



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΤΕΧΝΟΛΟΓΙΑΣ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΥΠΟΛΟΓΙΣΤΩΝ

Μέθοδοι βαθιάς μηχανικής μάθησης για χρηματιστηριακές συναλλαγές

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

της

ΣΟΦΙΑΣ Γ. ΓΑΛΑΝΑΚΗ

Επιβλέπων: Ανδρέας-Γεώργιος Σταφυλοπάτης
Καθηγητής ΕΜΠ

Αθήνα, Δεκέμβριος 2021



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΤΕΧΝΟΛΟΓΙΑΣ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΥΠΟΛΟΓΙΣΤΩΝ

Μέθοδοι βαθιάς μηχανικής μάθησης για χρηματιστηριακές συναλλαγές

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

της

ΣΟΦΙΑΣ Γ. ΓΑΛΑΝΑΚΗ

Επιβλέπων: Ανδρέας-Γεώργιος Σταφυλοπάτης
Καθηγητής ΕΜΠ

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 1η Δεκεμβρίου 2021.

(Υπογραφή)

(Υπογραφή)

(Υπογραφή)

.....
Ανδρέας-Γεώργιος Σταφυλοπάτης
Καθηγητής ΕΜΠ

.....
Στέφανος Κόλλιας
Καθηγητής ΕΜΠ

.....
Γεώργιος Στάμου
Καθηγητής ΕΜΠ

Αθήνα, Δεκέμβριος 2021



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

ΤΟΜΕΑΣ ΤΕΧΝΟΛΟΓΙΑΣ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΥΠΟΛΟΓΙΣΤΩΝ

Copyright © - All rights reserved. Με την επιφύλαξη παντός δικαιώματος.
Σοφία Γ. Γαλανάκη, 2021.

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.

Το περιεχόμενο αυτής της εργασίας δεν απηχεί απαραίτητα τις απόψεις του Τμήματος, του Επιβλέποντα, ή της επιτροπής που την ενέκρινε.

ΔΗΛΩΣΗ ΜΗ ΛΟΓΟΚΛΟΠΗΣ ΚΑΙ ΑΝΑΛΗΨΗΣ ΠΡΟΣΩΠΙΚΗΣ ΕΥΘΥΝΗΣ

Με πλήρη επίγνωση των συνεπειών του νόμου περί πνευματικών δικαιωμάτων, δηλώνω ευνογράφως ότι είμαι αποκλειστικός συγγραφέας της παρούσας Διπλωματικής Εργασίας, για την ολοκλήρωση της οποίας κάθε βοήθεια είναι πλήρως αναγνωρισμένη και αναφέρεται λεπτομερώς στην εργασία αυτή. Έχω αναφέρει πλήρως και με σαφείς αναφορές, όλες τις πηγές χρήσης δεδομένων, απόψεων, θέσεων και προτάσεων, ιδεών και λεκτικών αναφορών, είτε κατά κυριολεξία είτε βάσει επιστημονικής παράφρασης. Αναλαμβάνω την προσωπική και ατομική ευθύνη ότι σε περίπτωση αποτυχίας στην υλοποίηση των ανωτέρω δηλωθέντων στοιχείων, είμαι υπόλογος έναντι λογοκλοπής, γεγονός που σημαίνει αποτυχία στην Διπλωματική μου Εργασία και κατά συνέπεια αποτυχία απόκτησης του Τίτλου Σπουδών, πέραν των λοιπών συνεπειών του νόμου περί πνευματικών δικαιωμάτων. Δηλώνω, συνεπώς, ότι αυτή η Διπλωματική Εργασία προετοιμάστηκε και ολοκληρώθηκε από εμένα προσωπικά και αποκλειστικά και ότι, αναλαμβάνω πλήρως όλες τις συνέπειες του νόμου στην περίπτωση κατά την οποία αποδειχθεί, διαχρονικά, ότι η εργασία αυτή ή τμήμα της δεν μου ανήκει διότι είναι προϊόν λογοκλοπής άλλης πνευματικής ιδιοκτησίας.

(Υπογραφή)

.....
Σοφία Γ. Γαλανάκη

1 Δεκεμβρίου 2021

Περίληψη

Οι συναλλαγές στο χρηματιστήριο και ο τρόπος με τον οποίο μπορεί κανείς να βελτιώσει την αγοραπωλησία οικονομικών στοιχείων, ώστε να πετύχει το μέγιστο δυνατό κέρδος, είναι ένα θέμα που έχει απασχολήσει τόσο την επιστημονική κοινότητα όσο και ανθρώπους που προτίθενται να επενδύσουν σε μετοχές ή κρυπτονομίσματα. Στο πέρασμα των χρόνων, έχουν αξιοποιηθεί ποικίλα μοντέλα μαθηματικής και στατιστικής φύσεως με σκοπό την πληρέστερη περιγραφή της κατάστασης της αγοράς. Έχουν προσδιοριστεί δείκτες που υποδεικνύουν την τάση μιας μετοχής, αλλά και πιθανά σημεία εκτέλεσης κάποιας συναλλαγής. Τα τελευταία χρόνια, με την άνοδο της μηχανικής μάθησης, ποικίλα μοντέλα προβλέπουν την τιμή της μετοχής για κάποια μελλοντική χρονική στιγμή και ως εκ τούτου προσδιορίζουν τα καταλληλότερα σημεία που προσφέρονται για συναλλαγές. Ωστόσο, αυτό το είδος προβλήματος έχει αρκετές προκλήσεις. Μία εξ αυτών είναι η διαμόρφωση των δεδομένων για την καλύτερη περιγραφή της αγοράς.

Στόχος της διπλωματικής εργασίας είναι η μελέτη διαφορετικών μοντέλων βαθιάς μηχανικής και ενισχυτικής μάθησης για την επίλυση ενός προβλήματος ταξινόμησης. Κάθε δείγμα αντιστοιχίζεται σε μία ετικέτα που αντιπροσωπεύει την ενέργεια που είναι πιθανό να προβεί το σύστημα μια συγκεκριμένη χρονική στιγμή. Μελετούνται αναδρομικά και συνελκτικά μοντέλα. Ως δεδομένα εισόδου χρησιμοποιούνται οι αρχικές χρονοσειρές αλλά και εικόνες που προκύπτουν από το μετασχηματισμό αυτών.

Λέξεις Κλειδιά

Χρηματιστήριο, Συναλλαγές, Μετοχή, Βαθιά Μηχανική Μάθηση, Ενισχυτική Μάθηση, Deep Q-Learning, Χρονοσειρά, GAF (Gramian Angular Field)

Abstract

Stock market and asset trading greatly concern the scientific community and investors in assets, like stocks and cryptocurrencies. The literature uses various mathematical and statistical models to describe the market in the best possible way. Financial indicators identify the stock trends and its possible best execution levels. Recently, machine learning models forecast stock prices and predict trades more accurately. The latter approach faces many challenges. Such a challenge relates to the way that data can be transformed to better represent the market allowing models to extract more valuable information.

This thesis aims to investigate the various deep learning and deep reinforcement learning models to address a classification problem. A label, that corresponds to the system's possible action at each timestamp, is assigned to each sample. We implement both convolutional and recurrent neural networks. The data that are used to feed the neural networks include the initial timeseries of the stock prices and the images generated by their transformation.

Keywords

Stock Market, Trading, Stock, Deep Learning, Reinforcement Learning, Deep Q-Learning, Timeseries, GAF (Gramian Angular Field)

στην οικογένειά μου

Ευχαριστίες

Θα ήθελα να ευχαριστήσω τον καθηγητή κ. Σταφυλοπάτη για την ευκαιρία που μου έδωσε να ασχοληθώ με το συγκεκριμένο θέμα και να εκπονήσω την εργασία στο Εργαστήριο Τεχνητής Νοημοσύνης και Συστημάτων Μάθησης. Επίσης ευχαριστώ ιδιαίτερα τον κ. Σιόλα για την εξαιρετική επικοινωνία που είχαμε, την καθοδήγησή του και τις εύστοχες παρατηρήσεις του. Τέλος θα ήθελα να ευχαριστήσω την οικογένειά μου και τους φίλους μου για τη συμπαράσταση και την υποστήριξή τους κατά τη διάρκεια των σπουδών μου.

Αθήνα, Δεκέμβριος 2021

Σοφία Γ. Γαλανάκη

Περιεχόμενα

Περίληψη	1
Abstract	3
Ευχαριστίες	7
1 Εισαγωγή	15
1.1 Αντικείμενο της διπλωματικής	15
1.2 Οργάνωση του τόμου	15
I Θεωρητικό Μέρος	17
2 Θεωρητικό υπόβαθρο	19
2.1 Μηχανική Μάθηση	19
2.1.1 Είδη προβλημάτων μάθησης	19
2.1.2 Είδη μηχανικής μάθησης	20
2.1.3 Νευρωνικά δίκτυα	21
2.1.4 Ενισχυτική μάθηση	30
2.1.5 Στοιχεία της ενισχυτικής μάθησης	31
3 Περιγραφή θέματος	35
3.1 Χρήσιμες έννοιες των χρηματιστηριακών συναλλαγών	35
3.2 Σχετικές εργασίες	37
II Πρακτικό Μέρος	39
4 Ανάλυση και σχεδίαση	41
4.1 Δεδομένα προβλήματος	41
4.2 Προεπεξεργασία δεδομένων	41
4.3 Προσθήκη ετικετών	46
4.4 Μέθοδος εκπαίδευσης	48
4.5 Ανάλυση - περιγραφή αρχιτεκτονικής	49
4.5.1 Μέθοδοι βαθιάς μηχανικής μάθησης	49
4.5.2 Μέθοδοι βαθιάς ενισχυτικής μάθησης	55

5 Ανάλυση - αποτελέσματα πειραμάτων	57
5.1 Τεχνική αξιολόγηση	57
5.2 Οικονομική αξιολόγηση	63
6 Επίλογος	69
6.1 Συμπεράσματα	69
6.2 Μελλοντικές επεκτάσεις	70
Παραρτήματα	73
Α΄ Περαιτέρω αποτελέσματα	75
Βιβλιογραφία	78
Συντομογραφίες - Αρκτικόλεξα - Ακρωνύμια	79
Απόδοση ξενόγλωσσων όρων	81

Κατάλογος Σχημάτων

2.1	Μοντέλο ενισχυτικής μάθησης	21
2.2	Πλήρως συνδεδεμένο νευρωνικό δίκτυο	22
2.3	Βασική αρχιτεκτονική συνελκτικού δικτύου	23
2.4	Συναρτήσεις ενεργοποίησης	25
2.5	Σχήμα αναδρομικού δικτύου	26
α΄	Γενικευμένη μορφή αναδρομικού δικτύου A: μεμονωμένη δομή αναδρομικού δικτύου	26
β΄	Ανοιχτή μορφή αναδρομικού επιπέδου.	26
2.6	Ανεπτυγμένη μορφή αναδρομικού επιπέδου διπλής κατεύθυνσης.	27
2.7	Δομή κελιού μακράς και βραχείας μνήμης	29
3.1	Μορφή δεδομένων οικονομικών στοιχείων	36
α΄	Ορισμός κεριών με βάση την αρχική, μέγιστη, ελάχιστη και τελική τιμή	36
β΄	Παράδειγμα χρονοσειράς με τη χρήση δεδομένων OHLC.	36
4.1	Μετατροπή χρονοσειράς στο Γραμμικό γωνιακό χώρο	47
α΄	Τμήμα χρονοσειράς με τιμές κανονικοποιημένες σε εύρος [-1,1].	47
β΄	Τμήμα χρονοσειράς σε πολικές συντεταγμένες.	47
γ΄	Τμήμα χρονοσειράς σε Γραμμικό γωνιακό χώρο.	47
4.2	Κινητό παράθυρο για την εκπαίδευση του μοντέλου. Ανακατασκευασμένο διάγραμμα από [1]	48
4.3	Δίκτυο με δύο αναδρομικά επίπεδα μακράς και βραχείας μνήμης. X_i : χρονικές στιγμές εισόδου y_i : αντίστοιχες τιμές εξόδου	49
4.4	Απλό δίκτυο με δύο συνελκτικά επίπεδα.	50
4.5	Υβριδικό δίκτυο με συνελκτικό (με είσοδο εικόνες) και αναδρομικό τμήμα (με είσοδο χρονοσειρές).	52
4.6	Υβριδικό δίκτυο με συνελκτικό (με είσοδο εικόνες) και αναδρομικό τμήμα (με είσοδο χρονοσειρές).	54
4.7	Υβριδικό δίκτυο με αμφίδρομα αναδρομικά επίπεδα.	56
5.1	Επίδοση μοντέλων για τη μετοχή GS κατά το έτος 2020	66
α΄	Προβλέψεις GS με το μοντέλο BM_2	66
β΄	Προβλέψεις GS με το μοντέλο BM_4	66
6.1	Τμήματα του συστήματος	70

Κατάλογος Πινάκων

2.1	Συγκριτικός πίνακας παραμέτρων $k \times k$: μέγεθος πυρήνα I : αριθμός καναλιών εισόδου O : αριθμός καναλιών εξόδου	24
4.1	Λίστα μετοχών Dow-30, όπως προέκυψε στο τέλος του 2020	42
5.2	Πίνακας σύγχυσης με χρήση του μοντέλου BM_2	58
α'	Πίνακας σύγχυσης με εικόνες τεχνικής ανάλυσης	58
β'	Πίνακας σύγχυσης με εικόνες τεχνικής ανάλυσης	58
5.1	Πίνακας σύγχυσης με χρήση του μοντέλου BM_1	58
5.3	Πίνακας σύγχυσης με χρήση του μοντέλου BM_3	59
5.4	Πίνακας σύγχυσης με διαφορετικούς τρόπους μείωσης των διαστάσεων πριν την πρόσθεση των επιμέρους τμημάτων του δικτύου	59
α'	Πίνακας σύγχυσης με χρήση του μοντέλου BM_4	59
β'	Πίνακας σύγχυσης με χρήση του μοντέλου BM_5	59
5.5	Πίνακας σύγχυσης αναδρομικό με αναδρομικό δίκτυο διπλής κατεύθυνσης	60
α'	Πίνακας σύγχυσης με χρήση του μοντέλου BM_6 (συνένωση)	60
β'	Πίνακας σύγχυσης με χρήση του μοντέλου BM_7 (πρόσθεση)	60
5.6	Πίνακας σύγχυσης με τα μοντέλα ενισχυτικής μάθησης	61
α'	Πίνακας σύγχυσης με χρήση του μοντέλου EM_1	61
β'	Πίνακας σύγχυσης με χρήση του μοντέλου EM_2	61
5.7	Μετρικές επίδοσης των μοντέλων	62
5.8	Ετήσιες επιστροφές των μοντέλων (μέρος 1ο)	64
5.9	Ετήσιες επιστροφές των μοντέλων (μέρος 2ο)	65
A.1	Πίνακας σύγχυσης με τα μοντέλα BM_4 και BM_6 για δεδομένα TA	75
α'	Πίνακας σύγχυσης με χρήση του μοντέλου BM_4	75
β'	Πίνακας σύγχυσης με χρήση του μοντέλου BM_6	75
γ'	Μετρικές επίδοσης του μοντέλου BM_4	75
δ'	Μετρικές επίδοσης μοντέλου BM_6	75

Κεφάλαιο **1**

Εισαγωγή

1.1 Αντικείμενο της διπλωματικής

Σκοπός της διπλωματικής εργασίας είναι η μελέτη διαφόρων συστημάτων με στόχο την επίλυση του προβλήματος βέλτιστης εκτέλεσης συναλλαγών στο χρηματιστήριο. Στα πλαίσια αυτού του σκοπού συμπεριλαμβάνεται και η σύγκριση διαφορετικών μοντέλων βαθιάς και ενισχυτικής μάθησης για διαφορετικές μεθόδους διαμόρφωσης των δεδομένων εισόδου με στόχο την ταξινόμηση των δειγμάτων σε ενέργειες αγοράς, πώλησης, ή αδράνειας.

1.2 Οργάνωση του τόμου

Η προσέγγιση του θέματος, ξεκινάει με το θεωρητικό μέρος και την ανάλυση και επεξήγηση των όρων μηχανική μάθηση, νευρωνικά δίκτυα και ενισχυτική μάθηση στο κεφάλαιο **2**. Επιπλέον, στο κεφάλαιο **3** θίγονται ειδικοί όροι του θέματος εφαρμογής, που έχουν σχέση με το χρηματιστήριο.

Υστερα ακολουθεί το πρακτικό μέρος με τα κεφάλαια **4** και **5**. Το πρώτο περιλαμβάνει την αναλυτική περιγραφή των δεδομένων εισόδου, τις μεθόδους μετασχηματισμού αυτών, τον αλγόριθμο ανάθεσης ετικετών και την παρουσίαση των αρχιτεκτονικών των μοντέλων που σχεδιάστηκαν. Στο τελευταίο αναγράφονται και σχολιάζονται τα αποτελέσματα των διαφόρων πειραμάτων. Τέλος, στο κεφάλαιο **6** αναγράφονται τα συμπεράσματα -όπως αυτά προέκυψαν από τις παρατηρήσεις επί των αποτελεσμάτων- και τις μελλοντικές επεκτάσεις της εργασίας.

Μέρος I

Θεωρητικό Μέρος

Κεφάλαιο 2

Θεωρητικό υπόβαθρο

Στο κεφάλαιο αυτό αναλύεται η έννοια της μηχανικής μάθησης, και γίνεται απαρίθμηση των διαφορετικών ειδών μηχανικής μάθησης.

2.1 Μηχανική Μάθηση

Η μηχανική μάθηση σύμφωνα με το άρθρο [2] είναι ένα συνεχώς αναπτυσσόμενο παρακλάδι των υπολογιστικών αλγορίθμων που έχει ως στόχο να προσομοιάσει τον τρόπο λειτουργίας του ανθρώπινου εγκεφάλου. Θεωρείται από τις πλέον κατάλληλες τεχνικές για την αντιμετώπιση των σύγχρονων προβλημάτων που συνοδεύονται από την ύπαρξη μεγάλων συνόλων δεδομένων. Η μηχανική μάθηση έχει εφαρμοστεί με επιτυχία σε ποικίλα προβλήματα που περιλαμβάνουν την αναγνώριση προτύπων, την υπολογιστική όραση, την οικονομία και την ιατρική.

Η τεχνική της μηχανικής μάθησης σύμφωνα με τους Mohri κ.σ. [3] περιλαμβάνει υπολογιστικές μεθόδους που χρησιμοποιούν την εμπειρία για να βελτιώσουν την επίδοσή τους ή να πετύχουν ακριβέστερες προβλέψεις. Η εμπειρία, στα πλαίσια της μηχανικής μάθησης, σχετίζεται με την παρελθοντική πληροφορία που είναι διαθέσιμη στο μοντέλο εκμάθησης. Τα δεδομένα αυτά μπορεί να είναι κατηγοριοποιημένα σύνολα εκπαίδευσης ή άλλου είδους δεδομένα που έχουν προέλθει από την αλληλεπίδραση του μοντέλου με το περιβάλλον. Σε οποιαδήποτε περίπτωση, όμως, η ποσότητα και η ποιότητα των δεδομένων είναι έννοιες άρρηκτα συνδεδεμένες με την επιτυχία των προβλέψεων που παράγει το μοντέλο.

2.1.1 Είδη προβλημάτων μάθησης

Μερικά από τα πιο συνήθη προβλήματα μηχανικής μάθησης που έχουν μελετηθεί και συνεχίζονται και μελετώνται είναι:

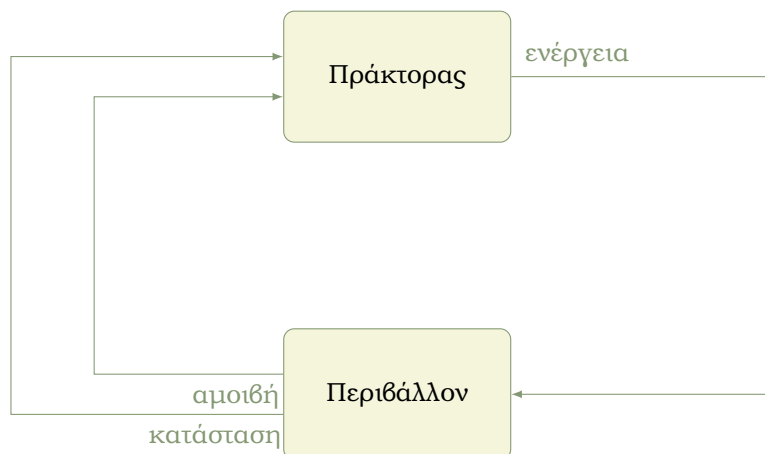
- Η ταξινόμηση: σε αυτή την κατηγορία προβλήματος γίνεται ανάθεση μιας κατηγορίας σε κάθε δείγμα του συνόλου δεδομένων και ο σκοπός του μοντέλου πρόβλεψης είναι να διαπιστώσει σε ποια κατηγορία ανήκει κάποια παρατήρηση. Σε αυτού του είδους τα προβλήματα, ο αριθμός των κλάσεων ποικίλει. Μπορεί να υπάρχουν δύο μόνο κλάσεις, που σημαίνει ότι πρόκειται για δυαδική ταξινόμηση, μπορεί να υπάρχουν μερικές δεκάδες ή εκατοντάδες κλάσεις ή και άπειρες όπως είναι το πρόβλημα της αναγνώρισης φωνής.

- Η παλινδρόμηση: αυτό είναι το πρόβλημα στο οποίο γίνεται πρόβλεψη μιας συνεχούς τιμής, όπως για παράδειγμα πρόβλεψη της τιμής μιας μετοχής. Σε αυτά τα προβλήματα, για την αξιολόγηση των προβλέψεων υπολογίζεται το πόσο πολύ διαφέρουν οι προβλεπόμενες από τις πραγματικές τιμές.
- Η ομαδοποίηση: σε αυτό το πρόβλημα γίνεται διαμέριση του συνόλου δεδομένων σε ομοιογενείς επιμέρους ομάδες. Συχνά χρησιμοποιείται ως μέρος της ανάλυσης δεδομένων.
- Η μείωση διαστατικότητας: το πρόβλημα αυτό αφορά τη διαδικασία κατά την οποία τα αρχικά δεδομένα μετατρέπονται σε αναπαραστάσεις μικρότερων διαστάσεων διατηρώντας παράλληλα την αρχική πληροφορία.
- Η κατάταξη: σε αυτό το πρόβλημα το μοντέλο μαθαίνει να κατατάσσει τα αντικείμενα μελέτης σε σειρά ανάλογα με κάποιο κριτήριο.

2.1.2 Είδη μηχανικής μάθησης

Η μηχανική μάθηση κατά τους συγγραφείς του [4] διακρίνεται σε επιμέρους κατηγορίες ανάλογα με τη μοντελοποίηση του εκάστοτε προβλήματος. Κατ' αυτόν τον τρόπο έχουμε:

- Επιβλεπόμενη μάθηση, όπου ο αλγόριθμος δημιουργεί μία συνάρτηση που αντιστοιχίζει τα δεδομένα εισόδου σε κάποια επιθυμητή έξοδο. Ένα είδος επιβλεπόμενης μάθησης είναι το πρόβλημα της ταξινόμησης, όπου το μοντέλο καλείται να μάθει τη συνάρτηση αντιστοίχισης ενός διανύσματος σε μία κλάση από ένα σύνολο κλάσεων που έχουν οριστεί για το πρόβλημα, έχοντας εκπαιδευτεί σε ένα σύνολο από δείγματα διανυσμάτων με τις αντίστοιχες κλάσεις στις οποίες ανήκουν.
- Μη επιβλεπόμενη μάθηση, όπου δεν υπάρχουν διαθέσιμες ετικέτες (κλάσεις) για κάθε δείγμα του συνόλου δεδομένων.
- Μερικώς επιβλεπόμενη μάθηση, όπου ο αλγόριθμος βασίζεται σε δείγματα που είτε έχουν είτε δεν έχουν ετικέτες.
- Ενισχυτική μάθηση, όπου ο αλγόριθμος μαθαίνει την πολιτική της λήψης μιας απόφασης βασισμένης σε μια παρατήρηση που λαμβάνει από το περιβάλλον του κόσμου που έχει οριστεί για το συγκεκριμένο πρόβλημα. Κάθε ενέργεια φέρει και το αντίστοιχο αποτέλεσμα στη διαμόρφωση του περιβάλλοντος την επόμενη χρονική στιγμή και ως εκ τούτου το μοντέλο εκπαιδεύεται τελικώς από την αλληλεπίδρασή του με το περιβάλλον.



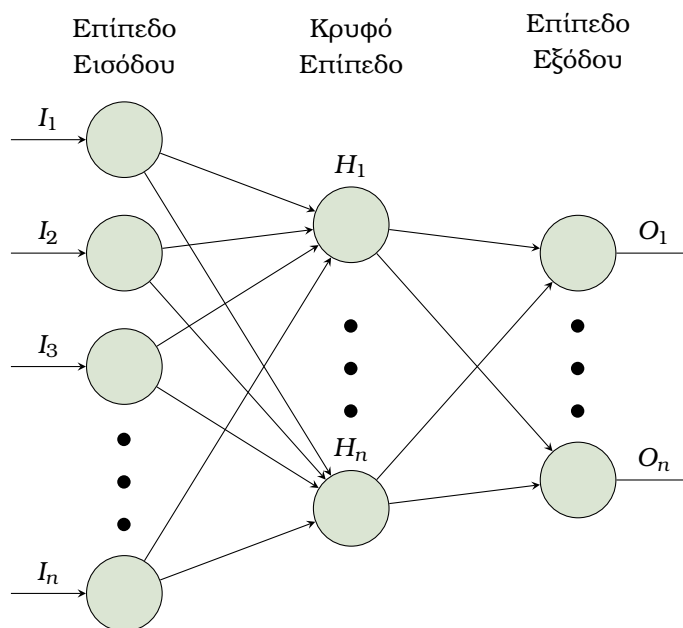
Σχήμα 2.1: Μοντέλο ενισχυτικής μάθησης

2.1.3 Νευρωνικά δίκτυα

Μοντέλα τεχνητών νευρωνικών δικτύων έχουν μελετηθεί για την καλύτερη αντιμετώπιση προβλημάτων ιδιαίτερα στο χώρο της υπολογιστικής όρασης, της επεξεργασίας φωνής και φυσικής γλώσσας. Τα μοντέλα αυτά περιλαμβάνουν πολλούς μη γραμμικούς υπολογισμούς που μπορούν να λειτουργήσουν παράλληλα προσομοιώνοντας έτσι την ανθρώπινη σκέψη. Κατ' αντιστοιχία με τον ανθρώπινο εγκέφαλο ένα νευρωνικό δίκτυο αποτελείται από υπολογιστικούς κόμβους και νευρώνες (συνάψεις) μεταξύ των κόμβων. Η συμβολή κάθε νευρώνα στην εκπαίδευση του μοντέλου καθορίζεται από το αντίστοιχο βάρος. Τα βάρη του δικτύου αναπροσαρμόζονται κατά τη διαδικασία εκπαίδευσης του μοντέλου με σκοπό την επίτευξη της ακριβέστερης πρόβλεψης. Στη συνέχεια γίνεται αναφορά στα είδη νευρωνικών δικτύων που χρησιμοποιήθηκαν στην παρούσα εργασία.

Πλήρως Συνδεδεμένα Νευρωνικά Δίκτυα

Τα πλήρως συνδεδεμένα νευρωνικά δίκτυα έχουν αρχιτεκτονική τέτοια ώστε όλοι οι κόμβοι ή οι νευρώνες ενός στρώματος να συνδέονται με όλους τους κόμβους του επόμενου στρώματος. Αυτός ο τύπος αλγορίθμου δεν συναντάται συχνά ιδίως όταν πρόκειται για ένα αρκετά βαθύ δίκτυο. Αυτό συμβαίνει επειδή τα δίκτυα αυτά απαιτούν μεγάλη υπολογιστική δύναμη και συγχρόνως είναι επιρρεπή στο να οδηγήσουν το μοντέλο σε υπερεκπαίδευση. Ένα παράδειγμα ενός τέτοιου δικτύου φαίνεται παρακάτω :



Σχήμα 2.2: Πλήρως συνδεδεμένο νευρωνικό δίκτυο

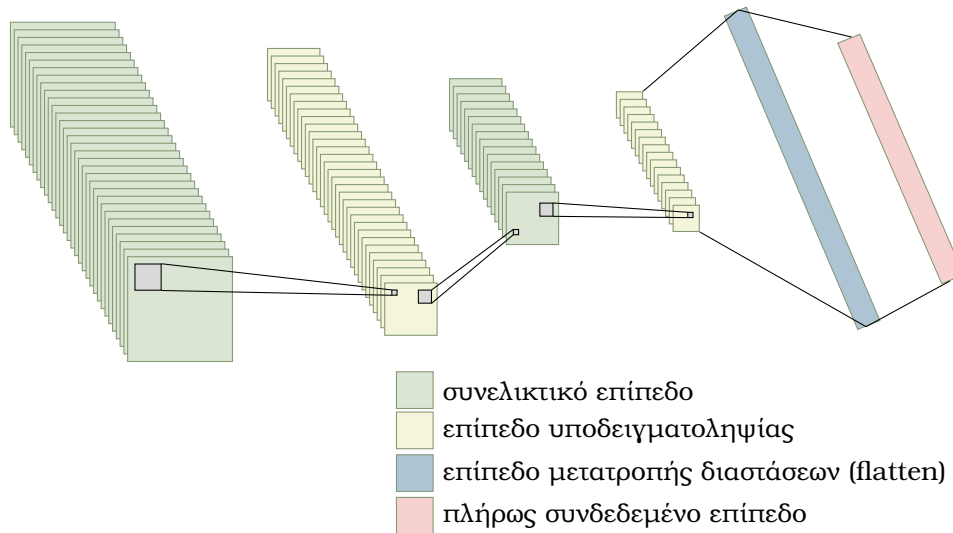
Συνελικτικά Νευρωνικά Δίκτυα

Τα συνελικτικά δίκτυα οφείλουν το όνομά τους στη μαθηματική γραμμική πράξη της συνέλιξης μεταξύ των πινάκων. Τέτοιου τύπου δίκτυα έχουν αποδειχθεί ικανά να εξαγάγουν χρήσιμες πληροφορίες από πίνακες. Έχουν εφαρμοστεί κυρίως σε προβλήματα υπολογιστικής όρασης, ταξινόμησης εικόνων αλλά και σε προβλήματα χρονοσειρών. Σύμφωνα με τον Albawi κ.σ. [5] ο λόγος που οδήγησε στην εκτεταμένη χρήση αυτού του είδους δικτύου είναι η μείωση των προς εκπαίδευση παραμέτρων. Πιο συγκεκριμένα, στην περίπτωση που αντί για συνελικτικά επίπεδα το δίκτυο απαρτιζόταν από πλήρως συνδεδεμένα επίπεδα για εικόνες εισόδου διαστάσεως $H \times W \times D$, για τη σύνδεση με ένα μόνο κόμβο στο κρυφό επίπεδο θα χρειαστούν $H \times W \times D$ συνδέσεις που σημαίνει $H \times W \times D \times 2$ παράμετροι. Ωστόσο, ένα κρυφό επίπεδο με έναν κόμβο δε θα προσφέρει σημαντική υπολογιστική ισχύ στον μοντέλο. Κατά συνέπεια, ψάχνοντας μία αποδοτικότερη λύση, αντί για πλήρη σύνδεση μεταξύ των κόμβων διαφορετικών επιπέδων, προτάθηκε η εξαγωγή χαρακτηριστικών ανά περιοχές της εικόνες. Με άλλα λόγια οι κρυφοί νευρώνες του επόμενου επιπέδου λαμβάνουν την είσοδο μόνο από την αντίστοιχη περιοχή του προηγούμενου επιπέδου.

Τα συνελικτικά επίπεδα εκτός από το μέγεθος πυρήνα έχουν και μία άλλη παραμέτρο που είναι ικανή να μειώσει περαιτέρω το συνολικό αριθμό παραμέτρων του δικτύου. Πρόκειται για το βήμα συνέλιξης που σχετίζεται με τον τρόπο που μετακινείται ο πυρήνας συνέλιξης στην εικόνα εισόδου.

Η μαθηματική αναπαράσταση της συνέλιξης ορίζεται ως ακολούθως:

$$conv(i,j) = (x * w)[i,j] = \sum_k (\sum_m \sum_n x_k[m,n] w[i-m,j-n])$$



Σχήμα 2.3: Βασική αρχιτεκτονική συνελικτικού δικτύου

Εκτός από τη συνηθισμένη μορφή της συνέλιξης που παρουσιάστηκε, στην παρούσα εργασία χρησιμοποιείται και η διαχωρίσιμη συνέλιξη. Πάνω σε αυτή τη δομή βασίστηκε το μοντέλο Xception [6]. Σύμφωνα με αυτό το άρθρο, αυτό το είδος της συνέλιξης αποτελείται από δύο στάδια:

- συνέλιξη ως προς το βάθος, δηλαδή χωρική συνέλιξη που εφαρμόζεται ανεξάρτητα σε κάθε κανάλι εισόδου
- σημειακή συνέλιξη, συνέλιξη 1×1 που ενώνει τις επιμέρους εξόδους των καναλιών.

Η μαθηματική έκφραση της διαχωρίσιμης συνέλιξης με βάση το [7] είναι: Συνέλιξη ως προς το βάθος:

$$conv_{depth}(i,j) = (x * w)[i,j] = \sum_m \sum_n x[m,n]w[i-m,j-n]$$

Σημειακή συνέλιξη:

$$conv_{point}(i,j) = \sum_l^L x[l] \cdot w[i,j,l]$$

Διαχωρίσιμη συνέλιξη:

$$conv_{seperable} = conv_{point}(x_p, conv_{depth}(x_d, w))$$

Το πλεονέκτημα της διχωρίσιμης ως προς το βάθος συνέλιξης έναντι της κανονικής συνέλιξης είναι ότι η πρώτη πρακτικά ορίζει ανεξάρτητα χαρακτηριστικά τα οποία στο τέλος συνενώνονται. Αντιθέτως, η τελευταία προσπαθεί να μάθει τα φίλτρα που πρέπει ταυτόχρονα να εξάγουν και να ενώσουν και τα χωρικά χαρακτηριστικά. Αυτό σημαίνει ότι ο αριθμός των προς εκπαίδευση παραμέτρων είναι πολύ μεγαλύτερος σε αυτή την περίπτωση και κατά συνέπεια αυξάνεται η πολυπλοκότητα και η επιρρέπεια του δικτύου στο φαινόμενο της υπερεκπαίδευσης.

Ο αριθμός των παραμέτρων στη γενική περίπτωση για τα δύο είδη συνέλιξης είναι:

Μέθοδος	Αριθμός παραμέτρων
Κανονική Συνέλιξη	$(k \times k \times I) \times I$
Διαχωρισμη Συνέλιξη ως προς το βάθος	$k \times k \times I + I \times O$

Πίνακας 2.1: Συγκριτικός πίνακας παραμέτρων

 $k \times k$: μέγεθος πυρήνα I : αριθμός καναλιών εισόδου O : αριθμός καναλιών εξόδου

Άλλα στοιχεία νευρωνικών δικτύων

Το επόμενο στρώμα μετά από κάποιο κρυφό επίπεδο (σαν αυτά που είδαμε παραπάνω) είναι μια μη γραμμική συνάρτηση ενεργοποίησης. Ο σκοπός αυτής της μη γραμμικότητας είναι να προσαρμόζει ή να φιλτράρει την έξοδο της συνέλιξης. Το επίπεδο αυτό εφαρμόζεται για να περιορίσει τις τιμές του παραγόμενου αποτελέσματος. Αν χρησιμοποιηθεί γραμμική συνάρτηση τότε θα είναι ευκολότερο για το μοντέλο να εκπαιδευτεί αλλά δυσκολότερο να μάθει περίπλοκες συσχετίσεις. Τέτοιου είδους συναρτήσεις χρησιμοποιούνται συνήθως στο επίπεδο εξόδου δικτύων που λύνουν προβλήματα παλινδρόμησης και έχουν ως στόχο να προβλέψουν μια ποσότητα δηλαδή μία συνεχή τιμή.

Μερικές από τις πιο γνωστές συναρτήσεις ενεργοποίησης σύμφωνα με τα άρθρα [8] και [9] είναι οι:

- σιγμοειδής: Η συνάρτηση αυτή λαμβάνει τιμές από 0 έως 1. Ο τύπος της συνάρτησης είναι ο ακόλουθος:

$$g(x) = \frac{1}{1+e^{-x}}, \text{ όπου } x = w_{ji}v_i + b_i$$

Ωστόσο, η παράγωγος της σιγμοειδούς συνάρτησης κοντά στην περιοχή του μηδενός και του ένα γίνεται σχεδόν μηδέν. Κατά συνέπεια, τα δεδομένα δεν περνάνε μέσω των νευρώνων για να ανανεώσουν τα βάρη κατά τη διάρκεια του back propagation. Έτσι, αυτό το φαινόμενο της εξαφάνισης της παραγώγου (vanishing gradient), όπως ονομάζεται, μειώνει την αποτελεσματικότητα του δικτύου. Επιπλέον, το γεγονός ότι είναι κεντραρισμένη στο 0.5 επιβραδύνει την εκμάθηση.


- υπερβολική εφαιπομένη (tanh): Η συνάρτηση αυτή έχει εύρος τιμών από -1 έως 1 και είναι κεντραρισμένη στο μηδέν. Ωστόσο, δεν λύνει το πρόβλημα της εξαφάνισης της παραγώγου. Ο τύπος της συνάρτησης είναι ο ακόλουθος:

$$\tanh(x) = \frac{\sinh(x)}{\cosh(x)} = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

- ReLU: Είναι πλέον από τις πιο διαδεδομένες συναρτήσεις ενεργοποίησης καθώς είναι αρκετά απλή και επιτυγχάνει χαμηλό υπολογιστικό χρόνο κατά την εκπαίδευση. Επίσης, η ReLU λύνει το πρόβλημα της εξαφάνισης της παραγώγου που εμφανίζεται με τις προηγούμενες δύο συναρτήσεις καθώς η παράγωγος είναι σταθερή για θετική είσοδο. Άλλο ένα πλεονέκτημα της συνάρτησης αυτής είναι ότι δημιουργεί μια πιο αραιή αναπαράσταση λόγω του μηδενός στην παραγωγή.

$$\text{relu}(x) = \max(0, x)$$

$$\frac{d}{dx}\text{relu}(x) = \begin{cases} 0 & \text{if } x \leq 0 \\ 1 & \text{if } x > 0 \end{cases}$$




Σχήμα 2.4: Συναρτήσεις ενεργοποίησης

Αναδρομικά νευρωνικά δίκτυα

Κατά την ενδελεχή μελέτη των Lipton κ.σ. [10] τα αναδρομικά δίκτυα είναι δίκτυα πρόσθιας τροφοδότησης που όμως περιλαμβάνουν επιπλέον ακμές οι οποίες συνδέουν διαδοχικές χρονικές στιγμές μεταξύ τους. Τη χρονική στιγμή t , οι κόμβοι με αναδρομικές ακμές λαμβάνουν είσοδο από το τρέχον δείγμα X_t αλλά και από τις τιμές των κρυφών κόμβων (h_{t-1}) της προηγούμενης κατάστασης του δικτύου. Η έξοδος κάθε χρονική στιγμή t υπολογίζεται από τις τιμές h_t . Κατ' αυτόν τον τρόπο η είσοδος τη στιγμή $t-1$ μπορεί να επηρεάσει το αποτέλεσμα \hat{y}_t τη χρονική στιγμή t αλλά και το αποτέλεσμα μεταγενέστερων χρονικών στιγμών χάρη στις αναδρομικές συνδέσεις μεταξύ των κόμβων.

Στην εικόνα 2.5 φαίνεται σχηματικά ένα αναδρομικό επίπεδο ενός δικτύου τόσο στην συμπυγμένη όσο και στην ανεπτυγμένη του μορφή. Για τη συνέχεια της εργασίας όταν θα γίνεται αναφορά σε αναδρομικό δίκτυο θα χρησιμοποιούνται τα σχήματα αυτά.


Στο άρθρο [11] των Schuster και Paliwal γίνεται λόγος για τα αμφίδρομα αναδρομικά δίκτυα. Στα απλά αναδρομικά δίκτυα η πληροφορία μεταφερόταν προς μία μόνο κατεύθυνση (πρόσθια). Αυτό, ωστόσο, παρουσιάζει κάποιους περιορισμούς σε ορισμένα προβλήματα. Για παράδειγμα, στο πρόβλημα πρόβλεψης της επόμενης λέξης σε μία πρόταση, το απλό αναδρομικό δίκτυο δεν έχει τη δυνατότητα να εκπαιδευτεί λαμβάνοντας υπόψη μεταγενέστερες λέξεις. Μπορεί να κρατήσει μόνο την προγενέστερη πληροφορία. Τα αναδρομικά δίκτυα διπλής κατεύθυνσης μπορούν έχουν καλύτερη αντίληψη του περιεχομένου καθώς η πληροφορία ρέει τόσο από το παρελθόν στο παρόν όσο και από το μέλλον στο παρόν. Η ιδέα της δομής αυτών των δικτύων βασίζεται στο γεγονός ότι οι έξοδοι από κάθε κατεύθυνση δεν συνδέονται με τις εξόδους της άλλης. Η ανεπτυγμένη μορφή του δικτύου για n χρονικές στιγμές φαίνεται στο σχήμα 2.6.



(α) Γενικευμένη μορφή αναδρομικού δικτύου
A: μεμονωμένη δομή αναδρομικού δικτύου

(β) Ανοιχτή μορφή αναδρομικού επιπέδου.

Σχήμα 2.5: Σχήμα αναδρομικού δικτύου



Σχήμα 2.6: Ανεπτυγμένη μορφή αναδρομικού επιπέδου διπλής κατεύθυνσης.

Όπως φαίνεται στο σχήμα, αν αφαιρέσουμε τη δεξιά σειρά αναδρομικών μονάδων προκύπτει μία δομή που είναι ίδια με αυτή του απλού αναδρομικού δικτύου. Στο αμφίδρομο αναδρομικό δίκτυο, η έξοδος της πρόσθιας κατεύθυνσης συνενώνεται με αυτή της προς τα πίσω κατεύθυνσης.

Ένα είδος αναδρομικού δικτύου που επικρατεί σε εφαρμογές με δεδομένα που σχετίζονται χρονικά μεταξύ τους είναι οι νευρώνες μακράς και βραχείας μνήμης (Long Short-Term Memory (LSTM)). Προτάθηκε από τους Hochreiter και Schmidhuber [12] ως λύση στα προβλήματα που εισήγαγαν οι παλαιότερες τεχνικές για διαδοχικά δεδομένα, όπως είναι η ταλάντωση μεταξύ τιμών στα βάρη του δικτύου και ο εξαιρετικά μεγάλος χρόνος γεφύρωσης μεγάλων χρονικών κενών ή ακόμα και η αδυναμία γεφύρωσης αυτών.

Σύμφωνα με τον Le κ.σ. [13] ένα τυπικό δίκτυο μακράς και βραχείας μνήμης αποτελείται από τμήματα μνήμης που λέγονται κελιά. Δύο πληροφορίες μεταφέρονται από το ένα κελί στο επόμενο. Αυτά είναι η κρυφή έξοδος και η έξοδος του κελιού. Η έξοδος του κελιού είναι που επιτρέπει τα δεδομένα να ρέουν από τις παρελθοντικές χρονικές στιγμές προς τις μελλοντικές. Κατά τη ροή της πληροφορίας μπορούν να συμβούν κάποιοι γραμμικοί μετασχηματισμοί. Τα δεδομένα μπορεί να προστεθούν ή να διαγραφούν από την έξοδο του κελιού μέσω σιγμοειδών πυλών. Ως πύλη, θεωρούμε μια σειρά από υπολογισμούς πινάκων που περιλαμβάνουν διαφορετικά βάρη. Έτσι, τα δίκτυα αυτά έχουν τη δυνατότητα να αποφεύγουν μακροπρόθεσμες συσχετίσεις καθώς χρησιμοποιούν πύλες για να ελέγχουν τη διαδικασία απομνημόνευσης της πληροφορίας που προέρχεται από τα δεδομένα εισόδου.

Η λογική σε κάθε βήμα εκπαίδευσης ενός τέτοιου αναδρομικού δικτύου είναι να εντο-

πίζεται ποιο τμήμα της πληροφορίας δε χρειάζεται και συνεπώς μπορεί να παραληφθεί στην πορεία της μάθησης, δηλαδή κατά τη μετάβαση στο επόμενο κελί. Τη διαδικασία αυτή αναλαμβάνει και φέρνει σε πέρας η σιγμοειδής συνάρτηση, η οποία παίρνει ως είσοδο την κρυφή έξοδο του προηγούμενου κελιού (h_{t-1}) καθώς επίσης και την τρέχουσα είσοδο (X_t). Η πύλη αυτή ονομάζεται πύλη συγκράτησης πληροφορίας (forget gate). Η πύλη αυτή δίνει ένα διάνυσμα τιμών με εύρος από μηδέν έως ένα, που αντιστοιχούν στις τιμές της κατάστασης κελιού (C_{t-1}). Πιο συγκεκριμένα, το διάνυσμα της πύλης αυτής υπολογίζεται ως εξής:

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

όπου:

- σ η σιγμοειδής συνάρτηση
- W_f, b_f τα διανύσματα βαρών της πύλης

Στη συνέχεια, με βάση τη νέα είσοδο X_t ενημερώνεται η κατάσταση του κελιού. Αυτό συμβαίνει σε δύο στάδια. Αρχικά η είσοδος περνάει από μια σιγμοειδή συνάρτηση η οποία αποφασίζει αν η νέα πληροφορία θα πρέπει να αγνοηθεί ή να συνυπολογιστεί. Ύστερα, περνάει από μία συνάρτηση υπερβολικής εφαπτομένης η οποία προσδιορίζει τα βάρη των τιμών που περνάνε. Οι έξοδοι των δύο αυτών συναρτήσεων πολλαπλασιάζονται για να ανανεώσουν τη νέα κατάσταση του κελιού. Αυτό το νέο τμήμα μνήμης προστίθεται στο προηγούμενο C_{t-1} και προκύπτει το διάνυσμα του C_t .

Η έξοδος της σιγμοειδούς είναι:

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

Η έξοδος της υπερβολικής εφαπτομένης είναι:

$$N_t = \tanh(W_n[h_{t-1}, X_t] + b_n)$$


Τέλος, η κατάσταση του κελιού υπολογίζεται ως εξής:

$$C_t = C_{t-1} \cdot f_t + N_t \cdot i_t$$

όπου b_o και W_o τα βάρη της πύλης εξόδου. Στο τελικό στάδιο, μία σιγμοειδής συνάρτηση αποφασίζει ποιο τμήμα της πληροφορίας θα καταλήξει στην έξοδο και ποιο όχι. Στη συνέχεια, η έξοδος της σιγμοειδούς πολλαπλασιάζεται με την έξοδο της υπερβολικής εφαπτομένης που έχει σαν είσοδο την κατάσταση του κελιού (C_t). Κατά συνέπεια, η εξίσωση υπολογισμού της εξόδου της μονάδας μακράς και βραχείας μνήμης ορίζεται ως ακολούθως:

$$h_t = \sigma(W_o[h_{t-1}, X_t] + b_o) \cdot \tanh(C_t)$$

Παρακάτω φαίνεται η δομή μιας μονάδας μακράς και βραχείας μνήμης, όπως αυτή περιγράφηκε στις προηγούμενες παραγράφους.



Σχήμα 2.7: Δομή κελιού μακράς και βραχείας μνήμης

Συνάρτηση απωλειών και βελτιστοποιητής

Σε ένα νευρωνικό δίκτυο, όπως αυτά που ορίστηκαν στις προηγούμενες παραγράφους, πρέπει να υπάρχει μια συνάρτηση απώλειας (loss function) βάσει της οποίας να παρακολουθείται η απόκλιση της πρόβλεψης από την πραγματική τιμή. Υπάρχουν πολλές συναρτήσεις που εξυπηρετούν αυτόν τον σκοπό και η καταλληλότητά τους εξαρτάται από το είδος του προβλήματος που καλείται να λύσει το νευρωνικό δίκτυο.

Για προβλήματα ταξινόμησης χρησιμοποιείται η απώλεια διασταυρούμενης εντροπίας που ορίζεται ως εξής:

$$J = - \sum_i^M p(y)_i \log(q(y)_i)$$

όπου:

- M είναι ο αριθμός των κλάσεων,
- $p(y)_i$ είναι η πιθανότητα του y_i να είναι η πραγματική τιμή και
- $q(y)_i$ είναι η πιθανότητα του y_i να είναι η προβλεπόμενη τιμή

Η συνάρτηση απωλειών είναι συνάρτηση διαφόρων παραμέτρων μάθησης του δικτύου (βάρη και σταθερές (weights and bias». Για ακριβείς προβλέψεις χρειάζεται κανείς να ελαχιστοποιήσει την απώλεια μεταξύ προβλέψεων και πραγματικών τιμών. Σε ένα νευρωνικό δίκτυο αυτό συμβαίνει με τη χρήση της προς τα πίσω διάδοσης. Η τρέχουσα διαφορά μεταξύ των τιμών διαδίδεται προς τα πίσω, σε κάποιο προηγούμενο επίπεδο, όπου χρησιμοποιείται για να αλλάξει τα βάρη με τέτοιο τρόπο ώστε η απώλεια, τελικά, να ελαχιστοποιείται.

$$W_{k+1} = W_k - \frac{\partial}{\partial W_k} J(w)$$

Τα βάρη αλλάζουν τιμές σύμφωνα με μια συνάρτηση που λέγεται συνάρτηση βελτιστοποίησης (optimization function). Συνήθως, τέτοιου είδους συναρτήσεις υπολογίζουν τη μερική

παράγωγο της συνάρτησης απωλειών ως προς τα βάρη και τα βάρη προσαρμόζονται σύμφωνα με την αντίθετη κατεύθυνση της κλίσης. Αυτή η διαδικασία συνεχίζεται έως φτάσει το ελάχιστο της συνάρτησης απωλειών.

Ο πιο δημοφιλής αλγόριθμος βελτιστοποίησης ο SGD, Stochastic Gradient Descent ανήκει στην κατηγορία αλγορίθμων με σταθερό ρυθμό μάθησης, όπου τα νέα βάρη υπολογίζονται ως εξής:

$$W_{k+1} = W_k - \eta(\Delta J(w)), \text{ όπου } \eta: \text{ ο ρυθμός μάθησης}$$

Η άλλη κατηγορία αλγορίθμων βελτιστοποίησης είναι αυτή που προσαρμόζουν το ρυθμό μάθησης. Αυτοί οι αλγόριθμοι έρχονται να αντιμετωπίσουν το πρόβλημα του SGD, ο οποίος απαιτεί τον εκ των προτέρων καθορισμό των υπερπαραμέτρων του. Διαθέτουν μεθόδους ρυθμού μάθησης για κάθε παράμετρο χωριστά, δίχως να απαιτείται πολλή δουλειά για τον προσδιορισμό των παραμέτρων από τον προγραμματιστή. Τέτοιος αλγόριθμος είναι ο Adam (Adaptive Moment Estimation) ο οποίος χρησιμοποιείται στα πειράματα της εργασίας.

2.1.4 Ενισχυτική μάθηση

Όπως αναφέρθηκε στην προηγούμενη ενότητα η ενισχυτική μάθηση βασίζεται στην αλληλεπίδραση του πράκτορα με το περιβάλλον του. Για κάθε ενέργεια που αποφασίζει να κάνει κερδίζει μια αμοιβή ή τιμωρείται με αφαίρεση «πόντων». Η μάθηση ενός τέτοιου μοντέλου επικεντρώνεται στη δυνατότητά του να μεγιστοποιήσει τον τρόπο με τον οποίο λαμβάνει αυτές τις αμοιβές.

Σύμφωνα με τους συγγραφείς του βιβλίου [14] η ενισχυτική μάθηση είναι θεμελιωμένη στην ιδέα της της θεωρίας δυναμικών συστημάτων και ειδικά στη θεωρία των Μαρκοβιανών διαδικασιών απόφασης. Ένας πράκτορας πρέπει να είναι σε θέση να καταλαβαίνει την κατάσταση του περιβάλλοντος με το οποίο έρχεται σε επαφή και να μπορεί να λαμβάνει αποφάσεις ικανές να μεταβάλλουν αυτή την κατάσταση. Επιπλέον, ένας πράκτορας πρέπει να έχει ένα στόχο ή ένα σύνολο από στόχους. Οι διαδικασίες λήψης απόφασης κατά Μαρκον (Markov decision process, MDP) είναι σχεδιασμένες να καλύπτουν αυτές τις τρεις προϋποθέσεις. Οποιαδήποτε μέθοδος είναι κατάλληλη να λύσει τέτοιου είδους προβλήματα θεωρείται μέθοδος ενισχυτικής μάθησης.

Μία μεγάλη πρόκληση σε αυτού του είδους τις μεθόδους είναι η ισορροπία μεταξύ της εξερεύνησης (exploration) και της εκμετάλλευσης (exploitation). Ο πράκτορας, προκειμένου να μεγιστοποιήσει το κέρδος του, θα πρέπει να προτιμήσει ενέργειες που έχει δοκιμάσει στο παρελθόν και αποδείχθηκαν επικερδείς. Από την άλλη όμως, θα πρέπει να δοκιμάσει και νέες ενέργειες ώστε να σχηματίσει καλύτερη εικόνα για το ευρύτερο περιβάλλον. Πρόκειται για δύο τάσεις του πράκτορα που έρχονται σε σύγκρουση μεταξύ τους και καμία από αυτές δε μπορεί να υιοθετηθεί πλήρως κατά τη διάρκεια της εκπαίδευσης χωρίς να οδηγήσει το σύστημα σε αποτυχία. Ο σκοπός του πράκτορα είναι να δοκιμάσει ποικίλες ενέργειες και προοδευτικά να αρχίσει να προτιμάει αυτές που φαίνονται καλύτερες.

2.1.5 Στοιχεία της ενισχυτικής μάθησης

Πέρα από τον πράκτορα και το περιβάλλον, μπορούμε να προσδιορίσουμε τέσσερα κυρίως στοιχεία ενός συστήματος ενισχυτικής μάθησης. Αυτά είναι τα ακόλουθα:

- **πολιτική:** Μία πολιτική, με την ευρεία έννοια, θα μπορούσε να θεωρηθεί ότι είναι ένα είδος αντιστοίχισης μεταξύ των καταστάσεων και των ενεργειών. Σε κάποιες περιπτώσεις η πολιτική μπορεί να είναι πολύ απλή όπως ένας πίνακας αντιστοίχισης, ενώ κάποιες άλλες φορές μπορεί να είναι ολόκληρη διαδικασία εύρεσης. Επίσης, μια πολιτική μπορεί να είναι στοχαστική, δηλαδή να προσδιορίζει πιθανότητες για κάθε ενέργεια. Γενικά, αποτελεί τον πυρήνα του συστήματος, αφού από μόνη της είναι επαρκής για να καθορίσει τη συμπεριφορά του πράκτορα.
- **αμοιβή:** Ένα σήμα αμοιβής προσδιορίζει το στόχο του μοντέλου ενισχυτικής μάθησης. Κάθε χρονική στιγμή το περιβάλλον απαντάει σε μια απόφαση δίνοντας κάποια αμοιβή ή τιμωρία στον πράκτορα. Η συνάρτηση αμοιβής είναι που καθορίζει τι είναι ωφέλιμο και τι επιβλαβές για την εκμάθηση του περιβάλλοντος. Μπορεί να είναι στοχαστικής φύσεως. Σε γενικές γραμμές, η αμοιβή καθορίζει την αλλαγή της πολιτικής, με την έννοια του ότι αν η αμοιβή είναι πολύ μικρή τότε η πολιτική θα αντιστοιχίσει την κατάσταση με κάποια άλλη ενέργεια.
- **συνάρτηση αξίας:** Η συνάρτηση αξίας σε αντίθεση με τη συνάρτηση αμοιβής εκφράζει τι είναι καλό για τον πράκτορα μακροπρόθεσμα και όχι για την τρέχουσα κατάσταση. Γενικά, η αξία μιας κατάστασης θεωρείται η συνολική αμοιβή που ένας πράκτορας αναμένει να κερδίσει στο μέλλον. Για παράδειγμα, μία κατάσταση μπορεί πάντα να αποδίδει μικρή αμοιβή όμως να ακολουθείται από άλλες καταστάσεις που αποδίδουν μεγάλη αμοιβή και έτσι μακροπρόθεσμα να πετυχαίνει μεγάλο άθροισμα αμοιβών. Επίσης, θα μπορούσε να συμβεί και το αντίθετο. Κατά συνέπεια η συνάρτηση αξίας είναι απαραίτητη για την εξασφάλιση σταθερής συμπεριφοράς του πράκτορα. Στην πραγματικότητα, αυτό που μας ενδιαφέρει στην ενισχυτική μάθηση είναι να μεγιστοποιήσουμε τη συνολική αμοιβή και κατ' επέκταση να κάνει το σύστημα ενέργειες που αποφέρουν μεγάλη αμοιβή - συνολικά. Ωστόσο, ο ορισμός της αξίας μιας κατάστασης του περιβάλλοντος είναι πολύ πιο δύσκολος από αυτόν της αμοιβής, καθώς η πρώτη θα πρέπει να υπολογίζεται ξανά και ξανά κατά τη διάρκεια μάθησης του μοντέλου.
- **μοντέλο περιβάλλοντος:** Πρόκειται για μίμηση της συμπεριφοράς του περιβάλλοντος και επιτρέπει στον πράκτορα να καταλαβαίνει πώς το περιβάλλον πρόκειται να συμπεριφερθεί μετά από κάθε ενέργεια. Πρέπει, για παράδειγμα, να γνωρίζει την επόμενη κατάσταση ή την επόμενη αμοιβή.

Λαμβάνοντας υπόψη την εισαγωγική περιγραφή της ενισχυτικής μάθησης, που έγινε παραπάνω, θα αναλύσουμε ένα στοχαστικό αλγόριθμο που ανήκει σε αυτή την κατηγορία μάθησης. Πρόκειται για τον αλγόριθμο Q-learning. Σύμφωνα με το βιβλίο του Haykin [15], ο αλγόριθμος αυτός έχει σκοπό να βελτιστοποιήσει την πολιτική, δοκιμάζοντας ακολουθίες καταστάσεων του περιβάλλοντος και υπολογίζοντας τις αμοιβές που χαρακτηρίζουν τις μεταβάσεις από κατάσταση σε κατάσταση. Για το λόγο αυτό, χρησιμοποιείται μια πολιτική

συμπεριφοράς όπως ονομάζεται και όχι πολιτική εκτίμησης, όπως είδαμε προηγουμένως. Η διαφορά έγκειται στο ότι, στην περίπτωση του Q-learning, ο αλγόριθμος προσπαθεί μέσα από δειγματοληπτικές διαδικασίες να ελέγξει όλες τις ενέργειες. Αντιθέτως, η πολιτική εκτίμησης συνήθως εξερευνά τις καταστάσεις άπληστα (greedy). Έτσι, ο αλγόριθμος αυτός χαρακτηρίζεται ως αλγόριθμος εκτός πολιτικής (off-policy).

Για τη μαθηματική περιγραφή του αλγορίθμου θα θεωρήσουμε το δείγμα:

$$(s_t, a_t, r_t, s_{t+1})$$

- s_t : Η κατάσταση του περιβάλλοντος τη στιγμή t .
- a_t : Η ενέργεια που εκτελείται στην κατάσταση s_t .
- r_t : Η αμοιβή που έλαβε ο πράκτορας με την εκτέλεση της ενέργειας a_t .
- s_{t+1} : Η επόμενη κατάσταση.

Θεωρώντας ως γ συντελεστή μείωσης της αμοιβής, η μειωμένη αμοιβή τη στιγμή t ορίζεται ως $R_t = \sum_{t'=t}^T \gamma^{t'-t} r_{t'}$, όπου T είναι η χρονική στιγμή του τερματισμού της αλληλεπίδρασης του πράκτορα με το περιβάλλον. Η βέλτιστη συνάρτηση ενέργειας-αξίας υπακούει στην ιδιότητα της εξίσωσης Bellman. Αυτό σημαίνει ότι αν η βέλτιστη τιμή $Q^*(s', a')$ μιας ακολουθίας s' ήταν γνωστή στην επόμενη χρονική στιγμή για όλες τις πιθανές ενέργειες τότε η βέλτιστη στρατηγική θα ήταν να επιλεγεί η ενέργεια εκείνη a' που μεγιστοποιεί την εκτιμώμενη τιμή $r + \gamma Q^*(s', a')$.

$$Q^*(s, a) = \mathbb{E}_{s'} [r + \gamma \max_{a'} Q^*(s', a')]$$

Στο άρθρο των Mnih κ.σ. [16] έγινε η πρώτη εισαγωγή στο βαθύ Q-learning (Deep Q-learning). Ο σκοπός των συγγραφέων ήταν να εκμεταλλευτούν τις δυνατότητες της βαθιάς μηχανικής μάθησης και να τη συνδυάσουν με την ενισχυτική μάθηση. Στα πλαίσια αυτής της προσπάθειας, εισήχθη ο όρος επανάληψη εμπειρίας (experience replay). Πρόκειται για την αποθήκευση δειγμάτων αλληλεπίδρασης του πράκτορα με το περιβάλλον του. Τέτοια δείγματα είναι της μορφής:

$$e_t = (s_t, a_t, r_t, s_{t+1})$$

Επομένως, προκύπτει ένα σύνολο δεδομένων $D = e_1, e_2, \dots, e_n$ που είναι αποθηκευμένο σε μια δομή που ονομάζεται μνήμη επανάληψης (replay memory). Κατά τη διάρκεια του αλγορίθμου η εσωτερική επανάληψη αντλεί τυχαία δείγματα εμπειρίας από τη μνήμη επανάληψης και τα ανανεώνει με την τεχνική Q-learning. Ύστερα, ο πράκτορας επιλέγει και εκτελεί μία ενέργεια σύμφωνα με την ϵ -άπληστη πολιτική (ϵ -greedy policy), δηλαδή με πιθανότητα ϵ επιλέγει μια τυχαία ενέργεια και με πιθανότητα $1 - \epsilon$ επιλέγει ενέργεια σύμφωνα με την άπληστη πολιτική.

Επίσης ο Mnih πρότεινε τη χρήση ενός δικτύου στόχου (target network) με παραμέτρους (θ_t^-). Το δίκτυο αυτό είναι το ίδιο με το δίκτυο εκπαίδευσης, μόνο που οι παράμετροί του αντιγράφονται κάθε τ χρονικές στιγμές από το δίκτυο εκπαίδευσης. Συνεπώς προκύπτει:

$$Y_t^{DQN} = R_{t+1} + \gamma \max_{a'} Q^*(s', a'; \theta_t^-)$$

Η προσέγγιση του Deep Q-learning έχει πλεονεκτήματα έναντι του κλασικού Q-learning:

- Αποδοτικότητα δεδομένων: Κάθε δείγμα εμπειρίας από το περιβάλλον μπορεί να αξιοποιηθεί σε περισσότερες από μία ανανεώσεις βαρών
- Αποδοτικότητα μάθησης: Η προσπάθεια του πράκτορα να μάθει παρατηρώντας συνεχόμενα δείγματα του περιβάλλοντος είναι συχνά αναποτελεσματική καθώς οι συσχετίσεις μεταξύ των δειγμάτων είναι ισχυρές. Η εισαγωγή της τυχαιότητας ως προς την επιλογή των δειγμάτων από την μνήμη επανάληψης διευκολύνει τη διαδικασία της μάθησης.
- Επίτευξη σύγκλισης: Όταν ο πράκτορας μαθαίνει εντός πολιτικής (on-policy) οι τρέχουσες παράμετροι καθορίζουν το επόμενο δείγμα στο οποίο οι παράμετροι έχουν εκπαιδευτεί. Κατά συνέπεια, στο σύστημα μάθησης υπεισέρχονται ανεπιθύμητοι βρόχοι με αποτέλεσμα το σύστημα να κολλάει σε τοπικά ακρότατα ή ακόμα και να μη συγκλίνει ποτέ. Το πρόβλημα αυτό επιλύεται χάρη στη μνήμη επανάληψης που πετυχαίνει την αποφυγή ταλαντώσεων μεταξύ ακρότατων και τη σύγκλιση του συστήματος.

Μετά την εισαγωγή του Deep Q-learning προέκυψαν άρθρα με παραλλαγές αυτής της μεθόδου μάθησης που οδήγησε σε ακόμα καλύτερη επίδοση των μοντέλων. Σημαντικά παραδείγματα αυτών είναι το άρθρο των [17] κ.σ. που έφερε στο φως την έννοια του Double Deep Q-learning, το άρθρο [18] που αμφισβήτησε την αναγκαιότητα ύπαρξης του δικτύου στόχου καθώς επίσης και η μελέτη [19], που συνδυάζει πολλές παραλλαγές ενωμένες σε ένα σύστημα.

Στα πλαίσια της παρούσας εργασίας θα αναφερθούμε στις αλλαγές που προτάθηκαν στο άρθρο [17] (Double Deep Q-learning). Ο παράγοντας max στην παραπάνω εξίσωση χρησιμοποιεί τις ίδιες τιμές και για να επιλέξει και για να αξιολογήσει μία ενέργεια. Αυτό αυξάνει την πιθανότητα να διαλέξει υπερεκτιμημένες τιμές, καταλήγοντας σε υπεραισιόδοξες εκτιμήσεις. Το πρόβλημα αυτό αντιμετωπίζεται με το διαχωρισμό της επιλογής από την αξιολόγηση. Έτσι, έχουμε δύο συναρτήσεις αξίας και συνεπώς δύο σύνολα παραμέτρων θ_t και θ'_t . Σε κάθε ανανέωση που γίνεται το ένα σύνολο χρησιμοποιείται για την άπληστη πολιτική και το άλλο για να καθορίσει την τιμή της. Πλέον, οι εξισώσεις γράφονται ως ακολούθως:

$$Y_t^Q = R_{t+1} + \gamma Q(s', \operatorname{argmax}'_a Q(s', a'; \theta_t); \theta_t)$$

$$Y_t^{DoubleQ} = R_{t+1} + \gamma Q(s', \operatorname{argmax}'_a Q(s', a'; \theta_t); \theta'_t)$$

Παρατηρούμε, ότι για την επιλογή χρησιμοποιούμε τις παραμέτρους θ_t του δικτύου εκπαίδευσης ενώ για την αξιολόγηση της πολιτικής χρησιμοποιούμε τις παραμέτρους θ'_t

Κεφάλαιο 3

Περιγραφή θέματος

Στο κεφάλαιο αυτό αρχικά γίνεται μια περιγραφή του προβλήματος που καλείται να αναλύσει η παρούσα εργασία.

3.1 Χρήσιμες έννοιες των χρηματιστηριακών συναλλαγών


Με τον όρο αλγοριθμικές συναλλαγές, σύμφωνα με το άρθρο [20], εννοείται η αυτοματοποιημένη διαδικασία κατά την οποία αναλύεται η εικόνα της αγοράς, εξάγονται χαρακτηριστικά που την περιγράφουν και προτείνονται σήματα για αγορά ή πώληση μετοχών, νομισμάτων κ.ά. Οι συναλλαγές αυτές μπορούν να επιτευχθούν κατευθείαν από κάποιον άνθρωπο, από τη συνεργασία ανθρώπου-υπολογιστή ή εξ' ολοκλήρου από τον υπολογιστή.

Πριν την εκτέλεση κάποιας ενέργειας (αγοράς ή πώλησης) πραγματοποιείται ανάλυση η οποία διακρίνεται σε τρία είδη:


- **Θεμελιώδης ανάλυση:** Πρόκειται για την ανάλυση που αφορά οποιαδήποτε πληροφορία μπορεί να επηρεάσει την κίνηση της τιμής. Για παράδειγμα, μπορεί να περιλαμβάνει τη λεπτομερή περιγραφή της οικονομικής κατάστασης δύο χωρών (δείκτης ανεργίας, ποσοστά τόκων / επιτοκίων, εθνικό ακαθάριστο προϊόν, εθνική πολιτική κ.ά.) Πρακτικά, η ανάλυση αυτή παράγει σήματα συναλλαγών όταν η τρέχουσα τιμή ενός στοιχείου αποκλίνει από την αναμενόμενη τιμή που προκύπτει από την θεμελιώδη ανάλυση.
- **Τεχνική ανάλυση:** Αποσκοπεί στην πρόβλεψη της κίνησης της αγοράς στο μέλλον η οποία βασίζεται σε ιστορικά δεδομένα και ορισμένες φορές σχετίζεται με πληροφορία που προκύπτει από τις συναλλαγές, όπως είναι ο όγκος των συναλλαγών. Αυτή η αναλυτική μέθοδος υποθέτει ότι οι τιμές της αγοράς αντικατοπτρίζουν όλες τις σχετικές πληροφορίες και έχει ως στόχο να εντοπίσει και να εκμεταλλευτεί μοτίβα στις μεταβολές της αγοράς και όχι να εξετάσει παράγοντες που επηρεάζουν τις τιμές των στοιχείων. Πολλές μέθοδοι τεχνικής ανάλυσης βασίζονται στην υπόθεση ότι οι τιμές κινούνται σύμφωνα με κάποια μοτίβα. Συνεπώς, παράγουν σήμα εισόδου όταν ένα ξεκινάει να εμφανίζεται ένα μοτίβο και σήμα εξόδου όταν αυτό σταματάει.
- **Ποσοτική ανάλυση:** Η ανάλυση αυτή θεωρεί ότι οι τιμές των στοιχείων είναι τυχαίες και χρησιμοποιεί μαθηματική και στατιστική ανάλυση ώστε να βρεθεί ένα κατάλληλο

μοντέλο ικανό να περιγράψει αυτή την τυχαιότητα. Αυτή η ανάλυση κυριαρχεί τα τελευταία χρόνια στην οικονομική βιομηχανία.

Για τις ανάγκες της παρούσας εργασίας θα εστιάσουμε περισσότερο στην τεχνική ανάλυση. Τα ιστορικά δεδομένα που χρησιμοποιούνται συνήθως περιλαμβάνουν για κάθε χρονική στιγμή την τιμή του στοιχείου (μετοχής, νομίσματος, κ.ά.). Ωστόσο, οι χρονικές στιγμές αυτές διαδέχονται πολύ γρήγορα η μία την άλλη και μάλιστα ανά μεταβλητά χρονικά διαστήματα. Συνεπώς, αυτή η μορφή των δεδομένων δυσχεραίνει την ανάλυσή τους και ως εκ τούτου πρέπει να μετατραπούν σε δεδομένα ανά λεπτό/ώρα/μέρα κ.ά. Αυτή η μορφή των δεδομένων αποτυπώνεται παρακάτω σύμφωνα με τον ορισμό της παρακάτω εικόνας



(α) Ορισμός κεριών με βάση την αρχική, μέγιστη, ελάχιστη και τελική τιμή
Διάγραμμα τιμής μετοχής



(β) Παράδειγμα χρονοσειράς με τη χρήση δεδομένων OHLC.

Σχήμα 3.1: Μορφή δεδομένων οικονομικών στοιχείων

Οι άνθρωποι που ασχολούνται με τις χρηματιστηριακές συναλλαγές παρατηρούν τα διαγράμματα αυτά και εντοπίζουν κάποια μοτίβα που υποδεικνύουν την κίνηση της αγοράς και κατ' επέκταση κάποιο σήμα συναλλαγής (αγορά ή πώληση στοιχείου). Σύμφωνα με το βιβλίο

του T. Bulkowski [21] υπάρχουν πάνω από εκατό μοτίβα που μπορεί κανείς να εντοπίσει.

3.2 Σχετικές εργασίες

Τα τελευταία χρόνια η επιστημονική κοινότητα έχει ασχοληθεί ποικιλοτρόπως με το θέμα της μεγιστοποίησης κερδών μέσω των χρηματιστηριακών συναλλαγών, αναλύοντάς το τόσο από την πλευρά της χρηματοοικονομικής επιστήμης όσο και από την πλευρά της επιστήμης των υπολογιστών. Στην παρούσα εργασία ερευνήθηκαν και σχεδιάστηκαν μοντέλα βαθιάς μηχανικής μάθησης με σκοπό να προσδιοριστεί η καταλληλότητα της επεξεργασίας εικόνων στα χρηματιστηριακά προβλήματα αυτού του είδους.

Έχουν πραγματοποιηθεί σχετικές εργασίες και στο παρελθόν, όπως είναι το άρθρο [22], σύμφωνα με το οποίο δεδομένα της μορφής OHLC μετατρέπονται σε εικόνες και ύστερα τροφοδοτούνται σε συνελκτικά νευρωνικά δίκτυα τα οποία ταξινομούν τις εικόνες σε ένα από οκτώ διαφορετικά μοτίβα που μπορούν να παρατηρηθούν στα δεδομένα OHLC, όπως αναλύθηκε παραπάνω. Οι Sezer κ.σ. πραγματοποίησαν άρθρο [1] σύμφωνα με το οποίο γίνεται τεχνική ανάλυση στα ιστορικά δεδομένα κάνοντας χρήση δεκαπέντε διαφορετικών δεικτών, που έχουν υπολογιστεί για δεκαπέντε διαφορετικές τιμές παραμέτρων, συνθέτοντας εν τέλει εικόνες διαστάσεως 15×15 . Στη συνέχεια συνελκτικό μοντέλο αναλαμβάνει την ταξινόμηση των εικόνων σε ενέργειες αγοράς, πώλησης ή τίποτα από τα δύο. Και στις δύο δημοσιεύσεις που αναφέρθηκαν οι εικόνες που σχηματίστηκαν -με διαφορετικό τρόπο στην κάθε περίπτωση- τροφοδοτούν βαθιά συνελκτικά νευρωνικά δίκτυα με σκοπό την ταξινόμησή τους.

Μέρος 

Πρακτικό Μέρος

Κεφάλαιο 4

Ανάλυση και σχεδίαση

Στο κεφάλαιο αυτό παρουσιάζεται η μελέτη που έγινε για την υλοποίηση του συστήματος. Αρχικά περιγράφονται τα δεδομένα που χρησιμοποιήθηκαν η προεπεξεργασία τους και στη συνέχεια η αρχιτεκτονική του μοντέλου μάθησης.

4.1 Δεδομένα προβλήματος

Στα πλαίσια της παρούσας εργασίας χρησιμοποιήθηκαν τα δεδομένα Dow 30 που αντλήθηκαν από την πλατφόρμα του Yahoo Finance. Πρόκειται για τις ημερήσιες αρχικές, τελικές, μέγιστες, ελάχιστες τιμές και τον όγκο συναλλαγών για τριάντα μετοχές στα τελευταία δεκαοκτώ χρόνια (2003-2020). Ο λόγος που χρησιμοποιούνται δεδομένα από τόσα χρόνια είναι για να αναλυθούν και συγκριθούν τα μοντέλα κατά τη διάρκεια του χρόνου και να ληφθούν ορισμένα συμπεράσματα για την καταλληλότητά τους. Στο πέρασμα των χρόνων οι μετοχές που συνιστούν αυτή την κατηγορία μετοχών αλλάζουν, έτσι παρατηρείται η εισαγωγή νέων μετοχών, η μετονομασία παλαιότερων και η απουσία κάποιων μετοχών από μία συγκεκριμένη χρονολογία και μετά.

Αναλυτικά οι τριάντα μετοχές που μελετούνται φαίνονται στον πίνακα 4.1.

4.2 Προεπεξεργασία δεδομένων

Τα δεδομένα, αμέσως μετά τη συλλογή τους, υφίστανται κάποια επεξεργασία προκειμένου να αποκτήσουν κατάλληλη μορφή και στη συνέχεια να τροφοδοτηθούν στο νευρωνικό δίκτυο. Έτσι, αρχικά, εφαρμόζεται μία μέθοδος συμπλήρωσης των τιμών που απουσιάζουν από το σύνολο δεδομένων. Η συμπλήρωση αυτή γίνεται σύμφωνα με τον κανόνα του μέσου όρου, δηλαδή, όλες οι απύσες τιμές αντικαθιστώνται με το μέσο όρο, όπως αυτός προκύπτει από την υπόλοιπη χρονοσειρά της εκάστοτε μετοχής την εκάστοτε χρονική περίοδο. Έπειτα, γίνεται κανονικοποίηση των τιμών ώστε αυτές να βρίσκονται σε εύρος -1 έως 1. Για την πραγματοποίηση των πειραμάτων, ακολουθήθηκαν δύο διαφορετικές μέθοδοι για την τελική διαμόρφωση των δεδομένων εισόδου. Και οι δύο τρόποι αφορούν το σχηματισμό εικόνων. Η πρώτη μέθοδος ακολουθεί τον τρόπο διαμόρφωσης των δεδομένων εισόδου στα πειράματα του άρθρου [1]. Πιο αναλυτικά, δημιουργήθηκαν εικόνες από δεκαπέντε διαφορετικούς δείκτες τεχνικής ανάλυσης για δεκαπέντε διαφορετικές τιμές. Παρακάτω απαριθμούνται οι δείκτες καθώς επίσης και ένας σύντομος ορισμός αυτών.

Σύμβολο	Χρονολογία εισαγωγής
<i>MMM</i>	1976-08-09
<i>AXP</i>	1982-08-30
<i>AMGN</i>	2020-08-31
<i>AAPL</i>	2015-03-19
<i>BA</i>	1987-03-12
<i>CAT</i>	1991-05-06
<i>CVX</i>	2008-02-19
<i>CSCO</i>	2009-06-08
<i>KO</i>	1987-03-12
<i>DOW</i>	2019-04-02
<i>GS</i>	2013-09-20
<i>HD</i>	1999-11-01
<i>HON</i>	2020-08-31
<i>IBM</i>	2020-08-31
<i>INTC</i>	1979-06-29
<i>JNJ</i>	1997-03-17
<i>JPM</i>	1991-05-06
<i>MCD</i>	1985-10-30
<i>MRK</i>	1979-06-29
<i>MSFT</i>	1999-11-01
<i>NKE</i>	2013-09-20
<i>PG</i>	1932-05-26
<i>CRM</i>	2020-08-31
<i>TRV</i>	2009-06-08
<i>UNH</i>	2012-09-24
<i>VZ</i>	2004-04-08
<i>V</i>	2013-09-20
<i>WBA</i>	2018-06-26
<i>WMT</i>	1997-03-17
<i>DIS</i>	1991-05-06

Πίνακας 4.1: Λίστα μετοχών Dow-30, όπως προέκυψε στο τέλος του 2020

- Δ_1 - Σχετικός δείκτης δύναμης (Relative Strength Index-RSI)

Αποτελεί δείκτη τύπου ταλαντωτή που δείχνει την ιστορική δύναμη και αδυναμία των μετοχών. Καθώς αλλάζουν οι τιμές της μετοχής ο δείκτης αυτός ταλαντώνεται μεταξύ του 0 και του 100, γεγονός που υποδεικνύει αν οι τιμές βρίσκονται στη ζώνη υπερ-πώλησης ή στη ζώνη υπερ-αγοράς. Η εξίσωση υπολογισμού του σχετικού δείκτη δύναμης είναι:

$$\Delta_1 = 100 - \frac{100}{1 + \text{μεσο_κερδος/μεση_απωλεια}}$$

- Δ_2 - Δείκτης Williams %R

Ο δείκτης Ωιλιαμς επίσης υποδεικνύει τις ζώνες υπερ-πώλησης και υπερ-αγοράς. Οι τιμές του ταλαντώνεται από το -100 έως το 0. Η εξίσωση υπολογισμού του δείκτη είναι:

$$\Delta_2 = -100 \frac{\max(\text{high}) - \text{close}}{\max(\text{high}) - \min(\text{low})}$$

- Δ_3 - Απλός κινητός μέσος όρος (ΑΚΜΟ)

Ο ΑΚΜΟ δείχνει τον κινητό μέσο των τιμών της μετοχής για μια συγκεκριμένη περίοδο. Η πιο γενική ερμηνεία αυτού του δείκτη είναι ότι πετυχαίνει να προσδιορίσει την κατεύθυνση της τάσης της αγοράς. Η εξίσωση υπολογισμού του ΑΚΜΟ είναι:

$$\Delta_3(M, n) = \sum_{k=a+1}^{a+n} \frac{M(k)}{n}$$

- Δ_4 - Εκθετικός κινητός μέσος όρος (ΕΚΜΟ)

Ο ΕΚΜΟ είναι και αυτός δείκτης κινητού μέσου, ωστόσο δίνει έμφαση περισσότερο στις πιο πρόσφατες τιμές, οι οποίες έχουν μεγαλύτερο βάρος όταν υπολογίζεται ο μέσος όρος. Η εξίσωση υπολογισμού του ΕΚΜΟ είναι:

$$\Delta_4(M, t, \tau) = (M(t) - \Delta_4(M, t - 1, \tau)) \cdot \frac{2}{\tau + 1} + \Delta_4(M, t - 1, \tau)$$

- Δ_5 - Σταθμισμένος κινητός μέσος όρος (ΣΚΜΟ)

Ο ΣΚΜΟ είναι και αυτός δείκτης κινητού μέσου, παρόμοιος με το ΕΚΜΟ. Η διαφορά είναι ότι ο ΣΚΜΟ αυξάνεται γραμμικά καθώς κινείται προς τις πιο πρόσφατες τιμές, ενώ ο ΕΚΜΟ αυξάνεται εκθετικά. Η εξίσωση υπολογισμού του ΣΚΜΟ είναι:

$$\Delta_5(M, n) = \frac{\sum_{t=1}^n (w_t \cdot M(t))}{\sum_{t=1}^n w_t}$$

- Δ_6 - Κινητός μέσος όρος του Hull

Ο δείκτης αυτός προσπαθεί να καλύψει το κενό του απλού κινητού μέσου όρου, όπως και οι δείκτες ΣΚΜΟ και ΕΚΜΟ. Ωστόσο, ο δείκτης αυτός έχει αποδειχθεί ότι βγάζει καλύτερα αποτελέσματα από τους άλλους δύο δείκτες. Η εξίσωση υπολογισμού του δείκτη του Χαλ είναι:

$$\Delta_6(M, n) = \Delta_5(2 \cdot \Delta_5(M, \frac{n}{2}) - \Delta_5(M, n)), \sqrt{n}$$

- Δ_7 - Τριπλός εκθετικός κινητός μέσος όρος (ΤΕΚΜΟ)
Ο δείκτης αυτός είναι παρόμοιος με τον ΕΚΜΟ και ο στόχος του είναι να φιλτράρει τις μικρές διαφοροποιήσεις στις τιμές της μετοχής και να μειώσει τη μεταβλητότητά της. Η εξίσωση υπολογισμού του ΤΕΚΜΟ είναι:

$$\Delta_7 = (3 \cdot \Delta_4 - 3 \cdot \Delta_4(\Delta_4)) + \Delta_4(\Delta_4(\Delta_4))$$

- Δ_8 - Commodity Channe Index
Ο δείκτης αυτός συγκρίνει τις τρέχουσες τιμές με τη μέση τιμή κατά τη διάρκεια μιας χρονικής περιόδου. Κυρίως ταλαντώνεται μεταξύ του -100 και του 100.

$$\Delta_8 = \frac{\text{πρεχουσα τιμη} - 20 \text{ AKMO}}{0.015 \cdot \text{μεση διαπορα}}$$

- Δ_9 - Chade momentum oscillator indicator
Ο δείκτης διακυμαίνεται από -100 έως 100. Αν η τιμή του είναι πάνω από 50 τότε θεωρείται ότι η μετοχή είναι στην ζώνη υπερ-πώλησης. Αντίστοιχα, αν είναι κάτω από -50 τότε θεωρείται ότι βρίσκεται στη ζώνη υπερ-αγοράς. Ο δείκτης υπολογίζεται ως εξής (S_u : άθροισμα ημερών ανοδικής πορείας, S_d : άθροισμα ημερών καθοδικής πορείας):

$$\Delta_9 = 100 \cdot \frac{S_u - S_d}{S_u + S_d}$$

- Δ_{10} - Κινούμενος μέσος όρος σύγκλισης και απόκλισης (ΚΜΟΣΑ)
Ο δείκτης ΚΜΟΣΑ υποδεικνύει την τάση της τιμής της μετοχής. Αν το σήμα αυτό περάσει το σήμα της τιμής κατά την ανοδική πορεία τότε θεωρείται πως η τιμή της μετοχής θα ανέβει. Αντιθέτως, αν ο ΚΜΟΣΑ διαπεράσει το σήμα κατά την καθοδική πορεία τότε σημαίνει ότι πιθανότατα η τιμή της μετοχής θα κατέβει.

Γραμμή του ΚΜΟΣΑ: 12 μέρες ΕΚΜΟ - 26 μέρες ΕΚΜΟ

Γραμμή σήματος: 9 μέρες ΕΚΜΟ της γραμμής ΚΜΟΣΑ

- Δ_{11} - Ταλαντωτής ποσοστιαίας τιμής (ΤΠΤ)
Ο δείκτης ΤΠΤ είναι παρόμοιος με τον ΚΜΟΣΑ.

$$\Delta_{11} = \frac{12 \text{ μερες ΕΚΜΟ} - 26 \text{ μερες ΕΚΜΟ}}{26 \text{ μερες ΕΚΜΟ}} \cdot 100$$

Γραμμή σήματος: 9 μέρες ΕΚΜΟ του Δ_{11}

- Δ_{12} - Ρυθμός μεταβολής (ΡΜ)
Ο δείκτης ΡΜ δείχνει την ταχύτητα με την οποία αλλάζει η τιμή σε μια χρονική περίοδο. Η εξίσωση υπολογισμού του δείκτη είναι:

$$\Delta_{12} = \frac{\text{latest close} - \text{previous close}}{\text{previous close}} \cdot 100$$

- Δ_{13} - Δείκτης ροής χρήματος του Chaikin (ΔPX)

Ο δείκτης ΔPX χρησιμοποιείται για να μετρήσει τον όγκο ροής χρήματος σε μία χρονική περίοδο. Οι τιμές του δείκτη κυμαίνονται από -1 ως 1. Αν η τιμή είναι κοντά στο 1 τότε η ανάγκη αγοράς αυξάνεται. Αντίθετα αν η τιμή είναι κοντά στο -1, η ανάγκη πώλησης αυξάνεται. Οι εξισώσεις υπολογισμού του δείκτη είναι:

$$\text{Multiplier} = \frac{(\text{Close}-\text{Low})-(\text{High}-\text{Close})}{\text{High}-\text{Low}}$$

$$\text{Money Flow Volume (MFV)} = \text{Volume} \cdot \text{Multiplier}$$

$$21\text{periodCMF} = \frac{21\text{periodsumofMFV}}{21\text{periodsumofvolume}} \cdot 100$$

- Δ_{14} - Δείκτης κατευθυντήριας κίνησης (ΔKK)

Ο δείκτης ΔKK δείχνει τη δύναμη και την κατεύθυνση της τάσης. Αποτελείται από τρία διαφορετικά σήματα, το σήμα μέσης κατεύθυνσης (ΣMK) και τον θετικό και αρνητικό κατευθυντήριο δείκτη. Ο τρόπος υπολογισμού του ΔKK είναι:

ΑΛΓΟΡΙΘΜΟΣ 4.1: Υπολογισμός ΔKK

Input: X (OHCL stock data)

Output: DMI (DMI indicator)

up_move = $X[\text{'high'}][t] - X[\text{'high'}][t-1]$

down_move = $X[\text{'low'}][t] - X[\text{'low'}][t-1]$

if up_move > down_move and up_move > 0 **then**

+DMI = up_move

else

+DMI = 0

end if

if down_move > up_move and down_move > 0 **then**

-DMI = down_move

else

-DMI = 0

end if

DMI=(+DMI,-DMI)

$$+DI = 100 \cdot \text{EMA} \frac{+DMI}{\text{Average True Range}}$$

$$-DI = 100 \cdot \text{EMA} \frac{-DMI}{\text{Average True Range}}$$

$$ADX = 100 \cdot \text{EMA} \left| \frac{(+DI) - (-DI)}{(+DI) + (-DI)} \right|$$

- Δ_{15} - Παραβολική SAR

Ο δείκτης αυτός χρησιμοποιείται για να εντοπιστούν τα πιθανά σημεία διακοπής και εναλλαγής. Το τρέχων SAR υπολογίζεται βάσει τριών στοιχείων:

- προηγούμενο SAR, που είναι μια τιμή SAR που αντιπροσωπεύει την προηγούμενη χρονική περίοδο,
- παράγοντας επιτάχυνσης, που εξηγεί το πόσο ευαίσθητη είναι η τιμή του SAR,

- extreme point, που είναι είτε η μεγαλύτερη τιμή του τρέχουσας ανοδικής τάσης είτε η μικρότερη τιμή της τρέχουσας καθοδικής τάσης.

Ανοδική παραβολική SAR: $previous\ SAR + previous\ AF(previous\ EP + Previous\ SAR)$

Καθοδική παραβολική SAR:

$previous\ SAR - previous\ AF(-previous\ EP + Previous\ SAR)$

Για όλους τους παραπάνω δείκτες -εκτός από τρεις (Δ_{10} , Δ_{11} , Δ_{15}) που δεν έχουν αντίστοιχη παράμετρο-, θεωρήθηκαν δεκαπέντε διαφορετικές τιμές (6,20) για το μέγεθος παρατηρήσεων που χρησιμοποιήθηκαν για τον υπολογισμό τους. Κατ' αυτόν τον τρόπο προκύπτουν πίνακες (εικόνες) διάστασης (15x15).

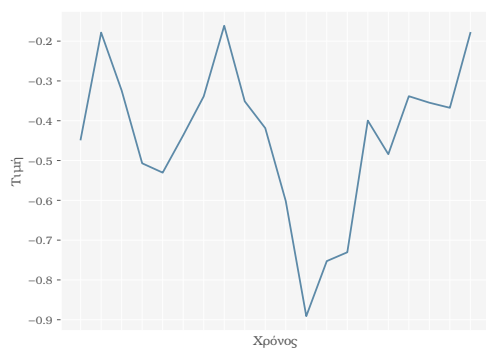
Η δεύτερη μέθοδος αφορά τη μετατροπή της χρονοσειράς σε εικόνα με τη μέθοδο GAF. Σύμφωνα με αυτή τη μέθοδο, τα σημεία της χρονοσειράς μετατρέπονται από καρτεσιανές συντεταγμένες σε πολικές. Κατ' αυτόν τον τρόπο διατηρείται η χρονική εξάρτηση μεταξύ των σημείων. Ύστερα κάθε σημείο συγκρίνεται με κάθε άλλο σημείο για να βρεθούν οι χρονικές συσχετίσεις. Το τελευταίο επιτυγχάνεται μέσω της χρήσης συνημιτόνου, η οποία οδηγεί στο σχηματισμό του πίνακα Gramian (βλ. σχήμα 4.1). Για το σχηματισμό των εικόνων GAF χρησιμοποιείται ένα παράθυρο παρατηρήσεων είκοσι ημερών. Κατά συνέπεια, οι διαστάσεις των εικόνων είναι (20x20).

4.3 Προσθήκη ετικετών


Στο πρόβλημα που καλείται να αντιμετωπίσει η παρούσα διπλωματική εργασία είναι απαραίτητο τα δείγματα που περιλαμβάνονται στο σύνολο δεδομένων να είναι χωρισμένα σε τρεις κλάσεις (ομάδες). Η πρώτη θα περιλαμβάνει τις χρονικές στιγμές που είναι καλό για το σύστημα να μην προβεί σε καμία ενέργεια, η δεύτερη θα περιλαμβάνει τις χρονικές στιγμές που προσφέρονται για πώληση ενός στοιχείου και αντίστοιχα η τρίτη ομάδα θα περιλαμβάνει τις στιγμές που είναι κατάλληλες για αγορά στοιχείου.

Υπάρχουν πολλοί αλγόριθμοι που μπορούν να χρησιμοποιηθούν ώστε να αποκτήσουμε ένα σύνολο δεδομένων με ετικέτες. Για τις ανάγκες της εργασίας υλοποιήθηκε ένας απλός αλγόριθμος ο οποίος βασίζεται στον κανόνα του κυλιόμενου παραθύρου. Σύμφωνα με αυτό, διατρέχουμε κάθε χρονοσειρά από τα αριστερά προς τα δεξιά κοιτάζοντας κάθε φορά μόνο έντεκα συνεχόμενες χρονικές στιγμές. Αν η τελική τιμή της ενδιάμεσης χρονικής στιγμής είναι η ελάχιστη από το σύνολο των σημείων του παραθύρου τότε, το σημείο αυτό λαμβάνει την ετικέτα της αγοράς, αν είναι ίση με το μέγιστο των σημείων τότε λαμβάνει την ετικέτα της πώλησης. Διαφορετικά το σημείο θα ανήκει στην ουδέτερη ομάδα.


Ο αλγόριθμος ετικετοποίησης παρουσιάζεται σε μορφή ψευδοκώδικα στο 4.2



(α) Τμήμα χρονοσειράς με τιμές κανονικοποιημένες σε εύρος $[-1, 1]$.



(β) Τμήμα χρονοσειράς σε πολικές συντεταγμένες.



(γ) Τμήμα χρονοσειράς σε Γραμμικό γωνιακό χώρο.

Σχήμα 4.1: Μετατροπή χρονοσειράς στο Γραμμικό γωνιακό χώρο

ΑΛΓΟΡΙΘΜΟΣ 4.2: *Ετικετοποίηση χρονικών στιγμών*

```

Input:  $X$  (stock timeseries)
Output:  $L$  ( $X$ 's labels)
 $W=11$  ( $W \rightarrow$  window size)
 $k=W//2$  ( $k \rightarrow$  counter for vector  $X$ )
while  $k \neq \text{length}(X)$  do
  if  $X[k] = \min X_i, k-W//2 \leq i \leq k+W//2$  then
     $L[k]=\text{BUY}$ 
  else if  $X[k] = \max X_i, k-W//2 \leq i \leq k+W//2$  then
     $L[k]=\text{SELL}$ 
  else
     $L[k]=\text{HOLD}$ 
  end if
   $k = k + 1$ 
end while

```

4.4 Μέθοδος εκπαίδευσης

Δεδομένου του ότι έχουν αντληθεί δεδομένα δεκαοκτώ χρόνων (βλ ενότητα 4.1) για την εκπαίδευση του μοντέλου και κατ' επέκταση την αξιολόγησή του θα εφαρμοστεί η μέθοδος που περιγράφεται στο άρθρο [1]. Πρόκειται για μια τεχνική που χωρίζει τα δεδομένα παίρνοντας ένα κινητό παράθυρο πέντε ετών για την εκπαίδευση και ενός έτους για την αξιολόγηση. Κατ' αυτόν τον τρόπο είμαστε σε θέση να γνωρίζουμε πώς συμπεριφέρεται το μοντέλο καθ' όλη τη διάρκεια των 18 χρόνων (14 χρόνων αξιολόγησης). Πιο συγκεκριμένα, για κάθε πέντε χρόνια εκπαίδευσης προκύπτει ένα μοντέλο το οποίο χρησιμοποιείται για την αξιολόγηση του επόμενου έτους και επιπλέον χρησιμοποιείται για την αρχικοποίηση των βαρών του μοντέλου που θα λάβει τα δεδομένα της επόμενης πενταετίας (τέσσερα τελευταία έτη της προηγούμενης πενταετίας συν ένα επόμενο έτος).

Η εκπαίδευση φαίνεται σχηματικά στο ακόλουθο διάγραμμα :



Σχήμα 4.2: *Κινητό παράθυρο για την εκπαίδευση του μοντέλου. Ανακατασκευασμένο διάγραμμα από [1]*

4.5 Ανάλυση - περιγραφή αρχιτεκτονικής

Στην ενότητα αυτή παρουσιάζονται οι διάφορες μορφές αρχιτεκτονικής που δοκιμάστηκαν για την επίλυση του προβλήματος.

4.5.1 Μέθοδοι βαθιάς μηχανικής μάθησης


Στα πλαίσια της εργασίας δοκιμάστηκαν ποικίλα μοντέλα βαθιάς μηχανικής μάθησης. Τα μοντέλα αυτά ήταν συνελκτικά, αναδρομικά ή και συνδυασμός αυτών των δύο.

BM₁ - Αναδρομικό δίκτυο με χρήση επιπέδου LSTM.

Η αρχιτεκτονική του δικτύου περιλαμβάνει:

- Ένα επίπεδο LSTM με 100 κόμβους,
- ένα επίπεδο LSTM με 32 κόμβους,
- ένα επίπεδο εξόδου με τρεις νευρώνες (ένα για κάθε πιθανή απόφαση)

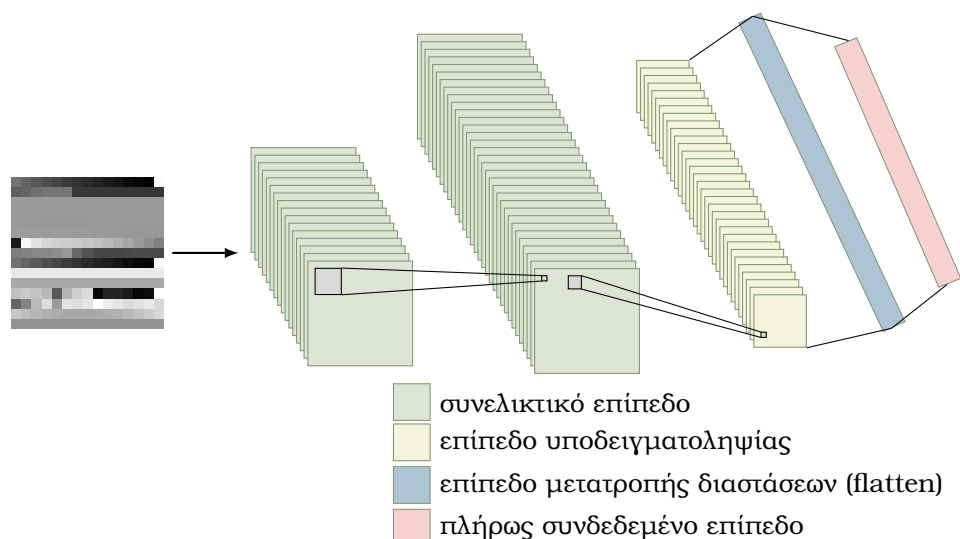
Στο σχήμα 4.3 απεικονίζεται σχηματικά η αρχιτεκτονική του μοντέλου.



Σχήμα 4.3: Δίκτυο με δύο αναδρομικά επίπεδα μακράς και βραχείας μνήμης.

X_i : χρονικές στιγμές εισόδου

y_i : αντίστοιχες τιμές εξόδου



Σχήμα 4.4: Απλό δίκτυο με δύο συνελκτικά επίπεδα.

BM₂ - Απλό συνελκτικό δίκτυο δύο επιπέδων

Η αρχιτεκτονική του μοντέλου που περιγράφεται στο άρθρο [1] περιλαμβάνει:

- Ένα συνελκτικό επίπεδο με μέγεθος πυρήνα 3x3 και αριθμό φίλτρων 32,
- ένα συνελκτικό επίπεδο με μέγεθος πυρήνα 3x3 και αριθμό φίλτρων 64,
- ένα επίπεδο υποδειγματοληψίας που κρατάει το μέγιστο από κάθε υποπίνακα 2x2,
- ένα πλήρως συνδεδεμένο επίπεδο με 128 κόμβους,
- ένα επίπεδο εξόδου με τρεις νευρώνες (ένα για κάθε πιθανή απόφαση)

Μετά την εφαρμογή του επιπέδου υποδειγματοληψίας, χρησιμοποιείται η τεχνική απενεργοποίησης νευρώνων σε ποσοστό 25%. Η ίδια τεχνική -αλλά σε ποσοστό 50%- χρησιμοποιείται και μετά την εφαρμογή του πλήρως συνδεδεμένου επιπέδου. Ο στόχος της τυχαίας απενεργοποίησης νευρώνων είναι να αντιμετωπίσει το φαινόμενο που παρουσιάζονται τα μοντέλα βαθιάς μάθησης όταν το αποτέλεσμά τους εξαρτάται άμεσα από το σύνολο παρατηρήσεων της εκπαίδευσης. Το πρόβλημα αυτό ονομάζεται υπερεκπαίδευση.

Η αρχιτεκτονική λαμβάνει εικόνες που προκύπτουν ύστερα από την τεχνική ανάλυση όπως περιγράφεται στο άρθρο [1] και όπως αναφέρθηκε στην ενότητα 4.1. Επομένως, στο προαναφερθέν δίκτυο τροφοδοτούνται εικόνες 15x15, οι οποίες αποτελούνται από τιμές δεικτών τεχνικής ανάλυσης που έχουν υπολογιστεί για δεκαπέντε παράθυρα χρονικών στιγμών.

Η σχηματική αναπαράσταση του δικτύου φαίνεται στην εικόνα 4.4

Η ίδια αρχιτεκτονική χρησιμοποιήθηκε και για εικόνες εισόδου GAF όπως αυτές παρουσιάστηκαν επίσης στην ενότητα 4.1. Η μορφή δεδομένων που βασίστηκε στους δείκτες της τεχνικής ανάλυσης εφαρμόστηκε μόνο στο πείραμα αυτής της αρχιτεκτονικής καθώς τα αποτελέσματα ήταν εμφανώς καλύτερα για τις εικόνες GAF.

BM₃ - Συνδυασμός συνέλιξης ως προς το βάθος και απλής συνέλιξης.

Η αρχιτεκτονική του μοντέλου αυτού αποτελείται από :

- Ένα συνελικτικό επίπεδο ως προς το βάθος με μέγεθος πυρήνα 3x3 και πολλαπλασιαστική 8,
- ένα συνελικτικό επίπεδο ως προς το βάθος με μέγεθος πυρήνα 3x3 και πολλαπλασιαστική 2,
- ένα συνελικτικό επίπεδο με μέγεθος πυρήνα 3x3 και αριθμό φίλτρων 64,
- ένα επίπεδο υποδειγματοληψίας που κρατάει το μέγιστο από κάθε υποπίνακα 2x2,
- ένα πλήρως συνδεδεμένο επίπεδο με 128 κόμβους,
- ένα επίπεδο εξόδου με τρεις νευρώνες (ένα για κάθε πιθανή απόφαση)

BM₄ - Συνδυασμός συνελικτικού και αναδρομικού δικτύου με πρόσθεση.

Η αρχιτεκτονική του δικτύου περιλαμβάνει δύο τμήματα :

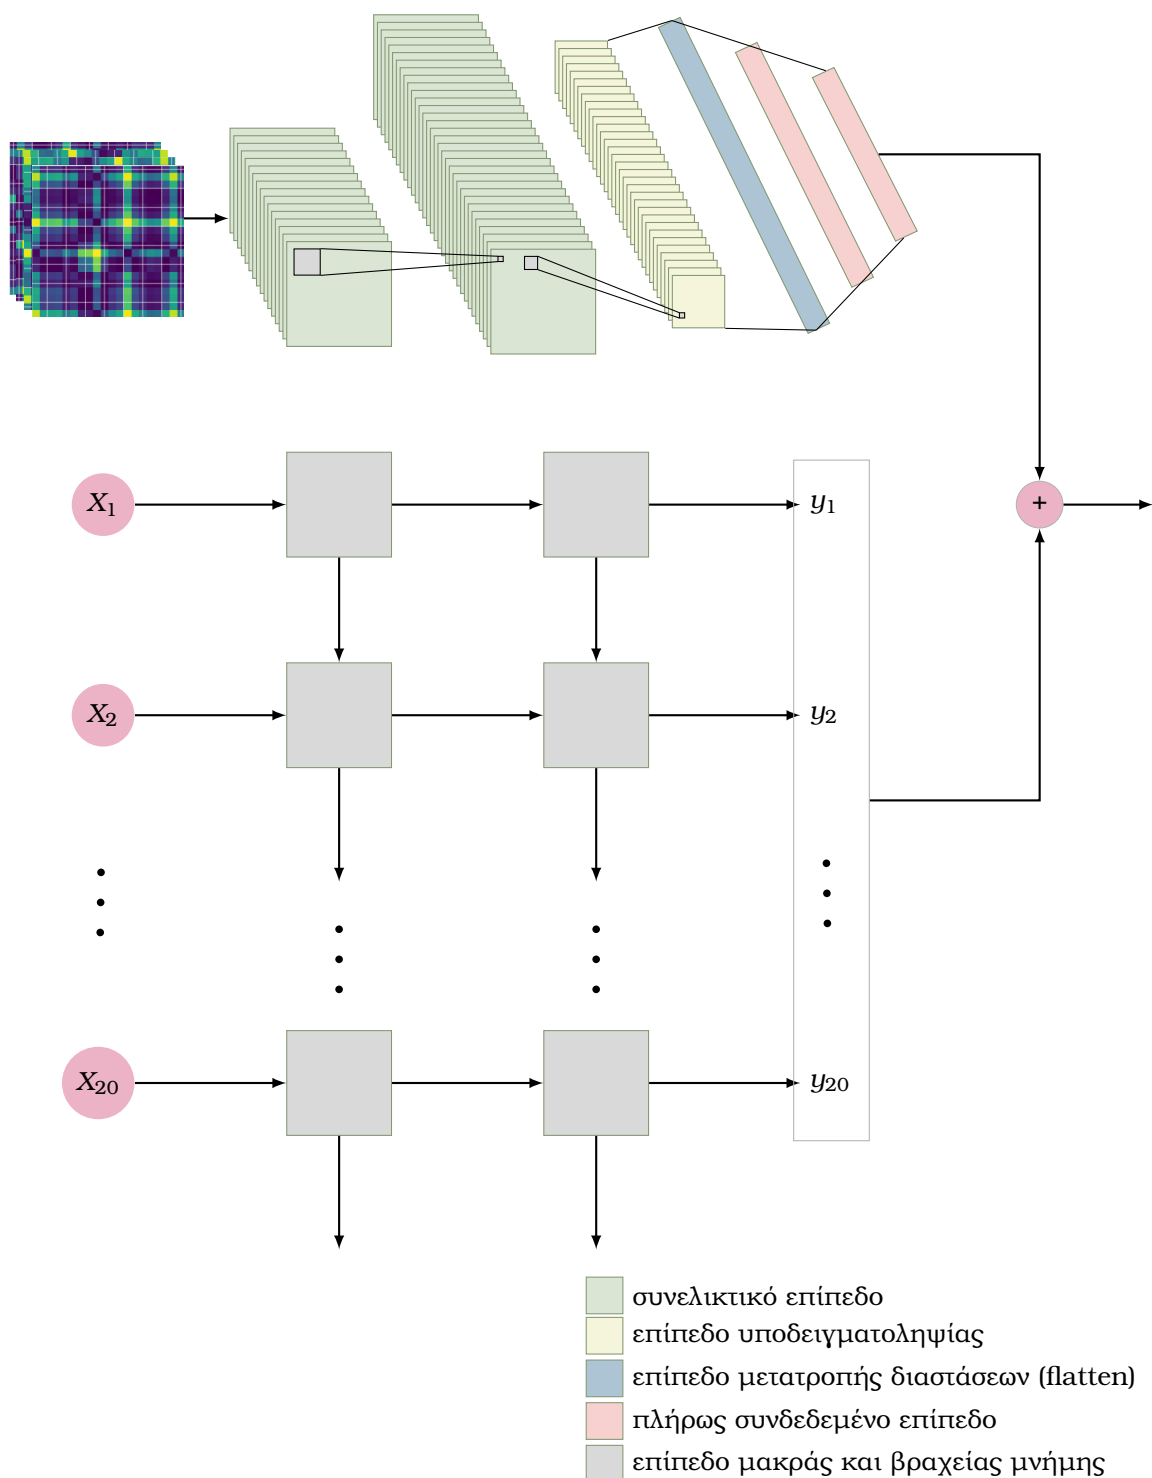
Το πρώτο αποτελείται από :

- Ένα συνελικτικό επίπεδο με μέγεθος πυρήνα 3x3 και αριθμό φίλτρων 32,
- ένα συνελικτικό επίπεδο με μέγεθος πυρήνα 3x3 και αριθμό φίλτρων 64,
- ένα επίπεδο υποδειγματοληψίας που κρατάει το μέγιστο από κάθε υποπίνακα 2x2,
- ένα πλήρως συνδεδεμένο επίπεδο με 256 κόμβους,
- ένα πλήρως συνδεδεμένο επίπεδο με 32 κόμβους,

Το δεύτερο αποτελείται από :

- ένα επίπεδο LSTM με 100 κόμβους
- ένα επίπεδο LSTM με 32 κόμβους

Στη συνέχεια τα δύο αυτά τμήματα ενώνονται μεταξύ τους με πρόσθεση των αντίστοιχων αναπαραστάσεων εξόδου και στη συνέχεια ακολουθεί το επίπεδο εξόδου του ενιαίου πλέον δικτύου. Στο συνελικτικό κομμάτι του δικτύου έχουν προστεθεί δύο πλήρως συνδεδεμένα επίπεδα και στην συνέχεια το αποτέλεσμα του δεύτερου επιπέδου προστίθεται στο αποτέλεσμα του αναδρομικού δικτύου για να οδηγηθεί εν τέλει στο επίπεδο εξόδου. Με αυτόν τον τρόπο επιτυγχάνεται η μείωση του μεγέθους εξόδου του συνελικτικού τμήματος ώστε να προκύψει ίδιο μέγεθος διανύσματος με το αντίστοιχο του αναδρομικού και να είναι δυνατή η κατά στοιχείο πρόσθεσή τους. Για το σχήμα του δικτύου βλ. εικόνα 4.5, όπου ο συντελεστής «+» σημαίνει πρόσθεση διανυσμάτων στοιχείο προς στοιχείο.



Σχήμα 4.5: Υβριδικό δίκτυο με συνελικτικό (με είσοδο εικόνες) και αναδρομικό τμήμα (με είσοδο χρονοσειρές).

BM₅ - Συνδυασμός συνελκτικού και αναδρομικού δικτύου με πρόσθεση.

Η αρχιτεκτονική του δικτύου περιλαμβάνει δύο τμήματα :

Το πρώτο αποτελείται από :

- Ένα συνελκτικό επίπεδο με μέγεθος πυρήνα 3x3 και αριθμό φίλτρων 32,
- ένα συνελκτικό επίπεδο με μέγεθος πυρήνα 3x3 και αριθμό φίλτρων 64,
- ένα επίπεδο υποδειγματοληψίας που κρατάει το μέγιστο από κάθε υποπίνακα 2x2,
- ένα συνελκτικό επίπεδο με μέγεθος πυρήνα 3x3 και αριθμό φίλτρων 16,
- ένα συνελκτικό επίπεδο με μέγεθος πυρήνα 3x3 και αριθμό φίλτρων 8,
- ένα επίπεδο υποδειγματοληψίας που κρατάει το μέγιστο από κάθε υποπίνακα 2x2,

Το δεύτερο αποτελείται από :

- ένα επίπεδο LSTM με 200 κόμβους

Στη συνέχεια τα δύο αυτά τμήματα ενώνονται μεταξύ τους με πρόσθεση των αντίστοιχων αναπαραστάσεων εξόδου και στη συνέχεια ακολουθεί το επίπεδο εξόδου του ενιαίου πλέον δικτύου. Στην περίπτωση αυτού του δικτύου, το συνελκτικό τμήμα παρουσιάζει στην αρχή ανοδική και στην συνέχεια καθοδική πορεία ως προς τον αριθμό των φίλτρων που χρησιμοποιεί το κάθε επίπεδο. Όπως και στο προηγούμενο δίκτυο έτσι και σ'αυτό δοκιμάστηκε μία μέθοδος μείωσης των διαστάσεων. Αυτή τη φορά, αντί για πλήρες συνδεδεμένο δίκτυο, έγινε συνελκτικών επιπέδων με μειωμένο αριθμό φίλτρων (16 και 8 αντίστοιχα). Για το σχήμα του δικτύου βλ. εικόνα 4.6, όπου ο συντελεστής «+» σημαίνει πρόσθεση διανυσμάτων στοιχείο προς στοιχείο.

BM₆ - Συνδυασμός συνελκτικού και αναδρομικού δικτύου με συνένωση.

Η αρχιτεκτονική του δικτύου περιλαμβάνει δύο τμήματα :

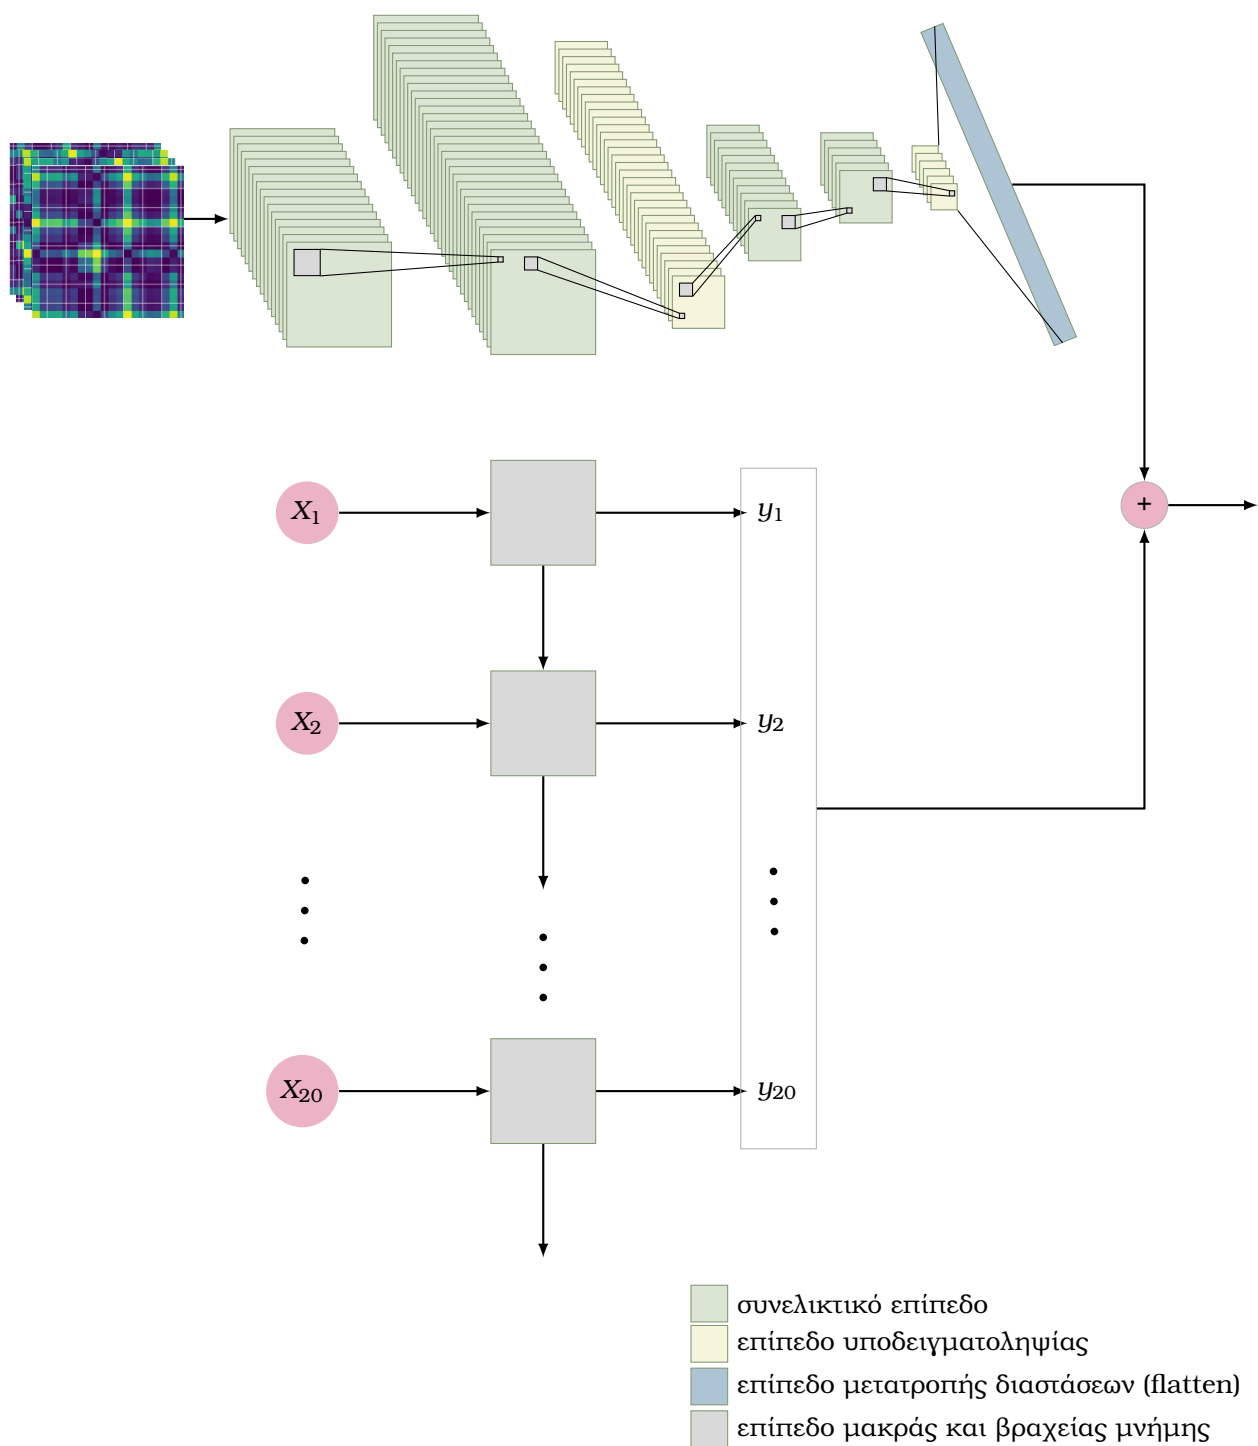
Το πρώτο αποτελείται από :

- Ένα συνελκτικό επίπεδο με μέγεθος πυρήνα 3x3 και αριθμό φίλτρων 32,
- ένα συνελκτικό επίπεδο με μέγεθος πυρήνα 3x3 και αριθμό φίλτρων 64,
- ένα επίπεδο υποδειγματοληψίας που κρατάει το μέγιστο από κάθε υποπίνακα 2x2,
- ένα συνελκτικό επίπεδο με μέγεθος πυρήνα 3x3 και αριθμό φίλτρων 16,
- ένα συνελκτικό επίπεδο με μέγεθος πυρήνα 3x3 και αριθμό φίλτρων 8,
- ένα επίπεδο υποδειγματοληψίας που κρατάει το μέγιστο από κάθε υποπίνακα 2x2,

Το δεύτερο αποτελείται από :

- δύο επίπεδα LSTM με 100 κόμβους διπλής κατεύθυνσης (bidirectional),

Στη συνέχεια τα δύο αυτά τμήματα ενώνονται μεταξύ τους με συνένωση των αντίστοιχων αναπαραστάσεων εξόδου και στη συνέχεια ακολουθεί το επίπεδο εξόδου του ενιαίου πλέον δικτύου. Για το σχήμα του δικτύου βλ. σχήμα 4.7, όπου ο συντελεστής «+» σημαίνει συνένωση δύο διανυσμάτων, δηλαδή τοποθέτηση της αρχής του ενός στο τέλος του άλλου.



Σχήμα 4.6: Υβριδικό δίκτυο με συνελκτικό (με είσοδο εικόνες) και αναδρομικό τμήμα (με είσοδο χρονοσειρές).

BM₇ - Συνδυασμός συνελκτικού και αναδρομικού δικτύου διπλής κατεύθυνσης με πρόσθεση.

Η αρχιτεκτονική του δικτύου περιλαμβάνει δύο τμήματα :

Το πρώτο αποτελείται από :

- Ένα συνελκτικό επίπεδο με μέγεθος πυρήνα 3x3 και αριθμό φίλτρων 32,
- ένα συνελκτικό επίπεδο με μέγεθος πυρήνα 3x3 και αριθμό φίλτρων 64,
- ένα επίπεδο υποδειγματοληψίας που κρατάει το μέγιστο από κάθε υποπίνακα 2x2,
- ένα συνελκτικό επίπεδο με μέγεθος πυρήνα 3x3 και αριθμό φίλτρων 16,
- ένα συνελκτικό επίπεδο με μέγεθος πυρήνα 3x3 και αριθμό φίλτρων 8,
- ένα επίπεδο υποδειγματοληψίας που κρατάει το μέγιστο από κάθε υποπίνακα 2x2,

Το δεύτερο αποτελείται από :

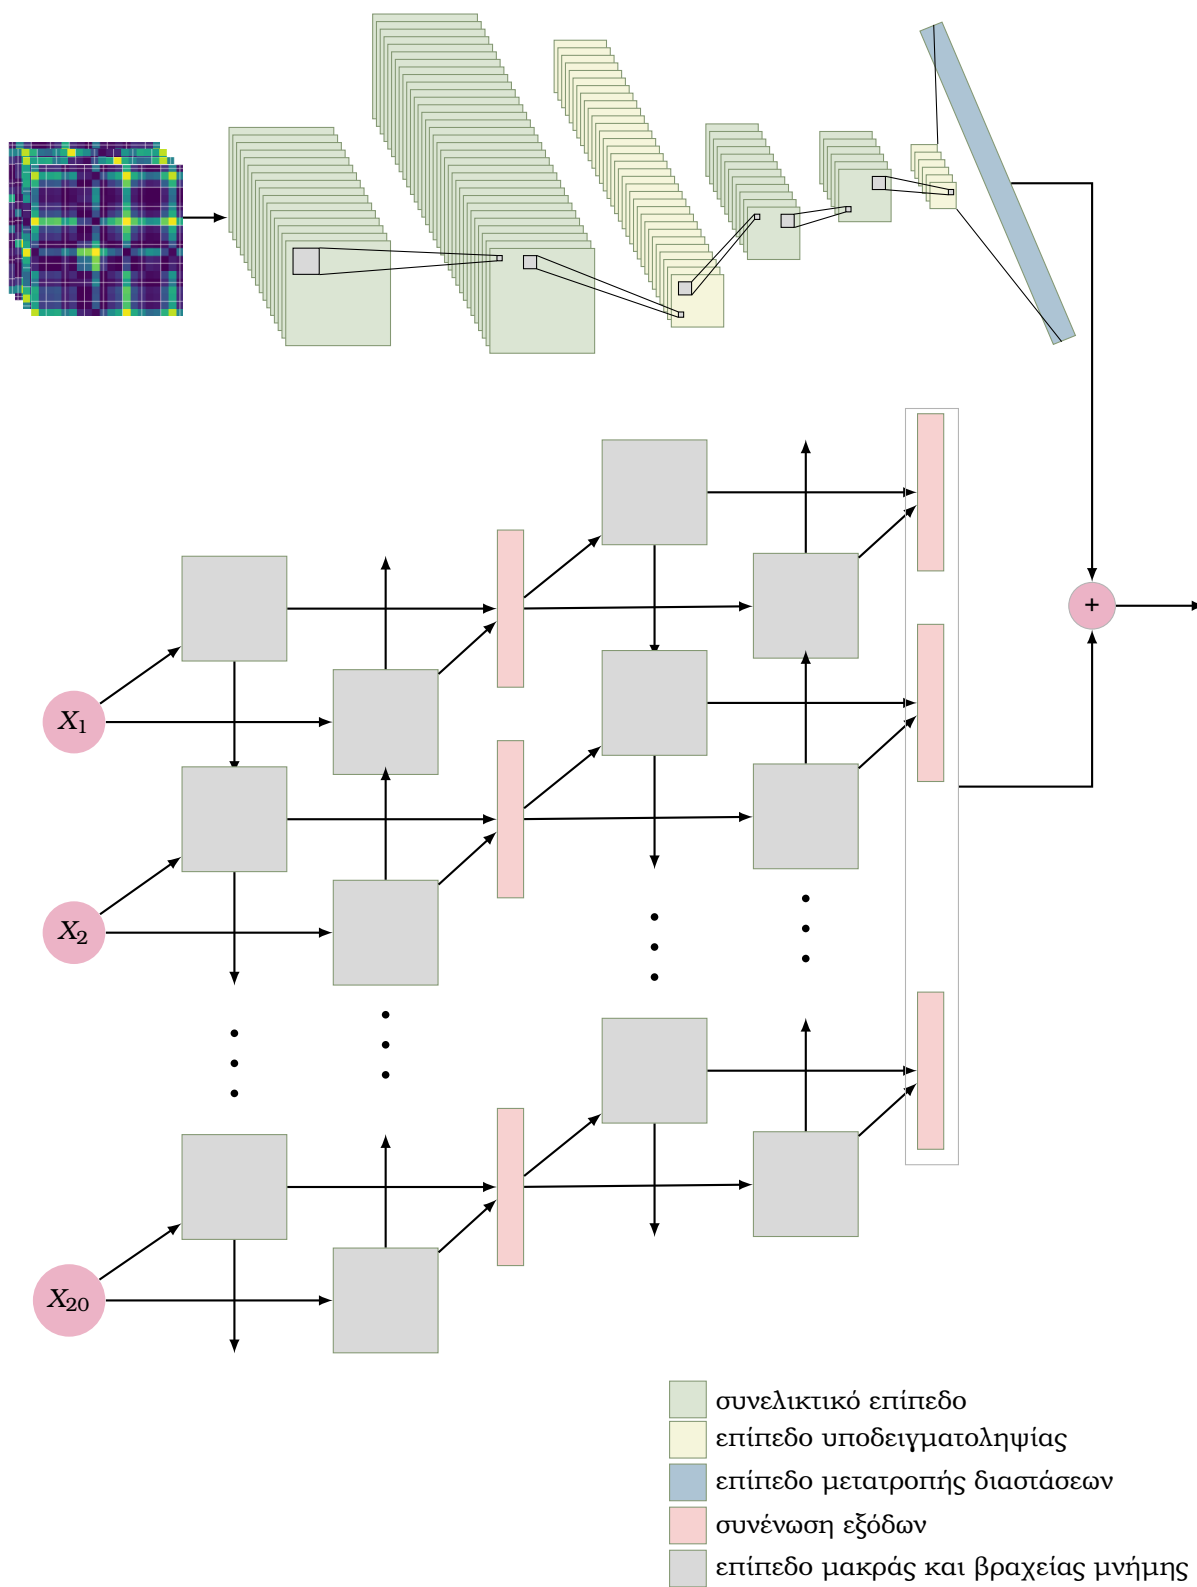
- δύο επίπεδα LSTM με 100 κόμβους διπλής κατεύθυνσης (bidirectional),

Στη συνέχεια τα δύο αυτά τμήματα ενώνονται μεταξύ τους με πρόσθεση των αντίστοιχων αναπαραστάσεων εξόδου και στη συνέχεια ακολουθεί το επίπεδο εξόδου του ενιαίου πλέον δικτύου. Για το σχήμα του δικτύου βλ. σχήμα 4.7, όπου ο συντελεστής «+» σημαίνει πρόσθεση διανυσμάτων στοιχείο προς στοιχείο.

4.5.2 Μέθοδοι βαθιάς ενισχυτικής μάθησης.

Για τα πειράματα βαθιάς ενισχυτικής μάθησης χρησιμοποιήθηκε ένας πράκτορας double deep q learning (ddqn). Όπως αναφέρθηκε στο θεωρητικό μέρος της εργασίας, ο πράκτορας αυτός περιλαμβάνει ένα βαθύ νευρωνικό δίκτυο. Στην παρούσα εργασία μελετήθηκαν συνελκτικά δίκτυα και πιο συγκεκριμένα τα πρώτα δύο δίκτυα της ενότητας 4.5.1. Για το υπόλοιπο της εργασίας θα γίνεται αναφορά σε αυτά τα μοντέλα με τις κωδικές ονομασίες EM_1 και EM_2 αντίστοιχα.

Η ιδέα για τη διεξαγωγή αυτών των πειραμάτων προέκυψε από το άρθρο [23]. Ως συνήθως η ενισχυτική μάθηση δεν αφορά προβλήματα επιβλεπόμενης μάθησης και επίσης δεν αφορά προβλήματα με μη ακολουθιακή συμπεριφορά δεδομένων. Ωστόσο, οι συγγραφείς του άρθρου πρότειναν τη χρήση ενός πράκτορα Deep Q-learning για την αντιμετώπιση του προβλήματος της ισορροπίας των δεδομένων, που άλλωστε είναι και η μεγαλύτερη πρόκληση στην περίπτωση της παρούσας εργασίας. Τα πειράματα του άρθρου περιλαμβάνουν ταξινόμηση συνόλων δεδομένων που μεταξύ άλλων είναι και εικόνες. Παραδείγματα τέτοιων συνόλων είναι το CIFAR [24] και το MNIST [25]. Και τα δύο αυτά σύνολα χρησιμοποιούνται για ταξινόμηση και επιπλέον αποτελούνται από εικόνες που είναι ανεξάρτητες μεταξύ τους και κατ' επέκταση δεν μπορούν να τοποθετηθούν σε κάποια σειρά.



Σχήμα 4.7: Υβριδικό δίκτυο με αμφίδρομα αναδρομικά επίπεδα.

Κεφάλαιο 5

Ανάλυση - αποτελέσματα πειραμάτων

5.1 Τεχνική αξιολόγηση

Τα πειράματα διενεργήθηκαν σε σύστημα με επεξεργαστή Intel(R) Core(TM) i7-5820K CPU @ 3.30GHz με έξι πυρήνες από δύο νήματα ο καθένας. Χρησιμοποιήθηκε η γλώσσα Python και πιο συγκεκριμένα, για την προεπεξεργασία και μετασχηματισμό των δεδομένων χρησιμοποιήθηκαν οι βιβλιοθήκες pandas και numpy. Για το σχεδιασμό των μοντέλων που περιγράφηκαν σε προηγούμενη ενότητα έγινε χρήση των βιβλιοθηκών keras και tensorflow, ενώ για την ενισχυτική μάθηση χρησιμοποιήθηκε η βιβλιοθήκη tf-agents.

Για τα πειράματα βαθιάς μάθησης (μοντέλα $BM_1 - BM_7$) χρησιμοποιήθηκαν οι ακόλουθες παράμετροι:

- ρυθμός μάθησης (learning rate): 0.001
- τμήμα συνόλου δεδομένων εκπαίδευσης (batch size): 32
- βελτιστοποιητής (optimizer): Adam
- συνάρτηση απωλειών (loss function): sparse categorical crossentropy
- αριθμός εποχών: 100

Ο σκοπός των πειραμάτων ήταν η σύγκριση των δύο διαφορετικών τρόπων αναπαράστασης των δεδομένων σε εικόνες και στη συνέχεια η μελέτη διαφορετικών μοντέλων, συνελικτικών, αναδρομικών, αλλά και συνδυασμών αυτών. Για τα μοντέλα αυτά χρησιμοποιήθηκε η αρχική μορφή των δεδομένων, δηλαδή οι χρονοσειρές των τιμών συναλλαγής των μετοχών, αλλά και η μορφή τους σε εικόνα GAF, που εμφάνισε καλύτερα αποτελέσματα από την άλλη μορφή των εικόνων, που βασίστηκε στην τεχνική ανάλυση.

Το ακόλουθο πείραμα -τα αποτελέσματα του οποίου φαίνονται στον πίνακα 5.1 - χρησιμοποιεί το δίκτυο BM_1 που είναι ένα απλό αναδρομικό δίκτυο δύο επιπέδων με μονάδες μακράς και βραχείας μνήμης.

	Τιμές Πρόβλεψης				Τιμές Πρόβλεψης				
	Τίποτα	Αγορά	Πώληση		Τίποτα	Αγορά	Πώληση		
Πραγματικές τιμές	Τίποτα	50227	17156	22358	Πραγματικές τιμές	Τίποτα	56352	14746	18643
	Αγορά	930	5379	0		Αγορά	934	5367	8
	Πώληση	961	0	5332		Πώληση	1197	11	5085

(α) Πίνακας σύγκρισης με εικόνες τεχνικής ανάλυσης

(β) Πίνακας σύγκρισης με εικόνες τεχνικής ανάλυσης

Πίνακας 5.2: Πίνακας σύγκρισης με χρήση του μοντέλου BM_2

	Τιμές Πρόβλεψης		
	Τίποτα	Αγορά	Πώληση
Τίποτα	45147	20205	24389
Αγορά	1391	4679	239
Πώληση	1603	227	4463

Πίνακας 5.1: Πίνακας σύγκρισης με χρήση του μοντέλου BM_1

Τα αποτελέσματα αυτού του πειράματος δεν είναι ιδιαίτερα πετυχημένα. Βλέπουμε ότι οι πετυχημένες προβλέψεις για την ενέργεια της αδράνειας («Τίποτα») είναι 45147, τη στιγμή που οι αποτυχημένες προβλέψεις αθροίζουν στο 44594 που σημαίνει ότι έχουμε περίπου 50% ακρίβεια. Επιπλέον, υπάρχει σημαντική σύγκριση μεταξύ των ετικετών «αγορά» και «πώληση» με 227 και 239 λάθος εκτιμήσεις αντίστοιχα.

Στο 5.2 παρουσιάζονται τα αποτελέσματα από τα δύο πειράματα με το ίδιο μοντέλο BM_2 .

Από τους πίνακες σύγκρισης, παρατηρούμε ότι οι προβλέψεις της αγοράς και της πώλησης είναι περίπου οι ίδιες. Ωστόσο, αξίζει να αναφερθεί ότι στην περίπτωση των εικόνων της τεχνικής ανάλυσης δεν υπάρχει ούτε μία σύγκριση μεταξύ αγοράς και πώλησης (μηδενικές τιμές στις αντίστοιχες θέσεις του πίνακα), σε αντίθεση με τις εικόνες GAF (τιμές 11 και 8 στον πίνακα). Επιπλέον, οι εικόνες GAF φαίνεται να είναι περισσότερο αποτελεσματικές ως προς την πρόβλεψη των στιγμών αγοράς και πώλησης, καθώς για αισθητά μικρότερο αριθμό προβλέψεων πετυχαίνει περίπου τον ίδιο αριθμό σωστών προβλέψεων. Υπάρχουν, δηλαδή, περίπου 6000 δείγματα στα οποία δεν τους έχει δοθεί λανθασμένα η ετικέτα «αγορά» ή η ετικέτα «πώληση».

Η καλύτερη επίδοση των εικόνων GAF οφείλεται στο ότι αυτές διατηρούν οποιαδήποτε χρονική εξάρτηση, με αποτέλεσμα να αφήνουν το νευρωνικό δίκτυο να εξαγάγει χρήσιμα χαρακτηριστικά για την καλύτερη ταξινόμηση των δειγμάτων. Ενώ με την τεχνική ανάλυση αν και γίνεται μία πολύ καλή προσέγγιση της κατάστασης της αγοράς, οι εικόνες δίνουν μία ήδη επεξεργασμένη αναπαράσταση, και κατά συνέπεια, μέρος της πληροφορίας χάνεται. Για το λόγο αυτό για τα υπόλοιπα πειράματα χρησιμοποιούμε τις εικόνες GAF (για περισσότερα

πειράματα με ΤΑ βλ. το σχήμα Α.1 του παραρτήματος Α).

Στη συνέχεια, παρουσιάζονται τα αποτελέσματα του μοντέλου BM_3 στο οποίο γίνεται χρήση της διαχωρίσιμης ως προς το βάθος συνέλιξης.

		Τιμές Πρόβλεψης		
		Τίποτα	Αγορά	Πώληση
Πραγματικές τιμές	Τίποτα	56417	14939	18385
	Αγορά	859	5445	5
	Πώληση	1210	17	5066

Πίνακας 5.3: Πίνακας σύγχυσης με χρήση του μοντέλου BM_3

Συγκριτικά με τα αποτελέσματα του προηγούμενου μοντέλου, δεν παρατηρούνται σημαντικές αλλαγές. Η ελάχιστη καλύτερη επίδοση του μοντέλου αυτού μπορεί να αποδοθεί ακόμα και στη στοχαστική φύση των νευρωνικών δικτύων. Ωστόσο, από το πείραμα αυτό προκύπτει το συμπέρασμα ότι με λιγότερες παραμέτρους μπορεί να επιτευχθεί αποτέλεσμα παρόμοιας ακρίβειας με την κλασική συνέλιξη.

Στη συνέχεια αναγράφονται τα αποτελέσματα για τα υβριδικά μοντέλα που συνδυάζουν την ικανότητα της συνέλιξης να εξάγει χαρακτηριστικά από τις εικόνες και την ικανότητα του αναδρομικού μοντέλου να εξάγει συσχετίσεις που βασίζονται στο χρόνο. Στον παρακάτω πίνακα συγκρίνουμε τους πίνακες σύγχυσης του μοντέλου BM_4 και BM_5 για εικόνες εισόδου GAF και χρονοσειρές που περιέχουν τις τιμές συναλλαγής των μετοχών καθημερινά για το τέλος της ημέρας.

		Τιμές Πρόβλεψης					Τιμές Πρόβλεψης		
		Τίποτα	Αγορά	Πώληση			Τίποτα	Αγορά	Πώληση
Πραγματικές τιμές	Τίποτα	52557	16512	20672	Πραγματικές τιμές	Τίποτα	55063	14746	19293
	Αγορά	1068	5236	5		Αγορά	853	5449	7
	Πώληση	1307	11	4975		Πώληση	1129	22	5142

(α) Πίνακας σύγχυσης με χρήση του μοντέλου BM_4

(β) Πίνακας σύγχυσης με χρήση του μοντέλου BM_5

Πίνακας 5.4: Πίνακας σύγχυσης με διαφορετικούς τρόπους μείωσης των διαστάσεων πριν την πρόσδεση των επιμέρους τμημάτων του δικτύου

Από τα αποτελέσματα των δύο μοντέλων, φαίνεται ότι τα συνελκτικά επίπεδα είναι περισσότερο αποτελεσματικά από τα πλήρως συνδεδεμένα καθώς, καταφέρνουν να μειώσουν το μέγεθος της αναπαράστασης κρατώντας περισσότερη πληροφορία. Ωστόσο, από τον πίνακα του BM_5 βλέπουμε ότι το αναδρομικό τμήμα δεν βελτίωσε την επίδοση του δικτύου. Αυτό, πιθανότατα, οφείλεται στη φύση του προβλήματος της ταξινόμησης, για το οποίο μάλλον τα αναδρομικά δίκτυα τελικά δεν είναι ισχυρά, όπως άλλωστε είδαμε νωρίτερα και στο αμιγώς

αναδρομικό δίκτυο BM_1 .

Τέλος, ακολουθούν τα αποτελέσματα των μοντέλων BM_6 και BM_7 .

		Τιμές Πρόβλεψης					Τιμές Πρόβλεψης		
		Τίποτα	Αγορά	Πώληση			Τίποτα	Αγορά	Πώληση
Πραγματικές τιμές	Τίποτα	55431	15108	19202	Πραγματικές τιμές	Τίποτα	55300	15077	19364
	Αγορά	855	5446	8		Αγορά	937	5357	15
	Πώληση	1122	7	5164		Πώληση	1136	14	5143

(α) Πίνακας σύγκρισης με χρήση του μοντέλου BM_6 (συνένωση) (β) Πίνακας σύγκρισης με χρήση του μοντέλου BM_7 (πρόσθεση)

Πίνακας 5.5: Πίνακας σύγκρισης αναδρομικό με αναδρομικό δίκτυο διπλής κατεύθυνσης

Τα μοντέλα BM_6 και BM_7 περιλαμβάνουν συνελκτικό τμήμα και αμφίδρομο αναδρομικό που συνδέονται με συνένωση και πρόσθεση των επιμέρους αναπαραστάσεων τους αντίστοιχα. Η τεχνική της συνένωσης φαίνεται να παρουσιάζει ελαφρώς καλύτερα αποτελέσματα από αυτή της πρόσθεσης.

Στη συνέχεια (πίνακας 5.6) ακολουθούν τα αποτελέσματα των πειραμάτων ενισχυτικής μάθησης, τα οποία έτρεξαν με τις εξής παραμέτρους και κανόνες:

- Ρυθμός μάθησης learning rate: 0.00025
- Μέγεθος μνήμης επανάληψης (replay memory): 100000
- Μέγεθος τμήματος δεδομένων εκπαίδευσης (batch size) : 64
- Αριθμός βημάτων/επαναλήψεων: 120000
- συντελεστής μείωσης γ (discount factor): 0.1
- συνάρτηση αμοιβής:

$$R(s, a, l) = \begin{cases} 1 & a = l, s \in D_b \\ -1 & a \neq l, s \in D_b \\ \hat{l}_1 & a = l, s \in D_s \\ -\hat{l}_1 & a \neq l, s \in D_s \\ \hat{l}_2 & a = l, s \in D_h \\ -\hat{l}_2 & a \neq l, s \in D_h \end{cases}$$

όπου $\hat{l}_1 = \frac{\text{αριθμος δειγματων αγορας}}{\text{αριθμος δειγματων πωλησης}}$, $\hat{l}_2 = \frac{\text{αριθμος δειγματων αγορας}}{\text{αριθμος δειγματων τιποτα}}$, l : η πραγματική ετικέτα, s : η κατάσταση του περιβάλλοντος, a : η ενέργεια που αποφασίστηκε από τον πράκτορα, D_b : το σύνολο των δεδομένων με ετικέτα «αγορά» (buy), D_s : το σύνολο των δεδομένων με ετικέτα «πώληση» (sell) και D_h : το σύνολο των δεδομένων με ετικέτα «τίποτα» (hold)

- κανόνας τερματισμού επεισοδίου: Ένα επεισόδιο τερματίζεται είτε όταν έχουν τροφοδοτηθεί όλα τα δεδομένα εκπαίδευσης είτε όταν η πραγματική ετικέτα του δείγματος είναι αγορά ή πώληση και η πρόβλεψη είναι λάθος.

Πραγματικές τιμές		Τιμές Πρόβλεψης			Πραγματικές τιμές		Τιμές Πρόβλεψης		
		Τίποτα	Αγορά	Πώληση			Τίποτα	Αγορά	Πώληση
Πραγματικές τιμές	Τίποτα	45787	17630	26324	Πραγματικές τιμές	Τίποτα	49926	17351	22464
	Αγορά	486	5759	64		Αγορά	410	5861	38
	Πώληση	490	31	5772		Πώληση	554	32	5707

(α) Πίνακας σύγχυσης με χρήση του μοντέλου EM_1

(β) Πίνακας σύγχυσης με χρήση του μοντέλου EM_2

Πίνακας 5.6: Πίνακας σύγχυσης με τα μοντέλα ενισχυτικής μάθησης

Ακολουθεί πίνακας 5.7 που περιλαμβάνει τις μετρικές f1-score, precision, recall για όλα τα πειράματα.

Μοντέλο	Ενέργεια	f1-score	precision	recall
BM_1	Τίποτα	0.654864	0.937808	0.503081
	Αγορά	0.297836	0.186333	0.741639
	Πώληση	0.252261	0.153415	0.709201
BM_2	Τίποτα	0.760363	0.963562	0.627940
	Αγορά	0.406083	0.266696	0.850689
	Πώληση	0.338673	0.214232	0.808041
$BM_2(TA)$	Τίποτα	0.708125	0.963717	0.559688
	Αγορά	0.372971	0.238695	0.852592
	Πώληση	0.313803	0.192560	0.847290
BM_3	Τίποτα	0.761224	0.964624	0.628665
	Αγορά	0.407712	0.266899	0.863053
	Πώληση	0.340583	0.215979	0.805021
BM_4	Τίποτα	0.726563	0.956765	0.585652
	Αγορά	0.373094	0.240636	0.829926
	Πώληση	0.311473	0.193942	0.790561
BM_5	Τίποτα	0.753529	0.965256	0.617977
	Αγορά	0.410842	0.269526	0.863687
	Πώληση	0.334602	0.210376	0.817098
BM_6	Τίποτα	0.753400	0.965562	0.617678
	Αγορά	0.405358	0.264870	0.863211
	Πώληση	0.336779	0.211865	0.820594
BM_7	Τίποτα	0.751798	0.963868	0.616218
	Αγορά	0.400419	0.261981	0.849104
	Πώληση	0.333798	0.209730	0.817257
EM_1	Τίποτα	0.670852	0.979128	0.510212
	Αγορά	0.387433	0.245901	0.912823
	Πώληση	0.300211	0.179478	0.917210
EM_2	Τίποτα	0.710028	0.981056	0.556334
	Αγορά	0.396643	0.252151	0.928990
	Πώληση	0.330821	0.202311	0.906881

Πίνακας 5.7: Μειτρικές επίδοσης των μοντέλων

5.2 Οικονομική αξιολόγηση

Το σύστημα έπειτα από την ταξινόμηση των δειγμάτων εκτελεί τον αλγόριθμο σύμφωνα με τον οποίο εκτελούνται οι συναλλαγές. Ο αλγόριθμος που έχει υλοποιηθεί είναι αυτός που έχει προταθεί στο [1]. Για το σύνολο δεδομένων που χρησιμοποιείται στην αξιολόγηση του μοντέλου λαμβάνουμε τις αρχικές τιμές (δηλ. πριν την προεπεξεργασία των δεδομένων) με τη σωστή χρονολογική σειρά. Έπειτα, για κάθε σήμα αγοράς ή πώλησης που έχει προκύψει από την ταξινόμηση του μοντέλου βαθιάς (ενισχυτικής) μάθησης, εκτελείται κάθε συναλλαγή εναλλάξ, με την πρώτη αλλαγή που θα παρατηρηθεί στις ετικέτες των ακολουθιακών δεδομένων. Επιπλέον, όταν αγοράζεται μία μετοχή, επενδύεται το συνολικό κεφάλαιο που έχει προκύψει μέχρι εκείνη τη στιγμή. Αντίστοιχα, όταν πωλείται κάποιο στοιχείο, πωλείται ολόκληρη η ποσότητα που έχει αγοραστεί προηγουμένως. Το αρχικό κεφάλαιο είναι 10.000 μονάδες χρήματος.

Ο ψευδοκώδικας του αλγορίθμου συναλλαγών είναι ο εξής:

ΑΛΓΟΡΙΘΜΟΣ 5.1: Υπολογισμός Αλγορίθμου Συναλλαγών

```

Input:  $X$  (test time series)
totalMoney=10000
counter=1
while counter<=length(X) do
  if X[counter].label==BUY then
    numberOfStocks =  $\frac{\text{totalMoney}}{X[\text{counter}].\text{price}}$ 
  else if X[counter].label==SELL then
    totalMoney = numberOfStocks * X[counter].price
  else no action
  end if
  counter += 1

```

Για την οικονομική αξιολόγηση των πειραμάτων χρησιμοποιείται η μετρική των ετήσιων επιστροφών (annualized returns). Αυτή ορίζεται ως εξής:

$$\text{annualizedReturns} = \left(\left(\frac{\text{totalMoney}}{\text{initialCapital}} \right)^{\frac{1}{\text{numberOfYears}}} - 1 \right) \cdot 100$$

όπου numberOfYears: ο συνολικός αριθμός των ετών για τα οποία αξιολογήθηκε το μοντέλο, initialCapital: το αρχικό κεφάλαιο (στη περίπτωση μας 10000 μονάδες χρήματος), totalMoney: ο συνολικός αριθμός μονάδων χρήματος που συγκεντρώθηκε μέχρι το τέλος της αξιολόγησης.

Ουσιαστικά, η συγκεκριμένη μετρική είναι ο γεωμετρικός μέσος όρος των χρημάτων που συγκεντρώθηκαν από τις επενδύσεις κάθε χρόνου και δείχνει τι θα κέρδιζε ένας επενδυτής σε μία χρονική περίοδο αν το ετήσιο κέρδος ήταν σταθερό. Το αποτέλεσμα της μετρικής εκφράζει το ποσοστό αύξησης του αρχικού ποσού επένδυσης μετά από ένα έτος (π.χ. 10% σημαίνει ότι μετά από ένα χρόνο θα έχουμε το 110% του αρχικού κεφαλαίου).


Stock	BM_1	$BM_2(TA)$	$BM_2(GAF)$	BM_3	$BM_4(GAF)$	$BM_4(TA)$
MMM	3.54	4.827	7.785	7.075	7.544	8.263
AXP	6.262	8.836	17.471	9.891	10.278	8.066
AMGN	9.5	1.986	4.542	9.138	4.645	6.031
AAPL	6.341	5.419	6.179	4.275	14.318	3.116
BA	-4.101	-2.766	9.017	7.982	7.087	-2.815
CAT	-0.572	-2.681	-0.17	-1.404	-3.897	-4.942
CVX	4.254	0.587	4.301	7.623	4.729	2.953
CSCO	6.9	5.864	8.264	7.007	12.767	6.54
KO	7.812	8.804	8.687	9.125	6.617	8.721
DOW	3.949	0.489	0.808	1.267	1.64	0.937
GS	8.541	1.838	2.629	4.25	7.16	-0.868
HD	8.43	4.633	4.704	4.345	13.824	5.0
HON	7.03	4.191	7.886	6.859	11.172	5.749
IBM	6.572	1.455	4.761	6.435	3.402	3.453
INTC	12.288	8.543	15.328	4.896	7.54	5.212
JNJ	4.17	4.509	4.521	5.721	6.614	2.519
JPM	10.314	7.361	19.812	14.808	23.466	10.583
MCD	13.44	10.815	11.421	12.507	17.081	13.108
MRK	4.451	7.483	6.751	7.502	8.981	5.875
MSFT	14.189	13.273	15.001	14.348	18.219	18.237
NKE	14.412	17.511	20.106	19.079	22.861	16.864
PG	5.73	7.507	3.868	7.488	8.836	5.505
CRM	23.044	12.49	19.309	16.307	18.801	15.913
TRV	10.727	13.047	19.214	16.003	20.545	8.905
UNH	7.99	9.458	11.288	12.37	7.816	1.189
VZ	7.988	5.102	1.771	4.936	7.648	3.982
V	16.96	19.338	19.05	21.797	22.702	18.119
WBA	0.441	2.128	6.088	9.511	3.759	1.673
WMT	6.011	9.281	12.166	10.591	10.496	9.5
DIS	10.028	9.818	10.308	9.481	11.684	4.955
Total	236.641	201.146	282.866	271.213	318.335	192.343

Πίνακας 5.8: Ετήσιες επιστροφές των μοντέλων (μέρος 1ο)


Stock	BM_5	$BM_6(GAF)$	$BM_6(TA)$	BM_7	EM_1	EM_2
MMM	9.371	7.706	5.999	9.368	3.892	4.777
AXP	8.984	3.366	10.413	13.718	5.792	9.477
AMGN	2.394	8.184	2.578	3.342	7.244	3.833
AAPL	6.09	2.366	6.621	5.226	9.683	18.064
BA	3.993	0.879	1.853	6.111	-1.706	-4.474
CAT	-0.212	-1.425	-6.467	-4.032	-4.159	14.128
CVX	5.179	4.439	0.864	7.673	-2.396	4.559
CSCO	6.14	9.822	5.966	3.859	5.113	10.609
KO	10.78	7.111	10.299	9.451	5.487	5.149
DOW	0.942	0.982	1.117	0.238	-1.687	-4.959
GS	3.86	3.791	-0.532	0.154	2.028	0.12
HD	4.502	9.835	6.784	1.414	7.032	4.325
HON	5.427	14.15	7.497	6.568	5.507	4.393
IBM	2.842	1.009	4.36	2.593	-0.916	-0.577
INTC	7.425	5.698	7.205	4.865	8.628	4.184
JNJ	5.647	4.708	4.51	3.45	3.997	1.384
JPM	11.799	12.261	10.136	7.99	6.68	12.916
MCD	9.397	11.96	11.475	11.732	6.73	4.5
MRK	6.837	6.452	7.562	5.058	3.752	0.12
MSFT	18.178	15.85	15.788	17.458	11.046	8.757
NKE	21.061	21.695	21.802	19.218	14.707	9.731
PG	6.342	5.694	7.469	9.75	6.327	7.186
CRM	18.8	18.937	15.05	10.442	14.368	17.218
TRV	17.277	13.276	13.127	19.062	13.712	8.294
UNH	3.804	9.204	9.759	7.412	-1.589	6.938
VZ	5.824	4.937	3.058	4.295	2.546	3.558
V	23.343	20.756	17.283	21.251	20.962	11.597
WBA	1.77	4.376	3.814	6.432	6.749	2.701
WMT	7.924	10.048	10.737	8.372	9.239	7.074
DIS	8.907	11.73	6.716	7.598	4.743	7.171
Total	244.627	249.797	222.843	230.068	173.511	182.753

Πίνακας 5.9: Ετήσιες επιστροφές των μοντέλων (μέρος 2ο)

Σε γενικές γραμμές, η επίδοση όλων των μοντέλων φαίνεται αρκετά υγιής, αφού για τη συντριπτική πλειοψηφία των μετοχών οι ετήσιες επιστροφές είναι θετικές. Από τους πίνακες 5.8 και 5.9 διαπιστώνουμε ότι το μοντέλο που απέδωσε καλύτερα από άποψη κέρδους φαίνεται να είναι το BM_4 με εικόνες εισόδου GAF. Η διαφορά από τα υπόλοιπα μοντέλα είναι μεγάλη. Σε ορισμένες μετοχές η επίδοση είναι περίπου η ίδια ενώ σε άλλες πετυχαίνει περισσότερα κέρδη. Το συγκεκριμένο μοντέλο, ωστόσο, είχε από τις χειρότερες επιδόσεις στην αξιολόγηση της ταξινόμησης. Κατά συνέπεια, το αυξημένο συνολικό κέρδος οφείλεται στο γεγονός ότι εξαιτίας των πολλών λανθασμένων προβλέψεων για τις ενέργειες αγορά/πώληση, το μοντέλο έχει μάθει να βρίσκει πολλά συνεχόμενα σήματα που αντιστοιχούν στην ίδια ενέργεια. Επομένως, οι συναλλαγές που εκτελούνται είναι πολύ λίγες και περισσότερο εύστοχες. Για να μελετηθεί καλύτερα η συμπεριφορά του BM_4 παρουσιάζεται στην εικόνα 5.1 η διαφορά στις προβλέψεις μεταξύ της μεθόδου αυτής και της αμέσως καλύτερης (BM_2) -απ' την άποψη των αποδοχών.



(α) Προβλέψεις GS με το μοντέλο BM_2



(β) Προβλέψεις GS με το μοντέλο BM_4

Σχήμα 5.1: Επίδοση μοντέλων για τη μετοχή GS κατά το έτος 2020

Δύο σημαντικές παρατηρήσεις απορρέουν από την απεικόνιση των προβλέψεων και των συναλλαγών που έχουν εκτελεστεί. Αρχικά, στην περίπτωση του BM_4 υπάρχουν περισσότερα πράσινα και κόκκινα σημεία, γεγονός που σημαίνει ότι το μοντέλο έλαβε περισσότερα σήματα για αγορά ή πώληση απ' ότι έλαβε το BM_2 . Το τελευταίο, ήταν φανερό και από τους αντίστοιχους πίνακες σύγκυσης που παρουσιάστηκαν παραπάνω. Το BM_4 κάνει περισσότερες προβλέψεις αγοράς/πώλησης και ως εκ τούτου η πληθώρα των αντίστοιχων ενδείξεων στο διάγραμμα είναι λογική.

Το δεύτερο σημείο που αξίζει να αναφερθεί είναι ότι οι προβλέψεις για το BM_4 είναι με τέτοιο τρόπο καταναμημένες στο χρόνο, που αν θεωρήσει κανείς μία νοητή οριζόντια γραμμή, θα μπορούσε να διαχωρίσει τα σημεία της αγοράς από αυτά της πώλησης. Κατά συνέπεια, φαίνεται να απορροφά τις μικρές διακυμάνσεις της αγοράς, πράγμα το οποίο οδηγεί σε πιο πετυχημένες συναλλαγές. Αντίθετα, για το BM_2 συμπεραίνουμε, ότι κάθε φορά που αλλάζει

η τάση της αγοράς, αλλάζουν και οι προβλέψεις σχεδόν αμέσως, με αποτέλεσμα να αγοραστεί κάποια μετοχή αρκετά πριν φτάσει τοπικό ελάχιστο και αντίστοιχα να πουληθεί πριν φτάσει κάποιο τοπικό μέγιστο.

Επιπλέον, είναι προφανές ότι τα μοντέλα EM_1 και EM_2 δεν παρουσιάζουν καλή επίδοση ούτε στην οικονομική αξιολόγηση. Μάλιστα παρουσιάζουν αρνητικές επιστροφές για περισσότερες μετοχές απ' ό,τι τα υπόλοιπα μοντέλα.

Κεφάλαιο 6

Επίλογος

Στο κεφάλαιο αυτό γράφονται αναλυτικά τα συμπεράσματα της παρούσας εργασίας καθώς επίσης και οι μελλοντικές επεκτάσεις που θα μπορούσαν να γίνουν ως συνέχεια της μελέτης αυτής.

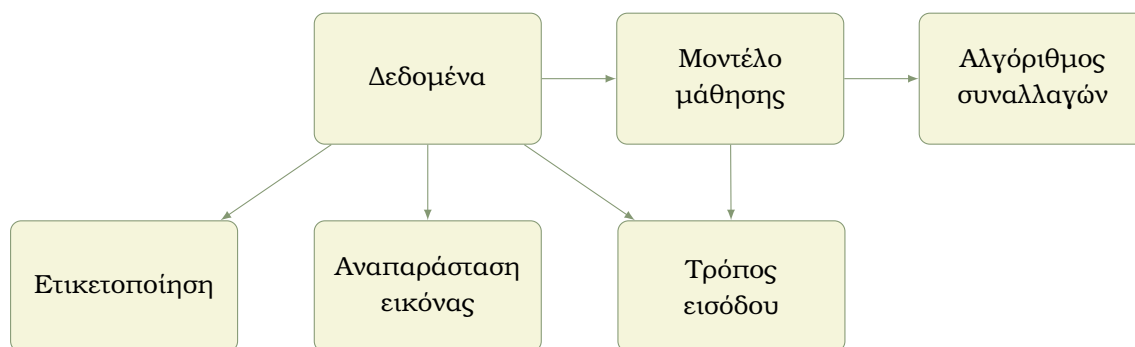
6.1 Συμπεράσματα

Τα συμπεράσματα που προκύπτουν από τη συγκεκριμένη μελέτη και τη διεξαγωγή των προαναφερθέντων πειραμάτων συνοψίζονται γύρω από τρία κύρια σημεία.

Το πρώτο έχει να κάνει με τη χρήση εικόνων (σαν ιδέα) για τη διευκόλυνση της εύρεσης καλύτερων συναλλαγών στο χρηματιστήριο. Για τη συγκεκριμένη μοντελοποίηση του προβλήματος (δηλ. τον αλγόριθμο ετικετοποίησης και την αντιμετώπιση του προβλήματος ως πρόβλημα ταξινόμησης) διαπιστώθηκε πως η χρήση εικόνων είναι καταλυτικής σημασίας για την άμεση και αποτελεσματική εξαγωγή χαρακτηριστικών χρησιμοποιώντας βαθιά νευρωνικά δίκτυα.

Δεύτερο σημείο ενδιαφέροντος, αποτελεί το γεγονός ότι τα αναδρομικά δίκτυα δεν κατάφεραν να σημειώσουν κάποια επιτυχία. Τα αμιγώς συνελκτικά δίκτυα εμφάνισαν καλά αποτελέσματα στις μετρικές τόσο της τεχνικής όσο και της οικονομικής αξιολόγησης. Η χρήση των μονάδων μακράς και βραχείας μνήμης σε υβριδικά μοντέλα (συνδυασμός συνελκτικών-αναδρομικών δικτύων) δε βελτίωσε την απόδοση του συστήματος. Ωστόσο, άξια αναφοράς είναι η συμπεριφορά του μοντέλου που συνδύασε αναδρομικά και συνελκτικά δίκτυα μειώνοντας της διαστάσεις χρησιμοποιώντας πλήρως συνελκτικά δίκτυα. Το συγκεκριμένο μοντέλο, ενώ είχε από τα εχιρότερα αποτελέσματα ακρίβειας στην ταξινόμηση των χρονικών στιγμών, σημείωσε το μεγαλύτερο κέρδος. Κατάφερε να διαχωρίσει με επιτυχία τα πιθανά σημεία αγοράς από τα αντίστοιχα της πώλησης και με λιγότερες συναλλαγές να πετύχει μεγαλύτερο κέρδος από τις υπόλοιπες μεθόδους.

Τέλος, η χρήση της βαθιάς ενισχυτικής μάθησης για το συγκεκριμένο πρόβλημα δεν απέδωσε καρπούς, πράγμα το οποίο οφείλεται στην περιορισμένη έρευνα που έγινε σχετικά με το συγκεκριμένο θέμα, καθώς επίσης και της δυσκολίας να προσδιοριστούν σωστά οι υπερπαράμετροι του μοντέλου.



Σχήμα 6.1: Τμήματα του συστήματος

6.2 Μελλοντικές επεκτάσεις

Λαμβάνοντας υπόψη τα παραπάνω, γίνεται αντιληπτό ότι η μελέτη του συγκεκριμένου θέματος μπορεί να αναπτυχθεί περαιτέρω και να συνεχιστεί σε κάθε στάδιο που αναφέρθηκε στα προηγούμενα κεφάλαια. Πιο συγκεκριμένα στην εικόνα 6.1 διακρίνονται τα διαφορετικά τμήματα από τα οποία αποτελείται το σύστημα που αναλύθηκε στην εργασία.

Οι μελλοντικές επεκτάσεις μπορούν να συμβούν:

- στο τμήμα των δεδομένων:

Αναλυτικά, έρευνα μπορεί να διεξαχθεί ως προς τον τρόπο αναπαράστασης των αρχικών δεδομένων των χρονοσειρών σε εικόνες. Στα πλαίσια της εργασίας είδαμε τη χρήση δεικτών τεχνικής ανάλυσης και τη χρήση του Γραμμιανού γωνιακού χώρου. Θα μπορούσε να γίνει αντίστοιχη ανάλυση για εικόνες που δείχνουν τη χρονοσειρά σαν διάγραμμα ή για εικόνες που προκύπτουν από τα candlesticks.

Ως προς την διαδικασία ετοιμασίας του συνόλου δεδομένων εκπαίδευσης, ο αλγόριθμος ανάθεσης ετικετών είναι ένα σημαντικό τμήμα του συστήματος, από το οποίο εξαρτάται και η προβλεπτική ισχύς του. Εναλλακτικοί αλγόριθμοι, λοιπόν, περιλαμβάνουν τη χρήση δεικτών τεχνικής ανάλυσης για την ανάθεση σημείων αγοράς ή πώλησης.

Επιπλέον, για τα πειράματα της εργασίας χρησιμοποιήθηκαν στατικές εικόνες. Θα άξιζε να γίνει προσπάθεια να τροφοδοτηθούν τα νευρωνικά δίκτυα με μία σειρά από διαδοχικές εικόνες. Κατ' αυτόν τον τρόπο, θα είναι δυνατή η χρήση αρχιτεκτονικών δικτύων που περιλαμβάνουν αναδρομικά δίκτυα τοποθετημένα στην κορυφή συνελικτικών δικτύων.

- στο μοντέλο μάθησης:

Ενδιαφέρον, επίσης, θα είχε και η ενδεδειγμένη μελέτη των συστημάτων ενισχυτικής μάθησης. Στα πλαίσια της παρούσας εργασίας, είδαμε Double Deep Q-learning με συνελικτικά δίκτυα. Ωστόσο, θα μπορούσε κανείς να προσεγγίσει το ζήτημα χρησιμοποιώντας συνδυασμό συνελικτικού και αναδρομικού δικτύου ή ακόμα και κάποιον άλλο πράκτορα. Η διαμόρφωση της συνάρτησης αμοιβής είναι ζωτικής σημασίας για την έκβαση της μάθησης. Κατά συνέπεια, θα μπορούσε να προσαρμοστεί ώστε να περιλαμβάνει και την πληροφορία της μεταβλητότητας της αγοράς ή του κέρδους από την πώληση ή την αγορά ενός στοιχείου.

- στο στάδιο της εκτέλεσης των συναλλαγών:

Σημαντικό θα ήταν να δοκιμαστούν διαφορετικοί τρόποι για τον αλγόριθμο των συναλλαγών. Η λογική που υιοθετήθηκε στην εργασία -δηλαδή αγορά/πώληση εναλλάξ με το πρώτο σήμα που βρίσκει ο αλγόριθμος βλέποντας το αποτέλεσμα του μοντέλου ταξινόμησης- είναι πολύ απλή και σίγουρα ανάλογα με τη μορφή της αγοράς για κάποια μετοχή μπορεί να μη φέρει τα επιθυμητά αποτελέσματα. Η ενισχυτική μάθηση, για παράδειγμα, θα μπορούσε να καλύψει αυτή την ανάγκη με μία πιο περίπλοκη συνάρτηση αμοιβής. Σε κάθε περίπτωση ένα πιο εκλεπτυσμένο στρώμα επεξεργασίας των εκτιμήσεων της ταξινόμησης θα ήταν χρήσιμο για την ασφαλέστερη εκτέλεση συναλλαγών.

Παραρτήματα

Περαιτέρω αποτελέσματα

Επιπλέον αποτελέσματα για πειράματα με εικόνες εισόδου που προέκυψαν από τη διαδικασία της τεχνικής ανάλυσης.

		Τιμές Πρόβλεψης					Τιμές Πρόβλεψης		
		Τίποτα	Αγορά	Πώληση			Τίποτα	Αγορά	Πώληση
Πραγματικές τιμές	Τίποτα	41671	21631	26439	Πραγματικές τιμές	Τίποτα	48566	18436	22739
	Αγορά	577	5732	0		Αγορά	804	5505	0
	Πώληση	727	0	5566		Πώληση	980	0	5313

(α) Πίνακας σύγχυσης με χρήση του μοντέλου BM_4

(β) Πίνακας σύγχυσης με χρήση του μοντέλου BM_6

Ενέργεια	f1-score	precision	recall	Ενέργεια	f1-score	precision	recall
Τίποτα	0.6280	0.9697	0.4643	Τίποτα	0.6933	0.9646	0.5412
Αγορά	0.340461	0.209480	0.9085	Αγορά	0.3640	0.2299	0.8726
Πώληση	0.2907	0.1739	0.8845	Πώληση	0.3094	0.1894	0.8443

(γ) Μειτρικές επίδοσης του μοντέλου BM_4

(δ) Μειτρικές επίδοσης μοντέλου BM_6

Πίνακας Α.1: Πίνακας σύγχυσης με τα μοντέλα BM_4 και BM_6 για δεδομένα ΤΑ

Βιβλιογραφία

- [1] Omer Berat Sezer και A. Ozbayoglu. *Algorithmic financial trading with deep convolutional neural networks: Time series to image conversion approach*. *Appl. Soft Comput.*, 70:525–538, 2018.
- [2] Issam El Naqa και Martin J Murphy. *What is machine learning?* σελίδες 3–11, 2015.
- [3] M. Mohri, A. Rostamizadeh και A. Talwalkar. *Foundations of Machine Learning, second edition*. Adaptive Computation and Machine Learning series. MIT Press, 2018.
- [4] Taiwo Oladipupo Ayodele. *Types of machine learning algorithms*. *New advances in machine learning*, 3:19–48, 2010.
- [5] Saad Albawi, Tareq Abed Mohammed και Saad Al-Zawi. *Understanding of a convolutional neural network*. *2017 International Conference on Engineering and Technology (ICET)*, σελίδες 1–6, 2017.
- [6] François Chollet. *Xception: Deep Learning with Depthwise Separable Convolutions*. *CoRR*, αβσ/1610.02357, 2016.
- [7] Lukasz Kaiser, Aidan N. Gomez και François Chollet. *Depthwise Separable Convolutions for Neural Machine Translation*. *CoRR*, αβσ/1706.03059, 2017.
- [8] Bekir Karlik και A Vehbi Olgac. *Performance analysis of various activation functions in generalized MLP architectures of neural networks*. *International Journal of Artificial Intelligence and Expert Systems*, 1(4):111–122, 2011.
- [9] Mian Mian Lau και King Hann Lim. *Review of Adaptive Activation Function in Deep Neural Network*. *2018 IEEE-EMBS Conference on Biomedical Engineering and Sciences (IECBES)*, σελίδες 686–690, 2018.
- [10] Zachary Chase Lipton. *A Critical Review of Recurrent Neural Networks for Sequence Learning*. *CoRR*, αβσ/1506.00019, 2015.
- [11] M. Schuster και K.K. Paliwal. *Bidirectional recurrent neural networks*. *IEEE Transactions on Signal Processing*, 45(11):2673–2681, 1997.
- [12] Sepp Hochreiter και Jürgen Schmidhuber. *Long Short-term Memory*. *Neural computation*, 9:1735–80, 1997.
- [13] Xuan Hien Le, Hung Viet Ho, Giha Lee και Sungho Jung. *Application of long short-term memory (LSTM) neural network for flood forecasting*. *Water*, 11(7):1387, 2019.

- [14] Richard S Sutton και Andrew G Barto. *Reinforcement learning: An introduction*. MIT press, 2018.
- [15] Simon S. Haykin. *Neural networks and learning machines*. Pearson Education, τηροδη έκδοση, 2009.
- [16] Volodymyr Mnih, Koray Kavukcuoglu, David Silver, Alex Graves, Ioannis Antonoglou, Daan Wierstra και Martin Riedmiller. *Playing Atari with Deep Reinforcement Learning*, 2013.
- [17] Hadovan Hasselt, Arthur Guez και David Silver. *Deep Reinforcement Learning with Double Q-Learning*. *Proceedings of the AAAI Conference on Artificial Intelligence*, 30(1), 2016.
- [18] S Kim, K Asadi, M Littman και G Konidaris. *DeepMellow: Removing the Need for a Target Network in Deep Q-Learning*. *Proceedings of the Twenty Eighth International Joint Conference on Artificial Intelligence*.
- [19] Matteo Hessel, Joseph Modayil, Hado Van Hasselt, Tom Schaul, Georg Ostrovski, Will Dabney, Dan Horgan, Bilal Piot, Mohammad Azar και David Silver. *Rainbow: Combining improvements in deep reinforcement learning*. *Thirty-second AAAI conference on artificial intelligence*, 2018.
- [20] G. Nuti, Mahnoosh Mirghaemi, P. Treleaven και Chaiyakorn Yingsaeree. *Algorithmic Trading*. *Computer*, 44:61-69, 2011.
- [21] Thomas N Bulkowski. *Encyclopedia of candlestick charts*, τόμος 332. John Wiley & Sons, 2012.
- [22] Yun Cheng Tsai, J. Chen και Chun Chieh Wang. *Encoding candlesticks as images for pattern classification using convolutional neural networks*. *Financial Innovation*, 6:1-19, 2019.
- [23] Enlu Lin, Qiong Chen και Xiaoming Qi. *Deep Reinforcement Learning for Imbalanced Classification*. *CoRR*, α6σ/1901.01379, 2019.
- [24] Alex Krizhevsky, Geoffrey Hinton και others. *Learning multiple layers of features from tiny images*. 2009.
- [25] Li Deng. *The mnist database of handwritten digit images for machine learning research*. *IEEE Signal Processing Magazine*, 29(6):141-142, 2012.

Συντομογραφίες - Αρκτικόλεξα - Ακρωνύμια

βλ	βλέπε
κλπ	και λοιπά
κ.ο.κ.	και ούτω καθεξής
κ.σ.	και συγγραφείς
ΤΑ	Τεχνική Ανάλυση

Απόδοση ξενόγλωσσων όρων

Απόδοση

μηχανική μάθηση
επιβλεπόμενη μάθηση
μη επιβλεπόμενη μάθηση
μερικώς επιβλεπόμενη μάθηση
ενισχυτική μάθηση
βαθιά μηχανική μάθηση
συνάρτηση ενεργοποίησης
συνάρτηση απωλειών
βελτιστοποιητής
τεχνική ανάλυση
Γραμμιανός Γωνιακός Χώρος
Συνελικτικό δίκτυο
Αναδρομικό δίκτυο

Ξενόγλωσσος όρος

machine learning
supervised learning
unsupervised learning
semi-supervised learning
reinforcement learning
deep learning
activation function
loss function
optimizer
technical analysis
Gramian Angular Field
Convolutional Network
Recurrent Network

