



**ΠΑΝΕΠΙΣΤΗΜΙΟ ΠΕΙΡΑΙΩΣ**  
**ΣΧΟΛΗ ΤΕΧΝΟΛΟΓΙΩΝ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΕΠΙΚΟΙΝΩΝΙΩΝ**  
**ΤΜΗΜΑ ΨΗΦΙΑΚΩΝ ΣΥΣΤΗΜΑΤΩΝ**

**ΠΡΟΓΡΑΜΜΑ ΜΕΤΑΠΤΥΧΙΑΚΩΝ ΣΠΟΥΔΩΝ**  
**“ΠΛΗΡΟΦΟΡΙΑΚΑ ΣΥΣΤΗΜΑΤΑ & ΥΠΗΡΕΣΙΕΣ”**

**Τίτλος Μεταπτυχιακής Διπλωματικής Εργασίας:**

*«Μελέτη οικονομικών στοιχείων για την πρόβλεψη  
συμπεριφοράς τους στη σύγχρονη οικονομική  
πραγματικότητα με χρήση τεχνητών νευρωνικών δικτύων»*  
*«Study of financial data to predict their behavior in modern  
economic reality using artificial neural networks»*

Από: Ξενάκη Κωνσταντίνο ΜΕ2051

Υποβάλλεται  
για την εκπλήρωση των προϋποθέσεων λήψης  
Μεταπτυχιακού Διπλώματος  
στην ειδίκευση «ΜΔΑ/ΠΠΣ/ΠΔ»  
του ΠΜΣ “Πληροφορικά Συστήματα & Υπηρεσίες”  
στο  
ΠΑΝΕΠΙΣΤΗΜΙΟ ΠΕΙΡΑΙΩΣ  
Φεβρουάριος 2024

Επιβλέπων: Καθηγητής Δρ. Φιλιππάκης Μιχαήλ  
Ακαδημαϊκή Θέση: Πρόεδρος Τμήματος Ψηφιακών Συστημάτων

Πανεπιστήμιο Πειραιώς. Κάτοχος όλων των δικαιωμάτων  
University of Piraeus,. All rights reserved.

Συγγραφέας Ξενάκης Κωνσταντίνος

## ΣΕΛΙΔΑ ΕΓΚΥΡΟΤΗΤΑΣ

**Όνοματεπώνυμο Φοιτητή:** Ξενάκης Κωνσταντίνος

**Τίτλος Μεταπτυχιακής Διπλωματικής Εργασίας:** Μελέτη οικονομικών στοιχείων για την πρόβλεψη συμπεριφοράς τους στη σύγχρονη οικονομική πραγματικότητα με χρήση τεχνητών νευρωνικών δικτύων

Η παρούσα Μεταπτυχιακή Διπλωματική Εργασία υποβάλλεται ως μερική εκπλήρωση των απαιτήσεων του Προγράμματος Μεταπτυχιακών Σπουδών "Πληροφορικά Συστήματα & Υπηρεσίες" του Τμήματος Ψηφιακών Συστημάτων του Πανεπιστημίου Πειραιώς και εγκρίθηκε στις 29/02/2024 [ημερομηνία έγκρισης] από τα μέλη της Εξεταστικής Επιτροπής.

### Εξεταστική Επιτροπή

Επιβλέπων (Τμήμα Ψηφιακών Συστημάτων, Πανεπιστήμιο Πειραιώς):  
Φιλιππάκης Μιχαήλ, Καθηγητής

Μέλος Εξεταστικής Επιτροπής: Πρέντζα Ανδριάννα, Καθηγήτρια

### ΥΠΕΥΘΥΝΗ ΔΗΛΩΣΗ ΑΥΘΕΝΤΙΚΟΤΗΤΑΣ

Ο Ξενάκης Κωνσταντίνος, γνωρίζοντας τις συνέπειες της λογοκλοπής, δηλώνω υπεύθυνα ότι η παρούσα εργασία με τίτλο «Μελέτη οικονομικών στοιχείων για την πρόβλεψη συμπεριφοράς τους στη σύγχρονη οικονομική πραγματικότητα με χρήση τεχνητών νευρωνικών δικτύων», αποτελεί προϊόν αυστηρά προσωπικής εργασίας και όλες οι πηγές που έχω χρησιμοποιήσει, έχουν δηλωθεί κατάλληλα στις βιβλιογραφικές παραπομπές και αναφορές. Τα σημεία όπου έχω χρησιμοποιήσει ιδέες, κείμενο ή/και πηγές άλλων συγγραφέων, αναφέρονται ευδιάκριτα στο κείμενο με την κατάλληλη παραπομπή και η σχετική αναφορά περιλαμβάνεται στο τμήμα των βιβλιογραφικών αναφορών με πλήρη περιγραφή.

Επιπλέον δηλώνω υπεύθυνα ότι η συγκεκριμένη Μεταπτυχιακή Διπλωματική Εργασία έχει συγγραφεί από εμένα προσωπικά και δεν έχει υποβληθεί ούτε έχει αξιολογηθεί στο πλαίσιο κάποιου άλλου μεταπτυχιακού ή προπτυχιακού τίτλου σπουδών, στην Ελλάδα ή στο εξωτερικό.

Παράβαση της ανωτέρω ακαδημαϊκής μου ευθύνης αποτελεί ουσιώδη λόγο για την ανάκληση του πτυχίου μου. Σε κάθε περίπτωση, αναληθούς ή ανακριβούς δηλώσεως, υπόκειμαι στις συνέπειες που προβλέπονται τις διατάξεις που προβλέπει η Ελληνική και Κοινοτική Νομοθεσία περί πνευματικής ιδιοκτησίας.

### Ο ΔΗΛΩΝ

**Όνοματεπώνυμο:** Ξενάκης Κωνσταντίνος

**Αριθμός Μητρώου:** ME2051

**Υπογραφή:**



## Ευχαριστίες

Θα ήθελα να ευχαριστήσω τον επιβλέποντα καθηγητή μου, κ. Μιχάλη Φιλιππάκη, που με εμπιστεύτηκε και μου έδωσε την ευκαιρία να εκπονήσω αυτή τη διατριβή. Η καθοδήγηση, η υπομονή και η υποστήριξή του έπαιξαν καθοριστικό ρόλο στο να με βοηθήσει να ολοκληρώσω την έρευνα που ανέλαβα για να καλύψω τις ανάγκες της διατριβής.

Θερμές ευχαριστίες στη σύζυγο μου για την κατανόηση που επέδειξε και την υποστήριξη που μου παρείχε στη διάρκεια του διδακτικού κύκλου του μεταπτυχιακού μου και κατά τη διάρκεια της υλοποίησης της παρούσας διπλωματικής εργασίας.

## Περίληψη

Η σωστή πρόβλεψη των κινήσεων των τιμών στα χρηματιστήρια έχει προφανή οικονομικά οφέλη. Η εργασία επιλύεται παραδοσιακά με την ανάλυση της υποκείμενης εταιρείας ή της ιστορικής εξέλιξης των τιμών της μετοχής της εταιρείας. Μια τρίτη επιλογή που βρίσκεται υπό ενεργό έρευνα είναι η δημιουργία ενός προγνωστικού μοντέλου της μετοχής χρησιμοποιώντας μηχανική μάθηση. Η παρούσα διατριβή ακολουθεί την τελευταία προσέγγιση, στην οποία παρουσιάζεται ένας αλγόριθμος μηχανικής μάθησης με δεδομένα ιστορικού αποθέματος. Ο αλγόριθμος χρησιμοποιεί αυτές τις πληροφορίες για να εκπαιδεύσει ένα μοντέλο που αναμένεται να συνάγει μελλοντικές τιμές με βάση τις πρόσφατες πληροφορίες τιμών. Η μηχανική μάθηση είναι ένα μεγάλο πεδίο στην επιστήμη των υπολογιστών και βρίσκεται υπό συνεχή ανάπτυξη. Οι ανακαλύψεις σε μια οικογένεια μοντέλων μηχανικής μάθησης γνωστών ως τεχνητά νευρωνικά δίκτυα έχουν προκαλέσει αυξημένο ενδιαφέρον για αυτά τα μοντέλα, συμπεριλαμβανομένης της εφαρμογής τους για οικονομική πρόβλεψη. Με μια πληθώρα διαθέσιμων μοντέλων, η επιλογή μεταξύ τους είναι δύσκολη, ειδικά λαμβάνοντας υπόψη τη συνεχή ροή των αναδυόμενων μοντέλων και των τεχνικών εκμάθησης. Αρχικά, στο πρώτο κεφάλαιο παρουσιάζεται η έννοια της μηχανικής μάθησης και τα είδη αυτής. Στο δεύτερο κεφάλαιο της εργασίας αναλύεται η έννοια του χρηματιστηρίου. Οι κανόνες που το διέπουν, τα στοιχεία τα οποία είναι απαραίτητα να είναι γνωστά έτσι ώστε να υπάρχει πλήρης κατανόηση της δημιουργίας των μοντέλων πρόβλεψης. Εν συνεχεία, το τρίτο κεφάλαιο αφιερώθηκε στην ανάλυση του ορισμού της πρόβλεψης και των αρχών που την διέπουν. Παρουσιάζονται οι βασικότερες μέθοδοι πρόβλεψης και τέλος εξετάζονται τα μέτρα αξιολόγησης και τα ενδεχόμενα σφάλματα. Στο τέταρτο κεφάλαιο προσεγγίζονται οι κυριότερες χρονοσειρές που σε συνδυασμό με το επιλεγμένο προβλεπτικό μοντέλο θα συγκροτήσουν τον αλγόριθμο ώστε να στηθεί το νευρωνικό δίκτυο για την πρόβλεψη της τιμής μιας μετοχής. Στο πέμπτο κεφάλαιο γίνεται θεωρητική εισαγωγή στα νευρωνικά δίκτυα, παρουσιάζεται η αρχιτεκτονική τους και αναλύονται τα βασικότερα νευρωνικά τεχνητά δίκτυα. Τέλος, στο έκτο κεφάλαιο θα γίνει ο πειραματικός έλεγχος με τη χρήση κατάλληλων λογισμικών και κλείνοντας θα γίνει η συμπερασματική προσέγγιση των αποτελεσμάτων.

## Abstract

The economic benefits of accurately predicting price movements in the stock market are obvious. This task has traditionally been solved by analyzing the underlying companies and their historical share prices. A third option is to build a stock price forecasting model using machine learning. Following the latter approach, this paper presents a machine learning algorithm that uses historical stock price data. The algorithm uses this information to train a model that infer future stock prices based on recent stock price information. Machine learning is an important branch of computer science and is in constant development. Dramatic advances in the class of machine learning models known as artificial neural networks have led to increased interest in such models, including their application to financial forecasting. With so many models available, it is difficult to choose among them, especially given that new models and learning techniques are constantly emerging. Initially, the first chapter presents the concept of machine learning and its types. In the second chapter of the paper, the concept of the stock market is analyzed. The rules that govern it, the elements that are necessary to be known so that there is a full understanding of the creation of the forecasting models. Subsequently, the third chapter was devoted to the analysis of the definition of forecasting and the principles governing it. The most basic forecasting methods are presented and finally the evaluation measures and possible errors are examined. In the fourth chapter, the main time series are approached which, in combination with the selected predictive model, will constitute the algorithm to set up the neural network for predicting the price of a share. In the fifth chapter, a theoretical introduction to neural networks is given, their architecture is presented and the most basic neural artificial networks are analyzed. Finally, in the sixth chapter, the experimental control will be done with the use of appropriate software and, closing, the conclusive approach to the results will be made.

## Πίνακας Περιεχομένων

<b>Ευχαριστίες</b> .....	<b>3</b>
<b>Περίληψη</b> .....	<b>4</b>
<b>Abstract</b> .....	<b>5</b>
<b>Πίνακας Εικόνων</b> .....	<b>8</b>
<b>Εισαγωγή</b> .....	<b>10</b>
<b>Σκοπός - Στόχοι - Εργαλεία</b> .....	<b>11</b>
<b>Δομή της Εργασίας</b> .....	<b>12</b>
<b>Κεφάλαιο 1</b> .....	<b>13</b>
<b>1. Μηχανική Μάθηση</b> .....	<b>13</b>
1.1. Εισαγωγή στη Μηχανική Μάθηση .....	13
1.2. Είδη Μηχανικής Μάθησης .....	14
1.2.1. Επιβλεπόμενη (supervised) μάθηση.....	14
1.2.2. Μη-επιβλεπόμενη (unsupervised) μάθηση .....	16
1.2.3. Ενισχυτική μάθηση (reinforcement learning).....	17
<b>Κεφάλαιο 2</b> .....	<b>18</b>
<b>2. Χρηματιστήριο και Μετοχές</b> .....	<b>18</b>
2.1. Απόδοση Μετοχής.....	19
2.2. Κίνδυνος .....	21
2.2.1. Πηγές του κινδύνου .....	21
2.2.2. Κίνδυνος επιτοκίων (interest rate risk).....	21
2.2.3. Κίνδυνος πληθωρισμού ή κίνδυνος αγοραστικής δύναμης (inflation risk or purchasing power risk) .....	21
2.2.4. Κίνδυνος αγοράς (market risk) .....	21
2.2.5. Επιχειρηματικός κίνδυνος (business risk).....	22
2.2.6. Χρηματοοικονομικός κίνδυνος (financial risk).....	22
2.2.7. Κίνδυνος ρευστότητας (liquidity risk) .....	22
2.2.8. Συναλλαγματικός κίνδυνος (exchange rate risk or currency risk) .....	22
2.2.9. Πολιτικός κίνδυνος (country risk or political risk).....	22
2.2.10. Συστηματικός και μη συστηματικός κίνδυνος .....	22
2.3. Μέτρηση Κινδύνου .....	23
2.4. Διαχείριση Κινδύνου.....	24
<b>Κεφάλαιο 3</b> .....	<b>26</b>
<b>3. Βασικές Έννοιες Πρόβλεψης</b> .....	<b>26</b>
3.1. Τί είναι πρόβλεψη .....	26
3.2. Αρχές Προβλέψεων .....	28
3.3. Μέθοδοι Πρόβλεψης.....	29
3.3.1. Λευκός Θόρυβος (White Noise).....	29
3.3.2. Τυχαίος Περίπατος (Random Walk).....	29
3.3.3. Μέθοδοι Πρόβλεψης με Κινητούς Μέσους (Moving Average) .....	31
3.3.4. Μέθοδος Απλής Εκθετικής Εξομάλυνσης (Exponential Smoothing Method).....	31
3.3.5. Εκθετική Εξομάλυνση με Προσαρμογή στην Τάση - Μέθοδος_Holt.....	32
3.3.6. Εκθετική Εξομάλυνση με προσαρμογή στην τάση και στην εποχικότητα – Μέθοδος Winters	33

3.3.7.	Μοντέλα για Στάσιμες Χρονοσειρές .....	35
3.3.8.	Μοντέλα για Μη Στάσιμες Χρονοσειρές.....	37
3.4.	Αιτιακές Μέθοδοι Πρόβλεψης (Casual Forecasting Methods).....	41
3.4.1.	Απλή Γραμμική Παλινδρόμηση (Simple Linear Regression) .....	41
3.4.2.	Πολλαπλή Γραμμική Παλινδρόμηση.....	43
3.5.	Επιλογή Μεθόδου Πρόβλεψης.....	44
3.6.	Μέτρα Αξιολόγησης Προβλέψεων .....	45
3.7.	Σφάλματα κατά την Πρόβλεψη .....	45
<b>Κεφάλαιο 4.....</b>		<b>48</b>
<b>4. Ανάλυση Χρονολογικών Σειρών .....</b>		<b>48</b>
4.1.	Ορισμός Χρονοσειρών (Time Series) .....	48
4.2.	Κατηγορίες Χρονοσειρών .....	48
4.3.	Συνιστώσες Χρονοσειράς.....	49
4.4.	Τύποι Χρονολογικών Σειρών .....	51
4.4.1.	Παλινδρόμηση .....	51
4.4.2.	Arima Models (στασιμότητα, συντελεστής αυτοσυσχέτισης) .....	52
4.4.3.	Μέθοδος Box Jenkins.....	53
4.5.	Σφάλμα Πρόβλεψης .....	54
<b>Κεφάλαιο 5.....</b>		<b>62</b>
<b>5. Τεχνητά Νευρωνικά Δίκτυα.....</b>		<b>62</b>
5.1.	Περιγραφή των νευρωνικών δικτύων .....	62
5.2.	Βιολογικά νευρωνικά δίκτυα.....	62
5.3.	Μοντέλο του τεχνητού νευρωνικού δικτύου .....	63
5.4.	Αρχιτεκτονική Νευρωνικών Δικτύων.....	64
5.5.	Βασικά Νευρωνικά Δίκτυα .....	68
5.5.1.	Πολυεπίπεδος Perception (Multilayer Perceptron - MLP).....	68
5.5.2.	Επαναλαμβανόμενα Νευρωνικά Δίκτυα (Recurrent Neural Networks-RNN).....	69
5.5.3.	Μακράς Βραχυχρόνιας Μνήμης Νευρωνικά Δίκτυα (Long Short-Term Memory - LSMT) .....	70
5.5.4.	Φραγμένα Επαναλαμβανόμενα Νευρωνικά Δίκτυα (Gated Recurrent Units -GRUs) .....	71
5.6.	Διαδικασία μάθησης ενός τεχνητού νευρωνικού δικτύου.....	72
<b>Κεφάλαιο 6.....</b>		<b>74</b>
<b>6. Υλοποίηση του θέματος της εργασίας .....</b>		<b>74</b>
6.1.	Πηγή Δεδομένων (Dataset) .....	74
6.2.	Βήματα μελέτης.....	75
6.3.	Συλλογή Δεδομένων και Οπτικοποίηση .....	75
6.4.	Επεξεργασία των Δεδομένων – Εκπαίδευση (Train) και Έλεγχος (Test).....	77
6.5.	Δημιουργία Στατικού Μοντέλου LSTM.....	79
6.5.1.	API Keras .....	79
6.6.	Πρόβλεψη των test δεδομένων και διαγραμματική απεικόνιση των αποτελεσμάτων .....	82
6.7.	Πρόβλεψη των μελλοντικών 30 ημερών και διαγραμματική απεικόνιση των αποτελεσμάτων .....	84
6.8.	Σύνοψη Αποτελεσμάτων .....	86
<b>Βιβλιογραφία.....</b>		<b>87</b>



## Πίνακας Εικόνων

Εικόνα 1 Εφαρμογές.....	11
Εικόνα 2 Είδη Μηχανικής Μάθησης .....	14
Εικόνα 3 Classification – Regression.....	15
Εικόνα 4 Τυχαίος Περίπατος .....	30
Εικόνα 5 Συνάρτηση Συντελεστή Αυτοσυσχέτισης Τυχαίου Περίπατου .....	30
Εικόνα 6 AR(1) με coefficient 0.1 .....	36
Εικόνα 7 AR(1) με coefficient 0.9 .....	36
Εικόνα 8 MA(1) με coefficient 0.9 .....	37
Εικόνα 9 Ευθεία Ελαχίστων Τετραγώνων.....	43
Εικόνα 10 Μηνιαία απεικόνιση από το 1958 έως το 2010 του CO2 στην πόλη Mauna Loa της Χαβάη .....	49
Εικόνα 11 MAE Python code .....	57
Εικόνα 12 MSE Python code.....	58
Εικόνα 13 RMSE Python code.....	58
Εικόνα 14 MAPE Python code .....	59
Εικόνα 15 SMAPE Python code.....	60
Εικόνα 16 MASE Python code.....	61
Εικόνα 17 Μη γραμμικό μοντέλο νευρώνων.....	64
Εικόνα 18 Δίκτυο εμπρός τροφοδότησης ενός επιπέδου .....	65
Εικόνα 19 Δίκτυο εμπρός τροφοδότησης ενός κρυφού επιπέδου και ενός επιπέδου εξόδου .....	66
Εικόνα 20 Δίκτυο με ανατροφοδότηση.....	67
Εικόνα 21 Αρχιτεκτονική MLP .....	68
Εικόνα 22 Απεικόνιση κελιού μνήμης .....	70
Εικόνα 23 Αρχική ημερομηνία δεδομένων μετοχής Apple .....	74
Εικόνα 24 Τελική ημερομηνία δεδομένων μετοχής Apple.....	74
Εικόνα 25 Αρχική ημερομηνία δεδομένων μετοχής Google .....	74
Εικόνα 26 Τελική ημερομηνία δεδομένων μετοχής Google .....	74
Εικόνα 27 Πλήθος τιμών κλεισίματος για τη μετοχή της Apple .....	75
Εικόνα 28 Πλήθος τιμών κλεισίματος για τη μετοχή της Google .....	75
Εικόνα 29 Η διαγραμματική απεικόνιση της τιμής κλεισίματος της μετοχής της Apple συναρτήσει των εγγραφών εμφάνισης στην περίοδο της πενταετίας .....	76
Εικόνα 30 Η διαγραμματική απεικόνιση της τιμής κλεισίματος της μετοχής της Google συναρτήσει των εγγραφών εμφάνισης στην περίοδο της πενταετίας .....	76
Εικόνα 31 Κανονικοποίηση των δεδομένων της μετοχής της Apple με χρήση της sklearn .....	77
Εικόνα 32 Διαχωρισμός δεδομένων σε Train Dataset και Test Dataset .....	78
Εικόνα 33 Data Preprocessing .....	78
Εικόνα 34 LSTM Stacked Model .....	81
Εικόνα 35 Γραφική Αναπαράσταση των πραγματικών τιμών με γαλάζιο και των προβλέψεων με πορτοκαλί για σύνολο των δεδομένων εκπαίδευσης ( $y_{train}$ ) και με πράσινο για το σύνολο των δεδομένων ελέγχου ( $y_{test}$ ) για τη μετοχή της Apple ..	82

Εικόνα 36 Γραφική Αναπαράσταση των πραγματικών τιμών με γαλάζιο και των προβλέψεων με πορτοκαλί για σύνολο των δεδομένων εκπαίδευσης ( $y_{train}$ ) και με πράσινο για το σύνολο των δεδομένων ελέγχου ( $y_{test}$ ) για τη μετοχή της Google	83
Εικόνα 37 Κώδικας για την πρόβλεψη μελλοντικών τιμών μετοχής για διάστημα 30 ημερών .....	84
Εικόνα 38 Διάγραμμα μετοχής Apple $test\_data$ και 30 νέων τιμών .....	85
Εικόνα 39 Διάγραμμα μετοχής Google $test\_data$ και 30 νέων τιμών .....	85
Εικόνα 40 Ενοποιημένο διάγραμμα Apple με το σύνολο δεδομένων και 30 νέων τιμών .....	86
Εικόνα 41 Ενοποιημένο διάγραμμα Google με το σύνολο δεδομένων και 30 νέων τιμών .....	86

## Εισαγωγή

Στην οικονομία τα τεχνητά νευρωνικά δίκτυα έχουν μεγάλη χρησιμότητα, προσφέροντας λύσεις σε σοβαρά ζητήματα προσφέροντας ισχυρά εργαλεία για ανάλυση, πρόβλεψη και λήψη αποφάσεων. Ακολουθεί μια ανάλυση των βασικών εφαρμογών τους:

**Αλγοριθμική διαπραγμάτευση:** Αναλύοντας τεράστιες ποσότητες δεδομένων της αγοράς, συμπεριλαμβανομένων των γραφημάτων, των ειδήσεων και του συναισθήματος των μέσων κοινωνικής δικτύωσης, τα νευρωνικά δίκτυα μπορούν να εντοπίσουν διακριτικά μοτίβα που μπορεί να ξεφεύγουν από τους παραδοσιακούς αλγόριθμους. Αυτό βοηθά τους επιχειρηματίες/επενδυτές να λαμβάνουν πιο ενημερωμένες αποφάσεις σχετικά με την αγορά και την πώληση.

**Ανίχνευση απάτης:** Τα νευρωνικά δίκτυα μπορούν να μάθουν την «κανονική» συμπεριφορά των οικονομικών συναλλαγών και να επισημάνουν ύποπτη δραστηριότητα που μπορεί να υποδηλώνει απάτη. Αυτό βοηθά τα χρηματοπιστωτικά ιδρύματα να προστατεύουν τον εαυτό τους και τους πελάτες τους.

**Πιστωτική βαθμολογία:** Αναλύοντας το οικονομικό ιστορικό ενός δανειολήπτη και άλλα σημεία δεδομένων, τα νευρωνικά δίκτυα μπορούν να αξιολογήσουν την πιστοληπτική τους ικανότητα με μεγαλύτερη ακρίβεια από τις παραδοσιακές μεθόδους. Αυτό επιτρέπει στους δανειστές να λαμβάνουν πιο δίκαιες και πιο κερδοφόρες αποφάσεις δανεισμού.

Μπορούν να βοηθήσουν στη βελτιστοποίηση αποφάσεων:

**Ποσοτική επένδυση:** Τα νευρωνικά δίκτυα μπορούν να χρησιμοποιηθούν για την ανάπτυξη ποσοτικών επενδυτικών στρατηγικών που εκμεταλλεύονται τις ανεπαίσθητες αναποτελεσματικότητες της αγοράς. Αυτές οι στρατηγικές μπορεί να είναι ιδιαίτερα κερδοφόρες, αλλά απαιτούν προσεκτικό σχεδιασμό και εφαρμογή.

**Διαχείριση Κινδύνων:** Αναλύοντας διάφορους παράγοντες, τα νευρωνικά δίκτυα μπορούν να βοηθήσουν τα χρηματοπιστωτικά ιδρύματα να αξιολογήσουν και να διαχειριστούν τη συνολική τους έκθεση σε κίνδυνο. Αυτό τους επιτρέπει να λαμβάνουν καλύτερες αποφάσεις σχετικά με την κατανομή κεφαλαίων και την προστασία των περιουσιακών τους στοιχείων.

**Βελτιστοποίηση χαρτοφυλακίου:** Τα νευρωνικά δίκτυα μπορούν να βοηθήσουν τους επενδυτές να δημιουργήσουν χαρτοφυλάκια που είναι βελτιστοποιημένα για τους ατομικούς στόχους ανοχής κινδύνου και απόδοσης. Αυτό μπορεί να οδηγήσει σε καλύτερες μακροπρόθεσμες επενδυτικές επιδόσεις.

Οπωσδήποτε τα νευρωνικά δίκτυα για να αποδώσουν με τον βέλτιστο τρόπο απαιτούν δεδομένα υψηλής ποιότητας, προσεκτική εκπαίδευση και συνεχή παρακολούθηση. Η επεξήγηση μπορεί να είναι μια πρόκληση. Σε αντίθεση με τα παραδοσιακά μοντέλα, μπορεί να είναι δύσκολο να κατανοήσουμε πώς ένα νευρωνικό δίκτυο καταλήγει στα συμπεράσματά του. Αυτό μπορεί να δυσκολέψει την εμπιστοσύνη των αποτελεσμάτων τους. Φυσικά καθώς τα νευρωνικά δίκτυα χρησιμοποιούνται ευρύτερα στη χρηματοδότηση, οι ρυθμιστικές αρχές εξακολουθούν να αναπτύσσουν πλαίσια για την επίβλεψή τους.

Συνολικά, τα νευρωνικά δίκτυα είναι ένα ισχυρό εργαλείο για τη χρηματοδότηση με τη δυνατότητα να φέρει επανάσταση στον κλάδο. Ωστόσο, είναι σημαντικό να χρησιμοποιούνται υπεύθυνα και να υπάρχει επίγνωση των περιορισμών τους.

## Σκοπός - Στόχοι - Εργαλεία

Στόχος της παρούσας εργασίας είναι η πρόβλεψη της απόδοσης εισηγμένης μετοχής χρηματιστηρίου με την βοήθεια αλγορίθμων μηχανικής μάθησης και συγκεκριμένα με χρήση τεχνητών νευρωνικών δικτύων καθώς επίσης και με χρήση χρονοσειρών. Η υλοποίηση θα γίνει με χρήση Python σε IDE Jupiter και τη γλώσσα στατιστικού προγραμματισμού R στην πλατφόρμα R Studio version 4.3.2.



Εικόνα 1 Εφαρμογές

## Δομή της Εργασίας

Γενική μεθοδολογική προσέγγιση και Φάσεις υλοποίησης εργασίας

Στην παρούσα εργασία έγινε αξιολόγηση της απόδοσης των τεχνητών νευρωνικών δικτύων για την πρόβλεψη τιμών μετοχής σε διαφορετικές χρονικές στιγμές. Η εργασία υλοποιήθηκε προγραμματιστικά σε περιβάλλον Python και σε R. Μετά την εκπαίδευση των δικτύων πραγματοποιήθηκαν προβλέψεις τα αποτελέσματα των οποίων σχολιάστηκαν, ως προς την εγκυρότητα τους ενώ παράλληλα έγινε ερμηνεία των προβλέψεων και της συσχέτισής τους με διάφορες παραμέτρους. Οι προβλέψεις αξιολογούνται ως προς την εγκυρότητά τους, συγκρίνονται μεταξύ τους και εξάγονται συμπεράσματα για την ποιότητα τους και την ικανότητα των νευρωνικών δικτύων του κάθε σεναρίου στην εκμάθησή των χαρακτηριστικών των χρονοσειρών. Παρακάτω ακολουθούν οι φάσεις υλοποίησης της εργασίας:

**1η Φάση:** Ανάθεση Διπλωματικής Εργασίας

Συζητήθηκαν οι δυνατότητες και η υλοποίηση μιας μεταπτυχιακής διατριβής, λαμβάνοντας υπόψη τα διαθέσιμα ιστορικά δεδομένα, το πλαίσιο της αναζήτησης περαιτέρω γνώσης, τη σκοπιμότητα του θέματος της διατριβής, την υλοποίηση του προγράμματος και το χρονικό πλαίσιο της διατριβής.

**2η Φάση:** Αναζήτηση για τη διάρθρωση της έρευνας

Αναζήτηση στο διαδίκτυο για τη διάρθρωση των κεφαλαίων από τα οποία θα αποτελείται η διπλωματική εργασία. Χωρίστηκαν σε δύο ενότητες, θεωρητικό επίπεδο για την περιγραφή και κατανόηση των όρων και σε πρακτικό επίπεδο όπου είναι η χρήση των νευρωνικών δικτύων και τα αποτελέσματα.

**3η Φάση:** Συλλογή δεδομένων

Από το διαδίκτυο συγκεντρώθηκαν από ελληνική και ξενόγλωσση αρθρογραφία και repositories οι ορισμοί και η ανάλυση των όρων, των μεγεθών, των χρονοσειρών, των προβλεπτικών μοντέλων και των νευρωνικών δικτύων. Έγινε επιλογή της πηγής δεδομένων της μετοχής προς εξέταση και ελέγχθηκαν τα προγραμματιστικά μοντέλα.

**4η Φάση:** Προετοιμασία των δεδομένων για την είσοδο τους στο προγραμματιστικό περιβάλλον.

Έγινε καθαρισμός, τυποποίηση και κανονικοποίηση των δεδομένων (αφαίρεση τιμών null, scaling, normalization)

**5η Φάση:** Επιλογή κατάλληλων νευρωνικών δικτύων στην Python και στατιστικών λειτουργιών στην R για την πραγματοποίηση της πρόβλεψης.

**6η Φάση:** Συγγραφή κώδικα.

**7η Φάση:** Σχολιασμός και σύγκριση των αποτελεσμάτων και των προβλέψεων.

Για κάθε σενάριο, πραγματοποιήθηκε ενδελεχής ανάλυση των αποτελεσμάτων της εκπαίδευσης του νευρωνικού δικτύου, ακολουθούμενη από σχολιασμό των παραγόμενων προβλέψεων και σύγκριση μεταξύ τους.

## Κεφάλαιο 1

### 1. Μηχανική Μάθηση

#### 1.1. Εισαγωγή στη Μηχανική Μάθηση

Μηχανική μάθηση (machine learning) ονομάζεται το πεδίο της επιστήμης των υπολογιστών που μελετά τη δημιουργία αλγορίθμων (αλγόριθμο ονομάζουμε ένα σύνολο εντολών που καθορίζουν μια διεργασία η οποία έχει φτιαχτεί με σκοπό την επίλυση ενός προβλήματος ή τη διεξαγωγή μιας υπολογιστικής διεργασίας) οι οποίοι «μαθαίνουν» χωρίς να έχουν προγραμματιστεί με συγκεκριμένους κανόνες. Με άλλα λόγια, οι αλγόριθμοι αυτοί χρησιμοποιούν δεδομένα με σκοπό να ανακαλύψουν μοτίβα και σχέσεις ώστε να κάνουν προβλέψεις ή να πάρουν αποφάσεις. Αναφορές στη μηχανική μάθηση υπάρχουν από τη δεκαετία του 1960 όμως η χρήση των τεχνικών αυτών αυξήθηκε ραγδαία μετά τη δεκαετία του 1990 ως αποτέλεσμα της ανάπτυξης κλάδων της επιστήμης υπολογιστών όπως είναι η ψηφιοποίηση αρχείων, η εξόρυξη δεδομένων και οι υπερυπολογιστές. [1]

Για τον όρο Μηχανική Μάθηση έχουν διατυπωθεί διάφοροι ορισμοί ανά τα χρόνια, όπως:

«Η μελέτη υπολογιστικών μεθόδων για την απόκτηση νέας γνώσης, νέων δεξιοτήτων και νέων τρόπων οργάνωσης της υπάρχουσας γνώσης.» - Carbonell (1987)

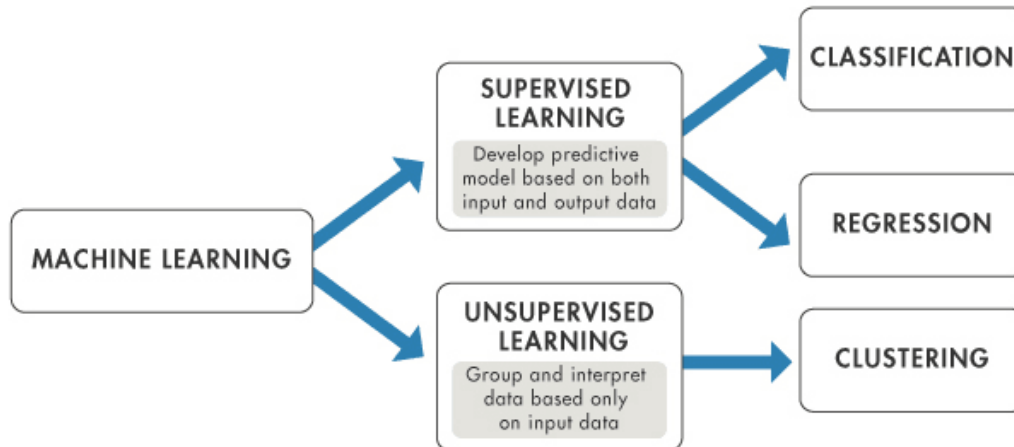
«Ένα πρόγραμμα υπολογιστή θεωρείται ότι μαθαίνει από την εμπειρία E σε σχέση με μια κατηγορία εργασιών T και μια μετρική απόδοσης P, αν η απόδοση του σε εργασίες της T, όπως μετριούνται από την P, βελτιώνονται με την εμπειρία E.» - Mitchell (1997)

«Κάτι μαθαίνει όταν αλλάζει τη συμπεριφορά του κατά τέτοιο τρόπο ώστε να αποδίδει καλύτερα στο μέλλον.» - Witten & Frank (2000)

Η Μηχανική Μάθηση ανήκει στον κλάδο της Τεχνητής Νοημοσύνης και δίνει την δυνατότητα στον άνθρωπο να επιλύσει πολύπλοκα προβλήματα με την βοήθεια αλγορίθμων και υπολογιστών, που σε άλλη περίπτωση θα ήταν δύσκολο. Ουσιαστικά η Μηχανική Μάθηση ασχολείται με τη μελέτη αλγορίθμων που βελτιώνουν τη συμπεριφορά τους σε κάποια εργασία που τους έχει ανατεθεί χρησιμοποιώντας την εμπειρία τους, σ' ένα υπολογιστικό σύστημα. Τέλος, η μηχανική μάθηση μπορεί να θεωρηθεί ως «η αναζήτηση σε ένα χώρο πιθανών υποθέσεων, εκείνης της υπόθεσης που ταιριάζει κατά τον καλύτερο τρόπο στα υπό εξέταση δεδομένα και στην πιθανώς προϋπάρχουσα γνώση». [2], [3], [4]

## 1.2. Είδη Μηχανικής Μάθησης

Η Μηχανική Μάθηση διακρίνεται σε τρεις κατηγορίες ως προς την εκπαίδευση των αλγορίθμων, που μοιάζουν με τον τρόπο που μαθαίνει ο άνθρωπος. Οι κατηγορίες είναι η επιβλεπόμενη μάθηση, η μη επιβλεπόμενη και η ενισχυτική μάθηση. [1]



Εικόνα 2 Είδη Μηχανικής Μάθησης

### 1.2.1. Επιβλεπόμενη (supervised) μάθηση

Η εποπτευόμενη μηχανική εκμάθηση μαθαίνει μοτίβα και σχέσεις μεταξύ δεδομένων εισόδου και εξόδου. Ορίζεται από τη χρήση επισημασμένων δεδομένων. Τα δεδομένα με ετικέτα είναι ένα σύνολο δεδομένων που περιέχει πολλά παραδείγματα Χαρακτηριστικών και Στόχων. Η εποπτευόμενη μάθηση χρησιμοποιεί αλγόριθμους που μαθαίνουν τη σχέση των Χαρακτηριστικών και του Στόχου από το σύνολο δεδομένων. Αυτή η διαδικασία αναφέρεται ως Εκπαίδευση ή Εφαρμογή.

Υπάρχουν δύο τύποι εποπτευόμενων αλγορίθμων μάθησης:

#### Ταξινόμηση (Classification)

Η ταξινόμηση είναι ένας τύπος εποπτευόμενης μηχανικής εκμάθησης όπου οι αλγόριθμοι μαθαίνουν από τα δεδομένα για να προβλέψουν ένα αποτέλεσμα ή ένα συμβάν στο μέλλον. Για παράδειγμα:

Μια τράπεζα μπορεί να έχει ένα σύνολο δεδομένων πελατών που περιέχει πιστωτικό ιστορικό, δάνεια, λεπτομέρειες επενδύσεων κ.λπ. και μπορεί να θέλει να μάθει εάν κάποιος πελάτης θα αθετήσει. Στα ιστορικά δεδομένα, θα έχουμε Χαρακτηριστικά και Στόχο.


Τα χαρακτηριστικά θα είναι χαρακτηριστικά ενός πελάτη όπως το πιστωτικό ιστορικό, τα δάνεια, οι επενδύσεις κ.λπ.

Ο στόχος θα αντιπροσωπεύει εάν ένας συγκεκριμένος πελάτης έχει αθετήσει τις υποχρεώσεις του στο παρελθόν (συνήθως αντιπροσωπεύεται από 1 ή 0 / Σωστό ή Λάθος / Ναι ή Όχι.


Οι αλγόριθμοι ταξινόμησης χρησιμοποιούνται για την πρόβλεψη διακριτών αποτελεσμάτων, εάν το αποτέλεσμα μπορεί να λάβει δύο πιθανές τιμές όπως True ή False, Default ή No Default, Yes ή No, είναι γνωστό ως Binary Classification. Όταν το αποτέλεσμα περιέχει περισσότερες από δύο πιθανές τιμές, είναι γνωστό ως Ταξινόμηση πολλαπλών κλάσεων. Υπάρχουν πολλοί αλγόριθμοι μηχανικής εκμάθησης που μπορούν να χρησιμοποιηθούν για εργασίες ταξινόμησης.

Κάποιοι από αυτούς είναι:

- Logistic Regression
- Decision Tree Classifier
- K Nearest Neighbor Classifier
- Random Forest Classifier
- Neural Networks



**Classification**



**Regression**

*Εικόνα 3 Classification – Regression*

### **Παλινδρόμηση (Regression)**

Η παλινδρόμηση είναι ένας τύπος εποπτευόμενης μηχανικής εκμάθησης όπου οι αλγόριθμοι μαθαίνουν από τα δεδομένα να προβλέπουν συνεχείς τιμές όπως οι πωλήσεις, ο μισθός, το βάρος ή η θερμοκρασία. Για παράδειγμα:

Ένα σύνολο δεδομένων που περιέχει χαρακτηριστικά του σπιτιού, όπως μέγεθος οικοπέδου, αριθμός υπνοδωματίων, αριθμός λουτρών, γειτονιά κ.λπ. και η τιμή του σπιτιού, ένας αλγόριθμος παλινδρόμησης μπορεί να εκπαιδευτεί για να μάθει τη σχέση μεταξύ των χαρακτηριστικών και της τιμής του σπιτιού.

Υπάρχουν πολλοί αλγόριθμοι μηχανικής μάθησης που μπορούν να χρησιμοποιηθούν για εργασίες παλινδρόμησης. Κάποιοι από αυτούς είναι:

- Linear Regression
- Decision Tree Regressor
- K Nearest Neighbor Regressor
- Random Forest Regressor
- Neural Networks



### 1.2.2. Μη-επιβλεπόμενη (unsupervised) μάθηση

Η μάθηση χωρίς επίβλεψη είναι ένας τύπος μηχανικής μάθησης όπου ο αλγόριθμος μαθαίνει από δεδομένα χωρίς ετικέτα χωρίς προκαθορισμένες εξόδους ή μεταβλητές στόχου. Η μάθηση χωρίς επίβλεψη βρίσκει μοτίβα, ομοιότητες ή ομαδοποιήσεις μέσα στα δεδομένα για να λάβει πληροφορίες και να λάβει αποφάσεις βάσει δεδομένων. Είναι ιδιαίτερα χρήσιμο όταν έχουμε να κάνουμε με μεγάλα σύνολα δεδομένων όπου η χειροκίνητη επισήμανση θα ήταν μη πρακτική ή δαπανηρή.

Υπάρχουν τρεις τύποι μη επιβλεπόμενων αλγορίθμων μάθησης:

#### **Αλγόριθμοι Ομαδοποίησης (Clustering Algorithms)**

**K-Means Clustering:** Σε αυτόν τον αλγόριθμο, τα δεδομένα χωρίζονται σε συγκεκριμένο αριθμό ομάδων ή συστάδων. Επιτυγχάνεται ελαχιστοποιώντας τις συνολικές τετραγωνικές αποστάσεις μεταξύ των σημείων δεδομένων και των κέντρων κάθε συστάδας.

**Ιεραρχική ομαδοποίηση:** Η ιεραρχική ομαδοποίηση αναπτύσσει μια ιεραρχία συστάδων με τη συγχώνευση ή τη διάσπασή τους ανάλογα με την ομοιότητά τους.

**DBSCAN (Χωρική ομαδοποίηση εφαρμογών με θόρυβο με βάση την πυκνότητα):** Το DBSCAN προσδιορίζει τα συμπλέγματα ως πυκνές περιοχές σημείων δεδομένων που χωρίζονται από πιο αραιές περιοχές.

#### **Αλγόριθμοι Μείωσης Διαστάσεων (Dimensionality Reduction Algorithms)**

Οι τεχνικές μείωσης διαστάσεων χρησιμοποιούνται για τη μείωση του αριθμού των μεταβλητών ή των χαρακτηριστικών εισόδου, διατηρώντας ταυτόχρονα σημαντικές πληροφορίες. Μερικοί δημοφιλείς αλγόριθμοι μείωσης διαστάσεων περιλαμβάνουν:

**Ανάλυση κύριου στοιχείου (PCA):** Το PCA μετατρέπει τα αρχικά χαρακτηριστικά σε χώρο μικρότερης διάστασης, διατηρώντας παράλληλα τη μέγιστη ποσότητα πληροφοριών.

**t-SNE (t-Distributed Stochastic Neighbor Embedding):** Το t-SNE είναι μια τεχνική που οπτικοποιεί δεδομένα υψηλών διαστάσεων μειώνοντάς τα σε χώρο χαμηλότερης διάστασης διατηρώντας παράλληλα την τοπική δομή.

### 1.2.3. Ενισχυτική μάθηση (reinforcement learning)

Η ενισχυτική μάθηση (RL) είναι ένας τύπος μηχανικής μάθησης που εμπνέεται από τον τρόπο με τον οποίο μαθαίνουν άνθρωποι και ζώα μέσω δοκιμής και λάθους. Ουσιαστικά πρόκειται για έναν πράκτορα (όπως ένα ρομπότ ή ένα πρόγραμμα λογισμικού) που αλληλεπιδρά με το περιβάλλον του, αναλαμβάνει ενέργειες και λαμβάνει ανταμοιβές ή ποινές με βάση το αποτέλεσμα. Ο στόχος του πράκτορα είναι να μάθει μέσα από αυτές τις αλληλεπιδράσεις ποιες ενέργειες οδηγούν στα πιο επιθυμητά αποτελέσματα, μεγιστοποιώντας τη μακροπρόθεσμη ανταμοιβή του.

Ακολουθούν ορισμένα βασικά σημεία σχετικά με την ενισχυτική μάθηση:

**Δοκιμή και σφάλμα:** Σε αντίθεση με την εποπτευόμενη μάθηση, η οποία λαμβάνει δεδομένα με ετικέτα, οι πράκτορες RL μαθαίνουν μέσω εξερεύνησης και πειραματισμού. Δοκιμάζουν διάφορες ενέργειες και παρατηρούν τα αποτελέσματα, βελτιώνοντας σταδιακά την κατανόησή τους για το περιβάλλον και τον τρόπο πλοήγησής τους.

**Ανταμοιβές και ποινές:** Ο πράκτορας λαμβάνει ανατροφοδότηση με τη μορφή ανταμοιβών (θετική ενίσχυση) για επιθυμητές ενέργειες και ποινές (αρνητική ενίσχυση) για ανεπιθύμητες. Αυτή η ανατροφοδότηση καθοδηγεί τη διαδικασία εκμάθησης του πράκτορα, βοηθώντας τον να διακρίνει μεταξύ καλών και κακών επιλογών.

**Προσανατολισμός στο στόχο:** Οι πράκτορες RL εκπαιδεύονται για την επίτευξη συγκεκριμένων στόχων, που ορίζονται από μια συνάρτηση ανταμοιβής. Αυτή η συνάρτηση καθορίζει ποιες ενέργειες θεωρούνται «καλές» και «κακές» στο πλαίσιο της συγκεκριμένης εργασίας.

**Δυναμικά περιβάλλοντα:** Το RL είναι κατάλληλο για πολύπλοκα και δυναμικά περιβάλλοντα όπου οι κανόνες δεν είναι πάντα σαφείς και ο πράκτορας πρέπει να προσαρμοστεί στις μεταβαλλόμενες καταστάσεις.

Ακολουθούν μερικά παραδείγματα για το πώς χρησιμοποιείται η ενισχυτική μάθηση:

Εκπαίδευση ρομπότ για την πλοήγηση στο περιβάλλον τους

Ανάπτυξη παιχνιδιών αυτο-παιχνιδιών

Βελτιστοποίηση της κυκλοφορίας στις πόλεις

Εξατομίκευση προτάσεων για προϊόντα ή περιεχόμενο

## Κεφάλαιο 2

### 2. Χρηματιστήριο και Μετοχές

Ως χρηματιστήριο νοείται μια οργανωμένη αγορά, συνήθως επίσημα αναγνωρισμένη από το κράτος, όπου τα ενδιαφερόμενα μέρη συναντώνται για να συναλλάσσονται σε κινητές αξίες (όπως μετοχές ανωνύμων εταιρειών, τραπεζικά ομόλογα, κρατικά ομόλογα και άλλα χρεόγραφα) ή/και εμπορεύματα. Τα χρηματιστήρια είναι μοναδικές αγορές υπό την έννοια ότι η ζήτηση και η προσφορά ικανοποιούνται ταυτόχρονα. Το χρηματιστήριο είναι ένας οικονομικός θεσμός γενικά αναγνωρισμένος από τη χώρα στην οποία λειτουργεί, η οποία ως επί το πλείστον καθορίζει το πλαίσιο εντός του οποίου διαμορφώνεται η αγορά και καθορίζει τους όρους και τις προϋποθέσεις λειτουργίας της μέσω νομοθετικών και διοικητικών μέτρων. Τα χρηματιστήρια διακρίνονται σε Χρηματιστήριο Αξιών, Χρηματιστήριο Εμπορευμάτων και Χρηματιστήριο Ναύλων. [5]

Μια μετοχή αντιπροσωπεύει ένα μερίδιο στην ιδιοκτησία μιας εταιρείας, συμπεριλαμβανομένης της αξίωσης για τα κέρδη και τα περιουσιακά στοιχεία της εταιρείας. Ως εκ τούτου, οι μέτοχοι είναι μερικοί ιδιοκτήτες της εταιρείας. Όταν η αξία της επιχείρησης αυξάνεται ή πέφτει, το ίδιο συμβαίνει και με την αξία της μετοχής. Οι μετοχές αγοράζονται και πωλούνται γενικά ηλεκτρονικά μέσω χρηματιστηρίων, με τα δύο κύρια στις Ηνωμένες Πολιτείες να είναι το Χρηματιστήριο της Νέας Υόρκης (NYSE) και η Εθνική Ένωση Διαπραγματευτών Κινητών Αξιών (NASDAQ) και στην Ελλάδα το Χρηματιστήριο Αθηνών. Ενώ ορισμένες εταιρείες πωλούν μετοχές απευθείας σε επενδυτές, οι περισσότερες πωλούν μετοχές μόνο μέσω μεσιτείας. Οι επενδυτές αγοράζουν και πωλούν μετοχές για διάφορους λόγους, συμπεριλαμβανομένης της δυνατότητας να αυξήσουν την αξία της επένδυσής τους με την πάροδο του χρόνου, να αποκομίσουν δυνητικά κέρδη από βραχυπρόθεσμες κινήσεις των τιμών των μετοχών ή ακόμα και να κερδίσουν εισόδημα επενδύοντας σε μετοχές που πληρώνουν μερίσματα. Το σκεπτικό πίσω από αυτές τις αποφάσεις προέρχεται συχνά από ποιοτικές και ποσοτικές τεχνικές όπως η θεμελιώδης ανάλυση ή η τεχνική ανάλυση. Να ληφθεί υπόψη ότι η τιμή μιας μετοχής μπορεί να πέσει τόσο εύκολα όσο μπορεί να αυξηθεί. Η επένδυση σε μετοχές δεν προσφέρει καμία εγγύηση ότι θα κερδηθούν χρήματα, και πολλοί επενδυτές χάνουν χρήματα αντ' αυτού. Η πληρωμή μερισμάτων μετοχών δεν είναι εγγυημένη και τα μερίσματα ενδέχεται να διακοπούν. Η υποκείμενη κοινή μετοχή υπόκειται σε κινδύνους αγοράς και επιχειρηματικούς κινδύνους, συμπεριλαμβανομένης της αφερεγγυότητας. Οι μετοχές αποτελούν σημαντικό μέρος οποιουδήποτε χαρτοφυλακίου λόγω των δυνατοτήτων τους για ανάπτυξη και υψηλότερες αποδόσεις έναντι άλλων επενδυτικών προϊόντων. Προκειμένου να προσδιοριστεί πόσα χρήματα μπορεί να διατεθούν σε μετοχές, θα πρέπει πρώτα να αναπτυχθεί ένα ολοκληρωμένο οικονομικό σχέδιο που να αντικατοπτρίζει τον επενδυτικό ορίζοντα και το επίπεδο κινδύνου που ο επενδυτής θα δεχτεί σε αντάλλαγμα για τις πιθανές ανοδικές μετοχές που μπορούν να προσφέρουν.

Οι μετοχές διακρίνονται σε:

- κοινές,
- προνομιούχες και επικαρπίας,
- ονομαστικές και ανώνυμες,
- μετά ψήφου ή χωρίς ψήφο,
- σε διαπραγματεύσιμες σε Χρηματιστήριο ή σε μη διαπραγματεύσιμες.

Η κοινή μετοχή είναι ο πιο συνηθισμένος τύπος μετοχής και περιλαμβάνει όλα τα βασικά δικαιώματα ενός μετόχου, όπως δικαίωμα συμμετοχής στα κέρδη, στην έκδοση νέων μετοχών, στο προϊόν της εκκαθάρισης, καθώς και δικαίωμα ψήφου στη Γενική Συνέλευση της εταιρείας και συμμετοχής στη διαχείρισή της.

Η προνομιούχος μετοχή προσφέρει απλά ένα προβάδισμα έναντι των κατόχων κοινών μετοχών, στη λήψη μερίσματος και στη λήψη του προϊόντος της εκκαθάρισης σε περίπτωση διάλυσης της επιχείρησης, αλλά συνήθως στερείται του δικαιώματος ψήφου και συμμετοχής στη διαχείριση της επιχείρησης.

Όταν μια επιχείρηση που έχει εκδώσει μετοχές έχει κέρδη, μπορεί να μοιράσει μέρος των κερδών αυτών στους μετόχους της με την μορφή μερίσματος, που αντιστοιχεί σε κάποιο ποσό ανά μετοχή. [6]

## 2.1. Απόδοση Μετοχής

Η απόδοση μιας επένδυσης είναι το μέγεθος κατά το οποίο μεταβάλλεται ο πλούτος ενός επενδυτή. Διακρίνονται οι παρακάτω έννοιες της απόδοσης:

- πραγματοποιηθείσα απόδοση (historical return): είναι η πραγματική απόδοση μιας επένδυσης η οποία πραγματοποιήθηκε μια συγκεκριμένη χρονική περίοδο.
- αναμενόμενη απόδοση (expected return): είναι η απόδοση την οποία οι επενδυτές προβλέπουν πως θα αποκομίσουν στο μέλλον από μια επένδυση.
- απαιτούμενη απόδοση (required return): είναι η ελάχιστη απόδοση την οποία οι επενδυτές απαιτούν να λάβουν από μία επένδυση ώστε να την αναλάβουν. Περιλαμβάνει την πραγματική απόδοση χωρίς κίνδυνο (real risk free rate), το αναμενόμενο ποσοστό πληθωρισμού και την ανταμοιβή για τον κίνδυνο που αναλαμβάνει ο επενδυτής (risk premium). Συνίσταται δε ως μέγεθος, στην απόδοση εισοδήματος (capital yield) και τα κέρδη ή ζημιές του κεφαλαίου (capital gain & capital loss).

Όταν οι διαπραγματεύσεις των αξιογράφων στο χρηματιστήριο αξιών δεν είναι συνεχείς, η απόδοση  $R$  του αξιογράφου  $i$  τη χρονική στιγμή  $t$  ισούται με τη μεταβολή της τιμής  $P$  τη χρονική στιγμή  $t$  από την τιμή που είχε τη χρονική στιγμή  $t-1$ , προς την αρχική αυτή τιμή. Δηλαδή, η απόδοση μετράει πόσο μεταβλήθηκε η αξία του αξιογράφου προς την αρχική του αξία.

$$R_{it} = (P_{it} - P_{it-1}) / (P_{it-1})$$

Όταν όμως έχουμε συνεχείς συναλλαγές των αξιογράφων, χρησιμοποιείται ο εξής λογάριθμος της τιμής  $P$  τη χρονική στιγμή  $t$  συν το μέρισμα  $D$  την ίδια χρονική στιγμή, προς την τιμή που είχε το αξιόγραφο τη στιγμή  $t-1$ :

$$R_{it} = \ln(P_{it} + D_{it}/P_{it-1})$$

Η αναμενόμενη απόδοση  $ER$  του αξιογράφου  $i$  τη χρονική στιγμή  $t$ , ορίζεται ως η πιθανότητα να πραγματοποιηθεί η συγκεκριμένη απόδοση αυτή τη δεδομένη

χρονική στιγμή. Μπορεί να υπολογισθεί ως ο σταθμικός μέσος όρος όλων των  $n$  δυνατικών αποδόσεων  $R$  που μπορούν να παρουσιασθούν σε μία επένδυση, έκαστη από τις οποίες σταθμίζεται από την αντίστοιχη πιθανότητα  $P$  να παρουσιασθεί [7]:

$$E(Rit) = \sum_{i=1}^n PiRit$$

## 2.2. Κίνδυνος

Στον οικονομικό κόσμο ορίζεται ως κίνδυνος η πιθανότητα το πραγματικό αποτέλεσμα από μια επένδυση να διαφέρει από το αναμενόμενο. Είναι, φυσικά, αυτονόητο ότι όλοι σχεδόν οι επενδυτές ανησυχούν για την περίπτωση εκείνη κατά την οποία το πραγματικό αποτέλεσμα μιας επένδυσης θα είναι μικρότερο του αναμενόμενου. Η αντίθετη περίπτωση (όταν δηλαδή το πραγματικό αποτέλεσμα είναι μεγαλύτερο του αναμενόμενου) αποτελεί μια ευχάριστη έκπληξη. Στην περίπτωση αυτή, κανένας δεν αναφέρεται στον κίνδυνο, μολονότι και αυτό αποτελεί κίνδυνο. Γενικά, όσο περισσότερο διαφέρει το πραγματικό αποτέλεσμα μιας επένδυσης από το αναμενόμενο (ή με άλλα λόγια, όσο μεγαλύτερη είναι η διασπορά των δυνητικών αποτελεσμάτων γύρω από το αναμενόμενο), τόσο μεγαλύτερος είναι και ο κίνδυνος τον οποίο αυτή περιέχει. Επιπλέον, εάν δεν υπάρχει διασπορά των δυνητικών (δηλαδή πιθανών) αποτελεσμάτων γύρω από το αναμενόμενο, δεν υπάρχει και κίνδυνος. Εκ των ανωτέρω κίνδυνος είναι η μεταβλητότητα (variability) των δυνητικών αποτελεσμάτων γύρω από την αναμενόμενη τιμή τους ή τον αριθμητικό τους μέσο.

### 2.2.1. Πηγές του κινδύνου

Όλες οι επενδύσεις ενέχουν κίνδυνο που κάνει τις μελλοντικές τους αποδόσεις αβέβαιες. Ο συνολικός κίνδυνος μιας επένδυσης προέρχεται από πολλές πηγές, οι κυριότερες από τις οποίες είναι οι εξής:

### 2.2.2. Κίνδυνος επιτοκίων (interest rate risk)

Είναι η πιθανή μεταβλητότητα (variability) των αποδόσεων μιας επένδυσης, η οποία προέρχεται από μεταβολές των επιτοκίων της αγοράς. Εάν υποθέσουμε ότι όλα τα άλλα παραμένουν σταθερά, μια μεταβολή στα επιτόκια θα επιφέρει μια αντίθετη μεταβολή στις τιμές των αξιογράφων. Εάν, για παράδειγμα, αυξηθούν τα επιτόκια της αγοράς, θα μειωθούν οι αξίες των ομολογιών, των μετοχών καθώς επίσης και των άλλων επενδύσεων. Το αντίστροφο θα συμβεί εάν μειωθούν τα επιτόκια. Η αντίθετη σχέση μεταξύ επιτοκίων και τιμών αξιογράφων οφείλεται στον τρόπο με τον οποίο γίνεται η αποτίμηση των αξιογράφων. Με το θέμα όμως αυτό θα ασχοληθούμε σε άλλο κεφάλαιο.

### 2.2.3. Κίνδυνος πληθωρισμού ή κίνδυνος αγοραστικής δύναμης (inflation risk or purchasing power risk)

Είναι η πιθανή μεταβλητότητα των αποδόσεων μιας επένδυσης, η οποία οφείλεται στη μείωση της αγοραστικής δύναμης των επενδυμένων κεφαλαίων. Στον βαθμό που ο πληθωρισμός που θα επικρατήσει στο μέλλον είναι αβέβαιος, η πραγματική απόδοση μιας επένδυσης (δηλαδή η αποπληθωρισμένη της απόδοση) περιλαμβάνει κίνδυνο ακόμη και αν η ονομαστική της απόδοση είναι βέβαιη (όπως, για παράδειγμα, στην περίπτωση της απόδοσης των εντόκων γραμματίων).

### 2.2.4. Κίνδυνος αγοράς (market risk)

Είναι η πιθανή μεταβλητότητα των αποδόσεων μιας επένδυσης η οποία προέρχεται από μεταβολές της συνολικής χρηματιστηριακής αγοράς. Οι εναλλαγές της χρηματιστηριακής αγοράς, για παράδειγμα, από ανοδική σε πτωτική και αντιστρόφως επηρεάζουν όλες τις επενδύσεις, αλλά οι μετοχές είναι οι επενδύσεις εκείνες οι οποίες είναι περισσότερο εκτεθειμένες στον κίνδυνο της αγοράς.

#### *2.2.5. Επιχειρηματικός κίνδυνος (business risk)*

Είναι η πιθανή μεταβλητότητα των αποδόσεων μιας επένδυσης σε μια επιχείρηση, η οποία προέρχεται από το είδος της δραστηριότητας της ίδιας της επιχείρησης. Για παράδειγμα, η επένδυση στην επιχείρηση Α, η οποία πουλά τρόφιμα και παρουσιάζει μέχρι σήμερα σταθερές πωλήσεις και αύξηση κερδών, ενέχει μικρότερο επιχειρηματικό κίνδυνο από ότι η επένδυση στην επιχείρηση Β, η οποία πουλά αυτοκίνητα και παρουσιάζει σημαντικές αυξομειώσεις στις πωλήσεις και τα κέρδη της.

#### *2.2.6. Χρηματοοικονομικός κίνδυνος (financial risk)*

Είναι η πιθανή μεταβλητότητα των αποδόσεων μιας επένδυσης σε μια επιχείρηση η οποία προέρχεται από τη χρήση δανειακών κεφαλαίων από την επιχείρηση. Όσο περισσότερα δανειακά κεφάλαια χρησιμοποιεί μια επιχείρηση, τόσο περισσότερο εκτεθειμένη είναι σε χρηματοοικονομικό κίνδυνο.

#### *2.2.7. Κίνδυνος ρευστότητας (liquidity risk)*

Είναι ο κίνδυνος ο οποίος προέρχεται από τη δευτερογενή αγορά στην οποία αποτελεί αντικείμενο διαπραγμάτευσης ένα αξιόγραφο. Όταν ένας επενδυτής αγοράζει ένα αξιόγραφο, αναμένει να είναι σε θέση να μετατρέψει το αξιόγραφο αυτό σε μετρητά, εάν κάποια στιγμή χρειαστεί. Η ικανότητα μιας επένδυσης να μετατραπεί σε μετρητά σε σύντομο χρονικό διάστημα δίχως να υποχρεωθεί ο επενδυτής να παραχωρήσει σημαντικές εκπτώσεις ή προμήθειες είναι γνωστή ως ρευστότητα. Κατά συνέπεια, όσο περισσότερη αβεβαιότητα υπάρχει σχετικά με τον χρόνο και τις παραχωρήσεις που θα απαιτηθούν για τη μετατροπή της επένδυσης σε μετρητά, τόσο μεγαλύτερος είναι ο κίνδυνος ρευστότητας που ενέχει η επένδυση.

#### *2.2.8. Συναλλαγματικός κίνδυνος (exchange rate risk or currency risk)*

Είναι η αβεβαιότητα των αποδόσεων μιας επένδυσης την οποία έχει κάνει ένας επενδυτής σε ξένο νόμισμα όταν οι αποδόσεις αυτές μετατραπούν στο νόμισμα της χώρας του επενδυτή. Εάν, για παράδειγμα, ένας Αμερικανός επενδυτής αγοράσει μετοχές στο Χρηματιστήριο Αθηνών, οι αποδόσεις που θα έχει από τους τίτλους αυτούς θα εξαρτηθούν και από τη μεταβολή της ισοτιμίας δολαρίου – ευρώ. Στην περίπτωση αυτή, μια σημαντική διολίσθηση του ευρώ έναντι του δολαρίου είναι πιθανό να εξανεμίσει μια αξιόλογη απόδοση των ελληνικών μετοχών.

#### *2.2.9. Πολιτικός κίνδυνος (country risk or political risk).*

Είναι η αβεβαιότητα στις αποδόσεις η οποία οφείλεται στην πιθανότητα μιας σημαντικής μεταβολής στο πολιτικό ή στο οικονομικό περιβάλλον μιας χώρας.

#### *2.2.10. Συστηματικός και μη συστηματικός κίνδυνος*

Η επισήμανση των κυριότερων πηγών επενδυτικών κινδύνων που έγινε προηγουμένως αποτελεί την παραδοσιακή προσέγγιση. Η σύγχρονη ανάλυση επενδύσεων διαχωρίζει τους κινδύνους σε δύο κατηγορίες: σε εκείνους οι οποίοι συνδέονται με τις κινήσεις της συνολικής αγοράς και σε εκείνους οι οποίοι οφείλονται σε λόγους ξεχωριστούς για την κάθε επένδυση. Στη σύγχρονη ορολογία οι δύο αυτοί κίνδυνοι ονομάζονται συστηματικός κίνδυνος (systematic risk or market risk) και μη συστηματικός κίνδυνος (unsystematic risk) αντίστοιχα. Άρα, στη σύγχρονη ανάλυση επενδύσεων ισχύει η σχέση:



Ο συστηματικός κίνδυνος ή κίνδυνος της αγοράς είναι ο κίνδυνος της επένδυσης ο οποίος συνδέεται με τις κινήσεις της συνολικής αγοράς και ο οποίος δεν μπορεί να εξαιρεθεί με τη διαφοροποίηση (diversification)<sup>4</sup> του χαρτοφυλακίου. Ο κίνδυνος αυτός οφείλεται σε δυνάμεις ανεξάρτητες από κάθε ξεχωριστή επένδυση που περιέχεται στο χαρτοφυλάκιο του επενδυτή. Για παράδειγμα, την 19η Οκτωβρίου 1987 υπήρξε μια απότομη πτώση των τιμών όλων των μετοχών στο χρηματιστήριο της Νέας Υόρκης. Την ημέρα αυτή ο δείκτης Dow Jones Industrial Average παρουσίασε μείωση ίση με 22%, δηλαδή 508 μονάδες. Συστηματικό κίνδυνο έχουν όλα τα αξιόγραφα, είτε είναι μετοχές είτε είναι ομολογίες, καθώς ο κίνδυνος αυτός συμπεριλαμβάνει τον κίνδυνο επιτοκίων, τον κίνδυνο της αγοράς και τον κίνδυνο του πληθωρισμού που αναφέρθηκαν προηγουμένως. Από την άλλη πλευρά, ο μη συστηματικός κίνδυνος είναι ο κίνδυνος ο οποίος οφείλεται σε λόγους ιδιαίτερους για κάθε επιχείρηση και, επομένως, μπορεί να εξαιρεθεί με την διαφοροποίηση του χαρτοφυλακίου. Αν και τα περισσότερα αξιόγραφα ενέχουν σε κάποιο βαθμό μη συστηματικό κίνδυνο, ο κίνδυνος αυτός συνδέεται κυρίως με τις μετοχές. Ο μη συστηματικός κίνδυνος συμπεριλαμβάνει τον επιχειρηματικό κίνδυνο, τον χρηματοοικονομικό κίνδυνο και τον κίνδυνο ρευστότητας. [8]

### 2.3. Μέτρηση Κινδύνου

Η κατάλληλη και αποτελεσματική αντιμετώπιση απαιτεί ακριβή ποσοτικοποίηση των πιθανών κινδύνων. Η αξία σε κίνδυνο ή Value at Risk (VAR) είναι η πιο συχνά χρησιμοποιούμενη στατιστική μέθοδος για τη μέτρηση του κινδύνου αγοράς. Η μέθοδος VAR χρησιμοποιείται για τον υπολογισμό της πιθανότητας δύο πραγμάτων:

- Πόση απώλεια μπορεί να πραγματοποιήσει ένα χαρτοφυλάκιο μετοχών ή επενδύσεων
- Πόσο πιθανό είναι να συμβεί αυτή η απώλεια

Το VAR μπορεί να είναι χρήσιμο για τη μέτρηση του κινδύνου αγοράς για μια ποικιλία επενδύσεων, συμπεριλαμβανομένων των μετοχών και των ομολόγων. Υπάρχουν διάφοροι τρόποι υπολογισμού του VAR, ξεκινώντας από την ιστορική μέθοδο. Σε αυτήν την περίπτωση, θα λαμβάνονται απλώς οι ιστορικές αποδόσεις μιας επένδυσης ή ενός χρηματιστηριακού δείκτη και θα ταξινομούνται από το χαμηλότερο στο υψηλότερο. Εξετάζοντας τα υψηλά και τα χαμηλά και πού είναι συγκεντρωμένα, μπορείτε να γίνει μια έμπειρη εικασία για το πού αναμένεται να μεγιστοποιηθούν οι απώλειες.

Μια δεύτερη μέθοδος για τον υπολογισμό του VAR χρησιμοποιεί αναμενόμενες αποδόσεις και τυπική απόκλιση για να προσδιορίσει τις καλύτερες και χειρότερες περιόδους απόδοσης μιας μετοχής. Παρόμοια με την πρώτη μέθοδο, μπορεί να



χρησιμοποιηθεί για να γίνει μια προβολή σχετικά με το πώς αναμένεται να αποδώσει μια μετοχή στο μέλλον.

Μπορεί επίσης να χρησιμοποιηθεί κάτι που ονομάζεται προσομοίωση Monte Carlo για να υπολογιστεί το VAR προκειμένου να μετρηθεί ο κίνδυνος της αγοράς. Αυτή η στρατηγική χρησιμοποιεί υποθετικά σενάρια για να προβλέψει τις κινήσεις των τιμών των μετοχών και τις μελλοντικές αποδόσεις. Η εκτέλεση πολλαπλών προσομοιώσεων μπορεί να δώσει ένα εύρος απωλειών για να γίνει εκτίμηση πιθανών απωλειών.

Ενώ το VAR χρησιμοποιείται συχνά για τη μέτρηση του κινδύνου αγοράς, έχει ορισμένα ελαττώματα. Αν και μπορεί να είναι εύκολο να εφαρμοστεί μία από αυτές τις μεθόδους υπολογισμού σε ένα μεμονωμένο απόθεμα, τα πράγματα μπορεί να γίνουν πιο περίπλοκα όταν εξετάζεται μια μεγαλύτερη ομάδα περιουσιακών στοιχείων. Αξίζει επίσης να σημειωθεί ότι οι τρεις μέθοδοι υπολογισμού ενδέχεται να μην παράγουν πανομοιότυπα αποτελέσματα, γεγονός που μπορεί να κάνει πιο δύσκολη τη μέτρηση του κινδύνου αγοράς.

#### 2.4. Διαχείριση Κινδύνου

Η διαχείριση κινδύνου είναι μια συστηματική διαδικασία εντοπισμού, αξιολόγησης και μετριασμού των κινδύνων που σχετίζονται με μια δραστηριότητα ή επένδυση. Ο κύριος στόχος της διαχείρισης κινδύνου είναι να ελαχιστοποιήσει την πιθανή επίδραση των κινδύνων σε ένα επενδυτικό χαρτοφυλάκιο μεγιστοποιώντας παράλληλα τις αποδόσεις του. Η διαχείριση κινδύνων στη χρηματιστηριακή αγορά περιλαμβάνει μια ολοκληρωμένη προσέγγιση που λαμβάνει υπόψη διάφορους παράγοντες που μπορούν να επηρεάσουν ένα επενδυτικό χαρτοφυλάκιο. Αυτοί οι παράγοντες μπορεί να περιλαμβάνουν μεταξύ άλλων τάσεις της αγοράς, οικονομικές συνθήκες, πολιτικά γεγονότα και την απόδοση της εταιρείας. Υπάρχουν πολλές τεχνικές διαχείρισης κινδύνου που μπορούν να χρησιμοποιήσουν οι επενδυτές για να διαχειριστούν αποτελεσματικά τους κινδύνους. Μια δημοφιλής στρατηγική είναι η διαφοροποίηση, όπου οι επενδυτές κατανέμουν τις επενδύσεις τους σε διαφορετικές κατηγορίες περιουσιακών στοιχείων ή τίτλους για να μειώσουν τον αντίκτυπο των διακυμάνσεων της αγοράς στο χαρτοφυλάκιο τους. Άλλες τεχνικές περιλαμβάνουν την αντιστάθμιση, όπου οι επενδυτές χρησιμοποιούν χρηματοοικονομικά μέσα, όπως δικαιώματα προαίρεσης ή συμβόλαια μελλοντικής εκπλήρωσης για να αντισταθμίσουν πιθανές ζημιές, και την ενεργή διαχείριση χαρτοφυλακίου, όπου οι διαχειριστές επενδύσεων παρακολουθούν και προσαρμόζουν συνεχώς τα χαρτοφυλάκια τους ανάλογα με τις μεταβαλλόμενες συνθήκες της αγοράς.

Υπάρχουν διάφορες στρατηγικές διαχείρισης κινδύνου που μπορούν να χρησιμοποιηθούν από τους επενδυτές στο χρηματιστήριο για τον μετριασμό των πιθανών κινδύνων και τη μεγιστοποίηση των αποδόσεων. Μερικές από τις πιο κοινές στρατηγικές διαχείρισης κινδύνου στο χρηματιστήριο περιλαμβάνουν:

- Διαφοροποίηση: Η διαφοροποίηση είναι μια στρατηγική που περιλαμβάνει την κατανομή των επενδύσεων σε διαφορετικές κατηγορίες περιουσιακών στοιχείων ή τίτλους για τη μείωση του αντίκτυπου των διακυμάνσεων της αγοράς στο χαρτοφυλάκιο. Επενδύοντας σε μια σειρά μετοχών σε διαφορετικούς τομείς, γεωγραφίες και κεφαλαιοποιήσεις αγοράς, οι επενδυτές μπορούν να ελαχιστοποιήσουν τον αντίκτυπο οποιασδήποτε μετοχής ή κλάδου στο χαρτοφυλάκιο.
- Εντολές Stop-Loss: Μια εντολή stop-loss είναι μια εντολή πώλησης μιας μετοχής εάν φτάσει σε ένα συγκεκριμένο σημείο τιμής. Αυτή η στρατηγική χρησιμοποιείται για τον περιορισμό των πιθανών απωλειών σε περίπτωση που η τιμή της μετοχής πέσει κάτω από ένα προκαθορισμένο όριο.
- Αντιστάθμιση: Η αντιστάθμιση περιλαμβάνει τη χρήση χρηματοοικονομικών μέσων όπως δικαιώματα προαίρεσης ή συμβόλαια μελλοντικής εκπλήρωσης για την αντιστάθμιση πιθανών ζημιών. Για παράδειγμα, ένας επενδυτής μπορεί να αγοράσει δικαιώματα πώλησης σε μια μετοχή για να προστατεύσει από πιθανές απώλειες εάν η τιμή της μετοχής πέσει.
- Ενεργή διαχείριση χαρτοφυλακίου: Η παρακολούθηση και η αλλαγή του χαρτοφυλακίου σε συνεχή βάση ως απάντηση στις μεταβαλλόμενες συνθήκες της αγοράς είναι γνωστή ως ενεργή διαχείριση χαρτοφυλακίου. Προκειμένου να γίνουν σοφές επενδυτικές επιλογές, αυτή η τεχνική απαιτεί αξιολόγηση των τάσεων της αγοράς, της εταιρικής απόδοσης και των οικονομικών δεδομένων.
- Θεμελιώδης ανάλυση: Η θεμελιώδης ανάλυση είναι μια προσέγγιση για τον προσδιορισμό της εγγενούς αξίας μιας εταιρείας μέσω της αξιολόγησης των οικονομικών καταστάσεων, των τάσεων του κλάδου και άλλων σχετικών δεδομένων. Αυτή η μέθοδος έχει σχεδιαστεί για να αποκαλύψει αποθέματα που είναι φθηνά και έχουν πιθανότητες ανάπτυξης.
- Μεταφοράς κινδύνου (Transfer Risk) σε άλλα μέρη όπως προμηθευτές, ασφαλιστικές εταιρείες

## Κεφάλαιο 3

### 3. Βασικές Έννοιες Πρόβλεψης

#### 3.1. Τί είναι πρόβλεψη

Πρόβλεψη είναι η διαδικασία εκτίμησης μελλοντικών γεγονότων με όσο το δυνατόν πιο έγκυρο τρόπο βασιζόμενη σε ιστορικά δεδομένα, εμπειρικά δεδομένα και γνώση μελλοντικών γεγονότων που θα μπορούσαν να την επηρεάσουν. Η πρόβλεψη χρησιμοποιείται σε διάφορους τομείς της ζωής μας λόγω της ανάγκης μας για την μείωση αποφασιστικού ρίσκου σχετικά με μελλοντικές μας δραστηριότητες. Οι οικονομικές οντότητες δίνουν επίσης μεγάλη σημασία στην διαδικασία της πρόβλεψης προσδοκώντας μέσω της ανάλυσης αυτής πιο έγκυρες πληροφορίες για την λήψη αποφάσεων με σκοπό να επιτυγχάνουν τους στόχους τους. Αποτελεί ουσιαστικά το βασικό εργαλείο για κάθε μελλοντική εξέλιξη και απόφαση και η ποιότητα της εξαρτάται από τον τρόπο με τον οποίον προέκυψαν και αναλύθηκαν οι πληροφορίες.

Πολλές μέθοδοι έχουν αναπτυχθεί για την καλύτερη πρόβλεψη, χωρίς όμως καμία να έχει καταφέρει να δημιουργήσει την "τέλεια". Η πρόβλεψη παραμένει μια εκτίμηση η οποία όσο υπάρχουν άγνωστοι αστάθμητοι παράγοντες, θα περιέχει κάποιο ποσοστό σφάλματος. Αυτό βέβαια δεν έχει σταματήσει τις οικονομικές οντότητες από το να χρησιμοποιούν τις διάφορες μεθόδους για να τους δοθεί έστω μια κατεύθυνση λαμβάνοντας βέβαια υπόψη μια απόκλιση (σφάλμα).

Οι μεγάλες οικονομικές οντότητες έχουν συνήθως τμήμα οικονομικών αναλυτών που συντάσσουν προβλέψεις για κάθε λογιστική περίοδο, και μάλιστα τις χρησιμοποιούν ως μέτρο σύγκρισης με τα πραγματικά αποτελέσματα. Στόχος των οντοτήτων είναι ότι τα πραγματικά αποτελέσματα και οι προβλέψεις είναι όσο το δυνατόν πιο κοντά. Αυτό βέβαια τις περισσότερες φορές δεν επιτυγχάνεται, αλλά το κέρδος που έχουν οι οντότητες από αυτήν την σύγκριση είναι η καλύτερη κατανόηση των "επιπλέον" ή αλλιώς εκτός πρόβλεψης αποτελεσμάτων. Στη συνέχεια οι αναλυτές επικεντρώνονται στα αίτια αυτών των διαφορών με σκοπό τη δημιουργία, κάθε φορά, καλύτερου μοντέλου πρόβλεψης.

Πολλές φορές η έννοια της Πρόβλεψης συγχέεται με τις έννοιες Στόχος και Προγραμματισμός. Αυτά είναι τρία διαφορετικά πράγματα και παρακάτω δίνεται εν συντομία ο ορισμός των τριών με σκοπό την διαφοροποίηση και την καλύτερη κατανόηση της πρόβλεψης.

#### **Πρόβλεψη**

Πρόκειται για την πρόβλεψη του μέλλοντος όσο το δυνατόν ακριβέστερα, λαμβάνοντας υπόψη όλες τις διαθέσιμες πληροφορίες, συμπεριλαμβανομένων ιστορικών δεδομένων και γνώσεων για τυχόν μελλοντικά γεγονότα που ενδέχεται να επηρεάσουν τις προβλέψεις.

### **Στόχοι**

Είναι αυτό που θα θέλαμε να συμβεί. Οι στόχοι πρέπει να συνδέονται με προβλέψεις και σχέδια, αλλά αυτό δεν συμβαίνει πάντα. Πολύ συχνά, οι στόχοι τίθενται χωρίς σχέδιο για τον τρόπο επίτευξής τους και δεν υπάρχουν προβλέψεις για το εάν είναι ρεαλιστικοί.

### **Προγραμματισμός**

Είναι μια απάντηση στις προβλέψεις και τους στόχους. Ο προγραμματισμός περιλαμβάνει τον καθορισμό των κατάλληλων ενεργειών που απαιτούνται για να φτάσουν οι προβλέψεις των επιχειρήσεων στους στόχους τους.

Η πρόβλεψη πρέπει να αποτελεί αναπόσπαστο μέρος των δραστηριοτήτων λήψης αποφάσεων της διοίκησης, καθώς μπορεί να διαδραματίσει σημαντικό ρόλο σε πολλούς τομείς της εταιρείας. Οι σύγχρονες οργανώσεις απαιτούν βραχυπρόθεσμες, μεσοπρόθεσμες και μακροπρόθεσμες προβλέψεις, ανάλογα με τη συγκεκριμένη εφαρμογή.

### **Βραχυπρόθεσμες προβλέψεις**

Απαιτούνται για τον προγραμματισμό του προσωπικού, της παραγωγής και της μεταφοράς. Στο πλαίσιο της διαδικασίας προγραμματισμού, συχνά απαιτούνται επίσης προβλέψεις για τη ζήτηση.

### **Μεσοπρόθεσμες προβλέψεις**

Απαιτούνται για τον προσδιορισμό των μελλοντικών απαιτήσεων πόρων, προκειμένου να αγοραστούν πρώτες ύλες, να προσληφθεί προσωπικό ή να αγοραστούν μηχανήματα και εξοπλισμός.

### **Μακροπρόθεσμες προβλέψεις**

Χρησιμοποιούνται στον στρατηγικό σχεδιασμό. Οι αποφάσεις αυτές πρέπει να λαμβάνουν υπόψη τις ευκαιρίες της αγοράς, τους περιβαλλοντικούς παράγοντες και τους εσωτερικούς πόρους.

Ένας οργανισμός πρέπει να αναπτύξει ένα σύστημα πρόβλεψης που περιλαμβάνει διάφορες προσεγγίσεις για την πρόβλεψη αβέβαιων γεγονότων. Τέτοια συστήματα πρόβλεψης απαιτούν την ανάπτυξη εμπειρογνομosύνης στον εντοπισμό προβλημάτων πρόβλεψης, την εφαρμογή μιας σειράς μεθόδων πρόβλεψης, την επιλογή κατάλληλων μεθόδων για κάθε πρόβλημα και την αξιολόγηση και αναλυτική εξέταση μεθόδων πρόβλεψης με την πάροδο του χρόνου.

Στα αρχικά στάδια ενός σχεδίου πρόβλεψης, πρέπει να ληφθούν αποφάσεις σχετικά με το τι πρέπει να προβλεφθεί. Είναι επίσης απαραίτητο να εξεταστεί ο χρονικός ορίζοντας. Οι προβλέψεις θα απαιτηθούν για ένα μήνα εκ των προτέρων, για 6 μήνες ή για δέκα χρόνια; Θα χρειαστούν διαφορετικοί τύποι μοντέλων, ανάλογα με τον ορίζοντα πρόβλεψης που είναι πιο σημαντικός. Οι προβλέψεις που πρέπει να παραχθούν συχνά γίνονται καλύτερα χρησιμοποιώντας ένα αυτοματοποιημένο σύστημα παρά με μεθόδους που απαιτούν προσεκτική χειρωνακτική εργασία.

Οι οικονομικές οντότητες πρέπει να αφιερώνουν χρόνο για να μιλήσουν με τους ανθρώπους που θα χρησιμοποιήσουν τις προβλέψεις για να βεβαιωθούν ότι καταλαβαίνουν τις ανάγκες τους και πώς θα χρησιμοποιηθούν οι προβλέψεις πριν προχωρήσουν σε εκτενή εργασία για την παραγωγή των προβλέψεων. Αφού προσδιοριστεί ποιες προβλέψεις απαιτούνται, τότε είναι απαραίτητο να εντοπιστούν ή να συλλεχθούν τα δεδομένα στα οποία θα βασίζονται οι

προβλέψεις. Τα δεδομένα που απαιτούνται για την πρόβλεψη ενδέχεται να υπάρχουν ήδη. Αυτές τις μέρες, καταγράφονται πολλά δεδομένα και το καθήκον του οικονομικού αναλυτή είναι συχνά να προσδιορίζει πού και πώς αποθηκεύονται τα απαιτούμενα δεδομένα. Τα δεδομένα μπορεί να περιλαμβάνουν τα αρχεία πωλήσεων μιας επιχείρησης, την ιστορική ζήτηση για ένα προϊόν ή το ποσοστό ανεργίας για μια γεωγραφική περιοχή. Ένα μεγάλο μέρος του χρόνου του αναλυτή μπορεί να δαπανηθεί για τον εντοπισμό και τη σύγκριση των διαθέσιμων δεδομένων πριν από την ανάπτυξη κατάλληλων μεθόδων πρόβλεψης. [10], [11], [12], [13]

### 3.2. Αρχές Προβλέψεων

Για την πιο σωστή και αποτελεσματική χρήση της πρόβλεψης, οι επιχειρήσεις θα πρέπει να ακολουθούν κάποιες γενικές αρχές που μπορούν να συμβάλλουν στην βελτίωση της ακρίβειας των προβλέψεων.

- Η μέθοδος πρόβλεψης πρέπει να ταιριάζει με την κατάσταση που προβλέπουμε. Αφού οι συνθήκες για τα προβλήματα πρόγνωσης ποικίλλουν δεν μπορεί να υπάρχει μία μόνο μέθοδος που να λειτουργεί σε όλες τις καταστάσεις.
- Είναι προτιμότερο να χρησιμοποιούνται απλές ποσοτικές μέθοδοι. Τα σύνθετα μοντέλα συχνά περιέχουν θόρυβο στα δεδομένα, ειδικά σε αβέβαιες καταστάσεις. Έτσι, η χρήση απλών μεθόδων είναι σημαντική όταν υπάρχει μεγάλη αβεβαιότητα σχετικά με την κατάσταση. Τα απλά μοντέλα είναι ευκολότερα από τα πολύπλοκα μοντέλα για να κατανοηθούν και είναι λιγότερο επιρρεπή σε λάθη. Είναι επίσης ακριβέστερα από πολύπλοκα μοντέλα όταν προβαίνουν σε προβλέψεις για πολύπλοκες και αβέβαιες καταστάσεις.
- Είναι προτιμότερο οι οικονομικές οντότητες να είναι συντηρητικές όταν υπάρχει αβεβαιότητα. Για δεδομένα εγκάρσιας τομής, αυτό σημαίνει παραμονή κοντά στην τυπική συμπεριφορά (συχνά αποκαλούμενη "ρυθμός βάσης"). Στις χρονοσειρές, οι οντότητες θα πρέπει να παραμένουν κοντά στον ιστορικό μέσο όρο. Εάν η ιστορική τάση υπόκειται σε μεταβολές, ασυνέχειες και ανατροπές, θα πρέπει οι αναλυτές να είναι προσεχτικοί με την παρεμβολή της ιστορικής τάσης. Μόνο όταν μια ιστορική χρονοσειρά δείχνει μια μακρά σταθερή τάση με μικρή διακύμανση θα πρέπει να παραταθεί η τάση στο μέλλον.
- Η πρόβλεψη είναι περισσότερο ακριβής όταν είναι βραχυπρόθεσμη. Όσο κοντινότερος είναι ο χρονικός ορίζοντας της πρόγνωσης τόσο μικρότερος είναι ο βαθμός αβεβαιότητας και άρα τόσο μικρότερο το σφάλμα που θα περιέχει. Βέβαια αυτό δεν σημαίνει πως η μακροπρόθεσμη πρόβλεψη δεν είναι εξίσου σημαντική, απλώς στην δεύτερη περίπτωση χρειάζεται να ληφθούν υπόψιν πολλοί άλλοι παράγοντες όπως η αγορά, ο στρατηγικός σχεδιασμός της επιχείρησης κλπ.
- Καμία πρόβλεψη δεν είναι τέλεια. Καθώς κάθε πρόβλεψη περιλαμβάνει το στοιχείο της αβεβαιότητας, η πρόβλεψη θα περιέχει κάποιο σφάλμα (δηλαδή

τη διαφορά μεταξύ της πρόβλεψης και της πραγματικότητας). Με βάση αυτό, στόχος της διαδικασίας πρόβλεψης είναι η ελαχιστοποίηση του σφάλματος για την όσο το δυνατόν ακριβέστερη προσέγγιση της πραγματικότητας.

- Συνδυασμός προβλέψεων. Ο συνδυασμός είναι ιδιαίτερα αποτελεσματικός όταν διατίθενται διαφορετικές μέθοδοι πρόβλεψης. Ιδανικά, πρέπει να χρησιμοποιούνται έως και 5 διαφορετικές μέθοδοι και να συνδυάζονται οι προβλέψεις τους χρησιμοποιώντας ένα προκαθορισμένο μηχανικό κανόνα. Εάν δεν υπάρχουν ισχυρές ενδείξεις ότι ορισμένες μέθοδοι είναι ακριβέστερες από άλλες, θα πρέπει να χρησιμοποιείται ένας απλός μέσος όρος των προβλέψεων. [10], [11], [12], [13]

### 3.3. Μέθοδοι Πρόβλεψης

#### 3.3.1. Λευκός Θόρυβος (*White Noise*)

Μια χρονοσειρά ονομάζεται λευκός θόρυβος αν δεν έχει κανένα ευκρινές σχήμα ή πρότυπο. Συμβολίζεται ως εξής:

$$Y(t)=\epsilon t$$

Όπου  $\epsilon t$  μία ακολουθία τυχαίων μεταβλητών με  $t = 0, \pm 1, \pm 2, \dots$ , για την οποία ισχύει ότι η μέση τιμή ίση με μηδέν και η διακύμανση είναι σταθερή όλες τις χρονικές στιγμές. Επιπλέον, όλες οι παρατηρήσεις της σειράς είναι ασυσχέτιστες μεταξύ τους, δηλαδή η αυτοσυνδιακύμανση της  $s$ -οστής είναι μηδενική.

$$E(\epsilon t) = 0$$

$$V(\epsilon t) = \sigma^2$$

$$\text{Cov}(\epsilon t, \epsilon t-s) = 0, s \neq 0$$

Άρα, μια τέτοια σειρά είναι πάντα στάσιμη και έχει μηδενικούς συντελεστές αυτοσυσχέτισης και μερικής αυτοσυσχέτισης. Χαρακτηριστικότερο παράδειγμα αποτελούν οι τυχεροί αριθμοί ΤΖΟΚΕΡ που καταγράφονται κάθε εβδομάδα. Σε αυτές τις περιπτώσεις οι προηγούμενες τιμές της χρονοσειράς δεν χρησιμεύουν και δεν σχετίζονται καθόλου με την πρόβλεψη των μελλοντικών τυχερών αριθμών που θα κληρωθούν.

#### 3.3.2. Τυχαίος Περίπατος (*Random Walk*)

Ο τυχαίος περίπατος (random walk) είναι μια μη-στάσιμη χρονοσειρά, όπου κάθε στοιχείο της  $y_t$  προκύπτει όταν στο προηγούμενο στοιχείο της  $y_{t-1}$  προστεθεί μια τυχαία μεταβλητή  $\epsilon t$ . Τέτοιες χρονοσειρές χαρακτηρίζονται από μακριές περιόδους, εμφανών τάσεων αυξητικών ή πτωτικών, με απότομες αλλαγές.


Δίνεται από την σχέση:

$$y_t = y_{t-1} + \epsilon t$$

Όπου  $\epsilon t$  η χρονοσειρά λευκού θορύβου. Αν υποθέσουμε ότι η τιμή  $y_0$  είναι μηδέν, τότε η χρονοσειρά του λευκού θορύβου είναι ανεξάρτητη από το  $y_0$ . Για το λόγο αυτό, η μέση τιμή του τυχαίου περιπάτου είναι μηδέν και η διακύμανση μεγαλώνει με το χρόνο.


$$E(y_t) = 0$$

$$V(y_t) = t \sigma^2$$



Εικόνα 4 Τυχαίος Περίπατος

Στην Εικόνα 3, ο συντελεστής αυτοσυσχέτισης υποδηλώνει την ύπαρξη υψηλής αυτοσυσχέτισης ως το lag = 8.



Εικόνα 5 Συνάρτηση Συντελεστή Αυτοσυσχέτισης Τυχαίου Περίπατου

### 3.3.3. Μέθοδοι Πρόβλεψης με Κινητούς Μέσους (Moving Average)

- Μέθοδος του Απλού Κινητού Μέσου (Simple Moving Average)

Είναι κατάλληλη για να απομακρύνει την τυχαία μεταβλητότητα στην πρόβλεψη, όταν η χρονοσειρά είναι στάσιμη, δηλαδή οι τιμές κυμαίνονται γύρω από έναν σταθερό μέσο όρο και κατ' επέκταση απουσιάζει η τάση και η εποχικότητα. Είναι πολύ σημαντικό να επιλεγεί το κατάλληλο διάστημα για τον κινητό μέσο. Όσο μεγαλύτερο είναι το επιλεγμένο διάστημα τόσο περισσότερο εξομαλύνεται το τυχαίο στοιχείο στην πρόβλεψη. Στα αρνητικά της μεθόδου είναι η εξάρτηση από η παρελθούσες παρατηρήσεις της σειράς, με ίδια βάρη σε όλες τις παρατηρήσεις, ακόμα και αν οι τελευταίες περιέχουν περισσότερη πληροφορία.

- Μέθοδος του Διπλού Κινητού Μέσου (Double Moving Average)

Η μέθοδος αυτή επιλέγεται για χρονοσειρές που εμφανίζουν ανοδική ή πτωτική γραμμική τάση. Υπολογίζεται ένας δεύτερος κινητός μέσος μετά τον απλό κινητό, λαμβάνοντας υπόψιν και την γραμμική τάση της χρονοσειράς. Η μέθοδος αυτή, μπορεί να χρησιμοποιηθεί για τη διενέργεια προβλέψεων για περισσότερες από μια μελλοντικές περιόδους ( $h > 1$ ), ενώ για  $h = 1$  δίνει την πρόβλεψη για την επόμενη περίοδο. [2]

### 3.3.4. Μέθοδος Απλής Εκθετικής Εξομάλυνσης (Exponential Smoothing Method)

Ο όρος «εκθετική εξομάλυνση» προκύπτει από το γεγονός ότι κάθε προσαύξηση στο παρελθόν μειώνεται κατά  $(1-\alpha)$ . Η σταθερά  $\alpha$  παίρνει τιμές από 0 έως 1. Συγκεκριμένα, αν η σταθερά  $\alpha$  ισούται με 0.05, τότε το βάρος της τελευταίας παρατήρησης θα είναι ίσο με  $\alpha(1-\alpha)^0$ , το βάρος της προτελευταίας θα είναι ίσο με  $\alpha(1-\alpha)^1$ , το βάρος της αμέσως προηγούμενης παρατήρησης θα είναι  $\alpha(1-\alpha)^2$  κ.ο.κ. Φυσικά, όλα τα βάρη αθροίζουν στη μονάδα ενώ το βάρος μειώνεται εκθετικά από την τιμή  $\alpha$  σε μικρότερες τιμές.

Ουσιαστικά, πρόκειται για έναν σταθμισμένο κινητό μέσο που υπακούει στη θεμελιώδη αρχή ότι η νέα πρόβλεψη ισούται με το άθροισμα της προηγούμενης και ενός ποσοστού του σφάλματος πρόβλεψης. Πιο συγκεκριμένα, ισχύει η σχέση:

$$F_t = \alpha X_t + (1-\alpha)F_{t-1}$$

όπου με  $F_t$  συμβολίζεται η εκθετικά εξομαλυμένη πρόβλεψη για την περίοδο  $t$  όπου  $t=1, \dots, n$ ,  $X_t$  είναι η πραγματική τιμή της μεταβλητής που σημειώθηκε κατά την περίοδο  $t$  και  $\alpha$  είναι μία σταθερά εξομάλυνσης.



### Σταθερά Εξομάλυνσης

Η σταθερά εξομάλυνσης παίρνει τιμές μεταξύ 0 και 1. Όσο πιο κοντά στη μονάδα βρίσκεται, τόσο μεγαλύτερη είναι η εξάρτηση της πρόβλεψης από τις τρέχουσες συνθήκες. Αντιθέτως, όσο μικρότερη είναι η τιμή της σταθεράς, τόσο πιο αμετάβλητη είναι η πρόβλεψη. Από την τιμή της εξαρτάται το επίπεδο της εξομάλυνσης και η ταχύτητα αντίδρασης σε πιθανές αποκλίσεις μεταξύ των προβλέψεων και των πραγματικών γεγονότων. Η τιμή της σταθεράς καθορίζεται τόσο από τη φύση του προϊόντος όσο και από την εκτίμηση του ερευνητή σχετικά με επιθυμητό ρυθμό απόκρισης στις αποκλίσεις.

#### 3.3.5. Εκθετική Εξομάλυνση με Προσαρμογή στην Τάση - Μέθοδος *Holt*

Η εκθετική εξομάλυνση με προσαρμογή στην τάση (Exponential Smoothing Adjusted for Trend), είναι γνωστή και ως μέθοδος Holt (Holt's Method). Πρόκειται για μία επέκταση της απλής εκθετικής εξομάλυνσης και χρησιμοποιείται όταν οι παρατηρήσεις της χρονοσειράς υποδεικνύουν την ύπαρξη γραμμικής τάσης. Η μέθοδος έχει δύο παραμέτρους εξομάλυνσης, την παράμετρο  $\alpha$  για την εξομάλυνση των τιμών της χρονοσειράς και την παράμετρο  $\beta$  για την εξομάλυνση της τάσης, οπότε αντίστοιχα χρησιμοποιούνται δύο εξισώσεις εξομάλυνσης. Φυσικά χρησιμοποιείται και μία εξίσωση για την τελική πρόβλεψη.

Η εφαρμογή της μεθόδου βασίζεται στην ακόλουθη διαδικασία:

- Γίνεται εξομάλυνση των παρατηρήσεων της χρονοσειράς με τη βοήθεια της σχέσης:

$$L_t = \alpha \cdot X_t + (1 - \alpha) \cdot (L_{t-1} + T_{t-1}), \quad t = 2, 3, \dots, n+1$$

όπου  $\alpha$  είναι η σταθερά για την εξομάλυνση των τιμών της χρονοσειράς,  $X_t$  είναι οι πραγματικές τιμές της χρονοσειράς για την περίοδο  $t$ ,  $T_t$  είναι η εκτίμηση της γραμμικής τάσης για την περίοδο  $t$  και τέλος με  $L_t$  συμβολίζεται η εξομαλυνθείσα τιμή της χρονοσειράς, δηλαδή η πρόβλεψη για την περίοδο  $t$  απαλλαγμένη από την προς τα εμπρός προβολή της γραμμικής τάσης για την επόμενη περίοδο.

Όπως φαίνεται, η εξίσωση ενσωματώνει με συντελεστή εξομάλυνσης  $\alpha$  την επίδραση της πραγματικής παρατήρησης για την περίοδο  $t$  και με συντελεστή  $(1 - \alpha)$  την επίδραση της απαλλαγμένης από την τάση πρόβλεψης για την προηγούμενη περίοδο και της γραμμικής τάσης επίσης για την προηγούμενη περίοδο.

- Έπειτα εφαρμόζεται πάλι εκθετική εξομάλυνση ώστε να εξομαλυνθεί η τάση με τη βοήθεια της σχέσης:

$$T_t = \beta \cdot (L_t - L_{t-1}) + (1 - \beta) \cdot T_{t-1}, \quad t = 2, 3, \dots, n+1$$

όπου  $\beta$  είναι η σταθερά για την εξομάλυνση της γραμμικής τάσης, ενώ οι υπόλοιπες μεταβλητές ορίστηκαν στο προηγούμενο βήμα. Η εξίσωση υπολογίζει την γραμμική τάση για την περίοδο  $t$  ενσωματώνοντας με συντελεστή  $\beta$  τη διαφορά των δύο τελευταίων εξομαλυνμένων (απαλλαγμένων από την τάση) προβλέψεων, η οποία αποτελεί την πλέον

πρόσφατη εκτίμηση της τάσης και με συντελεστή  $(1-\beta)$  τη γραμμική τάση της προηγούμενης περιόδου.

- Τέλος εξάγονται οι προβλέψεις συνυπολογίζοντας την επίδραση της γραμμικής τάσης από τη σχέση:

$$F_t = L_{t-1} + T_{t-1}, t=2,3,\dots,n+1$$

όπου στη βασική πρόβλεψη της εκθετικής εξομάλυνσης προστίθεται η γραμμική τάση για την ίδια περίοδο.

Οι συντελεστές εξομάλυνσης λαμβάνουν τιμές στο διάστημα  $(0,1)$  και φυσικά μπορούν να ισούται μεταξύ τους. Όμως, στην πλειοψηφία των εφαρμογών, η τιμή της  $\alpha$  επιλέγεται από το διάστημα  $[0.1, 0.3]$ , ενώ η τιμή της  $\beta$  επιλέγεται εμπειρικά ανάλογα με το πόσο έντονη είναι η γραμμική τάση που εμφανίζεται στο διάγραμμα διασποράς των παρατηρήσεων  $X_t$  της χρονοσειράς.

Σημαντικό σημείο της μεθόδου είναι η αρχικοποίηση των απαραίτητων μεταβλητών. Συνήθως ορίζουμε την αρχική τιμή της εξομαλυνθείσας πρόβλεψης (στην περίπτωση μας  $L_1$ ) να είναι ίση με την πραγματικής τιμή που εμφανίζεται στη χρονοσειρά για την αμέσως προηγούμενη περίοδο από την περίοδο που επιθυμούμε να εξετάσουμε. Η αρχικοποίηση της γραμμικής τάσης είναι περισσότερο περίπλοκη. Ως αρχική τιμή της γραμμικής τάσης χρησιμοποιείται η συνολική μεταβολή των τιμών της χρονοσειράς διαιρεμένη με το πλήθος των μεταβολών που σημειώθηκαν. Δηλαδή θεωρούμε σαν αρχική γραμμική τάση τον μέσο όρο μεταβολής, κάνοντας την παραδοχή ότι η γραμμική τάση παραμένει σταθερή για όλες τις μεταβολές μεταξύ των περιόδων στη χρονοσειρά.

### *3.3.6. Εκθετική Εξομάλυνση με προσαρμογή στην τάση και στην εποχικότητα –*

#### *Μέθοδος Winters*

Η ύπαρξη εποχικότητας στις παρατηρήσεις χρονοσειρών είναι συχνό φαινόμενο κατά τη διερεύνηση οικονομικών φαινομένων και για να εξεταστεί, θα πρέπει πρώτα να εξομαλυνθεί με την βοήθεια κάποιας κατάλληλης μεθόδου που μπορεί να την ενσωματώσει άμεσα. Η πλέον κατάλληλη μέθοδος για τον σκοπό αυτό είναι η εκθετική εξομάλυνση με προσαρμογή στην τάση και στην εποχικότητα (Exponential Smoothing Adjusted for Trend and Seasonality), γνωστή και ως μέθοδος Winters (Winters Method). Πρόκειται για μία επέκταση της μεθόδου Holt (η οποία με τη σειρά της αποτελεί, όπως είπαμε, επέκταση της απλής εκθετικής εξομάλυνσης) και χρησιμοποιείται όταν οι παρατηρήσεις της χρονοσειράς εκτός από γραμμική τάση υποδεικνύουν και την ύπαρξη εποχικότητας.

Η μέθοδος χρησιμοποιεί τρεις παραμέτρους εξομάλυνσης, τις  $\alpha, \beta$  και  $\gamma$ , οι οποίες βοηθούν στην εξομάλυνση των τιμών της χρονοσειράς, της τάσης και της εποχικότητας αντίστοιχα. Δηλαδή, έχουμε τις παραμέτρους της μεθόδου Holt, αλλά τώρα εισάγουμε μία επιπλέον παράμετρο. Αυτό σημαίνει ότι σημαίνει ότι χρησιμοποιεί επίσης μία επιπλέον σχέση από τη μέθοδο Holt, αυτή για την εξομάλυνση της εποχικότητας.

Η εφαρμογή της μεθόδου βασίζεται στην ακόλουθη διαδικασία:

- Γίνεται εξομάλυνση των τιμών της χρονοσειράς με τη βοήθεια της σχέσης:

$$L_t = \alpha \cdot X_t + E_{t-N} + (1-\alpha) \cdot (L_{t-1} + T_{t-1}), \quad t=1,2,\dots,n$$

όπου  $\alpha$  είναι η σταθερά για την εξομάλυνση των τιμών της χρονοσειράς,  $X_t$  είναι η πραγματική τιμή της χρονοσειράς για την περίοδο  $t$ ,  $E_t$  είναι ο δείκτης εποχικότητας για την περίοδο  $t$ ,  $T_t$  είναι η εκτίμηση της γραμμικής τάσης για την περίοδο  $t$  και τέλος με  $L_t$  συμβολίζεται η εξομαλυνθείσα τιμή της χρονοσειράς.

Παρατηρούμε ότι στην σχέση χρησιμοποιείται ο όρος  $E_{t-N}$  αντί του  $E_t$  (όπου  $N$  είναι ο αριθμός των περιόδων σε έναν ολόκληρο κύκλο εποχικότητας). Αυτό συμβαίνει καθώς η πιο πρόσφατη πληροφορία για τη συγκεκριμένη περίοδο, όταν στα δεδομένα υπάρχει εποχικότητα, είναι η πληροφορία για την αντίστοιχη περίοδο του προηγούμενου κύκλου, δηλαδή η τιμή  $E_{t-N}$ .

- Γίνεται εξομάλυνση της τάσης ακριβώς όπως στη μέθοδο Holt, δηλαδή με χρήση της σχέσης:

$$T_t = \beta \cdot (L_t - L_{t-1}) + (1-\beta) \cdot T_{t-1}, \quad t=1,2,\dots,n$$

όπου  $\beta$  είναι όπως είπαμε η σταθερά για την εξομάλυνση της τάσης.

- Η εξομάλυνση της εποχικότητας γίνεται ως ακολούθως:

$$E_t = \gamma \cdot X_t \cdot T_t + (1-\gamma) \cdot E_{t-N}, \quad t=1,2,\dots,n$$

όπου  $\gamma$  η σταθερά για την εξομάλυνση της εποχικότητας

- Η πρόβλεψη γίνεται με τη βοήθεια της σχέσης:

$$F_t = (L_{t-1} + T_{t-1}) \cdot E_{t+1-N}, \quad t=2,3,\dots,n$$

Οι συντελεστές εξομάλυνσης  $\alpha, \beta$  και  $\gamma$  λαμβάνουν τιμές στο διάστημα  $(0,1)$ . Συνήθως όμως, ο συντελεστής  $\gamma$  λαμβάνει μεγαλύτερη τιμή αυτή των  $\alpha$  και  $\beta$  καθώς οι δείκτες εποχικότητας επικαιροποιούνται μόνο μία φορά ανά κύκλο, σε αντίθεση με τις προβλέψεις εκθετικής εξομάλυνσης και γραμμικής τάσης που ανανεώνονται σε κάθε περίοδο. Όπως αναφέραμε στα πλαίσια της προηγούμενης μεθόδου, η τιμή της  $\alpha$  επιλέγεται στο διάστημα  $[0.1, 0.3]$  ενώ η τιμή της  $\beta$  επιλέγεται ανάλογα με το πόσο έντονη είναι η γραμμική τάση στα δεδομένα της χρονοσειράς. Όσο αναφορά την τιμή της σταθεράς  $\gamma$ , αυτή συνήθως επιλέγεται στο διάστημα  $[0.2, 0.6]$ .

Για να εκκινήσει η διαδικασία της πρόβλεψης, χρειάζεται να προσδιοριστούν οι αρχικές τιμές  $L_0, T_0$ . Γενικά δεν υπάρχει μοναδικός τρόπος αρχικοποίησης των μεταβλητών αυτών. Ο ερευνητής συνήθως προσδιορίζει τις τιμές αυτές εμπειρικά, ανάλογα με τη μορφή των δεδομένων που διαθέτει (για παράδειγμα πλήθος κύκλων εποχικότητας). [14]

### 3.3.7. Μοντέλα για Στάσιμες Χρονοσειρές

#### Αυτοπαλίνδρομα Μοντέλα (Autoregressive (AR) Models)

Ένα Αυτοπαλίνδρομο Υπόδειγμα τάξης  $p$  (AR( $p$ )) ορίζεται από την σχέση:

$$Y_t = a_0 + a_1 Y_{t-1} + \dots + a_p Y_{t-p} + \varepsilon_t$$

Η παράμετρος  $a_0$  σχετίζεται με τη μέση τιμή της χρονοσειράς και τα  $a_1, \dots, a_p$  είναι αυτοπαλινδρομούμενοι παράμετροι. Το  $p$  υποδηλώνει την τάξη του αυτοπαλινδρομου μοντέλου και αναφέρεται στο μήκος της χρονικής υστέρησης. Η μεταβλητή  $\varepsilon_t$  θεωρείται ότι είναι λευκός θόρυβος. Ο όρος αυτοπαλίνδρομο δημιουργείται επειδή η εξαρτημένη μεταβλητή  $Y_t$  παλινδρομεί τις προηγούμενες τιμές της της της μεταβλητής  $Y_t$ .

AR (1):


Εάν η τάξη είναι  $p=1$ , το μοντέλο δίνεται από την σχέση:

$$Y_t = a_0 + a_1 Y_{t-1} + \varepsilon_t$$

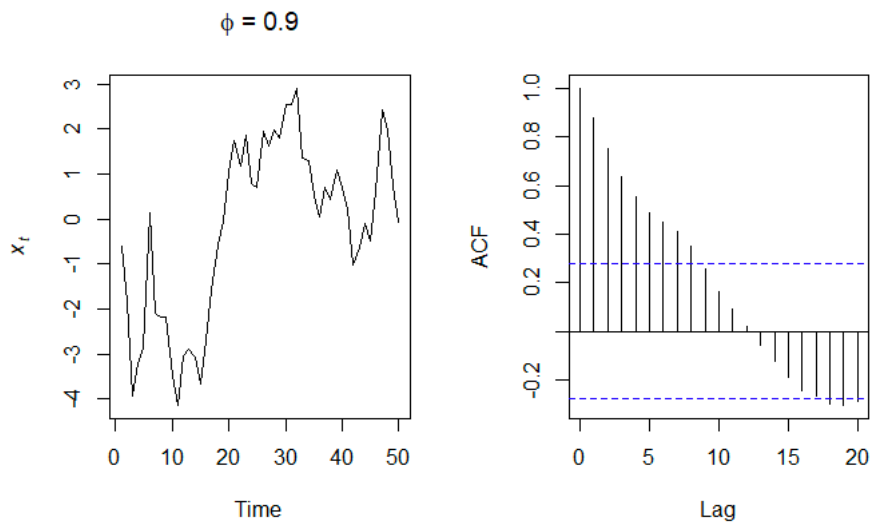
Ο συντελεστής  $a_1$  παίρνει τιμές ανάμεσα στο  $-1$  και  $1$ . Για  $a_1=0$  το μοντέλο είναι ισοδύναμο με ένα μοντέλο λευκού θορύβου, ενώ για  $a_1=1$  το μοντέλο είναι ισοδύναμο με ένα μοντέλο τυχαίου περιπάτου.

Γενικά, ένα AR( $p$ ) μοντέλο χρησιμοποιείται όταν οι συντελεστές αυτοσυσχέτισης φθίνουν εκθετικά στο μηδέν και ταυτόχρονα υπάρχουν  $p$  στατιστικοί σημαντικοί συντελεστές μερικής αυτοσυσχέτισης.

Παρακάτω αναπαρίσταται ένα μοντέλο AR (1), στο πρώτο σχήμα με μικρό δείκτη coefficient = 0.1 και στο δεύτερο με coefficient = 0.9.



Εικόνα 6 AR(1) με coefficient 0.1



Εικόνα 7 AR(1) με coefficient 0.9

Βάσει των γραφημάτων, παρατηρούμε ότι η χρονοσειρά με το μικρότερο AR coefficient, παραμένει κοντά στην περιοχή του 0, γεγονός που υποδηλώνει ότι ακολουθεί την λογική Λευκού Θορύβου και είναι στάσιμη χρονοσειρά, ως της τη μέση τιμή και ως της την διακύμανση. Εν αντίθεσή, η χρονοσειρά με μεγαλύτερο coefficient που τείνει στο 1, κινείται περισσότερο στο χώρο και ακολουθεί την λογική Τυχαίου Περιπάτου ως της τη μέση τιμή και διακύμανση ταυτόχρονα.

#### Κινητοί Μέσοι (Moving Average (MA) Models)

Ένα Υπόδειγμα Κινητών Μέσων τάξης q (MA(q)) ορίζεται από την σχέση:

$$Y_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q}$$

Όπου οι παράμετροι  $\mu$  και τα  $\theta_1, \theta_q$  είναι οποιοδήποτε πραγματικοί αριθμοί. Το q υποδηλώνει την τάξη της υψηλότερης υστέρησης, για την οποία γίνεται υπόθεση ότι είναι λευκός θόρυβος και το  $\varepsilon_t$  είναι η χρονοσειρά του λευκού θορύβου. Ο όρος κινητός μέσος οφείλεται στο γεγονός ότι η  $Y_t$  εμφανίζεται ως ένα σταθμισμένο άθροισμα των τιμών της  $\varepsilon_t$ .


MA (1):

Εάν η τάξη είναι q=1, το μοντέλο δίνεται από την σχέση:

$$Y_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1}$$

Η παρατήρηση  $Y_t$  εξαρτάται από την προηγούμενη παρατήρηση και την επόμενη. Για παράδειγμα η  $Y_3$  θα εξαρτάται από την  $Y_2$  και την  $Y_4$ . Ο συντελεστής  $\theta_1$  παίρνει τιμές από -1 μέχρι 1. Μια  $MA(1)$  διαδικασία μπορεί να χαρακτηριστεί ως αντιστρέψιμη, αν μπορεί να διατυπωθεί ως μία αυτοπαλίνδρομη διαδικασία με άπειρους όρους. Σε αυτή την περίπτωση η  $MA(1)$  μετατρέπεται σε  $AR(\infty)$ .

Γενικά, ένα μοντέλο  $MA(q)$  χρησιμοποιείται όταν οι συντελεστές μερικής αυτοσυσχέτισης φθίνουν εκθετικά στο μηδέν και συγχρόνως υπάρχουν  $q$  στατιστικοί σημαντικοί συντελεστές αυτοσυσχέτισης. Επιπρόσθετα, οι κινητοί μέσοι χρησιμοποιούνται για χρονοσειρές όπου τα γεγονότα επηρεάζουν άμεσα τη στιγμή που συμβαίνουν, αλλά μετά το τέλος των γεγονότων, τα αποτελέσματα συνεχίζουν να επηρεάζουν. Ένα τέτοιο παράδειγμα είναι, η οικονομία που επηρεάζεται κατά την διάρκεια της πανδημίας του κορωνοϊού, αλλά και κατά της επόμενους μήνες ακόμα και όταν θα έχει ξεπεραστεί.



Εικόνα 8  $MA(1)$  με coefficient 0.9

Παρατηρείται ότι για  $lag > q$  ο  $acf$  δείκτης τείνει στο 0.

### Αυτοπαλινδρόμενοι Κινητοί Μέσοι Όροι (Autoregressive Moving Average (ARMA) Models)

Ορισμένες χρονοσειρές δεν μπορούν να μοντελοποιηθούν αποκλειστικά ως  $AR(p)$  ή  $MA(q)$  χρονοσειρές, εφόσον μπορεί να παρουσιάζουν χαρακτηριστικά και από της δύο κατηγορίες. Για το λόγο αυτό δημιουργείται το μοντέλο Αυτοπαλινδρόμενοι Κινητοί Μέσοι Όροι (ARMA) που έρχεται να περιγράψει τέτοιες χρονοσειρές.

Το μοντέλο  $ARMA(p,q)$  ορίζεται από την σχέση:

$$Y_t = a_0 + a_1 Y_{t-1} + \dots + a_p Y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q}$$

Οι παράμετροι  $a_i$  και  $\theta_i$  περιορίζονται στο  $(-1,1)$ . Ουσιαστικά το μοντέλο είναι ο συνδυασμός  $p$  αυτοπαλίνδρομων όρων και  $q$  όρων κινητού μέσου. Η στασιμότητα της χρονοσειράς ορίζεται από το  $AR$  μέρος και η αντιστρεψιμότητα από το  $MA$  μέρος. Είναι προφανές ότι ένα καθαρά αυτοπαλίνδρομο μοντέλο ή ένα καθαρό μοντέλο κινητού μέσου μπορούν να θεωρηθούν ως ειδικές περιπτώσεις μιας  $ARMA$  χρονοσειράς ως εξής:

$$AR(p) = ARMA(p, 0)$$

$$MA(q) = ARMA(0, q)$$

#### 3.3.8. Μοντέλα για Μη Στάσιμες Χρονοσειρές

Τα τρία τελευταία μοντέλα που παρουσιάστηκαν αναφέρονται όλα σε στάσιμες χρονοσειρές, γεγονός που υποδηλώνει ότι ο μέσος, η διακύμανση και οι

αυτοδιακυμάνσεις δεν εξαρτώνται από το χρόνο. Ο μέσος και η διακύμανση παραμένουν σταθεροί, ενώ οι αυτοδιακυμάνσεις εξαρτώνται μόνο από τη χρονική υστέρηση.

Είναι σημαντικό κατά την διαδικασία πρόβλεψης η χρονοσειρά να είναι στάσιμη προκειμένου να αποφευχθούν διάφορα λάθη. Ωστόσο, στην πραγματικότητα οι περισσότερες χρονοσειρές, όπως δείκτες τιμών, ανεργία, οικονομικές χρονοσειρές, στην αρχική τους μορφή είναι μη στάσιμες, για το λόγο αυτό χρειαζόμαστε έναν τρόπο για να τις μετατρέψουμε σε στάσιμες.

#### **Μετατροπή Μη Στάσιμης Χρονοσειράς σε Στάσιμη**

Μία μη στάσιμη χρονοσειρά μετατρέπεται σε στάσιμη παίρνοντας τις απαραίτητες διαφορές. Όταν μια χρονοσειρά μετατρέπεται σε στάσιμη, παίρνοντας τις πρώτες διαφορές η σειρά ονομάζεται ολοκληρωμένη πρώτης τάξης και συμβολίζεται με  $I(1)$ . Εάν μετατρέπεται σε στάσιμη παίρνοντας τις δεύτερες διαφορές, είναι ολοκληρωμένη δεύτερης τάξης και συμβολίζεται με  $I(2)$ . Μια στάσιμη σειρά, όπως ο λευκός θόρυβος, θεωρείται ολοκληρωμένη σειρά μηδενικής τάξεως δηλαδή  $I(0)$ . Γενικεύοντας, εάν  $d$  είναι ο αριθμός των διαφορών που μετατρέπει μια χρονοσειρά σε στάσιμη, η σειρά ονομάζεται ολοκληρωμένη  $d$  τάξεως (integrated order) και συμβολίζεται με  $I(d)$ .

Ορίζεται από την σχέση:

$$\Delta y = y_t - y_{t-1}$$

#### **Ανάλυση ARIMA (Autoregressive Intergated Moving Average)**

Τα μοντέλα ARIMA περιγράφουν την διαχρονική συμπεριφορά ενός φυσικού μεγέθους. Χρησιμοποιούνται για να προβλέψουν τις μελλοντικές τιμές μίας στάσιμης σειράς, λαμβάνοντας υπόψιν τις παρελθοντικές τιμές. Για παράδειγμα, για μία τυχαία χρονοσειρά, τα μοντέλα ARIMA βασίζονται στην αλληλεξάρτηση μεταξύ των τιμών που λαμβάνει η χρονοσειρά για τις διάφορες χρονικές στιγμές. Τα ARMA μοντέλα που είδαμε παραπάνω μπορούν να χρησιμοποιηθούν μόνο για στάσιμες χρονοσειρές, αλλά επεκτείνονται και σε μη στάσιμες χρονοσειρές με τη χρήση της μεθόδου των διαφορών. Σε αυτή την περίπτωση τα μοντέλα μετατρέπονται σε ολοκληρωμένα αυτοπαλίνδρομα μοντέλα κινητού μέσου τάξεως ( $p, d, q$ ) και συμβολίζονται με ARIMA( $p, d, q$ ). Συνεπώς, το μοντέλο ARIMA( $p, d, q$ ), είναι μια διαδικασία που διαφορίζει την σειρά  $d$  φορές και παράγει εντέλει ένα ARMA( $p, q$ ) μοντέλο.

Συγκεκριμένα, οι τρεις παράμετροι αυτού του μοντέλου είναι: [12]

AR :  $p$  = δηλώνει την τάξη του αυτοπαλίνδρομου μοντέλου

I :  $d$  = δείχνει τον αριθμό των διαφορών (η τάξη της διαφόρισης) που απαιτούνται για να γίνει η σειρά στάσιμη

MA :  $q$  = που δηλώνει την τάξη του κινητού μέσου

Ειδικές Περιπτώσεις

ARIMA(0,0,0) = Λευκός Θόρυβος

ARIMA(0,1,0) = Τυχαίος Περίπατος

ARIMA (1,0,0) = AR (1)

ARIMA (0,0,1) = MA (1)

#### **Μέθοδος Box-Jenkins**

Τα μοντέλα ARIMA έχουν μελετηθεί εκτεταμένα από τους Box και Jenkins (1970), σε βαθμό που τα ονόματά τους είναι άρρηκτα συνδεδεμένα με τα μοντέλα ARIMA και τις εφαρμογές τους στην ανάλυση και την πρόβλεψη χρονοσειρών. Η προσέγγιση

Box-Jenkins αποτελεί μία μέθοδο εύρεσης του κατάλληλου στατιστικού μοντέλου ARIMA, που παριστάνει όσο πιο ρεαλιστικά γίνεται την διαδικασία από την οποία προήλθαν τα δεδομένα και θεωρείται ως καταλληλότερο μοντέλο, για την εκάστοτε σειρά, για την διαμόρφωση των προβλέψεων. Η μέθοδος αυτή εφαρμόζεται όταν η χρονοσειρά δεν είναι στάσιμη και περιλαμβάνει τα εξής τέσσερα στάδια:

#### **Ταυτοποίηση**

Σε αυτό το στάδιο καθορίζονται οι τιμές των παραμέτρων  $p$ ,  $d$ ,  $q$ . Αρχικά, ελέγχεται με την βοήθεια των συντελεστών αυτοσυσχέτισης αν η σειρά είναι στάσιμη. Αν είναι στάσιμη στο  $d$  αντιστοιχεί 0, καθώς δεν απαιτείται καμία διαφόριση προκειμένου να γίνει στάσιμη. Ωστόσο, αν είναι μη στάσιμη, πρέπει να πάρουμε τις κατάλληλες διαφορές προκειμένου να την μετατρέψουμε σε στάσιμη. Εν συνεχεία, καθορίζεται η τάξη  $p$  της αυτοπαλίνδρομης διαδικασίας και η τάξη  $q$  της διαδικασίας κινητού μέσου.

#### **Εκτίμηση**

Σ' αυτό το στάδιο γίνεται η εκτίμηση των  $p$  παραμέτρων  $\alpha_0, \alpha_1, \dots, \alpha_p$  της αυτοπαλίνδρομης διαδικασίας και των  $q$  παραμέτρων  $\theta_0, \theta_1, \dots, \theta_q$  της διαδικασίας κινητού μέσου. Αν η σειρά που εξετάζεται είναι μόνο αυτοπαλίνδρομη, οι παράμετροί της, μπορούν να εκτιμηθούν με τη μέθοδο των ελαχίστων τετραγώνων. Αν όμως, περιέχει και όρους κινητού μέσου τότε για την εκτίμηση των παραμέτρων του κινητού μέσου θα χρησιμοποιηθούν μη γραμμικές μέθοδοι εκτίμησης.



### Διαγνωστικός Έλεγχος

Σ' αυτό το στάδιο ελέγχεται αν το συγκεκριμένο υπόδειγμα ARIMA που προσδιορίστηκε παραπάνω είναι ικανοποιητικό και ταιριάζει (fitting) στα δεδομένα μας, για τις μελλοντικές προβλέψεις. Ελέγχεται ως προς την σημαντικότητα και τη σταθερότητα των συντελεστών του υποδείγματος, τις ιδιότητες των καταλοίπων και την προβλεπτική ικανότητα του υποδείγματος. Ο έλεγχος της σημαντικότητας ενός αριθμού συντελεστών αυτοσυσχέτισης γίνεται παράλληλα με τον έλεγχο των καταλοίπων. Μία διαδικασία ARIMA ταιριάζει κατάλληλα στη σειρά, όταν τα κατάλοιπα συμπεριφέρονται σαν μία διαδικασία λευκού θορύβου, δηλαδή δεν αυτοσυσχετίζονται μεταξύ τους. Αυτός ο έλεγχος γίνεται με την στατιστική διαδικασία Q των Box-Pierce. Η μηδενική υπόθεση είναι :

$H_0 = \rho_1, \rho_2, \dots, \rho_m = 0$ , όπου  $\rho_i, i = 1, 2, \dots, m$  οι συντελεστές αυτοσυσχέτισης.

Η στατιστική Q των Box-Pierce ορίζεται ως:

$$QBP = T \sum_{s=2}^m \hat{\rho}^2$$

Όπου  $\hat{\rho}_s$  είναι δειγματικές αυτοσυσχετίσεις των καταλοίπων και T ο αριθμός των παρατηρήσεων. Ο αριθμός των αυτοσυσχετίσεων ισούται με την τετραγωνική ρίζα του αριθμού των παρατηρήσεων, δηλαδή ισχύει  $m = \sqrt{T}$ . Η στατιστική QBP ακολουθεί την κατανομή  $\chi^2$  με  $m - p - q$  βαθμούς ελευθερίας. Η μηδενική υπόθεση θα απορρίπτεται αν η τιμή QBP είναι μεγαλύτερη από την κρίσιμη τιμή της κατανομής  $\chi^2$ , για δεδομένο επίπεδο σημαντικότητας  $\alpha$ . Οπότε θα ισχύουν τα παρακάτω:

Απόρριψη :  $H_0$ , αν  $QBP > \chi^2_{\alpha}$

Αποδοχή :  $H_0$ , αν  $QBP \leq \chi^2_{\alpha}$

Επιπλέον, σ' αυτό το στάδιο γίνεται ο έλεγχος της τάξης του υποδείγματος, μέσω της διαδικασίας της υπερπροσαρμογής (overfitting). Προκειμένου να ελεγχθεί η καταλληλότητα του εκτιμώμενου υποδείγματος, συγκρίνεται με ένα άλλο μοντέλο μεγαλύτερης τάξης. Δηλαδή, το εκτιμώμενο υπόδειγμα ARMA(p, q), συγκρίνεται με τα υποδείγματα ARIMA(p+1, q) και ARIMA(p, q+1) της αμέσως επόμενης τάξης. Το εκτιμώμενο υπόδειγμα είναι το καταλληλότερο για τα δεδομένα μας, αν οι συντελεστές στα μεγαλύτερα υποδείγματα δεν στατιστικά διαφορετικοί από το μηδέν. Αν αυτοί οι συντελεστές δεν είναι μηδέν, τότε υπάρχει κάποιο άλλο υπόδειγμα που να είναι πιο κατάλληλο για τα δεδομένα μας, απ' ότι το εκτιμημένο.

### Πρόβλεψη

Γνωρίζοντας πλέον το εκτιμώμενο υπόδειγμα και τις υπάρχουσες πληροφορίες για μια χρονοσειρά, μπορεί να παραχθεί η πρόβλεψη για τις επόμενες ζητούμενες περιόδους

### Ανάλυση SARIMA (Seasonal Autoregressive Intergated Moving Average)

Τα μοντέλα SARIMA είναι μια άλλη κατηγορία των υποδειγμάτων ARIMA. Όταν μία σειρά έχει δεδομένα μικρής διάρκειας, όπως μηνιαία, τριμηνιαία τότε την χαρακτηρίζει η εποχικότητα. Το εποχικό μέρος του υποδείγματος ARIMA έχει παρόμοια δομή με αυτή ενός μη εποχικού υποδείγματος και γράφεται ως SARIMA (Sp, Sd, Sq) x ARIMA (p, d, q). Στο εποχικό μέρος διεξάγονται πολλαπλασιασμοί της χρονικής υστέρησης S (δηλαδή τον αριθμό των περιόδων για μια εποχή) με τους συντελεστές p που είναι ο αριθμός των αυτοπαλίνδρομων εποχικών όρων (SAR), τον αριθμό των εποχικών διαφορών d και το εύρος των στοιχείων των εποχικών όρων του κινητού μέσου q (SMA).

Σε τέτοιες σειρές, μπορεί να αφαιρεθεί η εποχικότητα και στη συνέχεια να χρησιμοποιηθεί η μέθοδος των Box-Jenkins ή, επικρατέστερη είναι η μέθοδος η οποία ενσωματώνει το εποχικό πρότυπο των στοιχείων στο κανονικό υπόδειγμα ARIMA και χρησιμοποιεί την μεθοδολογία Box-Jenkins. Η μέθοδος αυτή καταλήγει στην εκτίμηση υποδειγμάτων με περισσότερες παραμέτρους. [2], [18], [19], [20], [21]

### 3.4. Αιτιακές Μέθοδοι Πρόβλεψης (Casual Forecasting Methods)

Πολλές φορές, η μεταβλητή ενδιαφέροντος έχει άμεση σχέση με μία ή περισσότερες άλλες μεταβλητές. Σε αυτή την περίπτωση η πρόβλεψη γίνεται με τη βοήθεια της ανάλυσης παλινδρόμησης. Η μεταβλητή που επιθυμούμε να προβλέψουμε ονομάζεται εξαρτημένη μεταβλητή καθώς η τιμή της εξαρτάται από τις τιμές άλλων μεταβλητών, τις οποίες χρειάζεται να γνωρίζουμε προκειμένου να εξάγουμε την πρόβλεψη. Οι μεταβλητές αυτές ονομάζονται αντίστοιχα ανεξάρτητες. Αυτού του είδους η προσέγγιση ονομάζεται αιτιακή πρόβλεψη.

Η ανάλυση παλινδρόμησης είναι μία στατιστική διαδικασία για τον προσδιορισμό της μαθηματικής σχέσης που συνδέει την ανεξάρτητη με τις εξαρτημένες μεταβλητές. Η απλή παλινδρόμηση περιλαμβάνει μία μόνο ανεξάρτητη μεταβλητή, για παράδειγμα την τιμή ή το μέγεθος της διαφήμισης σε μία συνάρτηση ζήτησης ενώ η πολλαπλή παλινδρόμηση περιλαμβάνει δύο ή περισσότερες μεταβλητές, στο προηγούμενο παράδειγμα τόσο την τιμή και όσο και το μέγεθος της διαφήμισης.

Στη συνέχεια, θα επικεντρωθούμε σε αιτιακές προβλέψεις όπου η μαθηματική σχέση που συνδέει την εξαρτημένη με τις ανεξάρτητες μεταβλητές θεωρείται γραμμική. Η ανάλυση που εφαρμόζεται σε αυτή την περίπτωση ονομάζεται γραμμική παλινδρόμηση.

#### 3.4.1. Απλή Γραμμική Παλινδρόμηση (Simple Linear Regression)

Το μοντέλο αυτό προκύπτει όταν το υπό μελέτη σύστημα περιλαμβάνει μία ανεξάρτητη μεταβλητή ενώ η μαθηματική σχέση που τη συνδέει με την εξαρτημένη μεταβλητή θεωρείται γραμμική. Σκοπός μας είναι η προσαρμογή μιας ευθείας γραμμής, η οποία επεξηγεί όσο το δυνατόν καλύτερα τη συμπεριφορά των δεδομένων μας. Αν ορίσουμε ως  $X$  την ανεξάρτητη μεταβλητή και  $Y$  την εξαρτημένη μεταβλητή (μεταβλητή ενδιαφέροντος), τότε η ευθεία θα έχει τη μορφή:

$$E(Y|X)=a+bX,$$

όπου οι σταθερές  $a$  και  $b$  αποτελούν τις παραμέτρους του μοντέλου ή αλλιώς τους συντελεστές παλινδρόμησης. Η παραπάνω σχέση είναι μία στατιστική σχέση που περιγράφει την αναμενόμενη τιμή της  $Y$  όταν γνωρίζουμε την τιμή της  $X$ .

Η προσαρμογή της καλύτερης ευθείας, δηλαδή η καλύτερη δυνατή εκτίμηση των παραμέτρων γίνεται λαμβάνοντας υπόψη τις  $n$  ανεξάρτητες παρατηρήσεις  $(X_i, Y_i), i=1, \dots, n$  που έχουμε στη διάθεσή μας προς επεξεργασία για τις οποίες υποθέτουμε ότι δεν υπόκεινται σε σφάλματα μέτρησης. Φυσικά, τα σημεία  $(X_i, Y_i)$  είναι πιθανό να διαφέρουν από τα σημεία  $(X_i, \hat{Y}_i)$ , όπου  $\hat{Y}_i = \hat{a} + \hat{b} X_i$  είναι η εκτίμηση της τιμής της τυχαίας μεταβλητής  $Y$  με βάση το απλό γραμμικό μοντέλο που προσαρμόσαμε στα δεδομένα μας και  $\hat{a}, \hat{b}$  οι εκτιμήσεις των παραμέτρων του μοντέλου. Οι παρατηρήσεις  $Y_i$  δίνονται από τη παρακάτω σχέση:

$$Y_i = E(Y_i | X_i) + \epsilon_i = a + b X_i + \epsilon_i,$$

όπου το  $\epsilon_i$  ονομάζεται τυχαίο σφάλμα και παριστάνει για δοθείσα τιμή  $X_i$  την κατακόρυφη απόσταση της τιμής  $Y_i$  από την ευθεία της συνάρτησης παλινδρόμησης

που είναι ακόμα άγνωστη. Σημειώνεται ότι το τυχαίο σφάλμα δεν πρέπει να συγγέεται με τη διαφορά  $e_i = Y_i - \hat{Y}_i = Y_i - \hat{a} - \hat{b}X_i$ , η οποία ονομάζεται υπόλοιπο και αποτελεί την κατακόρυφη απόκλιση του  $Y_i$  από την ευθεία της εκτιμημένης συνάρτησης παλινδρόμησης. Τα  $e_i$  μπορούν να θεωρηθούν ως οι εκτιμήσεις των άγνωστων τυχαίων σφαλμάτων  $e_i$ . Ο υπολογισμός των παραμέτρων του μοντέλου μπορεί να γίνει με τη μέθοδο ελαχίστων τετραγώνων που παρουσιάζεται στη συνέχεια.

### Μέθοδος Ελαχίστων Τετραγώνων

Πρόκειται για μία ευρέως χρησιμοποιούμενη μέθοδο στην ανάλυση παλινδρόμησης. Σκοπός είναι να εκτιμήσουμε τις παραμέτρους του μοντέλου της παλινδρόμησης, δηλαδή τους συντελεστές  $\alpha$  και  $\beta$ , κατά τέτοιο τρόπο, ώστε η ευθεία γραμμή που θα προκύψει να περιγράφει κατά τον καλύτερο δυνατό τρόπο τη σχέση μεταξύ των μεταβλητών  $X$  και  $Y$ . Η γραμμή της παλινδρόμησης πρέπει να περνάει κοντά από τα σημεία που αντιστοιχούν στα ζεύγη των παρατηρήσεων  $(X_i, Y_i)$ , έτσι ώστε να ελαχιστοποιούνται τα σφάλματα της πρόβλεψης.

Για να περιγράψουμε τη μέθοδο χρειάζεται πρώτα να ορίσουμε το σφάλμα ως τη διαφορά μεταξύ της πραγματικής και της εκτιμώμενης τιμής. Αν συμβολίσουμε το σφάλμα με  $e$ , τότε έχουμε:

$Y$  = πραγματική τιμή της εξαρτημένης μεταβλητής (παρατήρηση)

$\hat{Y}$  = αναμενόμενη τιμή της εξαρτημένης μεταβλητής που προέκυψε από τη σχέση  $\hat{Y} = \hat{a} + \hat{b}X$

$e = Y - \hat{Y}$ , σφάλμα πρόβλεψης

Η μέθοδος ελαχίστων τετραγώνων έγκειται στην ελαχιστοποίηση της παράστασης

$$U = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (Y_i - \hat{a} - \hat{b}X_i)^2$$

δηλαδή στην ελαχιστοποίηση του αθροίσματος των τετραγώνων των σφαλμάτων πρόβλεψης. Ουσιαστικά, με αφετηρία το διάγραμμα διασποράς ενός δείγματος τιμών  $(X_i, Y_i)$ , η μέθοδος προσαρμόζει σε αυτό μία ευθεία γραμμή έτσι ώστε το άθροισμα των τετραγώνων των κάθετων αποκλίσεων των  $Y_i$  από αυτή να ελαχιστοποιείται. Έπειτα, ακολουθώντας τη συνηθισμένη διαδικασία για τον υπολογισμό ελαχίστων τιμών, δηλαδή παραγωγίζοντας το  $U$  ως προς  $\hat{a}$  και ως προς  $\hat{b}$ , και θέτοντας στη συνέχεια αυτές τις παραγώγους ίσες με μηδέν καταλήγουμε εύκολα σε ένα ζεύγος εξισώσεων, τις κανονικές εξισώσεις:

$$\begin{aligned} n\hat{a} + \hat{b} \sum_{i=1}^n X_i &= \sum_{i=1}^n Y_i \\ \hat{a} \sum_{i=1}^n X_i + \hat{b} \sum_{i=1}^n X_i^2 &= \sum_{i=1}^n X_i Y_i \end{aligned}$$

από τις οποίες λαμβάνουμε τις εκτιμήσεις για τα  $\hat{a}, \hat{b}$  από τις σχέσεις:

$$\hat{b} = \frac{\sum_{i=1}^n X_i Y_i - n\bar{X}\bar{Y}}{\sum_{i=1}^n X_i^2 - n\bar{X}^2} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_{i=1}^n (X_i - \bar{X})^2}$$


και

$$\hat{a} = \bar{Y} - \hat{b}\bar{X}$$

όπου

$$\bar{X} = \frac{\sum_{i=1}^n X_i}{n} \text{ και } \bar{Y} = \frac{\sum_{i=1}^n Y_i}{n}$$

Είμαστε πλέον σε θέση να εκτιμήσουμε την τιμή της μεταβλητής ενδιαφέροντος από τη σχέση  $Y = \hat{a} + \hat{b}X^*$ , για μία δεδομένη τιμή  $X^*$ . Βέβαια, ο υπολογισμός των παραπάνω τιμών γίνεται συνήθως με τη βοήθεια κάποιου υπολογιστικού πακέτου, όπως θα δούμε στη συνέχεια.



Εικόνα 9 Ευθεία Ελαχίστων Τετραγώνων

Η μέθοδος βασίζεται σε ορισμένες υποθέσεις για τα τυχαία σφάλματα, που αν αποδειχθεί ότι παραβιάζονται, τότε το μοντέλο που έχουμε υποθέσει δεν είναι το κατάλληλο. Οι υποθέσεις είναι οι εξής:

- $\varepsilon_i \sim N(0, \sigma^2)$
- $COV(\varepsilon_i, \varepsilon_j) = 0$ , για  $i \neq j$  δηλαδή τα  $\varepsilon_i$  είναι ασυσχέτιστα

Σημειώνεται ότι, προτού εφαρμόσουμε την μέθοδο ελαχίστων τετραγώνων, είναι μέγιστης σημασίας η σχεδίαση του διαγράμματος διασποράς των παρατηρήσεων έτσι ώστε να διαπιστώσουμε ότι υπάρχει μία γραμμική σχέση ανάμεσα στις  $X$ ,  $Y$ . Αν για οποιοδήποτε λόγο, το δείγμα υποδεικνύει κάποια μη γραμμική σχέση, τότε η προσέγγιση που πρόκειται να εφαρμόσουμε και η γραμμική σχέση που υποθέτουμε ( $Y = a + bX$ ) δεν θα μας οδηγήσουν σε μία καλή προσαρμογή.

#### 3.4.2. Πολλαπλή Γραμμική Παλινδρόμηση

Σε πολλές περιπτώσεις, η μεταβλητή ενδιαφέροντος επηρεάζεται από δύο ή περισσότερες ανεξάρτητες μεταβλητές. Προκειμένου να εξάγουμε μία καλή πρόβλεψη για την τιμή της εξαρτημένης μεταβλητής, χρειάζεται να λάβουμε υπόψη όλες τις μεταβλητές που επηρεάζουν σημαντικά τη συμπεριφορά της. Έτσι, η τεχνική της απλής γραμμικής παλινδρόμησης που μόλις αναλύσαμε επεκτείνεται στην πολλαπλή γραμμική παλινδρόμηση.

Στην πραγματικότητα, στα περισσότερα προβλήματα Επιχειρησιακής Έρευνας εμφανίζονται πολλές ανεξάρτητες μεταβλητές. Για παράδειγμα, οι πωλήσεις ενός προϊόντος επηρεάζονται από πλήθος παραγόντων, όπως την τιμή του προϊόντος, τις δαπάνες για τη διαφήμιση και την προώθηση του, την καταναλωτική δύναμη του κοινού στο οποίο απευθύνεται, τον ανταγωνισμό, τις συνθήκες της αγοράς κ.α. Ομοίως, η αποτελεσματικότητα της διαφήμισης εξαρτάται από το μέσο προβολής, τον προϋπολογισμό που χρησιμοποιήθηκε, τη συχνότητα προβολής κ.α. Έτσι, οι

ερευνητές βρίσκονται καθημερινά αντιμέτωποι με προβλήματα όπου χρειάζεται να εφαρμόσουν την τεχνική της πολλαπλής παλινδρόμησης.

Ας θεωρήσουμε ότι έχουμε  $k$  ανεξάρτητες μεταβλητές που συνδέονται γραμμικά με την εξαρτημένη μεταβλητή. Τότε το μοντέλο της πολλαπλής γραμμικής παλινδρόμησης έχει την ακόλουθη μορφή:

$$Y = a + b_1X_1 + b_2X_2 + \dots + b_kX_k + \varepsilon \quad \text{ή} \quad E(Y|X_1, X_2, \dots, X_k) = a + b_1X_1 + b_2X_2 + \dots + b_kX_k,$$

όπου  $Y$  είναι η εξαρτημένη μεταβλητή,  $X_j, j=1,2,\dots,k$  οι ανεξάρτητες μεταβλητές,  $a, b_1, b_2, \dots, b_k$  είναι οι παράμετροι του μοντέλου ή αλλιώς οι συντελεστές παλινδρόμησης και  $\varepsilon$  το τυχαίο σφάλμα.

Για ένα σύνολο παρατηρήσεων της ακόλουθης μορφής  $(Y_1, X_{11}, X_{12}, \dots, X_{1k}), (Y_2, X_{21}, X_{22}, \dots, X_{2k}), \dots, (Y_n, X_{n1}, X_{n2}, \dots, X_{nk})$ , το μοντέλο γράφεται ισοδύναμα ως:

$$Y_i = a + b_1X_{i1} + b_2X_{i2} + \dots + b_kX_{ik} + \varepsilon_i, \quad i=1,2,\dots,n$$

Στην πολλαπλή γραμμική παλινδρόμηση, η παράμετρος  $a$  εκφράζει τη μέση τιμή της  $Y$  όταν όλες οι μεταβλητές,  $X_j, j=1,2,\dots,k$  είναι μηδέν. Αντίστοιχα, η παράμετρος  $b_j$  εκφράζει την αναμενόμενη μεταβολή της ανεξάρτητης μεταβλητής  $Y$  όταν η  $X_j$  αυξηθεί κατά μία μονάδα και οι υπόλοιπες  $X_k$  για  $k \neq j$ , παραμείνουν σταθερές.

Σκοπός μας είναι να εκτιμήσουμε τις παραμέτρους παλινδρόμησης έτσι ώστε να μπορούμε, για δεδομένες τιμές των ανεξάρτητων μεταβλητών, να προβλέψουμε την τιμή της εξαρτημένης μεταβλητής, δηλαδή τη μεταβλητή ενδιαφέροντος. Έχοντας στη διάθεση μας ένα σύνολο δεδομένων όπως το προηγούμενο, δηλαδή η διανύσματα  $(i=1,2,\dots,n)$  που περιέχουν τις τιμές των ανεξάρτητων μεταβλητών μαζί με την αντίστοιχη τιμή της εξαρτημένης, μπορούμε να εκτιμήσουμε τις παραμέτρους παλινδρόμησης. Ο πιο συνηθισμένος τρόπος είναι η μέθοδος των ελαχίστων τετραγώνων.

Η μέθοδος των ελαχίστων τετραγώνων, κατά αντιστοιχία με τη διαδικασία που περιγράψαμε στην ενότητα 4.2.1, έγκειται στην ελαχιστοποίηση του αθροίσματος των τετραγώνων των σφαλμάτων πρόβλεψης, δηλαδή των  $e_i = Y_i - \hat{Y}_i$ , όπου  $\hat{Y}_i = \hat{a} + \hat{b}_1X_{i1} + \hat{b}_2X_{i2} + \dots + \hat{b}_kX_{ik}$ . Από αυτήν την ελαχιστοποίηση προκύπτουν οι τιμές  $\hat{a}, \hat{b}_1, \hat{b}_2, \dots, \hat{b}_k$ , δηλαδή οι εκτιμήσεις των παραμέτρων της παλινδρόμησης. Λόγω μεγάλου μεγέθους δείγματος και πολυπλοκότητας των πράξεων, η διαδικασία αυτή γίνεται με τη βοήθεια είτε του Excel είτε κάποιου στατιστικού πακέτου όπως η R ή το Minitab. Έχοντας στη διάθεση μας τις εκτιμήσεις των παραμέτρων, μπορούμε για κάθε δεδομένη τιμή των ανεξάρτητων μεταβλητών να προβλέψουμε την τιμή της μεταβλητής ενδιαφέροντος από τη σχέση:  $\hat{Y}_i = \hat{a} + \hat{b}_1X_{i1} + \hat{b}_2X_{i2} + \dots + \hat{b}_kX_{ik}$ .

Σημειώνεται ότι βασική προϋπόθεση για την εφαρμογή της μεθόδου είναι ότι τα τυχαία σφάλματα  $e_i$  είναι ανεξάρτητα μεταξύ τους και ακολουθούν κανονική κατανομή με μέση τιμή ίση με μηδέν ( $e_i \sim N(0, \sigma^2)$ ). [14]

### 3.5. Επιλογή Μεθόδου Πρόβλεψης

Κατά την διαδικασία επιλογής της καταλληλότερης μεθόδου πρόβλεψης βασικός παράγοντας είναι η κατανόηση των κυρίων συνιστωσών μίας χρονολογικής σειράς. Ενδεικτικά ένας αναλυτής μπορεί να ακολουθεί το παρακάτω μοτίβο, όταν επιλέγει μέθοδο πρόβλεψης.

- Όταν μια χρονοσειρά είναι στάσιμη και η μέση τιμή της παραμένει σταθερή κατά το πέρασμα του χρόνου, τότε μπορεί να επιλεγθούν ο Απλός Κινητός Μέσος ή η μέθοδος ARMA.

- Όταν η χρονοσειρά εμφανίζει τάση και η μέση τιμή της μεταβάλλεται κατά την διάρκεια του χρόνου, τότε μπορεί να επιλεγθεί Διπλός Κινητός Μέσος ή Εκθετική Εξομάλυνση με προσαρμογή στη τάση (Holt) ή τα μοντέλα ARIMA.
- Όταν η χρονοσειρά εμφανίζει εποχικότητα, σε πρώτη φάση είτε με το αθροιστικό μοντέλο είτε με το πολλαπλασιαστικό γίνεται διάσπαση της χρονοσειράς και στη συνέχεια εκτιμάτε ο δείκτης εποχικότητας των δεδομένων. Αυτό μπορεί να γίνει με την απλή μέθοδο διάσπασης (decomposition) ή με την εκθετική εξομάλυνση (Winter) ή τα μοντέλα ARIMA.
- Όταν η χρονοσειρά εμφανίζει κυκλικότητα, είναι πιο δύσκολη η διαδικασία πρόβλεψης καθώς τα μαθηματικά μοντέλα δυσχεραίνουν όταν υπάρχει ανομοιογένεια στην περίοδο. Ωστόσο, προτείνεται η κλασική διάσπαση (decomposition) ή τα μοντέλα ARIMA.

Επισημαίνεται, σε κάθε περίπτωση η παραπάνω μεθοδολογία δεν είναι πανάκεια και είναι σοφότερο να δοκιμάζονται παραπάνω από μία μέθοδος πρόβλεψης για μία χρονοσειρά και στο τέλος να αξιολογείται από τα διάφορα μέτρα αξιολόγησης. [2]

### 3.6. Μέτρα Αξιολόγησης Προβλέψεων

Προκειμένου να γίνει η πρόβλεψη μελλοντικών τιμών της χρονοσειράς, χρησιμοποιούνται οι παρατηρήσεις της σειράς μέχρι την παρούσα χρονική στιγμή. Εάν αναφερόμαστε σε μία σειρά  $X_n$ , τότε η τελευταία παρατήρηση είναι  $x_n$  και η μελέτη γίνεται για την παρατήρηση,  $k$  χρονικές στιγμές μετά από την  $n$  στιγμή και συμβολίζεται με  $x_{n+k}$ . Η παρατήρηση τη χρονική στιγμή  $n+k$  συμβολίζεται με  $x_{n+k}$ . [2]

### 3.7. Σφάλματα κατά την Πρόβλεψη

Όπως έχουμε πει, δεν υπάρχει τέλεια πρόβλεψη. Κάθε προβλεπόμενη τιμή εμπεριέχει ένα σφάλμα. Τα σφάλματα όμως συνεπάγονται κόστος, ειδικότερα όταν οι τιμές τους είναι μεγάλες. Για τον λόγο αυτό ο ερευνητής, πρέπει διαρκώς να προσπαθεί να βελτιώσει την ακρίβεια των προβλέψεων του.

Η αποτελεσματικότητα μίας πρόβλεψης εκτιμάται με δύο τρόπους. Ο πρώτος τρόπος έγκειται στην εξαγωγή της πρόβλεψης χρησιμοποιώντας πολλές διαφορετικές μεθόδους και συγκρίνοντας τα αποτελέσματα μεταξύ τους. Ο δεύτερος τρόπος συνίσταται στην πρόβλεψη των τιμών μίας μεταβλητής για παλαιότερες περιόδους, για τις οποίες γνωρίζουμε τις πραγματικές τιμές που προέκυψαν, και στην μετέπειτα σύγκριση της εκτίμησης που δίνει η μέθοδος για την περίοδο εκείνη με την πραγματική τιμή. Δηλαδή, αν έχουμε τα δεδομένα των πωλήσεων ενός έτους για μία επιχείρηση, μπορούμε να προσαρμόσουμε ένα μοντέλο πρόβλεψης με βάση το δείγμα των έξι πρώτων μηνών και έπειτα να υπολογίσουμε τις εκτιμήσεις του μοντέλου για τους υπόλοιπους έξι μήνες. Έπειτα θα συγκρίνουμε τις τιμές του πρώτου και του δεύτερου εξαμήνου και παρατηρούμε οι εκτιμήσεις είναι καλές.

Οι συγκρίσεις που αναφέρονται παραπάνω πραγματοποιούνται με τη βοήθεια των μέτρων που θα ορίσουμε σε αυτό το κεφάλαιο. Τα πιο συνηθισμένα μέτρα αποτελεσματικότητας της πρόβλεψης είναι η μέση απόλυτη απόκλιση η οποία συμβολίζεται ως MAD (Mean Absolute Deviation), το μέσο τετραγωνικό σφάλμα που

συμβολίζεται ως MSE (Mean Square Error) και το μέσο ποσοστιαίο σφάλμα, γνωστό ως MAPE (Mean Average Percentage Error). Έστω ότι διαθέτουμε δείγμα με τις πραγματικές τιμές μίας μεταβλητής για  $n$  περιόδους. Τότε, οι τιμές των μέτρων υπολογίζονται από τις ακόλουθες σχέσεις:

$$MAD = \frac{\sum_{i=1}^n |e_t|}{n} \quad (5.1),$$

$$MSE = \frac{\sum_{i=1}^n e_t^2}{n} \quad (5.2),$$

$$MAPE = \frac{1}{n} * \sum_{i=1}^n e_t/a_t \quad (5.3),$$

όπου:

$n$  = πλήθος περιόδων

$X_t$  = η πραγματική τιμή που προέκυψε κατά την περίοδο  $t, t=1,2,\dots,n$

$F_t$  = η πρόβλεψη για την περίοδο  $t$  και

$e_t = F_t - X_t$  = το σφάλμα της πρόβλεψης για την περίοδο  $t$

Η τιμή του MAPE υπολογίζεται σε ποσοστό ενώ οι τιμές των MAD και MSE επηρεάζονται από τα τις μονάδες μέτρησης. Φυσικά, επιδιώκουμε τα παραπάνω μέτρα να λαμβάνουν μικρές τιμές, εφόσον αναφερόμαστε σε σφάλματα.

Στην πράξη τα μέτρα MAD και MSE χρησιμοποιούνται συχνά για την επιλογή της βέλτιστης σταθεράς εξομάλυνσης. Δηλαδή, εφαρμόζουμε μία από τις μεθόδους εκθετικής εξομάλυνσης για διάφορες τιμές των σταθερών εξομάλυνσης. Έπειτα υπολογίζουμε την τιμή του MAD ή του MSE για κάθε μία εφαρμογή της μεθόδου και διαλέγουμε εκείνη που αντιστοιχεί στην μικρότερη τιμή (του MAD ή του MSE) που προέκυψε. [14]



## Κεφάλαιο 4

### 4. Ανάλυση Χρονολογικών Σειρών

#### 4.1. Ορισμός Χρονοσειρών (Time Series)

Μια χρονοσειρά είναι μια ακολουθία σημείων δεδομένων που ευρετηριάζονται με χρονολογική σειρά. Είναι ουσιαστικά μια συλλογή μετρήσεων ή παρατηρήσεων που καταγράφονται σε μια χρονική περίοδο, όπως η ημερήσια τιμή κλεισίματος μιας μετοχής, οι μηνιαίες πωλήσεις ενός προϊόντος ή οι ωριαίες μετρήσεις θερμοκρασίας από έναν μετεωρολογικό σταθμό.

Ακολουθούν ορισμένα βασικά χαρακτηριστικά των δεδομένων χρονοσειρών:

**Σειρά:** Τα σημεία δεδομένων είναι ταξινομημένα με χρονολογική σειρά, δηλαδή έχει σημασία η σειρά με την οποία συλλέχθηκαν.

**Διαστήματα:** Τα σημεία δεδομένων μπορούν να συλλέγονται σε τακτά ή ακανόνιστα διαστήματα. Για παράδειγμα, οι τιμές των μετοχών καταγράφονται συνήθως σε διαστήματα λεπτών, ενώ τα δεδομένα καιρού μπορεί να συλλέγονται ανά ώρα ή καθημερινά.

**Εποχικότητα:** Πολλές χρονοσειρές παρουσιάζουν εποχικότητα, που σημαίνει ότι έχουν προβλέψιμα μοτίβα που επαναλαμβάνονται με την πάροδο του χρόνου. Για παράδειγμα, οι λιανικές πωλήσεις συχνά αυξάνονται κατά τη διάρκεια των διακοπών.


**Τάσεις:** Οι χρονοσειρές μπορούν επίσης να εμφανίζουν τάσεις, οι οποίες είναι μακροπρόθεσμες κινήσεις στα δεδομένα είτε προς τα πάνω είτε προς τα κάτω.

#### 4.2. Κατηγορίες Χρονοσειρών

Οι χρονοσειρές διακρίνονται στις συνεχείς και στις διακριτές. Συνεχείς είναι οι χρονοσειρές που η τιμή της μεταβλητής παρατηρείται και καταγράφεται συνεχώς ακόμα και αν παίρνει διακριτές τιμές, ενώ ως διακριτές ορίζονται οι χρονοσειρές που η τιμή της μεταβλητής καταγράφεται σε ορισμένα χρονικά διαστήματα ακόμα και αν η τιμή της μεταβλητής είναι συνεχής. Παράδειγμα συνεχούς χρονοσειράς είναι η συνεχής παρακολούθηση των σεισμών, ενώ παράδειγμα διακριτής χρονοσειράς είναι η καταγραφή των τιμών των μετοχών του χρηματιστηρίου, όπου οι διαδοχικοί όροι ισαπέχουν.

Επιπρόσθετα, οι χρονοσειρές χαρακτηρίζονται βάσει των μεταβλητών που καταγράφονται. Όταν μία χρονοσειρά αποτελείται από καταγραφές μόνο μίας μεταβλητής ονομάζεται univariate, ενώ όταν αποτελείται από καταγραφές περισσότερων ονομάζεται multivariate.

Για την καλύτερη κατανόηση μίας χρονοσειράς συνηθίζεται η γραφική απεικόνιση όπως φαίνεται στο παρακάτω παράδειγμα, για την μηνιαία καταγραφή του CO<sub>2</sub> στην πόλη Manua Loa της Χαβάης. [2]



Εικόνα 10 Μηνιαία απεικόνιση από το 1958 έως το 2010 του CO<sub>2</sub> στην πόλη Mauna Loa της Χαβάη

### 4.3. Συνιστώσες Χρονοσειράς

Οι τιμές των χρονολογικών σειρών που παρατηρούμε είναι το αποτέλεσμα της ταυτόχρονης επίδρασης τεσσάρων διαφορετικών συνιστωσών: της τάσης, της κυκλικότητας, της εποχικότητας και των τυχαίων κυμάνσεων.

#### **Τάση**

Τάση είναι η μακροχρόνια γενική κίνηση, που ακολουθεί η χρονοσειρά, που αναπαριστά την αύξηση, ή την πτώση των τιμών της σειράς σε μία εκτεταμένη περίοδο του χρόνου. Είναι, δηλαδή, η κατά κατά μέσο όρο απαλλαγμένη από βραχυχρόνιες αυξομειώσεις εξέλιξη της σειράς για μεγάλες χρονικές περιόδους, συνήθως πάνω από 10 έτη. Γι' αυτό το λόγο καλείται και μακροχρόνια τάση και μπορεί να είναι ανοδική ή καθοδική. Η τάση θεωρείται ανύπαρκτη, όταν η κεντρική κίνηση της χρονοσειράς είναι παράλληλη προς τον άξονα του χρόνου, μακροχρόνιες εξελίξεις του προς μελέτη μεγέθους, που εκφράζει η μεταβλητή και είναι αποτέλεσμα της εξέλιξης της οικονομίας, των τεχνολογικών μεταβολών, των μακροχρόνιων αλλαγών των διαφόρων βιομηχανικών κλάδων, κ.λ.π. Ορισμένες μέθοδοι προσδιορισμού της μακροχρόνιας τάσης είναι η μέθοδος των κινητών μέσων, η μέθοδος της ευθείας ελαχίστων τετραγώνων, η μέθοδος της καμπύλης ελαχίστων τετραγώνων και άλλα. παρουσιάζει τάση προς αύξηση ή μείωση. Η τάση ενσωματώνει τις μακροχρόνιες εξελίξεις του προς μελέτη μεγέθους, που εκφράζει η μεταβλητή και είναι αποτέλεσμα της εξέλιξης της οικονομίας, των τεχνολογικών μεταβολών, των μακροχρόνιων αλλαγών των διαφόρων βιομηχανικών κλάδων, κ.λ.π. Ορισμένες μέθοδοι προσδιορισμού της μακροχρόνιας τάσης είναι η μέθοδος των κινητών μέσων, η μέθοδος της ευθείας ελαχίστων τετραγώνων, η μέθοδος της καμπύλης ελαχίστων τετραγώνων και άλλα.

#### **Κυκλική Συνιστώσα**

Η κυκλική συνιστώσα αντιπροσωπεύει εκείνες τις επαναλαμβανόμενες κυμάνσεις γύρω από την τάση, που η διάρκειά τους είναι μεγαλύτερη του έτους. Οι κυμάνσεις αυτές έχουν ανοδικές και καθοδικές φάσεις οι οποίες, συνήθως, διαρκούν μερικά έτη. Μία πλήρης κυκλική κύμανση αποτελείται από δύο κάτω σημεία καμψής και ένα άνω σημείο καμψής, που χρονικά παρεμβάλλεται μεταξύ των δύο πρώτων. Ο χρόνος μεταξύ δύο διαδοχικών κάτω ή άνω σημείων καμψής

αποτελεί την περίοδο της κυκλικής κύμανσης. Οι οικονομικοί κύκλοι εμφανίζονται κυρίως στις οικονομικά ανεπτυγμένες οικονομίες. Έτσι, στις δυτικές χώρες τα περισσότερα οικονομικά μεγέθη, όπως τιμές, επενδύσεις, κατανάλωση, εισόδημα, κ.λ.π. παρουσιάζουν κυκλικές κυμάνσεις λίγο, ή πολύ έντονες. Μάλιστα, λόγω του ότι οι οικονομίες αυτές είναι ανοιχτές, οι κυμάνσεις μιας οικονομίας προκαλούν αντίστοιχες κυμάνσεις και στις οικονομίες των άλλων χωρών. Το κυριότερο πρόβλημα που αντιμετωπίζουμε στην εξέταση των οικονομικών κύκλων είναι ότι η διάρκεια τους δεν είναι σταθερή.

### **Εποχική Συνιστώσα**

Η εποχική συνιστώσα είναι μια κυκλική κύμανση με περίοδο όμως το έτος, διότι μέσα σ' αυτό εξαντλεί όλες τις ανοδικές και καθοδικές κινήσεις. Επίσης, είναι περιοδική, διότι επαναλαμβάνεται ρυθμικά κάθε έτος. Είναι προφανές ότι η εποχική κύμανση εμφανίζεται μόνο στις χρονοσειρές με εποχικές παρατηρήσεις. Η εποχική κύμανση, που το όνομα της προέρχεται από το γεγονός, ότι συνδέεται με τις εποχές, δεν οφείλεται μόνο στις κλιματολογικές διαφορές μεταξύ των εποχών. Ο μεταβαλλόμενος αριθμός των εργασιμων ημερών μεταξύ των μηνών του έτους, το διαφορετικό ωράριο των καταστημάτων κ.λ.π. είναι μερικές από τις αιτίες των περιοδικών κυμάνσεων, που εμφανίζουν οι χρονοσειρές με εποχικά δεδομένα.

### **Τυχαία Συνιστώσα**

Οποιαδήποτε επίδραση στη διαμόρφωση της τιμής της μεταβλητής, που δεν οφείλεται σε κάποια από τις παραπάνω συνιστώσες, θεωρείται τυχαία ή άρρυθμος κύμανση. Θα πρέπει όμως να σημειωθεί, ότι η τυχαία συνιστώσα εμφανίζεται ακανόνιστα με επιδράσεις, που άλλοτε είναι θετικές και άλλοτε αρνητικές. Οι τυχαίες κυμάνσεις οφείλονται σε όλες εκείνες τις επιδράσεις, που δεν είναι συστηματικές και επομένως δεν μπορούν να προβλεφθούν.

Παράδειγμα τέτοιων επιδράσεων είναι οι απρόβλεπτες αλλαγές τιμών στη διεθνή αγορά.

## **4.4. Τύποι Χρονολογικών Σειρών**

### **4.4.1. Παλινδρόμηση**

Η παλινδρόμηση ορίζεται ως η συναρτησιακή σχέση μεταξύ δύο συσχετισμένων μεταβλητών. Χρησιμοποιείται για την πρόβλεψη της μίας μεταβλητής δεδομένου των τιμών της άλλης. Η γραμμική παλινδρόμηση αναφέρεται στην ειδική περίπτωση της παλινδρόμησης όπου η σχέση μεταξύ των δύο μεταβλητών (στη συγκεκριμένη περίπτωση χρόνος και ζήτηση) είναι γραμμική. Τα δεδομένα πρέπει πρώτα να απεικονιστούν γραφικά για να διαπιστωθεί αν η σχέση των μεταβλητών παρουσιάζεται γραμμική.

Η ευθεία της γραμμικής παλινδρόμησης έχει τον τύπο:

$$Y = a + bX,$$

όπου,  $Y$  = εξαρτημένη μεταβλητή (Ζήτηση)  $a$  = σταθερά (αρχή της ευθείας)

$b$  = η κλίση της ευθείας

$X$  = η ανεξάρτητη μεταβλητή (Χρόνος)

Η γραμμική παλινδρόμηση ενδείκνυται για μακροπρόθεσμες προβλέψεις και ολικό προγραμματισμό. Για παράδειγμα, η γραμμική παλινδρόμηση είναι πολύ χρήσιμη για την πρόβλεψη της ζήτησης μιας ομάδας προϊόντων. Παρ' ότι η ζήτηση για τα επιμέρους προϊόντα μπορεί να ποικίλει μέσα στην καθορισμένη χρονική περίοδο, η ζήτηση για τη συνολική ομάδα προϊόντων θα είναι ομαλή. Ο κύριος περιορισμός της μεθόδου αυτής είναι ότι υποθέτουμε πως τα δεδομένα του παρελθόντος και οι προβλέψεις βρίσκονται σε μια ευθεία γραμμή. Παρ' όλο που το γεγονός αυτό περιορίζει την εφαρμογή της μεθόδου γραμμικής παλινδρόμησης, ορισμένες φορές, μπορεί να χρησιμοποιηθεί με τη χρήση μικρών χρονικών περιόδων. Η γραμμική παλινδρόμηση χρησιμοποιείται και για προβλέψεις με ανάλυση χρονοσειρών και για προβλέψεις με αιτιακές σχέσεις.

Όταν η εξαρτημένη μεταβλητή μεταβάλλεται με το χρόνο, τότε είναι ανάλυση χρονοσειρών. Αν μια μεταβλητή κινείται εξαιτίας της κίνησης μια άλλης μεταβλητής, τότε είναι αιτιακή σχέση.

#### 4.4.2. Arima Models (στασιμότητα, συντελεστής αυτοσυσχέτισης)

Σε ένα τυχαίο δείγμα οι διαφορές πρώτης τάξης οδηγούν σε διαδικασία λευκού θορύβου, δηλαδή σε στάσιμη διαδικασία. Στην γενική περίπτωση όμως, μια στάσιμη στοχαστική διαδικασία που προκύπτει παίρνοντας διαφορές κάποιας τάξης δεν είναι λευκός θόρυβος αλλά ARMA(p,q) στάσιμη διαδικασία. Οι Box – Jenkins προτείνουν για μια μη στάσιμη χρονολογική σειρά την χρήση διαφορών πρώτης, δεύτερης ή d τάξεως για την επίτευξη στασιμότητας. Στην νέα σειρά προσαρμόζεται ένα μοντέλο ARMA(p,q). Γενικά ένα μοντέλο ARMA(p,q) που εφαρμόζεται σε μια ολοκληρωμένη σειρά d τάξεως, ονομάζεται αυτοπαλίνδρομο ολοκληρωμένο μοντέλο κινητού μέσου τάξεως (p,q,d) (Autoregressive Integrated Moving Average) και συμβολίζεται με ARIMA(p,q,d). Με άλλα λόγια, ARIMA(p,q,d) διαδικασία, είναι μια διαδικασία η οποία 'διαφορίζεται' (κατά αναλογία με το 'ολοκληρωμένη') d φορές και παράγει ARMA(p,q) διαδικασία.

##### **Στασιμότητα**

Η στασιμότητα είναι πολύ σημαντική έννοια καθώς είναι απαραίτητη προϋπόθεση για τα περισσότερα εργαλεία της ανάλυση χρονολογικών σειρών. Όπως έχει ήδη αναφερθεί, χρονολογική σειρά είναι ένα σύνολο παρατηρήσεων  $x_t$  μιας τυχαίας μεταβλητής  $X$ , κάθε μια από τις οποίες λαμβάνεται την χρονική στιγμή  $t$ . Η χρονολογική σειρά μπορεί με άλλα λόγια να θεωρηθεί ως στοχαστική διαδικασία πεπερασμένου πλήθους παρατηρήσεων, δηλαδή, μια πραγματοποίηση μιας διαδικασίας  $x_1, x_2, \dots, x_t$ . Μια χρονολογική σειρά λέγεται στάσιμη εάν δεν υπάρχει συστηματική αλλαγή του μέσου όρου και της διασποράς της στο χρόνο. Με άλλα λόγια, εάν μια χρονολογική σειρά παρουσιάζει τάση τότε αυτή δεν θα είναι στάσιμη. Μια στοχαστική διαδικασία είναι αυστηρώς ή πλήρως στάσιμη (strictly – strongly – completely stationary) όταν οι ιδιότητες της δεν επηρεάζονται από μια αλλαγή στην αρχή μετρήσεως του χρόνου.

##### **Συντελεστής αυτοσυσχέτισης**

Είναι γνωστό από την θεωρία των πιθανοτήτων ότι ο λόγος της συνδιακύμανσης προς το γινόμενο των τετραγωνικών ριζών των διακυμάνσεων δυο μεταβλητών είναι ο συντελεστής συσχέτισής τους. Επίσης, ο συντελεστής συσχέτισης μας δίνει ένα μέτρο για τον βαθμό της μεταξύ τους σχέσης δυο μεταβλητών. Μάλιστα, η τιμή του συντελεστή συσχέτισης, που είναι απαλλαγμένος από τις μονάδες των μεταβλητών, δίνει μια αρκετά πλήρη εικόνα. Και έτσι, μπορούμε να απαντήσουμε εάν η μεταξύ τους σχέση είναι ισχυρή ή ασθενής κτλ. Τέλος, για τον συντελεστή συσχέτισης ισχύει ότι  $-1 \leq \rho \leq 1$  και εάν  $\rho = 1$  ή  $\rho = -1$  έχουμε την μεγίστη δυνατή συσχέτιση, εάν  $\rho > 0$  υπάρχει θετική συσχέτιση, η οποία είναι τόσο πιο ισχυρή όσο πιο κοντά ο συντελεστής συσχέτισης είναι στο 1, εάν  $\rho < 0$  υπάρχει αρνητική συσχέτιση, η οποία είναι τόσο πιο ισχυρή όσο πιο κοντά ο συντελεστής συσχέτισης είναι στο  $-1$ . Για  $\rho = 0$  δεν υπάρχει καμία συσχέτιση μεταξύ των δυο μεταβλητών. Στην περίπτωση των χρονολογικών σειρών ο συντελεστής συσχέτισής ανάμεσα στην  $Y_t$  και στην  $Y_{t+s}$  ονομάζεται συντελεστής αυτοσυσχέτισής.

#### 4.4.3. Μέθοδος Box Jenkins

Η ανάπτυξη και η κατασκευή υποδειγμάτων ARIMA ως εργαλεία πρόβλεψης των τιμών οικονομικών μεταβλητών είναι γνωστή ως μεθοδολογία Box-Jenkins. Πρόκειται στην πραγματικότητα για γραμμικά στατιστικά μοντέλα που μπορούν να περιγράψουν ικανοποιητικά τις διάφορες συνιστώσες της χρονολογικής σειράς.

Η προσέγγιση των Box-Jenkins στην ανάλυση χρονοσειρών είναι μια μέθοδος εύρεσης ενός στατιστικού υποδείγματος ARIMA που να παριστάνει ικανοποιητικά τη στοχαστική διαδικασία από την οποία προήλθαν τα δεδομένα, δηλαδή το δείγμα μας. Η μέθοδος αυτή εφαρμόζεται όταν η χρονοσειρά δεν είναι στάσιμη και περιλαμβάνει τέσσερα στάδια, την ταυτοποίηση (identification), την εκτίμηση (estimation), και το διαγνωστικό έλεγχο (diagnostic checking) και την πρόβλεψη (forecasting) και τα οποία θα αναλύσουμε στη συνέχεια.

##### **Πρώτο Στάδιο: Ταυτοποίηση**

Λέγοντας ταυτοποίηση του υποδείγματος εννοούμε ότι θα πρέπει να προσδιορισθούν: α) η τάξη της μη στασιμότητας β) η τάξη των AR και/ή πολυωνύμων Αυτό επιτυγχάνεται με σύγκριση της μορφής των δειγματικών συναρτήσεων αυτοσυσχετίσεως και μερικής αυτοσυσχετίσεως με τη μορφή θεωρητικών συναρτήσεων αυτοσυσχετίσεως και μερικής αυτοσυσχετίσεως που αντιστοιχούν σε διαδικασίες με άπειρο πλήθος όρων.

Πιο αναλυτικά, σε αυτό το στάδιο γίνεται η εξειδίκευση ενός ARIMA υποδείγματος με βάση τις πληροφορίες που παίρνουμε από το δείγμα. Αυτό σημαίνει ότι καθορίζονται οι τιμές των  $d, p$  και  $q$ . Δηλαδή, καθορίζεται ο αριθμός  $d$  των διαφορών που απαιτούνται για να μετατραπεί η σειρά σε στάσιμη, από τη στιγμή βέβαια που δεν είναι, και στη συνέχεια καθορίζεται η τάξη  $p$  της αυτοπαλίνδρομης διαδικασίας και η τάξη της  $q$  διαδικασίας κινητού μέσου. Για να διαπιστωθεί αν η σειρά είναι στάσιμη ή όχι, θα εξεταστεί η συμπεριφορά της δειγματικής συνάρτησης αυτοσυσχετίσεως. Αν οι αυτοσυσχετίσεις συγκλίνουν ταχύτατα προς το μηδέν σημαίνει ότι η σειρά μάλλον είναι στάσιμη. Αντίθετα, αν οι αυτοσυσχετίσεις φθίνουν με αργό ρυθμό, είναι σοβαρή ένδειξη ότι η σειρά είναι μη στάσιμη, οπότε πρέπει να γίνει στάσιμη. Σε αυτή την περίπτωση θα χρησιμοποιήσουμε τις πρώτες ή τις δεύτερες ή κ.τ.λ. διαφορές για να μετατραπεί η σειρά σε στάσιμη. Αφού η σειρά έχει γίνει στάσιμη, προσδιορίζεται στη συνέχεια η τάξη του υποδείγματος ARIMA, δηλαδή προσδιορίζονται οι τιμές του  $p$  και  $q$  του. Ο προσδιορισμός τους βασίζεται στις δειγματικές απλές και μερικές, αυτοσυσχετίσεις.

##### **Δεύτερο Στάδιο: Εκτίμηση**

Μετά την εξειδίκευση του υποδείγματος και την εύρεση της τάξης του ακολουθεί η εκτίμηση των  $p$  παραμέτρων  $\phi_1, \phi_2, \dots$  της αυτοπαλίνδρομης διαδικασίας και των  $q$  παραμέτρων  $\theta_1, \theta_2, \dots$  της διαδικασίας κινητού μέσου. Αν η σειρά που εξετάζουμε είναι μόνο αυτοπαλίνδρομη, οι παράμετροί της, όπως είδαμε προηγουμένως, μπορούν να εκτιμηθούν με τη μέθοδο των ελαχίστων τετραγώνων. Αν όμως, η σειρά περιέχει και όρους κινητού μέσου τότε για την εκτίμηση των παραμέτρων του κινητού μέσου θα χρησιμοποιηθούν μη γραμμικές μέθοδοι εκτίμησης.

Στη γενική περίπτωση η εκτίμηση των παραμέτρων του υποδείγματος επιτυγχάνεται με τη χρήση της μεθόδου της μέγιστης πιθανοφάνειας. Οι εκτιμήσεις πρέπει να είναι εντός των ορίων αντιστρεψιμότητας, στασιμότητας και φυσικά να είναι στατιστικά σημαντικές.

#### **Τρίτο Στάδιο: Διαγνωστικός έλεγχος**

Στο στάδιο αυτό γίνεται έλεγχος καλής προσαρμογής του υποδείγματος. Αυτό σημαίνει ότι ελέγχεται το πόσο καλά ταιριάζει το εκτιμώμενο υπόδειγμα με τα δεδομένα, γιατί είναι πιθανό κάποιο άλλο υπόδειγμα ARIMA να προσαρμόζεται καλύτερα. Θα εφαρμόσουμε κάποιους στατιστικούς ελέγχους για τη σημαντικότητα των παραμέτρων, τη συμπεριφορά των καταλοίπων και την τάξη του υποδείγματος.

Θα ασχοληθούμε πρώτα με τον έλεγχο των καταλοίπων. Αν το εκτιμώμενο υπόδειγμα είναι το πιο κατάλληλο για τα δεδομένα μας, αν δηλαδή εκφράζει ικανοποιητικά τη διαδικασία από την οποία προέρχονται τα δεδομένα, τότε τα κατάλοιπα θα πρέπει να συμπεριφέρονται ως μια διαδικασία λευκού θορύβου. Αυτό σημαίνει ότι τα κατάλοιπα δε πρέπει να αυτοσυσχετίζονται. Αυτός ο έλεγχος για τα κατάλοιπα γίνεται με τη στατιστική Q των Box- Pierce, με την οποία ελέγχεται από κοινού η σημαντικότητα ενός αριθμού συντελεστών αυτοσυσχέτισης, έστω m.

Η μηδενική υπόθεση τότε, θα είναι:

$$H_0 = P_1 = P_2 = \dots = P_m = 0$$

Όπου  $P_i, i = 1, 2, \dots, m$

είναι οι συντελεστές συσχέτισης των καταλοίπων.

#### **Τέταρτο Στάδιο: Μεταδιάγνωση (Πρόβλεψη)**

Το γεγονός ότι ένα δοκιμαστικό υπόδειγμα δεν απορρίφθηκε από το διαγνωστικό έλεγχο δε σημαίνει ότι μπορεί αυτόματα να γίνει αποδεκτό, καθώς είναι πιθανό να υπάρχουν και άλλα υποδείγματα που να ανταποκρίνονται στις απαιτήσεις των σταδίων 2 και 3. Έτσι δυνατόν να έχουμε περισσότερα του ενός αποδεκτά κατ' αρχήν υποδείγματα. Στο στάδιο της μεταδιάγνωσης επιλέγεται τελικά εκείνο το υπόδειγμα το οποίο εμφανίζει την καλύτερη προσαρμογή, ή/και την καλύτερη προβλεπτική ικανότητα.

#### **Έλεγχος της Τάξης του υποδείγματος**

Η καταλληλότητα του εκτιμώμενου υποδείγματος ελέγχεται συγκρίνοντας το με ένα άλλο υπόδειγμα μεγαλύτερης τάξης. Δηλαδή, το εκτιμώμενο υπόδειγμα ARMA (p, q) συγκρίνεται με τα υποδείγματα ARMA (p+1, q) και ARMA (p, q+1). Αν το υπόδειγμα που εκτιμήθηκε περιγράφει τη διαδικασία που παρήγαγε τα δεδομένα, οι επιπλέον συντελεστές στα μεγαλύτερα υποδείγματα δεν θα πρέπει να είναι στατιστικά διαφορετικοί από το μηδέν. Η παραπάνω διαδικασία ελέγχου ονομάζεται υπερπροσαρμογή.

#### **4.5. Σφάλμα Πρόβλεψης**

Για την επιλογή του κατάλληλου μοντέλου για την πρόβλεψη χρονοσειρών, οι επιχειρήσεις θα πρέπει να λάβουν διάφορα στοιχεία υπόψιν. Ένα σημαντικό στοιχείο που θα πρέπει να ληφθεί υπ' όψιν είναι η απόδοση των προβλέψεων, όπως αυτή καθορίζεται με βάση τα σφάλματα πρόβλεψης. Οι αναλυτές, λοιπόν, θα πρέπει να γνωρίζουν πώς να υπολογίζουν τα σφάλματα πρόβλεψης και πώς

να εντοπίζουν τυχόν λάθη στις μεθόδους πρόβλεψης. Οι προβλέψεις πάντα εμπεριέχουν κάποιο σφάλμα. Τα σφάλμα πρόβλεψης διακρίνονται σε συστηματικά (bias errors) και τυχαία (random errors). Τα συστηματικά σφάλματα οφείλονται σε συστηματικά λάθη του μοντέλου δηλαδή η πρόβλεψη είναι πάντα μεγαλύτερη ή πάντα μικρότερη από την πραγματική. Τα λάθη αυτά συχνά οφείλονται στην παράβλεψη ή στην μη ακριβή εκτίμηση του υποδείγματος της μεταβλητής. Τα τυχαία λάθη είναι αποτέλεσμα μη προβλέψιμων παραγόντων που προκαλούν απόκλιση της πρόβλεψης από την πραγματική τιμή. Με τον όρο σφάλμα πρόβλεψης αναφερόμαστε στη διαφορά μεταξύ της προβλεπόμενης και της πραγματικής τιμής για μία δεδομένη περίοδο. [13]

Οι μετρήσεις αξιολόγησης, επίσης γνωστές ως μετρήσεις απόδοσης ή μετρήσεις αξιολόγησης, είναι ποσοτικές μετρήσεις που χρησιμοποιούνται για την αξιολόγηση της απόδοσης και της ποιότητας ενός μοντέλου ή αλγορίθμου για την επίλυση ενός συγκεκριμένου προβλήματος. Παρέχει έναν τυποποιημένο τρόπο αξιολόγησης και σύγκρισης διαφορετικών μοντέλων και αλγορίθμων με βάση συγκεκριμένα κριτήρια. Στην περίπτωση μας, μας ενδιαφέρουν οι μετρήσεις αξιολόγησης που χρησιμοποιούνται ειδικά για την αξιολόγηση της απόδοσης των μοντέλων χρονοσειρών. Έχουν σχεδιαστεί για να μετρούν διάφορες πτυχές όπως η ακρίβεια, η ακρίβεια, η ανάκληση, το σφάλμα και η προγνωστική ισχύς, ανάλογα με τον τύπο του προβλήματος που αντιμετωπίζεται. Αυτές οι μετρήσεις μπορεί να είναι χρήσιμες σε διάφορα σενάρια:



**Αξιολόγηση απόδοσης:** Οι μετρήσεις αξιολόγησης μετρούν ποσοτικά πόσο καλά αποδίδει ένα μοντέλο χρονοσειρών στην πρόβλεψη μελλοντικών τιμών. Βοηθούν στην αξιολόγηση της ακρίβειας και της αποτελεσματικότητας του μοντέλου στην καταγραφή των υποκείμενων προτύπων και τάσεων στα δεδομένα.

**Σύγκριση μοντέλων:** Μπορείτε να χρησιμοποιήσετε διάφορες μετρήσεις για να συγκρίνετε πολλά μοντέλα και να προσδιορίσετε ποιο μοντέλο έχει καλύτερη απόδοση. Συγκρίνοντας μετρήσεις μεταξύ μοντέλων, μπορούμε να λάβουμε τεκμηριωμένες αποφάσεις σχετικά με το μοντέλο που θα χρησιμοποιήσουμε για τις ιδιαίτερες ανάγκες μας.

**Βελτιστοποίηση παραμέτρων:** Οι μετρήσεις αξιολόγησης μπορούν να καθοδηγήσουν τη διαδικασία βελτιστοποίησης παραμέτρων και επιλογής μοντέλου. Η αξιολόγηση της απόδοσης του μοντέλου κάτω από διαφορετικές διαμορφώσεις παραμέτρων μας επιτρέπει να βελτιστοποιήσουμε την απόδοση του μοντέλου και να επιλέξουμε το βέλτιστο σύνολο παραμέτρων.

**Λήψη αποφάσεων:** Τα μοντέλα χρονοσειρών χρησιμοποιούνται συχνά για σκοπούς πρόβλεψης και λήψης αποφάσεων. Οι μετρήσεις μας βοηθούν να αξιολογήσουμε την αξιοπιστία και την ακρίβεια των προβλέψεων, δίνοντάς μας εμπιστοσύνη στη λήψη τεκμηριωμένων αποφάσεων με βάση τα αποτελέσματα του μοντέλου.

Υπάρχουν πολλές διαθέσιμες μετρήσεις αξιολόγησης, επειδή διαφορετικές μετρήσεις καταγράφουν διαφορετικές πτυχές της απόδοσης του μοντέλου. Κάθε μέτρηση εστιάζει σε ένα συγκεκριμένο χαρακτηριστικό ή απαίτηση, επιτρέποντάς μας να επιλέξουμε την καταλληλότερη μέτρηση με βάση τις συγκεκριμένες ανάγκες και τους στόχους τους.

Οι μετρήσεις σφαλμάτων επικεντρώνονται στη μέτρηση της ακρίβειας και του μεγέθους των σφαλμάτων στις προβλεπόμενες τιμές σε σύγκριση με τις πραγματικές τιμές. Τονίζουν το μέγεθος των σφαλμάτων παρά τη συγκεκριμένη κατεύθυνση και παρέχουν πληροφορίες για τη συνολική απόδοση και ακρίβεια του μοντέλου πρόβλεψης.

Πριν εισαγάγουμε τις πιο συχνά χρησιμοποιούμενες μετρήσεις αξιολόγησης αυτού του είδους, ας εισαγάγουμε τον συμβολισμό που χρησιμοποιείται στις εξισώσεις:

$\hat{y}_i$  : αντιπροσωπεύει την προβλεπόμενη τιμή  $i$ -η παρατήρηση

$y_i$  : αντιπροσωπεύει την πραγματική τιμή για την  $i$ -η παρατήρηση

$n$  : αντιπροσωπεύει τον αριθμό των παρατηρήσεων]

### Μέσο Απόλυτο Σφάλμα (Mean Absolute Error - MAE)

Το μέσο απόλυτο σφάλμα (MAE) μετρά το μέσο μέγεθος του σφάλματος μεταξύ των προβλεπόμενων και των πραγματικών τιμών σε ένα σύνολο δεδομένων χρονοσειράς. Το MAE υπολογίζεται λαμβάνοντας την απόλυτη διαφορά μεταξύ των προβλεπόμενων και πραγματικών τιμών και υπολογίζοντας τον μέσο όρο τους.

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i|$$

Πλεονεκτήματα: Το MAE είναι απλό και εύκολο στην ερμηνεία, καθώς το μέσο σφάλμα εκφράζεται στις ίδιες μονάδες με τα αρχικά δεδομένα. Είναι λιγότερο ευαίσθητο σε ακραίες τιμές σε σύγκριση με άλλες μετρήσεις σφάλματος, όπως το μέσο τετράγωνο σφάλμα (MSE).

Μειονεκτήματα: Η MAE δεν κάνει διάκριση μεταξύ υπερεκτίμησης και υποεκτίμησης και δεν παρέχει πληροφορίες σχετικά με την κατεύθυνση ή το μέγεθος των μεμονωμένων σφαλμάτων. Επιπλέον, ανάλογα με το συγκεκριμένο πρόβλημά σας, μπορεί να θεωρηθεί ως μειονέκτημα ότι δεν τιμωρεί τις λανθασμένες προβλέψεις όσο το MSE.

Python

```
1 # Install library
2 !pip install scikit-learn
3
4 # Import function
5 from sklearn.metrics import mean_absolute_error
6
7 # Calculate MAE
8 mae = mean_absolute_error(actual_values, predicted_values)
9 print("Mean Absolute Error:", mae)
```

Εικόνα 11 MAE Python code

### Μέσο Σφάλμα Τετραγώνων (Mean Squared Error – MSE)

Το μέσο σφάλμα τετραγώνων (MSE) είναι μια μέτρηση που χρησιμοποιείται συνήθως για την αξιολόγηση της ακρίβειας των μοντέλων πρόβλεψης χρονοσειρών. Μετρά τη μέση τετραγωνική διαφορά μεταξύ των προβλεπόμενων και των πραγματικών τιμών για μια δεδομένη χρονική περίοδο.

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

Πλεονεκτήματα: η απλότητα και η ικανότητά του να καταγράφει τόσο μεγάλα όσο και μικρά σφάλματα. Τιμωρεί τα μεγάλα σφάλματα λόγω τετραγωνισμού.

Μειονεκτήματα: τονίζει μεγάλα σφάλματα λόγω τετραγωνισμού, κάτι που μπορεί να είναι μειονέκτημα όταν υπάρχουν ακραίες τιμές. Επίσης, δεν είναι εύκολα ερμηνεύσιμο αφού εκφράζεται σε τετράγωνα μονάδες των δεδομένων. Άλλες μετρήσεις, όπως το μέσο απόλυτο σφάλμα (MAE) ή το ριζικό μέσο τετράγωνο σφάλμα (RMSE), ενδέχεται να προτιμώνται σε ορισμένες περιπτώσεις όπου η ερμηνευτικότητα είναι απαραίτητη. Επίσης, δεν κάνει διάκριση μεταξύ υπερεκτίμησης και υποτίμησης.

```
Python
1 # Install library
2 !pip install scikit-learn
3
4 # Import function
5 from sklearn.metrics import mean_squared_error
6
7 # Calculate MSE
8 mse = mean_squared_error(actual_values, predicted_values)
9 print("Mean Squared Error:", mse)
```

Εικόνα 12 MSE Python code

### Σφάλμα Ρίζας Μέσου Τετραγώνου (Root Mean Squared Error - RMSE)

Το RMSE είναι μια άλλη μέτρηση που χρησιμοποιείται συνήθως για την αξιολόγηση της ακρίβειας των μοντέλων πρόβλεψης χρονοσειρών. Είναι η τετραγωνική ρίζα του MSE. Επομένως, μετρά τη μέση διαφορά μεταξύ των προβλεπόμενων και των πραγματικών τιμών, λαμβάνοντας υπόψη τις διαφορές στο τετράγωνο για να τονίσει τα μεγαλύτερα σφάλματα. Ωστόσο, εφαρμόζει την τετραγωνική ρίζα για να εκφράσει το αποτέλεσμα στο αρχικό μέγεθος των μεταβλητών.

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

Πλεονεκτήματα: τιμωρεί μεγάλα σφάλματα λόγω τετραγωνισμού και είναι εύκολα ερμηνεύσιμο χάρη στην έκφραση του αριθμού στο μέγεθος των μεταβλητών.

Μειονεκτήματα: είναι ευαίσθητο σε ακραίες τιμές και μπορεί να παραμορφωθεί από ακραίες τιμές. Επιπλέον, το RMSE δεν παρέχει πληροφορίες για την κατεύθυνση ή το μοτίβο των σφαλμάτων πρόβλεψης και δεν κάνει διάκριση μεταξύ υπερβολικών και υπο-προβλέψεων.

```
Python
1 # Install library
2 !pip install scikit-learn
3
4 # Import libraries
5 from sklearn.metrics import mean_squared_error
6 import numpy as np
7
8 # Calculate MSE
9 mse = mean_squared_error(actual_values, predicted_values)
10
11 # Calculate RMSE
12 rmse = np.sqrt(mse)
13
14 print("RMSE:", rmse)
```

Εικόνα 13 RMSE Python code

### Μέσο Απόλυτο Ποσοστό Σφάλματος (Mean Absolute Percentage Error - MAPE)

Το μέσο απόλυτο ποσοστό σφάλματος (MAPE) υπολογίζει τη μέση ποσοστιαία διαφορά μεταξύ των προβλεπόμενων τιμών και των πραγματικών τιμών. Το MAPE υπολογίζεται λαμβάνοντας την απόλυτη διαφορά μεταξύ των προβλεπόμενων και πραγματικών τιμών, διαιρώντας την με την πραγματική τιμή και στη συνέχεια υπολογίζοντας τον μέσο όρο των αποτελεσμάτων.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| * 100$$

Πλεονεκτήματα: η ικανότητά του να ερμηνεύει τα σφάλματα σε ποσοστά, καθιστώντας ευκολότερη την κατανόηση και τη σύγκριση μεταξύ διαφορετικών συνόλων δεδομένων.

Μειονεκτήματα: είναι ευαίσθητο σε ακραίες τιμές και δεν μπορεί να χειριστεί μηδενικές ή σχεδόν μηδενικές πραγματικές τιμές αφού δεν είναι δυνατή η διαίρεση με το μηδέν. Το MAPE αντιμετωπίζει τις υπερεκτιμήσεις και τις υποεκτιμήσεις διαφορετικά, πράγμα που σημαίνει ότι δεν είναι μια συμμετρική μέτρηση. Η κατεύθυνση του σφάλματος (είτε η πρόβλεψη είναι πάνω είτε κάτω από την πραγματική τιμή) επηρεάζει την τιμή MAPE. Αυτή η έλλειψη συμμετρίας σημαίνει ότι μπορεί να μην είναι κατάλληλο για καταστάσεις όπου οι υπερεκτιμήσεις και οι υποεκτιμήσεις έχουν διαφορετικές επιπτώσεις ή κόστος.

Python

```
1 # Install library
2 !pip install statsmodels
3
4 # Import function
5 from statsmodels.tools.eval_measures import mean_absolute_percentage_error
6
7 # Calculate MAPE
8 mape = mean_absolute_percentage_error(actual_values, predicted_values) * 100
9 print("MAPE:", mape, "%")
```

Εικόνα 14 MAPE Python code

### Συμμετρικό Μέσο Απόλυτο Ποσοστό Σφάλματος (Symmetric Mean Absolute Percentage Error – SMAPE)

Το συμμετρικό μέσο απόλυτο ποσοστό σφάλματος (SMAPE) είναι μια μέτρηση που μετρά την ποσοστιαία διαφορά μεταξύ των παρατηρούμενων και των προβλεπόμενων τιμών, λαμβάνοντας υπόψη την κλίμακα των δεδομένων. Το SMAPE υπολογίζεται βρίσκοντας την απόλυτη διαφορά μεταξύ της πραγματικής και της προβλεπόμενης τιμής, διαιρώντας την με τον μέσο όρο των απόλυτων τιμών των πραγματικών και προβλεπόμενων τιμών και στη συνέχεια πολλαπλασιάζοντας με το 100 για να εκφραστεί ως ποσοστό.

$$SMAPE = \frac{1}{n} \sum_{i=1}^n \frac{|\hat{y}_i - y_i|}{(|\hat{y}_i| + |y_i|)/2} * 100$$

Πλεονεκτήματα: η ικανότητά του να χειρίζεται μηδενικές τιμές και η συμμετρία του, που διασφαλίζει ότι τα σφάλματα υπερεκτίμησης και υποεκτίμησης αντιμετωπίζονται εξίσου

Μειονεκτήματα: Είναι ευαίσθητο σε ακραίες τιμές καθώς υπολογίζεται η ποσοστιαία διαφορά. Μπορεί να παράγει άπειρες τιμές εάν οι πραγματικές και οι προβλεπόμενες τιμές είναι και οι δύο μηδέν.

```
Python
1 # Import libraries
2 import numpy as np
3
4 # Define function
5 def sym_mean_absolute_percentage_error(actual, predicted):
6     """
7     Calculate SMAPE (Symmetric Mean Absolute Percentage Error).
8     """
9     return 2 * np.mean(np.abs(actual - predicted) / (np.abs(actual) + np.abs(predicted)))
10
11 # Calculate SMAPE
12 smape = sym_mean_absolute_percentage_error(actual_values, predicted_values)
13 print("SMAPE:", smape, "%")
```

Εικόνα 15 SMAPE Python code

### Μέσο Απόλυτο Σφάλμα Κλίμακας (Mean Absolute Scaled Error - MASE)

Το Μέσο Απόλυτο Σφάλμα Κλίμακας (MASE) μετρά τη σχετική ακρίβεια πρόβλεψης σε σύγκριση με το απλό μοντέλο ή το μοντέλο αναφοράς, το οποίο αναφέρεται στην απλή χρήση της τελευταίας παρατηρούμενης τιμής της χρονοσειράς ως πρόβλεψης για όλα τα μελλοντικά σημεία. Το MASE υπολογίζεται διαιρώντας το μέσο απόλυτο σφάλμα (MAE) των προβλέψεων του μοντέλου με το MAE του απλού μοντέλου.

$$MASE = \frac{MAE}{\frac{1}{n-1} \sum_{i=2}^n |\hat{y}_i - y_i - 1|}$$

**Πλεονεκτήματα:** είναι ανεξάρτητο από την κλίμακα, καθιστώντας το κατάλληλο για σύγκριση της ακρίβειας πρόβλεψης μεταξύ διαφορετικών χρονοσειρών με ποικίλες κλίμακες. Παρέχει ένα ουσιαστικό και ερμηνεύσιμο μέτρο της ακρίβειας των προβλέψεων. Τέλος, είναι ανθεκτικό σε ακραίες τιμές και ακραίες τιμές στα δεδομένα.

**Μειονεκτήματα:** μπορεί να είναι ευαίσθητο σε μηδενικές ή σχεδόν μηδενικές τιμές στον παρονομαστή, κάτι που μπορεί να οδηγήσει σε αστάθεια ή διαίρεση με το μηδέν. Υποθέτει ότι το αφελές μοντέλο είναι ακριβές, κάτι που μπορεί να μην συμβαίνει πάντα.

```
Python
1 # Install library
2 !pip install scikit-learn
3
4 # Import libraries
5 from sklearn.metrics import mean_absolute_error
6
7 def mean_absolute_scaled_error(actual, predicted):
8     """
9     Calculate MASE (Mean Absolute Scaled Error).
10    """
11    mae = mean_absolute_error(actual, predicted)
12    naive_error = np.mean(np.abs(actual[1:] - actual[:-1]))
13    return mae / naive_error
14
15 # Calculate MASE
16 mase = mean_absolute_scaled_error(actual_values, predicted_values)
17 print("MASE:", mase)
```

Εικόνα 16 MASE Python code

## Κεφάλαιο 5

### 5. Τεχνητά Νευρωνικά Δίκτυα

#### 5.1. Περιγραφή των νευρωνικών δικτύων

Τα τεχνητά νευρωνικά δίκτυα είναι απλοποιημένα μοντέλα του κεντρικού νευρικού συστήματος του ανθρώπινου οργανισμού. Προσομοιώνουν τη λειτουργία και τη δομή των βιολογικών νευρωνικών δικτύων. Αποτελούνται από συνδεδεμένα υπολογιστικά στοιχεία που έχουν την ικανότητα να ανταποκρίνονται σε ερεθίσματα που δέχονται στην είσοδο τους και να μαθαίνουν να προσαρμόζονται στο περιβάλλον τους.

Βασικό στοιχείο του εγκεφάλου είναι οι νευρώνες, δηλαδή τα νευρικά κύτταρα τα οποία δημιουργούν ένα πυκνό δίκτυο επικοινωνίας μεταξύ τους. Τα τεχνητά νευρωνικά δίκτυα χρησιμοποιούν πολύ βασικά χαρακτηριστικά των βιολογικών νευρωνικών δικτύων, κυρίως λόγω της υψηλής πολυπλοκότητας των δεύτερων.

Τα βασικά αυτά κοινά χαρακτηριστικά είναι:

- Η απόκτηση γνώσης μέσα από μια διαδικασία μάθησης, εκπαίδευσης και επανάληψης
- Η αποθήκευση γνώσης στα βάρη των νευρώνων

Για να είναι εφικτή η απόκτηση και αποθήκευση αυτής της γνώσης, το τεχνητό νευρωνικό δίκτυο θα πρέπει να έχει ένα πλήθος από νευρώνες (αναλόγως και του προβλήματος που επιζητούμε να επιλύσουμε) και οι νευρώνες αυτοί να έχουν ρυθμιζόμενες παραμέτρους ώστε να είναι πραγματοποιήσιμη η διαδικασία της μάθησης και αποθήκευσης.

#### 5.2. Βιολογικά νευρωνικά δίκτυα

Η λειτουργία ενός βιολογικού νευρωνικού δικτύου χωρίζεται σε τρία στάδια.

Το πρώτο στάδιο είναι η είσοδος του συστήματος και απαρτίζεται από αισθητήρες και υποδοχείς ερεθισμάτων από το περιβάλλον.

Το δεύτερο στάδιο είναι η επεξεργασία των ερεθισμάτων από τους υποδοχείς. Σε αυτό το στάδιο το νευρικό σύστημα αντιλαμβάνεται και αποθηκεύει της πληροφορίες που μεταφέρουν τα ερεθίσματα, μετατρέποντας τα σε κατάλληλες μορφές για περαιτέρω μετάδοση των πληροφοριών στο υπόλοιπο σύστημα.

Το τρίτο στάδιο αποτελείται από τους αποδέκτες των σημάτων των νευρώνων, ώστε αυτά να μετατραπούν σε κατάλληλο σήμα απόκρισης, αναλόγως του τελικού οργάνου αποδέκτη της πληροφορίας.

Το νευρικό σύστημα μπορούμε να το παρομοιάσουμε με ένα σύστημα με είσοδο, επεξεργασία και έξοδο, με ταυτόχρονη ύπαρξη ανατροφοδότησης.

Υπολογίζεται ότι στον ανθρώπινο εγκέφαλο υπάρχουν περίπου 10 δισεκατομμύρια νευρώνες, οι οποίοι έχουν αναπτύξει μεταξύ τους συνδέσεις που ονομάζονται συνάψεις και ο αριθμός τους υπολογίζεται στα περίπου 60 τρισεκατομμύρια.

Οι συνάψεις είναι οι στοιχειώδεις δομικές και λειτουργικές μονάδες που μεσολαβούν ώστε να αλληλοεπιδράσουν μεταξύ τους οι νευρώνες. Το πλήθος και το μέγεθος των

συνάψεων μεταβάλλεται διαρκώς στον εγκέφαλο, αναλόγως το πλήθος και το είδος των ερεθισμάτων που δέχεται το νευρικό σύστημα. Η πλειοψηφία των νευρώνων κωδικοποιούν τις εξόδους τους ως μια σειρά βραχέων παλμών. Αυτοί οι παλμοί είναι γνωστοί ως αιχμές. Οι αιχμές παράγονται από το κέντρο των νευρώνων και διαδίδονται με σταθερή ταχύτητα και πλάτος.

Η ταχύτητα μετάδοσης αυτών των αιχμών σε ένα νευρικό σύστημα είναι πολύ πιο αργή σε σχέση με την ταχύτητα μετάδοσης ενός παλμού σε ένα τεχνητό νευρωνικό δίκτυο, αλλά η πολυπλοκότητα και το βάθος της επεξεργασίας που υπάρχει ακόμα και σε έναν απλοϊκό βιολογικό οργανισμό είναι πολλές τάξεις μεγαλύτερη σε σύγκριση ακόμα και με τις πιο σύγχρονες υλοποιήσεις τεχνητών νευρωνικών δικτύων.

Οι τεχνητοί νευρώνες που χρησιμοποιούμε στα τεχνητά νευρωνικά δίκτυα είναι σε εμβρυικό στάδιο σε σύγκριση με τους βιολογικούς νευρώνες. Επίσης απλοϊκά είναι και τα νευρωνικά μας δίκτυα σε σύγκριση με το νευρικό σύστημα ενός βιολογικού οργανισμού. Είναι όμως ελπιδοφόρα η εξέλιξη που υπάρχει τόσο στην έρευνα της κατανόησης του νευρικού συστήματος, όσο και στην ανάπτυξη ολοένα και περισσότερο εξελιγμένων τεχνητών νευρωνικών δικτύων και σε ταχύτητα και σε πολυπλοκότητα.

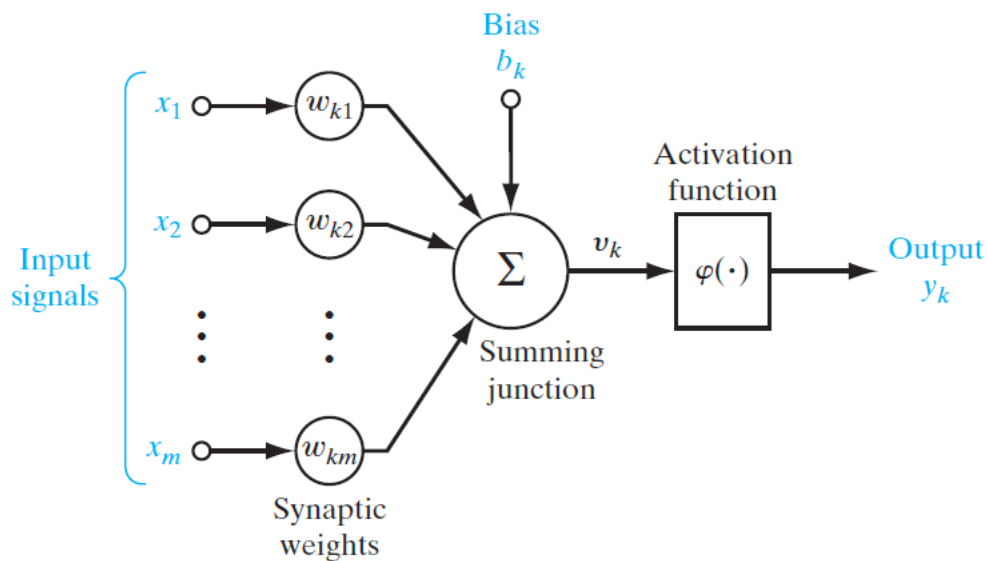
### 5.3. Μοντέλο του τεχνητού νευρωνικού δικτύου

Ένας νευρώνας είναι μια μονάδα επεξεργασίας που είναι θεμελιώδης για τη λειτουργία ενός νευρωνικού δικτύου. Στο παρακάτω διάγραμμα (Σχήμα 2.1) απεικονίζεται το μοντέλο ενός νευρώνα, που είναι η βάση μιας μεγάλης ομάδας τεχνητών νευρωνικών δικτύων.

Τα βασικά μέρη του μοντέλου είναι:

- Ένα σύνολο συνάψεων, κάθε μία από τις οποίες χαρακτηρίζεται από ένα συγκεκριμένο βάρος
- Ένας αθροιστής, ο οποίος αθροίζει τις εισόδους σταθμισμένες από τα αντίστοιχα βάρη
- Μία λειτουργία ενεργοποίησης για τον περιορισμό του εύρους της αιχμής εξόδου σε κάποια πεπερασμένη τιμή





Εικόνα 17 Μη γραμμικό μοντέλο νευρώνα

Το μοντέλο προβλέπει και μία εξωτερική είσοδο Bias για περίπτωση που χρειαστεί κάποιος νευρώνας να εξισορροπήσει το σήμα πριν την είσοδο της συνάρτησης ενεργοποίησης στην έξοδο του νευρώνα.

Η λειτουργία του τεχνητού νευρώνα εκφράζεται με μαθηματικό τρόπο ως εξής:

$$u_k = \sum_{j=1}^m w_{kj} x_j$$
$$v_k = u_k + b_k$$
$$y_k = \varphi(v_k)$$

όπου  $x_1, x_2, \dots, x_m$  είναι τα σήματα εισόδου από τις συνάψεις και  $w_{k1}, w_{k2}, \dots, w_{km}$  τα βάρη των συνάψεων του νευρώνα  $k$ .

Το νευρωνικό δίκτυο μπορεί να απεικονιστεί και ως κατευθυνόμενος γράφος με ακμές που μπορούν να έχουν γραμμικά βάρη ή και μη γραμμικά βάρη. Ο γράφος αυτός χαρακτηρίζεται από τέσσερις ιδιότητες:

- Κάθε νευρώνας (κόμβος) αποτελείται από μία ομάδα γραμμικών συνάψεων (ακμών) ή/και μη γραμμικών συνάψεων
- Οι γραμμικές συνάψεις έχουν βάρος
- Το σταθμισμένο άθροισμα των σημάτων εισόδου καθορίζει το επαγόμενο τοπικό πεδίο του νευρώνα
- Η λειτουργία ενεργοποίησης περιορίζει το εύρος του επαγόμενου τοπικού πεδίου, για να παράγει την έξοδο.


#### 5.4. Αρχιτεκτονική Νευρωνικών Δικτύων

Ο τρόπος με τον οποίο δομούνται οι νευρώνες ενός νευρωνικού δικτύου είναι στενά συνδεδεμένος με τον αλγόριθμο μάθησης που χρησιμοποιείται για την εκπαίδευση του δικτύου.

Γενικά υπάρχουν τρεις αρχιτεκτονικές τεχνητών νευρωνικών δικτύων:

•**Δίκτυα ενός επιπέδου εμπρός τροφοδότησης**


Είναι ο απλούστερος τύπος των τεχνητών νευρωνικών δικτύων, ο οποίος αποτελείται από ένα επίπεδο εισόδου και ένα επίπεδο νευρώνων εξόδου. Αναφέρεται ως ενός επιπέδου, διότι μόνο στο επίπεδο των νευρώνων γίνεται επεξεργασία των πληροφοριών-σημάτων.



Εικόνα 18 Δίκτυο εμπρός τροφοδότησης ενός επιπέδου

•**Δίκτυα πολλαπλών επιπέδων εμπρός τροφοδότησης**

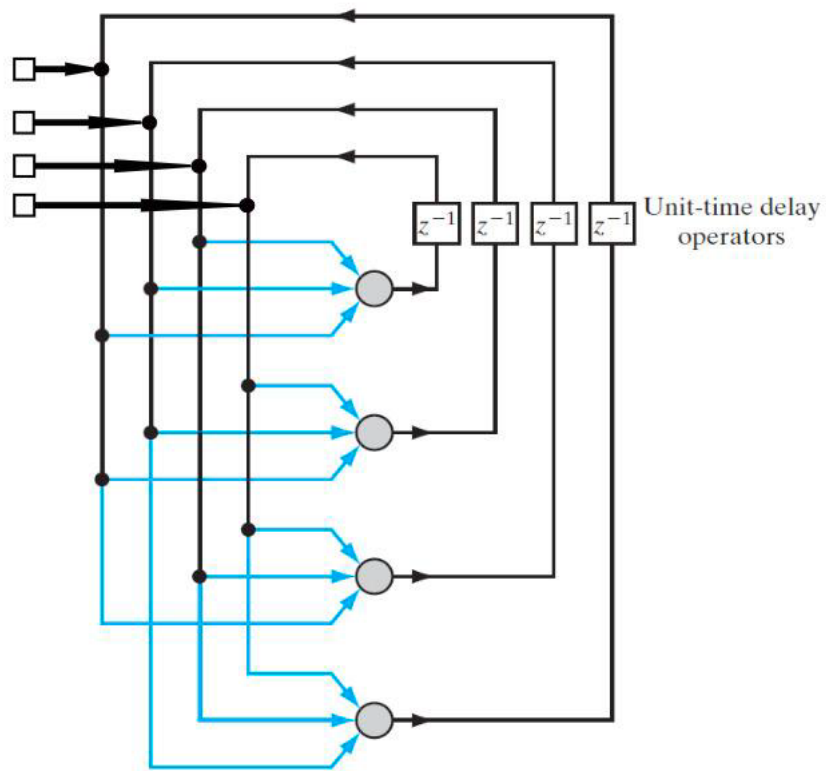
Σε αντίθεση με τα δίκτυα ενός επιπέδου, τα δίκτυα πολλαπλών επιπέδων περιέχουν εκτός από το επίπεδο εξόδου των σημάτων και ένα ή περισσότερα κρυφά επίπεδα νευρώνων, ενώ η είσοδος ενός επιπέδου είναι η έξοδος του προηγούμενου επιπέδου νευρώνων. Τα δίκτυα πολλαπλών επιπέδων έχουν τη δυνατότητα να επεξεργάζονται πληροφορίες εισόδου υψηλής πολυπλοκότητας με μεγαλύτερη ευχέρεια, λόγω των επιπλέον διαστάσεων που προστίθενται στο δίκτυο από τα επιπλέον κρυφά επίπεδα νευρώνων.



Εικόνα 19 Δίκτυο εμπρός τροφοδότησης ενός κρυφού επιπέδου και ενός επιπέδου εξόδου

#### •Δίκτυα με ανατροφοδότηση

Η διαφορά με τα δίκτυα εμπρός τροφοδότησης είναι η ύπαρξη ενός ή περισσότερων βρόγχων ανατροφοδότησης. Η ύπαρξη βρόγχου ανατροφοδότησης προσθέτει στο νευρωνικό δίκτυο μεγαλύτερη ικανότητα εκμάθησης και κυρίως αυξάνει την αποδοτικότητα του ως προς την ταχύτητα της διαδικασίας εκμάθησης. [




Εικόνα 20 Δίκτυο με ανατροφοδότηση

## 5.5. Βασικά Νευρωνικά Δίκτυα

### 5.5.1. Πολυεπίπεδος Perception (Multilayer Perceptron - MLP)

Η απλούστερη περίπτωση ΤΝΔ που αποτελούν και την ευρύτερη χρησιμοποιούμενη κατηγορία ΤΝΔ είναι τα δίκτυα πρόσθιας τροφοδότησης (feedforward networks). Το χαρακτηριστικό των δικτύων αυτών είναι ότι δεν υπάρχει ανατροφοδότηση της εξόδου ενός νευρώνα προς τους νευρώνες από τους οποίους επηρεάζεται άμεσα ή έμμεσα. Τα δίκτυα αυτά ονομάζονται πρόσθιας τροφοδότησης γιατί, με δεδομένη κάποια είσοδο  $x$ , για τον υπολογισμό της εξόδου πραγματοποιούνται υπολογισμοί, όλοι προς την ίδια κατεύθυνση: από την είσοδο προς την έξοδο. [2], [26]

Από τους πιο διαδεδομένους αλγόριθμους αυτού του είδους είναι ο πολυεπίπεδος Perceptron, όπου οι νευρώνες είναι οργανωμένοι σε επίπεδα (layers). Το χαρακτηριστικό των επιπέδων είναι ότι δεν υπάρχει διασύνδεση μεταξύ των νευρώνων του ίδιου επιπέδου, αλλά οι νευρώνες οποιουδήποτε επιπέδου τροφοδοτούν αποκλειστικά τους νευρώνες του επόμενου επιπέδου και τροφοδοτούνται από το προηγούμενο επίπεδο. Ο αλγόριθμος αποτελείται από το επίπεδο εισόδου, εξόδου και ένα ή περισσότερα ενδιάμεσα κρυμμένα επίπεδα (hidden layer). Επιπλέον, οι νευρώνες στο επίπεδο εισόδου δεν πραγματοποιούν υπολογισμούς, απλώς μεταδίδουν την τιμή του διανύσματος εισόδου στο επόμενο επίπεδο. Συνήθως οι συνδέσεις ξεκινούν από έναν νευρώνα και καταλήγουν σε νευρώνες στο επόμενο επίπεδο. Παρακάτω φαίνεται η αρχιτεκτονική ενός MLP.



Εικόνα 21 Αρχιτεκτονική MLP

Ένας MLP εκπαιδεύεται κυρίως με τον αλγόριθμο Back Propagation και χρησιμοποιεί μη γραμμικές συναρτήσεις ενεργοποίησης. Επικρατέστερες είναι οι σιγμοειδείς συναρτήσεις.

Σχεδιασμός και εκπαίδευση μοντέλου: [27]

- Επιλογή αριθμού κρυμμένων επιπέδων
- Επιλογή νευρώνων σε κάθε κρυμμένο επίπεδο
- Επιλογή βέλτιστης αλγοριθμικής λύσης για ελαχιστοποίηση σφάλματος
- Εφαρμογή της λύσης αυτής σε εύλογο χρονικό διάστημα
- Έλεγχος του Νευρωνικού Δικτύου για αποφυγή υπερπροσαρμογής (overfitting), δηλαδή τα δεδομένα να μην επαρκούν για την εκπαίδευση του μοντέλου

Ύστερα από το πέρας των παραπάνω βημάτων, στόχος είναι η μείωση του σφάλματος πρόβλεψης με την κατάλληλη επιλογή βαρών και ορίων. Σε αυτό βοηθούν οι αλγόριθμοι εκπαίδευσης που επιλέγονται για να εκπαιδεύσουν το δίκτυο σύμφωνα με την ιστορικότητα που έχουν συλλέξει. Συγκεκριμένα συγκρίνουν τα αποτελέσματα της κάθε στιγμής με συγκεκριμένες τιμές εξόδου. Όλες οι αποκλίσεις συλλέγονται σε μία συνάρτηση υπολογισμού σφάλματος του δικτύου. Αξίζει να σημειωθεί ότι ο MLP με μόνο ένα κρυφό επίπεδο μπορεί να παρουσιάσει πολύ καλά αποτελέσματα πρόβλεψης. Σπάνια είναι η επιλογή δύο κρυφών επιπέδων και όταν γίνεται είναι σε δεδομένα με ασυνέχεια. Τέλος, ο αριθμός των νευρώνων στα κρυμμένα επίπεδα, έχει καθοριστικό ρόλο στα αποτελέσματα του αλγορίθμου. Σε κάθε περίπτωση πρέπει να αποφεύγονται ο πολύ μικρός αριθμός νευρώνων, διότι υπάρχει κίνδυνος υποπροσαρμογής (underfitting) του μοντέλου, όπως και ο πολύ μεγάλος αριθμός νευρώνων γιατί μπορεί να οδηγηθεί σε υπερπροσαρμογή το δίκτυο (overfitting).

#### *5.5.2. Επαναλαμβανόμενα Νευρωνικά Δίκτυα (Recurrent Neural Networks-RNN)*

Τα RNN είναι από τα πολύ αποδοτικά δίκτυα, όταν πρόκειται να πραγματοποιηθούν προβλέψεις σε ακολουθιακά δεδομένα, όπως χρονοσειρές, ήχος, καιρικά φαινόμενα, οικονομικά δεδομένα, αναγνώριση φωνής, αναγνώριση χειρόγραφου κ.ά. όπως θα αναλυθεί παρακάτω.

Χαρακτηρίζονται ισχυρά δίκτυα στο χώρο των Νευρωνικών Δικτύων, καθώς αποτελούνται από κρυμμένους κόμβους όπου μπορούν να αποθηκεύουν πολλές παρελθοντικές πληροφορίες. Τα περισσότερα Νευρωνικά Δίκτυα θεωρούν ότι όλες οι τιμές εισόδου και εξόδου είναι ανεξάρτητες μεταξύ τους, γεγονός που δυσκολεύει τις περισσότερες φορές τις προβλέψεις. Αντιθέτως τα RNN λόγω της εσωτερικής μνήμης τους θυμούνται πολλές πληροφορίες που εισήχθησαν στο δίκτυο με αποτέλεσμα να δίνουν ακριβέστερες προβλέψεις.

#### **Λειτουργία**

Στα κλασικά Feed – Forward Νευρωνικά Δίκτυα η πληροφορία που εισέρχεται δεν περνάει δεύτερη φορά από έναν κόμβο και πηγαίνει προς μία μόνο κατεύθυνση, σε αντίθεση με τα RNN όπου η πληροφορία περιστρέφεται γύρω από έναν βρόγχο κάνοντας κύκλο στο δίκτυο, με αποτέλεσμα να λαμβάνει υπόψιν μαζί με την τρέχουσα τιμή και τις προηγούμενες. Συνεπώς, τα RNN έχουν δύο εισόδους, μία για την νέα πληροφορία και μία για την παρελθοντική, όπου συνδυάζονται προκειμένου να διαχειριστούν την νέα πληροφορία που θα εισαχθεί. Θα έλεγε κανείς ότι αυτός ο τρόπος λειτουργίας συνάδει αρκετά με του ανθρώπινου εγκέφαλου. Ουσιαστικά, με

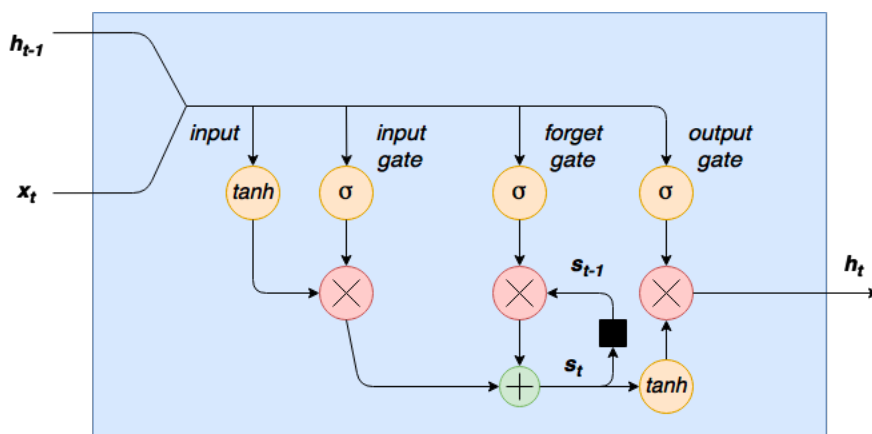
την βοήθεια της κρυμμένης εσωτερικής μνήμης, εντοπίζονται εξαρτήσεις μεταξύ πληροφοριών για διαδοχικές χρονικές στιγμές που ονομάζονται Μακροχρόνιες Εξαρτήσεις. Επιπλέον, σε κάθε κόμβο του δικτύου υπάρχουν τα αντίστοιχα βάρη που επηρεάζουν τα τελικά αποτελέσματα. Ακολουθεί η μαθηματική αναπαράσταση της παραπάνω διαδικασίας:

$$h_t = \Phi(W \cdot x_t + U \cdot h_{t-1})$$

Όπου  $h_t$  η κρυμμένη κατάσταση την χρονική στιγμή  $t$ ,  $W$  το βάρος μεταξύ των εισροών και του κρυμμένου επιπέδου,  $x_t$  η τιμή εισόδου την χρονική στιγμή  $t$ ,  $U$  ο συντελεστής μετάβασης μεταξύ του κρυμμένου επιπέδου και του εαυτού του και  $h_{t-1}$  η κρυμμένη κατάσταση την χρονική στιγμή  $t-1$ . Το σφάλμα που παράγεται θα επιστρέψει μέσω του Backpropagation και το Νευρωνικό θα προσαρμόσει κατάλληλα τα βάρη του. [28]

### 5.5.3. Μακράς Βραχυχρόνιας Μνήμης Νευρωνικά Δίκτυα (Long Short-Term Memory - LSTM)

Τα Νευρωνικά Δίκτυα Long-Short Term Memory (LSTM) εμφανίστηκαν το 1997, ανήκουν στην οικογένεια RNN και μοντελοποιήθηκαν με σκοπό να διαχειριστούν τις Μακροχρόνιες Εξαρτήσεις, παρουσιάζοντας υψηλές αποδόσεις ακρίβειας. [20] Η αρχιτεκτονική τους αποτελείται από ένα σύνολο επαναλαμβανόμενων (recurrent) συνδεδεμένων υπό-δικτύων, γνωστά ως μπλοκ μνήμης. Κάθε τέτοιο μπλοκ περιέχει ένα ή περισσότερα αυτό-συνδεδεμένα κελιά μνήμης (memory cells) και τρεις πύλες, την πύλη εισόδου, την πύλη εξόδου και την forget πύλη. Μία πύλη εισόδου, είναι ένα στρώμα από σιγμοειδείς κόμβους, με τιμές εξόδου 0 ή 1, οι οποίοι μπορούν να διώξουν όποια στοιχεία του διανύσματος εισόδου θεωρούν αχρείαστα. Η πύλη forget, ελέγχει ποια πληροφορία από την προηγούμενη κατάσταση θα περάσει στην τωρινή ή θα ξεχαστεί. Οι δύο αυτές πύλες μαζί, επιτρέπουν στο δίκτυο να ελέγχει ποια πληροφορία θα αποθηκεύεται και ποια θα αντικατασταθεί σε κάθε βήμα. Τέλος η πύλη εξόδου, είναι αυτή που ελέγχει ποιες τιμές θα επιτραπούν ως έξοδοι από το μπλοκ.



Εικόνα 22 Απεικόνιση κελιού μνήμης

Αναλυτικότερα, η είσοδος  $x_t$  συνδέεται με την προηγούμενη είσοδο  $h_{t-1}$  και η συνδυασμένη τιμή περνάει σ' ένα στρώμα συνάρτησης  $\tanh$ , στο πρώτο βήμα του μπλοκ. Στο δεύτερο βήμα περνάει από την πύλη εισόδου. Η πύλη εισόδου αποτελείται από σιγμοειδή συνάρτηση ενεργοποίηση και τα αποτελέσματα των κόμβων που ενεργοποιούνται πολλαπλασιάζονται με την τιμή που παράχθηκε από

το πρώτο επίπεδο. Στο τρίτο βήμα σ' ένα κελί μνήμης βρίσκεται ο βρόγχος της πύλη forget. . Στο μπλοκ υπάρχει η εσωτερική μεταβλητή  $st$ , αυτή η μεταβλητή με μία χρονική υστέρηση  $st-1$ , προστίθεται στα δεδομένα και δημιουργείται ένα στρώμα επανάληψης, το οποίο ελέγχεται από την πύλη forget. Τέλος, υπάρχει το στρώμα εξόδου με την συνάρτηση  $tanh$ , που ελέγχεται από την πύλη εξόδου. Η πύλη εξόδου είναι υπεύθυνη ποιες τιμές επιτρέπονται και ποιες απορρίπτονται ως έξοδοι από το μπλοκ.

Μαθηματικά εκφράζεται με την παρακάτω αλληλουχία:

Όπου  $x_t$  οι τιμές εισόδου και  $y_t$  οι τιμές εξόδου, τις χρονικές στιγμές από  $t=1$  έως  $T$ .  $U, V$  είναι τα βάρη της τιμής εισόδου και της προηγούμενης τιμής εξόδου αντίστοιχα, ενώ  $b$  η πόλωση της τιμής εισόδου.

$$\begin{aligned} g &= \tanh(bg + xtUg + ht-1Vg) \\ i &= \sigma(bi + xtUi + ht-1Vi) \\ g \circ i \\ f &= \sigma(bf + xtUf + ht-1Vf) \\ st &= st-1 \circ f + g \circ i \\ o &= \sigma(bo + xtUo + ht-1Vo) \\ ht &= \tanh(st) \circ o \end{aligned}$$

#### 5.5.4. Φραγμένα Επαναλαμβανόμενα Νευρωνικά Δίκτυα (Gated Recurrent Units - GRUs)

Η αρχιτεκτονική δικτύου GRU παρουσιάστηκε από το Cho Kyunghyun το 2014. Ανήκει στην οικογένειά RNN δικτύων και πιο συγκεκριμένα μοιάζει με τον LSTM αλγόριθμο σε απλούστερη μορφή. Το δίκτυο συνδυάζει τις πύλες εισόδου και forget σε μία πύλη, που ονομάζεται πύλη ενημέρωσης (update gate), παράλληλα η πύλη εξόδου ονομάζεται πύλη επαναφοράς (reset gate). Το μοντέλο είναι αρκετά πιο απλό από ένα LSTM ωστόσο έχει και αυτό σκοπό να αναβαθμίζει ή να επαναφέρει το περιεχόμενο της μνήμης. Το δίκτυο GRU εκθέτει πλήρως το περιεχόμενο της μνήμης του και με την μέθοδο ολοκλήρωση διαρροής (Leaky Integration), ισορροπεί μεταξύ του προηγούμενου περιεχομένου μνήμης και του νέου περιεχομένου μνήμης.

Η μαθηματική αλληλουχία που περιγράφει τα βάρη σ' ένα GRU δίκτυο είναι:

$$h_i^{(t)} = u_i^{(t-1)} h_i^{(t-1)} + (1 - u_i^{(t-1)}) \sigma \left( b_i + \sum_j U_{i,j} x_j^{(t)} + \sum_j W_{i,j} r_j^{(t-1)} h_j^{(t-1)} \right)$$

Όπου  $u$  είναι η πύλη ανανέωσης και  $r$  η πύλη επαναφοράς και δίνονται από τις σχέσεις:

$$\begin{aligned} u_i^{(t)} &= \sigma \left( b_i^u + \sum_j U_{i,j}^u x_j^{(t)} + \sum_j W_{i,j}^u h_j^{(t)} \right) \\ r_i^{(t)} &= \sigma \left( b_i^r + \sum_j U_{i,j}^r x_j^{(t)} + \sum_j W_{i,j}^r h_j^{(t)} \right) \end{aligned}$$

Οι πύλες ενημέρωσης μπορούν να περιορίσουν γραμμικά οποιαδήποτε κατάσταση και η πύλη επαναφοράς ρυθμίζει πόση από την προηγούμενη μνήμη θα χαθεί και πόση από την νέα θα συνυπολογιστεί στο δίκτυο.



## 5.6. Διαδικασία μάθησης ενός τεχνητού νευρωνικού δικτύου

Ο βασικός σκοπός ενός τεχνητού νευρωνικού δικτύου είναι να μπορεί να λύνει συγκεκριμένα προβλήματα ή να πραγματοποιεί από μόνο του ορισμένες διεργασίες. Για να μπορεί όμως να γίνει αυτό πρέπει πρώτα το δίκτυο να έχει εκπαιδευτεί κατάλληλα. Αυτό είναι και το πιο σημαντικό χαρακτηριστικό των νευρωνικών δικτύων, ότι δηλαδή εκπαιδεύονται και μαθαίνουν. Τα τεχνητά νευρωνικά δίκτυα πραγματοποιούν δύο βασικές λειτουργίες, τη μάθηση και την ανάκληση.

Μάθηση ονομάζεται η διαδικασία της τροποποίησης των βαρών των νευρώνων του δικτύου.

Ανάκληση ονομάζεται η διαδικασία του υπολογισμού ενός διανύσματος εξόδου για συγκεκριμένο διάνυσμα εισόδου και με συγκεκριμένες τιμές βαρών των νευρώνων.

Η μάθηση γίνεται με τη χρήση κάποιων παραδειγμάτων εκπαίδευσης και ενός αλγορίθμου εκπαίδευσης, ο οποίος είναι μια επαναληπτική διαδικασία με την οποία τροποποιούνται οι παράμετροι του νευρωνικού μας δικτύου.

Η διαδικασία αυτή ονομάζεται εκπαίδευση του νευρωνικού δικτύου και υπάρχουν τρία είδη εκπαίδευσης:

### •Μάθηση με επίβλεψη:

Δίνονται στο δίκτυο ζευγάρια διανυσμάτων εισόδου και επιθυμητής εξόδου. Ο αλγόριθμος εκπαίδευσης τροποποιεί καταλλήλως τα βάρη των νευρώνων του δικτύου ώστε να έχει το δίκτυο την επιθυμητή έξοδο για την κάθε είσοδο.

Ο εκπαιδευτής που τροφοδοτεί το δίκτυο με τα ζευγάρια διανυσμάτων, έχει γνώση του περιβάλλοντος που θα λειτουργήσει το νευρωνικό δίκτυο. Τελικός σκοπός της εκπαίδευσης του δικτύου είναι να μεταφερθεί αυτή η γνώση του εκπαιδευτή στο νευρωνικό δίκτυο.

**•Βαθμολογημένη μάθηση:**

Δίνονται στο δίκτυο διανύσματα εισόδου χωρίς όμως τις επιθυμητές εξόδους. Η έξοδος που θα παραχθεί από το νευρωνικό δίκτυο χαρακτηρίζεται από τον εκπαιδευτή ως καλή ή κακή με βάση μια αριθμητική κλίμακα, οπότε το δίκτυο προσαρμόζει αναλόγως τα βάρη των νευρώνων του ώστε να επιτύχει καλύτερα συνολικά αποτελέσματα.

Η διαδικασία αυτή είναι γνωστή ως ενίσχυση σήματος και ανατροφοδότησης του δικτύου ώστε να επιβραβεύονται τα καλά αποτελέσματα και να τιμωρούνται τα λάθος αποτελέσματα.

**•Μάθηση χωρίς επίβλεψη:**

Στην περίπτωση αυτή, η απόκριση του τεχνητού νευρωνικού δικτύου βασίζεται στην ικανότητά του να αυτό-οργανώνεται με βάση τα διανύσματα εισόδου, καθώς δεν δίνονται αντίστοιχα διανύσματα εξόδου. Αυτή η εσωτερική αυτό-οργάνωση πραγματοποιείται με τέτοιο τρόπο ώστε σε συγκεκριμένο σύνολο εισόδων να αντιδρά ισχυρά ένας μοναδικός νευρώνας.

Το δίκτυο χρησιμοποιεί έναν εσωτερικό έλεγχο κοινών χαρακτηριστικών στις εισόδους, ψάχνει να βρει κανονικότητα στα σήματα εισόδου και εκπαιδεύεται ώστε οι έξοδοι να έχουν τα ίδια χαρακτηριστικά με τις εισόδους. Έτσι το δίκτυο ελέγχει τον εαυτό του και διορθώνει τα σφάλματα στα δεδομένα με ένα μηχανισμό ανάδρασης. Όταν το δίκτυο σταματήσει να αλλάζει τις τιμές των βαρών των νευρώνων, τότε η εκπαίδευση έχει τερματίσει. [22]

## Κεφάλαιο 6

### 6. Υλοποίηση του θέματος της εργασίας

#### 6.1. Πηγή Δεδομένων (Dataset)

Για τη συλλογή δεδομένων χρησιμοποιήθηκε η πλατφόρμα ανίχνευσης Tiingo από τη βιβλιοθήκη Pandas Datareader που παρέχει ένα αρί δεδομένων με ιστορικές τιμές τέλους ημέρας σε μετοχές, αμοιβαία κεφάλαια και ETF. Για την παρούσα έρευνα χρησιμοποιήθηκαν οι τιμές των μετοχών των εταιρειών Apple (AAPL) και Google (GOOG).

Το σύνολο των δεδομένων αποτελεί μία χρονοσειρά τιμών πέντε ετών με χαρακτηριστικά symbol, date, close, high, low, open, volume, adjClose, adjHigh, adjLow, adjOpen, adjVolume, divCash, splitFactor.

	symbol	date	close	high	low	open	volume	adjClose	adjHigh	adjLow	adjOpen	adjVolume	divCash	splitFactor
0	AAPL	2019-03-11 00:00:00+00:00	178.90	179.12	175.35	175.49	32011034	43.055363	43.108310	42.200995	42.234688	128044136	0.0	1.0
1	AAPL	2019-03-12 00:00:00+00:00	180.91	182.67	179.37	180.00	32467584	43.539104	43.962679	43.168477	43.320097	129870336	0.0	1.0
2	AAPL	2019-03-13 00:00:00+00:00	181.71	183.30	180.92	182.25	31032524	43.731638	44.114299	43.541511	43.861598	124130096	0.0	1.0
3	AAPL	2019-03-14 00:00:00+00:00	183.73	184.10	182.56	183.90	23579508	44.217786	44.306833	43.936205	44.258699	94318032	0.0	1.0
4	AAPL	2019-03-15 00:00:00+00:00	186.12	187.33	183.74	184.85	39042912	44.792981	45.084188	44.220193	44.487333	156171648	0.0	1.0

Εικόνα 23 Αρχική ημερομηνία δεδομένων μετοχής Apple

	symbol	date	close	high	low	open	volume	adjClose	adjHigh	adjLow	adjOpen	adjVolume	divCash	splitFactor
1253	AAPL	2024-03-01 00:00:00+00:00	179.66	180.53	177.38	179.55	73563082	179.66	180.53	177.38	179.55	73563082	0.0	1.0
1254	AAPL	2024-03-04 00:00:00+00:00	175.10	176.90	173.79	176.15	81510101	175.10	176.90	173.79	176.15	81510101	0.0	1.0
1255	AAPL	2024-03-05 00:00:00+00:00	170.12	172.04	169.62	170.76	95132355	170.12	172.04	169.62	170.76	95132355	0.0	1.0
1256	AAPL	2024-03-06 00:00:00+00:00	169.12	171.24	168.68	171.06	68587707	169.12	171.24	168.68	171.06	68587707	0.0	1.0
1257	AAPL	2024-03-07 00:00:00+00:00	169.00	170.73	168.49	169.15	71765061	169.00	170.73	168.49	169.15	71765061	0.0	1.0

Εικόνα 24 Τελική ημερομηνία δεδομένων μετοχής Apple

	symbol	date	close	high	low	open	volume	adjClose	adjHigh	adjLow	adjOpen	adjVolume	divCash	splitFactor
0	GOOG	2019-03-11 00:00:00+00:00	1175.76	1176.19	1144.45	1144.450	1719192	58.7880	58.8095	57.2225	57.22250	34383840	0.0	1.0
1	GOOG	2019-03-12 00:00:00+00:00	1193.20	1200.00	1178.26	1178.260	2013115	59.6600	60.0000	58.9130	58.91300	40262300	0.0	1.0
2	GOOG	2019-03-13 00:00:00+00:00	1193.32	1200.93	1191.94	1200.645	1435936	59.6660	60.0465	59.5970	60.03225	28718720	0.0	1.0
3	GOOG	2019-03-14 00:00:00+00:00	1185.55	1197.88	1184.48	1194.510	1172815	59.2775	59.8940	59.2240	59.72550	23456300	0.0	1.0
4	GOOG	2019-03-15 00:00:00+00:00	1184.46	1196.57	1182.61	1193.380	2459957	59.2230	59.8285	59.1305	59.66900	49199140	0.0	1.0

Εικόνα 25 Αρχική ημερομηνία δεδομένων μετοχής Google

	symbol	date	close	high	low	open	volume	adjClose	adjHigh	adjLow	adjOpen	adjVolume	divCash	splitFactor
1253	GOOG	2024-03-01 00:00:00+00:00	138.08	140.00	137.975	139.61	28551525	138.08	140.00	137.975	139.61	28551525	0.0	1.0
1254	GOOG	2024-03-04 00:00:00+00:00	134.20	136.63	132.860	136.54	43571510	134.20	136.63	132.860	136.54	43571510	0.0	1.0
1255	GOOG	2024-03-05 00:00:00+00:00	133.78	134.02	131.550	132.74	28447550	133.78	134.02	131.550	132.74	28447550	0.0	1.0
1256	GOOG	2024-03-06 00:00:00+00:00	132.56	134.74	131.950	134.24	23175200	132.56	134.74	131.950	134.24	23175200	0.0	1.0
1257	GOOG	2024-03-07 00:00:00+00:00	135.24	135.82	132.660	133.89	24018212	135.24	135.82	132.660	133.89	24018212	0.0	1.0

Εικόνα 26 Τελική ημερομηνία δεδομένων μετοχής Google

## 6.2. Βήματα μελέτης

Τα βήματα για την επίτευξη της μελέτης είναι η συλλογή των δεδομένων και οπτικοποίηση αυτών, η επαναεπεξεργασία των δεδομένων - εκπαίδευση και έλεγχος, δημιουργία ενός μοντέλου LSTM, πρόβλεψη των test δεδομένων και διαγραμματική απεικόνιση των αποτελεσμάτων και τέλος πρόβλεψη των μελλοντικών 30 ημερών και διαγραμματική απεικόνιση των αποτελεσμάτων.

## 6.3. Συλλογή Δεδομένων και Οπτικοποίηση

Μέσα από το Jupiter Notebook σε web περιβάλλον από το Anaconda Navigator με χρήση της Pandas Datareader καλέσαμε τα δεδομένα με το κατάλληλο Api Key από την πλατφόρμα Tiingo. Οι χρηματιστηριακές εγγραφές για την τελευταία πενταετία είναι 1257 (συμπεριλαμβανομένης και της μηδενικής εγγραφής).

Για την παρούσα μελέτη θα χρησιμοποιηθεί η τιμή κλεισίματος των μετοχών.

```
df1=df.reset_index()['close']
```

df1	
0	178.90
1	180.91
2	181.71
3	183.73
4	186.12
...	
1253	179.66
1254	175.10
1255	170.12
1256	169.12
1257	169.00

Name: close, Length: 1258, dtype: float64

Εικόνα 27 Πλήθος τιμών κλεισίματος για τη μετοχή της Apple

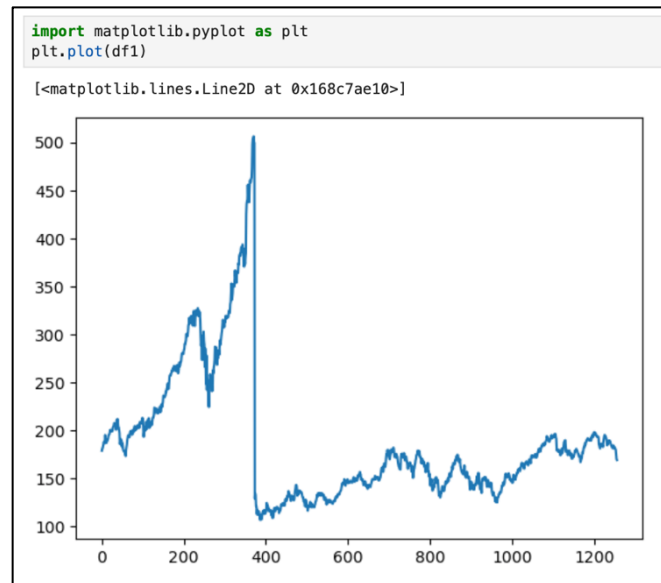
```
df1=df.reset_index()['close']
```

df1	
0	1175.76
1	1193.20
2	1193.32
3	1185.55
4	1184.46
...	
1253	138.08
1254	134.20
1255	133.78
1256	132.56
1257	135.24

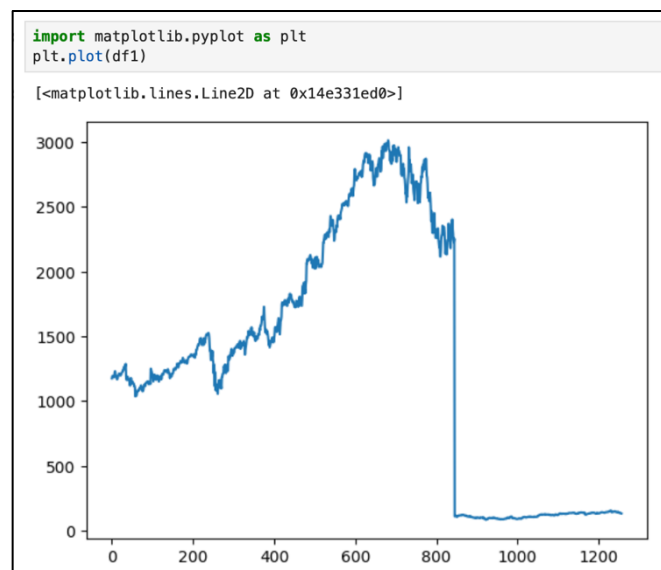
Name: close, Length: 1258, dtype: float64

Εικόνα 28 Πλήθος τιμών κλεισίματος για τη μετοχή της Google

Για την οπτικοποίηση των δεδομένων χρησιμοποιήθηκε η βιβλιοθήκη Matplotlib της Python.



Εικόνα 29 Η διαγραμματική απεικόνιση της τιμής κλεισίματος της μετοχής της Apple συναρτήσεϊ των εγγραφών εμφάνισης στην περίοδο της πενταετίας



Εικόνα 30 Η διαγραμματική απεικόνιση της τιμής κλεισίματος της μετοχής της Google συναρτήσεϊ των εγγραφών εμφάνισης στην περίοδο της πενταετίας

Το LSTM μοντέλο νευρωνικού δικτύου που θα χρησιμοποιηθεί είναι ευαίσθητο στην κλίμακα των δεδομένων εισόδου, ειδικά όταν χρησιμοποιούνται οι συναρτήσεϊς ενεργοποίησης σιγμοειδούς ή tanh. Είναι καλή πρακτική η επανακλιμάκωση των δεδομένων στο εύρος 0-1, που ονομάζεται επίσης κανονικοποίηση. Με αυτό τον τρόπο βοηθάμε το μοντέλο να συγκλίνει ταχύτερα. Είναι πιθανό ότι οι μεγάλες τιμές στις εισροές επιβραδύνουν τη μάθηση. Θα χρησιμοποιήσουμε το MinMaxScaler από τη βιβλιοθήκη sklearn για να κλιμακώσουμε τα δεδομένα.

```
from sklearn.preprocessing import MinMaxScaler
scaler=MinMaxScaler(feature_range=(0,1))
df1=scaler.fit_transform(np.array(df1).reshape(-1,1))

print(df1)

[[0.18048842]
 [0.18552286]
 [0.18752661]
 ...
 [0.15849718]
 [0.15599249]
 [0.15569192]]
```

Εικόνα 31 Κανονικοποίηση των δεδομένων της μετοχής της Apple με χρήση της sklearn

#### 6.4. Επεξεργασία των Δεδομένων – Εκπαίδευση (Train) και Έλεγχος (Test)

Στη μηχανική μάθηση (ML), η γενίκευση συνήθως αναφέρεται στην ικανότητα ενός αλγορίθμου να είναι αποτελεσματικός σε διάφορες εισόδους. Σημαίνει ότι το μοντέλο ML δεν αντιμετωπίζει υποβάθμιση της απόδοσης στις νέες εισόδους από την ίδια κατανομή των δεδομένων εκπαίδευσης.

Για τους ανθρώπους η γενίκευση είναι το πιο φυσικό πράγμα. Μπορούμε να ταξινομήσουμε με μεγάλη ευκολία. Για παράδειγμα, σίγουρα θα αναγνωρίζαμε έναν σκύλο ακόμα κι αν δεν είχαμε ξαναδεί αυτή τη ράτσα. Ωστόσο, μπορεί να είναι μια μεγάλη πρόκληση για ένα μοντέλο ML. Γι' αυτό ο έλεγχος της ικανότητας γενίκευσης του αλγορίθμου είναι μια σημαντική εργασία που απαιτεί μεγάλη προσοχή κατά την κατασκευή του μοντέλου.

Για να επιτευχθεί αυτό, ειδικά σε προβλήματα ταξινόμησης γραμμικής παλινδρόμησης χρησιμοποιούνται οι μέθοδοι Cross Validating και Random Seed.

Η διασταυρούμενη επικύρωση - Cross Validating (CV) είναι μια τεχνική για την αξιολόγηση ενός μοντέλου μηχανικής μάθησης και τη δοκιμή της απόδοσής του. Το CV χρησιμοποιείται συνήθως σε εφαρμοσμένες εργασίες ML. Βοηθά στη σύγκριση και την επιλογή ενός κατάλληλου μοντέλου για το συγκεκριμένο πρόβλημα προγνωστικής μοντελοποίησης.

Το CV είναι εύκολα κατανοητό, εύκολο στην εφαρμογή και τείνει να έχει χαμηλότερη προκατάληψη από άλλες μεθόδους που χρησιμοποιούνται για την καταμέτρηση των βαθμολογιών απόδοσης του μοντέλου. Όλα αυτά καθιστούν τη διασταυρούμενη επικύρωση ένα ισχυρό εργαλείο για την επιλογή του καλύτερου μοντέλου για τη συγκεκριμένη εργασία.

Υπάρχουν πολλές διαφορετικές τεχνικές που μπορούν να χρησιμοποιηθούν για τη διασταυρούμενη επικύρωση ενός μοντέλου. Ωστόσο, όλοι έχουν έναν παρόμοιο αλγόριθμο:

- Διαχωρισμός του συνόλου δεδομένων σε δύο μέρη: ένα για εκπαίδευση και άλλο για δοκιμή
- Εκπαίδευση του μοντέλου στο σετ εκπαίδευσης
- Επικύρωση του μοντέλου στο δοκιμαστικό σετ
- Επανάληψη των 1-3 βημάτων μερικές φορές. Αυτός ο αριθμός εξαρτάται από τη μέθοδο CV που χρησιμοποιείται

Η μέθοδος Random Seed χρησιμοποιείται για να διασφαλιστεί ότι τα αποτελέσματα είναι αναπαράξιμα. Με άλλα λόγια, η χρήση αυτής της παραμέτρου διασφαλίζει ότι

όποιος εκτελεί ξανά τον κώδικά σας θα έχει τις ίδιες ακριβώς εξόδους. Η αναπαραγωγή είναι μια εξαιρετικά σημαντική έννοια στην επιστήμη των δεδομένων και σε άλλους τομείς.

Στις χρονοσειρές (time series) όπου τα δεδομένα έχουν άμεση εξάρτηση από τις παρελθοντικές τιμές, όπως στην παρούσα μελέτη, θα προχωρήσουμε στο διαχωρισμό του συνόλου των δεδομένων σε train dataset και test dataset σε μία αναλογία 65%-35% και στη συνέχεια θα προχωρήσουμε στην προεπεξεργασία των δεδομένων.

```
training_size=int(len(df1)*0.65)
test_size=len(df1)-training_size
train_data,test_data=df1[0:training_size:],df1[training_size:len(df1),:1]

training_size,test_size

(817, 441)
```

Εικόνα 32 Διαχωρισμός δεδομένων σε Train Dataset και Test Dataset

Κατά τη φάση της προεπεξεργασίας των δεδομένων των δύο dataset υπενθυμίζουμε ότι υπάρχει άμεση συσχέτιση των τιμών κλεισίματος μίας μετοχής με τις προηγούμενες τιμές κλεισίματος. Βάση αυτής της λογικής θα δημιουργήσουμε μία loop με ορισμένο ένα χρονικό βήμα (timestep) το οποίο θα μας δώσει τους πίνακες X\_train, y\_train και X\_test, ytest όπου θα χρησιμεύσουν στην εκπαίδευση του μοντέλου LSTM.

```
import numpy
# convert an array of values into a dataset matrix
def create_dataset(dataset, time_step=1):
    dataX, dataY = [], []
    for i in range(len(dataset)-time_step-1):
        a = dataset[i:(i+time_step), 0] ###i=0, 0,1,2,3-----99 100
        dataX.append(a)
        dataY.append(dataset[i + time_step, 0])
    return numpy.array(dataX), numpy.array(dataY)

# reshape into X=t,t+1,t+2,t+3 and Y=t+4
time_step = 100
X_train, y_train = create_dataset(train_data, time_step)
X_test, ytest = create_dataset(test_data, time_step)
```

Εικόνα 33 Data Preprocessing

## 6.5. Δημιουργία Στατικού Μοντέλου LSTM

### 6.5.1. API Keras

Το Keras είναι το API υψηλού επιπέδου της πλατφόρμας TensorFlow. Παρέχει μια προσιτή, εξαιρετικά παραγωγική διεπαφή για την επίλυση προβλημάτων μηχανικής μάθησης (ML), με έμφαση στη σύγχρονη βαθιά μάθηση. Το Keras καλύπτει κάθε βήμα της ροής εργασιών μηχανικής εκμάθησης, από την επεξεργασία δεδομένων έως τον συντονισμό υπερπαραμέτρων έως την ανάπτυξη. Αναπτύχθηκε με έμφαση στην παροχή δυνατότητας γρήγορου πειραματισμού. Με το Keras, υπάρχει πλήρης πρόσβαση στις δυνατότητες επεκτασιμότητας και πολλαπλών πλατφορμών του TensorFlow. Το Keras μπορεί να εκτελεστεί σε ένα TPU Pod ή μεγάλα συμπλέγματα GPU και μπορείτε να εξαγάγετε μοντέλα Keras για εκτέλεση στο πρόγραμμα περιήγησης ή σε κινητές συσκευές. Μπορείτε επίσης να εξυπηρετήσετε μοντέλα Keras μέσω ενός web API.

Το Keras έχει σχεδιαστεί για να μειώνει το γνωστικό φορτίο επιτυγχάνοντας τους ακόλουθους στόχους:

- Προσφέρει απλές, συνεπείς διεπαφές.
- Ελαχιστοποιεί τον αριθμό των ενεργειών που απαιτούνται για περιπτώσεις κοινής χρήσης.
- Παρέχει σαφή μηνύματα λάθους με δυνατότητα ενεργοποίησης.
- Προοδευτική εκμάθηση
- Βοηθά σε ένα συνοπτικό και ευανάγνωστο κώδικα.

Οι βασικές δομές δεδομένων του Keras είναι επίπεδα και μοντέλα. Ένα επίπεδο είναι ένας απλός μετασχηματισμός εισόδου/εξόδου και ένα μοντέλο είναι ένα κατευθυνόμενο ακυκλικό γράφημα (DAG) επιπέδων.

#### **Επίπεδα**

Η κλάση `tf.keras.layers.Layer` είναι η θεμελιώδης αρχή στο Keras. Ένα Επίπεδο ενσωματώνει μια κατάσταση (βάρος) και κάποιους υπολογισμούς (που ορίζονται στη μέθοδο `tf.keras.layers.Layer.call`).

Τα βάρη που δημιουργούνται από στρώματα μπορεί να είναι εκπαιδευσιμα ή μη. Τα επίπεδα είναι αναδρομικά συνθέσιμα: Εάν αντιστοιχιστεί μια παρουσία επιπέδου ως χαρακτηριστικό ενός άλλου επιπέδου, το εξωτερικό στρώμα θα αρχίσει να παρακολουθεί τα βάρη που δημιουργούνται από το εσωτερικό στρώμα.

Μπορεί επίσης να χρησιμοποιηθούν επίπεδα για να χειριστούν εργασίες προεπεξεργασίας δεδομένων όπως η κανονικοποίηση και η διανυσματική διαμόρφωση κειμένου. Τα στρώματα προεπεξεργασίας μπορούν να συμπεριληφθούν απευθείας σε ένα μοντέλο, είτε κατά τη διάρκεια είτε μετά την εκπαίδευση, γεγονός που καθιστά το μοντέλο φορητό.



## Μοντέλα

Ένα μοντέλο είναι ένα αντικείμενο που ομαδοποιεί τα επίπεδα και το οποίο μπορεί να εκπαιδευτεί σε δεδομένα.

Ο απλούστερος τύπος μοντέλου είναι το Sequential model, το οποίο είναι μια γραμμική στοίβα στρωμάτων. Για πιο σύνθετες αρχιτεκτονικές, μπορείτε είτε να χρησιμοποιήσετε το λειτουργικό API Keras, το οποίο αποτρέπει από το να δημιουργηθούν αυθαίρετα γραφήματα επιπέδων, είτε να χρησιμοποιηθεί υποκλάση για να γραφούν τα μοντέλα από την αρχή.

Η τάξη `tf.keras.Model` διαθέτει ενσωματωμένες μεθόδους εκπαίδευσης και αξιολόγησης:

- `tf.keras.Model.fit`: Εκπαιδεύει το μοντέλο για σταθερό αριθμό εποχών.
- `tf.keras.Model.predict`: Δημιουργεί προβλέψεις εξόδου για τα δείγματα εισόδου.
- `tf.keras.Model.evaluate`: Εμφανίζει τις τιμές απώλειας και μετρήσεων για το μοντέλο. ρυθμίζεται μέσω της μεθόδου `tf.keras.Model.compile`.

Στο παρόν πείραμα χρησιμοποιούνται το Sequential Model, το οποίο αποτελείται από μία γραμμική στοίβα πολλών επιπέδων και το Dense Layer. Ο Optimizer Adam και για την αξιολόγηση της απόδοσης των μοντέλων χρησιμοποιείται ο δείκτης Mean Square Error (MSE).

Οι παραδοχές της `model.fit` είναι:

x: Εισαγωγή δεδομένων. Θα μπορούσε να είναι:

- Ένας πίνακας NumPy (ή σαν πίνακας) ή μια λίστα πινάκων (σε περίπτωση που το μοντέλο έχει πολλαπλές εισόδους).
- Ένας tensor ή μια λίστα tensors (σε περίπτωση που το μοντέλο έχει πολλαπλές εισόδους).
- Μια αντιστοίχιση εισόδου ονομάζει τον αντίστοιχο πίνακα/tensors, εάν το μοντέλο έχει ονομαστικές εισόδους.
- Ένα σύνολο δεδομένων `tf.data`. Θα πρέπει να επιστρέψει μια πλειάδα είτε (εισορές, στόχοι) είτε (εισορές, στόχοι, δείγματα\_βαρών).
- Ένα σύνολο `keras.utils.PyDataset` που επιστρέφει (εισοδους, στόχοι) ή (εισορές, στόχοι, δείγματα\_βαρών).

y: Δεδομένα στόχου.

Όπως και τα δεδομένα εισόδου `x`, θα μπορούσε να είναι είτε πίνακας NumPy είτε εγγενής tensor (-οι) backend. Εάν το `x` είναι ένα σύνολο δεδομένων, μια γεννήτρια ή μια περίπτωση `keras.utils.PyDataset`, το `y` δεν θα πρέπει να καθοριστεί (καθώς οι στόχοι θα ληφθούν από το `x`).

Batch\_size:

Ακέραιος ή Κανέναν. Αριθμός δειγμάτων ανά ενημέρωση κλίσης. Εάν δεν έχει καθοριστεί, το batch\_size θα είναι προεπιλεγμένο σε 32. Μην προσδιορίζετε το batch\_size εάν τα δεδομένα σας έχουν τη μορφή συνόλων δεδομένων, γεννητριών ή παρουσιών keras.utils.PyDataset (καθώς δημιουργούν παρτίδες).

Epoch:

Ακέραιος αριθμός. Αριθμός εποχών για την εκπαίδευση του μοντέλου. Μια εποχή είναι μια επανάληψη σε όλα τα δεδομένα x και y που παρέχονται (εκτός εάν η σημαία step\_per\_epoch έχει οριστεί σε κάτι διαφορετικό από None). Σημειώστε ότι σε συνδυασμό με την αρχική\_εποχή, οι εποχές πρέπει να νοούνται ως "τελική εποχή". Το μοντέλο δεν εκπαιδεύεται για έναν αριθμό επαναλήψεων που δίνονται από εποχές, αλλά απλώς μέχρι να φτάσει η εποχή των εποχών δεικτών.

Verbose:

"αυτόματο", 0, 1 ή 2. Λειτουργία βερμπαλισμού. 0 = αθόρυβο, 1 = γραμμή προόδου, 2 = μία γραμμή ανά εποχή. Το "auto" γίνεται 1 για τις περισσότερες περιπτώσεις. Λάβετε υπόψη ότι η γραμμή προόδου δεν είναι ιδιαίτερα χρήσιμη όταν είναι συνδεδεμένη σε ένα αρχείο, επομένως το verbose=2 συνιστάται όταν δεν εκτελείται διαδραστικά (π.χ. σε περιβάλλον παραγωγής). Οι προεπιλογές είναι "auto".

```
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense
from tensorflow.keras.layers import LSTM

model=Sequential()
model.add(LSTM(50, return_sequences=True, input_shape=(100, 1)))
model.add(LSTM(50, return_sequences=True))
model.add(LSTM(50))
model.add(Dense(1))
model.compile(loss='mean_squared_error', optimizer='adam')

model.fit(X_train,y_train, validation_data=(X_test,ytest), epochs=100, batch_size=64, verbose=1)
```

Εικόνα 34 LSTM Stacked Model

## 6.6. Πρόβλεψη των test δεδομένων και διαγραμματική απεικόνιση των αποτελεσμάτων


### Η LTSM για την Apple

Σε συνέχεια δοκιμών του μοντέλου με epoch 100, 300 και 500 έχουμε:

Test	Optimizer	Epoch	Test MSE y_train	Test MSE y_test
1	Adam	100	226.23	178.01
2	Adam	300	220.55	173.84
3	Adam	500	219.33	172.73

Από τον ανωτέρω πίνακα βλέπουμε ότι αποδοτικότερο είναι το μοντέλο στα 500 epoch.

Στο διάγραμμα βλέπουμε με μπλε χρώμα τις πραγματικές τιμές και με πορτοκαλί τις προβλέψεις για το σύνολο των δεδομένων (65% του αρχικού df) που χρησιμοποιήθηκε για την εκπαίδευση του μοντέλου ( $y_{train}$ ) και με πράσινο τις προβλέψεις για το σύνολο των δεδομένων που χρησιμοποιήθηκαν για τον έλεγχο του μοντέλου ( $y_{test}$ ). Παρατηρούμε ότι το μοντέλο λειτουργεί αρκετά καλά δεδομένου ότι δεν παρουσιάζονται διακυμάνσεις ανάμεσα στις προβλέψεις και τις πραγματικές τιμές.



Εικόνα 35 Γραφική Αναπαράσταση των πραγματικών τιμών με γαλάζιο και των προβλέψεων με πορτοκαλί για σύνολο των δεδομένων εκπαίδευσης ( $y_{train}$ ) και με πράσινο για το σύνολο των δεδομένων ελέγχου ( $y_{test}$ ) για τη μετοχή της Apple


## Η LSTM για την Google

Σε συνέχεια δοκιμών του μοντέλου με epoch 100, 300 και 500 έχουμε:

Test	Optimizer	Epoch	Test MSE $y_{train}$	Test MSE $y_{test}$
1	Adam	100	2082.59	159.94
2	Adam	300	2131.79	199.50
3	Adam	500	2056.46	125.43

Από τον ανωτέρω πίνακα βλέπουμε ότι αποδοτικότερο είναι το μοντέλο στα 500 epoch.

Στο διάγραμμα βλέπουμε με μπλε χρώμα τις πραγματικές τιμές και με πορτοκαλί τις προβλέψεις για το σύνολο των δεδομένων (65% του αρχικού df) που χρησιμοποιήθηκε για την εκπαίδευση του μοντέλου ( $y_{train}$ ) και με πράσινο τις προβλέψεις για το σύνολο των δεδομένων που χρησιμοποιήθηκαν για τον έλεγχο του μοντέλου ( $y_{test}$ ). Παρατηρούμε ότι το μοντέλο λειτουργεί αρκετά καλά δεδομένου ότι δεν παρουσιάζονται διακυμάνσεις ανάμεσα στις προβλέψεις και τις πραγματικές τιμές.



Εικόνα 36 Γραφική Αναπαράσταση των πραγματικών τιμών με γαλάζιο και των προβλέψεων με πορτοκαλί για σύνολο των δεδομένων εκπαίδευσης ( $y_{train}$ ) και με πράσινο για το σύνολο των δεδομένων ελέγχου ( $y_{test}$ ) για τη μετοχή της Google

## 6.7. Πρόβλεψη των μελλοντικών 30 ημερών και διαγραμματική απεικόνιση των αποτελεσμάτων

Η πρόβλεψη των μελλοντικών τιμών των μετοχών των επόμενων ημερών πέραν αυτών του dataset βασίζεται πάνω στις τελευταίες 100 τιμές του συνόλου δεδομένων που χρησιμοποιήθηκαν για τον έλεγχο του μοντέλου (test\_data).

Τα βήματα που ακολουθούνται είναι:

- πρόβλεψη για τις επόμενες 30 ημέρες, i=30
- βρίσκουμε το μέγεθος του test\_data
- κάνουμε reshape για την εύρυθμη λειτουργία του LSTM μοντέλου στις τελευταίες 100 τιμές του test\_data (n\_steps=100) και τα αποτελέσματα τα βάζουμε σε λίστα
- με την model.predict γίνεται πρόβλεψη της επόμενης τιμής της μετοχής και αυτή η τιμή προστίθεται στη λίστα
- τέλος τρέχουμε loop ώστε το μοντέλο να κινείται πάντα μία τιμή δεξιά από τη λίστα τιμών για να γίνεται πάντα υπολογισμός επί των τελευταίων 100 δεδομένων

```
from numpy import array


lst_output=[]
n_steps=100
i=0
while(i<30):

    if(len(temp_input)>100):
        #print(temp_input)
        x_input=np.array(temp_input[1:])
        print("{} day input {}".format(i,x_input))
        x_input=x_input.reshape(1,-1)
        x_input = x_input.reshape((1, n_steps, 1))
        #print(x_input)
        yhat = model.predict(x_input, verbose=0)
        print("{} day output {}".format(i,yhat))
        temp_input.extend(yhat[0].tolist())
        temp_input=temp_input[1:]
        #print(temp_input)
        lst_output.extend(yhat.tolist())
        i=i+1
    else:
        x_input = x_input.reshape((1, n_steps,1))
        yhat = model.predict(x_input, verbose=0)
        print(yhat[0])
        temp_input.extend(yhat[0].tolist())
        print(len(temp_input))
        lst_output.extend(yhat.tolist())
        i=i+1
```


Εικόνα 37 Κώδικας για την πρόβλεψη μελλοντικών τιμών μετοχής για διάστημα 30 ημερών

Κάτωθι τα διαγράμματα για τις μελλοντικές τιμές 30 ημερών των μετοχών Apple και Google για τις τελευταίες 131 τιμές (test\_data και 30 νέες τιμές), καθώς και τα ενοποιημένα διαγράμματα με το σύνολο όλων των τιμών.

Διαγράμματα Apple, Google test\_data και 30 νέων τιμών




Εικόνα 38 Διάγραμμα μετοχής Apple test\_data και 30 νέων τιμών




Εικόνα 39 Διάγραμμα μετοχής Google test\_data και 30 νέων τιμών

Ενοποιημένα διαγράμματα Apple, Google με το σύνολο δεδομένων και 30 νέων τιμών



Εικόνα 40 Ενοποιημένο διάγραμμα Apple με το σύνολο δεδομένων και 30 νέων τιμών



Εικόνα 41 Ενοποιημένο διάγραμμα Google με το σύνολο δεδομένων και 30 νέων τιμών

Βελτιστοποίηση όλου του μοντέλου μπορεί να γίνει εάν αυξηθούν τα timesteps σε 150 και η πρόβλεψη μελλοντικών τιμών σε 100.

### 6.8. Σύνοψη Αποτελεσμάτων

Συνοψίζοντας τα αποτελέσματα της μελέτης οικονομικών στοιχείων για την πρόβλεψη συμπεριφοράς τους στη σύγχρονη οικονομική πραγματικότητα με χρήση των τεχνητών νευρωνικών δικτύων καταλήγουμε στο συμπέρασμα ότι ένα μοντέλο νευρωνικού δικτύου με τη σωστή επιλογή χρονοσειράς (λίγες παρατηρήσεις και μικρή διακύμανση) και την κατάλληλη επεξεργασία, μπορεί να δώσει πολύ καλά αποτελέσματα.

## Βιβλιογραφία

- [1] Ράπτης Σάββας - Τι είναι η μηχανική μάθηση (machine learning); – Μέρος Α: “Εισαγωγή” - <https://2science.gr/machine-learning-1/>
- [2] Παγουρτζή Ουρ. [2021] Διπλωματική Εργασία «Τεχνικές Εξόρυξης Δεδομένων και Νευρωνικών Δικτύων σε Οικονομικά Δεδομένα»
- [3] Αικατερίνη Γεωργούλη (2015 Αθήνα). Μηχανική Μάθηση, Σύνδεσμος Ελληνικών Ακαδημαϊκών Βιβλιοθηκών, Κεφάλαιο 4.
- [4] Tom M. Mitchell (March 1, 1997). Machine Learning, McGraw-Hill Science/Engineering/Math, chapter 4.
- [5] Wikipedia, «Ορισμός\_Χρηματιστηρίου»\_ <https://el.wikipedia.org/wiki/Χρηματιστήριο>
- [6] Wikipedia, «Ορισμός\_Μετοχής»\_ [https://el.wikipedia.org/wiki/Μετοχή\\_\(χρηματοοικονομικά\)](https://el.wikipedia.org/wiki/Μετοχή_(χρηματοοικονομικά))
- [7] Λελεδάκης Γ. [2007] "Ανάλυση και Διαχείριση Χαρτοφυλακίου", Εκδόσεις Οικονομικού Πανεπιστημίου Αθηνών
- [8] Βασιλείου Δ., [2008], Διαχείριση Χαρτοφυλακίου, 2<sup>η</sup> έκδοση, Ελληνικό Ανοικτό Πανεπιστήμιο, Πάτρα
- [9] Τσόπελας Θ. [2023] Διπλωματική Εργασία «Τεχνικές Εξόρυξης Δεδομένων και Νευρωνικών Δικτύων σε Οικονομικά Δεδομένα»
- [10] Michel K Evans Practical Business Forecasting UK Robert H Shumway David S.Stoffer, [2011] Time series Analysis and its Applications
- [11] Wiley, [2008], Introduction to Time Series Analysis and Forecasting
- [12] Rob J Hyndman, [2009], Business Forecasting Methods
- [13] Ζιουαλιά Μ. [2018] Διπλωματική Εργασία «Ανάλυση Χρονοσειρών για την Πρόβλεψη Επιχειρήσεων»
- [14] Στούμπου Χ., [2021], Διπλωματική Εργασία «Μέθοδοι Πρόβλεψης και Εφαρμογές»
- [15] Καρώνη, Χ., Οικονόμου, Π. (2017). Στατιστικά Μοντέλα Παλινδρόμησης Με χρήση MINITAB και R (2η Έκδοση), Εκδόσεις ΣΥΜΕΩΝ, Αθήνα.
- [16] Φουσκάκης, Δ. (2013). Ανάλυση Δεδομένων με χρήση της R, Εκδόσεις Τσότρας, Αθήνα
- [17] Πανεπιστήμιο Πειραιά (2012), Πακέτο Σημειώσεων: Βασικές Σημειώσεις, Εκθετική Εξομάλυνση με τη χρήση του Microsoft Excel, URL: [https://eclass.unipi.gr/modules/document/file.php/OEP141/Βασικές%20σημειώσεις/exponential%20smoothing%20in%20excel.pdf?fbclid=IwAR3zpfKUrSTjup oG9iJAYhwK9EvmLigEgJFgE-dgw3xIE\\_JxNb7hGvOKS-I](https://eclass.unipi.gr/modules/document/file.php/OEP141/Βασικές%20σημειώσεις/exponential%20smoothing%20in%20excel.pdf?fbclid=IwAR3zpfKUrSTjup oG9iJAYhwK9EvmLigEgJFgE-dgw3xIE_JxNb7hGvOKS-I)
- [18] Sio-long Ao, [2009], “Applied Time Series Analysis and Innovative Computing”
- [19] Engle R.F., [1982], “Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation”, Econometrica. 50, pp.987-1008
- [20] Hamilton J.D., [1994], “Times Series Analysis”, Princeton University Press
- [21] C. Chatfield, [1984], “The Analysis of time series: An Introduction”, Third Edition
- [22] Αλχαζίδης Β., [2019], Διπλωματική Εργασία «Μελέτη χρήσης νευρωνικών δικτύων για την επεξεργασία χωροχρονικών δεδομένων από δίκτυα αισθητήρων»



- [23] Simon Haykin, [2009], “Neural Networks and Learning Machines”, 3rd ed., Pearson Education
- [24] Stephen Marsland, [2015 ], “Machine Learning, an Algorithmic Perspective”, 2nd ed., CRC Press
- [25] Αικατερίνη Γεωργούλη, [2015], «Μηχανική Μάθηση», Σύνδεσμος Ελληνικών Ακαδημαϊκών Βιβλιοθηκών
- [26] Σαλάτας Ι., [2011], Διπλωματική Εργασία «Υλοποίηση και εφαρμογή Τεχνητών Νευρωνικών Δικτύων για την πρόβλεψη χρονοσειρών συναλλαγματικών ισοτιμιών»
- [27] Behaviour Analysis of Multilayer Perceptrons with Multiple Hidden Neurons and Hidden Layers Article in International Journal of Computer Theory and Engineering, [2011]
- [28] Zachary C. Lipton, John Berkowitz, Charles Elkan, [2015], A Critical Review of Recurrent Neural Networks for Sequence Learning
- [29] <https://static.javatpoint.com/tutorial/machine-learning/images/regression-vs-classification-in-machine-learning.png>
- [30] <https://www.schwab.com/stocks/understand-stocks>
- [31] <https://www.5paisa.com/stock-market-guide/stock-share-market/risk-management-in-stock-market>
- [32] <https://hr.fullerton.edu/risk-management/information-and-document-requests/information-management/essential-techniques-of-risk-management.php>
- [33] [https://www.youtube.com/watch?v=H6du\\_pfuznE](https://www.youtube.com/watch?v=H6du_pfuznE)
- [34] <https://neptune.ai/blog/cross-validation-in-machine-learning-how-to-do-it-right>
- [35] <https://www.tensorflow.org/guide/keras>
- [36] [https://keras.io/api/models/model\\_training\\_apis/](https://keras.io/api/models/model_training_apis/)