



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ

ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

ΤΟΜΕΑΣ ΗΛΕΚΤΡΙΚΗΣ ΙΣΧΥΟΣ

Εκτίμηση Κατάστασης Δικτύου Διανομής με χρήση τεχνικών Μηχανικής Μάθησης

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Αναστάσιος Μαρίνος Ζορμπαλάς

Επιβλέπων: Άρης Λ. Δημέας

Καθηγητής Ε.Μ.Π.

Αθήνα, Φεβρουάριος 2025



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ

ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

ΤΟΜΕΑΣ ΗΛΕΚΤΡΙΚΗΣ ΙΣΧΥΟΣ

Εκτίμηση Κατάστασης Δικτύου Διανομής με χρήση τεχνικών Μηχανικής Μάθησης

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Αναστάσιος Μαρίνος Ζορμπαλάς

Επιβλέπων: Άρης Λ. Δημέας

Καθηγητής Ε.Μ.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 25^η Φεβρουαρίου 2025.

.....

.....

.....

Άρης Ευάγγελος Δημέας
Καθηγητής Ε.Μ.Π.

Γεώργιος Κορρές
Καθηγητής Ε.Μ.Π.

Πάυλος Γεωργιλάκης
Καθηγητής Ε.Μ.Π.

Αθήνα, Φεβρουάριος 2025

.....

Αναστάσιος Μαρίνος Ζορμπαλάς

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

Copyright © Αναστάσιος Μαρίνος Δ. Ζορμπαλάς 2025

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

Τα Δίκτυα Διανομής ηλεκτρικής ενέργειας είναι υπεύθυνα για την μεταφορά της ενέργειας από την παραγωγή στους καταναλωτές. Η εκτίμηση της κατάστασής τους, δηλαδή ο προσδιορισμός κρίσιμων παραμέτρων, είναι απαραίτητη για την ασφαλή λειτουργία και εποπτεία του συστήματος. Εξίσου σημαντική είναι η ανίχνευση της τοπολογίας, καθώς οι αλλαγές στη δομή επηρεάζουν τη ροή ισχύος.

Η περιορισμένη παρατηρησιμότητα λόγω έλλειψης αισθητήρων δυσκολεύει την ακριβή εκτίμηση κατάστασης και τοπολογίας, ειδικά όταν οι μεταβολές δεν είναι πλήρως ανιχνεύσιμες. Η ανάπτυξη αποτελεσματικών μεθόδων είναι κρίσιμη για την ενσωμάτωση ανανεώσιμων πηγών και τη διαχείριση ενεργειακών πόρων.

Η εργασία εξετάζει δύο προσεγγίσεις. Η πρώτη βασίζεται σε Νευρωνικά Δίκτυα (NNs), εκπαιδευμένα με προσομοιώσεις ροών ισχύος. Η δεύτερη χρησιμοποιεί Νευρωνικά Δίκτυα με Γράφο (GNNs), που αξιοποιούν τη φυσική δομή του Δικτύου, ενσωματώνοντας πληροφορίες σχέσεων μεταξύ ζυγών και γραμμών. Τα GNNs υπερέχουν σε ακρίβεια και προσαρμοστικότητα, ειδικά σε Δίκτυα με περιορισμένα στοιχεία.

Και στις δύο προσεγγίσεις, αναπτύχθηκε αλγόριθμος βέλτιστης τοποθέτησης αισθητήρων, που μειώνει τον αριθμό μετρητικών συσκευών, διασφαλίζοντας αξιόπιστα αποτελέσματα και βελτιστοποίηση κόστους.

Λέξεις Κλειδιά

Δίκτυα Διανομής, Εκτίμηση Κατάστασης, Αναγνώριση Τοπολογίας, Τεχνητή Νοημοσύνη, Νευρωνικά Δίκτυα, Γράφος

Abstract

Electric power distribution networks transfer energy from production to consumers. Estimating their state, i.e., determining critical parameters such as bus voltage, is essential for their safe operation and supervision. Equally important is topology detection, as structural changes affect power flow.

Limited observability due to a lack of sensors complicates accurate state and topology estimation, especially when structural changes are not fully detectable. Developing effective methods is crucial for integrating renewable energy sources and managing distributed energy resources.

This study examines two approaches. The first relies on Neural Networks (NNs) trained with power flow simulation data. The second utilizes Graph Neural Networks (GNNs), which leverage the network's natural graph structure by incorporating information about the relationships between buses and lines. GNNs outperform in accuracy and adaptability, particularly in networks with limited data.

In both approaches, a sensor placement optimization algorithm was developed to minimize the number of measuring devices while ensuring reliable results and cost efficiency.

Keywords

Distribution Networks, State Estimation, Topology Identification, Artificial Intelligence, Graph Neural Network

Ευχαριστίες

Θα ήθελα πρωταρχικά να ευχαριστήσω τον επιβλέποντα καθηγητή Δρ. Άρη Λ. Δημέα για την εμπιστοσύνη του και την καθοδήγηση του στην τελική εκπόνηση αυτής της διπλωματικής εργασίας. Επιπλέον, θα ήθελα να ευχαριστήσω τον Δρ. Θεμιστοκλή Χ. Ξύγκη και τον υποψήφιο διδάκτορα Κυριάκο Ανδρεσάκη για την πολύτιμη βοήθεια μιας και ήταν δίπλα μου σε οτιδήποτε χρειάστηκα ανά πάσα στιγμή. Τέλος, θέλω να ευχαριστήσω την οικογένεια μου, τους φίλους μου και συμφοιτητές μου για την στήριξη που μου προσέφεραν σε αυτή την διαρκή προσπάθεια όλα αυτά τα χρόνια.

Περιεχόμενα

Περίληψη	5
Abstract	7
Ευχαριστίες	8
1. Εισαγωγή.....	13
1.1. Στόχοι.....	13
1.2.Δομή	14
2. Θεωρητικό Υπόβαθρο	15
2.1. Power System	15
2.1.1. Εισαγωγή.....	15
2.1.2. Δίκτυα Διανομής	16
2.1.3. PMU	18
2.1.4. Power Flow.....	20
2.1.5. Εκτίμηση Κατάστασης και τοπολογίας.....	21
2.1.6. Μελλοντικές Τάσεις.....	24
2.2. Μηχανική Μάθηση.....	25
2.2.1. Εισαγωγή.....	25
2.2. Αλγόριθμοι Μηχανικής Μάθησης.....	26

2.2.1. Επιβλεπόμενη Μάθηση	27
2.2.2. Μη επιβλεπόμενη μάθηση	28
2.2.3. Ενισχυτική Μάθηση	28
2.3. Pytorch	29
2.4. Μοντέλα Μηχανικής Μάθησης.....	31
2.4.1. Πολυεπίπεδο Νευρωνικό Δίκτυο	31
2.4.3. CNN	34
2.4.4. GNN	37
2.5. Το μοντέλο GCN	38
2.5.1. Εισαγωγή.....	38
2.5.2. GCN Layers Forward	39
2.5.3. Input Features και Edge Attributes.....	40
2.5.4. MAPE και MAE ως δείκτες απόδοσης	40
2.5.4.1 Mean Absolute Percentage Error (MAPE)	40
2.5.4.2. Mean Absolute Error (MAE)	41
2.5.5. Accuracy σε σχέση με Topology Identification.....	42
3. Ορισμός προβλήματος	42
3.1. Εκτίμηση Κατάστασης	42
3.1.1. Βιβλιογραφική Ανασκόπηση	43
3.2. Ανίχνευση Τοπολογίας	43
4. Δημιουργία Συνόλου δεδομένων	44

4.1. IEEE 33 Bus System	44
4.2. Matlab.....	45
4.2.1. MATPOWER: Επισκόπηση και Εφαρμογές	46
4.2.2. Χρήση στη Βιβλιογραφία	47
4.3. Συνδυασμός MATLAB και MATPOWER με Νευρωνικά Δίκτυα	47
4.4. Παραγωγή Δεδομένων	48
4.4.1. Case33bw	48
4.4.2. Διαφοροποίηση Τοπολογιών	50
4.4.3. Τυχαιότητα	51
4.4.4. Επιλογή Χαρακτηριστικών	53
4.4.5. Προσομοιώσεις.....	53
5.Υλοποίηση Μοντέλου	55
5.1. Χρήση Python.....	55
5.2. Feature Selection στα δεδομένα.....	57
5.3. State Estimation	58
5.3.1. Στόχος	58
5.3.2. Προεπεξεργασία Δεδομένων	58
5.3.3.Επιλογή PMU	61
5.4.Εύρεση τοπολογίας (Topology Identification)	69
5.4.1. Νευρωνικό Δίκτυο	70
5.4.2 Προεπεξεργασία δεδομένων	70

5.4.3. Μοντέλο NN	71
5.4.4. Μοντέλο GNN	72
5.5. Σύγκριση και Συμπεράσματα	75
5.5.1. Σύγκριση State Estimation.....	75
5.5.2. Σύγκριση Ανίχνευσης Τοπολογίας	78
5.5.3. Συμπέρασμα	78
6. Μελλοντικές προεκτάσεις	79
7. Βιβλιογραφία	81

1. Εισαγωγή

1.1. Στόχοι

Η παρούσα διπλωματική εργασία στοχεύει στη μελέτη και ανάλυση της απόδοσης μοντέλων τεχνητής νοημοσύνης σε Δίκτυα διανομής ηλεκτρικής ενέργειας, με στόχο να αναδείξει την υπεροχή των Νευρωνικών Δικτύων με χρήση γράφων (GNNs) σε σύγκριση με τα συμβατικά Νευρωνικά Δίκτυα (NNs). Η μελέτη εστιάζει στη χρήση του πρότυπου Δικτύου διανομής IEEE 33 bus network, το οποίο αποτελεί ένα ευρέως χρησιμοποιούμενο μοντέλο στη μελέτη συστημάτων ηλεκτρικής ενέργειας. Μέσα από την ανάλυση αυτού του Δικτύου, παράγονται δεδομένα που χρησιμοποιούνται για την εκπαίδευση και αξιολόγηση τόσο ενός τυπικού Νευρωνικού Δικτύου όσο και ενός Νευρωνικού Δικτύου με γράφο. Ο κύριος στόχος είναι να αποδειχθεί ότι τα GNNs, λόγω της ικανότητάς τους να αξιοποιούν τη γραφική δομή των δεδομένων, μπορούν να προσφέρουν καλύτερη απόδοση σε προβλήματα που αφορούν Δίκτυα διανομής.

Η προσέγγιση αυτή βασίζεται στην παραδοχή ότι τα Δίκτυα διανομής, όπως το IEEE 33 bus network, αποτελούν γραφήματα, όπου οι κόμβοι αντιστοιχούν στους υποσταθμούς (buses) και οι ακμές στις γραμμές διανομής (branches). Τα GNNs είναι ειδικά σχεδιασμένα για την επεξεργασία τέτοιου είδους δεδομένων, καθώς λαμβάνουν υπόψη τόσο τα χαρακτηριστικά των κόμβων όσο και τη δομή του γραφήματος. Αντίθετα, τα συμβατικά Νευρωνικά Δίκτυα δεν είναι σχεδιασμένα για να εκμεταλλεύονται τη χωρική αλληλεπίδραση και τη συνδεσιμότητα των κόμβων, γεγονός που τα καθιστά λιγότερο αποτελεσματικά σε τέτοια προβλήματα. Για να αποδειχθεί αυτή η υπεροχή, η εργασία εστιάζει τόσο στην αξιολόγηση των δύο μοντέλων σε πλήρη δεδομένα εισόδου όσο και σε σενάρια με περιορισμένα δεδομένα εισόδου, όπου οι πληροφορίες από συγκεκριμένους κόμβους αποκρύπτονται. Στόχος είναι να μελετηθεί η ικανότητα κάθε μοντέλου να εκτιμά τις τιμές των αποκρυπτόμενων δεδομένων και να εξετάζεται πόσο επηρεάζεται η απόδοση τους σε περιπτώσεις έλλειψης δεδομένων.

Μέσω αυτής της μελέτης, διερευνάται όχι μόνο η ακρίβεια και η αποδοτικότητα των GNNs, αλλά και η συμβολή τους στην κατανόηση και επίλυση προβλημάτων που αφορούν τα συστήματα διανομής ηλεκτρικής ενέργειας. Τα GNNs, εκμεταλλευόμενα τη χωρική συσχέτιση και τη δομή των δεδομένων, μπορούν να παρέχουν πιο αξιόπιστες προβλέψεις και καλύτερη

γενίκευση, ακόμη και σε συνθήκες περιορισμένων δεδομένων. Αυτή η ιδιότητα τα καθιστά εξαιρετικά πολύτιμα εργαλεία για εφαρμογές σε πραγματικά συστήματα ηλεκτρικής ενέργειας, όπου η ακρίβεια και η αξιοπιστία των εκτιμήσεων είναι κρίσιμες.

Επιπλέον, η εργασία εξετάζει πώς η γραφική αναπαράσταση των δεδομένων και η χρήση GNNs μπορούν να συμβάλουν στη μείωση των υπολογιστικών απαιτήσεων, αναδεικνύοντας τις δυνατότητές τους για πρακτική εφαρμογή σε μεγάλης κλίμακας Δίκτυα. Το τελικό αποτέλεσμα είναι η ανάδειξη των GNNs ως ανώτερη μεθοδολογία, όχι μόνο για την επίτευξη υψηλότερης ακρίβειας αλλά και για την επίλυση προβλημάτων που δεν μπορούν να προσεγγιστούν αποτελεσματικά με παραδοσιακά Νευρωνικά Δίκτυα. Η παρούσα διπλωματική εργασία συνεισφέρει στην κατανόηση της εφαρμογής προηγμένων τεχνικών μηχανικής μάθησης σε συστήματα ηλεκτρικής ενέργειας, υποδεικνύοντας νέους δρόμους για τη βελτιστοποίηση και την αποδοτική διαχείρισή τους.

1.2.Δομή

Η παρούσα διπλωματική εργασία είναι οργανωμένη σε οκτώ κεφάλαια

- Στο **Κεφάλαιο 2** μελετάται το θεωρητικό υπόβαθρο που σχετίζεται με την παρούσα εργασία
- Στο **Κεφάλαιο 3** αναφέρεται ο ορισμός του προβλήματος με βιβλιογραφική ανασκόπηση
- Στο **Κεφάλαιο 4** αναλύεται η δημιουργία του συνόλου των δεδομένων και η βάση προγραμμάτων που την απαρτίζουν
- Στο **Κεφάλαιο 5** παρουσιάζεται η μεθοδολογία που ακολουθήθηκε για την προεπεξεργασία των δεδομένων, την εκπαίδευση των μοντέλων μηχανικής μάθησης καθώς και τα αποτελέσματα των διαφορετικών προσεγγίσεων με την αξιολόγησή τους.
- Στο **Κεφάλαιο 6** προτείνονται τρόποι επέκτασης της εργασίας σε συνδυασμό με μελλοντικές τάσεις
- Στο **Κεφάλαιο 7** αναγράφεται αναλυτικά η βιβλιογραφία που χρησιμοποιήθηκε στην παρούσα διπλωματική

2. Θεωρητικό Υπόβαθρο

Σε αυτό το κεφάλαιο παρουσιάζεται το θεωρητικό υπόβαθρο σχετικά με το θέμα της παρούσας εργασίας. Αρχικά μελετώνται τα συστήματα ηλεκτρικής ενέργειας και συγκεκριμένα τα Δίκτυα διανομής, η σημασία των παρατηρητών και η χρήση της ροής φορτίου. Τέλος, παρουσιάζεται η συμβολή της μηχανικής μάθησης στην κατάσταση, τοπολογία και οι μέθοδοι που χρησιμοποιούνται στην επεξεργασία δικτύων.

2.1. Power System

2.1.1. Εισαγωγή

Τα Συστήματα Ηλεκτρικής Ενέργειας (ΣΗΕ) αποτελούν ένα σύνολο δικτύων που έχουν σχεδιαστεί προκειμένου να παράγουν, να μεταφέρουν και να διανέμουν ηλεκτρική ενέργεια. Η παραγωγή, μπορεί να πραγματοποιηθεί από ποικίλες πηγές (υδροηλεκτρική, ηλιακή, πυρηνική, βιομάζα), όπου μέσω γεννητριών η ενέργεια μετατρέπεται σε ηλεκτρική, με σκοπό να εξυπηρετήσει τις ανάγκες του ανθρώπου. Η μεταφορά περιλαμβάνει ένα εκτενές Δίκτυο υποδομών, που αποτελείται από υποσταθμούς, για να διασφαλιστεί η αξιοπιστία. Οι σταθμοί, χρησιμοποιούν μετασχηματιστές που αυξάνουν την ηλεκτρική τάση, με αποτέλεσμα να μειώνονται οι απώλειες στη διάρκεια της μεταφοράς. Επιπλέον, συνδέουν διαφορετικά τμήματα του ηλεκτρικού Δικτύου, διευκολύνοντας την ροή που υπάρχει. Η διανομή της ενέργειας γίνεται από τους υποσταθμούς στους τελικούς χρήστες και έχει ως στόχο την εξασφάλιση της συνεχόμενης ενέργειας. Συνδυάζει τεχνολογίες όπως οι έξυπνοι μετρητές και τα Δίκτυα διανομής, χάρη στα οποία ενισχύεται η αποδοτικότητα και η διαχείριση της κατανάλωσης [\[1\]](#).

Η αποδοτική λειτουργία των ΣΗΕ απαιτεί την ενσωμάτωσή τους σε ένα ευρύτερο πλαίσιο ενεργειακής διαχείρισης, το οποίο προστατεύει την ομαλή και ασφαλή παραγωγή και κατανάλωση ηλεκτρικής ενέργειας. Οι σύγχρονες τεχνολογίες και οι στρατηγικές ενεργειακής διαχείρισης είναι κρίσιμες για την παρακολούθηση και την ανάλυση των φορτίων, διευκολύνοντας την προσαρμογή στις μεταβαλλόμενες συνθήκες του ενεργειακού συστήματος. Αυτή η συνολική προσέγγιση δεν διασφαλίζει μόνο την αποδοτικότητα αλλά και

τη σταθερότητα της ενέργειας που παρέχεται στους τελικούς χρήστες, δημιουργώντας τις προϋποθέσεις για την επόμενη φάση της ενεργειακής διαχείρισης [2].


2.1.2. Δίκτυα Διανομής

Ένα Δίκτυο διανομής είναι το σύστημα έχει ως στόχο να μεταφέρει ηλεκτρική ενέργεια από τους υποσταθμούς μεταφοράς στους τελικούς χρήστες, όπως είναι τα νοικοκυριά και οι επιχειρήσεις. Αυτό το Δίκτυο αποτελεί μια σημαντική παράμετρο της υποδομής ηλεκτρικής ενέργειας και περιλαμβάνει απαραίτητα στοιχεία. Οι υποσταθμοί είναι υπεύθυνοι για τη μετατροπή της υψηλής τάσης που προέρχεται από τα Δίκτυα μεταφοράς σε χαμηλότερες τάσεις, οι οποίες είναι έτοιμες για κατανάλωση. Οι γραμμές διανομής φέρνουν την ηλεκτρική ενέργεια μέσω Δικτύου καλωδίων σε διάφορες περιοχές και μπορεί να είναι είτε υπέργειες είτε υπόγειες.

Στην Ελλάδα συγκεκριμένα, υπάρχει Δίκτυο 113.358 χλμ. Μέσης Τάσης (MT) και 128.211 χλμ. Χαμηλής Τάσης (XT). Οι μεσαίας τάσης γραμμές, που κυμαίνονται από 1 kV έως 35 kV, επιτρέπουν τη διανομή της ηλεκτρικής ενέργειας από τους υποσταθμούς σε τοπικούς σταθμούς μετασχηματισμού, εξυπηρετώντας μεγάλους καταναλωτές. Οι γραμμές χαμηλής τάσης αντίθετα, χρησιμοποιούνται στα περισσότερα ηλεκτρικά συστήματα των νοικοκυριών, έχουν τάση που κυμαίνεται μεταξύ 100 και 230 V, ανάλογα με την περιοχή και διασφαλίζουν τη ασφαλή κατανάλωση της ηλεκτρικής ενέργειας μέσω διακοπών κυκλώματος [3].


Ένα **Ακτινικό Δίκτυο Διανομής** (radial distribution system) χαρακτηρίζεται από έναν σχεδιασμό Δικτύου όπου η ηλεκτρική ενέργεια μεταφέρεται από έναν μόνο υποσταθμό μέσω τροφοδοτών προς πολλούς καταναλωτές. Στο Δίκτυο αυτό, υπάρχει μία κεντρική πηγή, που συνεργάζεται με τον εκάστοτε τροφοδότη με σκοπό να εξυπηρετεί μια συγκεκριμένη περιοχή και να καταλήγει στις εγκαταστάσεις των καταναλωτών. Ένα από τα βασικά πλεονεκτήματα αυτού του συστήματος είναι ότι είναι απλούστερο και φθηνότερο στην εγκατάσταση σε σύγκριση με άλλες διαμορφώσεις, διαθέτοντας μια σχεδίαση που είναι εύκολη στη συντήρηση. Ωστόσο, φέρει και μειονεκτήματα, για παράδειγμα εάν προκύψει σφάλμα κατά μήκος της γραμμής, όλοι οι καταναλωτές που βρίσκονται κάτω από αυτό το σημείο χάνουν την ηλεκτρική ενέργεια, με τον χρόνο διακοπής να αυξάνεται σε μεγάλο βαθμό. Αυτή η χαρακτηριστική λειτουργία καθιστά τα ακτινικά Δίκτυα σημαντικά στην ηλεκτρική διανομή, αν και η

αποτελεσματικότητα και η αξιοπιστία τους μπορούν να επηρεαστούν από το σχεδιασμό και την συντήρησή τους [4].



Ακτινικό Δίκτυο Διανομής [4]

Ένα **Βροχοειδές Σύστημα Διανομής** (meshed distribution system) περιλαμβάνει πολλαπλές διασυνδεδεμένες γραμμές που επιτρέπουν την ηλεκτρική ενέργεια να ρέει μέσω εναλλακτικών διαδρομών, περιλαμβάνοντας κομμάτια ακτινικής τοπολογίας. Αυτή η αρχιτεκτονική προσφέρει μεγαλύτερη αξιοπιστία, καθώς αν σημειωθεί βλάβη σε ένα σημείο του Δικτύου, η ηλεκτρική τροφοδοσία μπορεί να ανακατευθυνθεί μέσω άλλων γραμμών, περιορίζοντας έτσι δραστικά τις διακοπές ρεύματος. Παρόλο που η εγκατάσταση ενός δικτυωτού συστήματος είναι πιο περίπλοκη και απαιτεί υψηλότερο κόστος, η αυξημένη ασφάλεια και η συνεχής τροφοδοσία που προσφέρει το καθιστούν κατάλληλο για κρίσιμες υποδομές, όπως είναι τα νοσοκομεία και οι βιομηχανίες [5].



Βροχοειδές Δίκτυο Διανομής [5]

2.1.3. PMU

Ως PMU (Phasor Measurement Unit) ορίζεται η συσκευή που εκτιμά φάσεις, συχνότητες και ρυθμούς μεταβολής μέσα από συγχρονισμένες μετρήσεις. Οι μετρήσεις αυτές, είναι ακριβείς χάρη στη χρήση GPS και συμβαίνουν σε πραγματικό χρόνο με εξαιρετική ακρίβεια. Οι PMUs τοποθετούνται πάνω στους υποσταθμούς του συστήματος και έχουν την δυνατότητα να μεταδίδουν τα δεδομένα κάθε κόμβου και τροφοδότη [6].

Μία φάση αποτελεί έναν αριθμό που περιλαμβάνει το μέγεθος και τη γωνία φάσης των κυμάτων που υπάρχουν στο εναλλασσόμενο ρεύμα.

$$x(t) = x_m \sin(\omega t + \phi)$$

Με ω την γωνιακή συχνότητα του σήματος σε rad ανά δευτερόλεπτο, ϕ τη γωνία φάσης και x_m τη μέγιστη τιμή του πλάτους.

Ο synchrophasor που δημιουργείται, από την συνεργασία μέτρησης με gps δίνει την δυνατότητα εκτενής ανάλυσης, παρακολούθησης σε πραγματικό χρόνο. Παράγει ακριβή δεδομένα, τα οποία διευκολύνουν σημαντικά την ανταπόκριση σε διαταραχές και διατηρούν την αξιοπιστία. Αυτά μπορούν να βοηθήσουν το σύστημα με πολλούς τρόπους:

- Βελτιώνουν την εκτίμηση κατάστασης
- Επιτρέπουν την δυναμική παρατήρηση του Δικτύου
- Επεκτείνουν τα γεωγραφικά όρια παρακολούθησης
- Αανιχνεύουν προβλήματα και ενημερώνουν
- Συντελούν στην συντομότερη αποκατάσταση σφαλμάτων Δικτύου

Είδη PMU

Υπάρχουν διάφορα είδη PMU τα οποία διαφοροποιούνται με βάση τις λειτουργίες τους. Τα πιο απλά είναι τα **Standalone PMUs** τα οποία δρουν αυτόνομα και τοποθετούνται στα πιο κομβικά σημεία ενός Δικτύου. Αποστέλλουν τις μετρήσεις τους στην κεντρική μονάδα διαχείρισης και χαρακτηρίζονται για την υψηλή τους ακρίβεια [7]. Τα **Embedded PMUs** βρίσκονται ήδη ενσωματωμένα σε άλλες συσκευές όπως οι διακόπτες ή οι διάταξης προστασίας. Αυτά μπορούν να προβούν σε μετρήσεις χωρίς την επιπλέον χρήση εξοπλισμού, γεγονός που τα καθιστά απαραίτητα για παρακολούθηση σε περιοχές που δεν απαιτείται τεράστια ακρίβεια. Για συστήματα χαμηλότερης τάσης γίνεται χρήση **Micro-PMUs** [8], τα οποία προσφέρουν λεπτομέρεια στο αποτέλεσμα και προτείνονται σε τοπικά συστήματα όπως είναι τα Δίκτυα διανομής. Είναι ιδανικά για περιπτώσεις όπου υπάρχουν συνεχώς δυναμικές αλλαγές στο σύστημα και έντονη αστάθεια. Τέλος, τα **Hybrid PMUs** αποτελούν πολύπλευρες συσκευές που μπορούν να καταγράψουν παραμέτρους πέραν των φασικών μετρήσεων και προσδίδουν μία ολοκληρωμένη εικόνα στον δέκτη. Χρησιμοποιούνται κατά κόρον σε περιπτώσεις που υπάρχει ανάγκη χαμηλού κόστους εγκατάστασης, με σκοπό να εξοικονομηθούν χρήματα.

2.1.4. Power Flow

Η μελέτη του Power Flow ή αλλιώς Ροή Φορτίου είναι μια διαδικασία που επιτρέπει καλύτερο σχεδιασμό και ανάλυση σε ένα σύστημα ισχύος. Γίνεται αντιληπτό πως ρέει η ηλεκτρική ενέργεια και περιλαμβάνει διάφορα μεγέθη όπως είναι η τάση, η γωνία τάσης, η ενεργός και η άεργος ισχύς. Το πρώτο βήμα για την επίλυση της ροής ισχύος ξεκινάει με τον ορισμό των γνωστών και των άγνωστων μεταβλητών στο σύστημα. Αυτές εξαρτώνται από τον τύπο του ζυγού, ο οποίος είναι είτε ζυγός φορτίου αν δεν συνδέεται με γεννήτρια, είτε ζυγός γεννήτριας αν συνδέεται.

Στο πρόβλημα της ροής ισχύος, παίρνουμε ως δεδομένο ότι η πραγματική ισχύς και η άεργος ισχύς σε κάθε ζυγό φορτίου, είναι γνωστές. Όσον αφορά τους Ζυγούς Γεννητριών, υποτίθεται ότι η πραγματική ισχύς καθώς και το μέγεθος της τάσης είναι γνωστά. Συνεπώς, για κάθε Ζυγό Φορτίου, το μέγεθος της τάσης και η γωνία της παραμένουν άγνωστα. Στην βιβλιογραφία, υπάρχουν ποικίλες μέθοδοι επίλυσης για το σύστημα εξισώσεων που παράγει το πρόβλημα της ροής φορτίου, με πιο διαδεδομένη να είναι η προσέγγιση Newton-Raphson [9]. Αυτή η μέθοδος αρχίζει με αρχικές εκτιμήσεις όλων των άγνωστων μεταβλητών, δηλαδή το μέγεθος της τάσης και οι γωνίες της στους Ζυγούς Φορτίου και οι γωνίες τάσης στους Ζυγούς Γεννήτριας. Έπειτα, γράφεται μια Σειρά Taylor με τους όρους υψηλότερης τάξης να αγνοούνται, για κάθε μια από τις εξισώσεις ισορροπίας ισχύος που περιλαμβάνονται στο σύστημα εξισώσεων [10].

$$\Delta P_i = -P_i + \sum_{k=1}^N |V_i||V_k|(G_{ik} \cos \theta_{ik} + B_{ik} \sin \theta_{ik})$$
$$\Delta Q_i = -Q_i + \sum_{k=1}^N |V_i||V_k|(G_{ik} \sin \theta_{ik} - B_{ik} \cos \theta_{ik})$$

Σειρά Taylor

Μια γενική προσέγγιση για την επίλυση του προβλήματος ροής ισχύος είναι πως:


- Γίνεται αρχική εκτίμηση όλων των άγνωστων μεγεθών. Συνήθως χρησιμοποιείται μία προσέγγιση, όπου όλες οι γωνίες τάσης ορίζονται σε μηδέν και όλα τα μεγέθη τάσης σε 1.0 ανά μονάδα.
- Λύνονται οι εξισώσεις ισορροπίας με χρήση των πιο πρόσφατων τιμών για τις γωνίες και τα μεγέθη τάσης.
- Ενημερώνονται οι νέες τιμές
- Ελέγχονται οι συνθήκες τερματισμού, όπου αν δεν πληρούνται επαναλαμβάνεται η διαδικασία από το δεύτερο βήμα.

2.1.5. Εκτίμηση Κατάστασης και τοπολογίας

Η Εκτίμηση Κατάστασης (System Estimation) αποτελεί μία διαδικασία διαχείρισης καθώς και ανάλυσης ενεργειακών συστημάτων. Λειτουργεί με βάση τον προσδιορισμό της εσωτερικής κατάστασης ενός συστήματος, χάρη στην χρήση μαθηματικών μοντέλων με μετρήσεις εισόδου και εξόδου. Χαρακτηριστικά παραδείγματα που η εκτίμηση κατάστασης κρίνεται απαραίτητη είναι συστήματα ενέργειας, όπως τα Δίκτυα διανομής ηλεκτρικής ενέργειας, οι αιολικοί σταθμοί και άλλοι περιβαλλοντικοί χώροι [\[11\]](#).

Αρχικά, το σύστημα λαμβάνει τις εισόδους που συμβολίζονται ως $u(t)$, ενώ διαθέτει και τις δικές του μετρήσεις $y(t)$ μέσα από ειδικούς αισθητήρες όπως τα PMUs. Προσπαθεί να παρατηρεί την εσωτερική κατάσταση $x(t)$ και να την προβλέψει μέσα από μαθηματικά μοντέλα τις τιμές τους και στο τέλος ο υπολογιστής συγκρίνει την εκτιμώμενη έξοδο με την αληθινή μετρημένη έξοδο.

Η εκτίμηση κατάστασης μπορεί να χωριστεί σε τρεις κατηγορίες ανάλογα με την φύση των μετρήσεων καθώς και το μοντέλο του δυναμικού συστήματος ηλεκτρικής ενέργειας που χρησιμοποιείται. Μία βασική κατηγορία, αποτελεί η **στατική εκτίμηση κατάστασης**, όπου έχουμε σταθερές χρονικά μετρήσεις και μοντέλο. Συγκεκριμένοι αλγόριθμοι που έχουν σχεδιαστεί κατάλληλα αναλύουν αυτές τις μετρήσεις και εξάγουν αξιόπιστα συμπεράσματα ως προς την αρχική κατάσταση του συστήματος. Οι **αλγόριθμοι παρακολούθησης** επεκτείνουν τις τεχνικές στατικής εκτίμησης. Ενεργοποιούν τις πιο πρόσφατες διαθέσιμες τιμές και βελτιώνουν την αποδοτικότητα σε συνδυασμό με την ταχύτητα υπολογισμού. Η **δυναμική εκτίμηση** κατάστασης έχει τη δυνατότητα όχι μόνο να χρησιμοποιεί τις παρούσες καταστάσεις αλλά να λαμβάνει υπόψη και τις προηγούμενες εκτιμήσεις. Αυτό της επιτρέπει να διαθέτει περισσότερο χρόνο για τις εκτιμήσεις της με ασφαλέστερα αποτελέσματα [12].



Εκτίμηση κατάστασης συστήματος ενέργειας [13]

Όσον αφορά την εκτίμηση κατάσταση συγκεκριμένα στα ηλεκτρικά συστήματα, είναι απαραίτητη για την κατανόηση και παρακολούθηση της κατάστασης ενός ενεργειακού συστήματος. Είναι μια κρίσιμη διαδικασία που επιτρέπει την κατανόηση και παρακολούθηση της κατάστασης ενός ενεργειακού συστήματος. Πρόκειται για την αξιολόγηση των εσωτερικών παραμέτρων του συστήματος με τη χρήση μαθηματικών μοντέλων και μετρήσεων από αισθητήρες. Αυτή η διαδικασία έχει πολλές εφαρμογές, όπως η παρακολούθηση της υγείας του Δικτύου, η πρόβλεψη δυναμικών συμπεριφορών και η υποστήριξη των λειτουργιών ελέγχου του συστήματος. Περιλαμβάνει την εκτίμηση των εσωτερικών παραμέτρων, όπως είναι η ενεργός και η άεργος ισχύς, χάρη στις εξισώσεις ισορροπίας. Μια σημαντική πρόκληση

αποτελεί και η παρουσία θορύβου στις μετρήσεις όπως και οι μη γραμμικές συμπεριφορές ενός Δικτύου. Ο θόρυβος προέρχεται από διάφορες πηγές, όπως οι ηλεκτρομαγνητικές παρεμβολές και τα σφάλματα κατά την εγκατάσταση των αισθητήρων. Αυτές μπορούν να επηρεάσουν τις μετρήσεις των PMUs, μειώνοντας την αξιοπιστία τους, οπότε χρησιμοποιούνται τεχνικές σαν τον αλγόριθμο Kalman filter, προκειμένου να ενοποιούνται δεδομένα από πολλές πηγές και να μειώνονται τα τελικά σφάλματα. Επιπρόσθετα, οι μη γραμμικές συμπεριφορές Δικτύου οδηγούν στην ανάπτυξη πιο πολύπλοκων μοντέλων για την εκτίμηση κατάστασης. Δημοφιλείς έχουν γίνει οι προσεγγίσεις μέσω Νευρωνικών Δικτύων που αποτυπώνουν καλύτερα τις πραγματικές δυναμικές του συστήματος. Προσφέρουν νέες δυνατότητες στην εκτίμηση κατάστασης, επιτρέποντας την ανάλυση πιο περίπλοκων σχέσεων και προτύπων στα δεδομένα.

Χάρη στην πρόοδο της τεχνολογίας PMU, παρέχεται η δυνατότητα παρατήρησης σε πραγματικό χρόνο, ενώ παράλληλα μειώνονται και οι συνέπειες των σφαλμάτων στις μετρήσεις. Με τον συνδυασμό αλγόριθμων εκτίμησης κατάστασης και τεχνολογίας PMU, οι προβλέψεις ενδεχόμενων διαταραχών γίνονται ευκολότερες, με αποτέλεσμα την ανάπτυξη τακτικών αποκατάστασης που διασφαλίζουν την σταθερότητα του ηλεκτρικού Δικτύου.

Πέραν της εκτίμησης κατάστασης, υπάρχει και η εκτίμηση τοπολογίας που αποτελεί ζωτική διαδικασία για τα συστήματα ηλεκτρικής ενέργειας καθώς επιβεβαιώνει την λειτουργική κατάσταση του Δικτύου, δηλαδή ποιες γραμμές και ποιοι διακόπτες είναι ανοιχτοί και ποιοι κλειστοί. Παίρνει μετρήσεις που προέρχονται από PMU ή SCADA (Supervisory Control And Data Acquisition) και αφορούν ρεύμα, τάση ή ισχύς στους κόμβους και στους κλάδους του Δικτύου. Προκειμένου να ελαχιστοποιηθούν τα σφάλματα, χρησιμοποιούνται έντονα αλγόριθμοι βασισμένοι σε θεωρίες γράφων, οι οποίοι διασταυρώνουν δεδομένα και παράγουν ακριβή αποτελέσματα. Ενδεικτικά παραδείγματα χρήσης είναι το Bayesian Inference και το Maximum Likelihood estimation [\[14\]](#).

2.1.6. Μελλοντικές Τάσεις


Τα συστήματα ηλεκτρικής ενέργειας αποτελούν έναν χώρο όπου συμβαίνουν τεχνολογικές εξελίξεις πυρετωδώς. Αρχικά, συνδέεται άμεσα με την ενσωμάτωση των ανανεώσιμων πηγών ενέργειας (ΑΠΕ), οι οποίες έχουν αρχίσει και κυριαρχούν στην κοινωνία σε συνεργασία με την βελτίωση της τεχνολογίας αποθήκευσης ενέργειας. Χαρακτηριστικά παραδείγματα, αποτελούν τα ψηφιακά Δίκτυα, τα έξυπνα Δίκτυα, τα μικροδίκτυα καθώς και τα πολυενεργειακά κέντρα, όπου πλέον αποτελούν κομβικό κομμάτι της λειτουργίας των ΣΗΕ. Επιτρέπουν την βέλτιστη αξιοποίηση πόρων εξοικονομώντας ενέργεια και χρήματα, ενώ συνδράμουν στην αποκέντρωση και τον εξηλεκτρισμό του ενεργειακού τομέα.

Βάρος έχει δοθεί και στις τεχνολογίες που αφορούν την μετατροπή ισχύος, όπως οι μετατροπείς DC-DC και DC-AC, που θα χρειαστεί να προσαρμοστούν στις νέες λειτουργίες που φέρνουν οι ανανεώσιμες πηγές. Νέες αρχιτεκτονικές θα αλλάξουν ριζικά αυτούς τους μετατροπείς καθώς και οι βελτιώσεις στις ελεγκτικές μεθόδους τους θα αναπτύξουν ριζικά τομείς έρευνας που αφορούν την απόδοση και αποδοτικότητα των συστημάτων [15].

Αξιοσημείωτη έρευνα συμβαίνει και στη χρήση προηγμένων αλγορίθμων για τον έλεγχο και την εποπτεία των συστημάτων με ΑΠΕ, καθώς και στις μεθόδους διεκπεραίωσης προγραμματισμού στην παραγωγή και τη διαχείριση των φορτίων. Οι **νέοι αλγόριθμοι πρόβλεψης φορτίου**, χρησιμοποιούν τεχνικές μηχανικής μάθησης για να προβλέψουν τη ζήτηση ενέργειας και την παραγωγή από ηλιακά ή αιολικά συστήματα. Αυτές οι προβλέψεις επιτρέπουν την καλύτερη προετοιμασία και αντιστάθμιση των μεταβολών στο Δίκτυο. Οι **αλγόριθμοι βελτιστοποίησης καταναεμημένης παραγωγής**, χρησιμοποιούνται για τον καθορισμό της βέλτιστης ποσότητας ενέργειας που πρέπει να παράγεται ή να αποθηκεύεται από διανεμημένους πόρους (όπως φωτοβολταϊκά πάνελ και μπαταρίες) ώστε να επιτυγχάνεται η σταθερότητα του συστήματος. Τέλος τα **Συστήματα αυτοματοποιημένου ελέγχου** χρησιμοποιούν δεδομένα από αισθητήρες σε πραγματικό χρόνο και αλγορίθμους ανάλυσης για να ανιχνεύουν ανωμαλίες στη λειτουργία του Δικτύου και να ενεργοποιούν ενέργειες για την αποκατάσταση της κανονικής λειτουργίας.

Μία ειδική αναφορά αξίζει να γίνει στην τεχνολογία έξυπνων δικτύων (Smart Grids), η οποία επαναστατεί ως προς την δομή λειτουργίας των ενεργειακών συστημάτων, αφού επιτρέπει την αυτόματα και συνεχόμενη μεταφορά πληροφοριών μεταξύ πάροχων ενέργειας και καταναλωτών [16]. Αυτή η αμφίδρομη επικοινωνία βελτιώνει αισθητά τη διαχείριση του φορτίου, επιτρέποντας την σωστότερη παρακολούθηση και τον έλεγχο της κατανάλωσης. Τα έξυπνα Δίκτυα περιλαμβάνουν προηγμένες τεχνολογίες, όπως οι αισθητήρες και οι έξυπνοι

μετρητές, οι οποίοι προσδίδουν δεδομένα σε πραγματικό χρόνο για την παραγωγή και την ζήτηση που υπάρχει, δίνοντας έτσι την δυνατότητα καλύτερης εκτίμησης και την προσαρμογή των λειτουργιών του Δικτύου.



Smart Grid και εφαρμογές

2.2. Μηχανική Μάθηση

2.2.1. Εισαγωγή

Η Τεχνητή Νοημοσύνη αποτελεί έναν από τους πιο νευραλγικούς τεχνολογικούς τομείς της σημερινής εποχής, επηρεάζοντας σχεδόν κάθε πτυχή του δημόσιου βίου, από την υγεία και την εκπαίδευση μέχρι τις επιχειρήσεις, τον αθλητισμό και την ψυχαγωγία. Πρακτικά, αποτελεί την ικανότητα των μηχανών να εκτελούν τις λειτουργίες που πρέπει χωρίς να απαιτούν την

αρωγή της ανθρώπινης νοημοσύνης, όπως η αναγνώριση ομιλίας, η επίλυση προβλημάτων, η μάθηση από εμπειρίες και η λήψη αποφάσεων [17].

Η **Μηχανική Μάθηση**, ένας βασικός κλάδος της τεχνητής νοημοσύνης, στηρίζεται στη χρήση δεδομένων με σκοπό την εκπαίδευση αλγορίθμων. Οι αλγόριθμοι αυτοί, δίνουν τη δυνατότητα στους υπολογιστές να αναλύουν μεγάλο όγκο δεδομένων, να ανιχνεύουν μοτίβα και να εξάγουν συμπεράσματα. Η καινοτομία που φέρνει η Μηχανική Μάθηση είναι πως οι υπολογιστές μπορούν να βελτιώνονται συνεχώς με την πάροδο του χρόνου, χωρίς να προγραμματίζει κάτι ο χρήστης χειροκίνητα. Αυτή τους η δυνατότητα, τους καθιστά σημαντικούς σε εφαρμογές όπως η ανάλυση μεγάλου όγκου δεδομένων και η αναγνώριση φωνής [18].

Επιπρόσθετα, υπάρχουν υποκατηγορίες που διαχωρίζουν τη Μηχανική Μάθηση, όπως η επιβλεπόμενη μάθηση, όπου οι αλγόριθμοι εκπαιδεύονται με συγκεκριμένα δεδομένα και αναμενόμενα αποτελέσματα αλλά και η μη επιβλεπόμενη μάθηση, όπου το σύστημα ψάχνει μοτίβα στα δεδομένα χωρίς επιθυμητά παραδείγματα. Ακόμη μία εξέλιξη αποτελεί η βαθιά μάθηση (Deep Learning), που κάνει χρήση Νευρωνικών Δικτύων προκειμένου να αναλύσει πολύπλοκα δεδομένα και να πετύχει αποτελέσματα σε τομείς όπως η αυτόνομη οδήγηση ή η αναγνώριση προσώπων.

Με την ατέρμονη ανάπτυξη της τεχνολογίας, η Τεχνητή Νοημοσύνη δεν περιορίζεται πλέον σε ερευνητικά πεδία αλλά προωθείται και σε καταναλωτικά προϊόντα όπως τα chatbots αλλά και τα συστήματα αυτόματης εξυπηρέτησης πελατών. Συγχρόνως, οι ηθικές και κοινωνικές συνέπειες ολοένα και διεγείρονται καθώς οι ανησυχίες γύρω από την ιδιωτικότητα, την ασφάλεια και την καχυποψία που υπάρχει για τους αλγόριθμους δυσχεραίνουν την κατάσταση, πόσο μάλλον όταν αυτή οδηγείται σε απώλεια θέσεων εργασίας χάρη στην αυτοματοποίηση των μηχανών.

Η **Τεχνητή Νοημοσύνη** δεν είναι ένα απλό εργαλείο για την διευκόλυνση της καθημερινότητας, αλλά ένας καταλύτης για μία παγκόσμια αλλαγή που θα επαναδιαμορφώσει το μέλλον.

2.2. Αλγόριθμοι Μηχανικής Μάθησης

Υπάρχουν πολλοί διαφορετικοί αλγόριθμοι που χρησιμοποιούνται στη **Μηχανική Μάθηση**, με τον καθένα από αυτούς να είναι κατάλληλος για διαφορετικού είδους προβλήματα. Η επιλογή του ιδανικού αλγόριθμου εξαρτάται πάντα από τις απαιτήσεις της εκάστοτε εφαρμογής, τη φύση των δεδομένων που χρησιμοποιούνται καθώς και το επιθυμητό αποτέλεσμα. Για παράδειγμα, άλλες φορές προτιμώνται αλγόριθμοι που εμβαθύνουν στην ακρίβεια πρόβλεψης, ενώ άλλες στην ταχύτητα εκτέλεσης. Συνεπώς, οι αλγόριθμοι μηχανικής μάθησης διαχωρίζονται σε τρεις βασικές κατηγορίες, την επιβλεπόμενη μάθηση, τη μη επιβλεπόμενη μάθηση και την ενισχυτική μάθηση [19].

2.2.1. Επιβλεπόμενη Μάθηση

Η επιβλεπόμενη μάθηση σχετίζεται με τη χρήση ενός συνόλου από δεδομένα που περιέχει επισημασμένες ετικέτες, δηλαδή συνεργασίες εισόδων και των αντίστοιχων εξόδων. Κατά την εκπαίδευση ενός μοντέλου μέσω επιβλεπόμενης μάθησης, οι αλγόριθμοι προσπαθούν να κατανοήσουν πως να συνδέουν τα δεδομένα εισόδου με τα ορθά αποτελέσματα, επιτρέποντας τους να κάνουν λεπτομερείς προβλέψεις σε νέα, άγνωστα δεδομένα. Προκειμένου να γίνει η εκπαίδευση χρησιμοποιείται ένα σύνολο δεδομένων με γνωστές τιμές εισόδου και εξόδου, όπου το μοντέλο καταλαβαίνει να αναγνωρίζει τα μοτίβα που διαμορφώνουν την έξοδο. Κατά την επικύρωση, το σύστημα κάνει τεστ με δεδομένα που δεν έχει ξαναδεί, αλλά είναι επίσης επισημασμένα. Σκοπός είναι η γενίκευση, δηλαδή το μοντέλο να είναι σε θέση να προβλέψει σωστά την έξοδο για νέα, αδημοσίευτα δεδομένα [20].

Οι πιο συνηθισμένες εφαρμογές της επιβλεπόμενης μάθησης χωρίζονται σε προβλήματα ταξινόμησης και προβλήματα παλινδρόμησης. Στα προβλήματα ταξινόμησης, οι αλγόριθμοι εκπαιδεύονται ώστε να μπορούν να προβλέπουν και να γενικεύουν μεταβλητές-στόχους, οι οποίες ανήκουν σε μία από πολλές διακριτές κατηγορίες ή κλάσεις. Ο στόχος της ταξινόμησης είναι να αντιστοιχίσει ένα σύνολο χαρακτηριστικών εισόδου σε μία συγκεκριμένη κατηγορία. Από την άλλη πλευρά, τα προβλήματα παλινδρόμησης ασχολούνται με την εκτίμηση συνεχών αριθμητικών τιμών. Αντί να προσδιορίσουν κατηγορίες, οι αλγόριθμοι παλινδρόμησης προσπαθούν να προβλέψουν τιμές πάνω σε ένα συνεχές φάσμα. Κάθε μία από αυτές τις προσεγγίσεις είναι εξαιρετικά χρήσιμη σε σχέση με το πρόβλημα που προσπαθεί να επιλυθεί, με την ταξινόμηση να είναι πιο δημοφιλής σε προβλήματα όπως η αναγνώριση αντικειμένων ή προσώπων και την παλινδρόμηση να βρίσκει εφαρμογή σε τομείς όπως η πρόβλεψη τιμών και οι οικονομικές αναλύσεις.

2.2.2. Μη επιβλεπόμενη μάθηση

Η μη επιβλεπόμενη μάθηση παίζει σημαντικό ρόλο στη **Μηχανική Μάθηση**, αφού αποτελείται από αλγόριθμους που έχουν τη δυνατότητα να ανακαλύπτουν μοτίβα και σχέσεις μεταξύ δειγμάτων που δεν έχουν επισημανθεί. Σε αυτή την λογική, οι αλγόριθμοι επιδιώκουν να ανιχνεύσουν φυσικές σχέσεις και ομαδοποιήσεις εντός των δεδομένων, χωρίς να έχουν στην κατοχή τους πληροφορίες σε σχέση με κάποιο συγκεκριμένο αποτέλεσμα. Πρακτικά, προσπαθούν να αναγνωρίσουν άγνωστες υποομάδες που διαθέτουν κοινά χαρακτηριστικά [\[21\]](#).

Σε αντίθεση με την επιβλεπόμενη μάθηση, όπου οι αλγόριθμοι εκπαιδεύονται με επισημασμένα δεδομένα που περιέχουν τις σωστές εξόδους, η μη επιβλεπόμενη μάθηση δεν παρέχει αυτές τις επισημασμένες εξόδους. Ο πρωταρχικός σκοπός αυτής της μεθόδου είναι η ανακάλυψη κρυφών μοτίβων, ομοιοτήτων που περιέχονται στα δεδομένα. Αυτές οι ανακαλύψεις μπορούν μετέπειτα να αξιοποιηθούν για διάφορες εφαρμογές, όπως η ομαδοποίηση και η εξερεύνηση δεδομένων.

Βασικό πλεονέκτημα της μη επιβλεπόμενης μάθησης είναι ότι δεν απαιτεί ανθρώπινη καθοδήγηση ή επίβλεψη, γεγονός που την καθιστά ιδιαίτερα ευπροσάρμοστη και χρήσιμη σε περιβάλλοντα όπου η συλλογή επισημασμένων δεδομένων είναι δύσκολη ή δαπανηρή. Οι αλγόριθμοι ομαδοποίησης είναι μια κοινή υλοποίηση της μη επιβλεπόμενης μάθησης και λειτουργούν με την κατηγοριοποίηση δειγμάτων με βάση αντίστοιχα χαρακτηριστικά. Αυτές τεχνικές, είναι δημοφιλείς σε πεδία όπως η μελέτη κειμένων και η ανάλυση πελατών.

Ενδεικτικά παραδείγματα εφαρμογών μη επιβλεπόμενης μάθησης αφορούν τη διαχωριστική ανάλυση, όπου τα δεδομένα ομαδοποιούνται σε ομάδες με βάση ομοιότητες, και τη μέθοδο K-means, που είναι ιδιαίτερα γνωστή για την ομαδοποίηση μεγάλων συνόλων δεδομένων [\[22\]](#).

2.2.3. Ενισχυτική Μάθηση

Η ενισχυτική μάθηση είναι μία ιδιαίτερη προσέγγιση της **Μηχανικής Μάθησης** που στηρίζεται στην αλληλεπίδραση ενός πράκτορα με το περιβάλλον του. Σε αυτή τη μέθοδο, ο

πράκτορας προσπαθεί να αυξήσει την απόδοσή του μέσω της εκτέλεσης ενεργειών και λήψης αποφάσεων. Η διαδικασία αυτή είναι επιτρεπτή μέσω της ανατροφοδότησης που λαμβάνει, η οποία εκφράζεται με τη μορφή ανταμοιβών ή ποινών.

Με τον όρο πράκτορα διατυπώνεται ένα ευφυές σύστημα, το οποίο έχει τη δυνατότητα να αντιλαμβάνεται το περιβάλλον του και να δρα στο εσωτερικό του. Αντίθετα από άλλες μεθόδους μηχανικής μάθησης, που στηρίζονται σε επισημασμένα σύνολα δεδομένων, η ενισχυτική μάθηση βασίζεται στην επαναληψιμότητα της προσέγγισης, όπου η διαδικασία εκπαίδευσης ορίζεται από την ανατροφοδότηση ανταμοιβών ή ποινών στο σύστημα [23].

Οι ανταμοιβές στην ενισχυτική μάθηση, δεν είναι κάτι άλλο από μία θετική ενίσχυση που προσφέρει κίνητρα στον πράκτορα να πράττει ώστε να εκτελεί τις σωστές ενέργειες. Όταν ο πράκτορας αναλαμβάνει μία επιθυμητή ενέργεια, ανταμείβεται, γεγονός που τον προδιαθέτει στο να επαναλάβει αυτή τη διαδικασία μελλοντικά. Αντιθέτως, οι ποινές έχουν τον ρόλο της αρνητικής ενίσχυσης, αποθαρρύνοντας τον πράκτορα από το να πράξει εκ νέου ανεπιθύμητες ενέργειες.

Η διαδικασία ενισχυτικής μάθησης είναι δυναμική και προσαρμόζεται συνεχώς. Με βάση την ανατροφοδότηση, ο πράκτορας καθορίζει την τακτική του και επαναλαμβάνει τις ίδιες ενέργειες, επηρεασμένος από τα νέα δεδομένα που έχουν προκύψει. Η στρατηγική αυτή, δίνει τη δυνατότητα στο σύστημα να μεγιστοποιεί διαρκώς την απόδοσή του, μαθαίνοντας από τις εμπειρίες του και βελτιώνοντας τις αποφάσεις του με στόχο τα καλύτερα αποτελέσματα. Οι εφαρμογές του μοντέλου αυτού είναι ποικίλες, από αυτόνομα οχήματα μέχρι βιομηχανικά ρομπότ. Καθημερινά ανοίγονται νέοι ορίζοντες στην ανάπτυξη ευφυών συστημάτων που μπορούν να μάθουν και να προσαρμόζονται σε δυναμικά και μεταβαλλόμενα περιβάλλοντα.

2.3. Pytorch

Το PyTorch είναι μια δημοφιλής βιβλιοθήκη μηχανικής μάθησης και βαθιάς μάθησης ανοιχτού κώδικα, που αναπτύχθηκε από το Facebook AI Research. Ξεχωρίζει για την ευελιξία του, την ταχύτητα και τη φιλικότητα προς τον χρήστη, καθιστώντας το ιδανικό εργαλείο για ερευνητές και μηχανικούς. Το PyTorch παρέχει ένα δυναμικό υπολογιστικό γράφημα (dynamic

computation graph), το οποίο επιτρέπει τη δημιουργία και τροποποίηση μοντέλων σε πραγματικό χρόνο, διευκολύνοντας την πειραματική εργασία [24].

Σε αντίθεση με άλλα πλαίσια, όπως το **TensorFlow** (σε παλαιότερες εκδόσεις του), το PyTorch χρησιμοποιεί δυναμικό υπολογιστικό γράφημα. Αυτό σημαίνει ότι οι δομές του γραφήματος δημιουργούνται και τροποποιούνται δυναμικά κατά την εκτέλεση του κώδικα. Το χαρακτηριστικό αυτό το καθιστά ιδιαίτερα φιλικό για εφαρμογές που απαιτούν πειραματισμούς και ταχεία ανάπτυξη. Το PyTorch διαθέτει ένα ενσωματωμένο σύστημα αυτόματης παραγωγής, που διευκολύνει την εκπαίδευση των Νευρωνικών Δικτύων. Οι χρήστες μπορούν να υπολογίζουν παραγώγους μέσω της λειτουργίας `torch.autograd`, κάτι που επιτρέπει την ταχεία προσαρμογή και βελτιστοποίηση των μοντέλων. Επιπλέον, προσφέρει πλήρη υποστήριξη για **GPU** μέσω του **CUDA**, παρέχοντας τη δυνατότητα ταχύτερων υπολογισμών. Ο κώδικας μπορεί εύκολα να μεταβεί από **CPU** σε **GPU** με εντολές όπως `model.to(device)`, όπου το `device` είναι είτε **CPU** είτε **CUDA**. Τα tensors είναι η βασική δομή δεδομένων του PyTorch, παρόμοια με τους πίνακες NumPy αλλά με υποστήριξη για παράλληλους υπολογισμούς σε GPU. Υποστηρίζουν λειτουργίες όπως προσθέσεις, πολλαπλασιασμούς και ανασχηματισμούς, προσφέροντας ταχύτητα και απόδοση. Το PyTorch παρέχει το API `torch.nn` για την κατασκευή Νευρωνικών Δικτύων. Οι χρήστες μπορούν να δημιουργήσουν εύκολα σύνθετες αρχιτεκτονικές με επίπεδα (layers) όπως πλήρως συνδεδεμένα (fully connected), συνελκτικά (convolutional) και αναδρομικά (recurrent). Συγχρόνως είναι η βάση για βιβλιοθήκες όπως το PyTorch Lightning και το Hugging Face Transformers, που διευκολύνουν τη δημιουργία και εκπαίδευση σύνθετων μοντέλων, όπως μετασχηματιστές (transformers) [25].

Τα βασικά πλεονεκτήματα που φέρει είναι:

1. Ευκολία στη χρήση μιας και η σύνταξη του θυμίζει έντονα τη γλώσσα προγραμματισμού Python
2. Η υψηλή απόδοση αφού ειδικά όταν γίνεται χρήση GPUs, η ταχύτητα υλοποίησης είναι πολύ υψηλή
3. Η εκτενής κοινότητα και υποστήριξη, με πλούσια τεκμηρίωση και πολλές διαθέσιμες πηγές για εκμάθηση.
4. Η πειραματική ελευθερία με τους ερευνητές να μπορούν να προσαρμόζουν εύκολα τα μοντέλα τους σε διαφορετικά σύνολα δεδομένων ή προβλήματα.

Η Χρήση του PyTorch στα Δίκτυα Διανομής

Τα Δίκτυα διανομής είναι σημαντικά συστήματα που περιλαμβάνουν τη μεταφορά ηλεκτρικής ενέργειας από τους σταθμούς παραγωγής στους τελικούς χρήστες. Στη Μηχανική Μάθηση και βαθιά μάθηση, η ανάλυση αυτών των δικτύων περιλαμβάνει την πρόβλεψη και την αναγνώριση διαταραχών, τη βελτιστοποίηση της κατανομής φορτίου και την ανίχνευση αλλαγών στην τοπολογία [\[26\]](#).

Με το PyTorch, οι ερευνητές μπορούν να δημιουργήσουν και να εκπαιδεύσουν Νευρωνικά Δίκτυα που μοντελοποιούν τη λειτουργία δικτύων διανομής, χρησιμοποιώντας τεχνικές όπως:

- **Graph Neural Networks (GNNs):** Ειδικά για την αναγνώριση τοπολογίας και την πρόβλεψη τάσεων σε κόμβους του Δικτύου.
- **Recurrent Neural Networks (RNNs):** Για την πρόβλεψη χρονικών σειρών που σχετίζονται με ζήτηση ή βλάβες.
- **Convolutional Neural Networks (CNNs):** Για ανάλυση δεδομένων εικόνας, όπως θερμικές εικόνες καλωδίων και εξοπλισμού.

Επιπλέον, το PyTorch μπορεί να ενσωματωθεί σε εργαλεία ανάλυσης δεδομένων πραγματικού χρόνου, προσφέροντας λύσεις για την ανίχνευση βλαβών, την πρόβλεψη ζήτησης και τη διαχείριση κρίσιμων καταστάσεων στο Δίκτυο.

2.4. Μοντέλα Μηχανικής Μάθησης

Για την εκπόνηση της παρούσας διπλωματικής χρησιμοποιήθηκε η λογική τριών μοντέλων μηχανικής μάθησης. Το πολυεπίπεδο Νευρωνικό Δίκτυο, το συνελκτικό Νευρωνικό Δίκτυο (CNN) και το Νευρωνικό Δίκτυο γράφου (GNN).

2.4.1. Πολυεπίπεδο Νευρωνικό Δίκτυο

Τα πολυεπίπεδα Νευρωνικά Δίκτυα (MLP), αποτελούν έναν από τους βασικότερους μηχανισμούς ταξινόμησης στην επιβλεπόμενη Μηχανική Μάθηση. Η τεχνολογία αυτή, προσφέρει ευέλικτες λύσεις για τα προβλήματα σε τομείς όπως η ανάλυση κειμένων και η αναγνώριση εικόνας. Τα MLP έχουν την ικανότητα να αναπαριστούν πολύπλοκες και μη γραμμικές σχέσεις στα δεδομένα εκπαίδευσης, κάνοντας τα ιδανικά για περιπτώσεις κατηγοριοποίησης και παλινδρόμησης. Η δομή τους αποτελείται από τρία επίπεδα με πρώτο το **επίπεδο εισόδου**. Αυτό περιλαμβάνει νευρώνες που λαμβάνουν απευθείας τα χαρακτηριστικά του συνόλου δεδομένων, με τον κάθε νευρώνα να αντιστοιχεί σε ένα χαρακτηριστικό. Οι τιμές εισόδου επηρεάζουν άμεσα τη λειτουργία του Δικτύου, οπότε κρίνεται σημαντική η σωστή επιλογή των χαρακτηριστικών για να υπάρχει η κατάλληλη απόδοση του μοντέλου. Μετά το επίπεδο εισόδου, έρχονται οι υπερπαράμετροι που μπορεί να περιέχει ένα μοντέλο και αποτελούν βασικό γρανάζι προκειμένου να βελτιωθεί η ακρίβεια και η ικανότητα του.

Αρχικά, έχουμε τα **κρυφά στρώματα** (hidden layers), τα οποία είναι τα ενδιάμεσα επίπεδα μεταξύ του στρώματος εισόδου και του στρώματος εξόδου. Ο ρόλος τους είναι να μετασχηματίζουν τα δεδομένα εισόδου μέσω διαδοχικών υπολογισμών, επιτρέποντας στο Δίκτυο να μάθει και να αναπαραστήσει σύνθετες μη γραμμικές σχέσεις. Ο αριθμός των κρυφών στρωμάτων και των νευρώνων σε κάθε στρώμα επηρεάζει σημαντικά την απόδοση του Δικτύου. Σύμφωνα με μελέτες, η αύξηση του αριθμού των κρυφών στρωμάτων μπορεί να βελτιώσει την ικανότητα του Δικτύου να αναγνωρίζει πολύπλοκα μοτίβα, αλλά ταυτόχρονα αυξάνει την υπολογιστική πολυπλοκότητα και τον κίνδυνο υπερπροσαρμογή (overfitting). Επομένως, η επιλογή του κατάλληλου αριθμού κρυφών στρωμάτων και νευρώνων απαιτεί προσεκτική εξισορρόπηση μεταξύ της ικανότητας του Δικτύου να γενικεύει και της αποφυγής υπερβολικής προσαρμογής στα δεδομένα εκπαίδευσης [\[27\]](#).

Ο **ρυθμός μάθησης** (learning rate) αποτελεί βασική παράμετρο κατά την εκπαίδευση Νευρωνικών Δικτύων, καθώς καθορίζει το μέγεθος των αλλαγών που εφαρμόζονται στα βάρη του Δικτύου σε κάθε βήμα της διαδικασίας βελτιστοποίησης. Εάν η τιμή του learning rate είναι υπερβολικά υψηλή, το μοντέλο μπορεί να μην συγκλίνει και να παρουσιάσει αστάθεια. Αντίθετα, μια πολύ χαμηλή τιμή μπορεί να επιβραδύνει την εκπαίδευση ή να αφήσει το Δίκτυο σε ανεπιθύμητα τοπικά ελάχιστα. Η σωστή ρύθμιση του learning rate είναι ουσιώδης για την αποτελεσματικότητα και την ταχύτητα εκπαίδευσης [\[28\]](#).

Ο αριθμός των **εποχών** (epochs) αναφέρεται στον αριθμό των πλήρων περασμάτων που κάνει το Νευρωνικό Δίκτυο μέσα από το σύνολο δεδομένων εκπαίδευσης. Ένας υπερβολικά μεγάλος αριθμός εποχών μπορεί να οδηγήσει σε υπερπροσαρμογή, καθώς το μοντέλο αρχίζει

να απομνημονεύει τα δεδομένα αντί να γενικεύει. Αντίθετα, λίγες εποχές ενδέχεται να αφήσουν το μοντέλο υποεκπαιδευμένο, περιορίζοντας την απόδοσή του. Η επιλογή του κατάλληλου αριθμού εποχών απαιτεί συχνά πειραματισμό και παρακολούθηση της απόδοσης [29].

Η **συνάρτηση ενεργοποίησης** (activation function) είναι ένα κρίσιμο στοιχείο των Νευρωνικών Δικτύων, καθώς εισάγει μη γραμμικότητα, επιτρέποντας στο μοντέλο να μάθει σύνθετα μοτίβα και σχέσεις στα δεδομένα. Χωρίς αυτήν, το Δίκτυο θα περιοριζόταν σε γραμμικούς μετασχηματισμούς, μειώνοντας σημαντικά τη δυνατότητά του να επιλύει περίπλοκα προβλήματα. Κάθε συνάρτηση ενεργοποίησης έχει τα πλεονεκτήματα και τις αδυναμίες της, με τις πιο κοινές να περιλαμβάνουν τις ReLU, Sigmoid και Tanh. Η επιλογή της κατάλληλης συνάρτησης εξαρτάται από την αρχιτεκτονική του μοντέλου και τη φύση του προβλήματος [30].

Το μέγεθος του **batch** (batch size) αναφέρεται στον αριθμό των παραδειγμάτων που χρησιμοποιούνται σε κάθε βήμα εκπαίδευσης του Νευρωνικού Δικτύου, πριν γίνει ενημέρωση των βαρών. Ένα μικρό batch size συνήθως οδηγεί σε πιο συχνές ενημερώσεις των βαρών, αλλά μπορεί να προκαλέσει μεγαλύτερη αστάθεια και θόρυβο στην εκπαίδευση. Αντίθετα, μεγαλύτερα batch sizes συνήθως προσφέρουν πιο ακριβείς εκτιμήσεις των παραγώγων και πιο σταθερές ενημερώσεις, αλλά απαιτούν περισσότερο χρόνο υπολογισμού και περισσότερη μνήμη. Η σωστή επιλογή του batch size εξαρτάται από τον διαθέσιμο υπολογιστικό πόρο και τις απαιτήσεις του προβλήματος [31].

Η **κανονικοποίηση** (normalization) είναι μια διαδικασία που χρησιμοποιείται για να προσαρμόσει τα δεδομένα εισόδου ώστε να έχουν κοινά χαρακτηριστικά, όπως την ίδια κλίμακα ή κατανομή. Αυτή η τεχνική βοηθά το Νευρωνικό Δίκτυο να συγκλίνει πιο γρήγορα και να αποφεύγει τη διακύμανση των τιμών των παραμέτρων, η οποία μπορεί να επηρεάσει αρνητικά τη διαδικασία εκπαίδευσης. Οι πιο κοινές μέθοδοι κανονικοποίησης περιλαμβάνουν τη χαρακτηριστική κανονικοποίηση (feature scaling) και την κανονικοποίηση κατά στρώματα (batch normalization). Ανάλογα με το είδος του προβλήματος και την αρχιτεκτονική του μοντέλου, μπορεί να βελτιώσει την απόδοση και τη σταθερότητα του Δικτύου [32].


Έπειτα, έρχεται το **επίπεδο εξόδου**, στο οποίο παράγονται οι τελικές προβλέψεις του συστήματος, με χρήση των πληροφοριών που επεξεργάστηκαν στα κρυφά επίπεδα. Αντίστοιχα, ο αριθμός νευρώνων στο επίπεδο εξόδου εξαρτάται από τη φύση του προβλήματος. Για προβλήματα δυαδικής ταξινόμησης ακόμη και ένας νευρώνας είναι αρκετός, αφού θα επιστρέφει την πιθανότητα του ανήκειν σε μία από τις δύο κατηγορίες. Σε περιπτώσεις

ταξινόμησης πολλαπλών κλάσεων, ο αριθμός των νευρώνων θα ισούται με τον αριθμό των κλάσεων και κάθε νευρώνας αποδίδει την πιθανότητα για τη συγκεκριμένη κατηγορία. Στα προβλήματα παλινδρόμησης, χρησιμοποιείται ένας νευρώνας που παρέχει μια συνεχή τιμή, επιτρέποντας την πρόβλεψη ποσοτικών δεδομένων.

Τα πολυεπίπεδα Νευρωνικά Δίκτυα, είναι ευρέως διαδεδομένα σε ποικιλία τομέων, όπως η υγειονομική περίθαλψη, η χρηματοπιστωτική ανάλυση και οι μεταφράσεις κειμένου. Ένα από τα κύρια πλεονεκτήματα τους είναι η δυνατότητα να μαθαίνουν από μεγάλα σύνολα δεδομένων, κάνοντας τα ιδιαίτερα σημαντικά σε περιβάλλοντα όπου η διαθέσιμη πληροφορία είναι πλούσια και σύνθετη. Ολοκληρώνοντας, τα MLP προσφέρουν μια πλατφόρμα κατάλληλη για την αντιμετώπιση των ζητούμενων μηχανικής μάθησης, με τη δομή και τη λειτουργία τους να πιστοποιούν την ευελιξία και την απόδοση που απαιτείται από τις σύγχρονες εφαρμογές.

2.4.3. CNN

Τα Συνελικτικά Νευρωνικά Δίκτυα (Convolutional Neural Networks, CNNs) αποτελούν έναν από τους πιο αναπτυσσόμενους τύπους deep νευρωνικών δικτύων, έχοντας σχεδιαστεί με σκοπό να επεξεργάζονται δεδομένα με χωρική ή χρονική συσχέτιση [\[33\]](#). Αρχικά, έγιναν γνωστά στην επεξεργασία εικόνας, αλλά η ευελιξία που διαθέτουν τους έχει επιτρέψει τη χρήση τους σε πολλούς άλλους κλάδους, όπως η ανάλυση φυσικής γλώσσας, η βιοϊατρική και η αναγνώριση ομιλίας [\[34\]](#).



Τυπικό Convolution Neural Network

Θεμελιώδη Στοιχεία CNNs

Στον πυρήνα των CNNs βρίσκονται τα συνελκτικά φίλτρα, τα οποία είναι υπεύθυνα να εκτελούν την μαθηματική πράξη του convolution. Αυτή η πράξη, δίνει τη δυνατότητα να εξαγονται τοπικά χαρακτηριστικά, όπως ακμές, γωνίες ή και σύνθετες μορφολογικές δομές γενικότερα. Μέσω weight sharing, προσφέρει το πλεονέκτημα σημαντικής μείωσης του αριθμού των παραμέτρων σε σχέση με τα παραδοσιακά και πλήρως συνδεδεμένα Δίκτυα. Έτσι, κατορθώνει να βελτιώσει την απόδοση ενώ παράλληλα μειώνει την πιθανότητα overfitting [35].

Ένα τυπικό CNN περιέχει μέσα συνελκτικά στρώματα αλλά και pooling layers. Συγκεκριμένα, ένα pooling layer σε ένα Δίκτυο, είναι ένα επίπεδο που χρησιμοποιείται για τη μείωση των διαστάσεων των δεδομένων εξόδου από τις συνελκτικές στρώσεις, διατηρώντας ταυτόχρονα τις σημαντικότερες πληροφορίες. Βασική του λειτουργία του είναι να ελαχιστοποιεί την πολυπλοκότητα του μοντέλου και να βελτιώνει την αποδοτικότητα του υπολογισμού.

Υπάρχουν δύο κύριοι τύποι pooling:

1. **Max Pooling** (Μέγιστη Συγκέντρωση):

Στην περίπτωση αυτή, το pooling επίπεδο επιλέγει την μέγιστη τιμή από κάθε περιοχή του feature map. Αυτό βοηθά στο να εντοπίζονται τα πιο έντονα χαρακτηριστικά.

2. **Average Pooling** (Μέση Συγκέντρωση):

Εδώ υπολογίζεται ο μέσος όρος των τιμών από κάθε περιοχή του feature map, κάτι που μπορεί να είναι χρήσιμο όταν θέλουμε να διατηρήσουμε περισσότερες πληροφορίες.

Μία άλλη τεχνική που χρησιμοποιείται κατά κόρον στα CNN είναι το **Batch Normalization**. Ουσιαστικά κανονικοποιεί τα δεδομένα εξόδου κάθε στρώσης, προσδίδοντας σταθερότητα στην εκπαίδευση. Μετά την κανονικοποίηση, εφαρμόζονται δύο παραμετρικοί όροι που υποβοηθούν το Δίκτυο να προσαρμοστεί στην αναπαράσταση των δεδομένων. Αυτό επιταχύνει την εκπαίδευση, περιορίζει το overfitting και μετατρέπει το μοντέλο σε λιγότερο ευαίσθητο ως προς την αρχικοποίηση των βαρών και τις αλλαγές των παραμέτρων.

Σε μεγαλύτερο βάθος ανάλυση:


Οι παραλλαγές των CNNs, όπως τα ResNets (Residual Networks), εισήγαγαν skip connections, τα οποία διευκολύνουν τη ροή των γραφημάτων υπολογισμού και αντιμετωπίζουν το vanishing gradient problem. Άλλες βελτιώσεις περιλαμβάνουν τα Dilated Convolutions, τα οποία αυξάνουν το αντιληπτικό πεδίο (receptive field) χωρίς αύξηση του αριθμού παραμέτρων, και τα Strided Convolutions, τα οποία αντικαθιστούν το pooling για μείωση της διάστασης [\[36\]](#).

Η χρήση ενεργοποιήσεων όπως η ReLU (Rectified Linear Unit) ενισχύει τη μη γραμμικότητα, ενώ οι τεχνικές κανονικοποίησης, όπως το dropout και το L2 regularization, μειώνουν την υπερεκπαίδευση σημαντικά.

Τα CNNs συνεχίζουν να εξελίσσονται, με μοντέλα όπως τα Vision Transformers (ViTs) να προσφέρουν νέες προσεγγίσεις που ενσωματώνουν τα πλεονεκτήματα του (self-attention) στη συνελκτική αρχιτεκτονική [\[36\]](#).

2.4.4. GNN

Μέσω των CNNs γίνονται πιο εύκολα αντιληπτά και τα GNNs (Graph Neural Networks) μιας και μοιράζονται κοινές αρχές. Και τα δύο βασίζονται στην έννοια της τοπικής συσσώρευσης πληροφορίας από τους γείτονες τους. Στα GNNs ωστόσο, η συσσώρευση αυτή γίνεται σε γράφους που αποτελούνται από κόμβους (nodes) και ακμές (edges), που αναπαριστούν αντικείμενα και τις σχέσεις τους αντίστοιχα. Έχουν εφαρμογές σε πλήθος πεδίων όπως η κοινωνική δικτύωση, η διασπορά των fake news και τα Δίκτυα υποδομών [37].



Περιγραφή λειτουργίας ενός GNN

Βασικά Στοιχεία

Η τυπική λειτουργία ενός GNN περιλαμβάνει τρία στάδια:

1. **Message Passing:** Οι κόμβοι ανταλλάσσουν πληροφορίες μέσω των ακμών.
2. **Aggregation:** Οι πληροφορίες συνδυάζονται, συχνά με χρήση συναρτήσεων όπως το μέσο όρο ή το μέγιστο.

3. **Update:** Τα χαρακτηριστικά κάθε κόμβου ενημερώνονται χρησιμοποιώντας νευρωνικές λειτουργίες.

Τεχνικές Λεπτομέρειες

Μία από τις βασικές τεχνικές στις GNNs είναι η χρήση των Convolutional Graph Networks (GCNs), όπου εφαρμόζονται φίλτρα convolution σε γράφους. Άλλες παραλλαγές περιλαμβάνουν τα Graph Attention Networks (GATs), που χρησιμοποιούν μηχανισμούς προσοχής για να δίνουν μεγαλύτερη βαρύτητα σε σημαντικούς γείτονες και προσαρμόζουν το μοντέλο τους γύρω από αυτό [\[38\]](#).

Εφαρμογές

Οι GNNs έχουν βρει εφαρμογή σε:

- **Προβλήματα πρόβλεψης στις κοινωνικές επιστήμες**, όπως η πρόβλεψη επιρροής.
- **Ανάλυση βιολογικών δικτύων**, π.χ., πρόβλεψη ιδιοτήτων πρωτεϊνών.
- **Συστήματα συστάσεων** σε πλατφόρμες όπως το Netflix, το Amazon.
- **Ενίσχυση ασφάλειας δικτύων** μέσω ανίχνευσης απειλών.

Περιορισμοί και Προκλήσεις

Παρά τις επιτυχίες τους, οι GNNs έχουν ορισμένους περιορισμούς [\[39\]](#). Η κλιμάκωση σε μεγάλα γράφους αποτελεί πρόκληση, καθώς αυξάνεται ο υπολογιστικός φόρτος. Ο χρόνος που θα πάρει σε ένα μοντέλο για να διεκπεραιωθεί είναι πολύ μεγαλύτερος από ένα Νευρωνικό Δίκτυο. Επίσης, η υπερπροσαρμογή σε μικρά σύνολα δεδομένων μπορεί να μειώσει την απόδοση [\[40\]](#).

2.5. Το μοντέλο GCN

2.5.1. Εισαγωγή

Στα πλαίσια της παρούσας διπλωματικής εργασίας, μελετήθηκε με βάση τη βιβλιογραφία [50] το Graph Convolutional Network (GCN), ένα εξειδικευμένο αρχιτεκτονικό μοντέλο νευρωνικής δικτύωσης που έχει σχεδιαστεί για την επεξεργασία και την ανάλυση δεδομένων σε γραφικές δομές. Ουσιαστικά, πρόκειται για ένα Νευρωνικό Δίκτυο που τροποποιεί τα παραδοσιακά Convolutional Networks, ώστε να μπορούν να λειτουργούν σε δεδομένα που απεικονίζονται ως γραφήματα. Σε αντίθεση με τις κλασικές προβλέψεις, τα GCNs αξιοποιούν τις δομικές πληροφορίες που παρέχονται από το γραφικό υπόβαθρο, ενσωματώνοντας την έννοια των κόμβων (nodes) και των ακμών (edges).

2.5.2. GCN Layers Forward

Το βασικό στοιχείο ενός GCN είναι τα layers που εκτελούν τη λειτουργία forward, δηλαδή την εξαγωγή χαρακτηριστικών (features) από τους κόμβους του γραφήματος [51]. Ένα typical GCN layer μπορεί να αναπαρασταθεί ως εξής:

$$H^{(l+1)} = \sigma \left(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H^{(l)} W^{(l)} \right)$$

Η συνάρτηση του GCN

Όπου:

- $\tilde{A}$ είναι το προσαρμοσμένο adjacent matrix που περιλαμβάνει τη δομή του γραφήματος,
- $\tilde{D}$ είναι ο κατασκευαστής του D matrix που περιέχει τους βαθμούς των κόμβων (διαγώνια ματριξ των γραμμών συνοχής)
- $H^{(l)}$ είναι το χαρακτηριστικό matrix για τους κόμβους στην l-th layer
- $W^{(l)}$ είναι τα βάρη του layer
- σ είναι μια μη γραμμική συνάρτηση, όπως ReLU (Rectified Linear Unit).

2.5.3. Input Features και Edge Attributes

Τα χαρακτηριστικά εισόδου (input features) των κόμβων είναι συνήθως αριθμητικά δεδομένα που περιγράφουν τη φυσική ή άλλου είδους κατάσταση ενός κόμβου, όπως το φορτίο, την τάση ή άλλες ηλεκτρικές παραμέτρους. Τα edge attributes είναι οι πληροφορίες που περιέχουν οι ακμές και μπορεί να αφορούν φυσικά χαρακτηριστικά μεταξύ των κόμβων, όπως τις γραμμές μεταφοράς ηλεκτρικής ενέργειας, την αντίσταση, ή την επιρροή του ενός κόμβου στον άλλο.

Στον τομέα της πρόβλεψης δεδομένων μέσω GCNs, οι πληροφορίες αυτές παίζουν καθοριστικό ρόλο. Τα χαρακτηριστικά εισόδου επηρεάζουν άμεσα την αρχική απόδοση του Δικτύου, ενώ οι πληροφορίες των ακμών διαμορφώνουν τις σχέσεις μεταξύ των κόμβων, προσδιορίζοντας πώς επηρεάζει ένας κόμβος έναν άλλο σε κάθε ενδιάμεσο στάδιο εκπαίδευσης του μοντέλου [\[52\]](#).

2.5.4. MAPE και MAE ως δείκτες απόδοσης

Για την αξιολόγηση της απόδοσης ενός GCN, χρησιμοποιούνται δύο βασικοί δείκτες:

2.5.4.1 Mean Absolute Percentage Error (MAPE)

Ο υπολογίζεται

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right|$$

MAPE

χρησιμοποιώντας τη σχέση:

Ο τύπος του MAPE

Όπου:

- Y_i είναι το πραγματικό δεδομένο,
- $\hat{Y}_i$ είναι η πρόβλεψη του GCN για το δεδομένο

2.5.4.2. Mean Absolute Error (MAE)

Ο MAE υπολογίζεται χρησιμοποιώντας τη σχέση:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |x_i - x|$$

Ο τύπος του MAE

Οι δύο αυτοί δείκτες είναι κρίσιμοι στην αξιολόγηση της ακρίβειας ενός GCN, καθώς αποτυπώνουν τη συνολική απόκλιση των προβλέψεων σε σύγκριση με τις πραγματικές τιμές.

Για την ακριβή αξιολόγηση της ακρίβειας σε σχέση με την αναγνώριση τοπολογίας στο πλαίσιο των Graph Convolutional Networks (GCN), είναι σημαντικό να εξετάσουμε πώς η τοπολογική πληροφορία επηρεάζει την απόδοση του μοντέλου. Η τοπολογία ενός γραφήματος περιλαμβάνει τη δομή των κόμβων και των ακμών, και είναι κρίσιμη για τη σωστή κατανόηση των δεδομένων γραφικών.

2.5.5. Accuracy σε σχέση με Topology Identification

Η ακρίβεια στην αναγνώριση τοπολογίας με GCN βασίζεται στην ικανότητα του μοντέλου να αναγνωρίζει σωστά τη δομή του γραφήματος (π.χ., τη σύνδεση μεταξύ κόμβων) και να προβλέπει τα χαρακτηριστικά τους [53]. Η τοπολογία ενός γραφήματος μπορεί να προσδιορίσει την αλληλεπίδραση μεταξύ των κόμβων και να επηρεάσει την απόδοση των προβλέψεων, όπως οι τάσεις, οι φορτίσεις, ή άλλες χαρακτηριστικές τιμές [54].

Για να αξιολογήσουμε αυτήν την ακρίβεια, χρησιμοποιούνται συνήθως δείκτες όπως:

- **Accuracy:** Ποσοστό των σωστών προβλέψεων σε σχέση με το σύνολο των προβλέψεων.
- **Precision:** Πόσες από τις προβλέψεις είναι σωστές σε σχέση με το σύνολο των πραγματικών θετικών αποτελεσμάτων.
- **Recall:** Πόσες από τις πραγματικά θετικές τιμές έχουν προβλεφθεί σωστά.
- **F1-score:** Μέσος όρος της Precision και της Recall.

3. Ορισμός προβλήματος

Η εκτίμηση κατάστασης και η ανίχνευση τοπολογίας αποτελούν κρίσιμα ζητήματα στα σύγχρονα συστήματα ισχύος, ιδίως καθώς η πολυπλοκότητα των δικτύων αυξάνεται. Αυτές οι τεχνικές προσφέρουν ουσιαστικές πληροφορίες για τη λειτουργία και τη διαχείριση των συστημάτων, βελτιώνοντας την αξιοπιστία και τη σταθερότητα.

3.1. Εκτίμηση Κατάστασης

Η εκτίμηση κατάστασης αφορά την ανακατασκευή των πραγματικών καταστάσεων ενός Δικτύου (όπως τάσεις και γωνίες φάσεων) βάσει μετρήσεων που συχνά είναι περιορισμένες, θορυβώδεις ή ελλιπείς. Με τη χρήση δεδομένων από μετρητές PMUs (Phasor Measurement Units), SCADA (Supervisory Control and Data Acquisition) και άλλα συστήματα, οι μέθοδοι εκτίμησης κατάστασης προσπαθούν να εξαγάγουν μια συνεπή εικόνα του Δικτύου. Ταυτόχρονα, η ανίχνευση τοπολογίας επικεντρώνεται στον εντοπισμό της διαμόρφωσης του Δικτύου, όπως οι καταστάσεις των διακοπών ή η σύνδεση συγκεκριμένων στοιχείων [41].

Παραδοσιακά, η εκτίμηση κατάστασης βασίζεται σε αλγορίθμους όπως η μέθοδος **ελαχίστων τετραγώνων (Least Squares)** ή οι επαναληπτικές μέθοδοι όπως η **Gauss-Newton**. Ωστόσο, καθώς τα Δίκτυα γίνονται μεγαλύτερα και πιο δυναμικά, οι προσεγγίσεις αυτές αντιμετωπίζουν προκλήσεις όσον αφορά την κλιμάκωση, την ευρωστία και την ταχύτητα [42]. Επιπλέον, οι μέθοδοι αυτές εξαρτώνται σε μεγάλο βαθμό από ακριβή μοντέλα δικτύου, τα οποία μπορεί να μην είναι πάντα διαθέσιμα [43].

Η είσοδος των τεχνικών μηχανικής μάθησης και ειδικότερα των Νευρωνικών Δικτύων (NN) έχει επιφέρει σημαντικές εξελίξεις [44] [45]. Τα NN μπορούν να μάθουν από δεδομένα, προσφέροντας πιο προσαρμοστικές και λιγότερο εξαρτημένες από τα μοντέλα λύσεις. Στα πλαίσια της εκτίμησης κατάστασης, τα NN χρησιμοποιούνται για την πρόβλεψη τιμών τάσης και γωνίας φάσεων από μετρήσεις εισόδου. Η ευελιξία τους επιτρέπει την αντιμετώπιση μη γραμμικών και θορυβωδών δεδομένων, ενώ η δυνατότητα μαζικής παράλληλης επεξεργασίας τα καθιστά ιδανικά για μεγάλα Δίκτυα.

Μια πιο πρόσφατη εξέλιξη είναι η εφαρμογή Γραφικών Νευρωνικών Δικτύων (Graph Neural Networks - GNNs) στα ενεργειακά συστήματα. Τα GNNs είναι ιδιαίτερα κατάλληλα για προβλήματα όπως η εκτίμηση κατάστασης και η ανίχνευση τοπολογίας, καθώς τα συστήματα ισχύος μπορούν να αναπαρασταθούν ως γράφοι. Στους γράφους αυτούς, οι κόμβοι αντιστοιχούν σε υποσταθμούς ή λεωφορεία, ενώ οι ακμές αναπαριστούν τις γραμμές μεταφοράς. Τα GNNs εκμεταλλεύονται τη δομή του γράφου για να μάθουν πλούσιες αναπαραστάσεις, λαμβάνοντας υπόψη τις σχέσεις μεταξύ των κόμβων και των ακμών.

3.1.1. Βιβλιογραφική Ανασκόπηση

Η βιβλιογραφία έχει δείξει ότι τα GNNs μπορούν να ξεπεράσουν τις παραδοσιακές μεθόδους και τα κλασικά NN σε πολλές περιπτώσεις. Εργασίες επισημαίνουν την ανωτερότητα των GNNs όσον αφορά την ακρίβεια, την ανθεκτικότητα στον θόρυβο και τη δυνατότητα γενίκευσης σε μη μετρημένους κόμβους ή νέες τοπολογίες. Επιπλέον, τα GNNs μπορούν να ενσωματώσουν φυσικούς περιορισμούς και νόμους, όπως η εξίσωση ροής ισχύος, κάτι που ενισχύει τη φυσική ερμηνεία των αποτελεσμάτων τους [46].

3.2. Ανίχνευση Τοπολογίας

Η ανίχνευση τοπολογίας μέσω GNNs είναι επίσης ένα ανερχόμενο πεδίο. Τα μοντέλα αυτά μπορούν να εντοπίσουν αλλαγές στη διαμόρφωση του Δικτύου, όπως την ενεργοποίηση

ή απενεργοποίηση γραμμών μεταφοράς, βασιζόμενα στις αλλαγές που παρατηρούνται στις μετρήσεις [47]. Το γεγονός ότι τα GNNs εκμεταλλεύονται τόσο τα τοπολογικά όσο και τα αριθμητικά χαρακτηριστικά του συστήματος προσφέρει έναν σαφή πλεονέκτημα έναντι άλλων μεθόδων.

Παρά τα πλεονεκτήματά τους, υπάρχουν προκλήσεις στην εφαρμογή των GNNs στα συστήματα ισχύος. Η συλλογή επαρκών και ποιοτικών δεδομένων για την εκπαίδευση, καθώς και η ανάπτυξη αρχιτεκτονικών που να κλιμακώνονται σε εξαιρετικά μεγάλα Δίκτυα, αποτελούν κρίσιμα ζητήματα. Επιπλέον, η ερμηνεία των αποτελεσμάτων παραμένει πρόκληση, αν και οι νέες μέθοδοι ενσωμάτωσης φυσικών νόμων προσφέρουν υποσχέσεις προς αυτή την κατεύθυνση.


Η σύγκριση μεταξύ NN και GNN δείχνει ότι τα GNNs είναι συχνά πιο κατάλληλα για προβλήματα όπου η τοπολογία παίζει κεντρικό ρόλο. Ενώ τα NN είναι ισχυρά για την πρόβλεψη τιμών βάσει εισόδων, τα GNNs εκμεταλλεύονται τη δομή του γράφου για να προσφέρουν πιο εμπλουτισμένες αναπαραστάσεις. Ωστόσο, η επιλογή της κατάλληλης τεχνικής εξαρτάται από τη φύση του προβλήματος, τα διαθέσιμα δεδομένα και την υπολογιστική ισχύ [48] [49].

4. Δημιουργία Συνόλου δεδομένων

4.1. IEEE 33 Bus System

Για την διεξαγωγή των προσομοιώσεων θα χρησιμοποιηθεί το Δίκτυο διανομής 33 ζυγών **IEEE 33 Bus Distribution Network** αποτελώντας ένα ευέλικτο πρότυπο για μελέτη διαφορετικών τοπολογιών και διαμορφώσεων. Θα υπάρξουν 14 παραλλαγές του αρχικού Δικτύου με αποτέλεσμα σύνολο οι τοπολογίες να φτάνουν τις 15 με την αρχική. Η κλασσική τοπολογία περιλαμβάνει την προσθήκη συνδέσεων όπως η σύνδεση μεταξύ των ζυγών 3-23, 6-26 και 2-19. Οι συνδέσεις αυτές δημιουργούν εναλλακτικές διαδρομές για τη ροή ισχύος, μειώνοντας τις απώλειες και ενισχύοντας την φερεγγυότητα. Η τροποποίηση της τοπολογίας μέσω ανοιγμάτων και κλεισμάτων γραμμών είναι χρήσιμη για την προσομοίωση

συνθηκών λειτουργίας με υψηλή διείσδυση ανανεώσιμων πηγών ενέργειας ή την ανάκτηση του Δικτύου μετά από βλάβες [55].



Οι τρεις επιπλέον γραμμές που επιλέχθηκαν είναι οι 21-8, 12-22 και 25-29 με σκοπό να επιτρέπονται νέες διαδρομές για την ισχύ που υποβοηθούν τη σταθερότητα. Η μελέτη διαφορετικών τοπολογιών σε αυτό το Δίκτυο παρέχει πολύτιμες πληροφορίες για τη βελτιστοποίηση της απόδοσης, τη μείωση των απωλειών, και τη διαχείριση φορτίων σε πραγματικά Δίκτυα διανομής.

IEEE 33-Bus Distribution Network

4.2. MATLAB

Για την παραγωγή των δεδομένων που θα χρειαστούν έγινε χρήση του λογισμικού MATLAB. Το MATLAB είναι ένα ευρέως χρησιμοποιούμενο εργαλείο για τη μοντελοποίηση,

ανάλυση και επίλυση σύνθετων προβλημάτων σε επιστημονικούς και τεχνολογικούς τομείς. Στον τομέα των δικτύων διανομής ηλεκτρικής ενέργειας, συνδυάζεται συχνά με εξειδικευμένες βιβλιοθήκες, όπως η MATPOWER, για την παραγωγή δεδομένων και την εκτέλεση αναλύσεων power flow. Αυτά τα δεδομένα χρησιμοποιούνται σε διάφορες εφαρμογές, συμπεριλαμβανομένων των Νευρωνικών Δικτύων, για την επίλυση προβλημάτων όπως η πρόβλεψη και η βελτιστοποίηση της λειτουργίας του Δικτύου.

4.2.1. MATPOWER: Επισκόπηση και Εφαρμογές

Η MATPOWER είναι μια ισχυρή βιβλιοθήκη ανοιχτού κώδικα, σχεδιασμένη για τη παραγωγή μοντέλων και ανάλυση συστημάτων ηλεκτρικής ισχύος. Πρόκειται για ένα λογισμικό που χρησιμοποιείται κυρίως για την εκτέλεση προσομοιώσεων steady-state power flow, optimal power flow (OPF) και άλλων σχετικών αναλύσεων. Το MATPOWER είναι γραμμένο σε MATLAB, καθιστώντας το εύκολα ενσωματώσιμο στο ευρύτερο οικοσύστημα του MATLAB. Είναι ιδιαίτερα δημοφιλές στην ακαδημαϊκή έρευνα λόγω της ευκολίας χρήσης του, της τεκμηρίωσής του και της δυνατότητας προσαρμογής του στις ανάγκες του χρήστη [\[56\]](#).

Το MATPOWER περιλαμβάνει διάφορα τυποποιημένα μοντέλα συστημάτων, όπως το case33bw, τα οποία μπορούν να χρησιμοποιηθούν για την προσομοίωση πραγματικών συνθηκών λειτουργίας σε Δίκτυα διανομής. Οι χρήστες μπορούν να εισάγουν δεδομένα για κόμβους (buses), γραμμές (branches) και γεννήτριες, να τροποποιήσουν τις παραμέτρους τους και να εκτελέσουν αναλύσεις για να παράγουν δεδομένα σχετικά με τις τάσεις, τις γωνίες φάσης, τις ροές ισχύος και τα ρεύματα. Τα δεδομένα αυτά αποτελούν τη βάση για περαιτέρω ανάλυση και ανάπτυξη εφαρμογών.

Παραγωγή Dataset με Χρήση MATPOWER

Για την παραγωγή δεδομένων, οι χρήστες μπορούν να δημιουργήσουν πλήρη μοντέλα δικτύων και να εκτελέσουν προσομοιώσεις power flow, χρησιμοποιώντας τις εντολές του MATPOWER, όπως το runpf (για απλές αναλύσεις power flow) και το runopf (για optimal power flow). Αυτές οι λειτουργίες επιστρέφουν δεδομένα που περιλαμβάνουν:

- Τάσεις (magnitudes) και γωνίες φάσης σε κάθε κόμβο.
- Ροές ενεργού (P) και άεργου (Q) ισχύος σε γραμμές και γεννήτριες.

- Ρεύματα στις γραμμές (branch currents) και στους κόμβους (bus currents).

Η δυνατότητα αυτή διευκολύνει τη δημιουργία μεγάλων συνόλων δεδομένων για χρήση σε Νευρωνικά Δίκτυα. Για παράδειγμα, οι χρήστες μπορούν να τρέξουν πολλαπλές προσομοιώσεις, τροποποιώντας παραμέτρους όπως η κατάσταση των γραμμών (branches), οι γεννήτριες ή τα φορτία, και να αποθηκεύσουν τα αποτελέσματα σε αρχεία CSV. Αυτά τα δεδομένα μπορούν να χρησιμοποιηθούν ως εισροές για την εκπαίδευση Νευρωνικών Δικτύων που προβλέπουν, π.χ., τις τιμές τάσεων ή ρευμάτων σε μη παρατηρήσιμους κόμβους.

4.2.2. Χρήση στη Βιβλιογραφία

Η MATPOWER έχει αναφερθεί ευρέως στη βιβλιογραφία ως ένα ευέλικτο εργαλείο για την παραγωγή δεδομένων και την εκτέλεση αναλύσεων power flow. Ένα χαρακτηριστικό παράδειγμα είναι η χρήση της σε έρευνες για την πρόβλεψη της κατάστασης συστημάτων ισχύος μέσω μηχανικής μάθησης. Οι επιστήμονες χρησιμοποιούν τη MATPOWER για να παράγουν μεγάλα datasets, μεταβάλλοντας δυναμικά παραμέτρους όπως το φορτίο, η γεννήτρια και η κατάσταση των γραμμών, και στη συνέχεια εφαρμόζουν τεχνικές τεχνητής νοημοσύνης για ανάλυση.

Ένα δημοφιλές μοντέλο που χρησιμοποιείται στη βιβλιογραφία είναι το radial distribution network case33bw, το οποίο έχει 33 κόμβους και 35 γραμμές. Το συγκεκριμένο μοντέλο παρέχει τη δυνατότητα δημιουργίας πολλών σεναρίων, τροποποιώντας την κατάσταση συγκεκριμένων γραμμών (π.χ., ανοιχτές ή κλειστές) και αναλύοντας πώς αυτές οι αλλαγές επηρεάζουν τις τάσεις και τις ροές ισχύος. Τα αποτελέσματα αποθηκεύονται σε αρχεία για περαιτέρω ανάλυση.

4.3. Συνδυασμός MATLAB και MATPOWER με Νευρωνικά Δίκτυα

Τα δεδομένα που παράγονται από τη MATPOWER μπορούν να χρησιμοποιηθούν για την εκπαίδευση Νευρωνικών Δικτύων, που είναι κατάλληλα για προβλήματα πρόβλεψης και ταξινόμησης σε Δίκτυα διανομής. Χρησιμοποιώντας MATLAB scripts, οι χρήστες μπορούν να

προετοιμάσουν τα δεδομένα για Νευρωνικά Δίκτυα, αφαιρώντας τυχαία δεδομένα από ορισμένους κόμβους και εκπαιδεύοντας το Δίκτυο για να προβλέψει τις τιμές των τάσεων ή των ρευμάτων σε αυτούς τους κόμβους [\[57\]](#).

4.4. Παραγωγή Δεδομένων

4.4.1. Case33bw

Για την παραγωγή των τοπολογιών το Δίκτυο IEEE 33 χρησιμοποιήθηκε μοντέλο της MATLAB μέσω του παραδείγματος «**Case33bw**» που παρέχει η MATPOWER. Το σύστημα αποτελείται από 33 ζυγούς, 35 γραμμές που συνδέουν τους ζυγούς ενώ τα όρια τάσης των ζυγών ορίζονται από 0,9 έως 1,1 (p.u.). Στους παρακάτω πίνακες παρατίθενται τα δεδομένα των ζυγών και των κλάδων του Δικτύου αντίστοιχα.


```

%% bus_data
% bus_i type Pd Qd Gs Bs area Vm Va baseKV zone Vmax Vmin
mpc.bus = [ %% (Pd and Qd are specified in kW & kVAr here, converted to MW & MVar below)
1 3 0 0 0 0 1 1 0 12.66 1 1.1 0.9;
2 1 100 60 0 0 1 1 0 12.66 1 1.1 0.9;
3 1 90 40 0 0 1 1 0 12.66 1 1.1 0.9;
4 1 120 80 0 0 1 1 0 12.66 1 1.1 0.9;
5 1 60 30 0 0 1 1 0 12.66 1 1.1 0.9;
6 1 60 20 0 0 1 1 0 12.66 1 1.1 0.9;
7 1 200 100 0 0 1 1 0 12.66 1 1.1 0.9;
8 1 200 100 0 0 1 1 0 12.66 1 1.1 0.9;
9 1 60 20 0 0 1 1 0 12.66 1 1.1 0.9;
10 1 60 20 0 0 1 1 0 12.66 1 1.1 0.9;
11 1 45 30 0 0 1 1 0 12.66 1 1.1 0.9;
12 1 60 35 0 0 1 1 0 12.66 1 1.1 0.9;
13 1 60 35 0 0 1 1 0 12.66 1 1.1 0.9;
14 1 120 80 0 0 1 1 0 12.66 1 1.1 0.9;
15 1 60 10 0 0 1 1 0 12.66 1 1.1 0.9;
16 1 60 20 0 0 1 1 0 12.66 1 1.1 0.9;
17 1 60 20 0 0 1 1 0 12.66 1 1.1 0.9;
18 1 90 40 0 0 1 1 0 12.66 1 1.1 0.9;
19 1 90 40 0 0 1 1 0 12.66 1 1.1 0.9;
20 1 90 40 0 0 1 1 0 12.66 1 1.1 0.9;
21 1 90 40 0 0 1 1 0 12.66 1 1.1 0.9;
22 1 90 40 0 0 1 1 0 12.66 1 1.1 0.9;
23 1 90 50 0 0 1 1 0 12.66 1 1.1 0.9;
24 1 420 200 0 0 1 1 0 12.66 1 1.1 0.9;
25 1 420 200 0 0 1 1 0 12.66 1 1.1 0.9;
26 1 60 25 0 0 1 1 0 12.66 1 1.1 0.9;
27 1 60 25 0 0 1 1 0 12.66 1 1.1 0.9;
28 1 60 20 0 0 1 1 0 12.66 1 1.1 0.9;
29 1 120 70 0 0 1 1 0 12.66 1 1.1 0.9;
30 1 200 600 0 0 1 1 0 12.66 1 1.1 0.9;
31 1 150 70 0 0 1 1 0 12.66 1 1.1 0.9;
32 1 210 100 0 0 1 1 0 12.66 1 1.1 0.9;
33 1 60 40 0 0 1 1 0 12.66 1 1.1 0.9;
];

```

Tα bas data του case33bw

```

%% branch data
% fbus tbus r x b rateA rateB rateC ratio angle status angmin angmax
mpc.branch = [ %% (r and x specified in ohms here, converted to p.u. below)
1 2 0.000575 0.000298 0.000160275600000000 0 0 0 0 0 1 -360 360
2 3 0.003076 0.001567 0.000160275600000000 0 0 0 0 0 1 -360 360
3 4 0.002284 0.001163 0.000160275600000000 0 0 0 0 0 1 -360 360
4 5 0.002378 0.001211 0.000160275600000000 0 0 0 0 0 1 -360 360
5 6 0.00511 0.004411 0.000160275600000000 0 0 0 0 0 1 -360 360
6 7 0.001168 0.003861 0.000160275600000000 0 0 0 0 0 1 -360 360
7 8 0.004439 0.001467 0.000160275600000000 0 0 0 0 0 1 -360 360
8 9 0.006426 0.004617 0.000160275600000000 0 0 0 0 0 1 -360 360
9 10 0.006514 0.004617 0.000160275600000000 0 0 0 0 0 1 -360 360
10 11 0.001227 0.000406 0.000160275600000000 0 0 0 0 0 1 -360 360
11 12 0.002336 0.000772 0.000160275600000000 0 0 0 0 0 1 -360 360
12 13 0.009159 0.007206 0.000160275600000000 0 0 0 0 0 1 -360 360
13 14 0.003379 0.004448 0.000160275600000000 0 0 0 0 0 1 -360 360
14 15 0.003687 0.003282 0.000160275600000000 0 0 0 0 0 1 -360 360
15 16 0.004656 0.0034 0.000160275600000000 0 0 0 0 0 1 -360 360
16 17 0.008042 0.010738 0.000160275600000000 0 0 0 0 0 1 -360 360
17 18 0.004567 0.003581 0.000160275600000000 0 0 0 0 0 1 -360 360
2 19 0.001023 0.000976 0.000160275600000000 0 0 0 0 0 1 -360 360
19 20 0.009385 0.008457 0.000160275600000000 0 0 0 0 0 1 -360 360
20 21 0.002555 0.002985 0.000160275600000000 0 0 0 0 0 1 -360 360
21 22 0.004423 0.005848 0.000160275600000000 0 0 0 0 0 1 -360 360
3 23 0.002815 0.001924 0.000160275600000000 0 0 0 0 0 1 -360 360
23 24 0.005603 0.004424 0.000160275600000000 0 0 0 0 0 1 -360 360
24 25 0.00559 0.004374 0.000160275600000000 0 0 0 0 0 1 -360 360
6 26 0.001267 0.000645 0.000160275600000000 0 0 0 0 0 1 -360 360
26 27 0.001773 0.000903 0.000160275600000000 0 0 0 0 0 1 -360 360
27 28 0.006607 0.005826 0.000160275600000000 0 0 0 0 0 1 -360 360
28 29 0.005018 0.004371 0.000160275600000000 0 0 0 0 0 1 -360 360
29 30 0.003166 0.001613 0.000160275600000000 0 0 0 0 0 1 -360 360
30 31 0.00608 0.006008 0.000160275600000000 0 0 0 0 0 1 -360 360
31 32 0.001937 0.002258 0.000160275600000000 0 0 0 0 0 1 -360 360
32 33 0.002128 0.003308 0.000160275600000000 0 0 0 0 0 1 -360 360
21 8 0.012479 0.012479 0.000160275600000000 0 0 0 0 0 0 -360 360
12 22 0.012479 0.012479 0.000160275600000000 0 0 0 0 0 0 -360 360
25 29 0.00312 0.00312 0.000160275600000000 0 0 0 0 0 0 -360 360
];

```

Τα branch data του case33bw

4.4.2. Διαφοροποίηση Τοπολογιών

Συγκεκριμένα, για την παραγωγή δεδομένων αυτής της διπλωματικής παράχθηκαν δεκαπέντε διαφορετικές τοπολογίες του IEEE33, οκτώ radial και οκτώ meshed (με το τυπικό

Δίκτυο να είναι διπλό από μία φορά σε κάθε είδος τοπολογίας). Όσον αφορά τις οκτώ radial, έχουμε τους τρεις επιπλέον κλάδους 21-8, 12-22 και 25-29. Ουσιαστικά κάθε κλάδος έχει δύο επιλογές είτε να είναι ανοιχτός είτε κλειστός και εφόσον έχουμε τρεις διαφορετικούς το σύνολο των πιθανών τοπολογιών είναι $2^3 = 8$.

Αντιθέτως για την παραγωγή των οκτώ meshed τοπολογιών, όποτε έκλεινε ένας από τους

```
% Define all possible combinations of status for the last three buses  
status_combinations = [0 0 0; 0 0 1; 0 1 0; 0 1 1; 1 0 0; 1 0 1; 1 1 0; 1 1 1];
```

τρεις κλάδους, άνοιγε ο αντίστοιχος κλάδος του στο αρχικό Δίκτυο (π.χ. αν κλείσει το 12-22 πρέπει να ανοίξει το 11-12).

4.4.3. Τυχαιότητα

Όσον αφορά τα δεδομένα είχαμε τα αρχικά και τα τελικά, η διαφορά τους ήταν η προσθήκη θορύβου και μια προσθήκη τυχαιότητας, προκειμένου να αυξήσουμε την αξιοπιστία τους και να υπάρχει καλύτερος πειραματισμός. Συγκεκριμένα, για κάθε προσομοίωση επιλέγονταν τυχαία μέσω της randi ορισμένοι ζυγοί και αυτοί δέχονταν μια μεταβολή στις τιμές ενεργής και άεργης ισχύς τους με αύξηση ή μείωση μέχρι 10%.

```
% Modify active (P) and reactive (Q) power values  
for i = 1:num_buses_to_modify  
    % Select a random percentage between -10% and +10%  
    percentage_change = (rand() * 20 - 10) / 100; % Random value between -0.1 and +0.1  
  
    % Apply the percentage change to both P and Q  
    old_P = net_sys.bus(bus_indices(i), 3); % Store original P value  
    old_Q = net_sys.bus(bus_indices(i), 4); % Store original Q value  
  
    net_sys.bus(bus_indices(i), 3) = old_P * (1 + percentage_change); % Active power P  
    net_sys.bus(bus_indices(i), 4) = old_Q * (1 + percentage_change); % Reactive power Q  
  
    % Set modification flag  
    modification_flags(bus_indices(i)) = 1; % Mark as changed  
end
```

Όταν επηρεάζονται η ενεργή (P) και η άεργος ισχύς (Q) σε ένα ηλεκτρικό κύκλωμα, οι επιδράσεις στις τάσεις, τις γωνίες τάσης και τα ρεύματα είναι σημαντικές λόγω της αλληλεξάρτησης αυτών των μεγεθών μέσω των εξισώσεων του συστήματος.

Η **τάση (V)** σε ένα σημείο του Δικτύου επηρεάζεται από την άεργο ισχύ (Q). Αύξηση της άεργου ισχύος συχνά προκαλεί μείωση της τάσης στα φορτία λόγω αυξημένων απωλειών ισχύος στο κύκλωμα, ενώ μείωση της άεργου ισχύος τείνει να αυξήσει την τάση. Αντίθετα, η ενεργή ισχύς (P) δεν έχει τόσο άμεση επίδραση στο μέτρο της τάσης, αλλά επηρεάζει τη γωνία της.

Η **γωνία τάσης (δ)** επηρεάζεται κυρίως από την ενεργή ισχύ. Αύξηση της ενεργού ισχύος προκαλεί αύξηση της γωνίας, καθώς το κύκλωμα πρέπει να μεταφέρει περισσότερη ισχύ, κάτι που αυξάνει τη διαφορά φάσης μεταξύ των σημείων του Δικτύου. Η άεργος ισχύς έχει μικρότερη επίδραση στη γωνία τάσης, αλλά οι αλλαγές στη Q μπορεί να επηρεάσουν έμμεσα τη γωνία μέσω των μεταβολών της τάσης.

Τα **ρεύματα (I)** στο κύκλωμα επηρεάζονται και από την ενεργό και από την άεργο ισχύ. Αύξηση της ενεργού ή της άεργου ισχύος αυξάνει το ρεύμα στη γραμμή, καθώς οι απαιτήσεις του φορτίου γίνονται μεγαλύτερες. Το ρεύμα σχετίζεται με την τάση και την ισχύ μέσω της σχέσης $I = S^*/V$, όπου $S = P + jQ$. Έτσι, αλλαγές στην ισχύ οδηγούν σε άμεσες μεταβολές στα ρεύματα, ενώ οι αυξημένες ροές ρεύματος προκαλούν μεγαλύτερες απώλειες στη γραμμή.

Συνολικά, η αλληλεπίδραση μεταξύ της ενεργού και άεργου ισχύος, της τάσης, της γωνίας τάσης και των ρευμάτων καθορίζεται από τις εξισώσεις ροής φορτίου του συστήματος και από τη δυναμική του κυκλώματος.

Απεναντίας, για την ενσωμάτωση θορύβου έγινε προσθήκη ή αφαίρεση της τιμής έως 1% σε σχέση με την αρχική προκειμένου να υπάρχουν πιο ρεαλιστικά αποτελέσματα [58]. Στα πραγματικά συστήματα, τα δεδομένα δεν είναι ποτέ ακριβή λόγω φυσικών παραγόντων, μεταβολών του φορτίου, σφαλμάτων μετρήσεων, ή διακυμάνσεων στην παραγωγή ενέργειας. Η ενσωμάτωση θορύβου προσομοιώνει αυτές τις αβεβαιότητες και βοηθά στη δημιουργία μοντέλων που λειτουργούν αποτελεσματικά ακόμη και κάτω από μη ιδανικές συνθήκες. Επιπλέον, η παρουσία θορύβου επιτρέπει στο μοντέλο να εκπαιδευτεί ώστε να ανταποκρίνεται καλύτερα σε πραγματικά δεδομένα που μπορεί να περιέχουν λάθη ή αβεβαιότητες. Έτσι, το μοντέλο καθίσταται πιο ανθεκτικό, γεγονός που εξασφαλίζει την καλύτερη γενίκευση στις προβλέψεις του.

Επιπλέον, η χρήση θορύβου παρέχει τη δυνατότητα να αξιολογηθεί η ανθεκτικότητα του μοντέλου, καθώς βοηθά στην κατανόηση πώς συμπεριφέρεται το μοντέλο όταν εκτίθεται σε

δεδομένα με περιορισμένη ακρίβεια [59]. Τέλος, με αυτόν τον τρόπο, γίνεται καλύτερη εκτίμηση της ακρίβειας του μοντέλου σε συνθήκες που πλησιάζουν πιο κοντά στη λειτουργία του πραγματικού Δικτύου.

4.4.4. Επιλογή Χαρακτηριστικών

Εκτός από τάση, γωνία τάσης, ενεργό και άεργο ισχύ, παρήχθησαν δεδομένα και για το ρεύμα. Συγκεκριμένα, υπολογίστηκε το ρεύμα στους κλάδους του Δικτύου, δηλαδή το ρεύμα που ρέει από την αρχή ενός κλάδου προς το τέλος του (I_f) και αντίστροφα (I_t), καθώς και το συνολικό ρεύμα που συνδέεται με κάθε κόμβο του Δικτύου (I_{bus}).

Οι υπολογισμοί αυτοί βασίστηκαν στις μήτρες αγωγιμότητας του συστήματος (Y_f , Y_t και Y_{bus}). Το ρεύμα I_f προέκυψε από τη σχέση $I_f = Y_f \cdot V$, όπου V είναι το διάνυσμα τάσης στους κόμβους, ενώ το ρεύμα I_t προέκυψε από τη σχέση $I_t = Y_t \cdot V$. Αντίστοιχα, το I_{bus} υπολογίστηκε από τη σχέση $I_{bus} = Y_{bus} \cdot V$, που εκφράζει τη σύνδεση μεταξύ των τάσεων στους κόμβους και του συνολικού ρεύματος που ρέει από ή προς αυτούς. Αυτά τα δεδομένα είναι εξαιρετικά σημαντικά για την ανάλυση της λειτουργίας του Δικτύου, την εκτίμηση της κατανομής των ρευμάτων και την αξιολόγηση της απόδοσης και της σταθερότητας του συστήματος [60].

4.4.5. Προσομοιώσεις

Τελικά, το μοντέλο της MATLAB παρήγαγε 1000 προσομοιώσεις 16 τοπολογιών δηλαδή σύνολο 16.000 csv αρχεία με δεδομένα. Τα δεδομένα αφορούν τις τιμές τάσης, γωνίας τάσης, I_f , I_t , I_{bus} και ενεργό με άεργο ισχύ. Παράλληλα, κρατήθηκαν τα P,Q που άλλαξαν κατά την διαδικασία της randi ενώ κάθε αρχείο έσπασε στα δύο σε ένα για τους 33 ζυγούς και σε ένα για τους 35 κλάδους. Στη συνέχεια τα αρχεία ενώθηκαν σε ένα μεγάλο dataset αλλά διασπάστηκαν και σε ξεχωριστές τοπολογίες προκειμένου να ερευνηθούν με διάφορους τρόπους.

Name	Date modified	Type	Size
 Topology_1	16/10/2024 10:14	Microsoft Excel W...	2.720 KB
 Topology_2	16/10/2024 09:40	Microsoft Excel W...	2.686 KB
 Topology_3	16/10/2024 09:43	Microsoft Excel W...	2.693 KB
 Topology_4	16/10/2024 09:45	Microsoft Excel W...	2.687 KB
 Topology_5	16/10/2024 09:45	Microsoft Excel W...	2.652 KB
 Topology_6	16/10/2024 09:47	Microsoft Excel W...	2.656 KB
 Topology_7	16/10/2024 09:47	Microsoft Excel W...	2.664 KB
 Topology_8	16/10/2024 09:49	Microsoft Excel W...	2.621 KB
 Topology_10	16/10/2024 10:18	Microsoft Excel W...	2.627 KB
 Topology_11	16/10/2024 09:55	Microsoft Excel W...	2.620 KB
 Topology_12	16/10/2024 09:56	Microsoft Excel W...	2.604 KB
 Topology_13	16/10/2024 09:58	Microsoft Excel W...	2.621 KB
 Topology_14	16/10/2024 09:58	Microsoft Excel W...	2.600 KB
 Topology_15	16/10/2024 09:59	Microsoft Excel W...	2.600 KB
 Topology_16	16/10/2024 10:01	Microsoft Excel W...	2.595 KB

Τα αρχεία κλάδων

 Topology_buses_1	16/10/2024 11:36	Microsoft Excel W...	1.558 KB
 Topology_Buses_2	16/10/2024 11:22	Microsoft Excel W...	1.556 KB
 Topology_Buses_3	16/10/2024 11:23	Microsoft Excel W...	1.559 KB
 Topology_Buses_4	16/10/2024 11:24	Microsoft Excel W...	1.563 KB
 Topology_Buses_5	16/10/2024 11:26	Microsoft Excel W...	1.560 KB
 Topology_Buses_6	16/10/2024 11:27	Microsoft Excel W...	1.562 KB
 Topology_Buses_7	16/10/2024 11:27	Microsoft Excel W...	1.563 KB
 Topology_Buses_8	16/10/2024 11:28	Microsoft Excel W...	1.563 KB
 Topology_buses_10	16/10/2024 11:42	Microsoft Excel W...	1.563 KB
 Topology_Buses_11	16/10/2024 11:30	Microsoft Excel W...	1.558 KB
 Topology_Buses_12	16/10/2024 11:31	Microsoft Excel W...	1.560 KB
 Topology_Buses_13	16/10/2024 11:31	Microsoft Excel W...	1.559 KB
 Topology_Buses_14	16/10/2024 11:32	Microsoft Excel W...	1.564 KB
 Topology_Buses_15	16/10/2024 11:33	Microsoft Excel W...	1.559 KB
 Topology_Buses_16	16/10/2024 11:34	Microsoft Excel W...	1.560 KB

Τα αρχεία ζυγών

5.Υλοποίηση Μοντέλου

5.1. Χρήση Python

Η γλώσσα προγραμματισμού που επιλέχθηκε για τη συνέχεια είναι η Python, μιας και θεωρείται ιδιαίτερα χρήσιμη για τη δημιουργία και εκπαίδευση μοντέλων Νευρωνικών Δικτύων (Neural Networks) καθώς και γραμμικών γνωσιακών δικτύων (Graph Neural Networks, GNN). Η Python προσφέρει ευελιξία, διαθέτοντας μια πλούσια βιβλιοθήκη εργαλείων για την επεξεργασία δεδομένων, την ανάλυση και τη μοντελοποίηση [\[61\]](#). Βιβλιοθήκες όπως το NumPy, το Pandas, το Scikit-learn, το TensorFlow, το PyTorch και το DGL (Deep Graph Library) παρέχουν όλα τα απαραίτητα εργαλεία για την επεξεργασία

δεδομένων από προσομοιώσεις και την προσαρμογή των μοντέλων ώστε να εκτιμηθούν οι τιμές των κρυμμένων σταθμών (hidden buses) [62].

Επιπλέον, η Python είναι ιδανική για σύνθετες υπολογιστικές διεργασίες, ενώ η υποστήριξή της για ανάλυση μεγάλων συνόλων δεδομένων και η δυνατότητα εύκολης ενσωμάτωσης με βάσεις δεδομένων καθιστούν τη γλώσσα την επιλογή πρώτης γραμμής για τέτοιου είδους εργασίες. Στη συγκεκριμένη εργασία, οι απαιτήσεις περιλαμβάνουν την εκπαίδευση μοντέλων που να αναλύουν δεδομένα από διάφορες προσομοιώσεις Δικτύου διανομής, κάτι που καθιστά την Python αναπόσπαστο εργαλείο.

Η χρήση του Visual Studio Code (VS Code) έρχεται ως φυσική συνέχεια της επιλογής της Python. Το VS Code είναι ένα από τα πιο δημοφιλή και ισχυρά περιβάλλοντα ανάπτυξης, παρέχοντας δυνατότητες κωδικοποίησης, debugging, και συνεργασίας σε ομάδα. Η δυνατότητα προσαρμογής μέσω extensions και το ισχυρό Git integration είναι μερικά από τα χαρακτηριστικά που καθιστούν το VS Code ιδανικό για την ανάπτυξη εφαρμογών και την εκτέλεση πειραμάτων [63].

Η ενσωμάτωση του VS Code με την Python προσφέρει ισχυρά εργαλεία για την εκτέλεση και ανάλυση μοντέλων, παρέχοντας αναλυτικά γραφήματα και στατιστικά στοιχεία για τα αποτελέσματα. Επίσης, το ενσωματωμένο terminal και το Jupyter Notebook extension διευκολύνουν την εκτέλεση κώδικα και την άμεση επισκόπηση των αποτελεσμάτων. Αυτές οι δυνατότητες καθιστούν το VS Code την καλύτερη πλατφόρμα ανάπτυξης για το συγκεκριμένο έργο, επιτρέποντας τη δημιουργία, δοκιμή και ανάλυση των μοντέλων Νευρωνικών Δικτύων και GNN σε ένα ενιαίο περιβάλλον.

Python

Η χρήση της Python ξεκίνησε με την ένωση των sets όπως αναφέρθηκε. Η ένωση συνόλων δεδομένων (sets) σε ένα dataset γίνεται μέσω της βιβλιοθήκης pandas. Αρχικά, τα δεδομένα πρέπει να είναι οργανωμένα σε μορφή DataFrame, καθώς αυτός είναι ο βασικός τύπος δεδομένων που χειρίζεται το pandas. Για την ένωση, η συνάρτηση merge επιτρέπει την ένωση δεδομένων με βάση κοινές στήλες ή κλειδιά, που λειτουργεί παρόμοια με ένα SQL join. Η join χρησιμοποιείται ειδικά για την ένωση δεδομένων με βάση το index. Τέλος, πριν την ένωση ελέγχτηκε η συνέπεια των δεδομένων (π.χ., ταιριαστές στήλες ή indexes). Αυτή η διαδικασία βοηθά στην ενσωμάτωση διαφορετικών πηγών δεδομένων σε ένα ενιαίο dataset για ανάλυση [64]. Έπειτα, έχοντας έτοιμα τα datasets υπήρχε η δυνατότητα να προχωρήσουμε στη

διαδικασία του state estimation (SE). Το πρώτο πράγμα που έπρεπε να γίνει είναι ένα pre data processing, ώστε να γίνουν οι ετοιμασίες για το μοντέλο

5.2. Feature Selection στα δεδομένα

Το **Feature Selection** σε ένα Δίκτυο διανομής είναι μια κρίσιμη διαδικασία για τη μείωση της πολυπλοκότητας των δεδομένων και τη βελτίωση της ακρίβειας των μοντέλων πρόβλεψης. Στην περίπτωση του Δικτύου διανομής που χρησιμοποιήσαμε επιλέχθηκαν χαρακτηριστικά όπως η **τελική τάση (V)** και **γωνία τάσης (δ)** μετά από θόρυβο, η **αρχική τάση (V)** και **γωνία τάσης (δ)** και το τελικό πραγματικό και φανταστικό μέρος του **ρεύματος** στον κλάδο (**If**). Η διαδικασία επιλογής χαρακτηριστικών διασφαλίζει ότι χρησιμοποιούνται μόνο οι πιο σχετικές παράμετροι για την ανάλυση. Η τελική τάση και η γωνία είναι βασικές μεταβλητές που αντικατοπτρίζουν την κατάσταση του συστήματος υπό κανονικές ή διαταραγμένες συνθήκες λειτουργίας, ενώ η αρχική τάση παρέχει μια βασική αναφορά για τις αλλαγές που έχουν προκύψει. Το πραγματικό και το φανταστικό μέρος του ρεύματος στον κλάδο If είναι σημαντικά για την κατανόηση της κατανομής των ροών ισχύος και των απωλειών στο Δίκτυο.

Με τον συνδυασμό αυτών των χαρακτηριστικών, το μοντέλο μπορεί να εκπαιδευτεί ώστε να προβλέπει κρίσιμες μεταβολές ή αποκλίσεις στο Δίκτυο με υψηλή ακρίβεια. Η διαδικασία επιλογής αυτών των χαρακτηριστικών περιλαμβάνει την αποτίμηση της συσχέτισής τους με την έξοδο του μοντέλου και την εξάλειψη χαρακτηριστικών που είναι είτε πλεονασματικά είτε άσχετα, όπως δεδομένα που επηρεάζονται υπερβολικά από θόρυβο ή δεν προσφέρουν επιπλέον πληροφορία. Επιπλέον, η επιλογή των τελικών χαρακτηριστικών επιτρέπει τη μείωση του κινδύνου υπερεκπαίδευσης (overfitting), καθώς το μοντέλο επικεντρώνεται μόνο στις πιο σημαντικές παραμέτρους.

Σε πρακτικό επίπεδο, η επιλογή αυτών των χαρακτηριστικών βοηθά στη μείωση του υπολογιστικού κόστους, ιδιαίτερα σε μεγάλα Δίκτυα με υψηλή διαστατικότητα. Για παράδειγμα, οι τεχνικές όπως η ανάλυση διακύμανσης (Variance Threshold), η αμοιβαία πληροφορία (Mutual Information) και τα Νευρωνικά Δίκτυα με ενσωματωμένες διαδικασίες προσοχής (attention mechanisms) μπορούν να αξιοποιηθούν για να εντοπιστούν τα πιο κρίσιμα χαρακτηριστικά. Συνολικά, η χρήση των παραπάνω χαρακτηριστικών όπως το τελικό και αρχικό V, η γωνία, και τα συστατικά του If, προσφέρει έναν ισχυρό συνδυασμό για την ακριβή ανάλυση και πρόβλεψη σε Δίκτυα διανομής, βελτιστοποιώντας την απόδοση και την ανθεκτικότητα του συστήματος.

5.3. State Estimation

5.3.1. Στόχος

Ο στόχος του **State Estimation (SE)** είναι να εκπαιδευτεί το μοντέλο στα δεδομένα που του προσφέρονται και στο τέλος να προσπαθήσει να προβλέψει τις αρχικές τιμές της τάσης ή της γωνίας τάσης πριν την επίδραση θορύβου. Χρησιμοποιείται ως output το initial V Magnitude όταν εκτιμάται η τιμή της τάσης και προκειμένου να φανεί η απόδοση του ελέγχεται με τον δείκτη MAPE. Αντιθέτως, χρησιμοποιείται ως output το initial V Angle όταν θέλω να προβλέπεται η τιμή της γωνίας τάσης και η απόδοση του μοντέλου μετριέται σε MAE.

5.3.2. Προεπεξεργασία Δεδομένων

Όσον αφορά το NN, το pre processing των δεδομένων θα δημιουργηθεί ένα feature matrix ώστε να συνεισφέρει σε μια οργανωμένη δομή δεδομένων, όπου κάθε γραμμή θα αντιπροσωπεύει ένα δείγμα και κάθε στήλη ένα χαρακτηριστικό. Αυτό το format είναι απαραίτητο για τα περισσότερα αλγόριθμους μηχανικής μάθησης, καθώς εξασφαλίζει ότι όλα τα δεδομένα βρίσκονται σε συνεπή μορφή και μπορούν να επεξεργαστούν εύκολα [\[65\]](#). Επιπλέον, διευκολύνει την κατανόηση και την ανάλυση των δεδομένων, καθώς επιτρέπει την εφαρμογή στατιστικών εργαλείων και τεχνικών προεπεξεργασίας. Η μετατροπή των δεδομένων σου σε feature matrix τα καθιστά κατάλληλα για εισαγωγή στο μοντέλο, είτε πρόκειται για ένα Νευρωνικό Δίκτυο, είτε για οποιοδήποτε άλλο αλγόριθμο. Μέσω αυτής της διαδικασίας, διασφαλίζεται ότι το μοντέλο μπορεί να αξιοποιήσει όλες τις διαθέσιμες πληροφορίες και να μάθει αποτελεσματικά τα μοτίβα που υπάρχουν στα δεδομένα. Συγκεκριμένα, ερευνώντας την τοπολογία 1 δημιουργείται ένα feature matrix με 1000 σειρές (samples) και 169 στήλες (33+33+33+35+35) αφού τα στοιχεία V αποτελούνται από 33 ζυγούς ενώ τα στοιχεία του ρεύματος από 35 κλάδους. Αφού γίνει το reshape προχωράει η διαδικασία του διαχωρισμού δεδομένων.

Η διαίρεση των δεδομένων σε σύνολα εκπαίδευσης (training), επικύρωσης (validation), και δοκιμής (test) με αναλογία 80-10-10 είναι μια κοινή πρακτική στη Μηχανική Μάθηση που αποσκοπεί στη σωστή ανάπτυξη και αξιολόγηση ενός μοντέλου. Ο κύριος σκοπός αυτής της προσέγγισης είναι να διασφαλιστεί ότι το μοντέλο μπορεί να μάθει από τα δεδομένα, να

βελτιστοποιηθεί χωρίς υπερπροσαρμογή και να αξιολογηθεί αντικειμενικά σε νέα, άγνωστα δεδομένα [66].

Το σύνολο εκπαίδευσης, που αποτελεί το 80% του συνολικού dataset, χρησιμοποιείται για την εκπαίδευση του μοντέλου. Εδώ το μοντέλο αναπτύσσει τη μαθηματική κατανόηση των δεδομένων, μαθαίνοντας να συνδέει τα χαρακτηριστικά (features) με τις επιθυμητές εξόδους (targets). Το μεγάλο μέγεθος αυτού του συνόλου είναι κρίσιμο, καθώς περισσότερα δεδομένα παρέχουν στο μοντέλο περισσότερες πληροφορίες για να μάθει καλύτερα τα μοτίβα που υπάρχουν.

Το σύνολο επικύρωσης (validation), που αντιστοιχεί στο 10% των δεδομένων, χρησιμοποιείται κατά τη διάρκεια της εκπαίδευσης για την αξιολόγηση της απόδοσης του μοντέλου σε δεδομένα που δεν έχει δει. Το validation set βοηθά στη ρύθμιση των παραμέτρων, όπως ο ρυθμός εκμάθησης, η αρχιτεκτονική του μοντέλου ή το μέγεθος του batch. Έτσι, εξασφαλίζεται ότι το μοντέλο δεν υπερπροσαρμόζεται στα δεδομένα εκπαίδευσης, αλλά μπορεί να γενικεύσει καλά.

Τέλος, το σύνολο δοκιμής (test), επίσης 10%, χρησιμοποιείται μόνο μετά την ολοκλήρωση της εκπαίδευσης για την τελική αξιολόγηση της απόδοσης. Παρέχει μια ανεξάρτητη μέτρηση της ικανότητας του μοντέλου να γενικεύσει σε νέα δεδομένα. Είναι σημαντικό το test set να μην επηρεάζει την εκπαίδευση ή την επιλογή παραμέτρων, διασφαλίζοντας αντικειμενική αξιολόγηση [67].

Η υλοποίηση της διάσπασης 80-10-10 έγινε με τη μέθοδο **train_test_split** από τη βιβλιοθήκη scikit-learn. Αρχικά, τα δεδομένα χωρίστηκαν σε training και temporary test set σε αναλογία 80%-20%. Στη συνέχεια, διαχωρίζουμε περαιτέρω το temporary test set σε validation και test set με αναλογία 50%-50%, εξασφαλίζοντας ότι το validation και το test set καλύπτουν το 10% το καθένα. Αυτή η διαδικασία εξασφαλίζει ότι τα δεδομένα είναι σωστά διαχωρισμένα και μπορούν να χρησιμοποιηθούν με ακρίβεια για την ανάπτυξη, την επικύρωση και την αξιολόγηση του μοντέλου.

```
# Split data (80-10-10)
X_train, X_temp, y_train, y_temp = train_test_split(X_selected, y_combined, test_size=0.2, random_state=42)
X_val, X_test, y_val, y_test = train_test_split(X_temp, y_temp, test_size=0.5, random_state=42)
```

Όσον αφορά το GNN η διαδικασία pre processing είναι διαφορετική, εκεί ο στόχος είναι η αναπαράσταση του Δικτύου διανομής ηλεκτρικής ενέργειας ως γράφου, όπου οι κόμβοι αντιπροσωπεύουν τις μονάδες του συστήματος, όπως οι ζυγοί, ενώ οι ακμές αντιστοιχούν στις συνδέσεις τους, δηλαδή στις γραμμές μεταφοράς. Κάθε κόμβος και ακμή περιέχουν χαρακτηριστικά όπως τάση, γωνία, ενεργή και άεργη ισχύ. Το preprocessing μετατρέπει αυτά τα δεδομένα σε κατάλληλη μορφή για χρήση από τη βιβλιοθήκη PyTorch Geometric.

Αρχικά, οι ακμές ορίζονται ως λίστα ζευγών κόμβων που περιγράφουν τις συνδέσεις του Δικτύου. Για να καταστούν συμβατές με τη βιβλιοθήκη, οι δείκτες των κόμβων μετατρέπονται σε 0-indexed, αφαιρώντας μία μονάδα από κάθε δείκτη, καθώς αυτό είναι το πρότυπο στις περισσότερες βιβλιοθήκες μηχανικής μάθησης. Οι λίστες των ακμών μετασχηματίζονται σε πίνακα NumPy και στη συνέχεια σε PyTorch tensor με διάταξη [2, num_edges], όπου οι δύο γραμμές αντιπροσωπεύουν την αρχή και το τέλος κάθε ακμής.

Για κάθε δείγμα προσομοίωσης, δημιουργούνται τα χαρακτηριστικά των κόμβων, τα χαρακτηριστικά των ακμών και οι στόχοι. Τα χαρακτηριστικά των κόμβων, που μπορεί να περιλαμβάνουν την τάση και τη γωνία, οργανώνονται σε πίνακα διαστάσεων [33, 2], όπου κάθε κόμβος έχει δύο χαρακτηριστικά. Οι ακμές φέρουν τα ρεύματα που αποθηκεύονται σε πίνακα διαστάσεων [35, 2]. Όλα αυτά τα στοιχεία συνδυάζονται σε ένα αντικείμενο Data της PyTorch Geometric, το οποίο περιλαμβάνει τα χαρακτηριστικά των κόμβων (x), τις ακμές (edge_index), τα χαρακτηριστικά των ακμών (edge_attr) και τους στόχους (y).

Τα δεδομένα χωρίζονται σε σύνολα εκπαίδευσης, επικύρωσης και δοκιμών με αναλογίες 80%, 10% και 10%, αντίστοιχα. Ο διαχωρισμός γίνεται πάλι με τη χρήση της μεθόδου train_test_split, εξασφαλίζοντας ότι τα δεδομένα διαχωρίζονται τυχαία αλλά διατηρώντας την αναλογία. Το αποτέλεσμα είναι τρία ξεχωριστά σύνολα δεδομένων που χρησιμοποιούνται για την εκπαίδευση, την επικύρωση και τη δοκιμή του μοντέλου.

Στη συνέχεια, τα δεδομένα φορτώνονται σε DataLoaders, οι οποίοι διευκολύνουν τη διαχείριση των δεδομένων κατά παρτίδες (batches). Οι παρτίδες περιέχουν πολλαπλά δείγματα που ενώνονται μεταξύ τους, διατηρώντας τη δομή του γράφου, ώστε να υποστηρίξουν την αποδοτική εκπαίδευση. Κάθε παρτίδα περιλαμβάνει τις ιδιότητες όλων των κόμβων και ακμών, ενώ οι στόχοι οργανώνονται με βάση τα δεδομένα των κόμβων [68].

Η διαδικασία αυτή διασφαλίζει ότι τα δεδομένα είναι συμβατά με τη δομή και τη λογική του GNN, επιτρέποντας στο μοντέλο να μάθει τις σχέσεις μεταξύ των κόμβων και των ακμών.

Η προετοιμασία αυτή είναι κρίσιμη για την αποδοτική και σωστή εκπαίδευση ενός GNN, καθώς εξασφαλίζει ότι το μοντέλο μπορεί να επεξεργαστεί τη χωρική πληροφορία του γράφου και να εκπαιδευτεί με ακρίβεια [69].

5.3.3.Επιλογή PMU

Η χρήση Νευρωνικών Δικτύων για την ελαχιστοποίηση του αριθμού των **Phasor Measurement Units (PMUs)** σε ένα Δίκτυο διανομής ηλεκτρικής ενέργειας αποτελεί μια καινοτόμο προσέγγιση που βασίζεται στην ικανότητα των δικτύων αυτών να εξάγουν μοτίβα και σχέσεις από δεδομένα [70]. Στην περίπτωση του Δικτύου IEEE 33 Bus, η αντικατάσταση 35 PMUs με μόνο 2 καθίσταται δυνατή με την κατάλληλη εκπαίδευση ενός Νευρωνικού Δικτύου που μπορεί να προβλέψει κρίσιμες παραμέτρους, όπως οι τάσεις και οι γωνίες των κόμβων, βασιζόμενο σε μετρήσεις από τις δύο επιλεγμένες θέσεις [71].

Η διαδικασία ξεκινά με την επιλογή των δύο καταλληλότερων ακμών του Δικτύου για την τοποθέτηση των PMUs. Αυτό επιτυγχάνεται με ανάλυση που βασίζεται στο Mean Absolute Percentage Error (MAPE) και άλλες μετρικές ακρίβειας. Οι δύο ακμές επιλέγονται με τέτοιο τρόπο ώστε να παρέχουν τις πιο κρίσιμες πληροφορίες για το Δίκτυο, καλύπτοντας το μεγαλύτερο δυνατό τμήμα του συστήματος.

Στη συνέχεια, ένα Νευρωνικό Δίκτυο εκπαιδεύεται χρησιμοποιώντας δεδομένα από προσομοιώσεις που περιλαμβάνουν μετρήσεις των δύο PMUs. Το Δίκτυο μαθαίνει να προβλέπει τις τιμές των υπόλοιπων κόμβων του συστήματος, εξάγοντας σχέσεις μεταξύ των δεδομένων εισόδου (μετρήσεις από τα δύο PMUs) και των δεδομένων εξόδου (τάσεις και γωνίες όλων των κόμβων). Μετά την εκπαίδευση, το Δίκτυο μπορεί να γενικεύσει και να παρέχει αξιόπιστες προβλέψεις ακόμη και για περιπτώσεις που δεν έχει συναντήσει κατά τη διάρκεια της εκπαίδευσης. Έτσι, με τη σωστή επιλογή θέσεων PMU και τη χρήση Νευρωνικών Δικτύων, είναι εφικτό να επιτευχθούν παρόμοια επίπεδα ακρίβειας στις εκτιμήσεις του συστήματος, όπως αυτά που θα επιτυγχάνονταν με τη χρήση 35 PMUs, μειώνοντας σημαντικά το κόστος εγκατάστασης [72].

Συγκεκριμένα, αναπτύχθηκε ένας αλγόριθμος που προσομοιώνει την τοποθέτηση ενός PMU σε κάθε μία από τις 35 διαθέσιμες ακμές του Δικτύου. Για κάθε περίπτωση, εκτιμήθηκαν τα στοιχεία του συστήματος βασιζόμενα αποκλειστικά στις μετρήσεις της αντίστοιχης ακμής.

Το Νευρωνικό Δίκτυο εκπαιδεύτηκε να προβλέπει κρίσιμες παραμέτρους, όπως οι τάσεις και οι γωνίες των κόμβων, χρησιμοποιώντας ως είσοδο τα δεδομένα από το PMU που είχε τοποθετηθεί στην εξεταζόμενη ακμή. Η απόδοση του συστήματος αξιολογήθηκε για κάθε πιθανή θέση με βάση την τιμή MAPE [74].

Μετά την ολοκλήρωση της πρώτης φάσης, προσδιορίστηκε η ακμή που παρείχε τη χαμηλότερη τιμή MAPE, δηλαδή τη βέλτιστη απόδοση στις προβλέψεις του Νευρωνικού Δικτύου. Η συγκεκριμένη ακμή αποτέλεσε την πρώτη θέση τοποθέτησης PMU. Στη συνέχεια, ο αλγόριθμος προχώρησε στη δεύτερη φάση, κατά την οποία εξετάστηκαν όλοι οι δυνατοί συνδυασμοί της πρώτης ακμής με καθεμία από τις υπόλοιπες 34. Για κάθε συνδυασμό, το Νευρωνικό Δίκτυο επανεκπαιδεύτηκε, και η απόδοση αξιολογήθηκε εκ νέου με βάση τη μετρική MAPE. Σκοπός αυτής της φάσης ήταν να εντοπιστεί ο συνδυασμός δύο ακμών που εξασφαλίζει τη βέλτιστη ακρίβεια στις εκτιμήσεις του συστήματος.

Τα αποτελέσματα της ανάλυσης έδειξαν ότι οι ακμές 6 και 22 αποτελούν τη βέλτιστη δυάδα για την τοποθέτηση δύο PMUs. Η επιλογή αυτών των ακμών βασίζεται στο γεγονός ότι η συνδυαστική πληροφορία που παρέχουν επαρκεί για την πλήρη και ακριβή παρακολούθηση του συστήματος, μειώνοντας σημαντικά την ανάγκη για περισσότερες συσκευές. Η τοποθέτηση των PMUs σε αυτές τις ακμές διασφαλίζει την παρακολούθηση όλων των κρίσιμων παραμέτρων του Δικτύου με ελάχιστο κόστος και υψηλή ακρίβεια.

5.3.4. Εκτίμηση Κατάστασης σε Νευρωνικό Δίκτυο


Η εργασία επικεντρώνεται στη χρήση του **MLP Regressor** για την πρόβλεψη της τάσης και τα γωνίας της στο Δίκτυο διανομής. Ο στόχος της μελέτης είναι να αξιολογηθεί η ικανότητα του μοντέλου να παράγει ακριβείς προβλέψεις υπό διαφορετικές συνθήκες εισόδου. Για την εκπαίδευση του μοντέλου, χρησιμοποιείται ένας πολυεπίπεδος προωθητικός Νευρωνικός ταξινομητής (MLP), ο οποίος αποτελεί ένα ισχυρό εργαλείο μηχανικής μάθησης για τη μοντελοποίηση μη γραμμικών σχέσεων. Το μοντέλο έχει δύο κρυφά επίπεδα, το καθένα με 64 νευρώνες ενώ ο αριθμός των μέγιστων εποχών έχει οριστεί στις 1000. Για την αποφυγή υπερεκπαίδευσης εφαρμόζεται πρόωρη διακοπή (early stopping) στις 20 συνεχόμενες εποχές χωρίς βελτίωση.

Η εκπαίδευση πραγματοποιείται χρησιμοποιώντας ως είσοδο το X_{train} για τα χαρακτηριστικά y_{train} (οι αρχικές τιμές). Η καμπύλη μάθησης παρακολουθείται κατά τη διάρκεια της διαδικασίας εκπαίδευσης, με το μοντέλο να βελτιώνει συνεχώς την ακρίβειά του


έως ότου σταθεροποιηθεί. Το μικρό βήμα εκμάθησης (0.001) εξασφαλίζει σταθερή σύγκλιση, ενώ η ανεκτικότητα (tol) ρυθμίζεται σε $1e-4$ για την αποφυγή τερματισμού της διαδικασίας λόγω μικρών διακυμάνσεων στο σφάλμα.

Τα αποτελέσματα δείχνουν ότι όταν χρησιμοποιούνται όλα τα διαθέσιμα δεδομένα του συστήματος, το μοντέλο αποδίδει εξαιρετικά καλά, με τιμές MAPE 0.046 και MAE 0.035. Αυτό υποδηλώνει ότι το μοντέλο είναι σε θέση να εκμεταλλευτεί πλήρως τις πληροφορίες του συστήματος για την πρόβλεψη των γωνιών τάσης. Όταν η διαθέσιμη πληροφορία περιορίζεται σε δεδομένα από δύο PMUs τοποθετημένα στους κόμβους 6 και 22, η απόδοση του μοντέλου μειώνεται ελαφρώς, με το MAPE να αυξάνεται στο 0.1 και το MAE στο 0.073. Αυτή η παρατήρηση καταδεικνύει τη σημασία της τοποθέτησης και του αριθμού των PMUs για τη διατήρηση της ακρίβειας του μοντέλου, αφού μόλις με δύο παρατηρητές τα αποτελέσματα δεν αλλάζουν δραματικά. Σίγουρα, η περιορισμένη παρατήρηση των μετρήσεων οδηγεί σε λιγότερο πληροφοριακές εισόδους για το MLP, γεγονός που δυσχεραίνει την ακριβή πρόβλεψη των γωνιών τάσης σε ολόκληρο το σύστημα.

Το **MLP Regressor** λειτουργεί ως μοντέλο παλινδρόμησης που προσπαθεί να ελαχιστοποιήσει τη διαφορά μεταξύ των προβλέψεων και των πραγματικών τιμών. Η χρήση των PMUs παρέχει κρίσιμη πληροφορία στο σύστημα, καθώς οι μετρήσεις των τάσεων και των ρευμάτων σε συγκεκριμένους κόμβους είναι απαραίτητες για τη σωστή εκτίμηση των χαρακτηριστικών του Δικτύου. Η μείωση της απόδοσης όταν χρησιμοποιούνται μόνο δύο PMUs μπορεί να αποδοθεί στην περιορισμένη κάλυψη των ροών ισχύος και των δυναμικών στο Δίκτυο. Καθώς το MLP βασίζεται στις εισόδους για να εκπαιδευτεί και να προβλέψει, οποιαδήποτε απώλεια πληροφορίας έχει επίδραση στην ικανότητά του να μοντελοποιήσει τη δυναμική του συστήματος [74].



Μέση τιμή MAPE ανά ζυγό



Μέση τιμή MAE ανά ζυγό

5.3.4. Εκτίμηση Κατάστασης σε GNN

Μετά το απλό Νευρωνικό Δίκτυο προχωράμε στην υλοποίηση του με γράφο (GNN). Το μοντέλο αξιοποιεί τα δεδομένα που σχετίζονται με τις συνδέσεις μεταξύ των buses, δηλαδή τις γραμμές που συνδέουν τα διάφορα σημεία του Δικτύου, και τα χαρακτηριστικά αυτών των συνδέσεων, όπως τα ρεύματα και οι γωνίες των φορτίων.

Ο βασικός στόχος αυτού του μοντέλου GCN είναι να προβλέψει τις αρχικές τιμές των τάσεων σε κάθε κόμβο (ζυγό), χρησιμοποιώντας τα δεδομένα των γειτονικών κόμβων και των γραμμών που τα συνδέουν. Η είσοδος του μοντέλου περιλαμβάνει χαρακτηριστικά από κάθε κόμβο, δηλαδή πληροφορίες όπως η τάση και η γωνία, καθώς και τα πραγματικά και φανταστικά ρεύματα. Αυτό επιτρέπει τη μεταφορά πληροφορίας μεταξύ γειτονικών κόμβων μέσω της διαδικασίας convolution που πραγματοποιείται στις ακμές του Δικτύου.

Το μοντέλο αποτελείται από τέσσερις στρώσεις GCN, οι οποίες είναι εξοπλισμένες με κανονικοποίηση Batch Normalization και λειτουργίες Dropout. Αυτές οι στρώσεις επιτρέπουν την εκμάθηση ισχυρών χαρακτηριστικών των κόμβων, ενώ ταυτόχρονα αποτρέπουν την υπερβολική προσαρμογή του μοντέλου. Οι συναρτήσεις ενεργοποίησης που χρησιμοποιούνται είναι κυρίως ReLU, που επιτρέπουν τη σύνθεση των χαρακτηριστικών [75].

Το μοντέλο βασίζεται στα χαρακτηριστικά των κλάδων (edge attributes), τα χαρακτηριστικά των κόμβων (node attributes) και το edge index για την πρόβλεψη στο GCN.

Εισαγωγή στην Αρχιτεκτονική του Μοντέλου:

1. Node Attributes:

Οι κόμβοι σε ένα γράφο αντιπροσωπεύουν τα buses του Δικτύου ηλεκτρικής ενέργειας, κάθε ένας από τους οποίους έχει χαρακτηριστικά (node attributes). Αυτά τα χαρακτηριστικά περιλαμβάνουν πληροφορίες όπως η αρχική τιμή της τάσης (voltage), η γωνία (angle), το πραγματικό φορτίο (P) και το φανταστικό φορτίο (Q) που σχετίζονται με κάθε bus. Οι πληροφορίες αυτές διατηρούνται για κάθε κόμβο και χρησιμοποιούνται στη διαδικασία εκπαίδευσης.

2. Edge Attributes:

Οι ακμές αντιπροσωπεύουν τις γραμμές μεταφοράς ηλεκτρικής ενέργειας που συνδέουν δύο buses. Οι ακμές αυτές φέρουν χαρακτηριστικά (edge attributes) τα οποία περιλαμβάνουν τις πληροφορίες των ρευμάτων (real και imaginary currents), καθώς και τις γωνίες των ρευμάτων που ρέουν μέσα από αυτές τις γραμμές. Αυτά τα χαρακτηριστικά είναι κρίσιμα για την κατανόηση της συμπεριφοράς του συστήματος και επιτρέπουν τη μεταφορά πληροφορίας από τον έναν κόμβο στον άλλο [76].

3. Edge Index:

Ο δείκτης των ακμών (edge index) είναι υπεύθυνος για τη συσχέτιση των χαρακτηριστικών των κόμβων με τους αντίστοιχους κλάδους. Κάθε ακμή στο γράφο συνδέει δύο κόμβους και το edge index δείχνει πώς οι ακμές συνδέονται με τους συγκεκριμένους κόμβους [77]. Αυτός ο δείκτης βοηθά στην ανάκτηση των χαρακτηριστικών που αντιστοιχούν σε κάθε γραμμή. Ουσιαστικά, το μοντέλο επιλέγει κλάδους και μαζί τους παίρνει τα δεδομένα των κόμβων από τους οποίους προέρχεται ο εκάστοτε κλάδος.

Εκπαίδευση


Η εκπαίδευση του μοντέλου γίνεται μέσω της απώλειας **Mean Squared Error (MSE)**, η οποία μετρά τη διαφορά μεταξύ των πραγματικών και των προβλεπόμενων τιμών. Αυτό το κριτήριο χρησιμοποιείται για να εκπαιδεύσει το μοντέλο να ελαχιστοποιεί τη μέση τετραγωνική απόκλιση των εκτιμήσεων από τα πραγματικά δεδομένα. Ταυτόχρονα, κατά τη διάρκεια της εκπαίδευσης, η απόδοση του μοντέλου παρακολουθείται μέσω των δεικτών MAPE και MAE ανάλογα με το αν εκτιμά την τάση ή την γωνία τάσης.

Η διαδικασία εκπαίδευσης περιλαμβάνει την αρχική εκπαίδευση μέσω mini-batches και την εφαρμογή της early stopping τεχνικής για την αποφυγή υπερβολικής εκπαίδευσης. Η early stopping διακόπτει την εκπαίδευση μόλις δεν παρατηρείται σημαντική βελτίωση στον επικύρωση, περιορίζοντας έτσι την υπερπροσαρμογή και διασφαλίζοντας ότι το μοντέλο δεν εκπαιδεύεται με περιττές λεπτομέρειες όταν ξεπεράσει τις 40 εποχές χωρίς αποτέλεσμα.


Το βασικό σημείο ενδιαφέροντος στην ανάλυση του κώδικα είναι τα αποτελέσματα που προκύπτουν από τη χρήση του μοντέλου GCN. Σύμφωνα με τις μετρήσεις που παρουσιάζονται, όταν το μοντέλο εκπαιδεύεται χρησιμοποιώντας όλες τις πληροφορίες από το Δίκτυο (και τους

33 κόμβους αλλά και τις συνδέσεις μεταξύ τους), τα επιτευχθέντα ποσοστά MAPE και MAE είναι αρκετά ικανοποιητικά, με MAPE της τάξεως του 0.022 και MAE περίπου 0.014. Αντίθετα, όταν χρησιμοποιούνται μόνο τα δεδομένα από τις γραμμές 6-22 και τους αντίστοιχους κόμβους, τα αποτελέσματα είναι λιγότερο ακριβή, με το MAPE να φτάνει το 0.03 και το MAE το 0.021.

Αυτό το φαινόμενο αποδεικνύει τη σημασία της πλήρους ενσωμάτωσης όλων των πληροφοριών του Δικτύου στην πρόβλεψη, καθώς οι περιορισμένες πληροφορίες φαίνεται να υποβαθμίζουν την απόδοση του μοντέλου, σε μικρό ωστόσο βαθμό. Το γεγονός ότι το MAPE και το MAE είναι υψηλότερα όταν τα δεδομένα είναι λιγότερα, υποδεικνύει ότι οι κόμβοι και οι γραμμές πρέπει να εκτιμώνται συνολικά και αλληλένδετα, για να επιτευχθούν πιο ακριβείς προβλέψεις.



Μέση τιμή MAPE ανά ζυγό GNN



Μέση τιμή MAE ανά ζυγό GNN

5.4.Εύρεση τοπολογίας (Topology Identification)

Εκτός από State Estimation στα πλαίσια της διπλωματικής εργασίας διερευνήθηκε και η εύρεση τοπολογίας. Όπως αναφέρθηκε έχουμε παράξει 15 διαφορετικές τοπολογίες μέσω της MATLAB με παραλλαγές του IEEE33 Bus Distribution System.

5.4.1. Νευρωνικό Δίκτυο

5.4.2 Προεπεξεργασία δεδομένων

Η προεπεξεργασία δεδομένων αποτελεί ένα κρίσιμο στάδιο πριν από τη δημιουργία και την εκπαίδευση ενός Νευρωνικού Δικτύου, καθώς επηρεάζει σημαντικά την ποιότητα των μοντέλων που θα δημιουργηθούν. Η διαδικασία περιλαμβάνει την επεξεργασία και την ενοποίηση πληροφοριών από διάφορες πηγές για να δημιουργηθεί ένα σύνολο δεδομένων που θα είναι κατάλληλο για εκπαίδευση με Νευρωνικό Δίκτυο.

Το αρχικό βήμα της διαδικασίας περιλαμβάνει τη φόρτωση των δεδομένων από δύο αρχεία Excel που περιέχουν πληροφορίες σχετικά με τις παρατηρήσεις των λεωφορείων και τις πληροφορίες των γραμμών. Τα δεδομένα από το πρώτο αρχείο Excel περιλαμβάνουν χαρακτηριστικά όπως την τελική τάση (p.u.) και την τελική γωνία (μοίρες) για κάθε ζυγό, ενώ το δεύτερο αρχείο περιέχει τις πραγματικές τελικές τιμές του ρεύματος (A). Οι στήλες αυτές επιλέγονται και απομονώνονται από το αντίστοιχο αρχείο δεδομένων.

Μετά τη διαμόρφωση των δεδομένων από τους ζυγούς και τις γραμμές μεταφοράς, τα δεδομένα επανασηματίζονται σε δυαδικό σχήμα για να εναρμονιστούν με τη μορφή του προβλήματος (reshaping). Τα δεδομένα από τους ζυγούς και τις γραμμές ενοποιούνται με τη χρήση της numpy για τη δημιουργία ενός ενιαίου συνόλου δεδομένων, το οποίο αποτελείται από 15 τοπολογίες και περιέχει 136 χαρακτηριστικά σε κάθε δείγμα.

Το σύνολο δεδομένων στη συνέχεια διαχωρίζεται σε τρία υποσύνολα: εκπαίδευσης, επικύρωσης και δοκιμής, με τη χρήση της `train_test_split` από τη βιβλιοθήκη `sklearn`. Αυτό το στάδιο είναι κρίσιμο, καθώς εγγυάται ότι τα υποσύνολα αυτά περιέχουν πληροφορίες που καλύπτουν όλη την κατανομή των δεδομένων, επιτρέποντας έτσι τη γενίκευση του μοντέλου.

Η διαδικασία προεπεξεργασίας ολοκληρώνεται με την ενσωμάτωση των ετικετών (labels) που αντιπροσωπεύουν την τοπολογία του συστήματος. Οι ετικέτες αυτές είναι αριθμοί από 1 έως 15 που επαναλαμβάνονται 1000 φορές, δίνοντας έτσι συνολικά 15.000 παρατηρήσεις, ώστε να γνωρίζει πάντα το μοντέλο ποια τοπολογία πρέπει να προβλέψει. Το τελικό σύνολο δεδομένων προορίζεται για εκπαίδευση ενός Νευρωνικού Δικτύου, το οποίο θα

μπορεί να προβλέπει τις πιθανές τοπολογίες του συστήματος βάσει των διαθέσιμων μετρήσεων.

5.4.3. Μοντέλο NN

Στη συνέχεια προχωράει η υλοποίηση του Νευρωνικού Δικτύου. Η αρχική λειτουργία του κώδικα είναι να εκτελέσει την εξαγωγή χαρακτηριστικών από δεδομένα, χρησιμοποιώντας επιλεγμένες γραμμές που έχουν σημασία για τη μελέτη του προβλήματος. Αυτή η διαδικασία εξασφαλίζει ότι το μοντέλο λαμβάνει την πιο σχετική πληροφορία για τη διαδικασία εκπαίδευσης.

Μετά την εξαγωγή χαρακτηριστικών, το σύνολο δεδομένων χρησιμοποιείται για την εκπαίδευση του μοντέλου. Ο κώδικας περιλαμβάνει τη χρήση ενός Sequential μοντέλου από την TensorFlow, το οποίο ορίζεται με διάφορα κρυφά στρώματα. Το πρώτο στρώμα είναι ένας πυκνός (dense) νευρώνας που λαμβάνει ως είσοδο τα εξαγόμενα χαρακτηριστικά, ενεργοποιείται μέσω της συνάρτησης ReLU και ακολουθείται από ένα δεύτερο πυκνό στρώμα. Τέλος, η τελευταία στρώση είναι το στρώμα εξόδου, το οποίο χρησιμοποιεί την softmax ενεργοποίηση για να εξαγάγει τις πιθανότητες κάθε τοπολογίας.


Η σύνθεση του κώδικα συνεχίζεται με τη λειτουργία της εκπαίδευσης του μοντέλου, το οποίο εκπαιδεύεται με βάση τα δεδομένα εκπαίδευσης και τις ετικέτες. Ο χρόνος εκπαίδευσης ορίζεται σε 500 εποχές, και η διαδικασία περιλαμβάνει τόσο την απώλεια όσο και την ακρίβεια των δεδομένων επικύρωσης.

Στο επόμενο βήμα, γίνονται προβλέψεις για το σύνολο δεδομένων δοκιμής και αξιολογείται η ακρίβεια του μοντέλου. Η τελική αξιολόγηση πραγματοποιείται μέσω του `accuracy_score`, ο οποίος συγκρίνει τις προβλέψεις με τις πραγματικές ετικέτες και επιστρέφει την απόδοση του μοντέλου. Το μοντέλο Νευρωνικού Δικτύου μας δίνει ακρίβεια 99.12% όταν γίνεται χρήση όλων των αρχείων εισόδου.

Έπειτα, έγινε έρευνα για το πόσο θα μπορούσαν να διατηρηθούν τα αποτελέσματα και η ακρίβεια του μοντέλου αν περιορίζαμε τα PMUs στο Δίκτυο, δηλαδή τα δεδομένα εισόδου. Ορίστηκε ως κατώτατο κατώφλι ακρίβειας το 95% και χρησιμοποιήθηκε ο κατάλληλος αλγόριθμος για να βρεθεί ο αριθμός των PMUs που χρειάζεται για να φτάσει σε αυτά τα επίπεδα ακρίβειας. Ουσιαστικά, το μοντέλο έτρεξε 35 φορές (μία για τον κάθε κλάδο ξεχωριστά), διαλέγοντας τον κλάδο με την υψηλότερη ακρίβεια. Αφού τον επέλεξε, έτρεξε ξανά το μοντέλο 34 φορές με τον επιλεγμένο κλάδο (τον νούμερο 6 για την ακρίβεια) με όλους

τους άλλους μαζί σαν ζευγάρια. Συνδυάζοντας τον 3 με τον 12, το μοντέλο πέτυχε ακρίβεια 97,65%, πάνω δηλαδή από το όριο του 95% οπότε και σταμάτησε.

Συμπερασματικά, με τη χρήση μόλις 2 PMUs επιτυγχάνονται αποτελέσματα πολύ κοντά με όταν χρησιμοποιούνται όλα τα δεδομένα εισόδου. Το μοντέλο εκπαιδεύεται με τέτοιο τρόπο που μπορεί να εκτιμά σωστά τα δεδομένα που λείπουν καταφέροντας να εκμηδενίσει το κόστος.



Η απώλεια και η ακρίβεια του NN μοντέλου ανάλογα με την πάροδο των εποχών

5.4.4. Μοντέλο GNN

Μετά τη διερεύνηση του Νευρωνικού Δικτύου έγινε και αντίστοιχη υλοποίηση με GNN προκειμένου να φανεί αν υπάρχει κάποια βελτίωση. Ο κώδικας που χρησιμοποιήθηκε είναι σχεδιασμένος για την εκπαίδευση ενός μοντέλου GNN, το οποίο χρησιμοποιείται για την πρόβλεψη τοπολογιών ενός συστήματος ισχύος. Το σύστημα απαρτίζεται από ένα σύνολο από με 33 κόμβους (buses) και 35 κλάδους (branches), οι οποίοι συνδέονται μεταξύ τους.

Η αρχική προσέγγιση ξεκινά με τη φόρτωση των δεδομένων από δύο διαφορετικά αρχεία Excel: το πρώτο περιέχει τα χαρακτηριστικά των ζυγών, ενώ το δεύτερο περιέχει τα χαρακτηριστικά των κλάδων. Από τα δεδομένα αυτά, το πρόγραμμα εξάγει σημαντικές πληροφορίες, όπως η τελική τιμή τάσης (Final V) και η γωνία (Final Angle) των κόμβων, καθώς και η πραγματική και φανταστική συνιστώσα του ρεύματος για τις γραμμές. Τα δεδομένα αυτά στη συνέχεια δομούνται σε ένα τρισδιάστατο σχήμα (δηλαδή, δεδομένα για κάθε τοπολογία, κάθε λεωφορείο και κάθε χαρακτηριστικό).

Οι κλάδοι μεταξύ των λεωφορείων διαμορφώνονται σε μια λίστα που περιγράφει τις συνδέσεις μεταξύ των κόμβων (λέγοντας ποιοι κόμβοι συνδέονται μεταξύ τους). Οι ακμές αυτές αρχικά ορίζονται σε 1-indexed, αλλά μετατρέπονται σε 0-ευρετική με τη μείωση 1 από κάθε δείκτη (προκειμένου το σύστημα να είναι 0 based). Στη συνέχεια, τα δεδομένα μετατρέπονται σε μορφή κατάλληλη για το GNN: οι κόμβοι αντιπροσωπεύονται μέσω των χαρακτηριστικών τους (features) και οι ακμές μέσω των χαρακτηριστικών των γραμμών που συνδέουν τους κόμβους [78].

Το κύριο μέρος αφορά τη δημιουργία ενός συνόλου δεδομένων (data list) που περιλαμβάνει πληροφορίες για κάθε σύνολο λεωφορείων και γραμμών, συμπεριλαμβάνοντας τα χαρακτηριστικά και την αντίστοιχη τοπολογία. Αυτά τα δεδομένα αποθηκεύονται ως αντικείμενα Data από τη βιβλιοθήκη PyTorch Geometric, η οποία παρέχει τις βασικές λειτουργίες για την επεξεργασία γραφικών δεδομένων. Κάθε αντικείμενο περιέχει τις ιδιότητες του κόμβου (λεωφορείο), τις ακμές και τις ακμές χαρακτηριστικά των γραμμών.

Ένα άλλο βασικό κομμάτι είναι η προετοιμασία των δεδομένων για εκπαίδευση, έλεγχο επικύρωσης και δοκιμή. Η διαίρεση των δεδομένων σε τρία σύνολα (εκπαίδευση, επικύρωση, δοκιμή) γίνεται και πάλι μέσω της συνάρτησης `train_test_split`.

Η εκπαίδευση του μοντέλου γίνεται μέσω όπως και στο State Estimation με `DataLoader` από το PyTorch, το οποίο διαχειρίζεται την κατανομή των δεδομένων σε batch για κάθε κλήση. Το `train_loader` προετοιμάζει τα δεδομένα για την εκπαίδευση, το `valid_loader` για τον έλεγχο επικύρωσης και το `test_loader` για την τελική αξιολόγηση του μοντέλου.


Προχωρώντας στην υλοποίηση, όταν όλα τα διαθέσιμα δεδομένα εισόδου χρησιμοποιούνται για την εκπαίδευση και την αξιολόγηση του GNN, το μοντέλο επιτυγχάνει 100% ακρίβεια, κάτι που υποδηλώνει την απόλυτη ικανότητά του να αναγνωρίζει την τοπολογία του συστήματος. Αυτό το αποτέλεσμα οφείλεται στην πλήρη πρόσβαση του GNN σε όλες τις πληροφορίες, εξαλείφοντας την αβεβαιότητα κατά την πρόβλεψη.

Ωστόσο, όταν περιορίζεται η είσοδος σε συγκεκριμένους κλάδους και τους σχετιζόμενους με αυτούς κόμβους, η ακρίβεια μειώνεται ελαφρώς. Συγκεκριμένα, όταν χρησιμοποιούνται μόνο οι κλάδοι 3 και 12 που βγήκαν προηγουμένως ως οι σημαντικότεροι, μαζί με τους κόμβους από τους οποίους προέρχονται, η ακρίβεια του GNN φτάνει στο 99,23%. Αυτή η μικρή πτώση υποδηλώνει ότι η απώλεια μέρους των δεδομένων επηρεάζει ελαφρώς την ικανότητα του μοντέλου να αναγνωρίζει την τοπολογία, αν και εξακολουθεί να διατηρεί υψηλή απόδοση. Ο περιορισμός των δεδομένων εισόδου ενδέχεται να οδηγεί σε μερική απώλεια κρίσιμων πληροφοριών, οι οποίες είναι απαραίτητες για την πλήρη κατανόηση της τοπολογίας.

Παρόλα αυτά, η ικανότητα του GNN να επιτυγχάνει τόσο υψηλή ακρίβεια, ακόμα και υπό περιορισμένες συνθήκες, καταδεικνύει την ισχυρή ικανότητα γενίκευσής του και τη δυνατότητα εκμετάλλευσης συσχετίσεων στους κλάδους και τους κόμβους του Δικτύου. Ο κώδικας που υλοποιεί αυτή τη διαδικασία περιλαμβάνει την κατασκευή ενός GNN με τη χρήση των βιβλιοθηκών PyTorch και PyTorch Geometric, παρέχοντας τη δυνατότητα ενσωμάτωσης χαρακτηριστικών των ακμών (edge attributes). Το GNN εκπαιδεύεται και αξιολογείται με χρήση ενός υποσυνόλου δεδομένων, όπου επιλέγονται οι κλάδοι 6 και 22 και οι κόμβοι που σχετίζονται με αυτούς [\[79\]](#).

Ο κώδικας αρχικά ορίζει την κλάση του GNN μέσω του GCNModelWithEdgeAttr ώστε να συμπεριληφθούν και οι τιμές του ρεύματος στους κλάδους. Το μοντέλο περιλαμβάνει τρία διαδοχικά layers, τα οποία επιτρέπουν τη χρήση ακμών με ιδιότητες (edge attributes) ως μέρος των υπολογισμών. Η διαδικασία επιλογής δεδομένων βασίζεται στη συνάρτηση `select_subset_by_source_edges`, η οποία απομονώνει συγκεκριμένους κλάδους και τους σχετιζόμενους κόμβους, φιλτράροντας τόσο τα χαρακτηριστικά των κόμβων όσο και τις ιδιότητες των ακμών. Η συνάρτηση δημιουργεί έναν νέο σύνολο δεδομένων, όπου περιλαμβάνονται μόνο οι επιλεγμένοι κλάδοι, οι κόμβοι που συνδέονται με αυτούς και τα αντίστοιχα χαρακτηριστικά τους [\[80\]](#).

Ο εκπαιδευτικός βρόχος υλοποιείται με βάση τις τυπικές πρακτικές της PyTorch, περιλαμβάνοντας έναν Adam optimizer και τη συνάρτηση απώλειας CrossEntropyLoss. Τα δεδομένα χωρίζονται σε σύνολα εκπαίδευσης, επικύρωσης και δοκιμής, με τα αντίστοιχα υποσύνολα να κατασκευάζονται μέσω της συνάρτησης `select_subset_by_source_edges`. Η ακρίβεια υπολογίζεται σε κάθε βήμα εκπαίδευσης, επικύρωσης και δοκιμής, ενώ το μοντέλο αξιολογείται σε κάθε εποχή.



Η απώλεια και η ακρίβεια του GNN μοντέλου ανάλογα με την πάροδο των εποχών

5.5. Σύγκριση και Συμπεράσματα

5.5.1. Σύγκριση State Estimation


Οι επιδόσεις του μοντέλου αξιολογήθηκαν με βάση το μέσο απόλυτο ποσοστιαίο σφάλμα (MAPE) και το μέσο απόλυτο σφάλμα (MAE) σε δύο διαφορετικά σενάρια: χρήση όλων των δεδομένων και χρήση περιορισμένων μετρήσεων από PMUs στους κλάδους 6-22.

	NN		GNN	
	MAPE	MAE	MAPE	MAE
Όλα τα PMUs	0.046	0.035	0.020	0.014
6 & 22	0.100	0.073	0.026	0.021

Σενάριο 1: Με χρήση Όλων των Δεδομένων


Στο πρώτο σενάριο, το GNN υπερείχε σημαντικά του NN, παρουσιάζοντας μειωμένα σφάλματα MAPE και MAE. Η ανώτερη απόδοση του GNN μπορεί να αποδοθεί στη δομή του, η οποία λαμβάνει υπόψη τις συνδέσεις και τις σχέσεις μεταξύ των κόμβων του Δικτύου, σε αντίθεση με το NN που επεξεργάζεται τα δεδομένα σε επίπεδο χαρακτηριστικών χωρίς να εκμεταλλεύεται την τοπολογία του Δικτύου.

Η διαφορά στις επιδόσεις είναι στατιστικά σημαντική. Συγκεκριμένα, το GNN παρουσίασε περίπου **130% υψηλότερη ακρίβεια στο MAPE** και **150% υψηλότερη ακρίβεια στο MAE** συγκριτικά με το NN. Αυτά τα αποτελέσματα αναδεικνύουν την ικανότητα των GNN να αναγνωρίζουν μοτίβα και σχέσεις σε δεδομένα Δικτύου.



Σενάριο 2: Με χρήση δύο PMUs

Όταν περιορίστηκαν οι διαθέσιμες μετρήσεις σε δύο PMUs, το GNN διατήρησε και βελτίωσε την ακρίβειά του σε υψηλά επίπεδα, ενώ το NN παρουσίασε σημαντική υποβάθμιση της απόδοσης. Το GNN πέτυχε **230% υψηλότερη ακρίβεια στο MAPE και 247% υψηλότερη ακρίβεια** σε σχέση με το NN, συνεπώς αγγίζει τα όρια του τετραπλασιασμού απόδοσης. Η υποβάθμιση της απόδοσης του NN υποδηλώνει ότι η προσβασιμότητα σε πλήρη δεδομένα είναι κρίσιμη για τη λειτουργία του. Αντίθετα, το GNN μπορεί να ξεπερνά αυτά τα εμπόδια αφού αξιοποίησε τη τοπολογία του Δικτύου, ενισχύοντας την ακρίβειά του παρά τον περιορισμένο αριθμό PMUs.



5.5.2. Σύγκριση Ανίχνευσης τοπολογίας

	NN	GNN
PMUs No 3 & 12	97,65	99,23%
Όλα τα PMUs accuracy	99,12	100%

Στην ανίχνευση τοπολογίας, το GNN απέδωσε βέλτιστα, φτάνοντας το 100% ακρίβεια με όλα τα δεδομένα. Ακόμη και όταν περιορίστηκαν οι μετρήσεις στους κλάδους 3 και 12, το GNN παρουσίασε μικρή μόνο μείωση της ακρίβειας, παραμένοντας στο 99.26%. Από την άλλη, το NN παρουσίασε μείωση της ακρίβειας όταν οι μετρήσεις περιορίστηκαν, καταλήγοντας στο 97.65%. Τα αποτελέσματα αυτά δείχνουν τη σαφή υπεροχή του GNN στην αναγνώριση της τοπολογίας του Δικτύου, ειδικά σε συνθήκες περιορισμένων δεδομένων.

5.5.3. Συμπέρασμα

Η ανάλυση των αποτελεσμάτων καταδεικνύει σαφώς ότι τα GNN υπερτερούν των NN στις συγκεκριμένες εφαρμογές. Αυτή η υπεροχή αποδίδεται στους εξής παράγοντες:

- Αξιοποίηση Τοπολογίας Δικτύου:** Τα GNNs μοντελοποιούν τις σχέσεις μεταξύ των κόμβων και των ακμών του Δικτύου. Σε ένα ηλεκτρικό Δίκτυο, όπου οι συνδέσεις μεταξύ των κόμβων αντιπροσωπεύουν φυσικές γραμμές μεταφοράς, αυτή η ιδιότητα προσδίδει στα GNNs σαφές πλεονέκτημα.
- Ανθεκτικότητα σε Περιορισμένα Δεδομένα:** Σε σενάρια με μειωμένες μετρήσεις, το GNN εξακολουθεί να αποδίδει με ακρίβεια, ενώ το NN επηρεάζεται σημαντικά λόγω της εξάρτησής του από πλήρη δεδομένα εισόδου.

3. **Εκμάθηση Μοτίβων:** Τα GNNs μαθαίνουν τα μοτίβα των δεδομένων όχι μόνο σε επίπεδο χαρακτηριστικών, αλλά και σε επίπεδο Δικτύου. Αυτή η ιδιότητα είναι κρίσιμη σε εφαρμογές που αφορούν Δίκτυα διανομής, όπου οι αλληλεπιδράσεις μεταξύ των κόμβων είναι σημαντικές για την ακρίβεια των προβλέψεων.
4. **Βελτιστοποίηση Πληροφοριών:** Τα GNNs ενσωματώνουν πληροφορίες γειτονικών κόμβων μέσω των layers τους, ενώ το NN λειτουργεί αυτόνομα για κάθε δεδομένο εισόδου, χωρίς να λαμβάνει υπόψη τις σχέσεις μεταξύ των κόμβων.

6. Μελλοντικές προεκτάσεις

Η αναγνώριση της ανωτερότητας των GNNs έναντι των παραδοσιακών Νευρωνικών Δικτύων στις προκλήσεις των δικτύων διανομής ηλεκτρικής ενέργειας ανοίγει νέους ορίζοντες στη χρήση τους, τόσο στο συγκεκριμένο πεδίο όσο και σε ένα ευρύτερο πλαίσιο εφαρμογών.

Η δυνατότητα των GNNs να αποδίδουν εξαιρετικά σε σύνθετα Δίκτυα με τοπολογικές ιδιαιτερότητες προσφέρει σημαντικά πλεονεκτήματα στον σχεδιασμό, τη διαχείριση και τη λειτουργία των σύγχρονων συστημάτων ηλεκτρικής ενέργειας. Πιο συγκεκριμένα, η ικανότητα των GNN να εκμεταλλεύονται τη δομή των δικτύων καθιστά δυνατή τη βελτίωση της ανίχνευσης σφαλμάτων, της παρακολούθησης των δικτύων σε πραγματικό χρόνο, καθώς και της αποδοτικής κατανομής των πόρων. Σε ένα Δίκτυο διανομής, όπου οι φυσικές συνδέσεις μεταξύ των κόμβων αντιπροσωπεύουν γραμμές μεταφοράς, τα GNNs μπορούν να παρέχουν ακριβέστερες προβλέψεις για τις τιμές των ηλεκτρικών μεγεθών, ακόμα και υπό συνθήκες περιορισμένων δεδομένων. Αυτό είναι ιδιαίτερα χρήσιμο για την ανάπτυξη συστημάτων αυτοματοποιημένης αποκατάστασης βλαβών, τα οποία απαιτούν άμεση και αξιόπιστη πληροφόρηση για τη λήψη αποφάσεων. Συγκεκριμένα θα μπορούσε να περιοριστεί το κόστος

εξοπλισμού μιας επιχείρησης σε PMUs και να αντικατασταθεί με λιγότερους μετρητές οι οποίοι χάρη στο μοντέλο θα αποδίδουν σαν να είναι πολλοί περισσότεροι.

Επιπλέον, η χρήση GNN μπορεί να διευκολύνει τη βελτιστοποίηση του ενεργειακού μείγματος μέσω πιο αποδοτικής ενσωμάτωσης ανανεώσιμων πηγών ενέργειας, όπως η ηλιακή και η αιολική ενέργεια, οι οποίες εμφανίζουν στοχαστική συμπεριφορά (μη σταθερή παραγωγή) [81]. Με τη χρήση GNN, οι φορείς ενέργειας μπορούν να αναπτύξουν πιο εύελικτα μοντέλα πρόβλεψης φορτίου και παραγωγής, εξασφαλίζοντας καλύτερη ισορροπία μεταξύ προσφοράς και ζήτησης. Παράλληλα, η ενίσχυση της ακρίβειας στην ανίχνευση τοπολογίας μπορεί να υποστηρίξει την ανάπτυξη έξυπνων δικτύων (smart grids) με δυνατότητες αυτοπαρακολούθησης και αυτοβελτιστοποίησης. Αυτά τα Δίκτυα θα είναι σε θέση να λειτουργούν αποτελεσματικά σε συνθήκες αυξημένης πολυπλοκότητας, παρέχοντας πιο αξιόπιστες υπηρεσίες στους καταναλωτές και μειώνοντας το κόστος λειτουργίας και συντήρησης.

Η προσαρμοστικότητα των GNNs, ωστόσο, δεν περιορίζεται στα Δίκτυα διανομής ηλεκτρικής ενέργειας. Οι ίδιες αρχές μπορούν να εφαρμοστούν σε άλλα είδη δικτύων, όπως τα Δίκτυα επικοινωνιών, τα κοινωνικά Δίκτυα, και τα Δίκτυα μεταφορών. Στα Δίκτυα επικοινωνιών, τα GNNs μπορούν να βελτιώσουν την κατανόηση και τη διαχείριση των τοπολογιών, επιτρέποντας την αποτελεσματική κατανομή εύρους ζώνης, τη βελτίωση της ποιότητας των υπηρεσιών, και την αποδοτικότερη δρομολόγηση δεδομένων. Σε κοινωνικά Δίκτυα, τα GNNs μπορούν να χρησιμοποιηθούν για την ανάλυση σύνθετων σχέσεων μεταξύ χρηστών, τη βελτίωση της στόχευσης περιεχομένου, ή ακόμα και την ανίχνευση κακόβουλων δραστηριοτήτων. Αντίστοιχα, στα Δίκτυα μεταφορών, η εφαρμογή τους μπορεί να συμβάλει στη διαχείριση της κυκλοφορίας σε πραγματικό χρόνο, στη βελτίωση της απόδοσης των logistics, και στη διαχείριση στόλων οχημάτων [82].

Μια άλλη πιθανή εφαρμογή αφορά τα συστήματα υγειονομικής περίθαλψης, όπου μπορούν να χρησιμοποιηθούν για την ανάλυση σύνθετων δεδομένων που σχετίζονται με τη δομή και τη λειτουργία του ανθρώπινου σώματος. Για παράδειγμα, μπορούν να συμβάλουν στην ανάλυση αλληλεπιδράσεων πρωτεϊνών, στη μοντελοποίηση δικτύων νευρώνων, και στη βελτίωση της κατανόησης των ασθενειών σε μοριακό επίπεδο. Παράλληλα, μπορούν να υποστηρίξουν την εξατομικευμένη ιατρική, παρέχοντας μοντέλα πρόβλεψης για την απόκριση σε θεραπείες ή τον κίνδυνο εμφάνισης παθήσεων [83].

Σε ευρύτερο επιστημονικό και τεχνολογικό επίπεδο, μπορούν να υποστηρίξουν την πρόοδο σε τομείς όπως η Μηχανική Μάθηση και η Τεχνητή Νοημοσύνη. Οι εφαρμογές των

GNNs στη ρομποτική, για παράδειγμα, μπορούν να ενισχύσουν τη δυνατότητα των ρομπότ να πλοηγούνται σε πολύπλοκα περιβάλλοντα ή να αλληλεπιδρούν με άλλα ρομπότ με τρόπο που λαμβάνει υπόψη τη δυναμική του περιβάλλοντος [84]. Στην ανάλυση δεδομένων, μπορούν να αποτελέσουν πολύτιμο εργαλείο για την αναγνώριση μοτίβων σε Δίκτυα, παρέχοντας νέες δυνατότητες στην επεξεργασία φυσικής γλώσσας, την οπτική αναγνώριση, και τη βελτίωση των συστημάτων σύστασης.

Μια εξίσου ενδιαφέρουσα προοπτική είναι η συμβολή τους στη διαχείριση κρίσεων και στην πρόβλεψη φυσικών καταστροφών. Μέσω της ικανότητάς τους να επεξεργάζονται δεδομένα που σχετίζονται με γεωγραφικές και περιβαλλοντικές τοπολογίες, τα GNNs δύναται να ενισχύσουν την κατανόηση των φυσικών φαινομένων και να βελτιώσουν τη διαχείριση κινδύνων. Παρόμοια, σε περιπτώσεις δικτύων νερού ή αερίου, μπορούν να χρησιμοποιηθούν για την ανίχνευση διαρροών, τη βελτιστοποίηση της χρήσης πόρων, και την πρόβλεψη βλαβών [85].

Συνοψίζοντας, οι μελλοντικές προεκτάσεις της χρήσης GNN είναι σχεδόν απεριόριστες. Η αποδεδειγμένη υπεροχή τους σε τοπολογικά δεδομένα τα καθιστά ιδανικά για οποιαδήποτε εφαρμογή περιλαμβάνει Δίκτυα, από τα φυσικά συστήματα έως τα κοινωνικά και τεχνητά Δίκτυα. Παρότι βρίσκονται ακόμα σε φάση εξέλιξης, οι δυνατότητές τους προμηνύουν ριζικές αλλαγές στον τρόπο με τον οποίο επεξεργάζονται και αξιοποιούνται τα δεδομένα.

7. Βιβλιογραφία

[1] ScienceDirect, “Electric power systems.” [Online]. Available: <https://www.sciencedirect.com/topics/engineering/electric-power-systems>. [Accessed: Mar. 17, 2025].

[2] Κ. Γ. Βουρνάς, *Εισαγωγή στα Συστήματα Ηλεκτρικής Ενέργειας*, Αθήνα: ΕΜΠ, 2001.

[3] Iberdrola, “Difference between high, medium, and low voltage.” [Online]. Available: <https://www.iberdrola.com/about-us/what-we-do/smart-grids/difference-high-medium-low-voltage>. [Accessed: Mar. 17, 2025].

[4] Your Electrical Guide, “Power transmission and distribution.” [Online]. Available: <https://www.yourelectricalguide.com/p-power-transmission-and-distribution-html>. [Accessed: Mar. 17, 2025].

[5] Electrical Engineering Portal, “Fundamentals of electrical distribution.” [Online]. Available: <https://electrical-engineering-portal.com/download-center/books-and-guides/electrical-engineering/fundamentals-of-electrical-distribution>. [Accessed: Mar. 17, 2025].

[6] Electrical India, “Phasor measurement units for power systems.” [Online]. Available: <https://www.electricalindia.in/phasor-measurement-units-for-power-systems/>. [Accessed: Mar. 17, 2025].

[7] A. G. Phadke and J. S. Thorp, *Synchronized Phasor Measurements and Their Applications*, Springer Science & Business Media, 2008.

[8] A. L. Moffat, M. Robinson, and S. Peisert, “Micro-synchrophasors for distribution systems,” *The Electricity Journal*, vol. 31, no. 1, pp. 26–34, 2018.

[9] M. Johnson, “The Newton-Raphson method and power flow calculations,” in *Modern Algorithms and Applications in Electrical Power Systems*, pp. 89–101, Feb. 2022.

[10] Encyclopedia.pub, “Overview of power system state estimation.” [Online]. Available: <https://encyclopedia.pub/entry/37777>. [Accessed: Mar. 17, 2025].

[11] ResearchGate, “Overview of state estimation technique for power system control.” [Online]. Available: https://www.researchgate.net/publication/271257810_Overview_of_State_Estimation_Technique_for_Power_System_Control. [Accessed: Mar. 17, 2025].

[12] G. Cavraro, R. Arghandeh, G. Barchi, et al., “Distribution network topology detection with time series measurements,” in *Proc. 2015 IEEE Power & Energy Society Innovative Smart Grid Technologies Conf. (ISGT)*, Washington, DC, USA, pp. 1–5, Feb. 2015.

[13] MDPI, “Power system state estimation and monitoring.” [Online]. Available: <https://www.mdpi.com/2079-9292/11/1/71>. [Accessed: Mar. 17, 2025].

[14] D. Nikos, “Beyond state estimation: Topology estimation in power systems,” *Journal of Power System Analysis and Control*, pp. 134–145, Mar. 2023.

- [15] F. Blaabjerg and S. B. Kjaer, “Power electronics as efficient interface in dispersed power generation,” *IEEE Transactions on Power Electronics*, vol. 21, no. 5, pp. 1372–1381, 2006.
- [16] R. H. Lasseter and P. Paevere, “Microgrids and distributed generation,” in *IEEE Power Engineering Society Summer Meeting*, vol. 1, pp. 305–308, 2004.
- [17] H. Sheikh, C. Prins, and E. Schrijvers, “Artificial intelligence: Definition and background,” pp. 15–41, 2023. doi: 10.1007/978-3-031-21448-6_2.
- [18] J. Bell, “What is machine learning?,” *Machine Learning and the City*, pp. 207–216, May 2022, doi: 10.1002/9781119815075.CH18.
- [19] A. Smith, “Introduction to artificial intelligence,” *AI and Society*, pp. 145–158, Mar. 2023, doi: 10.1002/9781234567890.CH12.
- [20] Ν. Παπαδόπουλος, “Επιβλεπόμενη μάθηση στα τεχνητά νευρωνικά δίκτυα,” *Τεχνητή Νοημοσύνη και Εφαρμογές*, σσ. 102–115, Ιαν. 2024.
- [21] Stanford Deep Learning, “Supervised learning in multilayer neural networks.” [Online]. Available: <http://deeplearning.stanford.edu/tutorial/supervised/MultiLayerNeuralNetworks/>. [Accessed: Mar. 17, 2025].
- [22] I. Goodfellow, Y. Bengio, and A. Courville, *Multilayer Neural Networks: Theory and Applications in Deep Learning*, MIT Press, 2016.
- [23] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
- [24] A. Paszke *et al.*, “PyTorch: An imperative style, high-performance deep learning library,” 2019.
- [25] Z. Zhang, P. Cui, and W. Zhu, “Deep learning on graphs: A survey,” *IEEE Transactions on Knowledge and Data Engineering*, vol. 34, no. 1, pp. 249–270, 2020.
- [26] Kipf, T. N., & Welling, M. (2017). "Semi-Supervised Classification with Graph Convolutional Networks." 2017.

[27] K. He, X. Zhang, S. Ren, and J. Sun, “Deep Residual Learning for Image Recognition,” *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016.

[28] D. P. Kingma and J. Ba, “Adam: A Method for Stochastic Optimization,” *International Conference on Learning Representations (ICLR)*, 2015.

[29] G. Hinton, N. Srivastava, and K. Swersky, “Neural Networks for Machine Learning,” *Lecture Notes*, University of Toronto, 2012.

[30] X. Glorot, A. Bordes, and Y. Bengio, “Deep Sparse Rectifier Neural Networks,” *Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics (AISTATS)*, 2011.

[31] L. Bottou, “Large-Scale Machine Learning with Stochastic Gradient Descent,” *Proceedings of the International Conference on Computational Statistics*, 2010.

[32] S. Ioffe and C. Szegedy, “Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift,” *Proceedings of the 32nd International Conference on Machine Learning (ICML)*, 2015.

[33] IBM, “What are convolutional neural networks?,” *IBM Topics*. [Online]. Available: <https://www.ibm.com/topics/convolutional-neural-networks>. [Accessed: Mar. 2025].

[34] S. Albawi, T. A. Mohammed, and S. Al-Zawi, “Understanding of a convolutional neural network,” in *2017 International Conference on Engineering and Technology (ICET)*, Antalya, Turkey, 2017, pp. 1–6, doi: 10.1109/ICEngTechnol.2017.8308186.

[35] Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *Proceedings of the International Conference on Machine Learning (ICML)*, 1–14.

[36] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “ImageNet Classification with Deep Convolutional Neural Networks,” *Communications of the ACM*, vol. 60, no. 6, pp. 84–90, Nov. 2017, doi: 10.1145/3065386.

[37] J. Zhou et al., “Graph Neural Networks: A Review of Methods and Applications,” *AI Open*, vol. 1, pp. 57–81, 2020.

[38] T. Kipf and M. Welling, “Semi-Supervised Classification with Graph Convolutional Networks,” *ICLR*, 2017.

[39] “A typical and basic architecture and processing procedures of GNN. First, GNN selects...,” *ResearchGate*. [Online]. Available: https://www.researchgate.net/figure/A-typical-and-basic-architecture-and-processing-procedures-of-GNN-First-GNN-selects_fig2_352526255. [Accessed: Mar. 17, 2025].

[40] Z. Wu, S. Pan, F. Chen, G. Long, C. Zhang, and S. Y. Philip, “A comprehensive survey on graph neural networks,” *IEEE Trans. on Neural Networks and Learning Systems*, vol. 32, no. 1, pp. 4–24, 2020.

[41] A. Abur and A. Gomez-Exposito, *Power System State Estimation: Theory and Implementation*, CRC Press, 2004.

[42] F. C. Schweppe and J. Wildes, “Power system static-state estimation, Part I: Exact model,” *IEEE Trans. on Power Apparatus and Systems*, vol. PAS-89, no. 3, pp. 1200–1206, 1970.

[43] F. C. Schweppe and J. Wildes, “Power system static-state estimation, Part I: Exact model,” *IEEE Trans. on Power Apparatus and Systems*, vol. PAS-89, no. 3, pp. 1200–1206, 1970.

[44] J. Zhao *et al.*, “Power system state estimation using neural networks: A comprehensive review,” *Electric Power Systems Research*, 2019.

[45] Y. Du *et al.*, “Topology identification in power grids: Machine learning approaches,” *IEEE Access*, 2020.

[46] Z. Chen, L. Wu, and B. Zhang, “Topology-aware graph neural networks for power grid monitoring,” *IEEE Trans. on Smart Grid*, vol. 12, no. 1, pp. 365–375, 2021.

[47] T. N. Kipf and M. Welling, “Semi-supervised classification with graph convolutional networks,” in *Proc. of the International Conference on Learning Representations (ICLR)*, 2017.

[48] J. Zhou, G. Cui, Z. Zhang, C. Yang, Z. Liu, L. Wang, C. Li, and M. Sun, “Graph neural networks: A review of methods and applications,” *AI Open*, vol. 1, pp. 57–81, 2020.

[49] M. M. Bronstein, J. Bruna, T. Cohen, and P. Veličković, “Geometric deep learning: Grids, graphs, groups, geodesics, and gauges,” *Commun. ACM*, vol. 64, no. 12, pp. 62–71, 2021.

[50] “Evaluating accuracy (or error) measures for model selection,” *Int. J. Forecasting*, vol. 9, no. 4, pp. 527–529.

[51] R. J. Hyndman and A. B. Koehler, “Another look at measures of forecast accuracy,” *Int. J. Forecasting*, vol. 22, no. 4, pp. 679–688, 2006.

[52] “Understanding the number of hidden layers in neural networks: A comprehensive guide,” *Medium*, [Online]. Available: https://medium.com/@sanjay_dutta/understanding-the-number-of-hidden-layers-in-neural-networks-a-comprehensive-guide-0c3bc8a5dc5d. [Accessed: Oct. 2024].

[53] Z. Wu, S. Pan, F. Chen, G. Long, and C. Zhang, “A comprehensive survey on graph neural networks,” 2019.

[54] T. N. Kipf and M. Welling, “Semi-supervised classification with graph convolutional networks,” *Proc. of the International Conference on Learning Representations (ICLR)*, 2016.

[55] M. E. Baran and F. F. Wu, “Optimal capacitor placement on radial distribution systems,” *IEEE Trans. Power Delivery*, vol. 4, no. 1, pp. 725–734, 1989.

[56] R. D. Zimmerman, C. E. Murillo-Sánchez, and R. J. Thomas, “MATPOWER: Steady-state operations, planning, and analysis tools for power systems research and education,” *IEEE Trans. Power Systems*, vol. 26, no. 1, pp. 12–19, 2011.

[57] G. Ruan and F. Li, “Deep learning for power system data analysis: A comprehensive review,” *CSEE J. Power Energy Systems*, vol. 6, no. 4, pp. 864–878, 2020.

[58] “Noise injection in power system data for model robustness,” *J. Electr. Eng.*, vol. 56, no. 3, pp. 123–135, 2022.

[59] “Impact of noise injection on power system data accuracy and model performance,” *Electric Power Systems Research*, vol. 137, pp. 105–115, 2021.

[60] H. Saadat, *Power System Analysis*, 3rd ed., McGraw-Hill Education, 2010, pp. 280–310, ISBN: 9780071831284.

- [61] G. Van Rossum and F. L. Drake, *The Python Language Reference Manual*, CreateSpace, 2009.
- [62] C. R. Harris et al., “Array programming with NumPy,” *Nature*, vol. 585, no. 7825, pp. 357–362, 2020.
- [63] Microsoft, “Visual Studio Code – Official Documentation,” Microsoft, 2021. [Online]. Available: <https://code.visualstudio.com/docs>. [Accessed: Oct. 2024].
- [64] “Pandas documentation,” [Online]. Available: <https://pandas.pydata.org/docs/>. [Accessed: Oct. 2024].
- [65] G. Hinton and R. Salakhutdinov, “Reducing the dimensionality of data with neural networks,” *Science*, vol. 313, no. 5786, pp. 504–507, 2006, doi: 10.1126/science.1127647.
- [66] I. Y. LeCun, Y. Bengio, and G. Hinton, “Deep Learning,” *Nature*, vol. 521, no. 7553, pp. 436–444, 2015, doi: 10.1038/nature14539.
- [67] A. Ng, “Feature selection, L1 vs. L2 regularization, and rotational invariance,” in *Proceedings of the 21st International Conference on Machine Learning (ICML)*, Banff, Alberta, Canada, pp. 78–85, 2004, doi: 10.1145/1015330.1015435.
- [68] T. N. Kipf and M. Welling, “Semi-supervised classification with graph convolutional networks,” in *Proceedings of the 5th International Conference on Learning Representations (ICLR)*, San Juan, Puerto Rico, 2016.
- [69] Ma, Y., & Tang, J. (2018). *Deep Learning on Graphs*. In *Proceedings of the 21st International Conference on Machine Learning (ICML)*, Banff, Alberta, Canada (pp. 78–85). doi: 10.1145/1015330.1015435.
- [70] S. Haykin, *Neural Networks and Learning Machines*, 3rd ed., Prentice Hall, 2008.
- [71] Q. Zhou and A. Abur, “Optimal placement of PMUs for state estimation,” *IEEE Trans. Power Syst.*, vol. 23, no. 3, pp. 1608–1616, 2008.
- [72] B. Gou, “Optimal placement of PMUs by integer linear programming,” *IEEE Trans. Power Syst.*, vol. 23, no. 3, pp. 1525–1526, 2008.
- [73] H. Zhang and F. Li, “An integrated neural network approach for state estimation in power systems,” *IEEE Trans. Power Syst.*, vol. 25, no. 3, pp. 1469–1479, 2010.

[74] P. Kundur, N. J. Balu, and M. G. Lauby, *Power System Stability and Control*, McGraw-Hill, 1994.

[75] S. Ioffe and C. Szegedy, “Batch normalization: Accelerating deep network training by reducing internal covariate shift,” in *Proceedings of the 32nd International Conference on Machine Learning (ICML)*, Lille, France, 2015.

[76] W. Liao, B. Bak-Jensen, J. R. Pillai, Y. Wang, and Y. Wang, “A review of graph neural networks and their applications in power systems,” *IEEE Access*, vol. 9, pp. 19142–19156, 2021.

[77] L. Gong and Q. Cheng, “Exploiting edge features in graph neural networks,” *IEEE Transactions on Neural Networks and Learning Systems*, 2018.

[78] H. Gao, Z. Wang, and S. Ji, “Large-scale learnable graph convolutional networks,” in *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2018, pp. 1416–1424, doi: 10.1145/3219819.3220077.

[79] P. W. Battaglia et al., “Relational inductive biases, deep learning, and graph networks,” *arXiv preprint arXiv:1806.01261*, 2018.

[80] M. Fey and P. Lenske, “PyTorch Geometric: A deep learning library for graph-structured data,” *arXiv preprint arXiv:2003.02103*, 2020.

[81] M. Korkali, G. K. Venayagamoorthy, D. C. Wunsch, and R. G. Harley, “Power system stabilizer design using differentiable neural networks,” *IEEE Transactions on Power Systems*, vol. 26, no. 4, pp. 2557–2566, 2011.

[82] J. Gilmer et al., “Neural message passing for quantum chemistry,” in *Proceedings of the 34th International Conference on Machine Learning (ICML)*, 2017, vol. 70, pp. 1263–1272.

[83] D. Duvenaud, D. Maclaurin, J. Aguilera-Iparraguirre, et al., “Convolutional networks on graphs for learning molecular fingerprints,” in *Proceedings of the 28th International Conference on Neural Information Processing Systems (NeurIPS)*, Montreal, Canada, 2015.

[84] J. Gilmer, S. S. Schoenholz, D. Duvenaud, et al., “Neural message passing for quantum chemistry,” *Proceedings of the 34th International Conference on Machine Learning (ICML)*, 2017, vol. 70, pp. 1263–1272.

[85] F. Monti et al., “Geometric deep learning on graphs and manifolds using MixEuclidean CNNs,” *Proceedings of the 34th International Conference on Machine Learning (ICML)*, 2017.