



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

Σχολή Ηλεκτρολόγων Μηχανικών και
Μηχανικών Υπολογιστών

Τομέας Ηλεκτρικών Βιομηχανικών
Διατάξεων & Συστημάτων
Αποφάσεων

Ανάπτυξη μοντέλων μηχανικής μάθησης για παραγωγή δεδομένων σε φωτοβολταϊκά πάρκα

Αθανάσιος Σαμπάνης

Επιβλέπων: Ευάγγελος Μαρινάκης
Επίκουρος Καθηγητής, ΕΜΠ

Αθήνα, Οκτώβριος, 2025



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

Σχολή Ηλεκτρολόγων Μηχανικών και
Μηχανικών Υπολογιστών

Τομέας Ηλεκτρικών Βιομηχανικών
Διατάξεων & Συστημάτων
Αποφάσεων

Ανάπτυξη μοντέλων μηχανικής μάθησης για παραγωγή δεδομένων σε φωτοβολταϊκά πάρκα

Αθανάσιος Σαμπάνης

Επιβλέπων: Ευάγγελος Μαρινάκης
Επίκουρος Καθηγητής, ΕΜΠ

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 16η Οκτωβρίου 2025

Ευάγγελος Μαρινάκης
Επίκουρος Καθηγητής, ΕΜΠ

Δημήτριος Ασκούνης
Καθηγητής, ΕΜΠ

Ευάγγελος Σπηλιώτης
Επίκουρος Καθηγητής, ΕΜΠ

Αθήνα, Οκτώβριος, 2025

Αθανάσιος Σαμπάνης

Διπλωματούχος Ηλεκτρολόγος Μηχανικός και Μηχανικός Υπολογιστών Ε.Μ.Π

Copyright © Αθανάσιος Σαμπάνης, 2025

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας, εξ ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για σκοπό μη κερδοσκοπικό, εκπαιδευτικής ή ερευνητικής φύσης, υπό την προϋπόθεση να αναφέρεται η πηγή προέλευσης και να διατηρείται το παρόν μήνυμα.

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.

στον πατέρα μου

Περίληψη

Η έλλειψη μεγάλων, δημόσια διαθέσιμων συνόλων δεδομένων από πραγματικά φωτοβολταϊκά πάρκα αποτελεί σημαντικό εμπόδιο στην ανάπτυξη μεθόδων μηχανικής μάθησης για την πρόβλεψη της παραγωγής ισχύος. Επιπλέον, σε αρκετές εγκαταστάσεις εφαρμόζεται αναγκαστικός περιορισμός παραγωγής, με αποτέλεσμα οι διαθέσιμες μετρήσεις να μην αντικατοπτρίζουν την πραγματική δυναμικότητα του συστήματος. Αντίστοιχα, σε πάρκα που βρίσκονται στο στάδιο του σχεδιασμού απουσιάζουν πλήρως ιστορικά δεδομένα, γεγονός που περιορίζει την αξιοπιστία τεχνικοοικονομικών αναλύσεων και την υποστήριξη λήψης αποφάσεων. Στο πλαίσιο αυτό, η παρούσα διπλωματική εργασία επικεντρώνεται στην ανάπτυξη μοντέλων για την παραγωγή συνθετικών δεδομένων της ημερήσιας καμπύλης ισχύος, βασισμένων σε μετεωρολογικά και γεωμετρικά δεδομένα της ίδιας ημέρας, χωρίς τη χρήση ιστορικών μετρήσεων εξόδου. Τα μοντέλα αξιοποιούν στατικές και δυναμικές παραμέτρους του φωτοβολταϊκού συστήματος, κατάλληλα κανονικοποιημένες ώστε να μπορούν να εφαρμοστούν σε πάρκα διαφορετικής ισχύος και διάταξης. Ιδιαίτερη έμφαση δίνεται στη δημιουργία δεδομένων για παρελθοντικές περιόδους, τόσο σε πάρκα όπου εφαρμόζεται περιορισμός παραγωγής όσο και σε πάρκα που δεν έχουν ακόμη κατασκευαστεί, παρέχοντας πολύτιμη πληροφορία για την αξιολόγηση της αποδοτικότητας νέων ή υφιστάμενων έργων. Επιπλέον, εξετάζεται το συμβιβαστικό αποτέλεσμα που προκύπτει όταν δεν υπάρχει μετεωρολογικός σταθμός στην εγκατάσταση και τα δεδομένα αντλούνται αποκλειστικά από ανοιχτές πηγές, αναδεικνύοντας τα πλεονεκτήματα και τους περιορισμούς κάθε επιλογής. Κεντρικός στόχος είναι η ανάπτυξη μοντέλων με υψηλό βαθμό γενικευσιμότητας, ικανών να υποστηρίξουν την αξιοπιστία και την πρακτική εφαρμογή ψηφιακών διδύμων σε πραγματικά φωτοβολταϊκά συστήματα.

Λέξεις Κλειδιά: Φωτοβολταϊκά Συστήματα, Πρόβλεψη Ισχύος, Μηχανική Μάθηση, Περιορισμός Παραγωγής, Συνθετικά Δεδομένα, Γενικευσιμότητα, Ανοικτές Μετεωρολογικές Πηγές, Ενεργειακή Διαχείριση.

Abstract

The lack of large, publicly available datasets from real photovoltaic plants constitutes a major obstacle in the development of machine learning methods for power production forecasting. In addition, in several installations a forced production limitation (curtailment) is applied, resulting in measurements that do not reflect the actual capacity of the system. Similarly, in plants that are still under design, historical data are entirely absent, which restricts the reliability of techno-economic analyses and decision-making processes. In this context, the present thesis focuses on the development of models for the generation of synthetic data representing the daily power curve, based on meteorological and geometrical data of the same day, without relying on historical output measurements. The models employ static and dynamic parameters of the PV system, appropriately normalized to allow their application to plants of different capacities and layouts. Particular emphasis is placed on generating data for past periods, both in plants where curtailment is applied and in plants that have not yet been constructed, thus providing valuable insights for assessing the performance of new or existing projects. Furthermore, the thesis investigates the trade-off that arises when no meteorological station is available at the installation site and data are obtained exclusively from open sources, highlighting the advantages and limitations of each approach. The central objective is the development of models with a high degree of generalizability, capable of supporting the reliability and practical application of digital twins in real PV systems.

KeyWords: Photovoltaic Systems, Power Forecasting, Machine Learning, Curtailment, Synthetic Data, Generalizability, Open Meteorological Sources, Energy Management.

Ευχαριστίες

Θα ήθελα πρώτα να ευχαριστήσω την καθηγητή Ευάγγελο Μαρινάκη για την επίβλεψη της παρούσας διπλωματικής εργασίας, καθώς και τον υποψήφιο διδάκτωρα Βασίλη Μιχαλάκοπουλο για την καθοδήγηση και την εξαιρετική συνεργασία που είχαμε. Επίσης, θα ήθελα να εκφράσω τις ιδιαίτερες ευχαριστίες μου προς την οικογένεια μου και τους φίλους μου για τη συνεχή καθοδήγηση και ηθική υποστήριξή τους όλα αυτά τα χρόνια.

Περιεχόμενα

Περίληψη	6
Abstract	8
Ευχαριστίες	10
Λίστα Συντομογραφιών	17
1 Εισαγωγή	18
1.1 Κίνητρο	18
1.2 Αντικείμενο και Στόχος Διπλωματικής	19
1.3 Συνεισφορά	19
1.4 Δομή Διπλωματικής	20
2 Θεωρητικό Υπόβαθρο Διπλωματικής	21
2.1 Μηχανική Μάθηση	21
2.1.1 Κατηγορίες Μηχανικής Μάθησης	22
2.1.2 Εισαγωγή στη Βαθιά Μάθηση	23
2.2 Νευρωνικά Δίκτυα	24
2.2.1 Feedforward Νευρωνικά Δίκτυα (FNNs)	24
2.3 Συνελκτικά Νευρωνικά Δίκτυα (CNNs)	28
2.3.1 Αναδρομικά Νευρωνικά Δίκτυα (RNNs) και LSTM	30
2.3.2 Αρχιτεκτονικές Encoder-Decoder	33
2.4 Μετρικές Αξιολόγησης	37
2.5 Βιβλιογραφική Ανασκόπηση	39
3 Γεωμετρικά και Περιβαλλοντικά Δεδομένα του Φωτοβολταϊκού Πάρκου . . .	44
3.1 Γεωμετρικά και Στατικά Χαρακτηριστικά	44
3.1.1 Γεωγραφικό Μήκος, Πλάτος και Υψόμετρο	44
3.1.2 Κλίση και Προσανατολισμός	44
3.1.3 Ονομαστική Ισχύς	45
3.2 Ηλιακά και Μετεωρολογικά Δεδομένα	45
3.2.1 Ακτινοβολία	45

3.2.2	Άλλοι Μετεωρολογικοί Παράγοντες	47
3.3	Υπολογισμός Σύνθετων Ηλιακών Παραμέτρων	48
3.3.1	Η βιβλιοθήκη <code>pvlib</code>	48
3.3.2	Υπολογισμός Ηλιακής Θέσης	48
3.3.3	Υπολογισμός Γωνίας Πρόσπτωσης (AOI)	49
3.3.4	Υπολογισμός Ακτινοβολίας στο Επίπεδο των Πάνελ (POA)	51
3.4	Σύνοψη	52
4	Μεθοδολογία	54
4.1	Συλλογή Δεδομένων	56
4.2	Προεπεξεργασία Δεδομένων	56
4.3	Εξαγωγή Χαρακτηριστικών	57
4.4	Ανάλυση Συσχετίσεων και Επιλογή Χαρακτηριστικών	58
4.4.1	Ανάλυση Συσχετίσεων	58
4.4.2	Elastic Net Regression	59
4.5	Ορισμός των Μοντέλων	60
4.6	Βελτιστοποίηση Υπερπαραμέτρων και Εκπαίδευση	61
4.7	Αξιολόγηση	62
5	Μελέτη Περίπτωσης	63
5.1	Σύνολο Δεδομένων	63
5.2	Συλλογή και Προεπεξεργασία Δεδομένων	64
5.3	Εξαγωγή Χαρακτηριστικών (Feature Extraction)	65
5.4	Ανάλυση Συσχετίσεων και Επιλογή Χαρακτηριστικών	66
5.4.1	Πείραμα 1	66
5.4.2	Πείραμα 2	68
5.5	Αναλυτική Παρουσίαση Πειραμάτων	70
5.6	Σχεδιασμός Πειράματος	70
5.6.1	Δεδομένα Εισόδου	70
5.6.2	Κανονικοποίηση και Τυποποίηση	71
5.6.3	Μοντέλα	72
5.6.4	Βιβλιοθήκες Υλοποίησης	75
5.7	Αποτελέσματα	76
5.7.1	Αποτελέσματα Πειράματος 1	76
5.7.2	Αποτελέσματα Πειράματος 2	80
6	Επίλογος	87
6.1	Συμπεράσματα	87
6.2	Μελλοντικές Επεκτάσεις	88

Κατάλογος σχημάτων

2.1	Αρχιτεκτονική ενός Πολυεπίπεδου Perceptron (MLP).	25
2.2	Αρχιτεκτονική ενός Μονοδιάστατου Συνελικτικού Δικτύου (CNN με πολλά επίπεδα Συνέλιξης)	28
2.3	Αρχιτεκτονική ενός κελιού μνήμης LSTM	32
2.4	Αρχιτεκτονική encoder-decoder	33
2.5	Διαφορά Scaled Dot-Product (αριστερά) και Multi-Head Attention (δεξιά).	35
2.6	Αρχιτεκτονική Temporal Fusion Transformer	36
3.1	Αναπαράσταση Ακτινοβολίας	47
3.2	Αναπαράσταση ηλιακής γωνίας ζενίθ και αζιμούθιας	49
3.3	Αναπαράσταση γωνίας πρόσπτωσης	50
3.4	Υπολογισμός POA	52
4.1	Διάγραμμα Μεθοδολογίας	55
5.1	Feature Correlation Heatmap για το Πείραμα 1	67
5.2	Feature Correlation Heatmap για το Πείραμα 2	69
5.3	Πείραμα 1: Γράφημα Πρόβλεψης Ενεργού Ισχύος μιας Ηλιόλουστης Ημέρας	77
5.4	Πείραμα 1: Γράφημα Πρόβλεψης Ενεργού Ισχύος μιας Ημέρας με μέτρια Νεφοκάλυψη	77
5.5	Πείραμα 1: Γράφημα Πρόβλεψης Ενεργού Ισχύος μιας Ημέρας με έντονα μεταβαλλόμενες συνθήκες λόγω μη σταθερής συννεφιάς	78
5.6	Πείραμα 1: Γράφημα Πρόβλεψης Ενεργού Ισχύος μιας Ηλιόλουστης Ημέρας με Περιορισμό Ισχύος	79
5.7	Πείραμα 1: Γράφημα Πρόβλεψης Ενεργού Ισχύος μιας Ημέρας με μέτρια Νεφοκάλυψη και Περιορισμό Ισχύος	79
5.8	Πείραμα 1: Γράφημα Πρόβλεψης Ενεργού Ισχύος μιας Ημέρας με έντονα μεταβαλλόμενες συνθήκες λόγω μη σταθερής συννεφιάς και Περιορισμό Ισχύος	80
5.9	Πείραμα 2: Γράφημα Πρόβλεψης Ενεργού Ισχύος μιας Ηλιόλουστης Ημέρας χωρίς και με feature extraction	82
5.10	Πείραμα 2: Γράφημα Πρόβλεψης Ενεργού Ισχύος μιας Ημέρας με μέτρια Νεφοκάλυψη χωρίς και με feature extraction	83

5.11	Πείραμα 2: Γράφημα Πρόβλεψης Ενεργού Ισχύος μιας Ημέρας με έντονα μεταβαλλόμενες συνθήκες λόγω μη σταθερής συννεφιάς χωρίς και με feature extraction	84
5.12	Πείραμα 2: Γράφημα Πρόβλεψης Ενεργού Ισχύος μιας Ηλιόλουστης Ημέρας με Περιορισμός Ισχύος	85
5.13	Πείραμα 2: Γράφημα Πρόβλεψης Ενεργού Ισχύος μιας Ημέρας με μέτρια Νεφοκάλυψη και Περιορισμό Ισχύος	86
5.14	Πείραμα 2: Γράφημα Πρόβλεψης Ενεργού Ισχύος μιας Ημέρας με έντονα μεταβαλλόμενες συνθήκες λόγω μη σταθερής συννεφιάς και Περιορισμό Ισχύος	86

Κατάλογος πινάκων

2.1	Ενδεικτικές μελέτες ML/DL για PV Power Forecasting	40
2.2	Ενδεικτικές μελέτες ML/DL για PV Power Forecasting - Συνέχεια	41
5.1	Πίνακας Συσχέτισης με την ενεργό ισχύ για το Πείραμα 1	66
5.2	Συντελεστές χαρακτηριστικών από το Elastic Net για το Πείραμα 1	67
5.3	Πίνακας Συσχέτισης με την ενεργό ισχύ για το Πείραμα 1	68
5.4	Συντελεστές χαρακτηριστικών από το Elastic Net για το Πείραμα 2	69
5.5	Κατανομή δεδομένων για το Πείραμα 1 (μετεωρολογικοί σταθμοί)	71
5.6	Κατανομή δεδομένων για το Πείραμα 2 (Open-Meteo)	71
5.7	Τελική αρχιτεκτονική BiLSTM (Πείραμα 1) μετά από βελτιστοποίηση με Optuna	73
5.8	Τελική αρχιτεκτονική CNN (Πείραμα 1) μετά από βελτιστοποίηση με Optuna	73
5.9	Τελική αρχιτεκτονική TFT (Πείραμα 1) μετά από βελτιστοποίηση με Optuna .	74
5.10	Τελική αρχιτεκτονική BiLSTM (Πείραμα 2) μετά από βελτιστοποίηση με Optuna	74
5.11	Τελική αρχιτεκτονική CNN (Πείραμα 2) μετά από βελτιστοποίηση με Optuna	75
5.12	Τελική αρχιτεκτονική TFT (Πείραμα 2) μετά από βελτιστοποίηση με Optuna .	75
5.13	Αποτελέσματα αξιολόγησης Πειράματος 1 για Validation και Test set	76
5.14	Αποτελέσματα αξιολόγησης Πειράματος 2 για Validation και Test set χωρίς feature extraction	81
5.15	Αποτελέσματα αξιολόγησης Πειράματος 2 για Validation και Test set με feature extraction	81

Λίστα Συντομογραφιών

Συντομογραφία	Περιγραφή
ΑΠΕ	Ανανεώσιμες Πηγές Ενέργειας
Φ/B	Φωτοβολταϊκό
AI	Artificial Intelligence
AOI	Angle of Incidence
BiLSTM	Bidirectional Long Short-Term Memory
ANN	Artificial Neural Network
CNN	Convolutional Neural Network
DHI	Diffuse Horizontal Irradiance
DNI	Direct Normal Irradiance
FNN	Feed Forward Neural Network
GHI	Global Horizontal Irradiance
LSTM	Long Short-Term Memory
MAE	Mean Absolute Error
MAPE	Mean Absolute Percentage Error
MBE	Mean Bias Error
ML	Machine Learning
MLP	Multi Layer Perceptron
NRMSE	Normalized Root Mean Squared Error
POA	Plane of Array
RMSE	Root Mean Squared Error
RNN	Recurrent Neural Network
sMAPE	Symmetrical Mean Absolute Percentage Error
TFT	Temporal Fusion Transformer

Κεφάλαιο 1

Εισαγωγή

1.1 Κίνητρο

Η συνεχής αύξηση της διείσδυσης των Ανανεώσιμων Πηγών Ενέργειας (ΑΠΕ) στο ενεργειακό μίγμα έχει καταστήσει τα φωτοβολταϊκά (Φ/Β) συστήματα έναν από τους βασικούς πυλώνες της ενεργειακής μετάβασης.[1–6] Παρά το υψηλό ηλιακό δυναμικό της, η Ελλάδα αντιμετωπίζει σημαντικές προκλήσεις στη διαχείριση της παραγωγής ηλεκτρικής ενέργειας από Φ/Β πάρκα. Σε αρκετές περιπτώσεις, λόγω κορεσμού του δικτύου ή ρυθμιστικών περιορισμών, εφαρμόζεται αναγκαστικός περιορισμός παραγωγής (curtailment).[7, 8] Αυτός υλοποιείται κυρίως μέσω ρυθμίσεων στους inverters ή με εντολές του Διαχειριστή του Δικτύου και έχει ως αποτέλεσμα η καταγεγραμμένη παραγωγή να είναι χαμηλότερη από τη θεωρητικά διαθέσιμη.

Το γεγονός αυτό δυσχεραίνει την αποτίμηση της πραγματικής δυναμικότητας των Φ/Β πάρκων και περιορίζει τη δυνατότητα αξιόπιστων τεχνικοοικονομικών αναλύσεων. Πέρα από το ζήτημα του curtailment, σε πολλά πάρκα παρατηρείται έλλειψη επαρκών ιστορικών δεδομένων. Αυτό συμβαίνει είτε επειδή το πάρκο βρίσκεται ακόμα στο στάδιο του σχεδιασμού και δεν έχει τεθεί σε λειτουργία, είτε επειδή οι διαθέσιμες μετρήσεις δεν είναι αντιπροσωπευτικές. Οι επενδυτές, οι μηχανικοί και οι διαχειριστές, λοιπόν, δεν έχουν πρόσβαση σε ακριβή δεδομένα που να αποτυπώνουν την πραγματική δυνατότητα παραγωγής, γεγονός που περιορίζει τη βελτιστοποίηση της λειτουργίας, την ορθή οικονομική αποτίμηση και την ανάπτυξη στρατηγικών συντήρησης.[9–11]

Σε αυτό το πλαίσιο, η έννοια του ψηφιακού διδύμου (Digital Twin) αναδεικνύεται σε καινοτόμο εργαλείο [12–19]. Μέσω της ενσωμάτωσης γεωμετρικών και μετεωρολογικών δεδομένων, καθώς και της χρήσης μεθόδων μηχανικής μάθησης, μπορεί να εκτιμηθεί η θεωρητική παραγωγή ενός Φ/Β πάρκου ακόμη και σε συνθήκες curtailment. Ένα τέτοιο μοντέλο επιτρέπει την αποκάλυψη της πραγματικής δυναμικότητας του συστήματος, ενώ ταυτόχρονα ενισχύει την ακρίβεια στην πρόβλεψη της παραγόμενης ισχύος.

Ωστόσο, τα περισσότερα ψηφιακά δίδυμα που έχουν αναπτυχθεί μέχρι σήμερα βασίζο-

νται σε μοντέλα μηχανικής μάθησης τα οποία εκπαιδεύονται αποκλειστικά σε δεδομένα του ίδιου πάρκου. Αυτό συνεπάγεται ότι για κάθε νέα εγκατάσταση απαιτείται η συλλογή εκτεταμένων ιστορικών μετρήσεων και η εκπαίδευση ενός ξεχωριστού μοντέλου, γεγονός που περιορίζει τη μεταφερσιμότητα και τη γενικευσιμότητα των μεθόδων. Ιδιαίτερα κρίσιμη διάσταση λοιπόν, αποτελεί η γενικευσιμότητα των μοντέλων, δηλαδή η δυνατότητά τους να εφαρμόζονται σε διαφορετικά Φ/Β πάρκα χωρίς ανάγκη εκ νέου εκπαίδευσης σε κάθε περίπτωση. Η ανάπτυξη μεθόδων που υπερβαίνουν τα τοπικά χαρακτηριστικά ενός συγκεκριμένου πάρκου και μπορούν να δώσουν αξιόπιστες προβλέψεις σε διαφορετικά περιβάλλοντα, είναι αναγκαία και μπορεί να καταστήσει τους ψηφιακούς διδύμους εργαλείο υποστήριξης λήψης αποφάσεων μεγάλης κλίμακας.

1.2 Αντικείμενο και Στόχος Διπλωματικής

Αντικείμενο της παρούσας διπλωματικής είναι η ανάπτυξη μοντέλων μηχανικής μάθησης που μπορούν να αξιοποιηθούν στο πλαίσιο ψηφιακών διδύμων για φωτοβολταϊκά πάρκα. Τα μοντέλα αυτά στοχεύουν στην υποστήριξη της εκτίμησης της παραγωγής σε περιπτώσεις όπου τα διαθέσιμα δεδομένα είναι ελλιπή ή μη αντιπροσωπευτικά, προσφέροντας έτσι ένα εργαλείο για την καλύτερη κατανόηση της πραγματικής δυναμικότητας των συστημάτων.

Κεντρικός στόχος της εργασίας είναι η ανάπτυξη μεθοδολογίας που συνδυάζει ακρίβεια και γενικευσιμότητα, ώστε τα παραγόμενα μοντέλα να μπορούν να εφαρμοστούν σε διαφορετικά πάρκα και συνθήκες με ελάχιστη ανάγκη προσαρμογής. Η υλοποίηση μιας τέτοιας προσέγγισης ενισχύει την αξιοπιστία των ψηφιακών διδύμων και παρέχει στους μηχανικούς, διαχειριστές και επενδυτές ένα εργαλείο για τεκμηριωμένη λήψη αποφάσεων και ορθολογικό σχεδιασμό έργων ανανεώσιμης ενέργειας.

1.3 Συνεισφορά

Η παρούσα διπλωματική εργασία συμβάλλει στην ερευνητική περιοχή των ψηφιακών διδύμων για φωτοβολταϊκά συστήματα, εστιάζοντας στην ανάπτυξη μοντέλων μηχανικής μάθησης τα οποία επιτρέπουν τη δημιουργία συνθετικών δεδομένων παραγωγής ισχύος. Σε αντίθεση με κλασικές προσεγγίσεις πρόβλεψης που βασίζονται στην ύπαρξη εκτεταμένων ιστορικών μετρήσεων, η μεθοδολογία που αναπτύχθηκε στηρίζεται αποκλειστικά σε γεωμετρικά και μετεωρολογικά δεδομένα της ίδιας ημέρας. Με αυτόν τον τρόπο επιτυγχάνεται η δημιουργία δεδομένων σε περιπτώσεις όπου οι διαθέσιμες μετρήσεις είναι ανεπαρκείς, παραμορφωμένες λόγω περιορισμού παραγωγής ή εντελώς απύσες, όπως συμβαίνει σε πάρκα που βρίσκονται ακόμη στο στάδιο του σχεδιασμού.

Επιπλέον, μελετάται η επίδραση της πηγής των μετεωρολογικών δεδομένων στην ακρίβεια των αποτελεσμάτων. Συγκεκριμένα, εξετάζεται το συμβιβαστικό αποτέλεσμα που προκύπτει όταν δεν υπάρχει τοπικός μετεωρολογικός σταθμός και οι υπολογισμοί βασίζονται

αποκλειστικά σε δεδομένα από ανοιχτές πηγές. Η ανάλυση αυτή αναδεικνύει τα πλεονεκτήματα και τους περιορισμούς κάθε επιλογής, προσφέροντας κατευθύνσεις για την πρακτική αξιοποίηση των αποτελεσμάτων.

Τέλος, η εργασία αναδεικνύει τη σημασία της γενικευσιμότητας των μοντέλων, δηλαδή της δυνατότητας εφαρμογής τους σε φωτοβολταϊκά πάρκα διαφορετικής ισχύος και διαμόρφωσης με ελάχιστη προσαρμογή. Η ανάπτυξη τέτοιων μοντέλων καθιστά δυνατή την αξιοποίησή τους ως βασικά εργαλεία στο πλαίσιο ψηφιακών διδύμων, ενισχύοντας τόσο την αξιοπιστία όσο και την πρακτική χρησιμότητά τους σε πραγματικά ενεργειακά συστήματα.

1.4 Δομή Διπλωματικής

Η παρούσα διπλωματική εργασία αποτελείται από έξι κεφάλαια. Στο πρώτο κεφάλαιο παρουσιάζονται το κίνητρο, το αντικείμενο και οι στόχοι της μελέτης, καθώς και η συνολική δομή της. Στο δεύτερο κεφάλαιο αναπτύσσεται το θεωρητικό υπόβαθρο, εστιάζοντας στις βασικές έννοιες της μηχανικής μάθησης που αξιοποιούνται για την πρόβλεψη χρονοσειρών, καθώς και στις εφαρμογές τους στον τομέα των φωτοβολταϊκών συστημάτων. Παρουσιάζονται επίσης μέθοδοι και αρχιτεκτονικές μοντέλων που έχουν χρησιμοποιηθεί στη βιβλιογραφία για την εκτίμηση της παραγωγής ενέργειας.

Στο τρίτο κεφάλαιο περιγράφονται οι στατικές και μετεωρολογικές παράμετροι που σχετίζονται με τη λειτουργία ενός φωτοβολταϊκού πάρκου. Αναλύονται τα γεωμετρικά χαρακτηριστικά της εγκατάστασης, η ηλιακή θέση, η γωνία πρόσπτωσης και η ακτινοβολία στο επίπεδο του πάνελ, τα οποία συνιστούν τις κύριες εισόδους των μοντέλων πρόβλεψης.

Το τέταρτο κεφάλαιο είναι αφιερωμένο στη μεθοδολογία που ακολουθήθηκε για την ανάπτυξη μοντέλων δημιουργίας συνθετικών δεδομένων παραγωγής. Παρουσιάζεται η διαδικασία συλλογής και προεπεξεργασίας δεδομένων, η επιλογή χαρακτηριστικών, καθώς και οι μέθοδοι μηχανικής μάθησης που εφαρμόστηκαν. Περιγράφονται επίσης τα κριτήρια αξιολόγησης και η διαδικασία εκπαίδευσης των μοντέλων.

Στο πέμπτο κεφάλαιο αναλύεται η μελέτη περίπτωσης που εφαρμόστηκε. Παρουσιάζονται τα αποτελέσματα των πειραμάτων, συγκρίνονται οι διαφορετικές προσεγγίσεις και σχολιάζεται η αποτελεσματικότητα των μεθόδων σε σχέση με την πραγματική λειτουργία ενός φωτοβολταϊκού πάρκου. Ιδιαίτερη έμφαση δίνεται στην αξιολόγηση της γενικευσιμότητας των μοντέλων.

Τέλος, το έκτο κεφάλαιο περιλαμβάνει τα συμπεράσματα της εργασίας, όπου συνοψίζονται τα βασικά ευρήματα και συζητούνται οι προοπτικές για μελλοντική έρευνα και βελτιώσεις, με στόχο τη βελτίωση της ακρίβειας και της αξιοπιστίας των ψηφιακών διδύμων σε φωτοβολταϊκά συστήματα.

Κεφάλαιο 2

Θεωρητικό Υπόβαθρο Διπλωματικής

Η ραγδαία ανάπτυξη της Μηχανικής Μάθησης (Machine Learning) και ιδιαίτερα των μεθόδων Βαθιάς Μάθησης (Deep Learning) έχει καταστήσει δυνατή την εφαρμογή εξελιγμένων τεχνικών πρόβλεψης σε ποικίλα επιστημονικά και τεχνολογικά πεδία [19–22]. Στον τομέα της ενέργειας, και ειδικότερα στην πρόβλεψη παραγωγής ισχύος φωτοβολταϊκών συστημάτων, η αξιοποίηση τέτοιων μεθόδων συμβάλλει στην καλύτερη ενσωμάτωση των ανανεώσιμων πηγών ενέργειας στο δίκτυο και στη βελτιστοποίηση της λειτουργίας τους.[23]

Στο κεφάλαιο αυτό παρουσιάζεται το θεωρητικό υπόβαθρο που υποστηρίζει την παρούσα εργασία. Αρχικά εισάγονται οι βασικές αρχές της μηχανικής μάθησης και οι κύριες κατηγορίες της, ώστε να τοποθετηθεί η εργασία στο κατάλληλο επιστημονικό πλαίσιο. Στη συνέχεια αναλύονται τα μοντέλα που χρησιμοποιήθηκαν, δηλαδή τα Συνελικτικά Νευρωνικά Δίκτυα (CNN), τα Αναδρομικά Νευρωνικά Δίκτυα τύπου BiLSTM και ο Temporal Fusion Transformer (TFT), ως εκπρόσωποι διαφορετικών αρχιτεκτονικών για την πρόβλεψη χρονοσειρών.

Οι μέθοδοι αυτές παρουσιάζουν ιδιαίτερο ενδιαφέρον όχι μόνο για την πρόβλεψη ή την παραγωγή συνθετικών δεδομένων ισχύος αλλά και για την ανάπτυξη εφαρμογών σε ψηφιακούς δίδυμους, όπου απαιτείται υψηλή ακρίβεια και ικανότητα μοντελοποίησης πολύπλοκων δυναμικών συστημάτων. Η δυνατότητά τους να μαθαίνουν και να αποτυπώνουν μη γραμμικές σχέσεις τα καθιστά κατάλληλα εργαλεία για την αναπαράσταση και προσομοίωση της λειτουργίας ενεργειακών συστημάτων σε πραγματικό χρόνο.[13]

Τέλος, το κεφάλαιο ολοκληρώνεται με την παρουσίαση των μετρικών αξιολόγησης, οι οποίες χρησιμοποιούνται για την εκτίμηση της απόδοσης των μοντέλων και τη σύγκρισή τους με βάση ποσοτικά κριτήρια, αλλά και με μία βιβλιογραφική ανασκόπηση αναφορικά με την παραγωγή ισχύος φωτοβολταϊκών.

2.1 Μηχανική Μάθηση

Η Μηχανική Μάθηση (Machine Learning – ML) αποτελεί έναν από τους σημαντικότερους κλάδους της Τεχνητής Νοημοσύνης (Artificial Intelligence – AI) και επικεντρώνεται

στην ανάπτυξη αλγορίθμων και μοντέλων που επιτρέπουν στους υπολογιστές να «μαθαίνουν» από δεδομένα. Σε αντίθεση με τις παραδοσιακές μεθόδους προγραμματισμού, όπου οι κανόνες καθορίζονται ρητά από τον άνθρωπο, στη μηχανική μάθηση οι κανόνες προκύπτουν έμμεσα μέσω της επεξεργασίας μεγάλου όγκου δεδομένων και της βελτιστοποίησης μαθηματικών συναρτήσεων. Ουσιαστικά, τα μοντέλα μηχανικής μάθησης επιχειρούν να ανακαλύψουν υποκείμενα πρότυπα και σχέσεις που δύσκολα μπορούν να περιγραφούν με κλασικές μεθόδους.[24]

Ένα βασικό χαρακτηριστικό της μηχανικής μάθησης είναι η ικανότητά της να γενικεύει, δηλαδή να εφαρμόζει τη γνώση που αποκτήθηκε από το σύνολο εκπαίδευσης σε νέα, άγνωστα δεδομένα. Για τον σκοπό αυτό, τα διαθέσιμα δεδομένα χωρίζονται συνήθως σε εκπαίδευση (training), επικύρωση (validation) και έλεγχο (test), με στόχο τόσο την εκμάθηση των παραμέτρων όσο και την αποφυγή του φαινομένου της υπερπροσαρμογής (overfitting). Η ποιότητα και η ποσότητα των δεδομένων παίζουν κρίσιμο ρόλο στην απόδοση των μοντέλων, καθώς ακόμη και ο πιο σύνθετος αλγόριθμος δεν μπορεί να παράγει αξιόπιστα αποτελέσματα χωρίς κατάλληλα δεδομένα.

2.1.1 Κατηγορίες Μηχανικής Μάθησης

Η Μηχανική Μάθηση μπορεί να διακριθεί σε τρεις κύριες κατηγορίες: την επιβλεπόμενη μάθηση, τη μη επιβλεπόμενη μάθηση και την ενισχυτική μάθηση. Η διάκριση αυτή βασίζεται στον τρόπο με τον οποίο παρέχονται τα δεδομένα στον αλγόριθμο και στον τρόπο με τον οποίο αξιολογείται η διαδικασία εκπαίδευσης[25].

Η επιβλεπόμενη μάθηση (Supervised Learning) είναι η πιο διαδεδομένη μορφή μηχανικής μάθησης και αφορά περιπτώσεις όπου τα δεδομένα συνοδεύονται από γνωστές ετικέτες (labels). Ο αλγόριθμος καλείται να μάθει μια συνάρτηση που αντιστοιχίζει τις εισόδους στις εξόδους, με σκοπό να μπορεί να προβλέπει σωστά νέες, άγνωστες περιπτώσεις. Χαρακτηριστικές εφαρμογές της επιβλεπόμενης μάθησης είναι η ταξινόμηση (classification), όπου η έξοδος είναι κατηγορική (π.χ. αναγνώριση εικόνας), και η παλινδρόμηση (regression), όπου η έξοδος είναι συνεχής (π.χ. πρόβλεψη ισχύος φωτοβολταϊκών). Στο πλαίσιο της παρούσας εργασίας, η πρόβλεψη χρονοσειρών εντάσσεται στην κατηγορία της επιβλεπόμενης μάθησης, καθώς τα ιστορικά δεδομένα συνοδεύονται από γνωστές τιμές στόχου.[26]

Αντίθετα, στη μη επιβλεπόμενη μάθηση (Unsupervised Learning) τα δεδομένα δεν περιλαμβάνουν ετικέτες. Ο στόχος του αλγορίθμου είναι να εντοπίσει εσωτερικές δομές, πρότυπα ή συσχετίσεις μέσα στο σύνολο των δεδομένων. Ένα χαρακτηριστικό παράδειγμα είναι η ομαδοποίηση (clustering), όπου τα δεδομένα χωρίζονται σε ομάδες με βάση την ομοιότητά τους, χωρίς να υπάρχει προϋπάρχουσα γνώση για το πλήθος ή το είδος των ομάδων. Άλλη σημαντική εφαρμογή αποτελεί η μείωση διαστασιμότητας (dimensionality reduction), η οποία διευκολύνει την αναπαράσταση και οπτικοποίηση δεδομένων μεγάλης κλίμακας. Παρόλο που η μη επιβλεπόμενη μάθηση δεν αξιοποιείται άμεσα στην παρούσα εργασία, μπο-

ρεί να λειτουργήσει συμπληρωματικά για την ανάλυση προτύπων ή την προεπεξεργασία δεδομένων.[27]

Τέλος, η ενισχυτική μάθηση (Reinforcement Learning) διαφέρει από τις δύο προηγούμενες κατηγορίες καθώς στηρίζεται στην αλληλεπίδραση του αλγορίθμου με ένα περιβάλλον. Ο «πράκτορας» (agent) εκτελεί ενέργειες, λαμβάνει παρατηρήσεις και δέχεται ανταμοιβές ή ποινές, με στόχο τη μεγιστοποίηση μιας συνολικής συνάρτησης απόδοσης. Η ενισχυτική μάθηση έχει γνωρίσει σημαντική ανάπτυξη τα τελευταία χρόνια, με εφαρμογές στη ρομποτική, στον έλεγχο συστημάτων και σε αυτόνομα δίκτυα. Αν και δεν εφαρμόζεται άμεσα στη συγκεκριμένη εργασία, η λογική της δυναμικής αλληλεπίδρασης με περιβάλλοντα την καθιστά ιδιαίτερα συναφή με εφαρμογές ψηφιακών διδύμων, όπου η συνεχής μάθηση και προσαρμογή είναι κρίσιμες.[28]

Συνολικά, οι τρεις αυτές κατηγορίες συγκροτούν το θεωρητικό υπόβαθρο πάνω στο οποίο αναπτύσσονται οι σύγχρονες μέθοδοι μηχανικής μάθησης. Η παρούσα εργασία επικεντρώνεται στην επιβλεπόμενη μάθηση και ειδικότερα σε προβλήματα παλινδρόμησης χρονοσειρών, αξιοποιώντας μοντέλα βαθιάς μάθησης για την παραγωγή συνθετικών δεδομένων ισχύος φωτοβολταϊκών συστημάτων.

2.1.2 Εισαγωγή στη Βαθιά Μάθηση

Η Βαθιά Μάθηση (Deep Learning) αποτελεί υποπεδίο της Μηχανικής Μάθησης, το οποίο επικεντρώνεται στη χρήση νευρωνικών δικτύων με πολλαπλά επίπεδα[29]. Μέσω αυτής της πολυεπίπεδης αρχιτεκτονικής, τα δίκτυα έχουν τη δυνατότητα να μαθαίνουν ιεραρχικές αναπαραστάσεις των δεδομένων, ξεκινώντας από απλές δομές και φτάνοντας σε πιο σύνθετες αφηρημένες έννοιες[30].

Σε αντίθεση με τις παραδοσιακές μεθόδους μηχανικής μάθησης, όπου η επιλογή και η εξαγωγή χαρακτηριστικών βασίζονταν συχνά σε χειροποίητους κανόνες ή στη γνώση του εκάστοτε πεδίου εφαρμογής, η βαθιά μάθηση μπορεί να αντλεί τόσο χαμηλού επιπέδου όσο και υψηλού επιπέδου χαρακτηριστικά απευθείας από τα ακατέργαστα δεδομένα. Η ιδιότητα αυτή καθιστά τα βαθιά δίκτυα ιδιαίτερα αποδοτικά σε προβλήματα όπου τα δεδομένα είναι μη δομημένα, όπως εικόνες, ήχος ή φυσική γλώσσα.

Κεντρικό στοιχείο των μοντέλων βαθιάς μάθησης είναι η ύπαρξη διαδοχικών επιπέδων που συνδυάζουν γραμμικούς μετασχηματισμούς με μη γραμμικές συναρτήσεις ενεργοποίησης. Με τον τρόπο αυτό, το δίκτυο μπορεί να αποτυπώνει ολοένα και πιο περίπλοκα μοτίβα καθώς προχωρά από τα αρχικά στα βαθύτερα επίπεδα. Χάρη σε αυτή τη δυνατότητα, η βαθιά μάθηση έχει επιτύχει εντυπωσιακά αποτελέσματα σε πληθώρα εφαρμογών, όπως την αναγνώριση εικόνας και την επεξεργασία φυσικής γλώσσας [31].

Η δύναμη της βαθιάς μάθησης έγκειται στην ευελιξία και τη δυνατότητα κλιμάκωσης που προσφέρει. Ωστόσο, η αποτελεσματική της εφαρμογή προϋποθέτει μεγάλο όγκο δεδομένων, ισχυρούς υπολογιστικούς πόρους και προσεκτική ρύθμιση υπερπαραμέτρων ώστε να

αποφεύγεται το φαινόμενο της υπερπροσαρμογής.

2.2 Νευρωνικά Δίκτυα

Τα Τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Networks, ANNs) αποτελούν μία από τις θεμελιώδεις κατηγορίες μεθόδων της Βαθιάς Μάθησης και είναι εμπνευσμένα από τη λειτουργία του ανθρώπινου εγκεφάλου. Ένα νευρωνικό δίκτυο αποτελείται από απλές μονάδες υπολογισμού, τους νευρώνες, οι οποίοι είναι οργανωμένοι σε επίπεδα και συνδέονται μεταξύ τους με σταθμισμένες συνδέσεις - βάρη (weights). Κάθε νευρώνας δέχεται σήματα εισόδου, τα συνδυάζει γραμμικά, εφαρμόζει μια μη γραμμική συνάρτηση ενεργοποίησης, και παράγει ως έξοδο ένα σήμα που μεταδίδεται σε επόμενους νευρώνες[32].

Η τυπική αρχιτεκτονική ενός νευρωνικού δικτύου περιλαμβάνει τρία είδη επιπέδων:

- Επίπεδο εισόδου (input layer), το οποίο λαμβάνει τα δεδομένα.
- Κρυφά επίπεδα (hidden layers), όπου γίνεται η κύρια επεξεργασία και η εξαγωγή χαρακτηριστικών.
- Επίπεδο εξόδου (output layer), το οποίο παρέχει το τελικό αποτέλεσμα της πρόβλεψης ή ταξινόμησης.

Η εκπαίδευση των νευρωνικών δικτύων πραγματοποιείται μέσω της διαδικασίας της οπισθοδιάδοσης (backpropagation), κατά την οποία το σφάλμα μεταξύ της επιθυμητής και της πραγματικής εξόδου υπολογίζεται και διαδίδεται προς τα πίσω, ενημερώνοντας τα βάρη με τη χρήση αλγορίθμων βελτιστοποίησης.[33].

Τα νευρωνικά δίκτυα έχουν αποδείξει την ικανότητά τους να προσεγγίζουν πολύπλοκες μη γραμμικές συναρτήσεις (Universal Approximation Theorem) και έχουν εφαρμοστεί με επιτυχία σε πληθώρα τομέων, από την αναγνώριση προτύπων έως την πρόβλεψη χρονοσειρών. Η εξέλιξή τους οδήγησε στη δημιουργία διαφόρων αρχιτεκτονικών, καθεμία από τις οποίες στοχεύει στην αντιμετώπιση συγκεκριμένων προκλήσεων: τα Feedforward Δίκτυα ως η βασική μορφή, τα Συνελικτικά Νευρωνικά Δίκτυα (CNNs) για την επεξεργασία χωρικών δεδομένων [34], τα Αναδρομικά Νευρωνικά Δίκτυα (RNNs) και οι παραλλαγές τους για την ανάλυση χρονικών ακολουθιών [35], καθώς και οι Transformers, οι οποίοι στηρίζονται στον μηχανισμό της προσοχής (attention) για την αποδοτική επεξεργασία μεγάλων ακολουθιών [36].

2.2.1 Feedforward Νευρωνικά Δίκτυα (FNNs)

Τα Feedforward Νευρωνικά Δίκτυα (FNNs), γνωστά και ως Πολυεπίπεδοι Perceptrons (MLPs), αποτελούν την πιο βασική αρχιτεκτονική τεχνητών νευρωνικών δικτύων και αποτελούν θεμέλιο λίθο της Βαθιάς Μάθησης. Το βασικό τους χαρακτηριστικό είναι ότι η πληρο-

φορία ρέει μονοκατευθυντικά από το επίπεδο εισόδου προς το επίπεδο εξόδου, χωρίς ανατροφοδότηση ή βρόχους [32].

Αρχιτεκτονική

Ένα MLP περιλαμβάνει τρία κύρια μέρη: το επίπεδο εισόδου (Input layer), το οποίο λαμβάνει τα αρχικά χαρακτηριστικά (features) των δεδομένων, τα κρυφά επίπεδα (Hidden layer), τα οποία αποτελούνται από πολλαπλούς νευρώνες που εκτελούν γραμμικούς μετασχηματισμούς και μη γραμμικές ενεργοποιήσεις, καθώς και το επίπεδο εξόδου (Output layer), το οποίο παράγει την τελική πρόβλεψη, είτε πρόκειται για ταξινόμηση είτε για παλινδρόμηση. Η αρχιτεκτονική ενός MLP παρουσιάζεται αναλυτικά στο σχήμα 2.1.


Η λειτουργία ενός νευρώνα περιγράφεται από τη σχέση:

$$h_j = f\left(\sum_{i=1}^n w_{ij}x_i + b_j\right). \quad (2.1)$$

όπου:

- x_i είναι οι είσοδοι,
- w_{ij} τα βάρη,
- b_j η προκατάληψη (bias) και
- $f()$ η συνάρτηση ενεργοποίησης.

Σχήμα 2.1: Αρχιτεκτονική ενός Πολυεπίπεδου Perceptron (MLP). Αναπαραγωγή από [37].



Συναρτήσεις Ενεργοποίησης

Για να μπορεί το δίκτυο να αποτυπώνει πολύπλοκες και μη γραμμικές σχέσεις στα δεδομένα, μετά από κάθε γραμμικό μετασχηματισμό ενός νευρώνα εφαρμόζονται συναρτήσεις

ενεργοποίησης. Οι συναρτήσεις αυτές εισάγουν τη μη γραμμικότητα στο μοντέλο, δίνοντάς του τη δυνατότητα να μάθει και να αναπαραστήσει σύνθετα πρότυπα [38]. Οι βασικές συναρτήσεις ενεργοποίησης που χρησιμοποιούνται στα νευρωνικά δίκτυα είναι οι εξής:

- **Sigmoid:**

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

- **Hyperbolic Tangent (tanh):**

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

- **Rectified Linear Unit (ReLU):**

$$\text{ReLU}(x) = \max(0, x)$$

- **Leaky ReLU:**

$$\text{Leaky Relu}(x) = \begin{cases} x, & x \geq 0 \\ \alpha x, & x < 0 \end{cases}$$

όπου α μια σταθερά ($0 \leq \alpha < 1$).

- **Quantile Loss (Pinball Loss):**

$$L_q(y, \hat{y}) = \begin{cases} q \cdot (y - \hat{y}), & y > \hat{y} \\ (1 - q) \cdot (\hat{y} - y), & y \leq \hat{y} \end{cases}$$

όπου y είναι η πραγματική τιμή, $\hat{y}$ η πρόβλεψη και $q \in (0, 1)$ το ποσοστημόριο που στοχεύουμε (π.χ. $q = 0.5$ για τη διάμεσο). Η συνάρτηση αυτή χρησιμοποιείται σε πιθανοτικά μοντέλα πρόβλεψης, όπως ο *Temporal Fusion Transformer*, ώστε να προβλέπονται διαφορετικά ποσοστημόρια της κατανομής (π.χ. 10ο, 50ό και 90ό).

Συναρτήσεις Κόστους

Οι συναρτήσεις κόστους χρησιμοποιούνται για να μετρούν την απόκλιση ανάμεσα στην πραγματική έξοδο και στην πρόβλεψη του δικτύου. Μερικές από τις πιο συνηθισμένες είναι:

- **Μέσο Τετραγωνικό Σφάλμα (Mean Squared Error, MSE):**

$$\mathcal{L}_{\text{MSE}} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2$$

- **Μέσο Απόλυτο Σφάλμα (Mean Absolute Error, MAE):**

$$\mathcal{L}_{\text{MAE}} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|$$

- **Διασταυρούμενη Εντροπία (Cross-Entropy Loss)** – κυρίως για ταξινόμηση:

$$\mathcal{L}_{\text{CE}} = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C y_{i,c} \log(\hat{y}_{i,c})$$

όπου C είναι ο αριθμός των κατηγοριών, $y_{i,c}$ η πραγματική ετικέτα, και $\hat{y}_{i,c}$ η πιθανότητα που προβλέπει το δίκτυο για την κατηγορία c .

- **Quantile Loss (Pinball Loss):**

$$L_q = \begin{cases} q \cdot (y - \hat{y}), & y > \hat{y} \\ (1 - q) \cdot (\hat{y} - y), & y \leq \hat{y} \end{cases}$$

όπου $q \in (0, 1)$ το ποσοστημόριο που στοχεύουμε (π.χ. $q = 0.5$ για τη διάμεσο).

Για προβλέψεις πολλαπλών ποσοστημορίων (π.χ. $Q = \{0.1, 0.5, 0.9\}$), η συνολική απώλεια υπολογίζεται ως ο μέσος όρος όλων των ποσοστημορίων:

$$\mathcal{L}_{\text{Quantile}} = \frac{1}{|Q|} \sum_{q \in Q} \frac{1}{N} \sum_{i=1}^N L_q(y_i, \hat{y}_i^{(q)})$$

όπου N είναι ο αριθμός των δειγμάτων. Η συνάρτηση αυτή χρησιμοποιείται σε πιθανοτικά μοντέλα πρόβλεψης, για την εκτίμηση διαφορετικών ποσοστημορίων της κατανομής και τη δημιουργία διαστημάτων πρόβλεψης (π.χ. 10ο, 50ο και 90ο ποσοστημόριο) [39].

Στόχος των Πολυεπίπεδων Perceptrons (MLPs), αλλά και γενικότερα όλων των νευρωνικών δικτύων, είναι η ελαχιστοποίηση της συνάρτησης κόστους που εκτιμά το σφάλμα μεταξύ πραγματικής και προβλεπόμενης εξόδου. Η διαδικασία αυτή επιτυγχάνεται μέσω της χρήσης αλγορίθμων βελτιστοποίησης, με πιο χαρακτηριστικά παραδείγματα τη βαθμίδωση κατηφόρου (Gradient Descent) και τις παραλλαγές της, καθώς και τον προσαρμοστικό αλγόριθμο Adam, ο οποίος έχει επικρατήσει ευρέως λόγω της ταχείας σύγκλισης και της σταθερότητας του κατά την εκπαίδευση [40].

Οπισθοδιάδοση (Backpropagation)

Η εκπαίδευση των νευρωνικών δικτύων βασίζεται στον αλγόριθμο της οπισθοδιάδοσης (backpropagation), ο οποίος εισήχθη από τους Rumelhart, Hinton και Williams (1986) [33]. Ο


αλγόριθμος αυτός υπολογίζει αρχικά το σφάλμα μεταξύ της πραγματικής και της προβλεπόμενης εξόδου μέσω της συνάρτησης κόστους. Στη συνέχεια, με την εφαρμογή του κανόνα της αλυσίδας από τον διαφορικό λογισμό, το σφάλμα διαδίδεται προς τα πίσω στο δίκτυο, επιτρέποντας τον υπολογισμό των μερικών παραγώγων της απώλειας ως προς κάθε βάρος.

2.3 Συνελικτικά Νευρωνικά Δίκτυα (CNNs)

Τα Συνελικτικά Νευρωνικά Δίκτυα (Convolutional Neural Networks, CNNs) αποτελούν μια κατηγορία νευρωνικών δικτύων ειδικά σχεδιασμένη για την ανίχνευση τοπικών μοτίβων σε δεδομένα με χωρική ή χρονική δομή. Αρχικά προτάθηκαν για αναγνώριση εικόνων [34], αλλά η προσαρμογή τους σε μονοδιάστατη μορφή (1D CNNs) τα καθιστά ιδιαίτερα αποτελεσματικά για προβλήματα χρονοσειρών [41], όπως η πρόβλεψη ισχύος φωτοβολταϊκών.

Τα Συνελικτικά Νευρωνικά Δίκτυα (CNNs) χαρακτηρίζονται από μια τυπική αρχιτεκτονική που αποτελείται από διαδοχικά στάδια. Αρχικά, το επίπεδο εισόδου δέχεται τα ακατέργαστα δεδομένα, τα οποία μπορεί να είναι εικόνες ή χρονοσειρές, ανάλογα με το πρόβλημα. Στη συνέχεια, τα συνελικτικά επίπεδα εφαρμόζουν φίλτρα (kernels) με σκοπό την εξαγωγή τοπικών χαρακτηριστικών, εντοπίζοντας μοτίβα που εμφανίζονται σε μικρές περιοχές των δεδομένων. Για να μειωθεί η διάσταση και το υπολογιστικό κόστος, παρεμβάλλονται επίπεδα υποδειγματοληψίας (pooling), τα οποία διατηρούν τα πιο αντιπροσωπευτικά στοιχεία. Ακολουθούν τα πλήρως συνδεδεμένα επίπεδα (dense layers), που συνδυάζουν τις πληροφορίες από τα προηγούμενα στάδια και συνθέτουν μια συνολική αναπαράσταση. Τέλος, το επίπεδο εξόδου παράγει την τελική πρόβλεψη, είτε πρόκειται για κατηγορία σε πρόβλημα ταξινόμησης είτε για συνεχή τιμή σε πρόβλημα παλινδρόμησης, όπως στην πρόβλεψη ισχύος φωτοβολταϊκών. Μια τυπική αρχιτεκτονική ενός μονοδιάστατου CNN παρουσιάζεται αναλυτικά στο σχήμα 2.2

Σχήμα 2.2: Αρχιτεκτονική ενός Μονοδιάστατου Συνελικτικού Δικτύου (CNN με πολλαπλά επίπεδα Συνέλιξης). Αναπαραγωγή από [42].



Συνελικτική λειτουργία (Convolution)

Η βασική λειτουργία ενός CNN είναι η εφαρμογή συνελίξεων με τη χρήση μικρών παραθύρων (kernels). Στην περίπτωση χρονοσειρών, χρησιμοποιείται η 1D συνέλιξη, όπου κάθε kernel σαρώνει τον άξονα του χρόνου και εξάγει χαρακτηριστικά:

$$s_j(t) = (x * w_j)(t) = \sum_{\tau=0}^{k-1} x(t + \tau) \cdot w_j(\tau) + b_j, \quad (2.2)$$

όπου $x(t)$ είναι η είσοδος, $w_j(\tau)$ το παράθυρο (kernel) j μήκους k , b_j η προκατάληψη (bias) και $s_j(t)$ η έξοδος της συνέλιξης.

Στην πράξη, σε κάθε συνελικτικό επίπεδο εφαρμόζονται πολλαπλά φίλτρα (filters), καθένα από τα οποία μαθαίνει να ανιχνεύει διαφορετικό τύπο χαρακτηριστικών [43]. Για παράδειγμα, σε δεδομένα Φ/Β, ένα φίλτρο μπορεί να εντοπίζει την τυπική ημερήσια καμπύλη παραγωγής, ενώ ένα άλλο να «μαθαίνει» τα πρότυπα πτώσης ισχύος λόγω νεφώσεων. Ο αριθμός των φίλτρων (π.χ. 32, 64, 128) είναι υπερπαραμέτρος που επηρεάζει τόσο την εκφραστικότητα όσο και την υπολογιστική πολυπλοκότητα του μοντέλου.

Max Pooling και Average Pooling

Μετά από κάθε συνελικτικό επίπεδο εφαρμόζεται συνήθως μια πράξη υποδειγματοληψίας (pooling), η οποία μειώνει τη διάσταση των δεδομένων και βοηθά στη γενίκευση του μοντέλου. Οι δύο πιο διαδεδομένες μέθοδοι είναι το max pooling και το average pooling.

Η μέθοδος Max Pooling κρατά την μέγιστη τιμή από κάθε παράθυρο μήκους k με εφαρμογή του τύπου:

$$s'_{\max}(t) = \max\{s(t), s(t+1), \dots, s(t+k-1)\}, \quad (2.3)$$

Αυτή η μέθοδος επικεντρώνεται στην πιο έντονη τοπική απόκριση, τονίζοντας τα χαρακτηριστικά που εμφανίζονται ισχυρότερα στο σήμα.

Η μέθοδος Average Pooling υπολογίζει τον μέσο όρο των τιμών στο ίδιο παράθυρο k με εφαρμογή του τύπου:

$$s'_{\text{avg}}(t) = \frac{1}{k} \sum_{\tau=0}^{k-1} s(t + \tau), \quad (2.4)$$

Με αυτόν τον τρόπο διατηρείται μια πιο «ομαλή» αναπαράσταση της χρονοσειράς, αποδίδοντας καλύτερα σε περιπτώσεις όπου τα δεδομένα περιέχουν υψηλό θόρυβο ή μικρές διακυμάνσεις που δεν είναι σημαντικές.

Και οι δύο μέθοδοι έχουν χρησιμοποιηθεί στη βιβλιογραφία· το max pooling θεωρείται καταλληλότερο για την ανίχνευση εντονότερων μοτίβων, ενώ το average pooling παρέχει πιο σταθερή και εξομαλυσμένη αναπαράσταση[44]. Η επιλογή εξαρτάται από τη φύση των δεδομένων και τον στόχο της πρόβλεψης.

Πλήρως Συνδεδεμένα Επίπεδα (Dense Layers)

Μετά τα συνελκτικά και τα pooling επίπεδα, τα εξαγόμενα χαρακτηριστικά μετατρέπονται σε μονοδιάστατο διάνυσμα μέσω της διαδικασίας flattening και εισάγονται σε ένα ή περισσότερα πλήρως συνδεδεμένα επίπεδα (Dense layers). Σε αυτά, κάθε νευρώνας συνδέεται με όλους τους νευρώνες του προηγούμενου επιπέδου, επιτρέποντας τον συνδυασμό όλων των τοπικών χαρακτηριστικών που έχουν εξαχθεί.

Μαθηματικά, η λειτουργία ενός Dense layer περιγράφεται ως:

$$y_j = f \left(\sum_{i=1}^n w_{ij} h_i + b_j \right),$$

όπου h_i είναι οι είσοδοι από το προηγούμενο επίπεδο, w_{ij} τα βάρη σύνδεσης, b_j ο όρος προκατάληψης (bias), και $f()$ η συνάρτηση ενεργοποίησης (συνήθως ReLU ή sigmoid, ανάλογα με το πρόβλημα).

Ο ρόλος των Dense layers είναι να πραγματοποιούν υψηλότερου επιπέδου συνδυασμούς των χαρακτηριστικών, λειτουργώντας ως «ταξινομητές» ή «παλινδρομητές» που χαρτογραφούν την αναπαράσταση των δεδομένων στην τελική έξοδο. Στην πρόβλεψη φωτοβολταϊκής ισχύος, το τελευταίο Dense layer παράγει το διάνυσμα εξόδου που αντιστοιχεί στις τιμές της προβλεπόμενης ισχύος για τον επιλεγμένο χρονικό ορίζοντα (π.χ. 288 χρονικά βήματα με ανάλυση 5 λεπτών).

Συνολικά, τα Dense layers ολοκληρώνουν τη λειτουργία των CNNs, συνδυάζοντας τα τοπικά πρότυπα που εντοπίζονται από τα συνελκτικά φίλτρα και παράγοντας μια συνολική εκτίμηση της επιθυμητής εξόδου.

2.3.1 Αναδρομικά Νευρωνικά Δίκτυα (RNNs) και LSTM

Τα Αναδρομικά Νευρωνικά Δίκτυα (Recurrent Neural Networks, RNNs) έχουν σχεδιαστεί για δεδομένα ακολουθιακού χαρακτήρα, ενσωματώνοντας εξάρτηση από προηγούμενες χρονικές καταστάσεις. Σε κάθε χρονικό βήμα t , η κρυφή κατάσταση h_t υπολογίζεται από την τρέχουσα είσοδο x_t και την προηγούμενη κατάσταση h_{t-1} :

$$h_t = f(w_h h_{t-1} + w_x x_t + b), \quad (2.5)$$

όπου $f()$ είναι μη γραμμική συνάρτηση ενεργοποίησης (π.χ. tanh) και w_x, w_h τα βάρη εισόδου και προηγούμενης κατάστασης αντίστοιχα. Παρά την εκφραστικότητά τους, τα κλασικά RNNs δυσκολεύονται να μάθουν μακροχρόνιες εξαρτήσεις λόγω του φαινομένου vanishing/exploding gradients κατά το backpropagation μέσα στον χρόνο (BPTT).

Long Short-Term Memory (LSTM)

Τα Long Short-Term Memory (LSTM) δίκτυα προτάθηκαν από τους Hochreiter και Schmidhuber [35] για να ξεπεράσουν το πρόβλημα της εξαφάνισης βαθμίδων (vanishing gradients) που χαρακτηρίζει τα κλασικά RNNs. Ο πυρήνας τους είναι το κελί μνήμης (C_t), το οποίο λειτουργεί ως μηχανισμός αποθήκευσης και μεταφοράς πληροφορίας κατά μήκος μεγάλων χρονικών διαστημάτων. Τρεις ειδικές πύλες (gates) ελέγχουν ποια πληροφορία θα προστεθεί, ποια θα διατηρηθεί και ποια θα απορριφθεί.

Ενα κελί μνήμης περιλαμβάνει τέσσερα βασικά συστατικά τα οποία ανανεώνουν και διατηρούν την κατάσταση του. Αυτά τα συστατικά είναι η forget gate (f_t), η input gate (i_t), το cell state (C_t) και η output gate (o_t). Σε κάθε χρονικό βήμα t κάθε συστατικό του κελιού υπολογίζονται ως εξής:

- Η πύλη **Forget gate** αποφασίζει ποιες πληροφορίες από την προηγούμενη κατάσταση μνήμης C_{t-1} θα διατηρηθούν ή θα απορριφθούν:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (2.6)$$

- Η πύλη **Input gate** καθορίζει ποιες νέες πληροφορίες θα προστεθούν στο κελί μνήμης:

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i), \quad (2.7)$$

- Η υποψήφια κατάσταση κελιού **Candidate Cell State** αντιπροσωπεύει μια φιλτραρισμένη εκδοχή της εισόδου:

$$\tilde{C}_t = \tanh(W_C[h_{t-1}, x_t] + b_C) \quad (2.8)$$

- Η πύλη **Cell state update** ενημερώνει την κατάσταση μνήμης συνδυάζοντας την προηγούμενη πληροφορία με τη νέα:

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (2.9)$$

- Η πύλη **Output gate** καθορίζει την έξοδο του κελιού και την κρυφή κατάσταση:


$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (2.10)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (2.11)$$

Στις παραπάνω εξισώσεις, $\sigma()$ είναι η λογιστική συνάρτηση (sigmoid), η οποία λειτουργεί ως φίλτρο μεταξύ 0 και 1, ενώ $\tanh()$ είναι η υπερβολική εφαπτομένη που περιορίζει τις τιμές στο διάστημα $[-1, 1]$. Οι πίνακες W_f , W_i , W_C , W_o είναι τα βάρη που μαθαίνονται κατά

την εκπαίδευση, ενώ b_f , b_i , b_C , b_o είναι τα αντίστοιχα biases. Το διάνυσμα $[h_{t-1}, x_t]$ συμβολίζει τη συνένωση της προηγούμενης κρυφής κατάστασης με την τρέχουσα είσοδο [45]. Μια τυπική αρχιτεκτονική ενός κελιού μνήμης LSTM παρουσιάζεται αναλυτικά στο σχήμα 2.3

Σχήμα 2.3: Αρχιτεκτονική ενός κελιού μνήμης LSTM. Αναπαραγωγή από [46].



Ο συνδυασμός αυτών των πυλών δίνει στα LSTM την ικανότητα να διατηρούν χρήσιμη πληροφορία για μεγάλα χρονικά διαστήματα και να απορρίπτουν ό,τι δεν είναι σημαντικό. Χάρη σε αυτήν την ιδιότητα, τα LSTM έχουν επιτύχει εξαιρετικά αποτελέσματα σε προβλήματα πρόβλεψης χρονοσειρών, όπως η πρόβλεψη παραγωγής φωτοβολταϊκής ισχύος, όπου συνυπάρχουν τόσο βραχυπρόθεσμες διακυμάνσεις (π.χ. λόγω νεφώσεων) όσο και μακροπρόθεσμα μοτίβα (π.χ. ημερήσιες περιοδικότητες).

Διδιάστατα LSTM (Bidirectional LSTM – BiLSTM)

Παρότι τα LSTM μοντελοποιούν εξαρτήσεις διαδοχικά (από παρελθόν προς μέλλον), σε πολλές εφαρμογές είναι ωφέλιμη η αξιοποίηση πληροφορίας και από τις επόμενες χρονικές στιγμές. Τα Bidirectional LSTM (BiLSTM) [47] επιτυγχάνουν αυτόν τον στόχο χρησιμοποιώντας δύο ξεχωριστές κατευθύνσεις επεξεργασίας: ένα forward LSTM και ένα backward LSTM. Για κάθε χρονικό βήμα t παράγονται δύο κρυφές καταστάσεις, οι οποίες συνδυάζονται:


$$h_t^{(bi)} = h_t^{(\rightarrow)} \oplus h_t^{(\leftarrow)}, \quad (2.12)$$

όπου $\oplus$ δηλώνει συνένωση (ή εναλλακτικά άθροιση/μέσο όρο), και $h_t^{(\rightarrow)}$, $h_t^{(\leftarrow)}$ οι έξοδοι των forward/backward LSTM. Η διπλή κατεύθυνση παρέχει πλουσιότερο περιεχόμενο (context), κάτι που έχει φανεί ωφέλιμο σε σειρές όπου το μοτίβο γύρω από ένα χρόνο t (πριν και μετά) είναι κρίσιμο. Στην πρόβλεψη φωτοβολταϊκής ισχύος, τα BiLSTM μπορούν να αξιοποιήσουν πληροφορία τόσο για το ιστορικό όσο και για τη μελλοντική δομή της ημέρας (π.χ. διαθέσιμες μετεωρολογικές προβλέψεις όλης της ημέρας).

2.3.2 Αρχιτεκτονικές Encoder-Decoder

Οι αρχιτεκτονικές encoder-decoder συνιστούν ένα θεμελιώδες πλαίσιο στη σύγχρονη έρευνα της βαθιάς μάθησης και έχουν υιοθετηθεί ευρέως σε προβλήματα που απαιτούν τη χαρτογράφηση δεδομένων εισόδου σε μια δομημένη και νοηματικά πλούσια έξοδο. Η γενική αρχή στηρίζεται στην ύπαρξη δύο διακριτών τμημάτων: του encoder, ο οποίος επεξεργάζεται την είσοδο και την συμπυκνώνει σε μία λανθάνουσα αναπαράσταση χαμηλότερης διάστασης, και του decoder, ο οποίος χρησιμοποιεί αυτήν την αναπαράσταση για να ανακατασκευάσει ή να μετασχηματίσει τα δεδομένα στην επιθυμητή μορφή, όπως φαίνεται στο σχήμα 2.4. Η διαμόρφωση αυτή καθιστά το μοντέλο ιδιαίτερα ευέλικτο, επιτρέποντας την αποδοτική μάθηση συμπαγών αναπαραστάσεων και τη μεταφορά γνώσης σε διαφορετικού τύπου δεδομένα[48].

Σχήμα 2.4: Αρχιτεκτονική encoder-decoder. Αναπαραγωγή από [49].



Η διαδικασία κωδικοποίησης επιδιώκει να απομονώσει και να ενισχύσει τα πιο κρίσιμα χαρακτηριστικά της εισόδου, απορρίπτοντας παράλληλα στοιχεία που θεωρούνται θορυβώδη ή μη συναφή με το υπό μελέτη πρόβλημα. Ανάλογα με το είδος των δεδομένων, η υλοποίηση του encoder μπορεί να βασίζεται σε διαφορετικά είδη νευρωνικών επιπέδων: συνελκτικά επίπεδα για δεδομένα με χωρική δομή (όπως εικόνες), αναδρομικά ή transformer-based επίπεδα για δεδομένα ακολουθιακής φύσης (όπως κείμενο ή σήματα), καθώς και πλήρως συνδεδεμένα δίκτυα για δεδομένα πινάκων.

Η λανθάνουσα αναπαράσταση που προκύπτει λειτουργεί ως «συμπιεσμένη περίληψη» των αρχικών δεδομένων, αναλαμβάνοντας τον ρόλο ενός στενοπού (bottleneck) μέσω του οποίου ενθαρρύνεται τόσο η γενίκευση όσο και η συμπίεση πληροφορίας. Από την πλευρά του, ο decoder αξιοποιεί τη συγκεκριμένη αναπαράσταση για να συνθέσει την έξοδο, η οποία μπορεί να έχει διαφορετική μορφή ή χρονική έκταση από την αρχική είσοδο, καθιστώντας την αρχιτεκτονική encoder-decoder κατάλληλη για εφαρμογές μετασχηματισμού ακολουθιών (sequence-to-sequence).

Μηχανισμός Προσοχής (Attention)

Ο μηχανισμός της προσοχής (attention mechanism) εισήχθη ως επέκταση των αρχιτεκτονικών τύπου encoder-decoder, με στόχο να αντιμετωπίσει το πρόβλημα της απώλειας πληροφορίας που εμφανίζεται όταν όλη η είσοδος συμπυκνώνεται σε ένα μοναδικό context vector [36]. Αντί να βασίζεται αποκλειστικά σε αυτή τη συνοπτική αναπαράσταση, το μοντέλο μπορεί να «εστιάσει» επιλεκτικά σε διαφορετικά μέρη της εισόδου, αποδίδοντας διαφορετικά βάρη ανάλογα με τη συνάφεια τους με την εκάστοτε πρόβλεψη.

Τυπικά, η συνάρτηση προσοχής αντιστοιχίζει ένα query με ένα σύνολο από ζεύγη key-value και παράγει ως έξοδο έναν σταθμισμένο συνδυασμό των values, όπου τα βάρη καθορίζονται από μία συνάρτηση συμβατότητας του query με το κάθε key.

Η πιο διαδεδομένη μορφή είναι η **Scaled Dot-Product Attention** [36]. Έστω queries $Q \in R^{n \times d_k}$, keys $K \in R^{m \times d_k}$ και values $V \in R^{m \times d_v}$. Ο μηχανισμός υπολογίζεται ως:

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right) V, \quad (2.13)$$

όπου d_k είναι η διάσταση των keys. Ο παράγοντας κανονικοποίησης $\sqrt{d_k}$ μειώνει το μέγεθος των εσωτερικών γινομένων, αποτρέποντας τη softmax από το να εισέρχεται σε περιοχές με πολύ μικρές κλίσεις.


Για να ενισχυθεί περαιτέρω η εκφραστικότητα, εισήχθη ο μηχανισμός **multi-head attention**. Τα queries, keys και values προβάλλονται σε πολλαπλούς υποχώρους μέσω διαφορετικών γραμμικών μετασχηματισμών, και σε κάθε υποχώρο υπολογίζεται ξεχωριστά προσοχή:

$$\text{head}_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V). \quad (2.14)$$

Οι έξοδοι όλων των κεφαλών συνενώνονται και προβάλλονται εκ νέου:

$$\text{MultiHead}(Q, K, V) = \text{Concat}(\text{head}_1, \dots, \text{head}_h)W^O. \quad (2.15)$$

Σχήμα 2.5: Διαφορά Scaled Dot-Product και Multi-Head Attention. Αναπαράγωγή από [36].



Η χρήση πολλαπλών κεφαλών επιτρέπει στο δίκτυο να εστιάζει ταυτόχρονα σε διαφορετικές θέσεις της ακολουθίας και σε διαφορετικούς υποχώρους αναπαράστασης, γεγονός που βελτιώνει την ικανότητα του να αποτυπώνει πολύπλοκες εξαρτήσεις. Ο μηχανισμός προσοχής αποτέλεσε το θεμέλιο για την ανάπτυξη των Transformers, τα οποία βασίζονται σχεδόν εξ ολοκλήρου σε αυτόν. Η διαφορά των δύο μηχανισμών προσοχής φαίνεται αναλυτικά στο σχήμα 2.5.

Transformers

Οι Transformers αποτέλεσαν σημείο καμπής στη μελέτη μοντέλων ακολουθιών, εισάγοντας τον μηχανισμό της αυτοπροσοχής (self-attention) ως βασικό δομικό στοιχείο [36]. Σε αντίθεση με τα αναδρομικά δίκτυα, τα οποία επεξεργάζονται τις ακολουθίες σειριακά, οι Transformers υπολογίζουν τις σχέσεις μεταξύ όλων των στοιχείων μιας ακολουθίας ταυτόχρονα, επιτυγχάνοντας έτσι παράλληλη επεξεργασία και σημαντική μείωση του υπολογιστικού κόστους.

Η αρχιτεκτονική τους βασίζεται σε πολλαπλές στρώσεις multi-head self-attention και πλήρως συνδεδεμένα υποδίκτυα, οι οποίες περικλείονται σε δομές τύπου encoder και decoder. Για να αντιμετωπιστεί η έλλειψη εγγενούς χρονικής διάστασης, εισάγονται επιπλέον διανύσματα θέσης (positional encodings), τα οποία παρέχουν πληροφορία σχετικά με τη σειρά των στοιχείων.

Η αποτελεσματικότητα των Transformers σε μεγάλα σύνολα δεδομένων, η δυνατότητα παράλληλης εκπαίδευσης και η ικανότητα αποτύπωσης μακροχρόνιων εξαρτήσεων τους καθιστούν κατάλληλους για ποικίλα προβλήματα, από την επεξεργασία φυσικής γλώσσας έως την πρόβλεψη χρονοσειρών.

Temporal Fusion Transformer (TFT)


Ο Temporal Fusion Transformer (TFT) [50] ως ένα προηγμένο μοντέλο πρόβλεψης χρονοσειρών πολλαπλών οριζόντων (multi-horizon forecasting), συνδυάζοντας την υψηλή ακρί-

βεια με ερμηνευσιμότητα. Η αρχιτεκτονική του TFT αξιοποιεί στοιχεία από RNNs, μηχανισμούς προσοχής και δίκτυα επιλογής μεταβλητών, με σκοπό να εκμεταλλευτεί τόσο τις βραχυπρόθεσμες όσο και τις μακροπρόθεσμες εξαρτήσεις στα δεδομένα, όπως φαίνεται στο σχήμα 2.6.

Τα κύρια συστατικά του μοντέλου είναι τα εξής:

- **Gated Residual Networks (GRNs)** τα οποία χρησιμοποιούνται για την επιλογή μεταβλητών (variable selection) σε κάθε χρονικό βήμα, επιτρέποντας στο δίκτυο να επικεντρώνεται στις πιο σημαντικές εισόδους και να αγνοεί τις λιγότερο σχετικές.
- **LSTM encoder-decoder layers**, τα οποία αποτυπώνουν τοπικές χρονικές εξαρτήσεις και λειτουργούν ως βάση της αρχιτεκτονικής, εξασφαλίζοντας την ακολουθιακή κατανόηση των δεδομένων.
- **Multi-Head Attention**, η οποία συλλαμβάνει μακροχρόνιες εξαρτήσεις, επιτρέποντας στο μοντέλο να σταθμίζει τη σημασία χρονικών στιγμών σε διαφορετικά σημεία της ακολουθίας.
- **Static covariate encoders**, οι οποίοι ενσωματώνουν στατικές πληροφορίες (π.χ. χωροταξικά ή γεωμετρικά χαρακτηριστικά ενός Φ/Β πάρκου), επηρεάζοντας τη δυναμική της πρόβλεψης σε όλα τα χρονικά βήματα.
- **Interpretable attention weights**, τα οποία παρέχουν δυνατότητα ερμηνείας, δείχνοντας ποιες μεταβλητές και ποιες χρονικές στιγμές συνέβαλαν περισσότερο στην πρόβλεψη.

Σχήμα 2.6: Αρχιτεκτονική Temporal Fusion Transformer. Αναπαραγωγή από [50].



Ένα σημαντικό πλεονέκτημα του TFT είναι η ικανότητά του να χειρίζεται διαφορετικού τύπου εισόδους: ιστορικές, μελλοντικές και στατικές μεταβλητές. Η ενσωμάτωση αυτών σε ενιαίο πλαίσιο επιτρέπει την αξιοποίηση εξωτερικών παραγόντων (π.χ. μετεωρολογικές προβλέψεις) σε συνδυασμό με ιστορικά δεδομένα. Αυτό καθιστά το μοντέλο ιδιαίτερα κατάλληλο για εφαρμογές στον ενεργειακό τομέα και ειδικά για την πρόβλεψη παραγωγής φωτοβολταϊκών συστημάτων, όπου απαιτείται τόσο υψηλή ακρίβεια όσο και ερμηνευσιμότητα.

Συνολικά, ο TFT συνδυάζει τα πλεονεκτήματα των RNNs (τοπική ακολουθιακή μοντελοποίηση), των Transformers (μακροχρόνια εξαρτήσεις και παράλληλη επεξεργασία), του μηχανισμού της προσοχής και των μηχανισμών επιλογής μεταβλητών, παρέχοντας ένα από τα πιο σύγχρονα και ισχυρά εργαλεία για πρόβλεψη χρονοσειρών.

2.4 Μετρικές Αξιολόγησης

Η αξιολόγηση της απόδοσης ενός μοντέλου πρόβλεψης χρονοσειρών πραγματοποιείται μέσω κατάλληλων μετρικών σφάλματος, οι οποίες συγκρίνουν τις πραγματικές τιμές y_t με τις προβλεπόμενες $\hat{y}_t$. Στην παρούσα εργασία χρησιμοποιήθηκαν οι μετρικές MAE, RMSE και R^2 , ωστόσο αναφέρεται επίσης και η MAPE, καθώς και ο λόγος που δεν χρησιμοποιήθηκε.

Mean Absolute Error (MAE).

Η μετρική MAE μετρά το μέσο απόλυτο σφάλμα μεταξύ πραγματικών και προβλεπόμενων τιμών:

$$\text{MAE} = \frac{1}{N} \sum_{t=1}^N |y_t - \hat{y}_t|. \quad (2.16)$$

Η MAE είναι απλή στην ερμηνεία, καθώς εκφράζει το μέσο σφάλμα στις ίδιες μονάδες με τη μεταβλητή στόχο [51].

Mean Bias Error (MBE).

Η MBE μετρά την τάση του μοντέλου να υπερεκτιμά ή να υποεκτιμά συστηματικά τις τιμές:

$$\text{MBE} = \frac{1}{N} \sum_{t=1}^N (\hat{y}_t - y_t). \quad (2.17)$$

Θετικές τιμές δείχνουν υπερεκτίμηση, ενώ αρνητικές υποεκτίμηση. Η MBE παρέχει χρήσιμη πληροφορία για την ύπαρξη συστηματικού σφάλματος.

Root Mean Squared Error (RMSE).

Η μετρική RMSE δίνει μεγαλύτερη βαρύτητα σε μεγαλύτερα σφάλματα, καθώς βασίζεται στα τετράγωνα των διαφορών:

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{t=1}^N (y_t - \hat{y}_t)^2}. \quad (2.18)$$

Η RMSE είναι ευαίσθητη σε ακραίες τιμές (outliers), αλλά συχνά χρησιμοποιείται σε προβλήματα πρόβλεψης ενέργειας για την ανάδειξη μεγάλων αποκλίσεων [51].

Normalized Root Mean Squared Error (NRMSE).

Για τη σύγκριση μοντέλων σε διαφορετικές κλίμακες, η RMSE μπορεί να κανονικοποιηθεί ως προς το μέσο ή το εύρος των δεδομένων:

$$\text{NRMSE} = \frac{\text{RMSE}}{\bar{y}} \times 100, \quad (2.19)$$

όπου $\bar{y}$ είναι ο μέσος όρος των πραγματικών τιμών. Η NRMSE εκφράζεται σε ποσοστό και επιτρέπει την αξιολόγηση ανεξάρτητα από τη μονάδα μέτρησης.

Mean Absolute Percentage Error (MAPE).

Η MAPE εκφράζει το μέσο σφάλμα ως ποσοστό των πραγματικών τιμών:

$$\text{MAPE} = \frac{100}{N} \sum_{t=1}^N \left| \frac{y_t - \hat{y}_t}{y_t} \right|. \quad (2.20)$$

Η μετρική αυτή είναι διαισθητική, καθώς αποδίδει σφάλμα σε ποσοστιαία μορφή. Ωστόσο, παρουσιάζει σοβαρό μειονέκτημα όταν $y_t = 0$, καθώς το κλάσμα δεν ορίζεται. Για τον λόγο αυτό, η MAPE δεν εφαρμόζεται σε περιπτώσεις όπου η πραγματική τιμή είναι μηδενική [52].

Symmetric Mean Absolute Percentage Error (sMAPE).

Η sMAPE αποτελεί μία βελτιωμένη, συμμετρική εκδοχή της MAPE, η οποία αποφεύγει το πρόβλημα διαίρεσης με το μηδέν και εξισορροπεί τα ποσοστιαία σφάλματα. Ορίζεται ως:

$$\text{sMAPE} = \frac{100}{N} \sum_{t=1}^N \frac{|y_t - \hat{y}_t|}{\frac{|y_t| + |\hat{y}_t|}{2}}. \quad (2.21)$$

Σε αντίθεση με τη MAPE, η sMAPE είναι περιορισμένη στο διάστημα $[0, 200]$ και παρέχει πιο αξιόπιστα αποτελέσματα όταν οι πραγματικές τιμές προσεγγίζουν το μηδέν [52]. Χρησιμοποιείται ευρέως σε προβλήματα πρόβλεψης ενέργειας και χρονοσειρών, καθώς συνδυάζει

την ευκολία ερμηνείας της MAPE με μεγαλύτερη σταθερότητα.

Συντελεστής Προσδιορισμού (R^2).

Ο συντελεστής προσδιορισμού (R^2) μετρά το ποσοστό της διακύμανσης των δεδομένων που εξηγείται από το μοντέλο:

$$R^2 = 1 - \frac{\sum_{t=1}^N (y_t - \hat{y}_t)^2}{\sum_{t=1}^N (y_t - \bar{y})^2}, \quad (2.22)$$

όπου $\bar{y}$ είναι ο μέσος όρος των πραγματικών τιμών. Τιμές κοντά στο 1 υποδεικνύουν υψηλή ακρίβεια πρόβλεψης, ενώ αρνητικές τιμές δείχνουν ότι το μοντέλο αποδίδει χειρότερα από έναν απλό μέσο όρο [53].

Συνολικά, η χρήση πολλαπλών μετρικών επιτρέπει μία πιο ολοκληρωμένη εκτίμηση της απόδοσης των μοντέλων, καθώς κάθε μετρική αναδεικνύει διαφορετικές πτυχές του σφάλματος.

2.5 Βιβλιογραφική Ανασκόπηση

Η βιβλιογραφία σχετικά με την πρόβλεψη παραγωγής ισχύος φωτοβολταϊκών (PV power forecasting) έχει γνωρίσει ραγδαία ανάπτυξη τις τελευταίες δεκαετίες, με έμφαση στη μετάβαση από παραδοσιακές στατιστικές μεθόδους σε μοντέλα μηχανικής και βαθιάς μάθησης. Η χρήση χρονοσειρών, σε συνδυασμό με μετεωρολογικά δεδομένα και δεδομένα λειτουργίας Φ/Β πάρκων, έχει καταστήσει δυνατή την εφαρμογή σύνθετων αλγορίθμων που αξιοποιούν μη γραμμικές σχέσεις και πολυδιάστατες εξαρτήσεις.

Ιδιαίτερα, μοντέλα όπως τα LSTM, τα CNN και πιο πρόσφατα οι Transformers (π.χ. Temporal Fusion Transformer – TFT) έχουν αναδειχθεί ως κύριες προσεγγίσεις για την πρόβλεψη χρονοσειρών, λόγω της ικανότητάς τους να αποτυπώνουν τόσο βραχυπρόθεσμες όσο και μακροπρόθεσμες εξαρτήσεις. Παράλληλα, υβριδικές προσεγγίσεις που συνδυάζουν διαφορετικά μοντέλα έχουν δείξει ενισχυμένη απόδοση.

Για να συνοψιστούν οι κυριότερες ερευνητικές προσπάθειες, στους Πίνακες 2.1 και 2.2 παρουσιάζονται αντιπροσωπευτικές μελέτες που αξιοποιούν διαφορετικές αρχιτεκτονικές, δεδομένα και μετρικές αξιολόγησης για PV forecasting. Ο πίνακας αυτός παρέχει μια συνολική εικόνα της τρέχουσας κατάστασης και αναδεικνύει τα κενά της βιβλιογραφίας, τα οποία επιχειρεί να καλύψει η παρούσα εργασία.

Πίνακας 2.1: Ενδεικτικές μελέτες ML/DL για PV Power Forecasting

Συγγραφείς / Έτος	Ορίζοντας Πρόβλεψης	Χρονική Ανάλυση	Τοποθεσία	Μοντέλο	Είσοδοι
Zamo et al. (2014) [54]	66 - 72 h	1h	France	LMQR, QR Forest	Weather Predicted Data (ghi, temperature, humidity, wind speed, cloud, air pressure)
Almonacid et al. (2014) [55]	1h	1h	Jaén, Spain	DANN – TDNN – NAR	Weather Predicted Data (ghi, temperature)
Sun et al. (2019) [56]	15 min		United States	CNN	Sky Images
Gao et al. (2019) [57]	1 day	15min	Shandong province, China	LSTM	Historical PV Power and Local Weather Data (ghi, temperature, humidity, wind speed, cloud, air pressure)
Pombo et al. (2022) [58]	1-3 days ahead	1h	Roskilde, Denmark	Physics Informed ML Model	Historical PV Power and Local Weather Data (temperature, wind speed)
Sarmas et al. (2022) [59]	1h	1h	Portugal	LSTM	Historical PV Power and Local Weather Data (ghi, temperature, humidity)
Wu et al. (2022) [60]	1 day	5 min	Yulara, Northern Territory, Australia	CNN-Informer	Historical PV Power and Local Weather Data (ghi, dhi, temperature, humidity, wind direction, wind speed, daily rainfall)
Dhaked et al. (2023) [61]	Multi-horizon	15 min	India	LSTM, BPNN	Local Weather Data(temperature, wind speed)
Babalhavaeji et al. (2023) [62]	Multi-horizon	15 min	Shandong, China	LSTM, CNN	Local Weather Data(POA, humidity, temperature, wind speed)

Πίνακας 2.2: Ενδεικτικές μελέτες ML/DL για PV Power Forecasting - Συνέχεια

Συγγραφείς / Έτος	Ορίζοντας Πρόβλεψης	Χρονική Ανάλυση	Τοποθεσία	Μοντέλο	Είσοδοι
Islam et al. (2023) [63]	1h	15 min	India	TFT	Historical PV Power and Local Weather Data (ghi, temperature)
Zhang et al. (2023) [13]	Multi-horizon	1h	China	Physical Model, CNN-BiLSTM	Weather Forecasted Data (ghi, temperature, wind speed, humidity)
Zhou et al. (2024) [64]	1 day	1h	Zhenjiang, China	TFT	Historical PV Power
Yang et al. (2025) [65]	5 min	5 min	Alice Springs, Australia	Transformer, Informer	Historical PV Power and Local Weather Data (ghi, dhi, temperature, humidity)
Liu et al. (2025) [66]	2 days to 1 month	5 min	Yulara, Northern Territory, Australia	IFTformer	Historical PV Power and Local Weather Data (ghi, dhi, poa, temperature, humidity, wind direction, wind speed, daily rainfall)
Zhai et al. (2025) [67]	15 min to 1h	1 min	Wuxi, Jiangsu Province, China	VMD-SSA-Transformer	Historical PV Power and Weather Forecasted Data (ghi, dni, dhi, temperature, humidity, wind speed)

Από την επισκόπηση της βιβλιογραφίας προκύπτει ότι η πρόβλεψη ισχύος φωτοβολταϊκών συστημάτων έχει μελετηθεί εκτενώς με πληθώρα μεθόδων μηχανικής και βαθιάς μάθησης. Οι πρώτες προσεγγίσεις στη βιβλιογραφία για την πρόβλεψη φωτοβολταϊκής ισχύος δεν περιελάμβαναν τη χρήση ιστορικών δεδομένων παραγωγής ως είσοδο, αλλά βασίζονταν αποκλειστικά σε μετεωρολογικές προβλέψεις καθώς τα δεδομένα είχαν μεγαλύτερη χρονική ανάλυση. Ενδεικτικά, οι Zamo et al. (2014) [54] και Almonacid et al. (2014) [55] χρησιμοποίησαν κλασικά μοντέλα μηχανικής μάθησης, όπως τα Quantile Regression Forests και τα DANN/TDNN αντίστοιχα, με δεδομένα ηλιακής ακτινοβολίας, θερμοκρασίας και λοιπών μετεωρολογικών παραμέτρων, επιτυγχάνοντας ικανοποιητικά αποτελέσματα σε βραχυπρόθεσμους ορίζοντες πρόβλεψης.

Με την εξέλιξη της βαθιάς μάθησης και την αύξηση των RNN, οι προσεγγίσεις μετατοπίστηκαν σε πιο σύνθετες αρχιτεκτονικές. Οι Gao et al. (2019) [57] εφάρμοσαν LSTM για ημερήσια πρόβλεψη, ενσωματώνοντας ιστορικά δεδομένα ισχύος σε συνδυασμό με μετεωρολογικές εισόδους, ενώ οι Dhaked et al. (2023) [61] εφάρμοσαν LSTM και BPNN για πολυ-ορίζοντα πρόβλεψη στην Ινδία, εστιάζοντας σε θερμοκρασία και άνεμο. Αντίστοιχα, οι Pombo et al. (2022) [58] πρότειναν ένα υβριδικό φυσικοστατιστικό μοντέλο (Physics-Informed ML), συνδυάζοντας φυσικές εξισώσεις με τεχνικές μηχανικής μάθησης.

Οι Sarmas et al. (2022) [59] διερεύνησαν την εφαρμογή τεχνικών transfer learning για LSTM, επιτρέποντας τη μεταφορά γνώσης μεταξύ διαφορετικών πάρκων. Παράλληλα, με εξέλιξη των CNN αυτά άρχισαν να χρησιμοποιούνται είτε για αναγνώριση εικόνων είτε ως συστατικά σε υβριδικά μοντέλα. Οι Sun et al. (2019) [56] εισήγαγαν τα CNN για πρόβλεψη 15 λεπτών χρησιμοποιώντας δεδομένα από εικόνες ουρανού, ενώ Οι Zhang et al. (2023) [13] και οι Babalhavaeji et al. (2023) [62] χρησιμοποίησαν υβριδικό CNN-LSTM με δεδομένα POA, επιτυγχάνοντας αυξημένη ακρίβεια σε πλαίσιο ψηφιακού διδύμου μέσω της ενσωμάτωσης φυσικών παραμέτρων.

Οι πιο πρόσφατες μελέτες επικεντρώνονται σε μοντέλα τύπου Transformer, τα οποία αξιοποιούν μηχανισμούς προσοχής για βελτίωση της απόδοσης και της ερμηνευσιμότητας. Οι Islam et al. (2023) [63] και Zhou et al. (2024) [64] εφάρμοσαν τον Temporal Fusion Transformer για πρόβλεψη μίας ώρας και μίας ημέρας αντίστοιχα, επιδεικνύοντας σημαντικά πλεονεκτήματα σε multi-horizon προβλέψεις. Οι Yang et al. (2025) [65] και Liu et al. (2025) [66] παρουσίασαν εξελιγμένες παραλλαγές Transformer (Informer και IFTformer), όπως και οι Wu et al. (2022) [60] οι οποίοι πρότειναν τον συνδυασμό CNN και Informer, επιτυγχάνοντας υψηλής ανάλυσης προβλέψεις 5 λεπτών. Τέλος, οι Zhai et al. (2025) [67] πρότειναν το VMD-SSA-Transformer, το οποίο συνδυάζει αποσύνθεση σήματος και μηχανισμούς προσοχής, ενισχύοντας την ακρίβεια σε δεδομένα υψηλής χρονικής ανάλυσης.

Η παρούσα εργασία τοποθετείται στο πλαίσιο αυτό, αξιοποιώντας σύγχρονες αρχιτεκτονικές βαθιάς μάθησης, όπως τα CNN, BiLSTM και TFT, οι οποίες έχουν αποδειχθεί ιδιαίτερα αποτελεσματικές στην πρόβλεψη χρονοσειρών παραγωγής φωτοβολταϊκών. Σε αντίθεση όμως με τις προαναφερθείσες προσεγγίσεις, οι οποίες εκπαιδεύονται κυρίως σε ιστορικά δε-

δομένα ισχύος, η παρούσα εργασία επικεντρώνεται στη δημιουργία δεδομένων ισχύος, αξιοποιώντας ως είσοδο παραμέτρους που προκύπτουν από φυσικές εξισώσεις και υπολογιστικά μοντέλα, όπως η γωνία πρόσπτωσης και η ακτινοβολία στο επίπεδο του πάνελ, οποίες θα παρουσιαστούν αναλυτικά στην ενότητα 3.3. Με αυτόν τον τρόπο, τα μοντέλα δεν εξαρτώνται από διαθέσιμες χρονοσειρές παραγωγής, οι οποίες συχνά απουσιάζουν σε νέα πάρκα ή σε εγκαταστάσεις υπό σχεδιασμό.

Ο στόχος της εργασίας δεν είναι η πρόβλεψη της μελλοντικής παραγωγής, αλλά η δημιουργία αξιόπιστων συνθετικών δεδομένων ισχύος, ικανών να αναπαραστήσουν τη συμπεριφορά ενός φωτοβολταϊκού πάρκου υπό συγκεκριμένες γεωμετρικές και μετεωρολογικές συνθήκες. Η προσέγγιση αυτή μπορεί να θεωρηθεί ως μία μορφή transfer learning, καθώς τα εκπαιδευμένα μοντέλα μαθαίνουν τη σχέση μεταξύ φυσικών παραμέτρων και ισχύος από ένα γνωστό πάρκο και στη συνέχεια μπορούν να μεταφερθούν για χρήση σε άλλα πάρκα με διαφορετικά χαρακτηριστικά, ακόμη και χωρίς ιστορικά δεδομένα παραγωγής.

Κεφάλαιο 3

Γεωμετρικά και Περιβαλλοντικά Δεδομένα του Φωτοβολταϊκού Πάρκου

Η αποδοτική λειτουργία ενός φωτοβολταϊκού (ΦΒ) πάρκου εξαρτάται άμεσα τόσο από τα γεωμετρικά του χαρακτηριστικά όσο και από τις επικρατούσες περιβαλλοντικές και ηλιακές συνθήκες. Παράγοντες όπως ο προσανατολισμός και η κλίση των πάνελ, η τοποθεσία εγκατάστασης, καθώς και η προσπίπτουσα ηλιακή ακτινοβολία και η θερμοκρασία περιβάλλοντος, επηρεάζουν σημαντικά την ενεργειακή απόδοση του συστήματος[68, 69]. Στο παρόν κεφάλαιο παρουσιάζονται αναλυτικά οι στατικές και γεωμετρικές παράμετροι του υπό μελέτη φωτοβολταϊκού πάρκου, καθώς και τα βασικά μετεωρολογικά και ηλιακά δεδομένα που χρησιμοποιήθηκαν για την ανάλυση και πρόβλεψη της παραγόμενης ισχύος.

3.1 Γεωμετρικά και Στατικά Χαρακτηριστικά

3.1.1 Γεωγραφικό Μήκος, Πλάτος και Υψόμετρο

Η γεωγραφική θέση του φωτοβολταϊκού πάρκου, δηλαδή το γεωγραφικό πλάτος, το μήκος και το υψόμετρο, βοηθούν να καθοριστεί η σχετική θέση του ήλιου αναφορικά με το πάρκο, η οποία επηρεάζει σημαντικά την προσπίπτουσα ηλιακή ακτινοβολία. Το γεωγραφικό πλάτος καθορίζει τη γωνία με την οποία ο ήλιος διασχίζει τον ουρανό σε διαφορετικές εποχές, ενώ το υψόμετρο συνδέεται με την ένταση της ακτινοβολίας λόγω μειωμένης ατμοσφαιρικής απορρόφησης. Επιπλέον, επηρεάζει και τη θερμοκρασία περιβάλλοντος, η οποία με τη σειρά της επηρεάζει την απόδοση των φωτοβολταϊκών πλαισίων μέσω θερμικών απωλειών.

3.1.2 Κλίση και Προσανατολισμός

Η κλίση (tilt) των πάνελ, δηλαδή η γωνία τους σε σχέση με το οριζόντιο επίπεδο, επηρεάζει τη γωνία πρόσπτωσης της ηλιακής ακτινοβολίας κατά τη διάρκεια της ημέρας και του

έτους. Βέλτιστα επίπεδα κλίσης επιτρέπουν τη μέγιστη ετήσια ή εποχική εκμετάλλευση της ηλιακής ενέργειας. Από την άλλη πλευρά, ο προσανατολισμός (azimuth) των πάνελ, που εκφράζεται ως γωνία από τον γεωγραφικό βορρά (με τον νότο στο βόρειο ημισφαίριο να αντιστοιχεί στις 180°), καθορίζει τη χρονική κατανομή της παραγόμενης ισχύος εντός της ημέρας. Ένα σύστημα με προσανατολισμό νοτιοανατολικά θα εμφανίζει υψηλότερη πρωινή παραγωγή, ενώ ένα σύστημα με νοτιοδυτικό προσανατολισμό θα ευνοεί την απογευματινή παραγωγή. [70]

3.1.3 Ονομαστική Ισχύς

Η ονομαστική ισχύς του συστήματος, τόσο στο συνεχές ρεύμα (DC) όσο και στο εναλλασσόμενο (AC), καθορίζει τη μέγιστη ισχύ που μπορεί να παραχθεί και να μεταφερθεί στο δίκτυο. Η DC ισχύς προκύπτει από τα φωτοβολταϊκά πλαίσια, ενώ η AC ισχύς περιορίζεται από την ικανότητα των μετατροπέων (inverters). Η αναλογία DC/AC, γνωστή και ως Inverter Loading Ratio (ILR), είναι κρίσιμος σχεδιαστικός παράγοντας, καθώς επηρεάζει την πιθανότητα ενεργειακού clipping, δηλαδή την απώλεια ενέργειας κατά τις ώρες μέγιστης ηλιοφάνειας όταν η DC παραγωγή υπερβαίνει την ικανότητα του inverter. Η κατανόηση και ενσωμάτωση της σχέσης αυτής είναι σημαντική, ιδιαίτερα όταν η έξοδος του μοντέλου πρόβλεψης πρόκειται να κανονικοποιηθεί ως ποσοστό της ονομαστικής ισχύος, ώστε να καταστεί εφικτή η σύγκριση μεταξύ συστημάτων διαφορετικής κλίμακας. [68, 71]

Συνοψίζοντας, τα στατικά και γεωμετρικά χαρακτηριστικά του φωτοβολταϊκού πάρκου δεν είναι από μόνα τους προβλεπτικές μεταβλητές, αλλά καθορίζουν ουσιαστικά το ενεργειακό δυναμικό του συστήματος και χρησιμεύουν ως βάση για τη δημιουργία κρίσιμων παραγόμενων μεταβλητών και κανονικοποιήσεων. Ως εκ τούτου, αποτελούν αναπόσπαστο μέρος της προεπεξεργασίας και του σχεδιασμού μοντέλων πρόβλεψης με δυνατότητα γενίκευσης σε πολλαπλά φωτοβολταϊκά πάρκα με ετερογενή χαρακτηριστικά.

3.2 Ηλιακά και Μετεωρολογικά Δεδομένα

Η ακριβής πρόβλεψη της παραγόμενης ισχύος από ένα φωτοβολταϊκό σύστημα απαιτεί, εκτός από τα γεωμετρικά χαρακτηριστικά, και τη συστηματική καταγραφή των μετεωρολογικών και ηλιακών συνθηκών που επικρατούν στον χώρο εγκατάστασης. Οι συνθήκες αυτές είναι δυναμικές και παρουσιάζουν έντονη χρονική και εποχιακή μεταβλητότητα, επηρεάζοντας άμεσα ή έμμεσα την απόδοση των φωτοβολταϊκών πλαισίων.

3.2.1 Ακτινοβολία

Η ηλιακή ακτινοβολία που φτάνει στην επιφάνεια της γης προέρχεται από την εξωατμοσφαιρική δέσμη ακτινοβολίας (EBI), η οποία υφίσταται απορρόφηση, σκέδαση και ανα-

κλάσεις από τα αέρια και τα σωματίδια της ατμόσφαιρας. Κατά την άφιξή της στο επίπεδο του εδάφους, η ακτινοβολία αυτή διακρίνεται σε δύο βασικές συνιστώσες: την άμεση κανονική ακτινοβολία (DNI) και την διάχυτη οριζόντια ακτινοβολία (DHI) [72]. Το συνολικό ποσό ακτινοβολίας που προσπίπτει σε μία οριζόντια επιφάνεια, δηλαδή η παγκόσμια οριζόντια ακτινοβολία (GHI), , όπως φαίνεται στο σχήμα 3.1, προκύπτει από το άθροισμα των δύο αυτών συνιστωσών, λαμβάνοντας υπόψη και τη γωνία ζενίθ του ήλιου, σύμφωνα με τη σχέση:

$$GHI = DHI + DNI \cdot \cos(\theta_z) \quad (3.1)$$

όπου θ_z είναι η γωνία ζενίθ, δηλαδή η γωνία μεταξύ της κατακόρυφης κατεύθυνσης και της διεύθυνσης του ήλιου. [73]

Η ολική οριζόντια ακτινοβολία (GHI - Global Horizontal Irradiance) αποτελεί το βασικότερο μέγεθος που χρησιμοποιείται στην αξιολόγηση της ηλιακής δυναμικής ενός τόπου, καθώς περιγράφει το σύνολο της ηλιακής ενέργειας που φτάνει σε οριζόντιο επίπεδο. Χρησιμοποιείται ευρέως σε σταθερές ΦΒ εγκαταστάσεις και σε ενεργειακές προσομοιώσεις, ενώ μπορεί να μετρηθεί με πυρηλιόμετρα ή πυρανομετρικούς αισθητήρες που είναι τοποθετημένοι οριζόντια.

Η άμεση κανονική ακτινοβολία (DNI - Direct Normal Irradiance) αντιπροσωπεύει την κατευθυνόμενη ηλιακή ακτινοβολία που προσπίπτει σε επιφάνεια προσανατολισμένη κάθετα προς τον ήλιο. Είναι κρίσιμη μεταβλητή για εγκαταστάσεις συγκέντρωσης ηλιακής ακτινοβολίας (CSP, CPV). Μετράται με πυρηλιόμετρα ή περιστρεφόμενους αισθητήρες σκί-ασης.

Η διάχυτη οριζόντια ακτινοβολία (DHI - Diffuse Horizontal Irradiance), από την άλλη πλευρά, περιγράφει την ακτινοβολία που φτάνει στο έδαφος μετά από σκέδαση στην ατμόσφαιρα. Δεν προέρχεται άμεσα από τον δίσκο του ήλιου, αλλά από το "διάχυτο" φως του ουρανού. Είναι σημαντική ιδιαίτερα σε συνθήκες νεφώδους καιρού ή ρύπανσης, καθώς επηρεάζει την παραγωγή ακόμα και όταν ο ήλιος δεν είναι ορατός.[72, 73]


Ωστόσο, οι παραπάνω μετρήσεις αναφέρονται σε οριζόντιες ή θεωρητικά προσανατολισμένες επιφάνειες και δεν επαρκούν από μόνες τους για την εκτίμηση της ακτινοβολίας που προσπίπτει στο επίπεδο των φωτοβολταϊκών πάνελ. Για τον λόγο αυτό, γίνεται υπολογισμός δύο κρίσιμων μεταβλητών, της Γωνίας πρόσπτωσης και της Ακτινοβολίας στο επίπεδο του πάνελ, ο υπολογισμός των οποίων θα γίνει αναλυτικά στην υποενότητα 2.4.

Η Γωνία Πρόσπτωσης (AOI - Angle of Incidence) είναι η γωνία μεταξύ της διεύθυνσης της ηλιακής ακτινοβολίας και της κάθετης στην επιφάνεια του πάνελ. Η AOI επηρεάζει την πραγματική ποσότητα ακτινοβολίας που απορροφάται από το πάνελ, καθώς οι ανακλάσεις και οι απώλειες αυξάνονται με τη γωνία.[74]

Η Ακτινοβολία στο Επίπεδο του Πάνελ (POA - Plane of Array Irradiance) είναι η συνολική ακτινοβολία (άμεση + διάχυτη + ανακλώμενη) που προσπίπτει στην κεκλιμένη επιφά-

νεια των πάνελ, λαμβάνοντας υπόψη τη γωνία εγκατάστασης. Η POA αποτελεί τη βέλτιστη προσέγγιση για την είσοδο της ενέργειας στο σύστημα και χρησιμοποιείται συχνά σε μοντέλα πρόβλεψης ισχύος.[73]

Σχήμα 3.1: Αναπαράσταση Ακτινοβολίας. Αναπαραγωγή από [75].



3.2.2 Άλλοι Μετεωρολογικοί Παράγοντες

Επιπλέον, ιδιαίτερη σημασία για την ενεργειακή απόδοση ενός φωτοβολταϊκού συστήματος έχει η **θερμοκρασία περιβάλλοντος**, καθώς επηρεάζει άμεσα τη θερμοκρασία λειτουργίας των φωτοβολταϊκών πλαισίων. Οι ηλιακές κυψέλες, αν και αποδίδουν καλύτερα σε υψηλή ηλιακή ακτινοβολία, παρουσιάζουν μειωμένη ηλεκτρική απόδοση σε υψηλές θερμοκρασίες, λόγω της αύξησης της εσωτερικής αντίστασης και των θερμικών απωλειών στους ημιαγωγούς. Η αύξηση της θερμοκρασίας του πάνελ οδηγεί σε μείωση της τάσης εξόδου, γεγονός που επηρεάζει σημαντικά την παραγόμενη ισχύ, ιδιαίτερα κατά τις μεσημβρινές ώρες με έντονη ηλιοφάνεια και χαμηλή κυκλοφορία αέρα.[68, 76]

Καθοριστικό ρόλο στη ρύθμιση της θερμοκρασίας των πάνελ διαδραματίζει η **ταχύτητα του ανέμου**, καθώς ο αέρας λειτουργεί ως φυσικός μηχανισμός απαγωγής θερμότητας από την πίσω επιφάνεια των πλαισίων. Η παρουσία ανέμου αυξάνει τον ρυθμό μεταφοράς θερμότητας με συναγωγή, μειώνοντας τη θερμοκρασία λειτουργίας των κυψελών και κατά συνέπεια βελτιώνοντας την απόδοσή τους. Αντιθέτως, σε συνθήκες νηνεμίας και έντονης ηλιοφάνειας, η θερμοκρασία των πάνελ μπορεί να αυξηθεί σημαντικά πάνω από τη θερμοκρασία

περιβάλλοντος, επηρεάζοντας αρνητικά την τελική ενεργειακή παραγωγή του συστήματος. [76]

3.3 Υπολογισμός Σύνθετων Ηλιακών Παραμέτρων

Για την αξιόπιστη πρόβλεψη της παραγόμενης ισχύος σε φωτοβολταϊκά πάρκα απαιτείται ο ακριβής υπολογισμός μεταβλητών που σχετίζονται με τη θέση του ήλιου και τη γεωμετρία του συστήματος. Η παρούσα εργασία αξιοποιεί τη βιβλιοθήκη `pvlib`, μία από τις πλέον ευρέως χρησιμοποιούμενες πλατφόρμες για την ηλιακή προσομοίωση και μοντελοποίηση σε περιβάλλον Python. Στις επόμενες υποενότητες παρουσιάζονται τα βήματα υπολογισμού βασικών ηλιακών παραμέτρων, όπως η ηλιακή θέση, η γωνία πρόσπτωσης (AOI) και η ακτινοβολία στο επίπεδο των πάνελ (POA), βάσει των γεωμετρικών και μετεωρολογικών δεδομένων του συστήματος.

3.3.1 Η βιβλιοθήκη `pvlib`


Η `pvlib` αποτελεί μία ανοιχτού κώδικα βιβλιοθήκη σε Python, η οποία προσφέρει εργαλεία για τη μοντελοποίηση της απόδοσης φωτοβολταϊκών συστημάτων. Αναπτύχθηκε ως επέκταση του αντίστοιχου λογισμικού σε MATLAB από το Sandia National Laboratories και σήμερα υποστηρίζεται ενεργά από την κοινότητα του GitHub και επιστημονικούς οργανισμούς. Περιλαμβάνει υλοποιήσεις για υπολογισμούς και προσομοιώσεις παραμέτρων σχετικές με την ηλιακή ενέργεια όπως είναι ο υπολογισμός της ηλιακής θέσης με διάφορα αλγοριθμικά μοντέλα (π.χ. NREL SPA, NOAA), η μετατροπή ακτινοβολίας από οριζόντιο σε κεκλιμένο επίπεδο (POA), μοντέλα inverter και module performance (Sandia, CEC) καθώς και απώλειες λόγω θερμοκρασίας, σκίασης και mismatch. Η βιβλιοθήκη είναι πλήρως τεκμηριωμένη και ελαφριά, με απλές κλήσεις συναρτήσεων που επιτρέπουν τον επαναλήψιμο και διαφανή υπολογισμό κρίσιμων παραμέτρων για μελέτες ενεργειακής απόδοσης και εκπαίδευση μοντέλων πρόβλεψης. [77, 78]

3.3.2 Υπολογισμός Ηλιακής Θέσης

Ο υπολογισμός της θέσης του ήλιου στον ουρανό αποτελεί βασικό στάδιο στην ηλιακή γεωμετρία, καθώς επιτρέπει την εκτίμηση της κατεύθυνσης της προσπίπτουσας ακτινοβολίας και των σχετικών γωνιών με το επίπεδο των φωτοβολταϊκών πλασίων. Οι δύο βασικές γωνιακές συντεταγμένες που χρησιμοποιούνται για τον σκοπό αυτό είναι η γωνία ζενίθ (solar zenith) και η γωνία αζιμουθίου (solar azimuth). Η γωνία ζενίθ ορίζεται ως η γωνία μεταξύ της κατακόρυφης διεύθυνσης και της ευθείας που ενώνει τη θέση του ήλιου με τον παρατηρητή, ενώ η γωνία αζιμουθίου μετρά τη διεύθυνση του ήλιου στο οριζόντιο επίπεδο ως προς τον γεωγραφικό βορρά, όπως παρουσιάζεται στο σχήμα 3.2.

Η εκτίμηση αυτών των γωνιών πραγματοποιείται, μέσω της βιβλιοθήκης `pvlib`, με τη χρήση του μοντέλου NREL SPA (Solar Position Algorithm)[79], το οποίο προσφέρει υψηλή ακρίβεια στον υπολογισμό της ηλιακής θέσης για κάθε χρονική στιγμή, λαμβάνοντας υπόψη γεωγραφικά δεδομένα (πλάτος, μήκος, υψόμετρο) και την ακριβή ώρα σε UTC. Οι παραγόμενες γωνίες είναι απαραίτητες τόσο για τον υπολογισμό της γωνίας πρόσπτωσης (AOI) όσο και για τη μετατροπή της οριζόντιας ακτινοβολίας σε κεκλιμένο επίπεδο.

Σχήμα 3.2: Αναπαράσταση ηλιακής γωνίας ζενίθ και αζιμούθιας. Αναπαραγωγή από [75].



Μία βοηθητική μεταβλητή που προκύπτει άμεσα από τη γωνία ζενίθ είναι το συνημίτονο της. Η τιμή αυτή εκφράζει το ποσοστό της ακτινοβολίας που προσπίπτει κάθετα στην επιφάνεια και λειτουργεί ως ένδειξη της γωνιακής προσέγγισης του ήλιου προς το σημείο παρατήρησης. Επειδή η ηλιακή ακτινοβολία δεν είναι πρακτικά διαθέσιμη κατά τις νυχτερινές ώρες, όταν η γωνία ζενίθ υπερβαίνει τις 90° (δηλαδή όταν ο ήλιος βρίσκεται κάτω από τον ορίζοντα), η μεταβλητή αυτή περιορίζεται θεωρητικά στο διάστημα:

$$\cos(\theta_z)' = \max \{ \cos(\theta_z), 0 \} \quad (3.2)$$


όπου θ_z είναι η γωνία ζενίθ του ήλιου (σε μοίρες), ώστε να αποτυπώνει ρεαλιστικά την πραγματική προσπίπτουσα ενέργεια. Με άλλα λόγια, όταν ο ήλιος δεν είναι ορατός, η τιμή της μεταβλητής λαμβάνεται ως μηδέν, γεγονός που συμβαδίζει με τη φυσική παρατήρηση ότι η παραγόμενη ισχύς από το φωτοβολταϊκό σύστημα είναι επίσης μηδενική.

3.3.3 Υπολογισμός Γωνίας Πρόσπτωσης (AOI)

Η γωνία πρόσπτωσης (Angle of Incidence – AOI) ορίζεται ως η γωνία μεταξύ της κατεύθυνσης της ηλιακής ακτινοβολίας και της κάθετου στην επιφάνεια του φωτοβολταϊκού

πάνελ, όπως φαίνεται στο σχήμα 3.3. Πρόκειται για μία από τις σημαντικότερες γωνιακές μεταβλητές στη φωτοβολταϊκή γεωμετρία, καθώς επηρεάζει άμεσα την ποσότητα της ακτινοβολίας που απορροφάται από το σύστημα. Όταν η ηλιακή ακτινοβολία προσπίπτει κάθετα ($\text{AOI} \approx 0^\circ$), η απορρόφηση είναι μέγιστη, ενώ όσο η γωνία αυξάνεται, αυξάνονται και οι ανακλάσεις στην επιφάνεια του πάνελ, μειώνοντας την ενεργειακή αξιοποίηση. Η γωνία πρόσπτωσης εξαρτάται τόσο από τη θέση του ήλιου (solar zenith, solar azimuth) όσο και από τον γεωμετρικό προσανατολισμό του πάνελ (tilt και azimuth).

Σχήμα 3.3: Αναπαράσταση γωνίας πρόσπτωσης. Αναπαραγωγή από [74].



Ο μαθηματικός τύπος για την AOI δίνεται από τη συνημιτονική προβολή των διανυσμάτων διεύθυνσης του ήλιου και της κάθετης στο πάνελ. Παρότι η εξίσωση είναι γεωμετρικά σύνθετη, το βασικό αποτέλεσμα εκφράζεται ως:

$$\cos(\theta_{\text{AOI}}) = \vec{s} \cdot \vec{n} \quad (3.3)$$

όπου:

- $\vec{s}$ είναι η μοναδιαία διεύθυνση του ήλιου (βάσει solar zenith και azimuth)
- $\vec{n}$ είναι το μοναδιαίο διάνυσμα κάθετο στην επιφάνεια του πάνελ (βάσει tilt και panel azimuth)

Επίσης, μπορεί να υπολογιστεί απευθείας μέσω γωνιών με τον εξής τύπο:

$$\cos(\theta_{\text{AOI}}) = \cos(\theta_z) \cdot \cos(\beta) + \sin(\theta_z) \cdot \sin(\beta) \cdot \cos(\phi_s - \phi_p) \quad (3.4)$$

όπου:

- θ_z είναι η γωνία ζενίθ του ηλίου (σε μοίρες)
- β είναι η κλίση των πάνελ (0° = οριζόντια, 90° = κάθετα)
- ϕ_s είναι η αζιμούθια γωνία του ήλιου
- ϕ_p είναι η αζιμούθια γωνία των πάνελ

Όπως και στην περίπτωση της γωνίας ζενίθ του ηλίου, είναι σκόπιμο να εφαρμόζεται περιορισμός (clipping) της τιμής της $\cos(\theta_{AOI})$ στο διάστημα $[0,1]$, έτσι ώστε να αποφεύγονται μαθηματικά αποτελέσματα που δεν έχουν φυσικό νόημα, ιδιαίτερα κατά τις πρωινές ή απογευματινές ώρες ή όταν ο ήλιος βρίσκεται κάτω από τον ορίζοντα. Η τιμή $\cos(\theta_{AOI}) < 0$ υποδηλώνει ότι ο ήλιος προσπίπτει από την πίσω πλευρά του πάνελ, οπότε πρακτικά θεωρείται μηδενική συμβολή στην παραγόμενη ισχύ. [74]

Άρα,

$$\cos(\theta_{AOI})' = \max \{ \cos(\theta_{AOI}), 0 \} \quad (3.5)$$

3.3.4 Υπολογισμός Ακτινοβολίας στο Επίπεδο των Πάνελ (POA)


Η ακτινοβολία στο επίπεδο των πάνελ (Plane of Array Irradiance – POA) αποτελεί μία από τις πιο κρίσιμες εισόδους για την εκτίμηση της παραγόμενης ισχύος ενός φωτοβολταϊκού συστήματος. Αντιπροσωπεύει την πραγματική ποσότητα ηλιακής ακτινοβολίας που φτάνει στην επιφάνεια των φωτοβολταϊκών πλαισίων, λαμβάνοντας υπόψη τη γεωμετρική τους διάταξη, τη θέση του ήλιου και την ατμοσφαιρική διάχυση. Ο υπολογισμός της POA δεν είναι άμεσος, καθώς απαιτεί τη γνώση και των τριών συνιστωσών της ηλιακής ακτινοβολίας: την άμεση κανονική (DNI), τη διάχυτη οριζόντια (DHI) και τη ολική οριζόντια (GHI).

Όταν είναι διαθέσιμες τουλάχιστον δύο από τις τρεις συνιστώσες, η τρίτη μπορεί να υπολογιστεί εύκολα μέσω της εξίσωσης:

$$GHI = DHI + DNI \cdot \cos(\theta_z)$$

όπου θ_z είναι η γωνία ζενίθ. Αν όμως διατίθεται μόνο η GHI, τότε απαιτείται η χρήση εμπειρικών ή μοντελοποιημένων σχέσεων για την εκτίμηση των DHI και DNI. Σε αυτή την περίπτωση, μέσω της `pvlib` εφαρμόζεται κάποιο μοντέλο διαχωρισμού της ακτινοβολίας (irradiance decomposition models), όπως το Erbs model, το οποίο βασίζεται σε στατιστικά δεδομένα και εμπειρικές σχέσεις.

Σχήμα 3.4: Υπολογισμός POA. Αναπαράγωγή από [73].



Αφού καθοριστούν οι συνιστώσες της ακτινοβολίας, η POA μπορεί να υπολογιστεί μέσα απο τον τύπο:

$$POA = POA_{dir} + POA_{diff, refl} + POA_{diff, sky} \quad (3.6)$$

Η άμεση ακτινοβολία στο πάνελ (POA_{dir}) μπορεί να υπολογιστεί απευθείας από την άμεση κανονική ακτινοβολία (DNI) και την γωνία πρόσπτωσης (AOI) μέσα από τον τύπο:

$$POA_{dir} = DNI \times \cos(AOI) \quad (3.7)$$

Η διάχυτη ακτινοβολία που ανακλάται από το έδαφος ($POA_{diff, refl}$) δίνεται απο τον τύπο:

$$POA_{diff, refl} = GHI \times \rho \times \frac{1 - \cos(\beta)}{2} \quad (3.8)$$

όπου:

- GHI είναι η ολική οριζόντια ακτινοβολία,
- ρ είναι ο συντελεστής ανακλαστικότητας του εδάφους (albedo),
- β είναι η κλίση των πάνελ

Η διάχυτη ακτινοβολία που ανακλάται από τον ουρανό ($POA_{diff, refl}$) μπορεί να υπολογιστεί, μέσω της $pnlib$, με κάποιο μοντέλο μετατροπής ακτινοβολίας (transposition irradiance model), όπως το Hay/Davies.[73]

Η διαδικασία Υπολογισμού της Ακτινοβολίας στο επίπεδο των πάνελ ανάλογα με την γνώση των συνιστωσών ακτινοβολίας παρουσιάζεται αναλυτικά στο σχήμα 3.4.

3.4 Σύνοψη

Παρότι όλες οι παραπάνω μεταβλητές αποτελούν σημαντικά μεγέθη για την κατανόηση και μοντελοποίηση της απόδοσης ενός φωτοβολταϊκού συστήματος, δεν συμβάλλουν όλες εξίσου στον υπολογισμό της παραγόμενης ισχύος από το μοντέλο πρόβλεψης. Στην ενοτητα

5.4 θα ακολουθήσει ποσοτική ανάλυση συσχέτισης (correlation analysis), στην οποία θα αποτυπωθεί η γραμμική σχέση κάθε μεταβλητής με την ισχύ εξόδου. Βάσει αυτής της ανάλυσης θα επιλεγούν οι πιο αντιπροσωπευτικές και χρήσιμες παράμετροι για την εκπαίδευση των μοντέλων μηχανικής μάθησης, ώστε να βελτιστοποιηθεί τόσο η απόδοση όσο και η γενίκευση του συστήματος πρόβλεψης.


Κεφάλαιο 4

Μεθοδολογία

Η ανάπτυξη ενός αξιόπιστου συστήματος παραγωγής συνθετικών δεδομένων ισχύος ενός Φ/Β πάρκου απαιτεί μια μεθοδική διαδικασία, η οποία περιλαμβάνει διαδοχικά στάδια επεξεργασίας δεδομένων, εξαγωγής και επιλογής χαρακτηριστικών, σχεδιασμού και εκπαίδευσης μοντέλων μηχανικής μάθησης, καθώς και αξιολόγησης των αποτελεσμάτων. Στο παρόν κεφάλαιο περιγράφεται αναλυτικά η μεθοδολογία που ακολουθήθηκε για την επίτευξη των στόχων της εργασίας.

Η συνολική ροή της μεθοδολογίας αποτυπώνεται στο Σχήμα 4.1, το οποίο παρουσιάζει με τρόπο συνοπτικό όλα τα βήματα της διαδικασίας: από τη συλλογή και την προεπεξεργασία των δεδομένων, έως την εξαγωγή και επιλογή των κατάλληλων χαρακτηριστικών, την εφαρμογή των μοντέλων πρόβλεψης και την τελική αξιολόγηση της απόδοσής τους. Στις υποενότητες που ακολουθούν αναλύεται ξεχωριστά κάθε στάδιο, σύμφωνα με τη διάρθρωση που παρουσιάζεται στο διάγραμμα.

Σχήμα 4.1: Διάγραμμα Μεθοδολογίας



4.1 Συλλογή Δεδομένων

Για την ανάπτυξη μεθόδων πρόβλεψης της φωτοβολταϊκής παραγωγής απαιτείται η συλλογή κατάλληλων χρονοσειρών μετεωρολογικών και ενεργειακών δεδομένων. Οι κύριες πηγές τέτοιων δεδομένων είναι οι τοπικοί μετεωρολογικοί σταθμοί, οι οποίοι καταγράφουν με υψηλή χρονική ανάλυση βασικές μεταβλητές όπως ηλιακή ακτινοβολία (GHI), θερμοκρασία και ταχύτητα ανέμου, καθώς και τα συστήματα καταγραφής της παραγόμενης ενεργού ισχύος. Παράλληλα, μπορούν να αξιοποιηθούν εκτιμήσεις μετεωρολογικών παραμέτρων από ανοιχτές διαδικτυακές πηγές (π.χ. Open-Meteo API), οι οποίες παρέχουν δεδομένα σε περιοχές όπου δεν υπάρχει διαθέσιμος σταθμός.

Η ύπαρξη πολλαπλών πηγών δεδομένων εξασφαλίζει την εφαρμοσιμότητα της μεθοδολογίας σε διαφορετικά σενάρια, ωστόσο η αξιοπιστία και η ακρίβεια των αποτελεσμάτων εξαρτώνται σε μεγάλο βαθμό από την ποιότητα των δεδομένων. Για τον λόγο αυτό, στην ενότητα 4.2 παρουσιάζεται η διαδικασία προεπεξεργασίας, η οποία αποσκοπεί στον καθαρισμό, τη συμπλήρωση και την κανονικοποίηση των χρονοσειρών πριν από τη χρήση τους στην εκπαίδευση των μοντέλων.

4.2 Προεπεξεργασία Δεδομένων

Η προεπεξεργασία των δεδομένων αποτελεί κρίσιμο στάδιο σε κάθε μελέτη που βασίζεται σε χρονοσειρές, καθώς η ποιότητα και η συνέπεια του συνόλου δεδομένων καθορίζουν σε μεγάλο βαθμό την απόδοση των μοντέλων μηχανικής μάθησης[80]. Ειδικά στην περίπτωση φωτοβολταϊκών εγκαταστάσεων, τα δεδομένα συχνά περιέχουν ελλειπίες ή εσφαλμένες εγγραφές λόγω βλαβών αισθητήρων, ασυνεχειών στις καταγραφές ή διακοπών επικοινωνίας. Η μη αντιμετώπιση αυτών των ζητημάτων μπορεί να οδηγήσει σε σημαντική υποβάθμιση της ακρίβειας των προβλέψεων.

Στην παρούσα εργασία, η διαδικασία προεπεξεργασίας περιέλαβε αρχικά τον χρονικό φιλτραρισμό των δεδομένων, με στόχο την επιλογή μόνο των εγγραφών που αντιστοιχούν στην περίοδο μελέτης. Ακολούθησε ο έλεγχος εγκυρότητας των χρονικών σημάνσεων, με διαγραφή των εγγραφών που εμφάνιζαν ελλιπή ή ασυνεπή στοιχεία. Παράλληλα, πραγματοποιήθηκε η αφαίρεση διπλοεγγραφών, ώστε να διασφαλιστεί η μοναδικότητα κάθε χρονικής στιγμής.

Ένα ιδιαίτερα σημαντικό βήμα αποτέλεσε ο συγχρονισμός των δεδομένων. Επειδή οι διάφορες πηγές (μετεωρολογικοί σταθμοί και Open-Meteo API) παρείχαν τιμές με διαφορετικό χρονικό βήμα (5 λεπτά και 30 λεπτά αντίστοιχα), κρίθηκε αναγκαία η ενοποίηση και κανονικοποίηση της χρονικής ανάλυσης. Η εναρμόνιση αυτή επιτρέπει την ομαλή τροφοδότηση των μοντέλων και την αποφυγή χρονικών κενών ή επικαλύψεων.

Η διαχείριση των ελλিপών τιμών αποτέλεσε το τελευταίο στάδιο της διαδικασίας. Για τα ενδιάμεσα χρονικά σημεία εφαρμόστηκε γραμμική παρεμβολή (linear interpolation), η οποία

εκτιμά τις τιμές βάσει των γειτονικών παρατηρήσεων. Η γραμμική παρεμβολή βασίζεται στην υπόθεση ότι η μεταβολή μιας μεταβλητής μεταξύ δύο γνωστών χρονικών σημείων ακολουθεί γραμμική σχέση. [81] Αν θεωρήσουμε δύο γνωστές παρατηρήσεις (t_1, y_1) και (t_2, y_2) , όπου $t_1 < t < t_2$ και η τιμή y στο χρονικό σημείο t είναι άγνωστη, τότε η παρεμβολή υπολογίζεται από τον τύπο:

$$y(t) = y_1 + \frac{y_2 - y_1}{t_2 - t_1} \cdot (t - t_1) \quad (4.1)$$

Η παραπάνω εξίσωση εκφράζει την κλίση της ευθείας που περνά από τα δύο γνωστά σημεία, πολλαπλασιασμένη με την απόσταση του αγνώστου σημείου από το πρώτο, και προστιθέμενη στην αρχική τιμή y_1 . Με αυτόν τον τρόπο, οι ενδιάμεσες τιμές εκτιμώνται με τρόπο που εξασφαλίζει τη συνέχεια και την ομαλότητα της χρονοσειράς. Για τα άκρα της χρονοσειράς, όπου δεν υπήρχαν διαθέσιμες τιμές εκατέρωθεν, χρησιμοποιήθηκε η μέθοδος προώθησης ή οπισθοδρόμησης της τελευταίας έγκυρης τιμής (forward/backward filling).

4.3 Εξαγωγή Χαρακτηριστικών

Η εξαγωγή χαρακτηριστικών (feature extraction) διαδραματίζει καθοριστικό ρόλο στην πρόβλεψη φωτοβολταϊκής παραγωγής, διότι επιτρέπει την ενίσχυση της πληροφορίας που παρέχεται από τις βασικές μετεωρολογικές μετρήσεις και τη γεωμετρία του συστήματος. Χωρίς αυτό το στάδιο, τα μοντέλα μηχανικής μάθησης μπορεί να μην καταφέρουν να αποτυπώσουν πλήρως τις πολύπλοκες σχέσεις που συνυπάρχουν (π.χ. πώς η γωνία πρόσπτωσης, το ύψος του ήλιου και η θερμοκρασία αλληλεπιδρούν για να διαμορφώσουν την παραγόμενη ισχύ). [82]

Επιπλέον, η εξαγωγή κατάλληλων χαρακτηριστικών συμβάλλει σημαντικά στην καλύτερη γενίκευση των μοντέλων, καθώς μειώνει την ανάγκη να “μαθαίνουν” περίπλοκες σχέσεις αποκλειστικά μέσα από τα αρχικά δεδομένα, κάτι που απαιτεί περισσότερα δείγματα και υπολογιστική ισχύ. Μέσα από την εξαγωγή, μπορούμε να ενσωματώσουμε φυσικές και γεωμετρικές παραμέτρους που έχουν ήδη τεκμηριωθεί στο κεφάλαιο 3.3 ότι βελτιώνουν την ακρίβεια των προβλέψεων.

Η χρήση των χαρακτηριστικών αυτών κρίθηκε απαραίτητη καθώς ενισχύουν την πληροφορία που παρέχουν οι βασικές μετεωρολογικές μετρήσεις (GHI, θερμοκρασία, ταχύτητα ανέμου), αποτυπώνοντας σημαντικές μη γραμμικές συσχετίσεις με την παραγόμενη ισχύ. Με αυτόν τον τρόπο, τα μοντέλα δεν περιορίζονται μόνο σε απλές χρονοσειρές μετεωρολογικών δεδομένων, αλλά αποκτούν πρόσβαση σε φυσικά τεκμηριωμένες μεταβλητές, γεγονός που βελτιώνει την ερμηνευσιμότητα και την ακρίβεια των προβλέψεων.

4.4 Ανάλυση Συσχετίσεων και Επιλογή Χαρακτηριστικών

Η επιλογή των κατάλληλων χαρακτηριστικών αποτελεί καθοριστικό στάδιο στη διαδικασία ανάπτυξης μοντέλων μηχανικής μάθησης, καθώς επηρεάζει τόσο την απόδοση όσο και τη γενίκευση. Πριν την εφαρμογή πιο σύνθετων μεθόδων, πραγματοποιείται αρχικά ανάλυση συσχετίσεων, η οποία επιτρέπει τον ποσοτικό προσδιορισμό της σχέσης ανάμεσα στις μεταβλητές εισόδου και την παραγόμενη ισχύ.

4.4.1 Ανάλυση Συσχετίσεων

Η πιο διαδεδομένη μετρική για την εκτίμηση της σχέσης μεταξύ δύο μεταβλητών είναι ο συντελεστής συσχέτισης Pearson, ο οποίος μετρά τον βαθμό στον οποίο δύο ποσοτικές μεταβλητές σχετίζονται μεταξύ τους. Όταν η σχέση είναι γραμμική, μπορεί να περιγραφεί από μια εξίσωση της μορφής:

$$y_i = \alpha x_i + b, \quad \alpha > 0 \Rightarrow \rho \rightarrow +1 \quad (4.2)$$

που δηλώνει θετική συσχέτιση, ή:

$$y_i = \alpha x_i + b, \quad \alpha < 0 \Rightarrow \rho \rightarrow -1 \quad (4.3)$$

που δηλώνει αρνητική συσχέτιση. Σε περιπτώσεις όπου δεν υπάρχει καμία γραμμική σχέση μεταξύ των μεταβλητών, ο συντελεστής λαμβάνει τιμή $\rho = 0$.

Ο γενικός μαθηματικός ορισμός του συντελεστή συσχέτισης Pearson είναι:

$$\rho_{(X,Y)} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \cdot \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (4.4)$$

με το οποίο υπολογίζεται ο βαθμός γραμμικής σχέσης μεταξύ δύο μεταβλητών X και Y . Οι τιμές του ρ κυμαίνονται στο διάστημα $[-1,1]$. Οι θετικές τιμές τις υποδηλώνουν ότι οι δύο μεταβλητές αυξάνονται ταυτόχρονα, οι αρνητικές τιμές ότι η αύξηση της μιας συνδέεται με μείωση της άλλης, ενώ τιμές κοντά στο μηδέν δείχνουν απουσία γραμμικής σχέσης. [83]

Η ανάλυση αυτή παρέχει μία πρώτη εικόνα για το ποιες μεταβλητές έχουν μεγαλύτερη σχέση με την παραγωγή ισχύος. Ωστόσο, περιορίζεται μόνο στις γραμμικές συσχετίσεις και δεν αποτυπώνει μη γραμμικές σχέσεις ή πολύπλοκες αλληλεξαρτήσεις. Σημαντική είναι και η ανάλυση συσχετίσεων ανάμεσα και στις υπόλοιπες μεταβλητές, ώστε να εντοπιστούν οι πλεονάζουσες (redundant) και να μειωθεί η πολυσυγγραμμικότητα. Η οπτικοποίηση της συσχέτισης Pearson πραγματοποιείται συχνά με scatter plots, τα οποία βοηθούν στην ανάδειξη της ύπαρξης ή μη σχέσης καθώς και της κατεύθυνσής της (θετική ή αρνητική).

4.4.2 Elastic Net Regression

Οι μέθοδοι κανονικοποιημένης παλινδρόμησης (regularized regression) έχουν αναπτυχθεί ώστε να αντιμετωπίζουν προβλήματα υπερπροσαρμογής και πολυσυγγραμμικότητας, ιδιαίτερα όταν ο αριθμός των χαρακτηριστικών είναι μεγάλος σε σχέση με τον αριθμό των δειγμάτων. Στο πλαίσιο της πρόβλεψης φωτοβολταϊκής παραγωγής, οι τεχνικές αυτές είναι ιδιαίτερα χρήσιμες, δεδομένου ότι οι μετεωρολογικές μεταβλητές εμφανίζουν υψηλές συσχετίσεις μεταξύ τους.

Το Elastic Net αποτελεί μία κανονικοποιημένη μέθοδο γραμμικής παλινδρόμησης, στόχος της οποίας είναι αφενός η επιλογή χαρακτηριστικών μέσω αραιώσης (sparsity), αφετέρου η μείωση της επίδρασης της πολυσυγγραμμικότητας, δηλαδή της ισχυρής συσχέτισης μεταξύ μεταβλητών. Η μέθοδος ελαχιστοποιεί την ακόλουθη αντικειμενική συνάρτηση:

$$\hat{\beta}(\text{enet}) = \left(1 + \frac{\lambda_2}{n}\right) \left\{ \arg \min_{\beta} \|y - X\beta\|_2^2 + \lambda_2 \|\beta\|_2^2 + \lambda_1 \|\beta\|_1 \right\} \quad (4.5)$$

όπου:

- n είναι ο αριθμός των δειγμάτων,
- x_i είναι το διάνυσμα εισόδου,
- y_i είναι η τιμή εξόδου,
- β είναι το διάνυσμα παραμέτρων,
- $\|y - X\beta\|_2^2 = \sum_{i=1}^n (y_i - x_i^T \beta)^2$ είναι η τετραγωνική συνάρτηση απώλειας ℓ_2 (δηλαδή το άθροισμα των τετραγώνων των υπολοίπων). Το x_i^T αντιστοιχεί στην i -οστή γραμμή του X ,
- $\|\beta\|_2^2 = \sum_{j=1}^p \beta_j^2$ είναι η ℓ_2 -νόρμα που επιβάλλει ποινή στο διάνυσμα β
- $\|\beta\|_1 = \sum_{j=1}^p |\beta_j|$ είναι η ℓ_1 -νόρμα που επιβάλλει ποινή στο διάνυσμα β

Ταυτόχρονα ορίζεται η μεταβλητή:

$$\alpha = \frac{\lambda_2}{\lambda_1 + \lambda_2}, 0 \leq \alpha \leq 1 \quad (4.6)$$

Το Elastic Net (ENET) μπορεί να θεωρηθεί ως μια γενίκευση δύο άλλων μεθόδων κανονικοποίησης, των μεθόδων Ridge και Lasso. Η ισοροπία ανάμεσα τους καθορίζεται μέσω της παραμέτρου α : όταν $\alpha=0$, το μοντέλο ταυτίζεται με το Lasso, ενώ όταν $\alpha=1$ ταυτίζεται με το Ridge. Η Ridge Regression εισάγει μια ποινή στο τετράγωνο των συντελεστών (L_2 penalty), με αποτέλεσμα οι συντελεστές να συρρικνώνονται προς το μηδέν αλλά να μην μηδενίζονται

πλήρως και είναι κατάλληλη όταν οι περισσότερες μεταβλητές συμβάλλουν με μικρές επιδράσεις. Ωστόσο, δεν εκτελεί επιλογή χαρακτηριστικών, αφού όλοι οι συντελεστές παραμένουν μη μηδενικοί. Αντίθετα, η Lasso Regression χρησιμοποιεί την L_1 ποινή, η οποία έχει την ιδιότητα να μηδενίζει αρκετούς συντελεστές, οδηγώντας σε αραιώση (sparsity) και άρα σε επιλογή χαρακτηριστικών. Η μέθοδος είναι ιδιαίτερα χρήσιμη σε προβλήματα υψηλής διάστασης, αλλά παρουσιάζει περιορισμούς όταν οι μεταβλητές είναι έντονα συσχετιζόμενες: τείνει να επιλέγει μόνο μία και να αγνοεί τις υπόλοιπες. Για ενδιάμεσες τιμές του α , το Elastic Net συνδυάζει τα πλεονεκτήματα και των δύο προσεγγίσεων και επιπλέον εφαρμόζει την μέθοδο του grouping effect, δηλαδή την ικανότητα να επιλέγει ομάδες έντονα συσχετιζόμενων χαρακτηριστικών, ακόμη και όταν αυτές οι ομάδες δεν είναι γνωστές εκ των προτέρων.[84]

Είναι σημαντικό να τονιστεί ότι το Elastic Net υπολογίζει μόνο γραμμικές σχέσεις μεταξύ μεταβλητών και εξόδου. Τα πιο πολύπλοκα μοντέλα μηχανικής μάθησης (LSTM, CNN, TFT) είναι σε θέση να αποτυπώσουν μη γραμμικές αλληλεξαρτήσεις. Ωστόσο, το Elastic Net παίζει καθοριστικό ρόλο ως εργαλείο προεπιλογής χαρακτηριστικών, μειώνοντας την πλεονάζουσα πληροφορία (redundancy) και εξασφαλίζοντας ότι τα μοντέλα εκπαιδεύονται σε ένα πιο καθαρό και αντιπροσωπευτικό dataset. Με τον τρόπο αυτό βελτιώνεται η αποδοτικότητα της εκπαίδευσης και ενισχύεται η γενίκευση των τελικών προβλέψεων.

4.5 Ορισμός των Μοντέλων

Για την πρόβλεψη της φωτοβολταϊκής παραγωγής χρησιμοποιήθηκαν τρία διαφορετικά μοντέλα βαθιάς μάθησης: Δικτύου Διπλής Κατεύθυνσης Μακράς Βραχυπρόθεσμης Μνήμης (BiLSTM), Συνελικτικού Νευρωνικού Δικτύου (CNN) και Temporal Fusion Transformer (TFT). Η επιλογή τους βασίστηκε στη δυνατότητα αποτύπωσης πολύπλοκων χρονικών εξαρτήσεων και στη βέλτιστη αξιοποίηση των μετεωρολογικών και γεωμετρικών χαρακτηριστικών που περιγράφουν το σύστημα.

Το Δίκτυο Διπλής Κατεύθυνσης Μακράς Βραχυπρόθεσμης Μνήμης (BiLSTM) αποτελεί επέκταση του κλασικού LSTM, το οποίο έχει τη δυνατότητα να αποθηκεύει πληροφορίες σε μεγάλες χρονικές κλίμακες μέσω μηχανισμών μνήμης και πυλών (gates). Σε αντίθεση με το απλό LSTM, το BiLSTM επεξεργάζεται τα δεδομένα και προς τις δύο χρονικές κατευθύνσεις (forward και backward), γεγονός που του επιτρέπει να εκμεταλλευτεί τόσο παρελθοντικές όσο και μελλοντικές πληροφορίες στο εσωτερικό της ακολουθίας. Το χαρακτηριστικό αυτό το καθιστά ιδιαίτερα κατάλληλο για δεδομένα παραγωγής από φωτοβολταϊκά, όπου η ισχύς εξαρτάται από την ομαλή εξέλιξη της ακτινοβολίας μέσα στη μέρα αλλά και από το σχήμα της συνολικής καμπύλης.

Το Συνελικτικό Νευρωνικό Δίκτυο (CNN) χρησιμοποιείται κυρίως για προβλήματα επεξεργασίας εικόνας, ωστόσο έχει αποδειχθεί ιδιαίτερα αποτελεσματική και στην ανάλυση χρονοσειρών. Μέσα από τους συνελικτικούς πυρήνες (convolutional filters), το CNN μπορεί να ανιχνεύει τοπικά μοτίβα και χαρακτηριστικά στις εισόδους, όπως απότομες μεταβολές

στην ακτινοβολία λόγω νεφοκάλυψης. Η ικανότητα του CNN να εντοπίζει τοπικές εξαρτήσεις το καθιστά ιδανικό για την παρακολούθηση ταχύτατων διακυμάνσεων στην παραγωγή ισχύος, κάτι που είναι κρίσιμο για την αξιοπιστία της πρόβλεψης σε πραγματικές συνθήκες λειτουργίας.

Το τρίτο μοντέλο, ο Temporal Fusion Transformer (TFT), αποτελεί μια σύγχρονη αρχιτεκτονική βασισμένη στον μηχανισμό της προσοχής (attention). Ο TFT μπορεί να συνδυάσει στατικά και δυναμικά χαρακτηριστικά, ενώ παράλληλα διαθέτει μηχανισμούς ερμηνευσιμότητας μέσω των attention weights. Στο πλαίσιο της πρόβλεψης φωτοβολταϊκής παραγωγής, το TFT μπορεί να προσαρμόζεται στις χρονικές διακυμάνσεις των εισόδων και να αποδίδει καλύτερα σε περιόδους όπου η σχέση μεταξύ ακτινοβολίας και παραγωγής είναι μη γραμμική ή υπόκειται σε ξαφνικές αλλαγές. Παράλληλα, ο μηχανισμός προσοχής επιτρέπει στο μοντέλο να δίνει μεγαλύτερη βαρύτητα στα πιο σημαντικά χαρακτηριστικά και χρονικά σημεία, γεγονός που βελτιώνει την αποδοτικότητα και την ακρίβεια.

4.6 Βελτιστοποίηση Υπερπαραμέτρων και Εκπαίδευση

Η εκπαίδευση των μοντέλων πραγματοποιήθηκε ακολουθώντας τη συνήθη διαδικασία διαχωρισμού των δεδομένων σε σύνολο εκπαίδευσης, επικύρωσης και ελέγχου. Στόχος του διαχωρισμού αυτού ήταν αφενός η εκμάθηση των βασικών σχέσεων από τα διαθέσιμα δεδομένα και αφετέρου η αποτίμηση της ικανότητας γενίκευσης των μοντέλων σε μη παρατηρημένα δείγματα.

Κατά τη διάρκεια της εκπαίδευσης εφαρμόστηκαν τεχνικές που αποσκοπούν στη σταθερότητα της διαδικασίας και στην αποφυγή υπερπροσαρμογής, μέσω της βελτιστοποίησης υπερπαραμέτρων (Hyperparameter Optimization) με χρήση της βιβλιοθήκης Optuna. Το Optuna αποτελεί μια σύγχρονη πλατφόρμα αυτόματης βελτιστοποίησης που υποστηρίζει προσαρμοστικούς αλγορίθμους αναζήτησης, όπως ο Tree-structured Parzen Estimator (TPE). Αντί να δοκιμάζονται οι υπερπαραμέτροι εξαντλητικά ή με χειροκίνητο πειραματισμό, το Optuna δημιουργεί ένα δυναμικό χώρο αναζήτησης και επιλέγει επαναληπτικά τα πιο υποσχόμενα σύνολα υπερπαραμέτρων, ελαχιστοποιώντας τον χρόνο υπολογισμού. Επιπλέον, διαθέτει μηχανισμούς όπως το early stopping και το pruning of unpromising trials, με αποτέλεσμα να τερματίζει πρόωρα τις λιγότερο αποδοτικές δοκιμές και να κατανέμει τους υπολογιστικούς πόρους στις πιο ελπιδοφόρες.[85]

Η χρήση του Optuna διασφάλισε ότι τα μοντέλα εκπαιδεύτηκαν με τις βέλτιστες δυνατές ρυθμίσεις (π.χ. learning rate, αριθμός νευρώνων, βάθος δικτύου, dropout rate), ενισχύοντας την ακρίβεια και τη γενίκευση των προβλέψεων.

4.7 Αξιολόγηση

Η αξιολόγηση της απόδοσης των μοντέλων αποτελεί αναπόσπαστο στάδιο της μεθοδολογίας, καθώς παρέχει ποσοτικά και ποιοτικά κριτήρια για τη σύγκριση διαφορετικών προσεγγίσεων. Για τον σκοπό αυτό χρησιμοποιήθηκαν ευρέως διαδεδομένες μετρικές, όπως αυτές αναλύθηκαν στην ενότητα 2.4, που μετρούν την ακρίβεια πρόβλεψης, την ευαισθησία στα σφάλματα και την ικανότητα επεξήγησης της διακύμανσης των δεδομένων.

Συγκεκριμένα, εφαρμόστηκαν:

- το Μέσο Απόλυτο Σφάλμα (MAE – Mean Absolute Error), που αποτυπώνει τη μέση απόκλιση των προβλέψεων από τις πραγματικές τιμές,
- η Ρίζα του Μέσου Τετραγωνικού Σφάλματος (RMSE – Root Mean Squared Error), η οποία δίνει μεγαλύτερη βαρύτητα σε μεγάλες αποκλίσεις,
- και ο Συντελεστής Προσδιορισμού (R^2 – Coefficient of Determination), που εκφράζει το ποσοστό της διακύμανσης των δεδομένων που εξηγείται από το μοντέλο.

Η χρήση πολλαπλών μετρικών κρίθηκε αναγκαία ώστε να ληφθούν υπόψη διαφορετικές πτυχές της απόδοσης: η ακρίβεια υπό κανονικές συνθήκες, η συμπεριφορά σε ακραία σφάλματα και η ικανότητα γενικής ερμηνείας των δεδομένων. Με τον τρόπο αυτό επιτυγχάνεται μια πιο ολοκληρωμένη αξιολόγηση, η οποία ενισχύει την αξιοπιστία των συμπερασμάτων που προκύπτουν από τα πειράματα.

Εκτός από τους αριθμητικούς δείκτες, η αξιολόγηση συνοδεύτηκε και από την παρουσίαση διαγραμμάτων σύγκρισης πραγματικών και προβλεπόμενων τιμών για αντιπροσωπευτικές ημέρες. Τα γραφήματα αυτά παρέχουν μια πιο διαισθητική κατανόηση της απόδοσης των μοντέλων, αναδεικνύοντας πώς συμπεριφέρονται σε διαφορετικές συνθήκες (ηλιόλουστες ημέρες, μέτρια νεφοκάλυψη, μεταβαλλόμενη συννεφιά). Με τον τρόπο αυτό επιτυγχάνεται μια πιο ολοκληρωμένη αξιολόγηση, που συνδυάζει αριθμητική ακρίβεια και οπτική ερμηνεία.

Κεφάλαιο 5

Μελέτη Περίπτωσης

Στο παρόν κεφάλαιο παρουσιάζεται η εφαρμογή της μεθοδολογίας που περιγράφηκε στο Κεφάλαιο 4 σε πραγματικά δεδομένα φωτοβολταϊκών πάρκων. Η μελέτη περίπτωσης έχει ως στόχο να αναδείξει πώς οι διαδικασίες συλλογής, προεπεξεργασίας, εξαγωγής χαρακτηριστικών και επιλογής τους, καθώς και η εκπαίδευση και αξιολόγηση των μοντέλων, υλοποιούνται σε πραγματικές συνθήκες.

Αρχικά περιγράφονται τα δεδομένα που χρησιμοποιήθηκαν και τα μεταδεδομένα που τα συνοδεύουν, ενώ στη συνέχεια παρουσιάζεται το πειραματικό πλαίσιο στο οποίο στηρίχθηκε η εκπαίδευση και η αξιολόγηση των μοντέλων. Τα αποτελέσματα αποτυπώνονται τόσο ποσοτικά, μέσω μετρικών σφάλματος, όσο και ποιοτικά, μέσω γραφημάτων που συγκρίνουν την πραγματική με την προβλεπόμενη παραγωγή ισχύος σε διαφορετικές συνθήκες λειτουργίας.

Η ενότητα αυτή συνδέει τη θεωρητική μεθοδολογία με την πρακτική εφαρμογή της, παρέχοντας μια ολοκληρωμένη εικόνα της αποδοτικότητας και των δυνατοτήτων των υπό εξέταση μοντέλων.

5.1 Σύνολο Δεδομένων

Για την υλοποίηση των πειραμάτων χρησιμοποιήθηκαν δεδομένα από δύο διαφορετικά φωτοβολταϊκά πάρκα (το ένα με ονομαστική ισχύ 405kW και το άλλο με 1MW), σε διαφορετικές τοποθεσίες, καθένα από τα οποία διαθέτει τον δικό του μετεωρολογικό σταθμό. Για κάθε φωτοβολταϊκό πάρκο είναι διαθέσιμα και τα μεταδεδομένα της εγκατάστασης, τα οποία περιλαμβάνουν το γεωγραφικό πλάτος και μήκος, την κλίση (tilt) και τον προσανατολισμό (azimuth) των φωτοβολταϊκών πλαισίων, καθώς και την ονομαστική ισχύ της εγκατάστασης. Τα μεταδεδομένα αυτά χρησιμοποιούνται ως στατικές παράμετροι στο πειραματικό πλαίσιο, επιτρέποντας την καλύτερη κατανόηση της γεωμετρίας και της δυναμικότητας των πάρκων, καθώς και στην εξαγωγή χαρακτηριστικών.

Οι μετρήσεις, από τα πάρκα και τους μετεωρολογικούς τους σταθμούς συλλέγονται με χρονική ανάλυση 5 λεπτών και περιλαμβάνουν την ολική οριζόντια ακτινοβολία (GHI), την Θερμοκρασία περιβάλλοντος (temperature), την ταχύτητα του ανέμου (wind speed) καθώς

και την ενεργό ισχύ (active power) των inverters. Απο το πρώτο πάρκο (405kW) υπάρχουν συνολικά δεδομένα 20 μηνών ενώ απο το δεύτερο πάρκο (1MW) υπάρχουν δεδομένα 6 μηνών με κανονική παραγωγή ισχύος καθώς και δεδομένα 6 μηνών με αναγκαστικό περιορισμό ισχύος (curtailment).

Η διάκριση σε δύο πάρκα επιτρέπει τη μελέτη της γενικευσιμότητας των μοντέλων: το πρώτο πάρκο χρησιμοποιείται για εκπαίδευση και επικύρωση (training/validation set), ενώ το δεύτερο λειτουργεί αποκλειστικά ως ανεξάρτητο test set. Με τον τρόπο αυτό αξιολογείται η ικανότητα των μοντέλων να μεταφέρονται σε νέα περιβάλλοντα, με διαφορετικές συνθήκες λειτουργίας. Παράλληλα, στις περιπτώσεις που υπάρχει αναγκαστικός περιορισμός ισχύος δίνεται η δυνατότητα να εκτιμηθεί η πραγματική παραγώμενη ισχύς.

Παράλληλα, σχεδιάστηκε ένα δεύτερο πείραμα που προσομοιώνει την περίπτωση φωτοβολταϊκών πάρκων χωρίς τοπικό μετεωρολογικό σταθμό. Για τον σκοπό αυτό χρησιμοποιήθηκαν δεδομένα από το Open-Meteo API, τα οποία παρέχουν τις ίδιες μετεωρολογικές μεταβλητές (GHI, θερμοκρασία, ταχύτητα ανέμου) με χρονική ανάλυση 30 λεπτών, βασισμένα στις γεωγραφικές συντεταγμένες των δύο πάρκων. Παράλληλα, το Open-Meteo δίνει την δυνατότητα για δύο ακόμα μετεωρολογικές μεταβλητές, την άμεση κανονική ακτινοβολία (DNI) και διάχυτη οριζόντια ακτινοβολία (DHI), οι οποίες θα έπρεπε να προσομοιαστούν κατά την εξαγωγή χαρακτηριστικών. Τα δεδομένα αυτά χρησιμοποιήθηκαν για την εκπαίδευση των μοντέλων, ενώ η αξιολόγηση πραγματοποιήθηκε πάλι πάνω σε πραγματικές μετρήσεις από το δεύτερο πάρκο.

Η ύπαρξη αυτών των δύο σεναρίων επιτρέπει τη διερεύνηση της ακρίβειας πρόβλεψης όταν υπάρχουν τοπικές μετρήσεις υψηλής ανάλυσης (μετεωρολογικοί σταθμοί), αλλά και της εφικτότητας πρόβλεψης όταν στηρίζομαστε σε μετεωρολογικά δεδομένα ανοιχτών πηγών (Open Meteo API), σενάριο ιδιαίτερα χρήσιμο για πάρκα που δεν διαθέτουν μετρητικό εξοπλισμό, για πάρκα που εφαρμόζεται curtailment αλλά και για περιπτώσεις μελέτης ενός μελλοντικού πάρκου, το οποίο είναι ακόμα στο στάδιο του σχεδιασμού.

5.2 Συλλογή και Προεπεξεργασία Δεδομένων

Η συλλογή δεδομένων πραγματοποιήθηκε από τους μετεωρολογικούς σταθμούς και τους inverters των δύο φωτοβολταϊκών πάρκων, καθώς και από το Open-Meteo API για το δεύτερο πείραμα. Αρχικά, τα δεδομένα φιλτραρίστηκαν ώστε να καλύπτουν μόνο την επιλεγμένη χρονική περίοδο ανάλυσης, ενώ απομακρύνθηκαν εγγραφές με εσφαλμένες ή μη αναγνώσιμες χρονικές σημάνσεις. Στη συνέχεια, πραγματοποιήθηκε έλεγχος για την ύπαρξη διπλών χρονικών στιγμών, οι οποίες αφαιρέθηκαν ώστε να διατηρείται μία μοναδική καταγραφή ανά χρονικό βήμα.

Για την εξασφάλιση συνέπειας, τα δεδομένα επαναδειγματολήθηκαν (resampling) σε ενιαίο χρονικό βήμα 5 λεπτών (ή 30 λεπτών στην περίπτωση των δεδομένων του Open-Meteo). Όπου υπήρχαν κενά, εφαρμόστηκαν μέθοδοι παρεμβολής (linear interpolation) για την εκτίμηση

των ενδιάμεσων τιμών, ενώ για ελλείψεις στην αρχή ή στο τέλος της χρονοσειράς χρησιμοποιήθηκαν τεχνικές προώθησης και οπισθοδρόμησης της τελευταίας έγκυρης τιμής (forward και backward filling). Με αυτόν τον τρόπο εξασφαλίστηκε ότι οι χρονοσειρές ήταν πλήρεις και χρονικά συνεπείς, έτοιμες για τα επόμενα στάδια της ανάλυσης.

5.3 Εξαγωγή Χαρακτηριστικών (Feature Extraction)

Η διαδικασία εξαγωγής χαρακτηριστικών είχε ως στόχο τον εμπλουτισμό του αρχικού συνόλου δεδομένων με μεταβλητές που περιγράφουν καλύτερα τις φυσικές διεργασίες που επηρεάζουν την παραγωγή ενέργειας. Πέρα από τις αρχικές μετρήσεις του μετεωρολογικού σταθμού – την ολική οριζόντια ακτινοβολία (GHI), τη θερμοκρασία περιβάλλοντος και την ταχύτητα ανέμου – στο dataset ενσωματώθηκαν και πρόσθετα χαρακτηριστικά, τα οποία προκύπτουν είτε από υπολογισμούς είτε από μετασχηματισμούς των διαθέσιμων δεδομένων και των στατικών μεταδεδομένων της εγκατάστασης. Ο υπολογισμός ή οι προσομοιώσεις των χαρακτηριστικών αυτών αναφέρονται αναλυτικά στην ενότητα 3.3. Συγκεκριμένα, συμπεριλήφθηκαν τα εξής:

- `cos_zenith`: το συνημίτονο της γωνίας ζενίθ του ήλιου περιορισμένο στο διάστημα $[0,1]$.
- `cos_aoi`: το συνημίτονο της γωνίας πρόσπτωσης της ακτινοβολίας στο επίπεδο των πάνελ, περιορισμένο στο διάστημα $[0,1]$.
- `dni` και `ghi`: η άμεση και η διάχυτη ακτινοβολία, που προσομοιώνονται στο πρώτο πείραμα, δηλαδή στην περίπτωση του μετεωρολογικού σταθμού ώστε να υπάρχει πληρέστερη εικόνα της κατανομής της ηλιακής ακτινοβολίας. Στην περίπτωση του `open-meteo` αυτοί οι δυο τύποι ακτινοβολίας παρέχονται απευθείας από το `api`.
- `poa_global`: η ολική ακτινοβολία στο επίπεδο των πάνελ
- `cos_time`: κυκλική αναπαράσταση της ημερήσιας χρονικής στιγμής, που επιτρέπει στο μοντέλο να εκμεταλλευτεί την περιοδικότητα της ηλιακής παραγωγής. Συγκεκριμένα, για κάθε χρονική στιγμή υπολογίζεται το πλήθος των λεπτών που έχουν παρέλθει από την αρχή της ημέρας (minute of day, με τιμές από 0 έως 1440) και στη συνέχεια εφαρμόζεται ο τύπος:

$$\cos_time = \cos\left(\frac{2\pi \cdot \text{minute_of_day}}{1440}\right) \quad (5.1)$$

Η ενσωμάτωση αυτών των μεταβλητών προσφέρει ένα πιο ολοκληρωμένο σύνολο εισόδων για την εκπαίδευση των μοντέλων, επιτρέποντας την καλύτερη κατανόηση των σχέσεων μεταξύ των περιβαλλοντικών συνθηκών, της γεωμετρίας της εγκατάστασης και της παραγόμενης ισχύος. Με τον τρόπο αυτό, η διαδικασία feature extraction ενισχύει την ικανότητα γενίκευσης των μοντέλων και συμβάλλει στη βελτίωση της ακρίβειας των προβλέψεων.

5.4 Ανάλυση Συσχετίσεων και Επιλογή Χαρακτηριστικών

Η διαδικασία ανάλυσης συσχετίσεων και επιλογής χαρακτηριστικών εφαρμόστηκε τόσο στο πρώτο πείραμα, όπου χρησιμοποιούνται μετρήσεις από τους μετεωρολογικούς σταθμούς των δύο φωτοβολταϊκών πάρκων, όσο και στο δεύτερο πείραμα, όπου αξιοποιούνται δεδομένα από το Open-Meteo API. Στόχος είναι η ανάδειξη των μεταβλητών που σχετίζονται περισσότερο με την παραγόμενη ενεργό ισχύ και η διαμόρφωση ενός βέλτιστου συνόλου εισόδων για την εκπαίδευση των μοντέλων.

Η συγκεκριμένη μεθοδολογία επιλέχθηκε καθώς είναι υπολογιστικά αποδοτική, παρέχει ερμηνεύσιμα αποτελέσματα και μπορεί να προσαρμοστεί σε δεδομένα με υψηλή συσχέτιση μεταξύ μεταβλητών — ένα συνηθισμένο φαινόμενο στα φωτοβολταϊκά δεδομένα (π.χ. GHI, DNI, DHI, POA). Με τον τρόπο αυτό, τα τελικά μοντέλα μηχανικής μάθησης (LSTM, CNN, TFT) εκπαιδεύτηκαν μόνο με τα πιο αντιπροσωπευτικά και χρήσιμα χαρακτηριστικά, μειώνοντας τον κίνδυνο υπερπροσαρμογής και βελτιώνοντας την αποδοτικότητα της εκπαίδευσης.

5.4.1 Πείραμα 1


Για το πείραμα 1 πραγματοποιήθηκε ανάλυση συσχετίσεων (correlation analysis) ανάμεσα στο στόχο (target), δηλαδή στην ενεργό ισχύ (active power) των inverter του πρώτου πάρκου (ονομαστική ισχύς 405 kW) το οποίο χρησιμοποιείται για εκπαίδευση και επικύρωση, και στα χαρακτηριστικά στα χαρακτηριστικά (features) που προέκυψαν από την συλλογή από τον μετεωρολογικό σταθμό του πάρκου και την επεξεργασία τους στην προηγούμενη ενότητα. Τα αποτελέσματα φαίνονται στον Πίνακα 5.1.

Πίνακας 5.1: Πίνακας Συσχέτισης με την ενεργό ισχύ για το Πείραμα 1

Χαρακτηριστικό	Συσχέτιση με Ενεργό Ισχύ
active_power(target)	1.000000
irradiance(ghi)	0.992928
poa_global	0.972956
cos_zenith	0.893392
cos_aoi	0.888133
dni	0.865302
dhi	0.757615
cos_time	0.751063
temperature	0.483604
wind_speed	0.293925

Στην συνέχεια πραγματοποιείται και ανάλυση συσχετίσεων ανάμεσα στα χαρακτηριστικά (features) προκειμένου να ελεγχθεί η ύπαρξη πολυσυγγραμμικότητας (multicollinearity) ανάμεσα στις μεταβλητές αυτές. Το αποτέλεσμα αυτής της διαδικασίας παρουσιάζεται με την μορφή heatmap στο σχήμα 5.1.

Σχήμα 5.1: Feature Correlation Heatmap για το Πείραμα 1



Επειδή στα δεδομένα παρατηρείται πολυσυγγραμμικότητα μεταξύ πολλών χαρακτηριστικών (π.χ. GHI, DNI, DHI, POA), χρησιμοποιήθηκε η μέθοδος Elastic Net. Ο συνδυασμός των κανονικοποιήσεων L1 και L2 επιτρέπει ταυτόχρονα επιλογή των πιο αντιπροσωπευτικών χαρακτηριστικών και σταθεροποίηση των συντελεστών σε ομάδες συσχετισμένων μεταβλητών. Τα αποτελέσματα της μεθόδου Elastic Net φαίνονται στον πίνακα 5.2.

Πίνακας 5.2: Συντελεστές χαρακτηριστικών από το Elastic Net για το Πείραμα 1

Χαρακτηριστικό	Συντελεστής
irradiance(ghi)	110.059078
cos_zenith	4.768172
poa_global	2.269251
dhi	1.796216
dni	1.244822
temperature	-0.919514
wind_speed	0.802743
cos_time	0.024294
cos_aoi	-0.000000

Τα αποτελέσματα του Elastic Net δείχνουν ότι η ολική ακτινοβολία (irradiance) αποτελεί τον κυρίαρχο παράγοντα πρόβλεψης της ενεργού ισχύος, με συντελεστή σημαντικά μεγαλύτερο από κάθε άλλο χαρακτηριστικό, γεγονός που φαινόταν και από τον πίνακα συσχετίσεων (0.99). Ένας τόσο μεγάλος συντελεστής σημαίνει ότι το συγκεκριμένο χαρακτηριστικό επηρεάζει καθοριστικά το αποτέλεσμα, ενώ τα υπόλοιπα, όπως οι γεωμετρικές μεταβλητές ή τα παράγωγα χαρακτηριστικά (POA, DNI, DHI, cos_zenith), συνεισφέρουν ελάχιστα ή είναι πλεονάζοντα, καθώς ουσιαστικά μεταφέρουν την ίδια πληροφορία με την GHI. Συνεπώς, δεν είναι απαραίτητος ο υπολογισμός των παραγόμενων χαρακτηριστικών, και για το Πείραμα 1 είναι καλύτερο να χρησιμοποιηθούν αποκλειστικά τα άμεσα μετρούμενα δεδομένα από τον σταθμό, δηλαδή:

- η άμεση ακτινοβολία (irradiance - ghi),
- η θερμοκρασία (temperature) και
- η ταχύτητα του ανέμου (wind_speed)


5.4.2 Πείραμα 2

Η ίδια διαδικασία πραγματοποιείται και για το δεύτερο πείραμα, δηλαδή με στόχο την ενεργό ισχύ του πάρκου με ονομαστική ισχύ 405 kW και χαρακτηριστικά που προέρχονται από το open-meteo api. Στον πίνακα 5.3 παρατίθενται τα αποτελέσματα της συσχέτισης των features με την ενεργό ισχύ ενώ στο σχήμα 5.2 παρατίθενται τα αποτελέσματα τις αυτοσυσχέτισης των features σε μορφή heatmap.

Πίνακας 5.3: Πίνακας Συσχέτισης με την ενεργό ισχύ για το Πείραμα 1

Χαρακτηριστικό	Συσχέτιση με Ενεργό Ισχύ
active_power	1.000000
poa_global	0.925979
irradiance	0.907079
cos_zenith	0.894897
cos_aoi	0.889251
dni	0.872033
dhi	0.790210
cos_time	0.751945
temperature	0.493375
wind_speed	0.345394

Σχήμα 5.2: Feature Correlation Heatmap για το Πείραμα 2



Πίνακας 5.4: Συντελεστές χαρακτηριστικών από το Elastic Net για το Πείραμα 2

Χαρακτηριστικό	Συντελεστής
poa_global	104.648711
cos_aoi	12.628436
dni	-3.455605
cos_time	2.084021
wind_speed	-2.018578
temperature	-1.462206
dhi	1.123726
irradiance	-0.000000
cos_zenith	-0.000000

Από τα αποτελέσματα του Elastic Net, όπως αυτά παρουσιάζονται στον πίνακα 5.4 διαπιστώνεται ότι το χαρακτηριστικό poa_global είναι το σημαντικότερο για την πρόβλεψη της ενεργού ισχύος, ενώ το cos_aoi παρουσιάζει επίσης υψηλή συνεισφορά. Τα dni και dhi διατηρούν μετρήσιμη σημασία, σε αντίθεση με τα irradiance και cos_zenith που μηδενίστηκαν και θεωρούνται πλεονάζοντα. Παράλληλα, οι μεταβλητές temperature και wind_speed κρίνονται

αναγκαίες καθώς περιγράφουν φυσικές επιδράσεις στη λειτουργία του συστήματος.

Συνεπώς, στο Πείραμα 2 θα πραγματοποιηθούν δύο διαφορετικές εκπαιδεύσεις: (α) με το βασικό σετ χαρακτηριστικών irradiance, temperature, wind_speed και (β) με το επεκταμένο σετ που περιλαμβάνει τα εξαγόμενα χαρακτηριστικά poa_global, dni, dhi, cos_aoi μαζί με τις temperature και wind_speed. Με αυτόν τον τρόπο θα μελετηθεί κατά πόσο η εξαγωγή και ενσωμάτωση πρόσθετων χαρακτηριστικών μπορεί να βελτιώσει την ακρίβεια πρόβλεψης όταν χρησιμοποιούνται δεδομένα από το Open-Meteo.

5.5 Αναλυτική Παρουσίαση Πειραμάτων

Συνοψίζοντας τις παραπάνω ενότητες, στο πλαίσιο της παρούσας μελέτης σχεδιάστηκαν δύο διακριτά πειράματα, με στόχο την αποτίμηση της προτεινόμενης μεθοδολογίας σε διαφορετικές πηγές δεδομένων και συνθήκες λειτουργίας.

Πείραμα 1 – Δεδομένα Μετεωρολογικών Σταθμών Το πρώτο πείραμα βασίστηκε σε μετρήσεις υψηλής χρονικής ανάλυσης (5 λεπτών) από τοπικούς μετεωρολογικούς σταθμούς που ήταν εγκατεστημένοι στα φωτοβολταϊκά πάρκα. Τα δεδομένα περιλάμβαναν ακτινοβολία, θερμοκρασία, ταχύτητα ανέμου και την παραγόμενη ενεργό ισχύ. Για την εκπαίδευση και επικύρωση χρησιμοποιήθηκε το πρώτο πάρκο, ενώ το δεύτερο αξιοποιήθηκε αποκλειστικά ως test set, επιτρέποντας την αξιολόγηση της ικανότητας των μοντέλων να γενικεύουν σε διαφορετικές εγκαταστάσεις.

Πείραμα 2 – Δεδομένα Open-Meteo Το δεύτερο πείραμα στηρίχθηκε σε δεδομένα που προέρχονται από το Open-Meteo API, με χρονικό βήμα 30 λεπτών. Το πείραμα οργανώθηκε σε δύο σκέλη: (α) χρήση μόνο των βασικών μετεωρολογικών μεταβλητών (irradiance, temperature, wind_speed) και (β) εμπλουτισμός των δεδομένων με επιπλέον χαρακτηριστικά που εξήχθησαν μέσω υπολογισμών (POA, dni, dhi, cos_aoi, temperature, wind_speed). Με τον τρόπο αυτό αξιολογείται η συμβολή του feature extraction στην περίπτωση που δεν υπάρχει διαθέσιμος μετεωρολογικός σταθμός.

Και στα δύο πειράματα εφαρμόστηκαν τα μοντέλα βαθιάς μάθησης BiLSTM, CNN και TFT. Η διαδικασία εκπαίδευσης υποστηρίχθηκε από βελτιστοποίηση υπερπαραμέτρων μέσω Optuna, ενώ η αξιολόγηση βασίστηκε σε μετρικές σφάλματος (MAE, RMSE, R^2) και στην παρουσίαση γραφημάτων που συγκρίνουν πραγματικές και προβλεπόμενες τιμές, ώστε να επιτευχθεί μια ολοκληρωμένη αποτίμηση της απόδοσης.

5.6 Σχεδιασμός Πειράματος

5.6.1 Δεδομένα Εισόδου

Για την αξιολόγηση της προτεινόμενης μεθοδολογίας σχεδιάστηκαν δύο διακριτά πειραματικά σενάρια. Σε κάθε πείραμα τα δεδομένα οργανώθηκαν σε τρία σύνολα: εκπαίδευσης

(training set), επικύρωσης (validation set) και ελέγχου (test set), ώστε να διασφαλιστεί η αντικειμενικότητα και η δυνατότητα γενίκευσης.

Για το Πείραμα 1 χρησιμοποιήθηκαν πραγματικές μετρήσεις από τοπικούς μετεωρολογικούς σταθμούς και αντίστοιχα δεδομένα παραγωγής. Το σύνολο εκπαίδευσης και επικύρωσης προήλθε από το πρώτο φωτοβολταϊκό πάρκο, ενώ το δεύτερο πάρκο χρησιμοποιήθηκε αποκλειστικά ως σύνολο ελέγχου (test set). Τα μοντέλα εκπαιδεύτηκαν με τις βασικές μεταβλητές (irradiance, temperature, wind_speed, ενώ η κατανομή των δεδομένων φαίνεται αναλυτικά στον πίνακα 5.5.

Πίνακας 5.5: Κατανομή δεδομένων για το Πείραμα 1 (μετεωρολογικοί σταθμοί)

Set	Πάρκο	Αρχή	Τέλος	Χρονική Ανάλυση	Αριθμός Δειγμάτων
Training	A (405kW)	12-08-2023	15-10-2024	5 λεπτά	124.128
Validation	A (405kW)	16-10-2024	31-01-2025	5 λεπτά	31.104
Test(normal)	B (1MW)	01-09-2023	29-02-2024	5 λεπτά	52.416
Test(curtailement)	B (1MW)	01-04-2024	30-09-2024	5 λεπτά	52.704

Για το Πείραμα 2 αξιοποιήθηκαν εκτιμήσεις καιρού από το Open-Meteo API με χρονικό βήμα 30 λεπτών. Το πείραμα περιλάμβανε δύο σκέλη:

- α') εκπαίδευση αποκλειστικά με τις βασικές μεταβλητές (irradiance, temperature, wind speed),
- β') εκπαίδευση με τα ίδια δεδομένα εμπλουτισμένα με εξαγόμενα χαρακτηριστικά (POA, dni, dhi, cos_aoi, temperature, wind_speed)

Η κατανομή των δεδομένων του πειράματος 2 φαίνεται αναλυτικά στον πίνακα 5.6. Η σύγκριση των δύο σκέλων επιτρέπει την αποτίμηση της συμβολής του feature extraction σε συνθήκες περιορισμένων δεδομένων.

Πίνακας 5.6: Κατανομή δεδομένων για το Πείραμα 2 (Open-Meteo)

Set	Πάρκο	Αρχή	Τέλος	Χρονική Ανάλυση	Αριθμός Δειγμάτων
Training	A (405kW)	12-08-2023	15-10-2024	30 λεπτά	20.688
Validation	A (405kW)	16-10-2024	31-01-2025	30 λεπτά	5.184
Test(normal)	B (1MW)	01-09-2023	29-02-2024	30 λεπτά	8.736
Test(curtailement)	B (1MW)	01-04-2024	30-09-2024	30 λεπτά	8.784

5.6.2 Κανονικοποίηση και Τυποποίηση

Για την εξασφάλιση της συγκρισιμότητας των χαρακτηριστικών και τη βελτίωση της εκπαίδευσης των νευρωνικών δικτύων, εφαρμόστηκε διαδικασία κανονικοποίησης και τυποποίησης των δεδομένων. Συγκεκριμένα, χρησιμοποιήθηκε ο μετασχηματισμός Min-Max

Scaler, ο οποίος αναδιατάσσει τις τιμές κάθε χαρακτηριστικού σε ένα προκαθορισμένο διάστημα $[0,1]$:

$$x'(t) = \frac{x(t) - x_{\min}}{x_{\max} - x_{\min}} \quad (5.2)$$

όπου x είναι η αρχική τιμή, ενώ $x_{\min}$ και $x_{\max}$ οι ελάχιστες και μέγιστες τιμές του χαρακτηριστικού αντίστοιχα.

Η κανονικοποίηση αυτή επιτρέπει σε όλες τις μεταβλητές να συνεισφέρουν ισότιμα στη διαδικασία εκπαίδευσης, αποτρέποντας φαινόμενα όπου μεταβλητές με μεγάλη κλίμακα (π.χ. ηλιακή ακτινοβολία σε W/m^2) υπερσχύουν έναντι άλλων (π.χ. ταχύτητα ανέμου σε m/s).

Επιπλέον, η ενεργός ισχύς (active power) κανονικοποιήθηκε ως ποσοστό της ονομαστικής ισχύος του εκάστοτε φωτοβολταϊκού πάρκου, ώστε να είναι δυνατή η άμεση σύγκριση ανάμεσα σε πάρκα διαφορετικής κλίμακας. Με τον τρόπο αυτό οι προβλέψεις εκφράζονται σε σχετικούς όρους και όχι σε απόλυτες τιμές, καθιστώντας το μοντέλο πιο γενικεύσιμο σε διαφορετικές εγκαταστάσεις.

5.6.3 Μοντέλα

Μετά τη διαδικασία βελτιστοποίησης υπερπαραμέτρων με το Optuna, τα τελικά μοντέλα που χρησιμοποιήθηκαν στα δύο πειράματα προσαρμόστηκαν στα ιδιαίτερα χαρακτηριστικά κάθε σετ δεδομένων. Η χρήση της αυτόματης αναζήτησης υπερπαραμέτρων επέτρεψε την αποφυγή χρονοβόρου χειροκίνητου πειραματισμού και οδήγησε σε μοντέλα πιο αποδοτικά και καλύτερα προσαρμοσμένα στη φύση των δεδομένων.

Για κάθε πείραμα παρουσιάζονται παρακάτω η τελική αρχιτεκτονική (π.χ. επίπεδα, αριθμός μονάδων, πυρήνες, κεφαλές προσοχής) καθώς και οι βασικές υπερπαραμέτροι εκπαίδευσης (όπως ρυθμός μάθησης, optimizer, loss function, αριθμός εποχών). Η καταγραφή αυτή είναι ουσιαστική καθώς εξασφαλίζει την αναπαραγωγικότητα των αποτελεσμάτων και επιτρέπει τη δίκαιη σύγκριση μεταξύ μοντέλων και πειραμάτων. Επιπλέον, δίνει τη δυνατότητα να αξιολογηθεί όχι μόνο η απόδοση των μοντέλων αλλά και η πολυπλοκότητά τους σε σχέση με τα δεδομένα που χρησιμοποιήθηκαν.

Στο πρώτο πείραμα, όπου χρησιμοποιήθηκαν δεδομένα υψηλής χρονικής ανάλυσης από τοπικούς μετεωρολογικούς σταθμούς, τα τρία μοντέλα (BiLSTM, CNN και TFT) κατέληξαν σε διαφορετικές διαμορφώσεις. Οι πίνακες που ακολουθούν αποτυπώνουν την τελική αρχιτεκτονική και τις υπερπαραμέτρους εκπαίδευσης για κάθε μοντέλο. Ο Πίνακας 5.7 παρουσιάζει τη διαμόρφωση του δικτύου BiLSTM, ο Πίνακας 5.8 δείχνει την τελική αρχιτεκτονική του CNN, ενώ ο πίνακας 5.9 αποτυπώνει τη διαμόρφωση του TFT.

Πίνακας 5.7: Τελική αρχιτεκτονική BiLSTM (Πείραμα 1) μετά από βελτιστοποίηση με Optuna

Συστατικό	Παράμετροι	Activation Function
Είσοδος	$(T=16, F)$	
Bidirectional LSTM	units = 16	
Dropout	0.31	
Dense Layer 1	units = 8	ReLU
Dense Layer 2	units = 4	ReLU
Dense Output	$T_{\text{out}} = 1$	Linear
Learning Rate	0.02	
Optimizer	Adam	
Loss	MSE	
Epochs	20	

Πίνακας 5.8: Τελική αρχιτεκτονική CNN (Πείραμα 1) μετά από βελτιστοποίηση με Optuna

Συστατικό	Παράμετροι	Activation Function
Είσοδος	$(T=288, F)$	
Conv1D Layer 1	φίλτρα $f_1 = 64$, kernel $k_1 = 3$	ReLU
Conv1D Layer 2	φίλτρα $f_2 = 64$, kernel $k_2 = 3$	ReLU
MaxPooling1D	pool_size = 2	
Flatten		
Dense Output	$T_{\text{out}} = 288$	Linear
Learning Rate	0.02	
Optimizer	Adam	
Loss	MSE	
Epochs	20	

Πίνακας 5.9: Τελική αρχιτεκτονική TFT (Πείραμα 1) μετά από βελτιστοποίηση με Optuna

Συστατικό	Παράμετροι	Activation Function
Είσοδος	$(T=288, F)$	
Hidden size	14	
Attention head size	3	
Dropout	0.1835	
Hidden continuous size	9	
Dense Output	$T_{\text{out}} = 288$	Linear
Learning Rate	0.01148	
Optimizer	Adam	
Loss	Quantile Loss	
Epochs	50	

Στο δεύτερο πείραμα χρησιμοποιήθηκαν δεδομένα από το Open-Meteo API, με χρονικό βήμα 30 λεπτών, μετά τη διαδικασία βελτιστοποίησης υπερπαραμέτρων με το Optuna, τα τρία μοντέλα που εξετάστηκαν προσαρμόστηκαν ανάλογα με τη φύση των δεδομένων. Και στα δύο σενάρια τα μοντέλα που χρησιμοποιήθηκαν ήταν ίδια με μόνη διαφορά τον αριθμό των παραμέτρων εισόδου F . Οι τελικές αρχιτεκτονικές και οι υπερπαραμέτροι εκπαίδευσης παρουσιάζονται στους πίνακες που ακολουθούν. Ο Πίνακας 5.10 παρουσιάζει τη διαμόρφωση του δικτύου BiLSTM, ο Πίνακας 5.11 δείχνει την τελική αρχιτεκτονική του CNN, ενώ ο πίνακας 5.12 αποτυπώνει τη διαμόρφωση του TFT.

Πίνακας 5.10: Τελική αρχιτεκτονική BiLSTM (Πείραμα 2) μετά από βελτιστοποίηση με Optuna

Συστατικό	Παράμετροι	Activation Function
Είσοδος	$(T=8, F)$	
Bidirectional LSTM	units = 8	
Dropout	0.28	
Dense Layer	units = 4	ReLU
Dense Output	$T_{\text{out}} = 1$	Linear
Learning Rate	0.01	
Optimizer	Adam	
Loss	MSE	
Epochs	20	

Πίνακας 5.11: Τελική αρχιτεκτονική CNN (Πείραμα 2) μετά από βελτιστοποίηση με Optuna

Συστατικό	Παράμετροι	Activation Function
Είσοδος	$(T=48, F)$	
Conv1D Layer 1	φίλτρα $f_1=24$, kernel $k_1=3$	ReLU
Conv1D Layer 2	φίλτρα $f_2=24$, kernel $k_2=3$	ReLU
MaxPooling1D	pool_size = 2	
Flatten		
Dense Output	$T_{\text{out}}=48$	Linear
Learning Rate	0.01	
Optimizer	Adam	
Loss	MSE	
Epochs	20	

Πίνακας 5.12: Τελική αρχιτεκτονική TFT (Πείραμα 2) μετά από βελτιστοποίηση με Optuna

Συστατικό	Παράμετροι	Activation Function
Είσοδος	$(T=48, F)$	
Hidden size	35	
Attention head size	2	
Dropout	0.1	
Hidden continuous size	19	
Dense Output	T_{out}	Linear
Learning Rate	0.005	
Optimizer	Adam	
Loss	Quantile Loss	
Epochs	50	

5.6.4 Βιβλιοθήκες Υλοποίησης

Η υλοποίηση των πειραματικών σεναρίων πραγματοποιήθηκε στη γλώσσα προγραμματισμού **Python**, αξιοποιώντας σύγχρονες βιβλιοθήκες ανοιχτού κώδικα για μηχανική μάθηση και επεξεργασία δεδομένων. Οι σημαντικότερες από αυτές ήταν οι εξής:

- **TensorFlow/Keras και PyTorch:** χρησιμοποιήθηκαν για την ανάπτυξη και εκπαίδευση των νευρωνικών δικτύων (CNN, BiLSTM, TFT). Οι βιβλιοθήκες αυτές παρέχουν υψηλού επιπέδου API για βαθιά μάθηση, με υποστήριξη GPU και αποδοτικούς αλγορίθμους βελτιστοποίησης [86, 87].
- **scikit-learn:** χρησιμοποιήθηκε για την προεπεξεργασία των δεδομένων, την κανονικοποίηση, τη διαίρεση σε σύνολα εκπαίδευσης/επαλήθευσης/δοκιμής, το καθώς και για

τον υπολογισμό βασικών μετρικών αξιολόγησης (MAE, RMSE, R^2) [88].

- **pandas και NumPy**: παρείχαν εργαλεία για τη διαχείριση και τον χειρισμό δεδομένων χρονοσειρών. Η pandas προσφέρει δομές δεδομένων υψηλού επιπέδου με υποστήριξη χρονοσειρών, ενώ η NumPy επιτρέπει αποδοτικές πράξεις σε πολυδιάστατους πίνακες [89, 90].
- **pvlb**: χρησιμοποιήθηκε για την εξαγωγή φυσικών χαρακτηριστικών που σχετίζονται με τη λειτουργία των φωτοβολταϊκών (π.χ. γωνία πρόσπτωσης, ακτινοβολία στο επίπεδο του πάνελ), τα οποία ενσωματώθηκαν ως είσοδοι στα μοντέλα πρόβλεψης [77].

Η επιλογή της Python σε συνδυασμό με τις παραπάνω βιβλιοθήκες εξασφάλισε αναπαραγωγιμότητα, επεκτασιμότητα και υψηλή αποδοτικότητα στην υλοποίηση και αξιολόγηση των μοντέλων.

5.7 Αποτελέσματα

5.7.1 Αποτελέσματα Πειράματος 1

Στο πρώτο πείραμα, τα μοντέλα εκπαιδεύτηκαν και επικυρώθηκαν με δεδομένα από το φωτοβολταϊκό πάρκο ισχύος 405 kW, ενώ η τελική αξιολόγηση πραγματοποιήθηκε στο ανεξάρτητο πάρκο ισχύος 1 MW, στο διάστημα στο οποίο δεν υπάρχει περιορισμός ισχύος. Η εκπαίδευση πραγματοποιείται με δεδομένα που προέρχονται απευθείας από τον μετεωρολογικό σταθμό του κάθε πάρκου χωρίς να έχει γίνει εξαγωγή δεδομένων, όπως αναφέρθηκε σε προηγούμενη ενότητα. Παρακάτω, παρατίθεται ο πίνακας 5.13 με τις τιμές των μετρικών (MAE, RMSE, R^2) για κάθε μοντέλο (LSTM, CNN, TFT), τόσο στο validation όσο και στο test set. Ο πίνακας αυτός επιτρέπει την άμεση σύγκριση της ακρίβειας πρόβλεψης ανά μοντέλο και φάση εκπαίδευσης.


Πίνακας 5.13: Αποτελέσματα αξιολόγησης Πειράματος 1 για Validation και Test set

Μοντέλο	Validation			Test		
	MAE	RMSE	R^2	MAE	RMSE	R^2
BiLSTM	10.2587	17.4797	0.9786	20.1019	41.7034	0.9758
CNN	12.7692	25.5390	0.9548	36.2842	69.1797	0.9318
TFT	3.5643	12.7170	0.9854	11.4707	40.6367	0.9765


Πέρα από τους συνολικούς δείκτες απόδοσης, κρίθηκε σκόπιμο να παρουσιαστούν ενδεικτικά παραδείγματα προβλέψεων για διαφορετικές συνθήκες λειτουργίας στην περίπτωση που δεν υπάρχει αναγκαστικός περιορισμός ισχύος. Συγκεκριμένα, επιλέχθηκαν τρεις ημέρες από το test set: μια καθαρά ηλιόλουστη ημέρα (σχήμα 5.3), μια ημέρα με μέτρια νεφοκάλυψη

(σχήμα 5.4) και μια ημέρα με έντονα μεταβαλλόμενες συνθήκες λόγω μη σταθερής συννεφιάς (σχήμα 5.5). Οι περιπτώσεις αυτές αποτυπώνουν αντιπροσωπευτικά τη συμπεριφορά των μοντέλων τόσο σε “εύκολες” όσο και σε “δύσκολες” καταστάσεις πρόβλεψης.


Σχήμα 5.3: Πείραμα 1: Γράφημα Πρόβλεψης Ενεργού Ισχύος μιας Ηλιόλουστης Ημέρας



Σχήμα 5.4: Πείραμα 1: Γράφημα Πρόβλεψης Ενεργού Ισχύος μιας Ημέρας με μέτρια Νεφοκάλυψη




Σχήμα 5.5: Πείραμα 1: Γράφημα Πρόβλεψης Ενεργού Ισχύος μιας Ημέρας με έντονα μεταβαλλόμενες συνθήκες λόγω μη σταθερής συννεφιάς




Με βάση τις μετρικές αλλά και τα διαγράμματα και τα τρία μοντέλα (BiLSTM, CNN, TFT) παρουσίασαν ικανοποιητική επίδοση, αναπαράγοντας με συνέπεια το ημερήσιο προφίλ παραγωγής. Το CNN κατέγραψε ικανοποιητική ικανότητα παρακολούθησης απότομων διακυμάνσεων, ωστόσο οι προβλέψεις του εμφάνισαν αυξημένο θόρυβο/διακύμανση. Το BiLSTM παρουσίασε συστηματική υποεκτίμηση γύρω από το μεσημέρι, γεγονός που αποδίδεται στο ότι κατά την εκπαίδευση δεν χρησιμοποιήθηκαν ιστορικές τιμές ισχύος (autoregressive όροι), με αποτέλεσμα το δίκτυο να βασίζεται αποκλειστικά σε εξωγενή χαρακτηριστικά και να αποδίδει πιο συντηρητικές κορυφές. Αντιθέτως, ο TFT παρήγαγε ομαλές και ταυτόχρονα πιο πιστές προβλέψεις στο σύνολο της ημέρας, αξιοποιώντας αποτελεσματικά τους μηχανισμούς επιλογής μεταβλητών και το attention για τη σύλληψη τόσο των αλληλεξαρτήσεων μεταξύ χαρακτηριστικών όσο και της ενδοημερήσιας δυναμικής. Συνολικά, και τα τρία μοντέλα ακολουθούν την πραγματική καμπύλη με καλή ακρίβεια, με διαφοροποιήσεις στο προφίλ σφαλμάτων: αυξημένος θόρυβος για το CNN, υποεκτίμηση στις ώρες αιχμής για το BiLSTM και υψηλότερη σταθερότητα/πιστότητα για το TFT.

Αφού τα μοντέλα αξιολογήθηκαν σε συνθήκες πλήρους παραγωγής, σε αυτό το σημείο κρίνεται χρήσιμο να παρουσιαστούν και οι προβλέψεις υπό σενάρια περιορισμού ισχύος. Με τον τρόπο αυτό καθίσταται δυνατή η σύγκριση μεταξύ της θεωρητικά διαθέσιμης παραγωγής και της τελικά παραγόμενης. Όπως και στην περίπτωση πλήρους παραγωγής και σε αυτήν την περίπτωση επιλέχθηκαν τρεις ημέρες από το test set: μια καθαρά ηλιόλουστη ημέρα (σχήμα 5.6), μια ημέρα με μέτρια νεφοκάλυψη (σχήμα 5.7) και μια ημέρα με έντονα μεταβαλλόμενες συνθήκες λόγω μη σταθερής συννεφιάς (σχήμα 5.8).


Σχήμα 5.6: Πείραμα 1: Γράφημα Πρόβλεψης Ενεργού Ισχύος μιας Ηλιόλουστης Ημέρας με Περιορισμός Ισχύος



Σχήμα 5.7: Πείραμα 1: Γράφημα Πρόβλεψης Ενεργού Ισχύος μιας Ημέρας με μέτρια Νεφοκάλυψη και Περιορισμό Ισχύος



Σχήμα 5.8: Πείραμα 1: Γράφημα Πρόβλεψης Ενεργού Ισχύος μιας Ημέρας με έντονα μεταβαλλόμενες συνθήκες λόγω μη σταθερής συννεφιάς και Περιορισμό Ισχύος



Όπως φαίνεται στα παραπάνω σχήμαρα, και τα τρία μοντέλα ακολουθούν πιστά την πραγματική παραγωγή έως το σημείο όπου εφαρμόζεται ο περιορισμός ισχύος. Από το σημείο αυτό και μετά, οι καμπύλες πρόβλεψης απεικονίζουν τη θεωρητικά διαθέσιμη παραγωγή, η οποία θα μπορούσε να επιτευχθεί χωρίς τον περιορισμό. Με αυτόν τον τρόπο καθίσταται εμφανής η διαφορά ανάμεσα στην πραγματική και στη δυνατή παραγωγή του συστήματος.

5.7.2 Αποτελέσματα Πειράματος 2

Στο δεύτερο πείραμα εξετάστηκε η περίπτωση εκπαίδευσης των μοντέλων πρόβλεψης με δεδομένα που δεν προέρχονται από τοπικό μετεωρολογικό σταθμό, αλλά από το Open-Meteo API, το οποίο παρέχει μετεωρολογικές εκτιμήσεις ανά μισή ώρα. Το πείραμα αυτό είναι ιδιαίτερα σημαντικό, καθώς προσομοιώνει το σενάριο φωτοβολταϊκών εγκαταστάσεων που δεν διαθέτουν μετεωρολογικό εξοπλισμό.

Η ανάλυση πραγματοποιήθηκε σε δύο στάδια:

- Σενάριο (α): Εκπαίδευση μοντέλων αποκλειστικά με τα δεδομένα του Open-Meteo (irradiance, temperature, wind_speed)
- Σενάριο (β): Εκπαίδευση μοντέλων με τα ίδια δεδομένα (εκτός της άμεσης ακτινοβολίας), εμπλουτισμένα όμως με τα εξαγόμενα χαρακτηριστικά (proa, cos_aoi, dni, dhi, temperature, wind_speed).

Με αυτόν τον τρόπο αξιολογείται η συμβολή της διαδικασίας της εξαγωγής χαρακτηριστικών (feature extraction) στη βελτίωση της ακρίβειας πρόβλεψης. Παρακάτω, παρουσιάζονται συγκριτικοί πίνακες με τις μετρικές MAE, RMSE και R^2 για τα τρία μοντέλα (BiLSTM, CNN, TFT) στα δύο σενάρια. Ο πίνακας 5.14 περιλαμβάνει τις μετρικές των μοντέλων που

έχουν εκπαιδευτεί σε δεδομένα χωρίς εξαγωγή χαρακτηριστικών, ενώ ο πίνακας 5.15 τις μετρικές των μοντέλων που έχουν εκπαιδευτεί σε δεδομένα με εξαγωγή χαρακτηριστικών. Οι πίνακες αυτοί επιτρέπουν την ποσοτική αξιολόγηση της βελτίωσης που επιτυγχάνεται μέσω της ενσωμάτωσης των εξαγόμενων χαρακτηριστικών.

Πίνακας 5.14: Αποτελέσματα αξιολόγησης Πειράματος 2 για Validation και Test set χωρίς feature extraction


Μοντέλο	Validation			Test		
	MAE	RMSE	R ²	MAE	RMSE	R ²
BiLSTM	23.4458	46.9330	0.8414	59.6897	115.7943	0.8100
CNN	27.9347	52.9787	0.7491	57.7568	113.1354	0.8186
TFT	26.3965	52.3552	0.7583	56.8990	118.7347	0.8028

Πίνακας 5.15: Αποτελέσματα αξιολόγησης Πειράματος 2 για Validation και Test set με feature extraction


Μοντέλο	Validation			Test		
	MAE	RMSE	R ²	MAE	RMSE	R ²
BiLSTM	24.7532	49.2362	0.8238	59.1159	114.3791	0.8146
CNN	24.9256	50.5428	0.7716	51.4996	109.5648	0.8299
TFT	24.1906	55.0431	0.7328	49.7966	115.6720	0.8128

Όπως και στο πρώτο πείραμα, παρατίθενται ενδεικτικά παραδείγματα για τρεις διαφορετικές ημέρες: μια ηλιόλουστη (σχήμα 5.9), μια μέση (σχήμα 5.10) και μια με μεταβαλλόμενη νεφοκάλυψη (σχήμα 5.11). Για κάθε περίπτωση παρουσιάζονται οι προβλέψεις με και χωρίς τα εξαγόμενα χαρακτηριστικά, ώστε να καταστεί εμφανής η διαφορά στην ακρίβεια και στη σταθερότητα των αποτελεσμάτων.


Σχήμα 5.9: Πείραμα 2: Γράφημα Πρόβλεψης Ενεργού Ισχύος μιας Ηλιόλουστης Ημέρας χωρίς και με feature extraction



Σχήμα 5.10: Πείραμα 2: Γράφημα Πρόβλεψης Ενεργού Ισχύος μιας Ημέρας με μέτρια Νεφο- κάλυψη χωρίς και με feature extraction



Σχήμα 5.11: Πείραμα 2: Γράφημα Πρόβλεψης Ενεργού Ισχύος μιας Ημέρας με έντονα μεταβαλλόμενες συνθήκες λόγω μη σταθερής συννεφιάς χωρίς και με feature extraction




Από τα αποτελέσματα προκύπτει ότι η εκπαίδευση αποκλειστικά με τα δεδομένα του Open-Meteo οδηγεί σε χαμηλότερη ακρίβεια σε σχέση με το πρώτο πείραμα με τοπικούς σταθμούς, γεγονός αναμενόμενο λόγω της χαμηλότερης χρονικής ανάλυσης και της εκτιμητικής φύσης των δεδομένων. Ωστόσο, η ενσωμάτωση των εξαγόμενων χαρακτηριστικών (Σενάριο β) βελτίωσε αισθητά την απόδοση όλων των μοντέλων, καθώς επέτρεψε την καλύτερη αποτύπωση της γεωμετρίας του συστήματος και της σχέσης μεταξύ ακτινοβολίας και παραγόμενης ισχύος.

Το CNN παρουσίασε τη μεγαλύτερη βελτίωση ($R^2 = 0.8299$), καταγράφοντας πιο ρεαλιστικές αποκρίσεις στις απότομες μεταβολές λόγω νεφοκάλυψης. Τοσο το BiLSTM ($R^2 = 0.8146$) όσο και ο TFT ($R^2 = 0.8128$), αν και εμφάνισαν σχετικά παρόμοια απόδοση σε σχέση με το CNN, δεν έφτασαν την σημαντικά ανώτερη επίδοση που είχαν στο πείραμα 1. Το αποτέλεσμα αυτό μπορεί να συνδέεται με την περιορισμένη χρονική ανάλυση (48 δείγματα ανά


μέρα έναντι 288) και την έλλειψη λεπτομερούς δυναμικής στα εισερχόμενα δεδομένα, γεγονός που δεν επιτρέπει στα μοντέλα να αξιοποιήσουν τους πολύπλοκους μηχανισμούς τους.

Αφού μελετήθηκε η σημασία της εξαγωγής χαρακτηριστικών στην περίπτωση του Open Meteo και αναδείχθηκε ο ρόλος της στην ακρίβεια των προβλέψεων, στο σημείο αυτό κρίνεται σκόπιμο να εξεταστούν οι προβλέψεις υπό σενάρια περιορισμού ισχύος με εξαγωγή χαρακτηριστικών. Η ανάλυση αυτή καθιστά δυνατή τη διάκριση ανάμεσα στη θεωρητικά διαθέσιμη παραγωγή, δηλαδή την παραγωγή που θα μπορούσε να επιτευχθεί χωρίς περιορισμούς, και στην τελικά παραγόμενη ενέργεια, όπως αυτή διαμορφώνεται υπό την εφαρμογή περιορισμών. Όπως και στην περίπτωση πλήρους παραγωγής και σε αυτήν την περίπτωση επιλέχθηκαν τρεις ημέρες από το test set: μια καθαρά ηλιόλουστη ημέρα (σχήμα 5.12), μια ημέρα με μέτρια νεφοκάλυψη (σχήμα 5.13) και μια ημέρα με έντονα μεταβαλλόμενες συνθήκες λόγω μη σταθερής συννεφιάς (σχήμα 5.14)


Σχήμα 5.12: Πείραμα 2: Γράφημα Πρόβλεψης Ενεργού Ισχύος μιας Ηλιόλουστης Ημέρας με Περιορισμός Ισχύος



Σχήμα 5.13: Πείραμα 2: Γράφημα Πρόβλεψης Ενεργού Ισχύος μιας Ημέρας με μέτρια Νεφοκάλυψη και Περιορισμό Ισχύος



Σχήμα 5.14: Πείραμα 2: Γράφημα Πρόβλεψης Ενεργού Ισχύος μιας Ημέρας με έντονα μεταβαλλόμενες συνθήκες λόγω μη σταθερής συννεφιάς και Περιορισμό Ισχύος



Όπως φαίνεται στα παραπάνω σχήματα, και τα τρία μοντέλα ακολουθούν με μεγάλη ακρίβεια την πραγματική παραγωγή έως το σημείο εφαρμογής του περιορισμού ισχύος. Από εκεί και μετά, οι καμπύλες πρόβλεψης αποτυπώνουν τη θεωρητικά διαθέσιμη παραγωγή, η οποία θα μπορούσε να επιτευχθεί χωρίς τον περιορισμό. Με τον τρόπο αυτό καθίσταται σαφής η διαφορά ανάμεσα στην πραγματική και στη δυνητική παραγωγή του συστήματος ακόμα και στις περιπτώσεις που ένα πάρκο δεν διαθέτει δικό του μετεωρολογικό σταθμό.

Κεφάλαιο 6

Επίλογος

6.1 Συμπεράσματα

Η παρούσα διπλωματική εργασία είχε ως στόχο την ανάπτυξη και αξιολόγηση μεθόδων παραγωγής συνθετικών δεδομένων ισχύος φωτοβολταϊκών συστημάτων με τη χρήση τεχνικών μηχανικής μάθησης. Η μεθοδολογική προσέγγιση περιλάμβανε όλα τα απαραίτητα στάδια: συλλογή και προεπεξεργασία δεδομένων, εξαγωγή και επιλογή χαρακτηριστικών, καθώς και τον ορισμό και τη βελτιστοποίηση διαφορετικών μοντέλων.

Η προσέγγιση αυτή εφαρμόστηκε σε πραγματικό πλαίσιο με δεδομένα από δύο φωτοβολταϊκά πάρκα, καλύπτοντας περίοδο 18 μηνών. Το πρώτο πάρκο αξιοποιήθηκε για εκπαίδευση και επικύρωση, ενώ το δεύτερο λειτούργησε αποκλειστικά ως test set, γεγονός που επέτρεψε την αποτίμηση της ικανότητας των μοντέλων να γενικεύουν σε εγκαταστάσεις διαφορετικής κλίμακας και χαρακτηριστικών. Επιπλέον, εξετάστηκε και η περίπτωση απουσίας τοπικού μετεωρολογικού σταθμού μέσω της χρήσης δεδομένων από το Open-Meteo API, ώστε να αναδειχθεί η πρακτική εφαρμοσιμότητα της μεθόδου σε συνθήκες περιορισμένων δεδομένων.

Στο πρώτο πείραμα, δηλαδή στην περίπτωση του μετεωρολογικού σταθμού, τα μοντέλα παρουσίασαν υψηλά επίπεδα ακρίβειας, ενώ το καλύτερο αποτέλεσμα επιτεύχθηκε με τον TFT, ο οποίος πέτυχε συντελεστή προσδιορισμού $R^2 = 0.9765$. Γενικά, και τα τρία μοντέλα είχαν την δυνατότητα να αποτυπώσουν επαρκώς τη σχέση μεταξύ καιρικών συνθηκών και παραγωγής ισχύος αλλά και να γενικεύσουν σε διαφορετικές περιπτώσεις.

Στο δεύτερο πείραμα αξιοποιήθηκαν δεδομένα χωρίς μετεωρολογικό σταθμό, γεγονός που καθιστά το πρόβλημα πιο απαιτητικό. Χωρίς εξαγωγή πρόσθετων χαρακτηριστικών, το καλύτερο μοντέλο σε αυτήν την περίπτωση (CNN) πέτυχε συντελεστή προσδιορισμού $R^2 = 0.8186$, ενώ με την ενσωμάτωση των εξαγόμενων χαρακτηριστικών, η απόδοση του ίδιου μοντέλου αυξήθηκε σε $R^2 = 0.8299$. Συνολικά, και στα τρία μοντέλα παρατηρήθηκε βελτίωση πάνω από 1%, γεγονός που καταδεικνύει τη σημασία της εξαγωγής χαρακτηριστικών και εμπλουτισμού των δεδομένων με χρήση φυσικών εξισώσεων για την ενίσχυση της ακρίβειας πρόβλεψης, ακόμη και σε περιπτώσεις περιορισμένων δεδομένων.

Τα αποτελέσματα καταδεικνύουν ότι η αξιοποίηση τόσο πραγματικών όσο και εκτιμώμενων δεδομένων, σε συνδυασμό με τεχνικές εξαγωγής και επιλογής χαρακτηριστικών, μπορεί να βελτιώσει σημαντικά την ακρίβεια πρόβλεψης. Ιδιαίτερα σε περιπτώσεις ελλιπών δεδομένων λόγω curtailment, αλλά και σε περιπτώσεις όπου δεν υπάρχουν διαθέσιμες μετρήσεις – όπως σε ένα φωτοβολταϊκό πάρκο που βρίσκεται ακόμη στο στάδιο του σχεδιασμού – τα προτεινόμενα μοντέλα μπορούν να αποτελέσουν αξιόπιστο εργαλείο πρόβλεψης και υποστήριξης αποφάσεων.

6.2 Μελλοντικές Επεκτάσεις

Αν και τα αποτελέσματα της παρούσας εργασίας ήταν ιδιαίτερα ενθαρρυντικά, υπάρχουν αρκετές κατευθύνσεις για περαιτέρω έρευνα και βελτίωση. Μία πρώτη προέκταση αφορά τη χρήση περισσότερων φωτοβολταϊκών πάρκων στο στάδιο της εκπαίδευσης, τα οποία θα περιλαμβάνουν δεδομένα τόσο από ακραίες μετεωρολογικές συνθήκες (π.χ. έντονη συννεφιά, καταιγίδες, καύσωνες) αλλά και από ακραία γεωμετρικά χαρακτηριστικά (π.χ. μεγάλη αζιμούθια γωνία, μικρή κλίση). Με αυτόν τον τρόπο τα μοντέλα θα εκτεθούν σε μεγαλύτερη ποικιλία σεναρίων, αυξάνοντας την ικανότητά τους να γενικεύουν και να παραμένουν αξιόπιστα σε πραγματικές συνθήκες λειτουργίας του δικτύου.

Μια δεύτερη κατεύθυνση αφορά την αξιοποίηση ανοιχτών μετεωρολογικών δεδομένων υψηλότερης χρονικής ανάλυσης, ακόμη και με βήμα πέντε λεπτών. Η χρήση τέτοιων δεδομένων θα επέτρεπε την πληρέστερη αξιοποίηση των μηχανισμών που διαθέτουν τα ισχυρά μοντέλα βαθιάς μάθησης, όπως ο TFT και τα LSTM, τα οποία έχουν σχεδιαστεί για να ανιχνεύουν και να αξιοποιούν λεπτές χρονικές εξαρτήσεις. Η διαθεσιμότητα δεδομένων με μικρότερο χρονικό βήμα θα ενίσχυε περαιτέρω την ακρίβεια και τη σταθερότητα των προβλέψεων.

Συνολικά, οι επεκτάσεις αυτές θα συνέβαλλαν τόσο στη βελτίωση της αποδοτικότητας των μοντέλων όσο και στην αύξηση της πρακτικής τους χρησιμότητας, ιδίως σε περιβάλλοντα όπου η πρόβλεψη της φωτοβολταϊκής παραγωγής αποτελεί κρίσιμο στοιχείο για τη λειτουργία και τον προγραμματισμό του ηλεκτρικού δικτύου.

Βιβλιογραφία

- [1] A. Lazaroiu, M. Gmal Osman, C. Strejoiu, and G. Lazaroiu, “A comprehensive overview of photovoltaic technologies and their efficiency for climate neutrality. sustainability 2023, 15, 16297,” 2023.
- [2] L. Todorean, T. Cioara, I. Anghel, E. Sarmas, V. Michalakopoulos, and V. Marinakis, “Demand response optimization for smart grid integrated buildings: Review of technology enablers landscape and innovation challenges,” *Energy and Buildings*, p. 115067, 2024.
- [3] V. Michalakopoulos, L. Spyropoulos, L. Ilias, E. Sarmas, V. Marinakis, and D. Askounis, “A comparative analysis of federated learning strategies for short-term photovoltaic power forecasting,” *Energy Reports*, vol. 13, pp. 4223–4235, 2025.
- [4] V. Michalakopoulos, E. Sarantinopoulos, E. Sarmas, and V. Marinakis, “Empowering federated learning techniques for privacy-preserving pv forecasting,” *Energy Reports*, vol. 12, pp. 2244–2256, 2024.
- [5] E. Sarantinopoulos, V. Michalakopoulos, E. Sarmas, V. Marinakis, L. Todorean, and T. Cioara, “Meta-heuristic federated learning aggregation methods for load forecasting,” *Energy and AI*, p. 100594, 2025.
- [6] L. Todorean, M. Daian, T. Cioara, I. Anghel, V. Michalakopoulos, E. Sarantinopoulos, and E. Sarmas, “Heuristic based federated learning with adaptive hyperparameter tuning for households energy prediction,” *Scientific Reports*, vol. 15, no. 1, p. 12564, 2025.
- [7] E. O’Shaughnessy, J. R. Cruce, and K. Xu, “Too much of a good thing? global trends in the curtailment of solar pv,” *Solar Energy*, vol. 208, pp. 1068–1077, 2020.
- [8] Z. Liu and Y. Du, “Evolution towards dispatchable pv using forecasting, storage, and curtailment: A review,” *Electric Power Systems Research*, vol. 223, p. 109554, 2023.
- [9] I. Papias, V. Michalakopoulos, E. Sarmas, V. Marinakis, G. Antonesi, T. Cioara, and I. Anghel, “A data-driven framework for estimating residential energy flexibility for aggregated demand-side management,” *Available at SSRN 5147627*, 2025.

- [10] V. Michalakopoulos, E. Sarvas, V. Daropoulos, G. Kazdaridis, S. Keranidis, V. Marinakis, and D. Askounis, "A multi-dimensional unsupervised machine learning framework for clustering residential heat load profiles," *arXiv preprint arXiv:2411.16701*, 2024.
- [11] I. Papias, V. Michalakopoulos, E. Sarvas, and V. Marinakis, "Aggregated flexibility dynamic forecasting of residential energy prosumers for dr programs," in *2024 15th International Conference on Information, Intelligence, Systems & Applications (IISA)*, pp. 1–9, 2024.
- [12] K. T. Alao, S. I. U. H. Gilani, K. Sopian, and T. O. Alao, "A review on digital twin application in photovoltaic energy systems: challenges and opportunities," *JMST Advances*, vol. 6, no. 3, pp. 257–282, 2024.
- [13] X. Zhang, Y. Li, T. Li, Y. Gui, Q. Sun, and D. W. Gao, "Digital twin empowered pv power prediction," *Journal of Modern Power Systems and Clean Energy*, vol. 12, no. 5, pp. 1472–1483, 2023.
- [14] G. Antonesi, T. Cioara, I. Anghel, V. Michalakopoulos, E. Sarvas, and L. Todorean, "A systematic review of transformers and large language models in the energy sector: Towards agentic digital twins," *Applied Energy*, vol. 401, p. 126670, 2025.
- [15] V. Michalakopoulos, A. Zakynthinos, E. Sarvas, V. Marinakis, and D. Askounis, "Hybrid short-term wind power forecasting model using theoretical power curves and temporal fusion transformers," *Renewable Energy*, p. 124008, 2025.
- [16] V. Michalakopoulos, E. Sarvas, I. Papias, P. Skaloumpakas, V. Marinakis, and H. Doukas, "A machine learning-based framework for clustering residential electricity load profiles to enhance demand response programs," *Applied Energy*, vol. 361, p. 122943, 2024.
- [17] I. Papias, V. Michalakopoulos, E. Sarvas, V. Marinakis, G. Antonesi, T. Cioara, and I. Anghel, "A data-driven framework for estimating residential energy flexibility for aggregated demand-side management," *Sustainable Energy, Grids and Networks*, p. 101783, 2025.
- [18] P. Skaloumpakas, A. Sianni, V. Michalakopoulos, P. Tobin, B. Murphy, E. Sarvas, and V. Marinakis, "Social-sciences-and humanities-based profiling of energy consumers towards increasing demand response engagement," *Electronics*, vol. 14, no. 18, p. 3700, 2025.
- [19] V. Michalakopoulos, S. Pelekis, G. Kormpakis, V. Karakolis, S. Mouzakitis, and D. Askounis, "Efi-dss: A machine learning-based decision support system for energy efficiency investments in buildings," in *2025 10th International Conference on Smart and Sustainable Technologies (SpliTech)*, pp. 1–7, IEEE, 2025.

- [20] V. Michalakopoulos, S. Pelekis, G. Kormpakis, V. Karakolis, S. Mouzakitis, and D. Askounis, "Data-driven building energy efficiency prediction using physics-informed neural networks," in *2024 IEEE Conference on Technologies for Sustainability (SusTech)*, pp. 84–91, IEEE, 2024.
- [21] V. Michalakopoulos, I. Papias, E. Sarantinopoulos, E. Sarmas, V. Marinakis, and D. Askounis, "A hyperparameter-space clustering methodology of residential electricity loads," *Applied Soft Computing*, p. 113497, 2025.
- [22] A. Gabriel, T. Cioara, I. Anghel, I. Papias, V. Michalakopoulos, and E. Sarmas, "Hybrid transformer model with liquid neural networks and learnable encodings for buildings' energy forecasting," *Energy and AI*, p. 100489, 2025.
- [23] C. Scott, M. Ahsan, and A. Albarbar, "Machine learning for forecasting a photovoltaic (pv) generation system," *Energy*, vol. 278, p. 127807, 2023.
- [24] Z.-H. Zhou, *Machine learning*. Springer nature, 2021.
- [25] E. F. Morales and H. J. Escalante, "A brief introduction to supervised, unsupervised, and reinforcement learning," in *Biosignal processing and classification using computational learning and intelligence*, pp. 111–129, Elsevier, 2022.
- [26] P. Cunningham, M. Cord, and S. J. Delany, "Supervised learning," in *Machine learning techniques for multimedia: case studies on organization and retrieval*, pp. 21–49, Springer, 2008.
- [27] G. James, D. Witten, T. Hastie, R. Tibshirani, and J. Taylor, "Unsupervised learning," in *An introduction to statistical learning: with applications in Python*, pp. 503–556, Springer, 2023.
- [28] M. A. Wiering and M. Van Otterlo, "Reinforcement learning," *Adaptation, learning, and optimization*, vol. 12, no. 3, p. 729, 2012.
- [29] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *nature*, vol. 521, no. 7553, pp. 436–444, 2015.
- [30] I. Goodfellow, Y. Bengio, A. Courville, and Y. Bengio, *Deep learning*, vol. 1. MIT press Cambridge, 2016.
- [31] J. Schmidhuber, "Deep learning in neural networks: An overview," *Neural networks*, vol. 61, pp. 85–117, 2015.
- [32] F. Rosenblatt, "The perceptron: a probabilistic model for information storage and organization in the brain," *Psychological review*, vol. 65, no. 6, p. 386, 1958.

- [33] 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.
- [34] K. O’shea and R. Nash, “An introduction to convolutional neural networks,” *arXiv preprint arXiv:1511.08458*, 2015.
- [35] S. Hochreiter and J. Schmidhuber, “Long short-term memory,” *Neural computation*, vol. 9, no. 8, pp. 1735–1780, 1997.
- [36] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, Ł. Kaiser, and I. Polosukhin, “Attention is all you need,” *Advances in neural information processing systems*, vol. 30, 2017.
- [37] W. H. Delashmit, M. T. Manry, *et al.*, “Recent developments in multilayer perceptron neural networks,” in *Proceedings of the seventh annual memphis area engineering and science conference, MAESC*, vol. 7, p. 33, 2005.
- [38] S. Sharma, S. Sharma, and A. Athaiya, “Activation functions in neural networks,” *Towards Data Sci*, vol. 6, no. 12, pp. 310–316, 2017.
- [39] D. B. Or, M. Kolomenkin, and G. Shabat, “Generalized quantile loss for deep neural networks,” *arXiv preprint arXiv:2012.14348*, 2020.
- [40] D. P. Kingma and J. Ba, “Adam: A method for stochastic optimization,” *arXiv preprint arXiv:1412.6980*, 2014.
- [41] W. Tang, G. Long, L. Liu, T. Zhou, J. Jiang, and M. Blumenstein, “Rethinking 1d-cnn for time series classification: A stronger baseline,” *arXiv preprint arXiv:2002.10061*, pp. 1–7, 2020.
- [42] R. Sánchez-Reolid, F. L. de la Rosa, M. T. López, and A. Fernández-Caballero, “One-dimensional convolutional neural networks for low/high arousal classification from electrodermal activity,” *Biomedical Signal Processing and Control*, vol. 71, p. 103203, 2022.
- [43] I. Cacciari and A. Ranfagni, “Hands-on fundamentals of 1d convolutional neural networks—a tutorial for beginner users,” *Applied Sciences (2076-3417)*, vol. 14, no. 18, 2024.
- [44] F. Bieder, R. Sandkühler, and P. C. Cattin, “Comparison of methods generalizing max-and average-pooling,” *arXiv preprint arXiv:2103.01746*, 2021.
- [45] K. Greff, R. K. Srivastava, J. Koutník, B. R. Steunebrink, and J. Schmidhuber, “Lstm: A search space odyssey,” *IEEE transactions on neural networks and learning systems*, vol. 28, no. 10, pp. 2222–2232, 2016.

- [46] A. A. Ismail, T. Wood, and H. C. Bravo, “Improving long-horizon forecasts with expectation-biased lstm networks,” *arXiv preprint arXiv:1804.06776*, 2018.
- [47] M. Schuster and K. K. Paliwal, “Bidirectional recurrent neural networks,” *IEEE transactions on Signal Processing*, vol. 45, no. 11, pp. 2673–2681, 1997.
- [48] K. Aitken, V. Ramasesh, Y. Cao, and N. Maheswaranathan, “Understanding how encoder-decoder architectures attend,” *Advances in Neural Information Processing Systems*, vol. 34, pp. 22184–22195, 2021.
- [49] T. Li, J. Song, Z. Song, A. Ablimit, and L. Chen, “Removing nonrigid refractive distortions for underwater images using an attention-based deep neural network,” *Intelligent Marine Technology and Systems*, vol. 2, no. 1, p. 25, 2024.
- [50] B. Lim, S. Ö. Arik, N. Loeff, and T. Pfister, “Temporal fusion transformers for interpretable multi-horizon time series forecasting,” *International journal of forecasting*, vol. 37, no. 4, pp. 1748–1764, 2021.
- [51] T. Chai and R. R. Draxler, “Root mean square error (rmse) or mean absolute error (mae)?—arguments against avoiding rmse in the literature,” *Geoscientific model development*, vol. 7, no. 3, pp. 1247–1250, 2014.
- [52] P. Goodwin and R. Lawton, “On the asymmetry of the symmetric mape,” *International journal of forecasting*, vol. 15, no. 4, pp. 405–408, 1999.
- [53] D. Chicco, M. J. Warrens, and G. Jurman, “The coefficient of determination r-squared is more informative than smape, mae, mape, mse and rmse in regression analysis evaluation,” *Peerj computer science*, vol. 7, p. e623, 2021.
- [54] M. Zamo, O. Mestre, P. Arbogast, and O. Pannekoucke, “A benchmark of statistical regression methods for short-term forecasting of photovoltaic electricity production. part ii: Probabilistic forecast of daily production,” *Solar Energy*, vol. 105, pp. 804–816, 2014.
- [55] F. Almonacid, P. Pérez-Higueras, E. F. Fernández, and L. Hontoria, “A methodology based on dynamic artificial neural network for short-term forecasting of the power output of a pv generator,” *Energy conversion and Management*, vol. 85, pp. 389–398, 2014.
- [56] Y. Sun, V. Venugopal, and A. R. Brandt, “Short-term solar power forecast with deep learning: Exploring optimal input and output configuration,” *Solar Energy*, vol. 188, pp. 730–741, 2019.
- [57] M. Gao, J. Li, F. Hong, and D. Long, “Day-ahead power forecasting in a large-scale photovoltaic plant based on weather classification using lstm,” *Energy*, vol. 187, p. 115838, 2019.

- [58] D. V. Pombo, H. W. Bindner, S. V. Spataru, P. E. Sørensen, and P. Bacher, “Increasing the accuracy of hourly multi-output solar power forecast with physics-informed machine learning,” *Sensors*, vol. 22, no. 3, p. 749, 2022.
- [59] E. Sarmas, N. Dimitropoulos, V. Marinakis, Z. Mylona, and H. Doukas, “Transfer learning strategies for solar power forecasting under data scarcity,” *Scientific Reports*, vol. 12, no. 1, p. 14643, 2022.
- [60] Z. Wu, F. Pan, D. Li, H. He, T. Zhang, and S. Yang, “Prediction of photovoltaic power by the informer model based on convolutional neural network,” *Sustainability*, vol. 14, no. 20, p. 13022, 2022.
- [61] D. K. Dhaked, S. Dadhich, and D. Birla, “Power output forecasting of solar photovoltaic plant using lstm,” *Green Energy and Intelligent Transportation*, vol. 2, no. 5, p. 100113, 2023.
- [62] A. Babalhavaeji, M. Radmanesh, M. Jalili, and S. A. González, “Photovoltaic generation forecasting using convolutional and recurrent neural networks,” *Energy Reports*, vol. 9, pp. 119–123, 2023.
- [63] M. Islam, S. S. Shuvo, J. A. Shohan, and O. Faruque, “Forecasting of pv plant output using interpretable temporal fusion transformer model,” in *2023 North American Power Symposium (NAPS)*, pp. 01–06, IEEE, 2023.
- [64] H. Zhou, P. Zheng, J. Dong, J. Liu, and Y. Nakanishi, “Interpretable feature selection and deep learning for short-term probabilistic pv power forecasting in buildings using local monitoring data,” *Applied Energy*, vol. 376, p. 124271, 2024.
- [65] X. Yang, L. Yang, Y. Li, Z. Zhao, and Y. Zhang, “A new method of photovoltaic clusters power prediction based on informer considering time-frequency analysis and convergence effect,” *Electric Power Systems Research*, vol. 238, p. 111049, 2025.
- [66] X. Liu, Q. Liu, S. Feng, Y. Ge, H. Chen, and C. Chen, “Novel model for medium to long term photovoltaic power prediction using interactive feature trend transformer,” *Scientific Reports*, vol. 15, no. 1, p. 6544, 2025.
- [67] C. Zhai, X. He, Z. Cao, M. Abdou-Tankari, Y. Wang, and M. Zhang, “Photovoltaic power forecasting based on vmd-ssa-transformer: Multidimensional analysis of dataset length, weather mutation and forecast accuracy,” *Energy*, vol. 324, p. 135971, 2025.
- [68] M. Fouad, L. A. Shihata, and E. I. Morgan, “An integrated review of factors influencing the performance of photovoltaic panels,” *Renewable and Sustainable Energy Reviews*, vol. 80, pp. 1499–1511, 2017.

- [69] K. Hasan, S. B. Yousuf, M. S. H. K. Tushar, B. K. Das, P. Das, and M. S. Islam, "Effects of different environmental and operational factors on the pv performance: A comprehensive review," *Energy Science & Engineering*, vol. 10, no. 2, pp. 656–675, 2022.
- [70] T. Yunus Khan, M. E. M. Soudagar, M. Kanchan, A. Afzal, N. R. Banapurmath, N. Akram, S. D. Mane, and K. Shahapurkar, "Optimum location and influence of tilt angle on performance of solar pv panels," *Journal of Thermal Analysis and Calorimetry*, vol. 141, no. 1, pp. 511–532, 2020.
- [71] S. Chen, P. Li, D. Brady, and B. Lehman, "Determining the optimum grid-connected photovoltaic inverter size," *Solar Energy*, vol. 87, pp. 96–116, 2013.
- [72] D. S. Kumar, G. M. Yagli, M. Kashyap, and D. Srinivasan, "Solar irradiance resource and forecasting: a comprehensive review," *IET Renewable Power Generation*, vol. 14, no. 10, pp. 1641–1656, 2020.
- [73] M. Lave, W. Hayes, A. Pohl, and C. W. Hansen, "Evaluation of global horizontal irradiance to plane-of-array irradiance models at locations across the united states," *IEEE journal of Photovoltaics*, vol. 5, no. 2, pp. 597–606, 2015.
- [74] A. Coelho and R. Castro, "Modeling and validation of pv power output with solar tracking," in *2011 International Conference on Power Engineering, Energy and Electrical Drives*, pp. 1–6, IEEE, 2011.
- [75] Y. Zhang, L. O. Wijeratne, S. Talebi, and D. J. Lary, "Machine learning for light sensor calibration," *Sensors*, vol. 21, no. 18, p. 6259, 2021.
- [76] Z. R. Tahir, A. Kanwal, M. Asim, M. Bilal, M. Abdullah, S. Saleem, M. Mujtaba, I. Veza, M. Mousa, and M. Kalam, "Effect of temperature and wind speed on efficiency of five photovoltaic module technologies for different climatic zones," *Sustainability*, vol. 14, no. 23, p. 15810, 2022.
- [77] W. F. Holmgren, C. W. Hansen, and M. A. Mikofski, "pvlib python: A python package for modeling solar energy systems," *Journal of Open Source Software*, vol. 3, no. 29, p. 884, 2018.
- [78] R. W. Andrews, J. S. Stein, C. Hansen, and D. Riley, "Introduction to the open source pv lib for python photovoltaic system modelling package," in *2014 IEEE 40th photovoltaic specialist conference (PVSC)*, pp. 0170–0174, IEEE, 2014.
- [79] I. Reda and A. Andreas, "Solar position algorithm for solar radiation applications," *Solar energy*, vol. 76, no. 5, pp. 577–589, 2004.

- [80] A. Bramm, S. Eroshenko, and A. Khalyasmaa, "Effect of data preprocessing on the forecasting accuracy of solar power plant," in *2021 XVIII International Scientific Technical Conference Alternating Current Electric Drives (ACED)*, pp. 1–5, IEEE, 2021.
- [81] N. M. Noor, M. M. Al Bakri Abdullah, A. S. Yahaya, and N. A. Ramli, "Comparison of linear interpolation method and mean method to replace the missing values in environmental data set," in *Materials science forum*, vol. 803, pp. 278–281, Trans Tech Publ, 2015.
- [82] W. Liu and Z. Mao, "Short-term photovoltaic power forecasting with feature extraction and attention mechanisms," *Renewable Energy*, vol. 226, p. 120437, 2024.
- [83] R. Pandey, M. Dhoundiyal, and A. Kumar, "Correlation analysis of big data to support machine learning," in *2015 Fifth International Conference on Communication Systems and Network Technologies*, pp. 996–999, IEEE, 2015.
- [84] J. O. Ogutu, T. Schulz-Streeck, and H.-P. Piepho, "Genomic selection using regularized linear regression models: ridge regression, lasso, elastic net and their extensions," in *BMC proceedings*, vol. 6, p. S10, Springer, 2012.
- [85] T. Akiba, S. Sano, T. Yanase, T. Ohta, and M. Koyama, "Optuna: A next-generation hyperparameter optimization framework," in *Proceedings of the 25th ACM SIGKDD international conference on knowledge discovery & data mining*, pp. 2623–2631, 2019.
- [86] M. Abadi, P. Barham, J. Chen, Z. Chen, A. Davis, J. Dean, M. Devin, S. Ghemawat, G. Irving, M. Isard, *et al.*, "{TensorFlow}: a system for {Large-Scale} machine learning," in *12th USENIX symposium on operating systems design and implementation (OSDI 16)*, pp. 265–283, 2016.
- [87] A. Paszke, S. Gross, F. Massa, A. Lerer, J. Bradbury, G. Chanan, T. Killeen, Z. Lin, N. Gimelshein, L. Antiga, *et al.*, "Pytorch: An imperative style, high-performance deep learning library," *Advances in neural information processing systems*, vol. 32, 2019.
- [88] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, *et al.*, "Scikit-learn: Machine learning in python," *the Journal of machine Learning research*, vol. 12, pp. 2825–2830, 2011.
- [89] W. McKinney and P. Team, "Pandas-powerful python data analysis toolkit," *Pandas—Powerful Python Data Analysis Toolkit*, vol. 1625, 2015.
- [90] C. R. Harris, K. J. Millman, S. J. Van Der Walt, R. Gommers, P. Virtanen, D. Cournapeau, E. Wieser, J. Taylor, S. Berg, N. J. Smith, *et al.*, "Array programming with numpy," *nature*, vol. 585, no. 7825, pp. 357–362, 2020.