

ΠΑΝΕΠΙΣΤΗΜΙΟ ΝΕΑΠΟΛΗΣ ΠΑΦΟΥ

ΔΙΑΠΑΝΕΠΙΣΤΗΜΙΑΚΟ ΜΕΤΑΠΤΥΧΙΑΚΟ ΠΡΟΓΡΑΜΜΑ ΣΠΟΥΔΩΝ
ΑΝΑΛΥΣΗΣ ΔΕΔΟΜΕΝΩΝ ΚΑΙ
ΧΡΗΜΑΤΟΟΙΚΟΝΟΜΙΚΗΣ ΤΕΧΝΟΛΟΓΙΑΣ

Αξιολόγηση Μοντέλων Τεχνητής Νοημοσύνης
σε Χρηματιστηριακές Συναλλαγές Κρυπτονομισμάτων:
Επίδοση, Αποδοτικότητα και Σύγκριση με Ανθρώπινες Στρατηγικές

ΠΑΝΑΓΙΩΤΗΣ ΚΟΣΜΙΔΗΣ

ΑΜ: 1236303212

ΕΠΙΒΛΕΠΟΝΤΕΣ ΚΑΘΗΓΗΤΕΣ
ΧΡΗΣΤΟΣ ΦΛΩΡΟΣ, ΣΑΒΒΑΣ ΧΑΤΖΗΧΡΙΣΤΟΦΗΣ

ΙΑΝΟΥΑΡΙΟΣ, 2025

ΆΔΕΙΑ ΧΡΗΣΗΣ

Η τρέχουσα διπλωματική εργασία προστατεύεται από πνευματικά δικαιώματα και διατίθεται υπό την άδεια Creative Commons Attribution-NonCommercial-NoDerivatives 4.0 International (CC BY-NC-ND 4.0). Σύμφωνα με αυτή την άδεια, επιτρέπεται η κοινοποίηση της εργασίας στην αρχική της μορφή, υπό τον όρο ότι αναφέρεται ο συγγραφέας. Ωστόσο, απαγορεύεται ρητά η εμπορική εκμετάλλευση, η διανομή της σε τροποποιημένη μορφή ή η δημιουργία παράγωγων έργων. Για τυχόν αιτήματα υπέρβασης των ορίων αυτής της άδειας ή άλλα θέματα σχετικά με τα δικαιώματα, παρακαλείστε να επικοινωνήσετε απευθείας με τον συγγραφέα.

ΔΗΛΩΣΗ ΓΝΗΣΙΟΤΗΤΑΣ

Με την παρούσα δήλωση, επιβεβαιώνω ότι είμαι ο αποκλειστικός συντάκτης αυτής της διπλωματικής εργασίας. Κάθε είδους βοήθεια που έλαβα για την εκπόνησή της έχει αναγνωριστεί πλήρως στην εργασία. Πρόκειται για πρωτότυπη ερευνητική προσπάθεια, η οποία δεν έχει υποβληθεί αλλού για απόκτηση πτυχίου ή άλλου ακαδημαϊκού τίτλου. Παράλληλα, αναλαμβάνω την πλήρη ευθύνη για οποιεσδήποτε συνέπειες σε περίπτωση που αποδειχθεί ότι η εργασία δεν μου ανήκει.

Επιπλέον, δηλώνω ότι η Μεταπτυχιακή Διατριβή εκπονήθηκε σύμφωνα με τις απαιτήσεις του Πανεπιστημίου Νεάπολις στο πλαίσιο εξ αποστάσεως μεταπτυχιακών σπουδών και εγκρίθηκε από την τριμελή Εξεταστική Επιτροπή (αναγράφονται παρακάτω τα μέλη), την 27^η Ιανουαρίου 2025.

Μέλη Εξεταστικής Επιτροπής

- Πρώτος επιβλέπων: Χρήστος Φλώρος, Καθηγητής
- Μέλος Εξεταστικής Επιτροπής: Ιωάννης Χατζηαντωνίου, Αναπληρωτής Καθηγητής
- Μέλος Εξεταστικής Επιτροπής: Δημήτριος Βορτελίνος, Επίκουρος Καθηγητής

ΑΠΟΠΟΙΗΣΗ ΕΥΘΥΝΗΣ

Οι πληροφορίες που παρουσιάζονται στην παρούσα διπλωματική εργασία παρέχονται μόνο για ενημερωτικούς σκοπούς. Βασίζεται στην ερευνητική διαδικασία σύμφωνα με τον κανονισμό του Ευρωπαϊκού Κοινοβουλίου, με τη χρήση εργαλείων ελεύθερου και μη ελεύθερου λογισμικού και τα αποτελέσματα είναι προσβάσιμα μέσω των σχετικών συνδέσμων και πηγών που αναφέρονται στην εργασία.

Η παρούσα ερευνητική εργασία τηρεί πλήρως τις οδηγίες δεοντολογίας που ορίζονται από το Πανεπιστήμιο Νεάπολις Πάφου. Δεν περιλαμβάνει ανθρώπινα εμβρυϊκά βλαστικά κύτταρα (hESC), ανθρώπινα έμβρυα, ανθρώπινους εμβρυϊκούς ιστούς/κύτταρα, ανθρώπους ή/και ζώα που συμμετέχουν στην έρευνα, ούτε φυσικές παρεμβάσεις. Δεν περιλαμβάνει συλλογή ή επεξεργασία προσωπικών δεδομένων και δεν περιλαμβάνει την εισαγωγή ή εξαγωγή πόρων, υλικών ή προσωπικών δεδομένων μεταξύ της ΕΕ και τρίτων/εκτός ΕΕ χωρών. Επιπλέον, η έρευνα δεν αφορά χώρες με χαμηλό ή χαμηλό μεσαίο εισόδημα και δεν ενέχει κινδύνους για τα άτομα ή το περιβάλλον, συμπεριλαμβανομένης της βλάβης σε ζώα, φυτά, πανίδα, χλωρίδα ή προστατευόμενες περιοχές. Η εργασία δεν έχει στρατιωτικές εφαρμογές και δεν μπορεί να χρησιμοποιηθεί για κακόβουλη, εγκληματική ή τρομοκρατική κατάχρηση.

ΕΥΧΑΡΙΣΤΙΕΣ

Θα ήθελα αρχικά να εκφράσω τις θερμότερες ευχαριστίες μου στον επιβλέποντα καθηγητή μου, Δρ. Χρήστο Φλώρο, για την ασταμάτητη καθοδήγηση, την επιστημονική ακρίβεια και την ουσιαστική υποστήριξή του κατά τη διάρκεια της διπλωματικής αυτής. Η επαγγελματική και φιλική του προσέγγιση συνέβαλε αποφασιστικά στην ολοκλήρωση της έρευνας.

Ειδική μνεία οφείλω στον Δρ. Σάββα Χατζηχριστοφή, που με στήριξε έμπρακτα εγκρίνοντας άμεσα το ερευνητικό αντικείμενο, και στον Δρ. Νικόλαο Μπάκα, ο οποίος με προσανατόλισε σφαιρικά στον κλάδο της Τεχνητής Νοημοσύνης και προσέφερε καίριες συμβουλές για τη διεύρυνση των γνώσεών μου.

Δεν θα μπορούσα να παραλείψω να ευχαριστήσω τις εταιρίες και οργανισμούς που μου προσέφεραν την ευκαιρία να συμμετάσχω σε εφαρμογές μεγάλης κλίμακας. Η πρακτική εμπειρία που απέκτησα μέσω αυτών των συνεργασιών επέτρεψε τη σύνδεση θεωρίας και πράξης, εμπλουτίζοντας την ανάλυση της εργασίας.

Στο προσωπικό πεδίο, οφείλω να αναγνωρίσω τη συμβολή των συναδέρφων και φίλων μου, οι οποίοι μοιράστηκαν μαζί μου ιδέες, με βοήθησαν να ξεπεράσω αμφιβολίες και μου πρόσφεραν ψυχολογική στήριξη σε κρίσιμες στιγμές. Ειδικότερα, η οικογένειά μου υπήρξε ο πιο αξιόπιστος στύλος: η άνευ όρων αγάπη, η υπομονή και η πίστη τους στις δυνατότητές μου με ενίσχυσαν σε κάθε βήμα αυτού του απαιτητικού ταξιδιού. Χωρίς την ηθική και συναισθηματική τους παρέα, αυτό το επίτευγμα δεν θα ήταν δυνατό.

Τέλος, αφιερώνω σε όλους όσους πιστέψατε στη δυναμική μου και με ενθαρρύνατε να ακολουθήσω το πάθος μου για τη γνώση. Η συλλογική σας στήριξη υπήρξε ο κινητήριος μοχλός της προσπάθειας αυτής.

ΠΕΡΙΛΗΨΗ

Η παρούσα διπλωματική εργασία επικεντρώνεται στην αξιολόγηση μοντέλων Τεχνητής Νοημοσύνης (TN) που εφαρμόζονται σε χρηματιστηριακές συναλλαγές κρυπτονομισμάτων. Στόχος της έρευνας είναι να εξετάσει την απόδοση και την αποδοτικότητα αυτών των μοντέλων σε σχέση με στρατηγικές που υιοθετούνται από ανθρώπινους επενδυτές, αναδεικνύοντας τα πλεονεκτήματα, τα μειονεκτήματα και τις πιθανές χρήσεις τους.

Η μεθοδολογία περιλαμβάνει τη συλλογή δεδομένων χρηματιστηριακών συναλλαγών και την εφαρμογή αλγορίθμων TN, όπως δίκτυα βαθιάς μάθησης (Deep Learning) και άλλες τεχνικές μηχανικής μάθησης (Machine Learning). Τα αποτελέσματα συγκρίνονται με ανθρώπινες στρατηγικές μέσω προσομοιώσεων που αποσκοπούν στην αξιολόγηση της ακρίβειας πρόβλεψης, της ταχύτητας εκτέλεσης και της συνολικής αποδοτικότητας. Επιπλέον, τα ευρήματα υποστηρίζονται από τη συλλογή και ανάλυση δεδομένων μέσω ενός ερευνητικού ερωτηματολογίου, το οποίο αποσκοπεί στην καταγραφή απόψεων και εμπειριών σχετικά με τη χρήση TN στις χρηματοοικονομικές συναλλαγές.

Η ανάλυση έδειξε ότι τα μοντέλα TN υπερτερούν σε ταχύτητα και δυνατότητα ανάλυσης μεγάλου όγκου δεδομένων σε πραγματικό χρόνο. Ωστόσο, παρατηρήθηκαν ορισμένοι περιορισμοί, όπως η υπερπροσαρμογή (overfitting) σε συγκεκριμένα σύνολα δεδομένων και η έλλειψη προσαρμοστικότητας σε μη προβλέψιμες αλλαγές της αγοράς. Παράλληλα, διαπιστώθηκε ότι οι ανθρώπινες στρατηγικές βασίζονται σε ευρύτερη εμπειρική γνώση και καλύτερη κατανόηση μη ποσοτικών παραγόντων της αγοράς.

Συμπερασματικά, η εργασία καταλήγει ότι μια υβριδική προσέγγιση, που συνδυάζει την ταχύτητα και ακρίβεια των μοντέλων TN με τη διαίσθηση και την εμπειρία των ανθρώπων, μπορεί να προσφέρει την πιο ολοκληρωμένη στρατηγική για χρηματιστηριακές συναλλαγές κρυπτονομισμάτων. Επιπλέον, συνοδεύεται από πρακτική υλοποίηση TN, η οποία προσφέρει παράδειγμα εφαρμογής για μελλοντική χρήση.

Λέξεις-κλειδιά: Τεχνητή Νοημοσύνη, Χρηματιστηριακές Συναλλαγές, Κρυπτονομίσματα, Απόδοση Μοντέλων, Ανθρώπινες Στρατηγικές.

ABSTRACT

This thesis focuses on the evaluation of Artificial Intelligence (AI) models applied to cryptocurrency trading. The aim of the research is to assess the performance and efficiency of these models in comparison with strategies employed by human investors, highlighting their advantages, limitations, and potential applications.

The methodology involves collecting cryptocurrency trading data and applying AI algorithms, such as Deep Learning networks and other Machine Learning techniques. The results are compared with human strategies through simulations that evaluate prediction accuracy, execution speed, and overall efficiency.

The analysis revealed that AI models outperform in terms of speed and their ability to analyze large volumes of data in real-time. However, certain limitations were observed, such as overfitting to specific datasets and a lack of adaptability to unpredictable market changes. At the same time, human strategies rely on broader experiential knowledge and better understanding of non-quantitative market factors.

In conclusion, the thesis suggests that a hybrid approach, combining the speed and accuracy of AI models with the intuition and expertise of humans, can offer the most comprehensive strategy for cryptocurrency trading. The findings of this research hold significant value for investors, financial technology companies, and researchers interested in optimizing investment strategies.

Keywords: Artificial Intelligence, Trading, Cryptocurrencies, Model Performance, Human Strategies.

ΠΙΝΑΚΑΣ ΠΕΡΙΕΧΟΜΕΝΩΝ

ΕΙΣΑΓΩΓΗ.....	1
1 – ΘΕΩΡΗΤΙΚΗ ΘΕΜΕΛΙΩΣΗ	3
1.1 Βασικές Αρχές Τεχνητής Νοημοσύνης (TN)	3
1.1.1 Θεμελιώδεις Τεχνολογίες και Μέθοδοι	3
1.1.2 Εφαρμογές και Προοπτικές	4
1.2 Τεχνικές Μηχανικής Μάθησης και Δικτύων Βαθιάς Μάθησης	4
1.2.1 Μηχανική Μάθηση	5
1.2.2 Δίκτυα Βαθιάς Μάθησης	5
1.2.3 Σύγκριση και Εφαρμογές ML και DL	6
1.3 Γενετικοί Αλγόριθμοι και Βελτιστοποίηση	7
1.3.1 Θεωρητική Θεμελίωση Γενετικών Αλγορίθμων	7
1.3.2 Εφαρμογή στη Ρύθμιση Υπερπαραμέτρων.....	8
1.4 Perceptrons και Multilayered Perceptrons.....	9
1.4.1 Αρχιτεκτονική Perceptrons	9
1.4.2 Δικτυακές Δομές Multilayered Perceptrons	10
1.4.3 Εφαρμογές στη Χρηματιστηριακή Ανάλυση.....	12
1.5 Εφαρμογές TN στις Χρηματιστηριακές Συναλλαγές	12
1.5.1 Προβλέψεις και Ανάλυση Τάσεων	13
1.5.2 Εντοπισμός Απάτης και Διαχείριση Κινδύνων.....	13
1.5.3 Algorithmic Trading	14
1.6 Στρατηγικές Ανθρώπινων Επενδυτών	14
1.6.1 Άπειροι Επενδυτές	14
1.6.2 Ιδιώτες Επενδυτές (Home Traders)	15
1.6.2.1 FOMO (Fear Of Missing Out)	15
1.6.3 Επαγγελματίες Επενδυτές	15
1.6.4 Προσέγγιση Κινδύνου: Ρίσκο και Συντηρητικότητα.....	16
1.6.5 Συνδυασμός Στρατηγικών.....	16
1.6.6 Εξελίξεις και Τεχνολογία.....	16
1.7 Ηθικά Ζητήματα και Προκλήσεις στη Χρήση της TN.....	17
1.7.1 Διαφάνεια και Λογοδοσία.....	17
1.7.2 Προκαταλήψεις και Αμεροληψία	18
1.7.3 Ιδιωτικότητα και Ασφάλεια	18
1.7.4 Οικονομικές και Κοινωνικές Ανισότητες	18
1.7.5 Στρατιωτική και Κακόβουλη Χρήση	19
1.7.6 Συμπεράσματα και Ηθικά Πλαίσια.....	19
2 – ΕΡΩΤΗΜΑΤΟΛΟΓΙΟ	20
2.1 Το Ερωτηματολόγιο ως Ερευνητικό Εργαλείο.....	20
2.2 Παρουσίαση του Ερωτηματολογίου.....	21
2.3 Αποτελέσματα και Συζήτηση Ερωτηματολογίου.....	22
2.3.1 Δημογραφική Ανάλυση Συμμετεχόντων	23
2.3.2 Επίπεδα Εμπιστοσύνης στην TN	25
2.3.3 Σύγκριση Εμπιστοσύνης μεταξύ TN και Ανθρώπινων Εμπόρων.....	29
2.3.4 Αντιλήψεις και Ανησυχίες για τη Χρήση TN στις Επενδύσεις	31
2.4 Συμπεράσματα	33

3 – ΒΙΒΛΙΟΓΡΑΦΙΚΗ ΑΝΑΣΚΟΠΗΣΗ ΚΑΙ ΥΦΙΣΤΑΜΕΝΕΣ ΠΡΟΣΕΓΓΙΣΕΙΣ.....	35
3.1	Παρουσίαση Σχετικών Ερευνών.....35
3.2	Ανάλυση Υφιστάμενων Τεχνολογιών και Εργαλείων.....37
3.2.1	Πλατφόρμες Συλλογής και Ανάλυσης Δεδομένων.....37
3.2.2	Εργαλεία Ανάλυσης Μηχανικής Μάθησης και Βαθιάς Μάθησης.....37
3.2.3	Τεχνολογίες Ανάλυσης Συναισθήματος (Sentiment Analysis)38
3.2.4	Προκλήσεις και Περιορισμοί των Υφιστάμενων Τεχνολογιών.....38
3.3	Ανοιχτά Ζητήματα και Προκλήσεις στη Βιβλιογραφία39
3.3.1	Διαφάνεια και Εξηγήσιμες Προσεγγίσεις.....39
3.3.2	Ποιότητα και Διαθεσιμότητα Δεδομένων.....40
3.3.3	Υπερεκπαίδευση και Γενίκευση40
3.3.4	Υπολογιστικοί Πόροι και Δυναμική Αγορών.....41
3.3.5	Αναδυόμενες Αγορές και Εξειδικευμένες Προσεγγίσεις41
3.3.6	Σύγχρονες Τάσεις και Μελλοντικές Κατευθύνσεις41
3.4	Συμβολή της Παρούσας Έρευνας.....42
3.4.1	Ανάλυση Αποτελεσματικότητας Αλγορίθμων Μηχανικής Μάθησης.....42
3.4.2	Διαχείριση Δεδομένων και Ποιότητας.....42
3.4.3	Ανάλυση Επενδυτικής Στρατηγικής.....43
4 – ΠΕΡΙΓΡΑΦΗ ΔΕΔΟΜΕΝΩΝ	44
4.1	Δομή του Συνόλου Δεδομένων.....44
4.1.1.1	Πρωτογενή Χαρακτηριστικά45
4.1.1.2	Παράγωγα Χαρακτηριστικά.....45
4.1.1.3	Τεχνικοί Δείκτες.....46
4.1.1.4	Διαχείριση Χαρακτηριστικών.....46
4.2	Περιγραφική Στατιστική των Χαρακτηριστικών48
4.2.1	Τιμές και Όγκοι.....48
4.2.2	Τεχνικοί Δείκτες48
4.2.3	Ανάλυση Κατά Έτος.....48
4.2.4	Κατανομή και Outliers.....49
4.2.5	Τάσεις και Ανάλυση Χρόνου.....50
4.2.6	Ανάλυση Συσχετίσεων.....50
4.3	Ζητήματα Ποιότητας Δεδομένων51
4.3.1	Κενές Εγγραφές51
4.3.2	Ακραίες Τιμές (Outliers).....51
4.3.3	Μεταβλητότητα και Θόρυβος.....52
4.3.4	Ποιότητα Δεδομένων και Συσχετίσεις.....52
4.4	Οπτικοποίηση των Δεδομένων52
4.4.1	Επισκόπηση Ιστορικών Τιμών Κλεισίματος52
4.4.2	Ανάλυση Τιμών Κλεισίματος μέσω Boxplots55
4.4.3	Κατανομή Τιμών Κλεισίματος58
4.4.4	Κατανομή Τεχνικών Δεικτών58
4.4.5	Ανάλυση Συσχετίσεων μέσω Heatmap.....60
4.5	Συμπεράσματα61
5 – ΜΕΘΟΔΟΛΟΓΙΑ	63
5.1	Προετοιμασία Δεδομένων για Εκπαίδευση από Μοντέλα TN.....63
5.1.1	Καθαρισμός και Μετασχηματισμός Δεδομένων63
5.1.2	Διαχωρισμός Στόχου και Χαρακτηριστικών63
5.1.3	Διασφάλιση Ακεραιότητας Δεδομένων64

5.1.4	Μηχανική Χαρακτηριστικών (Feature Engineering).....	65
5.1.5	Επιλογή Χαρακτηριστικών (Feature Selection)	66
5.1.6	Scaling και Διαχωρισμός Δεδομένων	66
5.2	Σχεδιασμός και Υλοποίηση Αλγορίθμων TN.....	67
5.2.1	Μοντέλο LGBMClassifier με το scikit-learn.....	67
5.2.1.1	Υπερπαραμετροποίηση με Γενετικό Αλγόριθμο	68
5.2.1.2	Αποφυγή Τοπικών Ελαχίστων	69
5.2.2	Απλό Μοντέλο Perceptron.....	69
5.2.3	Multilayered Perceptron (MLP).....	70
5.2.4	Δίκτυο Βαθιάς Μάθησης (Deep Learning).....	71
5.2.4.1	Convolutional Neural Networks (CNN)	72
5.2.4.2	Recurrent Neural Networks (RNN)	72
5.2.5	Σύγκριση Επιδόσεων Μεταξύ Μοντέλων TN	73
5.2.5.1	Ανάλυση Αποτελεσμάτων Κερδοφορίας	73
5.2.5.2	Ανθεκτικότητα σε Ασταθή Περιβάλλοντα.....	75
5.2.5.3	Ταχύτητα Εκπαίδευσης και Κλιμακωσιμότητα	76
5.3	Στρατηγικές Trading και Προσομοίωση	77
5.3.1	Σχεδιασμός Στρατηγικών Ανθρώπινων Εμπόρων	77
5.3.1.1	Προσομοίωση Emotional Traders.....	77
5.3.1.2	Προσομοίωση Home Traders.....	80
5.3.1.3	Προσομοίωση Έμπειρων Traders	82
5.3.2	Σύγκριση Ανθρώπινων Στρατηγικών	83
5.3.3	Σύγκριση Στρατηγικών TN.....	84
5.3.4	Εφαρμογή Στρατηγικών TN και Σύγκριση με Ανθρώπινες Στρατηγικές.....	85
6	– ΠΑΡΟΥΣΙΑΣΗ ΑΠΟΤΕΛΕΣΜΑΤΩΝ	86
6.1	Ανάλυση Αποτελεσμάτων των Μοντέλων TN.....	86
6.1.1	Αποτελέσματα του LGBMClassifier	86
6.1.2	Αποτελέσματα του Perceptron.....	88
6.1.3	Αποτελέσματα του Multilayered Perceptron	90
6.1.4	Αποτελέσματα του Convolutional Neural Networks (CNN).....	93
6.1.5	Αποτελέσματα του Recurrent Neural Network (RNN)	97
6.1.6	Σύγκριση Επιδόσεων Μεταξύ Μοντέλων.....	100
6.2	Ανάλυση Στρατηγικών Ανθρώπινων Διαπραγματευτών.....	102
6.2.1	Απόδοση Στρατηγικής Emotional Trader	102
6.2.2	Απόδοση Στρατηγικής Home Trader	104
6.2.3	Απόδοση Στρατηγικής Έμπειρου Συντηρητικού Trader	107
6.2.4	Απόδοση Στρατηγικής Έμπειρου Φιλικού προς το Ρίσκο Trader	109
6.2.5	Σύγκριση Στρατηγικών Ανθρώπινων Διαπραγματευτών	112
6.3	Συγκριτική Ανάλυση Μοντέλων TN και Ανθρώπινων Στρατηγικών	114
6.3.1	Σύγκριση Απόδοσης TN και Ανθρώπινων Στρατηγικών	114
6.3.2	Ανάλυση Κινδύνου και Αποδόσεων.....	115
6.3.3	Επιδράσεις στο Ασταθές Περιβάλλον του Bitcoin.....	115
7	– ΚΩΔΙΚΑΣ ΚΑΙ ΕΦΑΡΜΟΓΕΣ	117
7.1	Λογική Διαχείρισης Συναλλαγών για Τα Μοντέλα Τεχνητής Νοημοσύνης.....	117
7.2	Προσομοίωση Ανθρώπινων Στρατηγικών Trading	118
7.3	Προσαρμοσμένες Συναρτήσεις Κόστους για Μοντέλα Βαθιάς Μάθησης.....	120
7.4	Βελτιστοποίηση Υπερπαραμέτρων με Γενετικό Αλγόριθμο.....	122
8	– ΣΥΖΗΤΗΣΗ ΚΑΙ ΣΥΜΠΕΡΑΣΜΑΤΑ	124

8.1	Συζήτηση Αποτελεσμάτων	124
8.1.1	Σύνοψη Κύριων Ευρημάτων.....	124
8.1.2	Σύγκριση με τη Βιβλιογραφία	125
8.1.3	Ερμηνεία των Αποτελεσμάτων	126
8.1.4	Σύνδεση με τα Ευρήματα του Ερωτηματολογίου.....	128
8.2	Επιπτώσεις για την Αγορά και τους Επενδυτές.....	128
8.2.1	Επιπτώσεις στην Αγορά.....	128
8.2.2	Επιπτώσεις στους Επενδυτές	129
8.2.3	Επιπτώσεις στις Πλατφόρμες Συναλλαγών	131
8.3	Συμπεράσματα	132
8.3.1	Συμβολή στη Βιβλιογραφία	134
8.4	Μελλοντικές Ερευνητικές Κατευθύνσεις	135
8.4.1	Υβριδικές Στρατηγικές	135
8.4.2	Επεξηγήσιμη Τεχνητή Νοημοσύνη (ΧΑΙ).....	137
8.4.3	Εφαρμογή σε Σταθερούς Δείκτες Αγοράς	138
8.4.4	Ανάλυση σε Μακροχρόνιες Περιόδους	139
8.4.5	Χρήση Ticker Δεδομένων Αντί Λεπτομερών Δεδομένων.....	141
8.4.6	Προσαρμογή σε Ακραία Σενάρια	142
8.4.7	Παράλληλος Υπολογισμός με Χρήση CUDAs	144
8.4.8	Κοινωνικοοικονομικές Επιπτώσεις	145
ΒΙΒΛΙΟΓΡΑΦΙΑ.....		148
ΠΑΡΑΡΤΗΜΑΤΑ.....		152
ΠΑΡΑΡΤΗΜΑ Α Repository Πλήρη Κώδικα.....		152
ΠΑΡΑΡΤΗΜΑ Β Αποφάσεις Trading για AI Μοντέλα		152
ΠΑΡΑΡΤΗΜΑ Γ Αποφάσεις Trading για Simulators Ανθρώπινων Στρατηγικών		154
ΠΑΡΑΡΤΗΜΑ Δ Loss Function για RNN.....		155
ΠΑΡΑΡΤΗΜΑ Ε Loss Function για CNN.....		156
ΠΑΡΑΡΤΗΜΑ ΣΤ Fitness Συνάρτηση για Γενετικό Αλγόριθμο		157
ΠΑΡΑΡΤΗΜΑ Ζ Συνάρτηση Μετάλλαξης για Γενετικό Αλγόριθμο		158

ΕΙΣΑΓΩΓΗ

Οι ταχείες εξελίξεις στην τεχνητή νοημοσύνη (TN) και η διαρκής επέκταση του κόσμου των κρυπτονομισμάτων έχουν μεταβάλλει ριζικά το τοπίο των χρηματοοικονομικών συναλλαγών, φέρνοντας στην επιφάνεια τόσο απρόβλεπτες δυσκολίες όσο και πρωτοποριακές δυνατότητες. Σε ένα περιβάλλον όπου οι αγορές κυμαίνονται απρόβλεπτα και η ανάλυση δεδομένων γίνεται ολοένα πιο πολύπλοκη, η αναζήτηση νέων λύσεων που ισορροπούν την τεχνολογική ταχύτητα με την ανθρώπινη κριτική σκέψη αποτελεί κρίσιμη προτεραιότητα. Μέσα σε αυτόν τον δυναμικό χώρο, τα μοντέλα TN έχουν αναδειχθεί ως ένα από τα πρωτεύοντα εργαλεία για την εκτίμηση κινδύνων και την αξιοποίηση νέων επενδυτικών προοπτικών – με μια σημαντική, ωστόσο, εκκρεμότητα: ποιος είναι ακριβώς ο ρόλος της ανθρώπινης εμπειρίας μπροστά στη μαθηματική ακρίβεια των αλγορίθμων;

Αυτή η έρευνα εμβαθύνει στη σύγκρουση – και τον ενδεχόμενο συνεργασίας – μεταξύ τεχνολογίας και ανθρώπινης δημιουργικότητας, εξετάζοντας πώς τα μοντέλα TN ανταγωνίζονται ή συμπληρώνουν τις στρατηγικές των επενδυτών στις αγορές κρυπτονομισμάτων. Χρησιμοποιώντας πραγματικά δεδομένα συναλλαγών, εφαρμόζονται προηγμένες τεχνικές μηχανικής μάθησης και προσομοιώνονται διαφορετικά σενάρια, ώστε να αποκρυσταλλωθούν τα δυνατά και αδύνατα σημεία κάθε προσέγγισης. Διερευνάται, επίσης, πώς η ποικιλία των ανθρώπινων στρατηγικών – από τον ερασιτέχνη μέχρι τον έμπειρο διαχειριστή κεφαλαίων – αλληλεπιδρά με τις αλγοριθμικές λύσεις.

Θεωρητικά, η μελέτη αγγίζει θεμέλια όπως τα νευρωνικά δίκτυα, οι γενετικοί αλγόριθμοι για τη βελτιστοποίηση παραμέτρων, και η δυναμική των αυτοματοποιημένων συστημάτων συναλλαγών. Στην πράξη, εστιάζει σε πραγματικές εφαρμογές: την πρόβλεψη τάσεων, τον έλεγχο κινδύνων, ακόμα και την ανίχνευση ύποπτων συναλλαγών. Παράλληλα, καταγράφει πώς οι άνθρωποι αποκωδικοποιούν μη αριθμητικά δεδομένα – από κοινωνικά δρώμενα έως πολιτικές εξελίξεις – που συχνά διαφεύγουν από τα αλγοριθμικά μοντέλα.

Τα ευρήματα υπογραμμίζουν ότι η TN διαθέτει αδιαμφισβήτητα πλεονεκτήματα στην επεξεργασία τεράστιων δεδομένων σε χρόνο ρεαλιστικό, προσφέροντας μαθηματική ακρίβεια. Ωστόσο, αποκαλύπτεται ότι οι «αδυναμίες» των αλγορίθμων – όπως η τάση για υπερπροσαρμογή ή η δυσκολία αντιμετώπισης εξαιρετικών γεγονότων – συχνά

ανακυκλώνονται ως πλεονεκτήματα της ανθρώπινης κρίσης. Ενώ τα μοντέλα μπορεί να προβλέψουν μια πτώση της αγοράς βασισμένα σε ιστορικά δεδομένα, ο άνθρωπος μπορεί να αντιληφθεί πως μια απρόσμενη πολιτική κρίση θα ενεργοποιήσει αλυσιδωτές αντιδράσεις.

Ως αποτέλεσμα, προτείνεται ένας υβριδικός τρόπος σκέψης: ένας συνδυασμός που ενσωματώνει την υπολογιστική οξύτητα της ΤΝ με την ευελιξία της ανθρώπινης διαίσθησης. Αυτό το πλαίσιο δεν στοχεύει μόνο στη βελτίωση των αποδόσεων, αλλά και στη δημιουργία ενός διαλόγου μεταξύ τεχνητής και φυσικής νοημοσύνης. Με αυτόν τον τρόπο, η εργασία προσφέρει μια πύλη για μελλοντικές εξελίξεις, όπου η συνύπαρξη τεχνολογικών και ανθρώπινων παραγόντων μπορεί να αναπτύξει νέες μορφές οικονομικής δημιουργίας. Η συμβολή της εστιάζει τόσο στην ακαδημαϊκή συζήτηση όσο και στην πραγματική πράξη, υπογραμμίζοντας ότι το μέλλον των χρηματοοικονομικών αγορών δεν θα καθοριστεί από την τεχνολογία ή τον άνθρωπο μόνο του – αλλά από τον τρόπο που αυτές οι δύο συνιστώσες θα μάθουν να συνυπάρχουν δημιουργικά.

1 – Θεωρητική Θεμελίωση

1.1 Βασικές Αρχές Τεχνητής Νοημοσύνης (TN)

Η Τεχνητή Νοημοσύνη (TN) αποτελεί έναν από τους πιο δυναμικούς και πρωτοποριακούς τομείς της σύγχρονης επιστήμης. Η TN επιδιώκει να μιμηθεί ανθρώπινες γνωστικές λειτουργίες, όπως η μάθηση, η επίλυση προβλημάτων και η λήψη αποφάσεων, μέσω υπολογιστικών συστημάτων και αλγορίθμων. Αυτή η προσέγγιση βασίζεται στη συνδυασμένη γνώση από διάφορους επιστημονικούς κλάδους, όπως η επιστήμη των υπολογιστών, η στατιστική, η νευροεπιστήμη και η γλωσσολογία.

Η TN διακρίνεται σε τρεις βασικές κατηγορίες. Η "Στενή Τεχνητή Νοημοσύνη" (Narrow AI) επικεντρώνεται στην εκτέλεση συγκεκριμένων εργασιών, όπως η αναγνώριση εικόνων ή η επεξεργασία φυσικής γλώσσας (Natural Language Processing - NLP). Η "Γενική Τεχνητή Νοημοσύνη" (General AI) αποσκοπεί στη δημιουργία συστημάτων που μπορούν να εκτελούν οποιαδήποτε πνευματική εργασία είναι δυνατή για έναν άνθρωπο. Τέλος, η "Υπερνοημοσύνη" (Superintelligence) αναφέρεται σε μια υποθετική κατάσταση, όπου τα συστήματα TN ξεπερνούν την ανθρώπινη νοημοσύνη σε όλα τα επίπεδα. (Russell & Norvig, 2020)

1.1.1 Θεμελιώδεις Τεχνολογίες και Μέθοδοι

Η μηχανική μάθηση (Machine Learning - ML) αποτελεί το θεμέλιο της σύγχρονης TN. Το ML περιλαμβάνει τεχνικές όπως η Επιβλεπόμενη Μάθηση (Supervised Learning), όπου τα μοντέλα εκπαιδεύονται με δεδομένα εισόδου και εξόδου, η Μη Επιβλεπόμενη Μάθηση (Unsupervised Learning), που αναζητά μοτίβα χωρίς προκαθορισμένες ετικέτες, και η Ενισχυτική Μάθηση (Reinforcement Learning), η οποία βασίζεται στην αρχή της ανταμοιβής.

Παράλληλα, τα Νευρωνικά Δίκτυα (Neural Networks), εμπνευσμένα από τη βιολογία του ανθρώπινου εγκεφάλου, αποτελούν τη βάση για τις τεχνικές της βαθιάς μάθησης (Deep Learning). Η πολυστρωματική δομή των δικτύων αυτών επιτρέπει την επεξεργασία μεγάλου όγκου δεδομένων, προσφέροντας εξαιρετικά αποτελέσματα σε εφαρμογές όπως η αναγνώριση προσώπων και η ανάλυση εικόνων.

Ένας άλλος θεμελιώδης τομέας είναι η Επεξεργασία Φυσικής Γλώσσας (Natural Language Processing - NLP), η οποία επιτρέπει στους υπολογιστές να κατανοούν και να παράγουν ανθρώπινη γλώσσα. Εφαρμογές όπως οι ψηφιακοί βοηθοί και οι πλατφόρμες μετάφρασης βασίζονται σε αυτές τις τεχνικές. (Goodfellow, Bengio & Courville, 2016)

1.1.2 Εφαρμογές και Προοπτικές

Ήδη παρατηρούμε εμφανή επίδραση των τεχνολογιών TN σε πολυάριθμους κλάδους, από την ιατρική έως τη χρηματοοικονομική τεχνολογία (FinTech) και τα αυτόνομα μέσα μετακίνησης. Στον τομέα της υγείας, η ανάλυση ιατρικών δεδομένων με αλγορίθμους TN επιταχύνει τη διαδικασία διάγνωσης, ενώ στη FinTech τα εργαλεία TN διευκολύνουν τον εντοπισμό ύποπτων δραστηριοτήτων και βελτιστοποιούν τις στρατηγικές επένδυσης. Όσον αφορά τα αυτόνομα οχήματα (Autonomous Vehicles), η συνεχής επεξεργασία δεδομένων σε πραγματικό χρόνο εξασφαλίζει ασφαλέστερες διαδρομές και ακριβέστερη πλοήγηση, λ.χ., συλλέγουν αδιάκοπα δεδομένα από αισθητήρες, όπως κάμερες και LiDAR, και αλγόριθμοι TN λαμβάνουν αποφάσεις εντός κλάσματος δευτερολέπτου για ασφαλή πλοήγηση.

Οι προοπτικές της TN είναι τεράστιες, καθώς οι εξελίξεις στην υπολογιστική ισχύ και τη διαθεσιμότητα δεδομένων διευρύνουν τις δυνατότητες εφαρμογής της. Ωστόσο, η ενσωμάτωση της TN δεν αφορά μόνο την τεχνολογία, αλλά και την αποτελεσματική ρύθμιση των μοντέλων καθώς και συνεχή προσπάθεια για τη διασφάλιση της ηθικής και αποδοτικής χρήσης της. (Ευρωπαϊκό Κοινοβούλιο, 2021; Russel & Norvig, 1998)

1.2 Τεχνικές Μηχανικής Μάθησης και Δικτύων Βαθιάς Μάθησης

Η Μηχανική Μάθηση (Machine Learning – ML) και τα Δίκτυα Βαθιάς Μάθησης (Deep Learning – DL) αποτελούν δύο από τις πιο σημαντικές τεχνικές της Τεχνητής Νοημοσύνης (TN). Με τη χρήση αλγορίθμων και μοντέλων, οι τεχνικές αυτές επιτρέπουν στα συστήματα να αναλύουν δεδομένα, να αναγνωρίζουν μοτίβα και να λαμβάνουν αποφάσεις χωρίς την ανάγκη άμεσης ανθρώπινης παρέμβασης. Η συνεχής εξέλιξή τους αποτελεί θεμέλιο λίθο της σύγχρονης επιστημονικής και τεχνολογικής προόδου.

1.2.1 Μηχανική Μάθηση

Η Μηχανική Μάθηση επικεντρώνεται στην ανάπτυξη αλγορίθμων που επιτρέπουν στις μηχανές να μαθαίνουν από δεδομένα και να προσαρμόζονται μέσω της εμπειρίας. Βασικές μέθοδοι της Μηχανικής Μάθησης περιλαμβάνουν:

Εποπτευόμενη Μάθηση (Supervised Learning): Περιλαμβάνει την εκπαίδευση ενός αλγορίθμου με δεδομένα εισόδου και τις αντίστοιχες εξόδους. Χρησιμοποιείται ευρέως για πρόβλεψη τιμών μετοχών (regression) ή αναγνώριση απάτης (classification), αξιοποιώντας ιστορικά δεδομένα συναλλαγών.

Μη Εποπτευόμενη Μάθηση (Unsupervised Learning): Επικεντρώνεται στην ανάλυση δεδομένων χωρίς προκαθορισμένες ετικέτες. Μέθοδοι όπως το clustering βοηθούν στον εντοπισμό «ομάδων» επενδυτών ή παρόμοιων μοτίβων σε συναλλακτική δραστηριότητα..

Ενισχυτική Μάθηση (Reinforcement Learning): Βασίζεται στη μάθηση μέσω δοκιμών και λαθών, με το σύστημα να λαμβάνει ανταμοιβές για σωστές αποφάσεις.

Το εργαλείο scikit-learn (sklearn) είναι ένα από τα πιο δημοφιλή εργαλεία στη Μηχανική Μάθηση. Παρέχει βιβλιοθήκες και μεθόδους για εποπτευόμενη και μη εποπτευόμενη μάθηση, καθιστώντας το ιδανικό για την ανάπτυξη εφαρμογών ανάλυσης δεδομένων. (Haykin, 2007)

1.2.2 Δίκτυα Βαθιάς Μάθησης

Τα Δίκτυα Βαθιάς Μάθησης αποτελούν προέκταση των παραδοσιακών νευρωνικών δικτύων, με δυνατότητα ανάλυσης δεδομένων υψηλής πολυπλοκότητας. Η δομή τους περιλαμβάνει πολλαπλά επίπεδα (layers) που επιτρέπουν την εξαγωγή χαρακτηριστικών (features) και τη βελτιστοποίηση της απόδοσης. Οι κύριες αρχιτεκτονικές περιλαμβάνουν:

Συνελικτικά Νευρωνικά Δίκτυα (Convolutional Neural Networks – CNNs): Χρησιμοποιούνται για την ανάλυση εικόνων και την αναγνώριση αντικειμένων.

Επαναλαμβανόμενα Νευρωνικά Δίκτυα (Recurrent Neural Networks – RNNs): Εφαρμόζονται σε δεδομένα χρονικής ακολουθίας, όπως η πρόβλεψη χρονοσειρών.

Μετασχηματιστές (Transformers): Χρησιμοποιούνται κυρίως στην επεξεργασία φυσικής γλώσσας (Natural Language Processing – NLP), με εφαρμογές όπως το GPT και το BERT.

Ένα επίπεδο l ενός δικτύου λειτουργεί σύμφωνα με την παρακάτω εξίσωση:

$$a_j^{(l)} = g \left(\sum_i w_{ij}^{(l-1)} \cdot a_i^{(l-1)} + b_j^{(l)} \right)$$

Όπου $a_j^{(l)}$ η ενεργοποίηση του κόμβου j στο επίπεδο l , $w_{ij}^{(l-1)}$ το βάρος που συνδέει τον κόμβο i του προηγούμενου επιπέδου $l-1$ με τον κόμβο j , $b_j^{(l)}$ το bias του κόμβου j στο επίπεδο l . Ως g συμβολίζεται η συνάρτηση ενεργοποίησης (activation function), π.χ., ReLU, Sigmoid, κ.α. (Goodfellow, Bengio & Courville, 2016)

1.2.3 Σύγκριση και Εφαρμογές ML και DL

Η κύρια διαφορά μεταξύ ML και DL έγκειται στην πολυπλοκότητα και στη δυνατότητα εξαγωγής χαρακτηριστικών. Το ML απαιτεί από τον χρήστη να καθορίσει χειροκίνητα τα χαρακτηριστικά, ενώ το DL χρησιμοποιεί πολυστρωματικές αρχιτεκτονικές για την αυτόματη εξαγωγή χαρακτηριστικών.

Οι εφαρμογές αυτών των τεχνικών είναι πολυάριθμες. Στον τομέα της υγείας, χρησιμοποιούνται για τη διάγνωση ασθενειών και την ανάπτυξη νέων φαρμάκων. Στις χρηματοπιστωτικές συναλλαγές, βοηθούν στην ανίχνευση απάτης και την πρόβλεψη οικονομικών τάσεων. Στην ψυχαγωγία, ενισχύουν συστάσεις περιεχομένου σε πλατφόρμες streaming. Στα αυτόνομα οχήματα, υποστηρίζουν την επεξεργασία δεδομένων αισθητήρων για ασφαλή πλοήγηση. (Goodfellow, Bengio & Courville, 2016)

1.3 Γενετικοί Αλγόριθμοι και Βελτιστοποίηση

Εμπνευσμένοι από τους βιολογικούς μηχανισμούς της εξέλιξης, οι γενετικοί αλγόριθμοι (Genetic Algorithms - GAs) αξιοποιούν τη φυσική επιλογή που εισήγαγε ο Δαρβίνος για να αναπτύξουν πληθυσμούς υποψήφιων λύσεων. Με αυτόν τον τρόπο, βελτιστοποιούν προβλήματα μέσω επαναληπτικών διαδικασιών δημιουργίας, αξιολόγησης και μετάλλαξης, καλύπτοντας ευρύ φάσμα εφαρμογών στη μηχανική μάθηση, στη ρύθμιση υπερπαραμέτρων, στη ρομποτική και στον σχεδιασμό σύνθετων συστημάτων. (Buontempo, 2019; Russel & Norvig, 1998)

1.3.1 Θεωρητική Θεμελίωση Γενετικών Αλγορίθμων

Οι γενετικοί αλγόριθμοι βασίζονται στη δημιουργία ενός πληθυσμού υποψήφιων λύσεων, οι οποίοι συχνά αναφέρονται ως “χρωμοσώματα”. Κάθε χρωμόσωμα κωδικοποιεί μια πιθανή λύση στο πρόβλημα, ενώ η ποιότητά του καθορίζεται από μια συνάρτηση καταλληλότητας (fitness function). Η συνάρτηση αυτή μαθηματικά μπορεί να αναπαρασταθεί ως ακολούθως:

$$F(x) = \text{maximize} \left(\sum_{i=1}^n \ell(y_i, f(x_i)) \right)$$

Όπου ως x ορίζεται το σύνολο των υπερπαραμέτρων υπό εξέταση και ℓ η συνάρτηση απόδοσης του μοντέλου βάσει των υπερπαραμέτρων. Ο βασικός κύκλος ενός γενετικού αλγορίθμου περιλαμβάνει τα εξής στάδια:

1. **Αρχικοποίηση:** Δημιουργία αρχικού πληθυσμού μέσω τυχαίας δειγματοληψίας ή με βάση προκαθορισμένες στρατηγικές.
2. **Αξιολόγηση:** Υπολογισμός της συνάρτησης καταλληλότητας για κάθε χρωμόσωμα.
3. **Επιλογή:** Επιλογή γονέων για την παραγωγή απογόνων με βάση την καταλληλότητά τους. Συνήθεις μέθοδοι περιλαμβάνουν το "roulette wheel selection" και το "tournament selection".
4. **Γενετικές Ενέργειες:** Εφαρμογή διασταύρωσης (crossover) και μετάλλαξης (mutation) για τη δημιουργία νέων χρωμοσωμάτων.
5. **Αντικατάσταση:** Ενημέρωση του πληθυσμού με τα νέα χρωμοσώματα.

6. **Επανάληψη:** Επανάληψη των βημάτων μέχρι την επίτευξη των κριτηρίων τερματισμού, όπως ο αριθμός γενεών ή η σύγκλιση των λύσεων.

Η προσαρμοστικότητα και η δυνατότητα εξερεύνησης του χώρου λύσεων καθιστούν τους γενετικούς αλγόριθμους κατάλληλους για σύνθετα προβλήματα βελτιστοποίησης, όπου οι παραδοσιακές μέθοδοι συχνά αποτυγχάνουν.

1.3.2 Εφαρμογή στη Ρύθμιση Υπερπαραμέτρων

Στη μηχανική μάθηση, οι υπερπαραμέτροι παίζουν κρίσιμο ρόλο στον καθορισμό της απόδοσης ενός μοντέλου. Οι γενετικοί αλγόριθμοι χρησιμοποιούνται συχνά για τη βελτιστοποίηση των υπερπαραμέτρων, επιτρέποντας την αποτελεσματική εξερεύνηση του χώρου των παραμέτρων και την εύρεση συνδυασμών που μεγιστοποιούν την απόδοση του μοντέλου.

Η διαδικασία περιλαμβάνει:

Κωδικοποίηση Υπερπαραμέτρων: Κάθε χρωμόσωμα αντιπροσωπεύει έναν συγκεκριμένο συνδυασμό υπερπαραμέτρων, όπως ο ρυθμός εκμάθησης (learning rate), το μέγεθος παρτίδας (batch size) και η αρχιτεκτονική του νευρωνικού δικτύου.

Ορισμός Συνάρτησης Καταλληλότητας: Η καταλληλότητα κάθε χρωμοσώματος καθορίζεται από τη μέτρηση της απόδοσης του μοντέλου, όπως η ακρίβεια (accuracy) ή η απώλεια (loss) στο σύνολο επαλήθευσης (validation set).

Αναπαραγωγή και Μετάλλαξη: Δημιουργία νέων χρωμοσωμάτων με τη χρήση διασταύρωσης και μετάλλαξης, επιτρέποντας την εξερεύνηση νέων συνδυασμών παραμέτρων.

Επανάληψη και Βελτίωση: Μέσα από διαδοχικές γενιές, οι γενετικοί αλγόριθμοι συγκλίνουν προς βέλτιστες ρυθμίσεις υπερπαραμέτρων, μειώνοντας τον χρόνο και την προσπάθεια που απαιτείται για τη χειροκίνητη αναζήτηση.

Η χρήση γενετικών αλγορίθμων στη ρύθμιση υπερπαραμέτρων προσφέρει ένα σημαντικό πλεονέκτημα, καθώς μειώνει την πιθανότητα πτώσης σε τοπικά ελάχιστα και επιτρέπει την

εύρεση λύσεων που βελτιστοποιούν τη γενίκευση του μοντέλου. Αυτή η προσέγγιση έχει υλοποιηθεί επιτυχώς σε διάφορες εφαρμογές, όπως η εκπαίδευση νευρωνικών δικτύων, τα συστήματα σύστασης και οι προβλέψεις χρηματοοικονομικών δεδομένων.

1.4 Perceptrons και Multilayered Perceptrons

Οι perceptrons και τα multilayered perceptrons (MLPs) αποτελούν τα θεμέλια της σύγχρονης τεχνητής νοημοσύνης (TN), προσφέροντας λύσεις σε προβλήματα ταξινόμησης, παλινδρόμησης και ανάλυσης δεδομένων. Η ανάπτυξή τους έχει συνδεθεί άρρηκτα με την πρόοδο των νευρωνικών δικτύων και την ικανότητά τους να αναγνωρίζουν πολύπλοκα μοτίβα και σχέσεις σε μεγάλα σύνολα δεδομένων.

1.4.1 Αρχιτεκτονική Perceptrons

Εισαγμένο από τον Frank Rosenblatt το 1958, το perceptron λειτουργεί ως ένα απλοϊκό — αλλά ιστορικά καθοριστικό— νευρωνικό μοντέλο για την επίλυση γραμμικά διαχωρίσιμων προβλημάτων. Η αρχιτεκτονική του περιλαμβάνει έναν ή περισσότερους κόμβους εισόδου (inputs), οι οποίοι συνδυάζονται γραμμικά μέσω βαρών (weights), προτού εφαρμοστεί μια μη γραμμική συνάρτηση ενεργοποίησης (activation function) που καθορίζει το τελικό αποτέλεσμα. Η μαθηματική αναπαράστασή του έχει ως ακολούθως:

$$f(x) = \begin{cases} 1, & \text{if } w \cdot x + b > 0 \\ 0, & \text{otherwise} \end{cases}$$

Όπου w τα βάρη των εισόδων, x το διάνυσμα εισόδων και b το bias (βαθμός προκατάληψης)

Η λειτουργία του perceptron περιλαμβάνει τα εξής στάδια:

Εισαγωγή δεδομένων: Κάθε είσοδος πολλαπλασιάζεται με ένα βάρος.

Συνδυασμός: Οι πολλαπλασιασμένες τιμές αθροίζονται για να παραχθεί ένα καθαρό αποτέλεσμα (net input).

Ενεργοποίηση: Το καθαρό αποτέλεσμα περνά μέσα από τη συνάρτηση ενεργοποίησης, συνήθως το βήμα (step function), για να παραχθεί η έξοδος. Ενδεικτικές συναρτήσεις που συναντώνται συχνά είναι οι Sigmoid, tanh, ReLU, Leaky ReLU, Softmax και ELU.

Η Συνάρτηση ενεργοποίησης ουσιαστικά είναι και αυτή που διαφοροποιεί τον perceptron από μια κλασική γραμμική παλινδρόμηση (linear regression). Η γενική διαφορά είναι πως στη γραμμική παλινδρόμηση, το αποτέλεσμα είναι ένας συνεχής αριθμός και δεν υπάρχει συνάρτηση ενεργοποίησης, άρα, το αποτέλεσμα του μοντέλου είναι μια πρόβλεψη ενός συνεχούς αριθμητικού μεγέθους. Στον perceptron, το αποτέλεσμα περνά από μια συνάρτηση ενεργοποίησης (activation function, αλλιώς και βηματική συνάρτηση – step function), η οποία επιστρέφει δυαδικές τιμές (λ.χ. 0 ή 1), ανάλογα με το αν το γραμμικό άθροισμα ξεπερνά κάποιο όριο:

$$y = g\left(\sum_i w_i \cdot x_i + b\right)$$

Όπου y συμβολίζει την τιμή πρόβλεψης και g η συνάρτηση ενεργοποίησης.

Παρά τη σημασία του perceptron στην πρώιμη ανάπτυξη των νευρωνικών δικτύων, η ανικανότητά του να λύσει προβλήματα μη γραμμικά διαχωρίσιμα, όπως το XOR, οδήγησε στην ανάγκη για πιο πολύπλοκες αρχιτεκτονικές. (Haykin, 2007)

1.4.2 Δικτυακές Δομές Multilayered Perceptrons

Τα multilayered perceptrons (MLPs) επεκτείνουν την αρχιτεκτονική του perceptron, καθώς ένα από τα βασικά προβλήματα που αντιμετώπιζε ήταν η αδυναμία του να επιλύσει το γνωστό πρόβλημα «XOR»¹, εισάγοντας πολλαπλά επίπεδα νευρώνων (layers) που περιλαμβάνουν το επίπεδο εισόδου (input layer), ένα ή περισσότερα κρυφά επίπεδα (hidden layers), και το επίπεδο εξόδου (output layer). Η παρουσία των κρυφών επιπέδων επιτρέπει στα MLPs να αναγνωρίζουν και να επεξεργάζονται μη γραμμικές σχέσεις μεταξύ των δεδομένων. Αποτελούν μια συγκεκριμένη κατηγορία νευρωνικών δικτύων, που χαρακτηρίζεται από μια

¹

<https://humphryscomputing.com/Notes/Neural/single.neural.html#:~:text=A%20%22single%2Dlayer%22%20perceptron,invention%20of%20multi%2Dlayer%20networks.>

πλήρως συνδεδεμένη αρχιτεκτονική (fully connected architecture). Σε αυτή την αρχιτεκτονική, κάθε νευρώνας ενός επιπέδου συνδέεται με όλους τους νευρώνες του επόμενου επιπέδου. Παρόλο που τα MLPs ανήκουν στην οικογένεια των νευρωνικών δικτύων, δεν αντιπροσωπεύουν όλες τις δυνατότητες που προσφέρουν τα σύγχρονα δίκτυα βαθιάς μάθησης (deep learning).

Η αρχιτεκτονική ενός MLP βασίζεται στις εξής αρχές:

Προώθηση (Forward Propagation): Οι είσοδοι περνούν μέσα από τα διάφορα επίπεδα, όπου κάθε νευρώνας εφαρμόζει έναν γραμμικό συνδυασμό και μια συνάρτηση ενεργοποίησης (όπως η sigmoid, η ReLU ή η tanh).

Οπισθοδιάδοση (Backpropagation): Η διαδικασία υπολογισμού του σφάλματος στην έξοδο και η ρύθμιση των βαρών σε κάθε επίπεδο μέσω της χρήσης παραγώγων, βελτιώνοντας έτσι τη γενίκευση του μοντέλου. Η διαδικασία αυτή περιλαμβάνει μια συνάρτηση κόστους (cost function) που συχνά ορίζεται ως το μέσο τετραγωνικό σφάλμα (Mean Squared Error – MSE):

$$C = \frac{1}{2} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Όπου y_i η πραγματική τιμή ενώ $\hat{y}_i$ η πρόβλεψη του μοντέλου, C η συνάρτηση κόστους η οποία κατά το iteration της επιστροφής στο δίκτυο ενημερώνει τα βάρη βάσει του κανόνα Gradient Descent:

$$w_{ij}^{(t+1)} = w_{ij}^{(t)} - \eta \frac{\partial C}{\partial w_{ij}}$$

Όπου $w_{ij}^{(t)}$ το βάρος στη χρονική στιγμή t , « η » ο ρυθμός μάθησης (learning rate) και $\frac{\partial C}{\partial w_{ij}}$ η παράγωγος της συνάρτησης κόστους ως προς το βάρος w_{ij} .

Εκπαίδευση με Βελτιστοποίηση: Συνήθεις αλγόριθμοι, όπως ο Adam και ο Stochastic Gradient Descent (SGD), χρησιμοποιούνται για τη βελτιστοποίηση των παραμέτρων του μοντέλου.

Η πολυπλοκότητα των MLPs τα καθιστά ιδιαίτερα ευέλικτα για την επίλυση προβλημάτων μη γραμμικά διαχωρίσιμων, γεγονός που τα έχει καταστήσει αναπόσπαστο κομμάτι της σύγχρονης μηχανικής μάθησης. (Haykin, 2007; Goodfellow, Bengio & Courville, 2016)

1.4.3 Εφαρμογές στη Χρηματιστηριακή Ανάλυση

Τα perceptrons και τα multilayered perceptrons έχουν βρει ευρεία εφαρμογή στη χρηματιστηριακή ανάλυση, προσφέροντας εργαλεία για την κατανόηση της δυναμικής των αγορών και την ανάπτυξη στρατηγικών διαπραγμάτευσης. Οι κύριες εφαρμογές περιλαμβάνουν:

Πρόβλεψη Τιμών: Η χρήση των MLPs για την πρόβλεψη τιμών μετοχών και άλλων χρηματοοικονομικών μέσων μέσω ανάλυσης ιστορικών δεδομένων. (Goodfellow, Bengio & Courville, 2016)

Ανίχνευση Απάτης: Εφαρμογή μοντέλων perceptron για την αναγνώριση ανώμαλων μοτίβων στις συναλλαγές, προστατεύοντας από χειραγώγηση αγορών. (Smith & Valverde, 2021; Priatna κ.ά., 2024)

Βελτιστοποίηση Χαρτοφυλακίων: Χρήση των MLPs για την κατανομή πόρων σε διάφορα επενδυτικά μέσα, με στόχο τη μεγιστοποίηση της απόδοσης και τη μείωση του κινδύνου. (Goodfellow, Bengio & Courville, 2016)

Οι εφαρμογές αυτές δείχνουν τη δύναμη των νευρωνικών δικτύων στην επεξεργασία μεγάλου όγκου δεδομένων και στην εξαγωγή χρήσιμων προβλέψεων και συστάσεων για τους επενδυτές.

1.5 Εφαρμογές TN στις Χρηματιστηριακές Συναλλαγές

Η χρήση της Τεχνητής Νοημοσύνης (TN) στις χρηματιστηριακές συναλλαγές έχει φέρει επανάσταση στον τρόπο με τον οποίο οι επενδυτές, οι χρηματοπιστωτικοί οργανισμοί και οι διαχειριστές κεφαλαίων προσεγγίζουν τις αγορές. Με τη δυνατότητα ανάλυσης τεραστίων όγκων δεδομένων σε πραγματικό χρόνο, η TN επιτρέπει τη λήψη πληροφοριών που ήταν προηγουμένως αδύνατον να επεξεργαστούν από τον άνθρωπο. Η συνεισφορά της στη

βελτιστοποίηση στρατηγικών επενδύσεων και στη διαχείριση κινδύνων έχει καθιερωθεί ως αναντικατάστατη.

1.5.1 Προβλέψεις και Ανάλυση Τάσεων

Μια από τις πιο συνηθισμένες εφαρμογές της ΤΝ στις χρηματιστηριακές συναλλαγές είναι η ανάλυση δεδομένων για την πρόβλεψη οικονομικών τάσεων. Μοντέλα μηχανικής μάθησης (Machine Learning – ML) και δικτύων βαθιάς μάθησης (Deep Learning – DL) χρησιμοποιούνται για την επεξεργασία ιστορικών δεδομένων, εντοπίζοντας επαναλαμβανόμενα μοτίβα που σχετίζονται με τη συμπεριφορά των αγορών. Για παράδειγμα, τα επαναλαμβανόμενα νευρωνικά δίκτυα (Recurrent Neural Networks – RNNs) και οι μετασχηματιστές (Transformers) έχουν δείξει εξαιρετικά αποτελέσματα στην πρόβλεψη χρονοσειρών, εξεργάζοντας την πολυπλοκότητα των δεδομένων.

Η επεξεργασία φυσικής γλώσσας (Natural Language Processing - NLP) αποτελεί έναν ακόμη τομέα όπου η ΤΝ έχει ενισχύσει τη χρηματιστηριακή δραστηριότητα. Μέσω του NLP, οι υπολογιστές είναι σε θέση να αναλύουν ειδήσεις, αναφορές εταιριών και σχόλια στα μέσα κοινωνικής δικτύωσης, εξάγοντας συναισθηματικές τάσεις (sentiment analysis) που επηρεάζουν τις αποφάσεις των επενδυτών. Αυτή η διαδικασία επιτρέπει την ταχύτερη αντίδραση στις αλλαγές της αγοράς, καθώς και την αξιοποίηση μη παραδοσιακών πηγών πληροφορίας. (Zhao κ.ά., 2017)

1.5.2 Εντοπισμός Απάτης και Διαχείριση Κινδύνων

Ο εντοπισμός απάτης και η διαχείριση κινδύνων αποτελούν άλλη μια σημαντική εφαρμογή της ΤΝ. Τα συστήματα επιτηρούν συναλλαγές σε πραγματικό χρόνο, εντοπίζοντας ανωμαλίες που θα υποδήλωναν κακόβουλες δραστηριότητες. Με τη χρήση αλγορίθμων εποπτευόμενης μάθησης (Supervised Learning), οι χρηματοπιστωτικοί οργανισμοί είναι σε θέση να βελτιώσουν την ασφάλεια των συστημάτων τους και να μειώσουν τις οικονομικές απώλειες. (Odeniyi, Oyinloye & Thompson, 2021)

1.5.3 Algorithmic Trading

Μία από τις πιο καινοτόμες πτυχές της ΤΝ είναι η δημιουργία στρατηγικών αυτοματοποιημένων συναλλαγών (algorithmic trading). Οι αλγόριθμοι αναλύουν δεδομένα από πολλαπλές πηγές, όπως οικονομικές αναφορές, ειδήσεις, κοινωνικά δίκτυα, και λαμβάνουν αποφάσεις για συναλλαγές με ταχύτητα που ξεπερνά την ανθρώπινη ικανότητα. Παρά τη δυναμική τους, εγείρονται σημαντικά ηθικά ζητήματα, όπως η έλλειψη διαφάνειας στις αποφάσεις. Στο πλαίσιο του high-frequency trading (HFT), οι αλγόριθμοι εκτελούν συναλλαγές σε κλάσματα του δευτερολέπτου, εκμεταλλευόμενοι μικρές διαφορές τιμών, γεγονός που μπορεί να συμβάλει σε φαινόμενα όπως τα λεγόμενα flash crashes. (Perrin & Roncalli, 2019)

1.6 Στρατηγικές Ανθρώπινων Επενδυτών

Η επενδυτική συμπεριφορά και οι στρατηγικές των ανθρώπινων επενδυτών διαφέρουν σημαντικά, ανάλογα με το επίπεδο εμπειρίας, τις γνώσεις, την προσέγγιση στον κίνδυνο και την προσαρμοστικότητα στις αγοραστικές συνθήκες. Οι επενδυτές μπορούν να κατηγοριοποιηθούν σε διάφορες ομάδες, με βάση τη συμπεριφορά και την προσέγγισή τους στις χρηματιστηριακές συναλλαγές.

1.6.1 Άπειροι Επενδυτές

Οι άπειροι επενδυτές συχνά τις αγορές με περιορισμένη κατάρτιση, μετατρέποντας ενίοτε τις χρηματιστηριακές συναλλαγές σε άτυπη μορφή τζόγου. Στη λήψη αποφάσεων βασίζονται περισσότερο στη διαίσθηση ή ακόμη και στην τύχη, ενώ καθοδηγούνται σε μεγάλο βαθμό από συναισθηματικούς παράγοντες, όπως ο φόβος ή η απληστία. Αυτή η έλλειψη στρατηγικής προσέγγισης μπορεί εύκολα να οδηγήσει σε παρορμητικές αγορές ή πωλήσεις. Η έλλειψη στρατηγικής και η αδυναμία κατανόησης των μηχανισμών της αγοράς τους καθιστούν ευάλωτους στις διακυμάνσεις των τιμών και τις χειραγωγήσεις της αγοράς. (Thaler, 2016)

1.6.2 Ιδιώτες Επενδυτές (Home Traders)

Οι ιδιώτες επενδυτές, γνωστοί συχνά ως home traders, είναι άτομα που επενδύουν τα δικά τους κεφάλαια και συχνά δρουν από το σπίτι ή μέσω διαδικτυακών πλατφορμών συναλλαγών. Σε αντίθεση με τους άπειρους επενδυτές, οι home traders προσεγγίζουν τις αγορές με πιο μελετημένο τρόπο. Λαμβάνουν υπόψη τους τεχνικούς δείκτες, τις γραφικές παραστάσεις (charts) και ειδήσεις που σχετίζονται με την αγορά ή τις εταιρίες. Επενδύουν χρόνο στη μελέτη τεχνικής ανάλυσης (technical analysis) και στην κατανόηση μακροοικονομικών παραγόντων. Παρόλο που δεν έχουν την εξειδίκευση των επαγγελματιών, καταφέρνουν να εφαρμόζουν στρατηγικές που βασίζονται στην παρατήρηση και την πειθαρχία, ωστόσο, συχνά πέφτουν θύματα του λεγόμενου FOMO (Fear Of Missing Out). (Maggiulli, 2022)

1.6.2.1 FOMO (Fear Of Missing Out)

Το FOMO (Fear of Missing Out) αναφέρεται στον φόβο απώλειας ευκαιριών, ο οποίος συχνά παρατηρείται στις χρηματοπιστωτικές αγορές και στις επενδύσεις. Οι επενδυτές που βιώνουν FOMO συχνά παρασύρονται από την αυξανόμενη τιμή μιας μετοχής ή ενός περιουσιακού στοιχείου, φοβούμενοι ότι θα χάσουν μια κερδοφόρα ευκαιρία. Το φαινόμενο αυτό μπορεί να οδηγήσει σε παρορμητικές αποφάσεις, οι οποίες δεν βασίζονται σε στρατηγική ή ανάλυση, αλλά σε συναισθήματα. Στο πλαίσιο των χρηματιστηριακών συναλλαγών, το FOMO συχνά οδηγεί σε υπερβολική αγορά κατά τη διάρκεια ανοδικών τάσεων, συμβάλλοντας σε φαινόμενα όπως οι φούσκες της αγοράς (Kahneman, 2012; Thaler, 2016). Χαρακτηριστικό παράδειγμα αποτελεί η μανία γύρω από συγκεκριμένα “meme stocks” ή η αλματώδης άνοδος ορισμένων κρυπτονομισμάτων, όπου οι επενδυτές αγόραζαν μαζικά υπό τον φόβο ότι θα χάσουν την «ευκαιρία».

1.6.3 Επαγγελματίες Επενδυτές

Οι επαγγελματίες επενδυτές λειτουργούν στο πλαίσιο μεγάλων οργανισμών, όπως επενδυτικές τράπεζες, αμοιβαία κεφάλαια (mutual funds) και hedge funds. Η στρατηγική τους βασίζεται σε προηγμένα εργαλεία ανάλυσης, εξειδικευμένες γνώσεις και πρόσβαση σε αποκλειστικές πληροφορίες. Συχνά διαθέτουν ομάδες ειδικών που ασχολούνται με την ποσοτική ανάλυση, την πρόβλεψη τάσεων της αγοράς και τη διαχείριση κινδύνων. Οι επαγγελματίες επενδυτές επικεντρώνονται τόσο στη δημιουργία σταθερών αποδόσεων όσο και στην προστασία του

κεφαλαίου μέσω διαφοροποίησης (diversification) και εξελιγμένων στρατηγικών αντιστάθμισης κινδύνου (hedging). (Marks, 2020; Graham, 2003)

1.6.4 Προσέγγιση Κινδύνου: Ρίσκο και Συντηρητικότητα

Μια σημαντική διάσταση που διαφοροποιεί τους επενδυτές είναι η προσέγγισή τους στον κίνδυνο. Οι επενδυτές που είναι φιλικοί προς το ρίσκο (risk-tolerant) τείνουν να επιλέγουν στρατηγικές υψηλής απόδοσης, οι οποίες συχνά συνοδεύονται από υψηλό βαθμό μεταβλητότητας. Οι στρατηγικές τους περιλαμβάνουν επενδύσεις σε αναδυόμενες αγορές, τεχνολογικές startups και παράγωγα προϊόντα.

Αντίθετα, οι συντηρητικοί επενδυτές (conservative investors) αποφεύγουν την έκθεση σε υψηλούς κινδύνους και προτιμούν σταθερές, ασφαλείς επενδυτικές επιλογές. Οι επενδύσεις τους επικεντρώνονται σε κρατικά ομόλογα, blue-chip μετοχές και αμοιβαία κεφάλαια χαμηλής μεταβλητότητας. Αυτή η ομάδα επενδυτών συχνά υιοθετεί στρατηγικές μακροπρόθεσμης απόδοσης, επιδιώκοντας τη διατήρηση και την ανάπτυξη του κεφαλαίου τους με σταθερό τρόπο. (Marks, 2020; Kahneman, 2012; Graham, 2003)

1.6.5 Συνδυασμός Στρατηγικών

Ένας ακόμα σημαντικός παράγοντας είναι η τάση πολλών επενδυτών να συνδυάζουν στοιχεία από διαφορετικές στρατηγικές. Για παράδειγμα, ένας home trader μπορεί να εφαρμόσει τεχνικές ανάλυσης για την επιλογή μετοχών αλλά ταυτόχρονα να διαφοροποιήσει το χαρτοφυλάκιό του για να μειώσει τον κίνδυνο. Αντίστοιχα, ένας επαγγελματίας επενδυτής μπορεί να υιοθετήσει στρατηγικές ρίσκου σε συγκεκριμένα projects ενώ διατηρεί συντηρητική στάση σε άλλα μέρη του χαρτοφυλακίου. (Maggiulli, 2022; Thaler, 2016; Graham, 2003)

1.6.6 Εξελίξεις και Τεχνολογία

Η τεχνολογία παίζει σημαντικό ρόλο στη διαμόρφωση στρατηγικών ανθρώπινων επενδυτών. Οι πλατφόρμες συναλλαγών και τα εργαλεία ανάλυσης δεδομένων έχουν διευκολύνει την πρόσβαση σε πληροφορίες, επιτρέποντας τόσο στους home traders όσο και στους επαγγελματίες να λαμβάνουν καλύτερες αποφάσεις. Παράλληλα, η συνεργασία ανθρώπων και

TN αναδεικνύεται ως μια νέα τάση, καθώς οι αλγόριθμοι υποστηρίζουν τη διαδικασία λήψης αποφάσεων χωρίς να αντικαθιστούν πλήρως την ανθρώπινη κρίση.

Η διαφοροποίηση των στρατηγικών επενδυτών είναι ενδεικτική της πολυπλοκότητας και της δυναμικής των αγορών. Οι επιτυχημένες επενδύσεις δεν εξαρτώνται μόνο από την εμπειρία και την κατανόηση των μηχανισμών της αγοράς, αλλά και από την ικανότητα προσαρμογής στις συνεχώς μεταβαλλόμενες συνθήκες. (Marks, 2020; Kahneman, 2012)

1.7 Ηθικά Ζητήματα και Προκλήσεις στη Χρήση της TN

Η ανάπτυξη και η εφαρμογή της Τεχνητής Νοημοσύνης (TN) δημιουργεί σημαντικά ηθικά και κανονιστικά ζητήματα, ιδίως στον τομέα των χρηματιστηριακών συναλλαγών, όπου η εξάρτηση σε αλγοριθμικές στρατηγικές εντείνει κινδύνους όπως η αστάθεια των αγορών (π.χ. flash crashes) και η έλλειψη διαφάνειας στις αποφάσεις των συστημάτων. Αυτά τα ζητήματα εγείρουν ερωτήματα σχετικά με την ευθύνη σε περίπτωση αποτυχιών, την προστασία της ιδιωτικότητας λόγω συγκέντρωσης δεδομένων, καθώς και την άνιση πρόσβαση σε πληροφορίες. Παράλληλα, η TN προσφέρει αδιαμφισβήτητα πλεονεκτήματα, όπως αυτοματοποίηση, βελτιστοποίηση και προγνωστικές δυνατότητες, που συμβάλλουν στην αποδοτικότητα των αγορών. Προκειμένου να εξισορροπηθούν οι προκλήσεις με τις ευκαιρίες, μελλοντικές εξελίξεις αναμένεται να επικεντρωθούν στην υιοθέτηση τεχνικών επεξήγησης αλγορίθμων (Explainable AI), ώστε να ενισχυθεί η διαφάνεια, η λογοδοσία και η εμπιστοσύνη, ενώ παράλληλα να διαχειριστούν ζητήματα ανισότητας και ηθικής αξιολόγησης. Η συνεχής αξιολόγηση αυτών των θεμάτων παραμένει κρίσιμη για τη βιώσιμη ενοποίηση της TN σε τέτοιους τομείς. (Whittlestone κ.ά., 2019; Mittelstadt κ.ά., 2016; Floridi, 2023)

1.7.1 Διαφάνεια και Λογοδοσία

Ένα από τα κύρια ηθικά ζητήματα είναι η διαφάνεια των αλγορίθμων. Πολλά συστήματα TN λειτουργούν ως “μαύρα κουτιά” (black boxes), όπου η διαδικασία λήψης αποφάσεων δεν είναι πλήρως κατανοητή ή επεξηγήσιμη. Αυτό οδηγεί σε περιορισμένη εμπιστοσύνη εκ μέρους των χρηστών και εγείρει ζητήματα λογοδοσίας, ιδιαίτερα όταν οι αποφάσεις των συστημάτων έχουν σημαντικές επιπτώσεις, όπως σε χρηματοοικονομικές ή ιατρικές εφαρμογές. Η Εξηγήσιμη Τεχνητή Νοημοσύνη (Explainable AI) αποτελεί μια προσέγγιση που στοχεύει στη

διαφάνεια, αλλά η υλοποίησή της παραμένει περιορισμένη. (Whittlestone κ.ά., 2019; Mittelstadt κ.ά., 2016; Floridi, 2023)

1.7.2 Προκαταλήψεις και Αμεροληψία

Ένα δεύτερο ζήτημα αφορά την προκατάληψη (bias) στα δεδομένα και τους αλγορίθμους. Τα δεδομένα που χρησιμοποιούνται για την εκπαίδευση συστημάτων ΤΝ συχνά περιλαμβάνουν κοινωνικές ή πολιτισμικές προκαταλήψεις, οι οποίες μπορεί να ενισχυθούν από τους αλγορίθμους. Για παράδειγμα, στην περίπτωση των χρηματοοικονομικών εφαρμογών, η ανισότητα στα δεδομένα μπορεί να οδηγήσει σε άδικες ή διακριτικές αποφάσεις, όπως η άρνηση δανείου σε συγκεκριμένες κοινωνικές ομάδες. (Mittelstadt κ.ά., 2016; Binns, 2017; Cathy, 2017)

1.7.3 Ιδιωτικότητα και Ασφάλεια

Η προστασία της ιδιωτικότητας είναι επίσης ένα κρίσιμο ηθικό ζήτημα. Η ΤΝ βασίζεται στην ανάλυση μεγάλων όγκων δεδομένων, τα οποία συχνά περιλαμβάνουν ευαίσθητες προσωπικές πληροφορίες. Η ανεπαρκής προστασία αυτών των δεδομένων μπορεί να οδηγήσει σε παραβιάσεις της ιδιωτικότητας και της ασφάλειας, υπονομεύοντας την εμπιστοσύνη των χρηστών. Ειδικά στις χρηματιστηριακές συναλλαγές, όπου τα δεδομένα αποτελούν κρίσιμο περιουσιακό στοιχείο, η κακή διαχείριση της ιδιωτικότητας μπορεί να προκαλέσει σοβαρές συνέπειες. (Χατζηχριστοφής, 2022; Floridi, 2023)

1.7.4 Οικονομικές και Κοινωνικές Ανισότητες

Η χρήση της ΤΝ εντείνει τις κοινωνικές και οικονομικές ανισότητες. Εταιρίες με πρόσβαση σε μεγάλα δεδομένα και ισχυρούς αλγόριθμους έχουν τη δυνατότητα να αποκτήσουν δυσανάλογο πλεονέκτημα στις αγορές, αφήνοντας μικρότερους επενδυτές ή οργανισμούς σε μειονεκτική θέση. Αυτό δημιουργεί ένα νέο πεδίο ανταγωνισμού, όπου η πρόσβαση στην τεχνολογία καθορίζει την οικονομική επιτυχία. (Binns, 2017; Cathy, 2017)

1.7.5 Στρατιωτική και Κακόβουλη Χρήση

Ένα σημαντικό ηθικό ερώτημα αφορά τη στρατιωτική και κακόβουλη χρήση της ΤΝ. Οι δυνατότητες της ΤΝ για ανάλυση και πρόβλεψη μπορούν να χρησιμοποιηθούν για την ανάπτυξη στρατιωτικών εφαρμογών ή για εγκληματικές δραστηριότητες, όπως επιθέσεις στον κυβερνοχώρο. Η διαχείριση αυτών των κινδύνων απαιτεί παγκόσμια συνεργασία και αυστηρή ρύθμιση. (Cathy, 2017; Floridi, 2023)

1.7.6 Συμπεράσματα και Ηθικά Πλαίσια

Η κατανόηση και η αντιμετώπιση αυτών των ζητημάτων είναι απαραίτητη για τη βιώσιμη ανάπτυξη και χρήση της ΤΝ. Οι υπεύθυνοι χάραξης πολιτικής, οι ερευνητές και οι εταιρίες καλούνται να αναπτύξουν ηθικά πλαίσια που να διασφαλίζουν τη δικαιοσύνη, τη διαφάνεια και την προστασία των δικαιωμάτων των χρηστών. Μόνο μέσω της συνειδητής και υπεύθυνης προσέγγισης μπορούν να μετριαστούν οι κίνδυνοι και να μεγιστοποιηθούν τα οφέλη της ΤΝ. Στην Ευρωπαϊκή Ένωση, τα νομικά κείμενα για την προστασία των δεδομένων (GDPR) και το σχέδιο Ευρωπαϊκού Κανονισμού για την Τεχνητή Νοημοσύνη (AI Act) καταδεικνύουν μια πρώτη προσπάθεια ρύθμισης των κινδύνων, θέτοντας όρια στην επεξεργασία ευαίσθητων δεδομένων και επιβάλλοντας διαφάνεια.

2 – Ερωτηματολόγιο

2.1 Το Ερωτηματολόγιο ως Ερευνητικό Εργαλείο

Στην παρούσα έρευνα, χρησιμοποιήθηκε ερωτηματολόγιο ως κεντρικό μέσο συλλογής δεδομένων, προκειμένου να αποτυπωθούν οι αντιλήψεις, οι στάσεις και οι ανησυχίες του δείγματος για την εφαρμογή της Τεχνητής Νοημοσύνης (TN) στις επενδύσεις. Η επιτυχία του συγκεκριμένου εργαλείου εδράζεται στον προσεκτικό σχεδιασμό και την καθαρότητα των ερωτήσεων, οι οποίες διαμορφώθηκαν έτσι ώστε να παραγάγουν έγκυρα και αξιόπιστα ευρήματα. Σημαντικό ρόλο στην ποιότητα των απαντήσεων διαδραμάτισε η διασφάλιση της ανωνυμίας και της εμπιστευτικότητας των προσωπικών στοιχείων, σε πλήρη συμμόρφωση με τους κανόνες δεοντολογίας και τη σύγχρονη πρακτική στην κοινωνική έρευνα. (Bryman, 2012; Fowler, 2008)

Η παρούσα μελέτη χρησιμοποίησε το ερωτηματολόγιο για τη συλλογή δεδομένων σχετικά με τέσσερις βασικούς τομείς: τη δημογραφική σύνθεση των συμμετεχόντων, την εμπιστοσύνη στην TN σε διάφορες εφαρμογές, τις συγκρίσεις μεταξύ TN και ανθρώπινων επενδυτών, καθώς και τις αντιλήψεις και ανησυχίες για τη χρήση της TN στις επενδύσεις. Οι ερωτήσεις αναπτύχθηκαν με βάση τις βέλτιστες πρακτικές της βιβλιογραφίας, με έμφαση στη σαφήνεια και τη στόχευση. Όπως επισημαίνεται στη διεθνή βιβλιογραφία, ένα καλά σχεδιασμένο ερωτηματολόγιο πρέπει να είναι κατανοητό από τους συμμετέχοντες, να περιλαμβάνει ακριβείς οδηγίες και να αποφεύγει περιττές λεπτομέρειες που μπορεί να προκαλέσουν κόπωση ή σύγχυση.

Η χρήση του ερωτηματολογίου ως εργαλείου παρείχε πολλαπλά οφέλη στην παρούσα έρευνα. Αρχικά, η συλλογή δεδομένων πραγματοποιήθηκε με οικονομικό και πρακτικό τρόπο, καθώς το ηλεκτρονικό ερωτηματολόγιο επέτρεψε τη συμμετοχή ατόμων από διάφορες γεωγραφικές περιοχές χωρίς την ανάγκη φυσικής παρουσίας. Επιπλέον, τα δεδομένα ήταν εύκολα κωδικοποιήσιμα και αναλύσιμα με στατιστικές μεθόδους, γεγονός που συνέβαλε στη διατύπωση τεκμηριωμένων συμπερασμάτων. Ταυτόχρονα, η αντικειμενικότητα του εργαλείου μειώνει τον κίνδυνο μεροληψίας κατά τη συλλογή δεδομένων, παρέχοντας ακρίβεια και αξιοπιστία.

Η δομή του ερωτηματολογίου περιλάμβανε τόσο ποσοτικές όσο και ποιοτικές ερωτήσεις. Οι κλειστού τύπου ερωτήσεις χρησιμοποιήθηκαν για την καταγραφή ποσοτικών δεδομένων, όπως η κατανομή της εμπιστοσύνης σε συγκεκριμένες εφαρμογές της ΤΝ, ενώ οι ανοιχτού τύπου ερωτήσεις πρόσφεραν βαθύτερη κατανόηση των αντιλήψεων και ανησυχιών των συμμετεχόντων. Η συγκεκριμένη προσέγγιση διασφαλίζει ότι τα δεδομένα που συλλέχθηκαν είναι πολύπλευρα και επαρκή για την ανάλυση και τη διεξαγωγή συμπερασμάτων.

Βασιζόμενο σε καθιερωμένες μεθόδους της κοινωνικής έρευνας, το ερωτηματολόγιο παρέχει τη δυνατότητα σε ερευνητές να εξετάσουν σύνθετα ζητήματα με τρόπο που είναι προσιτός και εύκολα διαχειρίσιμος. Όπως υποστηρίζουν οι Dillman, Smyth και Christian (2014), ένα σαφές και καλά διαρθρωμένο ερωτηματολόγιο αυξάνει τη συμμετοχή και την ακρίβεια των απαντήσεων, καθιστώντας το ένα από τα πιο αποδοτικά εργαλεία συλλογής δεδομένων στη σύγχρονη ερευνητική πρακτική.

2.2 Παρουσίαση του Ερωτηματολογίου

Το ερωτηματολόγιο περιλάμβανε 21 ερωτήσεις, σχεδιασμένες για να διερευνήσουν σε βάθος τις αντιλήψεις, τα επίπεδα εμπιστοσύνης και τις ανησυχίες των συμμετεχόντων σχετικά με την Τεχνητή Νοημοσύνη (ΤΝ) στον τομέα των επενδύσεων. Η διαμόρφωση των ερωτήσεων βασίστηκε στη λογική της σταδιακής διερεύνησης, με τις πρώτες ερωτήσεις να αποσκοπούν στην καταγραφή βασικών δημογραφικών στοιχείων και τις επόμενες να επικεντρώνονται στην αξιολόγηση συγκεκριμένων θεμάτων εμπιστοσύνης, αντιλήψεων και συμπεριφορών.

Στην εναρκτήρια ενότητα, οι συμμετέχοντες κλήθηκαν να δηλώσουν βασικά δημογραφικά στοιχεία, όπως ηλικία, φύλο και επαγγελματική ιδιότητα. Η συλλογή αυτών των πληροφοριών κατέστησε εφικτή τη διαμόρφωση ενός αντιπροσωπευτικού δημογραφικού προφίλ, διευκολύνοντας την ανάλυση τυχόν διαφοροποιήσεων στις απαντήσεις ως προς τα κοινωνικά και επαγγελματικά χαρακτηριστικά.

Στις επόμενες ενότητες, οι συμμετέχοντες κλήθηκαν να αξιολογήσουν την εμπιστοσύνη τους στην ΤΝ μέσα από διάφορα πλαίσια εφαρμογής. Οι ερωτήσεις αυτές οργανώθηκαν σε ενότητες που περιλάμβαναν διαβαθμίσεις εμπιστοσύνης (από «καθόλου» έως «πολύ») μέσω κλιμάκων Likert, καθώς και συγκριτικές ερωτήσεις μεταξύ της ΤΝ και των ανθρώπινων επενδυτών. Με αυτόν τον τρόπο, εξετάστηκαν όχι μόνο τα επίπεδα εμπιστοσύνης, αλλά και η στάση απέναντι

σε διάφορες στρατηγικές διαχείρισης επενδύσεων, όπως η αυτόνομη ή συνεργατική διαχείριση.

Οι ερωτήσεις ανοικτού τύπου παρείχαν τη δυνατότητα στους συμμετέχοντες να εκφράσουν πιο σύνθετες απόψεις και ανησυχίες σχετικά με την ΤΝ. Ειδικότερα, ζητήθηκε από τους συμμετέχοντες να αναφέρουν τα μεγαλύτερα πλεονεκτήματα και μειονεκτήματα της ΤΝ, επιτρέποντας την εξαγωγή ποιοτικών δεδομένων που ενισχύουν την κατανόηση των ποσοτικών αποτελεσμάτων.

Το ερωτηματολόγιο σχεδιάστηκε ώστε να είναι εύχρηστο και κατανοητό, με ερωτήσεις που διατυπώθηκαν στη μητρική γλώσσα των συμμετεχόντων για να διασφαλιστεί η ακρίβεια των απαντήσεων. Η συλλογή των δεδομένων έγινε μέσω ηλεκτρονικής πλατφόρμας, επιτρέποντας τη συμμετοχή σε άτομα από διαφορετικά κοινωνικά και γεωγραφικά πλαίσια, ενώ εξασφαλίστηκε η ανωνυμία και η προστασία των προσωπικών δεδομένων.

Μετά τη συλλογή των απαντήσεων, τα δεδομένα οργανώθηκαν και κωδικοποιήθηκαν για περαιτέρω ανάλυση. Η χρήση κλιμάκων Likert διευκόλυνε την ποσοτικοποίηση των στάσεων και της εμπιστοσύνης, ενώ οι ερωτήσεις ανοικτού τύπου προσέφεραν εμπλουτισμένες περιγραφές των αντιλήψεων. Η ποιοτική και ποσοτική ανάλυση που ακολούθησε επέτρεψε την εξαγωγή συνολικών τάσεων και συσχετίσεων μεταξύ των δημογραφικών χαρακτηριστικών και των απαντήσεων.

2.3 Αποτελέσματα και Συζήτηση Ερωτηματολογίου

Τα ευρήματα που προέκυψαν από την ανάλυση² του ερωτηματολογίου³ αποκαλύπτουν ποικίλες απόψεις και στάσεις των συμμετεχόντων απέναντι στη χρήση της Τεχνητής Νοημοσύνης (ΤΝ) στον επενδυτικό τομέα. Συγκεκριμένα, καταγράφεται ποικιλία απόψεων όσον αφορά τα επίπεδα εμπιστοσύνης στην ΤΝ, τη σύγκρισή της με ανθρώπινους εμπόρους,

² Για πιο λεπτομερή παρουσίαση των δεδομένων και των ευρημάτων μπορείτε να ανατρέξετε εδώ: <https://url.kosmidis.me/nup-msc-questionnaire-analysis>

³ Τα αποτελέσματα του ερωτηματολογίου μπορείτε να τα δείτε εδώ: <https://url.kosmidis.me/nup-msc-questionnaire-results>

καθώς και τις ανησυχίες και τις αντιλήψεις για την αξιοποίησή της στον χρηματοοικονομικό τομέα.

Το ερωτηματολόγιο έλαβε συνολικά 250 υποβολές, ένας αριθμός που προσφέρει μια στατιστικά αξιόπιστη βάση για την εξαγωγή συμπερασμάτων. Αν και το μέγεθος του δείγματος δεν επιτρέπει την πλήρη γενίκευση των αποτελεσμάτων σε ολόκληρο τον πληθυσμό, εντούτοις διασφαλίζει ότι τα ευρήματα αντανακλούν σε σημαντικό βαθμό τις τάσεις και τις αντιλήψεις του δείγματος. Το μέγεθος αυτό είναι επαρκές για να προσφέρει πληροφορίες με στατιστική σημασία, ιδιαίτερα όταν πρόκειται για την ανάλυση και κατανόηση συγκεκριμένων τάσεων και παραμέτρων μέσα στο πλαίσιο της έρευνας.

Οι συμμετέχοντες παρουσίασαν διαφοροποιήσεις στις απόψεις τους με βάση δημογραφικά χαρακτηριστικά, ενώ σημαντικές τάσεις και προβληματισμοί αναδείχθηκαν σε σχέση με την ασφάλεια, την αξιοπιστία και την ηθική χρήση της ΤΝ στις επενδύσεις. Τα αποτελέσματα αυτά παρέχουν πολύτιμα δεδομένα που συμβάλλουν στην κατανόηση του τρόπου με τον οποίο η ΤΝ γίνεται αντιληπτή και αξιολογείται σε ένα συνεχώς εξελισσόμενο τεχνολογικό και οικονομικό περιβάλλον.


2.3.1 Δημογραφική Ανάλυση Συμμετεχόντων

Η δημογραφική ανάλυση των συμμετεχόντων αναδεικνύει το προφίλ και τα χαρακτηριστικά τους, παρέχοντας ένα πλαίσιο ερμηνείας για τις αντιλήψεις και στάσεις τους απέναντι στη χρήση της τεχνητής νοημοσύνης (ΤΝ) στις χρηματοοικονομικές επενδύσεις. Παρακάτω παρουσιάζονται τα βασικά στοιχεία που εξάγονται από τα δεδομένα του ερωτηματολογίου:

Ηλικιακή Κατανομή

Οι συμμετέχοντες ήταν από διάφορες ηλικιακές ομάδες. Η πλειοψηφία ανήκει στην ηλικιακή κατηγορία 31-40 ετών (30.4%), ενώ ακολουθούν οι κατηγορίες 21-30 ετών (27.2%) και 41-50 ετών (25.6%). Οι συμμετέχοντες άνω των 50 ετών ανέρχονται στο 12%, ενώ η νεότερη ηλικιακή ομάδα, κάτω των 20 ετών, αποτελεί μόνο το 4.8%.

● Κάτω από 20	12
● 21-30	68
● 31-40	76
● 41-50	64
● Άνω των 50	30




Διάγραμμα 1 - Ερώτημα 1: Ποια είναι η ηλικιακή σας ομάδα;

Φύλο

Η αναλογία φύλων δείχνει ότι 56% των συμμετεχόντων ήταν γυναίκες, ενώ οι άνδρες αποτελούν το 44%. Η κατανομή αυτή αντικατοπτρίζει μια σχετικά ισορροπημένη συμμετοχή φύλων, με ελαφρά υπεροχή των γυναικών.

● Άνδρας	110
● Γυναίκα	140




Διάγραμμα 2 - Ερώτημα 2: Ποιο είναι το φύλο σας;

Επαγγελματική Ιδιότητα

Το 36.3% των συμμετεχόντων εργάζεται στον οικονομικό τομέα, ενώ το 29.8% είναι φοιτητές. Επαγγελματίες στον τεχνολογικό τομέα αποτελούν το 13.7%. Επαγγέλματα όπως εκπαιδευτικοί, δημόσιοι και ιδιωτικοί υπάλληλοι, καθώς και άνεργοι, παρουσιάζουν μικρότερα ποσοστά συμμετοχής, κυμαινόμενα από 4.2% έως 7.7%.

● Φοιτητής/Φοιτήτρια	50
● Επαγγελματίας στον τομέα της τεχνολογίας	23
● Επαγγελματίας στον τομέα των οικονομικών	61
● Άνεργος/Άνεργη	13
● Other	103



Διάγραμμα 3 - Ερώτημα 3: Ποια είναι η επαγγελματική σας ιδιότητα;

Εμπειρία με την Τεχνητή Νοημοσύνη

Η εμπειρία με την τεχνητή νοημοσύνη (TN) παρουσιάζει σημαντική διακύμανση. Το **40.4%** των συμμετεχόντων ανέφερε ότι έχει ελάχιστη εμπειρία, ενώ το **26%** δήλωσε ότι δεν έχει καμία εμπειρία. Ένα **26.4%** διαθέτει μέτρια εμπειρία, ενώ μόλις το **7.2%** ανέφερε ότι έχει προχωρημένες γνώσεις στην TN.



Διάγραμμα 4 - Ερώτημα 4: Έχετε προηγούμενη εμπειρία με την τεχνητή νοημοσύνη;

Ενασχόληση με Επενδύσεις

Το μεγαλύτερο ποσοστό, **74.8%**, δήλωσε ότι δεν έχει ασχοληθεί ποτέ με επενδύσεις ή συναλλαγές κρυπτονομισμάτων. Ένα **17.6%** ανέφερε περιστασιακή εμπειρία, ενώ **7.6%** δήλωσε ότι ασχολείται τακτικά.



Διάγραμμα 5 - Ερώτημα 5: Έχετε ασχοληθεί ποτέ με επενδύσεις ή συναλλαγές κρυπτονομισμάτων;

2.3.2 Επίπεδα Εμπιστοσύνης στην TN

Η ανάλυση των δεδομένων σχετικά με την εμπιστοσύνη στην τεχνητή νοημοσύνη (TN) για επενδυτικές αποφάσεις αποκαλύπτει ποικιλία απόψεων μεταξύ των συμμετεχόντων. Οι

απαντήσεις αναδεικνύουν τη στάση των συμμετεχόντων απέναντι στις δυνατότητες της ΤΝ, αλλά και τις ανησυχίες που προκύπτουν από τη χρήση της στον χρηματοοικονομικό τομέα.

Συνολική Εμπιστοσύνη

Η περιγραφική ανάλυση καταδεικνύει ότι η μέση τιμή εμπιστοσύνης που εκφράστηκε από τους συμμετέχοντες είναι **3.2** (σε κλίμακα 1-5), ενώ η διάμεσος υπολογίστηκε σε **3.0**. Το γεγονός ότι οι τιμές αυτές είναι συγκρίσιμες υποδηλώνει συμμετρική κατανομή των απαντήσεων. Παρά τη γενική αυτή θετική στάση, ένα σημαντικό ποσοστό συμμετεχόντων εκφράζει χαμηλή εμπιστοσύνη, γεγονός που αποδίδεται σε παράγοντες όπως η περιορισμένη εμπειρία ή ανησυχίες για την αξιοπιστία της ΤΝ.

Σχέσεις με Δημογραφικά Χαρακτηριστικά

Η εφαρμογή του χ^2 ελέγχου ανεξαρτησίας αποκάλυψε ότι η εμπιστοσύνη στην ΤΝ διαφοροποιείται σημαντικά ως προς το φύλο ($\chi^2 = 12.45$, $p = 0.01$). Ειδικότερα, οι γυναίκες παρουσιάζουν υψηλότερα επίπεδα εμπιστοσύνης συγκριτικά με τους άνδρες. Ωστόσο, η ηλικία δεν βρέθηκε να επηρεάζει σημαντικά τα επίπεδα εμπιστοσύνης ($\chi^2 = 5.62$, $p = 0.24$), γεγονός που υποδηλώνει ότι οι στάσεις απέναντι στην ΤΝ είναι ανεξάρτητες ηλικιακών παραγόντων. (Field, 2013)

Συσχέτιση Εμπιστοσύνης με Εμπειρία στην ΤΝ

Η συσχέτιση Pearson ($r = 0.48$, $p < 0.001$) έδειξε μέτρια θετική σχέση μεταξύ της εμπειρίας στην ΤΝ και της εμπιστοσύνης που εκφράζεται για τις εφαρμογές της. Οι συμμετέχοντες με προχωρημένη εμπειρία εξέφρασαν αισθητά υψηλότερη εμπιστοσύνη, ενώ εκείνοι με περιορισμένη ή μηδενική εμπειρία εμφανίζονται πιο επιφυλακτικοί. Το εύρημα αυτό συνάδει με την άποψη ότι η αυξημένη επαφή με την ΤΝ διευκολύνει τη μείωση της αβεβαιότητας (Bryman, 2012), ενισχύοντας έτσι τη διαμόρφωση θετικότερων στάσεων.

Ανάλυση Συσταδοποίησης (K-Means Clustering)


Η ανάλυση κατέδειξε τρία σαφή προφίλ συμμετεχόντων:

1. Συμμετέχοντες με **χαμηλή εμπιστοσύνη και ελάχιστη εμπειρία**.
2. Συμμετέχοντες με **μέτρια εμπιστοσύνη και μέτρια εμπειρία**.
3. Συμμετέχοντες με **υψηλή εμπιστοσύνη και προχωρημένη εμπειρία**. Η κατηγοριοποίηση αυτή προσφέρει βαθύτερη κατανόηση των διαφορών στη στάση των

συμμετεχόντων, ενισχύοντας τη δυνατότητα στόχευσης παρεμβάσεων που εστιάζουν σε συγκεκριμένες ομάδες.

Εμπιστοσύνη σε Πολλαπλές Εφαρμογές

Η διερεύνηση των επιπέδων εμπιστοσύνης στην ΤΝ πραγματοποιήθηκε μέσω κλιμακωτών αξιολογήσεων (Likert) από το 1 (χαμηλότερη εμπιστοσύνη) έως το 5 (υψηλότερη εμπιστοσύνη), σε διαφορετικά πεδία εφαρμογής, καλύπτοντας τόσο τις απόψεις γύρω από την αυτόνομη λειτουργία της ΤΝ όσο και τη συγκριτική της απόδοση έναντι των ανθρώπινων επενδυτών. Τα αποτελέσματα αποκαλύπτουν σημαντικές διαφοροποιήσεις στην αντίληψη των συμμετεχόντων ανά εφαρμογή.



Διάγραμμα 6 - Ερώτημα 6: Πόσο εμπιστεύεστε την τεχνητή νοημοσύνη στις ακόλουθες εφαρμογές;

Η μεγαλύτερη εμπιστοσύνη καταγράφηκε στον τομέα της **υγειονομικής περίθαλψης (διάγνωση ή θεραπεία)**, με μέσο όρο **3.2** και διάμεσο **3.0**, γεγονός που υποδηλώνει ότι περίπου το **40%** των συμμετεχόντων δήλωσε μέτρια προς υψηλή εμπιστοσύνη για αυτήν την εφαρμογή. Παρομοίως, στις **συναλλαγές και επενδύσεις**, ο μέσος όρος ήταν **3.0**, με παρόμοια διάμεσο, ενώ περίπου το **35%** των συμμετεχόντων εξέφρασε μέτρια ή υψηλή εμπιστοσύνη.

Στον τομέα της **αυτόνομης οδήγησης**, η μέση τιμή εμπιστοσύνης περιορίστηκε στο **2.4**, ενώ μόνο το **20%** έδωσε ψήφους κοντά στο 4 ή το 5. Η **αυτόνομη πτήση σε εμπορικά αεροσκάφη** παρουσίασε ελαφρώς υψηλότερη βαθμολογία, με μέσο όρο **2.6**. Τέλος, η **διαχείριση προσωπικών χρημάτων** καταγράφηκε ως η εφαρμογή με τη χαμηλότερη εμπιστοσύνη (μέσος όρος **2.4**, διάμεσος **2.0**), με το **30%** να δηλώνει χαμηλή ή μηδενική εμπιστοσύνη.

Εμπιστοσύνη στην Τεχνητή Νοημοσύνη στις Επενδυτικές Εφαρμογές

Οι συμμετέχοντες κλήθηκαν να απαντήσουν στο ερώτημα εάν θα εμπιστευόνταν ένα μοντέλο τεχνητής νοημοσύνης να διαχειριστεί εξ ολοκλήρου τις επενδύσεις τους. Τα αποτελέσματα αποκαλύπτουν ένα υψηλό επίπεδο διστακτικότητας, με την πλειονότητα να απαντά αρνητικά.



Διάγραμμα 7 - Ερώτημα 7: Θα εμπιστευόσασταν ένα μοντέλο τεχνητής νοημοσύνης να διαχειριστεί εξ ολοκλήρου τις επενδύσεις σας;

Συγκεκριμένα, το **59.2%** των συμμετεχόντων δήλωσε ότι **δεν θα εμπιστευόταν** ένα τέτοιο μοντέλο, ενώ το **37.2%** εξέφρασε αβεβαιότητα, επιλέγοντας την απάντηση "**Ίσως**". Μόλις το **3.6%** των συμμετεχόντων ανέφερε ότι θα εμπιστευόταν πλήρως ένα μοντέλο τεχνητής νοημοσύνης για τη διαχείριση των επενδύσεών του.

Διαστήματα Εμπιστοσύνης

Η ακρίβεια των παραπάνω εκτιμήσεων ενισχύεται με την παρουσίαση του 95% διαστήματος εμπιστοσύνης για τον μέσο όρο εμπιστοσύνης, το οποίο κυμαίνεται από 3.1 έως 3.3. Η στατιστική αυτή παράμετρος υπογραμμίζει την αξιοπιστία των αποτελεσμάτων.

Ένα αξιοσημείωτο εύρημα που προκύπτει από τα δεδομένα είναι η φαινομενικά αντιφατική στάση των συμμετεχόντων. Οι άνθρωποι εμφανίζονται πιο πρόθυμοι να εμπιστευτούν τη ζωή τους σε αυτόνομη πτήση σε εμπορικά αεροσκάφη (μέσος όρος 2.6) από το να εμπιστευτούν τη διαχείριση των επενδύσεών τους σε ένα μοντέλο τεχνητής νοημοσύνης (μόλις το 3.6% των συμμετεχόντων απάντησε θετικά). Αυτό το αποτέλεσμα υπογραμμίζει την πιθανή ασάφεια ή έλλειψη εμπιστοσύνης στον χρηματοοικονομικό τομέα, ακόμα και όταν η TN παρουσιάζει μεγαλύτερη ωριμότητα και χρήση σε αυτόν τον κλάδο.

2.3.3 Σύγκριση Εμπιστοσύνης μεταξύ TN και Ανθρώπινων Εμπόρων

Μέσα από τη συγκριτική προσέγγιση των επιπέδων εμπιστοσύνης στην Τεχνητή Νοημοσύνη (TN) και στους ανθρώπινους εμπόρους, προκύπτουν ουσιαστικές διαφορές στις αντιλήψεις και στις προτιμήσεις του δείγματος. Παρότι η TN αναγνωρίζεται για συγκεκριμένα πλεονεκτήματα, οι συμμετέχοντες εκφράζουν επιφυλακτικότητα ως προς την ικανότητά της να υπερέχει πλήρως έναντι της ανθρώπινης κρίσης σε καίριους τομείς λήψης επενδυτικών αποφάσεων.

Αντίληψη για την Αξιοπιστία

Η αξιοπιστία της TN συγκρινόμενη με τους ανθρώπινους εμπόρους παρουσιάζει σημαντικές διαφοροποιήσεις. Το **60.4%** των συμμετεχόντων απάντησε ότι η αξιοπιστία της TN εξαρτάται από την περίπτωση, υποδεικνύοντας μια υπό όρους αποδοχή της τεχνολογίας. Παράλληλα, το **24.8%** εξέφρασε την άποψη ότι η TN είναι λιγότερο αξιόπιστη από τους ανθρώπους, ενώ μόλις το **14.8%** θεώρησε ότι η TN είναι πιο αξιόπιστη. Αυτή η διαφοροποίηση αναδεικνύει την ανάγκη για καλύτερη κατανόηση και τεκμηρίωση της αποτελεσματικότητας της TN στις επενδύσεις.



Διάγραμμα 8 - Ερώτημα 10: Πιστεύετε ότι η τεχνητή νοημοσύνη είναι πιο αξιόπιστη από τους ανθρώπους στις επενδύσεις;




Διάγραμμα 9 - Ερώτημα 20: Πώς θα αξιολογούσατε την τεχνητή νοημοσύνη σε σχέση με τους ανθρώπους στις ακόλουθες πτυχές;

Προτίμηση Διαχείρισης Επενδύσεων

Όταν οι συμμετέχοντες κλήθηκαν να επιλέξουν ανάμεσα σε έναν έμπειρο επενδυτή, την TN ή έναν συνδυασμό αυτών, το **45.78%** δήλωσε ότι θα εμπιστευόταν έναν έμπειρο επενδυτή, αναγνωρίζοντας την αξία της ανθρώπινης εμπειρίας και κρίσης. Παράλληλα, το **36.55%** δήλωσε ότι θα εμπιστευόταν εξίσου και τους δύο, υπογραμμίζοντας τη δυνητική συμπληρωματικότητα μεταξύ ανθρώπων και TN. Αντίθετα, μόνο το **7.23%** προτίμησε την αποκλειστική διαχείριση από την TN, επιβεβαιώνοντας τις ανησυχίες που υπάρχουν για την πλήρη αυτονομία της τεχνολογίας.

● Την τεχνητή νοημοσύνη	18
● Έναν έμπειρο επενδυτή	114
● Και τα δύο εξίσου	91
● Κανέναν	26




Διάγραμμα 10 - Ερώτηση 11: Ποιον θα εμπιστευόσασταν περισσότερο για τη διαχείριση των επενδύσεών σας;

Πλεονεκτήματα και Μειονεκτήματα της TN


Η ανάλυση των πλεονεκτημάτων της TN δείχνει ότι οι συμμετέχοντες αναγνωρίζουν την ταχύτητα ανάλυσης δεδομένων (**49.77%**) και τη λήψη αποφάσεων χωρίς συναισθηματική επιρροή (**32.39%**) ως τα μεγαλύτερα πλεονεκτήματά της. Ωστόσο, τα αποτελέσματα υπογραμμίζουν ότι οι άνθρωποι παραμένουν ανώτεροι σε πτυχές όπως η προσαρμογή σε μη αναμενόμενες καταστάσεις (**29.02%**) και η λήψη ηθικών αποφάσεων (**25.22%**). Η ανάγκη για αυτές τις δεξιότητες καθιστά την ανθρώπινη παρουσία απαραίτητη σε περιβάλλοντα που απαιτούν ευελιξία και στρατηγική κρίση.

● Γρήγορη ανάλυση δεδομένων	212
● Λήψη αποφάσεων χωρίς συναισθηματική επιρροή	138
● Ανίχνευση επενδυτικών ευκαιριών	46
● Αποφυγή απάτης	23
● Δεν θεωρώ ότι υπερέχει σε κάποια από αυτές	7



Διάγραμμα 11 - Ερώτηση 12: Σε ποια από τις ακόλουθες καταστάσεις θεωρείτε ότι η τεχνητή νοημοσύνη υπερέχει σε σχέση με τους ανθρώπους;

● Ερμηνεία μη ποσοτικών δεδομένων (π.χ. συναισθήματα της αγοράς)	103
● Προσαρμογή σε μη αναμενόμενες καταστάσεις	130
● Δημιουργικότητα στις στρατηγικές επενδύσεων	87
● Λήψη ηθικών αποφάσεων	114
● Δεν θεωρώ ότι υπερέχουν σε κάποια από αυτές	14




Διάγραμμα 12 - Ερώτημα 13: Σε ποιες από τις ακόλουθες καταστάσεις θεωρείτε ότι οι άνθρωποι υπερέχουν σε σχέση με την τεχνητή νοημοσύνη;

Αποδοχή Συνδυαστικών Μοντέλων

Ένα συντριπτικό **70.4%** των συμμετεχόντων δήλωσε ότι θα ήταν πρόθυμο να χρησιμοποιήσει ένα συνδυαστικό μοντέλο που θα συνδυάζει την TN με την ανθρώπινη εμπειρία. Το εύρημα αυτό υπογραμμίζει τη δυνατότητα της τεχνολογίας να ενισχύσει την ανθρώπινη απόδοση, παρά να την αντικαταστήσει.

● Ναι	176
● Όχι	17
● Δεν είμαι σίγουρος/η	57



Διάγραμμα 13 - Ερώτημα 14: Θα ήσασταν πρόθυμοι να χρησιμοποιήσετε ένα συνδυαστικό μοντέλο όπου η τεχνητή νοημοσύνη συνεργάζεται με έναν άνθρωπο επενδυτή;


2.3.4 Αντιλήψεις και Ανησυχίες για τη Χρήση TN στις Επενδύσεις

Η αποδοχή της τεχνητής νοημοσύνης για επενδυτικούς σκοπούς δεν εξαρτάται αποκλειστικά από τα πλεονεκτήματα που προσφέρει, αλλά επηρεάζεται σημαντικά από τους περιορισμούς και τις ανησυχίες που εγείρει. Τα αποτελέσματα της έρευνας αποκαλύπτουν κρίσιμες απόψεις των συμμετεχόντων, οι οποίες σχετίζονται με την αμφιβολία για τη διαφάνεια, την προσαρμοστικότητα και την ασφάλεια των συστημάτων τεχνητής νοημοσύνης.

Μεγαλύτερα Μειονεκτήματα της Τεχνητής Νοημοσύνης

Ένα από τα σημαντικότερα μειονεκτήματα της τεχνητής νοημοσύνης, σύμφωνα με το **36.25%** των συμμετεχόντων, είναι η δυσκολία προσαρμογής σε μη αναμενόμενες συνθήκες. Αυτή η αδυναμία αναδεικνύει την περιορισμένη ευελιξία των αλγορίθμων της τεχνητής νοημοσύνης


σε καταστάσεις που απαιτούν δημιουργική ή καινοτόμα σκέψη. Παράλληλα, το **33.50%** επισημαίνει ότι η τεχνητή νοημοσύνη επιδέχεται τεχνικά σφάλματα ή παραβιάσεις, γεγονός που εγείρει ανησυχίες για την αξιοπιστία της. Η εξάρτηση από δεδομένα του παρελθόντος αποτελεί άλλο ένα κρίσιμο ζήτημα, με το **17.25%** να το αξιολογεί ως βασικό μειονέκτημα, ενώ το **11.75%** θεωρεί ότι η έλλειψη διαφάνειας στη λήψη αποφάσεων είναι εξίσου προβληματική.



Διάγραμμα 14 - Ερώτηση 9: Ποιο θεωρείτε το μεγαλύτερο μειονέκτημα της τεχνητής νοημοσύνης στις επενδύσεις;

Ανησυχίες για την Ασφάλεια και Ιδιωτικότητα


Οι ανησυχίες σχετικά με την ασφάλεια και την ιδιωτικότητα κατέχουν κεντρική θέση στις αντιλήψεις των συμμετεχόντων. Ειδικότερα, το **25.76%** ανησυχεί για τον κίνδυνο τεχνικών σφαλμάτων, ενώ το **24.43%** επικεντρώνεται στις επιπτώσεις που μπορεί να έχουν αυτά τα συστήματα στην ιδιωτικότητα. Επίσης, το **20.26%** εντοπίζει δυσκολίες στην κατανόηση σύνθετων συνθηκών της αγοράς, υπογραμμίζοντας την ανάγκη για πιο εξελιγμένους αλγόριθμους που θα μπορούν να διαχειρίζονται πολυπαραγοντικά σενάρια. Η χρήση αναξιόπιστων δεδομένων, που επισημάνθηκε από το **18.35%** των συμμετεχόντων, και η έλλειψη διαφάνειας στη λήψη αποφάσεων, η οποία απασχόλησε το **10%**, αποτελούν επίσης σημαντικές ανησυχίες.



Διάγραμμα 15 - Ερώτηση 16: Τι σας ανησυχεί περισσότερο σχετικά με τη χρήση της τεχνητής νοημοσύνης στις επενδύσεις;

Δικαιοσύνη και Αντικειμενικότητα στη Λήψη Αποφάσεων

Σε ό,τι αφορά τη δικαιοσύνη και την αντικειμενικότητα, τα αποτελέσματα αποκαλύπτουν έντονες ανησυχίες. Ελάχιστοι συμμετέχοντες (2%) εκτιμούν ότι η τεχνητή νοημοσύνη είναι πάντα δίκαιη στις αποφάσεις της, ενώ το 34% πιστεύει ότι είναι δίκαιη τις περισσότερες φορές. Ωστόσο, το 46.40% θεωρεί ότι ο προγραμματισμός της μπορεί να περιέχει προκαταλήψεις ή σφάλματα, και το 16.80% αναγνωρίζει την πιθανότητα οι αποφάσεις της να επηρεάζονται από προκαταλήψεις στα δεδομένα που χρησιμοποιούνται. Αυτά τα ευρήματα ενισχύουν την ανάγκη για διαφάνεια και συστηματική αξιολόγηση των αλγορίθμων που εφαρμόζονται, ώστε να διασφαλίζεται η αντικειμενικότητα στη λήψη αποφάσεων.



Διάγραμμα 16 - Ερώτημα 17: Θεωρείτε την τεχνητή νοημοσύνη δίκαιη και αντικειμενική στη λήψη αποφάσεων;

2.4 Συμπεράσματα

Μέσω της χρήσης ερωτηματολογίου, το οποίο σχεδιάστηκε ως προσιτό και ευρύ ως προς το προφίλ των συμμετεχόντων, κατέστη δυνατή η συλλογή δεδομένων από ένα αντιπροσωπευτικό δείγμα διαφορετικών επαγγελματικών και κοινωνικοοικονομικών προελεύσεων. Η ανοιχτή αυτή προσέγγιση ενίσχυσε την εγκυρότητα των αποτελεσμάτων, επιτρέποντας τη διαμόρφωση μιας πολυδιάστατης εικόνας των αντιλήψεων σχετικά με την Τεχνητή Νοημοσύνη στις επενδύσεις.

Μέσα από την ανάλυση των δεδομένων, αποκτήθηκε πολύτιμη γνώση όχι μόνο για τις απόψεις του κοινού σχετικά με την τεχνητή νοημοσύνη και τη χρήση της στις επενδύσεις, αλλά και για τις αδυναμίες που θεωρείται ότι χαρακτηρίζουν την εφαρμογή της. Οι συμμετέχοντες ανέδειξαν προβληματισμούς που σχετίζονται με την ασφάλεια, την αξιοπιστία και τη διαφάνεια, στοιχεία που προσφέρουν σημαντικές ενδείξεις για το πώς αντιλαμβάνονται την τεχνολογία αυτή και πού εντοπίζουν περιθώρια βελτίωσης.

Επιπλέον, το γεγονός ότι η έρευνα ανέδειξε ενδιαφέρον από την πλευρά του κοινού ενισχύει τη σημασία της περαιτέρω μελέτης πάνω στο συγκεκριμένο αντικείμενο. Τα αποτελέσματα αυτά προσφέρουν πολύτιμα εφόδια για τη συνέχιση της έρευνας, καθώς όχι μόνο επιβεβαιώνουν τη χρησιμότητά της, αλλά και υποδεικνύουν τα πεδία που απαιτούν περαιτέρω διερεύνηση, συμβάλλοντας έτσι στην εμβάθυνση της κατανόησης για τη σχέση της τεχνητής νοημοσύνης με τον χρηματοοικονομικό τομέα.

3 – Βιβλιογραφική Ανασκόπηση και Υφιστάμενες Προσεγγίσεις

3.1 Παρουσίαση Σχετικών Ερευνών

Η παρούσα ενότητα εστιάζει στην επισκόπηση σχετικών ερευνών που άπτονται του αντικειμένου της διπλωματικής εργασίας, εξετάζοντας τη χρήση της Τεχνητής Νοημοσύνης (TN) και ειδικότερα τεχνικών μηχανικής μάθησης (Machine Learning) και δικτύων βαθιάς μάθησης (Deep Learning) στις χρηματιστηριακές συναλλαγές. Μέσα από την επισκόπηση της διεθνούς βιβλιογραφίας, διαμορφώνεται ένα συνολικότερο πλαίσιο αναφοράς που φωτίζει προσεγγίσεις, προκλήσεις και πιθανά κενά στη χρήση της Τεχνητής Νοημοσύνης στις χρηματοοικονομικές συναλλαγές. Το θεωρητικό αυτό υπόβαθρο καθίσταται καθοριστικό για την παρούσα εργασία, καθώς επιτρέπει την εστίαση σε ζητήματα που δεν έχουν επαρκώς διερευνηθεί.

Μία από τις βασικές ερευνητικές εργασίες που σχετίζονται με τη χρήση αλγορίθμων TN για τη βελτίωση των χρηματιστηριακών στρατηγικών είναι αυτή του Afaq (2021). Στη διπλωματική του εργασία, με τίτλο *Implementation of Deep Learning Algorithms for Stock Market Prediction*, ο Afaq εξετάζει πώς μοντέλα βαθιάς μάθησης, όπως τα Long Short-Term Memory Networks (LSTMs), μπορούν να χρησιμοποιηθούν για την πρόβλεψη των τιμών των μετοχών. Η έρευνα δείχνει ότι τα LSTMs υπερτερούν των παραδοσιακών μεθόδων πρόβλεψης λόγω της ικανότητάς τους να συλλαμβάνουν μακροχρόνιες εξαρτήσεις σε δεδομένα χρονοσειρών. Ωστόσο, αναδεικνύονται προκλήσεις που σχετίζονται με την ανάγκη για μεγάλα σύνολα δεδομένων και υψηλούς υπολογιστικούς πόρους.

Μια άλλη σημαντική συνεισφορά προέρχεται από τη δημοσίευση των Mashrur κ.ά. (2020), η οποία εστιάζει στην αυτοματοποίηση των επενδυτικών στρατηγικών μέσω αλγορίθμων μηχανικής μάθησης. Στο άρθρο τους *Machine Learning in Financial Portfolio Management: A Survey*, οι συγγραφείς αναλύουν τη χρήση διαφόρων τεχνικών, όπως τα Random Forests και τα Gradient Boosting Machines (GBMs), για τη διαχείριση επενδυτικών χαρτοφυλακίων. Η μελέτη αναδεικνύει τη δυνατότητα των τεχνικών αυτών να μειώνουν τους κινδύνους και να αυξάνουν τις αποδόσεις σε ένα ευμετάβλητο οικονομικό περιβάλλον. Παράλληλα, σημειώνεται η ανάγκη για περαιτέρω έρευνα που να συνδυάζει τα πλεονεκτήματα των στατιστικών μεθόδων με τις δυνατότητες της TN.

Στη μελέτη των Matsuo κ.ά. (2022), με τίτλο *"Deep learning, reinforcement learning, and world models"*, εξετάζεται η χρήση της ενισχυτικής μάθησης (Reinforcement Learning - RL) σε πολύπλοκα συστήματα, συμπεριλαμβανομένων των χρηματοοικονομικών αγορών. Οι συγγραφείς παρουσιάζουν πώς η RL μπορεί να βελτιστοποιήσει τις στρατηγικές συναλλαγών μέσω της συνεχούς προσαρμογής σε αλλαγές της αγοράς. Η έρευνα καταλήγει ότι, αν και οι τεχνικές RL είναι ιδιαίτερα υποσχόμενες, απαιτούνται εξειδικευμένες προσεγγίσεις για την αντιμετώπιση ζητημάτων όπως η υπερεκπαίδευση (overfitting) και η διαχείριση αβεβαιότητας.

Από τις ελληνικές συνεισφορές, ιδιαίτερη μνεία αξίζει η διπλωματική εργασία της Γαλανάκη (2021), η οποία εξετάζει τη χρήση της μηχανικής μάθησης για την ανάλυση δεδομένων χρηματιστηριακών συναλλαγών. Η Γαλανάκη αναδεικνύει τη σημασία της σωστής επιλογής χαρακτηριστικών (feature selection) για τη βελτίωση της ακρίβειας πρόβλεψης, ενώ προτείνει την εφαρμογή τεχνικών όπως οι Support Vector Machines (SVMs) για την κατηγοριοποίηση των δεδομένων. Παράλληλα, το βιβλίο του Κανάς (2023) παρέχει χρήσιμες πρακτικές για την ενίσχυση των επενδυτικών αποφάσεων, αναλύοντας τους περιορισμούς των παραδοσιακών μεθόδων και προτείνοντας νέες προσεγγίσεις βασισμένες σε σύγχρονες τεχνικές μηχανικής μάθησης.

Σύμφωνα με πρόσφατες έρευνες της KPMG, η γενετική τεχνητή νοημοσύνη (genAI) αναδεικνύεται ως καθοριστικός παράγοντας για τη βελτιστοποίηση χρηματοοικονομικών στρατηγικών. Η genAI επιτρέπει τη δημιουργία προσαρμοστικών μοντέλων που λαμβάνουν υπόψη τόσο ιστορικά δεδομένα όσο και μακροοικονομικές τάσεις, με εφαρμογές σε High-Frequency Trading (HFT) και διαχείριση κινδύνων. Παράλληλα, παρατηρείται σημαντική διαφοροποίηση στην υιοθέτηση της TN ανά γεωγραφική περιοχή: ενώ στις ΗΠΑ και την Ασία επικρατούν AI-driven συστήματα, στην Ευρώπη επικεντρώνεται η έμφαση στη συμμόρφωση με κανονιστικά πλαίσια (π.χ., Ευρωπαϊκός Κανονισμός AI). (KPMG, 2025; Money Review, 2025; HMEPHΣΙΑ, 2025)

Η παρούσα βιβλιογραφική ανασκόπηση αναδεικνύει τη σημαντική πρόοδο που έχει σημειωθεί στη χρήση της TN για χρηματιστηριακές εφαρμογές. Παρόλα αυτά, εξακολουθούν να υπάρχουν ανοιχτά ζητήματα, όπως η διαχείριση του θορύβου στα δεδομένα και η ανάγκη για ερμηνεύσιμες λύσεις. Η διπλωματική εργασία που ακολουθεί επιχειρεί να καλύψει αυτά τα

κενά, συνεισφέροντας με μια καινοτόμο προσέγγιση που συνδυάζει τεχνικές βαθιάς μάθησης και αναλυτικής.

3.2 Ανάλυση Υφιστάμενων Τεχνολογιών και Εργαλείων

Η εκρηκτική πρόοδος στις τεχνολογίες Τεχνητής Νοημοσύνης (TN) και Μηχανικής Μάθησης έχει επηρεάσει ριζικά τον χώρο των χρηματοοικονομικών συναλλαγών και της διαχείρισης επενδυτικών χαρτοφυλακίων, προσφέροντας εξελιγμένα εργαλεία για την ανάλυση, επεξεργασία και πρόβλεψη δεδομένων σε πραγματικό χρόνο. Παρ' όλα αυτά, μαζί με τις νέες δυνατότητες, έχουν προκύψει σημαντικές προκλήσεις, συμπεριλαμβανομένων ζητημάτων ποιότητας δεδομένων, αυξημένης υπολογιστικής πολυπλοκότητας και διαφάνειας των αλγοριθμικών μοντέλων. (KPMG, 2024)

3.2.1 Πλατφόρμες Συλλογής και Ανάλυσης Δεδομένων

Η συλλογή υψηλής ποιότητας δεδομένων αποτελεί προϋπόθεση για την αξιόπιστη λειτουργία των μοντέλων TN. Πλατφόρμες όπως το Bloomberg Terminal και το Refinitiv προσφέρουν δεδομένα σε πραγματικό χρόνο (τιμές μετοχών, συναλλαγματικές ισοτιμίες, μακροοικονομικοί δείκτες), ενσωματώνοντας εργαλεία ανάλυσης για μοντελοποίηση τάσεων και προβλέψεων (Cecconi, 2023). Παράλληλα, ανοιχτά σύνολα δεδομένων (π.χ., Yahoo Finance, Alpha Vantage) διευκολύνουν την έρευνα, ιδιαίτερα για εκπαίδευση αλγορίθμων μηχανικής μάθησης. Ωστόσο, η ύπαρξη θορύβου (noise) και η έλλειψη ομοιομορφίας στα δεδομένα αποτελούν συχνά εμπόδια, όπως επισημαίνεται σε έρευνες για την επεξεργασία χρηματοοικονομικών εγγράφων με NLP (Emagia, 2025). Τα παραπάνω συστήματα παρέχουν πολύτιμα δεδομένα για τους αλγορίθμους TN, διευκολύνοντας ωστόσο και τη μελέτη εννοιών όπως ο θόρυβος (noise) και η ομοιομορφία των συνόλων δεδομένων.

3.2.2 Εργαλεία Ανάλυσης Μηχανικής Μάθησης και Βαθιάς Μάθησης

Οι βιβλιοθήκες Scikit-learn, TensorFlow και PyTorch αποτελούν τη βάση για την ανάπτυξη προηγμένων μοντέλων. Το Scikit-learn, με την ευρεία γκάμα αλγορίθμων (επιβλεπόμενη/μη επιβλεπόμενη μάθηση), είναι ιδανικό για αρχικές αναλύσεις, ενώ τα TensorFlow και PyTorch επικεντρώνονται σε νευρωνικά δίκτυα και τεχνικές βαθιάς μάθησης. Για παράδειγμα,

Επαναλαμβανόμενα Νευρωνικά Δίκτυα (RNNs) και Μετασχηματιστές (Transformers) χρησιμοποιούνται για πρόβλεψη χρονοσειρών, με εφαρμογές σε High-Frequency Trading (HFT) και διαχείριση κινδύνων (Engineering Byte, 2025; Thakar, 2024).

Πρόσφατες τάσεις περιλαμβάνουν τη χρήση Generative AI (π.χ., GPT-4) για τη δημιουργία συναλλαγών βασισμένων σε φυσική γλώσσα, καθώς και την ενσωμάτωση τεχνικών Ενισχυτικής Μάθησης (Reinforcement Learning) για βελτιστοποίηση στρατηγικών (Thakar, 2024).

3.2.3 Τεχνολογίες Ανάλυσης Συναισθήματος (Sentiment Analysis)

Η ανάλυση συναισθήματος έχει γίνει απαραίτητο εργαλείο για την αξιολόγηση μη δομημένων δεδομένων (ειδήσεις, κοινωνικά μέσα, αναφορές). Εργαλεία όπως το VADER και το TextBlob προσφέρουν βασική κατηγοριοποίηση συναισθήματος, αλλά οι σύγχρονες εφαρμογές απαιτούν εξειδικευμένα μοντέλα όπως το FinBERT (BERT εκπαιδευμένο σε οικονομικά κείμενα) και το Whisper (μετατροπή ομιλίας σε κείμενο για ανάλυση σε πραγματικό χρόνο) (Thakar, 2024).

Σύμφωνα με έρευνες, η χρήση NLP για ανάλυση FOMC συζητήσεων επιτρέπει την πρόβλεψη αλλαγών στη νομισματική πολιτική, ενώ πλατφόρμες όπως το GiaDocsAI αυτοματοποιούν την εξαγωγή πληροφοριών από οικονομικά έγγραφα, βελτιώνοντας την ταχύτητα και την ακρίβεια (Emagia, 2025; Thakar, 2024).

3.2.4 Προκλήσεις και Περιορισμοί των Υφιστάμενων Τεχνολογιών

Παρά τις σημαντικές προόδους, οι υφιστάμενες τεχνολογίες αντιμετωπίζουν πολυάριθμες προκλήσεις που περιορίζουν την αποτελεσματικότητά τους. Η ποιότητα των δεδομένων παραμένει κρίσιμο ζήτημα, καθώς τα δεδομένα με θόρυβο (noise) ή ελλείψεις μπορούν να οδηγήσουν σε λανθασμένες προβλέψεις και αποφάσεις. Σύμφωνα με έρευνες, το 72% των εταιριών αναφέρουν ότι η ποιότητα των δεδομένων επηρεάζει άμεσα την ακρίβεια των μοντέλων (KPMG, 2024), ενώ η διαχείριση μεγάλων όγκων δεδομένων σε πραγματικό χρόνο αποτελεί συνεχή πρόκληση. Επιπλέον, οι υπολογιστικές απαιτήσεις για την εκπαίδευση μοντέλων βαθιάς μάθησης, όπως τα νευρωνικά δίκτυα και οι μετασχηματιστές, αυξάνονται συνεχώς, απαιτώντας υψηλό κόστος και εξειδικευμένες υποδομές (π.χ., GPUs). Αυτό

δημιουργεί ανισότητες στην πρόσβαση στις τεχνολογίες, ιδίως για μικρότερους οργανισμούς ή αναδυόμενες αγορές (Davis, 2024).

Ένας ακόμη σημαντικός περιορισμός είναι η έλλειψη διαφάνειας και εξηγησιμότητας (explainability) στα μοντέλα. Πολλά προηγμένα συστήματα, όπως τα Transformers, λειτουργούν ως «μαύρα κουτιά», καθιστώντας δύσκολη την κατανόηση της λογικής πίσω από τις προβλέψεις τους. Αυτό επηρεάζει την εμπιστοσύνη των χρηστών, ιδίως σε τομείς όπως οι επενδυτικές αποφάσεις και η διαχείριση κινδύνων. Τεχνικές όπως το SHAP (SHapley Additive exPlanations) και το LIME (Local Interpretable Model-agnostic Explanations) έχουν αναδειχθεί ως λύσεις, αλλά η εφαρμογή τους σε πραγματικά δεδομένα συχνά αποδεικνύεται περίπλοκη και χρονοβόρα (Thakar, 2024).

Τέλος, το ρυθμιστικό πλαίσιο αποτελεί συνεχή πρόκληση για τις εταιρίες που χρησιμοποιούν ΤΝ. Κανονισμοί όπως ο Ευρωπαϊκός Κανονισμός ΑΙ και οι απαιτήσεις του GDPR για την προστασία δεδομένων επιβάλλουν πρόσθετους περιορισμούς, ιδίως σε εφαρμογές που αφορούν την αυτόματη επεξεργασία συναλλαγών και την ανάλυση προσωπικών δεδομένων (Cecconi, 2023). Αυτές οι προκλήσεις υπογραμμίζουν την ανάγκη για συνεχή καινοτομία και προσαρμοστικότητα, καθώς οι τεχνολογίες εξελίσσονται ταχύτερα από τους κανονισμούς και τις υποδομές που υποστηρίζουν τη χρήση τους.

3.3 Ανοιχτά Ζητήματα και Προκλήσεις στη Βιβλιογραφία

Η παρούσα ενότητα εξετάζει τις προκλήσεις και τα ανοιχτά ζητήματα που έχουν εντοπιστεί στην υπάρχουσα βιβλιογραφία σχετικά με τη χρήση της Τεχνητής Νοημοσύνης (ΤΝ) στις χρηματοοικονομικές συναλλαγές. Οι ερευνητικές εργασίες που παρουσιάστηκαν στη βιβλιογραφική ανασκόπηση έχουν συμβάλει καθοριστικά στην πρόοδο του τομέα, ενώ η παρούσα ανάλυση στοχεύει να αναδείξει περιοχές που παραμένουν ανεξερευνήτες ή χρήζουν περαιτέρω διερεύνησης, προσθέτοντας στο διάλογο της επιστημονικής κοινότητας.

3.3.1 Διαφάνεια και Εξηγήσιμες Προσεγγίσεις

Μεταξύ των σημαντικότερων προκλήσεων που απασχολούν τη βιβλιογραφία περί ΤΝ στις χρηματοοικονομικές συναλλαγές συγκαταλέγεται το ζήτημα της διαφάνειας στους αλγόριθμους βαθιάς μάθησης (Deep Learning). Παρότι έχουν αναπτυχθεί τεχνικές όπως το

SHAP (SHapley Additive exPlanations) και το LIME (Local Interpretable Model-agnostic Explanations), η πρακτική τους αξιοποίηση σε πραγματικές συνθήκες αγοράς παραμένει περιορισμένη, υπογραμμίζοντας την ανάγκη για περαιτέρω βελτίωση και ενσωμάτωση σε καθημερινές επενδυτικές διαδικασίες. Οι προκλήσεις αυτές δεν μειώνουν την αξία των υφιστάμενων μελετών αλλά υπογραμμίζουν την ανάγκη για περαιτέρω έρευνα, με στόχο την ενίσχυση της εξηγησιμότητας και της εμπιστοσύνης των χρηστών. (Bahoo κ.ά., 2024)

Η ανάγκη για διαφάνεια δεν περιορίζεται μόνο στην τεχνική εξήγηση των μοντέλων, αλλά εκτείνεται και στη συμμόρφωση με κανονιστικές απαιτήσεις. Όπως αναφέρει η KPMG (2025), εταιρίες όπως η Nvidia και η Microsoft αντιμετωπίζουν αυξημένους κινδύνους λόγω αντιμονοπωλιακών νόμων και κανονισμών για την υπεύθυνη χρήση της ΤΝ. Για παράδειγμα, η εφαρμογή τεχνικών Explainable AI (XAI), όπως το SHAP και το LIME, δεν αρκεί από μόνη της· απαιτείται επίσης η δημιουργία audit trails και η διασφάλιση ότι τα μοντέλα δεν ενισχύουν προκαταλήψεις ή ανισότητες. Αυτό είναι ιδιαίτερα σημαντικό σε χρηματοοικονομικά συστήματα όπου οι αποφάσεις επηρεάζουν ευρέως το κοινό. (Koukoutsas, 2025; Rudin, 2019; ΗΜΕΡΗΣΙΑ, 2025)

3.3.2 Ποιότητα και Διαθεσιμότητα Δεδομένων

Η ποιότητα των δεδομένων αποτελεί βασικό παράγοντα για την αξιοπιστία των μοντέλων ΤΝ. Ο θόρυβος (π.χ., λανθασμένες συναλλαγές) και οι ελλείψεις (π.χ., μη δομημένα δεδομένα από αναδυόμενες αγορές) δυσχεραίνουν την εκπαίδευση αλγορίθμων. Παρόλο που μέθοδοι όπως η συμπλήρωση δεδομένων με generative AI έχουν δοκιμαστεί, η διαχείριση δεδομένων σε πραγματικό χρόνο εξακολουθεί να είναι μια πρόκληση, ειδικά σε τομείς όπως οι κρυπτονομισματικές συναλλαγές. (Μιχαήλ, 2024; Ξενοφώντα, 2023)

3.3.3 Υπερεκπαίδευση και Γενίκευση

Η υπερεκπαίδευση (overfitting) σε στατικά δεδομένα μειώνει την ικανότητα των μοντέλων να προσαρμόζονται σε δυναμικές αγορές. Τεχνικές όπως η κανονικοποίηση και η χρήση adversarial training έχουν προταθεί, αλλά η αποτελεσματικότητά τους σε περιβάλλοντα υψηλής μεταβλητότητας (π.χ., συναλλαγές με κρυπτονομίσματα) απαιτεί περαιτέρω βελτιστοποίηση (Μιχαήλ, 2024). Επιπλέον, η έλλειψη ιστορικών δεδομένων σε αναδυόμενες αγορές περιορίζει τη γενίκευση των μοντέλων (Koukoutsas, 2025).

3.3.4 Υπολογιστικοί Πόροι και Δυναμική Αγορών

Οι απαιτήσεις σε υπολογιστική ισχύ για μοντέλα βαθιάς μάθησης (π.χ., transformers) δυσχεραίνουν την υιοθέτησή τους από μικρούς οργανισμούς. Η χρήση cloud computing και edge AI έχει μερικώς αντιμετωπίσει το ζήτημα, αλλά το κόστος και η πολυπλοκότητα παραμένουν εμπόδια, ιδιαίτερα σε χώρες με περιορισμένη τεχνολογική υποδομή. (K2varnavas, 2024; Παπακώστας, 2024)

3.3.5 Αναδυόμενες Αγορές και Εξειδικευμένες Προσεγγίσεις

Οι αναδυόμενες αγορές παραμένουν λιγότερο μελετημένες στη βιβλιογραφία, γεγονός που αναδεικνύει την ανάγκη για νέες μεθόδους που να λαμβάνουν υπόψη τη μεταβλητότητα και την περιορισμένη διαθεσιμότητα δεδομένων. Οι υπάρχουσες έρευνες θέτουν τις βάσεις για περαιτέρω μελέτες που μπορούν να επεκτείνουν τη χρήση της TN σε διαφορετικά οικονομικά περιβάλλοντα.

Οι αναδυόμενες αγορές, όπως αυτές της Κίνας και της Ινδίας, παρουσιάζουν μοναδικές προκλήσεις λόγω της υψηλής μεταβλητότητας και της έλλειψης δομημένων δεδομένων. Σύμφωνα με έρευνα της KPMG (2025), η Κίνα προπορεύεται στην εφαρμογή TN για συναλλαγές με κρυπτονομίσματα, χάρη σε επενδύσεις σε υποδομές blockchain και τεχνητής νοημοσύνης. Αντίθετα, σε αγορές όπως η Νιγηρία και η Νότια Αφρική, η έλλειψη ρυθμιστικών πλαισίων και τεχνολογικής υποδομής περιορίζει τη δυνατότητα υιοθέτησης. Αυτό δημιουργεί την ανάγκη για εξειδικευμένες προσεγγίσεις που λαμβάνουν υπόψη τοπικούς παράγοντες, όπως η πολιτική σταθερότητα και η διαθεσιμότητα δεδομένων.

3.3.6 Σύγχρονες Τάσεις και Μελλοντικές Κατευθύνσεις

Σύμφωνα με την Forbes, η ανάπτυξη της Agentic AI (αυτόνομων συστημάτων που εκτελούν πολύπλοκες εργασίες χωρίς ανθρώπινη παρέμβαση) αναμένεται να επαναπροσδιορίσει τις χρηματοοικονομικές αγορές. Για παράδειγμα, αυτόματα συστήματα μπορούν να διαχειριστούν ολόκληρα χαρτοφυλάκια βασισμένα σε πραγματικές συνθήκες αγοράς, ενσωματώνοντας δεδομένα από IoT συσκευές και δορυφόρους (Papandreou, 2025). Επιπλέον, η μελέτη Wharton υπογραμμίζει τη σημασία του συνδυασμού ανθρώπινης διαίσθησης και TN, ιδιαίτερα σε περιπτώσεις όπου τα μοντέλα παρουσιάζουν "hallucinations" (ανακριβείς προβλέψεις λόγω

θορύβου στα δεδομένα). Μια υβριδική προσέγγιση, όπου οι επενδυτές επεξεργάζονται τις προτάσεις της TN μέσω φίλτρων εμπειρικής γνώσης, φαίνεται να είναι η πιο υποσχόμενη κατεύθυνση. (Basiouny, 2025)

3.4 Συμβολή της Παρούσας Έρευνας

Με την παρούσα διπλωματική εργασία, επιδιώκεται μια ουσιαστική επέκταση της γνώσης και της πρακτικής εφαρμογής της Τεχνητής Νοημοσύνης (TN) στον διαρκώς μεταβαλλόμενο χώρο των συναλλαγών κρυπτονομισμάτων. Μέσα από μια συνδυαστική προσέγγιση, η έρευνα φιλοδοξεί να αναδείξει τόσο τα πλεονεκτήματα όσο και τους περιορισμούς των σύγχρονων αλγορίθμων TN, θέτοντας στο επίκεντρο τη σύγκρισή τους με την ανθρώπινη εμπειρία. Μέσω συστηματικής ανάλυσης, επιδιώχθηκε να γεφυρωθούν θεωρητικά και πρακτικά κενά, αναδεικνύοντας τόσο τα πλεονεκτήματα όσο και τους περιορισμούς της TN, ειδικά όταν συγκρίνεται με ανθρώπινες στρατηγικές.

3.4.1 Ανάλυση Αποτελεσματικότητας Αλγορίθμων Μηχανικής Μάθησης

Στο πλαίσιο της παρούσας μελέτης, αναπτύχθηκε και εφαρμόστηκε το μοντέλο LGBMClassifier για την αξιολόγηση της αποτελεσματικότητάς του σε περιβάλλοντα υψηλής μεταβλητότητας, όπως η αγορά Bitcoin. Η επιλογή του εν λόγω αλγορίθμου βασίστηκε κυρίως στην ικανότητά του να χειρίζεται εκτενή σύνολα δεδομένων υψηλής διακύμανσης, αξιοποιώντας παράλληλα τις μεθόδους ενισχυτικής μάθησης (boosting) για καλύτερη προσαρμογή. Με την υποστήριξη στρατηγικών υπερπαραμετροποίησης, όπως η χρήση γενετικών αλγορίθμων, το μοντέλο πέτυχε ακρίβεια 75% στη διασταυρούμενη επικύρωση. Το αποτέλεσμα αυτό υπογραμμίζει την αξία της TN στη λήψη επενδυτικών αποφάσεων, ειδικά σε περιπτώσεις όπου η ανθρώπινη κρίση μπορεί να επηρεάζεται από συναισθηματικούς παράγοντες.

3.4.2 Διαχείριση Δεδομένων και Ποιότητας

Η ποιότητα των δεδομένων αποτελεί ακρογωνιαίό λίθο για την αξιοπιστία των μοντέλων TN. Στην παρούσα εργασία, τα δεδομένα υποβλήθηκαν σε ενδελεχή κανονικοποίηση μέσω MinMaxScaler και RobustScaler, εξασφαλίζοντας τη στατιστική ομοιομορφία των

χαρακτηριστικών. Επιπλέον, εντοπίστηκαν και διαχειρίστηκαν ακραίες τιμές με την εφαρμογή τεχνικών όπως Z-Score και Interquartile Range. Αυτές οι μέθοδοι βελτίωσαν τη συνοχή του dataset, το οποίο περιελάμβανε λεπτομερείς καταγραφές συναλλαγών, όπως τιμές ανοίγματος, κλεισίματος και όγκους συναλλαγών. Το dataset τελικά αξιολογήθηκε ως κατάλληλο για την υποστήριξη μοντέλων πρόβλεψης υψηλής ακρίβειας.

3.4.3 Ανάλυση Επενδυτικής Στρατηγικής

Η σύγκριση της απόδοσης του μοντέλου με υποθετικές ανθρώπινες στρατηγικές αποτέλεσε ένα ακόμα σημαντικό κομμάτι της παρούσας έρευνας. Τα αποτελέσματα δείχνουν ότι, αν και η TN μπορεί να υπερέχει σε περιπτώσεις ταχείας λήψης αποφάσεων, οι άνθρωποι επενδυτές παραμένουν ανταγωνιστικοί σε περιπτώσεις όπου η εμπειρία και η διαίσθηση διαδραματίζουν καθοριστικό ρόλο. Συνεπώς, το μοντέλο προτείνεται ως ένα υποστηρικτικό εργαλείο, που μπορεί να ενισχύσει την ακρίβεια των επενδυτικών αποφάσεων, χωρίς όμως να αντικαθιστά πλήρως τον ανθρώπινο παράγοντα.

4 – Περιγραφή Δεδομένων

Το σύνολο δεδομένων που επιλέχθηκε παρέχει μια εκτενή χρονολογική καταγραφή χρηματοοικονομικών συναλλαγών και τεχνικών δεικτών, επιτρέποντας την ανάπτυξη μοντέλων τεχνητής νοημοσύνης για την πρόβλεψη και τη λήψη επενδυτικών αποφάσεων. Η ανάλυση⁴ που πραγματοποιήθηκε περιλαμβάνει προεπεξεργασία και εμπλουτισμό των δεδομένων με χαρακτηριστικά όπως χρονικές μεταβλητές, καθώς και στατιστική αξιολόγηση κατανομών, συμμετρίας και παρουσίας ακραίων τιμών. Επιπλέον, εφαρμόστηκαν προηγμένες μέθοδοι χειρισμού ελλειπουσών τιμών και κατηγοριοποίησης ανά χρονικές περιόδους, διασφαλίζοντας τη συνοχή και τη στατιστική εγκυρότητα του dataset για την υποστήριξη πολύπλοκων μοντέλων πρόβλεψης.

Περιλαμβάνει χρονοσειρές με καταγραφές ανά λεπτό, που καλύπτουν την περίοδο από την 1η Ιανουαρίου 2020 έως τις 22 Οκτωβρίου 2023. Η συνολική βάση αποτελείται από 1.997.210 εγγραφές και 27 μεταβλητές (στήλες), περιλαμβάνοντας βασικά χαρακτηριστικά, όπως οι τιμές ανοίγματος, κλεισίματος, οι υψηλές και χαμηλές τιμές κάθε περιόδου, καθώς και οι όγκοι συναλλαγών. Παράλληλα, έχουν ενσωματωθεί τεχνικοί δείκτες, όπως οι EMA (Exponential Moving Average), MACD (Moving Average Convergence Divergence) και ATR (Average True Range), οι οποίοι αποτελούν σημαντικά εργαλεία για την ανάλυση και κατανόηση της δυναμικής των αγορών.

4.1 Δομή του Συνόλου Δεδομένων

Τα δεδομένα του BTC/USD προέρχονται από το Kaggle⁵ και περιλαμβάνουν στοιχεία που εκτείνονται από την 1η Ιανουαρίου 2020 έως την 22α Οκτωβρίου 2023. Οι βασικές πτυχές των δεδομένων περιγράφονται ως εξής:

Περίοδος Δεδομένων: 2020-01-01 00:01:00 – 2023-10-22 23:59:00

Μέγεθος Δεδομένων: 1.997.210 εγγραφές, 27 στήλες

⁴ Αναλυτική παρουσίαση των μεθόδων και της επεξεργασίας των δεδομένων είναι διαθέσιμη στη διεύθυνση: <https://url.kosmidis.me/nup-msc-data-analysis>

⁵ <https://www.kaggle.com/datasets/franoisgeorgesjulien/bitcoin-minute-data>

Βασικά Χαρακτηριστικά:

- OHLCV (Open, High, Low, Close, Volume): Κρίσιμα για την ανάλυση των τιμών.
- Trade Count: Πλήθος συναλλαγών ανά λεπτό.
- Ημερομηνίες και Ώρες: Κατανομή σε «day» και «hour».

Τεχνικοί Δείκτες: MACD, ATR, HMA, KAMA, Z-Score, QStick, και άλλοι, οι οποίοι παρέχουν πρόσθετες πληροφορίες για τη δυναμική της αγοράς.

4.1.1.1 Πρωτογενή Χαρακτηριστικά

Τα πρωτογενή χαρακτηριστικά περιλαμβάνουν τις βασικές χρηματοοικονομικές πληροφορίες για κάθε χρονική στιγμή, όπως:

Date (ημερομηνία): Η χρονική σήμανση κάθε εγγραφής, η οποία είναι ακριβής στο λεπτό.

Open (τιμή ανοίγματος): Η τιμή της αγοράς στην έναρξη του λεπτού.

High (υψηλή τιμή): Η μέγιστη τιμή κατά τη διάρκεια του λεπτού.

Low (χαμηλή τιμή): Η ελάχιστη τιμή κατά τη διάρκεια του λεπτού.

Close (τιμή κλεισίματος): Η τελική τιμή της αγοράς στο τέλος του λεπτού.

Volume USDT (όγκος συναλλαγών): Ο συνολικός όγκος συναλλαγών εκφρασμένος σε δολάρια ΗΠΑ (1 USD Tether = 1 USD).

Tradecount (πλήθος συναλλαγών): Ο αριθμός των συναλλαγών κατά τη διάρκεια του λεπτού.

4.1.1.2 Παράγωγα Χαρακτηριστικά

Εκτός από τα πρωτογενή χαρακτηριστικά, το dataset περιλαμβάνει παράγωγα χαρακτηριστικά που έχουν υπολογιστεί από τα πρωτογενή και παρέχουν επιπλέον πληροφόρηση:

Z-Score: Ένας δείκτης που κανονικοποιεί τις τιμές των δεδομένων, διευκολύνοντας τη μελέτη αποκλίσεων.

QStick: Ένας δείκτης που υπολογίζει τη διαφορά ανάμεσα στις τιμές ανοίγματος και κλεισίματος, παρέχοντας πληροφορίες για τη δυναμική της αγοράς.

4.1.1.3 Τεχνικοί Δείκτες

Το dataset περιλαμβάνει επίσης ειδικούς τεχνικούς δείκτες που χρησιμοποιούνται για την ανάλυση της αγοράς και την πρόβλεψη τάσεων:

EMA (Exponential Moving Average): Περιλαμβάνει κινητούς μέσους διαφορετικών χρονικών παραθύρων (5, 15, 30, 60, 100, και 200 λεπτών).

WMA (Weighted Moving Average): Σταθμισμένος κινητός μέσος που δίνει μεγαλύτερη έμφαση στις πρόσφατες τιμές.

MACD (Moving Average Convergence Divergence): Ένας δείκτης ορμής που χρησιμοποιείται για την ανίχνευση των τάσεων.

ATR (Average True Range): Δείκτης μεταβλητότητας που υπολογίζει το εύρος διακύμανσης τιμών.

HMA (Hull Moving Average) και KAMA (Kaufman Adaptive Moving Average): Προσαρμοστικοί κινητοί μέσοι που ενσωματώνουν μεταβλητότητα.

CMO (Chande Momentum Oscillator): Εξετάζει τη δύναμη των ανοδικών και καθοδικών κινήσεων της αγοράς.

4.1.1.4 Διαχείριση Χαρακτηριστικών

Στο πλαίσιο της ανάλυσης του συνόλου δεδομένων, πραγματοποιήθηκε μια συστηματική προσέγγιση για την κατανόηση και τη διαχείριση των χαρακτηριστικών, με στόχο τη διασφάλιση της ποιότητας και της αξιοπιστίας τους. Η διαδικασία περιλάμβανε τον έλεγχο των στατιστικών χαρακτηριστικών, την αντιμετώπιση των κενών εγγραφών, καθώς και την ανάλυση τάσεων για την εξαγωγή πολύτιμων πληροφοριών.

Κατανομή Χαρακτηριστικών

Αρχικά, εξετάστηκε η κατανομή κάθε χαρακτηριστικού τόσο για το σύνολο των δεδομένων όσο και για κάθε έτος ξεχωριστά. Η ανάλυση περιλάμβανε τη μέση τιμή, τη διάμεσο, το εύρος τιμών, καθώς και την τυπική απόκλιση. Ειδικότερα, αξιολογήθηκε η λοξότητα (skewness) και η συμμετρία (symmetry) των κατανομών, προκειμένου να εντοπιστούν τυχόν αποκλίσεις ή μοτίβα που θα μπορούσαν να επηρεάσουν την ανάλυση. Τα αποτελέσματα ανέδειξαν ότι τα

περισσότερα χαρακτηριστικά παρουσίαζαν συμμετρική κατανομή, ενώ μεμονωμένα χαρακτηριστικά, όπως ο όγκος συναλλαγών (Volume USDT), εμφάνισαν υψηλή λοξότητα.

Διαχείριση Κενών Εγγραφών

Η αντιμετώπιση των κενών εγγραφών αποτέλεσε σημαντικό βήμα για τη βελτίωση της ποιότητας των δεδομένων. Ακολουθήθηκε η εξής στρατηγική:

- Για τα χαρακτηριστικά με κενές γραμμές που δεν ξεπερνούσαν το 5% του συνόλου των δεδομένων, οι τιμές συμπληρώθηκαν με τη διάμεσο του τελευταίου τριμήνου που σχετίζεται με την εγγραφή.
- Για χαρακτηριστικά με πάνω από 5% κενές εγγραφές, αποφασίστηκε να διαγραφούν, αν και τελικά κανένα χαρακτηριστικό δεν πληρούσε αυτή την προϋπόθεση, γεγονός που ενίσχυσε τη συνολική πληρότητα του dataset.

Ανάλυση Τάσεων (Trend Analysis)

Πραγματοποιήθηκε ανάλυση τάσεων για κάθε έτος ξεχωριστά, καθώς και για το σύνολο του dataset. Εξετάστηκαν:

- Η υψηλότερη και η χαμηλότερη τιμή κλεισίματος για κάθε έτος, αναδεικνύοντας περιόδους έντονης ανόδου ή πτώσης στις τιμές.
- Ο υψηλότερος όγκος συναλλαγών ανά έτος, που παρέχει πληροφορίες για τις περιόδους αυξημένης δραστηριότητας της αγοράς.
- Η πιο συχνή ημέρα συναλλαγών, δηλαδή η ημέρα με το υψηλότερο πλήθος συναλλαγών, η οποία ανέδειξε μοτίβα χρονικής συγκέντρωσης δραστηριότητας.

Η συνολική ανάλυση των τάσεων έδειξε μια σταθερή αύξηση της δραστηριότητας σε συγκεκριμένες χρονικές περιόδους, ενώ επιβεβαίωσε τη σημασία χαρακτηριστικών όπως οι όγκοι συναλλαγών και οι τιμές κλεισίματος για την πρόβλεψη αγοραστικών και πωλητικών κινήσεων.

4.2 Περιγραφική Στατιστική των Χαρακτηριστικών

Το σύνολο δεδομένων περιλαμβάνει 1.997.210 εγγραφές, κατανεμημένες από το 2020 έως το 2023, με δεδομένα λεπτού (minute-level). Περιέχει 32 στήλες (27 αρχικές συν 5 που προσθέσαμε) που καλύπτουν τιμές αγοράς, τεχνικούς δείκτες και συναλλακτικές πληροφορίες.

4.2.1 Τιμές και Όγκοι

Η μέση τιμή κλεισίματος για την περίοδο κυμάνθηκε στα **28.347,77 USD** με διάμεσο **26.751,28 USD**. Η ανώτερη τιμή ανήλθε στα **69.000 USD**, ενώ η κατώτερη ήταν **3.706,96 USD**. Οι τιμές εμφάνισαν δεξιά λοξότητα, υποδεικνύοντας υψηλές τιμές εκτός της συνηθισμένης κατανομής.

Ο όγκος συναλλαγών (Volume USDT) είχε μέσο όρο **1.943.680 USDT** με διάμεσο **1.084.630 USDT**, υποδεικνύοντας υψηλές ανισορροπίες μεταξύ των λεπτών.

Η κατανομή των συναλλαγών (tradedcount) έδειξε έντονη λοξότητα, με μέσο **1.510** συναλλαγές ανά λεπτό και μέγιστο **5.900** συναλλαγές.

4.2.2 Τεχνικοί Δείκτες

Οι κινητοί μέσοι όροι (EMAs) εμφάνισαν σταθερή αύξηση ανάλογα με το χρονικό εύρος. Για παράδειγμα, ο EMA_5 είχε μέση τιμή **28.347,79 USD**, ενώ ο EMA_200 ήταν **28.348,40 USD**.

Ο δείκτης ATR (Average True Range) είχε μέσο όρο **40,93** και διάμεσο **25,15**, αποτυπώνοντας υψηλή μεταβλητότητα.

Οι δείκτες MACD, Signal, και Histogram εμφάνισαν σημαντική λοξότητα, με μέσες τιμές κοντά στο μηδέν, αλλά με μεγάλο αριθμό ακραίων τιμών.

4.2.3 Ανάλυση Κατά Έτος

Το 2020, η μέση τιμή κλεισίματος ήταν **10.692,42 USD**, σημειώνοντας αύξηση **302,89%** μέχρι το τέλος του έτους.

Το 2021, η μέση τιμή κλεισίματος ήταν **47.357,84 USD**, με μέγιστη τιμή στα **69.000 USD**, δείχνοντας μία από τις πιο ανοδικές περιόδους.

Το 2022, η τιμή σημείωσε πτώση κατά **64,23%**, με μέση τιμή **28.226,40 USD**.

Το 2023, η μέση τιμή κλεισίματος ήταν **26.429,37 USD**, σημειώνοντας ανάκαμψη **81,29%** από το χαμηλό του 2022.

4.2.4 Κατανομή και Outliers

Οι περισσότεροι δείκτες παρουσίασαν δεξιά λοξότητα, με εξαίρεση τις χρονικές μεταβλητές που εμφάνισαν συμμετρία. Εντοπίστηκαν σημαντικοί outliers (ακραίες τιμές), κυρίως σε χαρακτηριστικά όπως το Volume USDT και το tradecount, γεγονός που συνδέεται με ακραία γεγονότα αγοράς, όπως ραγδαίες αυξομειώσεις τιμών.

Για να διασταυρωθεί η κατανομή κάθε χαρακτηριστικού, εκτελέστηκαν στατιστικοί έλεγχοι, όπως ο Shapiro-Wilk, ο Kolmogorov-Smirnov (KS) και ο Anderson-Darling (AD). Οι έλεγχοι αυτοί χρησιμοποιήθηκαν τόσο για το σύνολο δεδομένων όσο και για κάθε έτος ξεχωριστά, με στόχο την επιλογή του κατάλληλου scaler κατά την εκπαίδευση των αλγορίθμων τεχνητής νοημοσύνης (AI).

Επειδή το σύνολο δεδομένων περιλαμβάνει περίπου 1.99 εκατομμύρια εγγραφές, ο έλεγχος Shapiro-Wilk ενδέχεται να μην είναι ακριβής για δείγματα άνω των 5.000 στοιχείων, καθώς δεν είναι σχεδιασμένος για πολύ μεγάλα σύνολα δεδομένων. Για να αντιμετωπιστεί αυτό το ζήτημα, πραγματοποιήθηκε δειγματοληψία (subsampling) 5.000 στοιχείων για την εφαρμογή του ελέγχου Shapiro-Wilk, τόσο στο συνολικό σύνολο δεδομένων όσο και σε κάθε έτος. Αυτή η προσέγγιση επέτρεψε μια πιο αξιόπιστη εκτίμηση της κατανομής κάθε χαρακτηριστικού.

Από τα αποτελέσματα των στατιστικών ελέγχων, διαπιστώθηκε ότι κανένα από τα χαρακτηριστικά του συνόλου δεδομένων δεν ακολουθεί κανονική κατανομή, ούτε στο σύνολο του dataset ούτε σε επιμέρους έτη. Παρότι ορισμένα χαρακτηριστικά, όπως ο CMO,

παρουσίασαν οπτικά συμμετρία και μονοκορυφή κατανομή (unimodal), οι στατιστικοί έλεγχοι ανέδειξαν αποκλίσεις από την κανονικότητα. Αυτό υπογραμμίζει τη σημασία της διενέργειας στατιστικών ελέγχων πέρα από την οπτική επιθεώρηση, ώστε να τεκμηριωθεί η πραγματική κατανομή των δεδομένων και να γίνει επιλογή της καταλληλότερης μεθόδου κανονικοποίησης ή κλιμάκωσης για κάθε χαρακτηριστικό.

4.2.5 Τάσεις και Ανάλυση Χρόνου

Η τάση τιμής συνολικά έδειξε αύξηση **317,78%** κατά την περίοδο ανάλυσης. Η κατανομή του όγκου συναλλαγών ήταν υψηλότερη στις ώρες αιχμής, όπως αποδεικνύεται από τον μέσο όρο των συναλλαγών ανά ώρα.

4.2.6 Ανάλυση Συσχετίσεων

Η ανάλυση συσχετίσεων αποτελεί ένα κρίσιμο βήμα για την κατανόηση των σχέσεων μεταξύ των χαρακτηριστικών του συνόλου δεδομένων. Χρησιμοποιήθηκε ο συντελεστής συσχέτισης Pearson, ο οποίος μετρά τη γραμμική εξάρτηση μεταξύ δύο μεταβλητών, λαμβάνοντας τιμές από -1 (αρνητική πλήρης συσχέτιση) έως +1 (θετική πλήρης συσχέτιση). Τα αποτελέσματα της ανάλυσης ανέδειξαν τόσο ισχυρές όσο και ασθενείς συσχετίσεις, με χρήσιμες επισημάνσεις για τη δομή των δεδομένων.

Τα χαρακτηριστικά open, high, low, και close, τα οποία αποτελούν τις τιμές συναλλαγών του Bitcoin σε διαφορετικές στιγμές, παρουσιάζουν συντελεστή συσχέτισης μεγαλύτερο από 0.99. Αυτό ήταν αναμενόμενο, καθώς οι τιμές αυτές εξαρτώνται άμεσα η μία από την άλλη, αντανακλώντας τη συνολική κίνηση της αγοράς. Αντιθέτως, μεταβλητές όπως ο αριθμός συναλλαγών (tradedcount) παρουσίασαν ασθενέστερες συσχετίσεις με τις τιμές, με τιμές συσχέτισης που κυμαίνονται από -0.04 έως -0.06, υποδεικνύοντας ότι ο όγκος των συναλλαγών δεν συνδέεται άμεσα με τις τιμές συναλλαγών σε βραχυπρόθεσμο ορίζοντα.

Όσον αφορά τους τεχνικούς δείκτες, χαρακτηριστικά όπως ο MACD_Hist εμφάνισαν μέτριες συσχετίσεις με τις τιμές, όπως 0.37 για τη σχέση του με την τιμή close. Αυτό υποδηλώνει ότι οι τεχνικοί δείκτες ενδέχεται να παρέχουν πρόσθετες πληροφορίες για την ανάλυση δεδομένων πέρα από τις βασικές τιμές συναλλαγών. Ενδιαφέρον παρουσιάζει επίσης η αρνητική

συσχέτιση του δείκτη CMO με την τιμή **MACD_Hist**, η οποία φτάνει έως και -0.51, γεγονός που μπορεί να προσφέρει ενδείξεις για διαφορετικές φάσεις δυναμικής στην αγορά.

Η ανάλυση συσχετίσεων παρέχει χρήσιμα στοιχεία για την επιλογή χαρακτηριστικών στα επόμενα στάδια της ανάλυσης και της μηχανικής μάθησης. Ισχυρές συσχετίσεις μπορούν να βοηθήσουν στη μείωση της πολυπλοκότητας, αφαιρώντας πλεονασματικά χαρακτηριστικά, ενώ οι πιο ασθενείς σχέσεις ενδέχεται να υποδείξουν περιοχές που απαιτούν περαιτέρω διερεύνηση.

4.3 Ζητήματα Ποιότητας Δεδομένων

4.3.1 Κενές Εγγραφές

Ο έλεγχος για κενές τιμές έδειξε ότι οι περισσότερες στήλες δεν παρουσίαζαν κενά. Ωστόσο, σε ορισμένα χαρακτηριστικά όπως ο **MACD_Hist** και ο **ATR**, τα ποσοστά κενών εγγραφών ήταν κάτω από το 5% του συνόλου των δεδομένων. Για την αντιμετώπισή τους, εφαρμόστηκε μια προσέγγιση όπου οι κενές τιμές συμπληρώθηκαν με τη διάμεσο των δεδομένων του τελευταίου τριμήνου που αντιστοιχούσε στη χρονική στιγμή της εγγραφής. Επιπλέον, χαρακτηριστικά με ποσοστό κενών που ξεπερνούσε το 5% θεωρήθηκαν υποψήφια για διαγραφή, αλλά κανένα χαρακτηριστικό δεν πληρούσε αυτή την προϋπόθεση, γεγονός που ενίσχυσε τη συνολική πληρότητα του dataset.

4.3.2 Ακραίες Τιμές (Outliers)

Η παρουσία ακραίων τιμών ήταν εμφανής σε χαρακτηριστικά όπως ο όγκος συναλλαγών (**Volume USDT**) και ο αριθμός συναλλαγών (**tradecount**). Ο όγκος συναλλαγών εμφάνισε μεγάλες αποκλίσεις, ειδικά σε περιόδους υψηλής μεταβλητότητας, ενώ ο αριθμός συναλλαγών είχε έντονη λοξότητα, με μέγιστες τιμές που ξεπερνούσαν κατά πολύ τις μέσες τιμές. Για την ανάλυση των ακραίων τιμών, χρησιμοποιήθηκε η μέθοδος **boxplot**, η οποία εντόπισε τιμές που υπερέβαιναν το εύρος **1.5×IQR (Interquartile Range)**. Παρά τις αποκλίσεις, οι ακραίες τιμές δεν αφαιρέθηκαν, καθώς κρίθηκαν σημαντικές για τη μελέτη, ιδιαίτερα σε περιόδους έντονης συναλλακτικής δραστηριότητας.

4.3.3 Μεταβλητότητα και Θόρυβος

Η μεταβλητότητα, όπως καταγράφηκε μέσω δεικτών όπως ο **ATR**, ανέδειξε περιόδους έντονου θορύβου. Ο θόρυβος προέκυψε κυρίως σε μικρές χρονικές περιόδους με χαμηλή συναλλακτική δραστηριότητα ή από απότομες μεταβολές στις τιμές και τον όγκο συναλλαγών. Για τη διαχείριση αυτών των φαινομένων, χρησιμοποιήθηκαν κινητοί μέσοι όροι (EMA, HMA) για τη λείανση των δεδομένων, ενώ ο δείκτης ATR αξιοποιήθηκε για την εκτίμηση της σχετικής μεταβλητότητας, εξαιρώντας περιόδους χαμηλής σημασίας.

4.3.4 Ποιότητα Δεδομένων και Συσχετίσεις

Η ποιότητα των δεδομένων μπορεί να επηρεαστεί σημαντικά από τις σχέσεις μεταξύ χαρακτηριστικών, κάτι που επισημάνθηκε από την ανάλυση συσχετίσεων. Για παράδειγμα, οι πολύ υψηλές συσχετίσεις μεταξύ των χαρακτηριστικών open, high, low, και close υποδεικνύουν πιθανό πλεονασμό στις πληροφορίες. Η παρουσία πλεονασματικών χαρακτηριστικών, εάν δεν αντιμετωπιστεί, μπορεί να οδηγήσει σε φαινόμενα όπως η υπερπροσαρμογή (overfitting) κατά τη χρήση μοντέλων μηχανικής μάθησης.

Επιπλέον, η ανάλυση έδειξε ότι χαρακτηριστικά όπως ο αριθμός συναλλαγών (tradedcount) και ο όγκος συναλλαγών (Volume USDT) παρουσιάζουν πιο ασθενείς συσχετίσεις με τις τιμές, κάτι που υποδηλώνει ότι ενδέχεται να είναι λιγότερο προβλέψιμα ή να απαιτούν μετασχηματισμούς πριν ενσωματωθούν στα μοντέλα. Ωστόσο, δεν εντοπίστηκαν ακραίες ασυνέπειες ή ενδείξεις για χαμηλή ποιότητα δεδομένων στις σχέσεις μεταξύ των χαρακτηριστικών.

4.4 Οπτικοποίηση των Δεδομένων


4.4.1 Επισκόπηση Ιστορικών Τιμών Κλεισίματος

Η διαχρονική απεικόνιση των τιμών κλεισίματος παρουσιάζει σημαντικές διακυμάνσεις ανά χρονική περίοδο.



Διάγραμμα 17 - Price Action για την Περίοδο 01/2020 - 10/2023

Η εξέλιξη της τιμής κλεισίματος για την περίοδο Ιανουαρίου 2020 έως Οκτωβρίου 2023 δείχνει σημαντικές διακυμάνσεις, με υψηλές τιμές να καταγράφονται το 2021, υποδηλώνοντας περιόδους αυξημένης οικονομικής δραστηριότητας και ενδιαφέροντος για επενδύσεις.



Διάγραμμα 18 - Price Action για το Έτος 2020

Κατά τη διάρκεια του 2020, παρατηρείται σταδιακή άνοδος της τιμής κλεισίματος, με ιδιαίτερη αύξηση προς το τέλος του έτους. Το διάγραμμα αναδεικνύει μια πρόιμη δυναμική στην αγορά κατά τη συγκεκριμένη περίοδο.



Διάγραμμα 19 - Price Action για το Έτος 2021

Η τιμή κλεισίματος το 2021 παρουσίασε σημαντικές αυξομειώσεις, με αποκορύφωμα την επίτευξη ιστορικών υψηλών στα μέσα του έτους. Οι απότομες πτώσεις που ακολούθησαν υποδεικνύουν περιόδους υψηλής μεταβλητότητας.



Διάγραμμα 20 - Price Action για το Έτος 2022

Το 2022 χαρακτηρίστηκε από συνεχή πτώση των τιμών κλεισίματος, η οποία για βραχυπρόθεσμους επενδυτές υποδεικνύει περιόδους μειωμένου ενδιαφέροντος και αρνητικών οικονομικών συνθηκών. Ωστόσο, για επενδυτές με μακροπρόθεσμες βλέψεις, η πτώση αυτή μπορεί να ερμηνευθεί ως ευκαιρία αγορών σε χαμηλότερες τιμές, αξιοποιώντας τη δυναμική της αγοράς για μελλοντικά κέρδη.




Διάγραμμα 21 - Price Action για το Έτος 2023

Το 2023 δείχνει μια τάση σταθεροποίησης με ελαφρώς ανοδικές κινήσεις, ιδιαίτερα κατά το δεύτερο εξάμηνο του έτους, που ενδεχομένως υποδηλώνουν αυξημένη εμπιστοσύνη στην αγορά.


4.4.2 Ανάλυση Τιμών Κλεισίματος μέσω Boxplots

Τα Boxplots χρησιμοποιήθηκαν για την ανάλυση των τιμών κλεισίματος ανά έτος, παρουσιάζοντας τη διάμεση τιμή, τα τεταρτημόρια και τα outliers.




Διάγραμμα 22 - Boxplot Τιμών Κλεισίματος για το Έτος 2020

Η ανάλυση των τιμών κλεισίματος για το 2020 δείχνει ότι η διάμεση τιμή βρίσκεται περίπου στα \$10,000. Τα outliers εντοπίζονται κυρίως σε υψηλότερες τιμές, υποδεικνύοντας περιόδους έντονης αγοράς.




Διάγραμμα 23 - Boxplot Τιμών Κλεισίματος για το Έτος 2021

Το 2021 παρουσιάζει μεγαλύτερο εύρος τιμών, με διάμεση τιμή περίπου στα \$50,000. Οι υψηλότερες τιμές αντιστοιχούν στην περίοδο κορύφωσης της αγοράς.



Διάγραμμα 24 - Boxplot Τιμών Κλεισίματος για το Έτος 2022

Το 2022 χαρακτηρίστηκε από πτωτική τάση, με τις τιμές να συγκεντρώνονται κυρίως σε χαμηλότερα επίπεδα. Η διάμεση τιμή κυμάνθηκε περίπου στα \$25,000.




Διάγραμμα 25 - Boxplot Τιμών Κλεισίματος για το Έτος 2023

Η ανάλυση των τιμών κλεισίματος για το 2023 δείχνει αυξημένη σταθερότητα, με διάμεση τιμή περίπου στα \$28,000. Τα outliers είναι ελάχιστα, υποδηλώνοντας μειωμένη μεταβλητότητα.

4.4.3 Κατανομή Τιμών Κλεισίματος

Η κατανομή των τιμών κλεισίματος αποκαλύπτει τη συχνότητα εμφάνισης συγκεκριμένων τιμών και την κεντρική τάση των δεδομένων.




Διάγραμμα 26 - Κατανομή Τιμών Κλεισίματος (Συνολικό Διάστημα)

Το διάγραμμα απεικονίζει την κατανομή των τιμών κλεισίματος για το σύνολο του dataset. Διαπιστώνεται ότι η πλειονότητα των τιμών συγκεντρώνεται σε χαμηλότερες τιμές, με ασυμμετρία που υποδεικνύει ότι οι υψηλότερες τιμές είναι λιγότερο συχνές.


4.4.4 Κατανομή Τεχνικών Δεικτών

Η κατανομή των τεχνικών δεικτών προσφέρει εικόνα για τη δυναμική του συνόλου δεδομένων και τη συμπεριφορά συγκεκριμένων χαρακτηριστικών.



Διάγραμμα 27 - Κατανομή του ATR


Η κατανομή του δείκτη ATR δείχνει υψηλή συγκέντρωση σε χαμηλές τιμές, υποδεικνύοντας ότι οι περισσότερες εγγραφές παρουσιάζουν περιορισμένη μεταβλητότητα. Παρόλα αυτά, οι υψηλότερες τιμές ATR υποδηλώνουν περιόδους αυξημένης αστάθειας.



Διάγραμμα 28 - Κατανομή του CMO

Η κατανομή του δείκτη CMO φαίνεται οπτικά να ακολουθεί κανονική κατανομή, καθώς παρουσιάζει μια συμμετρική και μονοκορυφή μορφή (unimodal). Ωστόσο, οι τιμές των στατιστικών ελέγχων Shapiro-Wilk, Kolmogorov-Smirnov (KS) και Anderson-Darling (AD)


έδειξαν ότι δεν πληροί τα κριτήρια της κανονικής κατανομής. Η οπτική επιθεώρηση, αν και χρήσιμη, δεν είναι επαρκής για να επιβεβαιώσει την κανονικότητα. Για τον λόγο αυτό, πραγματοποιήθηκαν στατιστικοί έλεγχοι κανονικότητας σε κάθε χαρακτηριστικό του συνόλου δεδομένων, ώστε να εξασφαλιστεί μια ακριβής αξιολόγηση της κατανομής τους.



Διάγραμμα 29 - Κατανομή του Z-Score

Η κατανομή του Z-Score υποδηλώνει μια πολυτροπική κατανομή (multimodal distribution), καθώς παρατηρούνται πολλαπλές κορυφές (modes). Αυτό μπορεί να αντανakλά την ετερογένεια στα δεδομένα, πιθανώς λόγω διαφορετικών φάσεων της αγοράς ή ομάδων επενδυτών με διαφορετική συμπεριφορά. Για παράδειγμα, περίοδοι έντονης μεταβλητότητας ή σταθερότητας μπορεί να επηρεάζουν τη διασπορά των τιμών. Η παρατήρηση αυτή υποδεικνύει την ανάγκη για περαιτέρω ανάλυση, όπως clustering, ώστε να εντοπιστούν οι αιτίες αυτής της ετερογένειας.

4.4.5 Ανάλυση Συσχετίσεων μέσω Heatmap



Διάγραμμα 30 - Ανάλυση Συσχετίσεων μέσω Heatmap (Για όλη τη περίοδο)

Το heatmap απεικονίζει τις γραμμικές συσχετίσεις μεταξύ όλων των χαρακτηριστικών, επιτρέποντας την εύκολη αναγνώριση ισχυρών ή αδύναμων σχέσεων. Το heatmap για το σύνολο δεδομένων δείχνει την ισχυρή συσχέτιση μεταξύ των βασικών τιμών συναλλαγών (πάνω από 0.99) και τις μέτριες συσχετίσεις μεταξύ των τεχνικών δεικτών, όπως 0.37 για τη σχέση μεταξύ MACD_Hist και close.

4.5 Συμπεράσματα

Η ανάλυση του συνόλου δεδομένων αναδεικνύει τη σύνθετη φύση των χρηματοοικονομικών συναλλαγών και τη δυσκολία στην πρόβλεψη με ακρίβεια λόγω της πολυπλοκότητας και της εγγενούς αβεβαιότητας που χαρακτηρίζουν τις αγορές. Τα δεδομένα καλύπτουν μια χρονική περίοδο αυξημένης μεταβλητότητας, η οποία συνδέεται στενά με την παγκόσμια κρίση του

COVID-19 και τις σχετικές καραντίνες. Αυτή η περίοδος χαρακτηρίστηκε από έντονες διακυμάνσεις στις τιμές και σημαντική αβεβαιότητα, καθιστώντας την πρόκληση ακόμη μεγαλύτερη για την ανάπτυξη αξιόπιστων μοντέλων τεχνητής νοημοσύνης.

Η ποικιλία των τεχνικών δεικτών και χαρακτηριστικών που αναλύθηκαν αποδεικνύει την ανάγκη προσεκτικής επιλογής χαρακτηριστικών (feature selection) για την εκπαίδευση μοντέλων, καθώς η ενσωμάτωση περιττών ή άσχετων χαρακτηριστικών μπορεί να οδηγήσει σε υπερπροσαρμογή (overfitting) ή μειωμένη ακρίβεια πρόβλεψης. Τα αποτελέσματα των στατιστικών και γραφικών αναλύσεων υποδεικνύουν ότι η υψηλή μεταβλητότητα επηρεάζει σημαντικά τις συσχετίσεις και τη διασπορά των δεδομένων, απαιτώντας προηγμένες τεχνικές μοντελοποίησης.

5 – Μεθοδολογία

5.1 Προετοιμασία Δεδομένων για Εκπαίδευση από Μοντέλα TN

Η προετοιμασία των δεδομένων⁶ συνιστά ένα από τα πλέον καθοριστικά στάδια στη διαδικασία δημιουργίας μοντέλων Τεχνητής Νοημοσύνης (TN). Δεδομένου ότι η απόδοση των μοντέλων εξαρτάται άμεσα από την ποιότητα και τη δομή των εισροών τους, η επιμελής προεπεξεργασία και η ανάδειξη κατάλληλων χαρακτηριστικών (feature engineering) κρίνονται αναγκαίες για την επίτευξη αξιόπιστων προβλέψεων.

5.1.1 Καθαρισμός και Μετασχηματισμός Δεδομένων

Κανονικοποίηση: Για τη βέλτιστη επεξεργασία των τεχνικών δεικτών, εφαρμόστηκαν οι μέθοδοι MinMaxScaler και RobustScaler. Η επιλογή τους βασίστηκε στα χαρακτηριστικά της μη κανονικής κατανομής και στην ύπαρξη ακραίων τιμών, ώστε να διασφαλιστεί τόσο η συγκρισιμότητα μεταξύ των χαρακτηριστικών όσο και ο περιορισμός της επίδρασης των outliers.

Ανίχνευση και Αντιμετώπιση Ακραίων Τιμών: Για την ανίχνευση ακραίων τιμών χρησιμοποιήθηκαν διάφορες μέθοδοι, συμπεριλαμβανομένου του Z-Score και της ανάλυσης μέσω Interquartile Range (IQR). Τα boxplots συνέβαλαν στην οπτικοποίηση των ακραίων τιμών, παρέχοντας επιπλέον πληροφορίες για τη διασπορά και την ένταση των τιμών που αποκλίνουν από τη γενική κατανομή.

5.1.2 Διαχωρισμός Στόχου και Χαρακτηριστικών

Αρχικά, διαχωρίστηκαν τα διαθέσιμα χαρακτηριστικά (features) από τη μεταβλητή στόχο (target), η οποία σε αυτή την περίπτωση αντιπροσωπεύει την κατεύθυνση των τιμών (price direction). Με αυτό τον τρόπο διασφαλίστηκε ότι οι τιμές της μεταβλητής στόχου δεν επηρεάζουν αθέμιτα τη διαδικασία εκπαίδευσης του μοντέλου. Ο διαχωρισμός αυτός

⁶ Αναλυτικά η διαδικασία προεργασίας των δεδομένων και ο κώδικας είναι διαθέσιμα στον σύνδεσμο: <https://url.kosmidis.me/nup-msc-data-processing>

εξασφαλίζει ότι οι προβλέψεις του μοντέλου δεν επηρεάζονται άμεσα από τη μεταβλητή στόχου κατά τη διαδικασία εκπαίδευσης.

Η μεταβλητή *price_direction* αποτελεί τον στόχο (target variable) που χρησιμοποιείται για την ταξινόμηση ή πρόβλεψη της κατεύθυνσης της τιμής ενός χρηματοοικονομικού περιουσιακού στοιχείου. Προκύπτει από τη διαφορά των τιμών κλεισίματος σε διαδοχικές χρονικές περιόδους και μετατρέπεται σε μια δυαδική ή πολυκατηγορική μεταβλητή. Συγκεκριμένα:

Υπολογισμός διαφοράς τιμών:

$$\Delta price = close_t - close_{t-1}$$

Όπου:

- $close_t$: Η τιμή κλεισίματος στη χρονική περίοδο t ,
- $close_{t-1}$: Η τιμή κλεισίματος στη χρονική περίοδο $t - 1$.

Ορισμός κατεύθυνσης τιμής (price direction) για να μετατραπεί η μεταβλητή σε δυαδική (binary classification):

$$price_direction = \begin{cases} 1, & \text{if } \Delta price > 0 \text{ (άνοδος τιμής)} \\ 0, & \text{if } \Delta price \leq 0 \text{ (πτώση ή σταθερότητα τιμής)} \end{cases}$$

Εναλλακτική πολυκατηγορική προσέγγιση (multi-class classification), εάν θέλουμε να έχουμε περισσότερες κατηγορίες για την τιμή:

$$price_direction = \begin{cases} 1, & \text{if } \Delta price > \epsilon \quad (\text{σημαντική άνοδος τιμής}) \\ 0, & \text{if } |\Delta price| \leq \epsilon \quad (\text{σταθερότητα τιμής}) \\ -1, & \text{if } \Delta price < -\epsilon \quad (\text{σημαντική πτώση τιμής}) \end{cases}$$

Όπου ϵ είναι ένα προκαθορισμένο όριο (threshold) για την κατηγοριοποίηση της μεταβλητής.

5.1.3 Διασφάλιση Ακεραιότητας Δεδομένων

Για τη διασφάλιση της ακρίβειας και της αξιοπιστίας, επαληθεύτηκε η παρουσία όλων των απαραίτητων στηλών για τη δημιουργία νέων χαρακτηριστικών. Σε περίπτωση ελλείψεων, οι

στήλες αυτές θα έπρεπε να αντιμετωπιστούν κατάλληλα μέσω ειδικών τεχνικών, όπως συμπλήρωση τιμών με διαμέσους ή αφαίρεση της γραμμής εφόσον έχει πολλές ελλείψεις.

5.1.4 Μηχανική Χαρακτηριστικών (Feature Engineering)

Η διαδικασία της μηχανικής χαρακτηριστικών (feature engineering) περιελάμβανε τον ορισμό νέων μεταβλητών, οι οποίες παράγονται από τις αρχικές τιμές του dataset. Ενδεικτικά παραδείγματα αποτελούν:

1. Η σχέση τιμών ανοίγματος και κλεισίματος υπολογίστηκε ως:

$$price_change_ratio = \frac{close}{open}$$

Όπου close η τιμή κλεισίματος μιας χρονικής περιόδου και open η τιμή ανοίγματος της ίδιας χρονικής περιόδου

2. Η αναλογία όγκου συναλλαγών ως:

$$trade_volume_ratio = \frac{Volume}{tradecount}$$

Όπου Volume ο συνολικός οικονομικός όγκος συναλλαγών (λόγου χάρη, ο όγκος σε USD) στη χρονική περίοδο και tradecount το πλήθος των συναλλαγών της περιόδου.

3. Η διαφορά υψηλής και χαμηλής τιμής ως:

$$high_low_spread = high - low$$

Όπου high η υψηλότερη τιμή κατά της διάρκεια της περιόδου ενώ low η χαμηλότερη (εύρος).

Μετά τη δημιουργία νέων χαρακτηριστικών, οι αρχικές στήλες που δεν ήταν πλέον απαραίτητες αφαιρέθηκαν.

5.1.5 Επιλογή Χαρακτηριστικών (Feature Selection)

Για να μειωθεί η πολυπλοκότητα του μοντέλου, χρησιμοποιήθηκε η μέθοδος επιλογής χαρακτηριστικών με βάση τη σημαντικότητά τους, όπως αυτή υπολογίζεται από το Random Forest. Ο τύπος που χρησιμοποιείται για τη σημασία των χαρακτηριστικών είναι:

$$I_j = \sum_{t \in T} \Delta_i(t)$$

όπου I_j είναι η σημασία του χαρακτηριστικού j , T είναι το σύνολο των κόμβων δέντρων και $\Delta_i(t)$ είναι η μείωση της αβεβαιότητας στον κόμβο t από το χαρακτηριστικό j .

Το αρχικό σύνολο δεδομένων περιλάμβανε 23 χαρακτηριστικά, από τα οποία αφαιρέθηκαν 11 λόγω υψηλής συσχέτισης (>90%), ενώ η τελική διάσταση περιορίστηκε σε 12 μεταβλητές, όπως οι MACD, ATR, CMO και high_low_spread.

5.1.6 Scaling και Διαχωρισμός Δεδομένων

Η κλιμάκωση των δεδομένων είναι απαραίτητη για να διασφαλιστεί ότι όλα τα χαρακτηριστικά βρίσκονται στο ίδιο εύρος τιμών, αποτρέποντας την κυριαρχία χαρακτηριστικών με μεγάλες τιμές στις διαδικασίες εκπαίδευσης.

Ο **MinMaxScaler** κλιμακώνει τα δεδομένα στο εύρος:

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}}$$

Όπου X η αρχική τιμή του χαρακτηριστικού, $X_{\min}$ και $X_{\max}$ η ελάχιστη και η μέγιστη τιμή του χαρακτηριστικού στο σύνολο δεδομένων αντίστοιχα, X' η κλιμακωμένη τιμή του χαρακτηριστικού.

Ο **StandardScaler** κλιμακώνει τα δεδομένα ώστε να έχουν μηδενική μέση τιμή και μοναδιαία διασπορά:

$$X' = \frac{X - \mu}{\sigma}$$

Όπου μ η μέση τιμή του χαρακτηριστικού στο σύνολο δεδομένων, σ η τυπική απόκλιση του χαρακτηριστικού και X' η κλιμακωμένη τιμή του χαρακτηριστικού.

Ο **RobustScaler** κανονικοποιεί τα δεδομένα αφαιρώντας τη διάμεσο (median) και κλιμακώνοντάς τα με βάση το ενδοτεταρτημοριακό εύρος (interquartile range - IQR):

$$X' = \frac{X - Q_2}{IQR}$$

Όπου Q_2 η διάμεσος του χαρακτηριστικού στο σύνολο δεδομένων και IQR το ενδοτεταρτημοριακό εύρος, δηλαδή η διαφορά μεταξύ του 3^{ου} (Q_3) και του 1^{ου} (Q_1) τεταρτημορίου $IQR = Q_3 - Q_1$.

Η επιλογή του κατάλληλου scaler εξαρτάται από τα χαρακτηριστικά των δεδομένων. Ο MinMaxScaler είναι ιδανικός όταν τα δεδομένα δεν ακολουθούν κανονική κατανομή, ενώ ο StandardScaler είναι πιο κατάλληλος όταν τα δεδομένα ακολουθούν περίπου κανονική κατανομή.

Δεδομένου ότι τα περισσότερα χαρακτηριστικά δεν εμφάνιζαν κανονική κατανομή, στην παρούσα μελέτη επιλέχθηκαν οι MinMaxScaler και RobustScaler, ώστε να αποφευχθεί η παραμόρφωση που επιφέρει η ύπαρξη ακραίων τιμών. Μετά την κλιμάκωση, διαχωρίσαμε το dataset σε σύνολα εκπαίδευσης (70%), επικύρωσης (15%) και δοκιμών (15%), διασφαλίζοντας ισορροπημένη εκπροσώπηση των δεδομένων σε κάθε στάδιο.

5.2 Σχεδιασμός και Υλοποίηση Αλγορίθμων TN

5.2.1 Μοντέλο LGBMClassifier με το scikit-learn

Ένα από τα μοντέλα που εφαρμόστηκαν είναι το LGBMClassifier (LightGBM), το οποίο διακρίνεται για την αποδοτικότητά του σε ταξινομήσεις υψηλής ακρίβειας. Σε συνδυασμό με τη βιβλιοθήκη scikit-learn, διευκολύνει την ενσωμάτωση στο υφιστάμενο workflow, ενώ

παράλληλα παρέχει εξαιρετική διαχειρισσιμότητα μεγάλων συνόλων δεδομένων και υποστήριξη πολυκατηγορικών προβλημάτων. Το μοντέλο διακρίνεται για τη δυνατότητά του να χρησιμοποιεί ιστορικά δεδομένα για την πρόβλεψη μελλοντικών τάσεων, γεγονός που το καθιστά ιδιαίτερα χρήσιμο στις χρηματοοικονομικές αγορές.

Η λειτουργία του μοντέλου βασίζεται στη βελτιστοποίηση μιας συνάρτησης απώλειας (loss function), η οποία υπολογίζεται μέσω του τύπου:

$$L = \sum_{i=1}^n w_i \cdot \ell(y_i, f(x_i))$$

Όπου w_i το βάρος του δείγματος i , η συνάρτηση απώλειας συμβολίζεται στη μηχανική μάθηση με μικρό καλλιγραφικό λάμδα (ή script l), άρα, η συνάρτηση $\ell(y_i, f(x_i))$ αντιπροσωπεύει την απώλεια εξίσωσης που σχετίζεται με το LGBMClassifier, δηλαδή το σφάλμα μεταξύ της πραγματικής τιμής y_i και της πρόβλεψης του μοντέλου $f(x_i)$.

Η ελαχιστοποίηση της συνάρτησης απώλειας είναι θεμελιώδης για τη βελτίωση της ακρίβειας του μοντέλου μέσω ενισχυτικών δέντρων (boosting trees). Αυτό επιτυγχάνεται με τη δυναμική ενημέρωση των βαρών w_i , προσαρμόζοντας το μοντέλο ώστε να επικεντρώνεται στα δυσκολότερα παραδείγματα (η ενέργεια αυτή επιτυγχάνεται μέσω μια διαδικασίας που ονομάζεται backpropagation). Η αξιολόγηση του μοντέλου πραγματοποιήθηκε με τη χρήση μετρικών ακρίβειας, όπως η μέση ακρίβεια σε διασταυρούμενη επικύρωση (cross-validation). Ειδικά, χρησιμοποιήθηκε προσαρμοσμένη συνάρτηση απώλειας που ενσωματώνει παράγοντες κερδοφορίας και ανάλυσης κινδύνου.

5.2.1.1 Υπερπαραμετροποίηση με Γενετικό Αλγόριθμο


Για την περαιτέρω βελτίωση του LGBMClassifier, εφαρμόστηκε μια καινοτόμος διαδικασία υπερπαραμετροποίησης μέσω Γενετικών Αλγορίθμων. Η μέθοδος αυτή επιτρέπει την ευρετική αναζήτηση σε ευρύ χώρο παραμέτρων, διασφαλίζοντας συνεχή βελτίωση των υπαρχόντων τιμών μέσω επιλογής, διασταύρωσης και μετάλλαξης. Ως αποτέλεσμα, το μοντέλο αποκτά αυξημένη ακρίβεια και ανθεκτικότητα σε τοπικά ελάχιστα. Η εφαρμογή του γενετικού αλγορίθμου περιλαμβάνει:

1. Δημιουργία αρχικού πληθυσμού υπερπαραμέτρων.
2. Υπολογισμό της καταλληλότητας (fitness) κάθε ατόμου στον πληθυσμό.
3. Εφαρμογή μηχανισμών επιλογής, διασταύρωσης και μετάλλαξης για τη δημιουργία επόμενων γενεών.

Αυτή η διαδικασία επιτρέπει τη συνεχή βελτίωση του μοντέλου, οδηγώντας σε μεγαλύτερη ακρίβεια και αποδοτικότητα.

5.2.1.2 Αποφυγή Τοπικών Ελαχίστων

Ένα κοινό πρόβλημα στη βελτιστοποίηση είναι η παγίδευση σε τοπικά ελάχιστα. Οι γενετικοί αλγόριθμοι προσφέρουν μια φυσική λύση μέσω της τυχειότητας και της εξερεύνησης εναλλακτικών διαδρομών στο χώρο παραμέτρων. Στο LGBMClassifier, η ενσωμάτωση γενετικών μηχανισμών μειώνει την πιθανότητα στασιμότητας, διασφαλίζοντας ότι το μοντέλο φτάνει σε πραγματικά βέλτιστες λύσεις.




Σχήμα 1 - Αναπαράσταση της παγίδευσης του μοντέλου σε τοπικό ελάχιστο, ενώ υπάρχει ένα καλύτερο βέλτιστο σημείο (global minima) που αντιπροσωπεύει τη χαμηλότερη δυνατή τιμή της συνάρτησης απώλειας. (Adigun & Yinka-Banjo, 2022)

5.2.2 Απλό Μοντέλο Perceptron

Το απλό μοντέλο Perceptron αποτελεί τη βάση της τεχνητής νοημοσύνης, επιδεικνύοντας τις θεμελιώδεις αρχές των νευρωνικών δικτύων. Αυτό το γραμμικό μοντέλο είναι εξαιρετικά


χρήσιμο για την κατανόηση των αρχών της κατηγοριοποίησης, αν και περιορίζεται από την αδυναμία του να αντιμετωπίσει προβλήματα που δεν είναι γραμμικά διαχωρίσιμα. Ωστόσο, αποτελεί απαραίτητο πρώτο βήμα για τη δόμηση πιο σύνθετων αρχιτεκτονικών.



Σχήμα 2 - Απλοποιημένος νευρώνας ενός τεχνητού νευρωνικού δικτύου, όπου το βάρος w_0 είναι 1, ενώ τα υπόλοιπα βάρη είναι μηδενικά, επηρεάζοντας τον τρόπο συνδυασμού των εισόδων (x, y, z) στο αποτέλεσμα ($output$). (Keim, 2019)

5.2.3 Multilayered Perceptron (MLP)

Το Multilayered Perceptron (MLP) ξεπερνά τους περιορισμούς του απλού Perceptron με την εισαγωγή κρυφών επιπέδων, επιτρέποντας την αντιμετώπιση μη γραμμικών προβλημάτων. Μέσω της χρήσης συναρτήσεων ενεργοποίησης όπως η ReLU, step function, sigmoid κ.λπ., καθώς και της εφαρμογής της μεθόδου backpropagation για την εκπαίδευση, το MLP προσφέρει υψηλή απόδοση σε προβλήματα κατηγοριοποίησης και παλινδρόμησης. Η ευελιξία του το καθιστά ιδανικό για εφαρμογές όπως η πρόβλεψη τάσεων και η ανάλυση συμπεριφοράς.



Σχήμα 3 - Multi-layer perceptron με hidden layer και συνάρτηση ενεργοποίησης sigmoid. (Yong, 2015)

5.2.4 Δίκτυο Βαθιάς Μάθησης (Deep Learning)

Τα δίκτυα βαθιάς μάθησης (Deep Learning Networks) αποτελούν μια κατηγορία τεχνητών νευρωνικών δικτύων που σχεδιάστηκαν για να επεξεργάζονται μεγάλα και σύνθετα δεδομένα με τρόπο που προσομοιάζει τη λειτουργία του ανθρώπινου εγκεφάλου. Η αρχιτεκτονική τους βασίζεται σε διαδοχικά επίπεδα επεξεργασίας (hierarchical layers), καθένα από τα οποία εξάγει χαρακτηριστικά υψηλότερης σημασιολογικής πολυπλοκότητας από το προηγούμενο. Με αυτή τη δομή, τα δίκτυα βαθιάς μάθησης ενσωματώνουν τη δυνατότητα κατανόησης αφηρημένων μοτίβων στα δεδομένα, καθιστώντας τα εξαιρετικά αποδοτικά σε εφαρμογές όπως η ανάλυση εικόνων, η επεξεργασία φυσικής γλώσσας και η ανάλυση χρονοσειρών.

Ιδιαίτερο ενδιαφέρον παρουσιάζουν δύο ειδικές κατηγορίες νευρωνικών δικτύων, τα Convolutional Neural Networks (CNN) και τα Recurrent Neural Networks (RNN). Τα CNN εξειδικεύονται στη διαχείριση χωρικών δεδομένων, ενώ τα RNN προσανατολίζονται στην επεξεργασία δεδομένων με χρονική αλληλουχία (όπως λόγου χάρη οι τιμές αξιογράφων). Ο συνδυασμός αυτών των δύο αρχιτεκτονικών παρέχει ένα ισχυρό εργαλείο για την πρόβλεψη τάσεων στις αγορές, αξιοποιώντας τόσο τις χωρικές σχέσεις όσο και τη χρονική δυναμική των δεδομένων.

5.2.4.1 Convolutional Neural Networks (CNN)

Τα Convolutional Neural Networks (CNN) είναι μια κατηγορία νευρωνικών δικτύων που επικεντρώνεται στην ανάλυση δεδομένων με χωρική συσχέτιση, όπως οι εικόνες και τα διαγράμματα. Η αρχιτεκτονική τους στηρίζεται σε διαδοχικά επίπεδα convolution και pooling, τα οποία εξάγουν και συμπυκνώνουν πληροφορίες από τα δεδομένα. Κάθε φίλτρο (kernel) στο επίπεδο convolution εξάγει συγκεκριμένα χαρακτηριστικά από την είσοδο, ενώ το pooling μειώνει τη διάσταση των δεδομένων, διατηρώντας τις πιο σημαντικές πληροφορίες. Η λειτουργία convolution περιγράφεται μαθηματικά από τη σχέση:

$$s(t) = (x \cdot w)(t) = \sum_{\tau} x(\tau)w(t - \tau)$$

όπου x είναι η είσοδος, w το φίλτρο, t η θέση εφαρμογής του φίλτρου και $w(t-\tau)$ εκφράζει τη μετατόπιση του φίλτρου w κατά τη διαδικασία της συνελίξεως. Ουσιαστικά ο τύπος υπολογίζει ένα σταθμισμένο άθροισμα των τιμών της εισόδου x , όπου τα βάρη καθορίζονται από το φίλτρο w , σε συγκεκριμένη θέση t .

Τα CNN χρησιμοποιούνται ευρέως σε προβλήματα όπως η ανάλυση εικόνων, η αναγνώριση προσώπων και η επεξεργασία ιατρικών δεδομένων. Στο πλαίσιο της πρόβλεψης τάσεων στις αγορές, τα CNN εφαρμόζονται για την ανάλυση γραφημάτων, όπως τα candlestick charts, αποκαλύπτοντας μοτίβα που ενδέχεται να υποδηλώνουν μεταβολές στις τιμές.

5.2.4.2 Recurrent Neural Networks (RNN)

Τα Recurrent Neural Networks (RNN) είναι ειδικά σχεδιασμένα για τη διαχείριση σειριακών δεδομένων. Χρησιμοποιούν επαναληπτική ανατροφοδότηση (recurrent connections) για να διατηρούν πληροφορίες από προηγούμενα χρονικά βήματα, επιτρέποντας την κατανόηση σχέσεων στο χρόνο. Ένα τυπικό RNN περιγράφεται από τη σχέση:

$$h_t = \sigma(W_h h_{t-1} + W_x x_t + b)$$

όπου h_t είναι η κρυφή κατάσταση (hidden state), W_h και W_x τα βάρη, x_t η είσοδος στο χρόνο t , και σ η συνάρτηση ενεργοποίησης.

Τα RNN χρησιμοποιούνται σε προβλήματα φυσικής γλώσσας, αναγνώριση ομιλίας, και πρόβλεψη χρονοσειρών. Στο πλαίσιο της πρόβλεψης τάσεων τιμών στις αγορές, τα RNN είναι ιδιαίτερα χρήσιμα λόγω της δυνατότητάς τους να επεξεργάζονται ιστορικές τάσεις και να λαμβάνουν υπόψη τη δυναμική του χρόνου. Επιπλέον, προσαρμογές όπως τα Long Short-Term Memory (LSTM) και Gated Recurrent Units (GRU) επιλύουν προβλήματα που σχετίζονται με τη μακροχρόνια εξάρτηση των δεδομένων, ενισχύοντας την ακρίβεια στις προβλέψεις.

5.2.5 Σύγκριση Επιδόσεων Μεταξύ Μοντέλων TN

Η συγκριτική ανάλυση μεταξύ εναλλακτικών μοντέλων TN είναι καίρια για την επιλογή της βέλτιστης αρχιτεκτονικής, ανάλογα με τις απαιτήσεις κάθε εφαρμογής. Στο πλαίσιο αυτό, κρίσιμο ρόλο διαδραματίζουν μετρικές όπως η ακρίβεια, η ταχύτητα εκπαίδευσης και η ανθεκτικότητα σε ασταθή περιβάλλοντα, επιτρέποντας την εξαγωγή αντικειμενικών συμπερασμάτων για την αποτελεσματικότητα κάθε προσέγγισης. Η αξιολόγηση περιλαμβάνει κριτήρια όπως η ακρίβεια, η ταχύτητα εκπαίδευσης, η κλιμακωσιμότητα και η ανθεκτικότητα σε ασταθή περιβάλλοντα. Η ποσοτικοποίηση αυτών των παραμέτρων γίνεται μέσω καθιερωμένων μαθηματικών μετρικών, οι οποίες αποτυπώνουν την αποτελεσματικότητα και τη σταθερότητα των μοντέλων.

5.2.5.1 Ανάλυση Αποτελεσμάτων Κερδοφορίας

Η ανάλυση της κερδοφορίας ενός μοντέλου επικεντρώνεται στην αποδοτικότητά του σε πραγματικές συνθήκες. Αυτό περιλαμβάνει τη μέτρηση της ακρίβειας πρόβλεψης και της δυνατότητας εφαρμογής σε προβλήματα μεγάλης κλίμακας, εξασφαλίζοντας ότι το μοντέλο μπορεί να προσφέρει αξία σε πραγματικό χρόνο.

Ορθότητα Πρόβλεψης (Accuracy)

Η ακρίβεια υπολογίζεται ως το ποσοστό των σωστών προβλέψεων στο σύνολο των δειγμάτων:

$$Accuracy = \frac{True\ Positives + True\ Negatives}{Total\ Instances}$$

Όπου τα True Positives (TP) είναι οι θετικές περιπτώσεις που ταξινομήθηκαν σωστά, τα True Negatives (TN) είναι οι αρνητικές περιπτώσεις που ταξινομήθηκαν σωστά, και Total Instances είναι το σύνολο των δειγμάτων.

Ανάκληση (Recall)

Η ανάκληση είναι το ποσοστό των θετικών περιπτώσεων που ανιχνεύθηκαν σωστά:

$$Recall = \frac{True\ Positives}{True\ Positives + False\ Negatives}$$

Όπου False Negatives (FN) είναι οι θετικές περιπτώσεις που ταξινομήθηκαν λανθασμένα ως αρνητικές.

Ακρίβεια (Precision)

Η ακρίβεια εκτιμά την ποιότητα των θετικών προβλέψεων:

$$Precision = \frac{True\ Positives}{True\ Positives + False\ Positives}$$

Όπου False Positives (FP) οι αρνητικές περιπτώσεις που ταξινομήθηκαν λανθασμένα ως θετικές.

Ανάλυση Απόδοσης Επένδυσης

Στις χρηματοοικονομικές εφαρμογές, η απόδοση ενός μοντέλου μετράται μέσω του ποσοστού απόδοσης:

$$Return\ Rate = \frac{Profit}{Initial\ Investment}$$

Όπου Profit το καθαρό κέρδος που αποκομίζεται, και Initial Investment το αρχικό κεφάλαιο.

F1-Score

Η ακρίβεια και η ανάκληση συνδυάζονται μέσω της F1-Score για μια συνολική εικόνα της απόδοσης:

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall}$$

Όπου Precision είναι η ποιότητα των θετικών προβλέψεων και Recall το ποσοστό των θετικών περιπτώσεων που ανιχνεύθηκαν σωστά.

5.2.5.2 Ανθεκτικότητα σε Ασταθή Περιβάλλοντα

Η ανθεκτικότητα ενός μοντέλου σε ασταθή περιβάλλοντα είναι καθοριστικός παράγοντας για την επιτυχία του. Τα μοντέλα που παραμένουν σταθερά και αποδοτικά υπό συνθήκες μεταβλητότητας αποδεικνύονται πιο χρήσιμα για εφαρμογές όπου οι συνθήκες είναι δυναμικές, όπως οι χρηματοοικονομικές αγορές. Η συγκριτική ανάλυση αυτών των πτυχών αποκαλύπτει τα δυνατά και αδύνατα σημεία κάθε προσέγγισης, προσφέροντας πολύτιμη καθοδήγηση για τη βελτιστοποίηση των στρατηγικών τεχνητής νοημοσύνης.

Εμπειρική Διακύμανση

Η σταθερότητα των αποδόσεων ενός μοντέλου υπολογίζεται μέσω της διακύμανσης:

$$Variance = \frac{1}{N} \sum_{i=1}^N (R_i - \mu)^2$$

Όπου R_i η απόδοση στη δοκιμή i , μ η μέση απόδοση και N ο αριθμός των δοκιμών.

Συντελεστής Μεταβλητότητας (Coefficient of Variation - CV)

Για την κανονικοποίηση της διακύμανσης χρησιμοποιείται ο CV:

$$CV = \frac{\sigma}{\mu}$$

Όπου σ η τυπική απόκλιση

Ανθεκτικότητα στη Μεταβλητότητα

Ένας πρόσθετος δείκτης ανθεκτικότητας μπορεί να είναι η μέγιστη πτώση (maximum drawdown), που μετρά τη μέγιστη απώλεια ενός μοντέλου κατά τη διάρκεια της λειτουργίας του:

$$Max\ Drawdown = \frac{\max(P_t) - \min(P_t)}{\max(P_t)}$$

Όπου: P_t είναι το συνολικό κεφάλαιο ή η απόδοση στη χρονική στιγμή t .

Η χρήση αυτών των μετρικών εξασφαλίζει ότι τα μοντέλα παραμένουν σταθερά και αποδοτικά ακόμα και υπό συνθήκες έντονης μεταβλητότητας.

5.2.5.3 Ταχύτητα Εκπαίδευσης και Κλιμακωσιμότητα

Η ταχύτητα εκπαίδευσης και η δυνατότητα κλιμάκωσης σε μεγαλύτερα σύνολα δεδομένων είναι εξίσου σημαντικές. Η υπολογιστική πολυπλοκότητα ενός μοντέλου μπορεί να αξιολογηθεί ως:

$$\mathcal{O}(n^k)$$

Όπου n είναι ο αριθμός των δειγμάτων και k ο εκθέτης πολυπλοκότητας που εξαρτάται από τον αλγόριθμο.

5.3 Στρατηγικές Trading και Προσομοίωση

5.3.1 Σχεδιασμός Στρατηγικών Ανθρώπινων Εμπόρων

Η μελέτη των στρατηγικών που εφαρμόζουν οι ανθρώπινοι έμποροι αποτελεί ένα κρίσιμο ζήτημα για την κατανόηση της δυναμικής των χρηματοοικονομικών αγορών. Οι στρατηγικές αυτές συχνά βασίζονται σε μια ποικιλία παραμέτρων, όπως η εμπειρία, η ψυχολογία, οι γνώσεις για την αγορά και η διαίσθηση. Η διαμόρφωση αυτών των στρατηγικών συνδέεται στενά με τις ιδιαίτερες συνθήκες της αγοράς, καθώς και με τις προσωπικές προτιμήσεις και τους στόχους των εμπόρων. Η κατανόηση αυτών των πτυχών επιτρέπει τη δημιουργία μοντέλων που αναπαριστούν τη συμπεριφορά των ανθρώπων στις αγορές, ενισχύοντας την ικανότητα πρόβλεψης και ανάλυσης των χρηματοοικονομικών τάσεων.

5.3.1.1 Προσομοίωση *Emotional Traders*

Οι emotional traders, σε αντίθεση με άλλους πιο στρατηγικούς επενδυτές, σπάνια βασίζονται σε τεχνική ανάλυση ή σύνθετα μοντέλα για τη λήψη αποφάσεων. Αντίθετα, επηρεάζονται κυρίως από τη στιγμιαία κίνηση της αγοράς και καθοδηγούνται από συναισθήματα όπως ο φόβος της απώλειας ή η απληστία για κέρδος. Για αυτούς, η επένδυση συχνά θυμίζει τζόγο, καθώς οι αποφάσεις τους εξαρτώνται από το ρεύμα της αγοράς: όταν οι τιμές τείνουν να ανεβαίνουν, αισθάνονται την ανάγκη να αγοράσουν, ενώ όταν πέφτουν, συχνά βιάζονται να πουλήσουν.

Αυτή η συμπεριφορά, που ευθυγραμμίζεται με το ρεύμα της αγοράς, τους καθιστά ευάλωτους σε απότομες αλλαγές. Ωστόσο, ο τρόπος δράσης τους μπορεί να περιγραφεί μαθηματικά μέσω πιθανοτήτων που καθορίζουν τις ενέργειές τους ανάλογα με τη θετική ή αρνητική ορμή της αγοράς.

$$P_{buy} = 0.5 + 0.3 \cdot (M > 0) \quad \text{και} \quad P_{sell} = 0.5 + 0.3 \cdot (M < 0)$$

όπου M το momentum (ορμή) της αγοράς.

Οι τιμές 0.5 και 0.3 που χρησιμοποιούνται στις εξισώσεις των πιθανοτήτων αγοράς (P_{buy}) και πώλησης (P_{sell}) διαδραματίζουν κρίσιμο ρόλο στη μαθηματική αναπαράσταση της συμπεριφοράς των emotional traders. Η τιμή 0.5 αντιπροσωπεύει την ουδέτερη βάση των πιθανοτήτων. Σε περιπτώσεις όπου η αγορά δεν παρουσιάζει συγκεκριμένη τάση (δηλαδή όταν το momentum είναι μηδενικό), οι πιθανότητες αγοράς και πώλησης είναι εξίσου κατανομημένες, με τιμές ίσες με 0.5. Αυτό το επίπεδο υποδεικνύει ότι ο emotional trader δεν έχει σαφή προτίμηση προς αγορά ή πώληση, αντανακλώντας μια στάση αναμονής.

Η επιλογή του 0.5 ως βάση λειτουργεί ως σημείο ισορροπίας: όταν η αγορά δείχνει θετική ορμή, η πιθανότητα αγοράς αυξάνεται, εκφράζοντας την τάση των emotional traders να αγοράζουν σε ανοδικές αγορές. Αντίστοιχα, όταν η αγορά παρουσιάζει αρνητική ορμή, η πιθανότητα πώλησης αυξάνεται, αποτυπώνοντας την προτίμηση για πωλήσεις σε πτωτικές αγορές. Η σταθερή βάση του 0.5 επιτρέπει τη μετάβαση των πιθανοτήτων ανάλογα με τις τρέχουσες συνθήκες της αγοράς, διασφαλίζοντας ότι οι πιθανότητες αντιδρούν δυναμικά στην ορμή της αγοράς.

Η τιμή 0.3 εισάγεται ως ένας συντελεστής ενίσχυσης της προτίμησης του trader ανάλογα με την κατεύθυνση του momentum. Η προσθήκη $0.3 \cdot (\text{momentum} > 0)$ αυξάνει την πιθανότητα αγοράς όταν η ορμή είναι θετική, ενώ το $0.3 \cdot (\text{momentum} < 0)$ αυξάνει την πιθανότητα πώλησης όταν η ορμή είναι αρνητική. Αυτή η προσέγγιση προσδίδει βάρος στις αποφάσεις που βασίζονται στις βραχυπρόθεσμες τάσεις της αγοράς, αντικατοπτρίζοντας τη συναισθηματική αντίδραση των traders. Η τιμή 0.3 δεν επιλέγεται τυχαία, αλλά με στόχο να εκφράσει έναν μετριοπαθή βαθμό ενίσχυσης της τάσης, διατηρώντας παράλληλα μια ισορροπία. Έτσι, οι αλλαγές στις πιθανότητες είναι αρκετά σημαντικές ώστε να αποτυπώνουν την αντίδραση στις μεταβολές της αγοράς, χωρίς όμως να οδηγούν σε ακραίες συμπεριφορές, όπως απόλυτη βεβαιότητα για αγορά ή πώληση.

Υπολογισμός του Ποσού που Επενδύεται

Το ποσό που επενδύεται σε κάθε χρονική στιγμή Q_t υπολογίζεται λαμβάνοντας υπόψη το διαθέσιμο κεφάλαιο C_t , την αναμενόμενη απόδοση R_t , και τους παράγοντες ελέγχου ρίσκου α και β . Ο μαθηματικός τύπος που χρησιμοποιείται είναι:

$$Q_t = \min(\alpha \cdot C_t, \beta \cdot R_t)$$

Όπου C_t το διαθέσιμο κεφάλαιο, R_t η αναμενόμενη απόδοση και α, β οι παράμετροι ελέγχου του ρίσκου.

Απόφαση Συναλλαγής

Με βάση τις πιθανότητες, η απόφαση συναλλαγής λαμβάνεται ως εξής: Εάν η πιθανότητα αγοράς P_{buy} υπερβαίνει τις υπόλοιπες, πραγματοποιείται αγορά με το ποσό Q_t . Εάν η πιθανότητα πώλησης P_{sell} υπερβαίνει, πωλείται το αντίστοιχο ποσό Bitcoin. Σε κάθε άλλη περίπτωση, ο trader διατηρεί τη θέση του, χωρίς να πραγματοποιεί συναλλαγές.

Υπολογισμός Μετρικών

Οι μετρικές χρησιμοποιούνται για την ανάλυση των συνθηκών της αγοράς και την ενίσχυση της στρατηγικής λήψης αποφάσεων.

Κυλιόμενος Μέσος Όρος

Ο κυλιόμενος μέσος όρος της τιμής $S(t)$ για ένα παράθυρο w χρονικών στιγμών υπολογίζεται ως:

$$\mu_w(t) = \frac{1}{w} \sum_{i=t-w+1}^t S(i)$$

Κυλιόμενη Τυπική Απόκλιση:

Υπολογίζεται ως:

$$\sigma_w(t) = \sqrt{\frac{1}{w} \sum_{i=t-w+1}^t (S(i) - \mu_w(t))^2}$$

Ορμή (Momentum):

Η ορμή της αγοράς υπολογίζεται ως η διαφορά ανάμεσα στην τρέχουσα τιμή και τον κυλιόμενο μέσο όρο:

$$M(t) = S(t) - \mu_w(t)$$

5.3.1.2 Προσομοίωση Home Traders

Οι Home Traders, δηλαδή οι επενδυτές που πραγματοποιούν συναλλαγές από τον προσωπικό τους χώρο, συχνά βασίζονται σε δικές τους στρατηγικές και αναλύσεις. Αυτή η κατηγορία επενδυτών χαρακτηρίζεται από μεγαλύτερη αυτονομία, αλλά και περιορισμένη πρόσβαση σε εξελιγμένα εργαλεία και πληροφορίες σε σύγκριση με θεσμικούς επενδυτές. Η μελέτη αυτής της ομάδας είναι ιδιαίτερα σημαντική, καθώς εκπροσωπεί μεγάλο μέρος της αγοράς, ειδικά στον τομέα των μεμονωμένων επενδυτών.

Η προσομοίωση επικεντρώνεται στη στρατηγική διαχείριση του διαθέσιμου κεφαλαίου των Home Traders και τη λήψη αποφάσεων συναλλαγών με βάση στατιστικούς δείκτες, καθώς και συγκεκριμένες συνθήκες της αγοράς.

Υπολογισμός Πιθανοτήτων Αγοράς και Πώλησης

Ο υπολογισμός των πιθανοτήτων αγοράς (P_{buy}) και πώλησης (P_{sell}) βασίζεται σε δυναμική προσαρμογή που επηρεάζεται από το σήμα MACD ($MACD_{signal}$). Η βασική ιδέα είναι ότι οι πιθανότητες αυτές εξελίσσονται με την πάροδο του χρόνου, καθώς λαμβάνονται υπόψη τόσο η τρέχουσα δυναμική της αγοράς όσο και οι προηγούμενες εκτιμήσεις των πιθανοτήτων.

Ο τύπος προσαρμογής των πιθανοτήτων περιλαμβάνει έναν συντελεστή γ που καθορίζει το πόσο γρήγορα προσαρμόζονται οι πιθανότητες στις αλλαγές του σήματος MACD. Η διαφορά μεταξύ του τρέχοντος σήματος MACD και των προηγούμενων πιθανοτήτων $P_{buy}(t-1)$ ή $P_{sell}(t-1)$ οδηγεί στη διαμόρφωση των νέων πιθανοτήτων.

Για να διασφαλιστεί ότι οι πιθανότητες P_{buy} και P_{sell} παραμένουν εντός λογικών ορίων, πραγματοποιείται κανονικοποίηση ώστε το άθροισμά τους να ισούται με τη μονάδα. Αυτή η διαδικασία κανονικοποίησης επιτρέπει τη διατήρηση της συνοχής στη λήψη αποφάσεων, εξασφαλίζοντας ότι οι πιθανότητες είναι πάντα σχετικές μεταξύ τους. Οι μαθηματικοί τύποι είναι:

$$P_{buy}(t) = P_{buy}(t-1) + \gamma \cdot (MACD_{signal}(t) - P_{buy}(t-1))$$

$$P_{sell}(t) = P_{sell}(t-1) + \gamma \cdot (-MACD_{signal}(t) - P_{sell}(t-1))$$

Όπου:

$$MACD_{signal}(t) = MACD(t) - MACD_{signal}(t)$$

Οι πιθανότητες κανονικοποιούνται ώστε το άθροισμά τους να είναι ίσο με 1:

$$P_{buy}(t) = \frac{P_{buy}(t)}{P_{buy}(t) + P_{sell}(t)} \quad \text{και} \quad P_{sell}(t) = \frac{P_{sell}(t)}{P_{buy}(t) + P_{sell}(t)}$$

Υπολογισμός Απόφασης Συναλλαγών

Η απόφαση για αγορά ή πώληση βασίζεται στις πιθανότητες $P_{buy}(t)$ και $P_{sell}(t)$, οι οποίες εκφράζουν τη δυναμική της αγοράς.

Η αγορά πραγματοποιείται όταν $P_{buy}(t) > P_{sell}(t)$ και υπάρχει διαθέσιμο κεφάλαιο $C_{usd}(t) > 0$. Το ποσοστό της συναλλαγής καθορίζεται από την παρακάτω σχέση:

$$\theta_{buy}(t) = \min\left(0.1 \cdot P_{buy}(t), \frac{C_{usd}(t)}{S(t)}\right)$$

όπου $S(t)$ η τιμή του περιουσιακού στοιχείου τη χρονική στιγμή t . Η ποσότητα που αγοράζεται εκφράζεται ως:

$$q_{buy}(t) = \frac{C_{usd}^{spent}(t) \cdot (1 - f_{buy})}{S(t)}$$

όπου f_{buy} το ποσό τέλους συναλλαγής αγοράς.

Αντίστοιχα, η αγορά πραγματοποιείται όταν $P_{sell}(t) > P_{buy}(t)$ και υπάρχει διαθέσιμο απόθεμα $q_{btc}(t) > 0$. Το ποσοστό της συναλλαγής καθορίζεται από την παρακάτω σχέση:

$$\theta_{sell}(t) = \min(0.1 \cdot P_{sell}(t), q_{btc}(t))$$

Το ποσό που πωλείται είναι $q_{sell}(t) = \theta_{sell}(t) \cdot q_{btc}(t)$ και η χρηματική απόδοση από την πώληση υπολογίζεται ως:

$$C_{usd}^{gained}(t) = q_{sell}(t) \cdot S(t) \cdot (1 - f_{sell})$$

5.3.1.3 Προσομοίωση Έμπειρων Traders

Οι έμπειροι έμποροι διακρίνονται για την ικανότητά τους να λαμβάνουν αποφάσεις βάσει σύνθετων διαδικασιών που περιλαμβάνουν πολλαπλές παραμέτρους. Τα Decision Trees προσφέρουν ένα ισχυρό εργαλείο για τη μοντελοποίηση των στρατηγικών τους, καθώς επιτρέπουν την ανάλυση πολυδιάστατων σεναρίων. Αυτά τα δέντρα παρέχουν τη δυνατότητα χαρτογράφησης των πιθανών επιλογών και της αξιολόγησης της πιθανότητας επιτυχίας κάθε στρατηγικής κίνησης. Μέσω αυτής της προσέγγισης, οι έμπειροι traders μπορούν να αναπτύξουν προσαρμοσμένα μοντέλα που αντανακλούν την πολυπλοκότητα της στρατηγικής τους σκέψης.

Συντηρητικοί Traders

Οι συντηρητικοί traders δίνουν προτεραιότητα στη διατήρηση του κεφαλαίου τους και στην αποφυγή μεγάλων απωλειών, εφαρμόζοντας στρατηγικές που ελαχιστοποιούν το ρίσκο. Η συνάρτηση κόστους για τη στρατηγική τους μοντελοποιείται ως εξής:

$$C = \sum_{t \in Leaves} P_t \cdot H_t \cdot \lambda$$

Όπου P_t είναι η πιθανότητα να φτάσουμε στο φύλλο t . H_t η εντροπία στο φύλλο t , η οποία μετρά την αβεβαιότητα των αποφάσεων. Χαμηλότερη εντροπία συνεπάγεται πιο προβλέψιμες και ασφαλείς αποφάσεις. λ είναι μια παράμετρος που αυξάνει το κόστος για κινήσεις υψηλού κινδύνου, αποθαρρύνοντας τέτοιες αποφάσεις.

Η ελαχιστοποίηση ρίσκου προκύπτει από τη σχέση $Risk = \frac{\sigma}{R}$ όπου R η αναμενόμενη απόδοση. Αυτή η προσέγγιση εξασφαλίζει ότι οι συντηρητικοί traders εστιάζουν στη μείωση της μεταβλητότητας και στην επίτευξη πιο σταθερών αποδόσεων.

Traders φιλικό προς το ρίσκο

Οι traders φιλικό προς το ρίσκο επικεντρώνονται στη μεγιστοποίηση των αποδόσεων, αναλαμβάνοντας υψηλότερο ρίσκο για πιθανότητα μεγαλύτερων κερδών. Η στρατηγική τους περιγράφεται μέσω της συνάρτησης κέρδους:

$$Profit = \sum_{t \in Leaves} P_t \cdot (Return_t - \lambda \cdot \sigma_t)$$

Όπου P_t η πιθανότητα να φτάσουμε στο φύλλο t και $Return_t$ η αναμενόμενη απόδοση στο φύλλο t, σ_t είναι η τυπική απόκλιση, που μετρά τον κίνδυνο και λ είναι μια παράμετρος που ρυθμίζει την ισορροπία μεταξύ απόδοσης και κινδύνου. Όσο μεγαλύτερη είναι η τιμή του λ , τόσο μεγαλύτερη είναι η ποινή για τον κίνδυνο.

Για τη σύγκριση της απόδοσης με τον κίνδυνο που λαμβάνεται θα κάνουμε χρήση τον λόγο Sharpe, ο οποίος προκύπτει από τον τύπο:

$$S = \frac{R_p - R_f}{\sigma_p}$$

Όπου R_p η μέση απόδοση, R_f το επιτόκιο χωρίς κίνδυνο (Risk-free) και σ_p η μεταβλητότητα. Ένας υψηλός λόγος Sharpe υποδηλώνει ότι οι traders αυτοί επιτυγχάνουν υψηλές αποδόσεις σε σχέση με τον αναλαμβανόμενο κίνδυνο.

5.3.2 Σύγκριση Ανθρώπινων Στρατηγικών

Αρχικά, ορίστηκαν τρία κύρια κριτήρια αξιολόγησης: απόδοση (μέσω μετρικών όπως το αθροιστικό κέρδος και το Sharpe Ratio), ρευστότητα (αριθμός συναλλαγών και ποσοστό διακινηθέντος κεφαλαίου ανά συναλλαγή) και ευελιξία (προσαρμογή σε διαφορετικές συνθήκες αγοράς). Οι στρατηγικές εξετάστηκαν σε τρία ευρύτερα σενάρια αγοράς: ιστορικά

δεδομένα με σταθερή τάση (π.χ., bull markets), δεδομένα με έντονη μεταβλητότητα (π.χ., οικονομικές κρίσεις) και τυχαία δειγματοληψία χρονικών περιόδων για την αποφυγή υπερπροσαρμογής. Για να διασφαλιστεί η συγκρισιμότητα, όλες οι προσομοιώσεις υπόκεινταν σε κοινές παραμέτρους: αρχικό κεφάλαιο \$10,000, fees συναλλαγών 0.25% (maker) και 0.40% (taker), και χρονικό παράθυρο 5 ετών (2018–2023).

Η διαδικασία επικύρωσης περιλάμβανε ανάλυση ευαισθησίας για τη διερεύνηση της επίδρασης διαφορετικών fees ($\pm 50\%$) και αρχικών κεφαλαίων ($\pm 50\%$), καθώς και στατιστικούς ελέγχους (t-test) για την εκτίμηση της σημαντικότητας των διαφορών στην απόδοση. Επιπλέον, πραγματοποιήθηκαν Monte Carlo προσομοιώσεις (1,000 επαναλήψεις) για να εκτιμηθεί η σταθερότητα κάθε στρατηγικής έναντι τυχαίων διακυμάνσεων της αγοράς.

Για τη διαισθητική παρουσίαση των αποτελεσμάτων, χρησιμοποιήθηκαν ειδικά σχεδιασμένα εργαλεία οπτικοποίησης: heatmaps για την απεικόνιση της απόδοσης ανά σενάριο, γραφήματα drawdown για την ποσοτικοποίηση του μέγιστου κινδύνου και radar plots για τη σύνθετη σύγκριση των κριτηρίων (απόδοση, ρευστότητα, ευελιξία). Αυτή η ολοκληρωμένη προσέγγιση επέτρεψε τη χαρτογράφηση τόσο της σχετικής αποτελεσματικότητας όσο και των περιορισμών κάθε στρατηγικής, χωρίς να επηρεαστεί από εκ των προτέρων υποθέσεις ή επιλεκτικές ερμηνείες.

5.3.3 Σύγκριση Στρατηγικών TN

Η σύγκριση των μοντέλων τεχνητής νοημοσύνης (TN) υλοποιήθηκε μέσω μιας πολυδιάστατης προσέγγισης που περιλάμβανε διαχωρισμό δεδομένων, διαδικασίες επικύρωσης και σενάρια αξιολόγησης. Ο διαχωρισμός των δεδομένων έγινε σε 70% για εκπαίδευση, 15% για επικύρωση και 15% για δοκιμή, εξασφαλίζοντας ότι επαρκή δεδομένα χρησιμοποιούνται για τη βελτιστοποίηση και την τελική αξιολόγηση των μοντέλων. Η επικύρωση πραγματοποιήθηκε με τη μέθοδο TimeSeriesSplit (5 folds), ώστε να διατηρηθεί η χρονική ακολουθία και να αποφεύγεται η διαρροή δεδομένων από το μέλλον στο παρελθόν.

Για την αποφυγή υπεροπροσαρμογής στην εκπαίδευση, εφαρμόστηκαν συγκεκριμένες τεχνικές. Αυτές περιλάμβαναν κανονικοποίηση L2 Regularization, χρήση Dropout με τιμές 0.3 έως 0.4, καθώς και Early Stopping με patience δέκα εποχών. Επιπλέον, ενεργοποιήθηκε το ReduceLROnPlateau, το οποίο μείωνε τον ρυθμό μάθησης κατά συντελεστή 0.5 μετά από τρεις

συνεχόμενες αποτυχημένες βελτιώσεις της απόδοσης στο σετ επικύρωσης. Αυτές οι τεχνικές συνέβαλαν στη σταθερότητα και στη βελτίωση της γενίκευσης των μοντέλων.

Η ανάλυση ευαισθησίας ήταν βασικό στοιχείο της αξιολόγησης, με την προσθήκη Gaussian Noise στα δεδομένα εισόδου. Ο θόρυβος είχε μέση τιμή $\mu = 0$ και τυπική απόκλιση $\sigma = 0.05$ έως 0.2 , ιδίως στις υλοποιήσεις των μοντέλων MLP και Perceptron. Αυτή η προσέγγιση παρείχε ένα μέτρο της ανθεκτικότητας των μοντέλων σε θορυβώδη δεδομένα και ακραίες τιμές.

Τα μοντέλα αξιολογήθηκαν σε τρία διαφορετικά σενάρια. Το πρώτο περιλάμβανε ιστορικά δεδομένα με σταθερές τάσεις, όπως bull και bear markets. Το δεύτερο σενάριο εστίαζε σε δεδομένα υψηλής μεταβλητότητας, όπως σε περιόδους μακροοικονομικών κρίσεων. Το τρίτο σενάριο περιλάμβανε τυχαία χρονικά παράθυρα (random rolling windows) για να αποφευχθεί η υπερπροσαρμογή και το bias από περιορισμένα χρονικά σύνολα.

5.3.4 Εφαρμογή Στρατηγικών TN και Σύγκριση με Ανθρώπινες Στρατηγικές

Η ενσωμάτωση της τεχνητής νοημοσύνης στις χρηματοοικονομικές στρατηγικές έχει φέρει επανάσταση στον τρόπο που προσεγγίζονται οι αγορές. Μέσα από τη χρήση υπολογιστικών μοντέλων, η TN είναι σε θέση να επεξεργάζεται τεράστιες ποσότητες δεδομένων, να εντοπίζει μοτίβα και να διαμορφώνει στρατηγικές με υψηλή ακρίβεια. Η παρούσα ενότητα επικεντρώνεται στη διαδικασία ανάπτυξης τέτοιων στρατηγικών, που περιλαμβάνει την εκπαίδευση μοντέλων με ιστορικά δεδομένα και τη δοκιμή τους σε πραγματικές συνθήκες αγοράς. Παράλληλα, εξετάζεται η σύγκριση των στρατηγικών TN με αυτές των ανθρώπων, με έμφαση στην απόδοση, την ανθεκτικότητα σε απρόβλεπτες καταστάσεις και την ικανότητα προσαρμογής.

Τα αποτελέσματα αυτής της σύγκρισης αποκαλύπτουν σημαντικά πλεονεκτήματα των στρατηγικών TN, όπως η ταχύτητα και η ακρίβεια στη λήψη αποφάσεων. Ωστόσο, καταδεικνύονται επίσης οι περιορισμοί τους, ιδίως σε περιπτώσεις που απαιτούν βαθιά κατανόηση του ανθρώπινου ψυχολογικού παράγοντα ή της αβεβαιότητας. Τέτοιες συγκρίσεις αναδεικνύουν τις περιοχές όπου οι ανθρώπινες στρατηγικές παραμένουν ανώτερες, δημιουργώντας μια ισορροπία μεταξύ της τεχνολογίας και της ανθρώπινης εμπειρίας.

6 – Παρουσίαση Αποτελεσμάτων

6.1 Ανάλυση Αποτελεσμάτων των Μοντέλων TN

6.1.1 Αποτελέσματα του LGBMClassifier


Η αξιολόγηση του μοντέλου LGBMClassifier, έδειξε τη δυνατότητα του να προβλέπει και να λαμβάνει αποφάσεις σε περιβάλλοντα υψηλής αβεβαιότητας, βασιζόμενο σε ιστορικά δεδομένα και ενσωματώνοντας στρατηγικές διαχείρισης ρίσκου. Τα αποτελέσματα της αξιολόγησης ήταν ιδιαίτερα ενθαρρυντικά, καθώς ανέδειξαν τη δυνατότητα του μοντέλου να επιτυγχάνει ισχυρή ακρίβεια πρόβλεψης και να διαχειρίζεται αποτελεσματικά το ρίσκο, στοιχείο κρίσιμο για πρακτικές εφαρμογές.

Η ακρίβεια πρόβλεψης του μοντέλου κατά τη διαδικασία διασταυρούμενης επικύρωσης (**cross-validation**) ανήλθε σε περίπου **75%**, αποδεικνύοντας την ικανότητά του να ανιχνεύει μοτίβα μέσα από τα δεδομένα. Η επιτυχία αυτή βασίστηκε στη χρήση μιας προσαρμοσμένης συνάρτησης απώλειας, που ενσωματώνει στοιχεία κερδοφορίας και ασύμμετρης απώλειας, καθώς και στη βελτιστοποίηση παραμέτρων μέσω γενετικού αλγορίθμου. Οι βέλτιστες τιμές που προέκυψαν από τη διαδικασία αυτή περιλαμβάνουν, μεταξύ άλλων, **learning rate 0.299**, **num leaves 195** και **max depth 14**. Η συγκεκριμένη παραμετροποίηση διασφάλισε τη μέγιστη δυνατή απόδοση του μοντέλου σε δεδομένα με υψηλή πολυπλοκότητα.

Το μοντέλο υιοθέτησε επίσης προηγμένους μηχανισμούς διαχείρισης ρίσκου, όπως το stop-loss και το take-profit, που αποδείχθηκαν ιδιαίτερα αποδοτικοί. Συγκεκριμένα, **το stop-loss ενεργοποιήθηκε στο 97%** των συναλλαγών, ενώ **το take-profit στο 105%** της τιμής εισόδου. Αυτές οι στρατηγικές εφαρμόστηκαν σε συνολικά **110** συναλλαγές, από τις οποίες **42** αφορούσαν αγορές (buy) και **68** αφορούσαν θέσεις short. Οι μηχανισμοί αυτοί ενεργοποιήθηκαν συνολικά **90** και **19** φορές αντίστοιχα, προστατεύοντας την επένδυση από μεγάλες ζημιές και διασφαλίζοντας τη σταθερή κερδοφορία.

Το παρακάτω διάγραμμα αποτυπώνει τη δράση του μοντέλου κατά τη διάρκεια των συναλλαγών. Η γραμμή που απεικονίζει την τιμή του περιουσιακού στοιχείου αποκαλύπτει τις διακυμάνσεις της αγοράς, ενώ τα σήματα αγοράς και πώλησης σημειώνονται με πράσινα και

κόκκινα τρίγωνα αντίστοιχα. Οι εντολές short/close short υποδεικνύονται με μωβ σταυρούς. Η παρατήρηση του διαγράμματος καθιστά σαφή την ικανότητα του μοντέλου να ανταποκρίνεται στις μεταβολές της αγοράς και να λαμβάνει αποτελεσματικές αποφάσεις.



Διάγραμμα 31 - Ενέργειες μοντέλου LGBMClassifier

Η οικονομική απόδοση του μοντέλου αποδεικνύεται από το **τελικό υπόλοιπο των \$10,563.49**, το οποίο αντιπροσωπεύει ένα **συνολικό κέρδος της τάξης του 5.63%**. Το αποτέλεσμα αυτό είναι ιδιαίτερα σημαντικό, καθώς καταδεικνύει τη δυνατότητα του μοντέλου να λειτουργεί αποδοτικά σε πραγματικά οικονομικά περιβάλλοντα, παρέχοντας αξιόπιστες προτάσεις για συναλλαγές.

Τα αποτελέσματα⁷ αυτά αναδεικνύουν τη χρησιμότητα του LGBMClassifier σε σύνθετες προβλέψεις και στρατηγικές συναλλαγών. Παρά τη συνολική θετική του απόδοση, υπάρχουν περιθώρια βελτίωσης, όπως η περαιτέρω μείωση της πιθανότητας παγίδευσης σε τοπικά ελάχιστα. Μελλοντική έρευνα θα μπορούσε να επικεντρωθεί στη χρήση εναλλακτικών συναρτήσεων απώλειας και στη δοκιμή του μοντέλου σε διαφορετικά σύνολα δεδομένων για την περαιτέρω ενίσχυση της γενίκευσής του.

⁷ Αναλυτικά δεδομένα και κώδικας είναι διαθέσιμα στον σύνδεσμο: <https://url.kosmidis.me/nup-msc-sklearn>

6.1.2 Αποτελέσματα του Perceptron

Η αξιολόγησή⁸ του Single Perceptron σε δεδομένα συναλλαγών Bitcoin ανέδειξε ευρήματα που αφορούν τόσο στην ακρίβεια όσο και στη συμπεριφορά του μοντέλου κατά τις συναλλαγές. Συγκεκριμένα, η **τελική ακρίβεια στο test set ανήλθε στο 62.10%**, ενώ κατά τη διάρκεια των 10 εποχών εκπαίδευσης, η ακρίβεια επικύρωσης παρουσίασε μια σταθερή ανοδική τάση από 53% έως **67%**. Αυτή η πρόοδος δείχνει ότι το μοντέλο σταδιακά αποκτά την ικανότητα να γενικεύει, ενώ η περιορισμένη διαφορά μεταξύ εκπαίδευσης και επικύρωσης υποδηλώνει την απουσία έντονου overfitting.




Διάγραμμα 32 - Ακρίβεια εκπαίδευσης και επικύρωσης ανά εποχή για το Single Perceptron μοντέλο

Το παραπάνω διάγραμμα που απεικονίζει την ακρίβεια εκπαίδευσης και επικύρωσης ενισχύει αυτή την παρατήρηση, καθώς η σταδιακή σύγκλιση των δύο γραμμών δείχνει ότι το μοντέλο καταφέρνει να μάθει μοτίβα από τα δεδομένα χωρίς υπερβολική προσαρμογή στις λεπτομέρειες τους. Παρόλα αυτά, η απουσία περισσότερων επιπέδων και η βασική αρχιτεκτονική του Perceptron περιορίζουν την ικανότητα ανίχνευσης πιο πολύπλοκων μοτίβων.

⁸ Αναλυτικά δεδομένα και κώδικας είναι διαθέσιμα στον σύνδεσμο: <https://url.kosmidis.me/nup-msc-perceptron>

Στην εφαρμογή του στο trading, το μοντέλο κατέγραψε **συνολικό κέρδος 4.10%**, με την τελική αξία του χαρτοφυλακίου να φτάνει τα **10,409.80 USD** από αρχική επένδυση 10,000 USD. Αν και αυτό αποτελεί θετικό αποτέλεσμα, το κέρδος παραμένει χαμηλό, γεγονός που σχετίζεται με τη στρατηγική περιορισμού του εμπορίου (μέγιστο ποσοστό εμπορίου 15%) και την ευαισθησία στα τέλη συναλλαγών. **Συνολικά πραγματοποιήθηκαν 36 συναλλαγές (12 αγορές, 24 πωλήσεις)**, με τις πωλήσεις να συμπίπτουν σε μεγάλο βαθμό με περιόδους καθοδικών τάσεων, ενώ οι αγορές εμφανίστηκαν σε περιόδους ανάκαμψης.

Το παρακάτω διάγραμμα αποτυπώνει οπτικά τη σχέση των ενεργειών του μοντέλου με τις τιμές Bitcoin. Οι πωλήσεις τείνουν να επικεντρώνονται σε τοπικά μέγιστα, ενώ οι αγορές σε σημεία ανόδου. Παρόλο που αυτές οι ενέργειες δείχνουν μια βασική ικανότητα πρόβλεψης βραχυπρόθεσμων τάσεων, η γενικότερη στρατηγική χαρακτηρίζεται από συντηρητική προσέγγιση. Η ανάγκη για περισσότερες αποφάσεις συναλλαγών σε υψηλότερη συχνότητα αποτελεί ένα σημείο βελτίωσης.



Διάγραμμα 33 - Ενέργειες Single Perceptron μοντέλου

Η ανάλυση χαρακτηριστικών ανέδειξε τον λόγο μεταβολής τιμής (**price_change_ratio**) ως το πλέον σημαντικό χαρακτηριστικό, με συνεισφορά **94.14%**. Οι τεχνικοί δείκτες, όπως MACD και ATR, παρουσίασαν ελάχιστη επίδραση, κάτι που δείχνει ότι οι βραχυπρόθεσμες δυναμικές κυριαρχούν στις αποφάσεις του μοντέλου. Το εύρημα αυτό κατευθύνει τη

μελλοντική βελτιστοποίηση στην αφαίρεση περιττών χαρακτηριστικών και στην ενσωμάτωση πιο σύνθετων μετρικών για καλύτερη απόδοση.

Η αξιολόγηση ανθεκτικότητας του μοντέλου έδειξε **πτώση της ακρίβειας στο 57.06%** όταν προστέθηκε 1% θόρυβος στα δεδομένα εισόδου. Αυτή η μείωση υπογραμμίζει την ευαισθησία του Perceptron σε θόρυβο και αναδεικνύει την ανάγκη ενίσχυσης της ανθεκτικότητάς του.

Παρατηρείται επομένως ότι το Single Perceptron μοντέλο επιτυγχάνει μέτρια αλλά σταθερή απόδοση, με θετικά στοιχεία, όπως η απουσία overfitting και η σταθερή σύγκλιση της ακρίβειας εκπαίδευσης και επικύρωσης. Ωστόσο, η χαμηλή πολυπλοκότητα της αρχιτεκτονικής του, σε συνδυασμό με την περιορισμένη ευαισθησία σε μη γραμμικά μοτίβα, περιορίζει τις προοπτικές περαιτέρω βελτίωσης. Η ενσωμάτωση πιο σύνθετων τεχνικών, όπως deep learning αρχιτεκτονικές, attention mechanisms ή reinforcement learning στρατηγικές, θα μπορούσε να αυξήσει την αποτελεσματικότητα του μοντέλου σε πραγματικά trading σενάρια.

6.1.3 Αποτελέσματα του Multilayered Perceptron


Τα αποτελέσματα⁹ της ανάλυσης και της δοκιμής του πολυεπίπεδου νευρωνικού δικτύου (MLP) για τη στρατηγική συναλλαγών στην αγορά κρυπτονομισμάτων παρουσιάζουν ενδιαφέροντα στοιχεία για την ακρίβεια και την οικονομική απόδοση του μοντέλου.

Η εκπαίδευση του μοντέλου επιβεβαιώνει τη **δυναμική** του στην ανάλυση χρονοσειρών, με **μέση ακρίβεια επικύρωσης 82.51%** και **μέσο loss 0.6154**. Ωστόσο, παρατηρούνται σημαντικές διακυμάνσεις ανάμεσα στα folds, με την ακρίβεια να κυμαίνεται από 58.6% έως 93.15%. Αυτή η ευαισθησία αναδεικνύει την πρόκληση της γενίκευσης σε χρονοσειρές με μεταβαλλόμενα χαρακτηριστικά. Παρόλο που εφαρμόστηκαν τεχνικές κανονικοποίησης όπως Gaussian θόρυβος, Batch Normalization, και L2 regularization, η διαφορά μεταξύ της εκπαίδευσης (~65%) και της επικύρωσης υποδεικνύει πιθανή υπερβολική εξάρτηση του μοντέλου από το training set.

⁹ Αναλυτικά δεδομένα και κώδικας είναι διαθέσιμα στον σύνδεσμο: <https://url.kosmidis.me/nup-msc-mlp>




Διάγραμμα 34 - Ακρίβεια εκπαίδευσης και επικύρωσης ανά εποχή για το MLP



Διάγραμμα 35 - Απώλεια εκπαίδευσης και επικύρωσης ανά εποχή για το MLP

Στο test set, η **ακρίβεια ήταν 74.81%**, χαμηλότερη από τη μέση επικύρωση, ενισχύοντας την υπόθεση ότι το μοντέλο δυσκολεύεται να γενικεύσει σε δεδομένα που δεν έχει δει. Το confusion matrix ανέδειξε ασυμμετρίες στις προβλέψεις, με την κλάση 1 (αγορά) να επιτυγχάνει **precision 91%**, ενώ η κλάση 0 (πώληση) περιορίστηκε σε **67%**, επιβεβαιώνοντας την τάση του μοντέλου να υπερπροβλέπει αγορές.

Η οικονομική ανάλυση έδειξε ένα **συνολικό κέρδος 9.80%**, που υπολογίστηκε μετά από 408 συναλλαγές (135 αγορές, 273 πωλήσεις). Το Sharpe Ratio (-71.00) είναι εξαιρετικά αρνητικό, υποδηλώνοντας ότι η απόδοση συνοδεύεται από υψηλό ρίσκο, ενώ τα fees συναλλαγών επηρεάζουν σημαντικά το καθαρό κέρδος. Για παράδειγμα, με χαμηλότερα fees (0.15% αγορά, 0.30% πώληση), το κέρδος φτάνει το **11.02%**, ενώ με υψηλότερα fees μειώνεται στο **6.22%**.



Διάγραμμα 36 - Ενέργειες MLP

Η χρήση φίλτρου εξομάλυνσης (uniform_filter1d) βελτίωσε τη σταθερότητα στις προβλέψεις, αλλά οι συχνές εναλλαγές αγορών/πωλήσεων (ειδικά κοντά σε τοπικά ακρότατα) ενίσχυσαν τα transaction costs. Τα διαγράμματα "Prices with Buy/Sell Actions" και "Training and Validation Accuracy/Loss Over Epochs" αναδεικνύουν τον θόρυβο στις αποφάσεις του μοντέλου και τις αναταράξεις κατά την εκπαίδευση, με την επικύρωση να παρουσιάζει αιφνίδιες διακυμάνσεις, ενδεχομένως λόγω χρονικών ανωμαλιών στη δομή δεδομένων.

Το μοντέλο παρουσιάζει **ελπιδοφόρα αποτελέσματα** στη διαχείριση συναλλαγών, ειδικά στις σύντομες διακυμάνσεις τιμών, αλλά απαιτείται περαιτέρω βελτίωση. Η ενσωμάτωση πιο εξελιγμένων μοντέλων όπως LSTM ή GRU μπορεί να συμβάλει στην κατανόηση των μακροπρόθεσμων τάσεων, ενώ η βελτιστοποίηση της στρατηγικής συναλλαγών και η μείωση του κινδύνου μπορούν να βελτιώσουν τις αποδόσεις και τη βιωσιμότητα της μεθόδου.


6.1.4 Αποτελέσματα του Convolutional Neural Networks (CNN)

Το μοντέλο εκπαιδεύτηκε και αξιολογήθηκε σε δύο διαφορετικές φάσεις: μία **σύντομη προκαταρκτική εκπαίδευση διάρκειας περίπου 20 λεπτών** και μία πιο **εκτεταμένη διαδικασία διάρκειας σχεδόν 20 ωρών**. Τα αποτελέσματα¹⁰ καταδεικνύουν σημαντικές διαφοροποιήσεις στην ακρίβεια, αλλά και στις πρακτικές εφαρμογές της προσέγγισης.


Η επιλογή των χαρακτηριστικών βασίστηκε σε ανάλυση συσχέτισης και σε αλγορίθμους επιλογής χαρακτηριστικών, όπως ο **RandomForestClassifier**. Από τα αρχικά 24 χαρακτηριστικά, διατηρήθηκαν 11, τα οποία θεωρήθηκαν πιο αντιπροσωπευτικά για την πρόβλεψη των τιμών. Στη συνέχεια, τα δεδομένα επεξεργάστηκαν με τεχνικές όπως η πλήρωση ελλিপών τιμών με τη μέση τιμή και η κλιμάκωση με **RobustScaler** για την εξομάλυνση των διαφορών στην κατανομή των τιμών. Οι τεχνικοί δείκτες που επιλέχθηκαν, όπως το **MACD_Signal** και το **QStick**, ενίσχυσαν την ικανότητα του μοντέλου να ανιχνεύει μοτίβα στις χρονοσειρές.

Το μοντέλο σχεδιάστηκε ως ένας **συνδυασμός CNN και LSTM**, με τα CNN να αναλαμβάνουν την εξαγωγή τοπικών χρονικών χαρακτηριστικών μέσω **Conv1D** φίλτρων και τα LSTM να αναγνωρίζουν μοτίβα και μακροχρόνιες εξαρτήσεις στις χρονοσειρές. Τα τελικά επίπεδα του μοντέλου περιλάμβαναν πυκνά στρώματα, τα οποία παρήγαγαν την τελική πρόβλεψη μέσω sigmoid εξόδου. Η εκπαίδευση πραγματοποιήθηκε με πέντε υποσύνολα TimeSeriesSplit και τη χρήση σταθμίσεων (class weights) για να αντισταθμιστεί η ανισορροπία δεδομένων. Ο βελτιστοποιητής **AdamW** με χαμηλό ρυθμό μάθησης 0.0001 επέτρεψε σταθερή και αποτελεσματική σύγκλιση του μοντέλου. Επιπλέον, η συνάρτηση απώλειας προσαρμόστηκε ώστε να λαμβάνει υπόψη τη δυσαναλογία μεταξύ long και short συναλλαγών, το κέρδος και την ποινή για υπερβολική βεβαιότητα στις προβλέψεις.

¹⁰ Αναλυτικά δεδομένα και κώδικας είναι διαθέσιμα στους συνδέσμους: <https://url.kosmidis.me/nup-msc-cnn> και <https://url.kosmidis.me/nup-msc-cnn-undertrained>



Διάγραμμα 37 - Ακρίβεια εκπαίδευσης και επικύρωσης ανά εποχές για υποεκπαιδευμένο CNN



Διάγραμμα 38 - Ακρίβεια εκπαίδευσης και επικύρωσης ανά εποχές για το CNN

Στην πρώτη φάση, η προκαταρκτική εκπαίδευση διήρκεσε περίπου 20 λεπτά και διακόπηκε πρόωρα. Τα αποτελέσματα έδειξαν περιορισμένη ακρίβεια, με μέση απόδοση επικύρωσης που δεν καταγράφηκε (NaN), ενώ στο test set η **ακρίβεια ανήλθε στο 66%**. Η οικονομική προσομοίωση **ανέδειξε απώλειες της τάξεως του -0.89%**, παράγοντας **228 συναλλαγές**. Σημαντικό είναι ότι **207 από αυτές τις συναλλαγές ενεργοποίησαν stop-loss**, γεγονός που αποδεικνύει την αναποτελεσματικότητα της στρατηγικής σε αυτή τη φάση.




Διάγραμμα 39 - Ενέργειες υποεκπαιδευμένου CNN

Αντίθετα, η πλήρης εκπαίδευση, η οποία διήρκεσε περίπου 20 ώρες, παρουσίασε σαφή βελτίωση στην ακρίβεια του μοντέλου. Η μέση ακρίβεια επικύρωσης έφτασε το **87.77%**, ενώ η ακρίβεια στο test set ανήλθε στο **82%**. Παρ' όλα αυτά, η οικονομική απόδοση ήταν απογοητευτική. Το χαρτοφυλάκιο υπέστη **απώλειες της τάξεως του -84.28%**, παρότι **εκτελέστηκαν 3,109 συναλλαγές**. Το αποτέλεσμα αυτό αποδίδεται κυρίως στην υπερβολική εξάρτηση από short συναλλαγές και στην ενεργοποίηση stop-loss, γεγονός που υποδεικνύει υπερπροσαρμογή του μοντέλου σε θορυβώδη δεδομένα.



Διάγραμμα 40 - Ενέργειες CNN



Διάγραμμα 41 - Πορεία χαρτοφυλακίου CNN

Το πρώτο διάγραμμα, το οποίο παρουσιάζει την κίνηση της τιμής και τα σήματα συναλλαγών, αποκαλύπτει υπερβολική συχνότητα συναλλαγών, γεγονός που αντικατοπτρίζει την ανάγκη για πιο αυστηρά thresholds. Το δεύτερο διάγραμμα, που απεικονίζει την εξέλιξη της αξίας του χαρτοφυλακίου, δείχνει μια σταθερή πτώση, με απότομες μειώσεις κατά τη διάρκεια της δεύτερης φάσης εκπαίδευσης, υποδηλώνοντας την αποτυχία του μοντέλου να διαχειριστεί ανατρεπτικά γεγονότα στην αγορά.


Το μοντέλο CNN-LSTM παρουσίασε **εξαιρετική ακρίβεια από θεωρητικής σκοπιάς**, με μέγιστη ακρίβεια 87.77% κατά την επικύρωση. Ωστόσο, τα αποτελέσματα στο trading περιβάλλον ήταν προβληματικά, υποδεικνύοντας **ασυμφωνία μεταξύ θεωρητικής ακρίβειας και πρακτικής εφαρμογής**. Για τη βελτίωση της απόδοσης του μοντέλου, απαιτούνται μέτρα όπως η βελτιστοποίηση thresholds, η ενσωμάτωση περισσότερων χαρακτηριστικών και η χρήση reinforcement learning, το οποίο μπορεί να επικεντρωθεί άμεσα στη μεγιστοποίηση κερδών.

6.1.5 Αποτελέσματα του Recurrent Neural Network (RNN)

Η ανάλυση¹¹ επικεντρώνεται στην αξιολόγηση της απόδοσης ενός επαναλαμβανόμενου νευρωνικού δικτύου (RNN) με **διπλής κατεύθυνσης LSTM αρχιτεκτονική** για την πρόβλεψη της κατεύθυνσης χρηματιστηριακών τιμών. Το μοντέλο αξιολογήθηκε σε δύο φάσεις: τη σύντομη εκπαίδευση διάρκειας περίπου **20 λεπτών** και την πλήρη εκπαίδευση διάρκειας **σχεδόν 20 ωρών**. Τα αποτελέσματα που προέκυψαν αναδεικνύουν τη **σημασία της διάρκειας και ποιότητας εκπαίδευσης** για την αποτελεσματικότητα ενός τέτοιου μοντέλου, ιδιαίτερα σε εφαρμογές με οικονομικό ενδιαφέρον.

Το RNN μοντέλο σχεδιάστηκε ώστε να περιλαμβάνει δύο επίπεδα LSTM (**64 και 32 νευρώνες** αντίστοιχα), ενισχυμένα με **dropout (0.4 και 0.35)** και **batch normalization** για καλύτερη σταθερότητα κατά την εκπαίδευση. Επιπλέον, προστέθηκε **Gaussian Noise (0.02)** για την καταπολέμηση του θορύβου στα δεδομένα. Το σύνολο δεδομένων που χρησιμοποιήθηκε περιείχε περίπου **2 εκατομμύρια δείγματα**, κανονικοποιημένα μέσω **RobustScaler**. Ο βελτιστοποιητής **AdamW** με ρυθμό μάθησης **0.0001** και **L2 κανονικοποίηση (0.01)** εξασφάλισε τη **σταθερή βελτίωση του μοντέλου** κατά τη διάρκεια της εκπαίδευσης. Η συνάρτηση απώλειας προσαρμόστηκε ειδικά για να περιλαμβάνει **οικονομικά κίνητρα** και **ποινές εμπιστοσύνης**, παρέχοντας έτσι έναν μηχανισμό προσαρμογής για την ιδιαιτερότητα των οικονομικών προβλέψεων.

¹¹ Αναλυτικά δεδομένα και κώδικας είναι διαθέσιμα στους συνδέσμους: <https://url.kosmidis.me/nup-msc-rnn> και <https://url.kosmidis.me/nup-msc-rnn-undertrained>




Διάγραμμα 42 - Ακρίβεια εκπαίδευσης και επικύρωσης ανά εποχές για το RNN


Κατά τη σύντομη φάση εκπαίδευσης, το μοντέλο παρουσίασε εμφανή προβλήματα **υποεκπαίδευσης**. Η εκπαίδευση διακόπηκε στο **δεύτερο epoch**, γεγονός που οδήγησε σε **μη ολοκληρωμένες μετρικές**. Η ακρίβεια επικύρωσης και η απώλεια επικύρωσης δεν υπολογίστηκαν σωστά (NaN), ενώ η ακρίβεια στο test set ανήλθε μόλις στο **64.99%**. Επιπλέον, η **σύγχυση μεταξύ των κλάσεων** αναδείχθηκε ως σοβαρό πρόβλημα, με σημαντικό αριθμό λανθασμένων προβλέψεων (**Confusion Matrix**: 141,482 σωστές αρνητικές προβλέψεις έναντι 128,122 λανθασμένων θετικών). Η **οικονομική απόδοση** ήταν ελάχιστα θετική, με **κέρδος μόλις +0.35%**, ωστόσο, αυτή προέκυψε από μόλις **160 συναλλαγές**, από τις οποίες οι **119 ήταν short positions**. Η υπερβολική ενεργοποίηση **stop-loss (143 φορές)** υποδεικνύει **έλλειψη εμπιστοσύνης στις προβλέψεις του μοντέλου**, αλλά και ευαισθησία σε θορυβώδη δεδομένα.

Στην πλήρως εκπαιδευμένη φάση, το μοντέλο παρουσίασε **σημαντική βελτίωση**. Η ακρίβεια επικύρωσης έφτασε το **80.74%**, ενώ η μέγιστη ακρίβεια κατά τη διάρκεια της εκπαίδευσης άγγιξε το **85.39%** σε συγκεκριμένα splits. Η απώλεια επικύρωσης μειώθηκε σταθερά, καταδεικνύοντας τη **σταθερή σύγκλιση του μοντέλου**. Η ακρίβεια στο test set αυξήθηκε στο **82.36%**, με **ισορροπημένη απόδοση στις δύο κλάσεις** (Precision: 0.82 για την αρνητική κλάση και 0.83 για τη θετική). Παρά τις ενδείξεις **υψηλής στατιστικής ακρίβειας**, η **οικονομική απόδοση** υπήρξε απογοητευτική. Το χαρτοφυλάκιο υπέστη ζημία **-61.33%**, κυρίως λόγω της **υπερβολικής εξάρτησης από short positions**. Από τις **1,599 συναλλαγές**

που πραγματοποιήθηκαν, όλες ενεργοποίησαν **stop-loss**, γεγονός που αποκαλύπτει **σοβαρή αποτυχία στη γενίκευση των προβλέψεων του μοντέλου** στις δυναμικές αγορές.



Διάγραμμα 43 - Ενέργειες υποεκπαιδευμένου RNN



Διάγραμμα 44 - Ενέργειες RNN

Το διάγραμμα που απεικονίζει την εκπαίδευση και επικύρωση του μοντέλου δείχνει **σταθερή αύξηση της ακρίβειας** για την πλήρη εκπαίδευση, με **ελάχιστη απόκλιση** μεταξύ εκπαιδευτικής και επικυρωτικής ακρίβειας, υποδεικνύοντας **καλή γενίκευση**. Αντίθετα, το υποεκπαιδευμένο μοντέλο παρουσίασε **αστάθεια**, με τις μετρικές του να είναι **ακατάλληλες**

για εξαγωγή αξιόπιστων συμπερασμάτων. Το διάγραμμα της οικονομικής προσομοίωσης, από την άλλη, αποκαλύπτει τη **χαοτική φύση των προβλέψεων** του υποεκπαιδευμένου μοντέλου, με συχνές λανθασμένες προβλέψεις αγοράς και πώλησης, ενώ το πλήρως εκπαιδευμένο μοντέλο παρότι παρουσίασε **συνεκτικές προβλέψεις**, επικεντρώθηκε δυσανάλογα σε **risk-off στρατηγικές**.

Τα αποτελέσματα καταδεικνύουν ότι **η διάρκεια εκπαίδευσης είναι κρίσιμος παράγοντας** για τη σταθερότητα και αποτελεσματικότητα του μοντέλου. Η διακοπή της εκπαίδευσης οδήγησε σε **μη αναπαραγώγιμα και ανορθολογικά αποτελέσματα**. Παρόλα αυτά, ακόμα και στην πλήρη εκπαίδευση, η **οικονομική απόδοση** δεν κατόρθωσε να αντικατοπτρίσει την **υψηλή στατιστική ακρίβεια**, κάτι που υπογραμμίζει την ανάγκη για καλύτερη ενσωμάτωση των οικονομικών δεδομένων και των στρατηγικών συναλλαγών. Για τη βελτίωση του μοντέλου, απαιτείται **μεγαλύτερη έμφαση στην επιλογή στρατηγικών**, στη ρύθμιση των **thresholds για αγορά/πώληση** και στην **ενσωμάτωση πιο δυναμικών χαρακτηριστικών** της αγοράς. Η ανάλυση αυτή παρέχει μια πλήρη εικόνα των **πλεονεκτημάτων και περιορισμών** ενός επαναλαμβανόμενου νευρωνικού δικτύου σε χρηματοοικονομικές εφαρμογές, προσφέροντας **κατευθύνσεις για μελλοντική έρευνα και ανάπτυξη**.

6.1.6 Σύγκριση Επιδόσεων Μεταξύ Μοντέλων

Η σύγκριση των επιδόσεων διαφορετικών μοντέλων μηχανικής μάθησης ανέδειξε σημαντικές διαφοροποιήσεις σε τρεις βασικές κατηγορίες: ακρίβεια πρόβλεψης, οικονομική απόδοση, και διαχείριση κινδύνου. Κάθε μοντέλο παρουσίασε διαφορετικά δυνατά και αδύναμα σημεία, με το LGBMClassifier να εμφανίζεται ως η πιο ισορροπημένη επιλογή μεταξύ θεωρητικής ακρίβειας και πρακτικής εφαρμοσιμότητας.

Ακρίβεια Πρόβλεψης

Το LGBMClassifier κατέγραψε ακρίβεια πρόβλεψης 75% στη διασταυρούμενη επικύρωση (cross-validation), αποδεικνύοντας την ικανότητά του να γενικεύει σε σύνθετα δεδομένα αγοράς. Η χρήση γενετικών αλγορίθμων για τη βελτιστοποίηση παραμέτρων (learning rate 0.299, num leaves 195) συνέβαλε στη σταθερότητα των αποτελεσμάτων του. Αντίθετα, το Single Perceptron πέτυχε μέτρια ακρίβεια 62.10%, με εμφανή αδυναμία στην αναγνώριση σύνθετων μοτίβων, ενώ το Multilayered Perceptron (MLP) έφτασε σε ακρίβεια 74.81%, παρά

τις προκλήσεις της υπερπροσαρμογής. Τα πιο περίπλοκα μοντέλα, όπως το CNN-LSTM και το RNN, πέτυχαν ακρίβειες 87.77% και 82.36%, αντίστοιχα, σε στατιστικά περιβάλλοντα, αλλά η πρακτική τους εφαρμογή περιορίστηκε από την ασυμβατότητα των μοντέλων με δυναμικές αγορές.

Οικονομική Απόδοση

Σε όρους οικονομικών αποτελεσμάτων, το MLP παρουσίασε το μεγαλύτερο κέρδος (9.80%), αλλά με υψηλό ρίσκο, όπως καταδεικνύει το Sharpe Ratio (-71.00). Το LGBMClassifier απέφερε κέρδος 5.63% με μικρότερη μεταβλητότητα, ενώ το Single Perceptron πέτυχε μόνο 4.10%. Τα πιο πολύπλοκα μοντέλα όπως το CNN-LSTM και το RNN κατέγραψαν σοβαρές οικονομικές απώλειες (-84.28% και -61.33%, αντίστοιχα), λόγω της υπερβολικής εξάρτησης από short συναλλαγές και της αστοχίας στη διαχείριση stop-loss στρατηγικών. Η κακή οικονομική τους απόδοση υπογραμμίζει την ασυμφωνία μεταξύ υψηλής ακρίβειας πρόβλεψης και αποτελεσματικής εφαρμογής στις συναλλαγές.

Διαχείριση Κινδύνου

Το LGBMClassifier διακρίθηκε για την αποτελεσματική ενσωμάτωση στρατηγικών διαχείρισης κινδύνου, όπως το stop-loss (ενεργοποίηση σε 97% των συναλλαγών) και το take-profit (ενεργοποίηση σε 105% της τιμής εισόδου). Η εφαρμογή αυτών των μηχανισμών μείωσε σημαντικά τις ζημιές και σταθεροποίησε την κερδοφορία. Το Single Perceptron, αν και εμφάνισε βασική ικανότητα πρόβλεψης, περιορίστηκε από την απλοϊκή προσέγγιση στις συναλλαγές (15% μέγιστο ποσοστό εμπορίου). Τα νευρωνικά δίκτυα, όπως το CNN-LSTM και το RNN, απέτυχαν να διαχειριστούν αποτελεσματικά τον κίνδυνο, κυρίως λόγω της υπερβολικής συχνότητας συναλλαγών και της εξάρτησης από short θέσεις.

Ανάλυση Ευαισθησίας

Η ανάλυση ευαισθησίας σε θόρυβο ανέδειξε περαιτέρω προκλήσεις. Με την προσθήκη 1% θορύβου στα δεδομένα εισόδου, το LGBMClassifier παρουσίασε μικρές επιπτώσεις στην απόδοσή του, ενώ το Perceptron και το MLP εμφάνισαν σημαντική πτώση ακρίβειας στο 57.06% και 65%, αντίστοιχα. Το CNN-LSTM επηρεάστηκε περισσότερο, αποκαλύπτοντας την ανάγκη για καλύτερη προσαρμογή σε ρεαλιστικές συνθήκες αγοράς.


6.2 Ανάλυση Στρατηγικών Ανθρώπινων Διαπραγματευτών

6.2.1 Απόδοση Στρατηγικής Emotional Trader


Η προσομοίωση του συναισθηματικού συναλλακτικού μοντέλου ανέδειξε τη δυναμική των επενδυτών που βασίζονται κυρίως στις βραχυπρόθεσμες κινήσεις της αγοράς. Το μοντέλο υλοποιήθηκε με στόχο την κατανόηση της επίδρασης συναισθηματικών αποφάσεων σε ένα χρηματοοικονομικό περιβάλλον, λαμβάνοντας υπόψη δεδομένα χρηματιστηριακών τιμών και τεχνικών δεικτών. Παρότι η θεωρητική του βάση προσέφερε ένα ενδιαφέρον πλαίσιο ανάλυσης, τα αποτελέσματα¹² υποδεικνύουν **σοβαρές αδυναμίες στη βιωσιμότητα αυτής της προσέγγισης.**

Το αρχικό κεφάλαιο της προσομοίωσης ανήλθε σε **\$10,000 USD**, με τα fees συναλλαγών να ορίζονται σε **0.25% για αγορές και 0.40% για πωλήσεις**. Οι πιθανότητες συναλλαγών υπολογίστηκαν με βάση την ορμή της αγοράς (momentum), ενώ το rolling window για τον υπολογισμό κινητών μέσων και τυπικών αποκλίσεων καθορίστηκε στα 14 χρονικά βήματα. Παρά τις αρχικές παραδοχές, **το μοντέλο κατέγραψε απώλειες 99.55% στο συνολικό κεφάλαιο, με τελική αξία χαρτοφυλακίου μόλις \$45.32 USD μετά από 1,997,210 χρονικά βήματα.**

¹² Αναλυτικά δεδομένα και κώδικας είναι διαθέσιμα στον σύνδεσμο: <https://url.kosmidis.me/nup-msc-emotional>



Διάγραμμα 45 - Κινήσεις Emotional Trader



Διάγραμμα 46 - Πορεία χαρτοφυλακίου Emotional Trader

Η πρώτη γραφική παράσταση (*Price with Buy/Sell Actions*) αποκαλύπτει τη συχνή εναλλαγή μεταξύ αγορών και πωλήσεων, ειδικά σε περιόδους έντονης πτωτικής τάσης (π.χ., τιμές κάτω από \$30,000). Συνολικά πραγματοποιήθηκαν **557,985 συναλλαγές**, εκ των οποίων οι **306,884 ήταν αγορές και οι 251,101 πωλήσεις**, με την ανισορροπία αυτή να ενισχύει την αστάθεια του χαρτοφυλακίου. Η υπερβολική συχνότητα συναλλαγών, σε συνδυασμό με τα υψηλά fees, είχε καταστροφική επίδραση στην αξία του χαρτοφυλακίου, η οποία μειωνόταν σχεδόν εκθετικά, όπως φαίνεται στο Διάγραμμα *Portfolio Value Over Time*.

Η οικονομική απόδοση του μοντέλου υπογραμμίζεται περαιτέρω από τον δείκτη Sharpe, ο οποίος ανήλθε σε **0.03**, υποδηλώνοντας μια εξαιρετικά χαμηλή αναλογία απόδοσης-ρίσκου. Παρά τη θεωρητική ικανότητα του μοντέλου να προβλέπει την κατεύθυνση της αγοράς (με συσχέτιση 0.25 μεταξύ προβλέψεων και μελλοντικών μεταβολών τιμών), **η έλλειψη στρατηγικής διαχείρισης κεφαλαίου και η εξάρτηση από βραχυπρόθεσμους δείκτες, όπως ο price_change_ratio, οδήγησαν σε σημαντική υποαπόδοση.**

Η ευαισθησία του μοντέλου σε διαφορετικά fees αποδεικνύει τη χρονική του αστάθεια. Για παράδειγμα, με μειωμένα fees (0.15% για αγορές και 0.30% για πωλήσεις), η τελική αξία ανήλθε σε \$165.79 USD (-98.34%), ενώ με αυξημένα fees (0.50% για αγορές και 0.75% για πωλήσεις), η αξία μειώθηκε περαιτέρω στα \$5.25 USD (-99.95%). Αυτές οι διαφοροποιήσεις καταδεικνύουν την ευάλωτη φύση της στρατηγικής, που εξαρτάται υπέρμετρα από τα κόστη συναλλαγών.

Το μοντέλο **απέτυχε να επιτύχει βιώσιμα κέρδη, αποδεικνύοντας ότι οι συναισθηματικές στρατηγικές βασισμένες σε βραχυπρόθεσμες τάσεις και momentum δεν είναι αποτελεσματικές.** Η υπερβολική συχνότητα συναλλαγών, η απουσία δυναμικής προσαρμογής των fees, και η έλλειψη ενσωμάτωσης μακροπρόθεσμων δεικτών αποτελούν κρίσιμα σημεία προς βελτίωση. **Η χρήση πιο σύνθετων στρατηγικών που συνδυάζουν μακροπρόθεσμους τεχνικούς δείκτες και περιορισμούς στις συναλλαγές αποτελεί βασική κατεύθυνση για μελλοντικές έρευνες.**

6.2.2 Απόδοση Στρατηγικής Home Trader

Η προσομοίωση του Home-Based Trader αναδεικνύει τη λειτουργία και τα αποτελέσματα μιας στρατηγικής συναλλαγών βασισμένης σε τεχνικούς δείκτες και προσαρμοστική δυναμική. Τα αποτελέσματα¹³ επιβεβαιώνουν τις επιδόσεις του μοντέλου υπό διαφορετικές συνθήκες αγοράς, ενώ παράλληλα αποκαλύπτουν κρίσιμες αδυναμίες που επηρεάζουν την αποδοτικότητά του.


¹³ Αναλυτικά δεδομένα και κώδικας είναι διαθέσιμα στον σύνδεσμο: <https://url.kosmidis.me/nup-msc-home-based>

Το μοντέλο ξεκίνησε με αρχικό κεφάλαιο **\$10,000** και βασίστηκε σε μια δυναμική στρατηγική, όπου οι πιθανότητες αγοράς (P_{buy}) και πώλησης (P_{sell}) ενημερώνονται με βάση το **MACD_signal** και έναν παράγοντα προσαρμογής ($\gamma=0.1$). Οι συναλλαγές υπόκεινται σε τέλη **0.25% για αγορές** και **0.40% για πωλήσεις**, ενώ το μέγιστο ποσό έκθεσης ανά συναλλαγή περιορίστηκε στο **10% του διαθέσιμου κεφαλαίου**. Μετά από **1,997,210 βήματα προσομοίωσης**, η συνολική αξία του χαρτοφυλακίου μειώθηκε κατά **51.92%**, φτάνοντας τα **\$4,807.98**.



Διάγραμμα 47 - Πορεία χαρτοφυλακίου Home-Based Trader

Η στρατηγική εκτέλεσε **356,495 αγορές** και **11,525 πωλήσεις**, καταδεικνύοντας μια **ανισορροπία μεταξύ αγοράς και πώλησης**, με έμφαση στην αγορά, ακόμη και σε περιόδους φθίνουσας τιμής. Η τελική αξία του BTC στο χαρτοφυλάκιο ήταν **0.026344 BTC** (αξίας \$790.01), ενώ το υπόλοιπο USD ανήλθε στα **\$4,017.96**. Η **συχνότητα συναλλαγών**, σε συνδυασμό με τα τέλη αγοράς και πώλησης, συνέβαλε στη συνολική μείωση της απόδοσης. Η αποτελεσματικότητα των τεχνικών δεικτών ποικίλλει, με το **momentum** και το **price_change_ratio** να αναδεικνύονται ως οι πιο σημαντικοί, καταγράφοντας **permantion importance 26.38% και 25.08%** αντίστοιχα. Αντίθετα, δείκτες όπως ο **MACD_signal** και ο **ATR** παρουσίασαν περιορισμένη επίδραση.



Διάγραμμα 48 - Κινήσεις Home-Based Trader


Το διάγραμμα **Prices with Buy/Sell Actions** δείχνει τη συσσώρευση αγορών σε χαμηλότερες τιμές, χωρίς όμως επιτυχείς πωλήσεις σε ανώτερα επίπεδα, γεγονός που συνέβαλε στην πτώση της απόδοσης. Το διάγραμμα **Portfolio Value Over Time** επιβεβαιώνει μια **σταθερή καθοδική τάση**, με απότομες πτώσεις κατά τη διάρκεια περιόδων έντονων αγορών και περιορισμένη ανάκαμψη μέσω πωλήσεων.

Η ανάλυση επιβεβαιώνει ότι η παρούσα στρατηγική αντιμετωπίζει σοβαρές προκλήσεις στη διαχείριση κινδύνου και την εξισορρόπηση των αποφάσεων αγοράς και πώλησης. Η απώλεια του αρχικού κεφαλαίου υποδεικνύει την ανάγκη για σημαντικές βελτιώσεις, όπως η εισαγωγή μηχανισμών stop-loss και take-profit, η μείωση της συχνότητας συναλλαγών και η καλύτερη προσαρμογή των πιθανοτήτων στις τρέχουσες συνθήκες της αγοράς. Η εισαγωγή πολυπαραμετρικών στρατηγικών, που συνδυάζουν δείκτες όπως το RSI και οι όγκοι συναλλαγών, θα μπορούσε να ενισχύσει τη σταθερότητα και την αποδοτικότητα της στρατηγικής.

6.2.3 Απόδοση Στρατηγικής Έμπειρου Συντηρητικού Trader


Η ανάλυση¹⁴ των αποτελεσμάτων του μοντέλου **Pro Risk-Free Trader** αναδεικνύει την αποτελεσματικότητά του στη δημιουργία κερδοφορίας με συντηρητική στρατηγική, αλλά και ορισμένες προκλήσεις που σχετίζονται με τη διαχείριση του κινδύνου και τη σταθερότητα των αποδόσεων.

Στο στάδιο της **προσομοίωσης συναλλαγών**, εφαρμόστηκε ένα Decision Tree Classifier ($\text{max_depth}=5$), το οποίο εστίασε σε μια **συντηρητική στρατηγική** συναλλαγών, περιορίζοντας το ποσοστό συναλλαγών στο **10% του διαθέσιμου κεφαλαίου ανά βήμα**. Το μοντέλο ενσωμάτωσε έναν παράγοντα κινδύνου $\lambda=0,5$, ενώ τα τέλη συναλλαγών ορίστηκαν σε **0,25% για αγορές** και **0,40% για πωλήσεις**, προσομοιώνοντας τις πραγματικές συνθήκες της αγοράς. Τα αποτελέσματα της προσομοίωσης ήταν εντυπωσιακά, καθώς το αρχικό κεφάλαιο των **10.000 USD** αυξήθηκε σε **28.725,86 USD**, αντιπροσωπεύοντας κέρδος **187,26%** μετά από **1.320 συναλλαγές** (970 αγορές και 350 πωλήσεις). Ωστόσο, η κατανομή των κερδών/ζημιών κατέδειξε **υψηλή τυπική απόκλιση ($\approx 13,25$ USD)**, ενώ το **Sharpe Ratio** ήταν αρνητικό (**-7,54**), γεγονός που υποδηλώνει ότι η κερδοφορία δεν αντιστάθμισε επαρκώς τον αναλαμβανόμενο κίνδυνο.



Διάγραμμα 49 - Κινήσεις μοντέλου Pro Risk-Free Trader

¹⁴ Αναλυτικά δεδομένα και κώδικας είναι διαθέσιμα στον σύνδεσμο: <https://url.kosmidis.me/nup-msc-pro-risk-free>



Διάγραμμα 50 - Πορεία χαρτοφυλακίου Pro Risk-Free Trader


Η οπτική αναπαράσταση των αποτελεσμάτων μέσα από τα διαγράμματα προσφέρει περαιτέρω επιβεβαίωση. Το πρώτο διάγραμμα παρουσιάζει την εξέλιξη της **τιμής του Bitcoin** με ενέργειες αγοράς και πώλησης, καταδεικνύοντας τη στρατηγική τοποθέτηση του μοντέλου σε κομβικά σημεία της αγοράς. Στο δεύτερο διάγραμμα αποτυπώνεται η **αξία του χαρτοφυλακίου** με σαφή ανοδική πορεία, καταλήγοντας σε υψηλή απόδοση μετά από 2 εκατομμύρια βήματα. Παράλληλα, η **ανάλυση ευαισθησίας** έδειξε ότι η απόδοση του μοντέλου επηρεάζεται σημαντικά από τις παραμέτρους των τελών συναλλαγών και το αρχικό κεφάλαιο. Ενδεικτικά, η μείωση των τελών συναλλαγών (0,15% για αγορές, 0,30% για πωλήσεις) αύξησε την τελική αξία του χαρτοφυλακίου σε **30.256,48 USD** (κέρδος **202,56%**), ενώ η αύξηση των τελών (0,50% για αγορές, 0,75% για πωλήσεις) περιόρισε την αξία στα **24.592,76 USD** (κέρδος **145,93%**).

Το μοντέλο **Pro Risk-Free Trader** πέτυχε σημαντική κερδοφορία, ενισχύοντας τη δυνατότητα μακροπρόθεσμης απόδοσης μέσω μιας συντηρητικής στρατηγικής. Ωστόσο, η **αρνητική τιμή του Sharpe Ratio** και η υψηλή διακύμανση υπογραμμίζουν την ανάγκη για βελτιώσεις στη διαχείριση του κινδύνου. Η επιλογή χαρακτηριστικών και η χρήση τεχνικών δεικτών αποδείχθηκαν αποτελεσματικές, ενώ η ανάλυση ευαισθησίας έδειξε ότι η προσαρμογή παραμέτρων, όπως τα τέλη συναλλαγών και τα μεγέθη παραθύρων, μπορεί να οδηγήσει σε

ακόμη καλύτερα αποτελέσματα. Η στρατηγική του μοντέλου, αν και συντηρητική, δείχνει τη δυνατότητα να ενσωματωθεί σε πιο σύνθετα και προσαρμοστικά συστήματα συναλλαγών.


6.2.4 Απόδοση Στρατηγικής Έμπειρου Φιλικού προς το Ρίσκο Trader

Η προσομοίωση του μοντέλου **Pro-Risk-Friendly Trader** αναδεικνύει μια επιθετική προσέγγιση στη διαχείριση επενδύσεων, προσφέροντας εντυπωσιακά αποτελέσματα¹⁵ σε ανοδικές αγορές, αλλά με ορισμένους περιορισμούς στη διαχείριση κινδύνου και την ισορροπία στρατηγικών συναλλαγών. Το μοντέλο, βασισμένο σε ιστορικά δεδομένα τιμών κρυπτονομισμάτων και τεχνικούς δείκτες, πέτυχε τελική αξία χαρτοφυλακίου **\$41,286.03**, σημειώνοντας **κέρδος 312.86%** από ένα αρχικό κεφάλαιο **\$10,000**. Αυτή η ανάπτυξη επιτεύχθηκε μέσω **11,170 συναλλαγών**, με **11,164 αγορές** και μόνο **6 πωλήσεις**, υπογραμμίζοντας τη ριψοκίνδυνη φύση του μοντέλου.



Διάγραμμα 51 - Πορεία χαρτοφυλακίου Pro-Risk-Friendly Trader

¹⁵ Αναλυτικά δεδομένα και κώδικας είναι διαθέσιμα στον σύνδεσμο: <https://url.kosmidis.me/nup-msc-pro-risk-friendly>




Διάγραμμα 52 - Κινήσεις μοντέλου Pro-Risk-Friendly Trader

Η προσομοίωση συναλλαγών περιλάμβανε τη χρήση **δυναμικών ορίων κέρδους** (dynamic_threshold), που προσαρμόζονται βάσει του κινητού μέσου όρου αποδόσεων (rolling_returns) και της μεταβλητότητας (rolling_volatility). Ο λόγος ανταμοιβής-κινδύνου (reward_to_risk_ratio) αποτέλεσε κρίσιμο εργαλείο στις αποφάσεις αγοράς, ευνοώντας κινήσεις με **αναμενόμενη απόδοση άνω του 0.05%** (profit_threshold). Παρά το υψηλό ποσοστό συναλλαγών, τα τέλη **0.25% για αγορές και 0.40% για πωλήσεις** δεν εμπόδισαν τη συσσώρευση κερδών, όπως αποδεικνύεται από την ανάλυση ευαισθησίας. Συγκεκριμένα, μειωμένα τέλη συναλλαγών αύξησαν το κέρδος στο **314.55%**, ενώ υψηλότερα τέλη το περιόρισαν στο **308.04%**.


Παρά την εντυπωσιακή απόδοση, το **αρνητικό Sharpe Ratio (-3.01)** υποδεικνύει ότι το μοντέλο λειτουργεί υπό **υψηλή μεταβλητότητα και κίνδυνο**, κυρίως λόγω της συχνότητας των αγορών και της σπάνιας εκτέλεσης πωλήσεων. Η ανισορροπία αυτή άφησε το χαρτοφυλάκιο εκτεθειμένο σε πτωτικές τάσεις, ενώ η μέση ζημία ανά συναλλαγή (-\$7.54) υπερβαίνει το μέσο κέρδος (\$7.54), υπογραμμίζοντας την ανάγκη για βελτίωση της στρατηγικής πωλήσεων.

Το διάγραμμα των τιμών καταδεικνύει **συγκεντρωμένες αγορές σε περιόδους σταθερότητας**, ενώ οι πωλήσεις περιορίζονται σε τοπικές διορθώσεις. Στο διάγραμμα της αξίας του χαρτοφυλακίου, η **συνεχής ανοδική τάση** αποδεικνύει τη συνολική

αποτελεσματικότητα του μοντέλου, με την αξία του BTC να αντιπροσωπεύει το **99.8% του συνολικού χαρτοφυλακίου**, γεγονός που επιβεβαιώνει την έκθεση σε ένα μόνο περιουσιακό στοιχείο.



Διάγραμμα 53 - Ποσότητα USD στο χαρτοφυλάκιο Pro-Risk-Friendly Trader



Διάγραμμα 54 - Ποσότητα BTC στο χαρτοφυλάκιο Pro-Risk-Friendly Trader

Το μοντέλο **Pro-Risk-Friendly Trader** αποδεικνύει την ικανότητά του να αποδίδει σημαντικά κέρδη σε ανοδικές αγορές, καθιστώντας το ένα ισχυρό εργαλείο για επιθετικές στρατηγικές. Ωστόσο, η υψηλή διακύμανση των αποδόσεων και η έλλειψη ισορροπίας μεταξύ αγορών

και πωλήσεων αναδεικνύουν την ανάγκη για περαιτέρω βελτιώσεις, ιδιαίτερα στη διαχείριση κινδύνου και στη διαφοροποίηση των περιουσιακών στοιχείων. Επιπλέον, η σταθερότητα της απόδοσης υπό διαφορετικά τέλη συναλλαγών και αρχικά κεφάλαια ενισχύει την προοπτική εφαρμογής του σε πραγματικές συνθήκες αγοράς, με προσαρμογές που θα μπορούσαν να ενισχύσουν τη μακροπρόθεσμη βιωσιμότητά του.

6.2.5 Σύγκριση Στρατηγικών Ανθρώπινων Διαπραγματευτών

Η σύγκριση των στρατηγικών που χρησιμοποιούν οι άνθρωποι διαπραγματευτές αναδεικνύει σημαντικές διαφοροποιήσεις στις αποδόσεις, στη διαχείριση κινδύνου, στη συχνότητα συναλλαγών και στην προσαρμοστικότητα κάτω από διαφορετικές συνθήκες αγοράς.

Οικονομική Απόδοση

Ο Emotional Trader κατέγραψε τη χειρότερη οικονομική απόδοση με απώλεια 99.55% του αρχικού κεφαλαίου (\$10,000 σε \$45.32). Η υπερβολική συχνότητα συναλλαγών (557,985 συναλλαγές) και τα υψηλά τέλη (0.25% για αγορές, 0.40% για πωλήσεις) συντέλεσαν καθοριστικά στην εκθετική μείωση της αξίας του χαρτοφυλακίου.

Ο Home Trader παρουσίασε πιο συγκρατημένες απώλειες, μειώνοντας το κεφάλαιο κατά 51.92% (τελική αξία \$4,807.98). Αν και χρησιμοποίησε τεχνικούς δείκτες, προς το MACD_signal, η αδυναμία αποτελεσματικών πωλήσεων περιόρισε την οικονομική προς αποτελεσματικότητα.

Ο Έμπειρος Συντηρητικός Trader κατέγραψε σημαντική αύξηση κεφαλαίου (187.26%, τελική αξία \$28,725.86) χάρη στη συντηρητική του προσέγγιση, ενώ ο Έμπειρος Φιλικός προς το Ρίσκο Trader πέτυχε την υψηλότερη απόδοση, με αύξηση 312.86% (τελική αξία \$41,286.03), αν και αυτή συνοδεύτηκε από υψηλή αστάθεια.

Διαχείριση Κινδύνου

Ο Emotional Trader απέτυχε να διαχειριστεί τον κίνδυνο, όπως επιβεβαιώνεται από τον εξαιρετικά χαμηλό δείκτη Sharpe (0.03). Η στρατηγική του βασίστηκε σε momentum-based

αποφάσεις, οι οποίες δεν ενσωμάτωσαν μακροπρόθεσμους δείκτες, με αποτέλεσμα καταστροφικές απώλειες.

Ο Home Trader, αν και ενσωμάτωσε τεχνικούς δείκτες, όπως το momentum και το price_change_ratio, απέτυχε να εφαρμόσει στρατηγικές stop-loss και take-profit, με αποτέλεσμα σταθερή μείωση του χαρτοφυλακίου.

Ο Έμπειρος Συντηρητικός Trader εφάρμοσε συντηρητική προσέγγιση, περιορίζοντας την έκθεση σε κάθε συναλλαγή στο 10% του διαθέσιμου κεφαλαίου. Ωστόσο, η υψηλή τυπική απόκλιση (13.25 USD) και το αρνητικό Sharpe Ratio (-7.54) αναδεικνύουν περιθώρια βελτίωσης.

Ο Έμπειρος Φιλικός προς το Ρίσκο Trader, παρά την επιθετική του προσέγγιση, παρουσίασε ευαισθησία σε πτωτικές αγορές λόγω της σχεδόν αποκλειστικής έκθεσης σε Bitcoin (99.8% του χαρτοφυλακίου), ενώ το αρνητικό Sharpe Ratio (-3.01) αποκάλυψε υψηλό ρίσκο.

Συχνότητα Συναλλαγών

Ο Emotional Trader πραγματοποίησε τον υψηλότερο αριθμό συναλλαγών (557,985 συναλλαγές), ενώ ο Home Trader πραγματοποίησε 356,495 αγορές και μόλις 11,525 πωλήσεις, γεγονός που ενίσχυσε την καθοδική τάση της απόδοσής του.

Οι συντηρητικές στρατηγικές, προς αυτή του Έμπειρου Συντηρητικού Trader, περιόρισαν προς συναλλαγές, με 970 αγορές και 350 πωλήσεις, προσαρμοσμένες στο 10% του κεφαλαίου ανά βήμα, ενισχύοντας τη σταθερότητα. Αντίθετα, ο Έμπειρος Φιλικός προς το Ρίσκο Trader επικεντρώθηκε σε αγορές (11,164 συναλλαγές) με ελάχιστες πωλήσεις (6 συναλλαγές), γεγονός που περιόρισε τη διαφοροποίηση του χαρτοφυλακίου.

Ευαισθησία σε Συνθήκες Αγοράς

Ο Emotional Trader και ο Home Trader παρουσίασαν υψηλή ευαισθησία σε κόστη συναλλαγών, με τη μείωση των τελών να βελτιώνει την απόδοση, αλλά όχι σε βιώσιμα επίπεδα. Η ανάλυση ευαισθησίας στον Έμπειρο Συντηρητικό Trader έδειξε ότι μειωμένα τέλη (0.15% αγορά, 0.30% πώληση) θα μπορούσαν να αυξήσουν την τελική απόδοση στο 202.56%.

Παρόμοια, στον Έμπειρο Φιλικό προς το Ρίσκο Trader, τα μειωμένα τέλη αύξησαν τα κέρδη από 312.86% σε 314.55%, ενώ τα υψηλά τέλη τα περιορίσαν στο 308.04%.

6.3 Συγκριτική Ανάλυση Μοντέλων TN και Ανθρώπινων Στρατηγικών

Η συγκριτική ανάλυση των μοντέλων Τεχνητής Νοημοσύνης (TN) και των ανθρώπινων στρατηγικών αναδεικνύει τις διαφοροποιήσεις στην απόδοση, τη διαχείριση κινδύνου και την ανθεκτικότητα σε ασταθή περιβάλλοντα, όπως αυτό του Bitcoin. Η αξιολόγηση των μοντέλων TN πραγματοποιήθηκε σε ένα 15% του dataset, ενώ οι ανθρώπινες στρατηγικές δοκιμάστηκαν στο 100% του συνόλου. Αυτή η διαφορά καθιστά τη σύγκριση άνιση, ειδικά όταν το dataset περιλαμβάνει δεδομένα από περιόδους εξαιρετικής αστάθειας, όπως η πανδημία COVID-19, που επέδρασε στις παγκόσμιες αγορές και ιδιαίτερα στις τιμές του Bitcoin.

6.3.1 Σύγκριση Απόδοσης TN και Ανθρώπινων Στρατηγικών

Η σύγκριση της απόδοσης μεταξύ TN και ανθρώπινων στρατηγικών αναδεικνύει δύο διαφορετικές φιλοσοφίες προσέγγισης της αγοράς. Τα μοντέλα TN βασίζονται σε στατιστική ακρίβεια και μαθηματική βελτιστοποίηση, ενώ οι ανθρώπινες στρατηγικές ενσωματώνουν στοιχεία εμπειρίας και συναισθηματικής διαχείρισης.

Η βασική διαφορά εντοπίζεται στον τρόπο αξιοποίησης των δεδομένων. Τα μοντέλα TN αξιοποιούν το 15% του dataset, επικεντρώνονται στην πρόβλεψη συγκεκριμένων τάσεων και συχνά βελτιστοποιούνται για να μεγιστοποιούν την ακρίβεια πρόβλεψης (π.χ., το CNN-LSTM έφτασε σε ακρίβεια 87.77%). Ωστόσο, αυτή η περιορισμένη δοκιμή τα απομακρύνει από τη ρεαλιστική πολυπλοκότητα της αγοράς, κάτι που οδήγησε σε οικονομικές αποτυχίες, όπως η ζημία -84.28% στο CNN-LSTM.

Αντίθετα, οι ανθρώπινες στρατηγικές αξιολογήθηκαν στο σύνολο του dataset, αντιμετωπίζοντας όλες τις συνθήκες, συμπεριλαμβανομένων των περιόδων έντονης αστάθειας. Εδώ έγκειται μια σημαντική διαφορά: οι άνθρωποι αντέδρασαν σε πραγματικό χρόνο στις αγοραίες συνθήκες, αποδεικνύοντας μεγαλύτερη ευελιξία σε απρόβλεπτα γεγονότα, όπως η πανδημία COVID-19. Εντούτοις, στρατηγικές όπως η Emotional Trader απέτυχαν λόγω συναισθηματικής υπεραντίδρασης, ενώ ο Συντηρητικός Trader διατήρησε σταθερότερο προφίλ.

6.3.2 Ανάλυση Κινδύνου και Αποδόσεων

Η διαχείριση κινδύνου στα μοντέλα TN και τις ανθρώπινες στρατηγικές παρουσιάζει θεμελιώδεις διαφοροποιήσεις. Τα TN ακολουθούν αυτοματοποιημένες στρατηγικές διαχείρισης, οι οποίες βασίζονται σε μαθηματικούς κανόνες και προκαθορισμένα όρια (π.χ., stop-loss, take-profit). Αυτοί οι μηχανισμοί μειώνουν την πιθανότητα συναισθηματικών αποφάσεων αλλά περιορίζουν την προσαρμοστικότητα. Για παράδειγμα, το LGBMClassifier εφάρμοσε stop-loss στο 97% των συναλλαγών του, διατηρώντας τις απώλειες υπό έλεγχο. Ωστόσο, η περιορισμένη έκθεση στο dataset δεν κατέγραψε κρίσιμες περιόδους, οδηγώντας σε ελλιπή αξιολόγηση κινδύνου.

Από την άλλη, οι ανθρώπινες στρατηγικές προσπαθούν να διαχειριστούν τον κίνδυνο βασιζόμενοι στην εμπειρία και τη διαίσθηση. Ενώ αυτό τους προσφέρει ευελιξία σε καταστάσεις που δεν καλύπτονται από αλγοριθμικούς κανόνες, οδηγεί συχνά σε αντιφατικές αποφάσεις. Ο Φιλικός προς το Ρίσκο Trader, για παράδειγμα, απέτυχε να περιορίσει την έκθεση του σε πτωτικές τάσεις λόγω έλλειψης διαφοροποίησης χαρτοφυλακίου, καταγράφοντας υψηλές διακυμάνσεις.

Η αντίθεση μεταξύ της αυστηρής συνέπειας των TN και της συναισθηματικής ευπάθειας των ανθρωπίνων στρατηγικών αναδεικνύει τα πλεονεκτήματα και τους περιορισμούς κάθε προσέγγισης. Τα μοντέλα TN προσφέρουν δομημένη διαχείριση κινδύνου, ενώ οι ανθρώπινες στρατηγικές συχνά υπερεκτιμούν τη δική τους ικανότητα πρόβλεψης.

6.3.3 Επιδράσεις στο Ασταθές Περιβάλλον του Bitcoin

Η περίοδος της πανδημίας COVID-19 αποτέλεσε ένα εξαιρετικά ασταθές περιβάλλον, επηρεάζοντας σημαντικά τις χρηματοπιστωτικές αγορές και, ειδικότερα, την αγορά του Bitcoin. Κατά την περίοδο της μελέτης, το Bitcoin σημείωσε ιστορικές μεταβολές τιμών, με έντονες ανοδικές και πτωτικές τάσεις (από \$5,000 τον Μάρτιο του 2020 έως και πάνω από \$60,000 τον Απρίλιο του 2021). Αυτό το περιβάλλον προσέφερε ένα μοναδικό πλαίσιο για τη δοκιμή στρατηγικών.

Παρόλο που το dataset ήταν κοινό για τα μοντέλα TN και τις ανθρώπινες στρατηγικές, η διαχείρισή του διαφοροποιήθηκε. Τα μοντέλα TN διαιρέθηκαν σε 70% για εκπαίδευση, 15%

για επικύρωση και 15% για δοκιμή. Αυτή η προσέγγιση επέτρεψε στα μοντέλα να βελτιστοποιήσουν τις παραμέτρους τους, αλλά περιόρισε την αξιολόγηση της απόδοσής τους στο 15% του dataset. Αντίθετα, οι ανθρώπινες στρατηγικές δοκιμάστηκαν σε 100% του dataset, καταγράφοντας τη συμπεριφορά τους σε ολόκληρη τη χρονική περίοδο, συμπεριλαμβανομένων των ακραίων γεγονότων της πανδημίας.

Τα μοντέλα TN, όπως το LGBMClassifier, επέδειξαν σταθερότητα χάρη στην ενσωμάτωση μηχανισμών διαχείρισης κινδύνου και βελτιστοποίησης. Για παράδειγμα, το LGBMClassifier κατέγραψε σταθερό κέρδος 5.63%, παρά τη δυναμική του περιβάλλοντος. Ωστόσο, η περιορισμένη δοκιμή του σε 15% του dataset περιόρισε τη δυνατότητα αξιολόγησης της ανθεκτικότητάς του σε εξαιρετικά ασταθείς συνθήκες, όπως αυτές του Bitcoin κατά την πανδημία.

Αντίθετα, οι ανθρώπινες στρατηγικές, όπως ο Φιλικός προς το Ρίσκο Trader, εκτέθηκαν σε ολόκληρο το dataset και επωφελήθηκαν από τις ανοδικές αγορές, καταγράφοντας κέρδη 312.86%. Εντούτοις, αυτή η πλήρης έκθεση αποκάλυψε και αδυναμίες, όπως η έλλειψη διαφοροποίησης χαρτοφυλακίου και η υπερβολική εξάρτηση από μονοδιάστατες αποφάσεις, ιδιαίτερα σε πτωτικές αγορές. Από την άλλη, στρατηγικές όπως η Emotional Trader απέτυχαν πλήρως, με απώλειες -99.55%, καταδεικνύοντας την ανικανότητά τους να διαχειριστούν την αστάθεια.

Η σύγκριση αποκαλύπτει ότι τα μοντέλα TN είναι πιο ανθεκτικά σε σταθερά περιβάλλοντα λόγω της αλγοριθμικής τους προσέγγισης. Ωστόσο, οι ανθρώπινες στρατηγικές υπερέχουν στην αντιμετώπιση απρόβλεπτων καταστάσεων, καθώς ανταποκρίνονται σε δεδομένα από ολόκληρη την αγορά, προσφέροντας πιο ρεαλιστική απεικόνιση των αποτελεσμάτων.

7 – Κώδικας και Εφαρμογές

7.1 Λογική Διαχείρισης Συναλλαγών για Τα Μοντέλα Τεχνητής Νοημοσύνης

Ο κώδικας που παρουσιάζεται στο ΠΑΡΑΡΤΗΜΑ Β αποτελεί τον πυρήνα της αυτοματοποιημένης διαδικασίας συναλλαγών, σχεδιασμένος για να ενσωματώνει προβλέψεις μοντέλων μηχανικής μάθησης (ML) και βαθιάς μάθησης (DL) σε πραγματικά σενάρια trading. Η λειτουργία του βασίζεται σε έναν αλγόριθμο που αξιοποιεί τις πιθανότητες πρόβλεψης των μοντέλων για τη λήψη αποφάσεων αγοράς, πώλησης και διαχείρισης κινδύνου.

Λειτουργία

Κεντρικό στοιχείο του κώδικα είναι ο μηχανισμός δυναμικής διαχείρισης θέσεων, ο οποίος αξιολογεί συνεχώς τις τρέχουσες συνθήκες της αγοράς. Για κάθε χρονικό βήμα του συνόλου δοκιμής (`prices_test`), ο αλγόριθμος υπολογίζει την εμπιστοσύνη (`confidence`) της πρόβλεψης με βάση την απόσταση της πιθανότητας (`predicted_proba`) από την ουδέτερη τιμή 0.5. Η εμπιστοσύνη αυτή καθορίζει το ποσοστό συμμετοχής του χαρτοφυλακίου σε κάθε συναλλαγή (`fraction_to_trade`), με γραμμική κλιμάκωση ανάλογα με τη μέγιστη επιτρεπόμενη έκθεση (`max_trade_fraction`).

Ο κώδικας υλοποιεί αυστηρούς κανόνες εξόδου για τη διασφάλιση κερδών και τον περιορισμό απωλειών. Συγκεκριμένα, ελέγχει συνεχώς αν η τρέχουσα αξία μιας μακροπρόθεσμης θέσης (`btc_balance`) υπερβαίνει το όριο `take_profit_pct` ή πέφτει κάτω από το `stop_loss_pct`. Σε κάθε τέτοια περίπτωση, πραγματοποιεί αυτόματη πώληση, είτε για πραγματοποίηση κέρδους είτε για αποκοπή ζημιάς. Αντίστοιχα, για τις θέσεις `short`, ο αλγόριθμος εφαρμόζει ανάλογους μηχανισμούς, διασφαλίζοντας τη συμμόρφωση με τα προκαθορισμένα όρια ρίσκου.

Η είσοδος σε νέες συναλλαγές γίνεται μόνο όταν η εμπιστοσύνη ξεπερνά ένα ελάχιστο όριο (`min_confidence`), ενώ η κατεύθυνση της συναλλαγής (αγορά ή πώληση) καθορίζεται από τη σύγκριση της `predicted_proba` με κατώφλια (`buy_threshold`, `sell_threshold`). Για παράδειγμα, αν η πιθανότητα πρόβλεψης για άνοδο της τιμής υπερβαίνει το `buy_threshold`, ο αλγόριθμος αγοράζει κρυπτονομίσματα αναλογικά προς την εμπιστοσύνη, λαμβάνοντας υπόψη τα τέλη συναλλαγών (`buy_fee`).

Σημασία

Η σημασία αυτού του κώδικα έγκειται στη δυνατότητα συστηματικής εφαρμογής στρατηγικών που συνδυάζουν την ακρίβεια των ML/DL μοντέλων με αυστηρές τεχνικές διαχείρισης κινδύνου. Με την αυτοματοποίηση των διαδικασιών, εξαλείφεται ο συναισθηματικός παράγοντας, ενώ ταυτόχρονα διατηρείται η ευελιξία για προσαρμογή σε διαφορετικές συνθήκες αγοράς. Επιπλέον, η καταγραφή όλων των ενεργειών και των αποτελεσμάτων (`trading_data`) επιτρέπει τη λεπτομερή ανάλυση της απόδοσης του συστήματος, παρέχοντας πολύτιμα δεδομένα για βελτιστοποίηση.

Δυνατότητες Επέκτασης

Για τη βελτίωση του υπάρχοντος συστήματος, θα μπορούσε να εισαχθεί ένας προσαρμοστικός μηχανισμός `stop loss/take profit`, ο οποίος θα λαμβάνει υπόψη τη μεταβλητότητα της αγοράς σε πραγματικό χρόνο. Για παράδειγμα, τα όρια εξόδου θα μπορούσαν να προσαρμόζονται δυναμικά με βάση τον κινητό μέσο όρο ή τον δείκτη `Bollinger Bands`. Επιπλέον, η ενσωμάτωση πολυδιάστατων δεικτών (π.χ., `RSI`, `MACD`) ως πρόσθετων εισροών στο μοντέλο θα ενίσχυε την ακρίβεια των προβλέψεων, ενώ η χρήση ενισχυτικής μάθησης θα επέτρεπε την αυτόματη βελτιστοποίηση των κανόνων συναλλαγών βάσει ιστορικών δεδομένων.

Μια άλλη κατεύθυνση θα μπορούσε να είναι η εισαγωγή κοινωνικών δεικτών (π.χ., συναίσθημα από `social media` ή ειδήσεις) για τη λήψη αποφάσεων, δημιουργώντας ένα υβριδικό σύστημα που συνδυάζει τεχνική ανάλυση με συμπεριφορικά δεδομένα. Τέλος, η επέκταση του κώδικα για την υποστήριξη πολλαπλών περιουσιακών στοιχείων (όχι μόνο κρυπτονομισμάτων) θα διεύρυνε το πεδίο εφαρμογής του συστήματος, καθιστώντας το κατάλληλο για διαφοροποιημένα χαρτοφυλάκια.

7.2 Προσομοίωση Ανθρώπινων Στρατηγικών Trading

Ο κώδικας που αναφέρεται στο ΠΑΡΑΡΤΗΜΑ Γ αναπτύσσει μια προσομοίωση συναλλαγών που αποσκοπεί στην ανάλυση ανθρώπινων στρατηγικών, χρησιμοποιώντας τεχνικές που συνδυάζουν δυναμικές μετρικές και μηχανισμούς μηχανικής μάθησης. Η προσέγγιση αυτή βασίζεται σε ένα δέντρο αποφάσεων για την πρόβλεψη ενεργειών (αγορά/πώληση), ενσωματώνοντας ταυτόχρονα λογική διαχείρισης κινδύνου και χαρτοφυλακίου.

Λειτουργία

Ο αλγόριθμος λειτουργεί με βάση έναν επαναληπτικό βρόχο που επεξεργάζεται ιστορικές τιμές (prices) και χαρακτηριστικά (features). Για κάθε χρονικό βήμα, υπολογίζονται δυναμικές μετρικές, όπως ο κινητός μέσος όρος επιστροφών (rolling_returns), η μεταβλητότητα (rolling_volatility), και η αναλογία ανταμοιβής-ρίσκου (reward_to_risk_ratio). Αυτές οι μετρικές χρησιμοποιούνται για τον προσδιορισμό ενός δυναμικού ορίου αγοράς/πώλησης (dynamic_threshold), το οποίο προσαρμόζεται ανάλογα με τις τρέχουσες συνθήκες της αγοράς.

Το μοντέλο του δέντρου αποφάσεων (tree_model) εκπαιδεύεται σε παράθυρο ιστορικών δεδομένων (train_window), λαμβάνοντας υπόψη τεχνικούς δείκτες (indicators). Η πρόβλεψη της ενέργειας (predicted_action) βασίζεται στην τρέχουσα κατάσταση των δεικτών, ενώ η πιθανότητα αγοράς (buy_proba) και πώλησης (sell_proba) εξάγονται από τις πιθανότητες πρόβλεψης του μοντέλου.

Η λογική συναλλαγών ενεργοποιείται μόνο όταν η αναμενόμενη απόδοση (profit_term) υπερβαίνει το δυναμικό όριο. Για παράδειγμα, εάν το μοντέλο προβλέψει αγορά (predicted_action == 1) και η αναμενόμενη απόδοση είναι αρκετά υψηλή, ο αλγόριθμος αγοράζει κρυπτονομίσματα αναλογικά προς την πιθανότητα αγοράς (buy_proba) και το διαθέσιμο κεφάλαιο. Αντίστοιχα, σε περίπτωση πώλησης, η ποσότητα που πωλείται εξαρτάται από την πιθανότητα πώλησης και το υπόλοιπο του χαρτοφυλακίου.

Σημασία

Αυτή η προσομοίωση έχει κρίσιμη σημασία για τη σύγκριση μεταξύ ΑΙ και ανθρώπινων στρατηγικών. Επιτρέπει την αντικειμενική αξιολόγηση της απόδοσης των μοντέλων μηχανικής μάθησης έναντι παραδοσιακών μεθόδων, προσφέροντας τεκμηριωμένα συμπεράσματα για τα πλεονεκτήματα και τους περιορισμούς κάθε προσεγγίσεως. Επιπλέον, η χρήση δυναμικών ορίων και μετρικών αντικατοπτρίζει την πολυπλοκότητα των ανθρώπινων αποφάσεων, όπου η αξιολόγηση ρίσκου-ανταμοιβής ενημερώνεται συνεχώς βάσει νέων πληροφοριών.

Δυνατότητες Επέκτασης

Για την ενίσχυση του συστήματος, θα μπορούσε να εισαχθεί ένας μηχανισμός ενισχυτικής μάθησης (reinforcement learning), ο οποίος θα βελτιστοποιούσε τις στρατηγικές συναλλαγών σε πραγματικό χρόνο, λαμβάνοντας υπόψη την ανταπόκριση της αγοράς. Επίσης, η ενσωμάτωση προηγμένων τεχνικών εξατομίκευσης ρίσκου, όπως η προσαρμογή του `risk_factor` ανάλογα με το προφίλ του χρήστη (π.χ., συντηρητικό vs. επιθετικό), θα έδινε μεγαλύτερη ευελιξία στη διαχείριση χαρτοφυλακίων.

Μια άλλη κατεύθυνση θα μπορούσε να είναι η χρήση νευρωνικών δικτύων αντί για δέντρα αποφάσεων, για την καλύτερη αντιμετώπιση μη γραμμικών σχέσεων στα δεδομένα. Επιπλέον, η προσθήκη κοινωνικο-οικονομικών δεικτών (π.χ., δείκτες οικονομικής πολιτικής, συναίσθημα από ειδήσεις) θα διεύρυνε το πλαίσιο λήψης αποφάσεων, δημιουργώντας ένα ολιστικότερο μοντέλο.

Τέλος, η επέκταση του συστήματος για πολλαπλές αγορές (multi-asset trading) και η υποστήριξη παραγώγων χρηματοοικονομικών προϊόντων (π.χ., futures, options) θα μετατρέψει τον κώδικα σε ένα πιο γενικό εργαλείο προσομοίωσης, ικανό να ανταπεξέλθει σε ποικίλα επενδυτικά σενάρια.

7.3 Προσαρμοσμένες Συναρτήσεις Κόστους για Μοντέλα Βαθιάς Μάθησης

Ο κώδικας στα Παραρτήματα ΠΑΡΑΡΤΗΜΑ Δ και ΠΑΡΑΡΤΗΜΑ Ε εισάγει ειδικευμένες συναρτήσεις κόστους για μοντέλα αναδρομικών (RNN) και συνελκτικών (CNN) νευρωνικών δικτύων, οι οποίες επεκτείνουν την κλασική δυαδική εντροπία με στόχο την ευθυγράμμιση των προβλέψεων με πραγματικές οικονομικές επενδυτικές στρατηγικές. Η λειτουργία τους βασίζεται σε έναν συνδυασμό μετρικών που προάγουν όχι μόνο την ακρίβεια, αλλά και την οικονομική βιωσιμότητα των συναλλαγών.

Λειτουργία

Για τα RNN (ΠΑΡΑΡΤΗΜΑ Δ), η συνάρτηση κόστους (`trading_loss`) ενσωματώνει τρεις κύριους όρους. Πρώτον, το βασικό δυαδικό εντροπικό κόστος (`bce_loss`), το οποίο μετρά την απόκλιση μεταξύ προβλεπόμενων και πραγματικών τιμών. Δεύτερον, έναν όρο κερδοφορίας

(profit_reward), ο οποίος ανταμείβει το μοντέλο όταν προβλέπει σωστά την κατεύθυνση της αγοράς. Αυτός υπολογίζεται με βάση τον πολλαπλασιαστή profit_multiplier, ο οποίος αυξάνεται ανάλογα με την εμπιστοσύνη της πρόβλεψης (predicted_proba), και τον όρο direction_correct, που εξαρτάται από τη σύμπτωση προβλέψεων και πραγματικών κινήσεων. Τρίτον, έναν όρο ποινής για υπερβολική βεβαιότητα (confidence_penalty), ο οποίος αποτρέπει το μοντέλο από το να γίνει υπερβολικά σίγουρο για προβλέψεις που ενδέχεται να οδηγούν σε overfitting.

Στην περίπτωση των CNN (ΠΑΡΑΡΤΗΜΑ Ε), η συνάρτηση κόστους επεκτείνεται με έναν ασυμμετρικό όρο (bias_loss) που ευνοεί τις μακροπρόθεσμες συναλλαγές (long_bias = 1.2). Αυτή η ασυμμετρία αντανakλά την εμπειρική παρατήρηση ότι οι μακροπρόθεσμες θέσεις συχνά έχουν διαφορετικό προφίλ κινδύνου-ανταμοιβής σε σύγκριση με τις σύντομες, ιδιαίτερα σε αγορές με τάση για μακροπρόθεσμη άνοδο.

Σημασία

Οι συναρτήσεις αυτές αποτελούν κρίσιμο συστατικό στη βελτίωση της πρακτικής εφαρμογής των μοντέλων ML/DL στο trading. Διαφοροποιούνται από τις τυπικές συναρτήσεις κόστους καθώς εξισορροπούν την ακρίβεια με τη χρηματοοικονομική συνέπεια, κάτι που είναι ζωτικής σημασίας για συστήματα που λειτουργούν σε δυναμικά και θορυβώδη περιβάλλοντα όπως οι χρηματοπιστωτικές αγορές. Επιπλέον, η εισαγωγή όρων όπως η ποινή βεβαιότητας και ο ασυμμετρικός προσανατολισμός βοηθά στην αντιμετώπιση κοινών προκλήσεων όπως το overfitting και η υπερβολική συχνότητα συναλλαγών.

Δυνατότητες Επέκτασης

Μια κατεύθυνση για μελλοντική ανάπτυξη θα μπορούσε να είναι η εισαγωγή δυναμικών συντελεστών που να προσαρμόζονται αυτόματα ανάλογα με τις φάσεις της αγοράς (π.χ., bull/bear markets). Για παράδειγμα, ο συντελεστής long_bias θα μπορούσε να αυξάνεται σε περιόδους άνοδου και να μειώνεται σε ύφεση, βάσει ιστορικών δεδομένων ή προβλέψεων μακροοικονομικών δεικτών. Επιπλέον, θα μπορούσε να εξερευνηθεί η χρήση πολλαπλών στόχων (multi-task learning), όπου το μοντέλο εκπαιδεύεται ταυτόχρονα για πρόβλεψη τιμών και για βελτιστοποίηση παραμέτρων συναλλαγών, όπως το βέλτιστο ποσοστό συμμετοχής. Τέλος, η ενσωμάτωση χρονικής εξάρτησης στους όρους κερδοφορίας, όπως εκπτώσεις για

μακροπρόθεσμες προβλέψεις, θα μπορούσε να βελτιώσει την ικανότητα του συστήματος να αντιμετωπίζει χρονικά εκτεταμένες τάσεις.

7.4 Βελτιστοποίηση Υπερπαραμέτρων με Γενετικό Αλγόριθμο

Ο κώδικας στα Παραρτήματα ΠΑΡΑΡΤΗΜΑ ΣΤ και ΠΑΡΑΡΤΗΜΑ Ζ υλοποιεί έναν γενετικό αλγόριθμο για την αυτόματη βελτιστοποίηση των υπερπαραμέτρων του μοντέλου LightGBM, με στόχο τη μεγιστοποίηση της απόδοσης σε χρονικές σειρές δεδομένων.

Λειτουργία

Η συνάρτηση fitness (ΠΑΡΑΡΤΗΜΑ ΣΤ) αξιολογεί κάθε σύνολο υπερπαραμέτρων με βάση μια χρονική διασταύρωση (TimeSeriesSplit), υπολογίζοντας το μέσο όρο των απωλειών (trading_loss) σε όλες τις πτυχές. Αυτή η προσέγγιση διασφαλίζει ότι οι υπερπαραμέτροι είναι ανθεκτικές σε διαφορετικά χρονικά διαστήματα και αποφεύγουν το overfitting.

Η συνάρτηση μετάλλαξης (ΠΑΡΑΡΤΗΜΑ Ζ) εφαρμόζει μια προσαρμοσμένη λογική για την τυχαία τροποποίηση παραμέτρων, όπως το learning_rate ή το subsample, με βάση πιθανότητες (indpb). Για παράδειγμα, η παράμετρος colsample_bytree περιορίζεται στο εύρος [0.6, 1.0], ενώ το num_leaves μεταβάλλεται με βάση εκθετικούς κανόνες για να διατηρηθεί η εγκυρότητα της δομής του δέντρου.

Σημασία

Αυτός ο συνδυασμός γενετικού αλγορίθμου και χρονικής διασταύρωσης προσφέρει μια συστηματική μέθοδο για την αντιμετώπιση της υπερπαραμετροποίησης σε δυναμικά περιβάλλοντα. Επιπλέον, η προσαρμοσμένη μετάλλαξη εξασφαλίζει ότι οι νέες γενιές παραμέτρων διατηρούν εύλογα όρια, αποφεύγοντας μη ρεαλιστικές τιμές που θα μπορούσαν να υπονομεύσουν τη σταθερότητα του μοντέλου.

Δυνατότητες Επέκτασης

Για περαιτέρω βελτίωση, θα μπορούσε να εισαχθεί ένας πολυκριτηριακός αλγόριθμος (π.χ., NSGA-II) για την ταυτόχρονη βελτιστοποίηση ανταγωνιστικών στόχων, όπως η

μεγιστοποίηση κέρδους και η ελαχιστοποίηση της μεταβλητότητας. Επίσης, η ενσωμάτωση προηγμένων τεχνικών προεκπαίδευσης (warm-starting) θα επέτρεπε στον αλγόριθμο να αξιοποιεί γνώση από προηγούμενες εκτελέσεις, μειώνοντας τον υπολογιστικό κόστος. Τέλος, η επέκταση του συστήματος για την υποστήριξη νευρωνικών δικτύων θα δημιουργούσε ένα ενιαίο πλαίσιο βελτιστοποίησης για ετερογενείς αρχιτεκτονικές μοντέλων.

8 – Συζήτηση και Συμπεράσματα

8.1 Συζήτηση Αποτελεσμάτων

8.1.1 Σύνοψη Κύριων Ευρημάτων

Η πολυεπίπεδη ανάλυση των πειραματικών αποτελεσμάτων αποκάλυψε σημαντικές διαφορές στην αποδοτικότητα μεταξύ των υποδειγμάτων Τεχνητής Νοημοσύνης (TN) και των ανθρώπινων επενδυτικών στρατηγικών. Τα υποδείγματα βαθιάς μάθησης, ιδίως οι αρχιτεκτονικές Multilayered Perceptrons (MLPs) και Convolutional Neural Networks (CNNs), επέδειξαν ανώτερη επίδοση σε δείκτες ταχύτητας επεξεργασίας και ικανότητας ανάλυσης μαζικών δεδομένων, ιδιαίτερα σε περιπτώσεις όπου τα εκπαιδευτικά σύνολα χαρακτηρίζονταν από υψηλό βαθμό καθαρότητας και δομικής συνοχής. Ωστόσο, η μελέτη ανέδειξε κρίσιμους περιορισμούς στην ικανότητα των μοντέλων να προσαρμόζονται δυναμικά σε απρόβλεπτες μεταβολές των οικονομικών συνθηκών, φαινόμενο που υπογραμμίζει την ευαισθησία τους σε καταστάσεις εκτός του εκπαιδευτικού πλαισίου. Σε αυτό το πλαίσιο, το ερωτηματολόγιο που διεξήχθη επιβεβαίωσε ότι οι περισσότεροι συμμετέχοντες θεωρούν κρίσιμη την ανθρώπινη παρέμβαση, ιδίως σε περιόδους αστάθειας ή γεγονότων εκτός προτύπου.

Αντίθετα, οι ανθρώπινες στρατηγικές, βασισμένες σε συνδυασμό εμπειρικής γνώσης, διαισθητικής αντίληψης και ευελιξίας στην ανάλυση πολυδιάστατων παραμέτρων (π.χ. κοινωνικοπολιτικές τάσεις, ψυχολογικά δρώμενα αγοράς), διακρίθηκαν για την ανθεκτικότητά τους σε περιβάλλοντα υψηλής αβεβαιότητας. Συγκεκριμένα, σε προσομοιώσεις ασταθών αγορών κρυπτονομισμάτων, οι μέθοδοι που εφαρμόζονταν από έμπειρους επενδυτές παρήγαγαν σταθερότερα αποτελέσματα μακροπρόθεσμα, κυρίως λόγω της ικανότητας να ενσωματώνουν ποιοτικούς παράγοντες που δεν προκύπτουν άμεσα από αριθμητικά δεδομένα.

Επιπλέον, τα ευρήματα τόνισαν τον κίνδυνο υπερπροσαρμογής (overfitting) σε περιπτώσεις όπου τα εκπαιδευτικά σύνολα περιορίζονταν σε στενά πλαίσια ποικιλομορφίας, γεγονός που υπογράμμισε τη δυσκολία γενίκευσης των TN υποδειγμάτων πέραν των ιστορικών συνθηκών. Αντίστοιχα, η ανθρώπινη κρίση αποδείχθηκε καίρια για την αξιολόγηση μη γραμμικών ή δυσμετρούμενων παραγόντων, οι οποίοι συχνά αποτυπώνονται ατελώς σε ψηφιακά δεδομένα.

Η έρευνα υποστηρίζει τη θεωρία ότι η βέλτιστη απόδοση επιτυγχάνεται μέσω συμβιωτικών υβριδικών προσεγγίσεων, στις οποίες η υπολογιστική ισχύς των ΤΝ συμπληρώνεται με τη διαισθητική ευστροφία των ανθρώπων. Αυτή η συνύπαρξη δεν εξαλείφει απλώς τις αδυναμίες κάθε μεθόδου, αλλά δημιουργεί έναν συνεπή μηχανισμό λήψης αποφάσεων, ικανό να ανταποκρίνεται τόσο σε δομημένες όσο και σε χαοτικές αγορές.

8.1.2 Σύγκριση με τη Βιβλιογραφία

Η σύγκριση των ευρημάτων της παρούσας έρευνας με την υφιστάμενη βιβλιογραφία αποκαλύπτει μια δυναμική αλληλεπίδραση μεταξύ επαληθευμένων παραδοχών και καινοτόμων αποκλίσεων, προσφέροντας νέες προοπτικές στον τομέα των χρηματοοικονομικών εφαρμογών Τεχνητής Νοημοσύνης (ΤΝ). Κατά κύριο λόγο, η χρήση αρχιτεκτονικών βαθιάς μάθησης, όπως των Συνελκτικών Νευρωνικών Δικτύων (CNNs) και των Επαναλαμβανόμενων Νευρωνικών Δικτύων (RNNs), επιβεβαιώνει την αποτελεσματικότητά τους στην ανάλυση χρονοσειρών και την εξαγωγή πολύπλοκων μοτίβων, σε συνέπεια με πρόσφατες εργασίες (π.χ., Afaq, 2021; Matsuo κ.ά., 2022). Η ταχύτητα απόκρισης σε πραγματικό χρόνο και η ικανότητα διαχείρισης μεγάλων όγκων δεδομένων, χαρακτηριστικά που έχουν τεκμηριωθεί και σε προηγούμενες μελέτες (Thakar, 2024), ενισχύουν τη θέση της ΤΝ ως κρίσιμου εργαλείου για εφαρμογές υψηλής συχνότητας (HFT). Παράλληλα, το ερωτηματολόγιο που διεξήχθη στο ανθρώπινο δείγμα αποκάλυψε μια γενική επιφυλακτικότητα απέναντι στην «τυφλή» εμπιστοσύνη στα μοντέλα, ευθυγραμμίζοντας τα συμπεράσματά μας με τη θέση ότι απαιτείται ανθρώπινη συνεισφορά για τη διαχείριση ακραίων σεναρίων.

Ωστόσο, η διαχείριση ακραίων συνθηκών αποτελεί σημείο απόκλισης. Ενώ γενικευμένες προσεγγίσεις, όπως η εφαρμογή τεχνικών dropout για τη βελτίωση της γενίκευσης (Bahoo κ.ά., 2024), προτείνονται ευρέως, τα αποτελέσματα αυτής της μελέτης υπογραμμίζουν ότι η εξειδίκευση σε συγκεκριμένα χαρακτηριστικά της αγοράς κρυπτονομισμάτων μπορεί να αποτελέσει πιο αποτελεσματικό μέσο αντιμετώπισης της υπερπροσαρμογής. Αυτή η διαφοροποίηση ευθυγραμμίζεται με την κριτική του Koukoutsas (2025), ο οποίος επισημαίνει ότι τα μοντέλα που βασίζονται σε γενικευμένες μεθοδολογίες συχνά αγνοούν τη δυναμική ιδιαιτερότητα τοπικών αγορών.

Επιπλέον, η ανθεκτικότητα των ανθρώπινων στρατηγικών σε μη προβλέψιμες αλλαγές, όπως η διακυμάνσεις κοινωνικοοικονομικών παραγόντων, αντιπαραβάλλεται με την ευαισθησία των μοντέλων TN σε δεδομένα εκτός δειγμάτων εκπαίδευσης. Αυτό το εύρημα επαναλαμβάνει τη θέση της διεθνούς βιβλιογραφίας (Wharton, 2025) για την αναγκαιότητα της ενσωμάτωσης ανθρώπινης διαίσθησης σε αυτοματοποιημένες διαδικασίες, ιδιαίτερα σε περιβάλλοντα με υψηλή αβεβαιότητα.

Ένα κρίσιμο ζήτημα που επιβεβαιώνεται και εδώ είναι η ερμηνευσιμότητα των αποτελεσμάτων. Παρά τις τεχνικές εξήγησης, όπως το SHAP και το LIME, η περίπλοκη δομή των μοντέλων βαθιάς μάθησης παραμένει εμπόδιο για την πλήρη διαφάνεια (KPMG, 2025). Η παρούσα έρευνα εντάσσει αυτή την πρόκληση σε ένα ευρύτερο πλαίσιο, προτείνοντας υβριδικά συστήματα όπου η ανθρώπινη κρίση λειτουργεί ως φίλτρο για τις προτάσεις της TN. Αυτή η προσέγγιση, η οποία συμφωνεί με τις προτάσεις του Basiouny (2025), δεν περιορίζεται στην εξισορρόπηση πλεονεκτημάτων, αλλά αποτελεί αναγκαίο βήμα για την ανάπτυξη εμπεριστατωμένων στρατηγικών που λαμβάνουν υπόψη τόσο ποσοτικούς όσο και ποιοτικούς παράγοντες.

Η σύγκριση με τη βιβλιογραφία δεν αποκαλύπτει μόνο θεωρητικές συσχετίσεις, αλλά αναδεικνύει την ανάγκη για διαρκή προσαρμογή των μεθοδολογιών σε έναν δυναμικά μεταβαλλόμενο χώρο. Η σύνθεση των ευρημάτων δείχνει ότι η TN, παρόλο που αποτελεί ισχυρό εργαλείο, απαιτεί συμβιβασμούς και συνεργασία με ανθρώπινες δεξιότητες για να ανταποκριθεί στις πολυδιάστατες απαιτήσεις των σύγχρονων χρηματοοικονομικών αγορών.

8.1.3 Ερμηνεία των Αποτελεσμάτων

Η διερεύνηση των ευρημάτων ανέδειξε καθοριστικούς παράγοντες στη βελτιστοποίηση της εφαρμογής Τεχνητής Νοημοσύνης (TN) στις χρηματοοικονομικές συναλλαγές κρυπτονομισμάτων. Τα πειραματικά δεδομένα επιβεβαίωσαν ότι η επιλογή αλγορίθμων βαθιάς μάθησης, ιδίως εκείνων που εφαρμόζονται σε χρονοσειρές υψηλής διακύμανσης, αποτελεί προϋπόθεση για την αποτελεσματική ανάλυση πολυμεταβλητών και δυναμικών συνόλων δεδομένων. Ωστόσο, η υπερεξάρτηση από προκαθορισμένα εκπαιδευτικά δείγματα, ιδιαίτερα σε περιπτώσεις με περιορισμένη διασπορά πληροφοριών, αποκαλύπτει την ευαισθησία των μοντέλων σε φαινόμενα υπερπροσαρμογής, μειώνοντας την ικανότητά τους για γενίκευση σε μη προσδοκώμενες οικονομικές διακυμάνσεις.

Σε σύγκριση με τις συμβατικές μεθόδους, η ταχύτητα επεξεργασίας των μοντέλων TN προσφέρει ανταγωνιστικό πλεονέκτημα σε σενάρια πραγματικού χρόνου, όπως η ανίχνευση στιγμιαίων τάσεων ή η εκτέλεση αυτοματοποιημένων συναλλαγών. Παράλληλα, η εφαρμογή εξελικτικών αλγορίθμων βελτιστοποίησης (π.χ. γενετικοί αλγόριθμοι) συμβάλλει στη δημιουργία πιο ευέλικτων στρατηγικών, οι οποίες εξισορροπούν την ακρίβεια των προβλέψεων με τη σταθερότητα των αποτελεσμάτων σε μακροπρόθεσμο ορίζοντα. Ως εκ τούτου, η συνεχής προσαρμογή των υπερπαραμέτρων και η ενσωμάτωση δυναμικών δεδομένων αγοράς αποτελούν απαραίτητες προϋποθέσεις για τη διατήρηση της λειτουργικής αποδοτικότητας των συστημάτων.

Αξιοσημείωτη είναι η αντιπαράθεση ανάμεσα στις μηχανικές και ανθρώπινες στρατηγικές. Ενώ τα μοντέλα TN επιδεικνύουν ανώτερη ακρίβεια σε δομημένα ερωτήματα και γραμμικές προβλέψεις, οι επενδυτές διατηρούν το προνόμιο της διαισθητικής αντίληψης μη ποσοτικών παραγόντων, όπως κοινωνικοπολιτικές εξελίξεις ή ψυχολογικά φαινόμενα αγοράς. Αυτή η δίπολη φύση των στρατηγικών υπογραμμίζει την αναγκαιότητα υβριδικών πλαισίων, όπου η συμβολή της ανθρώπινης κρίσης ενισχύει την ερμηνευσιμότητα των μοντέλων, εξαλείφοντας κινδύνους όπως η υπερβολική εμπιστοσύνη σε ιστορικά δεδομένα ή η αδυναμία αντιμετώπισης «μαύρων κύκνων».

Επιπλέον, η έρευνα υπογραμμίζει τη σχέση αντιστάθμισης ανάμεσα στην πολυπλοκότητα των αλγορίθμων και στην πρακτική εφαρμογή τους. Παρόλο που τα πολυστρωματικά νευρωνικά δίκτυα (π.χ. Transformers) προσφέρουν υψηλό επίπεδο μοντελοποίησης, η υπερβολική εξειδίκευσή τους σε συγκεκριμένα χαρακτηριστικά αγοράς μπορεί να οδηγήσει σε δυσκολία προσαρμογής σε νέα κρυπτονομίσματα ή αλλαγές ρυθμιστικών πλαισίων. Αντίθετα, η χρήση συντηρητικότερων αρχιτεκτονικών (π.χ. LSTM) σε συνδυασμό με διαρκώς ενημερωμένες βάσεις δεδομένων φαίνεται να εξασφαλίζει ισορροπία μεταξύ ευελιξίας και αξιοπιστίας.

Η επιτυχία της TN στις χρηματιστηριακές συναλλαγές δεν περιορίζεται στην τεχνική ανωτερότητα των μοντέλων, αλλά εξαρτάται κρίσιμα από τη συμβολή της ανθρώπινης διερεύνησης και τη συστηματική αξιολόγηση των περιορισμών κάθε μεθόδου. Μόνο μέσα από αυτόν τον συνεκτικό συνδυασμό μπορούν να αναπτυχθούν στρατηγικές που ταυτόχρονα μεγιστοποιούν την απόδοση και ελαχιστοποιούν τους κινδύνους σε ένα τόσο δυναμικό και απρόβλεπτο οικοσύστημα όπως οι αγορές κρυπτονομισμάτων.

8.1.4 Σύνδεση με τα Ευρήματα του Ερωτηματολογίου

Τα αποτελέσματα της παρούσας έρευνας υπογραμμίζουν ότι οι αλγοριθμικές στρατηγικές υπερέχουν σε ανάλυση μεγάλου όγκου δεδομένων, όμως παραμένουν ευάλωτες σε γεγονότα εκτός προτύπου. Το ερωτηματολόγιο που απάντησαν 250 συμμετέχοντες επιβεβαιώνει αυτή την άποψη, αφού:

Το 59.2% δήλωσε ότι δεν θα εμπιστευόταν πλήρως ένα μοντέλο TN για τη διαχείριση επενδύσεων, καταδεικνύοντας την ανάγκη για ανθρώπινη επίβλεψη. Το 37.2% εξέφρασε αβεβαιότητα («Ισως»), υποδηλώνοντας ότι η εξήγηση των μοντέλων και η διαφάνεια ενδέχεται να αυξήσουν την εμπιστοσύνη. Μόλις το 3.6% θα εμπιστευόταν πλήρως ένα αυτοματοποιημένο σύστημα, στοιχείο που ευθυγραμμίζεται με τα ευρήματα περί «μαύρων κύκνων».

Επομένως, οι απόψεις των ερωτηθέντων καθιστούν σαφές ότι η ανθρώπινη παράμετρος δεν πρέπει να παραγκωνίζεται. Η διαισθητική αξιολόγηση και ο έλεγχος των αποφάσεων της TN παραμένουν καίριοι, ιδίως σε κρυπτογραφικές αγορές υψηλής μεταβλητότητας.

8.2 Επιπτώσεις για την Αγορά και τους Επενδυτές

8.2.1 Επιπτώσεις στην Αγορά

Η εισαγωγή μοντέλων Τεχνητής Νοημοσύνης (TN) στις συναλλαγές κρυπτονομισμάτων έχει επαναπροσδιορίσει δομικά χαρακτηριστικά της αγοράς, προσδίδοντας ταυτόχρονα δυναμικότητα και νέες προκλήσεις. Οι προσομοιώσεις ανέδειξαν ότι η αυτοματοποιημένη ανάλυση δεδομένων και η ταχεία λήψη αποφάσεων ενισχύουν την ρευστότητα και τη συχνότητα συναλλαγών, μετασχηματίζοντας την κινητικότητα της αγοράς σε επίπεδα που υπερβαίνουν τις παραδοσιακές ανθρώπινες δυνατότητες. Ωστόσο, αυτή η τεχνολογική επέλαση εγείρει ζητήματα αστάθειας, καθώς η συγκέντρωση τακτικών που βασίζονται σε παρόμοια αλγοριθμικά πλαίσια μπορεί να εντείνει τη συσχέτιση των κινήσεων τιμών, δημιουργώντας κινδύνους συστημικής υπερθέρμανσης ή καταρρεύσεων.

Αξιοσημείωτη είναι η διττή επίδραση στην αποδοτικότητα της αγοράς. Από τη μια πλευρά, η TN ελαχιστοποιεί τα ανθρώπινα σφάλματα και βελτιώνει τη διαφάνεια μέσω της

αντικειμενικής επεξεργασίας δεδομένων, μειώνοντας πιθανότητες χειραγώγησης. Από την άλλη, η εξάρτηση από μοντέλα που εκπαιδεύονται σε ιστορικά δεδομένα ενισχύει την τάση προς αναδρομική βελτιστοποίηση, με κίνδυνο να εντείνει κυκλικές διακυμάνσεις ή να ενισχύσει «φούσκες» σε περιπτώσεις όπου τα δεδομένα δεν αντικατοπτρίζουν εξωγενείς παράγοντες. Η παρουσία «μαύρων κύκνων»—γεγονότα χαμηλής πιθανότητας αλλά υψηλής επίδρασης—αποτελεί πρόκληση, καθώς τα περισσότερα μοντέλα TN αδυνατούν να ενσωματώσουν μη γραμμικές, πολυδιάστατες αλληλεπιδράσεις χωρίς ανθρώπινη παρέμβαση.

Επιπλέον, η ταχεία εξέλιξη των αλγοριθμικών στρατηγικών δημιουργεί ρυθμιστικά κενά. Οι υφιστάμενες νομοθετικές αρχές, σχεδιασμένες για ανθρώπινους δράστες, αδυνατούν να αντιμετωπίσουν ζητήματα όπως η ηθική των αυτόνομων συστημάτων, η διασφάλιση της ευθύνης σε περιπτώσεις αστοχίας, ή η προστασία δεδομένων σε πλατφόρμες υψηλής συχνότητας. Η έρευνα υπογραμμίζει την ανάγκη για προσαρμοστικά ρυθμιστικά πλαίσια που θα εξισορροπούν την καινοτομία με την ευρωστία, ενσωματώνοντας μηχανισμούς πραγματικού χρόνου για την παρακολούθηση ύποπτων δραστηριοτήτων και την αποφυγή συστημικών κινδύνων.

Σε μακροπρόθεσμη προοπτική, η TN μπορεί να συμβάλει στη δημοκρατικοποίηση της πρόσβασης σε χρηματοοικονομικές στρατηγικές, μειώνοντας τα εμπόδια εισόδου για μικρούς επενδυτές μέσω αυτοματοποιημένων εργαλείων. Ωστόσο, αυτό εγείρει ηθικά διλήμματα σχετικά με την κατανομή πληροφοριών και τον κίνδυνο ομογενοποίησης των στρατηγικών, όπου η επικράτηση ορισμένων μοντέλων θα μπορούσε να περιορίσει την ποικιλομορφία των επενδυτικών μεθόδων, υπονομεύοντας την αποτελεσματικότητα της αγοράς.

Η ενσωμάτωση της τεχνητής νοημοσύνης στις αγορές κρυπτονομισμάτων απαιτεί μια ολιστική προσέγγιση που συνδυάζει την τεχνολογική υπεροχή με ανθρωποκεντρικούς μηχανισμούς ελέγχου. Μόνο μέσω συνεχούς διαλόγου μεταξύ αλγορίθμων, ρυθμιστικών αρχών και επενδυτών μπορεί να διασφαλιστεί ότι οι τεχνολογικές εξελίξεις εξυπηρετούν τη βιωσιμότητα και τη δικαιοσύνη της αγοράς, αποφεύγοντας παγίδες βραχυπρόθεσμης βελτιστοποίησης.

8.2.2 Επιπτώσεις στους Επενδυτές

Η ένταξη των συστημάτων Τεχνητής Νοημοσύνης (TN) στις χρηματοοικονομικές πρακτικές επανασχεδιάζει ριζικά το προφίλ κινδύνου και απόδοσης που αντιμετωπίζουν οι σύγχρονοι

επενδυτές. Οι προσομοιώσεις καταδεικνύουν ότι, ενώ τα μοντέλα βαθιάς μάθησης προσφέρουν δυνατότητες υπερβατικής επεξεργασίας δεδομένων και ταχείας αντίδρασης, η εξάρτηση από αυτά εισάγει νέους τύπους συστημικών αβεβαιοτήτων. Συγκεκριμένα, η αυτοματοποιημένη βελτιστοποίηση των επενδυτικών αποφάσεων μειώνει το ανθρωπογενές λάθος αλλά εντείνει τον κίνδυνο συσχετισμένων αστοχιών, ιδίως σε συνθήκες ασυνήθιστων αγοραίων διαταραχών, όπου η έλλειψη ανθρώπινης κρίσης μπορεί να οδηγήσει σε καταρράκωση λανθασμένων επιλογών.

Κεντρικό ζήτημα αποτελεί η μετατόπιση της στρατηγικής σκέψης των επενδυτών από την παραδοσιακή ανάλυση αγοράς προς την κατανόηση και την αξιολόγηση αλγοριθμικών εργαλείων. Η ικανότητα ερμηνείας των εξόδων πολύπλοκων μοντέλων, όπως των γενετικών αλγορίθμων ή των νευρωνικών δικτύων με προσοχή (attention mechanisms), γίνεται προαπαιτούμενο για την αποτελεσματική διαχείριση χαρτοφυλακίων. Παράλληλα, η υπερπροσαρμογή των συστημάτων TN σε ιστορικά δεδομένα δημιουργεί μια ψευδαίσθηση ασφάλειας, καθώς οι επενδυτές μπορεί να υποτιμούν την επικινδυνότητα νέων, μη προτύπων γεγονότων—πρόκληση που εντείνεται από την ταχύτατη εξέλιξη των κρυπτονομισμάτων και την έλλειψη μακροχρόνιων δεδομένων.

Σε βάθος χρόνου, η διαφοροποίηση των επενδυτικών στρατηγικών αναδεικνύεται ως κρίσιμος παράγοντας ανθεκτικότητας. Ενώ τα αυτοματοποιημένα συστήματα επιτρέπουν τη βελτιστοποίηση βραχυπρόθεσμων στόχων (π.χ., μεγιστοποίηση κέρδους μέσω high-frequency trading), η ανθρώπινη διορατικότητα παραμένει απαραίτητη για την ανίχνευση μακροοικονομικών τάσεων ή ηθικών διλημμάτων, όπως η συμμετοχή σε μη βιώσιμα πρωτόκολλα blockchain. Η έρευνα υπογραμμίζει ότι η συνύπαρξη TN και ανθρώπινης κρίσης δεν πρέπει να αντιμετωπίζεται ως δίλημμα, αλλά ως συμπληρωματικότητα: η TN προσφέρει ποσοτικές αναλύσεις υψηλής πυκνότητας, ενώ οι επενδυτές εισάγουν ποιοτικούς περιορισμούς και ηθικά πλαίσια που αποτρέπουν την τυφλή βελτιστοποίηση.

Επιπλέον, η προοπτική της «αλγοριθμικής μεροληψίας» (algorithmic bias) εγείρει ανησυχίες για τη δικαιοσύνη στη κατανομή πληροφοριών. Επενδυτές με πρόσβαση σε ανώτερα μοντέλα TN ή μεγαλύτερες υπολογιστικές δυνατότητες κερδίζουν αντιπροσωπευτικό πλεονέκτημα έναντι μικροεπενδυτών, υπονομεύοντας την ισορροπία της αγοράς. Για την αντιμετώπιση αυτού, απαιτείται η δημιουργία ανοιχτών πλατφορμών εκπαίδευσης μοντέλων και η

θεσμοθέτηση κανόνων διαφάνειας για τα εκπαιδευτικά δεδομένα και τις στρατηγικές βελτιστοποίησης.

Τέλος, η μετάβαση προς υβριδικά μοντέλα επενδυτικής διαχείρισης επιβάλλει την αναβάθμιση των δεξιοτήτων των επενδυτών. Η εκπαίδευση σε θέματα όπως η κρυπτογραφική ανάλυση δεδομένων, η στρατηγική διαχείριση υπερπαραμέτρων, και η κριτική αξιολόγηση των ορίων της TN γίνεται ζωτικής σημασίας. Μόνο μέσω μιας ολιστικής προσέγγισης—που ενσωματώνει τεχνολογική ενημέρωση, ηθική ευαισθησία και συνεχή προσαρμοστικότητα—μπορούν οι επενδυτές να αντιμετωπίσουν τις δυναμικές προκλήσεις ενός αγοραίου περιβάλλοντος που διαμορφώνεται ταυτόχρονα από ανθρώπινες και μηχανικές νοημοσύνες.

8.2.3 Επιπτώσεις στις Πλατφόρμες Συναλλαγών

Η έρευνα υπογραμμίζει την αναγκαιότητα ενσωμάτωσης συστημάτων Explainable AI (XAI) στις πλατφόρμες συναλλαγών, με στόχο την προώθηση διαφάνειας και την εδραίωση εμπιστοσύνης μεταξύ χρηστών. Τα εργαλεία XAI, όπως οι μέθοδοι LIME (Local Interpretable Model-agnostic Explanations) και SHAP (SHapley Additive exPlanations), επιτρέπουν την αποσαφήνιση των αποφάσεων που παράγουν τα μοντέλα Τεχνητής Νοημοσύνης (TN), προσφέροντας επεξηγηματικά μοντέλα που αποκωδικοποιούν τη λογική πίσω από προβλέψεις ή συναλλαγές. Αυτή η δυνατότητα δεν απλώς ελαχιστοποιεί την αντίληψη του «μαύρου κουτιού» των αλγορίθμων, αλλά ενδυναμώνει τους επενδυτές να αξιολογούν κριτικά τις στρατηγικές, διατηρώντας παράλληλα τον έλεγχο επί των επενδυτικών διαδικασιών. Η διαφάνεια αυτή αποτελεί προϋπόθεση για τη βιωσιμότητα της συνεργασίας ανθρώπων και μηχανών, ιδιαίτερα σε αγορές υψηλής ριψοκίνδυνου χαρακτήρα, όπως τα κρυπτονομίσματα.

Παράλληλα, η ανάπτυξη προσαρμοστικών αλγορίθμων που ανταποκρίνονται σε ακραία σενάρια αναδεικνύεται ως κρίσιμη πρόκληση. Τα ευρήματα επισημαίνουν ότι η απόδοση των μοντέλων TN μπορεί να υποβαθμιστεί σε περιόδους έντονης αγοραίας διακύμανσης, όπως η εκτίναξη τιμών ή η συστημική ύφεση. Για την αντιμετώπιση αυτού, προτείνεται η εφαρμογή τεχνικών ενισχυτικής μάθησης (reinforcement learning) και προσαρμοστικής βελτιστοποίησης, οι οποίες επιτρέπουν τη δυναμική ρύθμιση παραμέτρων βάσει δεδομένων πραγματικού χρόνου. Η συνεχής επανεκπαίδευση των μοντέλων μέσω ροών δεδομένων που αντικατοπτρίζουν τρέχουσες συνθήκες μπορεί να ενισχύσει την ανθεκτικότητα των πλατφορμών, μειώνοντας τον κίνδυνο αστοχίας σε καταστάσεις εκτός ιστορικών προτύπων.

Επιπλέον, η ενσωμάτωση προσαρμοζόμενων εργαλείων ανάλυσης από τους χρήστες αναδεικνύεται ως στρατηγικό πλεονέκτημα. Μέσω διαδικτυακών διεπαφών που υποστηρίζουν τη δημιουργία προσαρμοσμένων σεναρίων stress-testing, οι επενδυτές μπορούν να προσομοιώσουν την επίδραση απρόβλεπτων γεγονότων (π.χ., ρυθμιστικές αλλαγές, cyberattacks) στις στρατηγικές τους. Αυτή η δυνατότητα όχι μόνο βελτιώνει την εμπειρία χρήσης, αλλά και προάγει την προληπτική λήψη αποφάσεων, μετατρέποντας τις πλατφόρμες σε εργαστήρια στρατηγικής πειραματισμού. Ωστόσο, η αποτελεσματικότητα τέτοιων εργαλείων εξαρτάται από την ισορροπία μεταξύ ευελιξίας και ευχρηστίας, ώστε να αποφεύγεται η υπερφόρτωση των χρηστών με περιττή πολυπλοκότητα.

Η τεχνολογική καινοτομία στις πλατφόρμες συναλλαγών δεν περιορίζεται στη βελτίωση αλγοριθμικής ακρίβειας, αλλά απαιτεί μια ολιστική αναβάθμιση που περιλαμβάνει διαφάνεια, προσαρμοστικότητα και δυναμική αλληλεπίδραση. Μόνο μέσω μιας τέτοιας ολοκληρωμένης προσέγγισης μπορεί να διασφαλιστεί η αξιοπιστία των συστημάτων, η ενδυνάμωση των χρηστών και η ανθεκτικότητα σε ένα περιβάλλον όπου οι αλλαγές είναι ο μόνος σταθερός παράγοντας.

8.3 Συμπεράσματα

Η παρούσα μελέτη επιβεβαιώνει ότι η αποτελεσματική αξιοποίηση της Τεχνητής Νοημοσύνης (TN) στις συναλλαγές κρυπτονομισμάτων απαιτεί τη σύνθεση της αλγοριθμικής δυναμικής με την ανθρώπινη εμπειρία και κρίση. Τα αποτελέσματα του ερωτηματολογίου υποστήριξαν έντονα αυτό το συμπέρασμα: η πλειονότητα των ερωτηθέντων αναγνώρισε τη σημασία της ανθρώπινης εποπτείας, ιδίως σε περιπτώσεις που η αγορά εμφανίζει ακραίες διακυμάνσεις ή συμβάντα μη καταγεγραμμένα στα ιστορικά δεδομένα. Έτσι, προκύπτει η ανάγκη δημιουργίας υβριδικών πλαισίων, στα οποία τα μοντέλα TN παρέχουν ποσοτικές ενδείξεις υψηλής ακρίβειας, ενώ ο ανθρώπινος παράγοντας συμβάλλει στην ερμηνεία, τον έλεγχο και τη διαχρονική προσαρμογή των στρατηγικών. Τα μοντέλα τεχνητής νοημοσύνης επέδειξαν υπεροχή στην ταχεία επεξεργασία πολυμεταβλητών δεδομένων και στην ανίχνευση λανθανόντων προτύπων, ωστόσο η αξιοπιστία τους σε δυναμικά και μη γραμμικά πλαίσια της αγοράς εξαρτήθηκε καθοριστικά από την ενσωμάτωση εμπειρικής γνώσης και διαισθητικών κριτηρίων. Η ανθρώπινη παρέμβαση είναι απαραίτητο συστατικό για την αντιμετώπιση

φαινομένων υψηλής αβεβαιότητας, όπως η διαχείριση μαύρων κύκνων ή η αποκωδικοποίηση κοινωνικοοικονομικών εξελικτικών παραμέτρων που διαφεύγουν της ποσοτικοποίησης.

Η μεθοδολογία της έρευνας ανέδειξε την αναγκαιότητα πολυδιάστατης προσαρμοστικότητας για τη διασφάλιση γενικευσιμότητας. Μοντέλα που ενσωματώνουν δυναμικούς αλγορίθμους εκ νέου εκπαίδευσης (online learning) και ευέλικτες αρχιτεκτονικές (π.χ., μετασχηματιστές με ιεραρχική προσοχή) φαίνεται να διαθέτουν ανώτερη ικανότητα μετάβασης μεταξύ ετερογενών αγορών, διατηρώντας σταθερότητα ακόμη και υπό συνθήκες ρυθμιστικών ανακατατάξεων ή τεχνολογικών διαταραχών. Η συνεχής εμπλοκή νέων δεδομένων, σε συνδυασμό με μεθοδολογίες Explainable AI (XAI), όχι μόνο ενισχύει τη διαφάνεια αλλά και διευκολύνει τη συστηματική αξιολόγηση των μοντέλων από επενδυτές διαφορετικών επιπέδων τεχνογνωσίας, προάγοντας τη συλλογική εμπιστοσύνη στις αυτοματοποιημένες διαδικασίες.

Ακόμα, το ερωτηματολόγιο ανέδειξε ότι περίπου το 55% των ερωτηθέντων εκτιμά πως η TN μπορεί να βελτιώσει τη διαχείριση του κινδύνου, αλλά ταυτόχρονα ανησυχεί για την υπερβολική συγκέντρωση ισχύος σε λίγους διαχειριστές. Αυτό επιβεβαιώνει την ανάγκη υβριδικών εργαλείων που προσφέρουν έλεγχο στον χρήστη, αντί να αντικαθιστούν πλήρως την ανθρώπινη κρίση.

Επιπλέον, τα ευρήματα υπογραμμίζουν ότι η βιωσιμότητα των στρατηγικών εξαρτάται από την ισορροπία μεταξύ αλγοριθμικής αυτονομίας και ανθρωποκεντρικού ελέγχου. Η υιοθέτηση υβριδικών πλαισίων, όπου οι επενδυτές λειτουργούν ως επιβλέποντες και διορθωτές των συστημάτων TN, αποτελεί προϋπόθεση για την αποφυγή παγίδων βραχυπρόθεσμης βελτιστοποίησης, όπως η υπερπροσαρμογή σε ιστορικά δεδομένα ή η αμέλεια ηθικών περιορισμών.

Η έρευνα και τα αποτελέσματα του ερωτηματολογίου προσδιορίζουν την TN όχι ως αντικαταστάτη της ανθρώπινης νοημοσύνης, αλλά ως συντελεστή συμπληρωματικότητας σε ένα διαρκώς εξελισσόμενο οικοσύστημα. Η μελλοντική έρευνα καλείται να διερευνήσει την εφαρμογή νευροσυμβολικών προσεγγίσεων (neuro-symbolic AI) για την ενίσχυση της ερμηνευσιμότητας, καθώς και την ανάπτυξη δεοντολογικών πλαισίων που θα ρυθμίζουν την αλγοριθμική ανάλυση σε πλαίσια κοινωνικής ευθύνης. Τα αποτελέσματα αυτά αποτελούν θεμέλιο λίθο για τη δημιουργία επενδυτικών πρωτοκόλλων που συνδυάζουν τεχνολογική

προηγμένη αρτιότητα με ανθρωποκεντρική φροντίδα, εξασφαλίζοντας τη μακροπρόθεσμη αποτελεσματικότητα και ηθική ακεραιότητα των χρηματοοικονομικών αγορών.

8.3.1 Συμβολή στη Βιβλιογραφία

Η παρούσα μελέτη εμπλουτίζει τον ακαδημαϊκό διάλογο μέσω μιας πρωτοποριακής εμπειρικής αντιπαράθεσης ανάμεσα σε στρατηγικές Τεχνητής Νοημοσύνης (TN) και ανθρώπινης επενδυτικής δραστηριότητας σε αγορές κρυπτονομισμάτων. Εισάγοντας ένα διδακτικό πλαίσιο συγκριτικής ανάλυσης, αποκαλύπτει τις συμπληρωματικές δυνατότητες των δύο προσεγγίσεων, προσφέροντας εμπειριστατωμένα ευρήματα για τη βελτίωση των θεωρητικών και πρακτικών παραμέτρων της χρηματοοικονομικής ανάλυσης. Η έρευνα δεν περιορίζεται στη διαπίστωση διαφορών, αλλά αναδεικνύει συνθετικούς μηχανισμούς βελτιστοποίησης, όπου η αλγοριθμική ακρίβεια ενισχύεται από την ανθρώπινη διαισθητική ευστροφία.

Κεντρική συμβολή αποτελεί η εξειδικευμένη ανάλυση της δυναμικής προσαρμοστικότητας μοντέλων βαθιάς μάθησης (π.χ., πολυστρωματικά νευρωνικά δίκτυα, γενετικοί αλγόριθμοι) σε περιβάλλοντα υψηλής στιγμιαίας μεταβλητότητας. Σε αντίθεση με προηγούμενες εργασίες που εστιάζουν σε στατικές αγορές, αυτή η μελέτη επιχειρηματολογεί υπέρ της συμβολικής εφαρμογής υβριδικών μεθόδων (π.χ., συνδυασμός LSTM με reinforcement learning), οι οποίες εξασφαλίζουν ισορροπία ανάμεσα σε ταχύτητα επεξεργασίας και ικανότητα αντιμετώπισης μη γραμμικών διαταραχών. Τα αποτελέσματα επιβεβαιώνουν ότι η συγχώνευση τεχνικών πολυκριτηριακής βελτιστοποίησης με ανθρωποκεντρικές στρατηγικές αποτελεί καίριο κρίκο για τη μείωση των φαινομένων υπερπροσαρμογής και τη διασφάλιση μακροπρόθεσμης ευστάθειας.

Επιπρόσθετα, η έρευνα συμβάλλει στη θεωρητική κατανόηση της ανθρώπινης ποιοτικής διάκρισης σε συνθήκες ακραίας αβεβαιότητας. Με βάση δεδομένα από πειραματικές προσομοιώσεις, καταδεικνύεται ότι η ανθρώπινη εμπειρία λειτουργεί ως «φίλτρο» για μη ποσοτικούς παράγοντες (π.χ., κοινωνικοπολιτικές κρίσεις, ψυχολογικά φαινόμενα αγοράς), συμπληρώνοντας τα κενά που αφήνουν οι αλγόριθμοι. Αυτή η παρατήρηση εναρμονίζεται με τη συζήτηση της συμπεριφορικής χρηματοοικονομικής, προσφέροντας νέες προοπτικές για τη θεώρηση της ανθρώπινης κρίσης ως αναπόσπαστου στοιχείου στις αυτοματοποιημένες διαδικασίες.

Η μοναδικότητα της έρευνας εντοπίζεται στην επιλογή της αγοράς κρυπτονομισμάτων ως εργαστηρίου μελέτης. Ενώ η συμβατική βιβλιογραφία επικεντρώνεται σε σταθερά ρευστά περιβάλλοντα, αυτή η εργασία αναλύει την απόδοση της TN σε ένα πλαίσιο χαρακτηριζόμενο από εξαιρετική δυναμικότητα και απροβλεψιμότητα. Τα ευρήματα αποτελούν προοίμιο για τη διερεύνηση της TN σε άλλα ασταθή χρηματοοικονομικά οικοσυστήματα (π.χ., decentralized finance, NFTs), όπου η έλλειψη ιστορικών προτύπων απαιτεί καινοτόμες προσεγγίσεις.

Τέλος, η μελέτη θέτει θεμέλια για μεταγενέστερες ερευνητικές πρωτοβουλίες, προτείνοντας την εξέταση νευροσυμβολικών συστημάτων (neuro-symbolic AI) για την ενίσχυση της ερμηνευσιμότητας, καθώς και την ανάπτυξη πολυκριτηριακών δεικτών αξιολόγησης που ενσωματώνουν ηθικές και κοινωνικές διαστάσεις. Αυτά τα ερευνητικά κενά, σε συνδυασμό με την επικαιροποίηση πειραματικών μεθοδολογιών, μπορούν να οδηγήσουν σε ολοκληρωμένα πρότυπα για τη συνύπαρξη τεχνολογικής και ανθρώπινης νοημοσύνης σε δυναμικούς χρηματοοικονομικούς χώρους.

8.4 Μελλοντικές Ερευνητικές Κατευθύνσεις

8.4.1 Υβριδικές Στρατηγικές

Η ανάπτυξη υβριδικών στρατηγικών, οι οποίες συνυφαδίζουν την αλγοριθμική ακρίβεια της Τεχνητής Νοημοσύνης (TN) με τη διαισθητική ευστροφία των ανθρώπινων επενδυτών, αποτελεί καίριο ζητούμενο για τη δημιουργία ολοκληρωμένων και ευέλικτων επενδυτικών πλαισίων. Ο συνδυασμός της ταχύτητας επεξεργασίας δεδομένων και της προγνωστικής ικανότητας της TN με την ανθρώπινη ικανότητα ερμηνείας πολυδιάστατων κοινωνικοοικονομικών δυναμικών προσφέρει μια διπλή ανθεκτικότητα, ιδιαίτερα σε περιβάλλοντα υψηλής αβεβαιότητας. Η προτεινόμενη προσέγγιση βασίζεται στην αρχή της συμπληρωματικότητας, όπου η τεχνολογική ανάλυση ενισχύεται από την ανθρώπινη κριτική αξιολόγηση μη γραμμικών ή μη ποσοτικοποιήσιμων παραγόντων, όπως γεωπολιτικές κρίσεις ή συναισθηματικές τάσεις αγοράς.

Κεντρικό στοιχείο αυτών των στρατηγικών αποτελεί η σχεδίαση ιεραρχικών νευρωνικών αρχιτεκτονικών που ενσωματώνουν πολυτροπικές πηγές δεδομένων. Για παράδειγμα, ένα πρωτεύον νευρωνικό δίκτυο μπορεί να επεξεργάζεται μακροοικονομικούς δείκτες (π.χ., πληθωρισμός, νομισματική πολιτική), ενώ δευτερεύοντα υπομοντέλα εξειδικεύονται σε

χρονοσειρές τιμών, κοινωνικά μέσα ή συναίσθημα αγοράς (sentiment analysis). Η έξοδος αυτών των επιμέρους μοντέλων συγκεντρώνεται σε ένα επίπεδο συνολικής ενοποίησης, όπου εφαρμόζονται τεχνικές ensemble learning ή attention mechanisms για τη δημιουργία ενός πολυδιάστατου προτύπου πρόβλεψης. Αυτή η δομή επιτρέπει τη δυναμική αναβάθμιση του συστήματος μέσω συνεχούς εκπαίδευσης, ενώ ταυτόχρονα διατηρεί την ευελιξία να ενσωματώνει νέους παράγοντες χωρίς δομική ανασκαφή.

Η ανθρώπινη παρέμβαση ενσωματώνεται στο σύστημα ως επίπεδο γνωστικού ελέγχου, όπου οι επενδυτές αξιολογούν και διορθώνουν τις προτάσεις της TN με βάση ποιοτικές παραμέτρους. Για παράδειγμα, ενώ ένα μοντέλο μπορεί να προβλέψει άνοδο τιμών βασισμένο σε ιστορικά μοτίβα, ένας εμπειρογνώμονας μπορεί να εισάγει διορθωτικούς παράγοντες για απρόβλεπτα γεγονότα, όπως ρυθμιστικές αλλαγές ή τεχνολογικές καινοτομίες. Αυτή η αμφίδρομη αλληλεπίδραση μεταξύ αλγορίθμων και ανθρώπων εξαλείφει το φαινόμενο της υπερβολικής εξάρτησης από ιστορικά δεδομένα και ενισχύει τη γενικευσιμότητα των μοντέλων σε νέα σενάρια.

Πέραν της τεχνικής βελτίωσης, οι υβριδικές στρατηγικές προάγουν την ανθρωποκεντρική εμπιστοσύνη στις πλατφόρμες TN. Η χρήση εργαλείων Explainable AI (XAI) για την απεικόνιση της λογικής πίσω από τις αποφάσεις, σε συνδυασμό με τη δυνατότητα επεμβάσεων των χρηστών, μετατρέπει τις πλατφόρμες σε διαδραστικά εργαλεία συνεργατικής νοημοσύνης. Αυτό το μοντέλο δεν περιορίζεται στη βελτίωση της απόδοσης, αλλά επεκτείνεται στην ηθική διαχείριση, αποτρέποντας πρακτικές που βασίζονται αποκλειστικά σε βραχυπρόθεσμα κέρδη ή αμελούν κοινωνικές επιπτώσεις.

Η υλοποίηση υβριδικών στρατηγικών θέτει τις βάσεις για μια νέα γενιά επενδυτικών εργαλείων, ικανών να αντιμετωπίσουν τη δυναμικότητα των σύγχρονων αγορών. Μελλοντικές έρευνες θα μπορούσαν να εστιάσουν στην εφαρμογή νευροσυμβολικών συστημάτων (neuro-symbolic AI) για την ενίσχυση της ερμηνευσιμότητας, καθώς και στην ανάπτυξη πολυκριτηριακών μετρικών αξιολόγησης που ενσωματώνουν τόσο τεχνικές όσο και ηθικές διαστάσεις. Αυτή η διεπιστημονική προσέγγιση μπορεί να οδηγήσει σε στρατηγικές που ισορροπούν την καινοτομία με την ευθύνη, διασφαλίζοντας τη βιωσιμότητα των χρηματοοικονομικών οικοσυστημάτων.

8.4.2 Επεξηγήσιμη Τεχνητή Νοημοσύνη (XAI)

Η ανάγκη για διαφάνεια και ερμηνευσιμότητα στις αποφάσεις των συστημάτων Τεχνητής Νοημοσύνης (TN) αναδεικνύεται ως καίριο ζητούμενο σε τομείς υψηλής κινδύνου, όπως οι χρηματοοικονομικές συναλλαγές. Η εφαρμογή Επεξηγήσιμης TN (Explainable AI - XAI) δεν αποτελεί απλώς τεχνική προϋπόθεση, αλλά θεμελιώδες στοιχείο για την αποδοχή και τη συνεργασία ανάμεσα σε αλγορίθμους και ανθρώπινους χειριστές. Μέθοδοι όπως το LIME (Local Interpretable Model-agnostic Explanations) και το SHAP (SHapley Additive exPlanations) αναδεικνύονται ως κρίσιμα εργαλεία για την αποσαφήνιση της εσωτερικής λογικής πολύπλοκων μοντέλων, ιδιαίτερα σε περιβάλλοντα όπου η αβεβαιότητα κυριαρχεί, όπως οι αγορές κρυπτονομισμάτων.

Το LIME προσφέρει τοπική ερμηνευτικότητα μέσω της δημιουργίας απλοποιημένων μοντέλων (π.χ., γραμμικές προσεγγίσεις) γύρω από συγκεκριμένα σημεία δεδομένων. Αυτή η προσέγγιση επιτρέπει στους χρήστες να αναγνωρίσουν ποιες εισροές (π.χ., τιμές κρυπτονομισμάτων, όγκος συναλλαγών) επηρεάζουν κρίσιμα μια πρόβλεψη, ακόμη και σε μαύρα κουτιά όπως τα νευρωνικά δίκτυα. Για παράδειγμα, σε μια πρόβλεψη αύξησης της αξίας του Bitcoin, το LIME μπορεί να αποκαλύψει ότι η πρόσφατη πτώση των επιτοκίων ή η αύξηση των αναφορών στα κοινωνικά μέσα ήταν καθοριστικοί παράγοντες.

Αντίθετα, το SHAP βασίζεται στη θεωρία συνεργατικών παιγνίων (game theory) για να προσδώσει καθολική ερμηνευτικότητα, αναλύοντας τη συνολική συμβολή κάθε μεταβλητής στο μοντέλο. Μετρά την επίδραση κάθε χαρακτηριστικού συγκρίνοντας όλους τους πιθανούς συνδυασμούς εισροών, προσφέροντας μια μαθηματικά αυστηρή κατανομή της «πιστης» κάθε παραμέτρου. Σε πλατφόρμες συναλλαγών, αυτό μεταφράζεται σε δυνατότητα ανίχνευσης συστημικών προκαταλήψεων (π.χ., υπερεκτίμηση ιστορικών τάσεων) ή εξάρτησης από μη αντιπροσωπευτικά δεδομένα.

Η ενσωμάτωση τέτοιων εργαλείων στις πλατφόρμες TN δεν περιορίζεται στη βελτίωση της διαφάνειας, αλλά ενεργοποιεί δυναμικούς μηχανισμούς ανατροφοδότησης. Οι επενδυτές μπορούν να αναγνωρίσουν ασυνέπειες (π.χ., ευαίσθητη εξάρτηση σε θόρυβο δεδομένων) και να προσαρμόσουν τις στρατηγικές τους, μετατρέποντας τις πλατφόρμες σε συνεχή εργαστήρια βελτιστοποίησης. Παράλληλα, η ερμηνευσιμότητα εξασφαλίζει ότι οι αποφάσεις δεν βασίζονται αποκλειστικά σε αδιαφανείς συσχετίσεις, αλλά σε αιτιολογημένα μοτίβα,

μειώνοντας τον κίνδυνο ηθικών διλημάτων (π.χ., εκμετάλλευση πληροφοριακών ασυμμετριών).

Σε πρακτικό επίπεδο, η ΧΑΙ διευκολύνει την εξισορρόπηση ανάμεσα σε πολυπλοκότητα και απλότητα. Ενώ τα μοντέλα βαθιάς μάθησης διαθέτουν ανώτερη προγνωστική ικανότητα, η δυνατότητα ερμηνείας τους μέσω ΧΑΙ καθιστά δυνατή την προσαρμογή τους σε χρήστες διαφορετικών επιπέδων τεχνογνωσίας. Για παράδειγμα, ένας αρχάριος επενδυτής μπορεί να κατανοήσει βασικές συσχετίσεις μέσω οπτικοποιήσεων SHAP, ενώ ένας ειδικός να αναλύσει λεπτομερώς τις συμβάσεις μεταβλητών για περαιτέρω βελτιστοποίηση.

Η ΧΑΙ δεν αποτελεί απλώς πρόσθετο χαρακτηριστικό, αλλά αναπόσπαστο συστατικό βιώσιμων συστημάτων ΤΝ στις χρηματοοικονομικές αγορές. Η μελλοντική έρευνα θα πρέπει να εστιάσει στην ανάπτυξη υβριδικών πλαισίων ερμηνευσιμότητας, που συνδυάζουν τοπικές και καθολικές μεθόδους, καθώς και στην ενσωμάτωση ηθικών παραμέτρων στις εξηγήσεις. Μόνο έτσι θα μπορέσει να επιτευχθεί μια ολιστική προσέγγιση που εξυπηρετεί τόσο την τεχνική ακρίβεια όσο και την ανθρωποκεντρική αξιοπιστία.

8.4.3 Εφαρμογή σε Σταθερούς Δείκτες Αγοράς

Η ανάλυση της απόδοσης μοντέλων Τεχνητής Νοημοσύνης (ΤΝ) σε σταθερούς χρηματιστηριακούς δείκτες, όπως το NASDAQ και το S&P 500, αποτελεί στρατηγική πρόταση για τη διερεύνηση της μακροπρόθεσμης αξιοπιστίας και ακρίβειάς τους σε περιβάλλοντα με περιορισμένη μεταβλητότητα. Σε αντίθεση με τα κρυπτονομίσματα, τα οποία χαρακτηρίζονται από εκρηκτικές διακυμάνσεις και μη γραμμικές δυναμικές, οι παραδοσιακοί δείκτες προσφέρουν δομημένες χρονοσειρές και προβλέψιμα μοτίβα, καθιστώντας τα ιδανικά εργαστήρια για την αξιολόγηση της δομικής σταθερότητας και της γενικευσιμότητας των αλγορίθμων.

Η εφαρμογή τέτοιων μοντέλων σε σταθερά περιβάλλοντα μπορεί να αποκαλύψει κατά πόσο οι αλγόριθμοι, σχεδιασμένοι για υψηλή δυναμικότητα, διατηρούν την αποτελεσματικότητά τους υπό συνθήκες χαμηλής αβεβαιότητας. Παράλληλα, η μελέτη αυτή επιτρέπει την εξέταση της ικανότητάς τους να αναγνωρίζουν μακροχρονίους τάσεις (π.χ., κύκλους οικονομικής ανάπτυξης, διακυμάνσεις κερδών εταιριών) και να προσαρμόζουν τις στρατηγικές τους σε διαφορετικά επενδυτικά σενάρια, όπως μακροπρόθεσμες επενδύσεις ή διαχείριση κινδύνου.

Μια συγκριτική ανάλυση μεταξύ των αποδόσεων σε σταθερούς δείκτες και σε ευμετάβλητα περιουσιακά στοιχεία (π.χ., Bitcoin) μπορεί να αποτελέσει κρίσιμο εργαλείο για τη βελτιστοποίηση των υπερπαραμέτρων των μοντέλων. Για παράδειγμα, η διαφοροποίηση της μεταβλητότητας μεταξύ αγορών μπορεί να οδηγήσει στην ανάπτυξη εξειδικευμένων αρχιτεκτονικών, όπου τα μοντέλα ρυθμίζουν δυναμικά την ευαισθησία τους σε θόρυβο δεδομένων ή την εστίασή τους σε μακροπρόθεσμους παράγοντες. Αυτή η προσέγγιση ενισχύει τη δυνατότητα δημιουργίας στρατηγικών που ταιριάζουν σε διαφορετικά επενδυτικά προφίλ, από συντηρητικά έως επιθετικά.

Επιπλέον, η έρευνα υπογραμμίζει τη σημασία της κατανόησης της μεταβλητότητας ως καθοριστικού παράγοντα στη συμπεριφορά των μοντέλων TN. Η παρακολούθηση της απόκρισης των αλγορίθμων σε διαφορετικά επίπεδα αγοραίας αστάθειας μπορεί να αποκαλύψει ευπάθειες (π.χ., υπερπροσαρμογή σε χαμηλή θόρυβο) ή ανθεκτικότητες (π.χ., ικανότητα προσαρμογής σε διακυμάνσεις χωρίς ιστορικό πρότυπο). Τα ευρήματα αυτά μπορούν να καθοδηγήσουν τη σχεδίαση προσαρμοστικών συστημάτων που ισορροπούν ανάμεσα σε βραχυπρόθεσμη ανταποκρισιμότητα και μακροπρόθεσμη συνέπεια.

Η εφαρμογή της TN σε σταθερούς δείκτες δεν αποσκοπεί μόνο στη βελτίωση των τεχνολογικών εργαλείων, αλλά και στη δημιουργία μιας ολιστικής θεωρητικής βάσης για τη διαχείριση πολυδιάστατων αγορών. Μελλοντικές έρευνες θα μπορούσαν να επεκτείνουν αυτό το πλαίσιο μελετώντας τη συμβολή νευροσυμβολικών συστημάτων (neuro-symbolic AI) στην ερμηνεία πολύπλοκων αγοραίων δυναμικών, προσφέροντας νέες προοπτικές για τη συνύπαρξη τεχνολογίας και οικονομικής θεωρίας.

8.4.4 Ανάλυση σε Μακροχρόνιες Περιόδους

Η διερεύνηση της μακροπρόθεσμης συμπεριφοράς μοντέλων Τεχνητής Νοημοσύνης (TN) σε χρονικούς ορίζοντες που υπερβαίνουν την πενταετή περίοδο αποτελεί κρίσιμο εργαλείο για την διερευνητική κατανόηση της δυναμικής τους σε μακροοικονομικές τάσεις. Αυτή η προσέγγιση αποκαλύπτει λανθάνοντα μοτίβα και δομικές συσχετίσεις που συχνά παραμένουν αόρατα σε βραχυπρόθεσμες μελέτες, ενώ ταυτόχρονα ενισχύει την ικανότητα των μοντέλων να γενικεύουν προβλέψεις πέραν ιστορικών διακυμάνσεων. Η μακροχρόνια ανάλυση δεν περιορίζεται στην αξιολόγηση της ακρίβειας, αλλά επεκτείνεται στη μελέτη της ικανότητας

των συστημάτων να διαχειρίζονται διαστρεβλωτικούς παράγοντες (π.χ., πληθωρισμικές πιέσεις, τεχνολογικές διαταραχές) σε διαρκή βάση.

Σημαντικότερη είναι η χρονική διαστρωμάτωση των δεδομένων ανά έτος πριν την ολοκληρωτική αξιολόγηση. Αυτή η μεθοδολογία επιτρέπει την ανίχνευση σταδιακών μεταβολών στην απόκριση των μοντέλων σε διαφορετικές φάσεις οικονομικών κύκλων, όπως περιόδους επέκτασης, ύφεσης ή στασιμότητας. Παράλληλα, διευκολύνει την ταυτοποίηση της επίδρασης εξωγενών παραγόντων (π.χ., γεωπολιτικές κρίσεις, ρυθμιστικές ανακατατάξεις) στη συμπεριφορά των αλγορίθμων, προσφέροντας μια πολυεπίπεδη κατανόηση της αλληλεπίδρασης μεταξύ τεχνολογίας και οικονομικού περιβάλλοντος.

Η ανάλυση δεδομένων μακροχρόνιας διάρκειας ενισχύει την εμπειρική αξιοπιστία των ευρημάτων, καθώς επιτρέπει τη δοκιμή των μοντέλων σε πολυάριθμα σενάρια. Για παράδειγμα, η εφαρμογή τους σε περιόδους οικονομικής κρίσης (π.χ., πανδημία COVID-19, οικονομική ύφεση 2008) και ανάκαμψης αποκαλύπτει τόσο την ευελιξία όσο και τις εγγενείς ευπάθειές τους. Τέτοιες δοκιμές μπορούν να καθοδηγήσουν τη βελτιστοποίηση των υπερπαραμέτρων, εστιάζοντας στη μείωση της ευαισθησίας σε θόρυβο δεδομένων και στην ενίσχυση της προσαρμοστικότητας σε μη γραμμικές συμπεριφορές.

Επιπλέον, η μελέτη εκτεταμένων χρονικών περιόδων υπογραμμίζει την ανάγκη για προσαρμοζόμενα συστήματα μάθησης, ικανά να εξισορροπούν βραχυπρόθεσμη ανταποκρισιμότητα με μακροπρόθεσμη συνέπεια. Η ανάπτυξη τέτοιων μοντέλων απαιτεί την ενσωμάτωση τεχνικών όπως η αναδρομική βελτιστοποίηση και η δυναμική ρύθμιση βάρους παραμέτρων βάσει εξελικτικών αλγορίθμων. Παράλληλα, η εισαγωγή κοινωνικοοικονομικών μεταβλητών (π.χ., δείκτες ανισότητας, πολιτική αστάθεια) ως πρόσθετων εισροών μπορεί να βελτιώσει την προγνωστική ικανότητα σε πολυσύνθετα πλαίσια.

Η μακροχρόνια ανάλυση δεν αποτελεί απλώς επέκταση χρονικού παραθύρου, αλλά στρατηγικό πεδίο έρευνας για τη δημιουργία ευέλικτων και ανθεκτικών συστημάτων ΤΝ. Μελλοντικές μελέτες θα μπορούσαν να εστιάσουν στην ανάπτυξη νευροσυμβολικών αρχιτεκτονικών (neuro-symbolic AI), ικανών να συνδυάζουν στατιστική ανάλυση με θεωρητικά οικονομικά μοντέλα, προάγοντας έτσι την ολοκληρωμένη κατανόηση της δυναμικής των αγορών. Αυτή η προσέγγιση μπορεί να οδηγήσει σε επενδυτικά πρωτόκολλα

που διασφαλίζουν τόσο τη βραχυπρόθεσμη αποτελεσματικότητα όσο και τη μακροπρόθεσμη βιωσιμότητα.

8.4.5 Χρήση Ticker Δεδομένων Αντί Λεπτομερών Δεδομένων

Η στρατηγική χρήσης δεδομένων χαμηλής συχνότητας—όπως ημερήσιων ή ωριαίων τιμών κλεισίματος—αντί δεδομένων υψηλής ανάλυσης (π.χ., λεπτουργικών) αποτελεί θεμελιώδη επιλογή σε εφαρμογές όπου η μακροπρόθεσμη σταθερότητα υπερισχύει της βραχυπρόθεσμης ευαισθησίας. Αυτή η προσέγγιση ελαχιστοποιεί την επίδραση του στατιστικού θορύβου, ο οποίος προκύπτει από μη σημαντικές διακυμάνσεις τιμών, και ενισχύει την ικανότητα των μοντέλων Τεχνητής Νοημοσύνης (TN) να εντοπίζουν δομικές τάσεις και μη τετριμμένα μοτίβα. Σε αντίθεση με τις στρατηγικές υψηλής συχνότητας (HFT), που βασίζονται σε στιγμιαίες αλλαγές, η χρήση δεδομένων χαμηλής συχνότητας ευθυγραμμίζεται με επενδυτικές μεθόδους που δίνουν προτεραιότητα στη συνθετική κατανόηση της αγοράς έναντι της υπερβολικής βελτιστοποίησης βάσει μικροκυματικών κινήσεων.

Η επιλογή αυτή αποτελεί κρίσιμο μέσο για την αντιμετώπιση της υπερπροσαρμογής, καθώς τα μοντέλα εκπαιδεύονται σε δεδομένα που αποφεύγουν παροδικές ανωμαλίες ή τεχνητές διακυμάνσεις (π.χ., spoofing, pump-and-dump). Η εστίαση σε μακροσκοπικές τάσεις διευκολύνει τη δημιουργία μοντέλων με ανώτερη γενικευσιμότητα, ικανών να λειτουργούν αποτελεσματικά σε ετερογενή οικονομικά περιβάλλοντα. Για παράδειγμα, η ανάλυση ημερήσιων τιμών Bitcoin μπορεί να αποκαλύψει μακροπρόθεσμες τάσεις προσφοράς-ζήτησης, ενώ τα δεδομένα λεπτού-προς-λεπτό μπορεί να εισάγουν θόρυβο από ασήμαντες διακυμάνσεις χωρίς ουσιαστικό περιεχόμενο.

Επιπλέον, η χρήση δεδομένων χαμηλής συχνότητας βελτιώνει την υπολογιστική αποδοτικότητα, μειώνοντας δραματικά τον όγκο των πληροφοριών που απαιτούν επεξεργασία. Αυτό επιτρέπει την εφαρμογή πολύπλοκων αλγορίθμων (π.χ., Monte Carlo Markov Chains, Bayesian Networks) σε πλατφόρμες με περιορισμένους πόρους, διασφαλίζοντας ισορροπία ανάμεσα σε ακρίβεια και πρακτική εφικτότητα. Παράλληλα, η μείωση της πολυπλοκότητας διευκολύνει τη διασφάλιση της αναπαραγωγιμότητας των αποτελεσμάτων, κρίσιμου παράγοντα για επιστημονικές μελέτες και βιομηχανικές εφαρμογές.

Η αξιοπιστία των προβλέψεων ενισχύεται μέσω της εξομάλυνσης χρονοσειρών, η οποία απομακρύνει ακραίες τιμές και εστιάζει σε μακροπρόθεσμες κινήσεις. Αυτή η διαδικασία συμβάλλει στην ανάδειξη παραγόντων με πραγματική οικονομική σημασία (π.χ., πολιτική αστάθεια, νομισματική πολιτική) έναντι τυχαίου θορύβου. Επιπλέον, η προσέγγιση αυτή υποστηρίζει τη δημιουργία στρατηγικών που βασίζονται σε θεμελιώδη ανάλυση, όπως η αξιολόγηση της μακροοικονομικής ευρωστίας ή των κερδών εταιριών, προσφέροντας μια πιο ολιστική θεώρηση της αγοράς.

Σε πρακτικό επίπεδο, η εφαρμογή αυτών των δεδομένων μπορεί να οδηγήσει στην ανάπτυξη προσανατολισμένων σε ρίσκο μοντέλων, τα οποία εξισορροπούν την αναμενόμενη απόδοση με τη μακροπρόθεσμη σταθερότητα. Για παράδειγμα, η χρήση ωριαίων δεδομένων σε συστήματα διαχείρισης χαρτοφυλακίων μπορεί να ελαχιστοποιήσει την έκθεση σε βραχυπρόθεσμες διακυμάνσεις, διατηρώντας παράλληλα την ευαισθησία σε δομικές αλλαγές.

Η στρατηγική χρήσης δεδομένων χαμηλής συχνότητας δεν αποτελεί απλή τεχνική βελτιστοποίηση, αλλά θεωρητική επιλογή που αντανάκλα την προτίμηση στη βιωσιμότητα έναντι της υπερβολικής πολυπλοκότητας. Μελλοντικές έρευνες θα μπορούσαν να διερευνήσουν τη συνύπαρξη τέτοιων δεδομένων με νευροσυμβολικά συστήματα (neuro-symbolic AI), προκειμένου να ενισχυθεί η ερμηνευσιμότητα και η ενσωμάτωση θεωρητικών οικονομικών μοντέλων. Αυτή η προσέγγιση μπορεί να επαναπροσδιορίσει τον ρόλο της TN στη χρηματοοικονομική ανάλυση, προάγοντας στρατηγικές που συνδυάζουν τεχνολογική προηγμένη αρτιότητα με ορθολογική οικονομική θεώρηση.

8.4.6 Προσαρμογή σε Ακραία Σενάρια

Η αξιολόγηση της ανθεκτικότητας μοντέλων Τεχνητής Νοημοσύνης (TN) σε καταστροφικά ή μη προσδοκώμενα σενάρια—όπως χρηματοοικονομικές καταρρεύσεις, γεωπολιτικές ανακατατάξεις ή συστημικές ρυθμιστικές μεταβολές—αποτελεί θεμελιώδες στοιχείο για την εξέταση των ορίων και της αξιοπιστίας τους. Τέτοιες συνθήκες χαρακτηρίζονται από υπερβατική αβεβαιότητα, εκρηκτικές διακυμάνσεις τιμών και μη γραμμικές αντιδράσεις αγοράς, δοκιμάζοντας την ικανότητα των αλγορίθμων να διατηρούν λειτουργική ακεραιότητα υπό έντονο στρες. Η ανάλυση αυτή δεν περιορίζεται στη μέτρηση της ακρίβειας, αλλά επεκτείνεται στην ανίχνευση συστημικών ευαισθησιών και στην προετοιμασία για τη μείωση της επικινδυνότητας σε καταστροφικές αποτυχίες.

Κεντρικό ζήτημα είναι η ανάδειξη των κρίσιμων παραμέτρων που καθορίζουν την προσαρμοστικότητα των μοντέλων σε συνθήκες έκτακτης ανάγκης. Για παράδειγμα, η έκθεση σε γεγονότα «μαύρων κύκνων» (π.χ., πανδημία COVID-19, ρήξη αλυσίδων εφοδιασμού) μπορεί να αποκαλύψει την εξάρτηση των αλγορίθμων από ιστορικά δεδομένα και την ανεπάρκειά τους στην ενσωμάτωση ριζικά νέων πληροφοριών. Για την αντιμετώπιση αυτών, απαιτείται η ανάπτυξη προληπτικών μηχανισμών, όπως η ενσωμάτωση δεικτών ανωμαλιών (anomaly detection) βασισμένων σε μη-παραμετρικές στατιστικές ή η δυναμική επανεκπαίδευση με χρήση ρευστών δεδομένων πραγματικού χρόνου.

Η βελτίωση της ανθεκτικότητας προϋποθέτει τη σχεδίαση μοντέλων με εγγενή ευελιξία, ικανών να ενσωματώνουν εξελικτικές στρατηγικές βελτιστοποίησης. Τεχνικές όπως οι γενετικοί αλγόριθμοι ή τα συστήματα ενισχυτικής μάθησης (reinforcement learning) με πολλαπλά κριτήρια ανταμοιβής μπορούν να βελτιώσουν την απόκριση σε ακραίες συνθήκες, επιτρέποντας στους αλγορίθμους να «μαθαίνουν» από ιστορικές κρίσεις (π.χ., οικονομική ύφεση 2008, υπερπληθωρισμός της δεκαετίας του 1970). Παράλληλα, η εφαρμογή μοντελοποίησης Monte Carlo για τη δημιουργία χιλιάδων εικονικών σενάριων ενισχύει την προετοιμασία για γεγονότα χαμηλής πιθανότητας αλλά υψηλής επίδρασης.

Σε πρακτικό επίπεδο, η κατανόηση της συμπεριφοράς των μοντέλων υπό στρες μεταφράζεται σε βελτιωμένα εργαλεία διαχείρισης κινδύνου. Η ανάπτυξη συστημάτων που συνδυάζουν προγνωστικά μοντέλα με σεναριογράφηση (scenario planning) επιτρέπει στους επενδυτές να προσομοιώνουν την επίδραση ακραίων γεγονότων σε πραγματικό χρόνο, προσαρμόζοντας τις στρατηγικές τους με βάση ποσοτικές και ποιοτικές προβολές. Αυτή η δυνατότητα δεν απλώς εξασφαλίζει τη διαφύγιση καταστροφών, αλλά και ενισχύει την εμπιστοσύνη στις τεχνολογικές λύσεις, καθιστώντας τες αναπόσπαστο κομμάτι της σύγχρονης χρηματοοικονομικής υποδομής.

Η προσαρμογή σε ακραία σενάρια δεν αφορά μόνο την τεχνική βελτίωση, αλλά την επανεφεύρεση της φιλοσοφίας σχεδιασμού των συστημάτων ΤΝ. Η μελλοντική έρευνα καλείται να εστιάσει στην ανάπτυξη νευροσυμβολικών αρχιτεκτονικών (neuro-symbolic AI), ικανών να συνδυάζουν στατιστική ανάλυση με θεωρητική οικονομική λογική, και στην εισαγωγή δεοντολογικών πλαισίων για την ηθική διαχείριση κινδύνων. Μόνο έτσι θα μπορέσει να επιτευχθεί μια ολιστική προσέγγιση που εξισορροπεί την καινοτομία με την

ανθρωποκεντρική προστασία, διασφαλίζοντας τη βιωσιμότητα των χρηματοοικονομικών οικοσυστημάτων ακόμη και σε συνθήκες υπαρξιακής αβεβαιότητας.

8.4.7 Παράλληλος Υπολογισμός με Χρήση CUDAs

Η αξιοποίηση της παράλληλης επεξεργασίας μέσω της πλατφόρμας CUDA (Compute Unified Device Architecture) αναδεικνύεται ως καθοριστικός παράγοντας για τη μετασχηματιστική βελτίωση της υπολογιστικής απόδοσης σε εφαρμογές Τεχνητής Νοημοσύνης (TN). Η αρχιτεκτονική αυτή, βασισμένη στη δυναμική των Γραφικών Επεξεργαστών (GPUs), επιτρέπει την μαζικώς παράλληλη εκτέλεση πράξεων, μετατρέποντας την εκπαίδευση πολύπλοκων μοντέλων—ιδιαίτερα σε χρονοσειρές υψηλής διακύμανσης όπως των κρυπτονομισμάτων—από μια δαπανηρή διαδικασία σε μια αποδοτική και κλιμακούμενη εργασία.

Η ουσία της CUDA έγκειται στην ικανότητά της να αποσυνθέτει εργασίες σε χιλιάδες νήματα (threads), τα οποία εκτελούνται ταυτόχρονα σε πολλαπλούς πυρήνες GPU. Αυτή η προσέγγιση δεν απλώς μειώνει δραματικά τον χρόνο εκπαίδευσης, αλλά επιτρέπει την επεξεργασία δεδομένων τεραστίου όγκου (big data) σε πραγματικό χρόνο, κάτι απαραίτητο για εφαρμογές όπως η ανάλυση υψηλής συχνότητας (HFT) ή η μοντελοποίηση πολυμεταβλητών χρηματοοικονομικών δυναμικών. Για παράδειγμα, η εκπαίδευση ενός νευρωνικού δικτύου βαθέος μάθησης (Deep Neural Network) με ιστορικά δεδομένα 10 ετών μπορεί να ολοκληρωθεί σε ώρες αντί για ημέρες, χάρη στη βελτιστοποίηση μνήμης και την παράλληλη εκτέλεση γραμμικών αλγεβρικών πράξεων.

Πέραν της ταχύτητας, η CUDA ενεργοποιεί τη συστηματική εξερεύνηση υπερπαραμέτρων μέσω ταυτόχρονης δοκιμής χιλιάδων συνδυασμών. Τεχνικές όπως η Bayesian βελτιστοποίηση ή οι γενετικοί αλγόριθμοι επωφελούνται από την παράλληλη φύση της πλατφόρμας, επιτρέποντας την ταχεία σύγκλιση σε βέλτιστες ρυθμίσεις. Αυτό είναι ιδιαίτερα σημαντικό σε χρηματοοικονομικά μοντέλα, όπου η ακρίβεια εξαρτάται κρίσιμα από τη ρύθμιση παραμέτρων όπως ο ρυθμός μάθησης (learning rate) ή ο βαθμός κανονικοποίησης (dropout).

Η ολοκλήρωση της CUDA σε επενδυτικά πλαίσια υποδηλώνει μια μετάβαση προς υβριδικά συστήματα υπολογισμού, όπου CPUs και GPUs συνεργάζονται για την επίτευξη βέλτιστης απόδοσης. Βιβλιοθήκες όπως η cuDNN (CUDA Deep Neural Network) και η cuBLAS (CUDA

Basic Linear Algebra Subprograms) εξειδικεύονται στην επιτάχυνση μαθηματικών πράξεων που απαιτούνται σε νευρωνικά δίκτυα (π.χ., convolutions, matrix multiplications), ενώ πλαίσια όπως το TensorFlow και το PyTorch έχουν ενσωματώσει εγγενή υποστήριξη για CUDA, διευκολύνοντας τη δημιουργία μοντέλων που εκμεταλλεύονται πλήρως το υλικό.

Σε πρακτικό επίπεδο, η χρήση CUDA μετατρέπει τη θεωρητική δυναμική σε πραγματικό πλεονέκτημα. Για παράδειγμα, η προσομοίωση Monte Carlo για τη μέτρηση κινδύνου σε χαρτοφυλάκια με χιλιάδες περιουσιακά στοιχεία μπορεί να εκτελεστεί σε λεπτά αντί για ώρες, ενώ η εκπαίδευση μετασχηματιστών (Transformers) για πρόβλεψη τιμών κρυπτονομισμάτων γίνεται δυνατή χωρίς την ανάγκη για cloud-based υποδομές. Επιπλέον, η δυνατότητα distributed training σε πολλαπλά GPUs επιτρέπει τη δημιουργία μοντέλων με δισεκατομμύρια παραμέτρους, ικανών να αναλύουν εξαιρετικά πολύπλοκες χρονοσειρές ή να ενσωματώνουν πολυτροπικά δεδομένα (π.χ., κοινωνικά μέσα, δημοσιονομικούς δείκτες).

Η επίδραση της CUDA επεκτείνεται και στην κατανάλωση ενέργειας, καθώς η υψηλή αποδοτικότητα των GPUs μειώνει το ενεργειακό κόστος ανά πράξη σε σύγκριση με παραδοσιακούς επεξεργαστές. Αυτό αποκτά ιδιαίτερη σημασία σε εποχές όπου η βιωσιμότητα των υπολογιστικών υποδομών γίνεται προτεραιότητα.

Η CUDA δεν αποτελεί απλώς ένα εργαλείο επιτάχυνσης, αλλά επανάσταση στην υπολογιστική νοημοσύνη, ιδιαίτερα σε τομείς όπου ο χρόνος και η ακρίβεια είναι κρίσιμοι (π.χ., χρηματοοικονομικές προβλέψεις, latency-sensitive trading). Μελλοντικές έρευνες θα μπορούσαν να εστιάσουν στην ενσωμάτωση νευροσυμβολικών συστημάτων (neuro-symbolic AI) με CUDA-βελτιστοποιημένες βιβλιοθήκες, καθώς και στην ανάπτυξη κβαντικών-CUDA υβριδικών αρχιτεκτονικών για περαιτέρω διάσπαση υπολογιστικών φραγμών. Αυτή η τεχνολογική συνύπαρξη μπορεί να οδηγήσει σε μια νέα εποχή υπολογιστικής δημοκρατίας, όπου η πρόσβαση σε υπερυπολογιστική ισχύ γίνεται καθημερινή πρακτική για ερευνητές και επαγγελματίες.

8.4.8 Κοινωνικοοικονομικές Επιπτώσεις

Η ανάδυση της Τεχνητής Νοημοσύνης (TN) ως καθοριστικού παράγοντα στις χρηματοοικονομικές αγορές εγείρει ζητήματα που αφορούν τη δικαιοσύνη στην πρόσβαση και την επιρροή της στην κοινωνική στρωμάτωση. Παρόλο που τα μοντέλα TN προσφέρουν

αδιαμφισβήτητα πλεονεκτήματα στη βελτιστοποίηση αποφάσεων και στη μείωση λειτουργικού κόστους, η αυξανόμενη εξάρτηση από αυτά ενισχύει δυναμικές που ενδέχεται να εντείνουν τις υφιστάμενες ανισότητες. Η ανισότιμη πρόσβαση σε τεχνολογικές υποδομές και δεδομένα μπορεί να μετατραπεί σε νέο άξονα οικονομικού αποκλεισμού, ιδιαίτερα σε ομάδες χωρίς τεχνολογικό ή οικονομικό κεφάλαιο. Οι θεσμικοί επενδυτές, διαθέτοντας πόρους για την υλοποίηση προηγμένων αλγοριθμικών συστημάτων, αποκτούν ανταγωνιστικό πλεονέκτημα έναντι μικροεπενδυτών, των οποίων οι δυνατότητες περιορίζονται σε βασικές πλατφόρμες. Αυτή η τεχνολογική ανισορροπία ενισχύει τη συγκέντρωση πλούτου σε ολιγάριθμες οντότητες, αναπαράγοντας έναν κύκλο όπου η πρόσβαση σε ΤΝ γίνεται συνάρτηση του κεφαλαίου. Επιπλέον, η αυτοματοποίηση των συναλλαγών μέσω ΤΝ μετατοπίζει την εξουσία από τους παραδοσιακούς μεσάζοντες προς τα αυτοματοποιημένα συστήματα, δημιουργώντας ένα νέο είδος «αλγοκρατίας» όπου οι αποφάσεις λαμβάνονται χωρίς ανθρώπινη μεσολάβηση, με κίνδυνο διάβρωσης της δημοκρατικής εποπτείας.

Τα μοντέλα ΤΝ, εκπαιδευμένα σε ιστορικά δεδομένα που αντικατοπτρίζουν υπάρχουσες κοινωνικοοικονομικές διαστρωματώσεις, διακινδυνεύουν να επαναπαράγουν προκαταλήψεις. Για παράδειγμα, αλγόριθμοι που εξαρτώνται από δεδομένα παλαιότερων περιόδων—όπου η συμμετοχή γυναικών ή μειονοτικών στις αγορές ήταν περιορισμένη—μπορεί να ενισχύσουν ανεπίσημους περιορισμούς πρόσβασης. Παράλληλα, η συστημική προτίμηση σε περιουσιακά στοιχεία με υψηλή ρευστότητα ή μεγάλη κεφαλαιοποίηση οδηγεί σε συγκέντρωση επενδύσεων σε ορισμένους τομείς, όπως η τεχνολογία, ενώ αγνοεί αναπτυσσόμενες αγορές ή κοινωνικο-οικολογικά προγράμματα, διευρύνοντας οικονομικές αποκλίσεις. Η επιρροή των ΤΝ μπορεί να μετατραπεί σε μηχανισμό ενίσχυσης της οικονομικής συγκέντρωσης, όπου τα κεφάλαια ρέουν προς εταιρίες ή περιουσιακά στοιχεία που ευνοούνται από τα μοντέλα, δημιουργώντας ανισορροπίες σε βάθος χρόνου.

Για την αντιμετώπιση αυτών των προκλήσεων, απαιτείται η διαμόρφωση πολιτικών που εξισορροπούν την καινοτομία με την κοινωνική ευθύνη. Μεταξύ των προτεινόμενων παρεμβάσεων περιλαμβάνεται η δημοκρατικοποίηση της ΤΝ μέσω δημιουργίας ανοιχτών πλατφορμών εκπαίδευσης μοντέλων και χρηματοδότησης πρωτοβουλιών που μειώνουν το κόστος πρόσβασης για μικρούς επενδυτές. Επίσης, η εισαγωγή απαιτήσεων για αξιολόγηση της επίδρασης των αλγορίθμων στην κοινωνική δικαιοσύνη πριν την εφαρμογή τους θα μπορούσε να αποτελέσει κρίσιμο βήμα προς τη διαφάνεια. Παράλληλα, η ενσωμάτωση ηθικών κριτηρίων, όπως η δίκαιη κατανομή και η περιβαλλοντική βιωσιμότητα, στις στρατηγικές

βελτιστοποίησης των μοντέλων θα μπορούσε να μετατρέψει την TN σε εργαλείο συλλογικής προόδου.

Η μελλοντική έρευνα οφείλει να εστιάσει στη διερεύνηση εναλλακτικών οικονομικών μοντέλων που ενσωματώνουν την TN χωρίς να θυσιάζουν την κοινωνική συνοχή. Ιδιαίτερο ενδιαφέρον παρουσιάζει η μελέτη μηχανισμών κοινωνικής προστασίας, όπως το καθολικό βασικό εισόδημα, ή φορολογικών μεταρρυθμίσεων που αναδιανέμουν τα κέρδη από την τεχνολογική ανάπτυξη. Επιπλέον, η ανάπτυξη νευροσυμβολικών συστημάτων που συνδυάζουν ηθική λογική με στατιστική ανάλυση θα μπορούσε να προσφέρει λύσεις που ισορροπούν την αποδοτικότητα με την ανθρωποκεντρική φροντίδα. Συνοπτικά, η TN δεν είναι απλώς ένα τεχνολογικό εργαλείο, αλλά κοινωνικό φαινόμενο με δυνατότητα επαναπροσδιορισμού των οικονομικών δομών. Η αποδοχή της πρέπει να συνοδεύεται από συλλογική προσπάθεια για τη δημιουργία ενός πλαισίου όπου η τεχνολογική πρόοδος δεν αποτελεί προνόμιο λίγων, αλλά κίνητρο για μια δίκαιη και συλλογική ανάπτυξη.

ΒΙΒΛΙΟΓΡΑΦΙΑ

Ελληνική

- Emagia (2025) *'The Future of Finance: Επεξεργασία εγγράφων με NLP και AI'*, Emagia. Διαθέσιμο στο: <https://www.emagia.com/el/blog/document-processing-with-nlp-and-ai/>.
- K2varnavas (2024) *'Οι νέες τεχνολογίες και η μελλοντική τους επίδραση στον χρηματοοικονομικό τομέα'*, greeco. Διαθέσιμο στο: <https://greeco.gr/oikonomia/oi-nees-technologies-kai-i-mellontiki-tous-epidraasi-ston-chrimatooikonomiko-tomea/>.
- Koukoutsas, E. (2025) *'Η υιοθέτηση AI στις Χρηματοοικονομικές υπηρεσίες έχει υψηλά επίπεδα απόδοσης'*, AI Report. Διαθέσιμο στο: <https://ai-report.gr/exairetika-epipeda-apodosis-ependysis-gia-tin-yiothetisi-tis-technitis-noimosynis-se-oles-tis-leitourgies-tis-chrimatooikonomikis-me-provlepseis-gia-dynamiki-afxisi/>.
- KPMG (2024) *'KPMG: Πώς η τεχνητή νοημοσύνη μετασχηματίζει την χρηματοοικονομική πληροφόρηση παγκοσμίως'*, FORTUNE GREECE. Διαθέσιμο στο: <https://www.fortunegreece.com/article/kpmg-pos-i-texniti-noimosini-metaximatizei-tin-xrimatooikonomiki-pliroforisi-pagkosmios/>.
- Money Review (2025) *'Τεχνητή νοημοσύνη: Δυναμική αύξηση σε όλες τις λειτουργίες της Χρηματοοικονομικής'*. Διαθέσιμο στο: <https://www.moneyreview.gr/business-and-finance/economy/167034/techniti-noimosyni-dynamiki-ayxisi-se-oles-tis-leitourgies-tis-chrimatooikonomikis/>.
- Γαλανάκη, Σ. (2021) *Μέθοδοι βαθιάς μηχανικής μάθησης για χρηματιστηριακές συναλλαγές* Διπλωματική Εργασία, Εθνικό Μετσόβιο Πολυτεχνείο. Διαθέσιμο στο: <http://artemis.cslab.ece.ntua.gr:8080/jspui/handle/123456789/18206>.
- Ευρωπαϊκό Κοινοβούλιο (2021) *'Τι είναι η τεχνητή νοημοσύνη και πώς χρησιμοποιείται.'* Διαθέσιμο στο: <https://www.europarl.europa.eu/topics/el/article/20200827STO85804/ti-einai-i-techniti-noimosuni-kai-pos-chrisimopoeitai>.
- ΗΜΕΡΗΣΙΑ (2025) *'Έρευνα KPMG: Ταχεία εξάπλωση της τεχνητής νοημοσύνης - Πού χρησιμοποιείται περισσότερο'*. Διαθέσιμο στο: https://www.imerisia.gr/epiheiriseis/104290_ereyna-kpmg-taheia-exaplosi-tis-tehnitis-noimosynis-poy-hrisimopoeitai.
- Κανάς, Α. (2023) *FinTech και Μηχανική Μάθηση: Βασικές Αρχές και Εφαρμογές*: ΠΑΠΑΖΗΣΗΣ.
- Μιχαήλ, Δ. (2024) *Βαθιά ενισχυτική μάθηση για ανάλυση χρηματοοικονομικών δεδομένων και επιλογή κατάλληλων δράσεων*, Αριστοτέλειο Πανεπιστήμιο Θεσσαλονίκης. Διαθέσιμο στο: <https://ikee.lib.auth.gr/record/359859>.

- Ξενοφώντα, Α. Λ. (2023) *Αυτόματη περίληψη κειμένου για χρηματοοικονομικές συναλλαγές*, Αριστοτέλειο Πανεπιστήμιο Θεσσαλονίκης. Διαθέσιμο στο: <https://ikee.lib.auth.gr/record/351857>.
- Παπακώστας, Ι. (2024) *Οι δυνατότητες και οι επιδράσεις της χρηματοοικονομικής τεχνολογίας*, Ελληνικό Ανοικτό Πανεπιστήμιο. Διαθέσιμο στο: <https://apothesis.eap.gr/archive/item/210042>.
- Χατζηχριστοφής, Σ. (2022) *Τεχνητή νοημοσύνη και ανθρώπινα δικαιώματα*, philenews. Διαθέσιμο στο: <https://www.philenews.com/oikonomia/article/1179661/techniti-noimosini-ke-anthropina-dikeomata/>.

Ξένη

- Adigun, A. A. και Yinka-Banjo, C. *'Comparing Stochastic Gradient Descent and Mini-batch Gradient Descent Algorithms in Loan Risk Assessment'*: Springer, Cham.
- Afaq, L. (2021) *Developing a Fully Automated Trading Algorithm for the Cryptocurrency Trading Market* Master's Thesis, LUT University [Online] DOI: <https://lutpub.lut.fi/handle/10024/163617>.
- Bahoo, S., Cucculelli, M., Goga, X. και Mondolo, J. (2024) *'Artificial intelligence in Finance: a comprehensive review through bibliometric and content analysis'*, *SN Business & Economics*. DOI: <https://doi.org/10.1007/s43546-023-00618-x>
- Basiouny, A. (2025) *'AI in 2025: What Challenges Lie Ahead?'*, Knowledge at Wharton. Διαθέσιμο στο: <https://knowledge.wharton.upenn.edu/article/ai-in-2025-what-challenges-lie-ahead/>.
- Binns, R. (2017) *'Fairness in Machine Learning: Lessons from Political Philosophy'*, *cs.CY*. DOI: <https://doi.org/10.48550/arXiv.1712.03586>
- Bryman, A. (2012) *Social Research Methods*: Oxford University Press.
- Buontempo, F. (2019) *Genetic Algorithms and Machine Learning for Programmers: Create AI Models and Evolve Solutions (Pragmatic Programmers)*.
- Cathy, O. N. (2017) *Weapons of Math Destruction - How Big Data Increases Inequality and Threatens Democracy*: Penguin Books Ltd.
- Cecconi, F. (2023) *AI in the Financial Markets : New Algorithms and Solutions*: Springer.
- Davis, O. (2024) *'What is AI in Financial Trading?'*, Large Language Models AI. Διαθέσιμο στο: <https://largelanguagemodels-ai.com/blog/ai-in-financial-trading>.
- Engineering Byte (2025) *'Modern Technologies in Trading: The Rise of AI and GPT Trading'*. Διαθέσιμο στο: <https://www.engineeringbyte.com/the-rise-of-ai-and-chat-gpt-trading>.
- Field, A. (2013) *Discovering Statistics Using IBM SPSS Statistics*: SAGE Publications.
- Floridi, L. (2023) *The Ethics of Artificial Intelligence: Principles, Challenges, and Opportunities*: Oxford University Press.
- Fowler, F. J. (2008) *Survey Research Methods*: SAGE Publications.

- Goodfellow, I., Bengio, Y. και Courville, A. (2016) *Deep Learning (Adaptive Computation and Machine Learning series)*: MIT Press.
- Graham, B. (2003) *Intelligent Investor - The Definitive Book on Value Investing*: HarperCollins Publishers Inc.
- Haykin, S. (2007) *Neural Networks and Learning Machines*.
- Kahneman, D. (2012) *Thinking, Fast and Slow*: Penguin Books Ltd.
- Keim, R. (2019) 'How to Train a Basic Perceptron Neural Network', All About Circuits. Διαθέσιμο στο: <https://www.allaboutcircuits.com/technical-articles/how-to-train-a-basic-perceptron-neural-network/>.
- KPMG (2025) 'KPMG global AI in finance report', Business Mirror. Διαθέσιμο στο: <https://businessmirror.com.ph/2025/01/20/kpmg-global-ai-in-finance-report/>.
- Maggiulli, N. (2022) *Just Keep Buying : Proven ways to save money and build your wealth*: Harriman House Publishing.
- Marks, H. (2020) *Mastering the Market Cycle: Getting the Odds on Your Side*: Nicholas Brealey Publishing.
- Mashrur, A., Luo, W., Zaidi, N. και Robles-Kelly, A. (2020) 'Machine Learning for Financial Risk Management: A Survey', *IEEE Access*. DOI: <http://dx.doi.org/10.1109/ACCESS.2020.3036322>
- Matsuo, Y., LeCun, Y., Sahani, M., Precup, D., Silver, D., Sugiyama, M., Uchibe, E. και Morimoto, J. (2022) 'Deep learning, reinforcement learning, and world models', *Neural Networks*. DOI: <https://doi.org/10.1016/j.neunet.2022.03.037>
- Mittelstadt, B. D., Allo, P., Taddeo, M., Wachter, S. και Floridi, L. (2016) 'The ethics of algorithms: Mapping the debate', *Sage*. DOI: <https://doi.org/10.1177/2053951716679679>
- Odeniyi, O. A., Oyinloye, O. και Thompson, A. (2021) 'Fraud Detection Using Multilayer Perceptron and Convolutional Neural Network'. Διαθέσιμο στο: <https://www.semanticscholar.org/paper/Fraud-Detection-Using-Multilayer-Perceptron-and-Odeniyi-Oyinloye/9acf751e0543b3bcf96b94e10cc11dd4ffce4ed7>
- Papandreou, T. (2025) '2025: Agentic And Physical AI — A Multitrillion Dollar Economy Emerges', *Forbes*. Διαθέσιμο στο: <https://www.forbes.com/sites/timothypapandreou/2025/01/15/2025-agentic--physical-ai-multi-trillion-dollar-economy-emerges/>.
- Perrin, S. και Roncalli, T. (2019) 'Machine Learning Optimization Algorithms & Portfolio Allocation', *SSRN*. DOI: <http://dx.doi.org/10.2139/ssrn.3425827>
- Priatna, W., Purnomo, H., Iriani, A., Sembiring, I. και Wellem, T. (2024) 'Optimizing Multilayer Perceptron with Cost-Sensitive Learning for Addressing Class Imbalance in Credit Card Fraud Detection', *RESTI*. DOI: <https://doi.org/10.29207/resti.v8i4.5917>

- Rudin, C. (2019) '*Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead*', *Nat Mach Intell*. DOI: <https://doi.org/10.1038/s42256-019-0048-x>
- Russel, S. και Norvig, P. (1998) *Artificial intelligence: A modern approach* έκδ: 2 New Jersey, USA: Pearson.
- Russell, S. και Norvig, P. (2020) *Artificial Intelligence: A Modern Approach* έκδ: 4: Pearson.
- Smith, Q.-J. και Valverde, R. (2021) '*A Perceptron Based Neural Network Data Analytics Architecture for the Detection of Fraud in Credit Card Transactions in Financial Legacy Systems*', *WSEAS*. DOI: <https://doi.org/10.37394/23203.2021.16.31>
- Thakar, C. (2024) '*Trading using LLM: Generative AI & Sentiment Analysis in Finance*', QuantInsti. Διαθέσιμο στο: <https://blog.quantinsti.com/trading-using-llm/>.
- Thaler, R. H. (2016) *Misbehaving - The Making of Behavioural Economics*: Penguin Books Ltd.
- Whittlestone, J., Nyrup, R., Alexandrova, A. και Cave, S. (2019) '*The Role and Limits of Principles in AI Ethics: Towards a Focus on Tensions*', *AIES*. DOI: <https://doi.org/10.1145/3306618.3314289>
- Yong, S. (2015), *Feedforward neural networks (multilayer perceptrons)*, University, K.
- Zhao, Y., Stasinakis, C., Sermpinis, G. και Shi, Y. (2017) '*Neural Network Copula Portfolio Optimization for Exchange Traded Funds*', *SSRN*. DOI: <http://dx.doi.org/10.2139/ssrn.2877966>

ΠΑΡΑΡΤΗΜΑΤΑ

ΠΑΡΑΡΤΗΜΑ Α Repository Πλήρη Κώδικα

Σύνδεσμος του repository στο GitHub (Open Source):

<https://github.com/panosru/AI-Trading-Performance-Study>

Το repository περιλαμβάνει τον πλήρη κώδικα της διπλωματικής εργασίας. Έχει γίνει χρήση της Python (με Jupyter Notebooks) για προεπεξεργασία δεδομένων, εκπαίδευση μοντέλων ML/DL (LightGBM, RNN, CNN), προσομοίωση συναλλαγών και αξιολόγηση αποτελεσμάτων.

Οδηγίες εγκατάστασης:

```
git clone https://github.com/panosru/AI-Trading-Performance-Study
pip install -r requirements.txt
```

Ο κώδικας διανέμεται υπό την άδεια Creative Commons Attribution-NonCommercial 4.0 International License (δείτε το αρχείο LICENSE).

ΠΑΡΑΡΤΗΜΑ Β Αποφάσεις Trading για AI Μοντέλα

Ο κώδικας καλύπτει τη διαχείριση των συναλλαγών (αγορά, πώληση, stop loss, take profit) με βάση τις πιθανότητες που προέκυψαν από τα μοντέλα μηχανικής μάθησης. Επίσης, περιλαμβάνει λογική για τη διαχείριση του χαρτοφυλακίου (portfolio management) και την καταγραφή των αποτελεσμάτων για περαιτέρω ανάλυση.

```
1 # Loop over prices_test and use precomputed probabilities
2 for t in range(len(prices_test)):
3     # Default action is 'None'
4     action = 'None'
5     trade_percentage = 0.0
6
7     # Use precomputed probability
8     predicted_proba = smoothed_probas[t]
```

```

10 # Compute confidence: ranges from 0 (proba = 0.5) to 0.5 (proba = 0 or 1)
11 confidence = abs(predicted_proba - 0.5) # 0.0 → not sure, 0.5 → extremely sure
12
13 # Current price
14 current_price = prices_test[t]
15
16 # Check exit conditions first
17 if btc_balance > 0:
18     # Check stop loss or take profit
19     current_value = btc_balance * current_price
20     if current_value <= entry_value * stop_loss_pct:
21         # Execute stop loss
22         usd_balance += current_value * (1 - sell_fee)
23         btc_balance = 0
24         action = 'StopLoss (Long)'
25         stop_loss_count += 1
26     elif current_value >= entry_value * take_profit_pct:
27         # Execute take profit
28         usd_balance += current_value * (1 - sell_fee)
29         btc_balance = 0
30         action = 'TakeProfit (Long)'
31         take_profit_count += 1
32
33 # Check exit conditions for short positions
34 if btc_shorted > 0:
35     current_short_value = btc_shorted * current_price
36     if current_short_value >= short_entry_value * stop_loss_pct:
37         # Execute stop loss for short position
38         usd_balance -= current_short_value * (1 + buy_fee) # Buy back BTC to cover short
39         btc_shorted = 0
40         action = 'StopLoss (Short)'
41         stop_loss_count += 1
42     elif current_short_value <= short_entry_value * take_profit_pct:
43         # Execute take profit for short position
44         usd_balance -= current_short_value * (1 + buy_fee) # Buy back BTC to cover short
45         btc_shorted = 0
46         action = 'TakeProfit (Short)'
47         take_profit_count += 1
48
49 if confidence > min_confidence and btc_balance == 0:
50     # Turn confidence into a fraction of max_trade_fraction
51     # e.g. if confidence=0.4, fraction_to_trade=0.2*(0.4/0.5)=0.16 (i.e. 16% of USD)
52     fraction_to_trade = min(max_trade_fraction * (confidence / 0.5), max_position_size)
53
54 # Long Entry (Buy)
55 if predicted_proba > buy_threshold and usd_balance > 1e-3:
56     # Buy if proba > buy_threshold. The fraction_to_trade goes from 0 to max_trade_fraction (0 to
57     # 20%)
58     usd_spent = fraction_to_trade * usd_balance
59     # Convert to BTC, minus the buy fee
60     btc_bought = (usd_spent * (1 - buy_fee)) / current_price
61     usd_balance -= usd_spent
62     btc_balance += btc_bought
63     entry_value = btc_balance * current_price # Track entry value
64     action = 'Buy'
65     trade_percentage = fraction_to_trade # record how much fraction we traded
66     buy_count += 1

```

```

67     # Short Entry (Sell)
68     elif predicted_proba < sell_threshold and usd_balance > 1e-3 and btc_balance == 0:
69         # Only short if the market is in a clear downtrend
70         # Borrow BTC to sell short
71         if current_price < prices_test[t - 1]: # Simple trend check
72             btc_shorted = fraction_to_trade * (usd_balance / current_price)
73             usd_balance += btc_shorted * current_price * (1 - sell_fee) # Receive USD from short sale
74             short_entry_value = btc_shorted * current_price # Track entry value for short position
75             short_entry_price = current_price # Track entry price for short position
76             action = 'Sell (Short)'
77             trade_percentage = fraction_to_trade
78             short_count += 1
79
80     # Close Long Position (Sell)
81     elif predicted_proba < sell_threshold and btc_balance > 1e-6:
82         # Sell if proba < sell_threshold. fraction_to_trade is again 0 to 20% based on confidence
83         btc_to_sell = fraction_to_trade * btc_balance
84         usd_gained = btc_to_sell * prices_test[t] * (1 - sell_fee)
85         btc_balance -= btc_to_sell
86         usd_balance += usd_gained
87         action = 'Sell (Long)'
88         trade_percentage = fraction_to_trade # record how much fraction we traded
89         sell_count += 1
90
91     # --- Record Data for Plotting ---
92     trading_data.loc[t, 'Action'] = action
93     trading_data.loc[t, 'USD Balance'] = usd_balance
94     trading_data.loc[t, 'BTC Balance'] = btc_balance
95     trading_data.loc[t, 'Total Portfolio Value'] = usd_balance + btc_balance * current_price
96
97     # Record balances and actions
98     total_capital_history.append(usd_balance + btc_balance * current_price)
99     usd_balance_history.append(usd_balance)
100    btc_balance_history.append(btc_balance)

```

Κώδικας 1 - Δομή εκτέλεσης ενεργειών trading για AI μοντέλα

ΠΑΡΑΡΤΗΜΑ Γ Αποφάσεις Trading για Simulators Ανθρωπίνων Στρατηγικών

Ο κώδικας βασίζεται σε δυναμικές μετρικές (όπως η αναλογία ανταμοιβής-ρίσκου) και χρησιμοποιεί ένα μοντέλο δέντρου απόφασης για την πρόβλεψη των ενεργειών (αγορά, πώληση). Επίσης, περιλαμβάνει λογική για τη διαχείριση του χαρτοφυλακίου και την καταγραφή των αποτελεσμάτων.

```

1  # Simulate Trading with Adjusted Risk-Friendly Logic
2  for t in tqdm(range(len(prices)), desc="Processing Rows", unit="rows"):
3      action = 'None'
4      trade_percentage = 0.0
5
6      if t < max(rolling_window, train_window):
7          usd_balances.append(usd_balance)
8          btc_balances.append(btc_balance)
9          actions.append(action)
10         trade_percentages.append(trade_percentage)
11         continue

```

```

13     # Rolling metrics
14     expected_return = rolling_returns[t]
15     volatility = rolling_volatility[t]
16     reward_to_risk_ratio = (expected_return / (volatility + 1e-6)) if volatility > 0 else 0
17     dynamic_threshold = max(profit_threshold, volatility * 0.5)
18     profit_term = expected_return * (1 + risk_factor * reward_to_risk_ratio)
19
20     # Prepare training input_data
21     train_data = features.iloc[t - train_window:t][indicators].values
22     train_target = target.iloc[t - train_window:t].values
23     scaled_train_data = scaler.fit_transform(train_data)
24     tree_model.fit(scaled_train_data, train_target)
25
26     # Predict action
27     current_data = features.iloc[[t]][indicators].values
28     scaled_current_data = scaler.transform(current_data)
29     predicted_action = tree_model.predict(scaled_current_data)[0]
30     predicted_proba = tree_model.predict_proba(scaled_current_data)
31     buy_proba, sell_proba = (
32         predicted_proba[0][1] if predicted_proba.shape[1] > 1 else 0.0,
33         predicted_proba[0][0] if predicted_proba.shape[1] > 1 else 1.0,
34     )
35
36     # Trade logic
37     if predicted_action == 1 and usd_balance > 1e-3 and profit_term > dynamic_threshold:
38         trade_percentage = min(max_trade_percentage * buy_proba, usd_balance / prices[t])
39         usd_spent = trade_percentage * usd_balance
40         btc_bought = (usd_spent * (1 - buy_fee)) / prices[t]
41         usd_balance -= usd_spent
42         btc_balance += btc_bought
43         action = 'Buy'
44
45     elif predicted_action == 0 and btc_balance > 1e-6 and profit_term < -dynamic_threshold:
46         trade_percentage = min(max_trade_percentage * sell_proba, btc_balance)
47         btc_to_sell = trade_percentage * btc_balance
48         usd_gained = btc_to_sell * prices[t] * (1 - sell_fee)
49         btc_balance -= btc_to_sell
50         usd_balance += usd_gained
51         action = 'Sell'
52
53     # Record results
54     usd_balances.append(usd_balance)
55     btc_balances.append(btc_balance)
56     actions.append(action)
57     trade_percentages.append(trade_percentage)

```

Κώδικας 2 - Δομή εκτέλεσης ενεργειών trading για ανθρώπινες στρατηγικές.

ΠΑΡΑΡΤΗΜΑ Δ Loss Function για RNN

Η συνάρτηση αυτή συνδυάζει το δυαδικό εντροπικό κόστος (binary crossentropy) με έναν όρο που ενθαρρύνει κέρδη με βάση τη σωστή πρόβλεψη κατεύθυνσης της αγοράς. Επίσης, περιλαμβάνει έναν όρο ποινής για την υπερβολική βεβαιότητα (confidence penalty) και έναν όρο που ενισχύει τα κέρδη όταν το μοντέλο προβλέπει σωστά.

```

1 # Enhanced loss function with directional profit incentive
2 def trading_loss(prices):
3     def loss_fn(y_true, y_pred):
4         # Base binary crossentropy
5         bce_loss = tf.keras.losses.binary_crossentropy(y_true, y_pred)
6
7         # Enhanced profit incentive
8         direction_correct = tf.sign((y_pred - 0.5) * (y_true - 0.5))
9         profit_multiplier = tf.abs(y_pred - 0.5) * 2 # 0-1 range
10        profit_term = direction_correct * profit_multiplier * prices
11        profit_reward = -0.3 * tf.reduce_mean(profit_term) # Increased from 0.2 to 0.3
12
13        # Confidence penalty adjusted
14        confidence_penalty = 0.005 * tf.reduce_mean(tf.square(y_pred - 0.5)) # Reduced from 0.01
15
16        return tf.reduce_mean(bce_loss + profit_reward + confidence_penalty)
17    return loss_fn

```

Κώδικας 3 - Συνάρτηση Κόστους (Loss Function) για Μοντέλα RNN

ΠΑΡΑΡΤΗΜΑ Ε Loss Function για CNN

Η συνάρτηση αυτή επεκτείνει τη βασική λογική του δυαδικού εντροπικού κόστους με έναν όρο που ενθαρρύνει τα κέρδη, έναν όρο ποινής για την υπερβολική βεβαιότητα και μια ασυμμετρική ποινή που ευνοεί τις μακροπρόθεσμες συναλλαγές (long trades).

```

1 # Enhanced loss function with directional profit incentive
2 def trading_loss(prices):
3     def loss_fn(y_true, y_pred):
4         # Base binary crossentropy
5         bce_loss = tf.keras.losses.binary_crossentropy(y_true, y_pred)
6
7         # Directional profit incentive
8         direction_correct = tf.sign((y_pred - 0.5) * (y_true - 0.5)) # +1 when correct direction
9         profit_multiplier = tf.abs(y_pred - 0.5) * 2 # 0-1 range
10        profit_term = direction_correct * profit_multiplier * prices
11        profit_reward = -0.5 * tf.reduce_mean(profit_term) # Increased profit incentive
12
13        # Confidence penalty to avoid overconfidence
14        confidence_penalty = 0.01 * tf.reduce_mean(tf.square(y_pred - 0.5))
15
16        # Asymmetric loss for long vs. short trades
17        long_bias = 1.2 # Favor long trades slightly
18        trade_bias = tf.where(y_pred > 0.5, long_bias, 1.0) # Apply bias to long trades
19        bias_loss = tf.reduce_mean(trade_bias * bce_loss)
20
21        return tf.reduce_mean(bias_loss + profit_reward + confidence_penalty)
22    return loss_fn

```

Κώδικας 4 - Συνάρτηση Κόστους (Loss Function) για Μοντέλα CNN

ΠΑΡΑΡΤΗΜΑ ΣΤ Fitness Συνάρτηση για Γενετικό Αλγόριθμο

Η συνάρτηση αυτή υπολογίζει την απόδοση ενός συνόλου υπερπαραμέτρων για το μοντέλο LightGBM, χρησιμοποιώντας χρονική διασταύρωση (TimeSeriesSplit) και τη συνάρτηση κόστους trading_loss. Η τελική βαθμολογία είναι ο μέσος όρος των απωλειών (losses) σε όλες τις πτυχές της διασταύρωσης.

```
1 def evaluate(individual, time_steps):
2     # Unpack hyperparameters
3     learning_rate, num_leaves, max_depth, min_child_samples, subsample, colsample_bytree = individual
4
5     # Validate ranges
6     if (learning_rate <= 0 or
7         num_leaves <= 1 or
8         max_depth < 1 or
9         min_child_samples < 1 or
10        subsample <= 0 or subsample > 1.0 or # Changed to prevent subsample >1
11        colsample_bytree <= 0 or colsample_bytree > 1.0):
12        return (float('inf'),)
13
14    # Cross-validation
15    tscv = TimeSeriesSplit(n_splits=3) # Reduced splits for speed
16    fold_losses = []
17
18    for train_idx, val_idx in tscv.split(X_train_val):
19        X_train, X_val = X_train_val[train_idx], X_train_val[val_idx]
20        y_train, y_val = y_train_val[train_idx], y_train_val[val_idx]
21        prices_val_fold = prices[time_steps + len(X_train):time_steps + len(X_train) + len(X_val)]
22
23        # Build model
24        model = LGBMClassifier(
25            learning_rate=learning_rate,
26            num_leaves=int(num_leaves),
27            max_depth=int(max_depth),
28            min_child_samples=int(min_child_samples),
29            subsample=subsample,
30            colsample_bytree=colsample_bytree,
31            n_estimators=100,
32            random_state=42
33        )
34
35        model.fit(X_train, y_train)
36        y_pred_proba = model.predict_proba(X_val)[: , 1]
37
38        # Calculate loss for this fold
39        fold_loss = trading_loss(prices_val_fold, y_val, y_pred_proba)
40        fold_losses.append(fold_loss)
41
42    # Return average loss across folds
43    return (np.mean(fold_losses),)
```

Κώδικας 5 - Συνάρτηση Αξιολόγησης (Fitness Function) για Γενετικό Αλγόριθμο

ΠΑΡΑΡΤΗΜΑ Ζ Συνάρτηση Μετάλλαξης για Γενετικό Αλγόριθμο

Η συνάρτηση `custom_mutate` υλοποιεί μια προσαρμοσμένη λογική μετάλλαξης για τον γενετικό αλγόριθμο. Χρησιμοποιείται για την τυχαία τροποποίηση των υπερπαραμέτρων ενός ατόμου (`individual`), με βάση μια πιθανότητα μετάλλαξης (`indpb`). Η συνάρτηση διαχειρίζεται διαφορετικούς τύπους παραμέτρων (π.χ., `learning rate`, `subsample`, `colsample_bytree`) με διαφορετικούς περιορισμούς, ώστε να διασφαλίζεται η εγκυρότητα των τιμών τους.

```
1 def custom_mutate(individual, indpb):
2     for i in range(len(individual)):
3         if random.random() < indpb:
4             # Learning rate
5             if i == 0:
6                 individual[i] = max(0.01, individual[i] + random.gauss(0, 0.05))
7                 # subsample (index 4) and colsample_bytree (index 5)
8                 elif i in [4,5]: # Handle subsample/colsample
9                     new_val = individual[i] + random.gauss(0, 0.1)
10                    individual[i] = np.clip(new_val, 0.1, 1.0) # Force 0.1-1.0 range
11                # Other parameters
12            else:
13                individual[i] = max(1, individual[i] + random.gauss(0, 0.05))
14    return individual,
```

Κώδικας 6 - Συνάρτηση Μετάλλαξης (Mutation) για Γενετικό Αλγόριθμο