



*Εθνικό Μετσόβιο Πολυτεχνείο
Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών
Τομέας Διοίκησης Πληροφοριακών Συστημάτων*

***Αναδρομικά νευρωνικά δίκτυα για πρόβλεψη
χρηματιστηριακών μεγεθών***

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΤΟΥ

Καρλή Βασίλειου

Επιβλέπων: Γρηγόρης Μέντζας

Καθηγητής Ε.Μ.Π.

Αθήνα, Μάρτιος 2021



*Εθνικό Μετσόβιο Πολυτεχνείο
Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών
Υπολογιστών
Τομέας Διοίκησης Πληροφοριακών Συστημάτων*

***Αναδρομικά νευρωνικά δίκτυα για πρόβλεψη
χρηματιστηριακών μεγεθών***

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

του

Καρλή Βασίλειου

Επιβλέπων: Γρηγόρης Μέντζας

Καθηγητής Ε.Μ.Π.

Εγκρίθηκε από την τριμελή επιτροπή τη 18^η Μαρτίου

.....
Γρηγόρης Μέντζας

Καθηγητής Ε.Μ.Π.

.....
Δημήτριος Ασκούνης

Καθηγητής Ε.Μ.Π.

.....
Ιωάννης Ψαράς

Καθηγητής Ε.Μ.Π.

Αθήνα, Μάρτιος 2021

.....
ΚΑΡΛΗΣ ΒΑΣΙΛΕΙΟΣ

Διπλωματούχος Ηλεκτρολόγος Μηχανικός και Μηχανικός Υπολογιστών Ε.Μ.Π.

Copyright © Βασίλειος Καρλής, 2021.

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας, εξ ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για σκοπό μη κερδοσκοπικό, εκπαιδευτικής ή ερευνητικής φύσης, υπό την προϋπόθεση να αναφέρεται η πηγή προέλευσης και να διατηρείται το παρόν μήνυμα. Ερωτήματα που αφορούν τη χρήση της εργασίας για κερδοσκοπικό σκοπό πρέπει να απευθύνονται προς τον συγγραφέα. Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον συγγραφέα και δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις επίσημες θέσεις του Εθνικού Μετσόβιου Πολυτεχνείου.

Περίληψη

Οι προβλέψεις χρηματιστηριακών μεγεθών διαχρονικά προσελκύουν το ενδιαφέρον των επενδυτών και των ερευνητών, την στιγμή που η βαθιά μηχανική μάθηση διαμορφώνει την πιο πολλά υποσχόμενη κατηγορία σχετικών αλγορίθμων. Το αντικείμενο αυτής της διπλωματικής είναι η εφαρμογή και μελέτη της βαθιάς μηχανικής μάθησης και συγκεκριμένα των αναδρομικών νευρωνικών δικτύων μακράς και βραχείας μνήμης (Long Short-term Memory- LSTM), για την πραγματοποίηση βραχυπρόθεσμων χρηματιστηριακών προβλέψεων. Η βαθιά μηχανική μάθηση αποτελεί μια πολλά υποσχόμενη κατηγορία τεχνικής ανάλυσης και ειδικότερα τα LSTM είναι πολύ αποτελεσματικά για την μελέτη χρονοσειρών. Στα πλαίσια αυτής της διπλωματικής λοιπόν, υλοποιούνται χρηματιστηριακές προβλέψεις για μεγάλες τεχνολογικές εταιρείες και μελετώνται οι παράγοντες που επηρεάζουν την απόδοσή τους. Αναδεικνύεται η δυνατότητα του LSTM να αντιλαμβάνεται τις εξαρτήσεις των χρηματιστηριακών δεδομένων και να πραγματοποιεί αποτελεσματικές προβλέψεις. Ακόμη, γίνεται σαφής η σημασία της κατάλληλης ρύθμισης των παραμέτρων του νευρωνικού δικτύου και στην συνέχεια της κατάλληλης επιλογής χαρακτηριστικών εισόδου, με στόχο την βελτιστοποίηση της απόδοσης. Τέλος, συμπεραίνεται πως η απόδοση θα πρέπει να εξετάζεται συλλογικά και όχι μεμονωμένα με την ταυτόχρονη μελέτη αρκετών μετρικών και διαγραμμάτων.

Λέξεις κλειδιά: LSTM, RNN, Βαθιά Μηχανική Μάθηση, Μηχανική Μάθηση, Νευρωνικά Δίκτυα, Χρονοσειρές, Προβλέψεις, Χρηματιστήριο, Μετοχή

Abstract

Stock market forecasts over time attract the interest of investors and researchers, at a time when deep machine learning is shaping the most promising category of relevant algorithms. The subject of this dissertation is the application and study of deep machine learning and specifically Long Short-term Memory (LSTM) neural networks, for the implementation of short-term stock market forecasts. Deep learning is a promising category of technical analysis and in particular LSTM is very effective for time series study. In the context of this diplomatic process, stock market forecasts are implemented for large technology companies and the factors affecting their performance are studied. The LSTM's ability to understand stock market dependencies and make effective forecasts is highlighted. In addition, the importance of the proper configuration of the neural network and then the appropriate selection of input characteristics is made clear, with the aim of optimizing performance. Finally, it is concluded that performance should be considered collectively and not individually by simultaneously studying several metrics and diagrams.

Keywords: LSTM, RNN, Deep Learning, Machine Learning, Neural Networks, Time Series, Forecasting, Stock Market, Stock

Ευχαριστίες

Πρωτίστως, θα ήθελα να ευχαριστήσω τον επιβλέποντα καθηγητή μου Γρηγόρη Μέντζα για την δυνατότητα που μου έδωσε να εργαστώ πάνω σε ένα τόσο ενδιαφέρον και σύγχρονο θέμα. Η μεθοδικότητα του, η αφοσίωσή του, οι συμβουλές του και η οργανωτικότητα του με έκαναν να τον θαυμάζω και να τον εκτιμώ τόσο σαν καθηγητή όσο και σαν άνθρωπο.

Στην συνέχεια, ευχαριστώ τον διδάκτορα Αλέξανδρο Μπουσδέκη και την υποψήφια διδάκτορα Κατερίνα Λεπενιώτη και για την συγκινητική αφοσίωση και υπομονή τους, για τις πολύτιμες γνώσεις που μου μεταλαμπάδευσαν, για την καθοδήγησή τους και για την ανεκτίμητη συνεισφορά τους στην διπλωματική μου.

Τέλος, θα ήθελα να αφιερώσω την διπλωματική μου στους γονείς μου, την αδερφή μου, την Μαρίζα μου και τους φίλους μου και να τους ευχαριστήσω για την απεριόριστη υπομονή τους, την στήριξη και την αγάπη τους.

Καρλής Βασίλειος
Αθήνα, 18 Μαρτίου 2021

Περιεχόμενα

Κεφάλαιο 1: Εισαγωγή	1
1.1 Χρηματιστηριακές Προβλέψεις	1
1.2 Αντικείμενο της διπλωματικής	2
1.3 Δομή της διπλωματικής.....	2
Κεφάλαιο 2: Θεωρητικό υπόβαθρο	3
2.1 Υφιστάμενη κατάσταση σε εφαρμογές χρηματιστηριακών προβλέψεων	3
2.1.1 Εισαγωγή	3
2.1.2 Στατιστική ανάλυση	5
2.1.3 Αναγνώριση προτύπων	6
2.1.4 Ανάλυση συναισθήματος	6
2.1.5 Μηχανική μάθηση (Machine learning)	7
2.1.6 Υβριδική προσέγγιση.....	8
2.2 Αναδρομικά Νευρωνικά Δίκτυα Μακράς και Βραχείας Μνήμης.....	9
2.2.1 Εισαγωγή	9
2.2.2 Αναδρομικά νευρωνικά δίκτυα	9
2.2.3 Αναδρομικά νευρωνικά δίκτυα μακράς και βραχείας μνήμης	11
Κεφάλαιο 3: Αναδρομικά Νευρωνικά Δίκτυα Μακράς και Βραχείας Μνήμης για Χρηματιστηριακές Προβλέψεις.....	15
3.1 Εισαγωγή.....	15
3.2 Προτεινόμενη προσέγγιση.....	15
3.3 Αρχιτεκτονική του νευρωνικού δικτύου και διαδικασία προπόνησης	16
3.4 Δεδομένα εισόδου και δεδομένα εξόδου	17
3.5 Οι μέθοδοι αξιολόγησης.....	18
3.5.1 Εισαγωγή	18
3.5.2 Αξιολόγηση της εκπαίδευσης και του νευρωνικού(πρόβλημα παρεμβολής)	18
3.5.3 Αξιολόγηση μετά την μετατροπή σε πρόβλημα ταξινόμησης.....	19
Κεφάλαιο 4: Αποτελέσματα	22
4.1 Υλοποίηση.....	22
4.2 Πειραματική προσέγγιση	22
4.3 Πειράματα	23
4.3.1 Προβλέψεις για την μετοχή της Apple.....	23

4.3.2 Προβλέψεις για την μετοχή της IBM.....	42
4.3.3 Προβλέψεις για την μετοχή της Nvidia.....	46
4.3.4 Προβλέψεις για την μετοχή της Tesla.....	53
4.3.5 Προβλέψεις για την μετοχή της Microsoft	60
4.4 Συμπεράσματα Πειραμάτων	66
4.5 Σύγκριση Αποτελεσμάτων με την Βιβλιογραφία	68
Κεφάλαιο 5: Συμπεράσματα και μελλοντική εργασία.....	71
5.1 Συμπεράσματα	71
5.2 Περιορισμοί της διπλωματικής	71
5.3 Μελλοντική δουλειά	71

Κεφάλαιο 1: Εισαγωγή

1.1 Χρηματιστηριακές Προβλέψεις

Η έννοια της πρόβλεψης (forecasting) εκφράζει την εκτίμηση για πιθανά μελλοντικά γεγονότα, έχοντας σαν βάση την ανάλυση παρελθοντικών δεδομένων. Οι προβλέψεις λοιπόν, υπάρχουν παντού στην ζωή μας, βρίσκοντας εφαρμογή σε αμέτρητους κλάδους όπως για παράδειγμα την οικονομία, το περιβάλλον, την παραγωγή και τον καιρό. Μια βασική κατηγοριοποίηση για τις προβλέψεις προκύπτει με κριτήριο τον χρονικό ορίζοντα ενδιαφέροντος, καταλήγοντας έτσι στις τρεις ακόλουθες βασικές υποομάδες οι οποίες συμπεριλαμβάνουν σύμφωνα με τον Selvin et al. (2017):

- Τις βραχυπρόθεσμες προβλέψεις όπου ο χρονικός ορίζοντας πρόβλεψης μπορεί να είναι μερικά δευτερόλεπτα, λεπτά, μέρες ή και μήνες.
- Τις μεσοπρόθεσμες προβλέψεις που συμπεριλαμβάνουν προβλέψεις με χρονικό ορίζοντα 1-2 χρόνια.
- Τις μακροπρόθεσμες προβλέψεις οι οποίες σε γενικές γραμμές αφορούν χρονικό ορίζοντα πάνω από 2 χρόνια.

Η λύση στα περισσότερα προβλήματα πρόβλεψης μπορεί να προκύψει με την χρονική ανάλυση του παρελθόντος. Για μια οποιαδήποτε επιλεγμένη μεταβλητή, από το παρελθόν της προκύπτει μια χρονική ακολουθία παρατηρήσεων, η οποία ονομάζεται χρονοσειρά της μεταβλητής αυτής. Στην περίπτωση των χρηματιστηριακών προβλέψεων για παράδειγμα, η μεταβλητή αυτή θα μπορούσε να είναι η τιμή μιας χρηματιστηριακής μετοχής.

Η μετοχή ορίζεται ως ένα από τα ίσα μερίδια, στα οποία διαιρείται το κεφάλαιο μιας ανώνυμης εταιρείας, εισηγμένης στο χρηματιστήριο. Κάθε μετοχή λοιπόν, έχει την δική της τιμή, η οποία αλλάζει δυναμικά καθημερινά και εξαρτάται από αμέτρητους παράγοντες. Κατά συνέπεια, προκειμένου να μελετάται πιο συστηματικά η πορεία μιας μετοχής, έχουν οριστεί ορισμένες ημερήσιες τιμές αναφοράς, οι οποίες και μελετώνται. Στις τιμές αυτές συμπεριλαμβάνονται η τιμή ανοίγματος (open) και η τιμή κλεισίματος (close) της μετοχής, που εκφράζουν την τιμή της μετοχής κατά την πρώτη και κατά την τελευταία συναλλαγή μιας ημέρας. Ακόμη, ημερήσιες τιμές αναφοράς αποτελούν το υψηλό ημέρας (high) και το χαμηλό ημέρας (low), που χρησιμεύουν στην απεικόνιση της υψηλότερης και της χαμηλότερης τιμής της μετοχής, για τις οποίες πραγματοποιήθηκε συναλλαγή κατά την διάρκεια μιας ημέρας. Επιπλέον, χρησιμοποιείται η τιμή του όγκου (volume) που εκφράζει το ποσό των συναλλαγών που διακινήθηκαν σε μια μέρα. Τέλος, ιδιαίτερης σημασίας είναι η προσαρμοσμένη τιμή κλεισίματος (adjusted close), που σε αντίθεση με την τιμή κλεισίματος, συμπεριλαμβάνει αλλαγές που προκύπτουν από εταιρικές ενέργειες, όπως πληρωμές μερισμάτων, διασπάσεις μετοχών και έκδοση νέων μετοχών.

Οι χρηματιστηριακές προβλέψεις έχουν απασχολήσει σε μεγάλο βαθμό την επιστημονική κοινότητα. Αρκεί να αναλογιστεί κανείς πως μόλις από το 2012, το 85% των συναλλαγών στο χρηματιστήριο των Η.Π.Α. πραγματοποιούνταν από αλγόριθμους, όπως τονίζει ο Nelson et al. (2017). Για την ανάλυση των οικονομικών αγορών και την πρόβλεψη χρηματιστηριακών μεγεθών, ορίζονται δύο βασικές προσεγγίσεις (Park and Irwin 2007; Nguyen et al. 2015). Η πρώτη προσέγγιση είναι η θεμελιώδης ανάλυση που διερευνά κυρίως τον εντοπισμό θεμελιωδών οικονομικών παραγόντων που θα μπορούσαν να επηρεάσουν την αξία μιας μετοχής. Στον αντίποδα βρίσκεται η τεχνική ανάλυση, η οποία αναλύεται εκτενώς στα πλαίσια αυτής της διπλωματικής και αφορά την μελέτη της

παρελθοντικής συμπεριφοράς της αγοράς με στόχο την πρόβλεψη της μελλοντικής κίνησης μιας μετοχής (Shah et al., 2019).

1.2 Αντικείμενο της διπλωματικής

Σκοπός της διπλωματικής είναι η εφαρμογή και μελέτη της βαθιάς μηχανικής μάθησης και συγκεκριμένα των αναδρομικών νευρωνικών δικτύων μακράς και βραχείας μνήμης (Lstm), για την πραγματοποίηση βραχυπρόθεσμων χρηματιστηριακών προβλέψεων. Η βαθιά μηχανική μάθηση αποτελεί μια πολλά υποσχόμενη κατηγορία τεχνικής ανάλυσης και ειδικότερα τα Lstm είναι πολύ αποτελεσματικά για την μελέτη χρονοσειρών. Στα πλαίσια αυτής της διπλωματικής λοιπόν, υλοποιούνται χρηματιστηριακές προβλέψεις για μεγάλες τεχνολογικές εταιρείες και μελετώνται οι παράγοντες που επηρεάζουν την απόδοση των προβλέψεων, με τελικό σκοπό την βελτιστοποίηση των αποτελεσμάτων.

1.3 Δομή της διπλωματικής

Στο κεφάλαιο 2 παρουσιάζεται το θεωρητικό υπόβαθρο πάνω στο οποίο βασίζεται η διπλωματική. Συγκεκριμένα, αρχικά γίνεται λόγος για τις διαφορετικές κατηγορίες στις οποίες εντάσσονται οι χρηματιστηριακές προβλέψεις αλλά και για την υφιστάμενη κατάσταση σε εφαρμογές χρηματιστηριακών προβλέψεων. Στην συνέχεια, παρουσιάζονται θεωρητικά τα αναδρομικά νευρωνικά δίκτυα μακράς και βραχείας μνήμης.

Στο κεφάλαιο 3 παρουσιάζεται η προσέγγιση μας για τα αναδρομικά νευρωνικά δίκτυα μακράς και βραχείας μνήμης για χρηματιστηριακές προβλέψεις και γίνεται αναφορά στην αρχιτεκτονική του νευρωνικού δικτύου, την διαδικασία προπόνησης, τα δεδομένα εισόδου και εξόδου και τις επιλεγμένες μεθόδους αξιολόγησης.

Στο κεφάλαιο 4 παρουσιάζεται η υλοποίηση που πραγματοποιείται στα πλαίσια της διπλωματικής, η πειραματική προσέγγιση, τα πειράματα, τα συμπεράσματα των πειραμάτων και τέλος γίνεται σύγκριση των αποτελεσμάτων με την υπάρχουσα βιβλιογραφία.

Στο κεφάλαιο 5 εξάγονται τα συνολικά συμπεράσματα που προκύπτουν από την διπλωματική συνοδευόμενα από τους περιορισμούς της πρότασής μας και από τις προοπτικές για μελλοντική εργασία πάνω στο συγκεκριμένο αντικείμενο.

Κεφάλαιο 2: Θεωρητικό υπόβαθρο

2.1 Υφιστάμενη κατάσταση σε εφαρμογές χρηματιστηριακών προβλέψεων

2.1.1 Εισαγωγή

Οι προβλέψεις χρηματιστηριακών μεγεθών, αν και διαχρονικά προσελκύουν το ενδιαφέρον των αναλυτών και των επενδυτών, είναι αδιαμφισβήτητα πολύ δύσκολες. Αρκεί να αναλογιστεί κανείς την ύπαρξη διάσημων θεωριών που ορίζουν τις τιμές των μετοχών σαν ένα τυχαίο περίπατο που δεν μπορεί να προβλεφθεί. Σε κάθε περίπτωση η πρόβλεψη χρηματιστηριακών μεγεθών αποτελεί μεγάλη πρόκληση εξαιτίας του τεράστιου αριθμού παραμέτρων που επιδρούν στην τελική τιμή μιας μετοχής. Ενδεικτικά, τα χρηματιστηριακά μεγέθη επηρεάζονται από παράγοντες πολιτικούς, οικονομικούς, ψυχολογικούς και φυσικά παράγοντες που αφορούν την εκάστοτε εταιρεία.

Ο στόχος των επενδυτών κατά την είσοδο τους στο χρηματιστήριο είναι η επίτευξη μεγάλων κερδών, με την ύπαρξη, παράλληλα, χαμηλού ρίσκου. Τόσο οι επενδυτές όσο και η επιστημονική κοινότητα λοιπόν, έχουν εκδηλώσει ιδιαίτερο ενδιαφέρον για την ανάπτυξη σχετικών αλγορίθμων. Υπάρχουν δύο βασικές προσεγγίσεις, για την ανάλυση των οικονομικών αγορών, που μπορούν να οδηγήσουν τους επενδυτές στο επιθυμητό αποτέλεσμα, η τεχνική ανάλυση και η θεμελιώδης ανάλυση (Park and Irwin 2007; Nguyen et al. 2015).

Αφενός, η θεμελιώδης ανάλυση βασίζεται σύμφωνα με τον Hu et al. (2015) στις τρεις ακόλουθες βασικές αρχές.

α) Στην μακροοικονομική ανάλυση που συμπεριλαμβάνει την μελέτη του ακαθάριστου εγχώριου προϊόντος (Gross Domestic Product) και του δείκτη τιμών καταναλωτή (Consumer Price Index) για την ανάλυση της επίδρασης του μακροοικονομικού περιβάλλοντος στα μελλοντικά κέρδη της εταιρείας.

β) Στην ανάλυση της βιομηχανίας (industry analysis) που υπολογίζει την αξία της εταιρείας με βάση την κατάσταση και την προοπτική του κλάδου.

γ) Στην ανάλυση της εταιρείας (company analysis) που αφορά την λειτουργία και την οικονομική κατάσταση μιας εταιρείας για την αξιολόγηση της εσωτερικής της αξίας (internal value).

Από την άλλη, η τεχνική ανάλυση βασίζεται σύμφωνα με τον Hu et al. (2015) σε πληροφορία που συμπεριλαμβάνεται στα συναισθήματα (sentiments), στην ροή κεφαλαίων (flow-of-funds), σε ακατέργαστα δεδομένα (raw data), στην τάση (trend), το momentum, τον όγκο (volume), τους κύκλους (cycles), και την μεταβλητότητα (volatility). Συγκεκριμένα, με τον όρο των συναισθημάτων εκφράζονται οι συμπεριφορές διαφόρων συμμετεχόντων στην αγορά. Παράλληλα, η ροή των κεφαλαίων είναι ένας δείκτης που χρησιμοποιείται για την διερεύνηση της οικονομικής κατάστασης των επενδυτών, για να αξιολογηθεί εκ των προτέρων η ισχύς τους και η ικανότητα για αγορά ή πώληση μετοχών. Με τον όρο των ακατέργαστων δεδομένων γίνεται λόγος για χρονοσειρές που περιέχουν τιμές μετοχών και για τα διάφορα μοτίβα που προκύπτουν. Υπάρχει ακόμα ο δείκτης για την ανίχνευση τάσης και το momentum που αξιολογεί την ταχύτητα της μεταβολής της εκάστοτε τιμής ώστε να εντοπίζονται τελικά μεταβολές στην τάση. Ακόμη, ο όγκος, είναι ένας δείκτης που εκφράζει τον ενθουσιασμό των επενδυτών στο να επενδύουν ενώ επίσης αποτελεί την βάση για την πρόβλεψη των μεταβολών των μετοχών. Οι κύκλοι, βασίζονται στην θεωρία ότι οι τιμές των μετοχών εμφανίζουν για μεγάλα χρονικά

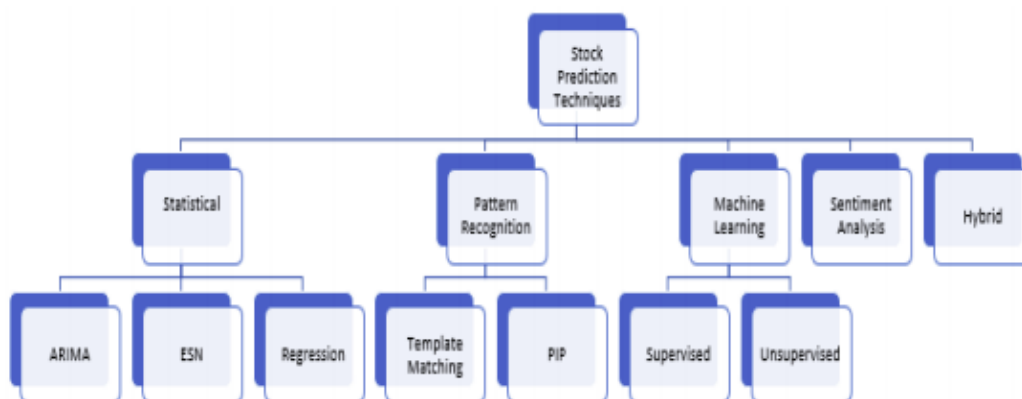
διαστήματα περιοδικότητα ημερών η εβδομάδων. Τέλος, η μεταβλητότητα εξετάζει την διακύμανση στην τιμή της μετοχής και επομένως το ρίσκο.

Η πρόβλεψη χρηματιστηριακών μεγεθών κρύβει πολλές παγίδες. Έχουν διατυπωθεί πολλές σχετικές θεωρίες που είτε προσπαθούν να εξηγήσουν την φύση του χρηματιστηρίου είτε προσπαθούν να εξηγήσουν αν το χρηματιστήριο μπορεί να νικηθεί. Μια πολύ διάσημη αλλά και πολύ συζητημένη θεωρία διατυπώθηκε από τον Fama (1970) και είναι η Efficient Market Hypothesis (EMH) που προτείνει ότι για κάθε χρονική στιγμή η τιμή μιας μετοχής ενσωματώνει όλη την πληροφορία που υπάρχει για την μετοχή. Αυτό με άλλα λόγια σημαίνει ότι μια καινούρια αλλαγή θα αλλάξει και την τιμή της μετοχής. Η θεωρία για το EMH έχει τρεις παραλλαγές που όμως σε κάθε περίπτωση θεωρούν τις αλλαγές στην τιμή της μετοχής απρόβλεπτες με αποτέλεσμα οι προβλέψεις για χρηματιστηριακά μεγέθη να μην έχουν ελπίδα.

Φυσικά, δεν θα μπορούσαν να μην υπάρχουν και πιο αισιόδοξες οπτικές. Οι Abu-Mostafa and Atiya (1996), υποστήριξαν πως η ύπαρξη τάσης στις τιμές των οικονομικών αγορών και η συσχέτιση ανάμεσα σε θεμελιώδη γεγονότα και οικονομικά μεγέθη, είναι δύο από τους πολλούς παράγοντες που αποτελούν αποδεικτικά στοιχεία έναντι του EMH. Έκτοτε λοιπόν, πολλοί επενδυτές και ερευνητές έχουν διαφωνήσει με αυτή την θεωρία τόσο εμπειρικά όσο και θεωρητικά. Πλέον, τα χρηματιστηριακά μεγέθη είναι αποδεκτό ότι σε έναν σημαντικό βαθμό μπορούν να προβλεφθούν. Με βάση την υφιστάμενη κατάσταση μπορούν να οριστούν οι τέσσερις ακόλουθες βασικές κατηγορίες όσον αφορά την πρόβλεψη και την ανάλυση των μετοχών.

- Στατιστική ανάλυση (statistical analysis)
- Αναγνώριση προτύπων (pattern recognition)
- Μηχανική μάθηση (machine learning)
- Ανάλυση συναισθήματος (sentiment analysis)

Αυτές οι κατηγορίες, οι οποίες αποτυπώνονται στην εικόνα 2.1, κατά κύριο λόγο ανήκουν στο ευρύτερο φάσμα της τεχνικής ανάλυσης, παρόλα αυτά υπάρχουν μέθοδοι της μηχανικής μάθησης που συνδυάζουν τεχνική και θεμελιώδη ανάλυση για την πρόβλεψη χρηματιστηριακών μεγεθών.



Εικόνα 2.1: Ταξινόμηση τεχνικών χρηματιστηριακών προβλέψεων

2.1.2 Στατιστική ανάλυση

Πριν από την έλευση των αλγορίθμων μηχανικής μάθησης, οι στατιστικές τεχνικές, που βέβαια συχνά υποθέτουν λανθασμένα γραμμικότητα και χρονική σταθερότητα (stationarity), παρείχαν αποτελεσματικές λύσεις για την ανάλυση και πρόβλεψη των μετοχών. Οι χρονοσειρές που χρησιμοποιούνται για την χρηματιστηριακή ανάλυση είναι χρονολογικές συλλογές παρατηρήσεων όπως για παράδειγμα οι ημερήσιες πωλήσεις και οι ημερήσιες τιμές μετοχών. Με την πάροδο των χρόνων, έχουν χρησιμοποιηθεί πολλές μέθοδοι που ανήκουν σε αυτή την κατηγορία τεχνικών, όπως για παράδειγμα το μοντέλο εκθετικής εξομάλυνσης (Exponential Smoothing Model) που είναι μια διάσημη τεχνική εξομάλυνσης για δεδομένα χρονοσειρών. Σε γενικές γραμμές όμως, υπάρχουν δύο βασικές κατηγορίες μεθόδων στατιστικής ανάλυσης, όπως διαχωρίστηκαν από τους Zhong and Enke (2017):

- Η πρώτη κατηγορία αφορά την ανάλυση μιας μεταβλητής (univariate analysis), όπου συγκεκριμένα μια είσοδος έχει την μορφή χρονοσειράς. Στην κατηγορία αυτή ανήκουν οι τεχνικές Auto-Regressive Moving Average (ARMA), Auto-Regressive Integrated Moving Average (ARIMA), Generalized Autoregressive Conditional Heteroskedastik (GARCH) volatility και το Smooth Transition Autoregressive (STAR) model. Από τα παραπάνω η ARIMA είναι πολύ διάσημη μέθοδος για χρηματιστηριακή ανάλυση. Η ARMA συνδυάζει Auto-Regressive (AR) μοντέλα, που προσπαθούν να εξηγήσουν την επίδραση των momentum και mean reversion που συχνά παρατηρούνται στις χρηματιστηριακές αγορές, και τα Moving Average (MA) μοντέλα που προσπαθούν να εντοπίσουν που παρατηρούνται στις χρονοσειρές. Ένας βασικός περιορισμός του μοντέλου ARMA είναι ότι δεν συνυπολογίζει ομαδοποίηση μεταβλητότητας (volatility clustering), ένα βασικό εμπειρικό φαινόμενο σε πολλές χρονοσειρές οικονομικών που σημείωσε για πρώτη φορά ο Mandelbrot (1963). Η ερμηνεία του φαινομένου από τον ίδιο είναι ότι "οι μεγάλες αλλαγές τείνουν να ακολουθούνται από μεγάλες αλλαγές, και των δύο σημείων, και οι μικρές αλλαγές τείνουν να ακολουθούνται από μικρές αλλαγές". Το μοντέλο ARIMA είναι μια φυσική επέκταση του μοντέλου ARMA που μπορεί να αντιστοιχίσει μη σταθερές χρονικά χρονοσειρές, σε σταθερές.
- Στην δεύτερη κατηγορία συνήθως συναντώνται πολλαπλές μεταβλητές εισόδου, και συναντάμε τεχνικές όπως Linear Discriminant Analysis (LDA), Quadratic Discriminant Analysis (QDA) και αλγορίθμους παλινδρόμησης.

Τελικά, οι τεχνικές στατιστικής ανάλυσης που απασχολούν περισσότερο την επιστημονική κοινότητα μέχρι και σήμερα λόγω της απόδοσης τους είναι οι ARIMA, ESM, Regression algorithms και οι παραλλαγές τους. Όπως έχει προειπωθεί όμως, οι παραπάνω τεχνικές, υποθέτουν πως υπάρχει μια δομή γραμμικής συσχέτισης στα δεδομένα των χρονοσειρών. Αυτός ο περιορισμός μπορεί να ξεπεραστεί από τον συνδυασμό στατιστικών μοντέλων με μηχανική μάθηση είτε με άλλες μεθόδους (Shah et al., 2019).

2.1.3 Αναγνώριση προτύπων

Η αναγνώριση προτύπων εστιάζει στον εντοπισμό μοτίβων και τάσεων στα δεδομένα με τελικό στόχο την πρόβλεψη μελλοντικών τάσεων. Τα μοτίβα (patterns) στο χρηματιστήριο είναι επαναλαμβανόμενες ακολουθίες που εντοπίζονται κατά κύριο λόγο στα διαγράμματα της τιμής ανοίγματος (open), της τιμή κλεισίματος (close), του υψηλού ημέρας (high), και του χαμηλού ημέρας (low), τα οποία οι συναλλασσόμενοι διαχρονικά χρησιμοποιούν σαν ενδείξεις για πώληση ή αγορά μετοχών. Γνώριμα μοτίβα που παρατηρούνται στις μετοχές είναι τα λεγόμενα gaps, spikes, flags, pennants, wedges, saucers, triangles, head-and-shoulders, tops και bottoms. Τα μοτίβα αυτά έχουν την δυνατότητα να ενημερώσουν έναν επενδυτή για την μελλοντική πορεία της μετοχής. Δύο πολύ διαδεδομένες μέθοδοι αναγνώρισης προτύπων είναι τα Perceptually Important Points (PIP) που βασίζονται στην μείωση του μεγέθους (του αριθμού των σημείων) της χρονοσειράς και το template matching, μια τεχνική που αντιστοιχεί ένα δοσμένο μοτίβο μιας μετοχής με μια εικονογραφική (pictographic) εικόνα για την ταυτοποίηση αντικειμένων. Σε γενικές γραμμές η αναγνώριση προτύπων είναι πολλά υποσχόμενη, αλλά από μόνη της δεν πείθει για την πρόβλεψη χρηματιστηριακών μεγεθών. Αυτό συμβαίνει διότι οι τεχνικές που προσφέρει είναι πιο κατάλληλες για την ανάλυση και την εξαγωγή μοτίβων παρά για την πρόβλεψη πραγματικών τιμών. Συμπερασματικά, η αναγνώριση προτύπων αντί να χρησιμοποιείται για πρόβλεψη μετοχών, φαίνεται πιο χρήσιμη όταν χρησιμοποιείται σε συνδυασμό με άλλες τεχνικές πρόβλεψης και εφαρμόζεται πιο αποτελεσματικά σε προβλήματα που αφορούν την ανίχνευση της τάσης (Shah et al., 2019).

2.1.4 Ανάλυση συναισθήματος

Η ανάλυση συναισθήματος αποτελεί μια ακόμη προσέγγιση που χρησιμοποιείται για την ανάλυση χρηματιστηριακών μεγεθών. Πρόκειται για την διαδικασία πρόβλεψης των τάσεων των μετοχών μέσα από την αυτοματοποιημένη ανάλυση κειμένων από πηγές όπως είναι η ροή ειδήσεων (news feeds) και τα tweets που είναι σχετικά με το χρηματιστήριο και με εισηγμένες σε αυτό εταιρείες. Η συγκεκριμένη κατηγορία ανάλυσης λοιπόν, η οποία είναι χρήσιμη για την επίλυση προβλημάτων ταξινόμησης, μπορεί να χωριστεί σε 2 βασικές υποκατηγορίες. Η πρώτη είναι η προσέγγιση μέσω μηχανικής μάθησης και η δεύτερη συμπεριλαμβάνει corpus-based προσεγγίσεις. Τα συναισθήματα μπορούν να οδηγήσουν σε βραχυπρόθεσμες διακυμάνσεις στην αγορά, οι οποίες με την σειρά τους μπορούν να οδηγήσουν σε διαφοροποίηση της τιμής της μετοχής και της πραγματικής αξίας του μερίσματος της εταιρείας. Φυσικά, σε βάθος χρόνου τα θεμελιώδη στοιχεία της εταιρείας θα οδηγήσουν την τιμή της μετοχής και την πραγματική αξία του μερίσματος της εταιρείας στο να συγκλίνουν. Τα συναισθήματα λοιπόν, παίζουν σημαντικό ρόλο στο χρηματιστήριο και η ανάλυση τους μπορεί να δώσει ενδείξεις σχετικά με το πως αντιδρά το χρηματιστήριο σε τέτοιου είδους πληροφορίες τόσο βραχυπρόθεσμα όσο και μακροπρόθεσμα. Η ανάλυση συναισθήματος βασίζεται σε μεγάλο βαθμό σε πληροφορία που είναι διαθέσιμη στα κοινωνικά δίκτυα, η οποία είναι όμως δύσκολο να συλλεχθεί σωστά καθώς είναι δύσκολο ένας υπολογιστής να μπορεί να καταλάβει τους διαφορετικούς τρόπους με τους οποίους μπορεί να εκφραστεί ένας άνθρωπος (π.χ. χιούμορ, σαρκασμός).

Σε αυτό το σημείο θα πρέπει να σημειωθεί πως έχουν γίνει αρκετές επιστημονικές μελέτες, σχετικά με την ανάλυση συναισθήματος, και η υπάρχουσα βιβλιογραφία είναι πολύ πλούσια. Ενδεικτικά, οι Schumaker and Chen (2009), βασισμένοι στην χρήση SVM, πραγματοποίησαν μελέτη για την βραχυπρόθεσμη επίδραση έκτακτων ειδήσεων πάνω στα χρηματιστηριακά μεγέθη. Λίγο αργότερα, ο Bollen et al. (2011) πραγματοποίησε μια από τις πρώτες μελέτες όπου έγινε χρήση δεδομένων από το twitter για την πρόβλεψη της τάσης χρηματιστηριακών μεγεθών. Συγκεκριμένα, η προσπάθεια αυτή πλαισιώθηκε από την χρήση ενός νευρωνικού δικτύου (Self-Organizing Fuzzy Neural Network (SOFNN)) και από την χρήση μιας αποτελεσματικής μεθόδου για την αφαίρεση των ανεπιθύμητων tweets, και μελετήθηκε η συσχέτιση των δημόσιων σχολίων με τις μεταβολές του δείκτη

Dow Jones Industrial Average (DJIA). Ακολούθως, ο Lee et al. (2014) πρότεινε ένα μοντέλο ανάλυσης κειμένου εφαρμοσμένο πάνω στα 8-K reports, που περιέχουν τα νέα της εταιρείας, και θεωρήθηκαν πιο σχετικά με το χρηματιστήριο, σε σχέση με τα δεδομένα που προκύπτουν από τα κοινωνικά δίκτυα. Οι συγγραφείς μελέτησαν την μελλοντική τάση και είδαν βελτίωση στην ακρίβεια πρόβλεψης κατά 10%, σημειώνοντας επομένως πρόοδο στις βραχυπρόθεσμες προβλέψεις. Επιπροσθέτως, οι Cakra and Trisedya (2015) και ο Pagolu et al. (2016) επίσης χρησιμοποίησαν πληροφορία από το twitter, με στόχο την παραγωγή προβλέψεων. Το υπάρχον πρόβλημα όπως αναφέρει ο τελευταίος με τα δεδομένα αυτού του είδους, είναι πως κρύβουν τον κίνδυνο για κακόβουλα και μεροληπτικά tweets, ενώ υπάρχουν και πολλοί ενεργοί χρήστες στο twitter που όμως δεν παίζουν στο χρηματιστήριο, οδηγώντας έτσι σε παραπλανητικά αποτελέσματα. Μια εναλλακτική λοιπόν, όπως προτάθηκε, θα μπορούσε να είναι η χρήση, αντί του twitter, ενός κοινωνικού δικτύου σχετικού με το χρηματιστήριο.

2.1.5 Μηχανική μάθηση (Machine learning)

Είναι ευρέως γνωστό πως η μηχανική μάθηση μπορεί να βρει εφαρμογή σε πληθώρα προβλημάτων διαφορετικού τύπου. Ανάλογα με τα εξεταζόμενα προβλήματα λοιπόν, η μηχανική μάθηση χωρίζεται σε δύο βασικές κατηγορίες, στην μάθηση με επίβλεψη (supervised learning) και στην μάθηση χωρίς επίβλεψη (unsupervised learning). Αμφότερες, οι δύο παραπάνω κατηγορίες, έχουν μελετηθεί εκτεταμένα για την προοπτική τους στις χρηματιστηριακές προβλέψεις. Με λίγα λόγια, στην μάθηση με επίβλεψη, στο σύστημα εισάγονται δεδομένα για τα οποία κάθε είσοδος συνοδεύεται από την έξοδο στην οποία αντιστοιχεί. Ο στόχος ενός προγράμματος που ανήκει σε αυτή την κατηγορία, είναι η προπόνηση ενός αλγορίθμου, ώστε έπειτα με την λήψη μιας εισόδου να είναι εφικτή η παραγωγή της σωστής εξόδου. Αντιθέτως, στην μάθηση χωρίς επίβλεψη δίνονται τα δεδομένα χωρίς να έχουν αντιστοιχηθεί σε κάποια έξοδο. Ο στόχος, σε αυτή την περίπτωση, είναι η προπόνηση ενός αλγορίθμου που τελικά να μπορεί να βρίσκει μοτίβα, συσχετίσεις και υποομάδες στα δεδομένα εισόδου. Εκτός αυτού του διαχωρισμού, ένας άλλος συνήθης διαχωρισμός, ο οποίος θα αποδειχθεί χρήσιμος για την συνέχεια, αφορά τα προβλήματα μάθησης με επίβλεψη και είναι ο διαχωρισμός σε προβλήματα ταξινόμησης, ή όπως αποκαλούνται αλλιώς προβλήματα κατηγοριοποίησης (classification problems), και σε προβλήματα παρεμβολής (regression problems). Συγκεκριμένα, στην πρώτη κατηγορία οι έξοδοι είναι μη διατεταγμένες, διακριτές τιμές (κατηγορίες), ενώ στην δεύτερη κατηγορία, οι έξοδοι είναι συνεχείς τιμές (Kotsiantis et al., 2007). Η βαθιά μηχανική μάθηση συναντάται με την χρήση αρκετών αλγορίθμων, όπως για παράδειγμα τον αλγόριθμο των αναδρομικών νευρωνικών δικτύων που θα μας απασχολήσει στα πλαίσια αυτής της διπλωματικής.

Έχουν χρησιμοποιηθεί δεκάδες αλγόριθμοι μηχανικής μάθησης με στόχο την πρόβλεψη της τάσης της χρηματιστηριακής τιμής. Απλούστερες τεχνικές όπως τα δέντρα απόφασης (decision tree) και ο αφελής μπεϋζιανός ταξινομητής (naïve Bayes) έχουν αντικατασταθεί από πιο σύνθετους αλγορίθμους που αποδίδουν όμως καλύτερα, όπως Random Forest, Logistic Regression, και νευρωνικά δίκτυα. Ταυτόχρονα, η ύπαρξη μη γραμμικών χαρακτηριστικών πολλαπλών εισόδων, έχει οδηγήσει τα νευρωνικά δίκτυα βαθιάς μηχανικής μάθησης ώστε να είναι το πλέον διάσημο και κυρίαρχο εργαλείο για την ανάλυση των οικονομικών αγορών.

Όσον αφορά την μάθηση με επίβλεψη, αποτυπώνονται συνοπτικά μερικές ενδεικτικές ερευνητικές προσπάθειες. Ο Bernal et al. (2012), υλοποίησε μια υποκλάση αναδρομικών νευρωνικών δικτύων (Recurrent Neural Networks) που ονομάζονται Echo State Networks (ESN) για την πρόβλεψη μετοχών του δείκτη S&P 500 χρησιμοποιώντας την τιμή της μετοχής, κινητούς μέσους όρους, και τον όγκο σαν χαρακτηριστικά (features). Στην συνέχεια, ο Ballings et al. (2015) υλοποίησε μια εκτενή σύγκριση αλγορίθμων, καταλήγοντας πως ο αλγόριθμος του Random Forest είχε τα καλύτερα αποτελέσματα σε σύγκριση με νευρωνικά δίκτυα (Neural Networks), Logistic Regression, Support Vector Machines, και τον αλγόριθμο των K-κοντινότερων γειτόνων (K-Nearest Neighbor Area),

χρησιμοποιώντας τον δείκτη Under the Curve (AUC) σαν κριτήριο απόδοσης. Ακολούθως, ο Milosevic (2016) έχοντας σαν αντικείμενο ενδιαφέροντος τις μακροπρόθεσμες προβλέψεις, επίλυσε πρόβλημα ταξινόμησης θεωρώντας μια μετοχή ‘καλή’ αν είχε αύξηση η τιμή της 10% σε βάθος ενός χρόνου, διαφορετικά θεωρώντας την ‘κακή’. Το συμπέρασμα ήταν πως ο αλγόριθμος Random Forest είχε το καλύτερο F-Score σε σύγκριση με τους αλγόριθμους SVM και τον αφελή μευζιανό ταξινομητή. Παράλληλα, ο Dey et al. (2016) χρησιμοποίησε τον αλγόριθμο eXtreme Gradient Boosting (XGBoost) που έχει μέχρι και σήμερα κεντρίσει το ενδιαφέρον της επιστημονικής κοινότητας και κατέληξε σε συμπεράσματα πολλά υποσχόμενα χρησιμοποιώντας σαν χαρακτηριστικά εισόδου τεχνικούς δείκτες. Εν συνεχεία, οι Di Persio and Honchar (2017) υλοποίησαν 3 διαφορετικούς αλγόριθμους που ανήκουν στο ευρύτερο φάσμα των Recurrent Neural Networks (RNN). Συγκεκριμένα, οι αλγόριθμοι αυτοί δεν ήταν άλλοι από το κλασικό RNN, το Gated Recurrent Unit (GRU) και το LSTM, με το τελευταίο να πετυχαίνει τα καλύτερα αποτελέσματα. Ακόμη μια ενδιαφέρουσα ερευνητική προσπάθεια είναι αυτή του Hossain et al. (2018) ο οποίος κατασκεύασε ένα υδριβικό μοντέλο βασισμένο σε αλγόριθμους μηχανικής μάθησης. Οι αλγόριθμοι που συνδυάστηκαν είναι το LSTM και το GRU και τα αποτελέσματα ήταν ενθαρρυντικά.

Επιπροσθέτως, αρκετές ερευνητικές προσπάθειες έχουν γίνει και όσον αφορά την μάθηση χωρίς επίβλεψη. Ενδεικτικά, ο Powell et al. (2008) έκανε σύγκριση μεταξύ μιας μεθόδου μηχανικής μάθησης με επίβλεψη (SVM) και της μεθόδου μηχανικής μάθησης χωρίς επίβλεψη του αλγορίθμου K-μέσων (K-means), σε δεδομένα του S&P 500, τονίζοντας πως μέσω των πειραμάτων επιτεύχθηκε παρόμοια απόδοση. Ακόμη, ο Babu et al. (2012) πρότεινε μια μέθοδο ομαδοποίησης (clustering) με όνομα HAK που αποτελεί συνδυασμό των Hierarchical Agglomerative Clustering (HAC) και Reverse K-means clustering (HRK). Το αποτέλεσμα της μελέτης ήταν πως με αυτή την μέθοδο επιτεύχθηκε καλύτερο accuracy σε σχέση με τις κλασικές μεθόδους των SVM και του αλγορίθμου K-μέσων. Επιπλέον, ο Wu et al. (2014) πρότεινε ένα μοντέλο βασισμένο στο AprioriAll algorithm (association rule learning) και τον αλγόριθμο K-μέσων, το οποίο αναγνωρίζει μοτίβα και προτείνει αγορά επιμένοντας σε αυτή την πρόταση για όσο υπάρχει το κατάλληλο μοτίβο.


2.1.6 Υβριδική προσέγγιση

Η υβριδική προσέγγιση, αφορά τον συνδυασμό διαφορετικών προσεγγίσεων, όπως για παράδειγμα το συνδυασμό προσεγγίσεων στατιστικής ανάλυσης και αναγνώρισης προτύπων, και προσεγγίσεων μηχανικής μάθησης σε συνδυασμό με στατιστική ανάλυση. Αξιόλογη ερευνητική προσπάθεια είναι αυτή των Markowska-Kaczmar and Dziedzic (2008) που εφάρμοσαν μια PIP τεχνική για την μείωση των διαστάσεων και την ανίχνευση τάσεων πριν τα δεδομένα δοθούν στα νευρωνικά δίκτυα πρόσθιας τροφοδότησης (feedforward NN) για πρόβλεψη. Ακολούθως ο Tiwari et al. (2010) πρότεινε έναν συνδυασμό statistical Hierarchical Hidden Markov model (HHMM) με την τεχνική μάθησης με επίβλεψη των δέντρων αποφάσεων για την πρόβλεψη της τάσης του δείκτη Bombay Stock Exchange Sensitive (BSE SENSEX) με χαρακτηριστικά εισόδου τιμές κλεισίματος, μερίσματα και κέρδη. Εν συνεχεία, ο Shen et al. (2012) πρότεινε έναν αλγόριθμο πρόβλεψης που συνδύασε προσεγγίσεις στατιστικής ανάλυσης και SVM, ενώ ο Wang et al. (2012) πρότεινε ένα μοντέλο που συνδύαζε τα μοντέλα ESM, ARIMA, και ένα νευρωνικό δίκτυο οπισθοδιάδοσης (Backpropagation Neural Network) και ισχυρίστηκε ότι ο συνδυασμός αποδίδει καλύτερα από τα μοντέλα ατομικά. Έπειτα, ο Yoshihara et al. (2014) μελέτησε τον συνδυασμό του Recurrent Neural Networks Restricted Boltzmann Machine (RNN-RBM) και του Deep Belief Network (DBN) για πρόβλεψη τάσης. Κλείνοντας ο Ding et al. (2015) συνδύασε ανάλυση συναισθήματος και μοντέλα συνελκτικών νευρωνικών δικτύων (Convolutional Neural Network) για την πρόβλεψη του δείκτη S&P 500 και ο Rather et al. (2015) εφάρμοσε έναν συνδυασμό ARIMA, ESN και RNN καταλήγοντας σε καλύτερη πρόβλεψη τιμής από αυτή του μεμονωμένου RNN (Shah et al., 2019).

2.2 Αναδρομικά Νευρωνικά Δίκτυα Μακράς και Βραχείας Μνήμης

2.2.1 Εισαγωγή

Η τεχνητή νοημοσύνη εδώ και πολλές δεκαετίες αποτελεί ένα τεράστιο επιστημονικό πεδίο. Υποσύνολο της τεχνητής νοημοσύνης θεωρείται η μηχανική μάθηση, ενώ τα τεχνητά νευρωνικά δίκτυα είναι, με την σειρά τους, ένα είδος μοντέλου μηχανικής μάθησης. Τα τεχνητά νευρωνικά δίκτυα, βασίζουν την λειτουργία τους στον τρόπο που λειτουργεί ο ανθρώπινος εγκέφαλος και έχουν γίνει ανάρπαστα για προβλήματα ταξινόμησης, ομαδοποίησης, αναγνώρισης προτύπων και πρόβλεψης (prediction). Με την σειρά της η βαθιά μηχανική μάθηση μπορεί να θεωρηθεί ως υποσύνολο της μηχανικής μάθησης. Στην βαθιά μηχανική μάθηση παρατηρούνται πιο σύνθετοι τρόποι για την σύνδεση των επιπέδων του νευρωνικού δικτύου, συναντώνται περισσότεροι νευρώνες, μεγαλύτερη υπολογιστική δύναμη, και ακόμη υπάρχει η δυνατότητα για αυτόματη εξαγωγή των χαρακτηριστικών. Η εικόνα 2.2 απεικονίζει γραφικά τις παραπάνω συσχετίσεις.



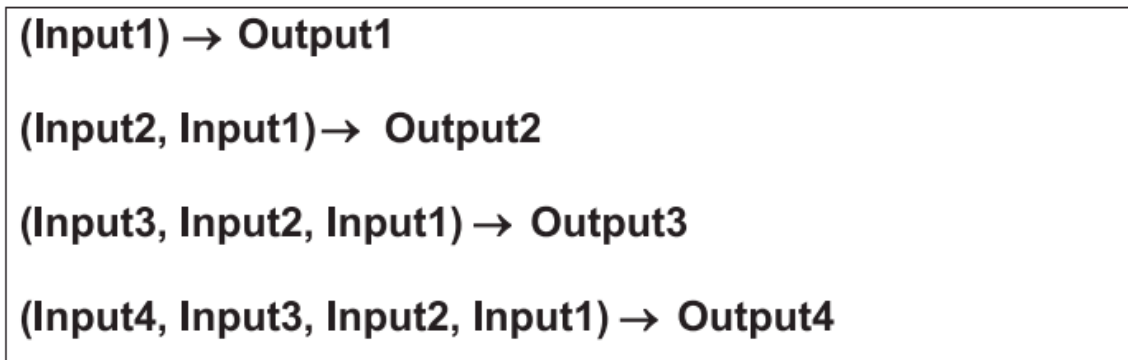
Εικόνα 2.2: Συσχέτιση βασικών εννοιών

Οι αλγόριθμοι βαθιάς μηχανικής μάθησης βρίσκουν μεγάλη εφαρμογή στην διαχείριση των μεγάλων δεδομένων (big data) με αξιοσημείωτη επιτυχία στην αναγνώριση φωνής, την αναγνώριση προτύπων, την όραση υπολογιστών, την επεξεργασία φυσικής γλώσσας, τα συστήματα συστάσεων κ.α. (Abiodun et al., 2018).

2.2.2 Αναδρομικά νευρωνικά δίκτυα


Τα αναδρομικά νευρωνικά δίκτυα (RNN) είναι στην ουσία νευρωνικά δίκτυα για ακολουθιακά δεδομένα και για αυτό τον λόγο βρίσκουν αποτελεσματική εφαρμογή σε προβλήματα χρονοσειρών. Η βασική ιδέα πίσω από τα RNN είναι ότι για να παραχθεί μια έξοδος δεν χρησιμοποιούνται μόνο τα δεδομένα εισόδου αλλά και οι προηγούμενες έξοδοι (Petnehazi et al., 2019). Τα RNN διαφέρουν από τα παραδοσιακά νευρωνικά δίκτυα πρόσθιας τροφοδότησης από την άποψη ότι δεν έχουν νευρώνες προς μια μόνο κατεύθυνση. Με άλλα λόγια, μπορούν να περνάνε πληροφορία και προς προηγούμενο επίπεδο ή και στο ίδιο επίπεδο. Κατά αυτόν τον τρόπο η πληροφορία δεν ρέει μόνο προς μια κατεύθυνση και αυτό μας δίνει την δυνατότητα να έχουμε βραχεία (short term) μνήμη (Nelson et al.,

2017). Το RNN μπορεί να θεωρηθεί σαν ένα δίκτυο με Multi-Layer Perceptron (MLP) με την προσθήκη loops στην κατασκευή του. Με τον όρο MLP γίνεται αναφορά ουσιαστικά σε απλά νευρωνικά δίκτυα πρόσθιας τροφοδότησης με τουλάχιστον τρία επίπεδα. Στα RNN υπάρχει ένα επίπεδο εισόδου (input layer), ένα κρυμμένο επίπεδο και ένα επίπεδο εξόδου. Αυτή η δομή θυμίζει την αρχιτεκτονική MLP με την μόνη διαφορά ότι τα κρυμμένα επίπεδα είναι μεταξύ τους διασυνδεδεμένα. Σε ένα vanilla (basic) RNN/LSTM οι κόμβοι συνδέονται προς μια κατεύθυνση. Αυτό το είδος αρχιτεκτονικής διασφαλίζει ότι η έξοδος $t=n$ εξαρτάται από τις εισόδους $t=n, t=n-1, \dots$, και $t=1$. Με άλλα λόγια η έξοδος θα εξαρτάται από μια ακολουθία δεδομένων και όχι από ένα δεδομένο όπως φαίνεται και στην εικόνα 2.3 (Manaswi et al., 2018).




Εικόνα 2.3: Συσχέτιση εισόδων και εξόδων σε ένα vanilla (basic) RNN/LSTM

Το παρακάτω διάγραμμα είναι ενδεικτικό της λειτουργίας ενός RNN, όπου διαφαίνεται η συσχέτιση των εισόδων και των εξόδων. Η επαναλαμβανόμενη διαδικασία επιτρέπει στην πληροφορία να περνάει από ένα βήμα στο επόμενο.



Εικόνα 2.4: Η λειτουργία ενός RNN

Τα recurrent neural networks έχουν την μορφή μιας αλυσίδας με επαναλαμβανόμενες διαδικασίες. Στο RNN η επαναλαμβανόμενη διαδικασία είναι πολύ απλή καθώς αποτελείται από ένα απλό tanh επίπεδο (Olah et al, 2015).



Εικόνα 2.5: Η επαναλαμβανόμενη διαδικασία κατά την λειτουργία ενός RNN


Με βάση τον τρόπο λειτουργίας των RNN, η εκμάθηση μακροπρόθεσμων εξαρτήσεων αποτελεί μεγάλη μαθηματική πρόκληση. Το βασικό πρόβλημα είναι ότι οι κλίσεις (gradients) που είναι απαραίτητο να ρυθμιστούν και υπολογίζονται κατά την οπισθοδιάδοση του λάθους (backpropagation), διαδίδονται σε τόσα στάδια τείνουν τις περισσότερες φορές να εξαφανίζονται και σε λιγότερες περιπτώσεις να αυξάνονται υπέρμετρα. Ακόμα και αν υπάρχει τρόπος ώστε να μην αυξάνεται υπέρμετρα η κλίση, η δυσκολία με τις μακροπρόθεσμες εξαρτήσεις προκύπτει από τα εκθετικά μικρότερα βάρη που δίνονται στις μακροπρόθεσμες αλληλεπιδράσεις σε σχέση με τα βάρη που δίνονται για τις βραχυπρόθεσμες αλληλεπιδράσεις (Goodfellow et al., 2018). Το πρόβλημα αυτό αποτελεί ανασταλτικό παράγοντα για την χρήση RNN όταν υπάρχουν μεγάλες ακολουθίες δεδομένων και αντιμετωπίζεται με την χρήση μιας πιο σύνθετης δομής νευρωνικού δικτύου, του LSTM.

2.2.3 Αναδρομικά νευρωνικά δίκτυα μακράς και βραχείας μνήμης

Τα νευρωνικά δίκτυα μακράς και βραχείας μνήμης (Long Short-Term Memory) ανήκουν στην ευρύτερη κατηγορία των RNN, αλλά αποδεικνύονται πολύ πιο αποτελεσματικά σε έναν μεγάλο αριθμό προβλημάτων. Το βασικό χαρακτηριστικό τους είναι ότι μπορούν να ξεχωρίζουν τα πρόσφατα από τα παλιά δεδομένα δίνοντας σε αυτά διαφορετικά βάρη, ενώ παράλληλα έχουν την δυνατότητα να “ξεχνούν” την πληροφορία που θεωρούν αδιάφορη για την πρόβλεψη μιας επόμενης τιμής. Κατά αυτόν τον τρόπο, τα LSTM θεωρούνται πολύ πιο κατάλληλα για την διαχείριση μεγάλων ακολουθιών σε σχέση με τα υπόλοιπα RNN που στην ουσία μπορούν να θυμούνται μόνο μικρές ακολουθίες (Nelson et al., 2017).


Αναλυτικότερα, το LSTM (Hochreiter and Schmidhuber [1997]) είναι μια μονάδα, που δίνει την δυνατότητα μνήμης μέσω πυλών (gated memory units), στα νευρωνικά δίκτυα. Συγκεκριμένα, μια μονάδα LSTM έχει τρεις πύλες (gates) που διαχειρίζονται το περιεχόμενο της μνήμης. Αυτές οι πύλες στην ουσία είναι απλές λογαριθμικές συναρτήσεις σταθμισμένων ποσών, όπου τα βάρη παίρνουν τιμές μέσω της οπισθοδιάδοσης του λάθους. Παρόλο που αυτή η διαδικασία είναι πιο σύνθετη, αναμφίβολα είναι πολύ πιο αποτελεσματική καθώς μέσω αυτών των πυλών, το LSTM μαθαίνει ότι χρειάζεται να μάθει, θυμάται ότι χρειάζεται να θυμάται, και ανακαλεί ότι χρειάζεται να ανακαλέσει χωρίς να χρειάζεται κάποια ιδιαίτερη προπόνηση ή βελτιστοποίηση. Οι 3 προαναφερθείσες πύλες είναι η πύλη εισόδου (input gate), η forget gate και η πύλη εξόδου (output gate). Η πύλη εισόδου και η forget gate ουσιαστικά διαμορφώνουν το κύτταρο κατάστασης (cell state), που εκφράζει την μακροπρόθεσμη μνήμη. Η πύλη εξόδου διαμορφώνει το output vector ή αλλιώς hidden state, που είναι η μνήμη πάνω στην οποία γίνεται η εστίαση. Αυτό το σύστημα μνήμης δίνει την δυνατότητα στο δίκτυο να έχει μνήμη για μεγάλο χρονικό διάστημα, στοιχείο που έλλειπε από τα RNN [?7].

Το LSTM λοιπόν, έχει επίσης την μορφή αλυσίδας αλλά αυτή την φορά η επαναλαμβανόμενη διαδικασία είναι πιο σύνθετη. Συγκεκριμένα, αντί για ένα επίπεδο νευρωνικού δικτύου, υπάρχουν τέσσερα, όπως φαίνεται στην εικόνα 2.6, τα οποία αλληλεπιδρούν με έναν πολύ ιδιαίτερο τρόπο.




Εικόνα 2.6: Το LSTM σαν προέκταση ενός RNN

Όπως φαίνεται και στην εικόνα 2.6, κάθε γραμμή μεταφέρει ένα ολόκληρο διάνυσμα από την έξοδο ενός κόμβου στην είσοδο άλλων. Οι στρογγυλοί κύκλοι αναπαριστούν ενδεικτικές λειτουργίες, όπως για παράδειγμα πρόσθεση διανυσμάτων ενώ τα κίτρινα κουτάκια είναι επίπεδα, η αλλιώς στρώματα, νευρωνικών δικτύων. Ακόμη, η συγχώνευση γραμμών σημαίνει συνένωση, ενώ η διακλάδωση μιας γραμμής οδηγεί σε δύο διαφορετικά αντίγραφα. Το κλειδί στην λειτουργία των LSTM είναι το κύτταρο κατάστασης, δηλαδή η οριζόντια γραμμή που βρίσκεται στην κορυφή του διαγράμματος. Η γραμμή αυτή επεκτείνεται στην αλυσίδα με μικρές γραμμικές αλλαγές στο περιεχόμενό της (εικόνα 2.7).



Εικόνα 2.7: Το κύτταρο κατάστασης

Το LSTM έχει την δυνατότητα να αφαιρεί ή να προσθέτει πληροφορία στο κύτταρο κατάστασης, με την χρήση δομών που λέγονται πύλες (gates). Οι πύλες είναι ένας τρόπος για να επιλέγεται η διαδιδόμενη πληροφορία. Αποτελούνται από ένα σιγμοειδές στρώμα (sigmoid layer) νευρωνικού δικτύου και μια λειτουργία πολλαπλού πολλαπλασιασμού (εικόνα 2.8).




Εικόνα 2.8: Η μορφή μιας πύλης στο εσωτερικό του LSTM

Το σιγμοειδές στρώμα έχει σαν έξοδο αριθμούς από 0 έως 1 με στόχο να περιγράψει “πόσο από κάθε συνιστώσα πρέπει να περάσει”. Το 0 σημαίνει “μην αφήσεις τίποτα να περάσει” ενώ το ένα σημαίνει “άσε στιδήποτε να περάσει”. Ένα LSTM έχει τρεις τέτοιες πύλες που προστατεύουν και ελέγχουν το κύτταρο κατάστασης.

Το πρώτο βήμα για το LSTM είναι να αποφασιστεί ποια πληροφορία θα αφαιρεθεί από το κύτταρο κατάστασης. Αυτή η απόφαση γίνεται μέσω ενός σιγμοειδούς στρώματος που ονομάζεται forget gate layer. Αυτή η πύλη, βλέπει το h_{t-1} και το x_t και δίνει έναν αριθμό από 0 έως 1 στην έξοδό της για κάθε έναν αριθμό του κύτταρο κατάστασης C_{t-1} . Το 1 σημαίνει «κράτησέ το πλήρως» ενώ το 0 «ξέχασέ το εξ ολοκλήρου».

Το επόμενο βήμα είναι να αποφασιστεί ποια καινούρια πληροφορία θα αποθηκευτεί στο κύτταρο κατάστασης. Το βήμα αυτό αποτελείται από δύο μέρη. Πρώτα, ένα σιγμοειδές στρώμα που ονομάζεται «στρώμα πύλης εισόδου» (input gate layer) αποφασίζει ποιες τιμές θα ανανεωθούν και στη συνέχεια ένα tanh στρώμα δημιουργεί το διάνυσμα των νέων υποψηφίων τιμών \tilde{C}_t που προορίζονται να προστεθούν στο κύτταρο κατάστασης. Αυτά τα πρώτα δύο βήματα αποτυπώνονται στην εικόνα 2.9.



Εικόνα 2.9: Τα πρώτα βήματα στην εσωτερική λειτουργία ενός LSTM

Οι συσχετίσεις που προκύπτουν στην εικόνα 2.9 είναι οι ακόλουθες:


$$f_t = \sigma (W_f \cdot [h_{t-1}, x_t] + b_f)$$

$$i_t = \sigma (W_i \cdot [h_{t-1}, x_t] + b_i)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c)$$

Είναι ώρα, λοιπόν, να ανανεωθεί η κατάσταση του κυττάρου από την παλιά, C_{t-1} , στην καινούρια, C_t . Τα προηγούμενα βήματα έχουν ήδη αποφασίσει για το τι θα συμβεί και απομένει η

υλοποίησή του. Πολλαπλασιάζεται η παλιά κατάσταση με f_t , ξεχνώντας τα στοιχεία που αποφασίστηκε ότι θα ξεχαστούν πρωτότερα. Έπειτα προστίθεται το γινόμενο $i_t * \tilde{C}_t$, οι νέες υποψήφιες τιμές δηλαδή κανονικοποιημένες ανάλογα με το πόσο αποφασίστηκε να ανανεωθεί κάθε τιμή του κυττάρου κατάστασης (εικόνα 2.10).




Εικόνα 2.10: Η ανανέωση του κυττάρου κατάστασης

Η εν λόγω ανανέωση εκφράζεται από την ακόλουθη σχέση:

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$$

Τέλος, θα πρέπει να αποφασιστεί ποια θα είναι η έξοδος h_t . Η έξοδος θα βασίζεται στο κύτταρο κατάστασης, αλλά θα είναι μια φιλτραρισμένη εκδοχή του. Πρώτα, χρησιμοποιείται ένα σιγμοειδές στρώμα το οποίο αποφασίζει ποια μέρη του κυττάρου κατάστασης θα προωθηθούν στην έξοδο. Στη συνέχεια, εφαρμόζεται στις τιμές του κυττάρου κατάστασης η συνάρτηση tanh, ώστε να κινηθούν στο διάστημα από -1 έως 1 , και τέλος γίνεται πολλαπλασιασμός με την έξοδο του σιγμοειδούς στρώματος ώστε να καταλήξουν στην έξοδο μόνο τα επιλεγμένα μέρη (εικόνα 2.11) (Olah et al., 2015).



Εικόνα 2.11: Η έξοδος του LSTM

Οι σχέσεις που περιγράφονται από την εικόνα 2.11 είναι οι ακόλουθες:

$$o_t = \sigma (W_o [h_{t-1}, x_t] + b_o)$$

$$h_t = o_t * \tanh (C_t)$$

Κεφάλαιο 3: Αναδρομικά Νευρωνικά Δίκτυα Μακράς και Βραχείας Μνήμης για Χρηματιστηριακές Προβλέψεις

3.1 Εισαγωγή

Η πρώτη απόφαση που καλείται να πάρει κανείς όταν δημιουργεί ένα νευρωνικό δίκτυο μηχανικής μάθησης με επίβλεψη έχει να κάνει με το είδος της πρόβλεψης που θα κάνει. Οι δύο επιλογές λοιπόν στα πλαίσια αυτής της διπλωματικής, όπου θα υλοποιηθούν χρηματιστηριακές προβλέψεις, είναι οι ακόλουθες:

- η επίλυση ενός προβλήματος παρεμβολής, δηλαδή η πραγματοποίηση πρόβλεψης για κάποια μελλοντική τιμή της μετοχής
- η επίλυση ενός προβλήματος ταξινόμησης, δηλαδή η πραγματοποίηση πρόβλεψης σχετικά με την κατηγορία της προβλεπόμενης τιμής (π.χ. άνοδος ή κάθοδος της τιμής της μετοχής)


Προκειμένου να ληφθεί η τελική σχετική απόφαση, ανακλήθηκε ο απώτερος σκοπός των χρηματιστηριακών προβλέψεων, που δεν είναι άλλος από την υποβοήθηση των επενδυτών να πραγματοποιούν σωστά προβλέψεις, πετυχαίνοντας μεγάλα κέρδη με χαμηλό ρίσκο. Για έναν επενδυτή, η σωστή πρόβλεψη είτε για άνοδο είτε για κάθοδο σημαίνει κέρδος. Την ίδια στιγμή όμως, για κάθε επενδυτή, έχει τεράστια σημασία και το ποσοστό της μεταβολής, καθώς μεγάλες ποσοστιαίες μεταβολές έχουν σαν αποτέλεσμα μεγαλύτερα κέρδη.

Κατά συνέπεια, αντικείμενο ενδιαφέροντος της διπλωματικής αποτελεί η αύξηση ή μείωση της τιμής μιας μετοχής, καθώς στην πραγματικότητα κάτι τέτοιο πιθανά θα σηματοδοτούσε την αγορά ή πώληση μιας μετοχής. Αυτό δίνει αμέσως την κατεύθυνση για πρόβλημα κατηγοριοποίησης και συγκεκριμένα καταδεικνύει την ανάγκη για δυο κατηγορίες. Αυτή της ανόδου και εκείνη της καθόδου. Είναι όμως στην πραγματικότητα αυτή η πληροφορία επαρκής, η μήπως θα μπορούσε να εμπλουτιστεί; Η αλήθεια είναι πως από την στιγμή που μεγαλύτερες μεταβολές συνεπάγονται μεγαλύτερο περιθώριο κέρδους για κάποιον επενδυτή σε περίπτωση που τις ανιχνεύσει σωστά, έχει μεγαλύτερη αξία, ένα σύστημα που να μπορεί να παρέχει πληροφορία σχετικά και με αυτή την μεταβολή. Ο αποδοτικότερος τρόπος για να διατίθενται οι παραπάνω πληροφορίες είναι η κατασκευή ενός προγράμματος που να κάνει πρόβλεψη προβλήματος παρεμβολής. Θα γίνεται λοιπόν πρόβλεψη της πραγματικής τιμής και στην συνέχεια με υπολογισμό της διαφοράς από την τελευταία μέρα πριν την πρόβλεψη θα αντιστοιχίζεται η πρόβλεψη στην αντίστοιχη κατηγορία (ανόδου ή καθόδου).

3.2 Προτεινόμενη προσέγγιση

Η προτεινόμενη προσέγγιση λαμβάνει ως είσοδο τα δεδομένα των μετοχών, τα οποία στην συνέχεια τα δεδομένα φιλτράρονται για να διατηρηθεί μόνο η χρήσιμη πληροφορία και κανονικοποιούνται στο διάστημα $[0,1]$, ώστε οι ποσοτικές διαφορές στην τιμή μιας μετοχής να μην αποτελούν τροχοπέδη για τις προβλέψεις. Ακολούθως τα δεδομένα μετασχηματίζονται, ώστε να μπορούν να αποτυπώνουν την κατάλληλη πληροφορία. Συγκεκριμένα, για κάθε πρόβλεψη σαν είσοδος δίνονται x χαρακτηριστικά εισόδου από τις τελευταίες y μέρες πριν την ημέρα που πραγματοποιείται πρόβλεψη. Το νευρωνικό δίκτυο, προκειμένου να μπορεί να αντιληφθεί τις εξαρτήσεις κατά την προπόνηση, λαμβάνει σαν εκάστοτε είσοδο έναν πίνακα διαστάσεων $[y,x]$. Αφού τεσταριστεί το

νευρωνικό δίκτυο σε άγνωστα κατά την προπόνηση δεδομένα, τα αποτελέσματα μετασχηματίζονται εκ νέου, προκειμένου να μπορεί να προσδιοριστεί αν τελικά η πορεία της μετοχής προβλέπεται ανοδική ή καθοδική. Τελικά τα αποτελέσματα αξιολογούνται προκειμένου να διαπιστωθεί κατά πόσο το πρόγραμμα επιλύει σωστά τόσο το πρόβλημα της ταξινόμησης όσο και το πρόβλημα της παρεμβολής. Η διαδικασία αυτή, η οποία αποτυπώνεται στο ακόλουθο διάγραμμα, επαναλαμβάνεται και εξάγονται συγκεντρωτικές στατιστικές τιμές.



Εικόνα 3.1: Διάγραμμα ροής του προγράμματος

3.3 Αρχιτεκτονική του νευρωνικού δικτύου και διαδικασία προπόνησης

Στα πλαίσια της διπλωματικής, αφενός χρειάστηκε να ληφθούν αποφάσεις σχετικά με την επιλογή παραμέτρων όπως του κατάλληλου αριθμού επιπέδων, του κατάλληλου αριθμού νευρώνων, του ποσοστού του περιορισμού ενεργοποίησης (dropout), του αλγορίθμου βελτιστοποίησης (optimizer) και της απώλειας (loss). Η μέθοδος που χρησιμοποιήθηκε λοιπόν κατά κύριο λόγο για την επιλογή των παραπάνω, είναι το grid search, δηλαδή εξαντλητική αναζήτηση με στόχο τον υπολογισμό των βέλτιστων τιμών των παραπάνω παραμέτρων. Παράλληλα, οι κατευθυντήριες γραμμές για την εύρεση των βέλτιστων παραμέτρων προέκυψαν από την βιβλιογραφία, με χαρακτηριστικό παράδειγμα να αποτελεί η επιλογή optimizer που συμπίπτει με αυτή του Karmiani et al. (2019).

Επιπροσθέτως, ιδιαίτερης προσοχής χρήζει η κατάλληλη επιλογή συνόλου δεδομένων εκπαίδευσης (training set), validation set και test set. Συγκεκριμένα, το μοντέλο μας προπονείται με το σύνολο των δεδομένων εκπαίδευσης και το validation set και στην συνέχεια για την αξιολόγηση του συστήματος μας χρησιμοποιείται το test set. Είναι σημαντικό, σε τέτοιου είδους προβλήματα, να μην γίνεται κάποιο ανακάτεμα στα δεδομένα προτού γίνει διαχωρισμός στα 3 παραπάνω σύνολα δεδομένων, παρόλο που γενικά ενδείκνυται το ανακάτεμα γενικά στα νευρωνικά δίκτυα. Αυτό συμβαίνει διότι οι εισοδοί, στην συγκεκριμένη περίπτωση, έχουν επικαλυπτόμενη πληροφορία μεταξύ τους. Επομένως, αφενός αν γίνει ανακάτεμα πριν τον διαχωρισμό στα σύνολα δεδομένων εκπαίδευσης και validate set τότε το σύστημα θα κάνει κατά την προπόνηση αξιολόγηση (evaluation) με δεδομένα που εν μέρη έχει ήδη δει και θα είναι προκατειλημένο θετικά, με αποτέλεσμα να μην μαθαίνει εν τέλει όλες τις εξαρτήσεις που θα μπορούσε να μάθει. Από την άλλη, σε περίπτωση που πραγματοποιηθεί κάποιο ανακάτεμα πριν την απομόνωση του test set, λόγω της κρυμμένης αυτής επικάλυψης, η προσέγγιση του προβλήματος καταλήγει να είναι λάθος.

Τέλος, συχνά υπάρχουν παρερμηνείες σχετικά με την επίδραση του μεγέθους δείγματος (batch size) και των epochs στην λειτουργία ενός νευρωνικού δικτύου. Αξίζει λοιπόν να σημειωθεί πως για συγκεκριμένο αριθμό, έστω n , ζευγαριών εισόδων-εξόδων το batch size θα προσδιορίσει μετά από την επεξεργασία πόσων ζευγαριών θα γίνει ανανέωση των βαρών του νευρωνικού δικτύου. Αντιθέτως, ο αριθμός των epochs θα προσδιορίσει πόσες φορές θα τροφοδοτηθούν στα νευρωνικό μας τα n ζευγάρια. Λαμβάνοντας υπόψη τα παραπάνω, οι παράμετροι στις οποίες καταλήξαμε για το νευρωνικό δίκτυο της προτεινόμενης προσέγγισης για την πρόβλεψη χρηματιστηριακών μεγεθών αναγράφονται στον πίνακα 3.1.

Πίνακας 3.1: Δομή νευρωνικού δικτύου

<i>Αριθμός επιπέδων</i>	2
<i>DROPOUT</i>	0.1
<i>LOSS</i>	Mse
<i>BATCH SIZE</i>	256
<i>EPOCHS</i>	50
<i>OPTIMIZER</i>	Adam

Ακόμη, το πρώτο επίπεδο του νευρωνικού δικτύου έχει 256 νευρώνες ενώ το δεύτερο έχει 128. Παράλληλα έχει χρησιμοποιηθεί Early Stopping για να αποφευχθεί η ανεπιθύμητη προπόνηση (overfitting) (Prechelt, 1998). Συγκεκριμένα, μέσω αυτής της τεχνικής είναι εφικτό ο αλγόριθμος να σταματάει όταν μετά από συγκεκριμένα epochs η απόδοση του νευρωνικού δικτύου σταματάει να βελτιώνεται.

3.4 Δεδομένα εισόδου και δεδομένα εξόδου

Το νευρωνικό μας δίκτυο δέχεται σαν την εκάστοτε είσοδο έναν δισδιάστατο πίνακα και δίνει σαν έξοδο μια τιμή. Οι διαστάσεις του πίνακα προσδιορίζονται από την παρελθοντική περίοδο ενδιαφέροντος και από τις παραμέτρους που έχει γίνει υπόθεση πως επηρεάζουν την πρόβλεψη. Οι διαδοχικές γραμμές στον πίνακα εκφράζουν τις διαφορετικές διαδοχικές μέρες που έχει θεωρηθεί πως επηρεάζουν την πρόβλεψη, ενώ οι στήλες εκφράζουν τα διάφορα χαρακτηριστικά εισόδου. Πιθανά χαρακτηριστικά είναι οι ημερήσιες χρηματιστηριακές τιμές που αφορούν είτε την μετοχή για την οποία θα γίνει πρόβλεψη, είτε συσχετιζόμενους δείκτες. Αντίστοιχα, η έξοδος του νευρωνικού δικτύου μας είναι η τιμή κλεισίματος της μετοχής ενδιαφέροντος για προεπιλεγμένο ορίζοντα πρόβλεψης.

Με την επιλογή για την παρελθοντική περίοδο ενδιαφέροντος και τον ορίζοντα πρόβλεψης, γίνεται εφικτή η δημιουργία μιας αντιστοιχίας εισόδων και εξόδων. Με άλλα λόγια δημιουργούνται ζευγάρια εισόδων-εξόδων. Για την εκάστοτε πρόβλεψη, δηλαδή για κάθε ζευγάρι, λαμβάνονται υπόψη οι τελευταίες 45 μέρες για πρόβλεψη 5 μέρες μετά. Στην συνέχεια πρέπει να αποσαφηνιστεί πόσα από αυτά τα ζευγάρια είναι αποδοτικότερο να δοθούν τελικά στο σύστημά μας ώστε αυτό να μάθει τις απαραίτητες συσχετίσεις και εξαρτήσεις. Η απόφαση αυτή, χρήζει ιδιαίτερης προσοχής καθώς πολλά ζευγάρια με άχρηστη πληροφορία θα μπορούσαν να αποπροσανατολίσουν το νευρωνικό δίκτυο, ενώ μικρός αριθμός συνολικών ζευγαριών θα μπορούσε να αποδειχθεί ελλιπής σχετικά με την πληροφορία που παρέχει.

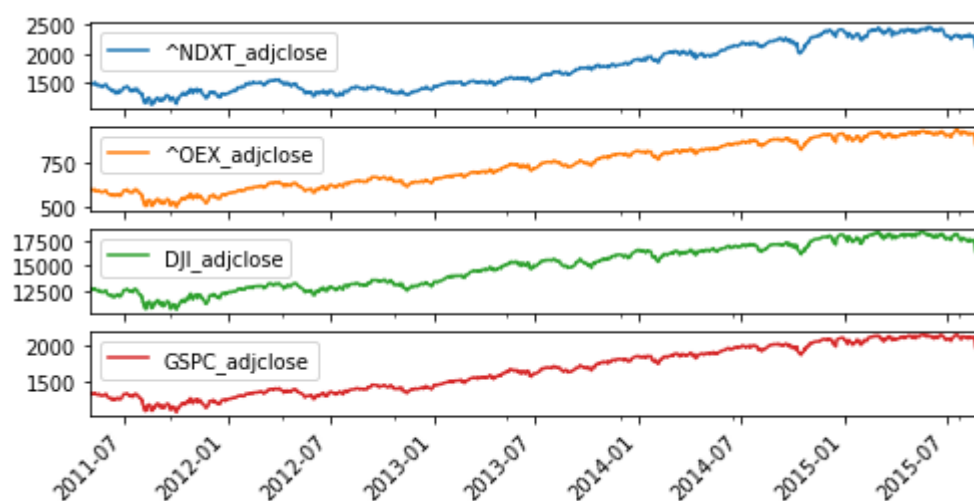
Τα χαρακτηριστικά εισόδου που έχουν χρησιμοποιηθεί, προκύπτουν από την επιλογή ημερησίων δεδομένων της εκάστοτε μετοχής και σχετικών χρηματιστηριακών δεικτών. Τα ημερήσια αυτά δεδομένα είναι οι τιμές ανοίγματος, κλεισίματος, η προσαρμοσμένη τιμή κλεισίματος, το υψηλό ημέρας, το χαμηλό ημέρας και ο όγκος, ενώ οι χρηματιστηριακοί δείκτες με τους οποίους έχουν πραγματοποιηθεί πειράματα είναι οι ακόλουθοι:

- Ο δείκτης S&P 500 (^GSPC) η αλλιώς Standard & Poor's 500 που είναι ένας δείκτης που έχει να κάνει με την κεφαλαιοποίηση της αγοράς, δηλαδή με την χρηματιστηριακή αξία των επιχειρήσεων που προκύπτει αν πολλαπλασιαστεί ο αριθμός των μετοχών τους επι την

τρέχουσα χρηματιστηριακή αξία των μετοχών και αφορά 500 από τις μεγαλύτερες εισηγμένες στο χρηματιστήριο εταιρείες στις Η.Π.Α. .

- Ο δείκτης S&P 100 (^OEX) , που είναι ένα υποσύνολο του δείκτη S&P 500, και είναι φτιαγμένος για να μετράει την επίδοση μεγάλων (large-cap) εταιρειών στις Η.Π.Α. . Ο δείκτης αυτός περιλαμβάνει 100 “blue chip” εταιρείες από ποικίλους κλάδους.
- Ο Dow Jones Industrial Average (^DJI) που είναι ένας χρηματιστηριακός δείκτης που αφορά 30 μεγάλες, “blue chip” εταιρείες που συναλλάσσονται στο New York Stock Exchange (NYSE) και στο NASDAQ. Ο DJIA είναι ο δεύτερος μεγαλύτερος χρηματιστηριακός δείκτης για τις Η.Π.Α. και κατασκευάστηκε για να λειτουργεί σαν πληρεξούσιο για την ευημερία της οικονομίας των Η.Π.Α.
- Ο δείκτης NASDAQ-100 Technology Sector (^NDXT) είναι ένας σταθμισμένος δείκτης που αφορά εταιρείες που κατηγοριοποιούνται ως τεχνολογικές σύμφωνα με το σύστημα ταξινόμησης Industry Classification Benchmark (ICB).

Ενδεικτικά, οι τιμές κλεισίματος των παραπάνω δεικτών διαφαίνονται για την χρονική περίοδο ενδιαφέροντος στον πίνακα 3.2.



Εικόνα 3.2: Τιμές κλεισίματος χρήσιμων χρηματιστηριακών δεικτών

3.5 Οι μέθοδοι αξιολόγησης

3.5.1 Εισαγωγή

Το νευρωνικό μας δίκτυο, επιλύει πρόβλημα παρεμβολής, πράγμα που σημαίνει πως γίνεται πρόβλεψη της πραγματικής τιμής της μετοχής. Στην συνέχεια όμως, με υπολογισμό της διαφοράς από την τελευταία μέρα πριν την πρόβλεψη, αντιστοιχίζεται η πρόβλεψη στην αντίστοιχη κατηγορία (ανόδου ή καθόδου). Κατά συνέπεια, μέσα από την ποτεινόμενη προσέγγιση επιλύουμε τόσο πρόβλημα παρεμβολής όσο και πρόβλημα ταξινόμησης και θα πρέπει αμφότερα να αξιολογηθούν.

3.5.2 Αξιολόγηση της εκπαίδευσης και του νευρωνικού(πρόβλημα παρεμβολής)

Σχετικά με την επίλυση του προβλήματος παρεμβολής, υπάρχει αφενός ένα πρώτο επίπεδο αξιολόγησης, το οποίο πραγματοποιείται κατά την διάρκεια της προπόνησης με την οπτική παρατήρηση των διαγραμμάτων για loss και mean absolute error. Τα διαγράμματα αυτά αποτυπώνουν

το loss και το mean absolute error τόσο για το σύνολο δεδομένων εκπαίδευσης όσο και για το validation set και είναι χρήσιμα για να αποκτηθεί από το στάδιο της προπόνησης μια αίσθηση σχετικά με το αν το νευρωνικό δίκτυο τελικά μαθαίνει τα δεδομένα. Παράλληλα με οπτική παρατήρηση, είναι εφικτό συνήθως να γίνει κατανοητό αν έχει γίνει κάποιο overfit.

Διαισθητικά, αν οι γραφικές παραστάσεις αρχίσουν να συγκλίνουν σε μια ευθεία $x=a$, αυτό σημαίνει πως το σύστημα δεν βελτιώνεται άλλο. Προκύπτει λοιπόν ότι είναι αισιόδοξο, οι γραφικές παραστάσεις τόσο για το σύνολο δεδομένων εκπαίδευσης όσο και για το validation set να συγκλίνουν στην $x=0$, δηλαδή να συγκλίνουν σε μηδενικό loss και mean absolute error, καθώς ο αριθμός των epochs μεγαλώνει. Παράλληλα, δεν είναι επιθυμητή η σύγκλιση για πάρα πολλά epochs, καθώς εφόσον η σύγκλιση υποδηλώνει πως το σύστημα δεν βελτιώνεται άλλο θα μπορούσε να υπάρξει overfit.

Επίσης, για την αξιολόγηση στα δεδομένα test, χρησιμοποιούνται στα πλαίσια της διπλωματικής δύο μετρικές. Η πρώτη μετρική είναι το Mean Absolute Error (MAE) το οποίο είναι στην ίδια κλίμακα με τα δεδομένα που μετριοούνται. Παρόλα αυτά δεν μας είναι χρήσιμο για την σύγκριση του σφάλματος για δεδομένα διαφορετικής κλίμακας.

$$Mae = \frac{1}{n} \sum |f_t - a_t|$$

Για τον λόγο αυτό χρησιμοποιείται και το Mean Absolute Percentage Error (MAPE) που είναι το absolute error κανονικοποιημένο ως προς την πραγματική τιμή, με αποτέλεσμα να δίνει την δυνατότητα για σύγκριση του error για δεδομένα διαφορετικής κλίμακας.

$$Mape = \frac{1}{n} \sum \frac{|f_t - a_t|}{a_t}$$

3.5.3 Αξιολόγηση μετά την μετατροπή σε πρόβλημα ταξινόμησης

Σε προβλήματα ταξινόμησης 2 κατηγοριών είθισται η μια κατηγορία να χαρακτηρίζεται ως σχετική (positive) και η άλλη ως μη σχετική (negative). Η επιλογή για το ποια κατηγορία θα θεωρηθεί positive και ποια negative είναι στο χέρι του σχεδιαστή του συστήματος. Σε προβλήματα που γίνεται εστίαση στην μια κατηγορία είναι προφανές και ότι η κατηγορία ενδιαφέροντος θα έχει τον ρόλο positive. Στην περίπτωση μας όμως, είναι απολύτως ισοδύναμο το πως θα διαχωριστούν οι κατηγορίες. Θεωρείται λοιπόν η άνοδος της τιμής μιας μετοχής σαν positive (+) και η κάθοδος της σαν negative(-). Επομένως, το TP (true positive) εκφράζει τις άνοδους που έχουν σωστά προβλεφθεί από το σύστημα σαν άνοδοι. Το FP (false positive) εκφράζει τις καθόδους που έχουν εσφαλμένα προβλεφθεί σαν άνοδοι. Αντιστοίχως το TN (true negative) εκφράζει τις καθόδους που έχουν σωστά προβλεφθεί σαν κάθοδοι και το FN (false negative) εκφράζει τις άνοδους που έχουν λανθασμένα προβλεφθεί σαν κάθοδοι.

Για την κατασκευή του πίνακα 3.2 θεωρείται πως καθε αντικείμενο συνδέεται με μια δυαδική ετικέτα (label) που αντιπροσωπεύει την πραγματική ορθότητα του αντικειμένου όσον αφορά την διαδικασία που διεξάγεται. Επιπλέον, το σύστημα παράγει μια εκχώρηση (assignment) z που δείχνει αν προβλέπει ότι το αντικείμενο είναι σωστό (σχετικό) ή όχι. Ακόμη, το + και το - εκφράζουν αντιστοίχα το σχετικό (positive) και το μη σχετικό (negative).

Πίνακας 3.2: Confusion Matrix

		Assignment z	
		+	-
Label ℓ	+	TP	FN
	-	FP	TN

Με σημείο αναφοράς τον πίνακα 3.2 υπάρχουν τέσσερις βασικές μετρικές που θα μας απασχολήσουν για την αξιολόγηση της προτεινόμενης προσέγγισης. Η πρώτη μετρική είναι το Accuracy, το οποίο εκφράζει τον λόγο των σωστών προβλέψεων ως προς τις συνολικές προβλέψεις.

$$Accuracy = \frac{\text{Number of correct predictions}}{\text{Total number of predictions}}$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

Ακόμη, από τον πίνακα 3.2 μπορεί κανείς να υπολογίσει τα Precision (p) και Recall (r) όπως φαίνεται ακολούθως, ενώ λαμβάνοντας τον σταθμισμένο αρμονικό μέσο όρο των precision και recall προκύπτει το F-score. Στα πειράματά μας έχει υπολογιστεί η F1, θέτοντας όπου β την τιμή 1. Τα precision και recall έχουν φυσική ερμηνεία που βοηθά στην καλύτερη κατανόησή τους. Συγκεκριμένα, το precision μπορεί να ερμηνευθεί ως η πιθανότητα ένα αντικείμενο να είναι σχετικό (positive) δεδομένου ότι επιστρέφεται από το σύστημα σαν positive. Από την άλλη, recall είναι η πιθανότητα ένα σχετικό (positive) αντικείμενο να επιστραφεί από το σύστημα σαν positive. Με άλλα λόγια, στο παράδειγμά μας, το precision εκφράζει την πιθανότητα όταν το σύστημα προβλέπει άνοδο της μετοχής να υπάρχει όντως άνοδος και το recall εκφράζει την πιθανότητα μια άνοδος να προβλεφθεί σωστά σαν άνοδος (Goutte et al, 2005).

$$p = P(\ell = + / z = +) \quad r = P(z = + / \ell = +)$$

$$p = \frac{TP}{TP + FP} \quad r = \frac{TP}{TP + FN}$$

$$F_\beta = (1 + \beta^2) \frac{pr}{r + \beta^2 p} = \frac{(1 + \beta^2)TP}{(1 + \beta^2)TP + \beta^2 FN + FP}$$

Υπάρχουν ποικίλα παραδείγματα όπου η κατηγορία positive έχει μεγαλύτερη σημασία με αποτέλεσμα οι παραπάνω μετρικές να είναι αρκετές. Ένα τέτοιο παράδειγμα αποτελεί ο εντοπισμός καρκίνου. Σε μια τέτοια περίπτωση, δεδομένου ότι ο καρκίνος θα αντιστοιχούσε στην κατηγορία positive, υψηλές τιμές των παραπάνω μετρικών θα έδειχναν ότι το σύστημα λειτουργεί αποτελεσματικά. Το ίδιο ισχύει αν προσπαθήσει κανείς να εντοπίσει αν υπάρχουν σκύλοι σε ένα σύνολο εικόνων. Τι ισχύει όμως αν είναι γνωστό πως σε κάθε εικόνα θα υπάρχει η ένας σκύλος ή μια γάτα; Σε αυτή την περίπτωση θα αντιστοιχούσε στο positive ο σκύλος ή η γάτα; Η απάντηση είναι πως για να αξιολογηθεί ένα τέτοιου είδους σύστημα επαρκώς θα πρέπει να υπολογιστούν οι παραπάνω μετρικές δύο φορές, λαμβάνοντας σαν positive διαφορετική κατηγορία κάθε φορά. Για τον λόγο αυτό

υπάρχουν οι έννοιες του inverse precision, inverse recall και inverse F1, οι οποίες θα χρησιμοποιηθούν στα πλαίσια της αξιολόγησης του μοντέλου μας.

Κεφάλαιο 4: Αποτελέσματα

4.1 Υλοποίηση

Η γλώσσα προγραμματισμού που χρησιμοποιήθηκε για την κατασκευή του αλγορίθμου μας είναι η python και η πλατφόρμα στην οποία έγινε ο προγραμματισμός είναι το Spyder, που είναι το επιστημονικό περιβάλλον ανάπτυξης για Python. Το συγκεκριμένο περιβάλλον ανάπτυξης συμπεριλαμβάνεται στο Anaconda, το λογισμικό που θεωρείται ως η ευκολότερη επιλογή για τον προγραμματισμό σε python/R για data science και μηχανική μάθηση σε έναν υπολογιστή. Ακολουθώντας, για την κατασκευή του νευρωνικού δικτύου χρησιμοποιήθηκαν τα Keras και Tensorflow. Το TensorFlow είναι μια πλατφόρμα ανοιχτού κώδικα για μηχανική μάθηση η οποία εμπεριέχει ένα ευέλικτο και περιεκτικό οικοσύστημα εργαλείων, βιβλιοθηκών και μιας κοινότητας που επιτρέπει στους ερευνητές να προχωρούν την επιστήμη της τεχνητής νοημοσύνης. Το Keras από την άλλη, αποτελεί ένα learning API γραμμένο σε python και τρέχει στην πλατφόρμα μηχανική μάθησης TensorFlow. Ενδεικτικά, το keras χρησιμοποιείται από εταιρείες όπως Netflix, Uber, Yelp, Instacart, Zocdoc, Square και πολλές άλλες. Επιπροσθέτως, αξίζει να σημειωθεί πως τα Keras και TensorFlow 2.0 χρησιμοποιούνται μαζί από την επιστημονική κοινότητα και είναι πρώτα σε προτίμηση όσον αφορά τις αναφορές σε επιστημονικά περιοδικά δημοσιευμένα στο Google Scholar. Επιπλέον, το Keras έχει υιοθετηθεί από τους ερευνητές σε μεγάλους επιστημονικούς οργανισμούς όπως CERN και NASA. Ακόμη, τα δεδομένα των μετοχών λαμβάνονται από το Yahoo Finance.

4.2 Πειραματική προσέγγιση

Στο συγκεκριμένο κεφάλαιο παρουσιάζονται τα αποτελέσματα των πειραμάτων για τις μετοχές των τεχνολογικών εταιρειών APPLE, IBM, NVDA, MICROSOFT, TESLA και συγκρίνονται για διαφορετικά χαρακτηριστικά εισόδου.

Επειδή τα αποτελέσματα για ένα τρέξιμο (τεστάρισμα) ενός νευρωνικού δικτύου κρύβουν τυχαιότητα, η παρουσίαση ενός μεμονωμένου πειράματος δεν μπορεί να θεωρηθεί αντιπροσωπευτική. Για την πλήρη αξιολόγηση επομένως του μοντέλου μας, για τις ίδιες παραμέτρους υλοποιούνται 50 πειράματα και καταγράφονται:

1. Ο μέσος όρος των Accuracy, Precision, Recall, F1 (Nelson et al., 2017) και οι Inverse μετρικές αυτών, το Mae και το Mape.
2. Φυσικά, ούτε αυτές οι τιμές μπορούν από μόνες τους να θεωρηθούν πλήρεις σχετικά με την επίδοση του συστήματός μας. Εκτός από τις απόλυτες αυτές τιμές, είναι χρήσιμο το πόσο κοντά συγκεντρώνονται οι τιμές τους αλλά και πόσο πολύ μπορούν να απομακρυνθούν. Οι πιο διαδεδομένες τεχνικές για την μελέτη των παραπάνω μεγεθών είναι το variation και standard deviation όπως εφαρμόζονται και από τον Karmiani et al. (2019) και βρίσκουν εφαρμογή στο Accuracy του μοντέλου μας.
3. Ακόμη, με στόχο την οπτικοποίηση της συμπεριφοράς όλων των τιμών για τις οποίες έχουν βρεθεί μέσοι όροι, στα πλαίσια της διπλωματικής κατασκευάζονται ενδεικτικά διαγράμματα που αποτυπώνουν ξεκάθαρα την συμπεριφορά της εκάστοτε μετρικής. Συγκεκριμένα, ο στόχος των διαγραμμάτων είναι η προβολή του κατά πόσο κατά την διάρκεια των τρεξιμάτων οι μεμονωμένες τιμές συγκεντρώνονται κοντά στην μέση τιμή.

Όσον αφορά την αξιολόγηση της ταξινόμησης, αξίζει να σημειωθεί και για την συνέχεια πως η βασική μετρική μελέτης είναι το Accuracy. Οι υπόλοιπες μετρικές όμως είναι χρήσιμες ώστε να μας

εξασφαλίζουν πως το Accuracy είναι μεγάλο για τους σωστούς λόγους. Συγκεκριμένα, οι μετρικές Recall, Precision, F1 και οι inverse μετρικές αυτών μας εξασφαλίζουν ότι το εκάστοτε σύστημά μας προβλέπει αποτελεσματικά τόσο ανόδους όσο και καθόδους. Ακόμη, τα Standard Deviation και Variance αλλά και οι εικόνες που αναπαριστούν τις συγκεντρώσεις τιμών, μας εξασφαλίζουν ότι οι υπολογισμένες τιμές είναι όντως αντιπροσωπευτικές.

Προτού γίνει σύγκριση για διαφορετικά χαρακτηριστικά εισόδου, έχουν πραγματοποιηθεί πέντε πειράματα για την μετοχή της Apple για διαφορετικά χαρακτηριστικά εισόδου. Ο πειραματισμός με διαφορετικά χαρακτηριστικά εισόδου, έχει σαν στόχο την εύρεση τελικά ενός συνόλου χαρακτηριστικών που να κάνει την πρόβλεψη βέλτιστη. Στα πειράματα που ακολουθούν λοιπόν, συμπεριλαμβάνεται η απλούστερη δυνατή προσέγγιση, που επιτυγχάνεται με την παρουσία της προσαρμοσμένης τιμής κλεισίματος σαν μοναδικό χαρακτηριστικό εισόδου και παράλληλα παρατηρείται ένα πείραμα που ξεχωρίζει ως προς την απόδοσή του. Στην συνέχεια λοιπόν, για όλες τις υπόλοιπες μετοχές πραγματοποιούνται και συγκρίνονται δύο πειράματα, ένα για την απλούστερη δυνατή προσέγγιση και ένα με το προτεινόμενο σύνολο χαρακτηριστικών εισόδου με το οποίο φυσικά επιτεύχθηκε η βέλτιστη απόδοση για την μετοχή της Apple.

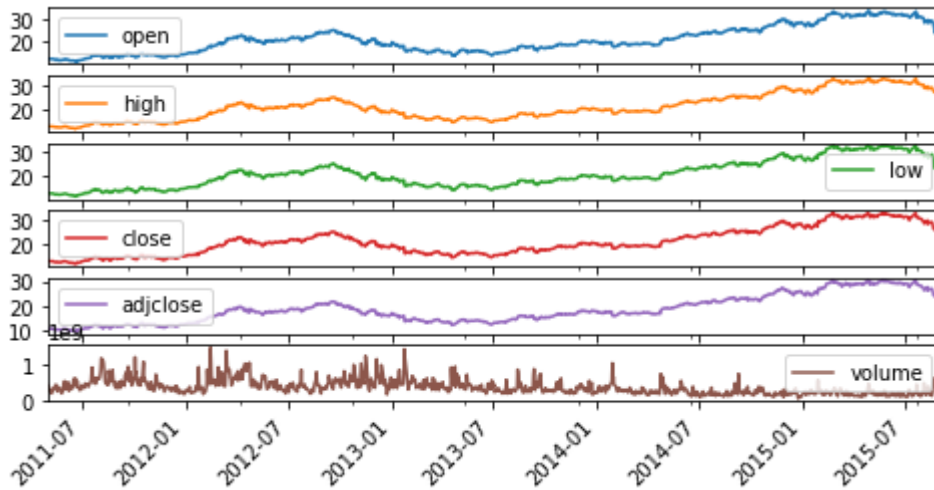
Για κάθε μετοχή που μελετάται, έχουν ληφθεί δεδομένα από 2011-05-02 μέχρι 2015-09-04. Συγκεκριμένα, έχουν ληφθεί η τιμή ανοίγματος (open) και η τιμή κλεισίματος (close) της μετοχής, το υψηλό ημέρας (high) και το χαμηλό ημέρας (low), η τιμή του όγκου (volume) και η προσαρμοσμένη τιμή κλεισίματος (adjusted close). Οι τιμές αυτές απεικονίζονται μάλιστα γραφικά για κάθε μετοχή πριν από την καταγραφή των πειραμάτων της.

Από τις ημερομηνίες αυτές κατασκευάζονται 993 ζευγάρια εισόδων-εξόδων τα οποία χρησιμοποιούνται κατά την προπόνηση και άλλα 53 ζευγάρια τα οποία χρησιμοποιούνται για την αξιολόγηση. Ακόμη, από τα ζευγάρια που χρησιμοποιούνται για την προπόνηση, το 90% χρησιμοποιείται σαν σύνολο δεδομένων εκπαίδευσης, και το υπόλοιπο 10% αντιστοιχίζεται στο validation set.

4.3 Πειράματα

4.3.1 Προβλέψεις για την μετοχή της Apple

Η αποτελεσματική πρόβλεψη για την μετοχή της Apple, ήταν σε πρώτο στάδιο το επίκεντρο του ενδιαφέροντός μας, στα πλαίσια της διπλωματικής αυτής. Στην εικόνα 4.1, διαφαίνονται οι ημερήσιες τιμές της μετοχής, για την περίοδο ενδιαφέροντος, όπως έχουν ληφθεί από το yahoo finance.




Εικόνα 4.1: Ημερήσιες τιμές για την μετοχή της Apple

Πείραμα 4.1

Σαν χαρακτηριστικό εισόδου στο εν λόγω πείραμα θεωρήθηκε μόνο η προσαρμοσμένη τιμή κλεισίματος της μετοχής. Ακολουθούν στον πίνακα 4.1 οι τιμές των μετρικών για το πρόβλημα της παρεμβολής που επιλύουμε.


Πίνακας 4.1: Μέση τιμή του Mae και του Mape για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα και με μοναδικό χαρακτηριστικό την προσαρμοσμένη τιμή κλεισίματος.

Mae	Mape
0.8787	3.3182



Εικόνα 4.2: Συγκέντρωση τιμών για το Mape για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα και με μοναδικό χαρακτηριστικό εισόδου την προσαρμοσμένη τιμή κλεισίματος.

Φυσικά, οι παραπάνω μέσες τιμές από μόνες τους κρύβουν αρκετή πληροφορία σχετικά με την απόδοση του νευρωνικού μας δικτύου. Είναι δόκιμο λοιπόν, να δείξουμε την συγκέντρωση και το εύρος των τιμών των παραπάνω μετρικών κατά την διάρκεια των 50 πειραμάτων και για τον λόγο αυτό παρέχονται οι εικόνες 4.2 και 4.3.




Εικόνα 4.3: Συγκέντρωση τιμών για το Mae για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, με μοναδικό χαρακτηριστικό εισόδου την προσαρμοσμένη τιμή κλεισίματος.

Συμπληρωματικά, ακολουθούν τα αποτελέσματα όπως προκύπτουν από την αξιολόγηση των προβλέψεων για το πρόβλημα της ταξινόμησης.

Πίνακας 4.2: Μέση τιμή για τους δείκτες Accuracy, Recall, Precision και F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, με μοναδικό χαρακτηριστικό εισόδου την προσαρμοσμένη τιμή κλεισίματος.

<i>Accuracy</i>	<i>Recall</i>	<i>Precision</i>	<i>F1</i>
0.6108	0.8737	0.4638	0.6037




Εικόνα 4.4: Συγκέντρωση των τιμών για τους δείκτες Accuracy, Recall, Precision και F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, με μοναδικό χαρακτηριστικό εισόδου την προσαρμοσμένη τιμή κλεισίματος.

Πίνακας 4.3: Στατιστικές τιμές για το Accuracy, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, με μοναδικό χαρακτηριστικό εισόδου την προσαρμοσμένη τιμή κλεισίματος.

<i>Standard Deviation of Accuracy</i>	<i>Variance of Accuracy</i>	<i>Population Standard Deviation of Accuracy</i>	<i>Population Variance of Accuracy</i>
0.0820	0.0067	0.0812	0.0066

Πίνακας 4.4: Μέση τιμή για τους δείκτες Inverse Recall, Inverse Precision και Inverse F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, με μοναδικό χαρακτηριστικό εισόδου την προσαρμοσμένη τιμή κλεισίματος.

<i>'Inverse Recall'</i>	<i>'Inverse Precision'</i>	<i>'Inverse F1'</i>
0.4793	0.8775	0.6127



Εικόνα 4.5: Συγκέντρωση των τιμών για τους δείκτες **Inverse Recall**, **Inverse Precision** και **Inverse F1**, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, με μοναδικό χαρακτηριστικό εισόδου την προσαρμοσμένη τιμή κλεισίματος

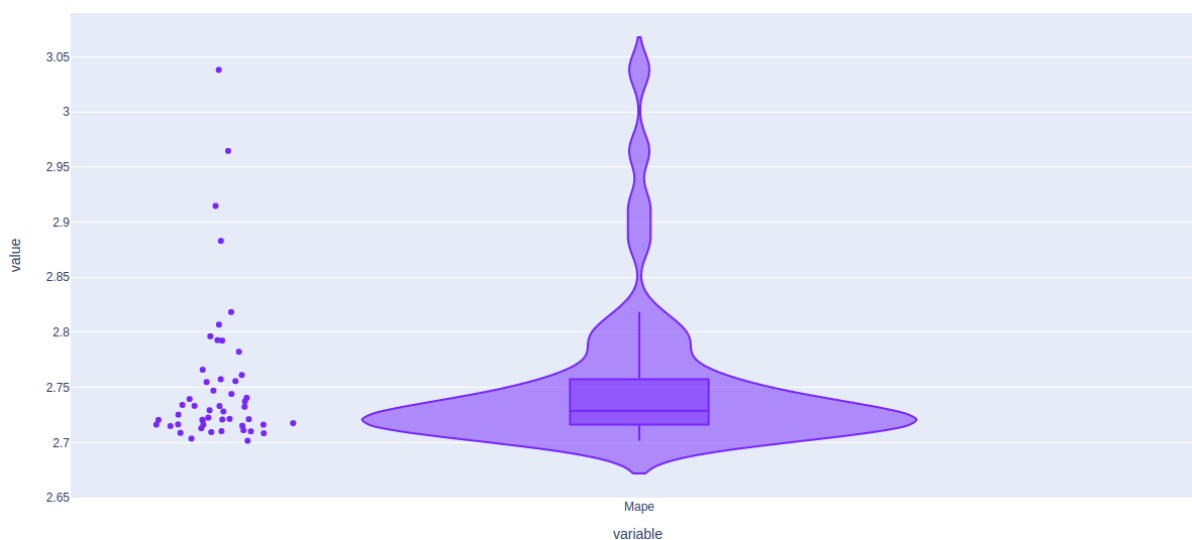
Πείραμα 4.2

Με στόχο να γίνει πιο αποτελεσματικό το νευρωνικό μας δίκτυο, στο συγκεκριμένο πείραμα εμπλουτίζεται η πληροφορία που δίνεται σαν εισόδος. Σαν χαρακτηριστικά εισόδου στο συγκεκριμένο πείραμα λοιπόν, θεωρήθηκαν τα ημερήσια χρηματιστηριακά μεγέθη της συγκεκριμένης μετοχής (τιμή ανοίγματος, τιμή κλεισίματος, υψηλό χαμηλό, όγκος και προσαρμοσμένη τιμή κλεισίματος). Τα αποτελέσματα όπως προκύπτουν από την αξιολόγηση των προβλέψεων για το πρόβλημα της παρεμβολής δίνονται στον πίνακα 4.5.


Πίνακας 4.5: Μέση τιμή του **Mae** και του **Mape** για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, με χαρακτηριστικά εισόδου τις ημερήσιες τιμές της μετοχής.

<i>Mae</i>	<i>Mape</i>
0.7393	2.7529

Οι εικόνες 4.6 και 4.7 βοηθούν ώστε να διατίθεται όλη η πληροφορία σχετικά με τις παραπάνω τιμές.



Εικόνα 4.6: Συγκέντρωση τιμών για το Mape για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, με χαρακτηριστικά εισόδου τις ημερήσιες τιμές της μετοχής.

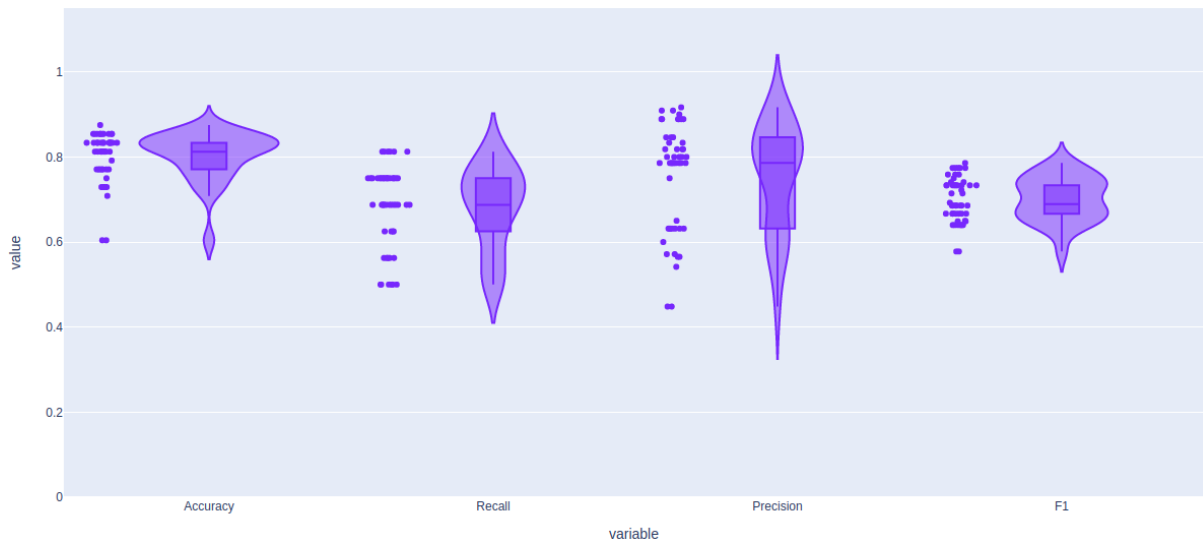


Εικόνα 4.7: Συγκέντρωση τιμών για το Mae για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, με χαρακτηριστικά εισόδου τις ημερήσιες τιμές της μετοχής.

Αντίστοιχα, τα αποτελέσματα όπως προκύπτουν από την αξιολόγηση των προβλέψεων για το πρόβλημα της ταξινόμησης δίνονται με τους ακόλουθους πίνακες και εμπλουτίζονται με τις συμπληρωματικές επεξηγηματικές εικόνες.

Πίνακας 4.6: Μέση τιμή για τους δείκτες Accuracy, Recall, Precision και F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, με χαρακτηριστικά εισόδου τις ημερήσιες τιμές της μετοχής.

<i>Accuracy</i>	<i>Recall</i>	<i>Precision</i>	<i>F1</i>
0.8029	0.6825	0.7530	0.7003




Εικόνα 4.8: Συγκέντρωση των τιμών για τους δείκτες Accuracy, Recall, Precision και F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, με χαρακτηριστικά εισόδου τις ημερήσιες τιμές της μετοχής.

Πίνακας 4.7: Στατιστικές τιμές για το Accuracy, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, με χαρακτηριστικά εισόδου τις ημερήσιες τιμές της μετοχής.

<i>Standard Deviation of Accuracy</i>	<i>Variance of Accuracy</i>	<i>Population Standard Deviation of Accuracy</i>	<i>Population Variance of Accuracy</i>
0.05789	0.0033	0.05731	0.0032

Πίνακας 4.8: Μέση τιμή για τους δείκτες Inverse Recall, Inverse Precision και Inverse F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, με χαρακτηριστικά εισόδου τις ημερήσιες τιμές της μετοχής.

<i>'Inverse Recall'</i>	<i>'Inverse Precision'</i>	<i>'Inverse F1'</i>
0.8631	0.8471	0.8497



Εικόνα 4.9: Συγκέντρωση των τιμών για τους δείκτες **Inverse Recall**, **Inverse Precision** και **Inverse F1**, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της **Apple**, έπειτα από 50 τρεξίματα, με χαρακτηριστικά εισόδου τις ημερήσιες τιμές της μετοχής.

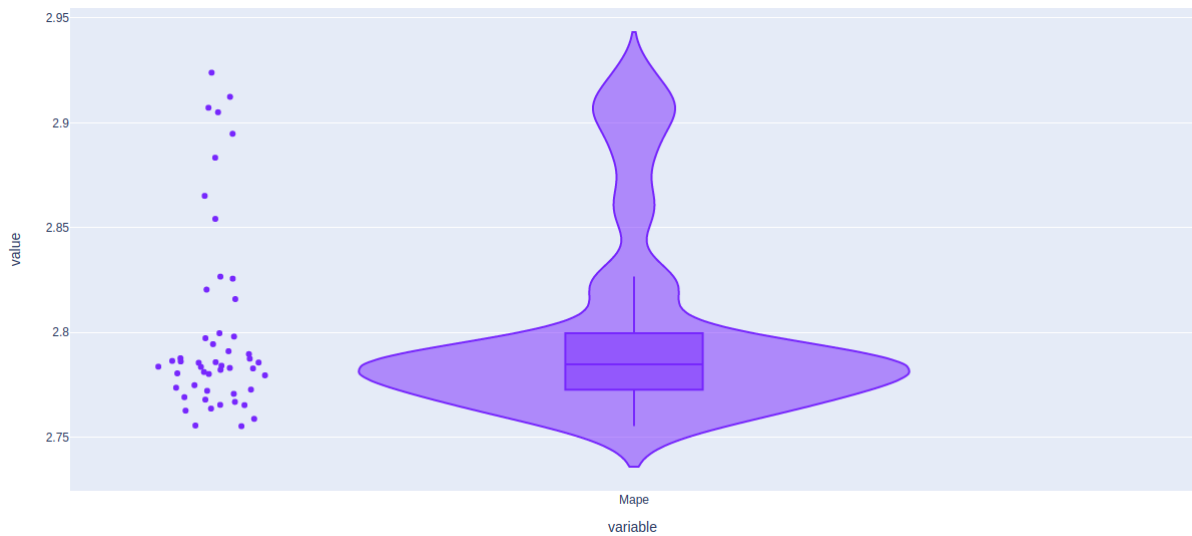
Πείραμα 4.3

Σαν χαρακτηριστικά εισόδου στο εν λόγω πείραμα χρησιμοποιήθηκαν τα ημερήσια χρηματιστηριακά μεγέθη της συγκεκριμένης μετοχής (τιμή ανοίγματος, τιμή κλεισίματος, υψηλό χαμηλό, όγκος και προσαρμοσμένη τιμή κλεισίματος) και προκειμένου το νευρωνικό μας δίκτυο να μπορέσει να μάθει περισσότερες συσχετίσεις δίνεται και η προσαρμοσμένη τιμή κλεισίματος του δείκτη S&P 500. Ακολουθούν και τα συγκεντρωτικά αποτελέσματα μετά από 50 τρεξίματα. Τα αποτελέσματα όπως προκύπτουν από την αξιολόγηση των προβλέψεων για το πρόβλημα της παρεμβολής αναγράφονται στον πίνακα 4.9


Πίνακας 4.9: Μέση τιμή του **Mae** και του **Mape** για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της **Apple**, έπειτα από 50 τρεξίματα, με χαρακτηριστικά εισόδου τις ημερήσιες τιμές της μετοχής και την προσαρμοσμένη τιμή κλεισίματος του δείκτη S&P 500.

<i>Mae</i>	<i>Mape</i>
0.7526	2.8005

Η πληροφορία που παρέχεται από τον πίνακα 4.9 , από μόνη της είναι ελλιπής και για τον λόγο αυτό παρέχονται οι εικόνες 4.10 και 4.11.



Εικόνα 4.10: Συγκέντρωση τιμών για το Mape για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, με χαρακτηριστικά εισόδου τις ημερήσιες τιμές της μετοχής και την προσαρμοσμένη τιμή κλεισίματος του δείκτη S&P 500.




Εικόνα 4.11: Συγκέντρωση τιμών για το Mae για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, με χαρακτηριστικά εισόδου τις ημερήσιες τιμές της μετοχής και την προσαρμοσμένη τιμή κλεισίματος του δείκτη S&P 500.

Σε πλήρη αντιστοιχία με τα προηγούμενα πειράματα, τα αποτελέσματα που προκύπτουν από την αξιολόγηση των προβλέψεων για το πρόβλημα της ταξινόμησης αποτυπώνονται στους ακόλουθους πίνακες και εμπλουτίζονται από τις συμπληρωματικές εικόνες.

Πίνακας 4.10: Μέση τιμή για τους δείκτες Accuracy, Recall, Precision και F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, με χαρακτηριστικά εισόδου τις ημερήσιες τιμές της μετοχής και την προσαρμοσμένη τιμή κλεισίματος του δείκτη S&P 500.

<i>Accuracy</i>	<i>Recall</i>	<i>Precision</i>	<i>F1</i>
0.8120	0.6862	0.7592	0.7096



Εικόνα 4.12: Συγκέντρωση των τιμών για τους δείκτες Accuracy, Recall, Precision και F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, με χαρακτηριστικά εισόδου τις ημερήσιες τιμές της μετοχής και την προσαρμοσμένη τιμή κλεισίματος του δείκτη S&P 500.

Πίνακας 4.11: Μέση τιμή για τους δείκτες Inverse Recall, Inverse Precision και Inverse F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, με χαρακτηριστικά εισόδου τις ημερήσιες τιμές της μετοχής και την προσαρμοσμένη τιμή κλεισίματος του δείκτη S&P 500.

<i>'Inverse Recall'</i>	<i>'Inverse Precision'</i>	<i>'Inverse F1'</i>
0.8750	0.8500	0.8591




Εικόνα 4.13: Συγκέντρωση των τιμών για τους δείκτες **Inverse Recall**, **Inverse Precision** και **Inverse F1**, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, με χαρακτηριστικά εισόδου τις ημερήσιες τιμές της μετοχής και την προσαρμοσμένη τιμή κλεισίματος του δείκτη S&P 500.

Πείραμα 4.4

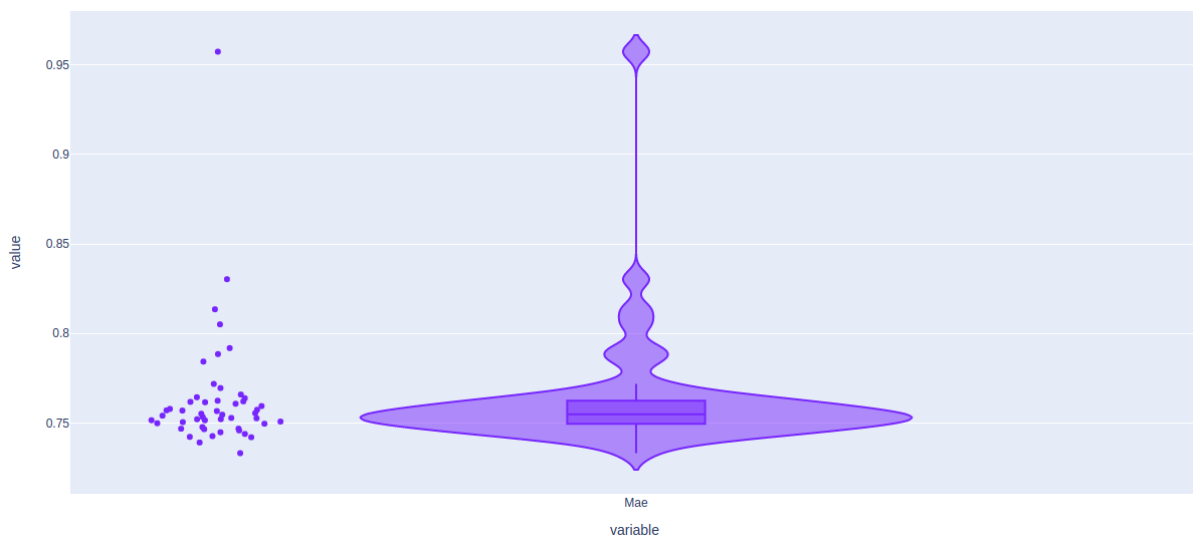
Σαν χαρακτηριστικά εισόδου στο εν λόγω πείραμα χρησιμοποιήθηκαν τα ημερήσια χρηματιστηριακά μεγέθη της συγκεκριμένης μετοχής (τιμή ανοίγματος, τιμή κλεισίματος, υψηλό χαμηλό, όγκος και προσαρμοσμένη τιμή κλεισίματος) και η προσαρμοσμένες τιμές κλεισίματος των S&P 500, S&P 100, Dow Jones Industrial Average. Τα αποτελέσματα όπως προκύπτουν από την αξιολόγηση των προβλέψεων όσον αφορά το πρόβλημα της παρεμβολής αναγράφονται στον πίνακα 4.12 και εμπλουτίζονται με τις εικόνες

Πίνακας 4.12: Μέση τιμή του **Mae** και του **Mape** για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, με χαρακτηριστικά εισόδου τις ημερήσιες τιμές της μετοχής και την προσαρμοσμένη τιμή κλεισίματος των δεικτών S&P 500, S&P 100, Dow Jones Industrial Average.

<i>Mae</i>	<i>Mape</i>
0.7633	2.8362



Εικόνα 4.14: Συγκέντρωση τιμών για το Mape για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, με χαρακτηριστικά εισόδου τις ημερήσιες τιμές της μετοχής και την προσαρμοσμένη τιμή κλεισίματος των δεικτών S&P 500, S&P 100, Dow Jones Industrial Average.




Εικόνα 4.15: Συγκέντρωση τιμών για το Mae για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, με χαρακτηριστικά εισόδου τις ημερήσιες τιμές της μετοχής και την προσαρμοσμένη τιμή κλεισίματος των δεικτών S&P 500, S&P 100, Dow Jones Industrial Average.

Επιπροσθέτως, ακολουθούν σε πλήρη αντιστοιχεία τα αποτελέσματα όπως προκύπτουν από την αξιολόγηση των προβλέψεων όσον αφορά το πρόβλημα της ταξινόμησης.

Πίνακας 4.13: Μέση τιμή για τους δείκτες Accuracy, Recall, Precision και F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, με χαρακτηριστικά εισόδου τις ημερήσιες τιμές της μετοχής και την προσαρμοσμένη τιμή κλεισίματος των δεικτών S&P 500, S&P 100, Dow Jones Industrial Average.

<i>Accuracy</i>	<i>Recall</i>	<i>Precision</i>	<i>F1</i>
0.8162	0.6675	0.7777	0.7067



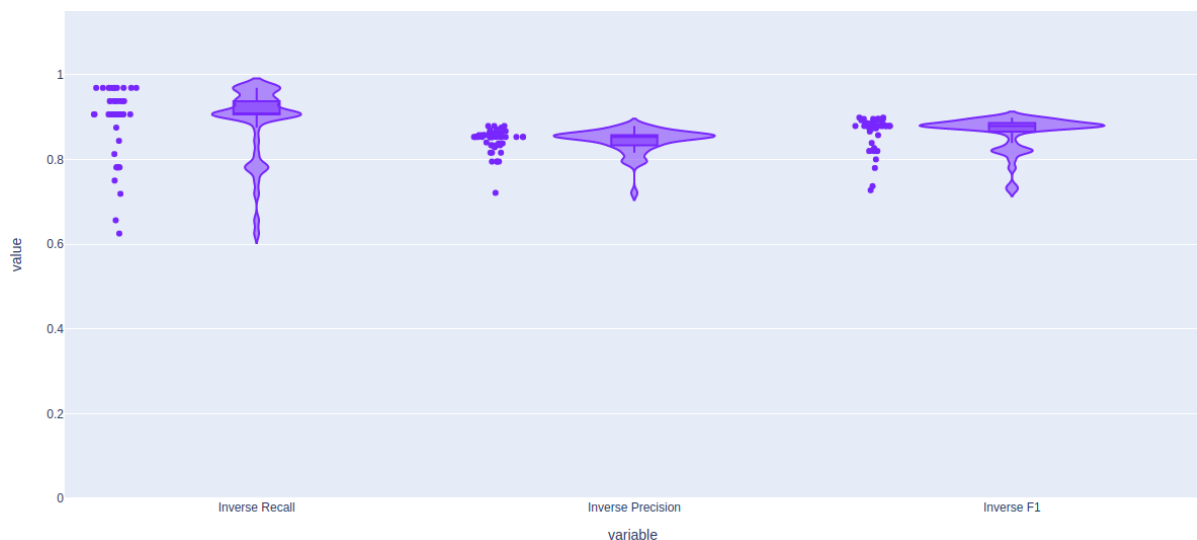
Εικόνα 4.16: Συγκέντρωση των τιμών για τους δείκτες Accuracy, Recall, Precision και F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, με χαρακτηριστικά εισόδου τις ημερήσιες τιμές της μετοχής και την προσαρμοσμένη τιμή κλεισίματος των δεικτών S&P 500, S&P 100, Dow Jones Industrial Average.

Πίνακας 4.14: Στατιστικές τιμές για το Accuracy, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, με χαρακτηριστικά εισόδου τις ημερήσιες τιμές της μετοχής και την προσαρμοσμένη τιμή κλεισίματος των δεικτών S&P 500, S&P 100, Dow Jones Industrial Average.

<i>Standard Deviation of Accuracy</i>	<i>Variance of Accuracy</i>	<i>Population Standard Deviation of Accuracy</i>	<i>Population Variance of Accuracy</i>
0.0416	0.0017	0.0411	0.0016

Πίνακας 4.15: Μέση τιμή για τους δείκτες Inverse Recall, Inverse Precision και Inverse F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρέξιμα, με χαρακτηριστικά εισόδου τις ημερήσιες τιμές της μετοχής και την προσαρμοσμένη τιμή κλεισίματος των δεικτών S&P 500, S&P 100, Dow Jones Industrial Average


<i>'Inverse Recall'</i>	<i>'Inverse Precision'</i>	<i>'Inverse F1'</i>
0.8906	0.8448	0.8643




Εικόνα 4.17: Συγκέντρωση των τιμών για τους δείκτες Inverse Recall, Inverse Precision και Inverse F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρέξιμα,

Πείραμα 4.5

Αξίζει να σημειωθεί πως ο συνδυασμός των χαρακτηριστικών εισόδου στο ακόλουθο πείραμα, με την αρχιτεκτονική και τις παραμέτρους του νευρωνικού δικτύου μας, αποτελεί και την τελική μας πρόταση για τις συγκεκριμένες προβλέψεις. Αυτό φυσικά συμβαίνει διότι οι οι μετρικές στο σύνολο τους είναι πολύ βελτιωμένες σε σχέση με τα προηγούμενα πειράματα. Σαν χαρακτηριστικά στο παρακάτω πείραμα, χρησιμοποιήθηκαν τα ημερήσια χρηματιστηριακά μεγέθη της συγκεκριμένης μετοχής (τιμή ανοίγματος, τιμή κλεισίματος, υψηλό χαμηλό, όγκος και προσαρμοσμένη τιμή κλεισίματος) και η προσαρμοσμένες τιμές κλεισίματος των NASDAQ-100 Technology Sector, S&P 100, Dow Jones Industrial Average . Δεδομένης της σημασίας των συγκεκριμένων χαρακτηριστικών εισόδου λοιπόν, στα πλαίσια του συγκεκριμένου πειράματος αποτυπώνονται και τα ενδεικτικά αποτελέσματα έπειτα από ένα τρέξιμο, εκτός από τις συγκεντρωτικές τιμές μετά από 50 τρέξιμα. Στις εικόνες 4.18 και 4.19 φαίνεται η πορεία του Mae και του Loss κατά την προπόνηση του νευρωνικού μας δικτύου. Είναι εμφανές, πως αρχικά υπάρχει μεγάλη βελτίωση και στην συνέχεια σχετική σταθεροποίηση με αποτέλεσμα να ενεργοποιείται το Early Stopping και να πραγματοποιούνται τελικά λιγότερα από 25 epochs.

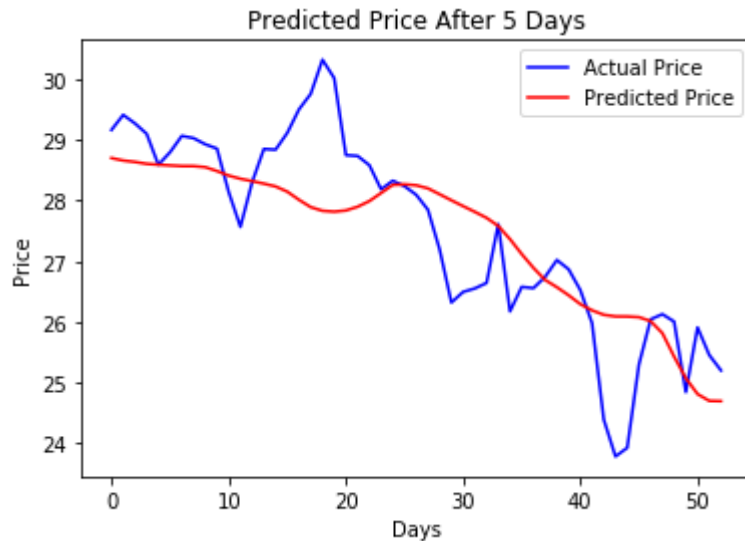


Εικόνα 4.18: Ενδεικτικό Mae έπειτα από ένα τρέξιμο για τα προτεινόμενα χαρακτηριστικά εισόδου



Εικόνα 4.19: Ενδεικτικό loss έπειτα από ένα τρέξιμο για τα προτεινόμενα χαρακτηριστικά εισόδου

Στην εικόνα 4.20 αποτυπώνεται η προβλεπόμενη τιμή για χρονικό ορίζοντα 5 ημερών σε σχέση με την πραγματική τελική τιμή. Είναι ξεκάθαρο, πως οι προβλεπόμενες και οι πραγματικές τιμές είναι πολύ κοντά.




Εικόνα 4.20: Προβλεπόμενη προσαρμοσμένη τιμή κλεισίματος σε βάθος χρόνου 5 ημερών για τα προτεινόμενα χαρακτηριστικά εισόδου

Ο πίνακας 4.16 αναγράφει τα αποτελέσματα των μετρικών παρεμβολής, η εικόνα 4.21 απεικονίζει το αντίστοιχο Confusion Matrix, και ο πίνακας 4.17 παρέχει τις μετρικές ταξινόμησης που προκύπτουν από το Confusion Matrix.

Πίνακας 4.16: Ενδεικτική τιμή του Mae και του Mape για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της , Apple, έπειτα από 1 τρέξιμο, για τα προτεινόμενα χαρακτηριστικά εισόδου.

<i>Mae</i>	<i>Mape</i>
0.7331	2.6967




Εικόνα 4.21: Confusion Matrix όπως προκύπτει για τα προτεινόμενα χαρακτηριστικά εισόδου

Πίνακας 4.17: Ενδεικτικές τιμές για τους δείκτες *Accuracy*, *Recall*, *Precision* και *F1*, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 1 τρέξιμο, για τα προτεινόμενα χαρακτηριστικά εισόδου.

<i>Accuracy</i>	<i>Recall</i>	<i>Precision</i>	<i>F1</i>
0.875	0.6875	0.9166	0.7857

Η εικόνα 4.22 απεικονίζει για λόγους κατανόησης τον Inverse Confusion Matrix, προκειμένου να γίνει αισθητή η συσχέτιση με το Confusion Matrix της εικόνας 4.21. Στην συνέχεια ο πίνακας 4.18 παρέχει τα αποτελέσματα των αντίστοιχων μετρικών όπως πηγάζουν από την εικόνα 4.22.



Εικόνα 4.22: Inverse Confusion Matrix όπως προκύπτει για τα προτεινόμενα χαρακτηριστικά εισόδου.


Πίνακας 4.18: Μέση τιμή για τους δείκτες *Inverse Recall*, *Inverse Precision* και *Inverse F1*, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρέξιμα, για τα προτεινόμενα χαρακτηριστικά εισόδου.

<i>'Inverse Recall'</i>	<i>'Inverse Precision'</i>	<i>'Inverse F1'</i>
0.9687	0.8611	0.9117


Στην συνέχεια ακολουθούν, κατά τα γνωστά τα συγκεντρωτικά αποτελέσματα, έπειτα από 50 τρέξιμα. Τα αποτελέσματα όπως προκύπτουν από την αξιολόγηση των προβλέψεων όσον αφορά το πρόβλημα της παρεμβολής αποτυπώνονται στον πίνακα 4.19 και εμπλουτίζονται από τις εικόνες 4.23 και 4.24.

Πίνακας 4.19: Μέση τιμή του Mae και του Mape για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, για τα προτεινόμενα χαρακτηριστικά εισόδου.

<i>Mae</i>	<i>Mape</i>
0.7440	2.7579



Εικόνα 4.23: Συγκέντρωση τιμών για το Mape για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα




Εικόνα 4.24: Συγκέντρωση τιμών για το Mae για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, για τα προτεινόμενα χαρακτηριστικά εισόδου.

Σε πλήρη αντιστοιχία και πάλι, ακολουθούν τα αποτελέσματα όπως προκύπτουν από την αξιολόγηση των προβλέψεων όσον αφορά το πρόβλημα της ταξινόμησης. Φυσικά, οι ακόλουθοι πίνακες εμπλουτίζονται όσον αφορά την παρεχόμενη πληροφορία, από τις συνοδευτικές εικόνες.

Πίνακας 4.20: Μέση τιμή για τους δείκτες Accuracy, Recall, Precision και F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, για τα προτεινόμενα χαρακτηριστικά εισόδου.

<i>Accuracy</i>	<i>Recall</i>	<i>Precision</i>	<i>F1</i>
0.8466	0.6462	0.8711	0.7353




Εικόνα 4.25: Συγκέντρωση των τιμών για τους δείκτες Accuracy, Recall, Precision και F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, για τα προτεινόμενα χαρακτηριστικά εισόδου.

Πίνακας 4.21: Στατιστικές τιμές για το Accuracy, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, για τα προτεινόμενα χαρακτηριστικά εισόδου.

<i>Standard Deviation of Accuracy</i>	<i>Variance of Accuracy</i>	<i>Population Standard Deviation of Accuracy</i>	<i>Population Variance of Accuracy</i>
0.0278	0.0007	0.0275	0.0007

Πίνακας 4.22: Μέση τιμή για τους δείκτες Inverse Recall, Inverse Precision και Inverse F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, για τα προτεινόμενα χαρακτηριστικά εισόδου.

<i>'Inverse Recall'</i>	<i>'Inverse Precision'</i>	<i>'Inverse F1'</i>
0.9468	0.8442	0.8914




Εικόνα 4.26: Συγκέντρωση των τιμών για τους δείκτες Inverse Recall, Inverse Precision και Inverse F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Apple, έπειτα από 50 τρεξίματα, για τα προτεινόμενα χαρακτηριστικά εισόδου.

Παρατηρούμε πως οι τελικές προβλέψεις για την μετοχή της Apple σημείωσαν σημαντική επιτυχία καθώς το Mape λαμβάνει μέση τιμή μόλις 2.7579 και το Accuracy είναι 0.8466. Παράλληλα, οι τιμές των Recall, Precision και F1 αλλά και των inverse τιμών τους εξασφαλίζουν την δυνατότητα του νευρωνικού δικτύου να προβλέπει εξίσου αποτελεσματικά ανόδους και καθόδους. Τέλος, οι στατιστικές τιμές για το Accuracy αλλά και τα διαγράμματα συγκεντρωτικών τιμών δείχνουν την συστηματικότητα των αποτελεσμάτων.

Οι προβλέψεις για την μετοχή της Apple δεν μπορούν από μόνες τους να αναδείξουν πλήρως την αποτελεσματικότητα του μοντέλου μας. Για τον λόγο αυτό ακολουθεί μια σειρά πειραμάτων για διαφορετικές μετοχές. Συγκεκριμένα για κάθε μετοχή πραγματοποιούνται δύο πειράματα, ένα με μοναδικό χαρακτηριστικό εισόδου την προσαρμοσμένη τιμή κλεισίματος και ένα με το προτεινόμενο σύνολο χαρακτηριστικών εισόδου όπως προέκυψε από το παραπάνω πείραμα. Για όλα τα ακόλουθα πειράματα αναγράφονται για κάθε μετοχή συγκεντρωτικοί πίνακες για να είναι εφικτή η σύγκριση αλλά και συμπληρωματικές εικόνες ώστε να εμπλουτίζεται και να είναι πιο πλήρης η πληροφορία που διατίθεται στους πίνακες.

4.3.2 Προβλέψεις για την μετοχή της IBM

Σην ενότητα αυτή συγκεκριμένα, εμπεριέχονται πειράματα για την μετοχή της IBM, οι ημερήσιες τιμές της οποίας διαφαίνονται, όπως έχουν ληφθεί από το yahoo finance, στην εικόνα 4.27. Επειδή όπως θα φανεί στην συνέχεια το προκύπτον Accuracy για μοναδική είσοδο την προσαρμοσμένη τιμή κλεισίματος είναι πολύ μικρό, κρίθηκε πως για αυτή την περίπτωση δεν θα είχαν ουσία τα σχετικά διαγράμματα οπότε και παραλείφθηκαν.



Εικόνα 4.27: Ημερήσιες τιμές για την μετοχή της IBM


Πειράματα 4.6 και 4.7

Σαν χαρακτηριστικό εισόδου στο πείραμα 4.6 θεωρήθηκε μόνο η προσαρμοσμένη τιμή κλεισίματος της μετοχής. Από την άλλη, στο πείραμα 4.7, χρησιμοποιήθηκαν σαν χαρακτηριστικά εισόδου τα ημερήσια χρηματιστηριακά μεγέθη της συγκεκριμένης μετοχής (τιμή ανοίγματος, τιμή κλεισίματος, υψηλό χαμηλό, όγκος και προσαρμοσμένη τιμή κλεισίματος) και η προσαρμοσμένες τιμές κλεισίματος των NASDAQ-100 Technology Sector, S&P 100, Dow Jones Industrial Average. Τα αποτελέσματα όπως προκύπτουν από την αξιολόγηση των προβλέψεων όσον αφορά το πρόβλημα της παρεμβολής αναγράφονται αμφοτέρωτα στον πίνακα 4.23


Πίνακας 4.23: Μέση τιμή του *Mae* και του *Mape* για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της IBM, έπειτα από 50 τρεξίματα, για διαφορετικά χαρακτηριστικά εισόδου

	<i>Mae</i>	<i>Mape</i>
Προσαρμοσμένη τιμή κλεισίματος	4.4716	3.6594
Προτεινόμενα χαρακτηριστικά εισόδου	2.5564	2.0551

Στις εικόνες 4.28 και 4.29 παρέχονται οι συγκεντρωτικές τιμές για το *Mae* και το *Mape*



Εικόνα 4.28: Συγκέντρωση τιμών για το Mape για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της IBM, έπειτα από 50 τρεξίματα και με τα προτεινόμενα χαρακτηριστικά εισόδου.

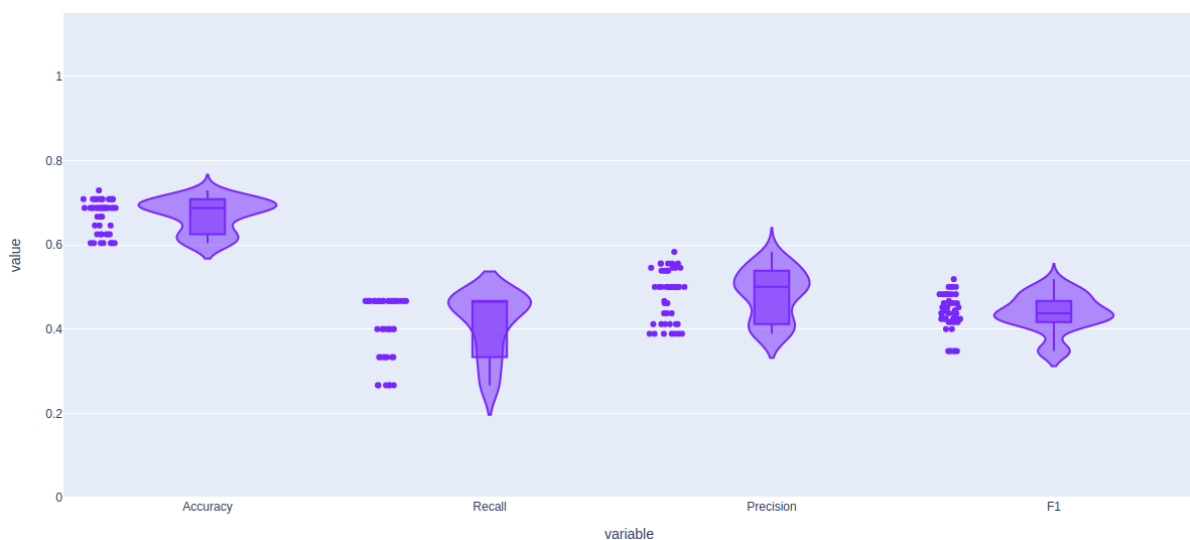


Εικόνα 4.29: Συγκέντρωση τιμών για το Mae για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της IBM, έπειτα από 50 τρεξίματα και με τα προτεινόμενα χαρακτηριστικά εισόδου.

Τα αποτελέσματα όπως προκύπτουν από την αξιολόγηση των προβλέψεων όσον αφορά το πρόβλημα της ταξινόμησης είναι ακολουθούν στους παρακάτω πίνακες και εικόνες.

Πίνακας 4.24: Μέση τιμή για τους δείκτες Accuracy, Recall, Precision και F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της IBM, έπειτα από 50 τρεξίματα, για διαφορετικά χαρακτηριστικά εισόδου.

	<i>Accuracy</i>	<i>Recall</i>	<i>Precision</i>	<i>F1</i>
<i>Είσοδος η προσαρμοσμένη τιμή κλεισίματος</i>	0.3950	0.8666	0.3247	0.4724
<i>Προτεινόμενα χαρακτηριστικά εισόδου</i>	0.6708	0.4133	0.4818	0.4375




Εικόνα 4.30: Συγκέντρωση των τιμών για τους δείκτες Accuracy, Recall, Precision και F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της IBM, έπειτα από 50 τρεξίματα, με τα προτεινόμενα χαρακτηριστικά εισόδου.

Πίνακας 4.25: Στατιστικές τιμές για το Accuracy, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της IBM, έπειτα από 50 τρεξίματα, για διαφορετικά χαρακτηριστικά εισόδου

	<i>Standard Deviation of Accuracy</i>	<i>Variance of Accuracy</i>	<i>Population Standard Deviation of Accuracy</i>	<i>Population Variance of Accuracy</i>
<i>Είσοδος η προσαρμοσμένη τιμή κλεισίματος</i>	0.0139	0.0001	0.0137	0.0001
<i>Προτεινόμενα χαρακτηριστικά εισόδου</i>	0.03834	0.0014	0.0379	0.0014

Πίνακας 4.26: Μέση τιμή για τους δείκτες Inverse Recall, Inverse Precision και Inverse F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της IBM, έπειτα από 50 τρεξίματα, για διαφορετικά χαρακτηριστικά εισόδου

	<i>'Inverse Recall'</i>	<i>'Inverse Precision'</i>	<i>'Inverse F1'</i>
<i>Είσοδος η προσαρμοσμένη τιμή κλεισίματος</i>	0.1806	0.7469	0.2905
<i>Προτεινόμενα χαρακτηριστικά εισόδου</i>	0.7878	0.7472	0.7652




Εικόνα 4.31: Συγκέντρωση των τιμών για τους δείκτες Inverse Recall, Inverse Precision και Inverse F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της IBM, έπειτα από 50 τρεξίματα, με τα προτεινόμενα χαρακτηριστικά εισόδου.

Από τα παραπάνω πειράματα για την μετοχή της IBM, φαίνεται για ακόμη μια φορά η αποτελεσματικότητα του μοντέλου μας με τα προτεινόμενα χαρακτηριστικά εισόδου και μάλιστα είναι ορατή η τεράστια βελτίωση και συνεισφορά σε σχέση με την απλή προσέγγιση όσον αφορά τα χαρακτηριστικά εισόδου.

4.3.3 Προβλέψεις για την μετοχή της Nvidia

Στην ενότητα αυτή εμπεριέχονται πειράματα για την μετοχή της Nvidia, η τιμές της οποίας διαφαίνονται στην εικόνα 4.32, όπως έχουν ληφθεί από το yahoo finance.




Εικόνα 4.32: Ημερήσιες τιμές για την μετοχή της Nvidia

Πείραμα 4.8 και 4.9


Σαν χαρακτηριστικό εισόδου στο πείραμα 4.8 θεωρήθηκε μόνο η προσαρμοσμένη τιμή κλεισίματος της μετοχής. Από την άλλη, στο πείραμα 4.9, χρησιμοποιήθηκαν σαν χαρακτηριστικά εισόδου τα ημερήσια χρηματιστηριακά μεγέθη της συγκεκριμένης μετοχής (τιμή ανοίγματος, τιμή κλεισίματος, υψηλό χαμηλό, όγκος και προσαρμοσμένη τιμή κλεισίματος) και η προσαρμοσμένες τιμές κλεισίματος των NASDAQ-100 Technology Sector, S&P 100, Dow Jones Industrial Average. Τα αποτελέσματα όπως προκύπτουν από το την αξιολόγηση των προβλέψεων όσον αφορά το πρόβλημα της παρεμβολής αποτυπώνονται στον πίνακα 4.27 και στις εικόνες 4.33-4.36.

Πίνακας 4.27: Μέση τιμή του Mae και του Mape για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Nvidia, έπειτα από 50 τρεξίματα, για διαφορετικά χαρακτηριστικά εισόδου.


	<i>Mae</i>	<i>Mape</i>
<i>Προσαρμοσμένη τιμή κλεισίματος</i>	1.0449	4.9443
<i>Προτεινόμενα χαρακτηριστικά εισόδου</i>	1.0491	4.8813




Εικόνα 4.33: Συγκέντρωση τιμών για το Mape για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Nvidia, έπειτα από 50 τρεξίματα και με μοναδικό χαρακτηριστικό εισόδου την προσαρμοσμένη τιμή κλεισίματος.



Εικόνα 4.34: Συγκέντρωση τιμών για το Mae για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Nvidia, έπειτα από 50 τρεξίματα και με μοναδικό χαρακτηριστικό εισόδου την προσαρμοσμένη τιμή κλεισίματος.



Εικόνα 4.35: Συγκέντρωση τιμών για το Mape για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της , έπειτα από 50 τρεξίματα, με τα προτεινόμενα χαρακτηριστικά εισόδου.




Εικόνα 4.36: Συγκέντρωση τιμών για το Mae για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της , έπειτα από 50 τρεξίματα, με τα προτεινόμενα χαρακτηριστικά εισόδου.


Όπως φαίνεται και στον πίνακα 4.27, με το προτεινόμενο μοντέλο υπάρχει βελτίωση στο Mape ενώ από τις εικόνες 4.33-4.36 διαφαίνεται πως οι τιμές των Mae και Mape είναι πιο συγκεντρωμένες στην μέση τιμή. Η βελτίωση αυτή παρατηρείται και στα αποτελέσματα που προκύπτουν από την αξιολόγηση των προβλέψεων όσον αφορά το πρόβλημα της ταξινόμησης καθώς όπως φαίνεται στον πίνακα 4.28 η βελτίωση στο Accuracy είναι και πάλι μεγάλη.

Πίνακας 4.28: Μέση τιμή για τους δείκτες Accuracy, Recall, Precision και F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Nvidia, έπειτα από 50 τρεξίματα, για διαφορετικά χαρακτηριστικά εισόδου.

	<i>Accuracy</i>	<i>Recall</i>	<i>Precision</i>	<i>F1</i>
<i>Είσοδος η προσαρμοσμένη τιμή κλεισίματος</i>	0.5362	0.5927	0.4962	0.5397
<i>Προτεινόμενα χαρακτηριστικά εισόδου</i>	0.6162	0.4454	0.6217	0.5145



Εικόνα 4.37: Συγκέντρωση των τιμών για τους δείκτες Accuracy, Recall, Precision και F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Nvidia, έπειτα από 50 τρεξίματα, με μοναδικό χαρακτηριστικό εισόδου την προσαρμοσμένη τιμή κλεισίματος.




Εικόνα 4.38: Συγκέντρωση των τιμών για τους δείκτες Accuracy, Recall, Precision και F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Nvidia, έπειτα από 50 τρεξίματα, με τα προτεινόμενα χαρακτηριστικά εισόδου.

Πίνακας 4.29 : Στατιστικές τιμές για το Accuracy, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Nvidia, έπειτα από 50 τρεξίματα, για διαφορετικά χαρακτηριστικά εισόδου


	<i>Standard Deviation of Accuracy</i>	<i>Variance of Accuracy</i>	<i>Population Standard Deviation of Accuracy</i>	<i>Population Variance of Accuracy</i>
<i>Είσοδος η προσαρμοσμένη τιμή κλεισίματος</i>	0.024	0.0005	0.0238	0.0005
<i>Προτεινόμενα χαρακτηριστικά εισόδου</i>	0.03066	0.0009	0.0303	0.0009

Πίνακας 4.30: Μέση τιμή για τους δείκτες Inverse Recall, Inverse Precision και Inverse F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Nvidia, έπειτα από 50 τρεξίματα, για διαφορετικά χαρακτηριστικά εισόδου

	<i>'Inverse Recall'</i>	<i>'Inverse Precision'</i>	<i>'Inverse F1'</i>
<i>Είσοδος η προσαρμοσμένη τιμή κλεισίματος</i>	0.4884	0.5852	0.5318
<i>Προτεινόμενα χαρακτηριστικά εισόδου</i>	0.7607	0.6177	0.6803




Εικόνα 4.39: Συγκέντρωση των τιμών για τους δείκτες Inverse Recall, Inverse Precision και Inverse F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Nvidia, έπειτα από 50 τρεξίματα, με μοναδικό χαρακτηριστικό εισόδου την προσαρμοσμένη τιμή κλεισίματος.



Εικόνα 4.40: Συγκέντρωση των τιμών για τους δείκτες **Inverse Recall**, **Inverse Precision** και **Inverse F1**, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Nvidia, έπειτα από 50 τρεξίματα, με τα προτεινόμενα χαρακτηριστικά εισόδου.


Οι σχετικά χαμηλές τιμές για τα Recall, Precision και F1 δεν είναι τυχαίες αλλά αντιθέτως δικαιολογούνται. Συγκεκριμένα όπως φαίνεται στην εικόνα 4.41, μετά την μέρα 30, πιθανώς πραγματοποιείται κάποιο ειδικό γεγονός (special event) που επιδρά θετικά στην τιμή της μετοχής. Το μοντέλο μας φυσικά εμφανίζει αδυναμία στην ανίχνευση και σωστή πρόβλεψη τέτοιων καταστάσεων.



Εικόνα 4.41: Special Event

4.3.4 Προβλέψεις για την μετοχή της Tesla

Στην ενότητα αυτή, σε απόλυτη αντιστοιχία με τις προηγούμενες ενότητες, εμπεριέχονται πειράματα για την μετοχή της Tesla, η τιμές της οποίας διαφαίνονται στην εικόνα 4.42, όπως έχουν ληφθεί από το yahoo finance.




Εικόνα 4.42: Ημερήσιες τιμές για την μετοχή της Tesla

Πειράματα 4.10 και 4.11


Σαν χαρακτηριστικό εισόδου στο πείραμα 4.10 θεωρήθηκε μόνο η προσαρμοσμένη τιμή κλεισίματος της μετοχής. Από την άλλη, στο πείραμα 4.11, χρησιμοποιήθηκαν σαν χαρακτηριστικά εισόδου τα ημερήσια χρηματιστηριακά μεγέθη της συγκεκριμένης μετοχής (τιμή ανοίγματος, τιμή κλεισίματος, υψηλό χαμηλό, όγκος και προσαρμοσμένη τιμή κλεισίματος) και η προσαρμοσμένες τιμές κλεισίματος των NASDAQ-100 Technology Sector, S&P 100, Dow Jones Industrial Average. Τα αποτελέσματα όπως προκύπτουν από την αξιολόγηση των προβλέψεων όσον αφορά το πρόβλημα της παρεμβολής παρουσιάζονται στον πίνακα 4.31 και στις εικόνες 4.43-4.46. Και πάλι παρατηρείται ορατή βελτίωση στις μετρικές Mae και Mape.

Πίνακας 4.31: Μέση τιμή του Mae και του Mape για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Tesla, έπειτα από 50 τρεξίματα, για διαφορετικά χαρακτηριστικά εισόδου.


	<i>Mae</i>	<i>Mape</i>
<i>Προσαρμοσμένη τιμή κλεισίματος</i>	2.1592	4.2485
<i>Προτεινόμενα χαρακτηριστικά εισόδου</i>	2.0820	4.1213




Εικόνα 4.43: Συγκέντρωση τιμών για το Mape για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Tesla, έπειτα από 50 τρεξίματα και με μοναδικό χαρακτηριστικό εισόδου την προσαρμοσμένη τιμή κλεισίματος.



Εικόνα 4.44: Συγκέντρωση τιμών για το Mae για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Tesla, έπειτα από 50 τρεξίματα και με μοναδικό χαρακτηριστικό εισόδου την προσαρμοσμένη τιμή κλεισίματος.



Εικόνα 4.45: Συγκέντρωση τιμών για το Mape για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Tesla, έπειτα από 50 τρεξίματα και με προτεινόμενα χαρακτηριστικά εισόδου.




Εικόνα 4.46: Συγκέντρωση τιμών για το Mae για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Tesla, έπειτα από 50 τρεξίματα και με τα προτεινόμενα χαρακτηριστικό εισόδου.


Τα αποτελέσματα όπως προκύπτουν από την αξιολόγηση των προβλέψεων όσον αφορά το πρόβλημα της ταξινόμησης αποτυπώνται στους πίνακες 4.32-4.34 και στις εικόνες 4.47-4.50 και αναδεικνύουν ότι και πάλι υπάρχει στοιχειώδης βελτίωση.

Πίνακας 4.32: Μέση τιμή για τους δείκτες Accuracy, Recall, Precision και F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Tesla, έπειτα από 50 τρεξίματα, για διαφορετικά χαρακτηριστικά εισόδου.

	<i>Accuracy</i>	<i>Recall</i>	<i>Precision</i>	<i>F1</i>
<i>Είσοδος η προσαρμοσμένη τιμή κλεισίματος</i>	0.6741	0.4815	0.8572	0.6147
<i>Προτεινόμενα χαρακτηριστικά εισόδου</i>	0.6879	0.5384	0.8531	0.6445



Εικόνα 4.47: Συγκέντρωση των τιμών για τους δείκτες Accuracy, Recall, Precision και F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Tesla, έπειτα από 50 τρεξίματα, με μοναδικό χαρακτηριστικό εισόδου την προσαρμοσμένη τιμή κλεισίματος.




Εικόνα 4.48: Συγκέντρωση των τιμών για τους δείκτες Accuracy, Recall, Precision και F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Tesla, έπειτα από 50 τρεξίματα, με τα προτεινόμενα χαρακτηριστικά εισόδου.

Πίνακας 4.33: Στατιστικές τιμές για το Accuracy, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Tesla, έπειτα από 50 τρεξίματα, για διαφορετικά χαρακτηριστικά εισόδου


	<i>Standard Deviation of Accuracy</i>	<i>Variance of Accuracy</i>	<i>Population Standard Deviation of Accuracy</i>	<i>Population Variance of Accuracy</i>
<i>Είσοδος η προσαρμοσμένη τιμή κλεισίματος</i>	0.0144	0.0002	0.0142	0.0002
<i>Προτεινόμενα χαρακτηριστικά εισόδου</i>	0.0247	0.0006	0.0244	0.0005

Πίνακας 4.34: Μέση τιμή για τους δείκτες Inverse Recall, Inverse Precision και Inverse F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Tesla, έπειτα από 50 τρεξίματα, για διαφορετικά χαρακτηριστικά εισόδου.

	<i>'Inverse Recall'</i>	<i>'Inverse Precision'</i>	<i>'Inverse F1'</i>
<i>Είσοδος η προσαρμοσμένη τιμή κλεισίματος</i>	0.9018	0.5957	0.7170
<i>Προτεινόμενα χαρακτηριστικά εισόδου</i>	0.8645	0.6227	0.7127




Εικόνα 4.49: Συγκέντρωση των τιμών για τους δείκτες Inverse Recall, Inverse Precision και Inverse F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Tesla, έπειτα από 50 τρεξίματα, με μοναδικό χαρακτηριστικό εισόδου την προσαρμοσμένη τιμή κλεισίματος.



Εικόνα 4.50: Συγκέντρωση των τιμών για τους δείκτες Inverse Recall, Inverse Precision και Inverse F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Tesla, έπειτα από 50 τρεξίματα, με τα προτεινόμενα χαρακτηριστικά εισόδου.

4.3.5 Προβλέψεις για την μετοχή της Microsoft

Η ενότητα αυτή έχει συμπεριληφθεί σαν αντιπαράδειγμα για όσα έχουν αναφερθεί μέχρι στιγμής. Συγκεκριμένα, στο σημείο αυτό, εμπεριέχονται πειράματα για την μετοχή της Microsoft, η τιμές της οποίας διαφαίνονται στην εικόνα 4.51, όπως έχουν ληφθεί από το yahoo finance. Η ειδοποιός διαφορά σε σχέση με τις προηγούμενες ενότητες είναι πως στην περίπτωση αυτή, αύξηση των χαρακτηριστικών εισόδου δεν συνεπάγεται και βελτίωση στο Accuracy. Αυτό μπορεί να συμβαίνει όταν η προστιθέμενη πληροφορία δεν είναι αντιπροσωπευτική των εξαρτήσεων που υπάρχουν για την μετοχή. Παρόλα αυτά, και σε αυτή την περίπτωση οι προβλέψεις παραμένουν εξαιρετικά αποτελεσματικές.



Εικόνα 4.51: Ημερήσιες τιμές για την μετοχή της Microsoft


Πειράματα 4.12 και 4.13

Σαν χαρακτηριστικό εισόδου στο πείραμα 4.12 θεωρήθηκε μόνο η προσαρμοσμένη τιμή κλεισίματος της μετοχής. Από την άλλη, στο πείραμα 4.13, χρησιμοποιήθηκαν σαν χαρακτηριστικά εισόδου τα ημερήσια χρηματιστηριακά μεγέθη της συγκεκριμένης μετοχής (τιμή ανοίγματος, τιμή


κλεισίματος, υψηλό χαμηλό, όγκος και προσαρμοσμένη τιμή κλεισίματος) και η προσαρμοσμένες τιμές κλεισίματος των NASDAQ-100 Technology Sector, S&P 100, Dow Jones Industrial Average. Τα αποτελέσματα όπως προκύπτουν από την αξιολόγηση των προβλέψεων όσον αφορά το πρόβλημα της παρεμβολής αναγράφονται στον πίνακα 4.35 και στις εικόνες 4.52-4.55.

Πίνακας 4.35: Μέση τιμή του Mae και του Mape για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Microsoft, έπειτα από 50 τρεξίματα, για διαφορετικά χαρακτηριστικά εισόδου.


	<i>Mae</i>	<i>Mape</i>
<i>Προσαρμοσμένη τιμή κλεισίματος</i>	1.2310	3.0828
<i>Προτεινόμενα χαρακτηριστικά εισόδου</i>	1.2135	3.0178




Εικόνα 4.52: Συγκέντρωση τιμών για το Mape για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Microsoft, έπειτα από 50 τρεξίματα και με μοναδικό χαρακτηριστικό εισόδου την προσαρμοσμένη τιμή κλεισίματος.



Εικόνα 4.53: Συγκέντρωση τιμών για το *Mae* για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της *Microsoft*, έπειτα από 50 τρεξίματα και με μοναδικό χαρακτηριστικό εισόδου την προσαρμοσμένη τιμή κλεισίματος.



Εικόνα 4.54: Συγκέντρωση τιμών για το *Mape* για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της *Microsoft*, έπειτα από 50 τρεξίματα και με τα προτεινόμενα χαρακτηριστικά εισόδου.




Εικόνα 4.55: Συγκέντρωση τιμών για το Mae για την πρόβλεψη της προσαρμοσμένης τιμής κλεισίματος της μετοχής της , έπειτα από 50 τρεξίματα, με τα προτεινόμενα χαρακτηριστικά εισόδου.


Τα αποτελέσματα όπως προκύπτουν από την αξιολόγηση των προβλέψεων όσον αφορά το πρόβλημα της ταξινόμησης αναγράφονται στους πίνακες 4.36-4.38 και στις εικόνες 4.56-4.59. Παρατηρείται λοιπόν πως το Accuracy χειροτερεύει υποτυποδώς.

Πίνακας 4.36: Μέση τιμή για τους δείκτες Accuracy, Recall, Precision και F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Microsoft, έπειτα από 50 τρεξίματα, για διαφορετικά χαρακτηριστικά εισόδου.

	<i>Accuracy</i>	<i>Recall</i>	<i>Precision</i>	<i>F1</i>
<i>Είσοδος η προσαρμοσμένη τιμή κλεισίματος</i>	0.6604	0.7000	0.6868	0.6845
<i>Προτεινόμενα χαρακτηριστικά εισόδου</i>	0.6437	0.5723	0.7131	0.6272



Εικόνα 4.56: Συγκέντρωση των τιμών για τους δείκτες Accuracy, Recall, Precision και F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Microsoft, έπειτα από 50 τρεξίματα, με μοναδικό χαρακτηριστικό εισόδου την προσαρμοσμένη τιμή κλεισίματος.



Εικόνα 4.57: Συγκέντρωση των τιμών για τους δείκτες Accuracy, Recall, Precision και F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Microsoft, έπειτα από 50 τρεξίματα, με τα προτεινόμενα χαρακτηριστικά εισόδου.

Πίνακας 4.37: Στατιστικές τιμές για το Accuracy, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της , έπειτα από 50 τρεξίματα, για διαφορετικά χαρακτηριστικά εισόδου

	<i>Standard Deviation of Accuracy</i>	<i>Variance of Accuracy</i>	<i>Population Standard Deviation of Accuracy</i>	<i>Population Variance of Accuracy</i>
<i>Είσοδος η προσαρμοσμένη τιμή κλεισίματος</i>	0.0295	0.0008	0.0292	0.0008
<i>Προτεινόμενα χαρακτηριστικά εισόδου</i>	0.0474	0.0022	0.0470	0.0022

Πίνακας 4.38: Μέση τιμή για τους δείκτες Inverse Recall, Inverse Precision και Inverse F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της , έπειτα από 50 τρεξίματα,

	<i>'Inverse Recall'</i>	<i>'Inverse Precision'</i>	<i>'Inverse F1'</i>
<i>Είσοδος η προσαρμοσμένη τιμή κλεισίματος</i>	0.6136	0.6483	0.6206
<i>Προτεινόμενα χαρακτηριστικά εισόδου</i>	0.7281	0.6012	0.6529



Εικόνα 4.58: Συγκέντρωση των τιμών για τους δείκτες Inverse Recall, Inverse Precision και Inverse F1, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Microsoft, έπειτα από 50 τρεξίματα, με μοναδικό χαρακτηριστικό εισόδου την προσαρμοσμένη τιμή κλεισίματος



Εικόνα 4.59: Συγκέντρωση των τιμών για τους δείκτες **Inverse Recall**, **Inverse Precision** και **Inverse F1**, για την πρόβλεψη της τάσης της προσαρμοσμένης τιμής κλεισίματος της μετοχής της Microsoft, έπειτα από 50 τρεξίματα, με τα προτεινόμενα χαρακτηριστικά εισόδου.

4.4 Συμπεράσματα Πειραμάτων

Από τα παραπάνω πειράματα γίνεται εμφανές πως χρειάζεται να εξετάζονται παράλληλα πολλές μετρικές ώστε τελικά να θεωρηθεί πως ένα τέτοιου είδους σύστημα είναι αποτελεσματικό. Μέσα από τα πειράματα μας καταδεικνύεται πως η αρχιτεκτονική και οι υπερπαραμέτροι του δικτύου μας οδηγούν σε πολύ καλά αποτελέσματα, τόσο σε σχέση με τις μεθόδους αξιολόγησης που χρησιμοποιήθηκαν, όσο και σε σχέση με την υπάρχουσα βιβλιογραφία. Στην συνέχεια αναγράφεται σε πολλές περιπτώσεις μεμονωμένα, το Accuracy των πειραμάτων παρόλο που έχει τονιστεί ότι, σαν μετρική από μόνη της δεν είναι αρκετή. Αξίζει λοιπόν να σημειωθεί, πως με όλες τις χρησιμοποιηθείσες μετρικές έχει εξασφαλιστεί πως το Accuracy μας δεν κρύβει επιβλαβή πληροφορία. Για παράδειγμα, σε όλα τα πειράματά μας έχει εξασφαλιστεί εξίσου η δυνατότητα για πρόβλεψη ανόδων και καθόδων. Για την πληρέστερη σύγκριση των πειραμάτων είναι χρήσιμη η ανασκόπηση των συνολικών αποτελεσμάτων κατά την διάρκεια μελέτης των ακόλουθων συμπερασμάτων.

Όσον αφορά τις προβλέψεις για την μετοχή της APPLE είναι εμφανές πως η επίδοση του νευρωνικού δικτύου μας είναι ιδιαίτερα αποτελεσματική ακόμα και όταν δίνονται σαν είσοδοι μόνο οι τιμές κλεισίματος της μετοχής. Γίνεται σαφές στην συνέχεια πόσο βελτιώνεται η πρόβλεψη με την προσθήκη των χρηματιστηριακών τιμών της μετοχής και στην συνέχεια πως βελτιώνεται ακόμα περισσότερο με την προσθήκη των συγκεκριμένων χρηματιστηριακών δεικτών. Αξίζει να σημειωθεί πως, όπως προκύπτει από τα διαγράμματά μας, τα χαρακτηριστικά εισόδου που προτείνονται σχεδόν εξασφαλίζουν Accuracy μεγαλύτερο από 80% σε αντίθεση με τις προηγούμενες περιπτώσεις.

Πίνακας 4.39: Σύγκριση του Accuracy για διαφορετικά χαρακτηριστικά εισόδου για την μετοχή της Apple

<i>Προσαρμοσμένη τιμή κλεισίματος</i>	<i>Ημερήσιες τιμές μετοχής</i>	<i>Προτεινόμενο σύνολο χαρακτηριστικών εισόδου</i>
0.6108	0.8029	0.8466

Οι μετρικές MAE και MAPE αν και είναι πολύ χρήσιμες για την αποτελεσματικότητα του νευρωνικού δικτύου μας, κρύβουν πληροφορία όσον αφορά την κατεύθυνση του σφάλματος. Αυτό έχει σαν αποτέλεσμα δύο πειράματα με σχεδόν ίδιο MAPE να μπορούν να οδηγήσουν σε πολύ διαφορετικό Accuracy, όταν η πληροφορία που παρέχεται από τα χαρακτηριστικά εισόδου αλλάζει ουσιαστικά. Για παράδειγμα στην μετοχή της Apple:

Πίνακας 4.40: Σύγκριση μετρικών για διαφορετικά χαρακτηριστικά εισόδου για την μετοχή της Apple

	<i>Mae</i>	<i>Mape</i>	<i>Accuracy</i>
<i>Ημερήσιες τιμές μετοχής</i>	0.7393	2.7529	0.8029
<i>Προτεινόμενο σύνολο χαρακτηριστικών εισόδου</i>	0.7440	2.7579	0.8466

Όσον αφορά την εφαρμογή της πρότασής μας σε άλλες μετοχές πέρα από την Apple, τα συμπεράσματα που προκύπτουν παρουσιάζουν τεράστιο ενδιαφέρον. Όσον αφορά τα χαρακτηριστικά εισόδου, σε όλες τις μετοχές η επίδοση είτε βελτιώνεται είτε παραμένει στα ίδια επίπεδα, όταν προστίθενται τα χαρακτηριστικά εισόδου που προτεινόμενου μοντέλου σε σχέση με την χρήση μεμονωμένα της τιμής κλεισίματος. Συγκεκριμένα στην IBM η βελτίωση είναι δραματική και στην NVDA η βελτίωση είναι αρκετά μεγάλη. Παράλληλα στην μετοχή της TESLA υπάρχει υποτυπώδης αύξηση και στην μετοχή της MICROSOFT υποτυπώδης μείωση με αποτέλεσμα να μπορεί να θεωρηθεί πως και στις δύο η απόδοση παραμένει σχετικά στα ίδια επίπεδα. Συλλογικά, όπως διαφαίνεται και στον ακόλουθο πίνακα, σε όλες τις χρησιμοποιηθείσες μετοχές το Accuracy που επιτυγχάνεται με το προτεινόμενο μοντέλο μας είναι σε κάθε περίπτωση πάνω από 60%.

Πίνακας 4.41: Σύγκριση του Accuracy που προκύπτει από το προτεινόμενο σύνολο χαρακτηριστικών εισόδου σε σχέση με αυτο που προκύπτει από την μεμονωμένη προσαρμοσμένη τιμή κλεισίματος, για όλες τις μελετημένες μετοχές.

	<i>Προσαρμοσμένη τιμή κλεισίματος</i>	<i>Προτεινόμενο σύνολο χαρακτηριστικών εισόδου</i>
Apple	0.6108	0.8466
Microsoft	0.66041	0.6437
IBM	0.3950	0.6708
Nvidia	0.5362	0.6162
Tesla	0.6741	0.6879

4.5 Σύγκριση Αποτελεσμάτων με την Βιβλιογραφία

Με στόχο την καλύτερη κατανόηση της αποτελεσματικότητας της διπλωματικής, γίνεται σύγκριση με δύο ερευνητικές δουλειές που επίσης ασχολούνται με την πρόβλεψη της τάσης χρηματιστηριακών μεγεθών με LSTM. Αρχικά, γίνεται σύγκριση με το άρθρο του Karmiani et al. (2019) στο οποίο ο σκοπός ήταν να επιτευχθεί όσο μεγαλύτερο Accuracy γίνεται, έχοντας δημιουργήσει μια ιδιαίτερη βάση δεδομένων. Σχετικά με τον τρόπο επιλογής των δεδομένων, επέλεξαν μια βάση που θα έπρεπε να έχει minimum deviation και normal behaviour, ενώ θεωρήθηκε σημαντική η επιλογή ενός χρονικού εύρους που να μην περιέχει απότομα άλματα ή πτώσεις στις τιμές. Ειδικότερα, οι συγγραφείς του άρθρου επίσης έλαβαν ιστορικά δεδομένα από το yahoo Finance για τεχνολογικές εταιρείες και συγκεκριμένα για τις Apple, Acer, Amazon, Google, HP, IBM, Intel, Microsoft, Sony από τον Ιανουάριο του 2009 μέχρι τον Οκτώβριο του 2018. Από τις παραμέτρους αυτές, οι συγγραφείς δημιούργησαν την δική τους βάση δημιουργώντας καινούριες μεταβλητές. Για κάθε τρέξιμο χρησιμοποίησαν διαφορετικό σύνολο δεδομένων εκπαίδευσης και test set και τα αποτελέσματα προέκυπταν μετά από 30 τρεξίματα. Τα αποτελέσματα που προκύπτουν συγκεντρώνονται στον πίνακα 4.42.

Πίνακας 4.42: Συγκεντρωτικά αποτελέσματα του Karmiani et al. (2019)

<i>No. of Epochs</i>	<i>Accuracy (%)</i>	<i>Standard Deviation</i>	<i>Variance</i>
10	68.51635	0.71779	0.51523
30	68.98083	0.05528	0.00306
50	68.95468	0.04981	0.00248
70	68.96183	0.05109	0.00261
100	69.04171	0.05204	0.00271

Στον πίνακα 4.43 ακολουθούν τα αντίστοιχα αποτελέσματα του πειράματός μας με τα προτεινόμενα χαρακτηριστικά εισόδου για την μετοχής της Apple.

Πίνακας 4.43: Παρουσίαση των βέλτιστων αποτελεσμάτων μας για την μετοχής της Apple

<i>No. of Epochs</i>	<i>Accuracy (%)</i>	<i>Standard Deviation</i>	<i>Variance</i>
50 (Early Stopping)	84.66	0.0278	0.0007

Συμπερασματικά, αφενός είναι ξεκάθαρο πως υπάρχει διαφωνία στην προσέγγιση του θέματος, στο σημείο ότι με βάση την προσέγγισή μας να είναι στόχος μόνο το υψηλό accuracy αλλά θα πρέπει να γίνεται προσπάθεια για την ταυτόχρονη βελτίωση όλων των μετρικών που έχουν χρησιμοποιηθεί στα πλαίσια αυτής της διπλωματικής. Ακόμη, λείπουν αρκετές μετρικές που στην διπλωματική μας έχουν θεωρηθεί απαραίτητες. Θα μπορούσε για παράδειγμα ένα σύστημα να κάνει προβλέψεις μονομερώς και παρόλα αυτά το Accuracy να είναι τόσο υψηλό. Κάτι τέτοιο όμως στο μοντέλο μας εξασφαλίζεται πως δεν συμβαίνει με την ύπαρξη των μετρικών Precision, Recall, F1 και των inverse μετρικών αυτών. Παρόλα αυτά όμως, όπως προκύπτει από τους πίνακες 4.42 και 4.43 οι προβλέψεις μας για την μετοχή της Apple πετυχαίνουν καλύτερα αποτελέσματα, τόσο σε επίπεδο Accuracy, όσο και σε επίπεδο Standard Deviation και Variance.

Ακόμη, ο Nelson et al. (2017) πραγματοποιεί πρόβλεψη για άνοδο ή κάθοδο της τιμής της μετοχής σε βάθος χρόνου 15 λεπτών. Τα δεδομένα σε αυτή την περίπτωση αφορούν ιστορικά δεδομένα διαφορετικών μετοχών από το Brazilian stock exchange (Bovespa). Μαζί με αυτά τα δεδομένα, οι συγγραφείς δημιούργησαν αρκετούς τεχνικούς δείκτες, τους οποίους τελικά έδωσαν στο νευρωνικό δίκτυο σαν χαρακτηριστικά εισόδου. Πιο συγκεκριμένα, χρησιμοποιήθηκαν δεδομένα από το 2008 μέχρι το 2015 από το IBovespa index στο BM&F Bovespa stock exchange. Για την προπόνηση του δικτύου οι συγγραφείς έδωσαν σε είσοδο τους τελευταίους 10 μήνες πριν από την ημέρα συναλλαγής, ενώ η τελευταία εβδομάδα πριν από αυτή την ημέρα χρησιμοποιήθηκε για validation. Ακόμη, τα τελικά πειράματα που πραγματοποιήθηκαν προέβλεπαν την πορεία της τιμής της μετοχής για τον Δεκέμβριο του 2014 για τις προαναφερθείσες μετοχές. Για την αξιολόγηση χρησιμοποιούνται σαν δείκτες οι μετρικές Accuracy, Precision, Recall και F-measure. Τα αποτελέσματα που προκύπτουν είναι τα ακόλουθα και έχουν σαν καλύτερο αποτέλεσμα Accuracy κατά μέσο όρο 55.9%.

Πίνακας 4.44: Συγκεντρωτικά αποτελέσματα του Nelson et al. (2017)

<i>Stock</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1</i>
<i>BOVA11</i>	0.546	0.560	0.350	0.431
<i>BBDC4</i>	0.559	0.553	0.129	0.209
<i>ITUB4</i>	0.545	0.475	0.134	0.209
<i>CIEL3</i>	0.530	0.476	0.137	0.213
<i>PETR4</i>	0.533	0.563	0.231	0.327

Όπως προκύπτει από τα παραπάνω αποτελέσματα, το Recall και το F1 είναι πάρα πολύ χαμηλά. Αυτό σημαίνει πως το συγκεκριμένο νευρωνικό δίκτυο είναι πιθανό να λειτουργεί μεροληπτικά, ανιχνεύοντας υπέρμετρα καθόδους σε βάρος των ανόδων. Αν και δεν μπορεί να γίνει άμεση σύγκριση καθώς αλλάζουν και οι μετοχές αλλά και ο ορίζοντας πρόβλεψης, τα αντίστοιχα αποτελέσματα όπως προέκυψαν από την προτεινόμενη προσέγγιση της διπλωματικής αναγράφονται στον πίνακα 4.45 και φαίνεται να υπερτερούν.

Πίνακας 4.45: Συγκεντρωτικά αποτελέσματα των πειραμάτων μας

<i>Stock</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1</i>
<i>Apple</i>	0.8466	0.6462	0.8711	0.7353
<i>Microsoft</i>	0.6437	0.5723	0.7131	0.6272
<i>IBM</i>	0.6708	0.4133	0.4818	0.4375
<i>Nvidia</i>	0.6162	0.4454	0.6217	0.5145
<i>Tesla</i>	0.6879	0.5384	0.8531	0.6445

Κεφάλαιο 5: Συμπεράσματα και μελλοντική εργασία

5.1 Συμπεράσματα

Από την συγκεκριμένη διπλωματική μπορούν να εξαχθούν αρκετά συμπεράσματα σχετικά με την εφαρμογή του Lstm για χρηματιστηριακές προβλέψεις. Αφενός, αποδείχθηκε η δυνατότητα του Lstm να αντιλαμβάνεται τις εξαρτήσεις των δεδομένων και να πραγματοποιεί αποτελεσματικές προβλέψεις. Συγκεκριμένα, τα αποτελέσματα μας είναι ευθέως συγκρίσιμα και πιθανώς καλύτερα από αυτά της βιβλιογραφίας. Προκειμένου να επιτευχθεί καλή απόδοση για το νευρωνικό μας δίκτυο, αποδείχθηκε αναγκαία αφενός η κατάλληλη ρύθμιση των παραμέτρων του νευρωνικού δικτύου και στην συνέχεια η κατάλληλη επιλογή χαρακτηριστικών εισόδου. Μάλιστα, από την μια η κατάλληλη επιλογή χαρακτηριστικών εισόδου είναι ικανή να βελτιώσει δραματικά την απόδοση, από την άλλη όμως αχρείαστη πληροφορία μπορεί να χειροτερεύσει τις προβλέψεις. Παράλληλα, η έννοια της απόδοσης για το συγκεκριμένο πρόβλημα, όπως προκύπτει και από την βιβλιογραφία, είναι σχετική. Από την μελέτη και την δουλειά μας συμπεραίνεται πως η απόδοση θα πρέπει να εξετάζεται συλλογικά και όχι μεμονωμένα με την ταυτόχρονη μελέτη όλων των προτεινόμενων μετρικών αλλά και των αντίστοιχων διαγραμμάτων.

5.2 Περιορισμοί της διπλωματικής

Φυσικά, η πρόταση μας δεν μπορεί να εφαρμοστεί άκριτα σε κάθε περίπτωση χρηματιστηριακής πρόβλεψης, αλλά αντιθέτως έχει περιορισμούς. Θα ήταν δόκιμο να επισημανθεί πως για κάθε σύνολο 50 πειραμάτων που αφορά μια μετοχή, το σύνολο δεδομένων εκπαίδευσης, validation set και test set προέρχονται από τις ίδιες ακριβώς συγκεκριμένες ημερομηνίες. Το σύστημα μας λοιπόν, δεν έχει αξιολογηθεί σε διαφορετικές ημερομηνίες. Ακόμη, το σύστημα μας δεν έχει αξιολογηθεί σε μετοχές που δεν σχετίζονται με τους χρησιμοποιηθέντες χρηματιστηριακούς δείκτες.

5.3 Μελλοντική δουλειά

Η βασική προοπτική της δουλειάς μας, είναι να μπορεί το νευρωνικό δίκτυο που κατασκευάστηκε να εφαρμόζεται σε πραγματικό χρόνο. Αφενός, προκειμένου ένα σύστημα να μπορεί να κάνει πάντα αποτελεσματικές προβλέψεις, ανεξαρτήτως εισόδου, θα πρέπει πιθανώς να λαμβάνει περισσότερα ζευγάρια εισόδων-εξόδων ώστε να είναι σε θέση να αναγνωρίσει περισσότερες καταστάσεις. Αφετέρου θα ήταν χρήσιμο να εμπλουτιστεί με διαφορετικής φύσεως πληροφορία. Μια καλή σχετική προσέγγιση, σύμφωνα και με την βιβλιογραφία, θα ήταν η υλοποίηση ενός υβριδικού μοντέλου που εκτός από την ανάλυση των χρηματιστηριακών τιμών, να πραγματοποιεί και ανάλυση συναισθήματος από τα κοινωνικά δίκτυα.

Βιβλιογραφικές αναφορές

- Abiodun, O. I., Jantan, A., & Omolara, A. E. (2018). Kemi Victoria Dada, Nachaat AbdElatif Mohamed, and Humaira Arshad. State-of-the-art in artificial neural network applications: A survey. *Jurnal Heliyon Elsevier*, 4.
- Abu-Mostafa, Y. S., & Atiya, A. F. (1996). Introduction to financial forecasting. *Applied intelligence*, 6(3), 205-213.
- Babu, M. S., Geethanjali, N., & Satyanarayana, B. (2012). Clustering approach to stock market prediction. *International Journal of Advanced Networking and Applications*, 3(4), 1281.
- Ballings, M., Van den Poel, D., Hespeels, N., & Gryp, R. (2015). Evaluating multiple classifiers for stock price direction prediction. *Expert systems with Applications*, 42(20), 7046-7056.
- Bernal, A., Fok, S., & Pidaparathi, R. (2012). Financial market time series prediction with recurrent neural networks. *State College: Citeseer*.
- Bollen, J., Mao, H., & Zeng, X. (2011). Twitter mood predicts the stock market. *Journal of computational science*, 2(1), 1-8.
- Cakra, Y. E., & Trisedya, B. D. (2015, October). Stock price prediction using linear regression based on sentiment analysis. In *2015 international conference on advanced computer science and information systems (ICACSIS)* (pp. 147-154). IEEE.
- Dey, S., Kumar, Y., Saha, S., & Basak, S. (2016). Forecasting to classification: Predicting the direction of stock market price using xtreme gradient boosting. *PESIT South Campus*.
- Di Persio, L., & Honchar, O. (2017). Recurrent neural networks approach to the financial forecast of Google assets. *International journal of Mathematics and Computers in simulation*, 11, 7-13.
- Ding, X., Zhang, Y., Liu, T., & Duan, J. (2015, June). Deep learning for event-driven stock prediction. In *Twenty-fourth international joint conference on artificial intelligence..*
- Goodfellow, I., Bengio, Y., & Courville, A. (2018). *Deep Learning*. Frechen: MITP.
- Goutte, C., & Gaussier, E. (2005, March). Aprobabilistic interpretation of precision, recall and F-score, with implication for evaluation. In *European conference on information retrieval* (pp. 345-359). Springer, Berlin, Heidelberg.
- Hossain, M., Karim, R., Thulasiram, R., Bruce, N.D., & Wang, Y. (2018). Hybrid Deep Learning Model for Stock Price Prediction. *2018 IEEE Symposium Series on Computational Intelligence (SSCI)*, 1837-1844.
- Hu, Y., Liu, K., Zhang, X., Su, L., Ngai, E. W. T., & Liu, M. (2015). Application of evolutionary computation for rule discovery in stock algorithmic trading: A literature review. *Applied Soft Computing*, 36, 534-551.
- Karmiani, D., Kazi, R., Nambisan, A., Shah, A., & Kamble, V. (2019, February). Comparison of predictive algorithms: Backpropagation, svm, lstm and kalman filter for stock market. In *2019 Amity International Conference on Artificial Intelligence (AICAI)* (pp. 228-234). IEEE.

- Kotsiantis, S. B., Zaharakis, I., & Pintelas, P. (2007). Supervised machine learning: A review of classification techniques. *Emerging artificial intelligence applications in computer engineering*, 160(1), 3-24.
- Lee, H., Surdeanu, M., MacCartney, B., & Jurafsky, D. (2014, May). On the Importance of Text Analysis for Stock Price Prediction. In *LREC* (Vol. 2014, pp. 1170-1175).
- Malkiel, B. G., & Fama, E. F. (1970). Efficient capital markets: A review of theory and empirical work. *The Journal of Finance*, 25(2), 383-417.
- Manaswi, N. K. (2018). Rnn and lstm. In *Deep Learning with Applications Using Python* (pp. 115-126). Apress, Berkeley, CA.
- Mandelbrot, B. (1963). The Variation of Certain Speculative Prices. *The Journal of Business*, 36(4), 394-419.
- Markowska-Kaczmar, U., & Dziejic, M. (2008). Discovery of technical analysis patterns. *2008 International Multiconference on Computer Science and Information Technology*, 195-200.
- Milosevic, N. (2016). Equity forecast: Predicting long term stock price movement using machine learning. *arXiv preprint arXiv:1603.00751*.
- Nelson, D. M., Pereira, A. C., & de Oliveira, R. A. (2017, May). Stock market's price movement prediction with LSTM neural networks. In *2017 International joint conference on neural networks (IJCNN)* (pp. 1419-1426). IEEE.
- Olah, C. (2015). Understanding lstm networks.
- Pagolu, V. S., Reddy, K. N., Panda, G., & Majhi, B. (2016, October). Sentiment analysis of Twitter data for predicting stock market movements. In *2016 international conference on signal processing, communication, power and embedded system (SCOPE5)* (pp. 1345-1350). IEEE.
- Park, C. H., & Irwin, S. H. (2007). What do we know about the profitability of technical analysis?. *Journal of Economic surveys*, 21(4), 786-826.
- Petneházi, G. (2019). Recurrent neural networks for time series forecasting. *arXiv preprint arXiv:1901.00069*.
- Powell, N., Foo, S. Y., & Weatherspoon, M. (2008, March). Supervised and unsupervised methods for stock trend forecasting. In *2008 40th Southeastern Symposium on System Theory (SSST)* (pp. 203-205). IEEE.
- Prechelt L. (1998) Early Stopping - But When?. In: Orr G.B., Müller KR. (eds) Neural Networks: Tricks of the Trade. Lecture Notes in Computer Science, vol 1524. Springer, Berlin, Heidelberg. https://doi.org/10.1007/3-540-49430-8_3
- Rather, A. M., Agarwal, A., & Sastry, V. N. (2015). Recurrent neural network and a hybrid model for prediction of stock returns. *Expert Systems with Applications*, 42(6), 3234-3241.
- Schumaker, R. P., & Chen, H. (2009). Textual analysis of stock market prediction using breaking financial news: The AZFin text system. *ACM Transactions on Information Systems (TOIS)*, 27(2), 1-19.

- Selvin, S., Vinayakumar, R., Gopalakrishnan, E. A., Menon, V. K., & Soman, K. P. (2017, September). Stock price prediction using LSTM, RNN and CNN-sliding window model. In *2017 international conference on advances in computing, communications and informatics (icacci)* (pp. 1643-1647). IEEE.
- Shah, D., Isah, H., & Zulkernine, F. (2019). Stock market analysis: A review and taxonomy of prediction techniques. *International Journal of Financial Studies*, 7(2), 26.
- Shen, S., Jiang, H., & Zhang, T. (2012). Stock market forecasting using machine learning algorithms. *Department of Electrical Engineering, Stanford University, Stanford, CA*, 1-5.
- Tiwari, S., Pandit, R., & Richhariya, V. (2010). Predicting future trends in stock market by decision tree rough-set based hybrid system with HHMM. *International Journal of Electronics and Computer Science Engineering*, 1(3).
- Wang, J. J., Wang, J. Z., Zhang, Z. G., & Guo, S. P. (2012). Stock index forecasting based on a hybrid model. *Omega*, 40(6), 758-766.
- Wu, K. P., Wu, Y. P., & Lee, H. M. (2014). Stock Trend Prediction by Using A-Means and AprioriAll Algorithm for Sequential Chart Pattern Mining. *Journal of Information Science & Engineering*, 30(3).
- Yoshihara, A., Fujikawa, K., Seki, K., & Uehara, K. (2014, December). Predicting stock market trends by recurrent deep neural networks. In *Pacific rim international conference on artificial intelligence* (pp. 759-769). Springer, Cham.
- Zhong, X., & Enke, D. (2017). Forecasting daily stock market return using dimensionality reduction. *Expert Systems with Applications*, 67, 126-139.