



ΠΑΝΕΠΙΣΤΗΜΙΟ ΠΕΙΡΑΙΩΣ
UNIVERSITY OF PIRAEUS



**«ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΚΑΙ ΕΦΑΡΜΟΓΕΣ
ΑΥΤΩΝ ΓΙΑ ΤΗΝ ΠΡΟΒΛΕΨΗ
ΧΡΟΝΟΣΕΙΡΩΝ ΣΤΟ ΧΡΗΜΑΤΙΣΤΗΡΙΟ»**

Από

Ηρακλής Παλληκάρης

Υποβάλλεται

για την εκπλήρωση των προϋποθέσεων λήψης

Μεταπτυχιακού Διπλώματος

στην «Τεχνητή Νοημοσύνη»

στο

ΠΑΝΕΠΙΣΤΗΜΙΟ ΠΕΙΡΑΙΩΣ

Συγγραφέας

Ηρακλής Παλληκάρης

ΔΠΜΣ «Τεχνητή Νοημοσύνη»

10, 2023

Έγινε αποδεκτό από

Μιχαήλ
Φιλιππάκης
Επιβλέπων

Έγινε αποδεκτό από

Ηλίας
Μαγκλογιάννης
Μέλος Εξεταστικής
Επιτροπής

Έγινε αποδεκτό από

Μαρία Χαλκίδη
Μέλος Εξεταστικής
Επιτροπής

**«ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΚΑΙ ΕΦΑΡΜΟΓΕΣ ΑΥΤΩΝ ΓΙΑ ΤΗΝ
ΠΡΟΒΛΕΨΗ ΧΡΟΝΟΣΕΙΡΩΝ ΣΤΟ ΧΡΗΜΑΤΙΣΤΗΡΙΟ»**

Από
Ηρακλής Παλληκάρης

Υποβλήθηκε στο ΔΠΜΣ «Τεχνητή Νοημοσύνη» την 12 Οκτωβρίου 2023 ως
υποχρέωση για την λήψη Μεταπτυχιακού Διπλώματος Σπουδών

Περίληψη

Στα πλαίσια της συγκεκριμένης διπλωματικής εργασίας, αρχικά πραγματοποιήθηκε βιβλιογραφική ανασκόπηση όσο αφορά τα νευρωνικά δίκτυα, δίνοντας έμφαση στα στοιχεία της αρχιτεκτονικής τους, τα είδη και το πεδίο εφαρμογής τους. Στην συνέχεια, πραγματοποιήθηκε παρουσίαση της πρόβλεψης χρονοσειρών, δίνοντας έμφαση στα βήματα για την πραγματοποίησή της, το πεδίο εφαρμογή της και τις προκλήσεις που σχετίζονται με την χρήση της. Στο πρακτικό μέρος, εξειδικεύτηκε περισσότερο η ανάλυση και μελετήθηκαν διάφορες αρχιτεκτονικές νευρωνικών δικτύων που μπορούν να εφαρμοστούν για την πρόβλεψη των τιμών ενός χρηματιστηριακού δείκτη. Καταγράφηκαν τα αποτελέσματα και η αξιολογήθηκε η αποτελεσματικότητα της πειραματικής διαδικασίας.

Ευχαριστίες

Η παρούσα εργασία αποτελεί διπλωματική εργασία στα πλαίσια του μεταπτυχιακού προγράμματος «Τεχνητή Νοημοσύνη» στο πανεπιστήμιο Πειραιά.

Πρωτίστως θέλω να ευχαριστήσω όλους τους διδάσκοντες του προγράμματος για τις πολύτιμες δεξιότητες και γνώσεις που μου προσέφεραν πάνω στο τομέα της τεχνητής νοημοσύνης και κυρίως τον επιβλέποντα καθηγητή της διπλωματικής μου εργασίας, Μιχαήλ Φιλλιπάκη, για την πολύτιμη καθοδήγηση του σε αυτήν την ομόρφη εμπειρία.

Έπειτα θα ήθελα να ευχαριστήσω όλα τα μέλη της οικογένειας μου για την υποστήριξη και βοήθεια τους ώστε να ολοκληρωθεί αυτός ο μεγάλος στόχος.

Πραγματικά δεν έχω να πω πολλές λέξεις παρά ένα μεγάλο ευχαριστώ σε όλους τους ανθρώπους που ήταν δίπλα μου με κάθε τρόπο κατά την διάρκεια όλου του προγράμματος.

Πίνακας Περιεχομένων

Εισαγωγή.....	13
Κεφάλαιο 1: Νευρωνικά Δίκτυα.....	14
1.1. Ορισμός	14
1.2. Εφαρμογές Νευρωνικών Δικτύων	15
1.3. Τύποι Νευρωνικών Δικτύων	17
1.3.1. Δίκτυα Εμπρόσθιας Τροφοδότησης	17
1.3.2. Συνελκτικά Νευρωνικά Δίκτυα	18
1.3.3. Επαναλαμβανόμενα Νευρωνικά Δίκτυα	19
1.3.4. Transformers	21
1.4. Προκλήσεις Νευρωνικών Δικτύων	22
Κεφάλαιο 2: Πρόβλεψη Χρονοσειρών	24
2.1. Εισαγωγή	24
2.2. Βήματα πρόβλεψης χρονοσειρών	24
2.3. Εφαρμογές πρόβλεψης χρονοσειρών	25
2.4. Μέθοδοι πρόβλεψης χρονοσειρών	27
2.4.1. Στατιστικές μέθοδοι.....	27
2.4.2. Μέθοδοι βαθιάς και μηχανικής μάθησης	29
2.5. Προκλήσεις στην πρόβλεψη χρονοσειρών	30
Κεφάλαιο 3: Πρακτικό Μέρος – Χρήση Νευρωνικών Δικτύων για πρόβλεψη χρονοσειρών στο χρηματιστήριο	32

3.1. Εισαγωγή	32
3.2. Παρουσίαση Συνόλου Δεδομένων	33
3.3. Πρώτη Αρχιτεκτονική Νευρωνικού Δικτύου	43
3.4. Δεύτερη Αρχιτεκτονική Νευρωνικού Δικτύου	52
3.5. Τρίτη Αρχιτεκτονική Νευρωνικού Δικτύου.....	61
Κεφάλαιο 4: Συμπεράσματα - Προτάσεις.....	70

Λίστα Εικόνων

Εικόνα 1: Βασικό μοντέλο νευρώνα	15
Εικόνα 2: Νευρωνικό Δίκτυο Εμπρόσθιας Τροφοδότησης.....	17
Εικόνα 3: Συνελκτικό Νευρωνικό Δίκτυο	18
Εικόνα 4: Επαναλαμβανόμενο Νευρωνικό Δίκτυο	20
Εικόνα 5: Νευρωνικό Δίκτυο LSTM και GRU	21
Εικόνα 6: Νευρωνικό Δίκτυο Transformer.....	22
Εικόνα 7: Περιβάλλον MATLAB.....	33
Εικόνα 8: Ιστόγραμμα συχνοτήτων στήλης AdjClose	35
Εικόνα 9: Ιστόγραμμα συχνοτήτων στήλης High	35
Εικόνα 10: Ιστόγραμμα συχνοτήτων στήλης Low.....	36
Εικόνα 11: Ιστόγραμμα συχνοτήτων στήλης Close	36
Εικόνα 12: Ιστόγραμμα συχνοτήτων στήλης Open.....	37
Εικόνα 13: Ιστόγραμμα συχνοτήτων στήλης Volume.....	37
Εικόνα 14: Boxplot στήλης AdjClose.....	38
Εικόνα 15: Boxplot στήλης High.....	38
Εικόνα 16: Boxplot στήλης Low.....	39
Εικόνα 17: Boxplot στήλης Close	39
Εικόνα 18: Boxplot στήλης Open.....	40
Εικόνα 19: Boxplot στήλης Volume.....	40
Εικόνα 20: Γράφημα Διασποράς (Scatter Plot) για τις στήλες Open – AdjClose	41
Εικόνα 21: Γράφημα Διασποράς (Scatter Plot) για τις στήλες Volume - AdjClose.....	41
Εικόνα 22: Γράφημα Διασποράς (Scatter Plot) για τις στήλες High – Volume	42
Εικόνα 23: Γραφική Παράσταση στήλης Adjusted Closing Value	42

Εικόνα 24: Διάγραμμα αρχιτεκτονικής πρώτου νευρωνικού δικτύου	43
Εικόνα 25: Σύγκριση προβλεπόμενων και πραγματικών τιμών - 1η Αρχιτεκτονική - Μέγεθος παραθύρου = 3	44
Εικόνα 26: Επαναλήψεις εκπαίδευσης - 1η Αρχιτεκτονική - Μέγεθος παραθύρου = 3 ..	45
Εικόνα 27: Σύγκριση προβλεπόμενων και πραγματικών τιμών - 1η Αρχιτεκτονική - Μέγεθος παραθύρου = 5	46
Εικόνα 28: Επαναλήψεις εκπαίδευσης - 1η Αρχιτεκτονική - Μέγεθος παραθύρου = 5 .	46
Εικόνα 29: Σύγκριση προβλεπόμενων και πραγματικών τιμών - 1η Αρχιτεκτονική - Μέγεθος παραθύρου = 7	47
Εικόνα 30: Επαναλήψεις εκπαίδευσης - 1η Αρχιτεκτονική - Μέγεθος παραθύρου = 7 .	48
Εικόνα 31: Σύγκριση προβλεπόμενων και πραγματικών τιμών - 1η Αρχιτεκτονική - Μέγεθος παραθύρου = 10	49
Εικόνα 32: Επαναλήψεις εκπαίδευσης - 1η Αρχιτεκτονική - Μέγεθος παραθύρου = 10	49
Εικόνα 33: RMSE - Time window size - 1η αρχιτεκτονική	51
Εικόνα 34: Διάγραμμα αρχιτεκτονικής δεύτερου νευρωνικού δικτύου	52
Εικόνα 35: Σύγκριση προβλεπόμενων και πραγματικών τιμών - 2η Αρχιτεκτονική - Μέγεθος παραθύρου = 3	53
Εικόνα 36: Επαναλήψεις εκπαίδευσης - 2η Αρχιτεκτονική - Μέγεθος παραθύρου = 3 ..	54
Εικόνα 37: Σύγκριση προβλεπόμενων και πραγματικών τιμών - 2η Αρχιτεκτονική - Μέγεθος παραθύρου = 5	55
Εικόνα 38: Επαναλήψεις εκπαίδευσης - 2η Αρχιτεκτονική - Μέγεθος παραθύρου = 5 ..	55
Εικόνα 39: Σύγκριση προβλεπόμενων και πραγματικών τιμών - 2η Αρχιτεκτονική - Μέγεθος παραθύρου = 7	56
Εικόνα 40: Επαναλήψεις εκπαίδευσης - 2η Αρχιτεκτονική - Μέγεθος παραθύρου = 7 ..	57

Εικόνα 41: Σύγκριση προβλεπόμενων και πραγματικών τιμών - 2η Αρχιτεκτονική -	
Μέγεθος παραθύρου = 10	58
Εικόνα 42: Επαναλήψεις εκπαίδευσης - 2η Αρχιτεκτονική - Μέγεθος παραθύρου = 10	58
Εικόνα 43: Time window size - RMSE - 2η Αρχιτεκτονική.....	60
Εικόνα 44: Διάγραμμα αρχιτεκτονικής τρίτου νευρωνικού δικτύου	61
Εικόνα 45: Σύγκριση προβλεπόμενων και πραγματικών τιμών - 3η Αρχιτεκτονική -	
Μέγεθος παραθύρου = 3	62
Εικόνα 46: Επαναλήψεις εκπαίδευσης - 3η Αρχιτεκτονική - Μέγεθος παραθύρου = 3.	63
Εικόνα 47: Σύγκριση προβλεπόμενων και πραγματικών τιμών - 3η Αρχιτεκτονική -	
Μέγεθος παραθύρου = 5	64
Εικόνα 48: Επαναλήψεις εκπαίδευσης - 3η Αρχιτεκτονική - Μέγεθος παραθύρου = 5.	64
Εικόνα 49: Σύγκριση προβλεπόμενων και πραγματικών τιμών - 3η Αρχιτεκτονική -	
Μέγεθος παραθύρου = 7	65
Εικόνα 50: Επαναλήψεις εκπαίδευσης - 3η Αρχιτεκτονική - Μέγεθος παραθύρου = 7.	66
Εικόνα 51: Σύγκριση προβλεπόμενων και πραγματικών τιμών - 3η Αρχιτεκτονική -	
Μέγεθος παραθύρου = 10	67
Εικόνα 52: Επαναλήψεις εκπαίδευσης - 3η Αρχιτεκτονική - Μέγεθος παραθύρου = 10	67
Εικόνα 53: Time window size - RMSE - 3η Αρχιτεκτονική	69

Λίστα Πινάκων

Πίνακας 1: Πλήθος εγγραφών και στηλών συνόλου δεδομένων	34
Πίνακας 2: Στήλες Συνόλου Δεδομένων	34
Πίνακας 3: Πληροφορίες κρυφών επιπέδων 1ης αρχιτεκτονικής	44
Πίνακας 4: Αποτελέσματα RMSE - 1η Αρχιτεκτονική - Μέγεθος Παραθύρου = 3.....	45
Πίνακας 5: Αποτελέσματα RMSE - 1η Αρχιτεκτονική - Μέγεθος Παραθύρου = 5.....	47
Πίνακας 6: Αποτελέσματα RMSE - 1η Αρχιτεκτονική - Μέγεθος Παραθύρου = 7.....	48
Πίνακας 7: Αποτελέσματα RMSE - 1η Αρχιτεκτονική - Μέγεθος Παραθύρου = 10	50
Πίνακας 8: Συγκριτικά αποτελέσματα RMSE - 1η Αρχιτεκτονική.....	50
Πίνακας 9: Εύρεση βέλτιστων αποτελεσμάτων - 1η αρχιτεκτονική.....	51
Πίνακας 10: Πλήθος νευρώνων ανά κρυφό επίπεδο 2ης αρχιτεκτονικής	53
Πίνακας 11: Αποτελέσματα RMSE - 2η Αρχιτεκτονική - Μέγεθος Παραθύρου = 3.....	54
Πίνακας 12: Αποτελέσματα RMSE - 2η Αρχιτεκτονική - Μέγεθος Παραθύρου = 5.....	56
Πίνακας 13: Αποτελέσματα RMSE - 2η Αρχιτεκτονική - Μέγεθος Παραθύρου = 7.....	57
Πίνακας 14: Αποτελέσματα RMSE - 2η Αρχιτεκτονική - Μέγεθος Παραθύρου = 10.....	59
Πίνακας 15: Συγκριτικά αποτελέσματα RMSE - 2η Αρχιτεκτονική	59
Πίνακας 16: Εύρεση βέλτιστων αποτελεσμάτων - 2η Αρχιτεκτονική	60
Πίνακας 17: Πλήθος κρυφών νευρώνων ανά επίπεδο 3ης αρχιτεκτονικής	62
Πίνακας 18: Αποτελέσματα RMSE - 3η Αρχιτεκτονική - Μέγεθος Παραθύρου = 3	63
Πίνακας 19: Αποτελέσματα RMSE - 3η Αρχιτεκτονική - Μέγεθος Παραθύρου = 5.....	65
Πίνακας 20: Αποτελέσματα RMSE - 3η Αρχιτεκτονική - Μέγεθος Παραθύρου = 7.....	66
Πίνακας 21: Αποτελέσματα RMSE - 3η Αρχιτεκτονική - Μέγεθος Παραθύρου = 10.....	68
Πίνακας 22: Συγκριτικά αποτελέσματα RMSE - 3η Αρχιτεκτονική	68
Πίνακας 23: Εύρεση βέλτιστων αποτελεσμάτων - 3η Αρχιτεκτονική.....	69

Εισαγωγή

Η ανάπτυξη μοντέλων, τα οποία χρησιμοποιούνται για προβλεπτικούς σκοπούς, αποτελεί μια πραγματικότητα, η οποία καλείται να δώσει λύση σε πολλές πτυχές της καθημερινής ζωής. Ένα σημαντικό πρόβλημα, το οποίο έχει απασχολήσει και συνεχίζει να απασχολεί την επιστημονική κοινότητα είναι η πρόβλεψη της εξέλιξης δεδομένων χρονοσειρών. Μια πτυχή του προβλήματος αυτού αποτελεί η πρόβλεψη της πορείας χρηματιστηριακών δεικτών ή και μετοχών, γεγονός που αποτέλεσε βασικό αντικείμενο της συγκεκριμένης διπλωματικής εργασίας.

Βασικός σκοπός της παρούσας διπλωματικής εργασίας είναι αφού πραγματοποιηθεί μια αρχική βιβλιογραφική παρουσίαση όσο αφορά τα νευρωνικά δίκτυα και την τεχνική της πρόβλεψης χρονοσειρών, δοθεί έμφαση στο πρακτικό μέρος το οποίο αφορά την εφαρμογή νευρωνικών δικτύων για πρόβλεψη χρονοσειρών στο χρηματιστήριο.

Στο *Κεφάλαιο 1* πραγματοποιείται μια παρουσίαση των συστατικών των νευρωνικών δικτύων. Επιπλέον, μελετώνται το πεδίο εφαρμογής και 4 βασικοί τύποι νευρωνικών δικτύων (εμπρόσθιας τροφοδότησης, συνελκτικό, επαναλαμβανόμενο, μετασχηματιστής). Τέλος, παρατίθενται μελλοντικές προκλήσεις που σχετίζονται με την χρήση τους.

Στο *Κεφάλαιο 2* παρουσιάζονται οι βασικές πτυχές της πρόβλεψης χρονοσειρών. Επιπλέον μελετώνται ακολουθούμενες μεθοδολογίες που κινούνται προς την συγκεκριμένη κατεύθυνση. Τέλος, παρατίθενται μελλοντικές προκλήσεις που σχετίζονται με την εφαρμογή της πρόβλεψης χρονοσειρών. Στο σημείο αυτό αξίζει να αναφερθεί ότι όλες οι ενότητες που αφορούν την πρόβλεψη χρονοσειρών, μπορούν χωρίς καμία εξαίρεση να εφαρμοστούν και στην περίπτωση των χρονοσειρών στο χρηματιστήριο.

Στο *Κεφάλαιο 3*, που αποτελεί και την ουσία της διπλωματικής εργασίας, παρουσιάζεται η πειραματική προσπάθεια που υλοποιήθηκε σε περιβάλλον MATLAB και αφορά την εφαρμογή 3 διαφορετικών τοπολογιών νευρωνικών δικτύων για την πραγματοποίηση πρόβλεψης της προσαρμοσμένης τιμής κλεισίματος (adjusted close price) του χρηματιστηριακού δείκτη S & P 500.

Κεφάλαιο 1: Νευρωνικά Δίκτυα

1.1. Ορισμός

Ένα νευρωνικό δίκτυο ^[1] αποτελεί ένα υπολογιστικό μοντέλο, το οποίο εμπνέεται από τη δομή και τον τρόπο λειτουργίας του ανθρώπινου εγκεφάλου. Όσο αφορά την αρχιτεκτονική του, αποτελείται από διασυνδεδεμένους κόμβους, οι οποίοι αποκαλούνται νευρώνες, και είναι οργανωμένοι σε στρώματα. Στην συνέχεια πραγματοποιείται μια παρουσίαση των βασικών συστατικών στοιχείων που σχετίζονται με τα νευρωνικά δίκτυα:

Νευρώνας : Οι νευρώνες είναι οι βασικές επεξεργαστικές μονάδες σε ένα νευρωνικό δίκτυο. Κάθε νευρώνας ^[2]:

1. λαμβάνει εισόδους
2. υπολογίζει ένα σταθμισμένο άθροισμα των εισόδων
3. εφαρμόζει μια συνάρτηση ενεργοποίησης πάνω στο άθροισμα αυτό και παράγει μια έξοδο.

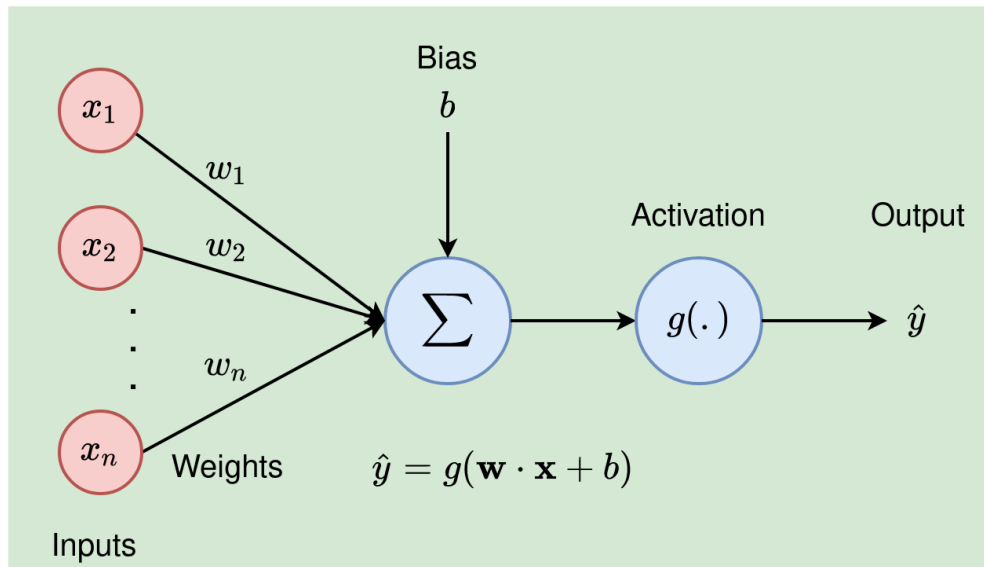
Βάρος: Κάθε σύνδεση ^[3] μεταξύ των νευρώνων χαρακτηρίζεται από ένα βάρος. Τα βάρη καθορίζουν τη σημαντικότητα της σύνδεσης και διαδραματίζουν καθοριστικό ρόλο στη μάθηση, καθώς προσαρμόζονται κατά τη διάρκεια της εκπαίδευσης με στόχο την βελτίωση της απόδοσης του δικτύου.

Συνάρτηση ενεργοποίησης: Μια συνάρτηση ενεργοποίησης ^[4] αποτελεί μια μαθηματική συνάρτηση που εφαρμόζεται στο σταθμισμένο άθροισμα των εισόδων σε κάθε νευρώνα.

Στρώμα: Οι νευρώνες σε ένα νευρωνικό δίκτυο οργανώνονται σε στρώματα. Υπάρχουν συνήθως τρεις τύποι στρωμάτων:

- Επίπεδο εισόδου: Το επίπεδο εισόδου λαμβάνει τα αρχικά δεδομένα ή χαρακτηριστικά που πρέπει να υποβληθούν προς επεξεργασία από το δίκτυο.
- Κρυμμένα στρώματα: Τα κρυμμένα στρώματα, τα οποία μπορεί να είναι ένα ή περισσότερα, αποτελούν ενδιάμεσα στρώματα μεταξύ των στρωμάτων εισόδου και του στρώματος εξόδου.

- Στρώμα εξόδου: Το στρώμα εξόδου παράγει τα τελικά αποτελέσματα του υπολογισμού του δικτύου.



Εικόνα 1: Βασικό μοντέλο νευρώνα [5]

1.2. Εφαρμογές Νευρωνικών Δικτύων

Στην παρούσα ενότητα, παρουσιάζονται ενδεικτικοί τομείς εφαρμογής των νευρωνικών δικτύων:

Υπολογιστική Όραση: Τα νευρωνικά δίκτυα, με πιο χαρακτηριστική την περίπτωση των συνελκτικών νευρωνικών δικτύων, έχουν συμβάλει με καθοριστικό τρόπο στον τομέα της υπολογιστικής όρασης [6]. Χρησιμοποιούνται σε λειτουργίες όπως: ταξινόμηση εικόνων, ανίχνευση αντικειμένων, αναγνώριση προσώπου και δημιουργία εικόνας. Οι λειτουργίες αυτές βρίσκουν εφαρμογή στην υποστήριξη αυτόνομων οχημάτων, ανάλυση ιατρικών εικόνων και δημιουργία συστημάτων επιτήρησης ασφαλείας.

Επεξεργασία Φυσικής Γλώσσας: Στην επεξεργασία φυσικής γλώσσας [7], τα νευρωνικά δίκτυα χρησιμοποιούνται για ανάλυση συναισθημάτων, μετάφραση γλώσσας, δημιουργία διαλογικών πρακτόρων και εξαγωγή περιλήψεων. Επιτρέπουν στις μηχανές να κατανοούν και να δημιουργούν την ανθρώπινη γλώσσα, καθιστώντας τις απαραίτητες σε εφαρμογές

όπως εικονικοί βοηθοί, υπηρεσίες μηχανικής μετάφρασης και συστήματα συστάσεων περιεχομένου.

Υγειονομική περίθαλψη: Διαδραματίζουν σημαντικό ρόλο στην υγειονομική περίθαλψη [8], συμβάλλοντας στην διάγνωση ασθενειών, στην ανάλυση ιατρικών εικόνων, στην προγνωστική μοντελοποίηση και στις εξατομικευμένες συστάσεις θεραπείας. Βοηθούν επίσης στην ανακάλυψη φαρμάκων, συμβάλλοντας με τον τρόπο αυτό στη βελτίωση της ιατρικής διάγνωσης και θεραπείας.

Οικονομία: Στην οικονομία [9], τα νευρωνικά δίκτυα χρησιμοποιούνται για την πρόβλεψη της πορείας της χρηματιστηριακής αγοράς (αποτελεί αντικείμενο της συγκεκριμένης διπλωματικής εργασίας), την αλγοριθμική διαπραγμάτευση, την αξιολόγηση του πιστωτικού κινδύνου και τον εντοπισμό οικονομικής απάτης. Αυτές οι εφαρμογές βοηθούν τα χρηματοπιστωτικά ιδρύματα να λαμβάνουν τεκμηριωμένες αποφάσεις, να διαχειρίζονται τον κίνδυνο και να βελτιώνουν τις εμπειρίες των πελατών.

Αυτόνομα Συστήματα: Αποτελούν το βασικό συστατικό στοιχείο των αυτόνομων συστημάτων, όπως τα αυτόνομα αυτοκίνητα, τα drones και τα βιομηχανικά ρομπότ. Επιτρέπουν σε αυτά να αντιλαμβάνονται το περιβάλλον τους, να λαμβάνουν αποφάσεις και να πλοηγούνται με ασφαλή τρόπο [10].

Εξυπηρέτηση διαφημιστικών σκοπών: Τα νευρωνικά δίκτυα χρησιμοποιούνται στο μάρκετινγκ για την κατάτμηση των πελατών, την στοχευμένη διαφήμιση, και την βελτιστοποίηση της πορείας των διαφημιστικών εκστρατειών [11].

Περιβάλλον: Αποτελούν ένα χρήσιμο εργαλείο για την περιβαλλοντική επιστήμη σε περιπτώσεις όπως η παρακολούθηση του περιβάλλοντος, η πρόβλεψη της ρύπανσης, η παρακολούθηση της άγριας ζωής και η πρόβλεψη εμφάνισης φυσικών καταστροφών. Είναι αδιαμφισβήτητο το γεγονός ότι βοηθούν τους επιστήμονες ώστε να αναλύουν πολύπλοκα περιβαλλοντικά δεδομένα και να λαμβάνουν τεκμηριωμένες αποφάσεις όσο αφορά την προστασία των οικοσυστημάτων και την αντιμετώπιση φυσικών καταστροφών [12].

Φυσικές Επιστήμες: Όσο αφορά τις φυσικές επιστήμες, τα νευρωνικά δίκτυα συμβάλλουν σε διάφορους τομείς, όπως η πρόβλεψη δομής πρωτεϊνών [13], η μοντελοποίηση του

κλίματος, η ανάλυση δεδομένων αστρονομίας και η μελέτη της επιστήμης των υλικών. Συμπερασματικά, βοηθούν τους επιστήμονες ώστε κατανοήσουν πολύπλοκα φαινόμενα και να πραγματοποιήσουν ανακαλύψεις σε διάφορους επιστημονικούς κλάδους.


1.3. Τύποι Νευρωνικών Δικτύων

1.3.1. Δίκτυα Εμπρόσθιας Τροφοδότησης

Ένα δίκτυο εμπρόσθιας τροφοδότησης (FNN) ^[14] έχει αρχιτεκτονική σαν αυτή που αναφέρθηκε προηγουμένως. Για την συγκεκριμένη κατηγορία δικτύων αξίζει να αναφερθούν επιπλέον τα παρακάτω:

Εμπρόσθια διάδοση: Η διαδικασία εμπρόσθιας διάδοσης ξεκινά με το επίπεδο εισόδου, όπου τα δεδομένα εισάγονται στο δίκτυο. Κάθε νευρώνας σε ένα στρώμα υπολογίζει την έξοδο του με βάση το σταθμισμένο άθροισμα των εισόδων και την συνάρτηση ενεργοποίησης. Οι έξοδοι υπολογίζονται σε κάθε στρώμα, προχωρώντας από το στρώμα εισόδου προς το στρώμα εξόδου, έως ότου ληφθεί η τελική πρόβλεψη.

Συνάρτηση απώλειας: Η συνάρτηση απώλειας ποσοτικοποιεί το σφάλμα ή τη διαφορά μεταξύ των προβλέψεων του δικτύου και των πραγματικών τιμών - στόχων. Η επιλογή της συνάρτησης απώλειας εξαρτάται από το εκάστοτε πρόβλημα, με το μέσο τετραγωνικό σφάλμα (MSE) να είναι συχνά χρησιμοποιούμενο.



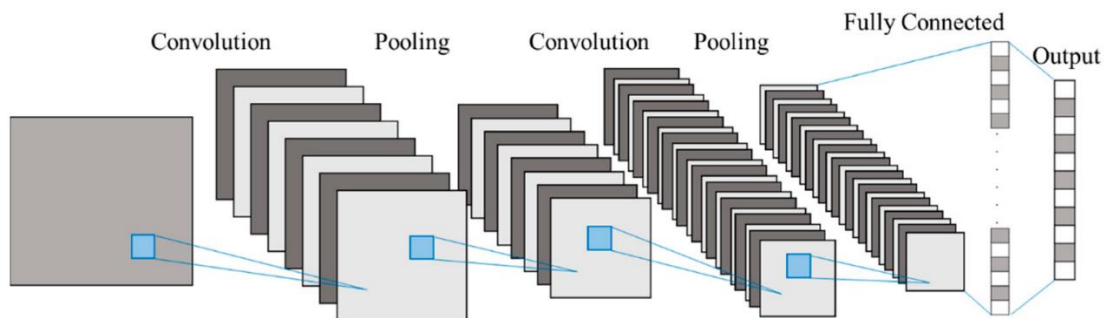
Εικόνα 2: Νευρωνικό Δίκτυο Εμπρόσθιας Τροφοδότησης [15]

Εκπαίδευση και πίσω διάδοση: Τα δίκτυα εμπρόσθιας τροφοδότησης εκπαιδεύονται χρησιμοποιώντας μια διαδικασία που ονομάζεται *backpropagation*. Η διαδικασία *backpropagation* περιλαμβάνει τον υπολογισμό των κλίσεων της συνάρτησης απώλειας σε σχέση με τα βάρη και τα χρησιμοποιούμενα κατώφλια του δικτύου.

Υπερπαράμετροι: Οι υπερπαράμετροι, όπως ο ρυθμός εκμάθησης, ο αριθμός των κρυφών στρωμάτων και ο αριθμός των νευρώνων σε κάθε στρώμα, πρέπει να αρχικοποιηθούν πριν από την εκκίνηση της διαδικασίας εκπαίδευσης. Η αρχικοποίηση των υπερπαραμέτρων με αποδοτικό τρόπο και με συνεχείς δοκιμές διαδραματίζει σημαντικό ρόλο στην επιτυχία της λειτουργίας του δικτύου.

1.3.2. Συνελικτικά Νευρωνικά Δίκτυα

Η αρχιτεκτονική των συνελικτικών νευρωνικών δικτύων [16] έχει διαδραματίσει σημαντικές εξελίξεις στην υπολογιστική όραση. Στην περίπτωση αυτής της αρχιτεκτονικής, τα συνελικτικά στρώματα επιτελούν τον σημαντικότερο φόρτο εργασίας και είναι υπεύθυνα για την εκμάθηση προτύπων και χαρακτηριστικών από δεδομένα εισόδου μέσω της εφαρμογής συνελικτικών φίλτρων. Αυτά τα φίλτρα επεξεργάζονται την είσοδο, ανιχνεύοντας χαρακτηριστικά υψηλότερου επιπέδου, τα οποία συνδυάζονται ιεραρχικά σε επόμενα στρώματα. Τα στρώματα συγκέντρωσης (*pooling layers*) μειώνουν τις χωρικές διαστάσεις των χαρακτηριστικών, συμβάλλοντας στην υπολογιστική αποτελεσματικότητα. Επιπλέον, οι συναρτήσεις ενεργοποίησης εισάγουν μη γραμμικότητα, επιτρέποντας στο δίκτυο να μοντελοποιεί πολύπλοκες σχέσεις στα δεδομένα.




Εικόνα 3: Συνελικτικό Νευρωνικό Δίκτυο [17]

Η αρχιτεκτονική εφαρμόζει επίσης κατανομή των βαρών, εξασφαλίζοντας ότι το ίδιο σύνολο βαρών χρησιμοποιείται σε διάφορα τμήματα της εισόδου, μειώνοντας τον αριθμό των παραμέτρων και ενισχύοντας την ικανότητα του δικτύου να γενικεύει. Συνήθως, στοιβάζονται πολλαπλά συνελικτικά στρώματα, καθένα από τα οποία καταγράφει όλο και πιο αφηρημένα χαρακτηριστικά.

Μετά από τα συνελικτικά στρώματα, χρησιμοποιούνται πλήρως συνδεδεμένα στρώματα για την πραγματοποίηση των τελικών προβλέψεων, επιτρέποντας στο δίκτυο να λαμβάνει αποφάσεις με βάση τα χαρακτηριστικά πάνω στα οποία έχει εκπαιδευτεί. Αυτός ο ιεραρχικός σχεδιασμός επιτρέπει στα συνελικτικά νευρωνικά δίκτυα να υπερτερούν σε εργασίες όπως η ταξινόμηση εικόνων, η ανίχνευση αντικειμένων και η αναγνώριση προσώπου, καθιστώντας τα απαραίτητα σε σύγχρονες εφαρμογές υπολογιστικής όρασης.

1.3.3. Επαναλαμβανόμενα Νευρωνικά Δίκτυα

Τα επαναλαμβανόμενα νευρωνικά δίκτυα (RNNs) ^[18] αποτελούν μια κατηγορία τεχνητών νευρωνικών δικτύων που έχουν σχεδιαστεί για τον χειρισμό ακολουθιών δεδομένων, καθιστώντας τα ιδιαίτερα κατάλληλα για εργασίες όπως η επεξεργασία φυσικής γλώσσας, η αναγνώριση ομιλίας και η πρόβλεψη χρονοσειρών. Το καθοριστικό χαρακτηριστικό των επαναλαμβανόμενων νευρωνικών δικτύων είναι η ικανότητά τους να διατηρούν μια κρυφή κατάσταση που συλλαμβάνει πληροφορίες από προηγούμενα χρονικά βήματα και τις ενσωματώνει στην τρέχουσα πρόβλεψη. Αυτή η κρυφή κατάσταση σχηματίζει έναν βρόχο, επιτρέποντας στα επαναλαμβανόμενα νευρωνικά δίκτυα να παρουσιάζουν χρονική δυναμική και να καταγράφουν εξαρτήσεις με την πάροδο του χρόνου.




Εικόνα 4: Επαναλαμβανόμενο Νευρωνικό Δίκτυο [19]

Ωστόσο, τα παραδοσιακά RNNs παρουσιάζουν περιορισμένη ικανότητα στο να καταγράφουν μακροπρόθεσμες εξαρτήσεις σε ακολουθίες. Για την αντιμετώπιση αυτών των ζητημάτων, έχουν αναπτυχθεί διάφορες αρχιτεκτονικές RNNs, όπως η αρχιτεκτονική LSTM και η αρχιτεκτονική GRU.

Τα δίκτυα LSTM, για παράδειγμα, εισάγουν εξειδικευμένους μηχανισμούς που τους επιτρέπουν να αποθηκεύουν και να ενημερώνουν επιλεκτικά πληροφορίες στην κρυφή κατάσταση, καθιστώντας τα αποτελεσματικά στο χειρισμό εξαρτήσεων μεγάλης εμβέλειας.

Τα GRUs, από την άλλη πλευρά, απλοποιούν την αρχιτεκτονική LSTM διατηρώντας παράλληλα μεγάλο μέρος της αποτελεσματικότητάς του. Αυτές οι αρχιτεκτονικές παραλλαγές έχουν βελτιώσει σημαντικά την ικανότητα των RNNs να μοντελοποιούν διαδοχικά δεδομένα και εξακολουθούν να αποτελούν θεμελιώδες εργαλείο στον τομέα της βαθιάς μάθησης.



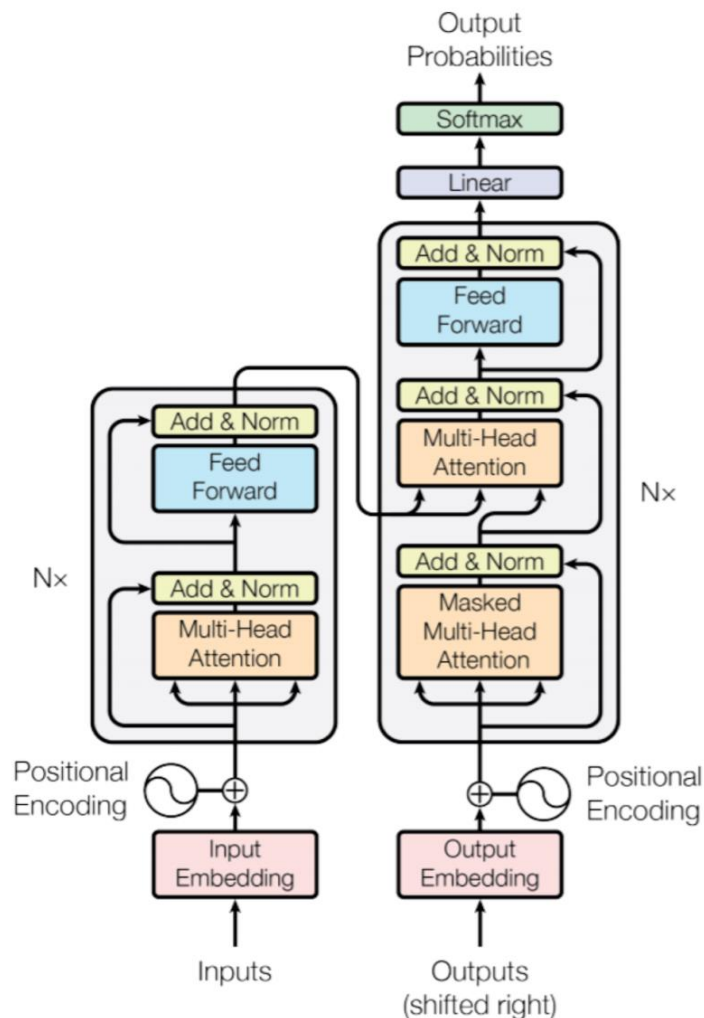
Εικόνα 5: Νευρωνικό Δίκτυο LSTM και GRU [20]

1.3.4. Transformers

Οι μετασχηματιστές (transformers) [21] αποτελούν μια σημαντική αρχιτεκτονική στον τομέα της βαθιάς μάθησης, γνωστή για τις εξαιρετικές επιδόσεις της στην επεξεργασία φυσικής γλώσσας. Το σημείο που ξεχωρίζει τους μετασχηματιστές είναι ο μηχανισμός αυτό-προσοχής που διαθέτουν, ο οποίος τους επιτρέπει να επεξεργάζονται αποτελεσματικά τις ακολουθίες εισόδου εξετάζοντας ταυτόχρονα τις σχέσεις μεταξύ όλων των στοιχείων. Αυτός ο μηχανισμός αυτό-προσοχής επιτρέπει στους μετασχηματιστές να καταγράφουν εξαρτήσεις υψηλής εμβέλειας.

Ο πυρήνας της αρχιτεκτονικής ενός δικτύου transformer αποτελείται από μια δομή κωδικοποιητή-αποκωδικοποιητή, η καθεμία από τις οποίες περιλαμβάνει πολλαπλά στρώματα αυτό-προσοχής και νευρωνικά δίκτυα εμπρόσθιας τροφοδότησης. Ο κωδικοποιητής επεξεργάζεται την ακολουθία εισόδου, ενώ ο αποκωδικοποιητής παράγει την ακολουθία εξόδου.

Άξιο αναφοράς είναι επίσης το γεγονός ότι οι transformers μπορούν να χρησιμοποιηθούν και σε πιο περίπλοκες μορφές δεδομένων, όπως ήχος και εικόνα, αφού πρώτα πραγματοποιηθούν οι κατάλληλες μετατροπές.



Εικόνα 6: Νευρωνικό Δίκτυο Transformer [22]

1.4. Προκλήσεις Νευρωνικών Δικτύων

Διαθεσιμότητα και ποιότητα δεδομένων: Είναι αδιαμφισβήτητο το γεγονός ότι τα νευρωνικά δίκτυα απαιτούν σε πολλές περιπτώσεις τεράστιες ποσότητες επισημασμένων δεδομένων για την πραγματοποίηση εκπαίδευσης [23]. Η ποσότητα στην συγκεκριμένη περίπτωση πρέπει να συνοδεύεται και από την αντίστοιχη ποιότητα όσο αφορά τα δεδομένα. Σε ορισμένους τομείς, όπως η υγειονομική περίθαλψη, τα επισημασμένα δεδομένα μπορεί να είναι σπάνια ή δύσκολο να ληφθούν, γεγονός που περιορίζει την επέκταση της εφαρμογής των νευρωνικών δικτύων.

Υπερβολική εκπαίδευση: Τα νευρωνικά δίκτυα είναι επιρρεπή σε υπερβολική εκπαίδευση, καθώς σε πολλές περιπτώσεις απομνημονεύουν τα δεδομένα εκπαίδευσης αντί να γενικεύουν με βάση αυτά. Το γεγονός αυτό μπορεί να οδηγήσει σε κακή απόδοση όταν λειτουργούν πάνω σε άγνωστα δεδομένα. Τεχνικές, όπως η κανονικοποίηση και η πρόωρη διακοπή, χρησιμοποιούνται προκειμένου να ελαχιστοποιήσουν την υπερβολική εκπαίδευση.

Υπολογιστικοί πόροι: Η εκπαίδευση πολύπλοκων νευρωνικών δικτύων με πολλαπλά επίπεδα και παραμέτρους απαιτεί σημαντικούς υπολογιστικούς πόρους, συμπεριλαμβανομένων ισχυρών GPU και TPU. Το γεγονός αυτό μπορεί να αποτελέσει εμπόδιο όσο αφορά την πραγματοποίηση ερευνητικών και όχι μόνο προσπαθειών που προσπαθούν να χρησιμοποιήσουν μεγάλης κλίμακας νευρωνικά δίκτυα.

Μεροληψία και Δικαιοσύνη: Τα νευρωνικά δίκτυα είναι πιθανόν να κληρονομήσουν προκαταλήψεις που υπάρχουν στα δεδομένα εκπαίδευσης, οδηγώντας σε άδικες ή προκατειλημμένες προβλέψεις. Η διασφάλιση της δικαιοσύνης και η άμβλυνση της προκατάληψης στις προβλέψεις των νευρωνικών δικτύων αποτελεί μια κρίσιμη ηθική ανησυχία, η οποία πρέπει να ληφθεί υπόψη στο άμεσο μέλλον.

Κεφάλαιο 2: Πρόβλεψη Χρονοσειρών

2.1. Εισαγωγή

Η πρόβλεψη χρονοσειρών ^[24] αναφέρεται στο έργο της πρόβλεψης μελλοντικών τιμών ή γεγονότων με βάση μια ακολουθία προηγούμενων παρατηρήσεων που συλλέχθηκαν με την πάροδο του χρόνου. Σε μια χρονοσειρά, τα σημεία δεδομένων καταγράφονται συνήθως σε τακτά χρονικά διαστήματα, όπως ημερήσια, μηνιαία ή ωριαία, και ταξινομούνται χρονολογικά.

Η πρόβλεψη χρονοσειρών περιλαμβάνει τη χρήση στατιστικών, μαθηματικών ή μοντέλων μηχανικής μάθησης για την ανάλυση ιστορικών δεδομένων και την πρόβλεψη μελλοντικών τιμών ή τάσεων. Επιγραμματικά αναφέρονται πεδία εφαρμογής της πρόβλεψης χρονοσειρών:

Πραγματοποίηση προβλέψεων στο χρηματιστήριο

- Πρόγνωση καιρού
- Πρόβλεψη ζήτησης
- Πρόβλεψη κατανάλωσης ενέργειας
- Πρόβλεψη πωλήσεων
- Πρόβλεψη κυκλοφορίας

Στο σημείο αυτό αξίζει να αναφερθεί ότι όσα θα αναφερθούν στις επόμενες ενότητες (και κυρίως όσο αφορά τις μεθοδολογίες πρόβλεψης χρονοσειρών) μπορούν να εφαρμοστούν και στην περίπτωση των χρονοσειρών για το χρηματιστήριο, χωρίς καμιά απώλεια γενικότητας.

2.2. Βήματα πρόβλεψης χρονοσειρών

Στα πλαίσια της συγκεκριμένης ενότητας παρουσιάζονται τα τυπικά βήματα που πρέπει να ακολουθούνται κατά την διαδικασία πραγματοποίησης προβλέψεων σε χρονοσειρές ^[24]:

1. *Συλλογή των δεδομένων*: Στο βήμα αυτό βρίσκεται η κατάλληλη πηγή δεδομένων, από την οποία αντλούνται τα δεδομένα ενδιαφέροντος.
2. *Ανάλυση και οπτικοποίηση των δεδομένων*: Εξετάζονται τα δεδομένα που έχουν συλλεχθεί, μελετώνται οι στατιστικές τους ιδιότητες και πραγματοποιούνται οι κατάλληλες οπτικοποιήσεις μέσω γραφημάτων.
3. *Προεπεξεργασία των δεδομένων*: Εφαρμόζονται τεχνικές προεπεξεργασίας με σκοπό την βελτίωση της ποιότητας των δεδομένων. Χαρακτηριστική είναι η περίπτωση της τεχνικής της συμπλήρωσης ελλিপών τιμών.
4. *Διαχωρισμός των δεδομένων*: Τα δεδομένα διαχωρίζονται σε δεδομένα εκπαίδευσης και δεδομένα ελέγχου.
5. *Επιλογή μοντέλου*: Επιλέγεται το κατάλληλο μοντέλο, το οποίο θα πραγματοποιηθεί για την εφαρμογή της πραγματοποίησης προβλέψεων.
6. *Επιλογή χαρακτηριστικών*: Επιλέγονται εκείνα τα χαρακτηριστικά (στήλες) από το σύνολο δεδομένων, πάνω στα οποία θα εφαρμοστεί το επιλεγμένο μοντέλο.
7. *Εκπαίδευση μοντέλου*: Το μοντέλο εκπαιδεύεται με βάση το σύνολο των δεδομένων εκπαίδευσης.
8. *Επικύρωση μοντέλου*: Επικυρώνεται η αποτελεσματικότητα του μοντέλου μέσω των δεδομένων ελέγχου, έτσι ώστε να εξεταστεί η δυνατότητα γενίκευσής του.
9. *Τροποποίηση μοντέλου*: Προαιρετικό βήμα, στο οποίο πραγματοποιείται τροποποίηση των παραμέτρων του μοντέλου, έτσι ώστε να βελτιωθεί η αποδοτικότητά του.
10. *Χρήση του τελικού μοντέλου*: Το μοντέλο χρησιμοποιείται για πραγματοποίηση προβλέψεων πάνω σε άγνωστα δεδομένα.

2.3. Εφαρμογές πρόβλεψης χρονοσειρών

Στην συγκεκριμένη ενότητα παρουσιάζονται ενδεικτικά πεδία εφαρμογής της πρόβλεψης χρονοσειρών [25]:

Ανάλυση χρηματοοικονομικών και χρηματιστηριακών αγορών: Η πρόβλεψη χρονοσειρών αποτελεί ζωτικής σημασίας τεχνική στον οικονομικό κλάδο όσο αφορά την πρόβλεψη των τιμών των μετοχών, επιτρέποντας στους επενδυτές και τους εμπόρους να

λαμβάνουν τεκμηριωμένες αποφάσεις με βάση τις προβλέψεις που έχουν πραγματοποιηθεί. Με την ανάλυση ιστορικών δεδομένων τιμών μετοχών και άλλων σχετικών χρηματοοικονομικών δεικτών, τα προγνωστικά μοντέλα μπορούν να βοηθήσουν στον εντοπισμό πιθανών επενδυτικών ευκαιριών ή κινδύνων, βελτιστοποιώντας με τον τρόπο αυτό τα κέρδη και ελαχιστοποιώντας τις ζημιές.

Πρόβλεψη πωλήσεων: Η πρόβλεψη πωλήσεων περιλαμβάνει τη χρήση ιστορικών δεδομένων πωλήσεων με σκοπό την πρόβλεψη μελλοντικών τάσεων όσο αφορά τις πωλήσεις. Αυτή η δυνατότητα είναι σημαντική για τις επιχειρήσεις προκειμένου να πραγματοποιούν βελτιστοποίηση της διαχείρισης αποθεμάτων, του σχεδιασμού παραγωγής και των στρατηγικών πωλήσεων, διασφαλίζοντας με τον βέλτιστο δυνατό τρόπο ότι ικανοποιούν τη ζήτηση των πελατών, ελαχιστοποιώντας παράλληλα το υπερβολικό απόθεμα ή τις ελλείψεις.

Πρόβλεψη ενεργειακής ζήτησης: Όσο αφορά τον ενεργειακό τομέα, η πρόβλεψη χρονοσειρών χρησιμοποιείται με σκοπό την πρόβλεψη προτύπων κατανάλωσης ενέργειας. Αυτή η δυνατότητα πραγματοποίησης προβλέψεων βοηθά τις εταιρείες κοινής ωφέλειας στην αποτελεσματική διαχείριση της παραγωγής και διανομής ηλεκτρικής ενέργειας, καθώς και στον καθορισμό τρόπων τιμολόγησης που αντικατοπτρίζουν την αναμενόμενη ζήτηση. Με τον τρόπο αυτό γίνεται προσπάθεια για εύρεση λύσης στο σημαντικό ζήτημα της πρόβλεψης κατανάλωσης ενέργειας, που ταλανίζει την σημερινή εποχή την ανθρωπότητα.

Πρόγνωση καιρού: Όπως είναι γνωστό, οι μετεωρολόγοι βασίζονται σε δεδομένα χρονοσειρών, όπως η θερμοκρασία, η βροχόπτωση και η ατμοσφαιρική πίεση, προκειμένου να κάνουν προβλέψεις όσο αφορά τα καιρικά φαινόμενα. Αυτές οι προβλέψεις είναι κρίσιμες για τη γεωργία, τις μεταφορές, την ετοιμότητα για αντιμετώπιση φυσικών καταστροφών και διάφορες βιομηχανίες που επηρεάζονται από τις καιρικές συνθήκες.

Υγειονομική περίθαλψη: Στην υγειονομική περίθαλψη, η πρόβλεψη χρονοσειρών μπορεί να χρησιμοποιηθεί για την πρόβλεψη των ποσοστών εισαγωγής ασθενών, των εστιών ασθενειών και της χρήσης υγειονομικών πόρων. Κατά τη διάρκεια κρίσεων δημόσιας

υγείας, όπως οι πανδημίες, αυτές οι προβλέψεις είναι πολύ σημαντικές για την αποτελεσματική κατανομή των πόρων υγειονομικής περίθαλψης.

Κυκλοφορία και μεταφορές: Στον συγκεκριμένο κλάδο χρησιμοποιείται για την πρόβλεψη της κυκλοφοριακής συμφόρησης, της ζήτησης των δημόσιων μεταφορών και των χρόνων ταξιδιού. Αυτές οι πληροφορίες είναι ζωτικής σημασίας για τον πολεοδομικό σχεδιασμό, τη βελτίωση της ροής της κυκλοφορίας και την ενίσχυση των υπηρεσιών δημόσιων μεταφορών.

2.4. Μέθοδοι πρόβλεψης χρονοσειρών

2.4.1. Στατιστικές μέθοδοι

Οι στατιστικές μέθοδοι παίζουν σημαντικό ρόλο στην πρόβλεψη χρονοσειρών, προσφέροντας διάφορες τεχνικές μοντελοποίησης και πρόβλεψης δεδομένων που εξαρτώνται από το χρόνο. Ακολουθούν μερικές βασικές στατιστικές μέθοδοι οι οποίες χρησιμοποιούνται για την πρόβλεψη χρονοσειρών:

ARIMA (Autoregressive Integrated Moving Average): Η ARIMA ^[26] είναι μια ευρέως χρησιμοποιούμενη στατιστική μέθοδος για την πρόβλεψη χρονοσειρών. Συνδυάζει αυτορρυθμιστικά (AR), διαφοροποιητικά (I) και κινούμενου μέσου(MA) συστατικά για να συλλάβει τα χρονικά πρότυπα στα δεδομένα. Τα μοντέλα ARIMA είναι ιδιαίτερα αποτελεσματικά για δεδομένα στατικών ή σχεδόν στατικών χρονοσειρών και είναι κατάλληλα τόσο για μονομεταβλητές όσο και για πολυμεταβλητές χρονοσειρές.

Μέθοδοι εκθετικής εξομάλυνσης: Οι μέθοδοι εκθετικής εξομάλυνσης περιλαμβάνουν την ενιαία εκθετική εξομάλυνση (SES), την διπλή εκθετική εξομάλυνση (μέθοδος Holt) και την τριπλή εκθετική εξομάλυνση (μέθοδος Holt-Winters) ^[27]. Αυτές οι μέθοδοι αποδίδουν εκθετικά μειωμένα βάρη σε προηγούμενες παρατηρήσεις προκειμένου να προβλέψουν μελλοντικές τιμές, καθιστώντας τις αποτελεσματικές για την καταγραφή διαφορετικών επιπέδων τάσης και εποχικότητας σε δεδομένα χρονοσειρών.

Space State μοντέλα: Τα μοντέλα Space State, συμπεριλαμβανομένου του φίλτρου Kalman και των παραλλαγών του, αποτελούν ευέλικτες στατιστικές τεχνικές για την πρόβλεψη χρονοσειρών. Μπορούν να χειριστούν ένα ευρύ φάσμα προτύπων χρονοσειρών, συμπεριλαμβανομένων γραμμικών και μη γραμμικών τάσεων, εποχικότητας και θορύβου μέτρησης. Τα μοντέλα Space State χρησιμοποιούνται συχνά στη μηχανική, την οικονομία και τη χρηματοδότηση [28].

Bayesian Structural Time Series(BSTS): Η μέθοδος BSTS [29] είναι μία Bayesian μέθοδος για τη μοντελοποίηση και την πρόβλεψη δεδομένων χρονοσειρών. Επιτρέπει την ευέλικτη μοντελοποίηση των συνιστωσών χρονοσειρών, όπως η τάση, και η εποχικότητα. Η μέθοδος αυτή παρέχει εκτιμήσεις αβεβαιότητας για τις προβλέψεις, καθιστώντας την πολύτιμο για τη λήψη αποφάσεων υπό αβεβαιότητα.

Vector Autoregression(VAR): Τα μοντέλα VAR [30] χρησιμοποιούνται σε περιπτώσεις δεδομένων πολυμεταβλητών χρονοσειρών. Επεκτείνουν την έννοια της αυτορρύθμισης σε πολλαπλές μεταβλητές χρονοσειρών, καταγράφοντας τις εξαρτήσεις μεταξύ τους. Τα μοντέλα VAR χρησιμοποιούνται ευρέως στην οικονομία με σκοπό τη μοντελοποίηση των αλληλεπιδράσεων μεταξύ διαφορετικών οικονομικών δεικτών.

GARCH (γενικευμένη αυτορρυθμιζόμενη υπό όρους ετεροσκεδαστικότητα): Τα μοντέλα GARCH [31] χρησιμοποιούνται για τη μοντελοποίηση και την πρόβλεψη της μεταβλητότητας σε δεδομένα χρηματοοικονομικών χρονοσειρών. Είναι ιδιαίτερα χρήσιμα για την πρόβλεψη της διακύμανσης ή της μεταβλητότητας των αποδόσεων των περιουσιακών στοιχείων, η οποία είναι ζωτικής σημασίας για τη διαχείριση κινδύνου και την τιμολόγηση των δικαιωμάτων προαίρεσης.

Φασματική ανάλυση: Οι τεχνικές φασματικής ανάλυσης [32], όπως ο μετασχηματισμός Fourier και η ανάλυση wavelet, χρησιμοποιούνται για τον εντοπισμό και τη μοντελοποίηση των συνιστωσών συχνότητας σε δεδομένα χρονοσειρών. Αυτές οι μέθοδοι είναι ιδιαίτερα χρήσιμες για την καταγραφή περιοδικών προτύπων και κυκλικής συμπεριφοράς.

Εκκίνηση και επαναδειγματοληψία: Οι τεχνικές εκκίνησης και επαναδειγματοληψίας [33] μπορούν να χρησιμοποιηθούν για την αξιολόγηση της αβεβαιότητας των προβλέψεων χρονοσειρών. Αυτές οι μέθοδοι περιλαμβάνουν τη δημιουργία πολλαπλών δειγμάτων από

τα ιστορικά δεδομένα και τη χρήση τους για την εκτίμηση διαστημάτων πρόβλεψης ή διαστημάτων εμπιστοσύνης.

2.4.2. Μέθοδοι βαθιάς και μηχανικής μάθησης

Στην ενότητα αυτή παρουσιάζονται μέθοδοι βαθιάς και μηχανικής μάθησης ^[34] για την πρόβλεψη χρονοσειρών:

Γραμμική παλινδρόμηση: Η γραμμική παλινδρόμηση μπορεί να εφαρμοστεί στην πρόβλεψη χρονοσειρών αντιμετωπίζοντας τις προηγούμενες παρατηρήσεις ως χαρακτηριστικά και την τιμή του επόμενου βήματος ως μεταβλητή στόχου. Είναι μια απλή προσέγγιση που υποθέτει μια γραμμική σχέση μεταξύ προηγούμενων και μελλοντικών τιμών, καθιστώντας την κατάλληλη για απλά δεδομένα χρονοσειρών.

K-πλησιέστεροι γείτονες (K-NN): Ο αλγόριθμος K-NN είναι μια μη παραμετρική μέθοδος που χρησιμοποιείται για την πρόβλεψη χρονοσειρών. Βασίζεται στην εύρεση των κ περισσότερο παρόμοιων ιστορικών ακολουθιών για την πραγματοποίηση προβλέψεων. Η μέθοδος αυτή είναι αποτελεσματική όταν ασχολείται με θορυβώδη ή ακανόνιστα δειγματοληπτικά δεδομένα χρονοσειρών.

Random Forests και δέντρα αποφάσεων: Οι αλγόριθμοι που βασίζονται σε δέντρα αποφάσεων, όπως είναι ο Random Forests, μπορούν να προσαρμοστούν για πρόβλεψη χρονοσειρών. Λειτουργούν με αναδρομική διαίρεση των δεδομένων με βάση τα χαρακτηριστικά και μπορούν να καταγράψουν πολύπλοκες σχέσεις μεταξύ προηγούμενων παρατηρήσεων και μελλοντικών τιμών.

Μοντέλο SVM: Το μοντέλο SVM μπορεί να εφαρμοστεί στην πρόβλεψη χρονοσειρών μετατρέποντας τα δεδομένα χρονοσειρών σε χώρο χαρακτηριστικών χρησιμοποιώντας λειτουργίες πυρήνα (kernel functions). Το μοντέλο SVM είναι κατάλληλο για σύνολα δεδομένων μικρών έως μεσαίων χρονοσειρών και μπορεί να χειριστεί τόσο γραμμικές όσο και μη γραμμικές σχέσεις.

Δίκτυα μακροχρόνιας βραχυπρόθεσμης μνήμης (LSTM): Όπως αναφέρθηκε και προηγουμένως, το LSTM είναι ένας τύπος επαναλαμβανόμενου νευρωνικού δικτύου

(RNN) που έχει σχεδιαστεί για μοντελοποίηση ακολουθιών. Είναι αποτελεσματικό στην καταγραφή μακροπρόθεσμων εξαρτήσεων σε δεδομένα χρονοσειρών, καθιστώντας το κατάλληλο για εργασίες με πολύπλοκα χρονικά πρότυπα, όπως η επεξεργασία φυσικής γλώσσας και η αναγνώριση ομιλίας.

Δίκτυα GRU: Αποτελούν μια άλλη παραλλαγή του RNN, που είναι υπολογιστικά αποδοτική και αποτελεσματική για την πρόβλεψη χρονοσειρών. Είναι παρόμοιο με το LSTM αλλά έχει μια απλούστερη αρχιτεκτονική με λιγότερες παραμέτρους.

Συνελικτικά Νευρωνικά Δίκτυα (CNNs): Ενώ τα CNNs χρησιμοποιούνται συνήθως για δεδομένα εικόνας, μπορούν επίσης να προσαρμοστούν για δεδομένα χρονοσειρών αντιμετωπίζοντας την ακολουθία ως μονοδιάστατο σήμα. Τα δίκτυα CNN είναι ιδιαίτερα χρήσιμα όταν υπάρχουν χωρικά πρότυπα ή τοπικές εξαρτήσεις στις χρονοσειρές.

Δίκτυα Εμπρόσθιας Τροφοδότησης (FNN): Όπως θα παρουσιαστεί και στο επόμενο κεφάλαιο που αφορά το πειραματικό μέρος, και ο συγκεκριμένος τύπος νευρωνικών δικτύων μπορεί να εφαρμοστεί με σκοπό την πρόβλεψη χρονοσειρών.

2.5. Προκλήσεις στην πρόβλεψη χρονοσειρών

Οι κύριες προκλήσεις όσο αφορά την πρόβλεψη χρονοσειρών συνοψίζονται στην συνέχεια ^[35]:

Μη στατικότητα: Τα δεδομένα χρονοσειρών συχνά παρουσιάζουν μη στατικότητα, πράγμα που σημαίνει ότι στατιστικές ιδιότητες όπως ο μέσος όρος, η διακύμανση και η αυτοσυσχέτιση αλλάζουν με την πάροδο του χρόνου. Η αντιμετώπιση μη στατικών δεδομένων μπορεί να είναι δύσκολη επειδή οι παραδοσιακές μέθοδοι υποθέτουν ύπαρξη στασιμότητας.

Σύνθετα πρότυπα: Τα δεδομένα χρονοσειρών μπορούν να περιέχουν διάφορα πρότυπα, συμπεριλαμβανομένων των τάσεων, της εποχικότητας, της κυκλικής συμπεριφοράς και των ακανόνιστων διακυμάνσεων. Η ακριβής μοντελοποίηση και καταγραφή αυτών των μοτίβων μπορεί να είναι δύσκολη, ειδικά όταν επικαλύπτονται ή αλλάζουν με την πάροδο του χρόνου.

Ποιότητα δεδομένων και ελλειπείς τιμές: Τα δεδομένα χρονοσειρών μπορεί να είναι θορυβώδη, να περιέχουν ακραίες τιμές και να περιέχουν ελλειπείς τιμές. Ο καθαρισμός και ο καταλογισμός δεδομένων που λείπουν διατηρώντας παράλληλα την ακεραιότητα των χρονοσειρών είναι μια δύσκολη εργασία προεπεξεργασίας.

Υψηλή διαστατικότητα: Τα δεδομένα πολλαπλών μεταβλητών χρονοσειρών με πολλαπλές μεταβλητές μπορούν να έχουν υψηλή διαστατικότητα, καθιστώντας δύσκολη την επιλογή των πιο σχετικών χαρακτηριστικών και την κατασκευή αποτελεσματικών μοντέλων.

Κλιμάκωση και κανονικοποίηση δεδομένων: Η κατάλληλη κλιμάκωση και ομαλοποίηση των δεδομένων χρονοσειρών είναι κρίσιμης σημασίας, καθώς διαφορετικές κλίμακες μπορούν να επηρεάσουν την απόδοση του μοντέλου. Η εύρεση της σωστής μεθόδου κλιμάκωσης είναι συχνά μια διαδικασία δοκιμής και σφάλματος.

Ανισορροπία δεδομένων: Σε περιπτώσεις ταξινόμησης που βασίζονται σε δεδομένα χρονοσειρών, η ανισορροπία μεταξύ των κλάσεων των δεδομένων μπορεί να είναι ένα ζήτημα, όταν μια κλάση ξεπερνά σημαντικά τις άλλες όσο αφορά το πλήθος των εγγραφών. Η εξισορρόπηση του συνόλου δεδομένων και η επιλογή κατάλληλων μετρήσεων αξιολόγησης είναι απαραίτητες.

Χρονικές εξαρτήσεις: Ορισμένες περιπτώσεις πρόβλεψης χρονοσειρών απαιτούν την καταγραφή μακροπρόθεσμων χρονικών εξαρτήσεων.

Υπερβολική εκπαίδευση: Τα δεδομένα χρονοσειρών μπορεί να είναι επιρρεπή σε υπερβολική εκπαίδευση, ειδικά όταν χρησιμοποιούνται πολύπλοκα μοντέλα ή όταν το σύνολο δεδομένων είναι μικρό. Η σωστή κανονικοποίηση και η επιλογή μοντέλου διαδραματίζει σημαντικό ρόλο στην αντιμετώπιση του ζητήματος αυτού.

Κεφάλαιο 3: Πρακτικό Μέρος – Χρήση Νευρωνικών Δικτύων για πρόβλεψη χρονοσειρών στο χρηματιστήριο

3.1. Εισαγωγή

Στόχος του πρακτικού μέρους της διπλωματικής εργασίας είναι η εφαρμογή της χρήσης νευρωνικών δικτύων για την πρόβλεψη χρονοσειρών που σχετίζονται με χρηματιστηριακό δείκτη. Πιο συγκεκριμένα με βάση σύνολο δεδομένων, το οποίο αφορά τον χρηματιστηριακό δείκτη S & P 500, αποφασίστηκε να δημιουργηθούν 3 διαφορετικές τοπολογίες νευρωνικών δικτύων εμπρόσθιας τροφοδότησης με σκοπό την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος (adjusted close price) του χρηματιστηριακού δείκτη S & P 500.

Πιο συγκεκριμένα, οι τοπολογίες νευρωνικών δικτύων, οι οποίες εξετάστηκαν, διαφοροποιούνταν ως προς το πλήθος των επιπέδων κρυφών νευρών και το πλήθος των νευρώνων ανά κρυφό επίπεδο. Οι 3 τοπολογίες είναι οι παρακάτω:

- Ένα κρυφό επίπεδο με 8 νευρώνες, ένα κρυφό επίπεδο με 4 νευρώνες, και ένα κρυφό επίπεδο με 1 νευρώνα
- Ένα κρυφό επίπεδο με 8 νευρώνες, ένα κρυφό επίπεδο με 4 νευρώνες, ένα κρυφό επίπεδο με 4 νευρώνες, και ένα κρυφό επίπεδο με 1 νευρώνα
- Ένα κρυφό επίπεδο με 8 νευρώνες, ένα κρυφό επίπεδο με 6 νευρώνες, ένα κρυφό επίπεδο με 4 νευρώνες, ένα κρυφό επίπεδο με 2 νευρώνες, και έναν κρυφό επίπεδο με έναν νευρώνα

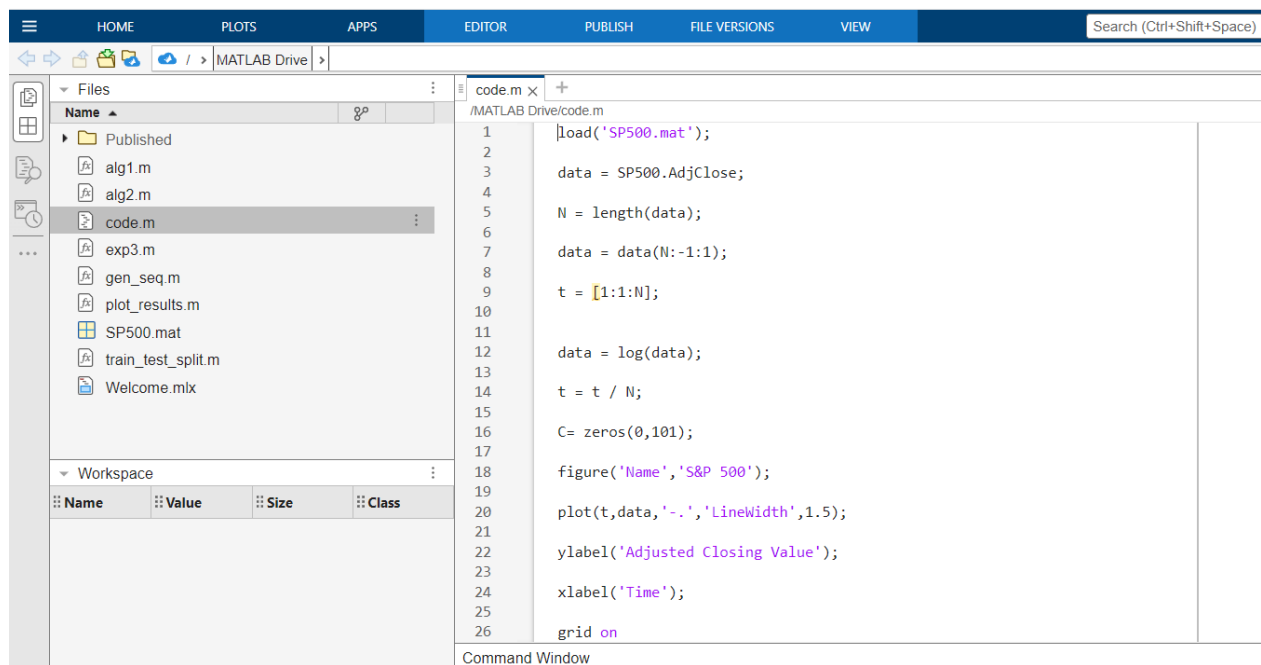
Στο σημείο αυτό αξίζει να αναφερθεί ότι όλες οι τοπολογίες πέρα από τα κρυφά επίπεδα, διαθέτουν και επίπεδο εισόδου και επίπεδο εξόδου. Για την ενίσχυση της πειραματικής διαδικασίας και την πραγματοποίηση πιο λεπτομερών πειραμάτων, δοκιμάστηκαν οι παρακάτω παραλλαγές όσο αφορά την τιμή του χρονικού παραθύρου πρόβλεψης:

- 3 ημέρες
- 5 ημέρες
- 7 ημέρες
- 10 ημέρες

Επιπλέον, οι 3 παραπάνω αρχιτεκτονικές αξιολογήθηκαν ως προς:

- Μετρική RMSE (Root Mean Square Error)
- Διαγράμματα που παρουσιάζουν την απόκλιση μεταξύ πραγματικών και προβλεπόμενων τιμών.
- Διαγράμματα εξέλιξης των επαναλήψεων εκπαίδευσης.

Όσο αφορά το εργαλείο υλοποίησης, χρησιμοποιήθηκε το περιβάλλον MATLAB (στο τέλος του κειμένου της διπλωματικής παρατίθεται και ο αντίστοιχος κώδικας ο οποίος υλοποιήθηκε):



```
1 load('SP500.mat');
2
3 data = SP500.AdjClose;
4
5 N = length(data);
6
7 data = data(N:-1:1);
8
9 t = [1:1:N];
10
11
12 data = log(data);
13
14 t = t / N;
15
16 C= zeros(0,101);
17
18 figure('Name','S&P 500');
19
20 plot(t,data,'-.','LineWidth',1.5);
21
22 ylabel('Adjusted Closing Value');
23
24 xlabel('Time');
25
26 grid on
```

Εικόνα 7: Περιβάλλον MATLAB

3.2. Παρουσίαση Συνόλου Δεδομένων

Όσο αφορά το σύνολο δεδομένων, χρησιμοποιήθηκε το αντίστοιχο αρχείο (SP500.mat), το οποίο περιέχει δεδομένα, τα οποία αφορούν τον χρηματιστηριακό δείκτη S&P 500. Τα δεδομένα αυτά καλύπτουν την περίοδο από 03-01-1950 έως 31-12-2014.

Περισσότερες πληροφορίες για το μέγεθος του συνόλου δεδομένων, παρατίθενται στον παρακάτω πίνακα:

Πίνακας 1: Πλήθος εγγραφών και στηλών συνόλου δεδομένων

Πλήθος Εγγραφών	16355
Πλήθος Στηλών	7

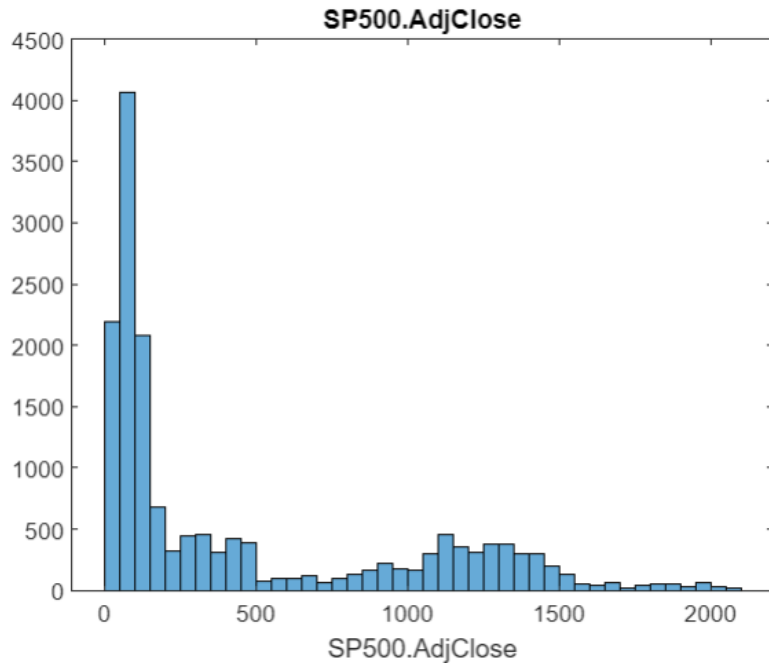
Στον επόμενο πίνακα, παρουσιάζονται πληροφορίες όσο αφορά στήλες του συνόλου δεδομένων:

Πίνακας 2: Στήλες Συνόλου Δεδομένων

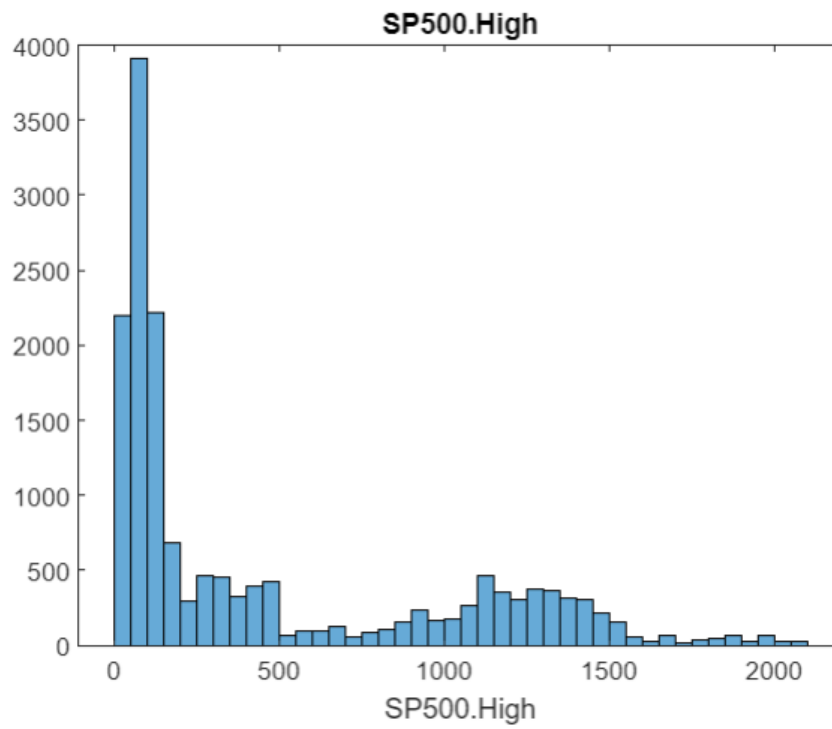
Όνομα Στήλης	Περιγραφή
AdjClose	Προσαρμοσμένη τιμή κλεισίματος
Date	Ημερομηνία
High	Υψηλότερη τιμή ημέρας
Low	Χαμηλότερη τιμή ημέρας
Close	Τιμή κλεισίματος
Open	Τιμή ανοίγματος
Volume	Όγκος συναλλαγών

Στην συνέχεια παρουσιάζονται τα ιστογράμματα συχνότητας, αλλά και τα διαγράμματα boxplots των παρακάτω στηλών δεδομένων:


- AdjClose
- High
- Low
- Close
- Open
- Volume



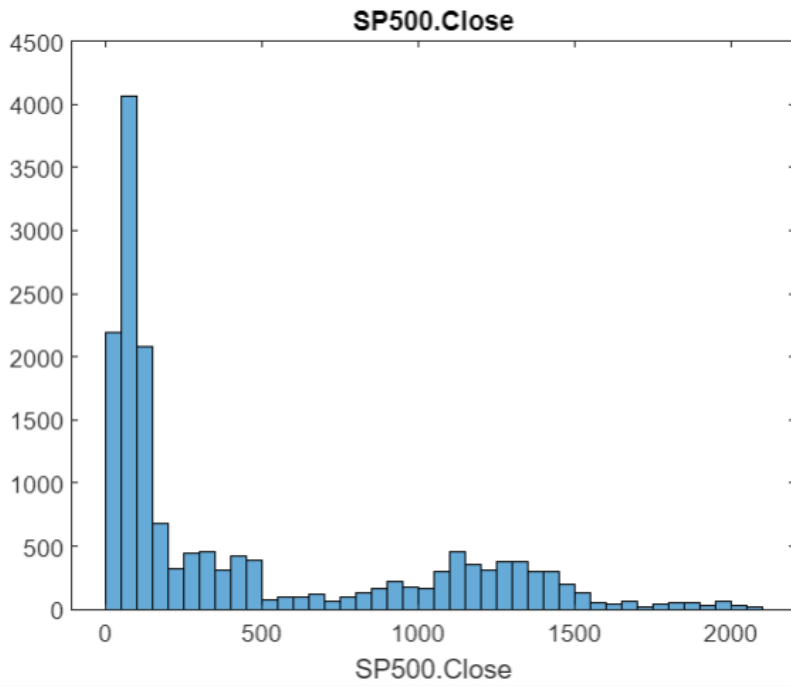
Εικόνα 8: Ιστόγραμμα συχνότητων στήλης AdjClose



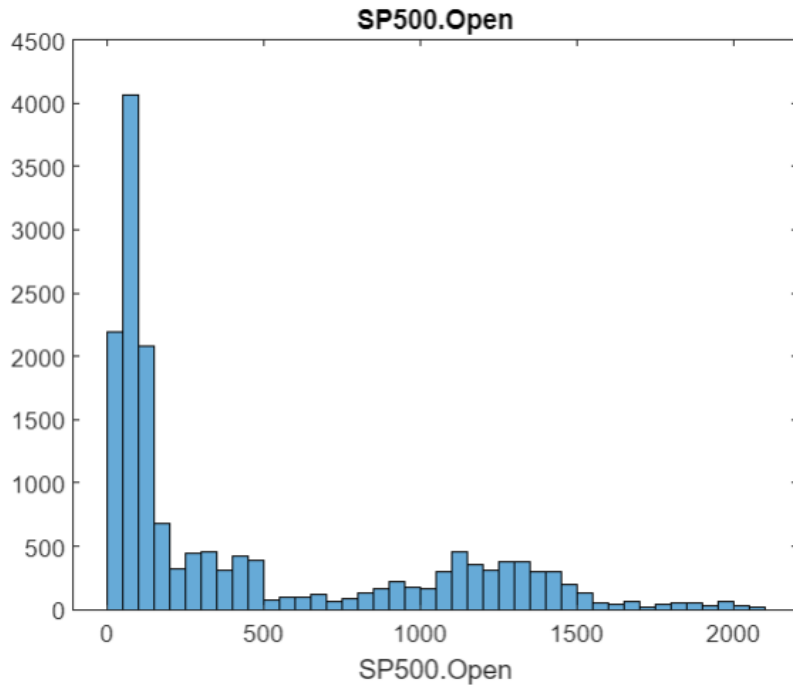
Εικόνα 9: Ιστόγραμμα συχνότητων στήλης High



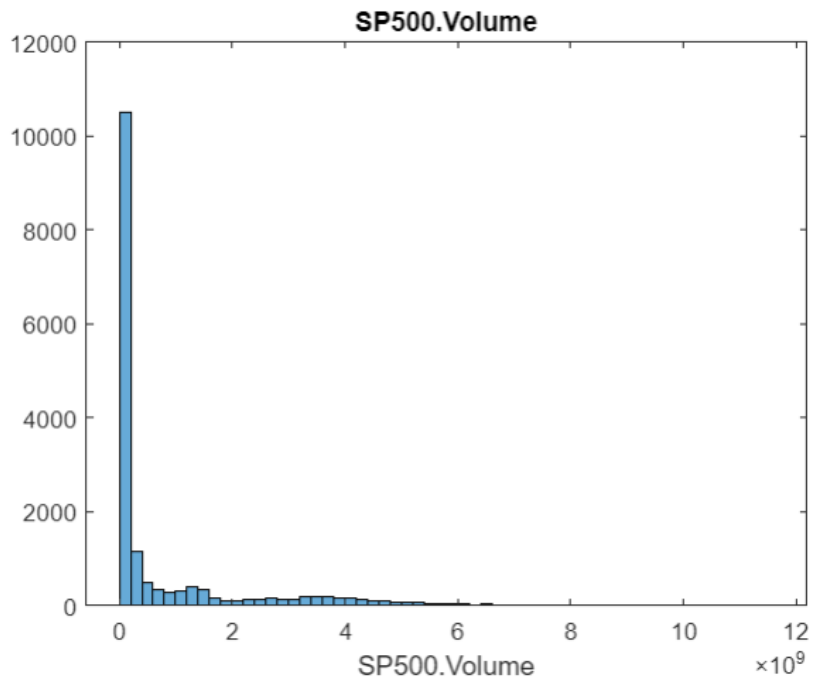
Εικόνα 10: Ιστόγραμμα συχνοτήτων στήλης Low




Εικόνα 11: Ιστόγραμμα συχνοτήτων στήλης Close



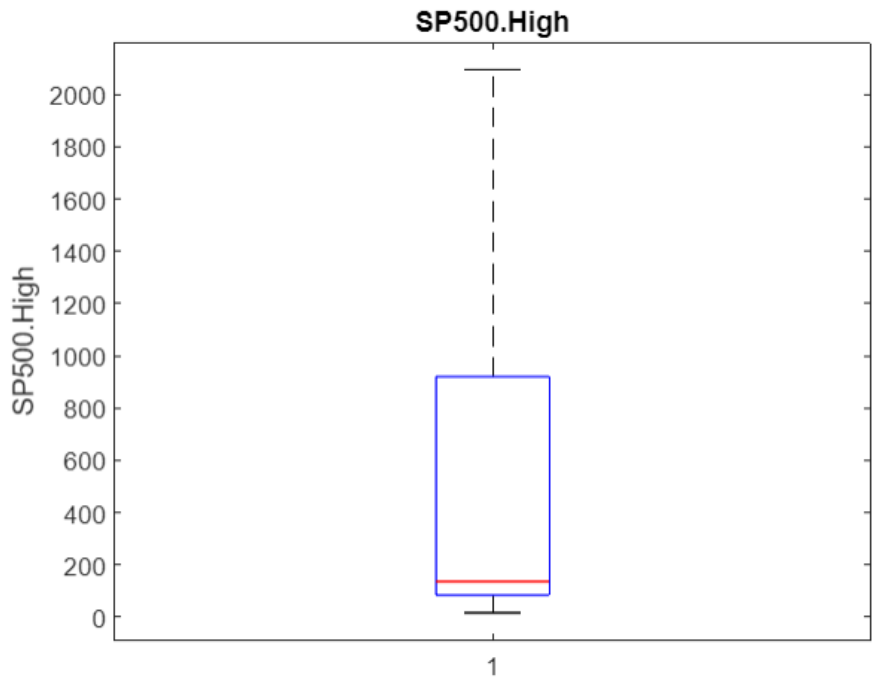
Εικόνα 12: Ιστόγραμμα συχνοτήτων στήλης *Open*



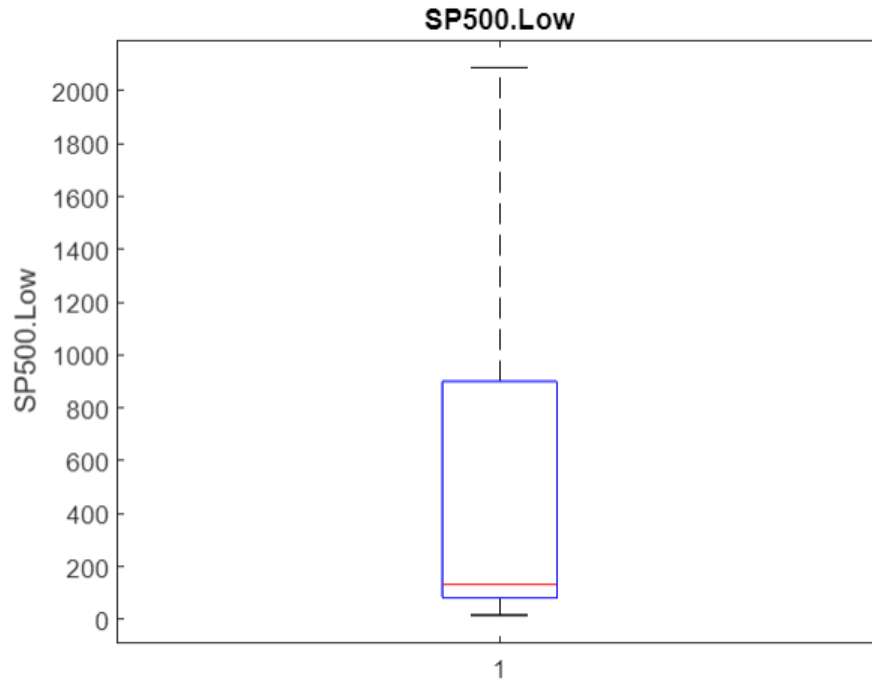
Εικόνα 13: Ιστόγραμμα συχνοτήτων στήλης *Volume*



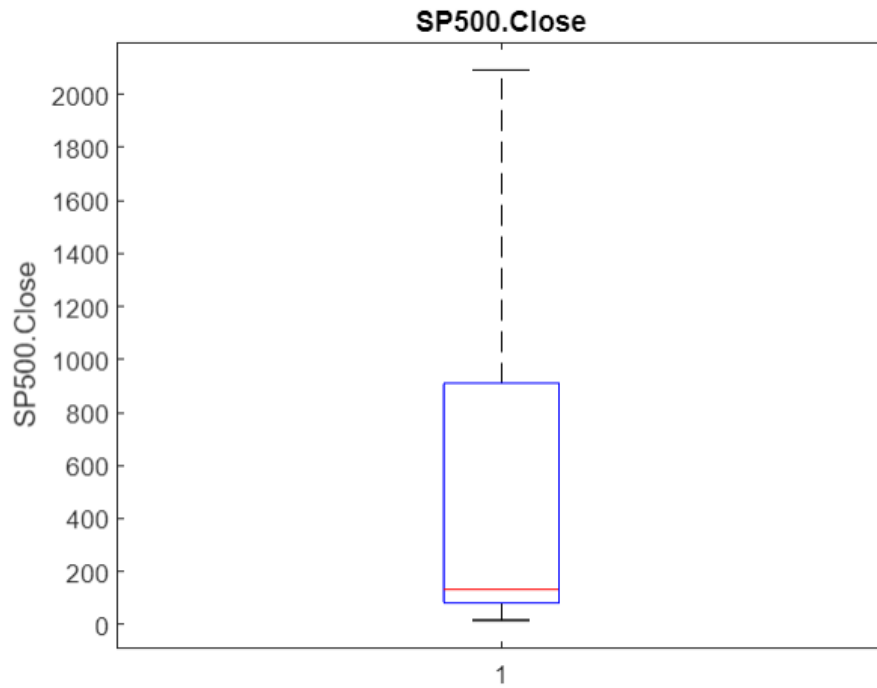
Εικόνα 14: Βoxplot στήλης AdjClose




Εικόνα 15: Βoxplot στήλης High



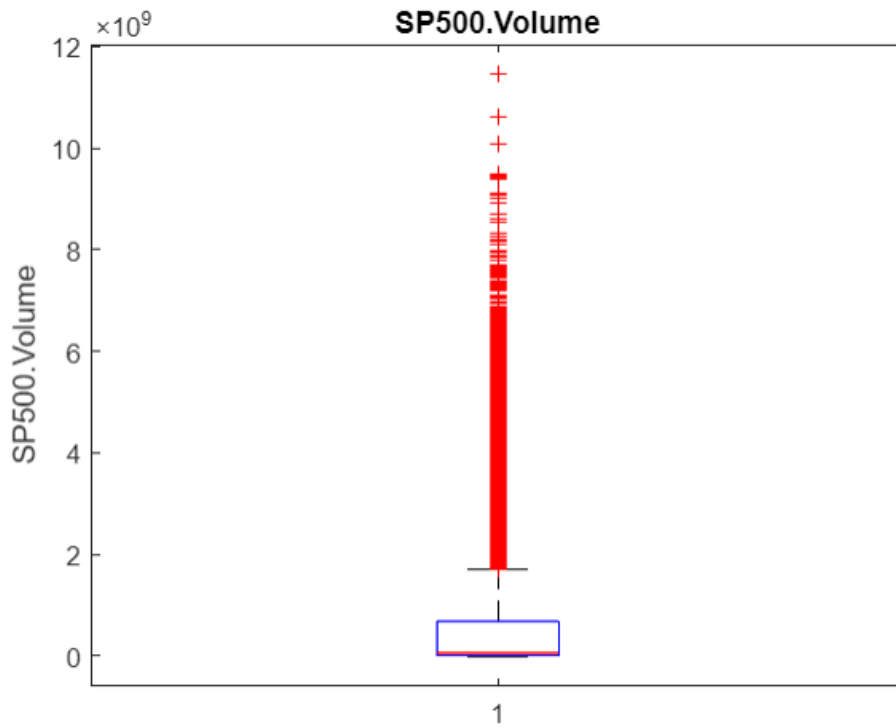
Εικόνα 16: Βοχplot στήλης Low



Εικόνα 17: Βοχplot στήλης Close

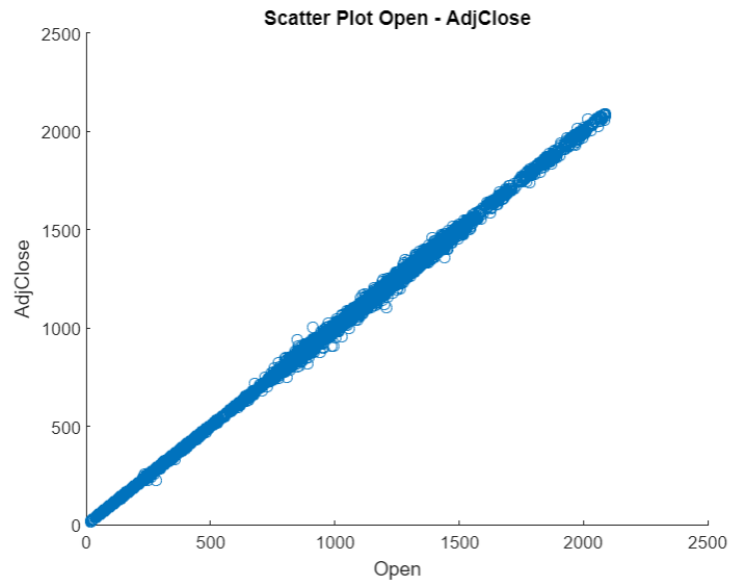


Εικόνα 18: Βοχplot στήλης Open



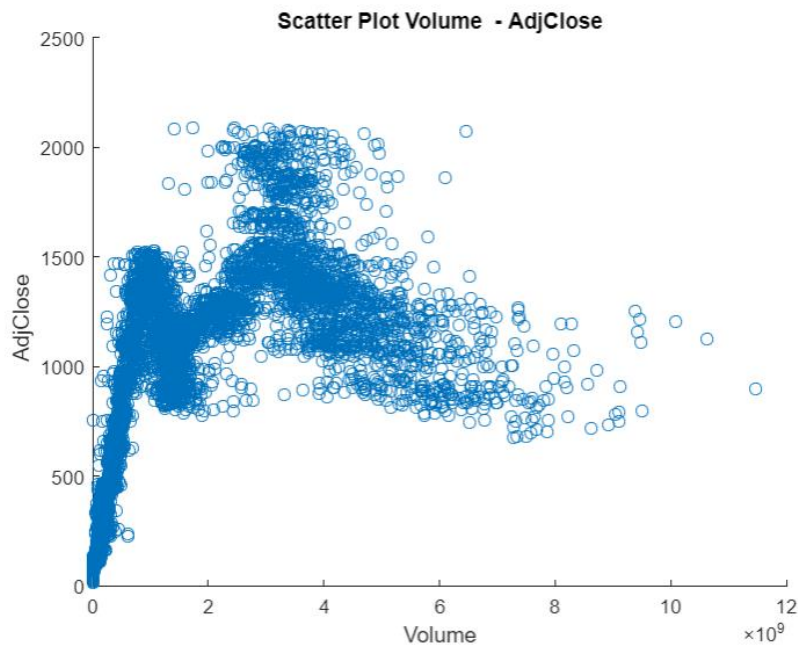
Εικόνα 19: Βοχplot στήλης Volume

Ακολουθεί το γράφημα διασποράς για τις στήλες Open και AdjClose:



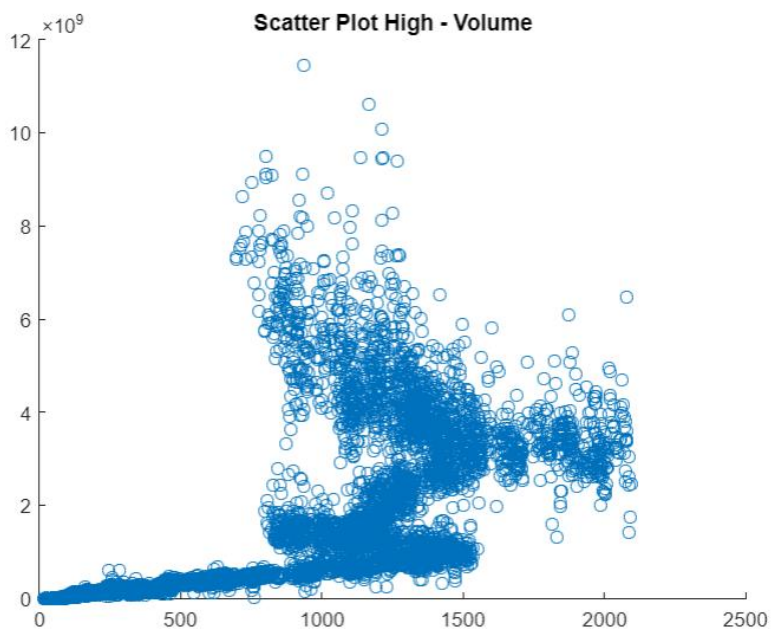
Εικόνα 20: Γράφημα Διασποράς (Scatter Plot) για τις στήλες Open – AdjClose

Το αντίστοιχο γράφημα διασποράς για τις στήλες Volume και AdjClose:




Εικόνα 21: Γράφημα Διασποράς (Scatter Plot) για τις στήλες Volume - AdjClose

Το γράφημα διασποράς για τις στήλες High και Volume:



Εικόνα 22: Γράφημα Διασποράς (Scatter Plot) για τις στήλες High – Volume


Τέλος, το γράφημα που παρουσιάζει την εξέλιξη των τιμών της στήλης Adjusted Closing Value, η οποία θα αποτελέσει και την στήλη ενδιαφέροντος όσο αφορά την διαδικασία της πρόβλεψης:



Εικόνα 23: Γραφική Παράσταση στήλης Adjusted Closing Value

3.3. Πρώτη Αρχιτεκτονική Νευρωνικού Δικτύου

Το διάγραμμα της αρχιτεκτονικής του πρώτου νευρωνικού δικτύου, το οποίο υλοποιήθηκε:




Εικόνα 24: Διάγραμμα αρχιτεκτονικής πρώτου νευρωνικού δικτύου

Στον παρακάτω πίνακα παρουσιάζονται πληροφορίες όσο αφορά τα κρυφά επίπεδα νευρώνων:


Πίνακας 3: Πληροφορίες κρυφών επιπέδων 1ης αρχιτεκτονικής

Κρυφό Επίπεδο	Πλήθος Νευρώνων
1 ^ο	8
2 ^ο	4
3 ^ο	1

Ακολουθούν τα αποτελέσματα για μέγεθος παραθύρου = 3 ημέρες:



Εικόνα 25: Σύγκριση προβλεπόμενων και πραγματικών τιμών - 1η Αρχιτεκτονική - Μέγεθος παραθύρου = 3




Εικόνα 26: Επαναλήψεις εκπαίδευσης - 1η Αρχιτεκτονική - Μέγεθος παραθύρου = 3

Ο πίνακας όσο αφορά τις τιμές της μετρικής RMSE για την διαδικασία εκπαίδευσης και την διαδικασία ελέγχου:

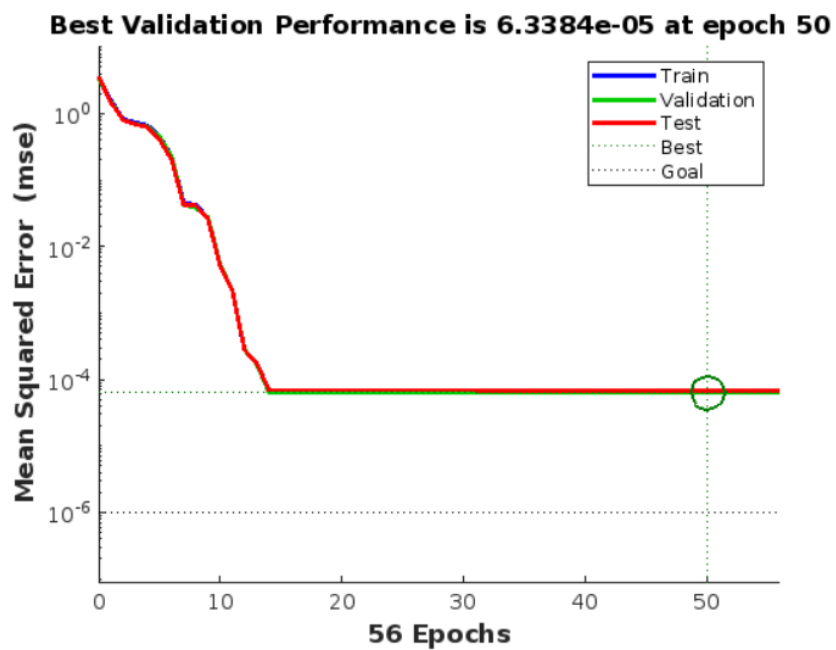
Πίνακας 4: Αποτελέσματα RMSE - 1η Αρχιτεκτονική - Μέγεθος Παραθύρου = 3

Σύνολο δεδομένων	Τιμή RMSE
Train Set	0.008222
Test Set	0.176288

Ακολουθούν τα αποτελέσματα για μέγεθος παραθύρου = 5 ημέρες:



Εικόνα 27: Σύγκριση προβλεπόμενων και πραγματικών τιμών - 1η Αρχιτεκτονική - Μέγεθος παραθύρου = 5



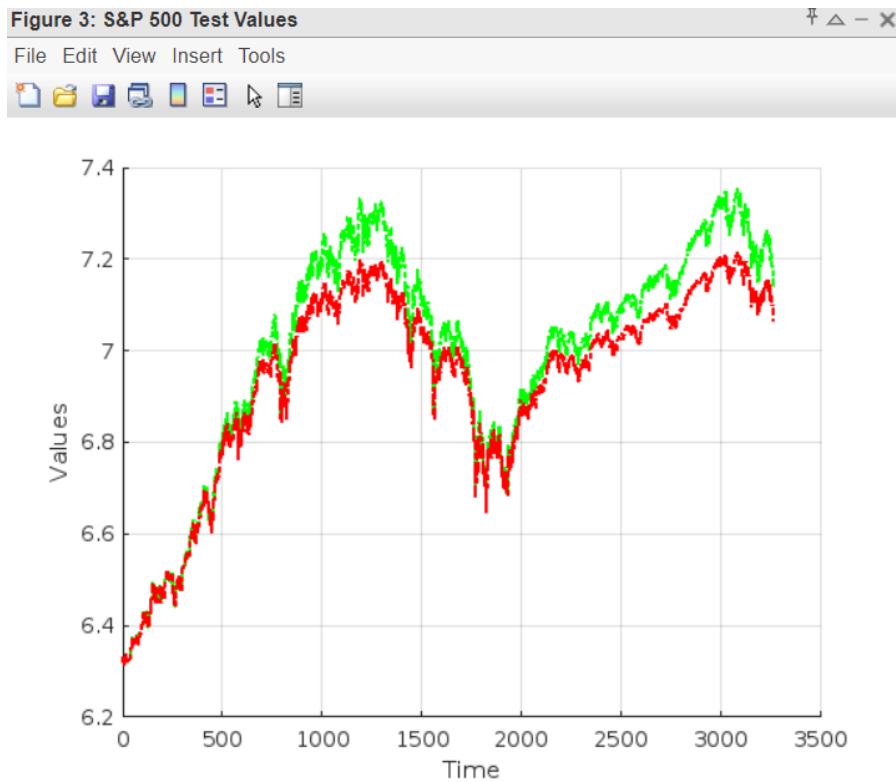
Εικόνα 28: Επαναλήψεις εκπαίδευσης - 1η Αρχιτεκτονική - Μέγεθος παραθύρου = 5

Ο πίνακας όσο αφορά τις τιμές της μετρικής RMSE για την διαδικασία εκπαίδευσης και την διαδικασία ελέγχου:


Πίνακας 5: Αποτελέσματα RMSE - 1η Αρχιτεκτονική - Μέγεθος Παραθύρου = 5

Σύνολο δεδομένων	Τιμή RMSE
Train Set	0.008239
Test Set	0.043336

Ακολουθούν τα αποτελέσματα για μέγεθος παραθύρου = 7 ημέρες:



Εικόνα 29: Σύγκριση προβλεπόμενων και πραγματικών τιμών - 1η Αρχιτεκτονική - Μέγεθος παραθύρου = 7




Εικόνα 30: Επαναλήψεις εκπαίδευσης - 1η Αρχιτεκτονική - Μέγεθος παραθύρου = 7

Ο πίνακας όσο αφορά τις τιμές της μετρικής RMSE για την διαδικασία εκπαίδευσης και την διαδικασία ελέγχου:


Πίνακας 6: Αποτελέσματα RMSE - 1η Αρχιτεκτονική - Μέγεθος Παραθύρου = 7

Σύνολο δεδομένων	Τιμή RMSE
Train Set	0.008256
Test Set	0.069011

Ακολουθούν τα αποτελέσματα για μέγεθος παραθύρου = 10 ημέρες:



Εικόνα 31: Σύγκριση προβλεπόμενων και πραγματικών τιμών - 1η Αρχιτεκτονική - Μέγεθος παραθύρου = 10



Εικόνα 32: Επαναλήψεις εκπαίδευσης - 1η Αρχιτεκτονική - Μέγεθος παραθύρου = 10

Ο πίνακας όσο αφορά τις τιμές της μετρικής RMSE για την διαδικασία εκπαίδευσης και την διαδικασία ελέγχου:

Πίνακας 7: Αποτελέσματα RMSE - 1η Αρχιτεκτονική - Μέγεθος Παραθύρου = 10

Σύνολο δεδομένων	Τιμή RMSE
Train Set	0.008290
Test Set	0.056022


Ακολουθεί συγκριτικός πίνακας με τις τιμές της μετρικής RMSE για όλα τα μεγέθη παραθύρου:

Πίνακας 8: Συγκριτικά αποτελέσματα RMSE - 1η Αρχιτεκτονική

Μέγεθος Παραθύρου	Τιμή RMSE
3	0.176288
5	0.043336
7	0.069011
10	0.056022

Από τον παραπάνω πίνακα διαπιστώνεται ότι για μέγεθος χρονικού παραθύρου = 5 ημέρες επετεύχθησαν τα καλύτερα αποτελέσματα όσο αφορά την τιμή της μετρικής RMSE. Αντίθετα, τα χειρότερα αποτελέσματα ελήφθησαν για τιμή παραθύρου = 3. Επιπλέον, αξίζει να αναφερθεί ότι σε όλες τις περιπτώσεις οι τιμές του RMSE ήταν ικανοποιητικές.

Για καλύτερη οπτικοποίηση των αποτελεσμάτων, παρατίθεται και το αντίστοιχο διάγραμμα εξέλιξης της τιμής του RMSE σε σχέση με την τιμή του χρονικού παραθύρου πρόβλεψης:



Εικόνα 33: RMSE - Time window size - 1η αρχιτεκτονική


Τέλος, παρουσιάζεται ο αντίστοιχος πίνακας στον οποίο καταγράφεται η επανάληψη στην οποία βρέθηκαν τα καλύτερα αποτελέσματα κατά την διάρκεια της εκπαίδευσης του μοντέλου:

Πίνακας 9: Εύρεση βέλτιστων αποτελεσμάτων - 1η αρχιτεκτονική

Μέγεθος Παραθύρου	Επανάληψη
3	217
5	50
7	376
10	31

3.4. Δεύτερη Αρχιτεκτονική Νευρωνικού Δικτύου

Το διάγραμμα της αρχιτεκτονικής του πρώτου νευρωνικού δικτύου, το οποίο υλοποιήθηκε:




Εικόνα 34: Διάγραμμα αρχιτεκτονικής δεύτερου νευρωνικού δικτύου

Στον παρακάτω πίνακα παρουσιάζονται πληροφορίες όσο αφορά τα κρυφά επίπεδα νευρώνων:


Πίνακας 10: Πλήθος νευρώνων ανά κρυφό επίπεδο 2ης αρχιτεκτονικής

Κρυφό Επίπεδο	Πλήθος Νευρώνων
1 ^ο	8
2 ^ο	4
3 ^ο	4
4 ^ο	1

Ακολουθούν τα αποτελέσματα για μέγεθος παραθύρου = 3 ημέρες:



Εικόνα 35: Σύγκριση προβλεπόμενων και πραγματικών τιμών - 2η Αρχιτεκτονική - Μέγεθος παραθύρου = 3




Εικόνα 36: Επαναλήψεις εκπαίδευσης - 2η Αρχιτεκτονική - Μέγεθος παραθύρου = 3

Ο πίνακας όσο αφορά τις τιμές της μετρικής RMSE για την διαδικασία εκπαίδευσης και την διαδικασία ελέγχου:


Πίνακας 11: Αποτελέσματα RMSE - 2η Αρχιτεκτονική - Μέγεθος Παραθύρου = 3

Σύνολο δεδομένων	Τιμή RMSE
Train Set	0.008398
Test Set	0.208900

Ακολουθούν τα αποτελέσματα για μέγεθος παραθύρου = 5 ημέρες:



Εικόνα 37: Σύγκριση προβλεπόμενων και πραγματικών τιμών - 2η Αρχιτεκτονική - Μέγεθος παραθύρου = 5




Εικόνα 38: Επαναλήψεις εκπαίδευσης - 2η Αρχιτεκτονική - Μέγεθος παραθύρου = 5

Ο πίνακας όσο αφορά τις τιμές της μετρικής RMSE για την διαδικασία εκπαίδευσης και την διαδικασία ελέγχου:


Πίνακας 12: Αποτελέσματα RMSE - 2η Αρχιτεκτονική - Μέγεθος Παραθύρου = 5

Σύνολο δεδομένων	Τιμή RMSE
Train Set	0.008252
Test Set	0.023451

Ακολουθούν τα αποτελέσματα για μέγεθος παραθύρου = 7 ημέρες:



Εικόνα 39: Σύγκριση προβλεπόμενων και πραγματικών τιμών - 2η Αρχιτεκτονική - Μέγεθος παραθύρου = 7




Εικόνα 40: Επαναλήψεις εκπαίδευσης - 2η Αρχιτεκτονική - Μέγεθος παραθύρου = 7

Ο πίνακας όσο αφορά τις τιμές της μετρικής RMSE για την διαδικασία εκπαίδευσης και την διαδικασία ελέγχου:


Πίνακας 13: Αποτελέσματα RMSE - 2η Αρχιτεκτονική - Μέγεθος Παραθύρου = 7

Σύνολο δεδομένων	Τιμή RMSE
Train Set	0.008307
Test Set	0.052669

Ακολουθούν τα αποτελέσματα για μέγεθος παραθύρου = 10 ημέρες:



Εικόνα 41: Σύγκριση προβλεπόμενων και πραγματικών τιμών - 2η Αρχιτεκτονική - Μέγεθος παραθύρου = 10



Εικόνα 42: Επαναλήψεις εκπαίδευσης - 2η Αρχιτεκτονική - Μέγεθος παραθύρου = 10

Ο πίνακας όσο αφορά τις τιμές της μετρικής RMSE για την διαδικασία εκπαίδευσης και την διαδικασία ελέγχου:

Πίνακας 14: Αποτελέσματα RMSE - 2η Αρχιτεκτονική - Μέγεθος Παραθύρου = 10

Σύνολο δεδομένων	Τιμή RMSE
Train Set	0.008288
Test Set	0.146371


Ακολουθεί συγκριτικός πίνακας με τις τιμές της μετρικής RMSE για όλα τα μεγέθη παραθύρου:

Πίνακας 15: Συγκριτικά αποτελέσματα RMSE - 2η Αρχιτεκτονική

Μέγεθος Παραθύρου	Τιμή RMSE
3	0.208900
5	0.023451
7	0.052669
10	0.146371

Από τον παραπάνω πίνακα διαπιστώνεται ότι για μέγεθος χρονικού παραθύρου = 5 ημέρες επετεύχθησαν τα καλύτερα αποτελέσματα όσο αφορά την τιμή της μετρικής RMSE. Αντίθετα, τα χειρότερα αποτελέσματα ελήφθησαν για τιμή παραθύρου = 3. Παρατηρείται η ίδια συμπεριφορά όσο αφορά το μέγεθος του παραθύρου σε σχέση και με την πρώτη αρχιτεκτονική. Επιπλέον, αξίζει να αναφερθεί ότι σε όλες τις περιπτώσεις οι τιμές του RMSE ήταν ικανοποιητικές.

Για καλύτερη οπτικοποίηση των αποτελεσμάτων, παρατίθεται και το αντίστοιχο διάγραμμα εξέλιξης της τιμής του RMSE σε σχέση με την τιμή του χρονικού παραθύρου πρόβλεψης:



Εικόνα 43: Time window size - RMSE - 2η Αρχιτεκτονική


Τέλος, παρουσιάζεται ο αντίστοιχος πίνακας στον οποίο καταγράφεται η επανάληψη στην οποία βρέθηκαν τα καλύτερα αποτελέσματα κατά την διάρκεια της εκπαίδευσης του μοντέλου

Πίνακας 16: Εύρεση βέλτιστων αποτελεσμάτων - 2η Αρχιτεκτονική

Μέγεθος Παραθύρου	Επανάληψη
3	40
5	114
7	36
10	80

3.5. Τρίτη Αρχιτεκτονική Νευρωνικού Δικτύου

Το διάγραμμα της αρχιτεκτονικής του τρίτου νευρωνικού δικτύου, το οποίο υλοποιήθηκε:




Εικόνα 44: Διάγραμμα αρχιτεκτονικής τρίτου νευρωνικού δικτύου

Στον παρακάτω πίνακα παρουσιάζονται πληροφορίες όσο αφορά τα κρυφά επίπεδα νευρώνων:


Πίνακας 17: Πλήθος κρυφών νευρώνων ανά επίπεδο 3ης αρχιτεκτονικής

Κρυφό Επίπεδο	Πλήθος Νευρώνων
1 ^ο	8
2 ^ο	6
3 ^ο	4
4 ^ο	2
5 ^ο	1

Ακολουθούν τα αποτελέσματα για μέγεθος παραθύρου = 3 ημέρες:



Εικόνα 45: Σύγκριση προβλεπόμενων και πραγματικών τιμών - 3η Αρχιτεκτονική - Μέγεθος παραθύρου = 3




Εικόνα 46: Επαναλήψεις εκπαίδευσης - 3η Αρχιτεκτονική - Μέγεθος παραθύρου = 3

Ο πίνακας όσο αφορά τις τιμές της μετρικής RMSE για την διαδικασία εκπαίδευσης και την διαδικασία ελέγχου:


Πίνακας 18: Αποτελέσματα RMSE - 3η Αρχιτεκτονική - Μέγεθος Παραθύρου = 3

Σύνολο δεδομένων	Τιμή RMSE
Train Set	0.008203
Test Set	0.064215

Ακολουθούν τα αποτελέσματα για μέγεθος παραθύρου = 5 ημέρες:



Εικόνα 47: Σύγκριση προβλεπόμενων και πραγματικών τιμών - 3η Αρχιτεκτονική - Μέγεθος παραθύρου = 5




Εικόνα 48: Επαναλήψεις εκπαίδευσης - 3η Αρχιτεκτονική - Μέγεθος παραθύρου = 5

Ο πίνακας όσο αφορά τις τιμές της μετρικής RMSE για την διαδικασία εκπαίδευσης και την διαδικασία ελέγχου:


Πίνακας 19: Αποτελέσματα RMSE - 3η Αρχιτεκτονική - Μέγεθος Παραθύρου = 5

Σύνολο δεδομένων	Τιμή RMSE
Train Set	0.008325
Test Set	0.137971

Ακολουθούν τα αποτελέσματα για μέγεθος παραθύρου = 7 ημέρες:



Εικόνα 49: Σύγκριση προβλεπόμενων και πραγματικών τιμών - 3η Αρχιτεκτονική - Μέγεθος παραθύρου = 7




Εικόνα 50: Επαναλήψεις εκπαίδευσης - 3η Αρχιτεκτονική - Μέγεθος παραθύρου = 7

Ο πίνακας όσο αφορά τις τιμές της μετρικής RMSE για την διαδικασία εκπαίδευσης και την διαδικασία ελέγχου:


Πίνακας 20: Αποτελέσματα RMSE - 3η Αρχιτεκτονική - Μέγεθος Παραθύρου = 7

Σύνολο δεδομένων	Τιμή RMSE
Train Set	0.008246
Test Set	0.071579

Ακολουθούν τα αποτελέσματα για μέγεθος παραθύρου = 10 ημέρες:



Εικόνα 51: Σύγκριση προβλεπόμενων και πραγματικών τιμών - 3η Αρχιτεκτονική - Μέγεθος παραθύρου = 10



Εικόνα 52: Επαναλήψεις εκπαίδευσης - 3η Αρχιτεκτονική - Μέγεθος παραθύρου = 10

Ο πίνακας όσο αφορά τις τιμές της μετρικής RMSE για την διαδικασία εκπαίδευσης και την διαδικασία ελέγχου:

Πίνακας 21: Αποτελέσματα RMSE - 3η Αρχιτεκτονική - Μέγεθος Παραθύρου = 10

Σύνολο δεδομένων	Τιμή RMSE
Train Set	0.008325
Test Set	0.129648

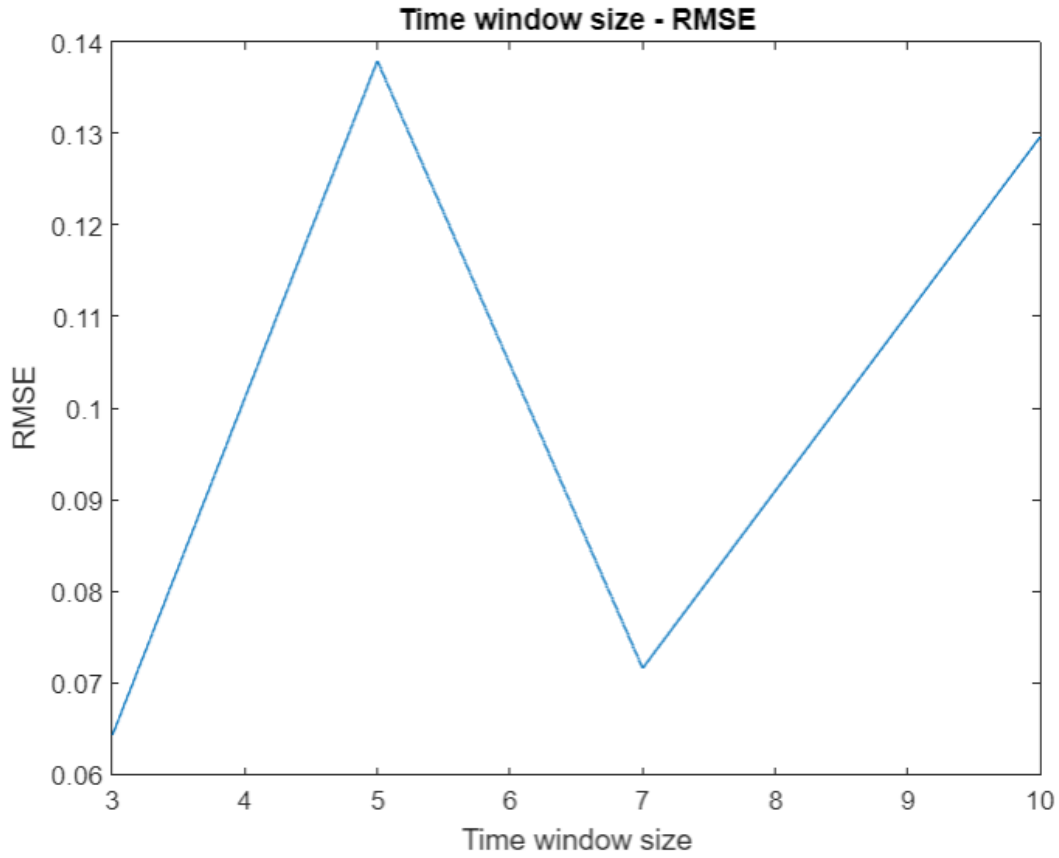
Ακολουθεί συγκριτικός πίνακας με τις τιμές της μετρικής RMSE για όλα τα μεγέθη παραθύρου:

Πίνακας 22: Συγκριτικά αποτελέσματα RMSE - 3η Αρχιτεκτονική

Μέγεθος Παραθύρου	Τιμή RMSE
3	0.064215
5	0.137971
7	0.071579
10	0.129648

Από τον παραπάνω πίνακα διαπιστώνεται ότι για μέγεθος χρονικού παραθύρου = 3 ημέρες επετεύχθησαν τα καλύτερα αποτελέσματα όσο αφορά την τιμή της μετρικής RMSE. Αντίθετα, τα χειρότερα αποτελέσματα ελήφθησαν για τιμή παραθύρου = 5. Παρατηρείται επομένως η ακριβώς αντίστροφη συμπεριφορά σε σχέση με τις 2 προηγούμενες αρχιτεκτονικές. Επιπλέον, αξίζει να αναφερθεί ότι σε όλες τις περιπτώσεις οι τιμές του RMSE ήταν ικανοποιητικές.

Για καλύτερη οπτικοποίηση των αποτελεσμάτων, παρατίθεται και το αντίστοιχο διάγραμμα εξέλιξης της τιμής του RMSE σε σχέση με την τιμή του χρονικού παραθύρου πρόβλεψης:



Εικόνα 53: Time window size - RMSE - 3η Αρχιτεκτονική

Τέλος, παρουσιάζεται ο αντίστοιχος πίνακας στον οποίο καταγράφεται η επανάληψη στην οποία βρέθηκαν τα καλύτερα αποτελέσματα κατά την διάρκεια της εκπαίδευσης του μοντέλου

Πίνακας 23: Εύρεση βέλτιστων αποτελεσμάτων - 3η Αρχιτεκτονική

Μέγεθος Παραθύρου	Επανάληψη
3	255
5	128
7	129
10	49

Κεφάλαιο 4: Συμπεράσματα - Προτάσεις

Στα πλαίσια της συγκεκριμένης διπλωματικής εργασίας, αρχικά πραγματοποιήθηκε περιεκτική βιβλιογραφική ανασκόπηση όσο αφορά τα νευρωνικά δίκτυα, αλλά και την τεχνική πρόβλεψης χρονοσειρών.

Στην συνέχεια, πραγματοποιήθηκε εκτεταμένη πειραματική διαδικασία σε περιβάλλον MATLAB, στην οποία χρησιμοποιήθηκαν τρεις διαφορετικές αρχιτεκτονικές νευρωνικών δικτύων προκειμένου να δοθεί λύση στο πρόβλημα πρόβλεψης σε σύνολο δεδομένων που αφορούσε τον χρηματιστηριακό δείκτη S &P 500. Για κάθε διαφορετική αρχιτεκτονική, μετρήθηκε η τιμή του RMSE για διάφορες τιμές χρονικών παραθύρων πρόβλεψης.

Ένα πρώτο συμπέρασμα, το οποίο προκύπτει από την πραγματοποίηση της πειραματικής διαδικασίας είναι ότι και στις 3 περιπτώσεις αρχιτεκτονικών και για όλες τις τιμές χρονικών παραθύρων ελήφθησαν ικανοποιητικά αποτελέσματα όσο αφορά το σφάλμα μεταξύ πραγματικών και προβλεπόμενων τιμών.

Ένα δεύτερο συμπέρασμα το οποίο προέκυψε είναι ότι ο μεγάλος όγκος του συνόλου δεδομένων (εγγραφές οι οποίες καλύπτουν τα έτη 1950 έως 2014), αλλά και η κανονικοποίηση των δεδομένων η οποία εφαρμόστηκε, συνέβαλλαν με θετικό τρόπο στην αύξηση της ποιότητας των αποτελεσμάτων.

Επιπλέον, το περιβάλλον MATLAB αποτέλεσε ένα αρκετά χρήσιμο εργαλείο για την πραγματοποίηση της πειραματικής διαδικασίας. Σημαντικά πλεονεκτήματα είναι το φιλικό προς τον χρήστη περιβάλλον διεπαφής, αλλά και η χρήση έτοιμων συναρτήσεων για την δημιουργία του εκάστοτε νευρωνικού δικτύου. Επιπλέον, η εύκολη δημιουργία γραφικών παραστάσεων διαδραμάτισε σημαντικό ρόλο στην ανάλυση και οπτικοποίηση των δεδομένων.

Είναι αδιαμφισβήτητο το γεγονός επίσης ότι η συγκεκριμένη πειραματική προσπάθεια μπορεί να επεκταθεί περαιτέρω στο μέλλον, έτσι ώστε να δημιουργηθούν ακόμη πληρέστερα συμπεράσματα στην συγκεκριμένη ερευνητική περιοχή.

Σαν μελλοντικές κατευθύνσεις, προτείνονται τα παρακάτω:

- Χρήση περισσότερων αρχιτεκτονικών νευρωνικών δικτύων με σκοπό την δημιουργία ακόμη περισσότερων συγκριτικών αποτελεσμάτων
- Εξέταση περισσότερων συνόλων δεδομένων. Στο σημείο αυτό προτείνεται και η χρήση δεδομένων μετοχών συγκεκριμένων εταιρειών πέρα από χρηματιστηριακούς δείκτες.
- Δοκιμή περισσότερων συνδυασμών παραμέτρων όσο αφορά την λειτουργία του νευρωνικού δικτύου (πχ. χρήση διαφορετικών συναρτήσεων ενεργοποίησης)
- Χρήση διαφορετικών τύπων αρχιτεκτονικών νευρωνικών δικτύων πέρα από τα δίκτυα εμπρόσθιας τροφοδότησης (πχ. RNN ή LSTM)

Πέρα από τις παραπάνω βασικές μελλοντικές κατευθύνσεις, θα μπορούσε προταθεί και η χρήση εναλλακτικού περιβάλλοντος υλοποίησης και διαφορετικής γλώσσας προγραμματισμού. Η γλώσσα Python, η οποία εξελίσσεται ραγδαίως και παρέχει πολύ σημαντικές δυνατότητες, αποτελεί την πλέον κυρίαρχη γλώσσα προγραμματισμού όσο αφορά την δημιουργία μοντέλων μηχανικής μάθησης. Με τον τρόπο αυτό, δυνητικά θα μπορούσαν να υλοποιηθούν ακόμη πιο περίπλοκες αρχιτεκτονικές με χρήση των βιβλιοθηκών της γλώσσας. Στόχος πάντοτε είναι οι όσο το δυνατόν ακριβέστερες προβλέψεις με ταυτόχρονη χρήση των υπολογιστικών πόρων σε χαμηλά επίπεδα.

ΠΑΡΑΡΤΗΜΑ ΚΩΔΙΚΑ

Κώδικας αρχείου code.m:

```
load('SP500.mat');

data = SP500.AdjClose;

N = length(data);

data = data(N:-1:1);

t = [1:1:N];

data = log(data);

t = t / N;

C= zeros(0,101);

figure('Name','S&P 500');

plot(t,data,'-','LineWidth',1.5);

ylabel('Adjusted Closing Value');

xlabel('Time');

grid on
```



```
size_of_time_window = 10;

[my_x,my_y] = gen_seq(data,size_of_time_window);

train_percent = 0.70;

validation_percent = 0.20;

[x_train,x_test,y_train,y_test]=
train_test_split(my_x,my_y,train_percent,validation_percent);

P = x_train(:,2:end);

T = x_train(:,1);

P = P';

T = T';

mynetwork = newff(P,T,[8 4 4 1],{'tansig' 'tansig' 'tansig' 'purelin'});

init(mynetwork);

mynetwork.trainParam.epochs = 1000;

mynetwork.trainParam.showCommandLine = 1;

mynetwork.trainParam.show = 1;

mynetwork.trainParam.goal = 0.000001;
```

```
mynetwork = train(mynetwork,P,T);

predicted_train = sim(mynetwork,P);

RMSE_train = sqrt(mean((predicted_train-T).^2));

P = x_test(:,2:end);

T = x_test(:,1);

P = P';

T = T';

predicted_test = sim(mynetwork,P);

Z = minus(T,predicted_test);

RMSE_test = sqrt(mean((predicted_test-T).^2));

figure_name = 'S&P 500 Train Values';

plot_results(figure_name,x_train(:,1),predicted_train)

figure_name = 'S&P 500 Test Values';

plot_results(figure_name,x_test(:,1),predicted_test)

fprintf('RMSE in training: %f\n',RMSE_train);
```

```
fprintf('RMSE in testing : %f\n',RMSE_test);
```

Κώδικας αρχείου gen_seq.m:

```
function [my_x,my_y] = gen_seq(data,size_of_time_window)

N = length(data);

my_x = zeros(size_of_time_window+1,N-size_of_time_window);

for k = 0:1:size_of_time_window

    my_x(k+1,:) = data(size_of_time_window+1-k:1:N-k);

end;

my_x = my_x';

my_number = N - size_of_time_window;

my_y = [1:1:my_number]';

my_y = my_y ./ my_number;

end
```

Κώδικας αρχείου train_test_split.m:

```
function [x_train,x_test,y_train,y_test] =  
train_test_split(my_x,my_y,train_percent,validation_percent)  
  
my_number = length(my_y);  
  
c = round(train_percent * my_number);  
  
tb = round((1-(validation_percent + train_percent)) * my_number);  
  
y_train = my_y(1:c);  
  
y_test = my_y(c+1:(my_number-tb));  
  
x_train = my_x(1:c,:);  
  
x_test = my_x(c+1:(my_number-tb),:);  
  
end
```

Κώδικας αρχείου plot_results.m:

```
function plot_results(figure_name,true,predicted)  
  
figure('Name',figure_name);  
  
hold on  
  
plot(true,'-g','LineWidth',1.5,'DisplayName','Actual Values');
```

```
plot(predicted,'-r','LineWidth',1.5,'DisplayName','Predicted Values');
```

```
hold off
```

```
grid on
```

```
xlabel('Time');
```

```
ylabel('Values');
```

```
end
```

ΒΙΒΛΙΟΓΡΑΦΙΑ – ΠΗΓΕΣ

- [1]. Gurney, K. (2018). An introduction to neural networks. CRC press.
- [2]. Grossi, E., & Buscema, M. (2007). Introduction to artificial neural networks. *European journal of gastroenterology & hepatology*, 19(12), 1046-1054.
- [3]. Rojas, R. (2013). *Neural networks: a systematic introduction*. Springer Science & Business Media.
- [4]. Sharma, S., Sharma, S., & Athaiya, A. (2017). Activation functions in neural networks. *Towards Data Sci*, 6(12), 310-316.
- [5]. <https://towardsdatascience.com/the-basics-of-neural-networks-neural-network-series-part-1-4419e343b2b>
- [6]. Khan, S., Rahmani, H., Shah, S. A. A., Bennamoun, M., Medioni, G., & Dickinson, S. (2018). A guide to convolutional neural networks for computer vision (Vol. 8, No. 1, pp. 1-207). San Rafael: Morgan & Claypool Publishers.
- [7]. Alshemali, B., & Kalita, J. (2020). Improving the reliability of deep neural networks in NLP: A review. *Knowledge-Based Systems*, 191, 105210.
- [8]. Begg, R., Kamruzzaman, J., & Sarker, R. (Eds.). (2006). *Neural networks in healthcare: Potential and challenges: Potential and challenges*. Igi Global.
- [9]. Huang, W., Lai, K. K., Nakamori, Y., Wang, S., & Yu, L. (2007). Neural networks in finance and economics forecasting. *International Journal of Information Technology & Decision Making*, 6(01), 113-140.
- [10]. Ivanov, R., Carpenter, T. J., Weimer, J., Alur, R., Pappas, G. J., & Lee, I. (2020). Verifying the safety of autonomous systems with neural network controllers. *ACM Transactions on Embedded Computing Systems (TECS)*, 20(1), 1-26.

- [11]. Yao, J., Teng, N., Poh, H. L., & Tan, C. L. (1998). Forecasting and analysis of marketing data using neural networks. *J. Inf. Sci. Eng.*, 14(4), 843-862.
- [12]. Oprea, M., & Matei, A. (2010, June). Applying artificial neural networks in environmental prediction systems. In *Recent Advances in Electrical Engineering Proceedings of the 11th WSEAS international conference on Automation & information* (pp. 110-115).
- [13]. Fariselli, P., Pazos, F., Valencia, A., & Casadio, R. (2002). Prediction of protein–protein interaction sites in heterocomplexes with neural networks. *European Journal of Biochemistry*, 269(5), 1356-1361.
- [14]. Sazli, M. H. (2006). A brief review of feed-forward neural networks. *Communications Faculty of Sciences University of Ankara Series A2-A3 Physical Sciences and Engineering*, 50(01).
- [15]. https://www.researchgate.net/publication/329068291_Do_Deep_Neural_Netw_orks_Outperform_Kernel_Regression_for_Functional_Connectivity_Prediction_of__Behavior/figures?lo=1&utm_source=google&utm_medium=organic
- [16]. O'Shea, K., & Nash, R. (2015). An introduction to convolutional neural networks. *arXiv preprint arXiv:1511.08458*.
- [17]. <https://www.mdpi.com/1424-8220/20/12/3539>
- [18]. Yu, Y., Si, X., Hu, C., & Zhang, J. (2019). A review of recurrent neural networks: LSTM cells and network architectures. *Neural computation*, 31(7), 1235-1270.
- [19]. <https://dataaspirant.com/how-recurrent-neural-network-rnn-works/>
- [20]. https://www.researchgate.net/publication/363907347_On_Building_Real_Time__Intelligent_Agricultural/figures?lo=1&utm_source=google&utm_medium=organic

- [21]. Khan, S., Naseer, M., Hayat, M., Zamir, S. W., Khan, F. S., & Shah, M. (2022). Transformers in vision: A survey. *ACM computing surveys (CSUR)*, 54(10s), 1-41.
- [22]. <https://machinelearningmastery.com/the-transformer-model/>
- [23]. Prieto, A., Prieto, B., Ortigosa, E. M., Ros, E., Pelayo, F., Ortega, J., & Rojas, I. (2016). Neural networks: An overview of early research, current frameworks and new challenges. *Neurocomputing*, 214, 242-268.
- [24]. Weigend, A. S. (2018). *Time series prediction: forecasting the future and understanding the past*. Routledge.
- [25]. Konar, A., & Bhattacharya, D. (2017). *Time-series prediction and applications*. Springer International Publishing.
- [26]. Liu, C., Hoi, S. C., Zhao, P., & Sun, J. (2016, February). Online arima algorithms for time series prediction. In *Proceedings of the AAAI conference on artificial intelligence (Vol. 30, No. 1)*.
- [27]. Kalekar, P. S. (2004). Time series forecasting using holt-winters exponential smoothing. *Kanwal Rekhi school of information Technology*, 4329008(13), 1-13.
- [28]. Aoki, M. (2013). *State space modeling of time series*. Springer Science & Business Media.
- [29]. Brodersen, K. H., Gallusser, F., Koehler, J., Remy, N., & Scott, S. L. (2015). Inferring causal impact using Bayesian structural time-series models.
- [30]. Zivot, E., & Wang, J. (2006). Vector autoregressive models for multivariate time series. *Modeling financial time series with S-PLUS®*, 385-429.
- [31]. Maller, R. A., Müller, G., & Szimayer, A. (2008). GARCH modelling in continuous time for irregularly spaced time series data.

- [32]. Granger, C. W. J., & Hatanaka, M. (2015). Spectral Analysis of Economic Time Series.(PSME-1) (Vol. 2066). Princeton university press.
- [33]. Moniz, N., Branco, P., & Torgo, L. (2017). Resampling strategies for imbalanced time series forecasting. International Journal of Data Science and Analytics, 3, 161-181.
- [34]. Lim, B., & Zohren, S. (2021). Time-series forecasting with deep learning: a survey. Philosophical Transactions of the Royal Society A, 379(2194), 20200209.
- [35]. Ren, L., Jia, Z., Laili, Y., & Huang, D. (2023). Deep Learning for Time-Series Prediction in IIoT: Progress, Challenges, and Prospects. IEEE Transactions on Neural Networks and Learning Systems.