



ΕΛΛΗΝΙΚΗ ΔΗΜΟΚΡΑΤΙΑ
Εθνικόν και Καποδιστριακόν
Πανεπιστήμιον Αθηνών
— ΙΔΡΥΘΕΝ ΤΟ 1837 —

ΣΧΟΛΗ ΟΙΚΟΝΟΜΙΚΩΝ ΚΑΙ ΠΟΛΙΤΙΚΩΝ ΕΠΙΣΤΗΜΩΝ
ΤΜΗΜΑ ΟΙΚΟΝΟΜΙΚΩΝ ΕΠΙΣΤΗΜΩΝ

Πρόγραμμα Μεταπτυχιακών Σπουδών
«ΔΙΟΙΚΗΣΗ ΟΙΚΟΝΟΜΙΚΩΝ ΜΟΝΑΔΩΝ»

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΤΙΤΛΟΣ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ

**Αξιολόγηση μοντέλων πρόβλεψης Μηχανικής
μάθησης με την χρήση των Χρονοσειρών του
Bitcoin και του Ethereum**

ΟΝΟΜΑ ΦΟΙΤΗΤΗ

ΠΑΝΑΓΙΩΤΗΣ ΜΠΑΛΑΤΣΟΣ

ΟΝΟΜΑ ΕΠΙΒΛΕΠΟΝΤΑ ΚΑΘΗΓΗΤΗ

ΣΠΥΡΟΣ ΜΗΣΙΑΚΟΥΛΗΣ

ΑΘΗΝΑ
ΙΟΥΛΙΟΣ, 2022

© Εθνικό και Καποδιστριακό Πανεπιστήμιο Αθηνών, 2018

Η παρούσα Εργασία καθώς και τα αποτελέσματα αυτής, αποτελούν συνιδιοκτησία του ΕΚΠΑ και του φοιτητή, ο καθένας από τους οποίους έχει το δικαίωμα ανεξάρτητης χρήσης, αναπαραγωγής και αναδιανομής τους (στο σύνολο ή τμηματικά) για διδακτικούς και ερευνητικούς σκοπούς, σε κάθε περίπτωση αναφέροντας τον τίτλο και το συγγραφέα της Εργασίας καθώς και το όνομα του ΕΚΠΑ όπου εκπονήθηκε.



«Αξιολόγηση μοντέλων πρόβλεψης Μηχανικής μάθησης με την χρήση των Χρονοσειρών του Bitcoin και του Ethereum»

Παναγιώτης Μπαλατσός

Επιβλέπων Καθηγητής:

Σπύρος Μησιακούλης

Καθηγητής Εθνικού και Καποδιστριακού Πανεπιστημίου Αθηνών

Αθήνα, Ιούλιος, 2022

Θα ήθελα να απευθύνω θερμές ευχαριστίες στον επιβλέποντα καθηγητή μου Κο Σπυρίδων Μησιακούλη για την εμπιστοσύνη που μου έδειξε, την καθοδήγησή του κατά τη διάρκεια της εκπόνησης της μεταπτυχιακής διπλωματικής εργασίας μου καθώς και τη δυνατότητα που μου έδωσε να ασχοληθώ με το συγκεκριμένο θέμα της εργασίας.

Επίσης, θερμές ευχαριστίες θα ήθελα να απευθύνω και στους γονείς μου (Ευδοξία και Δημοσθένη) για τη πίστη τους σε εμένα και τις δυνατότητές μου καθώς και την αστείρευτη συναισθηματική και ψυχολογική υποστήριξη που μου έδειξαν όλα αυτά τα χρόνια καθώς και για το συνεχές μέλημά τους, ως εκπαιδευτικοί και οι ίδιοι, για την καλύτερη δυνατή μόρφωση μου από μικρή ηλικία.

Τέλος, θα ήθελα να αφιερώσω αυτήν την διπλωματική εργασία στο σημαντικότερο άνθρωπο στη ζωή μου, την κόρη μου Μελίνα Μαρία που μου δίνει δύναμη και χαρές στην ζωή μου και να της ευχηθώ εκ βάθους καρδιάς να είναι η πορεία της ζωής της, πλημμυρισμένη με φως, χαμόγελα, κι' αγάπη.

Περίληψη

Το θέμα της μεταπτυχιακής εργασίας αφορά την αξιολόγηση μεθόδων μηχανικής μάθησης για την πρόβλεψη τιμών χρονοσειρών καθώς και η σύγκριση αυτών των προβλέψεων με διαφορετικές παραμέτρους.

Λόγω της ταχείας ανάπτυξης της επιστήμης και της τεχνολογίας τα τελευταία χρόνια, οι μέθοδοι μηχανικής μάθησης προσφέρουν πολλές δυνατότητες σε πολλούς τομείς, όπως η πρόβλεψη μελλοντικών τιμών χρονοσειρών. Σκοπός αυτής της εργασίας είναι τόσο η θεωρητική όσον αφορά την βαθιά μάθηση όσο και το πρακτικό μέρος αποβλέπει στην αξιολόγηση των μοντέλων πρόβλεψης των δύο τύπων τεχνητών νευρωνικών δικτύων που επιλέχτηκαν.

Το πρώτο μέρος της εργασίας περιλαμβάνει το απαιτούμενο θεωρητικό υπόβαθρο, όπως τα βασικά στοιχεία της Μηχανική Μάθησης, των τεχνητών νευρωνικών δικτύων, της βαθιάς μάθησης, των χρονοσειρών και έπειτα αναφέρονται οι βασικές ιδιότητες των κρυπτονομισμάτων.

Το δεύτερο και πρακτικό μέρος της εργασίας ασχολείται με την αξιολόγηση των δύο τεχνητών νευρωνικών δικτύων που χρησιμοποιήθηκαν για την πρόβλεψη των τιμών δύο ευρέως γνωστών κρυπτονομισμάτων (Bitcoin, Ethereum). Εκπαιδεύοντας και χρησιμοποιώντας τα βαθιά νευρωνικά δίκτυα (DNN) και τα δίκτυα μακροπρόθεσμης μνήμης (LSTM), προβλέφθηκαν οι μελλοντικές τιμές των χρονοσειρών του Bitcoin και του Ethereum και αυτές οι προβλέψεις συγκρίθηκαν αλλάζοντας την τοπολογία των δικτύων. Ταυτόχρονα, οι προβλέψεις συγκρίνονται μεταξύ τους λαμβάνοντας υπόψη τις διαφορετικές μεθόδους εκπαίδευσης (διαφορίση και μη διαφορίση χρονοσειρών) που χρησιμοποιήθηκαν. Τέλος, οι συγκρίσεις σχετικά με την απόδοση των μοντέλων πρόβλεψης γίνεται με βάση συγκεκριμένες μετρικές (RMSE, MSE, MAE κλπ.) και μέσω ενός συστήματος κατάταξης (Score Card) από το οποίο προκύπτουν χρήσιμα συμπεράσματα.

Λέξεις – Κλειδιά

Χρονολογικές Σειρές, Πρόβλεψη, Μηχανική Μάθηση, Βαθιά Μάθηση, Τεχνητά Νευρωνικά Δίκτυα, Βαθιά Νευρωνικά Δίκτυα(DNN), Νευρωνικά Δίκτυα Μακροπρόθεσμης Μνήμης(LSTM), Κρυπτονομίσματα, Μετρικές Αξιολόγησης.

Abstract

The subject of this postgraduate thesis is the study of machine learning methods to predict time series prices of two cryptocurrencies and compare these predictions with different parameters.

The aim of this study is to evaluate the reliability and the performance in terms of predictability of two types of Deep learning Artificial Neural Networks (DNN and LSTM) with the use of time series.

The first part of this thesis includes the required theoretical background, such as the basics of machine learning, artificial neural networks, deep learning, time series, and the fundamentals of cryptocurrencies.

The second part which is the practical part of this study focuses on the evaluation of the prediction models and the methodology that was applied to train the two types of the artificial neural networks (DNN and LSTM) .The numerical experiments are conducted using two time series from Cryptocurrency space (Bitcoin and Ethereum). In addition, the reliability of the predictions of each artificial Neural Network was evaluated by taking into account the different training methods that were used. Finally, the comparison of the proposed models was made based on specific metrics and through a Ranking system.

Keywords

Time Series, Prediction, Machine Learning, Deep Learning, Artificial Neural Networks, Deep Neural Networks (DNN), Long-Short Term Memory Neural Networks (LSTM), Cryptocurrencies

Περιεχόμενα

Περίληψη.....	v
Abstract	vii
Περιεχόμενα	viii
Κατάλογος Εικόνων / Σχημάτων	x
Κατάλογος Πινάκων	xii
Συντομογραφίες & Ακρωνύμια.....	xiii
1 Μηχανική Μάθηση (Machine Learning).....	1
1.1 Εισαγωγή στην Μηχανική Μάθηση	1
1.2 Οι βασικές αρχές της μαθησιακής Διαδικασίας	2
1.3 Το πεδίο της Μηχανικής Μάθησης.....	3
1.4 Πότε μαθαίνει μια μηχανή;.....	4
1.5 Μηχανική Μάθηση: Τομείς Επιστήμης.....	4
1.6 Η συμβολή της μηχανικής μάθησης	7
1.7 Τύποι Μάθησης.....	8
2 Νευρωνικά Δίκτυα	11
2.1 Εισαγωγή στα Νευρωνικά Δίκτυα	11
2.2 Βιολογικά Νευρωνικά Δίκτυα	12
2.3 Τεχνητά Νευρωνικά Δίκτυα.....	13
2.4 Αρχιτεκτονικές Τεχνητών Νευρωνικών Δικτύων.....	13
2.4.1 Τεχνητά Νευρωνικά Δίκτυα Ενός Επιπέδου (Εμπρόσθιας Τροφοδότησης).14	
2.4.2 Τεχνητά Νευρωνικά Δίκτυα Πολλαπλών Επιπέδων (Εμπρόσθιας Τροφοδότησης).....	15
2.4.3 Επενταλαμβανόμενα Τεχνητά Νευρωνικά Δίκτυα.....	16
2.5 Διαδικασίες μάθησης και Εκπαίδευσης Τεχνητών Νευρωνικών Δικτύων	17
3 Χρονολογικές Σειρές	19
3.1 Ενοιολογική προσέγγιση	19
3.1.1 Χαρακτηριστικά Χρονολογικών Σειρών	20
4 Βαθιά Μάθηση (Deep Learning).....	22
4.1 Εισαγωγή στην βαθιά μάθηση	22
4.2 Long Short-Term Memory networks	23
4.3 Μέθοδος Adam	25
4.4 Σχετικές Έρευνες - Ανασκόπηση Βιβλιογραφίας.....	26
5 Εισαγωγή στα Κρυπτονομίσματα	28
5.1 Εισαγωγή	28
5.2 Bitcoin.....	31
5.2.1 Βασικές Έννοιες.....	31
5.2.2 Παραγωγή Bitcoin και Mining.....	33
5.2.3 Block Chain και Hash	33
5.3 Ethereum	35
5.3.1 Βασικές Έννοιες.....	35
5.3.2 Παραγωγή Ethereum και Mining.....	37
5.3.3 Blockchain και hash.....	38
6 Εφαρμογή/Υλοποίηση προβλήματος	39

6.1	Περιγραφή Προβλήματος	39
6.1.1	Συνολικά Δεδομένα.....	39
6.1.2	Μεθοδολογία Έρευνας	43
6.2	Παρουσίαση Αποτελεσμάτων	48
6.2.1	Τεχνητό Νευρωνικό Δίκτυο (DNN).....	50
6.2.2	LSTM (Long-Short Term Memory Network).....	51
6.2.3	Συνολικά Αποτελέσματα (Σύστημα Κατάταξης).....	52
6.3	Συμπεράσματα	56
	Βιβλιογραφία.....	59
	Παράρτημα Α: Αποτελέσματα Deep Neural Network.....	62
	Παράρτημα Β: Αποτελέσματα LSTM	78

Κατάλογος Εικόνων / Σχημάτων

Εικόνα 1-1. Συσχέτιση Τομέων Επιστήμης.....	1
Εικόνα 2-1. Αντιστοιχία Βιολογικού με Τεχνητό Νευρώνα	13
Εικόνα 2-2. Εμπρόσθιας τροφοδότησης νευρωνικό δίκτυο ενός επιπέδου	15
Εικόνα 2-3. Εμπρόσθιας τροφοδότησης νευρωνικό δίκτυο πολλαπλών επιπέδων	15
Εικόνα 2-4. Επαναλαμβανόμενο δίκτυο χωρίς βρόγχους αυτοανάδρασης και κρυφούς νευρώνες.....	17
Εικόνα 2-5. Επαναλαμβανόμενο δίκτυο με κρυφούς νευρώνες.....	17
Εικόνα 4-1. Η Δομή του μοντέλου πρόβλεψης LSTM.....	24
Εικόνα 4-2. Αρχιτεκτονική του LSTM	25
Εικόνα 5-1. Κεντρικά έναντι αποκεντρωμένων δικτύων	30
Εικόνα 5-2. Λογότυπο Bitcoin	31
Εικόνα 5-3. Λειτουργία Blockchain του Bitcoin (S. Ghimire, 2019)	34
Εικόνα 5-4. Λογότυπο Ethereum	35
Εικόνα 6-1. Τιμή Κλεισίματος 2020-2022 (Bitcoin).....	40
Εικόνα 6-2. Τιμή Κλεισίματος 2020-2022 (Ethereum).....	40
Εικόνα 6-3. Καταμερισμός Δεδομένων Χρονοσειρών	41
Εικόνα 6-4. Training and Validation Set (Bitcoin)	41
Εικόνα 6-5. Training and Validation Set (Ethereum).....	42
Εικόνα 6-6. Training and Test Set (Bitcoin)	42
Εικόνα 6-7. Training and Test Set (Ethereum)	42
Εικόνα 6-8. Πλαίσιο Μοντέλου Πρόβλεψης (Διάγραμμα Ροής)	45
Εικόνα 6-9. Παράμετροι Διαχωρισμού Δεδομένων	49
Εικόνα 6-10. Παράμετροι LSTM.....	50
Εικόνα 6-11. Παράμετροι DNN	50
Εικόνα 6-12. Κώδικας Υπολογισμού Μετρήσεων.....	50
Εικόνα 0-1. Training - Test Results (DNN 40-18-10-1) - χωρίς Διαφόριση	62
Εικόνα 0-2. Test results (40-18-10-1) - Χωρίς Διαφόριση.....	62
Εικόνα 0-3. Training - Test Results (DNN 40-18-10-1) - με Διαφόριση.....	63
Εικόνα 0-4. Test Results (DNN 40-18-10-1) - με Διαφόριση.....	63
Εικόνα 0-5. Training - Test Results (DNN 82-45-10-1) - χωρίς Διαφόριση	64
Εικόνα 0-6. Test results (82-45-10-1) - Χωρίς Διαφόριση.....	64
Εικόνα 0-7. Training - Test Results (DNN 82-45-10-1) - με Διαφόριση.....	65
Εικόνα 0-8. Test Results (DNN 82-45-10-1) - με Διαφόριση	65
Εικόνα 0-9. Training - Test Results (DNN 100-65-24-1) - χωρίς Διαφόριση	66
Εικόνα 0-10. Test Results (DNN 100-65-24-1) - χωρίς Διαφόριση.....	66
Εικόνα 0-11. Training - Test Results (DNN 100-65-24-1) - με Διαφόριση.....	67
Εικόνα 0-12. Test Results (DNN 82-45-10-1) - με Διαφόριση	67
Εικόνα 0-13. Training - Test Results (DNN 150-50-18-1) - χωρίς Διαφόριση	68
Εικόνα 0-14. Test Results (DNN 150-50-18-1) - χωρίς Διαφόριση.....	68
Εικόνα 0-15. Training - Test Results (DNN 150-50-18-1) - με Διαφόριση.....	69
Εικόνα 0-16. Test Results (DNN 150-50-18-1) - με Διαφόριση	69
Εικόνα 0-17. Training - Test Results (DNN 40-18-10-1) - χωρίς Διαφόριση	70
Εικόνα 0-18. Test results (40-18-10-1) - Χωρίς Διαφόριση.....	70

Εικόνα 0-19. Training - Test Results (DNN 40-18-10-1) - με Διαφύριση.....	71
Εικόνα 0-20. Test Results (DNN 40-18-10-1) - με Διαφύριση.....	71
Εικόνα 0-21. Training - Test Results (DNN 82-45-10-1) - χωρίς Διαφύριση.....	72
Εικόνα 0-22. Test results (82-45-10-1) - Χωρίς Διαφύριση.....	72
Εικόνα 0-23. Training - Test Results (DNN 82-45-10-1) - με Διαφύριση.....	73
Εικόνα 0-24. Test Results (DNN 82-45-10-1) - με Διαφύριση.....	73
Εικόνα 0-25. Training - Test Results (DNN 100-65-24-1) - χωρίς Διαφύριση.....	74
Εικόνα 0-26. Test Results (DNN 100-65-24-1) - χωρίς Διαφύριση.....	74
Εικόνα 0-27. Training - Test Results (DNN 100-65-24-1) - με Διαφύριση.....	75
Εικόνα 0-28. Test Results (DNN 82-45-10-1) - με Διαφύριση.....	75
Εικόνα 0-29. Training - Test Results (DNN 150-50-18-1) - χωρίς Διαφύριση.....	76
Εικόνα 0-30. Test Results (DNN 150-50-18-1) - χωρίς Διαφύριση.....	76
Εικόνα 0-31. Training - Test Results (DNN 150-50-18-1) - με Διαφύριση.....	77
Εικόνα 0-32. Test Results (DNN 150-50-18-1) - με Διαφύριση.....	77
Εικόνα 0-1. Training - Test Results (LSTM 25-15-1) - χωρίς Διαφύριση.....	78
Εικόνα 0-2. Test results (LSTM 25-15-1) - Χωρίς Διαφύριση.....	78
Εικόνα 0-3. Training - Test Results (LSTM 25-15-1) - με Διαφύριση.....	79
Εικόνα 0-4. Test Results (LSTM 25-15-1) - με Διαφύριση.....	79
Εικόνα 0-5. Training - Test Results (LSTM 64-32-1) - χωρίς Διαφύριση.....	80
Εικόνα 0-6. Test results (64-32-1) - Χωρίς Διαφύριση.....	80
Εικόνα 0-7. Training - Test Results (LSTM 64-32-1) - με Διαφύριση.....	81
Εικόνα 0-8. Test Results (LSTM 64-32-1) - με Διαφύριση.....	81
Εικόνα 0-9. Training - Test Results (LSTM 120-60-1) - χωρίς Διαφύριση.....	82
Εικόνα 0-10. Test Results (LSTM 120-60-1) - χωρίς Διαφύριση.....	82
Εικόνα 0-11. Training - Test Results (LSTM 120-60-1) - με Διαφύριση.....	83
Εικόνα 0-12. Test Results (LSTM 120-60-1) - με Διαφύριση.....	83
Εικόνα 0-13. Training - Test Results (LSTM 160-85-1) - χωρίς Διαφύριση.....	84
Εικόνα 0-14. Test Results (LSTM 160-85-1) - χωρίς Διαφύριση.....	84
Εικόνα 0-15. Training - Test Results (LSTM 160-85-1) - με Διαφύριση.....	85
Εικόνα 0-16. Test Results (LSTM 160-85-1) - με Διαφύριση.....	85
Εικόνα 0-17. Training - Test Results (LSTM 25-15-1) - χωρίς Διαφύριση.....	86
Εικόνα 0-18. Test results (LSTM 25-15-1) - Χωρίς Διαφύριση.....	86
Εικόνα 0-19. Training - Test Results (LSTM 25-15-1) - με Διαφύριση.....	87
Εικόνα 0-20. Test Results (LSTM 25-15-1) - με Διαφύριση.....	87
Εικόνα 0-21. Training - Test Results (LSTM 64-32-1) - χωρίς Διαφύριση.....	88
Εικόνα 0-22. Test results (64-32-1) - Χωρίς Διαφύριση.....	88
Εικόνα 0-23. Training - Test Results (LSTM 64-32-1) - με Διαφύριση.....	89
Εικόνα 0-24. Test Results (LSTM 64-32-1) - με Διαφύριση.....	89
Εικόνα 0-25. Training - Test Results (LSTM 120-60-1) - χωρίς Διαφύριση.....	90
Εικόνα 0-26. Test Results (LSTM 120-60-1) - χωρίς Διαφύριση.....	90
Εικόνα 0-27. Training - Test Results (LSTM 120-60-1) - με Διαφύριση.....	91
Εικόνα 0-28. Test Results (LSTM 120-60-1) - με Διαφύριση.....	91
Εικόνα 0-29. Training - Test Results (LSTM 160-85-1) - χωρίς Διαφύριση.....	92
Εικόνα 0-30. Test Results (LSTM 160-85-1) - χωρίς Διαφύριση.....	92
Εικόνα 0-31. Training - Test Results (LSTM 160-85-1) - με Διαφύριση.....	93
Εικόνα 0-32. Test Results (LSTM 160-85-1) - με Διαφύριση.....	93

Κατάλογος Πινάκων

Πίνακας 6-1. DNN Metrics (Bitcoin)	51
Πίνακας 6-2. DNN Metrics (Ethereum)	51
Πίνακας 6-3. LSTM Metrics (Bitcoin).....	52
Πίνακας 6-4. LSTM Metrics (Ethereum).....	52
Πίνακας 6-5. Bitcoin (DNN AND LSTM SCORE CARD)	53
Πίνακας 6-6. Ethereum (DNN AND LSTM SCORE CARD).....	54
Πίνακας 6-7. Bitcoin and Ethereum (DNN AND LSTM - SCORE CARD)	55

Συνομογραφίες & Ακρωνύμια

ANN Artificial Neural Network

LSTM Long Short Term Memory

TNΔ Τεχνητά Νευρωνικά Δίκτυα


DL Deep Learning

1 Μηχανική Μάθηση (Machine Learning)

1.1 Εισαγωγή στην Μηχανική Μάθηση

Η Μάθηση θεωρείται μία από τις θεμελιώδεις γνωστικές διαδικασίες και ως πνευματική διαδικασία παρατηρείται μόνο στον άνθρωπο, η οποία κατευθύνεται σε μεγάλο βαθμό από τον ίδιο και εμφανίζεται στην συμπεριφορά του. Μέσω της μάθησης δύναται να τροποποιηθεί μία συμπεριφορά ως αποτέλεσμα εμπειρίας, διαμορφώνοντας τις προϋποθέσεις για την μακροπρόθεσμη βελτιστοποίηση της μέσω της αλλαγής. Αυτή η αλλαγή εφαρμόζει σταδιακές τροποποιήσεις στη συμπεριφορά, σύμφωνα με ένα δεδομένο κριτήριο, όταν συμβαίνει μία παρόμοια κατάσταση (Λαμπρόπουλος, 2015). Σε αυτό το πλαίσιο, οι άνθρωποι αλλάζουν τη συμπεριφορά τους με τέτοιο τρόπο που τους κάνει να αποδίδουν καλύτερα στο μέλλον (Witten, 2005).

Η Μηχανική Μάθηση συμπεριλαμβάνεται στον τομέα της επιστήμης της Πληροφορικής, Τεχνητής Νοημοσύνης και στόχος της είναι η ανάπτυξη αλγορίθμων και πιο συγκεκριμένα εφαρμογών υπολογιστών που έχουν την ικανότητα να μαθαίνουν, ανάλογα με τα δεδομένα που τροφοδοτούνται και να βελτιώνουν την απόδοσή τους. (Λαμπρόπουλος, 2015). Αυτή η μέθοδος εφαρμόζεται στους υπολογιστές ώστε να προγραμματιστούν μόνοι τους με βάση την εμπειρία και κάποιες αρχικές δομημένες γνώσεις (Mitchell, 2006).



Εικόνα 1-1. Συσχέτιση Τομέων Επιστήμης

1.2 Οι βασικές αρχές της μαθησιακής Διαδικασίας

Η μαθησιακή διαδικασία ως προς τον ορισμό της, πρέπει να πληροί τις παρακάτω βασικές προϋποθέσεις (Camastra, 2007) :

- Σύλληψη νέων δηλωτικών γνώσεων.
- Οργάνωση της νέας γνώσης σε γενικές αποτελεσματικές αναπαραστάσεις.
- Ανάπτυξη κινητικών και γνωστικών δεξιοτήτων μέσω διδασκαλίας ή εξάσκησης.
- Ανακάλυψη νέων γεγονότων και θεωριών μέσω παρατήρησης και πειραματισμού.

Με βάση τα παραπάνω δεδομένα είναι άμεσα αντιληπτό ότι οι περισσότεροι από τους προτεινόμενους ορισμούς μάθησης εμπεριέχουν ως κοινό χαρακτηριστικό την απόκτηση των γνώσεων ή των δεξιοτήτων μέσω της μελέτης, της διδασκαλίας ή των εμπειριών (Λαμπρόπουλος & Τσιχριντζής, 2015). Συγκεκριμένα, η γνώση δημιουργείται μέσα από την αλληλεπίδραση με το περιβάλλον, όπου τα αποτελέσματα αυτής της διαδικασίας οδηγούν σταδιακά στη βελτίωση των στοιχείων συμπεριφοράς, λαμβάνοντας υπόψη τις ακόλουθες παραμέτρους (Russell & Norvig, 2010):

- Τις συνιστώσες που χρήζουν βελτίωσης.
- Την προηγούμενη γνώση και το είδος των αναπαραστάσεων που έχει ήδη το άτομο.
- Την διαθέσιμη ανατροφοδότηση πληροφοριών από τα οποία μπορείτε να μάθει.

Οι πληροφορίες και οι γνώσεις μέσω της διαδικασίας της μοντελοποίησης καθώς και η προσομοίωση δομών και μηχανισμών που καθιστούν δυνατή τη μάθηση, εισάγουν την έννοια του «Γνωστικού Συστήματος». Ένα γνωστικό σύστημα είναι ουσιαστικά ένα φυσικό ή τεχνητό σύστημα επεξεργασίας πληροφοριών, συμπεριλαμβανομένων και αυτών που έχουν την ικανότητα να αντιλαμβάνονται, να μαθαίνουν, να συλλογίζονται, να λαμβάνουν αποφάσεις να επικοινωνούν και να δρουν. Η έννοια της μάθησης σε ένα γνωστικό σύστημα σχετίζεται με την ικανότητα απόκτησης γνώσης μέσω της αλληλεπίδρασης με το περιβάλλον στο οποίο λειτουργεί το σύστημα, καθώς και τη δυνατότητα βελτίωσης της κατάστασης του όταν εκτελεί κάποια λειτουργία και κατά συνέπεια την απόδοσης του μέσω της επανάληψης (Vlahavas et al., 2006).

1.3 Το πεδίο της Μηχανικής Μάθησης

Η μηχανική μάθηση ανήκει στο ερευνητικό πεδίο της τεχνητής νοημοσύνης, που διασταυρώνεται άμεσα με αρκετά επιστημονικά πεδία όπως η στατιστική, τα μαθηματικά και η πληροφορική μεταξύ άλλων. Υπό αυτό το πεδίο εφαρμογής, η μαθησιακή διαδικασία είναι βασισμένη σε παραδείγματα τα οποία δύναται να σχετίζονται με δεδομένα από παρατηρήσεις, οδηγίες και άλλα.

Η μηχανική μάθηση εστιάζει στους αλγόριθμους που δίνουν την δυνατότητα στα υπολογιστικά συστήματα να εκτελέσουν περίπλοκες διαδικασίες, εκμεταλλευόμενοι τις προηγούμενες πληροφορίες και γνώσεις. Ένα από τα κύρια χαρακτηριστικά της μηχανικής μάθησης είναι η αυτοματοποίηση διαδικασιών με ή χωρίς την ελάχιστη δυνατή ανθρώπινη προσπάθεια. Η ταξινόμηση και η παλινδρόμηση αποτελούν τις δύο κύριες κατηγορίες προβλημάτων στον τομέα της μηχανικής μάθησης. Στην πρώτη περίπτωση, ο στόχος είναι η κατηγοριοποίηση των δεδομένων σε προκαθορισμένες κατηγορίες-κλάσεις, ενώ στη δεύτερη ο στόχος είναι να προβλέψουμε μια πραγματική τιμή. Αυτό που είναι επιθυμητό και στις δύο περιπτώσεις είναι η ανάπτυξη αλγορίθμων γενικού σκοπού οι οποίες είναι αποτελεσματικές (Scharire, 2008).

Συμπερασματικά, η μηχανική μάθηση αναφέρεται στην υπολογιστική μοντελοποίηση των διαδικασιών μάθησης, με βάση την διαθέσιμες θεωρίες μάθησης. Στον τομέα της μηχανικής μάθησης, διαφορετικές προσεγγίσεις διακρίνονται:

- Η πρώτη προσέγγιση αφορά την ανάπτυξη και τη βελτιστοποίηση της μάθησης των συστημάτων, τα οποία έχουν την ικανότητα να προσομοιώνουν με ακρίβεια συγκεκριμένες μαθησιακές εργασίες δηλαδή μελέτες προσανατολισμένες στην εργασία.
- Η δεύτερη προσέγγιση περιλαμβάνει το σχεδιασμό και την κατασκευή υπολογιστικών μοντέλων, προκειμένου να προσομοιώσουν τις ανθρώπινες διαδικασίες μάθησης. Αυτή η ερευνητική προσέγγιση αποτελεί μέρος μιας διεπιστημονικής προσπάθειας, όπου επιστήμονες από διαφορετικούς κλάδους συνεργάζονται, προκειμένου να αποκρυπτογραφήσουν τον τρόπο λειτουργίας του ανθρώπινου νου.
- Η τρίτη προσέγγιση μελετά τις μεθόδους και τους αλγόριθμους μάθησης ανεξάρτητα από τον τομέα εφαρμογής (Camastra & Vinciarelli, 2007).

1.4 Πότε μαθαίνει μια μηχανή;

Σύμφωνα με τον ορισμό της μάθησης, οι άνθρωποι μαθαίνουν αλλάζοντας τον τρόπο που συμπεριφέρονται και αυτό είναι που τους κάνει να αποδίδουν καλύτερα στο μέλλον. Πώς όμως και υπό ποιες προϋποθέσεις το κάνει αυτό μία μηχανή μάθησης; Στην πραγματικότητα, αυτό το ερώτημα μπορεί να απαντηθεί μέσω της φιλοσοφικής οπτικής, αλλά αυτό είναι πέρα από το πεδίο αυτής της μελέτης. Σε μια ανθρωποκεντρική προσέγγιση, μάθηση σημαίνει σκέψη και σκοπός. Το να μάθεις κάτι πρέπει να το κάνεις συνειδητά. Πώς λοιπόν περιγράφουμε τη μάθηση χωρίς σκοπό - στόχο; Κάθε φορά που ένα μηχανήμα αλλάζει τη δομή, τα προγράμματα ή τα δεδομένα του, αυτό λαμβάνει ή ανταποκρίνεται στην εισροή εξωτερικών ερεθισμάτων – πληροφοριών, με αυτόν τον τρόπο η αναμενόμενη μελλοντική του απόδοση θα βελτιωθεί (Nilsson et al., 1998). Αυτή η βελτίωση σημαίνει προσαρμογή σε ένα νέο περιβάλλον και ανίχνευση προτύπων (Russell & Norvig, 2010).

Κατά συνέπεια, ένα μηχανήμα μαθαίνει σε σχέση με μια συγκεκριμένη εργασία "Task", μετρική απόδοσης "Performance" και τύπο εμπειρίας "Experience", εάν το σύστημα βελτιώνει αξιόπιστα την απόδοσή του "Performance" για την εργασία "Task", μετά την εμπειρία "Experience" (Mitchell, 2006).

1.5 Μηχανική Μάθηση: Τομείς Επιστήμης

Η μηχανική μάθηση είναι η διασταύρωση του τομέα της επιστήμης των υπολογιστών και της επιστήμης της στατιστικής (Nilsson et al., 1998). Ιστορικά, ο τομέας της στατιστικής είναι επικεντρωμένος στη δοκιμή υποθέσεων, ενώ ο τομέας της μηχανικής μάθησης είναι επικεντρωμένος στη διατύπωση της διαδικασίας γενίκευσης ως μία αναζήτηση μέσω των δυνατών υποθέσεων. Δεδομένου ότι ενώ πολλές τεχνικές μηχανικής μάθησης δεν περιλαμβάνουν οποιαδήποτε αναζήτηση και η στατιστική είναι πολύ πέρα από τον έλεγχο υποθέσεων, ή παραπάνω εννοιολογική είναι μια υπεραπλούστευση (Witten et al., 2011). Με βάση την συνολική πρόοδο που επιτεύχθηκε στη στατιστική και τη μηχανική μάθηση τις τελευταίες δεκαετίες, έχουν προκύψει περισσότερα από ένα σημεία σύγκλισης. Για παράδειγμα, στην πράξη, εφαρμόζονται τυπικές στατιστικές μέθοδοι στο αρχικό σύνολο παραδειγμάτων (π.χ. οπτικοποίηση δεδομένων, επιλογή χαρακτηριστικών, απόρριψη στοιχείων, και τα λοιπά.). Γενικά, μπορούμε να δούμε ότι χρησιμοποιούνται πολλές

στατιστικές δοκιμές για την επικύρωση των μοντέλων μηχανικής μάθησης και αξιολόγησης των αλγορίθμων μηχανικής μάθησης (Witten et al., 2011). Ως εκ τούτου η μηχανική μάθηση είναι αναμφίβολα ένα διεπιστημονικό πεδίο που συμπεριλαμβάνει διασταυρούμενες κατευθύνσεις, θεωρίες και ερευνητικούς μεθόδους από διαφορετικούς κλάδους. Οι τομείς που καλύπτονται από την μηχανική μάθηση συνοψίζονται παρακάτω:

- **Εγκεφαλικό Μοντέλο**

Εξαιρετική πηγή έμπνευσης και κινήτρου για όλα τα είδη μηχανικής μάθησης είναι η μελέτη του εγκεφάλου και η κατανόηση των βιολογικού νευρωνικού δικτύου. Μέσω του βιολογικού νευρωνικού δικτύου δημιουργήθηκαν τα τεχνητά νευρωνικά δίκτυα τα οποία είναι υπολογιστικά μοντέλα εμπνευσμένα από τον εγκέφαλο, που αποτελούνται από μη γραμμικά στοιχεία (Nilsson et al., 1998) και αποτελούν ένα ισχυρό εργαλείο μηχανικής μάθησης. Η Εφαρμογή του μοντέλου νευρωνικών δικτύων πέτυχε εξαιρετικές αποδόσεις σε σε πολλά σύνθετα προβλήματα.

- **Νοητικό Μοντέλο**

Αφορά την ψυχολογική μελέτη της εγκεφαλικής λειτουργίας και συμπεριφορά σε ένα επακριβώς καθορισμένο περιβάλλον. Δηλαδή, επικεντρώνεται στη μελέτη της επεξεργασίας πληροφοριών από την οπτική γωνία των ψυχολογικών γνωστικών διαδικασιών (π.χ. μνήμη, γλωσσικές δεξιότητες, επίλυση προβλημάτων κ.λπ.). Αυτή η μέθοδος βασίζεται κυρίως σε γνωστικά υπολογιστικά μοντέλα από τα οποία περνούν οι γνωστικές διαδικασίες προσομοίωσης.

- **Τεχνητή Νοημοσύνη**

Η τεχνητή νοημοσύνη και η μηχανική μάθηση συνδέονται στενά επειδή τα δύο πεδία μοιράζονται την ιδέα ότι ένα σύστημα (μοντέλο) πρέπει να μπορεί να μαθαίνει και να προσαρμόζεται μέσω της εμπειρίας. Η τεχνητή νοημοσύνη καλύπτει ένα ευρύ φάσμα προβλημάτων και διερευνά θέματα όπως π.χ. Ο ρόλος της αναλογίας στη μάθηση και ο τρόπος χρήσης της εμπειρίας από προηγούμενες καταστάσεις για την αντιμετώπιση νέων καταστάσεων, ανακάλυψη κανόνων για τα συστήματα κ.λπ. (Nielsen et al., 1998). Επίσης η τεχνητή νοημοσύνη επηρεάζεται από πολλούς επιστημονικούς κλάδους (Φιλοσοφία, Μαθηματικά, Οικονομικά, Ψυχολογία, Γλωσσολογία, Μηχανική Υπολογιστών, Θεωρία Ελέγχου και Κυβερνητική) (Russell & Norvig, 2010).

- **Στατιστική**

Η στατιστική μάθηση έγκειται στην εύρεση της επιθυμητής σχέσης εξάρτησης για κάποιο πεδίο ορισμού χρησιμοποιώντας έναν πεπερασμένο-περιορισμένο αριθμό δεδομένων (Λαμπρόπουλος & Τσιχριντζής, 2015). Το πρόβλημα σε αυτό το πλαίσιο είναι να βρεθεί ο βέλτιστος τρόπος χρήσης δειγμάτων που προέρχονται από άγνωστες κατανομές πιθανοτήτων, προκειμένου να αποφασιστεί από ποια κατανομή αντλείται κάποιο νέο δείγμα. Η μέθοδος αναφέρεται στην πρόβλεψη της εκτιμώμενης τιμής μιας άγνωστης συνάρτησης σε ένα νέο σημείο, δεδομένων των τιμών αυτής της συνάρτησης σε ένα σύνολο σημείων δείγματος (Nilsson et al., 1998).

Συνήθως, ο αριθμός των απαιτούμενων σχέσεων για έναν περιορισμένο όγκο δεδομένων είναι ατελείωτες. Δεδομένου αυτού του γεγονότος, το ενδιαφέρον των ανθρώπων για την επιλογή της πιο κατάλληλης σχέσης έχει αλλάξει.

Για να λύσουμε αυτό το πρόβλημα, χρησιμοποιούμε την αρχή της παρρησίας, ή όπως είναι γνωστό, «principle of Occam's razor», σύμφωνα με την οποία δεν πρέπει να αυξάνει κανείς τον αριθμό των οντοτήτων άσκοπα ή να κάνει περαιτέρω υποθέσεις από αυτές που χρειάζονται για να εξηγήσει οτιδήποτε. Όταν λοιπόν ένα πρόβλημα έχει πολλές προτεινόμενες λύσεις, πρέπει να επιλέξουμε την πιο απλή (Λαμπρόπουλος και Τσιχριντζής, 2015).

- **Θεωρία Προσαρμοστικού Ελέγχου**

Ο προσαρμοστικός έλεγχος προσεγγίζει το πρόβλημα που αφορά την εκτίμηση άγνωστων παραμέτρων μιας διεργασίας κατά τη λειτουργία της. Η δυσκολία έγκειται στο γεγονός ότι κατά τη λειτουργία, οι παράμετροι αλλάζουν συνεχώς και ελέγχοντας τη διαδικασία, αυτές οι αλλαγές πρέπει να παρακολουθούνται. Μέσω λοιπόν του προσαρμοστικού ελέγχου πραγματοποιείται χειρισμός των αγνώστων παραμέτρων και άρα της αβεβαιότητας του μοντέλου (Cao et al., 2012).

1.6 Η συμβολή της μηχανικής μάθησης

Με την μοντελοποίηση της μαθησιακής διαδικασίας στο πλαίσιο της μηχανικής μάθησης, δημιουργήθηκαν νέες προοπτικές στη διερεύνηση ερευνητικών και τεχνικών θεμάτων. κάποιοι από αυτές συνοψίζονται στις ακόλουθες ερωτήσεις:

- Πώς μαθαίνουν οι άνθρωποι, δηλαδή ποιοι είναι οι πιθανοί τρόποι μάθησης;
- Ποιες είναι οι διαδικασίες που είναι υπεύθυνες για την εδραίωση της μνήμης και της μάθησης;
- Ποιος είναι ο καλύτερος τρόπος επίλυσης δύσκολων υπολογιστικών προβλημάτων;
- Πώς να αναπτύσσονται αυτοματοποιημένοι μηχανισμοί για συγκεκριμένους τύπους προβλημάτων;

Η συνεισφορά της μηχανικής μάθησης αφορά και τον κλάδο της επιστήμης και της τεχνολογίας που ασχολείται με το σχεδιασμό, την κατασκευή και τη χρήση, μηχανών και κατασκευών και συνοψίζεται παρακάτω:

Ο πρώτος λόγος σχετίζεται με την ικανότητα του συστήματος μάθησης να προσαρμόζεται.

Αυτή η προσαρμογή αντιστοιχεί στην παραγωγή σωστών εξόδων με την χρήση μεγάλου αριθμού δειγμάτων εισόδων, περιορίζοντας την λειτουργία-συνάρτηση εισόδου-εξόδου τους με αυτόν τον τρόπο. (Nielsen et al., 1998).

Ο δεύτερος λόγος έχει να κάνει με τη διαδικασία ανακάλυψης μοτίβων σε μεγάλους αριθμούς δεδομένων. Η εξόρυξη δεδομένων, η ανακάλυψη κρυφών μοτίβων (ή σημαντικών σχέσεων) στον συνεχώς αυξανόμενο όγκο δεδομένων, αποτελεί ένα δημοφιλές είδος μηχανικής μάθησης. Βασική προϋπόθεση για την εξόρυξη δεδομένων είναι η μερική ή πλήρης αυτοματοποίηση των προγραμμάτων μηχανικής μάθησης. Τα μοτίβα που εξάγονται με αυτές τις τεχνικές πρέπει να συμμορφώνονται με μερικές βασικές αρχές σε τεχνικά και οικονομικά θέματα. Άλλη μία βασική απαίτηση σχετικά με την εξόρυξη δεδομένων είναι η διαθεσιμότητα των δεδομένων να είναι σε σημαντικές ποσότητες (big data).

Ο τρίτος λόγος αφορά τη συνεχή βελτίωση του σχεδιασμού των υπαρχόντων μηχανημάτων, δηλαδή να κάνουμε την μηχανή να προσαρμόζονται στις αλλαγές ενός συνεχούς μεταβαλλόμενου περιβάλλοντος. Οι μέθοδοι μηχανικής μάθησης μπορούν να χρησιμοποιηθούν για την βελτίωση των υπαρχόντων σχεδίων των μηχανών (Nilsson et al., 1998).

Η μηχανική μάθηση χρησιμοποιείται επίσης σε υπολογιστικά προβλήματα, όταν ο σχεδιασμός και ο προγραμματισμός αλγορίθμων δεν είναι εφικτός (Λαμπρόπουλος & Τσιχριντζής, 2015).

Είναι δεδομένο ότι τα πράγματα περιπλέκονται όταν μια υπόθεση περιλαμβάνει πολλά δεδομένα. Το ουσιώδες πλεονέκτημα των μεθόδων μηχανικής μάθησης σε αυτό τον τομέα είναι η διαχείριση μεγάλων ποσοτήτων δεδομένων, η ικανότητα χειραγώγησης της γνώσης και απόκτησης περισσότερων γνώσεων από αυτές που μπορούν οι άνθρωποι (Nielsen et al., 1998; Mitchell, 2006).

Η κύρια εστίαση της μηχανικής μάθησης αφορά ποιες υπολογιστικές αρχιτεκτονικές και αλγόριθμοι μπορούν να χρησιμοποιηθούν, προκειμένου να χειριστούν μεγάλο όγκο διαθέσιμων δεδομένων, δηλαδή την αποτελεσματική σύλληψη, αποθήκευση, ευρετηρίαση, ανάκτηση και συγχώνευση αυτών των δεδομένων.

1.7 Τύποι Μάθησης

Οι βασικές στρατηγικές μάθησης βασίζονται σε δύο διακριτές οντότητες, τους δασκάλους και τους μαθητές. Αυτές οι δύο οντότητες σχηματίζουν μια αμφίδρομη δυναμική σχέση. Οι εκπαιδευτικοί έχουν τις απαραίτητες πληροφορίες και γνώσεις (δηλαδή τεχνογνωσία) για να εκτελέσουν μια δεδομένη εργασία σε ένα δεδομένο πλαίσιο και ο εκπαιδευόμενος πρέπει να μάθει τις απαραίτητες πληροφορίες για την απόκτηση των απαραίτητων γνώσεων για την εκτέλεση της συγκεκριμένης εργασίας σε ένα δεδομένο πλαίσιο (Camastra & Vinciarelli, 2007; Λαμπρόπουλος & Τσιχριντζής, 2015).

Η ταξινόμηση των στρατηγικών μάθησης καθορίζεται από τα συμπεράσματα που βγάξει ο εκπαιδευόμενος σχετικά με τις πληροφορίες που παρέχονται από τον δάσκαλο. Σύμφωνα με αυτή την υπόθεση, ορίζονται οι ακόλουθοι τύποι μάθησης:

- μάθηση από διδασκαλία
- μάθηση κατ' αναλογία
- μάθηση από παραδείγματα
- Επαγωγική και συμπερασματική μάθηση
- Μάθηση μέσω επίβλεψης-εποπτείας
- Μάθηση χωρίς επίβλεψη -εποπτείας

Στην παρούσα εργασία η χρήση της εποπτευόμενης μάθησης έχει το μεγαλύτερο ενδιαφέρον μιας και η είναι η πιο κοινή μορφή μηχανικής μάθησης, με ή χωρίς βάθος (LeCun et al., 2015). Το σύστημα μαθαίνει μια λειτουργία με βάση την έννοια του συνόλου δεδομένων που αποτελεί περιγραφή ενός μοντέλου. Η διαδικασία επίβλεψης μάθησης μπορεί να συνοψιστεί ως εξής (Vlahavas et al., 2006):

- Το σύστημα πρέπει να αποκωδικοποιήσει τις εισερχόμενες πληροφορίες (δηλ. δεδομένα εισόδου) για να σχηματίσει μια αναπαράσταση του μοντέλου που μαθαίνει μια συνάρτηση-λειτουργία που ονομάζεται συνάρτηση-λειτουργία στόχος (για παράδειγμα, συμβολίζεται με "c"). Η συνάρτηση χρησιμοποιείται για την πρόβλεψη της τιμής της μεταβλητής, που ονομάζεται εξαρτημένη μεταβλητή ή μεταβλητή εξόδου, σύμφωνα με τις τιμές ενός συνόλου μεταβλητών, που ονομάζονται ανεξάρτητες μεταβλητές ή μεταβλητές εισόδου ή χαρακτηριστικά.
- Ένα σύνολο περιπτώσεων (για παράδειγμα, που συμβολίζονται με ένα "X") που αντιστοιχεί σε διαφορετικές τιμές εισόδου στη συνάρτηση, όπου κάθε στιγμιότυπο προέρχεται από ένα σύνολο μεταβλητών ή χαρακτηριστικών. Επομένως, για ένα υποσύνολο του συνόλου περιπτώσεων γνωρίζουμε τη μεταβλητή τιμή εξόδου, που αντιστοιχεί στο σετ εκπαίδευσης (π.χ. συμβολίζεται με "D").
- Στη συνέχεια, το σύστημα εξετάζει διάφορες υποψήφιες συναρτήσεις προκειμένου να γίνει προσέγγιση και εφαρμογή της συνάρτησης-λειτουργίας με πιο ακριβή τρόπο. Αυτές οι εναλλακτικές λειτουργίες ονομάζονται υποθέσεις (για παράδειγμα, συμβολίζεται με "h"), και το σύνολο όλων αυτών των δυνατών υποθέσεων συμβολίζεται με "H" (Vlahavas et al., 2006).
- Η μάθηση βασίζεται στην υπόθεση της επαγωγικής μάθησης, σύμφωνα με την οποία κάθε υπόθεση που έχει βρεθεί ότι προσεγγίζει στενά τη συνάρτηση-λειτουργία στόχο για ένα αρκετά μεγάλο σύνολο παραδειγμάτων, θα προσεγγίζει επίσης με τον ίδιο τρόπο την αντικειμενική συνάρτηση για περιπτώσεις που δεν έχουν εξεταστεί προηγουμένως. Μια υποθετική συνάρτηση λέγεται ότι είναι γενικευμένη όταν εκτιμά καλά στο σύνολο δοκιμών. Τόσο το μέσο τετράγωνο σφάλματος όσο και ο συνολικός αριθμός σφαλμάτων είναι κοινά μέτρα (Nilsson et al., 1998).

Η εποπτευόμενη μάθηση περιλαμβάνει εργασίες ταξινόμησης, πρόβλεψης και παλινδρόμησης. Τα αντικείμενα που σχετίζονται με μια συγκεκριμένη έννοια είναι ζεύγη μοτίβων εισόδου-εξόδου. Το σύστημα παρατηρεί μερικά παραδείγματα ζευγών εισόδου-εξόδου και μαθαίνει μια λειτουργία και την χαρτογραφεί από την είσοδο στην έξοδο (Russell & Norvig, 2010). Αυτή η υπόθεση σημαίνει ότι τα δεδομένα ανήκουν στην ίδια

έννοια που ήδη σχετίζεται με την τιμή στόχο (Λαμπρόπουλος & Ζιχριντζής, 2015). Οι κύριες εποπτευόμενες τεχνικές μάθησης είναι οι εξής (Vlahavas et al., 2006):

- Εκμάθηση εννοιών.
- Δέντρα ταξινόμησης ή απόφασης.
- Εκμάθηση κανόνων.
- Μάθηση βάσει παραδειγμάτων
- Μπεϋζιανή μάθηση.
- Γραμμικής παλινδρόμησης.
- Τεχνητά Νευρωνικά δίκτυα.
- Υποστήριξη Vector Machines (SVM).

2 Νευρωνικά Δίκτυα

2.1 Εισαγωγή στα Νευρωνικά Δίκτυα

Τα νευρωνικά δίκτυα είναι υπολογιστικά μοντέλα εμπνευσμένα από τον εγκέφαλο. Γενικά, ένα νευρωνικό δίκτυο είναι μια συλλογή μονάδων συνδεδεμένος μεταξύ τους και οι ιδιότητες του καθορίζονται από την τοπολογία του «Properties of Neurons» (Russell & Norvig, 2010). Η έρευνα για τα νευρωνικά δίκτυα στην θεωρία επηρεάζεται σε μεγάλο βαθμό από πολλούς διαφορετικούς κλάδους. Υπό αυτό το πρίσμα, βασίζεται εκτενώς στη νευροεπιστήμη, στην ψυχολογία, στα μαθηματικά και την επιστήμη των υπολογιστών. Τα μοντέλα δικτύου βασίζονται σε βιολογικά παραδείγματα επειδή χρησιμοποιούν διαδικασίες που μιμούνται τον ανθρώπινο εγκέφαλο. Επομένως, αυτά τα μοντέλα μας δίνουν γνώσεις για τη γνωστική λειτουργία ως μια προσπάθεια μοντελοποίησης της επεξεργασίας πληροφοριών που απορρέει από την ικανότητα του εγκεφάλου. Οι νευρώνες είναι τα βασικά στοιχεία του εγκεφάλου που μεταδίδουν ώσεις στο νευρικό Σύστημα (Basegmez, 2014). Δεδομένου ότι οι τεχνητοί νευρώνες ορίζονται ως υπολογιστικά μοντέλα, μερικά από αυτά μπορούν να ταιριάζουν με αυτά των βιολογικών νευρώνων (Vlahavas et al., 2006).

Τα Τεχνητά νευρωνικά δίκτυα είναι αλγόριθμοι εμπνευσμένοι από βιολογικούς νευρώνες, «Synaptic Links» (Hamed et al. 2013). Είναι συστήματα επεξεργασίας δεδομένων, συμπεριλαμβανομένων των τεχνητών νευρώνων και είναι οργανωμένα όπως ο ανθρώπινος εγκέφαλος και μπορούν θεωρηθούν ως μη γραμμικός εκτιμητής (Λαμπρόπουλος & Τσιχριντζής, 2015).

Οι θεμελιώδεις αρχές λειτουργίας των μοντέλων νευρωνικών δικτύων τα καθιστούν σημαντικά εργαλεία για την αντιμετώπιση πολλών δύσκολων προβλημάτων. Σε πολλές περιπτώσεις χρησιμοποιούνται νευρωνικά δίκτυα για τις διαδικασίες επεξεργασίας που λαμβάνουν χώρα στα κρυφά επίπεδα του δικτύου. Σε ένα τυπικό νευρωνικό δίκτυο, μια συγκεκριμένη είσοδος παράγει την επιθυμητή έξοδο, αλλά το πώς το δίκτυο επιτυγχάνει αυτό το αποτέλεσμα επαφίεται στη διαδικασία της αυτο-οργάνωσης (Rojas, 1996).

Ένα νευρωνικό δίκτυο αποτελείται από μη γραμμικά στοιχεία, ρυθμιζόμενα βάρη, όπου οι υπολογισμοί ερμηνεύονται με όρους αλληλεπιδράσεων δικτύου. Τα νευρωνικά δίκτυα έχουν χρησιμοποιηθεί ευρέως ως υπολογιστικά μοντέλα γνώσης και αποτελούν μια

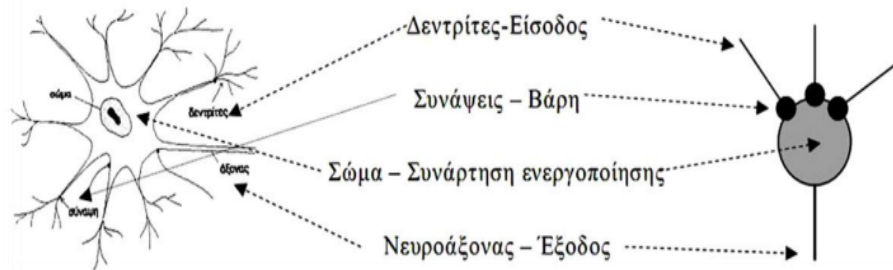
από τις πιο δημοφιλείς και αποτελεσματικές μορφές συστηματικής μάθησης και παίζουν σημαντικό ρόλο στον τομέα της μηχανικής μάθησης (Nilsson et al., 1998).

2.2 Βιολογικά Νευρωνικά Δίκτυα

Ένα βιολογικό νευρωνικό δίκτυο αποτελείται από ένα σύνολο νευρώνων, διασυνδεδεμένο με άξονες. Το συστατικό ενός τυπικού βιολογικού νευρώνα είναι το σώμα, στο οποίο οι δενδρίτες αποτελούν τον πυρήνα των νευρώνων, οι οποίοι είναι τα κύρια μονοπάτια εξόδου μέσω των οποίων οι νευρώνες στέλνουν σήματα μεταβιβάζοντας πληροφορίες σε άλλους νευρώνες. Τα σήματα (είσοδοι) που φτάνουν στους νευρώνες ορίζονται ως εισερχόμενες είσοδοι. Τα κενά μεταξύ αυτών των νευρώνων ονομάζονται συνάψεις και οι άξονες και οι δενδρίτες συνδέονται μεταξύ τους με συνάψεις (Πρωτόπαπας, 2004; Kandel et al., 2006; Basegmez, 2014). Στην συνέχεια, επιτελούνται χημικές διαδικασίες που λαμβάνουν χώρα μεταξύ των συνάψεων για να επιτευχθεί επιταχυνόμενη ή επιβραδυνόμενη ροή του ηλεκτρικού φορτίου στους νευρώνες. Έπειτα, απελευθερώνονται οι νευροδιαβιβαστές από τον νευρώνα στη σύναψη και παραλαμβάνονται από υποδοχείς στη λήψη δενδρίτες του νευρώνα. Η δράση ορισμένων νευροδιαβιβαστών έχει διεγερτικό αποτέλεσμα στον νευρώνα λήψης, αυξάνοντας έτσι την ενεργοποίηση του δικτύου. (Gluck and Myers, 2001).

Οι γνωστικές λειτουργίες, όπως προκύπτουν από τις υποκείμενες εγκεφαλικές διεργασίες, δείχνουν ότι η λειτουργία του εγκεφάλου προκύπτει από την ικανότητα των συνάψεων να συνεχίζουν να αλλάζουν την αγωγιμότητά τους. Το ηλεκτρικό σήμα που εισέρχεται στον νευρώνα λειτουργεί συνδυασμένα και όχι μεμονωμένα. Η ύπαρξη καθώς και η ενεργοποίηση κατωφλίου, καθορίζουν την αρχιτεκτονική και τις βασικές αρχές των νευρωνικών δικτύων. Ειδικότερα, όταν το συνδυασμένο αποτέλεσμα υπερβαίνει ένα όριο (συνήθως αυτή η τιμή είναι προκαθορισμένη), το σήμα διαδίδεται μέσω του άξονα σε άλλους νευρώνες (Vlahavas et al. 2006).

Συνοπτικά, καταλήγουμε στο συμπέρασμα ότι τα βιολογικά νευρωνικά δίκτυα είναι αυτο-οργανωτικά συστήματα και ότι κάθε μεμονωμένος νευρώνας είναι επίσης ένα ευαίσθητο αυτό-οργανωτικό σύστημα. Με άλλα λόγια, μια δομή που μπορεί να επεξεργαστεί πληροφορίες με πολλούς διαφορετικούς τρόπους. Αυτό το τεράστιο και ιεραρχικό δομημένο δίκτυο του εγκεφάλου είναι αυτό που συνθέτει την συμπεριφορά και την συνείδηση στους ανθρώπους (Rojas, 1996).



Εικόνα 2-1. Αντιστοιχία Βιολογικού με Τεχνητό Νευρώνα

2.3 Τεχνητά Νευρωνικά Δίκτυα

Η θεωρία του Τεχνητού Νευρωνικού Δικτύου, είναι γνωστή και ως, Παραλληλισμός, Κατανεμημένη Επεξεργασία (PDP) ή Νευρωνικός Υπολογισμός, βασίζεται στα βιολογικά νευρωνικά δίκτυα και όσον αφορά την επεξεργασία πληροφοριών, δεν λαμβάνουν υπόψη όλη την πολυπλοκότητα των πραγματικών βιολογικών νευρώνων. Γενικά, τα τεχνητά νευρωνικά δίκτυα, είναι ένα δίκτυο διασυνδεδεμένων μονάδων που λειτουργούν ως μοντέλο νευρώνων και χρησιμοποιούν υπολογιστικές λειτουργίες στην εισόδου τους. Εκτός από την ομοιότητα με τα βιολογικά μοντέλα, ένα τεχνητό νευρωνικό δίκτυο μπορεί να θεωρηθεί ως ένας στατιστικός επεξεργαστής που παρέχει πιθανολογικές υποθέσεις για τα δεδομένα (Jordan et al., 2006).

2.4 Αρχιτεκτονικές Τεχνητών Νευρωνικών Δικτύων


Η λειτουργικότητα και η ευελιξία των τεχνητών νευρωνικών δικτύων πηγάζουν από πολλά βασικά χαρακτηριστικά όπως η προσαρμοστικότητα, η μη γραμμικότητα και η αυθαίρετη αντιστοίχιση συναρτήσεων και η χωρητικότητα. Αυτά τα χαρακτηριστικά, στο πλαίσιο των αρχιτεκτονικών τεχνητών νευρωνικών δικτύων, τα καθιστούν πιο αξιόπιστη λύση σε προβλήματα όπως μοτίβα και ακολουθίες ταυτοποίησης (ταξινόμησης), επεξεργασία δεδομένων (π.χ. φιλτράρισμα, ομαδοποίηση κ.λπ.) (Zorbas, 2015). Η ιεραρχική πολυεπίπεδη δομή του νευρωνικού δικτύου κάνει τις πληροφορίες να διαβιβάζονται όχι μόνο στους πλησιέστερους νευρώνες, αλλά και σε απόμακρους κόμβους (Rojas, 1996). Ένα τεχνητό νευρωνικό δίκτυο είναι στην πραγματικότητα ένα γράφημα, με κορυφές (νευρώνες ή μονάδες) και ακμές (συνδέσεις) μεταξύ κορυφών (Jordan et al., 2006). Ένα τέτοιο δίκτυο

αποτελείται από ένα σύστημα διασυνδεδεμένων τεχνητών νευρώνων που μπορούν να ενεργοποιηθούν με βάση τα βάρη σύνδεσης (Gudi, 2014). Οι μονάδες επεξεργασίας ενός νευρωνικού δικτύου είναι οι κόμβοι (ή μονάδες). Οι νευρώνες συνδέονται μεταξύ τους μέσω κατευθυνόμενων συνδέσεων (δεσμών) και οι κόμβοι στο δίκτυο περιλαμβάνουν δύο τύπους συνδέσεων, τις εισερχόμενες και τις ανιχνεύσιμες. Επιπλέον, κάθε κόμβος έχει έναν ορισμένο βαθμό διέγερσης ή επίπεδο ενεργοποίησης. Ο βαθμός διέγερσης εξαρτάται από τον συγκεκριμένο κόμβο και το άθροισμα όλων των εισερχόμενων συνδέσεων.

Συνοψίζοντας, ο τρόπος με τον οποίο είναι δομημένοι οι νευρώνες ενός ΤΝΔ ονομάζεται τοπολογία ή αρχιτεκτονική του ΤΝΔ (Neural Network Architecture) και σχετίζεται με τον αλγόριθμο εκπαίδευσης που χρησιμοποιείται για το δίκτυο. Βλέπουμε τους νευρώνες σαν να ήταν διατεταγμένοι σε στρώματα. Κάθε ΤΝΔ έχει τουλάχιστον δύο επίπεδα: ένα επίπεδο εισόδου και ένα στρώμα εξόδου. Εάν το ΤΝΔ αποτελείται επίσης και από άλλα επίπεδα μεταξύ των επιπέδων εισόδου και εξόδου, αυτά τα επίπεδα ονομάζονται κρυφά επίπεδα και το ΤΝΔ ονομάζεται πολλαπλών επιπέδων. Ακολουθούν οι τρεις βασικές μορφές αρχιτεκτονικών νευρωνικών δικτύων.

2.4.1 Τεχνητά Νευρωνικά Δίκτυα Ενός Επιπέδου (Εμπρόσθιας Τροφοδότησης)


Η απλούστερη μορφή νευρωνικού δικτύου με στρώματα είναι ένα νευρωνικό δίκτυο ενός επιπέδου. Σε αυτή την περίπτωση έχουμε ένα στρώμα με κόμβους εισόδου και ένα στρώμα με Νευρώνες (όπου γίνεται ο υπολογισμός), το αντίστροφο δεν ισχύει, δηλαδή δεν μπορούμε να πάμε από νευρώνα εξόδου σε κόμβο εισόδου. Το δίκτυο είναι ένα αυστηρά feedforward δίκτυο, κα ονομάζεται Νευρωνικό δίκτυο μονού στρώματος εμπρόσθιας τροφοδοσίας (Livieris, 2019,2020). Ο όρος «ένα επίπεδο» αναφέρεται στο επίπεδο εξόδου, το οποίο περιέχει επίσης τους νευρώνες που ολοκληρώνουν τον υπολογισμό. Το επίπεδο εισόδου του κόμβου εισόδου δεν υπολογίζεται επειδή δεν γίνεται υπολογισμός εκεί (Livieris, 2020).



Εικόνα 2-2. Εμπρόσθιας τροφοδότησης νευρωνικό δίκτυο ενός επιπέδου

2.4.2 Τεχνητά Νευρωνικά Δίκτυα Πολλαπλών Επιπέδων (Εμπρόσθιας Τροφοδότησης)

Η δεύτερη περίπτωση ενός νευρωνικού δικτύου τροφοδοσίας διαφέρει από την πρώτη στο ότι υπάρχουν ένα ή περισσότερα κρυφά στρώματα με νευρώνες που ονομάζονται κρυφοί νευρώνες. Οι κρυφοί νευρώνες βρίσκονται μεταξύ των κόμβων εισόδου και των νευρώνων εξόδου του δικτύου. Οι κόμβοι εισόδου στο στρώμα εισόδου του δικτύου παρέχουν στοιχεία μοτίβου εισόδου με τη μορφή διανυσμάτων, τα οποία γίνονται οι είσοδοι στους νευρώνες στο δεύτερο επίπεδο. Το σήμα εξόδου των νευρώνων στο δεύτερο στρώμα γίνεται το σήμα εισόδου του τρίτου στρώματος, έτσι ώστε το σήμα να συνεχίζει να ρέει μεταξύ των στρωμάτων του δικτύου μέχρι το επίπεδο εξόδου. Το σύνολο των σημάτων εξόδου του σταδίου εξόδου αποτελεί επίσης την απόκριση του δικτύου στα δεδομένα εισόδου των κόμβων εισόδου (Livieris, 2020).




Εικόνα 2-3. Εμπρόσθιας τροφοδότησης νευρωνικό δίκτυο πολλαπλών επιπέδων


2.4.3 Επαναλαμβανόμενα Τεχνητά Νευρωνικά Δίκτυα

Ένα επαναλαμβανόμενο νευρωνικό δίκτυο, το οποίο θα ονομάσουμε ETNΔ, είναι διαφορετικό από ένα νευρωνικό δίκτυο ανατροφοδότησης επειδή περιέχει τουλάχιστον έναν βρόχο ανάδρασης. Δηλαδή, σε τουλάχιστον έναν νευρώνα, το σήμα εξόδου του επηρεάζει το σήμα που φτάνει στην είσοδο του νευρώνα. Για παράδειγμα, ένα ETNΔ μπορεί να αποτελείται από ένα μόνο στρώμα νευρώνων, όπου κάθε νευρώνας επιστρέφει το σήμα εξόδου του ως σήμα εισόδου σε όλους τους άλλους νευρώνες του στρώματος-επιπέδου. Σε αυτήν την περίπτωση, δεν υπάρχουν κρυφοί νευρώνες ή βρόχοι όπου ο νευρώνας επιστρέφει το σήμα εξόδου του ως είσοδο στον εαυτό του (Ζησιμοπούλου, 2019).

Τα επαναλαμβανόμενα νευρωνικά δίκτυα (Recurrent Neural Network) βασίζονται σε έναν ειδικό τύπο Αρχιτεκτονικής, όπου οι νευρώνες μπορούν να συνδεθούν κυκλικά. Τα επαναλαμβανόμενα δίκτυα είναι ισοδύναμα με ένα δίκτυο προώθησης που αποτελείται από άπειρο αριθμό επιπέδων, όπου κάθε στρώμα συνδέεται με το επόμενο στρώμα μέσω του δικτύου με κυκλικό τρόπο, παράγοντας μια συνεχή δυναμική, πράγμα που είναι χρήσιμο για την επεξεργασία χρονοσειρών εισόδου. Αυτό το χαρακτηριστικό αποτελεί συγκριτικό πλεονέκτημα έναντι των δικτύων προώθησης, αφού μπορεί να προσεγγίσει ένα επαρκή αριθμό κόμβων (μονάδων) (Kriegeskorte, 2015). Τα επαναλαμβανόμενα δίκτυα είναι επίσης ισχυρά εργαλεία μοντελοποίησης δεδομένων ακολουθίας. Σε ένα επαναλαμβανόμενο δίκτυο, μπορεί να υπάρχουν συνδέσεις μεταξύ ενός νευρώνα-στρώμα, τροφοδοτώντας την έξοδο του πίσω στη δική του είσοδο (Russell & Norvig, 2010), π.χ. κάθε κρυφή μονάδα μπορεί να αλληλεπιδράσει με άλλες κρυφές μονάδες (Kriegeskorte, 2015). Αυτά τα δίκτυα επεξεργάζονται συνεχώς τη ροή δεδομένων, για παράδειγμα, ένα στοιχείο στην ακολουθία εισόδου (χρονοσειρά). Επίσης τα επαναλαμβανόμενα δίκτυα μπορούν να υποστηρίξουν βραχυπρόθεσμη μνήμη (STM). Τα οφέλη από τη χρήση επαναλαμβανόμενων μοντέλων για την επίλυση πολύπλοκων υπολογισμών-προβλημάτων τα καθιστούν αυτά τα συστήματα μια πολύτιμη λύση.



Εικόνα 2-4. Επαναλαμβανόμενο δίκτυο χωρίς βρόγχους αυτοανάδρασης και κρυφούς νευρώνες



Εικόνα 2-5. Επαναλαμβανόμενο δίκτυο με κρυφούς νευρώνες

2.5 Διαδικασίες μάθησης και Εκπαίδευσης Τεχνητών Νευρωνικών Δικτύων

Η διαδικασία εκμάθησης του νευρωνικού δικτύου πραγματοποιείται μέσω της προσαρμογής των βαρών σύνδεσης μεταξύ των νευρώνων σε ένα σύστημα. Αυτή η ρύθμιση βάρους στις συνάψεις καθορίζουν τη συμπεριφορά των μεμονωμένων νευρώνων, καθώς και τη συνολική συμπεριφορά δικτύου. Η εκπαίδευση του νευρωνικού δικτύου γίνεται χρησιμοποιώντας πολύπλοκους αλγόριθμους. Σύμφωνα με την αρχιτεκτονική του δικτύου και το είδος του προβλήματος θα πρέπει να επιλέγεται κατάλληλος αλγόριθμος ο οποίος ταιριάζει σε κάθε περίπτωση. Σε κάθε περίπτωση, ανεξάρτητα από το είδος της μελέτης,

δηλαδή είτε πρόκειται για μάθηση υπό επίβλεψη είτε χωρίς επίβλεψη, ο στόχος είναι η βελτιστοποίηση της κατανομής των βαρών του δικτύου. Αυτό σημαίνει ότι η είσοδος του δικτύου να βρίσκεται σε ισορροπία. Κατά καιρούς έχουν προταθεί διεθνώς δεκάδες αλγόριθμοι στην βιβλιογραφία. Μερικοί από αυτούς τους αλγόριθμους θέτουν τις βάσεις για την τεχνητή εξέλιξη των νευρώνων και ενέπνευσε τη δημιουργία νέων αλγορίθμων. Μερικοί από τους πιο δημοφιλείς που είναι αποτελεσματικοί και συχνά εμπλέκονται σε εργασίες μηχανικής μάθησης είναι οι ακόλουθοι (Basegmez, 2014; Lake et al., 2016):

- The Perceptron algorithm (Rosenblatt, 1958)
- Hebbian learning (Hebb, 1949).
- The BCM rule (Bienenstock et al., 1982).
- Backpropagation algorithm (Rumelhart et al., 1986).
- The wake-sleep algorithm (Hinton et al., 1995).
- Contrastive divergence (Hinton, 2002).

3 Χρονολογικές Σειρές

3.1 Εννοιολογική προσέγγιση

Ο όρος χρονοσειρά αναφέρεται σε ένα σύνολο παρατηρήσεων ή μετρήσεων που συλλέγονται κατά διάρκεια μιας περιόδου προκειμένου να μελετήσουμε ένα φαινόμενο ή ένα χαρακτηριστικό. Εάν η παρατήρηση περιλαμβάνει μια μεμονωμένη μεταβλητή, τότε αναφερόμαστε σε μία μονομεταβλητή χρονοσειρά, ενώ εάν η παρατήρηση περιλαμβάνει περισσότερες από μία μεταβλητές, τότε πρόκειται για μία πολυμεταβλητή χρονοσειρά. Οι χρονοσειρές χωρίζονται σε δύο μεγάλες κατηγορίες, τις συνεχείς και τις διακριτές. Μια χρονοσειρά στην οποία η τιμή ενός φαινομένου παρατηρείται συνεχώς θεωρείται συνεχής. Για παράδειγμα κατά την καταγραφή σεισμών. Διακριτή είναι η αξία ενός παρατηρούμενου φαινομένου σε ένα συγκεκριμένο χρονικό διάστημα, όπως οι μηνιαίες πωλήσεις ενός προϊόντος. Αυτά τα χρονικά διαστήματα ή άλλες δειγματοληψίες διαφέρουν ανάλογα με την εφαρμογή και εναπόκειται στον κάθε αναλυτή να αποφασίσει ποια τιμή θα χρησιμοποιήσει. Μια άλλη ταξινόμηση βασίζεται στον αριθμό των μεταβλητών που πρέπει να αναλυθούν. (Vincent, & Thome, 2019).

Ας υποθέσουμε ότι συμβολίζουμε μια παρατήρηση με Y_i και την αντίστοιχη χρονική στιγμή (έτος, μήνας, ημέρα, ώρα, δευτερόλεπτο κ.λπ.) με X_i . Στη συνέχεια δημιουργούμε ζεύγη της μορφής $M(X_i, Y_i)$, τα οποία μπορούν να αναπαρασταθούν στο καρτεσιανό σύστημα αξόνων. Συνδέοντας τα σημεία, δημιουργείται ένα χρονοδιάγραμμα που δίνει μια γενική εικόνα της εξέλιξης του φαινομένου ή του χαρακτηριστικού που ερευνάται. Παραδείγματα τέτοιων χρονοσειρών είναι ο αριθμός των πελατών στο πολυκατάστημα τη στιγμή t , η κατανάλωση ηλεκτρικής ενέργειας ανά ημέρα, η οικονομικές χρονολογικές σειρές κ.λπ. Με βάση αυτό, έχουμε δύο κατηγορίες, τη μονομεταβλητή και την πολυμεταβλητή (Vincent & Thome, 2019).

Προκειμένου να αναλυθεί μία χρονολογική σειρά χρησιμοποιούνται δύο μοντέλα:

- Το προσθετικό: Το οποίο δίνεται από τον τύπο, $Y_t = T_t + S_t + C_t + R_t$ και
- Το πολλαπλασιαστικό: Που δίνεται από τον τύπο, $Y_t = T_t * S_t * C_t * R_t$

Όπου Y : η τιμή της μεταβλητής, T : η τάση, S η εποχιακή συνιστώσα, C : η κυκλική συνιστώσα, R : η τυχαία συνιστώσα.

Είναι σημαντικό να αναφερθεί ότι εκτός από τις στατιστικές μεθόδους μπορούν να χρησιμοποιηθεί και οι μέθοδοι στις μηχανικής μάθησης για την πρόβλεψη τιμών σε χρονοσειρές. Αυτό επιτυγχάνεται λαμβάνοντας τις τιμές των χρονοσειρών ως δεδομένα μέχρι ένα συγκεκριμένο χρονικό σημείο, το οποίο μπορεί να είναι μια ημέρα, ένας μήνας, ένα λεπτό, ανάλογα με το πρόβλημα που περιγράφει η χρονοσειρά. Στη συνέχεια, εφαρμόζεται ορισμένο μοντέλο μηχανικής εκμάθησης, χρησιμοποιούνται τα δεδομένα ως σύνολο εκπαίδευσης και με βάση τις προηγούμενες τιμές της προς πρόβλεψη μεταβλητής επιτυγχάνει την πρόβλεψη της τιμής της μεταβλητής για την επόμενη χρονική στιγμή ή ακόμα και για κάποιες από τις επόμενες χρονικές στιγμές.

3.1.1 Χαρακτηριστικά Χρονολογικών Σειρών

Για να εξαχθούν συμπεράσματα από τις χρονοσειρές, συχνά δεν αρκεί να παρατηρούμε απλώς το χρονοδιάγραμμα τους. Συνεπώς απαιτείται περαιτέρω ανάλυση αυτών με την χρησιμοποίηση συνιστώσων ή των χαρακτηριστικών της.

Στις χρονολογικές σειρές τέσσερις συνιστώσες έχουν σημαντικό ρόλο στην ανάλυσή τους:

- Η τάση (trend)
- Η εποχικότητα (seasonality)
- Στασιμότητα (stationary):
- Κυκλικότητα (Cyclical)
- Τυχαίες ή ακανόνιστες κινήσεις

Παρακάτω παρουσιάζονται συνοπτικά τα άνωθεν χαρακτηριστικά-συνιστώσες:

- **Τάση (Trend):** είναι η μακροπρόθεσμη μεταβολή της μέσης τιμής μιας παρατηρούμενης μεταβλητής σε μια συγκεκριμένη χρονική περίοδο, δηλαδή η συνολική εικόνα της χρονοσειράς. Συνήθως μια ευθεία γραμμή ή μια εκθετική καμπύλη χρησιμοποιείται για την εκτίμηση. Οι τάσεις μπορεί να είναι γραμμικές, μη γραμμικές ή σταθερές. Όταν η τάση είναι σταθερή, τα δεδομένα ονομάζονται σταθερά δεδομένα (στάσιμα). Για να μελετηθεί η ύπαρξη τάσεων σε μια χρονοσειρά, απαιτείται ένας ορισμένος αριθμός παρατηρήσεων για την εκτίμηση της διάρκειας περιόδου. Επίσης μέσω της επιλογής τους κατάλληλου αριθμού παρατηρήσεων αποφεύγονται τα λάθη στην εκτίμηση των τάσεων για να αποφευχθούν λάθη στην εκτίμηση των τάσεων (Κοτζοπαναγιώτου, 2019)

- **Στασιμότητα** (stationary) : Πρόκειται για την διακύμανση των τιμών των χρονοσειρών γύρω από το μέσο όρο, δηλαδή οι τιμές των χρονοσειρών δεν αλλάζουν σε σχέση με τις διακυμάνσεις του χρόνου. Εάν τα δεδομένα ποικίλλουν γύρω από μια σταθερή τιμή που ονομάζεται επίπεδο ή αναμενόμενη τιμή, τότε υπάρχει οριζόντια επανάληψη και μια τέτοια χρονοσειρά λέγεται ότι είναι σταθερή σε σχέση με την αναμενόμενη τιμή της.
- **Εποχικότητα** (seasonality): Αφορά περιοδικές αλλαγές με σταθερή διάρκεια μικρότερη του έτους. Είναι εύκολο να εντοπιστεί γιατί επαναλαμβάνεται με τον ίδιο ακριβώς τρόπο. Ένα παράδειγμα μπορεί να είναι η μεγάλη αύξηση πωλήσεων σε αναψυκτικά κατά την θερινή περίοδο ή η αύξηση κατανάλωσης παγωτών κατά την ίδια περίοδο και τα λοιπά.
- **Κυκλικότητα** (Cyclical): Εμφανίζεται περιοδικά και λόγω ειδικών εξωτερικών συνθηκών, αυτές οι περίοδοι δεν είναι σταθερές και μεγαλύτερες από ένα έτος. Η κυκλικότητα παρατηρείται κυρίως στις χρονοσειρές των Δεικτών της βιομηχανίας, οικονομίας κ.λπ.
- **Τυχαίες ή ακανόνιστες κινήσεις:** Αυτές αναφέρονται σε ακανόνιστες ή τυχαίες κινήσεις που μπορεί να συμβούν σε μία χρονοσειρά λόγω τυχαίων γεγονότων και παραγόντων. Κατά κύριο λόγο δεν είναι συστηματικές και δεν δύναται να προσδιοριστούν. Μερικά παραδείγματα τέτοιων παραγόντων θα μπορούσαν να είναι, για παράδειγμα, πόλεμος, ξαφνικές αλλαγές στις καιρικές συνθήκες, διάφορα φαινόμενα κ.λπ.

4 Βαθιά Μάθηση (Deep Learning)

4.1 Εισαγωγή στην βαθιά μάθηση

Η βαθιά μάθηση είναι επίσης γνωστή ως βαθιά δομημένη μάθηση, ως ιεραρχική μάθηση, ως εκμάθηση αναπαράστασης ή η εκμάθηση χαρακτηριστικών, κ.λπ., είναι μια δημοφιλής ερευνητική περιοχή της μηχανικής μάθησης η οποία αποτελείται από μια κατηγορία τεχνικών μηχανικής μάθησης που περιλαμβάνει πολλαπλά επίπεδα ιεραρχικών πληροφοριών και στάδια επεξεργασίας με βάση κάποια εποπτευόμενη αρχιτεκτονική που χρησιμοποιείται για την εκμάθηση χαρακτηριστικών-αναπαραστάσεων χωρίς επίβλεψη για την ανάλυση μοτίβων ή για ταξινόμηση (Deng & Yu, 2014). Οι μέθοδοι βαθιάς μάθησης επιτρέπουν στα υπολογιστικά μοντέλα που αποτελούνται από πολλαπλά επίπεδα επεξεργασίας ή στάδια μη γραμμικής πληροφορίας να επεξεργάζονται και να μαθαίνουν αναπαραστάσεις δεδομένων εξάγοντας σύνθετες σχέσεις μεταξύ των δεδομένων (Deng, 2013; LeCun et al., 2015; SAP SE, 2015).

Οι τεχνικές βαθιάς μάθησης αποτελούν μια επαναστατική μέθοδο μηχανικής μάθησης που έχει εφαρμοστεί σε ένα ευρύ φάσμα πεδίων όπως η ταξινόμηση, η ανάκτηση πληροφοριών, η ανάκτηση αναγνώρισης εικόνας, η μείωση διαστάσεων, η επεξεργασία φυσικής γλώσσας και η ρομποτική (SAP SE, 2015). Ενώ τα περισσότερα από τα προαναφερθέντα πεδία έχουν μελετηθεί επαρκώς από την κλασικές μεθόδους της μηχανικής μάθησης (Νευρωνικά δίκτυα, Support Vector Machines κτλ.) τα τελευταία χρόνια, η βαθιά μάθηση έχει επιδείξει εξαιρετικές επιδόσεις στα περισσότερα από αυτά τα πεδία, ανακαλύπτοντας πολύπλοκες δομές (μοτίβα) σε δεδομένα υψηλών διαστάσεων (LeCun et al., 2015). Επιπλέον, η ιεραρχική φύση της μαθησιακής διαδικασίας που εμφανίζεται στη βαθιά μάθηση είναι δομημένη ώστε να διευκολύνει την επεξεργασία μεγάλων δεδομένων (big data). Το βασικό σημείο πίσω από τη φιλοσοφία της βαθιάς αρχιτεκτονικής είναι ο υπολογισμός των αναπαραστάσεων ιεραρχικών χαρακτηριστικών ή παρατηρούμενων δεδομένων (δηλ. ακατέργαστων δεδομένων), όπου τα χαρακτηριστικά υψηλού επιπέδου ορίζονται από τα χαρακτηριστικά χαμηλού επιπέδου (Deng & Yu, 2014).

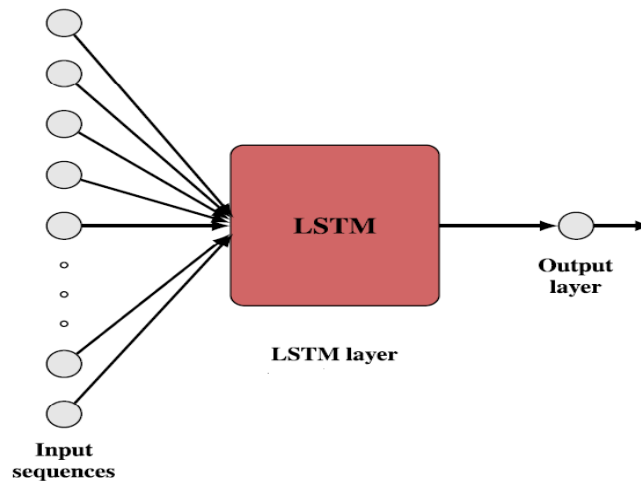
Συνοψίζοντας, η βαθιά μάθηση είναι μια από τις θεμελιώδεις μεθόδους που χρησιμοποιούνται ευρέως στον τομέα της μηχανικής μάθησης. Οι μέθοδοι και οι αλγόριθμοι που βασίζονται σε τεχνικές βαθιάς μάθησης έχουν αποδειχθεί πολύ επιτυχημένες στην επίλυση σύνθετων προβλημάτων. Τα μοντέλα βαθιάς μάθησης χρησιμοποιούνται ευρέως στους υπολογιστές, την επεξεργασία φυσικής γλώσσας, τα συστήματα συστάσεων, τη βιοϊατρική πληροφορική και άλλους τομείς. Η υπεροχή των βαθιών τεχνικών αποδίδεται κυρίως σε τρία βασικά στοιχεία, τα οποία σχετίζονται με τη βαθιά μάθηση και αποτελούν μία από τις θεμελιώδεις μεθόδους που χρησιμοποιούνται ευρέως στον τομέα της μηχανικής μάθησης, δηλαδή στην αποτελεσματικότητα, την ακρίβεια και την ευελιξία (Bengio et al., 2006; SAP SE, 2015). Τα πλεονεκτήματα της βαθιάς τεχνολογίας βρίσκονται κυρίως σε τρία βασικά στοιχεία,

- Τα συστήματα βαθιάς μάθησης είναι ικανά να μαθαίνουν πολύπλοκες και εξαιρετικά μεταβλητές λειτουργίες.
- Αναλύουν δεδομένα με ελάχιστη ανθρώπινη παρέμβαση.
- Λειτουργούν με μεγάλο αριθμό παραδειγμάτων, κυρίως χρησιμοποιώντας δεδομένα.
- Εκμεταλλεύονται επίσης τις συνέργειες που εμφανίζονται σε μεγάλο αριθμό εργασιών

(Bengio et al. 2006).


4.2 *Long Short-Term Memory networks*

Το νευρωνικό δίκτυο μακροπρόθεσμης μνήμης (LSTM) είναι η πιο ευρέως χρησιμοποιούμενη τοπολογία στα νευρωνικά δίκτυα βαθιάς μάθησης. Τα LSTM δύναται να μάθουν μακροπρόθεσμες εξαρτήσεις χρησιμοποιώντας συνδέσεις ανατροφοδότησης για να «θυμηθούν» προηγούμενες καταστάσεις του δικτύου. Έχουν γίνει πολύ δημοφιλή λόγω της επιτυχημένης χρήσης τους σε ένα ευρύ φάσμα εφαρμογών και λόγω της εξαιρετικής τους απόδοσης στην πρόβλεψη χρονοσειρών.



Εικόνα 4-1. Η Δομή του μοντέλου πρόβλεψης LSTM

Συγκεκριμένα, τα LSTM είναι ένας ειδικός τύπος βαθιών νευρωνικών δικτύων που εμπίπτουν στην κατηγορία των επαναλαμβανόμενων νευρωνικών δικτύων (RNN). Τα Recurrent Neural Networks προτάθηκαν για την επίλυση του προβλήματος των παραδοσιακών νευρωνικών δικτύων τροφοδοσίας, το οποία εξαντλούνται από μνήμη και επομένως δεν αποδίδουν καλά σε προβλήματα ακολουθίας και χρονοσειρών. Τα RNN χρησιμοποιούν επαναλαμβανόμενες συνδέσεις στα κρυφά τους στρώματα για να αποκτήσουν βραχυπρόθεσμη μνήμη και έτσι να μπορούν να επεξεργαστούν πληροφορίες από δεδομένα ακολουθίας και χρονοσειρών. Τα RNN περιορίζουν το μοντέλο για να μαθαίνουν εξαρτήσεις μεγάλης κλίμακας, επομένως τα νευρωνικά δίκτυα LSTM λύνουν αυτό το πρόβλημα αποθηκεύοντας χρήσιμες πληροφορίες σε κελιά μνήμης και απορρίπτοντας περιττές πληροφορίες, επιτυγχάνοντας συχνά καλύτερη απόδοση από τα RNN. Μια μονάδα LSTM αποτελείται από κελιά μνήμης, πύλες εισόδου, εξόδου και λήψης. Η πύλη εισόδου (it) μαζί με μια δεύτερη πύλη (ct), ελέγχει τις νέες πληροφορίες που αποθηκεύονται στο κελί μνήμης (ct) τη στιγμή t , ενώ η πύλη (gt) ελέγχει τις προηγούμενες πληροφορίες που πρέπει να εξαφανιστούν ή πρέπει να διατηρούνται στο κελί μνήμης τη στιγμή $time - 1$. Τέλος, η πύλη εξόδου (ot) ελέγχει την τελική τιμή πληροφοριών εξόδου (ht) που δίνεται μετά από καθυστέρηση 1 χρονικού βήματος σε όλες τις άλλες πύλες από έναν βρόχο σύνδεσης ανατροφοδότησης (Π. Αργυράκης, 2001). Σε αυτή τη δομή, τα LSTM καταφέρνουν να δημιουργήσουν μια ελεγχόμενη ροή πληροφοριών αποφασίζοντας ποιες πληροφορίες να ξεχάσουν και ποιες να θυμηθούν, μαθαίνοντας έτσι με επιτυχία μακροπρόθεσμες εξαρτήσεις.



Εικόνα 4-2. Αρχιτεκτονική του LSTM

4.3 Μέθοδος Adam

Για να ελαχιστοποιήσουμε το σφάλμα κατά την εκπαίδευση των νευρωνικών δικτύων χρησιμοποιούμε διάφορους αλγόριθμους βελτιστοποίησης. Στην μελέτη μας θα χρησιμοποιήσουμε την μέθοδο Adam.

Το ADAM είναι μια μέθοδος στοχαστικής βελτιστοποίησης συναρτήσεων που είναι πολύ σημαντική στη βαθιά μάθηση και στη μηχανική μάθηση. Η αναδρομική διαδικασία είναι εξαιρετική για την επίλυση γραμμικών συστημάτων με θορυβώδη δεδομένα και την προσέγγιση των ακραίων συναρτήσεων που μπορούν να εκτιμηθούν μόνο από θορυβώδεις παρατηρήσεις. Ο αλγόριθμος ADAM είναι απλός στην εφαρμογή του, έχει υψηλή υπολογιστική απόδοση και καταλαμβάνει λιγότερη μνήμη και είναι κατάλληλος για μεγάλα σύνολα δεδομένων και παραμέτρους. Το ADAM συνδυάζει δύο μεθόδους στοχαστικής κλίσης καθόδου, την προσαρμοστική κλίση και τη διάδοση του μέσου τετραγώνου της ρίζας. Αντί να χρησιμοποιεί ολόκληρο το σύνολο δεδομένων για τον υπολογισμό της πραγματικής διαβάθμισης, αυτός ο αλγόριθμος βελτιστοποίησης χρησιμοποιεί ένα τυχαία επιλεγμένο υποσύνολο δεδομένων για να δημιουργήσει μια τυχαία προσέγγιση (Kingma, 2014).

4.4 Σχετικές Έρευνες - Ανασκόπηση Βιβλιογραφίας

Η αξιολόγηση των μοντέλων πρόβλεψης Χρονοσειρών και η αντίστοιχη πρόβλεψη χρονοσειρών θεωρείται ένα από τα πιο απαιτητικά και πολύπλοκα πεδία μελέτης. Η πολυπλοκότητα της εσωτερικής δομής των χρονοσειρών πηγάζει από μια ποικιλία παραγόντων που έχουν βαθύ αντίκτυπο στις χρονοσειρές. Τα τελευταία χρόνια έχει γίνει μεγάλη έρευνα στον τομέα αυτό και με τη συμβολή της πληροφορικής έχουν γίνει μεγάλα βήματα προς αυτή την κατεύθυνση. Μερικές μελέτες σε αυτόν τον τομέα είναι οι εξής:

Οι Pintelas et al. (2020) Στη μελέτη τους, αξιολόγησαν την απόδοση προηγμένων μεθόδων μηχανικής μάθησης για την πρόβλεψη μελλοντικών τιμών των μεγάλων χρονοσειρών κρυπτονομισμάτων. Εξέτασαν εάν οι μέθοδοι μηχανικής εκμάθησης μπορούσαν να πραγματοποιήσουν αξιόπιστες προβλέψεις τιμών κρυπτονομισμάτων και κατέληξαν στο συμπέρασμα ότι μπορεί να υπάρχουν κάποια κρυφά μοτίβα σε χρονοσειρές κρυπτονομισμάτων, παρόλο που οι τιμές τους φαίνεται να προέρχονται από τυχαίες διαδικασίες. (S. Stavroyiannis, 2020)

Οι Livieris et al. (2020) Στην έρευνά τους, ανέλυσαν τα προβλήματα των μοντέλων βαθιάς μάθησης στην πρόβλεψη χρονοσειρών και τα έλυσαν διαφοροποιώντας τις χρονοσειρές πριν τις τροφοδοτήσουν στα μοντέλα που ανέπτυξαν. αυτή η τεχνική μειώνει σημαντικά το σφάλμα πρόβλεψης σε σχέση με την εισαγωγή χρονοσειρών σε ένα μονομεταβλητό μοντέλο, επιπλέον της βελτίωσης της αξιοπιστίας των προβλέψεων.

Οι Fawaz et al. (2019) στην ερευνά τους, εισήγαγαν την εφαρμογή της βαθιάς μάθησης στον τομέα της πρόβλεψης χρονοσειρών και εξήγησαν λεπτομερώς τη διαδικασία εξόρυξης δεδομένων χρονοσειρών και ανακάλυψης νέων πληροφοριών για τη λήψη αποφάσεων. Εφάρμοσαν τα παραπάνω σε χρονοσειρές που αφορούσαν τις τιμές των μετοχών, την ενεργειακή βιομηχανία και τη βιομηχανία κρυπτογράφησης.

Οι Liu et al. (2017) ανέπτυξαν ένα μοντέλο CNN-LSTM για να αναλύσει ποσοτικά τις τιμές των μετοχών και να βρει στρατηγικές μεγιστοποίησης του κέρδους, και το εφαρμόστηκε σε δεδομένα δεικτών για να αυξήσει τα ποσά των κερδών.

Οι Fischer και Krauss (2018) επικεντρώθηκαν στην ανάπτυξη ενός μοντέλου βαθιάς μάθησης για την πρόβλεψη χρηματιστηριακών δεικτών αναπτύσσοντας ένα μοντέλο

πρόβλεψης LSTM που ξεπέρασε τις μεθόδους ταξινόμησης όπως τα τυχαία δάση, η λογιστική παλινδρόμηση κ.λπ., έτσι πραγματοποίησαν μια ταξινόμηση με βάση τα κέρδη και τις ζημίες των μετοχών βάσει του S&P500. δείκτης εισοδήματος.

Συμπερασματικά, οι περισσότερες μέθοδοι στη βιβλιογραφία προσπαθούν να εξάγουν χρήσιμες πληροφορίες/γνώση από δεδομένα χρονοσειρών χρησιμοποιώντας τεχνικές βαθιάς μάθησης με στόχο να κάνουν τα προτεινόμενα μοντέλα τους να ξεπερνούν τα υπάρχοντα μοντέλα πρόβλεψης.

5 Εισαγωγή στα Κρυπτονομίσματα

5.1 Εισαγωγή

Στα παρακάτω κεφάλαια αναφέρονται οι βασικές αρχές που αφορούν την κρυπτό οικονομία και τα δύο κρυπτονομίσματα που εξετάζονται. Το σύνολο των πληροφοριών συλλέχθηκαν από την ηλεκτρονική βιβλιοθήκη μάθησης:

- <https://academy.binance.com/en>

του παγκόσμιου φήμης ανταλλακτηρίου κρυπτονομισμάτων Binance που αποτελεί μία από τις πιο έγκυρες και αναγνωρισμένες πηγές γνώσης στο συγκεκριμένο τομέα. Αντίστοιχα άρθρα που να περιγράφουν με τόση σαφήνεια τις έννοιες που διατυπώνονται παρακάτω δεν βρέθηκαν κατά την διάρκεια της έρευνας μου καθώς και της βιβλιογραφικής ανασκόπησης. (

Τα χρήματα τυπωμένα σε χαρτί ή τα ηλεκτρονικά θεωρούνται ο πιο αποδεκτός τρόπος αγοράς χρημάτων σε οποιοδήποτε κοινωνικό-οικονομικό πλαίσιο, προϊόν ή υπηρεσία. Από την αρχαιότητα θεωρήθηκε απαραίτητη η δημιουργία μιας μονάδας «ανταλλαγής» για ένα προϊόν που η αξία του εξαρτάται από το υλικό από το οποίο κατασκευάζεται. Τελικά, η χρήση νομισμάτων οδήγησε στην εμφάνιση αντιπροσωπευτικών νομισμάτων μέχρι σήμερα που είναι μία μια ευρέως και παγκοσμίως αποδεκτή πρακτική.

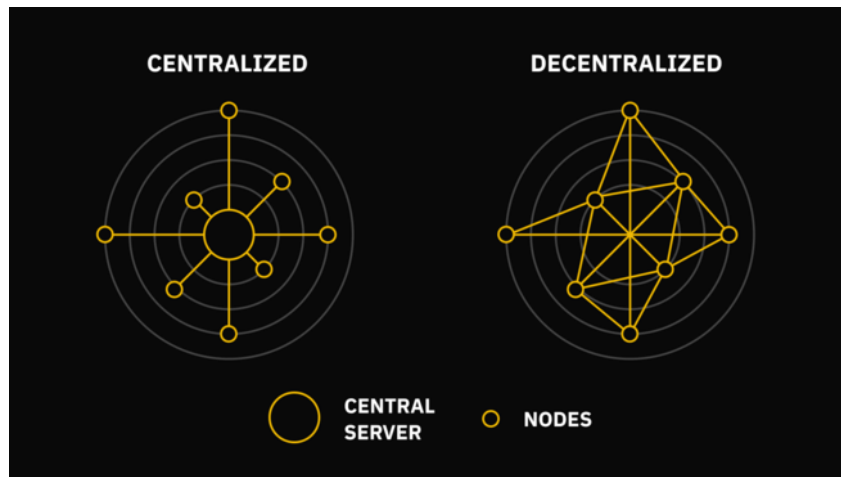
Για να συνοψίσουμε, μπορούμε να ορίσουμε ένα μέσο ανταλλαγής όπως το EUR ή το USD ως κρυπτονομίσμα, με τη διαφορά είναι ότι χρησιμοποιείται για την ανταλλαγή ψηφιακών πληροφοριών, μια διαδικασία που διέπεται από την χρήση ορισμένων κρυπτογραφικών αρχών.

Ο όρος κρυπτογράφηση αναφέρεται στη διαδικασία κωδικοποίησης-αποκωδικοποίησης πληροφοριών προκειμένου να μην επιτρέπεται η μετάδοσή τους σε μη εξουσιοδοτημένους χρήστες. Αυτό διασφαλίζει τις συναλλαγές, ενώ η διαδικασία παραγωγής νέων νομισμάτων ελέγχεται και το πιο σημαντικό είναι ότι οι εκάστοτε κυβερνήσεις δεν έχουν κανένα απολύτως έλεγχο μέχρι τώρα. Η λειτουργία του παραδοσιακού νομίσματος είναι ότι τα χρηματοπιστωτικά ιδρύματα έχουν τη δυνατότητα να εκδίδουν νέες μονάδες παραδοσιακού νομίσματος, με αποτέλεσμα μια πληθωριστική τάση. Αντίθετα, τα κρυπτονομίσματα έχουν σχεδιαστεί έτσι ώστε η

παραγωγή τους να μην μειώνεται. Για παράδειγμα, δεν θα υπάρχουν περισσότερα από 21 εκατομμύρια bitcoin σε κυκλοφορία. Οι πρώτες πληροφορίες για την οικονομία του Διαδικτύου, πάντα θεωρητικές, προέρχονται από τον Marshall McLuhan στο βιβλίο του *Understanding the Media*» (1964). Για πρώτη φορά το 1998 ο Wei Dai χρησιμοποιεί τον όρο κρυπτονόμισμα ως μια νέα μορφή χρήματος η οποία θα αντικαθιστούσε οποιαδήποτε κεντρική αρχή και θα χρησιμοποιούσε ουσιαστικά την κρυπτογραφία για να ελέγξει τη δημιουργία και τις συναλλαγές μιας νέας μορφής χρήματος.

Αξίζει να αναφερθεί σε αυτό το σημείο ότι το έναυσμα για την δημιουργία των κρυπτονομισμάτων ξεκίνησε περίπου το 2008 λόγω της οικονομικής κρίσης, η οποία επηρέασε σε μεγάλο βαθμό τον κόσμο λόγω της συνεχιζόμενης οικονομικής και εξουθενωτικής χρηματοπιστωτικής μετάβασης. Το παγκόσμιο χρηματοπιστωτικό σύστημα είχε καταρρεύσει και ενώ πολλές κεντρικές τράπεζες επέλεξαν να αυξήσουν τη ρευστότητα της αγοράς μέσω προγραμμάτων ποσοτικής χαλάρωσης, με απώτερο στόχο φυσικά να μην επαναληφθεί η Μεγάλη Ύφεση της δεκαετίας του 1930, οι κυβερνήσεις δεν είχαν άλλη επιλογή από το να εκτυπώσουν επιπλέον χρήματα πράγμα που υποτίμησε περαιτέρω την τρέχουσα αξία του χρήματος. Η οικονομική κρίση δημιούργησε πολιτικές αναταραχές, αύξηση στην επιβάρυνση των φορολογουμένων, χρέη στο δημόσιο ταμείο, οικονομίες χωρών στα όρια της χρεωκοπίας κ.λπ. και τότε κρίθηκε απαραίτητη από την κοινωνία, η δημιουργία ενός νέου αποκεντρωμένου συστήματος πληρωμών που θα λειτουργούσε ως κεντρική αρχή. Το κύριο χαρακτηριστικό όλων των κρυπτονομισμάτων (συμπεριλαμβανομένου του BITCOIN φυσικά) είναι ότι βασίζονται σε λογισμικό ανοιχτού κώδικα, το οποίο είναι δημόσιο και διαθέσιμο σε κάθε χρήστη που επιθυμεί να ελέγξει τις λεπτομέρειες της λειτουργίας τους.

Τα κρυπτονομίσματα είναι μοναδικά για διάφορους λόγους. Ωστόσο, η κύρια λειτουργία τους είναι να λειτουργεί ως ηλεκτρονικό σύστημα μετρητών που δεν ανήκει σε κανένα τραπεζικό σύστημα. Καμία κεντρική τράπεζα ή υποσύνολο χρηστών δεν μπορεί να αλλάξει τους κανόνες χωρίς συναίνεση. Οι συμμετέχοντες στο δίκτυο (κόμβοι) εκτελούν λογισμικό που τους συνδέει με άλλους συμμετέχοντες, ώστε να μπορούν να μοιράζονται πληροφορίες μεταξύ τους.



Εικόνα 5-1. Κεντρικά έναντι αποκεντρωμένων δικτύων

Στην παραπάνω εικόνα στα αριστερά είναι η κεντρική μέθοδος που χρησιμοποιούν οι τράπεζες. Οι χρήστες πρέπει να επικοινωνούν μέσω κεντρικού διακομιστή. Ενώ στα δεξιά, δεν υπάρχει ιεραρχία, οι κόμβοι συνδέονται μεταξύ τους και περνούν πληροφορίες μεταξύ τους. Η αποκέντρωση των δικτύων κρυπτονομισμάτων τα καθιστά ιδιαίτερα ανθεκτικά σε τερματισμούς λειτουργίας. Αντίθετα, για να ακρωτηριαστεί το κεντρικό δίκτυο, χρειάζεται απλώς να διακοπεί ο κύριος διακομιστής. Εάν η βάση δεδομένων μιας τράπεζας διαγραφόταν και δεν δημιουργήθηκαν αντίγραφα ασφαλείας, θα ήταν πολύ δύσκολο να προσδιοριστεί το υπόλοιπο λογαριασμού ενός χρήστη. Στα κρυπτονομίσματα, οι κόμβοι διατηρούν ένα αντίγραφο της βάσης δεδομένων. Το καθένα λειτουργεί αποτελεσματικά ως ο δικός του διακομιστής. Οι μεμονωμένοι κόμβοι μπορούν να βγουν εκτός σύνδεσης, αλλά οι υπόλοιποι εξακολουθούν να μπορούν να λάβουν πληροφορίες από άλλους κόμβους. Επομένως, τα κρυπτονομίσματα λειτουργούν 24 ώρες την ημέρα, 365 ημέρες το χρόνο. Συνεπώς, επιτρέπουν τη μεταφορά αξίας οπουδήποτε στον κόσμο χωρίς την παρέμβαση μεσάζοντα. Γι' αυτό συχνά αποκαλούμε αυτές συναλλαγές τις χωρίς άδεια(οποιοσδήποτε έχει σύνδεση στο Διαδίκτυο μπορεί να μεταφέρει χρήματα.)

5.2 Bitcoin

5.2.1 Βασικές Έννοιες

Το 2009 ένας γνωστός προγραμματιστής με το ψευδώνυμο SATOSHI NAKAMOTO δημιούργησε το BITCOIN ο οποίος δήλωσε, ‘Ασχολούμαι με ένα νέο σύστημα ηλεκτρονικού χρήματος , το οποίο λειτουργεί με το διομότιμο σύστημα (peer –to-peer system –P2P), χωρίς την παρουσία τρίτου , έμπιστου μέρους. Η προκήρυξη-έγγραφο είναι διαθέσιμο στην ηλεκτρονική διεύθυνση <http://www.bitcoin.org/bitcoin.pdf> . Το διομότιμο δίκτυο αποτρέπει τις διπλές δαπάνες ,δεν εμπλέκονται εκδότες ή άλλοι τρίτοι και συμμετέχοντες μπορεί να είναι ανώνυμοι. Τα καινούργια νομίσματα δημιουργούνται μέσω μιας Απόδειξης εργασίας (Proof of Work-POW) τύπου Hash. Η απόδειξη Εργασίας της παραγωγής καινούργιων νομισμάτων ενεργοποιεί επίσης το δίκτυο, ώστε να επιτρέπονται οι διπλές δαπάνες.



Εικόνα 5-2. Λογότυπο Bitcoin

Ίσως η πιο σημαντική πτυχή του Bitcoin είναι η ιδέα πίσω από αυτό. Το Bitcoin δημιουργήθηκε από τον προγραμματιστή Satoshi Nakamoto ο οποίος σχεδίασε μια εντελώς νέα μέθοδο πληρωμής για να ανατρέψει τον τρόπο με τον οποίο πληρώνουμε όλοι στο διαδίκτυο, λαμβάνοντας υπόψη του ορισμένα προβλήματα με τα υπάρχοντα συστήματα πληρωμών τα οποία θέλησε να τα λύσει.

Η υποδομή του Bitcoin έχει πλέον μελετηθεί και πολλές τράπεζες και ιδιωτικές εταιρίες εργάζονται πάνω στην τεχνολογία που τροφοδοτεί το Bitcoin καθώς βλέπουν τις δυνατότητές του και θέλουν να χρησιμοποιήσουν τη δύναμη αυτής της τεχνολογίας για τους δικούς τους σκοπούς. Φυσικά, είναι ελεύθεροι να το κάνουν, καθώς η βασική τεχνολογία Bitcoin γνωστή ως blockchain ήταν ανοιχτού κώδικα από την πρώτη μέρα για να τη δουν όλοι . Η δημιουργία Bitcoin «ως ανοιχτού κώδικα» σημαίνει ότι

οποιοσδήποτε μπορεί να δημιουργήσει τις δικές του βελτιώσεις και να δημιουργήσει πλατφόρμες πάνω από αυτές.

Ο ρόλος της βιομηχανίας κρυπτογραφίας στην ύπαρξη του Bitcoin είναι καθοριστικός και το Bitcoin χρησιμοποιεί ασύμμετρη κρυπτογράφηση. Η κρυπτογραφία είναι η τεχνική βάση για την αποκωδικοποίηση ενός μηνύματος από μια μη αναγνώσιμη φόρμα σε μια αναγνώσιμη μορφή χωρίς να γνωρίζουμε πώς έγινε η αρχική μετατροπή από την αναγνώσιμη μορφή σε μια μη αναγνώσιμη μορφή. Για να πραγματοποιήσετε συναλλαγές χρησιμοποιώντας Bitcoin, πρέπει να υπάρχουν δύο ψηφιακά κλειδιά: ένα δημόσιο κλειδί και ένα ιδιωτικό κλειδί. Το δημόσιο κλειδί είναι γνωστό σε όσους θέλουν να συναλλάσσονται με αυτόν τον χρήστη, ενώ το ιδιωτικό κλειδί αποδεικνύει την κυριότητα ενός συγκεκριμένου ποσού bitcoin και εγγυάται τη μεταφορά του ποσού στον παραλήπτη. Επομένως, κάθε χρήστης διαθέτει δύο ψηφιακά κλειδιά, ένα ιδιωτικό και ένα δημόσιο. Η ασύμμετρη κρυπτογράφηση είναι ότι ο κάτοχος του ιδιωτικού κλειδιού μπορεί να δημιουργήσει μαθηματικά το δημόσιο κλειδί, αλλά το αντίστροφο είναι εξαιρετικά απίθανο. Το Δημόσιο κλειδί αποτελείται από ένα σύνολο αριθμών και γραμμάτων (κεφαλαία και πεζά) που αποτελούν τη διεύθυνση που χρησιμοποιούν οι χρήστες για τη διεξαγωγή συναλλαγών (Η. Παρίσης, 2019) ενώ το Ιδιωτικό κλειδί είναι ένα σύνολο αριθμών και γραμμάτων, ακριβώς όπως ένα δημόσιο κλειδί. Ωστόσο, είναι μυστικό και είναι γνωστό μόνο στους χρήστες που το χρησιμοποιούν για την υπογραφή συναλλαγών. Αντίστοιχα το πορτοφόλι χρησιμοποιείται ως μια μέθοδος αποθήκευσης μιας μονάδας κρυπτονομίσματος που ανήκει σε έναν χρήστη χρησιμοποιώντας ένα ιδιωτικό κλειδί.

Το Bitcoin μπορεί να ειπωθεί ότι είναι ο οδηγός των κρυπτονομισμάτων. Ας το παραδεχτούμε, η διασταύρωση οικονομικών και τεχνολογίας είναι γεμάτη προβλήματα. Όλοι μας έχουμε επηρεαστεί από την τραπεζική κρίση του 21ου αιώνα και πολλές χώρες εξακολουθούν να αγωνίζονται να ανακάμψουν από την οικονομική κρίση. Ο προγραμματιστής του Bitcoin, Satoshi Nakamoto, θύμα κακής διαχείρισης της κεντρικής τράπεζας, αγωνίστηκε να βρει μια προτεινόμενη λύση μετά από πολύ και σκληρή σκέψη. Η κύρια χρηματοοικονομική υποδομή είναι ελαττωματική και οι βιώσιμες εναλλακτικές είναι πολύ ευπρόσδεκτες. Το αν αυτή η εναλλακτική θα είναι το Bitcoin μένει να φανεί.

5.2.2 Παραγωγή Bitcoin και Mining

Το Bitcoin, είναι ένα αποκεντρωμένο σύστημα, το οποίο απαιτεί συνεισφορές από υπολογιστές σε όλο τον κόσμο για την επιβεβαίωση συναλλαγών που πραγματοποιούνται σε παγκόσμια κλίμακα. Αυτή η διαδικασία απαιτεί τεράστια υπολογιστική ισχύ. Νέα bitcoin εκδίδονται κάθε δέκα λεπτά και όσοι συνεισφέρουν στην επιβεβαίωση της συναλλαγής ανταμείβονται με βάση τη συνεισφορά όλων. Εκείνοι που επιβεβαιώνουν συναλλαγές για τη συλλογή ανταμοιβών ονομάζονται miners και η διαδικασία είναι η εξόρυξη (mining) (Η. Παρίσης, 2019).

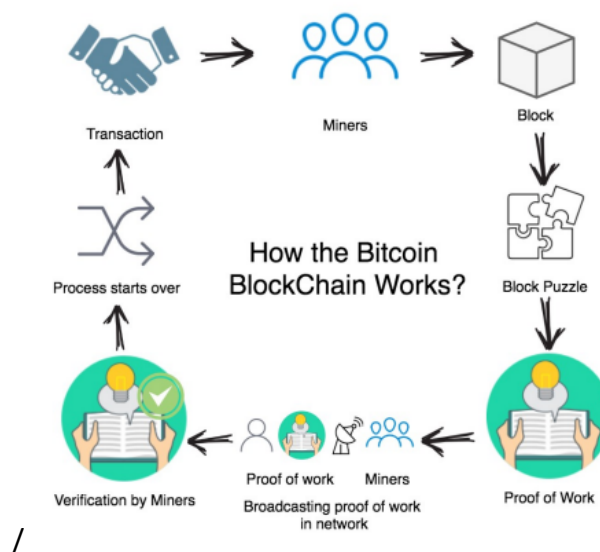
Κάθε συναλλαγή που γίνεται με Bitcoin ελέγχεται για επικύρωση και στη συνέχεια τοποθετείται σε ένα μπλοκ μαζί με άλλες ολοκληρωμένες συναλλαγές. Κάθε μπλοκ που δημιουργείται έχει άμεση σχέση με το προηγούμενο μπλοκ και όλα τα άλλα μπλοκ. Αυτό δημιουργεί μια αλυσίδα μπλοκ. Η σχέση κάθε νέου μπλοκ με το προηγούμενο καθορίζεται από έναν μαθηματικό αλγόριθμο. Κάθε φορά που δημιουργείται ένα νέο μπλοκ, αυτόματα δημιουργούνται μερικά νέα bitcoin και διανέμονται σε αυτούς που θα λύσουν τον αλγόριθμο με βάση τη συνεισφορά του καθενός (εξόρυξη). Όσο μεγαλύτερο είναι το ποσοστό της συνολικής υπολογιστικής ισχύος που χρησιμοποιεί κάποιος για να λύσει τον αλγόριθμο, τόσο μεγαλύτερο είναι το ποσοστό των bitcoin που παράγονται. Ο αλγόριθμος είναι πάντα τόσο δύσκολο να λυθεί που χρειάζονται κατά μέσο όρο 10 λεπτά για όλη την υπολογιστική ισχύ (όλοι οι εξορύκτες) να εργαστούν στη λύση του για να τον λύσουν. Έτσι, με την πάροδο του χρόνου, το σύστημα προσαρμόζει την αλγοριθμική λύση και τη δυσκολεύει, καθώς αυξάνεται ταυτόχρονα η συνολική υπολογιστική ισχύς που είναι διαθέσιμη στη λύση του (Η. Παρίσης, 2019).

5.2.3 Block Chain και Hash

Το blockchain είναι μια σειρά από μπλοκ που συνδέονται μεταξύ τους σαν μια αναπτυσσόμενη αλυσίδα. Κάθε ένα από αυτά τα μπλοκ περιέχει δεδομένα και έναν δείκτη κατακερματισμού στο προηγούμενο μπλοκ, δημιουργώντας την αλυσίδα. Ένα κατακερματισμένο ευρετήριο είναι παρόμοιο με ένα απλό ευρετήριο, αλλά δεν δείχνει μόνο το προηγούμενο μπλοκ, περιέχει επίσης όλες τις εγγραφές του προηγούμενου μπλοκ και αυτό το στοιχείο κάνει το blockchain τόσο αξιόπιστο. Στο blockchain, οι κατακερματισμοί (Hashes) χρησιμοποιούνται για τον προσδιορισμό της κατάστασης του blockchain και τη διασφάλιση της αμετάβλητης του. Κάθε συναλλαγή περιλαμβάνει

πληροφορίες όπως το ποσό που στάλθηκε, τη διεύθυνση στην οποία στάλθηκε, την ώρα και όλες τις πληροφορίες που εμπλέκονται στη συναλλαγή. Ως εκ τούτου, δημιουργείται ένας τύπος για τη δημιουργία μιας τιμής κατακερματισμού που ονομάζεται αναγνωριστικό συναλλαγής. Το αναγνωριστικό συναλλαγής είναι η τιμή κατακερματισμού (hash value) που χρησιμοποιούμε για να επιβεβαιώσουμε ότι η συναλλαγή πραγματοποιήθηκε.

Το πρώτο μπλοκ στην αλυσίδα μπλοκ, είναι γνωστό και ως μπλοκ γένεσης (genesis block), περιέχει πληροφορίες που όταν συνδυαστούν καταλήγουν σε ένα μοναδικό κατακερματισμό (hash). Όταν δημιουργείται το δεύτερο μπλοκ, ο κατακερματισμός του μπλοκ γένεσης συσχετίζεται με όλες τις νέες συναλλαγές που προστίθενται σε αυτό μαζί και ο συνδυασμός τους δημιουργεί τον επόμενο κατακερματισμό, έτσι η αλυσίδα συνεχίζει δημιουργώντας συνεχώς νέα μπλοκ που περιέχουν όλες τις νέες πληροφορίες συναλλαγής μαζί με τον κατακερματισμό ολόκληρου του προηγούμενου μπλοκ.



Εικόνα 5-3. Λειτουργία Blockchain του Bitcoin (S. Ghimire, 2019)

Κατακερματισμός (hashing) είναι η διαδικασία χρήσης μαθηματικών συναρτήσεων για την εισαγωγή πληροφοριών οποιουδήποτε μεγέθους σε μια έξοδο καθορισμένου μεγέθους. Αυτό σημαίνει ότι οποιαδήποτε πληροφορία, όσο μεγάλη κι αν είναι, μπορεί να μετατραπεί αλγοριθμικά σε μια σειρά από γράμματα και αριθμούς. Το μήνυμα που εισάγουμε ονομάζεται είσοδος, ο αλγόριθμος που χρησιμοποιούμε ονομάζεται

συνάρτηση κατακερματισμού και η έξοδος ονομάζεται τιμή κατακερματισμού. Στο πλαίσιο των κρυπτονομισμάτων όπως το Bitcoin, οι συναλλαγές αντιμετωπίζονται ως είσοδοι και εκτελούνται μέσω ενός αλγόριθμου κατακερματισμού (SHA-256), ο οποίος παρέχει μια έξοδο σταθερού μήκους.

Στην παρούσα μελέτη θα χρησιμοποιηθούν οι χρονοσειρές του Bitcoin στην αξιολόγηση των μοντέλων πρόβλεψης βάθιας μάθησης που παρουσιάζονται στα επόμενα κεφάλαια.

5.3 *Ethereum*

5.3.1 Βασικές Έννοιες

Το 2008, ένας άγνωστος προγραμματιστής (ή ομάδα προγραμματιστών) δημοσίευσε τη λευκή βίβλο του Bitcoin με το ψευδώνυμο Satoshi Nakamoto. Αυτό άλλαξε το τοπίο του ψηφιακού νομίσματος για πάντα. Λίγα χρόνια αργότερα, ένας νεαρός προγραμματιστής ονόματι Vitalik Buterin φαντάστηκε έναν τρόπο να προχωρήσει την ιδέα και να την εφαρμόσει σε κάθε είδους εφαρμογή. Αυτή η ιδέα τελικά ενσωματώθηκε στο Ethereum. Το Ethereum προτάθηκε από τον Buterin σε μια ανάρτηση ιστολογίου το 2013 με τίτλο Ethereum: The Ultimate Smart Contract and Decentralized Application Platform. Στην ανάρτησή του, περιγράφει την ιδέα μιας ολοκληρωμένης αλυσίδας μπλοκ Turing - ενός αποκεντρωμένου υπολογιστή που μπορεί να τρέξει οποιαδήποτε εφαρμογή με αρκετό χρόνο και πόρους. Με την πάροδο του χρόνου, οι τύποι εφαρμογών που μπορούν να αναπτυχθούν σε μια αλυσίδα μπλοκ θα περιοριστούν μόνο από τη φαντασία των προγραμματιστών. Το Ethereum στοχεύει να ανακαλύψει εάν η τεχνολογία blockchain έχει έγκυρες χρήσεις εκτός των εσκεμμένων περιορισμών σχεδιασμού του Bitcoin.



Εικόνα 5-4. Λογότυπο Ethereum

Το Ethereum, λειτουργεί σε χιλιάδες μηχανήματα σε όλο τον κόσμο ταυτόχρονα, πράγμα που σημαίνει ότι δεν έχει ιδιοκτήτη. Όπως το Bitcoin και άλλα κρυπτονομίσματα, το Ethereum επιτρέπει να μεταφερθούν ψηφιακά νομίσματα. Ωστόσο, οι ιδιότητες του είναι διευρυμένες και δύναται να αναπτύξει ο καθένας τον δικό του κώδικα και να αλληλοεπιδράσει με εφαρμογές που έχουν δημιουργηθεί από άλλους χρήστες. Επειδή είναι τόσο ευέλικτο, είναι δυνατό να ξεκινήσεις διάφορα πολύπλοκα προγράμματα στο Ethereum. Με λίγα λόγια, η κύρια ιδέα πίσω από το Ethereum είναι ότι οι προγραμματιστές μπορούν να δημιουργήσουν και να εκκινήσουν κώδικα που εκτελείται σε ένα κατακεντρωμένο δίκτυο, αντί να ζουν σε έναν κεντρικό διακομιστή. Αυτό σημαίνει ότι, θεωρητικά, αυτές οι εφαρμογές δεν μπορούν να τερματιστούν ή να λογοκριθούν.

Επίσης μπορούμε να ορίσουμε το Ethereum ως μηχανήμα κατάστασης. Αυτό σημαίνει ότι ανά πάσα στιγμή, μπορείτε να δούμε πώς μοιάζουν επί του παρόντος όλα τα υπόλοιπα λογαριασμών και τα έξυπνα συμβόλαια. Ορισμένες λειτουργίες οδηγούν σε ενημερώσεις κατάστασης, πράγμα που σημαίνει ότι όλοι οι κόμβοι ενημερώνουν τα δικά τους στιγμιότυπα για να αντικατοπτρίζουν τις αλλαγές.

Τα έξυπνα συμβόλαια που εκτελούνται στο Ethereum ενεργοποιούνται από συναλλαγές (από χρήστες ή άλλα συμβόλαια). Όταν ένας χρήστης στέλνει μια συναλλαγή σε ένα συμβόλαιο, κάθε κόμβος στο δίκτυο εκτελεί τον κώδικα της σύμβασης και καταγράφει την έξοδο. Αυτό το κάνει χρησιμοποιώντας την εικονική μηχανή Ethereum (EVM), η οποία μεταφράζει τα έξυπνα συμβόλαια σε οδηγίες που μπορούν να διαβάσουν οι υπολογιστές.

Για την ενημέρωση της κατάστασης, χρησιμοποιείται ένας ειδικός μηχανισμός που ονομάζεται εξόρυξη (επί του παρόντος). Η εξόρυξη γίνεται μέσω ενός αλγόριθμου απόδειξης εργασίας (proof of work), όπως ακριβώς το Bitcoin.

Μιλήσαμε για την ιδέα ότι το Ethereum μπορεί να εκτελεί κώδικα σε κατακεντρωμένα συστήματα. Επομένως, το πρόγραμμα δεν μπορεί να παραβιαστεί από εξωτερικά μέρη. Η βάση δεδομένων του Ethereum (το blockchain) έχει προγραμματιστεί έτσι ώστε να μην είναι δυνατή η επεξεργασία του κώδικα. Επίσης, η βάση δεδομένων είναι ορατή σε όλους, ώστε οι χρήστες να μπορούν να ελέγξουν τον κώδικα πριν αλληλοεπιδράσουν μαζί του. Αυτό σημαίνει ότι οποιοσδήποτε από οπουδήποτε μπορεί να εκκινήσει

εφαρμογές που δεν μπορούν να βρεθούν εκτός σύνδεσης. Ακόμη πιο ενδιαφέρον είναι ότι αυτές οι εφαρμογές μπορούν να θέσουν τις προϋποθέσεις για τη μεταφορά αξίας χάρη στην εγγενή τους μονάδα – τον αιθέρα (ethereum) – που αποθηκεύει αξία. Τα προγράμματα που συνθέτουν μια εφαρμογή ονομάζουμε έξυπνο συμβόλαιο. Στις περισσότερες περιπτώσεις, μπορούν να ρυθμιστούν να λειτουργούν χωρίς ανθρώπινη παρέμβαση.

Συνεπώς όπως είναι λογικό, η ιδέα ενός «προγραμματιζόμενου χρήματος» έχει προσελκύσει χρήστες, προγραμματιστές και επιχειρήσεις σε όλο τον κόσμο.

5.3.2 Παραγωγή Ethereum και Mining

Μιλήσαμε εν συντομία για την εξόρυξη του Bitcoin νωρίτερα αναφέροντας ότι η διαδικασία εξόρυξης είναι αναπόσπαστο κομμάτι της διασφάλισης και της ενημέρωσης του blockchain. Στο Ethereum, χρησιμοποιείται ίδια αρχή ,ανταμείβονται οι χρήστες που κάνουν εξόρυξη και το πρωτόκολλο τους ανταμείβει με αιθέρα.

Από τον Φεβρουάριο του 2020, η συνολική προσφορά Ethereum είναι περίπου 110 εκατομμύρια. Σε αντίθεση με το Bitcoin, το σχέδιο προσφοράς του Ethereum δεν αποφασίστηκε σκόπιμα κατά την κυκλοφορία. Το Bitcoin άρχισε να αποθηκεύει αξία περιορίζοντας την προσφορά του και μειώνοντας σταδιακά τον αριθμό των νέων νομισμάτων. Το Ethereum, από την άλλη πλευρά, στοχεύει να παρέχει μια βάση για αποκεντρωμένες εφαρμογές (DApps). Αυτή η ερώτηση παραμένει ανοιχτή καθώς δεν είναι σαφές ποιος τύπος προγράμματος έκδοσης Ethereum είναι καταλληλότερος για αυτόν τον σκοπό.

Η εξόρυξη είναι κρίσιμη για την ασφάλεια του δικτύου. Διασφαλίζει ότι το blockchain μπορεί να ενημερωθεί δίκαια και επιτρέπει στο δίκτυο να λειτουργεί χωρίς έναν μόνο υπεύθυνο λήψης αποφάσεων. Στην εξόρυξη, ένα υποσύνολο κόμβων (που ονομάζονται κατάλληλα εξορύκτες (miners) αφιερώνουν την υπολογιστική τους ισχύ στην επίλυση κρυπτογραφικών γρίφων. Αυτό που στην πραγματικότητα κάνουν είναι να κατακερματίζουν ένα σύνολο εκκρεμών συναλλαγών μαζί με κάποια άλλα δεδομένα. Για να θεωρηθεί ένα μπλοκ έγκυρο, η τιμή κατακερματισμού πρέπει να είναι χαμηλότερη από αυτή που υπαγορεύει το πρωτόκολλο. Εάν δεν είναι επιτυχείς, μπορούν να τροποποιηθούν ορισμένα δεδομένα και να προσπαθήσουν ξανά. Έτσι, για να

ανταγωνιστούν άλλους, οι εξορύκτες (miners) πρέπει να μπορούν να κατακερματίζουν όσο το δυνατόν γρηγορότερα. Όσο υψηλότερο είναι το hash rate στο δίκτυο, τόσο πιο δύσκολο είναι να λυθεί το παζλ. Όπως μπορείτε να φανταστείτε, ο διαδοχικός κατακερματισμός υψηλής ταχύτητας είναι ακριβός. Για να δοθούν κίνητρα στους εξορύκτες να προστατεύσουν το δίκτυο, ανταμείβονται.

5.3.3 Blockchain και hash

Το blockchain βρίσκεται στην καρδιά του Ethereum — είναι η βάση δεδομένων που περιέχει τις πληροφορίες που χρησιμοποιούνται από το πρωτόκολλο. Στο προηγούμενο κεφάλαιο που αναφέρεται το Bitcoin, έχετε αποκτήσει μια βασική κατανόηση του τρόπου λειτουργίας του blockchain. Το blockchain Ethereum είναι παρόμοιο με το Bitcoin, αν και τα δεδομένα που αποθηκεύει - και ο τρόπος που τα αποθηκεύει - είναι διαφορετικά. Το blockchain του Ethereum μπορούμε να το χαρακτηρίσουμε ως ένα βιβλίο στο οποίο συνεχίζετε να προσθέτετε σελίδες. Κάθε σελίδα ονομάζεται μπλοκ και συμπληρώνεται με πληροφορίες σχετικά με τη συναλλαγή. Όταν θέλουμε να προσθέσουμε μια νέα σελίδα, πρέπει να συμπεριλάβουμε μια ειδική τιμή στο επάνω μέρος της σελίδας. Αυτή η τιμή θα πρέπει να επιτρέπει σε οποιονδήποτε να δει ότι η νέα σελίδα προστέθηκε μετά την προηγούμενη σελίδα, αντί να εισαχθεί τυχαία στο βιβλίο. Ουσιαστικά, είναι λίγο σαν να αναφέρεσαι στον αριθμό σελίδας της προηγούμενης σελίδας. Βλέποντας τη νέα σελίδα, μπορούμε να πούμε με βεβαιότητα ότι ακολουθεί την προηγούμενη σελίδα. Για αυτό χρησιμοποιούμε μια διαδικασία που ονομάζεται κατακερματισμός (hashing).

Ένας κατακερματισμός παίρνει ένα κομμάτι δεδομένων, σε αυτήν την περίπτωση, τα πάντα στη σελίδα μας και επιστρέφει ένα μοναδικό αναγνωριστικό (το κατακερματισμό μας). Οι πιθανότητες δύο τεμαχίων δεδομένων να μας δώσουν τον ίδιο κατακερματισμό είναι αστρονομικά χαμηλές. Είναι επίσης μια μονόδρομη διαδικασία: μπορείτε εύκολα να υπολογίσετε τον κατακερματισμό, αλλά είναι σχεδόν αδύνατο να αντιστρέψετε τον κατακερματισμό για να χρησιμοποιήσετε τις πληροφορίες για τη δημιουργία του.

6 Εφαρμογή/Υλοποίηση προβλήματος

6.1 Περιγραφή Προβλήματος

Η διαδικασία του μοντέλου πρόβλεψης των τιμών χρονοσειρών των δύο κρυπτονομισμάτων (Bitcoin-BTC, Ethereum-ETH, περιγράφεται αναλυτικά παρακάτω χρησιμοποιώντας δύο μοντέλα βαθιάς μάθησης (Deep Learning Neural Network-DNN και Long Term Memory Neural Network-LSTM).

Τα τεχνητά νευρωνικά δίκτυα του τύπου που περιεγράφηκαν παραπάνω εκπαιδεύτηκαν χρησιμοποιώντας τη μέθοδο Adam και υποβλήθηκαν σε διάφορες δοκιμές στις τοπολογίες τους, οι οποίες θα αναλυθούν λεπτομερώς σε επόμενες ενότητες αυτού του κεφαλαίου, για να αντληθούν πληροφορίες και συμπεράσματα σχετικά με την εύρεση του καλύτερου μοντέλου και τοπολογίας για την πρόβλεψη των επί εξέταση χρονοσειρών. Προκειμένου να αξιολογήσουμε-συγκρίνουμε τα αποτελέσματα οι χρονοσειρές θα τροφοδοτηθούν στα μοντέλα με και χωρίς διαφόριση. Για την εφαρμογή και τους υπολογισμούς χρησιμοποιήθηκε η γλώσσα προγραμματισμού Python 3.6.2, οι βιβλιοθήκες Keras, tensorflow και το matplotlib στην πλατφόρμα Google Colab Research.

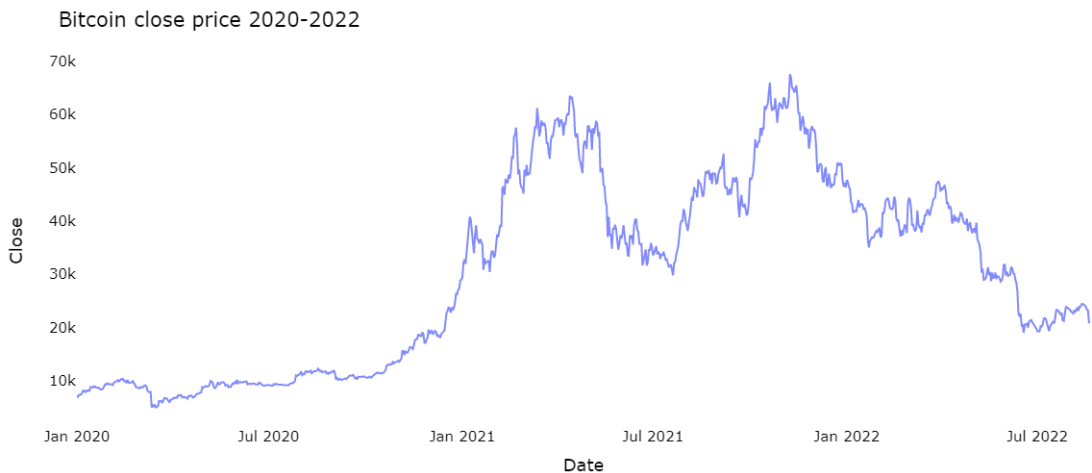
Τέλος, υπολογίζονται μετρήσεις αξιολόγησης απόδοσης για την σύγκριση των προβλέψεων που έγιναν και για την εξαγωγή συμπερασμάτων.

6.1.1 Συνολικά Δεδομένα


Τα συνολικά δεδομένα(τιμές) που χρησιμοποιήθηκαν αφορούν τα παρακάτω κρυπτονομίσματα:

- Bitcoin (BTC)
- Ethereum (ETH)

Τα δεδομένα (χρονοσειρές) συλλέχτηκαν μέσω του ιστότοπου Yahoo Finance και συγκεκριμένα από την επίσημη βάση δεδομένων που αποθηκεύει ιστορικά δεδομένα. Η τιμή που θα χρησιμοποιηθεί προκειμένου να γίνουν οι προβλέψεις και θα μας οδηγήσει στην αξιολόγηση των μοντέλων θα είναι εξ ορισμού, η τιμή κλεισίματος.



Εικόνα 6-1. Τιμή Κλεισίματος 2020-2022 (Bitcoin)



Εικόνα 6-2. Τιμή Κλεισίματος 2020-2022 (Ethereum)

Κάθε σύνολο δεδομένων χωρίζεται σε τρία μέρη, τα οποία χρησιμοποιούνται στο μοντέλο πρόβλεψης. Τα μέρη αυτά είναι τα εξής:


- σετ εκπαίδευσης, (training Set)
- και σετ επικύρωσης/δοκιμών. (Validation/Testing Set)

Training Set: Αφορά το σύνολο των δεδομένων που χρησιμοποιούμε για την εκπαίδευση του μοντέλου (βάρη και την μεροληψία(bias) για τα νευρωνικά δίκτυα. Το μοντέλο μαθαίνει από αυτά τα δεδομένα.

Validation Set: Είναι το δείγμα δεδομένων που χρησιμοποιείται για να παρέχει μια αξιολόγηση της προσαρμογής του μοντέλου στο σύνολο δεδομένων εκπαίδευσης κατά τον συντονισμό των υπερπαραμέτρων του μοντέλου. Χρησιμοποιούμε αυτά τα

δεδομένα για να βελτιώσουμε τις υπερπαραμέτρους του μοντέλου. Συνεπώς το μοντέλο βλέπει περιστασιακά αυτά τα δεδομένα, αλλά ποτέ δεν «μαθαίνει» από αυτά. Χρησιμοποιούμε τα αποτελέσματα από το σύνολο επικύρωσης και ενημερώνουμε τις υπερπαραμέτρους του μοντέλου.

Testing Set: Είναι το δείγμα δεδομένων που χρησιμοποιείται για την αξιολόγηση του τελικού μοντέλου που προσαρμόστηκε στο σύνολο δεδομένων εκπαίδευσης. Περιέχει δείγματα δεδομένων σε διάφορες κατηγορίες που θα συναντήσει το μοντέλο όταν χρησιμοποιηθεί στον πραγματικό κόσμο.



Εικόνα 6-3. Καταμερισμός Δεδομένων Χρονοσειρών

Τα συνολικά δεδομένα του BTC και του ETH που χρησιμοποιήθηκαν στην μελέτη μας διαμερίστηκαν ως εξής:

Χρησιμοποιήθηκαν ημερήσια δεδομένα από 01/01/2020 έως 20/08/2022.

- Training Set : 01/01/2020 έως 30/06/2021
- Validation Set: 01/7/2021 έως 11/11/2021
- Test set: 12/11/2021 έως 20/08/2022



Εικόνα 6-4. Training and Validation Set (Bitcoin)



Εικόνα 6-5. Training and Validation Set (Ethereum)



Εικόνα 6-6. Training and Test Set (Bitcoin)



Εικόνα 6-7. Training and Test Set (Ethereum)

6.1.2 Μεθοδολογία Έρευνας

Στη μελέτη αυτής της εργασίας, προκειμένου να προβλεφθούν οι τιμές των παραπάνω δύο χρονοσειρών, χρησιμοποιήθηκαν δύο τύποι τεχνητών νευρωνικών δικτύων. Τα μοντέλα που χρησιμοποιούνται είναι:

- Μοντέλο LSTM (ένα επίπεδο LSTM, ένα κρυφό στρώμα και ένα στρώμα εξόδου με 1 νευρώνα)
- Βαθύ νευρωνικό δίκτυο DNN (τρία κρυφά επίπεδα και ένα επίπεδο εξόδου με 1 νευρώνα)

Οι παραπάνω τοπολογίες Νευρωνικών δικτύων είναι παράμετροι εφαρμογής στην παρούσα έρευνα, επομένως μέσω αλλαγών και δοκιμών πραγματοποιήθηκε η σύγκριση των δύο μοντέλων για διάφορες τοπολογίες.

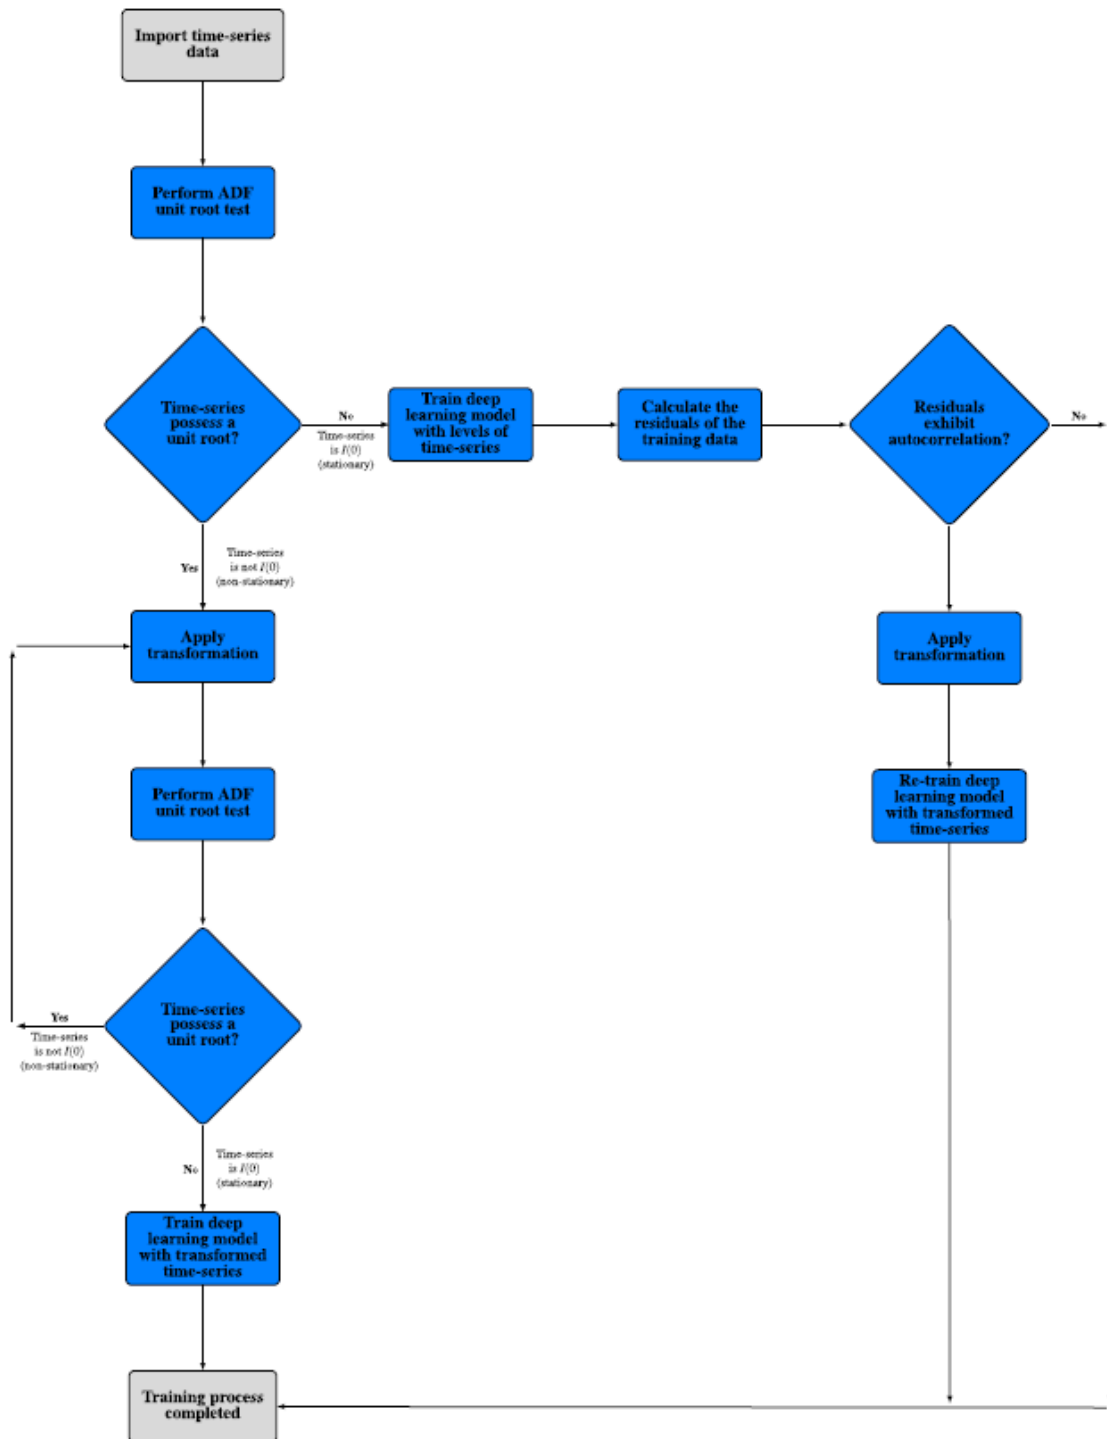
Όπως αναφέρθηκε παραπάνω σε αυτήν την εργασία βασική παράμετρο αποτελεί η τοπολογία του δικτύου. Συγκεκριμένα θα δοκιμάσουμε την απόδοση των δύο τύπων νευρωνικών δικτύων χρησιμοποιώντας διαφορετικές τοπολογίες και θα συγκρίνουμε αποτελέσματα.

Να σημειωθεί σε αυτό το σημείο ότι εάν παραβιαστεί η υπόθεση της μη αυτοσυσχέτισης των καταλοίπων, οι προβλέψεις μπορεί να μην είναι έγκυρες επειδή το μοντέλο δεν χρησιμοποιεί όλες τις πληροφορίες που εξάγονται κατά την εκπαίδευση του. Επομένως, η συσχέτιση μεταξύ των καταλοίπων δείχνει ότι το μοντέλο δεν ταίριαζε σωστά (fit) στα δεδομένα χρονοσειράς και ότι υπάρχουν αρκετές πληροφορίες που πρέπει να ληφθούν υπόψη (Livieris et al., 2020). Υπάρχουν δύο σημαντικά εργαλεία για την εύρεση της αυτοσυσχέτισης μεταξύ των καταλοίπων. Αυτές είναι οι συναρτήσεις αυτοσυσχέτισης ACF(AutoCorrelation Function), οι οποίες δίνονται από τη γραμμική συσχέτιση κάθε καταλοίπου με τα υπόλοιπα κατάλοιπα σε διαφορετικά Lags(et-1, et-2, και τα λοιπά) και δείχνουν την ισχύ-ένταση της χρονικής αυτοσυσχέτισης και το δεύτερο εργαλείο είναι το τεστ Ljung-Box Q για αυτοσυσχέτιση καταλοίπων, με τη μηδενική υπόθεση H_0 να υποδεικνύει ότι μια σειρά καταλοίπων δεν έχει αυτοσυσχέτιση για ένα σταθερό αριθμό Lags και το εναλλακτικό H_1 να δείχνει ότι ορισμένοι συντελεστές αυτοσυσχέτισης δεν είναι μηδέν.

Οι χρονοσειρές έχουν πολλές ιδιότητες που εμφανίζονται συχνά, όπως η αυτοσυσχέτιση, η μακροπρόθεσμη μνήμη και οι ιδιότητες αυτομοιότητας (fractal). Το μειονέκτημα των τιμών χρονοσειρών είναι ότι ακολουθούν τυχαίες διαδρομές. Ο συντελεστής

αυτοσυσχέτισης ρ_k για $k > 1$ είναι στατιστικά σημαντικός για μεγάλο αριθμό καθυστερήσεων L και ο συντελεστής αυτοσυσχέτισης πρώτης τάξης είναι ίσος με 1. Αυτές τις ονομάζουμε χρονικές σειρές μοναδιαίας ρίζας (unit root). Υπό αυτές τις συνθήκες, η μοντελοποίηση αυτών των χρονοσειρών είναι αναποτελεσματική επειδή τα κατάλοιπα δείχνουν αυτοσυσχέτιση και αμφισβητούν τη στατιστική σημασία. Για να μελετηθούν τέτοιες χρονοσειρές, πρέπει να είναι σταθερές-στάσιμες, κάτι που είναι σημαντικό για την ανάπτυξη αξιόπιστων μοντέλων πρόβλεψης. Η στασιμότητα διασφαλίζει ότι όλες οι στατιστικές ιδιότητες της τυχαίας διαδικασίας που δημιουργεί τις χρονοσειρές είναι σταθερές. Συνεπώς, οι στατικές διαδικασίες είναι πιο εύκολο να αναλυθούν, να μοντελοποιηθούν και να προβλεφθούν. Εάν η χρονική σειρά εμφανίζει μοναδιαία ρίζα $\rho_1=1$, αυτό σημαίνει ότι η πρώτη διαφορά $\Delta t = y_t - y_{t-1}$ πρέπει να χρησιμοποιηθεί για να διακρίνει ολόκληρη τη σειρά, με αυτόν τον τρόπο η σειρά γίνεται στατική.

Ωστόσο, όταν ασχολούμαστε με χρονοσειρές, μπορεί να παρατηρηθεί ότι πολλοί παράγοντες που συμβάλλουν στη μη σταθερότητα, όπως οι ρίζες μονάδας, οι οριζόντιες μετατοπίσεις, οι εποχιακές περίοδοι, οι ποικίλες διακυμάνσεις, μπορεί να επικαλύπτονται. Όπως αναφέρθηκε προηγουμένως, εάν η σειρά έχει μοναδιαία ρίζα, ο κατάλληλος μετασχηματισμός είναι να τη διαφοροποιήσουμε (differencing) με την πρώτη διαφορά για να την κάνουμε στάσιμη, αλλά αν παρουσιάζει ποικίλες διακυμάνσεις, ο μετασχηματισμός Box-Cox είναι η κατάλληλη λύση.



Εικόνα 6-8. Πλαίσιο Μοντέλου Πρόβλεψης (Διάγραμμα Ροής)

Το παραπάνω διάγραμμα ροής δείχνει το πλαίσιο που προτείνεται στην εργασία των Liveries et al (2020) για τη δημιουργία αξιόπιστων και αποτελεσματικών μοντέλων βαθιάς μάθησης.

Το παραπάνω πλαίσιο καλύπτει όλους τους τύπους σειρών, π.χ. μια σειρά μπορεί να είναι στάσιμη, αλλά το μοντέλο εμφανίζει αυτοσυσχέτιση στα κατάλοιπα, επομένως η σειρά πρέπει να αλλάξει-διαφοριστεί και το μοντέλο να επανεκπαιδευτεί.

Για την εφαρμογή μας, οι ακολουθίες που χρησιμοποιούμε είναι $I(1)$, που σημαίνει (με βάση το παραπάνω γράφημα) ότι πρέπει να διαφοριστούν μία φορά για να γίνουν στάσιμες και να ταιριάζουν στο εκπαιδευμένο μοντέλο. Τέλος, τονίζεται ότι όλα τα μοντέλα που εκπαιδεύτηκαν με τη διαφορική ακολουθία δεν εμφάνισαν αυτοσυσχέτιση στα κατάλοιπα, ενώ τα μοντέλα που εκπαιδεύτηκαν με την αρχική ακολουθία εμφάνισαν μικρή αυτοσυσχέτιση στα κατάλοιπα.

Επιπλέον, θα εξάγουμε και τα αντίστοιχα αποτελέσματα πρόβλεψης των μοντέλων χωρίς διαφορίση χρονοσειρών και θα συγκρίνουμε τα αποτελέσματα με και χωρίς διαφορήση χρονοσειρών.

Η αξιολόγηση των μοντέλων πρόβλεψης θα πραγματοποιηθεί με την χρήση των παρακάτω μετρικών απόδοσης ως προς την απόκλιση τους ή μη από τις πραγματικές τιμές.

- RMSE (Root Mean Square Error)
- MSE (Mean Square Error)
- MAE (Mean Absolute Error)
- VRS (Variance Regression Score)
- R^2 (Coefficient of determination)
- MAPE (Mean Absolute Percentage Error)

Έχοντας ένα μοντέλο πρόβλεψης που ταιριάζει με επιτυχία στα δεδομένα (fit), είναι σημαντικό να εκτιμηθεί εάν το μοντέλο είναι σε θέση να συλλάβει μοτίβα. Οι πιο συχνά χρησιμοποιούμενες μετρήσεις για την αξιολόγηση της απόδοσης παλινδρόμησης ενός προγνωστικού μοντέλου είναι το μέσο απόλυτο σφάλμα (MAE) και το ριζικό μέσο τετραγωνικό σφάλμα (RMSE). Ωστόσο, και οι δύο μετρήσεις αξιολόγησης καθορίζουν πόσο κοντά είναι η προβλεπόμενη τιμή στην πραγματική προβλεπόμενη τιμή και δεν αξιολογούν πόσο καλά ταιριάζει το μοντέλο στα δεδομένα χρονοσειρών.

Το μέσο τετραγωνικό σφάλμα (MSE) μετρά την απόκλιση του μέσου τετραγωνικού σφάλματος σε όλο το σύνολο πρόβλεψης. Λόγω του τετραγώνου, τα λάθη των αντίθετων πρόσημων δεν αλληλοεξουδετερώνονται. Ένα άλλο χαρακτηριστικό του MSE είναι ότι

«τιμωρεί» τα μεγάλα λάθη περισσότερο από τα μικρά. Ωστόσο, αξίζει να σημειωθεί ότι δεν είναι εύκολο να εξηγηθεί, αλλά θεωρείται ένας καλός τρόπος αναφοράς σφαλμάτων.

Η ρίζα του μέσου τετραγωνικού σφάλματος (RMSE) έχει τις ίδιες ιδιότητες με το MSE. Σε σύγκριση με το MSE, έχει το πλεονέκτημα ότι βρίσκεται στην ίδια κλίμακα με τα δεδομένα, άρα είναι πιο κατανοητό.

Το μέσο τετράγωνο σφάλμα (MAE) μετρά τη μέση απόλυτη απόκλιση της προβλεπόμενης τιμής από την πραγματική τιμή σε ολόκληρο το σύνολο των προβλέψεων. Λόγω της απόλυτης τιμής του, οι θετικές τιμές δεν ακυρώνουν τις αρνητικές τιμές. Επίσης, το σφάλμα είναι η ίδια κλίμακα με τα δεδομένα.

(MAPE) εκφράζεται ως ποσοστό και γίνεται εύκολα κατανοητό. Έχει τη δυνατότητα σύγκρισης δειγμάτων σε διαφορετικές κλίμακες δεδομένων λόγω ποσοστών.

Το R^2 είναι ουσιαστικά μια κανονικοποιημένη έκδοση του MSE, με κλίμακα 0 και 1.

Σύμφωνα με μία πρόσφατη μελέτη, τα νευρωνικά δίκτυα LSTM και DNN γνωρίζουμε ήδη ότι γενικά αποδίδουν καλύτερα στην πρόβλεψη χρονικών σειρών όταν οι σειρές πριν από την τροφοδότηση τους στο δίκτυο έχουν υποστεί διαφόριση (πρώτη διαφορά). Αυτή η τεχνική βελτιώνει σημαντικά την απόδοση των μοντέλων καθώς και την αξιοπιστία τους (Livieris et al., 2020)

Επομένως, δοκιμάζοντας τη νευρωνική τοπολογία (η οποία είναι παράμετρος της εφαρμογής μας), προσδιορίζουμε ποιο από τα δύο μοντέλα και ποια τοπολογία πέτυχε την καλύτερη πρόβλεψη για καθεμία από τις δύο χρονοσειρές που εξετάστηκαν. Ταυτόχρονα, συγκρίνονται τα αποτελέσματα πρόβλεψης με και χωρίς διαφόριση χρονοσειρών και επιβεβαιώνεται ότι η διαφόριση χρονοσειρών έχει καλύτερη απόδοση (λιγότερο σφάλμα) από το μοντέλο.

Αξίζει να αναφέρουμε ότι οι κλασικές μέθοδοι πρόβλεψης χρονοσειρών όπως το μοντέλο Autoregressive Integrated Moving Average (ARIMA) εφαρμόζεται κατά καιρούς σε προβλέψεις τιμών κρυπτονομισμάτων. Ωστόσο, αυτά τα μοντέλα δεν μπορούν να βρουν τα μη γραμμικά μοτίβα πολύ περίπλοκων προβλημάτων πρόβλεψης, σε αντίθεση με τους αλγόριθμους βαθιάς μάθησης, οι οποίοι έχουν επιτύχει καλύτερη απόδοση στην πρόβλεψη προβλημάτων χρονοσειρών (Livieris et al., 2020).

Η πρόβλεψη τιμής κρυπτονομισμάτων είναι εγγενώς ένα πολύ περίπλοκο και μη γραμμικό πρόβλημα, καθώς οι τιμές τους έχουν πολύ ασταθή και απρόβλεπτη συμπεριφορά με την πάροδο του χρόνου, γεγονός που καθιστά τις ακριβείς προβλέψεις τιμών πολύ δύσκολες. Οι αλγόριθμοι Deep Learning (DL) είναι ισχυροί αλγόριθμοι μηχανικής μάθησης που έχουν σχεδιαστεί για την επίλυση μη γραμμικών και πολύπλοκων προβλημάτων που συχνά χρησιμοποιούν μεγάλες ποσότητες δεδομένων για τη βελτίωση της αποτελεσματικότητας των μοντέλων πρόβλεψης (Pintelas, 2020). Επομένως, οι τεχνικές βαθιάς μάθησης μπορεί να είναι μια κατάλληλη προσέγγιση σε αυτό το πρόβλημα, ειδικά οι τεχνικές που διαφοροποιούν τις χρονοσειρές πριν τις τροφοδοτήσουν στο μοντέλο, με αποτέλεσμα καλύτερη απόδοση και πιο αξιόπιστη πρόβλεψη (Pintelas, 2020).

6.2 Παρουσίαση Αποτελεσμάτων

Στην παρούσα εργασία μελετήθηκαν τα ημερήσια δεδομένα δύο χρονοσειρών τα οποία προέρχονται από το Yahoo Finance. Οι επιλεγμένες χρονοσειρές είναι οι κάτωθι:

- Bitcoin
- Ethereum

Για την πρόβλεψη των μελλοντικών τιμών για αυτές τις χρονοσειρές, δύο τύποι νευρωνικών δικτύων (DNN και LSTM) χρησιμοποιούνται και εκπαιδεύονται με τη βελτιστοποίηση Adam. Η συγκεκριμένη μελέτη εξετάζει την αποτελεσματικότητα δύο μοντέλων σε προβλήματα πρόβλεψης χρονοσειρών, ακολουθώντας μια προσέγγιση που βασίζεται στη διαφορίση στις χρονοσειρές πριν τροφοδοτηθούν στο μοντέλο για να επιτύχει καλύτερη απόδοση, όπως καταδεικνύεται στην μελέτη "*A novel validation framework to enhance deep learning models in time-series forecasting*" που εκπονήθηκε από τους Livieris & Stavroyiannis & Pintelas τον Απρίλιο του 2020.

Ταυτόχρονα, πριν την εισαγωγή της χρονοσειράς στα μοντέλα, χωρίς προηγούμενη διαφοροποίηση (διαφορά πρώτης τάξης), δίνονται τα αντίστοιχα αποτελέσματα πρόβλεψης και τα αποτελέσματα συγκρίνονται ανάλογα.

Επίσης, προκειμένου να ερμηνευτούν τα αποτελέσματα των μοντέλων πρόβλεψης με βάση τις μετρικές απόδοσης, δημιουργήθηκαν αντίστοιχοι πίνακες κατάταξης που βαθμονομούν αριθμητικά κάθε μετρική (από την καλύτερη προς την χειρότερη απόδοση). Μέσω της βαθμονόμησης της κάθε μετρικής αποδόθηκε ανά Μοντέλο πρόβλεψης (για κάθε

τοπολογία, με ή χωρίς διαφόριση κατά την εκπαίδευση) η συνολική τους βαθμολογία (Total Score) και έπειτα η τελική κατάταξη (Rank) κάθε μοντέλου πρόβλεψης με βάση την μέθοδο της ταξινόμησης. Μέσω αυτού το συστήματος κατάταξης στο επόμενο κεφάλαιο παρουσιάζονται οι παρακάτω πίνακες:

- BTC (DNN AND LSTM - SCORE CARD)
- ETH (DNN AND LSTM - SCORE CARD)
- BTC + ETH (DNN AND LSTM - SCORE CARD)

Η ιδέα της χρήσης ενός LSTM ως μοντέλου μάθησης στο πρόβλημα πρόβλεψης τιμών χρονοσειράς είναι ότι μπορεί να συλλάβει χρήσιμες εξαρτήσεις προτύπων για μεγάλες ή σύντομες ακολουθίες λόγω του ειδικού αρχιτεκτονικού σχεδιασμού του που βοηθά στην απόδοση πρόβλεψης .

Παρακάτω είναι τα μέρη του κώδικα που εμπλέκονται στον διαχωρισμό των δεδομένων σε σύνολα εκπαίδευσης, επικύρωσης και δοκιμών. Επίσης εισάγονται τα μοντέλα πρόβλεψης και οι ερευνητικές παράμετροι των LSTM και DNN, δηλαδή η τοπολογία και τέλος δίνεται ο κώδικας υπολογισμού των μετρήσεων αξιολόγησης της έρευνας.

```
1 # download data and import to pd df
2 masterData = yf.download('BTC-USD', start='2020-01-01', end='2022-08-20')
3
4 # keep only close price - drop OHLV
5 data = masterData[['Close']]
6
7 # reset index
8 data = data.reset_index(drop=True)
9 print(data.tail(5))
10 print("Shape of 'close' dataframe:", data.shape)

1 # split train / test sets
2 training_size = int(len(closedf)*0.70)
3 test_size = len(closedf)-training_size
4
5 train_data,test_data=closedf[0:training_size,:],closedf[training_size:len(closedf),:1]
6
7 print("train_data: ", train_data.shape)
8 print("test_data: ", test_data.shape)
```

Εικόνα 6-9. Παράμετροι Διαχωρισμού Δεδομένων

```
1 model=keras.Sequential()
2 model.add(layers.LSTM(64,activation="relu"))
3 model.add(layers.Dense(32, activation='relu'))
4 model.add(layers.Dense(1, activation='linear'))
5 model.compile(loss="mean_squared_error",optimizer="adam")
```

```
1 history = model.fit(X_train,y_train,validation_data=(X_test,y_test),epochs=100,batch_size=64,verbose=1)
2 model.summary()
```

Εικόνα 6-10. Παράμετροι LSTM

```
1 model=keras.Sequential()
2 model.add(layers.Dense(150,activation="relu"))
3 model.add(layers.Dense(50, activation='relu'))
4 model.add(layers.Dense(18, activation='relu'))
5 model.add(layers.Dense(1, activation='linear'))
6 model.compile(loss="mean_squared_error",optimizer="adam")
```

```
1 history = model.fit(X_train,y_train,validation_data=(X_test,y_test),epochs=100,batch_size=64,verbose=1)
2 model.summary()
```

Εικόνα 6-11. Παράμετροι DNN

```
7 print("-----")
8 print("Test data RMSE: ", math.sqrt(mean_squared_error(original_ytest,test_predict)))
9 print("Test data MSE: ", mean_squared_error(original_ytest,test_predict))
10 print("Test data MAE: ", mean_absolute_error(original_ytest,test_predict,sample_weight=None))
11 print("Test data explained variance regression score:",
12       explained_variance_score(original_ytest, test_predict))
13 print("Test data R2 score:", r2_score(original_ytest, test_predict))
14 def mape(original_ytest, test_predict):
15     original_ytest, test_predict = np.array(original_ytest), np.array(test_predict)
16     return np.mean(np.abs((original_ytest - test_predict) / original_ytest))
17 print("Test Mape score:",mape(original_ytest, test_predict))
```

Εικόνα 6-12. Κώδικας Υπολογισμού Μετρήσεων

6.2.1 Τεχνητό Νευρωνικό Δίκτυο (DNN)

Στους παρακάτω πίνακες (DNN Metrics (Bitcoin) κ' DNN Metrics (Ethereum)) παρουσιάζονται οι μετρικές αξιολόγησης του μοντέλου πρόβλεψης DNN για τους τύπους τοπολογιών που χρησιμοποιήθηκαν κατά την εφαρμογή της έρευνας. Συγκεκριμένα για κάθε τοπολογία έχουν υπολογιστεί οι μετρικές με διάφοριση των χρονοσειρών (with Diff) και χωρίς διάφοριση. Τέλος, οι τιμές των κελιών των πινάκων αναπαρίσταται με ράβδους δεδομένων προκειμένου να είναι οπτικά αισθητές οι διαφορές των τιμών.

BTC (Neurons/ DNN Topology)	RMSE	MSE	MAE	VRS	R ²	MAPE
DNN 150-50-18-1	1491,745	2225302,694	1098,594	0,986	0,982	0,032
DNN 150-50-18-1 (with Diff)	1420,709	2119335,899	1046,280	0,991	0,987	0,029
DNN 100-65-24-1	1361,640	1854062,748	1002,660	0,985	0,985	0,028
DNN 100-65-24-1 (with Diff)	1296,800	1765774,046	954,915	0,990	0,990	0,025
DNN 82-45-10-1	1399,532	1958690,239	1022,214	0,986	0,984	0,029
DNN 82-45-10-1 (with Diff)	1332,888	1865419,275	973,538	0,991	0,989	0,026
DNN 40-18-10-1	1445,191	2088577,768	1095,010	0,985	0,983	0,030
DNN 40-18-10-1 (with Diff)	1376,373	1989121,684	1042,867	0,990	0,988	0,027

Πίνακας 6-1. DNN Metrics (Bitcoin)

ETH (Neurons/ DNN Topology)	RMSE	MSE	MAE	VRS	R ²	MAPE
DNN 150-50-18-1	120,304	14473,072	91,597	0,985	0,985	0,037
DNN 150-50-18-1 (with Diff)	114,575	13783,878	87,235	0,990	0,988	0,034
DNN 100-65-24-1	120,304	14473,072	91,597	0,985	0,985	0,037
DNN 100-65-24-1 (with Diff)	114,575	13783,878	87,235	0,990	0,989	0,034
DNN 82-45-10-1	119,758	14341,924	91,052	0,986	0,985	0,038
DNN 82-45-10-1 (with Diff)	114,055	13658,975	86,716	0,991	0,990	0,034
DNN 40-18-10-1	119,053	14173,582	90,105	0,986	0,985	0,037
DNN 40-18-10-1 (with Diff)	113,384	13498,649	85,815	0,990	0,991	0,033

Πίνακας 6-2. DNN Metrics (Ethereum)

Συμπληρωματικά, τα αποτελέσματα μέσω γραφικών παραστάσεων για το μοντέλο πρόβλεψη LSTM, ανά τοπολογία, ανά set δεδομένων, με ή χωρίς Διαφόριση παρουσιάζονται στο παράρτημα Α.

6.2.2 LSTM (Long-Sort Term Memory Network)

Στους παρακάτω πίνακες (LSTM Metrics (Bitcoin) κ' LSTM Metrics (Ethereum)) παρουσιάζονται αντιστοίχως οι μετρικές αξιολόγησης του μοντέλου πρόβλεψης LSTM για τους τύπους τοπολογιών που χρησιμοποιήθηκαν κατά την εφαρμογή της έρευνας. Συγκεκριμένα για κάθε τοπολογία έχουν υπολογιστεί οι μετρικές με διάφοριση των χρονοσειρών (with Diff) και χωρίς διαφόριση. Τέλος, οι τιμές των κελιών των πινάκων αναπαρίσταται με ράβδους δεδομένων προκειμένου να είναι οπτικά αισθητές οι διαφορές των τιμών.

BTC (Neurons/ LSTM Topology)	RMSE	MSE	MAE	VRS	R ²	MAPE
160-85-1	1487,353	2212219,171	1103,235	0,985	0,982	0,031
160-85-1 (with Diff)	1416,527	2106875,401	1050,700	0,990	0,987	0,029
120-60-1	1532,277	2347871,527	1163,321	0,982	0,981	0,033
120-60-1 (with Diff)	1459,311	2236068,121	1107,925	0,987	0,986	0,030
64-32-1	2128,922	4532309,656	1711,278	0,982	0,964	0,050
64-32-1 (with Diff)	2027,545	4316485,387	1629,789	0,987	0,969	0,046
25-15-1	1671,540	2794046,677	1259,172	0,982	0,978	0,037
25-15-1 (with Diff)	1591,943	2660996,836	1199,212	0,987	0,983	0,033

Πίνακας 6-3. LSTM Metrics (Bitcoin)

ETH (Neurons/ LSTM Topology)	RMSE	MSE	MAE	VRS	R ²	MAPE
160-85-1	130,972	17153,664	100,933	0,982	0,982	0,041
160-85-1 (with Diff)	124,735	16336,823	96,127	0,987	0,987	0,037
120-60-1	187,874	35296,599	148,168	0,981	0,963	0,062
120-60-1 (with Diff)	178,928	33615,808	141,112	0,986	0,968	0,056
64-32-1	144,839	20978,383	110,298	0,982	0,978	0,047
64-32-1 (with Diff)	137,942	19979,413	105,045	0,987	0,983	0,042
25-15-1	161,480	26075,825	123,110	0,979	0,973	0,053
25-15-1 (with Diff)	153,791	24834,119	117,248	0,984	0,978	0,048

Πίνακας 6-4. LSTM Metrics (Ethereum)

Συμπληρωματικά, τα αποτελέσματα μέσω γραφικών παραστάσεων για το μοντέλο πρόβλεψης DNN ανά τοπολογία, ανά set δεδομένων, με ή χωρίς Διαφόριση παρουσιάζονται στο παράρτημα Β.

6.2.3 Συνολικά Αποτελέσματα (Σύστημα Κατάταξης)

Στους παρακάτω πίνακες παρουσιάζονται τα συνολικά αποτελέσματα των μετρικών αξιολόγησης με βάση το σύστημα βαθμονόμησης/κατάταξης που εφαρμόστηκε και αναφέρεται στο Κεφάλαιο 6.1.2.

6.2.3.1 Bitcoin (DNN AND LSTM SCORE CARD)

Στο παρακάτω πίνακα παρουσιάζονται τα αποτελέσματα του συστήματος Κατάταξης για την χρονοσειρά του Bitcoin. Σύμφωνα με τα αποτελέσματα το μοντέλο πρόβλεψης LSTM είναι το επικρατέστερο (Rank=1) και κατά σειρά στις επόμενες δύο θέσεις αναφέρονται τα μοντέλα πρόβλεψης DNN. Με βάση τα αποτελέσματα επιβεβαιώνεται ότι τα μοντέλα πρόβλεψης βελτιώνουν την αποτελεσματικότητα – αξιοπιστία τους όταν οι χρονοσειρές διαφοριστούν (with diff) πριν την εισαγωγή τους σε αυτά.

BTC (DNN AND LSTM - SCORE CARD)	RMSE	MSE	MAE	VRS	R ²	MAPE	Total Score	Rank
LSTM 160-85-1 (with Diff)	1	1	1	1	1	1	6	1
DNN 100-65-24-1 (with Diff)	1	1	1	3	1	1	8	2
DNN 82-45-10-1 (with Diff)	2	3	2	1	2	2	12	3
LSTM 120-60-1 (with Diff)	2	3	3	3	2	2	15	4
LSTM 160-85-1	3	2	2	5	4	3	19	5
DNN 40-18-10-1 (with Diff)	4	5	5	4	3	3	24	6
DNN 100-65-24-1	3	2	3	7	5	4	24	6
LSTM 25-15-1 (with Diff)	5	5	5	4	3	5	27	7
LSTM 120-60-1	4	4	4	7	5	4	28	8
DNN 150-50-18-1 (with Diff)	6	7	6	2	4	5	30	9
DNN 82-45-10-1	5	4	4	5	6	6	30	9
LSTM 64-32-1 (with Diff)	7	7	7	2	7	7	37	10
LSTM 25-15-1	6	6	6	8	6	6	38	11
DNN 40-18-10-1	7	6	7	8	7	7	42	12
LSTM 64-32-1	8	8	8	6	8	8	46	13
DNN 150-50-18-1	8	8	8	6	8	8	46	13

Πίνακας 6-5. Bitcoin (DNN AND LSTM SCORE CARD)

6.2.3.2 Ethereum (DNN AND LSTM SCORE CARD)

Στο παρακάτω πίνακα παρουσιάζονται τα αποτελέσματα του συστήματος Κατάταξης για την χρονοσειρά του Ethereum. Σύμφωνα με τα αποτελέσματα δύο μοντέλα πρόβλεψης LSTM και DNN είναι τα επικρατέστερα (Rank=1) και κατά σειρά στις επόμενες δύο θέσεις κατάταξης αναφέρονται τα μοντέλα πρόβλεψης DNN και LSTM. Αξίζει να σημειώσουμε ότι και σε αυτήν την περίπτωση επιβεβαιώνεται ότι τα μοντέλα πρόβλεψης βελτιώνουν την αποτελεσματικότητα – αξιοπιστία τους όταν οι χρονοσειρές διαφοριστούν (with diff) πριν την εισαγωγή τους σε αυτά.

ETH (DNN AND LSTM - SCORE CARD)	RMSE	MSE	MAE	VRS	R ²	MAPE	Total Score	Rank
LSTM 160-85-1 (with Diff)	1	1	1	2	1	1	7	1
DNN 40-18-10-1 (with Diff)	1	1	1	2	1	1	7	1
DNN 82-45-10-1 (with Diff)	2	2	2	1	2	4	13	2
LSTM 64-32-1 (with Diff)	3	3	3	1	2	3	15	3
LSTM 160-85-1	2	2	2	6	3	2	17	4
DNN 150-50-18-1 (with Diff)	3	3	3	3	4	3	19	5
DNN 100-65-24-1 (with Diff)	4	4	4	4	3	2	21	6
LSTM 64-32-1	4	4	4	5	4	4	25	7
LSTM 25-15-1 (with Diff)	5	5	5	4	5	5	29	8
DNN 40-18-10-1	5	5	5	6	5	5	31	9
DNN 82-45-10-1	6	6	6	5	6	8	37	10
LSTM 25-15-1	6	6	6	8	6	6	38	11
LSTM 120-60-1 (with Diff)	7	7	7	3	7	7	38	11
DNN 150-50-18-1	7	7	7	7	7	6	41	12
LSTM 120-60-1	8	8	8	7	8	8	47	13
DNN 100-65-24-1	8	8	8	8	8	7	47	13

Πίνακας 6-6. Ethereum (DNN AND LSTM SCORE CARD)

6.2.3.3 Bitcoin and Ethereum (DNN AND LSTM - SCORE CARD)

Παρακάτω παρουσιάζονται τα συνολικά αποτελέσματα του συστήματος αξιολόγησης για το σύνολο των μοντέλων πρόβλεψης (DNN ή LSTM), καθώς και για το σύνολο των Χρονοσειρών (Bitcoin και Ethereum). Μέσω αυτής της ταυτόχρονης Συνολικής αξιολόγησης προκύπτει ότι την πρώτη σειρά κατάταξης (Rank) την κατέχει το νευρωνικό δίκτυο LSTM και έπειτα ακολουθούν με ισοβαθμία στην δεύτερη θέση τα νευρωνικά δίκτυα DNN και LSTM με μικρότερο βαθμό αξιολόγησης. Αξίζει επίσης να αναφερθεί ότι οι πρώτες οκτώ θέσεις κατάταξης αφορούν τύπους νευρωνικών δικτύων στα οποία οι χρονοσειρές έχουν διαφοριστεί πριν την εισαγωγή τους σε αυτά, γεγονός που επιβεβαιώνει ανάλογα την βιβλιογραφία.

BTC + ETH (DNN AND LSTM - SCORE CARD)	RMSE	MSE	MAE	VRS	R ²	MAPE	Total Score	Rank
LSTM 160-85-1 (with Diff)	1	1	1	1	1	1	6	1
LSTM 160-85-1 (with Diff)	1	1	1	2	1	1	7	2
DNN 40-18-10-1 (with Diff)	1	1	1	2	1	1	7	2
DNN 100-65-24-1 (with Diff)	1	1	1	3	1	1	8	3
DNN 82-45-10-1 (with Diff)	2	3	2	1	2	2	12	4
DNN 82-45-10-1 (with Diff)	2	2	2	1	2	4	13	5
LSTM 120-60-1 (with Diff)	2	3	3	3	2	2	15	6
LSTM 64-32-1 (with Diff)	3	3	3	1	2	3	15	6
LSTM 160-85-1	2		2	6	3	2	17	7
LSTM 160-85-1	3	2	2	5	4	3	19	8
DNN 150-50-18-1 (with Diff)	3	3	3	3	4	3	19	8
DNN 100-65-24-1 (with Diff)	4	4	4	4	3	2	21	9
DNN 40-18-10-1 (with Diff)	4	5	5	4	3	3	24	10
DNN 100-65-24-1	3	2	3	7	5	4	24	10
LSTM 64-32-1	4	4	4	5	4	4	25	11
LSTM 25-15-1 (with Diff)	5	5	5	4	3	5	27	12
LSTM 120-60-1	4	4	4	7	5	4	28	13
LSTM 25-15-1 (with Diff)	5	5	5	4	5	5	29	14
DNN 150-50-18-1 (with Diff)	6	7	6	2	4	5	30	15
DNN 82-45-10-1	5	4	4	5	6	6	30	15
DNN 40-18-10-1	5	5	5	6	5	5	31	16
LSTM 64-32-1 (with Diff)	7	7	7	2	7	7	37	17
DNN 82-45-10-1	6	6	6	5	6	8	37	18
LSTM 25-15-1	6	6	6	8	6	6	38	19
LSTM 25-15-1	6	6	6	8	6	6	38	19
LSTM 120-60-1 (with Diff)	7	7	7	3	7	7	38	19
DNN 150-50-18-1	7	7	7	7	7	6	41	20
DNN 40-18-10-1	7	6	7	8	7	7	42	21
LSTM 64-32-1	8	8	8	6	8	8	46	22
DNN 150-50-18-1	8	8	8	6	8	8	46	22
LSTM 120-60-1	8	8	8	7	8	8	47	23
DNN 100-65-24-1	8	8	8	8	8	7	47	23

Πίνακας 6-7. Bitcoin and Ethereum (DNN AND LSTM - SCORE CARD)

6.3 Συμπεράσματα

Από τα αποτελέσματα που περιγράφονται λεπτομερώς στους παραπάνω πίνακες για τα δύο κρυπτονομίσματα εξάγουμε ορισμένα συμπεράσματα σχετικά με τη χρήση των δύο τύπων νευρωνικών δικτύων (DNN και LSTM) για την πρόβλεψη των μελλοντικών τους τιμών, αλλά και ποιος τύπος Νευρωνικού δικτύου έδειξε την καλύτερη απόδοση για κάθε πρόβλημα, δηλαδή την πρόβλεψη με το μικρότερο σφάλμα. Επομένως, από τους παραπάνω πίνακες εξάγονται τα ακόλουθα συμπεράσματα:

- Όσον αφορά τις προβλέψεις τιμών Bitcoin, σημειώνουμε από τα αποτελέσματα αυτής της μελέτης ότι στις περισσότερες δοκιμές (τοπολογίες) που πραγματοποιήθηκαν, οι προβλέψεις που χρησιμοποιούν το νευρωνικό δίκτυο LSTM εμφάνισαν μικρότερα σφάλματα σε σύγκριση με τις προβλέψεις που χρησιμοποιούν DNN, με εξαίρεση ορισμένες τοπολογίες. Επομένως, χρησιμοποιώντας το νευρωνικό δίκτυο LSTM, η πρόβλεψη τιμής Bitcoin γίνεται πιο ακριβής.
- Για τις προβλέψεις τιμών Ethereum, παρατηρήσαμε ότι οι προβλέψεις που έγιναν χρησιμοποιώντας το νευρωνικό δίκτυο LSTM εμφάνισαν μικρότερα σφάλματα από τις προβλέψεις που χρησιμοποιούν DNN. Έτσι, η πρόβλεψη τιμής Ethereum είναι πιο ακριβής χρησιμοποιώντας το νευρωνικό δίκτυο LSTM.
- Όσον αφορά τα αποτελέσματα που προέκυψαν στις μελλοντικές προβλέψεις τιμών και για τις δύο χρονοσειρές, παρατηρούμε ότι τόσο για τα νευρωνικά δίκτυα LSTM όσο και για τα νευρωνικά δίκτυα DNN, οι προβλέψεις είναι πιο ακριβείς όταν η σειρά πριν από το μοντέλο εισόδου έχει διαφοριστεί, γεγονός που επιβεβαιώνεται ανάλογα στην βιβλιογραφία (Livieris, 2020)
- Επίσης από την ταυτόχρονη Συνολική αξιολόγηση των χρονοσειρών BTC και ETH όπως προκύπτει από το πίνακα που εφαρμόστηκε το σύστημα Κατάταξης στις μετρικές ανά τύπο μοντέλων πρόβλεψης, διαπιστώνουμε ότι την πρώτη θέση (Rank) την κατέχει το νευρωνικό δίκτυο LSTM και έπειτα ακολουθούν με ισοβαθμία στην δεύτερη θέση τα νευρωνικά δίκτυα DNN και LSTM με μικρότερο βαθμό αξιολόγησης. Αξίζει επίσης να αναφερθεί ότι οι πρώτες οκτώ θέσεις κατάταξης αφορούν τύπους νευρωνικών δικτύων στα οποία οι χρονοσειρές έχουν διαφοριστεί πριν την εισαγωγή τους σε αυτά, γεγονός που επιβεβαιώνει ανάλογα την βιβλιογραφία.

Συμπερασματικά, σημειώνουμε ότι ενώ γενικά τα νευρωνικά δίκτυα LSTM φαίνεται να παρουσιάζουν καλύτερη απόδοση (μικρότερο σφάλμα πρόβλεψης) ή βρίσκονται στις πρώτες θέσεις κατάταξης στις περισσότερες περιπτώσεις, η διαφορά στην πρόβλεψη μεταξύ

DNN και LSTM είναι μικρή. Όσον αφορά την πρόβλεψη με ή χωρίς διαφόριση χρονοσειρών, παρατηρούμε ότι η πρόβλεψη είναι πιο ακριβής όταν η χρονοσειρά διαφορίζεται. Η καλύτερη απόδοση οφείλεται στη διαφόριση της χρονοσειράς πριν τροφοδοτηθεί και στους δύο τύπους νευρωνικών δικτύων, γεγονός που απλοποιεί το πρόβλημα και δίνει πιο ακριβείς προβλέψεις και πιο αξιόπιστα αποτελέσματα από τα αντίστοιχα αποτελέσματα χωρίς πρώτη διαφόριση, γεγονός που επίσης επιβεβαιώθηκε από αντίστοιχες μελέτες.

Σε αυτή την εργασία, παρουσιάζεται μια προσέγγιση με βάση την βιβλιογραφία για την ανάπτυξη αποτελεσματικών και αξιόπιστων μοντέλων πρόβλεψης βαθιάς μάθησης. Η κύρια καινοτομία του προτεινόμενου πλαισίου που αναφέρετε ρητά στην έρευνα είναι ότι εγγυάται την αξιοπιστία πρόβλεψης των προβλέψεων που γίνονται από μοντέλα βαθιάς μάθησης, ανεξάρτητα από τα δεδομένα χρονοσειρών που χρησιμοποιούνται. Αυτό επιτυγχάνεται με την εφαρμογή μιας σειράς μετασχηματισμών που διασφαλίζουν ότι η χρονοσειρά ικανοποιεί τη σταθερότητα/στασιμότητα και είναι κατάλληλη για την προσαρμογή μοντέλων βαθιάς μάθησης. Επίσης παρέχονται πληροφορίες για την αποτελεσματικότητά και τα θεωρητικά πλεονεκτήματα του προτεινόμενου πλαισίου εκπαίδευσης χρονοσειρών (Livieris, 2020a, 2020b). Πιο συγκεκριμένα, πραγματοποιήσαμε μια σειρά από πειράματα στις χρονοσειρές BTC και Ethereum που δημιουργούν το μεγαλύτερο μέρος του ερευνητικού ενδιαφέροντος, δηλαδή τον τομέα των κρυπτονομισμάτων. Το πείραμά και η ανάλυση δείχνει ότι η προτεινόμενη μέθοδος βελτιώνει την απόδοση πρόβλεψης των μοντέλων βαθιάς μάθησης, όσον αφορά την ακρίβεια και την αξιοπιστία. Αυτό που δεν έχει διερευνηθεί ενδελεχώς είναι η πιθανότητα κάποιας μικρής απώλειας πληροφοριών λόγω της μη στασιμότητας των χρονοσειρών και της υλοποίησης του προτεινόμενου μετασχηματισμού.

Ολοκληρώνοντας την μελέτη, θα ήθελα να αναφέρω ότι η πρόβλεψη και η ανάλυση χρονοσειρών με μοντέλα πρόβλεψης νευρωνικών δικτύων θεωρούνται γενικά ως ένα από τα πιο απαιτητικά προβλήματα. Στη βιβλιογραφία, οι περισσότερες προσεγγίσεις που αφορούν προβλέψεις χρονοσειρών προσπαθούν να αξιοποιήσουν τη μηχανική μάθηση και τους αλγόριθμους βαθιάς μάθησης, με στόχο την καλύτερη απόδοση σε σύγκριση με τα υπάρχοντα ή τα προτεινόμενα πρότυπα, ωστόσο, δεν μπορούν να εγγραφούν με βεβαιότητα την ανάπτυξη αξιόπιστων μοντέλων πρόβλεψης. Επίσης, ανεξάρτητα από το πόσο προηγμένη είναι η τεχνολογία και οι τεχνικές πρόβλεψης, το μέλλον είναι ακόμα αβέβαιο

και θα πρέπει να λάβουμε τα αποτελέσματα αυτών των τεχνολογιών ως πρόσθετη συμβουλή για να λάβουμε ορισμένες αποφάσεις, είτε πρόκειται για αγορά είτε για πώληση ή οτιδήποτε άλλο μας αφορά και θα πρέπει πάντα να υπολογίζουμε ότι η πρόβλεψη αυτή δεν εμπεριέχει όλες τις παραμέτρους που μπορεί να υπάρχουν και μπορεί να κατανοήσει ένας άνθρωπος που παίρνει μια απόφαση για το μέλλον.

Βιβλιογραφία

Ακολουθούν οι βιβλιογραφικές αναφορές (πηγές) της Εργασίας.

Basegmez, E. (2014). *The Next Generation Neural Networks: Deep Learning and Spiking Neural Network*, Technische Universitat Munchen.

Bishop, C.M. (1995) *Neural Networks for Pattern Recognition*, Oxford University Press, Inc., New York, United States.

Camastra, F. & Vinciarelli, A. (2007). *Machine Learning for Audio, Image and Video Analysis: Theory and Applications*. Springer International Publishing, Switzerland.

Cao, C., Ma, L., & Xu, Y. (2012). “*Adaptive Control Theory and Applications*”, Journal of Control Science and Engineering, Vol. 2012, Article ID 827353, 2 pages, <https://doi.org/10.1155/2012/827353>.

Deng, L., & Liu, Y. (Eds.). (2018). *Deep Learning in Natural Language Processing*, Springer, Singapore, <https://doi.org/10.1007/978-981-10-5209-5>

Donahue, J, Jia, Y., Vinyals, O., Hoffman, J., Zhang, N., Tzeng, E., & Darrell, T. (2014) “*DeCAF: A Deep Convolutional Activation Feature for Generic Visual Recognition*”, Berkeley, CA, USA, P. 10.

Fawaz H.I, Forestier G, Weber J, Idoumghar L, Muller P. (2019), “*Deep learning for time series classification: a review*”, Data Mining and Knowledge Discovery (2019) 33:917–963 <https://doi.org/10.1007/s10618-019-00619-1>.

Fischer T, Krauss C (2018) Deep learning with long short-term memory networks for financial market predictions, Eur J OperRes 270(2), P. 654–669

Gluck, M. A. & Myers, C. E. (2000). *Gateway to Memory: An Introduction to Neural Network Models of the Hippocampus and Learning*, MIT Press, Cambridge, 2000.

Gudi, A. (2014). *Recognizing Semantic Features in Faces using Deep Learning*, Master’s Thesis, Informatics Institute, Graduate Schools of Science, University of Amsterdam.

Hamed, M. G., Gianazza, D., Serrurier, M., & Durand, N. (2013). “*Statistical prediction of aircraft trajectory: regression methods vs point-mass model*”, In Proceedings of USA/Europe Air Traffic Management Research and Development Seminar, 2013, P. 11, <https://hal-enac.archives-ouvertes.fr/hal-00911709>.

Kingma D., Ba J.L. (2015) “*Adam: A Method For Stochastic Optimization*”, 3rd International Conference for Learning Representations, San Diego.

Lampropoulos, A. S. & Tsihrantzis, G. A. (2015). *Machine Learning Paradigms, Applications in Recommender Systems*. Intelligent Systems Reference Library Vol. 92, Springer International Publishing, Switzerland.

- LeCun, Y., Boser, B. E., Denker, J. S., Henderson, D., Howard, R. E., Howard, W. E., & Jackel, L. D. (1990). *Advances in Neural Information Processing Systems. Handwritten Digit Recognition with a Back-Propagation Network*, Morgan Kaufmann Publishers Inc. San Francisco, CA, United States, P. 396-404.
- LeCun, Y., Bengio, B., & Hinton, G. (2015). “Deep learning”, *Nature*, Vol. 521, pp. 436-444, <https://doi.org/10.1038/nature14539>.
- Livieris, I.E., Pintelas, P. (2008) “A survey on algorithms for training artificial neural networks”, Technical Report TR08-01, Department of Mathematics, University of Patras.
- Livieris I.E. (2019) “Forecasting economy-related data utilizing constrained recurrent neural networks”, Algorithms, Department of Computer & Informatics Engineering, Technological Educational Institute of Western Greece, Patras, P. 12.
- Livieris, I.E., Kotsilieris, T., Stavroyiannis, S. & Pintelas, P. (2019), “Forecasting stock price index movement using a constrained deep neural network training algorithm”, Department of Mathematics, University of Patras.
- Livieris, I.E., Stavroyiannis, S., Pintelas, E., Pintelas, P. (2020) “A novel validation framework to enhance deep learning models in time-series forecasting”, *Neural Computing and Applications*, Springer-Verlag, London, P. 19.
- Livieris, I.E., Pintelas, E., Pintelas, P. (2020) “A CNN-LSTM model for gold price time-series forecasting”, Springer-Verlag London Ltd., part of Springer Nature 2020, <https://doi.org/10.1007/s00521-020-04867-x>.
- Liu S, Zhang C, Ma J (2017) *CNN-LSTM neural network model for quantitative strategy analysis in stock markets*. In: *International conference on neural information processing*, Springer, Berlin, pp 198–206
- Matthew, D., Fergus, R. (2014) “Visualizing and Understanding Convolutional Networks”, Dept. of Computer Science, New York University, USA, PP. 818-833.
- Mitchell, T. M. (2006). “*The Discipline of Machine Learning*”, School of Computer Science Carnegie Mellon University, Pittsburgh, P. 12.
- Nilsson, N. J. (1998). *Introduction to Machine Learning. An early draft of a proposed textbook*, Stanford University, Stanford.
- Pintelas, E., Kotsilieris, T., Livieris, I.E., Stavroyiannis, S., & Pintelas, P. (2020) “Investigating the Problem of Cryptocurrency Price Prediction: A Deep Learning Approach”, *Artificial Intelligence Applications and Innovations*, Springer, Greece, P. 99-110.
- Pintelas E. (2020) *Deep Neural Networks For Bitcoin Price Prediction*, University of Patras.
- Razavian, A.S., Azizpour, H., Sullivan, J., Carlsson, S. (2014), “CNN Features off-the-shelf: an Astounding Baseline for Recognition” CVAP, KTH (Royal Institute of Technology), Stockholm, Sweden, 2014, <https://doi.org/10.48550/arXiv.1403.6382>.

Rojas, R. (1996). *Neural Networks A Systematic Introduction*, Springer-Verlag, Berlin, 1996.

Russell, S. J. & Norvig P. (2010). *Artificial Intelligence: A Modern Approach*, 3rd Edition, Pearson Education, Inc, New Jersey.

Tzanis, G., Katakis I., Partalas I., Vlahavas I. (2006), “*Modern Applications of Machine learning*”, Department of Informatics, Aristotle University, Thessaloniki, p. 10.

Schapiro, R. (2008). “*Computer Science 511 Theoretical Machine Learning*”, Computer Science Department, Lecture #1, Princeton University, New Jersey.

Vincent, L. E., & Thome, N. (2019). “*Shape and time distortion loss for training deep time series forecasting models. In Advances in Neural Information Processing Systems*”, Paris, France (p. 13).

Witten, I. H., Frank, E., & Hall, M. A. (2011). *Data Mining, Practical Machine Learning Tools and Techniques*, 3rd Edition, Elsevier Inc., USA.

Zorbas, N., D. Zissis, K. Tserpes, and D. Anagnostopoulos. (2015). “*Predicting Object Trajectories from High-speed Streaming Data.*” In 2015 IEEE TrustCom/BigDataSE/ISPA, Helsinki, Finland, PP. 229–234.

Αργυράκης, Π. (2001) *Νευρωνικά Δίκτυα και Εφαρμογές*, Ελληνικό Ανοικτό Πανεπιστήμιο, Πάτρα.

Ζησιμοπούλου, Π. (2019) *Βαθιά Μάθηση από Ιατρικές Εικόνες, Μεταπτυχιακή Διπλωματική Εργασία*, Πανεπιστήμιο Πατρών.

Κοτζοπαναγιώτου, Ε. (2019) *Χρήση Μεθόδων Μηχανικής Μάθησης για Πρόβλεψη Μελλοντικών Τιμών Χρονοσειρών*, Μεταπτυχιακή Εργασία, Πανεπιστήμιο Πατρών.

Κώνστα, Μ.Ε (2016) *Κρυπτογραφικά νομίσματα: τεχνικές αρχές και τρόπος λειτουργίας: η περίπτωση του Bitcoin*, μεταπτυχιακή Εργασία, Πανεπιστήμιο Πατρών.

Παρίσης, Η. (2019) *Πρόβλεψη Τιμών Χρονοσειρών με Χρήση Αλγορίθμων Μηχανικής Μάθησης*, Διπλωματική Εργασία, Ελληνικό Ανοικτό Πανεπιστήμιο, Πάτρα

“LEARN ALL ABOUT Blockchain & Crypto, Binance, Accessible:
<https://academy.binance.com/en> (visited on :17/7/2022)

Παράρτημα Α: Αποτελέσματα Deep Neural Network

Α) Γραφική παράσταση αποτελεσμάτων χρονοσειρών (Bitcoin)

Ι. Αποτελέσματα DNN με τοπολογία 40-18-10-1, χωρίς την χρήση της παραμέτρου Διαφόρισης.

Comparison between original close price vs predicted close price



Εικόνα 0-1. Training - Test Results (DNN 40-18-10-1) - χωρίς Διαφόριση

Comparison between original close price vs predicted close price



Εικόνα 0-2. Test results (40-18-10-1) - Χωρίς Διαφόριση

II. Αποτελέσματα DNN με τοπολογία 40-18-10-1, με την χρήση της παραμέτρου Διαφοράς.

Comparison between original close price vs predicted close price



Εικόνα 0-3. Training - Test Results (DNN 40-18-10-1) - με Διαφοράση

Comparison between original close price vs predicted close price



Εικόνα 0-4. Test Results (DNN 40-18-10-1) - με Διαφοράση

III. Αποτελέσματα DNN με τοπολογία 82-45-10-1, χωρίς την χρήση της παραμέτρου Διαφόρισης.

Comparison between original close price vs predicted close price



Εικόνα 0-5. Training - Test Results (DNN 82-45-10-1) - χωρίς Διαφόριση

Comparison between original close price vs predicted close price



Εικόνα 0-6. Test results (82-45-10-1) - Χωρίς Διαφόριση

IV. Αποτελέσματα DNN με τοπολογία 82-45-10-1, με την χρήση της παραμέτρου Διαφοράς.

Comparison between original close price vs predicted close price



Εικόνα 0-7. Training - Test Results (DNN 82-45-10-1) - με Διαφοράση

Comparison between original close price vs predicted close price



Εικόνα 0-8. Test Results (DNN 82-45-10-1) - με Διαφοράση

V. Αποτελέσματα DNN με τοπολογία 100-65-24-1, χωρίς την χρήση της παραμέτρου Διαφόρισης.

Comparison between original close price vs predicted close price



Εικόνα 0-9. Training - Test Results (DNN 100-65-24-1) - χωρίς Διαφόριση

Comparison between original close price vs predicted close price



Εικόνα 0-10. Test Results (DNN 100-65-24-1) - χωρίς Διαφόριση

VI. Αποτελέσματα DNN με τοπολογία 100-65-24-1, με την χρήση της παραμέτρου Διαφοράς

Comparison between original close price vs predicted close price



Εικόνα 0-11. Training - Test Results (DNN 100-65-24-1) - με Διαφοράση

Comparison between original close price vs predicted close price



Εικόνα 0-12. Test Results (DNN 82-45-10-1) - με Διαφοράση

VII. Αποτελέσματα DNN με τοπολογία 150-50-18-1, χωρίς την χρήση της παραμέτρου Διαφοράς

Comparison between original close price vs predicted close price



Εικόνα 0-13. Training - Test Results (DNN 150-50-18-1) - χωρίς Διαφοράση

Comparison between original close price vs predicted close price



Εικόνα 0-14. Test Results (DNN 150-50-18-1) - χωρίς Διαφοράση

VIII. Αποτελέσματα DNN με τοπολογία 150-50-18-1, με την χρήση της παραμέτρου Διαφοράς

Comparison between original close price vs predicted close price



Εικόνα 0-15. Training - Test Results (DNN 150-50-18-1) - με Διαφορά

Comparison between original close price vs predicted close price



Εικόνα 0-16. Test Results (DNN 150-50-18-1) - με Διαφορά

Β) Γραφική παράσταση αποτελεσμάτων χρονοσειρών (Ethereum)

ΙΧ. Αποτελέσματα DNN με τοπολογία 40-18-10-1, χωρίς την χρήση της παραμέτρου Διαφόρισης.

Comparison between original close price vs predicted close price



Εικόνα 0-17. Training - Test Results (DNN 40-18-10-1) - χωρίς Διαφόριση

Comparison between original close price vs predicted close price



Εικόνα 0-18. Test results (40-18-10-1) - Χωρίς Διαφόριση

Χ. Αποτελέσματα DNN με τοπολογία 40-18-10-1, με την χρήση της παραμέτρου Διαφοράς.

Comparison between original close price vs predicted close price



Εικόνα 0-19. Training - Test Results (DNN 40-18-10-1) - με Διαφοράση

Comparison between original close price vs predicted close price



Εικόνα 0-20. Test Results (DNN 40-18-10-1) - με Διαφοράση

XI. Αποτελέσματα DNN με τοπολογία 82-45-10-1, χωρίς την χρήση της παραμέτρου Διαφόρισης.

Comparison between original close price vs predicted close price



Εικόνα 0-21. Training - Test Results (DNN 82-45-10-1) - χωρίς Διαφόριση

Comparison between original close price vs predicted close price



Εικόνα 0-22. Test results (82-45-10-1) - Χωρίς Διαφόριση

XII. Αποτελέσματα DNN με τοπολογία 82-45-10-1, με την χρήση της παραμέτρου Διαφοράς.

Comparison between original close price vs predicted close price



Εικόνα 0-23. Training - Test Results (DNN 82-45-10-1) - με Διαφύριση

Comparison between original close price vs predicted close price



Εικόνα 0-24. Test Results (DNN 82-45-10-1) - με Διαφύριση

XIII. Αποτελέσματα DNN με τοπολογία 100-65-24-1, χωρίς την χρήση της παραμέτρου Διαφοράς.

Comparison between original close price vs predicted close price



Εικόνα 0-25. Training - Test Results (DNN 100-65-24-1) - χωρίς Διαφοράση

Comparison between original close price vs predicted close price



Εικόνα 0-26. Test Results (DNN 100-65-24-1) - χωρίς Διαφοράση

XIV. Αποτελέσματα DNN με τοπολογία 100-65-24-1, με την χρήση της παραμέτρου Διαφοράς

Comparison between original close price vs predicted close price



Εικόνα 0-27. Training - Test Results (DNN 100-65-24-1) - με Διαφοράση

Comparison between original close price vs predicted close price



Εικόνα 0-28. Test Results (DNN 82-45-10-1) - με Διαφοράση

XV. Αποτελέσματα DNN με τοπολογία 150-50-18-1, χωρίς την χρήση της παραμέτρου Διαφοράς

Comparison between original close price vs predicted close price



Εικόνα 0-29. Training - Test Results (DNN 150-50-18-1) - χωρίς Διαφοράση

Comparison between original close price vs predicted close price



Εικόνα 0-30. Test Results (DNN 150-50-18-1) - χωρίς Διαφοράση

XVI. Αποτελέσματα DNN με τοπολογία 150-50-18-1, με την χρήση της παραμέτρου Διαφοράς

Comparison between original close price vs predicted close price



Εικόνα 0-31. Training - Test Results (DNN 150-50-18-1) - με Διαφορά

Comparison between original close price vs predicted close price



Εικόνα 0-32. Test Results (DNN 150-50-18-1) - με Διαφορά

Παράρτημα Β: Αποτελέσματα LSTM

Α) Γραφική παράσταση αποτελεσμάτων χρονοσειρών (Bitcoin)

XVII. Αποτελέσματα LSTM με τοπολογία 25-15-1, χωρίς την χρήση της παραμέτρου Διαφόρισης.

Comparison between original close price vs predicted close price



Εικόνα 0-1. Training - Test Results (LSTM 25-15-1) - χωρίς Διαφόριση

Comparison between original close price vs predicted close price



Εικόνα 0-2. Test results (LSTM 25-15-1) - Χωρίς Διαφόριση

XVIII. Αποτελέσματα LSTM με τοπολογία 25-15-1, με την χρήση της παραμέτρου Διαφόρισης.

Comparison between original close price vs predicted close price



Εικόνα 0-3. Training - Test Results (LSTM 25-15-1) - με Διαφύριση

Comparison between original close price vs predicted close price



Εικόνα 0-4. Test Results (LSTM 25-15-1) - με Διαφύριση

XIX. Αποτελέσματα LSTM με τοπολογία 64-32-1, χωρίς την χρήση της παραμέτρου Διαφόρισης.

Comparison between original close price vs predicted close price



Εικόνα 0-5. Training - Test Results (LSTM 64-32-1) - χωρίς Διαφόριση

Comparison between original close price vs predicted close price



Εικόνα 0-6. Test results (64-32-1) - Χωρίς Διαφόριση

XX. Αποτελέσματα LSTM με τοπολογία 64-32-1, με την χρήση της παραμέτρου Διαφοράς.

Comparison between original close price vs predicted close price



Εικόνα 0-7. Training - Test Results (LSTM 64-32-1) - με Διαφοράση

Comparison between original close price vs predicted close price



Εικόνα 0-8. Test Results (LSTM 64-32-1) - με Διαφοράση

XXI. Αποτελέσματα DNN με τοπολογία 120-60-1, χωρίς την χρήση της παραμέτρου Διαφοράς.

Comparison between original close price vs predicted close price



Εικόνα 0-9. Training - Test Results (LSTM 120-60-1) - χωρίς Διαφοράση


Comparison between original close price vs predicted close price



Εικόνα 0-10. Test Results (LSTM 120-60-1) - χωρίς Διαφοράση

XXII. Αποτελέσματα DNN με τοπολογία 120-60-1, με την χρήση της παραμέτρου Διαφοράς

Comparison between original close price vs predicted close price



Εικόνα 0-11. Training - Test Results (LSTM 120-60-1) - με Διαφοράση

Comparison between original close price vs predicted close price



Εικόνα 0-12. Test Results (LSTM 120-60-1) - με Διαφοράση

XXIII. Αποτελέσματα LSTM με τοπολογία 160-85-1, χωρίς την χρήση της παραμέτρου Διαφοράς

Comparison between original close price vs predicted close price



Εικόνα 0-13. Training - Test Results (LSTM 160-85-1) - χωρίς Διαφοράση

Comparison between original close price vs predicted close price



Εικόνα 0-14. Test Results (LSTM 160-85-1) - χωρίς Διαφοράση

XXIV. Αποτελέσματα LSTM με τοπολογία 160-85-1, με την χρήση της παραμέτρου Διαφοράς

Comparison between original close price vs predicted close price



Εικόνα 0-15. Training - Test Results (LSTM 160-85-1) - με Διαφοράση

Comparison between original close price vs predicted close price



Εικόνα 0-16. Test Results (LSTM 160-85-1) - με Διαφοράση

Β) Γραφική παράσταση αποτελεσμάτων χρονοσειρών (Ethereum)

I. Αποτελέσματα LSTM με τοπολογία 25-15-1, χωρίς την χρήση της παραμέτρου Διαφοράς.

Comparison between original close price vs predicted close price



Εικόνα 0-17. Training - Test Results (LSTM 25-15-1) - χωρίς Διαφοράση

Comparison between original close price vs predicted close price



Εικόνα 0-18. Test results (LSTM 25-15-1) - Χωρίς Διαφοράση

II. Αποτελέσματα LSTM με τοπολογία 25-15-1, με την χρήση της παραμέτρου Διαφοράς.

Comparison between original close price vs predicted close price



Εικόνα 0-19. Training - Test Results (LSTM 25-15-1) - με Διαφύριση

Comparison between original close price vs predicted close price



Εικόνα 0-20. Test Results (LSTM 25-15-1) - με Διαφύριση

III. Αποτελέσματα LSTM με τοπολογία 64-32-1, χωρίς την χρήση της παραμέτρου Διαφόρισης.

Comparison between original close price vs predicted close price



Εικόνα 0-21. Training - Test Results (LSTM 64-32-1) - χωρίς Διαφόριση

Comparison between original close price vs predicted close price



Εικόνα 0-22. Test results (64-32-1) - Χωρίς Διαφόριση

IV. Αποτελέσματα LSTM με τοπολογία 64-32-1, με την χρήση της παραμέτρου Διαφοράς.

Comparison between original close price vs predicted close price



Εικόνα 0-23. Training - Test Results (LSTM 64-32-1) - με Διαφοράση


Comparison between original close price vs predicted close price



Εικόνα 0-24. Test Results (LSTM 64-32-1) - με Διαφοράση

V. Αποτελέσματα LSTM με τοπολογία 120-60-1, χωρίς την χρήση της παραμέτρου Διαφόρισης.

Comparison between original close price vs predicted close price



Εικόνα 0-25. Training - Test Results (LSTM 120-60-1) - χωρίς Διαφόριση

Comparison between original close price vs predicted close price



Εικόνα 0-26. Test Results (LSTM 120-60-1) - χωρίς Διαφόριση

VI. Αποτελέσματα LSTM με τοπολογία 120-60-1, με την χρήση της παραμέτρου Διαφοράς

Comparison between original close price vs predicted close price



Εικόνα 0-27. Training - Test Results (LSTM 120-60-1) - με Διαφοράση

Comparison between original close price vs predicted close price



Εικόνα 0-28. Test Results (LSTM 120-60-1) - με Διαφοράση

VII. Αποτελέσματα LSTM με τοπολογία 160-85-1, χωρίς την χρήση της παραμέτρου Διαφόρισης

Comparison between original close price vs predicted close price



Εικόνα 0-29. Training - Test Results (LSTM 160-85-1) - χωρίς Διαφόριση

Comparison between original close price vs predicted close price



Εικόνα 0-30. Test Results (LSTM 160-85-1) - χωρίς Διαφόριση

VIII. Αποτελέσματα LSTM με τοπολογία 160-85-1, με την χρήση της παραμέτρου Διαφοράς

Comparison between original close price vs predicted close price



Εικόνα 0-31. Training - Test Results (LSTM 160-85-1) - με Διαφοράση

Comparison between original close price vs predicted close price



Εικόνα 0-32. Test Results (LSTM 160-85-1) - με Διαφοράση

Υπεύθυνη Δήλωση Συγγραφέα:

Δηλώνω ρητά ότι, σύμφωνα με το άρθρο 8 του Ν. 1599/1986 και τα άρθρα 2,4,6 παρ. 3 του Ν. 1256/1982, η παρούσα εργασία αποτελεί αποκλειστικά προϊόν προσωπικής εργασίας και δεν προσβάλλει κάθε μορφής πνευματικά δικαιώματα τρίτων και δεν είναι προϊόν μερικής ή ολικής αντιγραφής, οι πηγές δε που χρησιμοποιήθηκαν περιορίζονται στις βιβλιογραφικές αναφορές και μόνον.