



ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΙΑΣ

ΠΟΛΥΤΕΧΝΙΚΗ ΣΧΟΛΗ

ΤΜΗΜΑ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

**Ανάπτυξη μοντέλων βραχυπρόθεσμης πρόβλεψης οριακής τιμής
συστήματος για την Ελληνική χονδρεμπορική αγορά ηλεκτρικής
ενέργειας**

Μεταπτυχιακή Διπλωματική Εργασία

Σταύρος Σολδάτος

Επιβλέπων: Δημήτριος Μπαργιώτας

Φεβρουάριος 2023



ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΙΑΣ

ΠΟΛΥΤΕΧΝΙΚΗ ΣΧΟΛΗ

ΤΜΗΜΑ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ


**Ανάπτυξη μοντέλων βραχυπρόθεσμης πρόβλεψης οριακής τιμής
συστήματος για την Ελληνική χονδρεμπορική αγορά ηλεκτρικής
ενέργειας**

Μεταπτυχιακή Διπλωματική Εργασία

Σταύρος Σολδάτος

Επιβλέπων: Δημήτριος Μπαργιώτας

Φεβρουάριος 2023



UNIVERSITY OF THESSALY

SCHOOL OF ENGINEERING

DEPARTMENT OF ELECTRICAL AND COMPUTER ENGINEERING

**Development of models of short-term marginal system price
forecasting for Greek wholesale electricity market**

MSc Thesis

Stavros Soldatos

Supervisor: Dimitrios Bargiotas

February 2023

Εγκρίνεται από την Επιτροπή Εξέτασης:

Επιβλέπων

Δημήτριος Μπαργιώτας

Καθηγητής, Τμήμα Ηλεκτρολόγων Μηχανικών και Μηχανικών
Υπολογιστών, Πανεπιστήμιο Θεσσαλίας

Μέλος

Ασπασία-Καλλιόπη Δασκαλοπούλου

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

Μέλος

Φώτιος Πλέσσας

Αναπληρωτής Καθηγητής, Τμήμα Ηλεκτρολόγων Μηχανικών και
Μηχανικών Υπολογιστών, Πανεπιστήμιο Θεσσαλίας

**ΥΠΕΥΘΥΝΗ ΔΗΛΩΣΗ ΠΕΡΙ ΑΚΑΔΗΜΑΪΚΗΣ ΔΕΟΝΤΟΛΟΓΙΑΣ ΚΑΙ ΠΝΕΥΜΑΤΙΚΩΝ
ΔΙΚΑΙΩΜΑΤΩΝ**

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

Ο Δηλών

Σταύρος Σολδάτος

DISCLAIMER ON ACADEMIC ETHICS AND INTELLECTUAL PROPERTY RIGHTS

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

The Declarant

Stavros Soldatos

Ευχαριστίες

Με την περάτωση της παρούσας μεταπτυχιακής διπλωματικής εργασίας, θα ήθελα εκφράσω τις ευχαριστίες στον αείμνηστο καθηγητή Ι. Παναπακίδη και τον καθηγητή Δημήτριο Μπαργιώτα για την εμπιστοσύνη που έδειξαν στο πρόσωπό μου, την άριστη συνεργασία, τη συνεχή καθοδήγηση καθ' όλη την πορεία και τις χρήσιμες συμβουλές και υποδείξεις τους. Επιπλέον, θα ήθελα να εκφράσω την ευγνωμοσύνη μου σε όλους τους καθηγητές και συναδέλφους με τους οποίους συνεργάστηκα κατά τη διάρκεια των μεταπτυχιακών μου σπουδών. Τέλος, οφείλω ένα μεγάλο ευχαριστώ στην οικογένεια και τους φίλους μου για την αμέριστη υποστήριξη, την αγάπη και την ανεκτίμητη βοήθεια που μου παρείχαν σε όλη τη διάρκεια των σπουδών μου.

Ανάπτυξη μοντέλων βραχυπρόθεσμης πρόβλεψης οριακής τιμής συστήματος για την Ελληνική χονδρεμπορική αγορά ηλεκτρικής ενέργειας

Σταύρος Σολδάτος

Περίληψη

Στην παρούσα μεταπτυχιακή εργασία εξετάζεται η ανάπτυξη μοντέλων βραχυπρόθεσμης πρόβλεψης οριακής τιμής συστήματος (ΟΤΣ), βασισμένα σε Τεχνητά Νευρωνικά Δίκτυα (ΤΝΔ), με εφαρμογή στην Ελληνική χονδρεμπορική αγορά ηλεκτρικής ενέργειας. Αρχικά αναφέρονται κάποιες από τις βασικές θεωρίες και εργασίες σε σχέση με το θέμα. Στη συνέχεια, ακολουθεί το κυρίως μέρος της εργασίας αυτής, όπου περιγράφονται τα μοντέλα πρόβλεψης που θα αναπτύξουμε, τα οποία είναι τεχνητά νευρωνικά δίκτυα μακροχρόνιας βραχυπρόθεσμης μνήμης (LSTM), συνελκτικά (CNN) και επαναλαμβανόμενης μονάδας με πύλη (GRU). Στο τρίτο κεφάλαιο πραγματοποιείται πρόβλεψη ΟΤΣ για το έτος 2019, με το εκάστοτε νευρωνικό δίκτυο (LSTM, CNN και GRU) να εκπαιδεύεται στα έτη 2017 και 2018. Τα έτη 2017 και 2018 αποτελούν τα σύνολα εκπαίδευσης (training set), ενώ το έτος 2019 αποτελεί το σύνολο ελέγχου (test set). Στην συνέχεια παρουσιάζονται και συγκρίνονται τα αποτελέσματα που προέκυψαν από τα σενάρια και τα μοντέλα πρόβλεψης, τα οποία υλοποιήθηκαν σε ρυθμό με τις βιβλιοθήκες μηχανικής μάθησης keras-tensorflow. Στο τέταρτο κεφάλαιο γίνεται μια αποτίμηση των αποτελεσμάτων, η οποία αφορά το κατά πόσο το εκάστοτε μοντέλο κατάφερε να προβλέψει τις ΟΤΣ για το έτος 2019. Τα αποτελέσματα αυτά ευνοούν κυρίως τα LSTM και GRU μοντέλα, καθώς και τα σενάρια πιο καθαρών και συγκεκριμένων δεδομένων εισόδου. Τέλος, παρουσιάζονται προτάσεις για τις πιθανές προοπτικές εξέλιξης αυτών των μοντέλων, καθώς τα μοντέλα και τα αποτελέσματά τους, παρότι ελπιδοφόρα, σίγουρα δεν είναι βέλτιστα.

Λέξεις-κλειδιά:

Χονδρεμπορικές αγορές ηλεκτρικής ενέργειας, σύζευξη αγορών, διείσδυση των ΑΠΕ, μοντέλο προσομοίωσης των αγορών ηλεκτρισμού, μονάδες αποθήκευσης, Ελληνική αγορά ηλεκτρικής ενέργειας, βραχυπρόθεσμη πρόβλεψη της τιμής της ηλεκτρικής ενέργειας, μετάβαση από το μονοπώλιο στην ελεύθερη αγορά, μηχανική μάθηση, τεχνητά νευρωνικά δίκτυα, σφάλματα πρόβλεψης, οριακή τιμή συστήματος.

Development of models of short-term marginal system price forecasting for Greek wholesale electricity market

Stavros Soldatos

Abstract

In this thesis, the development of short-term system marginal clearing price (MCP) prediction models based on Artificial Neural Networks (ANNs), with application to the Greek wholesale electricity market, is investigated. First, some of the main theories and works related to the topic are mentioned. Then follows the main part of this paper, where the prediction models we will develop are described, which are long short-term memory (LSTM), convolutional (CNN) and recurrent gated unit (GRU) artificial neural networks. In the third chapter, MCP prediction for the year 2019 is carried out, with each neural network (LSTM, CNN and GRU) being trained in the years 2017 and 2018. The years 2017 and 2018 are the training sets, while the year 2019 is the test set. In the following, the results obtained from the scenarios and prediction models implemented in python with the keras-tensorflow machine learning libraries are presented and compared. In the fourth section an evaluation of the results is made, which concerns whether each model was able to predict the MCP for the year 2019. These results predominantly favour the LSTM and GRU models, as well as scenarios with cleaner and more specific input data. Finally, suggestions are presented on the possible prospects for the evolution of these models, as the models and their results, although promising, are certainly not optimal.

Keywords:

Wholesale electricity markets; short term electricity price forecasting; Python; simulation-optimization; predict; forecast; machine learning, artificial neural networks, marginal system price; create a model; train a model; make predictions; evaluate and improve model;

Πίνακας περιεχομένων

Ευχαριστίες.....	xiii
Περίληψη.....	xv
Abstract	xvii
Πίνακας περιεχομένων.....	xix
Κατάλογος σχημάτων.....	xxi
Κατάλογος πινάκων	xxiii
Συνοτομογραφίες.....	xxv
Κεφάλαιο 1: Εισαγωγή.....	1
1.1 Η Ελληνική αγορά ηλεκτρικής ενέργειας	2
1.1.1 Μετάβαση από το μονοπώλιο στην ελεύθερη αγορά	2
1.1.2 Συμμετέχοντες της αγοράς ηλεκτρικής ενέργειας.....	3
1.1.3 Μοντέλα οργάνωσης των αγορών ηλεκτρικής ενέργειας	4
1.1.3.1 Μοντέλο μιας Κεντρικά Οργανωμένης Αγοράς ή Κοινοπραξίας Ισχύος	6
1.1.3.2 Μοντέλο μιας Αποκεντρωμένης Αγοράς Διμερών Συμβάσεων	8
1.1.3.3 Υβριδικό Μοντέλο.....	9
1.1.4 Αξία της πρόβλεψης της τιμής της ηλεκτρικής ενέργειας	9
1.2 Βιβλιογραφική ανασκόπηση.....	11
Κεφάλαιο 2: Εισαγωγή στα μοντέλα πρόβλεψης ΟΤΣ	17
2.1 Πρόβλεψη Χρονοσειρών (TimeSeries Forecasting).....	18
2.2 Μηχανική Μάθηση.....	20
2.3 Αρχιτεκτονικές - κατηγορίες μοντέλων Νευρωνικών Δικτύων	23
2.3.1 Multilayer Perceptrons (MLPs) για χρονοσειρές.....	23
2.3.2 Συνελκτικά Νευρωνικά Δίκτυα για Χρονοσειρές (Convolutional Neural Networks for Time Series - CNNs)	26
2.3.3 Επαναλαμβανόμενα Νευρωνικά Δίκτυα για Χρονοσειρές (Recurrent Neural Networks for Time Series - RNNs) - Νευρωνικά Δίκτυα μακροχρόνιας βραχυπρόθεσμης μνήμης (Long Short Term Memory - LSTM)	28
2.3.4 ΤΝΔ επαναλαμβανόμενης μονάδας με πύλη για χρονοσειρές (Gated Recurrent Unit – GRU) for Time Series.....	31
2.3.5 Υβριδικά μοντέλα Νευρωνικών Δικτύων για Χρονοσειρές (Hybrid models of neural networks for Time Series).....	32
2.4 Σφάλματα πρόβλεψης - μέτρα αξιολόγησης της απόδοσης του συστήματος.....	33
Κεφάλαιο 3: Βραχυπρόθεσμη πρόβλεψη ΟΤΣ ηλεκτρικής ενέργειας για την ελληνική αγορά ΗΕ	35
3.1 Προεπεξεργασία των δεδομένων	36
3.2 Εφαρμογή νευρωνικών δικτύων	39
3.2.1 Εφαρμογή LSTM τεχνητών νευρωνικών δικτύων	41
3.2.2: Εφαρμογή CNN τεχνητών νευρωνικών δικτύων	50
3.2.3 Εφαρμογή GRU τεχνητών νευρωνικών δικτύων.....	59

3.3 Σχολιασμός και σύγκριση των μοντέλων.....	67
Κεφάλαιο 4: Επίλογος	69
4.1 Συμπεράσματα	69
4.2 Μελλοντικές επεκτάσεις	70
Βιβλιογραφία.....	73
Παράρτημα Α.....	77
LSTM.....	77
GRU	81
CNN	85

Κατάλογος σχημάτων

Σχήμα 1.1 Μοντέλα οργάνωσης των Ευρωπαϊκών αγορών ηλεκτρικής ενέργειας	6
Σχήμα 1.2 Καθορισμός ΟΤΣ από καμπύλες προσφοράς και ζήτησης	7
Σχήμα 2.1 Σύγκριση της δομής του ανθρώπινου νευρώνα με αυτήν ενός νευρωνικού δικτύου	22
Σχήμα 2.2 Γενική απεικόνιση ενός νευρωνικού με δύο κρυφά επίπεδα (hidden layers) ..	22
Σχήμα 2.3 Γενική απεικόνιση ενός MLP με ένα hidden layer	24
Σχήμα 2.4 Συνήθεις συναρτήσεις ενεργοποίησης	25
Σχήμα 2.5 Αρχιτεκτονική ενός CNN	27
Σχήμα 2.6 Οπτικοποίηση της αρχιτεκτονικής ενός CNN και των εσωτερικών λειτουργιών του	27
Σχήμα 2.7 Διάγραμμα της feedback λειτουργίας των RNN	28
Σχήμα 2.8 Αρχιτεκτονική ενός BI-LSTM	30
Σχήμα 2.9 Λειτουργία μιας GRU	32
Σχήμα 3.1 Συντελεστής αυτοσυσχέτισης των ΟΤΣ σε συνάρτηση με το χρόνο (σε ώρες). 38	
Σχήμα 3.2 Η αρχιτεκτονική του LSTM ΤΝΔ που υλοποιήθηκε	42
Σχήμα 3.3 Loss diagram LSTM ΤΝΔ για το σενάριο 1	43
Σχήμα 3.4 Επίδοση LSTM ΤΝΔ για το έτος 2019 στο σενάριο 1	44
Σχήμα 3.5 Loss Diagram LSTM ΤΝΔ για το σενάριο 2	44
Σχήμα 3.6 Επίδοση LSTM ΤΝΔ για το έτος 2019 στο σενάριο 2	45
Σχήμα 3.7 Loss diagram LSTM ΤΝΔ για το σενάριο 3	45
Σχήμα 3.8 Επίδοση LSTM ΤΝΔ για το έτος 2019 στο σενάριο 3	46
Σχήμα 3.9 Loss diagram LSTM ΤΝΔ για το σενάριο 4	46
Σχήμα 3.10 Επίδοση LSTM ΤΝΔ για το έτος 2019 στο σενάριο 4	47
Σχήμα 3.11 Loss diagram LSTM ΤΝΔ για το σενάριο 5	47
Σχήμα 3.12 Επίδοση LSTM ΤΝΔ για το έτος 2019 στο σενάριο 5	48
Σχήμα 3.13 Loss diagram LSTM ΤΝΔ για το σενάριο 6	48
Σχήμα 3.14 Επίδοση LSTM ΤΝΔ για το έτος 2019 στο σενάριο 6	49
Σχήμα 3.15 Αρχιτεκτονική CNN μοντέλου	51
Σχήμα 3.16 Loss diagram CNN ΤΝΔ για το σενάριο 1	52
Σχήμα 3.17 Επίδοση CNN ΤΝΔ για το έτος 2019 στο σενάριο 1	53
Σχήμα 3.18 Loss diagram CNN ΤΝΔ για το σενάριο 2	53
Σχήμα 3.19 Επίδοση CNN ΤΝΔ για το έτος 2019 στο σενάριο 2	54
Σχήμα 3.20 Loss diagram CNN ΤΝΔ για το σενάριο 3	54
Σχήμα 3.21 Επίδοση CNN ΤΝΔ για το έτος 2019 στο σενάριο 3	55
Σχήμα 3.22 Loss diagram CNN ΤΝΔ για το σενάριο 4	55
Σχήμα 3.23 Επίδοση CNN ΤΝΔ για το έτος 2019 στο σενάριο 4	56
Σχήμα 3.24 Loss diagram CNN ΤΝΔ για το σενάριο 5	56
Σχήμα 3.25 Επίδοση CNN ΤΝΔ για το έτος 2019 στο σενάριο 5	57
Σχήμα 3.26 Loss diagram CNN ΤΝΔ για το σενάριο 6	58
Σχήμα 3.27 Επίδοση CNN ΤΝΔ για το έτος 2019 στο σενάριο 6	58
Σχήμα 3.28 Αρχιτεκτονική GRU	60
Σχήμα 3.29 Loss diagram GRU ΤΝΔ για το σενάριο 1	61

Σχήμα 3.30 Επίδοση GRU ΤΝΔ για το έτος 2019 στο σενάριο 1	61
Σχήμα 3.31 Loss diagram GRU ΤΝΔ για το σενάριο 2	62
Σχήμα 3.32 Επίδοση GRU ΤΝΔ για το έτος 2019 στο σενάριο 2	62
Σχήμα 3.33 Loss diagram GRU ΤΝΔ για το σενάριο 3	63
Σχήμα 3.34 Επίδοση GRU ΤΝΔ για το έτος 2019 στο σενάριο 3	63
Σχήμα 3.35 Loss diagram GRU ΤΝΔ για το σενάριο 4	64
Σχήμα 3.36 Επίδοση GRU ΤΝΔ για το έτος 2019 στο σενάριο 4	64
Σχήμα 3.37 Loss diagram GRU ΤΝΔ για το σενάριο 5	65
Σχήμα 3.38 Επίδοση GRU ΤΝΔ για το έτος 2019 στο σενάριο 5	65
Σχήμα 3.39 Loss diagram GRU ΤΝΔ στο σενάριο 6	66
Σχήμα 3.40 Επίδοση GRU ΤΝΔ για το έτος 2019 στο σενάριο 6	66

Κατάλογος πινάκων

Πίνακας 3.1 Οι υπερπαράμετροι του LSTM ΤΝΔ	42
Πίνακας 3.2 Σφάλμα MAE για το LSTM σε όλα τα σενάρια	49
Πίνακας 3.3 Υπερπαράμετροι CNN μοντέλου	51
Πίνακας 3.4 MAE του CNN σε κάθε σενάριο	59
Πίνακας 3.5 Υπερπαράμετροι GRU	60
Πίνακας 3.6 MAE του GRU στο testing για το έτος 2019 σε κάθε σενάριο	67

Συντομογραφίες

ANN	Artificial Neural Networks
API	Application Programming Interface
BPF	BandPassFilter
CNN	Convolutional Neural Network
DAM	Day-Ahead Market
GRU	Gated Recurrent Unit
GSGP	Genetic Semantic Genetic Programming
GSO	Genetic Semantic Operator
LMP	Locational Marginal Price
LSTM	Long Short Term Memory
MAE	Mean Absolute Error
MAPE	Mean Absolute Percentage Error
MCP	Marginal Clearing Price
MLP	MultiLayer Perceptron
OTC	Over the Counter
RMSE	Root Mean Square Error
RNN	Recurrent Neural Networks
SARIMA	Seasonal Auto-Regressive Integrated Moving Average
SETAR	Self-Exciting Threshold Autoregressive
SVM	Support Vector Machine
ΑΔΜΗΕ	Ανεξάρτητος Διαχειριστής Μεταφοράς Ηλεκτρικής Ενέργειας
αΕΑΣ	Αυτόματη Εφεδρεία Αποκατάστασης Συχνότητας
ΑΠΕ	Ανανεώσιμες Πηγές Ενέργειας
ΓΠ	Γενετικός Προγραμματισμός

ΔΑΠΕΕΠ Διαχειριστής ΑΠΕ & Εγγυήσεων Προέλευσης

ΔΕΔΔΗΕ Διαχειριστής Ελληνικού Δικτύου Διανομής Ηλεκτρικής Ενέργειας

ΔΕΗ Δημόσια Επιχείρηση Ηλεκτρισμού

ΔΕΠ Διαδικασίες Ενοποιημένου Προγραμματισμού

Ε.Ε. Ευρωπαϊκή Ένωση

ΕΔΔΗΕ Ελληνικό Δίκτυο Διανομής Ηλεκτρικής Ενέργειας

ΕΔΣ Εφεδρεία Διατήρησης Συχνότητας

ΕΣΜΗΕ Ελληνικό Σύστημα Μεταφοράς Ηλεκτρικής Ενέργειας

ΕΧΕ Ελληνικό Χρηματιστήριο Ενέργειας

ΗΕ Ηλεκτρική Ενέργεια

ΚΙ Κοινοπραξία Ισχύος

ΚΟΤ Κομβική Οριακή Τιμή

ΛΑΓΗΕ Λειτουργός Αγοράς Ηλεκτρικής Ενέργειας

ΟΤΕ Οριακή Τιμή Εκκαθάρισης

ΟΤΣ Οριακή Τιμή Συστήματος

ΡΑΕ Ρυθμιστική Αρχή Ενέργειας

ΣΗΕ Σύστημα Ηλεκτρικής Ενέργειας

ΣΗΘΥΑ Συμπαράγωγή Ηλεκτρισμού και Θερμότητας Υψηλής Απόδοσης

ΣΜΕ Συμβόλαια Μελλοντικής Εκπλήρωσης

ΤΝΔ Τεχνικά Νευρωνικά Δίκτυα

ΦΟΣΕ Φορέας Σωρευτικής Εκπροσώπησης

ΧΕΑΣ Χειροκίνητη Εφεδρεία Αποκατάστασης Συχνότητας

Κεφάλαιο 1: Εισαγωγή

Τις τελευταίες δεκαετίες οι αγορές ηλεκτρικής ενέργειας έχουν γίνει πιο πολύπλοκες λόγω της σημαντικής αναδιάρθρωσης του ενεργειακού τομέα . Στην Ευρώπη, όπως και σε άλλες χώρες παγκοσμίως, η απορρύθμιση της ηλεκτρικής ενέργειας (ΗΕ) λόγω της απελευθέρωσης της αγοράς, οδήγησε σε νέες ανταγωνιστικές θέσεις μεταξύ των συμμετεχόντων της, καθώς και σε ανασφάλεια για τη μελλοντική εξέλιξη των αγορών ΗΕ [6, 7].

Σε παγκόσμιο επίπεδο, η διάπλαση της πρώτης απελευθερωμένης αγοράς ΗΕ πραγματοποιήθηκε το 1988 στη Χιλή. Στο εγχείρημα αυτό προχώρησαν και άλλες χώρες της Λατινικής Αμερικής. Η απελευθέρωση της αγοράς της ΗΕ σε ευρωπαϊκό επίπεδο υλοποιήθηκε πρωτίστως στην Αγγλία και στην Ουαλία το 1990, ενώ η απελευθέρωση της αγοράς της Νορβηγίας δημιούργησε την αρχή σημαντικών μεταμορφώσεων, διότι είχε ως αποτέλεσμα τη δημιουργία της πρώτης οργανωμένης διεθνούς αγοράς ΗΕ. Η απελευθερωμένη αγορά ΗΕ στη Νορβηγία, άρχισε να λειτουργεί το 1996, συνδέοντας τις περιφερειακές αγορές της Νορβηγίας και της Σουηδίας, και σε μεταγενέστερο χρόνο μπήκαν σε αυτήν η Δανία και η Φινλανδία. Μετά την απελευθέρωση της αγοράς της ΗΕ, η πρόβλεψη των τιμών ΗΕ έχει γίνει εξαιρετικά πολύτιμη και έχει σημαντική επίδραση στη διαπραγμάτευση της τιμής της ΗΕ [24, 6, 7].

Καθώς ένα από τα βασικά χαρακτηριστικά των αγορών της ΗΕ είναι οι μηχανισμοί τιμολόγησής τους, κάτι που μπορεί να επηρεάσει τον ανταγωνισμό και τα έσοδα των συμμετεχόντων, η ακρίβεια της πρόβλεψης των τιμών της ΗΕ μειώνει τον κίνδυνο υποεκτίμησης των εσόδων για τους συμμετέχοντες και παρέχει καλύτερη διαχείριση κινδύνου [6].

Ο τομέας της πρόβλεψης των τιμών της ΗΕ, παρόμοιος με αυτόν του οικονομικού τομέα για την πρόβλεψη των τιμών του Χρηματιστηρίου, χαρακτηρίζεται από έντονα δεδομένα, θόρυβο, μη σταθερότητα, υψηλό βαθμό αβεβαιότητας και κρυφούς συσχετισμούς. Επομένως, η πρόβλεψη των κινήσεων των τιμών στην αγορά της ΗΕ είναι αρκετά δύσκολη [6].

Οι τιμές του ηλεκτρικού ρεύματος και ιδιαίτερα οι αυξήσεις των τιμών, επηρεάζονται σημαντικά από ένα ευρύ φάσμα παραγόντων (όπως η συμφόρηση μετάδοσης, οι

διακοπές παραγωγής, οι συμμετέχοντες στην αγορά, η ζήτηση της ΗΕ, κ.α.). Οι παράγοντες αυτοί είναι δύσκολο να συσσωματωθούν σε μοντέλα πρόβλεψης τιμών ΗΕ. Πρόσφατα, έχουν προταθεί μέθοδοι πρόβλεψης τιμών ΗΕ με βάση την τεχνητή νοημοσύνη για την αντιμετώπιση των προαναφερθέντων προβλημάτων, αλλά συνεχίζουν να έχουν ελλείψεις που εμποδίζουν την επέκταση της χρήσης τους. Αυτές οι ελλείψεις περιλαμβάνουν υψηλά σφάλματα πρόβλεψης, αδυναμία αποτελεσματικής εκμετάλλευσης των χαρακτηριστικών των δεδομένων και τις υπερβολικές υπολογιστικές απαιτήσεις για την πρόβλεψη των τιμών [6].

Από την πλευρά της προσφοράς, οι τιμές που προσαρμόζουν οι παραγωγοί γίνεται με βάση τις προβλέψεις των τιμών της ΗΕ, μεγιστοποιώντας τα κέρδη τους. Από την πλευρά της ζήτησης, κάθε εταιρεία μπορεί να προγραμματίσει τη λειτουργία της σύμφωνα με τις ζώνες χαμηλών τιμών, αποφεύγοντας τις ώρες αιχμής, με αποτέλεσμα την ελαχιστοποίηση της κατανάλωσής τους [7].

1.1 Η Ελληνική αγορά ηλεκτρικής ενέργειας

Οι αγορές ΗΕ διαφέρουν από χώρα σε χώρα για διάφορους λόγους (π.χ. διαφορετικοί τρόποι παραγωγής ΗΕ). Λόγου χάρη, όταν το μερίδιο των ΑΠΕ (Ανανεώσιμες Πηγές Ενέργειας) αυξάνεται, οι τιμές τείνουν να μειώνονται [7].

Η Ελλάδα βρίσκεται σε ένα μεταβατικό στάδιο αναμόρφωσης του ενεργειακού τομέα, προσδοκώντας στην ανάπτυξη και στη λειτουργία ανταγωνιστικών και οικονομικά βιώσιμων αγορών ΗΕ. Οι αγορές αυτές θα πρέπει να διέπονται από διαφάνεια και να έχουν ως βασικούς στόχους, την ασφάλεια όσον αφορά τη λειτουργία τους, αλλά και τη διευκόλυνση της οικονομικής τους λειτουργίας.

1.1.1 Μετάβαση από το μονοπώλιο στην ελεύθερη αγορά

Με την απελευθέρωση της αγοράς της ΗΕ από μονοπωλιακή, προέκυψε ο υγιής ανταγωνισμός ο οποίος ανοίγει το δρόμο για τιμές που συμφέρουν περισσότερο, καθώς επίσης και πιο ποιοτικές υπηρεσίες για το χρήστη της ενέργειας. Πλέον καθιdrύονται εταιρείες, που ονομάζονται ανεξάρτητοι παραγωγοί, που δύναται να πωλούν και να παράγουν ενέργεια σε ανταγωνιστικές τιμές και αμερόληπτα.

Τα συστήματα διανομής και μεταφοράς ΗΕ συνεχίζουν να είναι μονοπώλια, αλλά έχει επέλθει μια αλλαγή στη νοοτροπία που διαχωρίζει την παραγωγή ή την πώληση της ΗΕ από τη μεταφορά της, η οποία οδήγησε σε ανταγωνιστικές αγορές ΗΕ.

Ο Stoft [5] υποστηρίζει ότι μια συγκεντρωτική ή μονοπωλιακή αγορά δεν μπορεί να επιτύχει τόσο την τιμολόγηση όσο το δυνατόν πλησιέστερα στο πραγματικό κόστος παραγωγής όσο και μη προσαρμοσμένα κίνητρα για την ελαχιστοποίηση του κόστους παραγωγής, σε αντίθεση με μια ελεύθερη ανταγωνιστική αγορά όπου και τα δύο μπορούν να επιτευχθούν ταυτόχρονα. Ο κρατικός έλεγχος στον τομέα της ηλεκτρικής ενέργειας παρουσίασε πολλά προβλήματα, καθώς οι εταιρείες ηλεκτρικής ενέργειας συχνά επηρεάζονταν περισσότερο από πολιτικά συμφέροντα παρά από λειτουργικά και οικονομικά κριτήρια.

Καθοριστικό ρόλο σε αυτή την πορεία, παίζουν οι παίκτες στην αγορά, οι οποίοι προσπαθούν να αυξήσουν τα κέρδη τους, ενώ οι καταναλωτές δίνουν προτεραιότητα στην οικονομική προσιτότητα, τις αξιόπιστες υπηρεσίες και τα λογικά έξοδα. Αντίθετα, οι Διαχειριστής Ανανεώσιμων Πηγών Ενέργειας και Εγγυήσεων Προέλευσης (ΔΑΠΕΕΠ), Ανεξάρτητος Διαχειριστής Μεταφοράς Ηλεκτρικής Ενέργειας (ΑΔΜΗΕ) και Ρυθμιστική Αρχή Ενέργειας (ΡΑΕ) παίζουν το ρόλο των αμερόληπτων οργανισμών που είναι επιφορτισμένοι με τη διασφάλιση των βασικών προϋποθέσεων για την αποτελεσματική λειτουργία των αγορών, με απώτερο σκοπό τον άνετο τρόπο ζωής της κοινωνίας.

1.1.2 Συμμετέχοντες της αγοράς ηλεκτρικής ενέργειας

Οι συμμετέχοντες στην αγορά, οι λεγόμενοι <<παίκτες της αγοράς>> ηλεκτρικής ενέργειας είναι μεταξύ άλλων και οι εξής:

1. Ο Παραγωγός, που παράγει και πωλεί, με μειοδοτικές διαδικασίες, ενέργεια στον ΑΔΜΗΕ. Ο παραγωγός μπορεί επίσης να πουλά και άλλες υπηρεσίες στο σύστημα ηλεκτρικής ενέργειας (ΣΗΕ) όπως άεργη ισχύ, ισχύ εφεδρείας.
2. Ο Προμηθευτής που αγοράζει από τον ΑΔΜΗΕ ενέργεια και την πουλάει στους καταναλωτές. Αυτός πρέπει να είναι και παραγωγός, υπό την ευρεία έννοια μπορεί να είναι και εισαγωγέας ενέργειας, εφόσον έχει παραγωγή στην επικράτεια της Ευρωπαϊκής Ένωσης.
3. Ο Πελάτης-Καταναλωτής, που αγοράζει ενέργεια από τους Προμηθευτές.

4. Το Δίκτυο Διανομής μέσης και χαμηλής τάσης με φορέα (ιδιοκτήτρια και διαχειρίστρια) τη ΔΕΗ, διασφαλίζοντας την ασφαλή και αξιόπιστη πρόσβαση σε αυτό από τους συμμετέχοντες, πάντα σε συμφωνία με τους όρους του δικτύου διανομής [4].
5. Το Σύστημα Μεταφοράς που περιλαμβάνει τις γραμμές υψηλής τάσης και τις εγκαταστάσεις διακίνησης ενέργειας με φορέα τον ΑΔΜΗΕ. Ο ΑΔΜΗΕ έχει στην αρμοδιότητά του, τη λειτουργία και την ανάπτυξη του συστήματος, τη συντήρησή του, την εκμετάλλευση και τη διακίνηση ενέργειας, ώστε να εξασφαλίζεται η χώρα με ΗΕ με ασφάλεια, αποδοτικότητα και αξιοπιστία [3].
6. Τη ΡΑΕ , που είναι μία ανεξάρτητη διοικητική αρχή που μεταξύ άλλων συντάσσει και εκδίδει κανόνες, γνωμοδοτεί άδειες, ελέγχει κατά πόσο πληρούνται, ελέγχει και παρακολουθεί την ομαλή λειτουργία ολόκληρης της αγοράς ΗΕ. Η όσο το δυνατόν μεγαλύτερη ένταξη παραγωγής από ΑΠΕ είναι ένας από τους πιο σημαντικούς στόχους της Ε.Ε. και αποτελεί ταυτόχρονα αρμοδιότητα της ΡΑΕ. Πλέον αυτή η αρμοδιότητα μετατράπηκε σε αποφασιστική, αφού κύριος στόχος της είναι αύξηση της παραγωγής της ΗΕ από ΑΠΕ [1].
7. Ο ΔΑΠΕΕΠ, αποσκοπώντας στην ικανοποίηση των σύγχρονων προκλήσεων στο χώρο των ΑΠΕ. Στρατηγικός στόχος του, είναι να γίνει ο κύριος πυλώνας ανάπτυξης των ΑΠΕ στη χώρα, μέσα από την εξασφάλιση και την ενδυνάμωση ενός ακέραιου επιχειρησιακά λειτουργικού πλαισίου, διασφαλίζοντας όλους του συμμετέχοντες στην προσπάθεια να επιτύχουν πιο καθαρές μορφές ενέργειας και πιο φιλικές προς το περιβάλλον.

Προϋπόθεση για έναν συμμετέχοντα, ώστε να λάβει μέρος στην αγορά, είναι να γνωρίζει ακριβώς πόση ενέργεια θα χρειαστεί και για πόσο χρονικό διάστημα. Μία υπερεκτίμηση της ηλεκτρικής ζήτησης θα οδηγούσε σε σπατάλη σημαντικών πόρων, ενώ μία υποεκτίμηση θα οδηγούσε σε αύξηση του λειτουργικού κόστους για τον προμηθευτή στην προσπάθεια να καλύψει την επιπλέον ζήτηση, αλλά και πρόβλημα στην αξιοπιστία του συστήματος.

1.1.3 Μοντέλα οργάνωσης των αγορών ηλεκτρικής ενέργειας

Τις τελευταίες δεκαετίες έχουν δημιουργηθεί διάφορες αγορές στον τομέα της ΗΕ, ανάλογα με το ρυθμιστικό πλαίσιο και την κατεύθυνση κάθε χώρας, λόγω της απελευθέρωσης που αναφέρθηκε προηγουμένως.

Στην Ελληνική αγορά ΗΕ υπάρχουν τέσσερις βασικοί τύποι αγορών σύμφωνα με τη ΡΑΕ [1]:

1. Μια από τις αγορές της ΗΕ που αναπτύχθηκε τα τελευταία 30 χρόνια είναι η Ενεργειακή Χρηματοπιστωτική Αγορά (Προθεσμιακή Αγορά), όπου συνάπτονται συμβόλαια μελλοντικής εκπλήρωσης για την εμπορία ΗΕ σε καθορισμένο χρόνο, ποσότητα και τιμή μεσοπρόθεσμα. Τα συμβόλαια αυτά γίνονται είτε διμερώς είτε μέσω ενός οργανωμένου Χρηματιστηρίου Ενέργειας.
2. Μια άλλη αγορά είναι η Αγορά Επόμενης Ημέρας, όπου γίνονται συναλλαγές για την αγορά και πώληση ΗΕ με δέσμευση παράδοσης την ημέρα D. Οι συναλλαγές αυτές πραγματοποιούνται μέσω διμερών συμβάσεων ή μέσω οργανωμένων χρηματιστηρίων ενέργειας. Η υποχρεωτική συμμετοχή επιβάλλεται στους παραγωγούς, ενώ οι υπόλοιποι συμμετέχοντες έχουν τη δυνατότητα να συμμετέχουν. Οι παραγωγοί υποβάλλουν εντολές πώλησης της διαθέσιμης ΗΕ των μονάδων τους που δεν έχει δεσμευτεί σε προηγούμενες συναλλαγές. Όλες οι συναλλαγές με φυσική παράδοση δηλώνονται σε δημοπρασία που διεξάγεται την προηγούμενη Ημέρα D-1, με στόχο την παράδοσή τους την ημέρα D. Πλεονέκτημα αυτής της αγοράς είναι ότι λειτουργεί σε πραγματικό χρόνο, με αποτέλεσμα στο τέλος της ημέρας η προσφορά να ισούται με τη ζήτηση. Έτσι δεν υπάρχει υποεκτίμηση ή υπερεκτίμηση για κάποιον από τους συμμετέχοντες και ο κίνδυνος ζημιάς ελαχιστοποιείται. Συνεπώς, με την προαναφερθείσα αγορά αυξάνεται η αξιοπιστία του συστήματος.
3. Η Ενδοημερήσια Αγορά (Intra-Day Market) επιτρέπει στους συμμετέχοντες να διαπραγματεύονται προσφορές την ημέρα της φυσικής παράδοσης D. Σκοπός της είναι η βελτίωση της ζήτησης ή της προσφοράς σε περίπτωση αποκλίσεων κοντά στον πραγματικό χρόνο παράδοσης. Η συμμετοχή είναι προαιρετική και οι συναλλαγές δημοπρατούνται μετά το κλείσιμο της αγοράς της επόμενης ημέρας.

4. Η Αγορά Εξισορρόπησης (Balancing Market) αποσκοπεί στη διόρθωση των ανισορροπιών μεταξύ ζήτησης και παραγωγής σε πραγματικό χρόνο για τη διατήρηση σταθερής και αδιάλειπτης παροχής ενέργειας στα προγραμματισμένα επίπεδα, λαμβάνοντας υπόψη τον προγραμματισμό και τις αγορές των συμμετεχόντων σε άλλες αγορές.

Η αγορά της επόμενης ημέρας (day-ahead market) είναι μία από τις κρίσιμες αγορές που μελετήθηκαν στην παρούσα διατριβή και από τη μελέτη του σχεδιασμού των ευρωπαϊκών αγορών ΗΕ εντοπίζονται τρεις γενικοί τύποι οργάνωσης (δύο ξεχωριστοί και ένας συνδυασμός), όπως απεικονίζεται στο Σχήμα 1.1.



Σχήμα 1.1 Μοντέλα οργάνωσης των Ευρωπαϊκών αγορών ηλεκτρικής ενέργειας

Οι τρεις αυτοί βασικοί τύποι οργάνωσης είναι οι εξής:

1. το μοντέλο μιας Κεντρικά Οργανωμένης Αγοράς ή Κοινοπραξίας Ισχύος (Power Pool)
2. το μοντέλος της Αποκεντρωμένης Αγοράς Διμερών Συμβάσεων
3. το Υβριδικό Μοντέλο (Hybrid Model)

Οι περισσότερες αγορές ΗΕ στην Ευρώπη μπορούν να ταξινομηθούν σε ένα από τα παραπάνω μοντέλα. Στη συνέχεια παρουσιάζονται οι αρχιτεκτονικές αυτές.


1.1.3.1 Μοντέλο μιας Κεντρικά Οργανωμένης Αγοράς ή Κοινοπραξίας Ισχύος

Η Κοινοπραξία Ισχύος (ΚΙ) είναι μια βραχυπρόθεσμη αγορά συναλλαγών ενέργειας που διαχειρίζεται τον μεγαλύτερο όγκο ημερήσιων συναλλαγών ενέργειας. Λειτουργεί ως μια κεντρικά οργανωμένη αγορά, όπου οι πωλήσεις και οι αγορές διαχειρίζονται από τον διαχειριστή της αγοράς. Όλες οι εταιρείες παραγωγής ΗΕ πρέπει να υποβάλλουν τις

προσφορές τους για την παραγωγή ενέργειας και την εφεδρεία στο διαχειριστή της αγοράς, ενώ όλοι οι καταναλωτές πρέπει να υποβάλλουν τις προσφορές τους για την ενέργεια που θα καταναλώσουν, ώστε έπειτα να συγκεντρωθούν από το διαχειριστή της αγοράς.

Παράλληλα, οι προμηθευτές υποβάλλουν προσφορές ποσότητας και τιμής για την ενέργεια που χρειάζονται, με σκοπό να επιτύχουν το χαμηλότερο κόστος από κάθε συναλλαγή. Στη συνέχεια, η αγορά σχηματίζει μια καμπύλη προσφοράς και μια καμπύλη ζήτησης με την τομή αυτών των καμπυλών να δίνει την Οριακή Τιμή Συστήματος (ΟΤΣ), η οποία είναι διαθέσιμη στο κοινό [24, 25].

Το Σχήμα 1.2 απεικονίζει τον τρόπο με τον οποίο καθορίζεται η ΟΤΣ με βάση την προσφορά και τη ζήτηση της αγοράς.



Σχήμα 1.2 Καθορισμός ΟΤΣ από καμπύλες προσφοράς και ζήτησης

Η σειρά προτεραιότητας για κάθε περίοδο κατανομής παράγεται με την ταξινόμηση των προσφορών των μονάδων παραγωγής κατά αύξουσα σειρά κόστους, με στόχο την ελαχιστοποίηση του κόστους του συστήματος. Η τιμή της οριακής προσφοράς της μονάδας που απαιτείται για την κάλυψη της προβλεπόμενης ζήτησης για μια δεδομένη περίοδο κατανομής ορίζεται ως ΟΤΣ [24]. Οι μονάδες παραγωγής που υποβάλλουν προσφορά σε τιμές υψηλότερες από το ΟΤΣ δεν κατανέμονται και συνεπώς δεν μπορούν να συμμετάσχουν στην αγορά, δημιουργώντας ανταγωνισμό μεταξύ των μονάδων παραγωγής που θα κατανεμηθούν και θα εισαχθούν με βάση την ΟΤΣ. Ομοίως, εάν οι προσφορές των προμηθευτών ή των καταναλωτών είναι χαμηλές, δε δύναται να μπούνε στην αγορά [24].

Η διαδικασία εκκαθάρισης της αγοράς περιλαμβάνει την επίλυση από τον διαχειριστή της αγοράς ενός σύνθετου προβλήματος βελτιστοποίησης της ενέργειας και των εφεδρειών, λαμβάνοντας υπόψη όλες τις υποβληθείσες προσφορές και τους περιορισμούς στη λειτουργία των μονάδων παραγωγής και του συστήματος. Μόλις επιλυθεί αυτό το πρόβλημα βελτιστοποίησης, λαμβάνονται οι εκκαθαρισμένες ποσότητες έγχυσης και απορρόφησης ΗΕ και οι τιμές εκκαθάρισης της ΚΙ [24, 25].

Εάν στο πρόβλημα βελτιστοποίησης που χρησιμοποιείται για την εκκαθάριση της αγοράς δεν περιλαμβάνει περιορισμούς του συστήματος μεταφοράς, λαμβάνεται μια ενιαία Οριακή Τιμή Εκκαθάρισης (ΟΤΕ) για κάθε ώρα της περιόδου κατανομής, η οποία είναι η τιμή αποζημίωσης που καταβάλλεται στους παραγωγούς και η τιμή χρέωσης για τους προμηθευτές φορτίου. Ωστόσο, εάν η εκκαθάριση της αγοράς υπόκειται στους περιορισμούς του δικτύου μεταφοράς, τότε λαμβάνεται μια ξεχωριστή Κομβική Οριακή Τιμή (ΚΟΤ) για κάθε έναν από τους κόμβους του συστήματος, η οποία αποτελείται από τρεις όρους: έναν όρο ενέργειας, έναν όρο που εξαρτάται από τη συμφόρηση των γραμμών μεταφοράς και έναν όρο που εξαρτάται από τις απώλειες του συστήματος [24, 25].

Στην περίπτωση της ΚΟΤ, οι χρεωστικές εγγραφές γίνονται για κάθε συμμετέχοντα στην αγορά ξεχωριστά, με βάση την ΚΟΤ που λαμβάνεται για τον κόμβο στον οποίο υποβάλλει την προσφορά του [24].

1.1.3.2 Μοντέλο μιας Αποκεντρωμένης Αγοράς Διμερών Συμβάσεων

Σε μία αποκεντρωμένη αγορά ΗΕ, οι συναλλαγές γίνονται με τη σύναψη διμερών συμβάσεων μεταξύ των συμμετεχόντων με σκοπό την παράδοση της ΗΕ σε προκαθορισμένες ποσότητες, τιμές και περιόδους. Αυτές οι συναλλαγές λαμβάνουν χώρα ηλεκτρονικά σε ανακοινώσεις ή μπορεί να γίνουν με μεσάζοντες, που έχουν ως σκοπό να εντοπίσουν κατάλληλους εταίρους για άμεσες ανταλλαγές ΗΕ. Ο προαναφερόμενος τύπος συναλλαγών είναι γνωστός με τον όρο "Εξωχρηματιστηριακά Συμβόλαια-Συναλλαγές" και προσδιορίζει τις συναλλαγές που γίνονται χωρίς κάποιον επιβλέποντα χρηματιστηρίου [24, 25].

Κύριο μειονέκτημα αυτού του μοντέλου αγορών είναι ότι συναλλαγές πραγματοποιούνται σε μεσο-μακροπρόθεσμο χρονικό διάστημα, το οποίο είναι εμπόδιο

για τη διασφάλιση της ασφάλειας του συστήματος ΗΕ. Συνεπώς, συνιστάται η λειτουργία ενός χρηματιστηρίου ταυτόχρονα με την αγορά διμερών συμβάσεων, του οποίου η συμμετοχή είναι εθελοντική μεταξύ των συμμετεχόντων και εκκαθαρίζει την αγορά βάσει μίας σειράς εκκαθάρισης των προσφορών. Σε αυτά τα χρηματιστήρια ενέργειας όπου πραγματοποιούνται συναλλαγές της επόμενης ημέρας ή και ενδοημερήσιες, είναι διαθέσιμες πλατφόρμες συναλλαγών ΗΕ που υλοποιούν δημοπρασίες κάθε μέρα κατά το μεσημέρι κυρίως ωριαία με σκοπό την παράδοση της ΗΕ την επόμενη ημέρα. Η τελική εκκαθάριση είναι αποτέλεσμα της αντιστοίχισης της προσφοράς με τη ζήτηση [24, 25].

1.1.3.3 Υβριδικό Μοντέλο

Το συγκεκριμένο μοντέλο είναι στην ουσία ο συνδυασμός των χαρακτηριστικών των δύο προαναφερθέντων μοντέλων. Εδώ ο προμηθευτής έχει τη δυνατότητα επιλογής διαπραγμάτευσης της αγοράς ΗΕ απευθείας με τους παραγωγούς μέσω διμερών συμβάσεων ή μπορεί ακόμα να αγοράσει την ΗΕ στην τρέχουσα τιμή της αγοράς. Η ευελιξία του μοντέλου έγκειται στη δημιουργία μιας ποικιλίας από υπηρεσίες και επιλογών τιμολόγησης, οι οποίες θα είναι επαρκείς για τις ατομικές ανάγκες του κάθε πελάτη.

1.1.4 Αξία της πρόβλεψης της τιμής της ηλεκτρικής ενέργειας

Η ηλεκτρική ενέργεια είναι μια κρίσιμη μορφή ενέργειας στις σύγχρονες κοινωνίες και χρησιμοποιείται ως πρωτογενής εισροή για την παραγωγή άλλων μορφών ενέργειας, όπως το πετρέλαιο, το φυσικό αέριο και ο άνθρακας. Λόγω των μοναδικών χαρακτηριστικών της, όπως η αδυναμία οικονομικής αποθήκευσης σε μεγάλες ποσότητες και οι περιορισμοί του δικτύου μεταφοράς, η ΗΕ πρέπει να παράγεται σε πραγματικό χρόνο για να διατηρείται η ισορροπία μεταξύ ζήτησης και παραγωγής. Η έλλειψη υποκατάστατου της ΗΕ ως εμπορεύματος βραχυπρόθεσμα καθιστά τη ζήτησή της εξαιρετικά ανελαστική. Ως εκ τούτου, η αγορά ΗΕ αποτελεί βασικό συστατικό της σύγχρονης οικονομίας και η πρόβλεψη των τιμών της έχει καταστεί σημαντικό μέλημα για όλους τους συμμετέχοντες στην αγορά μετά την απελευθέρωσή της.

Θα πρέπει να σημειωθεί ότι, αν και επί του παρόντος δεν υπάρχει κανένα εφαρμόσιμο ή σχετικό με την αγορά σχέδιο για την εξεύρεση υποκατάστατου της ΗΕ, η αγορά ΗΕ είναι ένα διαρκώς εξελισσόμενο και δυναμικό περιβάλλον [6,7]. Οι νόμοι του Kirchhoff υπαγορεύουν τη ροή της ΗΕ στις γραμμές του δικτύου μεταφοράς, η οποία υπόκειται σε απώλειες και σε ένα όριο της ποσότητας που μπορεί να μεταφερθεί ανά πάσα στιγμή. Το όριο αυτό εξαρτάται από τα θερμικά όρια των γραμμών μεταφοράς και τη σταθερότητα του συστήματος. Επιπλέον, μικρές διαταραχές μπορούν να προκαλέσουν σημαντικά προβλήματα στο ΣΗΕ, καθώς οι διακυμάνσεις της τάσης ή της συχνότητας μπορούν να οδηγήσουν σε διακοπές της παροχής [6, 7].

Οι βιομηχανίες ηλεκτρικής ενέργειας σε όλο τον κόσμο έχουν υποστεί απορρύθμιση, ιδιωτικοποίηση και αναδιάρθρωση μέσω της εισαγωγής του ανταγωνισμού. Αυτό έχει ως αποτέλεσμα η ΡΑΕ να μειώσει την τιμή της ΗΕ, να βελτιώσει την υπηρεσία παροχής της ΗΕ και να παράσχει σωστά επιλογή στον πελάτη. Η ακρίβεια της βραχυπρόθεσμης πρόβλεψης της ηλεκτρικής ενέργειας συνδέεται στενά με τα κέρδη της αγοράς στους συμμετέχοντες. Επομένως, η βραχυπρόθεσμη πρόβλεψη των τιμών πρέπει να εκτελεστεί με ακρίβεια, για να παρέχουν αποτελεσματικές πληροφορίες στους συμμετέχοντες της αγοράς που επιθυμούν να μεγιστοποιήσουν τα κέρδη τους [1].

Η ΟΤΣ είναι ένα σημαντικό μέρος της πληρωμής που λαμβάνουν οι παραγωγοί από την αγορά για το χρονοπρογραμματισμό των μονάδων παραγωγής. Από την πλευρά της γεννήτριας είναι πολύ σημαντικό να εκτιμηθεί ποια θα είναι η ΟΤΣ της επόμενης ημέρας, διότι μία σωστή πρόβλεψη μπορεί να βοηθήσει τους παραγωγούς να υποβάλλουν τις τιμές των μονάδων παραγωγής τόσο κοντά στην ΟΤΣ, και ως εκ τούτου, να αυξηθούν οι πωλήσεις ενός ανεξάρτητου παραγωγού ηλεκτρικής ενέργειας την επόμενη ημέρα του προγραμματισμού. Η ΟΤΣ κυμαίνεται ανάλογα με την ώρα της ημέρας, την ημέρα της εβδομάδας, της εποχής, της ζήτησης της ηλεκτρικής ενέργειας και συνολικά της κατάστασης της αγοράς [2].

Γενικά, αποφάσεις σχετικά με τη μεταφορά, την αύξηση, την επέκταση, την παραγωγή, τον σχεδιασμό και την ανταλλαγή ενέργειας μέσω των περιφερειών καθορίζονται σε μεγάλο βαθμό από τη μακροπρόθεσμη πρόβλεψη της τιμής της ηλεκτρικής ενέργειας. Το εμπόριο ενέργειας όμως μεταξύ των συμμετεχόντων της αγοράς, εξαρτάται σε μεγάλο βαθμό από τη βραχυπρόθεσμη πρόβλεψη των τιμών. Επιπλέον, με βάση την βραχυπρόθεσμη πρόβλεψη της τιμής της ΗΕ, οι αναλυτές της αγοράς αποφασίζουν για

το πιο κερδοφόρο τρόπο εκπλήρωσης των υποχρεώσεων που δεν καλύπτονται από τις μακροπρόθεσμες συμβάσεις. Η ΗΕ συμπεριφέρεται σαν χρηματιστηριακή τιμή σε κάποιες εκτάσεις και οι παραλλαγές της είναι κυμαινόμενες, κυκλικές και επηρεάζεται από πολλούς παράγοντες [1].

1.2 Βιβλιογραφική ανασκόπηση

Οι ερευνητές ασχολούνται ενεργά με την ανάπτυξη εργαλείων και αλγορίθμων για την πρόβλεψη των τιμών της ΗΕ. Στη συνέχεια ακολουθούν τα βασικότερα σημεία από τη σχετική βιβλιογραφία που μελετήθηκε στα πλαίσια της συγγραφής της παρούσας εργασίας.

Οι M. Castelli et al., [6] διερεύνησαν έναν τρόπο βελτίωσης της ακρίβειας της πρόβλεψης της ΗΕ με τη χρήση μηχανικής μάθησης, ο οποίος βασίζεται σε μία νέα προσέγγιση γενετικού προγραμματισμού (ΓΠ). Αντλώντας εμπειρικά δεδομένα από τις μεγαλύτερες ενεργειακές αγορές της Ε.Ε. όπως η Γερμανία, προτείνουν ένα μοντέλο πρόβλεψης που λαμβάνει υπόψη εξωγενείς μεταβλητές που σχετίζονται με τις καιρικές συνθήκες, τις τιμές του πετρελαίου και τις εκπομπές διοξειδίου του άνθρακα και προβλέπουν τις τιμές της ενέργειας της επόμενης ημέρας 24 ώρες μπροστά (day-ahead market). Διαπιστώθηκε ότι το προτεινόμενο μοντέλο παρέχει ακριβέστερες προβλέψεις για τις 24 ώρες μπροστά από τις υπάρχουσες μεθόδους πρόβλεψης. Η μέθοδος που χρησιμοποιούν ανήκει στον ερευνητικό τομέα της υπολογιστικής νοημοσύνης που ονομάζεται εξελικτικός υπολογισμός. Αρχικά δημιουργείται ένα πλήθος τυχαίων προγραμμάτων, στη συνέχεια ο στόχος του ΓΠ είναι να περιηγηθεί στο χώρο όλων των προγραμμάτων που μπορούν να αναπαρασταθούν με προκαθορισμένη κωδικοποίηση, αναζητώντας τα πιο κατάλληλα για την επίλυση του προβλήματος. Μετατρέπει κάθε τυχαία γενιά στοχαστικά (μέσω γενετικών χειρισμών) τους πληθυσμούς προγραμμάτων σε νέους πληθυσμούς πιθανώς πιο εφαρμόσιμων προγραμμάτων. Υπάρχουν πολλές διαφορετικές αναπαραστάσεις, αλλά η πιο συχνή είναι αυτή που κωδικοποιεί μία λύση τύπου δέντρου LISP. Παρά την επιτυχία του μοντέλου στην επίλυση σύνθετων πραγματικών προβλημάτων, οι παραδοσιακοί χειριστές ΓΠ που βασίζονται στη σύνταξη παράγουν νέα άτομα με τη λειτουργία ενός τυφλού μετασχηματισμού των γονέων. Πιο συγκεκριμένα η γνώση της παραγωγής (των εξόδων) που παράγεται από γονικά άτομα για ένα σύνολο εκπαίδευσης

παρατηρήσεων, δεν παρέχει χρήσιμες πληροφορίες για την παραγωγή που θα παράγουν (έξοδοι) τα παιδιά-άτομα. Παρόλο που ο GSGP (Γενετικός Σηματολογικός Γενετικός Προγραμματισμός) έχει αποδειχθεί αποτελεσματικός, ένα σημαντικό μειονέκτημα της χρήσης του GSO (Γενετικοί Σηματολογικοί Τελεστές) είναι ότι δεν είναι κατάλληλος για εφαρμογές όπου απαιτείται ένα αξιόπιστο μοντέλο σε σύντομο χρονικό διάστημα. Πολλαπλές μελέτες δείχνουν ότι οι GSO απαιτούν σημαντικό αριθμό επαναλήψεων για την επίτευξη βέλτιστης λύσης. Στην εργασία τους οι M. Castelli et al., προτείνουν να συμπεριληφθεί ένας τοπικός τελεστής-ερευνητής LS στον τελεστή μετάλλαξης GSM, για τη βελτίωση της ταχύτητας σύγκλισης του GSGP, που ονομάζεται LSGP. Στόχος του LSGP να επιτύχει την ίδια ακρίβεια με τον GSGP με λιγότερες επαναλήψεις. Η εκπαίδευση των μοντέλων έγινε για πλήθος δεδομένων 16 μέχρι το 2013 ενώ αυτή για τα σύνολα ελέγχου για δεδομένα μέχρι το 2015. Η μέτρηση της απόδοσης έγινε με το μέσο απόλυτο σφάλμα (MAE) μεταξύ των τιμών στόχου και των προβλεπόμενων τιμών. Λαμβάνοντας υπόψη τα αποτελέσματα στα σύνολα εκπαίδευσης και ελέγχου, το LSGP ξεπερνά το GSGP. Η ενσωμάτωση του τοπικού ανιχνευτή στον τελεστή GSM επιτρέπει στη διαδικασία GP να συγκλίνει σε μικρότερο αριθμό επαναλήψεων από ό,τι η GSPG, καθώς διευκολύνει μια πιο αποτελεσματική σύγκλιση.

Σε δεύτερη φάση πραγματοποιήθηκαν πειράματα του LSGP με άλλα συνηθισμένα μοντέλα πρόβλεψης στατιστικής και μηχανική μάθησης και συγκρίθηκαν τα αποτελέσματά τους. Πιο συγκεκριμένα έγινε σύγκριση με τις μεθόδους: γραμμική παλινδρόμηση (linear regression), συνήθης παλινδρόμηση ελαχίστου τετραγώνου (ordinary least square regression-SQ), ισotonική παλινδρόμηση (isotonic regression-ISO), δίκτυο λειτουργίας ακτινικής βάσης (radial basis function network-RBF), πολυστρωματικό perceptron εκπαιδευμένο με back propagation (multilayer perceptron trained with backpropagation-NN) και υποστήριξη φορέα με πολυωνυμικό πυρήνα βαθμού 1 και 2 (support vector machine-SVM) with polynomial kernel. Όπως προκύπτει από τα αποτελέσματα του μέσου απόλυτου σφάλματος MAE, ο αλγόριθμος LSGP ήταν ο αποδοτικότερος.

Λαμβάνοντας υπόψη το MAE στην περίπτωση εκπαίδευσης το LSGP έχει εμφανώς την καλύτερη επίδοση, αλλά με τιμές MAE που είναι συγκρίσιμες με αυτές του SVM2. Η χειρότερη τεχνική στην εκπαίδευση των μοντέλων είναι αυτή του πολυστρωματικού perceptron, ακολουθούμενη από τα μοντέλα SQ και RBF. Τα ISO, LIN και SVM παράγουν

καλύτερα αποτελέσματα από τις τελευταίες τεχνικές, αλλά χειρότερα από αυτά των LSGP και SVM2. Για την ένδειξη της καταλληλότητας μιας τεχνικής όμως, θα πρέπει να λάβουμε υπόψη και τα αποτελέσματα στην περίπτωση δοκιμής των μοντέλων. Ένα μοντέλο που είναι σημαντικά αποδοτικό σε περιπτώσεις εκπαίδευσης, αλλά δεν μπορεί να χειριστεί σωστά περιπτώσεις δοκιμής, είναι εντελώς άχρηστο σε πραγματικές εφαρμογές. Το LSGP εξακολουθεί να είναι η αποδοτικότερη τεχνική, αλλά από την άλλη πλευρά το SVM2 είναι η δεύτερη χειρότερη τεχνική, αποδεικνύοντας έτσι την κακή μέθοδο ικανότητας γενίκευσης, ότι δηλαδή τα αποτελέσματα στην περίπτωση εκπαίδευσης του SVM2 δεν συμφωνούν με αυτά στην περίπτωση δοκιμής. Η απόδοση των μηχανών διανυσμάτων υποστήριξης (SVM) στο σύνολο ελέγχου δεν είναι συνήθως τόσο καλή όσο στο σύνολο εκπαίδευσης, παρόλο που μπορούν να παραχθούν ικανοποιητικά αποτελέσματα στο τελευταίο.

Συνοψίζοντας, ο προτεινόμενος αλγόριθμος LSGP είναι ο αποτελεσματικότερος για ένα πρόβλημα πρόβλεψης, απαιτεί λιγότερες επαναλήψεις για να συγκλίνει προς λύσεις καλής ποιότητας σε σχέση με τα υπόλοιπα μοντέλα στα σύνολα εκπαίδευσης και ελέγχου, προφανώς έχει το μικρότερο MAE από τα υπόλοιπα μοντέλα, ξεπερνώντας άλλες στατιστικές τεχνικές και τεχνικές μηχανικής μάθησης που χρησιμοποιούνται συνήθως σε περιπτώσεις πρόβλεψης.

Τα Τεχνητά Νευρωνικά Δίκτυα (ΤΝΔ) έχουν χρησιμοποιηθεί επιτυχώς σε προβλήματα μηχανικής μάθησης και πιο συγκεκριμένα τα επαναλαμβανόμενα νευρωνικά δίκτυα (Recurrent Neural Networks-RNN) που προτείνονται στην εργασία των U. Ugurlu et al., [7]. Ειδικότερα, η μελέτη αυτή προτείνει τα Long Short Term Memory (LSTM) και multi-layer Gated Recurrent Units (GRU) για την εκτίμηση των τιμών της HE τα οποία συγκρίνονται με άλλα νευρωνικά δίκτυα, όπως τα συνελκτικά νευρωνικά δίκτυα (Convolutional Neural Networks-CNN), τα Artificial Neural Networks (ANN) πολλαπλών επιπέδων (βαθιά μηχανική μάθηση) αλλά και με στατιστικές μεθόδους χρονοσειρών (Markov Regime-Switching Autoregressive-MS-AR Model, Self-Exciting Threshold Autoregressive (SETAR), Seasonal Auto-Regressive Integrated Moving Average-SARIM, Naïve method). Η πρόβλεψη εκτυλίσσεται σε δεδομένα της Τουρκικής (Μπασίκτας) αγοράς HE της επόμενης ημέρας, βάσει δεδομένων από 1/1/2013 έως 21/12/2016. Εκτός από τις ενδογενείς ιστορικές τιμές (lagged values), χρησιμοποιούνται και εξωγενείς μεταβλητές για την πρόβλεψη των τιμών HE, όπως τιμές θερμοκρασίας, ζήτηση έναντι

προσφοράς και τιμές εξισορρόπησης της αγοράς, ενώ επιλέγονται διάφοροι συνδυασμοί αυτών των χαρακτηριστικών για τη μέτρηση των επιδράσεων των μεταβλητών. Για την αξιολόγηση των μοντέλων επιλέχθηκαν τα MAE (Mean Absolute Error-Μέσο Απόλυτο Σφάλμα), MAPE (Mean Absolute Percentage Error-Μέσο Απόλυτο Ποσοστιαίο Σφάλμα) και RMSE (Root Mean Square Error). Τα αποτελέσματα δείχνουν την επιτυχημένη απόδοση των νευρωνικών δικτύων εκτός του CNN σε σύγκριση με τις στατιστικές μεθόδους. Ειδικότερα την καλύτερη απόδοση έχουν τα επαναλαμβανόμενα νευρωνικά δίκτυα GRU και LSTM με χρήση της δοκιμής Diebold-Mariano. Ομοίως η μελέτη των U. Ugurlu et al., [11] συγκρίνει μία ποικιλία στατιστικών μεθόδων και ΤΝΔ αλλά για την ενδοημερήσια πρόβλεψη των τιμών της ΗΕ που εκτυλίσσεται στην Τουρκική αγορά ΗΕ. Και πάλι οι μέθοδοι των επαναλαμβανόμενων ΤΝΔ υπερτερούν των κλασσικών μεθόδων. Συγκεκριμένα η GRU επιτυγχάνει καλύτερα αποτελέσματα με μέσο απόλυτο σφάλμα MAE = 0,978 και RMSE = 1,302.

Το επιστημονικό άρθρο του R. Weron [8] προσφέρει μια λεπτομερή επισκόπηση των βασικών τεχνικών που χρησιμοποιούνται για την πρόβλεψη των τιμών ηλεκτρικής ενέργειας και παρέχει μια ολοκληρωμένη ανάλυση των υφιστάμενων μελετών όσον αφορά την περίοδο πρόβλεψης, τις μεταβλητές εισόδου και εξόδου που χρησιμοποιήθηκαν, τα επιτευχθέντα αποτελέσματα, τα σημεία δεδομένων που αναλύθηκαν, καθώς και την τεχνική προεπεξεργασία και την αρχιτεκτονική του χρησιμοποιούμενου μοντέλου. Στο άρθρο, ο Weron εξετάζει τις πιο συχνά χρησιμοποιούμενες προσεγγίσεις στην πρόβλεψη των τιμών ΗΕ, επισημαίνει τα πλεονεκτήματα και τους περιορισμούς κάθε μεθοδολογίας και εφιστά την προσοχή στις προκλήσεις και τις ευκαιρίες στον τομέα. Επιπλέον, ο συγγραφέας παρουσιάζει μια λεπτομερή ανάλυση των επιδόσεων διαφόρων μοντέλων και συγκρίνει την ακρίβειά τους, επισημαίνοντας τους παράγοντες που συμβάλλουν στη διακύμανση των επιδόσεών τους. Η παρούσα εργασία ανασκόπησης του R. Weron μπορεί να θεωρηθεί ως πολύτιμη πηγή για ερευνητές, επαγγελματίες και οποιονδήποτε ενδιαφέρεται να κατανοήσει την τρέχουσα κατάσταση στην πρόβλεψη των τιμών της ΗΕ. Πιο συγκεκριμένα χωρίζει τις κύριες μεθόδους πρόβλεψης τιμών ΗΕ σε πέντε κατηγορίες:

1. Πολυπρακτορικά μοντέλα
2. Θεμελιώδη μοντέλα

3. Μοντέλα μειωμένης μορφής
4. Στατιστικά μοντέλα
5. Μοντέλα υπολογιστικής νοημοσύνης

Τα στατιστικά μοντέλα και τα μοντέλα υπολογιστικής νοημοσύνης είναι τα πιο κοινά μοντέλα που χρησιμοποιούνται με βάση την βιβλιογραφία για την πρόβλεψη των τιμών της ΗΕ.

Τα στατιστικά μοντέλα ποικίλουν, από την πιο απλή μέθοδο Naïve [10] έως και τις πιο πολλούς μεθόδους που έχουν αναπτυχθεί [12]. Όπως ανέπτυξαν οι F. Ziel et al., [12] υπάρχουν μονομεταβλητά και πολυμεταβλητά πλαίσια για την πρόβλεψη των τιμών της ΗΕ. Στην πρόβλεψη των τιμών της ΗΕ της επόμενης ημέρας, οι συμμετέχοντες προβαίνουν σε προσφορές για τις τιμές και τις ποσότητες του επόμενου 24ωρου. Μια προσέγγιση για την πρόβλεψη των τιμών ΗΕ περιλαμβάνει την πρόβλεψη όλων των τιμών σε ένα ενιαίο μεταβλητό πλαίσιο ως χρονοσειρά για 24 ώρες στο μέλλον. Μια άλλη επιλογή είναι ένα πολυμεταβλητό πλαίσιο όπου οι τιμές προβλέπονται από 24 διαφορετικές χρονοσειρές ως προβλέψεις ενός βήματος για το μέλλον. Για παράδειγμα, οι R. Weron et al [13] χρησιμοποίησαν το μονομεταβλητό πλαίσιο για την πρόβλεψη των σκανδιναβικών δεδομένων. Ο T. Kristiansen [14] χρησιμοποίησε το πολυμεταβλητό πλαίσιο στο ίδιο σύνολο δεδομένων σε μία μελέτη παρακολούθησης, και υποστήριξε ότι η χρήση μονομεταβλητού πλαισίου αυξάνει την ακρίβεια πρόβλεψης. Ωστόσο, έρχεται σε αντίθεση με τα ευρήματα των E. Raviv et al., [15] στην ίδια αγορά, όπου συγκρίνουν τις προβλέψεις της ημερήσιας μέσης τιμής ενός βήματος μπροστά σε ένα μονομεταβλητό πλαίσιο με τις συγκεντρωτικές προβλέψεις 24 βημάτων μπροστά για τις ωριαίες τιμές. Βάσει εμπειρικών δεδομένων, δήλωσαν ότι πολυμεταβλητό πλαίσιο έχει λιγότερα σφάλματα από ένα μονομεταβλητό. Οι F. J. Nogales et al., [10], οι J. Contreras et al., [9] και οι A. J. Conejo et al., [16] παρουσίασαν ορισμένα ουσιαστικά παραδείγματα μοντέλων αυτόματης παλινδρόμησης (autoregressive models). Διαπίστωσαν ότι το Autoregressive Integrated Moving Average (ARIMA) μοντέλο κινούμενου μέσου όρου είναι χειρότερο από το μοντέλο με εξωγενείς μεταβλητές, ενώ δήλωσαν ότι η προσθήκη μιας εξωγενούς μεταβλητής δεν αυξάνει απαραίτητα την ακρίβεια της πρόβλεψης.

Σύμφωνα με τη βιβλιογραφία, υπάρχουν διάφορα μοντέλα υπολογιστικής νοημοσύνης που εφαρμόζονται για την πρόβλεψη των τιμών ΗΕ. Για παράδειγμα, οι P. Mandal et al.

[17] χρησιμοποίησαν το μοντέλο Τεχνητού Νευρωνικού Δικτύου (ANN) για να προβλέψουν τα φορτία και τις τιμές ΕΕ στην αγορά της Αυστραλίας για 1-6 ώρες μπροστά. Το MAPE αυξήθηκε από 9,75% σε 20,03% όταν η πρόβλεψη επεκτάθηκε από 1 σε 6 βήματα μπροστά. Εν τω μεταξύ, οι J. P. S. Catalao κ.ά. [18] χρησιμοποίησαν ένα νευρωνικό δίκτυο τριών επιπέδων τροφοδότησης προς τα εμπρός, το οποίο εκπαιδεύτηκε με τη μέθοδο Levenberg-Marquardt για να προβλέψει 168 βήματα μπροστά στις αγορές της Ισπανίας και της Καλιφόρνιας. Αν και παρουσίασαν αποτελέσματα για όλες τις εποχές στην ισπανική αγορά, τα αποτελέσματα είναι διαθέσιμα μόνο για την εαρινή περίοδο στην αγορά της Καλιφόρνιας, γεγονός που καθιστά δύσκολη τη σύγκριση των αποτελεσμάτων των δύο αγορών. Πρόσφατες μελέτες των D. Keles et al., [20] και των I. P. Panarakidis et al. [19], εφαρμόζουν κυρίως ANN μεθόδους. Οι πρώτοι [20] πρότειναν μοντέλα ANN με διαφορετικές μεταβλητές χρησιμοποιώντας τις μεθόδους ομαδοποίησης (clustering methods). Η μέθοδος αυτή υπερέχει των τυπικών μεθόδων Naïve και Seasonal Autoregressive Integrated Moving Average (SARIMA). Οι I. P. Panarakidis et al. [19] συνέκριναν τις προγνωστικές επιδόσεις διαφορετικών μοντέλων ANN με διάφορους αριθμούς μεταβλητών, επιπέδων και νευρώνων. Η κύρια προσέγγιση που εφάρμοσαν είναι η ομαδοποίηση των ομάδων (clustering of groups), η οποία δίνει σε ποσοστό 20% καλύτερα αποτελέσματα από τα υπόλοιπα μοντέλα.

Ενώ οι προηγούμενες μελέτες επικεντρώνονται κυρίως στην τιμή της ΗΕ της επόμενης ημέρας, η έρευνα των F. Ziel et al., [21] ασχολείται με το μέσο-μακροπρόθεσμο ορίζοντα πρόβλεψης (αρκετούς μήνες έως και 3 χρόνια).

Κεφάλαιο 2: Εισαγωγή στα μοντέλα πρόβλεψης ΟΤΣ

Πρόβλεψη είναι η εκτίμηση αβέβαιων μελλοντικών γεγονότων. Η πρόβλεψη είναι χρήσιμη για να βελτιώνονται και να λαμβάνονται αποφάσεις και σχεδιασμοί. Εάν είναι απαραίτητο να πάρουμε αποφάσεις για το μέλλον με τα δεδομένα τα οποία είναι διαθέσιμα, πρέπει να βασιστούμε σε δεδομένα που ισχύουν τώρα και σε όσο το δυνατόν πιο έγκυρες μελλοντικές προβλέψεις. Η απόφαση που θα λάβουμε θα πρέπει να βασίζεται στις μέχρι τώρα εμπειρίες, στην υπάρχουσα τεχνολογία και στις μελλοντικές εξελίξεις.

Η παρούσα μελέτη επικεντρώνεται στην τεχνητή νοημοσύνη ως τεχνική μηχανικής μάθησης λόγω του αυξανόμενου ενδιαφέροντος που παρουσιάζει σε διάφορους τομείς, όπως οι επιχειρήσεις και η υγειονομική περίθαλψη. Η τεχνητή νοημοσύνη έχει επιδείξει δυνητικά οφέλη σε πολλούς τομείς, συμπεριλαμβανομένης της αγοράς ενέργειας. Παρά την επιτυχία των μοντέλων τεχνητής νοημοσύνης στην επίτευξη συγκρίσιμων ανθρώπινων επιδόσεων σε πολύπλοκες εργασίες, θεωρούνται μαύρα κουτιά, καθώς δεν παρέχουν πληροφορίες αναφορικά με το πώς καταλήγουν στις προβλέψεις τους, όπως αναφέρεται από τους M. Castelli et. Al. [6]. Οι χρονοσειρές τιμών της αγοράς της ΗΕ χαρακτηρίζονται από υψηλή μεταβλητότητα. Αυτό οφείλεται σε πολλούς παράγοντες όπως ξαφνικές αυξήσεις ζήτησης, τιμές καυσίμων όπως π.χ. άνθρακα, προϊόντα πετρελαίου και φυσικού αερίου, λειτουργικά χαρακτηριστικά των ΑΠΕ, αξιοκρατική σειρά, ανταγωνισμό της αγοράς, ρύθμιση της αγοράς, συμφόρηση δικτύου κ.ά. Αυτή η εξάρτηση από πολλούς και διάφορους παράγοντες δημιουργεί εμπόδια στην πρόβλεψη των τιμών. Μέχρι και τα τελευταία χρόνια, οι περισσότερες αγορές ήταν δομημένες όπως τα μονοπώλια και οι τιμές υπόκεινται σε κανονιστικές ρυθμίσεις αποφασιστικότητας και ελέγχου. Ενώ όλο και περισσότερες αγορές έχουν μετατραπεί σε ανταγωνιστικές, η πρόβλεψη των τιμών θεωρείται σημαντική πτυχή στη λειτουργία του συστήματος της ΗΕ. Αυτό σχετίζεται με τον χρονοπρογραμματισμό των μονάδων, την κατανάλωση καυσίμου, την ενεργειακή εκμετάλλευση πόρων, την προσομοίωση συστημάτων ενέργειας και τη μοντελοποίηση της ζήτησης της ΗΕ. Η πρόβλεψη λοιπόν παίζει σημαντικό ρόλο στα προβλήματα μεγιστοποίησης του κέρδους. Η πρόβλεψη των τιμών μπορεί να ταξινομηθεί σε:

1. Μοντέλα Χρονοσειρών. Κατασκευάζεται μία μαθηματική συνάρτηση που συνδέει την τρέχουσα τιμή με τις προηγούμενες αξίες της. Ο χρήστης πρέπει να ορίσει τον τύπο και την παράμετρο της συνάρτησης.
2. Μοντέλα Υπολογιστικής Νοημοσύνης. Δεν υπάρχουν πληροφορίες για τη σχέση μεταξύ της υπό μελέτης παραμέτρου και των προηγούμενων τιμών της. Μέσα από μία φάση εκπαίδευσης το μοντέλο <<μαθαίνει>> τη σχέση μεταξύ των προτύπων εκπαίδευσης εισόδου και εξόδου. Αυτό οδηγεί στην αυτόματη δημιουργία της συνάρτησης που συσχετίζει τις εισόδους με τις εξόδους [6].

2.1 Πρόβλεψη Χρονοσειρών (TimeSeries Forecasting)

Μια χρονοσειρά είναι μια συλλογή παρατηρήσεων που καταγράφονται σε ίσα, διαδοχικά χρονικά διαστήματα και αντικατοπτρίζουν τις μεταβολές ενός συγκεκριμένου μεγέθους.

Οι χρονοσειρές κατηγοριοποιούνται σε δύο τύπους: συνεχείς και διακριτές. Οι συνεχείς χρονοσειρές είναι εκείνες στις οποίες το φαινόμενο παρακολουθείται συνεχώς, όπως για παράδειγμα μια καταγραφή θερμοκρασίας. Οι διακριτές χρονοσειρές, από την άλλη πλευρά, περιλαμβάνουν την καταγραφή του γεγονότος σε συγκεκριμένα χρονικά διαστήματα, όπως η ημερήσια τιμή ενός προϊόντος. [25]

Η χρονοσειρά είναι αντικείμενο μελέτης σε πολλούς επιστημονικούς κλάδους, όπως:

1. Στην οικονομία (ΑΕΠ, τιμές πετρελαίου, κ.ά.).
2. Στη φυσική (σεισμοί, μετεωρολογία).
3. Στο περιβάλλον (εκπομπές επιβλαβών αερίων κ.ά.).

Μπορούμε να διακρίνουμε δύο μοντέλα χρονοσειρών:

1. Ντετερμινιστικά μοντέλα: Προσδιορίζουν την πρόοδο ενός μεγέθους, προϋποθέτοντας ότι οι παράγοντες που επιδρούν σε αυτό είναι γνωστοί.
2. Στοχαστικά μοντέλα: Παίζει σημαντικό ρόλο ο τυχαίος παράγοντας στην πρόοδο ενός μεγέθους. Δεν επαρκεί μόνο το να γνωρίζουμε τις ιστορικές τιμές για να καθοριστούν οι μελλοντικές τιμές και την πρόοδο των χρονοσειρών τη διαμορφώνουν σε μεγάλο βαθμό και τυχαίοι παράγοντες.

Τα κύρια γνωρίσματα των χρονοσειρών είναι: η τάση, η κυκλικότητα, η εποχικότητα και οι ακραίες τιμές, που μπορεί κάποιος να τα παρατηρήσει και κατανοήσει από την οπτικοποίηση της σειράς στο πεδίο του χρόνου με τη χρήση γραφήματος. Ακολουθεί σύντομη περιγραφή τους.

Η τάση (trend), αναφέρεται στη βαθμωτή μετατόπιση της χρονοσειράς κατά μια μεγάλη χρονική περίοδο. Συμβολίζει τη γενική εικόνα της χρονοσειράς και μπορεί να καθοριστεί σαν τη μεταβολή του μέσου όρου των τιμών μακροπρόθεσμα. Δύναται να είναι πτωτική, σταθερή ή ανοδική και συχνά εκτιμάται ως μια ευθεία γραμμή ή εκθετική καμπύλη. Εάν υπάρχει τάση, τότε ο μέσος όρος των δειγμάτων (δεδομένων) και η διακύμανση μεταβάλλονται με το χρόνο. Για να είμαστε βέβαιοι αν μία χρονοσειρά παρουσιάζει ή όχι τάση, προϋπόθεση είναι η συλλογή ενός ικανού αριθμού παρατηρήσεων προκειμένου να εκτιμηθεί το ικανό μήκος περιόδου που θα πραγματοποιηθεί η αναζήτηση της τάσης. Σκοπός είναι η επιδίωξη να μην προκληθεί μπερδεμένη κατάσταση μεταξύ της τάσης και της κυκλικότητας που δύναται να παρουσιάσει μια χρονοσειρά.

Η κυκλικότητα (cyclic) αναφέρεται σε κάθε πρότυπο που εμφανίζεται άνω και κάτω της γραμμής της τάσης (trendline). Συμβολίζει μια κυματοειδή μεταβολή η οποία εμφανίζεται ανά διαστήματα που οφείλεται κυρίως σε εξωτερικούς οικονομικούς παράγοντες. Όσον αφορά τα διαστήματα να σημειωθεί ότι δεν είναι σταθερά και το μήκος τους υπερβαίνει πάντα το ένα έτος. Στις γραφικές παραστάσεις των χρονοσειρών ο κυκλικός παράγοντας είναι φανερός από τις ανόδους και τις υφέσεις μεταξύ της χαμηλότερης και της υψηλότερης στάθμης. Συναντάται βασικά σε οικονομικές χρονοσειρές που σχετίζονται με δείκτες βιομηχανίας, τιμές μετοχών και άλλα μακροοικονομικά μεγέθη, π.χ. ΑΕΠ, εξαιτίας των καθόδων και των ανόδων που εμφανίζουν οι οικονομίες.

Η εποχικότητα (seasonal) συμβολίζει μια διακύμανση ανά περιόδους της χρονοσειράς, με χρονική διάρκεια μικρότερη από ένα έτος και σταθερό μήκος. Ο εντοπισμός της διακύμανσης είναι εύκολος διότι το φαινόμενο επαναλαμβάνεται κατά τον ίδιο τρόπο χρονικά. Παρατηρείται συνήθως σε χρονοσειρές μεγεθών που επηρεάζονται σε μεγάλο βαθμό από την εποχή και η μέτρησή της είναι εύκολη με ποικίλες μεθόδους. Η διαφορά της από την κυκλικότητα βρίσκεται στη μικρότερη σταθερή διάρκεια του ενός έτους. Λόγου χάρη, η κατανάλωση του πετρελαίου θέρμανσης είναι μεγαλύτερη το χειμώνα

κάθε έτους ποσοτικά, άρα παρουσιάζει εποχικότητα. Η μεταβλητότητα της εποχικότητας εφόσον εμφανίζεται συστηματικά, μπορεί να εντοπιστεί και να αναγνωριστεί εύκολα ώστε να μετρηθεί σωστά, χωρίς να επιδρά στα δεδομένα [25].

Οι ακραίες τιμές (outliers), είναι απομονωμένες παρατηρήσεις που παρουσιάζονται στο διάγραμμα κάποιας χρονοσειράς ως απρόσμενες μεταβολές στο μοτίβο συμπεριφοράς της και οφείλονται σε κάποιο απρόοπτο γεγονός. Αυτές οι τιμές δεν μπορούν προφανώς να προβλεφθούν και επηρεάζουν τη χρονοσειρά για μικρό χρονικό διάστημα, οπότε η εκτίμηση τέτοιων παρατηρήσεων θα πρέπει να γίνεται με προσοχή [25].

Η πρόβλεψη δεδομένων χρονολογικών σειρών αποτελεί πρόκληση λόγω της χρονικής εξάρτησης μεταξύ των παρατηρήσεων. Σε αντίθεση με τα απλούστερα προβλήματα ταξινόμησης και παλινδρόμησης, τα προβλήματα χρονοσειρών απαιτούν εξειδικευμένο χειρισμό δεδομένων για τη μοντελοποίηση και την αξιολόγηση των μοντέλων. Αξιοποιώντας τη χρονική δομή, τα μοντέλα μπορούν να ενσωματώσουν τάσεις και εποχικότητα για να βελτιώσουν την απόδοση. [26]

Παραδοσιακά, οι γραμμικές μέθοδοι, όπως η Arima, είναι οι μέθοδοι που χρησιμοποιούνται για την πρόβλεψη χρονοσειρών λόγω της αποτελεσματικότητας και της ερμηνευσιμότητάς τους. Ωστόσο, αυτές οι κλασικές μέθοδοι έχουν περιορισμούς. Για παράδειγμα, δεν είναι σε θέση να χειριστούν ελλιπή ή αλλοιωμένα δεδομένα, υποθέτουν γραμμικές σχέσεις και επικεντρώνονται σε σταθερή χρονική εξάρτηση. Αντιμετωπίζουν επίσης μόνο μονομεταβλητά προβλήματα και περιορίζονται σε προβλέψεις ενός βήματος. Αντίθετα, οι μέθοδοι μηχανικής μάθησης μπορούν να αντιμετωπίσουν πιο σύνθετα προβλήματα πρόβλεψης χρονοσειρών που περιλαμβάνουν πολλαπλές μεταβλητές εισόδου, σύνθετες μη γραμμικές σχέσεις και ελλιπή δεδομένα. Επομένως, ενώ η πρόβλεψη χρονοσειρών μπορεί να είναι δύσκολη, τα μοντέλα μηχανικής μάθησης προσφέρουν πολλά υποσχόμενες λύσεις για πιο περίπλοκα και απαιτητικά προβλήματα. [26]

2.2 Μηχανική Μάθηση


Μηχανική μάθηση είναι ο τομέας της επιστήμης των υπολογιστών, οι οποίοι μπορούν να μαθαίνουν με βάση πρότυπα και προηγούμενη εμπειρία, και σαν τομέας υπάρχει από το 1950, με την δημοσίευση του A. Turing [27]. Διακρίνεται σε επιβλεπόμενη και σε μη

επιβλεπόμενη σύμφωνα με τις μεθόδους που θα εφαρμοστούν, ενώ υπάρχουν και ενδεχόμενα που μπορούν να συνδυαστούν και οι δύο. Στην επιβλεπόμενη μάθηση ο χρήστης εκπαιδεύει τον αλγόριθμο να προβλέψει τις κλάσεις με βάση γνωστά δεδομένα. Σε αντίθεση με τη μη επιβλεπόμενη μάθηση, όπου το πρόγραμμα δημιουργεί τις κλάσεις βάσει αταξινόμητων και άγνωστων δεδομένων, φτιάχνοντας ομάδες σύμφωνα με τα κοινά χαρακτηριστικά που έχουν τα δεδομένα μεταξύ τους ποσοτικά. Βασική χρήση τους είναι η ανακάλυψη προτύπων σε σύνολα δεδομένων.


Το “perceptron” προτάθηκε για πρώτη φορά το 1958 από τον Frank Rosenblatt [28] και σήμερα αποτελεί τη βασικότερη μονάδα ενός ΤΝΔ. Αρχικά αποτελούσε ένα ΤΝΔ ενός επιπέδου με σκοπό τη δυαδική ταξινόμηση ενός διανύσματος χαρακτηριστικών εισόδου. Ειδικότερα θα μπορούσαμε να πούμε ότι είναι ένας τομέας για τη διερεύνηση μοντέλων, σαν αυτό του ανθρώπινου εγκεφάλου, έχοντας τη δυνατότητα επίλυσης πολύπλοκων υπολογιστικών προβλημάτων.

Τα ΤΝΔ είναι υπολογιστικοί αλγόριθμοι. Σκοπός τους είναι η προσομοίωση της συμπεριφοράς βιολογικών συστημάτων που αποτελούνται από νευρώνες. Τα ANN είναι υπολογιστικά μοντέλα εμπνευσμένα από τα κεντρικά νευρικά συστήματα των ζώων. Είναι ικανά για μηχανική μάθηση καθώς και για αναγνώριση προτύπων. Παρουσιάζονται ως συστήματα διασυνδεδεμένων νευρώνων που μπορούν να υπολογίζουν τιμές από εισόδους.

Ένα νευρωνικό δίκτυο είναι ένας προσανατολισμένος γράφος. Αποτελείται από κόμβους που στη βιολογική αναλογία αντιπροσωπεύουν νευρώνες, οι οποίοι συνδέονται με τόξα. Αντιστοιχούν σε δενδρίτες και συνάψεις. Κάθε τόξο συνδέεται με ένα βάρος ενώ σε κάθε κόμβο εφαρμόζει τις τιμές που λαμβάνει ως είσοδο ο κόμβος και ορίζει συνάρτηση ενεργοποίησης κατά μήκος των εισερχόμενων τόξων, προσαρμοσμένη από τα βάρη των τόξων. Στα Σχήματα 2.1 και 2.2 παρουσιάζεται η βασική δομή ενός νευρωνικού δικτύου.



Σχήμα 2.1 Σύγκριση της δομής του ανθρώπινου νευρώνα με αυτήν ενός νευρωνικού δικτύου.



Σχήμα 2.2 Γενική απεικόνιση ενός νευρωνικού με δύο κρυφά επίπεδα (hidden layers)

Μια γενική απεικόνιση ενός νευρωνικού με δύο κρυφά επίπεδα (hidden layers) περιλαμβάνει:

1. Επίπεδο εισόδου — Αρχικό επίπεδο για τα δεδομένα εισόδου.
2. Κρυφά επίπεδα — Ενδιάμεσα επίπεδα όπου πραγματοποιούνται όλοι οι υπολογισμοί.
3. Επίπεδο εξόδου — Το αποτέλεσμα που παράγεται με βάση την είσοδο.

Οι υπολογισμοί σε ένα νευρωνικό δίκτυο παρουσιάζονται με τις ακόλουθες εξισώσεις:

$$f(x) = \sigma(WTx + b) \quad (2.1)$$

όπου “WT” είναι ο πίνακας με τα βάρη, “x” είναι η είσοδος, “b” είναι μία σταθερά (bias) και «σ» είναι η συνάρτηση ενεργοποίησης. Στην περίπτωση του “perceptron” του Frank Rosenblatt, η συνάρτηση ενεργοποίησης ήταν η βηματική και το b ήταν το κατώφλι:

$$\begin{aligned} f(x) &= 1, b + WT X > 0 \text{ ή} \\ f(x) &= 0, \text{αλλού} \end{aligned} \quad (2.2)$$


Η διαδικασία εκπαίδευσης ενός μοντέλου περιλαμβάνει τον προσδιορισμό της απόκλισης μεταξύ των πραγματικών τιμών και των προβλεπόμενων τιμών και την ανάλογη προσαρμογή των βαρών. Μια πρόκληση στην τεχνητή νοημοσύνη είναι η μοντελοποίηση χρονικά ευαίσθητων συστημάτων. Τα επαναλαμβανόμενα νευρωνικά δίκτυα (RNN) μπορούν να χειριστούν αυτό το ζήτημα ενσωματώνοντας ανατροφοδότηση μεταξύ των καταστάσεων, καθιστώντας τα αποτελεσματικά στη μοντελοποίηση δυναμικών συστημάτων και προσδίδοντάς τους την ικανότητα να θυμούνται παρελθούσες εισόδους. Ωστόσο, τα απλά RNN δυσκολεύονται να μοντελοποιήσουν τις μακροπρόθεσμες εξαρτήσεις, περιορισμός που ξεπερνιέται από τα δίκτυα μακράς βραχυπρόθεσμης μνήμης (LSTM). Ένας άλλος τύπος LSTM, τα αμφίδρομα LSTM, όχι μόνο λαμβάνουν υπόψη τις παρελθούσες καταστάσεις αλλά και τις μελλοντικές καταστάσεις.

2.3 Αρχιτεκτονικές - κατηγορίες μοντέλων Νευρωνικών Δικτύων

Σε αυτή την ενότητα θα περιγράψουμε κάποιες από τις βασικές αρχιτεκτονικές ΤΝΔ που χρησιμοποιούνται για την πρόβλεψη των τιμών της HE [26].

2.3.1 Multilayer Perceptrons (MLPs) για χρονοσειρές

Το πολυστρωματικό perceptron (MLP) είναι ένας τύπος νευρωνικού δικτύου πρόωσης. Αποτελείται από τρία επίπεδα: το επίπεδο εισόδου, το επίπεδο εξόδου και το κρυφό επίπεδο, όπως φαίνεται στο Σχήμα 2.3. Το στρώμα εισόδου δέχεται το σήμα εισόδου προς επεξεργασία. Το στρώμα εξόδου είναι υπεύθυνο για εργασίες όπως η ταξινόμηση και η πρόβλεψη. Η υπολογιστική ισχύς του MLP προέρχεται από έναν αυθαίρετο αριθμό κρυφών επιπέδων που τοποθετούνται μεταξύ των επιπέδων εισόδου και εξόδου. Όπως και σε ένα δίκτυο τροφοδότησης, τα δεδομένα ρέουν μονόδρομα από το επίπεδο εισόδου στο επίπεδο εξόδου. Για την εκπαίδευση των νευρώνων του MLP χρησιμοποιείται ο αλγόριθμος μάθησης backpropagation. Τα MLP μπορούν να προσεγγίσουν οποιαδήποτε συνεχή συνάρτηση και μπορούν να επιλύσουν προβλήματα που δεν είναι γραμμικά διαχωρίσιμα. Τα MLP χρησιμοποιούνται κυρίως για την προσέγγιση προτύπων, την πρόβλεψη, την ταξινόμηση και την αναγνώριση. Στο Σχήμα 2.3 απεικονίζεται ένα γενικό MLP με ένα hiddenlayer.



Σχήμα 2.3 Γενική απεικόνιση ενός MLP με ένα hidden layer

Οι υπολογισμοί που λαμβάνουν χώρα σε κάθε νευρώνα στο στρώμα εξόδου και στο κρυφό στρώμα είναι οι εξής:

$$o(x) = G(b(2) + W(2)h(x)) \quad (2.3)$$

$$h(x) = \Phi(x) = s(b(1) + W(1)x) \quad (2.4)$$

με διανύσματα προκατάληψης $b(1)$, $b(2)$, πίνακες βαρών $W(1)$, $W(2)$ και συναρτήσεις ενεργοποίησης G και s . Το σύνολο των παραμέτρων προς εκμάθηση είναι το σύνολο $\theta =$

$\{W(1), b(1), W(2), b(2)\}$. Τυπικές επιλογές για το s περιλαμβάνουν ως τις πιο συνήθεις συναρτήσεις ενεργοποίησης:

1. τη συνάρτηση $\tanh$ με

$$\tanh(x) = (e^x - e^{-x}) / (e^x + e^{-x}) \quad (2.5)$$


2. τη λογιστική σιγμοειδή συνάρτηση, με

$$\text{sigmoid}(x) = 1 / (1 + e^{-x}) \quad (2.6)$$

3. την ανορθωμένη γραμμική μονάδα (rectified linear unit ή ReLU), με

$$\text{relu}(x) = \max(0, x) \quad (2.7)$$

Στο Σχήμα 2.4 φαίνονται αυτές οι συναρτήσεις ενεργοποίησης, καθώς και άλλες συνήθειες:

Name	Plot	Equation	Derivative
Identity		$f(x) = x$	$f'(x) = 1$
Binary step		$f(x) = \begin{cases} 0 & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases}$	$f'(x) = \begin{cases} 0 & \text{for } x \neq 0 \\ ? & \text{for } x = 0 \end{cases}$
Logistic (a.k.a Soft step)		$f(x) = \frac{1}{1 + e^{-x}}$	$f'(x) = f(x)(1 - f(x))$
TanH		$f(x) = \tanh(x) = \frac{2}{1 + e^{-2x}} - 1$	$f'(x) = 1 - f(x)^2$
ArcTan		$f(x) = \tan^{-1}(x)$	$f'(x) = \frac{1}{x^2 + 1}$
Rectified Linear Unit (ReLU)		$f(x) = \begin{cases} 0 & \text{for } x < 0 \\ x & \text{for } x \geq 0 \end{cases}$	$f'(x) = \begin{cases} 0 & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases}$
Parametric Rectified Linear Unit (PReLU) [2]		$f(x) = \begin{cases} \alpha x & \text{for } x < 0 \\ x & \text{for } x \geq 0 \end{cases}$	$f'(x) = \begin{cases} \alpha & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases}$
Exponential Linear Unit (ELU) [3]		$f(x) = \begin{cases} \alpha(e^x - 1) & \text{for } x < 0 \\ x & \text{for } x \geq 0 \end{cases}$	$f'(x) = \begin{cases} f(x) + \alpha & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases}$
SoftPlus		$f(x) = \log_e(1 + e^x)$	$f'(x) = \frac{1}{1 + e^{-x}}$

Σχήμα 2.4 Συνήθειες συναρτήσεις ενεργοποίησης

Τα απλά νευρωνικά δίκτυα πρόσθιας διάδοσης (Feed-Forward Neural Networks), όπως το MLP, μπορούν να εκτιμήσουν τη συνάρτηση που αντιστοιχίζει τις μεταβλητές εισόδου στις μεταβλητές εξόδου σε μια χρονοσειρά. Τα Feed-Forward Neural Networks είναι ιδιαίτερα πολύτιμα για χρονοσειρές για διάφορους λόγους. Πρώτον, είναι ανθεκτικοί στο θόρυβο, γεγονός που τους καθιστά χρήσιμους για την αντιμετώπιση ελλιπών δεδομένων. Δεύτερον, είναι μη γραμμικοί και μπορούν να μάθουν γραμμικές και μη γραμμικές σχέσεις. Τα νευρωνικά δίκτυα μπορούν επίσης να χειριστούν πολυμεταβλητές εισροές και προβλέψεις πολλαπλών βημάτων. Ωστόσο, σε σύγκριση με τα επαναλαμβανόμενα νευρωνικά δίκτυα, τα απλά νευρωνικά δίκτυα πρόσθιας διάδοσης έχουν το μειονέκτημα ότι απαιτούν να καθοριστεί εκ των προτέρων η χρονική εξάρτηση. Αυτή η εξάρτηση είναι συχνά άγνωστη και πρέπει να προσδιοριστεί μέσω ανάλυσης [26].


2.3.2 Συνελικτικά Νευρωνικά Δίκτυα για Χρονοσειρές (Convolutional Neural Networks for Time Series - CNNs)

Τα συνελικτικά νευρωνικά δίκτυα (CNN) είναι ένας τύπος νευρωνικού δικτύου που είναι ιδιαίτερα ευέλικτο όσον αφορά τον χειρισμό δεδομένων εικόνας. Έχουν επιδείξει αξιοσημείωτη επιτυχία στον τομέα της όρασης υπολογιστών, επιτυγχάνοντας κορυφαία αποτελέσματα σε εργασίες όπως η ταξινόμηση εικόνων και ο εντοπισμός αντικειμένων και λεζάντες, μεταξύ άλλων. Τα CNN λειτουργούν απευθείας στα ακατέργαστα δεδομένα, όπως οι τιμές των εικονοστοιχείων, αντί για προκαθορισμένα χαρακτηριστικά, επιτρέποντάς τους να μαθαίνουν τα σχετικά χαρακτηριστικά απευθείας από τα ακατέργαστα δεδομένα. Αυτή η προσέγγιση ονομάζεται μάθηση αναπαράστασης, όπου τα CNN μπορούν να εξάγουν αυτόματα χαρακτηριστικά που είναι σημαντικά για το συγκεκριμένο πρόβλημα, ανεξάρτητα από τον τρόπο με τον οποίο εμφανίζονται στα δεδομένα εισόδου. Αυτός ο τύπος εξαγωγής χαρακτηριστικών είναι γνωστός ως μετασχηματισμός ή αναλλοίωτη παραμόρφωση.


Τα CNN συνδυάζουν τρεις αρχιτεκτονικές ιδέες για να εξασφαλίσουν κάποιο βαθμό της μετατόπισης ή της αμετάβλητης παραμόρφωσης: τοπικοί δείκτες, κοινά βάρη και μερικές φορές χωρική ή χρονική υποδειγματοληψία.

Η μεγαλύτερη απόδοση των CNN έγκειται στην ικανότητα της αυτόματης εκμάθησης, εξαγωγής και απόσταξης χρήσιμων χαρακτηριστικών από τα ακατέργαστα δεδομένα

εισόδου και μπορούν να εφαρμοστούν σε προβλήματα πρόβλεψης χρονοσειρών. Μία ακολουθία παρατηρήσεων μπορεί να αντιμετωπιστεί σαν μία μονοδιάστατη εικόνα που ένα μοντέλο CNN μπορεί να διαβάσει και να αποστάξει τα πιο σημαντικά στοιχεία. Στα Σχήματα 2.5 και 2.6 φαίνεται η αρχιτεκτονική ενός CNN:



Σχήμα 2.5 Αρχιτεκτονική ενός CNN



Σχήμα 2.6 Οπτικοποίηση της αρχιτεκτονικής ενός CNN και των εσωτερικών λειτουργιών του


Τα CNNs λαμβάνουν τα οφέλη των MLPs για την πρόβλεψη χρονοσειρών, δηλαδή την υποστήριξη πολλαπλών μεταβλητών εισόδου, πολλαπλών μεταβλητών εξόδου και την

εκμάθηση αυθαίρετων-τυχαίων, αλλά συγχρόνως πολύπλοκων λειτουργικών σχέσεων. Η διαφορά με τα MLPs είναι ότι δεν απαιτούν από το μοντέλο να μάθει άμεσα-απευθείας από παρατηρήσεις καθυστέρησης. Αντί γι'αυτό, το μοντέλο μπορεί να μάθει μία αναπαράσταση από μία μεγάλη ακολουθία εισόδου, η οποία είναι πιο σχετική για το πρόβλημα πρόβλεψης [7,26].

2.3.3 Επαναλαμβανόμενα Νευρωνικά Δίκτυα για Χρονοσειρές (Recurrent Neural Networks for Time Series - RNNs) - Νευρωνικά Δίκτυα μακροχρόνιας βραχυπρόθεσμης μνήμης (Long Short Term Memory - LSTM)

Ένα RNN είναι ένα συγκεκριμένο είδος τεχνητού νευρωνικού δικτύου που έχει σχεδιαστεί για να χειρίζεται δεδομένα χρονοσειρών ή διαδοχικές πληροφορίες. Σε αντίθεση με τα συμβατικά νευρωνικά δίκτυα πρόωσης που επεξεργάζονται ανεξάρτητα σημεία δεδομένων, τα RNN έχουν προσαρμοστεί για να χειρίζονται ακολουθίες όπου ένα σημείο δεδομένων εξαρτάται από το προηγούμενο σημείο δεδομένων. Αυτό επιτυγχάνεται μέσω του χαρακτηριστικού "μνήμης" των RNN που τους επιτρέπει να αποθηκεύουν και να χρησιμοποιούν πληροφορίες από προηγούμενες εισόδους για να προβλέπουν τις επόμενες εξόδους της ακολουθίας.

Ένα απλό RNN έχει ένα βρόχο ανάδρασης όπως φαίνεται στο πρώτο διάγραμμα του Σχήματος 2.7. Ο βρόχος ανατροφοδότησης B μπορεί να ξετυλιχθεί σε 3 χρονικά βήματα για να παραχθεί το δεύτερο δίκτυο του Σχήματος 2.7. Φυσικά, είναι δυνατό να διαφοροποιηθεί η αρχιτεκτονική έτσι ώστε το δίκτυο να ξετυλίγει χρονικά βήματα.



Σχήμα 2.7 Διάγραμμα της feedback λειτουργίας των RNN

Τα RNN έχουν διάφορα πλεονεκτήματα όπως:

1. Δυνατότητα χειρισμού δεδομένων ακολουθίας.
2. Δυνατότητα χειρισμού εισόδων διαφορετικού μήκους.
3. Δυνατότητα αποθήκευσης ή "απομνημόνευσης" ιστορικών πληροφοριών.

Τα μειονεκτήματα είναι τα εξής:

1. Ο υπολογισμός μπορεί να είναι πολύ αργός.
2. Το δίκτυο δεν λαμβάνει υπόψη τις μελλοντικές εισροές για τη λήψη αποφάσεων.
3. Πρόβλημα εξαφανιζόμενης κλίσης, όπου οι κλίσεις που χρησιμοποιούνται για τον υπολογισμό της ενημέρωσης των βαρών μπορεί να φτάσουν πολύ κοντά στο μηδέν εμποδίζοντας το δίκτυο να μάθει νέα βάρη. Όσο βαθύτερο είναι το δίκτυο, τόσο πιο έντονο είναι αυτό το πρόβλημα.


Τα επαναλαμβανόμενα νευρωνικά δίκτυα (RNN), συμπεριλαμβανομένου του δικτύου μακράς βραχυπρόθεσμης μνήμης (LSTM), είναι ένας τύπος νευρωνικού δικτύου που έχει τη μοναδική ικανότητα να χειρίζεται εγγενώς δεδομένα εισόδου που αποτελούνται από ακολουθίες παρατηρήσεων. Αυτή η εγγενής υποστήριξη των ακολουθιών αποτελεί κρίσιμο πλεονέκτημα των RNN για εργασίες χρονοσειρών για τους ακόλουθους λόγους:

1. Εγγενής υποστήριξη ακολουθιών (Native Support for Sequences): Τα RNN μπορούν να μοντελοποιήσουν άμεσα ακολουθίες δεδομένων εισόδου. Προσθέτοντας μια διάσταση ακολουθίας στη συνάρτηση που προσεγγίζεται, το δίκτυο μπορεί να μάθει μια συνάρτηση απεικόνισης που απεικονίζει μια ακολουθία εισόδων σε μια έξοδο. Τα LSTM μπορούν να επιλύσουν πολλές εργασίες χρονοσειρών χρησιμοποιώντας δίκτυα τροφοδότησης με χρονικά παράθυρα σταθερού μεγέθους. Αυτά τα δίκτυα μπορούν να μάθουν αυτόματα τη χρονική εξάρτηση στα δεδομένα.
2. Μαθημένη χρονική εξάρτηση (Learned Temporal Dependence): Τα RNN μπορούν να μάθουν το πιο σχετικό πλαίσιο από τις παρατηρήσεις εισόδου για την πρόβλεψη της εξόδου και αυτό το πλαίσιο μπορεί να ενημερώνεται δυναμικά καθώς επεξεργάζονται νέες εισόδους. Το μοντέλο μαθαίνει ποιες παρατηρήσεις έχουν παρατηρηθεί στο παρελθόν και πώς σχετίζονται με την πρόβλεψη. Εκτός από την

εκμάθηση μιας αντιστοίχισης από τις εισόδους στις εξόδους, το μοντέλο μαθαίνει ποιο πλαίσιο από την ακολουθία εισόδου είναι χρήσιμο για την αντιστοίχιση και πώς αυτό το πλαίσιο μπορεί να ενημερώνεται δυναμικά καθώς επεξεργάζεται νέα είσοδος. Επειδή τα RNN μπορούν να μάθουν τις μακροπρόθεσμες συσχετίσεις σε μια ακολουθία, δεν απαιτούν ένα προκαθορισμένο χρονικό παράθυρο και μπορούν να μοντελοποιήσουν με ακρίβεια πολύπλοκες πολυμεταβλητές ακολουθίες [7, 26].

Τα LSTM σχεδιάστηκαν για να αντιμετωπίσουν το πρόβλημα της εξαφανιζόμενης κλίσης στα RNN. Τα LSTM χρησιμοποιούν τρεις πύλες που ονομάζονται πύλη εισόδου, πύλη εξόδου και πύλη λήθης. Αυτές οι πύλες καθορίζουν ποιες πληροφορίες θα διατηρηθούν. Η αμφίδρομη μακροπρόθεσμη βραχυπρόθεσμη μνήμη (bi-LSTM) είναι μια τεχνική που επιτρέπει στα νευρωνικά δίκτυα να έχουν πληροφορίες σχετικά με την ακολουθία και προς τις δύο κατευθύνσεις: προς τα πίσω (από το μέλλον στο παρελθόν) και προς τα εμπρός (από το παρελθόν στο μέλλον).

Σε αντίθεση με την κανονική LSTM που επεξεργάζεται την είσοδο μόνο προς μία κατεύθυνση, είτε προς τα εμπρός είτε προς τα πίσω, η bi-LSTM επεξεργάζεται την είσοδο και προς τις δύο κατευθύνσεις, γεγονός που επιτρέπει τη διατήρηση τόσο των πληροφοριών του παρελθόντος όσο και του μέλλοντος. Στο Σχήμα 2.8, μπορούμε να δούμε τη ροή των πληροφοριών από τα προς τα πίσω και τα προς τα εμπρός στρώματα.



Σχήμα 2.8 Αρχιτεκτονική ενός BI-LSTM


Το BI-LSTM χρησιμοποιείται συνήθως όταν απαιτείται η αλληλουχία σε αλληλουχία εργασιών. Αυτό το είδος δικτύου μπορεί να χρησιμοποιηθεί σε μοντέλα ταξινόμησης κειμένου, αναγνώρισης ομιλίας και πρόβλεψης.

2.3.4 ΤΝΔ επαναλαμβανόμενης μονάδας με πύλη για χρονοσειρές (Gated Recurrent Unit – GRU) for Time Series

Το GRU, που εισήχθη από τους Cho et al., το 2014, στοχεύει στην επίλυση του προβλήματος της εξαφανιζόμενης κλίσης, το οποίο εμφανίζεται σε ένα τυπικό ανακυκλούμενο νευρωνικό δίκτυο. Το GRU μπορεί επίσης να θεωρηθεί ως παραλλαγή του LSTM, επειδή και τα δύο έχουν σχεδιαστεί με παρόμοιο τρόπο και, σε ορισμένες περιπτώσεις, παράγουν εξίσου εξαιρετικά αποτελέσματα. Τα GRU είναι βελτιωμένη έκδοση του τυπικού αναδρομικού νευρωνικού δικτύου [41].

Για την επίλυση του προβλήματος της εξαφανιζόμενης κλίσης ενός τυπικού RNN, το GRU χρησιμοποιεί, τα λεγόμενα, πύλη ενημέρωσης και πύλη επαναφοράς. Βασικά, πρόκειται για δύο διανύσματα που αποφασίζουν ποιες πληροφορίες πρέπει να περάσουν στην έξοδο. Το ιδιαίτερο σε αυτά είναι ότι μπορούν να εκπαιδευτούν ώστε να διατηρούν πληροφορίες από πολύ παλιά, χωρίς να τις ξεπλένουν μέσα στο χρόνο ή να αφαιρούν πληροφορίες που είναι άσχετες με την πρόβλεψη.

Τόσο η GRU όσο και η LSTM περιλαμβάνουν έναν μηχανισμό πύλης για τη διαχείριση της ροής πληροφοριών σε πολλαπλά χρονικά βήματα, όπως η μνήμη σε διαφορετικά πλαίσια. Ο στόχος είναι να καθοριστεί ποιες πληροφορίες του παρελθόντος θα πρέπει να διατηρηθούν και ποιες θα πρέπει να αγνοηθούν. Η GRU το υλοποιεί αυτό μέσω των πυλών ενημέρωσης και επαναφοράς, οι οποίες είναι ξεχωριστές μεταξύ τους. Κάθε μονάδα είναι σε θέση να μάθει πώς να παρακολουθεί τις εξαρτήσεις σε διαφορετικές χρονικές κλίμακες, όπως απεικονίζεται στο Σχήμα 2.9.



Σχήμα 2.9 Λειτουργία μιας GRU

Οι μονάδες GRU και LSTM χρησιμοποιούν πύλες για τη ρύθμιση της ροής πληροφοριών, επιτρέποντάς τους να καταγράφουν εξαρτήσεις σε διαφορετικές χρονικές κλίμακες. Οι βραχυπρόθεσμες εξαρτήσεις τείνουν να έχουν ενεργές πύλες επαναφοράς, ενώ οι μακροπρόθεσμες εξαρτήσεις έχουν πιο ενεργές πύλες ενημέρωσης.

Το πρόβλημα της εξαφανιζόμενης κλίσης, όπου οι κλίσεις γίνονται πολύ μικρές και εξαφανίζονται, μετριάζεται από τον μηχανισμό πυλών στις μονάδες GRU και LSTM.

Οι πύλες επιτρέπουν τη διατήρηση των πληροφοριών στη μνήμη για όσο χρονικό διάστημα χρειάζεται και την ενημέρωσή τους μόνο όταν είναι απαραίτητο. Η χρήση ενός συνδυασμού πυλών επιτρέπει στο δίκτυο να θυμάται τις κλίσεις ανεξάρτητα από το πόσο βαθύ είναι το νευρωνικό δίκτυο ή η ακολουθία εισόδου.

Το σφάλμα είναι προσθετικό και όχι πολλαπλασιαστικό, γεγονός που συμβάλλει στη διατήρησή του σε ένα λογικό εύρος. Η πύλη Forget στο LSTM και η πύλη Update στο GRU μπορούν να χειριστούν αποτελεσματικά μεγάλες εξαρτήσεις [41].

2.3.5 Υβριδικά μοντέλα Νευρωνικών Δικτύων για Χρονοσειρές (Hybrid models of neural networks for Time Series)

Παραδοσιακά, έχει επενδυθεί μεγάλη έρευνα στη χρήση MLPs για την πρόβλεψη χρονοσειρών με μέτρια αποτελέσματα. Ίσως ο πιο ελπιδοφόρο τομέας στην εφαρμογή των μεθόδων βαθιάς εκμάθησης για την πρόβλεψη χρονοσειρών είναι η χρήση CNN, LSTM και υβριδικών μοντέλων συνδυάζοντας τα 2 τελευταία μοντέλα.

2.4 Σφάλματα πρόβλεψης - μέτρα αξιολόγησης της απόδοσης του συστήματος

Τα λάθη είναι παρόντα σε κάθε πρόβλεψη που γίνεται. Αυτά τα λάθη, γνωστά ως σφάλματα πρόβλεψης, μπορούν να διαχωριστούν σε δύο κατηγορίες: συστηματικά σφάλματα και τυχαία σφάλματα. Τα συστηματικά σφάλματα προέρχονται από ζητήματα του μοντέλου πρόβλεψης, όπως λανθασμένες εκτιμήσεις παραμέτρων ή παραλείψεις, ενώ τα τυχαία σφάλματα προκύπτουν από απρόβλεπτους παράγοντες. Η μέτρηση των σφαλμάτων πρόβλεψης είναι ένας τρόπος μέτρησης της αποτελεσματικότητας των μεθόδων πρόβλεψης. Εάν το σφάλμα είναι αρνητικό, σημαίνει ότι οι προβλεπόμενες τιμές είναι πολύ υψηλές, ενώ ένα θετικό σφάλμα υποδηλώνει ότι οι τιμές υποεκτιμήθηκαν. Συνήθως, υπολογίζεται η απόλυτη τιμή του σφάλματος, εκτός εάν το συγκεκριμένο πρόβλημα απαιτεί διαφορετική προσέγγιση [25].

Στην αξιολόγηση της απόδοσης των τεχνικών πρόβλεψης, οι πιο γνωστές μετρητικές απόδοσης είναι: το μέσο απόλυτο σφάλμα (Mean Absolute Error-MAE), το μέσο απόλυτο ποσοστό σφάλματος (Mean Absolute Percentage Error-MAPE) και η ρίζα μέσου τετραγωνικού σφάλματος (Root Mean Square Error-RMSE). Αν και το MAPE δίνει τη δυνατότητα να συγκριθούν οι επιδόσεις πρόβλεψης τιμών HE από διάφορες και ποικίλες αγορές, για τιμές κοντά στο 0 δε δίνει ερμηνεύσιμα αποτελέσματα. Επομένως, για μηδενικά το MAPE μπορεί να μην υπολογιστεί, ενώ για μικρές θετικές τιμές το MAPE είναι πολύ υψηλό. Επίσης, στις συγκρίσεις δεν υπάρχει σημαντική διαφορά μεταξύ των τιμών MAE και RMSE, επειδή και τα 2 βασίζονται σε απόλυτα σφάλματα [7].

Το MAPE είναι μια ευρέως χρησιμοποιούμενη μέθοδος για την αξιολόγηση της ακρίβειας τέτοιων συστημάτων πρόβλεψης. Υπολογίζει το μέσο όρο των απόλυτων σφαλμάτων της πρόβλεψης ως ποσοστό της πραγματικής τιμής της χρονοσειράς. Εκφράζει το άθροισμα των απόλυτων σφαλμάτων πρόβλεψης διαιρούμενο με τον αριθμό των προβλέψεων που πραγματοποιήθηκαν κατά τη διάρκεια μιας καθορισμένης χρονικής περιόδου. Αυτό το

μέτρο δεν έχει μονάδα, γεγονός που το καθιστά χρήσιμο για την αξιολόγηση μεθόδων πρόβλεψης όταν το μέγεθος της μεταβλητής που προβλέπεται είναι σημαντικό. Χρησιμοποιείται επίσης συχνά για τη σύγκριση της ακρίβειας διαφορετικών μεθόδων πρόβλεψης σε πολλαπλές χρονοσειρές [25].

Παρόλα αυτά, στην παρούσα εργασία θα χρησιμοποιηθεί σαν μέτρο αξιολόγησης του συστήματος μας το MAE (mean absolute error):

$$MAE = \frac{\sum_{i=1}^n |Y_i - X_i|}{n} \quad (2.6)$$

Θα χρησιμοποιηθεί το MAE, διότι στην πραγματικότητα από την μία δείχνει σχεδόν το ίδιο πράγμα (παρότι δεν αποτελεί τις αληθινές marginal τιμές του συστήματος, αλλά το μέσο απόλυτο σφάλμα αυτών), και από την άλλη δεν διαιρεί πουθενά με γ , το οποίο βολεύει, καθώς το MAPE διαιρεί και μπορεί να δώσει μηδενικές τιμές, όπως διαπιστώθηκε και σε αυτήν την εργασία πειραματικά, καθώς τα παρόντα dataset έχουν αρκετά μηδενικά εντός του.

Κεφάλαιο 3: Βραχυπρόθεσμη πρόβλεψη ΟΤΣ ηλεκτρικής ενέργειας για την ελληνική αγορά ΗΕ

Στο κεφάλαιο αυτό θα αποτυπωθούν τα αποτελέσματα των προσομοιώσεων των μοντέλων πρόβλεψης βασισμένα σε ΤΝΔ για τη βραχυπρόθεσμη πρόβλεψη (day-ahead) της ΟΤΣ της Ελληνικής αγοράς ΗΕ. Θα περιγραφεί το dataset που θα χρησιμοποιηθεί για την υλοποίηση των πειραμάτων, τα πειράματα αυτά καθ' αυτά, τα είδη των νευρωνικών δικτύων που θα χρησιμοποιηθούν και τα διάφορα σενάρια που θα μελετηθούν. Στη συνέχεια, θα αναλυθούν τα αποτελέσματα αυτά καθ' αυτά, αλλά και θα συγκριθούν για τα διάφορα σενάρια τα διαφορετικά μοντέλα μεταξύ τους, για να προκύψει ένα συμπέρασμα για τη βέλτιστη εκπόνηση του πειράματος της παρούσας εργασίας. Για τον υπολογισμό και τον χειρισμό των δεδομένων, καθώς και για την υλοποίηση των νευρωνικών μοντέλων, χρησιμοποιήθηκε η έκδοση 3.7.4 της γλώσσας Python και το προγραμματιστικό περιβάλλον Google Colab. Η δημιουργία των νευρωνικών μοντέλων πραγματοποιήθηκε με τη χρήση του Keras, το οποίο είναι ένα υψηλού επιπέδου API για το TensorFlow, ιδανικό για την κατασκευή και την εκπαίδευση μοντέλων βαθιάς μάθησης. Η βιβλιοθήκη sklearn χρησιμοποιήθηκε για την κανονικοποίηση των δεδομένων και τον διαχωρισμό τους σε σύνολα δεδομένων εκπαίδευσης και επικύρωσης, ενώ για μαθηματικούς υπολογισμούς και χειρισμό των διανυσμάτων και των δεδομένων χρησιμοποιήθηκαν επίσης οι βιβλιοθήκες numpy, pandas της python, ενώ επίσης για στατιστική ανάλυση χρησιμοποιήθηκε το πακέτο statsmodels της python. Τέλος, ο κώδικας που αναπτύχθηκε για την εκπόνηση του πειράματος παρουσιάζεται στο Παράρτημα Α.

Επιγραμματικά, μία εργασία για την πρόβλεψη της ΟΤΣ της ΗΕ περιλαμβάνει μία σειρά από τα ακόλουθα βήματα:

1. Εισαγωγή δεδομένων - Import the data
2. Καθαρισμός δεδομένων - Clean the data
3. Διαχωρισμός δεδομένων σε σύνολα εκπαίδευσης και ελέγχου - Split the data into training/test sets
4. Δημιουργία του μοντέλου - Create a model
5. Εκπαίδευση του μοντέλου - Train the model

6. Εκτίμηση/Πρόβλεψη - Make predictions

7. Μέθοδοι αξιολόγησης και βελτίωσης του μοντέλου - Evaluate and improve model

Η εκπαίδευση ενός νευρωνικού δικτύου μπορεί να θεωρηθεί ως ένας συνδυασμός δύο συστατικών: μία αντικειμενική συνάρτηση (π.χ. logsig, tansig, κλπ) ή συνάρτηση στόχος και ένας αλγόριθμος βελτιστοποίησης (π.χ. Adam) που ελαχιστοποιεί τα σφάλματα αυτής της συνάρτησης. Η εκπαίδευση τελειώνει όταν το δίκτυο δεν βελτιώνεται σημαντικά για έναν προκαθορισμένο αριθμό εποχών. Άλλοι παράμετροι κατά τη διάρκεια της εκπαίδευσης: το batch size, π.χ. 3 χρόνια, η ορμή βελτιστοποίησης π.χ. 0,9, και το ποσοστό μάθησης-learning rate, π.χ. 0,001 [7].

3.1 Προεπεξεργασία των δεδομένων

Στην παρούσα εργασία θα πραγματοποιηθεί πρόβλεψη ΟΤΣ για το έτος 2019, με το νευρωνικό δίκτυο να εκπαιδεύεται στα έτη 2017 και 2018. Τα έτη 2017 και 2018 θα αποτελούν τα σύνολα εκπαίδευσης (training set), ενώ το έτος 2019 θα αποτελεί το σύνολο ελέγχου (test set). Όλα τα δεδομένα αντλήθηκαν από την πλατφόρμα "ENTSOE" [42] τον Δεκέμβριο του 2021, μια ιστοσελίδα διαφάνειας που παρέχει με δωρεάν πρόσβαση τα δεδομένα της πανευρωπαϊκής αγοράς ηλεκτρικής ενέργειας για όλους τους χρήστες, σε έξι κύριες κατηγορίες: φορτίο, παραγωγή, μεταφορά, εξισσορόπηση, διακοπές και διαχείριση συμφόρησης.

Για κάθε σενάριο θα υπάρχουν τα σετ δεδομένων: trainX, testX, trainy, testy. Τα trainy και testy θα είναι ίδια για όλα τα σενάρια. Το trainy περιλαμβάνει σε μία στήλη, 17520 (2έτη x 365ημέρες x 24ώρες) γραμμές των ωριαίων τιμών ΟΤΣ των ετών 2017 και 2018. Όμοια το testy περιλαμβάνει σε μία στήλη 8760 (1έτος x 365ημέρες x 24ώρες) γραμμές των ωριαίων τιμών ΟΤΣ του έτους 2019. Έπειτα για κάθε σενάριο είναι διαφορετικά τα trainX και testX, τα οποία περιγράφονται παρακάτω:

Σενάριο 1: Πρόβλεψη με μόνο ενδογενείς (ιστορικές τιμές) μεταβλητές

Είσοδοι 1-24 της στήλης Α στο αρχείο scen1_trainX για το σύνολο εκπαίδευσης του σεναρίου 1, αναφέρονται στις ωριαίες τιμές της ΟΤΣ της ημέρας D-1 των ετών 2017 και 2018.

Είσοδοι 1-168 της στήλης Β στο αρχείο scen1_trainX για το σύνολο εκπαίδευσης του σεναρίου 1, αναφέρονται στις ωριαίες τιμές της ΟΤΣ της ημέρας μίας εβδομάδας πριν την ημέρα D-7 των ετών 2017 και 2018.

Είσοδοι 1-24 της στήλης Α στο αρχείο scen1_testX για το σύνολο ελέγχου του σεναρίου 1, αναφέρονται στις ωριαίες τιμές της ΟΤΣ της ημέρας D-1 του έτους 2019.

Είσοδοι 1-168 της στήλης Β στο αρχείο scen1_testX για το σύνολο ελέγχου του σεναρίου 1, αναφέρονται στις ωριαίες τιμές της ΟΤΣ της ημέρας μίας εβδομάδας πριν την ημέρα D-7 υπό πρόβλεψη του έτους 2019.

Σενάριο 2: Παραμένουν τα δεδομένα του σεναρίου 1 και υπάρχουν επιπλέον 3 ενδογενείς μεταβλητές που περιγράφονται παρακάτω:

Είσοδοι 1-24 της στήλης C στο αρχείο scen1_trainX για το σύνολο εκπαίδευσης του σεναρίου 2, αναφέρονται στο 24ωρο της ημέρας D-1 των ετών 2017 και 2018. Οι επόμενοι 24 είσοδοι 24-48 της στήλης C αναφέρονται στο επόμενο 24ωρο κ.ο.κ.

Είσοδοι 1-24 της στήλης D στο αρχείο scen1_trainX για το σύνολο εκπαίδευσης του σεναρίου 2, αναφέρονται σε ημέρα της εβδομάδας, την Κυριακή για το έτος 2017. Οι επόμενοι 24 είσοδοι 25-28 αναφέρονται στην ημέρα της εβδομάδας Δευτέρα για το έτος 2017 κ.ο.κ.

Είσοδοι 1-744 της στήλης Ε στο αρχείο scen1_trainX για το σύνολο εκπαίδευσης του σεναρίου 2, αναφέρονται στον μήνα Γενάρη του έτους 2017. Οι επόμενοι 744 είσοδοι αναφέρονται στον μήνα Φλεβάρη του έτους 2017.

Αντίστοιχα για το scen2_testX.xlsx για το έτος 2019.

Σενάριο 3: Παραμένουν τα δεδομένα του σεναρίου 2 και υπάρχει άλλη μία εξωγενή μεταβλητή, η θερμοκρασία στα 2 μέτρα σε °C για τα έτη 2017, 2018 και 2019.


Σενάριο 4: Παραμένουν τα δεδομένα του σεναρίου 3 και υπάρχει άλλη μία εξωγενή μεταβλητή, η υγρασία σε ποσοστό (%) στα 2 μέτρα για τα έτη 2017, 2018 και 2019.

Σενάριο 5: Παραμένουν τα δεδομένα του σεναρίου 4 και υπάρχει άλλη μία εξωγενή μεταβλητή, η ταχύτητα ανέμου στα 2 μέτρα σε m/s για τα έτη 2017, 2018 και 2019.

Σενάριο 6: Παραμένουν τα δεδομένα του σεναρίου 5 και υπάρχει άλλη μία εξωγενή μεταβλητή, το πραγματικό φορτίο για τα έτη 2017, 2018 και 2019.

Οι εξωγενείς μεταβλητές: θερμοκρασία, υγρασία, ταχύτητα ανέμου και πραγματικό φορτίο είναι ο μέσος όρος των τιμών σε Αθήνα και Θεσσαλονίκη.

Μέσω του πακέτου statsmodels της python πραγματοποιήθηκε ο στατιστικός έλεγχος των δεδομένων. Κατ'αρχάς, δημιουργήθηκε και μελετήθηκε ο συντελεστής αυτοσυσχέτισης των οριακών τιμών του σετ δεδομένων μας για την εκπαίδευση του συστήματος. Ο συντελεστής αυτός δείχνει το πως σχετίζονται οι τιμές των δεδομένων σε σχέση με τις ίδιες για διαφορετικές χρονικές στιγμές. Το σχετικό γράφημα παρουσιάζεται στο Σχήμα 3.1:



Σχήμα 3.1 Συντελεστής αυτοσυσχέτισης των ΟΤΣ σε συνάρτηση με το χρόνο (σε ώρες).

(άξονας x: ώρα - h, άξονας y: συντελεστής αυτοσυσχέτισης)

Παρατηρείται πως ο συντελεστής αυτοσυσχέτισης παρουσιάζεται σχετικά παροδικά. Στην αρχή, όσο δεν περνάει επαρκής χρόνος, είναι αρκετά υψηλός, ενώ στην συνέχεια περνάει αρκετές διακυμάνσεις, στις οποίες λαμβάνει κάποιες υψηλές και ικανοποιητικές τιμές, ενώ σε σημεία λαμβάνει κάποιες αρκετά χαμηλές τιμές. Παρόλα αυτά, αυτό είναι λογικό για μια χρονοσειρά τέτοιου είδους, αυτής της ενέργειας δηλαδή, η οποία εξαρτάται από διάφορους σταθερούς αλλά και τυχαίους παράγοντες, οπότε δεν είναι ανησυχητικό για τα δεδομένα μας. Ούτως ή άλλως, οι ενίοτε υψηλές τιμές μας προδιαθέτουν για μια ικανοποιητική αυτοσυσχέτιση, η οποία θα μπορέσει να παίξει ουσιαστικό ρόλο στην εκπαίδευση των μοντέλων μας. Όπως και να έχει, μέσω της βιβλιοθήκης `sklearn` πραγματοποιείται κανονικοποίηση των δεδομένων ως προς `scale` και ο χωρισμός των σετ δεδομένων σε `training` και `validation`.

Όσον αφορά την προεπεξεργασία των δεδομένων, τα αρχεία `excel` μετατράπηκαν σε `.csv` τα οποία βολεύουν περισσότερο για την διαχείριση τους μέσω της βιβλιοθήκης `pandas`. Πριν γίνει η μετατροπή, τα δεδομένα έγιναν `labeled`, καθώς και κάποιες στήλες άλλων αρχείων `excel` ενώθηκαν με αυτές άλλων στην αρχή του κώδικα, για την ευκολότερη διαχείριση των δεδομένων.

Τέλος, χρειάστηκε να γίνει έλεγχος για τα `NaN` στοιχεία που προέκυψαν κατά την μετατροπή, τα οποία μετά αντικαταστάθηκαν με τον μέσο όρο των υπόλοιπων στοιχείων της ίδιας στήλης, για να μην προκύπτει πρόβλημα με τα σφάλματα των νευρωνικών δικτύων κατά την εκπαίδευση τους.

3.2 Εφαρμογή νευρωνικών δικτύων

Για να βελτιωθεί η ακρίβεια των προβλέψεων του νευρωνικού δικτύου, πραγματοποιήθηκε κανονικοποίηση των δεδομένων. Αφού έγιναν οι προβλέψεις, εφαρμόστηκε ο αντίστροφος μετασχηματισμός. Ο αλγόριθμος εφαρμόστηκε χρησιμοποιώντας τις τιμές του 2017 και του 2018 για δεδομένα εκπαίδευσης και τις τιμές του 2019 για δεδομένα επικύρωσης. Στο πλαίσιο της υλοποίησης του αλγορίθμου δημιουργήθηκαν ζεύγη δεδομένων εισόδου-εξόδου. Η είσοδος είναι πάντα οι D-1 και D-7 ΟΤΣ, δηλαδή οι τιμές για 1 μέρα και 1 βδομάδα αντίστοιχα πριν την μέρα πρόβλεψης D, και οι έξτρα εξωτερικές μεταβλητές αναλόγως το κάθε σενάριο, όπως η θερμοκρασία, η υγρασία κλπ. Η έξοδος είναι οι αληθινές τιμές της μέρας πρόβλεψης D. Αντιστοιχώς

δημιουργούνται τα ίδια ζεύγη εισόδου-εξόδου για το test set με τις τιμές για το 2019. Το σύνολο δεδομένων εκπαίδευσης οργανώθηκε σε ζεύγη εισόδου-εξόδου και χωρίστηκε τυχαία σε σύνολα εκπαίδευσης και επικύρωσης με αναλογία 80-20. Η μετρική σφάλματος που χρησιμοποιήθηκε ήταν το μέσο απόλυτο σφάλμα (MAE) και ο στόχος της εκπαίδευσης του νευρωνικού δικτύου ήταν η ελαχιστοποίηση του μέσου τετραγωνικού σφάλματος (MSE), το οποίο χρησίμευσε ως συνάρτηση απώλειας σε όλες τις αρχιτεκτονικές δικτύων που χρησιμοποιήθηκαν. Σε κάθε σενάριο και κάθε μοντέλο ως training set αντιμετωπίστηκαν οι ΟΤΣ για τα έτη 2017-2018 μαζί με τις επιπλέον κάθε φορά εξωτερικές παραμέτρους, ενώ σαν test set αντίστοιχα οι τιμές για το 2019. Σκοπός αυτού του διαχωρισμού ήταν η εκπαίδευση των ΤΝΔ πάνω σε συγκεκριμένες χρονιές, και ύστερα ο έλεγχος της επίδοσης τους σε τιμές χρονιάς που δεν έχουν αντιμετωπίσει ξανά. Κάθε σενάριο προς πρόβλεψη αντιμετωπίστηκε ανεξάρτητα, αφού οι χρονοσειρές είχαν διαφορετικά χαρακτηριστικά, και έτσι στις περισσότερες περιπτώσεις μεταβλήθηκαν η αρχιτεκτονική και οι υπερπαραμέτροι.

Τα νευρωνικά δίκτυα που χρησιμοποιήθηκαν για την εκπόνηση των πειραμάτων αυτής της εργασίας είναι τα:

1. Νευρωνικά δίκτυα μακροχρόνιας βραχυπρόθεσμης μνήμης (LSTM)
2. Συνελικτικά νευρωνικά δίκτυα (CNN)
3. Νευρωνικά δίκτυα επαναλαμβανόμενης μονάδας με πύλη (GRU)

Σε όλα τα ΤΝΔ ορίστηκαν ως τιμές εισόδου και εξόδου, δηλαδή οι παράμετροι history window και horizon, ως 500 και 1000, αντίστοιχα. Με τις τιμές αυτές τα μοντέλα παρατηρήθηκαν να εκπαιδεύονται και να αποδίδουν καλύτερα. Εξαίρεση στη λογική αυτή αποτελούν τα GRU μοντέλα, τα οποία με τόσο μεγάλες τιμές δεν εκπαιδεύονταν επαρκώς, αναλόγως το σενάριο βέβαια. Στα μοντέλα αυτά επιλέχθηκαν διαφορετικές τιμές, οι οποίες θα αναφερθούν παρακάτω.

Επιπλέον, οι εποχές σε όλα τα μοντέλα επιλέχθηκαν σταθερά στις 20, καθώς εκεί το μοντέλο εκπαιδεύεται καλύτερα, δεδομένου της μνήμης και υπολογιστικής ισχύος που μπορούσε να διατεθεί για τα πειράματα αυτά. Επιπλέον το Evaluation Interval, το οποίο αποτελεί μια παράμετρο του νευρωνικού που είναι υπεύθυνη για τον ορισμό του

συνολικού διαστήματος αξιολόγησης για τους κανόνες που μαθαίνει το μοντέλο σε κάθε εποχή, επιλέχθηκε για παρόμοιους λόγους σταθερά στην τιμή των 150 μονάδων.

Αξίζει επίσης να παρατηρηθεί πως σε κάποια loss diagrams, δηλαδή τα διαγράμματα κόστους και απωλειών της απόδοσης των νευρωνικών δικτύων, παρακάτω οι τιμές στον άξονα x είναι λιγότερες σε σχέση με άλλα διαγράμματα. Αυτό συμβαίνει λόγω των early stoppings, δηλαδή των περιπτώσεων που η εκπαίδευση στάματησε νωρίτερα από το καθορισμένο για να μην υπερεκπαιδευτεί το μοντέλο, που συνέβησαν σε κάποια σενάρια, και έτσι το μοντέλο δεν πρόλαβε να φτάσει τις 20 εποχές.

3.2.1 Εφαρμογή LSTM τεχνητών νευρωνικών δικτύων

Ο αρχικός σχεδιασμός του νευρωνικού δικτύου περιλάμβανε μια διαδοχική δομή στρωμάτων LSTM. Το πρώτο στρώμα αποτελούνταν από 150 νευρώνες, ακολουθούμενο από ένα στρώμα εγκατάλειψης με ποσοστό εγκατάλειψης 0,5. Το δεύτερο στρώμα LSTM περιείχε 100 νευρώνες, ακολουθούμενο από άλλο ένα στρώμα εγκατάλειψης με το ίδιο ποσοστό εγκατάλειψης. Τέλος, το στρώμα εξόδου ήταν ένα πυκνό στρώμα με αριθμό νευρώνων ίσο με την επιθυμητή έξοδο, η οποία ορίστηκε σε 1000 (Σχήμα 3.2). Η παράμετρος history window παίρνει την τιμή 500, όσες τιμές πίσω κοιτάει δηλαδή το τεχνητό νευρωνικό δίκτυο. Οι υπερπαραμέτροι που επιλέχθηκαν φαίνονται στον Πίνακα 3.1. [29] .

```

Model: "sequential_4"
=====
Layer (type)                Output Shape                Param #
=====
lstm_8 (LSTM)                (None, 500, 150)           92400
dropout_8 (Dropout)          (None, 500, 150)           0
lstm_9 (LSTM)                (None, 100)                100400
dropout_9 (Dropout)          (None, 100)                0
dense_4 (Dense)              (None, 1000)               101000
=====
Total params: 293,800
Trainable params: 293,800
Non-trainable params: 0

```


Σχήμα 3.2 Η αρχιτεκτονική του LSTM ΤΝΔ που υλοποιήθηκε

Πίνακας 3.1 Οι υπερπαράμετροι του LSTM ΤΝΔ

Υπερπαράμετρος	Σενάριο 1	Σενάριο 2	Σενάριο 3	Σενάριο 4	Σενάριο 5	Σενάριο 6
Batch size	256	256	256	256	256	256
Epochs	20	20	20	20	20	20
Optimizer	Adam, learning rate=0.05	Adam, learning rate=0.05	Adam, learning rate=0.05	Adam, learning rate=0.05	Adam, learning rate=0.05	Adam, learning rate=0.05
Loss function	mse	mse	mse	mse	mse	mse
Activation Function	-	-	-	-	-	-
Buffer size	256	256	256	256	256	256


Οι εποχές επιλέχθηκαν σταθερά στις 20, καθώς παρατηρήθηκε πως για περισσότερες εποχές τα αποτελέσματα του ΤΝΔ στην πρόβλεψη δεν άλλαζαν ιδιαίτερα, καθώς επίσης η απόδοση αυτού μερικές φορές μεγιστοποιούνταν και λίγο πριν τις 20, όπως π.χ. στις 18, άρα η τιμή 20 ήταν κάθε φορά η πιο ασφαλής για κάθε σενάριο.

Από το Σχήμα 3.3 μέχρι και το Σχήμα 3.14 παρουσιάζονται για κάθε σενάριο τα διαγράμματα κόστους και απωλειών της απόδοσης των νευρωνικών δικτύων loss diagrams, καθώς και οι προβλέψεις του ΤΝΔ για το έτος 2019. Σε κάθε σενάριο τα επιπλέον χαρακτηριστικά που προστίθενται είναι αυτά που αναφέρθηκαν και παραπάνω. Στον Πίνακα 3.2 παρουσιάζεται το σφάλμα MAE του LSTM ΤΝΔ για κάθε σενάριο.




Σχήμα 3.3 Loss diagram LSTM ΤΝΔ για το σενάριο 1

(άξονας x: epoch, άξονας y: loss)




Σχήμα 3.4 Επίδοση LSTM ΤΝΔ για το έτος 2019 στο σενάριο 1

(άξονας x: χρόνος - h , άξονας y: ΟΤΣ - €/MWh)




Σχήμα 3.5 Loss Diagram LSTM ΤΝΔ για το σενάριο 2

(άξονας x: epoch, άξονας y: loss)




Σχήμα 3.6 Επίδοση LSTM ΤΝΔ για το έτος 2019 στο σενάριο 2

(άξονας x: χρόνος - h , άξονας y: ΟΤΣ - €/MWh)




Σχήμα 3.7 Loss diagram LSTM ΤΝΔ για το σενάριο 3

(άξονας x: epoch, άξονας y: loss)




Σχήμα 3.8 Επίδοση LSTM ΤΝΔ για το έτος 2019 στο σενάριο 3

(άξονας x: χρόνος - h , άξονας y: ΟΤΣ - €/MWh)




Σχήμα 3.9 Loss diagram LSTM ΤΝΔ για το σενάριο 4

(άξονας x: epoch, άξονας y: loss)




Σχήμα 3.10 Επίδοση LSTM ΤΝΔ για το έτος 2019 στο σενάριο 4

(άξονας x: χρόνος - h , άξονας γ: ΟΤΣ - €/MWh)




Σχήμα 3.11 Loss diagram LSTM ΤΝΔ για το σενάριο 5

(άξονας x: epoch, άξονας γ: loss)




Σχήμα 3.12 Επίδοση LSTM ΤΝΔ για το έτος 2019 στο σενάριο 5

(άξονας x: χρόνος - h , άξονας y: ΟΤΣ - €/MWh)



Σχήμα 3.13 Loss diagram LSTM ΤΝΔ για το σενάριο 6

(άξονας x: epoch, άξονας y: loss)



Σχήμα 3.14 Επίδοση LSTM ΤΝΔ για το έτος 2019 στο σενάριο 6

(άξονας x: χρόνος - h , άξονας y: ΟΤΣ - €/MWh)

Πίνακας 3.2 Σφάλμα MAE για το LSTM σε όλα τα σενάρια

Μοντέλο	Σενάριο 1	Σενάριο 2	Σενάριο 3	Σενάριο 4	Σενάριο 5	Σενάριο 6
LSTM	10.633382 13287353 5	9.9044439 08111572	8.1622667 12615967	8.5992780 02716062	9.9502308 253479	13.327221922 271729

Παρατηρείται πως γενικά το σφάλμα βγαίνει χαμηλό, γεγονός που σημαίνει ότι το μοντέλο σε γενικές γραμμές λειτουργεί ικανοποιητικά. Συγκεκριμένα, παρατηρείται ότι την καλύτερη απόδοση, όσον αφορά τουλάχιστον το σφάλμα MAE, έχει το ΤΝΔ στα σενάρια 3 και 4. Παρόλα αυτά, στις γραφικές παραστάσεις η καλύτερη επίδοση

παρατηρείται στα σενάρια 1 και 5, όσον αφορά την προσέγγιση της πραγματικής καμπύλης.

Ενώ σε όλα τα σενάρια η προβλεπόμενη καμπύλη προσεγγίζει σε συμπεριφορά και σε τροχιά την πραγματική, παρατηρούμε ότι δυσκολεύεται να προσαρμοστεί και να μιμηθεί τις ακραίες απότομες τιμές που λαμβάνει ανά τακτά χρονικά διαστήματα. Παρόλα αυτά, παρατηρείται πως τα σενάρια 1 και 5 αποδίδουν αρκετά καλά, και η προβλεπόμενη καμπύλη προσπαθεί να προσεγγίσει την πραγματική και στα ακρότατα, ενώ με την πάροδο του χρόνου καταφέρνει και να ταυτιστεί μαζί της.

Αυτό εξηγείται στο ότι στο σενάριο 1 υπάρχουν τα πιο “καθαρά” και συγκεκριμένα δεδομένα και χαρακτηριστικά, ενώ επίσης στο σενάριο 5 υπάρχει αρκετή πληροφορία για την εκπαίδευση όλων αυτών των καινούργιων χαρακτηριστικών. Στα σενάρια 2-4 ενδεχομένως το ΤΝΔ να μην μπορεί να εκπαιδευτεί καλά στα πρώτα του καινούργια features, ενώ στο σενάριο 6 υπάρχει η πιθανότητα overfitting από τα πολλά features που παρουσιάζονται.

Ενώ σε γενικές γραμμές και στην θεωρία, όσον αφορά το σφάλμα, το μοντέλο αποδίδει καλά, χρειάζεται σίγουρα περαιτέρω βελτίωση του στην καλύτερη εύρεση των πραγματικών ακραίων τιμών [37, 38, 39].

3.2.2: Εφαρμογή CNN τεχνητών νευρωνικών δικτύων

Η αρχιτεκτονική που χρησιμοποιήθηκε στην παρούσα μελέτη απεικονίζεται στο Σχήμα 3.15 και περιλαμβάνει τα ακόλουθα στοιχεία:

1. Ένα 1-διάστατο συνελκτικό στρώμα που αποτελείται από 64 φίλτρα, το καθένα με μέγεθος φίλτρου 3.
2. Ένα στρώμα MaxPooling με μέγεθος παραθύρου 2.
3. Ένα στρώμα εγκατάλειψης (dropout) με πιθανότητα εγκατάλειψης 0,5.
4. Ένα επίπεδο ισοπέδωσης (flatten).
5. Ένα πυκνό στρώμα 30 νευρώνων.
6. Άλλο ένα στρώμα Dropout με πιθανότητα εγκατάλειψης 0,5.
7. Το τελικό στρώμα είναι ένα πυκνό, πλήρως συνδεδεμένο στρώμα 1000 νευρώνων, το οποίο ισούται με την επιθυμητή έξοδο ή την παράμετρο του ορίζοντα [30, 31, 40].

Οι συγκεκριμένες υπερπαράμετροι που επιλέχθηκαν για κάθε περίοδο πρόβλεψης φαίνονται στον Πίνακα 3.3.

```

Model: "sequential"
_____
Layer (type)                Output Shape                Param #
=====
conv1d (Conv1D)              (None, 498, 64)            3520
max_pooling1d (MaxPooling1D) (None, 249, 64)            0
dropout (Dropout)            (None, 249, 64)            0
flatten (Flatten)            (None, 15936)               0
dense (Dense)                 (None, 30)                  478110
dropout_1 (Dropout)           (None, 30)                  0
dense_1 (Dense)               (None, 1000)                31000
=====
Total params: 512,630
Trainable params: 512,630
Non-trainable params: 0

```

Σχήμα 3.15 Αρχιτεκτονική CNN μοντέλου


Πίνακας 3.3 Υπερπαράμετροι CNN μοντέλου

Υπερπαράμετρος	Σενάριο 1	Σενάριο 2	Σενάριο 3	Σενάριο 4	Σενάριο 5	Σενάριο 6
Batch size	256	256	256	256	256	256
Epochs	20	20	20	20	20	20
Optimizer	Adam, learning rate=0.05	Adam, learning rate=0.05	Adam, learning rate=0.05	Adam, learning rate=0.05	Adam, learning rate=0.05	Adam, learning rate=0.05
Loss function	mse	mse	mse	mse	mse	mse

Activation Function	relu	relu	relu	relu	relu	relu
Buffer size	256	256	256	256	256	256


Οι εποχές επιλέχθηκαν σταθερά στις 20, καθώς παρατηρήθηκε πως για περισσότερες εποχές τα αποτελέσματα του ΤΝΔ στην πρόβλεψη δεν άλλαζαν ιδιαίτερα, καθώς επίσης η απόδοση αυτού μερικές φορές μεγιστοποιούνταν και λίγο πριν τις 20, όπως π.χ. στις 18, άρα η τιμή 20 ήταν κάθε φορά η πιο ασφαλής για κάθε σενάριο.

Στα Σχήματα 3.16 με 3.27 φαίνονται για κάθε σενάριο τα διαγράμματα κόστους και απωλειών της απόδοσης των νευρωνικών δικτύων loss diagrams, καθώς και οι προβλέψεις του ΤΝΔ για το έτος 2019. Σε κάθε σενάριο τα επιπλέον χαρακτηριστικά που προστίθενται είναι αυτά που αναφέρθηκαν και παραπάνω. Στον Πίνακα 3.4 φαίνεται το σφάλμα MAE για κάθε σενάριο του CNN ΤΝΔ.




Σχήμα 3.16 Loss diagram CNN ΤΝΔ για το σενάριο 1

(άξονας x: epoch, άξονας y: loss)




Σχήμα 3.17 Επίδοση CNN ΤΝΔ για το έτος 2019 στο σενάριο 1

(άξονας x: χρόνος - h , άξονας y: ΟΤΣ - €/MWh)




Σχήμα 3.18 Loss diagram CNN ΤΝΔ για το σενάριο 2

(άξονας x: epoch, άξονας y: loss)




Σχήμα 3.19 Επίδοση CNN ΤΝΔ για το έτος 2019 στο σενάριο 2

(άξονας x: χρόνος - h , άξονας y: ΟΤΣ - €/MWh)




Σχήμα 3.20 Loss diagram CNN ΤΝΔ για το σενάριο 3

(άξονας x: epoch, άξονας y: loss)




Σχήμα 3.21 Επίδοση CNN ΤΝΔ για το έτος 2019 στο σενάριο 3

(άξονας x: χρόνος - h , άξονας y: ΟΤΣ - €/MWh)




Σχήμα 3.22 Loss diagram CNN ΤΝΔ για το σενάριο 4

(άξονας x: epoch, άξονας y: loss)




Σχήμα 3.23 Επίδοση CNN ΤΝΔ για το έτος 2019 στο σενάριο 4

(άξονας x: χρόνος - h , άξονας y: ΟΤΣ - €/MWh)




Σχήμα 3.24 Loss diagram CNN ΤΝΔ για το σενάριο 5

(άξονας x: epoch, άξονας y: loss)




Σχήμα 3.25 Επίδοση CNN ΤΝΔ για το έτος 2019 στο σενάριο 5

(άξονας x: χρόνος - h , άξονας y: ΟΤΣ - €/MWh)



Σχήμα 3.26 Loss diagram CNN TND για το σενάριο 6

(άξονας x: epoch, άξονας y: loss)



Σχήμα 3.27 Επίδοση CNN TND για το έτος 2019 στο σενάριο 6

(άξονας x: χρόνος - h , άξονας y: OTΣ - €/MWh)

Πίνακας 3.4 MAE του CNN σε κάθε σενάριο

Μοντέλο	Σενάριο 1	Σενάριο 2	Σενάριο 3	Σενάριο 4	Σενάριο 5	Σενάριο 6
CNN	9.1152830 0228882	13.973229 41052246	15.092108 78216552 7	7.7219150 89111327	7.7217447 09472656	6.3286761785 88867

Ξανά, παρατηρούμε πως τα MAE είναι χαμηλά, πράγμα που σημαίνει ότι μοντέλο αποδίδει καλά. Συγκεκριμένα τα σενάρια 5 και 6 όσον αφορά το σφάλμα έχουν την καλύτερη απόδοση [35, 36].

Όσον αφορά την πραγματική απόδοση, όπως φαίνεται και στα διαγράμματα, παραμένουν τα ίδια προβλήματα με το LSTM, ενώ συνολικά η απόδοση είναι χειρότερη. Το σενάριο 1 για τους ίδιους λόγους έχει την βέλτιστη απόδοση, ενώ στα 5 και 6 η προσέγγιση είναι επίσης καλή, αλλά χάνει στις ταλαντώσεις. Στα 2, 3, 4 η απόδοση είναι σίγουρα μακριά από επιθυμητή. Αξίζει να σημειωθεί πως επίσης το ΤΝΔ αυτό ήταν αρκετά πιο αργό και στον χρόνο εκτέλεσης του [34].

Η απόδοση του CNN είναι σχετικά αναμενόμενη, καθώς δεν συνηθίζεται να χρησιμοποιείται πολύ σε τέτοιου είδους προβλέψεις, αλλά έχει ενδιαφέρον πειραματικά η απόδοση του σε τέτοια πλαίσια.

3.2.3 Εφαρμογή GRU τεχνητών νευρωνικών δικτύων

Για το GRU ΤΝΔ υλοποιήθηκε ένα input στρώμα 100 νευρώνων, ύστερα ένα dropout στρώμα με πιθανότητα 0.5, άλλο ένα στρώμα 50 νευρώνων, ύστερα άλλο ένα output στρώμα με πιθανότητα 0.5, και τέλος ένα dense στρώμα εξόδου, με νευρώνες όσες και οι έξοδοι, δηλαδή 200, όση και η τιμή horizon. Στο Σχήμα 3.28 φαίνεται η αρχιτεκτονική του ΤΝΔ, ενώ στον Πίνακα 3.5 οι υπερπαραμέτροί του: [32]

```

Model: "sequential_2"
Layer (type)                Output Shape                Param #
=====
gru_4 (GRU)                  (None, 500, 100)          36000
dropout_4 (Dropout)          (None, 500, 100)          0
gru_5 (GRU)                  (None, 50)                 22800
dropout_5 (Dropout)          (None, 50)                 0
dense_2 (Dense)              (None, 200)               10200
=====
Total params: 69,000
Trainable params: 69,000
Non-trainable params: 0


```

Σχήμα 3.28 Αρχιτεκτονική GRU

Πίνακας 3.5 Υπερπαράμετροι GRU


Υπερπαράμετρος	Σενάριο 1	Σενάριο 2	Σενάριο 3	Σενάριο 4	Σενάριο 5	Σενάριο 6
Batch size	256	256	256	256	256	256
Epochs	20	20	20	20	20	20
Optimizer	Adam, learning rate=0.05	Adam, learning rate=0.05	Adam, learning rate=0.05	Adam, learning rate=0.05	Adam, learning rate=0.05	Adam, learning rate=0.05
Loss function	mse	mse	mse	mse	mse	mse
Activation Function	-	-	-	-	-	-
Buffer size	256	256	256	256	256	256
History Window	200	400	400	400	400	500
Horizon	50	100	100	100	100	200

Στα Σχήματα 3.29 με 3.40 φαίνεται η επίδοση του ΤΝΔ για κάθε σενάριο, ενώ στον Πίνακα 3.6 παρουσιάζεται το σφάλμα MAE του GRU ΤΝΔ σε κάθε σενάριο:




Σχήμα 3.29 Loss diagram GRU ΤΝΔ για το σενάριο 1

(άξονας x: epoch, άξονας y: loss)




Σχήμα 3.30 Επίδοση GRU ΤΝΔ για το έτος 2019 στο σενάριο 1

(άξονας x: χρόνος - h , άξονας y: ΟΤΣ - €/MWh)




Σχήμα 3.31 Loss diagram GRU ΤΝΔ για το σενάριο 2

(άξονας x: epoch, άξονας γ: loss)




Σχήμα 3.32 Επίδοση GRU ΤΝΔ για το έτος 2019 στο σενάριο 2

(άξονας x: χρόνος - h , άξονας γ: ΟΤΣ - €/MWh)




Σχήμα 3.33 Loss diagram GRU ΤΝΔ για το σενάριο 3

(άξονας x: epoch, άξονας y: loss)




Σχήμα 3.34 Επίδοση GRU ΤΝΔ για το έτος 2019 στο σενάριο 3

(άξονας x: χρόνος - h , άξονας y: ΟΤΣ - €/MWh)




Σχήμα 3.35 Loss diagram GRU ΤΝΔ για το σενάριο 4

(άξονας x: epoch, άξονας γ: loss)




Σχήμα 3.36 Επίδοση GRU ΤΝΔ για το έτος 2019 στο σενάριο 4

(άξονας x: χρόνος - h , άξονας γ: ΟΤΣ - €/MWh)




Σχήμα 3.37 Loss diagram GRU ΤΝΔ για το σενάριο 5

(άξονας x: epoch, άξονας γ: loss)




Σχήμα 3.38 Επίδοση GRU ΤΝΔ για το έτος 2019 στο σενάριο 5

(άξονας x: χρόνος - h , άξονας γ: ΟΤΣ - €/MWh)



Σχήμα 3.39 Loss diagram GRU ΤΝΔ στο σενάριο 6

(άξονας x: epoch, άξονας γ: loss)



Σχήμα 3.40 Επίδοση GRU ΤΝΔ για το έτος 2019 στο σενάριο 6

(άξονας x: χρόνος - h , άξονας γ: ΟΤΣ - €/MWh)

Πίνακας 3.6 MAE του GRU στο testing για το έτος 2019 σε κάθε σενάριο

GRU	7.718366482 543943	6.8564579 90722657 5	6.7266438116455 08	8.11812541809 0822	7.8777564 60266113	7.149271 8519592 29
-----	-----------------------	----------------------------	-----------------------	-----------------------	-----------------------	---------------------------

Παρατηρούμε πως αν και η απόδοση όσον αφορά την μετρική MAE είναι βέλτιστη, το GRU σε αρκετά σενάρια δεν αποδίδει πολύ καλά στην πράξη. Ξανά, τα σενάρια 1, 5 και 6 αποτελούν τα σενάρια βέλτιστης απόδοσης, ενώ τα 2,3,4 δεν έχουν καλά γραφήματα. Το GRU επίσης είχε αρκετά αργό χρόνο εκτέλεσης. Παρόλα αυτά, συνολικά αποδίδει χειρότερα από το LSTM, αλλά καλύτερα από το CNN. Είναι λογικό η επίδοση του να είναι παρεμφερής με αυτή του LSTM, καθώς οι αρχιτεκτονικές τους και οι τρόποι λειτουργίας του είναι συγγενικοί.

3.3 Σχολιασμός και σύγκριση των μοντέλων

Τα πειράματα που πραγματοποιήθηκαν για την παρούσα εργασία παρουσιάζουν έντονο επιστημονικό και ερευνητικό ενδιαφέρον, καθώς και τα αποτελέσματα αυτών. Συνολικά, τα αποτελέσματα των προσομοιώσεων φανερώνουν πως τα μοντέλα αυτά, κυρίως το LSTM και το GRU, μπορούν να παίξουν κομβικό ρόλο και τώρα και στο μέλλον στην πρόβλεψη ΟΤΣ ηλεκτρικής ενέργειας, και να καθορίσουν κατά αυτόν τον τρόπο τις κινήσεις των παροχών ενέργειας, καθώς και της ίδιας της αγοράς.

Αυτό διότι αν και πολλές φορές τα αποτελέσματα δεν ήταν βέλτιστα, φάνηκε μέσω των πειραμάτων αυτών πως με την κατάλληλη εκπαίδευση, άρα και την αντίστοιχη υπολογιστική ισχύ, τα μοντέλα αυτά μπορούν να προσεγγίσουν έως ένα βαθμό τις πραγματικές ΟΤΣ.

Στην εργασία αυτή, παρατηρήθηκε πως ποτέ τα μοντέλα δεν προέβλεψαν τέλεια τις ΟΤΣ, μερικές φορές μάλιστα απείχαν πολύ από αυτό. Πάντα όμως κατάφερναν να

προβλέψουν έως ένα βαθμό την τάση της καμπύλης των ΟΤΣ, καθώς και το βεληνεκές τιμών της. Αξίζει να σημειωθεί πως ιδιαίτερη αδυναμία παρουσιάστηκε στην προσέγγιση απότομων πολύ μεγάλων/μικρών μεγίστων/ελαχίστων της καμπύλης. Στις περιπτώσεις αυτές τα μοντέλα αντιμετώπισαν μεγάλη δυσκολία.

Συνολικά, εξάγεται το συμπέρασμα πως καλύτερα από όλα τα μοντέλα απέδωσε το LSTM, ενώ δεύτερο έρχεται το GRU και τελευταίο το CNN, κάτι που ήταν σχετικά αναμενόμενο, καθώς το CNN δεν συνηθίζεται να χρησιμοποιείται σε τέτοιου είδους πρόβλεψη χρονοσειρών, αλλά η δοκιμή του είχε και αυτή ένα ερευνητικό ενδιαφέρον.

Τέλος, αξίζει να σημειωθεί πως όλα τα μοντέλα έτειναν να αποδίδουν καλύτερα στο πρώτο σενάριο σίγουρα, και ύστερα στα σενάρια 4 και 5, ή 5 και 6, αναλόγως κάθε φορά το μοντέλο. Αυτό φανερώνει πως μια καθαρή είσοδο που αποτελείται μονάχα από ΟΤΣ διευκολύνει το μοντέλο, ενώ περιπτώσεις όπως αυτές των σεναρίων 2 και 3 όπου ναι μεν υπάρχουν νέα δεδομένα, αλλά ενδεχομένως δεν είναι αρκετά ξεκάθαρα ή επαρκή, ζορίζουν το μοντέλο και δυσχεραίνουν την απόδοση του. Επιπλέον, σε σενάριο όπως το 4, το 5 ή και το 6, το μοντέλο φαίνεται να αρχίζει να προσαρμόζεται στα αρκετά καινούργια χαρακτηριστικά που έχει ως είσοδο, και τα χρησιμοποιεί για να προβλέψει ακόμα καλύτερα.

Κεφάλαιο 4: Επίλογος

4.1 Συμπεράσματα

Σκοπός αυτής της εργασίας ήταν να παρουσιάσει, να αναλύσει και να συγκρίνει διάφορες τοπολογίες τεχνητών νευρωνικών δικτύων για την πρόβλεψη της ΟΤΣ του επόμενου 24ωρου καθώς και μία εβδομάδας μπροστά για την Ελληνική χονδρεμπορική αγορά ηλεκτρικής ενέργειας. Η Ελληνική Αγορά Ενέργειας είναι δομημένη έτσι ώστε οι παραγωγοί να υποβάλλουν τις προσφορές τους βάσει της επόμενης ημέρας. Ο Διαχειριστής του Συστήματος επιλύει μία βελτιστοποίηση ρουτίνας με στόχο την ελαχιστοποίηση του κόστους παραγωγής ηλεκτρικής ενέργειας. Αυτή η λύση του προβλήματος βελτιστοποίησης οδηγεί στον υπολογισμό της ΟΤΣ. Ακριβής προβλέψεις της ΟΤΣ μπορούν να αποφέρουν αυξημένα κέρδη αλλά και μία πιο αποτελεσματική διαχείριση του χαρτοφυλακίου από την προοπτική των παραγωγών.

Η ικανότητα πρόβλεψης της κατανάλωσης και της ζήτησης ενέργειας είναι ζωτικής σημασίας, καθώς όχι μόνο βοηθά στη βελτίωση της αποδοτικότητας της παραγωγής, αλλά παρέχει επίσης σημαντικές πληροφορίες για τη συνολική οικονομία μιας χώρας με βάση τις τάσεις και τις μεταβολές της.

Οι συμμετέχοντες στην αγορά ενέργειας θα πρέπει να έχουν την ικανότητα να κατανοούν το μοντέλο που χρησιμοποιούν για τη λήψη αποφάσεων που μπορούν να οδηγήσουν σε οικονομικά κέρδη, αλλά και σε σημαντικές απώλειες. Τα κόστος των υπερσυμβάσεων ή υποσυμβάσεων πώλησης και αγοράς ισχύος σε πραγματικό χρόνο χρειάζεται ιδιαίτερη προσοχή, ώστε να μην οδηγήσουν σε τεράστιες οικονομικές απώλειες ή ακόμα και σε χρεοκοπία εταιρειών. Θα πρέπει οι ειδικοί του συγκεκριμένου τομέα να είναι σε θέση να τροποποιήσουν ή να διορθώσουν το μοντέλο πρόβλεψης που χρησιμοποιούν σύμφωνα με την εμπειρία τους. Με αυτή την αρχή, οι εταιρείες μπορούν να παρέχουν ένα περιβάλλον ολοκληρωμένης εσωτερικής γνώσης για τη διαχείριση του ενεργειακού τομέα.

Σε αρκετές περιπτώσεις προσομοιώσεων για την πρόβλεψη της ΟΤΣ του ηλεκτρικού ρεύματος της ελληνικής αγοράς ενέργειας για το έτος 2019 τα αποτελέσματα δεν ήταν βέλτιστα. Αυτό παρατηρήθηκε κυρίως στο CNN μοντέλο και στα σενάρια (κάθε

μοντέλου), όπου η πληροφορία που δινόταν στο μοντέλο δεν ήταν τόσο εκτενής και πλήρης. Συγκεκριμένα, στις περιπτώσεις αυτές παρατηρήθηκαν MAE μεγαλύτερα του 10 και όχι τόσο εύστοχα διαγράμματα, όπου οι καμπύλες πρόβλεψης απείχαν αρκετά από τις πραγματικές καμπύλες της ΟΤΣ για το 2019. Αυτό βεβαίως ήταν κάτι το σχετικά αναμενόμενο, καθώς ούτε τα CNN δεν ειδικεύονται στις προβλέψεις χρονοσειρών, όπως ήταν τα δεδομένα της παρούσας εργασίας, ούτε τα πρώιμα σενάρια λιγότερης πληροφορίας βοηθούν ιδιαίτερα τα ΤΝΔ. Βέβαια, ήταν αναγκαίο τα CNN μοντέλα, καθώς και τα πιο πρώιμα σενάρια αυτά, να δοκιμαστούν σε ένα τέτοιο πείραμα, ώστε να φανούν κάποια όρια και κάποιες άλλες δυνατότητες.

Παρόλα αυτά, σίγουρα εξάγεται επίσης το συμπέρασμα πως τα LSTM και τα GRU αποτελούν κάποια πολύ υποσχόμενα ΤΝΔ, τα οποία ακόμα και στα πλαίσια ενός δύσκολου προβλήματος και περίπλοκου σετ δεδομένων, κατάφεραν σε περιπτώσεις να έχουν πολύ καλή επίδοση, όπως MAE μικρότερα του 7 και κάποια αρκετά εύστοχα γραφήματα. Κατάφεραν να παράξουν καμπύλες που πολύ συχνά, και ιδίως στα σενάρια επαρκούς input πληροφορίας, έβρισκαν με μεγάλη ευστοχία την τάση της καμπύλης των ΟΤΣ, καθώς και το ακριβές βεληνεκές τιμών της, ενώ αρκετές φορές ταυτιζόντουσαν μερικώς και με τις πραγματικές ΟΤΣ καμπύλες.

Συνεπώς, υπάρχει η ελπίδα πως τα πορίσματα της εργασίας αυτής μπορούν να αποτελέσουν φάρους αισιοδοξίας για την μελλοντική πρόβλεψη ΟΤΣ, ιδιαίτερα αν χρησιμοποιηθούν καλύτερα μοντέλα, ενδεχομένως πιο εξελιγμένα, και με αξιοποίηση περισσότερης υπολογιστικής ισχύος.

4.2 Μελλοντικές επεκτάσεις

Στόχος για το μέλλον θα μπορούσε να είναι η ανάπτυξη ενός μοντέλου για την αντιμετώπιση των προβλημάτων πρόβλεψης της ΗΕ, ξεπερνώντας βασικούς περιορισμούς, καθώς και τις υφιστάμενους μεθόδους που χρησιμοποιούνται σήμερα [6]. Επίσης, οι προσομοιώσεις, κυρίως για τα LSTM και GRU, θα μπορούσαν να γίνουν με χρήση περισσότερης υπολογιστικής ισχύος, έτσι ώστε να λαμβάνουν μεγαλύτερες αριθμητικά τιμές παράμετροι όπως αυτές των εποχών, του evaluation interval, καθώς και του ορίζοντα (horizon) πρόβλεψης.

Ακόμη, μεγάλο ενδιαφέρον για κάποια μελλοντική επέκταση της έρευνας πάνω στην πρόβλεψη ΟΤΣ με χρήση ΤΝΔ θα μπορούσε να έχει η αξιοποίηση και άλλων μοντέλων,

όπως αυτό του MLP, ή ακόμα και συνδυασμός μοντέλων μεταξύ τους, όπως για παράδειγμα ένα μοντέλο που να χρησιμοποιεί συγχρόνως CNN και LSTM. Θα μπορούσε έτσι να διερευνηθεί το ποια μοντέλα και υπό ποιους ακριβώς όρους αποδίδουν καλύτερα, καθώς και το αν υπάρχουν συνθήκες που το CNN μπορεί να λειτουργήσει καλύτερα για τέτοιου είδους προβλήματα.

Γενικά, με χρήση τέτοιων μεθόδων όπως της παρούσας εργασίας, εταιρείες παραγωγής ενέργειας συμβατικών καύσιμων και ΑΠΕ θα μπορούσαν μελλοντικά να βελτιστοποιήσουν τη λειτουργία τους και να αυξήσουν τα κέρδη τους, βάσει των προβλέψεων των τιμών ΗΕ [7].

Η ακρίβεια της βραχυπρόθεσμης πρόβλεψης ΗΕ, έχει πολύ μεγάλη σημασία για όλους τους συμμετέχοντες. Μία βελτίωση 1% του μέσου απόλυτου σφάλματος (MAE), θα είχε ως αποτέλεσμα μία σημαντική μείωση του κόστους της τάξεως 0,1-0,35%, από τη βραχυπρόθεσμη πρόβλεψη ΗΕ, το οποίο συνεπάγεται με 1,5M δολάρια ετησίως για φορτίο 5GW. Βέβαια το εμπόριο και η πρόβλεψη των τιμών ΗΕ διαφέρει από τα άλλα εμπορεύματα, λόγω των ιδιαίτερων χαρακτηριστικών του, όπως η απαίτηση να υπάρχει ισορροπία μεταξύ της παραγωγής και της ζήτησης, λόγω της ανελαστικότητας της ζήτησης, της πλευράς της παραγωγής ολιγοπωλίου και της μη δυνατότητας αποθηκευσιμότητας της ΗΕ για μεγάλα χρονικά διαστήματα. Τα προαναφερθέντα δημιουργούν ορισμένα σημαντικά χαρακτηριστικά των τιμών ΗΕ, όπως υψηλή μεταβλητότητα, απότομες αυξήσεις τιμών, εποχικότητα σε διαφορετικές συχνότητες, μέση διαδικασία επαναφοράς. Λόγω αυτών των ιδιοσυγκρασιακών χαρακτηριστικών, η πρόβλεψη της ΗΕ γίνεται δυσκολότερη [7].

Παρότι όμως η πρόβλεψη της ΗΕ γίνεται δυσκολότερη, η επιτυχία τέτοιων τελευταίας τεχνολογίας μεθόδων, όπως της παρούσας εργασίας, θα μπορούσε να αποτελέσει ένα κομβικό game changer στην αγορά ηλεκτρικής ενέργειας, καθώς και στις ζωές όλων μας, στο σύντομο μέλλον. Είναι στοίχημα το πως θα μπορέσει η ακαδημαϊκή και ερευνητική κοινότητα να κινηθεί σε αυτή τη κατεύθυνση, αλλά επίσης κάτι πραγματικά ελπιδοφόρο.

Βιβλιογραφία

- [1] ΡΑΕ, “Raewebsite,” *Ρυθμιστική Αρχή Ενέργειας*, 01-Jan-2020. [Online]. Available: <https://www.rae.gr/>. [Accessed: 20-Aug-2022].
- [2] ΔΑΠΕΕΠ, “Διαχειριστής ΑΠΕ & εγγυήσεων Προέλευσης Α.Ε. - ΔΑΠΕΕΠ Α.Ε.,” *Διαχειριστής ΑΠΕ & Εγγυήσεων Προέλευσης Α.Ε. - ΔΑΠΕΕΠ Α.Ε.*, 08-Nov-2022. [Online]. Available: <https://www.dapeep.gr/>. [Accessed: 10-Nov-2022].
- [3] ΑΔΜΗΕ, “Ανεξάρτητος Διαχειριστής μεταφοράς ηλεκτρικής ενέργειας,” *ΑΔΜΗΕ*, 08-Nov-2022. [Online]. Available: <https://www.admie.gr/>. [Accessed: 10-Nov-2022].
- [4] ΔΕΔΔΗΕ, “ΔΕΔΔΗΕ,” *Διαχειριστής Ελληνικού Δικτύου Διανομής Ηλεκτρικής Ενέργειας*, 01-Nov-2022. [Online]. Available: <https://deddie.gr/>. [Accessed: 10-Nov-2022].
- [5] S. Stoft, *Power Systems Economics: Designing Markets for Electricity*, IEEE Press, John Wiley and Sons, 2002.
- [6] M. Castelli, A. Groznik, and A. Popovič, “Forecasting Electricity Prices: A Machine Learning Approach,” *Algorithms*, vol. 13, no. 5, p. 119, May 2020.
- [7] U. Ugurlu, I. Oksuz, and O. Tas, “Electricity Price Forecasting Using Recurrent Neural Networks,” *Energies*, vol. 11, no. 5, p. 1255, May 2018.
- [8] R. Weron, “Electricity price forecasting: A review of the state-of-the-art with a look into the future,” *International Journal of Forecasting*, vol. 30, no. 4, pp. 1030–1081, 2014.
- [9] Javier Contreras, Rosario Espinola, Francisco J. Nogales, Antonio J. Conejo, “ARIMA Models to Predict Next-Day Electricity Prices”, *IEEE TRANSACTIONS ON POWER SYSTEMS*, VOL.18, NO. 3, August 2003.
- [10] Francisco J. Nogales, Javier Contreras, Antonio J. Conejo, Rosario Espinola, “Forecasting Next-Day Electricity Prices by Time Series Models”, *IEEE TRANSACTIONS ON POWER SYSTEMS*, VOL.17, NO. 2, May 2002.
- [11] Oksuz and U. Ugurlu, “Neural Network Based Model Comparison for Intraday Electricity Price Forecasting,” *Energies*, vol. 12, no. 23, p. 4557, Nov. 2019.

- [12] F. Ziel and R. Weron, "Day-ahead electricity price forecasting with high-dimensional structures: Univariate vs. Multivariate Modeling Frameworks," *Energy Economics*, vol. 70, pp. 459–500, 2018.
- [13] R. Weron and A. Misiorek, "Forecasting spot electricity prices: A comparison of parametric and semiparametric time series models," *International Journal of Forecasting*, vol. 24, no. 4, pp. 744–763, 2008.
- [14] T. Kristiansen, "Forecasting Nord Pool Day-ahead prices with an autoregressive model," *Energy Policy*, vol. 49, pp. 328–332, 2012.
- [15] E. Raviv, K. E. Bouwman, and D. J. van Dijk, "Forecasting Day-ahead electricity prices: Utilizing hourly prices," *SSRN Electronic Journal*, 2013.
- [16] Antonio J. Conejo, Miguel A. Plazas, Rosa Espinola, Ana B. Molina, "Day-Ahead Electricity Price Forecasting Using the Wavelet Transform and ARIMA Models", *IEEE TRANSACTIONS ON POWER SYSTEMS*, VOL. 20, NO. 2, May 2005.
- [17] P. Mandal, T. Senjyu, and T. Funabashi, "Neural Networks approach to forecast several hour ahead electricity prices and loads in deregulated market," *Energy Conversion and Management*, vol. 47, no. 15-16, pp. 2128–2142, 2006.
- [18] J. P. S. Catalão, S. J. P. S. Mariano, V. M. F. Mendes, and L. A. F. M. Ferreira, "Short-term electricity prices forecasting in a competitive market: A neural network approach," *Electric Power Systems Research*, vol. 77, no. 10, pp. 1297–1304, 2007.
- [19] I. P. Panapakidis and A. S. Dagoumas, "Day-ahead electricity price forecasting via the application of artificial neural network based models," *Applied Energy*, vol. 172, pp. 132–151, 2016.
- [20] D. Keles, J. Scelle, F. Paraschiv, and W. Fichtner, "Extended forecast methods for day-ahead electricity spot prices applying Artificial Neural Networks," *Applied Energy*, vol. 162, pp. 218–230, 2016.
- [21] F. Ziel and R. Steinert, "Probabilistic mid- and long-term electricity price forecasting," *Renewable and Sustainable Energy Reviews*, vol. 94, pp. 251–266, 2018.
- [22] Χ. Κ. Σίμογλου, "Βέλτιστες στρατηγικές προσφορών σε ημερήσια αγορά ενέργειας από εταιρείες παραγωγής ηλεκτρικής ενέργειας," *Διδακτορική Διατριβή, Αριστοτέλειο Πανεπιστήμιο Θεσσαλονίκης, Ελλάδα*, 2011.

- [23] Α. Αναγνωστόπουλος, “Το παραλληλόγραμμο της ισορροπίας,” Αναμόρφωση, 2016.
[Online]. Available: <https://anamorfosis.net/blog/?p=10674>. [Accessed: 10-Nov-2022].
- [24] Δημήτριος Ι. Χατζηγιάννης, “Ολοκλήρωση Ενεργειακών Αγορών”, Διδακτορική Διατριβή, Αριστοτέλειο Πανεπιστήμιο Θεσσαλονίκης, Ιούνιος 2014.
- [25] Μαρίνα Γιαννούκου, “Πρόβλεψη οριακής τιμής ηλεκτρικής ενέργειας με τη χρήση τεχνητών νευρωνικών δικτύων”, Διπλωματική Εργασία, Ε.Μ.Π., Ιούλιος 2020.
- [26] J. Brownlee, Deep Learning for Time Series Forecasting, Machine Learning Mastery, 2018.
- [27] A. M. Turing, Computing machinery and intelligence, Mind, vol. 59, no. October, pp. 433-60, 1950
- [28] F. Rosenblatt, The Perceptron, a Perceiving and Recognizing Automaton Project Para. Cornell Aeronautical Laboratory, 1957.
- [29] Géron Aurélien, Hands-on machine learning with scikit-learn, keras and tensorflow: Concepts, tools, and techniques to build Intelligent Systems. Sebastapol, CA: O'Reilly, 2023.
- [30] Vishwas, Hands-on time series analysis with python. Apress, 2020.
- [31] I. Goodfellow, Y. Bengio, and A. Courville, Deep learning. Cambridge (EE. UU.): MIT Press, 2016.
- [32] X. Zhang, F. Shen, J. Zhao, and G. H. Yang, “Time Series forecasting using GRU neural network with multi-lag after decomposition,” Neural Information Processing, pp. 523–532, 2017.
- [33] Wang, Kang & Li, Kenli & Zhou, Liqian & Hu, Yikun & Zhongyao, Cheng & Liu, Jing & Chen, Cen, “Multiple Convolutional Neural Networks for Multivariate Time Series Prediction”, Neurocomputing, 2019.
- [34] D. Herkert, “Multivariate time series forecasting with Deep Learning,” *Medium*, 07-Jan-2022. [Online]. Available: <https://towardsdatascience.com/multivariate-time-series-forecasting-with-deep-learning-3e7b3e2d2bcf?gi=bdc06fd0e2c0>. [Accessed: 25-Nov-2022].
- [35] P. D. Alvin T. Tan, “Stacking machine learning models for multivariate time series,” *Medium*, 16-Mar-2022. [Online]. Available: <https://towardsdatascience.com/stacking->

machine-learning-models-for-multivariate-time-series-28a082f881. [Accessed: 25-Nov-2022].

- [36] T. A. I. Team, "Univariate Time Series with stacked LSTM, BiLSTM, and NeuralProphet," Towards AI, 24-May-2022. [Online]. Available: <https://towardsai.net/p/l/univariate-time-series-with-stacked-lstm-bilstm-and-neuralprophet>. [Accessed: 25-Nov-2022].
- [37] J. Brownlee, "How to develop LSTM models for time series forecasting," MachineLearningMastery.com, 27-Aug-2020. [Online]. Available: <https://machinelearningmastery.com/how-to-develop-lstm-models-for-time-series-forecasting/>. [Accessed: 25-Nov-2022].
- [38] J. Brownlee, "Multivariate time series forecasting with lstms in Keras," MachineLearningMastery.com, 20-Oct-2020.[Online]. Available: <https://machinelearningmastery.com/multivariate-time-series-forecasting-lstms-keras/>. [Accessed: 25-Nov-2022].
- [39] J. Brownlee, "How to develop convolutional neural network models for time series forecasting," MachineLearningMastery.com, 27-Aug-2020. [Online]. Available: <https://machinelearningmastery.com/how-to-develop-convolutional-neural-network-models-for-time-series-forecasting/>. [Accessed: 25-Nov-2022].
- [40] S. Kostadinov, "Understanding GRU networks," Medium, 10-Nov-2019.[Online]. Available:<https://towardsdatascience.com/understanding-gru-networks-2ef37df6c9be>. [Accessed: 25-Nov-2022].
- [41] R. Khandelwal, "Multivariate time series using gated recurrent unit -GRU," Medium, 17-Nov-2019.[Online].Available: <https://medium.datadriveninvestor.com/multivariate-time-series-using-gated-recurrent-unit-gru-1039099e545a>. [Accessed: 25-Nov-2022].
- [42] ENTSOE, "ENTSOE Transparency Platform," 5-Jan-2015. [Online]. Available: <https://transparency.entsoe.eu/>. [Accesed:25-Nov-2020].

Παράρτημα Α

Οι κώδικες σε python στην πλατφόρμα google colab

Οι κώδικες που παρατίθενται (LSTM, GRU, CNN) αφορούν το πρώτο σενάριο. Με βάση την ανάλυση και τους πίνακες παραπάνω γίνονται οι αντίστοιχες αλλαγές και για τα υπόλοιπα σενάρια σε δεδομένα και πίνακες, με τον βασικό αλγόριθμο να παραμένει ίδιος.

LSTM

```
# -*- coding: utf-8 -*-
"""LSTMScenario1.ipynb

Automatically generated by Colaboratory.

"""

import keras
import pandas as pd
import numpy as np
import tensorflow as tf
from sklearn import preprocessing
from keras import backend as K
import matplotlib.pyplot as plt
tf.random.set_seed(123)
np.random.seed(123)

from google.colab import drive
drive.mount('/content/drive')
data = pd.read_csv('/content/drive/My
Drive/Scenarios/Scenario1/scen1_trainX.csv',
skipinitialspace=True)
data1 = pd.read_csv('/content/drive/My
Drive/Scenarios/Scenario1/scen1_trainy.csv',
skipinitialspace=True)
data2 = pd.read_csv('/content/drive/My
Drive/Scenarios/Scenario1/scen1_testX.csv',
skipinitialspace=True)
data3 = pd.read_csv('/content/drive/My
Drive/Scenarios/Scenario1/scen1_testy.csv',
skipinitialspace=True)
df1=pd.concat([data2, data3], axis=1)
```

```

df1

df = pd.concat([data, data1], axis=1)
df

df.bfill(inplace=True)
df1.bfill(inplace=True)

df.isnull().sum().sum()

df1.isnull().sum().sum()

df.fillna(0)
df1.fillna(0)

df.isnull().sum().sum()

def custom_ts_multi_data_prep(dataset, target, start, end,
window, horizon):
    X = []
    y = []
    start = start + window
    if end is None:
        end = len(dataset) - horizon

    for i in range(start, end):
        indices = range(i-window, i)
        X.append(dataset[indices])

        indicey = range(i+1, i+1+horizon)
        y.append(target[indicey])
    return np.array(X), np.array(y)

validate = df1[['19 d-1', '19 d-7', '2019 VALUES']]
#df.drop(df.tail(10).index,inplace=True)

x_scaler = preprocessing.MinMaxScaler()
y_scaler = preprocessing.MinMaxScaler()
dataX = x_scaler.fit_transform(df[['17-18 d-1', '17-18 d-7',
'2017-2018 VALUES']])
dataY = y_scaler.fit_transform(df[['2017-2018 VALUES']])

hist_window = 168
horizon = 168
TRAIN_SPLIT = 14000
x_train_multi, y_train_multi = custom_ts_multi_data_prep(
    dataX, dataY, 0, TRAIN_SPLIT, hist_window, horizon)
x_val_multi, y_val_multi= custom_ts_multi_data_prep(
    dataX, dataY, TRAIN_SPLIT, None, hist_window, horizon)

#numpy. nan_to_num(x)

```

```

print ('Single window of past history')
print(x_train_multi[0])
print ('\n Target horizon')
print (y_train_multi[0])

np.nan_to_num(x_train_multi)
np.nan_to_num(y_train_multi)

BATCH_SIZE = 24
BUFFER_SIZE = 256

train_data_multi =
tf.data.Dataset.from_tensor_slices((x_train_multi,
y_train_multi))
train_data_multi =
train_data_multi.cache().shuffle(BUFFER_SIZE).batch(BATCH_SIZE).repeat()

val_data_multi =
tf.data.Dataset.from_tensor_slices((x_val_multi,
y_val_multi))
val_data_multi = val_data_multi.batch(BATCH_SIZE).repeat()

optimizer=tf.keras.optimizers.Adam(lr=0.05)
lstm_multi = tf.keras.models.Sequential()
lstm_multi.add(tf.keras.layers.LSTM(150,input_shape=x_train_multi.shape[-2:],return_sequences=True))
lstm_multi.add(tf.keras.layers.Dropout(0.5)),
lstm_multi.add(tf.keras.layers.LSTM(units=100,return_sequences=False)),
lstm_multi.add(tf.keras.layers.Dropout(0.5)),
lstm_multi.add(tf.keras.layers.Dense(units=horizon)),
lstm_multi.compile(optimizer=optimizer, loss='mse')

lstm_multi.save('/content/drive/My
Drive/Scenarios/Scenario1/LSTM_Multivariatel.h5')

model_path='/content/drive/My
Drive/Scenarios/Scenario1/LSTM_Multivariate.h5'

x_train_multi=np.nan_to_num(x_train_multi)

np.isnan(np.min(x_train_multi))

EVALUATION_INTERVAL = 150
EPOCHS = 20
history = lstm_multi.fit(train_data_multi,
epochs=EPOCHS,steps_per_epoch=EVALUATION_INTERVAL,validation_
data=val_data_multi, validation_steps=50,verbose =1,
callbacks
=[tf.keras.callbacks.EarlyStopping(monitor='val_loss',

```

```

min_delta=0, patience=10, verbose=1,
mode='min'),tf.keras.callbacks.ModelCheckpoint(model_path,mon
itor='val_loss', save_best_only=True, mode='min',
verbose=0)])

Trained_model = tf.keras.models.load_model(model_path)

plt.plot(history.history['loss'])
plt.plot(history.history['val_loss'])
plt.title('Model loss')
plt.ylabel('loss')
plt.xlabel('epoch')
plt.legend(['train loss', 'validation loss'], loc='upper
left')
plt.rcParams["figure.figsize"] = [16,9]
plt.show()

# Show the model architecture
Trained_model.summary()

data_val = x_scaler.fit_transform(df1[['19 d-1', '19 d-7',
'2019 VALUES']].head(168))

val_rescaled = data_val.reshape(1, data_val.shape[0],
data_val.shape[1])

Predicted_results = Trained_model.predict(val_rescaled)

Predicted_results

Predicted_results_Inv_trans =
y_scaler.inverse_transform(Predicted_results)

Predicted_results_Inv_trans

from sklearn import metrics
def timeseries_evaluation_metrics_func(y_true, y_pred):

    def mean_absolute_percentage_error(y_true, y_pred):
        y_true, y_pred = np.array(y_true), np.array(y_pred)
        return np.mean(np.abs((y_true - y_pred) / y_true)) *
100

    print('Evaluation metric results:-')
    print(f'MSE is : {metrics.mean_squared_error(y_true,
y_pred)}')
    print(f'MAE is : {metrics.mean_absolute_error(y_true,
y_pred)}')
    print(f'RMSE is :
{np.sqrt(metrics.mean_squared_error(y_true, y_pred))}')
    print(f'MAPE is : {mean_absolute_percentage_error(y_true,
y_pred)}')

```

```

    print(f'R2 is : {metrics.r2_score(y_true,
y_pred)}',end='\n\n')

timeseries_evaluation_metrics_func(validate['2019
VALUES'].head(168),Predicted_results_Inv_trans[0])

plt.plot( list(validate['2019 VALUES'].head(168)))
plt.plot( list(Predicted_results_Inv_trans[0]))
plt.title("Actual vs Predicted")
plt.ylabel("2019 VALUES")
plt.legend(('Actual','predicted'))
plt.show()

```

GRU

```

# -*- coding: utf-8 -*-
"""GRUScenario1

Automatically generated by Colaboratory.

"""

import pandas as pd
import numpy as np
import tensorflow as tf
from sklearn import preprocessing
import matplotlib.pyplot as plt
tf.random.set_seed(123)
np.random.seed(123)

from google.colab import drive
drive.mount('/content/drive')
data = pd.read_csv('/content/drive/My
Drive/Scenarios/Scenario1/scen1_trainX.csv',
skipinitialspace=True)
data1 = pd.read_csv('/content/drive/My
Drive/Scenarios/Scenario1/scen1_trainy.csv',
skipinitialspace=True)
data2 = pd.read_csv('/content/drive/My
Drive/Scenarios/Scenario1/scen1_testX.csv',
skipinitialspace=True)
data3 = pd.read_csv('/content/drive/My
Drive/Scenarios/Scenario1/scen1_testy.csv',
skipinitialspace=True)
df1=pd.concat([data2, data3], axis=1)

df1

df = pd.concat([data, data1], axis=1)

```

```

df

df.bfill(inplace=True)
df1.bfill(inplace=True)

df.isnull().sum().sum()

df1.isnull().sum().sum()

def custom_ts_multi_data_prep(dataset, target, start, end,
window, horizon):
    X = []
    y = []
    start = start + window
    if end is None:
        end = len(dataset) - horizon

    for i in range(start, end):
        indices = range(i-window, i)
        X.append(dataset[indices])

        indicey = range(i+1, i+1+horizon)
        y.append(target[indicey])
    return np.array(X), np.array(y)

validate = df1[['2019 VALUES']]

x_scaler = preprocessing.MinMaxScaler()
y_scaler = preprocessing.MinMaxScaler()
dataX = x_scaler.fit_transform(df[['17-18 d-1', '17-18 d-7',
'2017-2018 VALUES']])
dataY = y_scaler.fit_transform(df[['2017-2018 VALUES']])

hist_window = 200
horizon = 50
TRAIN_SPLIT = 14000
x_train_multi, y_train_multi = custom_ts_multi_data_prep(
    dataX, dataY, 0, TRAIN_SPLIT, hist_window, horizon)
x_val_multi, y_val_multi = custom_ts_multi_data_prep(
    dataX, dataY, TRAIN_SPLIT, None, hist_window, horizon)

print ('Single window of past history')
print(x_train_multi[0])
print ('\n Target horizon')
print (y_train_multi[0])

np.nan_to_num(x_train_multi)
np.nan_to_num(y_train_multi)

BATCH_SIZE = 256
BUFFER_SIZE = 256

```

```

train_data_multi =
tf.data.Dataset.from_tensor_slices((x_train_multi,
y_train_multi))
train_data_multi =
train_data_multi.cache().shuffle(BUFFER_SIZE).batch(BATCH_SIZE).repeat()

val_data_multi =
tf.data.Dataset.from_tensor_slices((x_val_multi,
y_val_multi))
val_data_multi = val_data_multi.batch(BATCH_SIZE).repeat()

optimizer=tf.keras.optimizers.Adam(learning_rate=0.05)
GRU_model = tf.keras.models.Sequential([
    tf.keras.layers.GRU(100,
input_shape=x_train_multi.shape[-2:],return_sequences=True),
    tf.keras.layers.Dropout(0.5),
    tf.keras.layers.GRU(units=50,return_sequences=False),
    tf.keras.layers.Dropout(0.5),
    tf.keras.layers.Dense(units=horizon),
])
GRU_model.compile(optimizer=optimizer, loss='mse')

GRU_model.save('/content/drive/My
Drive/Scenarios/Scenario4/LSTM_Multivariate4.h5')
model_path='/content/drive/My
Drive/Scenarios/Scenario4/LSTM_Multivariate4.h5'

x_train_multi=np.nan_to_num(x_train_multi)

np.isnan(np.min(x_train_multi))

EVALUATION_INTERVAL = 150
EPOCHS = 20
history = GRU_model.fit(train_data_multi,
epochs=EPOCHS,steps_per_epoch=EVALUATION_INTERVAL,validation_
data=val_data_multi, validation_steps=50,verbose =1,
callbacks
=[tf.keras.callbacks.EarlyStopping(monitor='val_loss',
min_delta=0, patience=10, verbose=1,
mode='min'),tf.keras.callbacks.ModelCheckpoint(model_path,mon
itor='val_loss', save_best_only=True, mode='min',
verbose=0)])

Trained_model = tf.keras.models.load_model(model_path)

# Show the model architecture
Trained_model.summary()

plt.plot(history.history['loss'])

```

```

plt.plot(history.history['val_loss'])
plt.title('Model loss')
plt.ylabel('loss')
plt.xlabel('epoch')
plt.legend(['train loss', 'validation loss'], loc='upper
left')
plt.rcParams["figure.figsize"] = [16,9]
plt.show()

data_val = x_scaler.fit_transform(df1[['19 d-1', '19 d-7',
'2019 VALUES']].head(200))

val_rescaled = data_val.reshape(1, data_val.shape[0],
data_val.shape[1])

Predicted_results = Trained_model.predict(val_rescaled)

Predicted_results

Predicted_results_Inv_trans =
y_scaler.inverse_transform(Predicted_results)

Predicted_results_Inv_trans

from sklearn import metrics
def timeseries_evaluation_metrics_func(y_true, y_pred):

    def mean_absolute_percentage_error(y_true, y_pred):
        y_true, y_pred = np.array(y_true), np.array(y_pred)
        return np.mean(np.abs((y_true - y_pred) / y_true)) *
100
    print('Evaluation metric results:-')
    print(f'MSE is : {metrics.mean_squared_error(y_true,
y_pred)}')
    print(f'MAE is : {metrics.mean_absolute_error(y_true,
y_pred)}')
    print(f'RMSE is :
{np.sqrt(metrics.mean_squared_error(y_true, y_pred))}')
    print(f'MAPE is : {mean_absolute_percentage_error(y_true,
y_pred)}')
    print(f'R2 is : {metrics.r2_score(y_true,
y_pred)}',end='\n\n')

timeseries_evaluation_metrics_func(validate['2019
VALUES'].head(50),Predicted_results_Inv_trans[0])

plt.plot( list(validate['2019 VALUES'].head(50)))
plt.plot( list(Predicted_results_Inv_trans[0]))
plt.title("Actual vs Predicted")
plt.ylabel("2019 VALUES")
plt.legend(('Actual','predicted'))

```

```
plt.show()
```

CNN

```
# -*- coding: utf-8 -*-
"""CNNScenario1

Automatically generated by Colaboratory.

"""

import tensorflow as tf
import matplotlib.pyplot as plt
import numpy as np
import pandas as pd
from sklearn import preprocessing
from keras import backend as K
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense
from tensorflow.keras.layers import
Flatten,TimeDistributed,RepeatVector
from tensorflow.keras.layers import Conv1D
from tensorflow.keras.layers import MaxPool1D
from tensorflow.keras.layers import Dropout
tf.random.set_seed(123)
np.random.seed(123)

from google.colab import drive
drive.mount('/content/drive')
data = pd.read_csv('/content/drive/My
Drive/Scenarios/Scenario4/scen4_trainX.csv',
skipinitialspace=True)
data1 = pd.read_csv('/content/drive/My
Drive/Scenarios/Scenario4/scen4_trainy.csv',
skipinitialspace=True)
data2 = pd.read_csv('/content/drive/My
Drive/Scenarios/Scenario4/scen4_testX.csv',
skipinitialspace=True)
data3 = pd.read_csv('/content/drive/My
Drive/Scenarios/Scenario4/scen4_testy.csv',
skipinitialspace=True)
df1=pd.concat([data2, data3], axis=1)

df1

df = pd.concat([data, data1], axis=1)
df

df.bfill(inplace=True)
```

```

df1.bfill(inplace=True)

df.isnull().sum().sum()

df1.isnull().sum().sum()

def custom_ts_multi_data_prep(dataset, target, start, end,
window, horizon):
    X = []
    y = []
    start = start + window
    if end is None:
        end = len(dataset) - horizon

    for i in range(start, end):
        indices = range(i-window, i)
        X.append(dataset[indices])

        indicey = range(i+1, i+1+horizon)
        y.append(target[indicey])
    return np.array(X), np.array(y)

validate = df1[['2019 VALUES']]

x_scaler = preprocessing.MinMaxScaler()
y_scaler = preprocessing.MinMaxScaler()
dataX = x_scaler.fit_transform(df[['17-18 d-1', '17-18 d-7',
'2017-2018 VALUES']])
dataY = y_scaler.fit_transform(df[['2017-2018 VALUES']])

hist_window = 500
horizon = 1000
TRAIN_SPLIT = 14000
x_train_multi, y_train_multi = custom_ts_multi_data_prep(
    dataX, dataY, 0, TRAIN_SPLIT, hist_window, horizon)
x_val_multi, y_val_multi= custom_ts_multi_data_prep(
    dataX, dataY, TRAIN_SPLIT, None, hist_window, horizon)

print ('Single window of past history')
print(x_train_multi[0])
print ('\n Target horizon')
print (y_train_multi[0])

np.nan_to_num(x_train_multi)
np.nan_to_num(y_train_multi)

BATCH_SIZE = 256
BUFFER_SIZE = 256

```

```

train_data_multi =
tf.data.Dataset.from_tensor_slices((x_train_multi,
y_train_multi))
train_data_multi =
train_data_multi.cache().shuffle(BUFFER_SIZE).batch(BATCH_SIZE).repeat()

val_data_multi =
tf.data.Dataset.from_tensor_slices((x_val_multi,
y_val_multi))
val_data_multi = val_data_multi.batch(BATCH_SIZE).repeat()

optimizer=tf.keras.optimizers.Adam(learning_rate=0.05)
model = Sequential()
model.add(Conv1D(filters=64, kernel_size=3,
activation='relu', input_shape=(x_train_multi.shape[1],
x_train_multi.shape[2])))
model.add(MaxPool1D(pool_size=2))
model.add(Dropout(0.5))
model.add(Flatten())
model.add(Dense(30, activation='relu'))
model.add(Dropout(0.5))
model.add(Dense(horizon))
model.compile(optimizer=optimizer, loss='mse')

model.save('/content/drive/My
Drive/Scenarios/Scenario6/CNN_Multivariate6.h5')

model_path='/content/drive/My
Drive/Scenarios/Scenario6/CNN_Multivariate6.h5'

x_train_multi=np.nan_to_num(x_train_multi)

np.isnan(np.min(x_train_multi))

EVALUATION_INTERVAL = 100
EPOCHS = 20
history = model.fit(train_data_multi, epochs=EPOCHS,
steps_per_epoch=EVALUATION_INTERVAL,
validation_data=val_data_multi, validation_steps=50,
verbose=1,

callbacks=[tf.keras.callbacks.EarlyStopping(monitor='val_loss',
min_delta=0, patience=10, verbose=1, mode='min'),
tf.keras.callbacks.ModelCheckpoint(model_path,
monitor='val_loss', save_best_only=True, mode='min',
verbose=0)])

Trained_model = tf.keras.models.load_model(model_path)

# Show the model architecture

```

```

Trained_model.summary()

plt.plot(history.history['loss'])
plt.plot(history.history['val_loss'])
plt.title('Model loss')
plt.ylabel('loss')
plt.xlabel('epoch')
plt.legend(['train loss', 'validation loss'], loc='upper
left')
plt.rcParams["figure.figsize"] = [16,9]
plt.show()

data_val = x_scaler.fit_transform(df1[['19 d-1', '19 d-7',
'2019 VALUES']].head(500))

val_rescaled = data_val.reshape(1, data_val.shape[0],
data_val.shape[1])

Predicted_results = Trained_model.predict(val_rescaled)

Predicted_results

Predicted_results_Inv_trans =
y_scaler.inverse_transform(Predicted_results)

Predicted_results_Inv_trans

from sklearn import metrics
def timeseries_evaluation_metrics_func(y_true, y_pred):

    def mean_absolute_percentage_error(y_true, y_pred):
        y_true, y_pred = np.array(y_true), np.array(y_pred)
        return np.mean(np.abs((y_true - y_pred) / y_true)) *
100
    print('Evaluation metric results:-')
    print(f'MSE is : {metrics.mean_squared_error(y_true,
y_pred)}')
    print(f'MAE is : {metrics.mean_absolute_error(y_true,
y_pred)}')
    print(f'RMSE is :
{np.sqrt(metrics.mean_squared_error(y_true, y_pred))}')
    print(f'MAPE is : {mean_absolute_percentage_error(y_true,
y_pred)}')
    print(f'R2 is : {metrics.r2_score(y_true,
y_pred)}',end='\n\n')

timeseries_evaluation_metrics_func(validate['2019
VALUES'].head(1000),Predicted_results_Inv_trans[0])

plt.plot( list(validate['2019 VALUES'].head(1000)))
plt.plot( list(Predicted_results_Inv_trans[0]))

```

```
plt.title("Actual vs Predicted")  
plt.ylabel("2019 VALUES")  
plt.legend(('Actual', 'predicted'))  
plt.show()
```