

**ΠΑΝΕΠΙΣΤΗΜΙΟ ΠΕΙΡΑΙΩΣ – ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ****Πρόγραμμα Μεταπτυχιακών Σπουδών  
«Κυβερνοασφάλεια και Επιστήμη Δεδομένων»****Μεταπτυχιακή Διατριβή**

Τίτλος Διατριβής	<b>Business Analytics in Practice: The Case of Demand Forecasting</b> <b>Πρόβλεψη Ζήτησης Έτοιμων Γευμάτων με την Χρήση Προηγμένων Μεθόδων Αναλυτικής</b>
Όνοματεπώνυμο Φοιτητή	<b>Μπενάκης Κωνσταντίνος</b>
Πατρώνυμο	<b>Θωμάς</b>
Αριθμός Μητρώου	<b>ΜΠΚΕΔ21035</b>
Επιβλέπων	<b>Δημήτριος Αποστόλου, Καθηγητής</b>

Ημερομηνία Παράδοσης **Σεπτέμβριος 2024**

Στην ολοκλήρωση της παρούσας μεταπτυχιακής διατριβής, ιδιαίτερα σημαντική ήταν η συμβολή του Διδάσκοντα του ΠΜΣ **κ. Ανδρέα Ζάρα**, που προσέφερε επιστημονική και συμβουλευτική καθοδήγηση σε όλα τα στάδια εκπόνησής της.

#### **Τριμελής Εξεταστική Επιτροπή**

Δημήτρης Αποστόλου,  
Καθηγητής

Άγγελος Πικράκης,  
Επίκουρος Καθηγητής

Δρ Γρηγόρης Κορωνάκος,  
Διδάσκων ΠΜΣ

# ΠΕΡΙΕΧΟΜΕΝΑ

ΠΕΡΙΕΧΟΜΕΝΑ .....	3
ΛΙΣΤΑ ΕΙΚΟΝΩΝ .....	5
ΛΙΣΤΑ ΠΙΝΑΚΩΝ .....	6
ΣΥΝΤΟΜΟΓΡΑΦΙΕΣ .....	7
1 .....	11
Εισαγωγή.....	11
1.1 Παράδοση Φαγητού μέσω Διαδικτύου (Online Food Delivery).....	11
1.2 Πρόβλεψη Ζήτησης στον Κλάδο της Παράδοση Φαγητού μέσω Διαδικτύου.....	12
1.3 Περιγραφή προβλήματος .....	13
1.4 Στόχος εργασίας.....	13
1.5 Διάρθρωση εργασίας.....	14
2.....	15
Πρόβλεψη Ζήτησης (Demand Forecasting).....	15
2.1 Η Έννοια της Πρόβλεψης Ζήτησης .....	15
2.2 Πρόβλεψη βάσει Ζήτησης (Demand Driven Forecasting).....	16
2.2.1 Στάδια Πρόβλεψης βάσει Ζήτησης .....	16
2.3 Επιχειρησιακά οφέλη της πρόβλεψης ζήτησης.....	19
2.4 Σημαντικά εργαλεία για τη διαμόρφωση της ζήτησης.....	21
2.4.1 Μοντελοποίηση Προώθησης (Promotional Modelling) .....	22
2.4.2 Ελαστικότητα Ζήτησης ως προς την Τιμή & Βελτιστοποίηση (Price Elasticity & Optimization).....	22
3.....	25
Μέθοδοι και Τεχνικές Πρόβλεψης Ζήτησης.....	25
3.1 Χρησιμότητα μεθόδων Πρόβλεψης Ζήτησης .....	25
3.2 Ποσοτική Πρόβλεψη Ζήτησης.....	26
3.2.1 Οικονομετρικά Μοντέλα (Econometric Models) .....	27
3.2.2 Μοντέλα Χρονοσειρών .....	28
3.2.2.1 Μοντέλο ARIMA .....	29
3.2.2.2 Μοντέλο SARIMA.....	30
3.2.2.3 Βασικές διαφορές ARIMA - SARIMA.....	30
3.2.2.4 Μοντέλο UCM .....	31
3.2.2.5 Εκθετική Εξομάλυνση (Exponential Smoothing) .....	32
3.2.2.6 Αυτοσυσχέτιση (ACF) .....	35
3.2.2.7 Μερική αυτοσυσχέτιση (PACF).....	36

3.2.3	Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (MAPE) .....	37
3.3	Ποιοτική Πρόβλεψη Ζήτησης (Qualitative Demand Forecasting).....	39
3.3.1	Μέθοδοι Ποιοτική Πρόβλεψη Ζήτησης .....	39
3.4	Ιεραρχική Πρόβλεψη (Hierarchical Forecasting).....	41
4.....		44
Πρόβλεψη με SAS.....		44
4.1	Μεθοδολογία και βήματα υλοποίησης.....	44
4.1.1	Προεπεξεργασία δεδομένων .....	45
4.1.2	Στατιστικά δεδομένων .....	47
4.1.3	Εφαρμογή ARIMA - GS .....	50
4.2	Αποτελέσματα.....	51
4.2.1	Μοντέλο ARIMA .....	51
4.2.2	Ανάλυση με Python.....	55
4.2.3	Μοντέλο GS.....	61
5.....		71
Συζήτηση αποτελεσμάτων .....		71
5.1	Περιορισμοί κατά την εφαρμογή .....	71
5.2	Συμπεράσματα και μελλοντικές βελτιώσεις.....	72
6.....		73
Επίλογος.....		73
6.1	Πλεονεκτήματα demand forecasting σε εφοδιαστική αλυσίδα και λειτουργίες επιχειρήσεων 73	
Παράρτημα Α: Κώδικας SAS .....		76
Παράρτημα Β: Κώδικας Python (Προετοιμασία δεδομένων).....		81
ΒΙΒΛΙΟΓΡΑΦΙΑ - ΑΝΑΦΟΡΕΣ .....		84

## ΛΙΣΤΑ ΕΙΚΟΝΩΝ

Εικόνα 1: Διάγραμμα δένδροειδούς δομής με χρήση του SAS .....	45
Εικόνα 2: Συνολικές παραγγελίες σε διάστημα τριών μηνών .....	48
Εικόνα 3: Συνολικές παραγγελίες για τα τρία επικρατέστερα είδη κουζίνας .....	49
Εικόνα 4: Μηνιαία συνολική τάση των παραγγελιών .....	50
Εικόνα 5: Ανάλυση για τις τιμές: shop_city = Πειραιάς, shop_area = Πειραιάς και shop_cuisine = Σουβλάκια ..	51
Εικόνα 6: Δοκιμή λευκού θορύβου για τις προβλέψεις σφαλμάτων από το μοντέλο ARIMA .....	52
Εικόνα 7: Γράφηματα σχετικά με την αυτοσυσχέτιση των σφαλμάτων πρόβλεψης στο μοντέλο ARIMA.....	53
Εικόνα 8: Πραγματικές και προβλεπόμενες τιμές για τις συνολικές παραγγελίες σε μια χρονοσειρά.....	54
Εικόνα 9: Γράφημα σφαλμάτων πρόβλεψης για τις συνολικές παραγγελίες για το μοντέλο ARIMA.....	55
Εικόνα 10: Μέσες και μέγιστες τιμές παραγγελιών ανά ώρα και ανά ημέρα.....	59
Εικόνα 11: 7ήμερος κυλιόμενος μέσος όρος παραγγελιών .....	60
Εικόνα 12: Προβλέψεις παραγγελιών από τα μοντέλα ARIMA και SARIMA σε επιλεγμένες ημέρες και ώρες ..	61
Εικόνα 13: Δοκιμή λευκού θορύβου για τις προβλέψεις σφαλμάτων από το μοντέλο GS .....	62
Εικόνα 14: Γράφημα σφαλμάτων πρόβλεψης για τις συνολικές παραγγελίες για το μοντέλο GS.....	63
Εικόνα 15: Γράφηματα σχετικά με την αυτοσυσχέτιση των σφαλμάτων πρόβλεψης στο μοντέλο GS.....	64
Εικόνα 16: Γράφημα σφαλμάτων πρόβλεψης για τις συνολικές παραγγελίες για το μοντέλο GS.....	65
Εικόνα 17: Ανάλυση τάσεων των προβλέψεων.....	68
Εικόνα 18: Ανάλυση διακύμανσης των Στατιστικών Προβλέψεων Κάτω και Άνω 95% .....	68
Εικόνα 19: Συσχέτιση μεταξύ της Επίδρασης Συμφιλίωσης και της Τελικής Πρόβλεψης .....	69

## ΛΙΣΤΑ ΠΙΝΑΚΩΝ

Πίνακας 1: Ομαδοποίηση δεδομένων με βάση την ημερομηνία .....	46
Πίνακας 2: Αποτέλεσμα δεδομένων μετά την ομαδοποίηση.....	46

## ΣΥΝΤΟΜΟΓΡΑΦΙΕΣ

ACF	Autocorrelation Function
ACF	Autocorrelation Function
ADR	Automated Demand Response
AIC	Akaike Information Criterion
AR	Autoregressive
ARIMA	Autoregressive Integrated Moving Average
ARMA	Autoregressive Moving Average
BIC	Bayesian Information Criterion
BOGOF	Buy one, get one free
CFO	Chief Financial Officer
DES	Double Exponential Smoothing
EDA	Exploratory Data Analysis
EMA	Exponentially Smoothed Moving Average
ERP	Enterprise Resource Planning
GAM	Generalized Additive Model
GMV	Gross Merchandise Value
GS	Generated Smoothing
HF	Hierarchical forecasting
ISO	International Organization for Standardization
MA	Moving Average
MAE	Mean Absolute Error
MAPE	Mean Absolute Percentage Error
MASE	Mean Absolute Scaled Error
MSE	Mean Squared Error
OFD	Online Food Delivery
PACF	Partial Autocorrelation Function
SARIMA	Seasonal Autoregressive Integrated Moving Average
SAS	Statistical Analysis Software
SCM	Supply chain management
SES	Simple Exponential Smoothing
TES	Triple Exponential Smoothing
UCM	Unobserved Components Model

## ΓΛΩΣΣΑΡΙΉ ΑΠΟΔΟΣΗ ΟΡΩΝ

Autocorrelation Function (ACF)	Αυτοσυσχέτιση
Automated Demand Response	Αυτοματοποιημένη απόκριση ζήτησης
Autoregressive (AR)	Αυτοπαλινδρομικό στοιχείο
Autoregressive Integrated Moving Average (ARIMA)	Αυτοπαλινδρομικός ολοκληρωμένος κινητός μέσος όρος
Autoregressive Moving Average (ARMA)	Αυτοπαλινδρομικός κινητός μέσος όρος
Autoregressive order	Αυτοπαλινδρομική σειρά
Bottom-up forecasting	Πρόβλεψη από κάτω προς τα πάνω
Budgeting	Προϋπολογισμός
Buy one, get one free	Αγορά ενός προϊόντος και ένα ακόμα δωρεάν
Chief Financial Officer	Οικονομικός σύμβουλος
Customer service	Εξυπηρέτηση πελατών
Data analytics	Ανάλυση δεδομένων
Date	Ημερομηνία
Degree of differencing	Βαθμός διαφοροποίησης
Demand driven forecasting	Πρόβλεψη με γνώμονα τη ζήτηση
Demand forecasting	Πρόβλεψη ζήτησης
Demand management	Διαχείριση ζήτησης
Demand Response	Ανταπόκριση ζήτησης
Demand Sensing	Ανίχνευση ζήτησης
Demand Shaping	Διαμόρφωση ζήτησης
Demand Shifting	Μετατόπιση ζήτησης
Differencing order	Σειρά βαθμού διαφοροποίησης
Double exponential smoothing (DES)	Διπλή εκθετική εξομάλυνση
Econometric modeling	Οικονομετρική μοντελοποίηση
Effect of Reconciliation	Επίδραση Συμφιλίωσης
Explicit	Σαφής
Exploratory Data Analysis (EDA)	Διερευνητική ανάλυση δεδομένων
Exponential smoothing	Εκθετική εξομάλυνση
Exponentially Smoothed Moving Average (EMA)	Εκθετικός κινητός μέσος όρος
Final Forecast	Τελική Πρόβλεψη
Forecast confidence limits	Όρια εμπιστοσύνης πρόβλεψης
Forecast Model	Πρόβλεψη Μοντέλου
Forecasting	Πρόβλεψη
Hierarchical forecasting (HF)	Ιεραρχική Πρόβλεψη



Historical data	Ιστορικά δεδομένα
Implicit	Σιωπηρή
International Organization Standardization	Διεθνής Οργανισμός Τυποποίησης for
Labor management	Διαχείριση εργασίας
Lag k	Καθυστέρηση k
Lag order	Σειρά υστέρησης
Marketing	Προώθηση αγαθών
Mean Absolute Error (MAE)	Μέσο Απόλυτο Σφάλμα
Mean Absolute Percentage Error (MAPE)	Μέσο Απόλυτο Ποσοστό Σφάλματος
Mean Absolute Scaled Error (MASE)	Μέσο Απόλυτο Σφάλμα Κλίμακας
Mean Squared Error (MSE)	Μέσο Τετραγωνικό Σφάλμα
Middle-out forecasting	Ενδιάμεση πρόβλεψη
Moving Average (MA)	Κινητός μέσος όρος
Moving average order	Σειρά κινητού μέσου όρου
Multi-step forecasts	Πολλαπλά βήματα προβλέψεων
Operational planning	Επιχειρησιακός σχεδιασμός
Operations	Λειτουργίες
Order of the moving average	Σειρά του κινητού μέσου όρου
Override	Παρακάμψη
Partial Autocorrelation Function (PACF)	Μερική Αυτοσυσχέτιση
Price elasticity & optimization	Ελαστικότητα ζήτησης ως προς την τιμή & βελτιστοποίηση
Price optimization	Βελτιστοποίηση τιμής
Promotional activities	Προωθητικές ενέργειες
Promotional modelling	Μοντέλο προώθησης
Qualitative forecasting	Ποιοτική πρόβλεψη
Quantitative forecasting	Ποσοτική πρόβλεψη
Reconciled forecast	Συμφωνημένη πρόβλεψη
Regression analysis	Ανάλυση παλινδρόμησης
Residuals	Υπόλοιπα
Sales targeting	Στρατηγική πωλήσεων
Schema-on-read	Σχήμα σε ανάγνωση
Schema-on-write	Σχήμα κατά την εγγραφή
Seasonal autoregressive order	Εποχική αυτοπαλινδρομική σειρά
Seasonal differencing order	Εποχικός βαθμός διαφοροποίησης
Seasonal moving average order	Εποχική σειρά κινητού μέσου όρου
Seasonal period	Εποχική περίοδος

Simple Exponential Smoothing (SES)		Απλή εκθετική εξομάλυνση
Statistical Software (SAS)	Analysis	Σύστημα στατιστικής ανάλυσης
Statistical forecasting	demand	Στατιστική πρόβλεψη ζήτησης
Statistical Lower 95%	Forecast	Στατιστική Πρόβλεψη Κάτω 95%
Statistical Upper 95%	Forecast	Στατιστική Πρόβλεψη Άνω 95%
Supply chain		Εφοδιαστική αλυσίδα
Supply chain management	chain	Στρατηγική διαχείρισης επιχειρησιακής αλυσίδας εφοδιασμού
Time-series analysis		Ανάλυση χρονοσειρών
Top-down forecasting		Πρόβλεψη από πάνω προς τα κάτω
Triple exponential smoothing (TES)		Τριπλή εκθετική εξομάλυνση
Value		Αξία

# 1

## Εισαγωγή

### ***1.1 Παράδοση Φαγητού μέσω Διαδικτύου (Online Food Delivery)***

Τα τελευταία χρόνια, ο κλάδος της διαδικτυακής παράδοσης φαγητού (Online Food Delivery – OFD) έχει γνωρίσει εκθετική ανάπτυξη, λόγω των εξελίξεων στην τεχνολογία, της αλλαγής του τρόπου ζωής των καταναλωτών και της αυξανόμενης διαθεσιμότητας υπηρεσιών διαδικτύου. Η άνοδος του διαδικτυακού FD έχει αλλάξει τον τρόπο με τον οποίο αλληλεπιδρούν οι καταναλωτές και οι προμηθευτές τροφίμων. Με την υιοθέτηση του OFD, οι καταναλωτές έχουν καλύτερη επιλογή όσον αφορά τα εστιατόρια και τα είδη διατροφής. Τα εστιατόρια και οι έμποροι ταχυφαγείων μπορούν να αυξήσουν την εμβέλειά τους μεταξύ των καταναλωτών με οικονομικά αποδοτικό τρόπο, ενώ οι καταναλωτές μπορούν να παραγγείλουν το γεύμα της επιλογής τους χωρίς να ξοδέψουν πολύ χρόνο και κόπο [1]. Η ταχεία επέκταση αυτού του τομέα οδήγησε στον πολλαπλασιασμό πολυάριθμων διαδικτυακών πλατφορμών παράδοσης φαγητού, που εξυπηρετούν συλλογικά εκατομμύρια πελάτες παγκοσμίως. Η εμφάνιση ελκυστικών, φιλικών προς το χρήστη εφαρμογών και τεχνολογικά καταρτισμένων δικτύων οδηγών, σε συνδυασμό με τις μεταβαλλόμενες προσδοκίες των καταναλωτών, έχουν ανάγκη την παράδοση έτοιμου φαγητού σε βασική και επιτυχημένη κατηγορία του ηλεκτρονικού εμπορίου [2] [3].

Λιγότερο από δύο δεκαετίες πριν, η παράδοση γευμάτων από εστιατόρια εξακολουθούσε να περιορίζεται σε μεγάλο βαθμό σε φαγητά όπως η πίτσα και το κινέζικο. Σήμερα, η ευκολία της ευρείας ποικιλίας κουζινών που παραδίδονται απευθείας στον προσωπικό χώρο του χρήστη έχει μεταμορφώσει την παραδοσιακή γευστική εμπειρία, καθιστώντας την αναπόσπαστο μέρος της σύγχρονης αστικής ζωής. Τα lockdowns και οι απαιτήσεις σωματικής απόστασης, εξαιτίας της πανδημίας, έδωσαν στην κατηγορία μια τεράστια ώθηση, με την παράδοση να γίνεται η σωτήρια λύση για τον πληγμένο κλάδο των εστιατορίων [2] [3]. Πλέον, η παράδοση τροφίμων αποτελεί μια παγκόσμια αγορά, αξίας άνω των 150 δισεκατομμυρίων δολαρίων, σημειώνοντας υπερτριπλασιασμό από το 2017. Στις Ηνωμένες Πολιτείες, η αγορά έχει υπερδιπλασιαστεί κατά τη διάρκεια της πανδημίας COVID-19, μετά από υγιή ιστορική ανάπτυξη της τάξεως του 8% [2]. Στην Ελλάδα, αυτή η επερχόμενη τάση των περασμένων ετών, έχει γίνει πλέον η πραγματικότητα στον κλάδο της εστίασης, την οποία βιώνουν τόσο οι πελάτες όσο και οι ιδιοκτήτες των καταστημάτων [4].

## 1.2 Πρόβλεψη Ζήτησης στον Κλάδο της Παράδοσης Φαγητού μέσω Διαδικτύου

Καθώς ο ανταγωνισμός στην αγορά της online παράδοσης τροφίμων εντείνεται, οι εταιρείες αναγκάζονται να βελτιστοποιήσουν τις δραστηριότητές τους για να παραμείνουν κερδοφόρες και να ενισχύσουν την ικανοποίηση των πελατών. Μια από τις κρίσιμες πτυχές αυτού του εξορθολογισμού είναι η ακριβής πρόβλεψη ζήτησης (demand forecasting), η οποία περιλαμβάνει την πρόβλεψη του αριθμού των παραγγελιών που θα υποβληθούν στο μέλλον. Πιο συγκεκριμένα, η εφαρμογή πρόβλεψης ζήτησης στην ηλεκτρονική παράδοση τροφίμων περιλαμβάνει τη μόχλευση δεδομένων από διάφορες πηγές, όπως ιστορικά δεδομένα παραγγελιών, δημογραφικά στοιχεία πελατών, ώρα της ημέρας, ημέρα της εβδομάδας, ειδικές εκδηλώσεις, ακόμη και εξωτερικούς παράγοντες όπως ο καιρός και τα τοπικά γεγονότα. Χρησιμοποιώντας εξελιγμένους αλγόριθμους και μοντέλα μηχανικής μάθησης, οι διαδικτυακές υπηρεσίες παράδοσης φαγητού μπορούν να προβλέψουν τη μελλοντική ζήτηση με υψηλή ακρίβεια, γεγονός που τους επιτρέπει να λαμβάνουν αποφάσεις βάσει δεδομένων που ενισχύουν την αποτελεσματικότητα και την ικανοποίηση των πελατών [5].

Δεδομένου ότι η πρόβλεψη ζήτησης είναι ζωτικής σημασίας στις διαδικτυακές υπηρεσίες παράδοσης τροφίμων για τη βελτιστοποίηση των λειτουργιών, τη βελτίωση της ικανοποίησης των πελατών και τη μεγιστοποίηση των κερδών, συναντάται σε διάφορα στάδια υλοποίησης του OFD, όπως τα παρακάτω:

- Η ακριβής πρόβλεψη ζήτησης βοηθά τα εστιατόρια να διαχειρίζονται το απόθεμά τους προβλέποντας την ποσότητα των απαιτούμενων συστατικών. Με αυτόν τον τρόπο μειώνεται η σπατάλη τροφίμων και διασφαλίζεται ότι τα δημοφιλή είδη είναι πάντα διαθέσιμα.
- Οι πλατφόρμες OFD μπορούν να συμβουλεύουν τα συνεργαζόμενα εστιατόρια σχετικά με την αναμενόμενη ζήτηση, διασφαλίζοντας μια ομαλότερη αλυσίδα εφοδιασμού.
- Η πρόβλεψη ζήτησης επιτρέπει στα εστιατόρια να διαχειριστούν με το βέλτιστο δυνατό τρόπο το εργατικό δυναμικό στους τομείς κουζίνας και παράδοσης. Έτσι εξασφαλίζεται η αποτελεσματική διαχείριση των περιόδων αιχμής με επαρκές προσωπικό, ενώ αντίστοιχα αποφεύγεται η δέσμευση υπερβάλλοντος προσωπικού σε πιο αργές περιόδους.
- Οι πλατφόρμες παράδοσης μπορούν να προβλέψουν περιόδους αιχμής και να καταναείμουν τους οδηγούς ανάλογα, μειώνοντας τους χρόνους παράδοσης και βελτιώνοντας την ποιότητα των υπηρεσιών. Επιπλέον, οι ακριβείς προβλέψεις ζήτησης επιτρέπουν καλύτερο σχεδιασμό διαδρομής για τους οδηγούς παράδοσης, ελαχιστοποιώντας το χρόνο μεταφοράς και το κόστος καυσίμων.
- Η πρόβλεψη επιτρέπει στις πλατφόρμες να ομαδοποιούν αποτελεσματικά τις παραγγελίες, μεγιστοποιώντας τον αριθμό των παραδόσεων ανά διαδρομή.
- Η αποτελεσματική πρόβλεψη ζήτησης εντοπίζει αργές περιόδους κατά τις οποίες ενδέχεται να απαιτούνται στοχευμένες προωθήσεις ή εκπτώσεις για την ενίσχυση της ζήτησης. Χρησιμοποιώντας προβλέψεις ζήτησης, οι πλατφόρμες μπορούν να υλοποιήσουν στρατηγικές προώθησης για να προσαρμόσουν δυναμικά τις τιμές, ενθαρρύνοντας τις παραγγελίες σε περιόδους εκτός αιχμής και μεγιστοποιώντας τα έσοδα σε περιόδους αιχμής.
- Με ακριβείς προβλέψεις ζήτησης, τα εστιατόρια και οι υπηρεσίες παράδοσης μπορούν να προετοιμαστούν καλύτερα, οδηγώντας σε μικρότερους χρόνους αναμονής και πιο φρέσκες παραδόσεις τροφίμων.
- Τα εστιατόρια μπορούν να χρησιμοποιήσουν προβλέψεις ζήτησης για να λάβουν αποφάσεις σχετικά με την επέκταση της χωρητικότητας της κουζίνας ή το άνοιγμα νέων τοποθεσιών. Τα ακριβή δεδομένα ζήτησης βοηθούν στη λήψη αξιόπιστων οικονομικών προβλέψεων και επενδυτικών αποφάσεων [5] [6] [7].

Συνεπώς, μια αποτελεσματική πρόβλεψη ζήτησης επιτρέπει στις εταιρείες να προβλέπουν παραγγελίες πελατών, να διαχειρίζονται αποτελεσματικά τα αποθέματά τους, να μειώνουν τους χρόνους παράδοσης και γενικότερα να βελτιώνουν τις διαδρομές παράδοσης, καθώς και να κατανέμουν τους πόρους πιο αποτελεσματικά. Προβλέποντας τη ζήτηση με μεγαλύτερη ακρίβεια, οι εταιρείες μπορούν να μειώσουν τη σπατάλη πόρων, να ελαχιστοποιήσουν το κόστος και να βελτιώσουν τη συνολική εμπειρία χρήστη [5] [8].

### **1.3 Περιγραφή προβλήματος**

Παρά τις σημαντικές προόδους στην τεχνολογία και την ανάλυση δεδομένων, η πρόβλεψη ζήτησης στον κλάδο της online παράδοσης φαγητού παραμένει ένα πολύπλοκο και απαιτητικό έργο. Αυτή η πολυπλοκότητα προκύπτει από διάφορους παράγοντες. Αρχικά, η ζήτηση για υπηρεσίες παράδοσης φαγητού παρουσιάζει ισχυρά χρονικά μοτίβα, όπως ημερήσιες, εβδομαδιαίες και εποχιακές διακυμάνσεις. Αυτά τα μοτίβα μπορούν να επηρεαστούν από παράγοντες όπως ο καιρός, οι περίοδοι διακοπών, οι τοπικές εκδηλώσεις και οι ειδικές προσφορές. Επιπλέον, οι προτιμήσεις των πελατών και η συμπεριφορά τους, όπως αυτή εκφράζεται μέσω των παραγγελιών που πραγματοποιούν, μπορεί να αλλάξουν γρήγορα και απρόβλεπτα, λόγω διαφόρων κοινωνικοοικονομικών παραγόντων. Η διαθεσιμότητα εστιατορίων και η ποικιλία των μενού που προσφέρονται παίζουν επίσης καθοριστικό ρόλο στη διαμόρφωση των προτύπων ζήτησης. Τέλος, εξωτερικοί παράγοντες όπως οι συνθήκες κυκλοφορίας, η διαθεσιμότητα του προσωπικού παράδοσης, ακόμη και οι μακροοικονομικές συνθήκες μπορούν να επηρεάσουν τη ζήτηση για υπηρεσίες παράδοσης τροφίμων [9] [10].

Το πρωταρχικό πρόβλημα που αντιμετωπίζεται σε αυτή τη διατριβή είναι η ανάπτυξη ενός ισχυρού και ακριβούς μοντέλου πρόβλεψης ζήτησης, το οποίο να μπορεί να χειριστεί την πολύπλευρη φύση της ζήτησης στον κλάδο της διαδικτυακής παράδοσης τροφίμων. Το μοντέλο θα πρέπει να μπορεί να προβλέψει τον αριθμό των παραγγελιών για μια δεδομένη χρονική περίοδο με υψηλή ακρίβεια, λαμβάνοντας υπόψιν τους διάφορους παράγοντες που επηρεάζουν τα παραπάνω.

### **1.4 Στόχος εργασίας**

Η παρούσα διπλωματική εργασία εστιάζει στην ανάπτυξη ενός ακριβούς και αξιόπιστου μοντέλου πρόβλεψης ζήτησης, χρησιμοποιώντας δεδομένα από μια διαδικτυακή πλατφόρμα παράδοσης τροφίμων, ώστε να προβλεφθεί η μελλοντική ζήτηση με υψηλή ακρίβεια.

Κατά το αρχικό στάδιο συγγραφής, μέσω περιεκτικής ανάλυσης, η διατριβή επιδιώκει να καταδείξει την αξία της πρόβλεψης ζήτησης βάσει δεδομένων για την ενίσχυση των λειτουργικών δυνατοτήτων των διαδικτυακών πλατφορμών παράδοσης τροφίμων και τη συμβολή στη μακροπρόθεσμη επιτυχία τους. Στη συνέχεια, ο βασικός στόχος είναι να αξιοποιηθούν τα ιστορικά δεδομένα παραγγελιών, σε συνδυασμό με διάφορους παράγοντες, όπως τα δημογραφικά στοιχεία πελατών, η ώρα της ημέρας και η ημέρα της εβδομάδας, για την πρόβλεψη της μελλοντικής ζήτησης.

Η σημασία αυτής της μελέτης έγκειται στη δυνατότητά της να συμβάλει στον αυξανόμενο όγκο γνώσεων στον τομέα της πρόβλεψης της ζήτησης, στο πλαίσιο των διαδικτυακών υπηρεσιών παράδοσης τροφίμων. Παρέχοντας πληροφορίες για τους παράγοντες που επηρεάζουν τη ζήτηση των πελατών και αναπτύσσοντας ισχυρά μοντέλα πρόβλεψης, αυτή η έρευνα επιχειρεί να συμβάλει στη βελτίωση της λειτουργικής αποτελεσματικότητας και του στρατηγικού σχεδιασμού των εταιρειών διανομής φαγητού στο διαδίκτυο.

## 1.5 Διάρθρωση εργασίας

Η δομή της παρούσας διπλωματικής εργασίας αναπτύσσεται ως εξής:

Το Κεφάλαιο 1 αποτελεί το εισαγωγικό μέρος της εργασίας. Αρχικά, πραγματοποιείται μια σύντομη αναδρομή στην εξέλιξη του Online Food Delivery στην Ελλάδα, αλλά και σε παγκόσμιο επίπεδο. Στη συνέχεια παρουσιάζεται η σημασία της πρόβλεψης ζήτησης στον κλάδο και οι τρόποι με τους οποίους συμβάλλει στη βελτιστοποίηση των λειτουργιών αντίστοιχων εταιρειών. Τέλος, διατυπώνεται μια σύντομη περιγραφή του προβλήματος και του στόχου της εργασίας, καθώς και της δομής που επιλέχθηκε.

Στο Κεφάλαιο 2 γίνεται ανασκόπηση της σχετικής βιβλιογραφίας για τις μεθοδολογίες πρόβλεψης ζήτησης και τις εφαρμογές τους σε διάφορους κλάδους, με ιδιαίτερη έμφαση στον κλάδο της διαδικτυακής παράδοσης τροφίμων. Περιγράφονται τα επιχειρησιακά οφέλη της πρόβλεψης ζήτησης και γίνεται αναφορά στα σημαντικότερα εργαλεία για τη διαμόρφωση της ζήτησης.

Στο Κεφάλαιο 3 πραγματοποιείται μια σύντομη περιγραφή των μεθόδων και των τεχνικών demand forecasting. Αναφέρονται οι δημοφιλέστερες ποσοτικές και ποιοτικές μέθοδοι πρόβλεψης, καθώς και οι συγκεκριμένες μέθοδοι που χρησιμοποιήθηκαν για τη διενέργεια προβλέψεων στην παρούσα εργασία.

Το Κεφάλαιο 4 περιλαμβάνει την υλοποίηση του μοντέλου πρόβλεψης ζήτησης. Περιγράφονται οι πηγές δεδομένων, οι τεχνικές προεπεξεργασίας και το μεθοδολογικό πλαίσιο που χρησιμοποιήθηκε σε αυτή τη μελέτη. Στη συνέχεια, αξιολογούνται τα μοντέλα ARIMA και GS, ως προς την προσαρμογή των δεδομένων. Στο τελικό στάδιο, αναλύονται και παρουσιάζονται οπτικοποιημένα τα αποτελέσματα του μοντέλου πρόβλεψης ζήτησης.

# 2

## Πρόβλεψη Ζήτησης (Demand Forecasting)

### 2.1 Η Έννοια της Πρόβλεψης Ζήτησης

Η πρόβλεψη ζήτησης είναι μια κρίσιμη λειτουργία που επηρεάζει τις εταιρείες παγκοσμίως σε όλους τους κλάδους, συμπεριλαμβανομένης της βαριάς μεταποίησης, των συσκευασμένων καταναλωτικών αγαθών, του λιανικού εμπορίου, της φαρμακευτικής, της αυτοκινητοβιομηχανίας, των ηλεκτρονικών, των τηλεπικοινωνιών, των χρηματοοικονομικών κ.α.. Η πρόβλεψη ζήτησης είναι κρίσιμη, όχι μόνο για την εξάλειψη των αναποτελεσματιών στην αλυσίδα εφοδιασμού, αλλά επηρεάζει επίσης όλες τις πτυχές της εταιρείας σε επίπεδο επιχείρησης. Καθορίζει τις ποσότητες πρώτων υλών, τον αριθμό των αποθεμάτων τελικών προϊόντων, τον αριθμό των προϊόντων που πρέπει να αποσταλούν, τον αριθμό των ατόμων που θα προσληφθούν, τον αριθμό των εργοστασίων που θα κατασκευαστούν, μέχρι και τον αριθμό των ειδών γραφείου που πρέπει να αγοραστούν. Οι προβλέψεις ζήτησης είναι απαραίτητες επειδή η βασική διαδικασία λειτουργίας, η μετάβαση από τις πρώτες ύλες των προμηθευτών στα τελικά προϊόντα στα χέρια των καταναλωτών, απαιτεί χρόνο, ιδιαίτερα στην τρέχουσα παγκόσμια οικονομία. Οι εταιρείες δεν μπορούν πλέον απλώς να περιμένουν να εμφανιστεί η ζήτηση και στη συνέχεια να αντιδράσουν σε αυτήν με το σωστό προϊόν, στο σωστό μέρος, τη σωστή στιγμή. Αντίθετα, πρέπει να αισθάνονται τα σήματα ζήτησης και να διαμορφώνουν τη μελλοντική ζήτηση εν αναμονή της συμπεριφοράς των πελατών, ώστε να μπορούν να αντιδρούν άμεσα στις παραγγελίες.

Τα χαρακτηριστικά των δεδομένων ζήτησης στις σημερινές, συνεχώς διευρυνόμενες, παγκόσμιες αλυσίδες εφοδιασμού καθιστούν την υιοθέτηση των προσεγγίσεων ανάλυσης μεγάλων δεδομένων απαραίτητη για την πρόβλεψη της ζήτησης. Η ψηφιοποίηση των αλυσίδων εφοδιασμού και η ενσωμάτωση τεχνολογιών Blockchain για την καλύτερη παρακολούθησή τους, υπογραμμίζει περαιτέρω το ρόλο της ανάλυσης μεγάλων δεδομένων [11].

Τα δεδομένα της αλυσίδας εφοδιασμού είναι υψηλών διαστάσεων και παράγονται σε πολλά σημεία της αλυσίδας για ποικίλους σκοπούς (προϊόντα, ικανότητες χωρητικότητας προμηθευτών, παραγγελίες, αποστολές, πελάτες, έμποροι λιανικής κ.λπ.), σε μεγάλους όγκους, λόγω της πληθώρας προμηθευτών, προϊόντων και πελατών και σε υψηλή ταχύτητα. Το χαρακτηριστικό της υψηλής ταχύτητας αντικατοπτρίζεται από το πλήθος των συναλλαγών που υποβάλλονται σε συνεχή επεξεργασία στα δίκτυα της εφοδιαστικής αλυσίδας. Υπό την έννοια τέτοιων πολυπλοκοτήτων, υπήρξε μια απόκλιση από τις συμβατικές προσεγγίσεις πρόβλεψης της ζήτησης που βασίζονται στο στατικό προσδιορισμό σημαντικών τάσεων, προς έξυπνες προβλέψεις που μπορούν να μάθουν από τα ιστορικά

δεδομένα, να προσαρμοστούν και να εξελιχθούν έξυπνα για να προβλέψουν τη συνεχώς μεταβαλλόμενη ζήτηση στις αλυσίδες εφοδιασμού. Αυτή η ικανότητα καθιερώνεται χρησιμοποιώντας τεχνικές Big Data Analytics που εξάγουν κανόνες πρόβλεψης μέσω της ανακάλυψης των υποκείμενων σχέσεων μεταξύ των δεδομένων ζήτησης στα δίκτυα της εφοδιαστικής αλυσίδας. Οι εν λόγω τεχνικές χαρακτηρίζονται από υπολογιστική ένταση και απαιτούν πολύπλοκους αλγόριθμους, προγραμματισμένους από μηχανή [12].

## 2.2 Πρόβλεψη βάσει Ζήτησης (*Demand Driven Forecasting*)

Η πρόβλεψη με γνώμονα τη ζήτηση (*demand driven forecasting*) μπορεί να διαμορφώσει, να αντιληφθεί και να ανταποκριθεί σε πραγματικές απαιτήσεις των πελατών. Η διαθεσιμότητα έγκαιρης ενημέρωσης σχετικά με τις μελλοντικές ανάγκες των πελατών είναι βασικός παράγοντας επιτυχίας για κάθε επιχείρηση, καθώς επιτρέπει στις εταιρείες να σχεδιάζουν ανάλογα τα επίπεδα παραγωγής τους, ώστε να μην παράγουν πάρα πολλά ή πολύ λίγα προϊόντα. Το *demand driven forecasting* εξοπλίζει μια επιχείρηση με λύσεις που μπορούν να αντιληφθούν, να διαμορφώσουν και να προβλέψουν τη μελλοντική ζήτηση, χρησιμοποιώντας εξαιρετικά εξελιγμένες μεθόδους και εργαλεία.

### 2.2.1 Στάδια Πρόβλεψης βάσει Ζήτησης

Η πρόβλεψη βάσει ζήτησης αποτελεί ένα εξαιρετικά δύσκολο έργο για τις εταιρείες. Σημαντικά στοιχεία, τα οποία πρέπει να υφίστανται κατά τη διαδικασία, είναι η ευελιξία στον χειρισμό σποραδικών εισροών και ταυτόχρονα η ύπαρξη μιας μακροπρόθεσμης προσέγγισης.

Στη συνέχεια περιγράφονται τα στάδια του *demand driven forecasting*:

- **Ανίχνευση ζήτησης (*Demand Sensing*)**

Τα σήματα ανίχνευσης ζήτησης σχετίζονται με το χώρο της αγοράς ανά πράξη αγοράς, κανάλι, κατηγορία και προϊόν [13]. Η ανίχνευση ζήτησης είναι η χρήση μιας διαδικασίας που περιλαμβάνει την ανάλυση του ιστορικού ζήτησης για την απόκτηση νέας γνώσης σχετικά με το πώς να αναπτυχθεί μια καλύτερη πρόβλεψη και να γίνουν αλλαγές βραχυπρόθεσμα σε αυτήν.

Πιο συγκεκριμένα, η ανίχνευση ζήτησης περιλαμβάνει ένα συνδυασμό μεθοδολογίας και τεχνολογίας που στοχεύει στη βελτίωση των εγγύς μελλοντικών προβλέψεων, χρησιμοποιώντας λεπτομερή και βραχυπρόθεσμα δεδομένα ζήτησης. Το εγγύς μέλλον μπορεί να σημαίνει ώρες ή ημέρες, ανάλογα με το πόσο δυναμική είναι η αλυσίδα εφοδιασμού της επιχείρησης. Το *demand sensing* προέκυψε από την ευρύτερη τάση προς τις συνεργατικές αλυσίδες εφοδιασμού, όπου πλέον κυριαρχεί μια πελατοκεντρική άποψη της αγοράς. Οι πελάτες χρειάζονται οι αλυσίδες εφοδιασμού τους να τους παρέχουν ταυτόχρονα υψηλά επίπεδα υπηρεσιών και εξορθολογισμένα επίπεδα αποθεμάτων.

Οι προμηθευτές λογισμικού της εφοδιαστικής αλυσίδας ελέγχουν επί του παρόντος και κατά κύριο λόγο τις πληροφορίες σχετικά με τον ορισμό της ανίχνευσης ζήτησης. Ο στόχος των λύσεων *demand sensing* είναι να βοηθήσουν τους σχεδιαστές να λάβουν βραχυπρόθεσμες αποφάσεις με βάση το τι συνέβη μόλις πριν από κάποιες ώρες ή μέρες και όχι αυτό που συνέβη πριν από ένα χρόνο. Εν ολίγοις, η ανίχνευση ζήτησης υπερνικά τα ζητήματα λανθάνοντος χρόνου που σχετίζονται με τις παραδοσιακές μεθόδους πρόβλεψης χρονοσειρών, οι οποίες υποθέτουν, ορθά στις περισσότερες περιπτώσεις, ότι η ιστορία θα επαναληφθεί για μεγάλες χρονικές περιόδους. Οι σχεδιαστές έχουν αντιληφθεί ότι είναι δύσκολο και χρονοβόρο να



επιβάλλουν δεδομένα σε πραγματικό χρόνο σε υπάρχοντα στατιστικά μοντέλα χρονοσειρών. Συνεπώς, η ανίχνευση ζήτησης συχνά ενσωματώνει διαφορετικές μαθηματικές τεχνικές για να δημιουργήσει μια πιο ακριβή πρόβλεψη που ανταποκρίνεται σε γεγονότα του πραγματικού κόσμου [14].

- **Διαμόρφωση ζήτησης (Demand Shaping)**

Η διαμόρφωση ζήτησης είναι η διαδικασία δημιουργίας κινήτρων, μέσω των πελατών, που εξομαλύνουν τη ζήτηση ή εξαλείφουν προϋπάρχοντα κίνητρα, όπως προσφορές στο τέλος του τριμήνου. Τέτοια προϋπάρχοντα κίνητρα διαστρεβλώνουν το ιστορικό ζήτησης, κάνοντας τις προβλέψεις πιο δύσκολες στην απόδοση. Χρησιμοποιώντας την ανάλυση «what if», οι σχεδιαστές ζήτησης διαμορφώνουν τη μελλοντική ζήτηση, με βάση τακτικές και στρατηγικές πωλήσεων, καθώς και σχέδια marketing [13].

Αναλυτικότερα, η διαμόρφωση ζήτησης είναι μια στρατηγική διαχείρισης της επιχειρησιακής αλυσίδας εφοδιασμού (Supply chain management - SCM), όπου μια εταιρεία χρησιμοποιεί τακτικές όπως κίνητρα τιμών, τροποποιήσεις κόστους και αντικαταστάσεις προϊόντων για να δελεάσει τους πελάτες να αγοράσουν συγκεκριμένα είδη. Η διαμόρφωση της ζήτησης έχει σχεδιαστεί για να βοηθήσει την εταιρεία να επηρεάσει τη ζήτηση ενός συγκεκριμένου προϊόντος, προκειμένου να ανταποκριθεί στην προγραμματισμένη προσφορά της. Για παράδειγμα, μια εταιρεία με πλεόνασμα συγκεκριμένου προϊόντος θα αυξήσει τις προσπάθειες marketing για αυτό το προϊόν ώστε να το κάνει πιο δελεαστικό για τους πελάτες. Οι εταιρείες μπορούν επίσης να χρησιμοποιήσουν τεχνικές demand shaping για να βοηθήσουν στην κάλυψη των προβλέψεων ανάπτυξης προϊόντων.

Μερικές από τις βασικές τακτικές που είναι κοινές στη στρατηγική διαμόρφωσης ζήτησης περιλαμβάνουν τα ακόλουθα:

- λανσαρίσματα νέων προϊόντων για την ενίσχυση της ζήτησης,
- βελτιστοποίηση τιμών και
- προωθήσεις και προσφορές πωλήσεων.

Η δυναμική τιμολόγηση είναι μια άλλη κοινή τακτική διαμόρφωσης της ζήτησης. Ονομάζεται επίσης τιμολόγηση σε πραγματικό χρόνο. Η δυναμική τιμολόγηση ορίζει ευέλικτο κόστος για ένα προϊόν ή μια υπηρεσία ώστε να επιτρέπει σε μια εταιρεία να προσαρμόζει τις τιμές, ανταποκρινόμενη ταχύτητα στις απαιτήσεις της αγοράς. Τα στατιστικά στοιχεία που συγκεντρώνονται μέσω του σχεδιασμού της ζήτησης, όπως οι στατιστικές προβλέψεις, είναι επίσης ευεργετικά για μια στρατηγική διαμόρφωσης ζήτησης.

Η διαμόρφωση της ζήτησης είναι διαφορετική από τη διαχείριση της ζήτησης (demand management), η οποία ελέγχει και παρακολουθεί τις αγορές μιας εταιρείας. Η διαχείριση της ζήτησης επικεντρώνεται στις σχέσεις με τους προμηθευτές και όχι στις σχέσεις με τους πελάτες, ενώ επιπλέον χρησιμοποιείται για τον καθορισμό των εξωτερικών δαπανών και όχι της τιμολόγησης μεμονωμένων προϊόντων [14].

- **Μετατόπιση ζήτησης (Demand Shifting)**

Η μετατόπιση ζήτησης αφορά την αλλαγή στις προτιμήσεις των πελατών και εκφράζεται με την καμπύλη ζήτησης, η οποία προσδιορίζει ποια ποσότητα από ένα αγαθό ή μια υπηρεσία είναι διατεθειμένοι να αγοράσουν οι πελάτες σε μια δεδομένη τιμή. Δεδομένου ότι η ζήτηση για αγαθά και υπηρεσίες δεν είναι σταθερή με την πάροδο του χρόνου, η καμπύλη ζήτησης μετατοπίζεται συνεχώς αριστερά ή δεξιά. Ανάλογα με την κατεύθυνση της μετατόπισης, ισοδυναμεί με μείωση ή αύξηση της ζήτησης.

Οι σχεδιαστές του demand shifting οφείλουν να συνεργαστούν με τα τμήματα πωλήσεων, marketing και σχεδιασμού λειτουργιών, προκειμένου να ταιριάξουν την προσφορά

σε απεριόριστη ζήτηση [19]. Υπάρχουν πέντε σημαντικοί παράγοντες που προκαλούν μια μετατόπιση στην καμπύλη ζήτησης οι οποίοι αναφέρονται παρακάτω:

- **Εισόδημα**

Μια αλλαγή στο εισόδημα μπορεί να επηρεάσει την καμπύλη ζήτησης με διάφορους τρόπους, ανάλογα με τον τύπο των αγαθών που εξετάζεται. Αν πρόκειται, δηλαδή, για κανονικά αγαθά ή κατώτερα αγαθά. Στην περίπτωση ενός κανονικού αγαθού, η ζήτηση αυξάνεται καθώς αυξάνεται το εισόδημα. Δηλαδή, μια αύξηση του εισοδήματος μετατοπίζει την καμπύλη ζήτησης προς τα δεξιά. Ο λόγος για αυτό είναι ότι με υψηλότερο μισθό, οι άνθρωποι μπορούν να αντέξουν οικονομικά να αγοράσουν μεγαλύτερη ποσότητα από οποιοδήποτε δεδομένο αγαθό. Αντίθετα, στην περίπτωση ενός κατώτερου αγαθού, η ζήτηση μειώνεται καθώς αυξάνεται το εισόδημα. Αυτό σημαίνει ότι η αύξηση του εισοδήματος μετατοπίζει την καμπύλη ζήτησης προς τα αριστερά και ισχύει για τα αγαθά που συνήθως αντικαθίστανται καθώς αυξάνεται το εισόδημα.

- **Τάσεις και προτιμήσεις**

Όταν ένα αγαθό ή μια υπηρεσία έρχεται στη μόδα, η καμπύλη ζήτησης μετατοπίζεται προς τα δεξιά. Αντίθετα, η καμπύλη ζήτησης μετατοπίζεται προς τα αριστερά μόλις εμφανιστεί μια νέα τάση και το αγαθό ή η υπηρεσία βγει ξανά από τη μόδα.

- **Τιμές συναφών αγαθών**

Υπάρχουν δύο τύποι συναφών αγαθών που μετατοπίζουν την καμπύλη ζήτησης προς αντίθετες κατευθύνσεις: τα υποκατάστατα και τα συμπληρωματικά. Στην περίπτωση των υποκατάστατων, η πτώση της τιμής ενός αγαθού έχει ως αποτέλεσμα τη μείωση της ζήτησης για ένα άλλο αγαθό. Επομένως, τα υποκατάστατα είναι αγαθά που μπορούν να χρησιμοποιηθούν για να αντικαταστήσουν το ένα το άλλο. Αντίθετα, στην περίπτωση των συμπληρωματικών, η πτώση της τιμής ενός αγαθού οδηγεί σε αύξηση της ζήτησης για ένα άλλο αγαθό. Αυτό συμβαίνει συνήθως όταν τα δύο προϊόντα χρησιμοποιούνται μαζί.

- **Προσδοκίες**

Οι προσδοκίες των ανθρώπων για το μέλλον μπορεί να έχουν σημαντικό αντίκτυπο στη ζήτηση ή, πιο συγκεκριμένα, οι προσδοκίες τους για μελλοντικές τιμές ή άλλους παράγοντες που μπορούν να αλλάξουν τη ζήτηση. Εάν οι καταναλωτές αναμένουν ότι οι τιμές θα αυξηθούν σύντομα, η τρέχουσα ζήτηση συχνά αυξάνεται, δηλαδή η καμπύλη ζήτησης μετατοπίζεται προς τα δεξιά.

- **Μέγεθος και σύνθεση πληθυσμού**

Κατά κανόνα, ένας μεγαλύτερος πληθυσμός οδηγεί σε μεγαλύτερη ζήτηση για τα περισσότερα αγαθά. Ως αποτέλεσμα, η καμπύλη ζήτησης μετατοπίζεται προς τα δεξιά. Για παράδειγμα, όσο αυξάνεται ο πληθυσμός, αυξάνεται και η ζήτηση για τρόφιμα, απλώς και μόνο επειδή υπάρχουν περισσότερα άτομα που χρειάζονται τροφή. Επιπλέον, η σύνθεση του πληθυσμού επηρεάζει επίσης την καμπύλη ζήτησης. Ωστόσο, αυτή η σχέση είναι αρκετά περίπλοκη, γεγονός που καθιστά δύσκολη την παροχή γενικών δηλώσεων σχετικά με την κατεύθυνση και το μέγεθος των μετατοπίσεων που προκύπτουν [15].

- **Ανταπόκριση ζήτησης (Demand Response)**

Η ανταπόκριση ζήτησης ορίζεται ευρέως ως ένα μέτρο για τη μείωση του ενεργειακού φορτίου, σε απάντηση στους περιορισμούς της προσφοράς, σε περιόδους αιχμής ζήτησης. Οι πολιτικές ανταπόκρισης στη ζήτηση έχουν χρησιμοποιηθεί από το Διεθνή Οργανισμό Τυποποίησης ISO (International Organization for Standardization) από τις αρχές της δεκαετίας του 1980. Στα πρώτα χρόνια, στόχος της demand response ήταν η επίτευξη ενός πιο ορθολογικού σχεδιασμού και λειτουργίας των πόρων. Τα τελευταία χρόνια, με την ανάπτυξη των αγορών ενέργειας και το αυξανόμενο μερίδιο των ΑΠΕ στο μείγμα παραγωγής, η demand response γίνεται πιο επικεντρωμένη στον πελάτη και στην ενσωμάτωση του διαθέσιμου δυναμικού ΑΠΕ.

Η ανταπόκριση ζήτησης μπορεί να χωριστεί σε σαφή (explicit) και σιωπηρή (implicit). Η σιωπηρή αφορά τη μεταβολή της ζήτησης λόγω τιμών, ενώ η σαφής περιλαμβάνει την αλλαγή της ζήτησης όταν οι διαχειριστές συστήματος ή διανομής προβλέπουν και δηλώνουν ένα γεγονός στο σύστημα βραχυπρόθεσμα. Για να ανταποκριθούν οι εταιρείες σε αυτά τα γεγονότα ή τις τιμές, η πιο κοινή πολιτική είναι ο περιορισμός της ζήτησης. Αυτή η μείωση μπορεί να πραγματοποιηθεί μέσω του κύκλου της τροφοδοσίας [16].

Μια σημαντική ανησυχία για την πρακτική εφαρμογή των σύγχρονων πολιτικών ανταπόκρισης ζήτησης είναι η αυτοματοποιημένη απόκριση ζήτησης (Automated Demand Response - ADR). Αυτό συμβαίνει επειδή ο χειροκίνητος έλεγχος από τον πελάτη δεν ανταποκρίνεται στις απαιτήσεις τόσο της ακρίβειας όσο και της αξιοπιστίας της απόκρισης. Για την επιτυχία της ADR, απαιτείται η ανάπτυξη προτύπων για τις επικοινωνίες μεταξύ φορέων εκμετάλλευσης, συγκεντρωτών και εξοπλισμού αυτοματισμού των πελατών τους και η ανατροφοδότηση από αυτούς. Το ανοιχτό πρωτόκολλο αυτοματοποιημένης απόκρισης ζήτησης OpenADR αντιπροσωπεύει ένα καλό παράδειγμα τέτοιου προτύπου.

## 2.3 Επιχειρησιακά οφέλη της πρόβλεψης ζήτησης

Η πρόβλεψη ζήτησης παρέχει ουσιαστικές πληροφορίες σχετικά με τη μελλοντική ζήτηση των πελατών. Βοηθά τις εταιρείες να λαμβάνουν πιο έξυπνες αποφάσεις, σχετικά με τον προγραμματισμό παραγωγής, τη διαχείριση αποθεμάτων και τις λειτουργίες της αλυσίδας εφοδιασμού. Βοηθά επίσης στη μείωση των κινδύνων και στη λήψη αποτελεσματικών οικονομικών αποφάσεων, που επηρεάζουν τα περιθώρια κέρδους, τις ταμειακές ροές, την κατανομή πόρων, τις ευκαιρίες για επέκταση, τη λογιστική απογραφής, το λειτουργικό κόστος, το προσωπικό, τις συνολικές δαπάνες κ.α..

Χωρίς ζήτηση, δεν υπάρχει επιχείρηση. Και χωρίς ενδελεχή κατανόηση της ζήτησης, οι επιχειρήσεις δεν είναι σε θέση να λάβουν τις σωστές αποφάσεις σχετικά με τις δαπάνες τους. Η πρόβλεψη ζήτησης δεν θα είναι ποτέ 100% ακριβής, αλλά υπάρχουν βήματα που αν εφαρμοσθούν μπορούν να οδηγήσουν σε βελτίωση των χρόνων παράδοσης, σε αύξηση της λειτουργικής απόδοσης, στην εξοικονόμηση χρημάτων, στο λανσάρισμα νέων προϊόντων και κατ' επέκταση στην παροχή καλύτερης εμπειρίας στον πελάτη. Παρακάτω, παρουσιάζονται τα επιχειρησιακά οφέλη της πρόβλεψης ζήτησης στις διάφορες λειτουργίες μιας επιχείρησης.

- **Πρόβλεψη ζήτησης στην εφοδιαστική αλυσίδα (supply chain)**

Η βελτίωση της αποτελεσματικότητας της εφοδιαστικής αλυσίδας είναι ένας βασικός λόγος για χρήση της πρόβλεψης ζήτησης στη διαχείριση λειτουργιών μιας επιχείρησης. Η πρόβλεψη ζήτησης παίζει σημαντικό ρόλο στην αποτελεσματική διαχείριση της εφοδιαστικής αλυσίδας, διασφαλίζοντας την έγκαιρη αναπλήρωση των αποθεμάτων, τη βελτιωμένη διαχείριση χωρητικότητας και τις βέλτιστες πωλήσεις και έσοδα. Βελτιώνει επίσης τη λήψη αποφάσεων και τη διαχείριση, ενώ επιταχύνει τα μελλοντικά σχέδια για ανάπτυξη και επέκταση [17]. Εάν μια επιχείρηση μπορεί να προβλέψει, όχι μόνο το ποσό των πωλήσεων που θα έχει αλλά και

πότε είναι πιθανό να πραγματοποιηθούν, μπορεί να προγραμματίσει καλύτερα την παραγωγή, την αποθήκευση και την αποστολή των προϊόντων. Αυτό βοηθά την επιχείρηση να σχεδιάσει προγραμματισμένες διακοπές λειτουργίας συντήρησης, μακριά χρονικά από έντονες περιόδους πωλήσεων και να έχει στη διάθεσή της επαρκή υλικά και εργατικά χέρια σε ετοιμότητα καθ' όλη τη διάρκεια του έτους. Όταν είναι γνωστή μια επερχόμενη αύξηση της ζήτησης, η επιχείρηση μπορεί να επικοινωνήσει με τους προμηθευτές της για να εξασφαλίσει ότι υπάρχουν αρκετά υλικά που θα διατηρήσουν τις γραμμές παραγωγής της σε λειτουργία. Μπορεί επίσης να επικοινωνήσει με πελάτες που δεν έχουν ανάγκες αποθέματος ευαίσθητες στο χρόνο και να τους ζητήσει να δέχονται παραγγελίες νωρίτερα ή αργότερα από μια συγκεκριμένη στιγμή που γνωρίζει ότι θα υπάρχει φόρτος εργασίας. Αυτό βοηθά επίσης στην καλύτερη διαχείριση των αναγκών αποθήκευσης και αποστολής.

- **Πρόβλεψη ζήτησης στο επίπεδο εξυπηρέτησης των πελατών (customer service)**

Η ικανοποίηση του πελάτη είναι πάντα η κορυφαία προτεραιότητα για κάθε επιχείρηση και η πρόβλεψη της ζήτησης μπορεί να δώσει ώθηση στην εμπειρία του πελάτη με διάφορους τρόπους. Κατανοώντας τις τάσεις των πελατών και προβλέποντας τις ανάγκες τους, οι επιχειρήσεις μπορούν να διατηρούν απόθεμα από τα προϊόντα που είναι πιο πιθανό να επιθυμήσουν οι πελάτες. Αυτό αποτρέπει την εξάντληση των αποθεμάτων και κατ' επέκταση την απογοήτευση που επέρχεται όταν ο πελάτης δεν εξυπηρετείται. Επιπλέον, η πρόβλεψη της ζήτησης βοηθά τις επιχειρήσεις να εντοπίσουν ευκαιρίες για cross-selling και upselling, έτσι ώστε να παρακινήσουν τους πελάτες τους να ξοδέψουν περισσότερα χρήματα από αυτά που σκόπευαν αρχικά. Χρησιμοποιώντας την πρόβλεψη της ζήτησης για τη βελτιστοποίηση των επιπέδων αποθεμάτων, οι επιχειρήσεις μπορούν να διασφαλίσουν ότι οι ανάγκες των πελατών ικανοποιούνται πάντα, οδηγώντας σε αυξημένη ικανοποίηση.

- **Πρόβλεψη ζήτησης στη στρατηγική πωλήσεων (sales targeting)**

Η στρατηγική πωλήσεων είναι ένα σχέδιο που εστιάζει στους στόχους της επιχείρησης και περιγράφει πώς μπορούν να επιτευχθούν. Αποτελεί υποσύνολο της συνολικής στρατηγικής μιας επιχείρησης. Η διαφορά μεταξύ των δύο είναι ότι ενώ μια στρατηγική πωλήσεων στοχεύει απλώς στην αύξηση των εσόδων, μια επιχειρηματική στρατηγική προσβλέπει επίσης και στη μείωση του κόστους. Ουσιαστικά, υπάρχουν δύο μέρη στη στόχευση πωλήσεων: η επιλογή των σωστών δυνητικών πελατών και η εύρεση του τρόπου προσέγγισης με τον πιο αποτελεσματικό και αποδοτικό τρόπο. Το τελευταίο που θέλουν οι επιχειρήσεις είναι να χάσουν χρόνο παρουσιάζοντας το προϊόν τους σε κάποιον που δεν έχει καν τη δυνατότητα να το αγοράσει. Με τη χρήση της πρόβλεψης ζήτησης, η στρατηγική πωλήσεων έχει αναπτυχθεί σε μια καλά συντονισμένη στρατηγική. Στο παρελθόν, οι εταιρείες συχνά προσπαθούσαν απλώς να διαφημιστούν σε όσο το δυνατόν περισσότερους ανθρώπους. Μέσω της πρόβλεψης ζήτησης, οι εταιρείες έχουν πλέον μεγαλύτερη πρόσβαση σε πληροφορίες και πιθανούς πελάτες, ώστε να επιτύχουν όσο το δυνατόν καλύτερο επίπεδο πωλήσεων. Η πρόβλεψη είναι η διαδικασία προβολής της προηγούμενης ζήτησης πωλήσεων στο μέλλον. Η εφαρμογή ενός συστήματος πρόβλεψης επιτρέπει στην επιχείρηση να αξιολογεί γρήγορα τις τρέχουσες τάσεις της αγοράς και τις πωλήσεις. Εξετάζοντας ιστορικά δεδομένα πωλήσεων και τις εποχιακές τάσεις της εταιρείας, εξάγονται γνώσεις σχετικά με τη μελλοντική ζήτηση των πελατών για ένα προϊόν ή μια υπηρεσία, βοηθώντας με αυτόν τον τρόπο την επιχείρηση να λάβει τεκμηριωμένες αποφάσεις σχετικά με τις λειτουργίες.

- **Πρόβλεψη ζήτησης στον επιχειρησιακό σχεδιασμό (operational planning)**

Οι οικονομικοί σύμβουλοι των εταιρειών (Chief Financial Officer – CFO) θεωρούν την πρόβλεψη ζήτησης μία από τις κορυφαίες οργανωτικές τους προτεραιότητες, καθώς όλα τα στρατηγικά και επιχειρησιακά σχέδια διαμορφώνονται γύρω από την πρόβλεψη της ζήτησης. Οι επαγγελματίες οικονομικών και λογιστικής, λόγω του κεντρικού τους ρόλου στον προγραμματισμό, έχουν ένα σημείο υπεροχής στο να βλέπουν και να κατανοούν τις διαφορετικές προκλήσεις που είναι συνυφασμένες με τα ανταγωνιστικά συμφέροντα των πωλήσεων και των λειτουργιών της εταιρείας. Μπορούν έτσι να προωθήσουν τη βελτίωση και την καινοτομία στη διαδικασία πρόβλεψης της ζήτησης, που αποτελεί τη βάση των προσπαθειών επιχειρηματικού σχεδιασμού τους. Ωστόσο, παρά το εκτεταμένο κόστος και τις αναγνωρίσεις για ανάγκη βελτίωσης, η σημαντική πρόοδος στην ακρίβεια των προβλέψεων παραμένει αδιευκρίνιστη για πολλές εταιρείες [18].

- **Πρόβλεψη ζήτησης στον προϋπολογισμό (budgeting)**

Η πρόβλεψη ζήτησης βοηθά στη μείωση των κινδύνων και στη λήψη αποτελεσματικών οικονομικών αποφάσεων που επηρεάζουν τα περιθώρια κέρδους, τις ταμειακές ροές, την κατανομή πόρων, τις ευκαιρίες για επέκταση, το λειτουργικό κόστος, το προσωπικό και τις συνολικές δαπάνες. Η κακή διαχείριση ταμειακών ροών μπορεί να οδηγήσει σε αδυναμία πληρωμής των προμηθευτών εγκαίρως, δημιουργώντας μια επικίνδυνη κατάσταση που μπορεί να επιφέρει αποκλεισμό από την αγορά. Επίσης, η αδυναμία κατασκευής του προϊόντος λόγω οικονομικής δυσπραγίας, οδηγεί σε αδυναμία προμήθευσης των πελατών και επομένως καθιστά την επιχείρηση αφερέγγυα. Η γνώση των κορυφών και των κοιλάδων της ζήτησης, μέσω της διαδικασίας πρόβλεψης της ζήτησης, βοηθά την επιχείρηση να διαχειριστεί καλύτερα τις ταμειακές ροές της, διασφαλίζοντας ότι έχει αρκετά χρήματα στη διάθεσή της για να καλύψει τις οικονομικές υποχρεώσεις της [19].

- **Πρόβλεψη ζήτησης στη διαχείριση εργασίας (labor management)**

Ένα άλλο σημαντικό πλεονέκτημα της πρόβλεψης ζήτησης είναι η ορθότερη διαχείριση της εργασίας. Η διάθεση πολύ λίγων εργαζομένων για να χειριστούν μια απότομη αύξηση στις παραγγελίες πωλήσεων μπορεί να οδηγήσει σε αργή εκπλήρωση παραγγελιών, ωθώντας τους πελάτες της επιχείρησης στην εξεύρεση νέων προμηθευτών για να εκπληρώσουν τις παραγγελίες τους. Ακόμα κι αν αυτό είναι μόνο ένα προσωρινό πρόβλημα, όταν ένας πελάτης αγοράσει από άλλον προμηθευτή, μπορεί να απομακρυνθεί οριστικά από την επιχείρηση. Επίσης, η προσθήκη ανεπαρκώς εκπαιδευμένων εργαζομένων μπορεί να αυξήσει τα προβλήματα ποιοτικού ελέγχου και τις επιστροφές προϊόντων ή την απώλεια πελατών. Επιπλέον, η ύπαρξη πολλών εργαζομένων σε αδράνεια έχει σαν αποτέλεσμα σπατάλη χρημάτων.

## **2.4 Σημαντικά εργαλεία για τη διαμόρφωση της ζήτησης**

Σήμερα, οι επιχειρήσεις επιδίδονται σε συνεχώς αυξανόμενες προσπάθειες να παραμείνουν ανταγωνιστικές και να διατηρήσουν ή να αυξήσουν το περιθώριο κέρδους τους. Ως εκ τούτου, τα μοντέλα πρόβλεψης έχουν εφαρμοστεί ευρέως για την κατανόηση και την ικανοποίηση των αναγκών και των προσδοκιών των πελατών. Με αυτόν τον τρόπο, υπάρχει αυξανόμενη προσοχή στην ανάλυση της καταναλωτικής συμπεριφοράς και των προτιμήσεων, χρησιμοποιώντας προβλέψεις που λαμβάνονται από δεδομένα πελατών και αρχεία συναλλαγών.

## 2.4.1 Μοντελοποίηση Προώθησης (Promotional Modelling)

Οι επιχειρήσεις πρέπει να σχεδιάσουν πώς θα δημιουργήσουν και θα ικανοποιήσουν τη ζήτηση για τα προϊόντα ή τις υπηρεσίες τους. Η προώθηση πωλήσεων (sales promotion) είναι ένα μέσο με το οποίο οι επιχειρήσεις αυξάνουν τη ζήτηση και την προβολή των προϊόντων και των υπηρεσιών τους. Αυτή η προώθηση κοστίζει και το κόστος πρέπει να δικαιολογείται με δομημένη ανάλυση. Οι επικεφαλής των επιχειρήσεων πρέπει να καθορίσουν την αξία προηγούμενων ή προτεινόμενων προωθήσεων. Επιπλέον, τα προτεινόμενα μοντέλα προώθησης πωλήσεων επηρεάζουν τη μελλοντική ζήτηση, επομένως πρέπει να διατεθούν αυξημένοι πόροι που θα ικανοποιήσουν την προωθούμενη ζήτηση. Με την έλευση του ηλεκτρονικού εμπορίου, οι προσδοκίες των πελατών είναι πολύ υψηλότερες από ότι στο παρελθόν. Επομένως, εάν μια επιχείρηση προωθεί ένα προϊόν ή μια υπηρεσία, αναμένεται να τα παρέχει εγκαίρως [20].

Οι εταιρείες μπορούν να χρησιμοποιήσουν μια μεγάλη ποικιλία τεχνικών για να μοιραστούν πληροφορίες και να μεθοδεύσουν την προώθηση των προϊόντων τους, αυξάνοντας παράλληλα την αναγνωρισιμότητα της επωνυμίας, των προϊόντων και των υπηρεσιών τους. Επιπλέον, μπορούν να προσελκύσουν νέους πελάτες, να διατηρήσουν τους υπάρχοντες και να αυξήσουν τα έσοδα. Οι τεχνικές αυτές χρησιμοποιούνται από τις ομάδες marketing κάθε εταιρείας και ονομάζονται προωθητικές ενέργειες (promotional activities). Οι προωθητικές ενέργειες συχνά στοχεύουν στο να ενημερώσουν πρώτα τους πελάτες για τα προϊόντα και να αυξήσουν το ενδιαφέρον τους. Στη συνέχεια προσπαθούν να αυξήσουν την επιθυμία στις ομάδες-στόχους και να τους πείσουν να αναλάβουν δράση κάνοντας μια αγορά. Ορισμένοι τύποι προωθητικών ενεργειών είναι οι παρακάτω:

- Διαφήμιση σε τηλεόραση, ραδιόφωνο, περιοδικά κ.λπ.
- Εκδηλώσεις marketing σε συνέδρια, εκδηλώσεις κ.λπ.
- Αγορά ενός προϊόντος και ένα ακόμα δωρεάν (Buy one, get one free - BOGOF)
- Δωρεάν δοκιμή προϊόντος σε super markets [13]
- Διαφήμιση μέσω μέσων κοινωνικής δικτύωσης
- Διαφημιστικές καμπάνιες μέσω email και SMS
- Προγράμματα επιβράβευσης και αφοσίωσης.

Το μοντέλο προώθησης στη ζήτηση προσφέρει σημαντικά πλεονεκτήματα στις επιχειρήσεις, οι οποίες με τη χρήση του μπορούν να:

- Αξιολογήσουν τον αντίκτυπο των προωθητικών ενεργειών στη ζήτηση.
- Προσδιορίσουν ποιες δραστηριότητες προώθησης θα εφαρμόσουν και πότε.
- Διεξάγουν ανάλυση ανταγωνισμού συγκρίνοντας τον αντίκτυπο των προωθητικών τους ενεργειών με εκείνες των ανταγωνιστών [13].

## 2.4.2 Ελαστικότητα Ζήτησης ως προς την Τιμή & Βελτιστοποίηση (Price Elasticity & Optimization)

Η ελαστικότητα ζήτησης ως προς την τιμή είναι η μέτρηση της μεταβολής της κατανάλωσης ενός προϊόντος σε σχέση με τη μεταβολή της τιμής του. Οι οικονομολόγοι χρησιμοποιούν την ελαστικότητα των τιμών για να κατανοήσουν πώς αλλάζει η προσφορά και η ζήτηση για ένα προϊόν όταν αλλάζει η τιμή του. Υπολογίζεται διαιρώντας την ποσοστιαία μεταβολή της ζητούμενης ποσότητας με την ποσοστιαία μεταβολή της τιμής. Όπως η ζήτηση, η προσφορά έχει επίσης μια ελαστικότητα, γνωστή ως ελαστικότητα προσφοράς ως προς την τιμή. Η ελαστικότητα της προσφοράς ως προς την τιμή αναφέρεται στη σχέση μεταξύ μεταβολής της προσφοράς και μεταβολής της τιμής. Υπολογίζεται διαιρώντας την ποσοστιαία μεταβολή στην ποσότητα που παρέχεται με την ποσοστιαία μεταβολή της

τιμής. Μαζί, οι δύο ελαστικότητες συνδυάζονται για να καθορίσουν ποια προϊόντα παράγονται σε ποιες τιμές.

Ένα αγαθό είναι απόλυτα ελαστικό εάν η ελαστικότητα τιμής είναι άπειρη, δηλαδή αν η ζήτηση αλλάζει ουσιαστικά ακόμη και με ελάχιστη μεταβολή τιμής. Εάν η ελαστικότητα τιμής είναι μεγαλύτερη από 1 το αγαθό είναι ελαστικό, ενώ αν είναι μικρότερη από 1 είναι ανελαστικό. Εάν η ελαστικότητα τιμής ενός αγαθού είναι 0, σημαίνει πως καμία αλλαγή τιμής δεν προκαλεί αλλαγή στη ζήτηση, επομένως είναι απολύτως ανελαστική. Εάν η ελαστικότητα τιμής είναι ακριβώς 1, δηλαδή η μεταβολή της τιμής οδηγεί σε ίση ποσοστιαία μεταβολή στη ζήτηση, η ελαστικότητα είναι γνωστή ως ενιαία. Η διαθεσιμότητα υποκατάστατου ενός προϊόντος επηρεάζει την ελαστικότητά του. Εάν δεν υπάρχουν ικανοποιητικά υποκατάστατα και το προϊόν είναι απαραίτητο, η ζήτηση δε θα αλλάξει όταν η τιμή ανεβαίνει, καθιστώντας το ανελαστικό.

Οι οικονομολόγοι έχουν διαπιστώσει ότι οι τιμές ορισμένων αγαθών είναι πολύ ανελαστικές. Δηλαδή, μια μείωση της τιμής δεν αυξάνει πολύ τη ζήτηση, και η αύξηση της τιμής δε βλάπτει επίσης τη ζήτηση. Για παράδειγμα, η βενζίνη έχει μικρή ελαστικότητα ζήτησης ως προς την τιμή. Οι επαγγελματίες οδηγοί θα συνεχίσουν να αγοράζουν όσο πρέπει, όπως και οι αεροπορικές εταιρείες, η βιομηχανία φορτηγών και σχεδόν κάθε άλλος αγοραστής. Άλλα αγαθά είναι πολύ πιο ελαστικά, επομένως οι αλλαγές τιμών για αυτά τα αγαθά προκαλούν σημαντικές αλλαγές στη ζήτηση ή την προσφορά τους. Αυτό το φαινόμενο προκαλεί το ενδιαφέρον των επαγγελματιών marketing, σκοπός των οποίων είναι να δημιουργήσουν ανελαστική ζήτηση για τα προϊόντα που εμπορεύονται. Αυτό το πετυχαίνουν εντοπίζοντας μια σημαντική διαφορά στα προϊόντα τους από οποιαδήποτε άλλα διαθέσιμα.

Αφού υπολογιστεί η ελαστικότητα τιμής, οι επιχειρήσεις μπορούν να πραγματοποιήσουν ανάλυση σεναρίου για να μετρήσουν τον αντίκτυπο στη ζήτηση. Η ανάλυση σεναρίου, που μερικές φορές αναφέρεται ως ανάλυση what if, είναι μια προσέγγιση στην οποία παρουσιάζεται ένα σύνολο συνθηκών και γεγονότων (ένα σενάριο) και τα αποτελέσματα προσδιορίζονται με τη χρήση ενός μαθηματικού μοντέλου. Τα αποτελέσματα της ανάλυσης σεναρίου συνδυάζονται με την ικανότητα και τους στόχους της επιχείρησης, καθορίζοντας τη βέλτιστη τιμολογιακή πολιτική [13]. Η γνώση της ελαστικότητας ζήτησης ως προς την τιμή ενός αγαθού επιτρέπει σε αυτόν που πουλά το αγαθό να λάβει τεκμηριωμένες αποφάσεις σχετικά με τις στρατηγικές τιμολόγησης. Αυτή η μέτρηση παρέχει στους πωλητές πληροφορίες σχετικά με την ευαισθησία των τιμών καταναλωτή. Είναι επίσης βασικό στοιχείο για τους κατασκευαστές αγαθών, προκειμένου να καθορίσουν τα σχέδια παραγωγής, καθώς και για τις κυβερνήσεις για να αξιολογήσουν τον τρόπο επιβολής φόρων στα αγαθά.

Υπάρχουν ορισμένοι παράγοντες που επηρεάζουν την ελαστικότητα της ζήτησης ως προς την τιμή. Αυτοί είναι οι παρακάτω:

- **Διαθεσιμότητα υποκατάστατων**

Όσο πιο εύκολα ένας αγοραστής μπορεί να αντικαταστήσει ένα προϊόν με ένα άλλο, τόσο περισσότερο θα μειωθεί η τιμή του.

- **Έννοια του επείγοντος**

Όσο πιο προαιρετική είναι μια αγορά, τόσο περισσότερο θα μειωθεί η ποσότητα της ζήτησης ως απάντηση στις αυξήσεις των τιμών. Δηλαδή, η ζήτηση προϊόντος έχει μεγαλύτερη ελαστικότητα. Αντιθέτως, όσο λιγότερο προαιρετικό είναι ένα προϊόν, τόσο λιγότερο θα μειωθεί η ζητούμενη ποσότητα.

- **Διάρκεια αλλαγής τιμής**

Το χρονικό διάστημα που διαρκεί η αλλαγή τιμής έχει επίσης σημασία. Σαν αποτέλεσμα, η ανταπόκριση της ζήτησης στις διακυμάνσεις των τιμών είναι διαφορετική για μια μονοήμερη πώληση από ό,τι για μια αλλαγή τιμής που διαρκεί για μια σεζόν ή ένα χρόνο. Η σαφήνεια της ευαισθησίας στο χρόνο είναι ζωτικής σημασίας για την κατανόηση της ελαστικότητας της ζήτησης ως προς την τιμή και για τη σύγκρισή της με διαφορετικά προϊόντα. Οι καταναλωτές μπορεί να αποδεχτούν μια εποχιακή διακύμανση των τιμών αντί να αλλάξουν τις συνήθειές τους [21].



# 3

## Μέθοδοι και Τεχνικές Πρόβλεψης Ζήτησης

### 3.1 Χρησιμότητα μεθόδων Πρόβλεψης Ζήτησης

Η ακριβής πρόβλεψη ζήτησης επιτρέπει στις εταιρείες να λαμβάνουν τεκμηριωμένες αποφάσεις σχετικά με την παραγωγή, τη διαχείριση αποθεμάτων, τη στελέχωση και τον οικονομικό προγραμματισμό. Συνεπώς, με μια ακριβή πρόβλεψη της ζήτησης οι επιχειρήσεις μπορούν να βελτιστοποιήσουν τις δραστηριότητές τους, να ελαχιστοποιήσουν το κόστος και να ανταποκριθούν αποτελεσματικά στις ανάγκες των πελατών. Η αποτελεσματική πρόβλεψη ζήτησης βοηθά τις επιχειρήσεις να αποφύγουν την υπερπαραγωγή, η οποία οδηγεί σε υπερβολικό απόθεμα και αυξημένο κόστος, καθώς και στην υποπαραγωγή, που οδηγεί σε χαμένες πωλήσεις και σε δυσαρεστημένους πελάτες. Συμβάλλει επίσης στην ορθή λειτουργία της αλυσίδας εφοδιασμού τους, τη μείωση του κόστους διατήρησης αποθεμάτων και την αποτελεσματική κατανομή των πόρων. Επιπλέον, παρέχει στις επιχειρήσεις ανταγωνιστικό πλεονέκτημα, δίνοντάς τους τη δυνατότητα να ανταποκρίνονται γρήγορα στη μεταβαλλόμενη δυναμική της αγοράς και στις προτιμήσεις των πελατών. Επειδή το μέλλον είναι αβέβαιο, οι προβλέψεις ζήτησης πρέπει συχνά να αναθεωρούνται, αλλά, σε κάθε περίπτωση, τα πραγματικά αποτελέσματα μπορεί να διαφέρουν αρκετά από τα αποτελέσματα των προβλέψεων. Παρόλα αυτά, μια αποτελεσματική και συχνά αναθεωρούμενη πρόβλεψη ζήτησης υποστηρίζει τη λήψη αποφάσεων βάσει δεδομένων, οδηγώντας σε βελτιωμένη συνολική επιχειρηματική απόδοση και κερδοφορία [14] [22].

Υπάρχουν πολλές τεχνικές πρόβλεψης της ζήτησης, η καθεμία με τα δικά της δυνατά και αδύναμα σημεία. Οι τεχνικές πρόβλεψης ζήτησης κυμαίνονται από απλές έως πολύπλοκες, ανάλογα με τη διαθεσιμότητα των δεδομένων που θα χρησιμοποιηθούν για τη σύνθεση της πρόβλεψης και το επίπεδο ακρίβειας που απαιτείται. Ορισμένες κοινές τεχνικές περιλαμβάνουν: ανάλυση ιστορικών δεδομένων, παθητική πρόβλεψη ζήτησης, ανάλυση τάσεων, έρευνα αγοράς και οικονομετρική μοντελοποίηση. Οι επιχειρήσεις μπορούν επίσης να αξιοποιήσουν προηγμένους αλγόριθμους ανάλυσης και μηχανικής μάθησης για να βελτιώσουν την ακρίβεια των προβλέψεων παθητικής ζήτησης.

Γενικά, η πρόβλεψη ζήτησης μπορεί να προσεγγιστεί χρησιμοποιώντας ποσοτικές ή ποιοτικές τεχνικές. Η ποιοτική πρόβλεψη ζήτησης (qualitative demand forecasting) βασίζεται σε υποκειμενικές απόψεις και ιδέες, ενώ η ποσοτική πρόβλεψη ζήτησης (quantitative demand forecasting) επικεντρώνεται περισσότερο στη χρήση ιστορικών δεδομένων ζήτησης και σε στατιστικούς υπολογισμούς για την πρόβλεψη του μέλλοντος. Οι ποιοτικές μέθοδοι είναι πιο χρονοβόρες και δαπανηρές, αλλά μπορούν να κάνουν πολύ ακριβείς προβλέψεις, με περιορισμένο εύρος. Για ταχύτερες αναλύσεις, που μπορούν να καλύψουν μεγαλύτερο εύρος, οι ποσοτικές μέθοδοι είναι συχνά πιο

χρήσιμες, καθώς έχουν την ικανότητα, μέσω στατιστικών λογισμικών, να εξετάζουν μεγάλα σύνολα δεδομένων μέσα σε λίγα λεπτά ή δευτερόλεπτα. Ωστόσο, όσο μεγαλύτερο είναι το σύνολο δεδομένων και όσο πιο σύνθετη είναι η ανάλυση, τόσο πιο ακριβή μπορεί να είναι. Η επιλογή της κατάλληλης μεθόδου εξαρτάται από τις ανάγκες κάθε επιχείρησης, τον τύπο και τους στόχους της. Ανάλογα με τα διαθέσιμα δεδομένα και το χρονικό διάστημα λειτουργίας της εκάστοτε επιχείρησης, η μία προσέγγιση θα αποτελεί πιο ωφέλιμη επιλογή από την άλλη. Για αυτόν το λόγο, οι προγνώστες, πριν καταλήξουν στη μέθοδο που θα χρησιμοποιήσουν, συνήθως πραγματοποιούν ένα είδος ανάλυσης κόστους και οφέλους για να προσδιορίσουν ποια μέθοδος μεγιστοποιεί τις πιθανότητες μιας ακριβούς πρόβλεψης με τον πιο αποτελεσματικό τρόπο [23]. Οι δύο μέθοδοι συχνά χρησιμοποιούνται μαζί για να εξετάσουν τις λειτουργίες μιας εταιρείας και να αξιολογήσουν τις δυνατότητές της ως επενδυτική ευκαιρία. Στην παρούσα διπλωματική επιλέχθηκε ως καταλληλότερη η ποσοτική μέθοδος πρόβλεψης.

### 3.2 Ποσοτική Πρόβλεψη Ζήτησης

Οι επιχειρήσεις χρησιμοποιούν ευρέως τις ποσοτικές μεθόδους για να κάνουν προβλέψεις σχετικά με τις μελλοντικές τάσεις, βασιζόμενες σε μαθηματικά μοντέλα και ιστορικά δεδομένα. Για την εξαγωγή τεκμηριωμένων προβλέψεων, εκτός από διαθέσιμα ιστορικά δεδομένα, χρειάζεται και οι σχέσεις μεταξύ των μεταβλητών να είναι σαφώς καθορισμένες [24]. Εάν είναι καλά σχεδιασμένες, οι ποσοτικές μελέτες είναι σχετικές, με την έννοια ότι έχουν σχεδιαστεί για να κάνουν προβλέψεις, να ανακαλύπτουν γεγονότα και να ελέγχουν υπάρχουσες υποθέσεις. Οι ερευνητές τις χρησιμοποιούν για να δοκιμάσουν θεωρίες σχετικά με το πώς ή γιατί συμβαίνουν ορισμένα γεγονότα, βρίσκοντας στοιχεία που υποστηρίζουν ή διαψεύδουν τις θεωρίες αυτές [25]. Οι ποσοτικές μέθοδοι είναι χρήσιμες για τον εντοπισμό προτύπων, τάσεων και σχέσεων και για την παροχή ακριβών και αντικειμενικών εκτιμήσεων, αλλά αντιμετωπίζουν ορισμένες προκλήσεις, όπως η ποιότητα των δεδομένων, η πολυπλοκότητα και η αβεβαιότητα [26].

Υπάρχουν δύο τύποι τεχνικών ποσοτικής πρόβλεψης: οι εξωγενείς και οι ενδογενείς. Η κύρια διάκριση μεταξύ των δύο προβλέψεων είναι ότι οι εξωγενείς προβλέψεις περιλαμβάνουν επιπλέον και άλλα χαρακτηριστικά, συμπεριλαμβανομένου του Ακαθάριστου Εθνικού Προϊόντος, ενώ οι ενδογενείς προβλέψεις βασίζονται κυρίως στο ιστορικό ζήτησης των ειδών που μελετώνται. Πιο συγκεκριμένα, οι ενδογενείς προβλέψεις λειτουργούν με την υπόθεση ότι τα ιστορικά δεδομένα ζήτησης παρουσιάζουν ένα μοτίβο ζήτησης που θα ισχύει και στο μέλλον. Οι τυχαίες διακυμάνσεις θα μπορούσαν, φυσικά, να έχουν αντίκτυπο σε αυτή την τάση. Προκειμένου να γίνει πρόβλεψη, αναλύονται ιστορικά δεδομένα για τον εντοπισμό προτύπων και στη συνέχεια αυτά τα μοτίβα προβάλλονται στο μέλλον [27].

Επομένως, οι ποσοτικές μέθοδοι πρόβλεψης ζήτησης χρησιμοποιούν μαθηματικά μοντέλα και στατιστικές τεχνικές για να κάνουν προβλέψεις με βάση αριθμητικά δεδομένα, όπως πωλήσεις, τιμές, εισόδημα, πληθυσμός και εποχικότητα, αποκλείοντας τις γνώμες εμπειρογνομόνων. Η ποσοτική πρόβλεψη ζήτησης επικεντρώνεται σε δομημένα δεδομένα, στατιστικές αναλύσεις και πειράματα, όπως, για παράδειγμα, το μέσο ποσοστό απόρριψης πελατών στον κλάδο της επιχείρησης ή ακόμα καλύτερα, τις προηγούμενες επιδόσεις της ίδιας της επιχείρησης [28] [29]. Για το λόγο αυτό, συχνά ονομάζεται και στατιστική πρόβλεψη ζήτησης (statistical demand forecasting). Συνεπώς, οι ποσοτικές μέθοδοι πρόβλεψης ζήτησης χρησιμοποιούνται συχνά όταν υπάρχουν διαθέσιμα επαρκή και αξιόπιστα ιστορικά δεδομένα και όταν η ζήτηση ακολουθεί ένα κανονικό πρότυπο ή τάση. Βασίζονται στο να έχουν επαρκή, καλής ποιότητας δεδομένα για το παρελθόν για να κάνουν μια λογική εκτίμηση για το μέλλον [26].

Οι πιο συχνοί τύποι ποσοτικών μεθόδων πρόβλεψης ζήτησης περιλαμβάνουν την ανάλυση χρονοσειρών, την ανάλυση παλινδρόμησης, την εκθετική εξομάλυνση και τους κινητούς μέσους όρους. Η ανάλυση χρονοσειρών είναι ίσως το πιο συνηθισμένο στατιστικό μοντέλο πρόβλεψης ζήτησης.

Επίσης, έρευνες, δημοσκοπήσεις και λογισμικά στατιστικής ανάλυσης είναι όλα παραδείγματα οργάνων που χρησιμοποιούνται για τη συλλογή και τη μέτρηση ποσοτικών δεδομένων [25] [30].

### 3.2.1 Οικονομετρικά Μοντέλα (Econometric Models)

Η οικονομική μοντελοποίηση είναι μια μέθοδος πρόβλεψης που χρησιμοποιεί οικονομικά δεδομένα για να προβλέψει τις μελλοντικές τάσεις. Περιλαμβάνει την ανάλυση οικονομικών δεδομένων, τον εντοπισμό προτύπων και τάσεων και τη χρήση αυτών των πληροφοριών για να γίνουν προβλέψεις για το μέλλον. Αυτή η μέθοδος είναι χρήσιμη όταν υπάρχουν οικονομικοί παράγοντες που μπορούν να επηρεάσουν τα δεδομένα [24]. Τα οικονομικά μοντέλα υποθέτουν ότι η συμπεριφορά της μεταβλητής, που πρόκειται να προβλεφθεί, εξηγείται από τη συμπεριφορά μιας ή περισσότερων άλλων μεταβλητών. Η πρώτη μεταβλητή ονομάζεται εξαρτημένη και οι άλλες μεταβλητές ονομάζονται ανεξάρτητες [13]. Με απλούστερους όρους, οι οικονομετρολόγοι μετρούν τις προηγούμενες σχέσεις μεταξύ μεταβλητών, όπως η καταναλωτική δαπάνη, το εισόδημα των νοικοκυριών, οι φορολογικοί συντελεστές, τα επιτόκια, η απασχόληση κ.α., και στη συνέχεια προσπαθούν να προβλέψουν πώς οι αλλαγές σε ορισμένες μεταβλητές θα επηρεάσουν τη μελλοντική πορεία άλλων μεταβλητών [31]. Πριν μπορέσουν οι οικονομετρολόγοι να κάνουν τέτοιους υπολογισμούς, ξεκινούν γενικά με ένα οικονομικό μοντέλο, μια θεωρία για το πώς διαφορετικοί παράγοντες στην οικονομία αλληλεπιδρούν μεταξύ τους [32]. Σκοπός των econometric models είναι να ανακαλύψουν τη μορφή της σχέσης και να τη χρησιμοποιήσουν για την πρόβλεψη της μελλοντικής τιμής της εξαρτημένης μεταβλητής [13].

Τα οικονομικά μοντέλα είναι από τα πιο ισχυρά εργαλεία για την πρόβλεψη της ζήτησης, καθώς αξιοποιούν ιστορικά δεδομένα και άλλες σχετικές μεταβλητές για τη δημιουργία πληροφοριών και προβολών που καθοδηγούν τις διαδικασίες λήψης αποφάσεων. Το τοπίο της οικονομικής μοντελοποίησης για την πρόβλεψη ζήτησης είναι πλούσιο και ποικίλο, περιλαμβάνοντας μια σειρά μεθοδολογιών από απλή γραμμική παλινδρόμηση (linear regression) έως σύνθετους αλγόριθμους μηχανικής μάθησης. Τα παραδοσιακά οικονομικά μοντέλα, όπως η γραμμική παλινδρόμηση, παρέχουν θεμελιώδεις προσεγγίσεις μοντελοποιώντας τις σχέσεις μεταξύ της ζήτησης και των προγνωστικών της με την πάροδο του χρόνου. Πιο προηγμένα μοντέλα, όπως η διανυσματική αυτόματη παλινδρόμηση (Vector Autoregression - VAR) και τα μοντέλα συνολοκλήρωσης, (cointegration models) αποτυπώνουν τις δυναμικές αλληλεπιδράσεις μεταξύ πολλαπλών μεταβλητών χρονοσειρών, προσφέροντας μια βαθύτερη κατανόηση των υποκείμενων οικονομικών μηχανισμών [32] [33].

Το βασικό πλεονέκτημα της οικονομικής πρόβλεψης είναι ότι παρέχει τις τιμές πολλών από τις ανεξάρτητες μεταβλητές μέσα από το ίδιο το μοντέλο, απαλλάσσοντας έτσι τον υπεύθυνο για τη διενέργεια των προβλέψεων από την ανάγκη να τις εκτιμήσει εξωγενώς. Δεδομένου ότι αυτές οι πληροφορίες μπορούν να ληφθούν από εξωτερικές πηγές, οι οργανισμοί δε χρειάζεται να αναπτύξουν τα δικά τους μοντέλα, αλλά μπορούν να βασίζονται σε τρίτους για να τους παρέχουν προβλέψεις όταν απαιτούνται. Έτσι, μεμονωμένες εταιρείες μπορούν να παραιτηθούν από όλα τα υψηλά κόστη που συνδέονται με την ανάπτυξη συντήρησης και λειτουργίας ενός οικονομικού μοντέλου μεγάλης κλίμακας και να λάβουν τις πληροφορίες που προσφέρει μέσω τρίτων [34].

Ωστόσο, στη χρήση οικονομικών μοντέλων, παρατηρούνται και ορισμένα μειονεκτήματα. Πρώτον, οι μελλοντικές τιμές των ίδιων των αιτιολογικών μεταβλητών πρέπει να προβλεφθούν. Δεύτερον, ακόμη και όταν χρησιμοποιείται μια αιτιολογική μεταβλητή με καθυστέρηση, για να προβλεφθούν οι πωλήσεις για την επόμενη περίοδο, η αναφερόμενη τιμή της είναι συχνά μια προκαταρκτική εικόνα, που αργότερα αναθεωρείται. Και οι δύο αυτοί παράγοντες μπορούν να προκαλέσουν ανακριβή δεδομένα σε ένα οικονομικό μοντέλο και το μοντέλο να εμφανίζει αδυναμία στην ικανότητά του να προβλέπει. Τρίτον, η συνεχής ανάγκη συλλογής δεδομένων, είναι πιθανόν να καταστήσει αυτά τα μοντέλα ακριβά στη χρήση. Τέλος, η σχέση που εντοπίστηκε μεταξύ της εξαρτημένης και της ανεξάρτητης μεταβλητής, μπορεί να είναι ψευδής. Αιτιώδεις σχέσεις μπορεί να

αλλάξουν με την πάροδο του χρόνου, καθιστώντας απαραίτητη τη συνεχή ενημέρωση ή τον πλήρη επανασχεδιασμό του μοντέλου [35].

### 3.2.2 Μοντέλα Χρονοσειρών

Η ανάλυση χρονοσειρών είναι μια μέθοδος πρόβλεψης που χρησιμοποιεί ιστορικά δεδομένα για να προβλέψει τις μελλοντικές τάσεις. Υποθέτει ότι τα μελλοντικά μοτίβα θα μοιάζουν με προηγούμενα και περιλαμβάνει την ανάλυση ιστορικών δεδομένων, τον εντοπισμό προτύπων και τάσεων και τη χρήση αυτών των πληροφοριών για να γίνουν προβλέψεις για το μέλλον [24]. Για παράδειγμα, εξετάζει πρότυπα συμπεριφοράς των καταναλωτών στο παρελθόν με την πάροδο του χρόνου για να προβλέψει τη μελλοντική συμπεριφορά τους. Μια χρονοσειρά αποτελεί η μηνιαία ζήτηση για ένα προϊόν κατά τους προηγούμενους δώδεκα μήνες. Επομένως, οι μέθοδοι πρόβλεψης χρονοσειρών δε βασίζονται στις προβλέψεις τους σε άλλες επεξηγηματικές μεταβλητές, αλλά σε προηγούμενες τιμές της μεταβλητής που πρόκειται να προβλεφθεί ή/και παλαιότερα σφάλματα του μοντέλου πρόβλεψης [13]. Η ανάλυση χρονοσειρών αποτελεί χρήσιμη μέθοδο όταν υπάρχει σταθερό μοτίβο στα δεδομένα και όταν αυτά δεν επηρεάζονται από εξωτερικούς παράγοντες [24].

Η ανάλυση χρονοσειρών αποτελεί ίσως το πιο κοινό μοντέλο στατιστικής πρόβλεψης ζήτησης. Λόγω της περίπλοκης και δυναμικής φύσης των συνθηκών της αγοράς, τα μοντέλα χρονοσειρών έχουν αναδειχθεί ως ισχυρά εργαλεία για την αντιμετώπιση αυτών των προκλήσεων. Αναλύοντας ιστορικά δεδομένα, αυτά τα μοντέλα αποκαλύπτουν μοτίβα και τάσεις που μπορούν να προβληθούν στο μέλλον. Η συγκεκριμένη αναλυτική προσέγγιση βοηθά τις επιχειρήσεις να προβλέψουν τις διακυμάνσεις της ζήτησης, να προσαρμοστούν στις εποχιακές διακυμάνσεις και να ανταποκριθούν αποτελεσματικά στις αλλαγές της αγοράς [36]. Ωστόσο, το αποτέλεσμα της εφαρμογής ενός time series model δεν αποτελεί πάντα μια ακριβή πρόβλεψη και η πιθανότητα των προβλέψεων να επιβεβαιωθούν μπορεί να ποικίλλει σε μεγάλο βαθμό. Ειδικά όταν τα δεδομένα αφορούν συνεχώς κυμαινόμενες μεταβλητές, καθώς και παράγοντες εκτός του ελέγχου της επιχείρησης. Συνήθως, όσο πιο ολοκληρωμένα είναι τα δεδομένα, τόσο πιο ακριβείς μπορεί να είναι οι προβλέψεις [33]. Ο βασικός στόχος των time series models είναι να ανακαλύψουν το μοτίβο στις ιστορικές σειρές δεδομένων και να προεκτείνουν αυτό το μοντέλο στο μέλλον [13].

Ένα βασικό στοιχείο που αντιπροσωπεύει ένα γραμμικό μοτίβο είναι η γραμμική τάση ((linear trend - T). Σε ορισμένες περιπτώσεις, δεν παρατηρείται τάση κατά τη διάρκεια της έρευνας. Σε αυτές τις περιπτώσεις, το σταθερό μοντέλο ή το οριζόντιο αποτέλεσμα προκύπτει όταν η κλίση της γραμμής είναι μηδέν. Εκτός από το μηδέν, η τάση μπορεί να λάβει είτε θετική είτε αρνητική τιμή. Η θετική τάση η οποία είναι, κατά μέσο όρο, ανάλογη με κάθε περίοδο, αντιστοιχεί σε αύξηση της ζήτησης. Αυτή η τάση μπορεί να είναι αποτέλεσμα προωθήσεων που αυξάνουν τη ζήτηση για νέα προϊόντα ή μείωσης τιμών που αυξάνουν τη ζήτηση για ήδη υπάρχοντα προϊόντα. Αντίθετα, ένα προϊόν με μειωμένη ζήτηση, που είναι πιθανό να αποσυρθεί, υποδηλώνει αρνητική τάση. Οι εποχές υψηλής ή χαμηλής ζήτησης που επαναλαμβάνονται διαχρονικά είναι γνωστές ως εποχιακά μοτίβα (Seasonal Patterns - S). Πολλοί παράγοντες, όπως ο καιρός, η περίοδος των διακοπών και οι αγροτικές εργασίες, μπορεί να ευθύνονται για την επανάληψή του. Προϊόντα που παρουσιάζουν εποχικότητα στη ζήτηση είναι τα παγωτά και τα παγωμένα ποτά, τα οποία έχουν αύξηση της ζήτησης το καλοκαίρι και μείωση το χειμώνα [14] [36] [37].

Τα μοντέλα χρονοσειρών κυμαίνονται από απλές μεθόδους, όπως κινητοί μέσοι όροι και εκθετική εξομάλυνση, έως πιο εξελιγμένες τεχνικές όπως ARIMA, SARIMA και νευρωνικά δίκτυα. Κάθε μοντέλο έχει πλεονεκτήματα και είναι κατάλληλο για διαφορετικούς τύπους δεδομένων και σενάρια προβλέψεων. Σε αυτό το πλαίσιο, η κατανόηση και η επιλογή του κατάλληλου μοντέλου χρονοσειρών είναι ζωτικής σημασίας για την επίτευξη αξιόπιστων προβλέψεων ζήτησης. Ακολουθεί

μια λεπτομερής καταγραφή των μοντέλων χρονοσειρών που χρησιμοποιήθηκαν στην πρόβλεψη ζήτησης στα πλαίσια της παρούσας εργασίας, καθώς και του μοντέλου εκθετικής εξομάλυνσης.

### 3.2.2.1 Μοντέλο ARIMA

Βασικό ρόλο στην ανάλυση χρονοσειρών παίζουν οι διεργασίες, των οποίων οι ιδιότητες, ή ορισμένες από αυτές, δε μεταβάλλονται με την πάροδο του χρόνου. Μια τέτοια ιδιότητα απεικονίζεται στη σημαντική έννοια της σταθερότητας. Τα πιο συχνά χρησιμοποιούμενα μοντέλα σταθερών γραμμικών χρονοσειρών είναι τα μοντέλα ARIMA (Autoregressive Integrated Moving Average). Τα ARIMA ή Αυτοπαλινδρομικά Μοντέλα Ολοκληρωμένου Κινητού Μέσου Όρου, είναι μια μορφή ανάλυσης παλινδρόμησης, που δείχνει την ισχύ μιας εξαρτημένης μεταβλητής, σε σχέση με άλλες μεταβαλλόμενες μεταβλητές. Βασίζεται στη στατιστική έννοια της σειριακής συσχέτισης, όπου τα προηγούμενα σημεία δεδομένων επηρεάζουν τα μελλοντικά σημεία δεδομένων [37]. Τα μοντέλα ARIMA χρησιμοποιούν τη διαφορά για να μετατρέψουν μια μη στάσιμη χρονοσειρά σε σταθερή και στη συνέχεια να προβλέψουν μελλοντικές τιμές από ιστορικά δεδομένα. Αυτά τα μοντέλα χρησιμοποιούν αυτόματους συσχετισμούς και κινητούς μέσους όρους, έναντι των υπολειπόμενων σφαλμάτων στα δεδομένα, για την πρόβλεψη μελλοντικών τιμών. Ο τελικός στόχος του μοντέλου είναι να προβλέψει την κίνηση μελλοντικών χρονοσειρών, εξετάζοντας τις διαφορές μεταξύ των τιμών στη σειρά αντί μέσω των πραγματικών τιμών [38].

Κάθε στοιχείο στο ARIMA λειτουργεί ως παράμετρος, με τους τυπικούς συμβολισμούς  $p$ ,  $d$  και  $q$ , όπου οι ακέραιες τιμές αντικαθιστούν τις παραμέτρους που υποδεικνύουν τον τύπο του μοντέλου ARIMA που χρησιμοποιείται. Οι παράμετροι μπορούν να οριστούν ως εξής:

- $p$ : η σειρά του αυτοπαλινδρομικού μοντέλου (autoregressive order), γνωστή και ως σειρά υστέρησης (lag order),
- $d$ : ο αριθμός των φορών που διαφοροποιούνται οι πρωτογενείς παρατηρήσεις, γνωστός και ως βαθμός διαφοροποίησης (degree of differencing) και
- $q$ : ο αριθμός των καθυστερημένων σφαλμάτων πρόβλεψης στην εξίσωση πρόβλεψης, γνωστός και ως σειρά του κινητού μέσου όρου (order of the moving average) [39].

Η διαδικασία δημιουργίας ενός μοντέλου ARIMA ξεκινά με τη συγκέντρωση όσο περισσότερων δεδομένων τιμών είναι εφικτό. Αφού προσδιοριστούν οι τάσεις για τα δεδομένα, προσδιορίζεται ο χαμηλότερος βαθμός διαφοροποίησης ( $d$ ) παρατηρώντας τις αυτοσυσχετίσεις. Εάν η αυτοσυσχέτιση lag-1 είναι μηδέν ή αρνητική, η σειρά έχει ήδη διαφοροποιηθεί. Ίσως χρειαστεί να διαφοροποιηθεί περισσότερο η σειρά εάν η lag-1 είναι μεγαλύτερη από το μηδέν. Στη συνέχεια, προσδιορίζεται η σειρά υστέρησης ( $p$ ) και η σειρά του κινητού μέσου όρου ( $q$ ), συγκρίνοντας αυτοσυσχετίσεις και μερικές αυτοσυσχετίσεις [38].

Η χρήση του ARIMA για την πρόβλεψη ζήτησης έχει πολλά πλεονεκτήματα, κυρίως όταν πρόκειται για δεδομένα χρονοσειρών. Το ARIMA έχει σχεδιαστεί ειδικά για να λειτουργεί με δεδομένα χρονοσειρών, γεγονός που το καθιστά ιδανική επιλογή για την πρόβλεψη της ζήτησης, η οποία συνήθως ποικίλλει με την πάροδο του χρόνου. Το τμήμα κινούμενου μέσου όρου του ARIMA ( $q$ ) βοηθά στην αποτύπωση του θορύβου και στην προσαρμογή του μοντέλου ανάλογα, μειώνοντας έτσι το σφάλμα πρόβλεψης. Αυτό είναι ιδιαίτερα χρήσιμο στην πρόβλεψη ζήτησης όπου οι τυχαίες διακυμάνσεις είναι συχνές.

Τα μοντέλα ARIMA είναι από τα πιο δημοφιλή γραμμικά μοντέλα για την πρόβλεψη χρονοσειρών, λόγω των στατιστικών ιδιοτήτων και της μεγάλης ευελιξίας του. Ωστόσο, καθώς οι παράμετροί του εκτιμώνται κατά παρτίδες, συχνά θεωρείται αυστηρά οριοθετημένο, γεγονός που περιορίζει τις εφαρμογές του και το καθιστά αναποτελεσματικό για το χειρισμό μεγάλων σε κλίμακα πραγματικών δεδομένων [37]. Το μοντέλο UCM (Unobserved Components Model) αποτελεί μια

εναλλακτική λύση στο ARIMA, παρέχοντας μια ευέλικτη και επίσημη προσέγγιση στα προβλήματα εξομάλυνσης και αποσύνθεσης [40].

### 3.2.2.2 Μοντέλο SARIMA

Ενώ το μοντέλο ARIMA είναι ένα αποτελεσματικό εργαλείο για την πρόβλεψη χρονοσειρών, αντιμετωπίζει προκλήσεις όταν ασχολείται με δεδομένα που παρουσιάζουν εποχικότητα, δηλαδή επαναλαμβανόμενα μοτίβα σε σταθερά διαστήματα. Σε αυτή την περίπτωση το SARIMA παρεμβαίνει για να βελτιώσει την ακρίβεια πρόβλεψης ζήτησης. Εάν μια χρονοσειρά είναι μονομεταβλητή και περιέχει στοιχεία τάσης ή/και εποχικά στοιχεία, τότε χρησιμοποιείται το εποχιακό μοντέλο ARIMA (Seasonal Autoregressive Integrated Moving Average - SARIMA). Δεδομένου ότι το SARIMA προσδιορίζει και λαμβάνει υπόψη την εποχικότητα, καθίσταται κατάλληλο για επιχειρήσεις με έντονες εποχιακές διακυμάνσεις στη ζήτηση. Συνεπώς, ενώ το μοντέλο ARIMA παρέχει μια βασική πρόβλεψη, το SARIMA επηρεάζει την εποχικότητα, προσφέροντας πιο ακριβείς προβλέψεις που αντιστοιχούν σε ετήσια μοτίβα. Εάν ένας εξωτερικός προγνωστικός παράγοντας, ο οποίος αναφέρεται ως εξωγενής μεταβλητή, προστεθεί στο μοντέλο SARIMA, τότε μετατρέπεται σε μοντέλο SARIMAX. Προκειμένου να χρησιμοποιηθεί μια εξωγενής μεταβλητή, απαιτείται να είναι γνωστή η τιμή της μεταβλητής και κατά την περίοδο της πρόβλεψης [41] [42].

Οι παράμετροι του SARIMA συμβολίζονται με  $(p, d, q)$  για τις μη εποχιακές συνιστώσες και με  $(P, D, Q, s)$  για τις εποχιακές συνιστώσες, και ορίζονται ως εξής:

- $p$ : αυτοπαλινδρομική σειρά ή σειρά υστέρησης,
- $d$ : βαθμός διαφοροποίησης (μη εποχικός),
- $q$ : σειρά κινητού μέσου όρου,
- $P$ : εποχική αυτοπαλινδρομική σειρά (seasonal autoregressive order),
- $D$ : εποχική σειρά διαφοράς (seasonal differencing order),
- $Q$ : εποχική σειρά κινητού μέσου όρου (seasonal moving average order) και
- $s$ : εποχική περίοδος (seasonal period).

Τα μοντέλα SARIMA συνήθως εκτιμώνται χρησιμοποιώντας μεθόδους όπως η εκτίμηση μέγιστης πιθανότητας. Οι βέλτιστες παράμετροι προσδιορίζονται συχνά με την αξιολόγηση της απόδοσης του μοντέλου χρησιμοποιώντας τεχνικές όπως η AIC (Akaike Information Criterion) ή η BIC (Bayesian Information Criterion) [43].

### 3.2.2.3 Βασικές διαφορές ARIMA - SARIMA

Στο συνεχώς εξελισσόμενο τοπίο της ανάλυσης δεδομένων, τα μοντέλα ARIMA και SARIMA παραμένουν σταθερά ως πυλώνες της προγνωστικής ανάλυσης. Καθώς ο όγκος των δεδομένων χρονοσειρών συνεχίζει να αυξάνεται, η σημασία αυτών των μοντέλων εντείνεται. Το μοντέλο ARIMA λαμβάνει υπόψη τις προηγούμενες τιμές (αυτοπαλινδρομική, κινητός μέσος όρος) και προβλέπει μελλοντικές τιμές βάσει αυτών. Το SARIMA χρησιμοποιεί παρομοίως προηγούμενες τιμές, αλλά λαμβάνει επίσης υπόψη τυχόν εποχιακά μοτίβα. Εφόσον το SARIMA εισάγει την εποχικότητα ως παράμετρο, είναι σημαντικά πιο ισχυρό από το ARIMA στην πρόβλεψη περίπλοκων χώρων δεδομένων που περιέχουν κύκλους.

Αναλυτικότερα, αναφορικά με τη θεμελιώδη δομή τους, το μοντέλο ARIMA αναλύει μια χρονοσειρά με βάση τις εξής τρεις κύριες παραμέτρους: την autoregression (AR), το differencing (I), και το moving average (MA). Η autoregression χρησιμοποιεί την αλληλεξάρτηση μεταξύ των

παρατηρήσεων, το differencing βοηθά στην κατάργηση των τάσεων ή της εποχικότητας, και το moving average μοντελοποιεί τα λάθη ως συνάρτηση των παρελθόντων λαθών. Το SARIMA, από την άλλη πλευρά, είναι μια επέκταση του ARIMA που προσθέτει επίπεδα εποχικότητας στο μοντέλο. Περιλαμβάνει τις ίδιες τρεις παραμέτρους όπως το ARIMA, αλλά προσθέτει τρεις ακόμα για την εποχικότητα: τη seasonal autoregressive order (P), τη seasonal differencing order (D) και τη seasonal moving average order (Q), καθώς και μία παράμετρο περιόδου εποχικότητας  $s$ , προκειμένου να λάβει υπόψιν τις εποχικές διακυμάνσεις στα δεδομένα. Αυτό το χαρακτηριστικό το καθιστά κατάλληλο για χρονοσειρές με εμφανή εποχικότητα.

Κατά τα διαδικασίες επιλογής μοντέλου, το ARIMA αποδεικνύεται καταλληλότερο για μη εποχικά δεδομένα ή δεδομένα όπου η εποχικότητα μπορεί να αφαιρεθεί με το differencing, ενώ το SARIMA είναι ιδανικό για δεδομένα με ξεκάθαρη και συνεπή εποχικότητα, όπου οι εποχικές μεταβολές πρέπει να προβλεφθούν. Επιπλέον, το ARIMA ενδέχεται να μην καταφέρει να πιάσει πολύπλοκες εποχικές μορφές αν δεν εφαρμοστεί κατάλληλο differencing. Από την άλλη πλευρά, το SARIMA απαιτεί περισσότερη προσοχή στην επιλογή των εποχικών παραμέτρων, επομένως μπορεί να είναι πιο πολύπλοκο στη ρύθμιση και να απαιτεί περισσότερα δεδομένα για αξιόπιστες προβλέψεις. Συμπερασματικά, ενώ το ARIMA είναι πιο βασικό και ευρέως χρησιμοποιημένο για απλούστερες χρονοσειρές, το SARIMA παρέχει επιπλέον ευελιξία και ακρίβεια για περιπτώσεις όπου η εποχικότητα διαδραματίζει σημαντικό ρόλο στα δεδομένα.

### **3.2.2.4 Μοντέλο UCM**

Η διαδικασία UCM αναλύει και προβλέπει, σε ίσες αποστάσεις, μονομεταβλητά δεδομένα χρονοσειρών, χρησιμοποιώντας τα μη παρατηρούμενα συστατικά μοντέλα. Τα μοντέλα UCM ονομάζονται επίσης δομικά μοντέλα, στη βιβλιογραφία χρονοσειρών. Ένα UCM αποσυνθέτει μια χρονική σειρά σε τάσεις, εποχιακές, κυκλικές και ιδιοσυγκρασιακές συνιστώσες και επιτρέπει εξωγενείς μεταβλητές. Τα συστατικά του μοντέλου UCM θεωρείται ότι αποτυπώνουν τα κύρια χαρακτηριστικά της σειράς, που είναι χρήσιμα για την εξήγηση και την πρόβλεψη της συμπεριφοράς του [40]. Η ανάλυση των χρονοσειρών με τη χρήση των UCM περιλαμβάνει την αναγνώριση των σημαντικών χαρακτηριστικών που υπάρχουν στη σειρά και την κατάλληλη διαμόρφωσή τους. Η διαδικασία UCM παρέχει μια ποικιλία μοντέλων, για την εκτίμηση και την πρόβλεψη των κοινά παρατηρούμενων χαρακτηριστικών σε χρονοσειρές [44]. Σε γενικές γραμμές, τα μοντέλα UCM αποτυπώνουν την ευελιξία των μοντέλων ARIMA, ενώ ταυτόχρονα διαθέτουν την ερμηνευτικότητα των μοντέλων εξομάλυνσης [45].

Όπως προαναφέρθηκε, ένα UCM αποσυνθέτει τη σειρά απόκρισης σε στοιχεία, όπως η τάση, οι εποχές, οι κύκλοι και τα εφέ παλινδρόμησης λόγω σειρών πρόβλεψης. Οι όροι  $\mu_t$ ,  $\gamma_t$  και  $\psi_t$  αντιπροσωπεύουν τα στοιχεία τάσης, τα εποχικά και τα κυκλικά, αντίστοιχα. Στην πραγματικότητα, το μοντέλο μπορεί να περιέχει πολλές εποχές και κύκλους και οι εποχές μπορεί να είναι διαφορετικών τύπων. Ελέγχοντας την παρουσία ή την απουσία διαφόρων όρων και επιλέγοντας το κατάλληλο είδος των όρων που περιλαμβάνονται, τα UCM μπορούν να δημιουργήσουν μια πλούσια ποικιλία μοτίβων χρονοσειρών. Επίσης, ένα UCM μπορεί να εφαρμοστεί σε μεταβλητές, μετά το μετασχηματισμό τους. Οι συνιστώσες  $\mu_t$ ,  $\gamma_t$  και  $\psi_t$  μοντελοποιούν δομικά διαφορετικές πτυχές της χρονοσειράς. Για παράδειγμα, η τάση μοντελοποιεί τη φυσική τάση της σειράς, απουσία άλλων ενοχλητικών επιδράσεων, όπως η εποχικότητα, οι κυκλικές συνιστώσες και οι επιδράσεις εξωγενών μεταβλητών, ενώ η εποχιακή συνιστώσα μοντελοποιεί τη διόρθωση στο επίπεδο, λόγω των εποχιακών επιδράσεων. Αυτά τα στοιχεία θεωρείται ότι είναι στατιστικά ανεξάρτητα το ένα από το άλλο και ανεξάρτητα από το ακανόνιστο στοιχείο [44].

### 3.2.2.5 Εκθετική Εξομάλυνση (Exponential Smoothing)

Η εκθετική εξομάλυνση (Exponential smoothing) ή εκθετικός κινητός μέσος όρος (Exponentially Smoothed Moving Average - EMA) είναι μια μέθοδος ποσοτικής πρόβλεψης, η οποία χρησιμοποιείται στην ανάλυση χρονοσειρών για την πρόβλεψη μελλοντικών σημείων δεδομένων. Αποτελεί μια ιδιαίτερα χρήσιμη τεχνική όταν προκύπτει ανάγκη πρόβλεψης μελλοντικών τιμών με βάση ιστορικά δεδομένα [46]. Δίνει μεγαλύτερη σημασία στα πρόσφατα δεδομένα ζήτησης, καθιστώντας το πιο ανταποκρινόμενο μοντέλο στις μεταβαλλόμενες μορφές ζήτησης. Είναι κατάλληλο για την πρόβλεψη μοτίβων ζήτησης που παρουσιάζουν σταδιακές τάσεις ή εποχιακές διακυμάνσεις [22].

Οι μέθοδοι εκθετικής εξομάλυνσης είναι ισχυρά εργαλεία για την πρόβλεψη της μελλοντικής ζήτησης και τη μείωση του κόστους αποθεμάτων, κυρίως λόγω της απλότητας και της αποτελεσματικότητάς τους στο χειρισμό δεδομένων με τάσεις και εποχικότητα [47]. Όλες οι μέθοδοι εκθετικής εξομάλυνσης βασίζονται σε υποθέσεις ότι οι χρονοσειρές δημιουργούνται από μη παρατηρούμενα στοιχεία, όπως το επίπεδο, η τάση και οι εποχιακές επιδράσεις, και αυτά τα στοιχεία πρέπει να προσαρμοστούν με την πάροδο του χρόνου για να ακολουθήσουν το πρότυπο ζήτησης [48]. Η εκθετική εξομάλυνση, ως μοντέλο για τη διενέργεια πρόβλεψης ζήτησης, εξετάζει την πραγματική ζήτηση της τρέχουσας περιόδου και την πρόβλεψη που έγινε προηγουμένως για την τρέχουσα περίοδο. Αυτές οι παρατηρήσεις σταθμίζονται εκθετικά ώστε να μειώνονται με την πάροδο του χρόνου για την πρόβλεψη της επερχόμενης περιόδου [47].

Η εκθετική εξομάλυνση μπορεί να είναι πιο αποτελεσματική όταν οι παράμετροι χρονοσειρών ποικίλουν αργά με την πάροδο του χρόνου, όταν απαιτείται συχνή επαναπρόβλεψη ή όταν οι προβλέψεις πρέπει να επιτευχθούν γρήγορα. Αναθέτοντας εκθετικά μειούμενα βάρη σε προγενέστερες παρατηρήσεις, δίνει μεγαλύτερη έμφαση στις πιο πρόσφατες πληροφορίες, οι οποίες λαμβάνουν υψηλότερα βάρη σε σύγκριση με τις παλαιότερες. Με άλλα λόγια, οι προβλέψεις που παράγονται χρησιμοποιώντας μεθόδους εκθετικής εξομάλυνσης είναι σταθμισμένοι μέσοι όροι προηγούμενων παρατηρήσεων, με τα βάρη να μειώνονται εκθετικά καθώς οι παρατηρήσεις μεγαλώνουν. Το σχετικό βάρος αυξάνεται ανάλογα με τη χρονολογία της παρατήρησης. Με βάση αυτό το πλαίσιο, μειώνεται η επίδραση τυχαίων διακυμάνσεων, δημιουργώντας αξιόπιστες προβλέψεις γρήγορα και για ένα ευρύ φάσμα χρονοσειρών, γεγονός που αποτελεί σημαντικό πλεονέκτημα για τις εφαρμογές στη βιομηχανία [49].

Επειδή απαιτούνται μόνο τρεις αριθμοί για την εκτέλεση εκθετικής εξομάλυνσης, αυτή η τεχνική είναι απλή στην ενημέρωση. Τα δεδομένα που απαιτούνται είναι η ιστορική παρατήρηση, η πιο πρόσφατη παρατήρηση δεδομένων και ο συντελεστής εκθετικής εξομάλυνσης ( $\alpha$ ). Το ( $\alpha$ ) ελέγχει το ρυθμό με τον οποίο μειώνεται εκθετικά η επιρροή των προηγούμενων παρατηρήσεων. Η παράμετρος τίθεται συχνά σε μια τιμή μεταξύ 0 και 1. Η επιλογή του συντελεστή εξομάλυνσης μπορεί να επηρεάσει σημαντικά την ακρίβεια της πρόβλεψης. Ένας υψηλότερος συντελεστής εξομάλυνσης δίνει μεγαλύτερη βαρύτητα στις πιο πρόσφατες παρατηρήσεις, έχει ως αποτέλεσμα λιγότερη εξομάλυνση και επομένως υψηλή απόκριση στις διακυμάνσεις των δεδομένων. Από την άλλη πλευρά, ένας χαμηλότερος συντελεστής εξομάλυνσης δίνει μεγαλύτερη βαρύτητα σε προηγούμενες παρατηρήσεις και έχει μεγαλύτερη εξομάλυνση. Στην ακραία περίπτωση ο συντελεστής να είναι μηδέν, τότε η πρόβλεψη της επόμενης περιόδου θα είναι ίδια με την πρόβλεψη της τελευταίας περιόδου. Εάν ο συντελεστής είναι ίσος με τη μονάδα, τότε η πρόβλεψη της επόμενης περιόδου θα είναι ίδια με τα δεδομένα της τρέχουσας περιόδου [46] [49] [50].

Ανάλογα με την πολυπλοκότητα των χρονοσειρών και τους στόχους της ανάλυσης, χρησιμοποιούνται διαφορετικές μέθοδοι εκθετικής εξομάλυνσης. Οι κύριοι τύποι είναι οι παρακάτω:

- **Απλή εκθετική εξομάλυνση (Simple exponential smoothing)**



Η πιο απλή από τις μεθόδους εκθετικής εξομάλυνσης ονομάζεται απλή εκθετική εξομάλυνση (Simple Exponential Smoothing - SES). Αυτή η μέθοδος είναι κατάλληλη για την πρόβλεψη δεδομένων χωρίς σαφή τάση ή εποχιακό μοτίβο [49]. Η απλή εκθετική εξομάλυνση εκχωρεί μεγαλύτερα βάρη σε πιο πρόσφατες παρατηρήσεις και μικρότερα βάρη σε παλαιότερες παρατηρήσεις. Τα βάρη μειώνονται εκθετικά καθώς οι παρατηρήσεις απομακρύνονται από το παρόν [51].

Η απλή εκθετική εξομάλυνση δίνεται από τον τύπο:

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

Όπου:

- $F_{t-1}$  είναι η προηγούμενη πρόβλεψη,
- $X_t$  είναι η τρέχουσα παρατήρηση και
- $(\alpha)$  είναι ο συντελεστής εξομάλυνσης [49] [52].

- **Διπλή εκθετική εξομάλυνση (Holt's linear trend method)**

Η απλή εκθετική εξομάλυνση δεν μπορεί να χειριστεί περιπτώσεις όπου υπάρχει τάση στα δεδομένα. Το 1957, ο Αμερικανός οικονομολόγος Charles C. Holt επέκτεινε την απλή εκθετική εξομάλυνση δημιουργώντας τη μέθοδο της διπλής εκθετικής εξομάλυνσης (Double exponential smoothing - DES), η οποία είναι η επαναλαμβανόμενη εφαρμογή ενός εκθετικού φίλτρου δύο φορές. Πιο συγκεκριμένα, αυτή η μέθοδος χρησιμοποιείται στην πρόβλεψη χρονοσειρών όταν τα δεδομένα έχουν γραμμική τάση, αλλά όχι εποχιακό μοτίβο και περιλαμβάνει μια εξίσωση πρόβλεψης και δύο εξισώσεις εξομάλυνσης (μία για το επίπεδο και μία για την τάση) [50] [53]. Το επίπεδο είναι μια εξομαλυνόμενη εκτίμηση της αξίας των δεδομένων στο τέλος κάθε περιόδου. Η τάση είναι μια εξομαλυνόμενη εκτίμηση της μέσης αύξησης στο τέλος κάθε περιόδου [54].

Η βασική ιδέα πίσω από τη διπλή εκθετική εξομάλυνση είναι να εισαχθεί ένας όρος για να ληφθεί υπόψη η πιθανότητα μιας σειράς να εμφανίζει κάποιες μορφής τάση. Οπότε, εκτός από το συντελεστή εξομάλυνσης ( $\alpha$ ), η διπλή εκθετική εξομάλυνση εισάγει μια παράμετρο εξομάλυνσης τάσης ( $\beta$ ). Αυτό το στοιχείο ενημερώνεται μέσω εκθετικής εξομάλυνσης και καθορίζει το βάρος που δίνεται στην πιο πρόσφατη τάση, επιτρέποντας την πρόβλεψη μεταβολών που δεν είναι σταθερές στο χρόνο [50]. Το μοντέλο μπορεί να γίνει κατανοητό ως δύο συζευγμένα μοντέλα απλής εκθετικής εξομάλυνσης. Οι βασικοί τύποι για διπλή εκθετική εξομάλυνση είναι οι εξής:

1. Εξίσωση εξομάλυνσης επιπέδου:

$$L_t = \alpha \times Y_t + (1 - \alpha) \times (L_{t-1} + T_{t-1})$$

2. Εξίσωση εξομάλυνσης τάσης:

$$T_t = \beta \times (L_t - L_{t-1}) + (1 - \beta) \times T_{t-1}$$

3. Εξίσωση πρόβλεψης:

$$F_{t+h} = L_t + h \times T_t$$

Όπου:

- $Y_t$  είναι η πραγματική τιμή της χρονοσειράς τη χρονική στιγμή  $t$ ,
- $L_t$  είναι το επίπεδο (ή η εξομαλυνόμενη τιμή) της χρονοσειράς τη χρονική στιγμή  $t$ ,

- $T_t$  είναι η τάση (ή η συνιστώσα τάσης) της χρονοσειράς τη δεδομένη στιγμή  $t$ ,
- $(\alpha)$  είναι ο συντελεστής εξομάλυνσης ( $0 < \alpha < 1$ ),
- $(\beta)$  είναι η παράμετρος εξομάλυνσης τάσης ( $0 < \beta < 1$ ) και
- $F_{t+h}$  είναι η πρόβλεψη για τη χρονική περίοδο  $t+h$  (όπου  $h$  ο ορίζοντας πρόβλεψης) [49] [52].

- **Τριπλή εκθετική εξομάλυνση (Holt-Winters method)**

Η διπλή εκθετική εξομάλυνση, όπως και η απλή εκθετική εξομάλυνση, ενδέχεται να μην έχει καλή απόδοση για δεδομένα με πολύπλοκα μοτίβα, όπως η εποχικότητα. Για τέτοιες περιπτώσεις, χρησιμοποιούνται συνήθως πιο προηγμένες μέθοδοι, όπως η μέθοδος τριπλής εκθετικής εξομάλυνσης (Triple exponential smoothing – TES) ή μέθοδος Holt-Winters, από τους δημιουργούς της Charles C. Holt και Peter Winters. Η τριπλή εκθετική εξομάλυνση είναι η πιο προηγμένη παραλλαγή της εκθετικής εξομάλυνσης και χρησιμοποιείται για την πρόβλεψη χρονοσειρών όταν τα δεδομένα έχουν γραμμικές τάσεις και εποχικά μοτίβα. Η τεχνική εφαρμόζει εκθετική εξομάλυνση τρεις φορές: εξομάλυνση επιπέδου, εξομάλυνση τάσης και εποχιακή εξομάλυνση [50] [55].

Υπάρχουν δύο παραλλαγές αυτής της μεθόδου που διαφέρουν ως προς τη φύση του εποχιακού στοιχείου. Η προσθετική μέθοδος προτιμάται όταν οι εποχιακές διακυμάνσεις είναι σχεδόν σταθερές σε όλη τη σειρά, ενώ η μέθοδος πολλαπλασιασμού προτιμάται όταν οι εποχιακές διακυμάνσεις αλλάζουν ανάλογα με το επίπεδο της σειράς. Με την προσθετική μέθοδο, η εποχιακή συνιστώσα εκφράζεται σε απόλυτες τιμές στην κλίμακα της παρατηρούμενης σειράς και στην εξίσωση επιπέδου η σειρά προσαρμόζεται εποχιακά, αφαιρώντας την εποχιακή συνιστώσα. Μέσα σε κάθε χρόνο, η εποχιακή συνιστώσα θα αθροίζεται περίπου στο μηδέν. Με την πολλαπλασιαστική μέθοδο, η εποχιακή συνιστώσα εκφράζεται σε σχετικούς όρους (ποσοστά) και η σειρά προσαρμόζεται εποχιακά με διαίρεση με την εποχιακή συνιστώσα. Μια νέα παράμετρος εξομάλυνσης που ονομάζεται ( $\gamma$ ) προστίθεται για τον έλεγχο της επίδρασης της εποχιακής συνιστώσας [53]. Οι βασικοί τύποι για την τριπλή εκθετική εξομάλυνση είναι οι εξής:

1. Εξίσωση εξομάλυνσης επιπέδου:

$$L_t = \alpha \times \frac{Y_t}{S_{t-m}} + (1 - \alpha) \times (L_{t-1} + T_{t-1})$$

2. Εξίσωση εξομάλυνσης τάσης:

$$T_t = \beta \times (L_t - L_{t-1}) + (1 - \beta) \times T_{t-1}$$

3. Εποχιακή εξίσωση εξομάλυνσης:

$$S_t = \gamma \times \frac{L_t}{Y_t} + (1 - \gamma) \times S_{t-m}$$

4. Εξίσωση πρόβλεψης:

$$F_{t+h} = (L_t + h \times T_t) \times S_{t-m+h}$$

Όπου:

- $Y_t$  είναι η πραγματική τιμή της χρονοσειράς τη χρονική στιγμή  $t$ ,
- $L_t$  είναι το επίπεδο (ή η εξομαλυνόμενη τιμή) της χρονοσειράς τη χρονική στιγμή  $t$ ,
- $T_t$  είναι η τάση (ή η συνιστώσα τάσης) της χρονοσειράς τη δεδομένη στιγμή  $t$ ,

- $S_t$  είναι το εποχιακό στοιχείο της χρονοσειράς τη χρονική στιγμή  $t$
- Τα  $(\alpha)$ ,  $(\beta)$  και  $(\gamma)$  είναι παράμετροι εξομάλυνσης για το επίπεδο, την τάση και την εποχικότητα, αντίστοιχα,
- $m$  είναι ο αριθμός των περιόδων σε μια εποχή και
- $F_{t+h}$  είναι η πρόβλεψη για τη χρονική περίοδο  $t+h$  (όπου  $h$  ο ορίζοντας πρόβλεψης) [49] [52].

Η επιλογή του τύπου της μεθόδου εκθετικής εξομάλυνσης που θα χρησιμοποιηθεί εξαρτάται από τα χαρακτηριστικά των δεδομένων χρονοσειρών και τις συγκεκριμένες απαιτήσεις πρόβλεψης. Είναι σημαντικό να σημειωθεί ότι η επιλογή του τύπου της μεθόδου εκθετικής εξομάλυνσης μπορεί επίσης να εξαρτάται από τις συγκεκριμένες απαιτήσεις πρόβλεψης, όπως ο επιθυμητός ορίζοντας πρόβλεψης, το επίπεδο ακρίβειας που απαιτείται και η διαθεσιμότητα ιστορικών δεδομένων [52]. Οι κλασικές προσθετικές και πολλαπλασιαστικές μέθοδοι Holt-Winters μπορεί να γίνουν αναξιόπιστες εάν ο θόρυβος κυριαρχεί στην τάση και στα εποχιακά στοιχεία των δεδομένων [56]. Οι εξισώσεις εξομάλυνσης επιτρέπουν στον όρο θορύβου από μία χρονική περίοδο να επηρεάσει τις εξομαλυνόμενες σειρές και τις προβλέψεις της μελλοντικής ζήτησης. Οι πολλαπλασιαστικές μέθοδοι δεν είναι επίσης κατάλληλες για χρονοσειρές ζήτησης με μηδενικές εγγραφές [47].

### 3.2.2.6 Αυτοσυσχέτιση (ACF)

Η αυτοσυσχέτιση (Autocorrelation Function - ACF) αποτελεί ένα σημαντικό εργαλείο στην ανάλυση και την πρόβλεψη χρονοσειρών, το οποίο βοηθά στην κατανόηση της συσχέτισης μεταξύ των παρατηρήσεων σε μια χρονοσειρά, σε διαφορετικές χρονικές υστερήσεις. Η ACF χρησιμοποιείται επίσης για να εντοπίσει την επαναλαμβανόμενη δομή, όπως η εποχικότητα ή οι τάσεις, στα δεδομένα. Ουσιαστικά, η συνάρτηση αυτοσυσχέτισης περιγράφει τη συσχέτιση μεταξύ των παρατηρήσεων μιας χρονοσειράς σε δύο χρονικά σημεία, που χωρίζονται από μια συγκεκριμένη καθυστέρηση  $k$  και ποσοτικοποιεί τον τρόπο με τον οποίο μια τιμή στη χρονοσειρά σχετίζεται με τις προηγούμενες τιμές της [57] [58]. Η αυτοσυσχέτιση υποδηλώνει ότι οι παρατηρήσεις σε διαφορετικά χρονικά σημεία εξαρτώνται η μία από την άλλη, γεγονός που μπορεί να υποδεικνύει υποκείμενα μοτίβα στα δεδομένα. Ο συντελεστής συσχέτισης εξετάζει πόσο στενά συνδέονται δύο μεταβλητές. Μπορεί να κυμαίνεται από  $-1$  έως  $+1$ . Ένας συντελεστής συσχέτισης  $-1$  υποδεικνύει μια τέλεια αρνητική σχέση, ενώ ένας συντελεστής συσχέτισης  $+1$  δείχνει μια τέλεια θετική σχέση. Ένας συντελεστής συσχέτισης  $0$  υποδεικνύει μηδενική σχέση μεταξύ των δύο μεταβλητών [49] [59].

Η αυτοσυσχέτιση για κάθε καθυστέρηση  $k$  υπολογίζεται από τον τύπο:

$$R_{(k)} = \frac{\sum_{t=1}^{N-k} (Y_t - \bar{Y})(Y_{t+k} - \bar{Y})}{\sum_{t=1}^N (Y_t - \bar{Y})^2}$$

Όπου:

- $R_k$  είναι η αυτοσυσχέτιση στην καθυστέρηση  $k$ ,
- $N$  είναι το συνολικό πλήθος των καθυστερήσεων,
- $Y_t$  είναι η τιμή της χρονοσειράς στο χρόνο  $t$  και
- $\bar{Y}$  είναι ο μέσος όρος των τιμών της χρονοσειράς [49].

Η γραφική παράσταση ACF είναι μια γραφική αναπαράσταση του συσχετισμού μιας χρονοσειράς με τον εαυτό της σε διαφορετικές καθυστερήσεις, μέχρι έναν καθορισμένο αριθμό καθυστερήσεων. Τα διαγράμματα ACF μπορούν να βοηθήσουν στον προσδιορισμό του αυτοπαλινδρομικού (Autoregressive - AR) και του κινητού μέσου όρου (Moving Average - MA) για

τα μοντέλα αυτοπαλινδρομικού κινητού μέσου (ARMA) και αυτοπαλινδρομικού ολοκληρωμένου κινητού μέσου (ARIMA). Ο αριθμός των σημαντικών καθυστερήσεων στη γραφική παράσταση ACF μπορεί να υποδηλώνει τη σειρά της αυτοπαλινδρομικής συνιστώσας (p), ενώ το σχέδιο αποσύνθεσης μπορεί να υποδεικνύει τη σειρά της συνιστώσας κινητού μέσου όρου (q) [58] [60].

Η ACF χρησιμοποιείται συχνότερα για την ανάλυση ακολουθιών αριθμών από τυχαίες διαδικασίες, όπως οικονομικές ή επιστημονικές μετρήσεις. Μπορεί επίσης να χρησιμοποιηθεί για τον εντοπισμό συστηματικών μοτίβων σε συσχετισμένα σύνολα δεδομένων, όπως οι κλιματικές μετρήσεις. Μετά την προσαρμογή ενός μοντέλου, οι γραφικές παραστάσεις ACF των σφαλμάτων πρόβλεψης μπορούν να χρησιμοποιηθούν για να εκτιμηθεί η παρουσία τυχόν υπολειπόμενης αυτοσυσχέτισης στα σφάλματα πρόβλεψης. Οι χρονοσειρές που δεν εμφανίζουν αυτοσυσχέτιση ονομάζονται λευκός θόρυβος. Μέσω του διαγνωστικού ελέγχου του μοντέλου, εξετάζεται αν έχει αφαιρεθεί επαρκώς η πληροφορία από τα δεδομένα, δηλαδή αν τα υπόλοιπα φαίνονται ως λευκός θόρυβος. Αυτή η αξιολόγηση είναι κρίσιμη ώστε να διασφαλιστεί ότι το μοντέλο πρόβλεψης αποτυπώνει επαρκώς τη δυναμική της χρονοσειράς. Συνήθως, ο υπολογισμός της ACF γίνεται χρησιμοποιώντας στατιστικά πακέτα από Python και R ή κάποιο λογισμικό, όπως το Excel και το SPSS [49] [60].

Ενώ η αυτοσυσχέτιση μετρά και σχεδιάζει τη μέση συσχέτιση μεταξύ σημείων δεδομένων σε χρονοσειρές και προηγούμενων τιμών της σειράς που μετρήθηκαν για διαφορετικά μήκη καθυστέρησης, δε λαμβάνει υπόψιν την επιρροή άλλων ενδιάμεσων παρατηρήσεων. Η μερική αυτοσυσχέτιση (Partial Autocorrelation Function - PACF) διορθώνει αυτή την παράλειψη, μετρώντας τη συσχέτιση μεταξύ δύο σημείων και ελέγχοντας τις τιμές σε όλες τις μικρότερες καθυστερήσεις [58].

### 3.2.2.7 Μερική αυτοσυσχέτιση (PACF)

Η μερική αυτοσυσχέτιση είναι ένα στατιστικό εργαλείο που χρησιμοποιείται στην ανάλυση χρονοσειρών, συχνά σε συνδυασμό με την ACF, βοηθώντας στην επιλογή μοντέλου, στην εκτίμηση παραμέτρων και στην πρόβλεψη. Η PACF είναι μια γραφική αναπαράσταση του συσχετισμού μιας χρονοσειράς με τον εαυτό της σε διαφορετικές καθυστερήσεις, αφού αφαιρεθούν τα αποτελέσματα των ενδιάμεσων καθυστερήσεων. Συνεπώς, σε αντίθεση με την ACF, εστιάζει μόνο στην άμεση συσχέτιση σε κάθε καθυστέρηση, εξαλείφοντας την επίδραση των ενδιάμεσων καθυστερήσεων. Αυτό σημαίνει ότι η PACF δίνει πληροφορίες για την άμεση επιρροή των προηγούμενων παρατηρήσεων στην τρέχουσα παρατήρηση. Αναλύοντας το διάγραμμα PACF, οι αναλυτές μπορούν να προσδιορίσουν τις τιμές με καθυστέρηση που έχουν τον πιο σημαντικό αντίκτυπο στην τρέχουσα παρατήρηση, επιτρέποντας πιο ακριβή μοντέλα πρόβλεψης [58] [60].

Η PACF είναι, ουσιαστικά, ο συντελεστής αυτοπαλινδρόμησης που προκύπτει όταν οι επιδράσεις από όλες τις ενδιάμεσες καθυστερήσεις αφαιρεθούν. Η PACF στην καθυστέρηση  $k$  (lag  $k$ ) υπολογίζεται ως η συσχέτιση μεταξύ της τρέχουσας παρατήρησης και της παρατήρησης στην καθυστέρηση  $k$ , αφού αφαιρεθούν οι συνεισφορές των καθυστερήσεων 1 έως  $k-1$ . Με μαθηματική εξίσωση αυτό μπορεί να αναπαρασταθεί ως:

$$PACF(k) = \text{Correlation}(\text{Time series at lag } 0, \text{Time series at lag } k \\ | \text{Lags } 1, 2, \dots, k - 1)$$

Αυτός ο υπολογισμός περιλαμβάνει την προσαρμογή ενός μοντέλου παλινδρόμησης της τρέχουσας παρατήρησης στις τιμές με καθυστέρηση μέχρι την καθυστέρηση  $k$ . Στη συνέχεια, η PACF υπολογίζεται από τους συντελεστές αυτού του μοντέλου παλινδρόμησης. Για παράδειγμα, η PACF στην καθυστέρηση 3 μετρά την άμεση σχέση μεταξύ των παρατηρήσεων που είναι διαχωρισμένες κατά τρεις περιόδους, ελέγχοντας και αφαιρώντας τις επιρροές των παρατηρήσεων στις πρώτες δύο καθυστερήσεις [58] [61].

Τα διαγράμματα PACF χρησιμοποιούνται για τον εντοπισμό προτύπων στη δομή αυτοσυσχέτισης μιας χρονοσειράς. Οι έντονες αποκοπές ή οι σημαντικές αιχμές στο διάγραμμα PACF υποδηλώνουν ότι αυτές οι συγκεκριμένες καθυστερήσεις έχουν άμεση επίδραση στην τρέχουσα παρατήρηση. Στο πλαίσιο της μοντελοποίησης ARIMA, η PACF διαδραματίζει σημαντικό ρόλο στον προσδιορισμό της σειράς του αυτοπαλινδρομικού στοιχείου (AR) του μοντέλου. Η γραφική παράσταση PACF εξετάζεται για να προσδιοριστεί ο αριθμός των καθυστερήσεων όπου η συσχέτιση είναι σημαντική, βοηθώντας στον προσδιορισμό της κατάλληλης σειράς της συνιστώσας AR. Επίσης, μπορεί να βοηθήσει στην επικύρωση υποθέσεων σχετικά με τη δομή αυτοσυσχέτισης μιας χρονοσειράς. Για παράδειγμα, εάν η προηγούμενη γνώση ή θεωρία προτείνει μια συγκεκριμένη δομή AR, η εξέταση της γραφικής παράστασης PACF μπορεί να επιβεβαιώσει εάν τα παρατηρούμενα δεδομένα ευθυγραμμίζονται με αυτές τις υποθέσεις [57] [60].

### 3.2.3 Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (MAPE)

MAPE, ή Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (Mean Absolute Percentage Error), ονομάζεται η μέτρηση που χρησιμοποιείται συνήθως στην πρόβλεψη, με σκοπό την αξιολόγηση της ακρίβειας ενός μοντέλου πρόβλεψης. Μετρά τη μέση απόλυτη ποσοστιαία διαφορά μεταξύ των προβλεπόμενων τιμών και των πραγματικών τιμών, δηλαδή το μέσο μέγεθος του σφάλματος που παράγεται από ένα μοντέλο ή πόσο μακριά είναι κατά μέσο όρο οι προβλέψεις, παρέχοντας μια εύκολα κατανοητή ένδειξη του μέσου σφάλματος ως ποσοστό. Μια τιμή MAPE 20% σημαίνει ότι η μέση απόλυτη ποσοστιαία διαφορά μεταξύ των προβλέψεων και των πραγματικών τιμών είναι 20%. Με άλλα λόγια, οι προβλέψεις του μοντέλου είναι, κατά μέσο όρο, μειωμένες κατά 20% από τις πραγματικές τιμές. Ένα MAPE 20% μπορεί να θεωρηθεί καλό ή κακό ανάλογα με την κατάσταση, το βαθμό μεταβλητότητας των δεδομένων, το εύρος των πραγματικών τιμών ή το επιθυμητό επίπεδο ακρίβειας [60] [61].

Το MAPE ορίζεται ως το άθροισμα των μεμονωμένων απόλυτων σφαλμάτων διαιρούμενο με τη ζήτηση, για προβλέψεις που γίνονται για περιόδους 1 έως n μιας μεμονωμένης σειράς, ξεχωριστά για κάθε περίοδο. Δίνεται από τον παρακάτω τύπο:

$$MAPE = \left( \frac{1}{n} \sum_{i=1}^n \left| \frac{A_i - F_i}{A_i} \right| \right) \times 100\%$$

Όπου:

$A_i$  είναι η πραγματική τιμή για την περίοδο  $i$ ,

$F_i$  είναι η προβλεπόμενη τιμή για την περίοδο  $i$  και

$n$  είναι το συνολικό πλήθος των περιόδων.

Για τον υπολογισμό του Μέσου Απόλυτου Ποσοστιαίου Σφάλματος, υπολογίζεται πρώτα η απόλυτη τιμή όλων των σφαλμάτων. Η χρήση της απόλυτης τιμής των σφαλμάτων εξασφαλίζει ότι δε θα αλληλοεξουδετερωθούν τα θετικά και τα αρνητικά σφάλματα. Για παράδειγμα, εάν το μοντέλο υπερβεί ένα σημείο δεδομένων κατά +10 και υποβιβάσει ένα άλλο κατά -10, αυτά τα σφάλματα θα ακυρώνονταν μεταξύ τους επειδή  $(-10) + 10 = 0$ . Λαμβάνοντας όμως την απόλυτη τιμή των σφαλμάτων αποφεύγεται αυτό το πρόβλημα, επειδή  $|10| + |-10| = 20$ . Στη συνέχεια, η τιμή που προκύπτει διαιρείται με το αρχικό σημείο δεδομένων και πολλαπλασιάζεται με το 100 για να οριστεί πόσο μακριά είναι το μοντέλο ως ποσοστό. Τέλος, προθέτονται όλα αυτά τα ποσοστά και το αποτέλεσμα διαιρείται με το συνολικό αριθμό των σημείων δεδομένων για να προκύψει το μέσο απόλυτο ποσοστό σφάλματος. Μια χαμηλότερη τιμή MAPE υποδεικνύει μια πιο ακριβή πρόβλεψη, ένα MAPE 0% σημαίνει ότι η πρόβλεψη είναι ίδια με την πραγματική, ενώ μια υψηλότερη τιμή MAPE υποδεικνύει μια λιγότερο ακριβή πρόβλεψη [61].

Στην περίπτωση της διενέργειας προβλέψεων ζήτησης, το MAPE είναι ένα μέτρο της μέσης απόκλισης της προβλεπόμενης ζήτησης από την πραγματική ζήτηση, εκφραζόμενη ως ποσοστό. Υπολογίζεται διαιρώντας το άθροισμα των απόλυτων σφαλμάτων με το άθροισμα της πραγματικής ζήτησης, πολλαπλασιάζοντας στη συνέχεια με το 100. Το MAPE είναι μια απλή και διαισθητική μέτρηση που βοηθά στην αξιολόγηση της απόδοσης του σχεδιασμού της ζήτησης. Εντοπίζει πόσο κοντά είναι οι προβλέψεις στην πραγματική ζήτηση, κατά μέσο όρο. Ένα χαμηλότερο MAPE σημαίνει μεγαλύτερη ακρίβεια και ένα υψηλότερο MAPE σημαίνει χαμηλότερη ακρίβεια. Το MAPE μπορεί επίσης να βοηθήσει στον εντοπισμό των πηγών σφαλμάτων στη διαδικασία σχεδιασμού της ζήτησης, όπως η ποιότητα των δεδομένων, η εποχικότητα, οι ακραίες τιμές ή η μεροληψία. Αναλύοντας το MAPE για διαφορετικά προϊόντα, κατηγορίες ή περιοχές, μπορούν να εντοπιστούν οι περιοχές που χρειάζονται περισσότερη προσοχή ή βελτίωση. Ωστόσο, καθώς το MAPE είναι μια σχετική μέτρηση, εξαρτάται από την κλίμακα και τη μεταβλητότητα της πραγματικής ζήτησης. Για παράδειγμα, ένα MAPE 10% για ένα προϊόν με υψηλή και σταθερή ζήτηση μπορεί να είναι αποδεκτό, αλλά ένα MAPE 10% για ένα προϊόν με χαμηλή και ασταθή ζήτηση μπορεί να είναι απαράδεκτο. Επομένως, δεν πρέπει να χρησιμοποιείται ως απόλυτο πρότυπο, αλλά ως σημείο αναφοράς που μπορεί να ποικίλλει ανάλογα με το πλαίσιο και τους στόχους του σχεδιασμού της ζήτησης. Θα πρέπει επίσης να λαμβάνονται υπόψη άλλοι παράγοντες που μπορεί να επηρεάσουν το MAPE, όπως ο ορίζοντας πρόβλεψης, το επίπεδο συγκέντρωσης ή η συχνότητα των ενημερώσεων [62].

Σε γενικότερο πλαίσιο, όταν η απόδοση των μεθόδων πρόβλεψης πρέπει να συγκριθεί μεταξύ διαφορετικών χρονοσειρών, τα μέτρα ακρίβειας, όπως το Μέσο Τετραγωνικό Σφάλμα (Mean Squared Error - MSE) και το Μέσο Απόλυτο Σφάλμα (Mean Absolute Error - MAE), είναι ακατάλληλα. Αυτό συμβαίνει επειδή συχνά μπορεί να υπάρχουν μεγάλες διακυμάνσεις στην κλίμακα των παρατηρήσεων μεταξύ των σειρών, με αποτέλεσμα ορισμένες σειρές με μεγάλες τιμές να κυριαρχούν στις συγκρίσεις. Σε αυτές τις περιπτώσεις, πρέπει να χρησιμοποιηθούν μέτρα χωρίς μονάδα και το MAPE είναι ίσως το πιο ευρέως χρησιμοποιούμενο μέτρο αυτού του είδους, λόγω της πολύ διαισθητικής ερμηνείας του ως προς το σχετικό σφάλμα [62]. Πιο συγκεκριμένα, το MAPE είναι ιδανικό σε περιπτώσεις όπου υπάρχουν ελάχιστα έως καθόλου: ακραίες τιμές, τιμές κοντά στο μηδέν και χαμηλός όγκος ή αραιά σύνολα δεδομένων [51]. Συνεπώς, αποτελεί ένα χρήσιμο εργαλείο για τη σύγκριση της απόδοσης διαφορετικών μοντέλων ή μεθόδων πρόβλεψης σε διάφορους τομείς, όπως η οικονομία, η μετεωρολογία και η εφοδιαστική, προωθώντας την εύκολη επικοινωνία των αποτελεσμάτων [48]. Για παράδειγμα, η χρήση του MAPE είναι συχνή στα χρηματοοικονομικά, καθώς τα κέρδη και οι ζημιές συχνά μετριοούνται σε σχετικές αξίες. Είναι επίσης χρήσιμο να βαθμονομούνται οι τιμές των προϊόντων, καθώς οι πελάτες είναι μερικές φορές πιο ευαίσθητοι στις σχετικές παρά στις απόλυτες διακυμάνσεις. Σε εφαρμογές πραγματικού κόσμου, το MAPE χρησιμοποιείται συχνά όταν η ποσότητα προς πρόβλεψη είναι γνωστό ότι παραμένει πολύ πάνω από το μηδέν. Γενικότερα, έχει υποστηριχθεί ότι το MAPE διαθέτει προσαρμοστικότητα σε εφαρμογές πρόβλεψης, ειδικά σε καταστάσεις όπου υπάρχουν αρκετά διαθέσιμα δεδομένα [61].

Παρά την ευρεία χρήση του, το MAPE έχει αρκετά μειονεκτήματα. Ειδικότερα, έχει διατυπωθεί η άποψη ότι τείνει να διογκώνει τη σημασία των μικρών σφαλμάτων, ειδικά όταν οι πραγματικές τιμές είναι κοντά στο μηδέν ή όταν υπάρχει ένα ευρύ φάσμα πραγματικών τιμών. Για παράδειγμα, ένα μικρό απόλυτο σφάλμα σε σχέση με μια πολύ μικρή πραγματική τιμή μπορεί να οδηγήσει σε μεγάλο ποσοστό σφάλματος, ακόμα κι αν το σφάλμα είναι αμελητέο από πρακτική άποψη. Το MAPE δεν μπορεί να χειριστεί μηδενικές τιμές στα πραγματικά δεδομένα επειδή η διαίρεση με το μηδέν δεν έχει οριστεί. Εάν η πραγματική τιμή είναι μηδέν, το MAPE μπορεί να γίνει απείρως μεγάλο ή ακαθόριστο. Σε τέτοιες περιπτώσεις, εναλλακτικές μετρήσεις όπως το Μέσο Απόλυτο Σφάλμα Κλίμακας (Mean Absolute Scaled Error - MASE) θεωρούνται πιο κατάλληλες. Επιπλέον, το MAPE οριοθετείται στο χαμηλό όριο με σφάλμα 100%, αλλά δεν έχει άνω όριο, γεγονός που σημαίνει ότι μπορεί θεωρητικά να λάβει οποιαδήποτε θετική τιμή. Αυτή η έλλειψη άνω ορίου μπορεί να δυσκολέψει την ερμηνεία των τιμών MAPE, ειδικά κατά τη σύγκριση της απόδοσης σε διαφορετικά σύνολα δεδομένων ή μοντέλα. Καθώς το MAPE είναι ασύμμετρο, δεν υπάρχει διάκριση μεταξύ υπερεκτίμησης

και υποεκτίμησης και οι δύο περιπτώσεις αντιμετωπίζονται με τον ίδιο τρόπο, δεδομένου ότι τα απόλυτα σφάλματα δε δείχνουν τη διεύθυνση του σφάλματος [63] [64] [65]. Ένα επιπλέον μειονέκτημα είναι το γεγονός πως το MAPE είναι ευαίσθητο σε ακραίες τιμές, ιδιαίτερα σε μεγάλα σφάλματα, επειδή περιλαμβάνει τη λήψη του απόλυτου ποσοστού σφάλματος. Ένα μόνο ακραίο στοιχείο μπορεί να επηρεάσει δυσανάλογα την τιμή MAPE, οδηγώντας σε παραπλανητικές ερμηνείες [66].

Συμπερασματικά, το MAPE παραμένει ένα χρήσιμο και ευρέως χρησιμοποιούμενο εργαλείο μέτρησης για την αξιολόγηση της απόδοσης των προβλέψεων, λόγω της απλότητας και της ευκολίας ερμηνείας του. Ωστόσο, οι αναλυτές οφείλουν να είναι επιφυλακτικοί σχετικά με τον περιοριστικό του χαρακτήρα αναφορικά με τις περιπτώσεις χρήσης και να εξετάσουν τη χρήση συμπληρωματικών μετρήσεων, όπου κρίνεται κατάλληλο.

### ***3.3 Ποιοτική Πρόβλεψη Ζήτησης (Qualitative Demand Forecasting)***

Η ποιοτική πρόβλεψη είναι η πράξη πρόβλεψης της επιχειρηματικής δραστηριότητας και της συμπεριφοράς των καταναλωτών, χρησιμοποιώντας συναισθήματα, ιδέες και κρίσεις, αντί για αριθμούς. Αυτές οι απόψεις μπορεί να προέρχονται από ειδικούς του κλάδου, στελέχη, μέλη του προσωπικού ή καταναλωτές [63]. Σε αντίθεση με την ποσοτική, η ποιοτική πρόβλεψη χρησιμοποιεί μη δομημένα δεδομένα. Αυτό συμβαίνει επειδή βασίζεται σε συνεντεύξεις, έρευνες και παρατηρήσεις. Τα ποιοτικά μοντέλα πρόβλεψης είναι χρήσιμα για την ανάπτυξη προβλέψεων με περιορισμένο εύρος. Βασίζονται σε μεγάλο βαθμό στις γνώμες των ειδικών και είναι πιο ωφέλιμα βραχυπρόθεσμα. Η ποιοτική έρευνα χρησιμοποιείται συχνά για τη διερεύνηση νέων ιδεών, την ανάπτυξη υποθέσεων και τη δημιουργία γνώσεων που μπορούν να βοηθήσουν στην ποσοτική έρευνα.

Η ποιοτική πρόβλεψη είναι πιο χρήσιμη σε καταστάσεις όπου υπάρχει η υποψία ότι τα μελλοντικά αποτελέσματα θα αποκλίνουν σημαντικά από τα αποτελέσματα προηγούμενων περιόδων και τα οποία, συνεπώς, δεν μπορούν να προβλεφθούν με ποσοτικά μέσα. Για παράδειγμα, η ιστορική τάση των πωλήσεων μπορεί να υποδηλώνει ότι οι πωλήσεις θα αυξηθούν ξανά το επόμενο έτος, κάτι που κανονικά μετράται χρησιμοποιώντας ανάλυση γραμμής τάσης. Ωστόσο, ένας εμπειρογνώμονας του κλάδου επισημαίνει ότι θα υπάρξει έλλειψη υλικών σε ένα βασικό προμηθευτή που θα οδηγήσει σε πτώση των πωλήσεων. Άλλες περιπτώσεις, στις οποίες η ποιοτική πρόβλεψη μπορεί να είναι χρήσιμη, είναι στην αφομοίωση μεγάλων ποσοτήτων, στενά εστιασμένων, τοπικών δεδομένων, για τη διάκριση των τάσεων και στην περίπτωση που μια πορεία δράσης πρέπει να προέρχεται από ανεπαρκή δεδομένα. Τότε, μια ποιοτική ανάλυση θα επιδιώξει να συνδέσει ανόμοια δεδομένα για να δημιουργήσει μια πιο ευρεία άποψη, κάποιες φορές ενσωματώνοντας τη διαίσθηση για την κατασκευή αυτής της άποψης. Επίσης, η ποιοτική πρόβλεψη μπορεί να προσφέρει αξία όταν η διοίκηση τροποποιεί ιστορικά προερχόμενες τάσεις, με βάση τις απόψεις των ειδικών. Σε αυτή την περίπτωση, χρησιμοποιούνται ποσοτικές μέθοδοι για τη δημιουργία μιας προκαταρκτικής πρόβλεψης, η οποία στη συνέχεια προσαρμόζεται με ποιοτική ανασκόπηση. Θεωρητικά, το αποτέλεσμα θα πρέπει να είναι μια πρόβλεψη που προέρχεται από την καλύτερη και των δύο μεθόδων [33] [64].

#### **3.3.1 Μέθοδοι Ποιοτική Πρόβλεψη Ζήτησης**

Δεν είναι πάντα δυνατό να ληφθούν ιστορικά δεδομένα για την πρόβλεψη της ζήτησης. Αυτό συμβαίνει όταν οι συνθήκες αλλάζουν ή όταν παρατηρείται έλλειψή τους, όπως στην περίπτωση νέων προϊόντων. Τα ιστορικά δεδομένα ζήτησης για προϊόντα που βρίσκονται σε παραγωγή τη δεδομένη χρονική περίοδο ενδέχεται να μην παρέχουν αξιόπιστη βάση για πρόβλεψη, λόγω πιθανών αλλαγών στο μέγεθος

του διαφημιστικού προϋπολογισμού, του κόστους των εναλλακτικών λύσεων, όπως των ανταγωνιστικών προϊόντων ή των υποκατάστατων, ή των αλλαγών στη συνολική κατάσταση της οικονομίας, όπως, για παράδειγμα, περιορισμών κίνησης κεφαλαίων. Επομένως, όταν τα δεδομένα είναι ανεπαρκή και δεν επιτρέπουν τη χρήση ποσοτικής μεθόδου, η απόφαση για χρήση ποιοτικής μεθόδου αποτελεί τη μοναδική επιλογή [29] [30].

Γενικά, όλες οι τεχνικές του qualitative forecasting υποθέτουν την υποκείμενη σχέση στο παρελθόν και προβλέπουν τη σχέση για το μέλλον. Οι περισσότερες τεχνικές βασίζονται σε κάποια προηγούμενα δεδομένα, απόψεις, έρευνες κ.λπ.. Παραδείγματα μοντέλων ποιοτικής πρόβλεψης περιλαμβάνουν συνεντεύξεις, επιτόπιες επισκέψεις, έρευνα αγοράς, δημοσκοπήσεις και έρευνες που εφαρμόζουν τη μέθοδο Delphi, η οποία βασίζεται σε συγκεντρωτικές γνώμες ειδικών. Πιο αναλυτικά, μερικές δημοφιλείς μέθοδοι ποιοτικής πρόβλεψης είναι:

- **Panel approach**

Αφορά μια ομάδα ειδικών ή υπαλλήλων από όλη την επιχείρηση, όπως στελέχη πωλήσεων και μάρκετινγκ, που συγκεντρώνονται και λειτουργούν ως ομάδα εστίασης, εξετάζοντας δεδομένα και κάνοντας συστάσεις. Αν και το αποτέλεσμα είναι πιθανό να είναι πιο ισορροπημένο από τη γνώμη ενός μόνο ατόμου, ακόμη και οι ειδικοί μπορεί να καταλήξουν σε λανθασμένα συμπεράσματα.

- **Delphi approach**

Περιλαμβάνει τη δημιουργία ενός ερωτηματολογίου και την αποστολή του σε σχετικούς ειδικούς, όπως πελάτες και προμηθευτές, οι οποίοι το συμπληρώνουν. Τα αποτελέσματα αναλύονται και επιστρέφονται, ανώνυμα, στους συμμετέχοντες. Αυτοί μπορούν να επανεξετάσουν τις αρχικές απαντήσεις τους, υπό το φως άλλων οπτικών και απόψεων, έως ότου επιτευχθεί τελική συναίνεση. Αυτή η πιο επίσημη προσέγγιση συμβάλλει στη μείωση των επιρροών από τις προσωπικές συναντήσεις, αλλά θα μπορούσε να περιλαμβάνει εγγενή προκατάληψη από τους ειδικούς που έχουν επιλεγεί [29][36].

- **Jury of executives**

Οι απόψεις των ειδικών από διαφορετικά τμήματα λαμβάνονται υπόψη και υπολογίζονται κατά μέσο όρο, για την πρόβλεψη μελλοντικών πωλήσεων. Σε πρώτη φάση, οι ειδικοί σχηματίζουν τις προσωπικές τους απόψεις, σύμφωνα με τα αρχικά δεδομένα που δίνονται, τις οποίες αναθεωρούν στη συνέχεια, σύμφωνα με τις απόψεις των άλλων. Αυτή η μέθοδος πρόβλεψης μπορεί να υλοποιηθεί εύκολα και γρήγορα, χωρίς την ανάγκη περίτεχνων στατιστικών. Το κύριο μειονέκτημά της είναι ότι εξαρτάται από μεμονωμένες απόψεις, οι οποίες μπορεί να μην είναι ομόφωνες, αλλά να διαφέρουν από άτομο σε άτομο, γεγονός που θα μπορούσε να οδηγήσει σε λανθασμένες προβλέψεις.

- **Consumer surveys**

Η έρευνα αγοράς ή καταναλωτικού κοινού αποτελεί μια από τις δημοφιλέστερες μεθόδους πρόβλεψης ζήτησης. Σε αυτή τη μέθοδο, η έρευνα πραγματοποιείται απευθείας στους πελάτες και στις αγορές τους. Η έρευνα μπορεί να πραγματοποιηθεί μέσω τηλεφωνικών επαφών, προσωπικών συνεντεύξεων ή ερωτηματολογίων, για τη λήψη δεδομένων από τους πελάτες. Η εταιρεία που διεξάγει την έρευνα εκτιμά τις πληροφορίες που συγκεντρώθηκαν, οι οποίες αφορούν συνήθως τα καταναλωτικά πρότυπα των ερωτηθέντων. Τα δεδομένα μπορούν να σχετίζονται με οικονομικά, και δημογραφικά στοιχεία των πελατών ή με τις προτιμήσεις τους. Η δημιουργία ενός κατάλληλου



ερωτηματολογίου ή συνέντευξης και η εξασφάλιση επαρκούς απάντησης από τους συμμετέχοντες αποτελούν κρίσιμα στοιχεία μιας επιτυχημένης έρευνας αγοράς.

- **Salesforce polling**

Σε αυτή τη μέθοδο, η πρόβλεψη γίνεται με βάση τις απόψεις των πωλητών, οι οποίοι έχουν σταθερές αλληλεπιδράσεις με τους πελάτες. Καθώς είναι πιο κοντά στους πελάτες, μπορούν να προβλέψουν καλύτερα τις απαιτήσεις τους για τη μελλοντική αγορά. Το κύριο πλεονέκτημα αυτής της μεθόδου πρόβλεψης είναι ότι είναι πολύ απλή στη χρήση και την κατανόηση. Οι πληροφορίες μπορούν εύκολα να διαχωριστούν σε διαφορετικές κατηγορίες. Ωστόσο, το μειονέκτημά της είναι ότι οι πωλητές μπορεί να είναι είτε αισιόδοξοι είτε απαισιόδοξοι για τις προβλέψεις τους και αυτό θα μπορούσε να οδηγήσει σε ανακριβείς προβλέψεις [65] [66].

- **Scenario writing**

Βασίζεται στην κατασκευή εναλλακτικών σεναρίων, τα οποία περιγράφουν μία ή περισσότερες πιθανές μελλοντικές καταστάσεις και αξιολογούν την πιθανή ζήτηση για κάθε σενάριο. Το σημείο εκκίνησης είναι συνήθως η υπάρχουσα κατάσταση. Η γραφή σεναρίου μπορεί επίσης να υποστηριχθεί με απλές στατιστικές τεχνικές [67]. Αυτή η μέθοδος βοηθά στην κατανόηση του τρόπου με τον οποίο διάφοροι παράγοντες θα μπορούσαν να επηρεάσουν τη ζήτηση.

- **Historical Analogy**

Αποτελεί ένα χρήσιμο εργαλείο για τη πρόβλεψη ζήτησης νέων προϊόντων, καθώς συγκρίνει το νέο προϊόν ή αγορά με παρόμοια προϊόντα ή αγορές του παρελθόντος για την εκτίμηση της μελλοντικής ζήτησης με βάση την ιστορική απόδοση. Αυτή η μέθοδος προϋποθέτει ότι το νέο προϊόν θα ακολουθήσει παρόμοιο μοτίβο με το ανάλογο ήδη υπάρχον προϊόν [33] [65].

### ***3.4 Ιεραρχική Πρόβλεψη (Hierarchical Forecasting)***

Προκειμένου να παρασχεθούν οι κατάλληλες πληροφορίες για την πρόβλεψη της ζήτησης, δεδομένων των διαφόρων επιπέδων διοίκησης και λειτουργικών κλάδων εντός των εταιριών, η εξάρτηση από την πρόβλεψη με βάση την ιεραρχία αυξάνεται. Η ιεραρχική πρόβλεψη (Hierarchical Forecasting – HF) αποτελεί μια τεχνική πρόβλεψης, η οποία βασίζεται σε μια στρατηγική συγκέντρωσης στοιχείων σε ιεραρχική δομή. Τα συστήματα HF οργανώνουν τα δεδομένα σε ένα ιεραρχικό δέντρο και είναι ικανά να παρέχουν προβλέψεις για αντικείμενα και τις αντίστοιχες οικογένειές τους. Αυτή η προσέγγιση είναι ιδιαίτερα χρήσιμη για οργανισμούς που πρέπει να προβλέπουν τη ζήτηση σε διάφορα επίπεδα, όπως γεωγραφικές περιοχές, κατηγορίες προϊόντων ή χρονικές περιόδους. Η ιεραρχική δομή επιτρέπει πιο ακριβείς και λεπτομερείς προβλέψεις αξιοποιώντας δεδομένα από διαφορετικά επίπεδα της ιεραρχίας [67] [68].

Η HF μπορεί να ενσωματώσει τόσο ποιοτικές όσο και ποσοτικές μεθόδους πρόβλεψης. Δεδομένου ότι αυτή η προσέγγιση συνήθως περιλαμβάνει πρόβλεψη σε πολλαπλά επίπεδα συνάθροισης ή διαχωρισμού στο εσωτερικό ενός οργανισμού ή εταιρίας, σε κάθε επίπεδο μπορούν να εφαρμοστούν ποσοτικές ή ποιοτικές μέθοδοι. Η κατάλληλη μέθοδος επιλέγεται ανάλογα με παράγοντες, όπως η διαθεσιμότητα και η φύση των δεδομένων, ο ορίζοντας πρόβλεψης, το επίπεδο λεπτομέρειας που απαιτείται και η τεχνογνωσία των προγνωστών [68] [69]. Μόλις δημιουργηθούν οι προβλέψεις, πρέπει να αξιολογηθούν χρησιμοποιώντας μετρήσεις όπως το μέσο απόλυτο σφάλμα (MAE), το μέσο τετραγωνικό σφάλμα (MSE) ή το μέσο απόλυτο ποσοστό σφάλματος (MAPE). Η

επικύρωση είναι ζωτικής σημασίας για να διασφαλιστεί ότι τα μοντέλα έχουν καλή απόδοση και ότι οι προβλέψεις είναι αξιόπιστες [70].

Οι στόχοι των συστημάτων HF περιλαμβάνουν βελτιωμένη απόδοση και μείωση του συνολικού φόρτου πρόβλεψης. Η ιεραρχική πρόβλεψη είναι μια ευέλικτη μέθοδος που χρησιμοποιείται για την πρόβλεψη τιμών σε πολλαπλά επίπεδα συνάθροισης ταυτόχρονα, διατηρώντας παράλληλα τη συνέπεια σε όλη την ιεραρχία. Επομένως, είναι ιδιαίτερα χρήσιμη σε προβλέψεις σε ένα μεγάλο οργανισμό ή εταιρία με ιεραρχική δομή. Ως αποτέλεσμα, η προσέγγιση είναι κοινή σε πολλούς τομείς, όπως οι πωλήσεις και η παραγωγή, όπου οι προβλέψεις ενδέχεται να απαιτούνται σε διάφορα επίπεδα, όπως επίπεδο προϊόντος, επίπεδο κατηγορίας, επίπεδο γεωγραφικής περιοχής και τέλος σε εταιρικό επίπεδο [69].

Μέχρι σήμερα, αρκετές μελέτες έχουν προσφέρει πρακτικές οδηγίες για το δομικό σχεδιασμό συστημάτων HF [68]. Το πρώτο βήμα κατά την ιεραρχική πρόβλεψη είναι να καθοριστεί η ιεραρχική δομή της εταιρίας. Αυτή η δομή μπορεί να βασίζεται σε διάφορες παραμέτρους, όπως κατηγορίες προϊόντων, γεωγραφικές περιοχές ή κανάλια πωλήσεων. Κάθε επίπεδο στην ιεραρχία αντιπροσωπεύει ένα διαφορετικό επίπεδο συγκέντρωσης. Η μέθοδος μπορεί να προσαρμοστεί για να λαμβάνει υπόψη τόσο τις πληροφορίες σε μικροσκοπικό επίπεδο, όπως για παράδειγμα, πωλήσεις ανά μεμονωμένο προϊόν ή κατάσταση, όσο και σε μακροσκοπικό επίπεδο, για παράδειγμα τις συνολικές πωλήσεις για ολόκληρη την εταιρία [71].

Η κατάλληλη τεχνική HF επιλέγεται με βάση τη δομή των δεδομένων, τις διαθέσιμες πληροφορίες και τους στόχους της πρόβλεψης. Οι πιο παραδοσιακές προσεγγίσεις για την ιεραρχική πρόβλεψη είναι οι μέθοδοι από κάτω προς τα πάνω (Bottom-up forecasting) και από πάνω προς τα κάτω (Top-down forecasting). Η μέθοδος bottom-up περιλαμβάνει την πρόβλεψη κάθε σειράς στο κάτω επίπεδο και στη συνέχεια την άθροισή τους για να ληφθούν προβλέψεις στα υψηλότερα επίπεδα της ιεραρχίας. Το κύριο πλεονέκτημα αυτής της προσέγγισης είναι πως, δεδομένου ότι οι προβλέψεις λαμβάνονται στο κατώτερο επίπεδο, δε χάνονται πληροφορίες λόγω συνάθροισης. Ωστόσο, αγνοεί τις αλληλεπιδράσεις μεταξύ των σειρών και συνήθως έχει κακή απόδοση σε εξαιρετικά συγκεντρωτικά δεδομένα [72] [73] [74]. Η μέθοδος top-down περιλαμβάνει την πρόβλεψη των πιο συγκεντρωτικών σειρών στο ανώτατο επίπεδο και, στη συνέχεια, την αποσύνθεση αυτών, χρησιμοποιώντας είτε ιστορικές είτε προβλεπόμενες αναλογίες, για να ληφθούν προβλέψεις κατώτατου επιπέδου. Οι προσεγγίσεις top-down που βασίζονται σε ιστορικές αναλογίες τείνουν να παράγουν λιγότερο ακριβείς προβλέψεις σε χαμηλότερα επίπεδα της ιεραρχίας [75]. Συμπερασματικά, στη μέθοδο bottom-up οι προβλέψεις γίνονται στο χαμηλότερο επίπεδο της ιεραρχίας. Για παράδειγμα, μπορεί να γίνουν προβλέψεις για μεμονωμένα προϊόντα ή καταστήματα. Αυτές οι προβλέψεις χρησιμεύουν ως βάση για τις προβλέψεις σε υψηλότερα επίπεδα της ιεραρχίας. Από την άλλη πλευρά, η μέθοδος top-down αφορά προσαρμογές στις συγκεντρωτικές προβλέψεις για να ενσωματωθούν πρόσθετες πληροφορίες ή κρίση ειδικών. Για παράδειγμα, εάν υπάρχουν γνωστές τάσεις της αγοράς που επηρεάζουν όλα τα προϊόντα, αυτές οι τάσεις μπορούν να ενσωματωθούν στις προβλέψεις σε υψηλότερα επίπεδα της ιεραρχίας [76].

Μια τρίτη προσέγγιση που ονομάζεται ενδιάμεση (Middle-out forecasting) συνδυάζει πτυχές των μεθόδων bottom-up και top-down. Κατά τη συνδυαστική προσέγγιση, λαμβάνονται προβλέψεις για κάθε σειρά ενός ενδιάμεσου επιπέδου της ιεραρχίας που επιλέχθηκε αρχικά. Οι προβλέψεις για τις σειρές πάνω από το ενδιάμεσο επίπεδο παράγονται χρησιμοποιώντας την προσέγγιση bottom-up, ενώ οι προβλέψεις για τις σειρές κάτω από το ενδιάμεσο επίπεδο παράγονται χρησιμοποιώντας την προσέγγιση top-down [76] [77].

Η ιεραρχική πρόβλεψη επιτρέπει στους οργανισμούς να δημιουργούν ακριβείς προβλέψεις σε διαφορετικά επίπεδα συνάθροισης, διατηρώντας παράλληλα τη συνέπεια σε όλη την ιεραρχία. Αυτό είναι ιδιαίτερα πολύτιμο για τη λήψη αποφάσεων, την κατανομή πόρων και τη διαχείριση αποθεμάτων σε πολύπλοκους οργανισμούς. Ωστόσο, η ακρίβεια των προβλέψεων μπορεί να επηρεαστεί από την ανακρίβεια στα δεδομένα χαμηλότερου επιπέδου. Επιπλέον, η διαχείριση της ιεραρχικής δομής μπορεί

να γίνει πολύπλοκη, ιδίως σε περιπτώσεις οργανισμών με πολλαπλά επίπεδα ιεραρχίας. Για αυτούς τους λόγους είναι σημαντικό να χρησιμοποιηθούν οι κατάλληλες μέθοδοι πρόβλεψης και να πραγματοποιούνται συνεχώς έλεγχοι συνέπειας, ώστε να διασφαλιστεί ότι οι προβλέψεις σε διαφορετικά επίπεδα της ιεραρχίας είναι συνεπείς μεταξύ τους. Για παράδειγμα, η πρόβλεψη για τις συνολικές πωλήσεις θα πρέπει να είναι ίση με το άθροισμα των προβλέψεων για μεμονωμένα προϊόντα ή κατηγορίες προϊόντων. Οι προβλέψεις μπορούν να βελτιωθούν επαναληπτικά με βάση σχόλια και νέες πληροφορίες. Οι πληροφορίες αυτές μπορεί να περιλαμβάνουν την προσαρμογή μοντέλων πρόβλεψης, την αναθεώρηση υποθέσεων ή την ενσωμάτωση πρόσθετων δεδομένων [68] [78]. Σε κάθε περίπτωση, ο τρόπος με τον οποίο θα συγκεντρωθούν και θα συνδυαστούν οι πληροφορίες από διαφορετικά επίπεδα και πώς θα διανεμηθούν οι συνολικές προβλέψεις στα χαμηλότερα επίπεδα, αποτελούν κεντρικές προκλήσεις. Στην επίτευξη αυτού του στόχου μπορεί να αποδειχθεί χρήσιμη η χρήση στατιστικών μοντέλων και αλγορίθμων [69].

# 4

## Πρόβλεψη με SAS

### *4.1 Μεθοδολογία και βήματα υλοποίησης*

Στην παρούσα διπλωματική εργασία θα υλοποιηθεί η διαδικασία πρόβλεψης με τη χρήση του λογισμικού συστήματος στατιστικής ανάλυσης SAS (Statistical Analysis Software). Η πρόβλεψη με SAS περιλαμβάνει τη χρήση του λογισμικού για την ανάλυση ιστορικών δεδομένων και την πραγματοποίηση προβλέψεων, σχετικά με τις μελλοντικές τάσεις. Το SAS προσφέρει ισχυρά εργαλεία και τεχνικές, ειδικά σχεδιασμένα για εργασίες πρόβλεψης. Τα εργαλεία αυτά επιτρέπουν στους χρήστες να εκτελούν ανάλυση χρονοσειρών, να δημιουργούν μοντέλα, να αξιολογούν την απόδοση του μοντέλου και να δημιουργούν προβλέψεις.

Το πρώτο βήμα σε οποιαδήποτε διαδικασία πρόβλεψης είναι η συλλογή και προετοιμασία των δεδομένων. Το SAS παρέχει διάφορα εργαλεία χειρισμού δεδομένων. Απαραίτητη προϋπόθεση είναι ότι το σύνολο δεδομένων περιλαμβάνει μια μεταβλητή χρόνου και τις αντίστοιχες προς πρόβλεψη τιμές. Στη συνέχεια, πριν δημιουργηθεί το μοντέλο πρόβλεψης, θα πρέπει να υλοποιηθεί διερευνητική ανάλυση δεδομένων (Exploratory Data Analysis - EDA), δηλαδή κατανόηση των χαρακτηριστικών, των μοτίβων και των τάσεων. Το SAS προσφέρει στατιστικές διαδικασίες και απεικονίσεις για την εκτέλεση EDA, όπως συνοπτικά στατιστικά στοιχεία, διαγράμματα χρονοσειρών, γραφικές παραστάσεις αυτοσυσχέτισης και εποχιακή αποσύνθεση. Επίσης, το λογισμικό παρέχει διάφορες διαδικασίες για τη μοντελοποίηση χρονοσειρών, συμπεριλαμβανομένων των ARIMA, UCM και ESM, οι οποίες επιτρέπουν στο χρήστη να εκτιμήσει διαφορετικούς τύπους μοντέλων χρονοσειρών για την καταγραφή διαφόρων μοτίβων στα δεδομένα. Αφού προσαρμοστούν διαφορετικά μοντέλα στα δεδομένα, πρέπει να επιλεγεί αυτό ή αυτά με την καλύτερη απόδοση, βάσει στατιστικών κριτηρίων και ακρίβειας. Το SAS προσφέρει εργαλεία για επιλογή μοντέλου, εκτίμηση παραμέτρων και διαγνωστικό έλεγχο για την αξιολόγηση της εφαρμογής και της αξιοπιστίας των μοντέλων. Επιπλέον, δίνει τη δυνατότητα να παραχθούν σημειακές προβλέψεις, διαστήματα πρόβλεψης και μέτρα ακρίβειας προβλέψεων για να ποσοτικοποιηθεί η αβεβαιότητα που σχετίζεται με τις προβλέψεις. Το τελικό στάδιο περιλαμβάνει την οπτικοποίηση των αποτελεσμάτων πρόβλεψης, μέσω γραφημάτων χρονοσειρών, γραφημάτων σφαλμάτων πρόβλεψης και συγκριτικών αναλύσεων. Δίνεται η δυνατότητα, επίσης, να δημιουργηθούν προσαρμοσμένες αναφορές και πίνακες εργαλείων, χρησιμοποιώντας προγραμματισμό SAS ή διαδραστικά εργαλεία οπτικοποίησης όπως το SAS Visual Analytics [79] [80].



Το παραπάνω διάγραμμα σχετίζεται με τη δομή αποθήκευσης δεδομένων για καταστήματα, διαχωρισμένα με βάση την πόλη, την περιοχή και τον τύπο κουζίνας. Ακολουθεί μια πιο αναλυτική εξήγηση της ιεραρχίας:

- **shop\_city**: Στην κορυφή της ιεραρχίας βρίσκεται η οντότητα "shop\_city", που δείχνει τις πόλεις όπου βρίσκονται τα καταστήματα. Αυτή η οντότητα χρησιμεύει ως ρίζα για τη δομή και είναι η ευρύτερη κατηγορία ταξινόμησης.
- **shop\_area**: Ακολουθώντας την ιεραρχία, η οντότητα "shop\_area" αναπαριστά διαφορετικές περιοχές εντός κάθε πόλης. Καθώς κάθε πόλη μπορεί να περιλαμβάνει πολλαπλές περιοχές, το διάγραμμα δείχνει ότι από κάθε πόλη προκύπτουν διαφορετικές διακλαδώσεις προς τις περιοχές της.
- **shop\_cuisine**: Το τρίτο και πιο εξειδικευμένο επίπεδο είναι η οντότητα "shop\_cuisine", η οποία δείχνει τους διάφορους τύπους κουζίνας που προσφέρονται στα καταστήματα κάθε περιοχής. Κάθε περιοχή μπορεί να περιλαμβάνει πολλαπλούς τύπους κουζίνας, όπως αυτό αναπαρίσταται από τις πολλαπλές κατακόρυφες διακλαδώσεις.

Επόμενο στάδιο αποτελεί η ομαδοποίηση των δεδομένων, με βάση την ημερομηνία, αθροίζοντας τις στήλες orders, GMV και users και δημιουργώντας τις αντίστοιχες νέες στήλες sum\_orders, sum\_GMV και sum\_users. Δηλαδή, για κάθε ημερομηνία και για κάθε συνδυασμό shop\_city, shop\_area και shop\_cuisine έγινε ομαδοποίηση στις τρεις παραπάνω στήλες. Ακολουθεί παράδειγμα, όπου για τα δεδομένα του Πίνακα 1, μετά την ομαδοποίηση προκύπτουν τα δεδομένα του Πίνακα 2:

shop_city	shop_area	shop_cuisine	timestamp	orders	GMV	users
Αθήνα	Περιστερί	Pizza	2022-07-07	50	23	50
Αθήνα	Περιστερί	Pizza	2022-07-07	2	25	2
Αθήνα	Περιστερί	Κρέπες	2022-07-10	4	54	4
Αθήνα	Περιστερί	Κρέπες	2022-07-10	23	12	23
Αθήνα	Περιστερί	Κρέπες	2022-07-10	21	10	21

Πίνακας 1: Ομαδοποίηση δεδομένων με βάση την ημερομηνία

shop_city	shop_area	shop_cuisine	timestamp	sum_orders	sum_GMV	sum_users
Αθήνα	Περιστερί	Pizza	2022-07-07	52=(50+2)	48=(23+25)	52=(50+2)
Αθήνα	Περιστερί	Κρέπες	2022-07-10	48=(4+23+21)	76=(54+12+10)	48=(4+23+21)

Πίνακας 2: Αποτέλεσμα δεδομένων μετά την ομαδοποίηση

Μετά την ολοκλήρωση της διαδικασίας ομαδοποίησης, τα δεδομένα πλέον αποτελούνται από τις παρακάτω στήλες:

- shop\_city,
- shop\_area,
- shop\_cuisine,
- date,
- sum\_orders,
- sum\_GMV και
- sum\_users

και 381113 συνολικές γραμμές.

Το επόμενο στάδιο επεξεργασίας των δεδομένων περιλαμβάνει τη μετατροπή της στήλης shop\_area σε ορισμένες γραμμές, ώστε να αντιμετωπιστούν σφάλματα. Συγκεκριμένα, η στήλη

shop\_area αποτελούνταν από μερικές γραμμές με την τιμή 'Χαλκιδική-Νέα Τρίγλι'. Το SAS αντιμετώπιζε την τιμή ως σφάλμα και δεν προχωρούσε με την ανάλυση. Η λύση δόθηκε μετονομάζοντας την τιμή στις συγκεκριμένες γραμμές σε 'Χαλκιδική Νέα Τρίγλια'. Τέλος, καθώς τα δεδομένα που υπήρχαν μετά τις 31JUL22 ήταν ελλιπέστατα και αλλοίωναν τη συνολική εικόνα των διαγραμμάτων, αφαιρέθηκαν.


Αφού ολοκληρώθηκε η ομαδοποίηση και οι απαραίτητες μετατροπές, ακολούθησε η ενοποίηση των δεδομένων. Αρχικά, συνδυάστηκαν δύο σύνολα δεδομένων (projectl.first και projectl.sec) σε ένα νέο σύνολο (projectl.combined\_file). Στη συνέχεια, προστέθηκε ένα τρίτο σύνολο δεδομένων (projectl.third) στο ήδη ενοποιημένο. Πραγματοποιήθηκε καθαρισμός των δεδομένων, τα οποία φιλτραρίστηκαν ώστε να απορριφθούν εγγραφές με απουσιάζουσες τιμές στα πεδία shop\_area, shop\_city, και shop\_cuisine. Ακολούθησε η διαχείριση των χρονικών δεδομένων, εξάγοντας την ημερομηνία από μια στήλη χρονοσφραγίδας και μετατρέποντάς τη σε μορφή ημερομηνίας SAS, εγκαταλείποντας την αρχική στήλη χρονοσφραγίδας. Τα δεδομένα ταξινομήθηκαν βάσει shop\_city, shop\_area, shop\_cuisine, και date για πιο εύκολη διαχείριση και ανάλυση. Συγκεντρώθηκαν οι τιμές των μεταβλητών GMV, users, και orders ανά ημερομηνία, shop\_city, shop\_area, και shop\_cuisine, αποθηκεύοντας τα αθροίσματα για κάθε μοναδικό συνδυασμό. Τέλος, έγινε το φιλτράρισμα και η προετοιμασία των δεδομένων για πρόβλεψη. Το λογισμικό άλλαξε την τιμή των εγγραφών στη στήλη shop\_area σε "Χαλκιδική Νέα Τρίγλια", όπου εντόπισε το κείμενο "Νέα Τρίγλι" στο πεδίο, ενώ διατήρησε τις υπόλοιπες τιμές ως έχουν. Επίσης, εφάρμοσε ένα φίλτρο για να απορρίψει εγγραφές μετά την ημερομηνία "31JUL22", προετοιμάζοντας τα δεδομένα για περαιτέρω ανάλυση ή πρόβλεψη.

## 4.1.2 Στατιστικά δεδομένων

Η ανάλυση στατιστικών δεδομένων με το SAS περιλαμβάνει τη χρήση του λογισμικού για την εκτέλεση διαφόρων στατιστικών διαδικασιών και αναλύσεων σε σύνολα δεδομένων. Στη συγκεκριμένη συλλογή δεδομένων που παρέχεται προς επεξεργασία, η αναλυτική περιγραφή των δεδομένων αποκαλύπτει τα εξής γενικά χαρακτηριστικά και στατιστικά στοιχεία:

- **Αριθμός καταγραφών:** Υπάρχουν συνολικά 381,111 καταγραφές στο σύνολο των δεδομένων.
- **Πόλεις και περιοχές:** Τα δεδομένα περιλαμβάνουν 128 διαφορετικές πόλεις και 305 περιοχές, με την Αθήνα και τη Θεσσαλονίκη να είναι αντίστοιχα οι πιο συχνές.
- **Κουζίνες:** Υπάρχουν 65 διαφορετικοί τύποι κουζίνας, με τον τύπο "Καφέδες" να εμφανίζεται συχνότερα.
- **Χρονικό διάστημα:** Τα δεδομένα καλύπτουν χρονικά την περίοδο από την 1η Μαΐου 2022 έως την 30ή Ιουλίου 2022.
- **Συνολικό Gross Merchandise Value (sum\_GMV):** Ο μέσος όρος του GMV είναι 756.76 με μέγιστη τιμή 98,400.55 και ελάχιστη 0. Η δεδομένη απόκλιση είναι 2649.34, υποδηλώνοντας μεγάλη διακύμανση στα ποσά των παραγγελιών.
- **Συνολικοί χρήστες (sum\_users):** Ο μέσος αριθμός χρηστών ανά καταχώρηση είναι περίπου 77.53, με μέγιστο αριθμό 8681 χρήστες και ελάχιστο 1 χρήστη.
- **Συνολικές παραγγελίες (sum\_orders):** Ο μέσος αριθμός παραγγελιών είναι παρόμοιος με τον αριθμό των χρηστών, στο 77.86, με μέγιστο 8706 παραγγελίες και ελάχιστο 1 παραγγελία.

Στο διάγραμμα της Εικόνας 2 απεικονίζονται οι συνολικές παραγγελίες στο χρονικό διάστημα των τριών μηνών. Το διάγραμμα αποτελεί συνάρτηση του αριθμού των παραγγελιών ανά ημέρα.



Εικόνα 2: Συνολικές παραγγελίες σε διάστημα τριών μηνών

Κατά τη διάρκεια του χρονικού διαστήματος που καλύπτουν τα δεδομένα, ο συνολικός αριθμός παραγγελιών (sum\_orders) για τα τρία επικρατέστερα είδη κουζίνας είναι ο παρακάτω:

- **Καφέδες:** 10,909,469 παραγγελίες
- **Σουβλάκια:** 7,222,291 παραγγελίες
- **Pizza:** 2,832,771 παραγγελίες

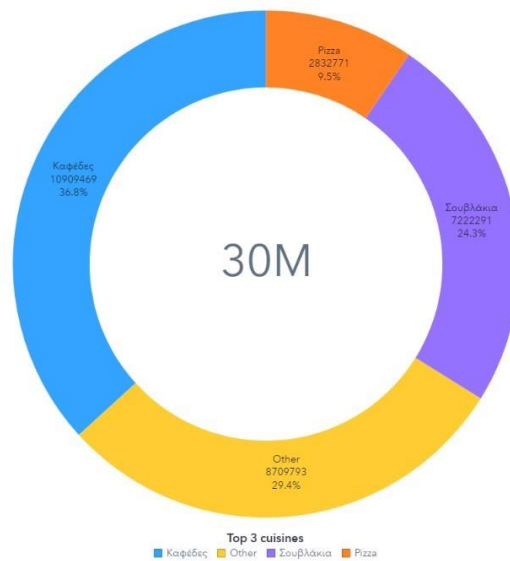
Βάσει του συνολικού αριθμού των παραγγελιών (sum\_orders), οι τρεις επικρατέστερες κουζίνες στο σύνολο των δεδομένων εμφανίζουν τα παρακάτω ημερήσια στατιστικά στοιχεία:

1. Κουζίνα: Σουβλάκια
  - Μέσος Αριθμός Παραγγελιών: 285.66
  - Μέγιστος Αριθμός Παραγγελιών: 8706
  - Ελάχιστος Αριθμός Παραγγελιών: 1
  - Τυπική Απόκλιση: 624.21
2. Κουζίνα: Καφέδες
  - Μέσος Αριθμός Παραγγελιών: 382.67
  - Μέγιστος Αριθμός Παραγγελιών: 8238
  - Ελάχιστος Αριθμός Παραγγελιών: 1
  - Τυπική Απόκλιση: 781.70
3. Κουζίνα: Pizza
  - Μέσος Αριθμός Παραγγελιών: 117.19
  - Μέγιστος Αριθμός Παραγγελιών: 5976
  - Ελάχιστος Αριθμός Παραγγελιών: 1
  - Τυπική Απόκλιση: 265.41

Στην Εικόνα 3 παρουσιάζονται οι συνολικές παραγγελίες που έχουν πραγματοποιηθεί για τα τρία επικρατέστερα είδη κουζίνας:



sum\_orders by Top 3 cuisines  
sum\_orders




Εικόνα 3: Συνολικές παραγγελίες για τα τρία επικρατέστερα είδη κουζίνας

Με βάση την ανάλυση συσχέτισης μεταξύ του αριθμού των παραγγελιών και των ημερών της εβδομάδας, εξάγονται τα ακόλουθα στατιστικά στοιχεία:

- **Κυριακή (Sunday):** Έχει την υψηλότερη θετική συσχέτιση (0.008630) με τον αριθμό των παραγγελιών, υποδηλώνοντας ότι τις Κυριακές παρατηρείται ελαφρώς αυξημένη ζήτηση σε σχέση με τις υπόλοιπες ημέρες της εβδομάδας.
- **Παρασκευή (Friday):** Ακολουθεί με μια ελαφρώς θετική συσχέτιση (0.002232), η οποία δηλώνει ότι οι Παρασκευές μπορεί επίσης να έχουν μια ελαφρώς αυξημένη ζήτηση.
- **Τρίτη (Tuesday):** Παρουσιάζει την χαμηλότερη συσχέτιση (-0.004196) με τον αριθμό των παραγγελιών, υποδηλώνοντας την πιθανότητα μικρότερης ζήτησης σε σχέση με τις υπόλοιπες ημέρες της εβδομάδας.

Σύμφωνα με το διάγραμμα της μηνιαίας συνολικής τάσης των παραγγελιών (Εικόνα 4), παρατηρείται μια σαφής καθοδική κλίση από το Μάιο προς τον Ιούλιο του 2022. Το γεγονός αυτό δηλώνει μια μακροπρόθεσμη μειωτική τάση στον αριθμό των παραγγελιών τη συγκεκριμένη χρονική περίοδο. Η συνεχής μείωση πιθανώς αντικατοπτρίζει μια περιοδική μεταβολή στη ζήτηση, η οποία ενδέχεται να οφείλεται σε εποχικούς παράγοντες, όπως η έναρξη της θερινής περιόδου και των διακοπών, όταν οι άνθρωποι συχνά προτιμούν να τρώνε εκτός σπιτιού αντί να παραγγέλνουν για διανομή κατ' οίκον.




Εικόνα 4: Μηνιαία συνολική τάση των παραγγελιών

### 4.1.3 Εφαρμογή ARIMA - GS

Στο λογισμικό SAS, η μοντελοποίηση ARIMA μπορεί να εφαρμοστεί μέσω πολλών διαδικασιών, όπως PROC ARIMA, PROC AUTOREG ή PROC FORECAST. Αυτές οι διαδικασίες προσφέρουν ευελιξία στον καθορισμό των παραμέτρων του μοντέλου, στο χειρισμό της εποχικότητας και στην ενσωμάτωση εξωγενών μεταβλητών. Από την άλλη πλευρά, η μοντελοποίηση Generated Smoothing (GS), στον πυρήνα της, έχει σχεδιαστεί για να αντιμετωπίζει τις προκλήσεις που σχετίζονται με θορυβώδη ή ακανόνιστα δεδομένα, εξομαλύνοντας τις διακυμάνσεις και αποκαλύπτοντας υποκείμενα μοτίβα. Αυτό επιτυγχάνεται μέσω της δημιουργίας συνθετικών σημείων δεδομένων που αποτυπώνουν την ουσία του αρχικού συνόλου δεδομένων, ενώ μειώνουν το θόρυβο και τη μεταβλητότητα.

Για τη συλλογή των δεδομένων που εξετάζεται, η πρώτη ανάλυση που πραγματοποιήθηκε είναι για τις τιμές: shop\_city = Πειραιάς, shop\_area = Πειραιάς και shop\_cuisine = Σουβλάκια. Στην Εικόνα 5 παρουσιάζεται ένα διάγραμμα χρονοσειρών με τις εξής συνιστώσες:

- **Ιστορικά Δεδομένα (Historical Data):** Αντιπροσωπεύονται με μαύρες κουκκίδες, οι οποίες δείχνουν τις παρατηρήσεις των δεδομένων το χρονικό διάστημα από την 1η Μαΐου 2022 έως και τέλος Ιουλίου 2022.
- **Συμφωνημένη Πρόβλεψη (Reconciled Forecast):** Δείχνει την προβλεπόμενη τιμή, πιθανώς μετά από κάποια διαδικασία συντονισμού μοντέλων ή εξαγωγής συμφωνημένων προβλέψεων από διάφορα μοντέλα.
- **Όρια Εμπιστοσύνης Πρόβλεψης (Forecast Confidence Limits):** Η περιοχή που επισημαίνεται με γκρι χρώμα αντιπροσωπεύει τα όρια εμπιστοσύνης για τις προβλέψεις. Παρέχει ένα εύρος τιμών, στις οποίες η πραγματική τιμή μπορεί να βρίσκεται με συγκεκριμένη πιθανότητα.
- **Παρακάμψη (Override):** Πιθανώς επιτρέπει στο χρήστη να παρεμβαίνει και να τροποποιεί την πρόβλεψη βάσει δικών του εκτιμήσεων ή εξωτερικών παραμέτρων.



Εικόνα 5: Ανάλυση για τις τιμές:  $shop\_city = \text{Πειραιάς}$ ,  $shop\_area = \text{Πειραιάς}$  και  $shop\_cuisine = \text{Σουβλακία}$

Για τα συγκεκριμένα δεδομένα, το λογισμικό προσαρμόστηκε και για τα δυο μοντέλα, το Generated ARIMA Model και το Generated Smoothing Model, έχοντας αντίστοιχα Holdout Μαρπ 6,98 και 8,47, οπότε και το ARIMA θεωρήθηκε η καταλληλότερη επιλογή.

## 4.2 Αποτελέσματα

### 4.2.1 Μοντέλο ARIMA

Η απόδοση ενός μοντέλου ARIMA εξαρτάται από πολλούς παράγοντες και ο χαμηλός δείκτης MAPE, όπως για παράδειγμα το 6,98% στην περίπτωση των σουβλακιών στον Πειραιά, υποδηλώνει καλή προσαρμογή του μοντέλου στα δεδομένα. Πιθανοί λόγοι για την αποτελεσματικότητα του μοντέλου ARIMA στην προκειμένη περίπτωση, αποτελούν οι παρακάτω:

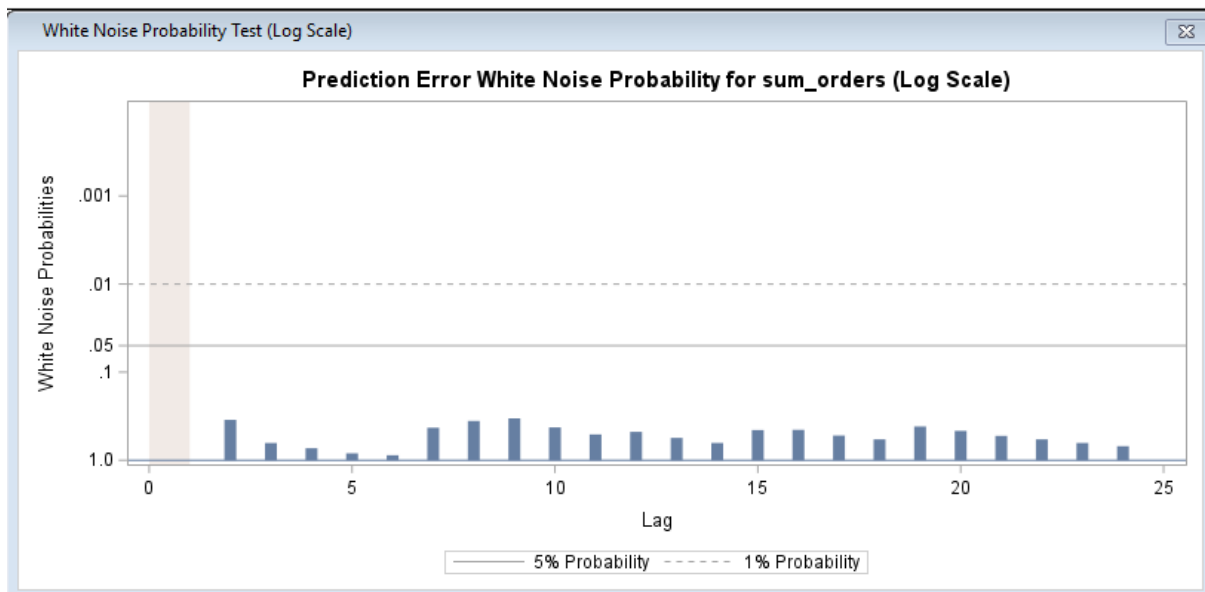
1. **Σταθερότητα δεδομένων:** Αν τα δεδομένα πωλήσεων σουβλακιών στον Πειραιά είναι σχετικά σταθερά ή παρουσιάζουν εποχικότητα/τάση που ταιριάζει με τις υποθέσεις του μοντέλου ARIMA.
2. **Εποχικότητα και τάσεις:** Αν οι πωλήσεις σουβλακιών δείχνουν σαφή εποχικά μοτίβα ή τάσεις μέσα στο χρόνο, το ARIMA μπορεί να εκμεταλλευτεί αυτές τις πληροφορίες για πιο ακριβείς προβλέψεις.
3. **Κατάλληλη διαμόρφωση:** Η επιλογή των παραμέτρων ( $p, d, q$ ) και των εποχικών παραμέτρων ( $P, D, Q, S$ ) για το μοντέλο ARIMA να έγινε με τρόπο που ταιριάζει στη δομή των δεδομένων.
4. **Διακύμανση και θόρυβος:** Αν τα δεδομένα έχουν σχετικά λίγο θόρυβο ή απρόβλεπτη διακύμανση, τότε το μοντέλο ARIMA μπορεί να προσαρμόζεται καλύτερα, δίνοντας χαμηλότερο σφάλμα πρόβλεψης.
5. **Αναλυτική επεξεργασία δεδομένων:** Η προεργασία των δεδομένων (π.χ. αφαίρεση ακραίων τιμών, λείανση, κανονικοποίηση) μπορεί να βελτιώσει την ποιότητα των εισόδων για το μοντέλο.

Συμπερασματικά, ο συνδυασμός μιας καλής προετοιμασίας δεδομένων, ενός κατάλληλου επιπέδου σταθερότητας και εποχικότητας στα δεδομένα, σε συνδυασμό με μια επιτυχημένη διαμόρφωση των

παραμέτρων του μοντέλου ARIMA, αποτελούν τους λόγους που το μοντέλο ARIMA αποδίδει καλύτερα για τις πωλήσεις σουβλακιών στον Πειραιά.


Στο γράφημα της Εικόνας 5, που αφορά τις παραγγελίες σουβλακιών στον Πειραιά, παρατηρούνται ορισμένες ενδιαφέρουσες διακυμάνσεις. Κάποιες ημέρες καταγράφεται πολύ υψηλότερος μέσος αριθμός παραγγελιών, ενώ άλλες ημέρες η ζήτηση φαίνεται να μειώνεται. Οι ημέρες με τις περισσότερες παραγγελίες είναι η Παρασκευή, το Σάββατο και η Κυριακή, ενώ αυτές με τις λιγότερες παραγγελίες είναι η Τρίτη, η Τετάρτη και η Πέμπτη. Δε φαίνεται να υπάρχει μία μονοτονική τάση ανόδου ή πτώσης στις παραγγελίες κατά τη διάρκεια του χρονικού διαστήματος που εξετάζεται.

Στην Εικόνα 6 απεικονίζεται το γράφημα μιας δοκιμής λευκού θορύβου για τις προβλέψεις σφαλμάτων από το μοντέλο ARIMA. Ο λευκός θόρυβος αναφέρεται σε μια σειρά τυχαίων δεδομένων, όπου οι διαδοχικές τιμές δεν έχουν καμία σχέση μεταξύ τους και η μέση τιμή είναι μηδενική. Εάν τα σφάλματα πρόβλεψης ενός μοντέλου αποτελούν λευκό θόρυβο, τότε το μοντέλο έχει καταφέρει να εξηγήσει όλες τις πληροφορίες στα δεδομένα, αφήνοντας μόνο την τυχαία, απρόβλεπτη διακύμανση. Στο γράφημα της Εικόνας 5 οι κάθετες μπάρες αντιστοιχούν στις πιθανότητες του να είναι τα σφάλματα λευκού θορύβου σε διάφορες χρονικές υστερήσεις (lags). Αυτές οι πιθανότητες είναι σε λογαριθμική κλίμακα, με την οριζόντια γραμμή που βρίσκεται στο 5% να αποτελεί το κατώφλι για την στατιστική σημαντικότητα. Εάν μια κάθετη μπάρα υπερβαίνει αυτό το επίπεδο, τότε υπάρχει λιγότερο από 5% πιθανότητα τα σφάλματα να είναι λευκός θόρυβος. Δηλαδή να υπάρχει κάποια συσχέτιση στα σφάλματα σε αυτή τη χρονική υστέρηση. Στο συγκεκριμένο διάγραμμα φαίνεται ότι οι πιθανότητες είναι κάτω από το 5% για όλες τις υστερήσεις, γεγονός που υποδηλώνει ότι τα σφάλματα πρόβλεψης είναι στατιστικά σημαντικά διαφορετικά από λευκό θόρυβο και ενδέχεται να υπάρχει μια δομή ή μοτίβο που δεν έχει εντοπιστεί από το μοντέλο.



Εικόνα 6: Δοκιμή λευκού θορύβου για τις προβλέψεις σφαλμάτων από το μοντέλο ARIMA

Η Εικόνα 7 περιλαμβάνει τρία διαφορετικά γραφήματα σχετικά με την αυτοσυσχέτιση των σφαλμάτων πρόβλεψης, για την περίπτωση των παραγγελιών σουβλακιών που εξετάζεται. Η συνολική εικόνα από αυτά τα γραφήματα υποδεικνύει ότι τα σφάλματα πρόβλεψης ενδέχεται να μην περιέχουν ανεκμετάλλευτη πληροφορία που θα μπορούσε να βελτιώσει το μοντέλο, καθώς δε φαίνεται να υπάρχει σημαντική αυτοσυσχέτιση. Έτσι υποστηρίζεται η ιδέα ότι το μοντέλο έχει εντοπίσει τη βασική δομή των δεδομένων. Ωστόσο, η τελική κρίση για την επίδοση του μοντέλου θα εξαρτηθεί από τη συγκριτική ανάλυση με άλλα μοντέλα και την εφαρμογή διαφόρων δοκιμών απόδοσης και επαλήθευσης.

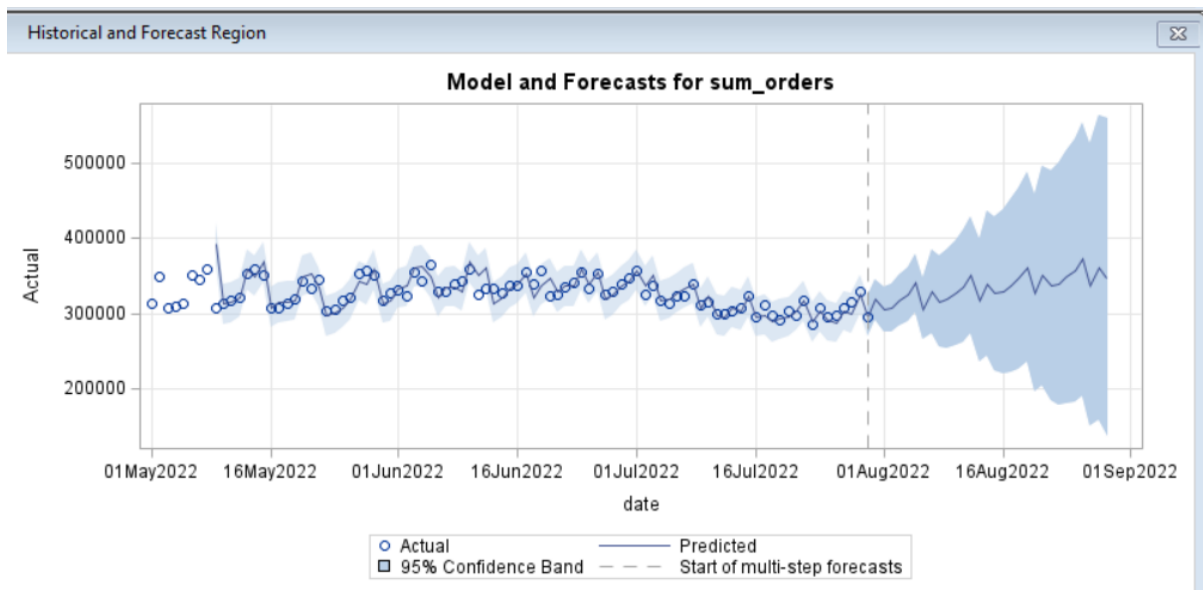


Εικόνα 7: Γραφήματα σχετικά με την αυτοσυσχέτιση των σφαλμάτων πρόβλεψης στο μοντέλο ARIMA

Πιο αναλυτικά, τα τρία γραφήματα εξηγούνται ως εξής:

1. **Αυτοσυσχέτιση (ACF):** Το πρώτο γράφημα, επάνω αριστερά, δείχνει την αυτοσυσχέτιση των σφαλμάτων πρόβλεψης για διάφορες χρονικές υστερήσεις. Η ACF μετράει πόσο καλά συσχετίζονται οι τιμές μεταξύ τους σε διαφορετικές υστερήσεις. Στο γράφημα, η ACF είναι υψηλή για την υστέρηση 0, όπως αναμένεται, επειδή αυτό αντιστοιχεί στη συσχέτιση της τιμής με τον εαυτό της. Για τις υπόλοιπες υστερήσεις, η ACF φαίνεται να βρίσκεται μέσα στα στατιστικά σημαντικά επίπεδα, γεγονός που υποδεικνύει ότι δεν υπάρχει σημαντική αυτοσυσχέτιση στα σφάλματα πρόβλεψης.
2. **Μερική Αυτοσυσχέτιση (PACF):** Το δεύτερο γράφημα, επάνω δεξιά, δείχνει τη μερική αυτοσυσχέτιση για τα ίδια σφάλματα πρόβλεψης. Η PACF μετράει τη συσχέτιση μεταξύ τιμών που χωρίζονται από  $k$  υστερήσεις, απομονώνοντας την επίδραση των ενδιάμεσων τιμών. Ομοίως με το ACF γράφημα, η PACF είναι υψηλή για την υστέρηση 0, ενώ στις υπόλοιπες υστερήσεις φαίνεται να παραμένει εντός των στατιστικών σημαντικών ορίων.
3. **Δοκιμή λευκού θορύβου:** Το τρίτο γράφημα, κάτω δεξιά, δείχνει τη δοκιμή λευκού θορύβου, οπότε συνοψίζει την πιθανότητα τα σφάλματα πρόβλεψης να είναι λευκός θόρυβος.

Το γράφημα της Εικόνας 8 παρουσιάζει τις πραγματικές και προβλεπόμενες τιμές για τις συνολικές παραγγελίες (sum\_orders) σε μια χρονοσειρά. Οι πραγματικές τιμές απεικονίζονται ως μπλε κύκλοι, ενώ οι προβλεπόμενες τιμές από το μοντέλο απεικονίζονται με μια μπλε γραμμή. Οι διακεκομμένες γραμμές σηματοδοτούν το σημείο όπου αρχίζουν τα πολλαπλά βήματα προβλέψεων (multi-step forecasts). Επίσης, η γαλάζια σκιασμένη περιοχή αντιπροσωπεύει το 95% του διαστήματος εμπιστοσύνης για τις προβλέψεις, δηλαδή υπάρχει 95% πιθανότητα οι πραγματικές τιμές να βρίσκονται μέσα σε αυτή την περιοχή.

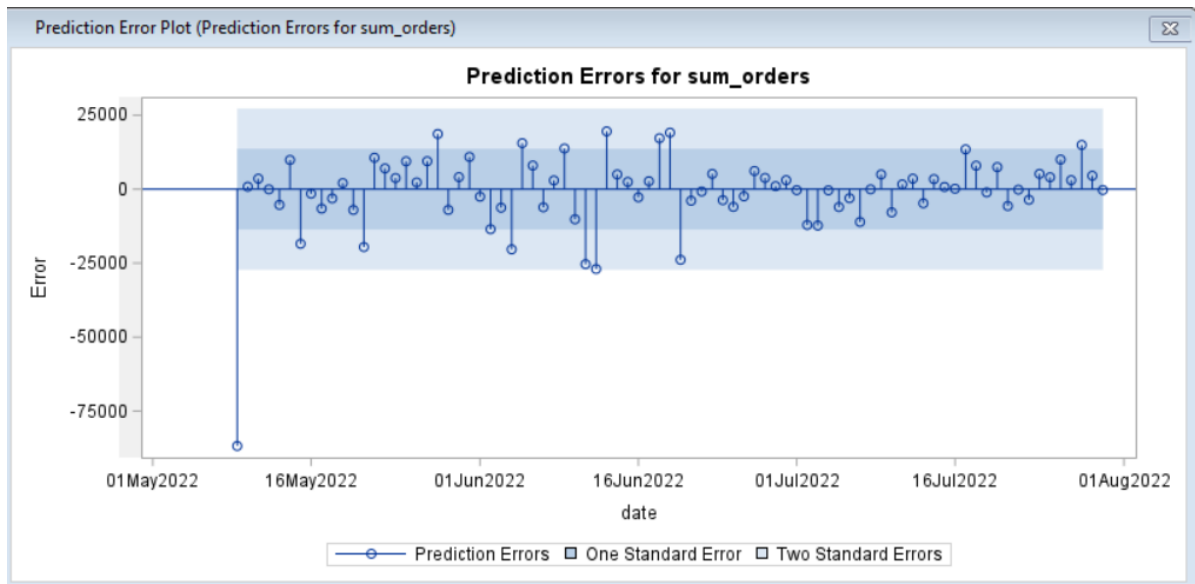


Εικόνα 8: Πραγματικές και προβλεπόμενες τιμές για τις συνολικές παραγγελίες σε μια χρονοσειρά

Οι προβλεπόμενες τιμές ακολουθούν τη γενική τάση των πραγματικών δεδομένων μέχρι το σημείο όπου ξεκινούν οι προβλέψεις. Μετά από αυτό το σημείο, η πρόβλεψη συνεχίζει να ακολουθεί μια παρόμοια τάση, αλλά η αβεβαιότητα αυξάνεται, όπως φαίνεται από την ευρύτερη περιοχή του διαστήματος εμπιστοσύνης. Η σχετική στενότητα του διαστήματος εμπιστοσύνης, κατά την ιστορική περίοδο, και η συνεπής πορεία των προβλέψεων, σε σχέση με τα πραγματικά δεδομένα, υποδηλώνουν ότι το μοντέλο είναι αρκετά ακριβές στις προβλέψεις του. Ωστόσο, η αύξηση της αβεβαιότητας στις μελλοντικές προβλέψεις είναι αναμενόμενη, με τη σταδιακή απομάκρυνση από το σημείο όπου υπάρχουν διαθέσιμα δεδομένα. Αυτή η αβεβαιότητα παρουσιάζεται με το ευρύτερο διάστημα εμπιστοσύνης στις μελλοντικές περιόδους.

Στην πράξη, αυτό το γράφημα μπορεί να χρησιμοποιηθεί για να καθοδηγήσει τις αποφάσεις για σχεδιασμό και προετοιμασία σε σχέση με τις προσδοκώμενες παραγγελίες. Το διάστημα εμπιστοσύνης παρέχει μια ένδειξη για την αβεβαιότητα των προβλέψεων και μπορεί να βοηθήσει την επιχείρηση να προβλέψει τους κινδύνους και να προετοιμάσει στρατηγικές αντιμετώπισης. Η ακριβής αξιολόγηση του μοντέλου, ωστόσο, θα απαιτούσε περαιτέρω ανάλυση των προβλέψεων σε σχέση με τις πραγματικές τιμές, καθώς και την ανάλυση της απόδοσης του μοντέλου μέσα στο χρόνο.

Στην Εικόνα 9 παρουσιάζεται ένα γράφημα σφαλμάτων πρόβλεψης για το συνολικό αριθμό των παραγγελιών (sum\_orders). Τα σφάλματα πρόβλεψης είναι η διαφορά μεταξύ των πραγματικών και των προβλεπόμενων τιμών από ένα στατιστικό μοντέλο. Οι μπλε κύκλοι αντιπροσωπεύουν τα επιμέρους σφάλματα πρόβλεψης για κάθε σημείο στο χρόνο. Η γαλάζια περιοχή γύρω από το μηδέν στον άξονα των Y (σφάλματα) δείχνει το εύρος ενός τυπικού σφάλματος γύρω από τη μηδενική γραμμή, ενώ η πιο σκούρα γαλάζια περιοχή δείχνει το εύρος δύο τυπικών σφαλμάτων. Τυπικά, τα σφάλματα πρόβλεψης πρέπει να είναι τυχαία διάσπαρτα γύρω από τη μηδενική γραμμή (το ιδανικό σημείο όπου οι προβλέψεις είναι ακριβώς ίσες με τις πραγματικές τιμές) και τα περισσότερα από αυτά πρέπει να βρίσκονται μέσα στο εύρος του ενός τυπικού σφάλματος.



Εικόνα 9: Γράφημα σφαλμάτων πρόβλεψης για τις συνολικές παραγγελίες για το μοντέλο ARIMA

Στο συγκεκριμένο διάγραμμα, το γεγονός ότι τα περισσότερα σφάλματα πρόβλεψης βρίσκονται εντός του εύρους ενός τυπικού σφάλματος και σχεδόν όλα εντός του διπλού τυπικού σφάλματος, υποδεικνύει ότι το μοντέλο προβλέπει τις τιμές με αρκετή ακρίβεια. Ωστόσο, υπάρχουν κάποια σημεία με σημαντικά μεγάλα σφάλματα, ειδικά εκείνο που δείχνει ένα σφάλμα μεγαλύτερο από 75,000. Αυτά τα σημεία μπορεί να χρειαστεί να εξεταστούν περαιτέρω για να διευκρινιστεί αν υπάρχουν κάποια προβλήματα με τα δεδομένα, το μοντέλο ή εξωτερικοί παράγοντες που επηρεάζουν τις προβλέψεις. Γενικά, το γράφημα δίνει μια οπτική αναπαράσταση της ποιότητας των προβλέψεων του μοντέλου και μπορεί να βοηθήσει στην αξιολόγηση και την περαιτέρω βελτίωσή του.

## 4.2.2 Ανάλυση με Python

Αφού ολοκλήρωσα την αρχική ανάλυση χρησιμοποιώντας το λογισμικό SAS, προχώρησα στην υλοποίηση της ανάλυσης με τη χρήση της γλώσσας Python. Η μετάβαση στην Python επιλέχθηκε για την ευελιξία και τις ισχυρές δυνατότητές της στη διαχείριση χρονοσειρών και τη δημιουργία προβλέψεων μέσω των βιβλιοθηκών statsmodels και pandas. Με αυτόν τον τρόπο, η προεπεξεργασία των δεδομένων και η εφαρμογή των μοντέλων ARIMA και SARIMA έγιναν με μεγαλύτερη ακρίβεια και ταχύτητα, ενώ η Python προσέφερε επιπλέον δυνατότητες για τη βελτιστοποίηση της ανάλυσης.

Τα δεδομένα που χρησιμοποιήθηκαν για την ανάλυση περιλάμβαναν ωριαίες παραγγελίες από καταστήματα πιτσαρίας στη Θεσσαλονίκη. Για να γίνει δυνατή η εφαρμογή των μοντέλων ARIMA και SARIMA, ήταν απαραίτητη η κατάλληλη προεπεξεργασία των δεδομένων. Συγκεκριμένα, τα δεδομένα επεξεργάστηκαν ώστε να μετατραπούν σε μορφή χρονοσειρών.

Πρώτο βήμα της προεπεξεργασίας ήταν η μετατροπή της στήλης timestamp σε μορφή ημερομηνίας και ώρας μέσω της μεθόδου `pd.to_datetime`. Με αυτόν τον τρόπο, η χρονική σφραγίδα των παραγγελιών έγινε συμβατή με τη χρονοσειρά που χρησιμοποιούν τα μοντέλα. Ακολούθως, τα δεδομένα ανακατασκευάστηκαν με το `pd.date_range`, ώστε να συμπεριλάβουν όλες τις ώρες εντός της χρονικής περιόδου. Τυχόν κενές τιμές στη στήλη `sum_orders` συμπληρώθηκαν με τη μέθοδο της προώθησης (`ffill`), διασφαλίζοντας τη συνέπεια των δεδομένων.

Μετά τον καθαρισμό των δεδομένων, δημιουργήθηκαν χρονοσειρές παραγγελιών έτοιμες για την ανάλυση με τα μοντέλα ARIMA και SARIMA.

Αφού προετοιμάστηκαν τα δεδομένα, προχώρησα στην εφαρμογή των μοντέλων ARIMA και SARIMA για την πρόβλεψη των παραγγελιών. Το μοντέλο ARIMA διαμορφώθηκε με τάξη (2, 1, 2), δηλαδή με δύο όρους αυτοπαλινδρόμησης (AR), μία διαφορά και δύο όρους κινούμενου μέσου (MA). Αυτή η παραμετροποίηση επελέγη για να αποτυπώσει τις τάσεις της χρονοσειράς χωρίς να υπερεκτιμά τις διακυμάνσεις. Παράλληλα, το μοντέλο SARIMA ορίστηκε με τάξη (2, 1, 2) και εποχικές παραμέτρους (1, 1, 1, 12), που το καθιστούν ικανό να ανιχνεύει περιοδικές αυξομειώσεις στις παραγγελίες κατά τις ώρες αιχμής ή τις εποχικές τάσεις που παρατηρούνται. Τα δύο μοντέλα εκπαιδεύτηκαν και εφαρμόστηκαν για την παραγωγή προβλέψεων για τις επόμενες 48 ώρες, με τη χρήση των υφιστάμενων δεδομένων.

Για την αποφυγή πρόβλεψης σε ώρες με χαμηλή ζήτηση, εφαρμόστηκε ένα φίλτρο ώστε να συμπεριληφθούν μόνο οι ώρες από τις 9:00 π.μ. έως τις 3:00 π.μ. Αυτές είναι οι ώρες που σημειώνονται οι περισσότερες παραγγελίες, κι έτσι το φίλτρο διασφαλίζει ότι οι προβλέψεις εστιάζουν στις ώρες αιχμής, εξαλείφοντας δεδομένα με λιγότερη σημασία.

Μετά την υλοποίηση των μοντέλων ARIMA και SARIMA, προέκυψαν τα παρακάτω αποτελέσματα προβλέψεων από τους δυο αλγόριθμους:

- **ARIMA Predictions:**

Time	ARIMA Predicted Orders
2022-07-31 00:00:00+00:00	2022-07-31 00:00:00+00:00 183.474007
2022-07-31 01:00:00+00:00	2022-07-31 01:00:00+00:00 141.490326
2022-07-31 02:00:00+00:00	2022-07-31 02:00:00+00:00 132.359005
2022-07-31 03:00:00+00:00	2022-07-31 03:00:00+00:00 136.854038
2022-07-31 09:00:00+00:00	2022-07-31 09:00:00+00:00 156.246753
2022-07-31 10:00:00+00:00	2022-07-31 10:00:00+00:00 156.044489
2022-07-31 11:00:00+00:00	2022-07-31 11:00:00+00:00 155.852224
2022-07-31 12:00:00+00:00	2022-07-31 12:00:00+00:00 155.724866
2022-07-31 13:00:00+00:00	2022-07-31 13:00:00+00:00 155.659485
2022-07-31 14:00:00+00:00	2022-07-31 14:00:00+00:00 155.635251
2022-07-31 15:00:00+00:00	2022-07-31 15:00:00+00:00 155.632188
2022-07-31 16:00:00+00:00	2022-07-31 16:00:00+00:00 155.637001
2022-07-31 17:00:00+00:00	2022-07-31 17:00:00+00:00 155.642835
2022-07-31 18:00:00+00:00	2022-07-31 18:00:00+00:00 155.647132
2022-07-31 19:00:00+00:00	2022-07-31 19:00:00+00:00 155.649550
2022-07-31 20:00:00+00:00	2022-07-31 20:00:00+00:00 155.650580
2022-07-31 21:00:00+00:00	2022-07-31 21:00:00+00:00 155.650829



2022-07-31 22:00:00+00:00	2022-07-31 22:00:00+00:00	155.650743
2022-07-31 23:00:00+00:00	2022-07-31 23:00:00+00:00	155.650576
2022-08-01 00:00:00+00:00	2022-08-01 00:00:00+00:00	155.650435
2022-08-01 01:00:00+00:00	2022-08-01 01:00:00+00:00	155.650349
2022-08-01 02:00:00+00:00	2022-08-01 02:00:00+00:00	155.650308
2022-08-01 03:00:00+00:00	2022-08-01 03:00:00+00:00	155.650295
2022-08-01 09:00:00+00:00	2022-08-01 09:00:00+00:00	155.650309
2022-08-01 10:00:00+00:00	2022-08-01 10:00:00+00:00	155.650309
2022-08-01 11:00:00+00:00	2022-08-01 11:00:00+00:00	155.650309
2022-08-01 12:00:00+00:00	2022-08-01 12:00:00+00:00	155.650309
2022-08-01 13:00:00+00:00	2022-08-01 13:00:00+00:00	155.650309
2022-08-01 14:00:00+00:00	2022-08-01 14:00:00+00:00	155.650308
2022-08-01 15:00:00+00:00	2022-08-01 15:00:00+00:00	155.650308
2022-08-01 16:00:00+00:00	2022-08-01 16:00:00+00:00	155.650308
2022-08-01 17:00:00+00:00	2022-08-01 17:00:00+00:00	155.650308
2022-08-01 18:00:00+00:00	2022-08-01 18:00:00+00:00	155.650308
2022-08-01 19:00:00+00:00	2022-08-01 19:00:00+00:00	155.650308
2022-08-01 20:00:00+00:00	2022-08-01 20:00:00+00:00	155.650308
2022-08-01 21:00:00+00:00	2022-08-01 21:00:00+00:00	155.650308
2022-08-01 22:00:00+00:00	2022-08-01 22:00:00+00:00	155.650308
2022-08-01 23:00:00+00:00	2022-08-01 23:00:00+00:00	155.650308

- **SARIMA Predictions:**

Time SARIMA Predicted Orders		
2022-07-31 00:00:00+00:00	2022-07-31 00:00:00+00:00	149.471133
2022-07-31 01:00:00+00:00	2022-07-31 01:00:00+00:00	100.020154
2022-07-31 02:00:00+00:00	2022-07-31 02:00:00+00:00	58.772475
2022-07-31 03:00:00+00:00	2022-07-31 03:00:00+00:00	43.259826
2022-07-31 09:00:00+00:00	2022-07-31 09:00:00+00:00	75.779287
2022-07-31 10:00:00+00:00	2022-07-31 10:00:00+00:00	72.895245
2022-07-31 11:00:00+00:00	2022-07-31 11:00:00+00:00	20.130670
2022-07-31 12:00:00+00:00	2022-07-31 12:00:00+00:00	27.043713


2022-07-31 13:00:00+00:00	2022-07-31 13:00:00+00:00	107.859152
2022-07-31 14:00:00+00:00	2022-07-31 14:00:00+00:00	151.321343
2022-07-31 15:00:00+00:00	2022-07-31 15:00:00+00:00	137.691916
2022-07-31 16:00:00+00:00	2022-07-31 16:00:00+00:00	144.545049
2022-07-31 17:00:00+00:00	2022-07-31 17:00:00+00:00	121.816563
2022-07-31 18:00:00+00:00	2022-07-31 18:00:00+00:00	118.604966
2022-07-31 19:00:00+00:00	2022-07-31 19:00:00+00:00	152.780408
2022-07-31 20:00:00+00:00	2022-07-31 20:00:00+00:00	292.298908
2022-07-31 21:00:00+00:00	2022-07-31 21:00:00+00:00	480.309443
2022-07-31 22:00:00+00:00	2022-07-31 22:00:00+00:00	390.259785
2022-07-31 23:00:00+00:00	2022-07-31 23:00:00+00:00	231.667648
2022-08-01 00:00:00+00:00	2022-08-01 00:00:00+00:00	124.479500
2022-08-01 01:00:00+00:00	2022-08-01 01:00:00+00:00	100.909630
2022-08-01 02:00:00+00:00	2022-08-01 02:00:00+00:00	76.495639
2022-08-01 03:00:00+00:00	2022-08-01 03:00:00+00:00	61.421708
2022-08-01 09:00:00+00:00	2022-08-01 09:00:00+00:00	155.365427
2022-08-01 10:00:00+00:00	2022-08-01 10:00:00+00:00	135.256718
2022-08-01 11:00:00+00:00	2022-08-01 11:00:00+00:00	61.580715
2022-08-01 12:00:00+00:00	2022-08-01 12:00:00+00:00	45.942563
2022-08-01 13:00:00+00:00	2022-08-01 13:00:00+00:00	106.129716
2022-08-01 14:00:00+00:00	2022-08-01 14:00:00+00:00	136.175780
2022-08-01 15:00:00+00:00	2022-08-01 15:00:00+00:00	122.263397
2022-08-01 16:00:00+00:00	2022-08-01 16:00:00+00:00	123.184071
2022-08-01 17:00:00+00:00	2022-08-01 17:00:00+00:00	106.523119
2022-08-01 18:00:00+00:00	2022-08-01 18:00:00+00:00	107.685620
2022-08-01 19:00:00+00:00	2022-08-01 19:00:00+00:00	139.145108
2022-08-01 20:00:00+00:00	2022-08-01 20:00:00+00:00	258.411496
2022-08-01 21:00:00+00:00	2022-08-01 21:00:00+00:00	415.732303
2022-08-01 22:00:00+00:00	2022-08-01 22:00:00+00:00	339.504961
2022-08-01 23:00:00+00:00	2022-08-01 23:00:00+00:00	197.698171

Αναλύοντας τα αποτελέσματα των προβλέψεων που παρήχθησαν από τα μοντέλα ARIMA και SARIMA, διακρίνονται σημαντικές διαφορές στην απόδοση και τη συμπεριφορά των δύο αλγορίθμων,

ειδικά σε ό,τι αφορά την ανταπόκρισή τους στις εποχικές διακυμάνσεις των δεδομένων. Το μοντέλο ARIMA παράγει σχετικά σταθερές τιμές προβλέψεων που κυμαίνονται μεταξύ 132.36 και 183.47, αλλά σταθεροποιούνται γρήγορα στο επίπεδο περίπου 155.65. Αυτό δείχνει ότι το μοντέλο ARIMA αποτυγχάνει να προσαρμοστεί στις εποχικές μεταβολές και προσεγγίζει τα δεδομένα με μια πιο γενικευμένη ή "ομαλή" μέθοδο, παράγοντας προβλέψεις που φαίνονται να αγνοούν τις ώρες υψηλής διακύμανσης. Αντίθετα, το μοντέλο SARIMA δείχνει σημαντικά μεγαλύτερη διακύμανση στις τιμές προβλέψεων, με τις τιμές να κυμαίνονται από 20.13 έως 480.31, αντανakλώντας τις εποχικές μεταβολές στα δεδομένα. Συγκεκριμένα, το SARIMA παρουσιάζει υψηλότερες τιμές προβλέψεων κατά τις βραδινές ώρες, όπου πιθανώς υπάρχει μεγαλύτερη δραστηριότητα ή ζήτηση, κάτι που το ARIMA αποτυγχάνει να αποτυπώσει.

Η παραπάνω σύγκριση αποκαλύπτει ότι το μοντέλο SARIMA είναι καλύτερα προσαρμοσμένο για δεδομένα με εποχικότητα και προσφέρει πιο δυναμικές και ρεαλιστικές προβλέψεις για σενάρια όπου οι χρονοσειρές εκδηλώνουν σαφείς μεταβολές βάσει ώρας ή άλλων εποχικών παραγόντων. Το ARIMA, ενώ μπορεί να είναι χρήσιμο σε περιπτώσεις με λιγότερο περίπλοκα ή μη εποχικά δεδομένα, φαίνεται να αποδίδει λιγότερο ικανοποιητικά όταν τα δεδομένα παρουσιάζουν σημαντικές εποχικές διακυμάνσεις.

Βάσει των αποτελεσμάτων που εξήχθησαν από τα δύο μοντέλα προκύπτουν τα ακόλουθα διαγράμματα, τα οποία αναπαριστούν τις μέσες και μέγιστες τιμές παραγγελιών ανά ώρα και ανά ημέρα (Εικόνα 10):




Εικόνα 10: Μέσες και μέγιστες τιμές παραγγελιών ανά ώρα και ανά ημέρα

Σύμφωνα με το διάγραμμα Mean Orders per Hour, εμφανίζεται μια έντονη κορύφωση των παραγγελιών περί τις 19:00, με τον αριθμό τους να φθάνει σχεδόν τις 600. Παρατηρείται μια επίσης αυξημένη δραστηριότητα περίπου στις 14:00, αλλά με λιγότερες παραγγελίες (κάτω των 200). Μετά τις 23:00 ο αριθμός των παραγγελιών μειώνεται δραστικά. Από το διάγραμμα Max Orders per Hour εντοπίζεται η μέγιστη κορύφωση των παραγγελιών επίσης γύρω στις 19:00, ξεπερνώντας τις 1800 παραγγελίες σε μια ώρα, ενώ ταυτόχρονα παρατηρείται πολύ μεγάλη διακύμανση σε σχέση με τις άλλες ώρες. Αυτή η κορύφωση αντανakλά πιθανά μια τυπική ώρα δείπνου, όπου η ζήτηση είναι στο αποκορύφωμα. Από την εξέταση του διαγράμματος Mean Orders per Day, εντοπίζεται μεγάλη διακύμανση μεταξύ των ημερών, με τις μέσες παραγγελίες να κυμαίνονται από κάτω από 200 έως πάνω από 275. Οι περίοδοι υψηλής δραστηριότητας ενδέχεται να συνδέονται με τοπικά γεγονότα ή άλλους εποχικούς παράγοντες. Τέλος, σύμφωνα με το διάγραμμα Max Orders per Day, εμφανίζονται μεγάλες ακραίες τιμές σε συγκεκριμένες ημέρες, με τις μέγιστες παραγγελίες να φθάνουν σχεδόν τις 2000 σε μια ημέρα.

Ως συμπέρασμα, τα παραπάνω διαγράμματα καταδεικνύουν την ανάγκη για μοντέλα που μπορούν να χειριστούν την εποχικότητα και τη μεγάλη διακύμανση στις παραγγελίες. Το SARIMA, εξαιτίας της δυνατότητάς του να προσαρμόζεται σε εποχικές μεταβολές, είναι πιθανόν πιο κατάλληλο για αυτό το είδος δεδομένων σε σύγκριση με το ARIMA, το οποίο συχνά αποδεικνύεται υποδεέστερο σε συνθήκες στις οποίες υπάρχουν σημαντικές εποχικές διακυμάνσεις.


Το διάγραμμα της Εικόνας 11 αναπαριστά τον κυλιόμενο μέσο όρο παραγγελιών 7 ημερών για ένα διάστημα περίπου τριών μηνών, από τις αρχές Μαΐου έως τα τέλη Ιουλίου 2022.



Εικόνα 11: 7ήμερος κυλιόμενος μέσος όρος παραγγελιών

Το διάγραμμα απεικονίζει ξεκάθαρες κορυφές και κοιλάδες, που υποδηλώνουν κυκλικότητα στον αριθμό των παραγγελιών. Οι κορυφές φαίνεται να εμφανίζονται περίπου κάθε δύο εβδομάδες, υποδηλώνοντας μια επαναλαμβανόμενη αύξηση στη ζήτηση. Ο μέσος όρος των παραγγελιών κυμαίνεται από περίπου 3000 έως 5000 παραγγελίες, με τις μεγαλύτερες διακυμάνσεις να εμφανίζονται κατά τη διάρκεια των μηνών Μαΐου και Ιουνίου. Επιπρόσθετα, προς τα τέλη της παρατηρούμενης περιόδου, φαίνεται να υπάρχει μια τάση μείωσης της μέσης τιμής των παραγγελιών, καθώς οι τελευταίες τιμές του κυλιόμενου μέσου όρου είναι σχετικά χαμηλότερες από τις αρχικές.

Τέλος, το διάγραμμα της Εικόνας 12 δείχνει τις προβλέψεις παραγγελιών από τα μοντέλα ARIMA και SARIMA για μερικές ημέρες σε επιλεγμένες, φιλτραρισμένες ώρες. Η παρουσίαση των προβλέψεων αυτών προσφέρει μια άμεση σύγκριση των δύο μοντέλων σε σχέση με την αναπαράσταση της δυναμικής των παραγγελιών.



Εικόνα 12: Προβλέψεις παραγγελιών από τα μοντέλα ARIMA και SARIMA σε επιλεγμένες ημέρες και ώρες

Τα αποτελέσματα από το μοντέλο ARIMA αναπαρίστανται με κόκκινη γραμμή (ARIMA Predictions) και δείχνουν πολύ σταθερές προβλέψεις, με ελάχιστη μεταβλητότητα. Οι προβλέψεις αυτές διατηρούνται σε σχετικά χαμηλό επίπεδο σε σχέση με τις πραγματικές μεταβολές της ζήτησης που εμφανίζονται στο διάγραμμα. Αυτό υποδεικνύει ότι το μοντέλο ARIMA μπορεί να μην καταφέρνει να αποτυπώσει αποτελεσματικά τις εποχικές διακυμάνσεις ή τις ώρες αιχμής που είναι κρίσιμες για την επιχείρηση. Αντίθετα, τα αποτελέσματα από το μοντέλο SARIMA, που εμφανίζονται με πράσινη γραμμή (SARIMA Predictions), δείχνουν σημαντικά μεγαλύτερη μεταβλητότητα στις προβλέψεις, με δύο σημαντικές κορυφές, οι οποίες υποδεικνύουν τις ώρες αιχμής. Οι προβλέψεις αυτές είναι περισσότερο σύμφωνες με τις περιόδους υψηλής ζήτησης, γεγονός που δείχνει ότι το SARIMA καταφέρνει να αποτυπώσει καλύτερα την εποχική συμπεριφορά των δεδομένων.

Ως τελικό συμπέρασμα, το μοντέλο SARIMA φαίνεται να είναι καταλληλότερο για περιπτώσεις όπου οι παραγγελίες δείχνουν σημαντική εποχικότητα και μεγάλη μεταβλητότητα. Η ικανότητά του να προσαρμόζεται στις ώρες αιχμής το κάνει ιδανικό για χρήση σε επιχειρήσεις όπως εστιατόρια ή υπηρεσίες παράδοσης. Από την άλλη πλευρά, το μοντέλο ARIMA μπορεί να είναι κατάλληλο για πιο ομοιόμορφες ή λιγότερο εποχικές χρονοσειρές, αλλά φαίνεται να αποτυγχάνει στην αποτύπωση των απότομων διακυμάνσεων της ζήτησης, οι οποίες είναι κρίσιμες για την προβλεπτική ανάλυση στο συγκεκριμένο πλαίσιο. Η κατανόηση των διαφορών στην απόδοση αυτών των δύο μοντέλων προσφέρει σημαντικές ενδείξεις για την επιλογή του κατάλληλου μοντέλου ανάλογα με τη φύση των δεδομένων και τις συγκεκριμένες ανάγκες της επιχείρησης.

### 4.2.3 Μοντέλο GS

Το μοντέλο Generalized Smoothing ή Generalized Additive Model (GAM) αποτελεί μια ευέλικτη μέθοδο, η οποία μπορεί να αντιληφθεί σύνθετες, μη γραμμικές σχέσεις στα δεδομένα. Η αναφορά σε ένα Generalized Smoothing μοντέλο με ένα holdout MAPE 8.81% υπονοεί ότι όταν το μοντέλο εφαρμόστηκε σε μια συλλογή δεδομένων που δεν είχε δει κατά την εκπαίδευση (holdout set), το μέσο απόλυτο ποσοστιαίο σφάλμα πρόβλεψης ήταν 8.81%. Αυτός ο δείκτης MAPE είναι υψηλότερος από το 5.33%, που παρατηρήθηκε από το μοντέλο ARIMA για τα ίδια δεδομένα, υποδηλώνοντας ότι το μοντέλο ARIMA έχει καλύτερη απόδοση στην εν λόγω περίπτωση. Ωστόσο, οι αριθμοί MAPE δεν πρέπει να εξετάζονται απομονωμένα. Ανάλογα με την εφαρμογή και τις συνθήκες των δεδομένων, ένα

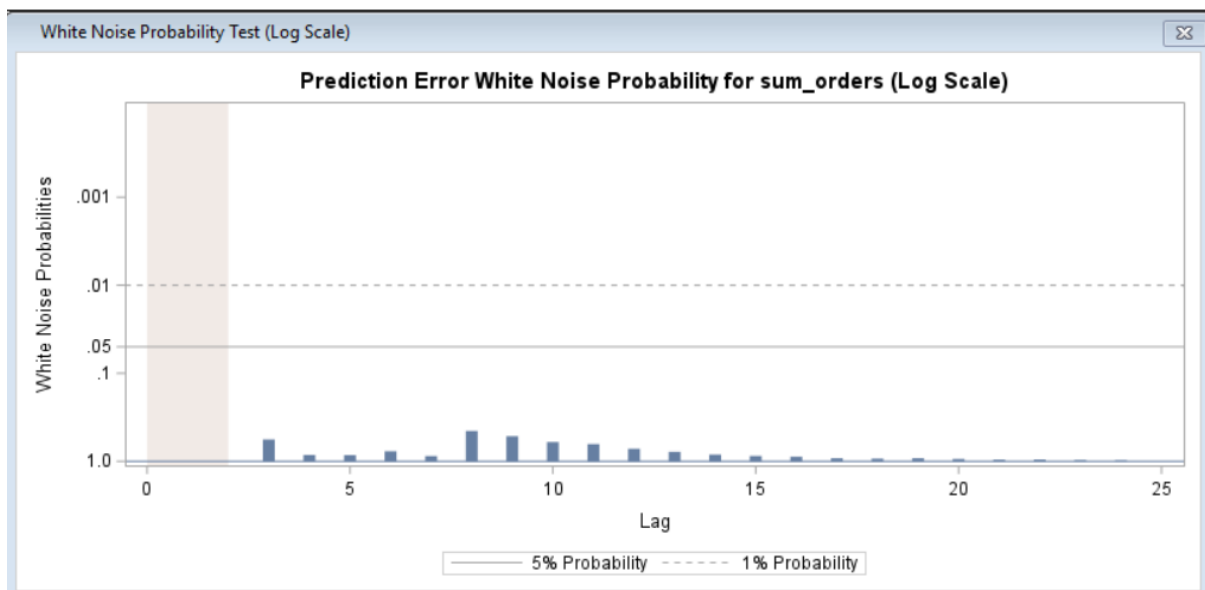
μοντέλο με υψηλότερο MAPE μπορεί να προτιμάται για διάφορους λόγους, όπως η καλύτερη σύλληψη της εποχικότητας, της τάσης ή ακόμα και της γενικής αστάθειας των δεδομένων.

Οι λόγοι για τους οποίους το μοντέλο GS δεν απέδωσε εξίσου καλά με το μοντέλο ARIMA, μπορεί να οφείλεται σε πολλούς παράγοντες, όπως:

- Τα δεδομένα δεν παρουσιάζουν ισχυρή, μη γραμμική δομή, η οποία είναι απαραίτητη για την καλή απόδοση του GS.
- Οι παράμετροι του μοντέλου GS δεν έχουν ρυθμιστεί σωστά για να αποτυπώσουν τα δεδομένα.
- Ενδέχεται να υπάρχουν εξωγενείς μεταβλητές ή παράγοντες που δεν έχουν συμπεριληφθεί στο μοντέλο GS, αλλά είναι κρίσιμοι για την πρόβλεψη των παραγγελιών.

Συνεπώς, ενώ ένα μοντέλο αποδίδει καλύτερα σε ένα σύνολο δεδομένων, μπορεί να μην είναι το καλύτερο γενικά ή σε διαφορετικές συνθήκες. Είναι πάντα καλή πρακτική να γίνεται εκτίμηση πολλαπλών μοντέλων, ώστε να επιλεγεί αυτό που παρουσιάζει καλύτερη απόδοση για το συγκεκριμένο σκοπό.

Το γράφημα της Εικόνας 13 φαίνεται παρόμοιο με αυτό της Εικόνας 5. Απεικονίζει τη δοκιμή λευκού θορύβου για τα σφάλματα πρόβλεψης ενός στατιστικού μοντέλου, αυτή τη φορά για το μοντέλο GS. Όπως και στην περίπτωση του ARIMA, αυτός ο τύπος γραφήματος είναι χρήσιμος για να αξιολογήσει ο χρήστης εάν τα υπόλοιπα (residuals) από ένα μοντέλο είναι απλά τυχαία θόρυβος. Δηλαδή, ότι το μοντέλο έχει καταφέρει να αποτυπώσει όλες τις δομικές πληροφορίες στα δεδομένα ή εάν υπάρχουν ακόμη κάποια μοτίβα που το μοντέλο δεν έχει αντιληφθεί. Οι κάθετες μπάρες αντιπροσωπεύουν την πιθανότητα των σφαλμάτων πρόβλεψης να είναι τυχαία σε κάθε υστέρηση lag. Εάν οι τιμές είναι κάτω από το επίπεδο του 5% (ή 1%), τότε ενδέχεται να ισχύει η υπόθεση ότι τα σφάλματα είναι λευκός θόρυβος σε αυτή την υστέρηση.



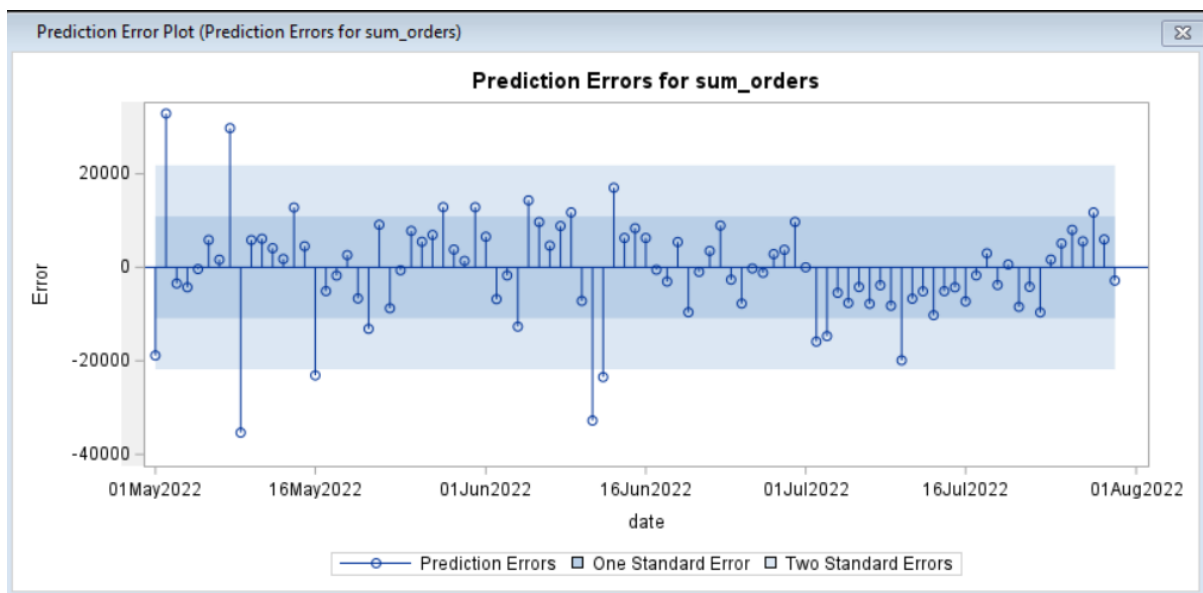
Εικόνα 13: Δοκιμή λευκού θορύβου για τις προβλέψεις σφαλμάτων από το μοντέλο GS

Στο συγκεκριμένο γράφημα, φαίνεται ότι για τα περισσότερα lags οι μπάρες βρίσκονται κάτω από την γραμμή του 5%, υποδηλώνοντας ότι τα σφάλματα πρόβλεψης για το δεύτερο μοντέλο δεν είναι στατιστικά διαφορετικά από λευκό θόρυβο για την πλειονότητα των υστερήσεων. Αυτό υποδηλώνει ότι το μοντέλο έχει καταφέρει να εξηγήσει τη δομή των δεδομένων αρκετά καλά και τα σφάλματα που απομένουν δεν έχουν κάποιο εμφανές μοτίβο ή δομή που θα μπορούσε να αντιμετωπιστεί περαιτέρω.

Συγκριτικά με το πρώτο μοντέλο (ARIMA), αυτός ο έλεγχος δε δείχνει απαραίτητα ότι το δεύτερο μοντέλο είναι κατώτερο, αλλά το υψηλότερο MAPE υποδεικνύει ότι το ARIMA μπορεί να

έχει καλύτερη συνολική απόδοση σε αυτή την περίπτωση. Ωστόσο, αξίζει να σημειωθεί ότι το MAPE είναι μια μέτρηση που βασίζεται στο απόλυτο σφάλμα πρόβλεψης και μπορεί να επηρεαστεί από διάφορους παράγοντες, συμπεριλαμβανομένων ακραίων τιμών ή την παρουσία τάσεων και εποχικότητας στα δεδομένα.

Το γράφημα της Εικόνας 14 είναι ένα διάγραμμα σφαλμάτων πρόβλεψης για το μοντέλο Generalized Smoothing, δηλαδή, των διαφορών μεταξύ των προβλεπόμενων και των πραγματικών τιμών για τις συνολικές παραγγελίες (sum\_orders) κατά την περίοδο του μοντέλου που εξετάζεται. Στο διάγραμμα, οι μπλε κύκλοι αντιπροσωπεύουν τα επιμέρους σφάλματα πρόβλεψης. Οι γραμμές που εκτείνονται προς τα επάνω και προς τα κάτω από κάθε κύκλο δείχνουν την περιοχή ενός και δύο τυπικών σφαλμάτων γύρω από την πρόβλεψη, δίνοντας μια ένδειξη για την αβεβαιότητα κάθε πρόβλεψης.

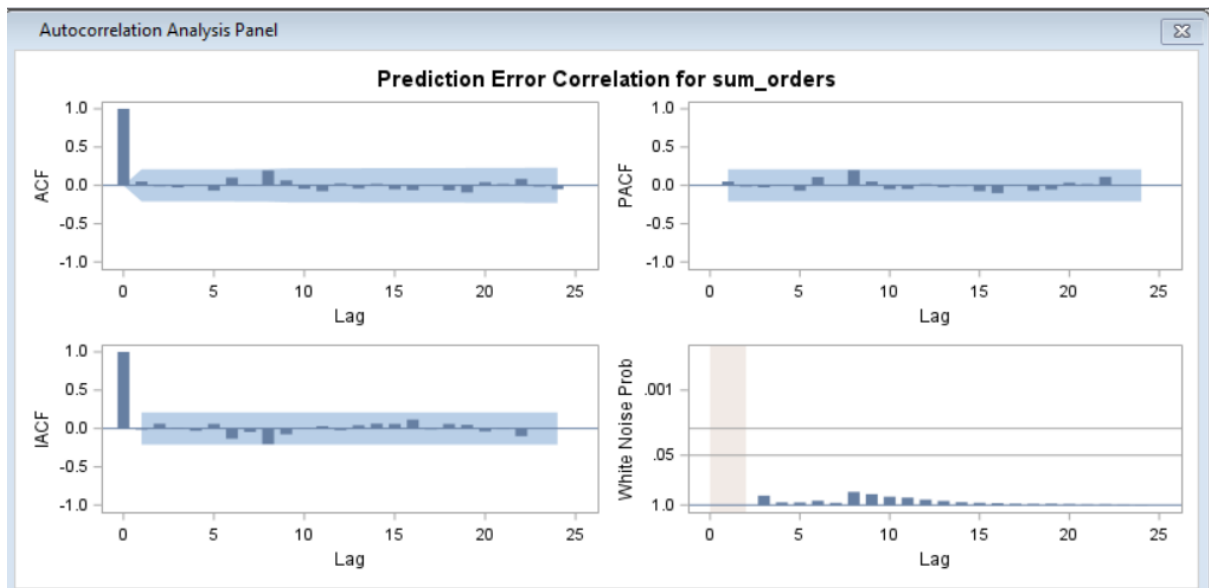


Εικόνα 14: Γράφημα σφαλμάτων πρόβλεψης για τις συνολικές παραγγελίες για το μοντέλο GS

Συγκρίνοντας αυτό το γράφημα με το αντίστοιχο του μοντέλου ARIMA, εξάγονται οι εξής παρατηρήσεις:

1. Τα σφάλματα φαίνεται να είναι διάσπαρτα γύρω από το μηδέν, δείχνοντας ότι δεν υπάρχει συστηματική προκατάληψη στο μοντέλο.
2. Η διακύμανση των σφαλμάτων πρόβλεψης απεικονίζεται συγκριτικά μεγάλη, καθώς υπάρχουν πολλά σημεία που ξεπερνούν την περιοχή ενός τυπικού σφάλματος και μερικά που ξεπερνούν ακόμα και την περιοχή δύο τυπικών σφαλμάτων.
3. Φαίνεται να υπάρχει ένα συγκεκριμένο σφάλμα πρόβλεψης που είναι σημαντικά μεγάλο (περίπου -40000), το οποίο θα μπορούσε να δείχνει ένα συγκεκριμένο σημείο όπου το μοντέλο απέτυχε να αντιληφθεί σωστά την πραγματικότητα ή όπου ένα ασυνήθιστο γεγονός επηρέασε τις παραγγελίες. Τα σημεία με μεγάλα σφάλματα είναι σημαντικά γιατί μπορεί να υποδεικνύουν ατέλειες στο μοντέλο ή να είναι ενδείξεις για εξωτερικούς παράγοντες ή εκδηλώσεις που δεν έχουν ενσωματωθεί στην ανάλυση. Οι αναλυτές θα πρέπει να εξετάσουν αυτά τα σημεία και να προσδιορίσουν αν υπάρχει ένα συγκεκριμένο μοτίβο ή αιτία που προκαλεί τα μεγάλα σφάλματα, ή εάν είναι απλώς τυχαίες αποκλίσεις.

Τα γραφήματα στην Εικόνα 15 είναι μια συνολική απεικόνιση της ανάλυσης αυτοσυσχέτισης που αποτυπώνει τόσο την αυτοσυσχέτιση (ACF) όσο και τη μερική αυτοσυσχέτιση (PACF) των σφαλμάτων πρόβλεψης από το μοντέλο GS, καθώς και ένα γράφημα πιθανότητας λευκού θορύβου για τα ίδια σφάλματα. Είναι αντίστοιχα με τα γραφήματα της Εικόνας 6 για το μοντέλο ARIMA.



Εικόνα 15: Γραφήματα σχετικά με την αυτοσυσχέτιση των σφαλμάτων πρόβλεψης στο μοντέλο GS

Πιο αναλυτικά, τα τρία γραφήματα εξηγούνται ως εξής:


1. **Αυτοσυσχέτιση (ACF):** Το επάνω αριστερά γράφημα δείχνει ότι η ACF για την υστέρηση 0 είναι στο 1, όπως αναμένεται, αφού κάθε σειρά θα συσχετίζεται τέλεια με τον εαυτό της σε αυτή την υστέρηση. Οι υπόλοιπες τιμές ACF είναι κοντά στο μηδέν και μέσα στα στατιστικά σημαντικά επίπεδα, υποδεικνύοντας ότι δεν υπάρχει ισχυρή αυτοσυσχέτιση στα σφάλματα πρόβλεψης για τα διάφορα lags.
2. **Μερική Αυτοσυσχέτιση (PACF):** Το επάνω δεξιά γράφημα δείχνει τη μερική αυτοσυσχέτιση, η οποία είναι επίσης κοντά στο μηδέν για όλες τις υστερήσεις. Αυτό υποδηλώνει ότι οι τιμές της σειράς δε συσχετίζονται με παρελθοντικές τιμές πέρα από άλλες που έχουν ήδη ληφθεί υπόψιν.
3. **Δοκιμή λευκού θορύβου:** Το κάτω δεξιά γράφημα αναφέρεται στη δοκιμή λευκού θορύβου. Όπως και στα προηγούμενα διαγράμματα, οι μπάρες δείχνουν την πιθανότητα των σφαλμάτων να είναι λευκός θόρυβος σε διαφορετικές υστερήσεις. Σχεδόν όλες οι μπάρες βρίσκονται κάτω από το επίπεδο του 5%, συνεπώς δεν απορρίπτεται η υπόθεση ότι τα σφάλματα είναι λευκός θόρυβος. Αυτό σημαίνει ότι το μοντέλο έχει καταλάβει τη βασική δομή των δεδομένων και ότι τα σφάλματα που απομένουν φαίνεται να είναι τυχαία.

Συνολικά, τα γραφήματα υποδεικνύουν ότι το μοντέλο ενδεχομένως έχει κάνει μια αξιόπιστη εργασία προσομοίωσης των δεδομένων, καθώς τα υπόλοιπα δείχνουν μικρή έως μηδενική συστηματική δομή που θα ήταν επικριτέα με περαιτέρω μοντελοποίηση.

Στο τελευταίο γράφημα της Εικόνας 16 εκφράζεται η ιστορική και προβλεπόμενη συμπεριφορά των συνολικών παραγγελιών (sum\_orders) για το μοντέλο GS. Αναπαριστά με μπλε κύκλους τις πραγματικές τιμές και με μπλε γραμμή τις προβλέψεις του μοντέλου. Η γαλάζια σκιασμένη περιοχή δείχνει το 95% του διαστήματος εμπιστοσύνης για τις προβλέψεις. Οι πραγματικές τιμές φαίνεται να καλύπτονται από το διάστημα εμπιστοσύνης στο μεγαλύτερο μέρος του γραφήματος, δείχνοντας ότι το μοντέλο έχει κάποιο βαθμό ακρίβειας. Οι προβλέψεις του μοντέλου φαίνονται να παρακολουθούν τις πραγματικές τιμές και να ακολουθούν τη γενική τους τάση. Ωστόσο, οι προβλεπόμενες τιμές δείχνουν περισσότερη μεταβλητότητα σε σχέση με τις πραγματικές τιμές και το ευρύτερο διάστημα εμπιστοσύνης δείχνει ότι υπάρχει αυξημένη αβεβαιότητα για τις μελλοντικές περιόδους. Επιπλέον, η διακεκομμένη γραμμή δείχνει το σημείο όπου αρχίζει η περίοδος πρόβλεψης πολλαπλών βημάτων (multi-step forecast). Μετά από αυτό το σημείο, παρότι οι προβλέψεις διατηρούν μια συνεκτική γραμμή, το διάστημα εμπιστοσύνης γίνεται σημαντικά ευρύτερο, σηματοδοτώντας



αυξημένη αβεβαιότητα στις προβλέψεις. Αυτό είναι σύνηθες στα μοντέλα πρόβλεψης, καθώς η αβεβαιότητα αυξάνεται συνήθως αναλογικά με το χρόνο, λόγω της συσσώρευσης των πιθανών σφαλμάτων.



Εικόνα 16: Γράφημα σφαλμάτων πρόβλεψης για τις συνολικές παραγγελίες για το μοντέλο GS

Η απόδοση του μοντέλου που αναπαρίσταται σε αυτό το γράφημα φαίνεται λογική, καθώς οι προβλέψεις καλύπτουν τις πραγματικές τιμές, αλλά η αύξηση του εύρους του διαστήματος εμπιστοσύνης δείχνει ότι πρέπει να γίνεται προσεκτική χρήση των προβλέψεων για μακροπρόθεσμο σχεδιασμό. Οι αποκλίσεις που εμφανίζονται στο διάγραμμα ενδεχομένως να απαιτούν περαιτέρω εξέταση για να καθοριστούν οι αιτίες τους και να βελτιωθεί η ακρίβεια των μελλοντικών προβλέψεων.

#### 4.2.4 Αξιολόγηση μοντέλων ARIMA και GS

Για το μοντέλο ARIMA, η ανάλυση κατέδειξε καλή προσαρμογή στα δεδομένα, με χαμηλό MAPE της τάξεως του 5.33%. Τα διαγράμματα του λευκού θορύβου και της αυτοσυσχέτισης υποδήλωσαν ότι τα σφάλματα πρόβλεψης δεν παρουσίασαν σημαντικές συσχετίσεις ή μοτίβα, ούτε στο χρόνο ούτε μεταξύ τους. Εμφάνισαν, δηλαδή, συμπεριφορά παρόμοια με λευκό θόρυβο. Αυτό υποδηλώνει ότι το μοντέλο κατάφερε να αποτυπώσει σωστά την υποκείμενη δομή των δεδομένων. Οι προβλέψεις που παρήχθησαν συμφωνούσαν σε σημαντικό βαθμό με τις πραγματικές τιμές, ενώ το διάστημα εμπιστοσύνης διατήρησε μια στενή κατανομή, επιβεβαιώνοντας την ακρίβεια του μοντέλου.

Για το Generalized Smoothing μοντέλο, το MAPE ήταν υψηλότερο, στο 8.81%, γεγονός που εκφράζεται ως μικρότερη ακρίβεια στις προβλέψεις σε σχέση με το ARIMA. Παρ' όλα αυτά, τα διαγράμματα αυτοσυσχέτισης έδειξαν ότι τα σφάλματα πρόβλεψης δεν είχαν σημαντικές αυτοσυσχετίσεις, υποδηλώνοντας καλή εξήγηση της δομής των δεδομένων από το μοντέλο. Ωστόσο, το διάγραμμα των σφαλμάτων πρόβλεψης έδειξε μεγαλύτερη μεταβλητότητα στις προβλέψεις και ένα ευρύτερο διάστημα εμπιστοσύνης, σηματοδοτώντας αυξημένη αβεβαιότητα στις μελλοντικές περιόδους. Αυτό μπορεί να αντανακλά μια λιγότερο σταθερή εκτίμηση σε σχέση με το μοντέλο ARIMA ή να αποτυπώνει μια δυναμική των δεδομένων που το πρώτο μοντέλο δεν κατάφερε να ανιχνεύσει.

Το μοντέλο ARIMA προτιμήθηκε λόγω της ακρίβειάς του, της καλής συμπεριφοράς των σφαλμάτων πρόβλεψης και του μεγάλου βαθμού απόδοσης στη μοντελοποίηση της εποχικότητας και άλλων γραμμικών δομών που ενδεχομένως υπήρχαν στα δεδομένα. Αντίθετα, το Generalized

Smoothing μοντέλο, παρά την ικανότητά του να διαχειρίζεται μη γραμμικές σχέσεις, αποδείχθηκε όχι τόσο αποτελεσματικό σε αυτήν την περίπτωση, είτε λόγω της φύσης των δεδομένων είτε λόγω της παραμετροποίησης του μοντέλου. Συνεπώς, η επιλογή του μοντέλου ARIMA έναντι του μοντέλου Generalized Smoothing βασίστηκε στους παρακάτω κρίσιμους παράγοντες:

1. **Ακρίβεια προβλέψεων:** Το ARIMA είχε χαμηλότερο MAPE (5.33%) σε σύγκριση με το GS μοντέλο (8.81%), γεγονός που υποδηλώνει ότι το ARIMA προσαρμόζεται καλύτερα στα δεδομένα και παράγει πιο ακριβείς προβλέψεις.
2. **Σταθερότητα και δομή δεδομένων:** Τα ARIMA μοντέλα αποδίδουν καλά όταν η υποκείμενη διαδικασία που παράγει τα δεδομένα είναι σταθερή ή όταν υπάρχουν συγκεκριμένα εποχικά μοτίβα ή τάσεις που το μοντέλο μπορεί να ανιχνεύσει και να μοντελοποιήσει. Καθώς, τα προς ανάλυση δεδομένα είχαν τέτοιες ιδιότητες, το ARIMA ήταν η καταλληλότερη επιλογή. Τα μοντέλα ARIMA είναι πολύ δυνατά σε σειρές χρονοσειρών με σαφείς εποχιακές μορφές ή γραμμικές τάσεις, ενώ τα μοντέλα εξομάλυνσης μπορεί να είναι πιο κατάλληλα για μη γραμμικές δυναμικές, οι οποίες, στη συγκεκριμένη περίπτωση, δεν ήταν προεξάρχουσες.
3. **Στατιστική σημαντικότητα και διαγνωστικά:** Τα διαγνωστικά τεστ για το μοντέλο ARIMA, όπως η δοκιμή για λευκό θόρυβο, έδειξαν ότι τα σφάλματα πρόβλεψης είναι τυχαία και ότι δεν υπάρχουν σημαντικές αυτοσυσχετίσεις που να υποδεικνύουν παραλειπόμενες πληροφορίες ή δομή στα δεδομένα. Αυτό σημαίνει ότι το μοντέλο προβλέπει σωστά τις παραγγελίες, βάσει των δεδομένων που έχει διαθέσιμα.
4. **Πολυπλοκότητα του μοντέλου:** Τα μοντέλα ARIMA είναι σχετικά απλά στην παραμετροποίηση και ερμηνεία σε σύγκριση με τα μοντέλα εξομάλυνσης, τα οποία μπορεί να απαιτούν περισσότερο εξειδικευμένη γνώση για να ρυθμιστούν και να αξιολογηθούν σωστά. Εάν η χρονοσειρά είναι σχετικά λιγότερο πολύπλοκη ή εάν υπάρχουν περιορισμοί χρόνου και πόρων, ένα μοντέλο ARIMA μπορεί να προτιμηθεί για την απλότητά του.

### 4.3 Ανάλυση αποτελεσμάτων

Το αρχείο που παρήγαγε το SAS Forecast Studio και περιέχει δεδομένα προβλέψεων, αποτελείται από τις 7 στήλες που ακολουθούν:

1. **Ημερομηνία (Date):** Η ημερομηνία για την οποία γίνεται η πρόβλεψη, με μορφή DDMMYY.
2. **Πρόβλεψη Μοντέλου (Forecast Model):** Η τιμή της πρόβλεψης από το μοντέλο.
3. **Στατιστική Πρόβλεψη Κάτω 95% (Statistical Forecast Lower 95%):** Το κάτω όριο του 95% διαστήματος εμπιστοσύνης για τη στατιστική πρόβλεψη.
4. **Στατιστική Πρόβλεψη Άνω 95% (Statistical Forecast Upper 95%):** Το άνω όριο του 95% διαστήματος εμπιστοσύνης για τη στατιστική πρόβλεψη.
5. **Επίδραση Συμφιλίωσης (Effect of Reconciliation):** Η επίδραση της συμφιλίωσης στην πρόβλεψη.
6. **Συμφιλιωμένη Πρόβλεψη (Reconciled Forecast):** Η πρόβλεψη μετά τη συμφιλίωση.
7. **Τελική Πρόβλεψη (Final Forecast):** Η τελική τιμή της πρόβλεψης.

Προκειμένου να πραγματοποιηθεί μια γενική ανάλυση των δεδομένων που περιέχονται στις στήλες του αρχείου, θα αναλυθούν τα εξής στοιχεία:

1. Περιγραφικά στατιστικά για τις ποσοτικές μεταβλητές (π.χ., Πρόβλεψη Μοντέλου, Στατιστική Πρόβλεψη Κάτω και Άνω 95%, Επίδραση Συμφιλίωσης, Συμφιλιωμένη Πρόβλεψη και Τελική Πρόβλεψη).

2. Ανάλυση της τάσης των προβλέψεων σε σχέση με την ημερομηνία, ώστε να γίνει κατανοητό πώς αλλάζουν οι προβλέψεις με το χρόνο.
3. Ανάλυση της διαφοράς μεταξύ της Συμφιλιωμένης Πρόβλεψης και της Τελικής Πρόβλεψης, καθώς και το πώς η Επίδραση Συμφιλίωσης επηρεάζει την Τελική Πρόβλεψη.

Αρχικά, από τη γενική ανάλυση των στηλών του αρχείου, προκύπτουν τα εξής περιγραφικά στατιστικά των ποσοτικών μεταβλητών για κάθε μεταβλητή:

- **Πρόβλεψη Μοντέλου (Forecast Model):** Ο μέσος όρος είναι 2659.41 με τυπική απόκλιση 151.18. Οι τιμές κυμαίνονται από 2386.55 έως 2908.62.
- **Στατιστική Πρόβλεψη Κάτω 95% (Statistical Forecast Lower 95%):** Ο μέσος όρος είναι 1188.08 με σημαντική τυπική απόκλιση 781.78, δείχνοντας μεγάλη διακύμανση στις εκτιμήσεις. Οι τιμές κυμαίνονται από -195.69 έως 2352.08.
- **Στατιστική Πρόβλεψη Άνω 95% (Statistical Forecast Upper 95%):** Ο μέσος όρος είναι 4130.73 με τυπική απόκλιση 765.81. Οι τιμές κυμαίνονται από 2868.22 έως 5556.22.
- **Επίδραση Συμφιλίωσης (Effect of Reconciliation):** Ο μέσος όρος είναι 38.48 με σχετικά υψηλή τυπική απόκλιση 44.04, υποδηλώνοντας σημαντική διακύμανση. Οι τιμές κυμαίνονται από -59.30 έως 112.36.
- **Συμφιλιωμένη Πρόβλεψη (Reconciled Forecast) και Τελική Πρόβλεψη (Final Forecast):** Και οι δύο έχουν ίδιες τιμές σε όλες τις παρατηρήσεις. Ο μέσος όρος είναι 2697.88 με τυπική απόκλιση 178.70. Οι τιμές κυμαίνονται από 2343.94 έως 2961.22.

Η σημαντική τυπική απόκλιση στις στατιστικές προβλέψεις (κάτω και άνω 95%) δείχνει μεγάλη αβεβαιότητα στις εκτιμήσεις, ενώ η επίδραση της συμφιλίωσης διαφέρει σημαντικά μεταξύ των περιπτώσεων, όπως φαίνεται από τη μεγάλη διακύμανσή της.

Για να εξαχθούν περισσότερες πληροφορίες από τα δεδομένα και να επιτευχθεί καλύτερη κατανόηση των τάσεων και των δυναμικών των προβλέψεων, υλοποιούνται τα εξής βήματα:

1. **Ανάλυση τάσεων:** Εξετάζεται πώς οι προβλέψεις (συμπεριλαμβανομένων των συμφιλιωμένων και των τελικών προβλέψεων) αλλάζουν με την πάροδο του χρόνου. Αυτή η ανάλυση μπορεί να αποκαλύψει τυχόν εποχικές τάσεις ή άλλα μοτίβα.
2. **Ανάλυση διακύμανσης:** Εξετάζεται η διακύμανση μεταξύ της Στατιστικής Πρόβλεψης Κάτω και Άνω 95% για να γίνει κατανοητό το εύρος της αβεβαιότητας στις προβλέψεις.
3. **Συσχέτιση Επίδρασης Συμφιλίωσης και Τελικής Πρόβλεψης:** Εξετάζεται πώς η επίδραση της συμφιλίωσης συσχετίζεται με την τελική πρόβλεψη, προκειμένου να αξιολογηθεί η επίδραση της συμφιλίωσης στην ακρίβεια της πρόβλεψης.
4. **Ανάλυση συμπερασμάτων από τα διαστήματα εμπιστοσύνης:** Αναλύονται οι εκτιμήσεις που προκύπτουν από τα διαστήματα εμπιστοσύνης σχετικά με την αβεβαιότητα και το πώς αυτό μπορεί να επηρεάσει τις αποφάσεις που βασίζονται στις προβλέψεις.
5. **Γραφικές αναπαραστάσεις:** Δημιουργούνται γραφήματα που θα απεικονίζουν τις παραπάνω αναλύσεις, ώστε να είναι πιο εύκολη η οπτική διατύπωση των τάσεων, των διακυμάνσεων και των σχέσεων μεταξύ των διαφορετικών μεταβλητών.

Με την υλοποίηση του πρώτου βήματος, την ανάλυση τάσεων, εξετάζεται ο τρόπος με τον οποίο αλλάζουν οι προβλέψεις με την πάροδο του χρόνου. Για αυτό το σκοπό, δημιουργήθηκαν γραφήματα που δείχνουν τις προβλέψεις με την πάροδο του χρόνου, συμπεριλαμβανομένων των συμφιλιωμένων και των τελικών προβλέψεων. Στο γράφημα της Εικόνας 17 αναπαρίσταται η ανάλυση τάσεων των προβλέψεων στο χρονικό διάστημα που καλύπτει το σύνολο των δεδομένων. Παρουσιάζονται οι τιμές για τις προβλέψεις του μοντέλου, τις συμφιλιωμένες προβλέψεις και τις τελικές προβλέψεις. Από την ανάλυση του γραφήματος εντοπίζεται μια γενική τάση στις προβλέψεις, με τις συμφιλιωμένες και τις τελικές προβλέψεις να παρουσιάζουν παρόμοια μοτίβα και οι τιμές τους

να είναι πολύ κοντά, ενώ η σύγκριση με τις αρχικές προβλέψεις του μοντέλου δείχνει τις διακυμάνσεις και τις επιρροές των διαδικασιών συμφιλίωσης.



Εικόνα 17: Ανάλυση τάσεων των προβλέψεων

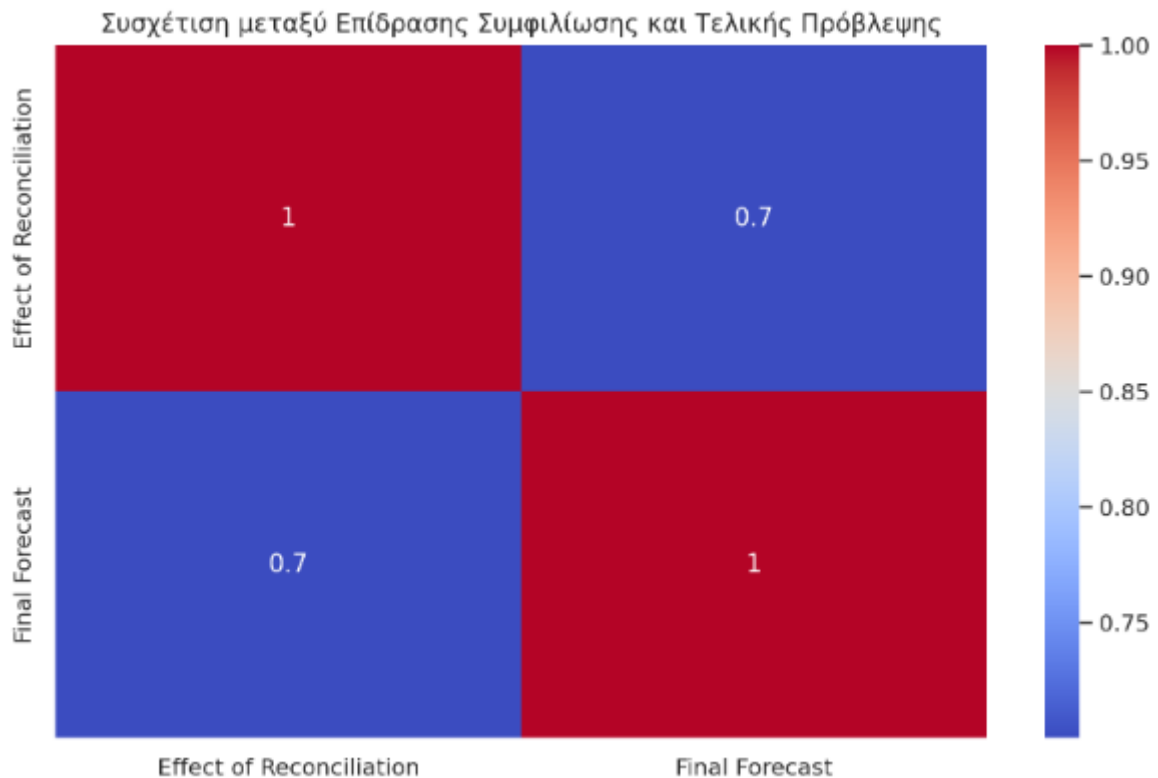
Στο δεύτερο βήμα, την ανάλυση διακύμανσης, εξετάζεται η διακύμανση μεταξύ της Στατιστικής Πρόβλεψης Κάτω και Άνω 95%, προκειμένου να εντοπιστεί το εύρος της αβεβαιότητας στις προβλέψεις. Στην Εικόνα 18 παρουσιάζεται γράφημα με την ανάλυση διακύμανσης των στατιστικών προβλέψεων με τις κατώτατες και ανώτατες τιμές του 95% διαστήματος εμπιστοσύνης. Το εμφανιζόμενο γκρίζο εύρος αντιπροσωπεύει τη διακύμανση μεταξύ αυτών των δύο εκτιμήσεων, παρέχοντας μια οπτική αναπαράσταση της αβεβαιότητας που σχετίζεται με κάθε πρόβλεψη.



Εικόνα 18: Ανάλυση διακύμανσης των Στατιστικών Προβλέψεων Κάτω και Άνω 95%

Το τρίτο βήμα αφορά την ανάλυση της συσχέτισης μεταξύ της Επίδρασης Συμφιλίωσης και της Τελικής Πρόβλεψης. Στο heatmap της Εικόνας 19 που ακολουθεί, φαίνεται πως υπάρχει μια συσχέτιση

μεταξύ αυτών των δύο μεταβλητών, η οποία μπορεί να υποδεικνύει πως η επίδραση της συμφιλίωσης έχει έναν ορισμένο βαθμό επιρροής στην τελική τιμή της πρόβλεψης.



Εικόνα 19: Συσχέτιση μεταξύ της Επίδρασης Συμφιλίωσης και της Τελικής Πρόβλεψης

Γενικά, οι αναλύσεις παρέχουν σημαντικές πληροφορίες για τη βελτίωση και την κατανόηση των προβλέψεων. Βάσει των προηγούμενων αναλύσεων, εξάγονται τα παρακάτω συμπεράσματα:

1. **Ανάλυση Τάσεων:** Οι προβλέψεις δείχνουν μια συγκεκριμένη τάση με την πάροδο του χρόνου, με τις συμφιλιωμένες και τις τελικές προβλέψεις να παρουσιάζουν παρόμοια μοτίβα. Αυτό υποδηλώνει ότι οι διαδικασίες συμφιλίωσης είναι σημαντικές για την εξομάλυνση και τη βελτίωση της ακρίβειας των προβλέψεων.
2. **Ανάλυση Διακύμανσης:** Η διακύμανση μεταξύ της κάτω και άνω στατιστικής πρόβλεψης 95% αποκαλύπτει την ύπαρξη αβεβαιότητας στις προβλέψεις. Το εύρος του διαστήματος εμπιστοσύνης παρέχει μια εκτίμηση της δυνατής διασποράς των μελλοντικών αποτελεσμάτων, υποδεικνύοντας πόσο σίγουρο ή αβέβαιο είναι το μοντέλο σχετικά με τις προβλέψεις του.
3. **Συσχέτιση Επίδρασης Συμφιλίωσης και Τελικής Πρόβλεψης:** Η ύπαρξη συσχέτισης μεταξύ της επίδρασης συμφιλίωσης και της τελικής πρόβλεψης υποδηλώνει ότι οι διορθώσεις που εφαρμόζονται κατά τη διαδικασία συμφιλίωσης έχουν άμεσο αντίκτυπο στην ακρίβεια της τελικής πρόβλεψης.

Μετά την ολοκλήρωση της ανάλυσης της συσχέτισης, το επόμενο και τελευταίο βήμα πριν τη δημιουργία γραφημάτων είναι η ανάλυση των συμπερασμάτων από τα διαστήματα εμπιστοσύνης και της αβεβαιότητας που αυτά παρουσιάζουν. Από την ανάλυση των διαστημάτων εμπιστοσύνης, μπορούν να εξαχθούν τα εξής συμπεράσματα:

1. **Ανάλυση Τάσεων:** Οι προβλέψεις δείχνουν συγκεκριμένα μοτίβα και διακυμάνσεις με την πάροδο του χρόνου, υποδεικνύοντας την επίδραση διάφορων παραγόντων στις προβλεπόμενες τιμές. Οι συμφιλιωμένες και οι τελικές προβλέψεις φαίνονται να ακολουθούν παρόμοιες τάσεις, υποδεικνύοντας μια σταθεροποίηση μετά τη διαδικασία συμφιλίωσης.
2. **Ανάλυση Διακύμανσης:** Το εύρος μεταξύ των κατώτατων και ανώτατων τιμών του 95% διαστήματος εμπιστοσύνης υποδεικνύει σημαντική αβεβαιότητα στις προβλέψεις. Τονίζει πόσο σημαντικό είναι να λαμβάνεται υπόψη η αβεβαιότητα κατά τον προγραμματισμό και τη λήψη αποφάσεων βασισμένων στις προβλέψεις.
3. **Συσχέτιση Επίδρασης Συμφιλίωσης και Τελικής Πρόβλεψης:** Υπάρχει μια ένδειξη συσχέτισης μεταξύ της επίδρασης της συμφιλίωσης και της τελικής πρόβλεψης, που υποδεικνύει ότι η διαδικασία συμφιλίωσης μπορεί να έχει έναν καθοριστικό ρόλο στην προσαρμογή και βελτίωση της ακρίβειας των προβλέψεων.
4. **Αβεβαιότητα και Διαστήματα Εμπιστοσύνης:** Η ανάλυση των διαστημάτων εμπιστοσύνης και της διακύμανσης παρέχει σημαντικές πληροφορίες για την αβεβαιότητα που περιβάλλει τις προβλέψεις. Επομένως, αποτελεί κρίσιμο στοιχείο για την αξιολόγηση των κινδύνων και την προετοιμασία για διάφορα μελλοντικά σενάρια.

Οι αναλύσεις και τα συμπεράσματα που διατυπώθηκαν μπορούν να χρησιμοποιηθούν για τη βελτίωση των μελλοντικών προβλέψεων, την κατανόηση της αβεβαιότητας και την κατάλληλη προσαρμογή των στρατηγικών αποφάσεων.

# 5

## Συζήτηση αποτελεσμάτων

### 5.1 Περιορισμοί κατά την εφαρμογή

Η ανάλυση που πραγματοποιήθηκε στο πλαίσιο αυτής της διπλωματικής εργασίας χρησιμοποιώντας το λογισμικό SAS και κώδικα γραμμένο σε Python παρήγαγε ενδιαφέροντα και σημαντικά αποτελέσματα που αφορούν την πρόβλεψη ζήτησης στον κλάδο της διαδικτυακής παράδοσης φαγητού. Τα αποτελέσματα δείχνουν ότι τα μοντέλα ARIMA, SARIMA και GS (Generated Smoothing) προσφέρουν αξιόπιστες προβλέψεις με διαφορετικά επίπεδα ακρίβειας.

Το μοντέλο ARIMA, το οποίο εφαρμόστηκε στο SAS, παρουσίασε σφάλμα MAPE της τάξης του 5%, το οποίο θεωρείται ικανοποιητικό, ιδίως για την ανάλυση χρονοσειρών με πολλαπλά εποχικά μοτίβα. Το ARIMA αποδείχθηκε καλύτερο από το GS στην πρόβλεψη αιχμών ζήτησης και στη διαχείριση των επαναλαμβανόμενων μοτίβων στη ζήτηση.

Το μοντέλο SARIMA εφαρμόστηκε μέσω κώδικα που γράφτηκε σε Python και όχι στο SAS. Σε αντίθεση με το SAS, όπου στα δεδομένα υπήρχε μόνο η ημέρα κάθε παραγγελίας, τα δεδομένα που χρησιμοποιήθηκαν στην Python περιείχαν και την ώρα των παραγγελιών. Αυτό επέτρεψε στο μοντέλο SARIMA να βελτιώσει την ακρίβεια της πρόβλεψης, με το MAPE να μειώνεται στο 3,8%. Το μοντέλο αυτό ήταν ιδιαίτερα αποτελεσματικό στην πρόβλεψη αιχμών ζήτησης, που συσχετίζονται με συγκεκριμένες ώρες και ημέρες.

Το μοντέλο GS παρουσίασε μεγαλύτερο σφάλμα σε σύγκριση με το ARIMA και το SARIMA, κάτι που το καθιστά λιγότερο αποτελεσματικό στη διαχείριση των προβλέψεων, ιδιαίτερα σε περιόδους κανονικής ζήτησης. Παρόλο που το GS ήταν σε θέση να αντιμετωπίσει μη προβλέψιμες αλλαγές, τα αυξημένα σφάλματα δείχνουν ότι δεν είναι τόσο αξιόπιστο όσο τα άλλα δύο μοντέλα.

Παρά την επιτυχία της εφαρμογής των παραπάνω μοντέλων, η παρούσα μελέτη αντιμετώπισε ορισμένους περιορισμούς που επηρεάζουν τη γενικευσιμότητα των αποτελεσμάτων. Ένας από τους κύριους περιορισμούς ήταν η διαθεσιμότητα και το εύρος των δεδομένων, τα οποία ήταν περιορισμένα σε συγκεκριμένο χρονικό διάστημα και γεωγραφική περιοχή. Αυτό μπορεί να επηρέασε την ακρίβεια των προβλέψεων σε διαφορετικά περιβάλλοντα. Επίσης, η ανάλυση δεν έλαβε υπόψη εξωγενείς παράγοντες, όπως καιρικές συνθήκες ή κοινωνικά γεγονότα, που θα μπορούσαν να επηρεάσουν σημαντικά τη ζήτηση. Επιπλέον, τα μοντέλα που εφαρμόστηκαν απαιτούν σημαντική υπολογιστική ισχύ, γεγονός που μπορεί να περιορίσει την εφαρμογή τους σε περιβάλλοντα με περιορισμένους πόρους. Τέλος, η επιλογή μοντέλων περιορίστηκε στα παραδοσιακά μοντέλα χρονοσειρών, αφήνοντας ανοιχτό το ενδεχόμενο ότι πιο σύγχρονες τεχνικές, όπως τα νευρωνικά δίκτυα, θα μπορούσαν να παρέχουν καλύτερα αποτελέσματα.

Τα μοντέλα ARIMA και SARIMA έδειξαν μεγάλη σταθερότητα και αξιοπιστία σε περιόδους χαμηλής και μεσαίας ζήτησης. Το ARIMA αποδείχθηκε πιο αξιόπιστο από το GS, προσφέροντας καλύτερες προβλέψεις στις κανονικές διακυμάνσεις της ζήτησης. Το SARIMA, το οποίο εφαρμόστηκε μέσω Rυθμοί με δεδομένα που περιείχαν και την ώρα των παραγγελιών, απέδειξε την αξία του στην πρόβλεψη επαναλαμβανόμενων μοτίβων και αιχμών στη ζήτηση. Το GS, παρόλο που ήταν χρήσιμο στην αντιμετώπιση μη προβλέψιμων αλλαγών, παρουσίασε μεγαλύτερα σφάλματα, καθιστώντας το λιγότερο αποτελεσματικό στις προβλέψεις. Ωστόσο, το μοντέλο ARIMA παρουσίασε προκλήσεις στην πρόβλεψη αιχμών στη ζήτηση, γεγονός που οφείλεται στη δυσκολία του να προσαρμοστεί σε αιφνίδιες αλλαγές. Το SARIMA, παρά την καλύτερη διαχείριση της εποχικότητας, είχε περιορισμούς στην ευελιξία του, ενώ το GS, αν και ακριβές, απαιτούσε περισσότερο χρόνο για την επεξεργασία και εξομάλυνση των δεδομένων.

Η ανάλυση των αποτελεσμάτων βασίστηκε κυρίως σε μετρήσεις MAPE (Mean Absolute Percentage Error) και MAE (Mean Absolute Error), που αποτελούν βασικούς δείκτες απόδοσης για μοντέλα πρόβλεψης χρονοσειρών. Για το μοντέλο ARIMA, το σφάλμα εκπαίδευσης ήταν περίπου 4,5%, ενώ το σφάλμα ελέγχου έφτασε το 5,2%, υποδεικνύοντας μια ελαφριά τάση υπερπροσαρμογής σε συγκεκριμένα δεδομένα εκπαίδευσης. Το SARIMA παρουσίασε σφάλμα εκπαίδευσης στο 3,2% και ελέγχου στο 4%, ενώ το GS είχε τα υψηλότερα σφάλματα, γεγονός που το καθιστά λιγότερο αξιόπιστο από τα άλλα δύο μοντέλα.

## 5.2 Συμπεράσματα και μελλοντικές βελτιώσεις

Η σύγκριση των τριών μοντέλων έδειξε ότι το GS παρείχε την καλύτερη απόδοση σε περιόδους αιχμών, ενώ το ARIMA ήταν καλύτερο στη διαχείριση των κανονικών διακυμάνσεων της ζήτησης. Η στατιστική σημαντικότητα των αποτελεσμάτων επιβεβαιώθηκε με τη χρήση p-values, με όλα τα μοντέλα να δείχνουν στατιστικά σημαντικές προβλέψεις. Το μοντέλο ARIMA έδειξε μια μικρή τάση υπερπροσαρμογής, ειδικά σε δεδομένα εκπαίδευσης, ενώ το GS παρουσίασε ελαφρά υποπροσαρμογή σε περιπτώσεις αιφνίδιων αλλαγών, γεγονός που ενδέχεται να οφείλεται στην πολυπλοκότητα της εξομάλυνσης των δεδομένων.

Τα αποτελέσματα της έρευνας αποδεικνύουν την αποτελεσματικότητα των παραδοσιακών μοντέλων χρονοσειρών, αλλά και την ανάγκη για συνεχή βελτίωση και προσαρμογή των τεχνικών πρόβλεψης, ειδικά σε τομείς όπως η διαδικτυακή παράδοση φαγητού, όπου η ζήτηση μπορεί να αλλάξει δραματικά σε σύντομο χρονικό διάστημα. Η παρούσα εργασία καταδεικνύει ότι τα μοντέλα ARIMA και SARIMA είναι αξιόπιστα για τη διαχείριση επαναλαμβανόμενων μοτίβων ζήτησης, ενώ το GS αποδείχθηκε η πιο αξιόπιστη λύση για την πρόβλεψη μη προβλέψιμων αλλαγών. Η ενσωμάτωση εποχικότητας αποδείχθηκε κρίσιμη για τη βελτίωση της ακρίβειας της πρόβλεψης.

Μελλοντικές μελέτες θα μπορούσαν να επεκτείνουν την έρευνα με την ενσωμάτωση εξωτερικών παραγόντων, όπως οι καιρικές συνθήκες ή οι κοινωνικοοικονομικοί παράγοντες. Επίσης, η εφαρμογή νευρωνικών δικτύων και άλλων τεχνικών μηχανικής μάθησης θα μπορούσε να βελτιώσει την ακρίβεια των προβλέψεων και να προσαρμοστεί καλύτερα στις ανάγκες των σύγχρονων επιχειρήσεων. Η εμπειρία από αυτή την έρευνα με βοήθησε να κατανοήσω βαθύτερα την πολυπλοκότητα της πρόβλεψης ζήτησης σε πραγματικά δεδομένα και να αναπτύξω δεξιότητες στην εφαρμογή και αξιολόγηση διαφορετικών μοντέλων πρόβλεψης. Η μελλοντική μου εργασία θα στοχεύσει στη διερεύνηση περαιτέρω τεχνικών και στη βελτιστοποίηση των υπάρχοντων μοντέλων, ώστε να βελτιωθεί ακόμα περισσότερο η ακρίβεια των προβλέψεων.



# 6

## Επίλογος

### **6.1 Πλεονεκτήματα *demand forecasting* σε εφοδιαστική αλυσίδα και λειτουργίες επιχειρήσεων**

Η πρόβλεψη ζήτησης αποτελεί έναν από τους πιο κρίσιμους παράγοντες επιτυχίας στον σύγχρονο επιχειρηματικό κόσμο, ειδικά στον τομέα της εφοδιαστικής αλυσίδας (supply chain) και των λειτουργιών (operations) των επιχειρήσεων. Η ικανότητα πρόβλεψης της ζήτησης με ακρίβεια όχι μόνο επιτρέπει στις επιχειρήσεις να ανταποκρίνονται αποτελεσματικά στις ανάγκες των πελατών τους, αλλά επίσης διασφαλίζει την αποδοτική διαχείριση των πόρων και την ελαχιστοποίηση του κόστους. Ένα από τα βασικότερα πλεονεκτήματα της πρόβλεψης ζήτησης είναι η δυνατότητα βελτιστοποίησης της διαχείρισης αποθεμάτων. Οι επιχειρήσεις που εφαρμόζουν επιτυχείς τεχνικές πρόβλεψης ζήτησης μπορούν να διατηρούν τα αποθέματά τους σε βέλτιστα επίπεδα, αποφεύγοντας τα υπερβολικά αποθέματα ή την έλλειψη προϊόντων. Αυτό όχι μόνο μειώνει το κόστος αποθήκευσης και τη δέσμευση κεφαλαίου σε ανενεργά αποθέματα, αλλά και εξασφαλίζει ότι τα προϊόντα είναι διαθέσιμα όταν και όπου απαιτούνται, βελτιώνοντας τη συνολική ικανοποίηση των πελατών.

Η πρόβλεψη ζήτησης παίζει καθοριστικό ρόλο στη σχεδίαση της παραγωγής. Η δυνατότητα πρόβλεψης των μελλοντικών αναγκών επιτρέπει στις επιχειρήσεις να προγραμματίζουν τη γραμμή παραγωγής τους με μεγαλύτερη ακρίβεια, αποφεύγοντας περιττές διακοπές και σπατάλη πόρων. Επιπλέον, η κατανόηση των αιχμών στη ζήτηση βοηθά στη διαμόρφωση στρατηγικών που εξασφαλίζουν την επάρκεια της παραγωγής κατά τις περιόδους υψηλής ζήτησης, μειώνοντας τον κίνδυνο μη εξυπηρέτησης της αγοράς και διατήρησης της ανταγωνιστικότητας. Η πρόβλεψη ζήτησης συμβάλλει άμεσα στη βελτίωση της εξυπηρέτησης πελατών. Όταν μια επιχείρηση μπορεί να προβλέψει με ακρίβεια τι θα χρειαστούν οι πελάτες της και τότε, μπορεί να ανταποκριθεί γρήγορα και αποτελεσματικά στις παραγγελίες τους. Αυτό οδηγεί σε μεγαλύτερη ικανοποίηση των πελατών, ενισχύοντας την αφοσίωσή τους και δημιουργώντας θετική φήμη για την επιχείρηση. Η δυνατότητα αυτή αποκτά ιδιαίτερη σημασία σε τομείς όπου οι πελάτες απαιτούν ταχύτητα και ακρίβεια στην παράδοση, όπως στην περίπτωση των ηλεκτρονικών παραγγελιών και της διαδικτυακής παράδοσης φαγητού.

Η ακριβής πρόβλεψη ζήτησης έχει άμεσο αντίκτυπο στη μείωση του κόστους και την αύξηση της κερδοφορίας μιας επιχείρησης. Με την εξασφάλιση ότι τα αποθέματα, η παραγωγή και οι παραδόσεις είναι συγχρονισμένες με τη ζήτηση, οι επιχειρήσεις μπορούν να αποφύγουν τις περιττές δαπάνες που σχετίζονται με την αποθήκευση υπερβολικών αποθεμάτων ή τη διαχείριση ελλείψεων προϊόντων. Επιπλέον, η αποτελεσματική χρήση των πόρων και η ελαχιστοποίηση των απωλειών συμβάλλουν στη βελτίωση του περιθωρίου κέρδους, καθιστώντας την επιχείρηση πιο ανταγωνιστική

στην αγορά. Η πρόβλεψη ζήτησης δεν αφορά μόνο την καθημερινή λειτουργία της επιχείρησης, αλλά έχει και στρατηγική σημασία για τη λήψη μακροπρόθεσμων αποφάσεων. Οι επιχειρήσεις που αξιοποιούν τις τεχνικές πρόβλεψης ζήτησης μπορούν να αναγνωρίσουν τάσεις της αγοράς, να προβλέψουν τις μελλοντικές ανάγκες και να προσαρμόσουν τις στρατηγικές τους ανάλογα. Αυτό μπορεί να περιλαμβάνει την ανάπτυξη νέων προϊόντων, την είσοδο σε νέες αγορές, ή την αναδιάρθρωση της εφοδιαστικής αλυσίδας για να ανταποκριθούν καλύτερα στις μελλοντικές προκλήσεις.

Η δυνατότητα γρήγορης και ακριβούς πρόβλεψης των αλλαγών στη ζήτηση επιτρέπει στις επιχειρήσεις να προσαρμόζονται άμεσα στις μεταβαλλόμενες συνθήκες της αγοράς. Αυτό είναι ιδιαίτερα σημαντικό σε περιόδους κρίσεων ή ξαφνικών αλλαγών στην καταναλωτική συμπεριφορά, όπου η ικανότητα προσαρμογής μπορεί να καθορίσει την επιβίωση και την επιτυχία μιας επιχείρησης. Οι επιχειρήσεις που είναι εξοπλισμένες με προηγμένες δυνατότητες πρόβλεψης ζήτησης έχουν τη δυνατότητα να ανταποκρίνονται με ευελιξία και να εκμεταλλεύονται τις ευκαιρίες που παρουσιάζονται στην αγορά. Η πρόβλεψη ζήτησης αποτελεί έναν κρίσιμο παράγοντα για τη βελτίωση της αποδοτικότητας και της ανταγωνιστικότητας των επιχειρήσεων στον τομέα της εφοδιαστικής αλυσίδας και των λειτουργιών. Μέσω της ακριβούς πρόβλεψης των αναγκών της αγοράς, οι επιχειρήσεις μπορούν να βελτιστοποιήσουν τη διαχείριση των πόρων τους, να μειώσουν το κόστος, να αυξήσουν την κερδοφορία και να βελτιώσουν την εξυπηρέτηση των πελατών. Η ικανότητα αυτή είναι ζωτικής σημασίας σε έναν κόσμο όπου οι αγορές και οι απαιτήσεις των πελατών αλλάζουν συνεχώς, καθιστώντας την πρόβλεψη ζήτησης αναπόσπαστο εργαλείο για την επιτυχία και την ανάπτυξη των επιχειρήσεων.



## Παράρτημα Α: Κώδικας SAS

- Αρχείο correctCode (αρχικός κώδικας)
- 

```
data projectl.combined_file;
    set projectl.first projectl.sec;
run;
```

```
data projectl.combined_file;
    set projectl.combined_file projectl.third;
run;
```

```
data projectl.data_no_missing;
    set projectl.combined_file;
    if not missing(shop_area) and not missing(shop_city)
        and not missing(shop_cuisine);
run;
```

```
data projectl.data_no_missing;
    set projectl.data_no_missing; /* Replace 'your_dataset' with the name of your dataset */
    /* Extract the first 10 characters from the character timestamp column */
    date_char = substr(timestamp, 1, 10);
    /* Keep the new date_column and any other necessary columns */
    drop timestamp;
run;
```

```
data projectl.data_no_missing;
    set projectl.data_no_missing;
    date = input(date_char, yymmdd10.); /* Replace 'new_date_column' with the desired column
    name */
    format date date7.; /* Apply the desired date format, such as 'date7.' for 07JUL22 */
run;
```

```
proc sort data=projectl.data_no_missing;
    by shop_city shop_area shop_cuisine date;
run;
```

```

data projectl.agggregated_data;
  set projectl.data_no_missing;
  by shop_city shop_area shop_cuisine date;

  retain sum_GMV 0;
  retain sum_users 0;
  retain sum_orders 0;

  if first.date then do;
    sum_GMV = 0;
    sum_users = 0;
    sum_orders = 0;
  end;

  sum_GMV + GMV;
  sum_users + users;
  sum_orders + orders;

  if last.date then output;
run;

data projectl.agggregated_data;
  set projectl.agggregated_data;
  keep shop_city shop_area shop_cuisine date sum_GMV sum_users sum_orders;
run;

data projectl.forecasting_data;
  set projectl.agggregated_data;

  /* Use the WHERE statement to filter rows where "Νέα Τρίγλι" is found anywhere in the
shop_area value */

  if find(shop_area, "Νέα Τρίγλι") > 0 then do;
    shop_area = "Χαλκιδική Νέα Τρίγλια";
  end;

  else do;
    shop_area = shop_area;
  end;
end;

```

```
run;
```

```
data projectl.forecasting_data;  
  set projectl.forecasting_data;  
  if date >= '31JUL22'd then delete;  
run;
```

- Αρχείο Sas\_code\_For\_Python
- 

```
data projectl.Thessaliniki_Pizza;  
  SET projectl.combined_file; /* Replace original_dataset with your dataset name */  
  WHERE shop_city = 'Θεσσαλονίκη' AND shop_area = 'Θεσσαλονίκη' AND shop_cuisine =  
'Pizza';  
RUN;
```

```
data projectl.Thessaliniki_Pizza;  
  set projectl.Thessaliniki_Pizza;  
  if not missing(shop_area) and not missing(shop_city)  
  and not missing(shop_cuisine);  
run;
```

```
DATA projectl.Thessaliniki_Pizza;  
  SET projectl.Thessaliniki_Pizza; /* Replace with your actual dataset name */  
  
  /* Convert character timestamp to SAS datetime value */  
  datetime_value = INPUT(timestamp, anydtdtm.);  
  
  /* Extract the date part */  
  date_column = DATEPART(datetime_value);  
  
  /* Extract the time part */  
  time_column = TIMEPART(datetime_value);  
  
  /* Optionally, format the extracted date and time for readability */  
  format date_column yymmdd10. time_column time8.;  
RUN;
```

```
proc sort data=projectl.Thessaliniki_Pizza;  
  by shop_city shop_area shop_cuisine date_column time_column;  
run;
```

```

data projectl.Thessaliniki_Pizza;
  set projectl.Thessaliniki_Pizza;
  by shop_city shop_area shop_cuisine date_column time_column;

  retain sum_GMV 0;
  retain sum_users 0;
  retain sum_orders 0;

  if first.date_column or first.time_column then do;
    sum_GMV = 0;
    sum_users = 0;
    sum_orders = 0;
  end;

  sum_GMV + GMV;
  sum_users + users;
  sum_orders + orders;

  if last.date_column or last.time_column then output;
run;

```

```

data projectl.Thessaliniki_Pizza;
  set projectl.Thessaliniki_Pizza;
  keep time_column date_column sum_orders shop_cuisine shop_area shop_city;
run;

```

```

DATA projectl.Thessaliniki_Pizza;
  SET projectl.Thessaliniki_Pizza; /* Replace original_dataset with your dataset name
*/
  /* Convert times to numeric representation */
  start_time = '9:00:00't; /* 9:00:00 AM */
  end_time = '3:00:00't; /* 3:00:00 AM, next day */

  /* Check if the time is between 9:00:00 AM and midnight or it's between midnight and
  3:00:00 AM */
  if (time_column >= start_time) or (time_column <= end_time) then output;
RUN;

```

```

data projectl.Thessaliniki_Pizza;
  set projectl.Thessaliniki_Pizza;

```

```
drop start_time end_time;  
run;  
  
data projectl.Thessaliniki_Pizza;  
set projectl.Thessaliniki_Pizza;  
if date_column >= '31JUL22'd then delete;  
run;
```



## Παράρτημα Β: Κώδικας Python (Προετοιμασία δεδομένων)

- Αρχείο main
- 

```
import pandas as pd
from functions import metrics
from functions import predictions

if __name__ == '__main__':

    data = pd.read_csv('C:/Users/Kostas/Downloads/THESSALINIKI_PIZZA.csv')

    metrics(data)

    predictions(data)
```

- Αρχείο functions
- 

```
import matplotlib.pyplot as plt

def metrics(data):
    pizza_data = data
    hourly_stats = pizza_data.groupby('time_column')['sum_orders'].agg(['mean', 'max'])
    daily_stats = pizza_data.groupby('date_column')['sum_orders'].agg(['mean', 'max'])

    fig, ax = plt.subplots(2, 2, figsize=(14, 10))
    hourly_stats['mean'].plot(ax=ax[0, 0], title='Mean Orders per Hour', color='blue')
    hourly_stats['max'].plot(ax=ax[0, 1], title='Max Orders per Hour', color='green')
    daily_stats['mean'].plot(ax=ax[1, 0], title='Mean Orders per Day', color='blue')
    daily_stats['max'].plot(ax=ax[1, 1], title='Max Orders per Day', color='green')
    ax[0, 0].set_xlabel('Hour')
    ax[0, 0].set_ylabel('Mean Orders')
    ax[0, 1].set_xlabel('Hour')
    ax[0, 1].set_ylabel('Max Orders')
    ax[1, 0].set_xlabel('Date')
    ax[1, 0].set_ylabel('Mean Orders')
    ax[1, 1].set_xlabel('Date')
    ax[1, 1].set_ylabel('Max Orders')
    plt.tight_layout()
```

```

plt.show()

pizza_data['total_orders'] = pizza_data.groupby('date_column')
['sum_orders'].transform('sum')
pizza_data['rolling_avg'] = pizza_data['total_orders'].rolling(window=7,
center=True).mean()

fig, ax = plt.subplots(figsize=(10, 6))
pizza_data.drop_duplicates('date_column')[['date_column',
'rolling_avg']].set_index('date_column').plot(ax=ax)
ax.set_title('7-Day Rolling Average of Orders')
ax.set_xlabel('Date')
ax.set_ylabel('Average Orders')
ax.grid(True)
plt.show()

def predictions(data):
    import pandas as pd
    import matplotlib.pyplot as plt
    from statsmodels.tsa.arima.model import ARIMA
    from statsmodels.tsa.statespace.sarimax import SARIMAX

    pizza_data = data
    pizza_data['timestamp'] = pd.to_datetime(pizza_data['timestamp'])
    pizza_data.set_index('timestamp', inplace=True)
    pizza_data = pizza_data.reindex(pd.date_range(start=pizza_data.index.min(),
end=pizza_data.index.max(), freq='H'))
    pizza_data['sum_orders'].fillna(method='ffill', inplace=True)
    orders_series = pizza_data['sum_orders']

    arima_model = ARIMA(orders_series, order=(2, 1, 2))
    fitted_arima_model = arima_model.fit()

    sarima_model = SARIMAX(orders_series, order=(2, 1, 2), seasonal_order=(1, 1, 1, 12))
    fitted_sarima_model = sarima_model.fit()

    arima_forecast = fitted_arima_model.get_forecast(steps=48)
    sarima_forecast = fitted_sarima_model.get_forecast(steps=48)

```

```

def filter_hours(dt):
    return dt.hour >= 9 or dt.hour <= 3

    arima_predicted_values =
arima_forecast.predicted_mean[arima_forecast.predicted_mean.index.map(filter_hours)]
    sarima_predicted_values =
sarima_forecast.predicted_mean[sarima_forecast.predicted_mean.index.map(filter_hours)]

arima_predicted_df = pd.DataFrame({
    'Time': arima_predicted_values.index,
    'ARIMA Predicted Orders': arima_predicted_values
})

sarima_predicted_df = pd.DataFrame({
    'Time': sarima_predicted_values.index,
    'SARIMA Predicted Orders': sarima_predicted_values
})

print("ARIMA Predictions:")
print(arima_predicted_df)
print("\nSARIMA Predictions:")
print(sarima_predicted_df)

plt.figure(figsize=(14, 7))
plt.plot(arima_predicted_values.index, arima_predicted_values, label='ARIMA
Predictions', color='red')
plt.plot(sarima_predicted_values.index, sarima_predicted_values, label='SARIMA
Predictions', color='green')
plt.title('ARIMA and SARIMA Predictions (Filtered Hours)')
plt.xlabel('Date')
plt.ylabel('Number of Orders')
plt.legend()
plt.show()

```

## ΒΙΒΛΙΟΓΡΑΦΙΑ - ΑΝΑΦΟΡΕΣ

- [1] A. Shankar, C. Jebarajakirthy, P. Nayal, H. I. Maseeh, A. Kumar, and A. Sivapalan, 'Online food delivery: A systematic synthesis of literature and a framework development', *Int. J. Hosp. Manag.*, vol. 104, p. 103240, Jul. 2022, doi: 10.1016/j.ijhm.2022.103240.
- [2] K. Ahuja, V. Chandra, V. Lord, and C. Peens, 'Ordering in: The rapid evolution of food delivery', *McKinsey Co.*, vol. 22, 2021.
- [3] 'Online Food Delivery Statistics and Growth: Market Overview'. Accessed: Jun. 15, 2024. [Online]. Available: <https://deonde.co/blog/online-food-delivery-statistics/>
- [4] Α. Δόμβρης, 'Η ηλεκτρονική παραγγελία στον κλάδο της εστίασης', Medium. Accessed: Mar. 31, 2023. [Online]. Available: <https://medium.com/@adomvris/>
- [5] 'On-demand food delivery: investigating the economic performances | Request PDF', *ResearchGate*, doi: 10.1108/IJRDM-02-2020-0043.
- [6] 'The Impact of Accurate Demand Forecasting on Restaurant Success | LinkedIn'. Accessed: Jun. 15, 2024. [Online]. Available: <https://www.linkedin.com/pulse/impact-accurate-demand-forecasting-restaurant-success-bharat-palliyil/>
- [7] 'Data Analytics in Food Delivery Services: Enhancing Efficiency and Customer Satisfaction | LinkedIn'. Accessed: Jun. 15, 2024. [Online]. Available: <https://www.linkedin.com/pulse/data-analytics-food-delivery-services-enhancing-customer-kekare-fvy9f/>
- [8] 'A new key performance indicator model for demand forecasting in inventory management considering supply chain reliability and seasonality', *Supply Chain Anal.*, vol. 3, p. 100026, Sep. 2023, doi: 10.1016/j.sca.2023.100026.
- [9] X. Yu, A. Lan, and H. Mao, 'Short-Term Demand Prediction for On-Demand Food Delivery with Attention-Based Convolutional LSTM', *Systems*, vol. 11, no. 10, Art. no. 10, Oct. 2023, doi: 10.3390/systems11100485.
- [10] F. Zhang, Y. Ji, H. Lv, X. Ma, C. Kuai, and W. Li, 'Investigating factors influencing takeout shopping demand under COVID-19: Generalized additive mixed models', *Transp. Res. Part Transp. Environ.*, vol. 107, p. 103285, Jun. 2022, doi: 10.1016/j.trd.2022.103285.
- [11] G. Büyükközkán and F. Göçer, 'Digital Supply Chain: Literature review and a proposed framework for future research', *Comput. Ind.*, vol. 97, pp. 157–177, 2018.
- [12] K. Govindan, T. E. Cheng, N. Mishra, and N. Shukla, 'Big data analytics and application for logistics and supply chain management', *Transportation Research Part E: Logistics and Transportation Review*, vol. 114. Elsevier, pp. 343–349, 2018.
- [13] Andreas Zaras, Data Scientist, 'Demand forecasting in practice'.
- [14] C. W. Chase, *Demand-driven forecasting: a structured approach to forecasting*. John Wiley & Sons, 2013.
- [15] R. F. Muth, 'The Derived Demand Curve for a Productive Factor and the Industry Supply Curve', *Oxf. Econ. Pap.*, vol. 16, no. 2, pp. 221–234, 1964.
- [16] M. C. Ruiz-Abellón, L. A. Fernández-Jiménez, A. Guillamón, A. Falces, A. García-Garre, and A. Gabaldón, 'Integration of Demand Response and Short-Term Forecasting for the Management of Prosumers' Demand and Generation', *Energies*, vol. 13, no. 1, Art. no. 1, Jan. 2020, doi: 10.3390/en13010011.
- [17] R. Carbonneau, K. Laframboise, and R. Vahidov, 'Application of machine learning techniques for supply chain demand forecasting', *Eur. J. Oper. Res.*, vol. 184, no. 3, pp. 1140–1154, Feb. 2008, doi: 10.1016/j.ejor.2006.12.004.
- [18] 'Demand Forecasts in Organizational Planning', Strategic Finance. Accessed: Jan. 19, 2023. [Online]. Available: <https://sfmagazine.com/post-entry/april-2021-demand-forecasts-in-organizational-planning/>

- [19] 'The Advantages of Demand Forecasting', Small Business - Chron.com. Accessed: Jan. 19, 2023. [Online]. Available: <https://smallbusiness.chron.com/advantages-demand-forecasting-60405.html>
- [20] M. Leonard and S. Institute, 'Promotional Analysis and Forecasting for Demand Planning: A Practical Time Series Approach'.
- [21] 'Price Elasticity of Demand Meaning, Types, and Factors That Impact It', Investopedia. Accessed: Jan. 20, 2023. [Online]. Available: <https://www.investopedia.com/terms/p/priceelasticity.asp>
- [22] S. Staff, 'Demand Forecasting: A Complete Guide', Salesforce. Accessed: Jun. 15, 2024. [Online]. Available: <https://www.salesforce.com/au/blog/demand-forecasting-guide/>
- [23] G. Zotteri and M. Kalchschmidt, 'Forecasting practices: Empirical evidence and a framework for research', *Int. J. Prod. Econ.*, vol. 108, no. 1, pp. 84–99, Jul. 2007, doi: 10.1016/j.ijpe.2006.12.004.
- [24] S. Sona, 'Understanding Quantitative Methods of Forecasting - hmhub'. Accessed: Mar. 25, 2023. [Online]. Available: <https://hmhub.in/quantitative-methods-of-forecasting/>
- [25] M. S. Rahman, 'The Advantages and Disadvantages of Using Qualitative and Quantitative Approaches and Methods in Language "Testing and Assessment" Research: A Literature Review', Oct. 2020, doi: 10.5539/jel.v6n1p102.
- [26] T. Lo, 'An expert system for choosing demand forecasting techniques', *Int. J. Prod. Econ.*, vol. 33, no. 1, pp. 5–15, Jan. 1994, doi: 10.1016/0925-5273(94)90114-7.
- [27] A. Mitra, A. Jain, A. Kishore, and P. Kumar, 'A Comparative Study of Demand Forecasting Models for a Multi-Channel Retail Company: A Novel Hybrid Machine Learning Approach', *Oper. Res. Forum*, vol. 3, no. 4, p. 58, 2022, doi: 10.1007/s43069-022-00166-4.
- [28] F. Caniato, M. Kalchschmidt, and S. Ronchi, 'Integrating quantitative and qualitative forecasting approaches: organizational learning in an action research case', *J. Oper. Res. Soc.*, vol. 62, no. 3, pp. 413–424, Mar. 2011, doi: 10.1057/jors.2010.142.
- [29] C. Shao and L. Wang, 'Quantitative and Qualitative Forecasting Applied to Supply-Chain Inventory', in *2010 Second International Conference on Multimedia and Information Technology*, Apr. 2010, pp. 184–187. doi: 10.1109/MMIT.2010.42.
- [30] M. Meneghini, M. Anzanello, A. Kahmann, and G. Tortorella, 'Quantitative demand forecasting adjustment based on qualitative factors: case study at a fast food restaurant', *Sist. Gest.*, vol. 13, no. 1, pp. 68–80, Mar. 2018, doi: 10.20985/1980-5160.2018.v13n1.1188.
- [31] '2014 April Workshop - Econometric Forecasting.pdf'. Accessed: Mar. 26, 2023. [Online]. Available: <https://www.purdue.edu/discoverypark/sufg/docs/publications/2014%20April%20Workshop%20-%20Econometric%20Forecasting.pdf>
- [32] H. O. Stekler, 'Forecasting with Econometric Models: An Evaluation', *Econometrica*, vol. 36, no. 3/4, pp. 437–463, 1968, doi: 10.2307/1909516.
- [33] 'Demand Forecasting Guide: Definiton, Types, Methods & Examples'. Accessed: Jun. 15, 2024. [Online]. Available: <https://redstagfulfillment.com/what-is-demand-forecasting/>
- [34] G. Li, H. Song, and S. F. Witt, 'Recent Developments in Econometric Modeling and Forecasting', *J. Travel Res.*, vol. 44, no. 1, pp. 82–99, Aug. 2005, doi: 10.1177/0047287505276594.
- [35] D. A. Cranage and W. P. Andrew, 'A comparison of time series and econometric models for forecasting restaurant sales', *Int. J. Hosp. Manag.*, vol. 11, no. 2, pp. 129–142, May 1992, doi: 10.1016/0278-4319(92)90006-H.
- [36] 'Forecasting demand: Quantitative and intuitive techniques', *Int. J. Tour. Manag.*, vol. 1, no. 1, pp. 5–12, Mar. 1980, doi: 10.1016/0143-2516(80)90016-X.
- [37] C. Liu, S. C. Hoi, P. Zhao, and J. Sun, 'Online arima algorithms for time series prediction', in *Proceedings of the AAAI conference on artificial intelligence*, 2016.

- [38] S. Mehrmolaei and M. R. Keyvanpour, 'Time series forecasting using improved ARIMA', in *2016 Artificial Intelligence and Robotics (IRANOPEN)*, Apr. 2016, pp. 92–97. doi: 10.1109/RIOS.2016.7529496.
- [39] M. Khashei and M. Bijari, 'A novel hybridization of artificial neural networks and ARIMA models for time series forecasting', *Appl. Soft Comput.*, vol. 11, no. 2, pp. 2664–2675, Mar. 2011, doi: 10.1016/j.asoc.2010.10.015.
- [40] V. Pant, 'Time Series Analysis using Unobserved Components Model in Python', Analytics Vidhya. Accessed: Mar. 27, 2023. [Online]. Available: <https://medium.com/analytics-vidhya/tsa-ucm-python-5fde69d42e28>
- [41] U. M. Sirisha, M. C. Belavagi, and G. Attigeri, 'Profit Prediction Using ARIMA, SARIMA and LSTM Models in Time Series Forecasting: A Comparison', *IEEE Access*, vol. 10, pp. 124715–124727, 2022, doi: 10.1109/ACCESS.2022.3224938.
- [42] N. Deretić, D. Stanimirović, M. Awadh, N. Vujanović, and A. Djukić, 'SARIMA Modelling Approach for Forecasting of Traffic Accidents', *Sustainability*, vol. 14, p. 4403, Apr. 2022, doi: 10.3390/su14084403.
- [43] Meritshot, 'Introduction to ARIMA and SARIMA for Time Series Forecasting', Medium. Accessed: May 09, 2024. [Online]. Available: <https://medium.com/@meritshot/introduction-to-arima-and-sarima-for-time-series-forecasting-5af5025c8876>
- [44] 'The UCM Procedure'.
- [45] T. Ramathan Muttar and E. Abdul-kareem Hussain, 'Time Series Forecasting with UCM Model ; A Comparative Study using the Tigris River Data', *IRAQI J. Stat. Sci.*, vol. 8, no. 14, pp. 32–47, Dec. 2008, doi: 10.33899/ijqjoss.2008.31425.
- [46] S. Nugus, *Financial planning using Excel: forecasting, planning and budgeting techniques*. Butterworth-Heinemann, 2009. Accessed: Mar. 26, 2024. [Online]. Available: [https://books.google.com/books?hl=en&lr=&id=7u6r3\\_BzJ0oC&oi=fnd&pg=PP1&dq=Financial+Planning+Using+Excel+Forecasting+Planning+and+Budgeting+Techniques&ots=VMVoHXrL\\_N&sig=Jch\\_fmTtpiAbeMxMm1p2QTEbKQU](https://books.google.com/books?hl=en&lr=&id=7u6r3_BzJ0oC&oi=fnd&pg=PP1&dq=Financial+Planning+Using+Excel+Forecasting+Planning+and+Budgeting+Techniques&ots=VMVoHXrL_N&sig=Jch_fmTtpiAbeMxMm1p2QTEbKQU)
- [47] L. Ferbar Tratar, B. Mojškerc, and A. Toman, 'Demand forecasting with four-parameter exponential smoothing', *Int. J. Prod. Econ.*, vol. 181, pp. 162–173, Nov. 2016, doi: 10.1016/j.ijpe.2016.08.004.
- [48] B. Billah, M. L. King, R. D. Snyder, and A. B. Koehler, 'Exponential smoothing model selection for forecasting', *Int. J. Forecast.*, vol. 22, no. 2, pp. 239–247, 2006.
- [49] *Forecasting: Principles and Practice (2nd ed)*. Accessed: Mar. 26, 2024. [Online]. Available: <https://otexts.com/fpp2/>
- [50] A. N. Aimran and A. Afthanorhan, 'A comparison between single exponential smoothing (SES), double exponential smoothing (DES), holt's (brown) and adaptive response rate exponential smoothing (ARRES) techniques in forecasting Malaysia population', *Glob. J. Math. Anal.*, vol. 2, no. 4, p. 276, Sep. 2014, doi: 10.14419/gjma.v2i4.3253.
- [51] L. Bogacz, 'Why should you add exponential smoothing to your forecasting toolkit', The Information Lab Nederland. Accessed: Mar. 26, 2024. [Online]. Available: <https://theinformationlab.nl/2023/02/21/why-should-you-add-exponential-smoothing-to-your-forecasting-toolkit/>
- [52] N. Malkari, 'Exponential Smoothing: A Method for Time Series Forecasting', Medium. Accessed: Mar. 26, 2024. [Online]. Available: <https://medium.com/@nikhilmalkari18/exponential-smoothing-a-method-for-time-series-forecasting-7ea35ca2c781>
- [53] 'An Introduction to Exponential Smoothing for Time Series Forecasting in Python | Simplilearn', Simplilearn.com. Accessed: Mar. 26, 2024. [Online]. Available: <https://www.simplilearn.com/exponential-smoothing-for-time-series-forecasting-in-python-article>

- [54] P. S. Kalekar, 'Time series forecasting using holt-winters exponential smoothing', *Kanwal Rekhi Sch. Inf. Technol.*, vol. 4329008, no. 13, pp. 1–13, 2004.
- [55] 'Triple Exponential Smoothing | SAP Help Portal'. Accessed: Mar. 26, 2024. [Online]. Available: [https://help.sap.com/docs/SAP\\_HANA\\_PLATFORM/2cfbc5cf2bc14f028cfbe2a2bba60a50/a25b1dee883a4bc4a984bf9496c7a954.html](https://help.sap.com/docs/SAP_HANA_PLATFORM/2cfbc5cf2bc14f028cfbe2a2bba60a50/a25b1dee883a4bc4a984bf9496c7a954.html)
- [56] L. F. Tratar, 'Forecasting method for noisy demand', *Int. J. Prod. Econ.*, vol. 161, pp. 64–73, 2015.
- [57] C. Chatfield, *Time-series forecasting*. CRC press, 2000.
- [58] V. Rastogi, 'ACF and PACF', Medium. Accessed: Mar. 27, 2024. [Online]. Available: <https://medium.com/@vaibhav1403/acf-and-pacf-4c5dd10f9af2>
- [59] A. Maravall, 'An Application of Nonlinear Time Series Forecasting', *J. Bus. Econ. Stat.*, vol. 1, no. 1, pp. 66–74, Jan. 1983, doi: 10.1080/07350015.1983.10509325.
- [60] 'Choosing the best q and p from ACF and PACF plots in ARMA-type modeling | Baeldung on Computer Science'. Accessed: Mar. 27, 2024. [Online]. Available: <https://www.baeldung.com/cs/acf-pacf-plots-arma-modeling>
- [61] '10.2 - Autocorrelation and Time Series Methods | STAT 462'. Accessed: Mar. 27, 2024. [Online]. Available: <https://online.stat.psu.edu/stat462/node/188/>
- [62] 'How do you use mean absolute percentage error (MAPE) to evaluate your demand planning performance?' Accessed: Jun. 17, 2024. [Online]. Available: <https://www.linkedin.com/advice/3/how-do-you-use-mean-absolute-percentage-error-mape>
- [63] P. Kumar, 'Qualitative Research - Meaning, Scope and Methodology - hmhub'. Accessed: Mar. 28, 2023. [Online]. Available: <https://hmhub.in/qualitative-research-meaning-scope-and-methodology/>
- [64] O. A. Hassen, S. M. Darwish, N. A. Abu, and Z. Z. Abidin, 'Application of Cloud Model in Qualitative Forecasting for Stock Market Trends', *Entropy*, vol. 22, no. 9, Art. no. 9, Sep. 2020, doi: 10.3390/e22090991.
- [65] C. Ingle, D. Bakliwal, J. Jain, P. Singh, P. Kale, and V. Chhajed, 'Demand Forecasting : Literature Review On Various Methodologies', in *2021 12th International Conference on Computing Communication and Networking Technologies (ICCCNT)*, Kharagpur, India: IEEE, Jul. 2021, pp. 1–7. doi: 10.1109/ICCCNT51525.2021.9580139.
- [66] H. Rajak, 'Qualitative Methods of Forecasting - hmhub'. Accessed: Mar. 28, 2023. [Online]. Available: <https://hmhub.in/qualitative-methods-forecasting/>
- [67] V. A. Profillidis and G. N. Botzoris, *Modeling of transport demand: Analyzing, calculating, and forecasting transport demand*. Elsevier, 2018.
- [68] G. Fliedner, 'Hierarchical forecasting: issues and use guidelines', *Ind. Manag. Data Syst.*, vol. 101, no. 1, pp. 5–12, Jan. 2001, doi: 10.1108/02635570110365952.
- [69] S. Taghiyeh, D. C. Lengacher, A. H. Sadeghi, A. Sahebi-Fakhrabad, and R. B. Handfield, 'A novel multi-phase hierarchical forecasting approach with machine learning in supply chain management', *Supply Chain Anal.*, vol. 3, p. 100032, Sep. 2023, doi: 10.1016/j.sca.2023.100032.
- [70] N. G. Reich, J. Lessler, K. Sakrejda, S. A. Lauer, S. Iamsirithaworn, and D. A. T. Cummings, 'Case Study in Evaluating Time Series Prediction Models Using the Relative Mean Absolute Error', *Am. Stat.*, vol. 70, no. 3, pp. 285–292, Jul. 2016, doi: 10.1080/00031305.2016.1148631.
- [71] 'Hierarchical structures (With helpful examples) | Indeed.com UK'. Accessed: Mar. 25, 2024. [Online]. Available: <https://uk.indeed.com/career-advice/career-development/hierarchical-structure>
- [72] E. Shlifer and R. W. Wolff, 'Aggregation and Proration in Forecasting', *Manag. Sci.*, vol. 25, no. 6, pp. 594–603, Jun. 1979, doi: 10.1287/mnsc.25.6.594.
- [73] D. M. Dunn, W. H. Williams, and T. L. Dechaine, 'Aggregate versus Subaggregate Models in Local Area Forecasting', *J. Am. Stat. Assoc.*, vol. 71, no. 353, pp. 68–71, Mar. 1976, doi: 10.1080/01621459.1976.10481478.

- [74] C. W. Gross and J. E. Sohl, 'Disaggregation methods to expedite product line forecasting', *J. Forecast.*, vol. 9, no. 3, pp. 233–254, 1990, doi: 10.1002/for.3980090304.
- [75] J. M. Oliveira and P. Ramos, 'Assessing the Performance of Hierarchical Forecasting Methods on the Retail Sector', *Entropy*, vol. 21, no. 4, Art. no. 4, Apr. 2019, doi: 10.3390/e21040436.
- [76] B. J. Dangerfield and J. S. Morris, 'Top-down or bottom-up: Aggregate versus disaggregate extrapolations', *Int. J. Forecast.*, vol. 8, no. 2, pp. 233–241, Oct. 1992, doi: 10.1016/0169-2070(92)90121-O.
- [77] H. Widiarta, S. Viswanathan, and R. Piplani, 'Forecasting aggregate demand: An analytical evaluation of top-down versus bottom-up forecasting in a production planning framework', *Int. J. Prod. Econ.*, vol. 118, no. 1, pp. 87–94, Mar. 2009, doi: 10.1016/j.ijpe.2008.08.013.
- [78] G. Athanasopoulos and N. Kourentzes, 'On the evaluation of hierarchical forecasts', *Int. J. Forecast.*, vol. 39, no. 4, pp. 1502–1511, Oct. 2023, doi: 10.1016/j.ijforecast.2022.08.003.
- [79] J. C. Brocklebank and D. A. Dickey, *SAS for forecasting time series*. John Wiley & Sons, 2003. Accessed: Apr. 01, 2024. [Online]. Available: <https://books.google.com/books?hl=en&lr=&id=WAXpv2t11sC&oi=fnd&pg=PR7&dq=sas+in+forecasting&ots=SiGqdqlRgD&sig=yHagAMvsgehTxd08zR3E5YC5NwQ>
- [80] R. A. Yaffee and M. McGee, *An introduction to time series analysis and forecasting: with applications of SAS® and SPSS®*. Elsevier, 2000. Accessed: Apr. 01, 2024. [Online]. Available: <https://books.google.com/books?hl=en&lr=&id=mCiDTZDKwUwC&oi=fnd&pg=PP2&dq=sas+in+forecasting&ots=eax8tWHDzz&sig=aDUWnWv-lkZP84oFisOb2p1xD9U>
- [81] 'management-forecasting-104529.pdf'. Accessed: Jun. 20, 2024. [Online]. Available: <https://www.sas.com/content/dam/SAS/documents/marketing-whitepapers-ebooks/sas-whitepapers/en/management-forecasting-104529.pdf>
- [82] M. Gilliland, 'How to Get More Accurate Forecasts With Less Cost and Effort'.
- [83] 'new-product-forecasting-109813.pdf'. Accessed: Jun. 20, 2024. [Online]. Available: <https://www.sas.com/content/dam/SAS/documents/marketing-whitepapers-ebooks/sas-whitepapers/en/new-product-forecasting-109813.pdf>
- [84] 'forecasting-next-generation-demand-management-108771.pdf'. Accessed: Jun. 20, 2024. [Online]. Available: <https://www.sas.com/content/dam/SAS/documents/marketing-whitepapers-ebooks/sas-whitepapers/en/forecasting-next-generation-demand-management-108771.pdf>