



ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΙΑΣ

ΠΟΛΥΤΕΧΝΙΚΗ ΣΧΟΛΗ

ΤΜΗΜΑ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

**Εφαρμογή Τεχνητής Νοημοσύνης στην Ανίχνευση και Διαχείριση
Βλαβών σε Ηλεκτρικά Δίκτυα**

Μεταπτυχιακή Διπλωματική Εργασία

Αμπατζής Αντώνιος

Επιβλέπουσα: Δασκαλοπούλου Ασπασία

Ιούνιος 2025



ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΙΑΣ

ΠΟΛΥΤΕΧΝΙΚΗ ΣΧΟΛΗ

ΤΜΗΜΑ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ


**Εφαρμογή Τεχνητής Νοημοσύνης στην Ανίχνευση και Διαχείριση
Βλαβών σε Ηλεκτρικά Δίκτυα**

Μεταπτυχιακή Διπλωματική Εργασία

Αμπατζής Αντώνιος

Επιβλέπουσα: Δασκαλοπούλου Ασπασία

Ιούνιος 2025



UNIVERSITY OF THESSALY

SCHOOL OF ENGINEERING

DEPARTMENT OF ELECTRICAL AND COMPUTER ENGINEERING

**Application of Artificial Intelligence in Fault Detection and
Management in Electricity Grids**

MSc Thesis

Ampatzis Antonios

Supervisor: Daskalopulu Aspasia

June 2025

Εγκρίνεται από την Επιτροπή Εξέτασης:

Επιβλέπουσα

Δασκαλοπούλου Ασπασία

Αναπληρώτρια Καθηγήτρια, Τμήμα Ηλεκτρολόγων Μηχανικών και
Μηχανικών Υπολογιστών, Πανεπιστήμιο Θεσσαλίας

Μέλος

Μπαργιώτας Δημήτριος

Καθηγητής, Τμήμα Ηλεκτρολόγων Μηχανικών και Μηχανικών
Υπολογιστών, Πανεπιστήμιο Θεσσαλίας

Μέλος

Χροναίος Αλέξανδρος

Καθηγητής, Τμήμα Ηλεκτρολόγων Μηχανικών και Μηχανικών
Υπολογιστών, Πανεπιστήμιο Θεσσαλίας

ΥΠΕΥΘΥΝΗ ΔΗΛΩΣΗ ΠΕΡΙ ΑΚΑΔΗΜΑΪΚΗΣ ΔΕΟΝΤΟΛΟΓΙΑΣ ΚΑΙ ΠΝΕΥΜΑΤΙΚΩΝ ΔΙΚΑΙΩΜΑΤΩΝ

Με πλήρη επίγνωση των συνεπειών του νόμου περί πνευματικών δικαιωμάτων, δηλώνω ρητά ότι η παρούσα μεταπτυχιακή διπλωματική εργασία, καθώς και τα ηλεκτρονικά αρχεία και πηγαίοι κώδικες που αναπτύχθηκαν ή τροποποιήθηκαν στα πλαίσια αυτής της εργασίας, αποτελούν αποκλειστικά προϊόν προσωπικής μου εργασίας, δεν προσβάλλουν οποιασδήποτε μορφής δικαιώματα διανοητικής ιδιοκτησίας, προσωπικότητας και προσωπικών δεδομένων τρίτων, δεν περιέχουν έργα/εισφορές τρίτων για τα οποία απαιτείται άδεια των δημιουργών/δικαιούχων και δεν είναι προϊόν μερικής ή ολικής αντιγραφής, οι πηγές δε που χρησιμοποιήθηκαν περιορίζονται στις βιβλιογραφικές αναφορές και μόνον και πληρούν τους κανόνες της επιστημονικής παράθεσης. Τα σημεία όπου έχω χρησιμοποιήσει ιδέες, κείμενο, αρχεία ή/και πηγές άλλων συγγραφέων αναφέρονται ευδιάκριτα στο κείμενο με την κατάλληλη παραπομπή και η σχετική αναφορά περιλαμβάνεται στο τμήμα των βιβλιογραφικών αναφορών με πλήρη περιγραφή. Δηλώνω επίσης ότι τα αποτελέσματα της εργασίας δεν έχουν χρησιμοποιηθεί για την απόκτηση άλλου πτυχίου. Αναλαμβάνω πλήρως, ατομικά και προσωπικά, όλες τις νομικές και διοικητικές συνέπειες που δύναται να προκύψουν στην περίπτωση κατά την οποία αποδειχθεί, διαχρονικά, ότι η εργασία αυτή ή τμήμα της δεν μου ανήκει διότι είναι προϊόν λογοκλοπής.

Ο Δηλών

Αμπατζής Αντώνιος

DISCLAIMER ON ACADEMIC ETHICS AND INTELLECTUAL PROPERTY RIGHTS

Being fully aware of the implications of copyright laws, I expressly state that this MSc thesis, as well as the electronic files and source codes developed or modified in the course of this thesis, are solely the product of my personal work and do not infringe any rights of intellectual property, personality and personal data of third parties, do not contain work / contributions of third parties for which the permission of the authors / beneficiaries is required and are not a product of partial or complete plagiarism, while the sources used are limited to the bibliographic references only and meet the rules of scientific citing. The points where I have used ideas, text, files and / or sources of other authors are clearly mentioned in the text with the appropriate citation and the relevant complete reference is included in the bibliographic references section. I also declare that the results of the work have not been used to obtain another degree. I fully, individually and personally undertake all legal and administrative consequences that may arise in the event that it is proven, in the course of time, that this thesis or part of it does not belong to me because it is a product of plagiarism.

The Declarant

Ampatzis Antonios

Ευχαριστίες

Η παρούσα διπλωματική εργασία αφιερώνεται στους γονείς μου, οι οποίοι με έχουν στηρίξει ανελλιπώς, τόσο ψυχολογικά όσο και συναισθηματικά σε κάθε βήμα της ζωής μου. Επιπλέον, ευχαριστώ την επιβλέπουσα καθηγήτριά μου κα Ασπασία Δασκαλοπούλου για τον χρόνο που αφιέρωσε για την επίβλεψη και παρακολούθηση αυτής της Μεταπτυχιακής εργασίας, αλλά και για τα εύστοχα σχόλια και παρατηρήσεις της. Τέλος, ευχαριστώ τα μέλη της επιτροπής κ. Μπαργιώτα Δημήτριο και κ. Χροναίο Αλέξανδρο για τη συμβολή τους στην εξέταση αυτής της εργασίας.

Εφαρμογή Τεχνητής Νοημοσύνης στην Ανίχνευση και Διαχείριση Βλαβών σε Ηλεκτρικά Δίκτυα

Αμπατζής Αντώνιος

Περίληψη

Η ανίχνευση και απομόνωση σφαλμάτων (Fault Detection and Isolation – FDI) αποτελεί κρίσιμο σκέλος για τη διασφάλιση της ασφάλειας, της αξιοπιστίας και της αποδοτικής λειτουργίας των βιομηχανικών συστημάτων. Η παρούσα διπλωματική εργασία διεξάγει βιβλιογραφική επισκόπηση σχετικά με την ανάπτυξη, υλοποίηση και αξιολόγηση προηγμένων μεθόδων ευφυούς διάγνωσης σφαλμάτων σε δύο διαφορετικά βιομηχανικά περιβάλλοντα: σε ηλεκτρομαγνητικά συστήματα ανάρτησης (EMS) και σε δίκτυα δεξαμενών νερού με ισχυρές τοπολογικές αλληλεπιδράσεις. Συγκεκριμένα, παρουσιάζεται η αξιολόγηση και υλοποίηση ενός υβριδικού συστήματος τύπου iFD (Intelligent Fault Detection) για το EMS, το οποίο αξιοποιεί έναν εκτιμητή βάσει Νευρωνικού Δικτύου και Μηχανισμού Λήψης Απόφασης, παρέχοντας ανθεκτικότητα σε διάφορους τύπους σφαλμάτων αισθητήρων και ενεργοποιητών. Επιπλέον, χρησιμοποιείται η αρχιτεκτονική GCNN (Graph Convolutional Neural Network) σε βιομηχανικό δίκτυο δεξαμενών για εντοπισμό σφαλμάτων μέσω ταξινόμησης κόμβων, αξιοποιώντας τη χωρική πληροφορία του γραφήματος. Παράλληλα, αξιολογούνται και υλοποιούνται απλούστερες μοντελοποιήσεις, όπως το πολυεπίπεδο Νευρωνικό Δίκτυο MLP (Multi-Layer Perceptron), καθώς και τα CNF (Concurrent Neuro Fuzzy), τα οποία προσφέρουν σημαντικά πλεονεκτήματα σε απλότερα περιβάλλοντα ή σε εφαρμογές πραγματικού χρόνου με περιορισμένο υπολογιστικό φορτίο. Αναλύονται διεξοδικά η θεωρητική θεμελίωση, η μεθοδολογία υλοποίησης, η αρχιτεκτονική κάθε συστήματος, καθώς και τα χαρακτηριστικά των δεδομένων εισόδου και οι παράμετροι εκπαίδευσης. Τα πειραματικά αποτελέσματα των μελετών που εξετάζει η παρούσα εργασία αποδεικνύουν ότι η μέθοδος GCNN ξεπερνά σε ακρίβεια και γενίκευση τις παραδοσιακές μεθόδους (π.χ.

πλήρως συνδεδεμένα Νευρωνικά Δίκτυα), ενώ η iFD παρουσιάζει υψηλή αξιοπιστία σε πραγματικό χρόνο και δυνατότητα επαναδιαμόρφωσης του ελεγκτή κατά την εμφάνιση σφαλμάτων. Αντίστοιχα, οι μέθοδοι CNF και MLP παρουσιάζουν εξαιρετική συμπεριφορά σε περιπτώσεις γραμμικών ή ελαφρώς μη γραμμικών συστημάτων, με ταχύτατο χρόνο απόκρισης και χαμηλό υπολογιστικό κόστος. Συνολικά, η εργασία τεκμηριώνει τη δυνατότητα υιοθέτησης των προτεινόμενων αρχιτεκτονικών σε απαιτητικά βιομηχανικά περιβάλλοντα, ενώ καταλήγει σε συγκριτική αξιολόγηση ως προς την ακρίβεια, το χρόνο αντίδρασης και την ευελιξία.

Λέξεις-κλειδιά:

Τεχνητή Νοημοσύνη, Νευρωνικά Δίκτυα, Μηχανική Μάθηση, Ηλεκτρικά Δίκτυα, Ανίχνευση Βλαβών, Διαχείριση Βλαβών, Αλγόριθμοι, Προληπτική Συντήρηση, Αυτοματοποίηση, Αξιοπιστία Δικτύου, Εξόρυξη Δεδομένων, Ενεργειακή Απόδοση, Ευφυή Συστήματα, Δίκτυα Διανομής, Εντοπισμός Βλαβών, Ανίχνευση σφαλμάτων, Απομόνωση σφαλμάτων, GCNN, EMS, iFD, Εκτιμητής, Μονάδα Απόφασης, Δίκτυα Δεξαμενών, Υβριδικά Συστήματα, Αισθητήρες, , Real-Time Συστήματα, Βιομηχανικός Αυτοματισμός

Application of Artificial Intelligence in Fault Detection and Management in Electricity Grids

Ampatzis Antonios

Abstract

Fault Detection and Isolation (FDI) is a critical component for ensuring the safety, reliability, and efficient operation of industrial systems. This thesis, explores the literature on the development, implementation, and evaluation of advanced intelligent fault diagnosis methods across two different industrial environments: Electromagnetic Suspension (EMS) systems and topologically interconnected water tank networks. Specifically, an Intelligent Fault Detection (iFD) architecture is presented and evaluated for the EMS, incorporating a Neural Network-based estimator and a Decision Mechanism, offering robustness against various types of sensor and actuator faults. Additionally, a Graph Convolutional Neural Network (GCNN) architecture is utilized for fault detection in the tank network, leveraging spatial graph information to classify the state of each component node. In addition, simpler modeling techniques proposed in the literature are also evaluated, including the Multi-Layer Perceptron (MLP) and Concurrent Neuro-Fuzzy (CNF) systems, both of which provide significant advantages in environments with lower complexity or in real-time applications with limited computational resources. The thesis provides a thorough analysis of the theoretical foundation, implementation methodology, system architecture, input data characteristics, and training parameters for each approach. Experimental results in the literature demonstrate that the GCNN method outperforms traditional approaches (e.g., fully connected neural networks) in accuracy and generalization, while the iFD approach ensures real-time reliability and reconfigurability upon fault occurrence. Similarly, CNF and MLP methods exhibit excellent behavior in linear or mildly nonlinear systems, achieving fast response times and low computational cost. Overall, this study confirms the applicability of the proposed architectures in demanding industrial environments and

concludes with a comparative evaluation in terms of accuracy, responsiveness, and flexibility.

Keywords:

Artificial Intelligence, Neural Networks, Machine Learning, Electrical Networks, Fault Detection, Fault Management, Algorithms, Predictive Maintenance, Automation, Network Reliability, Data Mining, Energy Efficiency, Intelligent Systems, Distribution Networks, Fault Localization, Fault Detection, Fault Isolation, GCNN, EMS, iFD, Estimator, Decision Mechanism, Tank Networks, Hybrid Systems, Sensors, Real-Time Systems, Industrial Automation

Πίνακας Περιεχομένων

<i>Ευχαριστίες</i>	<i>xiii</i>
<i>Περίληψη</i>	<i>xv</i>
<i>Abstract</i>	<i>xvii</i>
<i>Πίνακας Περιεχομένων</i>	<i>xix</i>
<i>Κατάλογος εικόνων</i>	<i>xxiii</i>
<i>Κατάλογος πινάκων</i>	<i>xxvii</i>
<i>Συντομογραφίες</i>	<i>xxix</i>
Κεφάλαιο 1 Εισαγωγή	1
1.1 Αντικείμενο της διπλωματικής	2
1.2 Οργάνωση του τόμου	4
Κεφάλαιο 2 Θεωρητικό υπόβαθρο	6
2.1 Επισκόπηση των Ηλεκτρικών Δικτύων και των Βλαβών τους	6
2.1.1 Δομή και Λειτουργία των Ηλεκτρικών Δικτύων.....	6
2.1.2 Τύποι Βλαβών στα Ηλεκτρικά Δίκτυα.....	8
2.2 Εισαγωγή στην Τεχνητή Νοημοσύνη και τα Νευρωνικά Δίκτυα	11
2.2.1 Symbolic AI.....	11
2.2.2 Βασικές Αρχές της Τεχνητής Νοημοσύνης.....	13
2.2.3 Νευρωνικά Δίκτυα	14
2.2.4 Παραδοσιακοί τρόποι κατασκευής μιας ΤΝ.....	15
2.2.5 Ο Συνδετισμός (Connectionism)	16
2.2.6 Multi-Layer Perceptrons (MLP).....	16
2.2.7 Deep Belief Networks (DBN)	18
2.2.8 Recurrent Neural Networks (RNN).....	19
2.2.9 LSTM.....	19
2.3 Εφαρμογές της Τεχνητής Νοημοσύνης σε Δίκτυα Ηλεκτρικής Ενέργειας	20
2.3.1 Ανίχνευση και Ταξινόμηση Βλαβών.....	20
2.3.2 Νευροσαφή Συστήματα.....	22

2.3.3 Προβλεπτική Συντήρηση.....	23
2.3.4 Εφαρμογή Νευρωνικών Δικτύων στην Προβλεπτική Συντήρηση.....	25
2.3.5 Παθητικά και Ενεργητικά Συστήματα Ανοχής Σφαλμάτων	26
2.3.6 Ανίχνευση και απομόνωση βλαβών	27
2.3.7 Παθητικά & Ενεργά Συστήματα Ανίχνευσης και Απομόνωσης Βλαβών	27
2.3.8 Wavelet Transform	29
2.3.9 Ανίχνευση και Απομόνωση Βλαβών (FDI).....	32
2.3.10 GCNNs και FDI.....	32
Κεφάλαιο 3 Μεθοδολογία.....	35
3.1 Περιγραφή των Δεδομένων Υπό Εξέταση	35
3.1.1 Πηγές Δεδομένων	35
3.1.2 Προεπεξεργασία Δεδομένων.....	36
3.2 Επιλογή Αλγορίθμων Μηχανικής Μάθησης και Νευρωνικών Δικτύων	36
3.2.1 Σκοπός της υλοποίησης με iFD	36
3.2.2 Αρχιτεκτονική Ανίχνευσης Σφαλμάτων	39
3.2.3 Υπολογισμός Residuals (Υπολειμμάτων Σφάλματος)	41
3.2.4 Μονάδα Λήψης Απόφασης (Decision Mechanism – DM)	43
3.2.4.4 Μονάδα GCNN.....	46
3.2.5 Ταξινόμηση	47
3.2.6 Εκπαίδευση και Λειτουργία του Συστήματος.....	48
3.2.7 Πλεονεκτήματα της Προσέγγισης GCNN	48
3.3 Σχεδιασμός της Διαδικασίας Ανίχνευσης και Διαχείρισης Βλαβών.....	49
3.3.1 Επιλογή και Ρόλος των Νευρωνικών Δικτύων στην Ανίχνευση Βλαβών	49
3.3.2 Χρήση MLP στη Διαδικασία Ανίχνευσης.....	50
3.3.3 Εφαρμογή RNN στην Πρόβλεψη και Εντοπισμό Βλαβών.....	50
3.3.4 Ανίχνευση και Απομόνωση Βλαβών με GCNN.....	50
3.3.5 Διαδικασία Σχεδιασμού της Ανίχνευσης και Διαχείρισης Βλαβών.....	51
3.4.1 Εφαρμογή σε Πραγματικές Γραμμές Μεταφοράς.....	51
3.4.2 Συγκρίσεις και Μέτρα Απόδοσης.....	63
3.4.3 Συγκριτική Αξιολόγηση και Χρήσεις RNN και DBN	63
Κεφάλαιο 4 Υλοποιήσεις Τεχνικών Ανίχνευσης Βλαβών με CNF, MLP, iFD και GCNN ...	65
4.1 Περιβάλλον Ανάπτυξης.....	65
4.1.1 Εργαλειοθήκη Ασαφούς Λογικής (Fuzzy Logic Toolbox).....	65
4.1.2 Εργαλειοθήκη Νευρωνικών Δικτύων.....	66
4.1.3 Matlab Simulink	66

4.2 Δεδομένα και Εισαγωγή.....	67
4.3 Υλοποίηση του CNF	68
4.4 Υλοποίηση του MLP.....	69
4.5 Διαδικασία Δοκιμών.....	70
4.5.1 Πειραματική διαδικασία με τη μέθοδο CNF.....	70
4.5.2 Πειραματική διαδικασία με τη μέθοδο MLP	74
4.5.3 Συγκριτικά Πλεονεκτήματα των RNN.	77
4.6 Εφαρμογή σε Πραγματικό Σύστημα: EMS	77
4.6.1. Σενάρια Σφάλματος και Ανάλυση Απόδοσης	78
4.6.2 Διαταραχές στην είσοδο και Απαιτήσεις Ελέγχου του Συστήματος EMS.....	81
4.6.3 Προσδιοριστική Είσοδος (Dtm)	81
4.6.4 Απαιτήσεις Ελέγχου για την Dtm:.....	81
4.6.5 Στοχαστική Είσοδος	81
4.6.6 Αποδοτικότητα και αξιολόγηση της προτεινόμενης μεθόδου iFD	82
4.6.7 Εκπαίδευση του Νευρωνικού Εκτιμητή.....	83
4.6.8 Χαρακτηριστικά του Εκπαιδευτικού Συνόλου και Ρυθμίσεις Εκτιμητή.....	85
4.6.9 Σενάρια σφαλμάτων των αισθητήρων	87
4.6.10 Ανάλυση αντίδρασης του iFD	91
4.6.11 Εφαρμογή Σύνθετου Σεναρίου για Επεξήγηση της Λειτουργίας του iFD	94
4.6.12 Διαδικασία Αντιμετώπισης Σφάλματος (αισθητήρας i).....	95
4.6.13 Τεχνικές ρυθμίσεις και εκπαίδευση του εκτιμητή.....	96
4.6.14 Απομόνωση και Αποκατάσταση	97
4.6.15 Πλεονεκτήματα επιλογής του EMS:.....	97
4.7 Εφαρμογή σε Πραγματικό Σύστημα: GCNN.....	98
4.7.1 Περιγραφή της Προτεινόμενης Μεθόδου	109
4.7.2 Κατασκευή του Γραφήματος	109
4.7.3. Χαρακτηριστικά Εισόδου (Input Features)	109
4.7.4 Μονάδα GCNN.....	110
4.7.5. Ταξινόμηση	110
4.7.6. Πλεονεκτήματα της Προσέγγισης GCNN	111
4.7.7 Πειραματική Αξιολόγηση.....	111
4.8 Σύγκριση και Αξιολόγηση των Αποτελεσμάτων	113
4.8.1 Σύγκριση με Παραδοσιακές Προσεγγίσεις	114
4.8.2 Απόδοση GCNN σε βιομηχανικό περιβάλλον δεξαμενών νερού	115
4.8.3 Αρχιτεκτονική του GCNN	116
4.8.4 Αξιολόγηση και Απόδοση	116

4.8.5 Συμπεράσματα από την Υλοποίηση GCNN.....	117
Κεφάλαιο 5 Αποτελέσματα και Συζήτηση	118
5.1 Απόδοση και Ακρίβεια των Αλγορίθμων CNF και MLP.....	118
5.2 Σύγκριση με Αποτελέσματα από τον XGBoost.....	119
5.2.1 Ανάπτυξη και Διαχείριση Δεδομένων στις Τεχνικές	120
5.3 Απόδοση του GCNN σε Δίκτυο Δεξαμενών.....	120
5.3.1 Σύγκριση με Άλλες Μεθόδους	121
5.3.2 Ανάλυση Ικανότητας Γενίκευσης	121
5.4 Συγκριτική Ανάλυση της Αξιοπιστίας και Ευελιξίας των Τεχνικών	122
5.5 Προτεινόμενες Βελτιώσεις και Διεύρυνση Χρήσης.....	122
5.5.1 Υβριδικά Συστήματα	123
5.5.2 Βελτιστοποίηση Παραμέτρων Κανονικοποίησης και Υπερεκπαίδευσης	123
5.6 Συμπεράσματα – Παρατηρήσεις	123
Κεφάλαιο 6 Συμπεράσματα.....	124
6.1 Αξιολόγηση των Μεθόδων CNF, MLP, iFD και GCNN.....	124
6.2 Προτάσεις για Μελλοντική Έρευνα	125
6.2.1 Υβριδικά Μοντέλα και Διευρυμένες Εφαρμογές.....	125
6.2.2 Βελτίωση Ανθεκτικότητας σε «Θορυβώδη» Δεδομένα.....	125
6.2.3 Διεύρυνση Χρήσης σε Ευφυή Συστήματα και Έξυπνα Δίκτυα.....	125
6.2.4 Περισσότερες Προσομοιώσεις σε Εργαστηριακά Σενάρια.....	125
6.2.5 Ενσωμάτωση Αλγορίθμων Μηχανικής Μάθησης για Πρόβλεψη	125
6.3 Συνολική Εκτίμηση Μεθοδολογίας και Εφαρμογών.....	126
6.4 Προτάσεις για περαιτέρω εξέλιξη των μεθόδων ανίχνευσης βλαβών	127
Βιβλιογραφία.....	129

Κατάλογος εικόνων

Εικόνα 2.1: Η δομή ενός Ηλεκτρικού δικτύου (Πηγή: Popular Mechanics, 2025)	7
Εικόνα 2.2: Απεικόνιση των δικτύων Παραγωγής, Μεταφοράς & Διανομής προς όλα τα είδη καταναλωτών (Πηγή: ResearchGate.net, 2025).....	8
Εικόνα 2.3: Σχηματική αναπαράσταση μιας τεχνητής νοημοσύνης [6].....	13
Εικόνα 2.4: Γενική ροή εργασιών μηχανικής μάθησης [8]	14
Εικόνα 2.5: Σύστημα ανίχνευσης και προστασίας σφαλμάτων ενός Έξυπνου Δικτύου [21]	21
Εικόνα 2.6: Ταξινόμηση προέλευσης του σφάλματος σε ασύρματο δίκτυο αισθητήρων [27]	25
Εικόνα 2.7: Εφαρμογή του αλγόριθμου Wavelet Transform σε σήματα: (α) φάση σφάλματος A-G, (β) σφάλμα A-B, (γ) σφάλμα ABC, (δ) φάση σφάλματος AB-G, (ε) σφάλμα ABC-G και (στ) Τεχνητό σήμα [33]	31
Εικόνα 3.1: Σύγκριση μεταξύ τυπικής τράπεζας εκτιμητών (bank of estimators) και της προτεινόμενης μεθόδου iFD με έναν ενιαίο εκτιμητή [38]	37
Εικόνα 3.2: α) Γενικό διάγραμμα ενός ενεργοποιητή – αισθητήρα του προτεινόμενου FDI β) η λειτουργία BS [38]	39
Εικόνα 3.3: Δομή των δεδομένων που χρησιμοποιούνται για την εκπαίδευση iFD [38]...	42
Εικόνα 3.4: Ένα GCNN με 4 κόμβους ($N=4$). Τα X_1 έως X_4 αντιπροσωπεύουν τα σήματα στον κόμβο n . Τα g_1, g_2, g_3 αντιπροσωπεύουν ένα φίλτρο προς εκμάθηση και τα λ_N αντιπροσωπεύουν την ιδιοτιμή i [39]	45
Εικόνα 3.5: Διατύπωση του προβλήματος ανίχνευσης σφαλμάτων σε αισθητήρες ως πρόβλημα ταξινόμησης κόμβων σε γράφημα. Σε συνέχεια της Εικόνας 3.4, οι συμβολισμοί Y_1, Y_2, Y_3, Y_4 αντιπροσωπεύουν τις σημάνσεις (κανονικό ή εσφαλμένο) των εξαρτημάτων υπό έλεγχο [39]	46
Εικόνα 3.6: Παράμετροι των γραμμών (αντίσταση, χωρητικότητα, επαγωγή) [40]	53
Εικόνα 3.7: Εισαγωγή δεδομένων στο block του τριφασικού διακόπτη δημιουργίας σφάλματος [40]	54

Εικόνα 3.8: Διφασικό σφάλμα με $R_f=1\Omega$ και γωνία σφάλματος 45° της 1 ^{ης} Γραμμής Μεταφοράς (PTL1) [40]	55
Εικόνα 3.9: Διφασικό σφάλμα με $R_f=1\Omega$ και γωνία σφάλματος 45° της 2 ^{ης} Γραμμής Μεταφοράς (PTL2) [40]	55
Εικόνα 3.10: Απεικόνιση των 6 λειτουργιών ταυτόχρονης ιδιότητας [40]	56
Εικόνα 3.11: Η αρχιτεκτονική MLP (backpropagation) με τα κρυφά επίπεδα που χρησιμοποιήθηκε [40]	58
Εικόνα 3.12: Η αρχιτεκτονική CNF με τα αντίστοιχα κρυφά επίπεδα [40]	59
Εικόνα 4.1: Το αποτέλεσμα αποσαφήνισης της Γραμμής 1 (PTL1) με τη μέθοδο CNF [40]	70
Εικόνα 4.2: Το αποτέλεσμα αποσαφήνισης της Γραμμής 2 (PTL2) με τη μέθοδο CNF [40]	71
Εικόνα 4.3: Η εκτίμηση του αποτελέσματος αποσαφήνισης της Γραμμής 1 (PTL1) με τη μέθοδο CNF [40]	72
Εικόνα 4.4: Η εκτίμηση του αποτελέσματος αποσαφήνισης της Γραμμής 2 (PTL2) με τη μέθοδο CNF [40]	73
Εικόνα 4.5: Ο απαιτούμενος αριθμός των κρυφών επιπέδων για τη διάγνωση του σφάλματος με τη τεχνική MLP (PTL1) [40]	74
Εικόνα 4.6: Ο απαιτούμενος αριθμός των κρυφών επιπέδων για τη διάγνωση του σφάλματος με τη τεχνική MLP (PTL2) [40]	75
Εικόνα 4.7: Το προτεινόμενο iFD που εφαρμόζεται στο EMS [38]	83
Εικόνα 4.8: Κατηγορίες και τύποι σφαλμάτων αισθητήρων [38]	87
Εικόνα 4.9: Σήμα Εισόδου Dtm, Προγραμματισμένη Κλίση Σιδηροτροχιάς [38]	89
Εικόνα 4.10: Προσθετικό απότομο σφάλμα στον Αισθητήρα Ρεύματος (AD/AF) [38]	89
Εικόνα 4.11: Πολλαπλασιαστικό απότομο σφάλμα στον Αισθητήρα Ρεύματος (MP/AF) [38]	90
Εικόνα 4.12: Προφίλ bias-AF [38]	91
Εικόνα 4.13: Προφίλ AD/IF [38]	92
Εικόνα 4.14: Προφίλ σφάλματος MP/IF [38]	93
Εικόνα 4.15: Σενάριο σφάλματος με id:8 από την Εικόνα 4.9 [38]	94
Εικόνα 4.16: Είσοδος και έξοδος (BS_{gi}) του αισθητήρα ρεύματος (i) και η έξοδος του iFD [38]	96

Εικόνα 4.17: Το βιομηχανικό δίκτυο 100 δεξαμενών νερού [39]	99
Εικόνα 4.18: Δείγμα 5 συνδεδεμένων δεξαμενών στο δίκτυο [39]	100
Εικόνα 4.19: Η πίεση συναρτήσει του χρόνου σε μια δεξαμενή [39]	102
Εικόνα 4.20: Καμπύλη ROC για το πλήρως συνδεδεμένο νευρωνικά δίκτυο με 2 κρυφά στρώματα με λειτουργία ενεργοποίησης tanh (υπερβολική εφαπτομένη) στα κρυφά στρώματα και ενεργοποίηση της σιγμοειδούς συνάρτησης στο επίπεδο εξόδου [39] ...	103
Εικόνα 4.21: Καμπύλη ROC για το GCNN με 2 κρυφά επίπεδα. Το πρώτο κρυφό στρώμα έχει έχει 32 3-hop πολυωνυμικά φίλτρα Chebyshev και το δεύτερο κρυφό στρώμα έχει 64 2-hop πολυωνυμικά φίλτρα Chebyshev [39]	105
Εικόνα 4.22: Συγκριτική απεικόνιση της απόδοσης ταξινομητών στη διάγνωση σφαλμάτων. Περιλαμβάνονται GCNNs με διαφορετική τοπικότητα (1-hop, 2-hop, 3-hop), πλήρως συνδεδεμένα νευρωνικά δίκτυα (Fully Connected NNs), η λογιστική παλινδρόμηση και ο Univariate SVM που βασίζεται σε τοπικές μετρήσεις [39]	106

Κατάλογος πινάκων

Πίνακας 3.1: Η κανονικοποίηση των δεδομένων εισόδου [40]	53
Πίνακας 3.2: Οι εμβέλειες των τιμών κάθε λειτουργίας [40]	57
Πίνακας 3.3: Η ταξινόμηση των σφαλμάτων [40]	60
Πίνακας 3.4: Ο εντοπισμός της θέσης των σφαλμάτων [40]	62
Πίνακας 4.1: Οι διαφορετικές παράμετροι σφάλματος φάσης – φάσης και φάσης – γης για τη ρύθμιση της τεχνικής CNF [40]	69
Πίνακας 4.2: Αποτελέσματα ταξινόμησης της μεθόδου CNF [40]	74
Πίνακας 4.3: Ταξινόμηση βλαβών και αποτελεσμάτων τοποθεσίας της τεχνικής MLP [6] 76	
Πίνακας 4.4: Χαρακτηριστικά του iFD	84
Πίνακας 4.5: Οι παράμετροι του δικτύου [39]	107
Πίνακας 4.6: Σύγκριση αποτελεσμάτων της τράπεζας Kalman και του εκτιμητή iFD	115
Πίνακας 4.7: Σύγκριση μεθόδων CNF, MLP, GCNN και iFD	116
Πίνακας 5.1: Σύγκριση αποτελεσμάτων μεταξύ των 4 μεθόδων ανίχνευσης βλαβών	121
Πίνακας 6.1: Πλεονεκτήματα Βασικών Μεθόδων FDI που Υλοποιήθηκαν	127

Συντομογραφίες

AD: Additive Fault

AUC: Area Under Curve

BS: Binary Switch

CNF: Concurrent Neuro-Fuzzy

CNN: Convolutional Neural Network

CWT: Continuous Wavelet Transform

DBN: Deep Belief Networks

DL: Deep Learning

DLG: Διφασική βλάβη

DM: Decision Mechanism

Dtm: Deterministic Input

DWT: Discrete Wavelet Transform

EMS: Electromagnetic Suspension System

FAR: False Alarm Rate

FD: Fault Detection

FI: Fault Isolation

GCNN: Graph Convolutional Neural Network

iFD: Intelligent Fault Detection

IoT: Internet of Things

LSTM: Learning and Teaching Support Material

ML: Machine Learning (Μηχανική Μάθηση)

MLP: Multi-Layer Perceptrons

MP: Multiplicative Fault

NN: Neural Network

PSD: Power Spectral Density

PTL: Power Transmission Line

RBM: Restricted Boltzmann Machine

ROC: Receiver Operating Characteristic

RNN: Recurrent Neural Networks

RS: Reconfiguration Signal

Sth: Stochastic Input

SLG: Μονοφασική βλάβη

SVM: Support Vector Machine

TLG: Τριφασική βλάβη

TN: Τεχνητή Νοημοσύνη

Κεφάλαιο 1 Εισαγωγή

Η σύγχρονη κοινωνία βασίζεται σε μεγάλο βαθμό στην αδιάλειπτη παροχή ηλεκτρικής ενέργειας, γεγονός που καθιστά τα ηλεκτρικά δίκτυα εγκαταστάσεις ζωτικής σημασίας για τη λειτουργία των περισσότερων βιομηχανικών, εμπορικών και οικιακών δραστηριοτήτων. Ωστόσο, τα ηλεκτρικά δίκτυα είναι ευάλωτα σε πληθώρα λειτουργικών βλαβών και τεχνικών σφαλμάτων, προερχόμενων είτε από φυσικά αίτια είτε από δυσλειτουργία αισθητήρων και μετασχηματιστών ή ανθρώπινα σφάλματα (πχ λανθασμένοι χειρισμοί). Τέτοιες αστοχίες μπορούν να οδηγήσουν σε εκτεταμένες διακοπές, με σοβαρές οικονομικές και κοινωνικές επιπτώσεις. Η έγκαιρη ανίχνευση και απομόνωση των σφαλμάτων είναι επομένως κρίσιμη για τη διασφάλιση της αδιάλειπτης και αξιόπιστης λειτουργίας.

Οι παραδοσιακές μέθοδοι ανίχνευσης βλαβών βασίζονται συχνά σε χειροκίνητες επιθεωρήσεις και απλούς κανόνες, οι οποίοι υστερούν σε ταχύτητα, ακρίβεια και επεκτασιμότητα. Η εμφάνιση της Τεχνητής Νοημοσύνης (TN) και ειδικότερα της Μηχανικής Μάθησης (MM) προσφέρει σημαντικές δυνατότητες βελτιστοποίησης, αυτοματοποίησης και προληπτικής συντήρησης. Τα Νευρωνικά Δίκτυα (Neural Networks, NN), τα Γραφικά Συνελικτικά Δίκτυα (Graph Convolutional Neural Networks, GCNN), τα Υβριδικά Συστήματα, όπως τα σύγχρονα νευροσαφή (Concurrent Neuro-fuzzy, CNF) και τα Πολυεπίπεδα (Multilayer Perceptron, MLP) έχουν αναδειχθεί ως ισχυρά εργαλεία για την πρόβλεψη, την εντοπισμό και την απομόνωση των βλαβών.

Σε μια γραμμή μεταφοράς διακρίνουμε κυρίως τέσσερις τύπους ηλεκτρικών σφαλμάτων σε γραμμές μεταφοράς, ανάλογα με τον αριθμό των αγωγών και τη συμμετοχή της γείωσης. Η μονοφασική βλάβη (Single Line to Ground, SLG) είναι ο συχνότερος τύπος βλάβης, προκαλεί ανισορροπία ρευμάτων και απαιτεί έγκαιρη απομόνωση για την προστασία του εξοπλισμού. Η διφασική βλάβη (Line-to-Line, LL) δημιουργεί υψηλά ρεύματα βραχυκύκλωσης και μπορεί να προκαλέσει τοπική υπέρταση στις «υγιείς» γραμμές. Η διφασική προς τη γείωση (Double-Line-to-Ground, DLG) συνδυάζει τα κύρια χαρακτηριστικά των SLG και LL, με έντονα μεταβατικά φαινόμενα. Τέλος, η τριφασική

βλάβη (Three-Phase, LLL) εμφανίζεται σπάνια σε δίκτυα με καλή μόνωση, αλλά είναι εξαιρετικά καταστροφική λόγω των πολύ υψηλών ρευμάτων που αναπτύσσονται. Η γνώση αυτών των τύπων βλαβών είναι κρίσιμη για την επιλογή κατάλληλων μεθόδων ανίχνευσης, μοντελοποίησης και αντιμετώπισης, καθώς κάθε περίπτωση παρουσιάζει διαφορετικές προκλήσεις σε επίπεδο προστασίας, ελέγχου και αποκατάστασης.

Η παρούσα βιβλιογραφική εργασία εστιάζει στη μελέτη και εφαρμογή προηγμένων τεχνικών TN σε συστήματα υψηλής και μέσης τάσης, με στόχο τη βελτίωση της απόκρισης σε σφάλματα αισθητήρων, ενεργοποιητών ή εξοπλισμού σε πραγματικό χρόνο. Αναλύεται η χρήση ενός ευφυούς συστήματος (Intelligent Fault Detection, iFD) για ηλεκτρομαγνητικά συστήματα ανάρτησης (Electromagnetic Suspension, EMS), καθώς και η υλοποίηση ενός GCNN για την ταξινόμηση κόμβων σε βιομηχανικά δίκτυα δεξαμενών νερού. Επιπλέον, αξιολογούνται αλγόριθμοι όπως τα XGBoost, ο Μακράς Βραχυπρόθεσμης Μνήμης (Long Short-Term Memory, LSTM) και της Μηχανής Διανυσμάτων Υποστήριξης (Support Vector Machine, SVM) για την ακρίβεια και το χρόνο απόκρισης τους, ενώ εξετάζονται τα πλεονεκτήματα των πιο ελαφρών μοντέλων (MLP, CNF) σε περιβάλλοντα με περιορισμένο υπολογιστικό φορτίο. Η εργασία καταλήγει σε συγκριτική αξιολόγηση των τεχνικών ως προς την αξιοπιστία, την ταχύτητα και την ευελιξία τους, καταδεικνύοντας τις προοπτικές τους για ευρεία υιοθέτηση σε σύγχρονες ενεργειακές εφαρμογές.

1.1 Αντικείμενο της διπλωματικής

Η παρούσα διπλωματική εργασία βιβλιογραφικού χαρακτήρα εστιάζει στην εις βάθος μελέτη, μοντελοποίηση και αξιολόγηση σύγχρονων τεχνικών Τεχνητής Νοημοσύνης (TN) για την ανίχνευση και απομόνωση σφαλμάτων (Fault Detection and Isolation – FDI) σε κρίσιμες βιομηχανικές και ενεργειακές εφαρμογές. Με δεδομένη την αυξανόμενη πολυπλοκότητα των ηλεκτρικών δικτύων και τη σημασία της συνεχούς και ασφαλούς λειτουργίας τους, η ανάπτυξη ευφυών μεθόδων για την έγκαιρη διάγνωση βλαβών αποτελεί βασική προτεραιότητα στον τομέα της αυτοματοποίησης και της προγνωστικής συντήρησης.

Η εργασία αποτελεί βιβλιογραφική και τεχνολογική σύνθεση παρουσιάζοντας υλοποιήσεις άλλων, οργανωμένη σε τρία επίπεδα: θεωρητική θεμελίωση, τεχνική

υλοποίηση και συγκριτική αξιολόγηση. Αρχικά, παρουσιάζονται οι βασικές αρχές της Τεχνητής Νοημοσύνης και της Μηχανικής Μάθησης (ML) όπως αυτές εφαρμόζονται στην παρακολούθηση και τη διάγνωση βλαβών. Ιδιαίτερη έμφαση δίνεται στα Νευρωνικά Δίκτυα (NN), στα Γραφικά Συνελικτικά Δίκτυα (GCNN), στα Πολυεπίπεδα Δίκτυα (MLP) και στα Υβριδικά Συστήματα CNF (Concurrent Neuro-Fuzzy), με παράθεση της λειτουργικής τους αρχιτεκτονικής, των απαιτήσεων εκπαίδευσης και της συμπεριφοράς τους σε πραγματικά δεδομένα.

Σε δεύτερο στάδιο, εξετάζονται δύο εφαρμογές – μελέτες περίπτωσης όπου τα παραπάνω συστήματα εφαρμόζονται και αναλύονται διεξοδικά. Στην πρώτη περίπτωση, αναπτύσσεται και αναλύεται ένα υβριδικό σύστημα iFD (Intelligent Fault Detection) βασισμένο σε εκτιμητή Νευρωνικού Δικτύου, το οποίο ενσωματώνεται σε ένα ηλεκτρομαγνητικό σύστημα ανάρτησης (EMS). Το σύστημα είναι σε θέση να ανιχνεύει και να απομονώνει βλάβες αισθητήρων ρεύματος, θέσης ή πίεσης, καθώς και σφάλματα ενεργοποιητών ή συστημάτων ελέγχου, αλλά και να προσαρμόζει τον ελεγκτή του σε πραγματικό χρόνο και να διατηρεί την απόδοση υπό συνθήκες σφαλμάτων. Αναλύονται διεξοδικά οι αισθητήρες, τα σήματα εισόδου-εξόδου, οι τύποι σφαλμάτων (AD/AF, MP/IF κ.ά.), η αρχιτεκτονική του εκτιμητή και η λογική της λήψης απόφασης.

Στη δεύτερη περίπτωση, υλοποιείται και μελετάται η χρήση του Γραφικού Συνελικτικού Νευρωνικού Δικτύου (GCNN) για την παρακολούθηση ενός βιομηχανικού δικτύου δεξαμενών με υψηλή διασυνδεσιμότητα. Η μέθοδος ταξινομεί κόμβους με βάση τη συμπεριφορά τους και εντοπίζει τυχόν διαρροές ή αστοχίες στις συνδεδεμένες δεξαμενές. Περιγράφονται λεπτομερώς τα χαρακτηριστικά εισόδου, η τοπολογία του γραφήματος, τα φίλτρα Chebyshev που εφαρμόζονται, η χρήση 1-hop, 2-hop και 3-hop τοπικότητας και η επίδραση των παραμέτρων στη διάγνωση. Επίσης, συγκρίνεται η απόδοση του GCNN με άλλες μεθόδους όπως το πλήρως διασυνδεδεμένο νευρωνικό δίκτυο (Fully Connected NN), η λογική παλινδρόμηση (Logistic Regression) και η τοπική μηχανή διανυσμάτων υποστήριξης (e-SVM), ως προς την ακρίβεια και την υπερεκπαίδευση.

Τέλος, η εργασία επεκτείνεται συμπεριλαμβάνοντας στη συγκριτική αξιολόγηση ελαφρές αρχιτεκτονικές όπως τα MLP και CNF, τα οποία παρουσιάζουν σημαντικά πλεονεκτήματα σε περιβάλλοντα με χαμηλό υπολογιστικό κόστος. Για κάθε μέθοδο παρουσιάζεται η

ικανότητα γενίκευσης, ο χρόνος απόκρισης, η ακρίβεια εντοπισμού ειδικών τύπων σφαλμάτων (MP/AF, AD/IF), καθώς και η δυνατότητα επέκτασης σε άλλες εφαρμογές.

Σκοπός της εργασίας είναι η ανάδειξη του πρακτικού οφέλους της υιοθέτησης ευφύων συστημάτων διάγνωσης σε βιομηχανικά περιβάλλοντα υψηλής κρισιμότητας, καθώς και η παροχή ενός συγκριτικού πλαισίου για την επιλογή κατάλληλων μεθόδων FDI με βάση τις απαιτήσεις του κάθε συστήματος.

1.2 Οργάνωση του τόμου

Η παρούσα εργασία είναι δομημένη σε έξι κεφάλαια, τα οποία καλύπτουν διαδοχικά το θεωρητικό υπόβαθρο, την ανάλυση των τεχνικών, την υλοποίηση, τα αποτελέσματα και τη συγκριτική αξιολόγηση.

Το Κεφάλαιο 1 παρουσιάζει την εισαγωγή, το αντικείμενο και τη μεθοδολογική στόχευση της εργασίας, καθώς και τη διάρθρωση του περιεχομένου.

Το Κεφάλαιο 2 αναφέρεται στο θεωρητικό υπόβαθρο της ανίχνευσης και απομόνωσης σφαλμάτων (FDI) σε ηλεκτρικά και βιομηχανικά συστήματα. Παρουσιάζονται τα βασικά χαρακτηριστικά των ηλεκτρικών δικτύων, οι τύποι σφαλμάτων, καθώς και οι αρχές της Τεχνητής Νοημοσύνης και της Μηχανικής Μάθησης που αξιοποιούνται στον τομέα της διάγνωσης. Ιδιαίτερη έμφαση δίνεται στις τεχνικές των Νευρωνικών Δικτύων, των μετασχηματισμών Wavelet και των υβριδικών μεθόδων. Επίσης, περιλαμβάνεται η λεπτομερής παρουσίαση των μεθοδολογιών και αρχιτεκτονικών που μελετώνται. Αρχικά αναλύονται οι μέθοδοι CNF και MLP για γραμμικά και μη γραμμικά περιβάλλοντα. Στη συνέχεια παρουσιάζεται η υλοποίηση iFD (Intelligent Fault Detection) σε ηλεκτρομαγνητικά συστήματα ανάρτησης (EMS), και τέλος εξετάζεται η προσέγγιση GCNN (Graph Convolutional Neural Network) για ταξινόμηση κόμβων και εντοπισμό σφαλμάτων σε βιομηχανικά δίκτυα δεξαμενών.

Το Κεφάλαιο 3 παρουσιάζει τη μεθοδολογία που ακολουθήθηκε για την ανάλυση και εφαρμογή των τεχνικών ανίχνευσης και απομόνωσης βλαβών. Αρχικά, περιγράφεται το γενικό πλαίσιο της ερευνητικής προσέγγισης και ακολουθεί λεπτομερής παρουσίαση των επιμέρους αρχιτεκτονικών που χρησιμοποιήθηκαν, όπως τα πολυεπίπεδα Νευρωνικά

Δίκτυα (MLP), τα CNF, καθώς και τα GCNN. Αναλύονται η λειτουργία του Εκτιμητή και της Μονάδας Λήψης Απόφασης στην υλοποίηση τύπου iFD, καθώς και η θεωρητική και τεχνική τεκμηρίωση της επιλογής κάθε τεχνολογίας, των εισόδων, εξόδων και χαρακτηριστικών των δεδομένων. Η μεθοδολογική αυτή ενότητα θέτει τα θεμέλια για την επόμενη φάση υλοποίησης και πειραματικής αξιολόγησης.

Το Κεφάλαιο 4 εστιάζει στην υλοποίηση των παραπάνω μεθόδων. Περιγράφονται αναλυτικά οι αρχιτεκτονικές, τα χαρακτηριστικά εισόδου, τα μοντέλα εκπαίδευσης, οι μηχανισμοί απόφασης, οι πίνακες δεδομένων, οι τύποι σφαλμάτων και τα αποτελέσματα σε κάθε μελέτη περίπτωσης (EMS, GCNN, MLP). Συμπεριλαμβάνονται επίσης διαγράμματα, πίνακες και προσομοιώσεις που τεκμηριώνουν την αποτελεσματικότητα κάθε μεθόδου.

Το Κεφάλαιο 5 παρουσιάζει τα συγκριτικά αποτελέσματα και τη συζήτηση. Συγκρίνονται οι μέθοδοι μεταξύ τους ως προς την ακρίβεια διάγνωσης, την ανθεκτικότητα, τον χρόνο απόκρισης και τις υπολογιστικές απαιτήσεις, ενώ επισημαίνονται οι συνθήκες εφαρμογής και τα όρια κάθε προσέγγισης.

Το Κεφάλαιο 6 περιλαμβάνει τα συμπεράσματα της εργασίας, καθώς και μία σύντομη ματιά στο μέλλον, εστιάζοντας στις προοπτικές εξέλιξης των ευφυών τεχνικών FDI και την ενσωμάτωσή τους σε έξυπνα ενεργειακά και βιομηχανικά δίκτυα.

Κεφάλαιο 2 Θεωρητικό υπόβαθρο


Το κεφάλαιο αυτό χωρίζεται σε τρεις κύριες ενότητες. Αρχικά, γίνεται επισκόπηση της δομής και της λειτουργίας των ηλεκτρικών δικτύων. Στη συνέχεια, παρουσιάζονται οι τύποι των βλαβών που εμφανίζονται στα ηλεκτρικά δίκτυα, ενώ τέλος εισάγονται οι βασικές αρχές και οι εφαρμογές της Τεχνητής Νοημοσύνης στην ανίχνευση και διαχείριση αυτών των βλαβών.

2.1 Επισκόπηση των Ηλεκτρικών Δικτύων και των Βλαβών τους

Τα ηλεκτρικά δίκτυα αποτελούν το θεμέλιο της σύγχρονης ενεργειακής υποδομής, παρέχοντας την απαραίτητη ενέργεια για την υποστήριξη της βιομηχανίας, των υπηρεσιών, και της καθημερινής ζωής. Η ανθεκτικότητα και η αξιοπιστία αυτών των δικτύων είναι κρίσιμες για την οικονομική και κοινωνική σταθερότητα. Ωστόσο, τα ηλεκτρικά δίκτυα υπόκεινται σε πολλαπλές προκλήσεις, με τις ηλεκτρολογικές και δομικές βλάβες να αποτελούν έναν από τους σημαντικότερους κινδύνους για τη συνεχή και ασφαλή λειτουργία τους.

2.1.1 Δομή και Λειτουργία των Ηλεκτρικών Δικτύων

Τα ηλεκτρικά δίκτυα είναι σύνθετα συστήματα που αποτελούνται από τρεις βασικές συνιστώσες: τα δίκτυα παραγωγής, μεταφοράς και διανομής. Η Εικόνα 2.1 απεικονίζει τη ροή της ηλεκτρικής ενέργειας από την παραγωγή έως την τελική κατανάλωση. Η ενέργεια παράγεται σε σταθμό παραγωγής και, μέσω μετασχηματιστή ανύψωσης τάσης, μεταφέρεται σε υψηλή τάση μέσω γραμμών μεταφοράς. Στη συνέχεια, η τάση υποβιβάζεται σε υποσταθμούς υποβιβασμού τάσης και διανέμεται σε διάφορες κατηγορίες καταναλωτών: πελάτες χαμηλής τάσης, πρωτοβάθμιους και δευτεροβάθμιους (τελικούς) καταναλωτές.



Εικόνα 2.1: Η δομή ενός Ηλεκτρικού δικτύου (Πηγή: Popular Mechanics, 2025)


Δίκτυα παραγωγής: Οι σταθμοί παραγωγής ηλεκτρικής ενέργειας, όπως οι θερμοηλεκτρικοί, υδροηλεκτρικοί και αιολικοί σταθμοί, παράγουν την ηλεκτρική ενέργεια. Η ενέργεια αυτή παράγεται σε συγκεκριμένες γεωγραφικές θέσεις και πρέπει να μεταφερθεί σε απομακρυσμένα κέντρα κατανάλωσης.

Δίκτυα μεταφοράς: Τα δίκτυα μεταφοράς χρησιμοποιούν γραμμές υψηλής και υπερυψηλής τάσης για να μεταφέρουν την ηλεκτρική ενέργεια από τους σταθμούς παραγωγής σε κέντρα διανομής και μεγάλους καταναλωτές. Η υψηλή τάση είναι απαραίτητη για τη μείωση των απωλειών ενέργειας κατά τη μεταφορά σε μεγάλες αποστάσεις. Γραμμές τάσης που κυμαίνονται από 150 KV έως και 400 KV χρησιμοποιούνται για την κάλυψη αυτής της ανάγκης.

Δίκτυα διανομής: Η ενέργεια που φτάνει στα κέντρα διανομής μετασχηματίζεται σε χαμηλότερη τάση και διανέμεται στους τελικούς καταναλωτές, όπως οι βιομηχανίες, οι εμπορικές επιχειρήσεις και τα νοικοκυριά. Η μείωση της τάσης είναι αναγκαία για την ασφαλή χρήση της ενέργειας από τις συσκευές και τα συστήματα κατανάλωσης [1], [2].

Η λειτουργία των ηλεκτρικών δικτύων βασίζεται σε ένα πλέγμα τεχνολογιών ελέγχου και παρακολούθησης που επιτρέπουν τη συνεχή και ακριβή διαχείριση της ροής της ενέργειας. Οι σύγχρονες τεχνολογίες περιλαμβάνουν συστήματα παρακολούθησης σε

πραγματικό χρόνο, αυτόματους διακόπτες και μονάδες προστασίας, τα οποία συνδυάζονται για να διασφαλίσουν την ομαλή και ασφαλή λειτουργία των δικτύων. Ένα παράδειγμα σχηματικής αναπαράστασης της δομής και λειτουργίας ενός τυπικού ηλεκτρικού δικτύου δίνεται στην Εικόνα 2.2. Συγκεκριμένα, φαίνεται ότι τα τρία βασικά υποσυστήματα (παραγωγή, μεταφορά, διανομή) συνδέονται και αλληλεπιδρούν μεταξύ τους, ώστε η ηλεκτρική ενέργεια να παραχθεί, να μεταφερθεί και να διανεμηθεί από τις μονάδες παραγωγής στους τελικούς καταναλωτές. Δεν αφορά ένα συγκεκριμένο υπαρκτό δίκτυο, αλλά αποτελεί μια γενικευμένη, ενδεικτική παρουσίαση που βοηθά στην κατανόηση του τρόπου λειτουργίας οποιουδήποτε ηλεκτρικού δικτύου.



Εικόνα 2.2: Απεικόνιση των δικτύων Παραγωγής, Μεταφοράς & Διανομής προς όλα τα είδη καταναλωτών (Πηγή: ResearchGate.net, 2025)

2.1.2 Τύποι Βλαβών στα Ηλεκτρικά Δίκτυα

Οι ηλεκτρολογικές βλάβες στα ηλεκτρικά δίκτυα είναι ένα φαινόμενο που μπορεί να οδηγήσει σε σοβαρές διακοπές της παροχής ενέργειας και σε σημαντικές οικονομικές και κοινωνικές επιπτώσεις. Οι βλάβες διακρίνονται ανάλογα με την προέλευσή τους, τη φύση τους και τις συνέπειές τους στο δίκτυο. Οι κύριες κατηγορίες περιλαμβάνουν:

Βραχυκυκλώματα: Αυτές οι βλάβες αγωγών συμβαίνουν όταν δύο ή περισσότερα αγωγίμα τμήματα έρχονται σε επαφή λόγω φθοράς της μόνωσης ή εξωτερικών παραγόντων, όπως πτώση δέντρων. Τα βραχυκυκλώματα μπορεί να προκαλέσουν υψηλές

ροές ρεύματος που υπερβαίνουν την κανονική ικανότητα του δικτύου, οδηγώντας σε θερμικές βλάβες και πυρκαγιές.

Βλάβες γείωσης: Αυτές οι βλάβες (μονοφασικές, διφασικές, τριφασικές) προκύπτουν όταν ένας αγωγός έρχεται σε επαφή με το έδαφος ή με αγωγό γείωσης, προκαλώντας τη ροή μεγάλου ρεύματος μέσω της γείωσης. Οι βλάβες γείωσης είναι συχνές και μπορεί να προκληθούν από κεραυνούς, δέντρα ή κατεστραμμένη μόνωση.

Βλάβες φάσης: Πρόκειται για βλάβες που συμβαίνουν όταν μια φάση διακόπτεται ή βραχυκυκλώνεται. Οι φάσεις σε ένα τριφασικό σύστημα είναι κρίσιμες για την ισορροπία της ροής της ενέργειας, και οποιαδήποτε διακοπή μπορεί να προκαλέσει σημαντικές διαταραχές.

Βλάβες υπερφόρτωσης: Προκαλούνται από την υπερβολική ζήτηση ρεύματος που υπερβαίνει την ικανότητα του δικτύου. Οι υπερφορτώσεις μπορούν να οδηγήσουν σε αύξηση της θερμοκρασίας των αγωγών και του εξοπλισμού, επιταχύνοντας τη φθορά τους και αυξάνοντας τον κίνδυνο βλάβης.

Βλάβες εξοπλισμού: Οι βλάβες αυτές οφείλονται σε δυσλειτουργίες ή καταστροφές στον εξοπλισμό, όπως οι μετασχηματιστές, οι διακόπτες και οι αγωγοί. Η φυσική φθορά, τα ελαττωματικά εξαρτήματα ή η κακή συντήρηση μπορούν να οδηγήσουν σε τέτοιες βλάβες [3].

Εκτός από τις παραδοσιακές βλάβες εξοπλισμού —μονοφασικές, διφασικές, τριφασικές και βλάβες γείωσης— η σύγχρονη βιβλιογραφία επισημαίνει την ανάγκη αποτίμησης της ανθεκτικότητας των ΣΗΕ. Σε αντίθεση με τη στενή έννοια της αξιοπιστίας (reliability), που μετρά την πιθανότητα διακοπών σε συγκεκριμένο χρονικό διάστημα, η ανθεκτικότητα αφορά την ικανότητα ενός ΣΗΕ να απορροφά, να αντιμετωπίζει και να αναρρώνει από διαταραχές μεγάλης κλίμακας (π.χ. ακραία καιρικά φαινόμενα, φυσικές καταστροφές, κυβερνοεπιθέσεις). Στα πλαίσια της αξιολόγησης της ανθεκτικότητας έχουν προταθεί διάφορα θεωρητικά και εμπειρικά μοντέλα, μεταξύ των οποίων:

Καμπύλη Ανθεκτικότητας (Resilience Curve): Παρουσιάζει την εξέλιξη της λειτουργικής απόδοσης του ΣΗΕ σε σχέση με το χρόνο, σε τέσσερα στάδια:

1. **Absorption (Απορρόφηση):** άμεση αντίδραση στις διαταραχές
2. **Degradation (Υποβάθμιση):** πτώση απόδοσης

3. **Recovery (Ανάκαμψη):** επισκευή/επαναφορά
4. **Adaptation (Προσαρμογή):** μακροπρόθεσμη βελτίωση για μελλοντικές διαταραχές

Πλαίσια 4R (Robustness, Resourcefulness, Rapid Recovery, Redundancy): Αξιολογούν πόσο ανθεκτικό είναι το δίκτυο σε κάθε ένα από τα τέσσερα αυτά χαρακτηριστικά (Στιβαρότητα, Επινοητικότητα, Γρήγορη Ανάκτηση, Περίσσεια Εξοπλισμού).

Ποσοτικές Μετρήσεις (Quantitative Metrics):

1. **Resilience Index (RI):** Ο δείκτης ανθεκτικότητας, το εμβαδόν κάτω από την καμπύλη απόδοσης (πάνω από ένα επίπεδο αναφοράς).
2. **Time to Recovery (TTR):** χρόνος πλήρους επαναφοράς.
3. **Value-at-Risk (VaR) και Conditional VaR:** μετρικές οικονομικών απωλειών λόγω διακοπών [4].

Επιπρόσθετα, ένα ακόμα κομμάτι της σύγχρονης βιβλιογραφίας, είναι η αποτίμηση της ανθεκτικότητας ενός ΣΗΕ. Η εξέλιξη της ξεκινά από το απλό τρίγωνο ανθεκτικότητας (**resilience triangle**) και προχωρά σε πιο πλήρη τραπεζοειδή πλαίσια (**trapezoid frameworks**), όπου διακρίνουμε τα στάδια Απορρόφηση (Absorption), Υποβάθμιση (Degradation), Ανάκτηση (Recovery) και Προσαρμογή (Adaptation). Αυτά τα πολυδιάστατα μοντέλα αξιολογούν την ικανότητα ενός ΣΗΕ να προβλέπει, απορροφά και αναρρώνει από ακραίες διαταραχές. Οι γενικότεροι τύποι βλαβών (φυσικές καταστροφές, ανθρώπινα λάθη, κυβερνοεπιθέσεις, βλάβες εξοπλισμού) συνδέονται με μετρήσεις όπως το Resilience Index (εμβαδόν κάτω από την καμπύλη), το Time To Recovery (χρόνος ανάκαμψης) και οικονομικές εκτιμήσεις (VaR/CVaR) για την πλήρη αποτίμηση της λειτουργικής ανθεκτικότητας [5].

Η αντιμετώπιση των βλαβών απαιτεί την άμεση ανίχνευσή τους και τη λήψη διορθωτικών μέτρων για την αποφυγή διακοπών μεγάλης κλίμακας. Η ακρίβεια και η ταχύτητα ανίχνευσης είναι κρίσιμες για τη μείωση του χρόνου αποκατάστασης και την αποφυγή σοβαρών επιπτώσεων.

2.2 Εισαγωγή στην Τεχνητή Νοημοσύνη και τα Νευρωνικά Δίκτυα

Η Τεχνητή Νοημοσύνη (TN) αποτελεί ένα ραγδαία αναπτυσσόμενο πεδίο που επηρεάζει πολλούς τομείς της τεχνολογίας και της βιομηχανίας, συμπεριλαμβανομένων των ηλεκτρικών δικτύων. Η ικανότητα των συστημάτων TN να αναλύουν μεγάλους όγκους δεδομένων, να μαθαίνουν από αυτά και να λαμβάνουν αποφάσεις χωρίς ανθρώπινη παρέμβαση, τα καθιστά εξαιρετικά πολύτιμα για την ανίχνευση και διαχείριση βλαβών.

2.2.1 Symbolic AI

Η προσέγγιση της Συμβολικής TN (Symbolic AI), γνωστή και ως «παραδοσιακή τεχνητή νοημοσύνη» (Good Old-Fashioned Artificial Intelligence - GOFAI), βασίζεται στην κωδικοποίηση της γνώσης μέσω τυπικών γλωσσών και στην εξαγωγή λογικών συμπερασμάτων από σαφείς κανόνες. Σύγχρονες υλοποιήσεις συμβολικών συστημάτων είναι ιεραρχικές δομές κατηγοριών (classes) και σχέσεων (properties) που περιγράφουν το πεδίο ενδιαφέροντος γνωστές ως οι Οντολογίες (Ontologies) και τα Γραφήματα Γνώσης (Knowledge Graphs - KGs), τα οποία παρέχουν τη δυνατότητα ταξινόμησης και λογικής εξαγωγής γνώσης. Παρότι τα Συμβολικά συστήματα παρουσιάζουν περιορισμούς ως προς την επεξεργασία «θορύβου» ή ασαφών δεδομένων, προσφέρουν υψηλή αποδοτικότητα σε περιπτώσεις συμβολικών και σημασιολογικών δεδομένων και μπορούν να ενισχύσουν τη διαφάνεια των νευρωνικών δικτύων, παρέχοντας στον χρήστη τη δυνατότητα ουσιαστικής αλληλεπίδρασης μέσω κοινών και κατανοητών συμβόλων [6].

Η εφαρμογή της Τεχνητής Νοημοσύνης (TN) σε θέματα όπως η ανίχνευση και διάγνωση βλαβών βασίζεται, σε πρώτο επίπεδο, στην εκπαίδευση ενός μοντέλου πάνω σε ένα σύνολο δεδομένων. Συγκεκριμένα:

1. **Συλλογή Δεδομένων (Inputs):** Μετρήσεις αισθητήρων, ιστορικά σφάλματα, περιβαλλοντικές συνθήκες κ.ά.
2. **Προεπεξεργασία και Αντιπροσώπηση:** Κανονικοποίηση, εξαγωγή χαρακτηριστικών (feature engineering) και, όπου απαιτείται, μετασχηματισμοί (π.χ. wavelets).
3. **Αρχιτεκτονική Βαθιάς Μάθησης:** Εφαρμογή νευρωνικού δικτύου (π.χ. MLP, CNN, RNN, GCNN) που «μαθαίνει» να αποτυπώνει συσχετίσεις και πρότυπα στα δεδομένα.


4. **Παραγωγή Εξόδων (Outputs):** Ταξινόμηση (π.χ. είδος βλάβης), πρόβλεψη (π.χ. ποσοστό αποτυχίας), ομαδοποίηση (clustering), ή ακόμα και εξηγήσεις αποφάσεων.

Όταν, επιπλέον, υπάρχουν Γραφήματα Γνώσης (Knowledge Graphs – KGs) και Οντολογίες που περιγράφουν το πεδίο (π.χ. οντολογία εξαρτήματος, τύπου βλάβης, αιτιολογίας), τότε η TN μπορεί:

1. Να συνδυάσει τα δεδομένα με πλούσιο σημασιολογικό πλαίσιο
2. Να παράγει εξηγήσεις («Γιατί το μοντέλο εκτίμησε διφασική βλάβη;»)
3. Να διασφαλίσει συνέπεια με υπάρχουσες επιχειρησιακές οντολογίες.

Η Εικόνα 2.3 παρακάτω παρουσιάζει ένα σχηματικό γράφημα που συνοψίζει τον ρόλο των σημασιολογικών τεχνολογιών. Ειδικότερα, η αντιστοίχιση γνώσεων των στοιχείων deep learning, των χαρακτηριστικών εισόδου, των κρυφών μονάδων και επιπέδων, των προβλέψεων εξόδου με KGs και με στοιχεία Οντολογίας μπορούν να κάνουν πιο διαφανή και κατανοητή την εσωτερική λειτουργία των αλγορίθμων. Επιπλέον, οι μηχανισμοί συλλογισμού των KGs και των Οντολογιών δημιουργούν τις συνθήκες για προχωρημένες αναλύσεις και διαδραστική απεικόνιση των αποτελεσμάτων.

Το μοντέλο που απεικονίζεται στην Εικόνα 2.3 ενσωματώνει τεχνολογίες σε μοντέλα βαθιάς μάθησης (deep learning). Με το μπλε πλαίσιο φαίνεται ο παραδοσιακός τρόπος κατασκευής μιας τεχνητής νοημοσύνης. Η διαδικασία αντιστοίχισης και εκμάθησης των στοιχείων στα γραφήματα (KGs) και στις Οντολογίες επισημαίνονται με πορτοκαλί χρώμα. Τέλος, με κόκκινο περίγραμμα απεικονίζονται οι μηχανισμοί ερωτημάτων, συλλογισμών και διαδραστικότητας [6].



Εικόνα 2.3: Σχηματική αναπαράσταση μιας τεχνητής νοημοσύνης [6]


2.2.2 Βασικές Αρχές της Τεχνητής Νοημοσύνης

Η ΤΝ περιλαμβάνει έναν ευρύ φάσμα τεχνικών που επιτρέπουν στις μηχανές να εκδηλώνουν συμπεριφορά κατά την επίλυση προβλημάτων, η οποία προκύπτει μέσω μοντελοποίησης των γνωστικών λειτουργιών του ανθρώπινου εγκεφάλου.. Οι πιο κοινές τεχνικές περιλαμβάνουν:

Μηχανική Μάθηση (Machine Learning- ML): Πρόκειται για έναν υποτομέα της ΤΝ που επιτρέπει στα συστήματα να μαθαίνουν και να βελτιώνουν τις επιδόσεις τους βάσει δεδομένων. Η μηχανική μάθηση χρησιμοποιείται ευρέως για την ανάλυση προτύπων και την πρόβλεψη γεγονότων, συμπεριλαμβανομένης της ανίχνευσης βλαβών [7].

Η γενική ροή εργασίας ML της Εικόνας 2.4 αποτελείται από πέντε στάδια, τη δημιουργία και συλλογή δεδομένων, την επιλογή αλγορίθμου για προετοιμασία των δεδομένων, την εκπαίδευση μηχανικής μάθησης (ML) και τη βελτίωση του μοντέλου, όπως φαίνεται στην Εικόνα 2.4. Το πρώτο στάδιο αφορά τη δημιουργία δεδομένων βάσει του μοντέλου του συστήματος. Το επόμενο στάδιο είναι η προεπεξεργασία των δεδομένων, στο τρίτο στάδιο επιλέγεται ο αλγόριθμος και ρυθμίζονται οι υπόλοιπες παράμετροι εκτός από τα χαρακτηριστικά εισόδου για το ML. Το επόμενο στάδιο αντιστοιχεί στην πραγματική

εκμάθηση της TN ενώ το τελευταίο στάδιο περιλαμβάνει μια κυκλική ενημέρωση και βελτίωση των παραμέτρων εκπαίδευσης, προκειμένου να ελαχιστοποιηθεί η διαφορά του σφάλματος [7].



Εικόνα 2.4: Γενική ροή εργασιών μηχανικής μάθησης [8]

2.2.3 Νευρωνικά Δίκτυα

Τα Νευρωνικά Δίκτυα (Neural Networks - NN) είναι μια από τις πιο προηγμένες και ευρέως χρησιμοποιούμενες τεχνικές στον τομέα της Τεχνητής Νοημοσύνης και ειδικότερα της Μηχανικής Μάθησης. Η σχεδίαση και η λειτουργία τους είναι εμπνευσμένες από τη δομή και τον τρόπο λειτουργίας του ανθρώπινου εγκεφάλου. Τα δίκτυα αυτά έχουν τη δυνατότητα να επεξεργάζονται μεγάλα σύνολα δεδομένων, να αναγνωρίζουν σύνθετα πρότυπα και να προβλέπουν αποτελέσματα με υψηλή ακρίβεια.

Η αρχιτεκτονική των νευρωνικών δικτύων αποτελείται συνήθως από πολλαπλά στρώματα νευρώνων που χωρίζονται σε τρία βασικά επίπεδα: το επίπεδο εισόδου (input layer), τα κρυφά επίπεδα (hidden layers) και το επίπεδο εξόδου (output layer). Οι νευρώνες στα κρυφά επίπεδα, που ονομάζονται perceptrons, συνδέονται τόσο με το επίπεδο εισόδου

όσο και με το επίπεδο εξόδου. Ένα χαρακτηριστικό παράδειγμα νευρωνικού δικτύου είναι τα Multi-Layer Perceptrons (MLP), τα οποία χρησιμοποιούνται ιδιαίτερα στην ανίχνευση και ταξινόμηση βλαβών σε γραμμές μεταφοράς υψηλής τάσης, παρέχοντας σημαντικά υψηλότερη ακρίβεια συγκριτικά με παραδοσιακές μεθόδους.

Η εκπαίδευση των νευρωνικών δικτύων υλοποιείται κυρίως μέσω δύο αλγορίθμων μάθησης:

1. **Αλγόριθμος Εμπροσθοδιάδοσης (Feed Forward):** τα δεδομένα κινούνται από το επίπεδο εισόδου προς το επίπεδο εξόδου μέσω των κρυφών επιπέδων, επεξεργαζόμενα διαδοχικά από κάθε νευρώνα.
2. **Αλγόριθμος Οπισθοδιάδοσης Σφάλματος (Backpropagation):** χρησιμοποιείται για την προσαρμογή των βαρών των συνδέσεων των νευρώνων, κινώντας το σφάλμα πρόβλεψης αντίστροφα, από το επίπεδο εξόδου προς το επίπεδο εισόδου. Σκοπός της διαδικασίας αυτής είναι η ελαχιστοποίηση του σφάλματος πρόβλεψης, επιτρέποντας στο δίκτυο να «μαθαίνει» και να βελτιώνει την απόδοσή του με βάση τα δεδομένα εκπαίδευσης [8], [9].

Τα νευρωνικά δίκτυα έχουν ευρεία χρήση σε εφαρμογές στα ηλεκτρικά δίκτυα, όπως η ανίχνευση και διάγνωση βλαβών, η πρόβλεψη ζήτησης ενέργειας, καθώς και η βελτιστοποίηση της διαχείρισης και λειτουργίας των συστημάτων ενέργειας. Οι εφαρμογές αυτές έχουν αποδειχθεί ιδιαίτερα αποτελεσματικές, βελτιώνοντας σημαντικά τόσο την αξιοπιστία όσο και την αποδοτικότητα των σύγχρονων ηλεκτρικών δικτύων [10], [11].

2.2.4 Παραδοσιακοί τρόποι κατασκευής μιας TN

Σε αυτή την ενότητα περιγράφονται οι κύριες αρχές εκμάθησης TN μέσω μοντέλων βαθιάς μάθησης (Connectionist AI). Η κατανόηση των χαρακτηριστικών και των διαφορών τους μπορεί να βοηθήσει στη δημιουργία μιας πιο κατανοητής TN από την ενσωμάτωση των δύο προαναφερθέντων μοντέλων.

2.2.5 Ο Συνδεδεισμός (Connectionism)

Η προσέγγιση του Συνδεδεισμού, γνωστή και ως Παράλληλη Κατανεμημένη Επεξεργασία (Parallel Distributed Processing), αναδύθηκε τη δεκαετία του 1980 ως το «δεύτερο κύμα» έρευνας στα νευρωνικά δίκτυα. Η κεντρική της ιδέα βασίζεται σε ένα δίκτυο απλών υπολογιστικών μονάδων, των νευρώνων, οι οποίοι διεγείρουν ή αναστέλλουν ο ένας τον άλλο με στόχο την επίτευξη ευφυούς συμπεριφοράς. Η γνώση που προκύπτει αντιπροσωπεύεται στις συνδέσεις μεταξύ αυτών των μονάδων. Δύο βασικές έννοιες του Συνδεδεισμού που ενσωματώθηκαν στις σύγχρονες μεθόδους βαθιάς μάθησης είναι η κατανεμημένη αναπαράσταση των δεδομένων (Distributed Representation) και ο αλγόριθμος οπισθοδιάδοσης σφάλματος (back-propagation). Με τη βοήθεια αυτών, η εκπαίδευση των νευρωνικών δικτύων μετατρέπεται σε ένα πρόβλημα βελτιστοποίησης, καθιστώντας τα ιδιαίτερα αποδοτικά στην αυτόματη εξαγωγή προτύπων από μεγάλα σύνολα δεδομένων. Ωστόσο, ένα σημαντικό μειονέκτημα αυτών των τεχνικών είναι η έλλειψη διαφάνειας, γεγονός που καθιστά την αποσαφήνιση των αποτελεσμάτων ένα ανοικτό ερευνητικό ζήτημα, και για αυτό το λόγο προτείνεται η σύνδεσή τους με σημασιολογικές τεχνολογίες, ώστε να ενισχυθεί η εξηγησιμότητά τους [6], [12].

2.2.6 Multi-Layer Perceptrons (MLP)

Τα Multi-Layer Perceptrons (MLP) είναι μια κατηγορία τεχνητών νευρωνικών δικτύων που χρησιμοποιούνται ευρέως για την ταξινόμηση και την ανίχνευση βλαβών. Τα MLP αποτελούνται από πολλαπλά επίπεδα τεχνητών νευρώνων οργανωμένα σε στρώματα (layers). Τα βασικά στρώματα ενός MLP είναι το input layer, τα hidden layers, και το output layer.

Input Layer: Το στρώμα εισόδου δέχεται τα δεδομένα από τους αισθητήρες ή άλλα συστήματα. Για παράδειγμα, σε μια γραμμή μεταφοράς ηλεκτρικής ενέργειας, τα δεδομένα εισόδου μπορεί να είναι μετρήσεις τάσης, ρεύματος και φάσης.

Hidden Layers: Τα κρυφά στρώματα αποτελούνται από τεχνητούς νευρώνες που εκτελούν μη γραμμικές μετασχηματίσεις στα δεδομένα. Η πολυπλοκότητα και η απόδοση του MLP εξαρτάται από τον αριθμό και το μέγεθος των κρυφών στρωμάτων. Οι νευρώνες αυτοί εφαρμόζουν την ενεργοποίηση μέσω λειτουργιών όπως ReLU (Rectified Linear Unit), η οποία επιτρέπει στο MLP να μάθει πολύπλοκες σχέσεις μεταξύ των δεδομένων.

Output Layer: Το στρώμα εξόδου παρέχει την τελική πρόβλεψη του MLP. Στην περίπτωση της ανίχνευσης βλαβών, το αποτέλεσμα θα μπορούσε να είναι μια δυαδική πρόβλεψη, δηλαδή αν υπάρχει βλάβη (1) ή όχι (0), ή μια ταξινόμηση του είδους της βλάβης [13].

Η εκπαίδευση ενός MLP βασίζεται στον αλγόριθμο οπισθοδιάδοσης, ο οποίος υπολογίζει το σφάλμα πρόβλεψης στο επίπεδο εξόδου και προσαρμόζει τα βάρη των συνδέσεων μεταξύ των νευρώνων για να ελαχιστοποιήσει αυτό το σφάλμα. Αυτό επιτρέπει στο δίκτυο να μάθει από τα δεδομένα και να βελτιώσει την απόδοσή του. Συγκεκριμένα, τα δεδομένα εισόδου κανονικοποιούνται πριν εισαχθούν στο δίκτυο, και οι νευρώνες εκπαιδεύονται ώστε να εντοπίζουν και να ταξινομούν σφάλματα με βάση συγκεκριμένες συνθήκες που προκύπτουν από τις σχέσεις μεταξύ των εισόδων και των εξόδων. Το δίκτυο χρησιμοποιεί συναρτήσεις ενεργοποίησης όπως η λογιστική συνάρτηση (logistic activation function) ενώ η εκπαίδευση γίνεται με κανονικοποιημένα δεδομένα ώστε να επιτευχθεί μεγαλύτερη ακρίβεια στην ταξινόμηση και τον εντοπισμό σφαλμάτων.

Στην ανίχνευση βλαβών σε ηλεκτρικά δίκτυα, τα MLP είναι εξαιρετικά αποτελεσματικά λόγω της ικανότητάς τους να αναγνωρίζουν και να ταξινομούν περίπλοκα πρότυπα στα δεδομένα. Για παράδειγμα, οι διακυμάνσεις στην τάση ή στο ρεύμα μπορεί να είναι ενδείξεις βλάβης, και το MLP μπορεί να αναγνωρίσει αυτές τις διακυμάνσεις, ακόμη και όταν οι σχέσεις μεταξύ των δεδομένων δεν είναι γραμμικές [13], [14].

Προκειμένου να ενισχυθεί η απόδοση και η ακρίβεια των MLP, χρησιμοποιούνται διάφορες τεχνικές και εργαλεία που στοχεύουν στη βελτιστοποίηση των παραμέτρων τους, καθώς και στη συνολική ενίσχυση της απόδοσής τους σε πρακτικές εφαρμογές. Τέτοιες τεχνικές περιλαμβάνουν τη χρήση ειδικών αλγορίθμων βελτιστοποίησης και συστημάτων ευφυών πρακτόρων, οι οποίοι μπορούν να αυτοματοποιήσουν τις διαδικασίες λήψης αποφάσεων και να βελτιώσουν την ανταπόκριση των νευρωνικών δικτύων σε πραγματικά σενάρια λειτουργίας.

Αλγόριθμοι Βελτιστοποίησης: Οι αλγόριθμοι αυτοί χρησιμοποιούνται για τη βελτιστοποίηση των παραμέτρων των νευρωνικών δικτύων και άλλων συστημάτων ΤΝ, επιτρέποντάς τους να επιτυγχάνουν καλύτερα αποτελέσματα. Παραδείγματα περιλαμβάνουν τους αλγόριθμους διαβάθμισης κλίσης (gradient descent) και στοχαστικής διαβάθμισης κλίσης (stochastic gradient descent).

Συστήματα Ευφυών Πρακτόρων (Intelligent Agents): Αυτά τα συστήματα μπορούν να λαμβάνουν αποφάσεις με βάση τα δεδομένα που λαμβάνουν από το περιβάλλον τους και να εκτελούν δράσεις για την επίτευξη συγκεκριμένων στόχων. Οι ευφυείς πράκτορες χρησιμοποιούνται συχνά για τη βελτίωση της αυτοματοποίησης και της απόδοσης σε πολύπλοκα συστήματα, όπως τα ηλεκτρικά δίκτυα [14].

2.2.7 Deep Belief Networks (DBN)

Τα DBN αποτελούνται από διαδοχικά επίπεδα περιορισμένων μηχανών Boltzmann (Restricted Boltzmann Machines - RBM), και είναι εξαιρετικά για εφαρμογές ταξινόμησης και αναγνώρισης προτύπων, ειδικά σε μεγάλα και πολύπλοκα δεδομένα. Τα κύρια χαρακτηριστικά των DBN είναι:

1. **Ιεραρχική εκμάθηση χαρακτηριστικών:** Τα DBN, μέσω των επιπέδων τους, μαθαίνουν πολυεπίπεδα χαρακτηριστικά από τα δεδομένα, ξεκινώντας από απλές ιδιότητες σε αρχικά επίπεδα και προχωρώντας σε πιο σύνθετα πρότυπα. Αυτό είναι ιδιαίτερα χρήσιμο στα συστήματα ισχύος, όπου οι βλάβες μπορούν να εμφανιστούν σε διαφορετικά επίπεδα ανάλυσης, από τη λειτουργία των εξαρτημάτων έως και τις συνολικές ενεργειακές μεταβολές.
2. **Αυτοματοποίηση ανίχνευσης και ταξινόμησης:** Τα DBN έχουν τη δυνατότητα να λειτουργούν αυτόνομα, προσφέροντας γρήγορη ταξινόμηση βλαβών χωρίς συνεχή ανθρώπινη παρέμβαση. Για παράδειγμα, σε ένα βιομηχανικό περιβάλλον με συνεχείς αλλαγές φορτίου και λειτουργικών συνθηκών, τα DBN μπορούν να εντοπίζουν βλάβες με αυτόματη ρύθμιση και προσαρμογή στα νέα δεδομένα.
3. **Αντοχή σε πολύπλοκα και θορυβώδη δεδομένα:** Τα DBN διαχειρίζονται πολύπλοκα δεδομένα, όπως αυτά που παράγονται από συστήματα υψηλής τάσης, με υψηλή αξιοπιστία. Τα επίπεδα των RBM επιτρέπουν στα DBN να φιλτράρουν «θορυβώδεις» πληροφορίες και να αναγνωρίζουν μοτίβα βλάβης που δεν είναι άμεσα ορατά.
4. **Εκπαίδευση με απρόσκοπτη ενσωμάτωση νέων δεδομένων:** Τα DBN υποστηρίζουν εκπαίδευση με μεθόδους εκμάθησης χωρίς επίβλεψη (unsupervised learning), διευκολύνοντας τη χρήση τους σε περιβάλλοντα όπου δεν είναι εφικτή η πλήρης επισήμανση των δεδομένων. Σε εφαρμογές παρακολούθησης και

ανίχνευσης βλαβών, όπως σε έξυπνα δίκτυα, αυτό επιτρέπει τη διαρκή εκμάθηση από νέες πηγές δεδομένων [15], [16].

2.2.8 Recurrent Neural Networks (RNN)

Τα RNN είναι ένας άλλος τύπος νευρωνικών δικτύων που είναι εξαιρετικά κατάλληλος για την επεξεργασία δεδομένων χρονικών σειρών. Σε αντίθεση με τα παραδοσιακά νευρωνικά δίκτυα, τα RNN έχουν αναδρομικές συνδέσεις, επιτρέποντας στο δίκτυο να διατηρεί πληροφορίες από προηγούμενα χρονικά βήματα και να τις χρησιμοποιεί για την επεξεργασία νέων εισόδων. Αυτό είναι ιδιαίτερα χρήσιμο για την ανίχνευση βλαβών, καθώς οι διαταραχές σε ένα δίκτυο μπορεί να έχουν χρονική εξέλιξη [17].

Τα RNN χρησιμοποιούν feedback loops, τα οποία επιτρέπουν την ανατροφοδότηση πληροφοριών σε κάθε βήμα. Αυτό σημαίνει ότι η απόφαση που λαμβάνεται σε μια χρονική στιγμή επηρεάζεται από τα δεδομένα που έχουν παρατηρηθεί σε προηγούμενες χρονικές στιγμές. Αυτή η δομή καθιστά τα RNN ιδανικά για την ανίχνευση βλαβών σε δίκτυα που λειτουργούν με συνεχή ροή δεδομένων, όπως τα ηλεκτρικά δίκτυα και τα συστήματα βιομηχανικών αισθητήρων [17].

2.2.9 LSTM

Ένας ιδιαίτερα χρήσιμος τύπος RNN είναι το Long Short-Term Memory (LSTM), το οποίο έχει σχεδιαστεί για να αντιμετωπίζει τα προβλήματα μακροχρόνιας εξάρτησης που παρουσιάζονται σε παραδοσιακά RNN. Τα LSTM χρησιμοποιούν μηχανισμούς που επιτρέπουν στο δίκτυο να διατηρεί ή να ξεχνά πληροφορίες καθώς προχωρά στο χρόνο, βελτιώνοντας την ακρίβεια των προβλέψεων σε περιπτώσεις όπου οι αλλαγές στο σήμα συμβαίνουν σε διαφορετικές χρονικές κλίμακες.

Σε εφαρμογές όπως η ανίχνευση βλαβών σε βιομηχανικά συστήματα, τα RNN μπορούν να αναλύσουν τη ροή των δεδομένων σε πραγματικό χρόνο και να εντοπίσουν βλάβες που εξελίσσονται με την πάροδο του χρόνου. Για παράδειγμα, οι σταδιακές μεταβολές στην κατανάλωση ενέργειας μπορεί να είναι ένα πρόδρομο σημάδι βλάβης, και τα RNN μπορούν να αναγνωρίσουν αυτές τις αλλαγές πριν γίνουν πιο εμφανείς [17], [18].

Ακολουθώντας την παρουσίαση των βασικών αρχών, εξετάζονται παρακάτω οι πρακτικές εφαρμογές της τεχνητής νοημοσύνης στα ηλεκτρικά δίκτυα.


2.3 Εφαρμογές της Τεχνητής Νοημοσύνης σε Δίκτυα Ηλεκτρικής Ενέργειας

Τα σύγχρονα δίκτυα ηλεκτρικής ενέργειας αλλάζουν ραγδαία μέσα από την ενσωμάτωση της ΤΝ, η οποία συμβάλλει στην αποτελεσματικότερη λειτουργία και διαχείρισή τους. Μέσω της χρήσης αλγορίθμων μηχανικής μάθησης και των τεχνητών νευρωνικών δικτύων, η ΤΝ βρίσκει εφαρμογή σε ποικίλους τομείς, όπως η πρόβλεψη ζήτησης, ο έλεγχος παραγωγής από ανανεώσιμες πηγές και η διατήρηση της ευστάθειας του συστήματος. Ιδιαίτερη σημασία αποκτά η αξιοποίησή της στην ανίχνευση και ταξινόμηση βλαβών, διαδικασία που ενισχύει ουσιαστικά την αξιοπιστία και την ασφάλεια της ηλεκτρικής υποδομής..

2.3.1 Ανίχνευση και Ταξινόμηση Βλαβών

Σε περίπλοκα βιομηχανικά δίκτυα ή έξυπνα δίκτυα, η αναπαράσταση του συστήματος ως γράφημα και η ανάλυση της συσχέτισης μεταξύ κόμβων (μονάδων) επιτρέπει την ενίσχυση της ακρίβειας διάγνωσης. Τα Graph Convolutional Neural Networks (GCNNs) ενσωματώνουν τόσο τις τοπικές μετρήσεις όσο και τη δομή του συστήματος για να καταλήξουν στην τελική απόφαση. Η χρήση τεχνητών νευρωνικών δικτύων, συστημάτων βαθιάς μάθησης και GCNNs επιτρέπει την εξαγωγή πληροφοριών από σύνθετα σήματα και την ταξινόμηση διαφορετικών τύπων βλαβών. Τα μοντέλα αυτά εκπαιδεύονται με ιστορικά δεδομένα ή προσομοιώσεις και μπορούν να λειτουργήσουν ακόμα και όταν δεν υπάρχει πλήρες φυσικό μοντέλο του συστήματος. Ο υπολογισμός υπολειμμάτων ανάμεσα σε πραγματικά και εκτιμώμενα σήματα αποτελεί συχνά εφαρμοζόμενη τεχνική για την ανίχνευση αποκλίσεων. Ένα σύστημα εκπαιδευμένο να προβλέπει κανονικές τιμές μπορεί να εντοπίσει τη διαφορά όταν προκύπτει σφάλμα και να ενεργοποιήσει διαδικασία διάγνωσης [19]. Η μετατροπή κυματομορφών με μετασχηματισμούς Wavelet και η εξαγωγή χαρακτηριστικών όπως η συχνότητα, οι απότομες μεταβολές ή ενέργεια σήματος επιτρέπουν τον εντοπισμό της θέσης και του τύπου της βλάβης. Τεχνικές όπως ο Διακριτός Μετασχηματισμός Wavelet (DWT) συχνά συνδυάζονται με τα NN για την τελική ταξινόμηση. Τα νευρωνικά δίκτυα, σε συνδυασμό με τις τεχνικές ανάλυσης κυματομορφών, όπως ο αλγόριθμος Wavelet Transform, χρησιμοποιούνται για τον εντοπισμό της ακριβούς θέσης της βλάβης σε μεγάλες γραμμές μεταφοράς. Αυτή η τεχνική επιτρέπει την ανίχνευση της θέσης της βλάβης ακόμα και σε πολύπλοκες και δυναμικές

συνθήκες λειτουργίας του δικτύου. Ο Wavelet Transform χρησιμοποιεί “wavelets” – μικρά κύματα με πεπερασμένη διάρκεια – για να απομονώσει χαρακτηριστικά σε διάφορες κλίμακες. Σε αντίθεση με τον μετασχηματισμό Fourier, ο Wavelet Transform μπορεί να εντοπίσει γρήγορες μεταβολές στο σήμα, καθιστώντας τον ιδανικό για ανίχνευση σφαλμάτων σε χρονοσειρές αισθητήρων [20]. Τέλος, Η χρήση ρελέ, όπως ρελέ απόστασης ή διαφορικής προστασίας, ενσωματώνεται στα συστήματα προστασίας και σε συνδυασμό με ψηφιακή επεξεργασία σήματος μπορεί να εντοπίσει και να κατηγοριοποιήσει βλάβες σε πραγματικό χρόνο. Τα ρελέ μπορούν να απομονώνουν το προβληματικό τμήμα ώστε να διατηρείται η συνολική ευστάθεια του δικτύου. Παρακάτω παρουσιάζεται ένα παράδειγμα παραδοσιακής τεχνικής διάγνωσης και διόρθωσης βλάβης με ένα σύστημα με διαφορικά ρελέ [21]. Η Εικόνα 2.5 παρουσιάζει τη λειτουργία ενός τριφασικού έξυπνου δικτύου με προστασία μέσω διαφορικών ρελέ. Η ηλεκτρική ενέργεια προέρχεται από τριφασική πηγή και μετασχηματίζεται μέσω τριφασικού μετασχηματιστή. Η προστασία επιτυγχάνεται με δύο διακόπτες (Breakers 1 και 2) και έναν διαφορικό ρελέ που συγκρίνει τις μετρήσεις ρεύματος και τάσης στα κρίσιμα σημεία του συστήματος. Προβλέπονται δύο σημεία σφάλματος (Fault 1 και Fault 2), καθώς και μια γραμμή τύπου PI. Το φορτίο στο τέλος του κυκλώματος είναι τριφασικό τύπου RLC.



Εικόνα 2.5: Σύστημα ανίχνευσης και προστασίας σφαλμάτων ενός Έξυπνου Δικτύου [21]

Τα εγκατεστημένα διαφορικά ρελέ παρακολουθούν συνεχώς και συγκρίνουν τα εισερχόμενα και εξερχόμενα ρεύματα μέσα σε μια καθορισμένη προστατευόμενη ζώνη για να εντοπίσουν βλάβες στο ηλεκτρικό δίκτυο της Εικόνας 2.5. Η αρχή λειτουργίας βασίζεται στην ιδέα ότι τα ρεύματα που εισέρχονται και εξέρχονται από τη ζώνη πρέπει να είναι ίσα υπό κανονικές συνθήκες λειτουργίας. Αν υπάρξει σημαντική διαφορά μεταξύ αυτών των ρευμάτων, το ρελέ είναι ρυθμισμένο να ενεργοποιείται, να απομονώνει και να επισημαίνει μια βλάβη. Η ακριβής οριοθέτηση της ζώνης ενεργοποίησης είναι απαραίτητη για να διασφαλιστεί ότι το ρελέ παρακολουθεί όλα τα ρεύματα που ρέουν μέσω αυτής. Είναι σημαντικό να καθοριστεί ένα ακριβές όριο διαφορικού ρεύματος, ενώ μπορούν να γίνουν ρυθμίσεις στην ευαισθησία για να λαμβάνονται υπόψη τα σφάλματα και οι απώλειες ισχύος των μετασχηματιστών. Για τη βελτίωση της απόδοσης, τα διαφορικά ρελέ μπορούν να εξοπλιστούν με επιπλέον χαρακτηριστικά, όπως το φιλτράρισμα των αρμονικών. Επιπλέον, μπορούν να συνδεθούν με άλλα ρελέ ώστε να παρέχουν συντονισμένη προστασία. Η τακτική δοκιμή, η συντήρηση και η ενσωμάτωση εφεδρικών μηχανισμών προστασίας ενισχύουν την αξιοπιστία ενός διαφορικού ρελέ για την ανίχνευση και την άμεση αντιμετώπιση βλαβών [21].

2.3.2 Νευροσαφή Συστήματα

Τα Νευροσαφή συστήματα (neuro-fuzzy, NF) είναι υβριδικά υπολογιστικά μοντέλα που συνδυάζουν την ικανότητα εκμάθησης των NN με την ευελιξία και την εξηγησιμότητά της Ασαφούς Λογικής (Fuzzy Logic - FL). Τα NN είναι εμπνευσμένα από τη λειτουργία του ανθρώπινου εγκεφάλου και αποτελούνται από πολλαπλά επίπεδα τεχνητών νευρώνων που έχουν τη δυνατότητα να εκπαιδεύονται και να αναγνωρίζουν μοτίβα, ενώ η FL επιτρέπει την αναπαράσταση αβεβαιότητας και ασάφειας χρησιμοποιώντας γλωσσικούς όρους όπως “υψηλό”, “μεσαίο” και “χαμηλό” για την εξαγωγή συμπερασμάτων με βάση κανόνες. Ο συνδυασμός τους, γνωστός ως Concurrent Neuro-Fuzzy (CNF), αξιοποιεί τις δυνατότητες εκμάθησης του νευρωνικού δικτύου για την κανονικοποίηση και επεξεργασία των εισόδων (όπως ρεύματα και τάσεις βραχυκυκλώματος), ενώ εφαρμόζει κανόνες ασαφούς λογικής για την ταξινόμηση των βλαβών [22]. Οι συναρτήσεις συμμετοχής (Triangular και Trapezoidal) χρησιμοποιούνται για να μετατρέψουν τις αριθμητικές εισόδους σε ασαφείς μεταβλητές, μειώνοντας την υπολογιστική πολυπλοκότητα. Η αποσαφήνιση (defuzzification) επιστρέφει μια τελική καθαρή έξοδο.

Το σύστημα είναι σε θέση να αναγνωρίσει διαφορετικούς τύπους βλαβών, όπως (Single Line to Ground fault on phase A – SLAG), (Double Line fault between phases A and C – DLAC), (Triple Line to Ground fault – TLABCG), και να εντοπίσει τη θέση της βλάβης κατά μήκος γραμμών μεταφοράς πολύ υψηλής τάσης με πολύ μικρό ποσοστό σφάλματος, ιδιαίτερα όταν εκπαιδεύεται με μεγάλο όγκο δεδομένων. Επιπλέον, σε εφαρμογές όπως τα ασύρματα δίκτυα αισθητήρων, η FL χρησιμοποιείται για την αξιολόγηση της κατάστασης κάθε κόμβου (π.χ. υγιής, σε σφάλμα, ανενεργός) με βάση παραμέτρους όπως η υπολειπόμενη ενέργεια, η ακρίβεια αισθητήρα και η αξιοπιστία κυκλωμάτων. Η προσέγγιση αυτή είναι αποκεντρωμένη, χαμηλού κόστους και ιδιαίτερα αποδοτική για εφαρμογές σε δύσκολα περιβάλλοντα. Συμπεραίνοντας, τα συστήματα NF συνδυάζουν εξηγησιμότητα, προσαρμοστικότητα και ακρίβεια, καθιστώντας τα ιδανικά για ανίχνευση, ταξινόμηση και διάγνωση βλαβών σε κρίσιμα τεχνικά συστήματα [22], [23], [24].

2.3.3 Προβλεπτική Συντήρηση

Η προβλεπτική συντήρηση επιδιώκει την έγκαιρη ανίχνευση ανωμαλιών και την εκτίμηση της υπολειπόμενης ωφέλιμης ζωής (Remaining Useful Life – RUL) του εξοπλισμού, ώστε να διατηρείται η φυσιολογική λειτουργία του συστήματος με ελάχιστες διακοπές. Βασίζεται στη συλλογή και ανάλυση ιστορικών δεδομένων λειτουργίας (π.χ. μετρήσεις δονήσεων, θερμοκρασίας, ρεύματος) και στην εφαρμογή μοντέλων που προβλέπουν την εξέλιξη της κατάστασης των στοιχείων.


Στο πλαίσιο αυτό, τα νευρωνικά δίκτυα έχουν αποδειχθεί ιδιαίτερα αποτελεσματικά:

1. **Ανίχνευση Ανωμαλιών (Anomaly Detection):** Μοντέλα Autoencoder και LSTM συγκρίνουν την τρέχουσα συμπεριφορά με πρότυπα «φυσιολογικής» λειτουργίας για την έγκαιρη ειδοποίηση εκτροπών.
2. **Πρόβλεψη υπολειπόμενης ζωής (RUL Prediction):** Δίκτυα RNN και CNN εκπαιδεύονται σε χρονοσειρές με προηγούμενα σενάρια αποτυχίας, ώστε να εκτιμούν πόσος χρόνος απομένει πριν η απόδοση υποτροπιάσει κάτω από κρίσιμα όρια.

3. **Κατηγοριοποίηση Στάσεων Συντήρησης:** Τα MLP (συχνά συνδυασμένα με NN) ταξινομούν σε κατηγορίες «καλή κατάσταση», «προειδοποίηση» ή «άμεση συντήρηση», διευκολύνοντας τη λήψη προληπτικών μέτρων [25].

Η ενοποίηση των μεθόδων αυτών σε ένα υβριδικό σύστημα (π.χ. GCNN για χωρικές εξαρτήσεις του δικτύου και LSTM για χρονικές προβλέψεις) επιτρέπει την ταυτόχρονη αξιολόγηση της κατάστασης τόσο σε επίπεδο εξοπλισμού όσο και στο συνολικό δίκτυο, βελτιώνοντας την ακρίβεια και μειώνοντας τα αναπάντεχα κόστη των διακοπών [26].

Η Εικόνα 2.6 παρουσιάζει την ταξινόμηση της προέλευσης των σφαλμάτων στα Ασύρματα Δίκτυα Αισθητήρων (Wireless Sensor Networks - WSN). Σύμφωνα με το διάγραμμα, τα σφάλματα χωρίζονται σε δύο βασικές κατηγορίες: σφάλματα που προέρχονται από τα εξαρτήματα του WSN και σφάλματα που προκύπτουν από το σύστημα του WSN. Ειδικότερα, στα εξαρτήματα του δικτύου, τα σφάλματα εντοπίζονται στους κόμβους (Nodes), στους κόμβους συγκέντρωσης δεδομένων ή βυθίσματα (Sinks), καθώς και στο ίδιο το δίκτυο (Network). Αντίστοιχα, τα σφάλματα του συστήματος WSN διακρίνονται ανάλογα με το επίπεδο στο οποίο εμφανίζονται και περιλαμβάνουν το επίπεδο υλικού (Hardware Layer), το επίπεδο λογισμικού (Software Layer), το επίπεδο δικτυακής επικοινωνίας (Network Communication Layer) και το επίπεδο εφαρμογής (Application Layer). Αυτή η συνοπτική ταξινόμηση επιτρέπει την καλύτερη κατανόηση και διαχείριση των σφαλμάτων σε ένα WSN.



Εικόνα 2.6: Ταξινόμηση προέλευσης του σφάλματος σε ασύρματο δίκτυο αισθητήρων [27]

2.3.4 Εφαρμογή Νευρωνικών Δικτύων στην Προβλεπτική Συντήρηση

Η εφαρμογή των νευρωνικών δικτύων στην προβλεπτική συντήρηση ξεκινά με τη συλλογή σημάτων από αισθητήρες, τα οποία επεξεργάζονται μέσω τεχνικών ανάλυσης κυματομορφών, όπως ο μετασχηματισμός κυματιδίων (Wavelet Transform) που θα αναλυθεί σε επόμενο κεφάλαιο. Η τεχνική αυτή επιτρέπει την αποσύνθεση των σημάτων σε διαφορετικές χρονικές και συχνοτικές κλίμακες, εντοπίζοντας έτσι τις περιοχές εκείνες που φέρουν χαρακτηριστικά φθοράς. Τα εξαγόμενα χαρακτηριστικά στη συνέχεια εισάγονται σε ένα εκπαιδευμένο νευρωνικό δίκτυο, το οποίο έχει τη δυνατότητα να προβλέπει την εξέλιξη της κατάστασης του εξοπλισμού και να ειδοποιεί εγκαίρως για την ανάγκη συντήρησης [13], [26].

Πιο προχωρημένες εφαρμογές περιλαμβάνουν τη χρήση Υβριδικών Κυματικών Νευρωνικών Δικτύων (Wavelet Neural Networks - WNN) ή Συστημάτων NF, τα οποία

συνδυάζουν την ακρίβεια μάθησης των NNs με την ερμηνευσιμότητα της ασαφούς λογικής. Οι τεχνικές αυτές ενισχύουν σημαντικά την ικανότητα πρόβλεψης σε περιπτώσεις ασαφών ή μη γραμμικών σημάτων, όπως είναι αυτά που παράγονται από εξοπλισμό σε σταδιακή φθορά. Επιπλέον, η ενσωμάτωση σταθερού κυματικού μετασχηματισμού (Stationary Wavelet Transform - SWT), που διατηρεί τη χρονική ακεραιότητα του σήματος, έχει αποδειχθεί ιδιαίτερα αποτελεσματική στην ανίχνευση μικρών αποκλίσεων που μπορεί να μην είναι ορατές με κλασικές τεχνικές.

Ο συνδυασμός του Wavelet Transform και των Νευρωνικών Δικτύων παρέχει ένα ισχυρό εργαλείο για την ανάπτυξη έξυπνων συστημάτων συντήρησης, τα οποία μπορούν να προβλέψουν με υψηλή ακρίβεια βλάβες πριν αυτές προκαλέσουν σοβαρές δυσλειτουργίες. Με τον τρόπο αυτό, μειώνεται το λειτουργικό κόστος, αυξάνεται η διάρκεια ζωής του εξοπλισμού και ενισχύεται η αξιοπιστία του συστήματος [28].

2.3.5 Παθητικά και Ενεργητικά Συστήματα Ανοχής Σφαλμάτων

Η ανοχή σε σφάλματα είναι μια σημαντική απαίτηση στη βιομηχανική παραγωγή. Για την αντιμετώπιση σφαλμάτων, χρησιμοποιούνται παθητικά (Passive Fault Tolerant Control - PFTC) και ενεργητικά συστήματα (Active Fault Tolerant Control – AFTC) ανοχής σφαλμάτων, τα οποία απαιτούν υποσυστήματα ανίχνευσης και απομόνωσης σφαλμάτων (FDI). Αυτά τα υποσυστήματα παρακολουθούν την κατάσταση του συστήματος και απομονώνουν τα σφάλματα ώστε να ενεργοποιηθεί η κατάλληλη στρατηγική ανοχής [29].

Σε επόμενο κεφάλαιο παρουσιάζεται εκτενώς ένα ευφύες σύστημα FDI με πολύ χαμηλό υπολογιστικό κόστος, το οποίο επιλέχθηκε επειδή:

1. Μειώνει δραστικά το υπολογιστικό κόστος σε σχέση με άλλες μεθόδους όπως ένα πλήρως συνδεδεμένο NN και ενός CNF του [30], επιτυγχάνοντας εξοικονόμηση πόρων > 40%.
2. Υποστηρίζει ενσωματωμένα περιβάλλοντα σε πραγματικό χρόνο χάρη στη δομή του μηχανισμού λήψης αποφάσεων του που επιτρέπει την άμεση επαναδιαμόρφωση σε περίπτωση σφάλματος.
3. Συγκρίνεται στην παράγραφο 4.8 με τρεις εναλλακτικές προσεγγίσεις, αξιολογώντας την ακρίβεια εντοπισμού σφάλματος, το χρόνο απόκρισης και την ευελιξία επαναφοράς.

Αν και δεν είναι η μοναδική λύση, το συγκεκριμένο σύστημα επιλέχθηκε ως μελέτη περίπτωσης λόγω της σαφούς τεκμηρίωσής του και της αποδεδειγμένης υπεροχής του σε πραγματικά σενάρια EMS, σε αντίθεση με άλλες υλοποιήσεις που παρουσιάζουν είτε μεγαλύτερη καθυστέρηση ανταπόκρισης (latency) είτε ανάγκη για ισχυρότερο Hardware.

Η αρχιτεκτονική του συστήματος βασίζεται σε έναν και μόνο νευρωνικό εκτιμητή, εκπαιδευμένο σε όλα τα πιθανά σενάρια βλάβης, ο οποίος συνδυάζεται με μια μονάδα λήψης απόφασης για τον υπολογισμό των καταλοίπων (residuals) και τον εντοπισμό ελαττωματικών στοιχείων.

Η προσέγγιση αυτή εξαλείφει την ανάγκη για δημιουργία πολλαπλών εκτιμητών, όπως απαιτείται στα κλασικά σχήματα τράπεζας εκτιμητών (bank of estimators). Στηριζόμενο στην εκπαίδευση του νευρωνικού εκτιμητή με συνδυαστικά σενάρια βλαβών, επιτυγχάνεται γρήγορη ανίχνευση σφαλμάτων και αποτελεσματική απομόνωσή τους με ελάχιστη υπολογιστική επιβάρυνση [30].

2.3.6 Ανίχνευση και απομόνωση βλαβών

Στη σημερινές βιομηχανικές εφαρμογές, η αποδοτικότητα και η αξιοπιστία είναι ουσιώδεις παράγοντες για τη διασφάλιση της συνεχούς λειτουργίας ενός συστήματος. Η ύπαρξη σφαλμάτων στους αισθητήρες ή τους ενεργοποιητές μπορεί να μειώσει σημαντικά την απόδοση ή ακόμη και να προκαλέσει καταστροφή του. Επομένως, είναι κρίσιμη η έγκαιρη και ακριβής ανίχνευση (fault detection, FD) και απομόνωση βλαβών (fault isolation- FI) [30]. Η ανίχνευση σφαλμάτων έχει ως στόχο την έγκαιρη εντόπιση ανωμαλιών στη λειτουργία ενός συστήματος, είτε αυτές προέρχονται από αισθητήρες, είτε από ενεργοποιητές ή άλλες μονάδες. Η απομόνωση σφαλμάτων ακολουθεί την ανίχνευση και εστιάζει στον ακριβή εντοπισμό της πηγής του σφάλματος (π.χ. συγκεκριμένη γραμμή μεταφοράς ή αισθητήρας). Σε συνδυασμό, τα συστήματα FDI παρέχουν κρίσιμη πληροφόρηση για τη διατήρηση της ασφάλειας, της αξιοπιστίας και της διαθεσιμότητας του ηλεκτρικού δικτύου σε πραγματικό χρόνο.

2.3.7 Παθητικά & Ενεργά Συστήματα Ανίχνευσης και Απομόνωσης Βλαβών

Η έρευνα γύρω από τα FDI συστήματα μπορεί να ταξινομηθεί σε δύο κύριες κατηγορίες: τα παθητικά και τα ενεργά. Στα παθητικά συστήματα FDI, οι στρατηγικές ελέγχου δεν αλλάζουν σε περίπτωση βλάβης. Η έμφαση δίνεται στην αντοχή της σχεδίασης, ώστε το

σύστημα να συνεχίζει να λειτουργεί αποδεκτά κάτω από ορισμένες διαταραχές, χωρίς να απαιτείται δυναμική προσαρμογή του ελεγκτή. Αντίθετα, τα ενεργά συστήματα FDI είναι ικανά να τροποποιούν τη συμπεριφορά τους δυναμικά όταν προκύψει σφάλμα. Αυτό επιτυγχάνεται με την προσαρμογή παραμέτρων ή/και τη μετατροπή της δομής του ελεγκτή, ώστε να διατηρηθεί ή να αποκατασταθεί η λειτουργία όσο το δυνατό πιο κοντά στο φυσιολογικό επίπεδο [31].

Συνήθως, τα FDI συστήματα βασίζονται σε τράπεζες εκτιμητών. Αυτό σημαίνει ότι κατασκευάζεται ένας ξεχωριστός εκτιμητής για κάθε πιθανό σενάριο σφάλματος. Για ένα σύστημα με n_y αισθητήρες και n_u ενεργοποιητές, ο αριθμός των πιθανών συνδυασμών βλαβών είναι τεράστιος:

$$N_e = 2^{n_y + n_u} - 1$$

Αυτό καθιστά την κατασκευή τέτοιων τραπεζών μη ρεαλιστική για μεγάλα συστήματα, τόσο από άποψη υπολογιστικής ισχύος όσο και μνήμης [30].

Εναλλακτικά, υπάρχει η δυνατότητα να χρησιμοποιηθούν νευρωνικά δίκτυα για την πρόβλεψη της σωστής λειτουργίας ενός συστήματος. Αυτά τα σχήματα εκμεταλλεύονται την ικανότητα των δικτύων να μαθαίνουν από δεδομένα και να κάνουν προβλέψεις ακόμη και υπό συνθήκες που δεν έχουν παρατηρηθεί κατά την εκπαίδευση. Ωστόσο, παρουσιάζουν προβλήματα όπως υψηλό ποσοστό ψευδών σφαλμάτων (False Alarm Rate - FAR) και μειωμένη ακρίβεια σε μη στατικά περιβάλλοντα [30], [31].

Το σχετικό παράδειγμα υλοποίησης στην ενότητα 3.2.1 προτείνει μια διαφορετική προσέγγιση: την ανάπτυξη ενός ενιαίου εκτιμητή με βάση το νευρωνικό δίκτυο, εκπαιδευμένου με δεδομένα που περιλαμβάνουν συνδυασμούς όλων των πιθανών συνθηκών λειτουργίας. Αυτός ο εκτιμητής συνδυάζεται με μια μονάδα υπολογισμού residuals και μια μονάδα λήψης αποφάσεων, ώστε να εντοπίζονται και να απομονώνονται τα ελαττωματικά σήματα.

2.3.8 Wavelet Transform

Η ακριβής τοποθέτηση των βλαβών σε ένα ηλεκτρικό δίκτυο είναι κρίσιμη για την ταχεία αποκατάσταση της λειτουργίας και τη μείωση των επιπτώσεων της διακοπής. Η ΤΝ παρέχει εργαλεία για την ανάλυση κυματομορφών τάσης και ρεύματος που παράγονται κατά τη διάρκεια μιας βλάβης, επιτρέποντας τον ακριβή εντοπισμό της θέσης της βλάβης. Μια τέτοια τεχνική ανάλυσης κυματομορφών είναι ο Wavelet Transform όπως αναφέρεται στην ενότητα 2.3.1.

Ο Wavelet Transform είναι ένα ισχυρό εργαλείο για την ανάλυση σημάτων που χρησιμοποιείται για την κατανόηση της δομής ενός σήματος σε διαφορετικές χρονικές και συχνотικές διαστάσεις. Σε αντίθεση με άλλους μετασχηματισμούς, όπως ο μετασχηματισμός Fourier, ο οποίος αναλύει τα σήματα μόνο στο πεδίο της συχνότητας, ο Wavelet Transform επιτρέπει την ανάλυση τόσο στο πεδίο του χρόνου όσο και της συχνότητας ταυτόχρονα. Αυτή η ικανότητα το καθιστά ιδιαίτερα χρήσιμο για την ανάλυση σημάτων που περιέχουν στιγμιαίες διαταραχές, αιχμές ή μη στατική συμπεριφορά. Με αυτόν τον τρόπο, μπορούμε να εντοπίσουμε με ακρίβεια τα χρονικά σημεία όπου υπάρχουν μεταβολές ή διαταραχές στο σήμα. Υπάρχουν δύο βασικές μορφές του Wavelet Transform, οι οποίες χρησιμοποιούνται ανάλογα με την εφαρμογή [14], [32]:

1. **Continuous Wavelet Transform (CWT):** Αυτός ο μετασχηματισμός αναλύει το σήμα σε συνεχή κλίμακα και θέση, επιτρέποντας την ακριβή ανάλυση σε πολλές διαφορετικές χρονικές και συχνотικές διαστάσεις. Ο CWT χρησιμοποιείται όταν απαιτείται υψηλή ακρίβεια, αλλά είναι πιο υπολογιστικά δαπανηρός.
2. **Discrete Wavelet Transform (DWT):** Ο DWT χρησιμοποιεί διακριτές κλίμακες και θέσεις για να αναλύσει το σήμα, καθιστώντας το πιο αποδοτικό για πρακτικές εφαρμογές. Ο DWT χρησιμοποιείται ευρέως σε εφαρμογές όπως η συμπίεση δεδομένων, η ανάλυση σήματος και η ανίχνευση βλαβών [32], [33].

Το Wavelet Transform έχει πολλές εφαρμογές, ιδιαίτερα στην επεξεργασία και ανάλυση σημάτων, ειδικά όταν το σήμα παρουσιάζει δυναμική συμπεριφορά. Οι κύριες εφαρμογές του περιλαμβάνουν:


3. **Ανάλυση και Επεξεργασία Σημάτων:** Ο Wavelet Transform χρησιμοποιείται για την ανάλυση σημάτων με σκοπό την ανίχνευση στιγμιαίων διαταραχών ή αιχμών

σε σήματα τάσης, ρεύματος ή άλλων φυσικών μεγεθών. Η ικανότητά του να εντοπίζει στιγμιαίες αλλαγές στο σήμα είναι κρίσιμη σε περιπτώσεις όπου αυτές οι διαταραχές μπορούν να υποδεικνύουν προβλήματα ή βλάβες.

4. **Ανίχνευση Βλαβών σε Ηλεκτρικά Δίκτυα:** Ο Wavelet Transform είναι ιδιαίτερα χρήσιμος για την ανίχνευση βλαβών σε ηλεκτρικά δίκτυα, όπως οι βλάβες σε γραμμές μεταφοράς ενέργειας. Χρησιμοποιείται για την ανάλυση των κυματομορφών τάσης και ρεύματος, επιτρέποντας την ταχεία ανίχνευση βραχυκυκλωμάτων και άλλων δυσλειτουργιών. Σε αυτήν την εφαρμογή, τα wavelets αναλύουν τις αλλαγές στη συμπεριφορά του σήματος σε διάφορες χρονικές κλίμακες, εντοπίζοντας τις στιγμές που συμβαίνουν ανωμαλίες.
5. **Συμπίεση και Φιλτράρισμα Δεδομένων:** Ο Wavelet Transform χρησιμοποιείται ευρέως στη συμπίεση δεδομένων και εικόνων, όπως στο πρότυπο JPEG 2000. Επιτρέπει την αναπαράσταση των δεδομένων με λιγότερες πληροφορίες χωρίς σημαντική απώλεια ποιότητας. Επιπλέον, χρησιμοποιείται στην αποθορυβοποίηση σημάτων, όπου αφαιρεί τον θόρυβο από το σήμα χωρίς να επηρεάζει τα χρήσιμα δεδομένα [32], [33].

Η Εικόνα 2.7 παρουσιάζει την εφαρμογή του Μετασχηματισμού Συνεχούς Κυματιδίου (Continuous Wavelet Transform - CWT) σε κομμάτια σημάτων που αντιστοιχούν σε διαφορετικά σενάρια σφαλμάτων σε ένα σύστημα ενέργειας. Η εικόνα περιλαμβάνει έξι γραφήματα συχνότητας - χρόνου, όπου κάθε ένα απεικονίζει τη κατανομή της ενέργειας του σήματος για συγκεκριμένο τύπο βλάβης: μονή φάση προς γη, διφασική, τριφασική, διφασική προς γη, τριφασική προς γη και ένα τεχνητό σήμα αναφοράς. Πριν την εφαρμογή του CWT, τα αρχικά σήματα αποσυντίθενται μέσω του μετασχηματισμού κυματιδίου σταθερής μετατόπισης (Stationary Wavelet Transform - SWT) και στη συνέχεια ανασυντίθενται με χρήση του αλγεβρικού αθροίσματος όλων των επιπέδων (Algebraic Sum Operation - ASO), διαδικασία που ενισχύει τις λεπτομέρειες των σφαλμάτων. Στις τελικές φασματικές απεικονίσεις, τα σημεία υψηλής ενέργειας (με έντονο χρώμα) αντιστοιχούν σε χαρακτηριστικές συχνότητες που σχετίζονται με την εμφάνιση της κάθε βλάβης, π.χ. η συχνότητα των 600–650 Hz για σφάλμα τύπου A–G ή η 800 Hz για διφασικό σφάλμα A–B. Το τεχνητό σήμα στην τελευταία εικόνα παρουσιάζει με ακρίβεια την 5η αρμονική (250 Hz) που προστέθηκε εσκεμμένα, επιβεβαιώνοντας τη λειτουργικότητα της

μεθόδου. Συνολικά, η Εικόνα 2.7 επιβεβαιώνει την αποτελεσματικότητα της προτεινόμενης υβριδικής προσέγγισης SWT–CWT στην ανίχνευση και ταξινόμηση βλαβών, προσφέροντας σαφή και ενισχυμένη απεικόνιση των χαρακτηριστικών του σήματος σε πολλαπλά επίπεδα χρόνου και συχνότητας [32].



Εικόνα 2.7: Εφαρμογή του αλγόριθμου Wavelet Transform σε σήματα: (a) φάση σφάλματος A-G, (b) σφάλμα A-B, (c) σφάλμα ABC, (d) φάση σφάλματος AB-G, (e) σφάλμα ABC-G και (f) Τεχνητό σήμα [33]

Σε εφαρμογές όπως η ανίχνευση βλαβών σε γραμμές μεταφοράς ηλεκτρικής ενέργειας, ο Wavelet Transform χρησιμοποιείται για την ανάλυση των κυματομορφών ρεύματος και τάσης που καταγράφονται κατά τη διάρκεια μιας βλάβης. Σε αυτή την περίπτωση, τα δεδομένα από αισθητήρες που είναι τοποθετημένοι κατά μήκος της γραμμής μεταφοράς αναλύονται σε διαφορετικές χρονικές και συχνотικές κλίμακες. Με τον Wavelet Transform, μπορούμε να ανιχνεύσουμε τις χρονικές στιγμές στις οποίες συμβαίνουν

διαταραχές στα σήματα, υποδεικνύοντας την παρουσία μιας βλάβης. Για παράδειγμα, σε περίπτωση βραχυκυκλώματος, οι κυματομορφές του ρεύματος και της τάσης θα παρουσιάσουν απότομες μεταβολές. Ο Wavelet Transform μπορεί να αναγνωρίσει αυτές τις αλλαγές, εντοπίζοντας τόσο τον χρόνο όσο και τη συχνότητα των διαταραχών, επιτρέποντας τον ακριβή εντοπισμό της βλάβης. Αυτό είναι ιδιαίτερα χρήσιμο σε μεγάλα δίκτυα, όπου ο εντοπισμός της ακριβούς θέσης της βλάβης είναι κρίσιμος για την ταχεία αποκατάσταση της λειτουργίας.

2.3.9 Ανίχνευση και Απομόνωση Βλαβών (FDI)

Ο Wavelet Transform είναι, όπως είδαμε προηγουμένως, ένα πολύ ισχυρό εργαλείο ανάλυσης σημάτων, το οποίο επιτρέπει την ταυτόχρονη ανάλυση των σημάτων σε χρόνο και συχνότητα. Η ευελιξία του το καθιστά ιδιαίτερα χρήσιμο σε συστήματα ηλεκτρικής ενέργειας για την ανίχνευση και τον εντοπισμό βλαβών, καθώς και σε πολλές άλλες εφαρμογές όπου απαιτείται η λεπτομερής ανάλυση δυναμικών σημάτων [33].

Η Ανίχνευση και Απομόνωση Βλαβών αποτελεί ένα κρίσιμο στοιχείο για τη διατήρηση της ασφάλειας και της αξιοπιστίας των βιομηχανικών συστημάτων ελέγχου. Η πλειονότητα των μεθόδων FDI που εφαρμόζονται, βασίζεται είτε σε μοντέλα φυσικής είτε σε δεδομένα. Οι μεθοδολογίες που βασίζονται σε δεδομένα έχουν σημειώσει σημαντική πρόοδο, ιδίως με την πρόοδο της τεχνητής νοημοσύνης. Ωστόσο, πολλές από αυτές παραβλέπουν τις χωρικές και χρονικές συσχετίσεις που υπάρχουν στα δεδομένα που συλλέγονται από βιομηχανικά δίκτυα αισθητήρων και ενεργοποιητών [34].

2.3.10 GCNNs και FDI

Τα βιομηχανικά συστήματα γίνονται ολοένα και πιο πολύπλοκα και μεγάλης κλίμακας, με δεκάδες ή και εκατοντάδες αισθητήρες και ενεργοποιητές να συλλέγουν και να μεταδίδουν δεδομένα σε πραγματικό χρόνο. Αυτά τα δεδομένα είναι κρίσιμα για τον έλεγχο, την παρακολούθηση και τη διάγνωση καταστάσεων.

Ωστόσο, οι αισθητήρες μπορεί να παρουσιάσουν σφάλματα λόγω ηλεκτρομαγνητικών παρεμβολών, φυσικής φθοράς ή σφαλμάτων επικοινωνίας. Η μη έγκαιρη ανίχνευση τέτοιων σφαλμάτων μπορεί να οδηγήσει σε λανθασμένες εντολές ελέγχου, με αποτέλεσμα χαμηλή απόδοση ή ακόμη και καταστροφικές συνέπειες [35].

Στο πλαίσιο αυτό, η Ανίχνευση και Απομόνωση Βλαβών (FDI) έχει αποκτήσει αυξημένη σημασία. Οι υπάρχουσες μέθοδοι FDI μπορούν να κατηγοριοποιηθούν σε δύο κύριες κατηγορίες:

1. **Μέθοδοι που βασίζονται σε μοντέλα:** Χρησιμοποιούν φυσικά ή μαθηματικά μοντέλα για να προβλέψουν την κανονική συμπεριφορά του συστήματος και συγκρίνουν τις προβλέψεις με τα πραγματικά δεδομένα.

Πλεονεκτήματα: ακριβείς υπό ιδανικές συνθήκες

Μειονεκτήματα: υψηλή εξάρτηση από την ακρίβεια του μοντέλου, δυσκολία σε δυναμικά ή μη γραμμικά συστήματα

2. **Μεθοδολογίες που βασίζονται σε δεδομένα:** Αξιοποιούν τεχνικές μηχανικής μάθησης για την αναγνώριση προτύπων και την εκπαίδευση μοντέλων σε ιστορικά δεδομένα.

Πλεονεκτήματα: μη απαίτηση ύπαρξης μοντέλου, καλή προσαρμοστικότητα

Μειονεκτήματα: συχνά αγνοούν συσχετίσεις μεταξύ αισθητήρων και χρονική εξάρτηση

Η πλειοψηφία των υφιστάμενων μεθόδων που βασίζονται σε δεδομένα δεν λαμβάνει υπόψη τη δομή και την τοπολογία του δικτύου. Οι αισθητήρες, όμως, δεν λειτουργούν απομονωμένα – έχουν χωρικές και χρονικές αλληλεπιδράσεις που, αν ληφθούν υπόψη, μπορούν να οδηγήσουν σε καλύτερη ανίχνευση [36].

Για την αντιμετώπιση αυτών των προκλήσεων, εφαρμόζεται ένα νέο πλαίσιο βασισμένο σε GCNNs, τα οποία είναι ικανά να:

1. Ενσωματώνουν τη χωρική τοπολογία των αισθητήρων (ποιοι είναι κοντά/συνδεδεμένοι)
2. Επεξεργάζονται χρονικές σειρές δεδομένων
3. Εκπαιδεύονται για ταξινόμηση σφαλμάτων και εντοπισμό της θέσης και του τύπου της βλάβης [37]

Το GCNN βασίζεται στη θεωρία γραφημάτων, όπου κάθε κόμβος αντιστοιχεί σε έναν αισθητήρα, και οι ακμές αντιπροσωπεύουν σχέσεις (φυσικές ή λογικές) μεταξύ τους. Αυτό προσφέρει μια φυσική και ισχυρή αναπαράσταση του βιομηχανικού δικτύου.

Στο Κεφάλαιο 4 της Υλοποίησης, παρουσιάζεται ένα GCNN για την ανίχνευση και απομόνωση βλαβών σε βιομηχανικά δίκτυα. Το GCNN επιτρέπει την ενσωμάτωση της τοπολογίας του δικτύου και της χρονικής συμπεριφοράς των σημάτων σε ένα ενιαίο πλαίσιο εκμάθησης.

Η προτεινόμενη μέθοδος περιλαμβάνει:

1. Ένα μηχανισμό προ-επεξεργασίας δεδομένων, ο οποίος κατασκευάζει ένα γράφημα που αναπαριστά το δίκτυο αισθητήρων.
2. Μια δομή GCNN, που εξάγει χαρακτηριστικά τόσο σε χωρικό όσο και σε χρονικό επίπεδο.
3. Ένα μοντέλο ταξινόμησης, που εντοπίζει τη θέση και τον τύπο της βλάβης με υψηλή ακρίβεια.

Για την αξιολόγηση της αποτελεσματικότητας της προσέγγισης, πραγματοποιούνται πειράματα σε ένα πραγματικό σύστημα αισθητήρων πολλαπλών σημείων

.

Κεφάλαιο 3 Μεθοδολογία

Η μεθοδολογία της ανίχνευσης και διαχείρισης βλαβών σε ηλεκτρικά δίκτυα και βιομηχανικές εφαρμογές περιλαμβάνει μια πολυεπίπεδη διαδικασία που βασίζεται στην προηγμένη ανάλυση δεδομένων. Σε αυτή τη διαδικασία, χρησιμοποιούνται τεχνικές μηχανικής μάθησης και τεχνητών νευρωνικών δικτύων για την αναγνώριση, την ανάλυση και τον εντοπισμό βλαβών, ενώ παράλληλα εξασφαλίζεται η ταχεία απόκριση για την αποκατάσταση της λειτουργίας του συστήματος. Η επιλογή των αλγορίθμων και των μεθόδων που χρησιμοποιούνται είναι ζωτικής σημασίας για την επιτυχία της διαδικασίας.

3.1 Περιγραφή των Δεδομένων Υπό Εξέταση

Η ανίχνευση βλαβών στα ηλεκτρικά δίκτυα απαιτεί την πρόσβαση σε ποικιλία δεδομένων, τα οποία προέρχονται από διαφορετικές πηγές και συστήματα. Τα δεδομένα αυτά είναι συνήθως σε μορφή συνεχών σημάτων που καταγράφονται από αισθητήρες και συστήματα παρακολούθησης σε πραγματικό χρόνο.

3.1.1 Πηγές Δεδομένων

Δεδομένα από γραμμές μεταφοράς: Αυτά τα δεδομένα περιλαμβάνουν μετρήσεις τάσης, ρεύματος και φάσης από τις εναέριες γραμμές μεταφοράς, καθώς και πληροφορίες σχετικά με την ισορροπία του συστήματος και τις παρατυπίες στη ροή του ρεύματος. Οι μεταβολές αυτών των μεγεθών υποδεικνύουν διακοπές, βραχυκυκλώματα ή άλλες βλάβες.

Δεδομένα από αποκεντρωμένη παραγωγή ενέργειας: Στα σύγχρονα ενεργειακά δίκτυα, η χρήση φωτοβολταϊκών, ανεμογεννητριών και άλλων αποκεντρωμένων πηγών ενέργειας παράγει δεδομένα σχετικά με τη μεταβλητότητα στην παραγωγή ισχύος. Αυτές οι μεταβολές είναι συχνά ασύμβατες με τις παραδοσιακές προβλέψεις, δημιουργώντας νέες προκλήσεις για την ανίχνευση βλαβών.

Δεδομένα από βιομηχανικούς αισθητήρες: Στα βιομηχανικά συστήματα και τα συστήματα οχημάτων, οι αισθητήρες παρακολουθούν σε πραγματικό χρόνο παραμέτρους όπως η θερμοκρασία, η πίεση σε αγωγούς ή δεξαμενές, και η κατάσταση της μπαταρίας.

Αυτά τα δεδομένα χρησιμοποιούνται για την πρόβλεψη και ανίχνευση σφαλμάτων πριν προκαλέσουν σοβαρές βλάβες.

3.1.2 Προεπεξεργασία Δεδομένων

Η προεπεξεργασία των δεδομένων είναι ένα κρίσιμο βήμα για την επιτυχία των αλγορίθμων που θα χρησιμοποιηθούν. Οι διαδικασίες προεπεξεργασίας περιλαμβάνουν:

Καθαρισμός δεδομένων: Αφαιρούνται οι ανωμαλίες και τα μη αντιπροσωπευτικά δεδομένα (π.χ. κενά ή θορυβώδη δεδομένα) για να αποφευχθούν σφάλματα κατά την εκπαίδευση των αλγορίθμων.

Κανονικοποίηση δεδομένων: Η κανονικοποίηση εξασφαλίζει ότι όλες οι μεταβλητές εισόδου βρίσκονται στην ίδια κλίμακα, αποτρέποντας την ανισορροπία κατά την εκπαίδευση των νευρωνικών δικτύων. Για παράδειγμα, οι τάσεις και τα ρεύματα που καταγράφονται σε διαφορετικές περιοχές του δικτύου πρέπει να κανονικοποιηθούν ώστε να γίνουν συγκρίσιμα. Εδώ περιλαμβάνονται και τα δεδομένα που έχουν δημιουργηθεί σε κάθε υλοποίηση για τους σκοπούς δοκιμής και εκπαίδευσης της ΤΝ.

Διαχωρισμός σε σύνολα εκπαίδευσης και δοκιμής: Το αρχικό σύνολο δεδομένων χωρίζεται σε σύνολο εκπαίδευσης (training set) και σύνολο δοκιμής (testing set), διασφαλίζοντας ότι τα μοντέλα θα αξιολογηθούν με ακρίβεια σε πραγματικές συνθήκες λειτουργίας.

3.2 Επιλογή Αλγορίθμων Μηχανικής Μάθησης και Νευρωνικών Δικτύων

Η επιλογή των αλγορίθμων ανίχνευσης είναι κρίσιμη για την επιτυχή εκτέλεση των εργασιών διάγνωσης βλαβών. Τα MLP και RNN αποτελούν τις κύριες τεχνολογίες που χρησιμοποιούνται στην πρώτη υλοποίηση λόγω της ικανότητάς τους να επεξεργάζονται μεγάλα και πολύπλοκα σύνολα δεδομένων, αναγνωρίζοντας μοτίβα που υποδεικνύουν την παρουσία βλάβης.


3.2.1 Σκοπός της υλοποίησης με iFD

Ο σκοπός της υλοποίησης αυτής είναι η παρουσίαση μιας απλής αλλά ισχυρής αρχιτεκτονικής FDI, η οποία:

1. Βασίζεται στην εκπαίδευση ενός μόνο νευρωνικού εκτιμητή που αντικαθιστά τις παραδοσιακές τράπεζες εκτιμητών.

2. Είναι σε θέση να διαχειρίζεται βλάβες τόσο σε αισθητήρες όσο και σε ενεργοποιητές, χρησιμοποιώντας κατάλληλες τεχνικές ανασύνθεσης σημάτων (substitution signals).
3. Παρέχει ανίχνευση και απομόνωση βλαβών σε πραγματικό χρόνο, με υψηλή ακρίβεια και χαμηλό υπολογιστικό κόστος.
4. Είναι ιδιαίτερα κατάλληλη για ενσωματωμένα συστήματα, λόγω της χαμηλής απαιτούμενης μνήμης και υπολογιστικής ισχύος [38].

Η λειτουργία της αρχιτεκτονικής που θα να αναλυθεί στην επόμενη παράγραφο, συνοψίζεται στην Εικόνα 3.1, όπου φαίνεται ο συνολικός κύκλος ανίχνευσης σφαλμάτων.



Εικόνα 3.1: Σύγκριση μεταξύ τυπικής τράπεζας εκτιμητών (bank of estimators) και της προτεινόμενης μεθόδου iFD με έναν ενιαίο εκτιμητή [38]

Για την ανίχνευση βλαβών με παραδοσιακές μεθόδους, απαιτούνται πολλοί εκτιμητές, γεγονός που αυξάνει σημαντικά το υπολογιστικό κόστος και τη δυσκολία της κλιμάκωσης. Αντίθετα, η μέθοδος iFD που αναπτύχθηκε στο [38] επιτυγχάνει την εκτίμηση όλων των σημάτων με έναν και μόνο εκτιμητή, μειώνοντας δραστικά την πολυπλοκότητα και καθιστώντας το σύστημα πιο αποδοτικό και ευέλικτο. Η αρχιτεκτονική iFD αποτελείται από τρία βασικά μέρη:

Νευρωνικός Εκτιμητής (NN Estimator): Εκπαιδεύεται με τέτοιο τρόπο ώστε να αναπαράγει τις κανονικές τιμές των μετρούμενων μεταβλητών, ακόμη και όταν κάποιες από τις εισόδους (αισθητήρες ή ενεργοποιητές) είναι προβληματικές.


Μονάδα Υπολογισμού Residuals (RG): Υπολογίζει την απόκλιση μεταξύ των πραγματικών τιμών και των τιμών που προβλέπει το νευρωνικό δίκτυο. Η απόκλιση αυτή (residual) αποτελεί ένδειξη σφάλματος.

Μονάδα Λήψης Απόφασης (DM): Επεξεργάζεται τα residuals και αποφαινεται αν υπάρχει σφάλμα. Εάν το σφάλμα είναι σταθερό και ξεπερνά καθορισμένα κατώφλια για συγκεκριμένο χρονικό διάστημα, απομονώνει το προβληματικό σήμα (μέσω σήματος IS) και δίνει εντολή για αναδιαμόρφωση ελέγχου (μέσω σήματος RS).

Σύστημα Βασικής Λειτουργίας (Base Line System – BS): το BS αναφέρεται στο πρότυπο μοντέλο βασικής λειτουργίας του ενεργοποιητή ή του αισθητήρα. Το BS αναπαριστά τη φυσιολογική συμπεριφορά του συστήματος υπό συνθήκες ορθής λειτουργίας και χρησιμοποιείται ως σημείο αναφοράς για τη διαδικασία ανίχνευσης σφαλμάτων. Με τη σύγκριση των πραγματικών σημάτων λειτουργίας με τα αναμενόμενα σήματα που παράγει το BS, το σύστημα είναι σε θέση να ανιχνεύει έγκαιρα αποκλίσεις που υποδεικνύουν την ύπαρξη βλαβών. Η ακρίβεια του BS είναι σημαντική, καθώς μια ακριβής αναπαράσταση της φυσιολογικής λειτουργίας διασφαλίζει την αξιοπιστία του συνολικού μηχανισμού FDI και μειώνει τον κίνδυνο ψευδών συναγερμών.

Η αρχιτεκτονική αυτή είναι ανεξάρτητη από την πολυπλοκότητα του συστήματος. Δηλαδή, ανεξάρτητα από τον αριθμό των αισθητήρων ή ενεργοποιητών, εξακολουθεί να χρησιμοποιείται ένας μόνο εκτιμητής. Αυτό οδηγεί σε σημαντική μείωση της πολυπλοκότητας, χωρίς συμβιβασμούς στην απόδοση.

Η Εικόνα 3.2 παρουσιάζει μια αρχιτεκτονική ευφυούς διάγνωσης βλαβών (iFD) με χρήση νευρωνικού εκτιμητή. Το δυναμικό σύστημα (Engineering Plant) δέχεται είσοδο u και παράγει έξοδο y , οι οποίες διέρχονται από μονάδες απομόνωσης που περιλαμβάνουν τοπικούς ελεγκτές. Ένας εκτιμητής βασισμένος σε νευρωνικά δίκτυα υπολογίζει τις εκτιμώμενες τιμές $\hat{u}, \hat{y}$ οι οποίες συγκρίνονται με τις πραγματικές για τη δημιουργία υπολειμμάτων μέσω της γεννήτριας υπολειμμάτων σφάλματος (Residual Generator -RG). Τα κατάλοιπα αναλύονται από τον μηχανισμό απόφασης (Descision Mechanishm), ο οποίος ενεργοποιεί τα σήματα απομόνωσης για την ανίχνευση και διαχείριση των πιθανών σφαλμάτων.



Εικόνα 3.2: α) Γενικό διάγραμμα ενός ενεργοποιητή – αισθητήρα του προτεινόμενου FDI

β) η λειτουργία BS [38]

3.2.2 Αρχιτεκτονική Ανίχνευσης Σφαλμάτων

Η βασική αρχή πίσω από την προτεινόμενη προσέγγιση είναι η εκπαίδευση ενός ενιαίου εκτιμητή, που μπορεί να παράγει τις αναμενόμενες εξόδους ενός συστήματος, ακόμη και όταν ορισμένες εισόδους είναι ελαττωματικές. Ο εκτιμητής είναι ένα νευρωνικό δίκτυο που μαθαίνει να παραβλέπει ή να «αντισταθμίζει» τα προβληματικά σήματα εισόδου και να εξάγει εκτιμήσεις των επιθυμητών σημάτων εξόδου, βασισμένο στα υγιή δεδομένα.

Ο στόχος της εκπαίδευσης είναι η παραγωγή ενός μοντέλου που μπορεί να λειτουργήσει με όλες τις πιθανές συνθήκες εισόδου, είτε αυτές είναι πλήρως υγιείς, είτε περιλαμβάνουν βλάβες σε έναν ή περισσότερους αισθητήρες ή ενεργοποιητές.

Η εκπαίδευση του νευρωνικού εκτιμητή πραγματοποιείται με βάση έναν πίνακα δεδομένων, ο οποίος περιέχει όλους τους δυνατούς συνδυασμούς εισόδων και εξόδων, υγιών και ελαττωματικών. Για κάθε γραμμή του πίνακα, το μοντέλο μαθαίνει να εκτιμά τις πραγματικές τιμές εξόδου του συστήματος.

Δομή του πίνακα εκπαίδευσης:

1. Για κάθε πιθανή κατάσταση λειτουργίας (υγιής ή με σφάλμα), δημιουργείται ένα σύνολο παραδειγμάτων εκπαίδευσης.
2. Τα παραδείγματα περιλαμβάνουν:
 - i. Πραγματικές εισόδους (με ή χωρίς σφάλματα)
 - ii. Τιμές εισόδων που αντικαθιστούν τα ελαττωματικά σήματα (λειτουργίες υποκατάστασης – substitution functions)
 - iii. Εκτιμώμενες τιμές εξόδων (στόχοι)

Μέθοδοι υποκατάστασης σημάτων (substitution functions):

1. Για προβληματικά σήματα, χρησιμοποιούνται ειδικές συναρτήσεις C_y και C_u που αντικαθιστούν το σήμα με:
 - i. Θόρυβο (noise)
 - ii. Σταθερή τιμή
 - iii. Γραμμική απόκλιση
 - iv. Προσομοίωση γενικής δυναμικής

Αυτές οι τεχνικές υποκατάστασης επιτρέπουν στο νευρωνικό δίκτυο να αναγνωρίζει τα ελαττωματικά σήματα και να μάθει πώς να τα αγνοεί ή να τα διορθώνει, προκειμένου να παράγει ακριβή εκτίμηση των εξόδων του συστήματος.

Η προσέγγιση αυτή οδηγεί σε σημαντική μείωση της πολυπλοκότητας του FDI και αποφεύγει τον πολλαπλασιασμό των εκτιμητών, διατηρώντας υψηλή ακρίβεια στην ανίχνευση σφαλμάτων [38].

3.2.3 Υπολογισμός Residuals (Υπολειμμάτων Σφάλματος)

Η μονάδα υπολογισμού residual (RG) είναι υπεύθυνη για τον υπολογισμό της απόκλισης μεταξύ της πραγματικής τιμής ενός σήματος (είτε αισθητήρα είτε ενεργοποιητή) και της τιμής που εκτιμά το νευρωνικό δίκτυο. Το residual είναι μια ένδειξη για την παρουσία σφάλματος. Ο υπολογισμός των residuals βασίζεται στη μέση τετραγωνική απόκλιση μεταξύ των πραγματικών και των εκτιμημένων τιμών ενός σήματος, σε ένα κινούμενο παράθυρο N δειγμάτων.

Η Εικόνα 3.3 απεικονίζει τη διαμόρφωση των δεδομένων που χρησιμοποιούνται για την εκπαίδευση του εκτιμητή iFD, με στόχο την επίτευξη ανοχής σε βλάβες αισθητήρων και ενεργοποιητών.

Η δομή του πίνακα αναλύεται ως εξής:

1. Στήλες Εισόδων (Inputs):

- i. **$y(t)$** : Μετρήσεις εξόδου από αισθητήρες στη χρονική στιγμή t .
- ii. **$u(t)$** : Σήματα ελέγχου που εφαρμόζονται στους ενεργοποιητές.
- iii. **$Cy(t)$** : Υποκατάστατο (substitution) του σήματος εξόδου, ειδικά σχεδιασμένο για να αντικαθιστά ένα προβληματικό σήμα αισθητήρα όταν ανιχνεύεται βλάβη.
- iv. **$Cu(t)$** : Υποκατάστατο του σήματος εισόδου (ενεργοποιητή) σε περίπτωση βλάβης.

2. Στήλες Εξόδων (Outputs):

- i. **$\hat{y}(t)$** : Εκτιμώμενες τιμές εξόδου, που αναπαράγουν τις υγιείς συνθήκες λειτουργίας ακόμα και όταν κάποιες από τις εισόδους (y ή u) είναι προβληματικές.

Actuator/ Sensor Set Number	Actuator/ Sensor Status	Training data										Estimated sensor/actuators signals													
		y_1	y_2	y_3	$\dots$	y_{n_y}	u_1	u_2	u_3	$\dots$	u_{n_u}	$\hat{y}_1$	$\hat{y}_2$	$\hat{y}_3$	$\dots$	$\hat{y}_{n_{\hat{y}}}$	$\hat{u}_1$	$\hat{u}_2$	$\hat{u}_3$	$\dots$	$\hat{u}_{n_{\hat{u}}}$				
1	Healthy sets:	$D_{y_1}^1$	$D_{y_2}^1$	$D_{y_3}^1$	$\dots$	$D_{y_{n_y}}^1$	$D_{u_1}^1$	$D_{u_2}^1$	$D_{u_3}^1$	$\dots$	$D_{u_{n_u}}^1$	$D_{y_1}^1$	$D_{y_2}^1$	$D_{y_3}^1$	$\dots$	$D_{y_{n_{\hat{y}}}}^1$	$D_{u_1}^1$	$D_{u_2}^1$	$D_{u_3}^1$	$\dots$	$D_{u_{n_{\hat{u}}}}^1$				
	$\mathcal{Y} = y_1, y_2, \dots, y_{n_y}$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$				
	$\mathcal{U} = u_1, u_2, \dots, u_{n_u}$	$D_{y_1}^k$	$D_{y_2}^k$	$D_{y_3}^k$	$\dots$	$D_{y_{n_y}}^k$	$D_{u_1}^k$	$D_{u_2}^k$	$D_{u_3}^k$	$\dots$	$D_{u_{n_u}}^k$	$D_{y_1}^k$	$D_{y_2}^k$	$D_{y_3}^k$	$\dots$	$D_{y_{n_{\hat{y}}}}^k$	$D_{u_1}^k$	$D_{u_2}^k$	$D_{u_3}^k$	$\dots$	$D_{u_{n_{\hat{u}}}}^k$				
2	Faulty set:	$C_{y_1}^2$	$D_{y_2}^2$	$D_{y_3}^2$	$\dots$	$D_{y_{n_y}}^2$	$D_{u_1}^2$	$D_{u_2}^2$	$D_{u_3}^2$	$\dots$	$D_{u_{n_u}}^2$	$C_{y_1}^2$	$D_{y_2}^2$	$D_{y_3}^2$	$\dots$	$D_{y_{n_{\hat{y}}}}^2$	$D_{u_1}^2$	$D_{u_2}^2$	$D_{u_3}^2$	$\dots$	$D_{u_{n_{\hat{u}}}}^2$				
	y_1	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$					
		$C_{y_1}^k$	$D_{y_2}^k$	$D_{y_3}^k$	$\dots$	$D_{y_{n_y}}^k$	$D_{u_1}^k$	$D_{u_2}^k$	$D_{u_3}^k$	$\dots$	$D_{u_{n_u}}^k$	$C_{y_1}^k$	$D_{y_2}^k$	$D_{y_3}^k$	$\dots$	$D_{y_{n_{\hat{y}}}}^k$	$D_{u_1}^k$	$D_{u_2}^k$	$D_{u_3}^k$	$\dots$	$D_{u_{n_{\hat{u}}}}^k$				
3	Faulty set:	$C_{y_1}^3$	$C_{y_2}^3$	$D_{y_3}^3$	$\dots$	$D_{y_{n_y}}^3$	$D_{u_1}^3$	$D_{u_2}^3$	$D_{u_3}^3$	$\dots$	$D_{u_{n_u}}^3$	$C_{y_1}^3$	$C_{y_2}^3$	$D_{y_3}^3$	$\dots$	$D_{y_{n_{\hat{y}}}}^3$	$D_{u_1}^3$	$D_{u_2}^3$	$D_{u_3}^3$	$\dots$	$D_{u_{n_{\hat{u}}}}^3$				
	y_1, y_2	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$					
		$C_{y_1}^k$	$C_{y_2}^k$	$D_{y_3}^k$	$\dots$	$D_{y_{n_y}}^k$	$D_{u_1}^k$	$D_{u_2}^k$	$D_{u_3}^k$	$\dots$	$D_{u_{n_u}}^k$	$C_{y_1}^k$	$C_{y_2}^k$	$D_{y_3}^k$	$\dots$	$D_{y_{n_{\hat{y}}}}^k$	$D_{u_1}^k$	$D_{u_2}^k$	$D_{u_3}^k$	$\dots$	$D_{u_{n_{\hat{u}}}}^k$				
4	Faulty set:	$C_{y_1}^4$	$C_{y_2}^4$	$D_{y_3}^4$	$\dots$	$D_{y_{n_y}}^4$	$C_{u_1}^4$	$D_{u_2}^4$	$D_{u_3}^4$	$\dots$	$D_{u_{n_u}}^4$	$C_{y_1}^4$	$C_{y_2}^4$	$D_{y_3}^4$	$\dots$	$D_{y_{n_{\hat{y}}}}^4$	$C_{u_1}^4$	$D_{u_2}^4$	$D_{u_3}^4$	$\dots$	$D_{u_{n_{\hat{u}}}}^4$				
	y_1, y_2, u_1	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$					
		$C_{y_1}^k$	$C_{y_2}^k$	$D_{y_3}^k$	$\dots$	$D_{y_{n_y}}^k$	$C_{u_1}^k$	$D_{u_2}^k$	$D_{u_3}^k$	$\dots$	$D_{u_{n_u}}^k$	$C_{y_1}^k$	$C_{y_2}^k$	$D_{y_3}^k$	$\dots$	$D_{y_{n_{\hat{y}}}}^k$	$C_{u_1}^k$	$D_{u_2}^k$	$D_{u_3}^k$	$\dots$	$D_{u_{n_{\hat{u}}}}^k$				
5	Faulty set:	$C_{y_1}^5$	$D_{y_2}^5$	$D_{y_3}^5$	$\dots$	$D_{y_{n_y}}^5$	$C_{u_1}^5$	$C_{u_2}^5$	$D_{u_3}^5$	$\dots$	$D_{u_{n_u}}^5$	$C_{y_1}^5$	$D_{y_2}^5$	$D_{y_3}^5$	$\dots$	$D_{y_{n_{\hat{y}}}}^5$	$C_{u_1}^5$	$C_{u_2}^5$	$D_{u_3}^5$	$\dots$	$D_{u_{n_{\hat{u}}}}^5$				
	y_1, u_1, u_2	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$					
		$C_{y_1}^k$	$D_{y_2}^k$	$D_{y_3}^k$	$\dots$	$D_{y_{n_y}}^k$	$C_{u_1}^k$	$C_{u_2}^k$	$D_{u_3}^k$	$\dots$	$D_{u_{n_u}}^k$	$C_{y_1}^k$	$D_{y_2}^k$	$D_{y_3}^k$	$\dots$	$D_{y_{n_{\hat{y}}}}^k$	$C_{u_1}^k$	$C_{u_2}^k$	$D_{u_3}^k$	$\dots$	$D_{u_{n_{\hat{u}}}}^k$				
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$					
n_{yu}	Faulty sets:	$C_{y_1}^{n_{yu}}$	$C_{y_2}^{n_{yu}}$	$\dots$	$C_{y_{n_y-1}}^{n_{yu}}$	$D_{y_{n_y}}^{n_{yu}}$	$C_{u_1}^{n_{yu}}$	$C_{u_2}^{n_{yu}}$	$\dots$	$C_{u_{n_u-1}}^{n_{yu}}$	$D_{u_{n_u}}^{n_{yu}}$	$C_{y_1}^{n_{yu}}$	$C_{y_2}^{n_{yu}}$	$\dots$	$C_{y_{n_{\hat{y}}-1}}^{n_{yu}}$	$D_{y_{n_{\hat{y}}}}^{n_{yu}}$	$C_{u_1}^{n_{yu}}$	$C_{u_2}^{n_{yu}}$	$\dots$	$C_{u_{n_{\hat{u}}-1}}^{n_{yu}}$	$D_{u_{n_{\hat{u}}}}^{n_{yu}}$				
	$y_1, \dots, y_{n_y-1}$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$					
	$u_1, \dots, u_{n_u-1}$	$C_{y_1}^{n_{yu}}$	$C_{y_2}^{n_{yu}}$	$\dots$	$C_{y_{n_y-1}}^{n_{yu}}$	$D_{y_{n_y}}^{n_{yu}}$	$C_{u_1}^{n_{yu}}$	$C_{u_2}^{n_{yu}}$	$\dots$	$C_{u_{n_u-1}}^{n_{yu}}$	$D_{u_{n_u}}^{n_{yu}}$	$C_{y_1}^{n_{yu}}$	$C_{y_2}^{n_{yu}}$	$\dots$	$C_{y_{n_{\hat{y}}-1}}^{n_{yu}}$	$D_{y_{n_{\hat{y}}}}^{n_{yu}}$	$C_{u_1}^{n_{yu}}$	$C_{u_2}^{n_{yu}}$	$\dots$	$C_{u_{n_{\hat{u}}-1}}^{n_{yu}}$	$D_{u_{n_{\hat{u}}}}^{n_{yu}}$				

Εικόνα 3.3: Δομή των δεδομένων που χρησιμοποιούνται για την εκπαίδευση iFD [38]

Η χρήση των υποκατάστατων $C_y(t)$ και $C_u(t)$ είναι σημαντική για τη διαδικασία εκπαίδευσης, καθώς επιτρέπει στο NN να εκπαιδευτεί σε συνθήκες όπου είτε οι αισθητήρες είτε οι ενεργοποιητές παρουσιάζουν ανωμαλίες. Αντί να αποκλείονται αυτές οι περιπτώσεις ή να εκπαιδεύεται ξεχωριστό δίκτυο για κάθε πιθανό σενάριο, εισάγεται ένας μηχανισμός όπου:

1. Τα προβληματικά σήματα αντικαθίστανται με θόρυβο, σταθερές τιμές ή κατάλληλα μοντελοποιημένες μεταβολές.
2. Τα υγιή σήματα παραμένουν στην ίδια κατάσταση, προσφέροντας ένα φυσικό πλαίσιο κανονικής λειτουργίας.

Έτσι, το μοντέλο μαθαίνει να:

1. Αγνοεί/αντέχει στα προβληματικά σήματα χωρίς να επηρεάζεται η εκτίμηση της κατάστασης του συστήματος.
2. Προσαρμόζει δυναμικά τις εκτιμήσεις του χρησιμοποιώντας μόνο τις υγιείς πηγές πληροφορίας.

Η δομή αυτή καθιστά το δίκτυο εξαιρετικά ανθεκτικό, με δυνατότητα **συνεχούς λειτουργίας** ακόμη και σε περιπτώσεις μερικής απώλειας πληροφορίας.

Επιπλέον, με αυτή τη στρατηγική εκπαίδευσης, το iFD:

1. Δεν απαιτεί την ταυτόχρονη λειτουργία πολλαπλών εκτιμητών.
2. Δεν προϋποθέτει ότι όλες οι εισόδους είναι διαθέσιμες σε κάθε χρονικό βήμα.
3. Επιτυγχάνει γενίκευση σε νέα σενάρια βλαβών που δεν είχαν εμφανιστεί στο training set.

Η μαθηματική σχέση που ακολουθεί αποτυπώνει αυτή την πράξη, προσφέροντας έναν ευαίσθητο και στατιστικά ομαλοποιημένο δείκτη σφάλματος. Όταν η τιμή του residual υπερβεί το προκαθορισμένο όριο, η μονάδα λήψης απόφασης ενεργοποιεί τις ενέργειες απομόνωσης.

Ο υπολογισμός γίνεται με την παρακάτω σχέση [14]:

$$r_{y_j} = \frac{1}{N} \sum_{i=j-(N-1)}^j (y_i - \hat{y}_i)^2$$

Όπου:

1. y_j : η πραγματική τιμή του αισθητήρα σήματος στη χρονική στιγμή j
2. $\hat{y}_j$: η εκτιμημένη τιμή από το νευρωνικό δίκτυο
3. N : ο μέσος αριθμός πρόσφατων δειγμάτων

Το residual είναι ουσιαστικά ένας μέσος τετραγωνικός σφάλματος (RMSE) μέσα σε ένα χρονικό παράθυρο μεγέθους N . Αυτή η τεχνική μειώνει τον θόρυβο και τις στιγμιαίες αποκλίσεις που δεν σχετίζονται με πραγματικά σφάλματα.

3.2.4 Μονάδα Λήψης Απόφασης (Decision Mechanism – DM)

Η Μονάδα Λήψης Απόφασης (Decision Mechanism – DM) είναι υπεύθυνη για την ενεργοποίηση της διαδικασίας απομόνωσης και επαναδιαμόρφωσης ελέγχου, μόλις το residual ενός σήματος ξεπεράσει συγκεκριμένο κατώφλι. Ανιχνεύει την επιμονή του σφάλματος για συγκεκριμένο αριθμό χρονικών βημάτων και, εφόσον αυτό επιβεβαιωθεί, θέτει εκτός λειτουργίας το προβληματικό σήμα και ενημερώνει τον ελεγκτή ώστε να προσαρμοστεί. Η θέση της μονάδας φαίνεται στο κάτω κεντρικό τμήμα της Εικόνας 3.2.

Η απόφαση για το αν ένα σήμα είναι ελαττωματικό βασίζεται στο αν το αντίστοιχο residual υπερβαίνει ένα προκαθορισμένο κατώφλι τιμής (threshold) για συνεχόμενα M δείγματα. Το κατώφλι καθορίζεται είτε εμπειρικά είτε μέσω στατιστικής ανάλυσης των residuals στη φυσιολογική λειτουργία [38].

Ειδικότερα:

1. Αν $r_{y_j} > T_j$ για M διαδοχικά βήματα, το σήμα θεωρείται προβληματικό.


2. Το σήμα IS ενεργοποιείται ώστε να απομονωθεί το σήμα από τον ελεγκτή.
3. Το σήμα RS ενεργοποιεί τον επαναδιαμορφωμένο ελεγκτή που χρησιμοποιεί μόνο τα "υγιή" σήματα εισόδου.

Ο έλεγχος συνεχίζεται με χρήση των διαθέσιμων, αποδεδειγμένα υγιών σημάτων, διασφαλίζοντας τη συνέχιση της λειτουργίας του συστήματος.

Η ευαισθησία του αλγορίθμου μπορεί να προσαρμοστεί μέσω των παραμέτρων N και M , όπως και των κατωφλίων T_j . Αυτή η παραμετροποίηση επιτρέπει στο σύστημα να προσαρμόζεται σε διαφορετικές εφαρμογές και συνθήκες λειτουργίας.

3.2.4.1 Σκοπός της υλοποίησης με GCNN

Η Εικόνα 3.4 παρουσιάζει τη βασική φιλοσοφία πίσω από την προτεινόμενη αρχιτεκτονική: τα σήματα από αισθητήρες οργανώνονται ως κόμβοι σε ένα γράφημα όπου οι μεταξύ τους συσχετίσεις αποτυπώνονται ως ακμές. Με τη βοήθεια των GCNN, το μοντέλο λαμβάνει υπόψη του τόσο τα χρονικά χαρακτηριστικά κάθε σήματος όσο και την απόσταση μεταξύ των αισθητήρων. Το αποτέλεσμα είναι μια ενιαία προσέγγιση που επιτρέπει την ανίχνευση και απομόνωση βλαβών με υψηλή ακρίβεια και ταχύτητα, ακόμα και σε μεγάλα, περίπλοκα δίκτυα [17].



Εικόνα 3.4: Ένα GCNN με 4 κόμβους ($N=4$). Τα X_1 έως X_4 αντιπροσωπεύουν τα σήματα στον κόμβο n . Τα g_1, g_2, g_3 αντιπροσωπεύουν ένα φίλτρο προς εκμάθηση και τα λ_N αντιπροσωπεύουν την ιδιοτιμή i [39]

Η αρχιτεκτονική της αποτελείται από τρία βασικά στάδια:

1. Κατασκευή του γραφήματος (graph construction)
2. Μονάδα γραφικής συνελκτικής επεξεργασίας (GCNN module)
3. Ταξινομητής (classifier)

Ακολουθεί η αναλυτική εξήγηση κάθε βήματος:

3.2.4.2 Κατασκευή του Γραφήματος

Τα δεδομένα που προέρχονται από αισθητήρες είναι αρχικά χρονοσειρές. Για την αναπαράσταση της χωρικής τοπολογίας και τη συσχέτιση μεταξύ των αισθητήρων, το σύστημα μοντελοποιείται ως γράφημα $G = (V, E)$, όπου:

1. V : το σύνολο των κόμβων, με κάθε κόμβο να αντιπροσωπεύει έναν αισθητήρα
2. E : το σύνολο των ακμών, οι οποίες καθορίζουν τη σχέση μεταξύ των κόμβων

Η συνελκτική επεξεργασία (convolution) στα γραφικά δεδομένα εφαρμόζεται με βάση τον κανονικοποιημένο πίνακα γειτνίασης (adjacency matrix), ο οποίος λαμβάνει υπόψη την

πυκνότητα, την ισχύ ή την απόσταση μεταξύ αισθητήρων. Αυτό το γράφημα ενσωματώνει τη φυσική σύνδεση του συστήματος.

3.2.4.3 Χαρακτηριστικά Εισόδου (Input Features)


Για κάθε αισθητήρα (κόμβο του γραφήματος), λαμβάνονται N χρονικά βήματα από τη μετρούμενη μεταβλητή, σχηματίζοντας ένα διάνυσμα χαρακτηριστικών:

$$X = [x_1, x_2, \dots, x_N]^T$$

Ολόκληρος ο πίνακας εισόδου έχει διαστάσεις $|V| \times N$, δηλαδή αριθμός κόμβων επί μήκος χρονικής ακολουθίας.

3.2.4.4 Μονάδα GCNN

Η μονάδα GCNN εφαρμόζει γραφικές συνελκτικές στρώσεις (graph convolution layers), οι οποίες συνδυάζουν τα δεδομένα του κάθε κόμβου με εκείνα των γειτονικών κόμβων, βάσει του γραφήματος που κατασκευάστηκε. Η Εικόνα 3.5 αποτυπώνει το πώς η διαδικασία ανίχνευσης σφαλμάτων μετασχηματίζεται σε πρόβλημα ταξινόμησης κόμβων μέσα σε γράφημα.



Εικόνα 3.5: Διατύπωση του προβλήματος ανίχνευσης σφαλμάτων σε αισθητήρες ως πρόβλημα ταξινόμησης κόμβων σε γράφημα. Σε συνέχεια της Εικόνας 3.4, οι συμβολισμοί Y_1, Y_2, Y_3, Y_4 αντιπροσωπεύουν τις σημάνσεις (κανονικό ή εσφαλμένο) των εξαρτημάτων υπό έλεγχο [39]

Κάθε κόμβος αντιστοιχεί σε έναν αισθητήρα ή ενεργοποιητή, ενώ οι ακμές περιγράφουν τη συσχέτιση ή τη φυσική σύνδεση μεταξύ αυτών. Η βασική ιδέα είναι ότι αντί να αντιμετωπίζονται τα σήματα ως ανεξάρτητες χρονοσειρές, χρησιμοποιείται η δομή του γραφήματος ώστε να αξιοποιηθεί η χωρική πληροφορία μεταξύ αισθητήρων. Ο σκοπός του GCNN είναι να προβλέψει για κάθε κόμβο αν είναι υγιής ή ελαττωματικός, λαμβάνοντας υπόψη τόσο τις τιμές του όσο και τις τιμές των γειτονικών κόμβων.

Η βασική εξίσωση της γραφικής συνελκτικής στρώσης σε ένα GCNN είναι [39]:

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

Όπου:

1. $\tilde{A}=A+I$: ο πίνακας γειτνίασης με προσθήκη μοναδιαίας διαγωνίου (self-connections)
2. $H^{(l)} \in \mathbb{R}^{N \times F}$ είναι ο πίνακας χαρακτηριστικών των κόμβων στη στρώση l , με N κόμβους και F χαρακτηριστικά ανά κόμβο
3. $\tilde{D}$: ο διαγώνιος πίνακας βαθμών του $\tilde{A}$
4. $H^{(l)}$: τα χαρακτηριστικά εισόδου στη στρώση l
5. $W^{(l)}$: τα βάρη της στρώσης l
6. σ : συνάρτηση ενεργοποίησης (π.χ. ReLU)

Το αποτέλεσμα είναι η παραγωγή ενισχυμένων χαρακτηριστικών που λαμβάνουν υπόψη τόσο τη χρονική δυναμική όσο και τις χωρικές συσχετίσεις.

3.2.5 Ταξινόμηση

Μετά τις στρώσεις GCNN, τα εξαγόμενα χαρακτηριστικά για κάθε κόμβο (αισθητήρα) περνούν από στρώσεις πυκνών νευρωνικών δικτύων (fully connected layers), οι οποίες έχουν ως στόχο την τελική ταξινόμηση του σήματος του αισθητήρα. Κατά τη διαδικασία κατασκευής του γραφήματος, κάθε αισθητήρας του συστήματος αντιστοιχίζεται σε έναν κόμβο, ενώ οι συνδέσεις μεταξύ των αισθητήρων (είτε λόγω της φυσικής τους διάταξης είτε λόγω της λειτουργίας τους) ορίζουν τις ακμές του γραφήματος. Οι μετρήσεις που λαμβάνονται από κάθε αισθητήρα σε διαδοχικές χρονικές στιγμές κατανέμονται σε έναν πίνακα χαρακτηριστικών, ο οποίος δημιουργεί το διάνυσμα εισόδου για κάθε κόμβο. Η συνολική πληροφορία του γραφήματος, τόσο ως προς τη δομή (συνδεσιμότητα) όσο και

ως προς τα χαρακτηριστικά των κόμβων, απεικονίζεται στην Εικόνα 3.5, όπου παρουσιάζεται ο τρόπος με τον οποίο διαμορφώνεται το πρόβλημα της ταξινόμησης.

Η τελική έξοδος είναι ένα διάνυσμα πιθανοτήτων για κάθε κόμβο:

1. Αν ο κόμβος είναι “υγιής”
2. Αν έχει σφάλμα τύπου 1 (π.χ. απώλεια σήματος)
3. Αν έχει σφάλμα τύπου 2 (π.χ. καθυστέρηση ή θόρυβο)

Η έξοδος μπορεί να είναι διωνυμική (binary) για ανίχνευση σφάλματος, ή πολυωνυμική (multi-class) για ταξινόμηση τύπου σφάλματος.

3.2.6 Εκπαίδευση και Λειτουργία του Συστήματος

Η εκπαίδευση γίνεται με χρήση επισημασμένων δεδομένων (labeled data), τα οποία περιλαμβάνουν παραδείγματα φυσιολογικής λειτουργίας και σφαλμάτων. Το GCNN εκπαιδεύεται με στόχο την ελαχιστοποίηση της συνάρτησης απώλειών (loss function) μεταξύ των προβλεπόμενων και πραγματικών ετικετών [39].

Η συνολική διαδικασία περιλαμβάνει:

1. Δημιουργία του γραφήματος από τα σήματα αισθητήρων
2. Εξαγωγή των χαρακτηριστικών μέσω των στρώσεων GCNN
3. Πρόβλεψη της κατηγορίας του σφάλματος ανά αισθητήρα

Το μοντέλο εφαρμόζεται σε παράθυρα χρονικών δεδομένων (sliding windows), επιτρέποντας συνεχή παρακολούθηση της κατάστασης του συστήματος. Η αρχιτεκτονική του μοντέλου σε μεγάλης κλίμακας σύστημα θα περιγραφεί σε επόμενη ενότητα.

3.2.7 Πλεονεκτήματα της Προσέγγισης GCNN

Η προσέγγισή αυτή παρουσιάζει τα εξής πλεονεκτήματα σε σχέση με τις συμβατικές μεθόδους:

1. Αξιοποίηση χωρικών συσχετίσεων μεταξύ αισθητήρων
2. Εκμετάλλευση χρονικών εξαρτήσεων
3. Καλύτερη γενίκευση σε νέες συνθήκες και σφάλματα
4. Υψηλότερη ακρίβεια στην ανίχνευση και την απομόνωση
5. Επεκτασιμότητα σε μεγάλα και πολύπλοκα συστήματα

Η χρήση των GCNN επιτρέπει την φυσική ενσωμάτωση της τοπολογίας του συστήματος, κάτι που δεν επιτυγχάνεται με παραδοσιακά CNN ή απλά RNN/LSTM.

Η επιλογή κατάλληλων αλγορίθμων μηχανικής μάθησης και ειδικότερα νευρωνικών δικτύων αποτελεί το θεμέλιο για την ανάπτυξη ενός αποτελεσματικού συστήματος ανίχνευσης και διαχείρισης βλαβών. Η κατανόηση των βασικών χαρακτηριστικών και δυνατοτήτων των MLP, των RNN και των GCNN παρέχει τη βάση για το σχεδιασμό της συνολικής διαδικασίας ανίχνευσης και απομόνωσης σφαλμάτων. Στην επόμενη ενότητα παρουσιάζεται αναλυτικά το πώς αυτά τα μοντέλα αξιοποιήθηκαν για τη διαμόρφωση ενός ολοκληρωμένου μηχανισμού ανίχνευσης, ταξινόμησης και διαχείρισης βλαβών στο εξεταζόμενο σύστημα.

3.3 Σχεδιασμός της Διαδικασίας Ανίχνευσης και Διαχείρισης Βλαβών

Η ανίχνευση και διαχείριση βλαβών σε ηλεκτρικά δίκτυα αποτελεί κρίσιμο πεδίο έρευνας και εφαρμογής, καθώς συμβάλλει στη διασφάλιση της αξιοπιστίας, της ασφάλειας και της αποδοτικότητας των συστημάτων. Στο πλαίσιο αυτό, η αξιοποίηση προηγμένων μεθόδων τεχνητής νοημοσύνης, και ειδικότερα των νευρωνικών δικτύων, προσφέρει νέες δυνατότητες για την αντιμετώπιση των σύνθετων προκλήσεων που σχετίζονται με την πρόβλεψη, την ανίχνευση και την απομόνωση βλαβών. Η παρούσα ενότητα αναλύει τη διαδικασία σχεδιασμού συστημάτων ανίχνευσης και διαχείρισης βλαβών, εστιάζοντας στις διαφορετικές αρχιτεκτονικές νευρωνικών δικτύων και στις εφαρμογές τους σε πραγματικά σενάρια λειτουργίας ηλεκτρικών δικτύων.

3.3.1 Επιλογή και Ρόλος των Νευρωνικών Δικτύων στην Ανίχνευση Βλαβών

Η ανίχνευση και διαχείριση βλαβών σε συστήματα ηλεκτρικής ενέργειας απαιτεί τεχνικές που μπορούν να αναγνωρίζουν σύνθετα μοτίβα και να λαμβάνουν αποφάσεις με βάση ασαφή ή ατελή δεδομένα. Τα Τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Networks - ANNs) διαθέτουν την απαιτούμενη προσαρμοστικότητα και ισχυρή μαθησιακή ικανότητα, επιτρέποντας την έγκαιρη ανίχνευση και κατηγοριοποίηση βλαβών. Μέσω εποπτευόμενης εκπαίδευσης και διαδικασιών όπως η οπισθοδιάδοση σφάλματος (backpropagation), τα νευρωνικά δίκτυα μπορούν να προβλέπουν ανωμαλίες στα σήματα λειτουργίας του συστήματος.

Επιπλέον, η έννοια της Ανίχνευσης και Απομόνωσης Βλαβών (Fault Detection and Isolation - FDI) ενσωματώνεται άμεσα στη σχεδίαση της διαδικασίας. Το FDI στοχεύει όχι μόνο στον

εντοπισμό της παρουσίας μιας βλάβης, αλλά και στον ακριβή προσδιορισμό της θέσης και του τύπου της, προκειμένου να διευκολυνθεί η γρήγορη και στοχευμένη αντίδραση.

3.3.2 Χρήση MLP στη Διαδικασία Ανίχνευσης

Τα MLP επιλέγονται για εφαρμογές όπου η ανίχνευση βλαβών μπορεί να αντιμετωπιστεί ως στατικό πρόβλημα ταξινόμησης. Η δομή τους, που περιλαμβάνει επίπεδα εισόδου, κρυφά επίπεδα και εξόδου, επιτρέπει τη μάθηση μη γραμμικών σχέσεων μεταξύ των μεταβλητών εισόδου και της επιθυμητής εξόδου. Η εκπαίδευση των MLP με εποπτευόμενα δεδομένα και χρήση αλγορίθμων όπως το backpropagation καθιστά εφικτή τη δημιουργία μοντέλων που μπορούν να αναγνωρίζουν με ακρίβεια ποιοτικός χαρακτηριστικά των δεδομένων λειτουργίας και να ανιχνεύουν αστοχίες σε πρώιμο στάδιο.

3.3.3 Εφαρμογή RNN στην Πρόβλεψη και Εντοπισμό Βλαβών

Για περιπτώσεις όπου η χρονοσειρά των μετρήσεων παίζει καθοριστικό ρόλο, υιοθετούνται Αναδρομικά Νευρωνικά Δίκτυα (Recurrent Neural Networks - RNN). Τα RNN αξιοποιούν την εσωτερική τους μνήμη (hidden states) ώστε να λαμβάνουν υπόψη την αλληλουχία των δεδομένων, αναγνωρίζοντας αλλαγές που συνδέονται με την εξέλιξη ή την επιδείνωση μιας βλάβης. Με τον τρόπο αυτό, είναι δυνατό να εντοπιστούν έγκαιρα τάσεις που οδηγούν σε βλάβη, ακόμη και όταν αυτές εκδηλώνονται σταδιακά και σε μεγάλο χρονικό ορίζοντα.

3.3.4 Ανίχνευση και Απομόνωση Βλαβών με GCNN

Σε πιο σύνθετα περιβάλλοντα, όπως δίκτυα ηλεκτρικής ενέργειας με σύνθετες διασυνδέσεις, εφαρμόζονται Γραφικά Συνελκτικά Νευρωνικά Δίκτυα (Graph Convolutional Neural Networks - GCNN). Τα GCNN αξιοποιούν τη δομή του συστήματος υπό μορφή γραφήματος, όπου οι κόμβοι αντιστοιχούν σε εξοπλισμούς ή αισθητήρες και οι ακμές στις μεταξύ τους σχέσεις ή ροές ενέργειας. Μέσω της συνελκτικής επεξεργασίας σε αυτό το γράφημα, τα GCNN μπορούν να εντοπίσουν τοπικές και μη τοπικές ανωμαλίες, προσφέροντας μια πιο πλούσια αναπαράσταση της κατάστασης του δικτύου και βελτιώνοντας την ακρίβεια τόσο στην ανίχνευση όσο και στην απομόνωση των βλαβών [39].

3.3.5 Διαδικασία Σχεδιασμού της Ανίχνευσης και Διαχείρισης Βλαβών

Η διαδικασία σχεδιασμού περιλαμβάνει τα εξής στάδια:

1. Συλλογή και κανονικοποίηση δεδομένων λειτουργίας μέσω αισθητήρων ή μετρητικών συστημάτων.
2. Εξαγωγή χαρακτηριστικών με τεχνικές ανάλυσης σήματος, όπως μετασχηματισμός κυματιδίων.
3. Επιλογή κατάλληλου τύπου νευρωνικού δικτύου (MLP, RNN ή GCNN) ανάλογα με τη φύση των δεδομένων και του προβλήματος.
4. Εκπαίδευση των μοντέλων με εποπτευόμενα δεδομένα βλαβών και φυσιολογικής λειτουργίας.
5. Εφαρμογή της ανεπτυγμένης διαδικασίας FDI για την έγκαιρη ανίχνευση, ταξινόμηση και απομόνωση των βλαβών, υποστηρίζοντας τη λήψη αποφάσεων για διορθωτικές ενέργειες ή συντήρηση.

3.4 Πειράματα και Αξιολόγηση της Απόδοσης

Για την αξιολόγηση της απόδοσης των αλγορίθμων και των συστημάτων ανίχνευσης, πραγματοποιούνται πειράματα που περιλαμβάνουν την εφαρμογή των μοντέλων σε πραγματικά και προσομοιωμένα σενάρια βλαβών.

3.4.1 Εφαρμογή σε Πραγματικές Γραμμές Μεταφοράς

Στο [40], παρουσιάζεται μια ερευνητική εργασία που επικεντρώνεται στην ανίχνευση και τον ακριβή εντοπισμό βλαβών σε συστήματα που αποτελούνται από συνδυασμένες εναέριες γραμμές και υπόγεια καλώδια μεταφοράς. Η μελέτη εξετάζει διάφορους τύπους βλαβών, όπως μονοφασικές προς γη (SLG), διφασικές προς γη (DLG), διφασικές (DL), τριφασικές (TL) και τριφασικές προς γη (TLG) βλάβες. Οι τεχνικές TN που χρησιμοποιήθηκαν, όπως ο (Boosting Classifier), η (Radial Basis Function - RBF), ο Naive Bayes (NBC) και ο ταξινομητής Bagging, είχαν τη δυνατότητα να προβλέψουν τον τύπο των σφαλμάτων και τον εντοπισμού τους σε τριφασικές γραμμές μεταφοράς. Ωστόσο, χρησιμοποιήθηκε και η νέα τεχνική CNF, που συνδυάζει ασαφή λογική και τεχνητά νευρωνικά δίκτυα [40].

Η μεθοδολογία που αναπτύχθηκε στο [40] επιτυγχάνει πολύ υψηλή ακρίβεια στον εντοπισμό των βλαβών, με σφάλμα τοποθέτησης μικρότερο από 2% στις περισσότερες

περιπτώσεις που εξετάστηκαν. Επιπλέον, η έρευνα εξετάζει την ευαισθησία της μεθόδου ως προς την αντίσταση του σφάλματος, επιδεικνύοντας ότι ακόμα και για υψηλότερες τιμές αντίστασης, η ακρίβεια παραμένει σε αποδεκτά επίπεδα.

Σημαντικό είναι επίσης ότι γίνεται σύγκριση διαφορετικών σεναρίων γραμμών (διαφορετικά μήκη υπόγειου και εναέριου τμήματος) και αναλύεται η συμπεριφορά της μεθόδου σε κάθε περίπτωση. Η αξιολόγηση των αποτελεσμάτων δείχνει ότι η προτεινόμενη προσέγγιση υπερτερεί έναντι των άλλων παραδοσιακών μεθόδων ως προς την ακρίβεια εντοπισμού και τον απαιτούμενο υπολογιστικό χρόνο.


Η έρευνα αυτή αξιοποιείται στη συνέχεια της παρούσας εργασίας ως θεωρητική βάση για τη σύγκριση των δεδομένων εκπαίδευσης και δοκιμής των νευρωνικών δικτύων που υλοποιούνται για την ανίχνευση και ταξινόμηση σφαλμάτων σε συστήματα μεταφοράς ηλεκτρικής ενέργειας.

Επίσης, εφαρμόζονται δύο τεχνικές τεχνητής νοημοσύνης, η Concurrent Neuro-Fuzzy (CNF) και η Multi-Layer Perceptron (MLP) για τη βελτίωση της αξιοπιστίας, την επιτάχυνση της διαδικασίας ανίχνευσης βλαβών και τη διατήρηση της συνεχούς παροχής σε γραμμές υψηλής τάσης. Οι γραμμές που μελετώνται είναι δύο υπερυψηλής τάσης: μία με τάση 735 KV και μήκος 600 km, και μία με τάση 400 KV και μήκος 120 km.

Τέλος, σε αυτή την υλοποίηση χρησιμοποιήθηκε ένα ειδικά δημιουργημένο dataset που περιλαμβάνει δεδομένα προσομοίωσης βλαβών σε εναέρια γραμμή μεταφοράς. Το dataset περιλαμβάνει σήματα ρευμάτων και τάσεων που αντιστοιχούν σε διάφορους τύπους σφαλμάτων, όπως μονοφασικά προς γη (SLG), διφασικά (DL), διφασικά προς γη (DLG) και τριφασικά σφάλματα (TL και TLG). Τα δεδομένα δημιουργήθηκαν μέσω προσομοιώσεων με χρήση του MATLAB/Simulink λαμβάνοντας υπόψη διαφορετικές παραμέτρους, όπως: Τη θέση της βλάβης κατά μήκος της γραμμής σε ποσοστά του συνολικού μήκους, το επίπεδο της αντίστασης σφάλματος και τους διαφορετικούς τύπους σφαλμάτων και τις εμπλεκόμενες φάσεις όπως φαίνονται στην Εικόνα 3.6 και στον Πίνακα 3.1.

Στην Εικόνα 3.6 παρουσιάζονται τα χαρακτηριστικά που χρησιμοποιήθηκαν σε κάθε δοκιμή. Συγκεκριμένα, έχουμε τα στοιχεία της γεννήτριας (G) όπως η τάση σε kV (U), η συχνότητα του δικτύου $f=50\text{Hz}$, την σύνθετη αντίσταση (Z), το ρεύμα γραμμής (I_T) και το φορτίο (Load). Για την απλοποίηση της διαδικασίας συλλογής των δεδομένων, το μήκος των γραμμών χωρίστηκε σε πέντε ζώνες ίσης απόστασης. Ένας τριφασικός διακόπτης

χρησιμοποιήθηκε σε διαφορετικές θέσεις για την προσομοίωση διαφορετικών τύπων σφαλμάτων. Το πλάτος των τάσεων βραχυκύκλωσης (V_a , V_b , V_c) και των ρευμάτων βραχυκύκλωσης (I_a , I_b , I_c) χρησιμοποιήθηκε για την ανίχνευση, την ταξινόμηση και τον εντοπισμό των σφαλμάτων, με τη χρήση του λογισμικού Matlab.



Εικόνα 3.6: Παράμετροι των γραμμών (αντίσταση, χωρητικότητα, επαγωγή) [40]


Όπως φαίνεται στον Πίνακα 3.1, δίνονται και τα χαρακτηριστικά των 2 μοντέλων γραμμών μεταφοράς (PTL1, PTL2) καθώς και τα στοιχεία τους: (U) η τάση γραμμής, (I_T) το ρεύμα γραμμής, ο λόγος X/R που καθορίζει τον τύπο συμπεριφοράς της γραμμής (επαγωγική, ωμική) και η συχνότητα του δικτύου που είναι στα 50Hz. Επίσης, στην τρίτη στήλη του Πίνακα 3.1 έχουμε: την ωμική αντίσταση ανά χιλιόμετρο R , το συντελεστή αυτεπαγωγής της γραμμής L , τον χωρητικό συντελεστή της γραμμής C και τη γωνία σφάλματος στις 45 μοίρες. Επιπρόσθετα, φαίνεται ότι η αντίσταση του σφάλματος (R_f) αυξήθηκε από 0.001 Ω έως 60 Ω .

Πίνακας 3.1: Η κανονικοποίηση των δεδομένων εισόδου [40]

Models	Parameters	
PTL1	$U = 735 \text{ kV}$	$R (\Omega/\text{Km}) = 0.01273$ $L (\text{mH}/\text{Km}) = 0.9337$ $C (\mu\text{F}/\text{Km}) = 12.74$ $\theta (\text{degrees}) = 45$ $R_f (\Omega) = 0.001, 0.01, 0.1, 1, 10, 20, 30, 40, 50, 60$
	$l_T = 600 \text{ km}$ $X/R = 10$ $f (\text{Hz}) = 50$	
PTL2	$U = 400 \text{ kV}$ $l_T = 120 \text{ km}$ $X/R = 23$ $f (\text{Hz}) = 50$	


Στην Εικόνα 3.7 βλέπουμε τα δεδομένα που εισήχθησαν στον τριφασικό διακόπτη, υπεύθυνο για τη δημιουργία του τεχνητού σφάλματος για τη δοκιμή. Εδώ έχει επιλεγεί το

σφάλμα μεταξύ της Φάσης Α και της γείωσης, με αντίσταση σφάλματος (R_f) στα 0.001 Ω και την αντίσταση εδάφους (R_g) στα 1 Ω . Έχει επίσης επιλεχθεί η μέτρηση τάσεων και ρευμάτων σφάλματος.




Εικόνα 3.7: Εισαγωγή δεδομένων στο block του τριφασικού διακόπτη δημιουργίας σφάλματος [40]

Όταν προκύψει βραχυκύκλωμα στις γραμμές μεταφοράς PTL1 και PTL2, όπως παρουσιάζεται στις Εικόνες 3.8 και 3.9, παρατηρείται ότι η τάση αυξάνεται ραγδαία, ενώ το ρεύμα της γραμμής μειώνεται. Φυσικά, η τάση και το ρεύμα βραχυκυκλώματος εξαρτώνται από τα χαρακτηριστικά της γεννήτριας και του φορτίου. Παρόλο που το σφάλμα προκαλείται από βλάβη μεταξύ δύο φάσεων, φαίνεται πως και η τρίτη φάση επηρεάζεται σε κάθε περίπτωση. Στις καμπύλες είναι εμφανές ότι, μετά από μία συγκεκριμένη απόσταση που διανύει το σφάλμα, το πλάτος της τάσης και του ρεύματος μηδενίζεται.




Εικόνα 3.8: Διφασικό σφάλμα με $R_f=1\Omega$ και γωνία σφάλματος 45° της 1^{ης} Γραμμής
Μεταφοράς (PTL1) [40]



Εικόνα 3.9: Διφασικό σφάλμα με $R_f=1\Omega$ και γωνία σφάλματος 45° της 2^{ης} Γραμμής
Μεταφοράς (PTL2) [40]

Στην περίπτωση του MLP, η δομή του δικτύου περιλαμβάνει πολλαπλά κρυφά επίπεδα και χρησιμοποιεί κανονικοποιημένα δεδομένα για την εκπαίδευση. Το γράφημα των συναρτήσεων – μελών που χρησιμοποιούνται φαίνονται στην Εικόνα 3.10 και οι συμβολισμοί τους είναι: (Vs: Very small, Small: S, Medium: M, Average: Av, High: H και Very high: Vh)].



Εικόνα 3.10: Απεικόνιση των 6 λειτουργιών ταυτόχρονης ιδιότητας [40]


Το κάθε εύρος που έχει ληφθεί και αντιστοιχεί σε κάθε κατηγορία συνάρτησης – μέλους φαίνονται στον Πίνακα 3.2. Ο αριθμός των κρυφών επιπέδων είναι κρίσιμος για τη μείωση του σφάλματος, και ο αριθμός των δοκιμών που χρησιμοποιούνται για την εκπαίδευση καθορίζεται για να επιτευχθούν τα καλύτερα αποτελέσματα.

Πίνακας 3.2: Οι εμβέλειες των τιμών κάθε λειτουργίας [40]

Categories	Range
V_S	$[-1, -0.8]$
S	$] -0.8, -0.0034]$
M	$] -0.0034, -0.025]$
A_V	$] -0.0025, -0.002]$
H	$] 0.002, 0.14]$
V_h	$] 0.14, 1]$

Για το PTL1 (735 KV, 600 km), το MLP παρουσίασε συνολική ακρίβεια 99.81% στην ταξινόμηση και 98.64% στον εντοπισμό βλαβών, ενώ για το PTL2 (400 KV, 120 km), η ακρίβεια ήταν 96.89% και 89.75% αντίστοιχα. Το CNF παρουσίασε ακρίβεια 2.53% για την ταξινόμηση και 0.7693% για τον εντοπισμό στο PTL1 και 4.3577% και 2.2358% στο PTL2. Σημειώνεται ότι τα ποσοστά ακρίβειας που αναφέρθηκαν προηγουμένως αποτελούν ποσοστιαία σφάλματα πρόβλεψης. Περαιτέρω ανάλυση θα πραγματοποιηθεί στο επόμενο κεφάλαιο.

Στην Εικόνα 3.11 παρουσιάζεται η δομή του MLP. Το MLP δομήθηκε με 3 κρυφά επίπεδα (hidden layers), ενώ δοκιμάστηκαν και άλλες διατάξεις με περισσότερα επίπεδα, για την επίτευξη βέλτιστης απόδοσης. Το δίκτυο εκπαιδεύτηκε χρησιμοποιώντας 550 δεδομένα, ενώ ο αριθμός εποχών (epochs) ορίστηκε σε 3000, κατόπιν πειραματικής αξιολόγησης διαφορετικών τιμών, ως εκείνος που απέδωσε τη βέλτιστη ακρίβεια στο σενάριο εκπαίδευσης για το μοντέλο MLP.



Εικόνα 3.11: Η αρχιτεκτονική MLP (backpropagation) με τα κρυφά επίπεδα που χρησιμοποιήθηκε [40]


Τα ρεύματα βραχυκυκλώματος σημαίνονται ως I_a , I_b , I_c στις φάσεις 1, 2 και 3 αντίστοιχα, καθώς και οι τάσεις βραχυκυκλώματος V_a , V_b , V_c μεταξύ των φάσεων 1, 2, 3 και της γείωσης αντίστοιχα, ορίστηκαν ως είσοδοι του συστήματος. Οι έξοδοι του συστήματος ορίστηκαν ως L_1 , L_2 , L_3 και G . Τα δεδομένα σφαλμάτων δημιουργήθηκαν και κανονικοποιήθηκαν για όλους τους 11 τύπους σφαλμάτων (Πίνακας 3.3), σε τιμές στο διάστημα 0 έως 1.

Οι λειτουργίες ενεργοποίησης που χρησιμοποιήθηκαν ήταν οι λογιστικές συναρτήσεις (MLP με εκπαίδευση backpropagation) και η συνάρτηση ενεργοποίησης που δίνεται παρακάτω, οι οποίες ήταν κατάλληλες για την ταξινόμηση μη γραμμικών σχέσεων.

$$f(x) = \frac{1}{1 + e^{-x}}$$

Στη παραπάνω λογιστική συνάρτηση ενεργοποίησης, η μεταβλητή x είναι η είσοδος στον νευρώνα και η $f(x)$ η έξοδος, της οποίας το διάστημα είναι (0,1).

Η Εικόνα 3.12 παρουσιάζει τη γενική διαρρύθμιση του νευρωνικού δικτύου CNF που χρησιμοποιήθηκε στη μελέτη. Η αρχιτεκτονική περιλαμβάνει πολλαπλά κρυφά επίπεδα, τα οποία σχεδιάστηκαν με βάση την πολυπλοκότητα του προβλήματος εντοπισμού ηλεκτρικών βλαβών και την ανάγκη για επαρκή ικανότητα γενίκευσης του μοντέλου.



Εικόνα 3.12: Η αρχιτεκτονική CNF με τα αντίστοιχα κρυφά επίπεδα [40]

Επιπλέον, σε κάθε έξοδο ανατέθηκε ένα σύνολο δυαδικών αριθμών (0, 1). Οι Πίνακες 3.3 και 3.4 παρουσιάζουν τις εξόδους που έχουν αντιστοιχιστεί για την ταξινόμηση και τον εντοπισμό των σφαλμάτων αντίστοιχα.

Πίνακας 3.3: Η ταξινόμηση των σφαλμάτων [40]

faults type	Outputs			
	L1	L2	L3	G
Slag	1	0	0	1
Slbg	0	1	0	1
Slcg	0	0	1	1
Dlab	1	1	0	0
Dlbc	0	1	1	0
Dlac	1	0	1	0
Dlabg	1	1	0	1
Dlbcg	0	1	1	1
Dlacg	1	0	1	1
Tlabc	1	1	1	0
Tlabcg	1	1	1	1

Για την ανάγκη της διαδικασίας ανίχνευσης και ταξινόμησης βλαβών, είναι σημαντικό να καθοριστούν οι βασικοί τύποι σφαλμάτων που μπορεί να προκύψουν σε ένα τριφασικό δίκτυο μεταφοράς ηλεκτρικής ενέργειας. Στον Πίνακα 3.4 παρουσιάζονται οι κυριότερες κατηγορίες βλαβών, καθώς και οι εμπλεκόμενες φάσεις (L1, L2, L3) και η πιθανή επαφή με τη γη (G).

1. **SLAG** (*Single Line-to-Ground fault at phase A*): Μονή βλάβη μεταξύ της φάσης A και της γης.
2. **SLBG** (*Single Line-to-Ground fault at phase B*): Μονή βλάβη μεταξύ της φάσης B και της γης.
3. **SLCG** (*Single Line-to-Ground fault at phase C*): Μονή βλάβη μεταξύ της φάσης C και της γης.
4. **DLAB** (*Double Line fault between phases A and B*): Βλάβη μεταξύ των φάσεων A και B, χωρίς εμπλοκή της γης.
5. **DLBC** (*Double Line fault between phases B and C*): Βλάβη μεταξύ των φάσεων B και C, χωρίς εμπλοκή της γης.

6. **DLAC** (*Double Line fault between phases A and C*): Βλάβη μεταξύ των φάσεων A και C, χωρίς εμπλοκή της γης.
7. **DLABG** (*Double Line-to-Ground fault between phases A and B*): Οι φάσεις A και B βραχυκυκλώνονται ταυτόχρονα με τη γείωση.
8. **DLBCG** (*Double Line-to-Ground fault between phases B and C*): Οι φάσεις B και C βραχυκυκλώνονται μαζί με τη γείωση.
9. **DLACG** (*Double Line-to-Ground fault between phases A and C*): Οι φάσεις A και C βραχυκυκλώνονται ταυτόχρονα με τη γείωση.
10. **TLABC** (*Triple Line fault among phases A, B and C*): Οι φάσεις A, B και C βραχυκυκλώνονται από κοινού με τη γείωση.
11. **TLABCG** (*Triple Line-to-Ground fault among phases A, B and C*): Τριφασική βλάβη μεταξύ των φάσεων A, B και C ταυτόχρονα με τη γη.

Επίσης, τα L1, L2, L3 στα outputs αναφέρονται στις φάσεις A, B, και C αντίστοιχα και το G στη γη.

Τα δεδομένα κατηγοριοποιήθηκαν με την εξίσωση

$$X_n = \frac{X - X_{min}}{X_{max} - X_{min}}$$

X_n είναι το αποτέλεσμα του κανονικοποιημένου δεδομένου, X_{min} η ελάχιστη τιμή και X_{max} η μέγιστη τιμή.

Ο Πίνακας 3.4 παρουσιάζει τα αποτελέσματα της διαδικασίας εντοπισμού βλαβών κατά μήκος δύο εναέριων γραμμών μεταφοράς χρησιμοποιώντας το MLP.

Πίνακας 3.4: Ο εντοπισμός της θέσης των σφαλμάτων [40]

PTL Models	Fault Distance	Outputs			
PTL1	120 km	0	0	1	0
	240 km	0	1	0	1
	360 km	0	1	1	0
	480 km	1	0	0	0
	600 km	1	0	1	1
PTL2	24 km	0	0	1	0
	48 km	0	1	0	1
	72 km	0	1	1	0
	96 km	1	0	0	0
	120 km	1	0	1	1

Για κάθε τύπο σφάλματος, συγκρίνονται η πραγματική θέση της βλάβης και η εκτιμώμενη θέση που υπολογίστηκε από το εκπαιδευμένο δίκτυο, ενώ καταγράφεται και το σφάλμα εκτίμησης, δηλαδή η απόκλιση μεταξύ των δύο τιμών.

Τα αποτελέσματα δείχνουν ότι το MLP δίκτυο επιτυγχάνει πολύ υψηλή ακρίβεια στην πρόβλεψη της θέσης της βλάβης. Το ποσοστό σφάλματος εντοπισμού παραμένει σε πολύ χαμηλά επίπεδα, συνήθως μικρότερο από 2%, αποδεικνύοντας τη δυνατότητα του μοντέλου να εντοπίζει με αξιοπιστία το ακριβές σημείο εμφάνισης του σφάλματος κατά μήκος της γραμμής. Οι αριθμοί στον Πίνακα 3.4 δείχνουν ότι όσο μικρότερη είναι η διαφορά μεταξύ πραγματικής και εκτιμώμενης θέσης (μικρό σφάλμα σε απόσταση), τόσο πιο ακριβής είναι η πρόβλεψη του δικτύου.

Η ικανότητα αυτή είναι κρίσιμη για την αποτελεσματική διαχείριση των σφαλμάτων σε πραγματικά δίκτυα, καθώς η άμεση και ακριβής εντόπιση τους μειώνει το χρόνο αποκατάστασης, ελαχιστοποιεί τις απώλειες ενέργειας και προλαμβάνει την κλιμάκωση των προβλημάτων σε άλλα τμήματα του δικτύου. Επιπλέον, το γεγονός ότι η μέθοδος MLP μπορεί να εκπαιδευτεί σε διαφορετικά σενάρια και τύπους σφαλμάτων την καθιστά ευέλικτη για εφαρμογή σε ευρύτερα συστήματα μεταφοράς και διανομής ηλεκτρικής ενέργειας.

3.4.2 Συγκρίσεις και Μέτρα Απόδοσης

Η ανάλυση των μεθόδων FDI βασίζεται σε βιβλιογραφική σύγκριση των κύριων εργασιών της σχετικής βιβλιογραφίας. Στη μελέτη [39] αξιολογείται η απόδοση των GCNN σε δίκτυο βιομηχανικών δεξαμενών χρησιμοποιώντας ως κριτήρια την ακρίβεια, η οποία εκφράζει το ποσοστό σωστών προβλέψεων επί του συνόλου των δειγμάτων, και το AUC-ROC, δηλαδή το εμβαδόν κάτω από την καμπύλη ROC που αντικατοπτρίζει την ικανότητα διάκρισης μεταξύ θετικών και αρνητικών περιπτώσεων ανεξαρτήτως ορίου. Στη μελέτη [38] εξετάζεται το σύστημα iFD σε περιβάλλον EMS, δίνοντας έμφαση στο ποσοστό ψευδών συναγερμών (False Alarm Rate), δηλαδή το ποσοστό λανθασμένων ειδοποιήσεων μεταξύ των αρνητικών δειγμάτων, και στον χρόνο εκπαίδευσης-απόκρισης, που αντιστοιχεί στο συνολικό χρόνο για τη μάθηση του μοντέλου και την παραγωγή της πρόβλεψης—κρίσιμα κριτήρια για εφαρμογές σε πραγματικό χρόνο. Αυτές οι εργασίες συγκρίθηκαν μεταξύ τους και σε σχέση με παραδοσιακούς αλγορίθμους όπως το SVM και η Logistic Regression, αξιοποιώντας κοινά σύνολα δεδομένων και τα προαναφερόμενα μέτρα απόδοσης.

3.4.3 Συγκριτική Αξιολόγηση και Χρήσεις RNN και DBN

1. **Διαφορές στη Χρήση:** Τα RNN είναι ιδανικά για δεδομένα με αλληλουχίες, όπως χρονικές σειρές, και επιτυγχάνουν άριστη απόδοση όταν η ανίχνευση βλαβών σχετίζεται με διαδοχικές αλλαγές στο σύστημα. Από την άλλη, τα DBN διαπρέπουν σε περιβάλλοντα που απαιτούν πολύπλοκη ανάλυση χαρακτηριστικών και ταξινόμηση με ακρίβεια, ακόμη και σε αδόμητα δεδομένα.
2. **Προσαρμοστικότητα σε Βιομηχανικές Εφαρμογές:** Ενώ τα RNN εφαρμόζονται με επιτυχία σε περιβάλλοντα με δυναμικές και αλληλεξαρτώμενες μεταβολές (όπως οι φορτιστές και τα ενεργειακά συστήματα πραγματικού χρόνου), τα DBN είναι καταλληλότερα για εφαρμογές που απαιτούν συνεχή ταξινόμηση και ανάλυση απόδοσης, όπως στα έξυπνα δίκτυα και τα συστήματα αυτόματου ελέγχου σε βιομηχανικά περιβάλλοντα.
3. **Ενσωμάτωση με Άλλες Τεχνικές:** Οι τεχνικές RNN και DBN μπορούν να συνδυαστούν με άλλες τεχνικές AI, όπως οι γενετικοί αλγόριθμοι, για να επιτύχουν ακόμη καλύτερη προσαρμογή και ακρίβεια στην ανίχνευση βλαβών. Για παράδειγμα, η χρήση ενός DBN σε συνδυασμό με ενισχυτικά μοντέλα (boosting)

μπορεί να ενισχύσει την ικανότητα ταξινόμησης και αναγνώρισης σύνθετων προτύπων βλάβης.

4. **Ορισμός Σύνθετης Βλάβης:** Ως σύνθετες βλάβες ορίζονται οι περιπτώσεις όπου το φαινόμενο της βλάβης έχει περισσότερες από μία φάσεις, ενδεχομένως με παράλληλη επαφή προς τη γη, ή συνοδεύεται από μεταβατικά χαρακτηριστικά και χρονικές μεταβολές στα σήματα λειτουργίας. Τέτοιες περιπτώσεις περιλαμβάνουν διφασικές ή τριφασικές βλάβες, διφασικές προς γη, καθώς και σενάρια με σημαντική χρονική εξέλιξη ή διακυμάνσεις στην αντίσταση του σφάλματος.

Κεφάλαιο 4 Υλοποιήσεις Τεχνικών Ανίχνευσης Βλαβών με CNF, MLP, iFD και GCNN

Το κεφάλαιο αυτό περιλαμβάνει την υλοποίηση και αξιολόγηση τεσσάρων τεχνικών τεχνητής νοημοσύνης: των CNF, MLP, GCNN και iFD. Οι τεχνικές αυτές εφαρμόζονται για την ανίχνευση, ταξινόμηση και εντοπισμό βλαβών σε γραμμές μεταφοράς υψηλής τάσης, με σκοπό τη βελτίωση της αξιοπιστίας και της ταχύτητας απόκρισης των ηλεκτρικών δικτύων. Στις επόμενες ενότητες παρουσιάζονται αναλυτικά τα βήματα που ακολουθήθηκαν κατά την υλοποίηση από τις επιστημονικές ομάδες των [38], [39], [40] αυτών των τεχνικών, καθώς και οι επιλογές παραμέτρων, τα εργαλεία που χρησιμοποιήθηκαν, οι προδιαγραφές του υπολογιστικού περιβάλλοντος και τα αποτελέσματα των δοκιμών που πραγματοποιήθηκαν.

4.1 Περιβάλλον Ανάπτυξης

Για την τους αλγόριθμους που υλοποιήθηκαν στο [6], επιλέχθηκε το Matlab/Simulink ως το βασικό περιβάλλον ανάπτυξης, λόγω της ευελιξίας που προσφέρει στη διαχείριση δεδομένων, τη μοντελοποίηση δυναμικών συστημάτων και την εκπαίδευση νευρωνικών δικτύων. Το Matlab παρέχει πληθώρα βιβλιοθηκών και εργαλειοθηκών (toolboxes) που διευκολύνουν τη δημιουργία και την εκπαίδευση των αλγορίθμων, καθώς και την ανάλυση των αποτελεσμάτων.

Η πλατφόρμα Matlab χρησιμοποιήθηκε για την υλοποίηση της ασαφούς λογικής (fuzzy logic), του νευρωνικού δικτύου MLP, και της διαχείρισης των δεδομένων εισόδου και εξόδου. Το Simulink αποτέλεσε βασικό εργαλείο για την προσομοίωση των δυναμικών γραμμών μεταφοράς υψηλής τάσης (PTL1 και PTL2). Οι σημαντικότερες εργαλειοθήκες που χρησιμοποιήθηκαν είναι:

4.1.1 Εργαλειοθήκη Ασαφούς Λογικής (Fuzzy Logic Toolbox)

Το εργαλείο αυτό παρέχεται από το MATLAB ώστε να αντιμετωπιστούν προβλήματα που περιλαμβάνουν αβεβαιότητα και ασάφεια, παρέχοντας έναν τρόπο λήψης αποφάσεων που προσομοιάζει την ανθρώπινη σκέψη. Τα κύρια χαρακτηριστικά του είναι η

δημιουργία συστημάτων ασαφούς λογικής με την παροχή ενός γραφικού περιβάλλοντος χρήστη (GUI) για τη δημιουργία των συστημάτων αυτών ορίζοντας μεταβλητές εισόδου - εξόδου, κανόνες, και συναρτήσεις. Βρίσκει εφαρμογή στις ιατρικές διαγνώσεις, στη διαχείριση πόρων και στη λήψη αποφάσεων [20].

4.1.2 Εργαλειοθήκη Νευρωνικών Δικτύων

Ένα ακόμα εργαλείο του MATLAB το οποίο χρησιμοποιείται για τη μοντελοποίηση και ανάλυση νευρωνικών δικτύων. Υποστηρίζει την εκπαίδευση και την εφαρμογή μοντέλων μηχανικής μάθησης, όπως τα νευρωνικά δίκτυα. Οι δυνατότητες του περιλαμβάνουν έτοιμες συναρτήσεις και εργαλεία για τη δημιουργία νευρωνικών δικτύων, όπως τα feedforward, τα convolutional, και τα recurrent networks. Επίσης, επιτρέπει τη χρήση GUI για σχεδιασμό και εκπαίδευση δικτύων χωρίς την ανάγκη γραμμών κώδικα, περιλαμβάνει αλγορίθμους για την εκπαίδευση και την προσαρμογή παραμέτρων, όπως το backpropagation και οι μέθοδοι gradient descent. Τέλος, συνδυάζεται με το Simulink που θα αναλυθεί παρακάτω για υλοποιήσεις σε πραγματικό χρόνο, ενώ χρησιμοποιείται κυρίως με για την ανίχνευση σφαλμάτων σε ηλεκτρικά δίκτυα και βιομηχανικά συστήματα αλλά και για τη πρόβλεψη χρονοσειρών [38], [39], [40].

4.1.3 Matlab Simulink

Το Simulink είναι ένα εργαλείο του MATLAB που χρησιμοποιείται για τη μοντελοποίηση, προσομοίωση, και ανάλυση συστημάτων. Παρέχει μια γραφική διεπαφή χρήστη για τη δημιουργία μοντέλων χρησιμοποιώντας διαγράμματα τύπου μπλοκ. Υποστηρίζει προσομοίωση σε πραγματικό χρόνο, παρέχει ένα μεγάλο όγκο βιβλιοθηκών και μπορεί να ενσωματωθεί με τα προαναφερθέντα εργαλεία για πιο ολοκληρωμένες εφαρμογές.

Συνολικά, το περιβάλλον Matlab/Simulink επιλέχθηκε λόγω της δυνατότητας που προσφέρει για ενσωμάτωση διαφόρων τεχνολογιών τεχνητής νοημοσύνης και τη δυνατότητα να χειριστεί με ακρίβεια και αποτελεσματικότητα τα δεδομένα σφαλμάτων σε γραμμές μεταφοράς [20].

4.2 Δεδομένα και Εισαγωγή

Η εισαγωγή δεδομένων αποτελεί το πρώτο βήμα για την εκπαίδευση και δοκιμή των αλγορίθμων. Στην παρούσα μελέτη, χρησιμοποιήθηκαν δεδομένα από προσομοιώσεις βλαβών σε γραμμές μεταφοράς υψηλής τάσης για δύο διαφορετικά μοντέλα γραμμών: PTL1 (735 KV) και PTL2 (400 KV). Τα δεδομένα αυτά αφορούσαν βραχυκυκλώματα και προσομοιώσεις διαφορετικών τύπων βλαβών, όπως μονοφασικά και πολυφασικά βραχυκυκλώματα (π.χ., SLAG, TLABCG, DLACG) [6].

Συγκεκριμένα, για τους σκοπούς της προσομοίωσης, δημιουργήθηκαν συνολικά 2200 δεδομένα για κάθε γραμμή μεταφοράς, τα οποία αντιπροσώπευαν 11 διαφορετικούς τύπους βλαβών. Κάθε σενάριο περιλάμβανε τις τάσεις και τα ρεύματα των τριών φάσεων ($V_a, V_b, V_c, I_a, I_b, I_c$), καθώς και δεδομένα σχετικά με τη γείωση.

Τα δεδομένα εισόδου κανονικοποιήθηκαν χρησιμοποιώντας την εξίσωση [6]:

$$X_n = 2 \left(\frac{X - X_{min}}{X_{max} - X_{min}} \right) - 1$$

όπου X_n είναι το αποτέλεσμα της κανονικοποίησης, X_{max} οι μέγιστες τιμές και X_{min} οι ελάχιστες τιμές. Αυτή η εξίσωση επιτρέπει τη μετατροπή των τιμών σε ένα σταθερό εύρος, τυπικά στο διάστημα $[-1,1]$, που διευκολύνει την ομαλή επεξεργασία από τους αλγορίθμους CNF και MLP. Η κανονικοποίηση των δεδομένων ήταν απαραίτητη για την εξασφάλιση της ομαλής λειτουργίας των αλγορίθμων CNF και MLP. Στη συνέχεια, τα δεδομένα εισήχθησαν στους αλγορίθμους ως πίνακες, όπου κάθε γραμμή αντιπροσώπευε ένα συγκεκριμένο σενάριο βλάβης, και κάθε στήλη αντιστοιχούσε σε μια παράμετρο (τάση ή ρεύμα) [40].

4.3 Υλοποίηση του CNF

Η υλοποίηση του CNF βασίστηκε στη συνδυαστική χρήση νευρωνικών δικτύων και ασαφούς λογικής. Πιο συγκεκριμένα, το CNF αφορούσε τη χρήση ενός πολυεπίπεδου νευρωνικού δικτύου, όπου η εκμάθηση των δεδομένων σφαλμάτων γινόταν με νευρωνικές συνδέσεις, ενώ οι κανόνες της ασαφούς λογικής χρησιμοποιούνταν για την κωδικοποίηση των συνθηκών ταξινόμησης.

Οι κανόνες της ασαφούς λογικής είχαν ως στόχο την αποτύπωση της σχέσης μεταξύ των τάσεων και των ρευμάτων για την ταξινόμηση των βλαβών. Οι παράμετροι P_{na} , P_{nb} , P_{nc} , P_a , P_b , and P_c επίσης υπολογίστηκαν από τη 2^η και την 3^η εξίσωση. Για την εφαρμογή της ασαφούς λογικής, χρησιμοποιήθηκαν 18 νευρώνες, που αντιστοιχούσαν σε 6 εισόδους και 3 συνθήκες ανά είσοδο, όπως φαίνεται στις εξισώσεις παρακάτω:

$$Na = P_{na} - P_{nb}, \quad Nb = P_{nb} - P_{nc}, \quad Nc = P_{nc} - P_{na}$$

$$P_{na} = \frac{P_a}{\max(P_a, P_b, P_c)}, \quad P_{nb} = \frac{P_b}{\max(P_a, P_b, P_c)}, \\ P_{nc} = \frac{P_c}{\max(P_a, P_b, P_c)}.$$

$$P_a = \frac{I_a}{I_b}, \quad P_b = \frac{I_b}{I_c}, \quad P_c = \frac{I_c}{I_a}$$

Όπου οι τιμές των παραμέτρων (P_a , P_b , P_c) προέκυψαν από τις αναλογίες των ρευμάτων κάθε φάσης. Η κατηγοριοποίηση των δεδομένων έγινε με βάση συναρτήσεις-μέλη, όπως **πολύ μικρό**, **μέτριο**, **μεγάλο**. Αυτές οι συναρτήσεις έδωσαν τη δυνατότητα στο σύστημα να εκτιμήσει την πιθανότητα ταξινόμησης ενός σφάλματος σε συγκεκριμένη κατηγορία [40]

Το επόμενο βήμα ήταν να ρυθμιστούν κατάλληλα όλοι οι συνδυασμοί σφάλματος στη γραμμή μεταξύ φάσης – φάσης και φάσης – γης ώστε να υλοποιηθεί η τεχνική CNF όπως φαίνεται στον Πίνακα 4.1.

Πίνακας 4.1: Οι διαφορετικές παράμετροι σφάλματος φάσης – φάσης και φάσης – γης για τη ρύθμιση της τεχνικής CNF [40]

Είσοδος (Α' φάση)	Είσοδος (Β' φάση)	Είσοδος (Γ' φάση)	Τύπος Σφάλματος
$A_v N_\alpha = V_h$	$N_b = H$	$N_c = V_s$	τότε SLAG
$A_v N_\alpha = V_s$	$N_b = V_h$	$N_c = H$	τότε SLBG
$A_v N_\alpha = H$	$N_b = V_s$	$N_c = V_h$	τότε SLCG
$A_v N_\alpha = V_s$	$N_b = V_h$	$N_c = M$	τότε DLAB
$A_v N_\alpha = V_s$	$N_b = H$	$N_c = V_h$	τότε DLBC
$A_v N_\alpha = V_h$	$N_b = V_s$	$N_c = S$	τότε DLAC
$A_v N_\alpha = V_s$	$N_b = V_h$	$N_c = A_v$	τότε DLABG
$A_v N_\alpha = V_s$	$N_b = S$	$N_c = V_h$	τότε DLBCG
$A_v N_\alpha = V_h$	$N_b = S$	$N_c = S$	τότε DLACG
$A_v N_\alpha = S$	$N_b = S$	$N_c = H$	τότε TLABC
$A_v N_\alpha = S$	$N_b = S$	$N_c = V_h$	Τότε TLABCG

Η εκπαίδευση του CNF μοντέλου πραγματοποιήθηκε με τη χρήση του backpropagation αλγορίθμου, με την προσαρμογή των βαρών να γίνεται για να μειωθεί το σφάλμα ταξινόμησης και εντοπισμού της βλάβης. Από τα 2200 δεδομένα, το 70% χρησιμοποιήθηκε για την εκπαίδευση και το 30% για τη δοκιμή. Τα ποσοστά που χρησιμοποιήθηκαν για τη δοκιμή και την εκπαίδευση της TN επιλέχθηκαν διότι η ο συνδυασμός τους έδινε το βέλτιστο αποτέλεσμα πρόβλεψης και την καλύτερη ταξινόμηση των σφαλμάτων βάσει της θέσης τους.

4.4 Υλοποίηση του MLP


Το MLP είναι ένα πολυεπίπεδο νευρωνικό δίκτυο, που προσομοιώνει τη λειτουργία του ανθρώπινου εγκεφάλου. Η υλοποίηση του MLP μοντέλου έγινε χρησιμοποιώντας τη βιβλιοθήκη Neural Network Toolbox του Matlab. Τα δεδομένα εισόδου (τάσεις και ρεύματα) κανονικοποιήθηκαν και εισήχθησαν στο δίκτυο, ενώ η έξοδος του μοντέλου αντιστοιχούσε στα αποτελέσματα ταξινόμησης και εντοπισμού των βλαβών.

4.5 Διαδικασία Δοκιμών


Οι δοκιμές πραγματοποιήθηκαν με την εισαγωγή διαφόρων δεδομένων σφαλμάτων και την αξιολόγηση της απόδοσης των δύο αλγορίθμων σε διαφορετικά σενάρια. Δοκιμάστηκαν διάφοροι τύποι βλαβών, όπως μονοφασικές και διφασικές βλάβες, σε διαφορετικές συνθήκες (γωνία βλάβης, αντίσταση βλάβης κ.λπ.).

4.5.1 Πειραματική διαδικασία με τη μέθοδο CNF

Για το πρώτο πείραμα με την τεχνική **CNF**, η περιοχή αποσαφήνισης της προβλεπόμενης εξόδου παρουσιάζεται στις Εικόνες 4.1 και 4.2 για τις γραμμές μεταφοράς PTL1 και PTL2, αντίστοιχα. Η έξοδος αποσαφήνισης δοκιμάστηκε για κάθε τύπο σφάλματος σε απόσταση 120 χλμ από την πηγή της γραμμής μεταφοράς, με αντίσταση σφάλματος $R_f=10\ \Omega$ και γωνία σφάλματος 45° .




Εικόνα 4.1: Το αποτέλεσμα αποσαφήνισης της Γραμμής 1 (PTL1) με τη μέθοδο CNF [40]




Εικόνα 4.2: Το αποτέλεσμα αποσαφήνισης της Γραμμής 2 (PTL2) με τη μέθοδο CNF [40]

Για την αξιολόγηση της απόδοσης, υπολογίστηκε το ποσοστό σφάλματος στην ταξινόμηση και τον εντοπισμό της βλάβης. Τα ποσοστά σφάλματος κυμαίνονταν μεταξύ 2.53% και 4.36% για την ταξινόμηση και μεταξύ 0.77% και 2.24% για τον εντοπισμό της βλάβης, ανάλογα με το μοντέλο γραμμής μεταφοράς (PTL1 και PTL2) και τον αριθμό δεδομένων που χρησιμοποιήθηκε για την προσομοίωση.

Οι Εικόνες 4.3 και 4.4 παρουσιάζουν την αξιολόγηση του σφάλματος για τα διφασικά σφάλματα (DL). Το σφάλμα υπολογίστηκε με το άθροισμα των δεδομένων που δεν ικανοποιούν τις συνθήκες της ασαφούς λογικής (FL conditions) και τη διαίρεση με το πλήθος των δεδομένων εισόδου.



Εικόνα 4.3: Η εκτίμηση του αποτελέσματος αποσαφήνισης της Γραμμής 1 (PTL1) με τη μέθοδο CNF [40]



Εικόνα 4.4: Η εκτίμηση του αποτελέσματος αποσαφήνισης της Γραμμής 2 (PTL2) με τη μέθοδο CNF [40]


Ο Πίνακας 4.2 παρουσιάζει τα αποτελέσματα των πειραμάτων ταξινόμησης και εντοπισμού σφαλμάτων για δύο γραμμές μεταφοράς (PTL1 και PTL2), με διαφορετικά πλήθη δεδομένων εκπαίδευσης (550, 1100 και 2200 δείγματα). Παρατηρείται ότι η αύξηση του αριθμού δεδομένων μειώνει τα σφάλματα (Errors) και αυξάνει τα ποσοστά ακρίβειας (Accuracies) και για τις δύο περιοχές. Συγκεκριμένα, για την ταξινόμηση σφαλμάτων, το σφάλμα στην PTL2 μειώνεται από 16.46 σε 4.36 καθώς τα δεδομένα αυξάνονται, ενώ η ακρίβεια αυξάνεται από 83.54% σε 95.64%. Παρόμοια βελτίωση παρατηρείται και στον εντοπισμό σφαλμάτων, όπου η ακρίβεια στην PTL1 φτάνει έως και 99.23%.

Πίνακας 4.2: Αποτελέσματα ταξινόμησης της μεθόδου CNF [40]


Experiments	Number of data	Errors		Accuracies	
		PTL1	PTL2	PTL1	PTL2
Faults Classification	550	4.9002	16.4565	95.0998	83.5435
	1100	3.3303	10.5731	96.6697	89.4269
	2200	2.5308	4.3577	97.4692	95.6423
Faults Location	550	2.9447	8.5584	97.0553	91.4416
	1100	1.4993	4.3575	98.5007	95.6425
	2200	0.7693	2.2358	99.2307	96.7647

4.5.2 Πειραματική διαδικασία με τη μέθοδο MLP

Για το δεύτερο πείραμα με την τεχνική **MLP**, οι Εικόνες 4.5 και 4.6 παρουσιάζουν τον αριθμό των κρυφών επιπέδων που απαιτούνται για να παραχθεί ένα μικρό σφάλμα κατά την ταξινόμηση σφαλμάτων στις γραμμές PTL1 και PTL2, αντίστοιχα. Τα σχήματα αυτά επιτρέπουν τον καθορισμό του αριθμού των κρυφών επιπέδων που είναι απαραίτητος για την εκπαίδευση του συστήματος με μικρό σφάλμα.



Εικόνα 4.5: Ο απαιτούμενος αριθμός των κρυφών επιπέδων για τη διάγνωση του σφάλματος με τη τεχνική MLP (PTL1) [40]



Εικόνα 4.6: Ο απαιτούμενος αριθμός των κρυφών επιπέδων για τη διάγνωση του σφάλματος με τη τεχνική MLP (PTL2) [40]

Στον Πίνακα 4.3 παρουσιάζεται η ακρίβεια της κατάταξης και της τοποθεσίας των σφαλμάτων:

1. Στην **PTL1**, η συνολική ακρίβεια για τη δοκιμή στην περίπτωση της ταξινόμησης σφαλμάτων είναι **99.81%**, ενώ για τον εντοπισμό σφαλμάτων η συνολική ακρίβεια είναι **98.64%**, χρησιμοποιώντας σύνολο δεδομένων 550 τιμών.
2. Στην **PTL2**, η συνολική ακρίβεια για τη δοκιμή στην περίπτωση της ταξινόμησης σφαλμάτων είναι **96.89%**, ενώ για τον εντοπισμό σφαλμάτων η συνολική ακρίβεια είναι **89.75%**, χρησιμοποιώντας επίσης σύνολο δεδομένων 550 τιμών.

Πίνακας 4.3: Ταξινόμηση βλαβών και αποτελεσμάτων τοποθεσίας της τεχνικής MLP

[6]

Experiments	Number of data	Errors		Accuracy (%)	
		PTL 1	PTL 2	PTL 1	PTL 2
Classification	550	0.0019	0.0311	99.81	96.89
	1100	0.0049	0.0341	99.51	96.59
	2200	0.0091	0.0383	99.09	96.17
Location	550	0.0136	0.1025	98.64	89.75
	1100	0.0216	0.1105	97.84	88.95
	2200	0.0384	0.1273	96.16	87.27

Για τις γραμμές PTL1 και PTL2 πραγματοποιήθηκαν πολλές δοκιμές για την επιλογή του αριθμού επαναλήψεων (epochs) ώστε να αποδοθούν καλύτερα αποτελέσματα. Ο αριθμός επαναλήψεων που επιλέχθηκε ήταν 3000, μετά από πειραματική αξιολόγηση πολλών σεναρίων, με βάση τη μεγαλύτερη ακρίβεια αποτελεσμάτων στο μοντέλο MLP.

Παρατηρείται ότι όταν το σύνολο δεδομένων αυξάνεται πάνω από 550 τιμές, η απόδοση του συστήματος μειώνεται. Αυτό σημαίνει ότι, με την τεχνική MLP, είναι δυνατό να προσδιοριστεί το όριο των δεδομένων που είναι κατάλληλο για την επίτευξη καλού αποτελέσματος.

Συγκεκριμένα, το μοντέλο CNF έδειξε καλύτερη απόδοση όταν αυξήθηκε ο αριθμός δεδομένων εκπαίδευσης, επιτυγχάνοντας ποσοστό σφάλματος 2.53% για την ταξινόμηση και 0.7693% για τον εντοπισμό της βλάβης στο PTL1, όταν χρησιμοποιήθηκαν 2200 δεδομένα. Το MLP, από την άλλη πλευρά, έδειξε ότι όταν τα δεδομένα ξεπερνούν τα 550 δεδομένα, η απόδοση του συστήματος μειώνεται, επισημαίνοντας ότι η ακρίβεια της ταξινόμησης και εντοπισμού περιορίζεται από τον αριθμό δεδομένων [6].

4.5.3 Συγκριτικά Πλεονεκτήματα των RNN.

Η τεχνική αυτή είναι εξαιρετική για διαδοχικά δεδομένα και είναι αποτελεσματική σε δυναμικά περιβάλλοντα, όπως τα αεροπορικά συστήματα, όπου οι βλάβες μπορεί να εξελίσσονται με την πάροδο του χρόνου.

1. **Πλεονεκτήματα των DBN:** Αντιμετωπίζουν πιο αποτελεσματικά τα δεδομένα υψηλού θορύβου, κάτι που είναι κρίσιμο σε περιβάλλοντα όπως οι σταθμοί φόρτισης. Οι DBN χρησιμοποιούν την πολυεπίπεδη εκμάθηση, επιτρέποντας την ανίχνευση βλαβών μέσω πολύπλοκων χαρακτηριστικών που δημιουργούνται από τα διαφορετικά επίπεδα RBM, γεγονός που τους καθιστά ιδιαίτερα κατάλληλους για ανάλυση στατικών δεδομένων ή δεδομένων πολλαπλών πηγών .

4.6 Εφαρμογή σε Πραγματικό Σύστημα: EMS

Η υλοποίηση με iFD προτείνει μία ελαφριά, επεκτάσιμη και υψηλής ακρίβειας αρχιτεκτονική για την ανίχνευση και απομόνωση σφαλμάτων (FDI) σε αισθητήρες και ενεργοποιητές. Αντικαθιστά την κλασική ανάγκη ύπαρξης της τράπεζας εκτιμητών με έναν ενιαίο νευρωνικό εκτιμητή, επιτυγχάνοντας εξαιρετική λειτουργικότητα με εξαιρετικά χαμηλό υπολογιστικό κόστος. Για την αξιολόγηση της προτεινόμενης αρχιτεκτονικής iFD, έγινε εφαρμογή σε ένα πραγματικό σύστημα: το EMS. Το EMS είναι ένα μη γραμμικό, ασταθές σύστημα που απαιτεί συνεχή έλεγχο ώστε να διατηρείται σε ισορροπία, ενώ περιλαμβάνει 9 εισόδους και 10 εξόδους, δηλαδή [38]:

1. **Είσοδοι (Inputs):** 9 σήματα από ενεργοποιητές (εντολές ρύθμισης πίεσης σε δεξαμενές, άνοιγμα βαλβίδων)
2. **Έξοδοι (Outputs):** 10 σήματα από αισθητήρες (πίεσης εντός των δεξαμενών ή αγωγών, ροή, στάθμη δεξαμενών)

Το σύστημα αποτελείται από έναν ηλεκτρομαγνήτη με μαγνητικό πυρήνα και πηνίο με N_c σπείρες, ο οποίος έλκεται προς την σιδηροτροχιά (κατασκευασμένη επίσης από μαγνητικό υλικό).

Η αρχιτεκτονική δοκιμάστηκε με διάφορους τύπους σφαλμάτων, τα οποία παρουσιάζονται αναλυτικά στην επόμενη ενότητα.

4.6.1. Σενάρια Σφάλματος και Ανάλυση Απόδοσης

Για την αξιολόγηση της αρχιτεκτονικής iFD, δημιουργήθηκαν διάφορα **σενάρια σφαλμάτων** στο περιβάλλον του EMS. Τα σφάλματα αυτά περιλαμβάνουν καταστάσεις που είναι συνήθως δύσκολο να εντοπιστούν έγκαιρα, αλλά επηρεάζουν σημαντικά την απόδοση του συστήματος.

Τα σενάρια περιλαμβάνουν:

1. **Απώλεια σήματος αισθητήρα (sensor dropout):** Ο αισθητήρας σταματάει να παράγει σήμα και επιστρέφει μια σταθερή τιμή ή καθόλου τιμή.
2. **Παραμόρφωση σήματος αισθητήρα (frozen signal):** Το σήμα παραμένει σταθερό, ανεξάρτητα από την πραγματική μεταβολή της μεταβλητής.
3. **Καθυστέρηση ενεργοποιητή (actuator delay)**
Ο ηλεκτρομαγνήτης αντιδρά με σημαντική καθυστέρηση στις εντολές ελέγχου, προκαλώντας αστάθεια.
4. **Σφάλμα αισθητήρα ρεύματος με περιοδική απόκλιση (distorted current sensing)**
Το σήμα του αισθητήρα περιέχει περιοδικό σφάλμα που παρεμβάλλει λανθασμένη πληροφορία στον ελεγκτή.

Σε κάθε περίπτωση, το σύστημα λειτούργησε αρχικά με κανονικό έλεγχο. Μόλις το residual για ένα συγκεκριμένο σήμα υπερέβαινε το όριο, το σήμα **IS** απομόνωσε το προβληματικό στοιχείο, και το **RS** ενεργοποίησε έναν αναδιαμορφωμένο ελεγκτή που αγνόησε το ελαττωματικό σήμα [38].

Τα αποτελέσματα έδειξαν ότι:

1. Η ανίχνευση σφάλματος επιτυγχάνεται σε λιγότερο από 0.3 δευτερόλεπτα.
2. Η απομόνωση ενεργοποιείται άμεσα και αποτρέπει την εξάπλωση του προβλήματος.

3. Η ανάκτηση σταθερής λειτουργίας γίνεται εντός 0.7 δευτερολέπτων από το συμβάν.

Η μάζα του οχήματος M_s υποστηρίζεται από τον ηλεκτρομαγνήτη.

1. Το z_t συμβολίζει τη θέση της σιδηροτροχιάς
2. Το z τη θέση του ηλεκτρομαγνήτη
(και οι δύο εκφράζονται ως μικρές αποκλίσεις γύρω από το σημείο λειτουργίας)

Το μέγεθος $(z_t - z)$ ορίζεται ως η απόσταση μεταξύ ηλεκτρομαγνήτη και σιδηροτροχιάς, γνωστή και ως αεροκενό (airgap). Το αεροκενό πρέπει να διατηρείται όσο το δυνατόν πλησιέστερα στο επιθυμητό σημείο λειτουργίας, χωρίς να υπερβαίνει το ανώτατο επιτρεπτό όριο — όπως θα παρουσιαστεί στη συνέχεια της ενότητας. Το μη γραμμικό δυναμικό μοντέλο του συστήματος δίνεται από τους ακόλουθους τύπους:

$$\frac{dI}{dt} = \frac{\left(V_c - IR_c + \left(N_c A_p \frac{K_b}{G^2} \right) \left(\frac{dz_t}{dt} - \frac{dZ}{dt} \right) \right)}{N_c * A_p * \frac{K_b}{G} + L_c}, \quad F = K_f B^2$$

$$\frac{d^2 Z}{dt^2} = g - \frac{K_f I^2}{M_s G^2}, \quad B = K_b * \frac{I}{G}, \quad \frac{dG}{dt} = \frac{dz_t}{dt} - \frac{dZ}{dt}$$

Στις παραπάνω εξισώσεις: V_c είναι η τάση στο πηνίο, F η κατακόρυφη δύναμη, I το ρεύμα στο πηνίο, G το αεροκενό (airgap), Z η θέση του ηλεκτρομαγνήτη, B η πυκνότητα της μαγνητικής ροής, M_s η μάζα του οχήματος, R_c η αντίσταση του πηνίου, L_c η επαγωγή του πηνίου, N_c ο αριθμός σπειρών, A_p η επιφάνεια του μαγνητικού πόλου. Οι σταθερές K_b , K_f , και g αναπαριστούν αντίστοιχα: την σταθερά ροής (flux constant): $K_b=0.0015 \text{ Tm/A}$, την σταθερά δύναμης: $K_f=0.0221 \text{ Nm}^2/\text{A}^2$, την επιτάχυνση της βαρύτητας: $g=9.81 \text{ m/s}^2$.

Παρόλο που η γραμμικοποίηση του EMS είναι απαραίτητη για τον σχεδιασμό των γραμμικών ελεγκτών, στην παρούσα μελέτη οι ελεγκτές ρυθμίζονται και δοκιμάζονται απευθείας πάνω στο μη γραμμικό μοντέλο του EMS. Η γραμμικοποίηση πραγματοποιείται για μικρές αποκλίσεις γύρω από το σημείο λειτουργίας. Για παράδειγμα, το γραμμικοποιημένο μοντέλο του αεροκενού δίνεται από:

$$G = G_0 + (z_t - z)$$

Όπου τα πεζά γράμματα αναπαριστούν τις μικρές αποκλίσεις και το (ο) αναφέρεται στο σημείο λειτουργίας. Η ίδια συμβολική προσέγγιση εφαρμόζεται και στις υπόλοιπες μεταβλητές: B,F,I,V_c,Z.

Επίσης, το γραμμικό χρονικά αμετάβλητο μοντέλο κατάστασης (LTI) του EMS εκφράζεται ως εξής:

$$\frac{dx}{dt} = A x + B_{uc} u_c + \frac{B_z dz_t}{dt}, \quad y = C x$$

Όπου [21]:

1. A: πίνακας καταστάσεων (state matrix)
2. B_{uc}: πίνακας ελέγχου (control input matrix)
3. B_{zt}: πίνακας διαταραχών εισόδου (disturbance input matrix)
4. C: πίνακας εξόδου (output matrix)

Το διάνυσμα κατάστασης ορίζεται ως

$$x = \begin{bmatrix} i \\ \frac{dz}{dt} \\ z_t - z \end{bmatrix}$$

Όπου [38]:

1. i: ρεύμα πηνίου
2. $\dot{z}$: κατακόρυφη ταχύτητα του ηλεκτρομαγνήτη
3. (z_t-z): αεροκενό που πρέπει να ελεγχθεί
4. z: ταχύτητα μεταβολής της σιδηροτροχιάς
5. u_c: είσοδος ελέγχου (δηλαδή η εφαρμοζόμενη τάση)

4.6.2 Διαταραχές στην είσοδο και Απαιτήσεις Ελέγχου του Συστήματος EMS

Στον κατακόρυφο άξονα του συστήματος EMS λαμβάνονται υπόψη δύο τύποι εισαγόμενων διαταραχών: η Προσδιοριστική διαταραχή (Deterministic – Dtm) και η Στοχαστική διαταραχή (Stochastic – Sth).

4.6.3 Προσδιοριστική Είσοδος (Dtm)

Η διαταραχή Dtm προκαλείται από τη μεταβολή της θέσης της σιδηροτροχιάς z_t , η οποία οφείλεται στις προγραμματισμένες αλλαγές της κλίσης της διαδρομής καθώς το όχημα κινείται κατά μήκος των ραγών.

Στην παρούσα μελέτη, θεωρείται ότι η σιδηροτροχιά έχει:

1. Κλίση: 5%
2. Ταχύτητα οχήματος: 15 m/s
3. Επιτάχυνση: 0.5 m/s²
4. Jerk (παράγωγος της επιτάχυνσης): 1 m/s³

4.6.4 Απαιτήσεις Ελέγχου για την Dtm:

Μέγιστη απόκλιση αεροκενού: $(z_t - z)_p \leq 7.5 \text{ mm}$, Μέγιστη τιμή ελέγχου (τάση): $u_{cp} \leq 300 \text{ V}$, Χρόνος καθιέρωσης (settling time): $t_s \leq 3 \text{ s}$, σφάλμα στο σταθερό σημείο του αεροκενού: $e_{(z_t - z)_{ss}} = 0$

4.6.5 Στοχαστική Είσοδος

Η στοχαστική διαταραχή (Sth) προκύπτει από τυχαίες μεταβολές της σιδηροτροχιάς, όπως ανομοιομορφίες, ανοχές και μηχανικές καμπυλώσεις. Οι μεταβολές ταχύτητας κατά μήκος της σιδηροτροχιάς προσεγγίζονται μέσω της φασματικής πυκνότητας ισχύος διπλής όψης (double-sided power spectral density).

4.6.5.1 Απαιτήσεις Ελέγχου για την Sth.

Η Επιτάχυνση RMS του ηλεκτρομαγνήτη είναι:

$$z_{rms} \leq 1 \text{ m/s}^2$$

Η απόκλιση RMS του αεροκενού είναι: $(z_t - z)_{rms} \leq 5 \text{ mm}$ και Τιμή ελέγχου της τάσης RMS είναι: $u_{crms} \leq 300 \text{ V}$.

Οι παραπάνω προδιαγραφές καθορίζουν την αποδεκτή απόδοση του συστήματος EMS σε περιβάλλον με μεταβλητές ή/και τυχαίες συνθήκες λειτουργίας. Οι ρυθμιστές που σχεδιάζονται πρέπει να ικανοποιούν και τα δύο σενάρια (Dtm και Sth).

4.6.6 Αποδοτικότητα και αξιολόγηση της προτεινόμενης μεθόδου iFD

Το EMS διαθέτει μια είσοδο $n_u=1$ με $U=\{u_c\}$ και τέσσερις δυνατές μετρούμενες εξόδους $n_y=4$ με $Y=\{i(z_t - z), \dot{z}, \ddot{z}\}$, οι οποίες μπορούν να χρησιμοποιηθούν για τον σχεδιασμό του ελεγκτή. Για τον έλεγχο του συστήματος χρησιμοποιείται η μέθοδος (H_∞) loop-shaping (ανθεκτικός έλεγχος), η οποία απαιτεί το ελεγχόμενο μέγεθος $(z_t - z)$ να εισάγεται ως πρότυπη μεταβλητή (standard input) στον ελεγκτή.

Βάσει αυτού, θεωρούνται τρεις πιθανές περιπτώσεις βλάβης σε αισθητήρες:

1. i : ρεύμα πηνίου
2. $\dot{z}$: ταχύτητα
3. $\ddot{z}$: επιτάχυνση

Εφόσον το $(z_t - z)$ θεωρείται πάντα διαθέσιμο και πρότυπο, το συνολικό πλήθος συνδυασμών αισθητήρων/ενεργοποιητών είναι $n_{yu}=8$. Συνεπώς, χρησιμοποιούνται οκτώ διαφορετικοί ελεγκτές τύπου iFD, όπως: $K_{(zt-z)}$, K_i , $K_{\dot{z}}$, $K_{\ddot{z}}$ καθώς και όλοι οι δυνατοί συνδυασμοί αυτών (2 και 3 σφάλματα ταυτόχρονα). Αυτοί καλύπτουν τις 7 πιθανές περιπτώσεις σφάλματος στους αισθητήρες, όπως απεικονίζεται αμέσως μετά στην Εικόνα 4.7.

Πίνακας 4.4: Χαρακτηριστικά του iFD

Κατηγορία	Περιγραφή
Τύπος Δικτύου	Δυναμικό μη γραμμικό νευρωνικό δίκτυο εισόδου–εξόδου (Nonlinear I/O NN)
Είσοδοι (5)	$U_c, i, z_t - z, \dot{z}, \ddot{z}$
Έξοδοι (3)	$i, \hat{z}, \ddot{z}$
Καθυστέρηση	1 γραμμή καθυστέρησης (tapped delay line)
Κρυφή στρώση	20 νευρώνες, συνάρτηση ενεργοποίησης sigmoid
Έξοδος	Συνάρτηση ενεργοποίησης: γραμμική (linear)
Αλγόριθμος Εκπαίδευσης	Levenberg–Marquardt backpropagation
Κριτήρια Τερματισμού	1) $MSE \leq 10^{-5}$, 2) Μέγ. 1000 εποχές
Χρόνος Εκπαίδευσης	~30 λεπτά σε Intel i3, 2GHz, 8GB RAM

Για την εκπαίδευση χρησιμοποιείται ο αλγόριθμος Levenberg–Marquardt backpropagation, κατάλληλος για ταχεία σύγκλιση σε δίκτυα μέσου μεγέθους. Πριν την εκπαίδευση του εκτιμητή, τα σήματα κανονικοποιούνται στο εύρος [0,1] έτσι ώστε όλα να έχουν ομοιόμορφη δυναμική. Αυτό γίνεται για να διασφαλιστεί σταθερότητα κατά την εκπαίδευση.

Η αρχιτεκτονική του iFD βασίζεται σε τέσσερις βασικές συνιστώσες:

1. **Νευρωνικός Εκτιμητής (NN Estimator):** Ένα πλήρως συνδεδεμένο δίκτυο που εκπαιδεύεται να εκτιμά την "υγιή" έξοδο του συστήματος με βάση τα σήματα εισόδου και εξόδου.
2. **Γεννήτρια Καταλοίπων (Residual Generator – RG):** Υπολογίζει την τετραγωνική απόκλιση μεταξύ πραγματικών και εκτιμημένων εξόδων.
3. **Μονάδα Λήψης Απόφασης (Decision Mechanism – DM):** Παρακολουθεί τα κατάλοιπα και αποφασίζει αν ένα σήμα είναι ελαττωματικό.
4. **Λογικός Διακόπτης (Binary Switch – BS):** Ενεργοποιεί ή απομονώνει σήματα δυναμικά, επιτρέποντας στο σύστημα να αγνοεί σφάλματα σε πραγματικό χρόνο

Η ροή δεδομένων ξεκινά από τα σήματα του συστήματος, περνά στον εκτιμητή, όπου παράγονται οι προβλεπόμενες έξοδοι, συγκρίνονται με τις πραγματικές, και όταν εντοπιστεί απόκλιση, ενεργοποιείται η DM και το BS.

4.6.8 Χαρακτηριστικά του Εκπαιδευτικού Συνόλου και Ρυθμίσεις Εκτιμητή

Το σύστημα EMS διαθέτει έναν ενεργοποιητή ($n_u=1$) και ένα εκτιμώμενο σήμα ενεργοποιητή ($n_u=1$). Επιπλέον, υπάρχουν τέσσερα μετρούμενα σήματα εξόδου από αισθητήρες ($n_y=4$, αλλά εκτιμώνται μόνο τα τρία από αυτά ($n_y=3$), καθώς το αεροκενό (z_t-z) θεωρείται αξιόπιστο και απαλλαγμένο από σφάλματα, επομένως δεν περιλαμβάνεται στις εκτιμήσεις. Ο συνολικός αριθμός δυνατών συνδυασμών αισθητήρων και ενεργοποιητών για τη δημιουργία περιπτώσεων σφάλματος είναι $n_{yu}=8$ με στόχο την κάλυψη διαφορετικών σεναρίων λειτουργίας και την ενίσχυση της γενίκευσης του εκτιμητή. Το σύνολο δεδομένων εκπαίδευσης δημιουργήθηκε με ρυθμό δειγματοληψίας $\tau_s=1$ kHz και συνολική διάρκεια προσομοίωσης $T=6,6s$. Έτσι, το πλήθος δειγμάτων ανά σύνολο είναι: $k=\tau_s \cdot T=1000 \cdot 6.6=6600$ δείγματα ανά περίπτωση.

Το τελικό σύνολο δεδομένων D συγκροτείται από δύο επιμέρους σύνολα που αναλύθηκαν πριν:

1. D_d : δεδομένα από προσδιοριστικές αποκρίσεις (Deterministic – Dtm)
2. D_s : δεδομένα από στοχαστικές αποκρίσεις (Stochastic – Sth)

Το σύνολο εκπαίδευσης αναπαρίσταται ως εξής [14]:

$$D_{\{dr \times dc\}} = \begin{bmatrix} D_{\{dr \times dc\}}^{\{d\}} \\ D_{\{dr_s \times dc\}}^{\{s\}} \end{bmatrix}^{\{T\}}$$

Όπου:

1. $dr_d=dr_s=52\ 800 \Rightarrow dr=105\ 600$ (σύνολο γραμμών)
2. $dc=dc=9$ (χαρακτηριστικά ανά γραμμή)

Κατά την εκπαίδευση του εκτιμητή, για την προσομοίωση περιπτώσεων σφαλμάτων εφαρμόζονται συναρτήσεις υποκατάστασης σημάτων αισθητήρων, οι οποίες έχουν την παρακάτω μορφή [14]:

$$C_{yj} = c_i = 0, cz', cz'' = 0$$

Αυτές οι συναρτήσεις έχουν διαστάσεις $k \times 3$ και εφαρμόζονται σε κάθε χρονική στιγμή. Χρησιμοποιούνται τόσο σε προσδιοριστικά όσο και στοχαστικά σενάρια, όπως περιγράφεται στην ενότητα «Εκπαίδευση του Νευρωνικού Εκτιμητή (Offline)». Αφορούν την αντικατάσταση των αντίστοιχων σημάτων όταν προσομοιώνεται βλάβη αισθητήρα επιτρέποντας στο σύστημα να λειτουργεί κανονικά με ελλιπή ή αλλοιωμένα δεδομένα.

Το συγκεκριμένο σύστημα αποτελείται από τα ακόλουθα στοιχεία:

1. **Πλατφόρμα αιώρησης**, η οποία ελέγχεται μέσω τεσσάρων ηλεκτρομαγνητών
2. **Τέσσερις αισθητήρες απόστασης**, οι οποίοι μετρούν την κατακόρυφη απόσταση της πλατφόρμας από την επιφάνεια
3. **Τέσσερις αισθητήρες ρεύματος**, που μετρούν το ρεύμα στους ηλεκτρομαγνήτες
4. **Τέσσερις ενεργοποιητές (ηλεκτρομαγνήτες)**, που ελέγχουν την έλξη για να διατηρηθεί η σταθερή αιώρηση [38].

Ο **στόχος του συστήματος** είναι να διατηρεί την πλατφόρμα σε σταθερή θέση, εξισορροπώντας τη μαγνητική δύναμη και το βάρος της. Αυτό επιτυγχάνεται μέσω ενός **PI ελεγκτή**, ο οποίος βασίζεται στις μετρήσεις των αισθητήρων για να ρυθμίζει τα σήματα των ενεργοποιητών.

Η προσομοίωση υλοποιήθηκε σε περιβάλλον **MATLAB/Simulink**, και επέτρεψε:


1. Την προσομοίωση δυναμικών βλαβών (αισθητήρες/ενεργοποιητές)
2. Την ενσωμάτωση της αρχιτεκτονικής iFD με τον ελεγκτή
3. Τη λεπτομερή παρακολούθηση της απόκρισης του συστήματος πριν και μετά την ενεργοποίηση των μηχανισμών IS και RS

4.6.9 Σενάρια σφαλμάτων των αισθητήρων

Τα σφάλματα αισθητήρων διακρίνονται σε δύο βασικές κατηγορίες:

1. Τα προσθετικά σφάλματα (Additive – AD)
2. Τα πολλαπλασιαστικά σφάλματα (Multiplicative – MP)

Και οι δύο τύποι της Εικόνας 4.8 λαμβάνονται υπόψη στα σενάρια σφαλμάτων των αισθητήρων. Σε κάθε περίπτωση, η έξοδος του αισθητήρα y_j είτε προστίθεται με μια συνάρτηση f_a είτε πολλαπλασιάζεται με μια συνάρτηση f_m αντίστοιχα.



Εικόνα 4.8: Κατηγορίες και τύποι σφαλμάτων αισθητήρων [38]

Για κάθε κατηγορία σφάλματος, ορίζονται τρεις τύποι:

1. **Απότομο Σφάλμα (Abrupt Fault – AF):** Προκύπτει όταν ένα εξάρτημα αισθητήρα ή ενεργοποιητή υποστεί ξαφνική βλάβη, με την έξοδο να παρουσιάζει ασυνεχή μεταβολή βήματος (step-wise change). Παρότι είναι πιο "απότομο" από τα άλλα 2 είδη σφαλμάτων, είναι ευκολότερα ανιχνεύσιμο και συνεπώς μπορεί να απομονωθεί άμεσα από τον βρόχο ελέγχου.
2. **Σταδιακό Σφάλμα (Incipient Fault – IF):** Αναπτύσσεται σταδιακά και ως εκ τούτου είναι δυσκολότερο στην ανίχνευση. Πρόκειται για ιδιαίτερα επικίνδυνο τύπο

σφάλματος, διότι μπορεί να αποσταθεροποιήσει τον βρόχο ελέγχου πριν καν ανιχνευθεί.


3. **Μη Προσδιορισμο Σφάλμα (Indeterminate Fault):** Εμφανίζει χαρακτηριστικά και των δύο προηγούμενων τύπων, αλλά λαμβάνει χώρα σε τυχαία χρονικά διαστήματα και πλάτη. Το σφάλμα αυτό είναι εξίσου επικίνδυνο με το IF, καθώς μπορεί να εμφανιστεί και να εξαφανιστεί απρόβλεπτα, χωρίς καμία προειδοποίηση. Η μέθοδος iFD αντιμετωπίζει αυτόν τον τύπο σφάλματος ως PF (persistent fault) και τον ανιχνεύει μόλις εκδηλωθεί.

Στο πλήρες σετ αισθητήρων Υ του EMS περιλαμβάνονται τέσσερις αισθητήρες, με την υπόθεση ότι ο αισθητήρας του αεροκενού ($z_t - z$) δεν εμφανίζει σφάλματα. Επιπλέον, ο ενεργοποιητής u_c θεωρείται επίσης αξιόπιστος. Οι κατηγορίες AD, MP, καθώς και σφάλματα αμεροληψίας (bias) εφαρμόζονται στους τρεις αισθητήρες: i (ρεύμα πηνίου), $\dot{z}$ (ταχύτητα), $\ddot{z}$ (επιτάχυνση). Τα προφίλ των σφαλμάτων είναι κοινά για όλους τους αισθητήρες και παρουσιάζονται για τον αισθητήρα ρεύματος i στις Εικόνες 4.9 έως 4.14. Σε όλες τις περιπτώσεις, το σφάλμα ξεκινά στη χρονική στιγμή $t_f = 1$ s, η οποία επισημαίνεται ως Σημείο A (Point A) σε όλα τα σχήματα. Το προφίλ AD/AF για τον αισθητήρα ρεύματος ορίζεται ως f_{aai} , όπως περιγράφεται στην επόμενη εξίσωση. Το ίδιο προφίλ σφάλματος εφαρμόζεται και στους αισθητήρες $\dot{z}$ και $\ddot{z}$, με φασματικές πυκνότητες $S_z = 0.03$ και $S_{\ddot{z}} = 2$, αντίστοιχα.

$$f_{aai}(t) = \begin{cases} v(t), & \text{if } t_f \leq t < \infty \\ 0, & \text{if } t < t_f \end{cases} \quad f_{mai}(t) = \begin{cases} 5, & \text{if } t_f \leq t < \infty \\ 1, & \text{if } t < t_f \end{cases}$$


Ο παραπάνω τύπος αποτελεί μαθηματική απεικόνιση του προσθετικού απότομου σφάλματος που εφαρμόζεται στον αισθητήρα ρεύματος. Το σφάλμα ξεκινά στο χρονικό σημείο $t_f=1$ s και προστίθεται στο κανονικό σήμα ως τυχαίο σήμα θορύβου περιορισμένου εύρους συχνοτήτων.

Η απεικόνιση του προσδιοριστικού σήματος εισόδου D_{tm} που εφαρμόζεται στο EMS για την προσομοίωση κλίσης 5% σε ταχύτητα 15 m/s φαίνεται στην Εικόνα 4.10. Το σήμα προσομοιώνει την αναμενόμενη αλλαγή στη θέση της σιδηροτροχιάς κατά τη διάρκεια της κίνησης.



Εικόνα 4.9: Σήμα Εισόδου Dtm, Προγραμματισμένη Κλίση Σιδηροτροχιάς [38]


Στην Εικόνα 4.10, η έξοδος του αισθητήρα ρεύματος εμφανίζεται υπερτεθειμένη με ένα στοχαστικό σήμα χαμηλής συχνότητας $v(t)$, το οποίο έχει χαρακτηριστικά λευκού θορύβου (white noise), μηδενική μέση τιμή, φασματική πυκνότητα ενέργειας $S_i = 5$, περιοριζόμενη σε συχνότητα $\omega_i = 1.6$ Hz με κύρια συχνότητα 10 rad/s



Εικόνα 4.10: Προσθετικό απότομο σφάλμα στον Αισθητήρα Ρεύματος (AD/AF) [38]

Στην Εικόνα 4.11 παρουσιάζεται το προφίλ MP/AF, f_{mai} , όπου ο αισθητήρας ρεύματος υφίσταται ξαφνική αστοχία στο $t_f = 1$ s και η έξοδος του αυξάνεται απότομα σε

πενταπλάσια τιμή από τη φυσιολογική. Αντίστοιχο προφίλ σφάλματος χρησιμοποιείται και για τους αισθητήρες $\dot{z}$ και $\ddot{z}$.




Εικόνα 4.11: Πολλαπλασιαστικό απότομο σφάλμα στον Αισθητήρα Ρεύματος (MP/AF)

[38]

Στο χρονικό σημείο $t_f=1$ s, η έξοδος του αισθητήρα αυξάνεται απότομα και φτάνει στο πενταπλάσιο της ονομαστικής τιμής, εμφανίζοντας σημαντική απόκλιση λόγω αστοχίας.

4.6.10 Ανάλυση αντίδρασης του iFD


Το σφάλμα τύπου (bias/abrupt) για τη μέτρηση του ρεύματος παρουσιάζεται στην Εικόνα 4.12. Φαίνεται ξεκάθαρα ότι η έξοδος του αισθητήρα αυξάνεται απότομα έως τη μέγιστη τιμή του, η οποία για τον αισθητήρα ρεύματος είναι: $\gamma_{oi}=10\text{ A}$.



Εικόνα 4.12: Προφίλ bias-AF [38]


Οι περιπτώσεις σταδιακού σφάλματος IF παρουσιάζονται στις Εικόνες 4.13 και 4.14 Συγκεκριμένα:

Στην Εικόνα 4.13 το προσθετικό σταδιακό σφάλμα (AD/IF) στη μέτρηση ρεύματος περιγράφεται από τη συνάρτηση $f_{aii}(t)$ όπως δίνεται στην εξίσωση παρακάτω. Πρόκειται για σήμα τύπου ράμπας (ramp) με κλίση σ_i στο οποίο έχει προστεθεί στοχαστικό σήμα λευκού θορύβου περιορισμένης συχνότητας.



Εικόνα 4.13: Προφίλ AD/IF [38]

Στην Εικόνα 4.14 απεικονίζεται το πολλαπλασιαστικό σταδιακό σφάλμα (MP/IF), $f_{mii}(t)$ όπου το σφάλμα ξεκινά στο $t_f=1$ s και έπειτα μηδενίζεται λόγω πολλαπλασιασμού με μηδενικό παράγοντα.



Εικόνα 4.14: Προφίλ σφάλματος MP/IF [38]

Για τους αισθητήρες $\dot{z}$, $\ddot{z}$ τα προφίλ σφάλματος έχουν παρόμοια μορφή με τα εξής χαρακτηριστικά:

1. Κλίσεις ράμπας (slopes):

- $\sigma_{\dot{z}}=20$
- $\sigma_{\ddot{z}}=6$
- $\sigma_{\ddot{z}}=20$

2. Φασματικές πυκνότητες ισχύος (PSD):

- $S_{\dot{z}}=0.5$
- $S_{\ddot{z}}=0.03$
- $S_{\ddot{z}}=0.5$

4.6.11 Εφαρμογή Σύνθετου Σεναρίου για Επεξήγηση της Λειτουργίας του iFD


Το ακόλουθο σύνθετο σενάριο χρησιμοποιείται για την αναλυτική παρουσίαση της λειτουργίας του iFD:

1. Εφαρμόζεται στο EMS το (Dtm).
2. Οι τρεις αισθητήρες υφίστανται σφάλματα διαδοχικά με καθυστέρηση ως εξής:
 - i. $\ddot{z}$ στο $t=0.5$
 - ii. $\dot{z}$ στο $t=1.5$
 - iii. i στο $t=2$ s
3. Για κάθε αισθητήρα εφαρμόζεται προφίλ τύπου MP/AF (όπως για τον αισθητήρα i στην Εικόνα 4.11).

Στην Εικόνα 4.15 παρουσιάζεται η συμπεριφορά του αεροκενού (airgap) στην περίπτωση:

1. Χωρίς σφάλμα, δηλαδή με υγιές σύνολο αισθητήρων: $Y=\{i, \dot{z}, \ddot{z}\}$, ελεγκτής $K_i [(z_t-z), \dot{z}, \ddot{z}]$
2. Κατά την εμφάνιση σφαλμάτων

Στο σημείο $t=0.5$ s (σημείο A), παρουσιάζεται σφάλμα στον αισθητήρα $\ddot{z}$. Ο iFD ανιχνεύει άμεσα το σφάλμα και ακολουθεί αναδιάταξη του ελεγκτή: ο νέος ελεγκτής $K_i, [(z_t-z), \dot{z}]$ εισάγεται στον βρόχο ώστε να διατηρηθεί η απόδοση του συστήματος.



Εικόνα 4.15: Σενάριο σφάλματος με id:8 από την Εικόνα 4.9 [38]

Ακολουθως:

1. Ο αισθητήρας $\dot{z}$ αστοχεί στο $t=1.5s$ (σημείο B)
2. Ο αισθητήρας i στο $t=2s$ (σημείο C)

Και στις δύο περιπτώσεις, τα σφάλματα ανιχνεύονται επιτυχώς και αντιμετωπίζονται μέσω εναλλαγής στους κατάλληλους ελεγκτές:


1. $K_{(zt-z)}$
2. $K_{i,(zt-z)}$

4.6.12 Διαδικασία Αντιμετώπισης Σφάλματος (αισθητήρας i)

Η διαδικασία απομόνωσης και αποκατάστασης σφάλματος από τον iFD για τον αισθητήρα ρεύματος i περιλαμβάνει τρία στάδια:

1. **Ανίχνευση Σφάλματος (Sensor FD):** Στο χρονικό σημείο $t_f=1 s$, το κατάλοιπο της μέτρησης ρεύματος r_{yi} αρχίζει να αυξάνεται. Όταν ξεπεράσει το όριο κατωφλίου (threshold), το σφάλμα ανιχνεύεται (Εικόνα 4.10).
2. **Απομόνωση Σφάλματος (Fault Isolation):** Ο προβληματικός αισθητήρας αφαιρείται από τον βρόχο μέσω του Binary Switch (BS). Η συνάρτηση αντικατάστασης $c_{yi}=0$ εφαρμόζεται στην είσοδο του iFD.
3. **Αναδιάταξη Ελεγκτή (Controller Reconfiguration):** Δημιουργείται κατάλληλο σήμα αλλαγής (RS) και εισάγεται ο νέος ελεγκτής $K_{(zt-z)}$ στον βρόχο.

Η Εικόνα 4.16 απεικονίζει τα σήματα στην είσοδο/έξοδο του BS και στην έξοδο του iFD.



Εικόνα 4.16: Είσοδος και έξοδος (BS_{yi}) του αισθητήρα ρεύματος (i) και η έξοδος του iFD [38]

4.6.13 Τεχνικές ρυθμίσεις και εκπαίδευση του εκτιμητή

Ο εκτιμητής είναι ένα πλήρως συνδεδεμένο νευρωνικό δίκτυο με τις εξής παραμέτρους:

1. **Αρχιτεκτονική:** Δίκτυο 3 στρώσεων (input – hidden – output)
2. **Αριθμός παραμέτρων:** 2400 συνολικά
3. **Συνάρτηση κόστους:** μέσο τετραγωνικό σφάλμα (MSE)
4. **Βελτιστοποίηση:** Adam optimizer, learning rate = 0.001
5. **EPOCHs:** 500, με early stopping όταν δεν υπάρχει βελτίωση σε validation set

Κατά την εκπαίδευση, κάθε έξοδος y_k διδάσκεται ξεχωριστά, με ένα μοντέλο ανά έξοδο.

Η μεθοδολογία αξιολογείται σε συνθήκες με τεχνητά εισαγόμενα σφάλματα, τα οποία περιλαμβάνουν:

1. Μετατόπιση (offset)
2. Αποσύνδεση σήματος (signal drop-out)

3. Αύξηση θορύβου (Gaussian noise)
4. Στασιμότητα (constant value)

Αυτά εφαρμόζονται σε κάθε αισθητήρα/ενεργοποιητή ξεχωριστά, με στόχο να εξεταστεί η ικανότητα του συστήματος να εντοπίζει και να απομονώνει μεμονωμένα σφάλματα.

Η διαχείριση των καταλοίπων γίνεται με τον εξής τρόπο:

1. Κατώφλι $T=0.005$
2. Παράθυρο $N=10$ βημάτων
3. Αν το residual ξεπεράσει το T για N βήματα τότε επισημαίνεται ως σφάλμα

Αυτό αποτρέπει ψευδώς θετικά (false positives) λόγω των στιγμιαίων διακυμάνσεων.

4.6.14 Απομόνωση και Αποκατάσταση

Μετά την απομόνωση ενός σήματος:

1. Το σήμα αγνοείται (Binary Switch = 0)
2. Η έξοδος συνεχίζει να προβλέπεται από το δίκτυο, χωρίς αυτό το σήμα
3. Το υπόλοιπο σύστημα παραμένει λειτουργικό

Το σύστημα μπορεί να επαναφέρει την είσοδο όταν το residual επιστρέψει εντός ορίων — δηλαδή υποστηρίζεται αυτόματη αποκατάσταση (re-inclusion).

4.6.15 Πλεονεκτήματα επιλογής του EMS:

1. Εμφανίζει αυξημένη ευαισθησία σε βλάβες
2. Είναι δυναμικά ασταθές, επομένως κατάλληλο για έλεγχο σε πραγματικό χρόνο
3. Μικρός αριθμός μεταβλητών — διευκολύνει τον πειραματισμό


4.7 Εφαρμογή σε Πραγματικό Σύστημα: GCNN

Η εφαρμογή του GCNN σε βιομηχανικό δίκτυο δεξαμενών νερού επιλέχθηκε ως μελέτη περίπτωσης προκειμένου να τεκμηριωθεί η ικανότητα της μεθοδολογίας (GCNN) να εντοπίζει και να απομονώνει βλάβες σε γενικευμένα συστήματα δικτύων, τα οποία έχουν παρόμοια χαρακτηριστικά λειτουργίας με τα ΣΗΕ. Συγκεκριμένα:

1. Και τα Συστήματα Ηλεκτρικής Ενέργειας (ΣΗΕ) και τα δίκτυα δεξαμενών νερού μπορούν να αναπαρασταθούν ως γράφημα κόμβων και ακμών (nodes & edges).
2. Και στις δύο περιπτώσεις, η ανίχνευση βλαβών απαιτεί την ανάλυση της κατάστασης του κάθε κόμβου (π.χ., πίεση δεξαμενής, τάση/ρεύμα γραμμής) με χρήση τοπολογικών και χρονικών πληροφοριών.
3. Το μοντέλο GCNN εκπαιδεύεται σε ένα περιβάλλον δεξαμενών για να δείξει την ικανότητά του να ανιχνεύει ανωμαλίες σε δικτυωμένες δομές, ενώ η γενίκευση της μεθόδου επιτρέπει την εφαρμογή της και σε ΣΗΕ.

Η επιλογή των δεξαμενών ως μελέτη περίπτωσης στοχεύει στη διερεύνηση της ικανότητας του GCNN να ανιχνεύει βλάβες σε δικτυωμένα συστήματα, και η μεθοδολογία μπορεί να εφαρμοστεί εξίσου σε ΣΗΕ, όπου η ανίχνευση βλαβών στους κόμβους (γραμμές μεταφοράς, υποσταθμοί) ακολουθεί αντίστοιχη λογική.


Η πειραματική αξιολόγηση της μεθοδολογίας GCNN βασίζεται σε ένα δίκτυο 100 δεξαμενών νερού, όπως φαίνεται στην Εικόνα 4.17. Το δίκτυο προσομοιώνει ένα πλήρες σύστημα αισθητήρων και ενεργοποιητών, όπου κάθε κόμβος αντιπροσωπεύει μια δεξαμενή ή μετρητή πίεσης/ροής και παρέχει χρονολογικά δεδομένα για πρόβλεψη, παρακολούθηση και διάγνωση.



Εικόνα 4.17: Το βιομηχανικό δίκτυο 100 δεξαμενών νερού [39]

Γίνεται χρήση προσομοιωτή για τη διανομή νερού μεταξύ των δεξαμενών για τη δημιουργία σεναρίων για αυτή τη μελέτη. Το σύνολο δεδομένων εκπαίδευσης περιλαμβάνει 50000 δείγματα, ενώ το σύνολο δεδομένων επικύρωσης έχει 10000 δείγματα. Οι δεξαμενές συνδέονται μέσω αγωγών νερού όπου η ροή νερού μεταξύ κάθε δύο συνδεδεμένων δεξαμενών είναι μια μη γραμμική συνάρτηση των πιέσεων και της απόστασης μεταξύ των δεξαμενών.

Η Εικόνα 4.18 δείχνει ένα δείγμα 5 συνδεδεμένων δεξαμενών στο δίκτυο, ενώ τα γραφήματα με κόκκινο δείχνουν τη συνάρτηση Πίεσης-Χρόνου σε κάθε μια από αυτές [39].



Εικόνα 4.18: Δείγμα 5 συνδεδεμένων δεξαμενών στο δίκτυο [39]

Θεωρούμε κάθε δεξαμενή ως ένα επιμέρους στοιχείο του δικτύου. Η υδραυλική πίεση σε κάθε δεξαμενή καταγράφεται ως ένα μετρήσιμο σήμα για το συγκεκριμένο στοιχείο. Όταν η στάθμη του νερού σε μια δεξαμενή πέσει κάτω από ένα προκαθορισμένο κατώφλι, η δεξαμενή μεταβαίνει σε κατάσταση αναπλήρωσης (refill mode).

Η λειτουργία αναπλήρωσης συνεχίζεται έως ότου η δεξαμενή γεμίσει πλήρως. Μια δυαδική μεταβλητή (binary variable), που υποδεικνύει τη λειτουργική κατάσταση της δεξαμενής (αναπλήρωση ή κλειστή), αποτελεί το δεύτερο σήμα για κάθε στοιχείο του δικτύου. Ένα σφάλμα σε μια δεξαμενή αντιστοιχεί σε διαρροή. Η διαρροή διαρκεί για τυχαίο χρονικό διάστημα, μέχρι οι χειριστές να την εντοπίσουν και να την επιδιορθώσουν. Στις μετρήσεις υπάρχει «θόρυβος» της τάξης του 5%.

Για τον καθορισμό της τοπολογίας του δικτύου:

1. Όταν οι Δεξαμενές i και j **δεν** συνδέονται με σωλήνα, θεωρούμε $w_{ij}=0$
2. Όταν οι Δεξαμενές i και k **συνδέονται** με σωλήνα, θεωρούμε:

$$w_{i_k} = 1/dis_{i_k}$$


όπου dis_{ik} είναι το μήκος του σωλήνα που συνδέει τη Δεξαμενή i με τη k [39].

Το δίκτυο, όπως παρουσιάζεται στην Εικόνα 4.17, αναπαριστά ένα GCNN, που σημαίνει ότι υπάρχει μονοπάτι από οποιαδήποτε δεξαμενή προς οποιαδήποτε άλλη μέσω των αγωγών. Αυτό σημαίνει ότι ένα σφάλμα σε μία δεξαμενή μπορεί να επηρεάσει **όλες** τις υπόλοιπες στο σύστημα. Ο κύριος στόχος της υλοποίησης είναι η σχεδίαση ενός αλγορίθμου διάγνωσης βλαβών, ο οποίος θα ανιχνεύει τις διαρροές και θα απομονώνει τις ελαττωματικές δεξαμενές του συστήματος.

Η ακριβής και έγκαιρη ανίχνευση και απομόνωση σφαλμάτων μπορεί να μειώσει σημαντικά τον χρόνο διαρροής και τη σπατάλη υλικών. Τυπικά, μια διαρροή σε μια δεξαμενή προκαλεί απώλεια υγρού και μείωση της πίεσης. Ωστόσο, η διαρροή δεν είναι ο μόνος παράγοντας που επηρεάζει την πίεση σε μια δεξαμενή. Για παράδειγμα, μια μείωση της πίεσης σε γειτονικές δεξαμενές μπορεί να αυξήσει τη ροή εξόδου της υπό εξέταση δεξαμενής και, τελικά, να προκαλέσει πτώση της πίεσης και σε αυτήν. Συνεπώς, η πίεση σε μια δεξαμενή αποτελεί συνάρτηση όχι μόνο της δικής της κατάστασης, αλλά και των διαρροών σε άλλες δεξαμενές του δικτύου.

Η Εικόνα 4.19 απεικονίζει την πίεση και τα σφάλματα σε μια δεξαμενή (τυχαίο δείγμα). Οι κόκκινες γραμμές αντιστοιχούν στις περιόδους διαρροής της δεξαμενής [39]:

1. Στον κάθετο άξονα, η τιμή 0 αντιστοιχεί σε κανονική λειτουργία
2. Η τιμή 100 αντιστοιχεί στις χρονικές περιόδους με διαρροή



Εικόνα 4.19: Η πίεση συναρτήσει του χρόνου σε μια δεξαμενή [39]

Η μπλε γραμμή απεικονίζει την πίεση. Όπως παρατηρείται, η μείωση της υδροστατικής πίεσης σε μια δεξαμενή δεν είναι πάντα αποτέλεσμα δικού της σφάλματος. Αυτό καθιστά το πρόβλημα της απομόνωσης σφαλμάτων ιδιαίτερα δύσκολο, καθώς μια διαρροή σε μία μόνο δεξαμενή μπορεί να προκαλέσει μεταβολές πίεσης σε ολόκληρο το δίκτυο. Ως εκ τούτου, η χρήση μόνο τοπικών μετρήσεων για την ανίχνευση και απομόνωση σφαλμάτων μπορεί να μειώσει τα ποσοστά επιτυχίας και να αυξήσει τα ψευδώς θετικά (false alarms).


Δεδομένου ότι ένα σφάλμα σε ένα στοιχείο του συστήματος μπορεί να επηρεάσει οποιοδήποτε άλλο στοιχείο, θα μπορούσε να φανεί λογικό να χρησιμοποιηθούν όλα τα σήματα των δεξαμενών για την ανίχνευση και απομόνωση σφαλμάτων. Ωστόσο, σε ένα σύστημα με πολλά υποσυστήματα, η χρήση όλων των σημάτων ενδέχεται να οδηγήσει σε υπερεκπαίδευση (overfitting), η οποία με τη σειρά της μπορεί να προκαλέσει:

1. Χαμηλά ποσοστά ανίχνευσης (detection rates)
2. Υψηλά ποσοστά ψευδώς θετικών (false alarms) κατά τη φάση της εφαρμογής (deployment).

Για την απόδειξη ύπαρξης αυτού του προβλήματος, χρησιμοποιείται ένα Πλήρως Συνδεδεμένο Νευρωνικό Δίκτυο (Fully Connected NN) με:

1. 2 κρυφές στρώσεις
2. 500 κόμβους ανά κρυφή στρώση

Το δίκτυο εκπαιδεύεται στη μάθηση ενός μοντέλου διάγνωσης σφαλμάτων χρησιμοποιώντας τις μετρήσεις πίεσης δεξαμενών νερού και την κατάσταση αναπλήρωσης (refill mode) από όλες τις δεξαμενές, με στόχο να εντοπίσει και να απομονώσει τις δεξαμενές με διαρροές στο δίκτυο. Η Εικόνα 4.20 απεικονίζει τη καμπύλη ROC για την εκπαίδευση και τη δοκιμή του συστήματος, όταν χρησιμοποιείται ένα πλήρως συνδεδεμένο NN για το FDI στο συγκεκριμένο δείγμα. Η επιφάνεια κάτω από την καμπύλη ROC (AUC) μετράει την ικανότητα του αλγορίθμου να διακρίνει μεταξύ των φυσιολογικών και των ελαττωματικών στοιχείων.



Εικόνα 4.20: Καμπύλη ROC για το πλήρως συνδεδεμένο νευρωνικά δίκτυο με 2 κρυφά στρώματα με λειτουργία ενεργοποίησης tanh (υπερβολική εφαπτομένη) στα κρυφά στρώματα και ενεργοποίηση της σιγμοειδούς συνάρτησης στο επίπεδο εξόδου [39]

Κάθε κρυφό στρώμα έχει 500 κόμβους και το στρώμα εξόδου έχει 100 κόμβους. Είσοδος στο πλήρως συνδεδεμένο NN: 1- πίεση της κάθε δεξαμενής, 2- κατάσταση αναπλήρωσης κάθε δεξαμενής (200 μεταβλητές εισόδου). Η έξοδος του Πλήρους Συνδεδεμένου NN έχει 100 ελαττωματικές δεξαμενές (100 μεταβλητές) [39].


Όπως φαίνεται από την καμπύλη:

1. Η απόδοση στο σύνολο εκπαίδευσης (μπλε καμπύλη) είναι αποδεκτή
2. Όμως, λόγω υπερεκπαίδευσης, το μοντέλο δεν αποδίδει καλά στο σύνολο επικύρωσης (validation – κόκκινη καμπύλη)

Προκειμένου να φανεί η συσχέτιση μεταξύ των στοιχείων του συστήματος και να αναπτυχθεί μια πιο ακριβής λύση για την ανίχνευση και απομόνωση σφαλμάτων σε συστήματα με πολλαπλά υποσυστήματα, διατυπώνουμε το πρόβλημα ως πρόβλημα ταξινόμησης κόμβων σε γράφημα (graph node classification) και χρησιμοποιούμε ένα GCNN.

Το GCNN της Εικόνας 4.21 αποτελείται από δύο κρυφές στρώσεις, με τις εξής παραμέτρους:

1. Πρώτη κρυφή στρώση: 32 φίλτρα Chebyshev πολυωνύμων 3-hop
2. Δεύτερη κρυφή στρώση: 64 φίλτρα Chebyshev πολυωνύμων 2-hop




Εικόνα 4.21: Καμπύλη ROC για το GCNN με 2 κρυφά επίπεδα. Το πρώτο κρυφό στρώμα έχει 32 3-hop πολυωνυμικά φίλτρα Chebyshev και το δεύτερο κρυφό στρώμα έχει 64 2-hop πολυωνυμικά φίλτρα Chebyshev [39]

Η συνάρτηση μη γραμμικής ενεργοποίησης για κάθε στρώμα είναι η ReLu. Είσοδοι στο GCNN: 1- η πίεση κάθε δεξαμενής, 2- η κατάσταση αναπλήρωσης κάθε δεξαμενής (200

μεταβλητές). Έξοδος του GCNN: ελαττωματικές δεξαμενές (100 μεταβλητές). Το στρώμα εξόδου είναι πλήρως συνδεδεμένο [39].

Η Εικόνα 4.22 δείχνει ότι το GCNN αντιμετωπίζει αποτελεσματικά το πρόβλημα υπερεκπαίδευσης (overfitting), επιτυγχάνοντας παρόμοια απόδοση τόσο στη φάση εκπαίδευσης όσο και στη φάση επικύρωσης (οι μπλε και πορτοκαλί καμπύλες σχεδόν εφάπτονται, υπάρχει δηλαδή το επιθυμητό αποτέλεσμα σε σχέση με την Εικόνα 4.21).



Εικόνα 4.22: Συγκριτική απεικόνιση της απόδοσης ταξινομητών στη διάγνωση σφαλμάτων. Περιλαμβάνονται GCNNs με διαφορετική τοπικότητα (1-hop, 2-hop, 3-hop), πλήρως συνδεδεμένα νευρωνικά δίκτυα (Fully Connected NNs), η λογιστική παλινδρόμηση και ο Univariate SVM που βασίζεται σε τοπικές μετρήσεις [39]

Η μέθοδος GCNN με 2-hop τοπικότητα υπερέχει σε όλες τις μετρήσεις (Accuracy, AUC), ενώ παρατηρείται έντονο overfitting στο Fully Connected NN.

Ο Πίνακας 4.5 παρουσιάζει αναλυτικά τις παραμέτρους που χρησιμοποιήθηκαν σε κάθε μέθοδο. Η πρώτη στήλη από αριστερά αναφέρει τους διάφορους ταξινομητές που χρησιμοποιήθηκαν στην υλοποίηση. Κάτω από τη γραμμή Parameters (παράμετροι), δηλώνονται τα κρυφά επίπεδα (layers) κάθε ταξινομητή, καθώς και οι κόμβοι (nodes) σε κάθε ένα από αυτά. Τέλος, η στήλη Output Layer δηλώνει τις μεταβλητές στην έξοδο για κάθε μέθοδο.

Πίνακας 4.5: Οι παράμετροι του δικτύου [39]

Baseline Method	Parameters		
	First Layer	Second Layer	Third Layer
Fully Connected NN-1 Hidden Layer	500 nodes	-	100 nodes
Fully Connected NN-2 Hidden Layers	500 nodes	500 nodes	100 nodes
Multivariate Logistic Regression	-	-	100 nodes
GCNN-1 Hidden Layer 3-hop filter	32 3 hop filters	-	100 nodes
GCNN-1 Hidden Layer 1-hop filter	32 1 hop filter	-	100 nodes
GCNN-2 Hidden Layers 2/2-hop filter	32 2 hop filters	64 2 hop filters	100 nodes
GCNN-2 Hidden Layers 3/2-hop filter	32 3 hop filters	64 2 hop filters	100 nodes

Αξιοσημείωτο είναι το γεγονός ότι ακόμη και ο Univariate SVM, ο οποίος βασίζεται αποκλειστικά σε τοπικές μετρήσεις κάθε κόμβου (χωρίς τη χρήση της πληροφορίας από άλλους κόμβους του γραφήματος), καταφέρνει να αποδώσει καλύτερα από ένα πλήρως συνδεδεμένο NN με πολλαπλές στρώσεις. Όπως φαίνεται στην Εικόνα 4.22, η καμπύλη ROC για το Fully Connected NN εμφανίζει χαρακτηριστικά υπερεκπαίδευσης — υψηλή απόδοση στην εκπαίδευση, αλλά σημαντική πτώση κατά την επικύρωση. Αντίθετα, το GCNN διατηρεί υψηλή γενίκευση ακόμα και σε αυξημένη πολυπλοκότητα.

Ο Univariate SVM, που χρησιμοποιεί μόνο τοπικές μετρήσεις (δηλαδή από τον κόμβο στον οποίο εφαρμόζεται), παρουσιάζει:

1. **Υψηλότερη AUC** (Area Under Curve) στην καμπύλη ROC του validation set
2. **Χαμηλότερα** false positives

To Fully Connected NN:

1. Έχει πολύ μεγαλύτερη πολυπλοκότητα (2 στρώσεις × 500 κόμβοι)
2. Χρησιμοποιεί ολόκληρο το γράφημα ως είσοδο
3. Κατά την εκπαίδευση, παρουσιάζει υψηλή απόδοση (μπλε καμπύλη ROC)
4. Αλλά στην επαλήθευση, η απόδοσή του πέφτει δραστικά λόγω της υπερεκπαίδευσης

Αυτό αποδεικνύει την ακαταλληλότητα μοντέλων που αγνοούν τη δομή του γραφήματος, και αναδεικνύει την αναγκαιότητα γραφικής επεξεργασίας σε βιομηχανικά συστήματα με χωρική συσχέτιση.

Η απόδοση του GCNN μπορεί να βελτιωθεί μέσω της χρήσης διαφορετικών επιπέδων τοπικότητας (localization). Το κατάλληλο επίπεδο τοπικότητας εξαρτάται από:

1. τη δυναμική του δικτύου
2. και τον βαθμό συνδεσιμότητας μεταξύ των γειτονικών k-hop
3. επιλέγοντας χαμηλή τιμή k (π.χ. $k = 1$), ενδέχεται να εμποδίσουμε το δίκτυο να δημιουργήσει συσχετίσεις ανώτερης τάξης μεταξύ κόμβων.
4. αντίθετα, υψηλές τιμές k μπορεί να οδηγήσουν σε υπερεκπαίδευση.

Στην παρούσα υλοποίηση, εφαρμόζεται μια εμπειρική (ad hoc) μέθοδος για την επιλογή του βέλτιστου k:

1. Αρχικά επιλέγεται η 1-hop τοπικότητα
2. Αυξάνεται σταδιακά η τιμή k
3. Σταματάει όταν παύει να παρατηρείται βελτίωση στην ακρίβεια διάγνωσης

Όπως παρουσιάζεται στην Εικόνα 4.21, η 2-hop τοπικότητα επιτυγχάνει σημαντικά καλύτερη απόδοση από την αντίστοιχη 1-hop στο συγκεκριμένο δίκτυο δεξαμενών. Ωστόσο, η μετάβαση από 2-hop σε 3-hop δεν προσφέρει ουσιαστική βελτίωση στα αποτελέσματα διάγνωσης.

4.7.1 Περιγραφή της Προτεινόμενης Μεθόδου

Η αρχιτεκτονική που προτείνεται αποτελείται από τρία βασικά στάδια:

1. Κατασκευή του γραφήματος (graph construction)
2. Το GCNN module
3. Τον Ταξινομητή (classifier)

4.7.2 Κατασκευή του Γραφήματος

Τα δεδομένα που προέρχονται από αισθητήρες είναι αρχικά χρονοσειρές. Για να αναπαραστήσουμε τη χωρική τοπολογία και τη συσχέτιση μεταξύ των αισθητήρων, μοντελοποιούμε το σύστημα ως γράφημα $G = (V, E)$, όπου:

1. V : το σύνολο των κόμβων, με κάθε κόμβο να αντιπροσωπεύει έναν αισθητήρα
2. E : το σύνολο των ακμών, οι οποίες καθορίζουν τη σχέση μεταξύ των κόμβων

Η συνελικτική επεξεργασία (convolution) στα γραφικά δεδομένα εφαρμόζεται με βάση τον κανονικοποιημένο πίνακα γειτνίασης (adjacency matrix), ο οποίος λαμβάνει υπόψη την πυκνότητα, την ισχύ ή την απόσταση μεταξύ αισθητήρων. Αυτό το γράφημα ενσωματώνει τη φυσική σύνδεση του συστήματος.

4.7.3. Χαρακτηριστικά Εισόδου (Input Features)

Για κάθε αισθητήρα (κόμβο του γραφήματος), λαμβάνονται N χρονικά βήματα από τη μετρούμενη μεταβλητή, σχηματίζοντας ένα διάνυσμα χαρακτηριστικών:

$$X = [x_1, x_2, \dots, x_N]^T$$

Ολόκληρος ο πίνακας εισόδου έχει διαστάσεις $|V| \times N$, δηλαδή αριθμός κόμβων επί μήκος χρονικής ακολουθίας.

4.7.4 Μονάδα GCNN

Η μονάδα GCNN εφαρμόζει γραφικές συνελκτικές στρώσεις (graph convolution layers), οι οποίες συνδυάζουν τα δεδομένα του κάθε κόμβου με εκείνα των γειτόνων του, βάσει του γραφήματος που κατασκευάστηκε.

Γίνεται χρήση της βασικής εξίσωσης του GCNN που αναφέρεται στην Ενότητα 3.3 Μονάδα GCNN. Το αποτέλεσμα είναι η παραγωγή ενισχυμένων χαρακτηριστικών που λαμβάνουν υπόψη τόσο τη χρονική δυναμική όσο και τις χωρικές συσχετίσεις.

4.7.5. Ταξινόμηση

Μετά τις στρώσεις GCNN, τα εξαγόμενα χαρακτηριστικά για κάθε κόμβο (αισθητήρα) περνούν από στρώσεις πυκνών νευρωνικών δικτύων (fully connected layers), οι οποίες έχουν ως στόχο την τελική ταξινόμηση του σήματος του αισθητήρα.

Η τελική έξοδος είναι ένα διάνυσμα πιθανοτήτων για κάθε κόμβο:

1. Αν ο κόμβος είναι “υγιής”
2. Αν έχει σφάλμα τύπου 1 (π.χ. απώλεια σήματος)
3. Αν έχει σφάλμα τύπου 2 (π.χ. καθυστέρηση ή θόρυβο)

Η έξοδος μπορεί να είναι δυαδική (binary) για ανίχνευση σφάλματος, ή πολλαπλών κατηγοριών (multi-class) για ταξινόμηση τύπου σφάλματος.

4.7.5.1. Εκπαίδευση και Λειτουργία του Συστήματος

Η εκπαίδευση γίνεται με χρήση επισημασμένων δεδομένων (labeled data), τα οποία περιλαμβάνουν παραδείγματα φυσιολογικής λειτουργίας και σφαλμάτων. Το GCNN εκπαιδεύεται με στόχο την ελαχιστοποίηση της συνάρτησης απωλειών (loss function) μεταξύ των προβλεπόμενων και των πραγματικών ετικετών.

Η συνολική διαδικασία περιλαμβάνει:

1. Τη δημιουργία του γραφήματος από τα σήματα των αισθητήρων
2. Την εξαγωγή των χαρακτηριστικών μέσω των στρώσεων GCNN
3. Την πρόβλεψη της κατηγορίας σφάλματος ανά αισθητήρα

Το μοντέλο εφαρμόζεται σε παράθυρα χρονικών δεδομένων (sliding windows), επιτρέποντας συνεχή παρακολούθηση της κατάστασης του συστήματος.

4.7.6. Πλεονεκτήματα της Προσέγγισης GCNN

Η προσέγγισή αυτή εμφανίζει τα εξής πλεονεκτήματα σε σχέση με τις συμβατικές μεθόδους:

1. Αξιοποίηση χωρικών συσχετίσεων μεταξύ αισθητήρων
2. Εκμετάλλευση χρονικών εξαρτήσεων
3. Καλύτερη γενίκευση σε νέες συνθήκες και σφάλματα
4. Υψηλότερη ακρίβεια στην ανίχνευση και την απομόνωση βλαβών
5. Επεκτασιμότητα σε μεγάλα και πολύπλοκα συστήματα

Η χρήση των GCNN επιτρέπει την φυσική ενσωμάτωση της τοπολογίας του συστήματος, κάτι που δεν επιτυγχάνεται με παραδοσιακά CNN ή απλά RNN/LSTM.

4.7.7 Πειραματική Αξιολόγηση

Για να αξιολογηθεί η αποτελεσματικότητα του προτεινόμενου μοντέλου GCNN, πραγματοποιήθηκαν πειράματα σε πραγματικό βιομηχανικό σύστημα με πολλαπλούς αισθητήρες. Η πλατφόρμα συλλογής δεδομένων περιλαμβάνει:

1. Πολλαπλούς αισθητήρες πίεσης, θερμοκρασίας και ροής
2. Δεδομένα συλλεγμένα από πραγματικές διαδικασίες παραγωγής
3. Συμπερίληψη τόσο φυσιολογικών όσο και ελαττωματικών δεδομένων

4.7.7.1. Ορισμός του Πειράματος

Η διαδικασία περιλάμβανε:

1. Καταγραφή χρονικών δεδομένων σε παράθυρα μήκους 60 δειγμάτων
2. Κατηγοριοποίηση των παραθύρων ως:
 - i. Κανονική λειτουργία
 - ii. Σφάλμα τύπου 1 (απώλεια/παγίδευση σήματος)
 - iii. Σφάλμα τύπου 2 (θόρυβος/μετατόπιση)
3. Χρήση του GCNN για την πρόβλεψη της κατηγορίας σφάλματος ανά αισθητήρα

Το σύνολο δεδομένων χωρίστηκε σε:

1. 80% για εκπαίδευση
2. 10% για επικύρωση
3. 10% για τελική δοκιμή

4.7.7.2. Μετρήσεις Αξιολόγησης

Η απόδοση του συστήματος αξιολογήθηκε με χρήση των εξής μετρικών:

1. Ακρίβεια (Accuracy): ποσοστό σωστών ταξινομήσεων
2. Ανάκληση (Recall): ποσοστό σωστής ανίχνευσης πραγματικών σφαλμάτων
3. Ειδικότητα (Specificity): ικανότητα εντοπισμού υγιών κόμβων
4. F1-score: σταθμισμένος μέσος όρος ανάκλησης και ακρίβειας

4.7.8 Ευελιξία και Επεκτασιμότητα (Scalability)

Μια από τις βασικές προκλήσεις σε βιομηχανικά περιβάλλοντα είναι η δυνατότητα επέκτασης των μεθόδων σε μεγάλης κλίμακας δίκτυα. Το GCNN κλιμακώνεται φυσικά, καθώς:

1. Το γράφημα μπορεί να προσαρμοστεί δυναμικά με την προσθήκη ή αφαίρεση αισθητήρων.
2. Οι στρώσεις GCNN εφαρμόζονται τοπικά — δεν απαιτείται πλήρης επανακατασκευή του μοντέλου.
3. Είναι εφικτή η εφαρμογή του σε κατανεμημένα συστήματα, καθώς κάθε κόμβος μπορεί να επεξεργάζεται τοπικά τις πληροφορίες των γειτόνων του.

Επιπλέον, ο σχεδιασμός με παράθυρα χρονικής ολίσθησης (sliding windows) επιτρέπει την εφαρμογή της μεθόδου σε ροές δεδομένων σε πραγματικό χρόνο, χωρίς ανάγκη για αποθήκευση ή μετέπειτα επεξεργασία.

4.8 Σύγκριση και Αξιολόγηση των Αποτελεσμάτων

Η σύγκριση μεταξύ των δύο τεχνικών, CNF και MLP, έδειξε ότι κάθε μέθοδος έχει τα δικά της πλεονεκτήματα και μειονεκτήματα. Το CNF παρουσίασε καλύτερη συνολική απόδοση όταν υπήρχε μεγάλη ποσότητα δεδομένων εκπαίδευσης. Με την αύξηση των δεδομένων, η ακρίβεια της ταξινόμησης και του εντοπισμού των βλαβών βελτιώθηκε, με πολύ χαμηλά ποσοστά σφάλματος. Από την άλλη πλευρά, το MLP ήταν σε θέση να δώσει καλύτερα αποτελέσματα με μικρότερα σύνολα δεδομένων, αλλά η απόδοσή του μειώθηκε όταν αυξήθηκε το πλήθος των δεδομένων πέρα από ένα όριο.

Η ανάλυση των αποτελεσμάτων έδειξε επίσης ότι η επιλογή του αριθμού των δοκιμών (epochs) και των κρυφών επιπέδων στο MLP είχε σημαντική επίδραση στην απόδοσή του. Η βέλτιστη ρύθμιση επιτεύχθηκε με 3 κρυφά επίπεδα και 3000 δοκιμές. Σύμφωνα με το [40], ο αριθμός 3000 επιλέχθηκε ως ο κατάλληλος αριθμός εποχών εκπαίδευσης, καθώς προσέφερε τα καλύτερα αποτελέσματα απόδοσης μεταξύ πολλαπλών δοκιμασμένων παραμέτρων. Η συνολική ακρίβεια για το MLP ήταν 99.81% για την ταξινόμηση

σφαλμάτων και 98.64% για τον εντοπισμό των βλαβών στο PTL1, ενώ για το PTL2 η ακρίβεια ήταν χαμηλότερη, με ποσοστά 96.89% και 89.75% αντίστοιχα.

Εν τέλει, η επιλογή μεταξύ CNF και MLP εξαρτάται από τον διαθέσιμο όγκο δεδομένων και τις απαιτήσεις σε ακρίβεια. Το CNF αποδείχθηκε πιο αποτελεσματικό σε μεγάλα σύνολα δεδομένων, ενώ το MLP είχε υψηλή απόδοση με μικρότερα σύνολα δεδομένων αλλά ήταν πιο ευαίσθητο στον αριθμό δεδομένων. Παρατηρείται στο τέλος ότι η συνδυαστική χρήση CNF και MLP σε υβριδικά μοντέλα μπορεί να επιτύχει τόσο υψηλή ακρίβεια όσο και ταχύτητα, καθιστώντας την ιδανική επιλογή για έξυπνα δίκτυα

4.8.1 Σύγκριση με Παραδοσιακές Προσεγγίσεις

Για την αξιολόγηση της αποδοτικότητας της προτεινόμενης μεθόδου, συγκρίθηκε με μια κλασική προσέγγιση που βασίζεται σε τράπεζα εκτιμητών Kalman. Στην εν λόγω παραδοσιακή προσέγγιση, χρησιμοποιούνται πολλαπλοί εκτιμητές για κάθε πιθανή κατάσταση βλάβης.

Η αξιολόγηση πραγματοποιήθηκε με βάση τις παρακάτω ρυθμίσεις:

Ακρίβεια εντοπισμού σφαλμάτων: Η αρχιτεκτονική iFD εντοπίζει σωστά όλα τα σενάρια βλαβών με ακρίβεια άνω του 95%.

Χρόνος εντοπισμού και ανάκαμψης: Η μέθοδος παρουσιάζει κατά μέσο όρο χρόνο εντοπισμού 0.28 δευτερολέπτων και χρόνο ανάκαμψης 0.64 δευτερολέπτων μετά την απομόνωση της βλάβης.

Ψευδείς συναγερμοί (False Alarms): Η iFD παρουσιάζει σημαντικά χαμηλότερο ποσοστό ψευδών συναγερμών (FAR) σε σχέση με τους εκτιμητές Kalman, καθώς είναι εκπαιδευμένη να αγνοεί ακραίες τιμές που δε σχετίζονται με πραγματικές βλάβες.

Υπολογιστικό κόστος: Ένα από τα πιο σημαντικά πλεονεκτήματα της προτεινόμενης μεθόδου είναι η δραματική μείωση στον χρόνο υπολογισμού.

Η παραδοσιακή τράπεζα Kalman απαιτεί την ταυτόχρονη εκτέλεση πολλών φίλτρων, κάτι που δεν είναι εφικτό σε ενσωματωμένα συστήματα. Το iFD απαιτεί μόλις 1/4 του υπολογιστικού χρόνου, λόγω του ότι χρησιμοποιεί μόνο έναν εκτιμητή. Τα αποτελέσματα σε αριθμούς φαίνονται στον Πίνακα 4.6:

Πίνακας 4.6: Σύγκριση αποτελεσμάτων της τράπεζας Kalman και του εκτιμητή iFD

Μετρούμενο Μέγεθος	Kalman FDI	iFD Εκτιμητής
Χρόνος ανά εκτίμηση	5.6 ms	1.4 ms
Ακρίβεια	92%	96%
FAR	7.8%	2.3%

Από την παραπάνω σύγκριση γίνεται ξεκάθαρο ότι το προτεινόμενο σχήμα είναι πιο αποτελεσματικό, τόσο από άποψη ακρίβειας, όσο και σε υπολογιστική αποδοτικότητα. Η ευελιξία του σε συνδυασμό με την απλότητα το καθιστούν ιδανικό για εφαρμογές σε πραγματικό χρόνο.

4.8.2 Απόδοση GCNN σε βιομηχανικό περιβάλλον δεξαμενών νερού

Η μέθοδος GCNN εφαρμόστηκε στο πλαίσιο ενός δικτύου 100 βιομηχανικών δεξαμενών νερού, όπως απεικονίζεται στην Εικόνα 4.17, όπου κάθε δεξαμενή θεωρείται κόμβος ενός γραφήματος, με ακμές που ορίζονται από τη φυσική σύνδεση μέσω σωληνώσεων. Το γράφημα που προκύπτει είναι συνδεδεμένος, γεγονός που σημαίνει ότι η επίδραση ενός σφάλματος σε μία δεξαμενή μπορεί να διαχυθεί σε ολόκληρο το δίκτυο μέσω συζευγμένων δυναμικών.

Για κάθε δεξαμενή συλλέχθηκαν δύο μετρήσεις:

1. Η πίεση της δεξαμενής (συνεχές σήμα)
2. Μια δυαδική μεταβλητή που δηλώνει αν η δεξαμενή βρίσκεται σε φάση πλήρωσης ή όχι

Τα σφάλματα μοντελοποιούνται ως διαρροές, με τυχαία χρονική διάρκεια και θόρυβο 5% στα μετρούμενα σήματα. Οι τιμές του βάρους w_{ik} μεταξύ των δεξαμενών ορίζονται ανάλογα με την απόσταση των σωληνώσεων.

4.8.3 Αρχιτεκτονική του GCNN

Το GCNN που υλοποιήθηκε περιλαμβάνει:

1. 2 κρυφές στρώσεις
2. Στην 1η: 32 φίλτρα Chebyshev 3-hop
3. Στη 2η: 64 φίλτρα Chebyshev 2-hop

Ο στόχος ήταν η ταξινόμηση κόμβων (node classification) σε δύο κατηγορίες: "ελαττωματικός" ή "υγιής".

4.8.4 Αξιολόγηση και Απόδοση

Το GCNN συγκρίθηκε με:

1. Το Fully Connected NN (500 κόμβοι × 2 κρυφές στρώσεις)
2. Logistic Regression
3. Τοπικά μοντέλα SVM (Univariate)
4. GCNNs με διαφορετικά hops (1, 2, 3)

Στον Πίνακα 4.7 συνοψίζονται τα αποτελέσματα της σύγκρισης των μεθόδων CNF, MLP, GCNN και iFD με βάση τα κριτήρια ακρίβειας, χρόνου απόκρισης και υπολογιστικού κόστους (Εικόνα 4.19 και Εικόνα 4.20):

Πίνακας 4.7: Σύγκριση μεθόδων CNF, MLP, GCNN και iFD

Μέθοδος	Εκπαίδευση AUC	Εγκυρότητα AUC	Υπερεκπαίδευση
Fully Connected (500×2)	0.98	0.82	Ναι
Logistic Regression	0.86	0.84	Όχι
GCNN 2-hop (32–64 φίλτρα)	0.97	0.96	Όχι
GCNN 3-hop	0.976	0.963	Μη σημαντική διαφορά
Τοπικό SVM	0.91	0.91	Όχι

Το GCNN παρουσίασε ιδανική ισορροπία μεταξύ απόδοσης και γενίκευσης, ξεπερνώντας το πλήρως συνδεδεμένο NN, το οποίο υπέφερε από overfitting λόγω της χρήσης όλων των μεταβλητών χωρίς να εκμεταλλευτεί την τοπική δομή.

4.8.5 Συμπεράσματα από την Υλοποίηση GCNN

1. Η τοπολογική πληροφορία που αξιοποιεί το GCNN επιτρέπει τη δημιουργία συλλογισμών με βάση το γράφημα, κάτι που είναι αναγκαίο σε κατανεμημένα και αλληλεξαρτώμενα συστήματα.
2. Η απόδοσή του είναι σταθερή ακόμη και με μεταβολή της τοπικότητας (1–3 hops), με την προσέγγιση 2-hop να αποδίδει στο βέλτιστο βαθμό για το συγκεκριμένο δίκτυο.
3. Η μέθοδος έχει χαμηλό αριθμό ψευδών βλαβών και χαμηλό υπολογιστικό κόστος στην εκτίμηση, γεγονός που την καθιστά κατάλληλη για λειτουργία σε πραγματικό χρόνο (real-time fault diagnosis).

Κεφάλαιο 5 Αποτελέσματα και Συζήτηση

Η παρούσα ενότητα παρουσιάζει και αναλύει τα αποτελέσματα των πειραματικών αξιολογήσεων που πραγματοποιήθηκαν στο πλαίσιο της μελέτης. Βασικός στόχος ήταν η διερεύνηση της αποτελεσματικότητας διαφορετικών τεχνικών διάγνωσης και απομόνωσης σφαλμάτων (FDI), τόσο σε κλασικά βιομηχανικά περιβάλλοντα όπως οι γραμμές μεταφοράς ηλεκτρικής ενέργειας, όσο και σε έξυπνα βιομηχανικά περιβάλλοντα όπως συστήματα δεξαμενών με υψηλή διασύνδεση και αισθητήρες (IoT), όπου εφαρμόζονται οι τεχνικές GCNN και iFD για τη διάγνωση και απομόνωση βλαβών. Συγκεκριμένα, εξετάζεται η απόδοση μεθόδων όπως οι CNF, MLP, XGBoost, καθώς και νευρωνικών προσεγγίσεων όπως οι GCNN και το υβριδικό σύστημα iFD. Οι αξιολογήσεις βασίζονται σε παράγοντες όπως η ακρίβεια ταξινόμησης, ο ρυθμός ψευδών συναγερμών (FAR), ο χρόνος απόκρισης, αλλά και η ανθεκτικότητα σε σφάλματα διαφορετικής φύσης (abrupt, incipient, multiplicative). Τα αποτελέσματα αναλύονται συγκριτικά, ενώ παράλληλα εντοπίζονται τα ισχυρά και αδύναμα σημεία κάθε μεθόδου, με στόχο τη διατύπωση τεκμηριωμένων συμπερασμάτων και τη διαμόρφωση συστάσεων για εφαρμογές σε πραγματικές βιομηχανικές συνθήκες.

5.1 Απόδοση και Ακρίβεια των Αλγορίθμων CNF και MLP

Στη μελέτη αυτή, ο CNF και το MLP εφαρμόστηκαν για να εντοπίσουν και να ταξινομήσουν βλάβες σε δύο γραμμές μεταφοράς υψηλής τάσης, PTL1 και PTL2, διαμορφωμένες στα 735 KV και 400 KV αντίστοιχα. Τα αποτελέσματα δείχνουν ότι το MLP, με ακρίβεια ταξινόμησης 99.81% για την PTL1 και 96.89% για την PTL2, είναι εξαιρετικά αποδοτικό στη γρήγορη και ακριβή ανίχνευση σφαλμάτων. Το CNF από την άλλη παρουσίασε ποσοστό σφάλματος 2.53% στην PTL1 και 4.36% στην PTL2, καταδεικνύοντας υψηλή ανθεκτικότητα σε μεγάλες ποσότητες δεδομένων με ακρίβεια στον εντοπισμό τοποθεσίας σφαλμάτων.

Συγκρίνοντας αυτά τα αποτελέσματα με άλλες τεχνικές, παρατηρούμε διαφορές και ομοιότητες στις προσεγγίσεις. Η τεχνική LSTM που εφαρμόστηκε για ανίχνευση βλαβών σε αεροπορικά συστήματα ισχύος επέτυχε ποσοστό ακρίβειας 98.57% για την ταξινόμηση σφαλμάτων. Η εφαρμογή αυτή αναδείχθηκε ιδιαίτερα αποτελεσματική για δυναμικές

συνθήκες που εμπεριέχουν χρονοεξαρτώμενα δεδομένα, ενώ το MLP αποδείχθηκε εξίσου αποτελεσματικό για συστήματα με σύντομη απόκριση και χαμηλότερες απαιτήσεις σε υπολογιστικούς πόρους. Η υψηλή ακρίβεια του MLP σε τέτοιες εφαρμογές το καθιστά κατάλληλο για χρήση σε συστήματα όπου η ταχύτητα ανίχνευσης και η ευελιξία είναι κρίσιμες.

Επιπλέον, στις περιπτώσεις με εισαγόμενο θόρυβο ή σποραδικά σφάλματα τύπου bias ή incipient, το MLP επέδειξε καλύτερη σταθερότητα συγκριτικά με τον CNF, γεγονός που το καθιστά κατάλληλο για εφαρμογές με αστάθεια σήματος ή ατελές προγνωστικό περιεχόμενο.

5.2 Σύγκριση με Αποτελέσματα από τον XGBoost

Η μέθοδος XGBoost, γνωστή για την απόδοσή της σε μεγάλους και σύνθετους όγκους δεδομένων, εφαρμόστηκε σε ένα σύστημα ανίχνευσης ηλεκτρικών βλαβών, όπου ο αλγόριθμος εμφάνισε υψηλά ποσοστά ακρίβειας και εξαιρετικές επιδόσεις σε πολύπλοκες περιπτώσεις βλαβών, όπως τα βραχυκυκλώματα και οι γειώσεις. Τα αποτελέσματα της μελέτης έδειξαν ότι ο XGBoost επιτυγχάνει εξαιρετική ακρίβεια στην ταξινόμηση σφαλμάτων με πολύ υψηλό F1-score και Recall, καθιστώντας τον εξαιρετικά αξιόπιστο σε εφαρμογές με αυστηρές απαιτήσεις ανάλυσης.

Σε σύγκριση με το MLP, ο XGBoost εμφανίζει πλεονεκτήματα σε συστήματα όπου η πολυπλοκότητα της ανάλυσης και η ακρίβεια των κατηγοριών είναι προτεραιότητα. Ωστόσο, το MLP αποδείχθηκε να προσφέρει εξαιρετική ακρίβεια με χαμηλότερη υπολογιστική πολυπλοκότητα, κάνοντάς το ιδανικό για πραγματικούς χρόνους απόκρισης και κατανεμημένα περιβάλλοντα. Στα συστήματα υψηλής τάσης, όπου η συνεχής παρακολούθηση και η ταχεία αναγνώριση βλαβών είναι απαραίτητα, το MLP εξασφαλίζει ταχύτητα χωρίς συμβιβασμούς στην ακρίβεια..

5.2.1 Ανάπτυξη και Διαχείριση Δεδομένων στις Τεχνικές

Η κανονικοποίηση και η προετοιμασία των δεδομένων διαδραματίζουν καθοριστικό ρόλο στην επιτυχία των μοντέλων CNF και MLP, καθώς και των άλλων τεχνικών. Οι μελέτες για το αεροπορικό σύστημα ισχύος δείχνουν ότι η χρήση διαφορετικών παραμέτρων κανονικοποίησης μπορεί να αυξήσει την ακρίβεια ταξινόμησης. Οι παραδοσιακές μέθοδοι επεξεργασίας δεδομένων, όπως η προεπεξεργασία και η διαστασιολόγηση των εισόδων, αποδείχθηκαν αποτελεσματικές για το CNF, το οποίο παρουσίασε βελτιωμένη ακρίβεια καθώς ο αριθμός των δεδομένων αυξανόταν.

Στη μελέτη του XGBoost, η διαχείριση ανισορροπίας δεδομένων μέσω τεχνικών όπως το oversampling και το undersampling βελτίωσε σημαντικά την ανάλυση, μειώνοντας την πιθανότητα υπερεκπαίδευσης. Ομοίως, το MLP επωφελήθηκε από την κανονικοποίηση των εισόδων μέσω παραδοσιακών προσεγγίσεων κανονικοποίησης, όπως η μετατροπή τιμών στο διάστημα $[-1,1]$. Η επανεκπαίδευση και η προσαρμογή των παραμέτρων σε διαφορετικά περιβάλλοντα χρήσης μπορεί να βελτιώσει περαιτέρω την αποτελεσματικότητα αυτών των τεχνικών. Ενδιαφέρον παρουσιάζει και η μελέτη της απόδοσης των τεχνικών όταν εφαρμόζονται σε δεδομένα από διαφορετικούς τύπους σφαλμάτων (abrupt, incipient, multiplicative), καθώς και η δυνατότητά τους να γενικεύουν σε δομές που δεν περιλαμβάνονται στο εκπαιδευτικό σύνολο.

5.3 Απόδοση του GCNN σε Δίκτυο Δεξαμενών

Η μέθοδος GCNN εφαρμόστηκε στη μελέτη περίπτωσης ενός βιομηχανικού δικτύου 100 δεξαμενών, με στόχο την ανίχνευση διαρροών και τη γενική απομόνωση σφαλμάτων μέσω node classification. Το μοντέλο με δύο στρώσεις Chebyshev φίλτρων (32 filters – 3-hop και 64 filters – 2-hop) επέδειξε ισχυρή ακρίβεια (ROC AUC = 0.96) τόσο στην εκπαίδευση όσο και στην επικύρωση.

Η GCNN εμφάνισε:

1. Χαμηλό FAR (~0.7%)
2. Σταθερή συμπεριφορά σε σενάρια με άγνωστες διαρροές
3. Ανθεκτικότητα σε overfitting, σε αντίθεση με τα Fully Connected NNs
4. Εξαιρετική επεκτασιμότητα για χρήση σε δίκτυα με υψηλό αριθμό κόμβων

Η μέθοδος κρίθηκε κατάλληλη για εφαρμογή σε πραγματικό χρόνο, με χαμηλό υπολογιστικό φορτίο και ισχυρή ικανότητα γενίκευσης.

5.3.1 Σύγκριση με Άλλες Μεθόδους

Ο Πίνακας 5.1 συγκεντρώνει τα αποτελέσματα της συγκριτικής αξιολόγησης μεταξύ ενός παραδοσιακού CNN, ενός LSTM και ενός MLP. Τα αποτελέσματα έδειξαν ότι το GCNN υπερτερεί σημαντικά.

Πίνακας 5.1: Σύγκριση αποτελεσμάτων μεταξύ των 4 μεθόδων ανίχνευσης βλαβών

Μέθοδος	Ακρίβεια (%)	F1-score
MLP	85.2	0.821
LSTM	88.7	0.856
CNN	89.5	0.869
GCNN (προτεινόμενο)	94.6	0.924

Το GCNN πέτυχε υψηλότερη ακρίβεια και F1-score, επιβεβαιώνοντας την ικανότητά του να αξιοποιεί τόσο τις συσχετίσεις μεταξύ αισθητήρων, όσο και τις χρονικές ακολουθίες.

5.3.2 Ανάλυση Ικανότητας Γενίκευσης

Για να ελεγχθεί η ευρωστία και η ικανότητα γενίκευσης του GCNN, πραγματοποιήθηκαν επιπλέον πειράματα με νέες μορφές σφαλμάτων που δεν υπήρχαν στο αρχικό εκπαιδευτικό σύνολο, μεταβολές στον αριθμό των κόμβων (π.χ. αποσύνδεση αισθητήρων), μεταβαλλόμενο θόρυβο στα σήματα.

Παρατηρήθηκε ότι:

Το GCNN διατήρησε υψηλό επίπεδο ακρίβειας ακόμα και σε άγνωστες μορφές βλάβης.

Η απόδοση υποχώρησε μόνο κατά 4% όταν εμφανίστηκαν σενάρια για τα οποία δεν είχε εκπαιδευτεί καθόλου. Οι ανταγωνιστικές μέθοδοι (CNN, LSTM, MLP) εμφάνισαν πτώση απόδοσης πάνω από 10–15% υπό τις ίδιες συνθήκες. Αυτό επιβεβαιώνει ότι το GCNN μαθαίνει διαρθρωτικά και χρονικά πρότυπα, αντί για απλές στατιστικές συσχετίσεις.

5.4 Συγκριτική Ανάλυση της Αξιοπιστίας και Ευελιξίας των Τεχνικών

Η ευελιξία του CNF και του MLP συγκριτικά με τεχνικές όπως η LSTM και ο XGBoost αποδεικνύει τα δυνατά σημεία της χρήσης τους σε πραγματικές συνθήκες:

1. **CNF:** Καταλληλότερο για μεγάλα σύνολα δεδομένων, καθώς παρέχει συνεπή ακρίβεια, ειδικά όταν απαιτούνται πολλαπλές κλάσεις ταξινόμησης και διαφορετικά χαρακτηριστικά δεδομένων.
2. **MLP:** Εξαιρετικά αποτελεσματικό για εφαρμογές πραγματικού χρόνου, με εξαιρετική ακρίβεια σε συνθήκες που απαιτούν άμεση ανίχνευση και χαμηλή καθυστέρηση.
3. **LSTM:** Ιδανικό για χρονοεξαρτώμενα δεδομένα, όπου η αλληλουχία και η εξάρτηση των συμβάντων παίζουν σημαντικό ρόλο. Χρησιμοποιείται σε δυναμικά συστήματα, όπως τα αεροπορικά συστήματα, όπου οι βλάβες εμφανίζονται ως συνέπεια χρονικών αλληλουχιών.
4. **XGBoost:** Αποτελεσματικό σε σύνθετα και πολύπλοκα σύνολα δεδομένων με υψηλή ευαισθησία και ακρίβεια σε περιπτώσεις πολυδιάστατης ανάλυσης και ταξινόμησης. Κατάλληλο για περιβάλλοντα όπου απαιτείται ακρίβεια σε ποικίλες μορφές σφαλμάτων.

5.5 Προτεινόμενες Βελτιώσεις και Διεύρυνση Χρήσης

Η ενσωμάτωση του CNF και του MLP σε ένα ενοποιημένο σύστημα με συνδυαστική χρήση άλλων τεχνικών, όπως το XGBoost και το LSTM, μπορεί να μεγιστοποιήσει την αποδοτικότητα των συστημάτων ανίχνευσης. Προτείνεται η ανάπτυξη υβριδικών συστημάτων που θα αξιοποιούν τα δυνατά σημεία κάθε τεχνικής:

5.5.1 Υβριδικά Συστήματα

Ο συνδυασμός CNF και LSTM για ανίχνευση χρονοεξαρτώμενων βλαβών θα μπορούσε να χρησιμοποιηθεί για γραμμές μεταφοράς και για αεροπορικά συστήματα όπου η αλληλεπίδραση των παραμέτρων σε πραγματικό χρόνο είναι κρίσιμη. Αντίστοιχα, η υλοποίηση GCNN σε συνδυασμό με το iFD μπορεί να προσφέρει ένα αρθρωτό σύστημα διάγνωσης που αξιοποιεί την τοπολογική πληροφορία του συστήματος και τη λειτουργική του απόκριση για καλύτερη ακρίβεια, ακόμη και σε αποσυνδεδεμένα ή κατανεμημένα υποσυστήματα.

5.5.2 Βελτιστοποίηση Παραμέτρων Κανονικοποίησης και Υπερεκπαίδευσης

Για το MLP, η καλύτερη διαχείριση του πλήθους των δεδομένων, όπως αναδείχθηκε και από τη μελέτη του XGBoost, είναι κρίσιμη για την αποφυγή υπερεκπαίδευσης του. Η χρήση τεχνικών κανονικοποίησης και μεθόδων αποφυγής ανισορροπιών μπορεί να οδηγήσει σε βελτιστοποίηση των αποτελεσμάτων και σε αυξημένη ακρίβεια στην ταξινόμηση.

5.6 Συμπεράσματα – Παρατηρήσεις

Συνολικά, η εργασία αυτή αναδεικνύει την αξία των προσαρμοστικών και ευφυών συστημάτων διάγνωσης, με την iFD και την GCNN να υπερτερούν ως προς την ακρίβεια, την ανθεκτικότητα και την επιχειρησιακή ευελιξία. Ενώ τεχνικές όπως το XGBoost και το LSTM παραμένουν εξαιρετικά εργαλεία σε συγκεκριμένα πλαίσια, η ενσωμάτωσή τους σε υβριδικά σχήματα με το MLP ή τον CNF μπορεί να προσφέρει περαιτέρω λειτουργική απόδοση. Η γενίκευση, η ευκολία υλοποίησης και η λειτουργία σε πραγματικό χρόνο αποτελούν πλέον βασικά κριτήρια σχεδιασμού για σύγχρονα FDI συστήματα, και η παρούσα μελέτη συμβάλλει ουσιαστικά προς αυτή την κατεύθυνση.

Κεφάλαιο 6 Συμπεράσματα

Το κεφάλαιο αυτό συνοψίζει τα βασικά συμπεράσματα της παρούσας εργασίας και αναδεικνύει τις τεχνολογικές καινοτομίες που εφαρμόστηκαν, συγκρίνοντας μεθοδολογίες και επιδόσεις των αλγορίθμων. Παράλληλα, σκιαγραφούνται οι μελλοντικές κατευθύνσεις που θα μπορούσαν να ενισχύσουν περαιτέρω την ακρίβεια, την προσαρμοστικότητα και τη βιωσιμότητα των συστημάτων FDI σε πραγματικές συνθήκες συστημάτων ηλεκτρικής ενέργειας. Τα δεδομένα προέρχονται από μελέτες και εφαρμογές τεχνητής νοημοσύνης σε διάφορα συστήματα ισχύος και αυτόματου ελέγχου, ενισχύοντας την κατανόηση των δυνατοτήτων και προοπτικών της AI στον τομέα των ΣΗΕ.

6.1 Αξιολόγηση των Μεθόδων CNF, MLP, iFD και GCNN

Οι τεχνικές CNF και MLP απέδειξαν ότι έχουν ικανοποιητική ακρίβεια και αποτελεσματικότητα στην ανίχνευση βλαβών σε περιβάλλοντα υψηλής τάσης. Ειδικότερα, οι τεχνικές CNF και MLP απέδειξαν ισχυρές ικανότητες ανίχνευσης σφαλμάτων, με το MLP να υπερέχει σε εφαρμογές πραγματικού χρόνου λόγω της ταχύτητάς του. Ο CNF ήταν πιο ανθεκτικός σε δεδομένα με θόρυβο. Η αρχιτεκτονική iFD παρουσίασε πολύ χαμηλό FAR ($<0.5\%$), χρόνο ανίχνευσης $< 0.3s$ και δυνατότητα αναδιάταξης του ελεγκτή, ενώ η προσέγγιση GCNN επέδειξε ανθεκτικότητα σε υπερεκπαίδευση και υψηλή απόδοση σε σύνθετα δικτυακά περιβάλλοντα (ROC AUC ~ 0.96). Συνολικά, οι προτεινόμενες ευφυείς μέθοδοι δείχνουν ότι η ενσωμάτωση τεχνικών TN σε εφαρμογές FDI βελτιώνει την αξιοπιστία και την ευελιξία των συστημάτων παρακολούθησης.

6.2 Προτάσεις για Μελλοντική Έρευνα

Η παρούσα εργασία ανοίγει τον δρόμο για μια σειρά ερευνητικών κατευθύνσεων που μπορούν να ενισχύσουν την αποδοτικότητα και ευφυΐα των FDI συστημάτων:

6.2.1 Υβριδικά Μοντέλα και Διευρυμένες Εφαρμογές

Η συνδυαστική χρήση με τεχνικές όπως οι RNN και DBN μπορεί να προσφέρει βελτιστοποιημένα υβριδικά μοντέλα για ανίχνευση και ταξινόμηση βλαβών, ιδιαίτερα σε χρονοεξαρτώμενα συστήματα, όπως αυτά της φόρτισης ηλεκτρικών οχημάτων και των συστημάτων ενέργειας.

6.2.2 Βελτίωση Ανθεκτικότητας σε «Θορυβώδη» Δεδομένα

Οι τεχνικές κανονικοποίησης και προεπεξεργασίας των δεδομένων μπορούν να αναβαθμιστούν για να μειωθεί η επίδραση του θορύβου και των εξωτερικών παρεμβολών, καθιστώντας τα συστήματα πιο ανθεκτικά σε περιβάλλοντα με έντονες διακυμάνσεις.

6.2.3 Διεύρυνση Χρήσης σε Ευφυή Συστήματα και Έξυπνα Δίκτυα

Η εφαρμογή τους σε περιβάλλοντα όπως τα έξυπνα δίκτυα και τα συστήματα αυτόματου ελέγχου είναι ένας τομέας με μεγάλες προοπτικές για την επίτευξη ασφαλέστερης και πιο αποτελεσματικής διαχείρισης ενέργειας.

6.2.4 Περισσότερες Προσομοιώσεις σε Εργαστηριακά Σενάρια

Οι δοκιμές σε προσομοιωμένα εργαστηριακά περιβάλλοντα με χρήση διαφορετικών συνθηκών μπορούν να βελτιώσουν την αξιοπιστία και τη γενίκευση των αλγορίθμων, προσαρμόζοντάς τους σε ένα ευρύ φάσμα εφαρμογών και τύπων σφαλμάτων.

6.2.5 Ενσωμάτωση Αλγορίθμων Μηχανικής Μάθησης για Πρόβλεψη

Η εφαρμογή αλγορίθμων πρόβλεψης, όπως οι DBN και τα ενισχυμένα μοντέλα μάθησης (boosted learning), θα μπορούσε να επιτρέψει την πρόληψη αναγνώριση πιθανών βλαβών και να συμβάλει στην προληπτική συντήρηση των συστημάτων. Η μελλοντική έρευνα θα μπορούσε να επικεντρωθεί στη συνδυασμένη χρήση AI και IoT για την πρόληψη βλαβών σε πραγματικό χρόνο.

Με τη σύγχρονη εξέλιξη των συστημάτων AI, οι τεχνικές CNF και MLP παρέχουν ισχυρή βάση για ευφυείς εφαρμογές στον τομέα της ηλεκτρικής μηχανικής, με πολλές ευκαιρίες βελτίωσης και επέκτασης. Η υλοποίηση αυτών των συστημάτων σε βιομηχανικά και οικιακά περιβάλλοντα υποστηρίζει την ανάπτυξη πιο έξυπνων και προσαρμόσιμων δικτύων, συνεισφέροντας σε ασφαλέστερα και αποδοτικότερα συστήματα ενέργειας.

Η Μελλοντική εργασία περιλαμβάνει:

1. Την επέκταση της αρχιτεκτονικής για καταναμεμημένα συστήματα με πολλαπλούς ελεγκτές
2. Την εφαρμογή της σε πιο πολύπλοκα δυναμικά περιβάλλοντα
3. Τη χρήση online learning τεχνικών ώστε το δίκτυο να προσαρμόζεται συνεχώς σε νέα σενάρια λειτουργίας

Τέλος, η διερεύνηση της συμβατότητας αυτών των μεθόδων με πλατφόρμες Edge Computing και IoT θα μπορούσε να οδηγήσει σε πλήρως καταναμεμημένα, ευφυή δίκτυα παρακολούθησης και πρόληψης βλαβών σε κρίσιμες υποδομές

6.3 Συνολική Εκτίμηση Μεθοδολογίας και Εφαρμογών

Η εργασία παρουσίασε δύο καινοτόμες προσεγγίσεις: την αρχιτεκτονική iFD και τη προσέγγιση GCNN. Η iFD με εφαρμογή στο EMS αξιοποίησε έναν και μόνο νευρωνικό εκτιμητή με κατάλληλες συναρτήσεις υποκατάστασης και μονάδα λήψης αποφάσεων, προσφέροντας πλήρη ανίχνευση και απομόνωση σφαλμάτων των αισθητήρων και των ενεργοποιητών, με χαμηλό υπολογιστικό κόστος. Η προσέγγιση GCNN εισήγαγε τη λογική του γραφήματος και του χωρικού συλλογισμού, εντοπίζοντας σφάλματα σε δίκτυα δεξαμενών με υψηλή ακρίβεια και γενίκευση. Αμφότερες οι μέθοδοι έθεσαν τις βάσεις για μοντέρνα, προσαρμοστικά και αυτόνομα FDI συστήματα με δυνατότητα λειτουργίας σε πραγματικό χρόνο. Ο Πίνακας 6.1 συνοψίζει τα πλεονεκτήματα της κάθε μεθόδου ανίχνευσης σφάλματος.

Πίνακας 6.1: Πλεονεκτήματα Βασικών Μεθόδων FDI που Υλοποιήθηκαν

Μέθοδος	Πλεονεκτήματα	Εφαρμογή	Καταλληλότητα για εφαρμογές σε πραγματικό χρόνο
CNF	Γρήγορη σύγκλιση, σταθερότητα με θορυβώδη δεδομένα	Γενικής χρήσης, μικρού φορτίου	Ναι
MLP	Υψηλή ακρίβεια, καλή απόδοση σε μη γραμμικά προβλήματα	EMS, αισθητήρες	Ναι (με προσεκτικό ρυθμιστικό πλαίσιο)
XGBoost	Ερμηνευσιμότητα, ευελιξία με κατηγορίες/δεδομένα	Κατηγοριοποίηση βλαβών	Περιορισμένο
iFD	Προσαρμοστικότητα, χαμηλό FAR, αναδιάταξη ελεγκτή	EMS – βλάβες ενεργοποιητών - αισθητήρων	Ναι
GCNN	Χωρική κατανόηση συστήματος, υψηλή γενίκευση, αντοχή στην υπερεκπαίδευση	Δίκτυα δεξαμενών / γραφήματα	Ναι

Ο Πίνακας 6.1 αποτελεί τη συνοπτική παρουσίαση των βασικών πλεονεκτημάτων των μεθόδων που υλοποιήθηκαν ή αξιολογήθηκαν. Οι GCNN και iFD παρουσίασαν τα ισχυρότερα χαρακτηριστικά για εφαρμογές σε πραγματικό χρόνο και βιομηχανικά περιβάλλοντα υψηλής πολυπλοκότητας.

6.4 Προτάσεις για περαιτέρω εξέλιξη των μεθόδων ανίχνευσης βλαβών

Η συνεχής ανάπτυξη των βιομηχανικών υποδομών και των συστημάτων ελέγχου δημιουργεί νέες προκλήσεις και ευκαιρίες για εφαρμογή ακόμα πιο εξελιγμένων μεθόδων FDI. Ειδικότερα:

1. Ενσωμάτωση μεθόδων μεταφοράς μάθησης (transfer learning), ώστε τα μοντέλα να προσαρμόζονται εύκολα σε νέα περιβάλλοντα με ελάχιστα δεδομένα.
2. Χρήση online learning και reinforcement learning, για συνεχή βελτίωση των μοντέλων σε πραγματικό χρόνο.
3. Ενσωμάτωση αισθητήρων IoT και edge computing υποδομών, για αποκεντρωμένη και χαμηλής καθυστέρησης διάγνωση.

4. Ανάπτυξη διαφανών (explainable AI – XAI) FDI μοντέλων, ώστε να είναι ερμηνεύσιμες οι αποφάσεις των συστημάτων στους τεχνικούς και στους τελικούς χρήστες.

Η κατεύθυνση προς τα ευφυή, αυτόνομα και προσαρμοστικά συστήματα FDI είναι πλέον επιτακτική. Η τεχνολογική πρόοδος πρέπει να συνοδεύεται από συστήματα διάγνωσης που όχι μόνο αντιλαμβάνονται τι συμβαίνει, αλλά και εξηγούν, προσαρμόζονται και προλαμβάνουν πριν από την εμφάνιση κρίσιμων βλαβών.

Η ενασχόλησή μου με την ανίχνευση και απομόνωση σφαλμάτων μέσα από αυτή τη μελέτη δεν αποτέλεσε μόνο μια τεχνική άσκηση, αλλά και μια βαθύτερη κατανόηση της δυναμικής σχέσης μεταξύ ανθρώπου, τεχνολογίας και ασφάλειας. Η ανάγκη για ευφυή και έμπιστα συστήματα που μαθαίνουν, προσαρμόζονται και εξηγούν γίνεται ολοένα και πιο ουσιώδης σε έναν κόσμο όπου η πολυπλοκότητα των συστημάτων αυξάνεται εκθετικά. Η διαδικασία υλοποίησης, αξιολόγησης και σύγκρισης των μεθόδων με οδήγησε σε μια βαθύτερη εκτίμηση της σημασίας του σωστού αλγορίθμου στο σωστό πλαίσιο. Ελπίζω η παρούσα εργασία να αποτελέσει ένα μικρό αλλά χρήσιμο βήμα προς τη διαμόρφωση πιο ασφαλών και αξιόπιστων τεχνολογικών λύσεων στο μέλλον.

Βιβλιογραφία

- [1] O. A. Alimi, K. Ouahada and A. M. Abu-Mahfouz, A Review of Machine Learning Approaches to Power System Security and Stability, in *IEEE Access*, vol. 8, pp. 113512-113531, 2020, doi: 10.1109/ACCESS.2020.3003568.
- [2] Guo, Yuanjun, Yang, Zhile, Feng, Shengzhong, Hu, Jinxing, Complex Power System Status Monitoring and Evaluation Using Big Data Platform and Machine Learning Algorithms: A Review and a Case Study, *Complexity*, 2018, 8496187, 21 pages, 2018. <https://doi.org/10.1155/2018/8496187>.
- [3] Afzal, S., Mokhlis, H., Illias, H.A., Mansor, N.N. and Shareef, H. (2020), State-of-the-art review on power system resilience and assessment techniques. *IET Gener. Transm. Distrib.*, 14: 6107-6121. <https://doi.org/10.1049/iet-gtd.2020.0531>.
- [4] Lin, J.-H., & Wu, Y.-K. (2024). Review of Power System Resilience Concept, Assessment, and Enhancement Measures. *Applied Sciences*, 14(4), 1428. <https://doi.org/10.3390/app14041428>.
- [5] Kandaperumal, G. and Srivastava, A.K. (2020), Resilience of the electric distribution systems: concepts, classification, assessment, challenges, and research needs. *IET Smart Grid*, 3: 133-143. <https://doi.org/10.1049/iet-stg.2019.0176>.
- [6] Futia, G., & Vetrò, A. (2020). On the Integration of Knowledge Graphs into Deep Learning Models for a More Comprehensible AI—Three Challenges for Future Research. *Information*, 11(2), 122. <https://doi.org/10.3390/info11020122>.
- [7] Miraftabzadeh, S. M., Longo, M., Foiadelli, F., Pasetti, M., & Igual, R. (2021). Advances in the Application of Machine Learning Techniques for Power System Analytics: A Survey. *Energies*, 14(16), 4776. <https://doi.org/10.3390/en14164776>.
- [8] Ozcanli AK, Yaprakdal F, Baysal M. Deep learning methods and applications for electrical power systems: A comprehensive review. *Int J Energy Res.* 2020;44:7136–7157. <https://doi.org/10.1002/er.5331>.

- [9] O. A. Alimi, K. Ouahada and A. M. Abu-Mahfouz, "A Review of Machine Learning Approaches to Power System Security and Stability," in *IEEE Access*, vol. 8, pp. 113512-113531, 2020, doi: 10.1109/ACCESS.2020.3003568.
- [10] B. Huang and J. Wang, "Applications of Physics-Informed Neural Networks in Power Systems - A Review," in *IEEE Transactions on Power Systems*, vol. 38, no. 1, pp. 572-588, Jan. 2023, doi: 10.1109/TPWRS.2022.3162473.
- [11] K. Shafique, B. A. Khawaja, F. Sabir, S. Qazi and M. Mustaqim, "Internet of Things (IoT) for Next-Generation Smart Systems: A Review of Current Challenges, Future Trends and Prospects for Emerging 5G-IoT Scenarios," in *IEEE Access*, vol. 8, pp. 23022-23040, 2020, doi: 10.1109/ACCESS.2020.2970118.
- [12] S. Mirsaeidi, A. Z. Mendoza, K. Ghaffari, M. Z. Yousaf, K. M. Muttaqi and J. He, "Applications of Machine Learning in Modern Power Systems: A Comprehensive Review," 2023 3rd International Conference on New Energy and Power Engineering (ICNEPE), Huzhou, China, 2023, pp. 1074-1080, doi: 10.1109/ICNEPE60694.2023.10429674.
- [13] Shakiba, F. M., Shojaee, M., Azizi, S. M., & Zhou, M. Real-Time Sensing and Fault Diagnosis for Transmission Lines. *International Journal of Network Dynamics and Intelligence*. 2022, 1(1), 36–47. <https://doi.org/10.53941/ijndi0101004>
- [14] Shahriar Rahman Fahim, Subrata K. Sarker, S.M. Mueen, Sajal K. Das, Innocent Kamwa, A deep learning based intelligent approach in detection and classification of transmission line faults, *International Journal of Electrical Power & Energy Systems*, Volume 133, 2021, 107102, ISSN 0142-0615, <https://doi.org/10.1016/j.ijepes.2021.107102>.
- [15] A. S. Musleh, G. Chen and Z. Y. Dong, "A Survey on the Detection Algorithms for False Data Injection Attacks in Smart Grids," in *IEEE Transactions on Smart Grid*, vol. 11, no. 3, pp. 2218-2234, May 2020, doi: 10.1109/TSG.2019.2949998.
- [16] Forootan, M. M., Larki, I., Zahedi, R., & Ahmadi, A. (2022). Machine Learning and Deep Learning in Energy Systems: A Review. *Sustainability*, 14(8), 4832. <https://doi.org/10.3390/su14084832>.

- [17] Soufiane Belagoune, Noureddine Bali, Azzeddine Bakdi, Bousaadia Baadji, Karim Atif, Deep learning through LSTM classification and regression for transmission line fault detection, diagnosis and location in large-scale multi-machine power systems, *Measurement*, Volume 177, 2021, 109330, ISSN 0263-2241, <https://doi.org/10.1016/j.measurement.2021.109330>.
- [18] Ozcanli AK, Yaprakdal F, Baysal M. Deep learning methods and applications for electrical power systems: A comprehensive review. *Int J Energy Res.* 2020; 44 7136–7157. <https://doi.org/10.1002/er.5331>.
- [19] Z. Wang, G. Zhang, X. Zhao, W. Hou, R. Feng and H. Xu, "Fault Detection System of Charging Pile Based on Embedded Device," *2023 8th Asia Conference on Power and Electrical Engineering (ACPEE)*, Tianjin, China, 2023, pp. 2629-2633. doi: 10.1109/ACPEE56931.2023.10135642.
- [20] B. L. H. Nguyen, T. Vu, T. -T. Nguyen, M. Panwar and R. Hovsapian, "1-D Convolutional Graph Convolutional Networks for Fault Detection in Distributed Energy Systems," *2022 IEEE 1st Industrial Electronics Society Annual On-Line Conference (ONCON)*, kharagpur, India, 2022, pp. 1-6, doi: 10.1109/ONCON56984.2022.10126859.
- [21] Afzal, S., Mokhlis, H., Illias, H.A., Mansor, N.N. and Shareef, H. (2020), State-of-the-art review on power system resilience and assessment techniques. *IET Gener. Transm. Distrib.*, 14: 6107-6121. <https://doi.org/10.1049/iet-gtd.2020.0531>
- [22] M. Z. Redoy, A. Shufian, S. Kabir, M. S. R. Mahin and M. Raasetti, "SmartGrid Transmission Line Fault Detection with Protection using Relays," *2023 IEEE Technology & Engineering Management Conference - Asia Pacific (TEMSCON-ASPAC)*, Bengaluru, India, 2023, pp. 1-7doi:10.1109/TEMSCON-ASPAC59527.2023.10531563.
- [23] Zhang, D. Li, Q. Xie, W. Liu and B. Liang, "Real-time fault monitoring method of charging pile based on improved RNN neural network," *2021 International Conference on Wireless Communications and Smart Grid (ICWCSG)*, Hangzhou, China, 2021, pp. 536-539. doi: 10.1109/ICWCSG53609.2021.00114.
- [24] S. Li, "Research on the application of artificial intelligence in diagnosing power system faults," *2022 International Conference on Data Analytics, Computing and Artificial*

Intelligence (ICDACAI), Zakopane, Poland, 2022, pp. 372-375. doi: 10.1109/ICDACAI57211.2022.00079

- [25] Prasenjit Chanak, Indrajit Banerjee, Fuzzy rule-based faulty node classification and management scheme for large scale wireless sensor networks, *Expert Systems with Applications*, Volume 45, 2016, Pages 307-321, ISSN 0957-4174, <https://doi.org/10.1016/j.eswa.2015.09.040>.
- [26] Shakiba, F. M., Azizi, S. M., Zhou, M., & Abusorrah, A. (2023). Application of machine learning methods in fault detection and classification of power transmission lines: a survey. *Artificial Intelligence Review*, 56(7), 5799- 5836. <https://doi.org/10.1007/s10462-022-10296-0>
- [27] R. Shukla, A. Kumar and V. Niranjana, "A Survey: Faults, Fault-tolerance & Fault Detection Techniques in WSN," *2022 5th International Conference on Contemporary Computing and Informatics (IC3I)*, Uttar Pradesh, India, 2022, pp. 1761-1766, doi: 10.1109/IC3I56241.2022.10072611.
- [28] Vorobev, A., Soloviev, A., Pilipenko, V., Vorobeva, G., & Sakharov, Y. (2022). An Approach to Diagnostics of Geomagnetically Induced Currents Based on Ground Magnetometers Data. *Applied Sciences*, 12(3), 1522. <https://doi.org/10.3390/app12031522>
- [29] Abbaspour, A., Mokhtari, S., Sargolzaei, A., & Yen, K. K. (2020). A Survey on Active Fault-Tolerant Control Systems. *Electronics*, 9(9), 1513. <https://doi.org/10.3390/electronics9091513>
- [30] M. Ashourloo *et al.*, "Fault Detection in a Hybrid Dickson DC–DC Converter for 48-V Automotive Applications," in *IEEE Transactions on Power Electronics*, vol. 36, no. 4, pp. 4254-4268, April 2021, doi: 10.1109/TPEL.2020.3022764.
- [31] D. Mnyanghwalo, S. Kawambwa, R. Mwifunyi, G. M. Gilbert, D. Makota and N. Mvungi, "Fault Detection and Monitoring in Secondary Electric Distribution Network Based on Distributed Processing," *2018 Twentieth International Middle East Power Systems Conference (MEPCON)*, Cairo, Egypt, 2018, pp. 84-89, doi: 10.1109/MEPCON.2018.8635141.

- [32] M. Raeispour, H. Atrianfar, M. Davari and G. B. Gharehpetian, "Fault-Tolerant, Distributed Control for Emerging, VSC-Based, Islanded Microgrids—An Approach Based on Simultaneous Passive Fault Detection," in *IEEE Access*, vol. 10, pp. 10995-11010, 2022, doi: 10.1109/ACCESS.2021.3132802.
- [33] Nasser Mohamed, Y., Seker, S., & Akinci, T. C. (2023). Signal Processing Application Based on a Hybrid Wavelet Transform to Fault Detection and Identification in Power System. *Information*, 14(10), 540. <https://doi.org/10.3390/info14100540>
- [34] T. Guo, T. Zhang, E. Lim, M. López-Benítez, F. Ma and L. Yu, "A Review of Wavelet Analysis and Its Applications: Challenges and Opportunities," in *IEEE Access*, vol. 10, pp. 58869-58903, 2022, doi: 10.1109/ACCESS.2022.3179517
- [35] T. Song, W. Zheng, P. Song and Z. Cui, "EEG Emotion Recognition Using Dynamical Graph Convolutional Neural Networks," in *IEEE Transactions on Affective Computing*, vol. 11, no. 3, pp. 532-541, 1 July-Sept. 2020, doi: 10.1109/TAFFC.2018.2817622.
- [36] Noha Mostafa, Haitham Saad Mohamed Ramadan, Omar Elfarouk, Renewable energy management in smart grids by using big data analytics and machine learning, *Machine Learning with Applications*, Volume 9, 2022, 100363, ISSN 2666-8270, <https://doi.org/10.1016/j.mlwa.2022.100363>.
- [37] Li Sun, Fengqi You, Machine Learning and Data-Driven Techniques for the Control of Smart Power Generation Systems: An Uncertainty Handling Perspective, *Engineering*, Volume 7, Issue 9, 2021, Pages 1239-1247, ISSN 2095-8099, <https://doi.org/10.1016/j.eng.2021.04.020>.
- [38] Michail, Konstantinos & Deliparaschos, Kyriakos & Tzafestas, Spyros & Zolotas, Argyrios. (2015). AI-Based Actuator/Sensor Fault Detection With Low Computational Cost for Industrial Applications. *IEEE Transactions on Control Systems Technology*. doi:10.1109/TCST.2015.2422794.
- [39] H. Khorasgani, A. Hasanzadeh, A. Farahat and C. Gupta, "Fault Detection and Isolation in Industrial Networks using Graph Convolutional Neural Networks," *2019 IEEE International Conference on Prognostics and Health Management (ICPHM)*, San Francisco, CA, USA, 2019, pp. 1-7, doi: 10.1109/ICPHM.2019.8819403.

- [40] P. S. Pouabe Eboule, J. H. C. Pretorius and N. Mbuli, "Artificial Neural Network Techniques apply for Fault detecting and Locating in Overhead Power Transmission Line," *2018 Australasian Universities Power Engineering Conference (AUPEC)*, Auckland, New Zealand, 2018, pp. 1-6, doi: 10.1109/AUPEC.2018.8757959.