



Εθνικό Μετσόβιο Πολυτεχνείο
Σχολή Ηλεκτρολόγων Μηχανικών
και Μηχανικών Υπολογιστών
Τομέας Τεχνολογίας Πληροφορικής και Υπολογιστών

**Εντοπισμός διαταραχών σε Πυρηνικούς Αντιδραστήρες στο
πεδίο του χρόνου με Αυτο-Επιβλεπόμενη Μηχανική
Μάθηση και Προσαρμογή Πεδίου**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΠΑΠΑΟΙΚΟΝΟΜΟΥ ΑΝΤΩΝΙΟΣ

Επιβλέπων : Στέφανος Κόλλιας
Καθηγητής Ε.Μ.Π.

Συνεπιβλέπων : Γεώργιος Αλεξανδρίδης
Ε.ΔΙ.Π. Ε.Μ.Π.

Αθήνα, Μάρτιος 2022



Εθνικό Μετσόβιο Πολυτεχνείο
Σχολή Ηλεκτρολόγων Μηχανικών
και Μηχανικών Υπολογιστών
Τομέας Τεχνολογίας Πληροφορικής και Υπολογιστών

**Εντοπισμός διαταραχών σε Πυρηνικούς Αντιδραστήρες στο
πεδίο του χρόνου με Αυτο-Επιβλεπόμενη Μηχανική
Μάθηση και Προσαρμογή Πεδίου**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΠΑΠΑΘΙΚΟΝΟΜΟΥ ΑΝΤΩΝΙΟΣ

Επιβλέπων : Στέφανος Κόλλιας
Καθηγητής Ε.Μ.Π.

Συνεπιβλέπων : Γεώργιος Αλεξανδρίδης
Ε.Δι.Π. Ε.Μ.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 1η Μαρτίου 2022.

.....
Στέφανος Κόλλιας
Καθηγητής Ε.Μ.Π.

.....
Ανδρέας Γεώργιος Σταφυλοπάτης
Καθηγητής Ε.Μ.Π.

.....
Γιώργος Στάμου
Καθηγητής Ε.Μ.Π.

Αθήνα, Μάρτιος 2022

.....
Παπαϊκονόμου Αντώνιος

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

Copyright © Παπαϊκονόμου Αντώνιος, 2022.
Με επιφύλαξη παντός δικαιώματος. All rights reserved.

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

Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον συγγραφέα και δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις επίσημες θέσεις του Εθνικού Μετσόβιου Πολυτεχνείου.

Περίληψη

Η παρούσα διπλωματική εργασία έρχεται να συμπληρώσει την ήδη υπάρχουσα έρευνα που γίνεται γύρω από την εποπτεία της λειτουργίας των πυρηνικών αντιδραστήρων και του εντοπισμού της πηγής των διαταραχών κατά την λειτουργία αυτών μέσω διαγνωστικών σφάλματος από τα σήματα νετρονικού θορύβου κάνοντας χρήση τεχνικών της Μηχανικής Μάθησης. Απώτερος σκοπός προκειμένου να γίνει ο εντοπισμός των διαταραχών αυτών είναι η εύρεση της αντίστροφης συνάρτησης μεταφοράς του αντιδραστήρα. Καθώς όμως το πλήθος των αισθητήρων που έχουμε διαθέσιμους σε κάθε αντιδραστήρα είναι περιορισμένο και σημαντικά μικρότερο από το πλήθος των πιθανών θέσεων εντοπισμού των διαταραχών, η συγκεκριμένη αναστροφή δεν είναι τετριμμένη πράγμα που καθιστά επιτακτική την χρήση της Μηχανικής Μάθησης. Το παραπάνω επιτυγχάνεται με χρήση Μονοδιάστατων καθώς και Δισδιάστατων Βαθιών Συνελκτικών Δικτύων (1D-CNNs, 2D-CNNs) μέσω εκπαίδευσης σε συνθετικά σήματα αισθητήρων απευθείας στο πεδίο του χρόνου, μειώνοντας σημαντικά την υπολογιστική πολυπλοκότητα. Τα συνθετικά δεδομένα αυτά έχουν παραχθεί μέσω του προσομοιωτικού προγράμματος S3K και αντιστοιχούν στο πυρηνικό εργοστάσιο Gösgen (KKG) τύπου PWR που εντοπίζεται στην Ελβετία. Τέλος, προκειμένου να γίνει εναρμόνιση των συνθετικών δεδομένων με τις αντίστοιχες πραγματικές μετρήσεις του ίδιου αντιδραστήρα παρουσιάζεται μια τεχνική Αυτο-Επιβλεπόμενης Προσαρμογής Πεδίου (SSDA) για την εκπαίδευση της προτεινόμενης αρχιτεκτονικής.

Λέξεις κλειδιά

Διαγνωστική Σφάλματος, Πυρηνικοί Αντιδραστήρες, Μοντελοποίηση Θορύβου Νετρονίων, Μη-Επεμβατικές Μέθοδοι Εποπτείας, Ανάλυση στο πεδίο του χρόνου, Συνθετικά/Πραγματικά Δεδομένα, Μηχανική Μάθηση, Βαθιά Νευρωνικά Δίκτυα, Μονοδιάστατα Συνελκτικά Δίκτυα, Επιβλεπόμενη/Αυτο-Επιβλεπόμενη Εκπαίδευση, Αυτο-Επιβλεπόμενη Μάθηση, Προσαρμογή Πεδίου

Abstract

This thesis complements the existing research on monitoring the operation of Nuclear Reactor Cores and locating the source of perturbations through fault diagnostics from neutron-noise signals using Machine Learning techniques. The ultimate goal in order to detect these perturbations is to find the Inverse transfer function of the reactor. However, as the number of sensors available in each reactor is limited and significantly smaller than the number of possible locations for the detection of perturbations, this inversion is not a trivial task, which makes the use of Machine Learning imperative. The above is achieved by using One-Dimensional as well as Two-Dimensional Deep Convolutional Neural Networks (1D-CNNs, 2D-CNNs) through training in synthetic sensor signals directly in the time domain, thus significantly reducing computational complexity. The synthetic data has been produced using the S3K simulation code and correspond to the PWR type Gösgen (KKG) Nuclear Power Plant located in Switzerland. Finally, in order to align the synthetic data with the corresponding actual measurements of the same reactor, a Self-Supervised Domain Adaptation (SSDA) technique is presented for the training of the proposed architecture.

Key words

Fault Diagnostics, Nuclear Reactors, Neutron Noise Modeling, Non-Intrusive Monitoring Methods, Time Domain Analysis, Synthetic/Real Data, Machine Learning, Deep Neural Networks, 1D-CNNs, Supervised/Self-Supervised Training, Self-Supervised Learning, Domain Adaptation

Ευχαριστίες

Θα ήθελα πρώτα από όλα να ευχαριστήσω θερμά τον επιβλέποντα καθηγητή αυτής της διπλωματικής εργασίας, κ. Σ. Κόλλια, καθηγητή Ε.Μ.Π., για την ευκαιρία να πραγματοποιήσω έρευνα στον τομέα της Μηχανικής Μάθησης, τις συμβουλές και την καθοδήγησή του, που υπήρξαν καθοριστικοί παράγοντες προς την επιτυχή ολοκλήρωσή αυτής καθώς και της μετέπειτα πορείας μου. Παράλληλα θα ήθελα να ευχαριστήσω την επιτροπή κ. Α. Γ. Σταφυλοπάτη, καθηγητή Ε.Μ.Π., και κ. Γ. Στάμου, καθηγητή Ε.Μ.Π., για τον χρόνο τους καθώς αποτελεί ιδιαίτερη τιμή για εμένα.

Ακόμα οφείλω να ευχαριστήσω το μέλος Εργαστηριακού και Διδακτικού Προσωπικού του Ε.Μ.Π., συνεργάτη και φίλο Γ. Αλεξανδρίδη για την καρποφόρα συνεργασία, την υπομονή και υποστήριξή του καθώς και τον υποψήφιο διδάκτορα στο University of Aberdeen, A. Durrant, η βοήθεια του οποίου για την επίλυση αποριών καθώς και την ολοκλήρωση της υλοποίησης υπήρξε κομβικής σημασίας.

Με την παρούσα εργασία κλείνει ο κύκλος των σπουδών μου στην ΣΗΜΜΥ. Κατά την διάρκεια αυτών των χρόνων διασταυρώθηκαν οι δρόμοι μας με πολλούς και αξιόλογους ανθρώπους αλλά θα ήθελα να ευχαριστήσω ιδιαίτερος τους: Γιάννη Π., Γιώργο Χ., Γιάννη Σ., Αλίκη Μ., Απόστολο Κ., Μαρίνο Χ. και τον Θεοδωρή Κ. χωρίς τους οποίους τίποτα δεν θα ήταν το ίδιο.

Κλείνοντας, δεν θα μπορούσα να μην αναφέρω την οικογένεια μου και ιδιαίτερα την μητέρα μου Άννα, τον πατέρα μου Δημήτρη και τον αδερφό μου Χριστόφορο για την αμέτρητη συμπαράσταση και βοήθεια σε κάθε πτυχή της ζωής μου που μου έχουν προσφέρει απλόχερα όλα αυτά τα χρόνια.

Η διπλωματική αυτή εργασία αφιερώνεται στην μνήμη της γιαγιάς μου, Νίνας.

Παπαοικονόμου Αντώνιος,

Αθήνα, 1η Μαρτίου 2022

Περιεχόμενα

Περίληψη	5
Abstract	7
Ευχαριστίες	9
Περιεχόμενα	11
Κατάλογος πινάκων	13
Κατάλογος σχημάτων	15
1. Εισαγωγή	17
1.1 Πυρηνικοί αντιδραστήρες	18
1.2 Μοντελοποίηση αντιδραστήρα και δεδομένα	18
1.2.1 Συνθετικά δεδομένα	21
1.2.2 Πραγματικά δεδομένα	21
1.2.3 Τάση σήματος / Αφαίρεση τάσης σήματος (Detrending)	22
2. Μηχανική μάθηση	23
2.1 Ορισμός και προσεγγίσεις	23
2.1.1 Επιβλεπόμενη μάθηση (Supervised learning)	23
2.1.2 Μη-Επιβλεπόμενη μάθηση (Unsupervised learning)	23
2.1.3 Ενισχυτική μάθηση (Reinforcement learning)	24
2.1.4 Ημι-επιβλεπόμενη και Αυτο-επιβλεπόμενη μάθηση (Semi-supervised and Self-supervised learning)	24
2.2 Νευρωνικά Δίκτυα	25
2.2.1 Βαθιά Νευρωνικά Δίκτυα με Εμπρόσθια Τροφοδότηση (DFNNs)	25
2.2.2 Συναρτήσεις ενεργοποίησης (Activation functions)	26
2.2.3 Συνελκτικά Νευρωνικά Δίκτυα (CNNs)	28
2.2.4 Κανονικοποίηση παρτίδας (Batch normalization)	29
2.2.5 Ομαδοποίηση (Pooling)	29
2.2.6 Dropout	29
2.3 Εκπαίδευση (Training)	31
2.3.1 Συναρτήσεις απωλειών (Loss functions)	31
2.3.2 Εμπρόσθια - Οπίσθια Διάδοση (Forward - Backward propagation)	31
2.3.3 Συναρτήσεις βελτιστοποίησης (Optimizer functions)	32
2.3.4 Μεταφορά Γνώσης (Transfer Learning)	33
2.3.5 Προσαρμογή Πεδίου (Domain Adaptation)	34

3. Υφιστάμενη έρευνα και επέκταση αυτής	35
3.1 Υφιστάμενη έρευνα	35
3.2 Αρχιτεκτονικές 1D-CNNs και 2D-CNN	37
3.2.1 1D-CNNs	37
3.2.2 2D-CNN	39
3.3 Αυτο-Επιβλεπόμενη Προσαρμογή Πεδίου (SSDA)	40
3.3.1 Βοηθητικές εργασίες (Auxiliary tasks)	40
4. Εκπαίδευση νευρωνικών δικτύων και αποτελέσματα	41
4.1 Διαδικασία εκπαίδευσης επιβλεπόμενης μάθησης	41
4.2 Αποτελέσματα επιβλεπόμενης μάθησης	44
4.3 Διαδικασία εκπαίδευσης αυτο-επιβλεπόμενης μάθησης	46
4.4 Αποτελέσματα αυτο-επιβλεπόμενης μάθησης	47
5. Συμπεράσματα και μελλοντικές κατευθύνσεις	49
5.1 Συμπεράσματα	49
5.2 Μελλοντικές κατευθύνσεις	50
Βιβλιογραφία	51
Παράρτημα	55
A. Ευρετήριο συντομογραφιών	55

Κατάλογος πινάκων

1.1	Προσομοιώσεις διαταραχών για συνθήκες λειτουργίας MOC39 και BOC40	20
4.1	Ακρίβεια εντοπισμού (εκφρασμένη σε RMSE) για διαφορετικές αρχιτεκτονικές ανα σενάριο σε MOC39	44
4.2	Ακρίβεια εντοπισμού (εκφρασμένη σε RMSE) για διαφορετικές αρχιτεκτονικές ανα σενάριο σε BOC40	44

Κατάλογος σχημάτων

1.1	Απεικόνιση λειτουργίας PWR αντιδραστήρα [1]	18
1.2	Αξονικό σχεδιάγραμμα κυψελών καυσίμου και θέσεων αισθητήρων για το μοντέλο του αντιδραστήρα Gösgen. Οι εσωτερικοί αισθητήρες παρουσιάζονται με I ενώ οι εξωτερικοί με E [2]	19
1.3	Είδη δονήσεων κυψελών καυσίμου (FAs): Cantilevered mode, C-shaped mode και S-shaped mode	20
1.4	Διαδικασία παραγωγής προσομοιώσεων από το PSI [3, 4]	21
1.5	Παράδειγμα αφαίρεσης τάσης (detrending) από τα σήματα των αισθητήρων	22
2.1	Νευρωνικό Δίκτυο με Εμπρόσθια Τροφοδότηση	25
2.2	Αρχιτεκτονική απλού Perceptron ενός επιπέδου	26
2.3	Γραφική αναπαράσταση προσέγγισης μη-γραμμικών προβλημάτων [5]	26
2.4	Αρχιτεκτονική Συνελκτικού Νευρωνικού Δικτύου (CNN) (LeNet-5) [6]	28
2.5	Παράδειγμα ομαδοποίησης με μέγιστη τιμή (Max pooling) [7]	30
2.6	Γραφική απεικόνιση σύγκλισης σε τρισδιάστατο χώρο με χρήση Gradient Descent σε μη-κυρτή συνάρτηση [8]	33
3.1	Οπτικοποίηση των δεδομένων στο πεδίο της συχνότητας με βάση προηγούμενα παραδοτέα του PSI	35
3.2	Αρχιτεκτονική 1D-CNN όπως περιγράφεται στο [9]	37
3.3	Αρχιτεκτονική 1D-CNN όπως περιγράφεται στο [10]	37
3.4	Custom αρχιτεκτονική 1D-CNN	38
3.5	Παράδειγμα παραγωγής φασματογραφημάτων από τα σήματα των αισθητήρων, για διαφορετικές κυψέλες καυσίμου (και τις αντίστοιχες συντεταγμένες τους στο επίπεδο)	39
3.6	Αρχιτεκτονική 2D-CNN όπως περιγράφεται στο [9]	39
4.1	Μετρικές εκπαίδευσης στα training και validation δεδομένα για την 1D-CNN αρχιτεκτονική (Σχήμα 3.2) στο σενάριο S1 για MOC39	41
4.2	Μετρικές εκπαίδευσης στα training και validation δεδομένα για την 1D-CNN αρχιτεκτονική (Σχήμα 3.3) στο σενάριο S1 για MOC39	42
4.3	Μετρικές εκπαίδευσης στα training και validation δεδομένα για την 2D-CNN αρχιτεκτονική (Σχήμα 3.6) στο σενάριο S3 για MOC39	42
4.4	Μετρικές εκπαίδευσης στα training και validation δεδομένα για την προτεινόμενη από αυτή την εργασία 1D-CNN αρχιτεκτονική (Σχήμα 3.4) στο σενάριο S1 για MOC39	42
4.5	Μετρικές εκπαίδευσης στα training και validation δεδομένα για την προτεινόμενη από αυτή την εργασία 1D-CNN αρχιτεκτονική (Σχήμα 3.4) στο σενάριο S3 για MOC39	43
4.6	Εκτίμηση στα συνθετικά δεδομένα με βάση το εκπαιδευμένο δίκτυο. Η δονούμενη κυψέλη καυσίμου εντοπίζεται στην θέση K06 (πράσινο χρώμα), με την εκτιμώμενη να είναι η L06 (κόκκινο χρώμα)	45
4.7	Διαδικασία εκπαίδευσης του 1D-CNN μοντέλου στα συνθετικά και πραγματικά δεδομένα και ροή πληροφοριών στο δίκτυο	46
4.8	Γραφική απεικόνιση των κανονικοποιημένων απωλειών (MSE) κατά την διάρκεια της εκπαίδευσης	47

4.9	Εκτίμηση στα πραγματικά δεδομένα με βάση το εκπαιδευμένο δίκτυο με εντοπισμό πιθανής διαταραχής στην κυψέλη καυσίμου J05	48
-----	--	----

Κεφάλαιο 1

Εισαγωγή

Η εκμετάλλευση της πυρηνικής ενέργειας μέσω πυρηνικών αντιδραστήρων έχει γίνει διαδεδομένη εδώ και αρκετά χρόνια στην Ευρώπη (δεκαετία 1960). Οι σταθμοί πυρηνικής ενέργειας παρήγαγαν περίπου το 24,6% της συνολικής ηλεκτρικής ενέργειας που παρήχθη στην Ευρωπαϊκή Ένωση το 2020, με 13 χώρες της ΕΕ να διαθέτουν λειτουργικούς πυρηνικούς αντιδραστήρες [11]. Παρά τα πολλά οφέλη, υπάρχουν και αρκετοί κίνδυνοι στην διαδικασία της παραγωγής της ενέργειας αυτής.


Η παρούσα διπλωματική εργασία έρχεται να συμπληρώσει την ήδη υπάρχουσα έρευνα που γίνεται γύρω από την εποπτεία της λειτουργίας (monitoring) των πυρηνικών αντιδραστήρων και του εντοπισμού της πηγής των διαταραχών κατά την λειτουργία τους μέσω διαγνωστικών σφάλματος (fault diagnostics) [12] από τα σήματα νετρονιακού θορύβου κάνοντας χρήση τεχνικών της Μηχανικής Μάθησης (ML) [13], με σκοπό την πρόβλεψη και αποφυγή καταστάσεων και γεγονότων όπως αυτές που αναφέρονται παρακάτω. Απώτερος σκοπός προκειμένου να γίνει ο εντοπισμός των διαταραχών αυτών είναι η εύρεση της αντίστροφης συνάρτησης μεταφοράς (Inverse Transform Function) του αντιδραστήρα. Καθώς όμως το πλήθος των αισθητήρων που έχουμε διαθέσιμους σε κάθε αντιδραστήρα είναι περιορισμένο και σημαντικά μικρότερο από το πλήθος των πιθανών θέσεων εντοπισμού των διαταραχών, η συγκεκριμένη αναστροφή δεν είναι τετριμμένη και καθιστά την εύρεση της τοποθεσίας της διαταραχής ένα δύσκολο πρόβλημα με βάση τις παραδοσιακές μεθόδους [14] πράγμα που καθιστά επιτακτική την χρήση της Μηχανικής Μάθησης. Το παραπάνω επιτυγχάνεται με χρήση Μονοδιάστατων καθώς και Δισδιάστατων Βαθιών Συνελκτικών Δικτύων (1D-CNNs, 2D-CNNs) μέσω εκπαίδευσης σε συνθετικά σήματα αισθητήρων απευθείας στο πεδίο του χρόνου, μειώνοντας σημαντικά την υπολογιστική πολυπλοκότητα. Τα συνθετικά δεδομένα αυτά έχουν παραχθεί από το Paul Scherrer Institut (PSI) και αντιστοιχούν στο πυρηνικό εργοστάσιο Gösgen (KKG) τύπου PWR που εντοπίζεται στην Ελβετία.¹

Τέλος, προκειμένου να γίνει εναρμόνιση των συνθετικών δεδομένων με τις αντίστοιχες πραγματικές μετρήσεις του ίδιου αντιδραστήρα παρουσιάζεται μια τεχνική Αυτο-Επιβλεπόμενης Προσαρμογής Πεδίου (Self-Supervised Domain Adaptation) για την εκπαίδευση της προτεινόμενης αρχιτεκτονικής.

¹ Τα δεδομένα καθώς και οι μεθοδολογίες που παρουσιάζονται σε αυτή την εργασία έχουν αναπτυχθεί στο πλαίσιο του Ευρωπαϊκού ερευνητικού προγράμματος Core monitoring techniques and experimental validation and demonstration (CORTEX, H2020) [15].

1.1 Πυρηνικοί αντιδραστήρες

Ο στόλος από πυρηνικούς αντιδραστήρες που βρίσκονται στην Ευρώπη απαρτίζεται από δύο βασικούς τύπους: τους Αντιδραστήρες Ελαφρού Ύδατος (LWR - Light-Water Reactors) οι οποίοι διακρίνονται σε Αντιδραστήρες Πεπιεσμένου Ύδατος (PWR - Pressurized Water Reactors) και σε Αντιδραστήρες Ζέοντος Ύδατος (BWR - Boiling Water Reactors) και τους Αντιδραστήρες Βαρέος Ύδατος (HWR - Heavy Water Reactors), με τον κύκλο λειτουργίας των πρώτων να παρουσιάζεται παρακάτω (Σχήμα 1.1) ενώ οι τεχνολογίες που χρησιμοποιούν καθώς και η ηλικία τους παραμένει έως και σήμερα αρκετά παλαιωμένη [16]. Ιστορικά έχουν παρατηρηθεί αρκετές περιπτώσεις όπου μικρές διαταραχές (ή ανωμαλίες στην λειτουργία των παραπάνω αντιδραστήρων) έχουν οδηγήσει σε ολέθριες και κοσμοϊστορικές καταστροφές (βλ. Chernobyl, RBMK, 1986) [17].

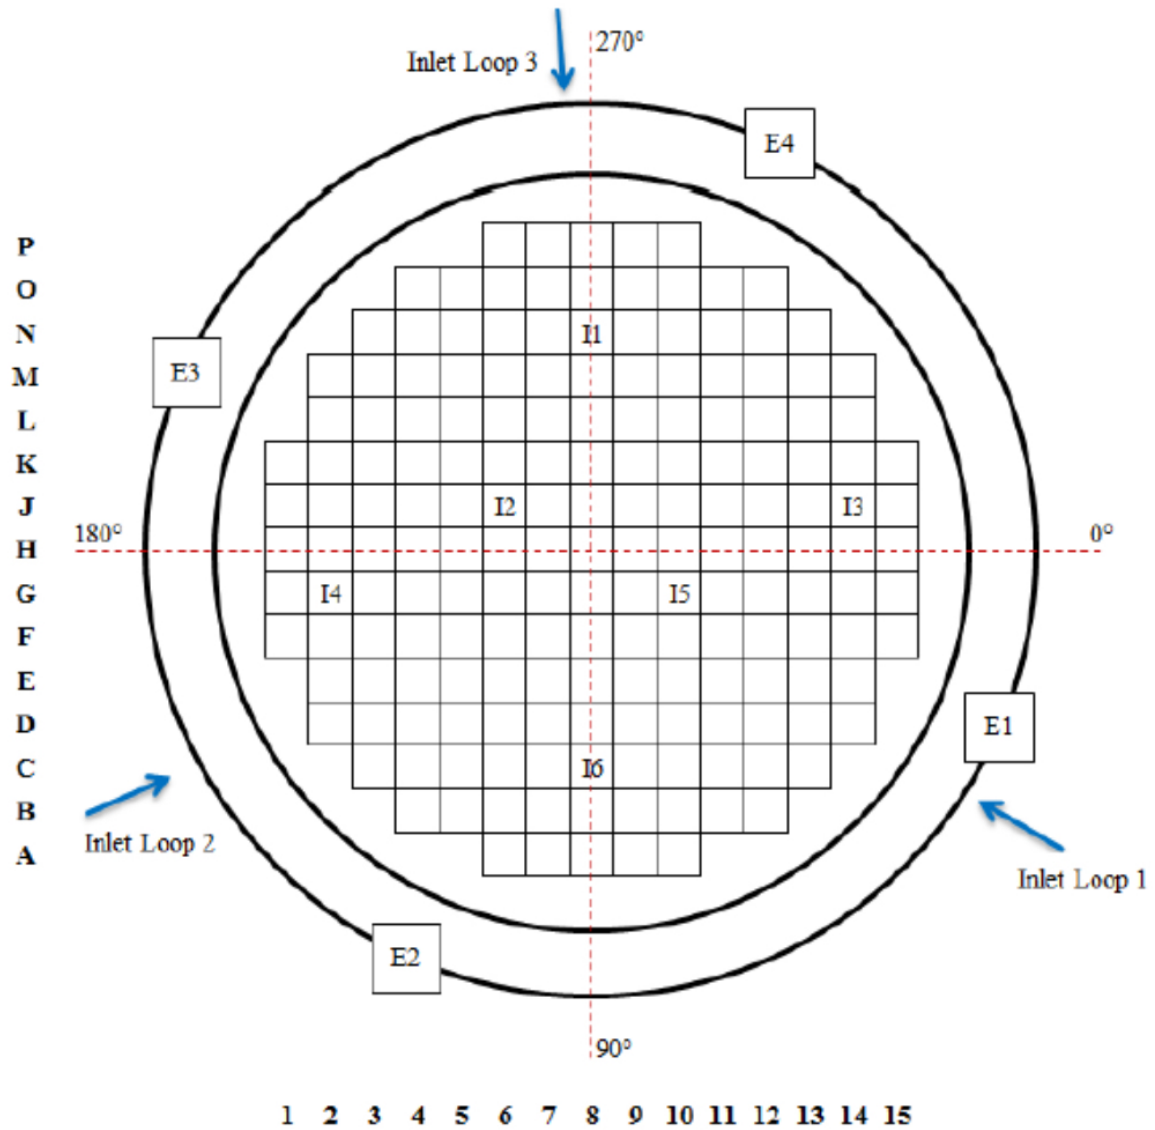


Σχήμα 1.1: Απεικόνιση λειτουργίας PWR αντιδραστήρα [1]

1.2 Μοντελοποίηση αντιδραστήρα και δεδομένα

Το μοντέλο του υπό εξέταση αντιδραστήρα αποτελείται από 177 διαφορετικές κυψέλες καυσίμου με τους εσωτερικούς αισθητήρες να βρίσκονται σε 6 συγκεκριμένες θέσεις και σε 6 επίπεδα (σύνολο 36) ενώ οι εξωτερικοί βρίσκονται σε 4 θέσεις σε 2 επίπεδα (σύνολο 8) όπως φαίνονται στο παρακάτω σχεδιάγραμμα (Σχήμα 1.2) οι οποίοι και παρέχουν τα σήματα της ροής νετρονίων [2].


Η καταγραφή των μετρήσεων του νετρονιακού θορύβου προέρχεται από αισθητήρες που βρίσκονται εντός και εκτός του πυρήνα του αντιδραστήρα (inner and outer core) και οι οποίοι καταμετρούν την ροή νετρονίων (neutron flux) σε ένα πεπερασμένο διάστημα χρόνου, με την καταγραφή των διαταραχών να γίνεται συγκρίνοντας την απόκλιση από τον (σταθμισμένο) αριθμητικό μέσο στο πεδίο του χρόνου.



Σχήμα 1.2: Αξονικό σχεδιάγραμμα κυψελών καυσίμου και θέσεων αισθητήρων για το μοντέλο του αντιδραστήρα Gösgen. Οι εσωτερικοί αισθητήρες παρουσιάζονται με I ενώ οι εξωτερικοί με E [2]

Όπως είναι γνωστό [18], για την διαδικασία της εκπαίδευσης ενός μοντέλου Μηχανικής Μάθησης απαιτείται ένας εύλογος όγκος δεδομένων έτσι ώστε αυτή να είναι αποδοτική, κάτι που όμως στην συγκεκριμένη περίπτωση δεν είναι διαθέσιμο. Επομένως θα στηριχθούμε στην παραγωγή συνθετικών δεδομένων μέσω προγραμμάτων προσομοίωσης της λειτουργίας πυρηνικών αντιδραστήρων, με βάση τον τύπο και τον κύκλο λειτουργίας τους [19].

Πιο συγκεκριμένα, για την παραγωγή των δεδομένων στο πεδίο του χρόνου έχει γίνει χρήση του προσομοιωτικού προγράμματος SIMULATE-3K (S3K) [4] και στα πλαίσια της εργασίας αυτής θα ασχοληθούμε με τα δεδομένα που αφορούν δονήσεις μεμονωμένων κυψελών καυσίμου (Vibrations of Individual Fuel Assemblies) στο νοητό πλέγμα (grid) του πυρήνα ενός Ελβετικού 3-loop Pre-KONVOI PWR αντιδραστήρα (Gösgen). Κατά την παραγωγή των σημάτων έχει γίνει προσθήκη Ημιτονοειδούς (SIN) και Λευκού Θορύβου (WN). Οι πιο συνήθεις και σημαντικοί τρόποι δονήσεων των κυψελών καυσίμου (FAs) που έχουν μοντελοποιηθεί αφορούν: την περίπτωση όπου το ένα άκρο της ράβδου παραμένει σταθερό, με το άλλο να ταλαντώνεται (σαν πρόβολος) (Cantilevered mode) καθώς και αυτή της πακτωμένης ράβδου όπου και τα δύο άκρα είναι σταθερά αλλά ταλαντώνεται εσωτερικά είτε σε σχήμα C (C-shaped mode) είτε σαν S (S-shaped mode) [20], όπως αυτές παρουσιάζονται στο παρακάτω διάγραμμα (Σχήμα 1.3).



Σχήμα 1.3: Είδη δονήσεων κυψελών καυσίμου (FAs): Cantilevered mode, C-shaped mode και S-shaped mode

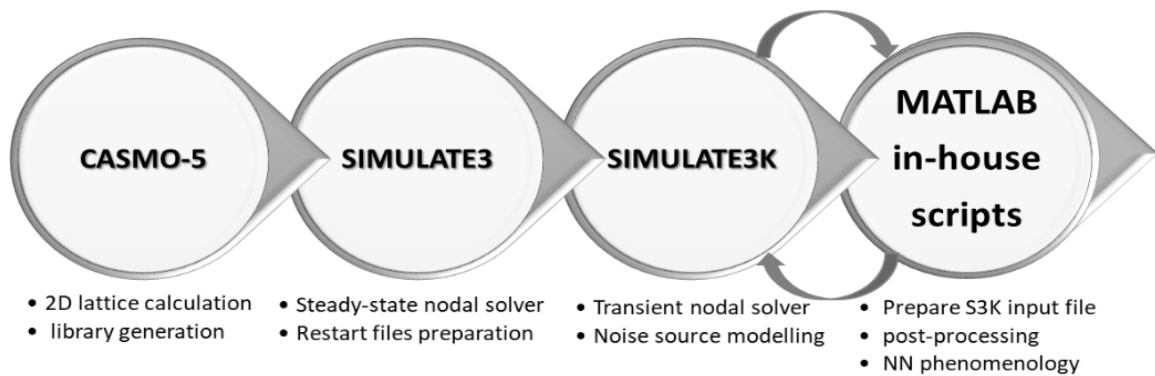
Σενάριο	Περιγραφή
S1	Μεμονωμένη FA με δόνηση σε Cantilevered mode
S2	Μεμονωμένη FA με δόνηση σε C-shaped mode
S3	Μεμονωμένη FA με δόνηση σε S-shaped mode

Πίνακας 1.1: Προσομοιώσεις διαταραχών για συνθήκες λειτουργίας MOC39 και BOC40

1.2.1 Συνθετικά δεδομένα

Οι προσομοιώσεις αφορούν τις συνθήκες λειτουργίας του αντιδραστήρα κατά την μέση του κύκλου 39 (Middle-of-Cycle 39, MOC39) και την αρχή του κύκλου 40 (Beginning-of-Cycle 40, BOC40), με την κύρια διαφορά μεταξύ των δύο αυτών συνθηκών να παρατηρείται στην ποσότητα του καυσίμου που καταναλώνεται. Κάθε σενάριο μοντελοποίησης έχει συνολική διάρκεια 100 δευτερολέπτων με βήμα 0.01 δευτερολέπτων ενώ τα S1-S3 αποτελούνται από 177 επιμέρους καταγραφές, όπου κάθε μια αντιστοιχεί σε μία κυψέλη καυσίμου (FA). Οι προσομοιώσεις έχουν πραγματοποιηθεί σε ονομαστική συχνότητα 1.2Hz για τα S1 και S2, 5Hz για το S3 και μέγιστο πλάτος μετατόπισης 1mm κατά τον άξονα.

Τα αποτελέσματα που βασίζονται στο S3K παρέχονται από το PSI [21] (παραδοτέα T3.1.3 [22] και T4.2.2 [23] για BOC40 και MOC39 αντίστοιχα) σε μορφή πινάκων MATLAB, σύμφωνα με την μέθοδο που απεικονίζεται στο διάγραμμα (Σχήμα 1.4) και τα αντίστοιχα σενάρια παρουσιάζονται στον (Πίνακα 1.1).



Σχήμα 1.4: Διαδικασία παραγωγής προσομοιώσεων από το PSI [3, 4]

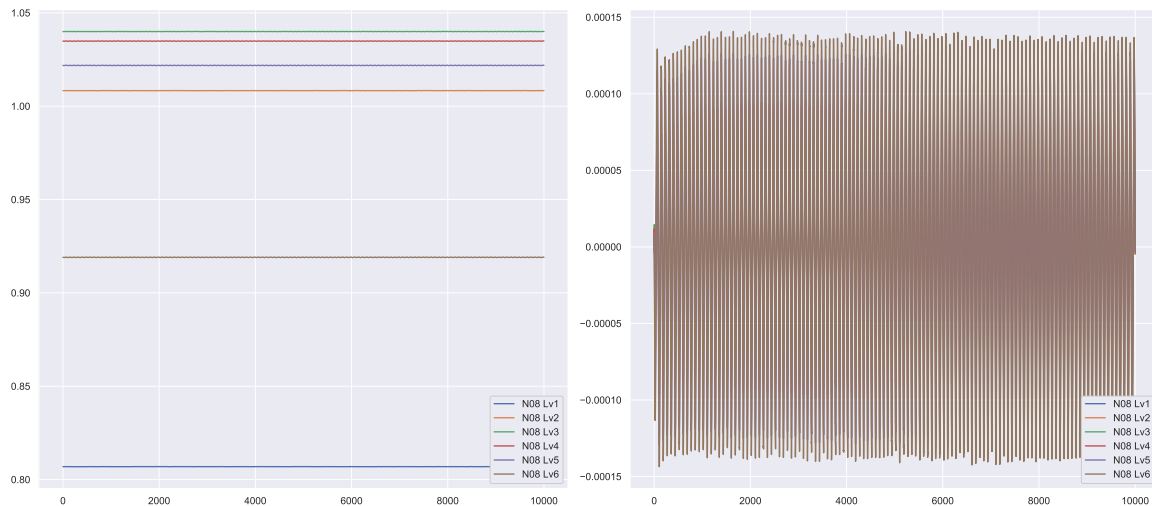
1.2.2 Πραγματικά δεδομένα

Τα πραγματικά δεδομένα που έχουν καταγραφεί από τον ίδιο αντιδραστήρα αφορούν και αυτά τις ίδιες συνθήκες λειτουργίας (MOC39 και BOC40) με συνολική διάρκεια καταγραφής 1000 δευτερόλεπτα και βήμα 0.04 δευτερολέπτων.

Στα παραπάνω δεδομένα έχει γίνει κατάλληλη προσαρμογή έτσι ώστε οι συχνότητες δειγματοληψίας καθώς και τα παράθυρα μεταξύ των συνθετικών και των πραγματικών δεδομένων να είναι ίδια.

1.2.3 Τάση σήματος / Αφαίρεση τάσης σήματος (Detrending)

Η τάση συνήθως αναφέρεται σε μια αλλαγή του μέσου όρου της τιμής του σήματος σε ένα πεπερασμένο χρονικό διάστημα. Όταν αφαιρείται η τάση, αφαιρείται μια πτυχή από τα δεδομένα που θεωρείται πως προκαλεί κάποιου είδους παραμόρφωση. Προκειμένου οι αποκλίσεις να γίνονται πιο εύκολα διακριτές (μιας και έχουμε να κάνουμε με αποκλίσεις της τάξεως του 10^{-5}) έχει γίνει προεπεξεργασία (preprocessing) των δεδομένων αφαιρώντας την τάση, όπου αυτή υπάρχει (detrending) όπως φαίνεται στο (Σχήμα 1.5).



Σχήμα 1.5: Παράδειγμα αφαίρεσης τάσης (detrending) από τα σήματα των αισθητήρων

Κεφάλαιο 2

Μηχανική μάθηση

2.1 Ορισμός και προσεγγίσεις

Η Μηχανική Μάθηση (ML) είναι το πεδίο της Τεχνητής Νοημοσύνης (AI) που μελετά αλγόριθμους υπολογιστών που βελτιώνονται αυτόματα μέσω της εμπειρίας. Οι αλγόριθμοι Μηχανικής Μάθησης δημιουργούν μαθηματικά μοντέλα βασισμένα σε δεδομένα δειγματοληψίας προκειμένου να κάνουν προβλέψεις ή αποφάσεις χωρίς να είναι ρητά προγραμματισμένοι να το κάνουν. Οι αλγόριθμοι αυτοί χρησιμοποιούνται σε μια μεγάλη ποικιλία εφαρμογών όταν είναι δύσκολο για έναν άνθρωπο να σχεδιάσει χειροκίνητα τους απαραίτητους αλγόριθμους, όπως στους τομείς της Όρασης Υπολογιστών (Computer Vision) και της Επεξεργασίας Φυσικής Γλώσσας (Natural Language Processing).

Οι προσεγγίσεις της Μηχανικής Μάθησης συνήθως χωρίζονται σε τρεις μεγάλες κατηγορίες, ανάλογα με την ανατροφοδότηση (feedback) που είναι διαθέσιμη στον αλγόριθμο εκμάθησης: την Επιβλεπόμενη μάθηση, την Μη-Επιβλεπόμενη μάθηση και την Ενισχυτική μάθηση. Έχουν επίσης αναπτυχθεί άλλες προσεγγίσεις που δεν ταιριάζουν σε αυτήν την κατηγοριοποίηση, με ορισμένα συστήματα να χρησιμοποιούν περισσότερες από μία προσεγγίσεις (όπως στην ημι-εποπτευόμενη μάθηση για παράδειγμα) [5].

2.1.1 Επιβλεπόμενη μάθηση (Supervised learning)

Το πρόβλημα της **Επιβλεπόμενης μάθησης (Supervised learning)** περιλαμβάνει την εκμάθηση μιας συνάρτησης από ζεύγη δειγμάτων εισόδου και εξόδου. Το σύστημα παρουσιάζεται με παραδείγματα εισόδων και τα επιθυμητά τους αποτελέσματα που ονομάζονται επίσης επισημασμένα δεδομένα εκπαίδευσης, τα οποία δίνονται από έναν ειδικό και ο στόχος είναι να μάθουμε έναν γενικό κανόνα που αντιστοιχίζει τις εισόδους σε εξόδους. Ένας εποπτευόμενος αλγόριθμος μάθησης αναλύει τα επισημασμένα δεδομένα εκπαίδευσης και παράγει μια συνάρτηση που μπορεί να χρησιμοποιηθεί για τη χαρτογράφηση νέων παραδειγμάτων εισόδου και στο βέλτιστο σενάριο θα προσδιορίσει σωστά την έξοδο για άγνωστες περιπτώσεις.

2.1.2 Μη-Επιβλεπόμενη μάθηση (Unsupervised learning)

Το πρόβλημα της **Μη-Επιβλεπόμενης μάθησης (Unsupervised learning)** περιλαμβάνει την εκμάθηση των μοτίβων στα δεδομένα εισόδου χωρίς δεδομένες τιμές εξόδου (ετικέτες). Γνωστή και ως αυτο-οργάνωση (self-organized), η μάθηση χωρίς επίβλεψη επιτρέπει τη μοντελοποίηση των πυκνοτήτων πιθανοτήτων στα δεδομένα εισόδου.

2.1.3 Ενισχυτική μάθηση (Reinforcement learning)

Η **Ενισχυτική μάθηση (Reinforcement learning)** είναι μια προσέγγιση στη Μηχανική Μάθηση που ασχολείται με το πώς τα συστήματα πρέπει να λαμβάνουν αποφάσεις προκειμένου να μεγιστοποιήσουν μια σωρευτική ανταμοιβή. Η ενισχυτική μάθηση διαφέρει από την εποπτευόμενη μάθηση στο ότι δεν χρειάζεται να παρουσιαστούν επισημασμένα ζεύγη εισόδου/εξόδου και οποιεσδήποτε υποβέλτιστες ενέργειες να διορθωθούν ρητά. Η ρύθμιση του προβλήματος τυπικά δηλώνεται με τη μορφή μιας διαδικασίας απόφασης Markov, καθώς πολλοί αλγόριθμοι μάθησης ενίσχυσης χρησιμοποιούν τεχνικές δυναμικού προγραμματισμού. Οι αλγόριθμοι Ενισχυμένης Μάθησης διαφέρουν από τις κλασικές μεθόδους δυναμικού προγραμματισμού στο ότι οι πρώτες δεν προϋποθέτουν γνώση ενός ακριβούς μαθηματικού μοντέλου της διαδικασίας απόφασης Markov και στοχεύουν σε τέτοιες διαδικασίες όπου οι ακριβείς μέθοδοι καθίστανται ανέφικτες.

2.1.4 Ημι-επιβλεπόμενη και Αυτο-επιβλεπόμενη μάθηση (Semi-supervised and Self-supervised learning)


Η **Ημι-επιβλεπόμενη μάθηση (Semi-supervised learning)** είναι μια προσέγγιση στην Μηχανική Μάθηση που συνδυάζει μια μικρή ποσότητα δεδομένων με ετικέτα με μια μεγάλη ποσότητα δεδομένων χωρίς ετικέτα κατά τη διάρκεια της εκπαίδευσης. Η ημι-επιβλεπόμενη μάθηση συνδυάζει τις προσεγγίσεις χωρίς επίβλεψη (χωρίς επισημασμένα δεδομένα κατάρτισης) και επιβλεπόμενης μάθησης (μόνο με επισημασμένα δεδομένα εκπαίδευσης). Τα δεδομένα χωρίς ετικέτα, όταν χρησιμοποιούνται μαζί με μια μικρή ποσότητα δεδομένων με ετικέτα, μπορούν να βελτιώσουν την απόδοση της εκμάθησης. Η συλλογή δεδομένων με ετικέτα για ένα γνωστικό πρόβλημα απαιτεί συχνά εξειδικευμένους ανθρώπους ή ένα φυσικό πείραμα. Αυτό το κόστος που σχετίζεται με τη διαδικασία επισήμανσης μπορεί να καταστήσει μη εφικτή την παραγωγή μεγάλων, πλήρως επισημασμένων σετ εκπαίδευσης, ενώ η απόκτηση δεδομένων χωρίς ετικέτα είναι σχετικά φθηνή. Επομένως, η ημι-επιβλεπόμενη μάθηση μπορεί να έχει μεγάλη πρακτική αξία.

Η **Αυτο-επιβλεπόμενη μάθηση (Self-supervised learning)** αποτελεί υποκατηγορία της Μη-επιβλεπόμενης μάθησης κατά την οποία όμως η διαδικασία της επίβλεψης καθώς και της εξαγωγής χαρακτηριστικών (feature extraction) γίνεται μέσω διεργασιών από τα ίδια τα δεδομένα και την διαδικασία της εκπαίδευσης.

2.2 Νευρωνικά Δίκτυα

2.2.1 Βαθιά Νευρωνικά Δίκτυα με Εμπρόσθια Τροφοδότηση (DFNNs)

Τα **Νευρωνικά Δίκτυα με Εμπρόσθια Τροφοδότηση (FNNs)** είναι τεχνητά νευρωνικά δίκτυα στα οποία η πληροφορία ρέει αποκλειστικά από το επίπεδο εισόδου (Input Layer), μέσω των κρυφών επιπέδων (Hidden Layers), καταλήγοντας στο επίπεδο εξόδου (Output Layer), όπως φαίνεται στο (Σχήμα 2.1).




Σχήμα 2.1: Νευρωνικό Δίκτυο με Εμπρόσθια Τροφοδότηση

Στόχος ενός νευρωνικού δικτύου με εμπρόσθια τροφοδότηση είναι να προσεγγίσει τη συνάρτηση f^* η οποία αντιστοιχίζει μια είσοδο x στην κατάλληλη έξοδο $y = f^*(x)$. Πιο συγκεκριμένα, σκοπός ενός τέτοιου δικτύου είναι να μάθει τις τιμές των παραμέτρων θ ώστε η συνάρτηση $y = f(x; \theta)$ να προσεγγίζει όσο το δυνατόν καλύτερα την f^* [5]. Η πιο απλή περίπτωση νευρωνικού δικτύου με εμπρόσθια τροφοδότηση είναι το Perceptron [24], ένα πλήρως συνδεδεμένο δίκτυο ενός επιπέδου. Το **Perceptron** (1958) είναι ένας αλγόριθμος επιβλεπόμενης μάθησης και πιο συγκεκριμένα ένας δυαδικός ταξινομητής και βασίζεται σε μια γραμμική συνάρτηση απόφασης συνδυάζοντας το διάνυσμα εισόδου με ένα διάνυσμα βάρων ως εξής:

$$f(x) = w^T x + b = \begin{cases} 1 & \text{αν } w^T x + b > 0 \\ 0 & \text{αλλιώς} \end{cases} \quad (2.1)$$

Παρ' όλο που το Perceptron έμοιαζε πολλά υποσχόμενο στην αρχή, εν τέλει αποδείχθηκε ότι τα Perceptrons είναι ικανά μόνο για την εκμάθηση γραμμικών προτύπων. Προκειμένου να καταπολεμηθεί αυτός ο περιορισμός αναπτύχθηκαν πιο ισχυρά πλήρως συνδεδεμένα νευρωνικά δίκτυα με εμπρόσθια τροφοδότηση, τα Πολυεπίπεδα Perceptrons. Τα **Πολυεπίπεδα Perceptrons (MLPs)** υλοποιούνται στοιβάζοντας απλά Perceptron μεταξύ τους, και χρησιμοποιώντας μη γραμμικές συναρτήσεις ενεργοποίησης g (π.χ. ReLU, sigmoid) μεταξύ των επιπέδων, παράγοντας έτσι μια μη γραμμική αντιστοίχιση μεταξύ εισόδου και εξόδου.

Επέκταση των παραπάνω αποτελούν τα σύγχρονα **Βαθιά Νευρωνικά Δίκτυα (DNNs)**. Τα Νευρωνικά Δίκτυα Τροφοδοσίας ανήκουν στην κατηγορία των δικτύων επειδή τυπικά αντιπροσωπεύονται από τη σύνθεση πολλών διαφορετικών συναρτήσεων. Το μοντέλο συσχετίζεται με ένα κα-




Σχήμα 2.2: Αρχιτεκτονική απλού Perceptron ενός επιπέδου

τευθυνόμενο ακυκλικό γράφημα που περιγράφει πώς συντίθενται οι συναρτήσεις. Για παράδειγμα, μπορεί να έχουμε τρεις συναρτήσεις $f^{(1)}$, $f^{(2)}$ και $f^{(3)}$ συνδεδεμένες σε μια αλυσίδα, σε $f(x) = f^{(3)}(f^{(2)}(f^{(1)}(x)))$. Αυτές οι δομές αλυσίδας είναι οι πιο συχνά χρησιμοποιούμενες δομές νευρωνικών δικτύων. Σε αυτή την περίπτωση, η $f^{(1)}$ ονομάζεται το πρώτο επίπεδο του δικτύου, η $f^{(2)}$ ονομάζεται δεύτερο επίπεδο και ούτω καθεξής. Το συνολικό μήκος της αλυσίδας δίνει το βάθος (depth) του μοντέλου. Ο όρος "Deep Learning" προέκυψε από αυτήν την ορολογία [5].

2.2.2 Συναρτήσεις ενεργοποίησης (Activation functions)

Προκειμένου να επιλυθούν γραμμικά μη διαχωρίσιμα προβλήματα, είναι απαραίτητο να εισαχθούν μη γραμμικότητες στους αλγόριθμους οι οποίες μας επιτρέπουν να προσεγγίζουμε αυθαίρετα πολύπλοκες συναρτήσεις.



Σχήμα 2.3: Γραφική αναπαράσταση προσέγγισης μη-γραμμικών προβλημάτων [5]

Οι **Συναρτήσεις ενεργοποίησης (Activation functions)** ορίζουν την έξοδο ενός κόμβου, λαμβάνοντας υπόψη τις εισόδους, και εκτελούν το βασικό καθήκον της λήψης μιας μη γραμμικής απόφασης. Με δεδομένο ένα Perceptron όπως στην (Εξίσωση 2.1) και μια συνάρτηση ενεργοποίησης g μπορούμε να ορίσουμε έναν απλό ταξινομητή με έναν κόμβο ως εξής:

$$\hat{y} = g(w^T x + b) \quad (2.2)$$

Οι πιο συνηθισμένες συναρτήσεις ενεργοποίησης είναι:

Η **Sigmoid** συνάρτηση έχει ένα χαρακτηριστικό σχήμα "S" (επίσης γνωστή και ως σιγμοειδής καμπύλη) και δίνεται από την (Εξίσωση 2.3):

$$\sigma(x) = \frac{1}{1 + e^{-x}} = \frac{e^x}{e^x + 1} \quad (2.3)$$

Η σιγμοειδής συνάρτηση είναι μια οριοθετημένη, διαφοροποιήσιμη, πραγματική συνάρτηση που ορίζεται για όλες τις πραγματικές τιμές εισόδου και έχει μη αρνητική παράγωγο σε κάθε σημείο. Γενικά, μια σιγμοειδής συνάρτηση είναι μονότονη και έχει πρώτη παράγωγο που έχει σχήμα καμπάνας. Μια σιγμοειδής συνάρτηση περιορίζεται από ένα ζεύγος οριζόντιων ασυμπτωτικών στο $x \rightarrow \pm\infty$. Η σιγμοειδής συνάρτηση είναι κυρτή για τιμές μικρότερες του 0 ενώ είναι κοίλη για τιμές μεγαλύτερες αυτού. Εξαιτίας αυτού, η σιγμοειδής συνάρτηση (και οι συγγενικές της συνθέσεις) μπορούν να έχουν πολλαπλά βέλτιστα.

Ωστόσο, η σιγμοειδής όπως ορίζεται από την (Εξίσωση 2.3) έχει δύο μειονεκτήματα: Πρώτα απ' όλα, όταν η τιμή του είναι κοντά στο 0 ή το 1, η τιμή της παραγώγου είναι κοντά στο 0. Δεύτερον, η έξοδος της σιγμοειδούς δεν είναι κεντραρισμένη στο 0. Έτσι, εάν τα δεδομένα που δίνονται ως είσοδος στον νευρώνα έχουν πάντα θετικές τιμές, η παράγωγος των βαρών θα είναι είτε πάντα θετική, είτε πάντα αρνητική με μια ανεπιθύμητη παραλλαγή να εισάγεται στο δίκτυο.

Η **Rectified Linear Unit (ReLU)** αποτελείται από έναν ανορθωτή (rectifier) που ορίζεται ως το θετικό μέρος του ορίσμάτος της (Εξίσωση 2.4):

$$g(x) = x^+ = \max(0, x) \quad (2.4)$$

Επίσης γνωστή και ως συνάρτηση ράμπας, είναι ανάλογη με την ανόρθωση μισού κύματος (half-wave) στην Ηλεκτρική Μηχανική. Ένα κύριο πλεονέκτημα της ReLU είναι η απλή ενεργοποίηση, καθώς σε ένα τυχαία αρχικοποιημένο δίκτυο μόνο το 50% περίπου των κρυφών μονάδων ενεργοποιείται (έχουν μη μηδενική έξοδο). Άλλα σημαντικά πλεονεκτήματα είναι η καλύτερη διάδοση της κλίσης, ο αποτελεσματικός υπολογισμός και η ιδιότητα αμετάβλητης κλίμακας (scale invariant). Πιθανά μειονεκτήματα της ReLU είναι η έλλειψη διαφοροποίησης γύρω από το 0, η συμμετρία μηδενικού κέντρου και το γεγονός ότι είναι μη-φραγμένη (unbounded). Ένα πολύ γνωστό μειονέκτημα είναι το λεγόμενο πρόβλημα της "θνήσκουσας ReLU (dying ReLU)", κατά το οποίο οι νευρώνες ωθούνται σε καταστάσεις που γίνονται ανενεργοί για ουσιαστικά όλες τις εισόδους, η ανανέωση των βαρών μέσω των παραγώγων δεν ρέει προς τα πίσω μέσω του νευρώνα και έτσι ο νευρώνας παραμένει σε μια διαρκώς ανενεργή κατάσταση.

Μια βελτιωμένη έκδοση της ReLU αποτελεί η **Leaky ReLU**, η οποία και διορθώνει το πρόβλημα της "dying ReLU" και δίνεται ως εξής:

$$g(x) = \begin{cases} x & \text{αν } x > 0 \\ ax & \text{αλλιώς} \end{cases} \quad (2.5)$$

Κάθε φορά που θέλουμε να αναπαραστήσουμε μια κατανομή πιθανότητας σε μια διακριτή μεταβλητή με n πιθανές τιμές, μπορούμε να χρησιμοποιήσουμε τη συνάρτηση **softmax**. Αυτό μπορεί να θεωρηθεί ως γενίκευση της σιγμοειδούς συνάρτησης (sigmoid), η οποία χρησιμοποιήθηκε για να αναπαραστήσει μια κατανομή πιθανότητας σε μια δυαδική μεταβλητή. Οι συναρτήσεις softmax χρησιμοποιούνται συχνότερα ως έξοδοι ενός ταξινομητή, για να αναπαραστήσουν τις διαφορετικές κλάσεις κατανομής πιθανότητας. Πιο σπάνια, οι συναρτήσεις softmax μπορούν να χρησιμοποιηθούν μέσα στο ίδιο το μοντέλο, εάν θέλουμε το μοντέλο να επιλέξει ανάμεσα σε μία από τις n διαφορετικές επιλογές για κάποια εσωτερική μεταβλητή [5].

Θεωρώντας ένα γραμμικό επίπεδο που προβλέπει μη κανονικοποιημένες λογαριθμικές πιθανότητες (Εξίσωση 2.6):


$$z = W^T + b \quad (2.6)$$

όπου $z_i = \log P(y = i | x)$. Η συνάρτηση softmax μπορεί στη συνέχεια να εκθεματίσει και να ομαλοποιήσει το z για να αποκτήσει το επιθυμητό y . Τυπικά, η συνάρτηση softmax δίνεται από την (Εξίσωση 2.7):

$$\text{softmax}(z)_i = \frac{\exp(z_i)}{\sum_j \exp(z_j)} \quad (2.7)$$

2.2.3 Συνελκτικά Νευρωνικά Δίκτυα (CNNs)

Το πολυεπίπεδο Perceptron αν και ανταποκρίνεται πολύ αποτελεσματικά σε σύνθετα προβλήματα φαίνεται να έχει κάποιους περιορισμούς. Όντας ένα πλήρως συνδεδεμένο δίκτυο, κάθε νευρώνας ενός επιπέδου είναι συνδεδεμένος με όλους τους νευρώνες του επόμενου. Αυτό καθιστά την λειτουργία του πολύ υπολογιστικά κοστοβόρα [25], έχοντας μάλιστα πλεονασμό από συνδέσεις μεταξύ νευρώνων αφού δεν έχουν πάντα όλα τα χαρακτηριστικά εισόδου υψηλή συσχέτιση μεταξύ τους. Επίσης, αυτή η πληθώρα συνδέσεων συνεπάγεται αυξημένη πολυπλοκότητα του μοντέλου και κατ' επέκταση αυξημένη δυσκολία γενίκευσης [26].



Σχήμα 2.4: Αρχιτεκτονική Συνελκτικού Νευρωνικού Δικτύου (CNN) (LeNet-5) [6]

Τα **Συνελκτικά Νευρωνικά Δίκτυα (CNNs)** [27, 28, 6, 29] είναι μια κατηγορία νευρωνικών δικτύων με εμπρόσθια τροφοδότηση που ξεπερνούν αυτούς τους δύο περιορισμούς. Τα CNNs είναι δίκτυα των οποίων τουλάχιστον ένα επίπεδο είναι συνελκτικό, δηλαδή εφαρμόζει την πράξη της συνέλιξης μεταξύ της εισόδου και ενός φίλτρου βαρών κοινό για όλα τα χαρακτηριστικά της εισόδου. Συνήθως, στην έξοδο του συνελκτικού επιπέδου εφαρμόζεται μια μη γραμμική συνάρτηση ενεργοποίησης (στα CNNs χρησιμοποιείται κυρίως η ReLU), ακολουθούμενη μερικές φορές από ένα επίπεδο υποδειγματοληψίας στο οποίο θα αναφερόμαστε ως μηχανισμός Pooling. Έτσι, ξεπερνάται το πρόβλημα της πλήρους συνδεσιμότητας σε μια απόπειρα δημιουργίας δικτύων με αραιή και πιο "εύστοχη" συνδεσιμότητα. Τα CNNs συνήθως χρησιμοποιούνται σε προβλήματα επεξεργασίας εικόνων και όρασης υπολογιστών. Εκμεταλλεύομενα την μεγάλη πιθανότητα υψηλής συσχέτισης που έχουν τα pixels μιας περιοχής της εικόνας μεταξύ τους, πετυχαίνουμε την μείωση των παραμέτρων και της πολυπλοκότητας του μοντέλου, και κατ' επέκταση δίνεται η δυνατότητα για την κατασκευή βαθύτερων δικτύων. Μπορούμε λοιπόν να σκεφτούμε τα CNNs ως δίκτυα στα οποία εμπεριέχεται τουλάχιστον ένα συνελκτικό επίπεδο. Ένα συνελκτικό επίπεδο αποτελείται από ένα πλήθος φίλτρων βαρών k (συνήθως μικρών διαστάσεων π.χ. 3×3 , 5×5) που καθένα απ' αυτά διασχίζει με κάποιο βήμα (stride) την εικόνα I σαν κυλιόμενο παράθυρο εφαρμόζοντας έτσι την πράξη της συνέλιξης [5]¹ (Εξίσωση 2.8):

$$(I * k)(i, j) = \sum_m \sum_n I(i + m, j + n) \cdot k(m, n) \quad (2.8)$$

¹ Η Εξίσωση 2.8 δεν αποτελεί τον πραγματικό ορισμό της πράξης της συνέλιξης, πρόκειται για μια παρόμοια συνάρτηση που ονομάζεται **cross-correlation**. Όπως συνηθίζεται στον χώρο της Μηχανικής Μάθησης, θα κάνουμε την σύμβαση με τον όρο "συνέλιξη" να αναφερόμαστε στο cross-correlation.

Λόγω των κοινών βαρών (weight sharing), το φίλτρο αναζητά στην εικόνα ένα συγκεκριμένο μοτίβο το οποίο μπορεί να εντοπίσει σε πολλά διαφορετικά μέρη αυτής κατά το πέρασμα του. Αυτό σε συνδυασμό με τον μηχανισμό Pooling, καθιστούν τα CNNs αμετάβλητα κατά τη μετατόπιση (translation-invariant). Γι' αυτό το λόγο τα CNNs είναι πολύ αποτελεσματικά στην ανίχνευση και αναγνώριση αντικειμένων, καθώς εκμεταλλεύονται την μεγάλη πιθανότητα υψηλής συσχέτισης που έχουν τα pixels μιας περιοχής της εικόνας μεταξύ τους. Χρησιμοποιώντας παρόμοια λογική με τα παραπάνω, η συσχέτιση αυτή μπορεί να εφαρμοστεί και σε επίπεδο σημάτων με ολισθούμενα παράθυρα συνέλιξης.

2.2.4 Κανονικοποίηση παρτίδας (Batch normalization)

Τα πολύ βαθιά μοντέλα περιλαμβάνουν τη σύνθεση πολλών λειτουργιών ή στρωμάτων. Η παράγωγος (κλίση) είναι αυτή που καθοδηγεί τον τρόπο ενημέρωσης κάθε παραμέτρου, με την υπόθεση ότι τα άλλα επίπεδα δεν αλλάζουν. Στην πράξη όμως ενημερώνουμε όλα τα επίπεδα ταυτόχρονα. Η εκπαίδευση των Βαθιών Νευρωνικών Δικτύων περιπλέκεται από το γεγονός ότι η κατανομή των εισόδων κάθε επιπέδου αλλάζει κατά τη διάρκεια της εκπαίδευσης, καθώς αλλάζουν οι παράμετροι των προηγούμενων επιπέδων. Αυτό επιβραδύνει την εκπαίδευση απαιτώντας χαμηλότερους ρυθμούς εκμάθησης και προσεκτική προετοιμασία παραμέτρων και καθιστά εξαιρετικά δύσκολη την εκπαίδευση μοντέλων με κορεσμένες μη γραμμικότητες [5].

Η **Κανονικοποίηση παρτίδας (Batch normalization)** παραμετροποιεί εκ νέου το μοντέλο για να κάνει ορισμένες μονάδες να τυποποιούνται πάντα εξ ορισμού, επηρεάζοντας την εκπαίδευση δικτύου με θεμελιώδη τρόπο: κάνει το πεδίο του αντίστοιχου προβλήματος βελτιστοποίησης να είναι σημαντικά πιο ομαλό. Αυτό διασφαλίζει ότι οι κλίσεις είναι πιο προγνωστικές και έτσι επιτρέπουν τη χρήση μεγαλύτερου εύρους ρυθμών εκμάθησης και ταχύτερη σύγκλιση δικτύου [30].


2.2.5 Ομαδοποίηση (Pooling)

Η **Ομαδοποίηση (Pooling)** είναι ένα βασικό βήμα σε συνελκτικά συστήματα που μειώνει τη διάσταση των χαρτών χαρακτηριστικών (feature maps). Συνδυάζει ένα σύνολο τιμών σε μικρότερο πλήθος τιμών, δηλαδή επιτυγχάνει τη μείωση της διαστάσεων του χάρτη χαρακτηριστικών. Μετατρέπει την κοινή αναπαράσταση χαρακτηριστικών σε πολύτιμες πληροφορίες διατηρώντας χρήσιμες πληροφορίες και εξαλείφοντας τις λιγότερες σχετικές. Οι τελεστές ομαδοποίησης παρέχουν μια μορφή αμετάβλητης χωρικής μετατροπής ενώ παράλληλα μειώνουν την υπολογιστική πολυπλοκότητα για τα ανώτερα στρώματα εξαλείφοντας ορισμένες συνδέσεις μεταξύ συνελκτικών επιπέδων. Αυτό το επίπεδο εκτελεί ουσιαστικά την υποδειγματοληψία στους χάρτες χαρακτηριστικών που προέρχονται από το προηγούμενο επίπεδο και παράγει τους νέους χάρτες χαρακτηριστικών σε μια συμπυκνωμένη μορφή και εξυπηρετεί δύο βασικούς σκοπούς: ο πρώτος είναι να μειώσει τον αριθμό των παραμέτρων ή βαρών, μειώνοντας έτσι το υπολογιστικό κόστος και ο δεύτερος είναι να ελέγξει την υπερπροσαρμογή (overfitting). Μια ιδανική μέθοδος ομαδοποίησης αναμένεται να εξάγει μόνο χρήσιμες πληροφορίες και να απορρίψει τις λιγότερο σχετικές λεπτομέρειες [7].

Οι δύο πιο συχνές μέθοδοι ομαδοποίησης αφορούν τους τελεστές που χρησιμοποιούνται κατά την διαδικασία της ομαδοποίησης και είναι η **Ομαδοποίηση με μέση τιμή (Average pooling)** και η **Ομαδοποίηση με μέγιστη τιμή (Max pooling)**. [5]

2.2.6 Dropout

Το **Dropout** [31] παρέχει μια φθηνή προσέγγιση για την εκπαίδευση και την αξιολόγηση ενός συσσωρευμένου συνόλου εκθετικά πολλών νευρωνικών δικτύων. Ειδικότερα, το dropout εκπαιδεύει το σύνολο που αποτελείται από όλα τα υποδίκτυα που μπορούν να δημιουργηθούν αφαιρώντας μονάδες μη εξόδου από ένα υποκείμενο δίκτυο βάσης. Στα περισσότερα σύγχρονα νευρωνικά δίκτυα, με βάση μια σειρά λεπτών μετασχηματισμών και μη γραμμικότητων, μπορούμε να αφαιρέσουμε αποτελεσματικά μια μονάδα από ένα δίκτυο πολλαπλασιάζοντας την τιμή εξόδου της με το μηδέν. Αυτή η



Σχήμα 2.5: Παράδειγμα ομαδοποίησης με μέγιστη τιμή (Max pooling) [7]

διαδικασία απαιτεί κάποια μικρή τροποποίηση για μοντέλα όπως δίκτυα Συναρτήσεων Ακτινικής Βάσης (RBF), τα οποία λαμβάνουν τη διαφορά μεταξύ της κατάστασης της μονάδας και κάποιας τιμής αναφοράς [5].

2.3 Εκπαίδευση (Training)

2.3.1 Συναρτήσεις απωλειών (Loss functions)

Τα τεχνητά νευρωνικά δίκτυα εκπαιδεύονται με μια μέθοδο βελτιστοποίησης, η οποία στοχεύει στην επιλογή ενός συνόλου παραμέτρων μοντέλου που ελαχιστοποιεί το σφάλμα πρόβλεψης. Το σφάλμα πρόβλεψης ενός μοντέλου f με παραμέτρους w εκτιμάται από μια συνάρτηση απώλειας $J(w)$. Η συνάρτηση απώλειας υπολογίζει μια μη αρνητική τιμή που μετρά την ασυνέπεια μεταξύ της προβλεπόμενης και του στόχου εξόδου.

$$\mathcal{L}(f(x^{(i)}; w), y^{(i)}) \quad (2.9)$$

Εφαρμόζοντας την (Εξίσωση 2.9) σε ολόκληρο το σύνολο δεδομένων, μπορούμε να ποσοτικοποιήσουμε τη συνολική απώλεια σε σχέση με το σύνολο δεδομένων, γνωστή και ως αντικειμενική συνάρτηση, συνάρτηση κόστους ή εμπειρικό κίνδυνο (Εξίσωση 2.10) [5].

$$J(w) = \frac{1}{n} \sum_{i=0}^n \mathcal{L}(f(x^{(i)}; w), y^{(i)}) \quad (2.10)$$

Το **Μέσο Τετραγωνικό Σφάλμα (Mean Squared Error - MSE)** αποτελεί μια από τις πιο βασικές συναρτήσεις απωλειών που χρησιμοποιούνται από την διεθνή επιστημονική κοινότητα στα μοντέλα παλινδρόμησης (regression) και δίνεται ως εξής (Εξίσωση 2.11):

$$MSE = \frac{1}{n} \sum_{i=0}^n \|Y_i - \hat{Y}_i\|^2 \quad (2.11)$$

Η **Ρίζα Μέσου Τετραγωνικού Σφάλματος (Root Mean Squared Error - RMSE)** αποτελεί απλά επέκταση της (Εξίσωση 2.11) κωδικοποιώντας ουσιαστικά την ευκλείδεια απόσταση μέσω της χρήσης της ρίζας.

2.3.2 Εμπρόσθια - Οπίσθια Διάδοση (Forward - Backward propagation)

Όταν χρησιμοποιούμε ένα Νευρωνικό Δίκτυο Εμπρόσθιας Τροφοδοσίας (Feedforward Neural Network) για να δεχτούμε μια είσοδο x και να παράγουμε μια έξοδο \hat{y} , οι πληροφορίες ρέουν προς τα εμπρός μέσω του δικτύου. Η είσοδος x παρέχει τις αρχικές πληροφορίες που στη συνέχεια διαδίδονται μέχρι τις κρυφές μονάδες σε κάθε επίπεδο και τελικά παράγουν το y , με την διαδικασία αυτή να ονομάζεται **Εμπρόσθια διάδοση (Forward propagation)**. Κατά τη διάρκεια της εκπαίδευσης, η διάδοση προς τα εμπρός μπορεί να συνεχιστεί έως ότου να παραχθεί ένα βαθμωτό κόστος $J(\theta)$. Ο αλγόριθμος της **Οπίσθιας διάδοσης (Back-propagation)** [32], γνωστός απλά και ως backprop, επιτρέπει στην πληροφορία από το κόστος να ρέει προς τα πίσω μέσω του δικτύου προκειμένου να γίνει ο υπολογισμός της παραγώγου (κλίσης). Ο υπολογισμός μιας αναλυτικής έκφρασης για την παράγωγο είναι σχετικά απλός, αλλά η αριθμητική αξιολόγηση μιας τέτοιας έκφρασης μπορεί να είναι υπολογιστικά ακριβή. Ο αλγόριθμος back-propagation το κάνει χρησιμοποιώντας μια απλή και φθηνή διαδικασία². Συγκεκριμένα, θα περιγράψουμε τον τρόπο υπολογισμού του $\nabla_x f(x, y)$ για μια αυθαίρετη συνάρτηση f , όπου είναι ένα σύνολο μεταβλητών των οποίων οι παράγωγοι είναι επιθυμητές, και είναι ένα πρόσθετο σύνολο μεταβλητών που είναι είσοδοι στη συνάρτηση αλλά των οποίων οι παράγωγοι δεν είναι απαιτούμενες. Στους αλγόριθμους εκμάθησης, η κλίση που απαιτούμε συνήθως είναι η κλίση της συνάρτησης κόστους σε σχέση με τις παραμέτρους, $\nabla_{\theta} J(\theta)$. Πολλές εργασίες μηχανικής μάθησης περιλαμβάνουν τον υπολογισμό άλλων παραγώγων, είτε ως μέρος της μαθησιακής

² Ο όρος back-propagation συχνά παρεξηγείται ως εννοώντας ολόκληρο τον αλγόριθμο εκμάθησης για πολυεπίπεδα νευρωνικά δίκτυα. Στην πραγματικότητα, η αντίστροφη διάδοση αναφέρεται μόνο στη μέθοδο για τον υπολογισμό της παραγώγου, ενώ άλλοι αλγόριθμοι (όπως ο Stochastic Gradient Descent που θα δούμε παρακάτω) χρησιμοποιούνται για την διεκπεραίωση της διαδικασίας της μάθησης χρησιμοποιώντας την παράγωγο αυτή.

διαδικασίας, είτε για την ανάλυση του μοντέλου που μαθαίνεται. Ο αλγόριθμος αναδρομικής διάδοσης μπορεί να εφαρμοστεί και σε αυτές τις εργασίες και δεν περιορίζεται στον υπολογισμό της κλίσης της συνάρτησης κόστους σε σχέση με τις παραμέτρους. Η ιδέα του υπολογισμού των παραγώγων με τη διάδοση πληροφοριών μέσω ενός δικτύου είναι πολύ γενική και μπορεί να χρησιμοποιηθεί για τον υπολογισμό τιμών όπως η Jacobian μιας συνάρτησης f με πολλαπλές εξόδους. Περιορίζουμε την περιγραφή μας εδώ στην πιο συχνά χρησιμοποιούμενη περίπτωση, όπου η f έχει μία μόνο έξοδο [5]. Παρακάτω (Αλγόριθμος 1) περιγράφεται αναλυτικά με χρήση ψευδοκώδικα ο αλγόριθμος backprop.

Αλγόριθμος 1 Back-propagation σε δίκτυο με εισόδους x, y και ενεργοποιήσεις $a^{(k)}$ για κάθε επίπεδο k με συνάρτηση κόστους J που εξαρτάται από τις παραμέτρους W, b

After the forward computation, compute the gradient on the output layer:

$$g \leftarrow \nabla_{\hat{y}} J = \nabla_{\hat{y}} L(\hat{y}, y)$$

for $k = l, l-1, \dots, 1$ **do**

Convert the output gradient into a gradient on the pre-nonlinearity activation:

$$g \leftarrow \nabla_{a^{(k)}} J = g \odot f'(a^{(k)})$$

Compute gradients on weights and biases (including the regularization term):

$$\nabla_{b^{(k)}} J = g + \lambda \nabla_{b^{(k)}} \Omega(\theta)$$

$$\nabla_{W^{(k)}} J = g h^{(k-1)\top} + \lambda \nabla_{W^{(k)}} \Omega(\theta)$$

Propagate the gradients w.r.t. the next lower-level hidden layer's activations:

$$g \leftarrow \nabla_{h^{(k-1)}} J = W^{(k)\top} g$$


end for

2.3.3 Συναρτήσεις βελτιστοποίησης (Optimizer functions)

Το παραπάνω πρόβλημα βελτιστοποίησης απώλειας αντιμετωπίζεται συνήθως από τον αλγόριθμο **Gradient Descent**. Ο gradient descent είναι ένας επαναληπτικός αλγόριθμος βελτιστοποίησης πρώτης τάξης για την εύρεση ενός τοπικού ελάχιστου μιας διαφοροποιήσιμης συνάρτησης. Για να βρούμε ένα τοπικό ελάχιστο μιας συνάρτησης χρησιμοποιώντας gradient descent, κάνουμε βήματα ανάλογα με το αρνητικό της διαβάθμισης, ή κατά προσέγγιση κλίση, της συνάρτησης στο τρέχον σημείο. Η κάθοδος βαθμίδας βασίζεται στην παρατήρηση ότι εάν μια συνάρτηση πολλαπλών μεταβλητών $f(x)$ ορίζεται και διαφοροποιείται σε μια γειτονιά ενός σημείου a , τότε η $f(x)$ μειώνεται ταχύτερα εάν κάποιος πάει από το σημείο a προς την κατεύθυνση της αρνητικής κλίσης του f στο a , $-\nabla f(a)$. Συνεπάγεται ότι το επόμενο σημείο θα μπορούσε να επιλεγεί ως $a_{n+1} = a_n - \gamma \nabla f(a_n)$ όπου τότε θα ισχύει ότι $f(a_n) \geq f(a_{n+1})$ με τον συντελεστή γ ευρέως γνωστό ως ρυθμό εκμάθησης (learning rate), έναν (αρκετά μικρό) θετικό πραγματικό αριθμό. Αφαιρούμε το $\gamma \nabla f(a)$ από το a για να κινηθούμε ενάντια στην κλίση, προς το τοπικό ελάχιστο. Δεδομένου αυτού, μπορούμε να γενικεύσουμε ξεκινώντας με ένα τυχαίο σημείο x_0 ως εικασία για ένα τοπικό ελάχιστο της f και να λάβουμε μια ακολουθία x_0, x_1, x_2, \dots τέτοια ώστε $x_{n+1} = x_n - \gamma_n \nabla f(x_n)$, $n \geq 0$. Στη συνέχεια παίρνουμε τη μονοτονική ακολουθία $f(x_0) \geq f(x_1) \geq f(x_2) \geq \dots$, οπότε η ακολουθία (x_n) συγκλίνει στο επιθυμητό τοπικό ελάχιστο.

Όταν η f είναι κυρτή, όλα τα τοπικά ελάχιστα είναι επίσης καθολικά ελάχιστα, οπότε σε αυτήν την περίπτωση η βαθμιδωτή κάθοδος μπορεί να συγκλίνει στην καθολική λύση. Με ορισμένες παραδοχές για τη συνάρτηση f , όπως ότι η f είναι κυρτή και η ∇f είναι Lipschitz συνεχής, καθώς και συγκεκριμένες επιλογές του γ , μπορεί να εξασφαλιστεί η σύγκλιση σε ένα τοπικό ελάχιστο. Δυστυχώς, η μη γραμμικότητα των βαθιών νευρωνικών δικτύων κάνει την επιφάνεια απώλειας μη κυρτή. Αυτό σημαίνει ότι δεν υπάρχει καμία εγγύηση ότι μια μέθοδος που βασίζεται στον gradient descent θα συγκλίνει στο συνολικό ελάχιστο.

Μια μεγάλη πρόκληση σύμφωνα με τον gradient descent είναι το γεγονός ότι ο υπολογισμός gradient σε ολόκληρο το σύνολο δεδομένων μπορεί να είναι πολύ υπολογιστικά εντατικός (γνωστό και ως batch gradient descent). Για να αντιμετωπιστεί το πρόβλημα αυτό, εισήχθη ο **Stochastic Gradient Descent (SGD)**, ο οποίος αλγόριθμος προτείνει να επιλέγεται σε κάθε επανάληψη ένα μόνο σημείο



Σχήμα 2.6: Γραφική απεικόνιση σύγκλισης σε τρισδιάστατο χώρο με χρήση Gradient Descent σε μη-κυρτή συνάρτηση [8]

δεδομένων i και να ενημερώνονται οι παράμετροι χρησιμοποιώντας την κλίση της απώλειας ακριβώς αυτού του σημείου ($\frac{\partial J_i(w)}{\partial w}$). Ο αλγόριθμος SGD περιγράφεται με χρήση ψευδοκώδικα παρακάτω (Αλγόριθμος 2):

Αλγόριθμος 2 Stochastic Gradient Descent

Initialize weights w randomly $\sim N(0, \sigma^2)$

repeat:

 Pick single data point i

 Compute $\frac{\partial J_i(w)}{\partial w}$

 Update $w^{(t+1)} := w^{(t)} + \gamma \frac{\partial J_i(w)}{\partial w}$

until convergence

return w

Η μέθοδος **Adaptive moment estimation (Adam)** [33] αποτελεί μια βελτιωμένη προσέγγιση του SGD. Ο SGD διατηρεί έναν ενιαίο ρυθμό εκμάθησης α για όλες τις ενημερώσεις βάρους και ο ρυθμός εκμάθησης δεν αλλάζει κατά τη διάρκεια της εκπαίδευσης. Ο Adam συνδυάζει τα πλεονεκτήματα δύο άλλων επεκτάσεων του SGD: του Adaptive Gradient Algorithm (AdaGrad) και του Root Mean Square Propagation (RMSProp), υπολογίζοντας μεμονωμένους προσαρμοστικούς ρυθμούς μάθησης για διαφορετικές παραμέτρους μέσω εκτιμήσεων πρώτης και δεύτερης τάξης των κλίσεων. Συγκεκριμένα, ο αλγόριθμος υπολογίζει έναν εκθετικό κινητό μέσο όρο της κλίσης και της τετραγωνικής κλίσης, με τις παραμέτρους β_1 και β_2 να ελέγχουν τους ρυθμούς απόσβεσης αυτών των κινητών μέσων.

2.3.4 Μεταφορά Γνώσης (Transfer Learning)

Στο κλασικό σενάριο επιβλεπόμενης μάθησης, εάν στοχεύουμε να εκπαιδύσουμε ένα μοντέλο για μια συγκεκριμένη εργασία και τομέα, υποθέτουμε ότι έχουμε επαρκή δεδομένα με ετικέτα για την ίδια εργασία και τομέα. Συνήθως ένα μοντέλο εκπαιδεύεται σε αυτό το σύνολο δεδομένων αναμένεται να έχει καλή απόδοση σε μη ορατά δεδομένα της ίδιας εργασίας και τομέα. Αναμένεται ότι τα δεδομένα θα είναι ανεξάρτητες και πανομοιότυπα κατανομημένες τυχαίες μεταβλητές (i.i.d.). Εάν αλλάξει η εργασία ή ο τομέας, τότε απαιτούνται νέα δεδομένα με ετικέτα της ίδιας εργασίας ή τομέα για την εκπαίδευση ενός νέου μοντέλου στον συγκεκριμένο τομέα. Το παραπάνω παραδοσιακό παράδειγμα μάθησης καταρρέει όταν δεν έχουμε επαρκή επισημασμένα δεδομένα για την επιθυμητή εργασία ή τομέα για να εκπαιδύσουμε ένα συγκεκριμένο μοντέλο.

Η **Μεταφορά γνώσης (Transfer learning)** αντιμετωπίζει αυτόν τον περιορισμό αξιοποιώντας

δεδομένα άλλων εργασιών και τομέων, γνωστών ως εργασία προέλευσης και τομέας προέλευσης (source). Η γνώση που αποκτάται για την επίλυση της εργασίας προέλευσης στον τομέα προέλευσης χρησιμοποιείται για την επίλυση της εργασίας στόχου στον τομέα προορισμού (target).

Η μάθηση με μεταφορά γνώσης αναφέρεται στην κατάσταση όπου ό,τι έχει μάθει ένα μοντέλο σε ένα περιβάλλον αξιοποιείται για τη βελτίωση της γενίκευσης σε ένα άλλο περιβάλλον. Στη μεταβιβαστική μάθηση, ο εκπαιδευόμενος πρέπει να εκτελέσει δύο ή περισσότερες διαφορετικές εργασίες, αλλά υποθέτουμε ότι πολλοί από τους παράγοντες που εξηγούν τις παραλλαγές στην πρώτη εργασία σχετίζονται με τις παραλλαγές που πρέπει να αποτυπωθούν για την εκμάθηση της δεύτερης εργασίας. Στην υποπερίπτωση της μάθησης με μεταφορά γνώσης, γνωστή και ως Προσαρμογή πεδίου, η εργασία (και η βέλτιστη αντιστοίχιση εισόδου-εξόδου) παραμένει η ίδια μεταξύ κάθε ρύθμισης, αλλά η κατανομή εισόδου είναι ελαφρώς διαφορετική.

Ένας τομέας D αποτελείται από ένα χώρο χαρακτηριστικών X και μια οριακή κατανομή πιθανότητας $P(x)$ στον χώρο χαρακτηριστικών, όπου $x \in X$. Δεδομένου ενός τομέα $D = X, P(X)$, μια εργασία T αποτελείται από ένα χώρο ετικέτας Y και μια υπό όρους κατανομή πιθανότητας $P(Y | X)$ που συνήθως μαθαίνεται από τα δεδομένα εκπαίδευσης x_i, y_i με $x_i \in X$ και $y_i \in Y$. Δεδομένου ενός τομέα πηγής D_S , μιας αντίστοιχης προέλευσης εργασίας T_S , καθώς και ενός τομέα στόχου D_T και μιας εργασίας στόχου T_T , ο στόχος της μάθησης μεταφοράς είναι να μας επιτρέψει να μάθουμε την κατανομή πιθανοτήτων στόχου υπό όρους $P(Y_T | X_T)$ στο D_T με τις πληροφορίες που αποκτήθηκε από τις D_S και T_S .

Η μάθηση με μεταφορά βελτιώνει την απόδοση των μοντέλων με τρεις τρόπους. Πρώτον, είναι η αρχική απόδοση που μπορεί να επιτευχθεί στην εργασία στόχο χρησιμοποιώντας μόνο τη μεταφερόμενη γνώση, πριν γίνει οποιαδήποτε περαιτέρω μάθηση, σε σύγκριση με την αρχική απόδοση ενός αδαή πράκτορα. Δεύτερον, είναι ο χρόνος που χρειάζεται για την πλήρη εκμάθηση της εργασίας στόχου δεδομένης της μεταφερόμενης γνώσης σε σύγκριση με τον χρόνο που απαιτείται για την εκμάθησή της από την αρχή. Τρίτον είναι το τελικό επίπεδο απόδοσης που μπορεί να επιτευχθεί στην εργασία στόχο σε σύγκριση με το τελικό επίπεδο χωρίς μεταφορά γνώσης.

Μια ειδική περίπτωση μεταφοράς γνώσης περιλαμβάνει την περίπτωση όπου η εργασία προέλευσης είναι χωρίς επίβλεψη ενώ η εργασία στόχος εποπτεύεται. Αυτό είναι ιδιαίτερα ενδιαφέρον επειδή έχουμε συχνά μεγάλες ποσότητες δεδομένων εκπαίδευσης χωρίς ετικέτα, αλλά σχετικά λίγα δεδομένα εκπαίδευσης με ετικέτα. Η προπόνηση με επιβλεπόμενες τεχνικές στο υποσύνολο με τις ενδείξεις συχνά οδηγεί σε υπερπροσαρμογή. Μαθαίνοντας καλές αναπαραστάσεις από τα δεδομένα χωρίς ετικέτα, μπορούμε να πετύχουμε καλύτερη απόδοση στην επιβλεπόμενη μαθησιακή εργασία. Αυτή η περίπτωση μάθησης μεταφοράς ονομάζεται προκατάρτιση χωρίς επίβλεψη. Αυτή η διαδικασία είναι ένα παράδειγμα του πώς μια αναπαράσταση που μαθαίνεται για μια εργασία (μάθηση χωρίς επίβλεψη, προσπάθεια αποτύπωσης του σχήματος της κατανομής εισόδου) μπορεί μερικές φορές να είναι χρήσιμη για μια άλλη εργασία (επιβλεπόμενη μάθηση). Ονομάζεται προεκπαίδευση, επειδή υποτίθεται ότι είναι μόνο ένα πρώτο βήμα πριν εφαρμοστεί ένας αλγόριθμος κοινής εκπαίδευσης για τη περαιτέρω ρύθμιση (fine-tuning) όλων των επιπέδων του δικτύου μαζί.

2.3.5 Προσαρμογή Πεδίου (Domain Adaptation)

Η **Προσαρμογή Πεδίου (Domain Adaptation)** είναι μια συγκεκριμένη υποπερίπτωση μεταφοράς γνώσης, που προκύπτει όταν στοχεύουμε να μάθουμε από μια διανομή δεδομένων πηγής ένα μοντέλο με καλή απόδοση σε μια διαφορετική, αλλά σχετική, διανομή δεδομένων στόχου. Η Προσαρμογή πεδίου, που ονομάζεται επίσης μεταδοτική μάθηση μεταφοράς, λαμβάνει χώρα όταν οι οριακές κατανομές πηγής και στόχου είναι διαφορετικές, αλλά η εργασία που επιδιώκουμε να μάθουμε είναι η ίδια στους δύο τομείς. Η προσαρμογή τομέα είναι η δυνατότητα εφαρμογής ενός αλγόριθμου εκπαιδευμένου σε έναν ή περισσότερους τομείς προέλευσης σε διαφορετικό, αλλά σχετικό, τομέα στόχο. Στην προσαρμογή τομέα, οι τομείς προέλευσης και στόχος έχουν όλοι τον ίδιο χώρο χαρακτηριστικών, αλλά διαφορετικές διανομές. Μια αλλαγή πεδίου εμφανίζεται επίσης κατά την ανάπτυξη συστημάτων μηχανικής μάθησης, καθώς συνήθως υπάρχει μια αλλαγή στην κατανομή δεδομένων μεταξύ του συνόλου δεδομένων εκπαίδευσης και των πραγματικών δεδομένων.


Κεφάλαιο 3

Υφιστάμενη έρευνα και επέκταση αυτής

3.1 Υφιστάμενη έρευνα

Η έρευνα που έχει γίνει στο παρελθόν στο πρόβλημα της ανίχνευσης και του εντοπισμού των διαταραχών όπως παρουσιάζεται στο [34] αφορά προηγούμενα παραδοτέα του PSI με δεδομένα παραγμένα απευθείας στο πεδίο της συχνότητας (Σχήμα 3.1). Ο πιο διαδεδομένος τρόπος για την προσέγγιση του παραπάνω προβλήματος σύμφωνα με την διεθνή βιβλιογραφία είναι μέσω του τομέα της Όρασης Υπολογιστών (Computer Vision) μέσω πολυδιάστατης χωρικής απεικόνισης των δεδομένων που έχουμε. Κάτι τέτοιο μπορεί να επιτευχθεί μέσω της κατασκευής των αντίστοιχων φασματογραφημάτων (spectrograms) [35] μέσω του Discrete Fourier Transform (DFT) (Εξίσωση 3.1) στα οποία μπορούν να εφαρμοστούν παραδοσιακές τεχνικές όπως γίνεται και στις εικόνες στην Μηχανική Μάθηση [34].

$$\hat{x}(k) = \sum_{n=0}^{N-1} x(n)e^{-i\frac{2\pi k}{N}n}, k = 0, 1, \dots, N-1 \quad (3.1)$$



Σχήμα 3.1: Οπτικοποίηση των δεδομένων στο πεδίο της συχνότητας με βάση προηγούμενα παραδοτέα του PSI

Ένα ακόμη βήμα που φαίνεται να χρησιμοποιείται είναι αυτό του υπολογισμού των Cross-Power Spectral Densities (CPSDs) το οποίο προσθέτει πληροφορία σχετικά με τον συσχετισμό μεταξύ των voxel(ογκοστοιχείων)/κυψελών καυσίμου στο πλέγμα. Στην συνέχεια, κάνοντας χρήση αρχιτεκτονικών βαθιών τρισδιάστατων συνελκτικών δικτύων (Deep 3D-CNNs) [36] μέσω της κατάλληλης προσαρμογής των τελικών επιπέδων εξόδου του δικτύου (output layer) αλλά και της διαδικασίας εκπαίδευσης αυτών και τις κατάλληλες συναρτήσεις απωλειών και βελτιστοποίησης (loss, optimization functions) έχει παρατηρηθεί ότι μπορεί να επιτευχθούν αρκετά ακριβή αποτελέσματα ως προς τον εντοπισμό της πηγής ακόμη και παράλληλων διαταραχών.

Στο [37], προτείνεται μια μεθοδολογία που μετατρέπει τα σήματα από το πεδίο του χρόνου σε scalograms που βασίζονται σε wavelets. Ένα βαθύ CNN χρησιμοποιείται στη συνέχεια για να ταξινομήσει τα μετασχηματισμένα σήματα σε πολλαπλές κατηγορίες. Επιπλέον, έχει προστεθεί τυχαίος θόρυβος στα σήματα, σε διάφορα πλάτη, διασφαλίζοντας τις δυνατότητες γενίκευσης του μοντέλου και διασφαλίζοντας την ευρωστία του (robustness).

Σχετικά με την ανάλυση των σημάτων στο πεδίο του χρόνου, στο [38], παρουσιάζεται μια μεθοδολογία όπου τα σήματα των διαταραχών χρησιμοποιούνται για την εκπαίδευση ενός σχήματος ένα-εναντίον-όλων (one-vs-all) από ένα σύνολο 1D-CNN και Long-Short Term Memory (LSTM) νευρωνικών δικτύων. Αυτό το πλαίσιο χρησιμοποιείται αργότερα για τον εντοπισμό πολλαπλών διαταραχών στα σήματα του πυρήνα. Πραγματοποιείται επίσης ανάλυση θορύβου για τη βελτίωση της συνολικής ευρωστίας της προτεινόμενης μεθόδου.

Αξίζει να σημειωθεί πως η μετατροπή των δεδομένων στο πεδίο της συχνότητας προσθέτει ένα σημαντικό υπολογιστικό κόστος (overhead) ενώ ακόμη η χρήση των τρισδιάστατων δεδομένων προσθέτει στην πολυπλοκότητα των υπολογισμών. Συνεπώς, προκειμένου να μειωθεί η υπολογιστική πολυπλοκότητα με στόχο την χρήση αυτής σε πραγματικό χρόνο (real-time) από υπολογιστές περιορισμένης επεξεργαστικής ισχύος ή ακόμη και ενσωματωμένα κυκλώματα ειδικού σκοπού (FPGAs) θα πρέπει να προσεγγίσουμε το θέμα από διαφορετική σκοπιά. Για να το πετύχουμε αυτό, έχουμε αφαιρέσει ουσιαστικά μια διάσταση, μεταφερόμενοι από τον τρισδιάστατο χώρο στο επίπεδο. Η χρήση και ο υπολογισμός των CPSDs στα 3D-CNNs στην προκειμένη περίπτωση έχει αντικατασταθεί από τα ολισθούμενα παράθυρα της συνέλιξης των σημάτων στο πεδίο του χρόνου στα 1D-CNNs. Επομένως, στην παρούσα εργασία θα εργαστούμε με τα δεδομένα απευθείας στο πεδίο του χρόνου.

3.2 Αρχιτεκτονικές 1D-CNNs και 2D-CNN

Τα CNNs έχουν χρησιμοποιηθεί επιτυχώς από την ερευνητική κοινότητα στον τομέα των αισθητήρων (sensors) για την ανίχνευση δονήσεων σε μηχανικά μέρη [10, 9] απευθείας μέσω των σημάτων από τους αισθητήρες.

Σχετικά με τις αρχιτεκτονικές που έχουν χρησιμοποιηθεί, έγινε μελέτη τόσο μεταξύ 2D-CNNs όσο και μεταξύ διαφορετικών 1D-CNNs που έχουν χρησιμοποιηθεί στον παραπάνω τομέα, ενώ για την αναπαράσταση των δεδομένων και την κωδικοποίηση της εξόδου του δικτύου έχει γίνει μετατροπή με χρήση των One-Hot Encoding vectors, τα οποία έχουν άσσο στην συντεταγμένη που εντοπίζεται η κάθε διαταραχή σε κάθε άξονα και μηδέν σε όλες τις υπόλοιπες θέσεις.

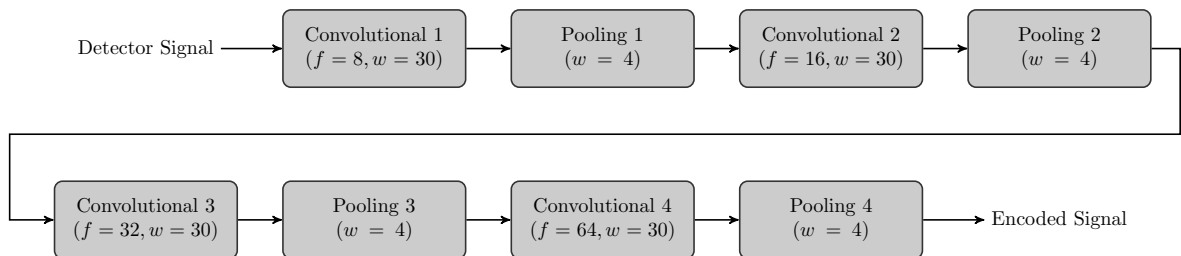
3.2.1 1D-CNNs

Ως προς τα 1D-CNNs, η μελέτη έγινε μεταξύ τριών αρχιτεκτονικών που έχουν προταθεί από την διεθνή βιβλιογραφία: δύο που έχουν χρησιμοποιηθεί στον τομέα της ανίχνευσης δονήσεων σε μηχανικά μέρη μέσω σημάτων από αισθητήρες [10, 9] καθώς και μιας σύζευξης των παραπάνω και προσαρμογής από εμάς (εφεξής custom).


Το 1D-CNN που χρησιμοποιείται στην εργασία αυτή περιέχει πολλαπλά μονοδιάστατα συνελκτικά στρώματα, με καθένα από αυτά να εκτελεί την (Εξίσωση 3.2) παρακάτω:

$$O_t^k = g\left(\sum_{i,j} w_k^{i,j} I_{t+i}^j + b\right) \quad (3.2)$$

όπου το O_t^k αντιπροσωπεύει την έξοδο k^{th} που αντιστοιχεί στη χρονική περίοδο t , το I_t^j αντιπροσωπεύει το j^{th} στα t , $w_k^{i,j}$ και b αντιπροσωπεύουν το συνελκτικό βάρος και την προκατάληψη του πυρήνα (bias) αντίστοιχα και το $g(\cdot)$ αντιπροσωπεύει μια συνάρτηση ενεργοποίησης (π.χ., ReLU, softmax).

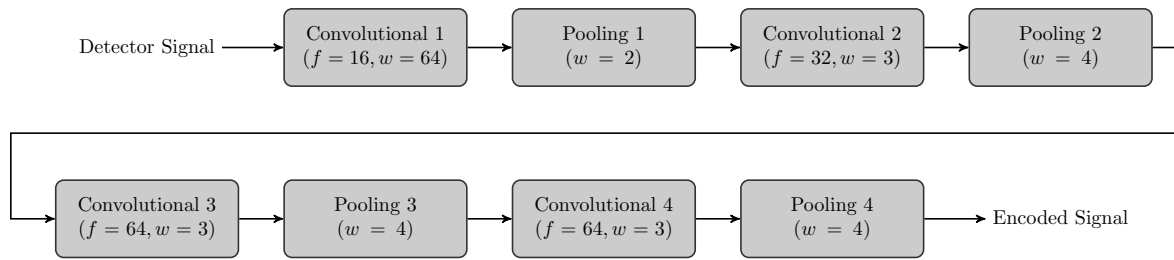


Σχήμα 3.2: Αρχιτεκτονική 1D-CNN όπως περιγράφεται στο [9]



Σχήμα 3.3: Αρχιτεκτονική 1D-CNN όπως περιγράφεται στο [10]

Συγκεκριμένα, οι παραπάνω αρχιτεκτονικές των Μονοδιάστατων Βαθιών Συνελκτικών Δικτύων αποτελούνται από τμήματα (blocks) τα οποία απαρτίζονται από ένα Μονοδιάστατο Συνελκτικό Φίλτρο/επίπεδο (1D-Convolutional Layer) με το σήμα εισόδου στην συνέχεια να κανονικοποιείται μέσω Κανονικοποίησης Παρτίδας (Batch Normalisation). Ως συνάρτηση ενεργοποίησης (activation function) έχει χρησιμοποιηθεί η ReLU, ενώ προκειμένου οι νευρώνες να μπορούν να γενικεύουν καλύτερα έχει



Σχήμα 3.4: Custom αρχιτεκτονική 1D-CNN

γίνει χρήση Dropout Layer σε μερικά blocks. Έπειτα οι έξοδοι από τα προηγούμενα επίπεδα περνούν από ένα Layer Max Pooling έτσι ώστε να μειωθεί η διάσταση του αποτελέσματος. Οι διαφορές μεταξύ των αρχιτεκτονικών εντοπίζονται κυρίως στο πλήθος αλλά και το μέγεθος και τις παραμέτρους των blocks. Τέλος μετά τα blocks, η κωδικοποιημένη πλέον είσοδος περνάει από ένα Πλήρως Συνδεδεμένο Νευρωνικό Δίκτυο με Εμπρόσθια Τροφοδότηση (FC-FNN) προτού κωδικοποιηθεί στην μορφή της εξόδου, στην οποία και γίνεται χρήση της συνάρτησης ενεργοποίησης softmax. Πιο συγκεκριμένα:


Στο (Σχήμα 3.2) το σήμα από κάθε αισθητήρα κωδικοποιείται μέσα από τέσσερα αλληπάλλληλα block με Συνελκτικά Φίλτρα μεγέθους 8, 16, 32 και 64 αντίστοιχα. Το μέγεθος του συνελκτικού πυρήνα (convolution kernel) είναι 30 για όλα τα φίλτρα και το stride ίσο με 1. Το κωδικοποιημένο σήμα περνάει μετά από ένα Fully-Connected Feedforward Neural Network που αποτελείται από 2 κρυφά επίπεδα (hidden layers) μεγέθους 128 και 32 αντίστοιχα.

Στο (Σχήμα 3.3) που προέρχεται από τον τομέα της ανίχνευσης σφάλματος σε αισθητήρες, το σήμα από κάθε αισθητήρα κωδικοποιείται μέσα από πέντε αλληπάλλληλα block με Συνελκτικά Φίλτρα αυξανόμενου μεγέθους από 16 σε 32 και 64. Το μέγεθος του πρώτου συνελκτικού πυρήνα (convolution kernel) είναι 64 ενώ για όλα τα επόμενα φίλτρα είναι ίσο με 3. Το κωδικοποιημένο σήμα περνάει στην συνέχεια από ένα FC-FNN που αποτελείται από ένα κρυφό επίπεδο μεγέθους 10, πριν το επίπεδο εξόδου που είναι αυτό που μας δίνει τελικά τις συντεταγμένες για τον εντοπισμό της διαταραχής.

Η τρίτη αρχιτεκτονική (Σχήμα 3.4) είναι το αποτέλεσμα της έρευνας στα πλαίσια αυτής της εργασίας και αποτελεί μια πρόσμιξη των προαναφερθέντων αρχιτεκτονικών υλοποιώντας ουσιαστικά μια απλουστευμένη εκδοχή της (Σχήμα 3.3) με ένα λιγότερο block (Συνελκτικό Φίλτρο με Pooling).

3.2.2 2D-CNN

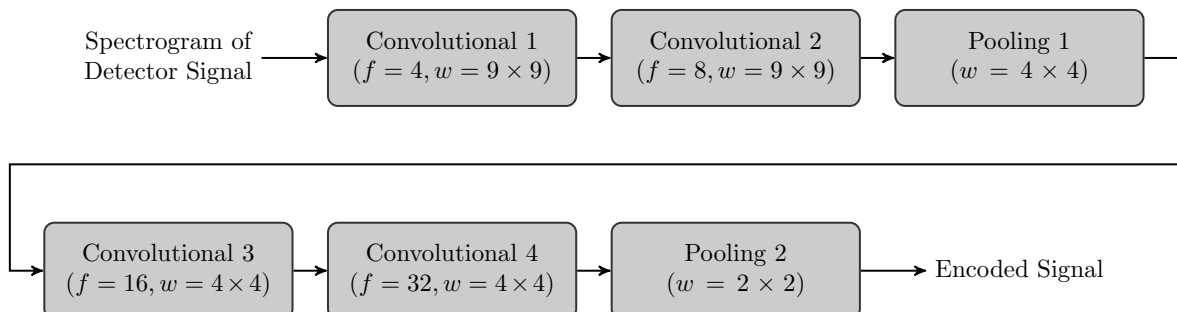
Για τα 2D-CNNs έχει γίνει πρώτα μετατροπή των δεδομένων στα αντίστοιχα φασματογραφήματα, αφού έχει γίνει η αφαίρεση της τάσης των σημάτων ενώ ως προς τα blocks της αρχιτεκτονικής αυτά παραμένουν ίδια με πριν με την αφαίρεση των dropout layers και την αλλαγή σε 2D-Convolutional Layer. Οι συναρτήσεις ενεργοποίησης σε όλα τα επίπεδα έχουν παραμείνει και αυτές ίδιες (ReLU, softmax).



Σχήμα 3.5: Παράδειγμα παραγωγής φασματογραφημάτων από τα σήματα των αισθητήρων, για διαφορετικές κυψέλες καυσίμου (και τις αντίστοιχες συντεταγμένες τους στο επίπεδο)

Η παρακάτω αρχιτεκτονική προέρχεται και αυτή από τον τομέα της ανίχνευσης δονήσεων σε μηχανικά μέρη μέσω αισθητήρων, όπως αυτή περιγράφεται στο [9] με μερικές απλοποιήσεις. Συγκεκριμένα:

Στο (Σχήμα 3.6) το σήμα από κάθε αισθητήρα αφού έχει μετατραπεί σε διδιάστατο φασματογράφημα όπως παρουσιάζεται παραπάνω, κωδικοποιείται μέσα από τέσσερα αλληλάλληλα block με Συνελκτικά Φίλτρα μεγέθους 4, 8, 16 και 32 αντίστοιχα. Το μέγεθος του συνελκτικού πυρήνα (convolution kernel) είναι (9×9) για τα πρώτα 2 επίπεδα ενώ για όλα τα επόμενα φίλτρα είναι ίσο με (4×4) και το stride ίσο με (2×2) σε όλα. Η κωδικοποιημένη απεικόνιση περνάει μετά από ένα FC-FNN που αποτελείται από 2 κρυφά επίπεδα (hidden layers) μεγέθους 64 και 32 αντίστοιχα. Όπως και στην προηγούμενη περίπτωση, η έξοδος μας δίνει τις συντεταγμένες στο επίπεδο της εντοπισμένης διαταραχής.



Σχήμα 3.6: Αρχιτεκτονική 2D-CNN όπως περιγράφεται στο [9]

3.3 Αυτο-Επιβλεπόμενη Προσαρμογή Πεδίου (SSDA)

Στις προηγούμενες ενότητες περιγράψαμε την χρήση των 1D-CNNs στον εντοπισμό των διαταραχών στο πλαίσιο της επιβλεπόμενης μάθησης και των συνθετικών δεδομένων. Παρόλα αυτά, όπως αναφέρεται και στο [34], δεν είναι αρκετό να εκπαιδεύσουμε το δίκτυο μόνο στα συνθετικά δεδομένα. Παρότι τα εργαλεία που έχουν χρησιμοποιηθεί από τις προσομοιώσεις για την παραγωγή των συνθετικών δεδομένων ορίζουν με μεγάλη ακρίβεια τις μεταβλητές περιβάλλοντος καθώς και τις συνθήκες λειτουργίας, η ύπαρξη διαφορών μεταξύ των κατανομών των πραγματικών και των συνθετικών δεδομένων, ευρύτερα γνωστή ως μετατόπιση πεδίου (domain shift) [39], είναι αναπόφευκτη. Πρακτικά, τα νευρωνικά δίκτυα μαθαίνουν τις αναπαραστάσεις για τα δεδομένα εισόδου που αντιστοιχούν στα δεδομένα κατά την διαδικασία της εκπαίδευσης (στην προκειμένη περίπτωση τα συνθετικά δεδομένα) και όταν δοθούν ως είσοδος δεδομένα από διαφορετική κατανομή (για παράδειγμα τα πραγματικά δεδομένα) τότε θα παραχθεί από το δίκτυο μια αναπαράσταση που θα καταλαμβάνει διαφορετική περιοχή στον χώρο αναπαράστασης των δεδομένων (embedding space). Επομένως, προκειμένου να μπορούμε να έχουμε έγκυρες εκτιμήσεις για τα πραγματικά δεδομένα θα πρέπει να προσαρμόσουμε το δίκτυο έτσι ώστε να εναρμονίζονται οι αναπαραστάσεις μεταξύ των διαφορετικών κατανομών στον ήδη υπάρχον χώρο που έχει δημιουργηθεί από τα συνθετικά δεδομένα.

Για να το πετύχουμε αυτό έχουμε εργαστεί την μέθοδο της Αυτο-Επιβλεπόμενης Προσαρμογής Πεδίου (Self-Supervised Domain Adaptation) [40], όπως αυτή παρουσιάζεται στο [34]. Σκοπός της συγκεκριμένης προσέγγισης είναι η εναρμόνιση των χώρων μεταξύ των συνθετικών και των πραγματικών δεδομένων, χωρίς όμως την ανάγκη για ανθρώπινη παρέμβαση προκειμένου να γίνει η επισήμανση και κατηγοριοποίηση των πραγματικών δεδομένων, πράγμα το οποίο εκ φύσης είναι σχεδόν αδύνατο δεδομένης της πολυπλοκότητας του προβλήματος καθώς και του όγκου των δεδομένων. Αντ' αυτού, χρησιμοποιούμε βοηθητικές εργασίες (auxiliary tasks) παράλληλα με την κύρια (εντοπισμός διαταραχών) προκειμένου να ευθυγραμμίσουμε τις αναπαραστάσεις των διαφορετικών κατανομών βελτιστοποιώντας κοινούς στόχους μεταξύ των τομέων.

3.3.1 Βοηθητικές εργασίες (Auxiliary tasks)

Οι βοηθητικές εργασίες κατασκευάζονται από τα ίδια τα δεδομένα χωρίς την ανάγκη ανθρώπινης επισήμανσης και ορίζονται για να βοηθήσουν ειδικά το δίκτυο να συλλάβει αναπαραστάσεις που είναι γνωστό ότι είναι κοινές μεταξύ των δύο πεδίων (όπως για παράδειγμα δομικών διαφορών ή μετα-δεδομένων). Ουσιαστικά εκπαιδεύουμε το δίκτυό μας να προβλέπει πανομοιότυπες εξόδους για τις βοηθητικές εργασίες, δεδομένου τόσο ενός προσομοιωμένου όσο και ενός πραγματικού δείγματος, το οποίο κατασκευάζει μια αντιστοίχιση εισόδου-εξόδου που είναι σε μεγάλο βαθμό πανομοιότυπη και για τους δύο τομείς όπως αυτό εξηγείται και στο [41].


Στην προκειμένη περίπτωση έχουμε χρησιμοποιήσει μια βοηθητική εργασία όπου αποκρύπτουμε τυχαία ένα τμήμα του σήματος εισόδου σε όλους τους ανιχνευτές και αναθέτουμε στο δίκτυο να προβλέψει το τμήμα του σήματος που λείπει. Η παραπάνω βοηθητική εργασία είναι εμπνευσμένη από τον τρόπο που έχει παρατηρηθεί πως ο ανθρώπινος εγκέφαλος μαθαίνει πράγματα για το περιβάλλον γύρω του, κάνοντας δηλαδή εκτιμήσεις για τις (μελλοντικές) καταστάσεις και συνθήκες [42], ενώ έχει εφαρμοστεί επιτυχώς και στους τομείς της Επεξεργασίας Φυσικής Γλώσσας (Natural Language Processing) σε γλωσσικά μοντέλα [43] καθώς και σε βίντεο [44]. Πιο συγκεκριμένα, η πρόβλεψη γίνεται δίνοντας ως είσοδο το πρώτο μισό ενός σήματος από τους ανιχνευτές και προβλέποντας το υπόλοιπο μισό, μετρώντας την απόκλιση από την πραγματική τιμή για κάθε δείγμα.

Κεφάλαιο 4


Εκπαίδευση νευρωνικών δικτύων και αποτελέσματα

4.1 Διαδικασία εκπαίδευσης επιβλεπόμενης μάθησης

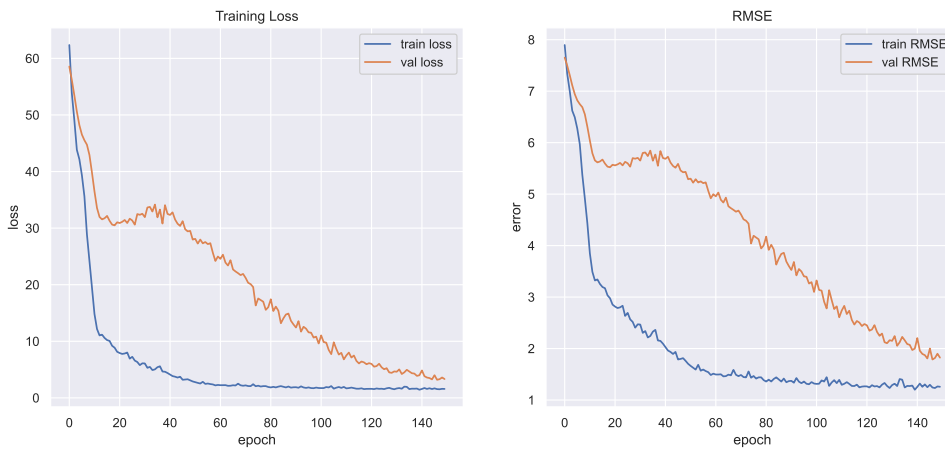
Η εκπαίδευση για όλες τις αρχιτεκτονικές έχει γίνει για 150 εποχές με Batch Size = 32. Η έξοδος του δικτύου ουσιαστικά αποτελεί τις συντεταγμένες x και y της κυψέλης καυσίμου στο επίπεδο στην οποία εντοπίζεται η διαταραχή. Ως συνάρτηση βελτιστοποίησης (optimizer) έχει γίνει χρήση του Adam [33] ενώ για συνάρτηση απώλειας (loss function) έχει γίνει χρήση του Μέσου Τετραγωνικού Σφάλματος (Mean Squared Error) το οποίο και κωδικοποιεί ουσιαστικά την έννοια της απόστασης μεταξύ των σημείων κατά την διάρκεια της εκπαίδευσης. Οι εκτιμήσεις για την απόδοση του δικτύου γίνονται με βάση την μετρική της Ρίζας του Μέσου Τετραγωνικού Σφάλματος (Root Mean Squared Error), τόσο στα test όσο και στα validation σύνολα δεδομένων. Για την μέτρηση της απόδοσης έχει γίνει χρήση ενός test συνόλου το οποίο προέρχεται από το εκάστοτε αρχικό με αναλογία training/test: 80/20, ενώ για το validation κατά την διάρκεια της εκπαίδευσης έχει γίνει επίσης χρήση αναλογίας 80/20 στα training δεδομένα.



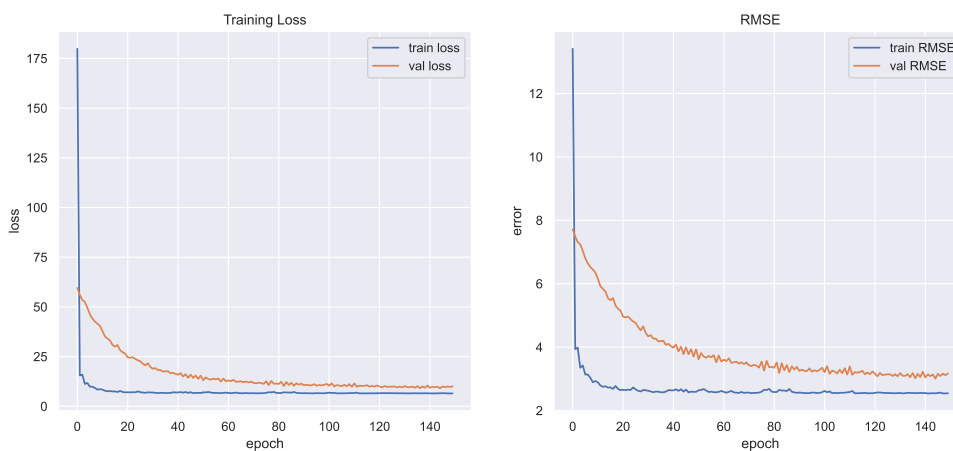
Σχήμα 4.1: Μετρικές εκπαίδευσης στα training και validation δεδομένα για την 1D-CNN αρχιτεκτονική (Σχήμα 3.2) στο σενάριο S1 για MOC39



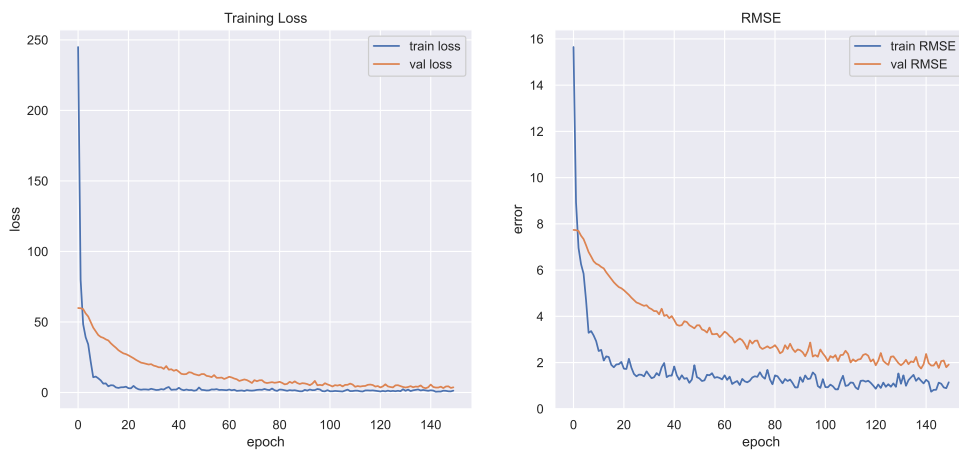
Σχήμα 4.2: Μετρικές εκπαίδευσης στα training και validation δεδομένα για την 1D-CNN αρχιτεκτονική (Σχήμα 3.3) στο σενάριο S1 για MOC39



Σχήμα 4.3: Μετρικές εκπαίδευσης στα training και validation δεδομένα για την 2D-CNN αρχιτεκτονική (Σχήμα 3.6) στο σενάριο S3 για MOC39



Σχήμα 4.4: Μετρικές εκπαίδευσης στα training και validation δεδομένα για την προτεινόμενη από αυτή την εργασία 1D-CNN αρχιτεκτονική (Σχήμα 3.4) στο σενάριο S1 για MOC39



Σχήμα 4.5: Μετρικές εκπαίδευσης στα training και validation δεδομένα για την προτεινόμενη από αυτή την εργασία 1D-CNN αρχιτεκτονική (Σχήμα 3.4) στο σενάριο S3 για MOC39

4.2 Αποτελέσματα επιβλεπόμενης μάθησης

Τα αποτελέσματα μετά από την εκπαίδευση των παραπάνω αρχιτεκτονικών συνοψίζονται παρακάτω στον (Πίνακα 4.1) και τον (Πίνακα 4.2):

Σενάριο	1D-CNN [9]	2D-CNN [9]	1D-CNN [10]	Custom
S1	2.73	1.71	3.28	2.93
S2	3.45	2.05	3.03	1.81
S3	3.33	1.77	2.77	2.08


Πίνακας 4.1: Ακρίβεια εντοπισμού (εκφρασμένη σε RMSE) για διαφορετικές αρχιτεκτονικές ανα σενάριο σε MOC39

Σενάριο	1D-CNN [9]	2D-CNN [9]	1D-CNN [10]	Custom
S1	3.49	2.21	4.03	1.70
S2	3.13	2.35	3.42	1.65

Πίνακας 4.2: Ακρίβεια εντοπισμού (εκφρασμένη σε RMSE) για διαφορετικές αρχιτεκτονικές ανα σενάριο σε BOC40

Παρατηρούμε πως στις ίδιες συνθήκες εκπαίδευσης (ίδιος κύκλος λειτουργίας, ίδιες εποχές) η προτεινόμενη από αυτή την εργασία custom αρχιτεκτονική παρουσιάζει βελτίωση έναντι τόσο των άλλων 1D-CNN αρχιτεκτονικών αλλά και της 2D-CNN, μειώνοντας το σφάλμα εντοπισμού της εκάστοτε διαταραχής.

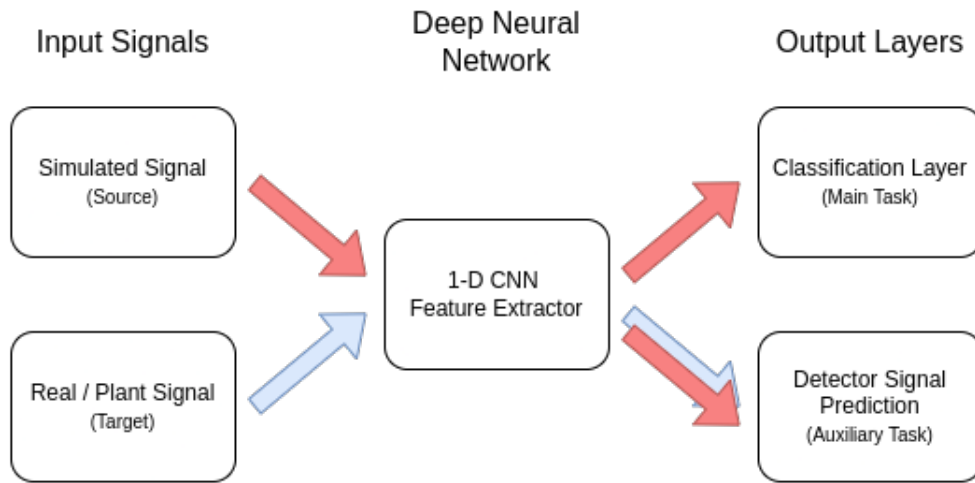
Παράλληλα στο (Σχήμα 4.6) παρουσιάζεται μια ενδεικτική εκτίμηση για τον εντοπισμό της διαταραχής στο test σύνολο των συνθετικών δεδομένων, σε σύγκριση με την πραγματική θέση της διαταραχής.



Σχήμα 4.6: Εκτίμηση στα συνθετικά δεδομένα με βάση το εκπαιδευμένο δίκτυο. Η δονούμενη κυψέλη καυσίμου εντοπίζεται στην θέση *K06* (πράσινο χρώμα), με την εκτιμώμενη να είναι η *L06* (κόκκινο χρώμα)

4.3 Διαδικασία εκπαίδευσης αυτο-επιβλεπόμενης μάθησης

Για την εκπαίδευση μέσω της αυτο-επιβλεπόμενης μάθησης έχει γίνει χρήση μόνο της custom 1D-CNN αρχιτεκτονικής, όπως αυτή περιγράφηκε προηγουμένως. Ο αρχιτεκτονικός σχεδιασμός της αυτο-επιβλεπόμενης προσαρμογής πεδίου απεικονίζεται στο (Σχήμα 4.7). Στο μονοδιάστατο CNN δίνεται ως είσοδος τόσο ένα προσομοιωμένο όσο και ένα πραγματικό σήμα, τα οποία έχουν επεξεργαστεί τυχαία σύμφωνα με την διαδικασία της βοηθητικής εργασίας που προαναφέρθηκε, με την έξοδό του να δίνεται στη συνέχεια στην βοηθητική εργασία και την βασική εργασία του εντοπισμού των διαταραχών να λαμβάνει μόνο τα προσομοιωμένα σήματα.



Σχήμα 4.7: Διαδικασία εκπαίδευσης του 1D-CNN μοντέλου στα συνθετικά και πραγματικά δεδομένα και ροή πληροφοριών στο δίκτυο

Η συνάρτηση προς ταυτόχρονη βελτιστοποίηση είναι τότε το σταθμισμένο άθροισμα όλων των επιμέρους εργασιών με αυτήν να περιγράφεται ως εξής:

$$\mathcal{L}(y_s, y_{aux}, \hat{y}_s, \hat{y}_{aux}) = \lambda_{CE} \cdot \mathcal{L}_{CE}(y_s, \hat{y}_s) + \lambda_{aux} \cdot \mathcal{L}_{aux}(y_{aux}, \hat{y}_{aux}) \quad (4.1)$$

όπου το y και το \hat{y} αντιπροσωπεύουν την προβλεπόμενη και την αναμενόμενη τιμή αντίστοιχα, το \mathcal{L}_{aux} αναφέρεται στη βοηθητική εργασία, το \mathcal{L}_{CE} υποδηλώνει την κύρια εργασία εντοπισμού μέσω softmax, τα λ_{CE} και λ_{aux} είναι πολλαπλασιαστικές σταθερές κάθε εργασίας και οι δείκτες s, aux υποδηλώνουν την είσοδο και την έξοδο για την εργασία του εντοπισμού και την βοηθητική εργασία.

Για την διαδικασία της εκτίμησης/πρόβλεψης χρησιμοποιείται μόνο το κύριο task εντοπισμού, αγνοώντας το auxiliary task και τις επαυξήσεις που σχετίζονται με αυτό.


Η διαδικασία της εκπαίδευσης έχει γίνει με παρόμοιο τρόπο με αυτόν που περιγράφεται στην (Ενότητα 4.1), με το μονοδιάστατο δίκτυο CNN να είναι προεκπαιδευμένο (αρχικοποιήθηκε με τις παραμέτρους από την εκπαίδευση μόνο σε προσομοιωμένα δεδομένα από την (Ενότητα 4.2)) (transfer learning) και στη συνέχεια να γίνει fine-tune μέσω της διαδικασίας προσαρμογής αυτο-επιβλεπόμενου πεδίου. Αυτή η λεπτομέρεια επιτρέπει την πλήρη εκμετάλλευση των προσομοιωμένων δεδομένων, για την παροχή καλύτερης απόδοσης στο task εντοπισμού με τα πραγματικά δεδομένα.

Το προαναφερθέν δίκτυο έχει εκπαιδευτεί τόσο σε προσομοιωμένες διαταραχές όσο και σε πραγματικές μετρήσεις του πυρήνα του Ελβετικού 3-loop Pre-KONVOI PWR αντιδραστήρα (Gösgen), χρησιμοποιώντας τον βελτιστοποιητή Adam [33] για 100 εποχές και ρυθμό εκμάθησης ίσο με 0,001.

Οι συντελεστές στάθμισης έχουν επιλεγεί εμπειρικά να είναι $\lambda_{CE} = 0.5$ και $\lambda_{aux} = 0.5$, εξισορροπώντας εξίσου τη βελτιστοποίηση μεταξύ της εργασίας του εντοπισμού και της ευθυγράμμισης των αναπαραστάσεων μέσω της βοηθητικής εργασίας.

4.4 Αποτελέσματα αυτο-επιβλεπόμενης μάθησης

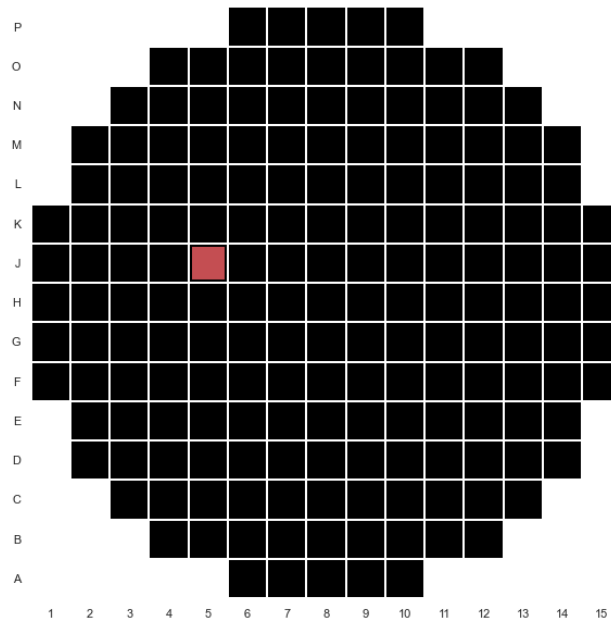
Η εκπαίδευση της custom αρχιτεκτονικής (Σχήμα 3.4) με την μέθοδο της αυτο-επιβλεπόμενης μάθησης συνοψίζεται στο παρακάτω γράφημα:



Σχήμα 4.8: Γραφική απεικόνιση των κανονικοποιημένων απωλειών (MSE) κατά την διάρκεια της εκπαίδευσης

Παρατηρούμε πως στο (Σχήμα 4.8) όπου και παρουσιάζονται οι κανονικοποιημένες απωλειες (MSE) των επιμέρους τμημάτων του δικτύου (όπως αυτές περιγράφονται παραπάνω) κατά την διάρκεια της εκπαίδευσης, η συνολική καθώς και οι επιμέρους απώλειες για κάθε task ακολουθούν φθίνουσα πορεία πράγμα που ενισχύει τόσο το γεγονός ότι το δίκτυο μαθαίνει επιτυχώς όσο και ότι οι κατανομές των δύο κατηγοριών δεδομένων που έχουμε διαθέσιμες (συνθετικά και πραγματικά) έχουν ευθυγραμμιστεί.

Τέλος, στο Σχήμα 4.9 παρουσιάζεται μια ενδεικτική εκτίμηση για την ύπαρξη διαταραχής στον πυρήνα με βάση τα πραγματικά δεδομένα (BOC40).



Σχήμα 4.9: Εκτίμηση στα πραγματικά δεδομένα με βάση το εκπαιδευμένο δίκτυο με εντοπισμό πιθανής διαταραχής στην κυψέλη καυσίμου J05

Κεφάλαιο 5

Συμπεράσματα και μελλοντικές κατευθύνσεις

5.1 Συμπεράσματα

Η παρούσα εργασία έρχεται να συμπληρώσει την ήδη υπάρχουσα έρευνα που γίνεται γύρω από το καίριο πρόβλημα της επίβλεψης της λειτουργίας των πυρηνικών αντιδραστήρων.

Συγκεκριμένα, στα πλαίσια αυτής της εργασίας εξετάσαμε την αποδοτικότητα των 1D-CNNs στον εντοπισμό των συντεταγμένων των διαταραχών που εντοπίζονται σε έναν Ελβετικό Pre-KONVOI PWR αντιδραστήρα τριών κύκλων (KKG) μέσω του νετρονιακού θορύβου από τα σήματα των αισθητήρων στο συνθετικό περιβάλλον, παρουσιάζοντας και προτείνοντας μια αρχιτεκτονική η οποία και ελαττώνει σημαντικά το σφάλμα εντοπισμού διαταραχής έως και 1.65. Ταυτόχρονα, παρουσιάζεται η αποδοτικότητα των προαναφερθέντων αρχιτεκτονικών σε σύγκριση με την πλέον διαδεδομένη από την επιστημονική κοινότητα μεθοδολογία των 2D-CNN στα φασματογραφήματα από τα σήματα των αισθητήρων.

Παράλληλα, προκειμένου να μπορέσουμε να κάνουμε εκτιμήσεις στα πραγματικά δεδομένα έχει υλοποιηθεί μια μέθοδος Αυτο-επιβλεπόμενης Προσαρμογής Πεδίου (SSDA) προκειμένου να γίνει εναρμόνιση των συνθετικών και των πραγματικών δεδομένων (που δεν έχουν επισημάνσεις) χωρίς να γίνει ανθρώπινη παρέμβαση. Ως βοηθητική εργασία έχει χρησιμοποιηθεί η πρόβλεψη των σημάτων των αισθητήρων δεδομένου ενός χρονικού διαστήματος, το οποίο και παρουσιάζει θετικά αποτελέσματα ως προς την εναρμόνιση των πεδίων των κατανομών των δεδομένων. Μετά από την συνολική εκπαίδευση του δικτύου βάση του pipeline που παρουσιάζεται έχει γίνει εκτίμηση στα πραγματικά δεδομένα που έχουν συλλεχθεί, όπου και φαίνεται η ύπαρξη ενδεχόμενης διαταραχής στην κυψέλη καυσίμου J05.

Η μέθοδος που παρουσιάζεται σε αυτή την εργασία έρχεται ως επικουρική στην διαδικασία της επίβλεψης της λειτουργίας των αντιδραστήρων, μιας και ουσιαστικά ο εντοπισμός γίνεται σε δισδιάστατο επίπεδο ως προς τις κυψέλες καυσίμου ενώ για την μέτρηση της απόδοσης της μεθόδου έχει γίνει χρήση του RMSE το οποίο μπορεί να μας δείξει με αρκετά καλή ακρίβεια την περιοχή από όπου ξεκίνησε μια διαταραχή και όχι απαραίτητα την συγκεκριμένη κυψέλη καυσίμου.

Τμήμα της παρούσας εργασίας έχει συμπεριληφθεί στην υποβολή με τίτλο *”Deep learning techniques for in-core perturbation identification and localization of time-series nuclear plant measurements”* στο Annals of Nuclear Energy Special Journal on Machine Learning.

5.2 Μελλοντικές κατευθύνσεις

Παρότι οι μέθοδοι που περιγράφονται σε αυτή την εργασία δείχνουν ενθαρρυντικά αποτελέσματα, υπάρχουν τομείς οι οποίοι απαιτούν επαλήθευση ή και βελτιστοποίηση.

Ο πρώτος τομέας έχει να κάνει με την επιλογή των υπερ-παραμέτρων που αφορούν τόσο τις αρχιτεκτονικές όσο και την εκπαίδευση. Αν και έχει γίνει μελέτη η οποία βασίζεται και στην διεθνή βιβλιογραφία, αξίζει να ελεγχθεί εάν οι διαδικασίες που περιγράφονται στην παρούσα εργασία επιδέχονται περαιτέρω βελτιστοποίηση.

Ο δεύτερος τομέας αφορά την διαδικασία της Αυτο-επιβλεπόμενης Προσαρμογής Πεδίου και την επιλογή των βοηθητικών εργασιών. Παρόλο που τα αποτελέσματα ως προς την προσαρμογή των πεδίων των δεδομένων είναι αρκετά καλά, μπορεί να διερευνηθεί η χρήση και άλλων βοηθητικών εργασιών παράλληλα με αυτό που παρουσιάζεται παραπάνω. Οι εργασίες αυτές θα μπορούσαν να αφορούν την αφαίρεση κάποιων αισθητήρων και την πρόβλεψη είτε του σήματος από αυτούς είτε και της θέση του αισθητήρα που έχει αφαιρεθεί ή ακόμη και την απόκρυψη κάποιων τυχαίων τμημάτων του σήματος από τους αισθητήρες (όπως γίνεται και στην εκπαίδευση των γλωσσικών μοντέλων [42]).

Βιβλιογραφία

- [1] W. N. Association, Mar 2022. [Online]. Available: <https://world-nuclear.org/information-library/nuclear-fuel-cycle/nuclear-power-reactors/nuclear-power-reactors.aspx>
- [2] J. Pohlus, J. U. Paquee, and G. Girardin, “Report about the measurement results of goesgen,” CORTEX deliverable D4.1, Tech. Rep., 2018.
- [3] R. Ferrer, “Casm0-5 methodology manual,” (SSP-08/405 - Rev 4), Tech. Rep., 2015.
- [4] G. Grandi, “Simulate-3k models & methodology,” (SSP-98/13 Rev. 7), Tech. Rep., 2011.
- [5] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. MIT Press, 2016, <http://www.deeplearningbook.org>.
- [6] Y. LeCun and Y. Bengio, *Convolutional Networks for Images, Speech, and Time Series*. Cambridge, MA, USA: MIT Press, 1998, p. 255–258.
- [7] G. Hossein and K. Hossein, “Pooling methods in deep neural networks, a review,” 2020.
- [8] A. Amini, A. Soleimany, S. Karaman, and D. Rus, “Spatial uncertainty sampling for end-to-end control,” 05 2018.
- [9] H.-Y. Chen and C.-H. Lee, “Deep learning approach for vibration signals applications,” *Sensors*, vol. 21, no. 11, p. 3929, 2021.
- [10] W. Zhang, G. Peng, C. Li, Y. Chen, and Z. Zhang, “A new deep learning model for fault diagnosis with good anti-noise and domain adaptation ability on raw vibration signals,” *Sensors*, vol. 17, no. 2, p. 425, 2017.
- [11] Eurostat, Jan 2022. [Online]. Available: https://ec.europa.eu/eurostat/statistics-explained/index.php/Nuclear_energy_statistics
- [12] J. Ma and J. Jiang, “Applications of fault detection and diagnosis methods in nuclear power plants: A review,” *Progress in Nuclear Energy*, vol. 53, no. 3, pp. 255 – 266, 2011. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0149197010001769>
- [13] C. Demazière, A. Mylonakis, P. Vinai, A. Durrant, F. D. S. Ribeiro, J. A. Wingate, G. Leontidis, and S. Kollias, “Neutron noise-based anomaly classification and localization using machine learning,” in *Proceedings of International Conference on Physics of Reactors (PHYSOR 2020: Transition to a Scalable Nuclear Future)*, Cambridge, UK, March 29th - April 2nd, 2020, 2020.
- [14] F. D. Ribeiro, F. Caliva, D. Chionis, A. Dokhane, A. Mylonakis, C. Demaziere, G. Leontidis, and S. Kollias, “Towards a deep unified framework for nuclear reactor perturbation analysis,” *2018 IEEE Symposium Series on Computational Intelligence (SSCI)*, 2018.
- [15] C. Demaziere, P. Vinai, M. Hursin, S. Kollias, and J. Herb, “Overview of the cortex project,” ser. PHYSOR 2018: reactor physics paving the way towards more efficient systems. Mexico: Sociedad Nuclear Mexicana, 2018.
- [16] P. D. Wilson, *The Nuclear Fuel Cycle*. Oxford University Press, 1996.

- [17] N. L. Char and B. J. Csik, *Nuclear power development: History and outlook*. IAEA, Sep 1987.
- [18] Y. Roh, G. Heo, and S. E. Whang, “A survey on data collection for machine learning: A big data - ai integration perspective,” *IEEE Transactions on Knowledge and Data Engineering*, vol. 33, no. 4, p. 1328–1347, 2021.
- [19] A. Mylonakis, P. Vinai, and C. Demazière, “Core sim+: A flexible diffusion-based solver for neutron noise simulations,” *Annals of Nuclear Energy*, vol. 155, p. 108149, 2021. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0306454921000256>
- [20] J. A. Thie, *Power reactor noise*, 1 1981. [Online]. Available: <https://www.osti.gov/biblio/5239676>
- [21] D. Chionis, A. Dokhane, L. Belblidia, H. Ferroukhi, G. Girardin, and A. Pautz, “Development and verification of a methodology for neutron noise response to fuel assembly vibrations,” *Annals of Nuclear Energy*, vol. 147, p. 107669, 2020. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0306454920303674>
- [22] C. Demaziere and A. Dokhane, “Cortex deliverable d3.1: Description of scenarios for the simulated data,” Core monitoring techniques and experimental validation and demonstration (CORTEX), Horizon 2020 EU Framework Programm (No. 754316), deliverable D3.1, 2019.
- [23] M. Kuentzel, P. Stulik, M. Seidl, S. Lipcsei, G. Girardin, and B. Schumaker, “Cortex deliverable 4.2: Core data for steady state calculations,” Core monitoring techniques and experimental validation and demonstration (CORTEX), Horizon 2020 EU Framework Programm (No. 754316), deliverable D4.2, 2018.
- [24] F. Rosenblatt, “The perceptron: A probabilistic model for information storage and organization in the brain.” *Psychological Review*, vol. 65, no. 6, p. 386–408, 1958.
- [25] B. Akkaya and N. Çolakoğlu, “Comparison of multi-class classification algorithms on early diagnosis of heart diseases,” 09 2019.
- [26] P. Comon and C. Jutten, *Handbook of Blind Source Separation: Independent Component Analysis and Applications*, 1st ed. USA: Academic Press, Inc., 2010.
- [27] K. Fukushima, “Neocognitron: A hierarchical neural network capable of visual pattern recognition,” *Neural Networks*, vol. 1, no. 2, pp. 119–130, 1988. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/0893608088900147>
- [28] Y. LeCun, B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard, and L. D. Jackel, “Backpropagation applied to handwritten zip code recognition,” *Neural Computation*, vol. 1, pp. 541–551, 1989.
- [29] Y. LeCun, P. Haffner, L. Bottou, and Y. Bengio, “Object recognition with gradient-based learning,” in *Feature Grouping*, D. Forsyth, Ed. Springer, 1999, (original is ps).
- [30] S. Ioffe and C. Szegedy, “Batch normalization: Accelerating deep network training by reducing internal covariate shift,” *CoRR*, vol. abs/1502.03167, 2015. [Online]. Available: <http://arxiv.org/abs/1502.03167>
- [31] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, “Dropout: a simple way to prevent neural networks from overfitting,” *The Journal of Machine Learning Research*, vol. 15, no. 1, pp. 1929–1958, 2014.
- [32] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, “Learning Representations by Back-propagating Errors,” *Nature*, vol. 323, no. 6088, pp. 533–536, 1986. [Online]. Available: <http://www.nature.com/articles/323533a0>

- [33] D. P. Kingma and J. Ba, “Adam: A method for stochastic optimization,” *arXiv preprint arXiv:1412.6980*, 2014.
- [34] A. Durrant, G. Leontidis, S. Kollias, L. Torres, C. Montalvo, A. Mylonakis, C. Demazière, and P. Vinai, “DETECTION AND LOCALISATION OF MULTIPLE IN-CORE PERTURBATIONS WITH NEUTRON NOISE-BASED SELF- SUPERVISED DOMAIN ADAPTATION,” *American Nuclear Society*, Oct. 2021. [Online]. Available: <https://doi.org/10.13182/M&C21-33650>
- [35] P. Welch, “The use of fast fourier transform for the estimation of power spectra: A method based on time averaging over short, modified periodograms,” *IEEE Transactions on Audio and Electroacoustics*, vol. 15, no. 2, pp. 70–73, 1967.
- [36] A. Durrant, G. Leontidis, and S. Kollias, “3d convolutional and recurrent neural networks for reactor perturbation unfolding and anomaly detection,” *EPJ Nuclear Sciences & Technologies*, 2019.
- [37] T. Tagaris, G. Ioannou, M. Sdraka, G. Alexandridis, and A. Stafylopatis, “Putting together wavelet-based scaleograms and convolutional neural networks for anomaly detection in nuclear reactors,” in *Proceedings of the 2019 3rd International Conference on Advances in Artificial Intelligence*, ser. ICAAI 2019. New York, NY, USA: Association for Computing Machinery, 2019, p. 237–243. [Online]. Available: <https://doi.org/10.1145/3369114.3369121>
- [38] G. Ioannou, T. Tagaris, G. Alexandridis, and A. Stafylopatis, “Intelligent techniques for anomaly detection in nuclear reactors,” *EPJ Web Conf.*, vol. 247, p. 21011, 2021. [Online]. Available: <https://doi.org/10.1051/epjconf/202124721011>
- [39] Y. Luo, L. Zheng, T. Guan, J. Yu, and Y. Yang, “Taking a closer look at domain shift: Category-level adversaries for semantics consistent domain adaptation,” in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2019, pp. 2507–2516.
- [40] Y. Sun, E. Tzeng, T. Darrell, and A. A. Efros, “Unsupervised domain adaptation through self-supervision,” *arXiv preprint arXiv:1909.11825*, 2019.
- [41] M. Thota, S. Kollias, M. Swainson, and G. Leontidis, “Multi-source domain adaptation for quality control in retail food packaging,” *Computers in Industry*, vol. 123, p. 103293, 2020.
- [42] Y. LeCun and I. Misra, Mar 2021. [Online]. Available: <https://ai.facebook.com/blog/self-supervised-learning-the-dark-matter-of-intelligence/>
- [43] H. Fang and P. Xie, “Cert: Contrastive self-supervised learning for language understanding,” 2020.
- [44] L. Huang, Y. Liu, B. Wang, P. Pan, Y. Xu, and R. Jin, “Self-supervised video representation learning by context and motion decoupling,” *2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2021.

Παράρτημα Α

Ευρετήριο συντομογραφιών

ML : Μηχανική Μάθηση (Machine Learning)

AI : Τεχνητή Νοημοσύνη (Artificial Intelligence)

SSL : Αυτο-επιβλεπόμενη μάθηση (Self-Supervised Learning)

DA : Προσαρμογή πεδίου (Domain Adaptation)

FNN : Νευρωνικό Δίκτυο με Εμπρόσθια Τροφοδότηση (Feedforward Neural Network)

1D-CNN : Μονοδιάστατα συνελκτικά νευρωνικά δίκτυα

2D-CNN : Δισδιάστατα συνελκτικά νευρωνικά δίκτυα

FA : Κυψέλη καυσίμου (Fuel Assembly)

BOC : Αρχή του κύκλου λειτουργίας (Beginning-of-cycle)

MOC : Μέση του κύκλου λειτουργίας (Middle-of-cycle)