

Πολυτεχνείο Κρήτης

Σχολή Μηχανικών Παραγωγής και Διοίκησης



Νευρό-ασαφείς τεχνικές πρόβλεψης κρυπτονομισμάτων

Πετράκης Βασίλειος

Φεβρουάριος, 2025

Εξεταστική Επιτροπή

Καθηγητής Ατσαλάκης Γεώργιος, Επιβλέπων καθηγητής

Καθηγητής Ζοπουνίδης Κωνσταντίνος

Καθηγήτρια Κρασαδάκη Ευαγγελία

Ευχαριστίες:

Θα ήθελα να εκφράσω την ειλικρινή μου ευγνωμοσύνη σε όλους όσους με υποστήριξαν καθ' όλη τη διάρκεια αυτής της διπλωματικής εργασίας. Πρώτα απ' όλα, εκφράζω τις θερμές μου ευχαριστίες στον επιβλέποντα καθηγητή μου, κύριο Ατσαλάκη, για την πολύτιμη υποστήριξη και την εξειδικευμένη γνώση που μοιράστηκε μαζί μου.

Ένα ιδιαίτερο ευχαριστώ απευθύνεται στους συναδέλφους και φίλους μου για την αμέριστη στήριξή τους, την ενθάρρυνση και την πολύτιμη συνεισφορά τους, που μου έδωσαν δύναμη και έμπνευση καθ' όλη τη διάρκεια της πορείας μου.

Τέλος, θα ήθελα να εκφράσω τη βαθιά μου ευγνωμοσύνη στην οικογένειά μου για την αμέριστη υποστήριξή της. Η πίστη τους στις δυνατότητές μου υπήρξε πηγή δύναμης, ενώ η υπομονή και η κατανόησή τους στις δύσκολες στιγμές συνέβαλαν καθοριστικά στην ολοκλήρωση αυτής της προσπάθειας.

Περίληψη:

Σε αυτή τη διπλωματική εργασία, επιδιώκεται η πρόβλεψη των τιμών κλεισίματος κρυπτονομισμάτων μέσω της εφαρμογής ενός προσαρμοστικού νευρό-ασαφούς συστήματος (Adaptive Neuro-Fuzzy System – ANFIS) και μέσω των ασαφών συνόλων (fuzzy type-2). Τα κρυπτό νομίσματα ενώ δεν αντιπροσωπεύουν νομίσματα ούτε επενδυτικά αγαθά με την παραδοσιακή έννοια, έχουν όμως προσελκύσει το ενδιαφέρον πολλών επενδυτών με αποτέλεσμα να διακινούνται τεράστια ποσά στην παγκόσμια οικονομία μέσω των κρυπτό-νομισμάτων. Οι διακυμάνσεις των τιμών τους, δίνει την δυνατότητα σε πολλούς επαγγελματίες συναλλαγών κρυπτό-νομισμάτων να αποκομίζουν σημαντικά κέρδη και φυσικά οι μη έχοντες εμπειρία να υπόκειται σε σημαντικές ζημιές. Το σύστημα ANFIS και το fuzzy type-2 επιλέχθηκε από μία πληθώρα μεθόδων πρόβλεψης, για τις δυνατότητες που παρέχει ο συνδυασμός της ασαφούς λογικής και των τεχνητών νευρωνικών δικτύων που δομούν τον αλγόριθμο ANFIS. Στο σύστημα fuzzy type-2 η βελτιστοποίηση του μοντέλου θα γίνει με τον αλγόριθμο Particle Swarm. Τα αποτελέσματα θα συγκριθούν, με παραδοσιακές μεθόδους πρόβλεψης, την Αυτοπαλινδρόμηση – (Auto Regression) και την αυτοπαλινδρόμηση κινούμενου μέσου όρου (Auto Regression Moving Average) για τη περαιτέρω αξιολόγηση των αποτελεσμάτων.

Abstract:

In this thesis, the prediction of cryptocurrency closing prices is pursued through the application of an adaptive neuro-fuzzy inference system (ANFIS) and the implementation of fuzzy sets (fuzzy type-2). Cryptocurrencies, while they do not represent traditional currencies (fiat currencies) or investment assets in a conventional way, have nonetheless attracted the interest of many investors, resulting in the circulation of vast amounts of capital in the global economy due to cryptocurrencies. Their price fluctuations provide an opportunity for many professional cryptocurrency traders to earn significant profits, while inexperienced traders are subject to substantial losses. The ANFIS system and the fuzzy type-2 method were selected from a variety of forecasting methods due to the advantages offered by the combination of fuzzy logic and artificial neural networks, which form the basis of the ANFIS algorithm. In the fuzzy type-2 system, model optimization will be performed using the particle swarm algorithm (PSO). The results will be compared with traditional forecasting methods, such as auto regression (AR) and auto regression moving average (ARMA), for further evaluation of the outcomes.

Keywords:

ANFIS Model, Fuzzy Type-2, Neuro-Fuzzy systems, Neural Networks, Auto-Regression model, Auto-Regression Moving Average Model, Cryptocurrency forecasting.

Πίνακας Περιεχομένων

Κεφάλαιο 1 : Εισαγωγή και δομή της διπλωματικής εργασίας.....	7
1.1 Εισαγωγή.....	7
1.2 Ανασκόπηση Βιβλιογραφίας.....	8
1.3 Ιστορική αναδρομή της πορείας των κρυπτονομισμάτων	15
1.4 Blockchain	16
1.5 Προβλέψεις στην αγορά των κρυπτονομισμάτων	17
1.6 Κρυπτονομίσματα υπό ανάλυση	17
1.7 Στόχοι της εργασίας	21
1.8 Σύγχρονα και παραδοσιακά μοντέλα πρόβλεψης.....	22
Κεφάλαιο 2: Μεθοδολογικό πλαίσιο.....	24
2.1 Ιστορική αναδρομή στη θεωρία της ασαφούς λογικής.....	24
2.2 Επισκόπηση.....	24
2.3 Ασαφή σύνολα	26
2.4 Συναρτήσεις συμμετοχής.....	27
2.5 Ασαφή συστήματα εξαγωγής συμπερασμάτων (FIS).....	30
2.6 Εφαρμογές της ασαφούς λογικής.....	32
2.7 Τεχνητά νευρωνικά δίκτυα	33
2.8 Προσαρμοστικά δίκτυα	39
2.9 Προσαρμοστικό νευρό-ασαφές σύστημα συμπερασμάτων - ANFIS	40
2.10 Αρχιτεκτονική του ANFIS.....	40
2.11 Ομαδοποίηση δεδομένων	43
2.12 Αλγόριθμοι βελτιστοποίησης	45
2.13 Μοντέλο ασαφούς λογικής τύπου 2	46
2.14 Εφαρμογές των συστημάτων ασαφούς λογικής τύπου 2.....	48
Κεφάλαιο 3 : Ανάλυση δεδομένων και παράμετροι των μοντέλων.....	50
3.1 Δεδομένα	50

3.2 Προετοιμασία δεδομένων	53
3.3 Παράμετροι του μοντέλου.....	53
Κεφάλαιο 4 : Αποτελέσματα.....	54
Αποτελέσματα του μοντέλου ANFIS για το Bitcoin	54
4.2 Αποτελέσματα των μοντέλων AR και ARMA για το Bitcoin.....	65
4.3 Αποτελέσματα του μοντέλου νευρωνικού δικτύου για το Bitcoin	67
4.4 Αποτελέσματα του ασαφούς μοντέλου τύπου 2 (Fuzzy Type-2) με βελτιστοποίηση μέσω του αλγορίθμου PSO για το Bitcoin	69
4.5 Αποτελέσματα του μοντέλου ANFIS για το Ethereum	74
4.6 Αποτελέσματα μοντέλων AR και ARMA για το Ethereum.....	81
4.7 Αποτελέσματα του μοντέλου νευρωνικού δικτύου για το Ethereum	84
4.8 Αποτελέσματα του ασαφούς μοντέλου τύπου 2 (Fuzzy Type-2) με βελτιστοποίηση μέσω του αλγορίθμου PSO για το Ethereum	85
4.9 Αποτελέσματα του μοντέλου ANFIS για το BNB	88
4.10 Αποτελέσματα των μοντέλων AR και ARMA για το BNB.....	95
4.11 Αποτελέσματα του μοντέλου νευρωνικού δικτύου για το	97
4.12 Αποτελέσματα του ασαφούς μοντέλου τύπου 2 (Fuzzy Type-2) με βελτιστοποίηση μέσω του αλγορίθμου PSO για το BNB	98
4.13 Αποτελέσματα του μοντέλου ANFIS για το Solana.....	100
4.14 Αποτελέσματα των μοντέλων AR και ARMA για το Solana	106
4.15 Αποτελέσματα του μοντέλου νευρωνικού δικτύου για το Solana.....	108
4.16 Αποτελέσματα του ασαφούς μοντέλου τύπου 2 (Fuzzy Type-2) με βελτιστοποίηση μέσω του αλγορίθμου PSO για το Solana.....	110
4.17 Αποτελέσματα του μοντέλου ANFIS για το XRP	112
4.18 Αποτελέσματα των μοντέλων AR και ARMA για το XRP	119
4.19 Αποτελέσματα του μοντέλου νευρωνικού δικτύου για το XRP	121
4.20 Αποτελέσματα του ασαφούς μοντέλου τύπου 2 (Fuzzy Type-2) με βελτιστοποίηση μέσω του αλγορίθμου PSO για το XRP	122

4.21 Συνοπτικός πίνακας αποτελεσμάτων των μετρήσεων σφάλματος και σύγκριση των εφαρμοσμένων μοντέλων	125
Κεφάλαιο 5 : Συμπεράσματα.....	135
Βιβλιογραφία	137

Κεφάλαιο 1: Εισαγωγή και δομή της διπλωματικής εργασίας

1.1 Εισαγωγή

Τα κρυπτονομίσματα έχουν αναδειχθεί σε έναν σημαντικό πυλώνα του παγκόσμιου χρηματοοικονομικού συστήματος, προσελκύοντας πολλούς επενδυτές λόγω της έντονης μεταβλητότητάς τους και των δυνητικών υψηλών αποδόσεων. Παρ' όλα αυτά, η πρόβλεψη των τιμών τους παραμένει μια σύνθετη πρόκληση, επηρεαζόμενη από παράγοντες όπως το επενδυτικό κλίμα, οι κανονιστικές ρυθμίσεις και οι τεχνολογικές εξελίξεις. Οι παραδοσιακές μέθοδοι πρόβλεψης, όπως η αυτοπαλινδρόμηση (Auto Regression - AR) και η αυτοπαλινδρόμηση μετακινούμενου μέσου όρου (Auto Regression Moving Average - ARMA), συχνά δεν επαρκούν λόγω της γραμμικής φύσης τους και της αδυναμίας τους να αποτυπώσουν τη δυναμική και μη γραμμική συμπεριφορά των αγορών κρυπτονομισμάτων.

Η παρούσα διπλωματική εργασία εστιάζει σε προηγμένες τεχνικές πρόβλεψης, αξιοποιώντας το προσαρμοστικό νεύρο-ασαφές σύστημα (Adaptive Neuro-Fuzzy Inference System - ANFIS) και τα μοντέλα ασαφούς λογικής τύπου-2 (Fuzzy Type-2). Για την περαιτέρω βελτίωση της ακρίβειας, τα μοντέλα ασαφούς λογικής τύπου-2 θα βελτιστοποιηθούν με τη χρήση του αλγορίθμου σμήνους σωματιδίων (Particle Swarm Optimization - PSO).

Ο κύριος στόχος είναι η πρόβλεψη των τιμών κλεισίματος των πέντε μεγαλύτερων κρυπτονομισμάτων βάσει της κεφαλαιοποίησης τους, καθώς και η σύγκριση της απόδοσης των προηγμένων προβλεπτικών μοντέλων με τις παραδοσιακές μεθόδους πρόβλεψης. Η ανάλυση αυτή αποσκοπεί στην παροχή πολύτιμων πληροφοριών για την αποτελεσματικότητα των νεύρο-ασαφών τεχνικών στην πρόβλεψη τιμών κρυπτονομισμάτων, ενισχύοντας την κατανόηση των προκλήσεων και των δυνατοτήτων της αγοράς.

1.2 Ανασκόπηση Βιβλιογραφίας

1. Πρόβλεψη τιμών κρυπτονομισμάτων χρησιμοποιώντας μοντέλα ασαφούς λογικής βασισμένα σε δεδομένα Level-Set

Στη συγκεκριμένη έρευνα αυτή, οι συγγραφείς Leandro Maciel et al. (2022) εξετάζουν την πρόβλεψη τιμών κρυπτονομισμάτων χρησιμοποιώντας μια μέθοδο ασαφούς μοντελοποίησης βασισμένη σε δεδομένα level-set. Αντί να παράγουν αποτελέσματα με βάση τις παραδοσιακές μεθόδους κανόνων (rule-based), η προσέγγιση αυτή παράγει έναν σταθμισμένο μέσο όρο των συναρτήσεων εξόδου των ενεργών ασαφών κανόνων, αντιστοιχίζοντας τα επίπεδα ενεργοποίησης τους απευθείας στην έξοδο-αποτέλεσμα του μοντέλου.

Το μοντέλο δοκιμάστηκε χρησιμοποιώντας ημερήσια δεδομένα τιμών κλεισίματος για δέκα κορυφαία κρυπτονομίσματα: Cardano (ADA), Binance Coin (BNB), Bitcoin (BTC), Ethereum (ETH), Chainlink (LINK), Litecoin (LTC), Tron (TRX), Stellar (XLM), Monero (XMR) και Ripple (XRP). Μια προσέγγιση διασταυρούμενης επικύρωσης (cross-validation) εφαρμόστηκε για την αξιολόγηση της απόδοσης του μοντέλου. Το μοντέλο αξιολογείται για την πρόβλεψη της τιμής του επόμενου βήματος (one-step-ahead) για τα παραπάνω κρυπτονομίσματα και η απόδοσή του συγκρίνεται με παραδοσιακά μοντέλα όπως το ARIMA (αυτοπαλινδρόμηση ολοκληρωμένου κινητού μέσου όρου), τα πολυεπίπεδα νευρωνικά δίκτυα (multilayer neural networks) και το μοντέλο τυχαίας κίνησης (Random Walk). Επιπλέον, η αξιολόγηση της απόδοσης των παραπάνω μεθόδων γίνεται χρησιμοποιώντας το ριζικό μέσο τετραγωνικό σφάλμα (RMSE), το μέσο απόλυτο σφάλμα (MAE) και το μέσο απόλυτο ποσοστιαίο σφάλμα (MAPE). Τα αποτελέσματα δείχνουν ότι το μοντέλο τυχαίας κίνησης υπερέχει σε σχέση με τους ανταγωνιστές ως προς την ακρίβεια, αλλά όταν αξιολογείται με βάση την κατεύθυνση της μεταβολής της τιμής, τα μοντέλα ασαφούς λογικής βασισμένα σε level-set παρουσιάζουν καλύτερη απόδοση.

2. Συγκριτική μελέτη για την πρόβλεψη τιμών του κρυπτονομίσματος Bitcoin την περίοδο 2017-2019

Στη μελέτη αυτή, οι συγγραφείς Tri Wijayanti Septiarini et al. (2020) επιδιώκουν να αναπτύξουν και να συγκρίνουν τα κλασικά στατιστικά μοντέλα με τα μοντέλα τεχνητής νοημοσύνης για την πρόβλεψη των τιμών του Bitcoin. Αξιολογούν την απόδοση πρόβλεψης αυτών των μοντέλων χρησιμοποιώντας τα σφάλματα τετραγωνικής ρίζας (RMSE) και μέσου τετραγωνικού σφάλματος (MSE). Τα μοντέλα που εξετάζονται περιλαμβάνουν κλασικές στατιστικές μεθόδους όπως η ARIMA (αυτοπαλινδρόμηση ολοκληρωμένου κινητού μέσου όρου) και η εκθετική εξομάλυνση (Exponential Smoothing), καθώς και μεθόδους τεχνητής νοημοσύνης όπως οι χρονοσειρές ασαφούς λογικής και το ANFIS (προσαρμοστικό νευρό-ασαφές σύστημα). Στη μελέτη χρησιμοποιήθηκαν δεδομένα που συλλέχθηκαν από τις 5 Ιανουαρίου 2017 έως την 1η Οκτωβρίου 2019, που περιλάμβαναν 1.000 ημερήσιες παρατηρήσεις. Έπειτα, τα

δεδομένα αυτά χωρίστηκαν σε 75% για εκπαίδευση και 25% για δοκιμές. Τέλος, τα αποτελέσματα δείχνουν ότι οι κλασικές στατιστικές μέθοδοι υπερίσχυαν των μοντέλων τεχνητής νοημοσύνης όσον αφορά την ακρίβεια πρόβλεψης, ωστόσο, τονίζεται στην μελέτη ότι κάθε χρονοσειρά έχει μοναδικά χαρακτηριστικά που απαιτούν περαιτέρω ανάλυση.

3. Ανάλυση και πρόβλεψη του Bitcoin μέσω του ασαφούς μετασχηματισμού

Οι συγγραφείς Maria Letizia Guerra et al. (2020) εξετάζουν τη χρήση του ασαφούς μετασχηματισμού (F-transform) για ανάλυση συναισθημάτων (sentiment analysis) στην πρόβλεψη των τιμών του Bitcoin. Χρησιμοποιούν την παραλλαγή Lp-norm του F-transform για να μοντελοποιήσουν τα δεδομένα χρονοσειρών, καταγράφοντας τις σχέσεις μεταξύ των τιμών του Bitcoin και των βαθμολογιών στο Google trends. Εφαρμόζοντας τεχνικές ομαδοποίησης και πίνακες μεταβάσεων, η μελέτη εντοπίζει τυποποιημένα γεγονότα (stylized facts) και αξιολογεί μοντέλα βραχυπρόθεσμης πρόβλεψης. Τα αποτελέσματα δείχνουν ότι η προ-ομαδοποίηση των δεδομένων, ακόμη και με τη χρήση απλών στρατηγικών ομαδοποίησης με σχετικά μικρό αριθμό ομάδων (από 20 έως 24), ενισχύει σημαντικά την ικανότητα εφαρμογής του F-transform. Το μοντέλο χρησιμοποιεί τα άμεσα στοιχεία του F-transform για να εκτιμήσει μελλοντικές τιμές του Bitcoin, ενσωματώνοντας πολυωνυμικούς όρους, εκδόσεις των βαθμολογιών στο Google trends και τις τιμές του Bitcoin. Οι μετρήσεις αξιολόγησης περιλαμβάνουν το μέσο τετραγωνικό σφάλμα (MSE), το μέσο απόλυτο ποσοστιαίο σφάλμα (MAPE) και την συσχέτιση του Kendall's tau. Οι άμεσοι και αντίστροφοι F-transforms προσφέρουν ευέλικτη και προσαρμοστική μη παραμετρική εξομάλυνση των δεδομένων. Ωστόσο, η μελέτη δεν υποστηρίζει την υπεροχή της πρόβλεψης βασισμένης στον F-transform σε σχέση με άλλες μεθόδους.

3. Μια υβριδική προσέγγιση για την πρόβλεψη των τιμών του Bitcoin

Στην έρευνα αυτή, οι συγγραφείς Büşra Kutlu Karabiyik και Zeliha Can Ergün (2021) χρησιμοποίησαν το προσαρμοστικό νευρό-ασαφές σύστημα (ANFIS) για την πρόβλεψη των τιμών του Bitcoin, χρησιμοποιώντας μια σειρά από οικονομικούς και τεχνικούς δείκτες από την 1η Μαΐου 2013 έως την 26η Φεβρουαρίου 2021. Ενσωματώνοντας μεταβλητές όπως η τιμή του αργού πετρελαίου, ο δείκτης S&P 500, το hash rate και τα έσοδα των εξορυκτών, το μοντέλο ANFIS απέδειξε υψηλή ακρίβεια στις προβλέψεις του. Τα δεδομένα χωρίστηκαν σε υποσύνολα εκπαίδευσης (90%) και δοκιμών (10%), με το μοντέλο να πετυχαίνει μέση τετραγωνική απόκλιση ρίζας (RMSE) ίση με 0.0053732 κατά την εκπαίδευση και 0.083966 κατά τις δοκιμές. Το μοντέλο, που χρησιμοποίησε 16 κανόνες (rules) και συναρτήσεις συμμετοχής (membership functions) σε σχήμα καμπάνας (bell-shaped), όπου έδειξε ισχυρή ταύτιση με τις πραγματικές τιμές του Bitcoin. Τα αποτελέσματα δείχνουν ότι το ANFIS είναι αποτελεσματικό για την πρόβλεψη των τιμών του Bitcoin, προσφέροντας πολύτιμες πληροφορίες για τους επενδυτές.

5. Εξελικτικά νευρό-ασαφή συστήματα και εφαρμογές

Στη μελέτη αυτή, οι συγγραφείς G. Castellano et al. (2007) παρουσιάζουν μια ενδελεχή επισκόπηση των υβριδικών συστημάτων υπολογιστικής νοημοσύνης, με ιδιαίτερη έμφαση στον συνδυασμό εξελικτικών αλγορίθμων και νευρωνικών δικτύων για την ενίσχυση των μαθησιακών και προσαρμοστικών δυνατοτήτων των ασαφών συστημάτων. Στη συγκεκριμένη μελέτη εισάγεται μια νέα προσέγγιση που συνδυάζει τη νευρωνική μάθηση με τη γενετική βελτιστοποίηση, επιδιώκοντας τόσο την εκμάθηση όσο και τη βελτιστοποίηση ενός ασαφούς μοντέλου, με στόχο τη βελτίωση της ακρίβειας και της ερμηνευσιμότητας του. Οι συγγραφείς προτείνουν το μοντέλο των εξελικτικών τεχνητών νευρωνικών δικτύων (EANNs), το οποίο συνδυάζει τους εξελικτικούς αλγορίθμους για την ενίσχυση της προσαρμοστικότητας των νευρωνικών δικτύων. Ο στόχος είναι η εφαρμογή εξελικτικών αρχών (evolutionary principals), όπως η επιλογή, η μετάλλαξη και η διασταύρωση, για τη βελτιστοποίηση διαφόρων πτυχών των νευρωνικών δικτύων, δηλαδή τα βάρη σύνδεσης, η τοπολογία του δικτύου και οι κανόνες μάθησης. Αυτά τα συστήματα συγχωνεύουν τα νευρωνικά δίκτυα, την ασαφή λογική και εξελικτικούς αλγορίθμους για να ξεπεράσουν τους περιορισμούς των μεμονωμένων προσεγγίσεων, ιδιαίτερα σε εργασίες που απαιτούν ευελιξία και προσαρμοστικότητα. Επιπλέον η μελέτη περιγράφει διάφορες στρατηγικές ενσωμάτωσης για τον συνδυασμό εξελικτικών αλγορίθμων και νευρωνικών δικτύων, όπως η βελτιστοποίηση των βαρών σύνδεσης, η προσαρμογή της αρχιτεκτονικής και οι κανόνες μάθησης. Η μελέτη υποστηρίζει τη σύνθεση τεχνητών νευρωνικών δικτύων, ασαφών συστημάτων και εξελικτικών αλγορίθμων για τη δημιουργία αποδοτικών και ερμηνεύσιμων μοντέλων, δίνοντας έμφαση στη σημασία της ισορροπίας μεταξύ ακρίβειας και ενός ασαφούς συνόλου κανόνων.

6. Μια προσέγγιση βασισμένη σε ένα προσαρμοστικό δίκτυο που αποσκοπεί στη προηγμένη πρόβλεψη τιμών κρυπτονομισμάτων

Οι συγγραφείς Ali Mehrban και Pegah Ahadian (2023) παρουσιάζουν μια μέθοδο για την πρόβλεψη των τιμών κρυπτονομισμάτων με χρονικό ορίζοντα τις επόμενες επτά ημέρες, χρησιμοποιώντας το προσαρμοστικό σύστημα νευρό-ασαφούς λογικής (ANFIS). Το μοντέλο ενσωματώνει αλγόριθμους μηχανικής μάθησης, υβριδικές μεθόδους και μεθόδους οπισθοδιάδοσης, καθώς και τεχνικές ομαδοποίησης όπως η διαίρεση πλέγματος (grid partition), η αφαιρετική ομαδοποίηση (subtractive clustering) και η Fuzzy C-means (FCM). Το ANFIS συνδυάζει τα νευρωνικά δίκτυα με ασαφή λογική μέσω μιας δομής αποτελούμενης από πέντε επίπεδα: την ασάφεια, τους κανόνες, τη κανονικοποίηση, τη αποσαφήνιση και τα επίπεδα εξόδου. Χρησιμοποιεί δύο μεθόδους εκπαίδευσης: τον υβριδικό αλγόριθμο, ο οποίος εφαρμόζει την εκτίμηση ελαχίστων τετραγώνων (LSE) και την gradient descent (GD), και τον αλγόριθμο οπισθοδιάδοσης (backpropagation), που ρυθμίζει όλες τις παραμέτρους μέσω της GD. Τα δεδομένα για τα Bitcoin, Ethereum, καθώς και οι μεταβλητές κυριαρχίας τους, που καλύπτουν την περίοδο

από τις 17 Αυγούστου 2017 έως τις 3 Ιουνίου 2022, χωρίζονται σε δύο υποσύνολα, στο πρώτο υποσύνολο ανήκει το 90% των δεδομένων που προορίζεται για εκπαίδευση και στο δεύτερο υποσύνολο ανήκει το 10% των δεδομένων που προορίζονται για δοκιμές. Η απόδοση του μοντέλου αξιολογείται μέσω του μέσου τετραγωνικού σφάλματος (RMSE) και του μέσου τετραγωνικού σχετικού σφάλματος. Η μελέτη καταλήγει ότι το ANFIS, ιδιαίτερα όταν συνδυάζεται με δείκτες κυριαρχίας της αγοράς, είναι αποτελεσματικό στη βελτίωση της ακρίβειας της πρόβλεψης των τιμών των κρυπτονομισμάτων.

7. Ένα ενστικτώδες νευρό-ασαφές σύστημα βασιζόμενο στη δικαιολογημένη κοκκομετρία

Σε αυτή τη μελέτη, οι συγγραφείς Petr Hajek et al. (2022) παρουσιάζουν ένα υβριδικό μοντέλο για την πρόβλεψη χρονοσειρών, το οποίο ενσωματώνει ασαφή συστήματα, νευρωνικά δίκτυα και μια τεχνική βελτιστοποίησης γνωστή ως "δικαιολογημένη κοκκομετρία". Το συγκεκριμένο μοντέλο σχεδιάστηκε για να αντιμετωπίζει την αβεβαιότητα και τη μη γραμμικότητα των δεδομένων χρονοσειρών. Το μοντέλο λειτουργεί σε τρία στάδια. Στο πρώτο στάδιο, προσεγγίζει τα δεδομένα της χρονοσειράς, διαχωρίζοντάς τα σε διαστήματα μεταβαλλόμενου μεγέθους μέσω της δικαιολογημένης κοκκομετρίας. Στη συνέχεια, τα δεδομένα αποσαφηνίζονται χρησιμοποιώντας τα ενστικτώδη ασαφή σύνολα, ώστε να αποτυπωθούν οι διακυμάνσεις. Στο δεύτερο στάδιο, δημιουργείται ένα νευρό-ασαφές ενστικτώδες σύστημα, βασιζόμενο σε ασαφείς κανόνες συσχέτισης, με σκοπό να παραχθεί μια αποδοτική και ερμηνεύσιμη βάση κανόνων. Στο τρίτο και τελευταίο στάδιο, πραγματοποιείται η πρόβλεψη και η αποσαφήνιση των δεδομένων, με τη χρήση του τελεστή intuitionistic fuzzy-weighted average (IFWA), για την εξαγωγή της τελικής πρόβλεψης. Η απόδοση του μοντέλου αξιολογείται μέσω ορισμένων εκτιμήσεων σφάλματος όπως το μέσο τετραγωνικό σφάλμα (RMSE) και το μέσο απόλυτο σφάλμα (MAE). Τα αποτελέσματα δείχνουν ότι το μοντέλο NIFS-JG επιτυγχάνει υψηλότερες αποδόσεις σε σχέση με τη στρατηγική "αγοράς και διατήρησης", αν και συνοδεύεται από αυξημένο ρίσκο.

8. Chaotic type-2 transient-fuzzy deep neuroOscillatory network (CT2TFDNN) για παγκόσμια τη χρηματοοικονομική πρόβλεψη

Στην έρευνα αυτή, ο συγγραφέας Raymond S. T. Lee (2019) παρουσίασε ένα μοντέλο χρηματοοικονομικής πρόβλεψης, το chaotic type-2 transient-fuzzy deep neuro-oscillatory network (CT2TFDNN), το οποίο συνδυάζει την ασαφή λογική τύπου-2 (Interval Type-2 Fuzzy Logic) και τις συναρτήσεις συμμετοχής τύπου chaotic transient-fuzzy type-2 (CT2TFMF) με ένα chaotic deep neuro-oscillatory network χρησιμοποιώντας τη παλινδρομική σήμανση (Retrograde Signaling). Αυτό το μοντέλο έχει σχεδιαστεί για να διαχειρίζεται την πολυπλοκότητα και το χάος που περιλαμβάνεται στα δεδομένα χρονοσειρών των χρηματοοικονομικών αγορών. Το CT2TFDNN χρησιμοποιεί χαοτικούς νευρωνικούς ταλαντωτές, γενετικούς αλγορίθμους, συστήματα τύπου-2 ασαφούς λογικής και ένα "βαθύ" χαοτικό νευρωνικό δίκτυο για την πρόβλεψη της συμπεριφοράς

της αγοράς. Το μοντέλο εκπαιδεύεται σε χρηματοοικονομικούς δείκτες και στα δεδομένα χρονοσειρών, χρησιμοποιώντας τα “βαθιά” νευρωνικά δίκτυα ταλαντώσεων με επίπεδα χαοτικής διχοτόμησης, με σκοπό τη βελτίωση της μάθησης του μοντέλου. Το σύστημα υπερτερεί των παραδοσιακών μοντέλων, όπως οι μηχανές υποστήριξης διανυσμάτων (SVM), τα “βαθιά” νευρωνικά δίκτυα μέσω της ανάλυσης των κυρίων συνιστωσών (DNN-PCA) και τα συστήματα διαστημάτων ασαφούς λογικής τύπου-2 (IT2FNN), όσον αφορά την ακρίβεια πρόβλεψης, αντιμετωπίζοντας έτσι αποτελεσματικά καίρια προβλήματα όπως η υπερ-εκπαίδευση και το αδιέξοδο (deadlock). Το CT2TFDNN προσφέρει πιο σταθερές και ακριβείς προβλέψεις, επιτυγχάνοντας ταχύτερη σταθερότητα απόδοσης σε σύγκριση με άλλα μοντέλα, κάνοντάς το ιδιαίτερα αποτελεσματικό σε χαοτικά χρηματοοικονομικά περιβάλλοντα.

9. Πρόβλεψη των τιμών κλεισίματος του Bitcoin με τη χρήση νευρό-ασαφών τεχνικών

Στη μελέτη αυτή, οι συγγραφείς George S. Atsalakis et al. (2019) παρουσιάζουν το υβριδικό μοντέλο νευρό-ασαφούς λογικής PATSOS για την πρόβλεψη των μεταβολών των τιμών κλεισίματος του Bitcoin. Το σύστημα ενσωματώνει δύο υποσυστήματα του ANFIS, το CON-ANFIS για την εφαρμογή της αντίστροφης μάθησης και το PR-ANFIS που μοντελοποιεί τη διαδικασία, μαζί σχηματίζουν έναν βρόχο ανατροφοδότησης (feedback loop). Σε παράδειγμα προσομοίωσης συναλλαγών, το PATSOS ξεπέρασε τη στρατηγική “αγοράς και διατήρησης”, προσφέροντας απόδοση 71,21% υψηλότερη σε σχέση με τη τελευταία. Επιπλέον, το PATSOS ξεχωρίζει για τη διαφάνεια και την ερμηνευσιμότητα του, χρησιμοποιώντας κανόνες “αν-τότε” (if-then) για να προσφέρει πιο κατανοητές προβλέψεις για τις επενδυτικές αποφάσεις. Η υπεροχή του έναντι των άλλων μοντέλων σχετικά με την απόδοσή του σε πολλαπλά κριτήρια αξιολόγησης αναδεικνύει τη δυναμική του για τη βελτίωση της πρόβλεψης της τιμής των κρυπτονομισμάτων.

10. Το προσαρμοστικό νευρό-ασαφές σύστημα (ANFIS) διαστήματος τύπου-2 με μη μονότονη ασαφοποίηση τύπου-2

Σε αυτή την έρευνα, οι Hossein MonirVaghefi et al. (2013) εξετάζουν την επέκταση του προσαρμοστικού νευρό-ασαφούς συστήματος (ANFIS) σε συστήματα διαστήματος ασαφούς λογικής τύπου-2 (IT2FLS) για την καλύτερη διαχείριση της αβεβαιότητας των δεδομένων. Η μελέτη αρχίζει με μια επισκόπηση της ασαφούς λογικής, τονίζοντας τη μετάβαση από τα συστήματα τύπου-1 σε συστήματα τύπου-2, τα οποία βελτιώνουν τη διαχείριση υψηλότερων επιπέδων αβεβαιότητας. Στη συνέχεια, οι συγγραφείς γενικεύουν το ANFIS για το IT2FLS ενσωματώνοντας την γκαουσιανή ασαφοποίηση με προηγμένες τεχνικές προσαρμογής παραμέτρων, όπως οι μέθοδοι Gradient Descent και Levenberg–Marquardt. Το ενισχυμένο σύστημα εφαρμόζεται για την πρόβλεψη δεδομένων θορυβώδους (noisy) χρονοσειράς Mackey–Glass, αποδεικνύοντας την αποτελεσματικότητά του στη διαχείριση των αβεβαιοτήτων και στη βελτίωση της ακρίβειας των προβλέψεων.

11. Προβλέψεις βραχυπρόθεσμων τάσεων χρηματιστηριακής αγοράς χρησιμοποιώντας μεθοδολογία βασισμένη στα νευρό-ασαφή συστήματα

Οι συγγραφείς George S. Atsalakis και Kimon P. Valavanis (2009) διερευνούν την αποτελεσματικότητα μιας μεθοδολογίας βασισμένης στη νευρό-ασαφή λογική, για την πρόβλεψη βραχυπρόθεσμων τάσεων στην αγορά του χρηματιστηρίου. Παρουσιάζουν ένα μοντέλο νευρό-ασαφούς λογικής του οποίου η σύνθεση αποτελείται από έναν ελεγκτή του προσαρμοστικού νευρό-ασαφούς μοντέλου που χρησιμοποιείται για τον έλεγχο του διαδικαστικού μοντέλου της χρηματιστηριακής αγοράς, το οποίο έχει αναγνωριστεί χρησιμοποιώντας νευρό-ασαφής τεχνικές. Οι ιστορικές τιμές των μετοχών χρησιμοποιούνται ως είσοδοι (inputs) και η απόδοση του μοντέλου αξιολογείται με βάση το μέσο τετραγωνικό σφάλμα (RMSE). Τα αποτελέσματα υποδεικνύουν ότι η προσέγγιση με βάση το προσαρμοστικό νευρό-ασαφές σύστημα αμφισβητεί την υπόθεση αποτελεσματικής αγοράς (EMH) αποδεικνύοντας την σαφώς ανώτερη ακρίβεια πρόβλεψης σε σχέση με παραδοσιακές μεθόδους και τη στρατηγική “αγορά και διατήρηση”. Συνολικά, η μελέτη υποστηρίζει ότι οι νευρό-ασαφής τεχνικές πρόβλεψης, και συγκεκριμένα το προσαρμοστικό νευρό-ασαφές σύστημα, προσφέρουν καλύτερα και πιο αξιόπιστα αποτελέσματα σε σχέση με τη στρατηγική “αγορά και διατήρηση” και 13 άλλες παρόμοιες προσεγγίσεις ήπιων υπολογιστικών μεθόδων (soft computing).

12. Προσαρμοστικό νευρό-ασαφές σύστημα για την πρόβλεψη διακύμανσης κρυπτονομισμάτων σε σταθερές και κρίσιμες περιόδους: Περίπτωση του COVID-19

Σε αυτή τη μελέτη, οι συγγραφείς Hager Chlif et al. (2022) προτείνουν ένα μοντέλο προσαρμοστικής νευρό-ασαφούς πρόβλεψης κρυπτονομισμάτων (ANFPC) για την πρόβλεψη των τιμών των κρυπτονομισμάτων κατά τη διάρκεια τόσο σταθερών όσο και κρίσιμων περιόδων, ειδικότερα κατά την κρίση του COVID-19 και την μετά-κρίση περίοδο των εμβολίων. Το μοντέλο ενσωματώνει χρηματοοικονομικά και μη χρηματοοικονομικά δεδομένα, χρησιμοποιώντας το ANFIS για την πρόβλεψη των διακυμάνσεων των τιμών για τα Bitcoin, Ethereum, Cardano, Ripple και Dogecoin. Το μοντέλο ANFPC υπερτερεί σε σχέση με παραδοσιακά μοντέλα όπως τη μνήμη μακράς και βραχείας διάρκειας (LSTM) και το τεχνητό νευρωνικό δίκτυο (ANN) στις περισσότερες περιπτώσεις, ιδιαίτερα για το Bitcoin, Ethereum και Dogecoin, επιτεύχθηκαν οι χαμηλότεροι δείκτες σφάλματος (MAE, MSE, RMSE). Η μελέτη αναδεικνύει τη δυνατότητα βελτίωσης του μοντέλου με την ενσωμάτωση επιπλέον μεταβλητών όπως η μεταβλητότητα, η ρευστότητα και οι μακροοικονομικοί παράγοντες.

13. Προσαρμοστική ασαφή μοντελοποίηση δεδομένων ροής με τιμές διαστημάτων και εφαρμογή στην πρόβλεψη των κρυπτονομισμάτων

Οι Leandro Maciel et al. (2021) παρουσιάζουν την προσέγγιση προσαρμοστικής ασαφούς μοντελοποίησης διαστημάτων (aFIM) για την πρόβλεψη των ημερήσιων, υψηλών και χαμηλών τιμών των σημαντικότερων κρυπτονομισμάτων όπως το Bitcoin, το Ethereum, το XRP και το Litecoin. Σε αντίθεση με τα παραδοσιακά μοντέλα πρόβλεψης, το aFIM προβλέπει διαστήματα τιμών αντί για τις μεμονωμένες τιμές, ενισχύοντας έτσι την ικανότητά του να καταγράφει την αστάθεια της αγοράς και να διαχειρίζεται καλύτερα το ρίσκο. Το μοντέλο προσαρμόζεται δυναμικά σε πραγματικό χρόνο ενημερώνοντας τη βάση κανόνων και τις παραμέτρους του, χρησιμοποιώντας δεδομένα με τιμές διαστημάτων και την αναδρομική ελάχιστη- τετραγωνική μέθοδο. Όταν συγκρίνεται με εγκαθιδρυμένες μεθόδους όπως το ANFIS, το LSTM (Long Short-Term Memory), το ARIMA (αυτοπαλινδρομικό μοντέλο κινητού μέσου όρου), το ETS (μοντέλο εκθετικής εξομάλυνσης) και τον τυχαίο περίπατο (Random Walk), το aFIM παραδίδει συνεχώς καλύτερη προβλεπτική ακρίβεια και καλύτερη κατεύθυνση πρόβλεψης. Η μελέτη καταλήγει στο συμπέρασμα ότι ο μηχανισμός συνεχούς μάθησης του aFIM, αποτελεί ένα ισχυρό εργαλείο για ανάλυση σε πραγματικό χρόνο και για τη διαχείριση του κινδύνου στην αγορά κρυπτονομισμάτων, παρουσιάζοντας σημαντικές βελτιώσεις σε σχέση με τις παραδοσιακές τεχνικές πρόβλεψης.

1.3 Ιστορική αναδρομή της πορείας των κρυπτονομισμάτων

Τα κρυπτονομίσματα εμφανίζουν τις ρίζες τους στα τέλη του 20ού αιώνα, όταν κρυπτογράφοι και προγραμματιστές άρχισαν να εξερευνούν τα ψηφιακά νομίσματα και τα αποκεντρωμένα χρηματοοικονομικά συστήματα. Ωστόσο, μόλις το 2009 εμφανίστηκε το πρώτο πραγματικό κρυπτονόμισμα, το Bitcoin, το οποίο εισήχθη από ένα ανώνυμο άτομο ή ομάδα γνωστή ως Satoshi Nakamoto. Το Bitcoin σχεδιάστηκε ως ένα αποκεντρωμένο, peer-to-peer νόμισμα που λειτουργεί χωρίς την ανάγκη κεντρικής αρχής, βασιζόμενο στην τεχνολογία blockchain, με στόχο την δημιουργία ενός ασφαλούς και διαφανούς συστήματος καταγραφής συναλλαγών.

Η δημιουργία του Bitcoin σηματοδότησε την αρχή μιας νέας εποχής στον χρηματοοικονομικό τομέα. Τα πρώτα χρόνια του χαρακτηρίζονταν από περιορισμένη υιοθέτηση και συσχέτιση με εξειδικευμένες κοινότητες, όπως κρυπτογράφους και πρώιμους λάτρεις της τεχνολογίας. Η ελκυστικότητα του Bitcoin έγκειται στην ικανότητά του να διευκολύνει ασφαλείς, ανώνυμες συναλλαγές, παρακάμπτοντας τους παραδοσιακούς χρηματοοικονομικούς οργανισμούς. Με την πάροδο του χρόνου, καθώς το Bitcoin απέκτησε αξία και αναγνώριση, αναδύθηκε ένα ευρύτερο ενδιαφέρον, οδηγώντας σε καινοτομίες στον χώρο του blockchain.

Το 2011, εμφανίστηκαν άλλα κρυπτονομίσματα, εμπνευσμένα από την υποκείμενη τεχνολογία του Bitcoin. Το Litecoin, που δημιουργήθηκε από τον Charlie Lee, στόχευε σε ταχύτερους χρόνους συναλλαγών και πιο προσιτή διαδικασία εξόρυξης. Την ίδια περίοδο, το Ripple αναπτύχθηκε ως ένα δίκτυο πληρωμών που επικεντρώνεται στη διευκόλυνση διασυνοριακών συναλλαγών σε πραγματικό χρόνο μεταξύ χρηματοοικονομικών ιδρυμάτων.

Ενώ το 2015, το Ethereum εισήχθη από τον Vitalik Buterin, αλλάζοντας ριζικά το εύρος δυνατοτήτων της τεχνολογίας blockchain. Σε αντίθεση με το Bitcoin, που επικεντρωνόταν αποκλειστικά στο ψηφιακό νόμισμα, το Ethereum εισήγαγε τα έξυπνα συμβόλαια, δηλαδή αυτοεκτελούμενες συμβάσεις με τους όρους της συμφωνίας γραμμένους απευθείας σε κώδικα. Αυτή η καινοτομία επέτρεψε την ανάπτυξη αποκεντρωμένων εφαρμογών (dApps) στην πλατφόρμα του Ethereum, δημιουργώντας ένα εκτεταμένο οικοσύστημα υπηρεσιών βασισμένων στο blockchain.

Η ανάπτυξη της αγοράς κρυπτονομισμάτων οδήγησε σε μια έκρηξη αρχικών προσφορών νομισμάτων (ICOs) το 2017, καθώς νέα προγράμματα επιδίωξαν να αντλήσουν κεφάλαια μέσω πωλήσεων tokens. Αυτή η περίοδος σηματοδότησε την κορύφωση των κερδοσκοπικών επενδύσεων, οδηγώντας τόσο σε τεράστια κέρδη για τους πρώιμους επενδυτές όσο και στη δημιουργία εύλογων ανησυχιών από τις ρυθμιστικές αρχές λόγω των κινδύνων απάτης στην αγορά.

Στα επόμενα χρόνια, η υιοθέτηση των κρυπτονομισμάτων συνέχισε να επεκτείνεται. Μεγάλοι χρηματοοικονομικοί κολοσσοί και εταιρείες όπως η PayPal και η Tesla άρχισαν

να αποδέχονται τα κρυπτονομίσματα ως μέθοδο πληρωμής, ενώ οι κεντρικές τράπεζες ξεκίνησαν να εξετάζουν τα ψηφιακά νομίσματα κεντρικών τραπεζών (CBDCs) για τον εκσυγχρονισμό των χρηματοοικονομικών συστημάτων τους. Παρά τις διακυμάνσεις στις τιμές της αγοράς, τα κρυπτονομίσματα, κυρίως το Bitcoin και το Ethereum, έχουν καθιερωθεί ως μια νέα κατηγορία περιουσιακών στοιχείων.

Σήμερα, το οικοσύστημα των κρυπτονομισμάτων περιλαμβάνει χιλιάδες ψηφιακά νομίσματα, το καθένα με τη δική του μοναδική χρήση, από την αποκεντρωμένη χρηματοδότηση (DeFi) έως τα μη ανταλλάξιμα tokens (NFTs). Καθώς αυξάνεται η υιοθέτηση τους από το ευρύ κοινό, τα κρυπτονομίσματα συνεχίζουν να αμφισβητούν τα παραδοσιακά χρηματοοικονομικά συστήματα και προσφέρουν νέες δυνατότητες για τη χρήση του μελλοντικού του χρήματος.

1.4 Blockchain

Το Blockchain είναι μια αποκεντρωμένη, ψηφιακή βάση δεδομένων που καταγράφει συναλλαγές σε ένα δίκτυο υπολογιστών με τρόπο που εξασφαλίζει ότι τα δεδομένα είναι ασφαλή, διαφανή και αμετάβλητα. Κάθε "μπλοκ" περιέχει μια λίστα συναλλαγών, και μόλις επαληθευτεί, συνδέεται με το προηγούμενο μπλοκ, σχηματίζοντας έτσι μια "αλυσίδα". Αυτή η τεχνολογία διασφαλίζει ότι μόλις προστεθούν τα δεδομένα, δεν μπορούν να τροποποιηθούν χωρίς να αλλάξουν όλα τα επόμενα μπλοκ, καθιστώντας την συγκεκριμένη τεχνολογία, ιδιαίτερα ασφαλή.

Η τεχνολογία Blockchain παρουσιάστηκε για πρώτη φορά το 2008 από ένα άτομο ή ομάδα γνωστή ως Satoshi Nakamoto, μέσα από τη λευκή βίβλο του Bitcoin. Το blockchain του Bitcoin επιτρέπει συναλλαγές peer-to-peer χωρίς την ύπαρξη κεντρικής αρχής. Ενώ το Bitcoin έκανε γνωστή την τεχνολογία blockchain, το Ethereum ήταν αυτό, που παρουσιάστηκε το 2015 και πραγματικά διεύρυνε τις εφαρμογές του. Το Ethereum εισήγαγε τα έξυπνα συμβόλαια, τις αυτοεκτελούμενες συμφωνίες που είναι κωδικοποιημένες στο blockchain. Αυτή η δυνατότητα επέτρεψε τη δημιουργία των αποκεντρωμένων εφαρμογών (dApps) και οδήγησε σε καινοτομίες όπως στη αποκεντρωμένη χρηματοδότηση (DeFi) και τα μη ανταλλάξιμα tokens (NFTs).

Μέχρι το 2016, μεγάλες βιομηχανίες άρχισαν να εξερευνούν τις δυνατότητες του blockchain πέρα από τον χρηματοοικονομικό τομέα. Η ασφάλεια και η διαφάνεια του blockchain εφαρμόστηκαν σε τομείς όπως η διαχείριση εφοδιαστικής αλυσίδας, η υγειονομική περίθαλψη και τα κτηματομεσιτικά. Το 2017, η χρηματοδότηση προγραμμάτων, μέσω των αρχικών προσφορών νομισμάτων (ICOs), έγινε ένα ευρέως διαδεδομένο φαινόμενο, επεκτείνοντας έτσι το φάσμα των δυνατοτήτων του blockchain. Το Blockchain συνεχίζει να επεκτείνεται βρίσκοντας εφαρμογές σε ψηφιακά νομίσματα κεντρικών τραπεζών (CBDCs) και στην αποκεντρωμένη χρηματοδότηση (DeFi).

1.5 Πρόβλεψη στην αγορά των κρυπτονομισμάτων

Οι παραδοσιακές μέθοδοι πρόβλεψης, όπως το μοντέλο αυτοπαλινδρόμησης (AR), το μοντέλο κινητού μέσου όρου (MA) και το αυτοπαλινδρομικό μοντέλο κινητού μέσου όρου (ARMA), χρησιμοποιήθηκαν ευρέως για την πρόβλεψη της συμπεριφοράς των χρηματοπιστωτικών αγορών. Αυτά τα μοντέλα, μαζί με πιο προηγμένες μεθόδους, όπως το γενικευμένο αυτοπαλινδρούμενο μοντέλο υπό συνθήκες ετεροσκεδασιμότητας (GARCH), το μοντέλο του εκθετικά σταθμισμένου κινητού μέσου όρου (EWMA) και τα μοντέλα στοχαστικής μεταβλητότητας (SV), ήταν αποτελεσματικά σε σταθερές αγορές αλλά αντιμετώπιζαν δυσκολίες στην αντιμετώπιση της υψηλής μεταβλητότητας και την πολυπλοκότητας των αναδυόμενων αγορών, όπως αυτής των κρυπτονομισμάτων.

Καθώς οι αγορές έγιναν πιο ασταθείς, τα παραδοσιακά γραμμικά μοντέλα αποδείχθηκαν ανεπαρκή στις σύγχρονες προκλήσεις. Η άνοδος υβριδικών τεχνικών, όπως το προσαρμοστικό νευρό-ασαφές σύστημα (ANFIS) και το μοντέλο ασαφούς λογικής τύπου-2 (fuzzy type-2), προσέφεραν μια καλύτερη προσέγγιση, συνδυάζοντας τις δυνατότητες μηχανικής μάθησης των νευρωνικών δικτύων με τη λογική ενός ασαφούς συνόλου για τη διαχείριση της αβεβαιότητας και της μη γραμμικότητας των δεδομένων. Αυτά τα μοντέλα βρίσκονται στην αιχμή του δόρατος στον χώρο της πρόβλεψης των χρηματαγορών, ειδικά όταν εξετάζονται δυναμικά και αβέβαια περιβάλλοντα, όπως η αγορά κρυπτονομισμάτων.


1.6 Κρυπτονομίσματα υπό ανάλυση

Τα παρακάτω διαγράμματα, απεικονίζουν τις ημερήσιες τιμές κλεισίματος των εξεταζόμενων κρυπτονομισμάτων. Τα γραφήματα προέρχονται από το CoinMarketCap.com.

Bitcoin

Το Bitcoin είναι ένα συναινετικό δίκτυο που επιτρέπει τη χρήση ενός νέου συστήματος πληρωμών, με την ροή ψηφιακών χρημάτων. Είναι το πρώτο αποκεντρωμένο δίκτυο πληρωμών peer-to-peer που λειτουργεί με τους χρήστες του, χωρίς την ύπαρξη κεντρικής αρχής ή μεσαζόντων. Από την οπτική γωνία του χρήστη, το Bitcoin είναι παρόμοιο με μετρητά, δηλαδή είναι ψηφιακό χρήμα για το διαδίκτυο. Το Bitcoin μπορεί επίσης να θεωρηθεί το πιο εξέχον σύστημα τριπλής λογιστικής που υπάρχει. Μόνο 21 εκατομμύρια


Bitcoins θα δημιουργηθούν ή θα εξορυχθούν ποτέ. Αυτός ο περιορισμός έχει ενσωματωθεί στον κώδικα του Bitcoin από τον δημιουργό του, τον Satoshi.



Σχήμα 1: Οι διακυμάνσεις της τιμής του Bitcoin κατά τη διάρκεια των ετών.

Ethereum

Το Ether (ETH) είναι το εγγενές κρυπτονόμισμα της αλυσίδας μπλοκ Ethereum και αποτελεί βασικό συστατικό του οικοσυστήματος του δικτύου. Χρησιμοποιείται κυρίως για την κάλυψη των προμηθειών "gas fees", τα οποία απαιτούνται για την εκτέλεση συναλλαγών και για τη λειτουργία εφαρμογών στο δίκτυο του Ethereum. Πέρα από την διευκόλυνση των συναλλαγών, το ETH διαδραματίζει καθοριστικό ρόλο στην ασφάλιση του δικτύου μέσω του staking, όπου οι κάτοχοι "κλειδώνουν" τα ETH τους για να βοηθήσουν στην επικύρωση συναλλαγών και τη διατήρηση της αλυσίδας blockchain, λαμβάνοντας ανταμοιβές ως αντάλλαγμα. Αναφερόμενοι στην τιμή του Ethereum, αναφερόμαστε συγκεκριμένα στην αγοραία αξία του ETH, του ψηφιακού περιουσιακού στοιχείου του δικτύου.



Σχήμα 2: Οι διακυμάνσεις της τιμής του ETH κατά τη διάρκεια των ετών.

BNB

Το BNB τροφοδοτεί το οικοσύστημα του BNB Chain, λειτουργώντας ως το κορυφαίο token του συστήματος. Είναι διαπραγματεύσιμο όπως οποιοδήποτε κρυπτονόμισμα και χρησιμοποιείται από διάφορες εφαρμογές σε διάφορους τομείς. Το BNB Smart Chain (BSC), είναι μια αλυσίδα μπλοκ συμβατή με την Ethereum Virtual Machine (EVM), και ενισχύει το BNB Chain παρέχοντας δυνατότητες προγραμματισμού και αδιάκοπης διαλειτουργικότητας. Το BSC έχει σχεδιαστεί για να προσφέρει ένα περιβάλλον υψηλής απόδοσης, χαμηλής καθυστέρησης εργασιών και οικονομικά αποδοτικό, καθιστώντας τα ιδανικό για τις αποκεντρωμένες εφαρμογές (dApps) και στη διαχείριση ψηφιακών περιουσιακών στοιχείων, προωθώντας την καινοτομία και την επεκτασιμότητα εντός του οικοσυστήματος.



Σχήμα 3: Οι διακυμάνσεις της τιμής του BNB κατά τη διάρκεια των ετών.

SOLANA

Το SOL είναι το εγγενές νόμισμα του blockchain του Solana και εξυπηρετεί πολλές βασικές λειτουργίες μέσα στο δίκτυο. Χρησιμοποιείται για την πληρωμή τελών συναλλαγών, ενοικίασης λογαριασμών και διάφορων άλλων δραστηριοτήτων του δικτύου. Το ένα SOL υποδιαιρείται σε 1 δισεκατομμύριο μικρότερες μονάδες που ονομάζονται Lamports. Όπως στις χρηματοοικονομικές εφαρμογές χειρίζονται τα σεντ του αμερικανικού δολαρίου (USD), οι εφαρμογές του Solana λειτουργούν κυρίως με Lamports για συναλλαγές, αποθήκευση και άλλες λειτουργίες του συστήματος. Αυτή η δομή

εξασφαλίζει υψηλή ακρίβεια και αποδοτικότητα στη διαχείριση των μικροσυναλλαγών μέσα στο οικοσύστημα Solana.



Σχήμα 4: Οι διακυμάνσεις της τιμής του SOL κατά τη διάρκεια των ετών.

XRP

Το XRP είναι ένα ψηφιακό περιουσιακό στοιχείο που ανήκει στο XRP Ledger, μία ανοιχτού κώδικα, μη αδειοδοτημένη, αποκεντρωμένη τεχνολογία blockchain. Δημιουργήθηκε το 2012 ειδικευόμενο στις πληρωμές και για να μπορεί να ολοκληρώσει τις συναλλαγές στο ledger σε 3-5 δευτερόλεπτα. Δημιουργήθηκε για να είναι καλύτερο από το Bitcoin, ταχύτερο, φθηνότερο και πιο φιλικό προς το περιβάλλον από οποιοδήποτε άλλο ψηφιακό περιουσιακό στοιχείο. Το XRP μπορεί να μεταφερθεί απευθείας χωρίς την ανάγκη κεντρικού διαμεσολαβητή, καθιστώντας το έτσι ένα βολικό εργαλείο για τη γρήγορη και αποδοτική σύνδεση δύο διαφορετικών νομισμάτων. Ανταλλάσσεται

ελεύθερα στην ανοιχτή αγορά και χρησιμοποιείται στον πραγματικό κόσμο για τη διευκόλυνση διασυνοριακών πληρωμών και μικροσυναλλαγών.



Σχήμα 5: Οι διακυμάνσεις της τιμής του XRP κατά τη διάρκεια των ετών.

1.7 Στόχοι της εργασίας

Στη μελέτη αυτή, ο στόχος μας είναι να προβλέψουμε τις τιμές κλεισίματος των πέντε σημαντικότερων κρυπτονομισμάτων, συγκεκριμένα του Bitcoin, του Ethereum, του Solana, του Binance coin (BNB) και του XRP, με τη βοήθεια του προσαρμοστικού συστήματος νευρό-ασαφούς λογικής (ANFIS) και του μοντέλου ασαφούς λογικής τύπου-2 (fuzzy type-2). Η μελέτη αποσκοπεί στην παροχή ακριβών προβλέψεων στην ασταθή και δυναμική αγορά των κρυπτονομισμάτων και στη σύγκριση αυτών των προηγμένων μεθόδων με παραδοσιακά μοντέλα πρόβλεψης, όπως το μοντέλο αυτοπαλινδρόμησης (AR) και το αυτοπαλινδρομικό μοντέλο κινητού μέσου (ARMA), καθώς και με το πρώσο-τροφοδοτούμενο νευρωνικό δίκτυο (FNN). Επιπρόσθετα, το πεδίο αυτής της διατριβής περιλαμβάνει την ανάλυση ιστορικών δεδομένων τιμών για αυτά τα κορυφαία κρυπτονομίσματα. Η αλγοριθμική βελτιστοποίηση για το μοντέλο ασαφούς λογικής τύπου-2 γίνεται χρησιμοποιώντας τον αλγόριθμο σμήνους σωματιδίων (Particle Swarm-PSO). Οι βασικοί περιορισμοί της εργασίας περιλαμβάνουν την εξάρτηση από τα ιστορικά δεδομένα των τιμών των κρυπτονομισμάτων, την επικέντρωση σε μόνο πέντε κρυπτονομίσματα και την μη συμπερίληψη εξωτερικών παραμέτρων, όπως οι κανονιστικές αλλαγές.

1.8 Σύγχρονα και παραδοσιακά μοντέλα πρόβλεψης

Η πρόβλεψη των τιμών κρυπτονομισμάτων αποτελεί μια δύσκολη πρόκληση λόγω της υψηλής μεταβλητότητας και της πολυπλοκότητάς τους. Η ενότητα αυτή εξετάζει σωρεία μεθόδων πρόβλεψης, από παραδοσιακά στατιστικά μοντέλα έως τις προηγμένες τεχνικές μηχανικής μάθησης, εστιάζοντας στην αποτελεσματικότητά τους στην πρόβλεψη των τιμών των κρυπτονομισμάτων. Παρακάτω θα αναφερθούμε στα χαρακτηριστικά των προβλεπτικών μοντέλων, όπως το ARIMA, τα μοντέλα τυχαίου περιπάτου, τα νευρωνικά δίκτυα και τις υβριδικές προσεγγίσεις, προσφέροντας μια συνοπτική επισκόπηση των τρεχουσών πρακτικών πρόβλεψης.

Παραδοσιακά μοντέλα πρόβλεψης

1. **Αυτοπαλινδρομικό μοντέλο κινητού μέσου όρου (ARIMA):** Τα μοντέλα ARIMA βρίσκουν ευρεία εφαρμογή στην πρόβλεψη χρονοσειρών. Συνδυάζουν τις συνιστώσες του αυτοπαλινδρομικού μοντέλου (AR) και του κινητού μέσου (MA) για να μοντελοποιήσουν και να προβλέψουν μελλοντικές τιμές με βασιζόμενα στις παρατηρήσεις του παρελθόντος. Αν και είναι αποτελεσματικά στην εφαρμογή του για στατικές χρονοσειρές, τα μοντέλα ARIMA συνήθως δυσκολεύονται με τα μη-στατικά και ασταθή φύση δεδομένα των κρυπτονομισμάτων.
2. **Τυχαίος Περίπατος (RW):** Το μοντέλο τυχαίου περιπάτου, υποθέτει ότι οι μελλοντικές κινήσεις τιμών είναι ανεξάρτητες από τις προηγούμενες κινήσεις, υποδεικνύοντας ότι οι τιμές ακολουθούν μια στοχαστική διαδικασία. Αυτό το μοντέλο είναι απλοϊκό, αλλά παρέχει μια στοιχειώδη γραμμή σύγκρισης σε σχέση με τις πιο σύνθετες μεθόδους.

Μοντέλα μηχανικής μάθησης

1. **Πολυεπίπεδα νευρωνικά δίκτυα (MLP):** Τα δίκτυα MLP, είναι προοδευτικά νευρωνικά δίκτυα, χρησιμοποιούνται για την μοντελοποίηση μη γραμμικών σχέσεων στα δεδομένα. Έχουν εφαρμοστεί στην πρόβλεψη κρυπτονομισμάτων λόγω της ικανότητας του στο να συλλάβουν πολύπλοκα μοτίβα στις κινήσεις των τιμών τους.
2. **Δίκτυα μακράς βραχύχρονης μνήμης (LSTM):** Τα δίκτυα μακράς βραχύχρονης μνήμης (LSTM) είναι μια κατηγορία αναδρομικών νευρωνικών δικτύων (RNN) που έχουν σχεδιαστεί για να μοντελοποιήσουν αποτελεσματικά μια ακολουθία δεδομένων και να καταγράψουν τις μακροχρόνιες εξαρτήσεις τους. Τα LSTM είναι ιδιαίτερα κατάλληλα για εργασίες που αφορούν χρονοσειρές και στη πρόβλεψη ακολουθιών, όπως η πρόβλεψη τιμών μετοχών ή κρυπτονομισμάτων, λόγω της ικανότητάς τους να μαθαίνουν από μοτίβα σε εκτεταμένα χρονικά πλαίσια.
3. **Μηχανές στήριξης διανυσμάτων (SVM):** Το SVM είναι ένας τύπος αλγορίθμου επιβλεπόμενης μάθησης που χρησιμοποιείται για εργασίες ταξινόμησης και παλινδρόμησης. Λειτουργεί βρίσκοντας το βέλτιστο “υπερεπίπεδο” που χωρίζει

τις διάφορες κατηγορίες στο χώρο των χαρακτηριστικών, λαμβάνοντας υπόψη την μέγιστη απόσταση τους. Για τις εργασίες παλινδρόμησης, το SVM προσαρμόζεται ως ένα παλινδρομικό μοντέλο στήριξης διανυσμάτων (SVR), με σκοπό να προβλέπει συνεχείς τιμές, προσαρμόζοντας μια ευθεία γραμμή εντός ενός καθορισμένου περιθωρίου ανοχής.

Υβριδικά και προχωρημένα μοντέλα

- 1. Μοντελοποίηση σε level-set παραγόμενα από τα δεδομένα (LSM):** Η μοντελοποίηση σε level-set (LSM) χρησιμοποιείται για τη μοντελοποίηση και πρόβλεψη των τιμών των κρυπτονομισμάτων, καταγράφοντας κατά κύριο λόγο τις δυναμικές συμπεριφορές της αγοράς.
- 2. GARCH με μηχανική μάθηση:** Υβριδικά μοντέλα που συνδυάζουν το GARCH με τεχνικές μηχανικής μάθησης όπως το ANN και το HONN (νευρωνικό δίκτυο υψηλότερης τάξης) που ενισχύουν την ακρίβεια της πρόβλεψης της μεταβλητότητας.
- 3. Σταθμισμένα και επιμελή κανάλια μνήμης (WAMC):** Αυτό το μοντέλο “βαθιάς” μηχανικής μάθησης προβλέπει τις ημερήσιες τιμές και διακυμάνσεις των κρυπτονομισμάτων εκμεταλλευόμενο τις υπάρχουσες συσχετίσεις μεταξύ των κρυπτονομισμάτων.
- 4. Χαοτικό μεταβατικό ασαφές νευροταλαντωτικό δίκτυο τύπου-2 (CT2TFDNN):** Ένα προηγμένο μοντέλο πρόβλεψης που συνδυάζει ασαφή λογική τύπου-2 με μεταβατικές ασαφείς συναρτήσεις συμμετοχής, χαοτικής φύσης, για τη πρόβλεψη των χρονοσειρών.

Νευρό-ασαφής προσεγγίσεις

- 1. Προσαρμοστικό νευρό-ασαφές σύστημα (ANFIS):** Αυτή η προσέγγιση συνδυάζει τα νευρωνικά δίκτυα με την ασαφή λογική για να μοντελοποιήσει τις πολύπλοκες, μη γραμμικές σχέσεις των δεδομένων των κρυπτονομισμάτων. Το ANFIS χρησιμοποιεί έναν συνδυασμό συστημάτων ασαφούς λογικής και αλγορίθμων προσαρμοστικής μάθησης για να βελτιώσει την ακρίβεια πρόβλεψης. Θα αναλυθεί εκτενώς στην συνέχεια αυτής της εργασίας.

2. Υβριδικά νευρό-ασαφή μοντέλα

Αυτά τα μοντέλα συνδυάζουν το ANFIS με άλλες τεχνικές πρόβλεψης, όπως τους γενετικούς αλγόριθμους (GA) ή την αλγοριθμική βελτιστοποίηση μέσω σμήνους σωματιδίων (PSO), για να βελτιστοποιήσουν τους ασαφείς κανόνες και να αυξήσουν την απόδοση της πρόβλεψης. Υβριδικές τεχνικές πρόβλεψης όπως το PATSOS έχουν αποδείξει ότι ξεπερνούν τις απλούστερες προσεγγίσεις νευρωνικών δικτύων και νευρό-ασαφής λογικής, προσφέροντας βελτιωμένη ακρίβεια πρόβλεψης μέσω τεχνικών προσαρμοστικής μάθησης.

Κεφάλαιο-2: Μεθοδολογικό πλαίσιο

2.1 Ιστορική αναδρομή στη θεωρία της ασαφούς λογικής:

Η ασαφής λογική, παρουσιάστηκε από τον Lotfi A. Zadeh το 1965, εμφανίστηκε ως μια επαναστατική προσέγγιση για την αντιμετώπιση της αβεβαιότητας και των “μερικών αληθειών” στα πολύπλοκα συστήματα. Σε αντίθεση με την παραδοσιακή δυαδική λογική, η ασαφής λογική επιτρέπει τον καθορισμό των βαθμών συμμετοχής, οι οποίοι αναπαρίστανται στο πραγματικό διάστημα $[0,1]$, όπου το 0 σημαίνει «εντελώς ψευδές», το 1 αντιπροσωπεύει «εντελώς αληθές» και οι ενδιάμεσες τιμές αντιστοιχούν στις “μερικές αλήθειες”. Αυτή η ευελιξία την καθιστά ιδανική για προβλήματα του πραγματικού κόσμου, όπου η ακρίβεια είναι δύσκολο να επιτευχθεί.

Η ασαφής λογική κέρδισε έδαφος τη δεκαετία του 1980, όταν ιαπωνικές εταιρείες την εφάρμοσαν επιτυχώς στη βιομηχανική αυτοματοποίηση και στα καταναλωτικά προϊόντα. Μέχρι τη δεκαετία του 1990, η επιρροή της είχε εξαπλωθεί παγκοσμίως, επηρεάζοντας τομείς όπως τα συστήματα αυτοκινήτων, οι μηχανισμοί ελέγχου και τις οικιακές συσκευές. Στα τέλη της δεκαετίας του 1990, η ασαφής λογική προχώρησε περαιτέρω με την ενσωμάτωση νευρωνικών δικτύων, οδηγώντας την, στη δημιουργία νευρό-ασαφών συστημάτων, όπως το προσαρμοστικό νευρό-ασαφές σύστημα (ANFIS). Αυτή η σύνθεση επέτρεψε τη δυναμική προσαρμογή του μοντέλου, διευρύνοντας τις εφαρμογές της σε τομείς όπως η πρόβλεψη, η τεχνητή νοημοσύνη και τη ρομποτική.

Σήμερα, η ασαφής λογική συνεχίζει να εξελίσσεται και να εφαρμόζεται σε ποικίλους τομείς, από την πρόβλεψη κρυπτονομισμάτων μέχρι τα αυτόνομα συστήματα, συγκλίνοντας όλο και περισσότερο με τις σύγχρονες τεχνολογίες τεχνητής νοημοσύνης και μηχανικής μάθησης.

2.2 Επισκόπηση:

Η ασαφής λογική αποτελεί μια ευέλικτη προσέγγιση για την αντιμετώπιση της αβεβαιότητας και της ανακρίβειας σε πολύπλοκα συστήματα. Σε αντίθεση με την παραδοσιακή δυαδική λογική, η οποία ασχολείται με απόλυτες και σχετικές “αλήθειες” (0 ή 1). Η ασαφής λογική επιτρέπει την ύπαρξη των βαθμών αλήθειας, που κυμαίνονται από 0 έως 1. Αυτό της δίνει τη δυνατότητα να μοντελοποιεί προβλήματα του πραγματικού κόσμου όπου οι ακριβείς τιμές είναι δύσκολο να οριστούν. Στον πυρήνα της, η ασαφής λογική χρησιμοποιεί ασαφή σύνολα, τα οποία επιτρέπουν μερική συμμετοχή, που σημαίνει ότι ένα στοιχείο μπορεί να ανήκει σε ένα σύνολο σε κάποιο βαθμό. Οι συναρτήσεις συμμετοχής ορίζουν την έκταση αυτής της συμμετοχής, ενώ γλωσσικές μεταβλητές, όπως «ζεστό» ή «κρύο», αποτυπώνουν ασαφείς όρους. Οι ασαφείς πράξεις, όπως η ένωση (OR), η τομή (AND) και η συμπλήρωση (NOT), βοηθούν στον συνδυασμό και τη διαχείριση των ασαφών συνόλων. Τα ασαφή συστήματα εξαγωγής συμπερασμάτων (FIS) εφαρμόζουν ασαφείς κανόνες (if-then) για τη λήψη αποφάσεων, και τα αποτελέσματα συνήθως αποσαφηνίζονται στις εξόδους. Η ασαφής

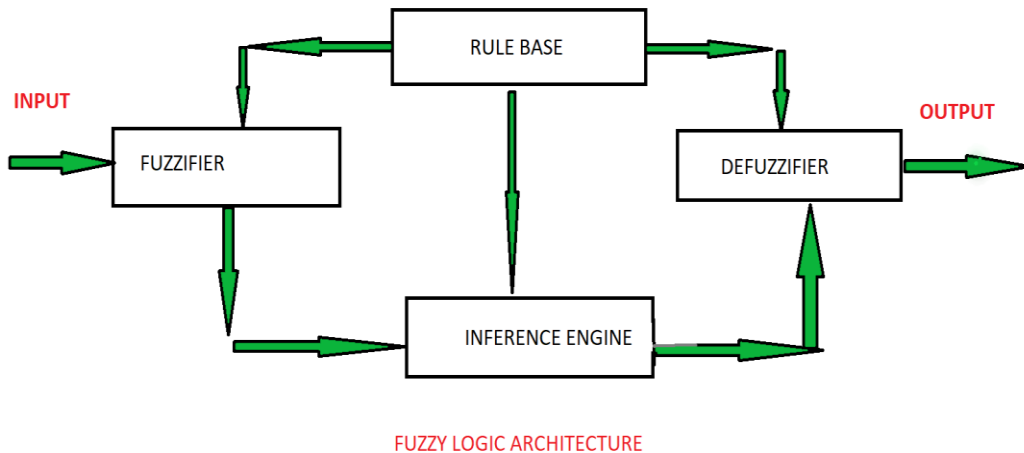
λογική έχει εξελιχθεί με την ενσωμάτωσή της σε νευρωνικά δίκτυα, σχηματίζοντας συστήματα νευρό-ασαφούς λογικής όπως το ANFIS, τα οποία προσαρμόζονται δυναμικά για τη βελτίωση της ακρίβειας πρόβλεψης.

Πλεονεκτήματα της ασαφούς λογικής:

1. Αντανάκλαση στον πραγματικό κόσμο: Η ασαφής λογική μοντελοποιεί καλύτερα τα προβλήματα του πραγματικού κόσμου σε σύγκριση με την κλασική λογική.
2. Χαμηλότερες απαιτήσεις σε εξαρτήματα υπολογιστών: Απαιτεί γενικά λιγότερο υλικό σε σύγκριση με την κλασική Boolean λογική.
3. Ανοχή στην Αβεβαιότητα: Οι αλγόριθμοι ασαφούς λογικής μπορούν να παρέχουν ακριβή αποτελέσματα ακόμη και με ασαφή ή ατελή δεδομένα.

Μειονεκτήματα της ασαφούς λογικής:

1. Ανάγκη για επικύρωση: Οι αλγόριθμοι ασαφούς λογικής απαιτούν εκτεταμένη επικύρωση και επαλήθευση για να διασφαλιστεί η ακρίβεια και η αξιοπιστία των αποτελεσμάτων τους.
2. Εξάρτηση από την εξειδίκευση: Τα αποτελεσματικά συστήματα ελέγχου ασαφούς λογικής εξαρτώνται σε μεγάλο βαθμό από την ανθρώπινη εξειδίκευση και γνώση.



Σχήμα 6: Τυπική δομή ενός συστήματος ασαφούς λογικής.

2.3 Ασαφή σύνολα:

Τα ασαφή σύνολα επεκτείνουν τη κλασική θεωρία συνόλων, επιτρέποντας στα στοιχεία τους να έχουν μεταβαλλόμενους βαθμούς συμμετοχής αντί για μια δυαδική κατηγοριοποίηση (αληθές/ψευδές). Σε ένα ασαφές σύνολο, κάθε στοιχείο συνδέεται με μια συνάρτηση συμμετοχής που αναθέτει μια τιμή μεταξύ 0 και 1, η οποία αντιπροσωπεύει τον βαθμό στον οποίο το στοιχείο ανήκει στο σύνολο. Αυτή η προσέγγιση αποτυπώνει την έμφυτη αοριστία και ανακρίβεια που υπάρχουν σε πραγματικές καταστάσεις, κάνοντάς την χρήσιμη για τη μοντελοποίηση πολύπλοκων και αβέβαιων συστημάτων. Τα ασαφή σύνολα είναι θεμελιώδη για την ασαφή λογική και χρησιμοποιούνται σε διάφορες εφαρμογές, όπως τα συστήματα ελέγχου και τις διαδικασίες λήψης αποφάσεων.

Μαθηματικός ορισμός ενός ασαφούς συνόλου:

Έστω X είναι το πεδίο αναφοράς (ένα σύνολο πιθανών στοιχείων). Ένα ασαφές σύνολο A στο X ορίζεται ως:

$$A = \{(x, \mu_A(x)) \mid x \in X\}$$

Όπου:

- x είναι στοιχείο του πεδίου X .
- $\mu_A(x)$ είναι η συνάρτηση συμμετοχής του ασαφούς συνόλου A , που αντιστοιχεί το x σε μια τιμή συμμετοχής στο διάστημα $[0,1]$.

Η συνάρτηση συμμετοχής $\mu_A(x)$ είναι συνάρτηση $\mu_A(x): X \rightarrow [0,1]$ που αναθέτει σε κάθε στοιχείο x έναν βαθμό συμμετοχής στο ασαφές σύνολο A . Η τιμή της $\mu_A(x)$ αντιπροσωπεύει τον βαθμό στον οποίο το x ανήκει στο A . Συγκεκριμένα:

1. $\mu_A(x)=0$ δείχνει ότι το x δεν ανήκει στο σύνολο A .
2. $\mu_A(x)=1$ δείχνει ότι το x ανήκει πλήρως στο σύνολο A .
3. Οι τιμές μεταξύ 0 και 1 δείχνουν μερική συμμετοχή.

Το ασαφές σύνολο A ορίζεται ως εξής:

$$A = \begin{cases} \sum_{x_i \in X} \mu_A(x_i)/x_i, & \text{για } X \text{ που ανήκει σε διακριτό διάστημα} \\ \int_X \mu_A(x_i)/x_i, & \text{για } X \text{ που ανήκει σε συνεχές διάστημα} \end{cases}$$

2.4 Συναρτήσεις συμμετοχής


Οι συναρτήσεις συμμετοχής στην ασαφή λογική, αντιστοιχίζουν κάθε στοιχείο από ένα πεδίο αναφοράς σε έναν βαθμό συμμετοχής μεταξύ 0 και 1, υποδεικνύοντας τον βαθμό στον οποίο το στοιχείο ανήκει στο ασαφές σύνολο. Αυτό επιτρέπει την ένταξη τους στις εξής κατηγορίες: το 0 σημαίνει καμία ένταξη, το 1 δηλώνει πλήρη ένταξη και οι τιμές μεταξύ 0 και 1 αντανακλούν διαφορετικούς βαθμούς ένταξης. Οι συναρτήσεις συμμετοχής μπορούν να έχουν διάφορα σχήματα, όπως τριγωνικό, τραπεζοειδές, γκαουσιανό ή σημειοειδές, ανάλογα με το ασαφές σύνολο που προσομοιώνεται. Είναι κρίσιμες για την ποσοτικοποίηση ασαφών εννοιών και τη βοήθεια στη λήψη αποφάσεων σε συστήματα ασαφούς συμπερασμάτων.

Παραμετροποίηση και διατύπωση των συναρτήσεων συμμετοχής

Τριγωνική συνάρτηση συμμετοχής:

$$\mu_A(x) = \begin{cases} 0 & \text{αν } x \leq a \\ \frac{x-a}{b-a} & \text{αν } a \leq x \leq b \\ \frac{c-x}{c-b} & \text{αν } b \leq x \leq c \\ 0 & \text{αν } x \geq c \end{cases}$$

Έστω ότι τα a , b and c αντιπροσωπεύουν τις συντεταγμένες x των τριών κορυφών της $\mu_A(x_i)$ σε ένα ασαφές σύνολο A (a : κάτω όριο and c : άνω όριο όπου ο βαθμός συμμετοχής είναι ίσος με 0, b : είναι το κέντρο όπου ο βαθμός συμμετοχής είναι ίσος με 1).




Σχήμα 7: Γραφική αναπαράσταση της τριγωνικής συνάρτησης συμμετοχής.

Τραπεζοειδής συνάρτηση συμμετοχής:

$$\mu_A(x) = \begin{cases} 0 & \text{αν } x < a \text{ ή } x > d \\ \frac{x-a}{b-a} & \text{αν } a \leq x \leq b \\ 1 & \text{αν } b < x \leq c \\ \frac{d-x}{d-c} & \text{αν } c < x \leq d \end{cases}$$

Έστω ότι τα a , b , c και d αναπαριστούν τις συντεταγμένες x της συνάρτησης συμμετοχής.




Σχήμα 8: Γραφική αναπαράσταση της τραπεζοειδούς συνάρτησης συμμετοχής.

Η Γκαουσιανή συνάρτηση συμμετοχής υπολογίζεται με τον παρακάτω τύπο:

$$\mu_A(x) = e^{-\frac{(x-c)^2}{2\sigma^2}}$$

Η γκαουσιανή συνάρτηση συμμετοχής συνήθως αναπαριστάτε ως Gaussian (x, c, s) όπου τα c, s αναπαριστούν τη μέση τιμή και τη τυπική απόκλιση.




Σχήμα 9: Γραφική αναπαράσταση της γκαουσιανής συνάρτησης συμμετοχής.

Γενικευμένη συνάρτηση συμμετοχής Bell:

$$\mu_A(x) = 1 / (1 + \left| \frac{x - c}{b} \right|^{2 \cdot b})$$

Μια γενικευμένη συνάρτηση συμμετοχής Bell έχει τρεις παραμέτρους: a – υπεύθυνη για το πλάτος της, c – υπεύθυνη για το κέντρο της και b – υπεύθυνη για τις κλίσεις της.




Σχήμα 10: Γραφική αναπαράσταση της γενικευμένης συνάρτησης συμμετοχής Bell.

Σιγμοειδής συνάρτηση συμμετοχής:

$$\mu_A(x) = 1/(1 + e^{-a*(x-c)})$$

Μια σιγμοειδής συνάρτηση συμμετοχής έχει δύο παραμέτρους: a – που είναι υπεύθυνη για την κλίση της, και στο σημείο διασταύρωσης $x = c$.



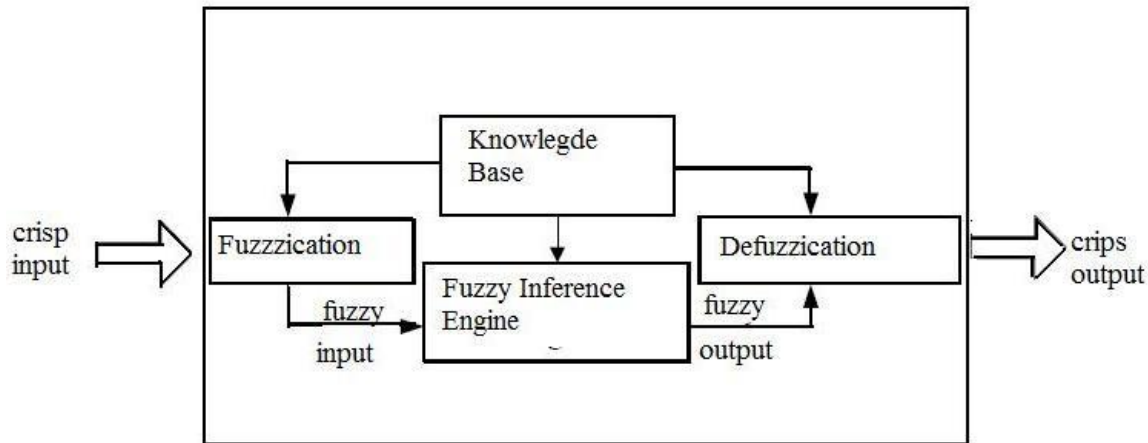
Σχήμα 11: Γραφική αναπαράσταση της σιγμοειδούς συνάρτησης συμμετοχής.

2.5 Ασαφή συστήματα εξαγωγής συμπερασμάτων (FIS)

Τα ασαφή συστήματα εξαγωγής συμπερασμάτων (FIS) είναι υπολογιστικά πλαίσια που χρησιμοποιούν την ασαφή λογική για να μοντελοποιήσουν και για να παίρνουν αποφάσεις σε σύνθετα συστήματα. Περιλαμβάνουν μια σειρά βασικών συστατικών όπως, την ασαφοποίηση, η οποία μετατρέπει τις εισόδους σε ασαφείς τιμές χρησιμοποιώντας συναρτήσεις συμμετοχής. Η βάση ασαφών κανόνων, η οποία περιέχει ασαφείς κανόνες αν-τότε που καθορίζουν τις σχέσεις εισόδου-εξόδου. Την ασαφής συνεπαγωγή, η οποία εφαρμόζει αυτούς τους κανόνες για να δημιουργήσει τα ασαφή αποτελέσματα και την αποσαφοποίηση, η οποία μετατρέπει το ασαφές αποτέλεσμα σε μια τελική τιμή. Οι τύποι FIS περιλαμβάνουν το μοντέλο Mamdani, γνωστό για την απλότητά του και την αποτελεσματικότητά του στα συστήματα ελέγχου, και το μοντέλο Sugeno, το οποίο χρησιμοποιείται συχνά σε προβλήματα βελτιστοποίησης λόγω της

άμεσης παραγωγής εξόδου. Τα FIS χρησιμοποιούνται εκτενώς σε επιστημονικά πεδία όπως, τα


συστήματα ελέγχου, τη λήψη αποφάσεων και την αναγνώριση προτύπων, προσφέροντας μια ισχυρή προσέγγιση για την αντιμετώπιση των αβεβαιοτήτων και των ανακρίβειών.



Σχήμα 12: Η βασική δομή ενός συστήματος ασαφούς εξαγωγής συμπερασμάτων (FIS).

Μοντέλο ασαφούς εξαγωγής συμπερασμάτων Mamdani


Το μοντέλο Mamdani, που αναπτύχθηκε από τον Ebrahim Mamdani το 1975, είναι ένα δημοφιλές σύστημα ασαφούς εξαγωγής συμπερασμάτων γνωστό για την απλότητά του και την αποτελεσματικότητά του σε εφαρμογές ελέγχου και λήψης αποφάσεων. Αποτελείται από τα εξής επίπεδα, την ασαφοποίηση (μετατροπή των εισόδων σε ασαφείς τιμές), βάση κανόνων (ασαφείς κανόνες αν-τότε), κινητήρα συμπερασμάτων (εφαρμογή κανόνων για τη δημιουργία ασαφών εξόδων) και αποσαφοποίηση (μετατροπή του συγκεντρωμένου ασαφούς συνόλου σε μια τελική τιμή).



Σχήμα 13: Μοντέλο ασαφούς εξαγωγής συμπερασμάτων Mamdani.

Μοντέλο ασαφούς εξαγωγής συμπερασμάτων Sugeno

Το μοντέλο Sugeno, αναπτύχθηκε από τον Michio Sugeno το 1985, είναι ένα σύστημα ασαφούς εξαγωγής συμπερασμάτων που επικεντρώνεται στη βελτιστοποίηση της απόδοσης του συστήματος. Διαφέρει από το μοντέλο Mamdani καθώς χρησιμοποιεί τον σταθμισμένο μέσο όρο ή έναν γραμμικό συνδυασμό των εξόδων των κανόνων, αντί να παράγει το ίδιο τα ασαφή αποτελέσματα. Το μοντέλο Sugeno περιλαμβάνει ασαφοποίηση, βάση κανόνων με κανόνες αν-τότε, κινητήρα συμπερασμάτων και αποσαφοποίηση. Υπολογίζει άμεσα τα ακριβή αποτελέσματα με βάση τα βάρη των κανόνων και τις τιμές των εισόδων.



Σχήμα 14: Μοντέλο ασαφούς εξαγωγής συμπερασμάτων Sugeno.

2.6 Εφαρμογές της ασαφούς λογικής

Η ασαφής λογική εφαρμόζεται ευρέως σε διάφορους τομείς λόγω της ικανότητάς της να χειρίζεται αβεβαιότητες και ανακρίβειες των δεδομένων. Στα συστήματα ελέγχου, χρησιμοποιείται για τη διαχείριση σύνθετων διαδικασιών όπως η ρύθμιση θερμοκρασίας και η αυτοματοποιημένη οδήγηση. Στα οικονομικά, η ασαφής λογική βοηθά στη μοντελοποίηση και πρόβλεψη τάσεων της αγοράς, προσφέροντας αξιόπιστες προβλέψεις ακόμα και υπό ασταθείς συνθήκες. Η ενσωμάτωση της ασαφούς λογικής με τα νευρωνικά δίκτυα οδήγησε στην ανάπτυξη συστημάτων νευρο-ασαφούς λογικής, όπως το ANFIS, τα οποία συνδυάζουν την προσαρμοστικότητα των νευρωνικών δικτύων με την ερμηνευσιμότητα της ασαφούς λογικής. Αυτή η συνένωση ενισχύει την ακρίβεια των προβλέψεων και τις ικανότητες λήψης αποφάσεων, ιδιαίτερα στην πρόβλεψη σύνθετων οικονομικών φαινομένων. Εκμεταλλευόμενα την ασαφή λογική και τα νευρωνικά δίκτυα, αυτά τα συστήματα παρέχουν ένα ισχυρό πακέτο εργαλείων για την επίλυση πραγματικών προβλημάτων με μεγαλύτερη ακρίβεια και ευελιξία.

2.7 Τεχνητά νευρωνικά δίκτυα

Ιστορική αναδρομή:

Τα Τεχνητά Νευρωνικά Δίκτυα (ANNs) πρωτοεμφανίστηκαν τη δεκαετία του 1940, όταν οι Warren McCulloch και Walter Pitts ανέπτυξαν το πρώτο μαθηματικό μοντέλο ενός νευρώνα, θέτοντας τα θεμέλια για την έρευνα στα νευρωνικά δίκτυα. Τα ANNs είναι αφηρημένοι, απλοποιημένοι προσομοιωτές του νευρωνικού δικτύου του ανθρώπινου εγκεφάλου (Neocleous και Schizas, 2002 και Dwivedi, 2016). Το 1958, ο Frank Rosenblatt εισήγαγε τον Perceptron, ένα μονοστρωματικό νευρωνικό δίκτυο που μπορούσε να κατατάξει εισόδους σε δύο κατηγορίες, σηματοδοτώντας ένα σημαντικό ορόσημο στην ανάπτυξη των ANNs. Το 1986, οι David Rumelhart και Geoffrey Hinton καθιέρωσαν τον αλγόριθμο οπισθοδιάδοσης (backpropagation), ο οποίος επέτρεψε την εκπαίδευση πολυστρωματικών δικτύων, τα οποία πλέον αναγνωρίζονται ως “βαθιά” μάθηση. Από τη δεκαετία του 2010, οι πρόοδοι στο τεχνητό υλικό (GPU) και η διαθεσιμότητα δεδομένων έχουν αναζωογονήσει το ενδιαφέρον για την έρευνα των ANNs, ειδικά στις τεχνικές “βαθιάς” μάθησης, οδηγώντας σε σύγχρονες εφαρμογές τεχνητής νοημοσύνης όπως η αναγνώριση εικόνας, η επεξεργασία φυσικής γλώσσας και τα συστήματα παιχνιδιών.

Επισκόπηση:

Τα Τεχνητά Νευρωνικά Δίκτυα (ANNs) είναι υπολογιστικά μοντέλα εμπνευσμένα από τη δομή και τη λειτουργία του ανθρώπινου εγκεφάλου. Αποτελούνται από στρώματα διασυνδεδεμένων “νευρώνων” (κόμβων) που συνεργάζονται για να επεξεργαστούν τα δεδομένα εισόδου. Σκοπός τους είναι να μάθουν πρότυπα και να κάνουν προβλέψεις ή λήψη αποφάσεων. Κάθε νευρώνας λαμβάνει μια τουλάχιστον είσοδο, εφαρμόζει έναν μαθηματικό μετασχηματισμό χρησιμοποιώντας ένα βάρος και μια προκατάληψη (bias) και παράγει μια έξοδο, η οποία περνά στο επόμενο στρώμα.

Απαρτίζονται από:


1. Επίπεδο εισόδου: Σε αυτό το επίπεδο το δίκτυο λαμβάνει τα δεδομένα του. Κάθε κόμβος (νευρώνας) στο στρώμα εισόδου αντιπροσωπεύει ένα χαρακτηριστικό από το σύνολο δεδομένων εισόδου. Ο αριθμός των νευρώνων στο στρώμα εισόδου αντιστοιχεί στον αριθμό των χαρακτηριστικών ή μεταβλητών στο σύνολο δεδομένων.
2. Κρυμμένα επίπεδα: Επεξεργάζονται τις εισόδους από το προηγούμενο στρώμα μέσω μιας σειράς βαρών και συναρτήσεων ενεργοποίησης, μαθαίνοντας εσωτερικές αναπαραστάσεις των δεδομένων.
3. Επίπεδο εξόδου: Το στρώμα εξόδου παρέχει την τελική πρόβλεψη ή ταξινόμηση με βάση τα δεδομένα που επεξεργάστηκαν τα κρυφά στρώματα. Ο αριθμός των νευρώνων στο στρώμα εξόδου εξαρτάται από την εκάστοτε εργασία.

Η ισχύς των τεχνητών νευρωνικών δικτύων (ANNs) έγκειται στην ικανότητά τους να μαθαίνουν από δεδομένα μέσω της εκπαίδευσης, η οποία συχνά χρησιμοποιεί αλγορίθμους όπως την οπισθοδιάδοση (backpropagation). Κατά τη φάση της εκπαίδευσης, το δίκτυο προσαρμόζει επαναληπτικά τα βάρη των συνδέσεων του, για να ελαχιστοποιήσει τα σφάλματα και να βελτιώσει την ακρίβεια των προβλέψεων. Αυτή η προσαρμοστικότητα επιτρέπει στα ANNs να μοντελοποιήσουν αποτελεσματικά τις σύνθετες και μη γραμμικές σχέσεις των δεδομένων.

Τα τεχνητά νευρωνικά δίκτυα (ANNs) ταξινομούνται με ποικίλους τύπους βάσει της αρχιτεκτονικής τους, όπως:

1. Πρώσο-τροφοδοτούμενα νευρωνικά δίκτυα (FNNs): Η πληροφορία σε αυτά τα συστήματα ρέει προς μία κατεύθυνση, από την είσοδο προς την έξοδο. Το κύριο πλεονέκτημά τους είναι η ικανότητα προσέγγισης μη γραμμικών συναρτήσεων, ακόμη και αν τα δεδομένα περιέχουν “θόρυβο” (noisy data). Το σύστημα του πρώσο-τροφοδοτούμενου νευρωνικού δικτύου αποτελείται από ένα επίπεδο εισόδου που χρησιμοποιείται για τη λήψη σημάτων, ένα κρυφό επίπεδο για την επεξεργασία τους και ένα επίπεδο εξόδου για τον τελικό υπολογισμό προβλεπόμενου χρονικού σήματος (Salim Lahmiri και Stelios Bekiros, 2020).
2. Επαναλαμβανόμενα νευρωνικά δίκτυα (RNNs): Η πληροφορία ρέει προς τα πίσω, επιτρέποντάς τους να διαχειρίζονται ακολουθίες, όπως δεδομένα χρονοσειρών ή γλώσσας. Σε αντίθεση με τα συμβατικά νευρωνικά δίκτυα, όπου οι είσοδοι και οι έξοδοι είναι ανεξάρτητες μεταξύ τους, στα RNNs οι έξοδοι ενός σταδίου γίνονται είσοδοι στο επόμενο στάδιο. Λόγω αυτής της ιδιότητας, τα RNNs έχουν εξαιρετική ικανότητα να εξάγουν χρονικά χαρακτηριστικά των δεδομένων. Ένα RNN μοιάζει με πολλαπλά νευρωνικά δίκτυα διατεταγμένα το ένα δίπλα στο άλλο, με την έξοδο του ενός δικτύου να αποτελεί είσοδο για το επόμενο (Mohil Maheshkumar et al., 2020).
3. Συνελικτικά νευρωνικά δίκτυα (CNNs): Τα CNN (Rawat και Wang, 2017) είναι ένας νέος τύπος νευρωνικών δικτύων που βασίζονται σε συνελικτικά επίπεδα και χαρακτηρίζονται από την ικανότητά τους να μαθαίνουν την εσωτερική αναπαράσταση των δεδομένων χρονοσειρών (Livieris, 2020). Τα συνελικτικά επίπεδα εφαρμόζουν συνελικτικές λειτουργίες μεταξύ των ακατέργαστων δεδομένων εισόδου και χρησιμοποιούν τους συνελικτικούς πυρήνες για την παραγωγή νέων τιμών χαρακτηριστικών.
4. Βαθιά νευρωνικά δίκτυα (DNNs): Δίκτυα αποτελούμενα από πολλά κρυφά επίπεδα, καθιστώντας τα αποτελεσματικά στην επίλυση πιο σύνθετων εργασιών όπως η αναγνώριση εικόνας και η επεξεργασία φυσικής γλώσσας. Ένα βαθύ νευρωνικό δίκτυο είναι στην ουσία ένα τεχνητό νευρωνικό δίκτυο που

ενσωματώνει πολλά επίπεδα μεταξύ των επιπέδων εισόδου και εξόδου του δικτύου (Gopinath M. et al., 2023).



Σχήμα 15: Η αρχιτεκτονική ενός τεχνητού νευρωνικού δικτύου.

Εκπαίδευση του τεχνητού νευρωνικού δικτύου:

Η εκπαίδευση ενός τεχνητού νευρωνικού δικτύου (ANN) ακολουθεί την ακόλουθη διαδικασία: Αρχικά, τα βάρη και οι παράμετροι του δικτύου ορίζονται τυχαία. Κατά τη διάρκεια της εμπροσθοδιάδοσης (forward propagation), τα δεδομένα εισόδου περνούν μέσω των επιπέδων, παράγοντας μια έξοδο. Στη συνέχεια, μια συνάρτηση απώλειας (loss function) υπολογίζει το σφάλμα μεταξύ της προβλεπόμενης εξόδου και της πραγματικής τιμής στόχου. Στη φάση της οπισθοδιάδοσης (backpropagation), το παραγόμενο σφάλμα διαδίδεται προς τα πίσω μέσω του δικτύου, για τον υπολογισμό των παραγώγων, οι οποίες δείχνουν πόσο πρέπει να προσαρμοστεί κάθε βάρος. Χρησιμοποιώντας τη μέθοδο gradient descent, τα βάρη ενημερώνονται για να μειώσουν το σφάλμα. Αυτή η διαδικασία επαναλαμβάνεται σε πολλές επαναλήψεις (epochs), βελτιώνοντας σταδιακά την ακρίβεια του δικτύου καθώς μαθαίνει από τα δεδομένα.

Η εκπαίδευση του τεχνητών νευρωνικών δικτύων (ANNs) μπορεί να χωριστεί σε δύο κατηγορίες: εποπτευόμενη και μη εποπτευόμενη εκπαίδευση:

1. **Εποπτευόμενη μάθηση:** Σε αυτή την προσέγγιση, το δίκτυο εκπαιδεύεται με δεδομένα σε “ετικέτες”, δηλαδή κάθε είσοδος έχει το αντίστοιχο σωστό αποτέλεσμα (ετικέτα). Κατά την εκπαίδευση, το τεχνητό νευρωνικό δίκτυο μαθαίνει να αντιστοιχεί την είσοδο στο σωστό αποτέλεσμα ελαχιστοποιώντας το σφάλμα με τη χρήση μεθόδων όπως η οπισθοδιάδοση.
2. **Μη εποπτευόμενη μάθηση:** Σε αυτή την προσέγγιση, το δίκτυο εκπαιδεύεται με μη “ετικετοποιημένα” δεδομένα, και ο στόχος είναι να βρει κρυφά μοτίβα ή δομές στα δεδομένα χωρίς τις προεπιλεγμένες ετικέτες. Το δίκτυο μαθαίνει να αναγνωρίζει ομάδες, μοτίβα ή χαρακτηριστικά από μόνο του.

Δομή της εκπαίδευσης:

1. Εμπροσθοδιάδοση:

Κατά την εμπροσθοδιάδοση, τα δεδομένα εισόδου τροφοδοτούνται στο νευρωνικό δίκτυο όπου πραγματοποιούνται υπολογισμοί από το ένα επίπεδο στο άλλο, μέχρι να παραχθεί το αποτέλεσμα. Κάθε νευρώνας στο δίκτυο λαμβάνει σήματα εισόδου, εφαρμόζει μια συγκεκριμένη συνάρτηση ενεργοποίησης σε αυτά, και περνά το αποτέλεσμα στους νευρώνες του επόμενου επιπέδου. Αυτή η διαδικασία συνεχίζεται μέχρι να παραχθεί το τελικό αποτέλεσμα. Η εμπροσθοδιάδοση είναι υπεύθυνη για την πραγματοποίηση προβλέψεων με βάση τις τρέχουσες παραμέτρους (βάρη και προκαταλήψεις) του δικτύου. Μαθηματικά, για έναν μεμονωμένο νευρώνα, το αποτέλεσμα y είναι ένα επίπεδο που μπορεί να εκφραστεί ως:

$$y = f(\sum (w_i * x_i) + b)$$

- w_i είναι τα βάρη.
- x_i είναι οι είσοδοι.
- b είναι η προκατάληψη.
- f είναι η συνάρτηση συμμετοχής.

Συνάρτηση απωλειών (υπολογισμός σφαλμάτων):

Μόλις παραχθεί το αποτέλεσμα, το επόμενο βήμα είναι η αξιολόγηση της απόδοσης του μοντέλου συγκρίνοντας τις προβλέψεις του, με τις πραγματικές τιμές στόχου από τα δεδομένα εκπαίδευσης. Αυτό γίνεται χρησιμοποιώντας μια συνάρτηση απώλειας, γνωστή και ως συνάρτηση κόστους, η οποία ποσοτικοποιεί τη διαφορά μεταξύ των προβλεπόμενων αποτελεσμάτων και της πραγματικής κατάστασης. Συναρτήσεις απώλειας περιλαμβάνουν σφάλματα όπως, το μέσο τετραγωνικό σφάλμα (MSE) για προβλήματα παλινδρόμησης και την απώλεια διασταυρούμενης εντροπίας για καθήκοντα ταξινόμησης. Ο στόχος κατά την εκπαίδευση είναι να ελαχιστοποιηθεί αυτή η συνάρτηση απώλειας, βελτιώνοντας έτσι την ακρίβεια του μοντέλου. Μαθηματικά, το

MSE και οι συναρτήσεις απώλειας διασταυρούμενης εντροπίας μπορούν να εκφραστούν ως:

$$\text{MSE} = \left(\frac{1}{N}\right) * \sum_{i=1}^N (y_i - \hat{y}_i)^2$$

- N είναι ο αριθμός των δεδομένων.
- y_i είναι η πραγματική τιμή.
- \hat{y}_i είναι η εκτιμώμενη τιμή.

Cross-Entropy = $-\frac{1}{N} * \sum_{i=1}^N [y_i * \log(\hat{y}_i) + (1 - y_i) * \log(1 - \hat{y}_i)]$,για τα δυαδικά προβλήματα:

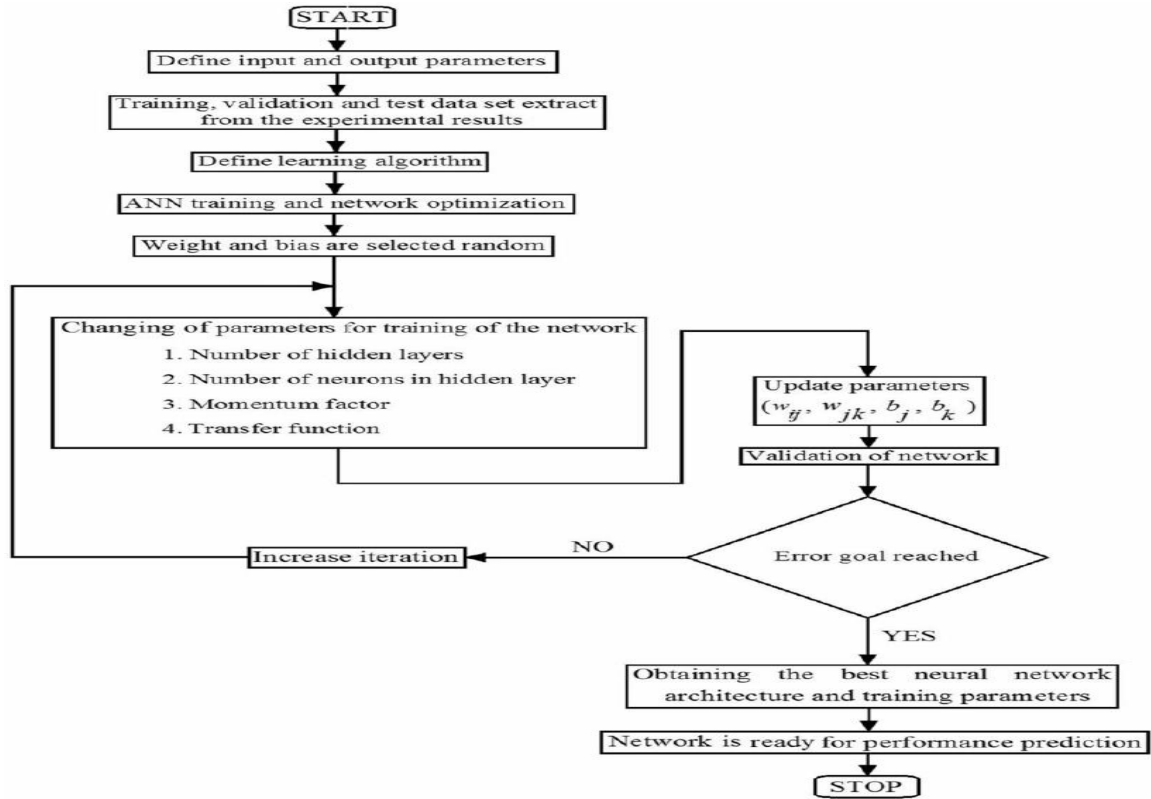
- N είναι ο αριθμός των δειγμάτων.
- y_i είναι η πραγματική ετικέτα (0 or 1).
- \hat{y}_i είναι η εκτιμώμενη πιθανότητα θετικής κλάσης.

Cross-Entropy = $-\sum_{i=1}^C y_i * \log(\hat{y}_i)$, για τα προβλήματα πολυταξικής ταξινόμησης.

Οπισθοδιάδοση:

Μετά τον υπολογισμό της συνάρτησης απώλειας, το δίκτυο προσαρμόζει τις εσωτερικές παραμέτρους του, συγκεκριμένα τα βάρη και τις προκαταλήψεις, προκειμένου να ελαχιστοποιήσει την απώλεια και να βελτιώσει την συνολική απόδοση. Η οπισθοδιάδοση, είναι μια διαδικασία ενημέρωσης αυτών των παραμέτρων υπολογίζοντας το βαθμό της συνάρτησης απώλειας ως προς τη κάθε παράμετρο. Αυτό περιλαμβάνει την προώθηση του σφάλματος προς τα πίσω μέσω του δικτύου, από το ένα επίπεδο στο άλλο, χρησιμοποιώντας τεχνικές όπως αυτή του κανόνα της αλυσίδας (chain rule). Στη συνέχεια, οι κλίσεις χρησιμοποιούνται για την ενημέρωση των παραμέτρων χρησιμοποιώντας τους αλγορίθμους βελτιστοποίησης όπως την gradient descent ή τις παραλλαγές της. Προσαρμόζοντας επαναληπτικά τις παραμέτρους με βάση


τις υπολογισμένες βαθμίδες, το δίκτυο μαθαίνει σταδιακά να κάνει πιο ακριβείς προβλέψεις και να ελαχιστοποιεί το σφάλμα.



Σχήμα 16: Διάγραμμα ροής της εκπαιδευτικής διαδικασίας ενός τεχνητού νευρωνικού δικτύου.

Ένας μικρός αριθμός εποχών της εκπαίδευσης συνήθως οδηγεί σε μη επιθυμητά αποτελέσματα, ενώ αντίθετα, ένας μεγάλος αριθμός εποχών μπορεί να προκαλέσει “υπερπροσαρμογή” (overfitting) και να απαιτεί σημαντικό υπολογιστικό χρόνο. Η

υπερπροσαρμογή συμβαίνει όταν το νευρωνικό δίκτυο προσαρμόζεται πολύ καλά στα δεδομένα εκπαίδευσης και μόνο σε αυτά τα δεδομένα.



Σχήμα 17: Παραδείγματα εκπαιδευμένων τεχνητών νευρωνικών δικτύων.

2.8 Προσαρμοστικά δίκτυα

Τα προσαρμοστικά δίκτυα είναι στη ουσία υπολογιστικές δομές σχεδιασμένα να τροποποιούν τις εσωτερικές τους παραμέτρους ως “αντίδραση” στα δεδομένα εισόδου, επιτρέποντάς τους να βελτιώνουν τις επιδόσεις τους με την πάροδο του χρόνου. Κάθε προσαρμοστικό δίκτυο αποτελείται από επίπεδο κόμβων, όπου κάθε κόμβος εκτελεί μια συγκεκριμένη λειτουργία ή υπολογισμό. Αυτοί οι κόμβοι συνδέονται μεταξύ τους μέσω συνδέσμων, οι οποίοι έχουν ορισμένο βάρος που καθορίζει τη δύναμη της σύνδεσης. Η διαδικασία προσαρμογής περιλαμβάνει την τροποποίηση αυτών των βαρών με βάση της ανατροφοδότησης του συστήματος, χρησιμοποιώντας αλγόριθμους εκμάθησης όπως η καθοδική κλίση (gradient descent) ή και τεχνικές βελτιστοποίησης. Η ανατροφοδότηση έρχεται με τη μορφή σφαλμάτων που υπολογίζονται κατά την εκπαίδευση, τα οποία υποδεικνύουν τη διαφορά μεταξύ της πραγματικής εξόδου και της επιθυμητής εξόδου. Στα προσαρμοστικά δίκτυα, υπάρχουν δύο βασικές φάσεις: η φάση της εμπροσθοδιάδοσης και η φάση της οπισθοδιάδοσης. Στη φάση της εμπροσθοδιάδοσης, η είσοδος επεξεργάζεται μέσω των επιπέδων του δικτύου για να παραχθεί μια έξοδος. Στη φάση της οπισθοδιάδοσης, τα σήματα των σφαλμάτων προωθούνται πίσω, μέσω του δικτύου και τα βάρη αναπροσαρμόζονται για να ελαχιστοποιηθεί το σφάλμα.

2.9 Προσαρμοστικό νευρό-ασαφές σύστημα συμπερασμάτων - ANFIS

Το προσαρμοστικό νευρό-ασαφές σύστημα συμπερασμάτων (ANFIS) είναι ένα υβριδικό μοντέλο που συνδυάζει τα πλεονεκτήματα των νευρωνικών δικτύων και της ασαφούς λογικής. Λειτουργεί ως ένα δίκτυο νευρώνων με δυνατότητες αυτοεκπαίδευσης, προσαρμόζοντας τις παραμέτρους του, για να βελτιστοποιήσει την απόδοση του. Το ANFIS αξιοποιεί ένα σύστημα βασισμένο σε κανόνες ασαφούς λογικής, χρησιμοποιώντας κανόνες IF-THEN για να προσεγγίσει σύνθετες και μη γραμμικές συναρτήσεις. Αυτή η προσέγγιση του επιτρέπει να διαχειρίζεται αποτελεσματικά την αβεβαιότητα και την ασάφεια, ενώ τα νευρωνικά δίκτυα διευκολύνουν τη μάθηση και τη βελτίωση μέσω της εκπαίδευσης. Η συνέργεια αυτών των μεθόδων καθιστά το ANFIS ένα ισχυρό εργαλείο για εφαρμογές όπως η αναγνώριση μοτίβων, ο έλεγχος συστημάτων και η πρόβλεψη.

2.10 Αρχιτεκτονική του ANFIS

Η αρχιτεκτονική του προσαρμοστικού συστήματος συμπερασμάτων νευρό-ασαφούς λογικής (ANFIS) συνήθως αποτελείται από πέντε επίπεδα, συνδυάζοντας τόσο τις αρχές των νευρωνικών δικτύων όσο και της ασαφούς λογικής. Στην συνέχεια, θα αναφερθούμε στη δομή του συστήματος ANFIS τύπου Sugeno με δύο εισόδους x , y και μία έξοδο f . Εάν οι κανόνες είναι οι εξής (Ali Mehrban και Pegah Ahadian, 2023):

Rule 1: *If x is A_1 and y is B_1 then $f_1 = p_1 * x + q_1 * y + r_1$*

Rule 2: *If x is A_2 and y is B_2 then $f_2 = p_2 * x + q_2 * y + r_2$*

Τα επίπεδα του συστήματος ANFIS είναι τα ακόλουθα:

Επίπεδο 1 - Επίπεδο εισόδου (ασαφοποίηση): Το πρώτο επίπεδο λαμβάνει τα δεδομένα εισόδου και στο τέλος καθορίζει τις συναρτήσεις συμμετοχής, καθορίζοντας τον βαθμό συμμετοχής για κάθε είσοδο στα ασαφή σύνολα. Κάθε κόμβος σε αυτό το επίπεδο αντιπροσωπεύει μια συνάρτηση συμμετοχής. Εάν υποθέσουμε ότι x_i , η είσοδος, η συνάρτηση συμμετοχής εκφράζεται ως $\mu_{A_i}(x_i)$, όπου A_i είναι ένα ασαφές σύνολο. Ουσιαστικά μετατρέπει τα δεδομένα εισόδου σε ασαφή σύνολα.

Επίπεδο 2 – Επίπεδο κανόνων: Το δεύτερο επίπεδο του συστήματος εφαρμόζει κανόνες ασαφούς λογικής πολλαπλασιάζοντας τις τιμές συμμετοχής από το Επίπεδο 1 για να υπολογίσει τη δύναμη ενεργοποίησης του κάθε κανόνα. Αντιστοιχεί το μέρος "αν" των κανόνων, που ονομάζεται το "επίπεδο κανόνων". Κάθε κόμβος σε αυτό το επίπεδο αντιπροσωπεύει έναν ασαφή κανόνα.

Σε περίπτωση που οι δύο εισοδοί 2 είναι x_1 και x_2 , η δύναμη του κανόνα i είναι $w_i = \mu_{A_1}(x_1) * \mu_{A_2}(x_2)$

Επίπεδο 3 – Επίπεδο κανονικοποίησης: Το τρίτο επίπεδο κανονικοποιεί την έξοδο του δεύτερου επιπέδου. Κάθε κόμβος κανονικοποιεί τη δύναμη ενεργοποίησης ενός συγκεκριμένου κανόνα.

Η κανονικοποιημένη δύναμη δίνεται από τον παρακάτω μαθηματικό τύπο $\overline{w_i} = \frac{w_i}{\sum_{i=1}^n w_i}$

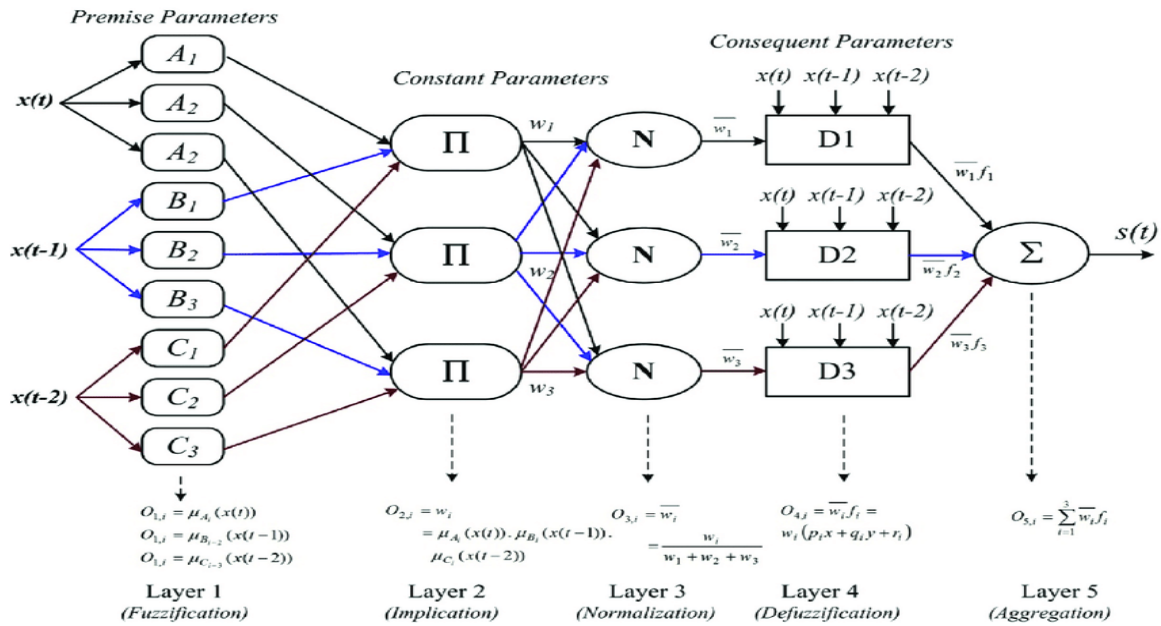
Επίπεδο 4 – Επίπεδο ασαφοποίησης: Το τέταρτο επίπεδο ασαφοποιεί τις τιμές που δίνονται από το τρίτο επίπεδο. Χαρτογραφεί την ασαφή έξοδο σε μια σαφή τιμή χρησιμοποιώντας μια γραμμική συνδυαστική των εισόδων και των παραμέτρων του κανόνα. Κάθε κόμβος σε αυτό το επίπεδο υπολογίζει τη συνεισφορά κάθε κανόνα στην έξοδο.

Η έξοδο του κάθε κόμβου υπολογίζεται ως εξής $w_i * f_i = w_i * (p_i * x + q_i * y + r_i)$, όπου {p, q, r} είναι οι παράμετροι που θα “μαθευτούν”.

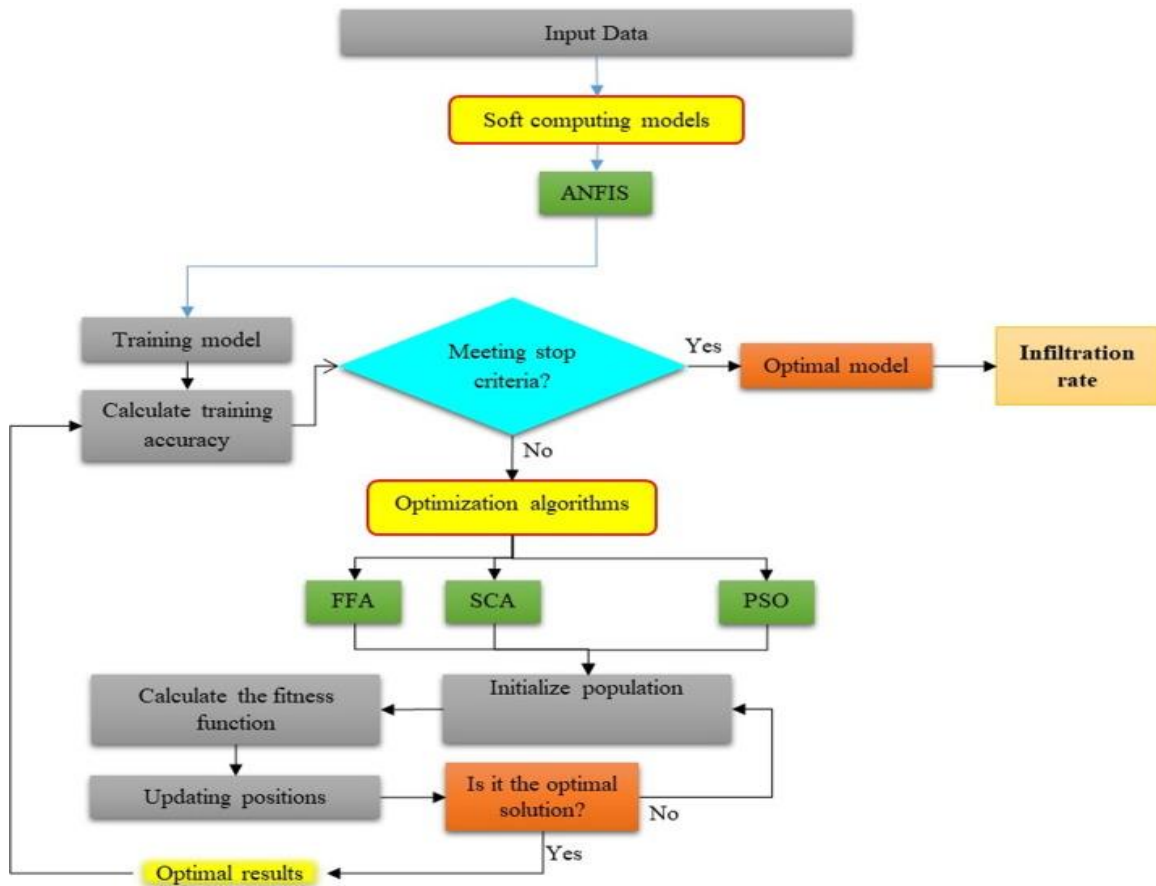
Επίπεδο 5 – Επίπεδο εξόδου (αποσαφοποίηση): Το πέμπτο επίπεδο παράγει την συνολική έξοδο του συστήματος αθροίζοντας όλες τις συνεισφορές από το προηγούμενο επίπεδο. Τελικά, παράγει την τελική έξοδο του συστήματος ANFIS.

Η έξοδος είναι το σταθμισμένο άθροισμα όλων των κανονικοποιημένων δυνάμεων εκτέλεσης.

$$\sum_i w_i * f_i = \frac{\sum_i w_i * f_i}{\sum_i w_i}$$



Σχήμα 18: Αρχιτεκτονική του ANFIS (Παράδειγμα 3 εισόδων).



Σχήμα 19: Διάγραμμα ροής της μεθοδολογίας που ακολουθήθηκε στην εργασία.

2.11 Ομαδοποίηση δεδομένων

Η ομαδοποίηση δεδομένων στο ANFIS αναφέρεται στη μέθοδο διαίρεσης των δεδομένων εισόδου σε ομάδες (clusters), για την βελτιστοποίηση της απόδοσης του προσαρμοστικού νευρό-ασαφούς συστήματος συμπερασμάτων (ANFIS). Η ομαδοποίηση βοηθά στη μείωση της υπολογιστικής πολυπλοκότητας, ομαδοποιώντας παρόμοια σημεία δεδομένων μαζί, απλοποιώντας το σύστημα ασαφών κανόνων και κάνοντάς το πιο αποδοτικό. Η προ-ομαδοποίηση των δεδομένων, ακόμα και με πολύ απλές στρατηγικές ομαδοποίησης και έναν σχετικά μικρό αριθμό ομάδων, βελτιώνει σημαντικά την ικανότητα προσαρμογής του μοντέλου (Maria Letizia Guerra et al., 2020).

Οι κύριες τεχνικές ομαδοποίησης που χρησιμοποιούνται στο ANFIS είναι:

Διαχωρισμός σε πλέγμα (Grid Partitioning, GP) είναι μια απλή μέθοδος ομαδοποίησης που χρησιμοποιείται στα προσαρμοστικά νευρό-ασαφή συστήματα συμπερασμάτων (ANFIS) για τη δημιουργία ασαφών κανόνων με βάση τα δεδομένα εισόδου. Στην προσέγγιση του διαχωρισμού σε πλέγματα, ο χώρος των δεδομένων εισόδου χωρίζεται σε ορθογώνιους υποχώρους με μια διαδικασία διαίρεσης, για να σχηματιστεί η βάση των ασαφών περιοχών χρησιμοποιώντας συναρτήσεις συμμετοχής. Για κάθε υποσύνολο εισόδου, αντιστοιχίζεται μια συνάρτηση συμμετοχής. Ο αριθμός των υποσυνόλων (συναρτήσεων συμμετοχής) μπορεί να διαφέρει ανάλογα με τη σημασία και την επίδραση των εισόδων (Zhongwei Zhang et al., 2023).

Ασαφής συστάδες C-Means (Fuzzy C-Means, FCM): Αυτή είναι μια μέθοδος που βασίζεται σε δεδομένα εισόδου που χωρίζονται σε συστάδες με τη μείωση μιας συνάρτησης κόστους που μετρά την απόσταση μεταξύ των δεδομένων και των κέντρων των συστάδων, επιτρέποντας ταυτόχρονα την μερική συμμετοχή κάθε δεδομένου σε πολλές συστάδες. Για να διασφαλιστεί η αποδοτική λειτουργία αυτής της προσέγγισης, κάθε δεδομένο ανατίθεται σε τιμές συμμετοχής με βάση την εγγύτητά του προς κάθε κέντρο συστάδας, το οποίο καθορίζεται από τη χωρική απόσταση μεταξύ του κέντρου του συστάδας και του συγκεκριμένου δεδομένου. Η βάση αυτού του αλγορίθμου είναι να χωρίσει τα δεδομένα σε έναν συγκεκριμένο αριθμό συστάδων έτσι ώστε κάθε δεδομένο να ανήκει σε διαφορετικές συστάδες, με διάφορους βαθμούς συμμετοχής (Zhongwei Zhang et al., 2023). Ο αλγόριθμος FCM επιδιώκει να μειώσει την εξής αντικειμενική συνάρτηση:

$$J = \sum_{i=1}^n \sum_{j=1}^s \mu_{ij}^m ||x_i - c_j||^2$$

Όπου J είναι η αντικειμενική συνάρτηση συμμετοχής που πρέπει να ελαχιστοποιηθεί,

μ_{ij} , είναι ο βαθμός συμμετοχής του δεδομένου j στη συστάδα i.

m είναι η παράμετρο ασάφειας.

x_i και c_j δείχνουν το i -th δεδομένο και τη j -th συστάδα, αντίστοιχα.

$\|x_i - c_j\|$ παρουσιάζουν την ευκλείδεια απόσταση μεταξύ του σημείου με το κέντρο της συστάδας.

Στη συνέχεια ακολουθεί, η τυχαία αρχικοποίηση των βαθμών συμμετοχής των συστάδων, $\sum_{i=1}^n \mu_{ij} = 1$

Ο υπολογισμός των κέντρων των συστάδων γίνεται ως εξής, $c_j = \frac{\sum_{i=1}^n \mu_{ij}^m * x_i}{\sum_{i=1}^n \mu_{ij}^m}$.

Επιπλέον, ανανεώνει τις τιμές συμμετοχής, $\mu_{ij} = \frac{1}{\sum_{k=1}^S \left(\frac{\|x_i - c_j\|}{\|x_i - c_k\|} \right)^{\frac{2}{m-1}}}$.

Τέλος, πραγματοποιείται έλεγχος σύγκλισης. Επαναλαμβάνονται τα παραπάνω βήματα μέχρι οι αλλαγές στα κεντροειδή ή στους βαθμούς συμμετοχής να πέσουν κάτω από ένα καθορισμένο όριο (κατώφλι).

Αφαιρετική ομαδοποίηση (SC): Αυτή η προσέγγιση έχει αναπτυχθεί με βάση την ομαδοποίηση βουνού (mountain clustering).

Ο κύριος στόχος των μεθόδων ομαδοποίησης είναι η συστηματική οργάνωση των δεδομένων σε ξεχωριστές ομάδες βάσει του μέτρου ομοιότητας. Η τεχνική της αφαιρετικής ομαδοποίησης (Subtractive Clustering - SC) λειτουργεί με την υπόθεση ότι κάθε μεμονωμένο σημείο δεδομένων έχει τη δυνατότητα να χρησιμεύσει ως το κέντρο μιας ομάδας. Ποσοτικοποιεί την πιθανότητα κάθε σημείου δεδομένων να γίνει το κέντρο ομάδας, αναλύοντας τη πυκνότητα των σημείων-δεδομένων στην άμεση γειτονιά του.

$$D_i = \sum_{j=1}^n e^{-\frac{\|x_i - x_j\|^2}{\left(\frac{r_a}{2}\right)^2}}$$

Αυτή η φόρμουλα αθροίζει τις συνεισφορές όλων των άλλων σημείων δεδομένων x_i που βρίσκονται εντός μιας καθορισμένης ακτίνας r από το x_j , με τα σημεία που βρίσκονται πιο κοντά στο x_j να συνεισφέρουν περισσότερο. Ο επαναυπολογισμός της πυκνότητας των σημείων-δεδομένων σύμφωνα με τις προδιαγραφές της πρώτης συστάδας γίνεται ως εξής:

$$D'_i = D_i - D_{c1} * e^{-\frac{\|x_i - x_{c1}\|^2}{\left(\frac{r_b}{2}\right)^2}}$$

2.12 Αλγόριθμοι βελτιστοποίησης

Ο κύριος στόχος των αλγορίθμων βελτιστοποίησης στο ANFIS (προσαρμοστικό νευρό-ασαφές σύστημα συμπερασμάτων) είναι να προσαρμόσουν τις παραμέτρους του συστήματος, όπως τις συναρτήσεις συμμετοχής, τους ασαφείς κανόνες και τα βάρη. Οι βασικοί αλγόριθμοι βελτιστοποίησης του ANFIS είναι οι εξής:

Βελτιστοποίηση σμήνους σωματιδίων (PSO)

Η βελτιστοποίηση σμήνους σωματιδίων (Particle Swarm Optimization - PSO) είναι ένας ισχυρός αλγόριθμος βελτιστοποίησης που βασίζεται στους πληθυσμούς και εμπνέεται από τη συλλογική συμπεριφορά που παρατηρείται στη φύση. Αναπτύχθηκε από τους James Kennedy και Russell Eberhart το 1995, και προσομοιώνει ένα απλοποιημένο κοινωνικό σύστημα όπου τα σωματίδια (που αντιπροσωπεύουν πιθανές λύσεις) εξερευνούν τον χώρο λύσεων. Κάθε σωματίδιο αξιολογεί την απόδοσή του χρησιμοποιώντας μια συνάρτηση καταλληλότητας (fitness function) και ενημερώνει τη θέση του με βάση την καλύτερη θέση που έχει βρει (pBest) και την καλύτερη θέση που έχει εντοπίσει το σμήνος (gBest). Μέσω επαναληπτικών ενημερώσεων θέσης και ταχύτητας, το σμήνος συγκλίνει προς τις βέλτιστες ή τις σχεδόν βέλτιστες λύσεις. Το PSO χρησιμοποιείται ευρέως σε διάφορους τομείς, όπως η βελτιστοποίηση συναρτήσεων, η εκπαίδευση νευρωνικών δικτύων, το ANFIS και ο σχεδιασμός μηχανικών συστημάτων, λόγω της απλότητας και της αποδοτικότητάς του στην εύρεση ελαχίστων ή μεγίστων.

Κατιούσα Κλίση - (GD)

Η βελτιστοποίηση κατιούσας κλίσης (Gradient Descent - GD) είναι ένας αλγόριθμος βελτιστοποίησης που χρησιμοποιείται για την ελαχιστοποίηση μιας συνάρτησης μέσω επαναληπτικής προσαρμογής των παραμέτρων της προς την κατεύθυνση της μέγιστης μείωσης του σφάλματος. Στα πλαίσια των νευρωνικών δικτύων και της μηχανικής μάθησης, προσαρμόζει τα βάρη και τις μεροληψίες (biases) του μοντέλου για να ελαχιστοποιήσει τη διαφορά μεταξύ των προβλεπόμενων και των πραγματικών εξόδων. Ο αλγόριθμος λειτουργεί υπολογίζοντας την κλίση (μερική παράγωγο) της συνάρτησης απώλειας ως προς τις παραμέτρους του μοντέλου και στη συνέχεια ενημερώνοντας αυτές τις παραμέτρους προς την αντίθετη κατεύθυνση της κλίσης, κλιμακωμένη από τον ρυθμό εκμάθησης (learning rate). Αυτή η διαδικασία συνεχίζεται έως ότου το μοντέλο συγκλίνει στη βέλτιστη λύση ή σταματήσει να βελτιώνεται.

Γενετικοί αλγόριθμοι - (GA)

Οι γενετικοί αλγόριθμοι (Genetic Algorithms - GA) είναι μέθοδοι βελτιστοποίησης εμπνευσμένες από τη φυσική εξέλιξη, όπου ένας πληθυσμός λύσεων εξελίσσεται με την πάροδο των γενεών. Οι λύσεις (χρωμοσώματα) υπόκεινται στη διαδικασία της επιλογής, όπου επιλέγονται οι πιο κατάλληλες για αναπαραγωγή λύσεις, δηλαδή για ανάμειξη (crossover). Κατά την διάρκεια αυτή της διαδικασίας, οι “λύσεις” ανταλλάσσουν

πληροφορίες για να δημιουργήσουν νέους απογόνους. Ένα μέρος των “λύσεων” υπόκεινται σε μετάλλαξη (mutation), που εισάγει τυχαίες παραλλαγές στο σύστημα. Αυτή η διαδικασία συνεχίζεται μέχρι ο αλγόριθμος να βρει μια βέλτιστη ή σχεδόν βέλτιστη λύση. Οι GA είναι αποτελεσματικοί για την επίλυση σύνθετων προβλημάτων, συμπεριλαμβανομένης της βελτιστοποίησης συστημάτων όπως το ANFIS, λόγω της ικανότητάς τους να εξερευνούν ποικίλους χώρους λύσεων και να αποφεύγουν τα τοπικά ελάχιστα.

2.13 Μοντέλο ασαφούς λογικής τύπου 2

Το ασαφές σύστημα τύπου 2 (Fuzzy Type-2 system) αποτελεί προχωρημένη επέκταση του παραδοσιακού ασαφούς συστήματος τύπου 1, σχεδιασμένο να διαχειρίζεται καλύτερα την αβεβαιότητα, την ασάφεια και την ανακρίβεια στα δεδομένα. Εισήχθη από τον καθηγητή Lotfi A. Zadeh το 1975. Σε αντίθεση με τα συστήματα τύπου 1, τα οποία χρησιμοποιούν συναρτήσεις συμμετοχής με συγκεκριμένες τιμές, ένα σύστημα τύπου 2 ενσωματώνει το αποτύπωμα αβεβαιότητας (Footprint of Uncertainty - FOU), επιτρέποντας ένα εύρος πιθανών βαθμών συμμετοχής σε κάθε σημείο του προβλήματος. Αυτή η πρόσθετη ευελιξία επιτρέπει στα συστήματα τύπου-2 να μοντελοποιούν την αβεβαιότητα πιο αποτελεσματικά, καθιστώντας τα ιδιαίτερα ανθεκτικά σε πολύπλοκα, θορυβώδη (noisy) ή ιδιαίτερα ευμετάβλητα περιβάλλοντα.

Η λειτουργία ενός ασαφούς συστήματος τύπου 2 περιλαμβάνει 4 βασικά βήματα:

1. **Ασαφοποίηση (Fuzzification):** Η διαδικασία σε ένα σύστημα ασαφούς λογικής όπου τα ακριβή αριθμητικά δεδομένα μετατρέπονται σε ασαφή σύνολα, επιτρέποντας στο σύστημα να χειριστεί την αβεβαιότητα και την ασάφεια. Σε αυτό το βήμα, οι τιμές εισόδου καθορίζονται σε ασαφή σύνολα χρησιμοποιώντας συναρτήσεις συνάφειας που δείχνουν το βαθμό συμμετοχής που λαμβάνει τιμές από 0 έως 1. Στα συστήματα ασαφούς τύπου-2, η συνάρτηση συμμετοχής είναι ίδια ασαφής, αντιπροσωπεύοντας μια σειρά πιθανών βαθμών (γνωστή ως το "αποτύπωμα αβεβαιότητας", ή FOU).
2. **Εφαρμογή Κανόνων (Rule application):** Σε ένα σύστημα ασαφούς λογικής, η εφαρμογή κανόνων περιλαμβάνει τη χρήση ασαφών κανόνων για τον προσδιορισμό του πώς οι είσοδοι σχετίζονται με τις εξόδους, με βάση τα ασαφή σύνολα που δημιουργούνται κατά τη διαδικασία της ασαφοποίησης. Κάθε κανόνας ακολουθεί συνήθως μια δομή "εάν-τότε", όπου το πρώτο (μέρος εάν) περιγράφει τις συνθήκες που βασίζονται σε ασαφή σύνολα εισόδων και το δεύτερο μέρος (μέρος τότε) προσδιορίζει το επακόλουθο ασαφές σύνολο εξόδου. Στα συστήματα ασαφούς τύπου-2, οι κανόνες λαμβάνουν υπόψη το αποτύπωμα της αβεβαιότητας (FOU) στα ασαφή σύνολα, επιτρέποντας μια σειρά πιθανών τιμών εξόδου αντί για μια μεμονωμένη ακριβή τιμή. Το σύστημα αξιολογεί τη δύναμη κάθε κανόνα εφαρμόζοντας τελεστές ασαφούς λογικής, όπως τα “και”,

”ή”, και το “ΟΧΙ”, για να προσδιορίσει το βαθμό ολοκλήρωσης των προηγούμενων .

3. **Μείωση Τύπου (Type-reduction):** Στο σύστημα ασαφούς λογικής τύπου-2, η διαδικασία της μείωσης τύπου είναι η διαδικασία απλοποίησης των ασαφών συνόλων τύπου-2 σε ασαφή σύνολα Τύπου-1, προκειμένου να διευκολυνθεί η υπολογιστική παραγωγή των τιμών εξόδου. Αυτό το βήμα είναι απαραίτητο επειδή τα ασαφή σύνολα τύπου-2, τα οποία ενσωματώνουν το αποτύπωμα αβεβαιότητας (FOU), μπορεί να είναι πολύπλοκα και υπολογιστικά απαιτητικά για άμεση επεξεργασία. Κατά τη διαδικασία μείωσης τύπου, το σύστημα συγκεντρώνει τις πληροφορίες από όλους τους εφαρμοστέους ασαφείς κανόνες και δημιουργεί ένα ασαφές σύνολο τύπου-1 που αναπαριστά την έξοδο. Το τελικό ασαφές σύνολο τύπου-1 αποτυπώνει την ουσία της εξόδου τύπου-2, διατηρώντας παράλληλα μια πιο απλή δομή, γεγονός που διευκολύνει την ερμηνεία και ανάλυση.
4. **Αποσαφoποίηση:** Είναι το τελικό βήμα σε ένα σύστημα ασαφούς λογικής που μετατρέπει το ασαφές σύνολο εξόδου σε μια ακριβή, εφαρμόσιμη τιμή για τη πρακτική λήψη αποφάσεων. Αυτή η διαδικασία είναι απαραίτητη καθώς οι εφαρμογές στον πραγματικό κόσμο συχνά απαιτούν συγκεκριμένες αριθμητικές εξόδους. Διάφορες μέθοδοι χρησιμοποιούνται για την ασαφoποίηση, όπως το κέντρο περιοχής (CoA), το τροποποιημένο κέντρο περιοχής (mCoA), το κέντρο αθροισμάτων (CoS), το κέντρο μέγιστου (CoM) ή ο μέσος όρος του μέγιστου (MoM). Η τελική ακριβής τιμή αντιπροσωπεύει την τελική πρόβλεψη ή απόφαση του συστήματος.

Αυτή η δομή αποδεικνύεται ιδιαίτερα επωφελής σε εφαρμογές όπως η πρόβλεψη τιμών κρυπτονομισμάτων, όπου τα δεδομένα είναι συχνά αβέβαια, θορυβώδη και επηρεάζονται από απρόβλεπτους παράγοντες. Με την ενσωμάτωση αυτών των αβεβαιοτήτων, ένα σύστημα τύπου-2 μπορεί να παράγει πιο ακριβείς και αξιόπιστες προβλέψεις σε σχέση με ένα παραδοσιακό σύστημα τύπου-1 ή άλλα μοντέλα πρόβλεψης. Επιπλέον, όταν βελτιστοποιείται χρησιμοποιώντας αλγόριθμους όπως ο αλγόριθμος σμήνους σωματιδίων (PSO), η απόδοση των συστημάτων ασαφούς τύπου-2 μπορεί να ενισχυθεί περαιτέρω, επιτρέποντας την πιο ακριβή μοντελοποίηση πολύπλοκων συνόλων δεδομένων.

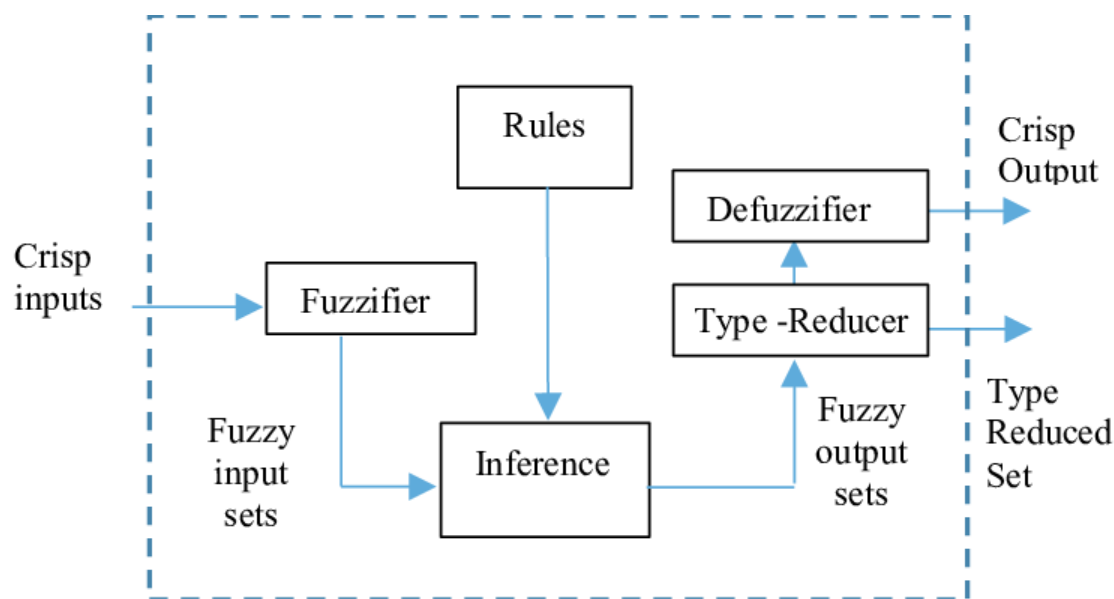
Μαθηματικά, ένα ασαφές σύνολο τύπου-2 \tilde{A} περιγράφεται ως εξής:

$$\tilde{A} = \{((x, u), \mu_{\tilde{A}}(x, u)) \mid x \in X, u \in J_x \subseteq [0, 1], 0 \leq \mu_{\tilde{A}}(x, u) \leq 1\}$$

Όπου,

- $\mu_{\tilde{A}}(x, u)$ είναι με συνάρτηση συμμετοχής τύπου-2, που αποδίδει τον βαθμό συμμετοχής σε κάθε ζεύγος (x, u) . Καθορίζει το ζεύγος (x, u) σε μία τιμή μεταξύ του 0 και 1, αντιπροσωπεύοντας τον βαθμό αβεβαιότητας της συμμετοχής του x .

- $J_x \subseteq [0,1]$ είναι η κύρια συνάρτηση συμμετοχής, ένα ασαφές σύνολο που ανήκει στο διάστημα $[0,1]$ και αντιπροσωπεύει το εύρος των πιθανών βαθμών συμμετοχής του x .
- μ είναι η δευτερεύουσα τιμή συμμετοχής ή του αποτυπώματος της αβεβαιότητας.
- X , είναι το πεδίο του διαστήματος.
- x είναι ένα συγκεκριμένο στοιχείο στο X .



Σχήμα 20: Η δομή του ελεγκτή ασαφούς λογικής τύπου 2.

2.14 Εφαρμογές των συστημάτων ασαφούς λογικής τύπου 2

Τα συστήματα ασαφούς τύπου-2 έχουν ποικίλες και σημαντικές εφαρμογές σε πολλούς τομείς, κυρίως λόγω της ικανότητάς τους να διαχειρίζονται αποτελεσματικά την αβεβαιότητα και την ασάφεια. Στην χρηματοοικονομική πρόβλεψη, αυτά τα συστήματα βελτιώνουν σημαντικά την ακρίβεια των προβλέψεων για τις τιμές των μετοχών, των κρυπτονομισμάτων και για τις ευρύτερες αγοραστικές τάσεις. Στα συστήματα ελέγχου, τα συστήματα ασαφούς τύπου-2 βελτιστοποιούν τους ασαφείς ελεγκτές στους αυτοματισμούς και στη ρομποτική, οδηγώντας τα σε βελτιωμένη απόδοση και αξιοπιστία, υπό συνθήκες αβεβαιότητας. Οι δυνατότητές τους επεκτείνονται επίσης σε διαδικασίες λήψης αποφάσεων, όπου βελτιώνουν τα σύνολα κανόνων (rule-sets) σε τομείς όπως η υγειονομική περίθαλψη και οι επιχειρήσεις, επιτρέποντας πιο ενημερωμένες επιλογές. Επιπλέον, στη μοντελοποίηση περιβαλλοντικών συστημάτων, τα συστήματα ασαφούς τύπου-2 παρέχουν αξιόπιστες προβλέψεις σχετικά με την κλιματική αλλαγή και τη διαχείριση πόρων, αναδεικνύοντας την αποτελεσματικότητά

τους στην αντιμετώπιση πολύπλοκων πραγματικών προκλήσεων. Συμπερασματικά, η προσαρμοστικότητα και η ακρίβεια των συστημάτων ασαφούς τύπου-2 τα καθιστούν ανεκτίμητα εργαλεία σε διάφορους τομείς που απαιτούν εξελιγμένη μοντελοποίηση της αβεβαιότητας.

Κεφάλαιο 3 : Ανάλυση δεδομένων και παράμετροι των μοντέλων

Η υλοποίηση των μοντέλων και η επακόλουθη ανάλυση των αποτελεσμάτων πραγματοποιήθηκαν χρησιμοποιώντας το MATLAB 2022b. Τα δεδομένα λήφθηκαν από τις πηγές Investing.com και Yahoo Finance.


3.1 Δεδομένα

Τα δεδομένα μας επικεντρώνεται στα πέντε κύρια κρυπτονομίσματα: Bitcoin, Ethereum, BNB, Solana και XRP. Για κάθε ένα από αυτά, έχουμε συλλέξει καθημερινές τιμές κλεισίματος από την αρχή τους μέχρι τον Απρίλιο του 2024.

- Τα δεδομένα καλύπτουν τις παρακάτω χρονικές περιόδους για κάθε κρυπτονόμισμα: Τα δεδομένα για το Bitcoin καλύπτουν την περίοδο από 19 Ιουλίου 2010 έως 7 Απριλίου 2024.
- Τα δεδομένα για το Ethereum και του BNB καλύπτουν την περίοδο από 10 Νοεμβρίου 2017 έως 7 Απριλίου 2024.
- Τα δεδομένα του Solana είναι από 14 Ιουλίου 2020 έως 14 Απριλίου 2024.
- Τα δεδομένα του XRP καλύπτουν την περίοδο από 23 Ιανουαρίου 2015 έως 14 Απριλίου 2024.

Οι κάτωθι γραφικές αναπαραστάσεις των ημερήσιων τιμών κλεισίματος των κρυπτονομισμάτων, είναι παραγόμενες από το λογισμικό Excel:

Bitcoin:




Σχήμα 21: Ημερήσιες τιμές κλεισίματος του Bitcoin.

Ethereum:



Σχήμα 22: Ημερήσιες τιμές κλεισίματος του Ethereum.

Binance Coin (BNB):




Σχήμα 23: Ημερήσιες τιμές κλεισίματος του BNB.

Solana:



Σχήμα 24: Ημερήσιες τιμές κλεισίματος του Solana.

XRP:



Σχήμα 25: Ημερήσιες τιμές κλεισίματος του XRP.

3.2 Προετοιμασία δεδομένων

Η προετοιμασία των δεδομένων ξεκινά με την ανάθεση τους στις μεταβλητές `mydata1` και `mydata`, ακολουθούμενη από την απεικόνιση των τιμών κλεισίματος μέσω γραφήματος. Υπολογίζεται ο συνολικός αριθμός των σημείων δεδομένων και επιλέγονται το 80% για εκπαίδευση και το υπόλοιπο 20% για αξιολόγηση. Τα δεδομένα εκπαίδευσης οργανώνονται στη συνέχεια σε τρεις καθυστερημένες εισόδους: $\{k-2, k-1, k \text{ (έξοδος)}\}$, οι οποίες συνδυάζονται στο `trn_data`, το οποίο δημιουργείται από την συνένωση των δεδομένων εισόδου και εξόδου.

3.3 Παράμετροι του μοντέλου

Για την υλοποίηση του μοντέλου, είναι απαραίτητο να οριστούν οι παράμετροι του μοντέλου, όπως ο αριθμός των εποχών, το μέγεθος του βήματος στις επαναλήψεις και οι συναρτήσεις συμμετοχής. Το μοντέλο εκπαιδεύεται με τα δεδομένα που του παρέχονται και η απόδοση εκπαίδευσης αξιολογείται χρησιμοποιώντας το ριζικό μέσο τετραγωνικό σφάλμα (RMSE). Στο μοντέλο αξιολογείται η απόδοσή του τόσο στα δεδομένα εντός του δείγματος όσο και στα δεδομένα εκτός του δείγματος, δημιουργώντας γραφήματα, για τη σύγκριση των πραγματικών και των προβλεπόμενων τιμών του. Στη συνέχεια, υπολογίζονται οι μετρήσεις σφάλματος, όπως το μέσο τετραγωνικό σφάλμα (MSE), το ριζικό μέσο τετραγωνικό σφάλμα (RMSE), το μέσο απόλυτο σφάλμα (MAE), το μέσο απόλυτο ποσοστιαίο σφάλμα (MAPE) και ο συντελεστής προσδιορισμού R^2 για την αξιολόγηση της ακρίβειας του μοντέλου. Υπολογίζονται επίσης οι κανονικοποιημένες μετρήσεις σφάλματος για τη περαιτέρω σύγκριση των αποτελεσμάτων.

Αυτές οι μετρήσεις σφάλματος εκφράζονται μαθηματικά ως εξής:

$$\text{Μέσο τετραγωνικό σφάλμα (MSE): } MSE = \left(\frac{1}{n}\right) * \sum_{i=1}^n (y_{actual,i} - y_{predicted,i})^2$$

$$\text{Ριζικό μέσο τετραγωνικό σφάλμα (RMSE): } RMSE = \sqrt{\left(\frac{1}{n}\right) * \sum_{i=1}^n (y_{actual,i} - y_{predicted,i})^2}$$

$$\text{Μέσο απόλυτο σφάλμα (MAE): } MAE = \left(\frac{1}{n}\right) * \sum_{i=1}^n |y_{actual,i} - y_{predicted,i}|$$

$$\text{Μέσο απόλυτο ποσοστιαίο σφάλμα (MAPE): } MAPE = \left(\frac{100}{n}\right) * \sum_{i=1}^n \left| \frac{y_{actual,i} - y_{predicted,i}}{(y_{actual,i})} \right|$$

$$\text{Συντελεστής προσδιορισμού: } R^2 = 1 - (\sum (y_i - \hat{y}_i)^2) / (\sum (y_i - \bar{y})^2)$$

Κεφάλαιο 4 : Αποτελέσματα

4.1 Αποτελέσματα του μοντέλου ANFIS για το Bitcoin

Τα δεδομένα χωρίζονται σε υποσύνολα εκπαίδευσης και δοκιμών, με το 80% των δεδομένων να προορίζεται για εκπαίδευση και το υπόλοιπο 20% για δοκιμές. Αυτή η προσέγγιση εγγυάται ότι το μοντέλο θα υποβληθεί σε επαρκή εκπαίδευση, ενώ παράλληλα θα αξιολογηθεί με ακρίβεια. Οι παράμετροι του μοντέλου, συμπεριλαμβανομένου του βήματος ($ss=0.8$), του αριθμού των εποχών ($epoch=400$) και του αριθμού των συναρτήσεων μέλους ($mf_n=4$), ρυθμίζονται για να μειώσουν τις μετρήσεις σφάλματος. Τα αποτελέσματα συνοψίζονται στους επόμενους συγκεντρωτικούς πίνακες. Αρχικά, το μοντέλο δημιουργεί ένα σύστημα ασαφούς συμπερασμού (FIS) με διαφορετικούς τύπους συναρτήσεων συμμετοχής και εκπαιδεύει το μοντέλο χρησιμοποιώντας τα δεδομένα χρονοσειρών. Η διαδικασία εκπαίδευσης απεικονίζεται με γραφήματα των συναρτήσεων συμμετοχής, των σφαλμάτων εκπαίδευσης και του βήματος. Υπολογίζονται διάφορες μετρήσεις σφαλμάτων, όπως τα RMSE, MSE και MAE, για την αξιολόγηση των προβλέψεων τόσο εντός όσο και εκτός του δείγματος. Τέλος, υπολογίζονται οι κανονικοποιημένες μετρήσεις σφάλματος για την περαιτέρω αξιολόγηση της απόδοσης του μοντέλου.

Οι συγκεντρωτικοί πίνακες μετρήσεων σφάλματος για διάφορους τύπους συναρτήσεων συμμετοχής, βήματος και αριθμού εποχών, προσφέρουν μια ολιστική αξιολόγηση των δοκιμών. Τα αποτελέσματα των δοκιμών παρουσιάζονται στους συγκεντρωτικούς Πίνακες 1,2,3,4,5,6,7,8 και 9. :

Πίνακας 1: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του Bitcoin ($Epochs=400$, $mf=4$, $ss=0,8$).

Epoch=400, mf=4, ss=0.8				
MSE	RMSE	MAE	R^2	MF Type
12199304.334	3492.750	1505.913	0.933	Gbell
3149690.210	1774.736	1217.010	0.982	Gauss
5338782803915.458	2310580.620	300965.279	-28951.454	Trimf
2272091.825	1507.345	1077.919	0.987	Gauss2
1909756.388	1381.939	964.053	0.989	Trampf
2107534.844	1451.735	972.012	0.988	Pimf

Πίνακας 2: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του Bitcoin (Epochs=100, mf=4, ss=0,8).

Epoch=100, mf=4, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	12437683.898	3526.710	1507.077	0.932
Gauss	3149377.453813	1774.648544	1217.439925	0.982
Trimf	5338782803915.458	2310580.620	300965.279	-28951.453
Gauss2	2273480.889	1507.806	1075.349	0.987
Trampf	1927499.966	1388.344	969.800	0.989
Pimf	3210159.500	1791.691	1088.177	0.982

Πίνακας 2: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του Bitcoin (Epochs=200, mf=4, ss=0,8).

Epoch=200, mf=4, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	12199304.334	3492.750	1505.913	0.933
Gauss	3149377.453	1774.648544	1217.439925	0.982
Trimf	5338782803915.458	2310580.620	300965.279	-28951.454
Gauss2	2272345.212	1507.430	1077.611	0.987
Trampf	1904160.120	1379.913	970.617	0.989
Pimf	1807826.263502	1344.554299	927.417469	0.990196

Πίνακας 3: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του Bitcoin (Epochs=100, mf=2, ss=0,8).

Epoch=100, mf=2, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	2251649.141	1500.549	1018.313	0.987
Gauss	1570650.059	1253.255	807.757	0.991
Trimf	3660898917.759	60505.362	9700.438	-18.853
Gauss2	1642482.704	1281.593	904.097	0.991
Trampf	1911965.643	1382.738	1034.552	0.989
Pimf	1847854.304	1359.358	999.908	0.989

Πίνακας 4: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του Bitcoin (Epochs=200, mf=2, ss=0,8).

Epoch=200, mf=2, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	2254922.813	1501.640	1019.013	0.987
Gauss	1797467.315	1340.696	850.630	0.990
Trimf	1047394930681.141	1023423.143	134086.441	-5679.068
Gauss2	2154054.624	1467.669	1053.167	0.988
Trampf	2319237.804	1522.904	1101.718	0.987
Pimf	1847854.304	1359.358	999.908	0.989

Πίνακας 5: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του Bitcoin (Epochs=400, mf=2, ss=0,8).

Epoch=400, mf=2, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	2254781.029	1501.592	1018.993	0.987
Gauss	2183903.693	1477.803	1003.349	0.988
Trimf	105934771109.256	325476.222	40146.676	-573.488
Gauss2	3128641.163	1768.796530	1274.300	0.983
Trampf	2321886.685	1523.773	1102.396	0.987
Pimf	1825339.311	1351.051	990.637	0.990

Πίνακας 6: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του Bitcoin (Epochs=100, mf=3, ss=0,8).

Epoch=100, mf=3, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	2595171.232	1610.953	1181.591	0.985
Gauss	2104234.235	1450.597	1032.971	0.988
Trimf	2740595636532.857	1655474.444	194785.583	-14861.370
Gauss2	2049224.736	1431.511	1023.308	0.988
Trampf	1908023.662	1381.312	990.181	0.989
Pimf	1913037.728	1383.126	976.615	0.989

Πίνακας 7: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του Bitcoin (Epochs=200, mf=3, ss=0,8).


Epoch=200, mf=3, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	2617385.723	1617.833	1184.551	0.985
Gauss	2051988.494	1432.476	1022.771	0.988
Trimf	2229136289126.382	1493029.232	175871.601	-12087.704
Gauss2	2321613.078	1523.684	1100.491	0.987
Trampf	1913246.605	1383.201	991.837	0.989
Pimf	1913037.728	1383.126	976.615	0.989

Πίνακας 8: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του Bitcoin (Epochs=400, mf=3, ss=0,8).

Epoch=400, mf=3, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	2631472.264	1622.181	1188.058	0.985
Gauss	4193584.314	2047.824	1399.709	0.977
Trimf	1757492307571.884	1325704.457	156558.851	-9529.958
Gauss2	2300916.251	1516.877	1104.324	0.987
Trampf	1911894.165	1382.712	991.435	0.989
Pimf	1913037.728	1383.126	976.615	0.989

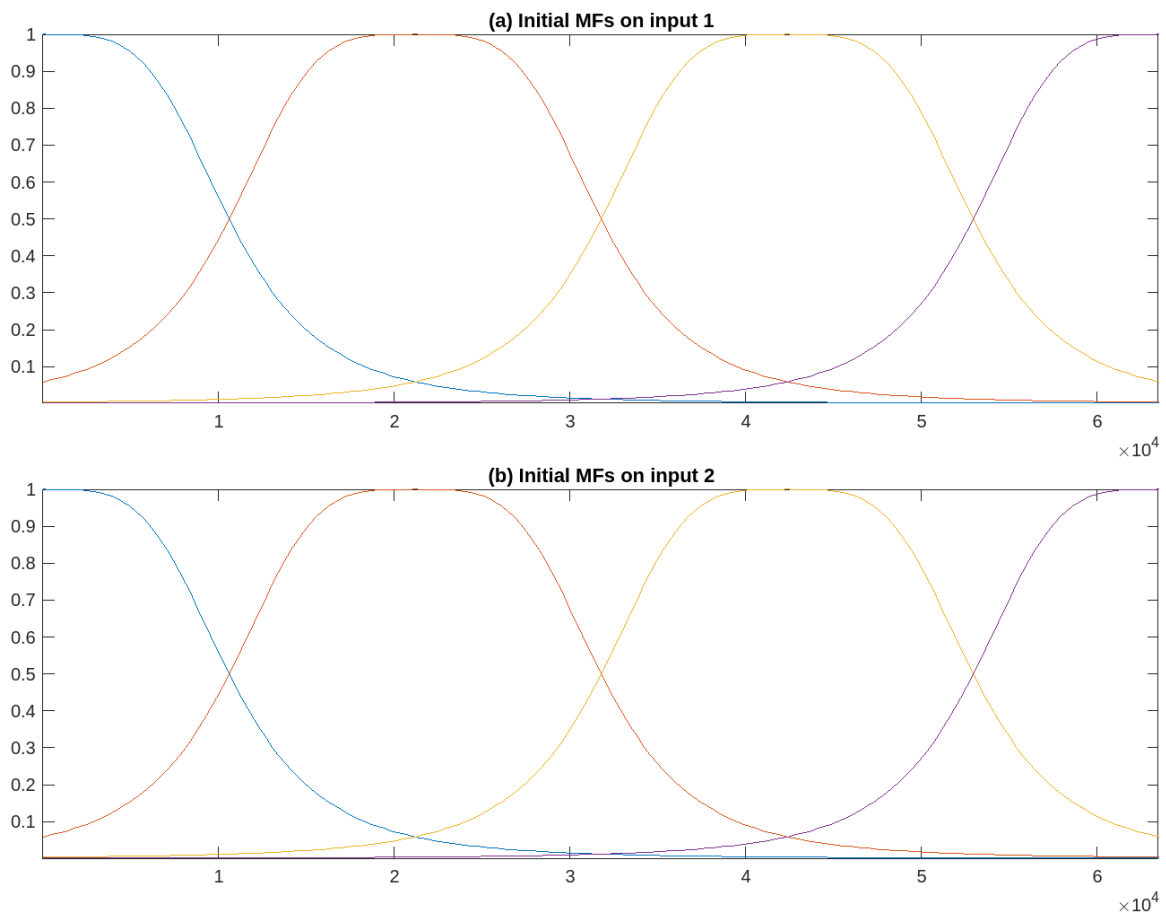
Από τους παραπάνω πίνακες, καταλήγουμε στο ότι για την ελαχιστοποίηση του RMSE στην πρόβλεψη των τιμών του Bitcoin, ο καλύτερος συνδυασμός παραμέτρων περιλαμβάνει την συνάρτηση συμμετοχής τύπου Gauss για τον αριθμό εποχών ίσο με 100 (Epochs = 100) ,με δύο συναρτήσεις μέλους ($mf=2$) και μέγεθος βήματος ίσο με 0.8 ($ss=0.8$). Ο προαναφερθέν συνδυασμός παραμέτρων αποδεικνύονται ο πιο αποτελεσματικός στη μείωση του RMSE, δηλαδή ελαχιστοποιεί τις αποκλίσεις μεταξύ των πραγματικών και των προβλεπόμενων τιμών, καθιστώντας τον τη βέλτιστη επιλογή για το εξεταζόμενο προβλεπτικό μοντέλο.

Τα παρακάτω γραφήματα απεικονίζουν τις εισαγωγικές μεταβλητές που χρησιμοποιούνται κατά τη διάρκεια της διαδικασίας εκπαίδευσης. Η πρώτη γραφική παράσταση δείχνει τις τιμές εισόδου για $x(k-2)$, που αντιπροσωπεύουν τη δεύτερη καθυστερημένη μεταβλητή, ενώ η δεύτερη γραφική παράσταση παρουσιάζει τις τιμές εισόδου για $x(k-1)$ οι οποίες αντιστοιχούν στην πρώτη καθυστερημένη μεταβλητή. Η τελευταία γραφική παράσταση παρουσιάζει τις τιμές για τα δεδομένα ελέγχου.




Σχήμα 26: Γραφική απεικόνιση των επιλεγμένων δεδομένων εκπαίδευσης (ρυθμός αλλαγής).

Οι παρακάτω γραφικές απεικονίζουν τόσο τις αρχικές όσο και τις τελικές συναρτήσεις συμμετοχής για την εισαγωγική μεταβλητή, με τον άξονα x να αντιπροσωπεύει τις τιμές εισόδου και τον άξονα y να υποδεικνύει το βαθμό συμμετοχής. Στο Σχήμα 27(a) απεικονίζονται οι αρχικές συναρτήσεις συμμετοχής για τη μεταβλητή εισόδου, ενώ στο Σχήμα 27 (b) εμφανίζονται οι αρχικές συναρτήσεις συμμετοχής για τη δεύτερη μεταβλητή. Ομοίως, στο Σχήμα 28 (a) και (b), εμφανίζονται οι τελικές συναρτήσεις συμμετοχής για τη πρώτη και δεύτερη εισαγωγική μεταβλητή αντίστοιχα.




Σχήμα 27: Αρχικές συναρτήσεις συμμετοχής για τις εισαγωγικές μεταβλητές πριν από την εκπαίδευση του μοντέλου ANFIS.




Σχήμα 28: Τελική συνάρτηση συμμετοχής για τις εισαγωγικές μεταβλητές μετά από την εκπαίδευση του μοντέλου ANFIS.

Στο Σχήμα 29, συγκρίνονται οι πραγματικές τιμές του συνόλου δεδομένων δοκιμής με τις τιμές που προβλέπει το μοντέλο ANFIS για τα τελευταία 60 δείγματα. Ο άξονας x αναπαριστά το χρόνο, ενώ ο άξονας y δείχνει τις ημερήσιες τιμές κλεισίματος του κρυπτονομίσματος. Τα μπλε τετράγωνα υποδεικνύουν τις πραγματικές τιμές από το σύνολο δεδομένων δοκιμής, ενώ οι κόκκινοι δείκτες αντιπροσωπεύουν τις προβλεπόμενες τιμές από το μοντέλο ANFIS.



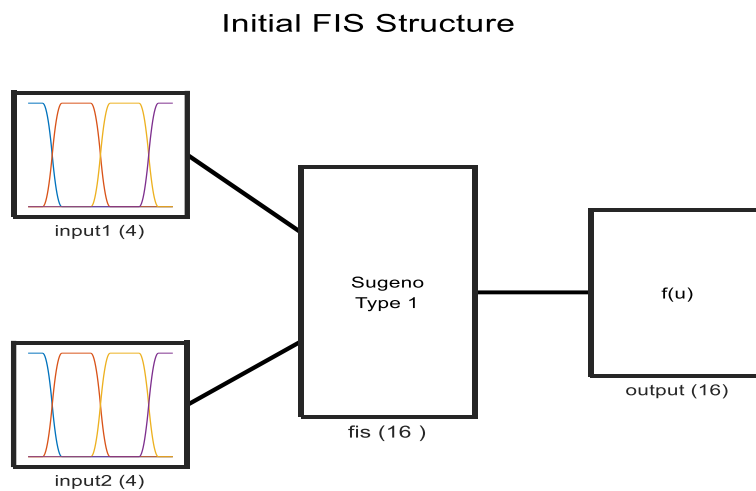
Σχήμα 29: Σύγκριση των τελευταίων 60 πραγματικών τιμών εισόδου της χρονοσειράς με τις αντίστοιχες προβλεπόμενες τιμές από το μοντέλο ANFIS.

Το παρακάτω διάγραμμα απεικονίζει τα σφάλματα πρόβλεψης σε σχέση με το χρόνο. Ο άξονας y αντιπροσωπεύει το σφάλμα, το οποίο υπολογίζεται ως η διαφορά μεταξύ των πραγματικών τιμών και των προβλεπόμενων τιμών, ενώ ο άξονας x δείχνει τις ημέρες μέτρησης. Στο παραπάνω σχήμα, παρατηρούμε ότι τα σφάλματα συγκεντρώνονται γύρω από το μηδέν, υποδεικνύοντας έτσι την υψηλή προβλεπτική ακρίβεια του μοντέλου. Τα σημεία κορύφωσης, είναι τα σημεία στα οποία εμφανίστηκαν οι μεγαλύτερες αποκλίσεις από τις πραγματικές τιμές.



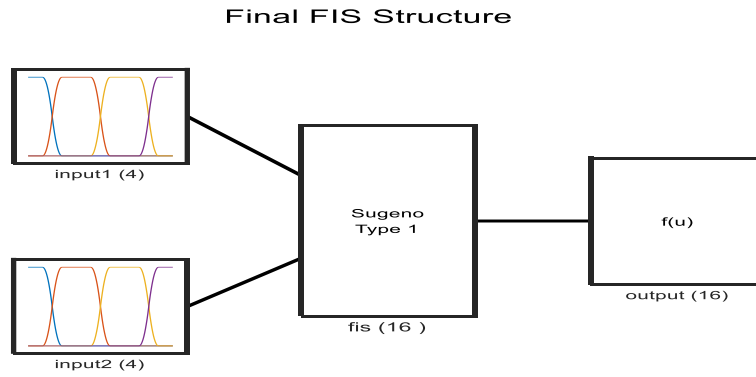
Σχήμα 30: Σφάλματα πρόβλεψης συναρτήσεως του χρόνου για το μοντέλο ANFIS.

Η αρχική διαμόρφωση του FIS απεικονίζεται στο παρακάτω γράφημα, το οποίο δείχνει τις συναρτήσεις συμμετοχής και τις αντίστοιχες παραμέτρους για τα δεδομένα εισόδου. Επιπλέον, στο Σχήμα 32, εμφανίζεται η τελική δομή του FIS μετά τη διαδικασία εκπαίδευσης.




System fis: 2 inputs, 1 outputs, 16 rules

Σχήμα 31: Αρχική διαμόρφωση του FIS.



System fis: 2 inputs, 1 outputs, 16 rules

Σχήμα 32: Τελική διαμόρφωση του FIS.



Σχήμα 33: Σφάλματα εκπαίδευσης για το σύνολο δεδομένων του Bitcoin.

Όπως παρατηρείται στο παραπάνω γράφημα, η συνέχιση της αναζήτησης και των δοκιμών πέρα από τις 400 επαναλήψεις δεν είναι αναγκαία, καθώς έχει ελάχιστο αντίκτυπο στη μείωση του RMSE.

4.2 Αποτελέσματα των μοντέλων AR και ARMA για το Bitcoin

Τα μοντέλα αυτοπαλινδρόμησης (AR) και αυτοπαλινδρομικό μοντέλο κινητού μέσου όρου (ARMA) χρησιμοποιούνται σε αυτήν την ενότητα για την πρόβλεψη χρονοσειρών. Τα μοντέλα εκπαιδεύονται με τα δεδομένα εισόδου, κάνουν προβλέψεις και συγκρίνουν αυτές τις προβλέψεις με τις πραγματικές τιμές. Οι μετρήσεις των σφαλμάτων γίνονται με το μέσο τετραγωνικό σφάλμα (MSE), τη ρίζα του μέσου τετραγωνικού σφάλματος (RMSE), το μέσο απόλυτο σφάλμα (MAE), και του συντελεστή προσδιορισμού (R^2). Επιπλέον, υπολογίζονται και τα κανονικοποιημένα σφάλματα για την περαιτέρω σύγκριση των μοντέλων.


Ο παρακάτω πίνακας παρουσιάζει τα αποτελέσματα των μετρήσεων σφάλματος για τα μοντέλα AR και ARMA, με βάση το σύνολο δεδομένων της ημερήσιας τιμής κλεισίματος του Bitcoin.

Πίνακας 9: Μετρήσεις απόδοσης μοντέλων AR και ARMA για πρόβλεψη τιμών του Bitcoin.

	AR	ARMA
MSE	1407152.437	1406684.941
RMSE	1186.234	1186.037
MAE	755.705	756.884
R^2	0.992	0.992


Από τον Πίνακα 10, προκύπτει ότι για την πρόβλεψη των τιμών του Bitcoin, το μοντέλο ARMA επιτυγχάνει ελαφρώς καλύτερο αποτέλεσμα όσον αφορά το RMSE, εμφανίζοντας σφάλμα ίσο με 1186.04 σε σχέση με το μοντέλο AR, το οποίο αποδίδει στην αντίστοιχη μέτρηση σφάλματος τιμή ίση με 1186.23. Αυτό υποδεικνύει ότι το μοντέλο ARMA προσφέρει καλύτερη ακρίβεια στην πρόβλεψη των τιμών του Bitcoin, ελαχιστοποιώντας καλύτερα τις αποκλίσεις μεταξύ των πραγματικών και των προβλεπόμενων τιμών σε σχέση με το μοντέλο AR.

Η παρακάτω γραφική απεικονίζει τις τελευταίες 60 πραγματικές τιμές εισόδου του συνόλου των δεδομένων, μαζί με τις προβλεπόμενες τιμές από το μοντέλο αυτοπαλινδρόμησης (AR). Όπως φαίνεται στην παρακάτω εικόνα, οι προβλεπόμενες τιμές εμφανίζονται ελαφρώς μετατοπισμένες προς τα δεξιά, κάτι που αποτελεί χαρακτηριστικό των μοντέλων AR, καθώς προβλέπουν μελλοντικές τιμές με βάση προηγούμενες παρατηρήσεις. Μόνο μικρές αποκλίσεις μεταξύ των πραγματικών και των προβλεπόμενων τιμών παρατηρούνται, γεγονός που δείχνει την ανθεκτικότητα του μοντέλου, υποδεικνύοντας έτσι ότι λειτουργεί αποτελεσματικά με την ύπαρξη λιγοστών σφαλμάτων και συλλαμβάνει αποτελεσματικά τα υποκείμενα μοτίβα των δεδομένων.



Σχήμα 34: Σύγκριση των τελευταίων 60 πραγματικών τιμών εισόδου με τις αντίστοιχες προβλεπόμενες τιμές από το Αυτοπαλινδρομικό μοντέλο (AR).

Το Σχήμα 35 απεικονίζει τις τελευταίες 60 πραγματικές τιμές εισόδου μαζί με τις αντίστοιχες προβλεπόμενες τιμές από το μοντέλο αυτοπαλινδρόμησης κινητού μέσου όρου (ARMA) στο παρακάτω διάγραμμα. Όπως και στην προηγούμενη εικόνα, οι προβλεπόμενες τιμές εμφανίζονται ελαφρώς μετατοπισμένες προς τα δεξιά, κάτι που αποτελεί χαρακτηριστικό των μοντέλων ARMA. Και σε αυτή τη περίπτωση, παρατηρούνται μικρές αποκλίσεις μεταξύ των πραγματικών και των προβλεπόμενων τιμών.



Σχήμα 35: Σύγκριση των τελευταίων 60 πραγματικών τιμών εισόδου με τις αντίστοιχες προβλεπόμενες τιμές από το αυτοπαλινδρομικό μοντέλο κινητού μέσου όρου (ARMA).

4.3 Αποτελέσματα του μοντέλου νευρωνικού δικτύου για το Bitcoin

Το νευρωνικό δίκτυο (NN) που εφαρμόζεται σε αυτήν την εργασία είναι ένα πρώτο-τροφοδοτούμενο νευρωνικό δίκτυο με 10 νευρώνες στο κρυφό επίπεδο. Ετοιμάζει τα σύνολα δεδομένων εκπαίδευσης και δοκιμής από τα ιστορικά δεδομένα των ημερήσιων τιμών κλεισίματος, απεικονίζει τις τάσεις εκπαίδευσης και τις κατανομές σφαλμάτων, και εκπαιδεύει το νευρωνικό δίκτυο με τα δεδομένα εκπαίδευσης. Για τη σωστή αξιολόγηση του μοντέλου, χρησιμοποιούνται οι παρακάτω μετρήσεις σφάλματος, όπως το μέσο απόλυτο σφάλμα (MAE), το μέσο τετραγωνικό σφάλμα (MSE), η ρίζα του μέσου τετραγωνικού σφάλματος (RMSE) και ο συντελεστής προσδιορισμού R^2 .

Ο ακόλουθος πίνακας παρουσιάζει τα αποτελέσματα μετρήσεων των σφαλμάτων για το μοντέλο NN, με βάση το σύνολο δεδομένων των ημερήσιων τιμών κλεισίματος του Bitcoin.

Πίνακας 110: Μετρήσεις απόδοσης του νευρωνικού δικτύου (NN) για πρόβλεψη τιμών του Bitcoin.

	NN
MSE	2262272.662
RMSE	1504.085
MAE	1074.032
R^2	0.987


Όπως αναδεικνύει και ο Πίνακας 11, το νευρωνικό δίκτυο (NN) εμφανίζει υψηλότερο RMSE (1504.085321) συγκριτικά με τα μοντέλα AR, ARMA και τον βέλτιστο συνδυασμό παραμέτρων του ANFIS, γεγονός που υποδεικνύει ότι το NN υπολείπεται στην ακρίβεια πρόβλεψης σε σχέση με τα άλλα μοντέλα.

Η ακόλουθη γραφική απεικονίζει τα δεδομένα εκπαίδευσης του μοντέλου νευρωνικού δικτύου (NN), τα οποία αποτελούνται από τα τελευταία 60 δείγματα. Ο άξονας x αναπαριστά τις εισερχόμενες τιμές, ενώ ο άξονας y αντιστοιχεί στην έξοδο.



Σχήμα 36: Τα δεδομένα εκπαίδευσης για το μοντέλο NN (Τελευταία 60 δείγματα).

Το παρακάτω διάγραμμα απεικονίζει τις τελευταίες 60 πραγματικές τιμές εισόδου του συνόλου δεδομένων, μαζί με τις αντίστοιχες προβλεπόμενες τιμές από το μοντέλο νευρωνικού δικτύου (NN). Και πάλι, παρατηρούνται μόνο μικρές αποκλίσεις μεταξύ των πραγματικών και των προβλεπόμενων τιμών.



Σχήμα 37: Σύγκριση των τελευταίων 60 πραγματικών τιμών εισόδου με τις αντίστοιχες προβλεπόμενες τιμές από το μοντέλο νευρωνικού δικτύου (NN).

4.4 Αποτελέσματα του ασαφούς μοντέλου τύπου-2 (Fuzzy Type-2) με βελτιστοποίηση μέσω του αλγορίθμου PSO για το Bitcoin

Σε αυτή την ενότητα, εφαρμόζεται ένα σύστημα ασαφούς συμπερασματικής λογικής (FIS) τύπου 2 Sugeno για την πρόβλεψη των ημερήσιων τιμών κλεισίματος του Bitcoin χρησιμοποιώντας τα ιστορικά δεδομένα. Η διαδικασία ξεκινά με την εισαγωγή και την προεργασία των δεδομένων, τα οποία στη συνέχεια χωρίζονται σε σύνολα εκπαίδευσης (80%) και επικύρωσης (20%). Δημιουργείται ένα FIS τύπου-1 χρησιμοποιώντας τη μέθοδο Fuzzy C-Means, το οποίο στη συνέχεια μετατρέπεται σε FIS τύπου-2. Το σύστημα βελτιστοποιείται μέσω της αλγορίθμου βελτιστοποίησης σμήνους σωματιδίων (PSO), ρυθμίζοντας τις συναρτήσεις συμμετοχής και τους κανόνες. Η απόδοση του βελτιστοποιημένου FIS αξιολογείται συγκρίνοντας τις προβλεπόμενες τιμές με τις πραγματικές τιμές, με την υπολογισμό των μετρήσεων σφάλματος όπως RMSE, MSE, MAE και R^2 για την αξιολόγηση της ακρίβειας του μοντέλου.


Ο παρακάτω πίνακας παρουσιάζει τα αποτελέσματα των μετρήσεων των σφαλμάτων για το μοντέλο Fuzzy Type-2 με βελτιστοποίηση μέσω particle swarm, βασισμένο στο σύνολο δεδομένων των ημερήσιων τιμών κλεισίματος Bitcoin.

Πίνακας 11: Μετρήσεις απόδοσης μοντέλου Fuzzy Type-2 μέσω της PSO βελτιστοποίησης για πρόβλεψη τιμών Bitcoin (εφαρμογή ομαδοποίησης Subtractive Clustering).

	Fuzzy Type-2 (PSO)
MSE	1655023.170
RMSE	1286.477
MAE	911.214
R^2	0.991

Σύμφωνα με τον Πίνακα 12, το μοντέλο Fuzzy Type-2 (μέσω αλγορίθμου βελτιστοποίησης PSO) εμφανίζει RMSE ίσο με 1286.4770, δηλαδή έχει καλύτερη απόδοση από το νευρωνικό δίκτυο (NN) αλλά υστερεί σε σχέση με τα μοντέλα AR, ARMA και τον βέλτιστο συνδυασμό παραμέτρων του ANFIS όσον αφορά την ελαχιστοποίηση του RMSE.


Στο Σχήμα 38 παρουσιάζεται η αρχική δομή του ασαφούς συστήματος συμπερασμού, πριν τη διαδικασία της εκπαίδευσης που συμπεριλαμβάνονται οι συναρτήσεις συμμετοχής με τι σχετικές παραμέτρους τους.



System sugeno21: 2 inputs, 1 outputs, 7 rules

Σχήμα 38: Σύστημα συμπερασμάτων ασαφούς λογικής (FIS) πριν την εκπαίδευση.


Όπως φαίνεται και στο Σχήμα 39, το FIS τύπου-1 μετατρέπεται σε FIS τύπου-2 μετά τη διαδικασία της εκπαίδευσης. Το FIS τύπου-2 ρυθμίζεται χρησιμοποιώντας PSO για τη βελτιστοποίηση των συναρτήσεων συμμετοχής και των κανόνων.



System sugeno21: 2 inputs, 1 outputs, 7 rules

Σχήμα 39: Σύστημα συμπερασμάτων ασαφούς λογικής (FIS) μετά την εκπαίδευση.

Η ακόλουθη γραφική παράσταση απεικονίζει τη σύγκριση μεταξύ των προβλεπόμενων και των πραγματικών τιμών για το μοντέλο Fuzzy Type-2 με βελτιστοποίηση μέσω PSO, με βάση τα δεδομένα του Bitcoin.



Σχήμα 40: Σύγκριση των τελευταίων 60 πραγματικών τιμών εισόδου με τις αντίστοιχες προβλεπόμενες τιμές από το μοντέλο Fuzzy Type-2.


Στη περίπτωση που εφαρμόζεται το Fuzzy C-Means Clustering (FCM) :

Πίνακας 123: Αξιολογήσεις απόδοσης του μοντέλου Fuzzy Type-2, βελτιστοποιημένο μέσω του PSO για την πρόβλεψη τιμών Bitcoin (FCM).

	Fuzzy Type-2 (PSO)
MSE	1394264.366
RMSE	1180.789
MAE	749.594
R^2	0.992

Όπως αναδεικνύεται από τον Πίνακα 12, το μοντέλο Fuzzy Type-2 (PSO) με ομαδοποίηση των δεδομένων μέσω του Fuzzy C-Means Clustering (FCM), αποδίδει σφάλμα ίσο με RMSE 1180.7897, είναι το πιο αποδοτικό μοντέλο, ξεπερνώντας όλα τα υπόλοιπα μοντέλα στην ελαχιστοποίηση του RMSE, καθιστώντας το την ιδανική επιλογή για την πρόβλεψη τιμών του Bitcoin στο συγκεκριμένο πλαίσιο.

Το παρακάτω γράφημα απεικονίζει το πόσο καλά οι προβλέψεις του συστήματος Fuzzy Type-2 ευθυγραμμίζονται με τις πραγματικές τιμές της αγοράς για τα πιο πρόσφατα 60 δείγματα. Οι γραμμές είναι κοντά η μία στην άλλη με ελάχιστη απόκλιση, υποδεικνύοντας ότι το σύστημα αποδίδει αποτελεσματικά την πρόβλεψη των τιμών του Bitcoin.



Σχήμα 41: Σύγκριση των τελευταίων 60 πραγματικών τιμών εισόδου με τις αντίστοιχες προβλεπόμενες τιμές από το μοντέλο Fuzzy Type 2 - (περίπτωση SC).


4.5 Αποτελέσματα του μοντέλου ANFIS για το Ethereum

Το σύνολο των δεδομένων του Ethereum χωρίζεται σε 80% για εκπαίδευση και 20% για δοκιμή, διασφαλίζοντας τη σωστή εκπαίδευση και αξιολόγηση του μοντέλου. Οι κύριοι παράμετροι είναι το βήμα ($ss=0.8$), οι επαναλήψεις ($epoch=400$) και οι συναρτήσεις μέλους ($mf_n=4$), που ρυθμίζονται για την ελαχιστοποίηση των μετρήσεων των σφαλμάτων. Τα αποτελέσματα συνοψίζονται στους παρακάτω πίνακες.


Πίνακας 134: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του Ethereum ($Epoch=400$, $mf=4$, $ss=0.8$).

Epoch=400, mf=4, ss=0.8				
MSE	RMSE	MAE	R^2	MF Type
5903314.549	2429.673	1352.406	0.967	Gbell
4619.642	67.967	43.026	0.986	Gauss
4506.301	67.128	43.404	0.987	Trimf
4289.655	65.495	42.880	0.987	Gauss2
4399.970	66.332	42.554	0.987	Trampf
4240.642	65.120	41.752	0.987	Pimf

Στο ακόλουθο διάγραμμα συγκρίνονται οι πραγματικές τιμές του συνόλου δεδομένων δοκιμής με τις τιμές που προβλέπει το μοντέλο ANFIS για τα τελευταία 60 δείγματα. Ο άξονας x αναπαριστά το χρόνο, ενώ ο άξονας y δείχνει τις τιμές του Ethereum. Τα μπλε τετράγωνα υποδεικνύουν τις πραγματικές τιμές από το σύνολο δεδομένων δοκιμής, ενώ οι κόκκινοι δείκτες αντιπροσωπεύουν τις προβλεπόμενες τιμές από το μοντέλο ANFIS. Όπως εύκολα μπορεί να παρατηρηθεί, το μοντέλο ANFIS έχει επιτύχει υψηλή προβλεπτική ακρίβεια, καθώς οι προβλεπόμενες τιμές του μοντέλου σχεδόν ταυτίζονται με τις πραγματικές τιμές.




Σχήμα 42: Σύγκριση των τελευταίων 60 πραγματικών τιμών εισόδου της χρονοσειράς με τις αντίστοιχες προβλεπόμενες τιμές από το μοντέλο ANFIS, για το σύνολο των δεδομένων του Ethereum.



Σχήμα 43: Σφάλματα πρόβλεψης συναρτήσεως του χρόνου για το μοντέλο ANFIS, για το σύνολο των δεδομένων του Ethereum.

Το Σχήμα-43 απεικονίζει τα σφάλματα πρόβλεψης συναρτήσει του χρόνου. Ο άξονας γ αντιπροσωπεύει το σφάλμα, το οποίο υπολογίζεται ως η διαφορά μεταξύ των πραγματικών τιμών και των προβλεπόμενων τιμών, ενώ ο άξονας x δείχνει τις ημέρες μέτρησης.



Σχήμα 44: Σφάλματα εκπαίδευσης για το σύνολο δεδομένων του Ethereum.

Όπως παρατηρείται στο Σχήμα 46, και σε αυτή τη περίπτωση συνέχιση της αναζήτησης και των δοκιμών πέρα από τις 400 επαναλήψεις δεν είναι αναγκαία, καθώς έχει ελάχιστο αντίκτυπο στη μείωση του RMSE.

Πίνακας 145: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του Ethereum (Epoch=100, mf=4, ss=0.8).

Epoch=100, mf=4, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	4196.591	64.781	41.425	0.988
Gauss	4526.494	67.279	42.679	0.987
Trimf	4508.358	67.144	43.398	0.987
Gauss2	4314.196	65.682	42.216	0.987
Trampf	4336.620	65.853	41.861	0.987
Pimf	4224.130	64.993	41.754	0.987

Πίνακας 156: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του Ethereum (Epoch=200, mf=4, ss=0.8).

Epoch=200, mf=4, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	4226.999	65.015	41.323	0.987
Gauss	4612.822	67.917	42.989	0.986
Trimf	4508.358	67.144	43.398	0.987
Gauss2	4260.970	65.276	42.146	0.987
Tramf	4382.820	66.202	42.358	0.987
Pimf	4240.201	65.116	41.751	0.987

Πίνακας 167: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του Ethereum (Epoch=100, mf=2, ss=0.8).

Epoch=100, mf=2, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	4240.201	65.116	41.751	0.987
Gauss	4149.364	64.415	41.507	0.988
Trimf	4108.415	64.096	41.094	0.988
Gauss2	4212.975	64.907	41.632	0.988
Tramf	4155.399	64.462	41.184	0.988
Pimf	4144.504	64.377	41.430	0.988

Πίνακας 178: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του Ethereum (Epoch=200, mf=2, ss=0.8).

Epoch=200, mf=2, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	4172.531	64.595	41.382	0.988
Gauss	4163.603	64.525	41.442	0.988
Trimf	4108.413	64.096	41.094	0.988
Gauss2	4206.634	64.858	41.637	0.988
Trampf	4155.867	64.466	41.187	0.988
Pimf	4144.504	64.377	41.430	0.988

Πίνακας 189: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του Ethereum (Epoch=400, mf=2, ss=0.8).

Epoch=400, mf=2, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	4171.734	64.588	41.383	0.988
Gauss	4234.048	65.069	41.430	0.987
Trimf	4108.416	64.096	41.094	0.988
Gauss2	4212.008	64.899	41.718	0.988
Trampf	4156.026	64.467	41.187	0.988
Pimf	4144.504	64.377	41.430	0.988

Πίνακας 20: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του Ethereum (Epoch=100, mf=3, ss=0.8).

Epoch=100, mf=3, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	4342.724	65.899	41.911	0.987
Gauss	4303.621	65.601	41.654	0.987
Trimf	4204.784	64.844	41.413	0.988
Gauss2	4327.626	65.784	42.003	0.987
Trampf	4270.139	65.346	41.807	0.987
Pimf	4099.897	64.030	41.833	0.988

Πίνακας 219: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του Ethereum (Epoch=200, mf=3, ss=0.8).

Epoch=200, mf=3, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	4341.195	65.887	41.910	0.987
Gauss	4266.783	65.320	41.775	0.987
Trimf	4202.279	64.824	41.408	0.988
Gauss2	4547.260	67.433	43.498	0.987
Trampf	4294.511	65.532	41.820	0.987
Pimf	4324.622	65.761	42.384	0.987

Πίνακας 22: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του Ethereum (Epoch=400, mf=3, ss=0.8).

Epoch=400, mf=3, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	4341.231	65.880	41.910	0.987
Gauss	4256.076	65.238	41.748	0.987
Trimf	4201.229	64.816	41.398	0.988
Gauss2	4596.218	67.795	43.936	0.986
Trampf	4297.515	65.555	41.869	0.987
Pimf	4285.507	65.463	42.372	0.987

Από τους παραπάνω πίνακες, συμπεραίνουμε ότι για την ελαχιστοποίηση του RMSE στην πρόβλεψη των τιμών του Ethereum, ο καλύτερος συνδυασμός παραμέτρων περιλαμβάνει την συνάρτηση συμμετοχής τύπου Pimf για τον αριθμό εποχών ίσο με 100 (Epochs = 100), με τρεις συναρτήσεις μέλους (mf=3) και μέγεθος βήματος ίσο με 0.08 (ss=0.8). Ο προαναφερθέν συνδυασμός παραμέτρων αποδεικνύεται ο πιο αποτελεσματικός στη μείωση του RMSE, καθώς αποδίδει σφάλμα ίσο με 64.030440, καθιστώντας τον έτσι τη βέλτιστη επιλογή για το εξεταζόμενο προβλεπτικό μοντέλο.

4.6 Αποτελέσματα μοντέλων AR και ARMA για το Ethereum

Ο παρακάτω πίνακας παρουσιάζει τα αποτελέσματα των μετρήσεων σφάλματος για τα μοντέλα AR και ARMA, με βάση το σύνολο δεδομένων των ημερήσιων τιμών κλεισίματος του Ethereum.


Πίνακας 23: Μετρήσεις απόδοσης μοντέλων των AR και ARMA για πρόβλεψη τιμών του Ethereum.

	AR	ARMA
MSE	4174.557	4239.089
RMSE	64.610	65.108
MAE	41.242	41.655
R^2	0.988	0.987

Από τον Πίνακα 23, βλέπουμε ότι για την πρόβλεψη των τιμών του Ethereum, το μοντέλο AR αποδίδει καλύτερα από το μοντέλο ARMA, καθώς επιτυγχάνει χαμηλότερο RMSE (64.61 έναντι 65.11). Αυτό υποδεικνύει ότι το μοντέλο AR έχει μικρότερη μέση απόκλιση από τις πραγματικές τιμές σε σχέση με το ARMA. Ωστόσο, η διαφορά στις μετρήσεις απόδοσης δεν είναι ιδιαίτερα σημαντική, πράγμα που σημαίνει ότι και τα δύο μοντέλα είναι σχετικά συγκρίσιμα για την πρόβλεψη του Ethereum, με το AR να υπερτερεί ελαφρώς.


Η παρακάτω γραφική παράσταση παρουσιάζει τις τελευταίες 60 πραγματικές τιμές του συνόλου δεδομένων, μαζί με τις προβλεπόμενες τιμές του μοντέλου αυτοπαλινδρόμησης (AR). Οι προβλεπόμενες τιμές εμφανίζονται ελαφρώς μετατοπισμένες προς τα δεξιά, χαρακτηριστικό των AR μοντέλων. Οι αποκλίσεις μεταξύ πραγματικών και

προβλεπόμενων τιμών είναι μικρές, υποδεικνύοντας κατά αυτόν τον τρόπο την καλή απόδοση του μοντέλου.



Σχήμα 45: 4 Σύγκριση των τελευταίων 60 πραγματικών τιμών εισόδου με τις αντίστοιχες προβλεπόμενες τιμές από το αυτοπαλινδρομικό μοντέλο (AR), για το σύνολο δεδομένων του Ethereum.

Στο Σχήμα 46 παρουσιάζονται οι τελευταίες 60 πραγματικές τιμές του συνόλου δεδομένων του Ethereum, μαζί με τις προβλεπόμενες τιμές από το μοντέλο αυτοπαλινδρόμησης κινητού μέσου όρου (ARMA). Οι προβλεπόμενες τιμές εμφανίζονται ελαφρώς μετατοπισμένες προς τα δεξιά, το οποίο αποτελεί χαρακτηριστικό των μοντέλων ARMA. Οι αποκλίσεις είναι μικρές, υποδεικνύοντας καλή απόδοση του μοντέλου.



Σχήμα 46: Σύγκριση των τελευταίων 60 πραγματικών τιμών εισόδου με τις αντίστοιχες προβλεπόμενες τιμές από το αυτοπαλινδρομικό μοντέλο κινητού μέσου όρου (ARMA), για το σύνολο δεδομένων του Ethereum.

4.7 Αποτελέσματα του μοντέλου νευρωνικού δικτύου για το Ethereum


Ο ακόλουθος πίνακας παρουσιάζει τα αποτελέσματα των μετρήσεων των σφαλμάτων για το μοντέλο NN, με βάση το σύνολο δεδομένων των ημερήσιων τιμών κλεισίματος του Ethereum.

Πίνακας 24: Μετρήσεις απόδοσης του νευρωνικού δικτύου (NN) για πρόβλεψη τιμών του Ethereum.

	NN
MSE	4221.850
RMSE	64.975
MAE	41.861
R^2	0.987

Από τον Πίνακα 24 παρατηρούμε ότι, το μοντέλο του νευρωνικού δικτύου (NN) έχει RMSE ίσο με 64.98, που είναι ελαφρώς υψηλότερο από το AR (64.61) και το ARMA (65.11), υποδεικνύοντας μεγαλύτερη απόκλιση από τις πραγματικές τιμές. Από την άλλη, όταν το συγκρίνουμε με το βέλτιστο συνδυασμό του μοντέλου ANFIS, το οποίο καταγράφει RMSE 64.38, το ANFIS αποδίδει καλύτερα από τα παραδοσιακά μοντέλα και το νευρωνικό δίκτυο, προσφέροντας μια πιο αξιόπιστη πρόβλεψη για τις τιμές του Ethereum.

Το παρακάτω διάγραμμα απεικονίζει τις τελευταίες 60 πραγματικές τιμές εισόδου του συνόλου δεδομένων του Ethereum, μαζί με τις αντίστοιχες προβλεπόμενες τιμές από το μοντέλο νευρωνικού δικτύου (NN). Και σε αυτή τη περίπτωση, παρατηρούνται μόνο μικρές αποκλίσεις μεταξύ των πραγματικών και των προβλεπόμενων τιμών.



Σχήμα 47: Σύγκριση των τελευταίων 60 πραγματικών τιμών εισόδου με τις αντίστοιχες προβλεπόμενες τιμές από το μοντέλο νευρωνικού δικτύου, για το σύνολο δεδομένων του Ethereum.

4.8 Αποτελέσματα του ασαφούς μοντέλου τύπου 2 (Fuzzy Type-2) με βελτιστοποίηση μέσω του αλγορίθμου PSO για το Ethereum


Ο παρακάτω πίνακας παρουσιάζει τα αποτελέσματα των μετρήσεων των σφαλμάτων για το μοντέλο Fuzzy Type-2 με βελτιστοποίηση μέσω Particle Swarm, βασισμένο στο σύνολο δεδομένων των ημερήσιων τιμών κλεισίματος του Ethereum.

Πίνακας 25: Μετρήσεις απόδοσης μοντέλου Fuzzy Type-2 μέσω της PSO βελτιστοποίησης για πρόβλεψη τιμών του Ethereum (Subtractive Clustering).

	Fuzzy Type-2 (PSO)
MSE	4125.717
RMSE	64.231
MAE	41.144
R^2	0.988

Όπως παρατηρείται στο Πίνακα 25, το μοντέλο Fuzzy Type-2 με βελτιστοποίηση PSO, μέσω της αφαιρετικής ομαδοποίησης (Subtractive Clustering) εμφανίζει σφάλμα RMSE ίσο με 64.23, το οποίο είναι το χαμηλότερο ανάμεσα σε όλα τα μοντέλα που εξετάστηκαν μέχρι τώρα (AR: 64.61, ARMA: 65.11, NN: 64.98, ANFIS: 64.38). Αυτό υποδεικνύει την καλύτερη απόδοση στη μείωση της απόκλισης από τις πραγματικές τιμές για την πρόβλεψη του Ethereum.

Η ακόλουθη γραφική παράσταση απεικονίζει τη σύγκριση μεταξύ των προβλεπόμενων και των πραγματικών τιμών για το μοντέλο Fuzzy Type-2 με βελτιστοποίηση μέσω PSO, με βάση τα δεδομένα του Ethereum.



Σχήμα 48: Σύγκριση των τελευταίων 60 πραγματικών τιμών εισόδου με τις αντίστοιχες προβλεπόμενες τιμές από το μοντέλο Fuzzy Type-2.

Στη περίπτωση που εφαρμόζεται η μέθοδος Fuzzy C-Means Clustering (FCM) :

Πίνακας 26: Αξιολογήσεις απόδοσης του μοντέλου Fuzzy Type-2, βελτιστοποιημένο με PSO για την πρόβλεψη τιμών του Ethereum (FCM).

	Fuzzy Type-2 (PSO)
MSE	4253.455
RMSE	65.218
MAE	42.113
R^2	0.987

Από τον Πίνακα 26 παρατηρούμε ότι, το μοντέλο Fuzzy Type-2 με βελτιστοποίηση PSO και χρήση του Fuzzy C-Means Clustering (FCM) εμφανίζει σφάλμα RMSE ίσο με 65.22, το οποίο είναι υψηλότερο σε σχέση με τα υπόλοιπα μοντέλα, όπως το AR (64.61), το ARMA (65.11), το NN (64.98) και του βέλτιστου συνδυασμού παραμέτρων του μοντέλου ANFIS (64.38). Επομένως, το Fuzzy Type-2 με FCM αποδίδει λιγότερο αποτελεσματικά στην πρόβλεψη των τιμών του Ethereum σε σύγκριση με άλλες προσεγγίσεις, παρουσιάζοντας μεγαλύτερη απόκλιση από τις πραγματικές τιμές.


4.9 Αποτελέσματα του μοντέλου ANFIS για το BNB

Το σύνολο των δεδομένων του Binance Coin (BNB), χωρίζεται σε 80% για εκπαίδευση και 20% για δοκιμή, διασφαλίζοντας τη σωστή εκπαίδευση και αξιολόγηση του μοντέλου. Οι κύριοι παράμετροι είναι το βήμα ($ss=0.8$), οι επαναλήψεις ($epoch=400$) και οι συναρτήσεις μέλους ($mf_n=4$), που ρυθμίζονται για την ελαχιστοποίηση των μετρήσεων των σφαλμάτων. Τα αποτελέσματα συνοψίζονται στους παρακάτω πίνακες.


Πίνακας 27: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του BNB ($Epoch=400$, $mf=4$, $ss=0.8$).

Epoch=400, mf=4, ss=0.8				
MSE	RMSE	MAE	R^2	MF Type
154.022	12.410	8.212	0.982	Gbell
139.965	11.830	6.547	0.984	Gauss
113.203	10.639	6.271	0.987	Trimf
127.525	11.292	6.285	0.985	Gauss2
109.500	10.464	6.280	0.987	Trampf
165.563	12.867	7.581	0.981	Pimf

Στο ακόλουθο διάγραμμα συγκρίνονται οι πραγματικές τιμές του συνόλου δεδομένων δοκιμής με τις τιμές που προβλέπει το μοντέλο ANFIS για τα τελευταία 60 δείγματα. Ο άξονας x αναπαριστά το χρόνο, ενώ ο άξονας y δείχνει τις τιμές του Ethereum. Τα μπλε τετράγωνα υποδεικνύουν τις πραγματικές τιμές από το σύνολο δεδομένων δοκιμής, ενώ οι κόκκινοι δείκτες αντιπροσωπεύουν τις προβλεπόμενες τιμές από το μοντέλο ANFIS.




Σχήμα 49: Σύγκριση των τελευταίων 60 πραγματικών τιμών εισόδου της χρονοσειράς με τις αντίστοιχες προβλεπόμενες τιμές από το μοντέλο ANFIS, για το σύνολο των δεδομένων του BNB.



Σχήμα 50: Σφάλματα πρόβλεψης συναρτήσει του χρόνου για το μοντέλο ANFIS, για το σύνολο των δεδομένων του BNB.

Το Σχήμα 50 απεικονίζει τα σφάλματα πρόβλεψης του μοντέλου ANFIS για το σύνολο δεδομένων του BNB, σε σχέση με το χρόνο. Ο άξονας γ αντιπροσωπεύει το σφάλμα, το οποίο υπολογίζεται ως η διαφορά μεταξύ των πραγματικών τιμών και των προβλεπόμενων τιμών, ενώ ο άξονας x δείχνει τις ημέρες μέτρησης. Και σε αυτή τη περίπτωση παρατηρούμε ότι τα σφάλματα κυμαίνονται γύρω από το μηδέν, με την ύπαρξη ελάχιστων εξαιρέσεων, κάτι που υποδεικνύει την υψηλή προβλεπτική ακρίβεια του μοντέλου.



Σχήμα 51: Σφάλματα εκπαίδευσης για το σύνολο δεδομένων του BNB.

Όπως παρατηρείται στο Σχήμα 51, η συνέχιση της αναζήτησης και των δοκιμών πέρα από τις 400 επαναλήψεις δεν είναι μας εξυπηρετεί, καθώς θα έχει ελάχιστο αντίκτυπο στη μείωση του σφάλματος RMSE.

Πίνακας 28: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του BNB (Epoch=100, mf=4, ss=0.8).

Epoch=100, mf=4, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	142.797	11.949	7.553	0.983
Gauss	132.975	11.531	6.572	0.984
Trimf	113.199	10.639	6.271	0.987
Gauss2	120.403	10.972	6.519	0.986
Trampf	124.712	11.167	7.559	0.985
Pimf	141.357	11.889	7.135	0.984

Πίνακας 29: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του BNB (Epoch=200, mf=4, ss=0.8).

Epoch=200, mf=4, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	147.166	12.131	7.673	0.983
Gauss	134.727	11.607	6.577	0.984
Trimf	113.203	10.639	6.271	0.987
Gauss2	126.002	11.225	6.361	0.985
Trampf	110.288	10.501	6.405	0.987
Pimf	159.816	12.641	7.518	0.981

Πίνακας 30: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του BNB (Epoch=100, mf=2, ss=0.8).

Epoch=100, mf=2, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	111.310	10.550	6.524	0.987
Gauss	107.414	10.364	6.266	0.987
Trimf	110.277	10.501	6.035	0.987
Gauss2	116.916	10.812	6.673	0.986
Trampf	111.043	10.537	6.325	0.987
Pimf	122.209	11.054	7.212	0.986

Πίνακας 320: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του BNB (Epoch=200, mf=2, ss=0.8).

Epoch=200, mf=2, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	111.657	10.566	6.557	0.987
Gauss	111.310	10.550	6.524	0.987
Trimf	110.285	10.501	6.036	0.987
Gauss2	118.622	10.891	6.786	0.986
Trampf	111.032	10.537	6.323	0.987
Pimf	118.151	10.869	6.867	0.986

Πίνακας 32: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του BNB (Epoch=400, mf=2, ss=0.8).

Epoch=400, mf=2, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	111.651	10.566	6.557	0.987
Gauss	107.386	10.362	6.301	0.987
Trimf	110.290	10.501	6.036	0.987
Gauss2	119.037	10.910	6.819	0.986
Trampf	111.030	10.537	6.323	0.987
Pimf	118.151	10.869	6.867	0.986

Πίνακας 33: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του BNB (Epoch=100, mf=3, ss=0.8).

Epoch=100, mf=3, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	106.812	10.335	6.315	0.987
Gauss	147.277	12.135	6.735	0.983
Trimf	116.246	10.781	6.586	0.986
Gauss2	105.523	10.272	6.087	0.988
Tramf	241.931	15.554	8.864	0.972
Pimf	133.726	11.564	7.317	0.984

Πίνακας 34: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του BNB (Epoch=200, mf=3, ss=0.8).

Epoch=200, mf=3, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	108.257	10.404	6.324	0.987
Gauss	164.474	12.824	6.745	0.981
Trimf	116.329	10.785	6.590	0.986
Gauss2	103.822	10.189	6.030	0.988
Tramf	242.978	15.587	8.879	0.972
Pimf	118.430	10.882	6.543	0.986

Πίνακας 35: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του BNB (Epoch=400, mf=3, ss=0.8).

Epoch=400, mf=3, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	108.023	10.393	6.299	0.987
Gauss	172.981	13.152	6.749	0.980
Trimf	116.373	10.787	6.592	0.986
Gauss2	102.843	10.141	5.977	0.988
Tramf	243.044	15.589	8.880	0.972
Pimf	118.430	10.882	6.543	0.986

Όπως φαίνεται από τους παραπάνω πίνακες, στην ανάλυση των αποτελεσμάτων του μοντέλου ANFIS για την πρόβλεψη των ημερήσιων τιμών κλεισίματος του BNB, προκύπτει ότι ο βέλτιστος συνδυασμός παραμέτρων περιλαμβάνει την συνάρτηση συμμετοχής τύπου Gauss2, με τετρακόσιες επαναλήψεις (Epoch=400), τρεις συναρτήσεις μέλους (mf=3) και μέγεθος βήματος (ss=0.8). Το μοντέλο πέτυχε την ελαχιστοποίηση του σφάλματος RMSE, καθώς αποδίδει σφάλμα ίσο με 10.1411, αποδεικνύοντας ότι αυτός ο συνδυασμός παραμέτρων παρέχει την υψηλότερη ακρίβεια στο σύνολο δεδομένων του BNB.

4.10 Αποτελέσματα μοντέλων AR και ARMA για το BNB

Ο παρακάτω πίνακας παρουσιάζει τα αποτελέσματα των μετρήσεων σφάλματος για τα μοντέλα AR και ARMA, με βάση το σύνολο δεδομένων των ημερήσιων τιμών κλεισίματος του BNB.


Πίνακας 36: Μετρήσεις απόδοσης μοντέλων των AR και ARMA για πρόβλεψη τιμών του BNB.

	AR	ARMA
MSE	107.997	111.810
RMSE	10.392	10.574
MAE	5.848	5.982
R^2	0.987	0.987

Σύμφωνα με τα αποτελέσματα του Πίνακα 36, το μοντέλο αυτοπαλινδρόμησης (AR) παρουσιάζει ελαφρώς καλύτερη απόδοση από το μοντέλο αυτοπαλινδρόμησης κινητού μέσου όρου (ARMA), επιτυγχάνοντας χαμηλότερη τιμή σφάλματος RMSE (10.392 έναντι 10.574) για την πρόβλεψη τιμών του BNB. Ωστόσο, ο βέλτιστος συνδυασμός παραμέτρων του μοντέλου ANFIS (Epoch=400, mf=3, ss=0.8, MF Type=Gauss2) επιτυγχάνει ακόμη χαμηλότερο σφάλμα RMSE (10.141), ξεπερνώντας τα ανωτέρω παραδοσιακά μοντέλα.


Η παρακάτω γραφική παράσταση παρουσιάζει τις τελευταίες 60 πραγματικές τιμές του συνόλου δεδομένων, μαζί με τις προβλεπόμενες τιμές του μοντέλου αυτοπαλινδρόμησης (AR). Οι προβλεπόμενες τιμές εμφανίζονται ελαφρώς μετατοπισμένες προς τα δεξιά, χαρακτηριστικό των AR μοντέλων. Οι αποκλίσεις μεταξύ πραγματικών και

προβλεπόμενων τιμών είναι μικρές, υποδεικνύοντας την ικανοποιητική προβλεπτική ικανότητα του μοντέλου.



Σχήμα 52: Σύγκριση των τελευταίων 60 πραγματικών τιμών εισόδου με τις αντίστοιχες προβλεπόμενες τιμές από το αυτοπαλινδρομικό μοντέλο (AR), για το σύνολο δεδομένων του BNB.

Το Σχήμα 53 απεικονίζει τις τελευταίες 60 πραγματικές τιμές του συνόλου δεδομένων του BNB, μαζί με τις αντίστοιχες προβλεπόμενες τιμές που παρήγαγε το μοντέλο αυτοπαλινδρόμησης κινητού μέσου όρου (ARMA). Οι αποκλίσεις παραμένουν περιορισμένες, υποδεικνύοντας την αξιόπιστη απόδοση του μοντέλου.



Σχήμα 53: Σύγκριση των τελευταίων 60 πραγματικών τιμών εισόδου με τις αντίστοιχες προβλεπόμενες τιμές από το αυτοπαλινδρομικό μοντέλο κινητού μέσου όρου (ARMA), για το σύνολο δεδομένων του BNB.

4.11 Αποτελέσματα του μοντέλου νευρωνικού δικτύου για το BNB


Ο ακόλουθος πίνακας παρουσιάζει τα αποτελέσματα μετρήσεων σφάλματος για το μοντέλο NN, με βάση το σύνολο δεδομένων των ημερήσιων τιμών κλεισίματος του BNB.

Πίνακας 37: Μετρήσεις απόδοσης του νευρωνικού δικτύου (NN) για πρόβλεψη τιμών του BNB.

	NN
MSE	117.461
RMSE	10.837
MAE	6.748
R^2	0.986

Σύμφωνα με τα αποτελέσματα του Πίνακα 37, το μοντέλο νευρωνικού δικτύου (NN) για την πρόβλεψη των τιμών του BNB, εμφανίζει σφάλμα RMSE ίσο με 10.838. Αν συγκρίνουμε αυτό το αποτέλεσμα με τον βέλτιστο συνδυασμό παραμέτρων του ANFIS (Epoch=400, mf=3, ss=0.8) που αποδίδει σφάλμα ίσο με RMSE 10.141, βλέπουμε ότι το ANFIS παρουσιάζει καλύτερη απόδοση, με μικρότερο σφάλμα πρόβλεψης σε σχέση με το νευρωνικό δίκτυο και εν συγκρίσει με τα προηγούμενα παραδοσιακά μοντέλα (AR και ARMA).

Το παρακάτω διάγραμμα απεικονίζει τις τελευταίες 60 πραγματικές τιμές εισόδου του συνόλου δεδομένων του BNB, μαζί με τις αντίστοιχες προβλεπόμενες τιμές από το μοντέλο νευρωνικού δικτύου (NN). Και πάλι, παρατηρούνται μόνο μικρές αποκλίσεις μεταξύ των πραγματικών και των προβλεπόμενων τιμών.



Σχήμα 54: Σύγκριση των τελευταίων 60 πραγματικών τιμών εισόδου με τις αντίστοιχες προβλεπόμενες τιμές από το μοντέλο νευρωνικού δικτύου, για το σύνολο δεδομένων του BNB.

4.12 Αποτελέσματα του ασαφούς μοντέλου τύπου 2 (Fuzzy Type-2) με βελτιστοποίηση μέσω του αλγορίθμου PSO για το BNB


Ο παρακάτω πίνακας παρουσιάζει τα αποτελέσματα των μετρήσεων των σφαλμάτων για το μοντέλο Fuzzy Type-2 με βελτιστοποίηση μέσω Particle Swarm Optimization, βασισμένο στο σύνολο δεδομένων των ημερήσιων τιμών κλεισίματος του BNB.

Πίνακας 38: Μετρήσεις απόδοσης μοντέλου Fuzzy Type-2 μέσω της PSO βελτιστοποίησης για πρόβλεψη τιμών του BNB (Subtractive Clustering).

	Fuzzy Type-2 (PSO)
MSE	110.155
RMSE	10.495
MAE	6.046
R^2	0.987

Σύμφωνα με τα αποτελέσματα του παραπάνω πίνακα, το μοντέλο Fuzzy Type-2, μέσω της εφαρμογής του αλγορίθμου βελτιστοποίησης σμήνους σωματιδίων (PSO) και με τη χρήση της αφαιρετικής ομαδοποίησης (Subtractive Clustering), απέδωσε σφάλμα RMSE ίσο με 10.496. Όταν το συγκρίνουμε με τον βέλτιστο συνδυασμό παραμέτρων του ANFIS (Epoch=400, mf=3, ss=0.8), το οποίο έχει RMSE 10.141, παρατηρούμε ότι το ANFIS καταγράφει το χαμηλότερο RMSE, υποδεικνύοντας ότι προσφέρει πιο ακριβή πρόβλεψη για τις τιμές του BNB. Το ίδιο ισχύει και με τη σύγκριση του με τα παραδοσιακά μοντέλα AR, ARMA, και το νευρωνικό δίκτυο (NN), όπου το ANFIS ξεχωρίζει για την καλύτερη απόδοση στο RMSE.

Η ακόλουθη γραφική παράσταση απεικονίζει τη σύγκριση μεταξύ των προβλεπόμενων και των πραγματικών τιμών για το μοντέλο Fuzzy Type-2 με βελτιστοποίηση μέσω PSO, με βάση τα δεδομένα του BNB.



Σχήμα 55: Σύγκριση των τελευταίων 60 πραγματικών τιμών εισόδου με τις αντίστοιχες προβλεπόμενες τιμές από το μοντέλο Fuzzy Type-2.

Στη περίπτωση που εφαρμόζεται η μέθοδος Fuzzy C-Means Clustering (FCM) :

Πίνακας 39: Αξιολογήσεις απόδοσης του μοντέλου Fuzzy Type-2, βελτιστοποιημένο με PSO για την πρόβλεψη τιμών του BNB (FCM).

	Fuzzy Type-2 (PSO)
MSE	116.812
RMSE	10.808
MAE	6.542
R^2	0.986

Σύμφωνα με τα αποτελέσματα του Πίνακα 39, το Fuzzy Type-2 μοντέλο βελτιστοποιημένο με PSO μέσω Fuzzy C-Means Clustering (FCM) εμφανίζει τιμή σφάλματος RMSE ίσο με 10.8080. Αυτή η τιμή είναι υψηλότερη σε σύγκριση με τα αποτελέσματα του βέλτιστου συνδυασμού του ANFIS (RMSE = 10.3934), καθώς και με τα παραδοσιακά μοντέλα AR (RMSE = 10.3922) και ARMA (RMSE = 10.5740). Το ίδιο ισχύει και σε σύγκριση με το νευρωνικό δίκτυο (NN), το οποίο αποδίδει τιμή σφάλματος RMSE ίση με 10.8379. Το ANFIS παραμένει το πιο αποδοτικό μοντέλο σύμφωνα με το RMSE.


4.13 Αποτελέσματα του μοντέλου ANFIS για το Solana

Το σύνολο των δεδομένων του Solana χωρίζεται σε 80% για εκπαίδευση και 20% για δοκιμή, για τη διασφάλιση της σωστής εκπαίδευσης και αξιολόγησης του μοντέλου. Οι κύριοι παράμετροι είναι το βήμα ($ss=0.8$), οι επαναλήψεις ($epoch=400$) και οι συναρτήσεις μέλους ($mf_n=4$), που ρυθμίζονται για την ελαχιστοποίηση των μετρήσεων των σφαλμάτων. Τα αποτελέσματα συνοψίζονται στους παρακάτω πίνακες.


Πίνακας 40: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του Solana ($Epoch=400$, $mf=4$, $ss=0.8$).

Epoch=400, mf=4, ss=0.8				
MSE	RMSE	MAE	R^2	MF Type
24.228	4.922	2.993	0.991	Gbell
23.218	4.818	2.896	0.991	Gauss
21.966	4.686	2.902	0.992	Trimf
23.401	4.837	2.919	0.991	Gauss2
25.567	5.056	3.025	0.991	Trampf
23.374	4.834	2.946	0.991	Pimf

Το παρακάτω γράφημα απεικονίζει τη σύγκριση μεταξύ των προβλεπόμενων και πραγματικών τιμών, καθώς και τη διακύμανση του σφάλματος του μοντέλου ANFIS, για τα δεδομένα του Solana.




Σχήμα 56: Σύγκριση των τελευταίων 60 πραγματικών τιμών εισόδου της χρονοσειράς με τις αντίστοιχες προβλεπόμενες τιμές από το μοντέλο ANFIS, για το σύνολο των δεδομένων του.



Σχήμα 57: Σφάλματα πρόβλεψης συναρτήσει του χρόνου για το μοντέλο ANFIS, για το σύνολο των δεδομένων του Solana.

Το παραπάνω διάγραμμα απεικονίζει τα σφάλματα πρόβλεψης σε σχέση με το χρόνο. Ο άξονας y αντιπροσωπεύει το σφάλμα, το οποίο υπολογίζεται ως η διαφορά μεταξύ των πραγματικών τιμών και των προβλεπόμενων τιμών, ενώ ο άξονας x δείχνει τις ημέρες μέτρησης



Σχήμα 58: Σφάλματα εκπαίδευσης για το σύνολο δεδομένων του Solana.

Όπως παρατηρείται στο Σχήμα 60, και σε αυτή τη περίπτωση η συνέχιση της αναζήτησης και των δοκιμών πέρα από τις 400 επαναλήψεις δεν είναι απαραίτητη, καθώς έχει ελάχιστο αντίκτυπο στη μείωση του RMSE

Πίνακας 421: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του Solana (Epoch=100, mf=4, ss=0.8).

Epoch=100, mf=4, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	23.642	4.862	2.971	0.991
Gauss	23.033	4.799	2.896	0.991
Trimf	22.525	4.746	2.919	0.992
Gauss2	23.464	4.843	2.908	0.991
Trampf	25.518	5.051	3.012	0.991
Pimf	23.395	4.836	2.947	0.991

Πίνακας 42: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του Solana (Epoch=200, mf=4, ss=0.8).

Epoch=200, mf=4, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	24.274	4.926	2.99	0.991
Gauss	23.245	4.821	2.899	0.991
Trimf	22.015	4.692	2.907	0.992
Gauss2	23.506	4.848	2.915	0.991
Trampf	25.570	5.056	3.021	0.991
Pimf	23.374	4.834	2.946	0.991

Πίνακας 43: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του Solana (Epoch=100, mf=2, ss=0.8).

Epoch=100, mf=2, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	22.950	4.790	2.903	0.992
Gauss	22.714	4.765	2.878	0.992
Trimf	22.305	4.722	2.868	0.992
Gauss2	22.462	4.739	2.919	0.992
Trampf	22.567	4.750	2.856	0.992
Pimf	22.950	4.790	2.903	0.992

Πίνακας 44: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του Solana (Epoch=200, mf=2, ss=0.8).

Epoch=200, mf=2, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	22.889	4.784	2.910	0.992
Gauss	22.654	4.759	2.882	0.992
Trimf	22.306	4.722	2.868	0.992
Gauss2	22.541	4.747	2.911	0.995
Trampf	22.566	4.750	2.856	0.992
Pimf	23.645	4.862	2.926	0.991

Πίνακας 45: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του Solana (Epoch=400, mf=2, ss=0.8).

Epoch=400, mf=2, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	23.103	4.806	2.924	0.991
Gauss	22.799	4.774	2.896	0.992
Trimf	22.306	4.722	2.868	0.992
Gauss2	22.489	4.742	2.902	0.992
Trampf	22.567	4.750	2.856	0.992
Pimf	23.645	4.862	2.926	0.991

Πίνακας 46: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του Solana (Epoch=100, mf=3, ss=0.8).

Epoch=100, mf=3, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	23.648	4.862	2.998	0.991
Gauss	22.331	4.725	2.917	0.992
Trimf	29.788	5.457	3.139	0.989
Gauss2	22.220	4.713	2.938	0.992
Trampf	22.108	4.701	2.911	0.992
Pimf	23.194	4.816	2.957	0.991

Πίνακας 47: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του Solana (Epoch=200, mf=3, ss=0.8).

Epoch=200, mf=3, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	23.680	4.866	3.001	0.991
Gauss	21.321	4.617	2.847	0.992
Trimf	33.398	5.779	3.221	0.988
Gauss2	21.825	4.671	2.939	0.992
Trampf	22.116	4.702	2.911	0.992
Pimf	23.077	4.803	2.954	0.991

Πίνακας 48: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του Solana (Epoch=400, mf=3, ss=0.8).

Epoch=400, mf=3, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	23.660	4.864	3.001	0.991
Gauss	22.354	4.728	2.883	0.992
Trimf	33.320	5.772	3.220	0.988
Gauss2	22.411	4.734	2.950	0.992
Trampf	22.114	4.702	2.911	0.992
Pimf	23.077	4.803	2.954	0.991

Από τους παραπάνω πίνακες, παρατηρούμε ότι για την ελαχιστοποίηση του RMSE στην πρόβλεψη των τιμών του Solana, ο καλύτερος συνδυασμός παραμέτρων περιλαμβάνει τη συνάρτηση συμμετοχής τύπου Gauss για τον αριθμό εποχών ίσο με 200 (Epochs = 200), με τρεις συναρτήσεις μέλους ($m_f = 3$) και μέγεθος βήματος ίσο με 0.8 ($ss = 0.8$). Ο συγκεκριμένος συνδυασμός παραμέτρων αποδεικνύεται ως ο πιο αποτελεσματικός στη μείωση του RMSE, καθώς αποδίδει σφάλμα ίσο με 4.617531, καθιστώντας τον έτσι τη βέλτιστη επιλογή για το σύνολο δεδομένων του Solana.

4.14 Αποτελέσματα μοντέλων AR και ARMA για το Solana

Ο παρακάτω πίνακας παρουσιάζει τα αποτελέσματα των μετρήσεων των σφαλμάτων για τα μοντέλα AR και ARMA, με βάση το σύνολο δεδομένων των ημερήσιων τιμών κλεισίματος του Solana.


Πίνακας 49: Μετρήσεις απόδοσης μοντέλων των AR και ARMA για πρόβλεψη τιμών του Solana.

	AR	ARMA
MSE	4174.557	4239.089
RMSE	64.610	65.108
MAE	41.242	41.655
R^2	0.988	0.987

Από τον Πίνακα 49, προκύπτει ότι τα μοντέλα AR και ARMA παρουσιάζουν συγκρίσιμη ακρίβεια με RMSE 64.610816 και 65.108289 αντίστοιχα. Ωστόσο, τα παραδοσιακά αυτά μοντέλα υπολείπονται σε ακρίβεια σε σχέση με το βέλτιστο μοντέλο ANFIS, το οποίο αποδεικνύεται πιο αποτελεσματικό στη μείωση του σφάλματος, για το σύνολο δεδομένων του Solana.


Η παρακάτω γραφική παράσταση παρουσιάζει τις τελευταίες 60 πραγματικές τιμές του συνόλου δεδομένων, μαζί με τις προβλεπόμενες τιμές του μοντέλου αυτοπαλινδρόμησης

(AR). Οι αποκλίσεις μεταξύ πραγματικών και προβλεπόμενων τιμών είναι μικρές, υποδεικνύοντας κατά αυτόν τον τρόπο την καλή απόδοση του μοντέλου.



Σχήμα 59: Σύγκριση των τελευταίων 60 πραγματικών τιμών εισόδου με τις αντίστοιχες προβλεπόμενες τιμές από το αυτοπαλινδρομικό μοντέλο (AR), για το σύνολο δεδομένων του Solana.

Το Σχήμα 60, παρουσιάζει τις τελευταίες 60 πραγματικές τιμές του συνόλου δεδομένων, μαζί με τις προβλεπόμενες τιμές από το μοντέλο αυτοπαλινδρόμησης κινητού μέσου όρου (ARMA). Οι αποκλίσεις είναι μικρές, υποδεικνύοντας καλή απόδοση του μοντέλου.



Σχήμα 60: Σύγκριση των τελευταίων 60 πραγματικών τιμών εισόδου με τις αντίστοιχες προβλεπόμενες τιμές από το αυτοπαλινδρομικό μοντέλο κινητού μέσου όρου (ARMA), για το σύνολο δεδομένων του Solana.

4.15 Αποτελέσματα του μοντέλου νευρωνικού δικτύου για το Solana


Ο ακόλουθος πίνακας παρουσιάζει τα αποτελέσματα μετρήσεων σφάλματος για το μοντέλο NN, με βάση το σύνολο δεδομένων των ημερήσιων τιμών κλεισίματος του Solana.

Πίνακας 50: Μετρήσεις απόδοσης του νευρωνικού δικτύου (NN) για πρόβλεψη τιμών του Solana.

	NN
MSE	4221.850
RMSE	64.975
MAE	41.861
R^2	0.987

Από τα αποτελέσματα που παρουσιάζονται στους πίνακες, παρατηρούμε ότι το μοντέλο νευρωνικού δικτύου (NN) εμφανίζει χαμηλότερη ακρίβεια σε σχέση με το μοντέλο αυτοπαλινδρόμησης (AR), καθώς αποδίδει σφάλμα RMSE ίσο 64.98, ενώ αντίστοιχα το μοντέλο αυτοπαλινδρόμησης αποδίδει σφάλμα ίσο με 64.61. Το μοντέλο ARMA παρουσιάζει ελαφρώς υψηλότερο σφάλμα RMSE (65.11), συγκρινόμενο με τα προηγούμενα. Σε σχέση με τα παραπάνω μοντέλα, το ANFIS με διαφορετικούς τύπους συναρτήσεων συμμετοχής και παραμέτρους, κατά γενική ομολογία, παρέχει την καλύτερη επίδοση στο RMSE, με τις τιμές να κυμαίνονται πιο κοντά στο 64, υπογραμμίζοντας την ικανότητα του για πιο ακριβή πρόβλεψη των τιμών του Solana.

Το παρακάτω διάγραμμα απεικονίζει τις τελευταίες 60 πραγματικές τιμές εισόδου του συνόλου δεδομένων του Solana, μαζί με τις αντίστοιχες προβλεπόμενες τιμές από το μοντέλο νευρωνικού δικτύου (NN). Και πάλι, παρατηρούνται μόνο μικρές αποκλίσεις μεταξύ των πραγματικών και των προβλεπόμενων τιμών.



Σχήμα 61: Σύγκριση των τελευταίων 60 πραγματικών τιμών εισόδου με τις αντίστοιχες προβλεπόμενες τιμές από το μοντέλο νευρωνικού δικτύου, για το σύνολο δεδομένων του Solana.

4.16 Αποτελέσματα του ασαφούς μοντέλου τύπου 2 (Fuzzy Type-2) με βελτιστοποίηση μέσω του αλγορίθμου PSO για το Solana

Ο παρακάτω πίνακας παρουσιάζει τα αποτελέσματα των μετρήσεων των σφαλμάτων για το μοντέλο Fuzzy Type-2 με βελτιστοποίηση μέσω Particle Swarm, βασισμένο στο σύνολο δεδομένων των ημερήσιων τιμών κλεισίματος του Solana.


Πίνακας 522: Μετρήσεις απόδοσης μοντέλου Fuzzy Type-2 μέσω της PSO βελτιστοποίησης για πρόβλεψη τιμών του Solana (Subtractive Clustering).

	Fuzzy Type-2 (PSO)
MSE	22.326
RMSE	4.725
MAE	2.880
R^2	0.992

Από τα αποτελέσματα του μοντέλου Fuzzy Type-2, που βελτιστοποιήθηκε μέσω PSO, στη περίπτωση της αφαιρετικής ομαδοποίησης (Subtractive Clustering), παρατηρούμε ότι το μοντέλο επιτυγχάνει το χαμηλότερο RMSE (4.7251) σε σύγκριση με τα άλλα μοντέλα. Αυτή η χαμηλή τιμή RMSE υποδεικνύει την εξαιρετική απόδοση του μοντέλου στην πρόβλεψη των τιμών του Solana, καθιστώντας το πιο αποτελεσματικό μοντέλο όσον αφορά την ελαχιστοποίηση του σφάλματος.

Η ακόλουθη γραφική παράσταση απεικονίζει τη σύγκριση μεταξύ των προβλεπόμενων και των πραγματικών τιμών για το μοντέλο Fuzzy Type-2 με βελτιστοποίηση μέσω PSO, με βάση τα δεδομένα του Solana. Όπως φαίνεται και στο Σχήμα 62 το εξεταζόμενο

προβλεπτικό μοντέλο πετυχαίνει αρκετά υψηλή απόδοση, καθώς στο σύνολο του δείγματος η απόσταση των προβλεπόμενων τιμών και των πραγματικών είναι ελάχιστη.



Σχήμα 62: Σύγκριση των τελευταίων 60 πραγματικών τιμών εισόδου με τις αντίστοιχες προβλεπόμενες τιμές από το μοντέλο Fuzzy Type-2, για το σύνολο δεδομένων του Solana.

Στη περίπτωση που εφαρμόζεται η μέθοδος Fuzzy C-Means Clustering (FCM) :

Πίνακας 52: Αξιολογήσεις απόδοσης του μοντέλου Fuzzy Type-2, βελτιστοποιημένο με PSO για την πρόβλεψη τιμών του Solana (FCM).

	Fuzzy Type-2 (PSO)
MSE	22.674
RMSE	4.761
MAE	2.894
R^2	0.992

Από τα παραπάνω αποτελέσματα, συμπεραίνουμε ότι για την πρόβλεψη των τιμών του Solana, το μοντέλο Fuzzy Type-2, βελτιστοποιημένο με PSO μέσω Fuzzy C-means Clustering (FCM), επιτυγχάνει το καλύτερο αποτέλεσμα όσον αφορά το RMSE, με τιμή ίση με 4.7251. Αυτή η τιμή του RMSE υποδηλώνει ότι το μοντέλο προσφέρει μια αξιόπιστη πρόβλεψη, συγκριτικά με τα υπόλοιπα μοντέλα, με μοναδική εξαίρεση, την χρήση του ίδιου μοντέλου, αλλά με τη χρήση της αφαιρετικής ομαδοποίησης που αποδίδει σφάλμα RMSE ίσο με 4.7251.


4.17 Αποτελέσματα του μοντέλου ANFIS για το XRP

Το σύνολο των δεδομένων του XRP χωρίζεται σε 80% για εκπαίδευση και 20% για δοκιμή, διασφαλίζοντας τη σωστή εκπαίδευση και αξιολόγηση του μοντέλου. Οι κύριοι παράμετροι είναι το βήμα ($ss=0.8$), οι επαναλήψεις ($epoch=400$) και οι συναρτήσεις συμμετοχής ($mf_n=4$), που ρυθμίζονται για την ελαχιστοποίηση των μετρήσεων των σφαλμάτων. Τα αποτελέσματα συνοψίζονται στους παρακάτω πίνακες.

Πίνακας 53: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του XRP.


Epoch=400, Mf=4, ss=0.8				
MSE	RMSE	MAE	R^2	MF Type
0.0004	0.0219	0.0120	0.9582	Gbell
0.0004	0.0220	0.0121	0.9577	Gauss
0.8353	0.9139	0.9076	-71.2515	Trimf
0.0004	0.0221	0.0123	0.9576	Gauss2
0.8353	0.9139	0.9076	-71.2515	Trampf
0.8353	0.9139	0.9076	-71.2515	Pimf

Στο ακόλουθο διάγραμμα συγκρίνονται οι πραγματικές τιμές του συνόλου δεδομένων δοκιμής με τις τιμές που προβλέπει το μοντέλο ANFIS για τα τελευταία 60 δείγματα. Ο άξονας x αναπαριστά το χρόνο, ενώ ο άξονας y δείχνει τις τιμές του XRP. Τα μπλε τετράγωνα υποδεικνύουν τις πραγματικές τιμές από το σύνολο δεδομένων δοκιμής, ενώ οι κόκκινοι δείκτες αντιπροσωπεύουν τις προβλεπόμενες τιμές από το μοντέλο ANFIS. Από το Σχήμα 63 μπορούμε εύκολα να διακρίνουμε ότι στο εξεταζόμενο δείγμα το μοντέλο ANFIS πέτυχε με ικανοποιητική ακρίβεια την πρόβλεψη των τιμών του XRP, καθώς οι προβλεπόμενες του μοντέλου εμφανίζουν ελάχιστες αποκλίσεις από τις πραγματικές τιμές του κρυπτονομίσματος.




Σχήμα 63: Σύγκριση των τελευταίων 60 πραγματικών τιμών εισόδου της χρονοσειράς με τις αντίστοιχες προβλεπόμενες τιμές από το μοντέλο ANFIS, για το σύνολο των δεδομένων του XRP.

Το Σχήμα 64 απεικονίζει τα σφάλματα πρόβλεψης σε σχέση με το χρόνο. Στον άξονα γ εμφανίζεται το σφάλμα, το οποίο υπολογίζεται ως η διαφορά μεταξύ των πραγματικών και των προβλεπόμενων τιμών, ενώ στον άξονα x αναπαρίστανται οι ημέρες μέτρησης. Το σφάλμα και σε αυτή τη περίπτωση κυμαίνεται κοντά στο μηδέν, όπως είναι και το επιθυμητό αποτέλεσμα, εμφανίζοντας όμως σε ορισμένους χρόνους κορύφωση των τιμών του σφάλματος, όπου το μοντέλο υστέρησε σε απόδοση, δηλαδή είναι τα σημεία στα οποία η απόσταση των πραγματικών και των προβλεπόμενων τιμών ήταν η μέγιστη.



Σχήμα 64: Σφάλματα πρόβλεψης συναρτήσει του χρόνου για το μοντέλο ANFIS, για το σύνολο των δεδομένων του XRP.

Όπως φαίνεται στο παραπάνω γράφημα, η συνέχιση των αναζητήσεων και των δοκιμών πέρα από τις 400 επαναλήψεις δεν είναι αναγκαία, καθώς θα έχει ελάχιστο αντίκτυπο στη επίδρασή της στη μείωση του σφάλματος RMSE.



Σχήμα 65: Σφάλματα εκπαίδευσης για το σύνολο δεδομένων του XRP.

Πίνακας 54: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του XRP (Epoch=100, mf=4, ss=0.8).

Epoch=100, mf=4, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	0.0004	0.0219	0.0120	0.9581
Gauss	0.0005	0.0224	0.0126	0.9562
Trimf	0.8353	0.9139	0.9076	-71.2515
Gauss2	0.0004	0.0223	0.0122	0.9569
Trampf	0.8353	0.9139	0.9076	-71.2515
Pimf	0.8353	0.9139	0.9076	-71.2515

Πίνακας 55: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του XRP (Epoch=200, mf=4, ss=0.8).

Epoch=200, mf=4, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	0.0004	0.0221	0.0122	0.9576
Gauss	0.0005	0.0224	0.0126	0.9562
Trimf	0.8353	0.9139	0.9076	-71.2515
Gauss2	0.0005	0.0223	0.0123	0.9567
Trampf	0.8353	0.9139	0.9076	-71.2515
Pimf	0.8353	0.9139	0.9076	-71.2515

Πίνακας 56: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του XRP (Epoch=100, mf=2, ss=0.8).

Epoch=100, mf=2, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	0.0004	0.0219	0.0120	0.9583
Gauss	0.0005	0.0227	0.0128	0.9551
Trimf	0.0005	0.0223	0.0127	0.9566
Gauss2	0.0004	0.0220	0.0122	0.9579
Trampf	0.8353	0.9139	0.9076	-71.2515
Pimf	0.0004	0.0217	0.0119	0.9590

Πίνακας 57: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του XRP (Epoch=200, mf=2, ss=0.8).

Epoch=200, mf=2, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	0.0004	0.0219	0.0120	0.9583
Gauss	0.0005	0.0227	0.0128	0.9551
Trimf	0.0005	0.0223	0.0127	0.9566
Gauss2	0.0004	0.0220	0.0122	0.9579
Trampf	0.8353	0.9139	0.9076	-71.2515
Pimf	0.0004	0.0217	0.0119	0.9590

Πίνακας 58: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του XRP (Epoch=400, mf=2, ss=0.8).

Epoch=400, mf=2, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	0.0004	0.0219	0.0120	0.9584
Gauss	0.0005	0.0227	0.0128	0.9551
Trimf	0.0005	0.0223	0.0127	0.9566
Gauss2	0.0004	0.0220	0.0122	0.9579
Trampf	0.8353	0.9139	0.9076	-71.2515
Pimf	0.0004	0.0217	0.0119	0.9590

Πίνακας 59: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του XRP (Epoch=100, mf=3, ss=0.8).

Epoch=100, mf=3, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	0.0004	0.0223	0.0123	0.9568
Gauss	0.0004	0.0222	0.0122	0.9573
Trimf	0.0005	0.0230	0.0125	0.9460
Gauss2	0.0005	0.0233	0.0125	0.9446
Trampf	0.7914	0.8896	0.8840	-79.5773
Pimf	0.7914	0.8896	0.8840	-79.5773

Πίνακας 60: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του XRP (Epoch=200, mf=3, ss=0.8).

Epoch=200, mf=3, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	0.0005	0.0230	0.0125	0.9460
Gauss	0.0005	0.0232	0.0124	0.9451
Trimf	0.0005	0.0230	0.0125	0.9460
Gauss2	0.0005	0.0233	0.0125	0.9446
Trampf	0.7914	0.8896	0.8840	-79.5773
Pimf	0.7914	0.8896	0.8840	-79.5773

Πίνακας 623: Μετρήσεις απόδοσης του μοντέλου ANFIS με διαφορετικούς τύπους συνάρτησης συμμετοχής για την πρόβλεψη τιμών του XRP (Epoch=400, mf=3, ss=0.8).

Epoch=400, mf=3, ss=0.8				
MF Type	MSE	RMSE	MAE	R^2
Gbell	0.0005	0.0229	0.0124	0.9465
Gauss	0.0005	0.0229	0.0123	0.9464
Trimf	0.0005	0.0230	0.0125	0.9460
Gauss2	0.0005	0.0233	0.0125	0.9446
Trampf	0.7914	0.8896	0.8840	-79.5773
Pimf	0.7914	0.8896	0.8840	-79.5773

Από τους παραπάνω πίνακες, προκύπτει ότι οι βέλτιστοι συνδυασμοί παραμέτρων για την ελαχιστοποίηση του RMSE στην πρόβλεψη των τιμών του XRP είναι τρεις. Αυτοί οι συνδυασμοί περιλαμβάνουν την συνάρτηση συμμετοχής τύπου Pimf με εκατό επαναλήψεις (Epoch = 100), δύο συναρτήσεις μέλους (mf = 2) και μέγεθος βήματος (ss = 0.8), την ίδια συνάρτηση συμμετοχής αυτή τη φορά σε διακόσιες επαναλήψεις (Epoch = 200), δύο συναρτήσεις μέλους (mf = 2) και μέγεθος βήματος ίσο με (ss = 0.8), καθώς και την ίδια συνάρτηση συμμετοχής με τετρακόσιες επαναλήψεις (Epoch = 400), δύο συναρτήσεις μέλους (mf = 2) και μέγεθος βήματος ίσο με (ss = 0.8). Όλοι αυτοί οι συνδυασμοί παραμέτρων αποδίδουν RMSE ίσο με 0.021762, καθιστώντας τους εξίσου αποτελεσματικούς για το συγκεκριμένο προβλεπτικό μοντέλο. Επομένως, η επιλογή του καλύτερου συνδυασμού μπορεί να βασιστεί σε επιπρόσθετα κριτήρια, όπως ο απαιτούμενος υπολογιστικός χρόνος.

4.18 Αποτελέσματα των μοντέλων AR και ARMA για το XRP


Ο παρακάτω πίνακας παρουσιάζει τα αποτελέσματα των μετρήσεων των σφαλμάτων για τα μοντέλα AR και ARMA, με βάση το σύνολο δεδομένων των ημερήσιων τιμών κλεισίματος του XRP.

Πίνακας 62: Μετρήσεις απόδοσης μοντέλων των AR και ARMA για πρόβλεψη τιμών του XRP.

	AR	ARMA
MSE	4174.5574	4239.0893
RMSE	64.6108	65.1082
MAE	41.2421	41.6554
R^2	0.9881	0.9879


Από τα αποτελέσματα που παρατίθενται στον Πίνακα 62, παρατηρούμε ότι το μοντέλο AR αποδίδει καλύτερα από το μοντέλο ARMA όσον αφορά στην ελαχιστοποίηση του RMSE στην πρόβλεψη των τιμών του XRP. Η τιμή του RMSE για το μοντέλο AR είναι 64.610816, ενώ για το μοντέλο ARMA είναι 65.108289. Αυτό δείχνει ότι το μοντέλο AR καταφέρνει να μειώσει το σφάλμα πιο αποτελεσματικά, γεγονός που το καθιστά πιο αποδοτικό σε σχέση με το ARMA για την πρόβλεψη των τιμών του XRP.

Η παρακάτω γραφική παράσταση παρουσιάζει τις τελευταίες 60 πραγματικές τιμές του συνόλου δεδομένων, μαζί με τις προβλεπόμενες τιμές του μοντέλου αυτοπαλινδρόμησης (AR). Οι προβλεπόμενες τιμές εμφανίζονται ελαφρώς μετατοπισμένες προς τα δεξιά, το οποίο αποτελεί χαρακτηριστικό των μοντέλων αυτοπαλινδρόμησης (AR) μοντέλων. Οι αποκλίσεις μεταξύ πραγματικών και προβλεπόμενων τιμών είναι μικρές, υποδεικνύοντας κατά αυτόν τον τρόπο την καλή απόδοση του μοντέλου.



Σχήμα 66: Σύγκριση των τελευταίων 60 πραγματικών τιμών εισόδου με τις αντίστοιχες προβλεπόμενες τιμές από το αυτοπαλινδρομικό μοντέλο (AR), για το σύνολο δεδομένων του XRP.

Η παρακάτω γραφική παράσταση παρουσιάζει τις τελευταίες 60 πραγματικές τιμές του συνόλου δεδομένων, μαζί με τις προβλεπόμενες τιμές από το μοντέλο αυτοπαλινδρόμησης κινητού μέσου όρου (ARMA). Οι αποκλίσεις μεταξύ των προβλεπόμενων και των πραγματικών τιμών είναι μικρές, υποδεικνύοντας καλή απόδοση του μοντέλου.



Σχήμα 67: Σύγκριση των τελευταίων 60 πραγματικών τιμών εισόδου με τις αντίστοιχες προβλεπόμενες τιμές από το αυτοπαλινδρομικό μοντέλο κινητού μέσου όρου (ARMA), για το σύνολο δεδομένων του XRP.

4.19 Αποτελέσματα του μοντέλου νευρωνικού δικτύου για το XRP


Ο ακόλουθος πίνακας παρουσιάζει τα αποτελέσματα μετρήσεων σφάλματος για το μοντέλο NN, με βάση το σύνολο δεδομένων των ημερήσιων τιμών κλεισίματος του XRP.

Πίνακας 63: Μετρήσεις απόδοσης του νευρωνικού δικτύου (NN) για πρόβλεψη τιμών του XRP.

	NN
MSE	4221.8505
RMSE	64.9757
MAE	41.8612
R^2	0.9879

Από τα αποτελέσματα του Πίνακα 63, παρατηρούμε ότι στα αποτελέσματα του νευρωνικού δικτύου (NN) για την πρόβλεψη των τιμών του XRP, ότι το RMSE του μοντέλου είναι ίσο με 64.975769. Συγκρίνοντας το, με τα υπόλοιπα μοντέλα, παρατηρούμε ότι το νευρωνικό δίκτυο υστερεί ελαφρώς σε σχέση με τον βέλτιστο συνδυασμό του ANFIS (Epoch=100, mf=3, ss=0.8), ο οποίος αποδίδει σφάλμα ίσο με RMSE 64.030440, που είναι το χαμηλότερο από όλα τα μοντέλα. Το μοντέλο AR (RMSE = 64.610816) και το μοντέλο ARMA (RMSE = 65.108289) επίσης υστερούν σε σχέση με το νευρωνικό δίκτυο (NN), αλλά το ANFIS αποδίδει σαφώς καλύτερα αποτελέσματα στην ως προς την ελαχιστοποίηση του RMSE.

Το παρακάτω διάγραμμα απεικονίζει τις τελευταίες 60 πραγματικές τιμές εισόδου του συνόλου δεδομένων του XRP, μαζί με τις αντίστοιχες προβλεπόμενες τιμές από το μοντέλο νευρωνικού δικτύου (NN). Και σε αυτή τη περίπτωση, παρατηρούνται μόνο μικρές αποκλίσεις μεταξύ των πραγματικών και των προβλεπόμενων τιμών.



Σχήμα 68: Σύγκριση των τελευταίων 60 πραγματικών τιμών εισόδου με τις αντίστοιχες προβλεπόμενες τιμές από το μοντέλο νευρωνικού δικτύου, για το σύνολο δεδομένων του XRP.

4.20 Αποτελέσματα του ασαφούς μοντέλου τύπου 2 (Fuzzy Type-2) με βελτιστοποίηση μέσω του αλγορίθμου PSO για το XRP


Ο παρακάτω πίνακας παρουσιάζει τα αποτελέσματα των μετρήσεων των σφαλμάτων για το μοντέλο Fuzzy Type-2 με βελτιστοποίηση μέσω Particle Swarm, βασισμένο στο σύνολο δεδομένων των ημερήσιων τιμών κλεισίματος του XRP.

Πίνακας 64: Μετρήσεις απόδοσης μοντέλου Fuzzy Type-2 μέσω της PSO βελτιστοποίησης για πρόβλεψη τιμών του XRP (Subtractive Clustering).

	Fuzzy Type-2 (PSO)
MSE	0.2261
RMSE	0.0052
MAE	0.1173
R^2	0.9488

Σύμφωνα με τα αποτελέσματα που αναγράφονται στον Πίνακα 64, το μοντέλο Fuzzy Type-2 με βελτιστοποίηση μέσω του αλγορίθμου Particle Swarm Optimization (PSO) και με την εφαρμογή της αφαιρετικής ομαδοποίησης (Subtractive Clustering) υπερέχει σημαντικά σε σύγκριση με τα υπόλοιπα μοντέλα όσον αφορά το RMSE. Συγκεκριμένα, το RMSE του μοντέλου Fuzzy Type-2 είναι 0.0052, το οποίο είναι εξαιρετικά χαμηλότερο από το RMSE του ANFIS (64.030440) και του NN (64.975769). Το RMSE των μοντέλων AR (64.610816) και ARMA (65.108289) είναι επίσης υψηλότερο, καταδεικνύοντας την αποτελεσματικότητα του μοντέλου Fuzzy Type-2 στην ελαχιστοποίηση του σφάλματος πρόβλεψης σε σχέση με όλα τα προηγούμενα μοντέλα.

Η ακόλουθη γραφική παράσταση απεικονίζει τη σύγκριση μεταξύ των προβλεπόμενων και των πραγματικών τιμών για το μοντέλο Fuzzy Type-2 με βελτιστοποίηση μέσω PSO, με βάση τα δεδομένα του XRP. Από το Σχήμα 69 μπορεί να διακριθεί η υψηλή προβλεπτική ικανότητα του παραπάνω μοντέλου, καθώς παρατηρούνται ελάχιστες αποκλίσεις μεταξύ των προβλεπόμενων και των πραγματικών τιμών του κρυπτονομίσματος.



Σχήμα 69: Σύγκριση των τελευταίων 60 πραγματικών τιμών εισόδου με τις αντίστοιχες προβλεπόμενες τιμές από το μοντέλο Fuzzy Type-2, για το σύνολο δεδομένων του XRP.

Στη περίπτωση που εφαρμόζεται η μέθοδος διαχωρισμού των δεδομένων Fuzzy C-Means Clustering (FCM) :

Πίνακας 65: Αξιολογήσεις απόδοσης του μοντέλου Fuzzy Type-2, βελτιστοποιημένο με PSO για την πρόβλεψη τιμών του XRP (FCM).

	Fuzzy Type-2 (PSO)
MSE	0.0006
RMSE	0.0237
MAE	0.0123
R^2	0.9396

Όπως φαίνεται και στον Πίνακα-65, στη περίπτωση του μοντέλου Fuzzy Type-2, βελτιστοποιημένο μέσω του αλγορίθμου Particle Swarm Optimization (PSO) με τη χρήση της μεθόδου διαχωρισμού των δεδομένων Fuzzy C-Means Clustering (FCM), η απόδοση του σφάλματος RMSE για το παραπάνω μοντέλο ανέρχεται σε 0.0237, το οποίο είναι χαμηλότερο από το RMSE του ANFIS (64.030440) και του νευρωνικού δικτύου (64.975769), καθώς και από τα μοντέλα AR (64.610816) και ARMA (65.108289). Παρόλο που το RMSE του μοντέλου Fuzzy Type-2 με FCM είναι μεγαλύτερο από το αντίστοιχο του μοντέλου με Subtractive Clustering (0.0052), παραμένει σημαντικά χαμηλότερο από τα αποτελέσματα των παραδοσιακών μοντέλων και του νευρωνικού δικτύου (NN), αποδεικνύοντας την ικανότητά του να μειώνει το σφάλμα πρόβλεψης εν συγκρίσει με τα υπόλοιπα μοντέλα.

4.21 Συνοπτικός πίνακας αποτελεσμάτων των μετρήσεων σφάλματος και σύγκριση των εφαρμοσμένων μοντέλων


Σε αυτό το κεφάλαιο παρουσιάζονται οι συνοπτικοί πίνακες των κανονικοποιημένων μετρήσεων των σφαλμάτων για τα διάφορα μοντέλα πρόβλεψης που εφαρμόστηκαν σε πέντε στα εξεταζόμενα κρυπτονομίσματα: το Bitcoin, το Ethereum, το Binance Coin (BNB), το Solana και το XRP. Η αποτελεσματικότητα κάθε μοντέλου αξιολογείται μέσω των μετρήσεων σφάλματος, όπως το κανονικοποιημένο μέσο τετραγωνικό σφάλμα (NMSE), το κανονικοποιημένο μέσο ριζικό τετραγωνικό σφάλμα (NRMSE) και το κανονικοποιημένο μέσο απόλυτο σφάλμα (NMAE). Για την ορθή αξιολόγηση και σύγκριση των μοντέλων, σε αυτήν την ενότητα δίνεται έμφαση στο μέσο ριζικό τετραγωνικό σφάλμα. Αυτή η ανάλυση στοχεύει στο να αναδείξει τις πιο αποτελεσματικές μεθόδους για την πρόβλεψη των ημερήσιων τιμών κλεισίματος των κρυπτονομισμάτων μέσω της σύγκρισης των προαναφερθέντων μοντέλων. Η κανονικοποίηση των σφαλμάτων πραγματοποιείται διαιρώντας τα με την τυπική απόκλιση των τιμών κλεισίματος. Αυτό ανεξαρτητοποιεί τις μετρήσεις από την απόλυτη κλίμακα των δεδομένων, διευκολύνοντας μας στη σύγκριση μεταξύ διαφορετικών μοντέλων για τα εξεταζόμενα σύνολα δεδομένων.

BITCOIN:

Πίνακας 66: Συγκεντρωτικός πίνακας αποτελεσμάτων των εφαρμογών των μοντέλων για το Bitcoin.

MODEL	NMSE	NRMSE	NMAE	Best Epochs	Best MFs	Clustering Method
ANFIS	115.606	0.092	0.059	100	2	Grid Partition
AR	103.572	0.087	0.055	-	-	-
ARMA	103.538	0.087	0.055	-	-	-
NN	166.513	0.110	0.079	16	-	-
Fuzzy Type-2	102.624	0.086	0.055	-	-	Subtractive Clustering
Fuzzy Type-2	102.624	0.086	0.055	-	-	FCM

Όπως παρατηρείται από το Πίνακα 66, το μοντέλο ασαφούς λογικής τύπου 2 (Fuzzy Type-2) πέτυχε την καλύτερη απόδοση στο σύνολο δεδομένων του Bitcoin με NRMSE 0.0869, ξεπερνώντας όλα τα υπόλοιπα μοντέλα. Τα μοντέλα AR και ARMA ακολούθησαν με NRMSE 0.0873, δείχνοντας ανταγωνιστική ακρίβεια. Το ANFIS είχε ελαφρώς υψηλότερο NRMSE 0.0922, ενώ το μοντέλο νευρωνικού δικτύου είχε το υψηλότερο NRMSE με 0.1107, υποδεικνύοντας τη χαμηλότερη ακρίβεια. Συνολικά, το Fuzzy Type-2 είναι το πιο αποτελεσματικό μοντέλο για την πρόβλεψη τιμών του Bitcoin, ενώ τα AR και ARMA επίσης αποδίδουν καλά.



Σχήμα 70: Σύγκριση των πέντε μοντέλων πρόβλεψης με τις πραγματικές τιμές: ANFIS, Νευρωνικό Δίκτυο, ARMA, AR και Fuzzy Type-2 για το Bitcoin.

Το παραπάνω διάγραμμα δείχνει ότι το μοντέλο ασαφούς λογικής τύπου 2 (Fuzzy Type-2) ευθυγραμμίζεται με μεγαλύτερη ακρίβεια, με τις πραγματικές τιμές κλεισίματος του Bitcoin, υποδεικνύοντας την αποτελεσματικότητά του στην αποτύπωση των κινήσεων των τιμών, άλλωστε είναι και το μοντέλο που πέτυχε το χαμηλότερο σφάλμα NRMSE. Ενώ τα μοντέλα ANFIS και AR αποδίδουν επίσης καλά, το μοντέλο Fuzzy Type-2 ξεχωρίζει για την ακρίβειά του. Αντίθετα, το μοντέλο νευρωνικού δικτύου δείχνει μεγαλύτερη απόκλιση από τις πραγματικές τιμές, υποδηλώνοντας χαμηλότερη ακρίβεια, σε σύγκριση με τα προαναφερθέντα μοντέλα. Συνολικά, το μοντέλο Fuzzy Type-2 είναι η πιο αποτελεσματική μέθοδος για την πρόβλεψη τιμών του Bitcoin σε αυτήν την ανάλυση.


ETHEREUM:

Στο συγκεντρωτικό Πίνακα 67, παρουσιάζεται συνοπτική απεικόνιση των αποτελεσμάτων για τις κανονικοποιημένες μετρήσεις σφάλματος που απέδωσαν τα εξεταζόμενα προβλεπτικά μοντέλα, στο σύνολο δεδομένων του Ethereum.

Πίνακας 67: Συγκεντρωτικός πίνακας αποτελεσμάτων των εφαρμογών των μοντέλων για το Ethereum.

MODEL	NMSE	NRMSE	NMAE	Best Epochs	Best MFs	Clustering Method
ANFIS	6.906	0.107	0.070	100	3	Grid Partition
AR	7.031	0.108	0.069	-	-	-
ARMA	7.140	0.109	0.070	-	-	-
NN	7.111	0.109	0.070	14	-	-
Fuzzy Type-2	6.949	0.108	0.069	-	-	Subtractive Clustering
Fuzzy Type-2	7.164	0.109	0.070	-	-	FCM

Το μοντέλο ANFIS απέδωσε το χαμηλότερο σφάλμα NRMSE για το Ethereum, με τιμή ίση με 0.1079, υποδεικνύοντας την καλύτερη συνολική ακρίβεια. Το μοντέλο Fuzzy Type-2 μέσω της αφαιρετικής ομαδοποίησης (Subtractive Clustering) ακολούθησε κοντά με NRMSE ίσο με 0.1082, δείχνοντας συγκρίσιμη ακρίβεια. Τα μοντέλα AR και ARMA είχαν ελαφρώς υψηλότερες τιμές NRMSE, 0.1088 και 0.1097 αντίστοιχα. Αντίθετα, το μοντέλο νευρωνικού δικτύου και το ασαφές σύστημα λογικής τύπου 2 (Fuzzy Type-2), εφαρμοσμένο με την μέθοδο ομαδοποίησης των δεδομένων FCM, απέδωσαν τα υψηλότερα NRMSE, 0.1095 και 0.1099 αντίστοιχα. Συνολικά, το μοντέλο ANFIS είναι το πιο αποτελεσματικό για την πρόβλεψη των τιμών του Ethereum.



Σχήμα 71: Σύγκριση των πέντε μοντέλων πρόβλεψης με τις πραγματικές τιμές: ANFIS, Νευρωνικό Δίκτυο, ARMA, AR και Fuzzy Type-2 για το Ethereum.

Το Σχήμα 71 αναδεικνύει την απόδοση διάφορων μοντέλων πρόβλεψης για την πρόβλεψη των τιμών του Ethereum. Το μοντέλο ANFIS επιδεικνύει την υψηλότερη ακρίβεια, ακολουθώντας στενά τις πραγματικές τιμές. Τα μοντέλα ασαφούς λογικής τύπου 2 (Fuzzy Type-2) και το αυτοπαλινδρομικό μοντέλο (AR) αποδίδουν επίσης καλά. Αντίθετα, τα μοντέλα νευρωνικού δικτύου και το αυτοπαλινδρομικό μοντέλο κινητού μέσου όρου (ARMA) δεν ευθυγραμμίζονται τόσο αποτελεσματικά με τις πραγματικές τιμές του Ethereum, υποδεικνύοντας την σχετικά χαμηλή τους απόδοση στο συγκεκριμένο σύνολο των δεδομένων.

Binance Coin (BNB):


Ο παρακάτω συγκεντρωτικός Πίνακας 68 παρέχει μια συνοπτική απεικόνιση των αποτελεσμάτων για τις κανονικοποιημένες μετρήσεις σφάλματος που προέκυψαν από την εφαρμογή των εξεταζόμενων προβλεπτικών μοντέλων στο σύνολο δεδομένων του Binance Coin (BNB).

Πίνακας 68: Συγκεντρωτικός πίνακας αποτελεσμάτων των εφαρμογών των μοντέλων για το BNB.

MODEL	NMSE	NRMSE	NMAE	Best Epochs	Best MFs	Clustering Method
ANFIS	1.092	0.107	0.063	400	3	Grid Partition
AR	1.147	0.110	0.062	-	-	-
ARMA	1.187	0.112	0.063	-	-	-
NN	1.247	0.115	0.071	120	-	-
Fuzzy Type-2	1.367	0.120	0.075	-	-	Subtractive Clustering
Fuzzy Type-2	1.240	0.114	0.069	-	-	FCM

Το μοντέλο ANFIS πέτυχε το χαμηλότερο σφάλμα NRMSE για το Binance Coin, αποδίδοντα σφάλμα ίσο με 0.1077, υποδεικνύοντας την καλύτερη συνολική ακρίβεια. Το μοντέλο AR ακολούθησε με ένα ελαφρώς υψηλότερο NRMSE 0.1104, ενώ το μοντέλο ARMA κατέγραψε ακόμη υψηλότερο NRMSE από το AR. Το μοντέλο νευρωνικού δικτύου απέδωσε NRMSE ίσο με 0.1151, υποδεικνύοντας χαμηλότερη ακρίβεια σε σχέση με τα προηγούμενα μοντέλα. Το μοντέλο Fuzzy Type-2, με την εφαρμογή της μεθόδου Subtractive Clustering παρήγαγε σφάλμα NRMSE ίσο με 0.1205, ενώ το μοντέλο Fuzzy Type-2 με FCM είχε υψηλότερο NRMSE ίσο με 0.1148, υποδεικνύοντας λιγότερη αποτελεσματικότητα σε αυτό το σύνολο δεδομένων. Συνολικά, το ANFIS είναι το πιο αποτελεσματικό μοντέλο για την πρόβλεψη των τιμών του Binance Coin, ακολουθούμενο

από τα μοντέλα AR και ARMA, ενώ τα μοντέλα Fuzzy Type-2 και Νευρωνικού Δικτύου έδειξαν χαμηλότερη ακρίβεια.



Σχήμα 72: Σύγκριση των πέντε μοντέλων πρόβλεψης με τις πραγματικές τιμές: ANFIS, Νευρωνικό Δίκτυο, ARMA, AR και Fuzzy Type-2 για το Binance Coin (BNB).

Το παραπάνω γράφημα απεικονίζει την αποτελεσματικότητα διαφόρων μοντέλων πρόβλεψης για τις τιμές του Binance Coin (BNB). Το μοντέλο ANFIS ξεχωρίζει ως το πιο ακριβές προβλεπτικό μοντέλο, ακολουθώντας στενά τις πραγματικές κινήσεις των τιμών. Ενώ τα υπόλοιπα μοντέλα, όπως τα AR, ARMA, νευρωνικό δίκτυο και Fuzzy Type-2, εμφανίζουν καλή απόδοση, κανένα δεν προσεγγίζει την ακρίβεια του ANFIS. Επομένως το προσαρμοστικό μοντέλο νευρό-ασαφούς λογικής (ANFIS) αποδεικνύεται ως η πιο αποτελεσματική μέθοδος για την πρόβλεψη των τιμών του Binance Coin (BNB).


SOLANA:

Ο Πίνακας 69 παρουσιάζει συνοπτικά τα αποτελέσματα των κανονικοποιημένων μετρήσεων σφάλματος που προέκυψαν από την εφαρμογή των υπό εξέταση προβλεπτικών μοντέλων στο dataset του Solana.

Πίνακας 69: Συγκεντρωτικός πίνακας αποτελεσμάτων των εφαρμογών των μοντέλων για το Solana.

MODEL	NMSE	NRMSE	NMAE	Best Epochs	Best MFs	Clustering Method
ANFIS	0.396	0.085	0.053	200	3	Grid Partition
AR	0.443	0.090	0.054	-	-	-
ARMA	0.453	0.091	0.055	-	-	-
NN	0.436	0.090	0.054	39	-	-
Fuzzy Type-2	0.415	0.088	0.053	-	-	Subtractive Clustering
Fuzzy Type-2	0.422	0.088	0.053	-	-	FCM

Το μοντέλο ANFIS πέτυχε το χαμηλότερο NRMSE για το Solana με 0.08597, υποδεικνύοντας την καλύτερη συνολική ακρίβεια ανάμεσα στα συγκρινόμενα μοντέλα. Το μοντέλο Fuzzy Type-2, μέσω της εφαρμογής της αφαιρετικής ομαδοποίησης των δεδομένων (Subtractive Clustering), ακολούθησε στενά αποδίδοντας σφάλμα NRMSE ίσο με 0.0880, παρουσιάζοντας ανταγωνιστική απόδοση. Το μοντέλο AR κατέγραψε NRMSE ίσο με 0.0909, ενώ το νευρωνικό δίκτυο πέτυχε ελαφρώς καλύτερο σφάλμα NRMSE με 0.0902. Το μοντέλο ARMA είχε το υψηλότερο NRMSE με 0.0919, υποδεικνύοντας χαμηλότερη ακρίβεια σε σχέση με τα υπόλοιπα μοντέλα. Συνοψίζοντας, το μοντέλο ANFIS είναι το πιο αποτελεσματικό μοντέλο για την πρόβλεψη των τιμών του Solana.



Σχήμα 73: Σύγκριση των πέντε μοντέλων πρόβλεψης με τις πραγματικές τιμές: ANFIS, Νευρωνικό Δίκτυο, ARMA, AR και Fuzzy Type-2 για το Solana.

Το παραπάνω διάγραμμα αναπαριστά την αποτελεσματικότητα των εξεταζόμενων μοντέλων πρόβλεψης για τις τιμές του Solana. Το μοντέλο ANFIS αναδεικνύεται ως το πιο ακριβές μοντέλο, καθώς οι προβλεπόμενες τιμές του σχεδόν ταυτίζονται με τις πραγματικές κινήσεις των τιμών. Ενώ άλλα μοντέλα, όπως τα AR, ARMA, νευρωνικό δίκτυο και Fuzzy Type-2, επιδεικνύουν ανταγωνιστική απόδοση, όμως κανένα δεν φτάνει την ακρίβεια του ANFIS. Από την παραπάνω οπτική απεικόνιση των αποτελεσμάτων, καταλήγουμε στο ότι το προβλεπτικό μοντέλο ANFIS κρίνεται ως τη πιο αποτελεσματική μέθοδος για την πρόβλεψη των ημερήσιων τιμών κλεισίματος του Solana σε αυτό το σύνολο δεδομένων.


XRP:

Στον Πίνακα 70 συνοψίζονται τα αποτελέσματα των κανονικοποιημένων μετρήσεων σφάλματος που προέκυψαν από την εφαρμογή των εξεταζόμενων προβλεπτικών μοντέλων στο σύνολο δεδομένων του XRP.

Πίνακας 70: Συγκεντρωτικός πίνακας αποτελεσμάτων των εφαρμογών των μοντέλων για το XRP.

MODEL	NMSE	NRMSE	NMAE	Best Epochs	Best MFs	Clustering Method
ANFIS	0.004	0.202	0.110	200	2	Grid Partition
AR	0.004	0.203	0.112	-	-	-
ARMA	0.004	0.211	0.121	-	-	-
NN	0.004	0.210	0.118	21		-
Fuzzy Type-2	0.005	0.245	0.127	-	-	Subtractive Clustering
Fuzzy Type-2	0.005	0.245	0.127	-	-	FCM

Το μοντέλο ANFIS πέτυχε τη χαμηλότερη τιμή σφάλματος NRMSE για το σύνολο δεδομένων του XRP, με σφάλμα ίσο με 0.004401, πετυχαίνοντας την καλύτερη συνολική ακρίβεια ανάμεσα σε όλα τα άλλα μοντέλα. Το μοντέλο Fuzzy Type-2, με την εφαρμογή της αφαιρετικής ομαδοποίησης των δεδομένων (Subtractive Clustering) ακολούθησε, αποδίδοντας σφάλμα NRMSE ίσο με 0.005800, δείχνοντας ανταγωνιστική απόδοση. Το νευρωνικό δίκτυο κατέγραψε σφάλμα NRMSE 0.004750, ενώ το μοντέλο AR είχε σφάλμα NRMSE ίσο με 0.004467. Το μοντέλο ARMA είχε το υψηλότερο σφάλμα NRMSE με 0.004835, υποδεικνύοντας χαμηλότερη ακρίβεια σε σχέση με τα άλλα μοντέλα. Συνολικά, το ANFIS είναι το πιο αποτελεσματικό μοντέλο για την πρόβλεψη των τιμών του XRP, καταγράφοντας συνολικά το χαμηλότερο κανονικοποιημένο μέσο ριζικό σφάλμα.



Σχήμα 74: Σύγκριση των πέντε μοντέλων πρόβλεψης με τις πραγματικές τιμές: ANFIS, Νευρωνικό Δίκτυο, ARMA, AR και Fuzzy Type-2 για το XRP.

Η παραπάνω γραφική παράσταση συγκρίνει τις προβλέψεις τιμών κλεισίματος του XRP από πέντε συγκρινόμενα μοντέλα (ANFIS, AR, ARMA, NN και FT2-PSO) με τις πραγματικές τιμές του κρυπτονομίσματος. Το μοντέλο ANFIS ξεπερνά όλα τα άλλα, ευθυγραμμίζοντας στενά με τις πραγματικές τιμές του XRP. Αντίθετα, το μοντέλο Fuzzy Type-2 βελτιστοποιημένο μέσω του αλγορίθμου βελτιστοποίησης σμήνους σωματιδίων (PSO) αποδίδει τη χειρότερη ακρίβεια, παρουσιάζοντας μεγαλύτερες αποκλίσεις από τις πραγματικές τιμές. Τα μοντέλα AR, ARMA και NN παρέχουν μέτρια ακρίβεια, αλλά δεν φτάνουν στην απόδοση του ANFIS. Επομένως, όπως αναφέρθηκε και στην ανάλυση του Πίνακα 70, το μοντέλο ANFIS κρίνεται ως η βέλτιστη προβλεπτική μέθοδος για το σύνολο των δεδομένων του XRP, και για τον λόγο αυτό, στην οπτική απεικόνιση των αποτελεσμάτων το ANFIS προσεγγίζει πιο αποτελεσματικά τις πραγματικές τιμές του κρυπτονομίσματος.

Κεφάλαιο 5 : Συμπεράσματα

Η παρούσα διπλωματική εργασία αναδεικνύει την σημαντική δυναμική των νευρό-ασαφών τεχνικών πρόβλεψης, συγκεκριμένα των προσαρμοστικών νευρό-ασαφών συστημάτων συμπερασμάτων (ANFIS) και των ασαφών συστημάτων τύπου 2 (Fuzzy Type-2), για την ακριβή πρόβλεψη των ημερήσιων τιμών κλεισίματος των κρυπτονομισμάτων. Δεδομένης της εγγενούς αστάθειας και της πολυπλοκότητας των κρυπτοαγορών, οι παραδοσιακές μέθοδοι πρόβλεψης όπως το αυτοπαλινδρομικό μοντέλο (AR) και το αυτοπαλινδρομικό μοντέλο κινητού μέσου όρου (ARMA) συχνά αδυνατούν να συλλάβουν τη μη γραμμική συμπεριφορά που παρατηρείται σε αυτά τα περιουσιακά στοιχεία. Η παρούσα μελέτη αποσκοπεί στην αντιμετώπιση αυτών των περιορισμών, ενσωματώνοντας προηγμένες τεχνικές πρόβλεψης που αξιοποιούν τα πλεονεκτήματα τόσο της ασαφούς λογικής όσο και των τεχνητών νευρωνικών δικτύων.

Τα ευρήματα της μελέτης αποκάλυψαν ότι το προσαρμοστικό νευρό-ασαφές σύστημα εξαγωγής συμπερασμάτων (ANFIS) υπερείχε συνεχώς των περισσότερων παραδοσιακών μεθόδων πρόβλεψης και του πρώσο-τροφοδοτούμενου νευρωνικού δικτύου στα εξεταζόμενα κρυπτονομίσματα που αναλύθηκαν. Συγκεκριμένα, το ANFIS παρουσίασε υψηλότερη ακρίβεια στην πρόβλεψη των τιμών κλεισίματος για το Ethereum, το Binance Coin, το Solana και το XRP, αναδεικνύοντας την ικανότητα του στο να χειρίζεται τη σύνθετη μεταβλητότητα και τις αβεβαιότητες της αγοράς κρυπτονομισμάτων. Οι μετρήσεις απόδοσης έδειξαν ότι το ANFIS παρήγαγε τα καλύτερα αποτελέσματα, επιτυγχάνοντας τις χαμηλότερες τιμές στα κανονικοποιημένα σφάλματα, όπως το κανονικοποιημένο μέσο τετραγωνικό σφάλμα (NMSE), το κανονικοποιημένο ριζικό μέσο τετραγωνικό σφάλμα (NRMSE) και το κανονικοποιημένο μέσο απόλυτο σφάλμα (NMAE), επιβεβαιώνοντας την αποτελεσματικότητά του στη σύλληψη των κινήσεων των τιμών.

Επιπλέον, το μοντέλο του πρώσο-τροφοδοτούμενου νευρωνικού δικτύου αποδείχθηκε επίσης αποτελεσματικό για την πρόβλεψη τιμών κρυπτονομισμάτων, ιδίως στην ανίχνευση σύνθετων μη γραμμικών τάσεων. Ωστόσο, και σε αυτή τη σύγκριση, το ANFIS υπερείχε του ανατροφοδοτούμενου νευρωνικού δικτύου, επιτυγχάνοντας καλύτερες αποδόσεις στις μετρήσεις των σφαλμάτων, λόγω της καλύτερης ικανότητάς του να διαχειρίζεται την αβεβαιότητα και τις διακυμάνσεις της αγοράς. Αυτό υποδεικνύει ότι, ενώ τα νευρωνικά δίκτυα είναι κατάλληλα για την αναγνώριση μοτίβων σε μη γραμμικά δεδομένα, η ακρίβεια πρόβλεψής τους μπορεί να ενισχυθεί περαιτέρω όταν συνδυάζονται με την ασαφή λογική, όπως παρατηρείται στην προσέγγιση του μοντέλου ANFIS, η οποία συνδυάζει τη προσαρμοστικότητα των νευρωνικών δικτύων με τη ερμηνευσιμότητα των ασαφών συστημάτων.

Ωστόσο, αξιοσημείωτο είναι ότι το μοντέλο ANFIS δεν υπερείχε σταθερά σε όλες τις περιπτώσεις. Στο σύνολο των δεδομένων του Bitcoin, το μοντέλο ασαφούς λογικής τύπου 2 (Fuzzy Type-2) πέτυχε την καλύτερη απόδοση, καθώς παρουσίασε μικρότερες αποκλίσεις μεταξύ των προβλεπόμενων και των πραγματικών τιμών.

Επιπλέον, τα παραδοσιακά μοντέλα όπως τα μοντέλα, αυτοπαλινδρόμησης (AR) και το αυτοπαλινδρομικό μοντέλο κινητού μέσου όρου (ARMA), παρουσίασαν ισχυρή απόδοση, συχνά ακολουθώντας στενά το ANFIS. Αυτή η απόκλιση στα αποτελέσματα υπογραμμίζει τη σημασία της επιλογής του κατάλληλου μοντέλου και την ανάγκη για μια λεπτομερή προσέγγιση στην πρόβλεψη, καθώς διαφορετικά μοντέλα ενδέχεται να εμφανίζουν διαφορετικά επίπεδα αποτελεσματικότητας ανάλογα με τα ιδιαίτερα χαρακτηριστικά των δεδομένων που αναλύεται.

Στη συγκεκριμένη εργασία υπογραμμίζεται επίσης η σημασία της εύρεσης των βέλτιστων συναρτήσεων συμμετοχής και των μεθόδων ομαδοποίησης, καθώς αυτές οι παράμετροι επηρέασαν σημαντικά την απόδοση των μοντέλων. Με την κατάλληλη επιλογή αυτών των παραμέτρων, η έρευνα κατάφερε να αναδείξει την προβλεπτική ακρίβεια του μοντέλου προσαρμοστικού νευρό-ασαφούς μοντέλου εξαγωγής συμπερασμάτων (ANFIS) και του μοντέλου νευρό-ασαφούς λογικής τύπου 2 (Fuzzy Type-2), αναδεικνύοντας τη δυναμική των νευρό-ασαφών τεχνικών στον χρηματοοικονομικό τομέα.

Συμπερασματικά, η παρούσα διατριβή συμβάλλει στην κατανόηση των προηγμένων μεθόδων πρόβλεψης στον τομέα των κρυπτονομισμάτων. Παρόλο που το προσαρμοστικό νευρό-ασαφές μοντέλο εξαγωγής συμπερασμάτων (ANFIS) αποδείχθηκε ένα ισχυρό εργαλείο πρόβλεψης, στην πλειοψηφία των εξεταζόμενων περιπτώσεων, η διαφοροποίηση της απόδοσής του ανάμεσα σε διαφορετικά κρυπτονομίσματα υποδεικνύει ότι ένας συνδυασμός των μεθόδων μπορεί να αποφέρει ακόμη καλύτερα αποτελέσματα. Μελλοντικές έρευνες θα μπορούσαν να εξετάσουν τα υβριδικά μοντέλα που ενσωματώνουν τα πλεονεκτήματα παραπάνω προσεγγίσεων, με στόχο τη περαιτέρω βελτίωση της ακρίβειας των προβλέψεων.

Βιβλιογραφία:

1. Atsalakis G. S., Atsalaki I. G., Pasiouras F., Zopounidis C. (2019). Bitcoin price forecasting with neuro-fuzzy techniques: 771-779.
2. Atsalakis G. S. and Valavanis K. P. (2009). Forecasting stock market short-term trends using a neuro-fuzzy based methodology: 10697-10706.
3. Barak S. and Sadegh S. S. (2016). Forecasting energy consumption using ensemble ARIMA–ANFIS hybrid algorithm: 93-103.
4. Bataineh K. M., Najia M. and Saqera, M. (2011). A comparison study between various fuzzy clustering algorithms: 336-342.
5. Brockwell P. J. and Davis Richard A. (2016). *Introduction to Time Series and Forecasting*: 7-8, 157-193.
6. Buterin V. (2014). Ethereum: A next-generation smart contract and decentralized application platform: 1-36.
7. Cocco L., Tonelli R. and Marchesi M. (2021). Predictions of bitcoin prices through machine learning based frameworks: 1-20.
8. Castellano G., Castiello C., Fanelli A. M. and Jain L. C. (2007). Evolutionary neuro-fuzzy systems and applications.
9. Chandra D. S. B., Shill P. C. and Murase K. (2013). Particle swarm optimization based adaptive strategy for tuning of fuzzy logic controller: 37-48.
10. Chang P. C. and Fan C. Y. (2008). A hybrid system integrating a wavelet and TSK fuzzy rules for stock price forecasting: 802-813.
11. Chang P. C. and Liu C. H. (2008). A TSK type fuzzy rule-based system for stock price prediction: 136-143.
12. Chlif H., Kanzari D. and Bensaid Y. R. (2022). Adaptive Neuro-Fuzzy system to predict cryptocurrency variation in stable and crisis periods: Case of COVID-19.
13. Djari A. (2023). Influence of the membership functions number of fuzzy logic controller on the performances of dynamic systems: 93-104.
14. Ehteram M., Teo F. Y., Ahmed A. N., Latif S. D., Huang Y. F., Abozweita O., Al-Ansari N. and El-Shafie A. (2021). Performance improvement for infiltration rate prediction using hybridized Adaptive Neuro-Fuzzy Inferences System (ANFIS) with optimization algorithms: 1666-1675.
15. Garrido A. (2012). A brief history of fuzzy logic: 71-76.
16. Guerra M. L., Sorini L. and Stefanini L. (2020). Bitcoin analysis and forecasting through fuzzy transform: 338-353.
17. Jain A. and Sharma A. (2020). Membership function formulation methods for fuzzy logic systems: A comprehensive review: 8718-8731.
18. Jang J. S. R. (1993). ANFIS: Adaptive-network-based fuzzy inference system: 1-13.
19. Karabıyık B. K. and Ergün Z. C. (2021). Forecasting Bitcoin prices with the ANFIS model: 295-315.

20. Klir G. J. and Yuan B. (1995). *Fuzzy sets and fuzzy logic: Theory and applications*: 11-22, 212-236.
21. Kumbure M., Mailagaha L., Christoph L. and Pasi P. J. Machine Learning Techniques and Data for Stock Market Forecasting: A Literature Review (2022): 1–35.
22. Lahmiri S. and Bekiros S. (2020). Intelligent forecasting with machine learning trading systems in chaotic intraday Bitcoin market: 1-7.
23. Lee R. S. Chaotic Type-2 Transient-Fuzzy Deep NeuroOscillatory Network (CT2TFDNN) for Worldwide Financial Prediction (2019): 1–15.
24. Lee R. S. (2023). Fuzzy Time Series for financial applications: 22-34.
25. Livieris I. E., Kiriakidou N., Stavroyiannis S. and Pintelas P. (2021). An advanced CNN-LSTM model for cryptocurrency forecasting: 1-15.
26. Livieris I. E., Stavroyiannis S., Pintelas E., Kotsilieris T. and Pintelas P. (2020). A dropout weight constrained recurrent neural network model for forecasting the price of major cryptocurrencies and CCI30 index: 86-99.
27. Maciel L., Ballini R. and Gomide F. (2021). Adaptive fuzzy modeling of interval-valued stream data and application in cryptocurrencies prediction.
28. Maciel L., Ballini R., Gomide F. and Yager R. R. Forecasting Cryptocurrencies Prices Using Data-Driven Level Set Fuzzy Models (2021): 1–12.
29. Mamdani E. H. and Assilian S. An Experiment in Linguistic Synthesis with a Fuzzy Logic Controller (1975): 1–13.
30. McNally S., Roche J. and Caton S. (2018). Predicting the price of Bitcoin using machine learning: 339-343.
31. Melin P. and Castillo O. (2014). A review on type-2 fuzzy logic applications in clustering, classification and pattern recognition: 569-576.
32. Mendel J. M., John R. I. and Liu F. (2006). Interval type-2 fuzzy logic systems made simple: 808-821.
33. Mendel J. M. and John R. I. Bob. (2002). Type-2 fuzzy sets made simple: 117-126.
34. Mehrban A. and Ahadian P. An Adaptive Network-Based Approach for Advanced Forecasting of Cryptocurrency Values (2023): 1–10.
35. Mo H., Wang F. Y., Zhou M., Li R. and Xiao Z. Footprint of Uncertainty for Type-2 Fuzzy Sets (2014): 97–108.
36. Mogharreban N. and DiLalla L. F. Comparison of Defuzzification Techniques for Analysis of Non-Interval Data (2006).

37. MonirVaghefi H., Sandgani M. R. and Shoorehdeli M. A. (2013). Interval type-2 Adaptive Network-based Fuzzy Inference System (ANFIS) with type-2 non-singleton fuzzification: 1-13.
38. Nakamoto S. (2008). Bitcoin: A peer-to-peer electronic cash system: 1-8.
39. Nelson D. M. Q., Pereira A. C. M. and Arantes D. R. (2017). Stock market's price movement prediction with LSTM neural networks: 1420-1424.
40. Oladipo S., Sun Y. and Amole A. O. Investigating the Influence of Clustering Techniques and Parameters on a Hybrid PSO-Driven ANFIS Model for Electricity Prediction (2024).
41. Pal S. S. and Kar S. Time Series Forecasting for Stock Market Prediction Through Data Discretization by Fuzzistics and Rule Generation by Rough Set Theory (2019): 18–29.
42. Qiu W., Zhang C. and Ping Z. (2015). Generalized fuzzy time series forecasting model enhanced with particle swarm optimization: 130-138.
43. Rahman J. (2024). Simply understanding artificial neural networks (ANN): Deep learning.
44. Rustum R, Kurichiyanil J., Anu M., Forrest S., Sommariva C., Adeloye A. J., Zounemat K. M. and Scholz M. (2020). Sustainability ranking of desalination plants using Mamdani fuzzy logic inference systems: 1-6.
45. Septiarini T. W., Taufik M. R., Afif M. and Masyrifah A. R. A Comparative Study for Bitcoin Cryptocurrency Forecasting in Period 2017–2019 (2020): 2–10.
46. Schwartz D., Youngs N. and Britto A. (2014). *Ripple Protocol Consensus Algorithm White Paper*: 1-8.
47. Sedighi M., Jahangirnia Hossein, Gharakhani Mohsen and Farahani Fard Saeed. (2019). A novel hybrid model for stock price forecasting based on metaheuristics and support vector machine: 3-11.
48. Song Q. and Chissom B. S. (1991). Fuzzy time series and its models: 269-276.
49. Takagi T. and Sugeno M. (1985). Fuzzy identification of systems and its applications to modeling and control: 116-132.
50. Velthuizen R. P., Hall L. O., Clarke L. P. and Silbiger M. L. (1996). An investigation of mountain method clustering for large data sets:1123-1134.
51. Wei L. Y. (2013). A hybrid model based on ANFIS and adaptive expectation genetic algorithm to forecast TAIEX: 894-899.
52. Wu J. and Zhao Y. (2019). Machine learning technology in the application of genome analysis: A systematic review: 149-155.
53. Yakovenko A. (2017). Solana. A new architecture for a high performance blockchain v0.8.13: 1-32.

54. Zhao C., Wang R., Hofbauer J., Jha S. and Xia Y. (2021). Cryptocurrency prediction using advanced machine learning methods: Survey and future directions: 1-9.
55. Zhao C., Wang R., Hofbauer J., Jankunas P., Yan A. and Li S. Binance Whitepaper (2017): 3–17.
56. Hajek P., Froelich W., Olej V. and Novotny J. Neural intuitionistic fuzzy system with justified granularity (2022).