

**ΠΑΝΕΠΙΣΤΗΜΙΟ ΠΕΙΡΑΙΩΣ – ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ****Πρόγραμμα Μεταπτυχιακών Σπουδών****«Πληροφορική»****Μεταπτυχιακή Διατριβή**

Τίτλος Διατριβής	Η Αξιοποίηση της Τεχνητής Νοημοσύνης στον Οικονομικό Κλάδο: Πρόβλεψη Τιμών Μετοχών με τη Χρήση Μηχανικής Μάθησης The Utilization of Artificial Intelligence in the Economic Sector: Forecasting Stock Prices Using Machine Learning
Όνοματεπώνυμο Φοιτητή	Μιχαήλ Παπανικόλας
Πατρώνυμο	Σπύρος
Αριθμός Μητρώου	ΜΠΠΛ20059
Επιβλέπων	Θεμιστοκλής Παναγιωτόπουλος, Καθηγητής

Ημερομηνία Παράδοσης **Φεβρουάριος 2023**

Τριμελής Εξεταστική Επιτροπή

Θεμιστοκλής
Παναγιωτόπουλος
Καθηγητής

Άγγελος Πικράκης
Επίκουρος Καθηγητής

Δημήτριος Αποστόλου
Καθηγητής

Περιεχόμενα

Κατάλογος Πινάκων – Διαγραμμάτων	5
Περίληψη	7
Abstract	8
Εισαγωγή	9
Κεφάλαιο 1^ο: Τεχνητή Νοημοσύνη	
1.1 Ο Όρος Τεχνητή Νοημοσύνη	10
1.2 Ιστορική Αναδρομή	11
1.3 Νευρωνικά Δίκτυα	13
1.4 Εκπαίδευση Νευρωνικών Δικτύων	14
1.5 Δημιουργία Νευρωνικών Δικτύων Μέσω της Βιβλιοθήκης Tensorflow	15
Κεφάλαιο 2^ο: Natural Language Processing (NLP)	
2.1 Ο Όρος NLP	17
2.2 Ιστορική Αναδρομή NLP	18
2.3 Τεχνικές NLP	19
2.4 Εφαρμογές NLP	20
2.5 Εξέλιξη NLP	20
Κεφάλαιο 3^ο: Μηχανική Μάθηση	
3.1 Ο Όρος Μηχανική Μάθηση	22
3.2 Ιστορική Αναδρομή της Μηχανικής Μάθησης	23
3.3 Τμηματοποίηση Πελατών – Ιεραρχική Ομαδοποίηση	24
3.4 Τμηματοποίηση Πελατών – Αλγόριθμος k-Means	25
3.5 Το Πρόβλημα των Unbalanced Data	27
3.6 Ανίχνευση Απάτης	27
3.7 Προχωρημένες Τεχνικές Ταξινόμησης	28
3.8 Credit Scoring	29
Κεφάλαιο 4^ο: Πρόβλεψη Τιμών Μετοχών με τη Χρήση Μηχανικής Μάθησης	
4.1 Πρόβλεψη Τιμών Μετοχών	31
4.2 Αναγκαιότητα Πρόβλεψης Τιμών Μετοχών	32
4.3 Η Μηχανική Μάθηση στην Πρόβλεψη Τιμών Μετοχών	33
Κεφάλαιο 5^ο: Ανάπτυξη Εφαρμογής	
5.1 Στάδια Σχεδιασμού	36
5.2 Παρουσίαση Κώδικα Εφαρμογής	40
Κεφάλαιο 6^ο: Παραδείγματα Εφαρμογής	
6.1 Παράδειγμα Μετοχής Apple	43
6.2 Παράδειγμα Μετοχής Facebook	52
6.3 Παράδειγμα Μετοχής Microsoft	60
6.4 Παράδειγμα Μετοχής Tesla	68
6.5 Παράδειγμα Μετοχής Google	76
Κεφάλαιο 7^ο: Ανάλυση Αποτελεσμάτων από την Πρόβλεψη Τιμών Μετοχών	
7.1 Ανάλυση Αποτελεσμάτων Μετοχής: Apple	84
7.2 Ανάλυση Αποτελεσμάτων Μετοχής: Facebook	85
7.3 Ανάλυση Αποτελεσμάτων Μετοχής: Microsoft	86
7.4 Ανάλυση Αποτελεσμάτων Μετοχής: Tesla	87
7.5 Ανάλυση Αποτελεσμάτων Μετοχής: Google	88

Συμπεράσματα	89
Προτάσεις για Μελλοντική Έρευνα	89
Βιβλιογραφία	90

Κατάλογος Εικόνων

Εικόνα 1: Μηχανή Παιχνιδιού Σκακιού «Ο Τούρκος».....	12
Εικόνα 2: Νευρωνικό Δίκτυο.....	14
Εικόνα 3: Natural Language Processing.....	18
Εικόνα 4: Τυπική Προσέγγιση Μηχανικής Μάθησης.....	22
Εικόνα 5: Αλγόριθμος K-means.....	26
Εικόνα 6: Διαδικασία του Αλγόριθμου Ομαδοποίησης K-means.....	26
Εικόνα 7: Καταμέτρηση Απάτης και Μη Απάτης.....	28
Εικόνα 8: Βιβλιοθήκες Εφαρμογής.....	37
Εικόνα 9: Φόρτωση Δεδομένων.....	37
Εικόνα 10: Προετοιμασία Δεδομένων.....	38
Εικόνα 11: Κατασκευή Μοντέλου.....	38
Εικόνα 12: Φόρτωση Δεδομένων Δοκιμής.....	39
Εικόνα 13: Πραγματοποιεί Προβλέψεις για τα Δεδομένα Δοκιμής.....	39
Εικόνα 14: Σχεδίασε τις Προβλέψεις του Test.....	39
Εικόνα 15: Πρόβλεψη της Επόμενης Ημέρας.....	40
Εικόνα 16: Κώδικας Εφαρμογής 1.....	40
Εικόνα 17: Κώδικας Εφαρμογής 2.....	41
Εικόνα 18: Κώδικας Εφαρμογής 3.....	41
Εικόνα 19: Κώδικας Εφαρμογής 4.....	42
Εικόνα 20: Πρόβλεψη Τιμής Μετοχής Apple (Πρώτη Ημέρα).....	43
Εικόνα 21: Διάγραμμα Μετοχής Apple (Πρώτη Ημέρα).....	43
Εικόνα 22: Τιμή Κλεισίματος Μετοχής Apple (Πρώτη Ημέρα).....	44
Εικόνα 23: Πρόβλεψη Τιμής Μετοχής Apple (Δεύτερη Ημέρα).....	45
Εικόνα 24: Διάγραμμα Μετοχής Apple (Δεύτερη Ημέρα).....	45
Εικόνα 25: Τιμή Κλεισίματος Μετοχής Apple (Δεύτερη Ημέρα).....	46
Εικόνα 26: Πρόβλεψη Τιμής Μετοχής Apple (Τρίτη Ημέρα).....	46
Εικόνα 27: Διάγραμμα Μετοχής Apple (Τρίτη Ημέρα).....	47
Εικόνα 28: Τιμή Κλεισίματος Μετοχής Apple (Τρίτη Ημέρα).....	47
Εικόνα 29: Πρόβλεψη Τιμής Μετοχής Apple (Τέταρτη Ημέρα).....	48
Εικόνα 30: Διάγραμμα Μετοχής Apple (Τέταρτη Ημέρα).....	48
Εικόνα 31: Τιμή Κλεισίματος Μετοχής Apple (Τέταρτη Ημέρα).....	49
Εικόνα 32: Πρόβλεψη Τιμής Μετοχής Apple (Πέμπτη Ημέρα).....	49
Εικόνα 33: Διάγραμμα Μετοχής Apple (Πέμπτη Ημέρα).....	50
Εικόνα 34: Τιμή Κλεισίματος Μετοχής Apple (Πέμπτη Ημέρα).....	50
Εικόνα 35: Πρόβλεψη Τιμής Μετοχής Facebook (Πρώτη Ημέρα).....	52
Εικόνα 36: Διάγραμμα Μετοχής Facebook (Πρώτη Ημέρα).....	52
Εικόνα 37: Τιμή Κλεισίματος Μετοχής Facebook (Πρώτη Ημέρα).....	53
Εικόνα 38: Πρόβλεψη Τιμής Μετοχής Facebook (Δεύτερη Ημέρα).....	53
Εικόνα 39: Διάγραμμα Μετοχής Facebook (Δεύτερη Ημέρα).....	54
Εικόνα 40: Τιμή Κλεισίματος Μετοχής Facebook (Δεύτερη Ημέρα).....	54
Εικόνα 41: Πρόβλεψη Τιμής Μετοχής Facebook (Τρίτη Ημέρα).....	55
Εικόνα 42: Διάγραμμα Μετοχής Facebook (Τρίτη Ημέρα).....	55
Εικόνα 43: Τιμή Κλεισίματος Μετοχής Facebook (Τρίτη Ημέρα).....	56
Εικόνα 44: Πρόβλεψη Τιμής Μετοχής Facebook (Τέταρτη Ημέρα).....	56
Εικόνα 45: Διάγραμμα Μετοχής Facebook (Τέταρτη Ημέρα).....	57
Εικόνα 46: Τιμή Κλεισίματος Μετοχής Facebook (Τέταρτη Ημέρα).....	57
Εικόνα 47: Πρόβλεψη Τιμής Μετοχής Facebook (Πέμπτη Ημέρα).....	58
Εικόνα 48: Διάγραμμα Μετοχής Facebook (Πέμπτη Ημέρα).....	58
Εικόνα 49: Τιμή Κλεισίματος Μετοχής Facebook (Πέμπτη Ημέρα).....	59
Εικόνα 50: Πρόβλεψη Τιμής Μετοχής Microsoft (Πρώτη Ημέρα).....	60
Εικόνα 51: Διάγραμμα Μετοχής Microsoft (Πρώτη Ημέρα).....	60
Εικόνα 52: Τιμή Κλεισίματος Μετοχής Microsoft (Πρώτη Ημέρα).....	61

Εικόνα 53: Πρόβλεψη Τιμής Μετοχής Microsoft (Δεύτερη Ημέρα).....	61
Εικόνα 54: Διάγραμμα Μετοχής Microsoft (Δεύτερη Ημέρα).....	62
Εικόνα 55: Τιμή Κλεισίματος Μετοχής Microsoft (Δεύτερη Ημέρα).....	62
Εικόνα 56: Πρόβλεψη Τιμής Μετοχής Microsoft (Τρίτη Ημέρα).....	63
Εικόνα 57: Διάγραμμα Μετοχής Microsoft (Τρίτη Ημέρα).....	63
Εικόνα 58: Τιμή Κλεισίματος Μετοχής Microsoft (Τρίτη Ημέρα).....	64
Εικόνα 59: Πρόβλεψη Τιμής Μετοχής Microsoft (Τέταρτη Ημέρα).....	64
Εικόνα 60: Διάγραμμα Μετοχής Microsoft (Τέταρτη Ημέρα).....	65
Εικόνα 61: Τιμή Κλεισίματος Μετοχής Microsoft (Τέταρτη Ημέρα).....	65
Εικόνα 62: Πρόβλεψη Τιμής Μετοχής Microsoft (Πέμπτη Ημέρα).....	66
Εικόνα 63: Διάγραμμα Μετοχής Microsoft (Πέμπτη Ημέρα).....	66
Εικόνα 64: Τιμή Κλεισίματος Μετοχής Microsoft (Πέμπτη Ημέρα).....	67
Εικόνα 65: Πρόβλεψη Τιμής Μετοχής Tesla (Πρώτη Ημέρα).....	68
Εικόνα 66: Διάγραμμα Μετοχής Tesla (Πρώτη Ημέρα).....	68
Εικόνα 67: Τιμή Κλεισίματος Μετοχής Tesla (Πρώτη Ημέρα).....	69
Εικόνα 68: Πρόβλεψη Τιμής Μετοχής Tesla (Δεύτερη Ημέρα).....	69
Εικόνα 69: Διάγραμμα Μετοχής Tesla (Δεύτερη Ημέρα).....	70
Εικόνα 70: Τιμή Κλεισίματος Μετοχής Tesla (Δεύτερη Ημέρα).....	70
Εικόνα 71: Πρόβλεψη Τιμής Μετοχής Tesla (Τρίτη Ημέρα).....	71
Εικόνα 72: Διάγραμμα Μετοχής Tesla (Τρίτη Ημέρα).....	71
Εικόνα 73: Τιμή Κλεισίματος Μετοχής Tesla (Τρίτη Ημέρα).....	72
Εικόνα 74: Πρόβλεψη Τιμής Μετοχής Tesla (Τέταρτη Ημέρα).....	72
Εικόνα 75: Διάγραμμα Μετοχής Tesla (Τέταρτη Ημέρα).....	73
Εικόνα 76: Τιμή Κλεισίματος Μετοχής Tesla (Τέταρτη Ημέρα).....	73
Εικόνα 77: Πρόβλεψη Τιμής Μετοχής Tesla (Πέμπτη Ημέρα).....	74
Εικόνα 78: Διάγραμμα Μετοχής Tesla (Πέμπτη Ημέρα).....	74
Εικόνα 79: Τιμή Κλεισίματος Μετοχής Tesla (Πέμπτη Ημέρα).....	75
Εικόνα 80: Πρόβλεψη Τιμής Μετοχής Google (Πρώτη Ημέρα).....	76
Εικόνα 81: Διάγραμμα Μετοχής Google (Πρώτη Ημέρα).....	76
Εικόνα 82: Τιμή Κλεισίματος Μετοχής Google (Πρώτη Ημέρα).....	77
Εικόνα 83: Πρόβλεψη Τιμής Μετοχής Google (Δεύτερη Ημέρα).....	77
Εικόνα 84: Διάγραμμα Μετοχής Google (Δεύτερη Ημέρα).....	78
Εικόνα 85: Τιμή Κλεισίματος Μετοχής Google (Δεύτερη Ημέρα).....	78
Εικόνα 86: Πρόβλεψη Τιμής Μετοχής Google (Τρίτη Ημέρα).....	79
Εικόνα 87: Διάγραμμα Μετοχής Google (Τρίτη Ημέρα).....	79
Εικόνα 88: Τιμή Κλεισίματος Μετοχής Google (Τρίτη Ημέρα).....	80
Εικόνα 89: Πρόβλεψη Τιμής Μετοχής Google (Τέταρτη Ημέρα).....	80
Εικόνα 90: Διάγραμμα Μετοχής Google (Τέταρτη Ημέρα).....	81
Εικόνα 91: Τιμή Κλεισίματος Μετοχής Google (Τέταρτη Ημέρα).....	81
Εικόνα 92: Πρόβλεψη Τιμής Μετοχής Google (Πέμπτη Ημέρα).....	82
Εικόνα 93: Διάγραμμα Μετοχής Google (Πέμπτη Ημέρα).....	82
Εικόνα 94: Τιμή Κλεισίματος Μετοχής Google (Πέμπτη Ημέρα).....	83
Εικόνα 95: Συγκεντρωτικό γράφημα πέντε ημερών μετοχής Apple.....	84
Εικόνα 96: Συγκεντρωτικό γράφημα πέντε ημερών μετοχής Facebook	85
Εικόνα 97: Συγκεντρωτικό γράφημα πέντε ημερών μετοχής Microsoft.....	86
Εικόνα 98: Συγκεντρωτικό γράφημα πέντε ημερών μετοχής Tesla.....	87
Εικόνα 99: Συγκεντρωτικό γράφημα πέντε ημερών μετοχής Google.....	88

Περίληψη

Η πρόβλεψη τιμών των μετοχών είναι ένα από τα θέματα με τη μεγαλύτερη έρευνα και συγκεντρώνει το ενδιαφέρον πολλών επιστημών και επενδυτών. Η ακριβής πρόβλεψη των αποδόσεων της χρηματιστηριακής αγοράς είναι πολύ δύσκολο έργο λόγω της ασταθούς και μη γραμμικής φύσης των χρηματοπιστωτικών αγορών. Με την εμφάνιση της Τεχνητής Νοημοσύνης (AI) και τις αυξημένες υπολογιστικές δυνατότητες, έχουν χρησιμοποιηθεί πολλοί αλγόριθμοι για την πρόβλεψη της κίνησης της αγοράς των μετοχών. Η συνδυασμένη εφαρμογή αλγορίθμων μηχανικής μάθησης (ML) και στατιστικών έχει σχεδιαστεί για την πρόβλεψη της τιμής της μετοχής την επόμενη ημέρα είτε για την κατανόηση της μακροπρόθεσμης αγοράς στο μέλλον. Σκοπός της παρούσας εργασίας είναι η διερεύνηση των διαφορετικών τεχνικών που χρησιμοποιούνται για την πρόβλεψη των τιμών των μετοχών από τις παραδοσιακές μεθόδους βαθιάς μάθησης και μηχανικής μάθησης έως τα νευρωνικά δίκτυα και τις προσεγγίσεις που βασίζονται σε γραφήματα. Ακόμα, σε αυτήν την εργασία οι τεχνικές πρόβλεψης έχουν χρησιμοποιηθεί για την πρόβλεψη της τιμής κλεισίματος της επόμενης ημέρας για πέντε μεγάλες εταιρίες. Τέλος, εμπεριέχει μια λεπτομερή ανάλυση των τεχνικών που χρησιμοποιούνται για την πρόβλεψη των τιμών των μετοχών καθώς και διερευνά τις προκλήσεις που συνεπάγονται μαζί με το μελλοντικό πεδίο εργασίας στον τομέα.

Λέξεις κλειδιά: Τεχνητή Νοημοσύνη, Μηχανική Μάθηση, Νευρωνικά Δίκτυα, NLP, Πρόβλεψη Τιμών Μετοχών, Οικονομικός Κλάδος

Abstract

Predicting stock prices is one of the most researched topics and attracts the interest of many scientists and investors. Accurately predicting stock market returns is a very difficult task due to the volatile and non-linear nature of financial markets. With the advent of Artificial Intelligence (AI) and increased computing capabilities, many algorithms have been used to predict stock market movement. The combined application of machine learning (ML) algorithms and statistics is designed to predict the stock price the next day or to understand the long-term market in the future. The purpose of this paper is to investigate the different techniques used to predict stock prices from traditional deep learning and machine learning methods to neural networks and graph-based approaches. Even in this work forecasting techniques have been used to predict the closing price of the next day for five large companies. Finally, it contains a detailed analysis of the techniques used to predict stock prices as well as explores the challenges involved along with the future field of work in the sector.

Keywords: *Artificial Intelligence, Machine Learning, Neural Networks, NLP, Stock Price Forecast, Economic Sector*

Εισαγωγή

Η τεχνητή νοημοσύνη ενσωματώνεται και εισχωρεί στον κόσμο των χρηματοοικονομικών υπηρεσιών λόγω της εξαιρετικής απόδοσης συγκεκριμένων εργασιών σε σύγκριση με τους ανθρώπους, ειδικά όταν εμπλέκονται ακατέργαστα αδόμητα δεδομένα. Ο κλάδος των χρηματοοικονομικών υπηρεσιών χρησιμοποιεί προσεκτικά την τεχνητή νοημοσύνη και τα τμήματά της, από στατιστικές μεθόδους έως υπολογιστική νοημοσύνη.

Η μηχανική μάθηση (ML), ένα υποσύνολο της τεχνητής νοημοσύνης αποδίδεται ευρέως στις ανάγκες χρηματοοικονομικών υπηρεσιών, καθώς αφομοιώνει δεδομένα και αυτοματοποιεί τη μάθηση που εφαρμόζεται σε συγκεκριμένες οικονομικές εργασίες όπως είναι ή πρόβλεψη τιμών μετοχών, ανίχνευση απάτης, βαθμολόγηση πιστώσεων, προβλέψεις συμπεριφοράς καταναλωτών και ή αυτοματοποίηση εργασιών, είναι πολλά πράγματα στα οποία μπορούν ενδεχομένως να συμβάλουν η μηχανική μάθηση (ML) και η τεχνητή νοημοσύνη (AI).

Οι επενδύσεις σε μετοχές είναι μια σημαντική επενδυτική δραστηριότητα. Ωστόσο, εάν οι επενδυτές δεν διαθέτουν επαρκείς πληροφορίες και γνώσεις, μπορεί να προκληθεί κάποια βέβαιη απώλεια της επένδυσής τους. Εάν μπορούσαμε να προβλέψουμε την τιμή της μετοχής με μεγαλύτερη ακρίβεια, μπορούμε να κάνουμε τους πόρους της κοινωνίας να κατανοηθούν σε ένα σωστό μέρος που να αποφεύγει τη σπατάλη εθνικών πόρων, ώστε το χρηματιστήριο να επεκταθεί υγιώς και οι άνθρωποι να επενδύσουν με μεγαλύτερη αυτοπεποίθηση για να αποφύγουν τυφλές επενδυτικές συμπεριφορές.

Για να επιτευχθεί αυτό, η εργασία που δημιουργήθηκε χωρίζεται σε δύο μέρη. Στο πρώτο μέρος της εργασίας παρατίθενται τα θεωρητικά στοιχεία, ενώ στο δεύτερο μέρος παρουσιάζεται η εφαρμογή που πραγματοποιεί την πρόβλεψη τιμών των μετοχών, καθώς στην συνέχεια ακολουθεί η ανάλυση των αποτελεσμάτων από την πρόβλεψη τιμών των μετοχών. Πιο συγκεκριμένα, το πρώτο κεφάλαιο αναφέρεται στην τεχνητή νοημοσύνη και στα νευρωνικά δίκτυα.

Στο δεύτερο κεφάλαιο επιδιώκεται η κατανόηση του όρου της επεξεργασία φυσικής γλώσσας (NLP) ενώ ταυτόχρονα προβάλλονται και οι τεχνικές που χρησιμοποιεί. Στην συνέχεια παρουσιάζονται οι εφαρμογές της επεξεργασίας φυσικής γλώσσας καθώς και η εξέλιξη που θα έχει στο μέλλον.

Στο τρίτο κεφάλαιο πραγματοποιείται εκτενής ανάλυση του όρου της μηχανικής μάθησης. Σε αυτό το κεφάλαιο αναφέρονται οι βασικές αρχές ομαδοποίησης (clustering) όπως είναι ή ιεραρχική ομαδοποίηση και ο αλγόριθμος K-means. Στην συνέχεια προβάλλονται οι βασικές αρχές της δημιουργίας μοντέλων κατηγοριοποίησης/ταξινόμησης και εξετάζεται το πρόβλημα που προκύπτει όταν μια κατηγορία υπερέχει σε συχνότητα εμφάνισης των υπολοίπων. Ακόμα, παρατίθενται οι αλγόριθμοι δημιουργίας μοντέλων κατηγοριοποίησης/ταξινόμησης και πραγματοποιείται η ανάλυση της μεθόδου της λογιστικής παλινδρόμησης και των δένδρων αποφάσεων. Επιπλέον γίνεται η ανάλυση των τεχνικών random forest και boosting. Στο τέλος του τρίτου κεφαλαίου προβάλλονται μερικοί από τους τρόπους που η μηχανική μάθηση και η τεχνητή νοημοσύνη επηρεάζουν την διαδικασία του credit scoring.

Το τέταρτο κεφάλαιο αναφέρεται αναλυτικά στους λόγους που είναι σημαντική η πρόβλεψη τιμών των μετοχών και πως η χρήση τεχνητής νοημοσύνης και της μηχανικής μάθησης βοηθάει στο να ανακαλύψουμε την μελλοντική αξία των μετοχών της εταιρείας και άλλων χρηματοοικονομικών περιουσιακών στοιχείων που διαπραγματεύονται σε ένα χρηματιστήριο.

Το δεύτερο μέρος της εργασίας καλύπτεται από την εφαρμογή. Συγκεκριμένα, στο πέμπτο κεφάλαιο παρουσιάζεται ή εφαρμογή που ανέπτυξα σε γλώσσα προγραμματισμού Python 3.9 για την πρόβλεψη τιμών των μετοχών, ακόμα συμπεριλαμβάνεται εκτενής ανάλυση του κώδικα.

Το έκτο και έβδομο κεφάλαιο περιλαμβάνει τα αποτελέσματα από την εφαρμογή που πραγματοποιεί την πρόβλεψη τιμών μετοχών για τις εταιρείες Apple, Facebook, Microsoft, Tesla, Google στην συνέχεια γίνεται σύγκριση πέντε ημερών της προβλεπόμενης τιμής με την τιμή της επόμενης ημέρας κλεισίματος. Η συγκεκριμένη διαδικασία πραγματοποιήθηκε για κάθε μετοχή ξεχωριστά.

Κεφάλαιο 1^ο: Τεχνητή Νοημοσύνη

1.1 Ο Όρος Τεχνητή Νοημοσύνη

Η τεχνητή νοημοσύνη αποτελείται από δύο λέξεις η μία είναι Τεχνητή και η δεύτερη είναι η νοημοσύνη, τεχνητή σημαίνει ανθρωπογενής και η νοημοσύνη σημαίνει ικανότητα σκέψης, οπότε μπορούμε να ορίσουμε την τεχνητή νοημοσύνη ως τον κλάδο της επιστήμης των υπολογιστών με την οποία μπορούμε να αναπτύξουμε έξυπνες μηχανές που μπορούν να συμπεριφέρονται σαν άνθρωποι, να σκέφτονται σαν άνθρωποι και να παίρνουν αποφάσεις σύμφωνα με το λογικό πρόγραμμα στη μνήμη (Bhobosale, Pujari & Multani, 2020).

Η Τεχνητή Νοημοσύνη είναι κλάδος της επιστήμης και της τεχνολογίας που δημιουργεί έξυπνες μηχανές και προγράμματα υπολογιστών για την εκτέλεση διαφόρων εργασιών που απαιτείται η ανθρώπινη νοημοσύνη. Είναι ένα σύστημα που μιμείται διάφορες λειτουργίες που μπορεί να κάνει ένας άνθρωπος (PK, 1984).

Η τεχνητή νοημοσύνη χρησιμοποιεί εξωτερικά δεδομένα όπως τα μεγάλα δεδομένα προκειμένου να επιτύχει εξαιρετική απόδοση για τις συγκεκριμένες εργασίες. Κάποτε, η τεχνητή νοημοσύνη ήταν απλώς μια έννοια που εμφανιζόταν σε επιστημονικές φαντασίες και συζητήσεις που συζητούσαν για την επίδραση της τεχνολογίας στον σύγχρονο κόσμο. Αλλά τώρα, έχει γίνει μέρος του εαυτού μας στην καθημερινή μας ζωή. Έχει γίνει η βασική λειτουργία πολλών τεχνικών και διαφόρων άλλων τομέων (PK, 1984).

Μια ιδιαίτερη δύναμη της ανθρώπινης νοημοσύνης είναι η προσαρμοστικότητα. Είμαστε σε θέση να προσαρμοστούμε σε διάφορες περιβαλλοντικές συνθήκες και να αλλάξουμε ανάλογα τη συμπεριφορά μας μέσω της μάθησης. Ακριβώς επειδή η μαθησιακή μας ικανότητα είναι τόσο πολύ ανώτερη από αυτή των υπολογιστών, η μηχανική μάθηση είναι σύμφωνα με τον ορισμό του Rich, υποκατηγορία της τεχνητής νοημοσύνης (Ertel, 2018).

Οι βασικότεροι τομείς που αναπτύσσεται η τεχνητή νοημοσύνη είναι οι παρακάτω:

Λογική Τεχνητή Νοημοσύνη: Τι γνωρίζει ένα πρόγραμμα για τον κόσμο γενικά τα γεγονότα της συγκεκριμένης κατάστασης στην οποία πρέπει να ενεργήσει, και οι στόχοι της όλοι αντιπροσωπεύονται από προτάσεις κάποιας μαθηματικής λογικής γλώσσας. Το πρόγραμμα αποφασίζει τι θα κάνει, συμπεραίνοντας ότι ορισμένες ενέργειες είναι κατάλληλες για την επίτευξη των στόχων του.

Αναζήτηση με χρήση Τεχνητής Νοημοσύνης: Τα προγράμματα αναζήτησης συχνά εξετάζουν μεγάλους αριθμούς πιθανοτήτων, π.χ. κινείται σε μια παρτίδα σκακιού ή συμπεράσματα από προγράμματα απόδειξης θεωρημάτων. Γίνονται συνεχώς ανακαλύψεις σχετικά με το πώς να γίνει αυτό πιο αποτελεσματικό σε διάφορους τομείς.

Αναγνώριση Μοτίβου: Όταν ένα πρόγραμμα κάνει παρατηρήσεις κάποιου είδους, είναι συχνά προγραμματισμένο να συγκρίνει αυτό που βλέπει με ένα μοτίβο. Για παράδειγμα, ένα πρόγραμμα όρασης μπορεί να προσπαθήσει να ταιριάξει ένα σχέδιο ματιών και μύτης σε μια σκηνή για να βρει ένα πρόσωπο. Πιο πολύπλοκα μοτίβα, π.χ. σε κείμενο φυσικής γλώσσας, ή στην ιστορία κάποιου γεγονότος μελετώνται επίσης. Αυτά τα πιο πολύπλοκα μοτίβα απαιτούν πολύ διαφορετικές μεθόδους από τα απλά μοτίβα που έχουν μελετηθεί περισσότερο.

Αναπαράσταση: Τα γεγονότα για τον κόσμο πρέπει να αντιπροσωπεύονται με κάποιο τρόπο. Συνήθως χρησιμοποιούνται γλώσσες μαθηματικής λογικής.

Κοινή λογική γνώση και συλλογισμός: Αυτή είναι η περιοχή στην οποία η τεχνητή νοημοσύνη είναι πιο μακριά από το ανθρώπινο επίπεδο, παρά το γεγονός ότι είναι ένας ενεργός ερευνητικός τομέας από τη δεκαετία του 1950. Ενώ υπήρξε σημαντική πρόοδος, π.χ. στην ανάπτυξη συστημάτων μη μονότονου συλλογισμού και θεωριών δράσης, χρειάζονται ακόμη περισσότερες νέες ιδέες. Το σύστημα Cyc περιέχει μια μεγάλη αλλά ανώμαλη συλλογή γεγονότων κοινής λογικής.

Μαθαίνοντας από την Εμπειρία: Τα προγράμματα το κάνουν αυτό. Οι προσεγγίσεις της τεχνητής νοημοσύνης που βασίζονται στη συνδεσιμότητα και τα νευρωνικά δίκτυα ειδικεύονται σε αυτό. Υπάρχει επίσης εκμάθηση νόμων που εκφράζονται στη λογική. Τα προγράμματα μπορούν να μάθουν μόνο ποια γεγονότα ή συμπεριφορές μπορούν να αντιπροσωπεύουν οι φορμαλισμοί τους και δυστυχώς τα συστήματα μάθησης βασίζονται σχεδόν όλα σε πολύ περιορισμένες ικανότητες αναπαράστασης πληροφοριών.

Σχεδίαση: Τα προγράμματα προγραμματισμού ξεκινούν με γενικά δεδομένα για τον κόσμο (ειδικά στοιχεία για τα αποτελέσματα των ενεργειών), γεγονότα για τη συγκεκριμένη κατάσταση και μια δήλωση ενός στόχου. Από αυτά, δημιουργούν μια στρατηγική για την επίτευξη του στόχου. Στις πιο συνηθισμένες περιπτώσεις, η στρατηγική είναι απλώς μια ακολουθία ενεργειών.

Οντολογία: Η οντολογία είναι η μελέτη των ειδών πραγμάτων που υπάρχουν. Στην τεχνητή νοημοσύνη, τα προγράμματα και οι προτάσεις ασχολούνται με διάφορα είδη αντικειμένων και μελετάμε τι είναι αυτά τα είδη και ποιες είναι οι βασικές τους ιδιότητες.

Ευρετικές: Η ευρετική είναι ένας τρόπος προσπάθειας να ανακαλύψουμε κάτι ή μια ιδέα που είναι ενσωματωμένη σε ένα πρόγραμμα. Ο όρος χρησιμοποιείται διαφορετικά στην τεχνητή νοημοσύνη. Οι ευρετικές συναρτήσεις χρησιμοποιούνται σε ορισμένες προσεγγίσεις για την αναζήτηση για τη μέτρηση της απόστασης ενός κόμβου σε ένα δέντρο αναζήτησης από έναν στόχο. Τα ευρετικά κατηγορήματα που συγκρίνουν δύο κόμβους σε ένα δέντρο αναζήτησης για να δουν εάν ο ένας είναι καλύτερος από τον άλλον, δηλ. αποτελεί πρόοδο προς τον στόχο, μπορεί να είναι πιο χρήσιμα.

Γενετικός προγραμματισμός: Ο γενετικός προγραμματισμός είναι μια τεχνική για να βάζουμε προγράμματα να λύσουν μια εργασία ζευγαρώνοντας τυχαία προγράμματα Lisp και επιλέγοντας τα καλύτερα σε εκατομμύρια γενιές (McCarthy, 2007).


Ακόμα, η Τεχνητή Νοημοσύνη έχει σημαντικό αντίκτυπο σε βιομηχανίες όπως η μεταποίηση, η υγειονομική περίθαλψη, οι αλυσίδες εφοδιασμού κ.λπ η ικανότητα της τεχνητής νοημοσύνης να κάνει πράγματα που ο άνθρωπος δεν μπορεί, φέρνει πολλές εφαρμογές που έχει ως αποτέλεσμα την βελτίωση της απόδοσης και της παραγωγικότητας (PK, 1984).

Οι πρόσφατες τάσεις παραγωγικότητας και εργασίας υπογραμμίζουν τη σημασία της κατανόησης της επίδρασης της τεχνητής νοημοσύνης στην οικονομία. Η επιβράδυνση της οικονομικής ανάπτυξης την τελευταία δεκαετία υπογραμμίζει τη σημασία της τεχνητής νοημοσύνης για την επίτευξη των πιθανών πλεονεκτημάτων παραγωγικότητας (Tenhagen, et al, 2004).

1.2 Ιστορική Αναδρομή

Η ιστορία της Τεχνητής Νοημοσύνης ξεκινά με κάποιες φαντασιώσεις που δημιουργήθηκαν από φιλοσόφους και συγγραφείς μυθοπλασίας. Οι φιλόσοφοι ανέπτυξαν την έννοια των ευφυών μηχανών για να μας κάνουν να καταλάβουμε τη σημασία του να είσαι άνθρωπος. Ο Γάλλος φιλόσοφος, Ρενέ Ντεκάρτ, χρησιμοποίησε τη μεταφορά «μηχανικός άνθρωπος» για να περιγράψει τη δυνατότητα των ευφυών μηχανών. Συγγραφείς επιστημονικής φαντασίας όπως ο Ιούλιος Βερν (19ος αιώνας), ο Ισαάκ Ασίμοφ (20ος αιώνας) χρησιμοποίησαν επίσης αυτή τη δυνατότητα για να φέρουν φαντασία στο έργο τους σχετικά με τον ευφυή μη ανθρώπινο οργανισμό (PK, 1984).

Το 1907, ο συγγραφέας του «Μάγου του Οζ». L. Frank Baum περιέγραψε για τον μηχανικό άνθρωπο ως «Εξαιρετικά ανταποκρινόμενο, που δημιουργεί σκέψεις, ομιλεί αρκετά καλά, σκέφτεται, ενεργεί και κάνει τα πάντα εκτός από τη ζωή». Πολλοί ερευνητές τεχνητής νοημοσύνης βρήκαν την έμπνευση μέσα από αυτούς τους συγγραφείς για την έρευνά τους. Το σκάκι είναι ένα πεδίο που απαιτεί πολύ χρόνο και σκέψη. Κατά τον 18ο και 19ο αιώνα, μια μηχανή παιχνιδιού σκακιού που ονομάζεται «Ο Τούρκος» εμφανίστηκε και παρουσιάστηκε ως μια έξυπνη μηχανή. Πολλοί άνθρωποι πίστευαν ότι αυτά τα μηχανήματα λειτουργούσαν αυτόματα. Αυτός ο μηχανισμός του σκακιού χρησιμοποιήθηκε για τη μελέτη των πρώιμων έργων AI (Buchanan, 2005).



Εικόνα 1: Μηχανή Παιχνιδιού Σκακιού «Ο Τούρκος»

Το 1942, ο Isaac Asimov, ένας Αμερικανός συγγραφέας μυθοπλασίας, έγραψε ένα διήγημα με τίτλο «Runaround», το οποίο αναφέρεται σε ένα ρομπότ που αναπτύχθηκε από τους μηχανικούς Gregory Powell και Mike Donovan. Αυτή η ιστορία εμπνέει πολλούς επιστήμονες που εργάζονται στον τομέα της Τεχνητής Νοημοσύνης, της Ρομποτικής, της Επιστήμης των Υπολογιστών. Την ίδια περίπου εποχή, ένας Άγγλος μαθηματικός ονόματι Άλαν Τούρινγκ, εφηύρε μια μηχανή για τη διάσπαση κωδικών, που ονομάζεται «The Bombe», η οποία θεωρείται ως ο πρώτος ηλεκτρομηχανικός υπολογιστής που λειτουργεί. Ανέπτυξε αυτό το μηχανήμα για τη Βρετανική Κυβέρνηση προκειμένου να αποκρυπτογραφήσει τον κώδικα Επίγραμμα που χρησιμοποιήθηκε κατά τον Β' Παγκόσμιο Πόλεμο από τον γερμανικό στρατό. Το 1950, ο Turing δημοσίευσε ένα άρθρο «Υπολογιστικές Μηχανές και Ευφυΐα» το οποίο περιγράφει τη δημιουργία και τη δοκιμή ευφύων μηχανών που ονομάζεται δοκιμή Turing. Το τεστ Turing χρησιμοποιείται για να βρει τη νοημοσύνη ενός συστήματος: εάν ένας άνθρωπος δεν μπορεί να κάνει διάκριση μεταξύ μιας μηχανής και ενός άλλου ανθρώπου όταν αλληλεπιδρά μαζί τους τότε το μηχανήμα είναι έξυπνο (Haenlein & Kaplan, 2019).

Το 1956, επιστήμονες υπολογιστών από το πανεπιστήμιο Στάνφορντ. Ο Μάρβιν Μίνσκι και ο Τζον ΜακΚάρθι φιλοξένησαν το «Καλοκαιρινό ερευνητικό πρόγραμμα του Dartmouth για την Τεχνητή Νοημοσύνη (DSRPAI)», το οποίο διήρκεσε περίπου οκτώ εβδομάδες. Αυτό το πρόγραμμα θεωρείται ως η αρχή της άνοιξης του ΑΙ. Στο εργαστήριο συμμετείχαν επίσης ο σχεδιαστής του πρώτου επιστημονικού υπολογιστή IBM 701, ο Nathaniel Rochester (επιστήμονας υπολογιστών) και ο ιδρυτής της θεωρίας της πληροφορίας, Claude Shannon (μαθηματικός). Ο κύριος στόχος αυτού του εργαστηρίου ήταν να συγκεντρώσει ερευνητές διαφόρων πεδίων για τη δημιουργία μιας ερευνητικής περιοχής για την κατασκευή μηχανών που μπορούν να προσομοιώσουν την ανθρώπινη νοημοσύνη. Το DSRPAI σημείωσε επιτυχία στον τομέα της Τεχνητής Νοημοσύνης (Haenlein & Kaplan, 2019).

Το 1963, ο Edward Feigenbaum και ο Julian Feldman έγραψαν ένα βιβλίο *Computers and Thought* το οποίο περιγράφει τη λειτουργία προγραμμάτων τεχνητής νοημοσύνης. Γύρω στο 1973, η βρετανική κυβέρνηση σταμάτησε να υποστηρίζει την έρευνα για την τεχνητή νοημοσύνη λόγω μιας δήλωσης του Βρετανού μαθηματικού James Lighthill. Η κυβέρνηση των ΗΠΑ ακολούθησε επίσης το βρετανικό παράδειγμα. που έχει ως αποτέλεσμα την πτώση της τεχνητής νοημοσύνης (Haenlein & Kaplan, 2019).

Το 2015, η Google δημιούργησε το AlphaGo, το οποίο χρησιμοποιεί τεχνητό νευρωνικό δίκτυο που ονομάζεται Deep Learning. Το Go είναι ένα παιχνίδι που είναι πιο περίπλοκο από το Σκάκι και το AlphaGo μπόρεσε να κερδίσει τον παγκόσμιο πρωταθλητή Go. Πολλές

εφαρμογές που υπάγονται στην τεχνητή νοημοσύνη λειτουργούν βάσει Deep Learning και τεχνητών νευρωνικών δικτύων (Haenlein & Kaplan, 2019).

1.3 Νευρωνικά Δίκτυα

Τα νευρωνικά δίκτυα όπως γνωρίζουμε είναι μοντέλα υπολογισμού που βασίζονται σε φυσικά και βιολογικά δίκτυα που αποτελούνται από νευρώνες. Το συγκεκριμένο μοντέλο πρωτοεμφανίστηκε το 1943 από τους Warren McCulloch και Walter Pitts στο άρθρο που έγραψαν με όνομα "A logical calculus of the ideas immanent in nervous activity". Μετά από εντατική ενασχόληση το ενδιαφέρον σε αυτά εξασθένησε. Πέρα από διάφορους θεωρητικούς λόγους η πιο βασική αιτία ήταν ότι οι υπολογιστές της τότε εποχής δεν ήταν όσο ισχυροί θα θέλανε για τη δημιουργία μεγάλων νευρωνικών δικτύων (McCulloch & Pitts, 1943).

Η εφεύρεση της backpropagation, μιας πολύ σημαντικής μεθόδου για την εκπαίδευση νευρωνικών δικτύων, από τον Paul J Werbos το 1974 έδωσε ένα εργαλείο για την αποτελεσματική κατασκευή και εκπαίδευση νευρωνικών δικτύων. Σε συνδυασμό με τον εκθετικό ρυθμό αύξησης της υπολογιστικής ισχύος που έχει αναπτυχθεί τα τελευταία χρόνια, η μέθοδος αυτή έχει κάνει τα νευρωνικά δίκτυα την βασικότερη μέθοδο σε εφαρμογές όπως η υπολογιστική όραση, επεξεργασία φυσικής γλώσσας και πολλά άλλα ακόμα (Werbos, 1994).

Βασικό δομικό στοιχείο των νευρωνικών δικτύων είναι οι νευρώνες ένα νευρωνικό κύτταρο αποτελείται από το κυρίως σώμα και έναν άξονα. Το κυρίως σώμα έχει σχηματισμούς που λέγονται δενδρίτες και συνδέονται με τους άξονες άλλων νευρώνων μέσω σχηματισμών που αποκαλούνται (νεύρο) αξονικές απολήξεις. Ένας νευρώνας δέχεται ηλεκτροχημικά ερεθίσματα μέσω των δενδριτών. Όταν η ισχύς των ερεθισμάτων αυτών ξεπεράσει ένα όριο τότε, ένα νέο ηλεκτροχημικό σήμα στέλνεται μέσω του άξονα (McCulloch & Pitts, 1943).


Τα τεχνητά νευρωνικά δίκτυα βασίζονται στο δίκτυο των νευρώνων στον φλοιό των θηλαστικών και διαμορφώνονται χαλαρά αλλά σε πολύ μικρότερη κλίμακα. Τα τεχνητά νευρωνικά δίκτυα μπορεί να είναι αλγόριθμοι ή ένα πραγματικό κομμάτι υλικού. Υπάρχουν δισεκατομμύρια νευρώνες στον εγκέφαλο των θηλαστικών που δίνουν τεράστιο μέγεθος της αλληλεπίδρασης και της αναδυόμενης συμπεριφοράς, αλλά σε ένα Τεχνητό Νευρωνικό Δίκτυο μπορεί να υπάρχουν εκατοντάδες ή χιλιάδες μονάδες επεξεργαστή που είναι πολύ μικρές σε σύγκριση με τη δομή του εγκέφαλου των θηλαστικών. Τα νευρωνικά δίκτυα οργανώνονται σε πολλαπλά επίπεδα και κάθε επίπεδο αποτελείται από έναν αριθμό διασυνδεδεμένων κόμβων που έχουν συναρτήσεις ενεργοποίησης που σχετίζονται με αυτά. Τα δεδομένα τροφοδοτούνται στο δίκτυο μέσω του επιπέδου εισόδου το οποίο στη συνέχεια επικοινωνεί με άλλα επίπεδα και επεξεργάζεται τα δεδομένα εισόδου με τη βοήθεια ενός συστήματος σταθμισμένων συνδέσεων. Αυτά τα επεξεργασμένα δεδομένα λαμβάνονται στη συνέχεια μέσω του επιπέδου εξόδου (Sharma & Athaiya, 2017).

Οι συναρτήσεις ενεργοποίησης είναι ένα από τα σημαντικότερα στοιχεία των νευρωνικών δικτύων, εάν μια συνάρτηση ενεργοποίησης δεν χρησιμοποιείται σε ένα νευρωνικό δίκτυο, τότε το σήμα εξόδου θα είναι απλώς μια απλή γραμμική συνάρτηση που είναι απλώς ένα πολυώνυμο του πρώτου βαθμού. Αν και μια γραμμική εξίσωση είναι απλή και εύκολη στην επίλυση αλλά η πολυπλοκότητά της είναι περιορισμένη και δεν έχουν τη δυνατότητα να μάθουν και να αναγνωρίσουν σύνθετες αντιστοιχίες από δεδομένα. Το νευρωνικό δίκτυο χωρίς συναρτήσεις ενεργοποίησης λειτουργεί ως μοντέλο γραμμικής παλινδρόμησης με περιορισμένη απόδοση και ισχύ τις περισσότερες φορές. Είναι επιθυμητό ένα νευρωνικό δίκτυο όχι μόνο να μαθαίνει και να υπολογίζει μια γραμμική συνάρτηση αλλά να εκτελεί εργασίες πιο περίπλοκες από αυτές όπως η μοντελοποίηση περίπλοκων τύπων δεδομένων όπως εικόνες, βίντεο, ήχος, ομιλία, κείμενο κ.λπ (Sharma & Athaiya, 2017).

Αυτός είναι ο λόγος που χρησιμοποιούμε συναρτήσεις ενεργοποίησης και τεχνικές τεχνητών νευρωνικών δικτύων όπως το Deep Learning που έχει νόημα για πολύπλοκα, υψηλών διαστάσεων και μη γραμμικά σύνολα δεδομένων όπου το μοντέλο έχει πολλαπλά κρυφά επίπεδα και επίσης μια πολύπλοκη αρχιτεκτονική για την εξαγωγή γνώσης, που είναι και πάλι ο απώτερος στόχος μας (Sharma & Athaiya, 2017).

Ένα νευρωνικό δίκτυο αποτελείται από ομάδες νευρώνων που ονομάζονται στρώματα τα οποία χωρίζονται σε:

- στρώμα εισόδου (Input layer) που απαρτίζεται από τους νευρώνες που δέχονται ως είσοδο τις τιμές ή τα δεδομένα με τα οποία τροφοδοτείται το νευρωνικό δίκτυο,
- στρώμα εξόδου (Output layer) που απαρτίζεται από τους νευρώνες των οποίων η έξοδος αποτελεί την έξοδο του νευρωνικού δικτύου,
- κρυφά (Hidden layers) στρώματα τα οποία είναι ενδιάμεσα στρώματα



Εικόνα 2: Νευρωνικό Δίκτυο

Οι νευρώνες ενός στρώματος δεν επικοινωνούν μεταξύ τους. Δέχονται τις τιμές εξόδου νευρώνων από το προηγούμενο στρώμα και στέλνουν τις δικές τους τιμές εξόδου στους νευρώνες του επόμενου στρώματος (McCulloch & Pitts, 1943).

Τα νευρωνικά δίκτυα μπορούν να χρησιμοποιηθούν για τη δημιουργία μοντέλων ταξινόμησης (classification) αλλά και για τη δημιουργία μοντέλων πρόβλεψης (prediction).

1.4 Εκπαίδευση Νευρωνικών Δικτύων

Υπάρχουν δύο τρόποι παρουσίασης δεδομένων σε ένα νευρωνικό δίκτυο κατά τη διάρκεια της εκπαίδευσης, συγκεκριμένα αυτά χωρίζονται σε Σταδιακή Εκπαίδευση και σε Μαζική Εκπαίδευση.

Η Σταδιακή Εκπαίδευση είναι η μέθοδος, στην οποία κάθε ένα από τα μοτίβα εισόδου ή τα δεδομένα εκπαίδευσης που παρουσιάζονται στο νευρωνικό δίκτυο καθώς και τα βάρη ενημερώνονται για κάθε παρουσιαζόμενο δεδομένο, επομένως ο αριθμός των ενημερώσεων βάρους θα είναι ίσος με το μέγεθος του συνόλου εκπαίδευσης. Ο εγγενής θόρυβος αυτού του τρόπου εκμάθησης καθιστά δυνατή τη διαφυγή από τα ανεπιθύμητα τοπικά ελάχιστα του δυναμικού σφάλματος όπου ο κανόνας μάθησης εκτελεί (στοχαστική) βαθμιδωτή κάθοδο. Ο θόρυβος σχετίζεται με τις διακυμάνσεις στον κανόνα μάθησης, ο οποίος είναι συνάρτηση των βαρών (Gudise & Venayagamoorthy, 2003).

Η Μαζική Εκπαίδευση είναι η δεύτερη μέθοδος, στην οποία όλα τα μοτίβα εισόδου ή τα δεδομένα εκπαίδευσης παρουσιάζονται στο νευρωνικό δίκτυο το ένα μετά το άλλο και στη συνέχεια τα βάρη ενημερώνονται με βάση μια αθροιστική συνάρτηση σφάλματος. Η διαδικασία μπορεί να επαναληφθεί σε πολλές επαναλήψεις/εποχές. Στην μαζική εκμάθηση, το δίκτυο συγκρούεται σε ένα τοπικό ελάχιστο, όπου το ελάχιστο εξαρτάται μόνο από την αρχική κατάσταση του δικτύου, ο θόρυβος είναι ομοιογενής, δηλαδή ο ίδιος σε κάθε ελάχιστο. Η

εκπαίδευση νευρωνικών δικτύων με την χρήση της BP (Back Propagation) βασίζεται στην μαζική εκπαίδευση (Gudise & Venayagamoorthy, 2003).

Για την δημιουργία ενός μοντέλου απαιτείται η ρύθμιση των βαρών κάθε νευρώνα, για να πραγματοποιηθεί η συγκεκριμένη ρύθμιση χρειαζόμαστε την μέθοδο Back Propagation. Η συγκεκριμένη μέθοδος τεχνικά είναι μια εφαρμογή του κανόνα της αλυσίδας για την παραγωγή και της μεθόδου gradient descent. Η διαδικασία που ακολουθεί είναι η παρακάτω:

1. Στην αρχή τα βάρη σε κάθε νευρώνα λαμβάνουν τυχαίες τιμές.
2. Σε δεύτερο βήμα κάθε στοιχείο του συνόλου των δεδομένων που χρησιμοποιούμε για την διαδικασία της εκπαίδευσης, μας δίνει μια αντιστοιχία τιμών εισόδου x_1, \dots, x_n με μία τιμή εξόδου y . Για κάθε συνδυασμό x_1, \dots, x_n υπολογίζουμε την εκτίμηση του νευρωνικού δικτύου και στην συνέχεια το σφάλμα εκτίμησης.
3. Σε Τρίτη φάση υπολογίζουμε προς ποια κατεύθυνση πρέπει να μεταβληθούν τα βάρη για να μειωθεί αυτό το σφάλμα (εδώ παρεμβαίνει η έννοια της παραγωγίσιμης και ο κανόνας της αλυσίδας).
4. Σε τελική φάση μεταβάλλουμε τα βάρη κατά μια ορισμένη ποσότητα προς την κατεύθυνση που έχουμε εντοπίσει στην τρίτη φάση (Werbos, 1994).

1.5 Δημιουργία Νευρωνικών Δικτύων Μέσω της Βιβλιοθήκης

Tensorflow

Η δημοφιλέστερη γλώσσα προγραμματισμού για την ανάπτυξη εφαρμογών όπως Data Analytics, Machine Learning και Artificial Intelligence είναι η Python. Η συγκεκριμένη γλώσσα προγραμματισμού χρησιμοποιεί διάφορες βιβλιοθήκες ώστε να μας δώσει το επιθυμητό αποτέλεσμα. Μια από τις σημαντικότερες βιβλιοθήκες για την δημιουργία Νευρωνικών Δικτύων είναι η βιβλιοθήκη TensorFlow (Zacccone & Karim, 2018).

Το TensorFlow είναι ένα πλαίσιο ανοιχτού κώδικα από την Google για επιστημονικούς και αριθμητικούς υπολογισμούς χρησιμοποιώντας γραφήματα ροής δεδομένων που αντιπροσωπεύουν το μοντέλο εκτέλεσης του TensorFlow. Τα γραφήματα ροής δεδομένων που χρησιμοποιούνται στην συγκεκριμένη βιβλιοθήκη βοηθούν τους ειδικούς στην μηχανική μάθηση να εκτελούν μια πιο προηγμένη και εντατική εκπαίδευση στα δεδομένα τους για να αναπτύξουν μοντέλα βαθιάς μάθησης και προγνωστικής ανάλυσης (Zacccone & Karim, 2018).

Όπως υποδηλώνει το όνομα το TensorFlow περιλαμβάνει λειτουργίες που εκτελούνται από νευρωνικά δίκτυα σε πολυδιάστατους πίνακες δεδομένων. Οι κόμβοι σε ένα γράφημα ροής αντιστοιχούν σε μαθηματικές πράξεις, δηλαδή πρόσθεση, πολλαπλασιασμό, παραγοντοποίηση μήτρας, κ.λπ., ενώ οι ακμές αντιστοιχούν σε τανύστες που διασφαλίζουν την επικοινωνία μεταξύ των ακμών και των κόμβων δηλαδή τη ροή δεδομένων και τη ροή ελέγχου. Με αυτόν τον τρόπο το TensorFlow περιέχει ορισμένα ευρέως χρησιμοποιούμενα και εύρωστα εφαπτόμενα γραμμικά μοντέλα καθώς και αλγορίθμους βαθιάς μάθησης (Zacccone & Karim, 2018).

Με την χρήση της συγκεκριμένης βιβλιοθήκης ακόμα μπορείτε να εκτελέσετε αριθμητικούς υπολογισμούς σε μια CPU, ωστόσο, είναι επίσης δυνατό να διανεμηθεί η εκπαίδευση σε πολλές συσκευές στο ίδιο σύστημα, ειδικά εάν έχετε περισσότερες από μία GPU στο σύστημά σας που μπορούν να μοιραστούν το υπολογιστικό φορτίο (Zacccone & Karim, 2018).

Η ανάπτυξη ενός μοντέλου πρόβλεψης ή γενικής χρήσης χρησιμοποιώντας την βιβλιοθήκη TensorFlow είναι απλή. Αφού κατασκευάσετε το μοντέλο του νευρωνικού δικτύου σας, μετά την απαιτούμενη μηχανική των χαρακτηριστικών, μπορείτε απλά να εκτελέσετε την εκπαίδευση διαδραστικά και να χρησιμοποιήσετε το TensorBoard για να απεικονίσετε το γράφημα TensorFlow, ακόμα μπορείτε να σχεδιάσετε ποσοτικές μετρήσεις σχετικά με την εκτέλεση του γραφήματος σας και να εμφανίσετε πρόσθετα δεδομένα (Zacccone & Karim, 2018).

Εάν η βιβλιοθήκη Tensorflow μπορέσει να έχει πρόσβαση σε συσκευές GPU, τότε θα διανέμει αυτόματα τους υπολογισμούς σε πολλές συσκευές μέσω μιας άπληστης διαδικασίας. Επομένως, δεν απαιτείται ειδική ρύθμιση παραμέτρων για να χρησιμοποιήσει τους πυρήνες της CPU. Ωστόσο, το Tensorflow επιτρέπει επίσης στο πρόγραμμα να καθορίσει ποιες λειτουργίες θα εκτελούνται και σε ποια συσκευή μέσω της τοποθέτησης του εύρους ονόματος. Τελικά αφού

αξιολογήσετε το μοντέλο, το αναπτύσσετε τροφοδοτώντας του κάποια δεδομένα δοκιμής (Zaccone & Karim, 2018).

Τα κύρια χαρακτηριστικά που προσφέρει η βιβλιοθήκη TensorFlow είναι τα εξής:

1. Ταχύτερος Υπολογισμός: Η βιβλιοθήκη TensorFlow είναι απίστευτα γρήγορη. Για παράδειγμα, το μοντέλο Inception-v3 εκτελείται 7,3 φορές πιο γρήγορα σε 8 GPU και το κατανεμημένο Inception-v3 εκτελείται 58 φορές πιο γρήγορα σε 64 GPU.
2. Ευελιξία: Το Tensorflow δεν είναι απλώς μια βιβλιοθήκη βαθιάς μάθησης. Έρχεται με σχεδόν όλα όσα χρειάζεται κάποιος για να κάνει ισχυρές μαθηματικές πράξεις, χάρη σε αυτό υπάρχουν λειτουργίες για την επίλυση των πιο δύσκολων προβλημάτων.
3. Φορητότητα: Το Tensorflow εκτελείται σε λειτουργικά Windows, Linux, Mac καθώς και σε φορητές πλατφόρμες όπως είναι το Android.
4. Εύκολη Αποσφαλμάτωση: Η συγκεκριμένη βιβλιοθήκη παρέχει το εργαλείο TensorBoard, το οποίο είναι χρήσιμο για την ανάλυση των μοντέλων που αναπτύσσετε.
5. Ενοποιημένο API: Το Tensorflow προσφέρει μια πολύ ευέλικτη αρχιτεκτονική που σας επιτρέπει να αναπτύξετε υπολογισμούς σε μία ή περισσότερες CPU ή GPU σε έναν επιτραπέζιο υπολογιστή, διακομιστή ή κινητή συσκευή με ένα μόνο API.
6. Διάφανη Χρήση των Υπολογιστών GPU: Με την χρήση της συγκεκριμένης βιβλιοθήκης αυτοματοποιείται η διαχείριση και η βελτιστοποίηση της μνήμης και των δεδομένων που χρησιμοποιούνται. Τώρα υπάρχει η δυνατότητα να χρησιμοποιήσετε το μηχάνημα σας για υπολογισμούς μεγάλης κλίμακας και μεγάλης έντασης δεδομένων με την χρήση των εργαλείων cuDNN και CUDA της NVIDIA.
7. Εύκολη Χρήση: Το Tensorflow είναι κατάλληλο για όλους. Δεν είναι κατάλληλο μόνο για φοιτητές, ερευνητές, επαγγελματίες της βαθιάς μάθησης, αλλά και για επαγγελματίες που εργάζονται στις βιομηχανίες.
8. Έτοιμο για Παραγωγή σε Κλίμακα: Πρόσφατα το TensorFlow έχει εξελιχθεί σε νευρωνικό δίκτυο για μηχανική μετάφραση σε παραγωγική κλίμακα.
9. Επεκτασιμότητα: Το TensorFlow είναι μια σχετικά νέα τεχνολογία και βρίσκεται ακόμα ενεργό σε ανάπτυξη.
10. Υποστήριξη: Υπάρχει μια μεγάλη κοινότητα προγραμματιστών και χρηστών που συνεργάζονται για να κάνουν την συγκεκριμένη βιβλιοθήκη καλύτερο προϊόν, παρέχοντας σχόλια και συμβάλλοντας ενεργά στον πηγαίο κώδικα.
11. Ευρεία Υιοθέτηση: Πολλές μεγάλες εταιρείες χρησιμοποιούν το TensorFlow για να αυξήσουν την δικιά τους επιχειρηματική ευφυΐα, όπως ή Google, Twitter, Dropbox, Airbnb, Intel καθώς και πολλές ακόμα (Zaccone & Karim, 2018).

Κεφάλαιο 2^ο: Natural Language Processing (NLP)

2.1 Ο Όρος NLP

Η επεξεργασία φυσικής γλώσσας (Natural Language Processing – NLP) είναι ένα πεδίο που συνδυάζει επιστημονικούς τομείς όπως η γλωσσολογία, η πληροφορική και η τεχνητή νοημοσύνη. Στόχος του είναι να επιτρέψει στους υπολογιστές να αναλύσουν και να επεξεργαστούν δεδομένα που αφορούν φυσιολογικό γραπτό ή προφορικό λόγο και όχι τεχνητό όπως είναι για παράδειγμα ο κώδικας σε μια γλώσσα προγραμματισμού. Η επεξεργασία φυσικής γλώσσας είναι ένας πολύ ενεργός τομέας έρευνας και ανάπτυξης, δεν υπάρχει ένας ενιαίος συμφωνημένος ορισμός που θα τους ικανοποιούσε όλους, αλλά υπάρχουν ορισμένες πτυχές, οι οποίες θα ήταν μέρος του ορισμού (Chopra, Prashar, Sain, 2013).

Ο ορισμός που είναι περισσότερο αποδεκτός από το επιστημονικό κοινό αναφέρει ότι η Επεξεργασία Φυσικής Γλώσσας έχει ένα εύρος υπολογιστικών τεχνικών με θεωρητικά κίνητρα για την ανάλυση και την αναπαράσταση φυσικών κειμένων σε ένα ή περισσότερα επίπεδα γλωσσικής ανάλυσης με σκοπό την επίτευξη ανθρώπινης γλωσσικής επεξεργασίας για μια σειρά εργασιών ή εφαρμογών (Liddy, 2001).

Πολλά στοιχεία αυτού του ορισμού μπορούν να αναλυθούν περαιτέρω, όπως η ανακριβής έννοια του «εύρους υπολογιστικών τεχνικών» είναι απαραίτητη επειδή υπάρχουν πολλές μέθοδοι ή τεχνικές από τις οποίες μπορεί κανείς να επιλέξει για να ολοκληρώσει έναν συγκεκριμένο τύπο γλωσσικής ανάλυσης (Liddy, 2001).

Τα «φυσικά κείμενα» μπορεί να είναι οποιασδήποτε γλώσσας, τρόπου, είδους, κ.λπ. Τα κείμενα μπορεί να είναι προφορικά ή γραπτά. Η μόνη απαίτηση είναι να είναι σε μια γλώσσα που χρησιμοποιούν οι άνθρωποι για να επικοινωνούν μεταξύ τους. Επίσης, το κείμενο που αναλύεται δεν θα πρέπει να έχει κατασκευαστεί ειδικά για τους σκοπούς της ανάλυσης, αλλά να συλλέγεται από την πραγματική χρήση (Liddy, 2001).

Η έννοια των «επιπέδων γλωσσικής ανάλυσης» αναφέρεται στο γεγονός ότι υπάρχουν πολλοί τύποι γλωσσικής επεξεργασίας που είναι γνωστό ότι λειτουργούν όταν οι άνθρωποι παράγουν ή κατανοούν τη γλώσσα. Θεωρείται ότι οι άνθρωποι συνήθως χρησιμοποιούν όλα αυτά τα επίπεδα αφού κάθε επίπεδο μεταφέρει διαφορετικούς τύπους νοήματος. Αλλά τα διάφορα συστήματα NLP χρησιμοποιούν διαφορετικά επίπεδα ή συνδυασμούς επιπέδων γλωσσικής ανάλυσης, και αυτό φαίνεται στις διαφορές μεταξύ των διαφόρων εφαρμογών NLP. Αυτό οδηγεί επίσης σε μεγάλη σύγχυση από την πλευρά των μη ειδικών ως προς το τι είναι πραγματικά το NLP, επειδή ένα σύστημα που χρησιμοποιεί οποιοδήποτε υποσύνολο αυτών των επιπέδων ανάλυσης μπορεί να ειπωθεί ότι είναι ένα σύστημα που βασίζεται σε NLP. Η διαφορά μεταξύ τους, επομένως, μπορεί στην πραγματικότητα να είναι αν το σύστημα χρησιμοποιεί «αδύναμο» ή «ισχυρό» NLP (Liddy, 2001).


Η «επεξεργασία γλώσσας παρόμοια με τον άνθρωπο» αποκαλύπτει ότι το NLP θεωρείται κλάδος της Τεχνητής Νοημοσύνης και η πλήρης γενεαλογία του NLP εξαρτάται και από πολλούς άλλους κλάδους (Liddy, 2001).

Η φράση «Για μια σειρά εργασιών ή εφαρμογών» επισημαίνει ότι το NLP συνήθως δεν θεωρείται ως στόχος από μόνος του, εκτός ίσως από ερευνητές τεχνητής νοημοσύνης. Για άλλους, το NLP είναι το μέσο για την ολοκλήρωση μιας συγκεκριμένης εργασίας. Επομένως, περιέχει συστήματα Ανάκτησης Πληροφοριών που χρησιμοποιούν NLP, καθώς και Μηχανική Μετάφραση όπως Ερωτήσεις-Απαντήσεις κ.λπ (Liddy, 2001).

Ακόμα υπάρχουν 5 φάσεις που εμπλέκονται στην επεξεργασία της φυσικής γλώσσας οι οποίες είναι:

1. Μορφολογική και Λεξική Ανάλυση: Το λεξικό μιας γλώσσας είναι το λεξιλόγιό της που περιλαμβάνει τις λέξεις και τις εκφράσεις της. Η μορφολογία απεικονίζει την ανάλυση, τον προσδιορισμό και την περιγραφή της δομής των λέξεων και η Λεξιλογική Ανάλυση Περιλαμβάνει τη διαίρεση ενός κειμένου σε παραγράφους, λέξεις και προτάσεις.
2. Συντακτική Ανάλυση: Η συντακτική ανάλυση χρησιμοποιείται για τον έλεγχο της γραμματικής, της διάταξης των λέξεων και δείχνει τη σχέση μεταξύ των λέξεων.
3. Σημασιολογική Ανάλυση: Η σημασιολογική ανάλυση ασχολείται με την αναπαράσταση του νοήματος. Εστιάζει κυρίως στην κυριολεκτική σημασία λέξεων, φράσεων και προτάσεων.

4. Ολοκλήρωση λόγου: Το νόημα οποιασδήποτε μεμονωμένης πρότασης εξαρτάται από τις προτάσεις που προηγούνται και επίσης επικαλείται τη σημασία των προτάσεων που την ακολουθούν.
5. Πραγματική Ανάλυση: Η Πραγματική Ανάλυση είναι η πέμπτη και τελευταία φάση του NLP η οποία βοηθάει να ανακαλύψετε το επιδιωκόμενο αποτέλεσμα εφαρμόζοντας ένα σύνολο κανόνων που χαρακτηρίζουν τους συνεργατικούς διαλόγους (Chopra, Prashar, Sain, 2013).



Εικόνα 3: Natural Language Processing

2.2 Ιστορική Αναδρομή NLP

Ο όρος NLP δεν είχε εμφανιστεί καθόλου ούτε μέχρι τα τέλη της δεκαετίας του 1940, αλλά η εργασία σχετικά με την αυτόματη μετάφραση (MT) είχε ήδη ξεκινήσει. Η έρευνα σε αυτήν την περίοδο δεν ήταν πλήρως εντοπισμένη. Τα Ρώσικα και τα Αγγλικά ήταν οι κυρίαρχες γλώσσες για την αυτόματη μετάφραση (MT), αλλά χρησιμοποιήθηκαν και διάφορες άλλες γλώσσες όπως τα Κινέζικα στην MT. Η έρευνα MT/NLP κόντεψε να τελειώσει οριστικά το 1966 διότι θεώρησαν οι επιστήμονες της εποχής ότι δεν θα καταλήξει πουθενά αλλά αργότερα ορισμένα συστήματα MT παρείχαν χρήσιμα προϊόντα στους πελάτες τους. Εκείνη την εποχή, είχαν ξεκινήσει και οι εργασίες για τη χρήση των υπολογιστών για λογοτεχνικές και γλωσσικές μελέτες (Khurana, Koli, Khatter & Singh, 2017).

Ήδη από το 1960 ξεκίνησε η κατασκευή βάσεων δεδομένων επηρεασμένη από την τεχνητή νοημοσύνη, με τα συστήματα απαντήσεων σε ερωτήσεις BASEBALL (Green et al., 1961). Το LUNAR και το SHRDLU ήταν φυσικοί διάδοχοι αυτών των συστημάτων, αλλά θεωρήθηκαν ως πιο εξελιγμένα, όσον αφορά τις γλωσσικές τους ικανότητες και τις ικανότητές τους σε επεξεργασία εργασιών. Υπήρχε μια ευρέως διαδεδομένη πεποίθηση ότι η πρόοδος θα μπορούσε να σημειωθεί και στις δύο πλευρές, η μία είναι το έργο ARPA Speech Understanding Research (SUR) (Lea, 1980) και το άλλο σε ορισμένα μεγάλα έργα ανάπτυξης συστημάτων για τη δημιουργία front-end βάσεων δεδομένων. Τα έργα front-end (Hendrix et al., 1978) προορίζονταν να υπερβούν το LUNAR στη διασύνδεση των μεγάλων βάσεων δεδομένων.

Στις αρχές της δεκαετίας του 1980 η υπολογιστική γραμματική θεωρία έγινε ένας πολύ ενεργός τομέας έρευνας που συνδέεται με λογικές εργασίες για την αναπαράσταση νοήματος και την ικανότητα της γνώσης που μπορεί να αντιμετωπίσει τις πεποιθήσεις και τις προθέσεις του χρήστη της γλώσσας, ακόμα μπορεί να συλλάβει χαρακτηριστικά και λειτουργίες λόγου όπως έμφαση και θέμα (Jones, 2001).

Μέχρι το τέλος της δεκαετίας του 1980, οι ισχυροί επεξεργαστές προτάσεων γενικού σκοπού όπως το Core Language Engine του SRI (Alshawi, 1992) και η Θεωρία Αναπαράστασης Λόγου (Khurana, Koli, Khatter & Singh, 2017) πρόσφεραν ένα μέσο αντιμετώπισης πιο εκτεταμένου λόγου εντός του γραμματικό-λογικού πλαισίου. Αυτή η περίοδος μπορεί να θεωρηθεί ως περίοδος αυξανόμενης εμπιστοσύνης και εδραίωσης. Έγιναν διαθέσιμοι πρακτικοί πόροι, γραμματικές καθώς και αλγόριθμοι ανάλυσης (π.χ. τα Alvey Natural Language Tools) (Boguraev et al., 1987).

Ακόμα βλέπουμε ότι τα συνέδρια (D)ARPA αναγνώρισης ομιλίας και κατανόησης μηνυμάτων (εξαγωγής πληροφοριών) δεν αφορούσαν μόνο τα καθήκοντα τους αλλά ασχολήθηκαν και έδωσαν έμφαση στη βαριά αξιολόγηση, ξεκινώντας μια τάση που έγινε κύριο χαρακτηριστικό τη δεκαετία του 1990 (Young & Chase, 1998; Sundheim & Chinchor, 1993).

Τα τελευταία δέκα χρόνια της χιλιετίας, το πεδίο αναπτυσσόταν ραγδαία. Αυτό μπορεί να αποδοθεί στην αυξημένη διαθεσιμότητα μεγάλων ποσοτήτων ηλεκτρονικού κειμένου, στην

διαθεσιμότητα υπολογιστών με αυξημένη ταχύτητα και μνήμη καθώς και στην έλευση του Διαδικτύου (Liddy, 2001).

Οι στατιστικές προσεγγίσεις κατάφεραν να αντιμετωπίσουν πολλά γενικά προβλήματα στην υπολογιστική γλωσσολογία, όπως η αναγνώριση μέρους του λόγου, η αποσαφήνιση της έννοιας της λέξης κ.λπ., και έχουν γίνει τυπικά σε όλο το NLP. Οι ερευνητές του NLP αναπτύσσουν τώρα συστήματα NLP επόμενης γενιάς που αντιμετωπίζουν αρκετά καλά το γενικό κείμενο και αντιμετωπίζει τα προβλήματα που ευθύνονται για ένα μεγάλο μέρος της μεταβλητότητας και της ασάφειας της γλώσσας (Liddy, 2001).

2.3 Τεχνικές NLP

Η επεξεργασία φυσικής γλώσσας (NLP) χρησιμοποιεί τεχνικές για την εξαγωγή δεδομένων από κείμενο. Υπάρχουν 5 κορυφαίες τεχνικές που χρησιμοποιούνται περισσότερο, αυτές οι τεχνικές είναι:

1. **Ανάλυση Συναισθήματος:** Η πιο ευρέως χρησιμοποιούμενη τεχνική στο NLP είναι η ανάλυση συναισθήματος και είναι η πιο χρήσιμη σε περιπτώσεις όπως οι έρευνες πελατών, κριτικές και σχόλια μέσω κοινωνικής δικτύωσης όπου οι άνθρωποι εκφράζουν τις απόψεις και τα σχόλια τους. Το απλούστερο αποτέλεσμα της ανάλυσης συναισθήματος είναι μια κλίμακα 3 σημείων συναισθημάτων (θετικά, αρνητικά, ουδέτερα). Σε πιο σύνθετες περιπτώσεις η έξοδος μπορεί να είναι μια αριθμητική βαθμολογία που μπορεί να χωριστεί σε όσες κατηγορίες απαιτείται. Στην περίπτωση αποσπάσματος κειμένου ο πελάτης εκφράζει διαφορετικά συναισθήματα σε διάφορα μέρη του κειμένου. Εξαιτίας αυτού η έξοδος δεν είναι πολύ χρήσιμη αντίθετα, μπορούμε να βρούμε το συναίσθημα κάθε πρότασης και να διαχωρίσουμε τα αρνητικά και τα θετικά μέρη της κριτικής. Η βαθμολογία συναισθήματος μπορεί επίσης να μας βοηθήσει να διαλέξουμε τα πιο αρνητικά και θετικά μέρη της κριτικής. Το πιο δημοφιλές εμποπτευμένο μοντέλο που χρησιμοποιείται για την ανάλυση συναισθημάτων είναι το Naïve Bayes (Nasukawa, Bunescu, Niblack, 2003).
2. **Αναγνώριση Επωνυμίας Οντότητας:** Η πιο βασική τεχνική στο NLP είναι η εξαγωγή των οντοτήτων στο κείμενο. Αναδεικνύει τις θεμελιώδεις έννοιες και αναφορές στο κείμενο. Η αναγνώριση ονομαστικών οντοτήτων (NER) προσδιορίζει οντότητες όπως άτομα, τοποθεσίες, οργανισμούς ημερομηνίες κ.λπ. από το κείμενο. Το NER βασίζεται γενικά σε κανόνες γραμματικής και εμποπτευμένα μοντέλα. Ωστόσο, υπάρχουν πλατφόρμες NER όπως το ανοιχτό NLP που διαθέτουν προεκπαιδευμένα και ενσωματωμένα μοντέλα NER (Maulud et al., 2021).
3. **Σύνοψη Κειμένου:** Όπως υποδηλώνει το όνομα, υπάρχουν τεχνικές στο NLP που βοηθούν στην σύνοψη μεγάλων τμημάτων κειμένου. Η σύνοψη κειμένων χρησιμοποιείται κυρίως σε περιπτώσεις όπως άρθρα ειδήσεων και ερευνητικά άρθρα. Δύο γενικές προσεγγίσεις για τη σύνοψη κειμένου είναι η εξαγωγή και η αφαίρεση. Η μέθοδος της εξαγωγής δημιουργεί μια περίληψη εξαγοντας μέρη από το κείμενο. Η μέθοδος της αφαίρεσης δημιουργεί την σύνοψη δημιουργώντας νέο κείμενο που μεταφέρει την ουσία του αρχικού κειμένου (Sun et al., 2017).
4. **Μοντελοποίηση Θεμάτων:** Η μοντελοποίηση θεμάτων είναι μια από τις πιο περίπλοκες μεθόδους για τον εντοπισμό φυσικών θεμάτων στο κείμενο. Ένα πρωταρχικό πλεονέκτημα της μοντελοποίησης θεμάτων είναι ότι είναι μια τεχνική χωρίς επίβλεψη. Δεν απαιτείται εκπαίδευση μοντέλου και επισημασμένο σύνολο δεδομένων εκπαίδευσης. Υπάρχουν αρκετοί αλγόριθμοι για τη μοντελοποίηση θεμάτων όπως είναι η Λανθάνουσα σημασιολογική ανάλυση (LSA) και η Λανθάνουσα κατανομή Dirichlet (LDA). Μια από τις πιο δημοφιλείς μεθόδους είναι η λανθάνουσα κατανομή Dirichlet. Η υπόθεση του LDA είναι ότι κάθε έγγραφο κειμένου αποτελείται από πολλά θέματα και κάθε θέμα αποτελείται από πολλές λέξεις. Η εισαγωγή που απαιτείται από το LDA είναι απλώς τα έγγραφα κειμένου και ο αναμενόμενος αριθμός θεμάτων (Maulud et al., 2021).
5. **Εξόρυξη Πτυχών:** Η εξόρυξη πτυχών προσδιορίζει τις διαφορετικές πτυχές του κειμένου. Όταν χρησιμοποιείται σε συνδυασμό με την ανάλυση συναισθήματος, εξάγει πλήρεις πληροφορίες για το κείμενο. Μία από τις ευκολότερες μεθόδους εξόρυξης πτυχών είναι η χρήση ετικετών μέρους του λόγου. Όταν χρησιμοποιείται εξόρυξη πτυχών μαζί με

ανάλυση συναισθήματος στο δείγμα κειμένου, η έξοδος μεταφέρει την πλήρη πρόθεση του κειμένου (Sun et al., 2017).

2.4 Εφαρμογές NLP

Η επικοινωνία είναι ένας σημαντικός παράγοντας που οικοδομεί σχέσεις μεταξύ των ατόμων, αλλά και μεταξύ οργανισμών και ατόμων. Οι αλληλεπιδράσεις μεταξύ των ανθρώπων από διαφορετικές χώρες έχουν διευκολυνθεί με τη χρήση μεταφραστών. Ωστόσο, με την ανάπτυξη του NLP, οι επικοινωνίες μεταξύ τέτοιων οντοτήτων έχουν γίνει ευκολότερες, με τη γλώσσα να μην αποτελεί πλέον εμπόδιο στις ανθρώπινες και στις επιχειρηματικές αλληλεπιδράσεις. Οι επιχειρήσεις μπορούν να διεθνοποιήσουν τις δραστηριότητες τους και οι εμπορικές σχέσεις μπορούν να βελτιωθούν, ενισχύοντας έτσι το παγκόσμιο εμπόριο. Αυτή τη στιγμή οι κυριότερες εφαρμογές επεξεργασίας φυσικής γλώσσας σχετίζονται με τη δημιουργία συστημάτων αυτόματης εξυπηρέτησης πελατών, marketing καθώς και με τα χρηματοοικονομικά (Bahja, 2020).

Για τον τομέα της εξυπηρέτησης πελατών, είναι διαδεδομένη η χρήση ανεπτυγμένων συστημάτων που λαμβάνουν τις εισερχόμενες κλήσεις και προσπαθούν μέσω αυτοματοποιημένων σεναρίων να εξυπηρετήσουν τους πελάτες περιορίζοντας έτσι την ανάγκη της ανθρώπινης παρέμβασης. Αυτά τα συστήματα συνομιλίας μας επιτρέπουν να κάνουμε την συνομιλία με το αυτοματοποιημένο σύστημα σε φυσική γλώσσα μέσω διασύνδεσης φωνής η κειμένου. Βοηθούν στην αυτοματοποίηση των πολύπλοκων ροών εργασίας σε έναν οργανισμό παρέχοντας υποστήριξη 24 ώρες 7 ημέρες την εβδομάδα στους χρήστες του. Οι πιο συνηθισμένοι τύποι συσκευών συνομιλίας είναι τα Chatbots και οι Virtual Assistants. Σήμερα αυτές οι δύο συσκευές χρησιμοποιούνται από τράπεζες, ηλεκτρονικό εμπόριο, μέσα κοινωνικής δικτύωσης και άλλα συστήματα αυτοεξυπηρέτησης σημείων πωλήσεων για την παροχή διαφόρων υπηρεσιών στους πελάτες τους (Kalyanathaya et al., 2019).

Στον τομέα του marketing ευρύτατα διαδεδομένη είναι η παρακολούθηση των social media από εταιρίες και από άλλους οργανισμούς για την μέτρηση της δημοτικότητας τους. Σε αυτό ειδικευμένο ρόλο παίζουν οι τεχνικές της Μηχανικής Μάθησης και της Τεχνητής Νοημοσύνης για την λεγόμενη ανάλυση συναισθημάτων (sentiment analysis). Οι τεχνικές αυτές επιτρέπουν την κατανόηση των συναισθημάτων του ατόμου που γράφει και προσφέρουν στις εταιρίες τη δυνατότητα να εξετάζουν αν το κοινό έχει θετική η αρνητική εικόνα για τα προϊόντα και τις δράσεις τους (Bahja, 2020).

Στα χρηματοοικονομικά οι λύσεις που βασίζονται στο NLP αναπτύσσονται σε εφαρμογές όπως η αξιολόγηση πιστοληπτικής ικανότητας, η ανάλυση συναισθημάτων και η αναζήτηση εγγράφων. Η εφαρμογή αξιολόγησης πιστοληπτικής ικανότητας βοηθά τις τράπεζες και τα χρηματοπιστωτικά ιδρύματα να αξιολογήσουν την πιστοληπτική ικανότητα ενός ατόμου και να παρέχουν πιστωτικό σκορ χρησιμοποιώντας NLP και Μηχανική Μάθηση. Σε εφαρμογές ανάλυσης συναισθήματος αυτοματοποιούν τις εργασίες εξόρυξης κειμένου για πληροφορίες σε πραγματικό χρόνο στην αγορά από ισότοπους ειδήσεων και μέσα κοινωνικής δικτύωσης και στη συνέχεια πραγματοποιούν ταξινόμηση εγγράφων και αναγνώριση ονομαστικών οντοτήτων για να φιλτράρουν τις περισσότερες σχετικές πληροφορίες για τις ανάγκες των επενδυτών. Σε εφαρμογές αναζήτησης εγγράφων, οι τράπεζες ή τα χρηματοπιστωτικά ιδρύματα χρησιμοποιούν διεπαφή chatbot που επιτρέπει στους πελάτες τους να αναζητούν πληροφορίες και να λαμβάνουν απαντήσεις σε βασικά ερωτήματα συναλλαγών (Bahja, 2020).

2.5 Εξέλιξη NLP

Τα τελευταία χρόνια η επεξεργασία φυσικής γλώσσας έχει πραγματοποιήσει αλματώδεις προόδους με τα νευρωνικά δίκτυα να αποτελούν ένα βασικό εργαλείο και το διαδίκτυο να είναι μια ανεξάντλητη πηγή δεδομένων αλλά και πεδίο εφαρμογών. Στο μέλλον σύμφωνα με ειδικούς οι οργανισμοί και οι εταιρίες θα πραγματοποιούν την επικοινωνία με τους πελάτες τους χρησιμοποιώντας φυσική γλώσσα μέσω ψηφιακών βοηθών. Η τεχνολογία που θα χρησιμοποιούν υπάρχει ήδη σε συσκευές όπως Google Home ανεπτυγμένη από την εταιρεία της Google, άλλη εταιρεία που έχει αναπτύξει τέτοια τεχνολογία είναι η Apple με το λογισμικό Siri καθώς και η εταιρεία Amazon έχει αντίστοιχο λογισμικό που ονομάζεται Alexa. Οι συσκευές αυτές επιτρέπουν στους χρήστες τους να κάνουν μια σειρά από εργασίες όπως το να

χειρίζονται οικιακές συσκευές, να αναζητούν πληροφορίες και να παραγγέλλουν προϊόντα (Johri et al., 2021).

Σύμφωνα με τον Brett King, ο οποίος είναι ο ιδρυτής της Moven στο μέλλον ο κόσμος θα επικοινωνεί με την χρήση τέτοιων συσκευών με τα χρηματοπιστωτικά ιδρύματα για να πληροφορείται την κατάσταση των λογαριασμών του και να αγοράζει τα προϊόντα τους. Ταυτόχρονα θα υπάρχουν σε λειτουργία αλγόριθμοι Τεχνητής Νοημοσύνης που θα προσπαθούν να προβλέψουν τις ανάγκες του κάθε ατόμου ξεχωριστά με σκοπό να του πωλούνται τα κατάλληλα προϊόντα και υπηρεσίες. Ήδη οι εταιρείες Google, Apple και Amazon έχουν αυτή την τεχνολογία και παρέχουν τις υπηρεσίες τους σε διάφορους Χρηματοοικονομικούς Οργανισμούς (Nichkasona et al., 2020).

Η επιρροή της αγοράς προκαλεί έντονο ανταγωνισμό μεταξύ των υφιστάμενων εταιρειών που βασίζονται στο NLP. Επίσης, ωθεί το NLP περισσότερο προς την ανάπτυξη ανοιχτού κώδικα. Εάν η κοινότητα του NLP αγκαλιάσει την Ανάπτυξη Ανοιχτού Κώδικα, θα κάνει τα συστήματα NLP λιγότερο ιδιόκτητα και επομένως λιγότερο ακριβά. Επίσης τα συστήματα που θα κατασκευαστούν θα έχουν εύκολα αντικαταστάσιμα εξαρτήματα, τα οποία θα χρειάζονται λιγότερο χρόνο για να κατασκευαστούν και θα είναι πιο φιλικά προς το χρήστη. Τα Chatterbot αν και υπάρχουν ήδη, νέες γενιές τους αναπτύσσονται συνεχώς (Reshamwala et al., 2013).

Κεφάλαιο 3^ο: Μηχανική Μάθηση


3.1 Ο Όρος Μηχανική Μάθηση

Ο όρος της Μηχανικής Μάθησης ή αλλιώς Machine Learning είναι μια υποκατηγορία του κλάδου της Τεχνητής Νοημοσύνης. Όταν ακούμε τον όρο της Μηχανικής Μάθησης μας έρχεται στο μυαλό το επιστημονικό πεδίο που δίνει μεγάλη βαρύτητα στους αλγορίθμους και στα στατιστικά μοντέλα που χρησιμοποιούνται στα υπολογιστικά συστήματα για να εκτελέσουν μια συγκεκριμένη εργασία ή ακόμα και να εξάγουν συμπεράσματα εκμεταλλευόμενα τα μοτίβα μέσα στα δεδομένα. Το σύνολο των δεδομένων υποβάλλεται σε επεξεργασία για την κατασκευή ενός απλού μοντέλου με πολύτιμή χρήση, για παράδειγμα, προγνωστική ακρίβεια. Οι τομείς εφαρμογής της Μηχανικής Μάθησης είναι άφθονοι τέτοιοι τομείς είναι ο χρηματοοικονομικός τομέας, οι τράπεζες που αναλύουν τα προηγούμενα δεδομένα τους για να δημιουργήσουν μοντέλα για χρήση σε πιστωτικές εφαρμογές, ανίχνευση απάτης, χρησιμοποιούνται ακόμα και στο χρηματιστήριο. Τα μοντέλα εκμάθησης χρησιμοποιούνται για βελτιστοποίηση, έλεγχο και αντιμετώπιση προβλημάτων (Alpaydin, 2020).

Η Μηχανική Μάθηση είναι ο προγραμματισμός υπολογιστών για τη βελτιστοποίηση ενός κριτηρίου απόδοσης χρησιμοποιώντας παραδείγματα δεδομένων η προηγούμενη εμπειρία. Έχουμε ένα μοντέλο που έχει οριστεί μέχρι κάποιες παραμέτρους και η εκμάθηση είναι η εκτέλεση ενός προγράμματος υπολογιστή για τη βελτιστοποίηση των παραμέτρων του μοντέλου χρησιμοποιώντας τα δεδομένα εκπαίδευσης η την προηγούμενη εμπειρία. Το μοντέλο μπορεί να είναι προγνωστικό για να κάνει προβλέψεις στο μέλλον η περιγραφικό για να αποκτήσει γνώση από δεδομένα ή και τα δύο (Alpaydin, 2020).

Η Μηχανική Μάθηση χρησιμοποιεί τη θεωρία των στατιστικών για τη δημιουργία μαθηματικών μοντέλων, επειδή η βασική εργασία είναι η εξαγωγή συμπερασμάτων από ένα δείγμα. Ο ρόλος της επιστήμης των υπολογιστών είναι διπλός: Πρώτον, στην εκπαίδευση χρειαζόμαστε αποτελεσματικούς αλγορίθμους για την επίλυση του προβλήματος βελτιστοποίησης, καθώς και για την αποθήκευση και επεξεργασία του τεράστιου όγκου δεδομένων που έχουμε γενικά. Δεύτερον, από την στιγμή που μαθαίνεται ένα μοντέλο, η αναπαράσταση του και η αλγοριθμική λύση για εξαγωγή συμπερασμάτων πρέπει επίσης να είναι αποτελεσματικές. Σε ορισμένες εφαρμογές, η αποτελεσματικότητά του αλγορίθμου μάθησης η συμπερασμάτων, δηλαδή η χωρική και χρονική πολυπλοκότητα του, μπορεί να είναι εξίσου σημαντική με την προγνωστική του ακρίβεια (Alpaydin, 2020).

Η απόδοση του μοντέλου Μηχανικής Μάθησης σε μια συγκεκριμένη εργασία μετράται από μια μέτρηση απόδοσης που βελτιώνεται με την εμπειρία και με την πάροδο του χρόνου. Για τον υπολογισμό της απόδοσης μοντέλων και αλγορίθμων Μηχανικής Μάθησης, χρησιμοποιούνται διάφορα στατιστικά και μαθηματικά μοντέλα. Μετά το τέλος της διαδικασίας, το εκπαιδευόμενο μοντέλο μπορεί να χρησιμοποιηθεί για την ταξινόμηση, πρόβλεψη ή ομαδοποίηση νέων παραδειγμάτων (δεδομένα δοκιμής) χρησιμοποιώντας την εμπειρία που αποκτήθηκε κατά τη διάρκεια της εκπαιδευτικής διαδικασίας.



Εικόνα 4: Τυπική Προσέγγιση Μηχανικής Μάθησης

Οι εργασίες της Μηχανικής Μάθησης ταξινομούνται συνήθως σε διαφορετικές ευρείες κατηγορίες ανάλογα με τον τύπο εκμάθησης (εποπτευόμενη/μη εποπτευόμενη), τα μοντέλα μάθησης (ταξινόμηση, παλινδρόμηση, ομαδοποίηση και μείωση διαστάσεων) ή τα μοντέλα μάθησης που χρησιμοποιούνται για την υλοποίηση της επιλεγμένης εργασίας (Liakos et al., 2018).

Στην εποπτευόμενη μάθηση, τα δεδομένα παρουσιάζονται με παραδείγματα εισρών και των αντίστοιχων εξόδων, και ο στόχος είναι να δημιουργηθεί ένας γενικός κανόνας που αντιστοιχίζει τις εισόδους στις εξόδους. Σε ορισμένες περιπτώσεις, οι εισροές μπορούν να είναι διαθέσιμες μόνο εν μέρει με ορισμένες από τις εξόδους-στόχους να λείπουν ή να δίνονται μόνο ως ανατροφοδότηση για τις ενέργειες σε ένα δυναμικό περιβάλλον (ενισχυτική μάθηση). Στην εποπτευόμενη ρύθμιση, το εκπαιδευμένο μοντέλο χρησιμοποιείται για την πρόβλεψη των αποτελεσμάτων που λείπουν (ετικέτες) για τα δεδομένα δοκιμής. Στην μάθηση χωρίς επίβλεψη, ωστόσο, δεν υπάρχει διάκριση μεταξύ συνόλων εκπαίδευσης και δοκιμών με τα δεδομένα να είναι χωρίς ετικέτα. Ο εκπαιδευόμενος επεξεργάζεται δεδομένα εισόδου με στόχο να ανακαλύψει κρυφά μοτίβα (Liakos et al., 2018).

Με την χρήση της Τεχνητής Νοημοσύνης και της Μηχανικής Μάθησης έχουν αναπτυχθεί πολλές μέθοδοι για την αποτελεσματική αντιμετώπιση προβλημάτων. Επομένως είναι πολύ χρήσιμο να έχουμε ένα σύστημα κατηγοριοποίησης τους. Αν χρησιμοποιήσουμε ως κριτήριο ταξινόμησης τη φύση του προβλήματος που επιλύει η κάθε μέθοδος τότε έχουμε τις εξής ομάδες όπως είναι η Κατηγοριοποίηση και Πρόβλεψη, Συσταδοποίηση ή Ομαδοποίηση, Επεξεργασία Φυσικής Γλώσσας, Υπολογιστική Όραση, Συστήματα Συστάσεων και τα λοιπά προβλήματα και μέθοδοι επίλυσης τους (Alzubi et al., 2018).

3.2 Ιστορική Αναδρομή της Μηχανικής Μάθησης

Το ενδιαφέρον για τις υπολογιστικές προσεγγίσεις στη μάθηση χρονολογείται από τις απαρχές της τεχνητής νοημοσύνης και της γνωστικής επιστήμης στα μέσα της δεκαετίας του 1950. Η ποικιλομορφία τόσο στις εργασίες όσο και στις μεθόδους χαρακτήρισε την έρευνα από την αρχή, με την εργασία να περιλαμβάνει θέματα όπως το παιχνίδι, η αναγνώριση γραμμάτων οι αφηρημένες έννοιες και η λεκτική μνήμη. Η μάθηση θεωρήθηκε ως κεντρικό χαρακτηριστικό των ευφυών συστημάτων και η εργασία τόσο στη μάθηση όσο και στην απόδοση αφορούσε την ανάπτυξη γενικών μηχανισμών για τη γνώση, τη αντίληψη και τη δράση (Langley, 1996).

Στα μέσα της δεκαετίας του 1960, τόσο οι ερευνητές της τεχνητής νοημοσύνης όσο και οι ψυχολόγοι συνειδητοποίησαν τη σημασία της γνώσης του τομέα, η οποία οδήγησε στην δημιουργία των πρώτων συστημάτων έντασης γνώσης. Ωστόσο, οι ερευνητές της μάθησης συνέχισαν να επικεντρώνονται σε γενικές, ανεξάρτητες από τον τομέα μεθόδους, με τις περισσότερες εργασίες να εφαρμόζονται σε αντιληπτικούς τομείς. Τελικά η αναγνώριση προτύπων και η τεχνητή νοημοσύνη χωρίστηκαν σε δύο διαφορετικά πεδία. Κατά την διάρκεια αυτής της περιόδου, οι περισσότεροι ερευνητές τεχνητής νοημοσύνης απέφυγαν ζητήματα μάθησης ενώ προσπαθούσαν να κατανοήσουν τον ρόλο της γνώσης στην ευφυή συμπεριφορά. Η έρευνα για την αναπαράσταση γνώσης, τη φυσική γλώσσα και τα έμπειρα συστήματα κυριάρχησαν αυτήν την εποχή. Ωστόσο ορισμένες εργασίες για τη μάθηση συνεχίστηκαν στο παρασκήνιο ενσωματώνοντας τις αναπαραστάσεις και τις ευρετικές μεθόδους που είχαν γίνει κεντρικές για την τεχνητή νοημοσύνη (Langley, 1996).

Στα τέλη της δεκαετίας του 1970, ένα νέο ενδιαφέρον για τη μηχανική μάθηση εμφανίστηκε στην τεχνητή νοημοσύνη και αναπτύχθηκε γρήγορα κατά τη διάρκεια μερικών ετών. Πολλοί ενθουσιάστηκαν από την προοπτική της αυτοματοποίησης της απόκτησης βάσεων γνώσεων για συγκεκριμένους τομείς και άλλοι ήλπιζαν να μοντελοποιήσουν την ανθρώπινη μάθηση. Η έρευνα για την επαγωγή εννοιών και την απόκτηση γλώσσας συνεχίστηκε, αλλά σε αυτήν συνδυάστηκε η εργασία για την ανακάλυψη μηχανών και τη μάθηση στην επίλυση προβλημάτων. Προτάθηκαν πολλές νέες μέθοδοι και εμφανίστηκε ένα ανανεωμένο ενδιαφέρον για τα νευρωνικά δίκτυα, επαναφέροντας τεχνικές που είχαν εγκαταλειφτεί από την τεχνητή νοημοσύνη χρόνια νωρίτερα (Langley, 1996).

Η μηχανική μάθηση συνέχισε να αναπτύσσεται και κατά τη διάρκεια της δεκαετίας του 1980, με την εργασία να επεκτείνεται στον προγραμματισμό τη διάγνωση τον σχεδιασμό και τον έλεγχο. Οι ερμηνευτές ήταν πιο σοβαροί σχετικά με τις πραγματικές δυνατότητες των

αλγορίθμων εκμάθησης και μια σειρά επιτυχημένων εφαρμογών στο πεδίο έδειξαν ότι η τεχνολογία θα μπορούσε να έχει αντίκτυπο στην βιομηχανία. Το πεδίο τοποθετήθηκε επίσης σε πολύ πιο σταθερές μεθοδολογικές βάσεις, με τον συστηματικό πειραματισμό σε κοινά σύνολα δεδομένων και την ακριβή θεωρητική ανάλυση να γίνονται ο κανόνας και όχι η εξαίρεση (Langley, 1996).

Η μηχανική μάθηση έγινε ένα ξεχωριστό πεδίο και άρχισε να αναπτύσσεται περισσότερο την δεκαετία του 1990. Η επίτευξη της τεχνητής νοημοσύνης στην αντιμετώπιση επιλύσιμων προβλημάτων πρακτικής φύσης άλλαξε τον στόχο του πεδίου, και ενώ οι αλγόριθμοι της μηχανικής μάθησης συνήθως επικεντρώνονται στην προγνωστική απόδοση, η εργασία για την ερμηνευτικότητα στην μηχανική μάθηση υπάρχει εδώ και πολλά χρόνια. Το ενσωματωμένο μέτρο σημασίας χαρακτηριστικών των τυχαίων δασών ήταν ένα από τα σημαντικά ορόσημα της μηχανικής μάθησης (Molnar et al., 2020).

Στη δεκαετία του 2010 ήρθε η διαφημιστική εκστρατεία βαθιάς μάθησης, αφού ένα βαθύ νευρωνικό δίκτυο κέρδισε την πρόκληση ImageNet. Λίγα χρόνια μετά, το πεδίο της μηχανικής μάθησης πραγματικά απογειώθηκε γύρω στο 2015, κρίνοντας από τη συχνότητα που αναζητούσε ο κόσμος τον όρο «Μηχανική Μάθηση» στο Google και τα έγγραφα που δημοσιεύονται με αυτούς τους όρους. Έκτοτε, έχουν εισαχθεί πολλές μέθοδοι επεξήγησης αγνωστικών μοντέλων, οι οποίες λειτουργούν για διαφορετικούς τύπους μοντέλων μηχανικής μάθησης. Αλλά και μέθοδοι επεξήγησης ειδικά για μοντέλα έχουν αναπτυχθεί, για παράδειγμα, για την ερμηνεία των βαθιών νευρωνικών δικτύων ή των συνόλων δέντρων. Η ανάλυση παλινδρόμησης και η βασισμένη σε κανόνες της μηχανικής μάθησης παραμένουν σημαντικοί και ενεργοί ερευνητικοί τομείς μέχρι σήμερα και συνδυάζονται μεταξύ τους (Molnar et al., 2020).

3.3 Τμηματοποίηση Πελατών – Ιεραρχική Ομαδοποίηση

Η ιεραρχική ομαδοποίηση είναι μια εξέχουσα κατηγορία αλγορίθμων ομαδοποίησης. Ήταν η κυρίαρχη προσέγγιση για την κατασκευή ενσωματωμένων σχημάτων ταξινόμησης. Σε σύγκριση με μεθόδους που βασίζονται σε επίπεδη ομαδοποίηση όπως το K-means, μια ιεραρχική ομαδοποίηση προσφέρει πολλά πλεονεκτήματα. Πρώτον, δεν χρειάζεται να προκαθορίσουμε τον αριθμό των συμπλεγμάτων. Η ιεραρχική ομαδοποίηση εξάγει το δένδρογραμμα, το οποίο ο χρήστης μπορεί στη συνέχεια να διασχίσει για να αποκτήσει την επιθυμητή ομαδοποίηση. Δεύτερον, η δομή του δένδρογραμματος παρέχει έναν βολικό τρόπο διερεύνησης των σχέσεων οντοτήτων σε όλα τα επίπεδα ευαισθησίας. Εξαιτίας αυτού, για ορισμένες εφαρμογές όπως για την κατασκευή ταξινόμησης, το ίδιο το δένδρογραμμα, όχι οποιαδήποτε συστάδα που βρίσκεται σε αυτό, είναι το επιθυμητό αποτέλεσμα (Ma & Dhavala, 2018).

Οι αλγόριθμοι της ιεραρχικής ταξινόμησης χωρίζονται στις παρακάτω δύο κατηγορίες, στους αλγόριθμους agglomerative (αλγόριθμοι συγκόλλησης) και στους αλγόριθμους divisive (αλγόριθμοι διαίρεσης). Οι αλγόριθμοι συγκόλλησης αρχίζουν θεωρώντας ότι κάθε στοιχείο τους συνόλου δεδομένων αποτελεί μια διαφορετική συστάδα. Σε επόμενο βήμα πραγματοποιεί συγχώνευση των συστάδων σύμφωνα με κάποιο κριτήριο και η συγκεκριμένη διαδικασία συνεχίζεται μέχρι να ενοποιηθούν όλα τα στοιχεία σε μία συστάδα. Ενώ στους αλγόριθμους διαίρεσης η διαδικασία που πραγματοποιείται είναι αντίθετη σε σχέση με τους αλγόριθμους συγκόλλησης. Ο αλγόριθμος διαίρεσης ξεκινάει θεωρώντας ότι υπάρχει μόνο μια συστάδα που περιέχει όλα τα απαραίτητα στοιχεία και στην συνέχεια σπάει τις συστάδες σε μικρότερες μέχρι να καταλήξει σε συστάδες που να περιέχουν μόνο ένα στοιχείο η κάθε μια (Murtagh & Contreras, 2012).

Οι βασικότερες παράμετροι και αποφάσεις που καλείται να πάρει ο αναλυτής δεδομένων είναι οι εξής:

- Ο τρόπος με τον οποίο θα υπολογίσει την απόσταση μεταξύ των στοιχείων του συνόλου δεδομένων. Εάν το κάθε στοιχείο αναπαρίσταται από ένα διάνυσμα αριθμητικών μεταβλητών τότε οι κλασικοί τρόποι που θα γίνουν οι υπολογισμοί είναι η ευκλείδεια μετρική, η μετρική Manhattan και διάφορες άλλες. Βέβαια εάν στα δεδομένα έχουμε και κατηγορικές μετρικές, τότε οι επιλογές μας αυξάνονται. Αρκετά σημαντικό είναι να γνωρίζουμε ότι οι κατηγορικές μεταβλητές συγκεκριμένα αυτές που έχουν λίγες τιμές όπως για παράδειγμα το φύλο, τείνουν να κυριαρχούν σε σχέση με τις υπόλοιπες. Για παράδειγμα μια μεταβλητή με το φύλο των ανθρώπων είναι ένας διαιρετικός

αλγόριθμος ο οποίος θα σπάσει την αρχική συστάδα σε δύο ανάλογα με το φύλο (Ma & Dhavala, 2018).

- Το κριτήριο με το οποίο συγχωνεύονται η σπάνε οι ομάδες σε κάθε ένα βήμα. Η πρώτη επιλογή είναι να συνενώσει ή να διασπάσει κάποιος τις ομάδες που απέχουν την μικρότερη απόσταση μεταξύ τους. Για να υπολογιστεί η απόσταση μεταξύ των δύο ομάδων υπάρχουν πάλι αρκετοί τρόποι. Ως απόσταση μπορεί να θεωρηθεί η μικρότερη απόσταση μεταξύ των δύο παρατηρήσεων A και B. Η μπορεί να θεωρηθεί η μεγαλύτερη απόσταση μεταξύ των δύο παρατηρήσεων A και B. Η να χρησιμοποιηθεί η απόσταση των κέντρων τους (Ma & Dhavala, 2018).
- Το στάδιο του αλγορίθμου που θα χρησιμοποιηθεί. Οι αλγόριθμοι ιεραρχικής ομαδοποίησης έχουν δύο ακραίες καταστάσεις: μια μόνο ομάδα με όλα τα δεδομένα και τόσες ομάδες όσες και τα δεδομένα. Ο αναλυτής θα πρέπει να αποφασίσει ποιο από τα ενδιάμεσα στάδια θα χρησιμοποιήσει (Murtagh & Contreras, 2012).

Επειδή οι διαφορετικές κλίμακες που έχουν οι μεταβλητές μεταξύ τους επηρεάζουν την ανάλυση, η πιο συνήθης τακτική είναι να κανονικοποιούνται. Η πρώτη μέθοδος είναι η αφαίρεση από όλες τις τιμές του μέσου όρου της μεταβλητής και η διαίρεση του αποτελέσματος με τη τυπική απόκλιση της, και η δεύτερη μέθοδος είναι η αφαίρεση από όλες τις τιμές της ελάχιστης τιμής της μεταβλητής και η διαίρεση του αποτελέσματος με το εύρος της (Ma & Dhavala, 2018).

3.4 Τμηματοποίηση Πελατών – Αλγόριθμος k-Means

Η ομαδοποίηση K-means είναι ο πιο ευρέως χρησιμοποιούμενος αλγόριθμος ομαδοποίησης που χρησιμοποιείται σε πολλούς τομείς όπως η ανάκτηση πληροφοριών, η υπολογιστική όραση και η αναγνώριση προτύπων. Η ομαδοποίηση K-means εκχωρεί η σημεία δεδομένων σε k συστάδες έτσι ώστε παρόμοια σημεία δεδομένων να μπορούν να ομαδοποιηθούν. Είναι μια επαναληπτική μέθοδος που εκχωρεί κάθε σημείο στο σύμπλεγμα του οποίου το κέντρο είναι το πλησιέστερο. Στη συνέχεια υπολογίζει ξανά το κέντρο αυτών των ομάδων λαμβάνοντας τον μέσο όρο του (Shukla & Naganna, 2014).

Το πρόβλημα αυτό είναι υπολογιστικά δύσκολο (NP-hard) και ο αλγόριθμος k-means προσπαθεί να βρει μια προσεγγιστική λύση. Αυτό το πραγματοποιεί εκτελώντας τα εξής βήματα:

1. Επιλέγει στην τύχη k σημεία ως κέντρα των k ομάδων.
2. Για κάθε σημείο δεδομένων βρίσκει το πλησιέστερο κέντρο και κατατάσσει το σημείο στην αντίστοιχη ομάδα
3. Επαναυπολογίζει τα βαρύκεντρα των ομάδων.
4. Επαναλαμβάνει το βήμα Δύο και Τρία

Οι επαναλήψεις συνεχίζονται μέχρι να ικανοποιηθεί μια συνθήκη. Οι συνθηέςτερες είναι ο συγκεκριμένος αριθμός επαναλήψεων ή μια μικρή μεταβολή του αθροίσματος των τετραγώνων των αποστάσεων κάθε σημείου από το κέντρο της αντίστοιχης ομάδας από την προηγούμενη επανάληψη ή μια μη μεταβολή των κέντρων. (Kijispongse & Suriya, 2012).

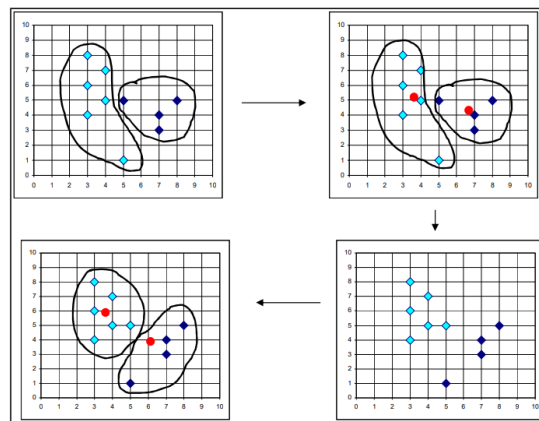
Προκειμένου να λυθεί ευρετικά το πρόβλημα, ο αλγόριθμος k-means ξεκινά με μια αρχική υποψήφια λύση $\{c_1, \dots, c_k\} \subseteq \mathbb{R}^d$, το οποίο μπορεί να επιλεγεί αυθαίρετα (συχνά, επιλέγεται ως ένα τυχαίο υποσύνολο του P). Στη συνέχεια, δύο βήματα εναλλάσσονται μέχρι τη σύγκλιση: Πρώτον, για κάθε c_i , ο αλγόριθμος υπολογίζει το σύνολο P_i όλων των σημείων στο P που είναι πιο κοντά στο c_i (όπου οι δεσμοί σπάνε αυθαίρετα). Στη συνέχεια, για κάθε $1 \leq i \leq k$, αντικαθιστά το c_i με το μέσο όρο του P_i . Λόγω αυτού του υπολογισμού του «μέσου» των συνόλων P_i , ο αλγόριθμος ονομάζεται αλγόριθμος k-means (Blömer et al., 2016).

THE k -MEANS ALGORITHMInput: Point set $P \subseteq \mathbb{R}^d$ number of centers k

1. Choose initial centers c_1, \dots, c_k of from \mathbb{R}^d
2. **repeat**
3. $P_1, \dots, P_k \leftarrow \emptyset$
4. **for each** $p \in P$ **do**
5. Let $i = \arg \min_{i=1, \dots, k} \|p - c_i\|^2$
6. $P_i \leftarrow P_i \cup \{p\}$
7. **for** $i = 1$ **to** k **do**
8. **if** $P_i \neq \emptyset$ **then** $c_i = \frac{1}{|P_i|} \sum_{p \in P_i} p$
9. **until** the centers do not change

Εικόνα 5: Αλγόριθμος K-means

Η λειτουργία του παραπάνω Αλγόριθμου μπορεί να εξηγηθεί ξεκάθαρα με τη βοήθεια ενός απλού παραδείγματος, το οποίο φαίνεται στην παρακάτω απεικόνιση.



Εικόνα 6: Διαδικασία του Αλγόριθμου Ομαδοποίησης K-means

Η Εικόνα 6 δείχνει τη γραφική αναπαράσταση για τη λειτουργία του αλγορίθμου K-means. Στο πρώτο βήμα υπάρχουν δύο σείτ αντικειμένων. Στη συνέχεια προσδιορίζονται τα κεντροειδή και των δύο συνόλων. Σύμφωνα με το κέντρο και πάλι σχηματίζονται οι συστάδες που έδωσαν τις διαφορετικές συστάδες δεδομένων. Αυτή η διαδικασία επαναλαμβάνεται μέχρι να επιτευχθούν οι καλύτερες ομάδες. Υπάρχουν άφθονα διαθέσιμα εργαλεία για την εξόρυξη δεδομένων. Μερικά από αυτά είναι τα Rapid Miner, R, Knime, Sas Or Sas Enterprise Miner και Matlab (Shukla & Naganna, 2014).

Ακόμα υπάρχουν ποικίλες εφαρμογές των τεχνικών ομαδοποίησης στους τομείς των οικονομικών, της υγειονομικής περίθαλψης, των τηλεπικοινωνιών, της επιστήμης, του Παγκόσμιου Ιστού κ.λπ. Μερικές από τις εφαρμογές είναι οι εξής:

- Αλγόριθμος ομαδοποίησης στις μηχανές αναζήτησης: Ο αλγόριθμος ομαδοποίησης παίζει σημαντικό ρόλο στη λειτουργία των μηχανών αναζήτησης. Ως εκ τούτου, λειτουργεί ως η ραχοκοκαλιά στις μηχανές που πραγματοποιούν την αναζήτηση. Ακόμα οι μηχανές αναζήτησης κάνουν προσπάθεια για να ομαδοποιήσουν παρόμοια είδη αντικειμένων σε ένα σύμπλεγμα και ανόμοια αντικείμενα σε άλλα. Η απόδοση των μηχανών αναζήτησης εξαρτάται από τη λειτουργία των τεχνικών ομαδοποίησης. Οι

πιθανότητες να λάβετε τα απαιτούμενα αποτελέσματα στην πρώτη σελίδα είναι περισσότερες εάν η τεχνική ομαδοποίησης είναι καλύτερη (Shukla & Naganna, 2014).

- Αλγόριθμος ομαδοποίησης για τους ακαδημαϊκούς: Η παρακολούθηση της ακαδημαϊκής προόδου των μαθητών ήταν ένα ζωτικό ζήτημα για την ακαδημαϊκή κοινωνία της τριτοβάθμιας εκπαίδευσης. Με την τεχνική ομαδοποίησης, αυτό το ζήτημα μπορεί να αντιμετωπιστεί εύκολα. Με βάση τις βαθμολογίες που έλαβαν οι μαθητές ομαδοποιούνται σε διαφορετικά clusters, όπου κάθε cluster δείχνει το διαφορετικό επίπεδο απόδοσης. Υπολογίζοντας τον αριθμό των μαθητών σε κάθε ομάδα μπορούμε να προσδιορίσουμε τη μέση επίδοση μιας ολόκληρης τάξης μαζί (Oyelade et al., 2010).

3.5 Το Πρόβλημα των Unbalanced Data

Με τον όρο μοντέλα ταξινόμησης ή κατηγοριοποίησης εννοούμε τα μαθηματικά μοντέλα που ως στόχο έχουν να ταξινομήσουν μια παρατήρηση σε μια από τις διαθέσιμες κατηγορίες. Η δημιουργία τέτοιων μοντέλων γίνεται με τη χρήση ενός αρχικού συνόλου παρατηρήσεων που είναι ήδη ταξινομημένες σε κατηγορίες. Το σύνολο αυτό ονομάζεται training set. Ένα από τα πιο δημοφιλή προβλήματα που υπάρχουν κατά την δημιουργία μοντέλων κατηγοριοποίησης/ταξινόμησης είναι ότι υπάρχει μεγάλη διαφορά μεταξύ της συχνότητας εμφάνισης μιας κατηγορίας από τις υπόλοιπες (Murhey et al., 2004).

Οι περιπτώσεις απόπειρας εξαπάτησης είναι μια τέτοια περίπτωση. Για παράδειγμα, εάν επιθυμούμε να δημιουργήσουμε ένα μοντέλο που να εκτιμά αν μια συναλλαγή με πιστωτική κάρτα είναι απόπειρα απάτης, τότε το σύνολο των δεδομένων που θα έχουμε θα περιέχει δύο ειδών συναλλαγές. Τις συναλλαγές που είναι απόπειρες εξαπάτησης και τις νόμιμες συναλλαγές. Σύμφωνα με τη λογική μπορούμε να υποθέσουμε ότι το 95% συναλλαγών θα είναι νόμιμες. Εάν κατασκευάζαμε ένα μοντέλο ναίει που για κάθε συναλλαγή απαντά ότι είναι νόμιμη, τότε αυτό θα είχε accuracy 95%. Αν μας ενδιέφερε μόνο η ακρίβεια (accuracy), ενώ ένα άλλο μοντέλο θα έπρεπε να είχε απόδοση μεγαλύτερη του 95%. Συνήθως στην πράξη μπορεί να προτιμηθεί ένα άλλο μοντέλο που να έχει χειρότερη επίδοση ως προς την ακρίβεια, αλλά καλύτερη επίδοση σε ένα άλλο δείκτη. Στο συγκεκριμένο παράδειγμα μπορεί να θέλαμε να εντοπίζουμε τις περισσότερες από τις μη νόμιμες συναλλαγές. Άρα θα θέλαμε το ποσοστό των μη νόμιμων συναλλαγών που σηματοδοτούνται ως τέτοιες να είναι υψηλό, δηλαδή θα θέλαμε μεγάλο recall για την κατηγορία των μη νόμιμων συναλλαγών. Από την άλλη βέβαια, δεν θα πρέπει το ποσοστό των νόμιμων συναλλαγών που σηματοδοτούνται ως απάτη να είναι μικρό, αλλιώς οι πελάτες μας θα αρχίσουν να παραπονιούνται (Padmaja et al., 2007).

Σε τεχνικό επίπεδο υπάρχουν διάφορες λύσεις που μπορούν να δοκιμαστούν για την αντιμετώπιση του προβλήματος. Μερικές από αυτές τις λύσεις είναι:

- Η χρήση ειδικών δεικτών στη βελτιστοποίηση των οποίων μπορεί να εστιάζει ο αλγόριθμος ταξινόμησης. Για παράδειγμα η βελτιστοποίηση του recall μιας κατηγορίας ή βελτιστοποίηση του F1-score ή η χρήση της accuracy σε συνδυασμό με κάποια βάρη.
- Η χρήση μέρους των διαθέσιμων δεδομένων όπου η κλάση που υπερέχει θα συμμετέχει σε μικρότερο ποσοστό. Η τεχνική αυτή λέγεται undersampling.
- Η χρήση συνόλου δεδομένων όπου έχουν προστεθεί περισσότερα αντίγραφα των κατηγοριών με μικρή συχνότητα. Η τεχνική αυτή λέγεται oversampling.
- Η δημιουργία συνθετικών περιπτώσεων των κατηγοριών με μικρή συχνότητα. Αυτό μπορεί να γίνει αν, για παράδειγμα με δεδομένα δύο παραδείγματα μιας κλάσης με μικρή συχνότητα, κατασκευάσουμε ένα καινούργιο παίρνοντας το μέσο όρο των τιμών στις συνεχείς μεταβλητές (Mountassir et al., 2012).

3.6 Ανίχνευση Απάτης


Η απάτη ταξινομείται ως οποιαδήποτε δραστηριότητα που σκοπεύει να προκαλέσει οικονομική ζημία. Με τη διεύρυνση του ψηφιακού χρήματος σε διάφορες χώρες, οι απάτες που σχετίζονται με αυτά έχουν επίσης αυξηθεί. Οι εταιρείες πιστωτικών καρτών και οι τράπεζες χάνουν δισεκατομμύρια από τέτοιες δόλιες δραστηριότητες κάθε χρόνο, γεγονός που τους κοστίζει ένα τεράστιο μέρος των εσόδων τους και επηρεάζει τις θέσεις εργασίας διάφορων εργαζομένων. Η Μηχανική Μάθηση και τα Νευρωνικά Δίκτυα μπορούν να χρησιμοποιηθούν για τον προσδιορισμό πιθανών απατεώνων χρησιμοποιώντας τα προηγούμενα λάθη και τις

λεπτομέρειες των προηγούμενων απατεώνων. Για να εντοπίσουμε εάν μια συναλλαγή είναι κανονική πληρωμή ή απάτη, θα χρησιμοποιήσουμε διάφορα μοντέλα πρόβλεψης. Οι αλγόριθμοι Machine Learning που χρησιμοποιούνται συνήθως είναι η Logistic Regression, Decision Trees και Deep Learning αλγόριθμους για την πρόβλεψη της απάτης μέσω τεχνητών νευρωνικών δικτύων (Ashraf et al., 2022).

Η μέθοδος της λογιστικής παλινδρόμησης (Logistic Regression) είναι μια μέθοδος ταξινόμησης/κατηγοριοποίησης. Στην πιο απλή της μορφή χρησιμεύει για την ταξινόμηση σε δύο κατηγορίες. Η λογιστική παλινδρόμηση κατασκευάζει ένα μοντέλο το οποίο εκτιμά την πιθανότητα να ανήκει μια περίπτωση σε μια κατηγορία (Azhan et al., 2020).

Η βασική ιδέα πίσω από την ταξινόμηση με την χρήση δένδρων αποφάσεων (Decision Trees) είναι ότι σε κάθε βήμα μια μεταβλητή του συνόλου δεδομένων επιλέγεται και το σύνολο χωρίζεται συνήθως σε δύο μέρη με βάση αυτή τη μεταβλητή και στη συνέχεια για κάθε μέρος επαναλαμβάνεται η ίδια διαδικασία. Αυτό συνεχίζεται μέχρι να ικανοποιηθεί κάποια συνθήκη. Για την επιλογή της μεταβλητής σε κάθε βήμα αλλά και για τον τρόπο χωρισμού της υπάρχουν διάφορα κριτήρια. Σε γενικές γραμμές χρησιμοποιείται μια συνάρτηση που εκτιμά πόσο καλά κάθε κόμβος του δένδρου περιέχει περιπτώσεις που ανήκουν σε μια μόνο κατηγορία. Ένα μέτρο καθαρότητας κάθε κόμβου. Για κάθε σπάσιμο υπολογίζεται ο σταθμισμένος μέσος όρος της καθαρότητας των κόμβων που προκύπτουν. Το σπάσιμο που έχει τον καλύτερο μέσο όρο καθαρότητας είναι αυτό που επιλέγεται (Ashraf et al., 2022).

Το σύνολο δεδομένων που ακολουθεί, αφορά Ευρωπαίους κάτοχους καρτών και περιλαμβάνει συναλλαγές που πραγματοποιήθηκαν με πιστωτικές κάρτες τον μήνα Σεπτέμβριο του έτους 2013. Αυτό το σύνολο δεδομένων περιλαμβάνει περιπτώσεις συναλλαγών πιστωτικών καρτών και το χαρακτηρισμό τους ως νόμιμες ή περιπτώσεις εξαπάτησης. Μεταξύ των δύο αυτών κλάσεων υπάρχει μεγάλη ανισορροπία με τις περιπτώσεις των μη νόμιμων συναλλαγών να αποτελούν μόλις το 0,172% του συνόλου όπως μπορούμε να δούμε και στο παρακάτω διάγραμμα. Εξαιτίας της ανισορροπίας αυτής δέχεται μόνο αριθμητικές μεταβλητές εισόδου που μετασχηματίζονται από την τεχνική της ανάλυσης σε κύριες συνιστώσες (PCA). Τα βασικά στοιχεία που λαμβάνονται από το PCA είναι τα V1, V2,.....V28. Ένα μειονέκτημα του συνόλου είναι ότι οι μόνες αναγνωρίσιμες μεταβλητές είναι το "Time" και το "Amount" τα οποία είναι τα μόνα χαρακτηριστικά που παραμένουν αναλλοίωτα από το PCA.



Εικόνα 7: Καταμέτρηση Απάτης και Μη Απάτης

Η συντριπτική πλειοψηφία των συναλλαγών είναι νόμιμες. Στην πραγματικότητα, μόνο το 0,17 τοις εκατό των συναλλαγών σε αυτό το σύνολο δεδομένων ήταν απάτες, αφήνοντας το 99,83 τοις εκατό από αυτές να είναι οι νόμιμες (Ashraf et al., 2022).

3.7 Προχωρημένες Τεχνικές Ταξινόμησης

Ο συνδυασμός διαφορετικών μοντέλων δίνει καλύτερα αποτελέσματα, συνήθως αυτός ο συνδυασμός γίνεται παίρνοντας τις εκτιμήσεις κάθε μοντέλου και στην περίπτωση που έχουμε πρόβλημα ταξινόμησης σε ομάδες θα επιστρέφει ως εκτίμηση του ensemble την ομάδα που επιλέγει η πλειοψηφία των μοντέλων, ενώ στην περίπτωση που έχουμε πρόβλημα παλινδρόμησης θα επιστρέφει ως εκτίμηση του ensemble τον μέσο όρο των εκτιμήσεων των

μοντέλων. Αρκετές φορές κάποια μοντέλα του ensemble έχουν μεγαλύτερο βάρος κατά τον υπολογισμό του μέσου όρου αντίστοιχα. Τεχνικά, αυτές είναι έξτρα παράμετροι που θα πρέπει να ρυθμίσει ο αναλυτής δεδομένων. Ένας τρόπος για να γίνει αυτό είναι να χωρίσει το training set σε δύο μέρη. Το πρώτο αποκαλείται πάλι training set, ενώ το δεύτερο που είναι συνήθως το μικρότερο, λέγεται validation set. Το training set χρησιμοποιείται πάλι για τη δημιουργία των μοντέλων, ενώ το validation set για να δοκιμαστούν διάφορες επιλογές της ανάθεσης του βάρους των μοντέλων κατά τη δημιουργία του ensemble. Έτσι αφού κατασκευαστούν τα μοντέλα επιλέγονται διάφορες αναθέσεις βαρών και υπολογίζεται η απόδοση κάθε μιας στο validation set. Εννοείται πως η τελική αξιολόγηση γίνεται όπως συνήθως με τη χρήση ενός test set που έχει δημιουργηθεί κατά τον χωρισμό του αρχικού συνόλου δεδομένων σε train και test datasets (Breiman, 2001).

Μια μέθοδος που εφαρμόζει τα παραπάνω είναι αυτή των Random Forests. Κατά την εφαρμογή της συγκεκριμένης μεθόδου επιλέγονται δείγματα του training set και για κάθε ένα από αυτά δημιουργείται ένα δένδρο αποφάσεων χρησιμοποιώντας ένα μόνο μέρος των διαθέσιμων μεταβλητών. Μετά τη δημιουργία τους τα δένδρα συνδυάζονται σε ένα ensemble. Η διαδικασία της επιλογής δειγμάτων από το σύνολο εκπαίδευσης, δημιουργίας μοντέλων από τα δείγματα αυτά και συνδυασμού τους με ίσα βάρη λέγεται bagging. Η τεχνική των Random Forests πρώτο εμφανίστηκε το 1995 από τον Tin Kam Ho και πήρε την τελική της μορφή από τους Leo Breiman και Adele Cutler. Ένα από τα βασικότερα πλεονεκτήματα της χρήσης των Random Forests είναι πως είναι λιγότερο πιθανό να εμφανίσουν υπερβολικά μεγάλη προσαρμογή στο training set που θα επηρέαζε αρνητικά τη γενικότερη απόδοσή τους και το φαινόμενο αυτό αποκαλείται overfitting. Ένα δεύτερο πλεονέκτημα τους είναι ότι μπορούν να χρησιμοποιηθούν για να εκτιμηθεί πόσο σημαντική είναι κάθε μεταβλητή για την εκτίμηση που μας ενδιαφέρει να κάνει το μοντέλο (Breiman, 2001).

Η διαδικασία κατά την οποία ένα ensemble χτίζεται σταδιακά προσθέτοντας μοντέλα ώστε κάθε νέο μοντέλο να προσπαθεί να διορθώσει το σφάλμα του προηγούμενου μέχρι τότε συνδυασμού λέγεται Boosting. Μια από τις πιο διαδεδομένες τεχνικές που εξειδικεύουν αυτήν τη φιλοσοφία είναι η τεχνική του gradient boosting. Για να γίνει πιο κατανοητή η εξήγηση του πως δουλεύει η gradient boosting είναι σημαντικό να αναφέρουμε, ότι βασίζεται στη διαίσθηση της ότι το επόμενο μοντέλο θα είναι το καλύτερο δυνατό, επίσης όταν συνδυάζεται με προηγούμενα μοντέλα, ελαχιστοποιεί το συνολικό σφάλμα πρόβλεψης. Η βασική ιδέα είναι να ορίζονται στοχευόμενα τα αποτελέσματα για αυτό το επόμενο μοντέλο προκειμένου να ελαχιστοποιείται το σφάλμα. Το αποτέλεσμα-στόχος για κάθε περίπτωση στα δεδομένα εξαρτάται από το πόσο η αλλαγή της πρόβλεψης αυτής της περίπτωσης επηρεάζει το συνολικό σφάλμα πρόβλεψης:

- Εάν έχουμε μια μικρή αλλαγή στην πρόβλεψη για μια περίπτωση που προκαλεί μεγάλη πτώση στο σφάλμα, τότε ο επόμενος στόχος της υπόθεσης είναι μια υψηλή τιμή. Οι προβλέψεις από το νέο μοντέλο που είναι κοντά στους στόχους του θα μειώσουν το σφάλμα.
- Εάν έχουμε μια μικρή αλλαγή στην πρόβλεψη για μια περίπτωση που δεν προκαλεί καμία αλλαγή στο σφάλμα, τότε η επόμενη στοχευόμενη έκβαση της υπόθεσης είναι μηδέν. Η αλλαγή αυτής της πρόβλεψης δεν μειώνει το σφάλμα.

Το όνομα gradient boosting προκύπτει επειδή τα αποτελέσματα στόχου για κάθε περίπτωση ορίζονται με βάση τη διαβάθμιση του σφάλματος σε σχέση με την πρόβλεψη. Κάθε νέο μοντέλο κάνει ένα βήμα προς την κατεύθυνση που ελαχιστοποιεί το σφάλμα πρόβλεψης, στο χώρο των πιθανών προβλέψεων για κάθε περίπτωση εκπαίδευσης (Chen et al., 2016).

3.8 Credit Scoring

Το Credit Scoring είναι η διαδικασία υπολογισμού ενός αριθμού που στηρίζεται στην ανάλυση της πιστωτικής ιστορίας ενός ατόμου ή οργανισμού και που αντανακλά την πιστοληπτική του ικανότητα. Αυτό το score χρησιμοποιείται κυρίως από τις τράπεζες για την χορήγηση νέων δανείων αλλά η χρήση του δεν περιορίζεται μόνο σε αυτό. Η τεχνική αυτή χρησιμοποιείται συχνά στον κλάδο των χρηματοοικονομικών υπηρεσιών αλλά έχει εφαρμογή και σε πολλές άλλες υπηρεσίες όπως για παράδειγμα από ασφαλιστικές εταιρείες, ιδιοκτήτες ακινήτων προς ενοίκιαση, κρατικές υπηρεσίες κλπ. Για τον υπολογισμό του Credit Score υπάρχουν πολλές μεθοδολογίες, όμως οι μεθοδολογίες αυτές μπορεί να χρησιμοποιούν μια πληθώρα δεδομένων

ενώ ανάλογα με τη χρήση τους μπορεί και να υπόκεινται σε κανονιστικούς περιορισμούς και οι δημιουργοί και χρήστες τους να έχουν συγκεκριμένες υποχρεώσεις. Στις ΗΠΑ τα FICO Scores είναι μια από τις πιο διαδεδομένες μεθοδολογίες η οποία πρώτο εμφανίστηκε το 1989 από την εταιρεία FICO και αυτή τη στιγμή χρησιμοποιείται από τις περισσότερες τράπεζες των ΗΠΑ. Ένα συνηθισμένο στοιχείο των μεθοδολογιών Credit Scoring είναι η δημιουργία και χρήση των λεγόμενων Credit Scorecards (Fahner, 2018).

Οι Credit Scorecards είναι πίνακες που για διάφορα χαρακτηριστικά του υπό εξέταση ατόμου ή οργανισμού αναθέτουν πόντους. Το τελικό άθροισμα των πόντων αυτών είναι το Credit Score. Για τον υπολογισμό Credit Scorecards η κλασική μέθοδος είναι να χρησιμοποιηθεί ένα σύνολο ιστορικών δεδομένων σχετικά με παλαιότερες χορηγήσεις πιστώσεων. Τα δεδομένα αυτά περιέχουν πληροφορίες όπως η οικογενειακή κατάσταση, το επάγγελμα και το μορφωτικό επίπεδο του πελάτη αν μιλάμε για φυσικό πρόσωπο ή το κλάδο δραστηριότητας, τον τύπο δηλαδή τη νομική μορφή και το μέγεθος αν μιλάμε για νομικό πρόσωπο. Όπως επίσης το σύνολο καταθέσεων, το σύνολο δανείων, την προηγούμενη πιστοληπτική συμπεριφορά, το ύψος και τη συχνότητα πληρωμών κλπ (Fahner, 2018).

Οι τεχνικές της Τεχνητής Νοημοσύνης και της Μηχανικής Μάθησης χρησιμοποιούνται ήδη από πολλούς οργανισμούς στη διαδικασία χορήγησης δανείων. Σε πολλές περιπτώσεις, οι τεχνικές αυτές δίνουν τη δυνατότητα της επεξεργασίας χιλιάδων μεταβλητών για κάθε υποψήφιο πελάτη που καλύπτουν περιοχές πέρα από το αυστηρά οικονομικό του ιστορικό. Θα πρέπει να σημειωθεί εδώ ότι συνήθως υπάρχουν κανονιστικοί περιορισμοί ως προς το ποιες πληροφορίες μπορούν να χρησιμοποιηθούν για την κατασκευή μοντέλων Credit Scoring. Για παράδειγμα σε αρκετές περιπτώσεις απαγορεύεται η χρήση στοιχείων σχετικά με το φύλο (Fahner, 2018).

Τεχνικές όπως το Random Forests και νευρωνικά δίκτυα βοηθούν έναν οικονομικό οργανισμό να αξιοποιήσει περισσότερα δεδομένα και να πάρει καλύτερες αποφάσεις. Έχουν όμως το μειονέκτημα μερικές φορές τα αποτελέσματα τους να μην είναι εύκολα ερμηνεύσιμα και οι χρήστες τους να μην είναι σε θέση να εξηγήσουν πλήρως το πώς λαμβάνονται οι αποφάσεις τους (Fahner, 2018).

Στο πεδίο των Credit Scorecards υπάρχουν δύο απλοί τρόποι εφαρμογής της Μηχανικής Μάθησης. Ο πρώτος τρόπος είναι με τον εντοπισμό των μεταβλητών που θα χρησιμοποιηθούν για την κατασκευή των καρτών καθώς και για την ομαδοποίηση των συνεχών μεταβλητών. Για παράδειγμα ο δημιουργός των καρτών μπορεί να κατασκευάσει πρώτα ένα δένδρο αποφάσεων και στη συνέχεια να χρησιμοποιήσει τις μεταβλητές που αυτό χρησιμοποιεί στα πρώτα βήματα. Μπορεί επίσης και να εκμεταλλευτεί τους κανόνες κάθε σπασίματος ώστε να ομαδοποιήσει τις συνεχείς μεταβλητές. Η δεύτερη απλή εφαρμογή αφορά τη χρήση τεχνικών της Μηχανικής Μάθησης για το χωρισμό των υποψήφιων δανειοληπτών σε ξεχωριστές ομάδες και τη δημιουργία διαφορετικών Credit Scorecards για κάθε ομάδα (Fahner, 2018).

Κεφάλαιο 4^ο: Πρόβλεψη Τιμών Μετοχών με τη Χρήση Μηχανικής Μάθησης

4.1 Πρόβλεψη Τιμών Μετοχών

Η προσπάθεια που γίνεται για να προβλεφθεί η επερχόμενη αξία της μετοχής, του τομέα της αγοράς ή ακόμα και ολόκληρης της αγοράς είναι γνωστή ως Χρηματιστηριακή Πρόβλεψη. Είναι ένας τομέας που έχει κεντρίσει το ενδιαφέρον πολλών ατόμων, συμπεριλαμβανομένων όχι μόνο εταιρειών, αλλά και εμπόρων, συμμετεχόντων στην αγορά, αναλυτών δεδομένων, ακόμη και μηχανικών υπολογιστών που εργάζονται στον τομέα της Μηχανικής Μάθησης (ML) και της Τεχνητής Νοημοσύνης (AI) (Soni et al., 2022).

Στην σημερινή εποχή έχει γίνει μια πολύ ενδιαφέρουσα δουλειά στον τομέα της εφαρμογής Αλγορίθμων Μηχανικής Μάθησης για την ανάλυση στα μοτίβα τιμών, την πρόβλεψη τιμών μετοχών και μεταβολών δεικτών. Οι περισσότεροι έμποροι μετοχών στις μέρες μας εξαρτώνται από τα Ευφυή Συστήματα Συναλλαγών που τους βοηθούν να προβλέψουν τις τιμές με βάση τις διάφορες καταστάσεις και συνθήκες, βοηθώντας τους έτσι στη λήψη στιγμιαίων επενδυτικών αποφάσεων. Οι τιμές των μετοχών θεωρούνται πολύ δυναμικές και επιρρεπείς σε γρήγορες αλλαγές λόγω της υποκείμενης φύσης του χρηματοοικονομικού τομέα και εν μέρει λόγω του μείγματος γνωστών παραμέτρων (Τιμή κλεισίματος προηγούμενων ημερών, αναλογία P/E κ.λπ.) και άγνωστων παραγόντων (όπως Εκλογικά αποτελέσματα, φήμες κ.λπ.) Ένας έξυπνος έμπορος θα προέβλεπε την τιμή της μετοχής και θα αγόραζε μια μετοχή πριν ανέβει η τιμή ή θα την πουλούσε πριν πέσει η αξία της. Αν και είναι πολύ δύσκολο να αντικατασταθεί η τεχνογνωσία που έχει αποκτήσει ένας έμπειρος έμπορος, ένας ακριβής αλγόριθμος πρόβλεψης μπορεί να οδηγήσει άμεσα σε υψηλά κέρδη τις εταιρείες επενδύσεων, υποδεικνύοντας τους μια άμεση σχέση μεταξύ της ακρίβειας του αλγορίθμου πρόβλεψης και του κέρδους από τη χρήση του αλγορίθμου (Shah, 2007).

Μία από τις προσεγγίσεις για την πρόβλεψη των τιμών των μετοχών είναι η προσέγγιση των μεγάλων δεδομένων που στοχεύει να αντλήσει πληροφορίες από μεγάλο όγκο δεδομένων που είναι δημόσια διαθέσιμα και αυτά τα δεδομένα αναλύονται σε πλατφόρμες όπως το TensorFlow. Η βασική ιδέα της προσέγγισης της βαθιάς μάθησης είναι να γίνονται υπολογισμοί με βάση τα νευρωνικά δίκτυα. Η Μακροπρόθεσμη Μνήμη (LSTM) είναι ένας ειδικός τύπος επαναλαμβανόμενου νευρωνικού δικτύου (RNN) που χρησιμοποιείται για να ξεπεραστεί το πρόβλημα των μακροπρόθεσμων εξαρτήσεων. Ένας άλλος τρόπος για την πρόβλεψη των τιμών των μετοχών είναι η ανάλυση των συναισθημάτων σε δεδομένα μέσω κοινωνικής δικτύωσης ή ειδήσεις που βοηθούν στον προσδιορισμό της γενικής τάσης που μπορεί να ακολουθήσουν οι μετοχές μιας συγκεκριμένης εταιρείας ή κλάδου βάσει μιας συλλογικής γνώμης. Η αξία μιας μετοχής θεωρείται συχνά ως μοντέλο χρονοσειρών και επομένως η ανάλυση χρονοσειρών είναι επίσης ένα δημοφιλές μοντέλο για την πρόβλεψη των τιμών των μετοχών (Soni et al., 2022).

Στην πράξη υπάρχουν δύο μεθοδολογίες για την πρόβλεψη των μετοχών:

- Θεμελιώδης Ανάλυση: Εκτελείται από τους Fundamental Analysts, αυτή η μέθοδος αφορά περισσότερο την εταιρεία παρά την πραγματική μετοχή. Οι αναλυτές λαμβάνουν τις αποφάσεις τους με βάση τις προηγούμενες επιδόσεις της εταιρείας, τις προβλέψεις κερδών κ.λπ.
- Τεχνική Ανάλυση: Εκτελείται από τους Τεχνικούς Αναλυτές, αυτή η μέθοδος ασχολείται με τον προσδιορισμό της τιμής της μετοχής με βάση τα προηγούμενα μοτίβα της μετοχής (χρησιμοποιώντας ανάλυση χρονοσειρών.)

Όταν εφαρμόζουμε τη Μηχανική Εκμάθηση στα Δεδομένα των Μετοχών, μας ενδιαφέρει περισσότερο να κάνουμε μια Τεχνική Ανάλυση για να δούμε αν ο αλγόριθμός μας μπορεί να μάθει με ακρίβεια τα υποκείμενα μοτίβα στη χρονοσειρά μετοχών. Η Μηχανική Μάθηση μπορεί επίσης να παίξει σημαντικό ρόλο στην αξιολόγηση και την πρόβλεψη της απόδοσης της εταιρείας και άλλων παρόμοιων παραμέτρων που βοηθούν στη Θεμελιώδη Ανάλυση. Στην πραγματικότητα, τα πιο επιτυχημένα αυτοματοποιημένα συστήματα πρόβλεψης μετοχών χρησιμοποιούν κάποιου είδους μοντέλο υβριδικής ανάλυσης που περιλαμβάνει τόσο τη Θεμελιώδη όσο και την Τεχνική Ανάλυση (Shah, 2007).

Σήμερα, ένας τεράστιος όγκος πολύτιμων πληροφοριών που σχετίζονται με την χρηματοπιστωτική αγορά είναι διαθέσιμος στο διαδίκτυο. Η πλειονότητα αυτών των πληροφοριών προέρχεται από άρθρα οικονομικών ειδήσεων, εκθέσεις εταιρειών και συστάσεις εμπειρογνομόνων (Ιστολόγια από έγκυρες πηγές μπορούν επίσης να λειτουργήσουν ως πηγή πληροφοριών). Τα περισσότερα από αυτά τα δεδομένα είναι σε μορφή κειμένου σε αντίθεση με μια αριθμητική μορφή που καθιστά δύσκολη την χρήση. Έτσι, ο τομέας του προβλήματος μπορεί πλέον να θεωρηθεί ως τομέας που περιλαμβάνει την εξόρυξη εγγράφων κειμένου και την ανάλυση χρονοσειρών ταυτόχρονα. Μια μέθοδος που έχει χρησιμοποιηθεί και περιλαμβάνει τον καθορισμό του αντίκτυπου των ειδήσεων σε μια συγκεκριμένη μετοχή: Θετική, Αρνητική και Ουδέτερη. Μια είδηση θεωρείται ότι έχει θετικό αντίκτυπο (ή αρνητικό αντίκτυπο) εάν η τιμή της μετοχής αυξηθεί (ή πέσει) σημαντικά για μια περίοδο, μετά τη μετάδοση της είδησης. Εάν η τιμή της μετοχής δεν αλλάξει δραματικά μετά τη δημοσιοποίηση της είδησης, τότε η είδηση θεωρείται ουδέτερη (Shah, 2007).

4.2 Αναγκαιότητα Πρόβλεψης Τιμών Μετοχών

Η εφαρμογή της τεχνητής νοημοσύνης και της μηχανικής μάθησης στις χρηματοοικονομικές υπηρεσίες μπορεί να έχει σημαντικό αντίκτυπο στις χρηματοπιστωτικές αγορές αποφέροντας σημαντικό κέρδος. Το χρηματιστήριο συσσωρεύει τις αγορές και τις πωλήσεις μετοχών με βάση την ιδιοκτησία των εμπόρων. Για την ανάλυση τέτοιων αγορών, τα ιστορικά δεδομένα της χρηματιστηριακής αγοράς καθώς και διάφοροι παράγοντες μπορούν να συνδυαστούν για να προκύψουν τα πρότυπα της αγοράς. Η υπόθεση της αποτελεσματικής αγοράς (EMH) προϋποθέτει ότι οι διαθέσιμες πληροφορίες της αγοράς ενσωματώνονται στις τιμές, ωστόσο, η απόδειξη επικύρωσης της EMH ήταν αμφιλεγόμενη για μια χρονική περίοδο. Από την άλλη πλευρά, τα επίπεδα πολυπλοκότητας των οικονομικών αγορών ορίζονται ως η φύση της χρονοσειράς, η υψηλή διασταυρούμενη συσχέτιση με διάφορες οντότητες και η συλλογική συμπεριφορά της αγοράς κατά τη διάρκεια ακραίων γεγονότων που την επηρεάζουν (Thakkar & Chaudhari, 2021).

Η συμπεριφορική χρηματοοικονομική έχει μελετηθεί με πρωταρχική έμφαση στον τρόπο με τον οποίο η ψυχολογία επηρεάζει τις συμπεριφορές των οικονομικών επαγγελματιών και τις συνέπειές της σε σχέση με τις χρηματιστηριακές αγορές. Τέτοιες ψυχολογικές προκαταλήψεις μπορούν να διαδραματίσουν κρίσιμο ρόλο στην αποτελεσματικότητα της αγοράς. Ως εκ τούτου, έχει προταθεί μια εναλλακτική θεωρία, συγκεκριμένα η προσαρμοστική υπόθεση αγοράς (AMH), σε αντίθεση με την άποψη όπου η EMH υποθέτει μια αγορά χωρίς τριβές και χωρίς ατέλειες. Η AMH αναπτύσσεται με βάση τις αρχές της εξελικτικής βιολογίας, δηλαδή τον ανταγωνισμό, τη μετάλλαξη, την αναπαραγωγή και τη φυσική επιλογή. Μια τέτοια εξελικτική προοπτική της AMH είναι μια συμφιλίωση που υποστηρίζει ότι οι χρηματοπιστωτικές αγορές εξελίσσονται και η αποτελεσματικότητά της ποικίλλει με το χρόνο. Ακόμη και ως μια ουσιαστικά ποιοτική και περιγραφική υπόθεση, τα επιχειρήματα της AMH έχουν υποστηριχθεί ευρέως με την προβλεψιμότητα της απόδοσης του χρηματιστηρίου καθώς και τις συναλλαγματικές ισοτιμίες. Αυτό τονίζει την κατανόηση ότι μεταξύ των διαφορετικών παραγόντων που μπορούν να επηρεάσουν τη χρηματιστηριακή αγορά, μια προσεκτική επιλογή συμπληρωματικών ή και αντικρουόμενων πτυχών μπορεί να συγχωνευθεί για να βελτιώσει τις πληροφορίες που συλλέγονται και επομένως να βελτιώσει τις προβλέψεις (Thakkar & Chaudhari, 2021).

Οι τεχνικές της ένωσης διαφορετικών πηγών δεδομένων, επεξεργασμένων πληροφοριών, παράγωγων χαρακτηριστικών ή και μεθόδων πρόβλεψης που συνδυάζονται κάτω από κατάλληλα σενάρια. Για μια μετοχή που δεν γνωρίζουμε τι αποτελέσματα θα έχει λόγω της πολυπλοκότητας της, οι παραπάνω τεχνικές μπορούν να βοηθήσουν στην εξαγωγή γνωσιακής βάσης από ένα ποικίλο σύνολο πηγών δεδομένων. Μπορεί να επεκτείνει τη δύναμη ενός μοντέλου για να ξεπεράσει την αδυναμία του άλλου μοντέλου, μπορεί να εκμεταλλευτεί τον χώρο αναζήτησης για την εξαγωγή αποτελεσματικών λύσεων (Thakkar & Chaudhari, 2021).

Λόγω του ότι η χρήση τεχνητής νοημοσύνης (AI) και μηχανικής μάθησης (ML) προσφέρουν τη δυνατότητα να βελτιώσουν σημαντικά την αποτελεσματικότητα της επεξεργασίας πληροφοριών, μειώνοντας έτσι τις ασυμμετρίες πληροφοριών, οι εφαρμογές της τεχνητής νοημοσύνης (AI) και της μηχανικής μάθησης (ML) έχουν τη δυνατότητα να ενισχύσουν

τη λειτουργία των πληροφοριών του χρηματοοικονομικού συστήματος. Οι μηχανισμοί με τους οποίους μπορεί να προκύψει αυτή η βελτίωση περιλαμβάνουν:

- Την χρήση της τεχνητής νοημοσύνης και της μηχανικής μάθησης η οποία μπορεί να επιτρέψει σε ορισμένους συμμετέχοντες στην αγορά να συλλέγουν και να αναλύουν πληροφορίες σε μεγαλύτερη κλίμακα. Συγκεκριμένα, αυτά τα εργαλεία μπορούν να βοηθήσουν τους συμμετέχοντες στην αγορά να κατανοήσουν τη σχέση μεταξύ της διαμόρφωσης των τιμών της αγοράς και διαφόρων παραγόντων, όπως στην ανάλυση συναισθήματος. Αυτό θα μπορούσε να μειώσει τις ασυμμετρίες πληροφοριών και έτσι να συμβάλει στην αποτελεσματικότητα και τη σταθερότητα των αγορών.
- Την χρήση της τεχνητής νοημοσύνης και της μηχανικής μάθησης η οποία μπορεί να μειώσει το κόστος συναλλαγών των συμμετεχόντων στην αγορά. Επιπλέον, η τεχνητή νοημοσύνη και η μηχανική μάθηση μπορούν να τους επιτρέψουν να προσαρμόσουν τις στρατηγικές των συναλλαγών και επενδύσεων σύμφωνα με ένα μεταβαλλόμενο περιβάλλον με γρήγορο τρόπο, βελτιώνοντας έτσι την ανακάλυψη τιμών και μειώνοντας το συνολικό κόστος συναλλαγών στο σύστημα (Thorne, 2017).

Ωστόσο, εάν υπάρχουν πολλοί συμμετέχοντες στην αγορά και αρχίσουν να χρησιμοποιούν παρόμοια προγράμματα τεχνητής νοημοσύνης και μηχανικής μάθησης στην πρόβλεψη μετοχών, οι επακόλουθοι κίνδυνοι ενδέχεται να συνεπάγονται κινδύνους χρηματοπιστωτικής σταθερότητας. Εάν οι έμποροι που βασίζονται στη μηχανική μάθηση αυξηθούν σε αριθμό, αυτό θα μπορούσε στο μέλλον να έχει ως αποτέλεσμα πολλοί περισσότεροι έμποροι να υιοθετήσουν παρόμοιες στρατηγικές μηχανικής μάθησης. Αν και δεν υπάρχουν ενδείξεις για κάτι τέτοιο μέχρι σήμερα, αυτό θα μπορούσε να γίνει σημαντικό πρόβλημα στο μέλλον με τη μεγαλύτερη υιοθέτηση τέτοιων στρατηγικών συναλλαγών (Thorne, 2017).

Καθώς η χρηματιστηριακή αγορά είναι στενά συνδεδεμένη με την οικονομική ανάπτυξη μιας χώρας και φέρνει τεράστιες επενδύσεις από τους επενδυτές και εκδίδει μετοχές προς το δημόσιο συμφέρον, η πρόβλεψη της κίνησης των τιμών των μετοχών και της αγοράς καθίσταται απαραίτητη για την αποφυγή τεράστιων ζημιών και τη λήψη σχετικών αποφάσεων.

4.3 Η Μηχανική Μάθηση στην Πρόβλεψη Τιμών Μετοχών

Σήμερα, χρησιμοποιούνται προηγμένες έξυπνες τεχνικές που βασίζονται είτε σε τεχνική ανάλυση είτε σε θεμελιώδη ανάλυση για την πρόβλεψη των τιμών των μετοχών. Ειδικότερα, για την ανάλυση της χρηματιστηριακής αγοράς, το μέγεθος των δεδομένων είναι τεράστιο και επίσης είναι μη γραμμικό. Για να αντιμετωπιστεί αυτή η ποικιλία αποδοτικών δεδομένων, απαιτείται ένα μοντέλο που μπορεί να εντοπίσει τα κρυμμένα μοτίβα και τις πολύπλοκες σχέσεις σε αυτό το μεγάλο σύνολο δεδομένων. Οι τεχνικές της μηχανικής μάθησης σε αυτόν τον τομέα έχουν αποδειχθεί ότι βελτιώνουν την αποτελεσματικότητα κατά 60-86 τοις εκατό σε σύγκριση με προηγούμενες μεθόδους. Πρόσφατη έρευνα έχει δείξει ότι η πρόβλεψη της χρηματιστηριακής αγοράς μπορεί να βελτιωθεί χρησιμοποιώντας διάφορες τεχνικές μηχανικής μάθησης. Τεχνικές όπως Support Vector Machine (SVM), Random Forest (RF), ακόμα υπάρχουν ορισμένες τεχνικές που βασίζονται σε νευρωνικά δίκτυα όπως το Τεχνητό Νευρωνικό Δίκτυο (ANN), το Συνελικτικό Νευρωνικό Δίκτυο (CNN), το Επαναλαμβανόμενο Νευρωνικό Δίκτυο (RNN) και τα βαθιά νευρωνικά δίκτυα όπως η Μακροπρόθεσμη Βραχυπρόθεσμη Μνήμη (LSTM) έχουν επίσης εμφανίσει πολλά υποσχόμενα αποτελέσματα (Vijh et al., 2020).

Το άλλο μη γραμμικό μοντέλο που χρησιμοποιείται ευρέως στις χρηματοπιστωτικές αγορές τα τελευταία χρόνια και το οποίο έχει επιτύχει επιθυμητά αποτελέσματα είναι το SVM. Το SVM έχει χρησιμοποιηθεί για την πρόβλεψη χρονοσειρών σε μη στάσιμη κατάσταση μεταβλητών, αδικαιολόγητη κλασική μέθοδο ή πολυπλοκότητα χρονοσειρών. Τα μοντέλα SVM ταξινομούνται σε SVM και SVR. Τα SVR είναι ένας συγκεκριμένος τύπος SVM που χρησιμοποιείται για μελλοντική πρόβλεψη τιμών. Το SVM έχει την ικανότητα στη διαδικασία πρόβλεψης να εξαλείφει άσχετα και διάσπαρτα δεδομένα και να βελτιώνει την ακρίβεια της πρόβλεψης. Το SVM βασίζεται στη δομική ελαχιστοποίηση του κινδύνου που προκύπτει από τη θεωρία της στατιστικής εκπαίδευσης. Το SVM στη μοντελοποίηση οικονομικών δεδομένων είναι εφαρμόσιμο εφόσον δεν υπάρχουν ισχυρές υποθέσεις.

Η βάση για το SVM είναι η γραμμική ταξινόμηση των δεδομένων, όπου γίνονται προσπάθειες να επιλεγεί μια γραμμή με υψηλότερη αξιοπιστία. Η επίλυση των εξισώσεων της βέλτιστης γραμμής για δεδομένα γίνεται μέσω τετραγωνικών μεθόδων προγραμματισμού, οι οποίες είναι γνωστές μέθοδοι επίλυσης προβλημάτων περιορισμού. Πριν από τη γραμμική ταξινόμηση, τα δεδομένα μεταφέρονται από μια συνάρτηση ϕ σε έναν ευρύτερο χώρο για να μπορέσει το μηχάνημα να ταξινομήσει τα εξαιρετικά πολύπλοκα δεδομένα. Εν συντομία, αυτός ο αλγόριθμος χρησιμοποιεί μια μη γραμμική χαρτογράφηση για να μετατρέψει τα κύρια δεδομένα σε υψηλότερη διάσταση και χρησιμοποιεί μια γραμμική βελτιστοποίηση για τον διαχωρισμό του υπερεπίπεδου (Nikou et al, 2019).

Ο αλγόριθμος Random Forest (RF) εισήχθη το 2001 για πρώτη φορά από τον Leo Breiman και βασίζεται σε ένα μοντέλο δέντρων απόφασης γνωστό ως δέντρα ταξινόμησης και παλινδρόμησης. Τα δέντρα αποφάσεων που χρησιμοποιούνται για την πρόβλεψη ταξινομημένων μεταβλητών είναι γνωστά ως δέντρα ταξινόμησης, καθώς τοποθετούν τα δείγματα σε κλάσεις ή κατηγορίες και τα δέντρα απόφασης που χρησιμοποιούνται για την πρόβλεψη συνεχών μεταβλητών ονομάζονται δέντρα παλινδρόμησης. Ωστόσο, η ομαδική φύση του αλγορίθμου RF οδηγεί σε συμβατότητα με αλλαγές και εξαλείφει την αστάθεια. Δύο κύρια χαρακτηριστικά στην κατασκευή των RF είναι το bagging και η τυχαία επιλογή σε κάθε κόμβο. Η μέθοδος bagging είναι ένας αλγόριθμος που βασίζεται σε έννοιες bootstrapping και σύνθεσης για τη βελτίωση της μηχανικής εκμάθησης. Στη μηχανική μάθηση, οι ομαδικοί αλγόριθμοι συνδυάζουν αρκετούς αδύναμους μαθητές για να επιτύχουν έναν δυνατό μαθητή, ο οποίος αποτρέπει την υπερβολική προσαρμογή δεδομένων. Στο bagging, παράγονται καλά αποτελέσματα όταν οι βασικές ταξινομήσεις αποτελούν μέρος ασταθών αλγορίθμων μάθησης (όπως ένα δέντρο αποφάσεων με ένα νευρωνικό δίκτυο) έτσι ώστε μικρές αλλαγές στα δεδομένα εκπαίδευσης να οδηγούν σε κύριες παραλλαγές στο μοντέλο που κατασκευάζεται από αυτόν τον αλγόριθμο (Nikou et al, 2019).

Το τεχνητό νευρωνικό δίκτυο ANN είναι μια τεχνική που αναπτύσσεται με την προσομοίωση των βιολογικών νευρικών συστημάτων, όπως ο ανθρώπινος εγκέφαλος. Έχει εξαιρετική ικανότητα πρόβλεψης από μεγάλες βάσεις δεδομένων. Γενικά, το ANN που χρησιμοποιείται για την πρόβλεψη της χρηματιστηριακής αγοράς βασίζεται στον αλγόριθμο back-propagation. Χρησιμοποιείται ένα πολυστρωματικό νευρωνικό δίκτυο perceptron (MLP) που αναπτύχθηκε από τον αλγόριθμο back-propagation. Αποτελείται από ένα στρώμα εισόδου που περιλαμβάνει ένα σύνολο αισθητηριακών κόμβων ως κόμβους εισόδου, ένα ή περισσότερα κρυφά στρώματα κόμβων υπολογισμού και ένα στρώμα εξόδου κόμβων υπολογισμού (Tsai & Wang, 2009).

Τα μοντέλα CNN είναι τα μοναδικά στα οπτικά δεδομένα και έχουν ευρεία εφαρμογή στην αναγνώριση εικόνων και βίντεο και στην επεξεργασία φυσικής γλώσσας. Επιπλέον, υπάρχουν τα RNN τα οποία είναι κατάλληλα για χρονομετρημένα δεδομένα τα RNN είναι νευρωνικά δίκτυα με έναν ή περισσότερους επαναλαμβανόμενους βρόχους. Αυτά τα δίκτυα στην πραγματικότητα δημιουργούνται για την επεξεργασία διαδοχικών σημάτων και διαθέτουν έναν τύπο μνήμης που καταγράφει τα δεδομένα που έχουν παρατηρηθεί μέχρι τώρα. Θεωρητικά, αυτά τα δίκτυα θα μπορούσαν να καταγράφουν και να χρησιμοποιούν δεδομένα σε μια μακρά σειρά. Ωστόσο, δεν συμβαίνει στην πράξη, και είναι τόσο περιορισμένοι από αυτή την άποψη, ώστε απλώς καταγράφουν δεδομένα που σχετίζονται με μερικά προηγούμενα βήματα. Το κύριο χαρακτηριστικό ενός RNN είναι η κρυφή του κατάσταση, η οποία αποθηκεύει τα δεδομένα μιας ακολουθίας. Επιπλέον, δεν είναι απαραίτητο να υπάρχει έξοδος και είσοδος σε κάθε χρονικό βήμα (Nikou et al, 2019).

Το LSTM είναι ένας τύπος μοντέλου ή δομής για διαδοχικά δεδομένα που προέκυψε από την ανάπτυξη RNN και βελτιώθηκε από τους Gers, Schmidhuber και Cummins. Η μακροπρόθεσμη μνήμη αναφέρεται στα μαθημένα βάρη και η βραχυπρόθεσμη μνήμη αναφέρεται στις εσωτερικές καταστάσεις των κυττάρων. Το LSTM δημιουργήθηκε για να αντιμετωπίσει το εξαφανιζόμενο πρόβλημα κλίσης που είχε το RNN των οποίων η κύρια αλλαγή που έγινε είναι η αντικατάσταση του μεσαίου επιπέδου RNN με ένα μπλοκ που ονομάζεται μπλοκ LSTM. Το κύριο χαρακτηριστικό του LSTM είναι η δυνατότητα μακροπρόθεσμης εκμάθησης αλληλεγγύης, κάτι που ήταν αδύνατο με τα RNN. Για την πρόβλεψη του επόμενου χρονικού βήματος, απαιτείται ενημέρωση των τιμών βάρους στο δίκτυο, κάτι που απαιτεί τη διατήρηση των δεδομένων του αρχικού χρονικού βήματος. Ένα RNN θα μπορούσε απλώς να

μάθει έναν περιορισμένο αριθμό βραχυπρόθεσμων συνεργασιών. Ωστόσο, οι μακροπρόθεσμες χρονικές σειρές, όπως τα 1000 χρονικά βήματα, δεν μπορούν να μαθευτούν από τα RNN. Αντίθετα, τα LSTM θα μπορούσαν να μάθουν σωστά αυτές τις μακροπρόθεσμες σχέσεις. Η δομή LSTM περιλαμβάνει ένα σύνολο επαναλαμβανόμενων υποδικτύων, που ονομάζονται μπλοκ μνήμης. Κάθε μπλοκ περιλαμβάνει ένα ή περισσότερα αυτοπαλινδρομικά κελιά μνήμης και τρεις πολλαπλές μονάδες «εισόδου, εξόδου και λήθης» που παρουσιάζουν τα ανάλογα της συνεχούς γραφής, ανάγνωσης και ρύθμισης των λειτουργιών των κελιών. Επιπλέον, υπάρχουν διάφοροι τύποι μπλοκ LSTM, συμπεριλαμβανομένων στοιβαγμένων LSTM, κωδικοποιητών-αποκωδικοποιητών LSTM, αμφίδρομων LSTM, CNN LSTM, και γενετικά LSTM. Όταν ένα υπολογιστικό πρόβλημα μπορεί να λυθεί χρησιμοποιώντας έναν συγκεκριμένο αλγόριθμο, το επόμενο ζήτημα, μετά τη δυνατότητα επίλυσης, είναι η χρονική και χωρική πολυπλοκότητα της μεθόδου λύσης. Σε αυτά τα συστήματα, ο χρόνος εκμάθησης δεν είναι σημαντικός, καθώς η μάθηση ολοκληρώνεται πριν από την εκτέλεση του πραγματικού συστήματος και υπάρχει αρκετός διαθέσιμος χρόνος για αυτό. Αυτό που είναι σημαντικό είναι η ακρίβεια της μάθησης και η μείωση των λαθών (Nikou et al, 2019).

Η πρόβλεψη της χρηματιστηριακής αγοράς είναι τόσο δύσκολη λόγω της μη γραμμικής, δυναμικής και περίπλοκης φύσης της, αλλά ταυτόχρονα είναι πολύ σημαντική. Η επιτυχημένη πρόβλεψη έχει μερικά ενδιαφέροντα οφέλη που συνήθως επηρεάζουν την απόφαση ενός χρηματοοικονομικού εμπόρου για την αγορά ή την πώληση ενός χρηματοοικονομικού μέσου. Ένας από τους κύριους παράγοντες που εξετάζουν οι επενδυτές στη λήψη αποφάσεων για επενδύσεις και αγορές και πώληση μετοχών είναι ο δείκτης τιμών μετοχών.

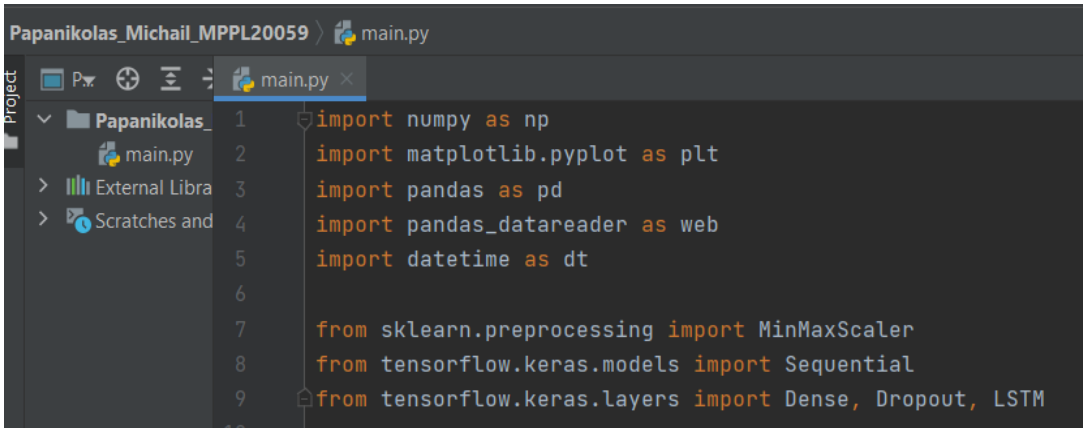
Κεφάλαιο 5^ο: Ανάπτυξη Εφαρμογής

5.1 Στάδια Σχεδιασμού

Η πρόβλεψη των τιμών των μετοχών ήταν πάντα ένα ελκυστικό θέμα για τους επενδυτές και τους ερευνητές. Οι επενδυτές πάντα αναρωτιούνται εάν η τιμή μιας μετοχής θα αυξηθεί ή όχι. Δεδομένου ότι υπάρχουν πολλοί περίπλοκοι χρηματοοικονομικοί δείκτες που μόνο οι επενδυτές και τα άτομα με καλές γνώσεις οικονομικών μπορούν να κατανοήσουν, η τάση του χρηματιστηρίου είναι ασυνεπής και φαίνεται πολύ τυχαία σε όποιον δεν έχει εξειδικευμένες γνώσεις. Η μηχανική μάθηση είναι μια εξαιρετική ευκαιρία για τους μη ειδικούς να προβλέπουν με ακρίβεια, να αποκτούν σταθερή περιουσία και να βοηθάει τους ειδικούς να κάνουν καλύτερες προβλέψεις.

Η γλώσσα προγραμματισμού που θα χρησιμοποιηθεί για την δημιουργία της εφαρμογής που θα πραγματοποιεί την πρόβλεψη των τιμών των μετοχών είναι η Python 3.9. Η συγκεκριμένη γλώσσα προγραμματισμού χρησιμοποιείται σε μεγάλο βαθμό για την δημιουργία εφαρμογών τεχνητής νοημοσύνης και μηχανικής μάθησης. Ο στόχος της συγκεκριμένης εφαρμογής είναι η δημιουργία ενός νευρωνικού δικτύου στο TensorFlow και στο Keras που προβλέπει τις τιμές του χρηματιστηρίου. Πιο συγκεκριμένα, θα κατασκευάσουμε ένα Επαναλαμβανόμενο Νευρωνικό Δίκτυο με LSTM καθώς είναι η τρέχουσα τεχνολογία αιχμής στην πρόβλεψη χρονοσειρών. Οι βιβλιοθήκες που θα χρησιμοποιηθούν είναι οι εξής:

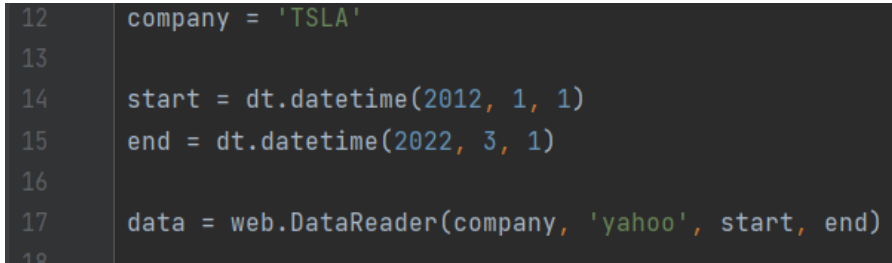
- NumPy: Η συγκεκριμένη βιβλιοθήκη χρησιμοποιείται για εργασία με πίνακες και έχει επίσης συναρτήσεις για εργασία στον τομέα της γραμμικής άλγεβρας, του μετασχηματισμού Fourier και των πινάκων, χρησιμοποιείται δηλαδή για επιστημονικές λειτουργίες.
- Matplotlib: Την βιβλιοθήκη matplotlib την χρησιμοποιούμε για οπτικοποίηση των αποτελεσμάτων.
- Pandas: Το panda είναι ένα πακέτο της Python που παρέχει γρήγορες, ευέλικτες και εκφραστικές δομές δεδομένων που έχουν σχεδιαστεί για να κάνουν την εργασία με σχεσιακά ή επισημασμένα δεδομένα τόσο εύκολη όσο και διαισθητική. Στόχος του είναι να είναι το θεμελιώδες δομικό στοιχείο υψηλού επιπέδου για την πραγματοποίηση πρακτικής ανάλυσης δεδομένων πραγματικού κόσμου στην Python. Επιπλέον, έχει τον ευρύτερο στόχο να γίνει το πιο ισχυρό και ευέλικτο εργαλείο ανάλυσης και χειρισμού δεδομένων ανοιχτού κώδικα που θα είναι διαθέσιμο σε οποιαδήποτε γλώσσα.
- Datetime: Η βιβλιοθήκη datetime χρησιμοποιείται όταν θέλουμε να πραγματοποιήσουμε μια εργασία με ημερομηνίες και ώρες.
- Sklearn: Η Scikit-learn (Sklearn) είναι η πιο χρήσιμη και ισχυρή βιβλιοθήκη για μηχανική μάθηση στην Python. Παρέχει μια επιλογή αποτελεσματικών εργαλείων για μηχανική μάθηση και στατιστική μοντελοποίηση, συμπεριλαμβανομένης της ταξινόμησης, της παλινδρόμησης, της ομαδοποίησης και της μείωσης διαστάσεων μέσω μιας διεπαφής συνέπειας στην Python. Αυτή η βιβλιοθήκη, η οποία είναι σε μεγάλο βαθμό γραμμένη σε Python, βασίζεται στα NumPy, SciPy και Matplotlib.
- TensorFlow.keras: Το Keras είναι μια συμπαγής, εύκολη στην εκμάθηση βιβλιοθήκη Python υψηλού επιπέδου που λειτουργεί πάνω από το πλαίσιο TensorFlow. Χρησιμοποίησα το Keras για να δημιουργήσω ένα LSTM έτσι ώστε να προβλέψω τις τιμές των μετοχών χρησιμοποιώντας την ιστορική τιμή κλεισίματος και να απεικονίσω τόσο τις προβλεπόμενες τιμές με την πάροδο του χρόνου όσο και τις βέλτιστες παραμέτρους για το μοντέλο. Είναι κατασκευασμένο με έμφαση στην κατανόηση τεχνικών βαθιάς μάθησης, όπως η δημιουργία επιπέδων για νευρωνικά δίκτυα διατηρώντας τις έννοιες των σχημάτων και των μαθηματικών λεπτομερειών.



```
1 import numpy as np
2 import matplotlib.pyplot as plt
3 import pandas as pd
4 import pandas_datareader as web
5 import datetime as dt
6
7 from sklearn.preprocessing import MinMaxScaler
8 from tensorflow.keras.models import Sequential
9 from tensorflow.keras.layers import Dense, Dropout, LSTM
```

Εικόνα 8: Βιβλιοθήκες Εφαρμογής

Στην Εικόνα 9 βλέπουμε το σημείο του κώδικα που πραγματοποιείται η φόρτωση των δεδομένων. Σε πρώτη φάση θα χρησιμοποιηθεί ένα σύνολο δεδομένων μετοχών της Tesla (TSLA) από το Yahoo finance το οποίο περιέχει δεδομένα μετοχών για δέκα χρόνια.



```
12 company = 'TSLA'
13
14 start = dt.datetime(2012, 1, 1)
15 end = dt.datetime(2022, 3, 1)
16
17 data = web.DataReader(company, 'yahoo', start, end)
18
```

Εικόνα 9: Φόρτωση Δεδομένων

Στο επόμενο βήμα γίνεται η προετοιμασία των δεδομένων για το νευρωνικό δίκτυο, επομένως θα δημιουργήσουμε πρώτα το scaler ώστε όλες τις τιμές που έχουμε να χωράνε μεταξύ 0 και 1, οπότε αν έχουμε την χαμηλότερη τιμή των 10 ευρώ και την υψηλότερη τιμή των 700 ευρώ, αυτό που θα κάνουμε θα είναι να συμπίεσουμε όλες αυτές τις τιμές μαζί ώστε να χωρούν στο μηδέν ή μεταξύ 0 και 1. Ο στόχος είναι να προβλέψουμε την τιμή κλεισίματος όπως μπορούμε να δούμε και στην γραμμή 21 στον παρακάτω στιγμιότυπο οθόνης. Στην συνέχεια θα ορίσουμε πόσες ημέρες στο μέλλον θέλουμε να προβλέψουμε ή πόσες μέρες θέλουμε από το παρελθόν για να προβλέψουμε την επόμενη ημέρα κλεισίματος, στην συγκεκριμένη εφαρμογή έχουν χρησιμοποιηθεί 60 ημέρες.

Για να γίνει η εκπαίδευση των δεδομένων θα χρειαστούμε δύο άδειες λίστες την x και y. Πρώτα θα ξεκινήσουμε με της ημέρες πρόβλεψης δηλαδή 60 και θα ανέβουμε μέχρι το μήκος των δεδομένων κλίμακας, οπότε θα αρχίσουμε να μετράμε από το 60 και θα πάμε μέχρι τον τελευταίο δείκτη και στην συνέχεια θα μετατρέψουμε τις λίστες σε numpy πίνακες και μετά θα πραγματοποιηθεί αναδιαμόρφωση έτσι ώστε να λειτουργούν με το νευρωνικό δίκτυο.

```

20 scaler=MinMaxScaler(feature_range=(0,1))
21 scaled_data=scaler.fit_transform(data['Close'].values.reshape(-1,1))
22
23 prediction_days = 60
24
25 x_train=[]
26 y_train=[]
27
28 for x in range(prediction_days, len(scaled_data)):
29     x_train.append(scaled_data[x-prediction_days:x, 0])
30     y_train.append(scaled_data[x, 0])
31
32 x_train, y_train = np.array(x_train), np.array(y_train)
33 x_train = np.reshape(x_train, (x_train.shape[0], x_train.shape[1], 1))
34

```

Εικόνα 10: Προετοιμασία Δεδομένων

Τώρα που έχουμε μια κατάλληλη συνάρτηση για τη φόρτωση και την προετοιμασία του συνόλου δεδομένων, χρειαζόμαστε μια άλλη βασική συνάρτηση για να δημιουργήσουμε το μοντέλο μας. Αρχικά, αρχικοποιήσαμε το μοντέλο μας ως διαδοχικό με 50 μονάδες στη διάσταση της εξόδου. Κάναμε `return_sequences=True` το επίπεδο LSTM με τρισδιάστατη είσοδο και `input_shape` διαμορφώνουμε το σύνολο δεδομένων μας. Κάνοντας το κλάσμα εγκατάλειψης 0,2 πέφτει το 20% των στρώσεων. Τέλος, προσθέτουμε ένα πυκνό στρώμα με τιμή 1 επειδή θέλουμε να βγάλουμε μία τιμή. Στην συνέχεια θέλοντας να συντάξουμε το μοντέλο χρησιμοποιούμε την εντολή στην γραμμή 46 που φαίνεται στην Εικόνα 11, χρησιμοποιήσαμε το `loss='mean_squared_error'` επειδή είναι πρόβλημα παλινδρόμησης και το `adam optimizer` για να ενημερώσουμε τα βάρη του δικτύου επαναληπτικά με βάση τα δεδομένα εκπαίδευσης. Τέλος στην γραμμή 47 στην παρακάτω εικόνα κάθε `epoch` αναφέρεται σε έναν κύκλο μέσα από το πλήρες σύνολο δεδομένων εκπαίδευσης και το `batch size` αναφέρεται στον αριθμό των παραδειγμάτων εκπαίδευσης που χρησιμοποιούνται σε μια επανάληψη.

```

36 model = Sequential()
37
38 model.add(LSTM(units=50, return_sequences=True, input_shape=(x_train.shape[1], 1)))
39 model.add(Dropout(0.2))
40 model.add(LSTM(units=50, return_sequences=True))
41 model.add(Dropout(0.2))
42 model.add(LSTM(units=50))
43 model.add(Dropout(0.2))
44 model.add(Dense(units=1)) #πρόβλεψη της επόμενης τιμής κλεισίματος
45
46 model.compile(optimizer='adam', loss='mean_squared_error')
47 model.fit(x_train, y_train, epochs=25, batch_size=32)
48

```

Εικόνα 11: Κατασκευή Μοντέλου

Στην συνέχεια αφού κατασκευάσαμε το μοντέλο θα προχωρήσουμε στην φόρτωση των δεδομένων δοκιμής και στον έλεγχο της ακρίβειας του μοντέλου σε υπάρχοντα δεδομένα. Στο βήμα αυτό θα δούμε ποιες είναι οι πιθανότητες να είναι σωστό το μοντέλο αν κοιτάζω πάντα τις τελευταίες 60 ημέρες και προβλέπω την επόμενη ημέρα. Το χρονικό εύρος της δοκιμής ορίστηκε να είναι από τις 1/3/2022 μέχρι και σήμερα και η δοκιμή θα αντλεί δεδομένα από το Yahoo. Στην συνέχεια στην γραμμή 56 στην Εικόνα 12 θα πάρουμε τις πραγματικές τιμές και όχι τις προβλεπόμενες και στην γραμμή 58 θα δημιουργήσουμε ένα σύνολο δεδομένων που θα συνδυάζει τα δεδομένα εκπαίδευσης και τα δεδομένα δοκιμής. Θα συνδυάσουμε τα δεδομένα

κλεισίματος με τα δεδομένα κλεισίματος δοκιμής. Έτσι ώστε το μοντέλο να μπορεί να προβλέψει την τιμή κλεισίματος της επόμενης ημέρας.

```

52 test_start=dt.datetime(2022, 3, 1)
53 test_end=dt.datetime.now()
54
55 test_data = web.DataReader(company, 'yahoo', test_start, test_end)
56 actual_prices=test_data['Close'].values
57
58 total_dataset=pd.concat((data['Close'], test_data['Close']), axis=0)
59
60 model_inputs=total_dataset[len(total_dataset)-len(test_data)-prediction_days:].values
61 model_inputs = model_inputs.reshape(-1, 1)
62 model_inputs = scaler.transform(model_inputs)

```

Εικόνα 12: Φόρτωση Δεδομένων Δοκιμής

Στο επόμενο βήμα αφού γίνει η φόρτωση των δεδομένων δοκιμής θα πραγματοποιηθούν προβλέψεις για τα δεδομένα δοκιμής για να αξιολογήσουμε πόσο ακριβές είναι το μοντέλο μας. Ορίζουμε μια κενή λίστα `x_test` και θα επαναλάβουμε την διαδικασία που πραγματοποιήσαμε και σε παραπάνω τμήμα του κώδικα.

```

65 x_test=[]
66
67 for x in range(prediction_days, len(model_inputs)):
68     x_test.append(model_inputs[x-prediction_days:x, 0])
69
70 x_test=np.array(x_test)
71 x_test=np.reshape(x_test, (x_test.shape[0], x_test.shape[1], 1))
72
73 predicted_prices=model.predict(x_test)
74 predicted_prices=scaler.inverse_transform(predicted_prices)
75

```

Εικόνα 13: Πραγματοποιεί Προβλέψεις για τα Δεδομένα Δοκιμής

Αφού πραγματοποιηθούν και η προβλέψεις για τα δεδομένα δοκιμής τότε προχωράμε στον σχεδιασμό των προβλέψεων του test. Στο διάγραμμα που θα σχεδιάσουμε θα εμφανίζονται οι πραγματικές τιμές (`actual_prices`) των μετοχών με μαύρο χρώμα και οι προβλεπόμενες τιμές (`predicted_prices`) των μετοχών με πράσινο χρώμα. Ο άξονας `x` θα εμφανίζει της ημέρες πρόβλεψης και ο άξονας `y` θα εμφανίζει την τιμή της μετοχής.

```

77 plt.plot(actual_prices, color = "black", label=f"Actual {company} Price")
78 plt.plot(predicted_prices, color="green", label=f"Predicted {company} Price")
79 plt.title(f"{company} Share Price")
80 plt.xlabel("Time")
81 plt.ylabel(f"{company} Share Price")
82 plt.legend()
83 plt.show()

```

Εικόνα 14: Σχεδίασε τις Προβλέψεις του Test

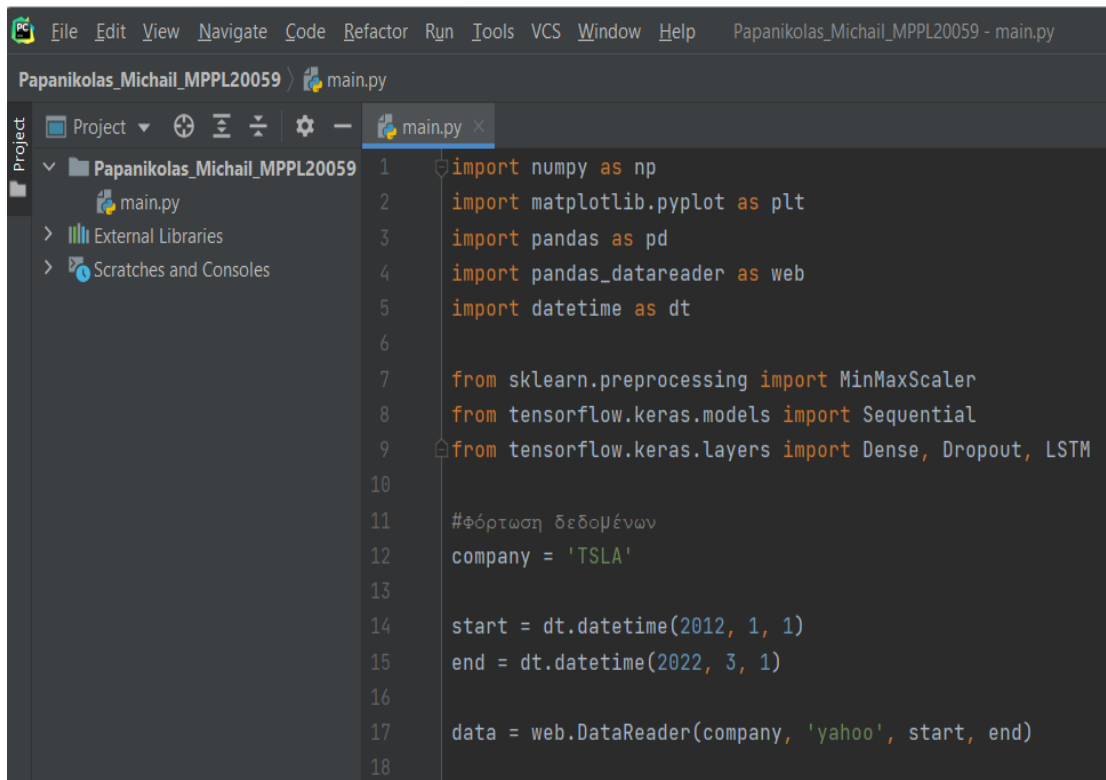
Στο τέλος αφού γίνει και ο σχεδιασμός των προβλέψεων του test θα μας δοθεί και η προβλεπόμενη τιμή της επόμενης ημέρας σε μορφή αριθμητικής τιμής.

```
87 real_data = [model_inputs[len(model_inputs)-prediction_days:len(model_inputs+1), 0]]
88 real_data = np.array(real_data)
89 real_data=np.reshape(real_data, (real_data.shape[0], real_data.shape[1],1))
90
91 prediction=model.predict(real_data)
92 prediction = scaler.inverse_transform(prediction)
93 print(f"Prediction: {prediction}")
```

Εικόνα 15: Πρόβλεψη της Επόμενης Ημέρας

Αφού τοποθετήσουμε σαν είσοδο για πια μετοχή επιθυμούμε να λάβουμε την προβλεπόμενη τιμή της επόμενης ημέρας. Τότε θα λάβουμε σαν έξοδο το διάγραμμα με την πραγματική τιμή η οποία θα συμβολίζεται με μαύρο χρώμα και την προβλεπόμενη τιμή που θα συμβολίζεται με πράσινο χρώμα. Επιπλέον ο αλγόριθμος θα μας επιστρέψει και την προβλεπόμενη αυριανή τιμή κλεισίματος.

5.2 Παρουσίαση Κώδικα Εφαρμογής



```
File Edit View Navigate Code Refactor Run Tools VCS Window Help Papanikolas_Michail_MPPL20059 - main.py
Papanikolas_Michail_MPPL20059 main.py
Project
  Papanikolas_Michail_MPPL20059
    main.py
  External Libraries
  Scratches and Consoles
1 import numpy as np
2 import matplotlib.pyplot as plt
3 import pandas as pd
4 import pandas_datareader as web
5 import datetime as dt
6
7 from sklearn.preprocessing import MinMaxScaler
8 from tensorflow.keras.models import Sequential
9 from tensorflow.keras.layers import Dense, Dropout, LSTM
10
11 #Φόρτωση δεδομένων
12 company = 'TSLA'
13
14 start = dt.datetime(2012, 1, 1)
15 end = dt.datetime(2022, 3, 1)
16
17 data = web.DataReader(company, 'yahoo', start, end)
18
```

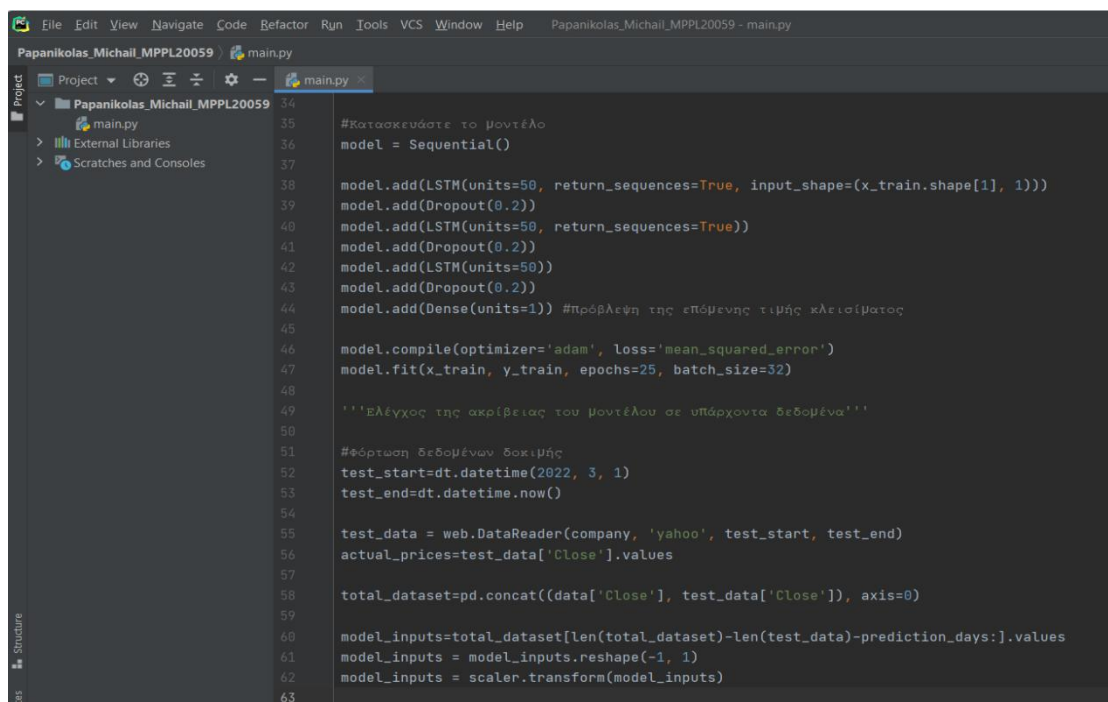
Εικόνα 16: Κώδικας Εφαρμογής 1


```

19 #Προετοιμασία Δεδομένων
20 scaler=MinMaxScaler(feature_range=(0,1))
21 scaled_data=scaler.fit_transform(data['Close'].values.reshape(-1,1))
22
23 prediction_days = 60
24
25 x_train=[]
26 y_train=[]
27
28 for x in range(prediction_days, len(scaled_data)):
29     x_train.append(scaled_data[x-prediction_days:x, 0])
30     y_train.append(scaled_data[x, 0])
31
32 x_train, y_train = np.array(x_train), np.array(y_train)
33 x_train = np.reshape(x_train, (x_train.shape[0], x_train.shape[1], 1))
34

```

Εικόνα 17: Κώδικας Εφαρμογής 2

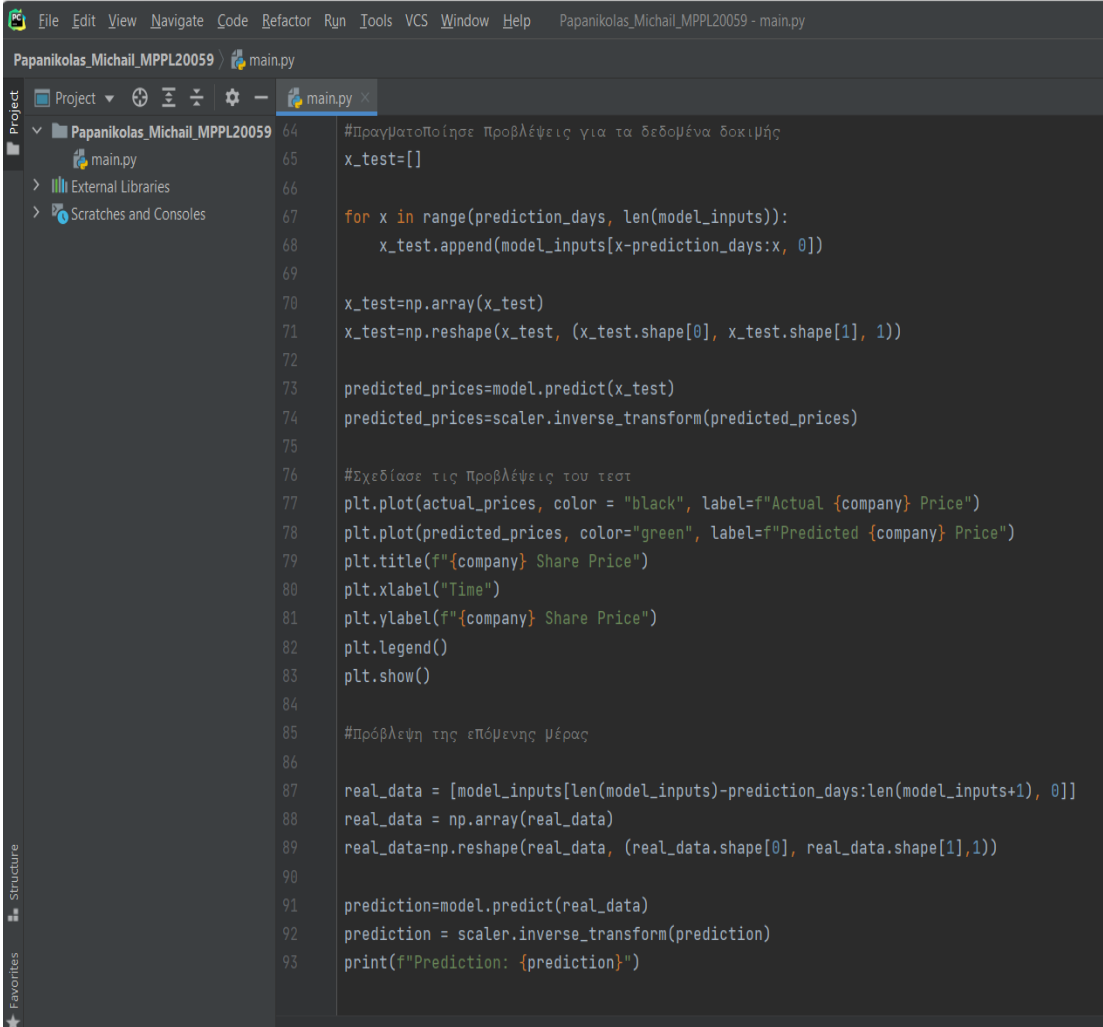


```

34 #Κατασκευάστε το μοντέλο
35 model = Sequential()
36
37
38 model.add(LSTM(units=50, return_sequences=True, input_shape=(x_train.shape[1], 1)))
39 model.add(Dropout(0.2))
40 model.add(LSTM(units=50, return_sequences=True))
41 model.add(Dropout(0.2))
42 model.add(LSTM(units=50))
43 model.add(Dropout(0.2))
44 model.add(Dense(units=1)) #πρόβλεψη της επόμενης τιμής κλεισίματος
45
46 model.compile(optimizer='adam', loss='mean_squared_error')
47 model.fit(x_train, y_train, epochs=25, batch_size=32)
48
49 '''Ελέγχος της ακρίβειας του μοντέλου σε υπάρχοντα δεδομένα'''
50
51 #Φόρτωση δεδομένων δοκιμής
52 test_start=dt.datetime(2022, 3, 1)
53 test_end=dt.datetime.now()
54
55 test_data = web.DataReader(company, 'yahoo', test_start, test_end)
56 actual_prices=test_data['Close'].values
57
58 total_dataset=pd.concat((data['Close'], test_data['Close']), axis=0)
59
60 model_inputs=total_dataset[len(total_dataset)-len(test_data)-prediction_days:].values
61 model_inputs = model_inputs.reshape(-1, 1)
62 model_inputs = scaler.transform(model_inputs)
63

```

Εικόνα 18: Κώδικας Εφαρμογής 3



```
File Edit View Navigate Code Refactor Run Tools VCS Window Help Papanikolas_Michail_MPPL20059 - main.py
Papanikolas_Michail_MPPL20059 main.py
Project
  Papanikolas_Michail_MPPL20059
  External Libraries
  Scratches and Consoles
Structure
Favorites

64 #Πραγματοποίησε προβλέψεις για τα δεδομένα δοκιμής
65 x_test=[]
66
67 for x in range(prediction_days, len(model_inputs)):
68     x_test.append(model_inputs[x-prediction_days:x, 0])
69
70 x_test=np.array(x_test)
71 x_test=np.reshape(x_test, (x_test.shape[0], x_test.shape[1], 1))
72
73 predicted_prices=model.predict(x_test)
74 predicted_prices=scaler.inverse_transform(predicted_prices)
75
76 #Σχεδίασε τις προβλέψεις του τεστ
77 plt.plot(actual_prices, color = "black", label=f"Actual {company} Price")
78 plt.plot(predicted_prices, color="green", label=f"Predicted {company} Price")
79 plt.title(f"{company} Share Price")
80 plt.xlabel("Time")
81 plt.ylabel(f"{company} Share Price")
82 plt.legend()
83 plt.show()
84
85 #Πρόβλεψη της επόμενης μέρας
86
87 real_data = [model_inputs[len(model_inputs)-prediction_days:len(model_inputs+1), 0]]
88 real_data = np.array(real_data)
89 real_data=np.reshape(real_data, (real_data.shape[0], real_data.shape[1],1))
90
91 prediction=model.predict(real_data)
92 prediction = scaler.inverse_transform(prediction)
93 print(f"Prediction: {prediction}")
```

Εικόνα 19: Κώδικας Εφαρμογής 4

Κεφάλαιο 6^ο: Παραδείγματα Εφαρμογής

6.1 Παράδειγμα Μετοχής Apple


Πρώτη Ημέρα

```

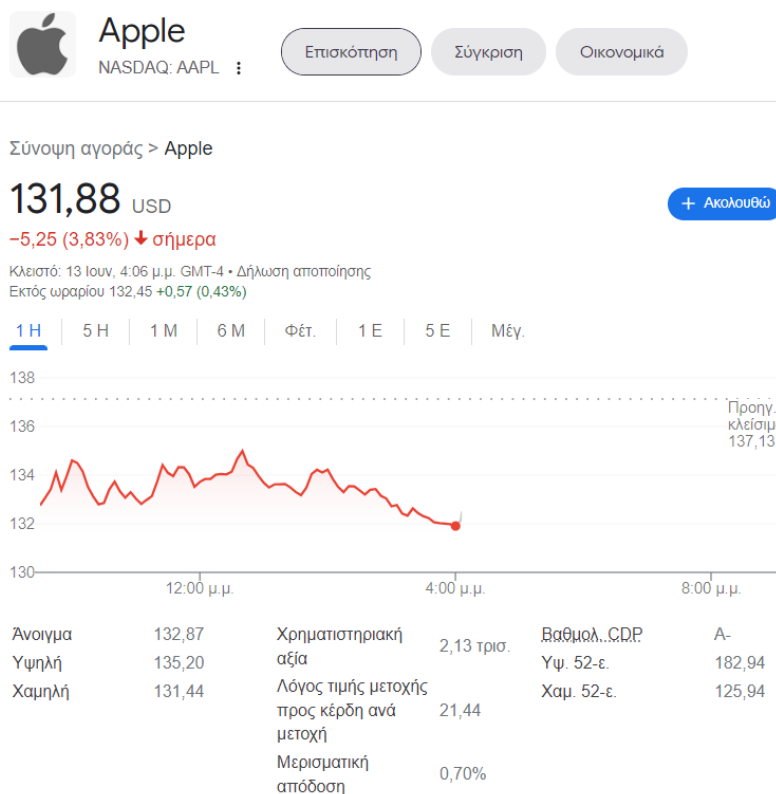
Run: main x
79/79 [=====] - 3s 43ms/step - loss: 8.0718e-04
Epoch 23/25
79/79 [=====] - 4s 45ms/step - loss: 8.6297e-04
Epoch 24/25
79/79 [=====] - 4s 45ms/step - loss: 0.0026
Epoch 25/25
79/79 [=====] - 3s 44ms/step - loss: 8.3133e-04
Prediction: [[138.0113]]

Process finished with exit code 0
    
```

Εικόνα 20: Πρόβλεψη Τιμής Μετοχής Apple (Πρώτη Ημέρα)



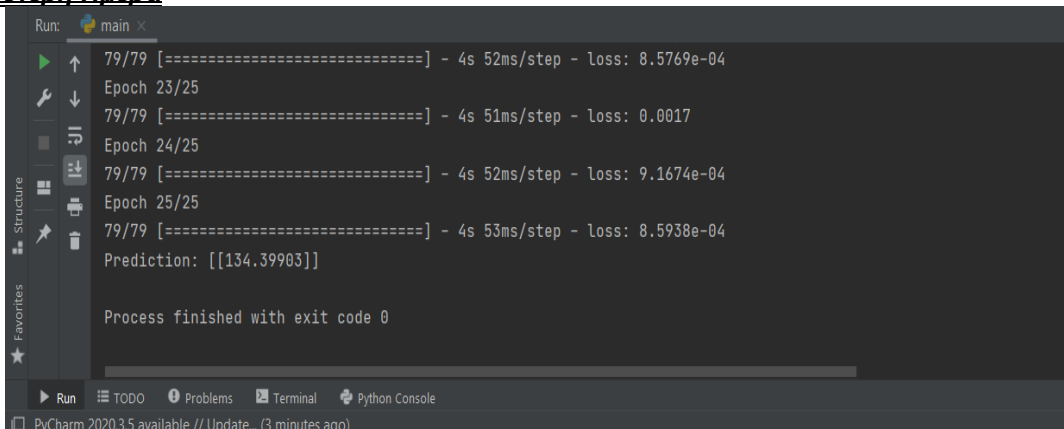
Εικόνα 21: Διάγραμμα Μετοχής Apple (Πρώτη Ημέρα)




Εικόνα 22: Τιμή Κλεισίματος Μετοχής Apple (Πρώτη Ημέρα)

Οι εικόνες 20 και 21 παρουσιάζουν την πρόβλεψη τιμής μετοχής της Apple την πρώτη ημέρα. Η πρόβλεψη της μετοχής πραγματοποιήθηκε στις 10 Ιουνίου 2022 και επιδιώκει να προβλέψει την τιμή κλεισίματος της μετοχής στις 13 Ιουνίου 2022. Από τις εικόνες προβλέπεται ότι η μετοχή της Apple θα κλείσει στην τιμή των 138,0113 δολαρίων. Στην εικόνα 22 παρατηρούμε ότι η μετοχή της Apple έκλεισε στην τιμή των 131,88 δολαρίων. Από τα παραπάνω στοιχεία φαίνεται ότι η πρόβλεψη της τιμής της μετοχής με την τιμή που είχε η μετοχή κατά το κλείσιμο εμφανίζει μια μικρή απόκλιση της τάξης των 6,1313 δολαρίων προς τα κάτω.

Δεύτερη Ημέρα



Εικόνα 23: Πρόβλεψη Τιμής Μετοχής Apple (Δεύτερη Ημέρα)




Εικόνα 24: Διάγραμμα Μετοχής Apple (Δεύτερη Ημέρα)



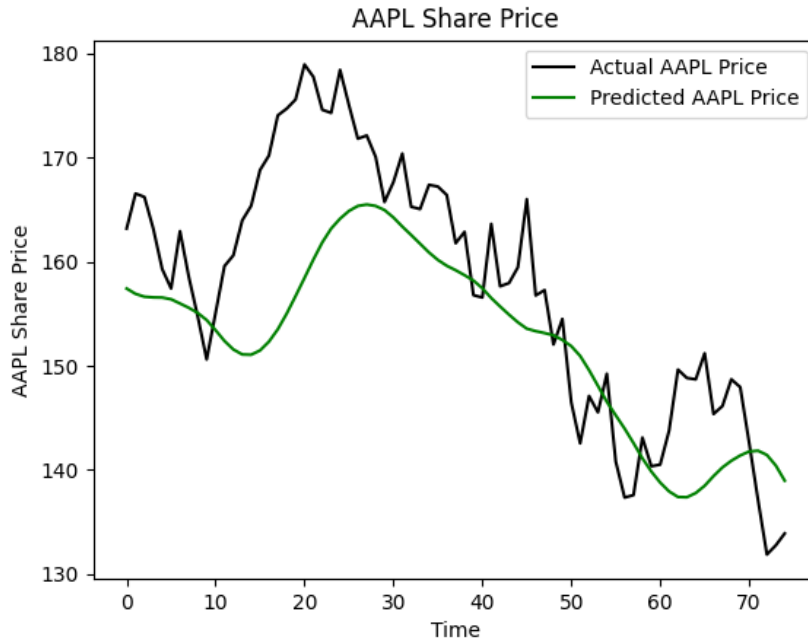
Εικόνα 25: Τιμή Κλεισίματος Μετοχής Apple (Δεύτερη Ημέρα)

Οι εικόνες 23 και 24 παρουσιάζουν την πρόβλεψη τιμής μετοχής της Apple την δεύτερη ημέρα. Η πρόβλεψη της μετοχής πραγματοποιήθηκε στις 13 Ιουνίου 2022 και επιδιώκει να προβλέψει την τιμή κλεισίματος της μετοχής στις 14 Ιουνίου 2022. Από τις εικόνες προβλέπεται ότι η μετοχή της Apple θα κλείσει στην τιμή των 134,39903 δολαρίων. Στην εικόνα 25 παρατηρούμε ότι η μετοχή της Apple έκλεισε στην τιμή των 132,76 δολαρίων. Από τα παραπάνω στοιχεία φαίνεται ότι η πρόβλεψη της τιμής της μετοχής με την τιμή που είχε η μετοχή κατά το κλείσιμο εμφανίζει μια μικρή απόκλιση της τάξης των 1,639 δολαρίων προς τα κάτω.


Τρίτη Ημέρα



Εικόνα 26: Πρόβλεψη Τιμής Μετοχής Apple (Τρίτη Ημέρα)



Εικόνα 27: Διάγραμμα Μετοχής Apple (Τρίτη Ημέρα)



Εικόνα 28: Τιμή Κλεισίματος Μετοχής Apple (Τρίτη Ημέρα)

Οι εικόνες 26 και 27 παρουσιάζουν την πρόβλεψη τιμής μετοχής της Apple την τρίτη ημέρα. Η πρόβλεψη της μετοχής πραγματοποιήθηκε στις 14 Ιουνίου 2022 και επιδιώκει να προβλέψει την τιμή κλεισίματος της μετοχής στις 15 Ιουνίου 2022. Από τις εικόνες προβλέπεται ότι η μετοχή της Apple θα κλείσει στην τιμή των 136,34306 δολαρίων. Στην εικόνα 28 παρατηρούμε ότι η μετοχή της Apple έκλεισε στην τιμή των 135,43 δολαρίων. Από τα παραπάνω στοιχεία φαίνεται ότι η πρόβλεψη της τιμής της μετοχής με την τιμή που είχε η μετοχή κατά το κλείσιμο εμφανίζει μια μικρή απόκλιση της τάξης των 0,91306 δολαρίων προς τα κάτω.

Τέταρτη Ημέρα


```

Run: main x
79/79 [=====] - 4s 45ms/step - loss: 7.8241e-04
Epoch 23/25
79/79 [=====] - 4s 44ms/step - loss: 8.3098e-04
Epoch 24/25
79/79 [=====] - 4s 45ms/step - loss: 8.0954e-04
Epoch 25/25
79/79 [=====] - 4s 45ms/step - loss: 8.0842e-04
Prediction: [[132.45287]]

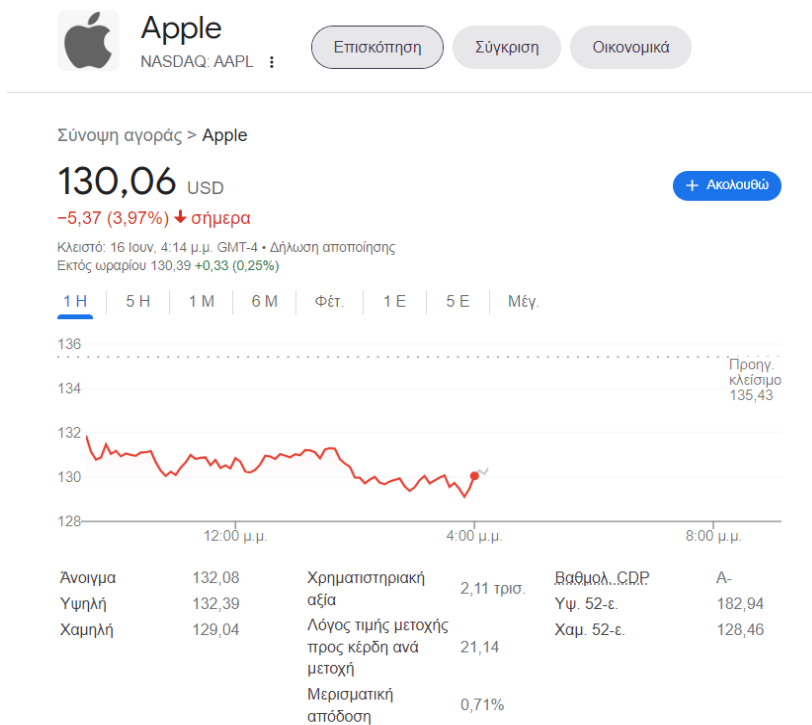
Process finished with exit code 0

```

Εικόνα 29: Πρόβλεψη Τιμής Μετοχής Apple (Τέταρτη Ημέρα)



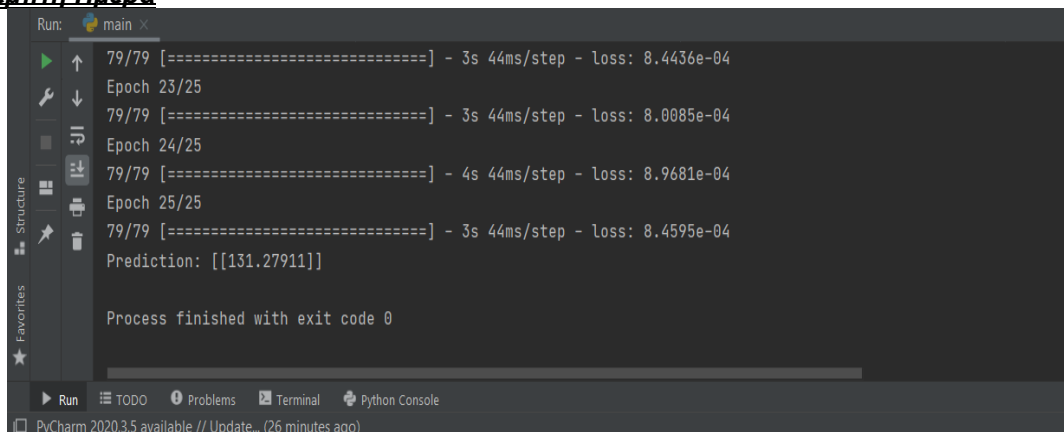
Εικόνα 30: Διάγραμμα Μετοχής Apple (Τέταρτη Ημέρα)




Εικόνα 31: Τιμή Κλεισίματος Μετοχής Apple (Τέταρτη Ημέρα)

Οι εικόνες 29 και 30 παρουσιάζουν την πρόβλεψη τιμής μετοχής της Apple την τέταρτη ημέρα. Η πρόβλεψη της μετοχής πραγματοποιήθηκε στις 15 Ιουνίου 2022 και επιδιώκει να προβλέψει την τιμή κλεισίματος της μετοχής στις 16 Ιουνίου 2022. Από τις εικόνες προβλέπεται ότι η μετοχή της Apple θα κλείσει στην τιμή των 132,45287 δολαρίων. Στην εικόνα 31 παρατηρούμε ότι η μετοχή της Apple έκλεισε στην τιμή των 130,06 δολαρίων. Από τα παραπάνω στοιχεία φαίνεται ότι η πρόβλεψη της τιμής της μετοχής με την τιμή που είχε η μετοχή κατά το κλείσιμο εμφανίζει μια μικρή απόκλιση της τάξης των 2,3928 δολαρίων προς τα κάτω.

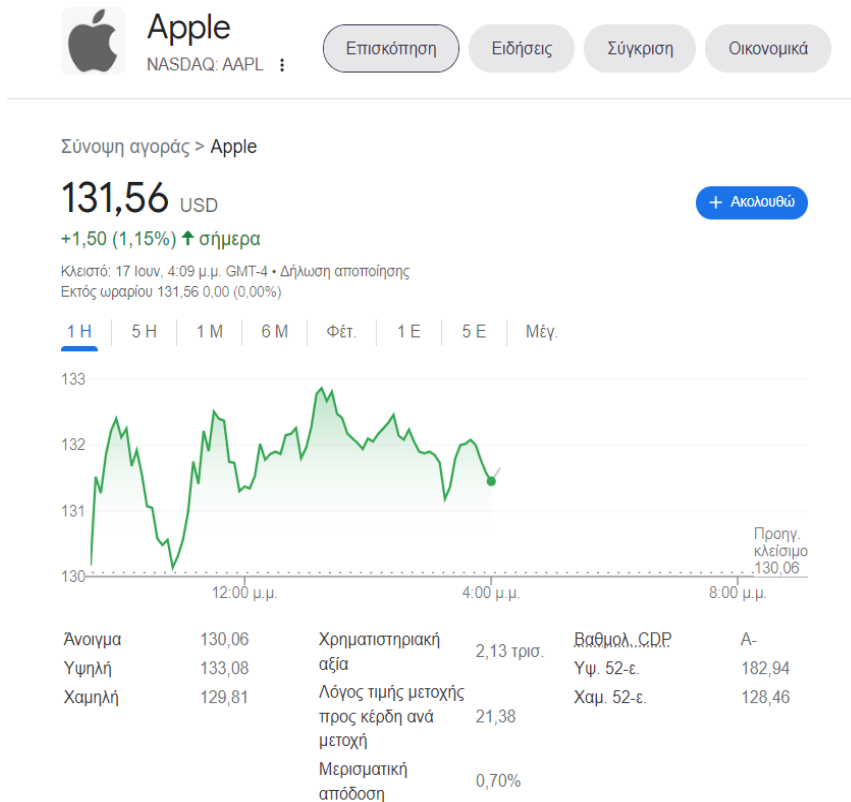
Πέμπτη Ημέρα



Εικόνα 32: Πρόβλεψη Τιμής Μετοχής Apple (Πέμπτη Ημέρα)



Εικόνα 33: Διάγραμμα Μετοχής Apple (Πέμπτη Ημέρα)



Εικόνα 34: Τιμή Κλεισίματος Μετοχής Apple (Πέμπτη Ημέρα)

Οι εικόνες 32 και 33 παρουσιάζουν την πρόβλεψη τιμής μετοχής της Apple την πέμπτη ημέρα. Η πρόβλεψη της μετοχής πραγματοποιήθηκε στις 16 Ιουνίου 2022 και επιδιώκει να προβλέψει την τιμή κλεισίματος της μετοχής στις 17 Ιουνίου 2022. Από τις εικόνες προβλέπεται ότι η μετοχή της Apple θα κλείσει στην τιμή των 131,27911 δολαρίων. Στην εικόνα 34 παρατηρούμε ότι η μετοχή της Apple έκλεισε στην τιμή των 131,56 δολαρίων. Από τα παραπάνω στοιχεία φαίνεται ότι η πρόβλεψη της τιμής της μετοχής με την τιμή που είχε η μετοχή κατά το κλείσιμο εμφανίζει μια μικρή απόκλιση της τάξης των 0,28089 δολαρίων προς τα πάνω.

6.2 Παράδειγμα Μετοχής Facebook

Πρώτη Ημέρα


```

Run: main x
76/76 [=====] - 3s 44ms/step - loss: 0.0012
Epoch 23/25
76/76 [=====] - 3s 44ms/step - loss: 0.0012
Epoch 24/25
76/76 [=====] - 3s 45ms/step - loss: 0.0013
Epoch 25/25
76/76 [=====] - 3s 44ms/step - loss: 0.0013
Prediction: [[170.48941]]

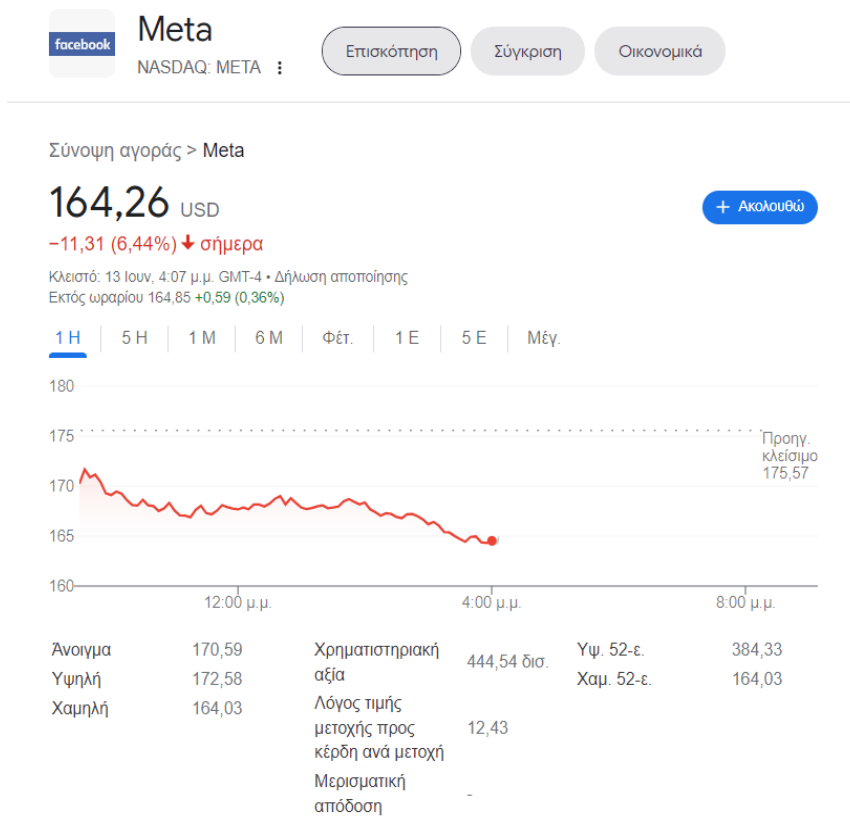
Process finished with exit code 0
    
```

Filesystem Case-Sensitivity Mismatch: The project seems to be located on a case-sensitive file system. // This does not match the IDE setting (controlled by prop

Εικόνα 35: Πρόβλεψη Τιμής Μετοχής Facebook (Πρώτη Ημέρα)



Εικόνα 36: Διάγραμμα Μετοχής Facebook (Πρώτη Ημέρα)



Εικόνα 37: Τιμή Κλεισίματος Μετοχής Facebook (Πρώτη Ημέρα)

Οι εικόνες 35 και 36 παρουσιάζουν την πρόβλεψη τιμής μετοχής του Facebook την πρώτη ημέρα. Η πρόβλεψη της μετοχής πραγματοποιήθηκε στις 10 Ιουνίου 2022 και επιδιώκει να προβλέψει την τιμή κλεισίματος της μετοχής στις 13 Ιουνίου 2022. Από τις εικόνες προβλέπεται ότι η μετοχή του Facebook θα κλείσει στην τιμή των 170,48941 δολαρίων. Στην εικόνα 37 παρατηρούμε ότι η μετοχή του Facebook έκλεισε στην τιμή των 164,26 δολαρίων. Από τα παραπάνω στοιχεία φαίνεται ότι η πρόβλεψη της τιμής της μετοχής με την τιμή που είχε η μετοχή κατά το κλείσιμο εμφανίζει μια μικρή απόκλιση της τάξης των 6,2294 δολαρίων προς τα κάτω.

Δεύτερη Ημέρα


```

Run: main x
76/76 [=====] - 3s 44ms/step - loss: 0.0013
Epoch 23/25
76/76 [=====] - 3s 45ms/step - loss: 0.0014
Epoch 24/25
76/76 [=====] - 3s 45ms/step - loss: 0.0012
Epoch 25/25
76/76 [=====] - 3s 45ms/step - loss: 0.0013
Prediction: [[166.17615]]

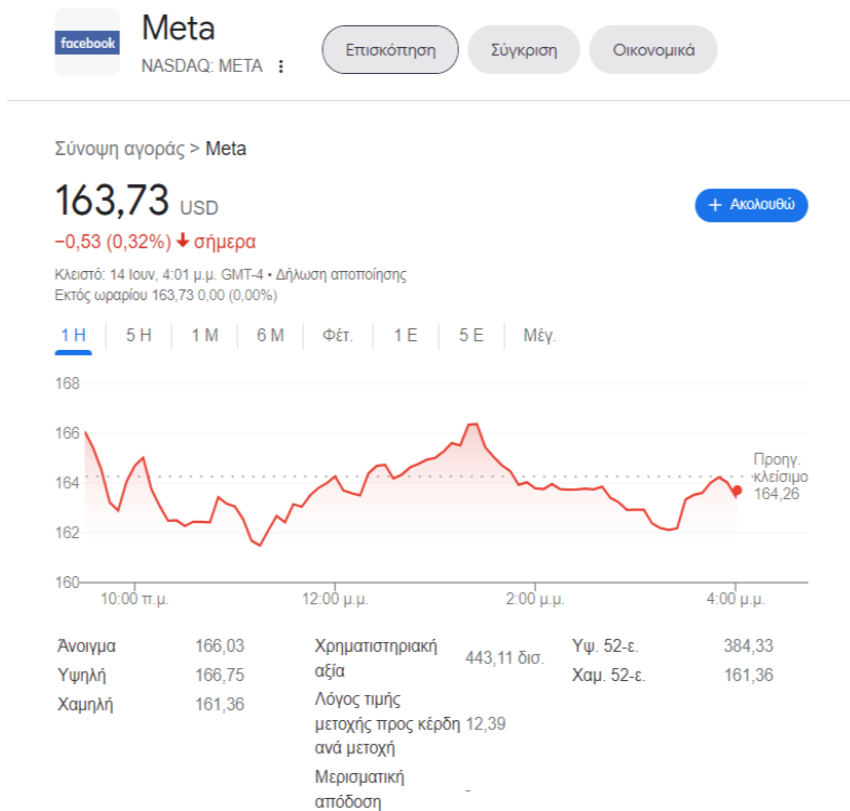
Process finished with exit code 0
  
```

Filesystem Case-Sensitivity Mismatch: The project seems to be located on a case-sensitive file system. // This does not match the IDE setting (control

Εικόνα 38: Πρόβλεψη Τιμής Μετοχής Facebook (Δεύτερη Ημέρα)



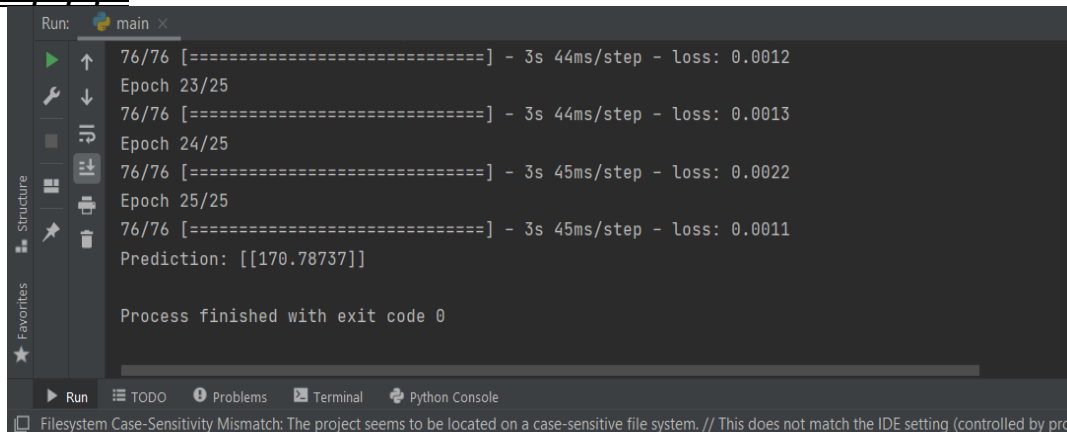
Εικόνα 39: Διάγραμμα Μετοχής Facebook (Δεύτερη Ημέρα)



Εικόνα 40: Τιμή Κλεισίματος Μετοχής Facebook (Δεύτερη Ημέρα)

Οι εικόνες 38 και 39 παρουσιάζουν την πρόβλεψη τιμής μετοχής του Facebook την δεύτερη ημέρα. Η πρόβλεψη της μετοχής πραγματοποιήθηκε στις 13 Ιουνίου 2022 και επιδιώκει να προβλέψει την τιμή κλεισίματος της μετοχής στις 14 Ιουνίου 2022. Από τις εικόνες προβλέπεται ότι η μετοχή του Facebook θα κλείσει στην τιμή των 166,17615 δολαρίων. Στην εικόνα 40 παρατηρούμε ότι η μετοχή του Facebook έκλεισε στην τιμή των 163,73 δολαρίων. Από τα παραπάνω στοιχεία φαίνεται ότι η πρόβλεψη της τιμής της μετοχής με την τιμή που είχε η μετοχή κατά το κλείσιμο εμφανίζει μια μικρή απόκλιση της τάξης των 2,4461 δολαρίων προς τα κάτω.

Τρίτη Ημέρα




```

Run: main x
76/76 [=====] - 3s 44ms/step - loss: 0.0012
Epoch 23/25
76/76 [=====] - 3s 44ms/step - loss: 0.0013
Epoch 24/25
76/76 [=====] - 3s 45ms/step - loss: 0.0022
Epoch 25/25
76/76 [=====] - 3s 45ms/step - loss: 0.0011
Prediction: [[170.78737]]

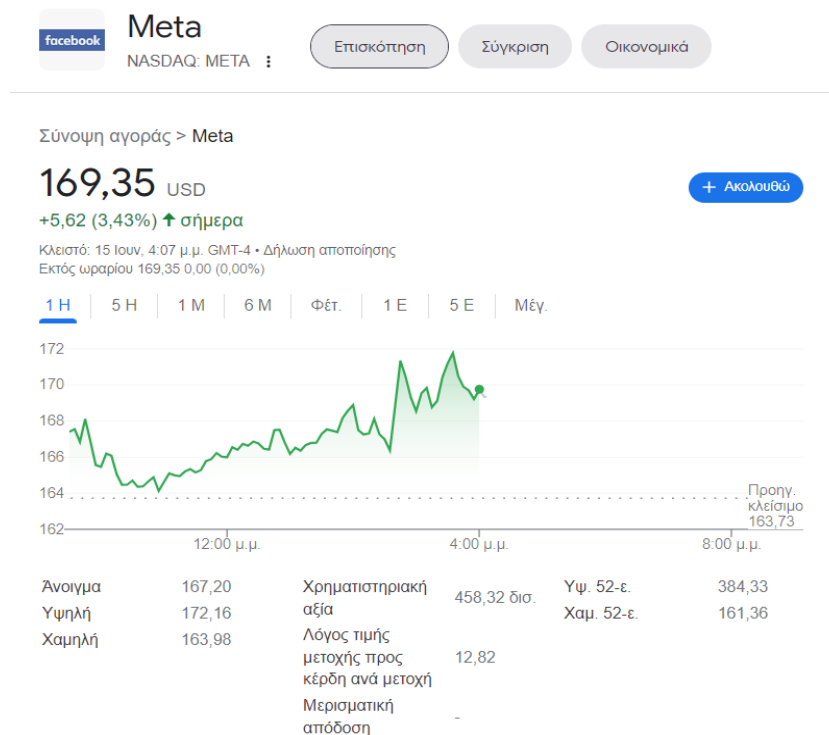
Process finished with exit code 0

```

Εικόνα 41: Πρόβλεψη Τιμής Μετοχής Facebook (Τρίτη Ημέρα)



Εικόνα 42: Διάγραμμα Μετοχής Facebook (Τρίτη Ημέρα)



Εικόνα 43: Τιμή Κλεισίματος Μετοχής Facebook (Τρίτη Ημέρα)

Οι εικόνες 41 και 42 παρουσιάζουν την πρόβλεψη τιμής μετοχής του Facebook την τρίτη ημέρα. Η πρόβλεψη της μετοχής πραγματοποιήθηκε στις 14 Ιουνίου 2022 και επιδιώκει να προβλέψει την τιμή κλεισίματος της μετοχής στις 15 Ιουνίου 2022. Από τις εικόνες προβλέπεται ότι η μετοχή του Facebook θα κλείσει στην τιμή των 170,78737 δολαρίων. Στην εικόνα 43 παρατηρούμε ότι η μετοχή του Facebook έκλεισε στην τιμή των 169,35 δολαρίων. Από τα παραπάνω στοιχεία φαίνεται ότι η πρόβλεψη της τιμής της μετοχής με την τιμή που είχε η μετοχή κατά το κλείσιμο εμφανίζει μια μικρή απόκλιση της τάξης των 1,4373 δολαρίων προς τα κάτω.

Τέταρτη Ημέρα


```

Run: main x
76/76 [=====] - 3s 44ms/step - loss: 0.0014
Epoch 23/25
76/76 [=====] - 3s 45ms/step - loss: 0.0012
Epoch 24/25
76/76 [=====] - 3s 45ms/step - loss: 0.0013
Epoch 25/25
76/76 [=====] - 3s 45ms/step - loss: 0.0013
Prediction: [[168.70924]]

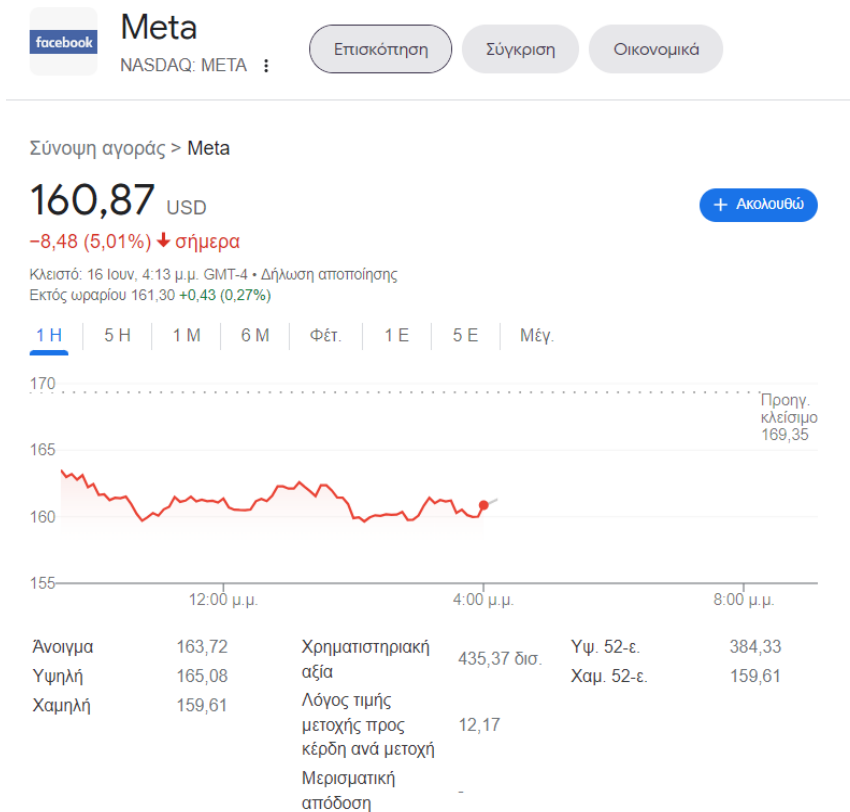
Process finished with exit code 0

```

Εικόνα 44: Πρόβλεψη Τιμής Μετοχής Facebook (Τέταρτη Ημέρα)



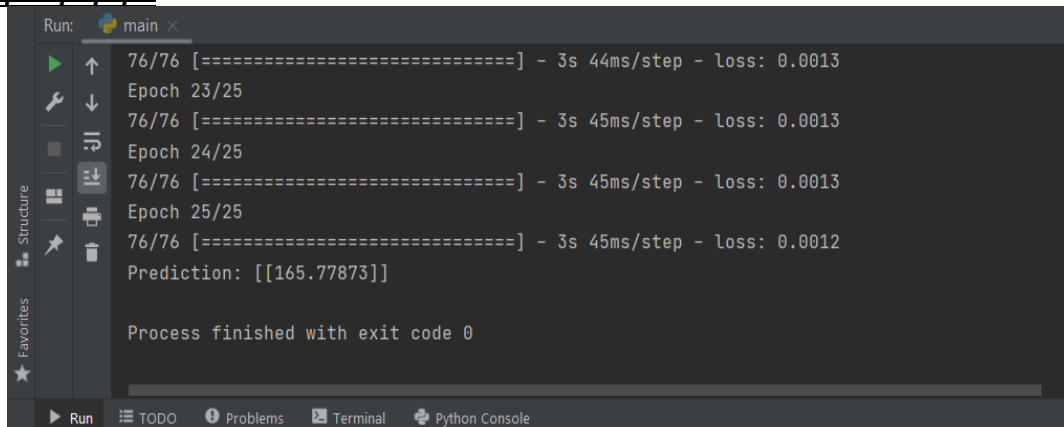
Εικόνα 45: Διάγραμμα Μετοχής Facebook (Τέταρτη Ημέρα)



Εικόνα 46: Τιμή Κλεισίματος Μετοχής Facebook (Τέταρτη Ημέρα)

Οι εικόνες 44 και 45 παρουσιάζουν την πρόβλεψη τιμής μετοχής του Facebook την τέταρτη ημέρα. Η πρόβλεψη της μετοχής πραγματοποιήθηκε στις 15 Ιουνίου 2022 και επιδιώκει να προβλέψει την τιμή κλεισίματος της μετοχής στις 16 Ιουνίου 2022. Από τις εικόνες προβλέπεται ότι η μετοχή του Facebook θα κλείσει στην τιμή των 168,70924 δολαρίων. Στην εικόνα 46 παρατηρούμε ότι η μετοχή του Facebook έκλεισε στην τιμή των 160,87 δολαρίων. Από τα παραπάνω στοιχεία φαίνεται ότι η πρόβλεψη της τιμής της μετοχής με την τιμή που είχε η μετοχή κατά το κλείσιμο εμφανίζει μια μικρή απόκλιση της τάξης των 7,8392 δολαρίων προς τα κάτω.

Πέμπτη Ημέρα




```

Run: main x
76/76 [=====] - 3s 44ms/step - loss: 0.0013
Epoch 23/25
76/76 [=====] - 3s 45ms/step - loss: 0.0013
Epoch 24/25
76/76 [=====] - 3s 45ms/step - loss: 0.0013
Epoch 25/25
76/76 [=====] - 3s 45ms/step - loss: 0.0012
Prediction: [[165.77873]]

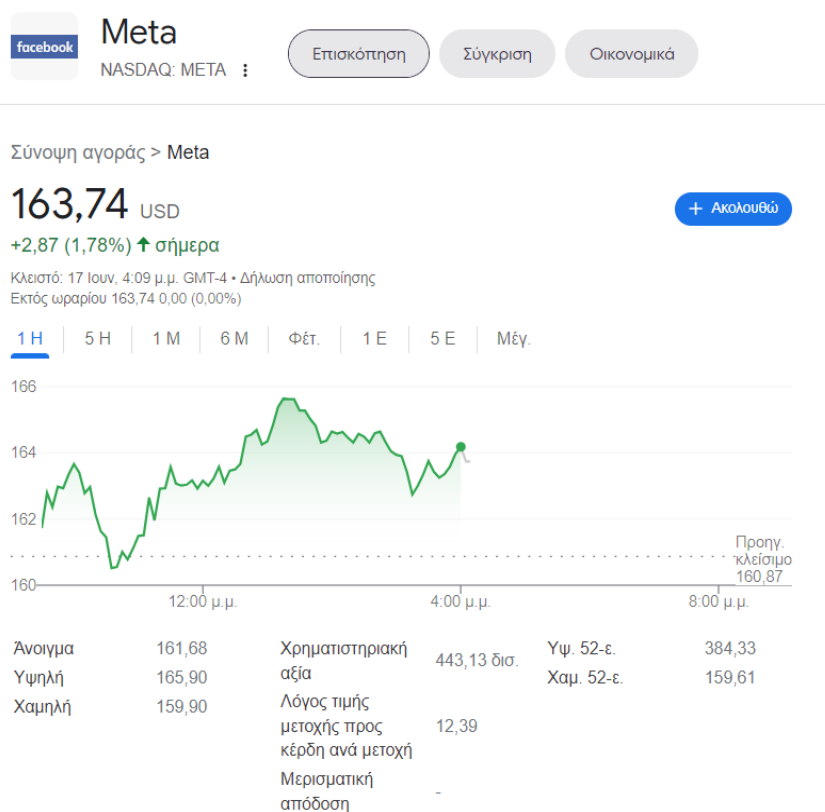
Process finished with exit code 0

```

Εικόνα 47: Πρόβλεψη Τιμής Μετοχής Facebook (Πέμπτη Ημέρα)



Εικόνα 48: Διάγραμμα Μετοχής Facebook (Πέμπτη Ημέρα)

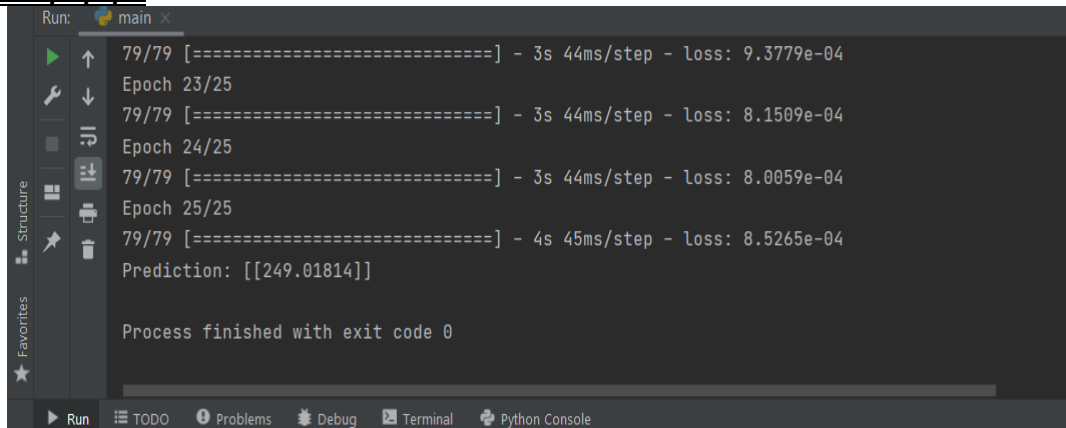


Εικόνα 49: Τιμή Κλεισίματος Μετοχής Facebook (Πέμπτη Ημέρα)


Οι εικόνες 47 και 48 παρουσιάζουν την πρόβλεψη τιμής μετοχής του Facebook την πέμπτη ημέρα. Η πρόβλεψη της μετοχής πραγματοποιήθηκε στις 16 Ιουνίου 2022 και επιδιώκει να προβλέψει την τιμή κλεισίματος της μετοχής στις 17 Ιουνίου 2022. Από τις εικόνες προβλέπεται ότι η μετοχή του Facebook θα κλείσει στην τιμή των 165,77873 δολαρίων. Στην εικόνα 49 παρατηρούμε ότι η μετοχή του Facebook έκλεισε στην τιμή των 163,74 δολαρίων. Από τα παραπάνω στοιχεία φαίνεται ότι η πρόβλεψη της τιμής της μετοχής με την τιμή που είχε η μετοχή κατά το κλείσιμο εμφανίζει μια μικρή απόκλιση της τάξης των 2,0387 δολαρίων προς τα κάτω.

6.3 Παράδειγμα Μετοχής Microsoft

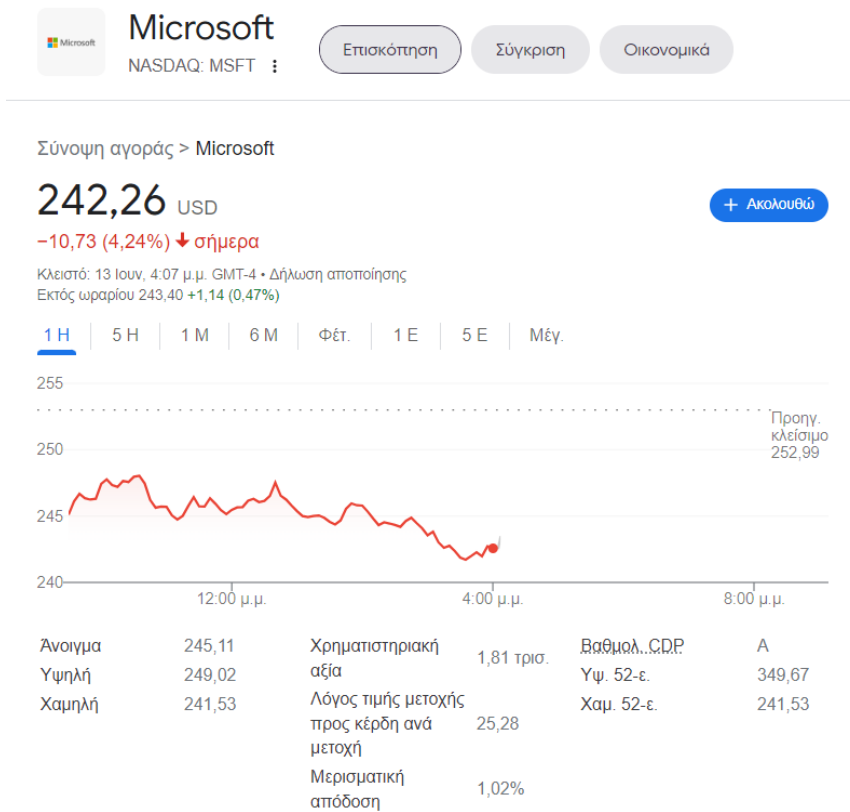
Πρώτη Ημέρα



Εικόνα 50: Πρόβλεψη Τιμής Μετοχής Microsoft (Πρώτη Ημέρα)



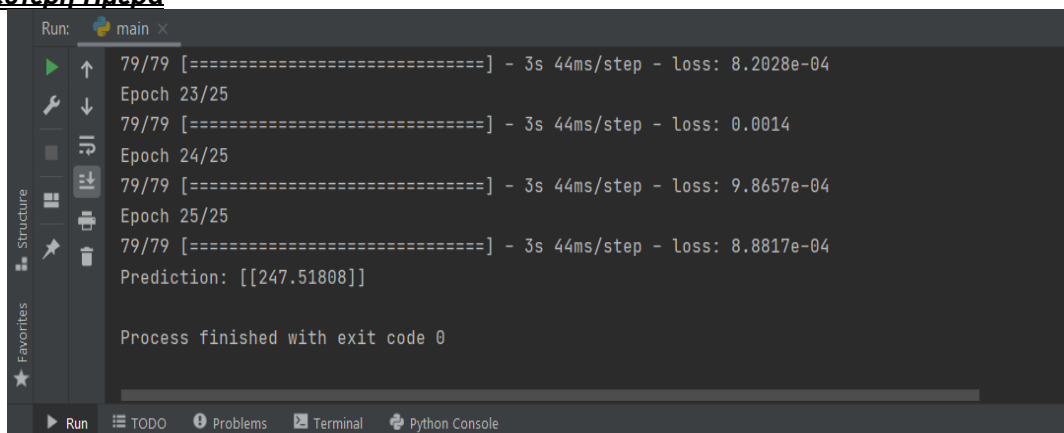
Εικόνα 51: Διάγραμμα Μετοχής Microsoft (Πρώτη Ημέρα)




Εικόνα 52: Τιμή Κλεισίματος Μετοχής Microsoft (Πρώτη Ημέρα)

Οι εικόνες 50 και 51 παρουσιάζουν την πρόβλεψη τιμής μετοχής της Microsoft την πρώτη ημέρα. Η πρόβλεψη της μετοχής πραγματοποιήθηκε στις 10 Ιουνίου 2022 και επιδιώκει να προβλέψει την τιμή κλεισίματος της μετοχής στις 13 Ιουνίου 2022. Από τις εικόνες προβλέπεται ότι η μετοχή της Microsoft θα κλείσει στην τιμή των 249,01814 δολαρίων. Στην εικόνα 52 παρατηρούμε ότι η μετοχή της Microsoft έκλεισε στην τιμή των 242,26 δολαρίων. Από τα παραπάνω στοιχεία φαίνεται ότι η πρόβλεψη της τιμής της μετοχής με την τιμή που είχε η μετοχή κατά το κλείσιμο εμφανίζει μια μικρή απόκλιση της τάξης των 6,7581 δολαρίων προς τα κάτω.


Δεύτερη Ημέρα



Εικόνα 53: Πρόβλεψη Τιμής Μετοχής Microsoft (Δεύτερη Ημέρα)



Εικόνα 54: Διάγραμμα Μετοχής Microsoft (Δεύτερη Ημέρα)



Εικόνα 55: Τιμή Κλεισίματος Μετοχής Microsoft (Δεύτερη Ημέρα)

Οι εικόνες 53 και 54 παρουσιάζουν την πρόβλεψη τιμής μετοχής της Microsoft την δεύτερη ημέρα. Η πρόβλεψη της μετοχής πραγματοποιήθηκε στις 13 Ιουνίου 2022 και επιδιώκει να προβλέψει την τιμή κλεισίματος της μετοχής στις 14 Ιουνίου 2022. Από τις εικόνες προβλέπεται ότι η μετοχή της Microsoft θα κλείσει στην τιμή των 241,51808 δολαρίων. Στην εικόνα 55 παρατηρούμε ότι η μετοχή της Microsoft έκλεισε στην τιμή των 244,49 δολαρίων. Από τα παραπάνω στοιχεία φαίνεται ότι η πρόβλεψη της τιμής της μετοχής με την τιμή που είχε η μετοχή κατά το κλείσιμο εμφανίζει μια μικρή απόκλιση της τάξης των 2,9719 δολαρίων προς τα πάνω.

Τρίτη Ημέρα


```

Run: main x
79/79 [=====] - 5s 58ms/step - loss: 7.5731e-04
Epoch 23/25
79/79 [=====] - 5s 57ms/step - loss: 7.6403e-04
Epoch 24/25
79/79 [=====] - 5s 58ms/step - loss: 9.1854e-04
Epoch 25/25
79/79 [=====] - 4s 51ms/step - loss: 8.3314e-04
Prediction: [[254.33833]]

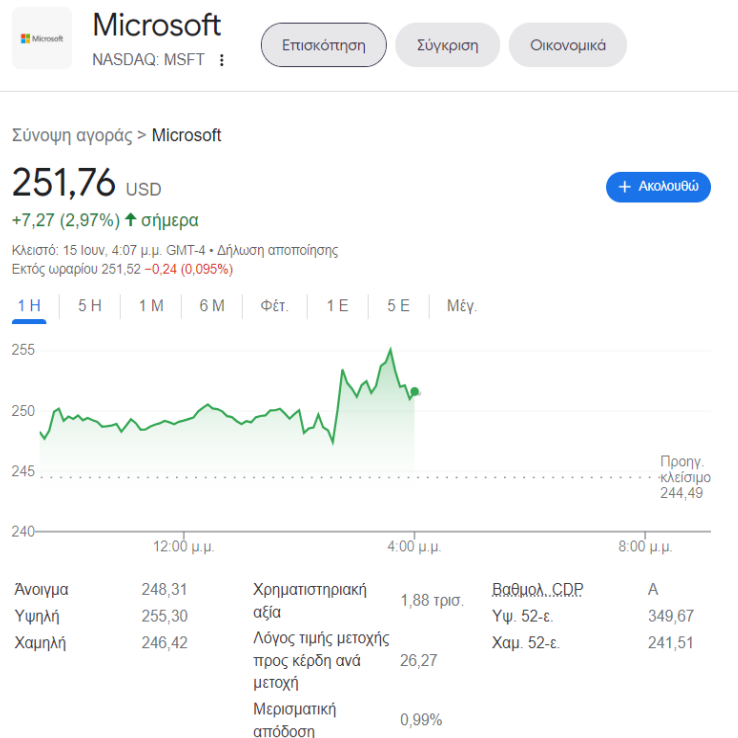
Process finished with exit code 0

```

Εικόνα 56: Πρόβλεψη Τιμής Μετοχής Microsoft (Τρίτη Ημέρα)



Εικόνα 57: Διάγραμμα Μετοχής Microsoft (Τρίτη Ημέρα)



Εικόνα 58: Τιμή Κλεισίματος Μετοχής Microsoft (Τρίτη Ημέρα)

Οι εικόνες 56 και 57 παρουσιάζουν την πρόβλεψη τιμής μετοχής της Microsoft την τρίτη ημέρα. Η πρόβλεψη της μετοχής πραγματοποιήθηκε στις 14 Ιουνίου 2022 και επιδιώκει να προβλέψει την τιμή κλεισίματος της μετοχής στις 15 Ιουνίου 2022. Από τις εικόνες προβλέπεται ότι η μετοχή της Microsoft θα κλείσει στην τιμή των 254,33833 δολαρίων. Στην εικόνα 58 παρατηρούμε ότι η μετοχή της Microsoft έκλεισε στην τιμή των 251,76 δολαρίων. Από τα παραπάνω στοιχεία φαίνεται ότι η πρόβλεψη της τιμής της μετοχής με την τιμή που είχε η μετοχή κατά το κλείσιμο εμφανίζει μια μικρή απόκλιση της τάξης των 2,5783 δολαρίων προς τα κάτω.

Τέταρτη Ημέρα


```

Run: main x
79/79 [=====] - 4s 46ms/step - loss: 8.9139e-04
Epoch 23/25
79/79 [=====] - 4s 45ms/step - loss: 8.7518e-04
Epoch 24/25
79/79 [=====] - 4s 45ms/step - loss: 9.0658e-04
Epoch 25/25
79/79 [=====] - 4s 45ms/step - loss: 7.9852e-04
Prediction: [[239.36844]]

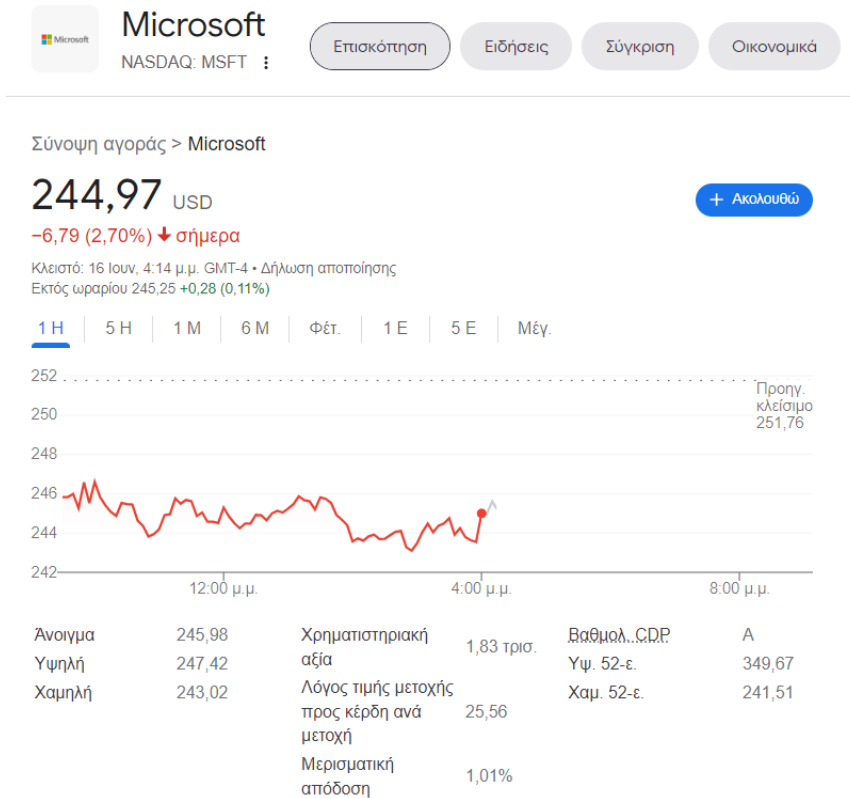
Process finished with exit code 0

```

Εικόνα 59: Πρόβλεψη Τιμής Μετοχής Microsoft (Τέταρτη Ημέρα)



Εικόνα 60: Διάγραμμα Μετοχής Microsoft (Τέταρτη Ημέρα)



Εικόνα 61: Τιμή Κλεισίματος Μετοχής Microsoft (Τέταρτη Ημέρα)

Οι εικόνες 59 και 60 παρουσιάζουν την πρόβλεψη τιμής μετοχής της Microsoft την τέταρτη ημέρα. Η πρόβλεψη της μετοχής πραγματοποιήθηκε στις 15 Ιουνίου 2022 και επιδιώκει να προβλέψει την τιμή κλεισίματος της μετοχής στις 16 Ιουνίου 2022. Από τις εικόνες προβλέπεται ότι η μετοχή της Microsoft θα κλείσει στην τιμή των 239,36844 δολαρίων. Στην εικόνα 61 παρατηρούμε ότι η μετοχή της Microsoft έκλεισε στην τιμή των 244,97 δολαρίων. Από τα παραπάνω στοιχεία φαίνεται ότι η πρόβλεψη της τιμής της μετοχής με την τιμή που είχε η μετοχή κατά το κλείσιμο εμφανίζει μια μικρή απόκλιση της τάξης των 5,6015 δολαρίων προς τα πάνω.

Πέμπτη Ημέρα


```

Run: main x
79/79 [=====] - 3s 44ms/step - loss: 0.0010
Epoch 23/25
79/79 [=====] - 4s 46ms/step - loss: 8.4695e-04
Epoch 24/25
79/79 [=====] - 4s 45ms/step - loss: 8.5357e-04
Epoch 25/25
79/79 [=====] - 4s 45ms/step - loss: 9.4151e-04
Prediction: [[243.04819]]

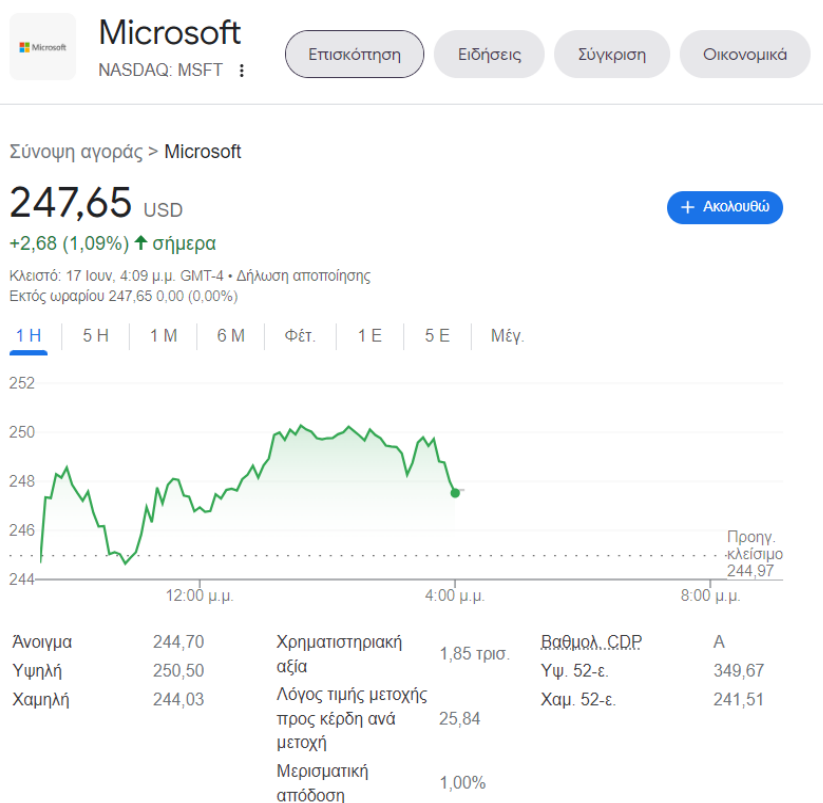
Process finished with exit code 0

```

Εικόνα 62: Πρόβλεψη Τιμής Μετοχής Microsoft (Πέμπτη Ημέρα)



Εικόνα 63: Διάγραμμα Μετοχής Microsoft (Πέμπτη Ημέρα)



Εικόνα 64: Τιμή Κλεισίματος Μετοχής Microsoft (Πέμπτη Ημέρα)

Οι εικόνες 62 και 63 παρουσιάζουν την πρόβλεψη τιμής μετοχής της Microsoft την πέμπτη ημέρα. Η πρόβλεψη της μετοχής πραγματοποιήθηκε στις 16 Ιουνίου 2022 και επιδιώκει να προβλέψει την τιμή κλεισίματος της μετοχής στις 17 Ιουνίου 2022. Από τις εικόνες προβλέπεται ότι η μετοχή της Microsoft θα κλείσει στην τιμή των 243,04819 δολαρίων. Στην εικόνα 64 παρατηρούμε ότι η μετοχή της Microsoft έκλεισε στην τιμή των 247,65 δολαρίων. Από τα παραπάνω στοιχεία φαίνεται ότι η πρόβλεψη της τιμής της μετοχής με την τιμή που είχε η μετοχή κατά το κλείσιμο εμφανίζει μια μικρή απόκλιση της τάξης των 4,6018 δολαρίων προς τα πάνω.

6.4 Παράδειγμα Μετοχής Tesla


Πρώτη Ημέρα

```


Run: main x
79/79 [=====] - 4s 44ms/step - loss: 6.7557e-04
Epoch 23/25
79/79 [=====] - 4s 45ms/step - loss: 7.8657e-04
Epoch 24/25
79/79 [=====] - 4s 45ms/step - loss: 7.1564e-04
Epoch 25/25
79/79 [=====] - 4s 45ms/step - loss: 7.8546e-04
Prediction: [[644.32227]]

Process finished with exit code 0
    
```

Εικόνα 65: Πρόβλεψη Τιμής Μετοχής Tesla (Πρώτη Ημέρα)



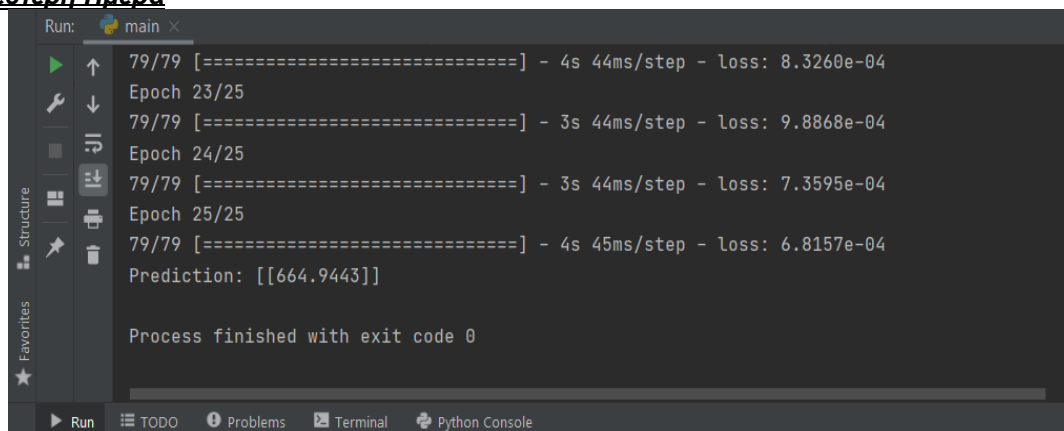
Εικόνα 66: Διάγραμμα Μετοχής Tesla (Πρώτη Ημέρα)




Εικόνα 67: Τιμή Κλεισίματος Μετοχής Tesla (Πρώτη Ημέρα)

Οι εικόνες 65 και 66 παρουσιάζουν την πρόβλεψη τιμής μετοχής της Tesla την πρώτη ημέρα. Η πρόβλεψη της μετοχής πραγματοποιήθηκε στις 10 Ιουνίου 2022 και επιδιώκει να προβλέψει την τιμή κλεισίματος της μετοχής στις 13 Ιουνίου 2022. Από τις εικόνες προβλέπεται ότι η μετοχή της Tesla θα κλείσει στην τιμή των 644,32227 δολαρίων. Στην εικόνα 67 παρατηρούμε ότι η μετοχή της Tesla έκλεισε στην τιμή των 647,21 δολαρίων. Από τα παραπάνω στοιχεία φαίνεται ότι η πρόβλεψη της τιμής της μετοχής με την τιμή που είχε η μετοχή κατά το κλείσιμο εμφανίζει μια μικρή απόκλιση της τάξης των 2,8877 δολαρίων προς τα πάνω.


Δεύτερη Ημέρα



Εικόνα 68: Πρόβλεψη Τιμής Μετοχής Tesla (Δεύτερη Ημέρα)



Εικόνα 69: Διάγραμμα Μετοχής Tesla (Δεύτερη Ημέρα)



Εικόνα 70: Τιμή Κλεισίματος Μετοχής Tesla (Δεύτερη Ημέρα)

Οι εικόνες 68 και 69 παρουσιάζουν την πρόβλεψη τιμής μετοχής της Tesla την δεύτερη ημέρα. Η πρόβλεψη της μετοχής πραγματοποιήθηκε στις 13 Ιουνίου 2022 και επιδιώκει να προβλέψει την τιμή κλεισίματος της μετοχής στις 14 Ιουνίου 2022. Από τις εικόνες προβλέπεται ότι η μετοχή της Tesla θα κλείσει στην τιμή των 664,9443 δολαρίων. Στην εικόνα 70 παρατηρούμε ότι η μετοχή της Tesla έκλεισε στην τιμή των 662,67 δολαρίων. Από τα παραπάνω στοιχεία φαίνεται ότι η πρόβλεψη της τιμής της μετοχής με την τιμή που είχε η μετοχή κατά το κλείσιμο εμφανίζει μια μικρή απόκλιση της τάξης των 2,2743 δολαρίων προς τα κάτω.

Τρίτη Ημέρα


```

Run: main x
79/79 [=====] - 4s 45ms/step - loss: 8.8163e-04
Epoch 23/25
79/79 [=====] - 3s 44ms/step - loss: 7.7362e-04
Epoch 24/25
79/79 [=====] - 3s 44ms/step - loss: 7.1859e-04
Epoch 25/25
79/79 [=====] - 3s 44ms/step - loss: 7.4658e-04
Prediction: [[703.9488]]

Process finished with exit code 0

```

Εικόνα 71: Πρόβλεψη Τιμής Μετοχής Tesla (Τρίτη Ημέρα)



Εικόνα 72: Διάγραμμα Μετοχής Tesla (Τρίτη Ημέρα)



Εικόνα 73: Τιμή Κλεισίματος Μετοχής Tesla (Τρίτη Ημέρα)

Οι εικόνες 71 και 72 παρουσιάζουν την πρόβλεψη τιμής μετοχής της Tesla την τρίτη ημέρα. Η πρόβλεψη της μετοχής πραγματοποιήθηκε στις 14 Ιουνίου 2022 και επιδιώκει να προβλέψει την τιμή κλεισίματος της μετοχής στις 15 Ιουνίου 2022. Από τις εικόνες προβλέπεται ότι η μετοχή της Tesla θα κλείσει στην τιμή των 703,9488 δολαρίων. Στην εικόνα 73 παρατηρούμε ότι η μετοχή της Tesla έκλεισε στην τιμή των 699 δολαρίων. Από τα παραπάνω στοιχεία φαίνεται ότι η πρόβλεψη της τιμής της μετοχής με την τιμή που είχε η μετοχή κατά το κλείσιμο εμφανίζει μια μικρή απόκλιση της τάξης των 4,9488 δολαρίων προς τα κάτω.

Τέταρτη Ημέρα


```

Run: main x
79/79 [=====] - 4s 46ms/step - loss: 9.2380e-04
Epoch 23/25
79/79 [=====] - 4s 49ms/step - loss: 9.5856e-04
Epoch 24/25
79/79 [=====] - 4s 47ms/step - loss: 8.0274e-04
Epoch 25/25
79/79 [=====] - 4s 46ms/step - loss: 7.7631e-04
Prediction: [[647.5302]]


Process finished with exit code 0

```

Εικόνα 74: Πρόβλεψη Τιμής Μετοχής Tesla (Τέταρτη Ημέρα)



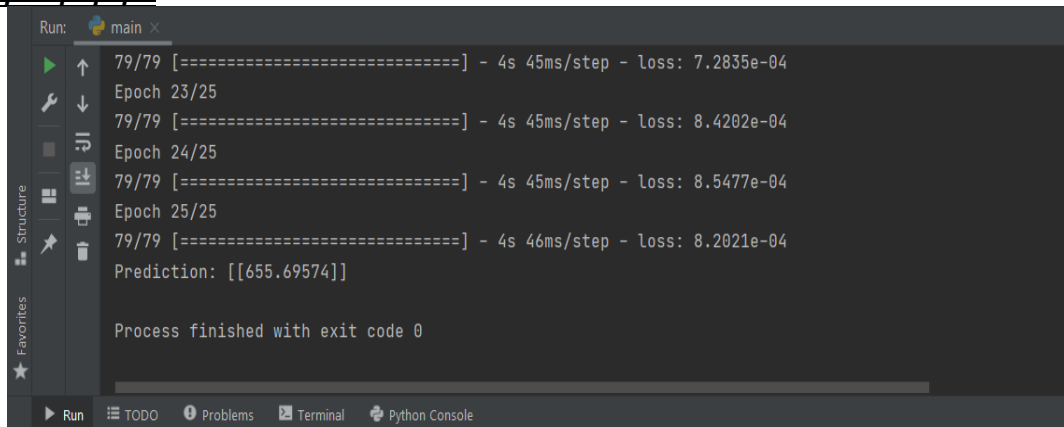
Εικόνα 75: Διάγραμμα Μετοχής Tesla (Τέταρτη Ημέρα)



Εικόνα 76: Τιμή Κλεισίματος Μετοχής Tesla (Τέταρτη Ημέρα)

Οι εικόνες 74 και 75 παρουσιάζουν την πρόβλεψη τιμής μετοχής της Tesla την τέταρτη ημέρα. Η πρόβλεψη της μετοχής πραγματοποιήθηκε στις 15 Ιουνίου 2022 και επιδιώκει να προβλέψει την τιμή κλεισίματος της μετοχής στις 16 Ιουνίου 2022. Από τις εικόνες προβλέπεται ότι η μετοχή της Tesla θα κλείσει στην τιμή των 647,5302 δολαρίων. Στην εικόνα 76 παρατηρούμε ότι η μετοχή της Tesla έκλεισε στην τιμή των 639,30 δολαρίων. Από τα παραπάνω στοιχεία φαίνεται ότι η πρόβλεψη της τιμής της μετοχής με την τιμή που είχε η μετοχή κατά το κλείσιμο εμφανίζει μια μικρή απόκλιση της τάξης των 8,2302 δολαρίων προς τα κάτω.

Πέμπτη Ημέρα




```

Run: main x
79/79 [=====] - 4s 45ms/step - loss: 7.2835e-04
Epoch 23/25
79/79 [=====] - 4s 45ms/step - loss: 8.4202e-04
Epoch 24/25
79/79 [=====] - 4s 45ms/step - loss: 8.5477e-04
Epoch 25/25
79/79 [=====] - 4s 46ms/step - loss: 8.2021e-04
Prediction: [[655.69574]]

Process finished with exit code 0

```

Εικόνα 77: Πρόβλεψη Τιμής Μετοχής Tesla (Πέμπτη Ημέρα)



Εικόνα 78: Διάγραμμα Μετοχής Tesla (Πέμπτη Ημέρα)


Tesla Motors

NASDAQ: TSLA

Επισκόπηση

Ειδήσεις

Σύγκριση

Οικονομικά

Σύνοψη αγοράς > Tesla Motors

650,28 USD

+ Ακολουθώ

+10,98 (1,72%) ↑ σήμερα

 Κλειστό: 17 Ιουν. 4:10 μ.μ. GMT-4 • Δήλωση αποποίησης
 Εκτός ωραρίου 649,73 -0,55 (0,085%)

1 H | 5 H | 1 M | 6 M | Φέτ. | 1 E | 5 E | Μέγ.



Ανοιγμα	640,30	Χρηματιστηριακή αξία	673,70 δισ.	Υψ. 52-ε.	1.243,49
Υψηλή	662,91	Λόγος τιμής μετοχής προς κέρδη ανά μετοχή	87,89	Χαμ. 52-ε.	593,50
Χαμηλή	639,59	Μερισματική απόδοση	-		

Εικόνα 79: Τιμή Κλεισίματος Μετοχής Tesla (Πέμπτη Ημέρα)

Οι εικόνες 77 και 78 παρουσιάζουν την πρόβλεψη τιμής μετοχής της Tesla την πέμπτη ημέρα. Η πρόβλεψη της μετοχής πραγματοποιήθηκε στις 16 Ιουνίου 2022 και επιδιώκει να προβλέψει την τιμή κλεισίματος της μετοχής στις 17 Ιουνίου 2022. Από τις εικόνες προβλέπεται ότι η μετοχή της Tesla θα κλείσει στην τιμή των 655,69574 δολαρίων. Στην εικόνα 79 παρατηρούμε ότι η μετοχή της Tesla έκλεισε στην τιμή των 650,28 δολαρίων. Από τα παραπάνω στοιχεία φαίνεται ότι η πρόβλεψη της τιμής της μετοχής με την τιμή που είχε η μετοχή κατά το κλείσιμο εμφανίζει μια μικρή απόκλιση της τάξης των 5,4157 δολαρίων προς τα κάτω.

6.5 Παράδειγμα Μετοχής Google


Πρώτη Ημέρα

```

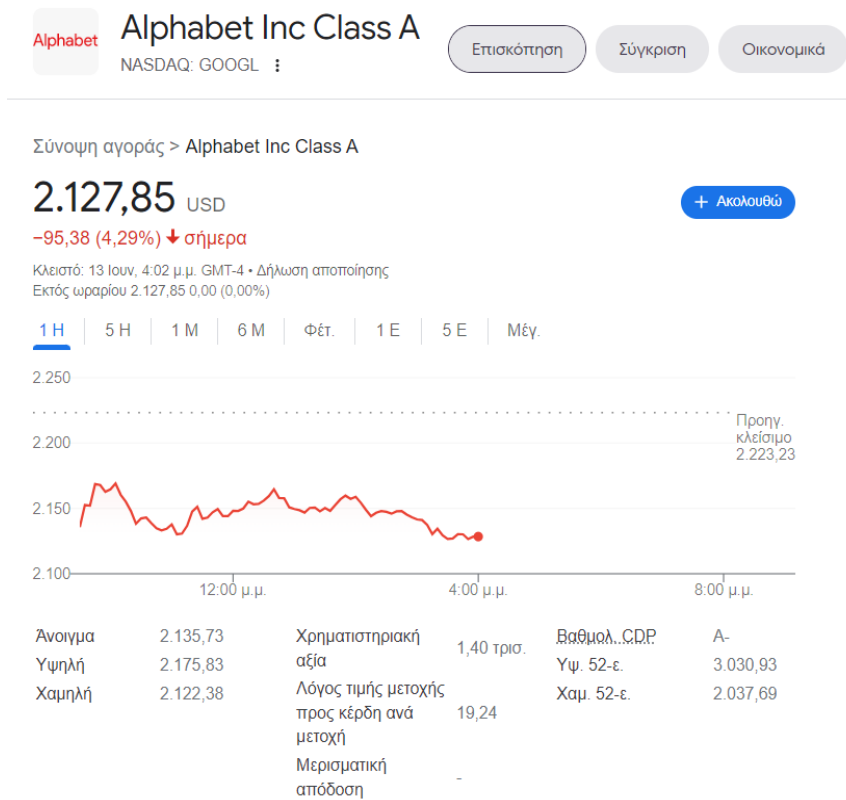
Run: main x
79/79 [=====] - 3s 44ms/step - loss: 8.9174e-04
Epoch 23/25
79/79 [=====] - 4s 44ms/step - loss: 0.0010
Epoch 24/25
79/79 [=====] - 3s 44ms/step - loss: 0.0010
Epoch 25/25
79/79 [=====] - 4s 45ms/step - loss: 8.7806e-04
Prediction: [[2165.2253]]

Process finished with exit code 0
    
```

Εικόνα 80: Πρόβλεψη Τιμής Μετοχής Google (Πρώτη Ημέρα)



Εικόνα 81: Διάγραμμα Μετοχής Google (Πρώτη Ημέρα)



Εικόνα 82: Τιμή Κλεισίματος Μετοχής Google (Πρώτη Ημέρα)

Οι εικόνες 80 και 81 παρουσιάζουν την πρόβλεψη τιμής μετοχής της Google την πρώτη ημέρα. Η πρόβλεψη της μετοχής πραγματοποιήθηκε στις 10 Ιουνίου 2022 και επιδιώκει να προβλέψει την τιμή κλεισίματος της μετοχής στις 13 Ιουνίου 2022. Από τις εικόνες προβλέπεται ότι η μετοχή της Google θα κλείσει στην τιμή των 2165,2253 δολαρίων. Στην εικόνα 82 παρατηρούμε ότι η μετοχή της Google έκλεισε στην τιμή των 2127,85 δολαρίων. Από τα παραπάνω στοιχεία φαίνεται ότι η πρόβλεψη της τιμής της μετοχής με την τιμή που είχε η μετοχή κατά το κλείσιμο εμφανίζει μια μικρή απόκλιση της τάξης των 37,3753 δολαρίων προς τα κάτω.

Δεύτερη Ημέρα


```

Run: main x
79/79 [=====] - 3s 44ms/step - loss: 8.2440e-04
Epoch 23/25
79/79 [=====] - 3s 44ms/step - loss: 8.5479e-04
Epoch 24/25
79/79 [=====] - 4s 45ms/step - loss: 0.0010
Epoch 25/25
79/79 [=====] - 3s 44ms/step - loss: 6.7895e-04
Prediction: [[2147.4683]]

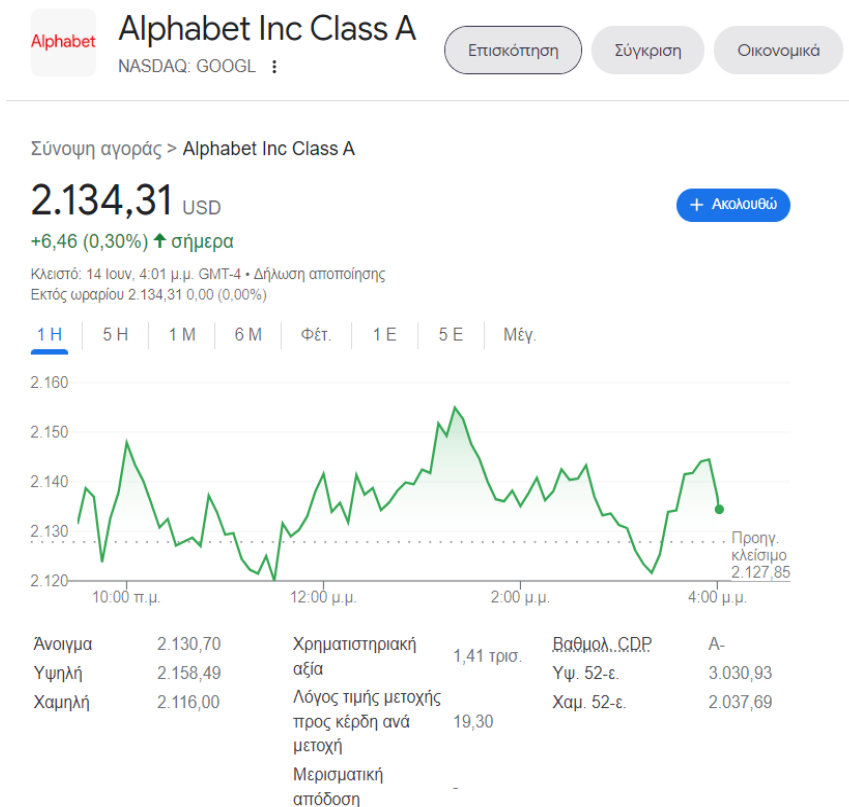
Process finished with exit code 0

```

Εικόνα 83: Πρόβλεψη Τιμής Μετοχής Google (Δεύτερη Ημέρα)



Εικόνα 84: Διάγραμμα Μετοχής Google (Δεύτερη Ημέρα)



Εικόνα 85: Τιμή Κλεισίματος Μετοχής Google (Δεύτερη Ημέρα)

Οι εικόνες 83 και 84 παρουσιάζουν την πρόβλεψη τιμής μετοχής της Google την δεύτερη ημέρα. Η πρόβλεψη της μετοχής πραγματοποιήθηκε στις 13 Ιουνίου 2022 και επιδιώκει να προβλέψει την τιμή κλεισίματος της μετοχής στις 14 Ιουνίου 2022. Από τις εικόνες προβλέπεται ότι η μετοχή της Google θα κλείσει στην τιμή των 2147,4683 δολαρίων. Στην εικόνα 85 παρατηρούμε ότι η μετοχή της Google έκλεισε στην τιμή των 2134,31 δολαρίων. Από τα παραπάνω στοιχεία φαίνεται ότι η πρόβλεψη της τιμής της μετοχής με την τιμή που είχε η μετοχή κατά το κλείσιμο εμφανίζει μια μικρή απόκλιση της τάξης των 13,1583 δολαρίων προς τα κάτω.

Τρίτη Ημέρα


```

Run: main x
79/79 [=====] - 3s 44ms/step - loss: 8.8992e-04
Epoch 23/25
79/79 [=====] - 4s 44ms/step - loss: 8.3391e-04
Epoch 24/25
79/79 [=====] - 4s 45ms/step - loss: 7.3534e-04
Epoch 25/25
79/79 [=====] - 3s 44ms/step - loss: 8.9682e-04
Prediction: [[2206.0251]]

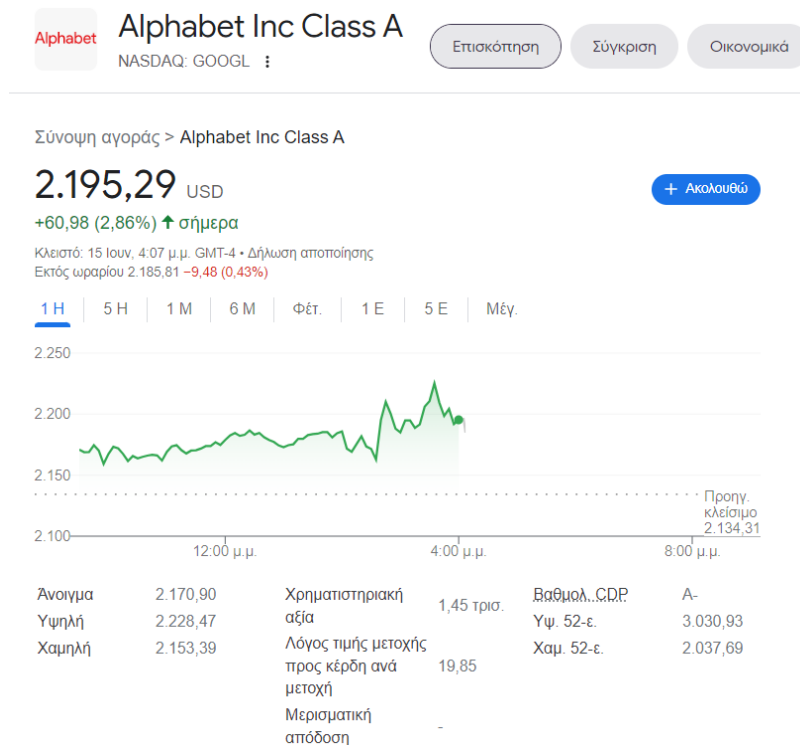
Process finished with exit code 0

```

Εικόνα 86: Πρόβλεψη Τιμής Μετοχής Google (Τρίτη Ημέρα)



Εικόνα 87: Διάγραμμα Μετοχής Google (Τρίτη Ημέρα)



Εικόνα 88: Τιμή Κλεισίματος Μετοχής Google (Τρίτη Ημέρα)

Οι εικόνες 86 και 87 παρουσιάζουν την πρόβλεψη τιμής μετοχής της Google την τρίτη ημέρα. Η πρόβλεψη της μετοχής πραγματοποιήθηκε στις 14 Ιουνίου 2022 και επιδιώκει να προβλέψει την τιμή κλεισίματος της μετοχής στις 15 Ιουνίου 2022. Από τις εικόνες προβλέπεται ότι η μετοχή της Google θα κλείσει στην τιμή των 2206,0251 δολαρίων. Στην εικόνα 88 παρατηρούμε ότι η μετοχή της Google έκλεισε στην τιμή των 2195,29 δολαρίων. Από τα παραπάνω στοιχεία φαίνεται ότι η πρόβλεψη της τιμής της μετοχής με την τιμή που είχε η μετοχή κατά το κλείσιμο εμφανίζει μια μικρή απόκλιση της τάξης των 10,7351 δολαρίων προς τα κάτω.

Τέταρτη Ημέρα


```

Run: main x
79/79 [=====] - 4s 46ms/step - loss: 8.3418e-04
Epoch 23/25
79/79 [=====] - 4s 46ms/step - loss: 8.4817e-04
Epoch 24/25
79/79 [=====] - 4s 46ms/step - loss: 8.2123e-04
Epoch 25/25
79/79 [=====] - 4s 45ms/step - loss: 9.5585e-04
Prediction: [[2134.0728]]

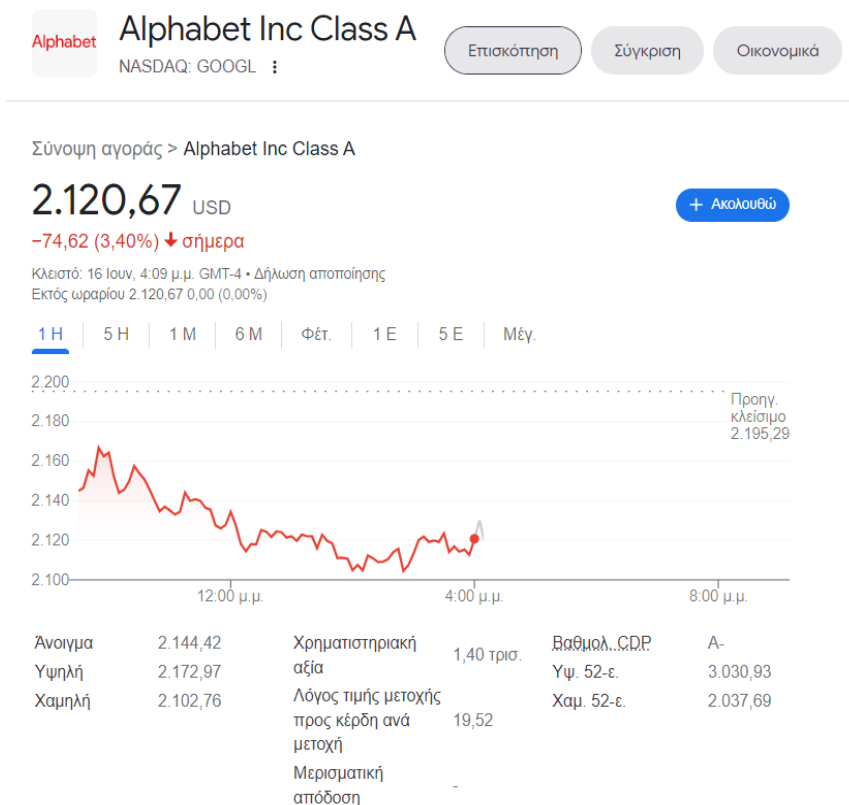
Process finished with exit code 0

```

Εικόνα 89: Πρόβλεψη Τιμής Μετοχής Google (Τέταρτη Ημέρα)



Εικόνα 90: Διάγραμμα Μετοχής Google (Τέταρτη Ημέρα)



Εικόνα 91: Τιμή Κλεισίματος Μετοχής Google (Τέταρτη Ημέρα)

Οι εικόνες 89 και 90 παρουσιάζουν την πρόβλεψη τιμής μετοχής της Google την τέταρτη ημέρα. Η πρόβλεψη της μετοχής πραγματοποιήθηκε στις 15 Ιουνίου 2022 και επιδιώκει να προβλέψει την τιμή κλεισίματος της μετοχής στις 16 Ιουνίου 2022. Από τις εικόνες προβλέπεται ότι η μετοχή της Google θα κλείσει στην τιμή των 2134,0728 δολαρίων. Στην εικόνα 91 παρατηρούμε ότι η μετοχή της Google έκλεισε στην τιμή των 2120,67 δολαρίων. Από τα παραπάνω στοιχεία φαίνεται ότι η πρόβλεψη της τιμής της μετοχής με την τιμή που είχε η μετοχή κατά το κλείσιμο εμφανίζει μια μικρή απόκλιση της τάξης των 13,4028 δολαρίων προς τα κάτω.

Πέμπτη Ημέρα


```

Run: main x
79/79 [=====] - 4s 45ms/step - loss: 8.2012e-04
Epoch 23/25
79/79 [=====] - 4s 45ms/step - loss: 8.1090e-04
Epoch 24/25
79/79 [=====] - 4s 46ms/step - loss: 8.1559e-04
Epoch 25/25
79/79 [=====] - 4s 46ms/step - loss: 8.4976e-04
Prediction: [[2144.9805]]

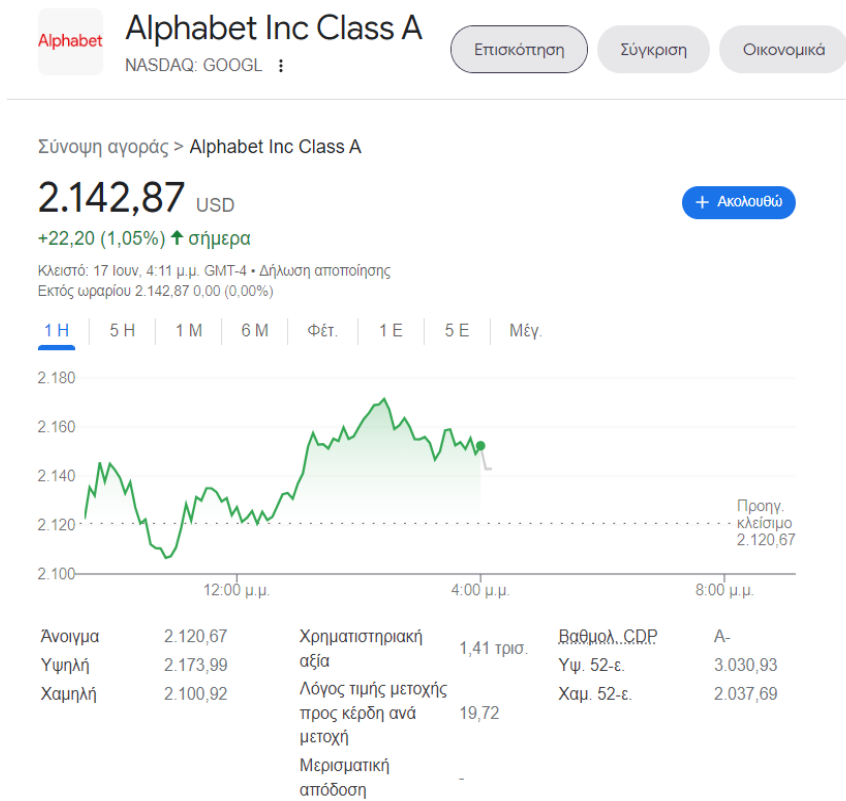
Process finished with exit code 0

```

Εικόνα 92: Πρόβλεψη Τιμής Μετοχής Google (Πέμπτη Ημέρα)



Εικόνα 93: Διάγραμμα Μετοχής Google (Πέμπτη Ημέρα)



Εικόνα 94: Τιμή Κλεισίματος Μετοχής Google (Πέμπτη Ημέρα)

Οι εικόνες 92 και 93 παρουσιάζουν την πρόβλεψη τιμής μετοχής της Google την πέμπτη ημέρα. Η πρόβλεψη της μετοχής πραγματοποιήθηκε στις 16 Ιουνίου 2022 και επιδιώκει να προβλέψει την τιμή κλεισίματος της μετοχής στις 17 Ιουνίου 2022. Από τις εικόνες προβλέπεται ότι η μετοχή της Google θα κλείσει στην τιμή των 2144,9805 δολαρίων. Στην εικόνα 94 παρατηρούμε ότι η μετοχή της Google έκλεισε στην τιμή των 2142,87 δολαρίων. Από τα παραπάνω στοιχεία φαίνεται ότι η πρόβλεψη της τιμής της μετοχής με την τιμή που είχε η μετοχή κατά το κλείσιμο εμφανίζει μια μικρή απόκλιση της τάξης των 2,1105 δολαρίων προς τα κάτω.


Κεφάλαιο 7ο: Ανάλυση Αποτελεσμάτων από την Πρόβλεψη Τιμών Μετοχών

7.1 Ανάλυση Αποτελεσμάτων Μετοχής: Apple

Από τα δεδομένα που μελετήθηκαν στα πλαίσια της παρούσας έρευνας οδηγούμαστε στην εξαγωγή ορισμένων πολύ χρήσιμων στοιχείων αναφορικά με την μετοχή της Apple. Πιο αναλυτικά, από την πρόβλεψη της τιμής της μετοχής της Apple η οποία πραγματοποιήθηκε για πέντε συνεχόμενες ημέρες παρατηρείται ότι οι αποκλίσεις που προκύπτουν κυμαίνονται σε χαμηλά επίπεδα.

Η μεγαλύτερη απόκλιση σημειώθηκε την πρώτη ημέρα, καθώς η τιμή της μετοχής προβλέφθηκε ότι θα είναι 138,0113 δολάρια, ενώ η μετοχή έκλεισε στην τιμή των 131,88 δολαρίων, εμφανίζοντας απόκλιση της τάξεως των 6,1313 δολαρίων προς τα κάτω. Ωστόσο, την πέμπτη ημέρα η τιμή της μετοχής προβλέφθηκε ότι θα είναι 131,27911 δολάρια, ενώ η μετοχή έκλεισε στην τιμή των 131,56 δολαρίων, εμφανίζοντας μια απόκλιση της τάξεως των 0,28089 δολαρίων προς τα πάνω αυτή τη φορά.

Τέλος, είναι σημαντικό να αναφερθεί ότι τη δεύτερη, τρίτη και τέταρτη ημέρα η πρόβλεψη τιμής της μετοχής με την αντίστοιχη τιμή κλεισίματος δεν εμφανίζει μεγάλες αποκλίσεις γεγονός που καθιστά την πρόβλεψη αρκετά ασφαλή.




Εικόνα 95: Συγκεντρωτικό γράφημα πέντε ημερών μετοχής Apple

7.2 Ανάλυση Αποτελεσμάτων Μετοχής: Facebook

Με βάση τα δεδομένα που μελετήθηκαν από την ερευνητική διαδικασία οδηγούμαστε στην εξαγωγή κάποιων στοιχείων αναφορικά με την μετοχή του Facebook.

Συγκεκριμένα, από την πρόβλεψη της τιμής της μετοχής του Facebook η οποία πραγματοποιήθηκε για πέντε συνεχόμενες ημέρες παρατηρείται ότι οι αποκλίσεις που προκύπτουν κυμαίνονται σε χαμηλά επίπεδα. Η μεγαλύτερη απόκλιση σημειώθηκε την τέταρτη ημέρα καθώς η τιμή της μετοχής προβλέφθηκε ότι θα είναι 168,70924 δολάρια, ενώ η μετοχή έκλεισε στην τιμή των 160,87 δολαρίων εμφανίζοντας απόκλιση της τάξεως των 7,8392 δολαρίων προς τα κάτω. Η δεύτερη μεγαλύτερη απόκλιση παρατηρήθηκε την πρώτη ημέρα καθώς η τιμή της μετοχής προβλέφθηκε ότι 170,48941 δολάρια, ενώ η μετοχή έκλεισε στην τιμή των 164,26 δολαρίων εμφανίζοντας απόκλιση της τάξεως των 6,2294 δολαρίων προς τα κάτω.

Τέλος, είναι σημαντικό να αναφερθεί ότι τη δεύτερη, τρίτη και την πέμπτη ημέρα η πρόβλεψη τιμής της μετοχής με την αντίστοιχη τιμή κλεισίματος δεν εμφανίζει μεγάλες αποκλίσεις γεγονός που καθιστά την πρόβλεψη αρκετά ασφαλή.




Εικόνα 96: Συγκεντρωτικό γράφημα πέντε ημερών μετοχής Facebook

7.3 Ανάλυση Αποτελεσμάτων Μετοχής: Microsoft

Σύμφωνα με τα δεδομένα που μελετήθηκαν κατά την έρευνα προκύπτουν κάποια ιδιαίτερα χρήσιμα στοιχεία για τη μετοχή της Microsoft. Πιο συγκεκριμένα, από την πρόβλεψη της τιμής της μετοχής της Microsoft η οποία πραγματοποιήθηκε για πέντε συνεχόμενες ημέρες παρατηρείται ότι οι αποκλίσεις που προκύπτουν κυμαίνονται σε χαμηλά επίπεδα. Η μεγαλύτερη απόκλιση σημειώθηκε την πρώτη ημέρα καθώς η τιμή της μετοχής προβλέφθηκε ότι θα είναι 249,01814 δολάρια, ενώ η μετοχή έκλεισε στην τιμή των 242,26 δολαρίων εμφανίζοντας απόκλιση της τάξεως των 6,7581 δολαρίων προς τα κάτω. Η δεύτερη μεγαλύτερη απόκλιση παρατηρήθηκε την τέταρτη ημέρα καθώς η τιμή της μετοχής προβλέφθηκε ότι θα είναι 239,36844 δολάρια, ενώ η μετοχή έκλεισε στην τιμή των 244,97 δολαρίων εμφανίζοντας απόκλιση της τάξεως των 5,6015 δολαρίων προς τα πάνω.

Τέλος, είναι σημαντικό να αναφερθεί ότι τη δεύτερη, τρίτη και την πέμπτη ημέρα η πρόβλεψη τιμής της μετοχής με την αντίστοιχη τιμή κλεισίματος δεν εμφανίζει μεγάλες αποκλίσεις γεγονός που καθιστά την πρόβλεψη αρκετά ασφαλή.




Εικόνα 97: Συγκεντρωτικό γράφημα πέντε ημερών μετοχής Microsoft

7.4 Ανάλυση Αποτελεσμάτων Μετοχής: Tesla

Τα δεδομένα που προκύπτουν από την έρευνα εμφανίζουν μία σειρά πολύ σημαντικών στοιχείων σε σχέση με τη μετοχή της Tesla. Πιο αναλυτικά, από την πρόβλεψη της τιμής της μετοχής της Tesla η οποία πραγματοποιήθηκε για πέντε συνεχόμενες ημέρες παρατηρείται ότι οι αποκλίσεις που προκύπτουν κυμαίνονται σε χαμηλά επίπεδα. Η μεγαλύτερη απόκλιση σημειώθηκε την τέταρτη ημέρα καθώς η τιμή της μετοχής προβλέφθηκε ότι θα 647,5302 δολάρια, ενώ η μετοχή έκλεισε στην τιμή των 639,30 δολαρίων εμφανίζοντας απόκλιση της τάξεως των 8,2302 δολαρίων προς τα κάτω.

Ωστόσο, τη δεύτερη ημέρα η τιμή της μετοχής προβλέφθηκε ότι θα είναι 664,9443 δολάρια, ενώ η μετοχή έκλεισε στην τιμή των 662,67 δολαρίων, εμφανίζοντας μια μικρή απόκλιση της τάξεως των 2,2743 δολαρίων προς τα κάτω.

Τέλος, είναι σημαντικό να αναφερθεί ότι την πρώτη, τρίτη και πέμπτη ημέρα η πρόβλεψη τιμής της μετοχής με την αντίστοιχη τιμή κλεισίματος δεν εμφανίζει μεγάλες αποκλίσεις γεγονός που καθιστά την πρόβλεψη αρκετά ασφαλή.




Εικόνα 98: Συγκενρωτικό γράφημα πέντε ημερών μετοχής Tesla

7.5 Ανάλυση Αποτελεσμάτων Μετοχής: Google

Σύμφωνα με τα δεδομένα που μελετήθηκαν στα πλαίσια της παρούσας έρευνας οδηγούμαστε στην εξαγωγή ορισμένων πολύ σημαντικών στοιχείων αναφορικά με την μετοχή της Google. Πιο αναλυτικά, από την πρόβλεψη της τιμής της μετοχής της Google η οποία πραγματοποιήθηκε για πέντε συνεχόμενες ημέρες παρατηρείται ότι οι αποκλίσεις που προκύπτουν κυμαίνονται σε χαμηλά επίπεδα. Η μεγαλύτερη απόκλιση σημειώθηκε την πρώτη ημέρα καθώς η τιμή της μετοχής προβλέφθηκε ότι θα είναι 2165,2253 δολάρια, ενώ η μετοχή έκλεισε στην τιμή των 2127,85 δολαρίων εμφανίζοντας απόκλιση της τάξεως των 37,3753 δολαρίων προς τα κάτω.

Ωστόσο, την πέμπτη ημέρα η τιμή της μετοχής προβλέφθηκε ότι θα είναι στην 2144,9805 δολάρια, ενώ η μετοχή έκλεισε στην τιμή των 2142,87 δολαρίων, εμφανίζοντας μια μικρή απόκλιση της τάξεως των 2,1105 δολαρίων προς τα κάτω.

Τέλος, είναι σημαντικό να αναφερθεί ότι τη δεύτερη, τρίτη και τέταρτη ημέρα η πρόβλεψη τιμής της μετοχής με την αντίστοιχη τιμή κλεισίματος δεν εμφανίζει μεγάλες αποκλίσεις γεγονός που καθιστά την πρόβλεψη αρκετά ασφαλή.



Εικόνα 99: Συγκεντρωτικό γράφημα πέντε ημερών μετοχής Tesla

Συμπεράσματα

Μέσα από τη συγγραφή της θεωρίας, καθώς και την ερευνητική διαδικασία προκύπτουν ορισμένα συμπεράσματα τα οποία είναι αρκετά χρήσιμο να αναφερθούν. Αρχικά, διαπιστώθηκε η ανάγκη αξιοποίησης της τεχνητής νοημοσύνης στον οικονομικό κλάδο. Συγκεκριμένα, από την χρήση της μηχανικής μάθησης μπορούν να εξαχθούν δεδομένα, τα οποία βοηθούν στην καλύτερη λήψη μίας απόφασης οικονομικής φύσεως. Με τον τρόπο αυτό μπορεί να μειωθεί το ποσοστό ρίσκου και να ελαχιστοποιηθεί ο κίνδυνος για μία λάθος απόφαση, η οποία θα έχει οικονομικές συνέπειες.

Ακόμα, η μηχανική μάθηση βοηθά στο σχεδιασμό εφαρμογών, οι οποίες αντλώντας δεδομένα μπορούν να προσφέρουν στο χρήστη πληροφορίες που θα τον βοηθήσουν να αποκτήσει μία πιο σφαιρική εικόνα για το αντικείμενο που μελετά. Η παραπάνω συνθήκη φαίνεται να πραγματοποιείται και από την ερευνητική διαδικασία της παρούσας εργασίας. Συγκεκριμένα, το πρόγραμμα αφού πρώτα λάμβανε στοιχεία από την πορεία της εκάστοτε μετοχής, τα ανέλυε και στο τέλος προσπαθούσε να προβλέψει την τιμή με την οποία θα έκλεινε την επόμενη ημέρα η μετοχή που ερευνούσε κάθε φορά.

Τέλος, αξίζει να σημειωθεί ότι η τεχνητή νοημοσύνη εκτός από τον οικονομικό κλάδο μπορεί να προσφέρει σημαντική βοήθεια και σε άλλες επιστήμες. Έτσι, μέσα από την κατάλληλη χρήση της τεχνητής νοημοσύνης μπορούν να καταπολεμηθούν ζητήματα που απασχολούν εδώ και χρόνια την ανθρωπότητα. Επιπλέον, μπορούν να αντιμετωπιστούν προβλήματα, τα οποία είναι δύσκολό να επιλυθούν με κάποιο άλλο τρόπο.

Προτάσεις για Μελλοντική Έρευνα

Η ολοκλήρωση της παρούσας εργασίας οδηγεί στην εξαγωγή πολύ σημαντικών στοιχείων. Από τα στοιχεία αυτά προκύπτει η ανάγκη για τη διεξαγωγή νέων ερευνών, οι οποίες θα συμβάλλουν καθοριστικά στην εξέλιξη του θέματος που μελετήθηκε. Αρχικά, θα μπορούσαν να πραγματοποιηθούν έρευνες που θα εξετάζουν την πρόβλεψη τιμών για άλλες μετοχές πέρα από αυτές που μελετήθηκαν σε αυτή την εργασία.

Ακόμα, θα είχε ενδιαφέρον να μελετηθούν μετοχές σε μεγαλύτερο βάθος χρόνου με σκοπό να προκύψουν πιο ασφαλή δεδομένα. Πιο αναλυτικά, η έρευνα που πραγματοποιήθηκε εξέτασε τις μετοχές που επιλέχθηκαν για πέντε συνεχόμενες ημέρες με σκοπό να προβλέψει την τιμή τους. Σε άλλη μελέτη θα μπορούσαν να εξεταστούν κάποιες μετοχές για περισσότερο χρονικό διάστημα. Έτσι, τα δεδομένα που θα προκύψουν θα είναι περισσότερα, γεγονός που θα οδηγήσει τον ερευνητή στην εξαγωγή πιο ασφαλών συμπερασμάτων.

Επίσης, και ο αριθμός των μετοχών που μελετώνται θα μπορούσε να αποτελέσει μία παράμετρο αλλαγής για μελλοντικές έρευνες. Συγκεκριμένα, η έρευνα που πραγματοποιήθηκε εξέτασε τις τιμές πέντε διαφορετικών μετοχών. Σε άλλες μελέτες θα μπορούσαν να ερευνηθούν περισσότερες μετοχές, με στόχο την άντληση περισσότερων πληροφοριών.

Τέλος, θα ήταν χρήσιμο να μελετηθούν μετοχές που ανήκουν στο ίδιο πεδίο περιεχομένου. Για παράδειγμα, θα μπορούσαν να εξεταστούν μετοχές που ανήκουν στον ίδιο κλάδο (π.χ. τηλεπικοινωνίες, εταιρείες παραγωγής αυτοκινήτων κ.ά.), με σκοπό αρχικά την πρόβλεψη και στη συνέχεια τη σύγκριση των τιμών που εμφανίζουν μεταξύ τους.

Βιβλιογραφία

- Alpaydin, E. (2020). *Introduction to machine learning*. MIT press.
- Alshawi, H. (Ed.). (1992). *The core language engine*. MIT press.
- Alzubi, J., Nayyar, A., & Kumar, A. (2018, November). Machine learning from theory to algorithms: an overview. In *Journal of physics: conference series* (Vol. 1142, No. 1, p. 012012). IOP Publishing.
- Ashraf, M., Abourezka, M. A., & Maghraby, F. A. (2022). A Comparative Analysis of Credit Card Fraud Detection Using Machine Learning and Deep Learning Techniques. In *Digital Transformation Technology* (pp. 267-282). Springer, Singapore.
- Azhan, M., & Meraj, S. (2020, December). Credit card fraud detection using machine learning and deep learning techniques. In *2020 3rd International Conference on Intelligent Sustainable Systems (ICISS)* (pp. 514-518). IEEE.
- Bahja, M. (2020). Natural language processing applications in business. In *E-Business-Higher Education and Intelligence Applications*. IntechOpen.
- Bhbosale, S., Pujari, V., & Multani, Z. (2020). Advantages And Disadvantages Of Artificial Intelligence. *Aayushi International Interdisciplinary Research Journal*, 227-230.
- Blömer, J., Lammersen, C., Schmidt, M., & Sohler, C. (2016). Theoretical analysis of the k-means algorithm—a survey. In *Algorithm Engineering* (pp. 81-116). Springer, Cham.
- Boguraev, B., & Briscoe, T. (1987). Large lexicons for natural language processing: utilising the grammar coding system of LDOCE. *Computational Linguistics*, 13, 203-218.
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.
- Buchanan, B. G. (2005). A (very) brief history of artificial intelligence. *Ai Magazine*, 26(4), 53-53.
- Chen, T., & Guestrin, C. (2016, August). Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining* (pp. 785-794).
- Chopra, A., Prashar, A., & Sain, C. (2013). Natural language processing. *International journal of technology enhancements and emerging engineering research*, 1(4), 131-134.
- Ertel, W. (2018). *Introduction to artificial intelligence*. Springer.
- Fahner, G. (2018). Developing transparent credit risk scorecards more effectively: An explainable artificial intelligence approach. *Data Anal*, 2018, 17.
- Green Jr, B. F., Wolf, A. K., Chomsky, C., & Laughery, K. (1961, May). Baseball: an automatic question-answerer. In *Papers presented at the May 9-11, 1961, western joint IRE-AIEE-ACM computer conference* (pp. 219-224).
- Gudise, V. G., & Venayagamoorthy, G. K. (2003, April). Comparison of particle swarm optimization and backpropagation as training algorithms for neural networks. In *Proceedings of the 2003 IEEE Swarm Intelligence Symposium. SIS'03 (Cat. No. 03EX706)* (pp. 110-117). IEEE.
- Haenlein, M., & Kaplan, A. (2019). A brief history of artificial intelligence: On the past, present, and future of artificial intelligence. *California management review*, 61(4), 5-14.
- Hendrix, G. G., Sacerdoti, E. D., Sagalowicz, D., & Slocum, J. (1978). Developing a natural language interface to complex data. *ACM Transactions on Database Systems (TODS)*, 3(2), 105-147.
- Johri, P., Khatri, S. K., Al-Taani, A. T., Sabharwal, M., Suvanov, S., & Kumar, A. (2021). Natural Language Processing: History, Evolution, Application, and Future Work. In *Proceedings of 3rd International Conference on Computing Informatics and Networks* (pp. 365-375). Springer, Singapore.
- Jones, K. S. (2001). Automatic language and information processing: rethinking evaluation. *Natural Language Engineering*, 7(1), 29-46.
- Kalyanathaya, K. P., Akila, D., & Rajesh, P. (2019). Advances in natural language processing—a survey of current research trends, development tools and industry applications. *International Journal of Recent Technology and Engineering*, 7(5C), 199-202.
- Khurana, D., Koli, A., Khatter, K., & Singh, S. (2017). Natural language processing: State of the art, current trends and challenges. *arXiv preprint arXiv:1708.05148*.

- Kijsipongse, E., & Suriya, U. (2012, May). Dynamic load balancing on GPU clusters for large-scale K-Means clustering. In *2012 Ninth International Conference on Computer Science and Software Engineering (JCSSE)* (pp. 346-350). IEEE.
- Langley, P. (1996). *Elements of machine learning*. Morgan Kaufmann.
- Lea, W. A. (1980). *Trends in speech recognition*. Prentice Hall PTR.
- Liakos, K. G., Busato, P., Moshou, D., Pearson, S., & Bochtis, D. (2018). Machine learning in agriculture: A review. *Sensors*, *18*(8), 2674.
- Liddy, E. D. (2001). Natural language processing.
- Ma, X., & Dhavala, S. (2018). Hierarchical clustering with prior knowledge. *arXiv preprint arXiv:1806.03432*.
- Maulud, D. H., Ameen, S. Y., Omar, N., Kak, S. F., Rashid, Z. N., Yasin, H. M., ... & Ahmed, D. M. (2021). Review on natural language processing based on different techniques. *Asian Journal of Research in Computer Science*, 1-17.
- McCarthy, J. (2007). What is artificial intelligence?.
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, *5*(4), 115-133.
- Molnar, C., Casalicchio, G., & Bischl, B. (2020, September). Interpretable machine learning—a brief history, state-of-the-art and challenges. In *Joint European Conference on Machine Learning and Knowledge Discovery in Databases* (pp. 417-431). Springer, Cham.
- Mountassir, A., Benbrahim, H., & Berrada, I. (2012, October). An empirical study to address the problem of unbalanced data sets in sentiment classification. In *2012 IEEE international conference on systems, man, and cybernetics (SMC)* (pp. 3298-3303). IEEE.
- Murphey, Y. L., Guo, H., & Feldkamp, L. A. (2004). Neural learning from unbalanced data. *Applied Intelligence*, *21*(2), 117-128.
- Murtagh, F., & Contreras, P. (2012). Algorithms for hierarchical clustering: an overview. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, *2*(1), 86-97.
- Nichkasova, Y., & Shmarlouskaya, H. (2020). Financial technologies as a driving force for business model transformation in the banking sector. *International Journal of Business and Globalisation*, *25*(4), 419-447.
- Nikou, M., Mansourfar, G., & Bagherzadeh, J. (2019). Stock price prediction using DEEP learning algorithm and its comparison with machine learning algorithms. *Intelligent Systems in Accounting, Finance and Management*, *26*(4), 164-174.
- Oyelade, O. J., Oladipupo, O. O., & Obagbuwa, I. C. (2010). Application of k Means Clustering algorithm for prediction of Students Academic Performance. *arXiv preprint arXiv:1002.2425*.
- Padmaja, T. M., Dhulipalla, N., Bapi, R. S., & Krishna, P. R. (2007, December). Unbalanced data classification using extreme outlier elimination and sampling techniques for fraud detection. In *15th International Conference on Advanced Computing and Communications (ADCOM 2007)* (pp. 511-516). IEEE.
- PK, F. A. (1984). What is Artificial Intelligence?. "Success is no accident. It is hard work, perseverance, learning, studying, sacrifice and most of all, love of what you are doing or learning to do"., 65.
- Reshamwala, A., Mishra, D., & Pawar, P. (2013). Review on natural language processing. *IRACST Engineering Science and Technology: An International Journal (ESTIJ)*, *3*(1), 113-116.
- Shah, V. H. (2007). Machine learning techniques for stock prediction. *Foundations of Machine Learning| Spring*, *1*(1), 6-12.
- Sharma, S., Sharma, S., & Athaiya, A. (2017). Activation functions in neural networks. *towards data science*, *6*(12), 310-316.
- Shukla, S., & Naganna, S. (2014). A review on K-means data clustering approach. *International Journal of Information and Computation Technology*, *4*(17), 1847-1860.
- Soni, P., Tewari, Y., & Krishnan, D. (2022). Machine Learning Approaches in Stock Price Prediction: A Systematic Review. In *Journal of Physics: Conference Series* (Vol. 2161, No. 1, p. 012065). IOP Publishing.

- Sun, S., Luo, C., & Chen, J. (2017). A review of natural language processing techniques for opinion mining systems. *Information fusion*, 36, 10-25.
- Sundheim, B. M., & Chinchor, N. (1993). Survey of the message understanding conferences. In *Human Language Technology: Proceedings of a Workshop Held at Plainsboro, New Jersey, March 21-24, 1993*.
- Tenhagen, B. A., Drillich, M., Surholt, R., & Heuwieser, W. (2004). Comparison of timed AI after synchronized ovulation to AI at estrus: Reproductive and economic considerations. *Journal of Dairy Science*, 87(1), 85-94.
- Thakkar, A., & Chaudhari, K. (2021). Fusion in stock market prediction: a decade survey on the necessity, recent developments, and potential future directions. *Information Fusion*, 65, 95-107.
- Thorne, R. (2017). Artificial intelligence and machine learning in financial services.
- Tsai, C. F., & Wang, S. P. (2009, March). Stock price forecasting by hybrid machine learning techniques. In *Proceedings of the international multiconference of engineers and computer scientists* (Vol. 1, No. 755, p. 60).
- Vijh, M., Chandola, D., Tikkiwal, V. A., & Kumar, A. (2020). Stock closing price prediction using machine learning techniques. *Procedia computer science*, 167, 599-606.
- Werbos, P. J. (1994). *The roots of backpropagation: from ordered derivatives to neural networks and political forecasting* (Vol. 1). John Wiley & Sons.
- Woods, W. A. (1978). Semantics and quantification in natural language question answering. In *Advances in computers* (Vol. 17, pp. 1-87). Elsevier.
- Yi, J., Nasukawa, T., Bunescu, R., & Niblack, W. (2003, November). Sentiment analyzer: Extracting sentiments about a given topic using natural language processing techniques. In *Third IEEE international conference on data mining* (pp. 427-434). IEEE.
- Young, S. J., & Chase, L. L. (1998). Speech recognition evaluation: a review of the US CSR and LVCSR programmes. *Computer Speech & Language*, 12(4), 263-279.
- Zaccone, G., & Karim, M. R. (2018). *Deep learning with tensorflow: Explore neural networks and build intelligent systems with python*. Packt Publishing Ltd.