδο διάνυσμα, προετοιμάζοντας τα για την επεξεργασία στα πλήρως συνδεδεμένα επίπεδα.
- **Σχετικά με τα επίπεδα Dense:**
 - **Πρώτο επίπεδο Dense:** Περιέχει 16 νευρώνες με ενεργοποίηση ReLU και ρυθμίζεται με κανονικοποίηση L2 για να περιορίζει την πολυπλοκότητα του μοντέλου.
 - **Τελικό επίπεδο Dense:** Περιέχει 9 νευρώνες, έναν για κάθε διακόπτη, με σιγμοειδή συνάρτηση ενεργοποίησης που παράγει τιμές μεταξύ 0 και 1, υποδηλώνοντας τις πιθανότητες κάθε διακόπτη να είναι ενεργοποιημένος ή όχι.

Και στα δύο μοντέλα αξιοποιείται η παράμετρος dropout που αντιμετωπίζει την υπερεκπαίδευση (overfitting) με τυχαία απομάκρυνση (μηδενισμός) ενός συγκεκριμένου ποσοστού των νευρώνων εισόδου, μαζί με τις αντίστοιχες συνδέσεις τους, κατά τη διάρκεια της φάσης εκπαίδευσης.

Παρακάτω συνοψίζονται οι διαφορές στην υλοποίηση των δύο μοντέλων :

- **Σχετικά με την αρχιτεκτονική του δικτύου:** Όπως περιγράφηκε και παραπάνω, τα συνελκτικό δίκτυο έχει συνελκτικά επίπεδα (conv2D) ενώ το δίκτυο MLP έχει πυκνά συνδεδεμένα επίπεδα.
- **Σχετικά με την προετοιμασία των δεδομένων εισόδου:** Στο συνελκτικό δίκτυο, τα δεδομένα εισόδου παίρνουν διαστάσεις 5x6, όπως περιγράφηκε αναλυτικά στην ενότητα 6.1 Δεδομένα εισόδου-εξόδου για να διατηρηθεί η πληροφορία σχετικά με τις χωρικές εξαρτήσεις. Στο MLP δίκτυο τα δεδομένα εισόδου περνούν μέσα από τη συνάρτηση flatten προκειμένου να δημιουργηθεί ένα μονοδιάστατο διάνυσμα για κάθε sample.
- **Σχετικά με τις υπερπαραμέτρους:** Χρειάζεται να γίνει ξεχωριστή ρύθμιση παραμέτρων για κάθε μοντέλο. Το συνελκτικό δίκτυο είναι πιο ευαίσθητο στην ρύθμιση παραμέτρων επειδή έχει πιο σύνθετη αρχιτεκτονική που περιλαμβάνει τα συνελκτικά επίπεδα.
- **Σχετικά με την εκπαίδευση:** Το συνελκτικό δίκτυο απαιτεί περισσότερο χρόνο και υπολογιστικούς πόρους στην εκπαίδευση συγκριτικά με το MLP για τους ίδιους λόγους.

6.4 Κριτήρια ακριβείας μοντέλου

Η αξιολόγηση της απόδοσης ενός νευρωνικού δικτύου είναι ένα κρίσιμο ζήτημα για να διασφαλιστεί η αξιοπιστία και η χρηστικότητα του. Τα κριτήρια ακριβείας είναι οι μετρήσεις που χρησιμοποιούνται για να ποσοτικοποιήσουν την απόδοση ενός μοντέλου, συγκρίνοντας τις προβλέψεις του με τις πραγματικές τιμές. Η επιλογή των κατάλληλων κριτηρίων ακριβείας εξαρτάται από τον τύπο του προβλήματος που αντιμετωπίζεται, το είδος των δεδομένων, και τους στόχους της ανάλυσης.

Η **μετρική RMSE (Root Mean Squared Error)** ισοδυναμεί με την τετραγωνική ρίζα της μέσης τιμής των διαφορών μεταξύ των πραγματικών και προβλεπόμενων τιμών υψωμένων στο τετράγωνο. Οι διαφορές αυτές καλούνται «residuals» και υποδεικνύουν πόσο συγκεντρωμένα είναι τα δείγματα γύρω από τη γραμμή παλινδρόμησης. Η μαθηματική έκφραση της μετρικής RMSE είναι:

$$RMSE = \sqrt{\frac{1}{N} \sum_{n=1}^N (y_t - y_p)^2} \quad (1)$$

Η **μετρική MAE (Mean Absolute Error)** χρησιμοποιείται για να μετρήσει τη μέση τιμή του μεγέθους των σφαλμάτων σε ένα σύνολο προβλέψεων, χωρίς να λαμβάνει υπόψη την κατεύθυνσή τους. Πρόκειται για τη μέση τιμή της απόλυτης τιμής των διαφορών μεταξύ των πραγματικών και προβλεπόμενων τιμών, όπου όλες οι διαφορές έχουν την ίδια βαρύτητα. Ο μαθηματικός τύπος της μετρικής MAE έχει ως εξής:

$$MAE = \frac{1}{N} \sum_{n=1}^N (y_t - y_p) \quad (2)$$

Συγκεκριμένα, y_t είναι η πραγματική κατάσταση του διακόπτη (δεδομένα εισόδου), y_p είναι η πρόβλεψη της κατάστασης του διακόπτη και το N είναι ο αριθμός των δειγμάτων στο σύνολο δεδομένων.

Η **μετρική ακρίβειας (accuracy)** στη μηχανική μάθηση ορίζεται ως το ποσοστό των προβλέψεων που ήταν σωστές σε σχέση με το συνολικό αριθμό περιπτώσεων που εξετάστηκαν. Χρησιμοποιείται για να αξιολογήσουμε πόσο καλά ένα μοντέλο έχει πραγματοποιήσει την κατηγοριοποίηση σε σενάρια διακριτής ταξινόμησης. Ο γενικός όρος ακρίβεια υπολογίζεται ως εξής:

$$\text{ακρίβεια} = \frac{TP + TN}{TP + TN + FP + FN} = \frac{\text{σωστές προβλέψεις}}{\text{σύνολο προβλέψεων}} \quad (3)$$

όπου:

- TP (True Positives): Ο αριθμός των περιπτώσεων που το μοντέλο προέβλεψε σωστά ως θετικές.
- TN (True Negatives): Ο αριθμός των περιπτώσεων που το μοντέλο προέβλεψε σωστά ως αρνητικές.
- FP (False Positives): Ο αριθμός των περιπτώσεων που το μοντέλο προέβλεψε εσφαλμένα ως θετικές.
- FN (False Negatives): Ο αριθμός των περιπτώσεων που το μοντέλο προέβλεψε εσφαλμένα ως αρνητικές

Στην περίπτωση που εξετάζεται, η θετική πρόβλεψη μπορεί να αντιστοιχεί με τον κλειστό διακόπτη και η αρνητική με τον ανοιχτό, ή το ανάποδο. Η μετρική **accuracy** αναφέρεται στην ακρίβεια πρόβλεψης της κατάστασης κάθε διακόπτη. Στο μοντέλο η μετρική αυτή έχει προσαρμοστεί για τις ανάγκες της συγκεκριμένης εφαρμογής, όπως περιγράφηκε και παραπάνω. Δηλαδή η ακρίβεια αναφέρεται στην πρόβλεψη της κατάστασης κάθε διακόπτη, και όχι στην πρόβλεψη της συνολικής τοπολογίας.

6.5. Αποτελέσματα μοντέλων

Τα μοντέλα έτρεξαν σε υπολογιστή με επεξεργαστή intel® Core™ i5-1035G1 CPU @1.00GHz, μνήμη RAM 8 GB και λειτουργικό σύστημα Windows 10 σε περιβάλλον visual studio code για την γλώσσα προγραμματισμού python με τα εξής αποτελέσματα:

	CNN	NN
Overall Test Loss	0.0503534041	0.1128032356
Model Accuracy	0.4453846216	0.25
Calculated Strict Accuracy	0.9980828166	0.9169861674
Loose Accuracy	0.9997442365	0.9841727018
Test Overall MAE	0.0207015499	0.0932602286
Test Overall RMSE	0.0443395376	0.1668549925
Test Accuracy for Switch 1	1.0	1.0
Test Accuracy for Switch 2	0.9996165633	0.9731594920
Test Accuracy for Switch 3	0.9996165633	0.9616564512
Test Accuracy for Switch 4	1.0	0.9616564512
Test Accuracy for Switch 5	0.9998083115	1.0
Test Accuracy for Switch 6	1.0	1.0
Test Accuracy for Switch 7	0.99884969	0.9998083114
Test Accuracy for Switch 8	1.0	0.9996165633
Test Accuracy for Switch 9	0.9998083115	0.9616564512

Καμπύλες μάθησης μοντέλου CNN




Figure 28 Καμπύλη loss over epochs για το CNN

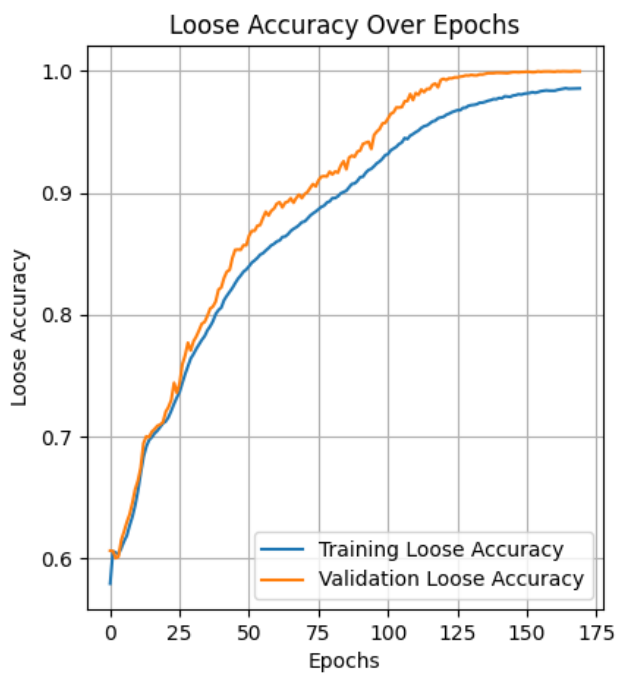


Figure 29 Καμπύλη loose accuracy over epochs για το CNN

6.6 Σύγκριση - Συμπεράσματα

Η σύγκριση μεταξύ του Συνελικτικού Νευρωνικού Δικτύου (CNN) και του Νευρωνικού Δικτύου (MLP) φανερώνει σημαντικές διαφορές τόσο στη θεωρητική τους προσέγγιση αναφορικά με τη δομή τους όσο και στην απόδοση στο πλαίσιο της ανίχνευσης τοπολογίας σε δίκτυα διανομής ενέργειας. Εξαρχής σημειώνεται ότι παρατηρείται διαφορά στην ακρίβεια του μοντέλου, με το **CNN να παρουσιάζει 1.5% μεγαλύτερη ακρίβεια**.

Αρχικά, τα CNNs είναι σχεδιασμένα για την επεξεργασία δεδομένων με χωρική δομή, όπως εικόνες ή πολυδιάστατους πίνακες, γεγονός που τα καθιστά ιδιαίτερα αποτελεσματικά στην αναγνώριση μοτίβων και χαρακτηριστικών σε τέτοιου είδους δεδομένα. Η βασική τους αρχή λειτουργίας είναι η χρήση συνελικτικών φίλτρων, τα οποία έχουν την ικανότητα να ανιχνεύουν τοπικά χαρακτηριστικά σε διάφορες κλίμακες και να μετατρέπουν τα ακατέργαστα δεδομένα σε αφηρημένες αναπαραστάσεις υψηλότερου επιπέδου. Αυτό επιτρέπει στα CNNs να "κατανοούν" τις σχέσεις μεταξύ των δεδομένων σε διαφορετικά επίπεδα λεπτομέρειας, βελτιώνοντας έτσι την ικανότητά τους να αναγνωρίζουν σύνθετα μοτίβα και να κάνουν ακριβείς προβλέψεις.

Αντίθετα, τα MLPs βασίζονται σε μια πιο απλή δομή, όπου κάθε νευρώνας σε ένα επίπεδο συνδέεται με κάθε νευρώνα στο επόμενο επίπεδο, χωρίς να λαμβάνονται υπόψη οι χωρικές σχέσεις των δεδομένων. Ενώ αυτή η προσέγγιση είναι επαρκής για την επεξεργασία δεδομένων όπου οι χωρικές ή τοπικές σχέσεις δεν είναι κρίσιμες, όπως σε προβλήματα κλασικής ταξινόμησης ή παλινδρόμησης, δεν αποδίδει εξίσου καλά όταν τα δεδομένα έχουν εγγενείς χωρικές δομές, όπως συμβαίνει με τα δεδομένα δικτύου που χρησιμοποιήθηκαν στην παρούσα εργασία. Το αποτέλεσμα είναι τα MLPs να παρουσιάζουν περιορισμένη ικανότητα αναγνώρισης σύνθετων δομών και μοτίβων στα δεδομένα, γεγονός που οδηγεί σε χαμηλότερη απόδοση σε προβλήματα όπως η ανίχνευση τοπολογίας.

Στη συγκεκριμένη εφαρμογή παρατηρήθηκε διαφορά απόδοσης μεταξύ των δύο μοντέλων. Το CNN κατέγραψε ακρίβεια που ήταν κατά 1,5% υψηλότερη από αυτή του MLP. Αυτό το αποτέλεσμα επιβεβαιώνει την υπεροχή των CNNs στην ανάλυση δομημένων δεδομένων που αναφέρονται στις μετρήσεις αισθητήρων δικτύου διανομής ενέργειας. Η δυνατότητα του CNN να εκμεταλλεύεται τις τοπικές συσχετίσεις μέσω των συνελικτικών φίλτρων του επέτρεψε να ανιχνεύσει τις τοπολογίες του δικτύου με μεγαλύτερη ακρίβεια και αξιοπιστία.

Τα αποτελέσματα της παρούσας εργασίας είναι συμβατά και με την βιβλιογραφία που εξετάστηκε [54]. Σε αυτή τη δημοσίευση η οποία αναφέρεται στην εφαρμογή ενός CNN που βασίζεται στη μεθοδολογία του «kernel-node-map» για την ανίχνευση τοπολογίας, τα αποτελέσματα δείχνουν ότι το CNN καταφέρνει να διατηρήσει υψηλή ακρίβεια ακόμη και υπό συνθήκες προσθήκης γκαουσιανού θορύβου. Η ανθεκτικότητα αυτή αποδεικνύεται καθοριστική για εφαρμογές με πραγματικά δεδομένα στο σύνολο δεδομένων (πχ μετρήσεις αισθητήρων) όπου θα υπάρχει θόρυβος και σφάλματα. Επομένως η χαμηλότερη ακρίβεια του MLP εκφράζει πιθανά και την χαμηλότερη

απόδοσή του στην εκπαίδευση σε ένα σύνολο δεδομένων που περιέχει θόρυβο. Λόγω της δομής τους, όπου κάθε νευρώνας συνδέεται με όλους τους νευρώνες του προηγούμενου επιπέδου, τα MLPs δεν εκμεταλλεύονται τις χωρικές σχέσεις των δεδομένων και είναι πιο επιρρεπή σε απώλεια ακρίβειας όταν τα δεδομένα περιέχουν θόρυβο.

7. Μελλοντικές προεκτάσεις

Σχετικά με μελλοντικές προεκτάσεις της εργασίας μπορούν να καταγραφούν οι παρακάτω:

- **Εκπαίδευση μοντέλου σε πραγματικά δεδομένα από μονάδες D-PMUs**

Η εκπαίδευση των νευρωνικών δικτύων σε πραγματικά δεδομένα από μονάδες D-PMUs αποτελεί έναν κρίσιμο τομέα έρευνας που μπορεί να βελτιώσει σημαντικά την απόδοση και την αξιοπιστία των μοντέλων μηχανικής μάθησης που χρησιμοποιούνται για την ανίχνευση τοπολογίας και άλλες εφαρμογές δικτύων διανομής ενέργειας. Σε αντίθεση με τα δεδομένα προσομοιώσεων που χρησιμοποιούνται συνήθως για την αρχική εκπαίδευση των μοντέλων, τα πραγματικά δεδομένα προσφέρουν μια πιο ρεαλιστική και ακριβή αναπαράσταση των συνθηκών που επικρατούν σε ένα πραγματικό δίκτυο. Αυτό περιλαμβάνει όλες τις πτυχές του συστήματος, όπως οι τυχαίες διακυμάνσεις, τα σφάλματα μετρήσεων, και οι δυναμικές αλλαγές στο φορτίο και τη ζήτηση.

Τα D-PMUs παρέχουν υψηλής ανάλυσης, συγχρονισμένες μετρήσεις οι οποίες είναι κρίσιμες για την ακριβή εκτίμηση της κατάστασης του δικτύου σε πραγματικό χρόνο. Οι μετρήσεις αυτές περιλαμβάνουν σημαντικές πληροφορίες για τις τάσεις, τα ρεύματα και τις γωνίες φάσης σε διάφορα σημεία του δικτύου, επιτρέποντας έτσι την ακριβή χαρτογράφηση της τοπολογίας του δικτύου και την ανίχνευση οποιωνδήποτε αλλαγών.

Η ενσωμάτωση αυτών των δεδομένων στην εκπαίδευση των νευρωνικών δικτύων αναμένεται να ενισχύσει την ακρίβεια των μοντέλων, καθώς θα επιτρέψει στο σύστημα να μάθει από τις πραγματικές συνθήκες λειτουργίας του δικτύου, συμπεριλαμβανομένων των τυχόν μη γραμμικών αλληλεπιδράσεων και των απρόβλεπτων συμβάντων που μπορεί να επηρεάσουν την απόδοση του δικτύου. Αυτό θα βελτιώσει την ικανότητα των μοντέλων να γενικεύουν και να λειτουργούν με ακρίβεια, καθιστώντας τα πιο αξιόπιστα για εφαρμογή σε πραγματικά δίκτυα.

Επιπλέον, η χρήση πραγματικών δεδομένων από D-PMUs θα επιτρέψει την εκτίμηση της απόδοσης των μοντέλων υπό πραγματικές συνθήκες λειτουργίας, όπως η παρουσία θορύβου και σφαλμάτων στις μετρήσεις, καθώς και η επίδραση των αλλαγών στη ζήτηση ή την παραγωγή ενέργειας λόγω της εισαγωγής ανανεώσιμων πηγών ενέργειας. Αυτό είναι ιδιαίτερα σημαντικό για τη βελτιστοποίηση των δικτύων διανομής, όπου οι ακριβείς και αξιόπιστες προβλέψεις μπορούν να οδηγήσουν σε καλύτερη διαχείριση των πόρων και βελτιωμένη σταθερότητα του συστήματος.

Τέλος, η εκπαίδευση των μοντέλων σε πραγματικά δεδομένα θα μπορούσε να ανοίξει το δρόμο για την ανάπτυξη πιο προηγμένων και εξειδικευμένων αλγορίθμων που θα είναι ικανοί να αντιμετωπίζουν τις ιδιαιτερότητες κάθε μεμονωμένου δικτύου, προσφέροντας εξατομικευμένες λύσεις για τη βελτίωση της απόδοσης και της αξιοπιστίας του.

- **Ανάπτυξη αλγορίθμου για την αυτόματη βέλτιστη αναδιάταξη και προετοιμασία των δεδομένων εισόδου.**

Η προετοιμασία των δεδομένων εισόδου είναι ένας κρίσιμος παράγοντας για την επιτυχία οποιουδήποτε μοντέλου μηχανικής μάθησης, ιδιαίτερα σε συστήματα που σχετίζονται με την ανίχνευση τοπολογίας σε δίκτυα διανομής ενέργειας. Ο προτεινόμενος αλγόριθμος θα εστιάζει στη βέλτιστη αναδιάταξη των δεδομένων εισόδου με βάση την έννοια της αντιστοίχισης πυρήνα – κόμβου που αναπτύχθηκε στην εργασία, ώστε να επιτυγχάνεται η μέγιστη απόδοση κατά την ανίχνευση της τοπολογίας στα δίκτυα διανομής. Η έννοια αυτή, που συνδέει τους πυρήνες του CNN με τις φυσικές τοπολογίες του δικτύου, επιτρέπει την εκμετάλλευση των τοπικών χαρακτηριστικών και τη μείωση των απαιτήσεων υπολογιστικής ισχύος, χωρίς να χάνεται η σημαντική πληροφορία που είναι απαραίτητη για την ανίχνευση της τοπολογίας.

Η εφαρμογή ενός τέτοιου αλγορίθμου μπορεί να έχει σημαντικές πρακτικές επιπτώσεις. Ειδικότερα, σε μεγάλα δίκτυα διανομής, η αξιοποίηση του CNN με αναδιαταγμένα και βελτιστοποιημένα δεδομένα εισόδου θα μπορούσε να βελτιώσει την ακρίβεια ανίχνευσης τοπολογίας και να μειώσει τον χρόνο που απαιτείται για την επεξεργασία των δεδομένων. Αυτό είναι ιδιαίτερα σημαντικό σε περιπτώσεις όπου η ταχύτητα και η ακρίβεια είναι κρίσιμες, όπως σε πραγματικούς χρόνους λειτουργίας και ελέγχου του δικτύου.

- **Υλοποίηση μοντέλου graph neural network**

Τα Γραφικά Νευρωνικά Δίκτυα (Graph Neural Networks, GNNs) είναι ειδικού τύπου νευρωνικά δίκτυα σχεδιασμένα για την επεξεργασία δεδομένων που μπορούν να αναπαρασταθούν ως γράφοι. Αυτά τα δίκτυα αξιοποιούν τη δομή και τις σχέσεις των δεδομένων για να εξάγουν συμπεράσματα και προβλέψεις από πολύπλοκες δομές δεδομένων. Οι GNNs χρησιμοποιούν την τεχνική του message passing, όπου κάθε κόμβος ανταλλάσσει πληροφορίες με τους γείτονές του για να ενημερώσει την αναπαράστασή του στον γράφο. Υπάρχουν διάφοροι τύποι GNNs, όπως τα Graph Convolutional Networks (GCNs), τα Graph Attention Networks (GATs), και τα Graph Recurrent Networks (GRNs). Ενδεικτικές δημοσιεύσεις: [64] [115]

- **Εφαρμογή Τεχνικών Μεταφοράς Μάθησης (Transfer Learning)**

Η μεταφορά μάθησης είναι μια τεχνική όπου ένα προεκπαιδευμένο μοντέλο επαναχρησιμοποιείται σε ένα νέο αλλά συναφές πρόβλημα, προσαρμόζοντας ορισμένα επίπεδα του δικτύου για να ανταποκριθούν καλύτερα στα δεδομένα του νέου προβλήματος. Αυτή η προσέγγιση θα μπορούσε να διερευνηθεί για να εκπαιδεύσει μοντέλα ανίχνευσης τοπολογίας χρησιμοποιώντας δεδομένα από διαφορετικά ή

παρόμοια δίκτυα, επιτρέποντας έτσι τη γρήγορη προσαρμογή σε νέα περιβάλλοντα χωρίς την ανάγκη εκτεταμένης νέας εκπαίδευσης.

- **Διερεύνηση της Ανάπτυξης Εξηγήσιμων Μοντέλων Μηχανικής Μάθησης (Explainable AI)**

Καθώς τα δίκτυα διανομής ενέργειας γίνονται όλο και πιο περίπλοκα, η ανάγκη για εξηγήσιμα μοντέλα μηχανικής μάθησης που μπορούν να παρέχουν διαφανείς προβλέψεις και να εξηγούν τις αποφάσεις τους γίνεται πιο επιτακτική. Η ανάπτυξη και εφαρμογή εξηγήσιμων μοντέλων AI στην ανίχνευση τοπολογίας θα μπορούσε να βοηθήσει τους διαχειριστές του δικτύου να κατανοήσουν καλύτερα τις προτάσεις των αλγορίθμων και να εμπιστευτούν τα αποτελέσματα των μοντέλων, ειδικά σε κρίσιμες καταστάσεις.

[Αυτή η σελίδα είναι σκόπιμα λευκή]

Βιβλιογραφία

- [1] Π. Β. Ν. Κ. Βουρνάς Κ., Παραγωγή Ηλεκτρικής Ενέργειας - Έλεγχος και Ευστάθεια Συστήματος, Αθήνα: Συμμετρία, 2011.
- [2] Κ. Γ. Βουρνάς Κ., Εισαγωγή στα Συστήματα Ηλεκτρικής Ενέργειας, Αθήνα: ΕΜΠ, 2001.
- [3] Βουρνάς Κ., Παπαδιάς Κ. , Ανάλυση Συστήματος Ηλεκτρικής Ενέργειας, Τόμος 1, Αθήνα: ΕΜΠ, 1985.
- [4] "ΔΕΔΔΗΕ "Το Δίκτυο Ηλεκτρισμού", [Online]. Available: <https://deddie.gr/el/deddie/to-diktuo-ilektrismou/>. [Accessed Ιούνιος 2024].
- [5] Π. Μελαχροινούδης, Η μετάβαση στα ευφυή ηλεκτρικά δίκτυα και η συμβολή της απόκρισης της ζήτησης στην αξιοπιστία των δικτύων διανομής, Αθήνα: ΕΜΠ, 2015.
- [6] "ΔΕΔΔΗΕ," [Online]. Available: www.deddie.gr. [Accessed Μάιος 2024].
- [7] "World Bank," [Online]. Available: <https://www.worldbank.org/en/news/press-release/2021/06/07/report-universal-access-to-sustainable-energy-will-remain-elusive-without-addressing-inequalities>. [Accessed Μάιος 2024].
- [8] Μοχιανάκης Καραμπατζάκης Αντώνης, Ενίσχυση Ανθεκτικότητας Συστημάτων Ηλεκτρικής Ενέργειας Έναντι Ακραίων Καιρικών Φαινομένων με Επιλεκτική Υπογειοποίηση Γραμμών Μεταφοράς, ΕΜΠ, 2021.
- [9] International Energy Agency, "Unlocking smart grid opportunities in emerging market and developing economies," 2024.
- [10] "Energy Independence and Security Act of 2007Q Title XIII - Smart Grid, Public Law 110-130, 110th Congress of the United States," Dec. 2007.
- [11] Monitor Deloitte, "Connecting the dots: Distribution grid investment to power the energy transition.," 2021.
- [12] B. Gates, "The surprising key to a clean energy future," [Online]. Available: <https://www.gatesnotes.com/Transmission>. [Accessed Μάιος 2024].
- [13] The Economist, "Hug pylons, not trees: The case for an environmentalism that builds," [Online]. Available: <https://www.economist.com/leaders/2023/04/05/the-case-for-an-environmentalism-that-builds>. [Accessed Ιούνιος 2024].
- [14] E. Commission, "Grids, the missing link - An EU Action Plan for Grids," 28/11/2023.
- [15] EuropeanCommission, "Factsheet - EU Action Plan to facilitate grids roll out," [Online]. Available: https://ec.europa.eu/commission/presscorner/detail/en/fs_23_6046. [Accessed Μάιος 2024].
- [16] International Energy Agency, "Tracking Clean Energy Progress 2023," [Online]. Available:

- <https://www.iea.org/energy-system/decarbonisation-enablers/digitalisation#tracking>. [Accessed Ιούνιος 2024].
- [17] ACER, CEER, "Challenges of the future electricity system. Recommendations and commitments," 11 July 2024. [Online]. Available: https://www.acer.europa.eu/sites/default/files/documents/Publications/Future_electricity_system_challenges_2024.pdf.
- [18] Γ. Γ. Νικόλαος Βοβός, "Ανάλυση Σ.Η.Ε," Πανεπιστήμιο Πατρών , [Online]. Available: https://eclass.upatras.gr/modules/document/file.php/EE630/%CE%91%CE%BD%CE%AC%CE%BB%CF%85%CF%83%CE%B7%20%CE%A3%CE%97%CE%95%20%CE%B5%CE%BD%CF%8C%CF%84%CE%B7%CF%84%CE%B1_4.pdf . [Accessed Ιούνιος 2024].
- [19] Cardenas, Jorge & Patynowski, Daniel, "Phasor Measurement Units (PMU) in Distribution Systems and Distributed Energy Resources (DER)," 2020.
- [20] Geethanjali Muthiah, Meenakshi Devi Manivannan, Hemavathi Ramadoss, Sharmeela Chenniappan, "Distribution Phasor Measurements Units (PMUs) in Smart Power Systems," *Artificial Intelligence-based Smart Power Systems, IEEE*, pp. 311-325, 2023.
- [21] Mahesh k. Panshanwar, Minakshi Gavande, M. F. A. R Satarkar, "Phasor Measurement Unit Technology and its Applications - A Review," *International Conference on Energy Systems and Applications (ICESA)*, 2015.
- [22] J. Sexauer, P. Javanbakht and S. Mohagheghi, "Phasor measurement units for the distribution grid: Necessity and benefits," *IEEE PES Innovative Smart Grid Technologies Conference (ISGT), Washington, DC, USA*, pp. 1-6, 2013.
- [23] George N. Korres, Nikolaos M. Manousakis, Themistoklis C. Xygkis, Johan Löfberg, "Optimal phasor measurement unit placement for numerical observability in the presence of conventional measurements using semi-definite programming," *IET Generation, Transmission & Distribution*, pp. 2427-2436, November 2015.
- [24] Cavraro, G., Bernstein, A., Kekatos, V., et al., "Real-time identifiability of power distribution network topologies with limited monitoring," *IEEE Control Syst. Lett*, p. 325–330, 4 2020 .
- [25] PWC, "Global Artificial Intelligence Study: Exploiting the AI Revolution," [Online]. Available: <https://www.pwc.com/gx/en/issues/data-and-analytics/publications/artificial-intelligence-study.html>. [Accessed Ιούνιος 2024].
- [26] Ευρωπαϊκό κοινοβούλιο, "Τι είναι η τεχνητή νοημοσύνη και πώς χρησιμοποιείται,;" [Online]. Available: <https://www.europarl.europa.eu/topics/el/article/20200827STO85804/ti-einai-i-techniti-noimosuni-kai-pos-chrisimopieitai>.
- [27] Unternehmertum, Center for Innovation and Business Creation at TUM , "Applying AI: The elements of a comprehensive AI strategy," [Online]. Available: https://aai.frb.io/assets/videos/AppliedAI_Elements-of-a-comprehensive-AI-Strategy.pdf.

- [Accessed Ιούνιος 2024].
- [28] "The Difference Between Artificial Intelligence, Machine Learning and Deep Learning," 2021. [Online]. Available: <https://community.intel.com/t5/Blogs/Tech-Innovation/Artificial-Intelligence-AI/The-Difference-Between-Artificial-Intelligence-Machine-Learning/post/1335666>. [Accessed Ιούνιος 2024].
- [29] Samuel, Arthur L., "Machine Learning," *The Technology Review*, pp. 42-45, 1959.
- [30] Mahesh Batta, "Machine learning algorithms-a review," *International Journal of Science and Research (IJSR)*, pp. 381-386, 2020.
- [31] Κ.-Π. Ανδρεσάκης, Ευφυείς Τεχνικές για την Ταξινόμηση Μαγνητικών Τομογραφιών σε Καρκινοπαθείς, ΕΜΠ, 2018.
- [32] Machine Learning Types you need to know, "thinkautonomous.ai," [Online]. Available: <https://www.thinkautonomous.ai/blog/types-of-learning-in-machine-learning/>.
- [33] "A simple overview of a multilayer perceptron," [Online]. Available: <https://www.analyticsvidhya.com/blog/2020/12/mlp-multilayer-perceptron-simple-overview/>. [Accessed Ιούνιος 2024].
- [34] Ian Goodfellow, Yoshua Bengio, Aaron Courville, *Deep Feedforward Networks in Deep Learning*, MIT Press, 2016.
- [35] O. Omitaomu and H. Niu, "Artificial Intelligence Techniques in Smart Grid: A Survey," *Smart cities*, pp. 548-568, 4 2021.
- [36] Feurer, M. & Hutter, *Hyperparameter Optimization in Automated Machine Learning: Methods, Systems, Challenges*, Cham: Springer International Publishing, 2019.
- [37] J. Bergstra, Y. Bengio, "Random Search for Hyper - Parameter Optimization," *Journal of Machine Learning Research*, vol. 13, No. 10, pp. 281-205, 2012.
- [38] Γ. Παπαλουκάς, Βραχυπρόθεσμη πρόβλεψη ηλεκτρικής ζήτησης οικιακών φορτίων με χρήση αναδρομικών νευρωνικών δικτύων, Αθήνα: ΕΜΠ, 2023.
- [39] "the correlation blog," [Online]. Available: <https://thecorrelation.in/overfitting-and-underfitting/>.
- [40] X. Ying, "An Overview of Overfitting and its Solutions," *Journal of Physics: Conference Series*, vol.1168, 2019.
- [41] L. Prechelt, "'Early stopping - But when?," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 7700 LECTU, p. 53-67, 2012.
- [42] A. Y. Ng, "Improving Deep Neural Networks: Hyperparameter Tuning, Regularization and Optimization," [Online]. Available: <https://www.coursera.org/lecture/deep-neural-network/train-dev-test-sets-cxG1s>.

- [43] Q. H. Nguyen, H.-B. Ly, L. S. Ho, N. Al-Ansari, H. Van Le, V. Q. Tran, I. Prakash and B. T. Pham, ""Influence of Data Splitting on Performance of Machine Learning Models in Prediction of Shear Strength of Soil," *Mathematical Problems in Engineering*, vol. vol 2021, p. p 15.
- [44] Jason Brownlee, Machine Learning Mastery, ""Machine Learning Mastery - A Gentle Introduction to Batch Normalization for Deep Neural Networks," Jan 2019. [Online]. Available: <https://machinelearningmastery.com/batch-normalization-for-training-of-deep-neural-networks/>.
- [45] Portland Data Science Group , "Regression methods in machine learning. Splitting datasets," [Online]. Available: <https://www.slideshare.net/slideshow/machine-learning-splitting-datasets/79767442#3>.
- [46] Ajit, Arohan, Koustav Acharya, and Abhishek Samanta, "A review of convolutional neural networks". *2020 international conference on emerging trends in information technology and engineering (ic-ETITE). IEEE, 2020.*
- [47] Μαστοράκης Αλέξιος, Επιβλέπων: Νικόλαος Χατζηαργυρίου, Βραχυπρόθεσμη πρόβλεψη φορτίου ηλεκτρικής ενέργειας με χρήση τεχνητών νευρωνικών δικτύων τύπου Long-Short Term Memory, ΕΜΠ, 2023.
- [48] MK Gurucharan, "Basic CNN Architecture: Explaining 5 Layers of Convolutional Neural Network," 27th July 2022. [Online]. Available: <https://www.upgrad.com/blog/basic-cnn-architecture/>. [Accessed Ιούνιος 2024].
- [49] Matlab, "What Is Feature Extraction?," [Online]. Available: <https://www.mathworks.com/discovery/feature-extraction.html>.
- [50] Utkarsh Pandey, Anshumaan Pathak, Adesh Kumar, Surajit Mondal, "Applications of artificial intelligence in power system operation, control and planning: a review," *Clean Energy, Volume 7, Issue 6*, p. 1199–1218, December 2023.
- [51] SIMON STOCK, DAVOOD BABAZADEH, CHRISTIAN BECKER, "Applications of Artificial Intelligence in Distribution Power System Operation," *IEEE Access*, 2021.
- [52] James P. Carmichael, Yuan Liao, "Application of Deep Neural Networks to Distribution System State Estimation and Forecasting," *Frontiers in Sustainable Cities*, January 2022.
- [53] Umlaut, part of Accenture , "Artificial Intelligence for the power grid of the future".
- [54] Mengmeng Xiao, Shaorong Wang, Zia Ullah, Yan Li, Reza Arghandeh, "Topology detection in power distribution system using kernel-node-map deep networks," *IET Generation, Transmission & Distribution*, pp. 4033-4041, 2020, Vol. 14, Iss. 19.
- [55] Guido Cavraro, Vassilis Kekatos, Liang Zhang, and Georgios B. Giannakis, "Learning Power Grid Topologies," [Online]. Available: <https://engineering.purdue.edu/~kekatos/papers/LearningPowerGridTopologies.pdf>.

- [56] A. Azizivahed et al., "Energy Management Strategy in Dynamic Distribution Network Reconfiguration Considering Renewable Energy Resources and Storage," *IEEE Transactions on Sustainable Energy*, pp. 662 - 673, April 2020.
- [57] Liu, Y., Zhang, N., and Kang, C, A review on data-driven analysis and optimization of power grid, *Dianli Xitong Zidonghua/Autom. Electr. Power Syst.* 42 (6), 157–167.
- [58] Li, Y., Yang, Z., Li, G., Zhao, D., and Tian, W, Optimal scheduling of an isolated microgrid with battery storage considering load and renewable generation uncertainties., *IEEE Trans. Ind. Electron.* 66 (2), 1565–1575, 2019.
- [59] L. Tang, F. Yang, and J. Ma, "A survey on distribution system feeder reconfiguration: Objectives and solutions," *Proc. IEEE Conf. Innov. Smart Grid Technol*, pp. 62-27, May 2014.
- [60] F.C. Schweppe, J. Wildes, and D.B. Rom, "Power System Static State Estimation - Part I, II, III," *IEEE Trans. Power App. Syst. vol PAS-89, no. 1*, pp. 120-135, Jan 1970.
- [61] A. Primadianto and C. N Lu, "A Review on Distribution System State Estimation," *IEEE Trans. on Power Syst. vol. 32, no.5*, pp. 3875-3883, Sep 2017.
- [62] Θεμιστοκλής Ξύγκης, Βέλτιστη διαχείριση μετρήσεων για ενίσχυση παρατηρησιμότητας και ακρίβειας σε εκτιμητές κατάστασης συστημάτων ηλεκτρικής ενέργειας με ελλιπή δεδομένα, ΕΜΠ, 2019.
- [63] Cavraro, G., Arghandeh, R, "Power distribution network topology detection with time-series signature verification method," *EEE Trans. Power Syst*, pp. 3500-3509, 2018, 33, (4).
- [64] Changgang Wang, Gang Mu, "Power System Network Topology Identification Based on Knowledge Graph and Graph Neural Network," *Frontiers in Energy Research* , 2021.
- [65] Zhu, W., Zhou, X., and Tang, R. , Elasticity network topology mapping for power grid, *Zhongguo Dianji Gongcheng Xuebao/Proc. Chin. Soc. Electr. Eng.* 31 (31), 109–117, 2011.
- [66] Ma, J., Zhang, Y., Ma, W., and Wang, Z., Power network topological analysis based on incidence matrix notation method and loop matrix., *Dianli Xitong Zidonghua/Autom. Electr. Power Syst.* (12), 74–80, 2014.
- [67] Yu, M., Zhang, Z., Li, X., Yu, J., Gao, J., Liu, Z., et al., Superposition graph neural network for offshore wind power prediction, *Future Generat. Comput. Syst.* 113, 145–157, 2020.
- [68] S. Bolognani, N. Bof, D. Michelotti, R. Muraro, and L. Schenato, "Identification of power distribution network topology via voltage correlation analysis," *Proc. IEEE Conf. Decis. Control*, p. 1659–1664, December 2013.
- [69] Y. Weng, Y. Liao, and R. Rajagopal, "Distributed energy resources topology identification via graphical modeling," *IEEE Trans. Power Syst*, pp. 2682-2694, July 2017.
- [70] S. Park, D. Deka, and M. Chertkov, "Exact topology and parameter estimation in distribution grids

- with minimal observability," *Proc. Power Syst. Comput. Conf.*, pp. 1-6, June 2018.
- [71] D. Deka, S. Backhaus, and M. Chertkov, "Learning topology of distribution grids using only terminal node measurements," *Proc. IEEE Int. Conf. Smart Grid Commun. Sydney, NSW, Australia*, pp. 205-211, November 2016.
- [72] G. Cavraro and V. Kekatos, "Graph algorithms for topology identification using power grid probing," *IEEE Control Syst. Lett.*, vol. 2, no. 4, pp. 689-694, October 2018.
- [73] G. Cavraro, V. Kekatos, and S. Veeramachaneni,, "Voltage analytics for power distribution network topology verification," *IEEE Trans. Smart Grid*, vol. 10, no. 1, pp. 1058-1067, January 2019.
- [74] Carta, D., Benigni, A., Muscas, C., "Model order reduction for PMU-based state estimation in distribution grids," *IEEE Syst. J.* , pp. 2711-1720, 2018, 12, (3).
- [75] Pegoraro, P.A., Meloni, A., Atzori, L., et al., "PMU-based distribution system state estimation with adaptive accuracy exploiting local decision metrics and IoT paradigm," *IEEE Trans. Instrum. Meas.* , pp. 704-717, 2017, 66, (4).
- [76] Macii, D., Barchi, G., Schenato, L., "On the role of phasor measurement units for distribution system state estimation," *Proc. 2014 IEEE Workshop on Environmental, Energy, and Structural Monitoring System Proc, Naples, Italy*, pp. 1-6, September 2014.
- [77] Cordova, J., Soto, C., Gilanifar, M., et.al., "Shape preserving incremental learning for power systems fault detection," *IEEE Control Syst. Lett.*, pp. 85-90, 2018, 3, (1).
- [78] Zhou, Y.X., Arghandeh, R., Zou, H., et al., "Nonparametric event detection in multiple time series for power distribution networks," *IEEE Trans. Ind. Electron*, pp. 1619-1628, 2019, 66, (2).
- [79] Zhou, Y.X., Arghandeh, R., Spanos, C.J, "Partial knowledge data-driven event detection for power distribution networks," *IEEE Trans. Smart Grid*, pp. 5152-5162, 2018, 9, (5).
- [80] Zhang, J.Y., Lu, C., Fang, C., et al, "Load shedding scheme with deep reinforcement learning to improve short-term voltage stability," *Proc. 2018 IEEE Innovative Smart Grid Technologies - Asia (ISGT Asia), Singapore, Singapore*, pp. 13-18, May 2018.
- [81] Sankur, M.D., Dobbe, R., Von, M.A., et al, "Model-free optimal voltage phasor regulation in unbalanced distribution systems," *IEEE Trans. Smart Grid*, pp. 884-894, 2020, 11, (1).
- [82] Cavraro, G., Arghandeh, R., Poolla, K., et al, "Data-driven approach for distribution network topology detection," *Proc. 2015 IEEE Power & Energy Society General Meeting, Denver, CO, USA*, pp. 1-5, July 2015.
- [83] Cavraro, G., Arghandeh, R., Barchi, G., et al., "Distribution network topology detection with time-series measurements," *Proc. 2015 IEEE Power & Energy Society Innovative Smart Grid Technologies Conf. (ISGT), Washington, DC, USA*, pp. 1-5, February 2015.

- [84] Arghandeh, R., Gahr, M., Von, M.A., et al., "Topology detection in microgrids with micro-synchrophasor," *Proc. 2015 IEEE Power & Energy Society General Meeting, Denver, CO, USA*, pp. 1-5, July 2015.
- [85] Von, M.A., Arghandeh, R., Brady, K., et al, "Synchrophasor monitoring for distribution systems: technical foundations and applications a white paper by the NASPI distribution task team.," *North American SynchroPhasor Initiative (NASPI), Berkeley, CA, USA*, 2018.
- [86] Von, M.A., Stewart, E., McEachern, A., et al, "Precision micro-synchrophasors for distribution systems: a summary of applications," *IEEE Trans. Smart Grid*, pp. 2926-2936, 2017, 8, (6).
- [87] Von, M.A., Culler, D., McEachern, A., et al, "Micro-synchrophasors for distribution systems," *Proc. 2014 IEEE Power & Energy Society Innovative Smart Grid Technologies Conf. (ISGT), Washington, DC, USA,,* pp. 1-5, February 2014.
- [88] Hayes, B., Escalera, A., Prodanovic, M.: "Event-triggered topology identification for state estimation in active distribution network," *Proc. 2016 IEEE PES Innovative Smart Grid Technologies Conf. Europe (ISGT-Europe), Ljubljana, Slovenia*, pp. 1-6, October 2016.
- [89] Deka, D., Backhaus, S., Chertkov, M, "Structure learning in power distribution networks," *IEEE Trans. Control Netw. Syst.*, pp. 1061-1074, 2018, 5, (3).
- [90] Weng, Y., Liao, Y.Z., Rajagopal, R, "Distributed energy resources topology identification via graphical modeling," *IEEE Trans. Power Syst.*, pp. 2682-2694, 2017, 32, (4).
- [91] Liao, Y.Z., Weng, Y., Liu, G., et al., "Urban mv and lv distribution grid topology estimation via group lasso," *IEEE Trans. Power Syst*, pp. 12-27, 2019, 34, (1).
- [92] Cavraro, G., Kekatos, V., Veeramachaneni, S, "Voltage analytics for power distribution network topology verification," *IEEE Trans. Smart Grid*, pp. 1058-1067, 2019, 10, (1).
- [93] Pappu, S.J., Bhatt, N., Pasumarthy, R., et al, "Identifying topology of low voltage distribution networks based on smart meter data," *IEEE Trans. Smart Grid*, pp. 2505-2516, 2018, 8, (5).
- [94] Yu, J.J.Q., Hou, Y.H., Li, V.O.K., "Online false data injection attack detection with wavelet transform and deep neural networks," *IEEE Trans. Ind. Inf.*, pp. 3271-3280, 2018, 7, (14).
- [95] He, Y.B., Mendis, G.J., Wei, J., "Real-time detection of false data injection attacks in smart grid: a deep learning-based intelligent mechanism," *IEEE Trans. Smart Grid*, pp. 2505-2516, 2017, 8, (5).
- [96] Wang, H.Z., Ruan, J.Q., Wang, G., et al, "Deep learning-based interval state estimation of AC smart grids against sparse cyber attacks," *IEEE Trans. Ind. Inf. ,* pp. 4766-4778, 2018, 14, (11).
- [97] Fan, C., Xiao, F., Zhao, Y.: " A short-term building cooling load prediction method using deep learning algorithms," *Appl. Energy* , pp. 222-233, 2017, 195.
- [98] Shi, H., Xu, M.H., Li, R, "Deep learning for household load forecasting-A novel pooling deep RNN," *IEEE Trans. Smart Grid*, pp. 5271-5280, 2017, 9, (5).

- [99] Kong, W.C., Dong, Z.Y, Jia, Y.W., et al, "Short-term residential load forecasting based on LSTM recurrent neural network," *IEEE Trans. Smart Grid*, pp. 841-851, 2017, 10, (1).
- [100] Zheng, C., Wang, S.H, Liu, Y.L., et al., "A novel equivalent model of active distribution networks based on LSTM," *IEEE Trans. Neural Netw Learn Syst.*, pp. 2611-2624, 2019, 30, (9).
- [101] Zheng, C., Wang, S.H, Liu, Y.L., et al, "A novel RNN based load modelling method with measurement data in active distribution system," *Electr. Power Syst. Res*, pp. 112-124, 2019, 166.
- [102] Alhalaseh, R., Kämmer, R., Nath, N.C., et al, "Convolutional neural network based fault location detector for power grids," *Proc. 2019 4th Int. Conf. on Smart and Sustainable Technologies (SpliTech), Split, Croatia, Croatia*, pp. 1-5.
- [103] "Deep-learning-based power distribution network switch action identification leveraging dynamic features of distributed energy resources," *IET Gener. Trans. Distrib.* 2019, 13, (14), pp. 3139-3147.
- [104] "Classification of power quality disturbances using wigner-ville distribution and deep convolutional neural networks," *IEEE Access*, 2019, 7, p. 119099–119109.
- [105] Mengmeng Xiao, Shaorong Wang, Zia Ullah, Yan Li, Reza Arghandeh, "Topology detection in power distribution," *IET Generation, Transmission & Distribution*, July 2020.
- [106] "Matpower," [Online]. Available: <https://matpower.org/docs/ref/matpower6.0/case33bw.html>. [Accessed Máioç 2024].
- [107] M. E. Baran and F. F. Wu,, "Network reconfiguration in distribution," *IEEE Trans. Power Del*, p. 1401–1407, April 1989.
- [108] "Python Graph library," [Online]. Available: <https://python-graph-library.readthedocs.io/en/latest/>.
- [109] "MathWorks," [Online]. Available: <https://www.mathworks.com/>. [Accessed Máioç 2024].
- [110] "Matpower," [Online]. Available: <https://matpower.org/>. [Accessed Máioç 2024].
- [111] Grainger, J. J., & Stevenson, W. D, *Power System Analysis*, McGraw-Hill, 1994.
- [112] "MatPower User's Manual," [Online]. Available: <https://matpower.org/docs/MATPOWER-manual-8.0b1.pdf>. [Accessed Máioç 2024].
- [113] "matpower," [Online]. Available: <https://matpower.org/docs/ref/matpower5.0/runpf.html>. [Accessed Máioç 2024].
- [114] Hara, K., Saito, D., Shouno, H, "Analysis of function of rectified linear unit used in deep learning," *Proc. 2015 Int. Joint Conf. on Neural Networks (IJCNN), Killarney, Ireland*, pp. 1-8, July 2015.
- [115] Wenlong Liao, Birgitte Bak-Jensen, Jayakrishnan Radhakrishna Pillai, Yuelong Wang, and Yusen Wang, "A Review of Graph Neural Networks and Their Applications in Power Systems," *Journal of modern power systems and clean energy*, vol 10, No2, March 2022.

