



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

Πρόβλεψη παραγωγής ενέργειας από
Φωτοβολταϊκά πάρκα με χρήση τεχνητών
νευρωνικών δικτύων

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

της

ΒΑΣΙΛΙΚΗΣ ΝΙΚΟΛΑΟΥ

Επιβλέπων: Νικόλαος Χατζηαργυρίου
Καθηγητής Ε.Μ.Π.

ΕΡΓΑΣΤΗΡΙΟ ΣΥΣΤΗΜΑΤΩΝ ΗΛΕΚΤΡΙΚΗΣ ΕΝΕΡΓΕΙΑΣ
Αθήνα, Ιούλιος 2020



Εθνικό Μετσόβιο Πολυτεχνείο
Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών
Τομέας Ηλεκτρικής Ισχύος
Εργαστήριο Συστημάτων Ηλεκτρικής Ενέργειας

Πρόβλεψη παραγωγής ενέργειας από
Φωτοβολταϊκά πάρκα με χρήση τεχνητών
νευρωνικών δικτύων

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

της

ΒΑΣΙΛΙΚΗΣ ΝΙΚΟΛΑΟΥ

Επιβλέπων: Νικόλαος Χατζηαργυρίου
Καθηγητής Ε.Μ.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 23η Ιουλίου 2020.

(Υπογραφή)

(Υπογραφή)

(Υπογραφή)

.....
Νικόλαος Χατζηαργυρίου
Καθηγητής Ε.Μ.Π.

.....
Πάυλος Γεωργιλιάκης
Καθηγητής Ε.Μ.Π.

.....
Σταύρος Παπαθανασίου
Καθηγητής Ε.Μ.Π.

Αθήνα, Ιούλιος 2020

(Υπογραφή)

.....
ΒΑΣΙΛΙΚΗ ΝΙΚΟΛΑΟΥ

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

© 2020 – All rights reserved



Εθνικό Μετσόβιο Πολυτεχνείο
Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών
Τομέας Ηλεκτρικής Ισχύος
Εργαστήριο Συστημάτων Ηλεκτρικής Ενέργειας

Copyright ©–All rights reserved Βασιλική Νικολάου, 2020.

Με επιφύλαξη παντός δικαιώματος.

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

Ευχαριστίες

Η παρούσα διπλωματική εκπονήθηκε στο Εργαστήριο Συστημάτων Ηλεκτρικής Ενέργειας της Σχολής Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών του Εθνικού Μετσόβιου Πολυτεχνείου.

Θα ήθελα να ευχαριστήσω θερμά τον επιβλέποντα καθηγητή κ. Χατζηαργυρίου, για την ευκαιρία που μου έδωσε, να εκπονήσω τη διπλωματική μου εργασία, σε ένα θέμα τόσο ενδιαφέρον και δημιουργικό.

Επίσης ευχαριστώ ιδιαίτερα τον υποψήφιο διδάκτορα Θωδωρή Κωνσταντίνου για την εξαιρετική συνεργασία και τη συνεχή καθοδήγηση κατά τη συγγραφή της εργασίας αυτής.

Από καρδιάς θα ήθελα να ευχαριστήσω πολύ τους φίλους και τις φίλες μου για την ουσιαστική συμπαράσταση και συνεργασία, όλα αυτά τα χρόνια. Την οικογένεια μου, τους γονείς μου, Πέτρο και Βαρβάρα, για την στήριξη και την εμπιστοσύνη τους. Τέλος, αφιερώνω την παρούσα εργασία στην αδερφή μου Μαρίνα, που μου προσφέρει έμπνευση και χαρά, να προσπαθώ περισσότερο.

Περίληψη

Οι ΑΠΕ διαδραματίζουν ολοένα και αποφασιστικότερο ρόλο στην παραγωγή ενέργειας και στην λύση του ενεργειακού ζητήματος. Τα φωτοβολταϊκά συστήματα έχουν πρωταγωνιστικό ρόλο ανάμεσα στις τεχνολογίες ΑΠΕ, με πλεονεκτήματα που τα καθιστούν ιδιαίτερα ελκυστικά στη νέα απελευθερωμένη αγορά ηλεκτρικής ενέργειας και ειδικότερα στα πλαίσια της “πράσινης” ανάπτυξης που προωθείται παγκοσμίως. Ωστόσο, η στοχαστική φύση της παραγωγής τους, μας οδηγεί στην ανάγκη για δημιουργία ασφαλών προβλέψεων σχετικά με αυτή. Η πρόοδος των τεχνητών νευρωνικών δικτύων και οι εξαιρετικές επιδόσεις τους στον εντοπισμό συσχετισμών μεταξύ παρατηρήσεων και στις προβλέψεις ακολουθιών μας οδηγούν στην εφαρμογή ορισμένων αρχιτεκτονικών στο πρόβλημα που περιγράφηκε παραπάνω.

Αντικείμενο της παρούσας διπλωματικής εργασίας είναι η δημιουργία βραχυπρόθεσμων προβλέψεων για τη χρονοσειρά παραγωγής φωτοβολταϊκών πάρκων. Οι προβλέψεις έχουν ορίζοντα 24 ωρών (day-ahead) και σκοπός της εργασίας είναι η σύγκριση των αποδόσεων διαφορετικών μοντέλων. Υλοποιούνται δυο στατιστικά μοντέλα, το μοντέλο παραμένουσας τιμής (Peristence) και ολοκληρωμένο αυτοπαλινδρομικό μοντέλο κινητού μέσου όρου (ARIMA). Ακόμα σχεδιάζονται και εκπαιδεύονται τρία βαθιά νευρωνικά δίκτυα. Ένα αναδρομικό νευρωνικό δίκτυο, συγκεκριμένα μακράς βραχέας μνήμης (LSTM), ένα μονοδιάστατο συνελικτικό νευρωνικό δίκτυο (CNN 1d) και τέλος ο συνδυασμός των παραπάνω αρχιτεκτονικών σε ένα τρίτο δίκτυο (CNN1d-LSTM). Η σχεδίαση των στατιστικών μοντέλων, καθώς και των νευρωνικών δικτύων, έγινε σε γλώσσα Python, έκδοση 3.7.4, με χρήση Keras, ενός high-level API της TensorFlow κατάλληλου για την κατασκευή και εκπαίδευση μοντέλων βαθιάς μάθησης. Για την σύγκριση των προβλέψεων υπολογίστηκε το Κανονικοποιημένο Μέσο Απόλυτο Σφάλμα (NMAE), σε συνολική και ανά ώρα τιμή.

Λέξεις Κλειδιά

Πρόβλεψη Χρονοσειρών, βραχυπρόθεσμες προβλέψεις, Νευρωνικά δίκτυα, ΑΠΕ, παραγωγή φωτοβολταϊκών, συνελικτικά νευρωνικά δίκτυα, αναδρομικά νευρωνικά δίκτυα, βραχέα-μακρά μνήμη .

Abstract

Renewables energy resources gradually play a crucial role in the power production as well as in the resolution of the energy issue. Photovoltaic systems have an important role within the various RES technologies, with a lot of advantages that render them particularly appealing in the new power market, and especially in the green energy development which grows rapidly around the world. However, the stochastic nature of green energy production forces the scientists to focus on solid forecasting models. The breakthrough in artificial neural networks and their outstanding performance in the identification of the correlations between observations and time series forecasting, leads the scientific community on the implementation of specific methodologies in the aforementioned problem. The objective of the present diploma thesis is the generation of short-term forecasting for production time series of Photovoltaic farms. The forecasts are based on 24h horizon and the goal of this research is the comparison of various models' efficiency. Two statistic models are investigated; the t-Persistence model and the t-Arima model. Furthermore, three neural networks are designed and trained. The selected models are : a recurrent neural network, with long short memory (LSTM), a one-dimensional convolutional neural network (CNN 1d) and finally the combination of the above architectures in a third network (CNN1d-LSTM) . The design of statistical models, as well as of the neural networks, was impelemented in Python version 3.7.4, using Keras, a high-level API of TensorFlow suitable for the construction and training of deep learning models. For the comparison of the forecasts, the Normal Average Absolute Error (NMAE) was calculated, in total and per hour value.

Keywords

Time Series Forecasting, Short-Term Forecasting, Neural Networks, RES, Photovoltaic Production, Convolutional Neural Networks, Recurrent Neural Networks, Long-Short Term Memory

Περιεχόμενα

Ευχαριστίες	1
Περίληψη	3
Abstract	5
Περιεχόμενα	8
Κατάλογος Σχημάτων	10
Κατάλογος Πινάκων	11
1 Εισαγωγή	13
1.1 Αντικείμενο Διπλωματικής	13
1.2 Συγγενικές εργασίες	16
1.3 Οργάνωση του τόμου	17
2 Φωτοβολταϊκά και σύνδεση στο δίκτυο	19
2.1 Εισαγωγή	20
2.2 Ηλιακή ενέργεια	24
2.2.1 Τεχνολογίες ΦΒ	25
2.2.2 Η κατάσταση στα Φωτοβολταϊκά σήμερα	28
2.3 Σύνδεση Φωτοβολταϊκών στο δίκτυο	31
3 Θεωρητικό υπόβαθρο	35
3.1 Εισαγωγή	35
3.2 Τεχνικές Προβλέψεων	36
3.2.1 Χαρακτηριστικά χρονοσειρών	36
3.2.2 Ολοκληρωμένα Αυτοπαλινδρομικά Μοντέλα Κινητού Μέσου Όρου - ARIMA	38
3.3 Τεχνητά Νευρωνικά Δίκτυα - Artificial Neural Networks	43
3.3.1 Εισαγωγή	43
3.3.2 Νευρώνας - Perceptron	43

3.3.3	Multilayer Perceptron	45
3.3.4	Συνελικτικό Νευρωνικό Δίκτυο - Convolutional Neural Networks	46
3.3.5	Αναδρομικά Νευρωνικά Δίκτυα - Recurrent Neural Networks	48
3.3.6	Νευρωνικό Δίκτυο Μακράς-Βραχείας Μνήμης - LSTM	50
3.4	Μετρικές Σφαλμάτων	51
4	Δεδομένα και Μεθοδολογία για Βραχυπρόθεσμη Πρόβλεψη Παραγωγής Φωτοβολταϊκών	53
4.1	Εισαγωγή	53
4.2	Σχολιάσιμος Δεδομένων	54
4.3	Μοντέλο Παραμένουσας Τιμής - Persistence Model	57
4.3.1	Αλγόριθμος	57
4.3.2	Αποτελέσματα	57
4.4	Ολοκληρωμένα Αυτοπαλινδρομικά Μοντέλα Κινητού Μέσου Όρου- ARIMA	61
4.4.1	Προεπεξεργασία Δεδομένων	61
4.4.2	Αλγόριθμος	63
4.4.3	Αποτελέσματα	64
4.4.4	Σφάλματα	65
4.5	Νευρωνικά δίκτυα μακράς βραχυπρόθεσμης μνήμης- LSTM	70
4.5.1	Αλγόριθμος	70
4.5.2	Αποτελέσματα	71
4.5.3	Σφάλματα	71
4.6	Συνελικτικό Νευρωνικό δίκτυο - CNN	72
4.6.1	Αλγόριθμος	72
4.6.2	Αποτελέσματα	72
4.6.3	Σφάλματα	73
4.7	CNN-LSTM	74
4.7.1	Αλγόριθμος	74
4.7.2	Αποτελέσματα	74
4.7.3	Σφάλματα	75
4.8	Σύγκριση Μοντέλων	76
5	Συμπεράσματα	79
5.1	Σύνοψη- Συμπεράσματα	79
5.2	Μελλοντικές Επεκτάσεις	81
	Βιβλιογραφία	83
	Γλωσσάριο	87

Κατάλογος Σχημάτων

2.2	Annual Worldwide Solar Irradiance	24
2.3	Photovoltaic Effect	26
2.4	From a solar cell to a PV System	27
2.6	Percentage of RES to Total Energy Generation	28
2.7	Total solar PV installed capacity 2000-2019	29
2.8	Total solar PV installed capacity shares 2012-2019	29
2.9	Solar capacity per capita	30
3.1	Example of a Stationary and a Non-Stationary Time Series	36
3.2	Trend, Cycle, Seasonality & Residuals of a Time Series	37
3.3	Artificial Neuron model and its parts	44
3.4	Activation functions	44
3.5	Three layer multilayer perceptron (MLP) neural network	46
3.6	CNN & MLP Architecture	46
3.7	Convolutional Layer of a CNN	47
3.8	CNN model architecture	48
3.9	Recursive Neural Network Unfolding	49
3.10	LSTM Model Architecture	50
4.1	Ετήσια Ωριαία Παραγωγή Ενεργού Ισχύος Ανά Υποσταθμό	54
4.2	Summer Bancroft Close	55
4.3	Winter Maple Drive East	56
4.4	Persistence Model Summer Bancroft Close Forecasts	57
4.5	Persistence Model Winter Middle East Drive Forecasts	58
4.6	Forecasts for 1st, 2nd, 3rd of March 2014 in MDE	58
4.7	Forecasts for 10th, 11th, 12th of March 2014 in MDE	59
4.8	Forecasts for 1st, 2nd, 3rd of August 2014 in BC	59
4.9	Forecasts for 10th, 11th, 12th of August 2014 in BC	60
4.10	Data, Rolling Mean & Std For Summer BC	61
4.11	Data, Rolling Mean & Std For Winter MDE	62
4.12	ACF & PACF for Summer BC	63
4.13	ACF & PACF for Winter MDE	63

4.14	Winter MDE Forecasts	64
4.15	Summer BC Forecasts	65
4.17	Hourly Error Distribution of Different ARIMA models	67
4.18	Daily Mean Absolute Error	68
4.19	Daily Error Standard Deviation	69
4.26	NMAE for Summer BC	76
4.27	NMAE for Winter MDE	77
4.28	Forecasts for 1st, 2nd 3rd of Aug'14	78
4.29	Forecasts for 1st, 2nd 3rd of Mar'14	78

Κατάλογος Πινάκων

4.1	Stationarity Tests for Summer Trimester of Bancroft Close	62
4.2	Stationarity Tests for Winter Trimester of MDE	62
4.3	Model Summary	70
4.4	Hyperparametres of LSTM Model	70
4.5	Model Summary	72
4.6	Hyperparametres of CNN 1d Model	72
4.7	Model Summary	74
4.8	Hyperparametres of CNN-LSTM Model	74

Κεφάλαιο 1

Εισαγωγή

1.1 Αντικείμενο Διπλωματικής

Η ενέργεια, ως αγαθό, είναι απαραίτητο στοιχείο για την λειτουργία των σύγχρονων κοινωνιών, σε παγκόσμιο επίπεδο, με τη μορφή που τις γνωρίζουμε. Το σύγχρονο μοντέλο οικονομικής ανάπτυξης, προϋποθέτει την χρήση τεράστιων ποσοτήτων ενέργειας για την κάλυψη πλήθους αναγκών, που αφορούν μετακινήσεις ανθρώπων ή προϊόντων, φωτισμό και θέρμανση, τη λειτουργία βιομηχανικών μονάδων και πολλούς άλλους τομείς. Η κάλυψη των απαιτήσεων σε ενέργεια εξασφαλίζεται από Συμβατικές Πηγές Ενέργειας και Ανανεώσιμες Πηγές Ενέργειας[1]. Οι βασικές μορφές ΑΠΕ αφορούν τις μεταβλητές, δηλαδή την ηλιακή και την αιολική ενέργεια και τις μη μεταβλητές, υδροηλεκτρική, βιομάζα και γεωθερμική. Οι ΣΠΕ αφορούν ορυκτά στερεά[2], υγρά ή αέρια καύσιμα, τα οποία έχουν σχηματιστεί σε παλαιότερες γεωλογικές περιόδους και βρίσκονται αποθηκευμένα στο υπέδαφος, σε μικρότερα ή μεγαλύτερα βάθη σε πεπερασμένες, μη ανανεώσιμες ποσότητες. Ωστόσο, η βιομηχανική ανάπτυξη και η εντατική χρήση ορυκτών καυσίμων, έχουν δημιουργήσει σοβαρά περιβαλλοντολογικά προβλήματα στον πλανήτη. Ακόμα, καθώς ο πληθυσμός της γης αυξάνεται διαρκώς, αυξάνονται και οι ανάγκες σε ενέργεια.

Ως εκ τούτου, γίνεται ολοένα και πιο επιτακτική η ανάγκη για μετάβαση σε ένα ενεργειακό μοντέλο που θα στηρίζεται σε μεγαλύτερο βαθμό στις ανανεώσιμες πηγές ενέργειας. Μάλιστα, τα πλεονεκτήματά των ΑΠΕ [3] για την προστασία του περιβάλλοντος (Λευκή Βίβλος «Ενέργεια για το Μέλλον» 1997) και για την ανεξαρτησία του ενεργειακού εφοδιασμού (Γρεεν Παπερ «Στρατηγική για την Ασφάλεια της παροχής Ενέργειας»), τις έχουν καταστήσει βασική προτεραιότητα της ΕΕ. Σύμφωνα με τα κύρια επιτεύγματα της Συμφωνίας Κρατών-Μελών της ΕΕ για το 2020 (στόχος 20-20-20), οι εκπομπές ΑτΘ μειώθηκαν κατά 22% ως προς τις εκπομπές του 1990 (τέλος 2016), οι ΑΠΕ συμμετέχουν κατά 16,7% στην τελική κατανάλωση ενέργειας το 2016, στην ΕΕ(28), ενώ στο τέλος του 2014, το μερίδιο της ΕΕ στην παγκοσμίως εγκατεστημένη δυναμικότητα ηλεκτροπαραγωγής από ΑΠΕ ανερχόταν σε 38,8%. Το νέο πλαίσιο πολιτικής της ΕΕ για το 2030 συστήνει μείωση των εκπομπών κατά 40% κάτω από το επίπεδο του 1990, διείσδυση των ΑΠΕ στη συνολική κατανάλωση ενέργειας τουλάχιστον κατά 32% το 2030, υψηλότερο επίπεδο εξοικονόμησης ενέργειας κατά περίπου 32.5%,

μεταρρύθμιση του συστήματος εμπορίας ρύπων καθώς και ένα νέο σύστημα διακυβέρνησης με βάση τα εθνικά σχέδια για ανταγωνιστική, ασφαλή και βιώσιμη ενέργεια.

Η αυξανόμενη διείσδυση των ανανεώσιμων πηγών ενέργειας (ΑΠΕ) παγκοσμίως δημιουργούν προοπτικές για καθαρότερο, πιο βιώσιμο και πιο ανθρακούχο μέλλον. Ωστόσο, εκτός από τα προφανή περιβαλλοντικά οφέλη, η μεγάλης κλίμακας διείσδυση ΑΠΕ στο δίκτυο πρέπει να αντιμετωπιστεί προσεκτικά, δεδομένου ότι φέρνει νέες προκλήσεις στον βραχυπρόθεσμο προγραμματισμό και λειτουργία των ΣΗΕ. Στο σημερινό ηλεκτρικό δίκτυο, καθώς αυξάνεται η διείσδυση των ανανεώσιμων πηγών ενέργειας (ΑΠΕ), αυξάνεται επίσης η αβεβαιότητα [4] στη διαθέσιμη παραγωγή. Ειδικότερα, όσο μεγαλύτερο είναι το μερίδιο των ΑΠΕ στο δίκτυο, τόσο περισσότερο εξαρτάται η παραγωγή ηλεκτρικής ενέργειας από τις καιρικές συνθήκες και με τη σειρά της, τόσο πιο απρόβλεπτη παραγωγή ηλεκτρικής ενέργειας γίνεται. Αυτή η αβεβαιότητα επηρεάζει επίσης την πλευρά της ζήτησης καθώς η κατανάλωση ηλεκτρικής ενέργειας εξαρτάται επίσης από τις καιρικές συνθήκες. Σε αυτό το πλαίσιο, προκειμένου να αντιμετωπιστεί η αβεβαιότητα στην παραγωγή και τη ζήτηση ηλεκτρικής ενέργειας, η πρόβλεψη της παραγωγής των ΑΠΕ έχει καταστεί απαραίτητη για την ευστάθεια, την αξιοπιστία και την ασφάλεια της λειτουργίας του ΣΗΕ, για τον προγραμματισμό της παραγωγής ενέργειας, το προγραμματισμό των αναγκαίων εφεδριών και για την βέλτιστη λειτουργία της αγοράς ηλεκτρικής ενέργειας.

Εκτός από τα αιολικά πάρκα, οι φωτοβολταϊκές μονάδες (PV) κερδίζουν συνεχώς την αποδοχή παγκοσμίως, καθώς μπορούν να εγκατασταθούν εύκολα και σε διάφορες τοποθεσίες. Ωστόσο, αν και η παραγωγή φωτοβολταϊκών ακολουθεί ένα σχετικά αναμενόμενο καθημερινό μοτίβο παραγωγής, παραμένει στοχαστική λόγω της εγγενούς δυσκολίας στην ακριβή πρόβλεψη των μετεωρολογικών συνθηκών, όπως η ηλιοφάνεια. Η σημασία της πρόβλεψης της παραγωγής των φωτοβολταϊκών έγκειται στα οικονομικά οφέλη που προσφέρει στον διαχειριστή του δικτύου, καθώς και στην καλύτερη λειτουργία του ΣΗΕ. Συγκεκριμένα, η μεταβλητότητα και η αβεβαιότητα της παραγωγής των Φωτοβολταϊκών αυξάνουν τα κόστη λειτουργίας των συμβατικών μονάδων ακόμα και σε περιπτώσεις που μειώνουν την απαιτούμενη παραγωγή από πλευράς τους (κόστη έναρξης και παύσης λειτουργίας). Η βελτίωση των προβλέψεων οδηγεί σε μείωση της παραγωγής από τις συμβατικές μονάδες άμεσης έναρξης, σε μείωση του κόστους παραγωγής και άρα μείωση του συνολικού κόστους λειτουργίας. Ταυτόχρονα οδηγεί σε καλύτερο προγραμματισμό των διαδικασιών συντήρησης των πάρκων.

Η ερευνητική κοινότητα έχει εστιάσει πρόσφατα στην ανάπτυξη προηγμένων μοντέλων και εργαλείων πρόβλεψης παραγωγής φωτοβολταϊκών, τα οποία γενικά χωρίζονται σε δύο κύριες ομάδες. Η πρώτη ομάδα περιλαμβάνει τα φυσικά μοντέλα, τα οποία μετατρέπουν την έξοδο των μοντέλων αριθμητικής πρόβλεψης καιρού (NWP) σε έξοδο φωτοβολταϊκής ισχύος πραγματοποιώντας κατάλληλους υπολογισμούς και συχνά εφαρμόζουν στατιστικά μοντέλα (MOS) για να διορθώσουν τις προβλέψεις. Η δεύτερη ομάδα περιλαμβάνει τα στατιστικά μοντέλα (δηλαδή χρονοσειρές, νευρωνικά δίκτυα, κ.λπ.), τα οποία εστιάζουν στην μελέτη της συσχέτισης μεταξύ ιστορικών δεδομένων προκειμένου να προβλεφθεί η μελλοντική έξοδος των φωτοβολταϊκών, λαμβάνοντας συνήθως υπόψη συσχετίσεις με εξωγενή μετεωρολογικά δεδομένα (π.χ. ηλιακή ακτινοβολία, θερμοκρασία).

Στο πεδίο αυτό έγκειται και ο σκοπός της παρούσας διπλωματικής. Το πρόβλημα που μελε-

τάται είναι η ανάγκη για, την κατα το δυνατόν ακριβή, πρόβλεψη της παραγωγής των φωτοβολταϊκών μονάδων με χρονικό ορίζοντα την επόμενη ημέρα. Μάλιστα επιδιώκεται η βελτίωση των προβλέψεων που παράγουν τα στατιστικά μοντέλα μέσω υλοποίησης τεχνολογιών βαθύων νευρωνικών μοντέλων. Αρχικά, γίνεται μια εισαγωγή στις ΑΠΕ και τις τεχνολογίες των φωτοβολταϊκών μονάδων. Έπειτα, επεξηγούνται τα μαθηματικά μοντέλα προβλέψεων που θα χρησιμοποιήσουμε. Στη συνέχεια υλοποιούνται τα στατιστικά μοντέλα που θα χρησιμοποιηθούν ως μέτρο σύγκρισης για τα αποτελέσματα των νευρωνικών. Κατόπιν σχεδιάζονται τα νευρωνικά μοντέλα, παράγονται οι προβλέψεις για τα διαθέσιμα δεδομένα και έπειτα συγκρίνονται τα αποτελέσματά των διαφορετικών μοντέλων. Τέλος εξάγονται συμπεράσματα και προτείνονται μελλοντικές επεκτάσεις.

1.2 Συγγενικές εργασίες

Παρουσιάζεται μια επισκόπηση συγγενικών εργασιών που μελετήθηκαν κατά την εκπόνηση της παρούσας εργασίας.

1. Στο [12] αναπτύσσονται δυο μοντέλα πρόβλεψης για την παραγωγή τεσσάρων φωτοβολταϊκών εγκαταστάσεων συνδεδεμένων στο δίκτυο, με χρονικό ορίζοντα πρόβλεψης 24 ωρών. Οι φωτοβολταϊκές εγκαταστάσεις βρίσκονται σε διαφορετικές τοποθεσίες σε όλη την Ελληνική επικράτεια. Συγκεκριμένα χρησιμοποιείται μια παραλλαγή του κλασικού μοντέλου ARIMA, το εποχιακό μοντέλο ARIMA (δηλαδή SARIMA), προκειμένου να ληφθεί υπόψη η εγγενής εποχιακότητα στην παραγόμενη ισχύ εξόδου του φωτοβολταϊκού. Το επιλεγμένο μοντέλο SARIMA βελτιώθηκε περαιτέρω από μοντέλα ΑΚΠ ενσωματώνοντας βραχυπρόθεσμες προβλέψεις για την ηλιακή ακτινοβολία, μελετήθηκε δηλαδή και το SARIMAX, (X exogenous parametre). Το δεύτερο μοντέλο υλοποιεί τεχνητά νευρωνικά δίκτυα με πολλαπλές εισόδους. Η απόδοση όλων των μοντέλων πρόβλεψης αξιολογείται με βάση τη Κανονικοποιημένη Ρίζα του Μέσου Τετραγωνικού Σφάλματος (Normalized Root Mean Squared Error), λαμβάνοντας υπόψη μόνο τις ώρες από την ανατολή έως τη δύση του ηλίου.
2. Στο άρθρο [14], παρουσιάζονται μερικά βαθιά συνελικτικά νευρωνικά δίκτυα CNN), που χρησιμοποιούν δεδομένα πρόγνωσης καιρού υψηλής ανάλυσης, με σκοπό την μελέτη χρονικών και χωρικών συσχετίσεων που αφορούν το μοτίβου κίνησης των συννέφων και την επίδρασή του στην πρόβλεψη της παραγωγής ηλιακής ενέργειας από ΦΒ. Το ποσοστό σφάλματος των προβλέψεων ανέρχεται σε 21% στο Persistence μοντέλο σύγκρισης, σε 15,1% από το μοντέλο SVR και στο 11,8% από τα συνελικτικά νευρωνικά δίκτυα.
3. Στο άρθρο [16] συγκρίνονται τέσσερις μέθοδοι για πρόβλεψη παραγωγής ηλεκτρικής ενέργειας από φωτοβολταϊκά συνδεδεμένα στο δίκτυο. Οι μέθοδοι αυτές είναι: ARIMA, SARIMAX (SARIMA με εξωγενή παράγοντα), τροποποιημένο μοντέλο SARIMA, ως αποτέλεσμα μιας εκ των υστέρων τροποποίησης, και ένα μοντέλο νευρωνικού δικτύου. Η σύγκριση των μοντέλων αυτών καταδεικνύει την χρησιμότητα των εξωγενών παραγόντων στην πρόβλεψη χρονοσειρών. Τελικά, οι ωριαίες προβλέψεις για την επόμενη ημέρα χρησιμοποιούνται για την αξιολόγηση των σφαλμάτων των μοντέλων SARIMA και SARIMAX. Όλα τα μοντέλα συγκρίνονται ως προς βάση τη Κανονικοποιημένη (σε σχέση με την εγκατεστημένη ΦΒ χωρητικότητα) Ρίζα του Μέσου Τετραγωνικού Σφάλματος (Normalized Root Mean Squared Error). Τέλος παρουσιάζονται τα αποτελέσματα από την εφαρμογή των μοντέλων πρόβλεψης σε μια ΦΒ εγκατάσταση στην Ελλάδα με πραγματικά δεδομένα.

1.3 Οργάνωση του τόμου

Στο πρώτο κεφάλαιο γίνεται αναφορά στο σκοπό και το αντικείμενο της διπλωματικής. Παρουσιάζονται συνοπτικά συγγενικές εργασίες από τη διεθνή βιβλιογραφία.

Στο δεύτερο κεφάλαιο αναλύονται τα χαρακτηριστικά των ανανεώσιμων πηγών ενέργειας, με έμφαση στην ηλιακή. Μελετάται το φωτοβολταϊκό φαινόμενο, εξετάζεται η θεωρία των φ/β συστημάτων, καθώς και η ανάπτυξη που παρουσιάζει ο τομέας στο σήμερα. Τέλος γίνεται ανάλυση του τρόπου σύνδεσης των φωτοβολταϊκών στο δίκτυο, καθώς και των πιθανών αρνητικών επιπτώσεων αυτής.

Στην συνέχεια, στο τρίτο κεφάλαιο παρουσιάζονται τα ποιοτικά χαρακτηριστικά των χρονοσειρών - αυτοσυσχέτιση, στασιμότητα κ.λ.π - που θα ληφθούν υπόψη στην ακόλουθη μελέτη. Κατόπιν εξηγείται συνοπτικά το μαθηματικό υπόβαθρο των μοντέλων που θα χρησιμοποιηθούν για την πρόβλεψη των χρονοσειρών. Γίνεται διάκριση στις στατιστικές τεχνικές προβλέψεων και στα νευρωνικά δίκτυα, με αναλυτική περιγραφή των αρχιτεκτονικών τους.

Στο κεφάλαιο τέσσερα, γίνεται ο σχεδιασμός και η πειραματική αξιολόγηση των προτεινόμενων μοντέλων. Εκπαιδεύονται τα μοντέλα με τα διαθέσιμα δεδομένα εισόδου και στην συνέχεια παράγονται προβλέψεις με χρονικό ορίζοντα 24 ωρών για το διάστημα ενός μήνα. Τα αποτελέσματα συγκρίνονται με τα δεδομένα των πραγματικών προβλέψεων και εξάγονται τα ωριαία κανονικοποιημένα μέσα απόλυτα σφάλματα.

Τέλος, στο πέμπτο κεφάλαιο, εξάγονται συμπεράσματα σχετικά με τη χρήση νευρωνικών δικτύων για βραχυπρόθεσμες προβλέψεις φωτοβολταϊκών, την σύγκριση της απόδοσης τους με τις κλασικές στατιστικές τεχνικές και προτείνονται μελλοντικές επεκτάσεις στην παρούσα εργασία.


Κεφάλαιο 2

Φωτοβολταϊκά και σύνδεση στο δίκτυο


Σκοπός του παρόντος κεφαλαίου είναι η μελέτη και η ανάλυση της θεωρίας των φωτοβολταϊκών συστημάτων με έμφαση στη πρόβλεψη της παραγωγής τους. Αρχικά, θα πραγματοποιηθεί εισαγωγή στην ηλιακή ενέργεια και στις δυνατότητες αξιοποίησης της. Στη συνέχεια, θα αναλυθεί το φωτοβολταϊκό φαινόμενο, η λειτουργία του και θα εξεταστούν τα ηλεκτρικά του χαρακτηριστικά. Τέλος, θα εξεταστούν οι επιπτώσεις αλλά και οι προϋποθέσεις της σύνδεσης ενός φωτοβολταϊκού συστήματος στο δίκτυο και η σημασία της πρόβλεψης της παραγωγής των ΦΒ για την λειτουργία του δικτύου.

2.1 Εισαγωγή

Οι ανανεώσιμες πηγές ενέργειας (ΑΠΕ) ή ήπιες μορφές ενέργειας είναι μορφές εκμεταλλεύσιμης ενέργειας που προέρχονται από διάφορες φυσικές διαδικασίες, όπως ο άνεμος, η γεωθερμία, η κυκλοφορία του νερού και άλλες. Ο όρος «ήπιες» αναφέρεται σε δυο βασικά χαρακτηριστικά τους. Καταρχάς, για την εκμετάλλευσή τους δεν απαιτείται κάποια ενεργητική παρέμβαση, όπως εξόρυξη, άντληση ή καύση, όπως με τις μέχρι τώρα χρησιμοποιούμενες πηγές ενέργειας, αλλά απλώς η εκμετάλλευση της ήδη υπάρχουσας ροής ενέργειας στη φύση. Δεύτερον, πρόκειται για «καθαρές» μορφές ενέργειας, πολύ «φιλικές» στο περιβάλλον, που δεν αποδεσμεύουν υδρογονάνθρακες, διοξείδιο του άνθρακα ή τοξικά και ραδιενεργά απόβλητα, όπως οι υπόλοιπες πηγές ενέργειας που χρησιμοποιούνται σε μεγάλη κλίμακα. Έτσι θεωρούνται από πολλούς μία αφετηρία για την επίλυση των οικολογικών προβλημάτων που αντιμετωπίζει η Γη. Οι ΑΠΕ έχουν μελετηθεί ως λύση στο πρόβλημα της αναμενόμενης εξάντλησης των (μη ανανεώσιμων) αποθεμάτων ορυκτών καυσίμων. Τελευταία, από την Ευρωπαϊκή Ένωση, αλλά και από πολλά μεμονωμένα κράτη, υιοθετούνται νέες πολιτικές για τη χρήση ανανεώσιμων πηγών ενέργειας, που προάγουν τέτοιες εσωτερικές πολιτικές και για τα κράτη μέλη. Οι ΑΠΕ αποτελούν τη βάση του μοντέλου οικονομικής ανάπτυξης της πράσινης οικονομίας και κεντρικό σημείο εστίασης της σχολής των οικολογικών οικονομικών, η οποία έχει κάποια επιρροή στο οικολογικό κίνημα.



(α') Renewable Energy Sources



(β') Penetration of RES in Europe

Τα είδη των ανανεώσιμων πηγών ενέργειας απαριθμούνται στη συνέχεια.

1. Αιολική ενέργεια. Πρόκειται για τη κινητική ενέργεια που παράγεται από τη δύναμη του ανέμου και μετατρέπεται, μέσω ανεμογεννητριών, σε απολήψιμη μηχανική ενέργεια ή/και σε ηλεκτρική ενέργεια. Χρησιμοποιείται από πολύ παλιά για την άντληση νερού από πηγάδια καθώς και για μηχανικές εφαρμογές (π.χ. την άλεση στους ανεμόμυλους).
2. Ηλιακή ενέργεια. Χρησιμοποιείται τόσο για θερμικές εφαρμογές (ηλιακοί θερμοσίφωνες και φούρνοι) όσο και για την παραγωγή ηλεκτρισμού (φωτοβολταϊκά πάρκα), με την βοήθεια της πολιτικής προώθησης των Ανανεώσιμων Πηγών Ενέργειας από το ελληνικό κράτος και την Ευρωπαϊκή Ένωση.

3. Υδραυλική ενέργεια. Η ενέργεια των υδατοπτώσεων που αξιοποιούν τα μικρά υδροηλεκτρικά έργα (μέχρι 15 ΜΩ ηλεκτρικής ισχύος). Είναι η πιο διαδεδομένη μορφή ανανεώσιμης ενέργειας.
4. Βιομάζα. Το βιοαποικοδομήσιμο κλάσμα προϊόντων, αποβλήτων και καταλοίπων που προέρχονται είτε από τις γεωργικές δραστηριότητες, συμπεριλαμβανομένων φυτικών και ζωικών ουσιών, είτε από τις δασοκομικές και τις συναφείς βιομηχανικές δραστηριότητες, καθώς και το βιοαποικοδομήσιμο κλάσμα βιομηχανικών αποβλήτων και αστικών λυμάτων και απορριμμάτων.
5. Γεωθερμική ενέργεια. Προέρχεται από τη θερμότητα που παράγεται από τη ραδιενεργό αποσύνθεση των πετρωμάτων της γης. Είναι εκμεταλλεύσιμη εκεί όπου η θερμότητα αυτή ανεβαίνει με φυσικό τρόπο στην επιφάνεια, π.χ. στους θερμοπίδακες ή στις πηγές ζεστού νερού. Μπορεί να χρησιμοποιηθεί είτε απευθείας για θερμικές εφαρμογές, είτε για την παραγωγή ηλεκτρισμού. Η Ισλανδία καλύπτει το 80-90% των ενεργειακών της αναγκών, όσον αφορά τη θέρμανση, και το 20%, όσον αφορά τον ηλεκτρισμό, με γεωθερμική ενέργεια. Η επιστημονική κοινότητα ταξινομεί συνήθως τη γεωθερμία στις ΑΠΕ. Το υπόγειο νερό ή ο ατμός που χρησιμοποιούνται για την παραγωγή ηλεκτρικής ενέργειας ή για την κάλυψη θερμικών αναγκών (άμεσες χρήσεις γεωθερμίας), με την κατάλληλη διαχείριση, δεν θα ελαττωθούν, επειδή η κατείδυση των επιφανειακών υδάτων θα συνεχίσει να επανατροφοδοτεί τους γεωθερμικούς ταμειυτήρες και δε χρειάζονται μεγάλοι γεωλογικοί χρόνοι (περίοδοι) για αναγέννηση. Επειδή οι δεξαμενές γεωθερμίας είναι τεράστιες σε μέγεθος συγκριτικά με τις ανάγκες του ανθρώπου, η γεωθερμική ενέργεια είναι πρακτικά ανανεώσιμη.
6. Ενέργεια από τη θάλασσα:
 - (α') Ενέργεια από παλίρροιες. Εκμεταλλεύεται τη βαρύτητα του Ήλιου και της Σελήνης, που προκαλεί ανύψωση της στάθμης του νερού. Το νερό αποθηκεύεται καθώς ανεβαίνει και για να ξανακατέβει αναγκάζεται να περάσει μέσα από μια τουρμπίνα, παράγοντας ηλεκτρισμό. Έχει εφαρμοστεί στην Αγγλία, τη Γαλλία, τη Ρωσία και αλλού.
 - (β') Ενέργεια από κύματα. Εκμεταλλεύεται την κινητική ενέργεια των κυμάτων της θάλασσας.
 - (γ') Ενέργεια από τους ωκεανούς. Εκμεταλλεύεται τη διαφορά θερμοκρασίας ανάμεσα στα στρώματα του ωκεανού, κάνοντας χρήση θερμικών κύκλων. Βρίσκεται στο στάδιο της έρευνας.
7. Ωσμωτική ενέργεια. Η ανάμιξη γλυκού και θαλασσινού νερού απελευθερώνει μεγάλες ποσότητες ενέργειας, όπως συμβαίνει όταν ένα ποτάμι εκβάλλει στον ωκεανό. Η ενέργεια αυτή ονομάζεται ωσμωτική ενέργεια (ή γαλάζια ενέργεια) και αναχτάται όταν το νερό του ποταμού και το θαλασσινό νερό είναι διαχωρισμένα από μια ημιδιαπερατή μεμβράνη και το γλυκό νερό περνάει μέσω αυτής.

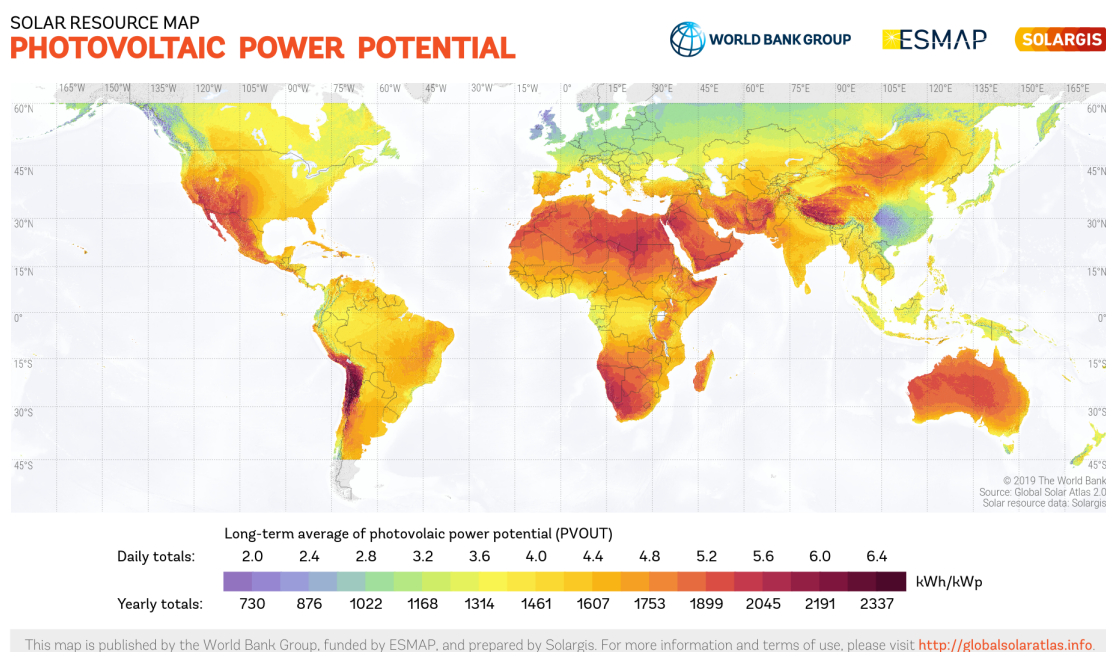
Τα πλεονεκτήματα της χρήσης ΑΠΕ για την παραγωγή ενέργειας είναι πολλά και δυναμικά όσο αυξάνεται η διείσδυση τους στο δίκτυο, ωστόσο μπορούν να αναφερθούν ενδεικτικά:

1. Είναι πρακτικά ανεξάντλητες πηγές ενέργειας (ήλιος, άνεμος, ποτάμια, οργανική ύλη, κ.α.) και συμβάλλουν στη μείωση της εξάρτησης από εξαντλήσιμους συμβατικούς ενεργειακούς πόρους, όπως είναι το πετρέλαιο, το φυσικό αέριο, ο άνθρακας, κλπ.
2. Είναι φιλικές προς το περιβάλλον και τον άνθρωπο, γι' αυτό και η αξιοποίησή τους είναι γενικά αποδεκτή από το ευρύ κοινό.
3. Αποτελούν (μαζί με την εξοικονόμηση ενέργειας) την κατ' εξοχήν περιβαλλοντικά φιλική λύση για τον περιορισμό των εκπομπών διοξειδίου του άνθρακα στην ατμόσφαιρα και την αντιμετώπιση του φαινομένου του θερμοκηπίου. Επιπλέον, υποκαθιστώντας τους σταθμούς παραγωγής ενέργειας από συμβατικές πηγές οδηγούν σε μείωση των εκπομπών και από άλλους ρυπαντές, όπως είναι π.χ. τα οξείδια του θείου που προκαλούν την όξινη βροχή, τα οξείδια του αζώτου που προκαλούν το φωτοχημικό νέφος, τα αιωρούμενα σωματίδια, κ.α.
4. Είναι εγχώριες πηγές ενέργειας και συνεισφέρουν στην ενίσχυση της ενεργειακής ανεξαρτησίας και της ασφάλειας του ενεργειακού εφοδιασμού σε εθνικό επίπεδο.
5. Είναι διάσπαρτες γεωγραφικά και συμβάλλουν στην αποκέντρωση του ενεργειακού συστήματος, δίνοντας τη δυνατότητα κάλυψης των ενεργειακών αναγκών σε τοπικό και περιφερειακό επίπεδο, ανακουφίζοντας έτσι τα συστήματα υποδομής (δίκτυα, δρόμοι, κλπ.) και μειώνοντας τις απώλειες από τη μεταφορά ενέργειας.
6. Προσφέρουν τη δυνατότητα ορθολογικής αξιοποίησης των ενεργειακών πόρων, καλύπτοντας ένα ευρύ φάσμα ενεργειακών αναγκών των χρηστών (π.χ. ηλιακή ενέργεια για θερμότητα χαμηλών θερμοκρασιών, αιολική ενέργεια για ηλεκτροπαραγωγή, κ.α.).
7. Έχουν συνήθως χαμηλό λειτουργικό κόστος που δεν επηρεάζεται από τις διακυμάνσεις της διεθνούς οικονομίας και ειδικότερα των τιμών των συμβατικών καυσίμων.
8. Οι εγκαταστάσεις εκμετάλλευσης των ΑΠΕ σχεδιάζονται συνήθως για να καλύπτουν τις συγκεκριμένες ανάγκες των χρηστών, τόσο σε μικρή όσο και σε μεγάλη κλίμακα εφαρμογών, και έχουν μικρό σχετικά χρόνο κατασκευής, επιτρέποντας έτσι τη γρήγορη ανταπόκριση της προσφοράς προς τη ζήτηση ενέργειας.
9. Οι επενδύσεις των ΑΠΕ δημιουργούν σημαντικό αριθμό νέων θέσεων εργασίας, ιδιαίτερα σε τοπικό επίπεδο.
10. Μπορούν να αποτελέσουν σε πολλές περιπτώσεις πυρήνα για την αναζωογόνηση οικονομικά και κοινωνικά υποβαθμισμένων περιοχών και πόλο για την τοπική ανάπτυξη, με την προώθηση ανάλογων επενδύσεων (π.χ. θερμοκηπιακές καλλιέργειες με τη χρήση γεωθερμικής ενέργειας, τηλεθέρμανση οικισμών, μικρών πόλεων, κλπ. με ατμό/ζεστό

νερό που προέρχεται από την ενεργειακή αξιοποίηση γεωργικής και δασικής βιομάζας, κ.α.).

2.2 Ηλιακή ενέργεια

Ηλιακή ενέργεια χαρακτηρίζεται το σύνολο των διαφόρων μορφών ενέργειας που προέρχονται από τον Ήλιο. Τέτοιες είναι το φως ή φωτεινή ενέργεια, η θερμότητα καθώς και διάφορες ακτινοβολίες ή ενέργεια ακτινοβολίας. Η ηλιακή ενέργεια στο σύνολό της είναι πρακτικά ανεξάντλητη, αφού προέρχεται από τον ήλιο, και ως εκ τούτου δεν υπάρχουν περιορισμοί χώρου και χρόνου για την εκμετάλλευσή της. Όταν η ηλιακή ακτινοβολία φτάνει στη Γη, κατανέμεται ανομοιόμορφα στις διάφορες περιοχές. Οι περιοχές κοντά στον Ισημερινό λαμβάνουν περισσότερη ακτινοβολία από τις υπόλοιπες. Η ηλιακή ακτινοβολία διαφέρει σημαντικά ανάλογα με τις εποχές και εξαρτάται από την ώρα της ημέρας, το κλίμα (τα σύννεφα σχεδιάζουν σε σημαντικό βαθμό τις ακτίνες του ήλιου) και την ατμοσφαιρική ρύπανση. Όλοι οι παραπάνω παράγοντες επηρεάζουν αποφασιστικά το ποσό της ηλιακής ενέργειας που διατίθεται και προσπίπτει στα φωτοβολταϊκά συστήματα. Όταν η ηλιακή ακτινοβολία (kW/m^2) αθροίζεται στη διάρκεια ενός έτους, προκύπτει η ετήσια ηλιακή ενέργεια (συνήθως σε kWh/m^2). Η τιμή αυτή διαφέρει σημαντικά [11] ανάλογα με την τοποθεσία. Η χώρα μας συγκαταλέγεται μεταξύ των χωρών υψηλής ακτινοβολίας.



Σχήμα 2.2: Annual Worldwide Solar Irradiance

Αυτό αποτελεί συγκριτικό πλεονέκτημα, ιδιαίτερα σε σχέση με τις χώρες του ευρωπαϊκού βορρά, στην εφαρμογή των φωτοβολταϊκών συστημάτων για την παραγωγή ηλεκτρικής ενέργειας.


2.2.1 Τεχνολογίες ΦΒ

Όσον αφορά την εκμετάλλευση της ηλιακής ενέργειας, θα μπορούσαμε να πούμε ότι χωρίζεται σε τρεις κατηγορίες εφαρμογών: τα παθητικά ηλιακά συστήματα, τα ενεργητικά ηλιακά συστήματα ή Ηλιοθερμικά συστήματα, και τα φωτοβολταϊκά συστήματα. Τα παθητικά και τα ενεργητικά ηλιακά συστήματα εκμεταλλεύονται τη θερμότητα που εκπέμπεται μέσω της ηλιακής ακτινοβολίας, ενώ τα φωτοβολταϊκά συστήματα στηρίζονται στη μετατροπή της ηλιακής ακτινοβολίας σε ηλεκτρικό ρεύμα μέσω του φωτοβολταϊκού φαινομένου.

Τα φωτοβολταϊκά συστήματα διαδραματίζουν πρωταγωνιστικό ρόλο στο αυξανόμενο ενδιαφέρον για τις ΑΠΕ, με πλεονεκτήματα που τα καθιστούν ιδιαίτερα ελκυστικά στη νέα απελευθερωμένη αγορά ηλεκτρικής ενέργειας και ειδικότερα στα πλαίσια της “πράσινης” ανάπτυξης που προωθείται παγκοσμίως.

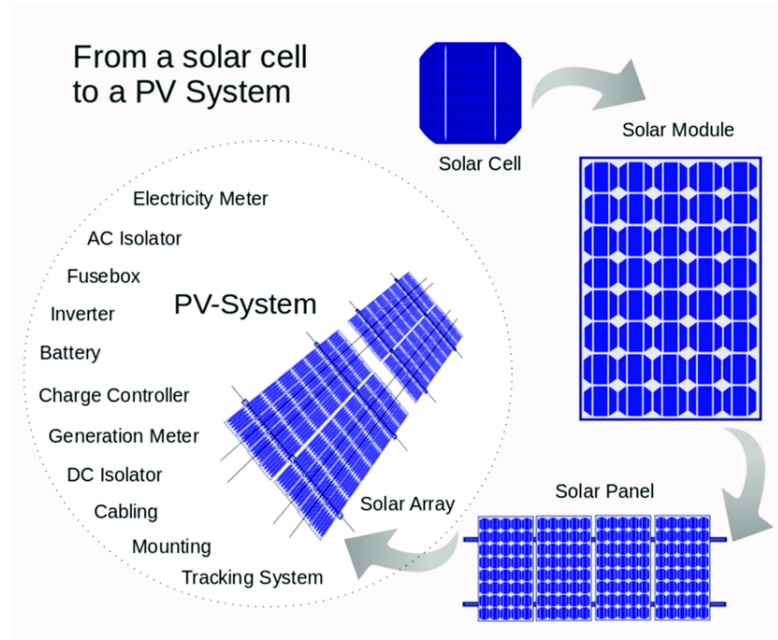
Το φωτοβολταϊκό φαινόμενο

Το φωτοβολταϊκό φαινόμενο, αποτελεί τη βασική φυσική διαδικασία μέσω της οποίας ένα φωτοβολταϊκό στοιχείο μετατρέπει την ηλιακή ακτινοβολία σε ηλεκτρική. Ημιαγωγικά υλικά όπως το πυρίτιο, χρησιμοποιούνται για το σκοπό αυτό. Όταν το φως προσπίπτει στην επιφάνεια ενός υλικού, τότε ένα μέρος αυτού ανακλάται, ένα άλλο τη διαπερνά, ενώ το υπόλοιπο απορροφάται από το υλικό. Η απορρόφηση του φωτός, έχει ως αποτέλεσμα τη μετατροπή του σε άλλη μορφή ενέργειας, η οποία συνήθως είναι θερμότητα. Παρ’ όλα αυτά, υπάρχουν κάποια υλικά τα οποία έχουν την ιδιότητα να μετατρέπουν την ενέργεια των φωτονίων που προσπίπτουν στην επιφάνειά τους, σε ηλεκτρική ενέργεια. Αυτά τα υλικά είναι οι ημιαγωγοί και σε αυτά οφείλεται σε μεγάλο βαθμό η τεχνολογική πρόοδος του τομέα της ηλεκτρονικής και του τομέα της πληροφορικής και των τηλεπικοινωνιών. Η ηλιακή ακτινοβολία αποτελείται από φωτόνια, δηλαδή “πακέτα” ηλιακής ενέργειας. Τα φωτόνια περιλαμβάνουν διαφορετικά ποσά ενέργειας, που αντιστοιχούν στα διάφορα μήκη κύματος του ηλιακού φάσματος. Η τεχνολογία, μας έδωσε τη δυνατότητα της άμεσης μετατροπής της ηλιακής ακτινοβολίας σε ηλεκτρικό ρεύμα. Τα φωτοβολταϊκά κύτταρα αποτελούν διόδους ημιαγωγικών ενώσεων τύπου π-ν με τη μορφή επίπεδης πλάκας. Κάθε φωτόνιο της προσπίπτουσας ηλιακής ακτινοβολίας με ενέργεια ίση ή μεγαλύτερη από το ενεργειακό διάκενο του ημιαγωγού, μπορεί να απορροφηθεί σε ένα χημικό δεσμό και να ελευθερώσει ένα ηλεκτρόνιο. Όσο διαρκεί η πρόσπτωση της ακτινοβολίας, δημιουργείται περίσσεια φορέων, δηλαδή περίσσεια ελεύθερων ηλεκτρονίων και οπών. Οι φορείς αυτοί, κυκλοφορούν στο στερεό και αν δεν επανασυνδεθούν με φορείς αντίθετου προσήμου, δέχονται την επίδραση του ηλεκτροστατικού πεδίου της ένωσης π-ν. Έτσι, τα ελεύθερα ηλεκτρόνια κατευθύνονται προς το τμήμα τύπου-ν και οι οπές προς το τμήμα τύπου π, με αποτέλεσμα να δημιουργείται διαφορά δυναμικού ανάμεσα στους ακροδέκτες των δύο τμημάτων της διόδου.



Σχήμα 2.3: Photovoltaic Effect

Αν στους ακροδέκτες συνδεθεί κατάλληλο ηλεκτρικό φορτίο, παρατηρείται ροή ηλεκτρικού ρεύματος από τη φωτοβολταϊκή διάταξη προς το φορτίο. Τελικά, η όλη διάταξη αποτελεί μία πηγή ηλεκτρικού ρεύματος, που διατηρείται για όσο χρονικό διάστημα διαρκεί η πρόσπτωση της ηλιακής ακτινοβολίας στην επιφάνεια του κυττάρου. Η ύπαρξη της διαφοράς δυναμικού ανάμεσα στους δύο ακροδέκτες της παραπάνω διάταξης, η οποία αντιστοιχεί σε ορθή πόλωση διόδου, ονομάζεται φωτοβολταϊκό φαινόμενο [12],[13]. Ανάλογα με και με το υλικό κατασκευής ή την ένταση της ηλιακής ακτινοβολίας που δέχεται, ένα ηλιακό στοιχείο μπορεί να δώσει συνεχή τάση μέχρι 0,5-1,0 V και πυκνότητα ρεύματος μέχρι 20-40 mA ανά cm^2 της επιφάνειάς του. Η συνήθης ισχύς ενός κυττάρου είναι λίγο μικρότερη από 3 Watt, συνεπώς για να έχουμε μία χρήσιμη ποσότητα ισχύος, πρέπει να καταφύγουμε σε εν παραλλήλω και εν σειρά συνδεσμολογίες των ΦΒ στοιχείων.




Σχήμα 2.4: From a solar cell to a PV System


Το ΦΒ πλαίσιο (module), αποτελείται από έναν αριθμό προκαλωδιωμένων ηλιακών κελιών σε σειρά, πακεταρισμένων σε ανθεκτικά περιβλήματα. Ένα τυπικό πλαίσιο έχει 36 κελιά σε σειρά, και συχνά ονομάζεται πλαίσιο των 12 V, με τυπικές τιμές ισχύος εξόδου 10-250 Wp.

Περιβαλλοντικοί παράγοντες που επιδρούν στην λειτουργία των ΦΒ

Η λειτουργία ενός φωτοβολταϊκού κυττάρου εξαρτάται από τη θερμοκρασία του και την ένταση της ηλιακής ακτινοβολίας. Στο σχήμα 2.9 παρουσιάζεται η εξάρτηση της τάσης ανοιχτού κυκλώματος και του ρεύματος βραχυκύκλωσης από τις μεταβολές των δύο παραπάνω μεγεθών. Πιο συγκεκριμένα, στο σχήμα 2.5 (α) φαίνεται ότι η τάση ανοιχτού κυκλώματος αυξάνει λογαριθμικά με την ένταση της ηλιακής ακτινοβολίας, ενώ η τάση βραχυκύκλωσης γραμμικά. Στο σχήμα 2.5 (β) παρατηρούμε ότι η αύξηση της θερμοκρασίας έχει ως κύριο αποτέλεσμα τη γραμμική μείωση της τάσεως ανοιχτού κυκλώματος, ενώ το ρεύμα βραχυκύκλωσης αυξάνεται πολύ λίγο. Η φορά των βελών στα παραπάνω σχήματα υποδεικνύει την αύξηση της ακτινοβολίας και της θερμοκρασίας αντίστοιχα. [12]



(α') PV Output VS Solar Irradiance




(β') PV Output VS Temperature

Συνεπώς παρατηρούμε ότι με την αύξηση της ακτινοβολίας αυξάνεται η παραγόμενη ενέργεια, ενώ αντίθετα η αύξηση της θερμοκρασίας των πλαισίων επηρεάζει αρνητικά την παραγωγή.

2.2.2 Η κατάσταση στα Φωτοβολταϊκά σήμερα

Τα πρώτα φωτοβολταϊκά στοιχεία παρήχθησαν στα τέλη της δεκαετίας του 50. Κατά την δεκαετία του 60 χρησιμοποιήθηκαν βασικά για την παραγωγή ενέργειας σε δορυφόρους. Αργότερα στα μέσα του 70 βελτιώσεις στον τρόπο παραγωγής τους, στην απόδοση και στην ποιότητα τους, οδήγησαν στην πτώση του κόστους τους με αποτέλεσμα να βρουν εφαρμογή σε συστήματα χαμηλής ισχύος κυρίως στην φόρτιση μπαταριών στην ναυσιπλοΐα και σε τηλεπικοινωνιακά συστήματα. Στη δεκαετία του 80 έγιναν πηγή ενέργειας για διάφορες ηλεκτρικές συσκευές όπως είναι οι υπολογιστές τσέπης, ρολόγια, ραδιόφωνα κ.τ.λ. Μετά την ενεργειακή κρίση του 70, έγιναν αξιοσημείωτες προσπάθειες για την παραγωγή φωτοβολταϊκών για οικιακή και εμπορική χρήση και για τους δύο τύπους συστημάτων τα απομονωμένα και τα διασυνδεδεμένα με το δίκτυο. Σήμερα, η φωτοβολταϊκή τεχνολογία εμφανίζει ραγδαία ανάπτυξη διεθνώς.


FIGURE 2 RENEWABLE POWER GENERATION AND CAPACITY AS A SHARE OF GLOBAL POWER, 2007-2017



Σχήμα 2.6: Percentage of RES to Total Energy Generation

Η συνολική εγκατεστημένη ισχύς φωτοβολταϊκών, σε παγκόσμιο επίπεδο αυξήθηκε κατά 23% σε 633,7 GW έως το τέλος του 2019, από 516,8 GW το 2018, όπως φαίνεται στο παρακάτω σχήμα. Αυτό σημαίνει ότι συνολικά, η ηλιακή ενέργεια έχει αυξηθεί σχεδόν 400 φορές από τις αρχές του αιώνα. Κατά τα τελευταία 10 χρόνια, η συνολική εγκατεστημένη φωτοβολταϊκή ισχύς αυξήθηκε κατά περισσότερο από 1.500% - από 41,4 GW το 2010.


FIGURE 10 TOTAL SOLAR PV INSTALLED CAPACITY 2000-2019



Σχήμα 2.7: Total solar PV installed capacity 2000-2019

Δραματικά βραδύτερη ανάπτυξη στην κορυφαία αγορά της Ασίας, την Κίνα, και μια κάπως μικρότερη αύξηση στο Νο. 2 της περιοχής, Ινδία, έχουν σταματήσει την περαιτέρω άνοδο στη Περιοχή Ασίας-Ειρηνικού. Ενώ η Ασία διατηρεί την ηγετική θέση για την εγκατεστημένη ισχύ ηλιακής ενέργειας το 2019, αντιπροσωπεύοντας το 58% της παγκόσμιας εγκατεστημένης χωρητικότητας, αυτό είναι ακριβώς το ίδιο ποσοστό με το προηγούμενο έτος. Προσθήκες 67,1 GW το 2019 είχαν ως αποτέλεσμα 368,3 GW συνολικής εγκατεστημένης χωρητικότητας.

FIGURE 11 TOTAL SOLAR PV INSTALLED CAPACITY SHARES 2012-2019



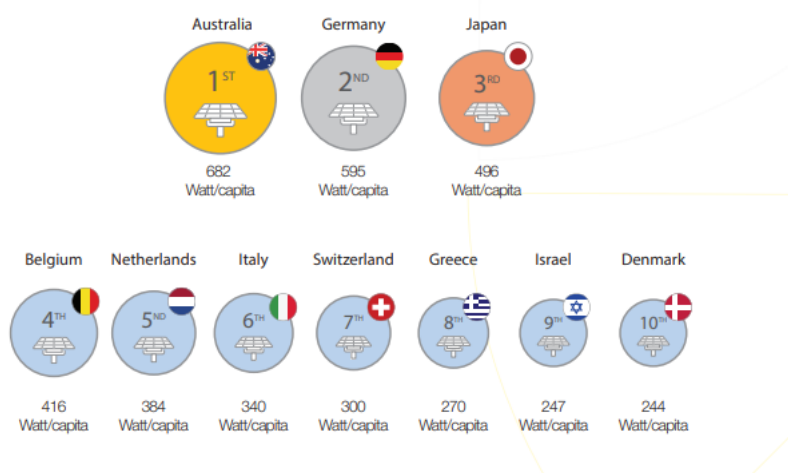
Σχήμα 2.8: Total solar PV installed capacity shares 2012-2019

Το έτος ισχυρής ανάπτυξης της Ευρώπης, από την άλλη πλευρά, δεν είχε αντίκρουσμα σε μερίδια αγοράς - η ήπειρος τελικά σταμάτησε αρκετές από τις ετήσιες απώλειες στην αγορά,

αλλά οι μετοχές του 2019 παρέμειναν στο επίπεδο του προηγούμενου έτους, στο 24%. Με προσθήκες 22,9 GW, η Ευρώπη διατήρησε τη δεύτερη θέση της, με την αθροιστική ΦΒ ισχύος να ανέρχεται σε 149,1 GW. Η Αμερική ήταν και πάλι η τρίτη μεγαλύτερη παραγωγός ηλιακής ενέργειας στον κόσμο για το 2019 - με συνολική εγκατεστημένη ισχύ 99,3 GW και μερίδιο 16%. Η ισχυρή δραστηριότητα στη Μέση Ανατολή και την Αφρική (ΜΕΑ) είχε μικρό αντίκτυπο στην ανάπτυξη της, καθώς με συνολική εγκατεστημένη ισχύ στα 17,0 GW, το μερίδιο της παγκόσμιας αγοράς αυξήθηκε σε 2,7% το 2019, από 2,0% το προηγούμενο έτος.

Σε ότι αφορά τα ελληνικά δεδομένα, μια αξιοσημείωτη παρατήρηση αποτελεί η υψηλή θέση της χώρας μας στην ποσοστιαία κατάταξη που αφορά εγκατεστημένη ισχύ ανά κάτοικο.

FIGURE 13 TOP 10 COUNTRIES SOLAR CAPACITY PER CAPITA 2019



Σχήμα 2.9: Solar capacity per capita

2.3 Σύνδεση Φωτοβολταϊκών στο δίκτυο

Τα σύγχρονα συστήματα διανομής ενέργειας είναι σχεδιασμένα με τέτοιο τρόπο ώστε να αποδέχονται την συνολική ισχύ που χρειάζονται στους μετασχηματιστές (Μ/Σ) και να τη διανέμουν στους καταναλωτές. Η ροή ισχύος λοιπόν τόσο της ενεργού όσο και της αέργου ισχύος ήταν πάντα από τα υψηλότερα στα χαμηλότερα επίπεδα τάσης (“συγκεντρωμένη” παραγωγή). Σήμερα με τη σημαντική διείσδυση των ΑΠΕ στα δίκτυα διανομής (δισπαρμένη παραγωγή) η ροή ισχύος μπορεί να αναστραφεί. Η αλλαγή στη ροή της ενεργού και της αέργου ισχύος που προκαλείται από τη δισπαρμένη παραγωγή, έχει σημαντικές τεχνικές αλλά και οικονομικές επιπτώσεις στα συστήματα ηλεκτρικής ενέργειας. Μέχρι σήμερα εξετάζονται κυρίως τα τεχνικά ζητήματα της σύνδεσης και της λειτουργίας της δισπαρμένης παραγωγής στα δίκτυα διανομής, ενώ οι περισσότερες χώρες έχουν αναπτύξει κριτήρια και πρακτικές για να αντιμετωπίζουν τέτοιες περιπτώσεις. Γενικά, είναι σημαντικό να βεβαιώνεται ότι η δισπαρμένη παραγωγή δεν επηρεάζει την ποιότητα της ισχύος που παρέχεται στους καταναλωτές, θεωρώντας τις γεννήτριες σαν “αρνητικά” φορτία. Όσον αφορά τις οικονομικές επιπτώσεις τώρα αρχίζουν να μελετώνται και να γίνονται πιο εμφανής σε 54 εταιρίες παροχής ηλεκτρικής ενέργειας κυρίως σε απελευθερωμένες αγορές, όπου και υπάρχει διαχωρισμός ανάμεσα στην παραγωγή και την διανομή ηλεκτρικής ενέργειας.

Αργές μεταβολές τάσης

Αν μία φ/β γεννήτρια συνδεθεί στο άκρο μιας γραμμής, τότε υπάρχει περίπτωση να αλλάξει η ροή ισχύος στο κύκλωμα, οπότε να αλλάξουν και οι τάσεις στους κόμβους. Καθώς στα φωτοβολταϊκά η παραγωγή ενέργειας σχετίζεται άμεσα με τις υπάρχουσες κλιματικές συνθήκες και μεταβάλλεται ανάλογα με αυτές, μπορεί να προκληθεί έντονη διακύμανση της τάσης στα σημεία σύνδεσης. Η χειρότερη δυνατή περίπτωση εμφανίζεται όταν το φορτίο βρίσκεται στην ελάχιστη τιμή του και η παραγωγή της γεννήτριας είναι στην μέγιστη δυνατή. Στην περίπτωση αυτή υπάρχει το ενδεχόμενο να ανυψωθεί η τάση πάνω από τα επιθυμητά επίπεδα. Με αυτό τον τρόπο προκαλούνται αργές μεταβολές της τάσης, οι οποίες είναι μεταβολές της τάσης που αφορούν την μόνιμη κατάσταση, οφείλονται σε αντίστοιχες διακυμάνσεις του φορτίου ή της παραγωγής και εκφράζονται μέσα από τιμές δεκαλέπτων.

Αύξηση της ισχύος ή στάθμης βραχυκύκλωσης

Η ισχύς ή στάθμη βραχυκύκλωσης είναι μία από τις πιο σημαντικές παραμέτρους των δικτύων διανομής και σχετίζεται άμεσα με την επιλογή του εξοπλισμού και τις κατασκευές του δικτύου. Μέσω της στάθμης βραχυκύκλωσης εκφράζεται η αντοχή σε ρεύματα βραχυκύκλωσης και δεν πρέπει σε καμία περίπτωση να υπερβαίνεται το όριο της (για παράδειγμα η ισχύς βραχυκύκλωσης $S_k=250\text{MVA}$ για το δίκτυο Μέσης Τάσης (ΜΤ) των 20 kV). Ουσιαστικά το μέγεθος αυτό φανερώνει την σθεναρότητα και την ακαμψία του δικτύου. Όσο μικρότερη λοιπόν είναι η στάθμη βραχυκύκλωσης τόσο πιο ευαίσθητο είναι το δίκτυο σε μεταβολές της τάσης, καθώς είναι αντιστρόφως ανάλογη με την ισοδύναμη αντίσταση του δικτύου στον αντίστοιχο ζυγό. Η δισπαρμένη παραγωγή (ΔΠ) γενικώς συνεισφέρει στα βραχυκυκλώματα και συνεπώς στην αύξηση της ισχύος βραχυκύκλωσης. Ωστόσο, όσον αφορά τις φωτοβολταϊκές γεννήτριες, η συνεισφορά στα σφάλματα είναι περιορισμένη, καθώς τα ηλεκτρονικά ισχύος

μέσω των οποίων συνδέονται αυτές στο δίκτυο, αποτρέπουν την παροχή ρευμάτων κατά πολύ μεγαλύτερων των ονομαστικών τους. Στις αστικές περιοχές όπου η στάθμη βραχυκύκλωσης πλησιάζει τα όρια των διακοπών, η αύξηση της μπορεί να είναι ένα σημαντικό εμπόδιο στην περαιτέρω ανάπτυξη της ΔΠ.

Ευστάθεια συστήματος

Στόχος της διεσπαρμένης παραγωγής είναι συνήθως η παραγωγή ηλεκτρικής ενέργειας από ΑΠΕ, συνεπώς δεν ενδιαφέρει η μεταβατική ευστάθεια του συστήματος. Ωστόσο, στην περίπτωση σφάλματος όπου θα μειωθεί η τάση του δικτύου, και η ΦΒ γεννήτρια βγει εκτός λειτουργίας, το μόνο που θα χαθεί θα είναι μία βραχύχρονη περίοδος παραγωγής. Συνεπώς, όταν το σύστημα επιστρέψει στην ομαλή κατάσταση λειτουργίας η ΦΒ γεννήτρια θα επανασυνδεθεί αυτόματα. Αντίθετα, αν η ΦΒ γεννήτρια θεωρηθεί ως πάροχος υποστήριξης για το σύστημα, η μεταβατική ευστάθεια στην περίπτωση αυτή γίνεται αξιοσημείωτη. Για παράδειγμα, αν μια μεγάλη μονάδα παραγωγής βγει εκτός λειτουργίας, θα υπάρξει πρόβλημα υποσυχνότητας στο σύστημα. Εάν τώρα λόγω της υποσυχνότητας αποσυνδεθεί και η ΦΒ γεννήτρια το πρόβλημα θα γίνει εντονότερο. Για το λόγο αυτό τα τελευταία χρόνια σε κάποιες χώρες έχει αρχίσει να υπάρχει απαίτηση από τη ΔΠ να μην αποσυνδέεται αμέσως σε περίπτωση σφάλματος αλλά να μπορεί να συνεισφέρει στην αποκατάσταση του δικτύου. Αυτή η ικανότητα της ΦΒ γεννήτριας να μπορεί να παραμένει συνδεδεμένη σε περίπτωση σφάλματος και συνεπώς σε περίπτωση βύθισης της τάσης ονομάζεται Fault-Ride-Through (FRT). Η απαιτούμενη συμπεριφορά από τη ΔΠ εξαρτάται κυρίως από δύο παράγοντες, το μέγεθος της βύθισης της τάσης καθώς επίσης και από τη διάρκεια της.

Μέσα προστασίας συστήματος

Η αμφίδρομη ροή ισχύος που οφείλεται στη διεσπαρμένη παραγωγή μπορεί να έχει αρνητική επίδραση στη λειτουργία των μέσων προστασίας του συστήματος, προκαλώντας ενδεχομένως ένα εσφαλμένο άνοιγμα διακόπτη. Οι προστασίες των ΦΒ γεννητριών θα πρέπει να συνεργάζονται με τις προστασίες του δικτύου, ώστε τα σφάλματα να γίνονται άμεσα αντιληπτά και να αντιμετωπίζονται το συντομότερο δυνατό. Ένα ζήτημα μεγάλης σημασίας αποτελεί το φαινόμενο της απομονωμένης λειτουργίας (νησιδοποίησης). Πρόκειται για μία ανεπιθύμητη κατάσταση στην οποία ένα τμήμα του δικτύου λειτουργεί απομονωμένα από το υπόλοιπο δίκτυο, δηλαδή συνεχίζει να ηλεκτροδοτείται παρότι το υπόλοιπο δίκτυο είναι ανενεργό. Στην περίπτωση αυτή προκαλούνται διακυμάνσεις στην τάση και τη συχνότητα με την οποία τροφοδοτούνται οι καταναλωτές. Επίσης υπάρχει σοβαρός κίνδυνος ασφάλειας για το προσωπικό που εργάζεται σε κάποιο τμήμα του δικτύου όπου υπάρχει νησιδοποίηση, καθώς θεωρείται ότι το τμήμα αυτό είναι ανενεργό μαζί με το υπόλοιπο δίκτυο, ενώ στην πραγματικότητα τροφοδοτείται με τάση. Επομένως είναι ιδιαίτερα σημαντικό η εγκατάσταση ΔΠ να ανιχνεύει τη νησιδοποίηση και να αποσυνδέεται. Αυτό επιτυγχάνεται μέσω της κατάλληλης ρύθμισης των ηλεκτρονόμων που ανιχνεύουν την τάση και τη συχνότητα του δικτύου για τυχόν αντικανονικές συνθήκες λειτουργίας. Όσον αφορά, την προστασία των ΦΒ γεννητριών από εσωτερικά σφάλματα, το ρεύμα σφάλματος που ρέει από το δίκτυο διανομής χρησιμοποιείται για την εύρεση του σφάλματος, και οι συνηθισμένες τεχνικές προστασίας είναι επαρκείς, οπότε πρόκειται για αρκετά εύκολη υπόθεση. Η προστασία του δικτύου διανομής ενώ βρίσκεται σε σφάλμα από

το ρεύμα σφάλματος των γεννητριών είναι αρκετά πιο δύσκολη υπόθεση. Όπως προαναφέρθηκε, οι ΦΒ γεννήτριες συνεισφέρουν στο σφάλμα σχεδόν με τον ονομαστικό τους ρεύμα, οπότε οι προστασίες τους δεν είναι εύκολο να το αντιληφθούν και να αποσυνδέσουν τη γεννήτρια. Έτσι, είναι απαραίτητη η λειτουργία των προστασιών του δικτύου για την εκκαθάριση των σφαλμάτων και την απομόνωση της γεννήτριας.

Κεφάλαιο 3

Θεωρητικό υπόβαθρο

3.1 Εισαγωγή

Αναλύονται τα βασικά χαρακτηριστικά των χρονοσειρών που είναι αναγκαία για την κατανόηση του τρόπου εργασίας. Στη συνέχεια παρουσιάζονται περιληπτικά οι τεχνικές προβλέψεων που θα χρησιμοποιήσει η διπλωματική. Σε αυτές γίνεται διάκριση μεταξύ των στατιστικών μοντέλων και των νευρωνικών δικτύων. Για τα νευρωνικά δίκτυα γίνεται αναφορά και στην συγκεκριμένη αρχιτεκτονική του κάθε μοντέλου.


3.2 Τεχνικές Προβλέψεων

3.2.1 Χαρακτηριστικά χρονοσειρών

Η ανάλυση χρονοσειρών και η πρόβλεψη δεδομένων είναι ένα από τα πλέον χρήσιμα και διαδεδομένα εργαλεία προκειμένου να στηριχθεί η λήψη αποφάσεων από διοικητικά στελέχη, επιχειρήσεις, πολυεθνικές εταιρίες και κυβερνήσεις. Με τον όρο χρονοσειρά [7] (time series) εννοούμε μία σειρά από δεδομένα τα οποία συλλέγονται διαχρονικά και εκφράζουν την εξέλιξη μιας μεταβλητής κατά τη διάρκεια ίσων χρονικών στιγμών ή περιόδων. Πιο συγκεκριμένα, η χρονοσειρά αποτελείται από ένα σύνολο παρατηρήσεων μιας μεταβλητής της οποίας οι τιμές αναφέρονται με βάση κάποια χρονική περίοδο π.χ. μέρα, εβδομάδα, μήνας, τρίμηνο κ.α. Μαθηματικά η χρονοσειρά ορίζεται από ένα δείγμα τιμών Y_1, Y_2, \dots, Y_t της μεταβλητής Y για κάθε χρονική στιγμή t . Επομένως, το Y είναι μία συνάρτηση του t , και αυτό συμβολίζεται ως $Y = f(t)$ ενώ η γραφική παράσταση της εν λόγω συνάρτησης παρουσιάζει την εξέλιξη της μεταβλητής Y στο χρόνο.

Στασιμότητα

Η στασιμότητα (stationarity) είναι μία από τις σημαντικότερες έννοιες, όσον αφορά τις χρονοσειρές, διότι είναι απαραίτητη προϋπόθεση για τα περισσότερα εργαλεία ανάλυσης. Γενικά, θα λέγαμε ότι μία χρονοσειρά είναι στάσιμη, εφόσον τα δεδομένα της παραμένουν διαχρονικά σε ένα σταθερό μέσο επίπεδο, ενώ αντίθετα στην περίπτωση που τα χαρακτηριστικά της μεταβάλλονται διαχρονικά, τότε αυτή θεωρείται μη στάσιμη. Πιο συγκεκριμένα, μία χρονο-



Σχήμα 3.1: Example of a Stationary and a Non-Stationary Time Series


σειρά ορίζεται ως στάσιμη όταν η συνάρτηση κατανομής των μετρήσεων είναι ανεξάρτητη του χρόνου. Μία μη στάσιμη χρονοσειρά παρουσιάζει διακυμάνσεις των τιμών της με την πάροδο του χρόνου και μπορεί να αναλυθεί σε τέσσερις συνιστώσες, οι οποίες είναι η τάση, η κυκλική συνιστώσα, η εποχικότητα και τα κατάλοιπα.

Πιο συγκεκριμένα:

- Η **τάση** (Trend T_t) αντιπροσωπεύει τη γενική μακροχρόνια συμπεριφορά της χρονοσειράς, η οποία μπορεί να είναι είτε αυξητική είτε με τάση μείωσης. Επίσης, μπορεί να αποτελείται είτε από μία γραμμική διαδικασία είτε από μία μη γραμμική διαδικασία.
- Η **κυκλική διακύμανση** (Cycle C_t) αντιπροσωπεύει και αυτή τη μακροχρόνια συμπεριφορά της χρονοσειράς και αποτελείται από κυματοειδείς διακυμάνσεις οι οποίες

διαρκούν περισσότερο της μίας χρονικής περιόδου. Το εύρος και η διάρκεια των διακυμάνσεων αυτών δεν είναι σταθερή.

- Η **εποχικότητα** (Seasonal effect I_t) αντιπροσωπεύει τη βραχυχρόνια συμπεριφορά της χρονοσειράς και αποτελείται από περιοδικές ταλαντώσεις οι οποίες επαναλαμβάνονται με την ίδια περίοδο και σε επόμενα χρονικά διαστήματα. Οι τιμές της χρονοσειράς αλλάζουν συμπεριφορά σε διαστήματα μικρότερα του έτους π.χ. βδομάδα, μήνα.
- Τα **κατάλοιπα** (Residuals E_t) αντιπροσωπεύουν τις βραχυχρόνιες διακυμάνσεις των τιμών της χρονοσειράς και οφείλονται σε τυχαίους παράγοντες. Συχνά, τα κατάλοιπα περιέχουν χρήσιμες πληροφορίες για την υπό εξέταση χρονοσειρά.



Σχήμα 3.2: Trend, Cycle, Seasonality & Residuals of a Time Series

Αυτοσυσχέτιση Η εμφάνιση αυτοσυσχέτισης (autocorrelation) στις χρονοσειρές αναφέρεται συχνά ως γραμμική ή σειριακή αυτοσυσχέτιση (linear autocorrelation). Η αυτοσυσχέτιση ρ_s για κάποια υστέρηση s είναι ο συντελεστής συσχέτισης δύο στοιχείων της χρονοσειράς που απέχουν χρονικά s βήματα. Η συνάρτηση αυτοσυσχέτισης (ACF) μίας στοχαστικής διαδικασίας είναι η εξής:

$$\rho_k = \frac{\sum_{t=k+1}^n (Y_t - \mu)(Y_{t-k} - \mu)}{\sum_{t=1}^n (Y_t - \mu)^2} \quad (3.1)$$

Η σημασία της συνάρτησης αυτοσυσχέτισης είναι ιδιαίτερα σημαντική διότι δείχνει το βαθμό συσχέτισης μεταξύ των παρατηρήσεων, οι οποίες απέχουν κατά χρονικό διάστημα s μεταξύ τους. Επιπλέον η εν λόγω συνάρτηση αντιπροσωπεύει το βαθμό (ένταση) και το μήκος (χρονική διάρκεια) της μνήμης της στοχαστικής διαδικασίας. Η έννοια της αυτοσυσχέτισης έχει νόημα όταν η χρονοσειρά είναι στάσιμη. Αν επιχειρήσουμε να υπολογίσουμε τη συνάρτηση αυτοσυσχέτισης σε μία μη στάσιμη χρονοσειρά με τάσεις, τότε θα παρατηρήσουμε ότι υπάρχουν πολύ υψηλές τιμές και ότι φθίνει πολύ αργά. Αυτό αποδεικνύει ότι υπάρχουν ισχυρές

συσχετίσεις μεταξύ των κοντινών χρονικών σημείων, λόγω τάσης. Με τον ίδιο τρόπο, η αυτοσυσχέτιση μίας μη στάσιμης χρονοσειράς με έντονη περιοδικότητα θα εμφανίζει ταλαντώσεις με κορυφές σε υστερήσεις πολλαπλάσια της περιοδικότητας. Στις παραπάνω περιπτώσεις η πληροφορία για τις συσχετίσεις δεν περιέχεται σε κάποιες υστερήσεις αλλά ενδεχομένως να μας δοθούν από τη χρονοσειρά των υπολοίπων. Θεωρητικά, η αυτοσυσχέτιση της χρονοσειράς λευκού θορύβου είναι μηδενική για $s \neq 0$, πρακτικά όμως η αυτοσυσχέτιση υπολογίζεται από μία πεπερασμένη χρονοσειρά και άρα οι διακυμάνσεις της κινούνται γύρω από το μηδέν. Η υπόθεση ότι μία στάσιμη χρονοσειρά, απαλλαγμένη από τάσεις και περιοδικότητα, δεν περιέχει αυτοσυσχέτιση είναι πολύ σημαντική για την ανάλυση των χρονοσειρών. Η έλλειψη αυτοσυσχέτισης είναι μία σημαντική υπόθεση που πρέπει να αποδειχθεί για μία χρονοσειρά προκειμένου να προχωρήσει κάποιος στην ανάλυση της και στη δημιουργία μοντέλου με σκοπό την περαιτέρω ανάλυση ή τη διενέργεια προβλέψεων.

3.2.2 Ολοκληρωμένα Αυτοπαλινδρομικά Μοντέλα Κινητού Μέσου Όρου - ARIMA

Για την πρόβλεψη χρονοσειρών χρησιμοποιούνται ευρέως τα ολοκληρωμένα αυτοπαλινδρομικά μοντέλα κινητών μέσων όρων ARIMA (Auto Regressive Integrated Moving Average). Πρόκειται για στοχαστικά μοντέλα τα οποία μας βοηθάνε να περιγράψουμε το μηχανισμό εξέλιξης ενός μεγέθους ενδιαφέροντος και ως εκ τούτου να προβλέψουμε την τιμή του στο μέλλον. Όπως και άλλα στατιστικά μοντέλα πρόβλεψης χρονοσειρών, π.χ. αυτά της εκθετικής εξομάλυνσης, τα μοντέλα ARIMA παράγουν προβλέψεις βασισζόμενα αποκλειστικά στις ιστορικές παρατηρήσεις του υπό εξέταση μεγέθους. Αυτό αποτελεί από μόνο του σημαντικό πλεονέκτημα, ειδικά σε περιπτώσεις που δεν γνωρίζουμε τις εξωτερικές μεταβλητές που το επηρεάζουν ή δεν μπορούμε να τις αξιοποιήσουμε άμεσα (βλ. ντετερμινιστικά μοντέλα). Στην πραγματικότητα, το κάθε μοντέλο ARIMA εκφράζει ένα διαφορετικό μηχανισμό εξέλιξης και η επιλογή του καταλληλότερου για την προέκταση μιας χρονοσειράς γίνεται εξετάζοντας παράγοντες όπως η σχέση μεταξύ k διαδοχικών παρατηρήσεων (αυτοσυσχέτιση), η ύπαρξη τάσης, η ύπαρξη εποχιακότητας και το σφάλμα πρόβλεψης.

Στην γενική τους μορφή τα μοντέλα ARIMA αποτελούνται από τον τυχαίο παράγοντα (παράγοντας MA), τις τιμές που εμφανίστηκαν σε προηγούμενες περιόδους (παράγοντας AR και I), και άλλες στοχαστικές μεταβλητές. Πιο συγκεκριμένα, κάθε μοντέλο ARIMA μπορεί να εκφραστεί ως γραμμικός συνδυασμός των παραπάνω παραγόντων και στόχος μας είναι να ανακαλύψουμε εκείνον που παράγει τις καλύτερες προβλέψεις. Έτσι, αν το μοντέλο περιλαμβάνει αποκλειστικά παράγοντες αυτοπαλινδρόμησης αναφέρεται ως AR(p), αν περιλαμβάνει αποκλειστικά παράγοντες κινητών μέσων όρων ως MA(q), και αν περιλαμβάνει και τους δύο ως ARMA(p,q), όπου τα p και q δηλώνουν την τάξη του μοντέλου ανά παράγοντα. Ο παράγοντας I(d) αναφέρεται στη διαφύριση της χρονοσειράς πριν την εφαρμογή ενός μοντέλου ARMA(p,q) και έχει ως στόχο την αφαίρεση της τάσης από τα δεδομένα. Σε περίπτωση που η χρονοσειρά είναι εποχιακή, τα μοντέλα ARIMA μπορούν να επεκταθούν κατάλληλα προκειμένου να προσομοιώσουν και την εποχιακή συμπεριφορά των δεδομένων. Σε αυτή την

περίπτωση η έκφρασή τους έχει τη μορφή $ARIMA(p,d,q)(P,D,Q)$, όπου τα P , D & Q αναφέρονται αντίστοιχα στην τάξη των εποχιακών παραγόντων $ARIMA$. Στην πράξη βέβαια δεν μπορούμε να είμαστε ποτέ σίγουροι για το ποιος είναι ο βέλτιστος συνδυασμός παραγόντων ή καλύτερα για το αν καταφέραμε να αποκαλύψουμε πλήρως το μοτίβο της χρονοσειράς. Μπορούμε ωστόσο να δίνουμε μία ικανοποιητική προσέγγιση στο εν λόγω ερώτημα εντοπίζοντας ένα μοντέλο που πληροί συγκεκριμένες προϋποθέσεις και παραμετροποιώντας το κατάλληλα.

Η εφαρμογή των μοντέλων $ARMA$ προϋποθέτει επίσης ότι πληρούνται ορισμένες απαιτήσεις. Αρχικά, η χρονοσειρά μήκους n πρέπει να είναι διακριτή, δηλαδή οι παρατηρήσεις της Y_t να αναφέρονται σε ισαπέχουσες χρονικές στιγμές $Y_t, Y_{t+T}, \dots, Y_{t+kT}$, όπου T ακέραιος μεγαλύτερος του μηδέν. Η παραπάνω απαίτηση είναι απαραίτητη καθώς, δεδομένου ότι τα μοντέλα συσχετίζουν χρονικά τις παρατηρήσεις της χρονοσειράς, η μη χρονική συνέχειά τους αναιρεί οποιαδήποτε υπόθεση έχει γίνει για τις σχέσεις διασύνδεσής τους. Εκτός αυτού, η χρονοσειρά οφείλει να είναι στάσιμη. Σε περίπτωση που η χρονοσειρά δεν είναι στάσιμη, κάτι τέτοιο μπορεί να επιτευχθεί με χρήση μετασχηματισμών ή/και διαφορίσης, με εφαρμογή δηλαδή κάποιου ολοκληρωμένου εποχιακού ή μη εποχιακού μοντέλου $ARIMA$ αντί για $ARMA$. Τέλος, η εφαρμογή των μοντέλων $ARIMA$ προϋποθέτει την παραγωγή βραχυπρόθεσμων προβλέψεων, καθώς, η αξιοπιστία και η ακρίβεια πρόβλεψης ενός μοντέλου $ARIMA$ αναμένεται να μειώνεται σημαντικά καθώς αυξάνει ο ορίζοντας πρόβλεψης.

Θέλοντας λοιπόν να αυτοματοποιήσουμε τη διαδικασία επιλογής, είθισται να ακολουθούμε την παρακάτω διαδικασία η οποία περιλαμβάνει τρία στάδια: την Αναγνώριση, την Εκτίμηση και τη Διάγνωση.

- **Αναγνώριση:** Στο στάδιο της αναγνώρισης επιλέγονται ένα ή περισσότερα μοντέλα $ARIMA$ τα οποία θεωρούμε βάσει κάποιων ενδείξεων, όπως π.χ. οι γραφικές παραστάσεις της αυτοσυσχέτισης και της μερικής αυτοσυσχέτισης, ότι μπορούν να περιγράψουν ικανοποιητικά τη χρονοσειρά.
- **Εκτίμηση:** Στο στάδιο της εκτίμησης εντοπίζονται για κάθε ένα από τα μοντέλα που αναγνωρίστηκαν οι παράμετροί p , d , q , P , D και Q , και βάσει αυτών παραμετροποιούνται κατάλληλα. Η εν λόγω διαδικασία μπορεί να γίνει με αρκετούς τρόπους, ο πιο διαδεδομένος εκ των οποίων είναι ο υπολογισμός της προσδοκώμενης πιθανοφάνειας. Η προσδοκώμενη πιθανοφάνεια δείχνει επί της ουσίας κατά πόσο το μοντέλο με τις παραμέτρους που επιλέχθηκαν έχει τη δυνατότητα να αναπαράγει τις πραγματικές τιμές της χρονοσειράς. Οι παράμετροι υπολογίζονται λοιπόν με κριτήριο την μεγιστοποίηση της πιθανοφάνειας ή την ελαχιστοποίηση του λογάριθμου αυτής ως εξής : όπου L η

$$L = \prod_{t=1}^n (2\pi\sigma^2)^{-\frac{1}{2}} e^{-\frac{(Y_t - F_t)^2}{2\sigma^2}} \rightarrow$$

$$L = (2\pi)^{-\frac{n}{2}} (\sigma^2)^{-\frac{n}{2}} e^{-\frac{1}{2\sigma^2} \sum_{t=1}^n (Y_t - F_t)^2} \rightarrow$$

$$-2\log L = n \log(2\pi) + n \log(\sigma^2) + \frac{\sum_{t=1}^n e_t^2}{\sigma^2}$$

προσδοκώμενη πιθανοφάνεια ταύτισης του μοντέλου με τα αρχικά δεδομένα, F_t η προ-

βλεπόμενη από το μοντέλο τιμή την περίοδο t , n ο αριθμός των ιστορικών δεδομένων, e_t το σφάλμα πρόβλεψης και η διακύμανση των σφαλμάτων του μοντέλου. Σημειώνεται πως η παραπάνω σχέση ισχύει αποκλειστικά για μοντέλα ARMA, δηλαδή δεν λαμβάνει υπόψη της τυχόν διαφορίσεις. Το κριτήριο της πιθανοφάνειας λειτουργεί πρακτικά όπως η μέθοδος ελαχίστων τετραγώνων στην περίπτωση της απλής γραμμικής παλινδρόμησης για την επιλογή των παραμέτρων α και β , το οποίο και ελαχιστοποιεί το άθροισμα των τετραγώνων των υπολειπόμενων σφαλμάτων μέσω της απαίτησης: Μάλιστα, στην

$$\min \left(\sum_{t=1}^n e_t^2 \right), \text{ όπου } e_t = Y_t - F_t$$

περίπτωση της γραμμικής παλινδρόμησης το κριτήριο της πιθανοφάνειας δίνει τις ίδιες παραμέτρους με αυτό των ελαχίστων τετραγώνων. Για την επιλογή των παραμέτρων συχνά συνδυάζεται η τεχνική των ελαχίστων τετραγώνων με αυτή της προσδοκώμενης πιθανοφάνειας για ακόμα καλύτερα αποτελέσματα. Εναλλακτικά, μπορεί κανείς να χρησιμοποιήσει άλλα κλασικά κριτήρια ελαχιστοποίησης σφαλμάτων (ME, MAPE, sMAPE κ.ο.κ.) όπως συμβαίνει π.χ. κατά τον υπολογισμό των παραμέτρων των μοντέλων εκθετικής εξομάλυνσης. Η πιθανοφάνεια αποτελεί ωστόσο όπως αναφέρθηκε την πιο διαδεδομένη βιβλιογραφικά αντικειμενική συνάρτηση βελτιστοποίησης παραμέτρων.

- **Διάγνωση:** Στο στάδιο του διαγνωστικού ελέγχου εφαρμόζονται στατιστικοί έλεγχοι προκειμένου να εξακριβωθεί αν τα μοντέλα που αναγνωρίστηκαν και εκτιμήθηκαν είναι προβλεπτικά άρτια. Ο διαγνωστικός έλεγχος γίνεται μελετώντας κυρίως την κατανομή των σφαλμάτων πρόβλεψης e_t των υποψήφιων μοντέλων. Αν το μοντέλο είναι άρτιο, τότε τα σφάλματα που αυτό παράγει θα πρέπει να οφείλονται αποκλειστικά στην τυχαιότητα της χρονοσειράς και συνεπώς να μην συσχετίζονται μεταξύ τους χρονικά.

Παρουσιάζουμε τα βασικά μοντέλα που συνθέτουν ένα ARIMA:

– Autoregressive (AR) Model

Σε ένα autoregressive μοντέλο [9], η μεταβλητή εξόδου y_t εξαρτάται γραμμικά από τις προηγούμενες τιμές της (y_{t-1}, \dots, y_{t-p}) και κάποιου λευκού θορύβου e_t . Εξορισμού ένα υπόδειγμα y_t λέγεται ότι είναι autoregressive p -τάξης και συμβολίζεται με AR(p), εάν το y_t περιγράφεται από την εξής σχέση:

$$y_t = a_1 y_{t-1} + a_2 y_{t-2} + \dots + a_p y_{t-p} + e_t,$$

όπου:

e_t λευκός θόρυβος (white noise) με μηδενικό μέσο (zero mean) και σταθερή διακύμανση

$\alpha_1, \dots, \alpha_p$: οι παράμετροι του υποδείγματος

$$\sigma^2 = \frac{\sum (X - \mu)^2}{N} \quad (3.2)$$

όπου N το πλήθος των δεδομένων, X η εκάστοτε παρατήρηση και μ η μέση τιμή. Επιπρόσθετα, αν θεωρήσουμε ως τυχαία τα διαδοχικά στοιχεία μιας χρονοσειράς, τότε αυτή η χρονοσειρά λέγεται ότι αποτελείται από ανεξάρτητες τυχαίες μεταβλητές με ίδια κατανομή, για $x_t, x_{t+1}, x_{t+\tau}$ για $\tau > 1$. Μια τέτοια χρονολογική σειρά είναι εντελώς τυχαία και δεν περιέχει αυτόσυσχετίσεις, γραμμικές ή μη-γραμμικές. Μια τέτοια χρονολογική σειρά, ονομάζεται και λευκός θόρυβος (white noise).

– Moving Average (MA) Model

Υποθέτοντας ότι e_t είναι μια καθαρά τυχαία διαδικασία με μηδενικό μέσο και διακύμανση σ^2 τότε ένα υπόδειγμα y_t λέγεται κινητού μέσου τάξης q MA(q) εάν το y_t περιγράφεται από την εξής σχέση:

$$y_t = e_t + \beta_1 e_{t-1} + \beta_2 e_{t-2} + \dots + \beta_p e_{t-p}$$

όπου,

e_t : ο λευκός θόρυβος (white noise)

β_1, \dots, β_p : οι παράμετροι του υποδείγματος

Στη διαδικασία κινητού μέσου το υπόδειγμα y_t θεωρείται ότι δημιουργείται ως ένας σταθμικός μέσος (weighted average) τυχαίων σφαλμάτων των q προηγούμενων περιόδων.

– Auto Regressive Moving Average (ARMA) Model

Το μοντέλο ARMA είναι ένα από τα πιο ευρέως χρησιμοποιούμενα μοντέλα καθώς συνδυάζει τα πλεονεκτήματα των δυο προαναφερθέντων. Το συγκεκριμένο υπόδειγμα τάξης (p, q) ορίζεται ως εξής:

$$y_t = \alpha_1 y_{t-1} + \alpha_2 y_{t-2} + \dots + \alpha_p y_{t-p} + e_t + \beta_1 e_{t-1} + \beta_2 e_{t-2} + \dots + \beta_p e_{t-p}$$

Όπου,

e_t : ο λευκός θόρυβος (white noise)

$\alpha_1, \dots, \alpha_p$: οι παράμετροι του υποδείγματος για το AR

β_1, \dots, β_p : οι παράμετροι του υποδείγματος για το MA

– Auto Regressive Integrated Moving Average (ARIMA) Model

Τα μοντέλα που παρουσιάστηκαν προηγουμένως, AR – AM – ARMA, χρησιμοποιούνται σε στάσιμες διαδικασίες. Δηλαδή, ο μέσος και η διακύμανση δεν εξαρτώνται από τον χρόνο t αλλά παραμένουν σταθερά. Στην πράξη οι περισσότερες χρονοσειρές είναι μη-στάσιμες οπότε για να εφαρμοστεί ένα στάσιμο υπόδειγμα θα πρέπει να αφαιρεθούν τα μη-στάσιμα χαρακτηριστικά. Μια λύση σε αυτό παρουσιάστηκε με το μοντέλο ARIMA τάξεως (p, d, q) . Η ικανότητα του ARIMA μοντέλου να ανταπεξέρχεται σε μη-στάσιμες διαδικασίες, το καθιστά μια από τις πιο χρησιμοποιούμενες προσεγγίσεις στη πρόβλεψη χρονοσειρών. Υπερνικά αυτόν τον περιορισμό με τη χρήση διαφορών και αυτό επιτυγχάνεται αφαιρώντας την παρατήρηση της τρέχουσας περιόδου από την προηγούμενη. Η διαφόριση αυτή μπορεί να είναι διαφόρων τάξεων. Για παράδειγμα η πρώτη τάξης διαφόριση πραγματοποιείται αντικαθιστώντας το y_t με την εξής σχέση: $y'_t = y_t - y_{t-1}$ Η γενική μορφή του υποδείγματος ARIMA (p, d, q) περιγράφεται από τη παρακάτω σχέση:

$$y'_t = \alpha_1 y'_{t-1} + \alpha_2 y'_{t-2} + \dots + \alpha_p y'_{t-p} + e_t + \beta_1 e_{t-1} + \beta_2 e_{t-2} + \dots + \beta_p e_{t-p}$$

Όπου,

p: οι παράμετροι της αυτοπαλίνδρομης διαδικασίας

d: ο αριθμός των διαφορών προκειμένου η χρονοσειρά να γίνει στάσιμη

q: οι παράμετροι της διαδικασίας του κινητού μέσου

– Seasonal ARIMA (SARIMA) Model

Το μοντέλο SARIMA είναι μια επέκταση του ARIMA και χρησιμοποιείται για δεδομένα όπου παρουσιάζουν περιοδικότητα. Το SARIMA διατυπώνεται ως SARIMA(p,d,q)(P,D,Q)_m όπου *P* το πλήθος των εποχικών autoregressive όρων, *D* το πλήθος των εποχικών διαφορών και *Q* το πλήθος των εποχικών όρων κινητού μέσου, *m* ο αριθμός των χρονικών βημάτων στη χρονική περίοδο μια εποχής.

3.3 Τεχνητά Νευρωνικά Δίκτυα - Artificial Neural Networks

3.3.1 Εισαγωγή

Ο Arthur Samuel ορίζει ως μηχανική μάθηση «Το πεδίο μελέτης που δίνει στους υπολογιστές την ικανότητα να μαθαίνουν, χωρίς να έχουν ρητά προγραμματιστεί». [17]. Η μηχανική μάθηση επικεντρώνεται στην ανάπτυξη αλγορίθμων που μπορούν να έχουν πρόσβαση σε δεδομένα και να τα χρησιμοποιούν για να μάθουν και να βελτιώνονται. Η μηχανική μάθηση χωρίζεται σε τρεις κύριες κατηγορίες:

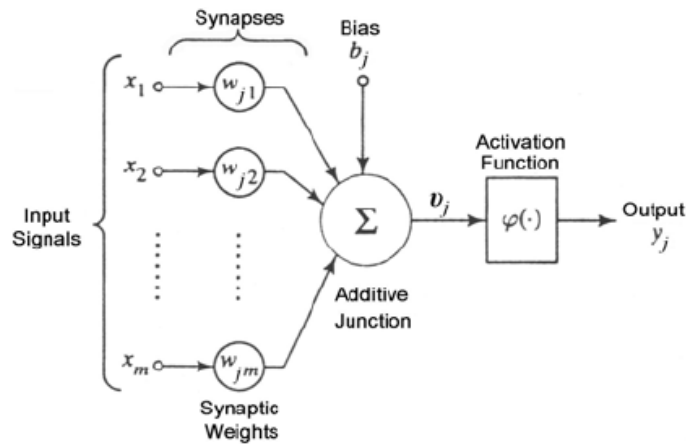
- **Επιβλεπόμενη Μάθηση (Supervised Learning)**. Ο αλγόριθμος εκπαιδεύεται σε ένα σύνολο παραδειγμάτων με ζευγάρια εισόδων και επιθυμητών εξόδων. Μερικοί από τους αλγορίθμους που χρησιμοποιούνται είναι: Μηχανές Διανυσμάτων Υποστήριξης (Support Vector Machines - SVM), Γραμμική Παλινδρόμηση (Linear Regression), Λογιστική Παλινδρόμηση (Logistic Regression), Δέντρα Αποφάσεων (Decision Trees), Νευρωνικά Δίκτυα (Neural Networks).
- **Μη Επιβλεπόμενη Μάθηση (Unsupervised Learning)**. Ο αλγόριθμος εκπαιδεύεται χρησιμοποιώντας πληροφορίες που δεν είναι ούτε ταξινομημένες αλλά ούτε επισημασμένες και επιτρέπουν το αλγόριθμο να ενεργεί χωρίς καθοδήγηση. Αλγόριθμοι για αυτή τη κατηγορία είναι: Συσταδοποίηση k-means, Ιεραρχική Συσταδοποίηση (Hierarchical Clustering), Ανάλυση Κύριων Συνιστωσών (Principle Component Analysis - PCA).
- **Ενισχυτική Μάθηση (Reinforcement Learning)**. Ο αλγόριθμος μαθαίνει πως να συμπεριφέρεται σε ένα περιβάλλον εκτελώντας ενέργειες και βλέποντας αποτελέσματα.

3.3.2 Νευρώνας - Perceptron

Η βασική μονάδα υπολογισμού σε ένα ANN είναι ο νευρώνας (Neuron), συχνά ονομαζόμενος και ως κόμβος. Το μοντέλο του Περσεπτρον, περιγράφηκε από τον Ροσενβλαττ [25]. Λαμβάνει εισόδους από άλλους κόμβους ή από μια εξωτερική πηγή και υπολογίζει μια έξοδο. Κάθε είσοδος πολλαπλασιάζεται με το αντίστοιχο βάρος (Weight) και υπολογίζεται το ολικό άθροισμα των γινομένων. Ο κόμβος εφαρμόζει μια συνάρτηση ενεργοποίησης σε αυτό το άθροισμα και υπολογίζεται η έξοδος του νευρώνα. Παρακάτω φαίνεται η αναπαράσταση ενός νευρώνα, καθώς και η εξίσωση της εξόδου.


$$k = f\left(\sum_{i=1}^n (w_i * x_i + b_i)\right) \quad (3.3)$$

Το παραπάνω δίκτυο παίρνει ως εισόδους τα $X_1, X_2 \dots X_n$ που έχουν για βάρη τα $W_1, W_2 \dots W_n$ αντίστοιχα. Επιπλέον υπάρχει ακόμα μια είσοδος 1 με βάρος b η οποία ονομάζεται πόλωση



Σχήμα 3.3: Artificial Neuron model and its parts

(bias). Η συνάρτηση f είναι μη γραμμική και ονομάζεται συνάρτηση ενεργοποίησης (activation function). Ο σκοπός της συνάρτησης ενεργοποίησης είναι να εισάγει μη γραμμικότητα στην έξοδο ενός νευρώνα. Αυτό είναι σημαντικό καθώς σχεδόν όλα τα πραγματικά δεδομένα είναι μη γραμμικά. Παραδείγματα τέτοιων συναρτήσεων είναι η σιγμοειδής συνάρτηση, η υπερβολική εφαπτομένη και η ReLU. Η ReLU αποδίδει συχνά καλύτερα από άλλες συναρτήσεις ενεργοποίησης για κρυφά επίπεδα. Ο βασικός λόγος της αυξημένης απόδοσης οφείλεται στο γεγονός ότι η ReLU είναι μια γραμμική συνάρτηση μη κορεσμού. Ο κορεσμός είναι το μεγαλύτερο πρόβλημα των δυο προηγούμενων σιγμοειδών συναρτήσεων. Σε αντίθεση λοιπόν με την logistic ή tanh, η ReLU δεν κορεάζεται στο -1 , 0 ή 1 . Στην πράξη η συχνότερα εμφανιζόμενη συνάρτηση ενεργοποίησης είναι η ReLU.



Σχήμα 3.4: Activation functions

Η χρήση [18] της ReLU έχει επικρατήσει διότι έχει χαρακτηριστικά που διευκολύνουν τη μάθηση μέσω μεθόδων γραδιεντ δεσεντ. Συγκεκριμένα, το γεγονός ότι στο ήμισυ του πεδίου ορισμού της, η τιμή της ReLU είναι μηδέν, διευκολύνει την ύπαρξη μεγαλύτερων τιμών κλίσης (gradient) της εξόδου ενός νευρώνα ως προς τα βάρη των συνάψεών του. Αντίθετα, οι σιγμοειδείς συναρτήσεις ενεργοποίησης παρουσιάζουν κορεσμό είτε σε μία θετική είτε σε μία αρνητική τιμή για το μεγαλύτερο μέρος του πεδίου ορισμού τους, γεγονός που οδηγεί σε πολύ μικρές τιμές κλίσης, καθιστώντας τη μάθηση αργή ή ακόμα και αδύνατη. Η συνάρτηση υπερβολικής εφαπτομένης πολλές φορές εμφανίζεται σαν συνάρτηση ενεργοποίησης σε νευρώνες αναδρομικών νευρωνικών μοντέλων όπως Long-Term Short-Term νευρώνες.

3.3.3 Multilayer Perceptron

Σύνδεση μεταξύ δύο νευρώνων υφίσταται, όταν η έξοδος του ενός χρησιμοποιείται σαν είσοδος του άλλου. Η σύνδεση πολλών νευρώνων μεταξύ τους μπορεί να δημιουργήσει μια συνάρτηση που να έχει τη δυνατότητα να λύση μη γραμμικά διαχωρίσιμα προβλήματα. Μια από τις συνηθισμένες κατασκευές είναι το Perceptron Πολλών Επιπέδων (Multiple Layer Perceptron, MLP). Στην τοπολογία αυτού του τύπου, οι νευρώνες διαμερίζονται σε επίπεδα (layers), και τα γειτονικά επίπεδα συνδέονται με συνδέσεις μονής κατεύθυνσης, χωρίς feedback. Ουσιαστικά, κάθε νευρώνας του i επιπέδου δέχεται σαν είσοδο τις εξόδους από κάθε νευρώνα του $i - 1$ επιπέδου. Η έξοδος του τροφοδοτείται στους νευρώνες του επόμενου επιπέδου, ή στην έξοδο του δικτύου αν ο νευρώνας ανήκει στο τελευταίο κρυφό επίπεδο.

Για ένα δίκτυο με m επίπεδα, για την έξοδο του i -οστού επιπέδου, όπου: $0 < i < m$,

ισχύει:


$$h^{(i)} = g^{(i)}(W^{(i)}h^{(i-1)} + b^{(i)}) = g^{(i)}(h^{(i-1)}; j^{(i)})$$

όπου: $h^{(i)}$ η έξοδος του επιπέδου, $g^{(i)}$ η συνάρτηση ενεργοποίησης των νευρώνων του επιπέδου, $W^{(i)}$ ο πίνακας των βαρών των συνδέσεων και $b^{(i)}$ το διάνυσμα της προκατάληψης.

Όμοια,

$$h^{(0)} = g^{(0)}(x; \theta^{(0)}) \text{ και } h^{(m-1)} = g^{(0)}(h^{(m-2)}; \theta^{(m-1)})$$

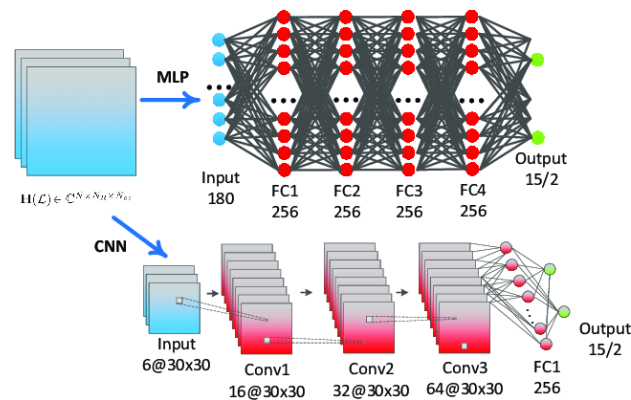
Τα επίπεδα $0 < i < m - 1$ ονομάζονται κρυφά επίπεδα (hidden layers) αφού η συμβολή τους στο δίκτυο δεν είναι εμφανής εκτός του μοντέλου. Τα επίπεδα $i = 0$ και $i = m - 1$ ονομάζονται επίπεδο εισόδου και εξόδου, αντίστοιχα. Γενικά, ένα δίκτυο ονομάζεται βαθύ (deep) αν $m > 3$, δηλαδή έχει τουλάχιστον ένα κρυφό επίπεδο.



Σχήμα 3.5: Three layer multilayer perceptron (MLP) neural network

3.3.4 Συνελικτικό Νευρωνικό Δίκτυο - Convolutional Neural Networks

Στη βαθιά μηχανική μάθηση, τα Συνελικτικά Νευρωνικά Δίκτυα (Convolutional Neural Networks, CNN) είναι μια κατηγορία νευρωνικών δικτύων που χρησιμοποιούνται συνήθως στον κλάδο της ανάλυσης εικόνας. Τα CNN είναι κανονικοποιημένες εκδόσεις των MLP. Τα MLP είναι πλήρως συνδεδεμένα δίκτυα. Αυτή η συνδεσιμότητα τα καθιστά επιρρεπή σε υπερεκπαίδευση. Τα CNNs αξιοποιούν τα ιεραρχικά μοτίβα που υπάρχουν στα δεδομένα και κατασκευάζουν περίπλοκα πρότυπα χρησιμοποιώντας μικρότερα και απλούστερα. Έτσι, τα CNNs είναι λιγότερο περίπλοκα δίκτυα. Αυτός ο τύπος δικτύου είναι εμπνευσμένος από τον οπτικό φλοιό (visual cortex) του εγκεφάλου.



Σχήμα 3.6: CNN & MLP Architecture

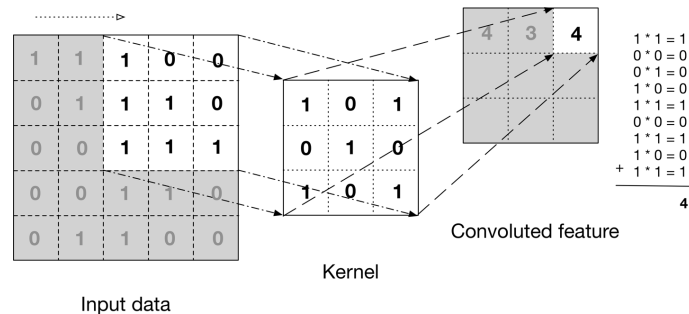
Η λέξη "συνελικτικό" στην ονομασία του δικτύου υποδεικνύει ότι αξιοποιεί τη μαθηματική πράξη της συνέλιξης. Η συνέλιξη είναι ένας ειδικός τύπος γραμμικού υπολογισμού. Τα CNN χρησιμοποιούν τη συνέλιξη στη θέση του πολλαπλασιασμού πινάκων, σε τουλάχιστον ένα από τα επίπεδά τους. Τα κρυφά επίπεδα ενός CNN, συνήθως, αποτελούνται από μια σειρά από συνελικτικά επίπεδα (convolutional layers) που πραγματοποιούν συνέλιξεις. Συνήθως, η

συνάρτηση ενεργοποίησης αυτών των επιπέδων είναι ένα ReLu layer που ακολουθείται από επιπλέον επίπεδα, που ονομάζονται επίπεδα υπερδειγματοληψίας (pooling layers).

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

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

Τα συνελικτικά επίπεδα διασχίζουν την είσοδο σε μέρη και περνάνε το αποτέλεσμα τους στο επόμενο επίπεδο. Αυτή η λειτουργία είναι παρόμοια με τον τρόπο που ανταποκρίνονται οι νευρώνες στον οπτικό φλοιό [19] για ένα συγκεκριμένο ερέθισμα. Κάθε συνελικτικός νευρώνας επεξεργάζεται δεδομένα που βρίσκονται αποκλειστικά στο δεκτικό του πεδίο (receptive field). Αν και για τις ίδιες λειτουργίες θα μπορούσε να χρησιμοποιηθεί ένα fully connected MLP, δεν είναι πρακτικό να χρησιμοποιηθεί αυτή η αρχιτεκτονική για την επεξεργασία εικόνων. Θα έπρεπε να χρησιμοποιηθεί μεγάλο πλήθος νευρώνων, ακόμα και σε αρχιτεκτονικές λίγων επιπέδων, εξαιτίας του μεγάλου μεγέθους της εισόδου.




Σχήμα 3.7: Convolutional Layer of a CNN

Για παράδειγμα, ένα MLP, για μια μικρή εικόνα διαστάσεων 100×100 , έχει 10000 παραμέτρους για κάθε νευρώνα του δευτέρου επιπέδου. Η συνέλιξη δίνει λύση σε αυτό το πρόβλημα, αφού μειώνει τον αριθμό των εκπαιδευσιμων παραμέτρων, επιτρέποντας στο δίκτυο να έχει περισσότερα επίπεδα και λιγότερες παραμέτρους. Παραδείγματος χάριν, ανεξάρτητα από το μέγεθος της εικόνας, η χρήση πυρήνων 5×5 , που μοιράζονται τα ίδια βάρη, χρειάζεται μόνο 25 εκπαιδευσιμες παραμέτρους.

Ειδικότερα, στη περίπτωση της διδιάστατης συνέλιξης, αν η είσοδος είναι μία εικόνα ή ένας τρισδιάστατος ταχυστής, η μαθηματική περιγραφή της λειτουργίας του συνελικτικού στρώματος για κάθε φίλτρο είναι:

$$S_l[i, j] = \text{ReLU}(b_l + \sum_{m=0}^{M_l-1} \sum_{n=0}^{N_l-1} W_l[m, n, :] o I[i - m, j - n, :]) \quad (3.4)$$

όπου λ ο δείκτης που αντιστοιχεί στο φίλτρο με τρισδιάστατο ταχυστή βαρών W_l , M_{l1} το ύψος και N_{l1} , b_l ένα διάνυσμα πόλωσης διάστασης ίσης με την τρίτη διάσταση του φίλτρου. Στη θέση της μη γραμμικής συνάρτησης ReLU θα μπορούσε να τοποθετηθεί οποιαδήποτε άλλη μη γραμμική συνάρτηση ενεργοποίησης. Στην πράξη, μέσω πειραματισμού έχει φανεί πως η ReLU δίνει τα καλύτερα αποτελέσματα σε πολλά προβλήματα [26, 24]. Μία σημαντική λεπτομέρεια που αποτελεί σχεδιαστική επιλογή, στην συντριπτική πλειοψηφία τέτοιων μοντέλων, είναι ότι ο αριθμός καναλιών της εισόδου ισούται με την τρίτη διάσταση του ταχυστή των φίλτρων. Αυτό υποδηλώνεται από την παραπάνω εξίσωση μέσω του συμβόλου " : " που υπονοεί πως όλα τα στοιχεία του ταχυστή κατά μήκος αυτής της τρίτης διάστασης, για σταθερή γραμμή m και στήλη n , χρησιμοποιούνται κατά τον υπολογισμό του κάθε γινομένου. Συνεπώς, τα γινόμενα της εξίσωσης εκτελούνται στοιχείο προς στοιχείο ανάμεσα στα βάρη του φίλτρου και το δεκτικό πεδίο του επί της εισόδου.



Σχήμα 3.8: CNN model architecture

Τα CNN ορισμένες φορές περιλαμβάνουν τοπικά ή μην επίπεδα για τον εξορθολογισμό του υπολογισμού. Τα pooling layers μειώνουν τις διαστάσεις των δεδομένων συγκεντρώνοντας τις εξόδους των νευρώνων σε ομάδες. Το τοπικό pooling (local pooling) κάνει μικρές ομαδοποιήσεις, συνήθως 2×2 . Αντίθετα, το καθολικό pooling (global pooling) επιδρά σε όλους τους νευρώνες του convolutional layer. Η τεχνική του pooling, μπορεί να υπολογίζει τη μέγιστη τιμή (max pooling) ή τον μέσο όρο (average pooling) της κάθε ομάδας από νευρώνες.


3.3.5 Αναδρομικά Νευρωνικά Δίκτυα - Recurrent Neural Networks

Τα αναδρομικά νευρωνικά δίκτυα είναι μία ειδική κατηγορία νευρωνικών δικτύων που επεξεργάζονται αποτελεσματικά κάθε είδους ακολουθιακά δεδομένα. Παραδείγματα, αποτελούν η φωνή, η γραφή, η οπτική πληροφορία που προκύπτει από μία κίνηση ή μία δράση ή ακόμα και τα πιξελ μίας εικόνας αν τα διατρέξουμε με κάποιο δομημένο τρόπο.[10]

Ένα αναδρομικό δίκτυο μετασχηματίζει κάθε νέα είσοδο με τρόπο που εξαρτάται τόσο από την ίδια την είσοδο όσο και από τις προηγούμενες εισόδους που έχει δεχτεί. Φορμαλιστικά αυτή η βασική αρχή περιγράφεται ως εξής: Αν X_t είναι η είσοδος την χρονική στιγμή t , $f(\&)$ η συνάρτηση που περιγράφει την επίδραση του αναδρομικού δικτύου πάνω στην είσοδο και h_t η έξοδος του, τότε:

$$h_t = f(x_t, h_{t-1}) = f(x_t, f(x_{t-1}, h_{t-2})) = \dots = f(x_t, f(x_{t-1}, \dots, (f(x_1, h_0)), \dots)) \quad (3.5)$$

Είναι φανερό πως υπάρχει στενή σχέση ανάμεσα στα γραφικά μοντέλα (graphical models) και τα αναδρομικά δίκτυα. Αυτή η σύνδεση ανάμεσα στις δύο κατηγορίες μοντέλων μπορεί να

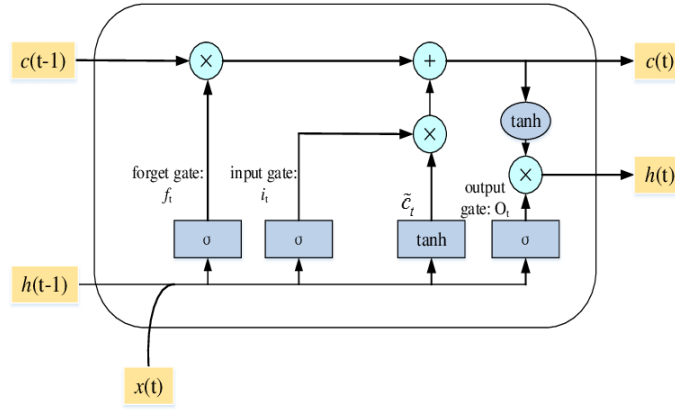


Σχήμα 3.9: Recursive Neural Network Unfolding

φανεί καλύτερα αν, όπως στο Σχήμα 2.8, το δίκτυο "ξεδιπλωθεί", σχεδιάζοντας "εικονικές" υπολογιστικές μονάδες για να αναπαρασταθούν οι αναδρομικές εκτελέσεις της συνάρτησης f πάνω στις εισόδους x_t, x_{t+1}, \dots, x_T . Σημειώνεται πως η έξοδος h_t συχνά αναφέρεται και ως κατάσταση του δικτύου. Στις παραπάνω εξισώσεις δεν εισήχθη για λόγους απλότητας η ύπαρξη ενός συνόλου παραμέτρων θ ή βαρών που όπως και στις άλλες περιπτώσεις νευρωνικών μοντέλων καθορίζουν την επίδραση του μοντέλου πάνω στην είσοδο τους. Οι παράμετροι αυτοί, και για τα αναδρομικά νευρωνικά δίκτυα είναι υπό μάθηση. Τα βάρη σε ένα αναδρομικό μοντέλο μπορούν να διαχωριστούν σε δύο κατηγορίες: αυτά που επιδρούν πάνω στην είσοδο (W) και αυτά που καθορίζουν την σημασία που δίνεται στην προηγούμενη κατάσταση του μοντέλου για τον υπολογισμό της επόμενης κατάστασης (U). Η γενική μορφή των εξισώσεων ενός αναδρομικού δικτύου είναι η εξής:

$$h_t = \phi(Wx_t + Uh_{t-1} + b) \quad (3.6)$$

όπου (\cdot) μία μη γραμμική συνάρτηση ενεργοποίησης, W ο πίνακας παραμέτρων που επιδρούν πάνω στην είσοδο Q_t , U ο πίνακας παραμέτρων που επιδρούν πάνω στην έξοδο του δικτύου την προηγούμενη χρονική στιγμή και β ένα διάνυσμα πόλωσης. Λόγω αυτού του μηχανισμού τα αναδρομικά δίκτυα έχουν τη δυνατότητα να μοντελοποιούν χρονικές εξαρτήσεις ακόμα και ανάμεσα σε μη συνεχόμενες παρατηρήσεις, αφού μέσω της αναδρομικότητας υλοποιούν έναν μηχανισμό μνήμης. Όμως, στη γενική μορφή τους τα νευρωνικά αναδρομικά δίκτυα δεν καταφέρνουν να μοντελοποιήσουν αποτελεσματικά εξαρτήσεις μακράς διάρκειας (όπου η χρήση του όρου μακράς είναι σχετική και εξαρτάται από το πρόβλημα). Η δυσκολία αυτή πηγάζει από το γεγονός ότι ο αλγόριθμος Back Propagation στο χρόνο, δεν διατηρεί μεγάλες τιμές κλίσεων όσο εξετάζουμε όλο και παλαιότερα τμήματα της ακολουθίας. Όπως φαίνεται και από την εξίσωση 2.6, ο υπολογισμός της κλίσης του κόστους ως προς κάποια παρελθοντική είσοδο περιλαμβάνει την παραγωγή μιας σύνθεσης συναρτήσεων που οδηγεί σε ένα όλο και αυξανόμενο αριθμό παραγόντων γινόμενου, καθώς κινούμαστε προς το παρελθόν. Κάποιο από τους παράγοντες αυτού του γινομένου είναι πιθανό να οδηγήσουν σε αστάθεια το συνολικό αποτέλεσμα αυξάνοντας ή μειώνοντας υπερβολικά την κλίση του κόστους ως προς τις παραμέτρους. Οι ανανεώσεις των παραμέτρων αυτών που περιγράφει ο αλγόριθμος Stochastic Gradient Descent βασίζονται στον υπολογισμό της κλίσης και συνεπώς αν σε αυτόν παρουσιαστούν υπερβολικά μεγάλες ή μικρές τιμές η μάθηση θα αποτύχει. Το πρόβλημα αυτό συνήθως αναφέρεται ως εξαφάνιση ή εκτόξευση της κλίσης (the vanishing or exploding gradient pro-



Σχήμα 3.10: LSTM Model Architecture

blem) και έχει σαν αποτέλεσμα η διαδικασία εκπαίδευσης να μην εντοπίζει ικανοποιητικά καλές τιμές για τα βάρη του μοντέλου.

3.3.6 Νευρωνικό Δίκτυο Μακράς-Βραχείας Μνήμης - LSTM

Η παραπάνω δυσλειτουργία των αναδρομικών δικτύων, αντιμετωπίστηκε μέσω της εισαγωγής των νευρώνων Μακράς-Βραχείας Μνήμης (Long Term Short Term Memory ή L.S.T.M) που προτάθηκαν πρώτη φορά από τους Hochreiter και Σζημιδηυβερ [20].

Αυτό το πιο εύρωστο είδος αναδρομικών δικτύων έχει φανεί πολύ αποτελεσματικό σε εφαρμογές όπως η επεξεργασία και μετάφραση φυσικής γλώσσας [23] ή η αναγνώριση συνεχούς χειρόγραφου [21, 22]. Αυτός ο τύπος δικτύου, μπορεί να "συγκρατεί" ακολουθίες εισόδου μεγάλου μήκους. Μια συνήθης αρχιτεκτονική των μονάδων του LSTM περιλαμβάνει: μια πύλη εισόδου (input gate), μια πύλη εξόδου (output gate) και μια πύλη (forget gate). Το input gate ελέγχει τη ροή ενός νέου στοιχείου, το forget gate ελέγχει αν θα παραμείνει το στοιχείο αυτό στη μονάδα του LSTM και το output gate ελέγχει τον βαθμό με τον οποίο, το στοιχείο που βρίσκεται στη μονάδα χρησιμοποιείται για να υπολογιστεί το αποτέλεσμα της συνάρτησης ενεργοποίησης της μονάδας. Τα activation functions του πυλών μιας μονάδας LSTM είναι sigmoid functions. Οι υπολογισμοί που πραγματοποιεί ένα LSTM unit κατά το εμπρόσθιο πέρασμα, είναι οι παρακάτω:

$$f_t = \sigma_g(W_f x_t + U_f h_{t-1} + b_f) \quad (3.7)$$

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (3.8)$$

$$o_t = \sigma_g(W_o x_t + U_o h_{t-1} + b_o) \quad (3.9)$$

$$c_t = f_t c_{t-1} + i_t \sigma_c(W_c x_t + U_c h_{t-1} + b_c) \quad (3.10)$$

$$h_t = o_t \sigma_h(c_t) \quad (3.11)$$

3.4 Μετρικές Σφαλμάτων

Τα μοντέλα που θα υλοποιηθούν στην παρούσα διπλωματική θα χρησιμοποιηθούν για βραχυπρόθεσμες προβλέψεις 24 ωρών. Διατηρώντας ένα μέρος των αρχικών παρατηρήσεων ως «δείγμα επαλήθευσης» θα αξιολογήσουμε πόσο ικανοποιητικές είναι οι παραχθείσες προβλέψεις. Συγκεκριμένα, τα δυο τρίτα του θερινού και του χειμερινού συνόλου δεδομένων θα χρησιμοποιηθούν ως είσοδοι στα μοντέλα για εκπαίδευση, και το υπόλοιπο ένα τρίτο, οι μήνες δηλαδή Μάρτιος & Αύγουστος για τη μέτρηση των σφαλμάτων.

Η αξιολόγηση των μεθόδων πρόβλεψης που χρησιμοποιήθηκαν γίνεται με τα παρακάτω μέτρα ακρίβειας που στηρίζονται στο σφάλμα πρόβλεψης, που εκφράζει στην απόκλιση της προβλεπόμενης τιμής από την πραγματική τιμή. Συνήθως συμβολίζεται με e_t και δίνεται από τον τύπο $Y - Y_t$, όπου Y η πραγματική τιμή και Y_t η προβλεπόμενη τιμή που μας παράγει η μέθοδος πρόβλεψης που επιλέξαμε. Παρακάτω θα αναφέρουμε τα πλέον συνηθισμένα μέτρα ακρίβειας εκφρασμένα με το σφάλμα πρόβλεψης όπως ορίστηκε πιο πάνω και το N που είναι το πλήθος των δεδομένων της χρονοσειράς. Τα πλέον χρησιμοποιούμενα μέτρα ακρίβειας ενός εφαρμοσμένου μοντέλου αναφέρονται παρακάτω. Για καλύτερη εικόνα των αποτελεσμάτων συνήθως χρησιμοποιούνται ταυτόχρονα, παραπάνω από ένα μέτρα ακρίβειας στις παραχθείσες προβλέψεις.

1. Το μέσο σφάλμα πρόβλεψης - Mean Forecast Error (MFE) ή απλά ME.

Το μέσο σφάλμα αποτελεί ένα μέτρο της μέσης απόκλισης των προβλεπόμενων τιμών από τις πραγματικές και υπολογίζεται ως $ME = \frac{1}{N} e_t$. Δείχνει την κατεύθυνση του σφάλματος και για αυτό ονομάζεται και αμεροληψία πρόβλεψης [27]. Για μια καλή πρόβλεψη είναι επιθυμητό το ME να είναι όσο το δυνατόν πιο κοντά στο μηδέν. Στο ME, οι επιπτώσεις των θετικών και αρνητικών σφαλμάτων ακυρώνονται και δεν πάχκει τρόπος να γνωρίζουμε το ακριβές ποσό τους, ενώ ένα μηδενικό ME δεν σημαίνει ότι οι προβλέψεις είναι τέλειες, δηλαδή ότι δεν περιέχουν σφάλματα, παρά μόνο δείχνει ότι οι προβλέψεις είναι προς τη σωστή κατεύθυνση. Ακόμη, δεν περικλείει ακραία σφάλματα και εξαρτάται από την κλίμακα μέτρησης των δεδομένων καθώς επίσης επηρεάζεται από τους μετασχηματισμούς των δεδομένων.

2. Το μέσο απόλυτο σφάλμα Mean Absolute Error (MAE) ή Μέση Απόλυτη Απόκλιση Mean Absolute Deviation (MAD)

Αποτελεί το πιο απλό κριτήριο καθώς υπολογίζει την μέση απόλυτη απόκλιση των προβλέψεων από τις πραγματικές τιμές και γι'αυτό ονομάζεται και μέση απόλυτη απόκλιση και δίνεται από τον τύπο $MAE = \frac{1}{N} * \sum_{t=1}^N |e_t|$. Σε αντίθεση με το ME στο MAE τα θετικά και αρνητικά σφάλματα δεν εξουδετερώνονται οπότε παράλληλα δεν δείχνει και την κατεύθυνση των σφαλμάτων, δείχνει όμως όλο το μέγεθος των σφαλμάτων. Επίσης εξαρτάται από την κλίμακα μέτρησης και επηρεάζεται από τους μετασχηματισμούς δεδομένων. Για να είναι καλές οι προβλέψεις θα πρέπει το MAE να είναι όσο το δυνατόν μικρότερο.

3. Το μέσο κανονικοποιημένο απόλυτο σφάλμα NMAE

Όμοια με το MAE, κανονικοποιούμε όμως τα σφάλματα ως προς την μέγιστη παρατήρηση Y_t .

4. Το μέσο απόλυτο ποσοστιαίο σφάλμα - Mean Absolute Percentage Error (MAPE)

Αντανακλά το ποσοστό του μέσου απόλυτου σφάλματος, δεν δείχνει την κατεύθυνση των σφαλμάτων αλλά ούτε και μεγάλες αποκλίσεις που πιθανόν να υπάρχουν. Το μέσο απόλυτο ποσοστιαίο σφάλμα δίνεται από τον τύπο $MAPE = \frac{1}{N} \sum_{t=1}^N \frac{|e_t|}{Y_t}$. Επειδή υπολογίζει τα απόλυτα, πάλι τυχόν ετερόσημα σφάλματα δεν εξουδετερώνονται. Σε αντίθεση με τα παραπάνω σφάλματα το MAPE είναι ανεξάρτητο από την κλίμακα μεγέθους, επηρεάζεται όμως από τυχόν μετασχηματισμούς στα δεδομένα. Επειδή το MAPE είναι απαλλαγμένο από μονάδες μέτρησης το χρησιμοποιούμε για να συγκρίνουμε την ακρίβεια ανάμεσα σε διαφορετικές μεθόδους πρόβλεψης.

5. Το μέσο τετραγωνικό σφάλμα - Mean Squared Error (MSE)

Μετράει τη μέση τετραγωνική απόκλιση των σφαλμάτων και δίνεται από τον τύπο $MSE = \frac{1}{N} \sum_{t=1}^N (e_t)^2$. Ακολουθεί την ίδια μονάδα μέτρησης με αυτήν της χρονοσειράς αλλά υψωμένη στο τετράγωνο. Τα ετερόσημα σφάλματα δεν αλληλοαφαιρούνται, μας δίνει μια ολοκληρωμένη εικόνα για το μέγεθος των σφαλμάτων ακόμη και των πιο ακραίων τιμών. Δεν δείχνει την κατεύθυνση των σφαλμάτων λόγω των τετραγώνων και τέλος είναι πολύ ευαίσθητο σε τυχόν αλλαγές στην κλίμακα ή σε κάποια τροποποίηση των δεδομένων.

6. Το κανονικοποιημένη ρίζα του μέσου τετραγωνικού σφάλματος - Normalized Root Mean Squared Error (NMSE)

Συνδυασμός της ρίζας του μέσου τετραγωνικού σφάλματος, με κανονικοποίηση. Η ρίζα του ΜΣΕ, ΡΜΣΕ και έχει όλες τις ιδιότητες του ΜΣΕ. Έχει την ίδια μονάδα μέτρησης με την χρονοσειρά και συχνά χρησιμοποιείται αντί του ΜΣΕ για να απαλειφθεί η υψωμένη στο τετράγωνο μονάδα μέτρησης. Μαζί με την κανονικοποίηση αποτελεί ένα ισορροπημένο μέτρο σφάλματος και ένα πολύ αποτελεσματικό μέτρο για την ακρίβεια του μοντέλου. Όσο μικρότερη η τιμή του τόσο καλύτερη η πρόβλεψη που παράγει το μοντέλο.

Κεφάλαιο 4

Δεδομένα και Μεθοδολογία για Βραχυπρόθεσμη Πρόβλεψη Παραγωγής Φωτοβολταϊκών

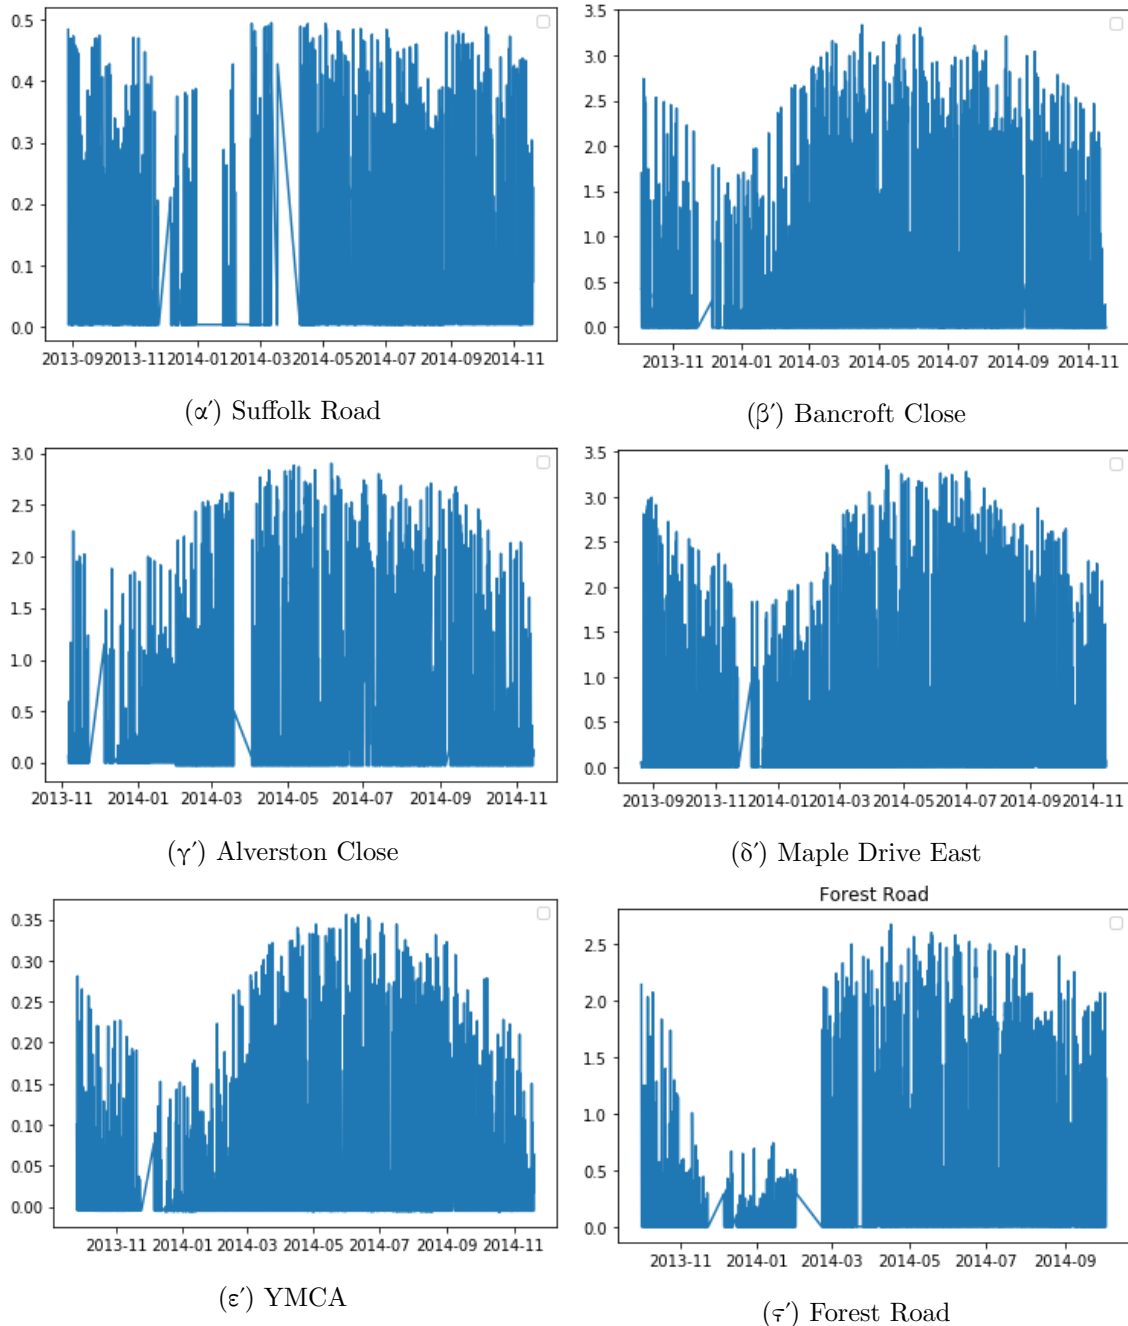
4.1 Εισαγωγή

Σε αυτό το κεφάλαιο, παρουσιάζεται η μεθοδολογία εργασίας αυτής της διπλωματικής. Παρουσιάζονται τα αρχικά δεδομένα, η δομή τους και τα ποιοτικά τους χαρακτηριστικά. Εν συνεχεία αναλύεται η αναγκαία επεξεργασία των δεδομένων και η μεθοδολογία που ακολουθήθηκε για κάθε τεχνική πρόβλεψης και Machine Learning ξεχωριστά. Κατόπιν συγκρίνονται τα αποτελέσματα των διαφορετικών μοντέλων.

Σε όλους τους απαραίτητους υπολογισμούς για το χειρισμό των δεδομένων, την εφαρμογή των στατιστικών τεχνικών προβλέψεων καθώς και τη σχεδίαση και την υλοποίηση των νευρωνικών μοντέλων χρησιμοποιήθηκε η γλώσσα Python έκδοση 3.7.4 και το προγραμματιστικό περιβάλλον Spyder 4.1.3 . Η σχεδίαση των νευρωνικών μοντέλων έγινε με χρήση Keras, ενός high-level API της TensorFlow κατάλληλου για την κατασκευή και εκπαίδευση μοντέλων βαθιάς μάθησης.

4.2 Σχολιάσιμος Δεδομένων

Το αρχικό Dataset περιείχε την ωριαία μέγιστη και ελάχιστη παραγωγή P_g φωτοβολταϊκών απο 6 σταθμούς ['Forest Road' 'Suffolk Road' 'Bancroft Close' 'Alverston Close' 'Maple Drive East' 'YMCA'] για διάστημα ενός χρόνου (10/2013-10/2014).




Σχήμα 4.1: Ετήσια Ωριαία Παραγωγή Ενεργού Ισχύος Ανά Υποσταθμό

Από την μέγιστη και ελάχιστη τιμή υπολογίστηκε η μέση ωριαία ενεργός ισχύς εξόδου των Φωτοβολταϊκών η οποία και χρησιμοποιήθηκε στη συνέχεια. Για καθένα σταθμό έγινε


μια οπτικοποίηση των δεδομένων προκειμένου να επιλεγούν τα σύνολα δεδομένων που θα πληρούν τις απαιτήσεις των μοντέλων. Ενδεικτικά, για τα Arima μοντέλα είναι επιθυμητή η ύπαρξη στασιμότητας και εν γένει είναι αναγκαία η όσο το δυνατόν μεγαλύτερη πληρότητα του Dataset. Κάποιοι από τους σταθμούς εμφάνιζαν ανα περιόδους missing values γεγονός που τους καθιστούσε ακατάλληλους για την εκπαίδευση των μοντέλων.

Επιλέχθηκαν οι σταθμοί Bancroft Close, Maple Drive East με κριτήριο την πληρότητα του dataset. Αυτό γίνεται αντιληπτό οπτικά ενώ εφαρμόστηκε και ο αντίστοιχος προγραμματιστικός έλεγχος. Κατόπιν έγινε ο χωρισμός των δεδομένων σε 2 τρίμηνα, ένα χειμερινό και ένα θερινό, λόγω της έντονης εποχικότητας που χαρακτηρίζει τη παραγωγή των Φωτοβολταϊκών. Από το Bancroft Close επιλέχθηκαν οι θερινοί μήνες, συγκεκριμένα το διάστημα από 01-06-2014 έως 30-08-2014,



Σχήμα 4.2: Summer Bancroft Close

ενώ από το Maple Drive East το χειμερινό τρίμηνο 01-01-2014 έως 30-03-2014.



Σχήμα 4.3: Winter Maple Drive East

Τα μοντέλα θα εκπαιδεύονται με είσοδο τους δυο πρώτους μήνες και θα προβλέπουν τις τιμές του τρίτου μήνα. Έχουμε δηλαδή ένα training set διάρκειας 2 μηνών που αντιστοιχεί σε 1440 ($2 \cdot 30 \cdot 24$) τιμές της χρονοσειράς και ένα test set διάρκειας 1 μήνα, δηλαδή 720 τιμές. Μια καλή πρακτική προκειμένου να επιταχύνουμε την εκπαίδευση των νευρωνικών είναι η κανονικοποίηση των δεδομένων. Για ποιοτική εννιαιότητα των αποτελεσμάτων και δυνατότητα σύγκρισης εφαρμόστηκε κανονικοποίηση και στα δεδομένα εισόδου των benchmark μοντέλων. Καθώς η εγκατεστημένη ισχύς του κάθε πάρκου δεν ήταν γνωστή, η κανονικοποίηση έγινε ως προς την μέγιστη ισχύ παραγωγής. $P_{norm} = \frac{P_{old}}{P_{max}}$

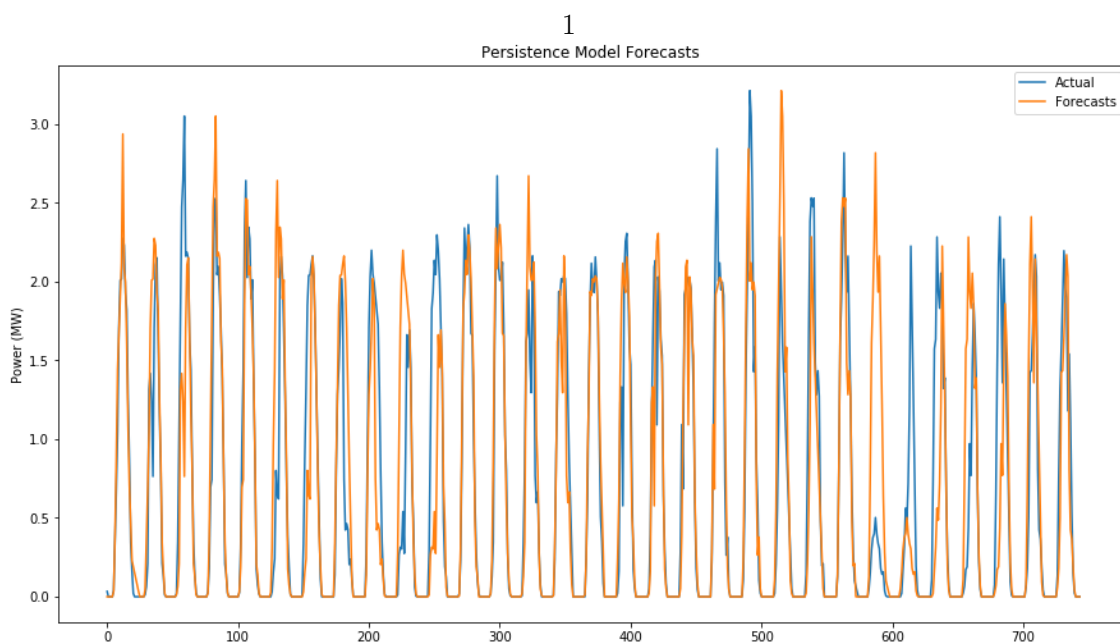
4.3 Μοντέλο Παραμένουσας Τιμής - Persistence Model

4.3.1 Αλγόριθμος


Για την σύγκριση των μοντέλων χρησιμοποιήσαμε κάποια βασικά στατιστικά μοντέλα πρόβλεψης. Το Persistence κάνει μια παλιή πρόβλεψη θεωρώντας την προβλεπόμενη ωριαία παραγωγή ίση με την παραγωγή της αντίστοιχης ώρας της προηγούμενης ημέρας. $P_t = P_{t-24}$

4.3.2 Αποτελέσματα

Παρουσιάζονται οι προβλέψεις για τη θερινή και τη χειμερινή περίοδο σε σύγκριση με τις πραγματικές τιμές παραγωγής.

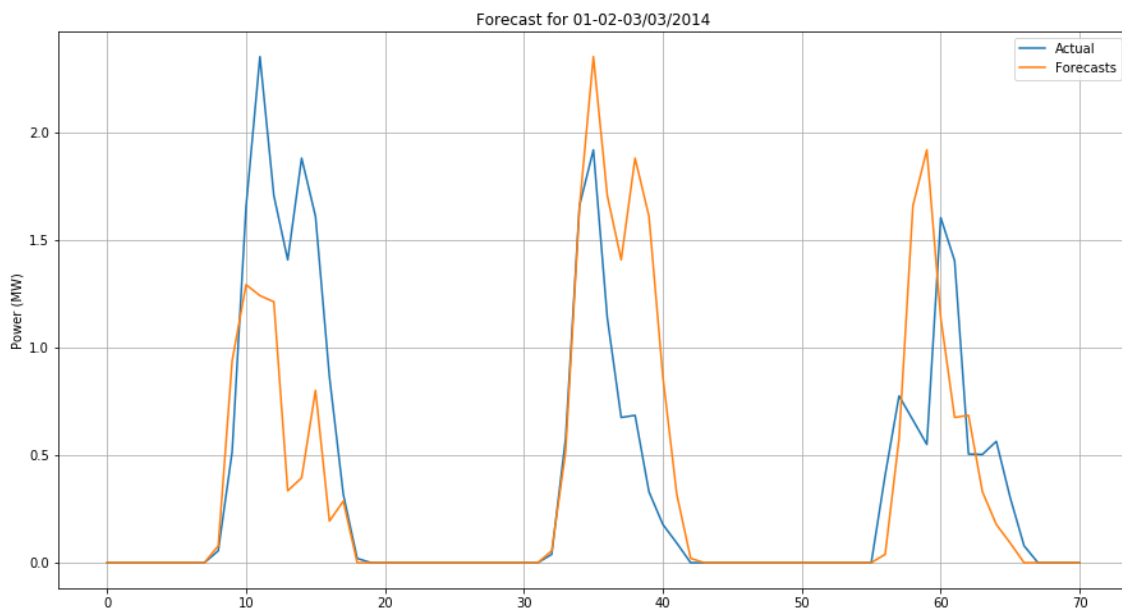


Σχήμα 4.4: Persistence Model Summer Bancroft Close Forecasts

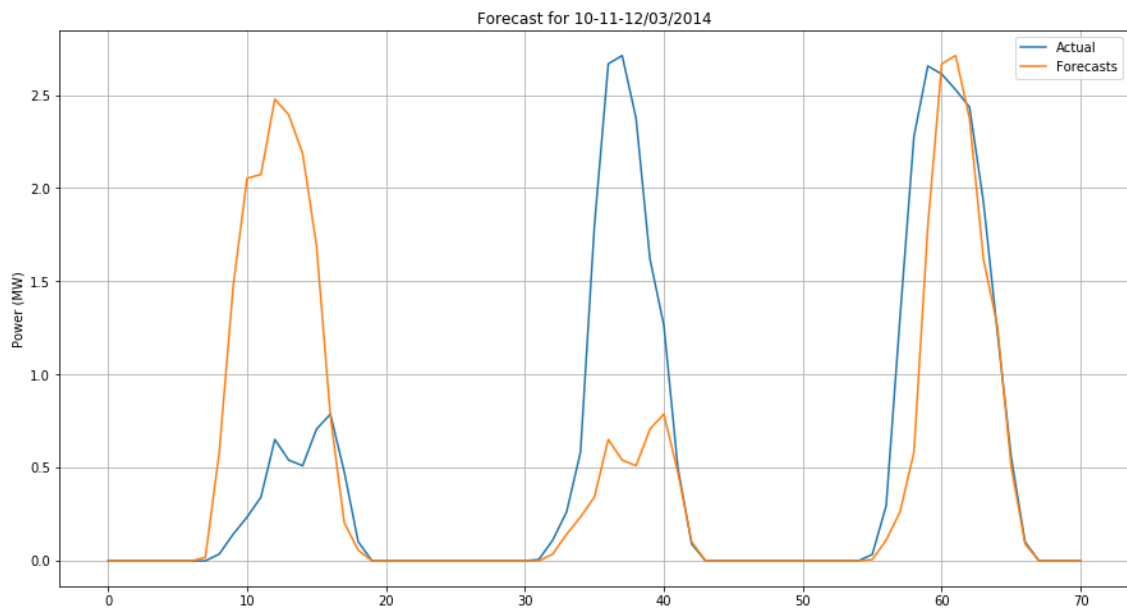


Σχήμα 4.5: Persistence Model Winter Middle East Drive Forecasts


Το Persistence μοντέλο παρουσιάζει ικανοποιητικά αποτελέσματα για τις συνεχόμενες ημέρες που έχουν το ίδιο αντίστοιχο μοτίβο παραγωγής. Αντίθετα, δεν κάνει καμία πρόβλεψη που να συσχετίζεται με τις προηγούμενες ώρες της ημέρας και παρουσιάζει έντονα σφάλματα σε μέρες με έντονη διαφορά στη παραγωγή.



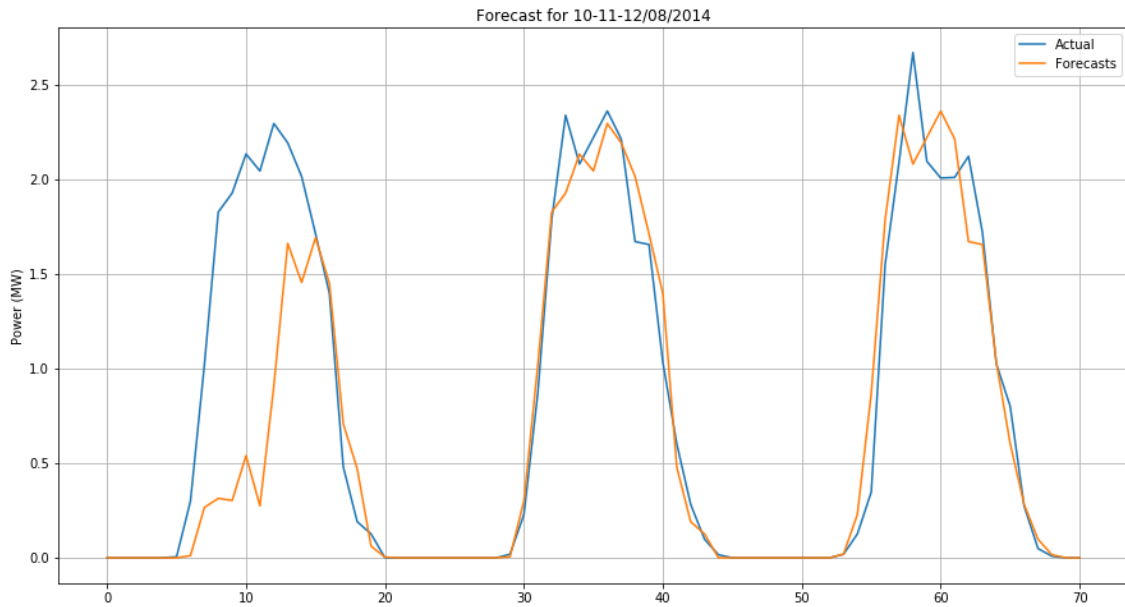
Σχήμα 4.6: Forecasts for 1st, 2nd, 3rd of March 2014 in MDE



Σχήμα 4.7: Forecasts for 10th, 11th, 12th of March 2014 in MDE

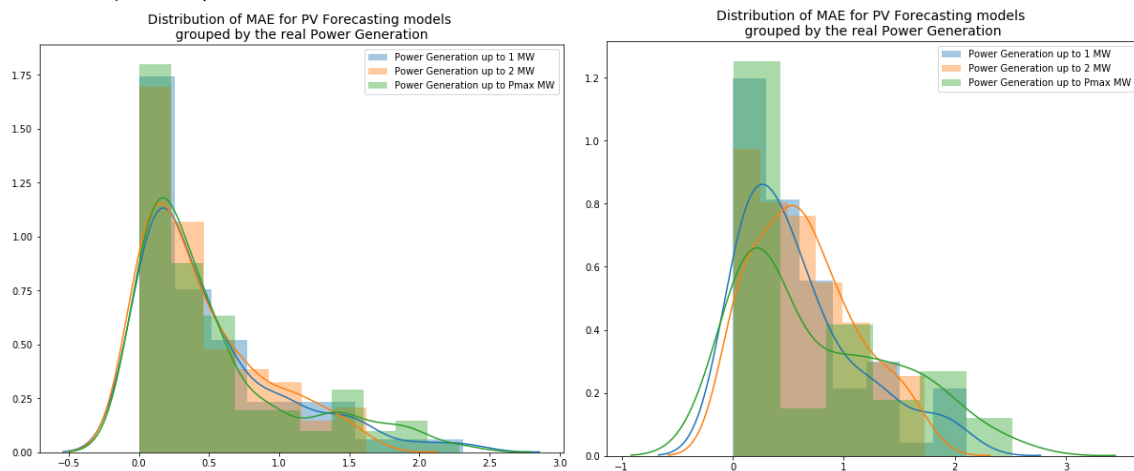


Σχήμα 4.8: Forecasts for 1st, 2nd, 3rd of August 2014 in BC



Σχήμα 4.9: Forecasts for 10th, 11th, 12th of August 2014 in BC


Μια ακόμα παρατήρηση αφορά την ομοιότητα με την οποία αντιμετωπίζει το Persistence κάθε πρόβλεψη. Έχουμε λοιπόν αντίστοιχη μέση τιμή σφάλματος και διασπορά για κάθε τάξη μεγέθους παραγωγής.




4.4 Ολοκληρωμένα Αυτοπαλινδρομικά Μοντέλα Κινητού Μέσου Όρου- ARIMA

4.4.1 Προεπεξεργασία Δεδομένων

Το Arima χρειάζεται στασιμότητα των δεδομένων, ως προς τη μέση τιμή και τη τυπική απόκλιση. Ως εκ τούτου παρουσιάζουμε τα δυο τρίμηνα που θα μελετήσουμε μαζί με τα rolling mean & rolling standard deviation. Επειδή η οπτική, ποιοτική εκτίμηση της στασιμότητας δεν αρκεί, πραγματοποιήσαμε τα Dickey- Fuller test, KPSS-test που θα παρουσιαστούν στους πίνακες.



Σχήμα 4.10: Data, Rolling Mean & Std For Summer BC



Σχήμα 4.11: Data, Rolling Mean & Std For Winter MDE

Summer BC	Augmented Dickey Fuller	KPSS test
Test Statistics	-8.080295	0.244505
p-value	1.467589e-12	0.010000
#Lags Used	24	24
Critical Value (1%)	-3.433625	0.739000
Critical Value (5%)	-2.862987	0.463000
Critical Value (10%)	-2.567540	0.347000
Results:	Stationary	Stationary

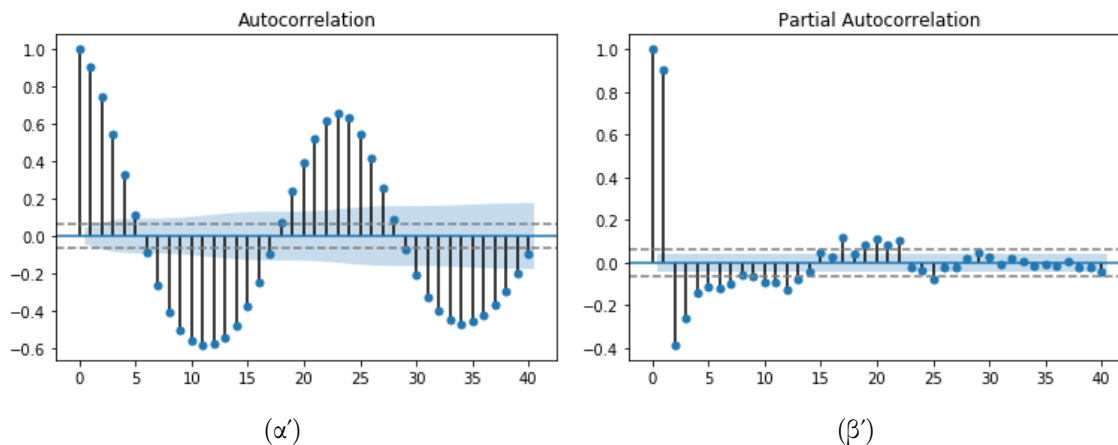
Πίνακας 4.1: Stationarity Tests for Summer Trimester of Bancroft Close

Οι έλεγχοι υποδεικνύουν στασιμότητα των δεδομένων και ως εκ τούτου δεν πραγματοποιήσαμε κανέναν μετασχηματισμό στα δεδομένα του θερινού τριμήνου. Αντίστοιχα παρουσιάζουμε για το χειμερινό τρίμηνο:

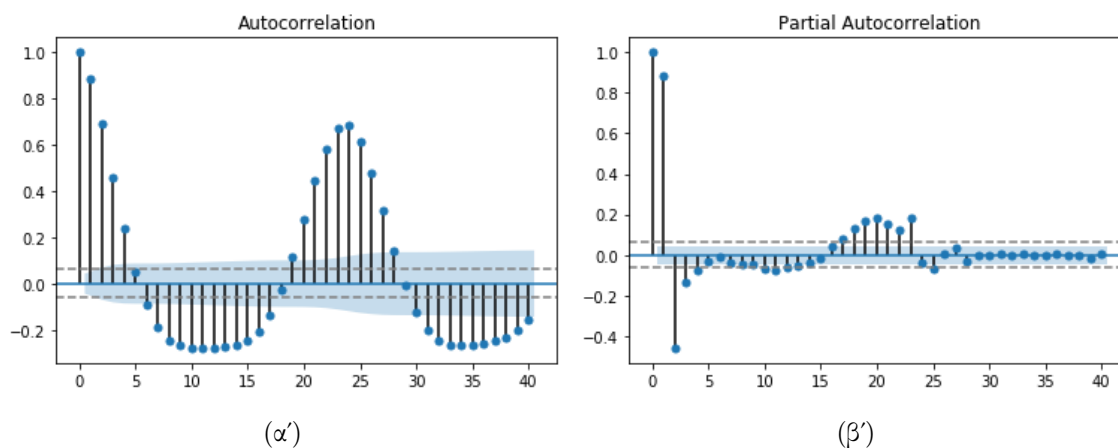
Winter	Augmented Dickey Fuller	KPSS test
Test Statistics	-4.556799	3.943157
p-value	0.000155	0.010000
#Lags Used	24	24
Critical Value (1%)	-3.433561	0.739000
Critical Value (5%)	-2.862959	0.463000
Critical Value (10%)	-2.567525	0.347000
Results:	Stationary	Stationary

Πίνακας 4.2: Stationarity Tests for Winter Trimester of MDE

Τέλος μελετήθηκε η αυτοσυσχέτιση και η μερική αυτοσυσχέτιση των δεδομένων, προκειμένου να αποφασιστεί το καλύτερο μοντέλο Arima για την πρόβλεψη της χρονοσειράς. Παρατηρούμε ισχυρή αυτοσυσχέτιση μέχρι και την 24η παρατήρηση.



Σχήμα 4.12: ACF & PACF for Summer BC

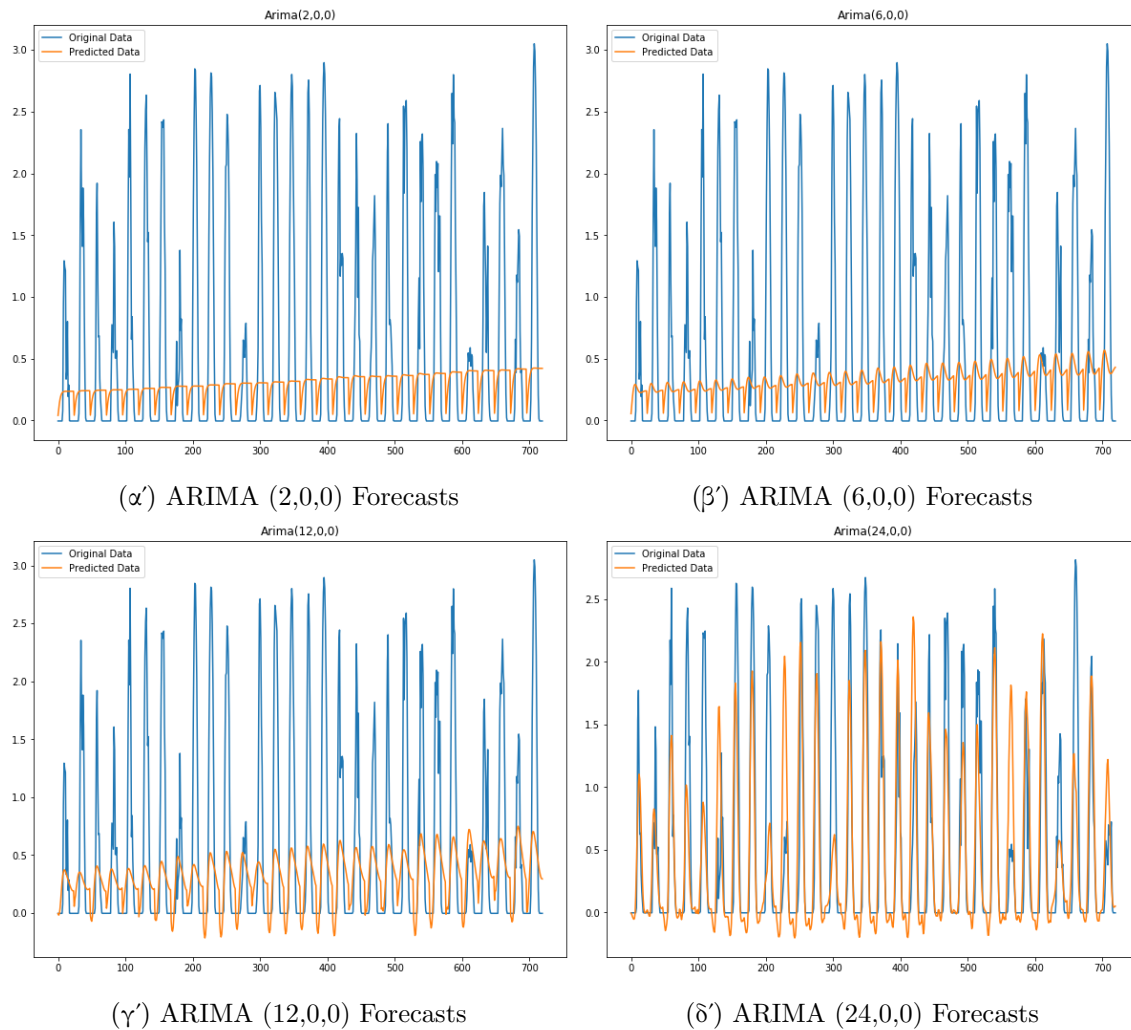


Σχήμα 4.13: ACF & PACF for Winter MDE

4.4.2 Αλγόριθμος

Το μοντέλο ARIMA εκπαιδεύεται από κάποια δεδομένα εισόδου, έστω χρονοσειρά από παρατηρήσεις μήκους T - δηλαδή από την 0 έως $d-1$ ημέρα, και παράγει 24 μελλοντικές τιμές ($T+1, \dots, T+24$) για την ημέρα πρόβλεψης d . Στη συνέχεια, η χρονοσειρά θα ενσωματώσει την ημέρα d , με βάση τα πραγματικά δεδομένα που έχουμε για αυτή και το μοντέλο θα επανεκπαιδευτεί με την νέα χρονοσειρά, πάλι μήκους T , από την ημέρα 1 έως d , προκειμένου να προβλέψει την επόμενη ημέρα $d+1$. Η διαδικασία αυτή θα γίνει επαναληπτικά για κάθε ημέρα του μήνα πρόβλεψης, για το θερινό και το χειμερινό τρίμηνο αντίστοιχα.

Για την επιλογή του καλύτερου ARIMA μοντέλου δοκιμάστηκαν διάφορες τιμές για τις μεταβλητές p, q . Με δεδομένο ότι τα data εισόδου τόσο για το θερινό όσο και για το χειμε-

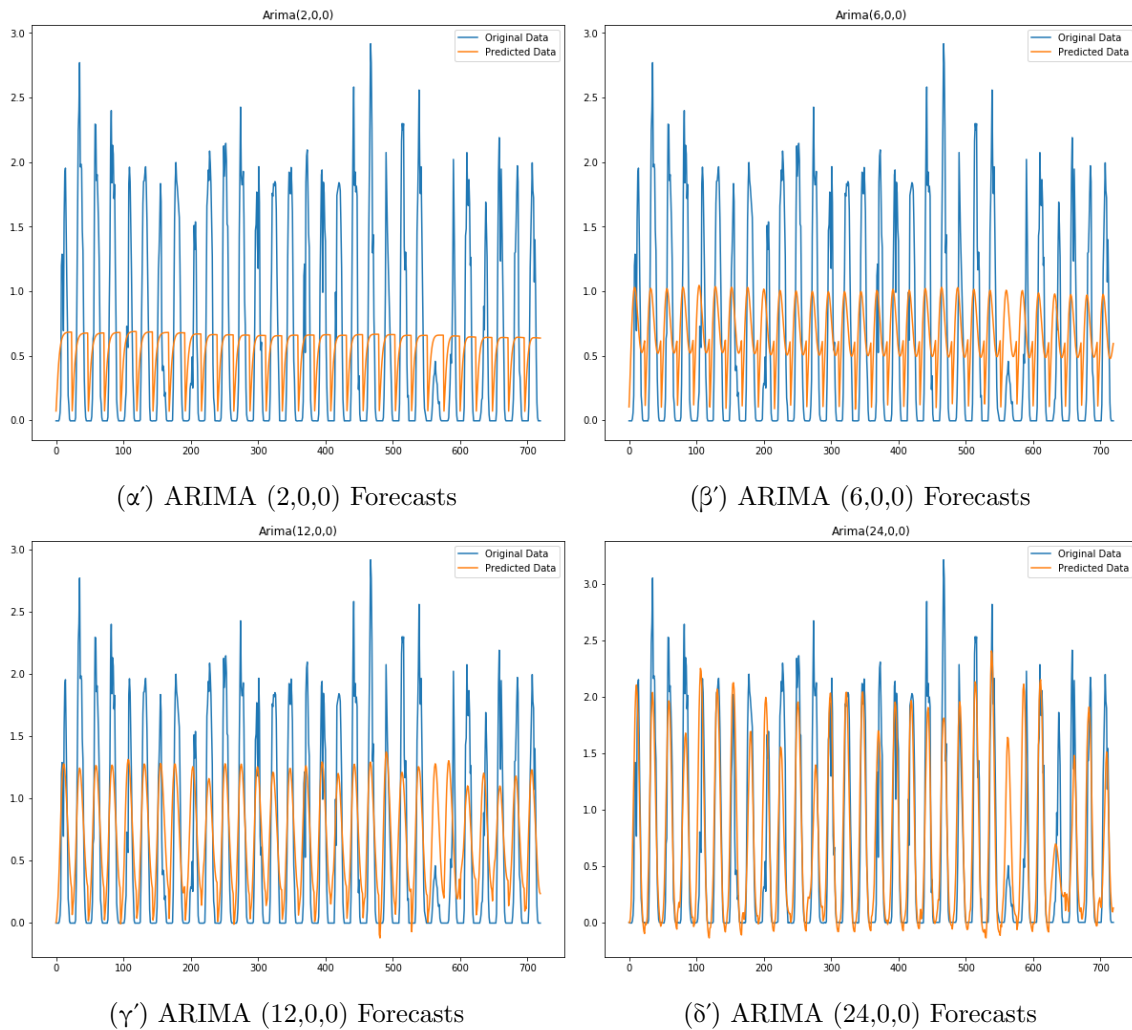


Σχήμα 4.14: Winter MDE Forecasts

ρινό τρίμηνο κρίθηκαν επαρκώς στάσιμα από τα παραπάνω test, δεν χρειάστηκε η διαφορίση τους, οπότε η μεταβλητή d τέθηκε ίση με μηδέν. Για τη μεταβλητή q δοκιμάστηκαν οι τιμές 0 και 1, αλλά τα μοντέλα με τη καλύτερη απόδοση ήταν για $q=0$, δηλαδή AR μοντέλα αυτοπαλινδρόμησης. Η ισχυρή αυτοσυσχέτιση των τελευταίων 24 τιμών όπως φαίνεται και απο τα ACF, PACF plots, καθώς και όπως υποδεικνύει η σχετική βιβλιογραφία [14, 15] μας οδήγησε στο συμπέρασμα ότι η μεταβλητή αυτοσυσχέτισης θα λάβει την τιμή 24. Πράγματι το μοντέλο (24,0,0) είχε την βέλτιστη απόδοση σε σχέση με τα μοντέλα AR(2), AR(6), AR(12), ARMA(6,1), ARMA(1,1).

4.4.3 Αποτελέσματα

Παραθέτουμε τις προβλέψεις για κάθε μοντέλο ARIMA που υλοποιήθηκε.




Σχήμα 4.15: Summer BC Forecasts


Όπως φαίνεται τόσο στο χειμερινό όσο στο θερινό dataset οι προβλέψεις βελτιώνονται αισθητά για $p = 24$. Η παρατήρηση αυτή έρχεται σε συμφωνία με όσα περιμέναμε στην περιγραφή του αλγορίθμου ARIMA. Ως εκ τούτου το μοντέλο AR(24) είναι αυτό που θα χρησιμοποιήσουμε ως benchmark μοντέλο για την σύγκριση με τα νευρωνικά.

4.4.4 Σφάλματα


Ιδιαίτερο ενδιαφέρον έχει η σύγκριση των σφαλμάτων που παρουσιάζουν τα διαφορετικά μοντέλα. Συγκεκριμένα, παρατηρούμε πως τα μοντέλα με τάξη 2, 6 παρουσιάζουν μικρά σφάλματα για τις νυχτερινές ώρες, καθώς εκεί η παραγωγή ενέργειας ούσα μηδενική ταυτίζεται με τις προηγούμενες 2 ή 6 αντίστοιχα παρελθοντικές τιμές. Αντίθετα, στις μεσημερινές ώρες 11.00-16.00 που η παραγωγή ενέργειας μεγιστοποιείται -και άρα μας ενδιαφέρει περισσότερο η μεγαλύτερη ακρίβεια στις προβλέψεις- το μοντέλο AR(24) παρουσιάζει πολύ μικρότερο μέσο σφάλμα και η καμπάνα της κατανομή σφάλματος έχει μικρότερο εύρος.




(α) 07.00



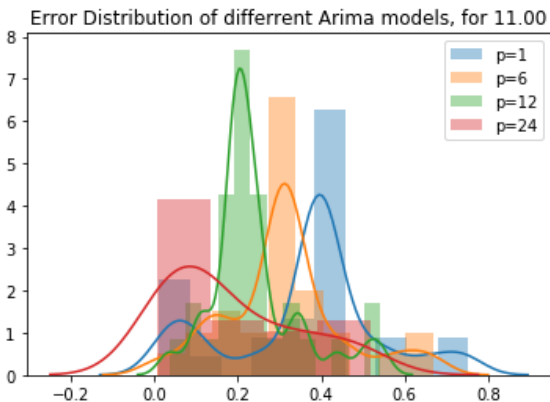
(β') 08.00




(γ') 09.00



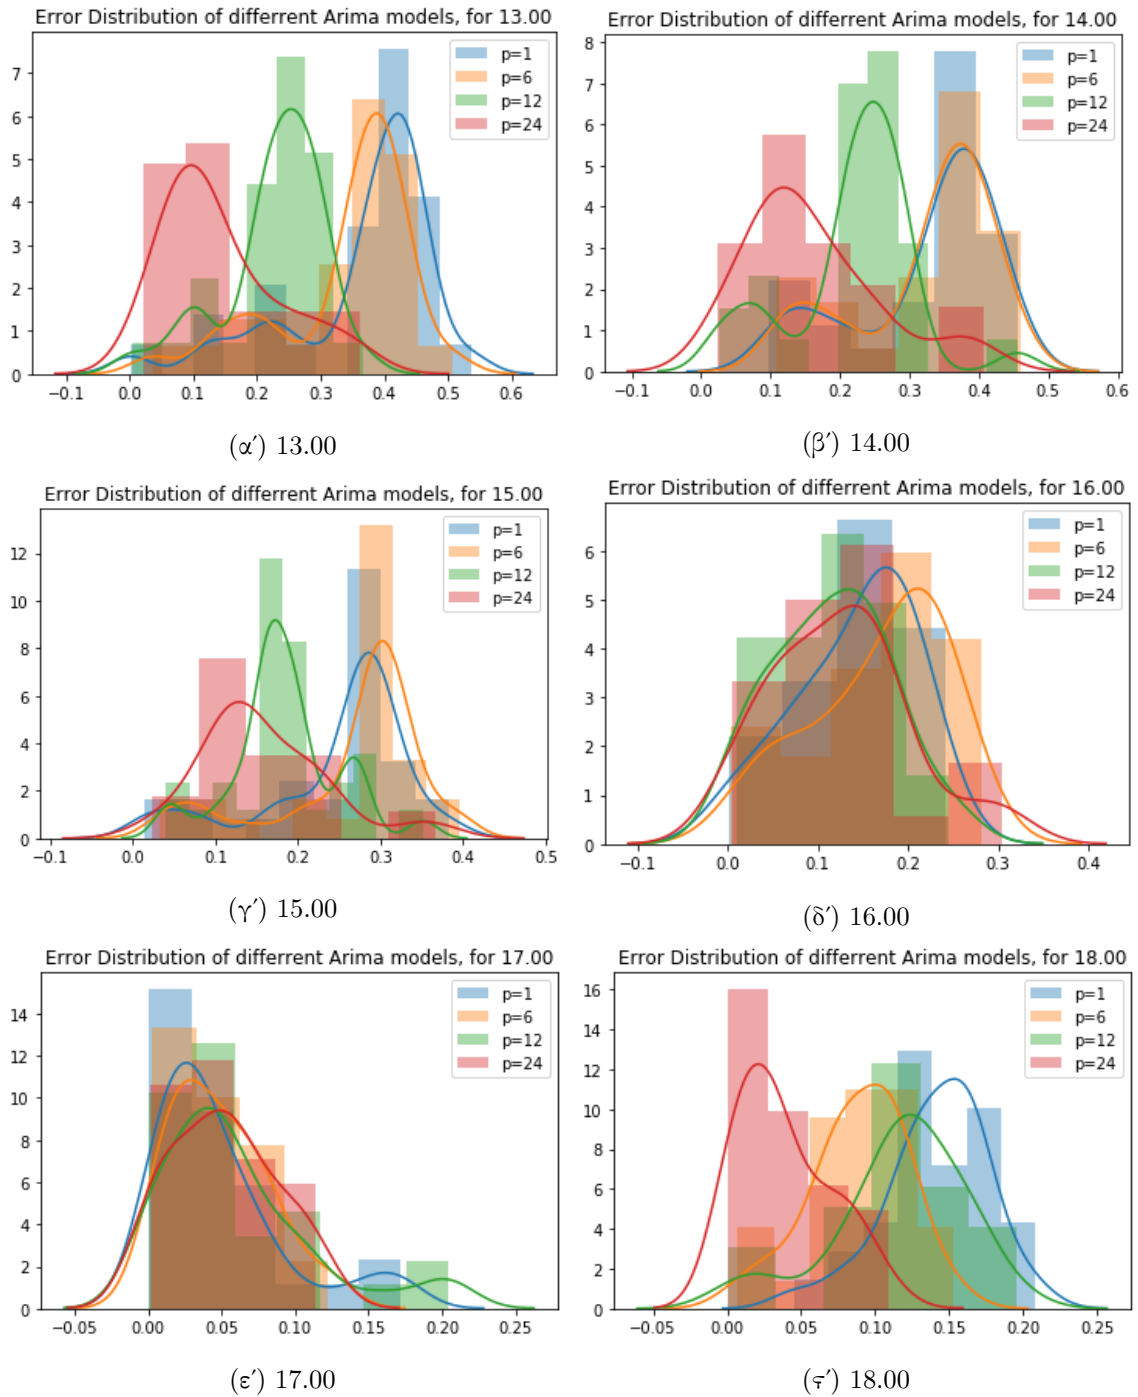
(δ') 10.00




(ε') 11.00




(ϖ') 12.00



Σχήμα 4.17: Hourly Error Distribution of Different ARIMA models



Σχήμα 4.18: Daily Mean Absolute Error



Σχήμα 4.19: Daily Error Standard Deviation

4.5 Νευρωνικά δίκτυα μακράς βραχυπρόθεσμης μνήμης-LSTM

4.5.1 Αλγόριθμος

Χρησιμοποιήσαμε νευρωνικά δίκτυα προκειμένου να προβλέψουμε μια ακολουθία 24 τιμών P μιας ημέρας δίνοντας σαν είσοδο τις προηγούμενες 24 τιμές. Έγινε σχεδιασμός ενός LSTM seq2seq μοντέλου. Καθώς η ακολουθία εξόδου είναι συγκεκριμένου μήκους και δεν εξαρτάται από την ακολουθία είσοδου δεν έγινε χρήση encoder-decoder. Σχεδιάσαμε με τη βοήθεια του Keras, ακολουθιακό νευρωνικό μοντέλο με δυο επίπεδα LSTM, 100 νευρώνες στο καθένα, ενώ χρησιμοποιήσαμε ένα ενδιάμεσο επίπεδο Dropout προκειμένου να μειωθεί η υπερπροσαρμογή και να βελτιωθεί η απόδοση του μοντέλου. Μετά από τα τρία αυτά επίπεδα, χρησιμοποιήσαμε ένα Fully Connected Dense Layer 24 νευρώνων προκειμένου να έχουμε την επιθυμητή έξοδο 24 τιμών για πρόβλεψη. Οι υπερπαραμέτροι του καθορίστηκαν με δοκιμές διαφορετικών

Layer (type)	Output Shape	Param #
lstm 1 (LSTM)	(None, 24, 100)	40800
dropout 1 (Dropout)	(None, 24, 100)	0
lstm 2 (LSTM)	(None, 100)	80400
dense 1 (Dense)	(None, 24)	2424

Πίνακας 4.3: Model Summary


μοντέλων, ενώ οι βέλτιστες επιλέχθηκαν ως: Το μοντέλο αρχικά εκπαιδεύτηκε με είσοδο τα

Epochs	16
Number of Batches	16
Activation Function	ReLu
Optimizer	Adam
Bidirectional	Yes


Πίνακας 4.4: Hyperparameters of LSTM Model

δεδομένα του θερινού διμήνου, τα οποία χωρίστηκαν σε training set & validation set με αναλογία 80 - 20. Κατόπιν για κάθε μέρα του μήνα πρόβλεψης έγινε με επαναληπτική διαδικασία η παραγωγή των προβλέψεων. Έπειτα, δημιουργήσαμε και εκπαιδεύσαμε ένα πανομοιότυπο μοντέλο για το χειμερινό δίμηνο. Ο λόγος που δημιουργήθηκαν δυο ξεχωριστά μοντέλα είναι πως, τα δεδομένα που είχαμε στη διάθεση μας, κρίνονται λίγα για να εκπαιδευτεί επαρκώς ένα μόνο μοντέλο.

4.5.2 Αποτελέσματα




(α') Summer Bancroft Close Forecasts LSTM




(β') Winter MDE Forecasts LSTM

4.5.3 Σφάλματα

Το LSTM παρουσιάζει μεγαλύτερο σφάλμα κατά τις μεσημεριανές ώρες, με κορυφή στις 10.00a.m. Το συνολικό NMAE, για το θερινό τρίμηνο ανέρχεται σε 0.0676 και για το χειμερινό σε 0.09224.



(α') Summer BC NMAE



(β') Winter MDE NMAE

4.6 Συνελικτικό Νευρωνικό δίκτυο - CNN

4.6.1 Αλγόριθμος

Η λογική που ακολουθήσαμε στην υλοποίηση του Convolutional 1-Dimension Neural Network είναι αντίστοιχη με τα υπόλοιπα νευρωνικά. Τα δεδομένα χωρίστηκαν σε training & test dataset, δημιουργήθηκε το μοντέλο με χρήση Keras, εκπαιδεύτηκε και ύστερα έγιναν οι προβλέψεις για το θερινό και το χειμερινό μήνα.


Layer (type)	Output Shape	Param #
conv1d 23 (Conv1D)	(None, 23, 64)	192
max pooling1d 23	MaxPooling(None,11,64)	0
flatten 15 (Flatten)	(None, 704)	0
dense 6 (Dense)	(None, 50)	35250
dense 7 (Dense)	(None, 24)	1224

Πίνακας 4.5: Model Summary

Epochs	32
Number of Batches	16
Activation Function	ReLu
Optimizer	Adam

Πίνακας 4.6: Hyperparameters of CNN 1d Model

4.6.2 Αποτελέσματα




(α') Summer BC Forecasts CNN1d


(β') Winter MDE Forecasts CNN1d

4.6.3 Σφάλματα

Το CNN παρουσιάζει μεγαλύτερο σφάλμα κατά τις μεσημεριανές ώρες, με κορυφή στις 10.00a.m. Το συνολικό NMAE, για το θερινό τρίμηνο ανέρχεται σε 0.07811 και για το χειμερινό σε 0.093368.



(α') Summer BC NMAE



(β') Winter MDE NMAE

4.7 CNN-LSTM

4.7.1 Αλγόριθμος

Για την δημιουργία του μοντέλου CNN-LSTM, ουσιαστικά συνενώσαμε τα δυο προηγούμενα μοντέλα, τροποποιώντας κατάλληλα την έξοδο από το CNN, έτσι ώστε να είναι στη κατάλληλη μορφή για είσοδο στο LSTM.

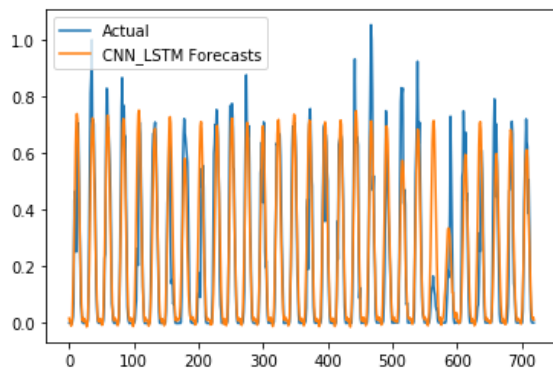
Layer (type)	Output Shape	Param #
conv1d 20 (Conv1D)	(None, 23, 64)	192
max pooling1d 20	MaxPooling (None, 12, 64)	0
flatten 12 (Flatten)	(None, 768)	0
reshape 13 (Reshape)	(None, 12, 64)	0
lstm 7 (LSTM)	(None, 12, 100)	66000
bidirectional 1	Bidirection (None, 200)	160800
dense 2 (Dense)	(None, 24)	4824

Πίνακας 4.7: Model Summary


Epochs	16
Number of Batches	256
Activation Function	ReLu
Optimizer	Adam

Πίνακας 4.8: Hyperparameters of CNN-LSTM Model

4.7.2 Αποτελέσματα




(α') Summer BC Forecasts CNN-LSTM




(β') Winter MDE Forecasts CNN-LSTM

4.7.3 Σφάλματα

Το CNN-LSTM παρουσιάζει μεγαλύτερο σφάλμα κατά τις μεσημεριανές ώρες, με κορυφή στις 09.00a.m. Το συνολικό NMAE, για το θερινό τρίμηνο ανέρχεται σε 0.07663 και για το χειμερινό σε 0.098249.



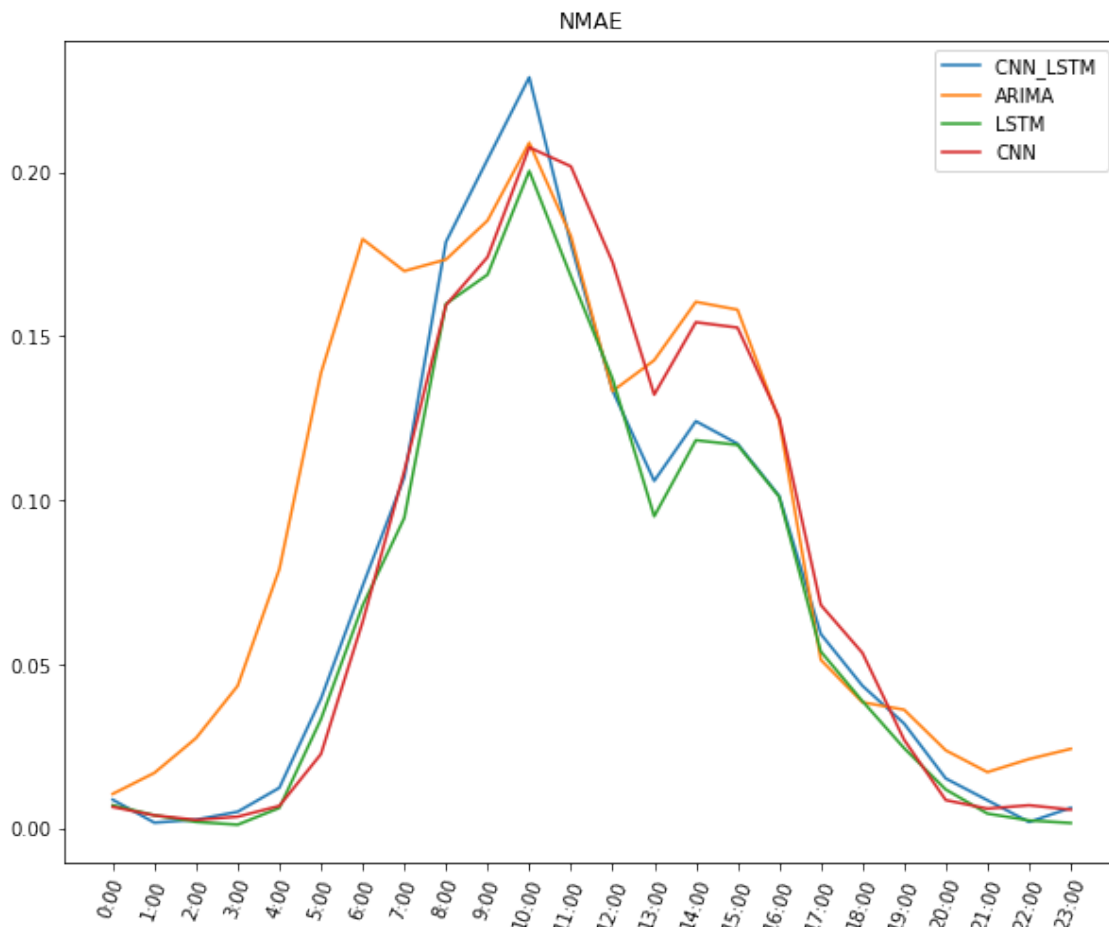
(α') Summer BC NMAE



(β') Winter MDE NMAE


4.8 Σύγκριση Μοντέλων

Σε αυτήν την ενότητα, αξιολογείται η ακρίβεια των τριών παραπάνω μοντέλων, LSTM, CNN & CNN-LSTM και ύστερα γίνεται σύγκριση με τα μοντέλα αναφοράς, Arima & Persistence. Μέσω της σύγκρισης, η παρούσα εργασία εξετάζει ποια μοντέλα πρόβλεψης είναι πιο κατάλληλα για τη δημιουργία βραχυπρόθεσμων προβλέψεων που αφορούν χρονοσειρές παραγωγής φωτοβολταϊκών. Στα διαγράμματα που ακολουθούν αναπαριστάται το ωριαίο σφάλμα NMAE για κάθε μοντέλο, για τους δυο μήνες πρόβλεψης, Μάρτιο & Αύγουστο. Το ωριαίο σφάλμα έχει προκύψει υπολογίζοντας αρχικά τα NMAE για κάθε πρόβλεψη και ύστερα παίρνοντας το μέσο όρο των σφαλμάτων ανά ώρα για κάθε μέρα του μήνα πρόβλεψης.




Σχήμα 4.26: NMAE for Summer BC

Όλα τα νευρωνικά μοντέλα ανταποκρίνονται εξαιρετικά στις ώρες χαμηλής παραγωγής, δηλαδή τις πρώτες πρωινές 00.00-05.00 & τις βραδυνές 20.00-23.00, ώρες που δεν υπάρχει ηλιοφάνεια. Αντίθετα το Arima παρουσιάζει υψηλό σφάλμα, ειδικά 00.00-05.00. Για το θερινό μήνα πρόβλεψης (Αύγουστος 2014) παρατηρούμε κορύφωση των σφαλμάτων κατά τις πρώτες ώρες ηλιοφάνειας, 09.00-12.00, με κορυφή στις 10.00. Το μοντέλο με το χαμηλότερο μέγιστο ωριαίο σφάλμα είναι το LSTM, ενώ αυτό που έχει το χειρότερο μέγιστο ωριαίο είναι το




Σχήμα 4.27: NMAE for Winter MDE

CNN-LSTM. Ωστόσο, η συνολική επίδοση των νευρωνικών είναι καλύτερη από τα μοντέλα αναφοράς. Οι παρατηρήσεις αυτές ισχύουν και στο χειμερινό μήνα πρόβλεψης, στον οποίο όμως το Arima μοντέλο έχει αρκετά καλύτερη συγκριτικά επίδοση.



Σχήμα 4.28: Forecasts for 1st, 2nd 3rd of Aug'14



Σχήμα 4.29: Forecasts for 1st, 2nd 3rd of Mar'14

Κεφάλαιο 5

Συμπεράσματα

5.1 Σύνοψη- Συμπεράσματα

Στη παρούσα διπλωματική έγινε προσπάθεια για βραχυπρόθεσμη πρόβλεψη της παραγωγής φωτοβολταϊκών.

Ο χρονικός ορίζοντας των ωριαίων προβλέψεων ήταν η επόμενη ημέρα, δηλαδή 24 προβλέψεις. Ο τρόπος που εργαστήκαμε αφορούσε πρόβλεψη χρονοσειρών, δηλαδή εκμεταλλευτήκαμε την συσχέτιση που έχουν οι παρελθοντικές παρατηρήσεις με τις επόμενες, καθώς είχαμε στη διάθεσή μας ένα έτος παραγωγής (2013-2014). Αρχικά επεξεργαστήκαμε τα δεδομένα από τα φωτοβολταϊκά πάρκα. Ορισμένα εμφάνισαν κενά στη δειγματοληψία, με αποτέλεσμα να μην είναι διαθέσιμες όλες οι τιμές της παραγωγής. Στο βαθμό που κάτι τέτοιο αποτελούσε μεμονωμένο περιστατικό δεν ήταν σημαντικό πρόβλημα, όμως, όταν υπήρχαν μεγάλα κενά διαστήματα στη δειγματοληψία, τότε το αντίστοιχο σύνολο δεδομένων χαρακτηριζόταν ακατάλληλο για επεξεργασία. Βάση αυτής της λογικής επιλέχθηκαν τα δυο βέλτιστα σετ δεδομένων που αφορούν τις περιοχές Βανςροφτ Όλοσε και Μιδδλε Δριε Εαστ. Κρίθηκε σκόπιμο να γίνει προσπάθεια για πρόβλεψη σε ένα θερινό σύνολο δεδομένων και σε ένα χειμερινό, καθώς αυτά αντιπροσωπεύουν τις ακραίες καταστάσεις παραγωγής. Τα δεδομένα κανονικοποιήθηκαν ως προς την μέγιστη ισχύ παραγωγής.

Για την πρόβλεψη των μελλοντικών τιμών των χρονοσειρών χρησιμοποιήθηκαν βαθιά νευρωνικά μοντέλα και στατιστικά μοντέλα. Συγκεκριμένα υλοποιήθηκε ένα Ολοκληρωμένο Αυτοπαλινδρομικό Μοντέλο Κινητού Μέσου Όρου (ARIMA). Για την επιλογή του βέλτιστου μοντέλου και τον καθορισμό των παραμέτρων (π, δ, χ) δοκιμάστηκαν διάφορα μοντέλα και βάση των σφαλμάτων τους επιλέξαμε το (24,0,0). Η παράμετρος δ που αφορά την τάξη διαφορίσης των δεδομένων επιλέχθηκε 0, καθώς σύμφωνα με τους ελέγχους στασιμότητας που πραγματοποιήθηκαν, τα δεδομένα ήταν επαρκώς στάσιμα και δεν χρειαζόνταν διαφορίση.

Κατόπιν σχεδιάστηκαν νευρωνικά δίκτυα για την πρόβλεψη ακολουθίας τιμών. Οι αρχιτεκτονικές που επιλέξαμε ήταν τα Αναδρομικά Νευρωνικά Δίκτυα και συγκεκριμένα τα Νευρωνικά Δίκτυα Μακράς και Βραχείας Μνήμης (LSTM) και τα Συνελικτικά Νευρωνικά Δίκτυα. Ο λόγος που επιλέχθηκαν αναδρομικά νευρωνικά είναι η ικανότητα τους να ανταποκρίνονται πολύ καλά σε πρόβλεψη ακολουθιών και σε εντοπισμό συσχετίσεων μεταξύ των προηγούμε-

νων παρατηρήσεων. Για τον λόγο αυτό χρησιμοποιούνται ευρέως σε επεξεργασία φυσικής γλώσσας. Τα LSTM προσθέτουν ουσιαστικά μνήμη στα κλασικά PNN. Η αρχιτεκτονική τους ήταν η εξής: Σχεδιάσαμε με τη βοήθεια του Keras, ακολουθιακό νευρωνικό μοντέλο με δυο επίπεδα LSTM, 100 νευρώνων. Το μοντέλο αρχικά εκπαιδεύτηκε με είσοδο τα δεδομένα του θερινού διμήνου, τα οποία χωρίστηκαν σε training set & validation set με αναλογία 80 - 20. Κατόπιν για κάθε μέρα του μήνα πρόβλεψης έγινε με επαναληπτική διαδικασία η παραγωγή των προβλέψεων. Έπειτα, δημιουργήσαμε και εκπαιδεύσαμε ένα πανομοιότυπο μοντέλο για το χειμερινό δίμηνο. Η ίδια λογική ακολουθήθηκε και στο σχεδιασμό του συνελικτικού, μιας διάστασης, νευρωνικού δικτύου ("NN 1d). Ακόμα δοκιμάστηκε ο σχεδιασμός ενός μοντέλου που θα συνδυάζει την αναδρομική με την συνελικτική αρχιτεκτονική. Πρόκειται Αντίστοιχα, γίνονται προβλέψεις για έναν θερινό μήνα και για έναν χειμερινό. Για τους μήνες αυτούς υπολογίζεται το NMAE συνολικά και ανά ώρα.

Συμπερασματικά, παρατηρούμε ότι όλα τα νευρωνικά μοντέλα ανταποκρίνονται εξαιρετικά στις ώρες χαμηλής παραγωγής, που δεν υπάρχει ηλιοφάνεια. Αντίθετα το Arima δυσκολεύεται να προβλέψει με ακρίβεια την παραγωγή για εκείνες τις ώρες. Για το θερινό μήνα πρόβλεψης παρατηρούμε κορύφωση των σφαλμάτων κατά τις πρώτες ώρες ηλιοφάνειας, με το χαμηλότερο μέγιστο ωριαίο σφάλμα να παρουσιάζει το LSTM, ενώ αυτό που έχει το χειρότερο μέγιστο ωριαίο είναι το CNN-LSTM. Ωστόσο, η συνολική επίδοση των νευρωνικών είναι καλύτερη από τα μοντέλα αναφοράς. Οι παρατηρήσεις αυτές ισχύουν και στο χειμερινό μήνα πρόβλεψης, στον οποίο όμως το Arima μοντέλο έχει αρκετά καλύτερη συγκριτικά επίδοση.

5.2 Μελλοντικές Επεκτάσεις

Η ανάγκη για πρόβλεψεις στα ζητήματα που αφορούν τις ΑΠΕ και την διεσπαρμένη παραγωγή είναι ολοένα και αυξανόμενη. Οι προβλέψεις μπορεί να είναι βραχυπρόθεσμες, μεσοπρόθεσμες και μακροπρόθεσμες, να αφορούν φορτίο, παραγωγή, καιρικές συνθήκες κτλ. Σε κάθε περίπτωση μας ενδιαφέρει η μείωση των σφαλμάτων και οι γρήγορες και ασφαλείς προβλέψεις. Οι τεχνολογίες των νευρωνικών δικτύων αποδεικνύονται χρήσιμο εργαλείο για την επίλυση αυτού του ζητήματος με νέες αρχιτεκτονικές να παρουσιάζουν ενδιαφέρον για μελέτη. Στη παρούσα διπλωματική μελετήθηκε το ζήτημα της πρόβλεψης αποκλειστικά από την σκοπία της πρόβλεψης χρονοσειρών, αγνοώντας τις παραμέτρους από τις οποίες εξαρτάται η παραγωγή των φωτοβολταϊκών. Η ενσωμάτωση δεδομένων σχετικά με αυτές, στα νευρωνικά μοντέλα, συγκεκριμένα για την ηλιακή ακτινοβολία και τη θερμοκρασία, θα είχε σίγουρα ενδιαφέρον για έρευνα.

Βιβλιογραφία

- [1] Γελεγένης Ι., Αζαόπουλος Π., 'Πηγές ενέργειας, συμβατικές και ανανεώσιμες', εκδ.Σύγχρονη εκδοτική, 2005
- [2] Αλβανού Αδαμαντία, Διπλ.εργασία, 'Συμβατικές Πηγές Ενέργειας και Σύγχρονες προκλήσεις ενεργειακής πολιτικής', τμήμα Μηχανικών Χωροταξίας & Ανάπτυξης, Θεσσαλονίκη, 2016
- [3] Σταύρος Αθ. Παπαθανασίου, Καθηγητής ΕΜΠ, 'Ανάπτυξη και προοπτικές των ανανεώσιμων πηγών ενέργειας'
- [4] <http://www.incite-itn.eu/blog/forecasting-in-the-electrical-grid/>
- [5] Παπακωνσταντίνου Χ. Κωνσταντίνος, Διπλ.Εργασία, 'Μελέτη διαστασιολόγησης και ενσωμάτωσης στο δίκτυο φωτοβολταϊκών-αποθηκευτικών συστημάτων υπό τον θεσμό της ιδιοκατανάλωσης' ΗΜΜΥ ΕΜΠ, Αθήνα, Απρίλιος 2015
- [6] www.solarpowereurope.org/wp-content/uploads/2020/06/21-SPE-GMO-report-mr.pdf?cf_id=15053
- [7] Ζγέρα Χριστίνα, 'Μοντελοποίηση και Προβλέψεις: Ανάλυση των Τιμών του Αργού Πετρελαίου (WTI) με τη Χρήση Χρονοσειρών', Μεταπτυχιακή Διατριβή, Σχολή Οικονομικών και Πολιτικών Επιστημών, Α.Π.Θ., Θεσσαλονίκη, Φεβρουάριος 2016 .
- [8] Ευάγγελος Σπηλιώτης 'Ολοκληρωμένα Αυτοπαλινδρομικά Μοντέλα Κινητού Μέσου Όρου (ARIMA)', Σημειώσεις για το μάθημα 'Τεχνικές Προβλέψεων'.
- [9] Ευθύμιος Ι. Νικολάου, 'Συγκριτική ανάλυση και εφαρμογή γραμμικών, μη-γραμμικών και νευρο-ασαφών μεθόδων, για την βραχυπρόθεσμη πρόβλεψη παραγωγής ενέργειας από αιολικά πάρκα', Διπλ. Εργασία, ΗΜΜΥ ΕΜΠ.
- [10] Μαρία Φουσταλιεράκη, 'Πρόβλεψη χρονοσειρών αέριας ρύπανσης και ενεργειακής κατανάλωσης με την χρήση ARIMA και LSTM μοντέλων', Μεταπτυχιακή Διατριβή, Τμ.Πληροφορικής, Πανεπιστήμιο Πειραιώς
- [11] Πετρίδης Στέφανος - Ευστράτιος, 'Προσδιορισμός των beat μουσικών κομματιών με μηχανική μάθηση', Διπλωματική Εργασία, ΗΜΜΥ ΕΜΠ

- [12] E. G Kardakos M. C. Alexiadis, S. I. Vagropoulos, C. K. Simoglou, P. N. Biskas, and A. G. Bakirtzis Application of Time Series and Artificial Neural Network Models in Short-term Forecasting of PV Power Generation.
- [13] Rui Zhang, Minwei Feng, Wei Zhang, Siyuan Lu, Fei Wang "Forecast of Solar Energy Production – A Deep Learning Approach", 2018 IEEE International Conference on Big Knowledge
- [14] Samanta, Mayukh "Short-Term Power Forecasting of Solar PV Systems Using Machine Learning Techniques, 2014 .
- [15] Meyers, Bennet and Júlio Hoffmann. "Short time horizon solar power forecasting." (2017).
- [16] Stylianos I. Vagropoulos, G. I. Chouliaras, E. G. Kardakos, C. K. Simoglou, A. G. Bakirtzis, Comparison of SARIMAX, SARIMA, Modified SARIMA and ANN-based Models for Short-Term PV Generation Forecasting
- [17] Phil Simon, Too Big to Ignore: The Business Case for Big Data, Wiley Publishing, 2013
- [18] Olgac, A & Karlik, Bekir. (2011). Performance Analysis of Various Activation Functions in Generalized MLP Architectures of Neural Networks. International Journal of Artificial Intelligence And Expert Systems. 1. 111-122.
- [19] D. C V. Essen and J. L. Gallant, "Neural Mechanism of Form and Motion Processing in the Primate Visual System", in *euron*, vol. 13, 1994, pp. 1-10.
- [20] S. Hochreiter and S. Schmidhuber, "Long short-term memory," in *Neural Computation*, vol. 9(8), pp 1735–1780, 1997.
- [21] A. Graves, "Supervised Sequence Labelling with Recurrent Neural Networks, Ph.D thesis, Dept. of Informatics, Technical Univ. Munich, Munich, 2014.
- [22] A. Graves, S. Fernández, F. Gomez, J. Schmidhuber, "Connectionist temporal classification: labelling unsegmented sequence data with recurrent neural networks", in *Proc. 23rd Int. Conf. on Machine learning (ICML), Pittsburgh, Pennsylvania, USA, June 25 - 29, 2006*
- [23] I. Sutskever, O. Vinyals and Q. V. Le, "Sequence to Sequence Learning with Neural Networks," arXiv:1409.3215, 2014.
- [24] D. Tran et al, "Learning spatiotemporal features with 3d convolutional networks," in *Proc IEEE Int. Conf. on Comput. Vision, (ICCV), 2015, pp. 4489- 4497.*
- [25] F. Rosenblatt, "The perceptron: a probabilistic model for information storage and organization in the brain.", in *Psychological review vol. 65, 1958, pp. 6.*

-
- [26] A. Krizhevsky, I. Sutskever and G. E. Hinton, "Imagenet classification with deep convolutional neural networks", in Advances in Neural Information Processing systems, 2012, pp. 1097-1105.
- [27] Νταβίντ Καρολίνα, Διπλ.Εργασία, "Συλλογή Μακροχρόνιων Χρονοσειρών για Παραγωγή και Αξιολόγηση Μακροπρόθεσμων Προβλέψεων", ΗΜΜΥ ΕΜΠ, Αθήνα, Φεβρουάριος 2018

Γλωσσάριο

Ελληνικός όρος

ΑΠΕ

χρονοσειρές

εκπαίδευση

νευρωνικά μοντέλα

συνελικτικό

αυτοσυσχέτιση

στασιμότητα

έξυπνα δίκτυα

πολυστρωματικό νευρωνικό δίκτυο

εμπροσθοτροφοδοτούμενο

παράθυρο

Ολοκληρωμένα Αυτοπαλινδρομικά Μοντέλα Ακέραιου Μέσου Όρου

Κανονικοποιημένο Μέσο Απόλυτο Σφάλμα Normalized Mean Absolute Error

αναδρομικό νευρωνικό δίκτυο

Αγγλικός όρος

RES

time series

training

artificial neural networks

convolutional

autocorrelation

stationarity

smart grids

multilayer perceptron

feedforward

window

ANNMA

Normalized Mean Absolute Error

recursive neural network

