



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΣΧΟΛΗ ΠΟΛΙΤΙΚΩΝ ΜΗΧΑΝΙΚΩΝ

ΤΟΜΕΑΣ ΥΔΑΤΙΚΩΝ ΠΟΡΩΝ ΚΑΙ ΠΕΡΙΒΑΛΛΟΝΤΟΣ

**Διερεύνηση του προβλήματος πρόγνωσης παραγωγής
ενέργειας σε διάφορες χρονικές κλίμακες από
Υδροηλεκτρικούς Ταμιευτήρες**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

του

ΒΑΤΣΙΚΟΥΡΙΔΗ ΙΩΑΝΝΗ

Επιβλέπων : Ανδρέας Ευστρατιάδης
Επίκουρος Καθηγητής Ε.Μ.Π.

Συνεπιβλέπων : Ιωάννης Τσουκαλάς
Δρ. Πολιτικός Μηχανικός ΕΜΠ

Αθήνα, Μάρτιος 2022

ΠΕΡΙΕΧΟΜΕΝΑ

ΠΡΟΛΟΓΟΣ.....	6
ΠΕΡΙΛΗΨΗ.....	9
ABSTRACT.....	10
1. ΕΙΣΑΓΩΓΗ	11
1.1 Αντικείμενο και Στόχοι	11
1.2 Διάρθρωση της Εργασίας	12
2. ΥΔΡΟΗΛΕΚΤΡΙΚΗ ΕΝΕΡΓΕΙΑ ΚΑΙ ΕΡΓΑ	14
2.1 Υδροηλεκτρική Ενέργεια	14
2.2 Λειτουργία και Κατηγοριοποίηση Υδροηλεκτρικών Έργων	17
2.3 Ηλεκτρομηχανολογικός Εξοπλισμός-Υδροστρόβιλοι.....	19
2.3.1 Τυπικός Η/Μ εξοπλισμός υδροηλεκτρικών έργων	19
2.3.2 Στρόβιλοι Δράσης.....	20
2.3.3 Στρόβιλοι Αντίδρασης	22
3. ΠΡΟΣΟΜΟΙΩΣΗ ΛΕΙΤΟΥΡΓΙΑΣ ΥΔΡΟΗΛΕΚΤΡΙΚΩΝ ΤΑΜΙΕΥΤΗΡΩΝ.....	24
3.1 Δεδομένα Εισόδου.....	24
3.2 Προσομοίωση υδατικού ισοζυγίου ταμιευτήρα	25
4. ΓΕΝΙΚΑ ΧΑΡΑΚΤΗΡΙΣΤΙΚΑ ΤΑΜΙΕΥΤΗΡΩΝ ΕΝΔΙΑΦΕΡΟΝΤΟΣ ΚΑΙ ΑΠΟΤΕΛΕΣΜΑΤΑ ΠΡΟΣΟΜΟΙΩΣΕΩΝ ΛΕΙΤΟΥΡΓΙΑΣ.....	33
4.1 Φράγμα Κρεμαστών	33
4.1.1 Γενικά Στοιχεία.....	33
4.1.2 Τεχνικά Χαρακτηριστικά.....	34
4.1.3 Μοντέλο Προσομοίωσης Λειτουργίας Ταμιευτήρα	35
4.2 Φράγμα Μεσοχώρας.....	37
4.2.1 Γενικά Στοιχεία.....	37

4.2.2	Τεχνικά Χαρακτηριστικά.....	38
4.2.3	Μοντέλο Προσομοίωσης Λειτουργίας Ταμιευτήρα	39
4.3	Φράγμα Ευήγου	41
4.3.1	Γενικά Στοιχεία.....	41
4.3.2	Τεχνικά Χαρακτηριστικά.....	41
4.3.3	Μοντέλο Προσομοίωσης Λειτουργίας Ταμιευτήρα	42
5.	ΘΕΩΡΗΤΙΚΟ ΠΛΑΙΣΙΟ ΓΙΑ ΤΑ ΠΡΟΣΔΙΟΡΙΣΤΙΚΑ ΜΟΝΤΕΛΑ	
	ΠΡΟΒΛΕΨΕΩΝ.....	45
5.1	Έννοια Στοχαστικής Διεργασίας.....	45
5.2	Εισαγωγή στις Χρονοσειρές	46
5.2.1	Ποιοτικά Χαρακτηριστικά Χρονοσειρών	46
5.2.2	Στατιστική Ανάλυση Χρονοσειρών.....	48
5.2.3	Στασιμότητα.....	50
5.3	Στάσιμα Υποδείγματα Χρονοσειρών ARMA.....	51
5.3.1	Αυτοπαλίνδρομο Υπόδειγμα AR(1)	52
5.3.2	Μέθοδοι Εκτίμησης Παραμέτρων AR(p) Υποδειγμάτων	54
5.4	Τεχνητά Νευρωνικά Δίκτυα και LSTM.....	57
5.4.1	Διαδικασίες Μηχανικής Μάθησης.....	57
5.4.2	Βιολογικά Νευρωνικά Δίκτυα	59
5.4.3	Τεχνητά Νευρωνικά Δίκτυα	60
5.4.4	Συναρτήσεις Ενεργοποίησης	62
5.4.5	Συνάρτηση Κόστους	66
5.4.6	Αλγόριθμος Οπισθοδρόμησης Σφάλματος (Backpropagation)	67
5.4.7	Πρόληψη υπερπροσαρμογής	68
5.4.8	Αλγόριθμοι Βελτιστοποίησης.....	71
5.4.9	Αναδρομικά Νευρωνικά Δίκτυα	74
5.4.10	Νευρωνικό Δίκτυο Μακράς-Βραχείας Μνήμης (LSTM).....	75

5.4.11	Νευρωνικό δίκτυο μακράς-βραχείας μνήμης διπλής κατεύθυνσης (Bidirectional-LSTM)	78
5.5	Μέθοδος Κ-Πλησιέστερων Γειτόνων (K-Nearest Neighbors)	79
5.6	Μέτρα αξιολόγησης Προβλέψεων	80
5.6.1	Μέσο Σφάλμα (Mean Error)	81
5.6.2	Μέσο Απόλυτο Σφάλμα (Mean Absolute Error)	81
5.6.3	Μέσο Ποσοστιαίο Σφάλμα (Mean Percentage Error)	82
5.6.4	Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (Mean Absolute Percentage Error)	82
5.6.5	Μέσο Τετραγωνικό Σφάλμα (Mean Square Error)	82
5.6.6	Ρίζα Μέσου Τετραγωνικού Σφάλματος (Root Mean Squared Error)	82
5.6.7	Συντελεστής Προσδιορισμού R^2 (Coefficient of Determination)	83
6.	ΕΦΑΡΜΟΓΗ ΜΕΘΟΔΩΝ ΠΡΟΒΛΕΨΗΣ – ΥΛΟΠΟΙΗΣΗ ΣΤΗΝ ΠΥΘΟΝ	84
6.1	Προβλέψεις με το Μοντέλο AR(1)	85
6.1.1	Εφαρμογή στον Ταμιευτήρα των Κρεμαστών	87
6.1.2	Εφαρμογή στον Ταμιευτήρα της Μεσοχώρας	90
6.1.3	Εφαρμογή στον Ταμιευτήρα του Ευήνου	92
6.2	Προβλέψεις με το Μοντέλο LSTM	95
6.2.1	Εφαρμογή στον Ταμιευτήρα των Κρεμαστών	97
6.2.2	Εφαρμογή στον Ταμιευτήρα της Μεσοχώρας	101
6.2.3	Εφαρμογή στον Ταμιευτήρα του Ευήνου	104
6.3	Προβλέψεις με το Μοντέλο KNN	107
6.3.3	Εφαρμογή στον Ταμιευτήρα των Κρεμαστών	110
6.3.2	Εφαρμογή στον Ταμιευτήρα της Μεσοχώρας	113
6.3.3	Εφαρμογή στον Ταμιευτήρα του Ευήνου	116
6.4	Δείκτης Οικονομικής Αξιολόγησης Μοντέλων και Σύγκριση Αποτελεσμάτων	118

7.	ΠΟΣΟΤΙΚΟΠΟΙΗΣΗ ΤΗΣ ΑΒΕΒΑΙΟΤΗΤΑΣ ΜΕ ΤΗ ΧΡΗΣΗ ΣΥΖΕΥΞΕΩΝ (COPULAS).....	122
8.	ΣΥΜΠΕΡΑΣΜΑΤΑ ΚΑΙ ΠΡΟΤΑΣΕΙΣ.....	129
	ΒΙΒΛΙΟΓΡΑΦΙΑ	132

ΠΡΟΛΟΓΟΣ

Μία πολύ όμορφη εμπειρία φτάνει στο τέλος της. Λένε πως η αρχή είναι το ήμισυ του παντός, όμως στη δική μου περίπτωση, το τέλος επιφύλασσε τις πιο όμορφες και έντονες εκπλήξεις . Κάτω από συνθήκες υγειονομικής κρίσης, γνώρισα μια ομάδα ανθρώπων που συνέβαλε ώστε οι τελευταίες αναμνήσεις από την φοιτητική μου πορεία να είναι οι πιο όμορφες και γλυκές. Οφείλω και θέλω να ευχαριστήσω τον καθέναν τους ξεχωριστά.

Πρώτα από όλους ευχαριστώ τον κ. Ανδρέα Ευστρατιάδη, Επίκουρο Καθηγητή Ε.Μ.Π, που με αγκάλιασε και με εμπιστεύθηκε από την πρώτη στιγμή. Η διαρκής βοήθεια, οι συμβουλές και ο χρόνος που διέθεσε είναι πολύ σημαντικά όταν μιλάμε για το ρόλο ενός δασκάλου. Τα πιο σημαντικά όμως έχουν να κάνουν με το ήθος, την ευγένεια, την θετική ενέργεια και την καθαρή ματιά. Αυτά έμειναν στο τέλος της ημέρας και μου έδωσαν κίνητρο να δουλέψω και να αφοσιωθώ. Τον ευχαριστώ για τις συζητήσεις που κάναμε, ακαδημαϊκού ενδιαφέροντος και μη, για την ευαισθησία που έδειξε σε ό,τι με απασχολούσε, ενώ δε θα ξεχάσω ποτέ την συμβολή του στα πρώτα επαγγελματικά μου βήματα.

Στη συνέχεια, θα ήθελα να ευχαριστήσω τον Δρ. Ιωάννη Τσουκαλά τόσο για την συνεισφορά του στην εργασία, όσο και για το πηγαίο ενδιαφέρον του καθ' όλη τη διάρκεια εκπόνησής της. Με αμεσότητα και μεταδοτικότητα με έκανε να εξοικειωθώ γρήγορα με έννοιες που αγνοούσα και ήταν παρών τις στιγμές που χρειαζόμουν μια ψύχραιμη οπτική. Πάντα με αγάπη και μεράκι για αυτό που κάνει, μου έδωσε κίνητρο και συνέβαλε καθοριστικά στην πρόοδο της εργασίας.

Έπειτα, οφείλω να ευχαριστήσω θερμά τις Υποψήφιες Δρ. Σακκή Γεωργία-Κωνσταντίνα και Ρίσβα Κωνσταντίνα για την στήριξη τους. Παρά το νεαρό της ηλικίας τους είναι σε θέση να δώσουν καίριες συμβουλές και η βοήθεια τους ήταν πολύτιμη. Δημιούργησαν ένα ιδιαίτερα ευχάριστο και παραγωγικό πλαίσιο συνεργασίας και εύχομαι ολόψυχα καλή συνέχεια και πρόοδο στην ακαδημαϊκή τους καριέρα.

Ακόμη, ευχαριστώ τον Δρ. Παναγιώτη Κοσσιέρη για την ηθική στήριξη και το ενδιαφέρον που έδειξε. Τόσο οι παρατηρήσεις του όσο και οι χρήσιμες συμβουλές του αποδείχτηκαν σημαντικές για την εκπόνηση αυτής της εργασίας.

Τέλος, ευχαριστώ την οικογένεια και τους φίλους μου για το γεγονός ότι βρίσκονταν δίπλα μου καθ' όλη τη διάρκεια των σπουδών μου και με στήριζαν πνευματικά και ηθικά.

Βατσικουρίδης Ιωάννης

Αθήνα, Μάρτιος 2022

ΠΕΡΙΛΗΨΗ

Η υδροηλεκτρική ενέργεια, από μεγάλης κλίμακας έργα είναι χρονικά ρυθμιζόμενη, γεγονός που την καθιστά αξιόπιστη πηγή παραγωγής ενέργειας και δη σε περιόδους αιχμής. Στην παρούσα εργασία διενεργούνται προβλέψεις εισροών για τους ταμιευτήρες των Κρεμαστών, της Μεσοχώρας και του Ευήνου με τρία διαφορετικά ντετερμινιστικά μοντέλα και για δύο χρονικούς ορίζοντες πρόγνωσης σε μηνιαία κλίμακα (4 και 12 μήνες). Αρχικά δοκιμάζεται το μοντέλο αυτοπαλινδρόμησης 1^{ης} τάξης AR(1) με πλεονέκτημα τον μικρό υπολογιστικό του φόρτο. Στη συνέχεια χρησιμοποιούνται τεχνητά νευρωνικά δίκτυα και συγκεκριμένα το LSTM (Long-Short Term Memory) που έχει γενικώς καλή απόδοση σε σειριακά δεδομένα αλλά μεγάλο υπολογιστικό χρόνο και τέλος, ο αλγόριθμος KNN (K-Nearest Neighbors), μια μη παραμετροποιημένη μέθοδος μηχανικής μάθησης που βασίζεται στην ομοιότητα των ιστορικών δεδομένων με τα προβλεπόμενα. Μετά την πρόγνωση των εισροών, η τελευταία μετατρέπεται σε πρόγνωση παραγωγής ενέργειας μέσω του υδατικού ισοζυγίου του εκάστοτε ταμιευτήρα και των αντίστοιχων κανόνων λειτουργίας του. Τελικά, προκύπτει ότι το απλό Αυτοπαλίνδρομο Μοντέλο 1^{ης} Τάξης AR(1) έχει πολύ καλή απόδοση σε μέσες και χαμηλές ροές αλλά δε μπορεί να προβλέψει ικανοποιητικά την μεταβλητότητα τους κατά τους χειμερινούς μήνες. Αντίθετα, τα δύο υποδείγματα μάθησης μηχανών είναι σημαντικά πιο ικανά. Το LSTM έχει την καλύτερη απόδοση όσον αφορά τις προβλέψεις 4 μηνών κάτι που αντανακλάται και στην οικονομική αξιολόγηση που μελετήθηκε. Αφότου πραγματοποιήθηκαν οι σημειακές προβλέψεις το μοντέλο με την καλύτερη επίδοση (LSTM) χρησιμοποιήθηκε ώστε να δοθούν και πιθανοτικές προβλέψεις με τη χρήση συζεύξεων (copulas) , αντιλαμβανόμενοι πως σε επίπεδο επιχειρησιακής λειτουργίας των ταμιευτήρων η ποσοτικοποίηση της αβεβαιότητας είναι εξίσου, αν όχι πιο σημαντική, καθώς προετοιμάζει τον διαχειριστή του έργου τόσο για το αισιόδοξο όσο και για το απαισιόδοξο σενάριο.

Οι αναλύσεις μας εστιάζουν στην διαφορετική επίδοση των τριών προσδιοριστικών μοντέλων στον εκάστοτε ταμιευτήρα λόγω της διαφορετικής κλίμακας, λειτουργίας και χωρητικότητας τους, γεγονός που γεννά την ιδέα για τη δημιουργία ενός υβριδικού μοντέλου πρόγνωσης που να εκμεταλλεύεται τα δυνατά στοιχεία κάθε υποδείγματος.

ABSTRACT

Hydroelectric power from large-scale dams is time-regulated, which makes it a reliable source of energy production, especially in peak periods. In the present study, inflow forecasts are conducted for the Kremasta, Mesochora and Evinos reservoirs with the use of three different deterministic models and for two forecast time horizons on monthly scale (4 and 12 months ahead). Firstly, the Autoregressive Model of first order AR(1) is used, with the advantage of its small computational load. Then, artificial neural networks are used, and specifically the LSTM (Long-Short Term Memory) model, which generally has good performance in serial data but big computing time as a drawback, and finally, we try the KNN algorithm (K-Nearest Neighbors), a non-parameterized machine learning method based on the similarity of the historical data with the predicted ones. After the inflow forecasts, the latter is converted into a forecast of energy production through the simulation of the water balance of each reservoir and its respective operating rules. Finally, it turns out that the simple AR (1) model has very good performance in medium and low flows but cannot adequately predict their variability during the winter months. In contrast, the two machine learning models are significantly more capable. The LSTM model has the best performance in terms of 4-month forecasts, which is reflected on the financial evaluation that has been studied. After the point forecasts were made, the best-performing model (LSTM) was used to make probabilistic predictions using copulas. As far as the operational level of the reservoirs is concerned, the quantification of predictive uncertainty is as much, if not more important, as it prepares the project manager for both the optimistic and the pessimistic scenario.

Our analyzes focus on the different performance of the three deterministic models for each reservoir due to their different scale, operation and capacity, which gives rise to the idea of creating a hybrid forecast model that takes advantage of the strengths of each model.

1. ΕΙΣΑΓΩΓΗ

1.1 Αντικείμενο και Στόχοι

Το γεγονός ότι η υδροηλεκτρική ενέργεια, από μεγάλης κλίμακας έργα (με δυνατότητα ταμίευσης), είναι χρονικά ρυθμιζόμενη, της προσδίδει σημαντική αξία. Εκεί οφείλεται κατά βάση και η υπεροχή της έναντι των υπολοίπων ανανεώσιμων πηγών ενέργειας, στη δυνατότητά της δηλαδή, να παράγεται κατά βούληση σε περιόδους αιχμής και υψηλής ζήτησης. Αντικείμενο της παρούσας εργασίας αποτελεί η διενέργεια προβλέψεων απορροής σε μεγάλους υδροηλεκτρικούς ταμιευτήρες που αποσκοπούν στην εκτίμηση της παραγωγής ενέργειας σε μηνιαία κλίμακα. Το ενδιαφέρον προκύπτει ακριβώς από την αποθηκευτική ικανότητα των ταμιευτήρων που οδηγεί σε εξομάλυνση των σφαλμάτων της απορροής, όταν το ζητούμενο είναι μια σταθερή ενεργειακή απόληψη (στόχος παραγωγής πρωτεύουσας ενέργειας).

Η λειτουργία ενός υδροηλεκτρικού ταμιευτήρα σχετίζεται με την λήψη αποφάσεων. Οι αποφάσεις αυτές έχουν ως στόχο να εκτιμήσουν το πότε είναι επωφελής η παραγωγή ενέργειας και πότε η αποθήκευση του νερού, ενώ καθορίζονται σε μεγάλο βαθμό από το επίπεδο της ζήτησης της ηλεκτρικής ενέργειας αλλά και από την τιμή αυτής. Συνεπώς, με την διενέργεια προβλέψεων απορροής και συνεπαγόμενα της ενεργειακής παραγωγής, γίνεται προσπάθεια διευκόλυνσης της απόφασης του εκάστοτε διαχειριστή του έργου σε επίπεδο επιχειρησιακής λειτουργίας. Η σωστή διαχείριση των ελλειμμάτων δεν αποσκοπεί μόνο στην κερδοφορία αλλά και στην κατά το δυνατόν κάλυψη της ζήτησης.

Το πρακτικό ενδιαφέρον της εργασίας εντοπίζεται στην επιλογή του κατάλληλου μοντέλου για τη διενέργεια των προβλέψεων. Δοκιμάζονται ντετερμινιστικά μοντέλα πρόγνωσης διαφορετικής πολυπλοκότητας και υπολογιστικού φόρτου σε ταμιευτήρες διαφορετικών χαρακτηριστικών και για διαφορετικούς χρονικούς ορίζοντες, ενώ προβλέψεις δίνονται και μετά από χρήση πιθανοτικής μεθόδου. Με δεδομένο ότι τα σφάλματα της πρόγνωσης της απορροής σε έναν μεγάλο ταμιευτήρα είναι γενικά μεγαλύτερα από τα αντίστοιχα της ενεργειακής παραγωγής, πόση αξία έχει η χρησιμοποίηση πολύπλοκων υποδειγμάτων πρόγνωσης; Ποια μοντέλα έχουν τις

καλύτερες επιδόσεις και πως αυτό αντανακλά στο οικονομικό όφελος για τον διαχειριστή του έργου; Μπορεί ένα μοντέλο να έχει καλύτερη επίδοση για μια χρονοσειρά (ταμιευτήρα) και χειρότερη για άλλη; Ποια είναι τα κατάλληλα μέτρα για την αξιολόγηση αυτής της επίδοσης; Είναι προτιμότερη η χρησιμοποίηση προσδιοριστικής ή πιθανοτικής πρόγνωσης; Αυτά είναι μόνο μερικά από τα ερωτήματα που έδωσαν κίνητρο για την πραγματοποίηση αυτής της μελέτης και μαζί με πολλά ακόμα που προέκυψαν στην πορεία της εργασίας, έγινε προσπάθεια να απαντηθούν στα επόμενα κεφάλαια.

1.2 Διάρθρωση της Εργασίας

Η παρούσα εργασία διαρθρώνεται σε 8 κεφάλαια.

Στο πρώτο κεφάλαιο γίνεται αναφορά στο αντικείμενο της εργασίας, τους αρχικούς προβληματισμούς που αποτέλεσαν κίνητρο, και στους στόχους στους οποίους αποβλέπουμε.

Το δεύτερο κεφάλαιο εστιάζει σε γενικά στοιχεία που αφορούν την Υδροηλεκτρική ενέργεια και τους Υδροηλεκτρικούς Ταμιευτήρες, ενώ γίνεται αναφορά στον Ηλεκτρομηχανολογικό εξοπλισμό που απαιτείται και στον ακριβή τρόπο μετατροπής της δυναμικής ενέργειας του νερού σε ηλεκτρική.

Στο τρίτο κεφάλαιο παρουσιάζεται ο τρόπος λειτουργίας ενός ταμιευτήρα μέσω της προσομοίωσης του υδατικού ισοζυγίου του.

Στο τέταρτο κεφάλαιο δίνονται τα γενικά και τεχνικά χαρακτηριστικά των ταμιευτήρων ενδιαφέροντος και αναλύονται τα επιμέρους μοντέλα προσομοίωσης της λειτουργίας τους.

Το πέμπτο κεφάλαιο αναφέρεται στο θεωρητικό πλαίσιο των προσδιοριστικών μοντέλων με τα οποία θα γίνει η διενέργεια των προβλέψεων απορροής και ενέργειας. Πρόκειται για το μοντέλο αυτοπαλινδρόμησης 1^{ης} τάξης, τα νευρωνικά δίκτυα LSTM και ένα υπόδειγμα μη επιβλεπόμενης μάθησης, το KNN. Παρουσιάζονται επίσης τα μέτρα αξιολόγησης της επίδοσης των υποδειγμάτων που χρησιμοποιήθηκαν.

Στο έκτο κεφάλαιο αναλύεται η μεθοδολογία που ακολουθήθηκε για κάθε ντετερμινιστικό μοντέλο πρόγνωσης. Παρουσιάζονται τα αποτελέσματα, γίνεται σύγκριση μεταξύ αυτών και δίνεται μία οικονομική αξιολόγηση με βάση ορισμένες παραδοχές για την τιμή πώλησης πρωτεύουσας και δευτερεύουσας ενέργειας.

Στο έβδομο κεφάλαιο παρουσιάζεται μια μεθοδολογία για την ποσοτικοποίηση της αβεβαιότητας. Το προσδιοριστικό μοντέλο που είχε την καλύτερη επίδοση επιλέγεται και χρησιμοποιούνται τα αποτελέσματα του ώστε να δοθεί και πιθανοτική πρόγνωση με τη χρήση συζεύξεων (copulas), συναρτήσεων δηλαδή, που συνδέουν την πολυδιάστατη συνάρτηση κατανομής με τις μονοδιάστατες περιθώριες συναρτήσεις.

Στο όγδοο κεφάλαιο συνοψίζονται οι ερευνητικοί στόχοι που επιτυγχάνονται και τα συμπεράσματα που εξάγονται από την παραπάνω διαδικασία, ενώ γίνεται αναφορά στις προοπτικές ανάπτυξης του παρόντος θέματος και τις προοπτικές μελλοντικής έρευνας.

2. ΥΔΡΟΗΛΕΚΤΡΙΚΗ ΕΝΕΡΓΕΙΑ ΚΑΙ ΕΡΓΑ

2.1 Υδροηλεκτρική Ενέργεια

Η παραγωγή ενέργειας είναι μία από τις σημαντικές χρήσεις νερού που εξυπηρετούν οι ταμιευτήρες. Η ποσότητα της ενέργειας εξαρτάται από τον διαθέσιμο όγκο νερού στον ταμιευτήρα και από την υψομετρική διαφορά που δημιουργείται μεταξύ της στάθμης του νερού στον ταμιευτήρα και της στάθμης εξόδου του αγωγού φυγής στο σταθμό παραγωγής. Αρχικά, το νερό που βρίσκεται σε κάποιο υψόμετρο, έχει δυναμική ενέργεια η οποία μετατρέπεται σε υδραυλική (κινητική ενέργεια και ενέργεια πίεσης), όταν αυτό ρέει προς περιοχές χαμηλότερου υψομέτρου. Έπειτα, η υδραυλική ενέργεια, μέσω μιας υδροδυναμικής μηχανής, που ονομάζεται στρόβιλος και των συνοδών του Η/Μ έργων (γεννήτρια, μετασχηματιστής), μετατρέπεται τελικώς σε ηλεκτρική. Η βασική σχέση που διέπει την παραγόμενη ενέργεια, σε μια χρονική στιγμή t , E_t , δίνεται από τη σχέση:

$$E_t = \psi V_t H_t \quad (2.1)$$

όπου ψ είναι η ειδική ενέργεια, δηλαδή η ενέργεια ανά μονάδα όγκου και ανά μονάδα ύψους πτώσης, V_t είναι ο όγκος νερού που διέρχεται από το στρόβιλο και H_t το ολικό ύψος πτώσης. Η ειδική ενέργεια δίνεται από τη σχέση:


$$\psi = 0.02725 \eta \frac{H_n}{H} \quad (2.2)$$

όπου η είναι ο βαθμός απόδοσης του στρόβιλου, H το ολικό, ακαθάριστο ύψος πτώσης και H_n το καθαρό ύψος πτώσης, το οποίο προκύπτει με αφαίρεση των απωλειών ενέργειας (γραμμικών και τοπικών) από το ολικό ύψος πτώσης.

Η ενέργεια που μπορεί να παραχθεί από έναν ταμιευτήρα διακρίνεται σε πρωτεύουσα και δευτερεύουσα. Πρωτεύουσα ενέργεια καλείται η ποσότητα εκείνη που δύναται να παραχθεί χωρίς καμία ή με πολύ μικρή διακοπή για το σύνολο της περιόδου λειτουργίας του. Η ενέργεια που παράγεται πέραν της πρωτεύουσας ονομάζεται δευτερεύουσα, και συναντάται κυρίως σε χρονικές περιόδους μεγάλων εισροών στον ταμιευτήρα. Οι μεγαλύτερες εκροές πραγματοποιούνται με σκοπό την αποφυγή υπερχειλίσεων.

Η πρόσβαση στην ενέργεια αποτελεί πολύτιμο στοιχείο για την διατήρηση της ποιότητας ζωής του ανθρώπου σε ένα υψηλό επίπεδο, και συμβάλλει στην οικονομική

και κοινωνική ανάπτυξη. Η παγκόσμια ζήτηση σε ενέργεια αυξάνεται με γοργούς ρυθμούς, καθιστώντας την επαρκή πρόσβαση σε όλους μία συνεχή πρόκληση. Από το 1950 μέχρι το 2019 η παγκόσμια κατανάλωση σε ενέργεια έχει αυξηθεί από τις 28 TWh στις 159 TWh, αύξηση της τάξης του 470% (Our World in Data, 2020) . Μάλιστα, σύμφωνα με τη Διαχειριστική Αρχή Ενεργειακών Πληροφοριών των Ηνωμένων Πολιτειών (U.S. Energy Information Administration), προβλέπεται περαιτέρω αύξηση της παγκόσμιας ζήτησης σε ενέργεια κατά 50% μέχρι το 2050. Η εν λόγω ραγδαία αύξηση της ζήτησης, σε συνδυασμό με την παγκόσμια περιβαλλοντική ευαισθητοποίηση, έχουν συμβάλει στη σταδιακή απομάκρυνση από τα συμβατικά ορυκτά καύσιμα και στην επακόλουθη στροφή προς ανανεώσιμες πηγές, όπως η υδροηλεκτρική ενέργεια, η αιολική ενέργεια, η ηλιακή ενέργεια, η βιομάζα και η γεωθερμία. Συγκεκριμένα, το 2019 το 11% της συνολικής παγκόσμιας ενέργειας και το 26 % της παγκόσμιας ηλεκτρικής ενέργειας προήλθε από ανανεώσιμες πηγές (Our World in Data, 2020).



Εικόνα 2.1. Παγκόσμια Κατανάλωση Ενέργειας 1950-2019 κατά είδος (Our World in Data)

Όπως φαίνεται και στην Εικόνα (2.1), η παραγωγή υδροηλεκτρικής ενέργειας έχει το μεγαλύτερο ποσοστό της συνολικής ανανεώσιμης ενέργειας του πλανήτη, χάρη σε πληθώρα πλεονεκτημάτων που εμφανίζει σε σχέση με τις υπόλοιπες μορφές ενέργειας.

Κάποια από τα πιο σημαντικά πλεονεκτήματα της υδροηλεκτρικής ενέργειας που συντελούν στην παραπάνω στατιστική εικόνα είναι τα εξής:

- Οι βαθμοί απόδοσης των υδροστρόβιλων των υδροηλεκτρικών έργων (ΥΗΕ) μπορούν να υπερβούν το 90%, ποσοστό πολύ μεγάλο σε σχέση με άλλες πηγές ενέργειας. Για παράδειγμα, η μετατροπή της κινητικής ενέργειας του ανέμου σε ηλεκτρική έχει βαθμούς απόδοσης 30 – 40% και η μετατροπή της ηλιακής ακτινοβολίας σε ηλεκτρική ενέργεια 12 – 17%. Ακόμα και ο βαθμός απόδοσης των ορυκτών καυσίμων, ο οποίος γενικά είναι μεγαλύτερος του 70%, όταν γίνεται άμεση χρήση τους για παραγωγή θερμότητας, στην περαιτέρω μετατροπή της θερμότητας για παραγωγή ηλεκτρικής ενέργειας, ο ολικός βαθμός απόδοσης κυμαίνεται μεταξύ 35% και 50%.
- Οι υδατοπτώσεις είναι ανανεώσιμη πηγή ενέργειας και δεν αντιμετωπίζεται κίνδυνος εξάντλησής τους.
- Η διάρκεια οικονομικής ζωής των ΥΗΕ είναι μεγάλη, της τάξεως των 50 ετών. Τα έργα πολιτικού μηχανικού από τα οποία απαρτίζονται έχουν χρόνο ζωής ως και 100 έτη.
- Τα ΥΗΕ εκμεταλλεύονται την φυσική ροή του ποταμού χωρίς να υποβαθμίζουν την ποιότητα του νερού. Ακόμη, δεν αφήνουν απόβλητα ή κατάλοιπα και δεν μολύνουν το περιβάλλον.
- Οι υδροηλεκτρικοί σταθμοί με ταμιευτήρες προσφέρουν λειτουργική ευελιξία, καθώς επιτρέπουν αναρρύθμιση των απορροών μέσω της αποθήκευσης, και συνεπώς μπορούν να ανταποκριθούν άμεσα στις διακυμάνσεις της ζήτησης ηλεκτρικής ενέργειας. Συνεπώς, τα έργα μεγάλης ισχύος λειτουργούν για την κάλυψη των αιχμών του δικτύου κατά την διάρκεια των οποίων η αξία της KWh είναι πολλαπλάσια της αξίας της KWh βάσης.
- Το νερό των ποταμών είναι εγχώριος πόρος, ο οποίος, σε αντίθεση με τα καύσιμα ή το φυσικό αέριο, δεν υπόκειται σε διακυμάνσεις της αγοράς. Επίσης, το κόστος της παραγόμενης ηλεκτρικής ενέργειας δεν παρουσιάζει μεγάλες διακυμάνσεις και αφορά, ουσιαστικά, στις αποσβέσεις του έργου, αφού το κόστος λειτουργίας των ΥΗΕ είναι μικρό.
- Οι υδροηλεκτρικές εγκαταστάσεις φέρνουν υποδομές, όπως ηλεκτρικά δίκτυα και οδικά έργα, σε απομακρυσμένες κοινότητες, αναπτύσσοντας έτσι την

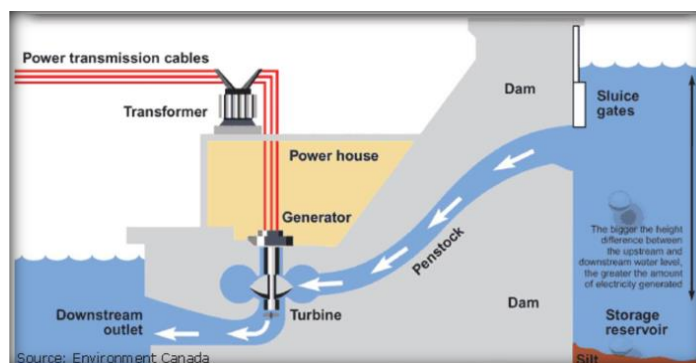
οικονομία, επεκτείνοντας την πρόσβαση στην υγεία και την εκπαίδευση και βελτιώνοντας την ποιότητα ζωής.

- Η κατασκευή ΥΗΕ συνδυάζεται συχνά με άλλες χρήσεις νερού, όπως άρδευση, ύδρευση, ρύθμιση πλημμύρας, αλιεία, αναψυχή, κλπ.

Η υδροηλεκτρική ενέργεια χρησιμοποιείται εδώ και αιώνες και αυτό δεν προβλέπεται να αλλάξει. Η συνολική παγκόσμια εγκατεστημένη ισχύς υδροηλεκτρικών έργων θα πρέπει να αυξηθεί κατά 800 GW τα επόμενα 20 χρόνια, προκειμένου να επιτευχθούν οι κύριες ενεργειακές συνιστώσες των Στόχων Αειφόρου Ανάπτυξης, όπως αυτοί τέθηκαν από τον Οργανισμό Ηνωμένων Εθνών (IHA, 2020). Στην Ελλάδα η εγκατεστημένη ισχύς των ΥΗΕ ανέρχεται περίπου στα 3500 MW και εξασφαλίζει το 10% περίπου της ηλεκτρικής ενέργειας της χώρας (Μαμάσης και Κουτσογιάννης, 2019 Μαμάσης κ.ά., 2018).

2.2 Λειτουργία και Κατηγοριοποίηση Υδροηλεκτρικών Έργων


Τα υδροηλεκτρικά έργα αξιοποιούν την υδροδυναμική ενέργεια, μέσω μετατροπής της πρώτα σε υδραυλική, στη συνέχεια σε μηχανική (ενέργεια περιστροφής των στροβίλων), και στην συνέχεια σε ηλεκτρική, μέσω γεννήτριας. Η λειτουργία των υδροηλεκτρικών μονάδων βασίζεται στην κίνηση του νερού λόγω της υψομετρικής διαφοράς μεταξύ των σημείων εισόδου και εξόδου. Η ποσότητα της παραγόμενης ενέργειας εξαρτάται τόσο από την υψομετρική διαφορά, όσο και από την ποσότητα του νερού που διέρχεται από τους στροβίλους. Για το λόγο αυτόν μόνο σε περιοχές με σημαντικές βροχοπτώσεις, πλούσιες πηγές και κατάλληλη γεωλογική διαμόρφωση είναι δυνατόν να κατασκευαστούν υδροηλεκτρικά έργα (Wikipedia,2020).



Εικόνα 2.2. Συνήθης διάταξη ΥΗΕ με φράγμα (U.S Geological Survey)

Όσον αφορά τις παραπάνω αρχές λειτουργίας, τα υδροηλεκτρικά έργα δεν διαφέρουν μεταξύ τους. Ωστόσο, υπάρχουν διαφορετικές κατηγορίες που αφορούν το μέγεθος, την διάταξη και τον τρόπο αξιοποίησης της υδροδυναμικής ενέργειας. Συγκεκριμένα, τα υδροηλεκτρικά έργα διαχωρίζονται σε μεγάλα ή μικρά, με βάση την εγκατεστημένη ισχύ τους και δευτερευόντως με βάση το ύψος πτώσης του νερού. Σύμφωνα με τη νομοθεσία, ένα υδροηλεκτρικό έργο χαρακτηρίζεται ως μικρό αν η εγκατεστημένη ισχύς του είναι μικρότερη των 15 MW. Το όριο αυτό εφαρμόζεται τώρα και στην Ελλάδα, ενώ σε άλλες χώρες εφαρμόζονται όρια από 5 έως 15 MW (Μαμάσης κ.ά., 2018). Υποκατηγορίες των ΜΥΗΕ αποτελούν τα έργα εγκατεστημένης ισχύος μέχρι 0.01 MW (pico), μέχρι 0.1 MW (micro) και μέχρι 1 MW (mini). Με βάση το ύψος πτώσης κατηγοριοποιούνται ως εξής:

- Έργα μικρού ύψους, για $H < 30$ m
- Έργα μεσαίου ύψους, για $30 \text{ m} < H < 200\text{-}300$ m
- Έργα μεγάλου ύψους, για $H > 200\text{-}300$ m



Εικόνα 2.3. Έργα πολιτικού μηχανικού στους Υδροηλεκτρικούς Ταμιευτήρες (Ευστρατιάδης κ.α., 2019)

Μια ακόμα ενδιαφέρουσα κατηγοριοποίηση των ΥΗΕ είναι με βάση την χρονική κατανομή της παραγόμενης ενέργειας. Στα έργα βάσης, οι στρόβιλοι βρίσκονται σε συστηματική λειτουργία και διοχετεύεται ενέργεια στο σύστημα στο μεγαλύτερο διάστημα του χρόνου. Αντίθετα, τα έργα αιχμής επιδιώκουν την παροχή ενέργειας στα διασυνδεδεμένα ηλεκτρικά δίκτυα μόνο κατά τις ώρες αιχμής της ενεργειακής ζήτησης. Έτσι λειτουργούν συνήθως ΥΗΕ υψηλής εγκατεστημένης ισχύος με μεγάλης χωρητικότητας ανάντη ταμιευτήρες, μέσω των οποίων ετεροχρονίζεται κατά βούληση η παραγωγή ενέργειας από τις φυσικές εισροές. Υποκατηγορία των έργων αιχμής αποτελούν και τα έργα αντιστρεπτής λειτουργίας, τα οποία στοχεύουν στην παραγωγή ενέργειας τις ώρες αιχμής της ζήτησης και στην άντληση τις ώρες περίσσειας ηλεκτρικής ενέργειας. Τα έργα αυτά αποτελούνται συνήθως από δύο ταμιευτήρες σε διαφορετικά υψόμετρα και αντλούν νερό από τον ταμιευτήρα χαμηλότερου υψομέτρου («φόρτιση») κατά τις περιόδους μικρής ζήτησης και στην συνέχεια το χρησιμοποιούν για την παραγωγή ενέργειας («εκφόρτιση») κατά τις περιόδους αιχμής. Η παραπάνω διαδικασία αξιοποιεί τη διαθέσιμη υδροδυναμική ενέργεια μεταξύ των δεξαμενών, όπως μια συμβατική μονάδα υδροηλεκτρικής ενέργειας.


Στην παρούσα διπλωματική εργασία, εκτός από το κομμάτι της ανάλυσης για την πραγματοποίηση προβλέψεων εισροής, εστιάζουμε στους μεγάλους υδροηλεκτρικούς ταμιευτήρες και στην ανάλυση του μοντέλου προσομοίωσης της λειτουργίας τους.

2.3 Ηλεκτρομηχανολογικός Εξοπλισμός-Υδροστρόβιλοι

2.3.1 Τυπικός Η/Μ εξοπλισμός υδροηλεκτρικών έργων

Η λειτουργία ενός ΥΗΕ εξαρτάται άμεσα και από τον εγκατεστημένο ηλεκτρομηχανολογικό εξοπλισμό. Τα δύο σημαντικότερα μέρη αυτού είναι οι υδροστρόβιλοι (turbines) και η ηλεκτρογεννήτρια (generator), όπως φαίνονται στην Εικόνα (2.4). Ο υδροστρόβιλος μετατρέπει την ενέργεια του ρέοντος νερού σε μηχανική ενέργεια, ενώ η ηλεκτρογεννήτρια μετατρέπει αυτή τη μηχανική ενέργεια σε ηλεκτρική ενέργεια. Η λειτουργία μιας γεννήτριας βασίζεται στις αρχές που ανακαλύφθηκαν από τον Faraday, σύμφωνα με τις οποίες εάν ένα πηνίο περιστραφεί μέσα σ' ένα μαγνητικό πεδίο, τότε στις άκρες του πηνίου παράγεται ηλεκτρικό ρεύμα. Πιο αναλυτικά, η γεννήτρια αποτελείται από το σταθερό της μέρος που λέγεται στάτορας, στο οποίο υπάρχουν μαγνήτες και το κινητό μέρος που λέγεται ρότορας, στο

οποίο υπάρχουν πηγία. Η ενέργεια του νερού που πέφτει από μεγάλο υψόμετρο περιστρέφει τον υδροστρόβιλο ο οποίος με την σειρά του θέτει σε κίνηση τον ρότορα. Αναλυτικότερη αναφορά στην λειτουργία των υδροστροβίλων γίνεται στην συνέχεια. Επισημαίνεται, πως εκτός των δύο προαναφερθέντων κύριων μελών του ηλεκτρομηχανολογικού εξοπλισμού, μια υδροηλεκτρική εγκατάσταση έχει και ανάγκες σε δευτερεύοντα ή βοηθητικό εξοπλισμό, όπως είναι ο ρυθμιστής στροφών, οι μετασχηματιστές, οι ηλεκτρικοί πίνακες και τα ανυψωτικά μηχανήματα.



Εικόνα 2.4 -Σύστημα Υδροστροβίλου και Ηλεκτρογεννήτριας (U.S. Army Corps of Engineers)


2.3.2 Στρόβιλοι Δράσης

Οι στροβιλομηχανές δράσης (impulse turbines) αποτελούνται από έναν δρομέα (runner) με σκαφίδια (buckets), που τίθενται σε κίνηση μέσω του νερού, το οποίο εκτοξεύεται από ακροφύσια (nozzles). Τα ακροφύσια προσδίδουν στο νερό ταχύτητες που φτάνουν τα 100 ως 150 m/s, ενώ η ταχύτητες στον αγωγό προσαγωγής δεν υπερβαίνουν τα 4 ως 6 m/s. Με αυτόν τον τρόπο η δυναμική ενέργεια πτώσης του νερού μετατρέπεται σε κινητική ενέργεια, η οποία με την σειρά της μετατρέπεται σε περιφερειακή ταχύτητα του τροχού κατά την πρόσκρουση του νερού στα σκαφίδια. Τα σκαφίδια σχεδιάζονται έτσι ώστε να απορροφούν όσο το δυνατό περισσότερη από την κινητική ενέργεια του νερού, για να διατηρούν την ταχύτητα εξόδου όσο το δυνατό μικρότερη. Η ταχύτητα περιστροφής του τροχού πρέπει να είναι υποδιπλάσια της ταχύτητας του νερού.

Η τυπικότερη κατηγορία υδροστροβίλων δράσης είναι η μηχανή Pelton, η οποία αναπτύχθηκε το 1880 από τον Αμερικάνο εφευρέτη Lester Allan Pelton (IHA, 2020). Συνήθως, αυτός ο τύπος χρησιμοποιείται όταν η υδατόπτωση γίνεται από μεγάλα ύψη αλλά η παροχή είναι μικρή. Σε στροβίλους τέτοιας κατηγορίας, το νερό προσκρούει

στα σκαφίδια και μεταφέρει περίπου το 97% της κινητικής του ενέργειας στην περιστροφική ενέργεια του δρομέα. Μέσω ειδικής διάταξης του ακροφυσίου, η φλέβα νερού διασπάται σε δύο ίσα μέρη, τα οποία εκτοξεύονται προς το εκάστοτε σκαφίδιο, όπως φαίνεται στην Εικόνα (2.5). Ο διαχωρισμός τόσο της ροής όσο και των σκαφιδίων σε δύο τμήματα συμβάλει στην ελαχιστοποίηση των απωλειών ενέργειας.

Ένας επίσης δημοφιλής τύπος υδροστροβίλου δράσης είναι ο Turgo, ο οποίος αναπτύχθηκε από τον Gilkes το 1919, με βάση τον στρόβιλο Pelton. Στον εν λόγω τύπο, η δέσμη του νερού προσπίπτει στον δρομέα υπό κλίση, ο οποίος χρησιμοποιεί ένα αντί για δύο πτερύγια, τα οποία είναι στενότερα και οικονομικότερα από τα αντίστοιχα του στροβίλου Pelton. Ενδείκνυται για σημαντικό εύρος μέσων και μεγάλων υψών πτώσης (15-300 m), καθώς και για μεγάλο εύρος παροχών, αφού εμποδίζεται η αλληλεπίδραση του εκτοξευόμενου νερού μεταξύ των διαδοχικών πτερυγίων. Σε σχέση με τον τύπο Pelton παρατηρείται μικρή πτώση του βαθμού απόδοσης ο οποίος είναι $\approx 87\%$



Εικόνα 2.5 - Σκαφίδιο Στροβίλου Pelton



Εικόνα 2.6 - Σκαφίδιο στροβίλου Turgo


2.3.3 Στρόβιλοι Αντίδρασης

Οι υδροστρόβιλοι αντίδρασης (reaction turbines) αποτελούνται από έναν δρομέα με πτερύγια, συνδεδεμένο σε κινητήριο άξονα. Ο δρομέας και τα πτερύγια τοποθετούνται σε περίβλημα που είναι πλήρως καλυμμένο με νερό και συνεπώς ο στρόβιλος βρίσκεται συνεχώς υπό πίεση. Η δυναμική ενέργεια του νερού μετατρέπεται σε κινητική ενέργεια και πίεση, οι οποίες με την σειρά τους μετατρέπονται σε ταχύτητα περιστροφής του δρομέα και κατ' επέκταση του άξονα, ο οποίος είναι συνδεδεμένος με την γεννήτρια όπως φαίνεται στην Εικόνα (2.7). Ο άξονας είναι συνήθως κατακόρυφος και το νερό εξέρχεται κατακόρυφα μέσα στον αγωγό φυγής.

Η συγκεκριμένη κατηγορία στροβίλων έχει την δυνατότητα μεταβολής της κλίσης των πτερυγίων, η οποία προσδίδει στον υδροστρόβιλο ευελιξία, ώστε να λειτουργεί με τον μέγιστο βαθμό απόδοσης στις διάφορες συνθήκες ύψους πτώσης και παροχής. Επίσης, για να μειωθεί η κινητική ενέργεια που παραμένει στο νερό στην έξοδο του στροβίλου, τοποθετείται κωνικός σωλήνας (ή διαχύτης) μεταξύ του στροβίλου και της επιφάνειας του νερού (draft tube). Οι στρόβιλοι αντίδρασης εξασφαλίζουν υψηλότερο βέλτιστο βαθμό απόδοσης σε σχέση με τους στροβίλους δράσης, αλλά για μικρότερη περιοχή παροχών (Μάργαρης, 2015).

Ένας εκ των κύριων τύπων υδροστροβίλων αντίδρασης είναι ο Francis. Ο συγκεκριμένος τύπος αναπτύχθηκε από τον Άγγλο μηχανικό James Francis το 1849 και αποτελεί μέχρι σήμερα τον ευρύτερα χρησιμοποιούμενο τύπο υδροστροβίλου παγκοσμίως. Ο Francis είναι στρόβιλος αξονικής ή μικτής ροής και χρησιμοποιείται συνήθως για μέσα γεωδαιτικά ύψη (60 έως 150 m) και μέτριες παροχές. Σε αντίθεση με τον επίσης ευρέως διαδεδομένο στρόβιλο Kaplan, ο Francis αποτελείται από σταθερά πτερύγια στον δρομέα και είναι αντιπροσωπευτικός σαν μηχανή διαγώνιας (ημιαξονικής) ροής. Ο στρόβιλος αντίδρασης Kaplan αναπτύχθηκε από τον Αυστριακό καθηγητή Viktor Kaplan το 1913 και αποτελεί στρόβιλο αξονικής ροής. Χρησιμοποιείται συνήθως σε υδροηλεκτρικά έργα επί της κοίτης, με μικρά ύψη πτώσης νερού (≤ 30 m) και μεγάλες παροχές. Επισημαίνεται σε αυτό το σημείο πως η επιλογή του καταλληλότερου τύπου υδροστροβίλου για κάθε έργο αποτελεί απόφαση υψίστης σημασίας για την οικονομική βιωσιμότητα του. Σε πολλές περιπτώσεις, για δεδομένη υδραυλική πτώση και παροχή σχεδιασμού η επιλογή του τύπου του υδροστροβίλου δεν είναι μονοσήμαντη. Στις περιπτώσεις αυτές λαμβάνονται υπόψη και άλλα κριτήρια,

όπως το κόστος του υδροστροβίλου, το κόστος του αντίστοιχου υδροηλεκτρικού σταθμού στέγασης και το εύρος λειτουργίας του.



Εικόνα 2.7 - Αναπαράσταση Στροβίλου Kaplan

3. ΠΡΟΣΟΜΟΙΩΣΗ ΛΕΙΤΟΥΡΓΙΑΣ ΥΔΡΟΗΛΕΚΤΡΙΚΩΝ ΤΑΜΙΕΥΤΗΡΩΝ

Το πρώτο βήμα για την διενέργεια προβλέψεων παραγωγής ενέργειας σε υδροηλεκτρικούς ταμιευτήρες σχετίζεται με την προσομοίωση λειτουργίας αυτών, μέσω των εξισώσεων του υδατικού ισοζυγίου. Το υδατικό ισοζύγιο περιγράφει τη σχέση μεταξύ προσφοράς και ζήτησης νερού για την κάλυψη διαφόρων αναγκών (π.χ. παραγωγή ενέργειας) από τον ταμιευτήρα, για το χρονικό ορίζοντα που εξετάζεται. Επειδή η ακριβής περιγραφή των διεργασιών ενός τέτοιου συστήματος είναι εξαιρετικά πολύπλοκη, αναγκαστικά γίνονται ορισμένες παραδοχές που αφορούν τόσο στον τρόπο λειτουργίας του συστήματος όσο και στη διαδοχική σειρά των διεργασιών μέσα σε αυτό. Ανάλογα με τη φύση του προβλήματος και την επιλογή του χρονικού βήματος που επιλέγεται (π.χ. ημερήσιο, μηνιαίο κ.λπ.) ορισμένες διεργασίες είναι πιθανό είτε να παραληφθούν είτε να περιγραφούν με απλούστερο τρόπο. Στο κεφάλαιο αυτό, μετά την αναλυτική περιγραφή των εξισώσεων υδατικού ισοζυγίου για ένα ταμιευτήρα (με την ενσωμάτωση διάφορων παραδοχών), ακολουθεί εκτενής αναφορά στους ταμιευτήρες όπου πραγματοποιήθηκαν τα πειράματα καθώς και ενδεικτική παρουσίαση μεγεθών που τους χαρακτηρίζουν. Αυτή η μεθοδολογία όπως και οι περισσότερες αναλύσεις ετούτης της εργασίας πραγματοποιήθηκαν σε περιβάλλον *Python* και θα παρουσιαστούν εκτενώς στο Κεφάλαιο 6.

3.1 Δεδομένα Εισόδου

Για την κατάστρωση του υδατικού ισοζυγίου, είναι απαραίτητη η συλλογή διαφόρων στοιχείων που αφορούν τόσο στο φυσικό περιβάλλον όσο και στα τεχνικά χαρακτηριστικά του συστήματος. Ιδιαίτερης σημασίας είναι τα διαθέσιμα δεδομένα των υδρολογικών διεργασιών. Τέτοια μεγέθη είναι οι εισροές από τη λεκάνη απορροής του ταμιευτήρα που αφορούν στο χρονικό ορίζοντα μελέτης και οι οποίες δίνονται (ή δημιουργούνται σε περίπτωση που δεν είναι γνωστές για τη συγκεκριμένη χρονική περίοδο αλλά υπάρχουν ιστορικά δεδομένα) με τη μορφή χρονοσειρών. Οι εισροές αυτές θα πρέπει να βρίσκονται σε συμφωνία με το χρονικό βήμα που επιλέγεται να εξετασθεί. Στην περίπτωση μας, όπου η προσομοίωση είναι μηνιαία, θα πρέπει να είναι γνωστές οι εισροές κάθε μήνα για όλη την περίοδο ελέγχου.

Πέραν των υδρολογικών δεδομένων, είναι απαραίτητη η γνώση των τεχνικών χαρακτηριστικών του ταμιευτήρα, όπως είναι η Ανώτατη Στάθμη Λειτουργίας (ΑΣΛ), η Κατώτατη Στάθμη Λειτουργίας (ΚΣΛ), η στάθμη εξόδου του αγωγού φυγής, η παροχετευτικότητα του αγωγού προσαγωγής κ.λπ. Ακόμη, πρέπει να είναι γνωστές οι σχέσεις μεταβολής της επιφάνειας και του αποθέματος, για διάφορες στάθμες. Οι υπόψη σχέσεις δίνονται είτε σε μορφή νομογραφήματος (καμπύλες ταμιευτήρα) είτε σε αναλυτική μορφή.

Επίσης, είναι αναγκαία η γνώση των ποσοτικών μεγεθών που αφορούν στις ζητήσεις νερού που αναμένεται να καλύψει ο ταμιευτήρας. Γενικά, τέτοιες ζητήσεις σχετίζονται με την ύδρευση, την άρδευση, την διατήρηση της περιβαλλοντικής ροής κατάντη του ταμιευτήρα, την παραγωγή ενέργειας κ.λπ. Οι ζητήσεις αυτές τίθενται ως στόχοι που καλείται να καλύψει ένα σύστημα. Συνήθως, όταν ένα σύστημα είναι σχεδιασμένο ώστε να καλύπτει πάνω από μια ζητήσεις, ο διαχειριστής επιλέγει να δώσει σειρά προτεραιότητας για την κάλυψη τους, ανάλογα με τη φύση του συστήματος. Στη συγκεκριμένη εργασία, προς απλοποίηση του προβλήματος, αλλά χωρίς βλάβη της γενικότητας, επιλέχθηκε η εξέταση αμιγώς υδροηλεκτρικών ταμιευτήρων που έχουν ως στόχο την κάλυψη ενεργειακών αναγκών. Βέβαια, στο πλαίσιο αυτό εφαρμόζεται πάντα και η διατήρηση της περιβαλλοντικής ροής στα κατάντη, καθώς είναι απαραίτητη για την εξασφάλιση και προστασία των οικοσυστημάτων που αναπτύσσονται στην περιοχή και για το λόγο αυτό δεν μπορεί να παραληφθεί.

Παρακάτω, περιγράφονται αναλυτικά όλες οι εξισώσεις που χρησιμοποιήθηκαν για την κατάστρωση του υδατικού ισοζυγίου ενός ταμιευτήρα. Το ισοζύγιο διαμορφώθηκε με τέτοιο τρόπο ώστε να εξυπηρετεί τις ανάγκες της παρούσας ερευνητικής εργασίας, και για τον λόγο αυτό ορισμένες φυσικές διεργασίες (π.χ. απώλειες λόγω εξάτμισης ή υπόγειων διαφυγών) παραλείφθηκαν, ενώ άλλες απλοποιήθηκαν.

3.2 Προσομοίωση υδατικού ισοζυγίου ταμιευτήρα

Έστω ότι η χρονική περίοδος χωρίζεται σε ίσα διαστήματα $\Delta t = t_j - t_{j-1}$. Όλες οι εξισώσεις που ακολουθούν δείχνουν τα στάδια υπολογισμού του ισοζυγίου σε ένα χρονικό βήμα j . Η πρώτη σχέση που παρατίθεται είναι η εξίσωση που δίνει το απόθεμα S_j συναρτήσει της στάθμης Z_j :

$$S_j = k(Z_j - Z_0)^\lambda \quad (3.1)$$

Επιλύοντας την εξίσωση (3.1) ως προς Z_j , προκύπτει η επόμενη σχέση, η οποία προϋποθέτει τη γνώση της στάθμης πυθμένα Z_0 και του αρχικού αποθέματος S_0 του ταμιευτήρα στην αρχή της περιόδου που εξετάζεται. Με βάση αυτό, υπολογίζεται η στάθμη Z για το χρονικό βήμα j ως εξής:

$$Z_j = Z_0 + \left(\frac{S_{j-1}}{\kappa}\right)^{\frac{1}{\lambda}} \quad (3.2)$$

όπου, Z_j είναι η στάθμη του νερού σε m, Z_0 η στάθμη πυθμένα σε m, S_{j-1} το απόθεμα του ταμιευτήρα σε hm^3 στο τέλος του προηγούμενου βήματος (για το λόγο αυτό στο πρώτο βήμα της προσομοίωσης πρέπει να είναι γνωστό το αρχικό απόθεμα S_0), κ και λ είναι οι συντελεστές κλίμακας και σχήματος αντίστοιχα, και περιγράφουν τη γεωμετρία της λεκάνης κατάκλυσης που σχηματίζεται ανάντη του φράγματος, συναρτήσει της στάθμης.

Στη συνέχεια, υπολογίζεται το ύψος πτώσης, που προκύπτει ως η υψομετρική διαφορά μεταξύ της στάθμης του νερού στον ταμιευτήρα και της στάθμης εξόδου του αγωγού φυγής, ως εξής:

$$H_j = Z_j - Zp_j \quad (3.3)$$

όπου H_j είναι το ύψος πτώσης, Z_j η στάθμη του νερού στον ταμιευτήρα και Zp_j η στάθμη εξόδου του αγωγού φυγής, εκφρασμένα σε m.

Με βάση το ύψος πτώσης, υπολογίζεται η παροχαρακτηριστικότητα του αγωγού προσαγωγής (ή πτώσης). Αυτό γίνεται μέσω μιας μη γραμμικής σχέσης της γενικής μορφής $y = ax^b$.

Έτσι προκύπτει:

$$q_j = \alpha H_j^b \quad (3.4)$$

όπου q_j είναι η παροχαρακτηριστικότητα του αγωγού προσαγωγής σε hm^3 , H_j το ύψος πτώσης σε m και α , b συντελεστές. Στο σημείο αυτό θα πρέπει να αναφερθεί ότι η σχέση (3.4) εκφράζεται σε όρους όγκου νερού που μπορεί να διέλθει από τον αγωγό στο διάστημα ενός μήνα, άρα η τιμή του συντελεστή κλίμακας α αναφέρεται σε μηνιαίο βήμα προσομοίωσης.

Στη συνέχεια υλοποιούνται οι εισροές και εκροές νερού, με μια προκαθορισμένη σειρά που ορίζεται συμβατικά. Προφανώς, αυτό αποτελεί παραδοχή του αριθμητικού σχήματος, δεδομένου ότι οι διεργασίες του υδατικού ισοζυγίου εξελίσσονται σε συνεχή χρόνο. Σε κάθε περίπτωση, μετά το πέρας κάθε προσθήκης ή αφαίρεσης νερού,

επικαιροποιείται το απόθεμα του ταμιευτήρα. Με τον τρόπο αυτό, σε κάθε στάδιο υπολογισμών εντός του ίδιου χρονικού βήματος, προκύπτει ένα «ενδιάμεσο» απόθεμα που θα επισημαίνεται με τον αντίστοιχο δείκτη.

Σύμφωνα με τα παραπάνω, στο πρώτο στάδιο ο προσδιορισμός του νέου αποθέματος προκύπτει μετά από την προσθήκη των εισροών στον ταμιευτήρα ως εξής:

$$S_j^1 = S_{j-1} + I_j \quad (3.5)$$

όπου S_j^1 είναι το νέο ενδιάμεσο απόθεμα, I_j οι εισροές στον ταμιευτήρα και S_{j-1} το απόθεμα του ταμιευτήρα στο τέλος του προηγούμενου βήματος. Όλα τα μεγέθη της εξίσωσης είναι εκφρασμένα σε hm^3

Η πρώτη σε προτεραιότητα ζήτηση που δύναται να καλύψει ο ταμιευτήρας είναι η διατήρηση της περιβαλλοντικής ροής στα κατάντη. Ο όγκος που απαιτείται συμβολίζεται με V_{env} και γενικά έχει μια σταθερή τιμή. Στην ανάλυση μας εκφράζεται ως σταθερό ποσοστό (10%) του μέσου όρου των συνολικών εισροών ως εξής:

$$V_{env} = 10\% \text{ average}(I) \quad (3.6)$$

όπου I είναι οι εισροές στον ταμιευτήρα στη χρονική περίοδο που εξετάζεται. Τόσο οι εισροές όσο και ο όγκος V_{env} είναι εκφρασμένα σε hm^3 .

Μετά την απόληψη για διατήρηση της περιβαλλοντικής ροής επικαιροποιείται το απόθεμα του ταμιευτήρα, ώστε να χρησιμοποιηθεί στους μετέπειτα υπολογισμούς. Έτσι προκύπτει:

$$S_j^2 = S_j^1 - V_{envj} \quad (3.7)$$

όπου S^1, S^2 οι αλλαγές στο απόθεμα κατά τη διάρκεια του βήματος j και V_{envj} η απόληψη για εξασφάλιση της περιβαλλοντικής ροής στο βήμα αυτό. Όλα τα μεγέθη είναι εκφρασμένα σε hm^3 .

Η επόμενη χρήση νερού που πρέπει να καλυφθεί από τον ταμιευτήρα είναι η ζήτηση σε ηλεκτρική ενέργεια. Έχοντας ως δεδομένο ένα στόχο ενέργειας, σταθερό σε κάθε χρονικό βήμα της προσομοίωσης, τον οποίο αναμένεται να καλύψει ο ταμιευτήρας, η ζήτηση σε όρους όγκου στο βήμα j υπολογίζεται ως εξής:

$$V_{energy_j} = \frac{E^*}{\psi H_j} \quad (3.8)$$

όπου V_{energy_j} είναι η ζήτηση για κάλυψη του ενεργειακού στόχου στο βήμα j σε hm^3 , E^* ο στόχος ενέργειας του βήματος (σταθερός για κάθε βήμα), εκφρασμένος σε GWh, ψ είναι η ειδική ενέργεια.

Ειδική λέγεται η ενέργεια ανά μονάδα όγκου και ανά μονάδα ύψους πτώσης, εκφρασμένη σε GWh/hm^4 , και H_j είναι το ύψος πτώσης σε m.

Με βάση αυτή τη ζήτηση και σε συνδυασμό με ορισμένους περιορισμούς, υπολογίζεται η εκροή του στροβίλου στο βήμα j , μέσω της παρακάτω σχέσης:

$$Re_j = \min(V_{energy_j}, \max(S_j^2 - Vd, 0), q_j) \quad (3.9)$$

όπου Re_j είναι η εκροή του στροβίλου, S^2 είναι το απόθεμα στον ταμιευτήρα στο συγκεκριμένο στάδιο της προσομοίωσης και q_j είναι η παροχαρακτηριστική του αγωγού προσαγωγής. Το μέγεθος Vd υποδηλώνει το νεκρό όγκο του ταμιευτήρα. Όλα τα μεγέθη είναι εκφρασμένα σε hm^3 .

Μετά την αφαίρεση της εκροής του στροβίλου υπολογίζεται εκ νέου το απόθεμα του ταμιευτήρα, ώστε να χρησιμοποιηθεί στους μετέπειτα υπολογισμούς. Έτσι προκύπτει:

$$S_j^3 = S_j^2 - Re_j \quad (3.10)$$

όπου S_j^3, S_j^2 οι αλλαγές στο απόθεμα κατά τη διάρκεια του βήματος j και Re_j η εκροή του στροβίλου στο βήμα αυτό. Όλα τα μεγέθη είναι εκφρασμένα σε hm^3 .

Έχοντας υπολογίσει τις ζητήσεις του συστήματος, απομένει να εξεταστεί αν υπάρχει περίσσεια αποθέματος στον ταμιευτήρα, δηλαδή αν το απόθεμα, όπως προέκυψε, υπερβαίνει την μέγιστη χωρητικότητά του. Αν υπάρχει, θα χρησιμοποιηθεί αρχικά για την παραγωγή δευτερεύουσας ενέργειας και στη συνέχεια ό,τι περισσέψει θα

υπερχειλίσει από τον ταμιευτήρα. Η σειρά των σταδίων της διαδικασίας αυτής έχει ως εξής:

Αρχικά, ελέγχεται αν υπάρχει περίσσεια αποθέματος, συγκρίνοντας το τρέχον απόθεμα με την μικτή χωρητικότητα του ταμιευτήρα, η οποία υπολογίζεται ως εξής:

$$S_{max} = \kappa(A\Sigma\Lambda - Z_0)^\lambda \quad (3.11)$$

όπου S_{max} είναι η μικτή χωρητικότητα σε hm^3 , $A\Sigma\Lambda$ είναι η Ανώτατη Στάθμη Λειτουργίας του ταμιευτήρα σε m, Z_0 η στάθμη πυθμένα σε m, κ και λ είναι οι συντελεστές κλίμακας και σχήματος της σχέσης στάθμης - αποθέματος.

Στη συνέχεια ελέγχεται αν υπάρχει περίσσεια νερού, ήτοι υπέρβαση της χωρητικότητας, με χρήση της παρακάτω εξίσωσης:

$$Sur_j = \max(S_j^3 - S_{max}, 0) \quad (3.12)$$

όπου Sur_j είναι η περίσσεια αποθέματος, S_j^3 είναι το απόθεμα στον ταμιευτήρα στο συγκεκριμένο στάδιο της προσομοίωσης και S_{max} η μικτή χωρητικότητα, όλα εκφρασμένα σε hm^3 .

Αν υπάρχει περίσσεια, τότε δρομολογείται μια πρόσθετη εκροή, η οποία αργότερα χρησιμοποιείται για τον υπολογισμό της δευτερεύουσας ενέργειας που παράγεται από το σύστημα, ενώ σε αντίθετη περίπτωση η πρόσθετη εκροή τίθεται μηδέν, ως εξής:

$$R_{plus_j} = \min(q_j - Re_j, Sur_j) \quad (3.13)$$

όπου R_{plus_j} είναι η πρόσθετη εκροή, Sur_j είναι η περίσσεια αποθέματος, q_j είναι η παροχαρακτηριστικότητα του αγωγού προσαγωγής και Re_j είναι η εκροή του στροβίλου. Όλα τα μεγέθη είναι εκφρασμένα σε hm^3 .

Επόμενο υπολογιστικό στάδιο είναι η ενημέρωση του αποθέματος μετά την αφαίρεση της πρόσθετης εκροής, σύμφωνα με τον τύπο:

$$S_j^4 = S_j^3 - R_{plus_j} \quad (3.14)$$

Όπου S_j^4, S_j^3 οι ενδιάμεσες τιμές στο απόθεμα κατά τη διάρκεια του βήματος j και R_{plus_j} η πρόσθετη εκροή στο βήμα αυτό. Όλα τα μεγέθη είναι εκφρασμένα σε hm^3 .

Αν μετά την αλλαγή του αποθέματος συνεχίζει να υπάρχει περίσσεια στον ταμιευτήρα, η ποσότητα αυτή φεύγει από τον ταμιευτήρα μέσω υπερχειλίσης. Αυτή η διαδικασία διατυπώνεται με την παρακάτω εξίσωση:

$$Rspill_j = \max(S_j^4 - S_{max}, 0) \quad (3.15)$$

όπου $Rspill_j$ είναι η ποσότητα υπερχειλίσης, S_j^4 είναι το απόθεμα στον ταμιευτήρα στο συγκεκριμένο στάδιο της προσομοίωσης και S_{max} η μικτή χωρητικότητα, όλα εκφρασμένα σε hm^3 .

Μετά τον έλεγχο υπερχειλίσης, υπολογίζεται το τελικό απόθεμα στον ταμιευτήρα ως εξής:

$$S_j^5 = S_j^4 - Rspill_j \quad (3.16)$$

Όπου S_j^5, S_j^4 οι αλλαγές στο απόθεμα κατά τη διάρκεια του βήματος j και $Rspill_j$ η ποσότητα υπερχειλίσης στο βήμα αυτό. Όλα τα μεγέθη είναι εκφρασμένα σε hm^3 .

Στο σημείο αυτό γίνεται επαναπροσδιορισμός της στάθμης, χρησιμοποιώντας στη σχέση (3.2) το απόθεμα S_j^5 ως εξής:

$$Z_{newj} = Z_0 + \left(\frac{S_j^5}{\kappa}\right)^{\frac{1}{\lambda}} \quad (3.17)$$

όπου Z_{newj} είναι η τελική στάθμη του νερού σε m, Z_0 η στάθμη πυθμένα σε m, S_j^5 το απόθεμα του ταμιευτήρα στο συγκεκριμένο στάδιο της προσομοίωσης σε hm^3 , κ και λ είναι οι συντελεστές κλίμακας και σχήματος της σχέσης στάθμης - αποθέματος.

Αντίστοιχα με τη σχέση (3.3) και χρησιμοποιώντας την στάθμη στην αρχή και το πέρας του χρονικού βήματος υπολογίζεται το αντίστοιχο ύψος πτώσης ως εξής:

$$H_{newj} = \frac{Z_j + Z_{newj}}{2} - Zp_j \quad (3.18)$$

όπου H_{newj} είναι το νέο ύψος πτώσης, Z_j , Z_{newj} η αρχική και τελική στάθμη του νερού και Zp_j η στάθμη εξόδου του αγωγού φυγής, όλα εκφρασμένα σε m.

Ο υπολογισμός του νέου ύψους πτώσης γίνεται διότι στη συνέχεια, αφού γίνει ένας επαναληπτικός κύκλος με το νέο ύψος πτώσης, στην εξίσωση υπολογισμού της πρωτεύουσας και δευτερεύουσας ενέργειας χρησιμοποιείται το νέο αντί του αρχικού ύψους πτώσης (3.3). Αυτό γίνεται με σκοπό την ακριβέστερη εκτίμηση των υδροενεργειακών μεγεθών που εξαρτώνται από τη στάθμη, εξασφαλίζοντας ακόμη την

εξομάλυνση της καμπύλης διάρκειας - παραγωγής ενέργειας, η οποία αποτελεί ένα από τα βασικά ζητούμενα της προσομοίωσης.

Μετά την ολοκλήρωση των υπολογισμών αυτών, προσδιορίζεται η πρωτεύουσα ενέργεια που παράγεται στο βήμα j και δίνεται από τον τύπο:

$$Ef_j = \psi Re_j Hnew_j \quad (3.19)$$

όπου Ef_j είναι η παραγόμενη πρωτεύουσα ενέργεια σε GWh, ψ είναι η ειδική ενέργεια, δηλαδή η ενέργεια ανά μονάδα όγκου και ανά μονάδα ύψους πτώσης, εκφρασμένη σε GWh/hm^4 , Re_j είναι η εκροή του στροβίλου σε hm^3 και $Hnew_j$ είναι το νέο ύψος πτώσης σε hm.

Αντίστοιχα, στην περίπτωση που έχουμε πρόσθετη εκροή από τον στροβίλο, γίνεται υπολογισμός της δευτερεύουσας ενέργειας που παράγεται ως εξής:

$$Es_j = \psi Rplus_j Hnew_j \quad (3.20)$$

όπου Es_j είναι η παραγόμενη δευτερεύουσα ενέργεια σε GWh, ψ είναι η ειδική ενέργεια, δηλαδή η ενέργεια ανά μονάδα όγκου και ανά μονάδα ύψους πτώσης, εκφρασμένη σε GWh/hm^4 , $Rplus_j$ είναι η πρόσθετη εκροή σε hm^3 και $Hnew_j$ είναι το νέο ύψος πτώσης σε hm.

Η συνολική ενέργεια που παράγεται από το σύστημα στο βήμα j είναι το άθροισμα της πρωτεύουσας (Ef_j) και της δευτερεύουσας (Es_j), δηλαδή:

$$Etotal_j = Ef_j + Es_j \quad (3.21)$$

Στη συνέχεια, ερευνάται το ενδεχόμενο ελλείμματος πρωτεύουσας ενέργειας (Def_j) δηλαδή η περίπτωση που ο στόχος E^* του βήματος είναι μεγαλύτερος από την παραγόμενη πρωτεύουσα ενέργεια (Ef_j). Υπολογίζεται η διαφορά:

$$Def_j = E^* - Ef_j \quad (3.22)$$

Όλα τα μεγέθη εκφράζονται σε GWh.

Στο τελευταίο στάδιο, τίθεται το απόθεμα S^5 (εκφρασμένο σε hm^3), ως τελικό απόθεμα του τρέχοντος βήματος j , το οποίο στη συνέχεια αποτελεί και το αρχικό απόθεμα του επόμενου βήματος

$j + 1$, δηλαδή:

$$S_{j+1}^0 = S_j^5 \quad (3.23)$$

Με τον τρόπο αυτό ολοκληρώνεται το μαθηματικό σκέλος που αφορά στο υδατικό ισοζύγιο για ένα χρονικό βήμα j . Η διαδικασία αυτή επαναλαμβάνεται για όλα τα βήματα του χρονικού ορίζοντα που εξετάζεται. Στη συνέχεια, βάσει των αποτελεσμάτων της προσομοίωσης και χρησιμοποιώντας ενδεικτικές τιμές πώλησης πρωτεύουσας και δευτερεύουσας ενέργειας και μια τιμή ρήτρας ελλείμματος ενέργειας π.χ. σε € ανά kWh, μπορεί να γίνει κάποια απλουστευμένη αποτίμηση του μέσου ετήσιου οφέλους ή κόστους. Μετά από διαδικασία βελτιστοποίησης με στόχο την μεγιστοποίηση του οικονομικού οφέλους, προκύπτει ένας σταθερός ενεργειακός στόχος. Για την εύρεση του χρησιμοποιήθηκε όλη η χρονοσειρά των ιστορικών δεδομένων εισροών. Αυτός ο στόχος θα ληφθεί υπόψη σαν δεδομένο εισόδου στην διαδικασία αξιολόγησης των προβλέψεων στο Κεφάλαιο 5.


Οι ταμειυτήρες που θα χρησιμοποιηθούν στις αναλύσεις είναι αυτοί των Κρεμαστών, της Μεσοχώρας και του Ευήνου. Πρόκειται για ταμειυτήρες διαφορετικών τεχνικών χαρακτηριστικών, γεγονός που βοηθάει στην κατά το δυνατόν γενίκευση των συμπερασμάτων.

4. ΓΕΝΙΚΑ ΧΑΡΑΚΤΗΡΙΣΤΙΚΑ ΤΑΜΙΕΥΤΗΡΩΝ ΕΝΔΙΑΦΕΡΟΝΤΟΣ ΚΑΙ ΑΠΟΤΕΛΕΣΜΑΤΑ ΠΡΟΣΟΜΟΙΩΣΕΩΝ ΛΕΙΤΟΥΡΓΙΑΣ

4.1 Φράγμα Κρεμαστών

4.1.1 Γενικά Στοιχεία

Το φράγμα των Κρεμαστών βρίσκεται στον Νομό Αιτωλοακαρνανίας, πάνω στον ρου του ποταμού Αχελώου, περί το 1.2 km κατάντη της συμβολής του με τους παραποτάμους του Ταυρωπού και Αγραφιώτη και περίπου 55 km βορειοανατολικά της πόλης του Αγρινίου. Οι μελέτες για την κατασκευή του φράγματος ξεκίνησαν από της αρχές του 20ου αιώνα και οδήγησαν στην έναρξη της κατασκευής το 1962. Το έργο τέθηκε σε εμπορική λειτουργία τον Ιανουάριο του 1966. Για την περάτωση του έργου εργάστηκαν έως και 3500 άτομα καθημερινά σε 24ωρη βάση σε τρεις βάρδιες. Στην διάρκεια της τριετούς κατασκευής συνέβησαν εκατοντάδες εργατικά ατυχήματα, 30 εκ των οποίων θανατηφόρα. Η τεχνητή λίμνη των Κρεμαστών δημιουργήθηκε το 1965 από τη συσσώρευση υδάτινων όγκων των ποταμών Αχελώου, Αγραφιώτη, Ταυρωπού και Τρικεριώτη. Βρίσκεται ανάμεσα στους νομούς Αιτωλοακαρνανίας και Ευρυτανίας. Η φραγή του ποταμού και η πλήρωση της λίμνης είχαν ως αποτέλεσμα πολλές περιοχές να βυθιστούν κάτω από το νερό. Οι σημαντικότερες περιοχές που κατακλύστηκαν ήταν τα χωριά Επισκοπή, Άγιος Βασίλειος και Σίδερα καθώς και το βυζαντινό μοναστήρι της Επισκοπής. Στην περιοχή του χωριού της Επισκοπής κατασκευάστηκε ομώνυμη γέφυρα για την ένωση των νομών Αιτωλοακαρνανίας και Ευρυτανίας. Η περιοχή είναι ενταγμένη στο πρόγραμμα Natura 2000.



Εικόνα 4.1 - Φράγμα Κρεμαστών

4.1.2 Τεχνικά Χαρακτηριστικά


Παρακάτω παρατίθενται τα τεχνικά χαρακτηριστικά του υδροηλεκτρικού έργου των Κρεμαστών από το Υ.ΠΕ.ΘΕ. και από την Ελληνική Επιτροπή Μεγάλων Φραγμάτων.

- Το φράγμα είναι χωμάτινο με αργιλικό πυρήνα και μέγιστο ύψος από την θεμελίωση 165 m. Το ωφέλιμο ύψος είναι 136 m και το υψόμετρο στέψης είναι 287 m. Το μήκος της στέψης είναι 456 m και το πλάτος της είναι 10 m ενώ το μέγιστο πλάτος στη βάση του φράγματος είναι 670 m. Ο όγκος του χωμάτινου φράγματος είναι $8.2 \times 10^6 \cdot \text{m}^3$
- Ο εκχειλιστής αποτελείται από θυροφράγματα, επενδυμένη διάρρυγα και κάδο αναπήδησης. Έχει μέγιστη παροχευτικότητα $3000 \text{ m}^3/\text{s}$.
- Ο ταμιευτήρας των Κρεμαστών έχει επιφάνεια 80.6 km^2 και συνολική ωφέλιμη χωρητικότητα $4.75 \times 10^9 \text{ m}^3$.
- Η σήραγγα εκτροπής του έργου είναι επενδυμένη από σκυρόδεμα και έχει μήκος 754 m.
Έχει κυκλική διατομή και η εσωτερική διάμετρος της είναι 12.6 m.
- Ο σταθμός παραγωγής των Κρεμαστών βρίσκεται στο αριστερό αντέρεισμα κοντά στον πόδα του φράγματος. Είναι ημιυπαίθριος και εξοπλισμένος με 4 μονάδες τύπου Francis με κατακόρυφο άξονα εγκατεστημένης ισχύος 109.3 MW η κάθε μία. Το νερό καταλήγει στο σταθμό παραγωγής μέσω τεσσάρων αγωγών πτώσεως. Η μέση ετήσια παραγόμενη ενέργεια του έργου ανέρχεται στις 848 GWh.
- Ιδιαίτερη σημασία έχει η συνολική εγκατεστημένη ισχύς του έργου, που ανέρχεται στα 437.2 MW, ενώ σημαντικά είναι τα στοιχεία της ετήσιας παραγόμενης ενέργειας (848 GWh) και του συνολικού κόστους της επένδυσης των Κρεμαστών. Όπως προκύπτει από την αναφορά έργου που συνέταξε η εταιρία ECI για την ΔΕΗ το 1974, το συνολικό κόστος του έργου ήταν 84.781.000 \$.


4.1.3 Μοντέλο Προσομοίωσης Λειτουργίας Ταμιευτήρα

Κατασκευάστηκε μοντέλο προσομοίωσης για την λειτουργία του υδροηλεκτρικού έργου των Κρεμαστών, μέσω του οποίου εξήχθησαν ενεργειακά αποτελέσματα. Η προσομοίωση ουσιαστικά αφορά το ισοζύγιο εισόδου - εξόδου νερού από τον ταμιευτήρα με ταυτόχρονο υπολογισμό της παραγόμενης ενέργειας της εγκατάστασης, όπως αυτό αναλύθηκε διεξοδικώς με τη μορφή εξισώσεων στην προηγούμενη ενότητα του Κεφαλαίου.

Τα βασικά δεδομένα εισόδου που χρησιμοποιήθηκαν για την προσομοίωση ήταν χρονοσειρά μέσω μηνιαίων εισροών στον ταμιευτήρα από τον Οκτώβριο του 1966 έως τον Σεπτέμβριο του 2008 σε hm³, η κατώτατη και ανώτατη στάθμη λειτουργίας του ταμιευτήρα 227 και 282 m αντίστοιχα, η στάθμη του πυθμένα ίση με 160 m, η αρχική στάθμη η οποία ορίστηκε στα 270 m, η μηνιαία ζήτηση ενέργειας που ορίστηκε στις 65 GWh μετά από βελτιστοποίηση, το υψόμετρο του ΥΗΣ 143.5 m καθώς και η σχέση ύψους φράγματος – όγκου ταμίευσης η οποία φαίνεται στην καμπύλη της Εικόνας 4.2 και η σχέση ύψους φράγματος – επιφάνειας ταμιευτήρα η οποία φαίνεται στην καμπύλη της Εικόνας 4.3.

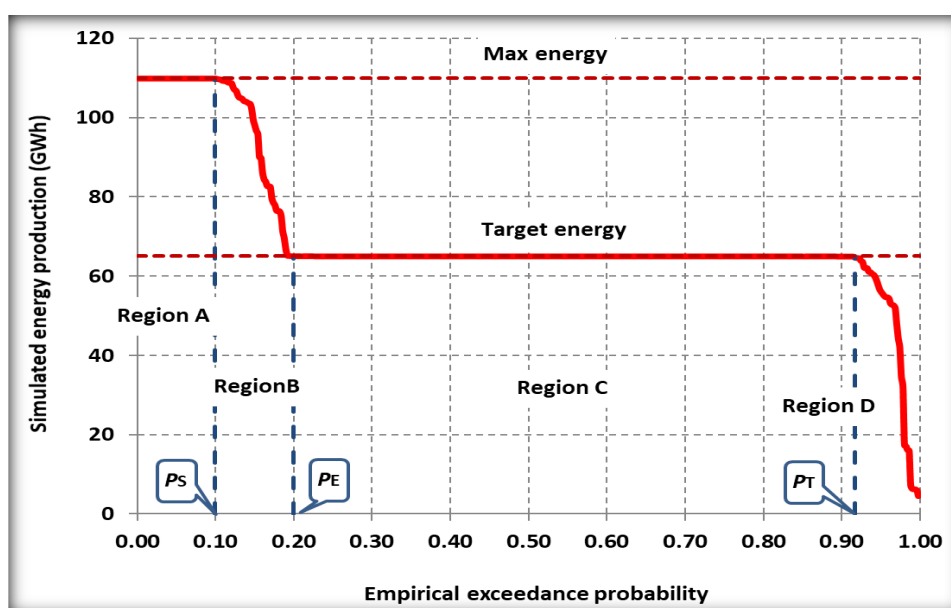


Εικόνα 4.2-Καμπύλη ύψους φράγματος-Όγκου ταμίευσης Φράγματος Κρεμαστών



Εικόνα 4.3-Καμπύλη ύψους φράγματος-επιφάνειας του ταμιευτήρα των Κρεμαστών

Η προσομοίωση της λειτουργίας και ενεργειακής παραγωγής του έργου των Κρεμαστών κατέστησαν δυνατό το σχεδιασμό της καμπύλης ενέργειας – πιθανότητας (EPC), η οποία εκφράζει την κατανομή της ενέργειας κατά την περίοδο προσομοίωσης και ενσωματώνει όλες τις βασικές πληροφορίες για την αναγνώριση διαφορετικών πτυχών της λειτουργίας του συστήματος. Στο συγκεκριμένο διάγραμμα ο άξονας των τεταγμένων εκφράζει την τιμή της ενέργειας και ο άξονας των τεταγμένων εκφράζει το ποσοστό του χρόνου, όπου η ενέργεια που παράγεται ξεπερνά την αντίστοιχη τιμή του άξονα των τεταγμένων. Η βελτιστοποιημένη καμπύλη ενέργειας – πιθανότητας φαίνεται στην Εικόνα 4.4.



Εικόνα 4.4-Καμπύλη Ενέργειας-Πιθανότητας Κρεμαστών

Στην Περιοχή Α το σύστημα παράγει περισσότερη ενέργεια από το στόχο ενέργειας των 65 GWh/μήνα. Μεταφέρει τον πλεονάζοντα αποθηκευμένο όγκο στους στροβίλους μέσω του αγωγού προσαγωγής, ο οποίος δουλεύει με τη μέγιστη παροχευτικότητα του και έτσι το υπόλοιπο νερό, πάνω από τη στάθμη υπερχειλίσης, υπερχειλίζει. Σε αυτήν την περίπτωση η καμπύλη είναι επίπεδη, αφού τόσο η παροχή όσο και η υδραυλική πτώση είναι στην μέγιστη τιμή τους και έτσι η ενέργεια λαμβάνει τη μέγιστη τιμή της. Από αυτήν την περιοχή του διαγράμματος λαμβάνεται και η πιθανότητα υπερχειλίσης του ταμιευτήρα των Κρεμαστών, $PS \approx 10$ %.

Στην Περιοχή Β το σύστημα παράγει περίσσεια ενέργεια, περνώντας όλο το πλεόνασμα νερού από τους στροβίλους. Σε αυτήν την περίπτωση δεν υπάρχουν απώλειες μέσω υπερχειλίσης. Από αυτήν την περιοχή του διαγράμματος λαμβάνεται και η πιθανότητα παραγωγής περίσσειας ενέργειας του ΥΗΕ των Κρεμαστών, $PE \approx 20$ %.

Στην Περιοχή C το σύστημα λειτουργεί βάσει προγράμματος, παράγοντας σταθερά το στόχο ενέργειας των 65 GWh/μήνα, γεγονός που οδηγεί σε επίπεδη καμπύλη ενέργειας –πιθανότητας.

Το διάγραμμα σχεδιάστηκε για βέλτιστο στόχο ενέργειας για τον οποίο η περιοχή D, όπου το σύστημα παράγει λιγότερη ενέργεια από το στόχο εξαιτίας μειωμένου όγκου ταμίευσης και μειωμένου ύψους πτώσης, έχει εξαλειφθεί. Έτσι η πιθανότητα το ΥΗΕ των Κρεμαστών να παράγει ενέργεια τουλάχιστον ίση με τον στόχο ενέργειας, δηλαδή η αξιοπιστία του ΥΗΕ σε σχέση με το συγκεκριμένο στόχο, είναι $PT \approx 90$ %.

4.2 Φράγμα Μεσοχώρας

4.2.1 Γενικά Στοιχεία

Το Υδροηλεκτρικό Έργο Μεσοχώρας βρίσκεται στον άνω ρου του ποταμού Αχελώου, κοντά στο χωριό Μεσοχώρα, και αποτελεί την πρώτη βαθμίδα αξιοποίησής του. Γεωγραφικά, ανήκει στο Νομό Τρικάλων και διοικητικά στη Περιφέρεια Θεσσαλίας. Το έργο είναι υδροενεργειακό και μπορεί να λειτουργήσει αυτόνομα και ανεξάρτητα από την εκτροπή ή όχι του Αχελώου προς τη Θεσσαλική πεδιάδα.

Η θέση του φράγματος βρίσκεται νοτιοδυτικά του οικισμού Μεσοχώρα (ευθεία απόσταση περίπου 2km), η θέση του σταθμού παραγωγής βρίσκεται βορειοδυτικά του οικισμού Γλίστρα (ευθεία απόσταση 1km) και η σήραγγα προσαγωγής κινείται μεταξύ των περιοχών Μεσοχώρας και Γλίστρας, με κατεύθυνση Β-ΝΔ (μήκος 7,4km περίπου). Το έργο είναι ήδη κατασκευασμένο σχεδόν στο σύνολό του. Οι εργασίες έλαβαν μέρος την περίοδο 1986-2011. Εξαίρεση αποτελούν κάποιες ελάχιστες τελικές εργασίες που θα απαιτηθούν προκειμένου να λειτουργήσει (π.χ. έμφραξη σήραγγας προσωρινής εκτροπής, κατασκευή εκκενωτή πυθμένα μαζί με το μικρό υδροηλεκτρικό στον πόδα του κ.λπ.)



Εικόνα 4.5-Φράγμα Μεσοχώρας

4.2.2 Τεχνικά Χαρακτηριστικά

Το Υδροηλεκτρικό Έργο (ΥΗΕ) συνθέτουν τα εξής επιμέρους έργα κατά το Υ.ΠΕ.ΘΕ:


- Λιθόρριπτο φράγμα, ύψους 150 m από την κοίτη και ταμιευτήρας επιφάνειας 7,8 km².
- Σήραγγα εκτροπής πεταλοειδούς διατομής, διαμέτρου 11 μέτρων, μήκους 645 m και ανάντη πρόφραγμα, με στέψη στο υψόμετρο 648 m.
- Η Σήραγγα προσαγωγής από το φράγμα Μεσοχώρας προς τον ΥΗΣ διασχίζει την οροσειρά της Πίνδου διανοίχθηκε με μηχάνημα ολομέτωπης κοπής πετρώματος TBM. Αποτελείται από τμήμα μήκους 7.390m και διαμέτρου 5,30m με επένδυση από σκυρόδεμα, στο τέλος του οποίου υπάρχει φρέαρ ανάπαλσης, ύψους 124,30 m και διαμέτρου 12,50m και από τμήμα μήκους 433m και διαμέτρου 4,30m, με χαλύβδινη επένδυση.
- Εκχειλιστής με δύο θυροφράγματα, παροχής 3.300 m³/s .

- Μικρός ΥΗ σταθμός στον πόδα του φράγματος, τύπου Francis, οριζόντιου άξονα, 1570 KW, σε ύψος σχεδιασμού 100m.
- Σήραγγα προσαγωγής, μήκους 7,4 km περίπου.
- Σταθμός παραγωγής στη Γλίστρα, ημιυπαίθριος με 2 μονάδες Francis, κατακόρυφου άξονα, 2x82,65 MW, στο ύψος σχεδιασμού 200m.
- Έργα αποκατάστασης τμημάτων οδικών δικτύων που κατακλύζονται, οδός αποκατάστασης επικοινωνίας Μεσοχώρας με στέψη φράγματος και αποκατάσταση επικοινωνίας Νέας Πεύκης με οδό Βαθυρέματος – Μεσοχώρας.
- Σταθεροποιητικό επίχωμα στο Αρματωλικό

4.2.3 Μοντέλο Προσομοίωσης Λειτουργίας Ταμιευτήρα

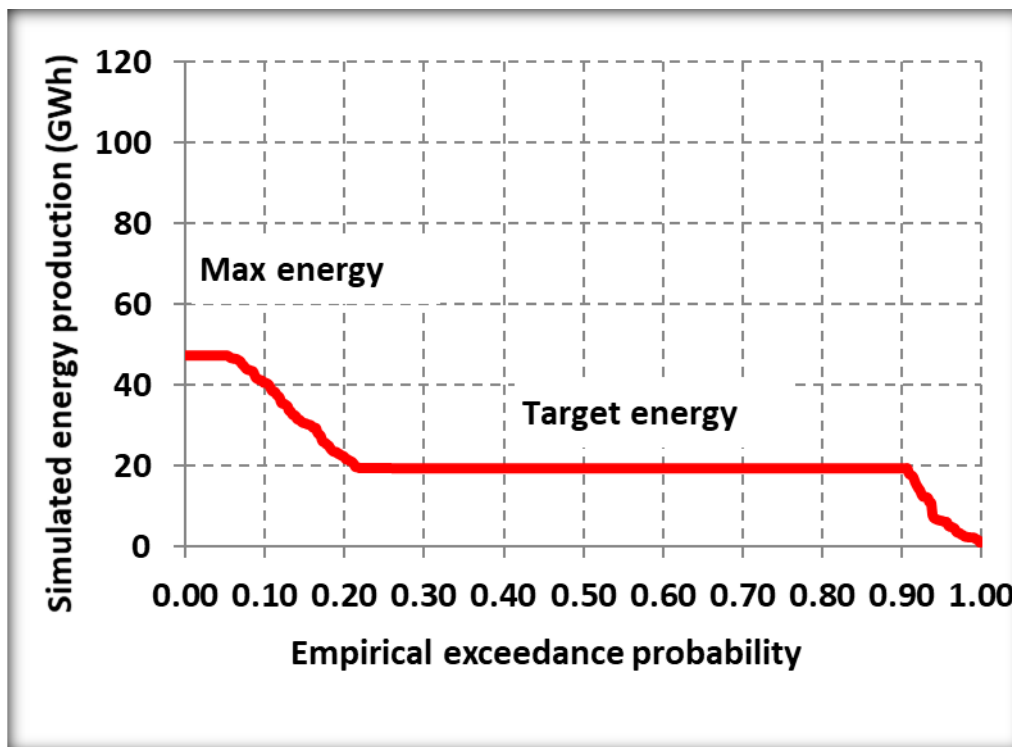
Ομοίως με την προηγούμενη υποενότητα κατασκευάστηκε το μοντέλο προσομοίωσης για την λειτουργία του υδροηλεκτρικού έργου της Μεσοχώρας.

Τα βασικά δεδομένα εισόδου που χρησιμοποιήθηκαν για την προσομοίωση ήταν χρονοσειρά μέσω μηνιαίων εισροών στον ταμιευτήρα από τον Οκτώβριο του 1966 έως τον Σεπτέμβριο του 2008 σε hm³ τα οποία προέκυψαν από τον λόγο του εμβαδού των Λεκανών Κρεμαστών και Μεσοχώρας ήτοι $633/3570 = 0.177$. Η κατώτατη και ανώτατη στάθμη λειτουργίας του ταμιευτήρα 731 και 770 m αντίστοιχα, η στάθμη του πυθμένα ίση με 640 m, η αρχική στάθμη η οποία ορίστηκε στα 750 m, η μηνιαία ζήτηση ενέργειας που ορίστηκε στις 19.5 GWh μετά από βελτιστοποίηση, το υψόμετρο του ΥΗΣ 550 m καθώς και η σχέση ύψους φράγματος – όγκου ταμίευσης η οποία φαίνεται στην καμπύλη της Εικόνας 4.6



Εικόνα 4.6-Καμπύλη Ύψους φράγματος-όγκου ταμίευσης φράγματος Μεσοχώρας

Η προσομοίωση της λειτουργίας και ενεργειακής παραγωγής του υδροηλεκτρικού έργου της Μεσοχώρας κατέστησαν δυνατό το σχεδιασμό της βελτιστοποιημένης καμπύλης ενέργειας – πιθανότητας (EPC) όπως φαίνεται στην Εικόνα (4.7).



Εικόνα 4.7-Καμπύλη Ενέργειας-Πιθανότητας Φράγματος Μεσοχώρας

Ο στόχος ενέργειας που προέκυψε από την βελτιστοποίηση είναι 19.5 GWh/μήνα. Στην πρώτη περιοχή ο πλεονάζοντας αποθηκευμένος όγκος μεταφέρεται στους στροβίλους μέσω του αγωγού προσαγωγής, ο οποίος δουλεύει με τη μέγιστη παροχαρακτηριστικότητα του και έτσι το υπόλοιπο νερό, πάνω από τη στάθμη υπερχειλίσης, υπερχειλίζει. Σε αυτήν την περίπτωση η καμπύλη είναι επίπεδη, αφού τόσο η παροχή όσο και η υδραυλική πτώση είναι στην μέγιστη τιμή τους και έτσι η ενέργεια λαμβάνει τη μέγιστη τιμή της. Από αυτήν την περιοχή του διαγράμματος λαμβάνεται και η πιθανότητα υπερχειλίσης του ταμιευτήρα της Μεσοχώρας, $P \approx 6\%$.

Έπειτα, το σύστημα παράγει περίσσεια ενέργεια, περνώντας όλο το πλεόνασμα νερού από τους στροβίλους. Σε αυτήν την περίπτωση δεν υπάρχουν απώλειες μέσω υπερχειλίσης. Από αυτήν την περιοχή του διαγράμματος λαμβάνεται και η πιθανότητα παραγωγής περίσσειας ενέργειας του ΥΗΕ των Κρεμαστών, $P \approx 22\%$.

Το σύστημα λειτουργεί στη συνέχεια βάσει προγράμματος, παράγοντας σταθερά το στόχο ενέργειας των 19.5 GWh/μήνα, γεγονός που οδηγεί σε επίπεδη καμπύλη ενέργειας-πιθανότητας.

Τελικά φαίνεται πως η πιθανότητα το ΥΗΕ της Μεσοχώρας να παράγει ενέργεια τουλάχιστον ίση με τον στόχο ενέργειας, δηλαδή η αξιοπιστία του ΥΗΕ σε σχέση με το συγκεκριμένο στόχο, είναι $P \approx 92\%$.

4.3 Φράγμα Ευήνου

Το συγκεκριμένο φράγμα δεν έχει σαν σκοπό την παραγωγή ενέργειας. Παρόλα αυτά σε αντίθεση με τους 2 προηγούμενους ταμιευτήρες, η χωρητικότητα του είναι σημαντικά μικρότερη από τη μέση ετήσια εισροή και για αυτό το λόγο χρησιμοποιήθηκε για ερευνητικούς σκοπούς στις αναλύσεις θεωρώντας ένα υποθετικό υδροηλεκτρικό έργο.

4.3.1 Γενικά Στοιχεία

Στον ποταμό Ευήνο, στην περιοχή Αγίου Δημητρίου του νομού Αιτωλοακαρνανίας (Ορεινή Ναυπακτία), κατασκευάστηκε το έργο του Ευήνου που περιλάμβανε κατασκευή Φράγματος, δημιουργία Ταμιευτήρα και κατασκευή της Σήραγγας Ευήνου - Μόρνου. Ο σχεδιασμός και η υλοποίηση του έργου προέβλεπε την ενίσχυση του βασικού Ταμιευτήρα του Μόρνου από τη γειτονική λεκάνη του ποταμού Ευήνου. Η έναρξη των εργασιών στον Ευήνο έγινε το 1992 με την κατασκευή χωμάτινου φράγματος το οποίο περατώθηκε τον Ιούνιο του 2001 οπότε και ξεκίνησε η διαδικασία της πρώτης πλήρωσης του ταμιευτήρα του Φράγματος, η οποία ολοκληρώθηκε τον Οκτώβριο του 2002.

4.3.2 Τεχνικά Χαρακτηριστικά

Για το φράγμα:

- Γενικά: αδιαπέρατος αργιλικός πυρήνας, φίλτρο κατάντη του πυρήνα, στραγγιστήρια από χάλικες στο ανάντη σώμα και προστατευτική λιθορριπή στην ανάντη πλευρά
- Τύπος φράγματος: χωμάτινο, με αργιλικό πυρήνα

- Μέγιστο ύψος φράγματος: 107 m
- Μέγιστο ύψος από τη θεμελίωση: 127 m
- Μήκος στέψης: 640 m
- Πλάτος στέψης: 10 m
- Μέγιστο πλάτος με βάση: 610 m
- Υψόμετρο στέψης: +519 m
- Ανώτατη στάθμη πλημμύρας: +517 m
- Κλίσεις πρανών: ανάντη 1:2.3, κατόντη 1:2
- Όγκος υλικού φράγματος: 14 hm³
- Στάθμη υπερχειλίσης: +505 m
- Παροχή υπερχειλιστή: 400 m³/s
- Παροχή εκκενωτή πυθμένα: 100 m³/s
- Κατώτατη στάθμη εκκένωσης: χαμηλή είσοδος +430 m, υψηλή είσοδος: +450 m

Για τον ταμιευτήρα:

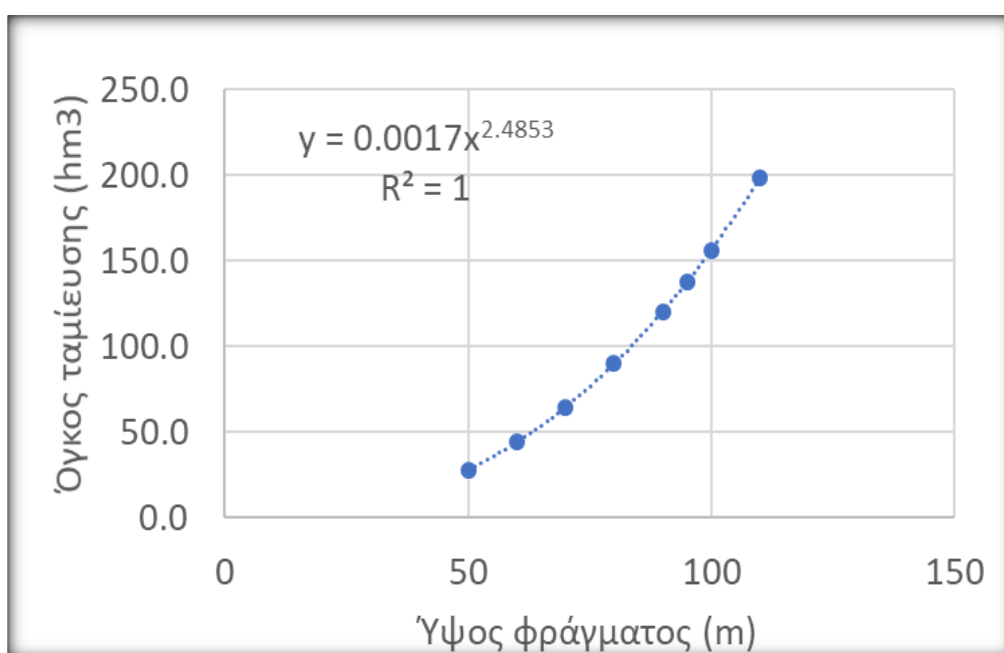
- Επιφάνεια στη στάθμη υπερχειλίσης: 3.6 km²
- Έκταση λεκάνης απορροής: 351.9 km²
- Μέση ετήσια βροχόπτωση: 1219 mm
- Μέση ετήσια απορροή: 280 hm³
- Μέγιστη χωρητικότητα: 137.6 hm³
- Μέγιστος ωφέλιμος όγκος: 113.0 hm³
- Κανονική στάθμη λειτουργίας πύργου υδροληψίας: +458.3 m (κατώτατη στάθμη)
- Ελάχιστη στάθμη υδροληψίας: +444.7 m
- Στάθμη εισόδου σήραγγας Εύηνου-Μόρνου: +435.0 m

4.3.3 Μοντέλο Προσομοίωσης Λειτουργίας Ταμιευτήρα

Κατασκευάστηκε μοντέλο προσομοίωσης για την λειτουργία του υποθετικού υδροηλεκτρικού έργου στον Εύηνο, με βάση ορισμένες παραδοχές και την ίδια μεθοδολογία που ακολουθήθηκε στους δύο προηγούμενους ταμιευτήρες.

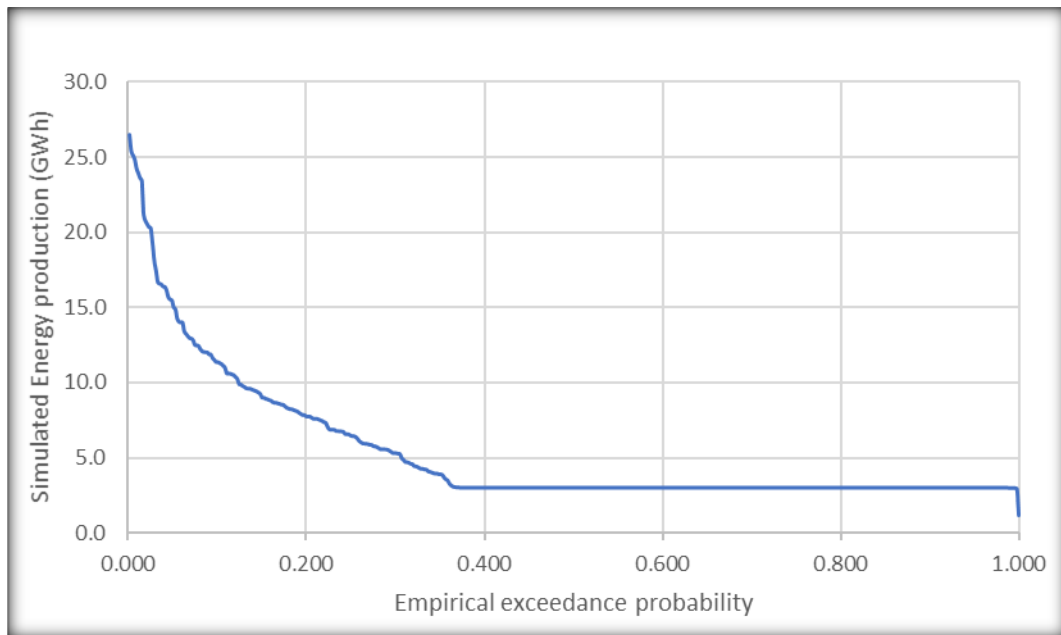
Τα βασικά δεδομένα εισόδου που χρησιμοποιήθηκαν για την προσομοίωση ήταν χρονοσειρά μέσω μηνιαίων εισροών στον ταμιευτήρα από τον Οκτώβριο του 1970

έως τον Φεβρουάριο του 2021 σε hm³. Η κατώτατη και ανώτατη στάθμη λειτουργίας του ταμιευτήρα 458.5 και 505 m αντίστοιχα, η στάθμη του πυθμένα ίση με 410 m, η αρχική στάθμη η οποία ορίστηκε στα 485 m, η μηνιαία ζήτηση ενέργειας που ορίστηκε στις 3 GWh μετά από βελτιστοποίηση, το υψόμετρο του ΥΗΣ 400 m καθώς και η σχέση ύψους φράγματος – όγκου ταμίευσης η οποία φαίνεται στην καμπύλη της Εικόνας 4.8. Θεωρήθηκε ένα υδροηλεκτρικό το οποίο αν εκμεταλλεύεται όλη την εισροή θα μπορεί να παράγει 50 GWh ετησίως.



Εικόνα 4.8-Καμπύλη Ύψους φράγματος-Όγκου ταμίευσης φράγματος Ευήνου

Η προσομοίωση της λειτουργίας και ενεργειακής παραγωγής του έργου του Ευήνου κατέστησαν δυνατό το σχεδιασμό της καμπύλης ενέργειας – πιθανότητας (EPC), η οποία εκφράζει την κατανομή της ενέργειας κατά την περίοδο προσομοίωσης. Η βελτιστοποιημένη καμπύλη ενέργειας – πιθανότητας φαίνεται στην Εικόνα 4.9.



Εικόνα 4.9-Καμπύλη Ενέργειας-Πιθανότητας φράγματος Ευήνου

Ο στόχος ενέργειας που προέκυψε από την βελτιστοποίηση είναι 3 GWh/μήνα. Για αυτό το στόχο ενέργειας βλέπουμε ότι δεν υπάρχουν υπερχειλίσεις. Όλο το πλεόνασμα νερού περνάει από τους στροβίλους. Από αυτήν την περιοχή του διαγράμματος λαμβάνεται και η πιθανότητα παραγωγής περίσσειας ενέργειας του ΥΗΕ του Ευήνου, $P \approx 37\%$.

Στην επόμενη περιοχή το σύστημα λειτουργεί βάσει προγράμματος, παράγοντας σταθερά το στόχο ενέργειας των 3 GWh/μήνα, γεγονός που οδηγεί σε επίπεδη καμπύλη ενέργειας-πιθανότητας.

Το διάγραμμα σχεδιάστηκε για βέλτιστο στόχο ενέργειας. Η περιοχή για την οποία το σύστημα παράγει λιγότερη ενέργεια από το στόχο εξαιτίας μειωμένου όγκου ταμίευσης και μειωμένου ύψους πτώσης, έχει εξαλειφθεί. Έτσι η πιθανότητα του Ευήνου να παράγει ενέργεια τουλάχιστον ίση με τον στόχο ενέργειας, δηλαδή η αξιοπιστία του ΥΗΕ σε σχέση με το συγκεκριμένο στόχο, είναι $P \approx 99\%$.

5. ΘΕΩΡΗΤΙΚΟ ΠΛΑΙΣΙΟ ΓΙΑ ΤΑ ΠΡΟΣΔΙΟΡΙΣΤΙΚΑ ΜΟΝΤΕΛΑ ΠΡΟΒΛΕΨΕΩΝ

5.1 Έννοια Στοχαστικής Διεργασίας

Παρότι στο κεφάλαιο αυτό θα ασχοληθούμε με ορισμένα ντετερμινιστικά υποδείγματα (models) σημειακών προβλέψεων (point forecasts), απαραίτητη κρίνεται η παρουσίαση, έστω και σε στοιχειώδες επίπεδο, του μηχανισμού παραγωγής δεδομένων τα οποία θα χρησιμοποιηθούν σαν είσοδος για τα υποδείγματα αυτά (χρονοσειρές). Ο μηχανισμός αυτός αποτελεί μια στοχαστική διεργασία. Σε γενικές γραμμές, η **στοχαστική διεργασία (stochastic process)** ορίζεται ως ένα σύνολο τυχαίων μεταβλητών, κάθε μία από τις οποίες έχει δική της κατανομή πιθανότητας και όλες μαζί αποτελούν μια οικογένεια από κοινού κατανομημένων τυχαίων μεταβλητών.

Όταν λοιπόν έχουμε μια χρονολογική σειρά με N παρατηρήσεις, έστω Y_1, Y_2, \dots, Y_n θεωρούμε ότι κάθε παρατήρηση Y_t από αυτές είναι το αποτέλεσμα της πραγματοποίησης της συγκεκριμένης τυχαίας μεταβλητής Y_t από το σύνολο τυχαίων μεταβλητών $\{Y_1, Y_2, \dots, Y_n\}$, που αποτελούν μια στοχαστική διεργασία. Κάθε μία από τις τυχαίες μεταβλητές Y_t θα έχει το δικό της μέσο και τη δική της διακύμανση. Άρα σε κάθε στοχαστική διεργασία αντιστοιχεί μια ακολουθία μέσων και μία ακολουθία διακυμάνσεων αντίστοιχα.

Επιπλέον, μεταξύ διαφόρων τυχαίων μεταβλητών της ίδιας στοχαστικής διεργασίας υπάρχει συνήθως αλληλοσυσχέτιση. Στα περισσότερα προβλήματα στατιστικής προσπαθούμε να εκτιμήσουμε τις ιδιότητες του πληθυσμού από ένα δείγμα. Στις χρονοσειρές όμως δε μπορούμε να έχουμε περισσότερες από μία παρατηρήσεις για κάθε μία μεταβλητή σε συγκεκριμένο χρόνο. Πράγματι, σε μία διαγραμματική παρουσίαση μια χρονολογικής σειράς, σε κάθε χρονικό σημείο t , μπορούμε να θεωρήσουμε μία κατανομή πιθανών αποτελεσμάτων, εκ των οποίων μόνο ένα πραγματοποιείται. Γύρω από κάθε παρατήρηση, πρέπει να φανταζόμαστε μία σειρά κατανομών πιθανότητας που προφανώς μπορεί να μην συμπίπτει με το κέντρο της κατανομής. Έτσι, στο τέλος παρατηρούμε μόνο ένα αποτέλεσμα, τη δειγματική παρατήρηση της χρονολογικής σειράς Y_t τη συγκεκριμένα χρονική στιγμή t .

Με βάση τα προηγούμενα, θα θεωρούμε τις παρατηρήσεις μιας χρονολογικής σειράς σαν ένα δείγμα πραγματοποιήσεων από έναν άπειρο πληθυσμό τέτοιων δειγμάτων, τα

οποία θα μπορούσαν να έχουν παραχθεί από την ίδια στοχαστική διεργασία. Η έννοια του *πληθυσμού* της κλασικής στατιστικής αντιστοιχεί στην έννοια της στοχαστικής διεργασίας, ενώ η έννοια του *δείγματος* στην έννοια της *παρατηρούμενης* χρονοσειράς. Στις αναλύσεις που ακολουθούν ο όρος ‘χρονοσειρά’ αφορά τόσο στα παρατηρούμενα δεδομένα της σειράς, όσο και στη στοχαστική διεργασία μέσω της οποίας αυτά έχουν παραχθεί.

5.2 Εισαγωγή στις Χρονοσειρές

Με τον όρο χρονολογική σειρά (*χρονοσειρά* ή ‘*time series*’) ορίζουμε, όπως προαναφέρθηκε, ένα σύνολο παρατηρήσεων που συλλέγονται διαδοχικά στο χρόνο. Αν οι παρατηρήσεις αναφέρονται σε κάθε σημείο του χρόνου, τότε μιλάμε για μια συνεχή (continuous) χρονολογική σειρά (π.χ. η θερμοκρασία), ενώ αν οι μετρήσεις γίνονται σε προκαθορισμένα διαστήματα χρόνου, τότε μιλάμε για διακριτή (discrete) χρονολογική σειρά (π.χ. οι μισθοί).

Στην παρούσα εργασία θα ασχοληθούμε μόνο με διακριτές χρονοσειρές που οι παρατηρήσεις τους καταγράφονται σε σταθερά και ίσα χρονικά διαστήματα διάρκειας **ενός μήνα**. Αν συμβολίσουμε τη χρονολογική σειρά με το γράμμα Y και με τον υποδείκτη t δηλώσουμε τη χρονική περίοδο που ελήφθη η παρατήρηση (στην περίπτωση μας : ο μήνας), τότε η ακολουθία τιμών

$$Y_1, Y_2, \dots, Y_n \quad \text{ή} \quad \{Y_t\}, t = 1, 2, \dots, N$$

αποτελεί ένα δείγμα N παρατηρήσεων (observations) της χρονολογικής σειράς Y_t . Η μελέτη μιας χρονολογικής σειράς προϋποθέτει τη συλλογή ενός μεγάλου αριθμού παρατηρήσεων με συγκεκριμένη συχνότητα στο χρόνο.

5.2.1 Ποιοτικά Χαρακτηριστικά Χρονοσειρών

Η πραγματοποίηση της ορθής μελέτης μίας χρονοσειράς γίνεται μέσω της επισκόπησής της στο πεδίο του χρόνου. Για την κατανόηση των βασικών χαρακτηριστικών των χρονοσειρών, μπορούμε να αναλύσουμε την χρονοσειρά στα βασικά της στοιχεία τα οποία είναι : η τάση, η κυκλικότητα, η εποχικότητα, όπως και οι ασυνέχειες (οι οποίες αποτελούν υποσύνολο των μη κανονικών διακυμάνσεων)

- **Η τάση (trend)**, ορίζεται ως η μακροπρόθεσμη μεταβολή του μέσου επιπέδου των τιμών μιας χρονοσειράς. Δίνοντας ιδιαίτερη έμφαση στον όρο μακροπρόθεσμη μεταβολή, για την επιτυχή αναγνώριση της τάσης θα πρέπει να υπάρχει επαρκής αριθμός παρατηρήσεων, όπως και να έχει οριστεί κατάλληλα το μήκος της περιόδου μέσα στην οποία θα αναζητηθεί η τάση. Η τάση μπορεί να είναι ανοδική, πτωτική ή μηδενική, ενώ σε κάθε περίπτωση αντιπροσωπεύει μία γενική απεικόνιση της χρονοσειράς.
- **Η κυκλικότητα (cyclic)**, θεωρείται ως μια κυματοειδής μεταβολή (ανοδική ή πτωτική), που εμφανίζεται σε περιόδους και οφείλεται σε εξωτερικούς παράγοντες. Αν και το μήκος της δεν είναι σταθερό τείνει να είναι μεγαλύτερο του ενός έτους.
- **Η εποχικότητα (seasonality)**, μπορεί να οριστεί ως μια περιοδική διακύμανση που έχει σταθερό μήκος μικρότερο του ενός έτους. Το σταθερό μήκος που την διακρίνει είναι και το χαρακτηριστικό που την διαφοροποιεί από την κυκλικότητα, αφού η διακυμάνσή της είναι σταθερή και μπορεί να εμφανίζεται με διακριτότητα ημέρας, εβδομάδας ή μήνα. Η συγκεκριμένη διακύμανση είναι άμεσα κατανοητή και προβλέψιμη, αφού επαναλαμβάνεται με το ίδιο μοτίβο σε σχέση με το χρόνο, γεγονός που την κάνει εύκολα εξηγήσιμη.
- **Οι ασυνέχειες**, αντιπροσωπεύουν απότομες αλλαγές στο γράφημα κάποιας χρονοσειράς και μπορεί να έχουν παροδικό ή και μόνιμο χαρακτήρα. Οι παροδικές ασυνέχειες (outliers) έχουν μικρή χρονική διάρκεια και συχνά αποτελούν μια ασυνήθιστη παρατήρηση, η οποία οφείλεται σε κάποιο εξαιρετικό γεγονός. Αντιθέτως, οι ασυνέχειες που έχουν μόνιμο χαρακτήρα (level-shifts) έχουν την μορφή μιας απότομης αλλαγής στο μέσο επίπεδο των τιμών μιας χρονοσειράς.
- **Οι μη κανονικές διακυμάνσεις**, είναι οι τιμές που υπολείπονται, έπειτα από την απομόνωση των υπόλοιπων χαρακτηριστικών μιας χρονοσειράς (τάση, κυκλικότητα, εποχικότητα) . Μπορεί να εκφράζουν μια τυχαία μεταβλητή,

δηλαδή τον τυχαίο παράγοντα μιας στοχαστικής διεργασίας, ή μια ασυνέχεια λόγω κάποιου ακραίου γεγονότος.

Για να μπορέσουμε να εξάγουμε, τα παραπάνω χαρακτηριστικά τα οποία θα οδηγήσουν στην καλύτερη κατανόηση και μελέτη της χρονοσειράς χρησιμοποιούμε μαθηματικές σχέσεις για την απομόνωσή τους. Σύμφωνα με τη μέθοδο διάσπασης (**decomposition method**) μια χρονοσειρά μπορεί να διαχωριστεί σε 4 επιμέρους συνιστώσες. Στη γενική μορφή έχουμε :

$$Y_t = f(T_t, S_t, C_t, I_t) \quad (5.1)$$

όπου

T_t = τάση (μακροχρόνια διακύμανση)

S_t = εποχικότητα (εποχιακές περιοδικές κυμάνσεις)

C_t = κύκλοι (βραχυχρόνιες κυμάνσεις γύρω από την τάση του)

I_t = ακανόνιστες κυμάνσεις ή τυχαίες επιδράσεις ή κατάλοιπο λάθους ή θόρυβος

5.2.2 Στατιστική Ανάλυση Χρονοσειρών

Μέσω της στατιστικής ανάλυσης των χρονοσειρών μπορούν να υπολογιστούν οι βασικοί στατιστικοί δείκτες σε μια δεδομένη χρονοσειρά Y με μέγεθος n παρατηρήσεων, κάτι το οποίο οδηγεί στην συνέχεια στην αποτελεσματική επιλογή μεθοδολογιών πρόβλεψης. Οι βασικοί στατιστικοί δείκτες είναι:

- **Δειγματική Μέση τιμή (Average)**, η οποία αποτελεί τον γραμμικό μέσο όρο των τιμών των παρατηρήσεων και δείχνει το επίπεδο στο οποίο κυμαίνονται οι πραγματικές τιμές της χρονοσειράς. Μαθηματικά, υπολογίζεται από τον τύπο

$$\mu = \frac{\sum_{i=1}^N Y_i}{N} \quad (5.3)$$

- **Δειγματική Τυπική απόκλιση (Standard Deviation)**, η οποία ονομάζεται και ως διασπορά μιας και είναι ένας δείκτης του βαθμού διασποράς των παρατηρήσεων γύρω από την μέση τιμή. Η δειγματική τιμή της προκύπτει από τον τύπο:

$$\sigma = \sqrt{\frac{\sum_{i=1}^N (Y_i - \mu)^2}{N}} \quad (5.4)$$

- **Δειγματική Διακύμανση (Variance)**, η οποία προκύπτει από το τετράγωνο της τυπικής απόκλισης.
- **Δειγματική Συνδιακύμανση (Covariance)**, η οποία για δύο διακριτές τυχαίες μεταβλητές X και Y , δίνει ένα μέτρο συσχέτισης μεταξύ δύο περιοχών δεδομένων, με αποτέλεσμα να ορίζει το αν οι μεταβλητές μεταβάλλονται ανάλογα (θετική συνδιακύμανση), αντιστρόφως ανάλογα (αρνητική συνδιακύμανση), ή αν οι μεταβλητές είναι ασυσχέτιστες μεταξύ τους (μηδενική συνδιακύμανση). Μαθηματικά υπολογίζεται από τον τύπο :

$$Cov(X, Y) = \frac{\sum_{i=1}^N (Y_i - \mu_x)(Y_i - \mu_y)}{N} \quad (5.5)$$

- **Δειγματικός Συντελεστής αυτοσυσχέτισης (Autocorrelation Coefficient)**, ο οποίος αποτελεί ένδειξη της συσχέτισης μεταξύ των παρατηρήσεων της ίδιας μεταβλητής με χρονική υστέρηση k περιόδων. Το εύρος των τιμών του συντελεστή αυτοσυσχέτισης είναι μεταξύ του διαστήματος $[-1, 1]$. Έτσι, εάν η τιμή του είναι κοντά στο μηδέν, δηλώνει την μηδενική συσχέτιση των παρατηρήσεων με χρονική υστέρηση k περιόδων, αν η τιμή του είναι κοντά στο ένα δηλώνει θετική συσχέτιση μεταξύ των παρατηρήσεων αυτών, ενώ αν είναι κοντά στο μείον ένα, την αρνητική συσχέτιση μεταξύ των παρατηρήσεων. Η τιμή του συντελεστή αυτοσυσχέτισης αποδεικνύεται εξαιρετικά χρήσιμη στον προσδιορισμό της εποχιακής συμπεριφοράς μιας σειράς παρατηρήσεων.

Μαθηματικά υπολογίζεται από τον τύπο :

$$\rho_k = \frac{\sum_{i=1+k}^N (Y_i - \mu_y)(Y_{i-k} - \mu_y)}{\sum_{i=1}^N (Y_i - \mu_y)^2} \quad (5.6)$$

Όλοι οι παραπάνω μαθηματικοί τύποι έχουν προκύψει από το ίδιο το δείγμα και για αυτό ονομάζονται δειγματικοί. Σημαντικό είναι να μην συγχέονται με τους θεωρητικούς τύπους. Όσο περισσότερη είναι η ιστορική πληροφορία τόσο μικρότερη θα είναι η απόκλιση μεταξύ θεωρητικής και δειγματικής τιμής.

5.2.3 Στασιμότητα

Η βασική ιδέα της στασιμότητας είναι ότι οι νόμοι πιθανότητας που διέπουν μια στοχαστική διεργασία δεν μεταβάλλονται με το χρόνο. Η στασιμότητα ορίζεται με την αυστηρή έννοια, είτε με την ασθενέστερη που είναι και η επικρατούσα. Μια στοχαστική διαδικασία χαρακτηρίζεται ως αυστηρά στάσιμη (strictly stationary) όταν οι στατιστικές ιδιότητες δεν επηρεάζονται από μια μετακίνηση στο χρόνο, παραμένουν δηλαδή χρονικά αμετάβλητες. Ειδικότερα, μια στοχαστική διαδικασία $\{Y_t\}$ θεωρείται αυστηρά στάσιμη αν η από κοινού κατανομή πιθανότητας των $\{Y_t, Y_{t+1}, \dots, Y_{t+N-1}\}$ είναι η ίδια με την από κοινού κατανομή του συνόλου $\{Y_{t+k}, Y_{t+k+1}, \dots, Y_{t+k+N-1}\}$ για οποιαδήποτε επιλογή του χρόνου t , του πλήθους N και των υστερήσεων k .

Ένας παρόμοιος ορισμός αλλά μαθηματικά λιγότερο αυστηρός, είναι αυτός της ασθενούς στασιμότητας. Ο ορισμός αυτός απαιτεί στασιμότητα μόνο στις στατιστικές ροπές πρώτης τάξης (δηλαδή του μέσου) και της δεύτερης τάξης (δηλαδή των διακυμάνσεων και των συνδιακυμάνσεων). Έτσι μια χρονοσειρά θα είναι **ασθενώς στάσιμη (weakly stationary)**, αν ο μέσος και η διακύμανση δεν μεταβάλλονται με το χρόνο και η συνδιακύμανση μεταξύ των τιμών της σε δύο χρονικά σημεία εξαρτάται μόνο από την απόσταση ανάμεσα σε αυτά τα χρονικά σημεία και όχι από τον ίδιο το χρόνο.

Μαθηματικά, αν η χρονολογική σειρά είναι ασθενώς στάσιμη, τότε θα ισχύουν οι εξής συνθήκες:

$$\bullet \quad E(Y_t) = \mu_y, \text{ για όλα τα } t \quad (5.7)$$

$$\bullet \quad \text{Var}(Y_t) = E[Y_t - E(Y_t)]^2 = \sigma_y^2, \text{ για όλα τα } t \quad (5.8)$$

$$\bullet \quad \text{Cov}(Y_t, Y_{t+k}) = \text{Cov}(Y_{t+m}, Y_{t+m+k}) = \gamma_k, \text{ για όλα τα } t \text{ και } k, m \neq 0 \quad (5.9)$$

όπου μ_y συμβολίζει το σταθερό μέσο της Y_t , το σ_y^2 συμβολίζει τη σταθερή διακύμανση της και το γ_k τη συνδιακύμανση μεταξύ δύο οποιονδήποτε τιμών της Y_t που απέχουν k χρονικές περιόδους. Στο εξής, η τελευταία θα ονομάζεται **αυτοσυνδιακύμανση (autocovariance)** και ορίζεται ως

$$\gamma_k = \text{Cov}(Y_t, Y_{t+k}) = E[Y_t - E(Y_t)][Y_{t+k} - E(Y_{t+k})] \quad (5.10)$$

Η πρώτη συνθήκη υποδηλώνει σταθερό μέσο και η δεύτερη σταθερή διακύμανση για οποιαδήποτε χρονική στιγμή t . Η τρίτη δηλώνει ότι η συνδιακύμανση μεταξύ δύο οποιωνδήποτε τιμών της Y_t που απέχουν k περιόδους είναι συνάρτηση μόνο του k ,

δηλαδή της χρονικής υστέρησης των δύο αυτών τιμών. Είναι φανερό ότι η αυτοσυνδιακύμανση μηδενικής υστέρησης είναι η διακύμανση, δηλαδή

$$\gamma_0 = \text{Cov}(Y_t, Y_t) = \text{Var}(Y_t) = \sigma_y^2 \quad (5.11)$$

Έτσι μπορούμε να ενοποιήσουμε τις δύο τελευταίες συνθήκες και να διατυπώσουμε πιο συνοπτικά της συνθήκες στασιμότητας ως

1. Σταθερός μέσος σε όλα τα χρονικά σημεία t
2. Συνδιακυμάνσεις γ_k ανεξάρτητες του χρόνου t για οποιονδήποτε ακέραιο k .

Παραβίαση οποιασδήποτε από τις συνθήκες (5.7) – (5.9) καθιστά τη σειρά μη στάσιμη. Στη βιβλιογραφία μια διαδικασία που πληροί τις παραπάνω συνθήκες μπορεί να αναφέρεται και ως **στάσιμη δεύτερης τάξεως (second order stationary)** ή **στάσιμη ως προς την συνδιακύμανση (covariance stationary)**. Στο εξής, ο όρος στασιμότητα αναφέρεται στον τελευταίο ορισμό της ασθενούς στασιμότητας.

5.3 Στάσιμα Υποδείγματα Χρονοσειρών ARMA

Τα υποδείγματα αυτά ανήκουν στη γενικότερη κατηγορία των γραμμικών υποδειγμάτων. Πρόκειται για τα αυτοπαλίνδρομα μοντέλα κινητών μέσων γνωστά και ως ARMA. Η χρησιμότητα των υποδειγμάτων αυτών είναι μεγάλη, γιατί έχει αποδειχθεί ότι ερμηνεύουν σε ικανοποιητικό βαθμό μεγάλο αριθμό πραγματικών δεδομένων από διάφορους επιστημονικούς χώρους.

Από τη στιγμή που κάνουμε λόγο για στασιμότητα, κρίνεται σημαντικό να παρουσιαστεί η πιο γνωστή στάσιμη χρονολογική σειρά, αυτή του λευκού θορύβου. Το απλούστερο δυνατό σχήμα χρονολογικής σειράς είναι η στοχαστική διαδικασία του **λευκού θορύβου (white noise)**. Μια σειρά είναι λευκός θόρυβος αν στην ουσία δεν έχει κανένα ευκρινές σχήμα ή πρότυπο. Αν συμβολίσουμε με e_t μια τέτοια σειρά, τότε θα λέμε ότι είναι λευκός θόρυβος αν έχει σταθερό μέσο (συνήθως μηδέν), σταθερή διακύμανση και οι τιμές της δεν αυτοσυσχετίζονται. Πιο συγκεκριμένα, η υπόθεση του λευκού θορύβου συνεπάγεται τα εξής:

- $E(e_t) = 0$, για όλα τα t
- $\gamma_0 = E(e_t)^2 = \sigma_\varepsilon^2$, για όλα τα t
- $\gamma_k = E(e_t e_{t-k}) = 0$, για όλα τα t

Επομένως αναλύοντας τη διαδικασία του λευκού θορύβου το βασικότερο εξαγόμενο είναι ότι οι τιμές της είναι τυχαίες και δεν αλληλοσυσχετίζονται. Στην πράξη όμως, αυτό που παρατηρούμε είναι αλληλοεξάρτηση των τιμών που χαρακτηρίζει τις περισσότερες χρονολογικές σειρές. Άρα η διαδικασία του λευκού θορύβου κρίνεται ακατάλληλη για την περιγραφή τέτοιων χρονοσειρών. Αντίθετα, η ανάπτυξη ARMA υποδειγμάτων στηρίζεται στην ιδέα της ισχυρής συσχέτισης που εμφανίζουν διάφορες σειρές από το χώρο της υδρολογίας και άλλων επιστημών.

Η γενική μορφή ενός ARMA υποδείγματος είναι η εξής:

$$Y_t = \delta + \alpha_1 Y_{t-1} + \alpha_2 Y_{t-2} + \dots + \alpha_p Y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (5.13)$$

όπου δ δηλώνει τη σταθερά της εξίσωσης, οι παράμετροι $\alpha_1, \alpha_2, \dots, \alpha_p$ είναι οι συντελεστές του **αυτοπαλίνδρομου (autoregressive, AR)** μέρους και $\theta_1, \theta_2, \dots, \theta_q$ οι συντελεστές των **κινητών μέσων (moving average, MA)**. Τα ε_t αποτελούν λευκό θόρυβο όπως τον ορίσαμε προηγουμένως. Πρόκειται για ένα υπόδειγμα παλινδρόμησης με εξαρτημένη μεταβλητή τη χρονοσειρά Y_t και ερμηνευτικές μεταβλητές τις προηγούμενες τιμές της ίδιας σειράς (υστερήσεις p -τάξεως) καθώς και έναν αριθμό προηγούμενων λαθών (υστερήσεις q -τάξεως της τυχαίας μεταβλητής ε_t). Γι' αυτό και ονομάζεται **αυτοπαλίνδρομο μοντέλο κινητών μέσων όρων τάξεως (p,q)**, συμβολιζόμενο ως **ARMA (p,q)**.

5.3.1 Αυτοπαλίνδρομο Υπόδειγμα AR(1)

Από την οικογένεια των ARMA μοντέλων διαλέξαμε να ασχοληθούμε με το αυτοπαλίνδρομο μοντέλο 1^{HS} τάξης, ένα απλό σε σύλληψη και χωρίς μεγάλες απαιτήσεις σε υπολογιστικό φόρτο μοντέλο. Χρησιμοποιήθηκε σαν το μοντέλο βάσης για τις προβλέψεις.

Αν στο γενικό υπόδειγμα (5.13) θεωρήσουμε μόνο μια υστέρηση της χρονοσειράς Y_t και μόνο το τρέχον σφάλμα ε_t , τότε λαμβάνουμε το **αυτοπαλίνδρομο υπόδειγμα πρώτης τάξεως (autoregressive of order 1)** ή υπόδειγμα **AR(1)**:

$$Y_t = \delta + \alpha_1 Y_{t-1} + \varepsilon_t \quad (5.14)$$

όπου το τυχαίο σφάλμα ε_t είναι λευκός θόρυβος και ανεξάρτητο των υστερήσεων. Το υπόδειγμα αυτό αναλύεται ευκολότερα αν το επιλύσουμε με την επαναληπτική μέθοδο των διαδοχικών αντικαταστάσεων.

Έτσι, θεωρώντας ως αρχική τιμή το Y_0 , η ακολουθία των Y_1, Y_2, \dots, Y_t μπορεί να ληφθεί αντικαθιστώντας διαδοχικά στην (5.14) τις προηγούμενες τιμές της Y_t :

$$\begin{aligned} Y_1 &= \delta + \alpha Y_0 + \varepsilon_1 \\ Y_2 &= \delta + \alpha(\delta + \alpha Y_0 + \varepsilon_1) + \varepsilon_2 \\ &\dots \\ Y_t &= \delta \sum_{j=0}^{t-1} \alpha^j + \alpha^t Y_0 + \sum_{j=0}^{t-1} \alpha^j \varepsilon_{t-j} \end{aligned} \tag{5.15}$$

Αυτή αποτελεί την **αναδρομική μορφή (recursive form)** του υποδείγματος με βάση την οποία μπορούμε να μελετήσουμε τις συνθήκες στασιμότητας της Y_t . Για τη στασιμότητα του μέσου, λαμβάνουμε κατά μέλη την αναμενόμενη τιμή της (5.15):

$$E(Y_t) = \delta \sum_{j=0}^{t-1} \alpha^j + \alpha^t E(Y_0) + \sum_{j=0}^{t-1} \alpha^j E(\varepsilon_{t-j}) \tag{5.16}$$

όπου οι παράμετροι δ και α είναι σταθερές. Ο τελευταίος όρος στη σχέση αυτή μηδενίζεται αφού $E(\varepsilon_t)=0$ για όλα τα t και θεωρώντας την αρχική τιμή Y_0 δεδομένη, η εξίσωση του μέσου (4.16) απλοποιείται ως εξής:

$$E(Y_t) = \delta \sum_{j=0}^{t-1} \alpha^j + \alpha^t Y_0 = \delta \sum_{j=0}^{\infty} \alpha^j - \sum_{j=t}^{\infty} \alpha^j + \alpha^t Y_0 \tag{5.17}$$

Αυτή είναι συνάρτηση του χρόνου που σημαίνει ότι γενικά η Y_t δεν είναι στάσιμη. Παρατηρούμε όμως ότι τα δυο αθροίσματα στην (5.17) τείνουν στο άπειρο, οπότε για να συγκλίνουν θα πρέπει να ικανοποιείται η συνθήκη $|\alpha| < 1$. Αν πράγματι ισχύει η συνθήκη αυτή τότε τα αθροίσματα στην παρένθεση αποτελούν φθίνουσα γεωμετρική πρόοδο απείρου τάξεως με λόγο το α . Το όριο του πρώτου είναι $\frac{1}{1-\alpha}$, ενώ του δεύτερου είναι $\frac{\alpha^t}{1-\alpha}$. Κάνοντας αλγεβρικές πράξεις, προκύπτει ότι ο μέσος ισούται με :

$$\begin{aligned} E(Y_t) &= \delta \left(\frac{1}{1-\alpha} - \frac{\alpha^t}{1-\alpha} \right) + \alpha^t Y_0 = \\ &= \frac{\delta}{1-\alpha} \end{aligned} \tag{5.18}$$

καθόσον $a^t \rightarrow 0$ καθώς το $t \rightarrow \infty$ για $|\alpha| < 1$. (5.19)

Επομένως, η σειρά Y_t είναι στάσιμη στο όριο και η παραπάνω συνθήκη $|\alpha| < 1$ αποτελεί τη συνθήκη στασιμότητας του **AR(1)** υποδείγματος. Από την (5.18) προκύπτει ότι η σταθερά δ της εξίσωσης του **AR(1)** ισούται με

$$\delta = \mu(1 - \alpha), \mu = E(Y_t) \quad (5.20)$$

5.3.2 Μέθοδοι Εκτίμησης Παραμέτρων **AR(p)** Υποδειγμάτων

Ο τρόπος και η δυσκολία εκτίμησης των παραμέτρων ενός υποδείγματος **AR(p)** εξαρτάται από την τάξη του p . Μία πρώτη και εύκολη προσέγγιση στηρίζεται στις σχέσεις που συνδέουν τους συντελεστές αυτοσυσχέτισης ρ_k της χρονοσειράς με τις παραμέτρους των υποδειγμάτων αυτών, μέσω δηλαδή των εξισώσεων **Yule-Walker**. Η μέθοδος αυτή ονομάζεται **μέθοδος των ροπών** και τα αποτελέσματα της είναι αρκετά ικανοποιητικά στην περίπτωση αυτοπαλίνδρομων μορφών.

Γενικά, στην κατηγορία των γραμμικών υποδειγμάτων παλινδρόμησης, δύο είναι οι πιο γνωστές μέθοδοι εκτίμησης, η **μέθοδος ελάχιστων τετραγώνων (Least Squares, LS)** και η **μέθοδος μέγιστης πιθανοφάνειας (Maximum Likelihood, ML)**. Η πρώτη, δηλαδή η **μέθοδος LS**, οδηγεί σε εκτιμήσεις οι οποίες δεν πληρούν τις ιδιότητες των εκτιμητών μεγάλων δειγμάτων. Αντίθετα, η **μέθοδος μέγιστης πιθανοφάνειας**, δίνει εκτιμητές που ισχύουν και ασυμπτωτικά.

Στην επόμενη ενότητα θα ασχοληθούμε με την μαθηματική περιγραφή της μεθόδου των ροπών, αφού αποτελεί την μέθοδο που επιλέχθηκε για να εκτιμήσει τις παραμέτρους του μοντέλου **AR(1)** της παρούσας εργασίας.

5.3.3 Μέθοδος Εκτίμησης των Ροπών στα **AR(p)** Υποδείγματα

Όπως ελέχθη προηγούμενα, η μέθοδος εκτίμησης των ροπών στηρίζεται στην επίλυση εξισώσεων που συνδέουν τους συντελεστές αυτοσυσχέτισης ρ_k της χρονολογικής σειράς με τις παραμέτρους των συγκεκριμένων υποδειγμάτων που επιθυμούμε να εκτιμήσουμε.

Μία συνάρτηση που χρησιμοποιείται στη μελέτη χαρακτηριστικών μιας χρονοσειράς είναι η συνάρτηση των συντελεστών μερικής αυτοσυσχέτισης. Γενικά, ο συντελεστής μερικής αυτοσυσχέτισης, έστω $r_{xy; z_1, \dots, z_n}$ μετρά τη συσχέτιση μεταξύ των μεταβλητών

x και y όταν έχει αφαιρεθεί η επίδραση που ασκούν οι z_1, \dots, z_n πάνω σε αυτές. Στην περίπτωση μιας χρονολογικής σειράς, ο **συντελεστής μερικής αυτοσυσχέτισης (partial autocorrelation coefficient)** μεταξύ Y_t και Y_{t+k} ορίζεται ως ο συντελεστής συσχέτισης μεταξύ τους, όταν έχουν ληφθεί υπόψη οι συσχετίσεις όλων των ενδιάμεσων τιμών.

Η έννοια της μερικής αυτοσυσχέτισης μπορεί να εξηγηθεί καλύτερα μέσα από τα μοντέλα αυτοπαλινδρόμησης. Για απλούστευση, θεωρούμε ότι η χρονοσειρά μας έχει μηδενικό μέσο. Στο εξής θα συμβολίζουμε τις τιμές αυτές με μικρά γράμματα

$y_t = Y_t - \bar{Y}$ οπότε ισχύει $\bar{y} = 0$. Αρχίζουμε με μία αυτοπαλινδρόμηση, δηλαδή παλινδρομούμε τη σειρά y_t στις δύο προηγούμενες μετρήσεις της ίδιας μεταβλητής:

$$y_t = \varphi_{21}y_{t-1} + \varphi_{22}y_{t-2} + \varepsilon_t \quad (5.21)$$

όπου ο πρώτος υποδείκτης του συντελεστή φ_{ij} δηλώνει τη χρονική υστέρηση της μεταβλητής που πολλαπλασιάζει και ο δεύτερος τη μέγιστη τάξη της παλινδρόμησης (δύο στη συγκεκριμένη περίπτωση). Τότε, ο συντελεστής της y_{t-2} μετρά τον συντελεστή μερικής αυτοσυσχέτισης δεύτερης τάξης (φ_{22}) καθόσον αυτός δείχνει τη συσχέτιση μεταξύ των y_t και y_{t-2} όταν έχει συμπεριληφθεί στην παλινδρόμηση η ενδιάμεση y_{t-1} παρατήρηση.

Γενικότερα, ο **συντελεστής μερικής αυτοσυσχέτισης k-οστής τάξης**, συμβολίζεται με το γράμμα φ_{kk} και είναι ο συντελεστής του y_{t-k} στην παλινδρόμηση :

$$y_t = \varphi_{k1}y_{t-1} + \varphi_{k2}y_{t-2} + \dots + \varphi_{kk}y_{t-k} + \varepsilon_t \quad (5.22)$$

Είναι προφανές ότι ο συντελεστής πρώτης τάξης φ_{11} ταυτίζεται με τον απλό συντελεστή αυτοσυσχέτισης ρ_1 .

Στην πράξη εκτιμούμε υποδείγματα της μορφής (5.22), ξεκινώντας με μια χρονική υστέρηση y_t και προσθέτοντας διαδοχικά από μια υστέρηση κάθε φορά. Οι εκτιμήσεις ελάχιστων τετραγώνων των συντελεστών φ_{kk} σε κάθε τέτοιο υπόδειγμα για $k = 1, 2, 3, \dots$ μας δίνει τη σειρά των συντελεστών μερικής αυτοσυσχέτισης $\widehat{\varphi}_{11}, \widehat{\varphi}_{12}, \widehat{\varphi}_{13}, \dots$. Έτσι, για παράδειγμα, οι τρεις πρώτοι συντελεστές προκύπτουν από τις εκτιμήσεις των υποδειγμάτων:

$$\begin{aligned} y_t &= \varphi_{11}y_{t-1} + \varepsilon_t && \rightarrow \widehat{\varphi}_{11} \\ y_t &= \varphi_{21}y_{t-1} + \varphi_{22}y_{t-2} + \varepsilon_t && \rightarrow \widehat{\varphi}_{22} \quad (5.23) \\ y_t &= \varphi_{31}y_{t-1} + \varphi_{32}y_{t-2} + \varphi_{33}y_{t-3} + \varepsilon_t && \rightarrow \widehat{\varphi}_{33} \end{aligned}$$

Οι τιμές των $\widehat{\varphi}_{kk}$ για διάφορες τιμές του $k = 1, 2, 3, \dots$ αποτελούν τη **συνάρτηση μερικής αυτοσυσχέτισης (partial autocorrelation function)** που συμβολίζεται με PACF ή απλώς PAC. Η μορφή της συνάρτησης αυτής, καθώς και της απλής συνάρτησης αυτοσυσχέτισης (ACF), είναι εξαιρετικά χρήσιμη καθώς μας καθοδηγεί στον προσδιορισμό της μορφής της στοχαστικής διαδικασίας που δημιουργήσε τη δεδομένη χρονολογική σειρά.

Υπάρχει όμως και η μέθοδος υπολογισμού των συντελεστών μερικής αυτοσυσχέτισης μέσω των συντελεστών αυτοσυσχέτισης ρ_k εφόσον αυτοί είναι γνωστοί. Πράγματι, αν πολλαπλασιάσουμε την εξίσωση (5.22) με y_{t-j} κατά μέλη και λάβουμε τις αναμενόμενες τιμές, τότε προκύπτουν οι εξισώσεις των αυτοσυνδιακυμάνσεων:

$$\gamma_j = \varphi_{k1}\gamma_{j-1} + \varphi_{k2}\gamma_{j-2} + \dots + \varphi_{kk}\gamma_{j-k}, \quad j = 1, 2, \dots, k \quad (5.24)$$

καθόσον ισχύει ότι

$$\begin{aligned} E(y_{t-m}y_{t-k}) &= \gamma_{k-m} \\ E(y_{t-k}\varepsilon_t) &= 0, \quad k > 0 \end{aligned} \quad (5.25)$$

Το τελευταίο οφείλεται στο γεγονός ότι οι τιμές y_{t-j} είναι συνάρτηση των προηγούμενων λαθών μέχρι και ε_{t-j} , αλλά δεν συσχετίζονται με το τρέχον σφάλμα. Διαιρώντας κατά μέλη την (5.24) με τη διακύμανση γ_0 λαμβάνουμε το σύστημα των **Yule-Walker εξισώσεων**

$$\rho_j = \varphi_{k1}\rho_{j-1} + \varphi_{k2}\rho_{j-2} + \dots + \varphi_{kk}\rho_{j-k}, \quad j = 1, 2, \dots, k \quad (5.26)$$

Το σύστημα των k εξισώσεων της (5.26) ως προς τις παραμέτρους $\varphi_{k1}, \varphi_{k2}, \varphi_{kk}$ είναι γνωστό ως **σύστημα των εξισώσεων Yule-Walker**:

$$\varphi_k = P_k^{-1}\rho_k \quad (5.27)$$

όπου

$$\varphi_k = \begin{bmatrix} \varphi_{k1} \\ \varphi_{k2} \\ \vdots \\ \varphi_{kk} \end{bmatrix}, \quad P_k = \begin{bmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{k-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & 1 \end{bmatrix}, \quad \rho_k = \begin{bmatrix} \rho_1 \\ \rho_2 \\ \vdots \\ \rho_1 \end{bmatrix}$$

Ο τελευταίος συντελεστής φ_{kk} του συστήματος μας δίνει κάθε φορά το συντελεστή μερικής αυτοσυσχέτισης k τάξεως. Επιλύοντας διαδοχικά το σύστημα (5.27) για $k = 1, 2, 3, \dots$ λαμβάνουμε τη συνάρτηση μερικής αυτοσυσχέτισης.

Μετά την παρουσίαση του συστήματος Yule-Walker επιστρέφουμε στη μέθοδο εκτίμησης των Ροών. Αν το υπόδειγμα που έχουμε επιλέξει είναι της μορφής $AR(p)$, τότε λύνοντας το σύστημα εξισώσεων (5.27) και αντικαθιστώντας τις θεωρητικές τιμές ρ_k των συντελεστών αυτοσυσχέτισης με τις δειγματικές $\widehat{\rho}_k$, λαμβάνουμε τις εκτιμήσεις του διανύσματος $\varphi = [\alpha_1 \alpha_2 \alpha_3 \dots \alpha_p]$ των παραμέτρων του $AR(p)$. Στη δική μας περίπτωση, για το $AR(1)$, η εκτίμηση της παραμέτρου α ισούται με

$$\alpha = \widehat{\rho}_1 \quad (5.28)$$

Ενδεικτικά, για λόγους πληρότητας εργασίας παρατίθενται και οι εκτιμήσεις για το μοντέλο $AR(2)$,

$$\widehat{\alpha}_1 = \frac{\widehat{\rho}_1}{1 - \widehat{\rho}_1^2} (1 - \widehat{\rho}_2) \quad , \quad \widehat{\alpha}_2 = \frac{\widehat{\rho}_1^2}{1 - \widehat{\rho}_1^2} (1 - \widehat{\rho}_2) \quad (5.29)$$

Συνεχίζοντας τη διαδικασία αυτή μπορούμε να εκτιμήσουμε τους συντελεστές αυτοπαλινδρόμησης οποιασδήποτε τάξης μέσω των εξισώσεων (5.27). Η επίλυση τους μπορεί να γίνει με διάφορες μεθόδους. Μερικές από αυτές είναι η μέθοδος *Cramer* των οριζουσών, αλλά και ο αλγόριθμος των *Durbin-Levinson* που αποτελεί αποτελεσματική και εύχρηστη μέθοδο επίλυσης.

5.4 Τεχνητά Νευρωνικά Δίκτυα και LSTM

5.4.1 Διαδικασίες Μηχανικής Μάθησης

Με τον όρο μηχανική μάθηση αναφερόμαστε στο πεδίο της επιστήμης των υπολογιστών, το οποίο ασχολείται με την κατασκευή αλγορίθμων που μαθαίνουν από δεδομένα και μπορούν να κάνουν προβλέψεις σχετικά με αυτά. Όπως οι άνθρωποι οργανισμοί έχουν αναπτύξει διαφορετικούς τρόπους για να μαθαίνουν από το περιβάλλον τους, έτσι και στην μηχανική μάθηση αλγόριθμοι όπως αυτοί των νευρωνικών δικτύων χρησιμοποιούνται με διαφορετικούς τρόπους για την επίτευξη μάθησης. Οι βασικότερες κατηγορίες στις οποίες μπορεί να χωριστούν οι διαδικασίες μάθησης των νευρωνικών δικτύων είναι, η μάθηση με εκπαιδευτή (επιβλεπόμενη μάθηση) και η μάθηση χωρίς εκπαιδευτή, με την δεύτερη να χωρίζεται σε δυο επιμέρους κατηγορίες την μη επιβλεπόμενη μάθηση και την ενισχυτική μάθηση. Συνοψίζοντας τα χαρακτηριστικά της κάθε κατηγορίας μπορούμε να πούμε περιληπτικά :

- **Επιβλεπόμενη μάθηση (Supervised learning).** Η μάθηση αυτού του είδους περιλαμβάνει έναν εκπαιδευτή που έχει γνώση του περιβάλλοντος, το οποίο


αντιπροσωπεύεται μέσω παραδειγμάτων εισόδου-εξόδου. Το περιβάλλον ωστόσο είναι άγνωστο για το νευρωνικό δίκτυο. Κατά την εκπαίδευση, ο εκπαιδευτής δίνει στο νευρωνικό δίκτυο ως είσοδο ένα διάνυσμα εκπαίδευσης, ενώ λόγω της γνώσης του περιβάλλοντος δίνει στο νευρωνικό δίκτυο και την επιθυμητή απόκριση για το διάνυσμα εκπαίδευσης. Το νευρωνικό δίκτυο λοιπόν, προσαρμόζει τις παραμέτρους του βάσει της επιρροής του διανύσματος εκπαίδευσης και του σήματος σφάλματος που ορίζεται ως η διαφορά της πραγματικής με την επιθυμητή απόκριση του δικτύου. Με την επανάληψη της παραπάνω διαδικασίας στόχος είναι το νευρωνικό δίκτυο να μπορεί να προσομοιώσει την συμπεριφορά του εκπαιδευτή με αυξανόμενη ακρίβεια μειώνοντας το σήμα σφάλματος. Όταν επιτευχθεί ο παραπάνω στόχος, η γνώση του περιβάλλοντος που προσφέρεται από τον εκπαιδευτή θα έχει μεταφερθεί στα συναπτικά βάρη του νευρωνικού δικτύου, οπότε και το δίκτυο θα μπορεί να απαλλαγεί από τον εκπαιδευτή και να προσομοιώσει μόνο του το περιβάλλον.

- **Μη επιβλεπόμενη μάθηση (Unsupervised learning).** Σε αντίθεση με την επιβλεπόμενη μάθηση, στην μη επιβλεπόμενη δεν υπάρχει κάποιος εξωτερικός εκπαιδευτής ο οποίος δίνει γνώση του περιβάλλοντος στο νευρωνικό δίκτυο και επιβλέπει την εκπαίδευση. Αντιθέτως, ορίζεται ένα ανεξάρτητο μέτρο της ποιότητας της αναπαράστασης, που το νευρωνικό δίκτυο καλείται να μάθει με βάση το οποίο βελτιστοποιούνται οι ελεύθεροι παράμετροι του. Έπειτα από τον συντονισμό του ανεξάρτητου αυτού μέτρου στα δεδομένα εισόδου, το δίκτυο αποκτά την δυνατότητα σχηματισμού εσωτερικών αναπαραστάσεων για την κωδικοποίηση των χαρακτηριστικών εισόδου, δημιουργώντας αυτόματα νέες κλάσεις.
- **Ενισχυτική μάθηση (Reinforcement learning).** Στόχος της ενισχυτικής μάθησης είναι η μάθηση μέσω συνεχούς αλληλεπίδρασης με το εξωτερικό περιβάλλον, μιας αντιστοιχίας εισόδου-εξόδου με σκοπό την ελαχιστοποίηση ενός βαθμωτού δείκτη απόδοσης. Η ενισχυτική μάθηση διαφοροποιείται από την επιβλεπόμενη και την μη επιβλεπόμενη μάθηση, μιας και ενώ υπάρχει μιας μορφής επίβλεψης αυτή δεν είναι η συσχέτιση κάθε επιθυμητής εξόδου με την αντίστοιχη είσοδο. Αντιθέτως, οι αλγόριθμοι ενισχυτικής μάθησης λαμβάνουν πληροφορίες από το περιβάλλον αφότου έχουν επιλέξει την έξοδο (η οποία

ονομάζεται δράση) για τα δεδομένα μιας συγκεκριμένης εισόδου. Οι πληροφορίες του εξωτερικού περιβάλλοντος δείχνουν σε πιο βαθμό η έξοδος ικανοποιεί τις απαιτήσεις του περιβάλλοντος.

5.4.2 Βιολογικά Νευρωνικά Δίκτυα


Νευρώνας ή αλλιώς ένα νευρικό κύτταρο ονομάζεται το βιολογικό κύτταρο που έχει την δυνατότητα επεξεργασίας πληροφορίας. Αποτελείται από το κυτταρικό σώμα, τον άξονα και τους δενδρίτες. Το κυτταρικό σώμα με την σειρά του αποτελείται από τον πυρήνα, στον οποίο περιέχονται πληροφορίες σχετικά με τα κληρονομικά χαρακτηριστικά και το πλάσμα το οποίο συγκρατεί τον μοριακό εξοπλισμό για την παραγωγή των απαιτούμενων συστατικών που χρειάζεται ο νευρώνας. Η βασική λειτουργία του νευρώνα είναι η λήψη σημάτων από άλλους νευρώνες μέσω των δενδριτών τους, αλλά και η μετάδοση σημάτων τα οποία παράγονται από το κυτταρικό του σώμα κατά μήκος του άξονα, ο οποίος διακλαδίζεται σε απολήξεις. Στο τέλος των απολήξεων υπάρχουν οι συνάψεις, οι οποίες είναι οι λειτουργικές μονάδες αλληλεπίδρασης μεταξύ δύο νευρώνων. Όταν ένας παλμός φτάσει στο τέλος της σύναψης απελευθερώνεται μια χημική ουσία που ονομάζεται νευροδιαβιβαστής. Οι νευροδιαβιβαστές απελευθερώνονται στο συναπτικό κενό και βελτιώνουν ή καταστέλλουν (ανάλογα με τον τύπο της σύναψης) την δυνατότητα του νευρώνα να εκπέμπει ηλεκτρικούς παλμούς. Η αποτελεσματικότητα της σύναψης έχει την δυνατότητα να μεταβάλλεται ανάλογα με τα σήματα που την διαπερνούν ώστε να μαθαίνει από τις δραστηριότητες που λαμβάνει μέρος. Ενδιαφέρον είναι ακόμα, το γεγονός, ότι σύμφωνα με υπολογισμούς οι νευρώνες του εγκεφάλου είναι πέντε με έξι τάξεις μεγέθους πιο αργοί σε σχέση με τις λογικές πύλες (υλοποιημένες από πυρίτιο) που χρησιμοποιούνται στα σημερινά ολοκληρωμένα κυκλώματα. Το παραπάνω φαινόμενο ωστόσο αντισταθμίζεται λόγω του τεράστιου αριθμού νευρώνων στον ανθρώπινο εγκέφαλο, μιας και υπολογίζεται ότι στον ανθρώπινο εγκεφαλικό φλοιό υπάρχουν 10 δισεκατομμύρια νευρώνες οι οποίοι συνδέονται μεταξύ τους με 60 τρισεκατομμύρια συνάψεις. Η αναπαράσταση ενός νευρώνα αποτυπώνεται στην Εικόνα (5.1):



Εικόνα 5.1-Βιολογικό νευρωνικό δίκτυο

5.4.3 Τεχνητά Νευρωνικά Δίκτυα

Σε αντιστοιχία με τους νευρώνες των βιολογικών νευρωνικών δικτύων μπορούν να δημιουργηθούν τεχνητοί νευρώνες, δηλαδή μονάδες επεξεργασίας πληροφορίας για τον σχηματισμό τεχνητών νευρωνικών δικτύων. Ένα τέτοιο μοντέλο μπορεί να απεικονιστεί όπως στην εικόνα (5.2):



Εικόνα 5.2-Τεχνητό νευρωνικό δίκτυο

Για την ορθή περιγραφή ενός τεχνητού νευρωνικού δικτύου απαιτούνται τρία βασικά στοιχεία :

1. Αρχικά ένα σύνολο συνάψεων (διασυνδέσεων), κάθε μια από τις οποίες χαρακτηρίζεται από ένα δικό της ξεχωριστό βάρος. Παραδείγματος χάρη, ένα σήμα x_j στην είσοδο μιας σύναψης j που συνδέεται με το νευρώνα k θα πρέπει να πολλαπλασιαστεί με το συναπτικό βάρος w_{kj} . Μέσω αυτής της περιγραφής ο πρώτος

δείκτης του βάρους w_{kj} αναφέρεται στον νευρώνα που θέλουμε να περιγράψουμε, ενώ ο δεύτερος στο άκρο εισόδου της σύναψης στην οποία αντιστοιχεί το βάρος. Μια χαρακτηριστική διαφορά μεταξύ των συναπτικών βαρών του βιολογικού και του τεχνητού νευρωνικού δικτύου είναι πως τα πρώτα μπορούν να πάρουν μόνο θετικές τιμές, σε αντίθεση με τα δεύτερα τα οποία έχουν την δυνατότητα να πάρουν και αρνητικές.

2. Έναν αθροιστή (adder), που χρησιμεύει στην άθροιση των σημάτων εισόδου, τα οποία έχουν πρώτα σταθμιστεί ανάλογα με τα συναπτικά βάρη του κάθε νευρώνα.

3. Μια συνάρτηση ενεργοποίησης (activation function), μέσω της οποίας περιορίζεται το πλάτος του σήματος ενός νευρώνα. Η συνάρτηση ενεργοποίησης ονομάζεται και συνάρτηση περιορισμού (squashing function), λόγω του ότι ενεργεί ως περιοριστής του επιτρεπτού εύρους πλάτους του σήματος εξόδου σε κάποια πεπερασμένη τιμή. Συνηθισμένα εύρη πλάτους τιμών της εξόδου ενός νευρώνα είναι διαστήματα όπως $[0, 1]$, $[-1, 1]$.

Τελευταίο χαρακτηριστικό του νευρωνικού δικτύου είναι η εξωτερικά εφαρμοζόμενη πόλωση b_k , που έχει ως στόχο την αύξηση ή μείωση της δικτυακής διέγερσης της συνάρτησης ενεργοποίησης ανάλογα με το αν είναι θετική ή αρνητική.


Μοντελοποιώντας μαθηματικά τα παραπάνω ο νευρώνας k μπορεί να περιγραφεί ως:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (5.30)$$

$$y_k = \varphi(u_k + b_k) \quad (5.31)$$

όπου x_1, x_2, \dots, x_m και $w_{k1}, w_{k2}, \dots, w_{km}$ είναι τα σήματα εισόδου και τα αντίστοιχα συναπτικά βάρη του νευρώνα k . Παρατηρούμε επομένως, πως η έξοδος y_k του νευρωνικού δικτύου είναι το άθροισμα των γινομένων των σημάτων εισόδου επί τα αντίστοιχα βάρη τους και της πόλωσης, αφού πρώτα εισέλθουν από την συνάρτηση ενεργοποίησης.

Οι νευρώνες των νευρωνικών δικτύων ταξινομούνται σε επίπεδα, έτσι ο νευρώνας της εικόνας (5.2) μπορεί να θεωρηθεί ως ένα νευρωνικό δίκτυο ενός επιπέδου. Συνδυάζοντας πολλαπλά επίπεδα, καθένα από τα οποία μπορεί έχει πολλαπλό αριθμό νευρώνων μπορούμε να δημιουργήσουμε ένα πολυεπίπεδο νευρωνικό δίκτυο το οποίο ονομάζεται Multilayer Perceptron (MLP). Ένα τέτοιο δίκτυο απεικονίζεται στην εικόνα (5.3).



Εικόνα 5.3-Πολυεπίπεδο Νευρωνικό Δίκτυο

Ένα πολυεπίπεδο νευρωνικό δίκτυο, αποτελείται από τουλάχιστον τρία επίπεδα με το πρώτο να είναι το επίπεδο εισόδου (Input layer), στο οποίο εισάγουμε ένα διάνυσμα εκπαίδευσης, ένα ή περισσότερα κρυφά επίπεδα (Hidden layer), τα οποία συνδέουν το επίπεδο εισόδου με το επίπεδο εξόδου και ένα επίπεδο εξόδου (Output layer), από το οποίο λαμβάνεται η απόκριση του νευρωνικού δικτύου για το διάνυσμα εκπαίδευσης. Προσθετικά, κάθε νευρώνας με εξαίρεση αυτούς του επιπέδου εισόδου λαμβάνει και μια συνάρτηση ενεργοποίησης, όπως ορίστηκε και στο μοντέλο του απλού νευρώνα. Από την εικόνα (5.3) μπορεί να παρατηρηθεί ακόμα πως κάθε νευρώνας σε οποιοδήποτε επίπεδο συνδέεται με όλους τους άλλους του προηγούμενου επιπέδου, ώστε το νευρωνικό δίκτυο να χαρακτηρίζεται ως πλήρως συνδεδεμένο (fully connected), όπως και ότι η ροή του σήματος έχει κατεύθυνση από τα αριστερά προς τα δεξιά. Λόγω της τελευταίας αυτής ιδιότητάς του νευρωνικού δικτύου ονομάζεται και νευρωνικό δίκτυο εμπρόσθιας τροφοδότησης (Feed-forward neural network).

5.4.4 Συναρτήσεις Ενεργοποίησης


Όπως έχει αναφερθεί, ένας από τους σημαντικότερους παράγοντες κατά την υλοποίηση διαφόρων αρχιτεκτονικών νευρωνικών δικτύων είναι η επιλογή της συνάρτησης ενεργοποίησης. Αντίστοιχα με το μοντέλο του απλού νευρώνα και στα πολυεπίπεδα νευρωνικά δίκτυα αλλά και σε άλλες αρχιτεκτονικές νευρωνικών δικτύων (οι οποίες θα αναλυθούν εκτενώς στην συνέχεια), πρέπει να ορίσουμε την συνάρτηση ενεργοποίησης του κάθε επιπέδου (με εξαίρεση του επιπέδου εισόδου), η οποία θα

καθορίζει το πλάτος εξόδου του σήματος από το κάθε επίπεδο του δικτύου. Οι συχνότερα χρησιμοποιούμενες συναρτήσεις ενεργοποίησης συνοψίζονται παρακάτω:

Συνάρτηση βήματος (Binary Step Function)

Η συνάρτηση βήματος απεικονίζεται στην εικόνα (5.4) και αποτελεί την πιο απλή συνάρτηση ενεργοποίησης. Ουσιαστικά, είναι μία συνάρτηση κατωφλίου threshold function, αφού αν η τιμή εισόδου της είναι πάνω από το κατώφλι που έχει οριστεί η έξοδος παίρνει την τιμή 1, ενεργοποιώντας το νευρώνα, προωθώντας το σήμα στο επόμενο επίπεδο, ενώ σε αντίθετη περίπτωση η έξοδος παίρνει την τιμή 0, αφήνοντας τον νευρώνα απενεργοποιημένο. Λόγω της δυνατότητας της να λαμβάνει μόνο δύο τιμές μπορεί να χρησιμοποιηθεί μόνο για δυαδική ταξινόμηση μη έχοντας την δυνατότητα να ταξινομεί περισσότερες κατηγορίες. Τέλος, επειδή η κλίση (gradient) της συνάρτησης είναι 0 δημιουργεί προβλήματα κατά την εκπαίδευση μέσω του αλγορίθμου Backpropagation που θα αναλυθεί στην συνέχεια. Μαθηματικά η συνάρτηση ορίζεται ως :

$$f(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases} \quad (5.32)$$




Εικόνα 5.4-Συνάρτηση βήματος

Σιγμοειδής συνάρτηση (Sigmoid Function)

Η σιγμοειδής συνάρτηση είναι από τις πιο γνωστές συναρτήσεις ενεργοποίησης, μιας και είναι μία μη γραμμική συνάρτηση. Μετατρέπει το σήμα εισόδου σε μία τιμή με εύρος από το 0 έως το 1 και μπορεί να οριστεί ως :

$$f(x) = \frac{e^x}{e^x + 1} \quad (5.32)$$

Η συγκεκριμένη συνάρτηση είναι μια συνεχής και διαφορίσιμη συνάρτηση, όμως δεν είναι συμμετρική γύρω από το μηδέν, κάτι το οποίο ωστόσο μπορεί να βελτιωθεί μέσω παραμετροποίησής της. Η σιγμοειδής συνάρτηση απεικονίζεται στην εικόνα (5.5).



Εικόνα 5.5-Σιγμοειδής συνάρτηση


Συνάρτηση υπερβολικής εφαπτομένης (Tanh Function)

Η συνάρτηση υπερβολικής εφαπτομένης είναι παρόμοια με την σιγμοειδή συνάρτηση με διαφορά ότι είναι συμμετρική και έχει κέντρο της το μηδέν. Ορίζεται ως :

$$f(x) = \frac{e^{2x} - 1}{e^{2x} + 1}$$

(5.33)

Η συνάρτηση της υπερβολικής εφαπτομένης είναι συνεχής διαφορίσιμη και οι τιμές της κυμαίνονται από το -1 έως το 1. Προτιμάται σε σχέση με την σιγμοειδή συνάρτηση, μιας και η κλίση της (gradient) είναι πιο απότομη και χρησιμοποιείται για εισόδους με έντονες αρνητικές και θετικές τιμές. Η γραφική της παράσταση φαίνεται στην εικόνα (5.6).




Εικόνα 5.6-Συνάρτηση υπερβολικής εφαπτομένης

Συνάρτηση ReLU (Rectifier Linear Unit)

Η συνάρτηση ReLU είναι μια από τις πιο συχνά χρησιμοποιούμενες, μη γραμμική συνάρτηση ενεργοποίησης. Ορίζεται ως :

$$f(x) = \max(x, 0) \quad (5.34)$$

Η ευρεία χρήση της οφείλεται στο ότι είναι πιο αποδοτική από τις υπόλοιπες συναρτήσεις, μιας και δεν ενεργοποιεί ταυτόχρονα όλους τους νευρώνες του δικτύου. Ακόμα, ένας νευρώνας απενεργοποιείται μόνο όταν η έξοδος από την συνάρτηση είναι μικρότερη από το 0. Αυτό δίνει την δυνατότητα στις τιμές της κλίσης της (gradient) να παίρνουν μεγαλύτερες τιμές, αφού όταν είναι μικρότερες από το μηδέν δεν ανανεώνονται, κάτι το οποίο βοηθάει στο να μη παρουσιάζει κορεσμό, σε αντίθεση με την σιγμοειδή συνάρτηση και τη συνάρτηση υπερβολικής εφαπτομένης. Η συνάρτηση ReLU απεικονίζεται στην εικόνα (5.7).



Εικόνα 5.7-Συνάρτηση ReLU

5.4.5 Συνάρτηση Κόστους

Για την αξιολόγηση ενός αλγορίθμου μηχανικής μάθησης θα πρέπει να οριστεί ένα μέτρο της αποτελεσματικότητας του. Για την μέτρηση λοιπόν της επίδοσής του, χρησιμοποιούνται συναρτήσεις που πρέπει να βελτιστοποιήσουμε (να ελαχιστοποιήσουμε ή μεγιστοποιήσουμε), οι οποίες ονομάζονται αντικειμενικές συναρτήσεις (objective functions). Έτσι, η αντικειμενική συνάρτηση σε ένα πρόβλημα ενισχυτικής μάθησης θα είναι η μεγιστοποίηση της συνολικής ανταμοιβής (reward), ενώ σε ένα πρόβλημα παλινδρόμησης η ελαχιστοποίηση του μέσου τετραγωνικού σφάλματος. Επειδή η αντικειμενική συνάρτηση αποτελεί μια γενική έννοια, αναφερόμαστε πιο ειδικά σε αυτή ως συνάρτηση κόστους (cost function) ή συνάρτηση απωλειών (σφάλματος) (loss function (error function)). Η διαφορά μεταξύ των τελευταίων δύο είναι ότι μέσω της συνάρτησης απωλειών αναφερόμαστε σε σφάλμα ενός μόνο παραδείγματος εκπαίδευσης, ενώ μέσω της συνάρτησης κόστους σε όλα τα δεδομένα εκπαίδευσης. Μέσω της συνάρτησης σφάλματος επομένως μετράμε το πόσο καλά αποδίδει ο αλγόριθμός μας στα δεδομένα, αφού το σφάλμα μας βοηθάει να κατανοήσουμε πόσο διαφέρουν οι προβλεπόμενες τιμές από τις κανονικές. Αν οι προβλέψεις μας διαφέρουν πολύ από την πραγματικότητα η συνάρτηση σφάλματος μεγαλώνει, ενώ σε αντίθετη περίπτωση διατηρεί μια μικρή τιμή. Παραμετροποιώντας το μοντέλο μας, η συνάρτηση απωλειών μας βοηθά να κατανοήσουμε αν ο αλγόριθμος μας βελτιώνεται ή όχι. Λόγω των διαφορετικών ειδών προβλημάτων οι συναρτήσεις σφάλματος διαφέρουν μεταξύ τους και χωρίζονται σε αυτές για προβλήματα παλινδρόμησης (regression), όπου προβλέπουμε μια συνεχή τιμή στην έξοδο, δυαδικής ταξινόμησης (Binary Classification), όπου η έξοδος μας μπορεί να πάρει δύο τιμές (0 και 1) και ταξινόμησης πολλών κλάσεων (Multi-Class Classification), όπου μπορούμε να έχουμε πολλές διαφορετικές κατηγορίες που θέλουμε να προβλέψουμε. Παίρνοντας ουσιαστικά το μέσο όρο όλων αυτών των συναρτήσεων, για κάθε δεδομένο εκπαίδευσης δημιουργούμε την συνάρτηση κόστους. Η συνάρτηση κόστους είναι το μέτρο της απόδοσης των αλγορίθμων μηχανικής μάθησης, μιας και υπολογίζει το σφάλμα όλων των προβλεπόμενων τιμών σε σχέση με τις πραγματικές και το ποσοτικοποιεί σε έναν πραγματικό αριθμό. Ανάλογα πάλι με το πρόβλημα που έχουμε να αντιμετωπίσουμε, η συνάρτηση κόστους μπορεί να χρήζει ελαχιστοποίησης ή βελτιστοποίησης. Μια από τις πιο συχνά χρησιμοποιούμενες συναρτήσεις κόστους για προβλήματα παλινδρόμησης είναι αυτή του μέσου τετραγωνικού σφάλματος (Mean

Squared Error), (η οποία πρέπει να ελαχιστοποιηθεί) και μετράει όπως προδίδει και το όνομά της το τετραγωνικό σφάλμα της προβλεπόμενης τιμής $f(x_i|\theta)$ σε σχέση με την αναμενόμενη y_i για όλα τα διαθέσιμα δεδομένα (μεγέθους N) x_i και τις παραμέτρους τους θ . Έτσι υπολογίζεται ως :

$$MSE(\theta) = \frac{1}{N} \sum_{i=1}^N (f(x_i|\theta) - y_i)^2 \quad (5.34)$$

5.4.6 Αλγόριθμος Οπισθοδρόμησης Σφάλματος (Backpropagation)

Ο αλγόριθμος Backpropagation ανακαλυφθηκε το 1986 και είναι ο πιο συχνά χρησιμοποιούμενος αλγόριθμος για την εκπαίδευση νευρωνικών δικτύων πρόσθιας τροφοδότησης. Η λειτουργία του αλγορίθμου αυτού είναι ο υπολογισμός του σφάλματος πρόβλεψης του μοντέλου και η διάδοσή του (propagation), με ταυτόχρονη προσαρμογή των βαρών του νευρωνικού δικτύου, από το τελευταίο επίπεδο του δικτύου προς το πρώτο. Πιο συγκεκριμένα, μέσω του αλγορίθμου Backpropagation υπολογίζεται η κλίση (gradient) της συνάρτησης κόστους του νευρωνικού δικτύου, ως προς το κάθε βάρος του δικτύου κάνοντας χρήση του κανόνα της αλυσίδας (chain rule). Λόγω της μεγάλης του αποτελεσματικότητας, δίνει την δυνατότητα σε μεθόδους κλίσης (gradient methods) να χρησιμοποιηθούν για την εκπαίδευση πολυεπίπεδων νευρωνικών δικτύων μέσω της ανανέωσης των βαρών του δικτύου για την ελαχιστοποίηση του σφάλματος της συνάρτησης κόστους. Θεωρούμε λοιπόν ότι $y_j^{(l)}$ είναι η έξοδος του νευρώνα j στο επίπεδο l , m είναι ο αριθμός των νευρώνων στο επίπεδο $l+1$, σ_l η συνάρτηση ενεργοποίησης του επιπέδου l και

$y_j^{(l)} = \sum_{i=0}^K w_{j,i}^{(l)} y_i^{(l-1)}$, το άθροισμα των εισόδων του νευρώνα j στο επίπεδο l . Για την ανανέωση του κάθε βάρους του νευρωνικού δικτύου, θα πρέπει να υπολογίσουμε την κλίση της συνάρτησης σε σχέση με το βάρος όπου μέσω του αλγορίθμου Backpropagation και κάνοντας χρήση του κανόνα της αλυσίδας ισούται με:

$$\frac{\partial J(\theta)}{\partial w_{j,k}^{(l)}} = \delta_j^{(l)} y_k^{(l-1)} \quad (5.35)$$

όπου αναλόγως αν το επίπεδο l είναι επίπεδο εξόδου ή κρυφό επίπεδο το $\delta_j^{(l)}$ υπολογίζεται ως:

$$\delta_j^{(l)} = \begin{cases} \frac{\partial J(\theta)}{\partial y_j^{(l)}} \sigma'_l z_j^{(l)}, & \text{εάν το } l \text{ είναι επίπεδο εξόδου} \\ \left(\sum_{i=0}^m \delta_j^{(l+1)} w_{i,j}^{(l+1)} \right) \sigma'_l z_j^{(l)}, & \text{εάν το } l \text{ είναι κρυφό επίπεδο} \end{cases} \quad (5.36)$$

Όπως παρατηρούμε από τις εξισώσεις πριν την εκκίνηση του αλγορίθμου Backpropagation πρέπει να προηγηθεί το πρόσθιο πέρασμα ώστε να υπολογιστούν οι τιμές των $z(l)$ και της εξόδου $y(l)$. Στην συνέχεια, υπολογίζονται οι κλίσεις μέσω του αλγορίθμου Backpropagation, ώστε έπειτα μέσω ενός αλγόριθμου βελτιστοποίησης να γίνει η ανανέωση των βαρών. Έτσι, αν ο αλγόριθμος αυτός είναι ο αλγόριθμος κατάβασης κλίσης που είναι ο πιο συχνά χρησιμοποιούμενος (ο οποίος θα αναλυθεί στην συνέχεια) η ανανέωση των βαρών θα έχει την μορφή :


$$w_{j,k}^{(l)} = w_{j,k}^{(l)} - \eta \frac{\partial J(\theta)}{\partial w_{j,k}^{(l)}} \quad (5.37)$$

Αφού ολοκληρωθεί και η ανανέωση των βαρών, μπορεί να ξεκινήσει η επόμενη επανάληψη του αλγορίθμου μέχρι να ικανοποιηθεί ένα κριτήριο τερματισμού, το οποίο θέτουμε και μπορεί να είναι παραδείγματος χάρη ένας μέγιστος αριθμός επαναλήψεων του αλγορίθμου, ή η μείωση της συνάρτησης σφάλματος σε μια αποδεκτή τιμή.

5.4.7 Πρόληψη υπερπροσαρμογής

Κατά την σχεδίαση στατιστικών μοντέλων και μοντέλων μηχανικής μάθησης βασικό μας μέλημα αποτελεί η υλοποίηση μοντέλων που έχουν την δυνατότητα γενίκευσης (Generalisation), δηλαδή έχουν την δυνατότητα να κάνουν ορθές προβλέψεις για δεδομένα που δεν έχουν δει στο παρελθόν. Τα μοντέλα μηχανικής μάθησης εκπαιδεύονται μέσω δεδομένων εκπαίδευσης και η απόδοσή τους ελέγχεται σε δεδομένα που δεν έχουν ξαναδεί, τα οποία αποτελούν τα δεδομένα ελέγχου. Ένα καλό μοντέλο μηχανικής μάθησης παρουσιάζει παρόμοια συμπεριφορά προβλέποντας με υψηλή ακρίβεια και τα δεδομένα εκπαίδευσης, αλλά και τα άγνωστα για αυτό δεδομένα ελέγχου. Σε αυτή την περίπτωση, θεωρούμε ότι το μοντέλο έχει την δυνατότητα γενίκευσης της πληροφορίας που έμαθε και μπορεί να την εφαρμόσει σε άγνωστα για

αυτό δεδομένα. Παρόλα αυτά, η απόκριση των μοντέλων μηχανικής μάθησης δεν είναι πάντα η επιθυμητή. Μια από τις πιθανές καταστάσεις είναι η υποπροσαρμογή (underfitting) του μοντέλου μας. Αυτό σημαίνει, πως το μοντέλο μας παρουσιάζει χαμηλή ακρίβεια κατά την δημιουργία προβλέψεων και στα δεδομένα εκπαίδευσης αλλά και στα δεδομένα ελέγχου. Κάτι τέτοιο συμβαίνει όταν οι αλγόριθμοι που χρησιμοποιούνται για την δημιουργία του μοντέλου είναι απλοί, με αποτέλεσμα να μην μπορεί να μάθει σύνθετες αναπαραστάσεις. Ένα παράδειγμα είναι η χρήση γραμμικών μοντέλων για την πρόβλεψη μη γραμμικών δεδομένων, αφού σε αυτή την περίπτωση το μοντέλο υπεραπλουστεύει τα δεδομένα κάνοντας λανθασμένες υποθέσεις για αυτά, αφού δεν μπορεί να διαχειριστεί τις μη γραμμικές σχέσεις μεταξύ των δεδομένων εισόδου και εξόδου, με αποτέλεσμα να παρουσιάζει μεγάλα σφάλματα. Πρέπει ωστόσο να επισημάνουμε σε αυτό το σημείο, ότι με την ανάπτυξη των αλγορίθμων μηχανικής μάθησης και λόγω της βαθιάς μάθησης μέσω νευρωνικών δικτύων πιο συχνό πρόβλημα αποτελεί η υπερπροσαρμογή (overfitting) των μοντέλων. Όταν ένα μοντέλο παρουσιάζει υπερπροσαρμογή σημαίνει πως εμφανίζει πολύ μεγάλη ακρίβεια στην πρόβλεψη των δεδομένων εισόδου, αλλά πολύ μικρότερη στα δεδομένα ελέγχου. Αυτό έχει ως αποτέλεσμα το μοντέλο να χάνει την δυνατότητα γενίκευσης, αφού δεν μπορεί να γενικεύσει τις πληροφορίες που έμαθε κατά την εκπαίδευση στα δεδομένα ελέγχου. Η υπερπροσαρμογή παρουσιάζεται όταν οι αλγόριθμοι που χρησιμοποιούνται είναι πολύ πολύπλοκοι και επηρεάζονται έντονα από τα δεδομένα εκπαίδευσης μαθαίνοντας λεπτομέρειες των μοτίβων που τους παρουσιάζονται, οι οποίες περιέχουν θόρυβο μη μπορώντας να τις γενικεύσουν. Έτσι λοιπόν, τα μοντέλα καταλήγουν να μαθαίνουν τον τυχαίο θόρυβο των δεδομένων εκπαίδευσης αντί να εστιάζουν στην ουσιαστική και γενικευμένη πληροφορία. Όσα περιγράψαμε μέχρι στιγμής μπορούν να παρατηρηθούν και οπτικά μέσω της εικόνας (5.8).



Εικόνα 5.8-Δυνατές προσαρμογές μοντέλων μηχανικής μάθησης

Λόγω της ραγδαίας αύξησης στην χρήση μοντέλων βαθιάς μάθησης, τα φαινόμενα υπερπροσαρμογής έχουν γίνει όλο και πιο συχνά. Έτσι λοιπόν, έχουν αναπτυχθεί στρατηγικές μερικές από τις οποίες χρησιμοποιούνται για την μείωση του σφάλματος ελέγχου και την εξάλειψη των φαινομένων υπερπροσαρμογής, και θα περιγράψουμε στην συνέχεια :


Εγκατάλειψη (Dropout)

Η εγκατάλειψη (Dropout), είναι μια από τις πιο συχνά χρησιμοποιούμενες τεχνικές ομαλοποίησης. Μέσω αυτής της τεχνικής, κατά την φάση της εκπαίδευσης επιλέγονται με τυχαίο τρόπο κάποιες μονάδες (νευρώνες) από το σύνολό τους, οι οποίες αγνοούνται. Έτσι, κατά τα το πρόσθιο και το οπίσθιο πέρασμα του νευρωνικού αυτές οι μονάδες δε λαμβάνονται υπόψη. Αναλυτικότερα, σε κάθε στάδιο εκπαίδευσης ένα ποσοστό p μεμονωμένων κόμβων επιλέγεται να διατηρηθεί κατά την εκπαίδευση, ενώ το υπόλοιπο $1-p$ αφαιρείται μειώνοντας έτσι τον αριθμό των παραμέτρων του δικτύου. Κατά αυτόν τον τρόπο κάθε επανάληψη αποτελείται από ένα διαφορετικό σετ κόμβων, γεγονός που βοηθάει στην μείωση της υπερπροσαρμογής.

Early Stopping

Κατά την εκπαίδευση των μοντέλων βαθιάς μάθησης, συνηθίζεται να παρατηρούμε τις καμπύλες που δημιουργούνται από την πορεία της συνάρτησης σφάλματος σε κάθε στάδιο της εκπαίδευσης. Για τον έλεγχο αυτό υπολογίζουμε το σφάλμα στα δεδομένα εκπαίδευσης, αλλά και στα δεδομένα επαλήθευσης (τα οποία διαφέρουν από αυτά του ελέγχου) που επιλέγονται ως ένα ποσοστό των δεδομένα εκπαίδευσης και δεν λαμβάνουν μέρος στην διαδικασία της εκπαίδευσης, αλλά χρησιμοποιούνται ως μια πιο αντικειμενική ένδειξη του σφάλματος έπειτα από κάθε στάδιο εκπαίδευσης. Ένα μοντέλο θεωρούμε ότι υπερπροσαρμόζεται στα δεδομένα εκπαίδευσης, όταν ενώ το σφάλμα σε αυτά μειώνεται σε κάθε στάδιο της εκπαίδευσης, το σφάλμα στα δεδομένα επαλήθευσης τα οποία είναι ουσιαστικά άγνωστα για το μοντέλο μειώνεται μέχρι ένα σημείο και στην συνέχεια αυξάνεται. Για την αποφυγή της υπερπροσαρμογής, η εκπαίδευση πρέπει να τερματίζεται όταν το σφάλμα στα δεδομένα επαλήθευσης αρχίζει να αυξάνεται, κάτι το οποίο επιτυγχάνεται με το Early Stopping, το οποίο αποθηκεύει τις βέλτιστες παραμέτρους με το μικρότερο σφάλμα επαλήθευσης. Το Early Stopping έχει ακόμα ως παράμετρο την patience, μέσω της οποίας ορίζουμε τον αριθμό των εποχών που θα περιμένει το Early Stopping χωρίς να βλέπει περαιτέρω

βελτίωση στα δεδομένα επαλήθευσης, μιας και στην πραγματικότητα η καμπύλη αυτών δεν είναι ομαλή αλλά έχει διακυμάνσεις. Τα γραφήματα των σφαλμάτων αλλά και το βέλτιστο σημείο τερματισμού της εκπαίδευσης φαίνονται στην εικόνα (5.9):



Εικόνα 5.9-Βέλτιστο σημείο διακοπής μάθησης

5.4.8 Αλγόριθμοι Βελτιστοποίησης

Οι αλγόριθμοι βελτιστοποίησης αποτελούν ένα σημαντικό κομμάτι κατά την δημιουργία συστημάτων μηχανικής μάθησης. Χρησιμοποιούνται για την αλλαγή των βαρών του νευρωνικού δικτύου και ρόλος τους είναι η ελαχιστοποίηση (μεγιστοποίηση) της συνάρτησης στόχου που έχει οριστεί για το σύστημα. Ένας από τους πιο συχνά χρησιμοποιούμενους αλγόριθμους βελτιστοποίησης είναι ο αλγόριθμος κατάβασης κλίσης, ο οποίος χρησιμοποιείται για την ελαχιστοποίηση της συνάρτησης σφάλματος. Παρακάτω θα περιγραφούν οι πιο βασικοί αλγόριθμοι βελτιστοποίησης.


Κατάβασης κλίσης (Gradient Descent)

Ο αλγόριθμος κατάβασης κλίσης χρησιμοποιείται για την ελαχιστοποίηση μιας συνάρτησης $J(\theta)$, αντιπροσωπεύει το διάνυσμα των παραμέτρων του δικτύου. Ανήκει στην οικογένεια των αλγορίθμων βελτιστοποίησης πρώτης τάξης (first-order optimization algorithms), δηλαδή κάνει χρήση μόνο των πρώτων παραγώγων για την ανανέωση των παραμέτρων. Ο τρόπος με τον οποίο ελαχιστοποιεί την συνάρτηση κόστους, είναι μέσω ανανέωσης των παραμέτρων προς την αντίθετη κατεύθυνση από

αυτή της κλίσης (gradient) της συνάρτησης κόστους $\nabla_{\theta} J(\theta)$. Η ανανέωση των παραμέτρων μπορεί να περιγραφεί μέσω της εξίσωσης :

$$\theta = \theta - \eta \nabla_{\theta} J(\theta) \quad (5.38)$$

Στην παραπάνω εξίσωση το η δηλώνει το ρυθμό μάθησης (learning rate), δηλαδή το μέγεθος του βήματος που κάνει ο αλγόριθμος για να φτάσει στο ελάχιστο. Πιο συγκεκριμένα, ο αλγόριθμος κατάβασης κλίσης ακολουθεί την κατεύθυνση της καμπύλης που δημιουργείται από την αντικειμενική συνάρτηση με κατηφορικό τρόπο έως ότου φτάσει στο ελάχιστο.



Εικόνα 5.10-Βελτιστοποίηση συνάρτησης μέσω αλγορίθμου κατάβασης κλίσης

Adagrad

Ο Adagrad είναι ακόμα ένας αλγόριθμος βασισμένος στην κλίση (gradient-based algorithm). Χαρακτηριστικό του αποτελεί, ότι προσαρμόζει το ρυθμό μάθησης στις παραμέτρους του, με αποτέλεσμα να εκτελεί μεγαλύτερες ανανεώσεις για μη συχνές παραμέτρους και μικρότερες για πιο συχνές παραμέτρους. Αυτή του η ιδιότητα, τον κάνει ιδανικό για διαχείριση αραιών δεδομένων. Σε αντίθεση λοιπόν με τον αλγόριθμο κατάβασης κλίσης, που πραγματοποιεί την ανανέωση των παραμέτρων του θ με τον ίδιο ρυθμό η , στον αλγόριθμο Adagrad, χρησιμοποιείται διαφορετικός ρυθμός μάθησης για κάθε παράμετρο θ_i σε κάθε χρονική στιγμή t . Μια από τις αδυναμίες του αλγορίθμου αυτού αποτελεί η συσσώρευση των τετραγώνων των κλίσεων στον παρονομαστή, αφού οι όροι που προστίθενται είναι πάντα θετικοί, ώστε ο ρυθμός μάθησης να μικραίνει και να φτάνει σε σημείο να μη μπορεί να μάθει περαιτέρω πληροφορίες.

Adadelta

Ο αλγόριθμος Adadelta είναι μια προέκταση του αλγορίθμου Adagrad, με στόχο να βελτίωση αυτή την μόνιμη μείωση του ρυθμού μάθησης. Η διαφορά τους έγκειται στο ότι ο Adadelta χρησιμοποιεί ένα παράθυρο περιορισμού μήκους w για την συσσώρευση των παρελθοντικών κλίσεων. Για το παράθυρό αυτό επομένως, ο αλγόριθμος υπολογίζει αναδρομικά το άθροισμα των κλίσεων ως μέσο όρο των προηγούμενων κλίσεων, με αποτέλεσμα ο μέσος όρος σε μια χρονική στιγμή t να εξαρτάται από το προηγούμενο μέσο όρο και την κλίση σε αυτή τη χρονική στιγμή.

RMSprop

Ο αλγόριθμος RMSprop είναι ένας αλγόριθμος προσαρμοστικής μάθησης που προτάθηκε από τον Geoff Hinton. Και αυτός αναπτύχθηκε ώστε να προσφέρει λύση στο πρόβλημα του αλγορίθμου Adagrad, σχετικά με την εκμηδένιση του ρυθμού μάθησης.

Ο RMSprop επίσης διαιρεί τον ρυθμό μάθησης με τον εκθετικά μειούμενο μέσο όρο των τετραγώνων των κλίσεων. Ο Geoff Hinton προτείνει η τιμή του γ να είναι 0.9, ενώ μια καλή αρχική τιμή του ρυθμού μάθησης είναι 0.001.

Adam

Ο αλγόριθμος Adaptive Moment Estimation (Adam), είναι ένας ακόμα αλγόριθμος ο οποίος χρησιμοποιεί προσαρμοσμένους ρυθμούς μάθησης για κάθε παράμετρό του. Εκτός όμως από την αποθήκευση του εκθετικά μειούμενου μέσου όρου των παρελθοντικών τετραγώνων των κλίσεων, αποθηκεύει και τον εκθετικά μειούμενο μέσο όρο των παρελθοντικών κλίσεων m_t αντίστοιχα με την προσθήκη της ορμής *momentum* που έχει προηγουμένως αναλυθεί :

$$\begin{aligned}m_t &= \beta_1 m_{t-1} + (1 - \beta_1) g_t \\u_t &= \beta_2 u_{t-1} + (1 - \beta_2) g_t^2\end{aligned}$$

(5.39)


όπου τα m_t και u_t είναι εκτιμήσεις της πρώτης ορμής (μέσου) και της δεύτερης ορμής (μη κεντραρισμένη απόκλιση) των κλίσεων. Λόγω του ότι τα m_t και u_t αρχικοποιούνται ως πίνακες μηδενικών, παρατηρήθηκε ότι είναι μεροληπτικά γύρω

από αυτή την περιοχή, κυρίως κατά τις αρχικές χρονικές στιγμές. Για την εξάλειψη αυτής της μεροληψίας εκτιμητές του πρώτου και του δεύτερου όρου :

$$\widehat{m}_t = \frac{m_t}{1-\beta_1^t} \quad , \quad \widehat{u}_t = \frac{u_t}{1-\beta_2^t} \quad (5.40)$$

5.4.9 Αναδρομικά Νευρωνικά Δίκτυα

Τα αναδρομικά νευρωνικά δίκτυα χαρακτηρίζονται από εσωτερικές συνδέσεις, οι οποίες επιτρέπουν την επεξεργασία χρονικών συσχετίσεων. Όταν τα αναδρομικά νευρωνικά δίκτυα επεξεργάζονται σειριακές πληροφορίες, πραγματοποιούν τις ίδιες μετατροπές και διαδικασίες σε κάθε στοιχείο της σειριακής εισόδου. Η έξοδος των RNN σε κάθε χρονικό βήμα εξαρτάται από την προηγούμενη είσοδο και τους προηγούμενους υπολογισμούς του νευρωνικού δικτύου. Ως συνέπεια, το RNN ενσωματώνει παρελθοντικές πληροφορίες μαζί με πληροφορίες της κάθε εισόδου ώστε να προβλέψει μελλοντικές τιμές. Αυτή η διαδικασία επιτρέπει στο νευρωνικό δίκτυο να σχηματίζει μνήμη των προηγούμενων δεδομένων, την οποία κωδικοποιεί στις μεταβλητές του κρυμμένου επιπέδου (hidden state) του. Λόγω της σειριακής επεξεργασίας δεδομένων τα αναδρομικά νευρωνικά δίκτυα θεωρούνται κατάλληλα για την επεξεργασία χρονοσειρών και άλλων ακολουθιακών δεδομένων. Η απεικόνιση ενός ‘ξεδιπλωμένου’ αναδρομικού δικτύου παρουσιάζεται στην εικόνα (5.11).




Εικόνα 5.11-Αναδρομικό νευρωνικό δίκτυο RNN

Παρά την κατάλληλη αρχιτεκτονική τους, για τον χειρισμό ακολουθιακών δεδομένων, παρατηρείται ότι τα RNN νευρωνικά δίκτυα εμφανίζουν προβλήματα στην διαχείριση μεγάλου μήκους ακολουθιακών εισόδων. Αιτία του προβλήματος αποτελεί η εξαφάνιση κλίσεων (vanishing gradients), δηλαδή η μείωση των κλίσεων σε πολύ

μικρές τιμές που έχουν ως αποτέλεσμα την πρακτικά μηδενική ανανέωση των βαρών. Κάτι τέτοιο μπορεί να εξηγηθεί λόγω του ότι τα αναδρομικά νευρωνικά δίκτυα για τον υπολογισμό των κλίσεων τους δεν βασίζονται στον αλγόριθμο Backpropagation, αλλά σε μια παραλλαγή του που ονομάζεται Backpropagation through time (BPTT).

5.4.10 Νευρωνικό Δίκτυο Μακράς-Βραχείας Μνήμης (LSTM)


Για την επίλυση των παραπάνω προβλημάτων, αναπτύχθηκε το νευρωνικό δίκτυο μακράς- βραχείας μνήμης LSTM το 1997 από τους Hochreiter και Schmidhuber. Η βασική ιδέα πίσω από την δημιουργία του ήταν η ανάγκη αποφυγής των προβλημάτων στην επεξεργασία μεγάλου μήκους εξαρτήσεων και την απόκτηση μνήμης για μεγάλες περιόδους. Ενώ η επαναλαμβανόμενη μονάδα του LSTM ακολουθεί την αναδρομική αρχιτεκτονική του RNN, η εσωτερική της δομή που φαίνεται στην εικόνα (5.12) είναι αρκετά πιο περίπλοκη.



Εικόνα 5.12-Κρυφό κύτταρο LSTM

Λόγω της σημαντικότητας του μοντέλου αλλά και της πολυπλοκότητας του, θα αναλυθεί ακριβώς η αρχιτεκτονική του κρυφού του επιπέδου, το οποίο αποτελείται από το κύτταρο cell και τρεις πύλες (gates), οι οποίες ελέγχουν την ροή της πληροφορίας στην μονάδα του LSTM και ονομάζονται πύλη εισόδου (input gate), πύλη εξόδου (output gate), πύλη λυσμόνησης (forget gate).

Για να ξεκινήσουμε την πιο λεπτομερή περιγραφή, πρέπει να επισημάνθει πως ένα κύτταρο LSTM διατρέχεται κατά μήκος του από την δομή της κυτταρικής κατάστασης (cell state) που φαίνεται στην εικόνα (5.13).



Εικόνα 5.13-Κυτταρική κατάσταση LSTM


Το cell state, είναι υπεύθυνο για την μεταφορά της πληροφορίας από τον έναν κόμβο της αλυσίδας στο επόμενο. Το κύτταρο του LSTM έχει την δυνατότητα να προσθέτει και να αφαιρεί πληροφορίες στην κυτταρική κατάσταση μέσω των πυλών που αναφέρθηκαν ονομαστικά. Έτσι, κατά το πρώτο βήμα της επεξεργασίας η πύλη λησμόνησης κοιτάει την προηγούμενη κρυφή κατάσταση h_{t-1} και την είσοδο x_t την χρονική στιγμή t και δίνει σαν έξοδο έναν αριθμό ανάμεσα στην 0 και το 1 για κάθε αριθμό στην κυτταρική κατάσταση C_{t-1} . Ο αριθμός αυτός, δηλώνει το ποσοστό της πληροφορίας που πρέπει να περάσει στο επόμενο στάδιο, με το 0 να δηλώνει το να μην περάσει καθόλου η προηγούμενη πληροφορία και το 1 να σημαίνει να περάσει χωρίς καμία αλλαγή. Η έξοδος του πρώτου σταδίου είναι περιορισμένη στις τιμές 0 και 1 μιας και το αποτέλεσμα των h_{t-1} και x_t της πύλης λυσμόνησης περνάει από μια σιγμοειδή συνάρτηση για τον περιορισμό του. Η συνάρτηση που περιγράφει το πρώτο στάδιο της επεξεργασίας είναι:

$$f_t = \sigma (W_f [h_{t-1}, x_t] + b_f) \quad (5.41)$$

Το επόμενο βήμα σχετίζεται με την επιλογή της καινούργιας πληροφορίας θα αποθηκεύσουμε στην κυτταρική κατάσταση. Το βήμα αυτό χωρίζεται σε δυο επιμέρους καταστάσεις, όπου αρχικά ένα σιγμοειδές επίπεδο το οποίο ονομάζεται επίπεδο εισόδου, αποφασίζει ποιες τιμές θα ανανεώσουμε. Στην συνέχεια ένα επίπεδο υπερβολικής εφαπτομένης σχηματίζει έναν πίνακα των καινούργιων υποψηφίων τιμών C_t , που θα μπορούσαν να προστεθούν στην κυτταρική κατάσταση. Έπειτα, συνδυάζονται οι δυο παραπάνω διαδικασίες, ώστε να υλοποιήσουμε την ανανέωση της κυτταρικής κατάστασης. Το δεύτερο στάδιο απεικονίζεται στην εικόνα (5.14) και περιγράφεται από τις εξισώσεις :

$$i_t = \sigma (W_i [h_{t-1}, x_t] + b_i) \quad (5.42)$$


$$C_t = \tanh (W_C [h_{t-1}, x_t] + b_C) \quad (5.43)$$



Εικόνα 5.14-Πύλη εισόδου

Πλέον, πρέπει να ανανεώσουμε την παλιά κυτταρική κατάσταση C_{t-1} στην καινούργια C_t . Έτσι, πολλαπλασιάζουμε την παλιά κατάσταση με την πύλη λησμόνησης f_t , ώστε να ξεχάσει η παλιά κατάσταση τις πληροφορίες που έχουμε επιλέξει, ενώ ακόμα προσθέτουμε στην παλιά κατάσταση την υποψήφια καινούργια $i_t * C_t$, προσαρμοσμένη κατάλληλα μέσω του όρου i_t . Η απεικόνιση της νέας κυτταρικής κατάστασης φαίνεται στην εικόνα (5.15) και περιγράφεται ως :

$$C_t = f_t C_{t-1} + i_t \hat{C}_t$$




Εικόνα 5.15-Νέα κυτταρική κατάσταση

Τελευταίο βήμα στην επεξεργασία των πληροφοριών στο κύτταρο του LSTM, αποτελεί η απόφαση της εξόδου του. Η έξοδος θα βασιστεί σε μια φιλτραρισμένη εκδοχή της κυτταρικής κατάστασης. Πιο συγκεκριμένα, αρχικά χρησιμοποιούμε ένα σιγμοειδές επίπεδο το οποίο αποφασίζει από ποια κομμάτια θα αποτελείται η έξοδος. Στην συνέχεια, περνάμε την κυτταρική κατάσταση από ένα επίπεδο υπερβολικής εφαπτομένης, ώστε να περιορίσουμε τις τιμές ανάμεσα στο -1 και το 1 και την πολλαπλασιάζουμε με το σιγμοειδές επίπεδο, ώστε τελικά να αφήσουμε στην έξοδο μόνο το κομμάτι το οποίο επιθυμούμε. Η τελική αυτή διαδικασία φαίνεται στην εικόνα (5.16) και μαθηματικά περιγράφεται ως :

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (5.44)$$


$$h_t = o_t \tanh(C_t) \quad (5.45)$$



Εικόνα 5.16-Εξοδος κυττάρου LSTM

5.4.11 Νευρωνικό δίκτυο μακράς-βραχείας μνήμης διπλής κατεύθυνσης (Bidirectional-LSTM)

Το Bidirectional-LSTM νευρωνικό δίκτυο, αποτελεί μια πιο εμπλουτισμένη εκδοχή του απλού LSTM δικτύου. Η αρχιτεκτονική του αποτελείται ουσιαστικά από τον διπλασιασμό του απλού LSTM, όπως φαίνεται και από την εικόνα (5.17). Παρατηρούμε ότι το διάνυσμα εισόδου παρουσιάζεται μία φορά με με την κανονική χρονική ακολουθία και μια με την ανάποδη. Μετά την επεξεργασία του κάθε επιπεδου, οι έξοδοι ενώνονται για κάθε χρονική στιγμή. Λόγω της συγκεκριμένης αρχιτεκτονικής λοιπόν, επιτρέπεται στο δίκτυο να επεξεργαστεί τα ακολουθιακά δεδομένα προς δυο κατευθύνσεις κάτι το οποίο αποδεικνύεται ότι σε ορισμένες περιπτώσεις βελτιώνει σημαντικά τα αποτελέσματα σε σχέση με το παραδοσιακό LSTM.



Εικόνα 5.17-Bidirectional LSTM

5.5 Μέθοδος K-Πλησιέστερων Γειτόνων (K-Nearest Neighbors)

Ο αλγόριθμος K-Κοντινότερων Γειτόνων (K-NN) είναι μια μέθοδος που χρησιμοποιείται κυρίως για ταξινόμηση αλλά βρίσκει χρήση και σε προβλήματα παλινδρόμησης. Πρόκειται για μη-παραμετροποιημένη μέθοδο μάθησης αφού δεν κάνει καμία υπόθεση για την κατανομή των δεδομένων και είναι επίσης σκληρή (lazy) αφού χρησιμοποιεί όλα τα δεδομένα για την ταξινόμηση νέων δειγμάτων.

Χρησιμοποιείται τόσο για ταξινόμηση δεδομένων όσο και για παλινδρόμηση. Και στις δύο περιπτώσεις η έξοδος επιλέγεται ως η κλάση των k πιο κοντινών δειγμάτων εκπαίδευσης στο σύνολο δεδομένων. Ο υπολογισμός της απόστασης του νέου σημείου πρέπει να γίνει ως προς όλα τα άλλα σημεία του συνόλου δεδομένων ώστε να βρεθούν οι κοντινότεροι γείτονες. Υπάρχει λοιπόν η περίπτωση, τα χαρακτηριστικά των δεδομένων να έχουν διαφορετική κατανομή και συνεπώς να δίνεται μεγαλύτερη σημασία σε κάποια έναντι άλλων, με αποτέλεσμα η κανονικοποίηση των χαρακτηριστικών των δεδομένων να αυξήσει την ακρίβεια δραματικά. Επιπροσθέτως για να αποφύγουμε τις ισοψηφίες συνήθως επιλέγεται μονή τιμή για το k . Η επιλογή της βέλτιστης τιμής για το k είναι εξαρτώμενη των δεδομένων και η αύξηση της μπορεί να μειώσει την επίδραση του θορύβου αλλά κάνει τα όρια επιλογής λιγότερο διακριτά, μιας και η κλάση με τα περισσότερα δείγματα θα υπερισχύει.

Η μέθοδος του κοντινότερου γείτονα είναι μια γενική μέθοδος με εφαρμογές στην κατασκευή μοντέλων πρόβλεψης νέων τιμών που μπορεί να χρησιμοποιηθούν και για την κατάταξη παρατηρήσεων. Η βασική ιδέα είναι πως αν θέλουμε να προβλέψουμε την τιμή μιας καινούριας παρατήρησης x χρησιμοποιώντας το ήδη υπάρχον δείγμα για να προβλέψουμε μια άλλη μεταβλητή y , τότε χρησιμοποιούμε για την πρόβλεψη μιας την πληροφορία που περιέχουν οι τιμές του δείγματος που μοιάζουν περισσότερο με τη νέα παρατήρηση για την οποία θέλουμε να κάνουμε πρόβλεψη. Η εκτίμηση αυτή δίνεται ως:

$$\hat{y} = \frac{1}{K} \sum_{xi \in N_k(x)} y_i \quad (5.46)$$

όπου $N_k(x)$ είναι το σύνολο που περιέχει τις k πιο κοντινές παρατηρήσεις στο x για

το οποίο θέλουμε να κάνουμε πρόβλεψη. Δηλαδή βρίσκουμε ποιες παρατηρήσεις είναι πιο κοντά στην τιμή που θέλουμε να κάνουμε πρόβλεψη και προβλέπουμε παίρνοντας το μέσο όρο των τιμών των κοντινότερων παρατηρήσεων.

Η παραπάνω ιδέα έχει ως παραμέτρους αφενός τη τιμή του k , δηλαδή του αριθμού των πιο κοντινών με το x παρατηρήσεων και αφετέρου κάποια απόσταση την οποία χρησιμοποιούμε για να βρούμε τις κοντινότερες παρατηρήσεις. Και για τα δύο αυτά χαρακτηριστικά τίθεται το θέμα της επιλογής τους. Υπάρχουν τρόποι να διαλέξουμε το βέλτιστο k , η απόσταση που θα χρησιμοποιήσουμε εξαρτάται από τη φύση του προβλήματος. Σε όλες τις κοντινές παρατηρήσεις ουσιαστικά δίνουμε το ίδιο βάρος.

Ο αλγόριθμος αυτός, κατηγοριοποιεί ένα στοιχείο σε σχέση με τους k κοντινότερους γείτονές του. Αυτό γίνεται με την ιδέα πως, κάθε στοιχείο έχει παρόμοιες ιδιότητες με τα γειτονικά του στοιχεία. Στην παλινδρόμηση, αντί να δίνει κατηγορία στο στοιχείο δίνει μια τιμή ίση με τον μέσο όρο των τιμών των k κοντινότερων γειτόνων του. Ένας τρόπος για να βρεθούν οι κοντινότεροι γείτονες, είναι ο υπολογισμός της Ευκλείδειας Απόστασης του σημείου προς ταξινόμηση με τα υπόλοιπα του συνόλου.

Ευκλείδεια Απόσταση:

$$D(x, y) = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_n - y_n)^2} \quad (5.47)$$

όπου, x και y είναι δύο σημεία στον n -διάστατο Ευκλείδειο χώρο.

Ο αλγόριθμος k -κοντινότερων γειτόνων, είναι αρκετά απλός στη χρήση και την κατανόηση, και προτείνεται για αρχικά πειράματα. Το γεγονός όμως ότι δε δίνει καλά αποτελέσματα για dataset με μεγάλο αριθμό attributes, τον κάνει κατάλληλο για αυτό το πείραμα δεδομένου ότι έχουμε να κάνουμε με μια μονάχα χρονοσειρά εισροών.

5.6 Μέτρα αξιολόγησης Προβλέψεων

Στην αξιολόγηση της επίδοσης μιας μεθόδου πρόβλεψης θεμελιώδους σημασίας είναι η χρήση τεχνικών οπτικοποίησης των προβλέψεων σε σχέση με τις αντίστοιχες παρατηρημένες τιμές. Τέτοιες τεχνικές μπορούν να υποστηρίξουν ποιοτικές κατανοήσεις, ωστόσο δεν προσφέρονται για μαζική αξιολόγηση, η οποία είναι πολλές φορές απαραίτητη, ούτε μπορούν να αποτελέσουν την βάση κάποιας αντικειμενικής κρίσης. Τα συγκεκριμένα ζητούμενα μπορεί να εξασφαλίσει η χρήση

μέτρων - μαθηματικών εργαλείων που ποσοτικοποιούν την εξεταζόμενη επίδοση. Στην βιβλιογραφία προτείνονται πολλά τέτοια μέτρα, καθένα από τα οποία δίνει έμφαση σε συγκεκριμένη ιδιότητα από τις επιθυμητές για τις μεθόδους πρόβλεψης και με τη σειρά του χαρακτηρίζεται από ορισμένα πλεονεκτήματα και μειονεκτήματα.

Στην τρέχουσα ενότητα ορίζονται τα μέτρα που χρησιμοποιούνται για την σύγκριση των μεθόδων πρόβλεψης πάνω στα δεδομένα της εργασίας, δηλαδή στις συνθετικές και τις ιστορικές χρονοσειρές. Η διαφορετική πληροφορία που φέρει το καθένα από αυτά τα μέτρα για την επίδοση των μεθόδων εξηγείται επίσης στις παραγράφους που ακολουθούν. Σημαντικό στοιχείο είναι ότι στο πλαίσιο της εργασίας οι τιμές που λαμβάνουν τα μέτρα δεν χρησιμοποιούνται για απόλυτη αξιολόγηση εκάστης των μεθόδων, παρά μόνο για την συναξιολόγηση αυτών (βλ. Papacharalampous, Tyralis and Koutsoyiannis, 2018). Για τον ορισμό των μέτρων θεωρείται μία χρονοσειρά N παρατηρήσεων. Έστω επίσης ότι προσαρμόζεται ένα μοντέλο στις $N - n$ πρώτες παρατηρήσεις της με σκοπό πρόβλεψη των τιμών των τελευταίων n παρατηρήσεων, έστω x_1, x_2, \dots, x_n . Έστω τέλος ότι οι προβλέψεις που προκύπτουν είναι οι f_1, f_2, \dots, f_n .

5.6.1 Μέσο Σφάλμα (Mean Error)

Το μέτρο Mean Error (ME) ορίζεται με την εξ. (5.48).

$$ME = \frac{1}{n} \sum_{i=1}^n (f_i - x_i) \quad (5.48)$$

Το συγκεκριμένο μέτρο ενδείκνυται για την αξιολόγηση μίας μεθόδου πρόβλεψης ως προς την ιδιότητα της αμεροληψίας.

5.6.2 Μέσο Απόλυτο Σφάλμα (Mean Absolute Error)

Το μέτρο Mean Absolute Error (MAE) ορίζεται με την εξ. (5.49).

$$MAE = \frac{1}{n} \sum_{i=1}^n |f_i - x_i| \quad (5.49)$$

Το συγκεκριμένο μέτρο μπορεί να χρησιμοποιηθεί για την αξιολόγηση μίας μεθόδου πρόβλεψης ως προς την ακρίβεια που προσφέρει. Ωστόσο, επειδή οι τιμές που λαμβάνει εξαρτώνται από την κλίμακα στην οποία αυτές έχουν μετρηθεί, το εν λόγω μέτρο δεν μπορεί να υποστηρίξει την σύγκριση της επίδοσης μιας μεθόδου πάνω σε διαφορετικά σύνολα δεδομένων.

5.6.3 Μέσο Ποσοστιαίο Σφάλμα (Mean Percentage Error)

Το μέτρο Mean Percentage Error (MPE) ορίζεται με την εξ. (5.50).

$$MPE = \frac{1}{n} \sum_{i=1}^n \frac{(f_i - x_i)}{x_i} 100 \quad (5.50)$$

Το συγκεκριμένο μέτρο έχει την ίδια χρησιμότητα με το ME, παρέχοντας επίσης τη δυνατότητα σύγκρισης της επίδοσης μιας μεθόδου πάνω σε διαφορετικά σύνολα δεδομένων, λόγω της αδιαστατοποίησης που λαμβάνει χώρα κατά τον υπολογισμό του.

5.6.4 Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (Mean Absolute Percentage Error)

Το μέτρο Mean Absolute Percentage Error (MAPE) ορίζεται με την εξ. (5.51).

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{(f_i - x_i)}{x_i} \right| 100 \quad (5.51)$$

Το συγκεκριμένο μέτρο είναι κατάλληλο για αξιολόγηση μεθόδων ως προς την ακρίβεια. Μπορεί επίσης να υποστηρίξει συγκρίσεις της επίδοσης μιας μεθόδου πρόβλεψης πάνω σε διαφορετικές χρονοσειρές, ενώ είναι ένα από τα πιο δημοφιλή μέτρα. Ωστόσο, παρουσιάζει το μειονέκτημα ότι απειρίζεται θετικά για μηδενικές τιμές των παρατηρήσεων ή λαμβάνει ακραίες θετικές τιμές για πολύ μικρές τιμές των παρατηρήσεων.

5.6.5 Μέσο Τετραγωνικό Σφάλμα (Mean Square Error)

Το μέτρο Mean Square Error (MSE) ορίζεται με την εξ. (5.52).

$$MSE = \frac{1}{n} \sum_{i=1}^n (f_i - x_i)^2 \quad (5.52)$$

Το συγκεκριμένο μέτρο μπορεί να χρησιμοποιηθεί όπως και το MAE, παρουσιάζοντας ωστόσο μεγαλύτερη ευαισθησία στις ακραίες τιμές.

5.6.6 Ρίζα Μέσου Τετραγωνικού Σφάλματος (Root Mean Squared Error)

Το μέτρο Root Mean Square Error (RMSE) ορίζεται με την εξ. (5.53).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (f_i - x_i)^2}{n}} \quad (5.53)$$

Το συγκεκριμένο μέτρο χρησιμοποιείται ευρύτατα για την μέτρηση της ακρίβειας που προσφέρει μια μέθοδος πρόβλεψης. Σε σχέση με το MSE, παρουσιάζει το πλεονέκτημα ότι το σφάλμα μετριέται στις ίδιες μονάδες με τα δεδομένα.

5.6.7 Συντελεστής Προσδιορισμού R^2 (Coefficient of Determination)

Ορίζεται το μέτρο Coefficient of Determination (R^2) με την εξ. (5.54).

$$R^2 = \frac{\sum_{i=1}^n (f_i - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (5.54)$$

Όπου \bar{x} αντιπροσωπεύει τον μέσο όρο των τιμών x_i . Μας δίνει το ποσοστό της διακύμανσης του x_i που μπορεί να προβλεφθεί από το εκάστοτε μοντέλο. Απαντάει δηλαδή στο κατά πόσο οι προβλεπόμενες τιμές μπορούν να εξηγήσουν τις παρατηρημένες.

6. ΕΦΑΡΜΟΓΗ ΜΕΘΟΔΩΝ ΠΡΟΒΛΕΨΗΣ – ΥΛΟΠΟΙΗΣΗ ΣΤΗΝ ΡΥΤΗΘΝ

Έχοντας πλέον παρουσιάσει τα βασικά μαθηματικά και θεωρητικά εργαλεία, θα καταπιαστούμε με την ουσία ετούτης της εργασίας, την διενέργεια των προβλέψεων. Αναφερόμαστε σε προβλέψεις εισροών νερού (hm^3) στους τρεις ταμιευτήρες ενδιαφέροντος, οι οποίες μέσω των εξισώσεων του υδατικού ισοζυγίου και των σχετικών προσομοιώσεων, θα μετατραπούν σε προβλέψεις παραγωγής ενέργειας μηνιαίου βήματος.

Για την επεξεργασία των δεδομένων αλλά και για όλες τις αναλύσεις της εργασίας χρησιμοποιήθηκε η γλώσσα προγραμματισμού *Python* και η έκδοση 3.6.8. Μερικές από τις σημαντικότερες βιβλιοθήκες που βοήθησαν στην υλοποίηση των αναλύσεων είναι οι *Numpy*, *Pandas*, *API Keras*, *Tensorflow*, διεξοδική αναφορά στις οποίες θα γίνει στη συνέχεια του τρέχοντος Κεφαλαίου.

Τα δεδομένα που είχαμε στη διάθεση μας αφορούσαν τις εισροές των ταμιευτήρων στα Κρεμαστά και στον Εύηγο. Όσον αφορά τον ταμιευτήρα της Μεσοχώρας, τα δεδομένα προέκυψαν από τον λόγο του εμβαδού της λεκάνης της με την αντίστοιχη των Κρεμαστών. Αμφότεροι οι ταμιευτήρες βρίσκονται στον Αχελώο.

Για το μοντέλο AR(1) χρησιμοποιήθηκαν μονάχα τα ιστορικά δεδομένα για τις αναλύσεις. Αντίθετα για τη διαδικασία της εκπαίδευσης των μοντέλων LSTM και KNN χρησιμοποιήθηκαν συνθετικές χρονοσειρές που διατηρούν τα στατιστικά χαρακτηριστικά των αντίστοιχων ιστορικών. Η αξιολόγηση ωστόσο και για τα τρία μοντέλα έλαβε χώρα στην ίδια χρονοσειρά ιστορικών δεδομένων.

Σημαντικό στάδιο της ανάλυσης των δεδομένων αναφέρεται στον χωρισμό των δεδομένων με κατάλληλο τρόπο για την εφαρμογή τόσο των αλγορίθμων μηχανικής μάθησης όσο και του αυτοπαλίνδρομου μοντέλου 1^{ης} Τάξης. Ο χωρισμός των δεδομένων για την πρόβλεψη πολλαπλών χρονικών στιγμών στο μέλλον είναι ένα πρόβλημα που μπορεί να αντιμετωπιστεί με διαφορετικές προσεγγίσεις. Μία από αυτές είναι η αναδρομική, στην οποία το μοντέλο προβλέπει μια τιμή στο μέλλον την οποία στην συνέχεια χρησιμοποιεί ως είσοδο για την πρόβλεψη της επόμενης. Άλλη επιλογή είναι η δημιουργία ενός μοντέλου για κάθε ξεχωριστό χρονικό ορίζοντα πρόβλεψης. Μια από τις πιο αποδοτικές στρατηγικές όμως, είναι αυτή των πολλαπλών εισόδων-πολλαπλών εξόδων (Multi- Input Multi-Output (MIMO)), όπου η έξοδος αποτελεί την

συνολική πρόβλεψη όλου του ορίζοντα χρησιμοποιώντας ένα μοντέλο. Η συγκεκριμένη μέθοδος φέρει αρκετά πλεονεκτήματα, όπως αυτό της μοντελοποίησης των εξαρτήσεων μεταξύ των προβλεπόμενων τιμών, αφού στην έξοδο προβλέπεται το σύνολο του μελλοντικού χρονικού ορίζοντα. Ακόμα, αυτή η μέθοδος είναι απαλλαγμένη από την συσσώρευση των σφαλμάτων πρόβλεψης που θα εμφανιζόταν στην αναδρομική στρατηγική .

Στην παρούσα εργασία επιλέχθηκε η αναδρομική στρατηγική για το υπόδειγμα AR(1), ενώ για τα μοντέλα μηχανικής μάθησης κατάλληλη κρίθηκε η στρατηγική MIMO. Οι χρονικοί ορίζοντες προβλέψεων είναι τεσσάρων (4) και δώδεκα (12) μηνών αντίστοιχα.

6.1 Προβλέψεις με το Μοντέλο AR(1)

Σαν μοντέλο βάσης για τις προβλέψεις μας επιλέχθηκε το Αυτοπαλίνδρομο 1^{ης} τάξεως. Πρόκειται για ένα φειδωλό μοντέλο με μικρές απαιτήσεις σε υπολογιστικό φόρτο, το θεωρητικό υπόβαθρο του οποίου καλύφθηκε στο Κεφάλαιο 5.

Η επιλογή του στηρίχθηκε στην αποθηκευτική ικανότητα των μεγάλων ταμιευτήρων. Η εργασία αποβλέπει στην πρόβλεψη παραγωγής ενέργειας και τυχόντα λάθη που μπορεί να γίνουν στην πρόγνωση απορροής, εξομαλύνονται σε όρους πρόγνωσης ενεργειακής παραγωγής.

Το υπόδειγμα σύμφωνα με την (5.14) έχει την παρακάτω μορφή:

$$Y_t = \delta + \alpha_1 Y_{t-1} + \varepsilon_t$$

Εμείς επιλέγουμε να δώσουμε, σε αυτό το πρώτο στάδιο της εργασίας, ντετερμινιστικές προβλέψεις και διαμορφώνουμε το υπόδειγμα χρησιμοποιώντας την κεντρική τιμή κατανομής των σφαλμάτων ε_t . Με αυτόν τον τρόπο, και μέσω της (5.20) έχουμε την τελική μορφή του μοντέλου:

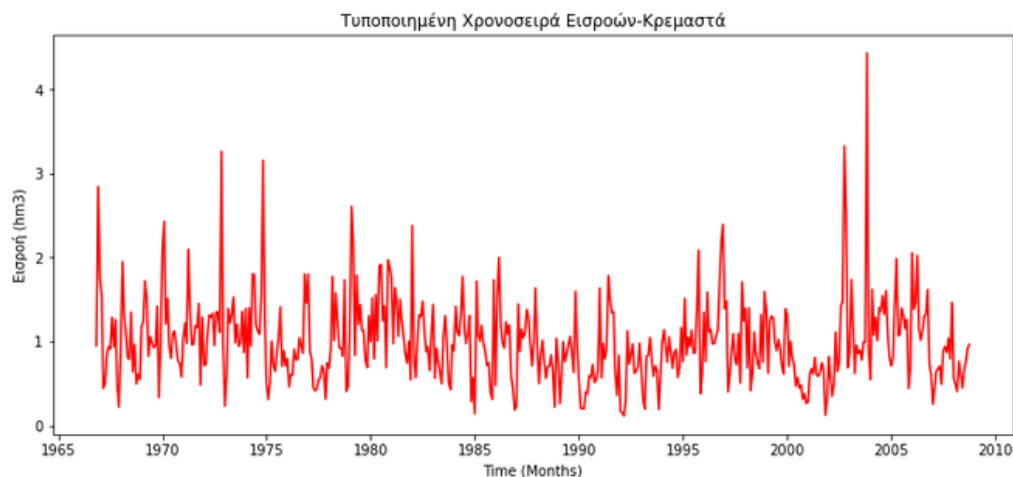
$$Y_t = \mu(1 - \alpha_1) + \alpha_1 Y_{t-1} \quad (6.1)$$

Όπου α_1 είναι ο συντελεστής αυτοσυσχέτισης 1^{ης} Τάξης όπως αποδείχτηκε στην (5.28)

Τυποποίηση Χρονοσειράς Απορροής

Πρώτο βήμα της μεθοδολογίας αφορά στην αφαίρεση της εποχικότητας που εμφανίζεται στις εισροές. Με αυτόν τον τρόπο τα στατιστικά χαρακτηριστικά της

χρονοσειράς γίνονται σταθερά στο χρόνο μετατρέποντας την σε στάσιμη. Ένας τρόπος για την τυποποίηση αυτή είναι η αφαίρεση της μέσης τιμής και η διαίρεση με την τυπική απόκλιση κάθε μήνα. Εμείς επιλέξαμε μία άλλη προσέγγιση, αυτή της διαίρεσης με την μέση τιμή κάθε μήνα αποφεύγοντας έτσι προβλήματα με αρνητικές προκύπτουσες τιμές. Ενδεικτικά παρακάτω φαίνεται στην Εικόνα (6.1) η τυποποιημένη χρονοσειρά των εισροών στα Κρεμαστά.



Εικόνα 6.1-Τυποποιημένη χρονοσειρά εισροών για το Φράγμα των Κρεμαστών

Χωρισμός του Δείγματος

Η εφαρμογή του υποδείγματος με σκοπό την αξιολόγηση του συστήματος να περιλαμβάνει δύο φάσεις, την φάση της εκπαίδευσης των μοντέλων πάνω σε ένα σύνολο δεδομένων εκπαίδευσης (**training set**) και την φάση της δοκιμής, η οποία ακολουθεί την προαναφερθείσα. Η δοκιμή γίνεται κατά κανόνα σε ανεξάρτητο σύνολο δεδομένων, το σύνολο δεδομένων δοκιμής (**test set**), και βάσει αυτής αξιολογούνται οι εκάστοτε μέθοδοι. Στο συγκεκριμένο πλαίσιο, τα παραπάνω σύνολα δεδομένων προκύπτουν μέσω του χωρισμού μιας χρονοσειράς σε δύο τμήματα κατάλληλου μεγέθους. Συγκεκριμένα, καθεμία χρονοσειρά χωρίζεται σε δύο τμήματα για τις φάσεις της εκπαίδευσης και της δοκιμής αντίστοιχα, ικανοποιώντας την αναλογία 3:1, η οποία είναι μία από τις συνιστώμενες στην βιβλιογραφία και θα χρησιμοποιηθεί στην εργασία μας. Άλλη συνιστώμενη αναλογία είναι η 4:1. (βλ. Paracharalampous, Tyrallis and Koutsoyiannis, 2017)

Έτσι λοιπόν, έχοντας χωρίσει τα δεδομένα στα 2 sets, εκτιμάμε τις παραμέτρους της εξίσωσης (6.1) του μοντέλου που θα χρησιμοποιηθεί για την παλινδρόμηση. Η


εκτίμηση θα γίνει με χρήση του training set. Δοκιμάζονται δύο ορίζοντες πρόβλεψης. Αυτός των 4 και αυτός των 12 μηνών. Οι παράμετροι του μοντέλου αλλάζουν ανά 4άδα ή 12άδα προβλέψεων, καθώς για την εκτίμηση των νέων παραμέτρων το training set μεγαλώνει, ενημερώνεται, ενσωματώνοντας έτσι τη νέα στατιστική πληροφορία του δείγματος. Στις ενότητες που ακολουθούν θα γίνει μία απεικόνιση της μεταβολής των στατιστικών χαρακτηριστικών για κάθε ταμιευτήρα.

Μόλις πάρουμε τις 4άδες ή 12άδες των προβλέψεων **αποτυποποιούμε** τις τιμές πολλαπλασιάζοντας με την μέση τιμή κάθε μήνα. Δημιουργείται έτσι ένα μητρώο προβλέψεων της απορροής, το οποίο συγκρίνεται με τις πραγματικές τιμές του αντίστοιχου μητρώου στο test set.


Τελικά για να πάρουμε τις προβλέψεις παραγωγής ενέργειας, χρησιμοποιούμε σαν είσοδο το μητρώο προβλέψεων στην προσομοίωση λειτουργίας του ταμιευτήρα όπως αυτή περιεγράφηκε στο Κεφάλαιο 3. Η απώληση για την παραγωγή ενέργειας είναι σταθερή ανά μηνιαίο βήμα και έχει προκύψει μετά από βελτιστοποίηση.

6.1.1 Εφαρμογή στον Ταμιευτήρα των Κρεμαστών


Τα διαθέσιμα δεδομένα απορροής για τα Κρεμαστά ξεκινάνε από τον Οκτώβριο του 1966 και ολοκληρώνονται τον Σεπτέμβρη του 2008. Είναι ένας ταμιευτήρας πολύ μεγάλου μεγέθους και τα σφάλματα πρόγνωσης της απορροής εξομαλύνονται σε πολύ μεγάλο βαθμό στα αντίστοιχα της παραγωγής ενέργειας. Παρακάτω φαίνονται τα ιστογράμματα εισροών πριν και μετά την τυποποίηση αλλά και η χρονοσειρά των εισροών στον Ταμιευτήρα.



Εικόνα 6.2-Χρονοσειρά Εισροών για το φράγμα των Κρεμαστών



Εικόνα 6.3-Ιστόγραμμα συχνοτήτων εισροών σε hm³



Εικόνα 6.4-Ιστόγραμμα συχνοτήτων τυποπ. εισροών σε hm³


Μετά από την εφαρμογή της μεθοδολογίας που περιγράφηκε στην προηγούμενη ενότητα, προέκυψαν τα πρώτα αποτελέσματα. Το μοντέλο μετά από την εκτίμηση των παραμέτρων του πήρε την μορφή:

$$Y_t = 0.66 + 0.34 Y_{t-1}$$


Φυσικά, όπως έχει ήδη αναφερθεί οι αριθμητικές τιμές των παραμέτρων του μοντέλου αλλάζουν με τον χρόνο, αφού προστίθεται πληροφορία μετά από κάθε 4άδα ή 12άδα πρόβλεψης. Παρόλο που η διαδικασία αυξάνει την ακρίβεια στις προβλέψεις αφού χρησιμοποιείται περισσότερη ιστορική πληροφορία, η επίδραση αναμένεται να είναι μακροπρόθεσμη. Ο συντελεστής αυτοσυσχέτισης πρώτης τάξης λαμβάνει τιμές από 0.33 έως 0.38. Ενδεικτικά παραπάνω, παρουσιάστηκε η μορφή του μοντέλου πριν την τελευταία 4άδα προβλέψεων. Τα σφάλματα απορροής εκφρασμένα σε ποσοστιαίες μονάδες δεν έχουν μεγάλη απόκλιση για τους 2 διαφορετικούς χρονικούς ορίζοντες.

ERROR METRICS	ΚΡΕΜΑΣΤΑ		ERROR METRICS	ΚΡΕΜΑΣΤΑ	
	AR(1)			AR(1)	
	ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ		ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ
	LEAD TIME = 4			LEAD TIME = 12	
MAPE (%)	51.69	1.86	MAPE (%)	53.6	4.5
MPE (%)	-30.34	-0.62	MPE (%)	-32.16	-2.78
RMSE	149.69	5.69	RMSE	150.89	10.2
R ²	0.57	0.7	R ²	0.56	0.34

Πίνακας 6.1-Μετρικές Σφαλμάτων μοντέλου AR(1) για Lead time = 4 και Lead time=12 στον ταμιευτήρα Κρεμαστών



Εικόνα 6.5-Προβλέψεις εισροών AR(1) LT=4 για τα Κρεμαστά




Εικόνα 6.6-Προβλέψεις εισροών AR(1) LT=12 για τα Κρεμαστά

Και για τους 2 ορίζοντες προβλέψεων παρατηρούμε μια καλύτερη επίδοση για τις χαμηλές και μέσες τιμές εισροών οι οποίες φαίνεται να έχουν μικρότερη μεταβλητότητα. Αντίθετα οι υψηλές τιμές δεν είναι τόσο εύκολο να προβλεφθούν και γενικά υποεκτιμώνται. Παρόλα αυτά από τον πίνακα (6.1) φαίνεται ότι τα σφάλματα στην παραγωγή ενέργειας είναι πολύ μικρότερα σε σχέση με αυτά της απορροής. Σημαντική κρίνεται και οι απεικόνιση των σφαλμάτων εισροής στο χρόνο για μια καλύτερη εκτίμηση της στατιστικής εικόνας. Βλέπουμε ότι το υπόδειγμα μας, είναι ικανό να μοντελοποιήσει σε ένα ικανοποιητικό επίπεδο τα ιστορικά δεδομένα και τις προβλέψεις απορροής. Λόγω της ασάφειας των δεδομένων καιρού, αλλά και της τυχαιότητας που εμφανίζει η χρονοσειρά απορροής, δεν μπορούν να προβλεφθούν οι απότομες μεταβολές.


Φαίνεται επίσης μία περιοδικότητα στο σφάλμα, που οφείλεται στην καλή εκτίμηση των χαμηλών τιμών εισροής (κατά τους καλοκαιρινούς μήνες) και στην δυσκολία πρόβλεψης των ακραίων φαινομένων στη χειμερινή περίοδο.

Αυτές οι προβλέψεις για τον ταμιευτήρα των Κρεμαστών μεταφράζονται σε όρους παραγωγής ενέργειας. Τα αποτελέσματα οπτικοποιούνται στα παρακάτω διαγράμματα

των εικόνων (6.7) και (6.8) για τους χρονικούς ορίζοντες ενδιαφέροντος. Αναμενόμενα, η επίδοση του μοντέλου για χρονικό ορίζοντα τεσσάρων μηνών είναι καλύτερη.



Εικόνα 6.7-Προβλέψεις ενέργειας AR(1) LT=4 για τα Κρεμαστά



Εικόνα 6.8-Προβλέψεις ενέργειας AR(1) LT=12 για τα Κρεμαστά

6.1.2 Εφαρμογή στον Ταμιευτήρα της Μεσοχώρας

Το φράγμα της Μεσοχώρας επιλέχθηκε να αποτελέσει αντικείμενο μελέτης για να διαπιστώσουμε το ρόλο που διαδραματίζει το ζήτημα της κλίμακας στις προβλέψεις παραγωγής ενέργειας, καθώς πρόκειται για έναν ταμιευτήρα σαφώς μικρότερου μεγέθους από αυτόν των Κρεμαστών. Όπως έχει ήδη ειπωθεί τα δεδομένα απορροής


προέκυψαν από τον λόγο του εμβαδού της λεκάνης της Μεσοχώρας με την αντίστοιχη των Κρεμαστών. Επομένως τα σφάλματα απορροής είναι τα ίδια για τους 2 ταμειυτήρες. Το ενδιαφέρον στην περίπτωση αυτή είναι η επίδραση στην παραγωγή ενέργειας.

ERROR METRICS	ΜΕΣΟΧΩΡΑ		ERROR METRICS	ΜΕΣΟΧΩΡΑ	
	AR(1)			AR(1)	
	ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ		ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ
	LEAD TIME = 4			LEAD TIME = 12	
MAPE (%)	51.69	16.87	MAPE (%)	53.6	45.94
MPE (%)	-30.34	-6.55	MPE (%)	-32.16	-37
RMSE	26.49	7.08	RMSE	26.71	8.54
R ²	0.57	0.55	R ²	0.56	0.34


Πίνακας 6.2-Μετρικές Σφαλμάτων μοντέλου AR(1) για Lead time = 4 και Lead time=12 στον ταμειυτήρα Μεσοχώρας

Σε αντίθεση με την ανάλυση των Κρεμαστών, στη Μεσοχώρα υπάρχει σημαντική διαφορά όταν ο χρονικός ορίζοντας πρόβλεψης είναι τεσσάρων μηνών. Στους 12 μήνες τα σφάλματα ενέργειας σταματάνε να εξομαλύνονται με τον ίδιο ρυθμό. Αυτό τουλάχιστον ερμηνεύεται από τις αθροιστικές τιμές των αποτελεσμάτων. Χρειάζεται να απεικονιστεί και η πορεία τους στο χρόνο για πιο ασφαλή συμπεράσματα.

Βλέπουμε πως το υπόδειγμα έχει μηδενικές τιμές σφάλματος σημαντικό διάστημα στη διάρκεια των μηνών που απαρτίζουν το test set. Παρόλα αυτά η επίδοση του είναι αρκετά χειρότερη από αυτή των Κρεμαστών όπως αναμενόταν. Επιπλέον πληθαίνουν οι περιπτώσεις που το μοντέλο είναι σημαντικά άστοχο. Προφανώς δεν είναι εύκολο να προβλεφθούν ακραία φαινόμενα ειδικά για ένα φειδωλό μοντέλο όπως το AR(1), όμως η διαφορά είναι εμφανής. Στις εικόνες (6.9) και (6.10) παρακάτω, βλέπουμε ότι μπορεί να υστερεί σε ακρίβεια σε μερικές περιπτώσεις, αλλά γενικά το μοντέλο είναι σε θέση να αντιληφθεί σε ποιο επίπεδο θα κινηθεί η παραγωγικότητα του επόμενου μήνα. Φυσικά στις υψηλές τιμές η ακρίβεια στις προβλέψεις είναι μικρότερη.





Εικόνα 6.9-Προβλέψεις ενέργειας AR(1) LT=4 για την Μεσοχώρα



Εικόνα 6.10-Προβλέψεις ενέργειας AR(1) LT=12 για την Μεσοχώρα

6.1.3 Εφαρμογή στον Ταμιευτήρα του Εύηνου

Η χωρητικότητα του Εύηνου είναι αρκετά πιο μικρή από τη μέση ετήσια εισροή. Αυτός είναι και ο λόγος που επιλέχτηκε να αποτελέσει παράγοντα στις αναλύσεις. Θεωρήθηκε ένα υποθετικό υδροηλεκτρικό έργο με θεωρητικό υδροδυναμικό 50 GWh ετησίως. Τεχνικές λεπτομέρειες για το φράγμα αλλά και για τις υποθέσεις που έγιναν, αναφέρονται εκτενώς στην ενότητα 4.3. Στα Στις εικόνες (6.11) και (6.12) φαίνονται τα ιστογράμματα πυκνότητας συχνότητας της απορροής του Εύηνου καθώς και η χρονοσειρά της.



Εικόνα 6.11-Ιστόγραμμα συχνοτήτων εισροών σε hm³ Εικόνα 6.12-Ιστόγραμμα συχνοτήτων τυποπ. εισροών σε hm³




Εικόνα 6.13-Χρονοσειρά Εισροών για το φράγμα του Ευήνου


Τα αποτελέσματα πρόγνωσης απορροής και ενέργειας παρουσιάζονται στα παρακάτω σχήματα τόσο σε μορφή πίνακα αθροιστικών σφαλμάτων τόσο και στην απεικόνισή τους στο χρόνο. Σημαντικές είναι και οι χρονοσειρές πρόγνωσης και για τους 2 χρονικούς ορίζοντες ενδιαφέροντος.

ERROR METRICS	ΕΥΗΝΟΣ		ERROR METRICS	ΕΥΗΝΟΣ	
	AR(1)			AR(1)	
	ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ		ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ
	LEAD TIME = 4			LEAD TIME = 12	
MAPE (%)	67.6	22.8	MAPE (%)	70.2	36.6
MPE (%)	-43.22	-9.7	MPE (%)	-45.2	-22.6
RMSE	16.05	3.22	RMSE	16.6	3.7
R ²	0.51	0.46	R ²	0.47	0.29


Πίνακας 6.3-Μετρικές Σφαλμάτων μοντέλου AR(1) για Lead time = 4 και Lead time=12 στον ταμιευτήρα Ευήνου




Εικόνα 6.14-Προβλέψεις εισροών AR(1) LT=4 για τον Εύηνο



Εικόνα 6.15-Προβλέψεις εισροών AR(1) LT=12 για τον Εύηνο



Εικόνα 6.16-Προβλέψεις ενέργειας AR(1) LT=4 για τον Εύηνο



Εικόνα 6.17-Προβλέψεις ενέργειας AR(1) LT=12 για τον Εύηνο


Όπως αναμενόταν για ένα έργο με την συγκεκριμένη περιορισμένη χωρητικότητα, η επίδοση του μοντέλου είναι αρκετά χειρότερη σε σχέση με τους δύο προηγούμενους ταμειυτήρες, ειδικά για ορίζοντα πρόβλεψης 12 μηνών. Μπορεί η μοντελοποίηση των μέσων και χαμηλών ροών να παραμένει ικανοποιητική, ωστόσο με την μετατροπή σε όρους ενέργειας είναι φανερή η ανάγκη δοκιμής για εφαρμογή ενός πιο σύνθετου μοντέλου για τον περιορισμό των σφαλμάτων πρόγνωσης, χωρίς αυτό ωστόσο, να εγγυάται απαραίτητως καλύτερα αποτελέσματα ως προς την ακρίβεια.

6.2 Προβλέψεις με το Μοντέλο LSTM

Στην παρούσα εργασία γίνεται μελέτη του Long-Short Term Memory (LSTM) επαναλαμβανόμενου τεχνητού νευρωνικού δικτύου (recursive). Σε αντίθεση με τα κλασικά ανεστραμμένα νευρωνικά δίκτυα (feedforward), το LSTM διαθέτει πύλες ανάδρασης με δυνατότητες μνήμης που λαμβάνουν υπόψη μεγαλύτερο μήκος χρονοσειράς. Συνεπώς το LSTM μπορεί να ανιχνεύσει πιο αποτελεσματικά τη μεταβλητότητα των φυσικών φαινομένων.

Όπως έχει ειπωθεί η στρατηγική που χρησιμοποιήσαμε για τα μοντέλα μηχανικής μάθησης είναι αυτή των πολλαπλών εισόδων-πολλαπλών εξόδων (Multi- Input Multi- Output (MIMO)), όπου η έξοδος αποτελεί την συνολική πρόβλεψη όλου του ορίζοντα. Ακολουθώντας την παραπάνω στρατηγική, πρέπει να δημιουργηθεί ένα κινούμενο παράθυρο το οποίο θα ολισθαίνει στις παρατηρήσεις της χρονοσειράς, δημιουργώντας

ζεύγη εισόδου-εξόδου που θα παρουσιαστούν στους αλγορίθμους μας, μετατρέποντας το πρόβλημα της πρόβλεψης σε ένα πρόβλημα επιβλεπόμενης μάθησης. Τα μοντέλα που θα παρουσιαστούν δέχονται ως είσοδο ένα συγκεκριμένου μήκους διάνυσμα και έχουν ως έξοδο ένα dense layer, που αποτελείται από 4 ή 12 νευρώνες όσες δηλαδή και οι μελλοντικές παρατηρήσεις που επιθυμούμε να προβλέψει το νευρωνικό δίκτυο. Η διαδικασία χωρισμού των παρατηρήσεων μίας χρονοσειράς σε ζεύγη εισόδου-εξόδου φαίνεται στην εικόνα (6.18).



Εικόνα 6.18-Διαδικασία χωρισμού παρατηρήσεων σε ζεύγη εισόδου-εξόδου

Όπως παρατηρείται, ένα παράθυρο σταθερού μήκους ολισθαίνει κατά μήκος της χρονοσειράς, δημιουργώντας τα ζεύγη εισόδου-εξόδου. Εδώ, πρέπει να τονίσουμε ότι για την δημιουργία των δεδομένων εκπαίδευσης, το παράθυρο ολισθαίνει με βήμα ενός μήνα, για την δημιουργία περισσότερων ζευγαριών εισόδου-εξόδου, μιας και τα βαθιά νευρωνικά δίκτυα απαιτούν πληθώρα δεδομένων για την εκπαίδευσή τους. Ακόμα, πρέπει να διευκρινιστεί πως ενώ το μήκος της εξόδου είναι σταθερό, το μήκος των δεδομένων εισόδου είναι μια παράμετρος που πρέπει να αποφασιστεί. Ο καθορισμός του εξαρτάται από πολλούς παράγοντες, όπως η φύση των δεδομένων, το μοντέλο που θα χρησιμοποιηθεί και ο ορίζοντας πρόβλεψης. Στην παρούσα εργασία για την επιλογή του ορίζοντα των δεδομένων εισόδου δοκιμάστηκαν διάφορες τιμές. Ρόλο στην επιλογή αυτή έπαιξε το γεγονός ότι το LSTM νευρωνικό δίκτυο έχει περιορισμένη ικανότητα χειρισμού μεγάλου μήκους δεδομένων.

Σημαντικό είναι πως για την εκπαίδευση των μοντέλων χρησιμοποιήθηκαν συνθετικές χρονοσειρές που προήλθαν από τις ιστορικές διατηρώντας τα στατιστικά χαρακτηριστικά τους. Ωστόσο η αξιολόγηση γίνεται και για τα νευρωνικά δίκτυα στο ίδιο set δεδομένων που έγινε και για το αυτοπαλίνδρομο AR(1).

Οι μέθοδοι μηχανικής μάθησης εφαρμόζονται ιδανικά σε τέσσερις φάσεις. Στην πρώτη εκπαιδεύονται πάνω στην ίδια πληροφορία διάφορα μοντέλα, τα οποία βασίζονται μεν στον ίδιο αλγόριθμο, διαφέρουν δε ως προς τις υπερπαραμέτρους του συγκεκριμένου αλγορίθμου. Τα εκπαιδευμένα μοντέλα δοκιμάζονται στην συνέχεια στην πρόβλεψη ενός άλλου συνόλου δεδομένων, το οποίο καλείται σύνολο δεδομένων επικύρωσης (validation set). Από την σύγκριση αυτή προκύπτει ένα μοντέλο με το μικρότερο σφάλμα πρόβλεψης με βάση κάποιο μέτρο, συνήθως το RMSE. Η συγκεκριμένη διαδικασία βελτιστοποίησης ως προς τις υπερπαραμέτρους των μοντέλων μηχανικής μάθησης συστήνεται για τον περιορισμό της υπερπροσαρμογής των μοντέλων (Prechelt, 1998).

Η τελευταία είναι εξίσου μη επιθυμητή με την κακή προσαρμογή. Στην τρίτη φάση ένα νέο μοντέλο με ίδιες υπερπαραμέτρους με αυτές του μοντέλου - νικητή της δεύτερης φάσης προσαρμόζει τις παραμέτρους του στο σύνολο της πληροφορίας που χρησιμοποιείται στις πρώτες δύο φάσεις, δηλαδή στο σύνολο των δεδομένων εκπαίδευσης και το σύνολο δεδομένων επικύρωσης μαζί. Το μοντέλο που προκύπτει δοκιμάζεται στην τελευταία φάση στην πληροφορία που προορίζεται για τον συγκεκριμένο σκοπό.

6.2.1 Εφαρμογή στον Ταμιευτήρα των Κρεμαστών

Η επιλογή των παραμέτρων του μοντέλου είναι διαφορετική για κάθε ταμιευτήρα και κάθε data set και βασίζεται σε δοκιμές. Σημαντική είναι η παρατήρηση πως ακόμα και αν γίνει η ίδια προσομοίωση με ακριβώς τις ίδιες παραμέτρους πολλές φορές, πάντα τα αποτελέσματα θα διαφέρουν μεταξύ τους. Στην Εικόνα (6.19) φαίνεται ο κώδικας σε περιβάλλον *Python* που περιγράφει το μοντέλο που χρησιμοποιήθηκε για τον ταμιευτήρα των Κρεμαστών το οποίο είχε τις καλύτερες επιδόσεις. Κατά την εκπαίδευση, η συνάρτηση σφάλματος καταλήγει να έχει τιμή *loss*= 0.0058.

```

BUILD LSTM MODEL

In [22]: model = Sequential()
          model.add(tf.keras.layers.Bidirectional(LSTM(units = 300,
          activation = 'relu', return_sequences=True, input_shape=(24,1)))
          model.add(tf.keras.layers.Dropout(0.2))
          model.add(tf.keras.layers.Bidirectional(LSTM(units = 300,
          activation = 'relu')))
          model.add(tf.keras.layers.Dropout(0.2))
          model.add(Dense(lead_time))

In [23]: model.compile(loss='mse', optimizer='Adam')

In [24]: callback = tf.keras.callbacks.EarlyStopping(monitor='val_loss', patience=5)
          history = model.fit(X_train, y_train, epochs=50,
          batch_size=32, validation_split=0.2, callbacks=[callback])


```

Εικόνα 6.19-Ενδεικτική παρουσίαση μέρους του κώδικα για την παραμετροποίηση του LSTM μοντέλου Κρεμαστών σε περιβάλλον PYTHON


Τα σφάλματα απορροής για χρονικό ορίζοντα πρόβλεψης τεσσάρων μηνών που προκύπτουν είναι μικρότερα από αυτά του μοντέλου AR(1). Ωστόσο σημαντικό στοιχείο αποτελεί το γεγονός ότι για αυτά τα ελαφρώς καλύτερα αποτελέσματα χρειάστηκαν πολλές δοκιμές και πολλές βελτιώσεις στο μοντέλο. Στην εξίσωση φυσικά μπαίνει και η δύναμη του H/Y που χρησιμοποιήθηκε.

ERROR METRICS	ΚΡΕΜΑΣΤΑ		ERROR METRICS	ΚΡΕΜΑΣΤΑ	
	LSTM			LSTM	
	ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ		ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ
	LEAD TIME = 4			LEAD TIME = 12	
MAPE (%)	45.34	1.73	MAPE (%)	65.6	7.14
MPE (%)	-29.31	-0.6	MPE (%)	-49	-6.6
RMSE	140.1	5.21	RMSE	164.1	13.2
R ²	0.59	0.73	R ²	0.52	0.37

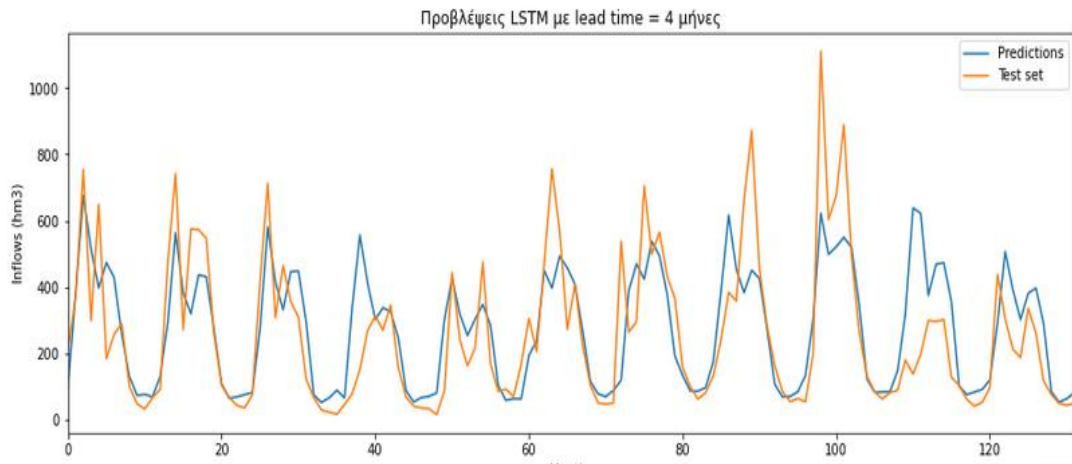
Πίνακας 6.4-Μετρικές Σφαλμάτων μοντέλων LSTM για Lead time = 4 και Lead time=12 στον ταμιευτήρα Κρεμαστών




Εικόνα 6.20-Διάγραμμα διασποράς πραγματικών και προβλεπόμενων εισροών για τον ταμιευτήρα των Κρεμαστών για LT=4




Εικόνα 6.21-Διάγραμμα διασποράς πραγματικών και προβλεπόμενων εισροών για τον ταμιευτήρα των Κρεμαστών για $LT=12$




Εικόνα 6.22-Προβλέψεις εισροών LSTM $LT=4$ για τα Κρεμαστά



Εικόνα 6.23-Προβλέψεις ενέργειας LSTM $LT=4$ για τα Κρεμαστά



Εικόνα 6.24-Προβλέψεις εισροών LSTM LT=12 για τα Κρεμαστά



Εικόνα 6.25-Προβλέψεις ενέργειας LSTM LT=12 για τα Κρεμαστά

Για χρονικό ορίζοντα δώδεκα μηνών το μοντέλο LSTM έχει χειρότερη επίδοση από αυτή του AR(1) . Έγινε προσπάθεια περαιτέρω βελτιστοποίησης του, αλλά ο υπολογιστικός φόρτος που απαιτήθηκε κρίθηκε αντιστρόφως ανάλογος του σκοπού της εργασίας.

Στις εικόνες (6.22) και (6.24) βλέπουμε πως το LSTM μοντέλο δεν έχει τόσο καλή επίδοση σε μέσες και χαμηλές ροές. Παρόλα αυτά έχει το μεγάλο πλεονέκτημα πως είναι σε θέση να αντιληφθεί την μεταβλητότητα του επιπέδου τιμών στις υψηλές ροές. Πρόκειται για ένα σημαντικό εξαγόμενο που θα φανεί ιδιαίτερα χρήσιμο στην πορεία της εργασίας καθώς όπως είναι λογικό μικρότερες αποκλίσεις από τις υψηλές τιμές σημαίνει και μικρότερη απώλεια εσόδων από την πώληση της ενέργειας.

6.2.2 Εφαρμογή στον Ταμιευτήρα της Μεσοχώρας

Ενώ τα δεδομένα εισροών για τη Μεσοχώρα είναι ανάλογα των Κρεμαστών, οι παράμετροι που χρησιμοποιήθηκαν και οδήγησαν σε καλύτερα αποτελέσματα διαφέρουν. Συγκεκριμένα φάνηκε πως λιγότεροι νευρώνες (100 αντί για 300) και μονάχα ένα Layer ήταν αρκετά για να επιτευχθούν παρόμοια αποτελέσματα. Συμπεραίνουμε λοιπόν πως το εύρος στις τιμές των δεδομένων επηρεάζει σημαντικά την παραμετροποίηση του μοντέλου. Κατά την εκπαίδευση, η συνάρτηση σφάλματος καταλήγει να έχει τιμή $loss = 0.006$.

BUILD LSTM MODEL

```
In [22]: model = Sequential()
model.add(tf.keras.layers.Bidirectional(LSTM(units = 100,
activation = 'relu', input_shape=(24,1))))
model.add(tf.keras.layers.Dropout(0.2))
#model.add(Dense(24, activation='relu'))
model.add(Dense(lead_time))


In [23]: model.compile(loss='mse', optimizer='Adam')

In [24]: callback = tf.keras.callbacks.EarlyStopping(monitor='val_loss', patience=5)
history = model.fit(X_train, y_train, epochs=50,
batch_size=64, validation_split=0.2, callbacks=[callback])
```


Εικόνα 6.26-Ενδεικτική παρουσίαση μέρους του κώδικα για την παραμετροποίηση του LSTM μοντέλου Μεσοχώρας σε περιβάλλον PYTHON

ERROR METRICS	ΜΕΣΟΧΩΡΑ		ERROR METRICS	ΜΕΣΟΧΩΡΑ	
	LSTM			LSTM	
	ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ		ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ
	LEAD TIME = 4		LEAD TIME = 12		
MAPE (%)	50.3	15.7	MAPE (%)	64	57.1
MPE (%)	-31.4	-6.8	MPE (%)	-49	-54.1
RMSE	26.3	5.88	RMSE	27.24	8.4
R ²	0.58	0.66	R ²	0.54	0.43


Πίνακας 6.5-Μετρικές Σφαλμάτων μοντέλων LSTM για Lead time = 4 και Lead time=12 στον ταμιευτήρα Μεσοχώρας




Εικόνα 6.27-Διάγραμμα διασποράς πραγματικών και προβλεπόμενων εισροών για τον ταμιευτήρα της Μεσοχώρας για $LT=4$




Εικόνα 6.28-Προβλέψεις εισροών LSTM $LT=4$ για την Μεσοχώρα



Εικόνα 6.29-Προβλέψεις ενέργειας LSTM $LT=4$ για την Μεσοχώρα



Εικόνα 6.30-Προβλέψεις εισροών LSTM LT=12 για την Μεσοχώρα



Εικόνα 6.31-Προβλέψεις ενέργειας LSTM LT=12 για την Μεσοχώρα

Σε αντιστοιχία με το φράγμα των Κρεμαστών φαίνεται και στην παρούσα ανάλυση μια ικανότητα πρόβλεψης της μεταβλητότητας του επιπέδου τιμών τόσο σε όρους παραγωγής ενέργειας όσο και εισροών. Στην περίπτωση αυτή μάλιστα, που λόγω της κλίμακας του έργου η παραγωγή ενέργειας δεν είναι για μεγάλο διάστημα σταθερή (και ίση με τον στόχο πρωτεύουσας ενέργειας) βλέπουμε μία καλή επίδοση στην εκτίμηση των ακραίων τιμών παραγωγής ενέργειας για τις προβλέψεις με ορίζοντα δώδεκα μηνών, πολύ περισσότερο δε, για αυτές των τεσσάρων.


Τονίζεται βέβαια ξανά, ότι για τους 12 μήνες, δεν επιμείναμε στην βέλτιστη παραμετροποίηση του μοντέλου για λόγους υπολογιστικού φόρτου. Σημειώνεται ωστόσο ότι η απόκλιση των σφαλμάτων της Μεσοχώρας στο LSTM μοντέλο έχουν μικρότερη απόκλιση από αυτά του AR(1) σε σχέση με τα αντίστοιχα του ταμειυτήρα των Κρεμαστών. Ρόλο και εδώ φαίνεται να παίζει το εύρος των τιμών που κάνουν την εκπαίδευση του μοντέλου πιο εύκολη.

6.2.3 Εφαρμογή στον Ταμιευτήρα του Ευήνου


Τα αποτελέσματα του LSTM για το φράγμα του Ευήνου είναι, χωρίς τη χρήση σύνθετου μοντέλου, καλύτερα από τα αντίστοιχα του AR(1). Αυτή τη φορά όχι μόνο για προβλέψεις χρονικού ορίζοντα τεσσάρων μηνών αλλά και για αυτόν των δώδεκα. Φυσικά τα σφάλματα ενέργειας δεν εξομαλύνονται στον ίδιο βαθμό με τα άλλα 2 φράγματα αλλά αυτό είναι αποκλειστικά θέμα κλίμακας έργου. Κατά την εκπαίδευση, η συνάρτηση σφάλματος καταλήγει να έχει τιμή $loss = 0.0083$.

ERROR METRICS	ΕΥΗΝΟΣ		ERROR METRICS	ΕΥΗΝΟΣ	
	LSTM			LSTM	
	ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ		ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ
	LEAD TIME = 4			LEAD TIME = 12	
MAPE (%)	65.95	21.99	MAPE (%)	69.08	33.7
MPE (%)	-34.72	-7.02	MPE (%)	-40.4	-15.7
RMSE	15.25	3.13	RMSE	16.2	3.5
R ²	0.5	0.4	R ²	0.49	0.3


Πίνακας 6.6-Μετρικές Σφαλμάτων μοντέλου LSTM για Lead time = 4 και Lead time=12 στον ταμιευτήρα Ευήνου



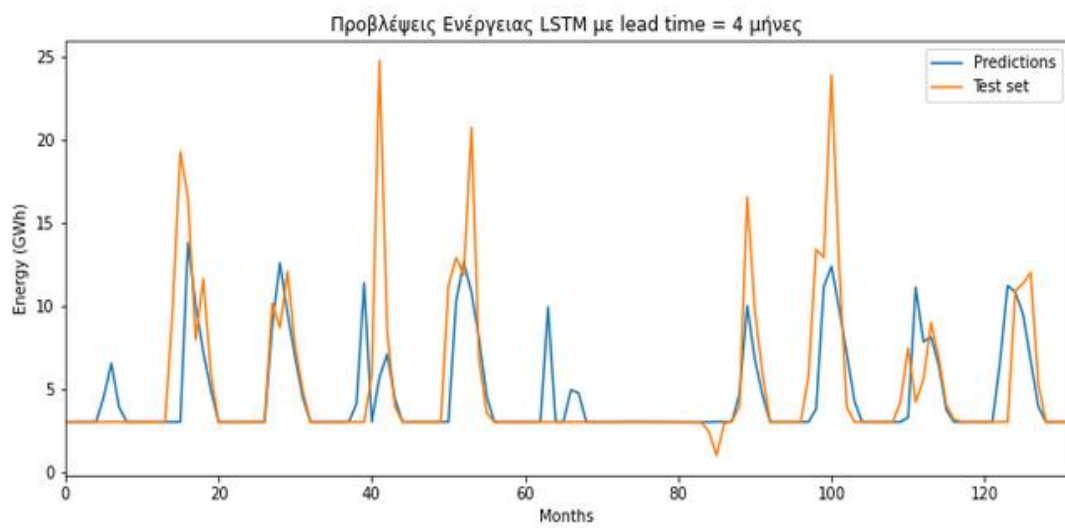
Εικόνα 6.32-Διάγραμμα διασποράς πραγματικών και προβλεπόμενων εισροών για τον ταμιευτήρα του Ευήνου για LT=4




Εικόνα 6.33-Διάγραμμα διασποράς πραγματικών και προβλεπόμενων εισροών για τον ταμιευτήρα του Εύηνου για $LT=12$




Εικόνα 6.34-Προβλέψεις εισροών LSTM $LT=4$ για τον Εύηνο



Εικόνα 6.35-Προβλέψεις ενέργειας LSTM $LT=4$ για τον Εύηνο



Εικόνα 6.36-Προβλέψεις εισροών LSTM LT=12 για τον Εύηνο



Εικόνα 6.37-Προβλέψεις ενέργειας LSTM LT=12 για τον Εύηνο

Παρατηρούμε ότι το μοντέλο όταν εφαρμόζεται στα δεδομένα εισροών του Εύηνου, έχει μεγαλύτερη ακρίβεια σε μέσες και χαμηλές ροές σε σχέση με τους 2 άλλους ταμειυτήρες, ενώ διατηρεί την ικανότητα του να προβλέπει ικανοποιητικά τη μεταβλητότητα του επιπέδου των υψηλών τιμών. Αυτό μας οδηγεί ασφαλώς στη γενίκευση ότι το LSTM μοντέλο είναι καταλληλότερο από το AR(1) για φράγματα στην χωρητικότητα του Εύηνου σε συνδυασμό με τα κλιματικά δεδομένα της περιοχής.

6.3 Προβλέψεις με το Μοντέλο KNN

Τις τελευταίες δεκαετίες παρουσιάστηκε η χρήση τεχνικών υπολογιστικής νοημοσύνης για την πρόβλεψη χρονοσειρών. Αν και τα τεχνητά νευρωνικά δίκτυα είναι η πιο σημαντική τεχνική μηχανικής μάθησης που χρησιμοποιείται στην πρόβλεψη χρονοσειρών, έχουν εφαρμοστεί και άλλες προσεγγίσεις, όπως το KNN. Σε σύγκριση με τα κλασικά στατιστικά μοντέλα, οι μέθοδοι υπολογιστικής νοημοσύνης παρουσιάζουν ενδιαφέροντα χαρακτηριστικά, όπως η μη γραμμικότητά τους ή η έλλειψη υποκείμενου μοντέλου, δηλαδή είναι μη παραμετρικές.

Ο KNN είναι ένας πολύ δημοφιλής αλγόριθμος που χρησιμοποιείται στην ταξινόμηση και την παλινδρόμηση. Αυτός ο αλγόριθμος αποθηκεύει απλώς μια συλλογή παραδειγμάτων. Κάθε παράδειγμα αποτελείται από ένα διάνυσμα χαρακτηριστικών (που περιγράφει το παράδειγμα) και τη σχετική κλάση του (για ταξινόμηση) ή αριθμητική τιμή (για πρόβλεψη). Με ένα νέο παράδειγμα, το KNN βρίσκει τα k πιο παρόμοια παραδείγματά του (που ονομάζονται πλησιέστεροι γείτονες), σύμφωνα με μια μετρική απόστασης (όπως η Ευκλείδεια απόσταση) και προβλέπει την κλάση του ως την πλειοψηφική τάξη των πλησιέστερων γειτόνων του ή, στην περίπτωση της παλινδρόμησης, ως συνάθροιση των τιμών στόχου που σχετίζονται με τους πλησιέστερους γείτονές του. Σε αυτή την εργασία ο αλγόριθμος δημιουργήθηκε σε περιβάλλον Python με χρήση της βιβλιοθήκης *sklearn* για πρόβλεψη μονομεταβλητής χρονοσειράς εισροών χρησιμοποιώντας παλινδρόμηση KNN.

Η στρατηγική που ακολουθήθηκε είναι η ίδια με αυτή των νευρωνικών δικτύων (Multi-Input Multi-Output (MIMO)). Η έξοδος και εδώ αποτελεί την συνολική πρόβλεψη του εκάστοτε ορίζοντα. Χωρίζουμε τα δεδομένα σε train και test set. Στο train set έχουμε τα συνθετικά δεδομένα και στο test set τα ιστορικά στα οποία γίνεται και η σύγκριση όλων των μοντέλων.

```
In [6]: data_train = eisroes.iloc[:]['ΕΙΣΡΟΗ']
        data_test = eisroes_historic.iloc[348:]['ΕΙΣΡΟΗ']
        data_train[-20:]
```

Εικόνα 6.38-Δεδομένα εκπαίδευσης και δοκιμής όπως διαμορφώθηκαν σε περιβάλλον Python

Έπειτα δημιουργούμε κυλιόμενα παράθυρα στο σετ των δεδομένων εκπαίδευσης τα οποία αποτελούνται από διανύσματα εισόδου ανάλογα με το πόσα lags αποφασίζουμε

να επιλέξουμε, και από διανύσματα εξόδου που έχουν μέγεθος ίδιο με τον χρονικό ορίζοντα πρόβλεψης. Δοκιμάστηκαν υστερήσεις 12,24 και 36 μηνών για τα διανύσματα εισόδου.

```
In [8]: X_train , y_train = [], []

for i in range(12, len(data_train)-lead_time+1):
    X_train.append(data_train[i-12:i])
    y_train.append(data_train[i:i+lead_time])
```

Εικόνα 6.39-Δημιουργία κυλιόμενων παραθύρων για τα δεδομένα εκπαίδευσης

Στη συνέχεια έγινε μια τυποποίηση των τιμών χρησιμοποιώντας την συνάρτηση `MinMaxScaler()` για να βοηθήσουμε τον αλγόριθμο να κάνει πιο απλούς και ακριβείς υπολογισμούς.

```
In [2]: from sklearn.neighbors import KNeighborsRegressor
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import mean_squared_error
```

Εικόνα 6.40-Εισαγωγή των απαραίτητων βιβλιοθηκών για τη εφαρμογή του KNN μοντέλου

Σημαντική επιλογή για την αποτελεσματικότητα του μοντέλου είναι αυτή της παραμέτρου K . Η καλύτερη τιμή για το K είναι κάτι που πρέπει να βρεθεί εμπειρικά για κάθε σύνολο δεδομένων. Για να βρούμε την καλύτερη τιμή για το K , θα χρησιμοποιήσετε ένα εργαλείο που ονομάζεται `GridSearchCV`. Χρησιμοποιείται συχνά για τον συντονισμό υπερπαραμέτρων μοντέλων μηχανικής εκμάθησης. Στην περίπτωσή μας, θα βοηθήσει βρίσκοντας αυτόματα την καλύτερη τιμή του K για το σύνολο δεδομένων.


Το `GridSearchCV` είναι διαθέσιμο στο `scikit-learn` και έχει το πλεονέκτημα ότι χρησιμοποιείται σχεδόν με τον ίδιο τρόπο όπως τα μοντέλα `scikit-learn`:

```
>>> from sklearn.model_selection import GridSearchCV
>>> parameters = {"n_neighbors": range(1, 50)}
>>> gridsearch = GridSearchCV(KNeighborsRegressor(), parameters)
>>> gridsearch.fit(X_train, y_train)
GridSearchCV(estimator=KNeighborsRegressor(),
              param_grid={'n_neighbors': range(1, 50),
                           'weights': ['uniform', 'distance']})
```

Εικόνα 6.41-Κώδικας για την εύρεση της κατάλληλης τιμής για την παράμετρο K του KNN μοντέλου μέσω μίας αυτοματοποιημένης διαδικασίας

Εδώ, χρησιμοποιούμε το GridSearchCV για να κάνουμε fit το μοντέλο. Εν ολίγοις, το GridSearchCV προσαρμόζει επανειλημμένα τους αναδρομείς KNN σε ένα μέρος των δεδομένων και ελέγχει τις επιδόσεις στο υπόλοιπο μέρος των δεδομένων. Κάνοντας αυτό επανειλημμένα θα αποφέρει μια αξιόπιστη εκτίμηση της προγνωστικής απόδοσης καθεμιάς από τις τιμές για το K. Δοκιμάζεται στις τιμές από 1 έως 50. Στο τέλος, θα διατηρήσει την τιμή K με την καλύτερη προγνωστική απόδοση και την χαμηλότερη βαθμολογία σφάλματος, την οποία θα βρούμε χρησιμοποιώντας την εντολή .best_params_.

Ουσιαστικά, προσαρμόζουμε το μοντέλο στα δεδομένα εκπαίδευσης και αξιολογούνται τα δεδομένα δοκιμής. Η χρήση του GridSearchCV για την εύρεση μιας τιμής για το k έχει μειώσει το πρόβλημα της υπερπροσαρμογής στα δεδομένα εκπαίδευσης.



Εικόνα 6.42-Διάγραμμα Σφάλματος-K μέσω του GridSearchCV

Μετά την επιλογή του κατάλληλου K, κάνουμε fit το μοντέλο στα δεδομένα μας παίρνουμε τις προβλέψεις και τις αποτυποποιούμε όπως φαίνεται στην εικόνα (5.43).

```
In [23]: model2 = KNeighborsRegressor(n_neighbors=8,metric='euclidean')
In [24]: model2.fit(X_train,y_train)
Out[24]: KNeighborsRegressor(metric='euclidean', n_neighbors=8)
In [25]: y_pred = model2.predict(X_test)
In [26]: len(y_pred)
Out[26]: 36
In [27]: y_pred=y_scaler.inverse_transform(y_pred)
         np.array(y_pred)
```

Εικόνα 6.43-Εφαρμογή του KNN μοντέλου και εύρεση τελικών προβλέψεων

6.3.3 Εφαρμογή στον Ταμιευτήρα των Κρεμαστών


Ο KNN είναι ένας αλγόριθμος που βασίζεται στην ομοιότητα που μπορεί να έχουν οι τιμές που θα έρθουν με αυτές που έχουν παρατηρηθεί στο παρελθόν. Όσο περισσότερα δεδομένα λοιπόν τόσο μεγαλύτερες θα είναι οι πιθανότητες για καλύτερες προβλέψεις. Χρησιμοποιήθηκαν έτσι, συνθετικά δεδομένα που προήλθαν από τα ιστορικά των Κρεμαστών.

Η γέννηση των συνθετικών χρονοσειρών έγινε μέσω του λογισμικού AnySim (Tsoukalas et al., 2020). Αυτό επιτρέπει τη σύζευξη πολλαπλών σχημάτων στοχαστικής προσομοίωσης διεργασιών, που ακολουθούν οποιαδήποτε δεδομένη στατιστική κατανομή και στοχαστική δομή στον χώρο και τον χρόνο, σε διάφορες χρονικές κλίμακες ενδιαφέροντος, και μπορεί επίσης να αλλάζουν εποχιακά. Ακρογωνιαίος λίθος της όλης προσέγγισης είναι το από κοινού μοντέλο πιθανότητας Nataf, που σχετίζεται με τη γκαουσιανή copula, και επιτρέπει την μοντελοποίηση τυχαίων μεταβλητών από οποιαδήποτε κατανομή, δεσμευμένων ή μη, καθώς και στοχαστικών διεργασιών.


Πέρα από την ορθή προετοιμασία των δεδομένων σε επίπεδο κωδικοποίησης, η δυσκολία του αλγορίθμου KNN έχει να κάνει με την επιλογή της κατάλληλης τιμής για την παράμετρο K, έτσι ώστε να αποφευχθούν φαινόμενα υπερπροσαρμογής. Μόλις αυτό το εμπόδιο ξεπεραστεί το μοντέλο δεν επιδέχεται περαιτέρω βελτιώσεων. Οι μόνες παράμετροι που χρειάζεται να δοκιμαστούν είναι αυτές των διανυσμάτων εισόδου. Για τον ταμιευτήρα των Κρεμαστών παρουσιάζονται παρακάτω τα αποτελέσματα. Τα αθροιστικά σφάλματα είναι εμφανώς μεγαλύτερα από αυτά του LSTM μοντέλου.

ERROR METRICS	ΚΡΕΜΑΣΤΑ		ERROR METRICS	ΚΡΕΜΑΣΤΑ	
	KNN			KNN	
	ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ		ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ
	LEAD TIME = 4			LEAD TIME = 12	
MAPE (%)	67.4	1.74	MAPE (%)	72.3	6.36
MPE (%)	-51.3	-0.51	MPE (%)	-55.2	-3.75
RMSE	155.9	6.32	RMSE	167.8	12.57
R ²	0.54	0.67	R ²	0.46	0.29


Πίνακας 6.7-Μετρικές Σφαλμάτων μοντέλου KNN για Lead time = 4 και Lead time=12 στον ταμιευτήρα Κρεμαστών




Εικόνα 6.44-Διάγραμμα διασποράς πραγματικών και προβλεπόμενων εισροών για τον ταμιευτήρα του Κρεμαστών για $LT=4$



Εικόνα 6.45-Διάγραμμα διασποράς πραγματικών και προβλεπόμενων εισροών για τον ταμιευτήρα των Κρεμαστών για $LT=12$




Εικόνα 6.46-Προβλέψεις εισροών KNN $LT=4$ για τα Κρεμαστά




Εικόνα 6.47-Προβλέψεις ενέργειας KNN LT=4 για τα Κρεμαστά

Παρατηρούνται ομοιότητες σε σχέση με την επίδοση του LSTM μοντέλου για χρονικό ορίζοντα 4 μηνών (Lead Time=4). Και εδώ υπάρχει δυσκολία στην εκτίμηση μέσω και χαμηλών ροών, ενώ είναι εμφανής η ικανότητα εντοπισμού της μεταβλητότητας του επιπέδου τιμών στις εισροές.



Εικόνα 6.48-Προβλέψεις εισροών KNN LT=12 για τα Κρεμαστά



Εικόνα 6.49-Προβλέψεις ενέργειας KNN LT=12 για τα Κρεμαστά


Αντίθετα, για τους δώδεκα μήνες η μεταβλητότητα των υψηλών τιμών δεν είναι τόσο έντονη και η συνολικότερη αποτελεσματικότητα του μοντέλου μειώνεται ακόμα και σε σύγκριση με το φειδωλό AR(1).

6.3.2 Εφαρμογή στον Ταμιευτήρα της Μεσοχώρας


Παρατηρώντας τον Πίνακα (6.8) βλέπουμε ότι τα ποσοστιαία σφάλματα του KNN σε σχέση με αυτά τα Κρεμαστών για LT=4 είναι ακριβώς τα ίδια. Αυτό συμβαίνει διότι το διάνυσμα εισόδου έχει το ίδιο μήκος και για τις 2 αναλύσεις όπως ίδια είναι και η επιλογή της παραμέτρου K . Έτσι, καταλαβαίνουμε πως σε αντίθεση με το LSTM μοντέλο η κλίμακα των τιμών των δεδομένων δε παίζει κανένα ρόλο στην τελική επίδοση. Με μία πρώτη ματιά στα αθροιστικά σφάλματα του πίνακα (5.8) βλέπουμε πως η επίδοση του KNN είναι η χειρότερη εκ των τριών μοντέλων, ωστόσο κρίνεται αξιοπρεπής και πρέπει να ληφθεί υπόψη ο ελάχιστος υπολογιστικός φόρτος που απαιτεί.

ERROR METRICS	ΜΕΣΟΧΩΡΑ		ERROR METRICS	ΜΕΣΟΧΩΡΑ	
	KNN			KNN	
	ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ		ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ
	LEAD TIME = 4			LEAD TIME = 12	
MAPE (%)	67.4	22.8	MAPE (%)	74.8	59.8
MPE (%)	-51.3	-14	MPE (%)	-59.2	-52.6
RMSE	27.6	7.4	RMSE	29.7	9.3
R ²	0.54	0.52	R ²	0.47	0.32


Πίνακας 6.8-Μετρικές Σφαλμάτων μοντέλου KNN για Lead time = 4 και Lead time=12 στον ταμιευτήρα Μεσοχώρας




Εικόνα 6.50-Διάγραμμα διασποράς πραγματικών και προβλεπόμενων εισροών για τον ταμιευτήρα της Μεσοχώρας για LT=4




Εικόνα 6.51-Διάγραμμα διασποράς πραγματικών και προβλεπόμενων εισροών για τον ταμιευτήρα της Μεσοχώρας για $LT=12$




Εικόνα 6.52-Προβλέψεις εισροών KNN $LT=4$ για τη Μεσοχώρα



Εικόνα 6.53-Προβλέψεις ενέργειας KNN $LT=4$ για τη Μεσοχώρα



Εικόνα 6.54-Προβλέψεις εισροών KNN LT=12 για τη Μεσοχώρα



Εικόνα 6.55-Προβλέψεις ενέργειας KNN LT=12 για τη Μεσοχώρα


Παρατηρείται η ικανότητα του μοντέλου να ακολουθήσει τα επίπεδα τιμών. Παρουσιάζει παρόμοια επίδοση με το LSTM στις μέσες και χαμηλές ροές. Θα μπορούσε να χρησιμοποιηθεί σε αναλύσεις φραγμάτων με μεγάλη αποθηκευτική ικανότητα όπως αυτό των Κρεμαστών.

6.3.3 Εφαρμογή στον Ταμιευτήρα του Ευήνου


ERROR METRICS	ΕΥΗΝΟΣ		ERROR METRICS	ΕΥΗΝΟΣ	
	KNN			KNN	
	ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ		ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ
	LEAD TIME = 4			LEAD TIME = 12	
MAPE (%)	78.7	24.1	MAPE (%)	75	35.6
MPE (%)	-48.3	-7.8	MPE (%)	-48	-18.2
RMSE	17.4	3.6	RMSE	17.1	3.9
R ²	0.43	0.36	R ²	0.47	0.32

Πίνακας 6.9-Μετρικές Σφαλμάτων μοντέλου KNN για Lead time = 4 και Lead time=12 στον ταμιευτήρα Ευήνου


Στην περίπτωση του Ευήνου τα πράγματα δε διαφοροποιούνται. Το μοντέλο υστερεί σε σχέση με τα υπόλοιπα 2 και αυτό όταν η αποθηκευτική ικανότητα του ταμιευτήρα δεν είναι σημαντική γίνεται ακόμα μεγαλύτερο πρόβλημα. Εν τέλει δε βρέθηκε κάποιο φράγμα με χαρακτηριστικά που να ευνοούν την εφαρμογή ενός μοντέλου όπως το KNN.



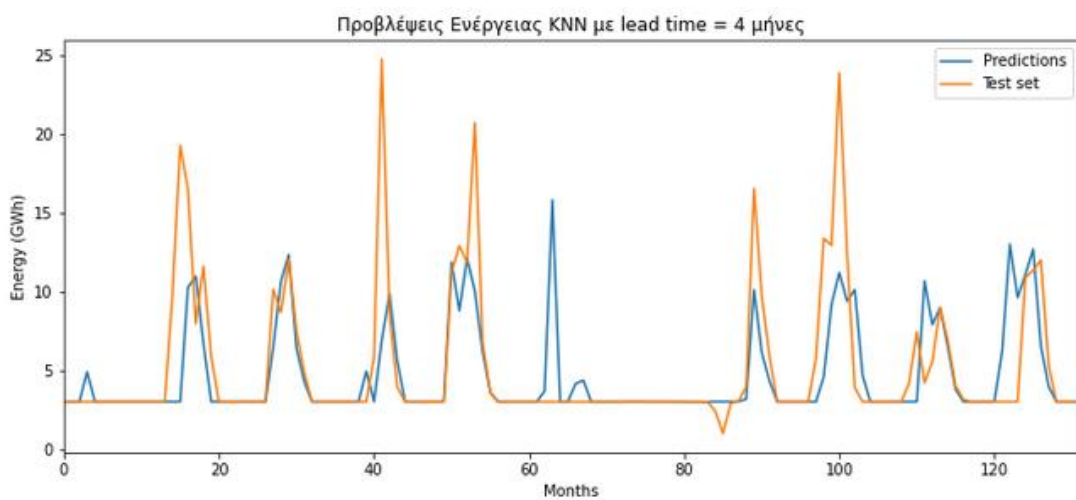
Εικόνα 6.56-Διάγραμμα διασποράς πραγματικών και προβλεπόμενων εισροών για τον ταμιευτήρα του Ευήνου για LT=4




Εικόνα 6.57-Διάγραμμα διασποράς πραγματικών και προβλεπόμενων εισροών για τον ταμιευτήρα του Ευήνου για $LT=12$




Εικόνα 6.58-Προβλέψεις εισροών KNN $LT=4$ για τον Εύηνο



Εικόνα 6.59-Προβλέψεις ενέργειας KNN $LT=4$ για τον Εύηνο



Εικόνα 6.60-Προβλέψεις εισροών KNN $LT=12$ για τον Εύηνο



Εικόνα 6.61-Προβλέψεις ενέργειας KNN $LT=12$ για τον Εύηνο

6.4 Δείκτης Οικονομικής Αξιολόγησης Μοντέλων και Σύγκριση Αποτελεσμάτων

Πέρα από την αξιολόγηση της αποτελεσματικότητας των μοντέλων πρόγνωσης, χρήσιμο είναι να πραγματοποιηθεί και μία οικονομική αξιολόγηση ώστε να φανεί με πιο άμεσο τρόπο η επιρροή των πλεονασμάτων και των ελλειμμάτων στις τελικές προγνώσεις.

Για το σκοπό αυτό υποθέτουμε μία οικονομική μονάδα για την οποία θα γίνονται οι παραδοχές που φαίνονται στον Πίνακα (5.10)

Τιμή πώλησης πρωτεύουσας ενέργειας	0.10 €/kWh
Τιμή πώλησης δευτερεύουσας ενέργειας	0.05 €/kWh
Ρήτρα ελλείμματος ενέργειας	1.0 €/kWh

Πίνακας 6.10-Παραδοχές για τιμές πώλησης πρωτεύουσας, δευτερεύουσας ενέργειας και ρήτρας ελλείμματος

Οι προβλεπόμενες τιμές ενέργειας για κάθε βήμα θεωρούνται μηνιαίοι στόχοι πρωτεύουσας ενέργειας. Εάν η πραγματική ενέργεια που παράγεται είναι μεγαλύτερη από τον στόχο πρωτεύουσας τότε το κέρδος θα προκύπτει από την πώληση της πρωτεύουσας στην αντίστοιχη τιμή και του πλεονάσματος στην τιμή της δευτερεύουσας ενέργειας. Αντίθετα αν παραχθεί ενέργεια τιμής χαμηλότερης από αυτή του στόχου, τότε η ενέργεια αυτή θα πωληθεί ως πρωτεύουσα και για το έλλειμμα προβλέπεται μία ποινή-ρήτρα. Η υλοποίηση των παραπάνω στην *Python* φαίνεται στην Εικόνα (6.62).

```

ΟΙΚΟΝΟΜΙΚΗ ΑΞΙΟΛΟΓΗΣΗ

In [92]: kerdos=np.zeros(156)
         wfelos_prwteuousas=0.1
         wfelos_deytereiousas=0.05
         rhtra_elleimatos=1
         for i in range(156):
             if errors1_sim[i]>=0:
                 kerdos[i] = -(tests_sim_energy[i]-preds_sim_energy[i])*rhtra_elleimatos +
                             preds_sim_energy[i] * wfelos_prwteuousas
             else:
                 kerdos[i] = tests_sim_energy[i]* wfelos_prwteuousas - (preds_sim_energy[i]-
                             tests_sim_energy[i])*wfelos_deytereiousas

In [95]: np.mean(kerdos)
Out[95]: 6.004396035405329

```

Εικόνα 6.62- Κώδικας για την οικονομική αξιολόγηση των προβλέψεων σε περιβάλλον Python

Στους πίνακες (6.11-6.16) παρουσιάζονται τα ομαδοποιημένα συγκριτικά αποτελέσματα για κάθε φράγμα και χρονικό ορίζοντα πρόβλεψης ξεχωριστά και συμπεριλαμβάνεται ο δείκτης οικονομικής αξιολόγησης.

ERROR METRICS	ΚΡΕΜΑΣΤΑ					
	AR(1)		LSTM		KNN	
	ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ	ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ	ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ
	LEAD TIME = 4		LEAD TIME = 4		LEAD TIME = 4	
MAPE (%)	51.69	1.86	45.34	1.73	67.4	1.74
MPE (%)	-30.34	-0.62	-29.31	-0.6	-51.3	-0.51
RMSE	149.69	5.69	140.1	5.21	155.9	6.32
R ²	0.57	0.7	0.59	0.73	0.54	0.67
ΚΕΡΔΟΣ(εκ. €/μήνα)	5.99		6.05		5.93	

Πίνακας 6.11-Συγκριτικά Αποτελέσματα όλων των Μοντέλων για τον ταμιευτήρα των Κρεμαστών με LT=4

ERROR METRICS	ΜΕΣΟΧΩΡΑ					
	AR(1)		LSTM		KNN	
	ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ	ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ	ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ
	LEAD TIME = 4		LEAD TIME = 4		LEAD TIME = 4	
MAPE (%)	51.69	16.87	50.3	15.7	67.4	22.8
MPE (%)	-30.34	-6.55	-31.4	-6.8	-51.3	-14
RMSE	26.49	7.08	26.3	5.88	27.6	7.4
R ²	0.57	0.55	0.58	0.66	0.54	0.52
ΚΕΡΔΟΣ(εκ. €/μήνα)	0.86		0.91		0.12	

Πίνακας 6.12-Συγκριτικά Αποτελέσματα όλων των Μοντέλων για τον ταμιευτήρα της Μεσοχώρας με LT=4

ERROR METRICS	ΕΥΗΝΟΣ					
	AR(1)		LSTM		KNN	
	ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ	ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ	ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ
	LEAD TIME = 4		LEAD TIME = 4		LEAD TIME = 4	
MAPE (%)	67.6	22.8	65.95	21.99	78.7	24.1
MPE (%)	-43.22	-9.7	-34.72	-7.02	-48.3	-7.8
RMSE	16.05	3.22	15.25	3.13	17.4	3.6
R ²	0.51	0.46	0.5	0.4	0.43	0.36
ΚΕΡΔΟΣ(εκ. €/μήνα)	-0.08		-0.02		-0.06	

Πίνακας 6.13-Συγκριτικά Αποτελέσματα όλων των Μοντέλων για τον ταμιευτήρα του Ευήνου με LT=4

ERROR METRICS	ΚΡΕΜΑΣΤΑ					
	AR(1)		LSTM		KNN	
	ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ	ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ	ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ
	LEAD TIME = 12		LEAD TIME = 12		LEAD TIME = 12	
MAPE (%)	53.6	4.5	65.6	7.14	72.3	6.36
MPE (%)	-32.16	-2.78	-49	-6.6	-55.2	-3.75
RMSE	150.89	10.2	164.1	13.2	167.8	12.57
R ²	0.56	0.34	0.52	0.37	0.46	0.29
ΚΕΡΔΟΣ(εκ. €/μήνα)	4.42		2.25		3.4	

Πίνακας 6.14-Συγκριτικά Αποτελέσματα όλων των Μοντέλων για τον ταμιευτήρα των Κρεμαστόν με LT=12

ERROR METRICS	ΜΕΣΟΧΩΡΑ					
	AR(1)		LSTM		KNN	
	ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ	ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ	ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ
	LEAD TIME = 12		LEAD TIME = 12		LEAD TIME = 12	
MAPE (%)	53.6	45.94	64	57.1	74.8	59.8
MPE (%)	-32.16	-37	-49	-54.1	-59.2	-52.6
RMSE	26.71	8.54	27.24	8.4	29.7	9.3
R ²	0.56	0.34	0.54	0.43	0.47	0.32
ΚΕΡΔΟΣ(εκ. €/μήνα)	-0.57		-1.36		-1.94	

Πίνακας 6.15-Συγκριτικά Αποτελέσματα όλων των Μοντέλων για τον ταμιευτήρα της Μεσοχώρας με LT=12

ERROR METRICS	ΕΥΗΝΟΣ					
	AR(1)		LSTM		KNN	
	ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ	ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ	ΕΙΣΡΟΕΣ	ΕΝΕΡΓΕΙΑ
	LEAD TIME = 12		LEAD TIME = 12		LEAD TIME = 12	
MAPE (%)	70.2	36.6	69.08	33.7	75	35.6
MPE (%)	-45.2	-22.6	-40.4	-15.7	-48	-18.2
RMSE	16.6	3.7	16.2	3.5	17.1	3.9
R ²	0.47	0.29	0.49	0.3	0.47	0.32
ΚΕΡΔΟΣ(εκ. €/μήνα)	-0.49		-0.31		-0.4	

Πίνακας 6.16-Συγκριτικά Αποτελέσματα όλων των Μοντέλων για τον ταμιευτήρα του Ευήνου με LT=12

7. ΠΟΣΟΤΙΚΟΠΟΙΗΣΗ ΤΗΣ ΑΒΕΒΑΙΟΤΗΤΑΣ ΜΕ ΤΗ ΧΡΗΣΗ ΣΥΖΕΥΞΕΩΝ (COPULAS)

Η ποσοτικοποίηση της αβεβαιότητας είναι ένα αντικείμενο που έχει απασχολήσει έντονα την υδρολογική κοινότητα. Χαρακτηριστικές έρευνες είναι αυτές των Montanari and Koutsoyiannis (2012) και Todini (2008). Στην πρόσφατη εργασία των Koutsoyiannis and Montanari (2022), παρουσιάζεται μια νέα μέθοδος προσομοίωσης και πρόγνωσης υδρολογικών μεταβλητών. Στη δική μας περίπτωση, θα γίνει χρήση της μεθοδολογίας των συζεύξεων για πρόγνωση απορροής.

Από μια οπτική, οι συζεύξεις (copulas; Sklar, 1959; 1973) είναι συναρτήσεις που συνδέουν την πολυδιάστατη συνάρτηση κατανομής με τις μονοδιάστατες περιθώριες συναρτήσεις. Από την άλλη, οι συζεύξεις μπορούν να θεωρηθούν ως πολυδιάστατες συναρτήσεις κατανομών, των οποίων οι περιθώριες είναι ομοιόμορφες στο διάστημα $[0,1]$.

Οι συζεύξεις μπορεί να είναι ιδιαίτερα χρήσιμα εργαλεία για την ποσοτικοποίηση της προγνωστικής αβεβαιότητας ενός μοντέλου (\mathcal{M}), αφού επιτρέπουν την παραγωγή δεσμευμένων κατανομών (βλ., Tsoukalas (2018)). Συγκεκριμένα, έστω ότι τα Y^O και Y^M υποδηλώνουν τυχαίες μεταβλητές (TM) που αντιστοιχούν στα δεδομένα που παρατηρήθηκαν και μοντελοποιήθηκαν αντίστοιχα. Οι περιθώριες αθροιστικές συναρτήσεις κατανομής τους (CDF) συμβολίζονται με $F_{Y^O}(y_O)$ και $F_{Y^M}(y_M)$. Να σημειωθεί ότι το Y^M είναι συνάρτηση του προσδιοριστικού μοντέλου $\mathcal{M}(\theta)$, όπου το θ δηλώνει τις παραμέτρους του. Επιπλέον, η από κοινού αθροιστική συνάρτηση κατανομής (CDF) μεταξύ των Y^O και Y^M , μπορεί να εκφραστεί ως :

$$F(Y_O, Y_M) := P(Y_O \leq y_O, Y_M \leq y_M) = C(F_{Y^O}(y_O), F_{Y^M}(y_M)) = C(u_o, u_M) \quad (7.1)$$

όπου το $C(x, y)$ υποδηλώνει την σύζευξη (copula) CDF, καθώς και $u_o = F_{Y^O}(y_O)$ και $u_M = F_{Y^M}(y_M)$ είναι ομοιόμορφα κατανεμημένες τυχαίες μεταβλητές στο $[0, 1]$. Προκειμένου να ποσοτικοποιηθεί η προγνωστική αβεβαιότητα του μοντέλου, η ιδέα είναι να εφαρμοστεί η δεσμευμένη CDF, $F(Y_O|Y_M = y_M) := P(Y_O \leq y_O|Y_M = y_M)$ η οποία είναι,

$$F(Y_O|Y_M = y_M) = \frac{\partial C(u_o, u_M)}{\partial u_M} =: C_{O|M}(u_o|u_M) \quad (7.2)$$

όπου $C_{O|M}$ είναι η δεσμευμένη σύζευξη. Η δεσμευμένη κατανομή $C_{O|M}$ μπορεί να αντιστραφεί και να λυθεί για u_o , για δεδομένη πιθανότητα (μη υπέρβασης) $a := C_{O|M}$ (π.χ., a μπορεί εκφράζει το επίπεδο αβεβαιότητας 5, 50 ή 95%). Η παραπάνω διαδικασία μπορεί να γραφτεί και ως:

$$u_o^{a|u_M} = C_{O|M}^{-1}(a|u_M) \quad (7.3)$$

όπου $C_{O|M}^{-1}(a|u_M)$ είναι η αντίστροφη της $C_{O|M}(u_o|u_M)$.

Τέλος, για να βρούμε το $F_{(Y_O|Y_M)}^{-1}(a|y_M)$ το τελικό βήμα συνεπάγεται τη μετατροπή του $u_o^{a|u_M}$ από ομοιόμορφο πεδίο ορισμού στο στόχο χρησιμοποιώντας την αντίστροφη CDF της περιθώριας κατανομής του, δηλ.

$$y_o^{a|u_M} = F_{Y_O|Y_M}^{-1}(a|y_M) = F_{Y_O}^{-1}(u_o^{a|u_M}) = F_{Y_O}^{-1}(C_{O|M}^{-1}(a|u_M)) \quad (7.4)$$

Η αλλιώς γράφεται και ως,

$$y_o^{a|F_{Y_M}(y_M)} = F_{Y_O}^{-1}(C_{O|M}^{-1}(a|F_{Y_M}(y_M))) \quad (7.5)$$

Συγκεκριμένα, στην περίπτωση του Gaussian copula, η τελευταία εξίσωση γράφεται ως εξής,

$$y_o^{a|F_{Y_M}(y_M)} = F_{Y_O}^{-1}\left(\Phi\left(\theta\Phi^{-1}(F_{Y_M}(u_M)) + \sqrt{(1-\theta^2)}\Phi^{-1}(a)\right)\right) \quad (7.6)$$

Όπου το Φ συμβολίζει την μονομεταβλητή Gaussian CDF και θ είναι η παράμετρος του Gaussian copula (και συνδέεται με των συντελεστή συσχέτισης των παρατηρημένων και μοντελοποιημένων δεδομένων).

Για λόγους απλούστευσης, στην παρούσα εργασία χρησιμοποιείται το Gaussian copula. Γίνεται επίσης η θεώρηση ότι τα παρατηρημένα και τα μοντελοποιημένα δεδομένα ακολουθούν λογαριθμοκανονική κατανομή. Η παραδοχή αυτή μπορεί να θεωρηθεί εύλογη αφενός διότι οι εισροές δύναται να λάβουν μόνο θετικές τιμές, και αφετέρου μας διευκολύνει στην εύρεση της παραμέτρου θ . Στην περίπτωση της λογαριθμοκανονικής κατανομής η παράμετρος θ εκτιμάται μέσω της χρήσης αναλυτικής σχέσης (βλ. εξίσωση 7.9). Σε αντίθετη περίπτωση θα χρειαζόνταν αρκετά πιο σύνθετοι μαθηματικοί υπολογισμοί (μιας και στη γενική περίπτωση απαιτείται η επίλυση ενός διπλού ολοκληρώματος) που ξεφεύγουν από το σκοπό της παρουσίασης της συγκεκριμένης μεθοδολογίας.

Για την εκπαίδευση/βαθμονόμηση του μοντέλου χρησιμοποιήθηκαν τα ίδια ιστορικά δεδομένα του train set που χρησιμοποιήθηκαν και για τις σημειακές προβλέψεις και εφαρμόστηκαν οι παρακάτω σχέσεις για την εκτίμηση των παραμέτρων της λογαριθμοκανονικής κατανομής, αλλά και της παραμέτρου θ του Gaussian copula :


$$a := \mu_{\text{LogN}} = \ln \left(\frac{\mu}{\sqrt{1 + \frac{\sigma^2}{\mu^2}}} \right) \quad (7.7)$$

$$b^2 := \sigma_{\text{LogN}}^2 = \ln \left(1 + \frac{\sigma^2}{\mu^2} \right) \quad (7.8)$$


$$\theta = \frac{\ln(1+\rho) \sqrt{(\exp(b_1^2)-1)(\exp(b_2^2)-1)}}{b_1 b_2} \quad (7.9)$$

όπου, ρ ο συντελεστής συσχέτισης μεταξύ των παρατηρημένων και μοντελοποιημένων δεδομένων. Τελικά, με την εφαρμογή της παραπάνω μεθοδολογίας προκύπτουν τα διαγράμματα εισροών (εικόνες 7.2-7.7) των test set όπως αυτά χρησιμοποιήθηκαν και για τις σημειακές προβλέψεις του LSTM μοντέλου. Όλη η διαδικασία πραγματοποιήθηκε σε περιβάλλον *Excel 2016*.


Χρησιμοποιήθηκαν αποκλειστικά τα αποτελέσματα του LSTM μοντέλου όπως αυτά προέκυψαν μετά από τις αναλύσεις. Ο λόγος είναι ότι στην πλειοψηφία έχει την καλύτερη επίδοση όλων τα προσδιοριστικά μοντέλων. Ακόμα και για τις περιπτώσεις που κάτι τέτοιο δεν ισχύει, έχει ενδιαφέρον να δούμε κατά πόσο η μεθοδολογία που ακολουθούμε θα είναι αποτελεσματική.



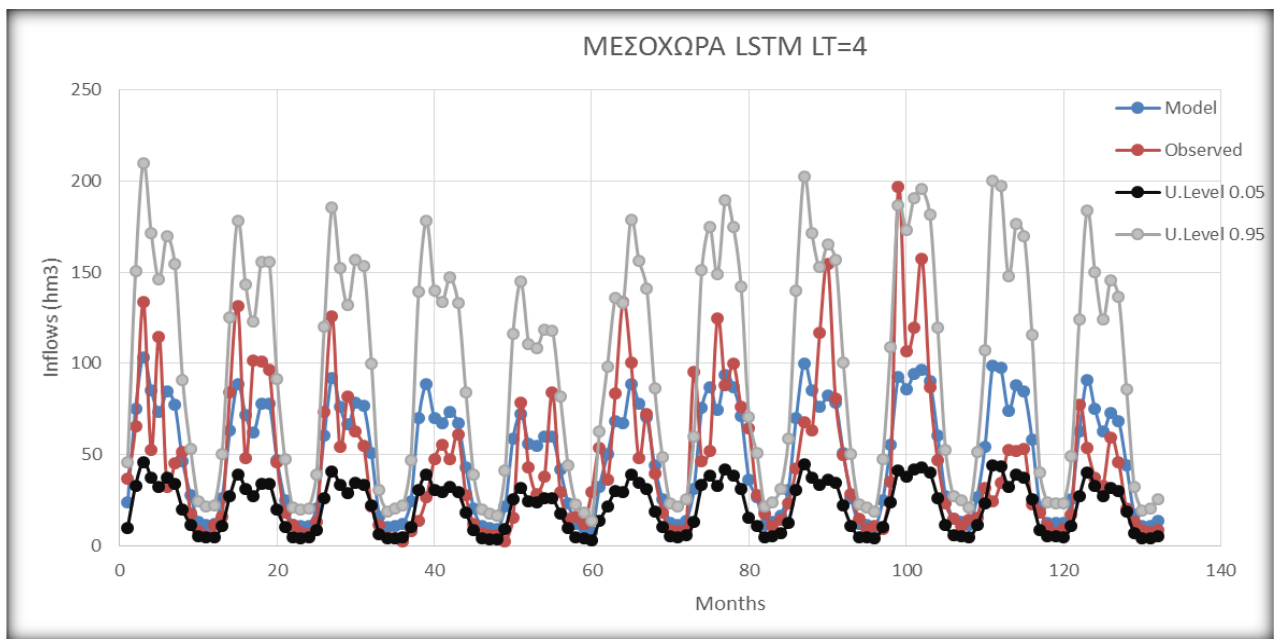
Εικόνα 7.1-Ενδεικτικό Διάγραμμα Διασποράς μεταξύ παρατηρημένων και μοντελοποιημένων (LSTM) δεδομένων με αποτυπωμένα τα επίπεδα αβεβαιότητας 5% και 95% για την ανάλυση των Κρεμαστών




Εικόνα 7.2- Χρονοσειρά προβλεπόμενων και πραγματικών εισροών στο set δοκιμής του ταμιευτήρα Κρεμαστήν για $LT=4$ με ενσωματωμένα τα επίπεδα αβεβαιότητας 5% και 95%




Εικόνα 7.3- Χρονοσειρά προβλεπόμενων και πραγματικών εισροών στο set δοκιμής του ταμιευτήρα Κρεμαστήν για $LT=12$ με ενσωματωμένα τα επίπεδα αβεβαιότητας 5% και 95%




Εικόνα 7.4- Χρονοσειρά προβλεπόμενων και πραγματικών εισροών στο set δοκιμής του ταμιευτήρα Μεσοχώρας για $LT=4$ με ενσωματωμένα τα επίπεδα αβεβαιότητας 5% και 95%



Εικόνα 7.5- Χρονοσειρά προβλεπόμενων και πραγματικών εισροών στο set δοκιμής του ταμιευτήρα Μεσοχώρας για $LT=12$ με ενσωματωμένα τα επίπεδα αβεβαιότητας 5% και 95%



Εικόνα 7.6- Χρονοσειρά προβλεπόμενων και πραγματικών εισροών στο set δοκιμής του ταμιευτήρα Ευήνου για $LT=4$ με ενσωματωμένα τα επίπεδα αβεβαιότητας 5% και 95%



Εικόνα 7.7- Χρονοσειρά προβλεπόμενων και πραγματικών εισροών στο set δοκιμής του ταμιευτήρα Ευήνου για $LT=12$ με ενσωματωμένα τα επίπεδα αβεβαιότητας 5% και 95%

Παρατηρούμε ότι στη συντριπτική πλειονότητα των περιπτώσεων οι παρατηρημένες χρονοσειρές εισροών είναι μέσα στα επίπεδα αβεβαιότητας που έχουν δοθεί ακόμα και στις περιπτώσεις που το LSTM δεν είναι το καλύτερο σε επίδοση. Αυτό δείχνει πως η μεθοδολογία δουλεύει σωστά. Φανερό είναι επίσης η μεγάλη αβεβαιότητα που παρατηρείται. Παρά το γεγονός αυτό, βλέπουμε πως η εξομάλυνση των σφαλμάτων σε όρους ενέργειας είναι σημαντική για όλα τα έργα όπως φαίνεται στις Εικόνες (6.22-6.35) του προηγούμενου Κεφαλαίου. Αυτός ήταν άλλωστε ένας βασικός ο στόχος της εργασίας, να δούμε δηλαδή, το κατά πόσον και με ποιο τρόπο μπορούν να απορροφηθούν τα σφάλματα ενέργειας ανάλογα με τα χαρακτηριστικά κάθε ταμιευτήρα και της αναρρυθμιστικής του ικανότητας. Αντικείμενο μελλοντικής έρευνας θα μπορούσε να είναι η δημιουργία κατάλληλης μεθοδολογίας μέσω των συζεύξεων που θα εκμεταλλεύεται την αβεβαιότητα των εισροών και να τη μεταφράζει σε όρους ενέργειας.

Είναι πλέον θέμα του διαχειριστή το τι επίπεδο αβεβαιότητας θα επιλέξει, το πόσο θέλει να ρισκάρει. Είναι προετοιμασμένος για όλα τα σενάρια, αισιόδοξα ή απαισιόδοξα. Πεδίο έρευνας θα μπορούσε να αποτελέσει η διερεύνηση του ακριβούς επιπέδου αβεβαιότητας που θα είναι πιο κερδοφόρο για κάθε έργο.

Όσο καλό και ακριβές να είναι ένα προσδιοριστικό υπόδειγμα πρόγνωσης, όταν μιλάμε για καιρικά φαινόμενα δε γίνεται να αγνοούμε τον χαοτικό τους χαρακτήρα. Η δημιουργία μοντέλου πρόγνωσης που να λαμβάνει υπόψη την αβεβαιότητα κρίνεται αναγκαία.

8. ΣΥΜΠΕΡΑΣΜΑΤΑ ΚΑΙ ΠΡΟΤΑΣΕΙΣ

Ο σκοπός της εργασίας ήταν να δώσει απαντήσεις σε πρακτικά ζητήματα που αφορούν την πρόγνωση παραγωγής ενέργειας σε μεγάλους υδροηλεκτρικούς ταμιευτήρες με συγκεκριμένα χαρακτηριστικά. Το πρώτο σκέλος της έχει να κάνει με σημειακές προγνώσεις. Ωστόσο, όσο περνούσε ο καιρός έγινε αντιληπτή η μεγάλη σημασία της ποσοτικοποίησης της αβεβαιότητας και η αναγκαιότητά της. Έτσι το δεύτερο σκέλος της εργασίας εστίασε στην δημιουργία ενός μοντέλου που να την λαμβάνει υπόψη.

Έχοντας πια μια ολοκληρωμένη εικόνα μπορούμε να εστιάσουμε στα συγκεκριμένα συμπεράσματα που προέκυψαν με την ολοκλήρωση της έρευνας. Αρχικά, το LSTM μοντέλο έχει την καλύτερη εικόνα σε όλα τα μέτρα επίδοσης στις αναλύσεις με χρονικό ορίζοντα πρόβλεψης τους 4 μήνες και για τους 3 ταμιευτήρες. Όσον αφορά στους 12 μήνες, εκεί το LSTM υπερέχει μόνο στην περίπτωση του ταμιευτήρα στον Εύηνο. Παρόλα αυτά σημαντικότερο εξαγόμενο αποτελεί το γεγονός πως το συγκεκριμένο μοντέλο μπορεί να διακρίνει και να εντοπίσει την μεταβλητότητα του επιπέδου τιμών σε αρκετά πιο ικανοποιητικό βαθμό σε σχέση με τα άλλα 2 μοντέλα.

Αντίθετα, στις μέσες και χαμηλές ροές η επίδοση του είναι χειρότερη σε σχέση με αυτή του απλού AR(1). Το γεγονός αυτό γεννά την ιδέα δημιουργίας ενός υβριδικού μοντέλου που θα εκμεταλλεύεται τα δυνατά στοιχεία των 2 επιμέρους μοντέλων. Τους χειμερινούς μήνες με τις έντονες καιρικές συνθήκες και τις απρόβλεπτες υψηλές τιμές εισροών θα χρησιμοποιείται το LSTM, ενώ τους καλοκαιρινούς μήνες το AR(1). Το μοντέλο αυτό αποτελεί πρόταση της εργασίας για περαιτέρω έρευνα.

Η επίδοση του AR(1) ήταν μια ευχάριστη έκπληξη. Στην αρχή επιλέχτηκε με το ρόλο του baseline μοντέλου ως φειδωλό και απλό. Στην πορεία όμως διαδραμάτισε σημαντικό ρόλο στις αναλύσεις. Ειδικά για το φράγμα των Κρεμαστών, αν το ζητούμενο είναι αποκλειστικά η ενεργειακή παραγωγή, τα σφάλματα εξομαλύνονται σε τέτοιο βαθμό που δεν έχει νόημα η εφαρμογή ενός πιο σύνθετου μοντέλου όπως του LSTM, ειδικά αν αυτό έχει τόσες απαιτήσεις σε υπολογιστικό φόρτο. Ακόμα και ένα πολύ σύνθετο LSTM με αυτοματοποιημένη παραμετροποίηση, έδωσε ελαφρώς

καλύτερα αποτελέσματα. Χωρίς αυτό να σημαίνει ότι με ισχυρότερο H/Y τα σφάλματα δε θα ήταν μικρότερα.

Από την άλλη ο αλγόριθμος KNN είχε χειρότερη επίδοση από αυτή που αναμέναμε. Μπορεί τα συνθετικά δεδομένα που χρησιμοποιήθηκαν να βοήθησαν (λόγω της φύσης του μοντέλου) ωστόσο δεν στάθηκαν αρκετά σε σύγκριση πάντα με τα άλλα 2 μοντέλα. Φυσικά, ο μικρός υπολογιστικός φόρτος που απαιτεί και η σχετική ευκολία στην εφαρμογή το καθιστούν αξιόπιστη επιλογή για φράγματα με μεγάλη χωρητικότητα και δυνατότητα σημαντικής αναρρύθμισης των εισροών νερού. Στα θετικά του, η ικανότητα του να αντιλαμβάνεται σε ικανοποιητικό βαθμό την μεταβλητότητα των τιμών. Μπορεί να υστέρησε σε σχέση με τα άλλα 2 μοντέλα παραμένουν όμως αξιοπρεπείς οι προγνώσεις που έδωσε, δίνοντας αξία στην επιλογή για τη μελέτη της επίδοσής του.

Η εργασία εστιάζει όπως είπαμε, στην πρόγνωση παραγωγής ενέργειας σε μεσοπρόθεσμη και μακροπρόθεσμη κλίμακα. Ο διαχειριστής του έργου λοιπόν θα έχει μία πληροφορία-εκτίμηση για τους επόμενους 4 μήνες (ή παραπάνω). Θα είχε μεγάλο ενδιαφέρον το κατά πόσο και με ποιον τρόπο θα μπορούσε να διαχειριστεί τα τυχόντα ελλείμματα (ή ακόμα και πλεονάσματα) που θα προέκυπταν με βέλτιστο τρόπο. Θα μας ήταν ιδιαίτερα ευχάριστο να γίνει μία σχετική έρευνα στο μέλλον.

Όσον αφορά την οικονομική αξιολόγηση, με βάση τις παραδοχές της ψευδό-οικονομικής μονάδας που θεωρήθηκε, ενδιαφέρον στοιχείο αποτελεί το γεγονός ότι μόνο στους ταμιευτήρες Μεσοχώρας και Κρεμαστών για $LT=4$ και Κρεμαστών για $LT=12$, ο δείκτης οικονομικής αξιολόγησης λαμβάνει θετικές τιμές. Ίσως αυτό μας οδηγεί στο συμπέρασμα πως για υδροηλεκτρικούς ταμιευτήρες χωρίς μεγάλη αποθηκευτική ικανότητα δεν έχει νόημα η μακροπρόθεσμη πρόγνωση παρά μόνο βραχυπρόθεσμη και μεσοπρόθεσμη.

Από την οικονομική αξιολόγηση προκύπτει επίσης πως και πάλι το LSTM έχει τους υψηλότερους δείκτες κέρδους για όλες τις αναλύσεις με $LT=4$ και για αυτή του Ευήνου με $LT=12$. Παρατηρώντας τους ίδιους δείκτες είναι εμφανές πως λανθασμένη επιλογή

μοντέλου πρόγνωσης μπορεί να στοιχίσει σε ετήσια κλίμακα πολλά εκατομμύρια ευρώ, γεγονός που αναδεικνύει την πρακτική σημασία της έρευνας που πραγματοποιήσαμε.

Σε ένα αντικείμενο μελέτης που η κρίση και οι αποφάσεις του διαχειριστή του έργου είναι τόσο καθοριστικές δε νοείται να μη ληφθεί υπόψη η αβεβαιότητα. Οι συζεύξεις, ως πολυδιάστατες συναρτήσεις κατανομών, είναι πολύ χρήσιμα εργαλεία και η μεθοδολογία που παρουσιάστηκε θα μπορούσε να βοηθήσει σημαντικά στη λήψη αποφάσεων. Το επίπεδο αβεβαιότητας ορίζεται από τον διαχειριστή και συνεπώς μπορεί να έχει στα χέρια του όλα τα πιθανά σενάρια. Αντικείμενο μελλοντικής έρευνας θα μπορούσε να είναι ο συνδυασμός δύο ή και περισσότερων ντετερμινιστικών μοντέλων που μέσω των συζεύξεων θα δημιουργούσαν μία ακόμα πιο αξιόπιστη πιθανοτική μέθοδο πρόγνωσης.

ΒΙΒΛΙΟΓΡΑΦΙΑ

1. Abadi, M., et al., “TensorFlow: A system for large-scale machine learning,”2016.
2. Ahmad, A., El-Shafie, A., Razali, S. F. M., and Mohamad, Z. S.: Reservoir Optimization in Water Resources: a Review, *Water Resour. Manage.*, 28, 3391–3405, <https://doi.org/10.1007/s11269-014-0700-5>, 2014.
3. Alemu, E. T., Palmer, R. N., Polebitski, A., and Meaker, B.: Decision Support System for Optimizing Reservoir Operations Using Ensemble Streamflow Predictions, *J. Water Resour. Plan. Manage.*, 137, 72–82, [https://doi.org/10.1061/\(ASCE\)WR.1943-5452.0000088](https://doi.org/10.1061/(ASCE)WR.1943-5452.0000088), 2011.
4. Alvisi, S., M., Franchini, (2015): Assessment of predictive uncertainty within the framework of waterdemand forecasting using the Model Conditional Processor (MCP), *Urban Water Journal*, DOI: 10.1080/1573062X.2015.1057182
5. Anghileri, D., Voisin, N., Castelletti, A., Pianosi, F., Nijssen, B., and Lettenmaier, D.P.: Value of long-term streamflow forecasts to reservoir operations for water supply in snow-dominated river catchments, *Water Resour. Res.*, 52, 4209–4225, 2016.
6. Apaydin, H, Feizi, H, Sattari MT, Colak MS, Shamshirband S, Chau K-W. Comparative Analysis of Recurrent Neural Network Architectures for Reservoir Inflow Forecasting. *Water*. 2020; 12(5):1500. <https://doi.org/10.3390/w12051500>
7. Arcuri, A, Fraser, G, (2013) Parameter tuning or default values? An empirical investigation in search-based software engineering. *Empirical Software Engineering* 18(3):594–623.
8. Armstrong, JS (2001) Evaluating forecasting methods. In: Armstrong JS (eds) *Principles of forecasting: A handbook for researchers and practitioners*. Springer US, pp 443-472. doi:10.1007/978-0-306-47630-3_20
9. Azmi, Mohammad 1 Shahab Araghinejad 2 .Development of K-Nearest Neighbour Regression Method in Forecasting River Stream Flow

10. Ban T., Zhang R., Pang S., Sarrafzadeh A., Inoue D. (2013) Referential k NN Regression for Financial Time Series Forecasting. In: Lee M., Hirose A., Hou ZG., Kil R.M. (eds) Neural Information Processing. ICONIP 2013. Lecture Notes in Computer Science, vol 8226. Springer, Berlin, Heidelberg.
https://doi.org/10.1007/978-3-642-42054-2_75
11. Barros, M. T. L., Tsai, F. T.-C., Yang, S. L., Lopes, J. E. G., and Yeh, W. W.-G.: Optimization of Large-Scale Hydropower System Operations, *J. Water Resour. Plan. Manage.*, 129, 178–188, [https://doi.org/10.1061/\(ASCE\)0733-9496\(2003\)129:3\(178\)](https://doi.org/10.1061/(ASCE)0733-9496(2003)129:3(178)), 2003. a
12. Boucher, M. A., Tremblay, D., Delorme, L., Perreault, L., and Anctil, F.: Hydro-economic assessment of hydrological forecasting systems, *J. Hydrol.*, 416–417, 133–144, <https://doi.org/10.1016/j.jhydrol.2011.11.042>, 2012. a, b
13. Bowden, G. J., G. C. Dandy, and H. R. Maier, “Input determination for neural network models in water resources applications. Part 1 -Background and methodology,” *J. Hydrol.*, 2005, doi: 10.1016/j.jhydrol.2004.06.021.
14. Cassagnole, Manon, Maria-Helena Ramos, Ioanna Zalachori, Guillaume Thirel, Rémy Garçon, Joël Gailhard, and Thomas Ouillon. Impact of the quality of hydrological forecasts on the management and revenue of hydroelectric reservoirs - a conceptual approach
15. Chollet, Francois, A ten minute introduction to sequence to sequence learning in keras. <https://blog.keras.io/a-ten-minute-introduction-to-sequence-to-sequence-learning-in-keras.html>, 2017.
16. Coulibaly, P., F. Anctil, B. Bobee, Daily reservoir inflow forecasting using artificial neural networks with stopped training approach, *J. Hydrol.* 230 (2000) 244–257. doi:10.1016/S0022-1694(00)00214-6.
17. Daniell, T. M., “Neural networks. Applications in hydrology and water resources engineering,”1991.
18. Dobson, B., Wagener, T., and Pianosi, F.: An argument-driven classification and comparison of reservoir operation optimization methods, *Adv. Water Resour.*, 128, 74–86, <https://doi.org/10.1016/j.advwatres.2019.04.012>, 2019. a, b
19. Fan, F. M., Schwanenberg, D., Collischonn, W., and Weerts, A.: Verification of inflow into hydropower reservoirs using ensemble forecasts of the TIGGE

- database for large scale basins in Brazil, *J. Hydrol.: Reg. Stud.*, 4, 196–227, <https://doi.org/10.1016/j.ejrh.2015.05.012>, 2015. a
20. Hamlet, A., Huppert, D., and Lettenmaier, D.: Economic value of long-lead streamflow forecasts for Columbia River hydropower, *J. Water Resour. Plan. Manage.*, 128, 91–101, [https://doi.org/10.1061/\(ASCE\)0733-9496\(2002\)128:2\(91\)](https://doi.org/10.1061/(ASCE)0733-9496(2002)128:2(91)), 2002. a
 21. Hyndman, RJ, Athanasopoulos G (2013) *Forecasting: principles and practice*. OTexts: Melbourne, Australia. Available online at:<http://otexts.org/fpp/>
 22. Hyndman, A., R.J. *Forecasting: principles and practice*, 2nd edition. OTexts: Melbourne, Australia, 2018.
 23. Hyndman, RJ, Koehler AB (2006) Another look at measures of forecast accuracy. *International Journal of Forecasting* 22(4):679-688. doi: 10.1016/j.ijforecast.2006.03.001
 24. Hochreiter, S. and J. Schmidhuber. Long short-term memory. *Neural computation*, 9(8):1735{1780, 1997.
 25. Jain, SK, Das, A, Srivastava, DK (1999) Application of ANN for reservoir inflow prediction and operation. *Journal of Water Resources* 125(5):263-271. doi:10.1061/(ASCE)0733-9496(1999)125:5(263)
 26. Kotsiantis, S. B., D. Kanellopoulos, “Data preprocessing for supervised learning,” *Int. J.*, 2006, doi: 10.1080/02331931003692557.
 27. Koutsoyiannis, D., H. Yao, and A. Georgakakos, Medium-range flow prediction for the Nile: a comparison of stochastic and deterministic methods, *Hydrological Sciences Journal*, 53 (1), 142–164, doi:10.1623/hysj.53.1.142, 2008.
 28. Koutsoyiannis, D., & Montanari, A. (2022). Bluecat: A local uncertainty estimator for deterministic simulations and predictions. *Water Resources Research*, 58, e2021WR031215. <https://doi.org/10.1029/2021WR031215>
 29. Kratzert, F.; Klotz, D.; Shalev, G.; Klambauer, G.; Hochreiter, S.; Nearing, G. Benchmarking a Catchment-Aware Long Short-Term Memory Network (LSTM) for Large-Scale Hydrological Modeling. *Hydrol. Earth Syst. Sci. Discuss.* 2019, 2019, 1–32.
 30. Kratzert, F., “Neural Hydrology,” Using Neural Networks in Hydrology, 2020. <https://neuralhydrology.github.io/>

31. Lamontagne, J. and Stedinger, J.: Generating Synthetic Streamflow Forecasts with Specified Precision, *J. Water Resour. Plan. Manage.*, 144, 04018007, [https://doi.org/10.1061/\(ASCE\)WR.1943-5452.0000915](https://doi.org/10.1061/(ASCE)WR.1943-5452.0000915), 2018. a, b
32. Makinde, F., C. Ako, O. Orodu, and I. Asuquo. Prediction of crude oil viscosity using feed-forward back-propagation neural network (_bpnn). *Petroleum & Coal*, 54(2):120{131, 2012.
33. Martínez, F., Frías, M.P., Pérez, M.D. et al. A methodology for applying k-nearest neighbor to time series forecasting. *Artif Intell Rev* 52, 2019–2037 (2019). <https://doi.org/10.1007/s10462-017-9593-z>
34. Martínez, Francisco, María Pilar Frías, María Dolores Pérez-Godoy, Antonio Jesús Rivera. Dealing with seasonality by narrowing the training set in time series forecasting with kNN, *Expert Systems with Applications* <https://doi.org/10.1016/j.eswa.2018.03.005>.
35. Mbakaa J.G., Mwanikib M.W., 2017. Small Hydro-power Plants in Kenya: A Review of Status, Challenges and Future Prospects, Department of Land and Water Management -University of Embu, Embu, Kenya
36. Modaresi, F., Araghinejad, S. & Ebrahimi, K. A Comparative Assessment of Artificial Neural Network, Generalized Regression Neural Network, Least-Square Support Vector Regression, and K-Nearest Neighbor Regression for Monthly Streamflow Forecasting in Linear and Nonlinear Conditions. *Water Resour Manage* 32, 243–258 (2018). <https://doi.org/10.1007/s11269-017-1807-2>
37. Montanari, A., and D. Koutsoyiannis (2012), A blueprint for process-based modeling of uncertain hydrological systems, *Water Resour. Res.*, 48, W09555, doi:10.1029/2011WR011412.
38. Murphy, A.: What is a good forecast? An essay of the nature of goodness in weather forecasting, *Weather Forecast.*, 8, 281293, [https://doi.org/10.1175/15200434\(1993\)008<0281:WIAGFA>2.0.CO;2](https://doi.org/10.1175/15200434(1993)008<0281:WIAGFA>2.0.CO;2), 1993. a
39. Nesreen K. Ahmed, Amir F. Atiya, Neamat El Gayar & Hisham El-Shishiny (2010) An Empirical Comparison of Machine Learning Models for Time

Series Forecasting, *Econometric Reviews*, 29:5-6, 594-621, DOI:
10.1080/07474938.2010.481556

40. Papacharalampous, G., Hristos Tyralis, and Demetris Koutsoyiannis.
Comparison of stochastic and machine learning methods for multi-step ahead forecasting of hydrological processes (2017)
41. Papacharalampous, G., H. Tyralis, and D. Koutsoyiannis, Error evolution patterns in multi-step ahead streamflow forecasting, 13th International Conference on Hydroinformatics (HIC 2018), Palermo, Italy, doi:10.29007/84k6, 2018.
42. Papacharalampous, G.; Tyralis, H.; Koutsoyiannis, D. Error Evolution in Multi-Step Ahead Streamflow Forecasting for the Operation of Hydropower Reservoirs. *Preprints 2017*, 2017100129 (doi:10.20944/preprints201710.0129)
43. Papacharalampous, G., H. Tyralis, and D. Koutsoyiannis, Forecasting of geophysical processes using stochastic and machine learning algorithms, 10th World Congress on Water Resources and Environment "Panta Rhei", Athens, EWRA2017_A_110904, doi:10.13140/RG.2.2.30581.27361, European Water Resources Association, Athens, 2017.
44. Pereira, M. V. F. and Pinto, L. M. V. G.: Multi-stage stochastic optimization applied to energy planning, *Math. Program.*, 52, 359–375, <https://doi.org/10.1007/bf01582895>, 1991. a
45. Qi, Y., Zhou, Z., Yang, L. et al. A Decomposition-Ensemble Learning Model Based on LSTM Neural Network for Daily Reservoir Inflow Forecasting. *Water Resour Manage* 33, 4123–4139 (2019). <https://doi.org/10.1007/s11269-019-02345-1>
46. Roulin, E.: Skill and relative economic value of medium-range hydrological ensemble predictions, *Hydrol. Earth Syst. Sci.*, 11, 725–737, <https://doi.org/10.5194/hess-11-725-2007>, 2007. a
47. Ruder, S. An overview of gradient descent optimization algorithms. *arxiv* 2016. ArXiv preprint arXiv:1609.04747, 2020.
48. Sella Nevo, T. A., (Senior Software Engineer/Google Research, “An Inside Look at Flood Forecasting,”2019. <https://ai.googleblog.com/2019/09/an-inside-look-at-flood-forecasting.html>.

49. Sharma, S., Activation functions in neural networks. *Towards Data Science*, 6, 2017.
50. Srivastava, N., G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov. Dropout: a simple way to prevent neural networks from over_fitting. *The journal of machine learning research*, 15(1):1929{1958, 2014.
51. Taieb, S. Ben, G. Bontempi, A. F. Atiya, and A. Sorjamaa. Time Series Forecasting with KNN in R: the tsfknn Package by A review and comparison of strategies for multi-step ahead time series forecasting based on the NN5 forecasting competition. *Expert Syst. Appl.*, 39(8):7067–7083, 2012. URL <https://doi.org/10.1016/j.eswa.2012.01.039>.
52. Tang, G., Zhou, H., Li, N., Wang, F., Wang, Y., and Jian, D.: Value of Medium-range Precipitation Forecasts in Inflow Prediction and Hydropower Optimization, *Water Resour. Manage.*, 24, 2721–2742, <https://doi.org/10.1007/s11269-010-9576-1>, 2010. a
53. Tejada-Guibert, J., Johnson, S., and Stedinger, J.: The Value of Hydrologic Information in Stochastic Dynamic Programming Models of a Multi-Reservoir System, *Water Resour. Res.*, 31, 2571–2580, <https://doi.org/10.1029/95WR02172>, 1995. a
54. Todini, E., (2008) A model conditional processor to assess predictive uncertainty in flood forecasting, *International Journal of River Basin Management*, 6: 2,123-137, DOI: 10.1080/15715124.2008.9635342
55. Tsoukalas, I., P. Kossieris, and C. Makropoulos, Simulation of non-Gaussian correlated random variables, stochastic processes and random fields: Introducing the anySim R-Package for environmental applications and beyond, *Water*, 12 (6), 1645, doi:10.3390/w12061645, 2020.
56. Tsoukalas, I.: Modelling and simulation of non-Gaussian stochastic processes for optimization of water-systems under uncertainty, PhD thesis, Dept. of Civil Engineering, National Technical University of Athens, 2018 (available at: <https://www.itia.ntua.gr/1933/>).
57. Tsoukalas, I., P. Kossieris, and C. Makropoulos, Simulation of non-Gaussian correlated random variables, stochastic processes and random fields:

- Introducing the anySim R-Package for environmental applications and beyond, *Water*, 12(6),1645, <https://doi.org/10.3390/w12061645>, 2020.
58. Turner, S. W. D., Bennett, J. C., Robertson, D. E., and Galelli, S.: Complex relationship between seasonal streamflow forecast skill and value in reservoir operations, *Hydrol. Earth Syst. Sci.*, 21, 4841–4859, <https://doi.org/10.5194/hess-21-4841-2017>, 2017. a
 59. Van der Vaart., Dr. A.W. Time series notes. <https://www.math.leidenuniv.nl/avdvaart/timeseries/dictaat.pdf>, 1995-2010.
 60. Van Rossum, G., Python2.7 tutorial. 1995. Article. Gradient descent optimization and challenges. http://primo.ai/index.php?title=Gradient_Descent_Optimization_%26_Challenges.
 61. Weber, Noah, Why lstms stop your gradients from vanishing: A view from the backwards pass. https://weberna.github.io/blog/2017/11/15/LSTM_Vanishing-Gradients.html
 62. Wang WC, Chau KW, Cheng CT, Qiu L (2009) A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series. *J Hydrol* 374:294–306
 63. WuK, C.L., W.Chau, Data-driven models for monthly streamflow time series prediction Author links open overlay panel. Department of Civil and Structural Engineering, Hong Kong Polytechnic University, Hung Hom, Kowloon, Hong Kong, People’s Republic of China <https://doi.org/10.1016/j.engappai.2010.04.003>
 64. Yang, M., Wang, H., Jiang, Y. et al. GECA Proposed Ensemble–KNN Method for Improved Monthly Runoff Forecasting. *Water Resour Manage* 34, 849–863 (2020). <https://doi.org/10.1007/s11269-019-02479-2>
 65. Yuan, L., Zhou, J., Li, C., Xie, M., and Mo, L.: Benefit and Risk Balance Optimization for Stochastic Hydropower Scheduling, *Water Resour. Manage.*, 30, 3347–3361, <https://doi.org/10.1007/s11269-016-1354-2>, 2016. a, b
 66. Yunpeng, L., H. Di, B. Junpeng and Q. Yong, "Multi-step Ahead Time Series Forecasting for Different Data Patterns Based on LSTM Recurrent Neural Network," *2017 14th Web Information Systems and Applications Conference (WISA)*, Liuzhou, China, 2017, pp. 305-310, doi: 10.1109/WISA.2017.25.

67. Δημέλη, Σοφία. Σύγχρονες μέθοδοι ανάλυσης χρονολογικών σειρών, ΕΚΔΟΣΕΙΣ ΟΠΑ
68. Ευστρατιάδης Α., και Παπανικολάου Π., 2018. Σημειώσεις μαθήματος "Υδραυλικές Κατασκευές και Φράγματα", Τομέας Υδατικών Πόρων και Περιβάλλοντος – Εθνικό Μετσόβιο Πολυτεχνείο, Αθήνα.
69. Κουτσογιάννης, Δημήτρης, Στατιστική Υδρολογία, Εθνικό Μετσόβιο Πολυτεχνείο, Έκδοση 3
70. Μαμάσης Ν., και Κουτσογιάννης Δ., 2019. "Η τραγωδία της υδροηλεκτρικής ενέργειας στην Ελλάδα της κρίσης", Ημερίδα Εταιρείας Θεσσαλικών Μελετών (ΕΘΕΜ), Αθήνα.
71. Μάργαρης Δ., 2015. Σημειώσεις μαθήματος "Ρευστοδυναμικές Μηχανές", Εργαστήριο Ρευστοδυναμικής, Τμήμα Μηχανολόγων και Αεροναυπηγών Μηχανικών – Πανεπιστήμιο Πατρών, Πάτρα.
72. Χρυσάφινου, Ουρανία, Εισαγωγή στις Στοχαστικές Ανελίξεις, Β έκδοση, Εκδόσεις ΣΟΦΙΑ.