



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

ΤΟΜΕΑΣ ΗΛΕΚΤΡΙΚΩΝ ΒΙΟΜΗΧΑΝΙΚΩΝ ΔΙΑΤΑΞΕΩΝ ΚΑΙ ΣΥΣΤΗΜΑΤΩΝ ΑΠΟΦΑΣΕΩΝ

**Ευφύες σύστημα για τη βέλτιστη διαχείριση  
αποθεμάτων βασισμένο σε αλγορίθμους  
μηχανικής μάθησης και μεταφοράς γνώσης**

*Intelligent system for optimal inventory management utilizing  
machine learning algorithms and transfer learning*

---

ΔΙΔΑΚΤΟΡΙΚΗ ΔΙΑΤΡΙΒΗ

**Θεοδώρου Μ. Ευάγγελος**

Αθήνα, Απρίλιος 2023

---





# Ευφυές σύστημα για τη βέλτιστη διαχείριση αποθεμάτων βασισμένο σε αλγορίθμους μηχανικής μάθησης και μεταφοράς γνώσης

*Intelligent system for optimal inventory management utilizing  
machine learning algorithms and transfer learning*

## ΔΙΔΑΚΤΟΡΙΚΗ ΔΙΑΤΡΙΒΗ

**Θεοδώρου Μ. Ευάγγελος**

**Συμβουλευτική Επιτροπή:** Βασίλειος Ασημακόπουλος, Ομ. Καθηγητής Ε.Μ.Π.  
Ιωάννης Ψαρράς, Καθηγητής Ε.Μ.Π.  
Δημήτριος Ασκούνης, Καθηγητής Ε.Μ.Π.

Εγκρίθηκε από την επταμελή εξεταστική επιτροπή την 26<sup>η</sup> Απριλίου 2023.

.....  
Βασίλειος Ασημακόπουλος  
Ομ. Καθηγητής Ε.Μ.Π.

.....  
Ιωάννης Ψαρράς  
Καθηγητής Ε.Μ.Π.

.....  
Δημήτριος Ασκούνης  
Καθηγητής Ε.Μ.Π.

.....  
Γρηγόριος Μέντζας  
Καθηγητής Ε.Μ.Π.

.....  
Χρυσόστομος Δούκας  
Αν. Καθηγητής Ε.Μ.Π.

.....  
Ευάγγελος Μαρινάκης  
Επ. Καθηγητής Ε.Μ.Π.

.....  
Κωνσταντίνος Μεταξιώτης  
Καθηγητής Παν. Πειραιώς

Αθήνα, Απρίλιος 2023

.....

**Ευάγγελος Μ. Θεοδώρου**

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

Copyright © **Ευάγγελος Θεοδώρου**, 2023

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας, εξ ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για σκοπό μη κερδοσκοπικό, εκπαιδευτικής ή ερευνητικής φύσης, υπό την προϋπόθεση να αναφέρεται η πηγή προέλευσης και να διατηρείται το παρόν μήνυμα. Ερωτήματα που αφορούν τη χρήση της εργασίας για κερδοσκοπικό σκοπό πρέπει να απευθύνονται προς τον συγγραφέα.

Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον συγγραφέα και δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις επίσημες θέσεις του Εθνικού Μετσόβιου Πολυτεχνείου.

*Στην οικογένειά μου.*



## Πρόλογος

---

Η παρούσα διδακτορική διατριβή εκπονήθηκε στα πλαίσια των ερευνητικών δραστηριοτήτων της Μονάδας Προβλέψεων και Στρατηγικής του Εργαστηρίου Συστημάτων Αποφάσεων και Διοίκησης κατά τα ακαδημαϊκά έτη 2018-2021. Η μονάδα υπάγεται στον Τομέα Ηλεκτρικών Βιομηχανικών Διατάξεων και Συστημάτων Αποφάσεων της Σχολής Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών του Εθνικού Μετσόβιου Πολυτεχνείου στην οποία και αποτελώ ενεργό μέλος ως ερευνητικός συνεργάτης από το 2018. Η ενασχόλησή μου με τις προβλέψεις και τα συστήματα υποστήριξης αποφάσεων ξεκίνησε σε προπτυχιακό επίπεδο, όταν και μέσα από το μάθημα των Τεχνικών Προβλέψεων ήρθα σε επαφή με τους ανθρώπους του εργαστηρίου και ξεκίνησα να ασχολούμαι με τους συγκεκριμένους κλάδους στο πλαίσιο της διπλωματικής μου εργασίας. Το πέρας των προπτυχιακών μου σπουδών ακολούθησε η εγγραφή μου ως Υποψήφιος Διδάκτορας του ΕΜΠ το Νοέμβριο του 2018 και η συστηματική μου ενασχόληση με το ευρύτερο επιστημονικό πεδίο των συστημάτων υποστήριξης αποφάσεων, τόσο σε θεωρητικό όσο και σε πρακτικό επίπεδο. Η ολοκλήρωση της παρούσας διατριβής αποτελεί για μένα σταθμό στην πορεία μου ως ερευνητής και ταυτόχρονα αφετηρία για μία νέα στον τομέα της επιχειρησιακής έρευνας.

Αρχικά, θα ήθελα να ευχαριστήσω τον Καθηγητή μου, Βασίλειο Ασημακόπουλο, για την ευκαιρία που μου έδωσε να ασχοληθώ με το αντικείμενο των συστημάτων αποφάσεων, την εμπιστοσύνη που μου έδειξε καθ' όλη τη διάρκεια της στενής μας συνεργασίας, αλλά και για τις πολύτιμες συμβουλές και προτάσεις του σε κάθε ζήτημα που προέκυψε μέχρι και την περαίωση της διδακτορικής μου διατριβής. Ακόμα, θα ήθελα να ευχαριστήσω τα άλλα δύο μέλη της συμβουλευτικής μου επιτροπής, τον Καθηγητή Ιωάννη Ψαρρά και τον Καθηγητή Δημήτριο Ασκούνη για την σημαντική υποστήριξή τους, όπως και τον Αν. Καθηγητή Χρυσόστομο Δούκα και τον Επ. Καθηγητή Ευάγγελο Μαρινάκη, τόσο για τη συμμετοχή τους στην επιτροπή εξέτασης, όσο και για την ευρύτερη ερευνητική μας συνεργασία. Για την τιμή που μου έκαναν να συμμετάσχουν στην επιτροπή εξέτασης θα ήθελα να ευχαριστήσω ακόμα τον Καθηγητή Γρηγόριο Μέντζα, και τον Καθηγητή Κωνσταντίνο Μεταξιώτη.

Επίσης, ιδιαίτερος θα ήθελα να ευχαριστήσω τον υπεύθυνο της Μονάδας, μέντορα, συνεργάτη και φίλο, Δρ Ευάγγελο Σπηλιώτη για την καθοδήγησή του, την υποστήριξή του και το ενδιαφέρον που συνεχίζει να δείχνει στην γενικότερη πορεία μου.

Θα ήθελα ακόμα να ευχαριστήσω τους φίλους και συνεργάτες μου στη Μονάδα Δρ Νικολέττα Ζαμπέτα Λεγάκη, Αρτέμη Σεμένογλου, Τάσο Καλτσούνη, Δρ Διαμαντή Κουτσανδρέα, Τάσο Σούρσο, Χρήστο Τσόκλα, Αχιλλέα Ράπη, Χριστίνα Κωνσταντινίδου, Άντρη Τόσκα και Γιώργο Ρήτα για την εξαιρετική συνεργασία μας. Ένα ιδιαίτερο ευχαριστώ

ανήκει στην κα. Λένα Μαυροδοπούλου για τη συνεχή βοήθειά της και συμβολή της σε κάθε πρακτική δυσκολία.

Τέλος, τη μεγαλύτερη ευγνωμοσύνη την οφείλω στους δικούς μου ανθρώπους, συγγενείς και φίλους, για τη στήριξή τους όλα αυτά τα χρόνια και την ενθάρρυνση όταν ο δρόμος φάνταζε μακρύς. Ευχαριστώ τους γονείς μου, Ελένη και Μάριο, και τον αδελφό μου, Φάνη, που πάντα με στηρίζουν και πιστεύουν σε μένα, αλλά κυρίως για την αγάπη που με περιβάλλουν.

Ευάγγελος Θεοδώρου  
Αθήνα, Απρίλιος 2023



## Περίληψη

---

Οι αλγόριθμοι μηχανικής μάθησης έχουν δείξει μεγάλες δυνατότητες σε διάφορους τομείς, αλλά η εμφάνισή τους στη βελτιστοποίηση των ρυθμίσεων διαχείρισης αποθεμάτων, που αποτελεί σημαντικό μέρος μιας εφοδιαστικής αλυσίδας, και πρωταρχικής σημασίας για τις εταιρείες λιανικής, παραμένει περιορισμένη.

Αντικείμενο της παρούσας διατριβής είναι η ανάπτυξη ενός ολοκληρωμένου συστήματος βελτιστοποίησης των πολιτικών αποθεματοποίησης μέσω της ελαχιστοποίησης του συνολικού κόστους αποθεματοποίησης, το οποίο εκμεταλλεύεται προηγμένα μοντέλα μηχανικής μάθησης, που βασίζονται σε δέντρα αποφάσεων, προκειμένου να προσεγγίσει τις επιμέρους συνιστώσες που επηρεάζουν άμεσα το συνολικό κόστος σε επίπεδο προϊόντος. Τα μοντέλα μηχανικής μάθησης, έτσι, δύνανται να προσεγγίσουν αυτές τις επιμέρους συνιστώσες λαμβάνοντας ως εισόδους τα μοτίβα εμφάνισης της ζήτησης, δηλαδή τα χαρακτηριστικά των χρονοσειρών που αναπαριστούν τη ζήτηση, και τις βασικές παραμέτρους της πολιτικής αποθεματοποίησης που χρησιμοποιείται.

Η προτεινόμενη τεχνική βασίζεται σε δεδομένα και είναι ταχύτερη σε σύγκριση με τους διαδεδομένους τρόπους βελτιστοποίησης της διαδικασίας αποθεματοποίησης, μέσω προσομοιώσεων, χωρίς, όμως, να υπολείπεται σε απόδοση, ενώ παράλληλα είναι ευέλικτη ως προς τις μεθόδους που μπορεί να χρησιμοποιήσει για την πρόβλεψη της ζήτησης ή την εκτίμηση του μέσου επιπέδου αποθέματος, των χαμένων πωλήσεων και του αριθμού παραγγελιών, μεταξύ άλλων. Επιπλέον, το εν λόγω πλαίσιο, εφόσον αυτό είναι επιθυμητό, μπορεί να κάνει χρήση γνώσεων που εξάγονται από διαφορετικά σύνολα δεδομένων από αυτά που βελτιστοποιούνται, τεχνική που ονομάζεται μεταφορά μάθησης, παρέχοντας έτσι πιο ακριβείς προτάσεις σε περιπτώσεις όπου τα ιστορικά δεδομένα είναι ελλιπή ή περιορισμένου μεγέθους.

Το πλαίσιο αξιολογήθηκε χρησιμοποιώντας δεδομένα του διαγωνισμού προβλέψεων M5, με τα αποτελέσματα να υποδηλώνουν ότι το προτεινόμενο πλαίσιο, και ιδιαίτερα η προσέγγιση που κάνει χρήση μεταφοράς μάθησης, μπορεί να οδηγήσει σε σημαντικές βελτιώσεις, τόσο ως προς το συνολικό κόστος αποθεματοποίησης όσο και ως προς το επίπεδο εξυπηρέτησης πελατών.

Τέλος, στο πλαίσιο της διατριβής αναπτύχθηκε, επίσης, ένα ισχυρό σύστημα υποστήριξης αποφάσεων, το οποίο εμπεριέχει την προσέγγιση μεταφοράς μάθησης του προτεινόμενου πλαισίου, δημιουργώντας ένα φιλικό προς τον χρήστη και πολύτιμο εργαλείο για τους υπεύθυνους λήψης αποφάσεων.

## **Λέξεις Κλειδιά**

Συστήματα υποστήριξης λήψης αποφάσεων, Συστήματα διαχείρισης αποθεμάτων, Κόστος αποθεματοποίησης, Χρονοσειρές διακοπόμενης ζήτησης, Πρότυπα ζήτησης, Μηχανική μάθηση, Μεταφορά μάθησης

# Abstract

---

Inventory policy optimization is a critical component of supply chain management. Well planned inventory management can boost operational efficiency and profitability, allowing businesses to meet customer demands while reducing costs. Machine learning algorithms have shown great promise in a variety of domains, including supply chain, in recent years. However, the application of machine learning in the field of inventory policy optimization has been rather limited, with organizations frequently relying on standard simulations to inform their decisions.

To address this gap, this dissertation creates a novel inventory cost minimization framework based on advanced decision-tree based machine learning models. The proposed approach approximates inventory performance at the item level while taking key replenishment policy parameters and demand patterns into account. Several advantages of the proposed approach over traditional inventory simulations include flexibility, adaptability and the ability to quickly compute data-driven approximations. The framework can also incorporate knowledge from items other than those being optimized, which is useful when historical data is limited or heavily influenced by stock-outs.

To evaluate the effectiveness of the proposed framework, the M5 competition dataset was used. The study's findings revealed that the methodology, particularly its transfer learning variant, resulted in significant reductions in total inventory cost while maintaining the same or even improving customer service level. The proposed framework was also incorporated in a decision support system, giving organizations a user friendly and valuable tool aiding in inventory management.

In conclusion, the proposed framework makes an important contribution to the field of supply chain management. The framework provides a highly efficient and effective method for optimizing inventory control settings by leveraging advanced machine learning models. This approach has the potential to transform inventory management practices, resulting in significant improvements in operational efficiency and profitability.

## Keywords

Decision support systems, Inventory management, Inventory cost, Intermittent demand time series, Demand patterns, Machine learning, Transfer learning



# Περιεχόμενα

<b>Πρόλογος</b>	<b>7</b>
<b>Περίληψη</b>	<b>9</b>
<b>Abstract</b>	<b>11</b>
<b>Περιεχόμενα</b>	<b>13</b>
<b>Ευρετήριο Σχημάτων</b>	<b>17</b>
<b>Ευρετήριο Πινάκων</b>	<b>23</b>
<b>Ευρεία Περίληψη</b>	<b>25</b>
<b>Extended Summary</b>	<b>33</b>
<b>1<sup>ο</sup> Κεφάλαιο: Εισαγωγή</b>	<b>41</b>
1.1 Πρόλογος . . . . .	41
1.2 Αντικείμενο και στόχος της διατριβής . . . . .	43
1.3 Συμβολή της διατριβής . . . . .	45
1.4 Δομή της διατριβής . . . . .	46
1.5 Ερευνητικά αποτελέσματα της διατριβής . . . . .	47
<b>2<sup>ο</sup> Κεφάλαιο: Συστήματα διαχείρισης αποθεμάτων</b>	<b>51</b>
2.1 Εισαγωγή στη διαχείριση αποθεμάτων . . . . .	51
2.2 Κατηγοριοποίηση αποθεμάτων . . . . .	53
2.2.1 Αποθέματα βάσει της ροής τους . . . . .	53
2.2.2 Αποθέματα βάσει της χρήσης τους . . . . .	54
2.3 Πλεονεκτήματα διατήρησης αποθεμάτων . . . . .	55
2.4 Μειονεκτήματα διατήρησης αποθεμάτων . . . . .	55
2.5 Στοιχεία κόστους αποθεματοποίησης . . . . .	56
2.5.1 Κόστος τοποθέτησης παραγγελίας (Ordering Cost) . . . . .	56
2.5.2 Κόστος ελέγχου αποθεμάτων (Review Cost) . . . . .	56
2.5.3 Κόστος διατήρησης αποθεμάτων (Carrying or Holding Cost) . . . . .	57
2.5.4 Κόστος έλλειψης αποθεμάτων (Shortage or Lost sales Cost) . . . . .	58
2.5.5 Κόστος αγοράς αποθεμάτων (Purchasing or Item Cost) . . . . .	59
2.6 Κατηγοριοποίηση συστημάτων διαχείρισης αποθεμάτων . . . . .	59

2.7	Μη εξυπηρετούμενη ζήτηση . . . . .	61
2.8	Πολιτική Οικονομικής Ποσότητας Παραγγελίας (Economic Order Quantity) . . . . .	61
2.9	Πολιτική αποθέματος ασφαλείας . . . . .	64
2.10	Πολιτικές αποθεματοποίησης πολλαπλών περιόδων . . . . .	66
2.10.1	Πολιτικές συνεχούς εξέτασης (Continuous review models) . . . . .	67
2.10.1.1	Πολιτική (s, Q) . . . . .	67
2.10.1.2	Πολιτική (s, S) . . . . .	68
2.10.2	Πολιτικές περιοδικής εξέτασης (Periodic review models) . . . . .	68
2.10.2.1	Πολιτική (R, s, Q) . . . . .	69
2.10.2.2	Πολιτική (R, s, S) . . . . .	69
2.11	Κριτήρια απόδοσης πολιτικών . . . . .	70
2.12	Βελτιστοποίηση της επιλεγμένης πολιτικής . . . . .	72
2.13	Ταξινόμηση βάσει κριτηρίων αξίας (A-B-C) . . . . .	73
<b>3°</b>	<b>Κεφάλαιο: Ανάλυση και κατηγοριοποίηση χρονοσειρών</b>	<b>77</b>
3.1	Ποιοτικά χαρακτηριστικά χρονοσειρών . . . . .	77
3.2	Αποσύνθεση χρονοσειρών . . . . .	81
3.3	Στατιστική ανάλυση χρονοσειρών . . . . .	82
3.4	Χρονοσειρές διακοπτόμενης ζήτησης . . . . .	85
3.5	Στατιστική ανάλυση χρονοσειρών διακοπτόμενης ζήτησης . . . . .	86
3.6	Κατηγοριοποίηση χρονοσειρών . . . . .	88
3.6.1	Κατηγοριοποίηση σύμφωνα με τον Williams (1984) . . . . .	88
3.6.2	Κατηγοριοποίηση σύμφωνα με τους Johnston & Boylan (1996) . . . . .	89
3.6.3	Κατηγοριοποίηση σύμφωνα με τους Eaves & Kingsman (2004) . . . . .	89
3.6.4	Κατηγοριοποίηση σύμφωνα με τους Syntetos et al. (2005) . . . . .	90
3.6.5	Κατηγοριοποίηση σύμφωνα με τους Boylan et al. (2008) . . . . .	92
<b>4°</b>	<b>Κεφάλαιο: Μέθοδοι στατιστικής πρόβλεψης χρονοσειρών</b>	<b>95</b>
4.1	Διαδεδομένες τεχνικές πρόβλεψης χρονοσειρών συνεχούς ζήτησης . . . . .	96
4.1.1	Απλοϊκή μέθοδος (Naive) . . . . .	96
4.1.2	Μέθοδοι μέσων όρων . . . . .	96
4.1.3	Απλή γραμμική παλινδρόμηση (Simple linear regression) . . . . .	97
4.1.4	Μοντέλα εκθετικής εξομάλυνσης . . . . .	97
4.1.4.1	Απλή εκθετική εξομάλυνση (Simple exponential smoothing) . . . . .	98
4.1.4.2	Εκθετική εξομάλυνση με τάση . . . . .	98
4.1.4.3	Εκθετική εξομάλυνση με εποχιακότητα . . . . .	100
4.1.5	Μέθοδος ETS (Error/Trend/Seasonality) . . . . .	101
4.1.6	Μέθοδος $\theta$ (Theta method) . . . . .	103
4.2	Διαδεδομένες τεχνικές πρόβλεψης χρονοσειρών διακοπτόμενης ζήτησης . . . . .	105
4.2.1	Μέθοδος Croston . . . . .	105
4.2.2	Παραλλαγές της μεθόδου Croston . . . . .	107
4.2.2.1	Μέθοδος SBA (Syntetos-Boylan Approximation) . . . . .	107
4.2.2.2	Μέθοδος modified Croston (mCroston) και προσαρμογές . . . . .	107

4.2.2.3	Μέθοδος SBJA (Shale-Boylan-Johnston Approximation)	108
4.2.2.4	Μέθοδος TSB (Teunter-Syntetos-Babai)	108
4.2.2.5	Μέθοδος modified SBA (mSBA)	109
4.2.2.6	Μέθοδος modified TSB (mTSB)	109
4.2.3	Αυτοπαλινδρομούμενα μοντέλα κινητού μέσου όρου (AutoRegressive Moving Average)	109
4.2.3.1	Μοντέλα ARMA	109
4.2.3.2	Μοντέλα DARMA (Discrete ARMA)	110
4.2.3.3	Μοντέλα INARMA (INteger-valued ARMA)	110
4.2.4	Τεχνικές Bootstrapping	111
4.2.5	Τεχνικές πρόβλεψης μέσω χρονικής συνάθροισης (Temporal aggregation)	112
4.2.5.1	Μέθοδος ADIDA (Aggregate-Disaggregate Intermittent Demand Approach)	113
4.2.5.2	Μέθοδος iADIDA (inverse ADIDA)	113
4.2.5.3	Μέθοδος iMAPA (Multiple Aggregation Prediction Algorithm for intermittent demand)	114
4.3	Πιθανοτικές προβλέψεις (Probabilistic forecasting)	116
4.4	Επιλογή της καταλληλότερης μεθόδου πρόβλεψης	118
4.5	Κριτήρια απόδοσης μοντέλων πρόβλεψης	121
4.6	Ακρίβεια προβλέψεων και συστήματα διαχείρισης αποθεμάτων	126
<b>5° Κεφάλαιο: Παραγωγή τεχνητών χρονοσειρών και προσομοίωση αποθέματος</b>		<b>129</b>
5.1	Ανασκόπηση γεννητριών παραγωγής τεχνητών χρονοσειρών	129
5.2	Γεννήτρια παραγωγής τεχνητών χρονοσειρών	130
5.2.1	Υλοποίηση γεννήτριας και παραγωγή χρονοσειρών	131
5.2.2	Παρουσίαση των παραγόμενων χρονοσειρών	134
5.3	Διαγωνισμοί προβλέψεων M	136
5.4	Αντιπροσωπευτικότητα των παραγόμενων χρονοσειρών	141
5.5	Προσομοίωση της διαδικασίας αποθεματοποίησης	146
<b>6° Κεφάλαιο: Μηχανική μάθηση</b>		<b>151</b>
6.1	Είδη μηχανικής μάθησης	151
6.2	Μηχανική μάθηση με επιτήρηση	153
6.2.1	Μηχανές διανυσμάτων υποστήριξης (Support Vector Machines)	153
6.2.2	Νευρωνικά δίκτυα (Neural Networks)	153
6.2.3	Δέντρα αποφάσεων (Decision trees)	155
6.2.3.1	Τυχαία δάση (Random forests)	159
6.2.3.2	Ενίσχυση κλίσης (Gradient Boosting)	160
6.2.3.3	Light Gradient Boosting Machine (LightGBM)	161
6.3	Σημαντικότητα ανεξάρτητων μεταβλητών (Feature importance)	164
6.4	Μεταφορά μάθησης (Transfer learning)	166
6.5	Μηχανική μάθηση και συστήματα διαχείρισης αποθεμάτων	168

6.6	Μηχανική μάθηση και προβλέψεις χρονοσειρών διακοπτόμενης ζήτησης . . .	171
<b>7°</b>	<b>Κεφάλαιο: Προτεινόμενο μεθοδολογικό πλαίσιο</b>	<b>175</b>
7.1	Στοιχεία του μεθοδολογικού πλαισίου . . . . .	175
7.2	Αλγόριθμος βελτιστοποίησης . . . . .	180
<b>8°</b>	<b>Κεφάλαιο: Πειραματική διάταξη - Παρουσίαση και ανάλυση αποτελεσμάτων</b>	<b>185</b>
8.1	Δεδομένα . . . . .	185
8.2	Πειραματική διάταξη . . . . .	186
8.3	Αποτελέσματα μεθοδολογίας για τα δεδομένα του διαγωνισμού M5 . . . . .	189
8.4	Ακρίβεια προβλέψεων και συνολικό κόστος αποθεματοποίησης . . . . .	197
8.5	Ευαισθησία του συνολικού κόστους αποθεματοποίησης ως προς τους παράγοντες που το διαμορφώνουν . . . . .	202
<b>9°</b>	<b>Κεφάλαιο: Πληροφοριακό σύστημα</b>	<b>213</b>
9.1	Ανάπτυξη και λειτουργικότητα . . . . .	213
9.2	Αρχιτεκτονική συστήματος . . . . .	215
9.3	Παρουσίαση συστήματος . . . . .	217
<b>10°</b>	<b>Κεφάλαιο Συμπεράσματα και προεκτάσεις</b>	<b>227</b>
10.1	Ανασκόπηση . . . . .	227
10.2	Συμβολή και στοιχεία καινοτομίας . . . . .	229
10.3	Συμπεράσματα διατριβής . . . . .	230
10.4	Προεκτάσεις διατριβής . . . . .	232
	<b>Βιβλιογραφία</b>	<b>251</b>
	<b>Παραρτήματα</b>	<b>253</b>
<b>A.</b>	<b>Ανάπτυξη σε R</b>	<b>255</b>
A.1	Συνάρτηση υπολογισμού χαρακτηριστικών χρονοσειράς . . . . .	255
A.2	Συνάρτηση υπολογισμού αποθέματος ασφαλείας σύμφωνα με τη μέθοδο του Greasley (2013) . . . . .	256
A.3	Συνάρτηση παραγωγής προβλέψεων σύμφωνα με τη μέθοδο του Croston (1972) . . . . .	257
A.4	Συνάρτηση προσομοίωσης της διαδικασίας αποθεματοποίησης κάνοντας χρήση της πολιτικής $(R, s, S)$ . . . . .	257
<b>B.</b>	<b>Λίστα Δημοσιεύσεων</b>	<b>261</b>
B.1	Δημοσιεύσεις σε επιστημονικά περιοδικά . . . . .	261
B.2	Ανακοινώσεις σε επιστημονικά συνέδρια . . . . .	261



# Ευρετήριο Σχημάτων

1.1	Αρχιτεκτονική εφοδιαστικής αλυσίδας. . . . .	41
1.2	Ερευνητικά πεδία της εφοδιαστικής αλυσίδας. . . . .	43
1.3	Δομή της παρούσας διδακτορικής διατριβής. . . . .	46
2.1	Απεικόνιση αναλογίας αποθέματος με δεξαμενή νερού. . . . .	52
2.2	Κατηγορίες αποθεμάτων βάσει της ροής τους. . . . .	53
2.3	Ταξινόμηση συστημάτων διαχείρισης αποθεμάτων. . . . .	59
2.4	Μοντέλο Οικονομική Ποσότητας Παραγγελίας (EOQ). . . . .	62
2.5	Εντοπισμός της βέλτιστης ποσότητας παραγγελίας και του ελαχίστου συνολικού κόστους αποθεματοποίησης. . . . .	63
2.6	Πολιτικές χωρίς (επάνω) και με (κάτω) απόθεμα ασφαλείας. . . . .	65
2.7	Πολιτική συνεχούς εξέτασης σταθερής ποσότητας παραγγελίας ( $s, Q$ ). . . . .	67
2.8	Πολιτική συνεχούς εξέτασης μεταβλητής ποσότητας παραγγελίας ( $s, S$ ). . . . .	68
2.9	Πολιτική περιοδικής εξέτασης σταθερής ποσότητας παραγγελίας ( $R, s, Q$ ). . . . .	69
2.10	Πολιτική περιοδικής εξέτασης μεταβλητής ποσότητας παραγγελίας ( $R, s, S$ ). . . . .	70
2.11	Παράδειγμα tradeoff curves τριών εναλλακτικών στρατηγικών για επίπεδα εξυπηρέτησης πελατών στόχους από 90% έως 99%. . . . .	71
2.12	Τρισδιάστατος χώρος συνολικού κόστους αποθέματος όταν μεταβάλλονται τα $R$ και $L$ . (Πηγή: Theodorou et al. (2021a)) . . . . .	73
2.13	Η αρχή Pareto. (Πηγή: Στειακάκης & Κωφίδης (2017)) . . . . .	74
2.14	Διάγραμμα ABC με ποσοστό συνολικής αξίας εμπορευμάτων σε σχέση με τα συνολικά αποθέματα και καμπύλη Pareto. . . . .	75
3.1	Χρονοσειρές του διαγωνισμού M3 με έντονο το χαρακτηριστικό της τάσης, εκθετικής (αριστερά) και γραμμικής (δεξιά). (Πηγή: Σπηλιώτης (2017)) . . . . .	78
3.2	Χρονοσειρά του διαγωνισμού M3 με έντονο το χαρακτηριστικό της κυκλικότητας. (Πηγή: Σπηλιώτης (2017)) . . . . .	79
3.3	Χρονοσειρά του διαγωνισμού M3 με έντονο το χαρακτηριστικό της εποχιακότητας. (Πηγή: Σπηλιώτης (2017)) . . . . .	79
3.4	Χρονοσειρά του διαγωνισμού M3 με έντονο το χαρακτηριστικό της τυχαιότητας. (Πηγή: Σπηλιώτης (2017)) . . . . .	80
3.5	Χρονοσειρά, η οποία αναπαριστά κλήσεις σε τηλεφωνικό κέντρο ελληνικής επιχείρησης, με έντονες ασυνέχειες λόγω της επίπτωσης του lockdown που επεβλήθη στην Ελλάδα στις αρχές του 2020 ως μέτρο προστασίας από την πανδημία του COVID-19. (Πηγή: Theodorou et al. (2020)) . . . . .	80
3.6	Χρονοσειρά διακοπτόμενης φύσης. . . . .	85

3.7	Απεικόνιση συστήματος κατηγοριοποίησης σύμφωνα με τον Williams (1984) .	89
3.8	Απεικόνιση συστήματος κατηγοριοποίησης σύμφωνα με τους Eaves & Kingsman (2004) . . . . .	90
3.9	Απεικόνιση συστήματος κατηγοριοποίησης σύμφωνα με τους Syntetos et al. (2005). . . . .	91
3.10	Χώρος παραμέτρων για τον οποίο κάθε μέθοδος πρόβλεψης είναι καλύτερη από την άλλη, σύμφωνα με την διόρθωση των Kostenko & Hyndman (2006) στο σύστημα των Syntetos et al. (2005). . . . .	92
3.11	Απεικόνιση συστήματος κατηγοριοποίησης σύμφωνα με τους Boylan et al. (2008) . . . . .	92
4.1	Διαδικασία πρόβλεψης της κλασσικής μεθόδου $\theta$ , κάνοντας χρήση δύο γραμμών με παραμέτρους $\theta = 0$ και $\theta = 2$ . . . . .	104
4.2	Απεικόνιση των βημάτων που ακολουθούνται κατά την πρόβλεψη μιας χρονοσειράς με τη μέθοδο ADIDA. (Πηγή: Nikolopoulos et al. (2011)) . . . .	114
4.3	Χρονοσειρά διακοπτόμενης φύσης (επάνω) και η αντίστροφή της (κάτω) σύμφωνα με το μεθοδολογικό πλαίσιο της iADIDA. . . . .	115
4.4	Διαίρεση της κατανομής σε ποσοστημόρια. . . . .	117
4.5	Μορφή μελλοντικών προβλέψεων με απεικόνιση των prediction intervals (μπλε γραμμές). . . . .	117
4.6	Η τεχνική της κυλιόμενης πρόβλεψης (rolling forecasting), αυξανόμενου παραθύρου (επάνω) και σταθερού παραθύρου (κάτω). . . . .	120
4.7	Η τεχνική του επικαλυπτόμενου (overlapping) παραθύρου (επάνω) και του μη επικαλυπτόμενου (non-overlapping) παραθύρου (κάτω). . . . .	120
4.8	Απεικόνιση των εννοιών της προκατάληψης (bias) και της ακρίβειας (precision)126	
5.1	Το γραφικό περιβάλλον της R, RStudio. . . . .	133
5.2	Κατηγοριοποίηση των παραγόμενων χρονοσειρών με βάση το $ADI$ και το $CV^2$ . 135	
5.3	Ενδεικτικές χρονοσειρές του παραγόμενου συνόλου δεδομένων. . . . .	136
5.4	Ομαδοποιημένες χρονοσειρές που χρησιμοποιούνται στον διαγωνισμό M5. Τα δεδομένα συγκεντρώνονται σε 12 επίπεδα συνάθροισης χρησιμοποιώντας πληροφορίες είτε τοποθεσίας είτε σχετικές με το προϊόν. . . . .	138
5.5	Απεικόνιση των πολιτειών προέλευσης των δεδομένων του διαγωνισμού M5 στο χάρτη των ΗΠΑ. . . . .	138
5.6	Κατηγοριοποίηση των χρονοσειρών του διαγωνισμού M5 με βάση το $ADI$ και το $CV^2$ , σύμφωνα με την κατηγοριοποίηση των Syntetos et al. (2005), ανά επίπεδο συνάθροισης. (Πηγή: Makridakis et al. (2022)) . . . . .	139
5.7	Κατηγοριοποίηση των χρονοσειρών του επιπέδου συνάθροισης 12 του διαγωνισμού M5 με βάση το $ADI$ και το $CV^2$ , σύμφωνα με την κατηγοριοποίηση των Syntetos et al. (2005). . . . .	140
5.8	Ενδεικτικές χρονοσειρές του συνόλου δεδομένων του διαγωνισμού M5. . . . .	141
5.9	Σύγκριση των αποτελεσμάτων των μεθοδολογιών t-SNE (αριστερά) και PCA (δεξιά) στο ίδιο σύνολο δεδομένων, χρησιμοποιώντας τα ίδια χαρακτηριστικά. 143	

5.10	Απεικόνιση της έντασης των χαρακτηριστικών των χρονοσειρών τριών συνόλων δεδομένων στον χώρο με χρήση t-SNE. Απεικονίζεται το σύνολο δεδομένων τεχνητών χρονοσειρών (αριστερά), το σύνολο δεδομένων του διαγωνισμού M5 (μέση) και το σύνολο δεδομένων μιας ελληνικής αλυσίδας σουπερ μάρκετ (δεξιά).	144
5.11	Απεικόνιση της έντασης των χαρακτηριστικών των χρονοσειρών τριών συνόλων δεδομένων στον χώρο με χρήση PCA. Απεικονίζεται το σύνολο δεδομένων τεχνητών χρονοσειρών (αριστερά), το σύνολο δεδομένων του διαγωνισμού M5 (μέση) και το σύνολο δεδομένων μιας ελληνικής αλυσίδας σουπερ μάρκετ (δεξιά).	145
5.12	Επεξήγηση του παραγόμενου χώρου της μεθοδολογίας PCA, με ταυτόχρονη παρουσίαση τριών παραδειγμάτων χρονοσειρών από συγκεκριμένα σημεία του χώρου.	146
5.13	Διάγραμμα ροής για την προσομοίωση της διαδικασίας αποθεματοποίησης.	147
5.14	Παράδειγμα προσομοίωσης της διαδικασίας αποθεματοποίησης χρησιμοποιώντας τα στοιχεία του Πίνακα 5.4.	148
6.1	Κατηγορίες μηχανικής μάθησης.	152
6.2	Το υπερ-επίπεδο και το μέγιστο περιθώριο ενός SVM που έχει εκπαιδευτεί με παρατηρήσεις δύο κλάσεων.	154
6.3	Απεικόνιση μοντέλου νευρώνα.	155
6.4	Παράδειγμα δέντρου αποφάσεων.	156
6.5	Παράδειγμα οπτικοποίησης δέντρου αποφάσεων χρησιμοποιώντας το ευρέως χρησιμοποιούμενο σύνολο δεδομένων iris.	158
6.6	Παράδειγμα οπτικοποίησης αλγορίθμου τυχαίων δασών κλίσης (Random Forests).	160
6.7	Παράδειγμα οπτικοποίησης αλγορίθμου ενίσχυσης κλίσης (Gradient Boosting). (Πηγή: Zhang et al. (2018))	161
6.8	Απεικόνιση αλγορίθμου ανάπτυξης δέντρου με βάση τα φύλλα (leaf-wise, κάτω), σε αντίθεση με έναν αλγόριθμο ο οποίος αναπτύσσει ένα δέντρο κατά βάθος (level-wise, επάνω).	162
6.9	Παράδειγμα οπτικοποίησης πέντε δέντρων αποφάσεων του μοντέλου LightGBM που κατασκευάστηκε για να ταξινομήσει τις παρατηρήσεις του συνόλου δεδομένων iris.	163
6.10	Σημαντικότητα των ανεξάρτητων μεταβλητών που χρησιμοποιήθηκαν στο δέντρο αποφάσεων του Υποκεφαλαίου 6.2.3 (αριστερά) και στο μοντέλο LightGBM του Υποκεφαλαίου 6.2.3.3 (δεξιά).	165
6.11	Διαφορές της διαδικασίας μάθησης που ακολουθείται στην παραδοσιακή μηχανική μάθησης (αριστερά) και με χρήση μεταφοράς μάθησης (δεξιά).	166
6.12	Απεικόνιση μοντελοποίησης ενός μεταμοντέλου προσομοίωσης.	170
7.1	Διάγραμμα ροής του προτεινόμενου μεθοδολογικού πλαισίου, αποτελούμενο από μία off-line και μία on-line φάση.	183

8.1	Διάγραμμα ροής της πειραματικής διάταξης: εφαρμογή του προτεινόμενου μεθοδολογικού πλαισίου. . . . .	187
8.2	Απόδοση ως προς το συνολικό κόστος αποθεματοποίησης διαφόρων συνόλων υπερπαραμέτρων πολιτικής αποθεματοποίησης στις ιστορικές παρατηρήσεις του συνόλου δεδομένων M5. . . . .	188
8.3	Διάγραμμα ροής της πειραματικής διάταξης: αξιολόγηση της απόδοσης του προτεινόμενου μεθοδολογικού πλαισίου. . . . .	189
8.4	Σημαντικότητα μεταβλητών (feature importance) των τριών LightGBM μοντέλων που αποτελούν το σει μοντέλων $ML_{Sim}$ (επάνω) και το $ML_{M5}$ (κάτω). . . . .	190
8.5	Απόδοση των εξεταζόμενων στρατηγικών διαχείρισης αποθεμάτων (προσεγγίσεις του MOIC και σημεία αναφοράς). Τα “κουτιά” αντιπροσωπεύουν την κατανομή του συνολικού κόστους αποθεματοποίησης (αριστερά) και του επιπέδου εξυπηρέτησης πελατών (δεξιά) των 8.504 σειρών του συνόλου δεδομένων M5. . . . .	193
8.6	Απόδοση των εξεταζόμενων στρατηγικών διαχείρισης αποθεμάτων (προσεγγίσεις του MOIC και σημεία αναφοράς), όπου τα “κουτιά” αντιπροσωπεύουν την κατανομή του συνολικού κόστους αποθεματοποίησης ανά κατηγορία προτύπου ζήτησης. . . . .	194
8.7	Απόδοση των εξεταζόμενων στρατηγικών διαχείρισης αποθεμάτων (προσεγγίσεις του MOIC και σημεία αναφοράς), όπου τα “κουτιά” αντιπροσωπεύουν την κατανομή του συνολικού κόστους αποθεματοποίησης ανά αποθήκη/πολιτεία των ΗΠΑ. . . . .	195
8.8	Απαιτούμενος χρόνος βελτιστοποίησης της διαδικασίας αποθεματοποίησης για 850 προϊόντα χρησιμοποιώντας προσομοιώσεις και χρησιμοποιώντας το προτεινόμενο μεθοδολογικό πλαίσιο. . . . .	196
8.9	Απεικόνιση του $RMSSE$ ως προς το $C_{Tot}$ των εξεταζόμενων μεθόδων πρόβλεψης κατά την προσέγγιση του $FSH$ (επάνω) και του $ML_{Sim}$ (κάτω). . . . .	199
8.10	Απεικόνιση του $RMSSE$ ως προς το $\overline{SL}$ των εξεταζόμενων μεθόδων πρόβλεψης κατά την προσέγγιση του $FSH$ (επάνω) και του $ML_{Sim}$ (κάτω). . . . .	200
8.11	Ταξινόμηση του συνολικού κόστους αποθεματοποίησης όπως προέκυψε από τις εξεταζόμενες μεθόδους πρόβλεψης και στρατηγικές διαχείρισης αποθεμάτων	201
8.12	Επίπτωση της μεταβολής της υπερπαραμέτρου κόστους αποθέματος $h$ στο συνολικό κόστος αποθεματοποίησης. . . . .	204
8.13	Επίπτωση της μεταβολής της υπερπαραμέτρου κόστους αποθέματος $k$ στο συνολικό κόστος αποθεματοποίησης. . . . .	204
8.14	Επίπτωση της μεταβολής της υπερπαραμέτρου κόστους αποθέματος $b$ στο συνολικό κόστος αποθεματοποίησης. . . . .	205
8.15	Επίπτωση της μεταβολής της υπερπαραμέτρου κόστους αποθέματος $p$ στο συνολικό κόστος αποθεματοποίησης. . . . .	206
8.16	Επίπτωση της μεταβολής της υπερπαραμέτρου πολιτικής αποθεματοποίησης $TSL$ στο συνολικό κόστος αποθεματοποίησης για σειρές της κατηγορίας erratic	206
8.17	Επίπτωση της μεταβολής της υπερπαραμέτρου πολιτικής αποθεματοποίησης $TSL$ στο συνολικό κόστος αποθεματοποίησης για σειρές της κατηγορίας lumpy	207

8.18 Επίπτωση της μεταβολής της υπερπαραμέτρου πολιτικής αποθεματοποίησης <i>TSL</i> στο συνολικό κόστος αποθεματοποίησης για σειρές της κατηγορίας <i>smooth208</i>	
8.19 Επίπτωση της μεταβολής της υπερπαραμέτρου πολιτικής αποθεματοποίησης <i>TSL</i> στο συνολικό κόστος αποθεματοποίησης για σειρές της κατηγορίας <i>intermittent</i> . . . . .	208
8.20 Επίπτωση της μεταβολής της υπερπαραμέτρου πολιτικής αποθεματοποίησης <i>TSL</i> στο πραγματοποιηθέν επίπεδο εξυπηρέτησης πελατών ( $\bar{S}_L$ ) για κάθε κατηγορία μοτίβου ζήτησης. . . . .	210
9.1 Δομή μιας εφαρμογής <i>shiny</i> που αποτελείται αποκλειστικά από το αρχείο <i>app.R</i>	214
9.2 Αντιδραστικά ( <i>reactive</i> ) στοιχεία που συναντώνται στο πακέτο <i>shiny</i> της R. . .	215
9.3 Αρχιτεκτονική του υλοποιημένου συστήματος υποστήριξης αποφάσεων. . . .	216
9.4 Απεικόνιση του αρχείου <i>app.R</i> στο περιβάλλον <i>RStudio</i> . . . . .	217
9.5 Παρουσίαση της μπάρας πλοήγησης ( <i>navigation bar</i> ) της εφαρμογής. . . . .	218
9.6 Παρουσίαση της σελίδας “ <i>Stock Control Simulation</i> ” της εφαρμογής. . . . .	219
9.7 Παρουσίαση της σελίδας “ <i>MOIC Demo</i> ” της εφαρμογής. . . . .	219
9.8 Παρουσίαση των εισόδων του μεθοδολογικού πλαισίου όπως εμφανίζονται στην εφαρμογή. . . . .	220
9.9 Επιλογή σεναρίων του μεθοδολογικού πλαισίου μέσω της εφαρμογής. . . . .	220
9.10 Παρουσίαση των συγκριτικών αποτελεσμάτων των επιλεγμένων σεναρίων μέσω της εφαρμογής. . . . .	221
9.11 Παρουσίαση των αποτελεσμάτων βελτιστοποίησης μέσω της εφαρμογής. . . .	221
9.12 Παρουσίαση της σελίδας “ <i>MOIC Implementation</i> ” της εφαρμογής. . . . .	222
9.13 Απεικόνιση των δεδομένων εισαγωγής στη σελίδα “ <i>MOIC Implementation</i> ” της εφαρμογής. . . . .	222
9.14 Απεικόνιση των αποτελεσμάτων της βελτιστοποίησης στη σελίδα “ <i>MOIC Implementation</i> ” της εφαρμογής. . . . .	223
9.15 Εμφάνιση της διαδικτυακής εφαρμογής. . . . .	224



# Ευρετήριο Πινάκων

2.1 Η σημειογραφία των τύπων πολιτικών διαχείρισης αποθεμάτων που συναντώνται συχνότερα στη βιβλιογραφία. . . . .	67
4.1 Μοντέλα εκθετικής εξομάλυνσης βάσει τάσης και εποχιακότητας. . . . .	101
4.2 Κωδικοποίηση μοντέλων εκθετικής εξομάλυνσης. . . . .	102
4.3 Μοντέλα ETS με αθροιστικό σφάλμα $\epsilon_t$ . . . . .	102
4.4 Μοντέλα ETS με πολλαπλασιαστικό σφάλμα $\epsilon_t$ . . . . .	102
4.5 Η διαδικασία δημιουργία της αντίστροφης χρονοσειράς σύμφωνα με το μεθοδολογικό πλαίσιο της iADIDA. . . . .	115
4.6 Παρατηρήσεις χρονοσειράς και προβλέψεις προς στατιστική ανάλυση απόδοσης προβλέψεων. . . . .	121
5.1 Χαρακτηριστικά παραγόμενων χρονοσειρών. . . . .	135
5.2 Πλήθος χρονοσειρών του διαγωνισμού M5 ανά επίπεδο συνάθροισης (aggregation level). . . . .	138
5.3 Παρουσίαση των δύο κύριων συστατικών (principal components) όπως προέκυψαν από τη μέθοδο PCA. . . . .	145
5.4 Παράδειγμα προσομοίωσης της διαδικασίας αποθεματοποίησης κάνοντας χρήση της πολιτικής $(R, s, S)$ χωρίς απόθεμα ασφαλείας και με χαμένες πωλήσεις. . . . .	148
8.1 Απόδοση των εξεταζόμενων στρατηγικών διαχείρισης αποθεμάτων (προσεγγίσεις του MOIC και σημεία αναφοράς) ως προς το συνολικό κόστος αποθεματοποίησης και το επίπεδο εξυπηρέτησης πελατών. Τα αποτελέσματα αναφέρονται στις 8.504 σειρές του συνόλου δεδομένων M5. . . . .	191
8.2 Απόδοση των εξεταζόμενων στρατηγικών διαχείρισης αποθεμάτων (προσεγγίσεις του MOIC και σημεία αναφοράς) ως προς το συνολικό κόστος αποθεματοποίησης και το επίπεδο εξυπηρέτησης πελατών. Τα αποτελέσματα παρουσιάζονται ανά κατηγορία προτύπων ζήτησης. . . . .	192
8.3 Απόδοση των εξεταζόμενων στρατηγικών διαχείρισης αποθεμάτων (προσεγγίσεις του MOIC και σημεία αναφοράς) ως προς το συνολικό κόστος αποθεματοποίησης και το επίπεδο εξυπηρέτησης πελατών. Τα αποτελέσματα παρουσιάζονται ανά περιοχή/αποθήκη. . . . .	192

8.4 Απόδοση των εξεταζόμενων στρατηγικών διαχείρισης αποθεμάτων (προσεγγίσεις του MOIC και σημεία αναφοράς) ως προς το συνολικό κόστος αποθεματοποίησης και το επίπεδο εξυπηρέτησης πελατών. Τα αποτελέσματα αναφέρονται στις 8.504 σειρές του συνόλου δεδομένων M5, έχοντας χρησιμοποιήσει την πολιτική (s, S). . . . .	195
8.5 Απόδοση των εξεταζόμενων στρατηγικών διαχείρισης αποθεμάτων και μεθόδων πρόβλεψης ως προς την ακρίβεια προβλέψεων, το συνολικό κόστος αποθεματοποίησης και το επίπεδο εξυπηρέτησης πελατών. . . . .	198



# Ευρεία Περίληψη

---

## I. Εισαγωγή

Η σωστή διαχείριση των αποθεμάτων αποτελεί αναπόσπαστο κομμάτι μιας εταιρείας λιανικής και κατέχει πρωταρχικό ρόλο στις αποφάσεις στρατηγικού σχεδιασμού. Οι αποφάσεις που λαμβάνονται καθημερινά προκειμένου να επιτευχθεί η διαχείριση αυτή επηρεάζουν καταλυτικά τόσο την κερδοφορία της όσο και την εικόνα της, όπως την αντιλαμβάνονται οι τελικοί καταναλωτές. Κύρια στοιχεία της διαχείρισης αποθεμάτων αποτελούν η βραχυπρόθεσμη, μεσοπρόθεσμη και μακροπρόθεσμη πρόβλεψη της ζήτησης των προϊόντων καθώς και ο υπολογισμός της ποσότητας των παραγγελιών που πρέπει να πραγματοποιηθούν προς τους προμηθευτές αλλά και η σωστή επιλογή της στιγμής στην οποία οι παραγγελίες αυτές πρέπει να τοποθετηθούν. Όπως είναι εμφανές, η συγκεκριμένη διαδικασία είναι αρκετά σύνθετη και η βελτιστοποίησή της, σε πραγματικές συνθήκες, είναι αρκετά απαιτητική και χρονοβόρα.

Η επίλυση του συγκεκριμένου προβλήματος μπορεί να επιτευχθεί με δύο τρόπους, κάθε ένας από τους οποίους έχει πλεονεκτήματα και μειονεκτήματα. Ο πρώτος εστιάζει στην κατασκευή μαθηματικών εξισώσεων οι οποίες περιγράφουν τις διαδικασίες που εκτελούνται κατά την διαχείριση αποθεμάτων και επικεντρώνεται στην ελαχιστοποίηση ή μεγιστοποίηση μιας εξίσωσης κόστους. Το πρόβλημα, έτσι, ανάγεται σε πρόβλημα της θεωρίας βέλτιστου ελέγχου, η οποία αποτελεί κλάδο της μαθηματικής βελτιστοποίησης και ασχολείται με την εύρεση του βέλτιστου σημείου σε ένα δυναμικό σύστημα εξισώσεων. Ο δεύτερος τρόπος, εστιάζει στην κατασκευή προσομοιώσεων οι οποίες εκτελούνται για διάφορες τιμές εισόδων και υπολογίζουν συγκεκριμένες μεταβλητές-εξόδους. Η βελτιστοποίηση σε αυτή την περίπτωση πραγματοποιείται μέσα από τη δοκιμή διαφόρων τιμών εισόδων και τον εντοπισμό των τιμών εκείνων που οδηγούν στα επιθυμητά ή σχεδόν βέλτιστα αποτελέσματα.

Η μαθηματική προσέγγιση, αν και σε απλά συστήματα διαχείρισης αποθεμάτων μπορεί να υπολογίσει τις βέλτιστες τιμές σε μικρό χρονικά διάστημα, υποχρεούται σε αυστηρές παραδοχές, οι οποίες σχετίζονται κυρίως με τη φύση της ζήτησης, και σπάνια ισχύουν στην πραγματικότητα, ενώ ταυτόχρονα, όταν εξετάζονται αρκετά σύνθετα συστήματα δεν είναι εφαρμόσιμη. Από την άλλη πλευρά, η προσέγγιση των προσομοιώσεων μπορεί να δώσει λύση σε σύνθετα συστήματα διαχείρισης αποθεμάτων, πραγματοποιώντας ελάχιστες ή ακόμα και μηδενικές παραδοχές, με το μειονέκτημα, ωστόσο, του υπολογιστικού κόστους και της χρονικής διάρκειας που απαιτεί, τα οποία είναι άρρηκτα συνδεδεμένα με την αρχιτεκτονική της προσομοίωσης και την πολυπλοκότητα του συστήματος που εξετάζεται.

Στην παρούσα διατριβή εξετάζεται η προσέγγιση των προσομοιώσεων. Σε αυτή την κατεύθυνση, προτείνεται μία μεθοδολογία η οποία χρησιμοποιεί μοντέλα μηχανικής μάθησης προκειμένου να αντικαταστήσει τη διενέργεια των χρονοβόρων προσομοιώσεων

προσεγγίζοντας τα αποτελέσματά τους για διάφορες τιμές εισόδου. Η συγκεκριμένη μεθοδολογία αξιολογείται σε μεγάλο πλήθος πραγματικών δεδομένων, ενώ, εξετάζεται η εκπαίδευση των μοντέλων μηχανικής μάθησης τόσο από μέρος του ίδιου συνόλου δεδομένων στο οποίο αξιολογείται όσο και από τεχνητά δεδομένα. Τα τεχνητά δεδομένα δημιουργούνται από μία γεννήτρια χρονοσειρών που θα κατασκευαστεί για αυτόν ακριβώς το σκοπό και η οποία δίνει τη δυνατότητα παραγωγής προκαθορισμένου πλήθους δεδομένων με συγκεκριμένα χαρακτηριστικά κάθε φορά.

Στις ακόλουθες παραγράφους συνοψίζεται το περιεχόμενο καθενός από τα κεφάλαια της παρούσας διδακτορικής διατριβής. Στο δεύτερο κεφάλαιο παρουσιάζονται αναλυτικά τα συστήματα διαχείρισης αποθεμάτων, ενώ στο κεφάλαιο που ακολουθεί περιγράφονται οι τεχνικές που συναντώνται στη βιβλιογραφία για την ανάλυση και κατηγοριοποίηση των χρονοσειρών. Στο τέταρτο κεφάλαιο παρουσιάζονται οι βασικότερες μέθοδοι παραγωγής στατιστικών προβλέψεων με χρήση στατιστικών μοντέλων χρονοσειρών, εμβαθύνοντας στις χρονοσειρές διακοπόμενης ζήτησης, και στο πέμπτο κεφάλαιο αναπτύσσεται η γεννήτρια τεχνητών δεδομένων. Το επόμενο κεφάλαιο εστιάζει στη χρήση αλγορίθμων μηχανικής μάθησης και στο έβδομο κεφάλαιο παρουσιάζεται το μεθοδολογικό πλαίσιο, το οποίο συνδέει μέρη των προηγούμενων κεφαλαίων. Στο όγδοο κεφάλαιο αναλύεται η επίδοση της μεθοδολογίας και στο ένατο κεφάλαιο παρουσιάζεται το πληροφοριακό σύστημα υποστήριξης αποφάσεων που κατασκευάστηκε στο πλαίσιο της παρούσας διατριβής και εμπεριέχει το προτεινόμενο πλαίσιο. Τέλος, στο τελευταίο κεφάλαιο συνοψίζονται τα συμπεράσματα της εργασίας και τίθενται συγκεκριμένοι στόχοι ως μελλοντικές προεκτάσεις της μεθοδολογίας προκειμένου αυτή να βελτιωθεί αλλά και να υιοθετηθεί από επιχειρήσεις.

## **II. Συστήματα διαχείρισης αποθεμάτων**

Τα αποθέματα λειτουργούν ως προστασία απέναντι στην αβεβαιότητα που εμφανίζεται σε διάφορα μέρη της εφοδιαστικής αλυσίδας, με τη διαχείρισή τους, ωστόσο, να δημιουργεί διάφορα κόστη για κάθε εταιρεία. Τα κύρια από τα κόστη αυτά προέρχονται από τις επιβαρύνσεις που δημιουργούν η διατήρηση των εν λόγω αποθεμάτων, η πραγματοποίηση των παραγγελιών προς τους προμηθευτές αλλά και η απώλεια πωλήσεων από την έλλειψη διαθέσιμων αποθεμάτων.

Η διαχείριση, αυτή, των αποθεμάτων μπορεί να πραγματοποιηθεί από συστήματα διαχείρισής τους, δηλαδή από ένα σύνολο κανόνων οι οποίοι καθορίζουν τον τρόπο με τον οποίο υπολογίζεται η ποσότητα μιας παραγγελίας αλλά και η χρονική στιγμή που η παραγγελία θα πραγματοποιηθεί. Τα συστήματα διαχείρισης αποθεμάτων μπορούν να διακριθούν ανάλογα με το πλήθος των διαφορετικών προϊόντων που διαχειρίζονται, το χρόνο εξέτασης των αποθεμάτων, τη φύση της ζήτησης, την δομή της εφοδιαστικής αλυσίδας της επιχείρησης και τα κόστη που λαμβάνουν υπόψη.

Πρώτη αναφορά πολιτικής αποθεματοποίησης αποτελεί αυτή της Οικονομικής Ποσότητας Παραγγελίας, η οποία μπορεί να χρησιμοποιηθεί για τον υπολογισμό της βέλτιστης ποσότητας και συχνότητας παραγγελίας, σε συνθήκες όπου η ζήτηση είναι σταθερή και ντετερμινιστική. Ωστόσο, στην πραγματικότητα η ζήτηση εμφανίζεται τυχαία, είναι στοχαστική, και τις περισσότερες φορές η κατανομή της μεταβάλλεται με την πάροδο

---

του χρόνου. Ίσως η πιο διαδεδομένη πολιτική αποθεματοποίησης που χρησιμοποιείται σε τέτοιες συνθήκες, και συναντάται τόσο στη βιβλιογραφία όσο και στην πράξη, είναι η πολιτική  $(R, s, S)$ . Σύμφωνα με τη συγκεκριμένη πολιτική, κάθε  $R$  περιόδους, και εφόσον το διαθέσιμο απόθεμα βρίσκεται κάτω από ένα επίπεδο αναπαραγγελίας  $s$ , πραγματοποιείται μία παραγγελία  $Q$  η οποία επαναφέρει το απόθεμα στο επίπεδο στόχο  $S$ . Υποπεριπτώσεις της πολιτικής  $(R, s, S)$  αποτελούν οι  $(R, S)$  και  $(s, S)$ , όπου στην πρώτη δεν υφίσταται επίπεδο αναπαραγγελίας ενώ στη δεύτερη ο έλεγχος του αποθέματος και η ενδεχόμενη τοποθέτησή μιας παραγγελίας μπορεί να πραγματοποιείται σε κάθε περίοδο.

Ένα σημαντικό στοιχείο κάθε συστήματος διαχείρισης αποθεμάτων αποτελεί το κριτήριο απόδοσης. Ο δείκτης, δηλαδή, που η επιχείρηση επιθυμεί να ελαχιστοποιήσει ή να μεγιστοποιήσει κάθε φορά. Ένα σύστημα, συνήθως, στοχεύει στην ελαχιστοποίηση του συνολικού κόστους, στη μεγιστοποίηση του ποσοστού εξυπηρέτησης των πελατών ή τη σύγκλιση αυτού σε ένα προκαθορισμένο επίπεδο, ή ακόμα και σε κάποιο συνδυασμό των παραπάνω.

Όπως αναφέρθηκε, οι τιμές των παραμέτρων της πολιτικής που χρησιμοποιείται πρέπει να επιλέγονται προσεκτικά, καθώς επηρεάζουν άμεσα την απόδοση της εταιρείας, με αποτέλεσμα να απαιτείται η βελτιστοποίηση των εν λόγω παραμέτρων σε τακτά χρονικά διαστήματα. Η βελτιστοποίηση αυτή τις περισσότερες φορές δεν είναι μια εύκολη διαδικασία, πόσο μάλλον όταν μία επιχείρηση έχει να διαχειριστεί εκατοντάδες ή χιλιάδες διαφορετικά προϊόντα, κάθε ένα από τα οποία πρέπει να εξεταστεί ξεχωριστά.

### **III. Ανάλυση και κατηγοριοποίηση χρονοσειρών**

Το σύνολο των διαδοχικών παρατηρήσεων ενός μεγέθους ονομάζεται χρονοσειρά. Μία χρονοσειρά μπορεί να απεικονίζει τις πωλήσεις ενός προϊόντος, το απόθεμα μιας εταιρείας ή την τιμή μιας μετοχής μεταξύ πολλών άλλων. Οι τιμές μιας χρονοσειράς, έτσι, ενδέχεται να αυξάνονται με την πάροδο του χρόνου, να εμφανίζουν μία επαναλαμβανόμενη φύση ανά μικρά ή μεγάλα διαστήματα ή ακόμα και οι διακυμάνσεις τους να είναι τυχαίες. Οι παρατηρήσεις αυτές, που μπορούν να εντοπιστούν από την οπτική μελέτη της χρονοσειράς, αποκαλούνται ποιοτικά χαρακτηριστικά των χρονοσειρών και παρέχουν σημαντικές πληροφορίες τόσο κατά την ανάλυσή τους όσο και κατά τη διαδικασία παραγωγής προβλέψεων. Συνεπώς, η απομόνωση των ποιοτικών χαρακτηριστικών μιας σειράς είναι βαρύνουσας σημασίας, διαδικασία η οποία αποκαλείται αποσύνθεση.

Μία ιδιαίτερη περίπτωση χρονοσειρών αποτελούν οι σειρές διακοπτόμενης ζήτησης, οι οποίες εμφανίζουν αρκετές μηδενικές παρατηρήσεις. Οι εν λόγω χρονοσειρές συνήθως αναπαριστούν τις πωλήσεις βραδυκίνητων προϊόντων, δηλαδή προϊόντων τα οποία δεν εμφανίζουν κάποια πώληση σε κάθε χρονική περίοδο. Όπως είναι αναμενόμενο η πρόβλεψη αυτής της κατηγορίας σειρών είναι αρκετά δύσκολη καθώς πέρα από τον υπολογισμό της ποσότητας της ζήτησης που αναμένεται να εμφανιστεί είναι σημαντικός και ο προσδιορισμός της στιγμής που θα κάνει την εμφάνισή της.

Συχνά οι επιχειρήσεις κατηγοριοποιούν τις σειρές διακοπτόμενης ζήτησης προκειμένου να είναι σε θέση να τις αντιμετωπίσουν πιο αποδοτικά, γεγονός που έχει εξεταστεί εκτενώς στη βιβλιογραφία, με αποτέλεσμα να συναντώνται διάφοροι τρόποι κατηγοριοποίησης. Κύριο

χαρακτηριστικό όλων των μεθοδολογιών κατηγοριοποίησης είναι ο διαχωρισμός των σειρών στις επιμέρους κατηγορίες βάσει της σποραδικότητας της ζήτησης, δηλαδή των διαστημάτων μεταξύ δύο μη μηδενικών παρατηρήσεων, και της διακύμανσής της, δηλαδή τη διακύμανση των μη μηδενικών παρατηρήσεων.

#### **IV. Μέθοδοι στατιστικής πρόβλεψης χρονοσειρών**

Στόχος των προβλέψεων αποτελεί η παραγωγή αριθμητικών εκτιμήσεων που αφορούν στη μελλοντική εξέλιξη των τιμών της εξεταζόμενης μεταβλητής. Στην παρούσα διατριβή εξετάζονται τα στατιστικά μοντέλα πρόβλεψης χρονοσειρών, τα οποία στηρίζονται, κυρίως, στην ανάλυση των χρονοσειρών και την επέκτασή τους χρησιμοποιώντας μαθηματικές εξισώσεις οι οποίες συνδέουν τις μελλοντικές τιμές με τις παρελθοντικές. Στη βιβλιογραφία συναντώνται πληθώρα στατιστικών μοντέλων πρόβλεψης τα οποία παρουσιάζουν αξιόλογα αποτελέσματα, μεγάλης ακρίβειας, σε πλήθος εφαρμογών.

Όσον αφορά στις χρονοσειρές διακοπτόμενης ζήτησης, η πιο διαδεδομένη μέθοδος είναι η μέθοδος Croston, η οποία, παρά το γεγονός ότι εμφανίστηκε το 1972, χρησιμοποιείται ακόμα και σήμερα, λόγω της απλότητάς της, και κατά συνέπεια της παραγωγής προβλέψεων σε μικρό χρονικό διάστημα, και της σχετικά καλής απόδοσής της. Από τότε, έχουν κάνει την εμφάνισή τους διάφορες παραλλαγές της συγκεκριμένης μεθόδου, κάποιες με μεγαλύτερη και κάποιες με μικρότερη επιτυχία, καθώς και μέθοδοι οι οποίοι αντιμετωπίζουν το πρόβλημα της παραγωγής προβλέψεων σε διακοπτόμενες σειρές με διαφορετικό τρόπο από την Croston, όπως η χρονική συνάθροιση ή η αναδειγματοληψία.

Σε κάθε περίπτωση, ο εντοπισμός της κατάλληλης μεθόδου πρόβλεψης για την χρονοσειρά ή το σύνολο δεδομένων που εξετάζεται κάθε φορά αποτελεί μια δύσκολη διαδικασία, η οποία βασίζεται στα αποτελέσματα του υπολογισμού στατιστικών δεικτών που συγκρίνουν τις παραγόμενες προβλέψεις με τις πραγματικές παρατηρήσεις.

#### **V. Γεννήτρια παραγωγής τεχνητών δεδομένων**

Προκειμένου να παραχθούν χρονοσειρές με τεχνητό τρόπο απαιτείται ο καθορισμός της διαδικασίας μέσω της οποίας αυτές θα δημιουργούνται. Απαιτείται έτσι ένας μηχανισμός ο οποίος θα καθορίζει τα χαρακτηριστικά που αποτελούν μία σειρά και τις επιθυμητές τιμές των χαρακτηριστικών αυτών για να τα συνθέσει. Στην παρούσα διατριβή, σε ακολουθία με τη βιβλιογραφία, πραγματοποιείται η υπόθεση ότι κάθε χρονοσειρά μπορεί να αναλυθεί σύμφωνα με τη μέθοδο της πολλαπλασιαστικής αποσύνθεσης διακοπτόμενης ζήτησης σε δύο συνιστώσες, την σποραδικότητα της ζήτησης και τη διακύμανσή της, όπως αναφέρθηκε και παραπάνω.

Επίσης, πραγματοποιείται μία σύγκριση των παραγόμενων σειρών με τα δεδομένα του διαγωνισμού προβλέψεων M5, τα οποία, αφορούν σε δεδομένα πωλήσεων της εταιρείας Walmart, και χρησιμοποιούνται στην πειραματική διαδικασία της παρούσας διατριβής.

Η γεννήτρια υλοποιήθηκε με χρήση της γλώσσας R, μιας γλώσσας προγραμματισμού ελεύθερου λογισμικού η οποία χρησιμοποιείται ευρέως λόγω των ισχυρών βιβλιοθηκών που διαθέτει. Έτσι, βάσει της γεννήτριας που κατασκευάστηκε, ο χρήστης μπορεί να δημιουργήσει ένα σύνολο δεδομένων με ίδιο πλήθος σειρών όλων των κατηγοριών, όμοια

---

κατανεμημένων εντός των ορίων που έχουν δοθεί, ορίζοντας μόνο το επιθυμητό συνολικό πλήθος χρονοσειρών.

## **VI. Μηχανική Μάθηση**

Ο κλάδος της μηχανικής μάθησης παρουσιάζει τεράστια ανάπτυξη τα τελευταία χρόνια, με τους αλγόριθμους του συγκεκριμένου κλάδου, είτε πρόκειται για νευρωνικά δίκτυα, μηχανές διανυσμάτων υποστήριξης ή δέντρα αποφάσεων, να βρίσκουν εφαρμογή σε διάφορα προβλήματα. Παρά το γεγονός ότι οι αλγόριθμοι αυτοί συναντώνται όλο και πιο συχνά, με ενθαρρυντικά αποτελέσματα τις περισσότερες φορές, στον κλάδο της διαχείρισης αποθεμάτων, και συγκεκριμένα στη βελτιστοποίηση των πολιτικών αποθεματοποίησης, η εμφάνισή τους παραμένει σποραδική.

Οι αλγόριθμοι μηχανικής μάθησης μπορούν να διακριθούν στις κατηγορίες της επιτηρούμενης, μη επιτηρούμενης, ημι-επιτηρούμενης και ενισχυτικής μάθησης. Η παρούσα διατριβή χρησιμοποιεί αλγόριθμους επιτηρούμενης μάθησης, και πιο συγκεκριμένα δέντρα αποφάσεων ενίσχυσης κλίσης, που αποτελεί μία εκ των τεχνικών για το συνδυασμό των απλών δέντρων.

Ένα από τα πιο διαδεδομένα πλαίσια της συγκεκριμένης κατηγορίας είναι το Light Gradient Boosting Machine (LightGBM), το οποίο έχει χρησιμοποιηθεί σε προβλήματα classification και regression εστιάζοντας τόσο στην απόδοση όσο και την επεκτασιμότητα. Χαρακτηριστικό παράδειγμα της επιτυχίας του LightGBM αποτελεί το γεγονός ότι μία προσέγγιση που χρησιμοποιούσε το πλαίσιο αυτό ήταν η νικητήρια στον πρόσφατο διαγωνισμό M5 competition, ο οποίος εστιάζει στο δύσκολο πρόβλημα της πρόβλεψης δεδομένων λιανικών πωλήσεων χιλιάδων προϊόντων σε διάφορα καταστήματα και περιοχές των ΗΠΑ.

Ένα από τα μειονεκτήματα των αλγορίθμων ή μοντέλων μηχανικής μάθησης αποτελεί η ανάγκη ύπαρξης ενός μεγάλου συνόλου δεδομένων, με το οποίο το μοντέλο θα εκπαιδευτεί. Ένας από τους τρόπους αντιμετώπισης του προβλήματος αυτού είναι με χρήση μεταφοράς μάθησης (transfer learning), κατά την οποία το μοντέλο εκπαιδεύεται με δεδομένα ενός συγκεκριμένου περιβάλλοντος προέλευσης με σκοπό να εφαρμοστεί σε ένα άλλο περιβάλλον στόχο. Η τεχνική αυτή χρησιμοποιείται στην παρούσα διατριβή, όπου τα μοντέλα του προτεινόμενου μεθοδολογικού πλαισίου εκπαιδεύονται με τα δεδομένα που παρήχθησαν από τη γεννήτρια παραγωγής δεδομένων, και αποτελεί την πιο αποδοτική προσέγγιση από όσες εξετάζονται.

## **VII. Προτεινόμενο μεθοδολογικό πλαίσιο**

Στο πλαίσιο της παρούσας διδακτορικής διατριβής προτείνεται ένα καινοτόμο μεθοδολογικό πλαίσιο βελτιστοποίησης των παραμέτρων της επιλεγμένης πολιτικής αποθεματοποίησης, το οποίο συνδυάζει τη διεξαγωγή προσομοιώσεων με την εφαρμογή αλγορίθμων μηχανικής μάθησης. Σύμφωνα με το συγκεκριμένο πλαίσιο, οι σχεδόν βέλτιστες παράμετροι που προκύπτουν δεν είναι πανομοιότυπες για όλα τα προϊόντα, αλλά διαφέρουν μεταξύ των διαθέσιμων προϊόντων επιλέγοντας κάθε φορά το σύνολο παραμέτρων το οποίο αναμένεται να μειώσει το συνολικό κόστος. Ουσιαστικά, τα σύνολα των

παραμέτρων καθορίζονται με βάση προσομοιώσεις που πραγματοποιήθηκαν στα ιστορικά δεδομένα ή σε κάποια άλλα δεδομένα προέλευσης και μια προσέγγιση μηχανικής μάθησης που έχει ως στόχο να προσδιορίσει τη “βέλτιστη” λύση.

Πιο συγκεκριμένα, χρησιμοποιώντας δεδομένα προηγούμενων πωλήσεων και υποθέτοντας διάφορα σύνολα παραμέτρων πολιτικής αποθεματοποίησης, πραγματοποιούνται προσομοιώσεις ελέγχου των αποθεμάτων και υπολογίζονται ξεχωριστά το κόστος διαχείρισης αποθεμάτων, το κόστος τοποθέτησης παραγγελιών και οι χαμένες πωλήσεις για κάθε περίπτωση. Στη συνέχεια, εξειδικευμένα μοντέλα παλινδρόμησης αναλαμβάνουν την πρόβλεψη βασικών στοιχείων αποθέματος, όπως για παράδειγμα το μέσο επίπεδο αποθέματος και τον αριθμό παραγγελιών που έχουν υποβληθεί, τα οποία επηρεάζουν το κόστος, χρησιμοποιώντας ως εισόδους πληροφορίες σχετικές με τη ζήτηση και τις επιλεγμένες παραμέτρους αποθέματος. Δεδομένων των εν λόγω πληροφοριών σχετικά με ένα τυχαίο, νέο, προϊόν για το οποίο επιθυμείται η βελτιστοποίηση των παραμέτρων της πολιτικής, τα εκπαιδευμένα μοντέλα μπορούν να χρησιμοποιηθούν αποτελεσματικά για την προσέγγιση του συνολικού κόστους αποθεματοποίησης της επιλεγμένης ρύθμισης και, κατά συνέπεια, για τον εντοπισμό μιας σχεδόν βέλτιστης ρύθμισης.

Το σημαντικότερο χαρακτηριστικό του προτεινόμενου μεθοδολογικού πλαισίου είναι η προσαρμοστικότητά του και η εν γένει ανεκτικότητα στην τροποποίηση, μιας και είναι ανεξάρτητο από κάποιο συγκεκριμένο μοντέλο, τόσο όσον αφορά στη μέθοδο πρόβλεψης της ζήτησης που περιλαμβάνει, όσο και στην πολιτική αποθεματοποίησης που λαμβάνει υπόψη αλλά και στον αλγόριθμο μηχανικής μάθησης που αξιοποιεί για να κάνει τους απαραίτητους συσχετισμούς. Αυτό συμβαίνει καθώς η προτεινόμενη προσέγγιση βασίζεται αποκλειστικά στα διαθέσιμα δεδομένα ζήτησης, τον τρόπο με τον οποίο ορίζονται οι προσομοιώσεις και το μοντέλο που συνδέει κατάλληλα τις εισόδους και τις εξόδους αυτών. Με άλλα λόγια, λειτουργεί ως μία παράκαμψη στην πραγματοποίηση προσομοιώσεων, συνδέοντας τους παράγοντες που συνεισφέρουν καταλυτικά στη διαδικασία παραγγελιοδότησης με τα αποτελέσματα αυτής για συγκεκριμένο χρονικό διάστημα.

### **VIII. Παρουσίαση και ανάλυση αποτελεσμάτων**

Η μελέτη των αποτελεσμάτων στα δεδομένα του διαγωνισμού M5 οδήγησε σε ξεκάθαρα αποτελέσματα όσον αφορά στην επίδοση του προτεινόμενου μεθοδολογικού πλαισίου ως προς τους σημαντικότερους παράγοντες της διαδικασίας αποθεματοποίησης, το συνολικό κόστος και το επίπεδο εξυπηρέτησης πελατών. Καταρχάς, εκ των αποτελεσμάτων αποδεικνύεται ότι η μεθοδολογία δύναται να χρησιμοποιηθεί για τη βελτιστοποίηση μιας πολιτικής αποθεματοποίησης, παρουσιάζοντας εξαιρετικά σταθερά αποτελέσματα ανεξάρτητα από τα μοτίβα ζήτησης που εμφανίζονται στις χρονοσειρές ζήτησης στόχο και πιθανές διαφορές μεταξύ των αποθηκών που ελέγχθηκαν.

Ένα σημαντικό στοιχείο είναι ότι η εκπαίδευση των μοντέλων μηχανικής μάθησης της προτεινόμενης μεθοδολογίας με “πραγματική” ζήτηση προσδίδει αξία έναντι στην εκπαίδευσή τους με δεδομένα πωλήσεων, ενώ ταυτόχρονα, η εκπαίδευσή τους με ένα πλήρες σύνολο δεδομένων είναι αρκετά ευεργετική.

---

Όσον αφορά στο υπολογιστικό κόστος, αφού έχουν εκπαιδευτεί τα μοντέλα της μεθοδολογίας, η βελτιστοποίηση μιας πολιτικής αποθεματοποίησης μπορεί να πραγματοποιηθεί σε σημαντικά μικρό χρονικό διάστημα, εκτιμώντας το συνολικό κόστος για δεδομένες ρυθμίσεις έως και 70 φορές πιο γρήγορα από τον χρόνο που απαιτεί μια προσομοίωση.

Ως ένα επιπλέον βήμα εξετάστηκε η επίπτωση της βελτίωσης της ακρίβειας των προβλέψεων ζήτησης στο συνολικό κόστος και πραγματοποιήθηκε μία σύγκριση μεταξύ της βελτίωσης της εν λόγω ακρίβειας και της βελτιστοποίησης των παραμέτρων της πολιτικής αποθεματοποίησης που χρησιμοποιήθηκε. Εκ των αποτελεσμάτων προκύπτει ότι, αν και γενικά οι πιο ακριβείς προβλέψεις μπορούν να οδηγήσουν σε μικρότερο κόστος αποθεματοποίησης, αυτό δεν ισχύει πάντα και, επίσης, η σχέση μεταξύ βελτίωσης της ακρίβειας προβλέψεων και μείωσης του κόστους δεν είναι ξεκάθαρη. Εξίσου σημαντικό είναι το αποτέλεσμα ότι η βελτιστοποίηση της πολιτικής μπορεί να επιφέρει σημαντικά μεγαλύτερο όφελος από την βελτίωση αποκλειστικά της ακρίβειας των προβλέψεων.

## **ΙΧ. Πληροφοριακό σύστημα**

Προκειμένου να καταστεί ο τρόπος λειτουργίας του πλαισίου εύκολα κατανοητός και το σύνολο των δυνατοτήτων του εύκολα προσβάσιμο, κατασκευάστηκε μία διαδικτυακή εφαρμογή, η οποία περιλαμβάνει τη γεννήτρια παραγωγής τεχνητών δεδομένων, τη δυνατότητα πραγματοποίησης προσομοίωσης για μία παραγόμενη σειρά ζήτησης, την επεξήγηση του τρόπου με τον οποίο λειτουργεί η προτεινόμενη μεθοδολογία σε μία χρονοσειρά καθώς και η δυνατότητα βελτιστοποίησης πλήθους αυτών, χρησιμοποιώντας τα προεκπαιδευμένα μοντέλα μηχανικής μάθησης τα οποία επέδειξαν την καλύτερη επίδοση κατά την πειραματική διαδικασία της παρούσας διατριβής. Η εν λόγω εφαρμογή κατασκευάστηκε εξ ολοκλήρου στη γλώσσα προγραμματισμού R, χρησιμοποιώντας τη βιβλιοθήκη shiny, δημιουργώντας ένα περιβάλλον αρκετά εύκολο τόσο στην κατανόηση όσο και στον τρόπο λειτουργίας.

Ένα από τα σημαντικότερα, ίσως, χαρακτηριστικά της εφαρμογής αποτελεί η δυνατότητα επέκτασης και εξέλιξής της, μιας και τα προεκπαιδευμένα μοντέλα μπορούν εύκολα να αντικατασταθούν στο μέλλον από νέα, πιο εξελιγμένα και μεγαλύτερης ακρίβειας καθώς και να προστεθούν ή να αφαιρεθούν μεταβλητές στο γραφικό περιβάλλον καλύπτοντας τις ανάγκες των νέων αυτών μοντέλων.

Με τον τρόπο αυτό, δημιουργήθηκε ένα σύστημα υποστήριξης αποφάσεων το οποίο χρησιμοποιεί μοντέλα μηχανικής μάθησης και μπορεί να συνεισφέρει στη λήψη στρατηγικών αποφάσεων για τη βελτιστοποίηση της πολιτικής αποθεματοποίησης που χρησιμοποιείται με στόχο την ελαχιστοποίηση του κόστους.

## **X. Συμπεράσματα και προεκτάσεις**

Εκ των αποτελεσμάτων της πειραματικής διαδικασίας προκύπτουν πολλά και ενδιαφέροντα συμπεράσματα, τα πιο σημαντικά από τα οποία παρουσιάζονται συνοπτικά παρακάτω, ενώ παρουσιάζονται επιγραμματικά και οι βασικότερες προεκτάσεις.

Το πιο ενδιαφέρον συμπέρασμα αποτελεί η επιβεβαίωση πως η χρήση αλγορίθμων μηχανικής μάθησης για την προσέγγιση των αποτελεσμάτων της διαδικασίας αποθεματοποίησης, και κατά συνέπεια η χρήση της προσέγγισης αυτής για τη βελτιστοποίηση μιας πολιτικής αποθεματοποίησης, έχει θετικά αποτελέσματα, ενώ παράλληλα τα αποτελέσματα αυτά είναι εμφανή ανεξαρτήτως μοτίβου ζήτησης ή συνόλου προϊόντων που εξετάζονται κάθε φορά.

Όσον αφορά στην εκπαίδευση των αλγορίθμων, συμπεραίνεται ότι η χρησιμοποίηση ενός πλήρους συνόλου δεδομένων ζήτησης το οποίο εμπεριέχει μεγάλο πλήθος χρονοσειρών ζήτησης όλων των πιθανών μοτίβων, και αναπαριστά την πραγματική ζήτηση και όχι τις πωλήσεις, έχει επίσης σημαντική θετική επίπτωση. Με τον τρόπο αυτό, γίνεται ξεκάθαρη η θετική επίδραση της μεταφοράς γνώσης από ένα αμερόληπτο σύνολο δεδομένων σε ένα άλλο σύνολο δεδομένων στόχο.

Τα παραπάνω, σε συνδυασμό με την ταχύτητα εκτέλεσης που εγγυάται το στάδιο εφαρμογής των μοντέλων μηχανικής μάθησης, αφού δηλαδή αυτά έχουν εκπαιδευτεί, δημιουργούν τις κατάλληλες συνθήκες για την υιοθέτηση τέτοιου είδους προσεγγίσεων σε συστήματα βελτιστοποίησης τα οποία μπορούν να προσφέρουν ακριβείς προτάσεις παρέχοντάς τους ελάχιστα στοιχεία ως εισόδους.

Ένα άλλο συμπέρασμα είναι ότι, παρά το γεγονός ότι στην γενική περίπτωση η ακρίβεια των προβλέψεων ζήτησης μπορεί να μειώσει το συνολικό κόστος αποθεματοποίησης, αυτό δεν συμβαίνει πάντα, ενώ ταυτόχρονα τα οφέλη που μπορούν να προκύψουν από τη βελτιστοποίηση της πολιτικής αποθεματοποίησης υπερτερούν αυτών που μπορούν να προκύψουν από τη βελτίωση της ακρίβειας των προβλέψεων.

Αν και αποδεικνύεται πως η προτεινόμενη μεθοδολογία μπορεί να εντοπίσει τις βέλτιστες ή σχεδόν βέλτιστες τιμές των παραμέτρων μιας πολιτικής αποθεματοποίησης, ενώ ταυτόχρονα είναι σημαντικά γρηγορότερη από τις κλασσικές προσομοιώσεις, υπάρχουν αρκετές προεκτάσεις προκειμένου να αποδώσει ακόμα μεγαλύτερο όφελος στους τελικούς χρήστες.

Θα μπορούσαν πιθανώς να εξεταστούν διαφορετικοί αλγόριθμοι μηχανικής μάθησης ή πιο σύνθετες τεχνικές μεταφοράς μάθησης, να επεκταθεί το μεθοδολογικό πλαίσιο προκειμένου να είναι σε θέση να συμπεριλαμβάνει ταυτόχρονα πολλαπλές πολιτικές αποθεματοποίησης αλλά και να διευρυνθεί η πειραματική διαδικασία εξετάζοντας επιπρόσθετα σύνολα δεδομένων.



# Extended Summary

---

## I. Introduction

Inventory management is an integral part of a retail company and has a primary role in strategic planning decisions. These decisions are taken daily and can affect both its profitability and its image as perceived by the customers. The main elements of inventory management are demand forecasting, and most importantly the calculation of the quantity and timing of each order that must be placed. It is evident that this process is quite complex and its optimization, in real conditions, is demanding and time-consuming.

Solving this particular problem can be achieved by two approaches, each of which has both advantages and disadvantages. The first approach focuses on constructing mathematical equations that describe the processes performed during inventory management and solves the problem by optimizing a cost function. The problem, thus, is reduced to a problem of optimal control theory, which is a branch of mathematical optimization and deals with finding the optimal point in a dynamic system of equations. The second approach focuses on conducting simulations that are repeated for various input values and calculate the results. Optimization in this case is done through testing various input values and identifying the ones that lead to the desired or optimal outcome.

The mathematical approach, besides the fact that in simple stock control systems it can calculate the optimal parameters in a short period of time, it is obliged to make strict assumptions regarding the nature of demand which are rarely true in reality, while at the same time, when considering more complex systems it may not be applicable. On the other hand, the simulations approach can provide a solution to complex inventory management systems, making minimal or zero assumptions, with the disadvantage, however, of the computational cost and time it requires, which are of course linked to the architecture of the simulation and the complexity of the system under consideration.

In the present thesis only the simulations approach is examined. In this direction, a methodology is proposed that uses machine learning models in order to replace the time-consuming simulations by approximating their results for various input values. The specific methodology is evaluated on a sufficient amount of real data, while the training process is conducted using either part of the evaluation data set or generated data. The generated ones result from a time series generator that was built for this very purpose and which enables the production of a predetermined set of data with specific characteristics.

The following paragraphs summarize each chapter of this thesis. In the second chapter, inventory management systems are presented in detail, while in the third chapter, the techniques for the analysis and categorization of time series are described.

The fourth chapter presents the most used time series methods of statistical forecasting, focusing in intermittent demand time series, and the fifth chapter presents the data generator and the generated series. The next chapter focuses on machine learning algorithms and the seventh chapter presents the methodological framework. In the eighth chapter the performance of the methodology is analyzed and in the following chapter the decision support system built in the context of the present thesis, which contains the proposed framework, is presented. Finally, in the last chapter the conclusions are summarized and specific objectives are set as future extensions of the methodology in order to further improve it.

## **II. Inventory management systems**

Inventories act as a protection against the uncertainty that occurs in different parts of supply chain, with their management, however, creating various costs for each company. The main of these costs come from the burdens created by maintaining stock, placing orders to suppliers and also losing sales due to the lack of available stock.

Inventory management can be carried out by a management system, i.e. by a set of rules that determine the way in which the quantity of an order is calculated and also the time when the order will be placed. Inventory management systems can be distinguished according to the number of different products they manage, the inventory review time, the nature of demand, the supply chain structure and the costs they take into account.

The first reference to stock control policy is the Economic Order Quantity (EOQ), which can be used to calculate the optimal order quantity and frequency, in conditions where demand is constant and deterministic. However, in reality demand appears randomly, is stochastic, and more often than not its distribution changes over time. Perhaps the most common inventory policy used in such circumstances, and encountered both in the literature and in practice, is the  $(R, s, S)$  policy. According to this policy, every  $R$  periods, and if the available inventory is below a reorder level  $s$ , an order  $Q$  is placed which restores the inventory to the target level  $S$ . Subcases of the  $(R, s, S)$  policy are the  $(R, S)$  and the  $(s, S)$ , where in the first there is no reorder level, while in the second inventory control and the eventual placement of an order can be held at any period.

An important element of any inventory management system is the performance measurement. The index that the company wishes to minimize or maximize each time. A system usually aims to minimize total cost, maximize customer service level or converge to a predetermined one, or even some combination of the above.

As mentioned, the values of the policy parameters used must be chosen carefully, as they directly affect the performance of the company, thus requiring the optimization of said parameters regularly. The optimization is often not an easy process, especially when a company has to manage hundreds or thousands of different products, each of which must be considered separately.

---

### **III. Time series analysis and categorization**

The set of consecutive observations of a quantity is called a time series. A time series can depict the sales of a product, the stock of a company, or the price of a product among many others. The values of a time series may increase over time, exhibit a recurring nature over short or long intervals, or even have random fluctuations. These observations, which can be identified visually, are called qualitative characteristics of the time series and provide important information both during their analysis and the forecasting process. Therefore, the isolation of the qualitative features of a series, a process called decomposition, is of paramount importance.

A special case of time series is intermittent demand, which show several zero observations. These series usually represent sales of slow-moving products, i.e. products that do not have sales in every period. As expected, forecasting this category of series is quite difficult as besides calculating the amount of demand that is expected to appear, it is also important to identify the moment when it will appear.

Companies often categorize intermittent demand series in order to be able to deal with them more efficiently, an approach that has been extensively examined in the literature with various categorizations being proposed. A key feature of all categorization methodologies is the separation of series into subcategories based on the demand's sporadicity, i.e. the intervals between two non-zero observations, and its variance, i.e. the variance of the non-zero observations.

### **IV. Statistical forecasting methods**

The objective of forecasting is the production of numerical estimations of the future values of the examined variable. In the present thesis, statistical models of time series forecasting are examined, which are mainly based on the analysis of time series and their extension using mathematical equations that connect future values with past ones. In the literature, there are many statistical forecasting models that show remarkable results, of great accuracy, in various applications.

As for intermittent time series, the most well known method is the one originally proposed by Croston, which, despite the fact that it appeared in 1972, is still used, due to its simplicity, and consequently the fast production of forecasts, and due to its relatively good performance. Since then, many variations of this method have emerged, some with better and some with less success, as well as methods that approach the problem of generating forecasts in intermittent series in a different way than Croston, utilizing techniques like time aggregation or resampling.

In any case, identifying the appropriate forecasting method for the time series or data set under consideration at any given time is a difficult process, which mostly relies on the results of calculating statistical indices that compare the generated forecasts with the actual observations.

## **V. Data generator**

In order to produce time series artificially it is necessary to define the process through which they will be created. Thus, a mechanism is required which will determine the features that make up a series, their values of these features and the way they have to be combined in order to compose a new series. In the present thesis, in line with the literature, the assumption is made that each time series can be analyzed using the method of the multiplicative decomposition of intermittent demand into two components, the sporadicity of the demand and its variation, as also met in the categorization schemes. Also, a comparison of the generated series is carried out with the data of the M5 forecasting competition, which present sales data of Walmart, and are also used in the experimental process.

The generator was implemented using the R language, an open-source programming language that is widely used due to its powerful libraries. Thus, with the created time series generator, a user can create a data set with the same number of series of all demand categories, specifying only the desired total number of series.

## **VI. Machine learning**

The field of machine learning has seen tremendous growth in recent years, with machine learning algorithms, whether they are neural networks, support vector machines, or decision trees, being applied to a variety of problems. Despite the fact that these algorithms are increasingly encountered, with encouraging results most of the time, in the industry of inventory management, and specifically in the optimization of inventory policies, their appearance remains rather limited.

Machine learning algorithms can be distinguished into the categories of supervised, unsupervised, semi-supervised and reinforcement learning. The present thesis focuses on supervised learning algorithms, and more specifically gradient boosting decision trees, which is one of the techniques available for combining simple decision trees.

One of the most popular frameworks in this category is Light Gradient Boosting Machine (LightGBM), which has been used in both classification and regression problems, with the main advantages besides accuracy being both performance and scalability. A typical example of the success of LightGBM is the fact that an approach using this framework was the winner of the recent M5 competition, which focuses on the difficult problem of predicting retail sales data of thousands of products in different stores and US regions.

One of the disadvantages of machine learning algorithms or models is the need of having a large data set with which the model need to be trained. One of the ways to deal with this problem is by using transfer learning, a technique in which the model is trained with data from a specific source environment in order to be applied to another target environment. This technique is also used in the thesis, with surprising results, where the models of the proposed methodological framework are trained with the data produced by the data generator presented on the fifth chapter.

---

## **VII. Proposed methodological framework**

In the context of the present doctoral thesis, an innovative methodological framework for optimizing the parameters of the selected stock control policy is proposed, which combines simulations with the application of machine learning algorithms. According to the framework, the resulting near-optimal parameters are not identical for all products, but differ between the available products by choosing each time the set of parameters that is expected to reduce the total inventory cost. Essentially, the sets of parameters are determined based on simulations performed on the historical data or some other source data and a machine learning approach that aims to determine the “optimal” solution.

More specifically, using past sales data and assuming various sets of inventory policy parameters, inventory control simulations are performed and the costs derived from carrying inventory, placing orders and losing sales are calculated separately for each case. Then, specialized regression machine learning models take on the task of predicting key inventory factors, such as average inventory level and number of orders placed, which affect these costs, using demand-related information and the selected inventory parameters each time as inputs. Given such information about a random, new, product for which the policy parameters are desired to be optimized, the trained models can be effectively used to approximate the total inventory cost of the chosen setting and, consequently, to identify a near optimal setting.

The most important feature of the proposed methodological framework is its adaptability and in general tolerance to modification, since it is independent of any specific model, both in terms of the demand forecasting method it includes, and control policy it takes into account, as well as in the machine learning algorithm it leverages to make the necessary correlations. This is because the proposed approach is solely based on the available demand data, the way the simulations are defined and the model that appropriately connects their inputs and outputs. In other words, it acts as a bypass in performing simulations, linking the factors that affect the inventory control process to its outcomes over a specific period of time.

## **VIII. Presentation of results**

Analyzing the results of the evaluation procedure on the M5 competition data set led to clear results regarding the performance of the proposed methodological framework in terms of total inventory cost and realized customer service level. First of all, the results show that the methodology can be used to optimize an inventory policy, presenting extremely stable results regardless of the demand patterns appearing in the series and possible differences between the examined warehouses.

An important point is that training the machine learning models of the proposed methodology with “real” demand adds value in comparison with training them with sales data, while at the same time, training with a complete and unbiased data set is also beneficial.

In terms of computational cost, once the methodology’s models have been trained, the optimization of a control policy can be performed in a significantly shorter time than

conducting simulations, estimating the total cost for given settings almost 70 times faster.

As an additional step, the impact of improving the accuracy of demand forecasts on the total cost was examined and a comparison was made between the improvement in said accuracy and the optimization of the parameters of the control policy used. The results show that although in general more accurate forecasts can lead to lower inventory costs, this is not always the case and also the relationship between improving forecast accuracy and reducing costs is not clear. Equally important is the result that policy optimization can yield significantly greater benefit than solely improving forecast accuracy.

## **IX. Information system**

In order to make all capabilities of the framework easy to understand and accessible, a web application was built, which includes the artificial data generator, the ability to perform a stock control simulation for a generated demand series, the explanation of how the proposed methodology works for a single series as well as the ability to optimize a number of them, using the pre-trained machine learning models that demonstrated the best performance in the evaluation procedure. This application was built entirely using the R programming language, using the shiny library, creating an environment that is quite easy to understand and operate.

One of the most important, perhaps, features of the application is its ability of expansion and evolution, since the models can be easily replaced in the future by new, more sophisticated and more accurate ones, while also variables can be added or removed from the graphical interface, according to the needs of these new models.

In this way, a decision support system was created that uses machine learning models and can contribute to strategic decision making in order to optimize the inventory policy used by of minimizing inventory costs.

## **X. Conclusions and way forward**

From the results of the experimental procedure, many interesting conclusions emerge, the most important of which are briefly presented below, while the most interesting extensions are also presented.

The most interesting conclusion is the confirmation that using machine learning algorithms to approximate the results of the inventory control process, and consequently the use of this approach to optimize a control policy, has positive results, while at the same time these results are evident regardless of the demand pattern or set of products considered each time.

Regarding the training of the algorithms, it is concluded that using a complete set of demand data that contains a large number of series of all possible patterns, and represents real demand rather than sales, also has a significant positive impact. In this way, the positive effect of knowledge transfer from an unbiased data set to another target data set becomes more clear.

The above, combined with the guaranteed speed of the inference phase of machine learning models, create the right conditions for adopting such approaches in optimization

---

systems that can offer accurate suggestions while they need minimal data as inputs .

Another conclusion is that, despite the fact that in general demand forecast accuracy can reduce the total inventory cost, this is not always the case, while at the same time the benefits that derive from the optimization of the inventory policy outweigh those that can come from improving forecast accuracy.

Although it is proven that the proposed methodology can identify the optimal or near-optimal values of the parameters of an stock control policy, while at the same time it is significantly faster than conducting simulations for this purpose, there are several extensions in order to provide even greater benefit to the end users.

Additional machine learning algorithms or more complex transfer learning techniques could possibly be considered, the methodological framework could be extended so as to be able to simultaneously include multiple inventory policies and the experimental procedure could also be extended by examining additional data sets.

“Η πραγματική βελτιστοποίηση είναι η επαναστατική συμβολή της σύγχρονης έρευνας στις διαδικασίες λήψης αποφάσεων.”  
– *George Dantzig*



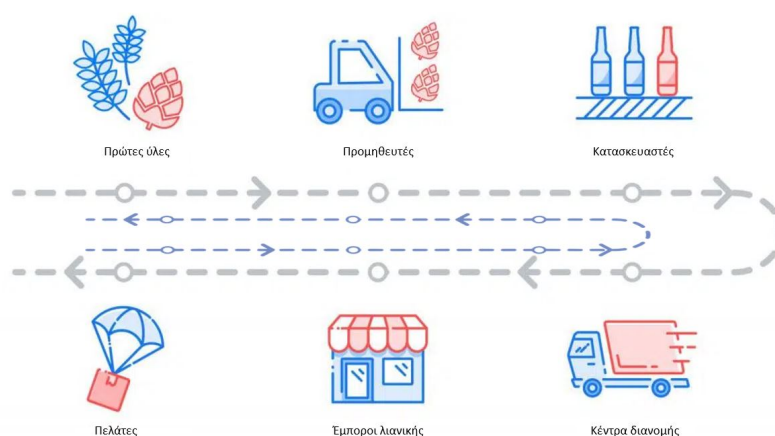
# Κεφάλαιο 1

## Εισαγωγή

---

### 1.1 Πρόλογος

Το σύστημα οργανισμών, ανθρώπων, δραστηριοτήτων, πληροφοριών και πόρων που εμπλέκονται στην παραγωγή, τη μεταφορά και την πώληση ενός συγκεκριμένου προϊόντος ή υπηρεσίας ονομάζεται εφοδιαστική αλυσίδα. Οι δραστηριότητες της μετατρέπουν τους φυσικούς πόρους, τις πρώτες ύλες και τα συστατικά τους σε ένα τελικό προϊόν που παραδίδεται στον πελάτη (Nagurney, 2006). Περιλαμβάνει τους κατασκευαστές, τους προμηθευτές, τους διανομείς, τους χονδρεμπόρους, τους λιανοπωλητές και τους ίδιους τους τελικούς πελάτες όπως απεικονίζεται στο Σχήμα 1.1. Σε μια σύγχρονη εφοδιαστική αλυσίδα οι πόροι και οι πληροφορίες μπορούν να μεταφερθούν από προμηθευτή σε πελάτη αλλά και το αντίστροφο.



Σχήμα 1.1: Αρχιτεκτονική εφοδιαστικής αλυσίδας.

Σκοπός κάθε εφοδιαστικής αλυσίδας είναι η ικανοποίηση των αναγκών του τελικού καταναλωτή δημιουργώντας, παράλληλα, κέρδη για όλα τα μέρη που εμπλέκονται σε αυτή, τα οποία από την πλευρά τους προσπαθούν διαρκώς να ελαχιστοποιήσουν τα λειτουργικά τους κόστη και να αυξήσουν τις πωλήσεις τους.

Όσο πιο διευρυμένη είναι μια εφοδιαστική αλυσίδα και όσο περισσότεροι οργανισμοί και εταιρείες εμπλέκονται σε αυτή, τόσο πιο δύσκολος γίνεται ο συντονισμός τους, με τις πρακτικές συνεργασίας που δημιουργούνται μεταξύ τους να ποικίλλουν σημαντικά. Προφανώς, η εφοδιαστική αλυσίδα ενός κατασκευαστή μπορεί να περιλαμβάνει πολλούς

προμηθευτές και εμπόρους λιανικής και η αλυσίδα μιας εταιρείας λιανικής μπορεί να περιλαμβάνει πολλούς κατασκευαστές, προμηθευτές και πελάτες.

Υπό ορισμένες συνθήκες, η διακύμανση της ζήτησης έχει την τάση να ενισχύεται καθώς προχωρά προς τα ανώτερα επίπεδα μιας αλυσίδας, δηλαδή από τους πελάτες στους λιανοπωλητές και έπειτα στους κατασκευαστές, καθιστώντας την παραγωγή προβλέψεων υψηλής ακρίβειας ολοένα και πιο δύσκολη. Υπάρχουν, έτσι, πιθανές βελτιώσεις στην ακρίβεια αυτή, οι οποίες μπορεί να επιτευχθούν με διαφορετικές μορφές συνεργασίας, συμπεριλαμβανομένης της ανταλλαγής πληροφοριών σχετικές με τη ζήτηση μεταξύ των διαφορετικών επιπέδων της εφοδιαστικής αλυσίδας.

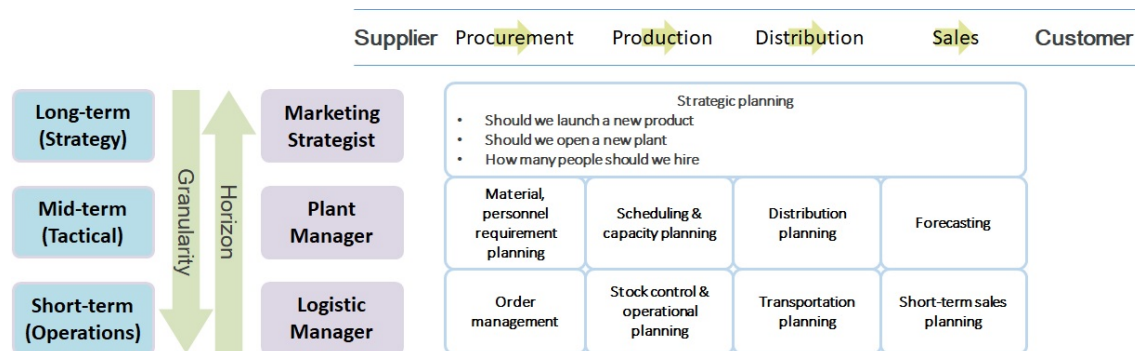
Η απόκτηση γνώσης της πραγματικής ζήτησης σε βάθος, και η παραγωγή ακριβών προβλέψεων αυτής, όμως, από μόνες τους αποτελούν μόνο ένα μέρος των διαδικασιών που απαιτούνται από πλευράς μιας εταιρείας προκειμένου αυτή να μπορεί να ικανοποιεί τις ανάγκες των καταναλωτών, ενώ παράλληλα να διατηρεί τα κόστη της σε λογικά και συμφέροντα για την ίδια επίπεδα. Στις διαδικασίες αυτές συμπεριλαμβάνονται και ο εντοπισμός της κατάλληλης στιγμής που πρέπει να επιθεωρούνται τα αποθέματα, και να πραγματοποιείται μια παραγγελία, ο υπολογισμός των μεγεθών των παραγγελιών αυτών, αλλά και η βελτιστοποίηση της στοχοθέτησης διαφόρων δεικτών που έχουν σημασία για την εταιρεία, μεταξύ άλλων. Οι παραπάνω επιμέρους διαδικασίες περιγράφουν τη διαχείριση αποθεμάτων, στην οποία πρέπει να πραγματοποιούνται αναθεωρήσεις και βελτιστοποιήσεις ανά τακτά χρονικά διαστήματα προκειμένου να λαμβάνονται υπόψη διάφορες μεταβολές που μπορεί να εμφανιστούν τόσο στη ζήτηση όσο και στον ανεφοδιασμό.

Η διαχείριση των αποθεμάτων, έτσι, αποτελεί ένα από τα στοιχεία κλειδιά της διαχείρισης της εφοδιαστικής αλυσίδας και μπορεί να επηρεάσει σημαντικά την απόδοση και τη γενικότερη ευημερία μιας επιχείρησης (Priniotakis & Argyropoulos, 2018). Ένας από τους κύριους λόγους για τους οποίους μια εταιρεία διατηρεί αποθέματα είναι η αναντιστοιχία που παρατηρείται μεταξύ προσφοράς και ζήτησης και η αβεβαιότητα που η αναντιστοιχία αυτή δημιουργεί. Συχνά είναι πολύ δύσκολο να προβλεφθεί η ακριβής στιγμή που θα εμφανιστεί η ζήτηση και το μέγεθος αυτής, με αποτέλεσμα χωρίς αποθέματα, οι πελάτες της εταιρείας να πρέπει να περιμένουν μέχρι να κατασκευαστεί ή να αναπληρωθεί το προϊόν. Επιπλέον, η ποσότητα και η ποιότητα των προϊόντων που λαμβάνονται από κάποιον προμηθευτή ενδέχεται να ποικίλουν ή να μην ανταποκρίνονται στις απαιτήσεις της εταιρείας λόγω αβεβαιότητας που περιλαμβάνεται στις διαδικασίες παραγωγής ή μεταφοράς. Με τον τρόπο αυτό, τα αποθέματα δύνανται να γεφυρώσουν το χάσμα μεταξύ προσφοράς και ζήτησης που εμφανίζεται σε διάφορα σημεία μιας εφοδιαστικής αλυσίδας.

Γενικά, η διαχείριση των αποθεμάτων αφορά δύο θεμελιώδη ερωτήματα: “πότε πρέπει να πραγματοποιηθεί μία παραγγελία και πόση ποσότητα πρέπει να παραγγελθεί;” Έτσι, αν και στην πράξη οι υπεύθυνοι λήψης αποφάσεων μπορεί να παίρνουν διάφορες αποφάσεις ανάλογα με την πολυπλοκότητα του συστήματος αποθεματοποίησης που χρησιμοποιούν, στο τέλος της μέρας οι πιο σημαντικές αποφάσεις επικεντρώνονται σε αυτά τα θεμελιώδη ερωτήματα. Ομοίως, και η βιβλιογραφία επικεντρώνεται κυρίως στην απάντηση των ίδιων ερωτήσεων για διάφορα συστήματα διαχείρισης αποθεμάτων, μοτίβα εμφάνισης της ζήτησης, παραδοχές και περιορισμούς που διέπουν μία εταιρεία.

Τα ερευνητικά πεδία της εφοδιαστικής αλυσίδας ποικίλουν ανάλογα με το επίπεδο της

αλυσίδας που εξετάζεται κάθε φορά, αλλά και το χρονικό ορίζοντα σχεδιασμού που λαμβάνεται υπόψη, όπως χαρακτηριστικά φαίνεται στο Σχήμα 1.2. Ο κλάδος της διαχείριση αποθεμάτων απασχολεί τόσο τον μεσοπρόθεσμο σχεδιασμό μιας εταιρείας όσο και τον βραχυπρόθεσμο, με τη πρώτη περίπτωση να στοχεύει τη βελτίωση της πολιτικής αποθεματοποίησης που χρησιμοποιείται για κάθε προϊόν, ενώ τη δεύτερη να αφορά στον καθημερινό ή περιοδικό έλεγχο των αποθεμάτων και την πραγματοποίηση των παραγγελιών. Όπως είναι αναμενόμενο, κάθε ερευνητικό πεδίο δεν είναι αυτοτελές αλλά εξαρτάται από τα υπόλοιπα πεδία, ανεξαρτήτως ορίζοντα σχεδιασμού και επιπέδου στο οποίο ανήκουν. Η διαχείριση αποθεμάτων, έτσι, μπορεί να επηρεαστεί από την πρόβλεψη της ζήτησης, το στόχο εξυπηρέτησης πελατών που τίθεται από τη διοίκηση, το πλήθος των διαθέσιμων υπαλλήλων, υπό την έννοια της δυνατότητας ή όχι πραγματοποίησης συγκεκριμένων διαδικασιών, το πλάνο διανομής και άλλα.



Σχήμα 1.2: Ερευνητικά πεδία της εφοδιαστικής αλυσίδας.

## 1.2 Αντικείμενο και στόχος της διατριβής

Όπως αναφέρθηκε η διαχείριση αποθεμάτων αποτελεί αναπόσπαστο κομμάτι του στρατηγικού σχεδιασμού, του προγραμματισμού και της οργάνωσης των επιχειρήσεων και των οργανισμών, επηρεάζοντας άμεσα τη βιωσιμότητά τους. Ως δομικά στοιχεία του κλάδου της θεωρίας αποθεμάτων (inventory theory) εμφανίζονται τα μοντέλα που εξετάζουν ένα προϊόν κάθε φορά, το οποίο μπορεί να αποθηκευτεί σε ένα μόνο μέρος. Το πιο ιστορικό και πιθανώς το πιο γνωστό μοντέλο αποθεματοποίησης, ενός προϊόντος, μιας τοποθεσίας, είναι το μοντέλο Οικονομικής Ποσότητας Παραγγελίας (EOQ) του Harris (1913), το οποίο αποτελεί στην ουσία την αρχή του κλάδου της θεωρίας αποθεμάτων και παρουσιάζει με έναν απλό τύπο τη σχέση μεταξύ ποσότητας παραγγελίας και κόστους αποθεματοποίησης.

Ωστόσο, οι ραγδαίες εξελίξεις στην τεχνολογία και τα πληροφοριακά συστήματα, έχουν αλλάξει δραστικά την ταχύτητα και τη φύση της ροής των αποθεμάτων και της πληροφορίας από την εποχή που δραστηριοποιούταν ο Harris. Σήμερα, για να ανταποκριθούν στις αυξημένες προσδοκίες και απαιτήσεις των πελατών, οι εταιρείες πρέπει να προσφέρουν μεγαλύτερη ποικιλία, μικρότερους χρόνους παράδοσης και καλύτερη ποιότητα σε χαμηλότερες τιμές. Καθώς όλο και περισσότερα προϊόντα αναπτύσσονται και εισάγονται στην αγορά, ο κύκλος ζωής των προϊόντων τείνει να μειώνεται, με αποτέλεσμα ο κίνδυνος απαξίωσης και η αβεβαιότητα της ζήτησης να αυξάνονται σημαντικά. Αυτός ο δυναμισμός

της αγοράς έχει κάνει τα κόστη πιο ευμετάβλητα και δύσκολα να προβλεφθούν, με τα μοντέλα διαχείρισης αποθεμάτων να πρέπει να γίνουν και αυτά με τη σειρά τους πιο δυναμικά προκειμένου να ανταπεξέλθουν. Απαιτούνται, έτσι, αυτοματοποιημένες και προσαρμοζόμενες μεθοδολογίες οι οποίες μπορούν να κάνουν χρήση των πρόσφατων τεχνολογικών ανακαλύψεων και οι οποίες θα βρίσκονται σε θέση να προσαρμοστούν εύκολα σε πιθανές μελλοντικές.

Σε μία πλήρως αυτοματοποιημένη διαδικασία βελτιστοποίησης των επιμέρους μερών που αφορούν στη διαχείριση των αποθεμάτων αναδύονται δύο βασικά εμπόδια. Το πρώτο αφορά στο υπολογιστικό κόστος τέτοιων διαδικασιών, δηλαδή το χρόνο αλλά και τους πόρους υπολογιστικής δύναμης που απαιτούνται σε καθημερινή βάση για να πραγματοποιούνται οι υπολογισμοί για χιλιάδες διαφορετικά προϊόντα. Το δεύτερο αφορά στα δεδομένα ζήτησης τα οποία δεν είναι σπάνιο να είναι ελλιπή, μιας και ακόμα και σήμερα υπάρχουν εταιρείες οι οποίες δεν έχουν εναρμονιστεί με τις νέες τεχνολογίες, με αποτέλεσμα η σωστή καταγραφή των δεδομένων τους να βρίσκεται σε εμβρυικό στάδιο, αλλά επίσης λόγω της έντονης παρουσίας νέων προϊόντων όπως αναφέρθηκε.

Ανατρέχοντας κανείς στη βιβλιογραφία ανακαλύπτει πληθώρα πολιτικών διαχείρισης αποθεμάτων και αλγορίθμων βελτιστοποίησης αυτών κάτω από συγκεκριμένους περιορισμούς κάθε φορά, οι οποίοι όμως χρησιμοποιούνται σπάνια στην πράξη καθώς είναι εξαιρετικά χρονοβόροι. Τα τελευταία χρόνια κάνουν την εμφάνισή τους στον ευρύτερο κλάδο των εφοδιαστικών αλυσίδων αλγόριθμοι και μοντέλα μηχανικής μάθησης που είναι σε θέση να υπερκεράσουν τα εμπόδια που αναφέρθηκαν παραπάνω, με το κλάδο της θεωρίας αποθεμάτων, ωστόσο, να μην πρωτοστατεί σε αυτή την εξέλιξη. Αξίζει να αναφερθεί ότι ως αλγόριθμος ορίζεται ένα μεθοδικό σύνολο βημάτων που μπορούν να χρησιμοποιηθούν για την πραγματοποίηση υπολογισμών, την επίλυση προβλημάτων και τη λήψη αποφάσεων. Ένας αλγόριθμος, έτσι, δεν είναι ένας συγκεκριμένος υπολογισμός, αλλά η μέθοδος που ακολουθείται για να γίνει ο υπολογισμός.

Στην κατεύθυνση δημιουργίας μίας αυτοματοποιημένης και γενικευμένης μεθοδολογίας εντοπισμού των βέλτιστων ρυθμίσεων της πολιτικής διαχείρισης αποθεμάτων, στην παρούσα διατριβή προτείνεται ένα μεθοδολογικό πλαίσιο το οποίο κάνει χρήση αλγορίθμων μηχανικής μάθησης και είναι σε θέση να μεταφέρει τη γνώση που αποκομίζει από μια εφαρμογή του σε μία άλλη, ενώ ταυτόχρονα αναπτύσσεται ένα ολοκληρωμένο σύστημα υποστήριξης αποφάσεων το οποίο εμπεριέχει προ-εκπαιδευμένα μοντέλα που έχουν προκύψει από το εν λόγω πλαίσιο και είναι έτοιμα να εφαρμοστούν.

Πρώτος στόχος της παρούσας διατριβής είναι ο εντοπισμός της προστιθέμενης αξίας που ενδέχεται να έχει η χρήση αλγορίθμων μηχανικής μάθησης στη θεωρία αποθεμάτων και στη συνέχεια η αξιοποίηση στο μέγιστο βαθμό των πιο καινοτόμων και ευρέως χρησιμοποιούμενων αλγορίθμων ούτως ώστε να προκύψει μία ευέλικτη μεθοδολογία με πολλές δυνατότητες, η οποία θα μπορεί να αξιοποιηθεί σε ένα ολοκληρωμένο σύστημα παράγοντας αξιόπιστες και εύκολα χρησιμοποιούμενες προτάσεις.

Η ανάλυση και η εξέταση των επιμέρους κομματιών της διαχείρισης αποθεμάτων, όπως η πολιτική αποθεματοποίησης, η πρόβλεψη της ζήτησης και το κόστος αποθεματοποίησης, μεταξύ άλλων, είναι πρωταρχικής σημασία, απαραίτητες τόσο για την κατανόηση του τρόπου με τον οποίο διάφοροι παράγοντες επηρεάζουν τη βελτιστοποίηση της εν λόγω διαδικασίας

όσο και για την κατασκευή του μεθοδολογικού πλαισίου και τον ορισμό των ανεξάρτητων και εξαρτημένων μεταβλητών των μοντέλων μηχανικής μάθησης.

Δεύτερος στόχος της παρούσας διατριβής είναι, κατά συνέπεια, να εξακριβωθεί η αποτελεσματικότητα της μεθοδολογίας σε πραγματικά δεδομένα με και χωρίς τη μεταφορά γνώσης από ένα σύνολο δεδομένων σε ένα άλλο. Για τη δεύτερη περίπτωση θα κατασκευαστούν αλγόριθμοι παραγωγής χρονοσειρών με τεχνητό τρόπο, ενώ ως πραγματικά δεδομένα θα αξιοποιηθούν χρονοσειρές από γνωστό διαγωνισμό προβλέψεων που αποτελεί σημείο αναφοράς στον κλάδο και προέρχονται από τη μεγαλύτερη εταιρεία λιανικής των ΗΠΑ.

Τέλος, ένας επιπρόσθετος στόχος της παρούσας διδακτορικής διατριβής είναι η κατασκευή ενός πληροφοριακού συστήματος (διαδικτυακή εφαρμογή) το οποίο θα περιλαμβάνει το προτεινόμενο μεθοδολογικό πλαίσιο παρέχοντας, με έναν προσιτό και εύκολα κατανοήσιμο τρόπο, τις δυνατότητές του προς χρήση.

### 1.3 Συμβολή της διατριβής

Η συμβολή της παρούσας διατριβής αφορά το ευρύτερο επιστημονικό πεδίο της επιχειρησιακής έρευνας και συγκεκριμένα αυτό της αποδοτικότερης παραγωγής προτάσεων για τη βελτίωση της διαχείρισης των αποθεμάτων για επιχειρήσεις και οργανισμούς. Δεδομένης της αβεβαιότητας του μέλλοντος και της σημασίας των αποθεμάτων στις καθημερινές αποφάσεις, τον προγραμματισμό και το σχεδιασμό μίας επιχείρησης, το εν λόγω αντικείμενο μελέτης χρίζει ιδιαίτερου ενδιαφέροντος. Τέσσερις είναι οι άξονες καινοτομίας της εν λόγω διατριβής:

- Στα πλαίσια εύρεσης μίας γενικευμένης μεθοδολογίας για τη βελτιστοποίηση της πολιτικής αποθεματοποίησης πληθώρας χρονοσειρών που απεικονίζουν τη ζήτηση προϊόντων διαφορετικών μοτίβων, εντοπίστηκε ο τρόπος που επηρεάζουν διάφοροι παράγοντες το κόστος αποθεματοποίησης. Τα παραπάνω συμπεράσματα οδήγησαν αφενός στην κατανόηση του τρόπου με τον οποίο θα μπορούσαν να αξιοποιηθούν αλγόριθμοι μηχανικής μάθησης για τη βελτιστοποίηση πολιτικών αποθεματοποίησης και αφετέρου στην κατασκευή αλγορίθμων ακριβώς με αυτό το σκοπό.
- Η εν λόγω διατριβή οδήγησε στο σχεδιασμό και την ανάπτυξη μίας ενιαίας μεθοδολογίας η οποία συνδυάζει αποτελεσματικά τεχνολογίες με αδιαμφισβήτητα αποτελέσματα στους τομείς τους, ενώ ταυτόχρονα είναι παραμετροποιήσιμη ούτως ώστε να είναι ικανή να συμπεριλάβει νέες τεχνολογίες και πολιτικές στο μέλλον. Η εν λόγω μεθοδολογία εξασφαλίζει την ακρίβεια των προτάσεών της με εντυπωσιακά μικρό υπολογιστικό κόστος, και επιτρέπει την πλήρη αυτοματοποίηση της διαδικασίας βελτιστοποίησης των παραμέτρων της επιλεγμένης πολιτικής αποθεματοποίησης ακόμα και σε περιπτώσεις έλλειψης σημαντικού πλήθους δεδομένων.
- Η αποτελεσματικότητα της προτεινόμενης μεθοδολογίας εξακριβώθηκε χρησιμοποιώντας ένα αντιπροσωπευτικό σετ από πραγματικά δεδομένα, μελετώντας παράλληλα τη δυνατότητα μεταφοράς μάθησης από ένα σύνολο δεδομένων αναφοράς

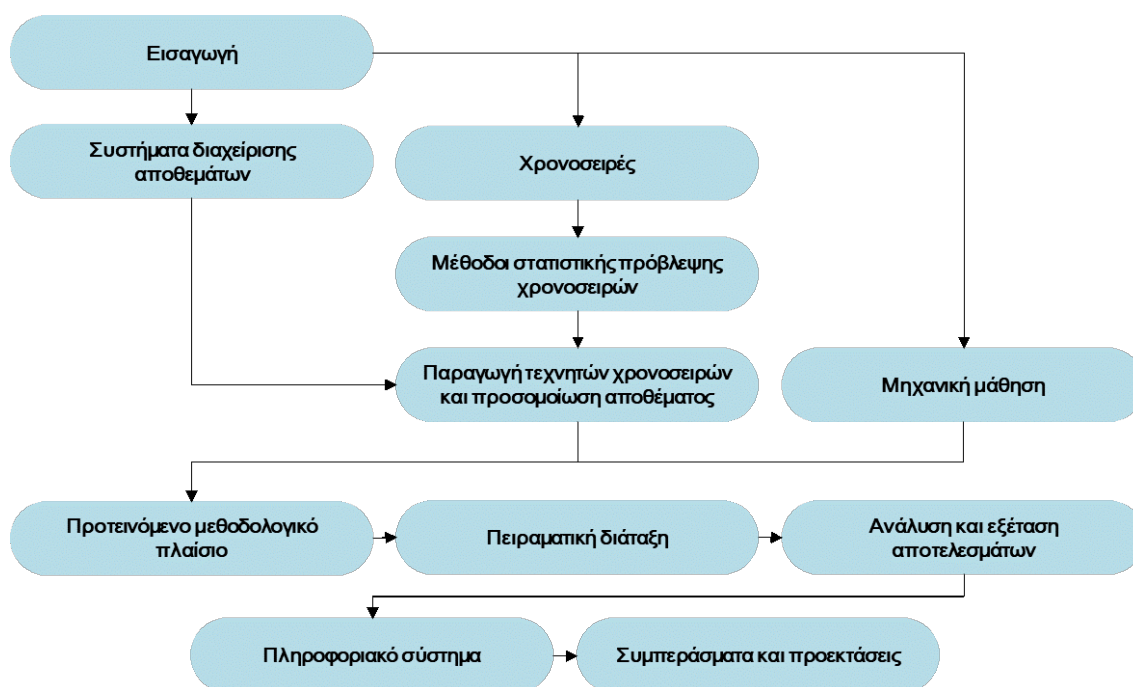
σε σειρές στόχους. Τα πραγματικά δεδομένα που χρησιμοποιήθηκαν προέρχονται από τη μεγαλύτερη εταιρεία λιανικής των ΗΠΑ και αποτελούν μέρος ενός από τους πιο γνωστούς διαγωνισμούς προβλέψεων, ενώ για την προσέγγιση της μεταφοράς μάθησης αναπτύχθηκε κατάλληλη γεννήτρια για την παραγωγή νέων χρονοσειρών ποικίλων χαρακτηριστικών.

- Αναπτύχθηκε μία διαδικτυακή εφαρμογή η οποία εμπεριέχει την προσέγγιση μεταφοράς γνώσης, καθώς περιλαμβάνει προ-εκπαιδευμένα μοντέλα μηχανικής μάθησης τα οποία είναι σε θέση να δώσουν γρήγορα ακριβείς προτάσεις για τη βελτίωση των παραμέτρων μιας πολιτικής αποθεματοποίησης για δεδομένες τιμές των παραμέτρων που αντικατοπτρίζουν τη λειτουργία μιας εταιρείας και των αναμενόμενων χαρακτηριστικών των χρονοσειρών ζήτησης των προϊόντων αυτής. Το εν λόγω πληροφοριακό σύστημα μπορεί να συμβάλει στη διευκόλυνση των εταιρειών λιανικής στη λήψη αποφάσεων που αφορούν στη διαχείριση των αποθεμάτων τους.

## 1.4 Δομή της διατριβής

Η παρούσα διατριβή οργανώνεται σε δέκα κεφάλαια κατά μήκος των οποίων παρουσιάζονται οι τεχνικές κατηγοριοποίησης και πρόβλεψης χρονοσειρών που εμφανίζονται στη βιβλιογραφία και αξιοποιήθηκαν, οι τεχνικές δημιουργίας τεχνητών χρονοσειρών, οι αλγόριθμοι μηχανικής μάθησης και τα συστήματα διαχείρισης αποθεμάτων που αξιοποιήθηκαν, η σχεδίαση της προτεινόμενης μεθοδολογίας, τα πειραματικά αποτελέσματα, η σχεδίαση του ολοκληρωμένου συστήματος που κατασκευάστηκε στο πλαίσιο της διατριβής, τα συμπεράσματα και οι προεκτάσεις της.

Η δομή της διατριβής συνοψίζεται στο Σχήμα 1.3.



Σχήμα 1.3: Δομή της παρούσας διδακτορικής διατριβής.

Πιο αναλυτικά, στο Κεφάλαιο 2 πραγματοποιείται μια διεξοδική ανάλυση του κλάδου της διαχείρισης αποθεμάτων, περιγράφεται η σημαντικότητά του για την λειτουργία των επιχειρήσεων, αναλύονται τα μέρη που τον αποτελούν και περιγράφονται οι διάφορες πολιτικές που χρησιμοποιούνται κατά την αποθεματοποίηση, οι διαφορές αυτών και οι τρόποι βελτιστοποίησής τους. Στο Κεφάλαιο 3 εισάγεται η έννοια της χρονοσειράς και αναλύονται οι τρόποι στατιστικής ανάλυσής τους, ενώ πραγματοποιείται μία ενδελεχής παρουσίαση των συστημάτων κατηγοριοποίησης των εν λόγω σειρών, όπως εμφανίζονται στη βιβλιογραφία. Στο Κεφάλαιο 4 παρουσιάζονται οι πιο διαδεδομένες στατιστικές μέθοδοι πρόβλεψης των χρονοσειρών και οι δείκτες υπολογισμού της ακρίβειας των παραγόμενων προβλέψεων, πραγματοποιώντας μία σημαντική διάκριση μεταξύ των σειρών συνεχούς και διακοπτόμενης ζήτησης, εμβαθύνοντας περισσότερο στη δεύτερη ομάδα σειρών, μιας και αυτές περιγράφουν καλύτερα τη ζήτηση στο επίπεδο της εφοδιαστικής αλυσίδας στο οποίο επικεντρώνεται η παρούσα διατριβή. Στο Κεφάλαιο 5 πραγματοποιείται αρχικά μια βιβλιογραφική ανασκόπηση των γεννητριών παραγωγής τεχνητών χρονοσειρών και στη συνέχεια παρουσιάζεται η μεθοδολογία που ακολουθήθηκε προκειμένου να παραχθούν τεχνητές χρονοσειρές ποικίλων χαρακτηριστικών και ομοιόμορφα κατανεμημένων ως προς αυτά, ενώ ακολούθως παρουσιάζονται συγκεκριμένοι διαγωνισμοί προβλέψεων και αναλύεται ο τρόπος σύγκρισης δύο ή περισσότερων συνόλων δεδομένων, ενώ παρουσιάζεται και ο τρόπος με τον οποίο μπορεί να πραγματοποιηθεί μία προσομοίωση της διαδικασίας αποθεματοποίησης. Στο Κεφάλαιο 6 γίνεται μια εισαγωγή στη μηχανική μάθηση, αναλύοντας ορισμένους αλγορίθμους που χρησιμοποιήθηκαν στο πλαίσιο της παρούσας διδακτορικής διατριβής, ενώ στο Κεφάλαιο 7 περιγράφεται αναλυτικά το μεθοδολογικό πλαίσιο που προτείνεται και τα μέρη που το απαρτίζουν. Στη συνέχεια, στο Κεφάλαιο 8 περιγράφεται η πειραματική διαδικασία που ακολουθήθηκε προκειμένου να εξακριβωθεί η αξία της προτεινόμενης μεθοδολογίας και παρουσιάζονται αναλυτικά τα αποτελέσματα που προέκυψαν. Στο Κεφάλαιο 9, παρουσιάζεται το σύστημα διαχείρισης αποφάσεων που κατασκευάστηκε και το οποίο εμπεριέχει την προτεινόμενη μεθοδολογία, και τέλος στο Κεφάλαιο 10 παρατίθενται τα συμπεράσματα και οι προεκτάσεις της εργασίας.

## 1.5 Ερευνητικά αποτελέσματα της διατριβής

Η διατριβή ολοκληρώθηκε σε περίπου τέσσερα έτη (2018-2022) και οδήγησε σε:

### ✓ 3 δημοσιεύσεις σε επιστημονικά περιοδικά

- ① Theodorou, E., Spiliotis, E., Assimakopoulos, V. (2022). Optimizing inventory control through a data-driven and model-independent framework. *EURO Journal on Transportation and Logistics*, 12: 100103
- ② Theodorou, E., Spiliotis, E. (2022). Better forecasts or more appropriate stock control policies? *Foresight: The International Journal of Applied Forecasting*, Issue 68, 40-44
- ③ Theodorou, E., Wang, S., Kang, Y., Spiliotis, E., Makridakis, S., Assimakopoulos, V. (2021). Exploring the representativeness of the M5 competition data. *International Journal of Forecasting*, 38 (4), 1500-1506

✓ **5 ανακοινώσεις σε επιστημονικά συνέδρια**

- ① Theodorou, E., Spiliotis, E., Assimakopoulos, V. (2023). Forecasting accuracy and inventory performance: Evidence on their relationship from the M5 competition data. 43rd International Symposium on Forecasting - ISF 2023, June 25-28, 2023, Charlottesville, Virginia USA (*accepted*)
- ② Theodorou, E., Spiliotis, E., Assimakopoulos, V. (2022). A data-driven stock control optimization framework. 42nd International Symposium on Forecasting - ISF 2022, July 10-13, 2022, Oxford, England
- ③ Theodorou, E., Spiliotis, E., Assimakopoulos, V. (2021). Evaluating the impact of business practices on inventory performance. 41st International Symposium on Forecasting - ISF 2021, June 27-30, 2021, online
- ④ Theodorou, E., Spiliotis, E., Assimakopoulos, V. (2020). Footfall forecasting as a workforce optimization tool. 40th International Symposium on Forecasting - ISF 2020, October 26-28, 2020, online
- ⑤ Theodorou, E., Spiliotis, E., Assimakopoulos, V. (2019). Supply Chain Management: Bridging the gap between business and academia. 39th International Symposium on Forecasting - ISF 2019, June 16-19, 2019, Thessaloniki, Greece





“Όσο περισσότερο απόθεμα έχει μια εταιρεία, τόσο λιγότερο πιθανό είναι να έχει αυτό που  
χρειάζεται.”  
– *Taichi Ohno*

## Κεφάλαιο 2

### Συστήματα διαχείρισης αποθεμάτων

---

Πρωταρχική σημασία για μια εταιρεία αποτελεί η σωστή διαχείριση των αποθεμάτων της, των αγαθών που εισάγονται στην επιχείρηση και ξεπερνούν αυτές που εξάγονται από αυτή, των αγαθών που μπορούν να αποθηκευτούν προκειμένου να ικανοποιήσουν κάποια τρέχουσα ή μελλοντική ανάγκη.

Στο παρόν Κεφάλαιο πραγματοποιείται μια εκτενής περιγραφή των συστημάτων διαχείρισης αποθεμάτων, παρουσιάζονται τα κύρια μέρη από τα οποία απαρτίζονται και αναλύονται τα πιο ευρέως χρησιμοποιούμενα τόσο στη βιβλιογραφία όσο και στη βιομηχανία.

#### 2.1 Εισαγωγή στη διαχείριση αποθεμάτων

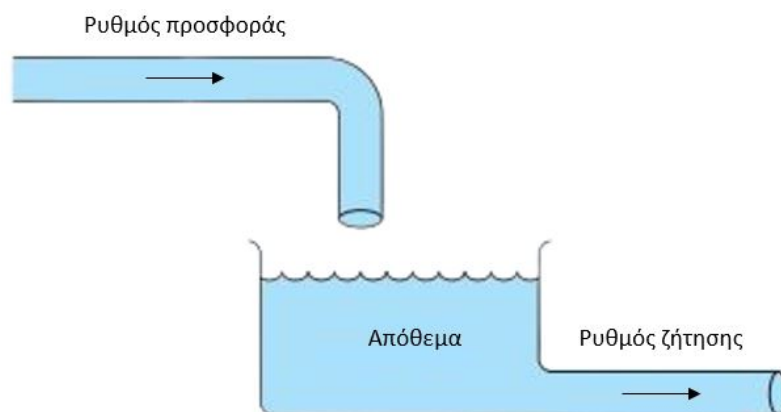
Αποθέματα μιας επιχείρησης ονομάζονται τα περιουσιακά στοιχεία που αυτή έχει στην κατοχή της, τα οποία συνήθως προέρχονται από απογραφή, από αγορά και από ιδιοπαραγωγή, ενώ σε εξαιρετικές περιπτώσεις προέρχονται από εισφορά σε είδος, από ανταλλαγές ή από δωρεές και έχουν τα ακόλουθα χαρακτηριστικά (Reid & Sanders, 2019):

- είναι διαθέσιμα προς πώληση κατά τη συνήθη πορεία των εργασιών της επιχείρησης,
- βρίσκονται ήδη στη διαδικασία παραγωγής της επιχείρησης προκειμένου να μετεξελιχθούν σε έτοιμα προϊόντα και να διατεθούν προς πώληση και
- έχουν τη μορφή πρώτων υλών ή υλικών τα οποία θα χρησιμοποιηθούν από την ίδια την επιχείρηση για τη παραγωγή άλλων αγαθών.

Η δημιουργία αποθεμάτων μπορεί να είναι προσχεδιασμένη, με στόχο την εξομάλυνση της διαφοράς προσφοράς και ζήτησης των αγαθών, αλλά και της αβεβαιότητας που διέπει αυτές τις δύο μεταβλητές, ή αποτέλεσμα άλλων παραγόντων, όπως ο κακός σχεδιασμός ή κάποια έκτακτα φαινόμενα.

Ανεξάρτητα από το τί αποθηκεύεται ως απόθεμα ή σε ποιο σημείο της παραγωγικής διαδικασίας τοποθετείται, το απόθεμα υπάρχει αποκλειστικά λόγω της χρονικής διαφοράς και των μεταβολών της σχέσης προσφοράς και ζήτησης. Στην περίπτωση όπου η προσφορά γίνεται ακριβώς την ίδια στιγμή με τη ζήτηση, δεν θα υπήρχε ανάγκη για αποθήκευση. Αυτό μπορεί να γίνει πιο εύκολα αντιληπτό στη δεξαμενή νερού του Σχήματος 2.1. Όταν ο ρυθμός παροχής νερού στη δεξαμενή διαφέρει από τον ρυθμό ζήτησης, χρειάζεται μια

δεξαμενή (απόθεμα) για να διατηρείται η παροχή νερού. Όταν ο ρυθμός προσφοράς υπερβαίνει το ρυθμό ζήτησης, το απόθεμα αυξάνεται, ενώ όταν ο ρυθμός ζήτησης υπερβαίνει το ρυθμό προσφοράς, το απόθεμα μειώνεται. Κατ' αναλογία, εάν μια επιχείρηση καταφέρει να εναρμονίσει τους ρυθμούς προσφοράς και ζήτησης, μπορεί να εξισορροπήσει και να μειώσει το επίπεδο αποθεμάτων της.



Σχήμα 2.1: Απεικόνιση αναλογίας αποθέματος με δεξαμενή νερού.

Η διαχείριση των αποθεμάτων, έτσι, εστιάζει στην ισορροπία που απαιτείται όταν ο υπεύθυνος λήψης αποφάσεων προσπαθεί να καλύψει τη ζήτηση και ταυτόχρονα να μεγιστοποιήσει το κέρδος της επιχείρησης, με κύρια σημεία ενδιαφέροντος τον προσδιορισμό του βέλτιστου ύψους αποθέματος και το χρονικό προγραμματισμό των παραγγελιών, με στόχο την ελαχιστοποίηση του κόστους που δημιουργείται από την διατήρηση των αποθεμάτων αυτών, αλλά και τον καθορισμό των διαδικασιών ελέγχου τόσο των αποθεμάτων όσο και του ίδιου του συστήματος (Hax & Candea, 1984). Με τη σειρά της, μια πολιτική αποθεματοποίησης καθορίζει τον τρόπο με τον οποίο πρέπει να παίρνονται αυτές οι αποφάσεις. Οι όροι “πολιτική” ή “μοντέλο” αποθεματοποίησης τις περισσότερες φορές αναφέρονται σε ένα σύστημα διαχείρισης αποθεμάτων, το οποίο προφανώς αποτελεί απλοποίηση της πραγματικότητας.

Κάθε απόφαση σχετική με τη διαχείριση αποθεμάτων περιστρέφεται γύρω από τρεις βασικές ερωτήσεις (Silver, 1981):

- Πότε πρέπει να ελέγχεται το επίπεδο του αποθέματος;
- Ποιά πρέπει να είναι η ποσότητα παραγγελίας;
- Πότε πρέπει να πραγματοποιηθεί η παραγγελία;

Τα ζητήματα αυτά αποτελούν σημεία εκκίνησης της διαχείρισης αποθεμάτων και αντιπροσωπεύουν παραδοσιακά χαρακτηριστικά μιας κατάστασης αποθεμάτων.

Η πρώτη σχετική δημοσιευμένη μελέτη πραγματοποιήθηκε από τον Harris (1913), και προήλθε από την εργασιακή εμπειρία του συγγραφέα και την ανάγκη του να υπολογίσει την πιο οικονομική ποσότητα παραγγελίας. Ο τύπος με την τετραγωνική ρίζα που πρότεινε είναι σήμερα γνωστός ως μοντέλο Οικονομικής Ποσότητας Παραγγελίας (Economic Order Quantity - EOQ), περισσότερα για τον οποίο θα συζητηθούν στο Υποκεφάλαιο 2.8.

Σήμερα, η βιβλιογραφία που ασχολείται με θέματα της διαχείριση αποθεμάτων είναι τουλάχιστον εκτενής. Εξετάζονται θέματα που κυμαίνονται από τη λήψη αποφάσεων σε στρατηγικό επίπεδο, το σχεδιασμό δικτύου διανομής, έως τη πρόβλεψη της ζήτησης των προϊόντων, τη βελτιστοποίηση του επιπέδου του αποθέματος τόσο στις αποθήκες όσο και στα καταστήματα λιανικής και το συντονισμό στην αναπλήρωση μεταξύ τους.

## 2.2 Κατηγοριοποίηση αποθεμάτων

Τα αποθέματα μπορούν να διακριθούν βάσει της ροής τους μέσα στη διαδικασία παραγωγής (φυσική μορφή), αλλά και με βάση την αιτία της δημιουργίας τους (Slack et al., 2010; Reid & Sanders, 2019).

### 2.2.1 Αποθέματα βάσει της ροής τους

Οι τύποι αποθεμάτων που σχετίζονται με τη ροή τους είναι οι εξής:

1. Πρώτες ύλες (raw materials): οι εισροές στην παραγωγική διαδικασία που θα τροποποιηθούν ή θα μετατραπούν σε έτοιμα προϊόντα.
2. Ανταλλακτικά (components): υλικά ή υποπροϊόντα τα οποία χρησιμοποιούνται για την δημιουργία του έτοιμου προϊόντος.
3. Υλικά υπό επεξεργασία ή ημικατεργασμένα (work-in-process, WIP): έτοιμα εν μέρει τελικά προϊόντα που βρίσκονται ακόμη στην παραγωγική διαδικασία.
4. Έτοιμα προϊόντα (finished goods): τα τελικά προϊόντα που είναι έτοιμα προς πώληση, διανομή ή αποθήκευση.
5. Απόθεμα διανομής (distribution inventory): τα έτοιμα προϊόντα που βρίσκονται σε διάφορα σημεία του συστήματος διανομής.
6. Υλικά για συντήρηση, επισκευές και λειτουργία (maintenance, repair and operational inventory, MRO): τα υλικά που χρησιμοποιούνται για να υποστηρίξουν την παραγωγή, αλλά δεν αποτελούν μέρος του τελικού προϊόντος, όπως εργαλεία, ανταλλακτικά ή προϊόντα καθαρισμού.



Σχήμα 2.2: Κατηγορίες αποθεμάτων βάσει της ροής τους.

Κάθε επιχείρηση διαθέτει διαφορετικά είδη αποθεμάτων, ανάλογα τη λειτουργία της και τη θέση της στην εφοδιαστική αλυσίδα. Έτσι, η κατάταξη των αποθεμάτων σε καθεμιά από τις παραπάνω κατηγορίες, εξαρτάται άμεσα από την επιχείρηση που εξετάζεται, μιας και το έτοιμο προϊόν μιας επιχείρησης μπορεί να είναι η πρώτη ύλη μιας άλλης.

### 2.2.2 Αποθέματα βάσει της χρήσης τους

Τα αποθέματα, ανάλογα με το βασικό σκοπό της δημιουργίας τους, μπορούν να κατηγοριοποιηθούν ως εξής:

- Αποθέματα αναμονής (Anticipation Inventory or Seasonal Inventory): τα αποθέματα που δημιουργούνται εν αναμονή κάποιας μελλοντικής ζήτησης, προγραμματισμένων προωθητικών προγραμμάτων, εποχιακών διακυμάνσεων ή διακοπών. Χρησιμοποιούνται συνήθως όταν οι διακυμάνσεις στη ζήτηση είναι μεγάλες αλλά σχετικά προβλέψιμες. Οι εταιρείες δημιουργούν απόθεμα αναμονής για να διατηρήσουν το επίπεδο της παραγωγής καθ' όλη τη διάρκεια του έτους.
- Αποθέματα ασφαλείας (Fluctuation Inventory or Safety Stock): τα αποθέματα που διατηρεί η επιχείρηση προκειμένου να αντισταθμίσει τις απρόβλεπτες διακυμάνσεις της προσφοράς και της ζήτησης. Τα αποθέματα ασφαλείας προστατεύουν την επιχείρηση από προβλήματα έλλειψης προϊόντων και κατ' επέκταση εξυπηρέτησης πελατών.
- Κυκλικά αποθέματα (Lot-size Inventory or Cycle Stock): τα αποθέματα που προκύπτουν όταν η επιχείρηση παράγει ή αγοράζει προϊόντα τα οποία υπερκαλύπτουν τη ζήτηση μία χρονική στιγμή. Μπορεί να προκύψουν από την ανάγκη της επιχείρησης να εκμεταλλευτεί χαμηλότερες τιμές ή εκπτώσεις προμηθευτών ή από την ύπαρξη ελάχιστης ποσότητας κατασκευής ή παραγγελίας η οποία είναι μεγαλύτερη της ζήτησης.
- Αποθέματα σε κίνηση (Transportation or Pipeline Inventory): τα αποθέματα τα οποία αποτελούν παραγγελίες που έχουν πραγματοποιηθεί αλλά δεν έχουν ακόμη παραληφθεί. Προκύπτουν λόγω του χρόνου που απαιτείται για να μεταφερθούν τα προϊόντα από την επιχείρηση στο σημείο ζήτησης, και υπολογίζεται με τον τύπο:

$$ATI = \frac{tD}{365},$$

όπου  $ATI$  είναι το μέσο απόθεμα σε κίνηση (μονάδες),  $t$  ο χρόνος κίνησης (ημέρες) και  $D$  η ετήσια ζήτηση (μονάδες)

- Αποθέματα αντιστάθμισης κινδύνου (Speculative or Hedge Inventory): τα αποθέματα που χρησιμοποιούνται για την προστασία από κάποιο μελλοντικό γεγονός, όπως μια απεργία στον προμηθευτή, μια αύξηση τιμής ή μια έλλειψη ενός προϊόντος που μπορεί να συμβεί αλλά μπορεί και να μην συμβεί.
- Αποθέματα συντήρησης, επισκευής και λειτουργίας (Maintenance, Repair, and Operating (MRO) Inventory): τα αποθέματα που περιλαμβάνουν προϊόντα συντήρησης, ανταλλακτικά, λιπαντικά, καθαριστικά και αναλώσιμα απαραίτητα για την καθημερινή λειτουργία.
- Αποθέματα απόζευξης (Decoupling Inventory): τα αποθέματα που χρησιμοποιούνται ώστε να επιτρέπουν στα κέντρα εργασίας ή τις διαδικασίες να λειτουργούν σχετικά ανεξάρτητα προκειμένου να αποφεύγονται διακοπές στην εφοδιαστική αλυσίδα λόγω έλλειψης συντονισμού μεταξύ των φάσεων.

## 2.3 Πλεονεκτήματα διατήρησης αποθεμάτων

Όπως είναι φανερό, τα αποθέματα αποτελούν προστασία απέναντι στην αβεβαιότητα σε διάφορα μέρη της εφοδιαστικής αλυσίδας (Davis, 1993). Ωστόσο, η διατήρηση αποθεμάτων δημιουργεί κόστη στην επιχείρηση, τόσο φανερά όσο και μη, καθιστώντας τη μία πρόκληση στον τομέα της διοίκησης επιχειρησιακών λειτουργιών, μιας και ενώ η ύπαρξη αποθεμάτων είναι απαραίτητη, προκειμένου να επιτευχθεί το επιθυμητό επίπεδο εξυπηρέτησης πελατών, δεν είναι επιθυμητή (Plinere et al., 2015).

Οι κύριοι λόγοι διατήρησης αποθεμάτων είναι οι εξής (Russell & Taylor, 2010):

- Η αντιμετώπιση απρόβλεπτων διακυμάνσεων στην προσφορά και στη ζήτηση.
- Η παροχή ασφάλειας σε μη προγραμματισμένες καταστάσεις όπως σε περίπτωση διακοπής της παραγωγικής διαδικασίας, ή τυχόν καθυστερήσεων στους χρόνους προμήθειας και παράδοσης των προϊόντων.
- Η εξασφάλιση ανεξαρτησίας μεταξύ του κάθε μέρους του συστήματος προμήθειες-παραγωγή-διανομή.
- Η διεκδίκηση κάποιας έκπτωσης από τον προμηθευτή σε περίπτωση παραγγελίας μεγάλων ποσοτήτων.

## 2.4 Μειονεκτήματα διατήρησης αποθεμάτων

Παρά το γεγονός ότι το απόθεμα αποτελεί κύριο κομμάτι της απόδοσης των λειτουργιών μιας επιχείρησης, υπάρχουν ορισμένες αρνητικές πτυχές του, οι οποίες συνοψίζονται στα παρακάτω:

- Δεσμεύει χρήματα, με τη μορφή κεφαλαίου κίνησης, το οποίο επομένως δεν είναι διαθέσιμο για άλλες χρήσεις, όπως η μείωση δανείων ή η πραγματοποίηση επενδύσεων.
- Συνεπάγεται κόστος αποθήκευσης με τη μορφή μίσθωσης χώρου, διατήρησης κατάλληλων συνθηκών κ.ά.
- Μπορεί να καταστεί παρωχημένο με την εμφάνιση διαθέσιμων εναλλακτικών λύσεων.
- Μπορεί να καταστραφεί ή να φθαρεί.
- Μπορεί να χαθεί ή να είναι δαπανηρή η ανάκτησή του, καθώς κρύβεται μεταξύ άλλων αποθεμάτων.
- Η αποθήκευσή του μπορεί να είναι επικίνδυνη (για παράδειγμα εύφλεκτοι διαλύτες, εκρηκτικά, χημικά και φάρμακα), ή να απαιτεί ειδικές εγκαταστάσεις και συστήματα για ασφαλή χειρισμό.
- Χρησιμοποιεί χώρο που θα μπορούσε να χρησιμοποιηθεί για να προσθέσει αξία στην επιχείρηση.
- Η διαχείρισή του περιλαμβάνει διάφορα διοικητικά και ασφαλιστικά έξοδα.

## 2.5 Στοιχεία κόστους αποθεματοποίησης

Οι κύριες παράμετροι που επηρεάζουν το κόστος διαχείρισης των αποθεμάτων είναι το κόστος που αφορά στην πραγματοποίηση της παραγγελίας προς τους προμηθευτές, το κόστος διατήρησης των αποθεμάτων και το κόστος έλλειψης σε δεδομένη ζήτηση (Russell & Taylor, 2010), ενώ στην πραγματικότητα, το κόστος επηρεάζεται και από άλλες παραμέτρους, όπως το κόστος αγοράς του εκάστοτε προϊόντος, το κόστος διαχείρισης της παραγγελίας, το κόστος μεταφοράς ή τα κόστη βλάβης, φθοράς και απαξίωσης (Slack et al., 2010; Κακούρης, 2013; Reid & Sanders, 2019). Παρά το γεγονός ότι οι μεταβλητές που απαιτούνται για τον υπολογισμό των παραπάνω παραμέτρων, δεν είναι πάντα σταθερές, αλλά μπορεί είτε να μεταβάλλονται με το χρόνο ή να σχετίζονται με το επίπεδο του αποθέματος κάθε φορά, στη βιβλιογραφία οι τιμές που παίρνουν είναι συνήθως σταθερές (Yang, 2014).

Παρακάτω παρουσιάζονται τα πιο σημαντικά κόστη, με τις αντίστοιχες εξισώσεις τους, όταν αυτά αφορούν σε ένα προϊόν. Προφανώς ο υπολογισμός ενός από τα εν λόγω κόστη στο σύνολο μιας αποθήκης, δηλαδή όταν αφορά σε πολλά προϊόντα, υπολογίζεται ως το άθροισμα του αποτελέσματος κάθε προϊόντος. Πιο αναλυτικά, έστω κόστος  $C_i$  του προϊόντος  $i$  και  $n$  προϊόντα σε μία αποθήκη, τότε το κόστος της αποθήκης υπολογίζεται ως  $\sum_{i=1}^n C_i$ .

### 2.5.1 Κόστος τοποθέτησης παραγγελίας (Ordering Cost)

Όταν πραγματοποιείται μια παραγγελία σε έναν προμηθευτή για μία πρώτη ύλη, κάποιο εξάρτημα ή ένα προϊόν, η επιχείρηση επιβαρύνεται με κάποιο κόστος το οποίο ονομάζεται κόστος τοποθέτησης παραγγελίας (ordering cost). Αυτό το κόστος είναι συνήθως ανεξάρτητο της ποσότητας παραγγελίας και περιλαμβάνει τα κόστη όλων των δραστηριοτήτων σχετικών με τη λήψη, την προετοιμασία, την αποστολή, την παρακολούθηση των παραγγελιών αλλά και με το χειρισμό των αγαθών. Για ένα προϊόν και διάστημα  $T$  περιόδων το κόστος τοποθέτησης παραγγελίας μπορεί να υπολογιστεί με τον παρακάτω τύπο :

$$C_O = k \sum_{t=1}^T NO_t,$$

όπου το  $NO_t$  παίρνει τη τιμή 1 εάν πραγματοποιήθηκε μια παραγγελία και 0 σε αντίθετη περίπτωση και αναπαριστά το πλήθος παραγγελιών που πραγματοποιήθηκαν στο συγκεκριμένο διάστημα, και  $k$  είναι το κόστος πραγματοποίησης μιας παραγγελίας.

Ενώ στη βιβλιογραφία, ιδιαίτερα την πιο πρόσφατη, εμφανίζονται σχέσεις του κόστους πραγματοποίησης μιας παραγγελίας με το χρόνο, αλλά και το χρόνο παράδοσης (Hemalatha & Annadurai, 2020), στις περισσότερες περιπτώσεις επιλέγεται μια σταθερή τιμή (Shang & Zhou, 2010; Altay et al., 2012; Lagodimos et al., 2012), η οποία κυμαίνεται από \$0.25 μέχρι \$1.

### 2.5.2 Κόστος ελέγχου αποθεμάτων (Review Cost)

Το κόστος ελέγχου των αποθεμάτων αποτελεί την επιβάρυνση που δημιουργείται στην επιχείρηση κάθε φορά που καταμετρείται το διαθέσιμο απόθεμα. Δεν είναι σπάνιο το



συγκεκριμένο κόστος να είναι βαρύνουσας σημασίας, ιδιαίτερα σε περιπτώσεις όπου δεν έχουν υιοθετηθεί νέες τεχνολογίες οι οποίες πραγματοποιούν την καταμέτρηση των αποθεμάτων αυτόματα με αποτέλεσμα ο συγκεκριμένος έλεγχος να πραγματοποιείται από εργαζομένους. Το συγκεκριμένο κόστος, στη βιβλιογραφία εμφανίζεται ως ανεξάρτητο του μεγέθους των αποθεμάτων, λαμβάνοντας μία σταθερή τιμή κάθε φορά που πραγματοποιείται ένας έλεγχος (Silver, 1981; Christou et al., 2020). Έτσι, για ένα προϊόν και διάστημα  $T$  περιόδων το κόστος ελέγχου αποθεμάτων μπορεί να υπολογιστεί με τον παρακάτω τύπο:

$$C_R = w \sum_{t=1}^T RO_t,$$

όπου το  $RO_t$  παίρνει τη τιμή 1 εάν πραγματοποιήθηκε ένας έλεγχος και 0 σε αντίθετη περίπτωση και αναπαριστά το πλήθος των ελέγχων αποθεμάτων που πραγματοποιήθηκαν στο συγκεκριμένο διάστημα, και  $w$  είναι το σταθερό κόστος πραγματοποίησης ενός ελέγχου.

### 2.5.3 Κόστος διατήρησης αποθεμάτων (Carrying or Holding Cost)

Ως κόστος διατήρησης αποθεμάτων ονομάζεται το κόστος που σχετίζεται με την αναμονή προϊόντων στο απόθεμα. Το κόστος αυτό εξαρτάται άμεσα από το επίπεδο αποθέματος και περιστασιακά με το χρονικό διάστημα που παραμένει ένα προϊόν στο απόθεμα. Γενικά η σχέση του κόστους αυτού με το επίπεδο του αποθέματος είναι γραμμική, όσο αυξάνεται το επίπεδο αυξάνεται και το κόστος διατήρησης αποθεμάτων, και περιλαμβάνει τα εξής:

- Αποθηκευτικός χώρος (ενοικίαση, απόσβεση, ρεύμα, θέρμανση, ψύξη, φωτισμός, ασφάλεια, ψύξη, φόροι, ασφάλειες κ.λπ.)
- Διακίνηση υλικών (εξοπλισμός)
- Εργασία
- Τήρηση αρχείων
- Δανεισμός για αγορά αποθεμάτων (τόκοι δανείων, φόροι, ασφάλειες)
- Φθορά προϊόντος, αλλοίωση, θραύση, απαξίωση, κλοπή

Το κόστος διατήρησης αποθεμάτων μπορεί να υπολογιστεί είτε αθροίζοντας όλα τα παραπάνω επιμέρους στοιχεία είτε να εκφραστεί ως ποσοστό της αξίας ενός προϊόντος ή της μέσης αξίας του αποθέματος. Σύμφωνα με τους Lambert & Stock (1993) το κόστος διατήρησης αποθέματος ως ποσοστό της αξίας ενός προϊόντος κυμαίνεται μεταξύ 12% και 34%, ανάλογα τον κλάδο της επιχείρησης, όμως πιο πρόσφατες έρευνες υποστηρίζουν ότι, για ορισμένα προϊόντα, το κυρίαρχο μέρος του κόστους διατήρησης αποθεμάτων είναι το κόστος κεφαλαίου, το οποίο, κατά μέσο όρο, είναι ίσο με την αξία του προϊόντος επί το πραγματικό επιτόκιο χωρίς κίνδυνο (real risk-free rate), το οποίο εκτιμάται στο 1% (Berling & Rosling, 2005).

Το κόστος διατήρησης αποθεμάτων για ένα προϊόν και διάστημα  $T$  περιόδων μπορεί να υπολογιστεί ως εξής :

$$C_H = h\bar{I}p = \frac{h}{T} \sum_{t=1}^T I_t p,$$

όπου  $h$  είναι το κόστος διατήρησης μιας μονάδας προϊόντος ως ποσοστό της αξίας του προϊόντος,  $p$  η αξία του προϊόντος, και  $\bar{I}$  το μέσο επίπεδο αποθέματος στο συγκεκριμένο διάστημα.

#### 2.5.4 Κόστος έλλειψης αποθεμάτων (Shortage or Lost sales Cost)

Το κόστος έλλειψης αποθεμάτων δημιουργείται όταν δεν υπάρχει διαθέσιμο απόθεμα προκειμένου να ικανοποιηθεί η ζήτηση. Η έλλειψη αυτή μπορεί να προκληθεί είτε από εξάντληση των προϊόντων, γεγονός που οφείλεται σε αυξημένη ζήτηση ή σε λανθασμένες προβλέψεις στην παραγωγή, είτε από περιορισμένο απόθεμα λόγω μη διαθέσιμων κεφαλαίων ή χώρων αποθήκευσης, και έχει ως αποτέλεσμα την αδυναμία εξυπηρέτησης των πελατών, οι οποίοι είναι πιθανόν να στραφούν σε άλλους προμηθευτές, γεγονός που οδηγεί σε απώλεια πωλήσεων και συνεπώς κέρδους από τη μεριά της επιχείρησης. Όταν η ζήτηση είναι στοχαστική, οι ελλείψεις στο απόθεμα είναι αναπόφευκτες.

Στην περίπτωση όπου η ζήτηση δεν μπορεί να εκπληρωθεί, εξαρτάται από τον τρόπο που λειτουργεί η επιχείρηση, είναι πιθανό είτε να καλυφθεί στο μέλλον, μόλις υπάρξει διαθέσιμο απόθεμα (αναδρομικές παραγγελίες) είτε να χαθεί από πώληση (χαμένες πωλήσεις). Παρά το γεγονός ότι στο πρώτο σενάριο οι πελάτες θα λάβουν τελικά το προϊόν που παρήγγειλαν, θα έχει μεσολαβήσει κάποιο μη επιθυμητό διάστημα από τη στιγμή της παραγγελίας μέχρι τη στιγμή της παραλαβής, που σημαίνει ότι η πώληση δεν χάνεται αλλά δημιουργείται ένα κόστος το οποίο σχετίζεται με αυτή την καθυστέρηση και μπορεί να επηρεάσει τη φήμη της επιχείρησης, την διάθεση του πελάτη και μακροπρόθεσμα μπορεί να οδηγήσει σε απώλεια μεριδίου αγοράς (Anderson et al., 2018). Στο δεύτερο σενάριο, εκτός από τα παραπάνω, δεν πραγματοποιείται η πώληση με αποτέλεσμα να χάνεται και το κέρδος που θα προέκυπτε από αυτή.

Ενώ έχουν γίνει προσπάθειες να μοντελοποιηθεί το κομμάτι που αφορά στην επίπτωση στη φήμη της επιχείρησης (Alfares & Elmorra, 2005), είναι δύσκολο να εκτιμηθεί και συχνά παραγκωνίζεται (Liao et al., 2011), δίνοντας έτσι στο κόστος έλλειψης ( $b$ ) τη τιμή του περιθωρίου κέρδους του προϊόντος.

Στην περίπτωση των χαμένων πωλήσεων, το κόστος έλλειψης αποθεμάτων μπορεί να υπολογιστεί ως εξής :

$$C_{LS} = b \sum_{t=1}^T LS_t p,$$

όπου  $b$  είναι το κόστος έλλειψης ως ποσοστό της αξίας του προϊόντος ( $p$ ), και  $LS_t$  οι χαμένες πωλήσεις που προέκυψαν στο συγκεκριμένο διάστημα.

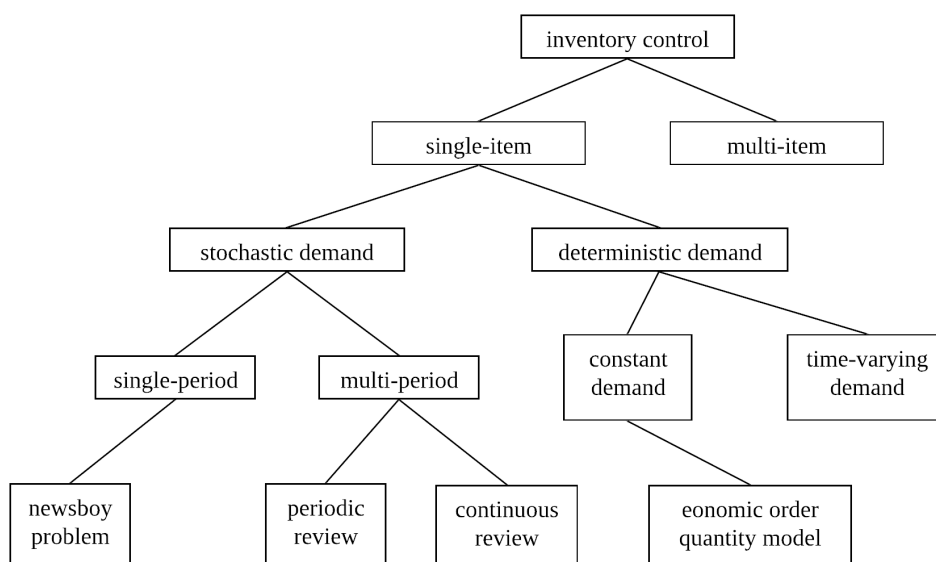
### 2.5.5 Κόστος αγοράς αποθεμάτων (Purchasing or Item Cost)

Το κόστος αγοράς των αποθεμάτων περιλαμβάνει την τιμή αγοράς του προϊόντος, τους πιθανούς εισαγωγικούς δασμούς και φόρους, έξοδα μεταφοράς που καταβάλλει η επιχείρηση για να φτάσει το προϊόν στις αποθήκες της (φορτωτικά, μεταφορικά από την αποθήκη του προμηθευτή, εκφορτωτικά έξοδα κλπ), τυχόν έξοδα διαχείρισης, έξοδα παράδοσης, ασφάλιστρα και άλλες τέτοιου είδους δαπάνες (Thornton, 2006). Επιπρόσθετα, στο κόστος αγοράς μπορεί να περιλαμβάνονται συναλλαγματικές διαφορές που προκύπτουν στην περίπτωση που τα αποθέματα προέρχονται από χώρες με διαφορετικό νόμισμα. Θεωρώντας ότι τα παραπάνω επιμερίζονται ισομερώς και συμπεριλαμβάνονται στην αξία του προϊόντος ( $p$ ), η οποία παραμένει σταθερή, το κόστος αγοράς αποθεμάτων ενός προϊόντος για το διάστημα  $T$  μπορεί να υπολογιστεί με τον παρακάτω τύπο:

$$C_P = \sum_{t=1}^T Q_t p.$$

### 2.6 Κατηγοριοποίηση συστημάτων διαχείρισης αποθεμάτων

Οι Hadley & Whitin (1963) στο βιβλίο τους “Analysis of Inventory systems” παρουσιάζουν μια σειρά συστημάτων διαχείρισης αποθεμάτων τα οποία μπορούν να διακριθούν ανάλογα με το πλήθος των διαφορετικών προϊόντων που διαχειρίζονται, το χρόνο εξέτασης των αποθεμάτων, τη φύση της ζήτησης, την δομή της εφοδιαστικής αλυσίδας της επιχείρησης και τα κόστη που λαμβάνουν υπόψη. Μία ενδεικτική κατηγοριοποίηση των συστημάτων διαχείρισης αποθεμάτων (Bijvank, 2009) φαίνεται στο Σχήμα 2.3.



Σχήμα 2.3: Ταξινόμηση συστημάτων διαχείρισης αποθεμάτων.

Όταν σε ένα σύστημα διαχείρισης αποθεμάτων ένα προϊόν μπορεί να αποθηκευτεί σε περισσότερα από ένα σημεία αποθήκευσης, τότε αυτό ονομάζεται σύστημα διαχείρισης

αποθεμάτων πολλαπλών κλιμακίων (multiechelon system). Τα περισσότερα συστήματα που συναντώνται στη βιβλιογραφία εξετάζουν ένα προϊόν κάθε φορά, ωστόσο υπάρχουν συστήματα που εξετάζουν πολλά προϊόντα ταυτόχρονα (Zipkin, 2000), λόγω περιορισμών στη διαθέσιμη χωρητικότητα της αποθήκης, οικονομίας κλίμακας ή άλλων λόγων, και η ταξινόμησή τους είναι παρόμοια με αυτή των συστημάτων ενός προϊόντος γι' αυτό και δεν περιλαμβάνονται στο Σχήμα 2.3.

Μία σημαντική διάκριση των συστημάτων οφείλεται στη φύση της ζήτησης. Εάν η μελλοντική ζήτηση μπορεί να προβλεφθεί με μεγάλη ακρίβεια, είναι λογικό να χρησιμοποιηθεί μια πολιτική που προϋποθέτει ότι όλες οι προβλέψεις θα είναι πάντα ακριβείς. Αυτό συμβαίνει στα νιτερμινιστικά μοντέλα. Ωστόσο, όταν η ζήτηση δεν μπορεί εύκολα να προβλεφθεί, καθίσταται απαραίτητο να χρησιμοποιηθεί ένα στοχαστικό μοντέλο, όπου η ζήτηση σε οποιαδήποτε χρονική περίοδο είναι μια τυχαία μεταβλητή και όχι μια γνωστή σταθερά. Τα μοντέλα στα οποία η ζήτηση είναι γνωστή (ή προβλεπόμενη) και σταθερή σε έναν ορίζοντα προγραμματισμού ονομάζονται κλασικά μοντέλα μεγέθους παρτίδας (classical lot-size models). Ένα πολύ γνωστό παράδειγμα είναι το μοντέλο Οικονομικής Ποσότητας Παραγγελίας (EOQ) που αναφέρθηκε παραπάνω. Όταν η ζήτηση δεν είναι σταθερή, αλλά εξακολουθεί να είναι προβλέψιμη, τα μοντέλα ονομάζονται δυναμικά μοντέλα μεγέθους παρτίδας (dynamic lot-size models). Παραδείγματα τεχνικών για τον προσδιορισμό του μεγέθους της παραγγελίας για τέτοια μοντέλα είναι οι αλγόριθμοι Wagner & Whitin (1958) και Silver (1973).

Στην πράξη όμως, η ζήτηση σπάνια είναι γνωστή εκ των προτέρων. Έτσι, στα στοχαστικά μοντέλα μια κατανομή πιθανότητας χρησιμοποιείται για να περιγράψει τη συμπεριφορά της ζήτησης. Μια ειδική κατηγορία συστημάτων διαχείρισης αποθεμάτων αφορά σε προϊόντα που έχουν πολύ περιορισμένο χρονικό διάστημα στο οποίο μπορούν να πωληθούν. Τέτοια προϊόντα είναι ευπαθή είδη (όπως τρόφιμα και λουλούδια) ή αντικείμενα με περιορισμένη ωφέλιμη ζωή (όπως εφημερίδες). Για τέτοια συστήματα δεν χρειάζεται να ληφθεί απόφαση σχετικά με το πότε θα πρέπει να πραγματοποιηθεί η αναπλήρωση, αλλά μόνο σχετικά με το μέγεθος της παραγγελίας μίας μόνο χρονικής περιόδου. Τέτοια μοντέλα ονομάζονται μοντέλα διαχείρισης αποθεμάτων μιας περιόδου ή μοντέλα επίλυσης του προβλήματος του εφημεριδοπώλη (newsboy problem).

Σε μοντέλα πολλών περιόδων θα πρέπει επίσης να προσδιορίζεται πότε ενεργοποιούνται οι εντολές αναπλήρωσης. Το πόσο συχνά πρέπει να ελέγχεται η κατάσταση του αποθέματος για αναπλήρωση καθορίζεται από το διάστημα ελέγχου. Αυτή είναι η περίοδος που μεσολαβεί μεταξύ δύο διαδοχικών στιγμών κατά τις οποίες είναι γνωστό το επίπεδο του αποθέματος. Δύο τύποι συστημάτων επιθεώρησης χρησιμοποιούνται ευρέως, στον πρώτο το απόθεμα παρακολουθείται συνεχώς (συνεχείς αναθεωρήσεις - continuous review) ενώ στον δεύτερο το απόθεμα ελέγχεται σε τακτά περιοδικά χρονικά διαστήματα (περιοδικές αναθεωρήσεις - periodic review). Περισσότερα για αυτούς τους τύπους συστημάτων διαχείρισης αποθεμάτων θα αναπτυχθούν στη συνέχεια του Κεφαλαίου.

## 2.7 Μη εξυπηρετούμενη ζήτηση

Είναι σημαντική η πληροφορία σχετικά με την αντίδραση του πελάτη στην περίπτωση έλλειψης αποθέματος. Η συμπεριφορά του πελάτη αυτή πρέπει να περιλαμβάνεται στο μοντέλο διαχείρισης αποθεμάτων προκειμένου να αντανακλά καλύτερα την πραγματικότητα.

Η συμπεριφορά του σε σχέση με την μη εξυπηρετούμενη ζήτηση μπορεί να κατηγοριοποιηθεί ως εξής:

- η ζήτηση καλύπτεται από μια αναδρομική παραγγελία,
- η ζήτηση αντικαθίσταται από ένα διαφορετικό προϊόν στο ίδιο σημείο,
- η ζήτηση ικανοποιείται από το ίδιο προϊόν σε διαφορετικό σημείο, ή
- η ζήτηση χάνεται.

Παρατηρείται ότι στη βιβλιογραφία μεγαλύτερη προσοχή έχουν λάβει οι πολιτικές που ενσωματώνουν αναδρομικές παραγγελίες, μιας και αποδεικνύονται βέλτιστες σε συστήματα διαχείρισης αποθεμάτων περιοδικής εξέτασης (Scarf, 1959; Federgruen & Zipkin, 1984; Federgruen & Zheng, 1992). Στην πραγματικότητα, όμως, η υπερβολική ζήτηση που δεν μπορεί να εξυπηρετηθεί, συνήθως χάνεται, ειδικά σε καταστήματα λιανικής όπου οι πελάτες μπορούν να επιλέξουν από ένα ευρύ φάσμα αντίστοιχων προϊόντων και ανταγωνιστών.

Εκτός από τις παραπάνω περιπτώσεις, συναντώνται μοντέλα στα οποία κατά το διάστημα έλλειψης αποθέματος ένα ποσοστό της ζήτησης ( $a$ ) εξυπηρετείται από μια αναδρομική παραγγελία ενώ το υπόλοιπο ποσοστό ( $1 - a$ ) χάνεται. Οι Montgomery et al. (1973) ήταν οι πρώτοι που ασχολήθηκαν με πολιτικές αποθεματοποίησης με μείγμα χαμένων πωλήσεων και αναδρομικών παραγγελιών και πρότειναν συναρτήσεις κόστους για στοχαστική και ντετερμινιστική ζήτηση, σε συνεχή και περιοδική εξέταση. Πιο πρόσφατα οι Lodree Jr (2007) και Hu et al. (2009) εξετάζουν πολιτικές αποθεματοποίησης όπου αυτό το ποσοστό επηρεάζεται γραμμικά από το πλήθος των αναδρομικών παραγγελιών σε εκκρεμότητα.

## 2.8 Πολιτική Οικονομικής Ποσότητας Παραγγελίας (Economic Order Quantity)

Το βασικό μοντέλο Οικονομικής Ποσότητας Παραγγελίας, σύμφωνα με τους Russell & Taylor (2010), χρησιμοποιείται πρωτίστως για τον προσδιορισμό της βέλτιστης ποσότητας παραγγελίας το οποίο ελαχιστοποιεί το συνολικό κόστος αποθεματοποίησης. Όπως αναφέρθηκε και παραπάνω, το μοντέλο αναπτύχθηκε από τον Harris (1913), αλλά έγινε ευρέως γνωστό από τον Wilson (1934), ο οποίος πήρε και τα εύσημα. Ωστόσο, το μοντέλο προκύπτει από ένα σύνολο απλοποιητικών και κάπως περιοριστικών παραδοχών, οι οποίες είναι οι εξής:

- Η ζήτηση είναι σταθερή και ντετερμινιστική.
- Η ποσότητα παραγγελίας δεν χρειάζεται να είναι ένας στρογγυλός αριθμός, και δεν υπάρχουν ελάχιστοι ή μέγιστοι περιορισμοί στο μέγεθός της.

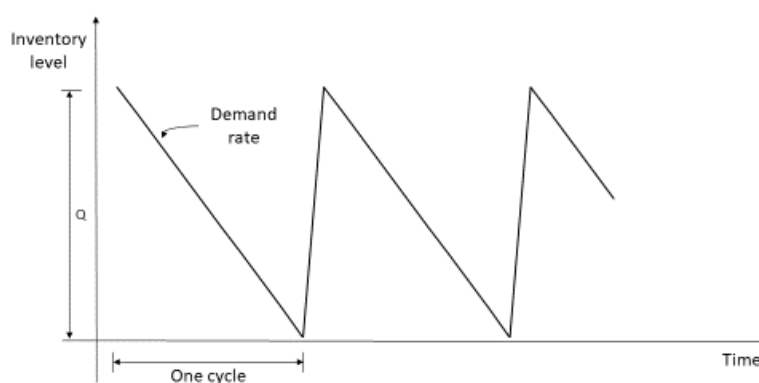
- Η τιμή αγοράς του προϊόντος δεν εξαρτάται από την ποσότητα παραγγελίας (δεν υπάρχουν εκπτώσεις)
- Τα στοιχεία κόστους δεν αλλάζουν με το χρόνο
- Το προϊόν αντιμετωπίζεται ανεξάρτητα από άλλα προϊόντα (οφέλη από κοινή διαχείριση ή αναπλήρωση δεν υπάρχουν ή απλώς αγνοούνται).
- Ο χρόνος παράδοσης είναι μηδενικός (ωστόσο επέκταση σε έναν ντετερμινιστικό, μη μηδενικό χρόνο παράδοσης δεν δημιουργεί πρόβλημα).
- Δεν επιτρέπονται ελλείψεις αποθέματος.
- Ολόκληρη η ποσότητα παραγγελίας παραδίδεται ταυτόχρονα.
- Ο ορίζοντας προγραμματισμού είναι μεγάλος.

Πάρα το γεγονός ότι κάποιες από αυτές τις παραδοχές φαίνονται εκ πρώτης όψης αρκετά περιοριστικές, έχει υπολογιστεί ότι το κόστος χρήσης την ΕΟQ αντί μίας πιο σύνθετης, βέλτιστης, ποσότητας παραγγελίας, όταν η ζήτηση είναι τυχαία, είναι λιγότερο από 1/8 (Zheng, 1992) και μπορεί να είναι μικρότερο ακόμα και από 11.8% (Axsäter, 1996).

Από τη στιγμή που το μοντέλο ΕΟQ υποθέτει σταθερή ζήτηση και σταθερό χρόνο αναπλήρωσης, το σημείο αναπαραγγελίας υπολογίζεται ως εξής:

$$R = D \cdot L,$$

όπου  $R$  το σημείο αναπαραγγελίας,  $D$  η ζήτηση και  $L$  ο χρόνος αναπλήρωσης αποθέματος (χρόνος παράδοσης παραγγελίας από τους προμηθευτές).



Σχήμα 2.4: Μοντέλο Οικονομική Ποσότητας Παραγγελίας (EOQ).

Στο συνολικό κόστος αποθεματοποίησης δεν περιλαμβάνονται τα κόστη ελλείψεων, αφού όλη η ζήτηση ικανοποιείται, και το κόστος αγοράς του προϊόντος, αφού αυτό είναι ανεξάρτητο


της ποσότητας παραγγελίας και άρα παραμένει σταθερό, χωρίς να επηρεάζει το μοντέλο. Έτσι, το ετήσιο συνολικό κόστος αποτελείται αποκλειστικά από το κόστος τοποθέτησης των παραγγελιών και το κόστος διατήρησης των αποθεμάτων, και υπολογίζεται ως εξής:

$$C_{Tot} = h\frac{Q}{2} + k\frac{D}{Q},$$

όπου  $h$  το ετήσιο κόστος διατήρησης μιας μονάδας προϊόντος,  $Q$  η ποσότητα παραγγελίας και  $k$  το κόστος τοποθέτησης μιας παραγγελίας.

Όπως φαίνεται και στο Σχήμα 2.5, το συνολικό κόστος ελαχιστοποιείται όταν το κόστος διατήρησης αποθεμάτων εξισώνεται με το κόστος τοποθέτησης των παραγγελιών. Η βέλτιστη ποσότητα παραγγελίας ( $Q^*$ ), η οποία επιτυγχάνει την παραπάνω ισότητα, υπολογίζεται ως εξής:

$$Q^* = \sqrt{\frac{2kD}{h}}$$



Σχήμα 2.5: Εντοπισμός της βέλτιστης ποσότητας παραγγελίας και του ελαχίστου συνολικού κόστους αποθεματοποίησης.

Έτσι, χρησιμοποιώντας τη βέλτιστη ποσότητα παραγγελίας ( $Q^*$ ), μπορεί να υπολογιστεί ο βέλτιστος αριθμός παραγγελιών στη διάρκεια ενός έτος ( $N^*$ ), ως εξής:

$$N^* = \frac{D}{Q^*},$$

καθώς και ο βέλτιστος χρόνος μεταξύ δύο διαδοχικών παραγγελιών ( $T^*$ ), ως εξής:

$$T^* = \frac{Q^*}{D}$$

## 2.9 Πολιτική αποθέματος ασφαλείας

Το μοντέλο ΕΟQ βασιζόταν στην υπόθεση ότι η ζήτηση είναι γνωστή και γενικά σταθερή, κάτι το οποίο συμβαίνει σπάνια στην πραγματικότητα, αφού η ζήτηση, αλλά πολλές φορές και ο χρόνος παράδοσης, μεταβάλλονται με κίνδυνο να δημιουργηθεί έλλειψη αποθέματος. Οι επιχειρήσεις, έτσι, πρέπει να διατηρούν ένα απόθεμα ασφαλείας (safety stock), όπως αναφέρθηκε και παραπάνω, η ύπαρξη του οποίου συνεπάγεται όφελος αλλά και κόστος.

Εμφανίζονται διάφοροι τύπου υπολογισμού του αποθέματος ασφαλείας (SS) που θα πρέπει να έχει μια επιχείρηση, οι οποίοι βασίζονται αφενός στην υπόθεση ότι η ζήτηση κατά τη διάρκεια του χρόνου αναπλήρωσης είναι αβέβαιη και ακολουθεί κάποια κατανομή (π.χ. κανονική ή Poisson), και αφετέρου στο επιθυμητό επίπεδο εξυπηρέτησης, όπως αυτό καθορίζεται κάθε φορά από την επιχείρηση.

Διάφοροι τύποι έχουν προταθεί για τον υπολογισμό του αποθέματος ασφαλείας (SS), χωρίς να έχει βρεθεί κάποιος με καθολική εφαρμογή, μιας και όλοι έχουν τα μειονεκτήματά τους. Ο τύπος μέσης τιμής προσφέρει έναν απλό τρόπο υπολογισμού του απαιτούμενου αποθέματος ασφαλείας, αλλά δεν λαμβάνει υπόψη τις εποχικές αλλαγές στη ζήτηση (SCMDojo, 2017). Η προσέγγιση των Heizer & Render (2013), αλλά και η μέθοδος του King (2011), αντιμετωπίζουν αυτό το ελάττωμα λαμβάνοντας υπόψη την τυπική απόκλιση. Στην πρώτη περίπτωση, ωστόσο, δεν λαμβάνεται υπόψη η επίπτωση του χρόνου (Emmanuel Ebikake, 2014). Ο Greasley (2013) πρότεινε μια κομψή μέθοδο υπολογισμού που λαμβάνει υπόψη τις διακυμάνσεις τόσο της ζήτησης όσο και του χρόνου παράδοσης, όπως και η μέθοδος McKinsey & Company (SCMDojo, 2017). Παρά την πληθώρα τύπων υπολογισμού του αποθέματος ασφαλείας, ακόμα και στην πιο πρόσφατη βιβλιογραφία (Alicke, 2005; Herrmann, 2011; Gudehus & Kotzab, 2012), είναι ελάχιστες οι μελέτες που συγκρίνουν τα αποτελέσματα των διαφόρων μεθόδων (Hunduzza, 2020).

Οι πιο γνωστοί τύπου υπολογισμού του αποθέματος ασφαλείας παρουσιάζονται παρακάτω.

- **Απλός τύπος**

$$SS = average(sales) \cdot safety\ days$$

- **Τύπος μέσης τιμής**


$$SS = (max(sales) \cdot max(L)) - (average(sales) \cdot average(L))$$

- **Μέθοδος του King (2011)**

$$SS = Z \sqrt{\frac{PC}{T_1}} \sigma_d,$$

όπου  $Z$  ο αριθμός τυπικών αποκλίσεων από τον μέσο όρο ( $Z$ -score),  $PC$  ο κύκλος απόδοσης ή συνολικός χρόνος παράδοσης,  $T_1$  μια χρονική προσαύξηση που χρησιμοποιείται για τον υπολογισμό της τυπικής απόκλισης της ζήτησης και  $\sigma_d$  η τυπική απόκλιση της ζήτησης





Σχήμα 2.6: Πολιτικές χωρίς (επάνω) και με (κάτω) απόθεμα ασφαλείας.

- **Μέθοδος των Heizer & Render (2013)**

$$SS = Z\sigma_{dL},$$

όπου  $\sigma_{dL}$  η τυπική απόκλιση της ζήτησης κατά τη διάρκεια του χρόνου παράδοσης.

- **Μέθοδος του Greasley (2013)**

$$SS = Z\sqrt{L}\sigma_d,$$

για συστήματα συνεχούς ελέγχου και

$$SS = Z\sqrt{L + R}\sigma_d,$$

για συστήματα περιοδικού ελέγχου.

Σημαντικό να αναφερθεί πως η τυπική απόκλιση της ζήτησης υπολογίζεται από τον τύπο :

$$\sigma_d = \sqrt{\frac{\sum_{i=1}^n (d_i - \bar{d})^2}{n}},$$

όπου  $d_i$  η ζήτηση για μια χρονική περίοδο  $i$ ,  $\bar{d}$  η μέση ζήτηση και  $n$  ο αριθμός των χρονικών περιόδων που συνεκτιμώνται, περισσότερα για την οποία θα αναφερθούν στο επόμενο Κεφάλαιο, και ο αριθμός τυπικών αποκλίσεων ( $Z$ ) υπολογίζεται χρησιμοποιώντας την αντίστροφη αθροιστική συνάρτηση της κανονικής κατανομής για επιλεγμένο επίπεδο εξυπηρέτησης ( $SL$ ), δηλαδή :

$$Z = \Phi^{-1}(SL).$$

Με αυτόν τον τρόπο, φαίνεται ξεκάθαρα ότι μέσω του  $Z$ , και πιο συγκεκριμένα του  $SL$ , η κάθε επιχείρηση μπορεί να χρειάζεται μεγαλύτερο ή μικρότερο απόθεμα ασφαλείας βάσει του στόχου στο επίπεδο εξυπηρέτησης που έχει θέσει και των χαρακτηριστικών της ζήτησης.

## 2.10 Πολιτικές αποθεματοποίησης πολλαπλών περιόδων

Ένα σύστημα διαχείρισης αποθεμάτων ελέγχει το επίπεδο των αποθεμάτων προσδιορίζοντας κάθε φορά την ποσότητα της νέας παραγγελίας και το χρόνο αυτής. Τα συστήματα, έτσι, μπορούν να κατηγοριοποιηθούν με διαφορετικούς τρόπους. Οι πιο σημαντικοί εξ αυτών είναι α) βάσει τους τύπου της ποσότητας παραγγελίας, η οποία μπορεί να είναι σταθερή ή μεταβλητή, και β) βάσει του τρόπου ελέγχου του αποθέματος, ο οποίος μπορεί να είναι συνεχής ή περιοδικός. Με αυτό τον τρόπο δημιουργούνται οι τέσσερις πιο γνωστές πολιτικές αποθεματοποίησης (Bijvank, 2009) που αναγράφονται παρακάτω και παρουσιάζονται στον Πίνακα 2.1:

- Σταθερής ποσότητας παραγγελίας συνεχούς ελέγχου ( $s, Q$ )
- Σταθερής ποσότητας παραγγελίας περιοδικού ελέγχου ( $R, s, Q$ )
- Μεταβλητής ποσότητας παραγγελίας συνεχούς ελέγχου ( $s, S$ )
- Μεταβλητής ποσότητας παραγγελίας περιοδικού ελέγχου ( $R, s, S$ )

Όπως αναφέρθηκε και παραπάνω,  $R$  (review period) είναι ο χρόνος μεταξύ δύο διαδοχικών παραγγελιών,  $s$  (reorder point) είναι το σημείο αναπαραγγελίας,  $Q$  (order quantity) είναι η ποσότητα παραγγελίας και  $S$  (order-up-to-level) είναι το επίπεδο στόχος του αποθέματος.

Όσον αφορά στην σύγκριση μεταξύ των δύο κατηγοριών, συνεχούς και περιοδικής εξέτασης, κάθε μία έχει ορισμένα πλεονεκτήματα αλλά και μειονεκτήματα. Όταν τα προϊόντα κατασκευάζονται από το ίδιο μηχάνημα ή αγοράζονται από τον ίδιο προμηθευτή, ο συντονισμός στην διαδικασία της αναπλήρωσης και κατά συνέπεια ο περιοδικός έλεγχος είναι πιο ελκυστικός. Με τον περιοδικό έλεγχο, επίσης, προβλέπεται πιο εύκολα το επίπεδο του φόρτου εργασίας του εμπλεκόμενου προσωπικού, ενώ αντίθετα, με το συνεχή έλεγχο, μια απόφαση αναπλήρωσης μπορεί να ληφθεί οποιαδήποτε στιγμή, με αποτέλεσμα ο

φόρτος εργασίας να είναι λιγότερο προβλέψιμος. Ένα άλλο μειονέκτημα του συνεχούς ελέγχου είναι τα κόστη που συνεπάγεται, ιδιαίτερα σε ταχυκίνητα προϊόντα τα οποία απαιτούν πολλές παραγγελίες και ελέγχους σε μικρά χρονικά διαστήματα. Το μεγαλύτερο πλεονέκτημα, ωστόσο, του συνεχούς ελέγχου είναι ότι μπορεί να παρέχει σταθερό ποσοστό εξυπηρέτησης, ενώ απαιτεί μικρότερο απόθεμα ασφαλείας, και κατά συνέπεια μικρότερο κόστος διατήρησης αποθεμάτων, από τον περιοδικό έλεγχο.

Πίνακας 2.1: Η σημειογραφία των τύπων πολιτικών διαχείρισης αποθεμάτων που συναντώνται συχνότερα στη βιβλιογραφία.


		Συχνότητα παραγγελίας	
		Συνεχής έλεγχος	Περιοδικός έλεγχος
Ποσότητα παραγγελίας	Σταθερή	$(s, Q)$	$(R, s, Q)$
	Μεταβλητή	$(s, S)$	$(R, s, S)$

### 2.10.1 Πολιτικές συνεχούς εξέτασης (Continuous review models)

Κλασσική αναφορά στα συστήματα αποθεματοποίησης συνεχούς εξέτασης αποτελεί το βιβλίο των Hadley & Whitin (1963), στα οποία το επίπεδο του αποθέματος εξετάζεται διαρκώς.

#### 2.10.1.1 Πολιτική $(s, Q)$

Η πολιτική αποθεματοποίησης  $(s, Q)$  είναι πολιτική συνεχούς εξέτασης του αποθέματος, κατά την οποία όταν το επίπεδο αποθέματος φτάνει το σημείο αναπαραγγελίας ( $s$ ), ή πέφτει κάτω από αυτό, τοποθετείται μία παραγγελία σταθερής ποσότητας ( $Q$ ). Η ποσότητα αυτή προστίθεται στο απόθεμα μετά από ένα διάστημα ίσο με το χρόνο παράδοσης της παραγγελίας από τον προμηθευτή ( $L$ ), όπως φαίνεται στο Σχήμα 2.7.




Σχήμα 2.7: Πολιτική συνεχούς εξέτασης σταθερής ποσότητας παραγγελίας  $(s, Q)$ .

Η συγκεκριμένη πολιτική είναι αρκετά απλή, εύκολα κατανοητή και διαχειρίσιμη από τους υπαλλήλους της αποθήκης και τους προμηθευτές, με αποτέλεσμα να μην εμφανίζονται

συχνά λάθη στην αποθήκη αλλά και στην παραγωγική διαδικασία. Βασικό μειονέκτημά της είναι ότι αυτή η σταθερότητα της ποσότητας παραγγελίας μπορεί να μην είναι ικανή να αντιμετωπίσει αποτελεσματικά κάποια ξαφνική μεγάλη παραγγελία, και σε ορισμένες περιπτώσεις είναι πιθανό μία παραγγελία μεγέθους  $Q$  να μην ανεβάσει το απόθεμα πάνω από το σημείο αναπαραγγελίας ( $S$ ).

### 2.10.1.2 Πολιτική ( $s, S$ )

Η πολιτική αποθεματοποίησης ( $s, S$ ) είναι πολιτική συνεχούς εξέτασης του αποθέματος, κατά την οποία, όπως και στην ( $s, Q$ ), όταν το επίπεδο αποθέματος φτάνει το σημείο αναπαραγγελίας ( $s$ ), ή πέφτει κάτω από αυτό, τοποθετείται μία παραγγελία τέτοια ώστε να ανεβάσει το απόθεμα στο επίπεδο στόχου ( $S$ ). Στην περίπτωση όπου η παραγγελία πραγματοποιείται όταν το απόθεμα βρίσκεται ακριβώς στο επίπεδο ( $s$ ), η ποσότητα παραγγελίας είναι  $Q = S - s$ , αλλιώς είναι  $Q = S - I$ , όπου  $I$  το επίπεδο του αποθέματος την στιγμή της παραγγελίας. Η πολιτική αυτή συχνά αναφέρεται ως min-max σύστημα, καθώς όταν ο χρόνος παράδοσης ( $L$ ) είναι μηδενικός, το απόθεμα, εκτός από πιθανές στιγμιαίες περιπτώσεις όπου μπορεί να βρεθεί κάτω από το επίπεδο αναπαραγγελίας, βρίσκεται συνέχεια ανάμεσα στην ελάχιστη τιμή του επιπέδου αναπαραγγελίας ( $s$ ) και τη μέγιστη τιμή του επιπέδου στόχου ( $S$ ). Η πολιτική ( $s, S$ ) με  $L > 0$  απεικονίζεται στο Σχήμα 2.8.



Σχήμα 2.8: Πολιτική συνεχούς εξέτασης μεταβλητής ποσότητας παραγγελίας ( $s, S$ ).

Μία βέλτιστη πολιτική ( $s, S$ ) αποδεικνύεται ότι μπορεί να έχει μικρότερο συνολικό κόστος αποθεματοποίησης από την βέλτιστη ( $s, Q$ ), ωστόσο το υπολογιστικό κόστος που απαιτείται προκειμένου να υπολογιστεί το βέλτιστο ζεύγος ( $s, S$ ) είναι σημαντικά μεγαλύτερο. Η πολιτική αυτή συναντάται συχνά στην πράξη, αλλά οι τιμές επιπέδου αναπαραγγελίας και επιπέδου αποθέματος στόχου επιλέγονται τις περισσότερες φορές αρκετά αυθαίρετα.

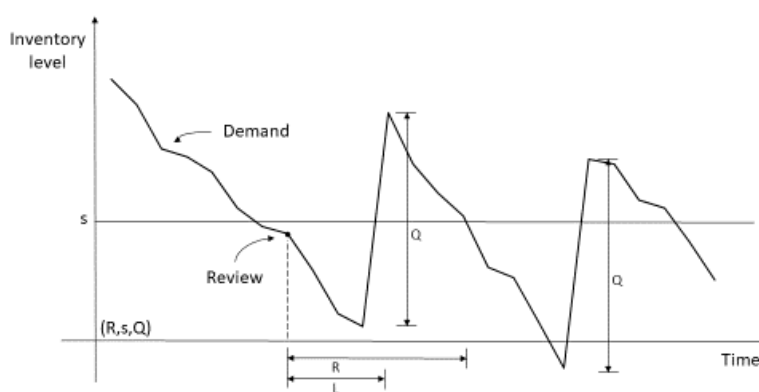
### 2.10.2 Πολιτικές περιοδικής εξέτασης (Periodic review models)

Μία από τις πρώτες μελέτες σχετικά με τα συστήματα διαχείρισης αποθεμάτων περιοδικής εξέτασης πραγματοποιήθηκε από τους Bellman et al. (1955), οι οποίοι εξέτασαν

την περίπτωση χαμένων πωλήσεων με μη μηδενικούς χρόνους παράδοσης και ελαχιστοποίησαν τα κόστη τοποθέτησης παραγγελίας και έλλειψης αποθέματος υπό τον περιορισμό ότι ο χρόνος μεταξύ δύο παραγγελιών είναι ίσος με το χρόνο παράδοσης ( $R = L$ ).

### 2.10.2.1 Πολιτική $(R, s, Q)$

Η πολιτική αποθεματοποίησης  $(R, s, Q)$  είναι πολιτική περιοδικής εξέτασης, συναντάται συχνά στην πράξη, κατά την οποία κάθε  $R$  μονάδες χρόνου, και σε περίπτωση που το απόθεμα είναι ίσο ή μικρότερο από το επίπεδο αναπαραγγελίας ( $s$ ), τοποθετείται μία παραγγελία σταθερής ποσότητας  $Q$ , όπως φαίνεται και στο Σχήμα 2.9.

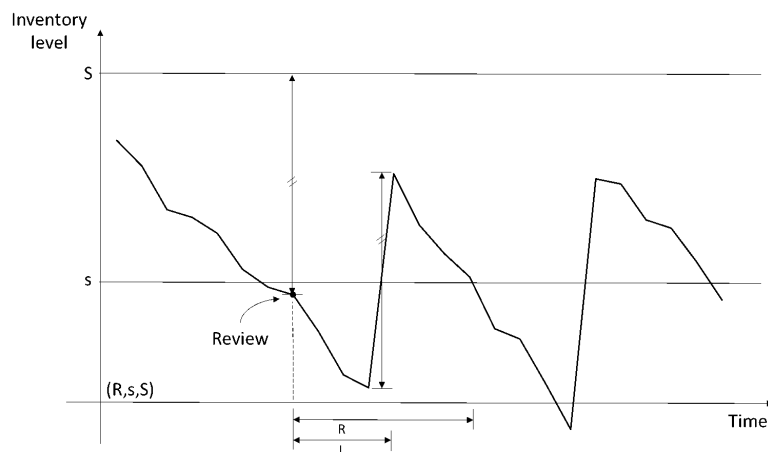


Σχήμα 2.9: Πολιτική περιοδικής εξέτασης σταθερής ποσότητας παραγγελίας  $(R, s, Q)$ .

### 2.10.2.2 Πολιτική $(R, s, S)$

Η πολιτική αποθεματοποίησης  $(R, s, S)$  είναι πολιτική περιοδικής εξέτασης, κατά την οποία κάθε  $R$  μονάδες χρόνου, και σε περίπτωση που το απόθεμα είναι ίσο ή μικρότερο από το επίπεδο αναπαραγγελίας ( $s$ ), τοποθετείται μία παραγγελία ποσότητας  $Q$  τέτοια ώστε να ανεβάσει το απόθεμα στο επίπεδο στόχο ( $S$ ), όπως φαίνεται και στο Σχήμα 2.10.

Έχει αποδειχθεί (Scarf, 1959), κάτω από αρκετά γενικές παραδοχές σχετικά με το μοτίβο της ζήτησης και τους σχετικούς παράγοντες κόστους, ότι η βέλτιστη  $(R, s, S)$  πολιτική παρέχει μικρότερα κόστη παραγγελίας, διατήρησης και έλλειψης σε σχέση με κάθε άλλη πολιτική, απαιτώντας όμως ταυτόχρονα το μεγαλύτερο υπολογιστικό κόστος προκειμένου να βρεθούν οι βέλτιστες παράμετροι της πολιτικής αυτής. Ωστόσο, πιο πρόσφατες μελέτες υποστηρίζουν ότι, σε ένα σύστημα με χαμένες πωλήσεις, η συγκεκριμένη πολιτική δεν είναι η βέλτιστη, ωστόσο το συνολικό κόστος αποθεματοποίησης αυξάνεται κατά μέσο όρο μόλις 1.1% (Bijvank & Vis, 2011). Σε κάθε περίπτωση, η συγκεκριμένη πολιτική αποτελεί μία εκ των πιο διαδεδομένων πολιτικών αποθεματοποίησης, και χρησιμοποιείται ευρέως στις επιχειρήσεις (Babai et al., 2010), παρουσιάζοντας εντυπωσιακά αποτελέσματα (Silver et al., 1998; Syntetos & Boylan, 2006a).



Σχήμα 2.10: Πολιτική περιοδικής εξέτασης μεταβλητής ποσότητας παραγγελίας  $(R, s, S)$ .

Όπως μπορεί εύκολα να φανταστεί κανείς, η πολιτική  $(R, s, S)$  αποτελεί μία αρκετά γενικευμένη πολιτική, καθώς για ακραίες τιμές των παραμέτρων της  $R$  και  $s$  μετασχηματίζεται σε πιο απλές πολιτικές. Πιο συγκεκριμένα, όταν η παράμετρος  $R$  λαμβάνει την τιμή 1, δηλαδή το απόθεμα ελέγχεται καθημερινά, και κατά συνέπεια η πολιτική πλέον είναι συνεχούς εξέτασης, η πολιτική  $(R, s, S)$  μετασχηματίζεται στην πολιτική  $(s, S)$ . Αντίστοιχα, όταν η παράμετρος  $s$  λαμβάνει τιμή ίση με την τιμή της παραμέτρου  $S$ , δηλαδή το επίπεδο αναπαραγγελίας ταυτίζεται με το επίπεδο αποθέματος στόχο, και κατά συνέπεια το πραγματικό επίπεδο αποθέματος δεν βρίσκεται ποτέ πάνω από το επίπεδο αναπαραγγελίας, η πολιτική  $(R, s, S)$  μετασχηματίζεται στην πολιτική  $(R, S)$ , όπου πραγματοποιείται μία παραγγελία κάθε  $R$  περιόδους.


## 2.11 Κριτήρια απόδοσης πολιτικών

Όταν η ζήτηση είναι ασυνήθιστα μεγάλη, μπορεί να προκύψει έλλειψη αποθέματος ή να απαιτηθούν επείγουσες ενέργειες προκειμένου αυτή η έλλειψη να αποφευχθεί. Από την άλλη πλευρά, εάν η ζήτηση είναι χαμηλότερη από την αναμενόμενη ή η αναπλήρωση φτάνει νωρίτερα από ότι χρειάζεται, δημιουργείται επιπλέον απόθεμα το οποίο δημιουργεί ένα κόστος διατήρησης. Οι υπεύθυνοι λήψης αποφάσεων έχουν διαφορετικές οπτικές για το πώς πρέπει να εξισορροπήσουν αυτούς τους δύο κινδύνους και αρκετές φορές μπορεί να θεωρούν πιο σημαντική μία από αυτές τις περιπτώσεις.

Με τον τρόπο αυτό, ένα σημαντικό στοιχείο κάθε συστήματος διαχείρισης αποθεμάτων είναι το κριτήριο απόδοσης, το κριτήριο που επιθυμεί η επιχείρηση να ελαχιστοποιήσει ή να μεγιστοποιήσει κάθε φορά. Μπορεί, έτσι, ένα σύστημα να στοχεύει στην ελαχιστοποίηση του συνολικού κόστους αποθεματοποίησης (cost-based) ή στη μεγιστοποίηση, ή στη σύγκλιση σε ένα προκαθορισμένο επίπεδο, του ποσοστού εξυπηρέτησης (service-based) (Goltsos et al., 2022). Λιγότερο δημοφιλείς εναλλακτικές περιλαμβάνουν τη μεγιστοποίηση του ποσοστού κάλυψης της ζήτησης (Heath & Jackson, 1994) και την μεγιστοποίηση κάποιας συνάρτησης κέρδους (Johnston et al., 2011). Να σημειωθεί εδώ ότι το ποσοστό κάλυψης της ζήτησης απεικονίζει το κλάσμα της ζήτησης που ικανοποιείται από το διαθέσιμο απόθεμα σε ένα

διάστημα, ενώ το επίπεδο εξυπηρέτησης είναι η πιθανότητα μη εξάντλησης του αποθέματος, και υπολογίζεται ως το μέσο κλάσμα της ζήτησης που ικανοποιείται σε κάθε μονάδα χρόνου μιας χρονικής περιόδου.

Στις περιπτώσεις της σύγκρισης της απόδοσης δύο ή περισσότερων συστημάτων διαχείρισης αποθεμάτων, ή του ίδιου συστήματος αλλά με διαφορετικές παραμέτρους, πέρα από τα κριτήρια απόδοσης που αναφέρθηκαν παραπάνω συναντώνται και άλλες πρακτικές. Ο Gardner (1990, 2006) συνιστά τη χρήση “καμπυλών ανταλλαγής” (tradeoff curves) για το σκοπό αυτό, ενώ άλλες προτάσεις για την αξιολόγηση της απόδοσης είναι η χρήση “δεικτών μέτρησης λύπης” (regret metrics) (Sani & Kingsman, 1997) ή ο υπολογισμός των ενδεχόμενων αποθεμάτων που θα προέκυπταν χρησιμοποιώντας ένα συγκεκριμένο περιθώριο ασφαλείας παρέχοντας κατά μέγιστο μηδέν ημέρες μηδενικού αποθέματος (Eaves & Kingsman, 2004). Μια εναλλακτική διατύπωση περιλαμβάνει τον καθορισμό ενός επιπέδου εξυπηρέτησης πελατών στόχου και την αναζήτηση της επένδυσης (κόστος) που απαιτείται για την επίτευξη του στόχου αυτού. Σύμφωνα με τους Syntetos et al. (2015), οι tradeoff curves είναι ίσως η πιο ρεαλιστική αναπαράσταση της συγκριτικής απόδοσης των διαφόρων προσεγγίσεων και η πιο σημαντική από την πλευρά των υπευθύνων λήψης αποφάσεων.



Σχήμα 2.11: Παράδειγμα tradeoff curves τριών εναλλακτικών στρατηγικών για επίπεδα εξυπηρέτησης πελατών στόχους από 90% έως 99%.

Ένα παράδειγμα σύγκρισης συστημάτων διαχείρισης αποθεμάτων με χρήση tradeoff curves απεικονίζεται στο Σχήμα 2.11. Φαίνεται η σχέση επένδυσης -ως προς το απόθεμα- με εξυπηρέτηση πελατών, για πέντε τιμές επιπέδου εξυπηρέτησης στόχο και τρεις πολιτικές up-to-level στις οποίες διαφοροποιείται μόνο η συχνότητα τοποθέτησης παραγγελιών (κάθε 3, 5 ή 7 ημέρες). Σε απεικονίσεις αυτού του είδους, το πιο επιθυμητό σύστημα είναι εκείνο το οποίο βρίσκεται όσο το δυνατόν πιο δεξιά και κάτω στο σχήμα, επιφέροντας τη μεγαλύτερη εξυπηρέτηση πελατών με τη μικρότερη επένδυση.

Δυστυχώς, δεν υπάρχουν εύκολοι κανόνες για την επιλογή της κατάλληλης προσέγγισης, αλλά η επιλογή εξαρτάται από το ανταγωνιστικό περιβάλλον στο οποίο δραστηριοποιείται η

κάθε επιχείρηση και τα χαρακτηριστικά της.

## 2.12 Βελτιστοποίηση της επιλεγμένης πολιτικής

Αφού έχει επιλεγεί μία πολιτική αποθεματοποίησης, ή και περισσότερες από μία, και το κριτήριο απόδοσης, δηλαδή είναι διαθέσιμο ένα σύστημα εξισώσεων το οποίο μοντελοποιεί το πρόβλημα, απομένει να υπολογιστούν οι μεταβλητές εκείνες οι οποίες οδηγούν στη βέλτιστη λύση. Με άλλα λόγια, απομένει να υπολογιστούν οι τιμές που προκύπτουν από την επιλεγμένη πολιτική, όπως οι  $R$ ,  $S$ ,  $Q$  ή  $s$ , οι οποίες οδηγούν είτε στο ελάχιστο συνολικό κόστος αποθεματοποίησης ή στο μέγιστο ποσοστό εξυπηρέτησης.

Το παραπάνω πρόβλημα, επομένως, ανάγεται σε πρόβλημα της θεωρίας βέλτιστου ελέγχου (optimal control theory), η οποία αποτελεί κλάδο της μαθηματικής βελτιστοποίησης και ασχολείται με την εύρεση ενός σημείου σε ένα δυναμικό σύστημα εξισώσεων τέτοιο ώστε μια προκαθορισμένη συνάρτηση να βελτιστοποιείται (Ross, 2015). Μία από τις πιο διαδεδομένες τεχνικές αντιμετώπισης ενός τέτοιου προβλήματος είναι κάνοντας χρήση της εξίσωσης των Hamilton–Jacobi–Bellman (Naidu, 2002; Wen & Yin, 2019).

Κατά το παρελθόν, οι αλγόριθμοι υπολογισμού της καλύτερης πολιτικής χρησιμοποιούνταν σπάνια καθώς θεωρούνταν απαγορευτικά χρονοβόροι καθώς απαιτούσαν αρκετή υπολογιστική δύναμη. Οι Federgruen & Zipkin (1984) προσπάθησαν να εξαλείψουν αυτόν τον μύθο προτείνοντας μια μέθοδο, που ήταν παρόμοια με αυτές των Johnson (1968) και Küenle & Küenle (1977), η οποία βασίζεται σε μια προσαρμογή της γενικής μεθόδου επίλυσης προβλημάτων αποφάσεων Markov. Η ανάγκη για αλγόριθμους αυτής της μορφής προέκυψε από τη γενική αντίληψη ότι η συνάρτηση κόστους, γενικά, δεν συμπεριφέρεται ομαλά, συμπεραίνοντας ότι σχεδόν όλοι οι πιθανοί συνδυασμοί πρέπει να αξιολογηθούν. Πράγματι, η συνάρτηση κόστους δεν είναι τέλεια κυρτή και μπορεί να εμφανίζει αρκετά τοπικά βέλτιστα. Οι μέθοδοι των Bell (1970) και Archibald & Silver (1978) εφαρμόζουν αυτήν ακριβώς τη λογική, αξιολογώντας όλους τους πιθανούς συνδυασμούς.


Σε αντίθεση με τις παραπάνω προσεγγίσεις, οι Zheng & Federgruen (1991) πρότειναν έναν αλγόριθμο ο οποίος παρέχει μία πιο αποτελεσματική αναζήτηση στο χώρο των  $(s, S)$ . Ο αλγόριθμος αυτός αποτελεί έναν γρήγορο τρόπο υπολογισμού των βέλτιστων τιμών για τις παραμέτρους  $s$  και  $S$  για μία δεδομένη τιμή  $R$ , υποθέτοντας μια διακριτή κατανομή της ζήτησης. Ωστόσο, όταν πρέπει να βελτιστοποιηθεί και η τιμή της παραμέτρου  $R$ , ή και άλλων, το πρόβλημα γίνεται ακόμα πιο πολύπλοκο (Lagodimos et al., 2012). Στην κατεύθυνση αυτή, οι Visentin et al. (2021) πρότειναν έναν αλγόριθμο για τον υπολογισμό των βέλτιστων παραμέτρων της πολιτικής  $(R, s, S)$ , ο οποίος αποτελεί ένα υβρίδιο δέντρων αναζήτησης και δυναμικού προγραμματισμού, το οποίο ενισχύεται από προεπιλεγμένα όρια τιμών. Παρά το γεγονός ότι ο συγκεκριμένος αλγόριθμος εμφάνισε ενθαρρυντικά αποτελέσματα στην εύρεση των βέλτιστων ή σχεδόν βέλτιστων τιμών της πολιτικής  $(R, s, S)$ , το υπολογιστικό κόστος που απαιτεί, παραμένει αξιόλογο.

Έτσι, δεδομένου ότι οι παραδοσιακές βελτιστοποιήσεις ελέγχου αποθέματος που αναφέρθηκαν μπορούν να γίνουν ιδιαίτερα κοστοβόρες υπολογιστικά, το υπολογιστικό



κόστος που συνεπάγεται μια τέτοια προσέγγιση δεν πρέπει να παραβλέπεται, ειδικά όταν αυτή εκτελείται για χιλιάδες ή εκατομμύρια διαφορετικά προϊόντα σε τακτική βάση (Seaman, 2018).

Στο Σχήμα 2.12 φαίνεται χαρακτηριστικά ο χώρος που δημιουργείται κατά τον υπολογισμό του συνολικού κόστους αποθεματοποίησης ενός προϊόντος, κάνοντας χρήση της πολιτικής  $(R, s, S)$  και διατηρώντας σταθερές όλες τις παραμέτρους εκτός από τα  $R$  και  $L$ . Φαίνεται ότι όσο μεταβάλλεται μία εκ των παραμέτρων αυτών, το κόστος μεταβάλλεται μη γραμμικά. Με τον ίδιο τρόπο, αλλάζοντας οποιαδήποτε άλλη παράμετρο, πέρα από αυτές που εμφανίζονται στο Σχήμα 2.12, το συνολικό κόστος αποθεματοποίησης μεταβάλλεται με διαφορετικό τρόπο. Γίνεται έτσι πιο ξεκάθαρη η πολυπλοκότητα που εμπεριέχεται στην επίλυση ενός τέτοιου συστήματος.



Σχήμα 2.12: Τρισδιάστατος χώρος συνολικού κόστους αποθέματος όταν μεταβάλλονται τα  $R$  και  $L$ . (Πηγή: Theodorou et al. (2021a))

Πέρα από αυτές τις ακριβείς μεθόδους που συζητήθηκαν παραπάνω, λόγω της πολυπλοκότητας που τις διακατέχει, στη βιβλιογραφία εντοπίζεται και μια σειρά από ευριστικές (heuristic) μεθόδους, όπως αυτές των Schneider (1978), Tijms & Groenevelt (1984) και Sahin & Sinha (1987). Οι ευριστικές μέθοδοι συνήθως χρησιμοποιούν μία πιο πρακτική προσέγγιση, που δεν είναι εγγυημένα βέλτιστη, αλλά είναι επαρκής, μιας και συνήθως πηγάζει από προηγούμενες εμπειρίες με παρόμοια προβλήματα, για να προσεγγίσει τη βέλτιστη κατάσταση.

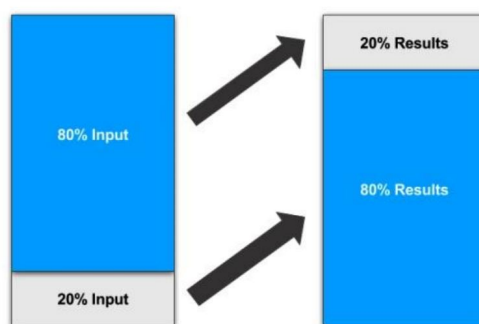
Μία εξίσου σημαντική προσέγγιση αποτελεί ο σχεδιασμός και η χρήση προσομοιώσεων της διαδικασίας αποθεματοποίησης, όπου μέσω της επαναλαμβανόμενης εφαρμογής τους δύναται να εντοπιστούν οι τιμές των παραμέτρων της πολιτικής αποθεματοποίησης οι οποίες οδηγούν στη βέλτιστη κατάσταση. Η παρούσα διατριβή εστιάζει στη συγκεκριμένη προσέγγιση, η οποία παρουσιάζεται αναλυτικά στο Υποκεφάλαιο 5.5.

## 2.13 Ταξινόμηση βάσει κριτηρίων αξίας (A-B-C)

Σήμερα οι περισσότερες αποθήκες εμπεριέχουν αποθέματα με μεγάλο αριθμό διαφορετικών προϊόντων, κάποια από τα οποία είναι πιο σημαντικά και άλλα λιγότερο σημαντικά για την επιχείρηση. Ορισμένα προϊόντα χρησιμοποιούνται περισσότερο από

κάποια άλλα, οπότε μία ενδεχόμενη έλλειψη αυτών θα απογοητεύσει τους πελάτες σε μεγαλύτερο βαθμό, ενώ άλλα μπορεί να είναι μεγαλύτερης αξίας, συνεπώς υψηλά επίπεδα αποθέματος επιβαρύνουν την επιχείρηση (Slack et al., 2010). Η ύπαρξη αυτή πολλών διαφορετικών προϊόντων καθιστά τον προγραμματισμό της επιχείρησης δύσκολο, οδηγώντας τες έτσι στην ανάγκη κατηγοριοποίησης και ταξινόμησης των προϊόντων, προκειμένου να μπορούν να ελέγχουν αποτελεσματικά κάθε κατηγορία, ανάλογα πάντα και με το βαθμό σπουδαιότητάς του.

Μια από τις πιο γνωστές τεχνικές ταξινόμησης αποθεμάτων και προϊόντων είναι η ανάλυση ABC (Dickie, 1951), η οποία βασίζεται στην αρχή Pareto, που απεικονίζεται στο Σχήμα 2.13, σύμφωνα με την οποία, για πολλά γεγονότα, το 80% των αποτελεσμάτων προκύπτει από το 20% των αιτιών (Sanders, 1987).



Σχήμα 2.13: Η αρχή Pareto. (Πηγή: Στειακάκης & Κωφίδης (2017))

Αντίστοιχα, στην περίπτωση μιας επιχείρησης, αυτό μπορεί να σημαίνει ότι το 20% όλων των τύπων προϊόντων σε απόθεμα συντελεί στο 80% των πωλήσεων της (Dhoka & Choudary, 2013). Με άλλα λόγια, ένα μικρό μέρος των προϊόντων σε απόθεμα συμβάλει περισσότερο στη μεγιστοποίηση των πωλήσεων και των εσόδων κάθε επιχείρησης (Millstein et al., 2014).

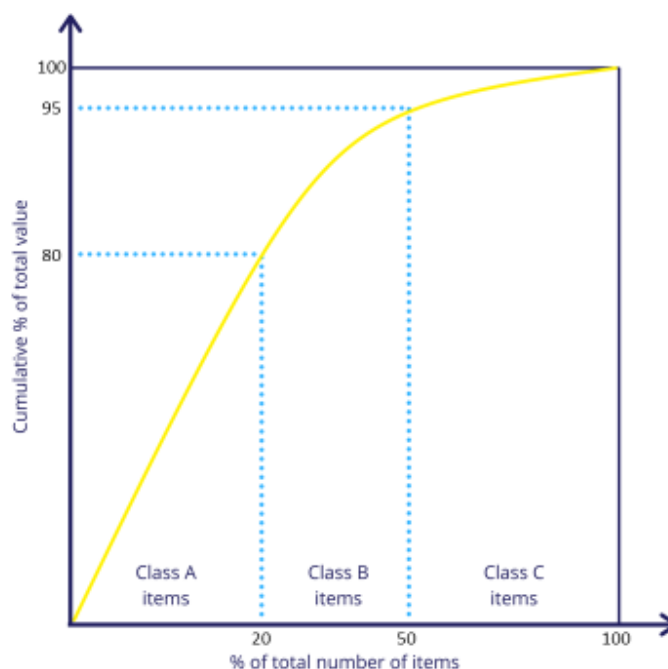
Η ανάλυση ABC, που απεικονίζεται στο Σχήμα 2.14, στην ουσία προσδιορίζει ποια προϊόντα πρέπει να πάρουν προτεραιότητα στη διαχείριση των αποθεμάτων της επιχείρησης, ομαδοποιώντας τα σε τρεις κατηγορίες:

- A: μεγάλης σημασίας
- B: μεσαίας σημασίας
- C: μικρής σημασίας

Στην πρώτη κατηγορία ανήκει ένα μικρό ποσοστό του συνόλου των αποθεμάτων (20%) που είναι όμως εξαιρετικά σημαντικά για την επιχείρηση λόγω της μεγάλης ζήτησης και του υψηλού κόστους τους. Η δεύτερη κατηγορία περιλαμβάνει προϊόντα μικρότερης σημασίας που αντιστοιχούν περίπου στο 30% του συνόλου των αποθεμάτων και στο 15% των πωλήσεων της επιχείρησης. Τέλος, η τρίτη κατηγορία περιλαμβάνει τα περισσότερα προϊόντα, που όμως έχουν τον ελάχιστο αντίκτυπο στις πωλήσεις της επιχείρησης (5% περίπου), λόγω χαμηλής ζήτησης ή χαμηλής αξίας (Torabi et al., 2012).

Σύμφωνα με τους Ravinder & Misra (2014), οι επιχειρήσεις πρέπει να εστιάζουν πρωτίστως στη διαχείριση των προϊόντων της A κατηγορίας. Αντίστοιχα, τα προϊόντα της

κατηγορίας C πρέπει να λαμβάνουν τη λιγότερη προσοχή, ενώ αυτά της κατηγορίας B να βρίσκονται ενδιάμεσα. Έτσι, τα αποθέματα των προϊόντων της A κατηγορίας πρέπει να ελέγχονται συχνά και η ζήτησή τους να προβλέπεται συχνά, ενώ κινούμενοι προς τις άλλες κατηγορίες η σημασία του συχνού ελέγχου φθίνει (Plinere et al., 2015).



Σχήμα 2.14: Διάγραμμα ABC με ποσοστό συνολικής αξίας εμπορευμάτων σε σχέση με τα συνολικά αποθέματα και καμπύλη Pareto.

Ορισμένα κέντρα διανομής μεγάλου όγκου προϊόντων σχεδιάζουν την κατανομή των προϊόντων μέσα στον αποθηκευτικό χώρο βάσει του ποσοστού χρήσης τους και τον όγκο που καταλαμβάνουν ανά μονάδα. Παρομοίως, προκειμένου να προσδιοριστούν τα πιο σημαντικά προϊόντα χρησιμοποιείται ορισμένες φορές η ταξινόμηση βάσει του γινομένου κέρδος×όγκος, τα προϊόντα τα οποία ανήκουν στο κάτω μέρος της καμπύλης συχνά διακόπτονται. Στη βιβλιογραφία συναντώνται και πιο σύνθετοι τρόποι ταξινόμησης οι οποίοι περιλαμβάνουν πλήθος συναλλαγών (Krupp, 1994) ή την κρισιμότητα της παραμονής των προϊόντων σε απόθεμα (Reynolds, 1994). Σε κάθε περίπτωση, λόγω της διαφορετικής οπτικής αλλά και των διαφορετικών στόχων που μπορεί να έχουν διαφορετικές επιχειρήσεις, προμηθευτές και μεταφορείς, ένα προϊόν μπορεί να ανήκει στην κατηγορία A για μία μέθοδο ταξινόμησης ή μία επιχείρηση και στην κατηγορία C για μία άλλη.

“Η στατιστική είναι τα γραμμάτια της επιστήμης.”  
– *Karl Pearson*

## Κεφάλαιο 3

# Ανάλυση και κατηγοριοποίηση χρονοσειρών

---

Χρονοσειρά ή χρονολογική σειρά ονομάζεται ένα σύνολο διαδοχικών παρατηρήσεων της τιμής ενός μεγέθους, όπου αυτή ακριβώς η διατεταγμένη τοποθέτηση των παρατηρήσεων στον άξονα του χρόνου παρέχει σημαντικές πληροφορίες σχετικά με τα χαρακτηριστικά του μεγέθους αυτού και τον τρόπο με τον οποίο εξελίσσεται. Επομένως, η ανάλυση των χρονοσειρών, η οποία μπορεί να γίνει μέσω διαφόρων στατιστικών μεθόδων, έχει ιδιαίτερη αξία.

Στην περίπτωση όπου κάθε παρατήρηση εξαρτάται από τις προηγούμενες παρατηρήσεις και μπορεί να υπολογιστεί μέσω μιας συγκεκριμένης σχέσης, η χρονοσειρά ονομάζεται ντετερμινιστική και, υπό την προϋπόθεση ότι η σχέση αυτή μπορεί να προσδιοριστεί, οι μελλοντικές παρατηρήσεις μπορούν να προβλεφθούν με μεγάλη ακρίβεια. Ωστόσο, κάτι τέτοιο δεν είναι πάντα εφικτό σε πραγματικά δεδομένα, μιας και εκτός από τη σχέση που ενδέχεται να συνδέει τις επιμέρους παρατηρήσεις της χρονοσειράς, αυτές επηρεάζονται σημαντικά και από άλλους παράγοντες, όπως ο θόρυβος ή η τυχαιότητα. Οι χρονοσειρές αυτές που περιέχουν τον στοχαστικό παράγοντα της τυχαιότητας ονομάζονται στοχαστικές.

Και στις δύο περιπτώσεις χρονοσειρών, ντετερμινιστικών και στοχαστικών, ορισμένα από τα βασικά χαρακτηριστικά τους μπορούν να απομονωθούν και να υπολογιστούν με ικανοποιητική ακρίβεια. Παρακάτω παρουσιάζονται τα ποιοτικά χαρακτηριστικά των χρονοσειρών, αναλύονται σε μεγαλύτερο βαθμό οι κατηγορίες τους και περιγράφονται οι στατιστικοί δείκτες που είναι απαραίτητοι για την μελέτη τους.


### 3.1 Ποιοτικά χαρακτηριστικά χρονοσειρών

Με τον όρο ποιοτικά χαρακτηριστικά χρονοσειρών αναφέρονται όλα τα μεγέθη μιας χρονοσειράς τα οποία ένας παρατηρητής μπορεί να εντοπίσει κατά την οπτική μελέτη της. Παρά το γεγονός ότι τα μεγέθη αυτά έχουν ορισθεί καταχρηστικά, προκειμένου τα μοντέλα πρόβλεψης που σχεδιάζονται να προσαρμόζονται σε μεγέθη με τα οποία είναι εξοικειωμένος ο άνθρωπος και η λειτουργίας τους γίνεται πιο εύκολα αντιληπτή, η διαδικασία αποσύνθεσης της χρονοσειράς στα ποιοτικά χαρακτηριστικά της είναι ιδιαίτερα χρήσιμη. Αυτό γιατί η διαδικασία της αποσύνθεσης δίνει τη δυνατότητα να απομονωθούν τα συστατικά της χρονοσειράς και να εφαρμοστούν κατάλληλα μοντέλα πρόβλεψης σε αυτά προκειμένου να βελτιωθεί η προβλεπτική ικανότητα στο σύνολό της.

Σύμφωνα με τους Makridakis et al. (1983), τα ποιοτικά χαρακτηριστικά μιας χρονοσειράς

είναι η τάση, η κυκλικότητα (κύκλος), η εποχιακότητα και η τυχαιότητα (μη κανονικές διακυμάνσεις), τα οποία περιγράφονται πιο αναλυτικά παρακάτω.


**Τάση:** Ονομάζεται η μακροπρόθεσμη μεταβολή του μέσου επιπέδου των τιμών μιας χρονοσειράς, η οποία για να γίνει αντιληπτή θα πρέπει να είναι διαθέσιμο ένα ικανό πλήθος παρατηρήσεων, προφανώς σε σχέση με τη συχνότητα των δεδομένων. Σε μία ετήσια χρονοσειρά, για παράδειγμα, τάση μπορεί να εντοπιστεί ακόμα και σε ελάχιστες παρατηρήσεις, ωστόσο στην περίπτωση ωριαίων δεδομένων το αντίστοιχο δείγμα θα πρέπει να είναι σαφώς μεγαλύτερο. Η τάση δεν έχει πάντα ένα συγκεκριμένο μοτίβο, αλλά συναντώνται περιπτώσεις όπου μπορεί να είναι γραμμική (σταθερή μεταβολή επιπέδου), εκθετική (μη γραμμική μεταβολή επιπέδου), λογαριθμική ή και άλλης μορφής. Δεδομένου ότι είναι σπάνιο να εντοπίζονται ιδιαίτερες ενδείξεις σχετικές με τον τύπο της τάσης, καταχρηστικά θεωρείται ότι δεν μεταβάλλεται και εκτιμάται γραμμικά. Χαρακτηριστικά παραδείγματα χρονοσειρών με τάση παρουσιάζονται στο Σχήμα 3.1.



Σχήμα 3.1: Χρονοσειρές του διαγωνισμού M3 με έντονο το χαρακτηριστικό της τάσης, εκθετικής (αριστερά) και γραμμικής (δεξιά). (Πηγή: Σπηλιώτης (2017))


**Κυκλικότητα:** Αναφέρεται στις μακροχρόνιες, και συνήθως κυματοειδής μορφής, μεταβολές που εντοπίζονται σε μία χρονοσειρά και συμβαίνουν κυρίως λόγω ειδικών εξωγενών συνθηκών που εμφανίζονται κατά περιόδους. Ο κύκλος δεν είναι ένα περιοδικό μέγεθος, με συγκεκριμένο διάστημα και ομοιόμορφη ένταση, αλλά οι περίοδοι είναι συνήθως μεταβαλλόμενοι με μήκος κατά κανόνα μεγαλύτερο του έτους. Κυκλικότητα συναντάται σε χρονοσειρές των περισσότερων οικονομικών μεγεθών, όπως το Ακαθάριστο Εγχώριο Προϊόν (Α.Ε.Π.) και οι δείκτες βιομηχανικής παραγωγής, και είναι αποτέλεσμα των γενικότερων οικονομικών συνθηκών που χαρακτηρίζονται από διαδοχικές ανόδους και υφέσεις. Ένα χαρακτηριστικό παράδειγμα χρονοσειράς στην οποία εντοπίζεται κυκλικότητα απεικονίζεται στο Σχήμα 3.2.

**Εποχιακότητα:** Ονομάζεται η περιοδική διακύμανση των παρατηρήσεων μιας χρονοσειράς η οποία έχει σταθερό μήκος και κατά κανόνα μικρότερο του έτους. Η διακύμανση αυτή είναι εύκολα μετρήσιμη, κατανοητή και ως αποτέλεσμα προβλέψιμη. Λόγω της ευκολίας αυτής, είναι σύνηθες να προβλέπονται οι χρονοσειρές αφού έχει αφαιρεθεί η εποχιακότητα (seasonally adjusted time series) και να προστίθεται έπειτα στις προβλέψεις. Κλασικά παραδείγματα αποτελούν οι πωλήσεις παγωτών, οι οποίες εμφανίζουν μία έντονη αύξηση κατά τους καλοκαιρινούς μήνες, όπως και οι πωλήσεις



Σχήμα 3.2: Χρονοσειρά του διαγωνισμού Μ3 με έντονο το χαρακτηριστικό της κυκλικότητας. (Πηγή: Σπηλιώτης (2017))


καυσίμων, οι οποίες εμφανίζουν αντίστοιχα μία έντονη άνοδο κατά τους χειμερινούς μήνες. Μία χρονοσειρά με έντονη εποχιακότητα παρουσιάζεται στο Σχήμα 3.3.



Σχήμα 3.3: Χρονοσειρά του διαγωνισμού Μ3 με έντονο το χαρακτηριστικό της εποχιακότητας. (Πηγή: Σπηλιώτης (2017))

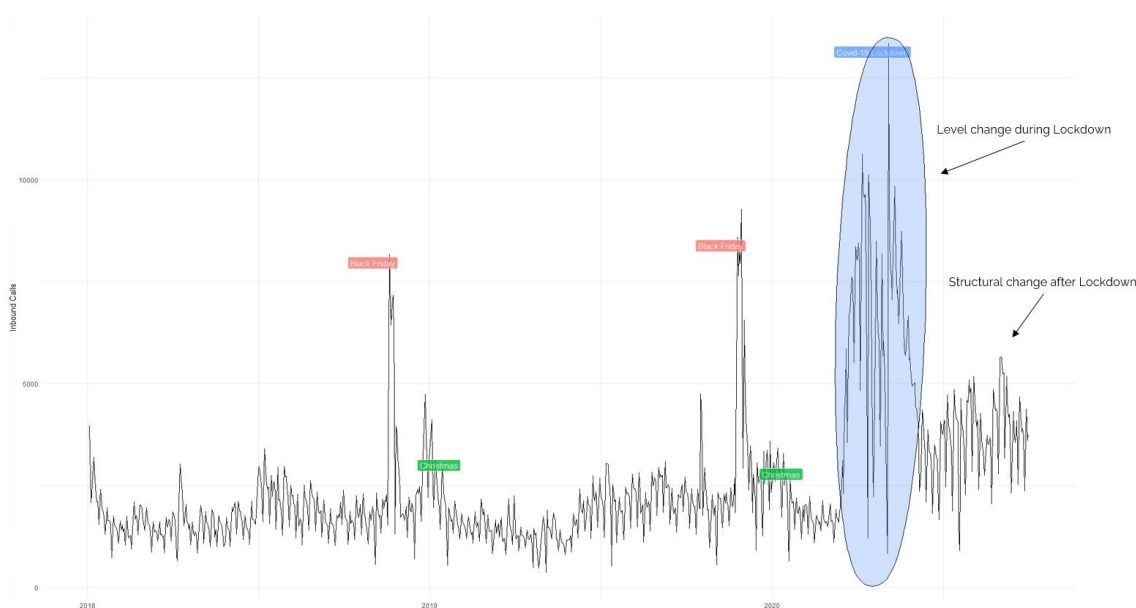
**Τυχαιότητα (Μη κανονικές διακυμάνσεις):** Αναφέρεται στις διακυμάνσεις που απομένουν όταν όλα τα υπόλοιπα ποιοτικά χαρακτηριστικά μιας χρονοσειράς (τάση, κυκλικότητα, εποχιακότητα) έχουν απομονωθεί (residuals). Οι διακυμάνσεις αυτές μπορούν είτε να έχουν παροδικό χαρακτήρα, αντιπροσωπεύοντας μία τυχαία μεταβλητή (απότομες αλλαγές στο πρότυπο συμπεριφοράς - ακραίες τιμές), είτε μόνιμο χαρακτήρα που συνδέεται με κάποιο εξαιρετικό γεγονός (μεταβολή επιπέδου - ασυνέχειες). Όπως είναι εμφανές, οι χρονοσειρές που εμφανίζουν αυτό το χαρακτηριστικό σε μεγάλο βαθμό είναι δύσκολο να προβλεφθούν. Μία χρονοσειρά με έντονη τυχαιότητα απεικονίζεται στο Σχήμα 3.4.

Στην πραγματικότητα, μιας και οι χρονοσειρές έχουν στοχαστικό χαρακτήρα, τυχαιότητα εντοπίζεται σε κάθε χρονοσειρά. Έτσι, κατά την ανάλυση μιας χρονοσειράς, μεγαλύτερης σημασίας είναι συγκεκριμένες εκφάνσεις της τυχαιότητας, γνωστές ως outliers, οι οποίες διακρίνονται σε μόνιμες μεταβολές επιπέδου (level change), προσωρινές μεταβολές επιπέδου (temporal change) και ακραίες τιμές (extreme values) (Ledolter, 1989). Σε περιπτώσεις



Σχήμα 3.4: Χρονοσειρά του διαγωνισμού M3 με έντονο το χαρακτηριστικό της τυχαιότητας. (Πηγή: Σπηλιώτης (2017))

ακραίων μεταβολών, είναι σύνηθες να εξομαλύνονται ή να απαλείφονται προκειμένου να μην αλλοιώσουν τα βασικά ποιοτικά χαρακτηριστικά, διεργασία που πραγματοποιείται μέσω κατάλληλων μεθόδων.



Σχήμα 3.5: Χρονοσειρά, η οποία αναπαριστά κλήσεις σε τηλεφωνικό κέντρο ελληνικής επιχείρησης, με έντονες ασυνέχειες λόγω της επίπτωσης του lockdown που επεβλήθη στην Ελλάδα στις αρχές του 2020 ως μέτρο προστασίας από την πανδημία του COVID-19. (Πηγή: Theodorou et al. (2020))

Ένα χαρακτηριστικό παράδειγμα χρονοσειράς με αρκετά outliers εμφανίζεται στο Σχήμα 3.5. Το σχήμα αυτό απεικονίζει τις εισερχόμενες κλήσεις στο τηλεφωνικό κέντρο μιας ελληνικής επιχείρησης για το διάστημα από τις αρχές του 2018 έως τα μέσα του 2020. Κατά το διάστημα που επεβλήθη lockdown στην Ελλάδα ως μέτρο προστασίας από την πανδημία του COVID-19, Μάρτιος του 2020, παρατηρείται μία έντονη αύξηση στις κλήσεις, αύξηση μεγαλύτερη και από αυτή των περιόδων του Black Friday των προηγούμενων ετών,



αλλά και πολύ μεγαλύτερης διάρκειας, μιας και η άνοδος αυτή παραμένει καθ' όλη τη διάρκεια του lockdown (temporal change). Με το τέλος του lockdown, ενώ παρατηρείται μία πτώση σε σχέση με την περίοδο όπου τα καταστήματα ήταν κλειστά, παρατηρείται επίσης μία αύξηση επιπέδου σε σχέση με τις παρελθοντικές παρατηρήσεις, η οποία παραμένει (level change) και γίνεται εμφανής μία δομική αλλαγή στη συμπεριφορά της χρονοσειράς (structural change), ιδιαίτερα όσον αφορά στην εποχιακότητα. Προφανώς, αιτία των παραπάνω αλλαγών κατέστη το γεγονός ότι τα καταστήματα ήταν κλειστά και οι πελάτες στράφηκαν προς το τηλεφωνικό κέντρο προκειμένου να πραγματοποιήσουν τις αγορές τους, κάτι που οδήγησε ίσως σε μία πιο μόνιμη αλλαγή τις αγοραστικής συνήθειας των πελατών οι οποίοι άρχισαν να επιλέγουν σε μεγαλύτερο βαθμό το τηλεφωνικό κέντρο ακόμα και σε περιόδους ανοικτών καταστημάτων.

### 3.2 Αποσύνθεση χρονοσειρών

Με το όρο αποσύνθεση ορίζεται η μαθηματική διαδικασία η οποία αποσκοπεί στην απομόνωση των επιμέρους ποιοτικών χαρακτηριστικών μιας χρονοσειράς, τα οποία αναφέρθηκαν παραπάνω, δηλαδή στην τάση (T-trend), στην κυκλικότητα (C-circle), στην εποχιακότητα (S-seasonality) και στην τυχαιότητα (R-randomness). Η διαδικασία της αποσύνθεσης είναι ιδιαίτερα σημαντική τόσο για την καλύτερη κατανόηση των ιδιοτήτων της χρονοσειράς όσο και για τη βελτίωση της απόδοσης των μοντέλων πρόβλεψης. Η μαθηματική διατύπωσή της είναι η εξής (Πετρόπουλος & Ασημακόπουλος, 2011):

$$Y_t = f(S_t, T_t, C_t, R_t),$$

όπου  $Y_t$  η παρατήρηση κατά τη χρονική περίοδο  $t$ ,  $S_t$  η συνιστώσα της εποχιακότητας,  $T_t$  η συνιστώσα της τάσης,  $C_t$  η συνιστώσα της κυκλικότητας και  $R_t$  η συνιστώσα της τυχαιότητας.

Σύμφωνα με τη βιβλιογραφία, οι δύο πιο διαδεδομένοι τρόποι είναι η κλασική πολλαπλασιαστική μέθοδος αποσύνθεσης κινητών μέσων όρων (Classical Multiplicative Decomposition by Moving Averages) και η κλασική προσθετική μέθοδος αποσύνθεσης κινητών μέσων όρων (Classical Additive Decomposition by Moving Averages) (Kendall et al., 1946). Η πρώτη μέθοδος θεωρεί ότι κάθε χρονοσειρά αποτελείται από τα τέσσερα συστατικά που αναφέρθηκαν και την παράγουν μέσω του γινόμενού τους, ενώ η δεύτερη θεωρεί ότι η σχέση μεταξύ των συστατικών της είναι προσθετική, δηλαδή:

$$Y_t = S_t \cdot T_t \cdot C_t \cdot R_t, \text{ και}$$

$$Y_t = S_t + T_t + C_t + R_t \text{ αντίστοιχα.}$$

Όπως είναι προφανές, στην περίπτωση της προσθετικής μεθόδου οι μεταβολές που οφείλονται σε κάθε συστατικό της αποσύνθεσης εφαρμόζονται ανεξάρτητα προκειμένου να παραχθεί η αρχική χρονοσειρά, ενώ στην περίπτωση της πολλαπλασιαστικής μεθόδου τα συστατικά αλληλοεπιδρούν. Με τον τρόπο αυτό, σε μία χρονοσειρά στην οποία εντοπίζεται εποχιακότητα και αυξητική τάση, η εποχιακότητα θα γίνεται εντονότερη με την πάροδο του χρόνου μέσω της πολλαπλασιαστικής μεθόδου, ενώ θα παραμένει ομοιόμορφη μέσω της

προσθετικής. Σύμφωνα με τον Kuiper (1978), ένας τρόπος επιλογής μεταξύ των δύο είναι πρώτα να εφαρμοστεί το πολλαπλασιαστικό μοντέλο, για να αποεποχικοποιηθεί η χρονοσειρά, και έπειτα να περάσει η ευθεία της απλής γραμμικής παλινδρόμησης από την εναπομείνουσα χρονοσειρά. Εάν η ευθεία που προκύπτει εμφανίζει στατιστική σημαντικότητα και κλίση, τότε η επιλογή του πολλαπλασιαστικού μοντέλου ήταν σωστή, ενώ σε αντίθετη περίπτωση πρέπει να επιλεγεί η προσθετική μέθοδος.

Προφανώς υπάρχουν και άλλοι τρόποι αποσύνθεσης χρονοσειρών, όπως οι εξής:

- Zaycoff's Method (Zaycoff, 1936)
- Central Planning Bureau Method - CPB (Wald, 1936)
- SABL Method (Cleveland et al., 1978)
- Census II Method: X-11 και X-12 (McKenzie, 1984)
- Seasonal decomposition by Loess (Cleveland et al., 1990)

Να σημειωθεί ότι στη βιβλιογραφία εμφανίζονται αρκετές εκδόσεις και διαφοροποιήσεις των παραπάνω μεθόδων αποσύνθεσης, που αφορούν σε μεγαλύτερο βαθμό στον τρόπο εξομάλυνσης ή εξαίρεσης ακραίων τιμών πριν τον υπολογισμό των συστατικών αποσύνθεσης και στην εφαρμογή μεθόδων συρρίκνωσης των εποχιακών δεικτών.

### 3.3 Στατιστική ανάλυση χρονοσειρών

Η βασική στατιστική ανάλυση χρονοσειρών πραγματοποιείται μέσω του υπολογισμού στατιστικών δεικτών και, σε συνδυασμό με την γραφική απεικόνιση των χρονοσειρών που εξετάζονται, επιτρέπει την καλύτερη και πιο δομημένη κατανόηση της πληροφορίας που περιέχουν και διευκολύνει στην επιλογή των κατάλληλων διαδικασιών πρόβλεψης. Οι πιο βασικοί στατιστικοί δείκτες παρουσιάζονται παρακάτω.

#### **Μέση τιμή (Average ή Mean)**

Δείχνει το επίπεδο γύρω από το οποίο μεταβάλλονται οι παρατηρήσεις μιας χρονοσειράς και υπολογίζεται ως εξής:

$$\bar{Y} = \frac{1}{n} \sum_{i=1}^n Y_i,$$

όπου  $n$  το πλήθος των παρατηρήσεων της χρονοσειράς και  $Y_i$  η τιμή της χρονοσειράς  $Y$  τη στιγμή  $i$ .

#### **Ελάχιστη (minimum) και μέγιστη (maximum) τιμή**

Είναι οι ακραίες τιμές της χρονοσειράς και δείχνουν τη διακύμανση των παρατηρήσεων.

#### **Ενδιάμεση τιμή (Median)**

Είναι η μεσαία παρατήρηση της χρονοσειράς όταν αυτές ταξινομηθούν σε αύξουσα σειρά, ενώ όταν το πλήθος των παρατηρήσεων είναι άρτιο, επιλέγεται ο μέσος όρος των δύο μεσαίων παρατηρήσεων.

#### **Πλέον εμφανιζόμενη τιμή (Mode)**

Είναι εκείνη η τιμή της χρονοσειράς η οποία εμφανίζεται πιο συχνά.

Και στις δυο παραπάνω περιπτώσεις, στην ενδιάμεση και στην πλέον εμφανιζόμενη τιμή, όταν οι παρατηρήσεις διακρίνονται από ασυνέχεια συνήθως εφαρμόζονται τεχνικές kernel για τον προσδιορισμό της κατανομής τους και τον υπολογισμό των δεικτών, με στόχο έναν πιο στιβαρό προσδιορισμό του εκάστοτε επιπέδου.

#### **Τυπική απόκλιση ή διασπορά (Standard deviation)**

Δείχνει το βαθμό συγκέντρωσης των παρατηρήσεων γύρω από τη μέση τιμή και υπολογίζεται ως εξής:

$$\sigma_{\text{πληθυσμού}} = \sqrt{\frac{\sum_{i=1}^n (Y_i - \bar{Y})^2}{n}}, \text{ και}$$

$$\sigma_{\text{δείγματος}} = \sqrt{\frac{\sum_{i=1}^n (Y_i - \bar{Y})^2}{n-1}}$$

Το τετράγωνο της διασποράς ( $\sigma^2$ ) ονομάζεται διακύμανση και χρησιμοποιείται για τον ίδιο σκοπό.

#### **Συνδιακύμανση (Covariance)**

Δείχνει τη σχέση ανάμεσα σε δύο μεταβλητές, συγκρίνοντας αν μεταβάλλονται προς την ίδια (θετική συνδιακύμανση) ή προς την αντίθετη κατεύθυνση (αρνητική συνδιακύμανση) και τη συσχέτιση ή μη των συνόλων των δύο μεταβλητών (όταν δεν υπάρχει συσχέτιση, πρόκειται για μηδενική συνδιακύμανση). Υπολογίζεται ως εξής:

$$\text{Cov}(X, Y) = \frac{1}{n} \sum_{i=1}^n [(X_i - \bar{X})(Y_i - \bar{Y})],$$

όπου όταν:

- $\text{Cov}(X, Y) > 0$ , τα δύο μεγέθη μεταβάλλονται ανάλογα,
- $\text{Cov}(X, Y) < 0$ , τα δύο μεγέθη μεταβάλλονται αντιστρόφως ανάλογα,
- $\text{Cov}(X, Y) = 0$ , τα δύο μεγέθη μεταβάλλονται είναι ασυσχέτιστα.

Στην περίπτωση των χρονοσειρών συνήθως υπολογίζεται η συνδιακύμανση των παρατηρήσεων με τον αύξοντα αριθμό της χρονικής περιόδου.

#### **Συντελεστής γραμμικής συσχέτισης (Linear correlation coefficient)**

Είναι το μέτρο της συγκέντρωσης των παρατηρήσεων ενός διαγράμματος διασποράς γύρω από την ευθεία παλινδρόμησης, που στην ουσία υποδηλώνει τη γραμμική συσχέτιση μεταξύ δύο μεταβλητών και υπολογίζεται ως εξής:

$$r_{XY} = \frac{\sum_{i=1}^n [(X_i - \bar{X})(Y_i - \bar{Y})]}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}},$$

όπου όταν:

- $r_{XY} = -1$ , οι δύο μεταβλητές εμφανίζουν τέλεια αρνητική συσχέτιση,

- $-1 < r_{XY} < -0.75$ , οι δύο μεταβλητές εμφανίζουν πολύ ισχυρή αρνητική γραμμική συσχέτιση,
- $-0.75 \leq r_{XY} < -0.35$ , οι δύο μεταβλητές εμφανίζουν ισχνή αρνητική γραμμική συσχέτιση,
- $-0.35 \leq r_{XY} < 0$ , οι δύο μεταβλητές εμφανίζουν σχεδόν ανύπαρκτη αρνητική γραμμική συσχέτιση,
- $r_{XY} = 0$ , οι δύο μεταβλητές δεν εμφανίζουν καθόλου συσχέτιση,
- $0 < r_{XY} \leq 0.35$ , οι δύο μεταβλητές εμφανίζουν σχεδόν ανύπαρκτη θετική γραμμική συσχέτιση,
- $0.35 < r_{XY} \leq 0.75$ , οι δύο μεταβλητές εμφανίζουν ισχνή θετική γραμμική συσχέτιση,
- $0.75 < r_{XY} < 1$ , οι δύο μεταβλητές εμφανίζουν πολύ ισχυρή θετική γραμμική συσχέτιση,
- $r_{XY} = 1$ , οι δύο μεταβλητές εμφανίζουν τέλεια θετική συσχέτιση.

### Συντελεστής αυτοσυσχέτισης (Autocorrelation coefficient)

Δείχνει τη συσχέτιση μεταξύ των παρατηρήσεων μιας μεταβλητής οι οποίες έχουν χρονική διαφορά  $k$  περιόδους. Συνήθως χρησιμοποιείται για τη μελέτη της εποχιακότητας μιας χρονοσειράς, επιλέγοντας  $k$  ίσο με τη συχνότητα της χρονοσειράς, και της γραμμικής τάσης, επιλέγοντας  $k$  ίσο με 1. Υπολογίζεται ως εξής:

$$ACF_k = \frac{\sum_{i=1+k}^n [(Y_i - \bar{Y})(Y_{i-k} - \bar{Y})]}{\sum_{i=1}^n (Y_i - \bar{Y})^2},$$

όπου όταν:

- $ACF_k = 0$ , οι παρατηρήσεις χρονικής υστέρησης  $k$  εμφανίζουν μηδενική συσχέτιση,
- $ACF_k = 1$ , οι παρατηρήσεις χρονικής υστέρησης  $k$  εμφανίζουν μεγάλη συσχέτιση.

### Συντελεστής μεταβλητότητας (Coefficient of variation)

Είναι η κανονικοποιημένη διασπορά ως προς τη μέση τιμή της μεταβλητής, η οποία αποτελεί ένδειξη ως προς την τυχαιότητα σε μία χρονοσειρά και υπολογίζεται ως εξής:

$$CV = \frac{\sigma}{\bar{Y}} 100\%.$$

### Ρυθμός ανάπτυξης (Growth rate)


Είναι ένα ποσοστό που εκφράζει το μέτρο της αύξουσας ή φθίνουσας πορείας μίας χρονοσειράς για ένα συγκεκριμένο χρονικό διάστημα, αποτελεί ένδειξη ως προς την τάση, και υπολογίζεται ως εξής:

$$Growth Rate = \frac{\frac{1}{ppy} \sum_{i=n-ppy+1}^n Y_i - \frac{1}{n-ppy} \sum_{i=1}^{n-ppy} Y_i}{\frac{1}{n-ppy} \sum_{i=1}^{n-ppy} Y_i} 100\%,$$

όπου  $ppy$  το πλήθος των περιόδων στο μήκος ενός έτους.

### 3.4 Χρονοσειρές διακοπτόμενης ζήτησης

Ένα υποσύνολο των χρονοσειρών αποτελούν οι χρονοσειρές διακοπτόμενης φύσης ή χρονοσειρές διακοπτόμενης ζήτησης ή, απλά, διακοπτόμενη ζήτηση. Κύριο χαρακτηριστικό της ζήτησης είναι ότι μπορεί να εμφανίζεται σποραδικά, δηλαδή να μεσολαβούν λιγότερες ή περισσότερες περίοδοι όπου αυτή είναι μηδενική, με αποτέλεσμα κατά την γραφική απεικόνιση μιας τέτοιας χρονοσειράς να φαίνονται λιγότερες ή περισσότερες μηδενικές παρατηρήσεις. Επίσης, όταν παρουσιαστεί ζήτηση (μη μηδενική παρατήρηση), το μέγεθός της μπορεί να ποικίλει, ακόμα και σε σημαντικό βαθμό. Ένα χαρακτηριστικό παράδειγμα χρονοσειράς διακοπτόμενης φύσης απεικονίζεται στο Σχήμα 3.6.



Σχήμα 3.6: Χρονοσειρά διακοπτόμενης φύσης.

Στην πράξη, χρονοσειρές διακοπτόμενης φύσης συναντώνται πιο συχνά σε διάφορα στάδια της εφοδιαστική αλυσίδας, σε μονάδες διαχείρισης αποθεμάτων (stock keeping units), σε ανταλλακτικά (spare parts) και σε αγορές προϊόντων από του τελικούς πελάτες, και δημιουργεί αρκετά προβλήματα στην πρόβλεψη της ζήτησης, των αναμενόμενων πωλήσεων, και κατ'επέκταση στη διαχείριση των αποθεμάτων. Η δυσκολία αυτή στην πρόβλεψη οφείλεται εξίσου στην ασυνέχεια των μη μηδενικών παρατηρήσεων και στη διακύμανση μεταξύ δύο διαδοχικών μη μηδενικών παρατηρήσεων.

Η αλήθεια είναι ότι στη βιβλιογραφία έχει δοθεί περιορισμένη προσοχή στις συγκεκριμένες χρονοσειρές και τις αντίστοιχες μεθόδους πρόβλεψης, καθώς υπάρχει η αντίληψη ότι αφορούν μόνο σε ανταλλακτικά (Nikolopoulos, 2021). Ωστόσο, η πραγματικότητα είναι αρκετά διαφορετική, αλλά ακόμα και αν δεν ήταν τα ανταλλακτικά αποτελούν το μεγαλύτερο μέρος κάθε αποθέματος (Syntetos et al., 2016), επομένως συνιστάται περαιτέρω έρευνα.

### 3.5 Στατιστική ανάλυση χρονοσειρών διακοπτόμενης ζήτησης

Δεν είναι σπάνιο σε μία χρονοσειρά διακοπτόμενης φύσης, λόγω του πλήθους των μηδενικών τιμών που περιέχει, η μέση τιμή των παρατηρήσεων της να είναι μηδενική. Αυτό έχει ως αποτέλεσμα να καθίσταται αδύνατος ο υπολογισμός ορισμένων στατιστικών δεικτών που χρησιμοποιούνται ευρέως στην βασική στατιστική ανάλυση των χρονοσειρών, που αναφέρθηκαν παραπάνω.

Έτσι, βάσει της ανάγκης για υπολογισμό των δύο βασικών συστατικών της διακοπτόμενης ζήτησης, δηλαδή της ασυνέχειας των μη μηδενικών παρατηρήσεων και της διακύμανσης μεταξύ δύο διαδοχικών μη μηδενικών παρατηρήσεων, κρίνεται απαραίτητο να προστεθούν στους στατιστικούς δείκτες η μέση τιμή διαστημάτων μεταξύ των ζητήσεων (average inter-demand interval) και ο τετραγωνικός συντελεστή μεταβλητότητας της ζήτησης (squared coefficient of variation of demand), που αναλύονται παρακάτω.

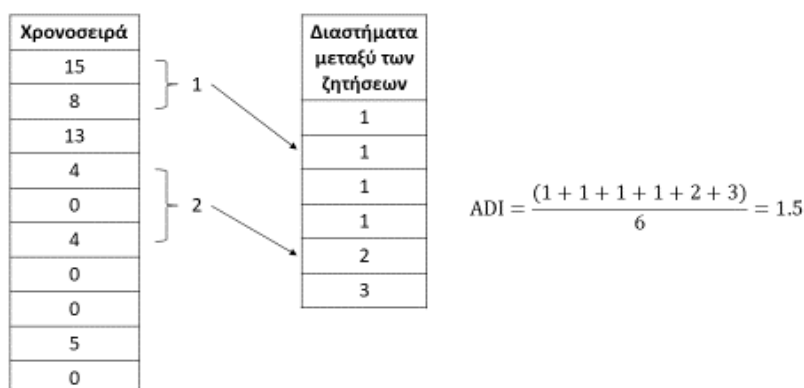
#### Μέση τιμή διαστημάτων μεταξύ των ζητήσεων (Average inter-demand interval)

Εκφράζει τη μέση τιμή των αποστάσεων μεταξύ δύο μη μηδενικών παρατηρήσεων και υποδηλώνει τη σποραδικότητα της ζήτησης. Αν ισούται με τη μονάδα, τότε αναφερόμαστε σε δεδομένα συνεχούς ζήτησης, ενώ όσο μεγαλώνει η τιμή του δείκτη συνεπάγεται και μεγαλύτερα, κατά μέσο όρο, διαστήματα μεταξύ μη μηδενικών παρατηρήσεων. Η μέση τιμή διαστημάτων μεταξύ των ζητήσεων υπολογίζεται ως εξής:

$$ADI = \frac{\sum_{i=1}^N t_i}{N},$$

όπου  $N$  είναι το πλήθος μη μηδενικών παρατηρήσεων και  $t_i$  είναι το μεσοδιάστημα μεταξύ του ζευγαριού  $i$  των διαδοχικών μη μηδενικών παρατηρήσεων.

Ένα παράδειγμα υπολογισμού του  $ADI$  μιας χρονοσειράς διακοπτόμενης φύσης αναλύεται παρακάτω:



### Τετραγωνικός συντελεστής μεταβλητότητας της ζήτησης (Squared coefficient of variation of demand)

Εκφράζει τη μεταβλητότητα της ζήτησης και υπολογίζεται ως εξής:

$$CV^2 = \left( \frac{\sigma_d}{\bar{d}} \right)^2 = \frac{\sum_{i=1}^N (d_i - \bar{d})^2}{(N-1)\bar{d}^2},$$

όπου  $N$  είναι το πλήθος μη μηδενικών παρατηρήσεων και  $d_i$  και  $\bar{d}$  είναι η  $i$ -οστή ζήτηση και η μέση ζήτηση, αντίστοιχα.

Ένα παράδειγμα υπολογισμού του  $CV^2$  μιας χρονοσειράς διακοπτόμενης ζήτησης αναλύεται παρακάτω:

Χρονοσειρά
15
8
13
4
0
4
0
0
5
0

Ζήτηση
15
8
13
4
4
5

$$CV^2 = \left( \frac{\sigma_d}{\bar{d}} \right)^2 = \left( \frac{4.79}{8.16} \right)^2 = 0.34$$

$$\bar{d} = \frac{(15+8+13+4+4+5)}{6} = 8.16$$

$$\sigma_d = \sqrt{\frac{(15-8.16)^2 + (8-8.16)^2 + (13-8.16)^2 + (4-8.16)^2 + (4-8.16)^2 + (5-8.16)^2}{5}} = 4.79$$

Να σημειωθεί εδώ ότι, όπως φαίνεται και από την παραπάνω επεξήγηση του υπολογισμού του  $CV^2$ , για τον υπολογισμό της τυπικής απόκλισης ο παρονομαστής παίρνει την μορφή  $N - 1$  αντί για  $N$ . Στην πραγματικότητα δεν χρησιμοποιείται ο τύπος του δείγματος αντί του πληθυσμού, αλλά αυτό που συμβαίνει είναι ότι πραγματοποιείται ένας πολλαπλασιασμός με τον παράγοντα  $\frac{N}{N-1}$ , διόρθωση Bessel (Bessel's correction), ο οποίος δίνει έναν πιο αμερόληπτο (unbiased) υπολογισμό της διασποράς σε ανεξάρτητες και πανομοιότυπα κατανεμημένες (independent and identically distributed - i.i.d.) παρατηρήσεις (Reichmann et al., 1962).

Αρκετά χρήσιμα εργαλεία της στατιστικής ανάλυσης χρονοσειρών αποτελούν τα πακέτα `tsfresh` (Christ et al., 2018) στην γλώσσα προγραμματισμού `python` και `tsfeatures` (Hyndman et al., 2020) στην `R`. Αθροιστικά τα δύο αυτά πακέτα περιλαμβάνουν περισσότερους από 800 στατιστικούς δείκτες που περιγράφουν διάφορα χαρακτηριστικά των χρονοσειρών που εξετάζονται. Το πακέτο `tsfresh` περιλαμβάνει μια ποικιλία δεικτών, όπως βασικά στατιστικά στοιχεία χρονοσειρών, δείκτες συσχέτισης, εκτιμήσεις εντροπίας, και από την άλλη πλευρά, το πακέτο `tsfeatures` περιλαμβάνει στατιστικά στοιχεία που

υπολογίζονται για τις διαφορές πρώτης και δεύτερης τάξης της αρχικής χρονοσειράς, λαμβάνουν υπόψη την εποχικότητα και εκμεταλλεύονται τα αποτελέσματα δημοφιλών μεθόδων αποσύνθεσης, μεταξύ άλλων.

### 3.6 Κατηγοριοποίηση χρονοσειρών

Η δυσκολία των επιχειρήσεων να διαχειριστούν το απόθεμα του ολοένα και μεγαλύτερου αριθμού διαφορετικών προϊόντων σε τακτά χρονικά διαστήματα, οδήγησε στην υιοθέτηση διαφόρων τεχνικών κατηγοριοποίησης των προϊόντων αυτών, όπως η ανάλυση ABC που σχολιάστηκε στο Υποκεφάλαιο 2.13. Κάποιες τεχνικές εξ αυτών, αντί να αναλύουν την σημαντικότητα των προϊόντων, αναλύουν τη φύση των χρονοσειρών που απεικονίζουν τη ζήτηση του εκάστοτε προϊόντος, υπολογίζοντας συγκεκριμένους στατιστικούς δείκτες και κατηγοριοποιούν τις χρονοσειρές, και κατ' επέκταση τα προϊόντα, βάσει των τιμών αυτών (Altay & Litteral, 2011).

#### 3.6.1 Κατηγοριοποίηση σύμφωνα με τον Williams (1984)

Ο Williams (1984) είναι ο πρώτος που εξέτασε τα μοτίβα και τις κατηγορίες της διακοπόμενης ζήτησης, παρουσιάζοντας ένα σχήμα ταξινόμησης που βασίζεται στην κατάτμηση της διακύμανσης (variance partition), ότι δηλαδή η διακύμανση της ζήτησης κατά το χρόνο παράδοσης μπορεί να χωριστεί στη διακύμανση των μεγεθών παραγγελίας, τη μεταβλητότητα των συναλλαγών και τη διακύμανση του χρόνου παράδοσης. Υποθέτοντας τυχαίες αφίξεις ζήτησης (ο αριθμός των αφίξεων ανά περίοδο  $n$  ακολουθεί κατανομή Poisson με μέση τιμή  $k$ ) και σταθερό χρόνο παράδοσης, εξάγεται ο ακόλουθος τύπος:


$$CV_{DDTL}^2 = \frac{1}{\bar{L}} + \frac{CV_x^2}{\bar{L}}$$

Οι δύο παραπάνω όροι χρησιμοποιούνται ως δείκτες στο σύστημα κατηγοριοποίησης, στο οποίο οι τιμές που δημιουργούν τις επιμέρους κατηγορίες υπολογίστηκαν από τον Williams (1984) μέσω ενός διαθέσιμου συνόλου δεδομένων (data set) 11.000 χρονοσειρών, σχετικά μικρής ζήτησης. Έτσι προκύπτει το σύστημα του Σχήματος 3.7, στο οποίο όσο υψηλότερη είναι η αναλογία  $\frac{1}{\bar{L}}$  τόσο πιο σποραδική η ζήτηση (intermittent), και όσο υψηλότερη η αναλογία  $\frac{CV_x^2}{\bar{L}}$  τόσο μεγαλύτερη η διακύμανσή της (lumpy). Δημιουργούνται, έτσι, οι παρακάτω κατηγορίες χρονοσειρών:

- A - smooth (ομαλές)
- B - slow moving (αργής κίνησης)
- C - irregular (ακανόνιστες)
- D1 - sporadic (σποραδικές)
- D2 - highly sporadic (εξαιρετικά σποραδικές)

Ο καθορισμός των ορίων, ωστόσο, μέσω ενός υποκειμενικού συνόλου δεδομένων θέτει την καθολική εγκυρότητα της συγκεκριμένης προσέγγισης υπό αμφισβήτηση.





Σχήμα 3.7: Απεικόνιση συστήματος κατηγοριοποίησης σύμφωνα με τον Williams (1984)

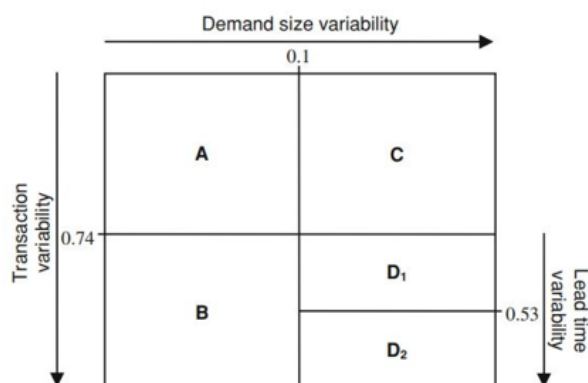
### 3.6.2 Κατηγοριοποίηση σύμφωνα με τους Johnston & Boylan (1996)

Οι Johnston & Boylan (1996) σύγκριναν την απόδοση της μεθόδου πρόβλεψης Croston (Croston, 1972) με τον εκθετικά σταθμισμένο κινούμενο μέσο όρο (Exponentially Weighted Moving Average - EWMA), χρησιμοποιώντας τεχνικές χρονοσειρές σε ένα ευρύ φάσμα συνθηκών, εισάγοντας τον δείκτη “μέση τιμή διαστημάτων μεταξύ των ζητήσεων”. Έδειξαν ότι η Croston υπερέχει της EWMA όταν το ADI είναι μεγαλύτερο από 1.25 περιόδους αναθεώρησης των προβλέψεων. Με τον τρόπο αυτό, η συγκεκριμένη τεχνική κατηγοριοποίησης είναι η πρώτη η οποία επιδιώκει την καθολική εγκυρότητα, επαναφέρει στο προσκήνιο τη σποραδικότητα της ζήτησης, δείχνοντας την αξία της μεθόδου που αναπτύχθηκε αποκλειστικά για χρονοσειρές διακοπτόμενης φύσης, και συνδέει ένα χαρακτηριστικό των χρονοσειρών με την επιλογή της βέλτιστης μεθόδου πρόβλεψης.

### 3.6.3 Κατηγοριοποίηση σύμφωνα με τους Eaves & Kingsman (2004)

Οι Eaves & Kingsman (2004) ανέλυσαν δεδομένα από τη Βασιλική Πολεμική Αεροπορία του Ηνωμένου Βασιλείου (Royal Air Force - RAF). Πρόκειται για ένα σύνολο δεδομένων το οποίο έχει χρησιμοποιηθεί εκτενώς στη βιβλιογραφία και περιέχει πληροφορίες σχετικά με τη ζήτηση 3000 ανταλλακτικών της RAF σε μηνιαίο επίπεδο από τον Ιούλιο του 1992 έως τον Ιούνιο του 1998 (Syntetos & Boylan, 2006b). Κατέληξαν, έτσι, στο συμπέρασμα ότι το σύστημα του Williams (1984) δεν περιέγραφε επαρκώς την παρατηρούμενη μορφή της ζήτησης και σε συνέχεια πρότειναν ένα αναθεωρημένο σύστημα κατηγοριοποίησης, το οποίο απεικονίζεται στο Σχήμα 3.8.

Πιο αναλυτικά, το συγκεκριμένο σύστημα κατηγοριοποιεί τη ζήτηση βάσει της μεταβλητότητας του ρυθμού συναλλαγών (transaction variability), του μεγέθους της ζήτησης (demand size variability) και του χρόνου παράδοσης (lead time variability). Οι χρονοσειρές με χαμηλή μεταβλητότητα συναλλαγής χωρίζονται σε ομαλές (smooth - κατηγορία A) και ακανόνιστες (irregular - κατηγορία C) ανάλογα με τη μεταβλητότητα του μεγέθους της ζήτησης. Αντίστοιχα, οι χρονοσειρές με μεγάλη μεταβλητότητα συναλλαγής



Σχήμα 3.8: Απεικόνιση συστήματος κατηγοριοποίησης σύμφωνα με τους Eaves & Kingsman (2004)

χωρίζονται σε αργής κίνησης (slow moving - κατηγορία B) και ασταθείς (erratic), ενώ βάσει της μεταβλητότητας του χρόνου παράδοσης οι ασταθείς μπορεί να είναι απλά ασταθείς (erratic - κατηγορία D1) ή εξαιρετικά ασταθείς (highly erratic - κατηγορία D2).

Οι κατηγορίες ομαλής και αργής ζήτησης διακρίνονται από τις υπόλοιπες με βάση τη διακύμανση των μεγεθών ζήτησης και η διακύμανση χρόνου παράδοσης χρησιμοποιείται μόνο για τη διάκριση μεταξύ ακανόνιστης και εξαιρετικά ασταθούς ζήτησης. Οι τιμές αποκοπής αποφασίστηκαν με βάση: (α) τα χαρακτηριστικά του συγκεκριμένου συνόλου δεδομένων ζήτησης και (β) το μέγεθος του επαρκούς υποδείγματος (εντός κάθε κατηγορίας ζήτησης).

Ομοίως με την κατηγοριοποίηση σύμφωνα με τον Williams (1984), οι τιμές αποκοπής και σε αυτό το σύστημα επιλέχθηκαν ώστε να έχουν νόημα στο σύνολο δεδομένων που ήταν διαθέσιμο. Χωρίς να υπάρχει αμφιβολία για την ποιότητα και τη σημασία των επιλεγμένων δεικτών με τους οποίους πραγματοποιείται η κατηγοριοποίηση, η αυθαίρετη επιλογή των τιμών αποκοπής δημιουργεί επιφυλάξεις και αμφιβολίες για το κατά πόσο το συγκεκριμένο σύστημα διαθέτει καθολική εγκυρότητα.

### 3.6.4 Κατηγοριοποίηση σύμφωνα με τους Syntetos et al. (2005)

Οι Syntetos et al. (2005) ακολουθώντας μία αναλυτική προσέγγιση προσπάθησαν να εντοπίσουν τις περιοχές εκείνες στις οποίες συγκεκριμένες μέθοδοι πρόβλεψης εμφανίζουν καλύτερα αποτελέσματα. Πιο συγκεκριμένα, σύγκριναν το μέσο σφάλμα (Mean Standard Error - MSE) των μεθόδων EWMA, Croston και SBA (Syntetos Boylan Approximation (Syntetos & Boylan, 2001), και πρότειναν τέσσερις κατηγορίες βάσει της μέσης τιμής διαστημάτων μεταξύ των ζητήσεων (*ADI*) και του τετραγωνικού συντελεστή μεταβλητότητας της ζήτησης ( $CV^2$ ).

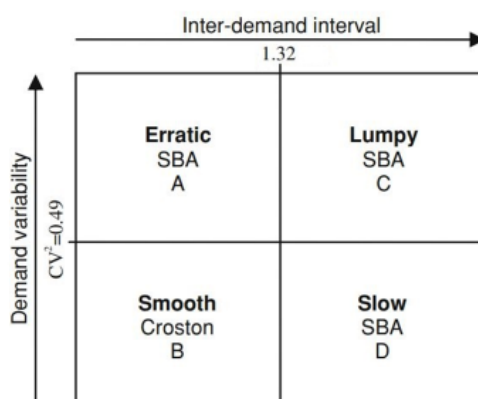
Στο Σχήμα 3.9 απεικονίζεται το συγκεκριμένο σύστημα, στο οποίο εμφανίζονται οι εξής κατηγορίες χρονοσειρών:

- A - erratic (ασταθείς)

- B - smooth (ομαλές)
- C - lumpy (ακανόνιστες ή με “εξογκώματα”)
- D - intermittent or slow (σποραδικές ή αργής κίνησης)

και τα αντίστοιχα όρια που τις διακρίνουν είναι 0.49 για το  $CV^2$  και 1.32 για το  $ADI$ .

Οι Syntetos et al. (2005) απέδειξαν ότι στις κατηγορίες A,C,D η μέθοδος SBA εμφανίζει το μικρότερο σφάλμα, ενώ στην κατηγορία A, δεν προέκυψε κάποια μέθοδος να έχει σταθερά την καλύτερη επίδοση, αλλά η Croston φάνηκε να έχει αρκετά μικρό σφάλμα, οπότε και επλέχθηκε.

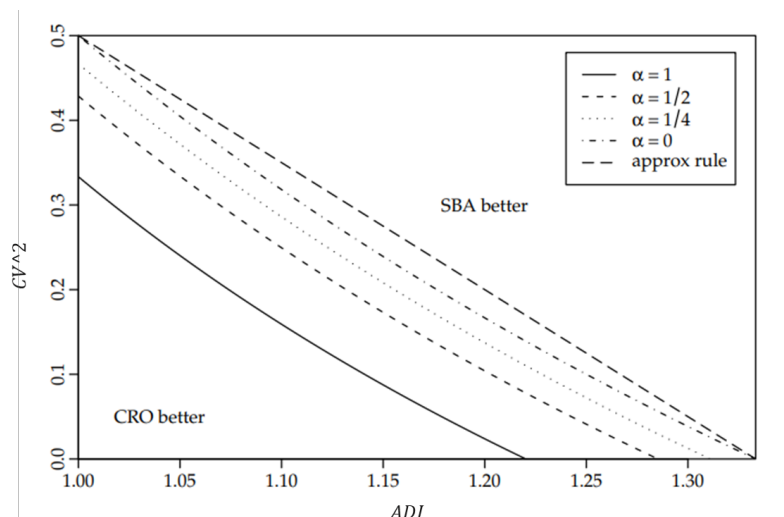


Σχήμα 3.9: Απεικόνιση συστήματος κατηγοριοποίησης σύμφωνα με τους Syntetos et al. (2005).

Το συγκεκριμένο σύστημα είναι το πρώτο που επιδιώκει την καθολική εγκυρότητα και αποτελεί την βάση, στην πρόσφατη βιβλιογραφία, της δημιουργίας πιο ολοκληρωμένων, σύγχρονων συστημάτων κατηγοριοποίησης χρονοσειρών με μοτίβα διακοπτόμενης ζήτησης.

Οι Kostenko & Hyndman (2006) επανεξέτασαν το συγκεκριμένο πρόβλημα, προτείνοντας τα αρχικά όρια να μεταφερθούν στο 0.5, από 0.49, για το  $CV^2$  και στο 4/3, από 1.32, για το  $ADI$ , υποστηρίζοντας ότι η μέθοδος SBA εμφανίζει μικρότερο σφάλμα από την Croston στο διαφορετικό τμήμα που δημιουργείται, δίνοντας επιπλέον μια απλή προσέγγιση υπολογισμού των ορίων αυτών, η οποία χρησιμοποιεί και την παράμετρο εξομάλυνσης  $\alpha$  των μεθόδων που εξετάζονται, όπως φαίνεται στο Σχήμα 3.10.

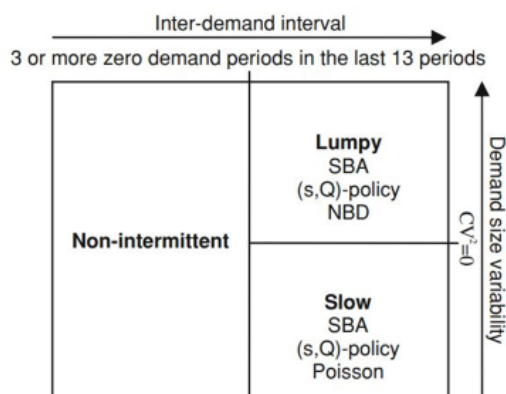
Αν και, όπως είναι αναμενόμενο, η εξέταση διαφορετικών ή πρόσθετων μεθόδων πρόβλεψης μπορεί να οδηγήσει σε διαφορετικά όρια για τις μεταβλητές  $ADI$  και  $CV^2$ , οι Syntetos et al. (2005), και κατ' επέκταση οι Kostenko & Hyndman (2006), υποστηρίζουν τη σταθερότητα των προτεινόμενων ορίων, τα οποία, όπως αναφέρθηκε, έχουν ελάχιστη διαφορά, με αποτέλεσμα να έχουν υιοθετηθεί ευρέως στη βιβλιογραφία, συμπεριλαμβανομένης και της ανάλυσης των αποτελεσμάτων του διαγωνισμού προβλέψεων M5. Για το σκοπό αυτό, το συγκεκριμένο σύστημα, και τα αντίστοιχα όρια, όπως αρχικά προτάθηκαν, χρησιμοποιούνται στην παρούσα διατριβή για τη διευκόλυνση της συζήτησης των αποτελεσμάτων.



Σχήμα 3.10: Χώρος παραμέτρων για τον οποίο κάθε μέθοδος πρόβλεψης είναι καλύτερη από την άλλη, σύμφωνα με την διόρθωση των Kostenko & Hyndman (2006) στο σύστημα των Syntetos et al. (2005).

### 3.6.5 Κατηγοριοποίηση σύμφωνα με τους Boylan et al. (2008)

Οι Boylan et al. (2008), επεκτείνοντας το σύστημα κατηγοριοποίησης των Syntetos et al. (2005), εξέτασαν την απόδοση διαφόρων μεθόδων πρόβλεψης αλλά και μοντέλων διαχείρισης αποθεμάτων ανά κατηγορία χρονοσειρών, σε ένα σύνολο δεδομένων 16000 προϊόντων από την αυτοκινητοβιομηχανία, αεροδιαστημική και χημική βιομηχανία. Έτσι, το συγκεκριμένο σύστημα αποτελεί περισσότερο μια προσέγγιση βέλτιστης πρακτικής παρά ένας αναλυτικός κανόνας.



Σχήμα 3.11: Απεικόνιση συστήματος κατηγοριοποίησης σύμφωνα με τους Boylan et al. (2008)

Όπως φαίνεται και στο Σχήμα 3.11, οι Boylan et al. (2008) προτείνουν τη χρήση της πολιτική (s, Q), η οποία παρουσιάστηκε αναλυτικά στο Υποκεφάλαιο 2.10.1.1, και της μεθόδου πρόβλεψης SBA σε χρονοσειρές με υψηλά ADI και CV<sup>2</sup>, αλλάζοντας όμως το πλήθος των κατηγοριών από τέσσερεις, που υπάρχουν στο σύστημα των Syntetos et al.

(2005), σε τρεις αλλά και τις τιμές αποκοπής. Πιο συγκεκριμένα, καθώς σχεδόν το 50% του συνόλου δεδομένων εμφάνιζε μηδενικό  $CV^2$ , επέλεξαν αυτή τη τιμή για να διακρίνουν τις χρονοσειρές σε αργής κίνησης (slow) και ακανόνιστες (lumpy). Επίσης, το πλήθος των μηδενικών περιόδων για τις τελευταίες 13 περιόδους χρησιμοποιήθηκε ως δείκτης της σποραδικότητας της ζήτησης, με τις 3 περιόδους να επιλέγονται ως το σημείο διαχωρισμού των κατηγοριών, αποκαλώντας τις χρονοσειρές με λιγότερες ή ίσες με 2 μηδενικές περιόδους στις τελευταίες 13 περιόδους μη σποραδικές (non-intermittent).

Παρά το γεγονός ότι προτάθηκε η πολιτική (s, Q), οι Boylan et al. (2008) επισήμαναν ότι δεν εντοπίστηκαν σημαντικές διαφορές από τις πολιτικές (R, S) και (R, s, S), συμφωνώντας έτσι με τα συμπεράσματα των Sani & Kingsman (1997).

“Ο στόχος των προβλέψεων δεν είναι να προβλέψουν το μέλλον, αλλά να σου πουν τι πρέπει να γνωρίζεις ώστε να κάνεις τις ουσιαστικές κινήσεις σήμερα.”

– *Paul Saffo*

## Κεφάλαιο 4

# Μέθοδοι στατιστικής πρόβλεψης χρονοσειρών

---

Ο εντοπισμός της σχέσης εξάρτησης των μελλοντικών παρατηρήσεων μιας ακολουθίας από τις παρελθοντικές αποτελεί το βασικό στόχο των προβλέψεων. Είναι, έτσι, μια τεχνική η οποία χρησιμοποιώντας τα ιστορικά δεδομένα ενός μεγέθους προσπαθεί να προσδιορίσει την κατεύθυνση και το μέγεθος των μελλοντικών τιμών του μεγέθους αυτού. Όπως είναι προφανές, ο τομέας των προβλέψεων έχει ευρεία εφαρμογή στο επιχειρησιακό περιβάλλον, έχει μεγάλο ενδιαφέρον από ακαδημαϊκής σκοπιάς και ως αποτέλεσμα έχει γνωρίσει σημαντική ανάπτυξη τα τελευταία χρόνια.

Σύμφωνα με τους Πετρόπουλος & Ασημακόπουλος (2011), τα μοντέλα μπορούν να χαρακτηριστούν ως ποσοτικά και ως ποιοτικά, βάσει του τρόπου με τον οποίο εξάγουν τις προβλέψεις. Τα ποσοτικά μοντέλα πρόβλεψης, ή αλλιώς στατιστικά, διαχωρίζονται στα μοντέλα χρονοσειρών και τα αιτιοκρατικά μοντέλα, ενώ τα ποιοτικά διαχωρίζονται στις κριτικές προβλέψεις και την πρόβλεψη στόχου.

Στην παρούσα εργασία θα εξεταστούν μόνο τα στατιστικά μοντέλα προβλέψεων και πιο συγκεκριμένα τα μοντέλα χρονοσειρών. Απαραίτητη προϋπόθεση εφαρμογής των μοντέλων αυτών είναι αφενός η ποσοτικοποίηση της δοθείσας πληροφορίας με την μορφή αριθμητικών δεδομένων και αφετέρου η ύπαρξη μεγάλου όγκου ιστορικών δεδομένων προκειμένου να είναι δυνατή η επιλογή του καλύτερου προτύπου συμπεριφοράς, ενώ παράλληλα βασίζονται στην υπόθεση ότι η μεταβολή της τιμής του μεγέθους που εξετάζεται ακολουθεί ένα πρότυπο που επαναλαμβάνεται στο χρόνο και παραμένει σταθερό. Μία αναλυτική βιβλιογραφική ανασκόπηση, εγκυκλοπαιδικής φύσης, του κλάδου των προβλέψεων χρονοσειρών έχει πραγματοποιηθεί από τους Petropoulos et al. (2022).

Στο παρόν Κεφάλαιο γίνεται μια εισαγωγή στα μοντέλα πρόβλεψης και παρουσιάζονται τα βασικά στατιστικά μοντέλα που χρησιμοποιούνται για την πρόβλεψη χρονοσειρών συνεχούς ζήτησης και τα πιο ευρέως διαδεδομένα για χρονοσειρές διακοπόμενης ζήτησης. Στα Υποκεφάλαια 4.1 και 4.2 αναλύονται μοντέλα τα οποία παράγουν σημειακές προβλέψεις, τα οποία θα χρησιμοποιηθούν στη συνέχεια της παρούσας διατριβής, ενώ στο Υποκεφάλαιο 4.3 παρουσιάζεται μία άλλη κατηγορία στατιστικών μοντέλων, τα πιθανοτικά, τα οποία έχουν έναν διαφορετικό τρόπο διαχείρισης των δεδομένων και έχει αξία να αναφερθούν καθώς, έστω και σποραδικά, συναντώνται στον κλάδο της διαχείρισης αποθεμάτων.

## 4.1 Διαδεδομένες τεχνικές πρόβλεψης χρονοσειρών συνεχούς ζήτησης

### 4.1.1 Απλοϊκή μέθοδος (Naive)

Η Naive αποτελεί την πιο απλή μέθοδο πρόβλεψης χρονοσειρών, κατά την οποία ως πρόβλεψη για την επόμενη χρονική περίοδο δίνεται η αμέσως προηγούμενη παρατήρηση που είναι διαθέσιμη, ως εξής:

$$F_t = Y_{t-1},$$

όπου  $F_t$  η προβλέπόμενη τιμή την περίοδο  $t$  και  $Y_t$  η πραγματική τιμή της χρονοσειράς την περίοδο  $t$ .

Στην ουσία γίνεται μια υπόθεση ότι το μέλλον θα ταυτίζεται πάντα με το παρόν, χωρίς να λαμβάνονται υπόψη πιθανές διακυμάνσεις στο επίπεδο ή την τάση της χρονοσειράς, με αποτέλεσμα να πραγματοποιεί συνήθως προβλέψεις χαμηλής ακρίβειας.

Παραλλαγή της Naive είναι η Naive2, ή εποχιακή Naive (Seasonal Naive - SNaive), κατά την οποία η Naive εφαρμόζεται επί των αποεποχικοποιημένων δεδομένων προκειμένου να ληφθεί υπόψη η εποχιακότητα.

### 4.1.2 Μέθοδοι μέσων όρων

#### Απλός μέσος όρος

Η μέθοδος του απλού μέσου όρου στην ουσία είναι η εύρεση το μέσου όρου όλων των παρατηρήσεων της σειράς και η χρήση αυτής της τιμής για πρόβλεψη. Η πρόβλεψη, έτσι, δίνεται ως εξής:

$$F_{t+1} = \frac{1}{t} \sum_{i=1}^t Y_i$$

Η χρήση της συγκεκριμένης μεθόδου ενδείκνυται για περιπτώσεις που οι παρατηρήσεις δεν παρουσιάζουν τάση ή αξιοπρόσεκτη εποχιακότητα.

#### Κινητός μέσος όρος

Ένας τρόπος να διαχειριστεί η επιρροή των παρελθουσών παρατηρήσεων στην πρόβλεψη όταν έχει επιλεγθεί ως μέθοδος πρόβλεψης η μέθοδος του κινητού μέσου είναι να καθοριστεί το πλήθος των παρατηρήσεων που θα ληφθούν υπ' όψη στην εξαγωγή της πρόβλεψης.

Ο όρος κινητός μέσος όρος χρησιμοποιείται για να περιγράψει αυτή τη διαδικασία καθώς όταν μία νέα παρατήρηση γίνεται διαθέσιμη, τότε υπολογίζεται ο νέος μέσος όρος των τελευταίων παρατηρήσεων του συγκεκριμένου μήκους που έχει επιλεγθεί. Αυτός ο νέος μέσος όρος είναι η τιμή της πρόβλεψης που παράγεται από αυτήν την μέθοδο για την επόμενη χρονική περίοδο. Είναι σημαντικό να τονιστεί ότι το πλήθος των παρατηρήσεων που χρησιμοποιούνται για την εξαγωγή του μέσου όρου παραμένει σταθερό καθ' όλη τη διαδικασία πρόβλεψης και περιλαμβάνει πάντα τις πιο πρόσφατες παρατηρήσεις. Η σχέση που χρησιμοποιείται για την εφαρμογή της μεθόδου του κινητού μέσου όρου, ο οποίος



συμβολίζεται και ως MA(k) (Moving Average of length k), είναι η εξής:

$$F_{t+1} = \frac{1}{k} \sum_{i=t-k+1}^t Y_i$$

### 4.1.3 Απλή γραμμική παλινδρόμηση (Simple linear regression)

Η απλή γραμμική παλινδρόμηση υποθέτει την εξάρτηση μιας μεταβλητής  $Y$  από μία ανεξάρτητη μεταβλητή  $X$  σύμφωνα με τον τύπο:

$$Y = a + bX + e,$$

όπου  $a$  είναι το αρχικό σημείο ( $X = 0$ ),  $b$  η κλίση της ευθείας και  $e$  το σφάλμα, δηλαδή η απόκλιση της ευθείας από τις παρατηρήσεις.

Στόχος της συγκεκριμένης μεθόδου είναι η εκτίμηση των  $a$  και  $b$  προκειμένου η ευθεία  $Y = a + bX$  να προσαρμόζεται όσο το δυνατόν καλύτερα στις παρατηρήσεις. Το σφάλμα ( $e$ ) αποτελεί σε κάθε περίοδο  $t$  την κατακόρυφη απόκλιση της παρατήρησης από την ευθεία, δηλαδή:

$$e_t = Y_t - F_t$$

Ως βέλτιστη ευθεία, επιλέγεται εκείνη για την οποία το άθροισμα των τετραγώνων των σφαλμάτων ελαχιστοποιείται. Η μέθοδος αυτή είναι γνωστή ως μέθοδος των ελαχίστων τετραγώνων και δίνεται από τη σχέση:

$$\sum_{i=1}^n e_i^2 = \sum_{i=1}^n (Y_i - F_i)^2 = \sum_{i=1}^n (Y_i - a - bX_i)^2$$

Κατά συνέπεια οι παράμετροι  $a$  και  $b$  μπορούν να υπολογιστούν ως εξής:

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

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

Σε πολλές περιπτώσεις, ωστόσο, είναι πιθανό στα δεδομένα να εφαρμόζεται καλύτερα κάποιας άλλης μορφής συνάρτηση, όπως είναι η παραβολή ή η λογαριθμική, ή η μεταβλητή  $Y$  να εξαρτάται από περισσότερες από μία ανεξάρτητες μεταβλητές ( $X_1, X_2, \dots, X_n$ ). Σε αυτές τις περιπτώσεις ακολουθείται παρόμοια διαδικασία υπολογισμού των επιμέρους παραμέτρων με την απλή γραμμική παλινδρόμηση, κάνοντας χρήση της μεθόδου των ελαχίστων τετραγώνων.

### 4.1.4 Μοντέλα εκθετικής εξομάλυνσης

Τα μοντέλα εκθετικής εξομάλυνσης παρά το γεγονός ότι πρωτοεμφανίστηκαν τη δεκαετία του '50 (Brown, 1959; Holt, 1957; Winters, 1960), παρέχουν αρκετά ικανοποιητική ακρίβεια σε σχέση με άλλα πιο σύνθετα και σύγχρονα μοντέλα προβλέψεων. Τα συγκεκριμένα μοντέλα στην ουσία αποτελούν σταθμισμένους κινητούς μέσους όρους, με βάρη τα οποία φθίνουν εκθετικά και το συγκριτικό τους πλεονέκτημα

οφείλεται κυρίως στο γεγονός ότι αποσυνθέτουν τη χρονοσειρά στις βασικές της συνιστώσες, καθεμία εκ των οποίων εξομαλύνεται και επαναπροσδιορίζεται καθώς περνά ο χρόνος.

#### 4.1.4.1 Απλή εκθετική εξομάλυνση (Simple exponential smoothing)

Η μέθοδος SES αποτελεί την απλούστερη περίπτωση των μοντέλων εκθετικής εξομάλυνσης. Το μοντέλο σταθερού επιπέδου, όπως επίσης αποκαλείται, που βασικό του χαρακτηριστικό είναι η υπόθεση απουσίας τάσης από την χρονοσειρά, αποδίδει καλύτερα σε περιπτώσεις στάσιμων χρονοσειρών, χωρίς παρουσία εποχιακότητας, και περιγράφεται από τις παρακάτω εξισώσεις:

$$\begin{aligned}e_t &= Y_t - F_t \\l_t &= \alpha Y_t + (1 - \alpha)l_{t-1} \\F_{t+h} &= l_t,\end{aligned}$$

όπου  $e_t$  είναι το σφάλμα της πρόβλεψης την περίοδο  $t$ ,  $l_t$  είναι το επίπεδο της χρονοσειράς στο τέλος της περιόδου  $t$  και  $\alpha$  ο συντελεστής εξομάλυνσης, ο οποίος λαμβάνει τιμές από 0 έως 1.

Για κάθε  $\alpha$  μεταξύ 0 και 1 στις παραπάνω εξισώσεις, όσο κινούμαστε προς τα πίσω ( $t - 1, t - 2, t - 3, \dots$ ) τα βάρη των παρατηρήσεων μικραίνουν εκθετικά, εξού και η ονομασία εκθετική εξομάλυνση. Στην περίπτωση όπου το  $\alpha$  είναι κοντά στο 0, περισσότερο βάρος δίνεται από την συγκεκριμένη μέθοδο στις παρατηρήσεις του μακρινού παρελθόντος, ενώ στην περίπτωση όπου το  $\alpha$  είναι κοντά στο 1, περισσότερο βάρος δίνεται στο πιο πρόσφατο παρελθόν. Στην ακραία περίπτωση όπου  $\alpha = 1$  οι προβλέψεις της SES ταυτίζονται με αυτές τις Naïve, ενώ όταν  $\alpha = 0$  οι προβλεπόμενες τιμές ισούνται όλες με το αρχικό επίπεδο της χρονοσειράς ( $l_0$ ). Σύμφωνα με τον Silver et al. (1998), όταν οι προβλέψεις πραγματοποιούνται σε μηνιαία βάση, ο συντελεστής εξομάλυνσης πρέπει να παίρνει τιμές μεταξύ 0.1 και 0.3.

Επομένως, προκειμένου να εφαρμοστεί η απλή εκθετική εξομάλυνση, είναι απαραίτητο να οριστούν οι τιμές του συντελεστή εξομάλυνσης ( $\alpha$ ) και το αρχικό επίπεδο ( $l_0$ ), οι οποίες μπορούν είτε να επιλεγθούν αυθαίρετα είτε να υπολογιστούν χρησιμοποιώντας τις διαθέσιμες παρατηρήσεις της χρονοσειράς και τη μέθοδο των ελαχίστων τετραγώνων. Σε αντίθεση με την απλή γραμμική παλινδρόμηση, όπου οι βέλτιστες παράμετροι μπορούν να υπολογιστούν από συγκεκριμένες εξισώσεις, στην περίπτωση της SES η διαδικασία αυτή αποτελεί ένα μη γραμμικό πρόβλημα ελαχιστοποίησης.

#### 4.1.4.2 Εκθετική εξομάλυνση με τάση

Όπως αναφέρθηκε, η απλή εκθετική εξομάλυνση δίνει μία σταθερή πρόβλεψη για κάθε μελλοντική περίοδο  $t$ , με αποτέλεσμα η συγκεκριμένη μέθοδος να μην μπορεί να αποτυπώσει την τάση των παρατηρήσεων μιας χρονοσειράς. Για το λόγο αυτό αναπτύχθηκαν μέθοδοι εκθετικής εξομάλυνσης που επεκτείνουν την SES εισάγοντας στις προβλέψεις το χαρακτηριστικό της τάσης της εκάστοτε χρονοσειράς.

##### Εκθετική εξομάλυνση γραμμικής τάσης (Holt exponential smoothing)

Η μέθοδος εκθετικής εξομάλυνσης γραμμικής τάσης, θεωρητικά, μπορεί να δώσει καλύτερες προβλέψεις από την SES, δεδομένου ότι προσαρμόζεται ταυτόχρονα τόσο στο επίπεδο της χρονοσειράς όσο και στην τάση αυτής. Η μέθοδος Holt (1957), έτσι, μοιάζει αρκετά με τη μέθοδο της απλής γραμμικής παλινδρόμησης, με τη διαφορά ότι επαναπροσδιορίζει συνεχώς τις τιμές της δίνοντας όλο και μεγαλύτερη έμφαση στις πιο πρόσφατες παρατηρήσεις, με την τελική πρόβλεψη να είναι στην ουσία το άθροισμα της τρέχουσας τάσης και του τρέχοντος επιπέδου της χρονοσειράς. Το συγκεκριμένο μοντέλο περιγράφεται από τις παρακάτω εξισώσεις:

$$\begin{aligned}l_t &= a Y_t + (1 - a)(l_{t-1} + b_{t-1}) \\b_t &= b(l_t - l_{t-1}) + (1 - b)b_{t-1} \\F_{t+h} &= l_t + h b_t,\end{aligned}$$

όπου  $l_t$  είναι το επίπεδο της χρονοσειράς στο τέλος της περιόδου  $t$ ,  $b_t$  η τάση,  $h$  ο χρονικός ορίζοντας της πρόβλεψης και  $a, b$  οι συντελεστές εξομάλυνσης, που λαμβάνουν τιμές από 0 έως 1.

#### **Εκθετική εξομάλυνση μη γραμμικής τάσης (Damped)**

Η μέθοδος εκθετικής εξομάλυνσης μη γραμμικής τάσης αποτελεί προέκταση της μεθόδου Holt, που παρουσιάστηκε παραπάνω, η οποία προσπαθεί να περιγράψει χρονοσειρές που παρουσιάζουν μεταβαλλόμενη τάση (Gardner Jr, 1985; Gardner Jr & McKenzie, 1989). Αυτό επιτυγχάνεται μέσω της παραμέτρου διόρθωσης τάσης  $\phi$ . Έχει διαπιστωθεί ότι η Damped παράγει πιο ακριβή αποτελέσματα τόσο από τη SES όσο και από τη Holt, ιδιαίτερα σε περιπτώσεις όπου δεν είναι εύκολος ο εντοπισμός του μοτίβου τάσης που ακολουθεί μία χρονοσειρά. Ένα επιπρόσθετο πλεονέκτημα της συγκεκριμένης μεθόδου είναι ότι, σε αντίθεση με τις άλλες δύο μεθόδους εκθετικής εξομάλυνσης που αναφέρθηκαν, μπορεί να δώσει πολύ καλύτερες προβλέψεις και σε μακροπρόθεσμο επίπεδο καθώς αναθεωρεί συστηματικά τόσο το επίπεδο όσο και τον ρυθμό ανάπτυξης της χρονοσειράς. Οι εξισώσεις που περιγράφουν το συγκεκριμένο μοντέλο είναι οι εξής:

$$\begin{aligned}l_t &= a Y_t + (1 - a)(l_{t-1} + \phi b_{t-1}) \\b_t &= b(l_t - l_{t-1}) + (1 - b)\phi b_{t-1} \\F_{t+h} &= l_t + \sum_{i=1}^h \phi^i b_t\end{aligned}$$

Όπως φαίνεται οι εξισώσεις της Damped είναι όμοιες με αυτές της Holt, με μόνη διαφοροποίηση την παράμετρο  $\phi$ , η οποία προκαλεί μη γραμμικό υπολογισμό της πρόβλεψης  $F$ , σε αντίθεση με την Holt όπου η τάση αυξανόταν γραμμικά σε κάθε περίοδο. Ανάλογα τη τιμή του  $\phi$  μπορούν να προσεγγιστούν διαφορετικού μοτίβου χρονοσειρές, αυξανόμενης τάσης, σταθερού επιπέδου αλλά και φθίνουσας τάσης. Πιο συγκεκριμένα, για  $0 < \phi < 1$  προκύπτει φθίνουσα τάση και το μέγεθος κατά το οποίο αυξάνει η τιμή των προβλέψεων μικραίνει κάθε χρονική περίοδο, ενώ για  $\phi > 1$  προκύπτει εκθετική τάση και το μέγεθος κατά το οποίο αυξάνει η τιμή των προβλέψεων μεγαλώνει κάθε φορά. Τέλος, για  $\phi = 0$  πραγματοποιείται εφαρμογή της μεθόδου SES, ενώ για  $\phi = 1$  εφαρμογή της μεθόδου

γραμμικής τάσης. Συνήθως επιλέγονται τιμές στο διάστημα [0.8, 0.98].

#### 4.1.4.3 Εκθετική εξομάλυνση με εποχιακότητα

Ο Holt (1957) και ο Winters (1960) επέκτειναν τη μέθοδο εκθετικής εξομάλυνσης γραμμικής τάσης ώστε να αποτυπώνει και την εποχιακότητα μιας χρονοσειράς. Η εποχιακή μέθοδος Holt-Winters, έτσι, αποτελείται από την εξίσωση της πρόβλεψης και τρεις εξισώσεις εξομάλυνσης, μία για το επίπεδο ( $l_t$ ), μία για την τάση ( $b_t$ ) και μία για την εποχιακότητα ( $s_t$ ), με τις αντίστοιχες παραμέτρους εξομάλυνσης ( $a, b, \gamma$ ). Επίσης, χρησιμοποιείται η μεταβλητή  $n$  για να προσδιορίσει τη συχνότητα της εποχιακότητας, δηλαδή το πλήθος των περιόδων σε ένα έτος. Έτσι, για παράδειγμα, για μηνιαία δεδομένα χρησιμοποιείται  $n = 12$  και για τριμηνιαία  $n = 4$ .

Υπάρχουν δύο παραλλαγές της συγκεκριμένης μεθόδου, το προσθετικό και το πολλαπλασιαστικό μοντέλο, τα οποία διαφέρουν ως προς τη φύση του εποχιακού στοιχείου. Το προσθετικό μοντέλο προτιμάται όταν οι εποχιακές διακυμάνσεις είναι περίπου σταθερές σε όλη τη σειρά, ενώ το πολλαπλασιαστικό προτιμάται όταν οι εποχιακές διακυμάνσεις αλλάζουν ανάλογα με το επίπεδο της χρονοσειράς.

##### Προσθετικό μοντέλο Holt-Winters

Το συγκεκριμένο μοντέλο περιγράφεται από τις παρακάτω εξισώσεις:

$$\begin{aligned}l_t &= a(Y_t - s_{t-n}) + (1 - a)(l_{t-1} + b_{t-1}) \\b_t &= b(l_t - l_{t-1}) + (1 - b)b_{t-1} \\s_t &= \gamma(Y_t - l_{t-1} - b_{t-1}) + (1 - \gamma)s_{t-n} \\F_{t+h} &= l_t + h b_t + s_{t+h-n(k+1)},\end{aligned}$$

όπου  $n$  η εποχιακή περίοδος

##### Πολλαπλασιαστικό μοντέλο Holt-Winters

Το συγκεκριμένο μοντέλο περιγράφεται από τις παρακάτω εξισώσεις:

$$\begin{aligned}l_t &= a \frac{Y_t}{s_{t-n}} + (1 - a)(l_{t-1} + b_{t-1}) \\b_t &= b(l_t - l_{t-1}) + (1 - b)b_{t-1} \\s_t &= \gamma \frac{Y_t}{l_{t-1} + b_{t-1}} + (1 - \gamma)s_{t-n} \\F_{t+h} &= (l_t + h b_t) s_{t+h-n(k+1)}\end{aligned}$$

##### Damped μοντέλο Holt-Winters

Επίσης, μπορεί να εφαρμοστεί μείωση της τάσης (“damping”) μέσω της παραμέτρου  $\phi$  για το προσθετικό και το πολλαπλασιαστικό μοντέλο. Μια αρκετά δημοφιλής επιλογή για πρόβλεψη εποχιακών χρονοσειρών αποτελεί η Holt-Winters με μη γραμμική τάση και πολλαπλασιαστική εποχιακότητα. Το συγκεκριμένο μοντέλο περιγράφεται από τις παρακάτω

εξισώσεις:

$$l_t = \alpha \frac{Y_t}{s_{t-n}} + (1 - \alpha)(l_{t-1} + \phi b_{t-1})$$

$$b_t = b(l_t - l_{t-1}) + (1 - b)\phi b_{t-1}$$

$$s_t = \gamma \frac{Y_t}{l_{t-1} + \phi b_{t-1}} + (1 - \gamma)s_{t-n}$$

$$F_{t+h} = (l_t + \sum_{i=1}^h \phi^i b_t) s_{t+h-n(k+1)}$$

#### 4.1.5 Μέθοδος ETS (Error/Trend/Seasonality)

Οι διάφορες μέθοδοι εκθετικής εξομάλυνσης μπορούν να μοντελοποιήσουν χρονοσειρές με γραμμική, προσθετική, πολλαπλασιαστική, damped, πολλαπλασιαστική damped ή χωρίς τάση και με προσθετική, πολλαπλασιαστική ή χωρίς εποχιακότητα. Για κάθε ζευγάρι, έτσι, των διαφορετικών μορφών που παίρνουν τα χαρακτηριστικά της τάσης και της εποχιακότητας, μπορεί να επιλεγθεί και το κατάλληλο μοντέλο εκθετικής εξομάλυνσης. Μπορούν να προκύψουν 15 συνδυασμοί των διαφόρων χαρακτηριστικών της εκάστοτε χρονοσειράς, άρα και 15 μοντέλα εκθετικής εξομάλυνσης (5 μορφές τάσης και 3 μορφές εποχιακότητας), όπως φαίνεται στους Πίνακες 4.1 και 4.2. Η συγκεκριμένη κατηγοριοποίηση προτάθηκε από τον Pegels (1969) και επεκτάθηκε από τους Gardner Jr (1985) και Taylor (2003). Τα λιγότερο χρησιμοποιούμενα μοντέλα είναι εκείνα που θεωρούν ότι η τάση είναι πολλαπλασιαστική, καθώς σπάνια συναντώνται χρονοσειρές με το συγκεκριμένο χαρακτηριστικό με αποτέλεσμα να δίνεται μεγαλύτερη έμφαση στις τρεις πρώτες γραμμές του πίνακα.

Πίνακας 4.1: Μοντέλα εκθετικής εξομάλυνσης βάσει τάσης και εποχιακότητας.

Τάση (T)	Εποχιακότητα (S)		
	Χωρίς	Προσθετική	Πολλαπλ/κή
Χωρίς	SES	Όχι T, Προσθετική S	Όχι T, Πολλαπλ/κή S
Προσθετική	Holt	Προσθετική Holt-Winters	Πολλαπλ/κή Holt-Winters
Προσθετική Damped	Προσθετική Damped T	Damped T, Προσθετική S	Damped Holt-Winters
Πολλαπλ/κή	Πολλαπλ/ική T, Όχι S	Πολλαπλ/ική T, Προσθετική S	Πολλαπλ/ική T, Πολλαπλ/ική S
Πολλαπλ/κή Damped	Πολλαπλ/ική Damped T, Όχι S	Πολλαπλ/ική Damped T, Προσθετική S	Πολλαπλ/ική Damped T, Πολλαπλ/ική S

Στηριζόμενοι στα παραπάνω, οι Hyndman et al. (2008) παρουσίασαν τη μέθοδο Exponential Smoothing State Space Model ή αλλιώς ETS (Error-Trend-Seasonality), η οποία επεκτείνει τις μεθόδους εκθετικής εξομάλυνσης που αναφέρθηκαν, με μια συνιστώσα σφάλματος  $\epsilon_t$  η οποία προστίθεται στις υφιστάμενες εξισώσεις επιπέδου, τάσης και

Πίνακας 4.2: Κωδικοποίηση μοντέλων εκθετικής εξομάλυνσης.

Τάση (T)	Εποχιακότητα (S)		
	N (None)	A (Additive)	M (Multiplicative)
N (None)	N,N	N,A	N,M
A (Additive)	A,N	A,A	A,M
Ad (Additive damped)	Ad,N	Ad,A	Ad,M
M (Multiplicative)	M,N	M,A	M,M
Md (Multiplicative damped)	Md,N	Md,A	Md,M

Πίνακας 4.3: Μοντέλα ETS με αθροιστικό σφάλμα  $\epsilon_t$ .

Τάση (T)	Εποχιακότητα (S)		
	Χωρίς	Προσθετική	Πολλαπλ/κή
Χωρίς	$Y_t = l_{t-1} + \epsilon_t$ $l_t = l_{t-1} + a\epsilon_t$	$Y_t = l_{t-1} + s_{t-m} + \epsilon_t$ $l_t = l_{t-1} + a\epsilon_t$ $s_t = s_{t-m} + \gamma\epsilon_t$	$Y_t = l_{t-1}s_{t-m} + \epsilon_t$ $l_t = l_{t-1} + a\epsilon_t/s_{t-m}$ $s_t = s_{t-m} + \gamma\epsilon_t/l_{t-1}$
Προσθετική	$Y_t = l_{t-1} + b_{t-1} + \epsilon_t$ $l_t = l_{t-1} + b_{t-1} + a\epsilon_t$ $b_t = b_{t-1} + b\epsilon_t$	$Y_t = l_{t-1} + b_{t-1} + s_{t-m} + \epsilon_t$ $l_t = l_{t-1} + b_{t-1} + a\epsilon_t$ $b_t = b_{t-1} + b\epsilon_t$ $s_t = s_{t-m} + \gamma\epsilon_t$	$Y_t = (l_{t-1} + b_{t-1})s_{t-m} + \epsilon_t$ $l_t = l_{t-1} + b_{t-1} + a\epsilon_t/s_{t-m}$ $b_t = b_{t-1} + b\epsilon_t/s_{t-m}$ $s_t = s_{t-m} + \gamma\epsilon_t/(l_{t-1} + b_{t-1})$
Προσθετική Damped	$Y_t = l_{t-1} + \phi b_{t-1} + \epsilon_t$ $l_t = l_{t-1} + \phi b_{t-1} + a\epsilon_t$ $b_t = \phi b_{t-1} + b\epsilon_t$	$Y_t = l_{t-1} + \phi b_{t-1} + s_{t-m} + \epsilon_t$ $l_t = l_{t-1} + \phi b_{t-1} + a\epsilon_t$ $b_t = \phi b_{t-1} + b\epsilon_t$ $s_t = s_{t-m} + \gamma\epsilon_t$	$Y_t = (l_{t-1} + \phi b_{t-1})s_{t-m} + \epsilon_t$ $l_t = l_{t-1} + \phi b_{t-1} + a\epsilon_t/s_{t-m}$ $b_t = \phi b_{t-1} + b\epsilon_t/s_{t-m}$ $s_t = s_{t-m} + \gamma\epsilon_t/(l_{t-1} + \phi b_{t-1})$

εποχιακότητας. Η συνιστώσα  $\epsilon_t$  μπορεί να σχετίζεται με τόσο με προσθετικό όσο και με πολλαπλασιαστικό τρόπο με τις υπόλοιπες συνιστώσες, με αποτέλεσμα η ETS να περιλαμβάνει  $2 \cdot 15 = 30$  μεθόδους πρόβλεψης εκθετικής εξομάλυνσης.

Στον Πίνακα 4.3 παρουσιάζονται τα μοντέλα εκθετικής εξομάλυνσης προσθετικού σφάλματος της συγκεκριμένης μεθόδου, ενώ παραλείπονται τα μοντέλα πολλαπλασιαστικής τάσης, για τους λόγους που αναφέρθηκαν παραπάνω, ενώ τα αντίστοιχα μοντέλα πολλαπλασιαστικού σφάλματος παρουσιάζονται στον Πίνακα 4.4.

Ένα σημαντικό πλεονέκτημα της μεθόδου ETS είναι πως η επιλογή του κατάλληλου μοντέλου μπορεί να γίνει με αυτόματο τρόπο, μέσω της ελαχιστοποίησης κριτηρίων πληροφορίας όπως τα AIC - Akaike information criterion (Akaike et al., 1973), AIC<sub>C</sub> -

Πίνακας 4.4: Μοντέλα ETS με πολλαπλασιαστικό σφάλμα  $\epsilon_t$ .

Τάση (T)	Εποχιακότητα (S)		
	Χωρίς	Προσθετική	Πολλαπλ/κή
Χωρίς	$Y_t = l_{t-1}(1 + \epsilon_t)$ $l_t = l_{t-1}(1 + a\epsilon_t)$	$Y_t = (l_{t-1} + s_{t-m})(1 + \epsilon_t)$ $l_t = l_{t-1} + a(l_{t-1} + s_{t-m})\epsilon_t$ $s_t = s_{t-m} + \gamma(l_{t-1} + s_{t-m})\epsilon_t$	$Y_t = l_{t-1}s_{t-m}(1 + \epsilon_t)$ $l_t = l_{t-1}(1 + a\epsilon_t)$ $s_t = s_{t-m}(1 + \gamma\epsilon_t)$
Προσθετική	$Y_t = (l_{t-1} + b_{t-1})(1 + \epsilon_t)$ $l_t = (l_{t-1} + b_{t-1})(1 + a\epsilon_t)$ $b_t = b_{t-1} + b(l_{t-1} + b_{t-1})\epsilon_t$	$Y_t = (l_{t-1} + b_{t-1} + s_{t-m})(1 + \epsilon_t)$ $l_t = l_{t-1} + b_{t-1} + a(l_{t-1} + b_{t-1} + s_{t-m})\epsilon_t$ $b_t = b_{t-1} + b(l_{t-1} + b_{t-1} + s_{t-m})\epsilon_t$ $s_t = s_{t-m} + \gamma(l_{t-1} + b_{t-1} + s_{t-m})\epsilon_t$	$Y_t = (l_{t-1} + b_{t-1})s_{t-m}(1 + \epsilon_t)$ $l_t = (l_{t-1} + b_{t-1})(1 + a\epsilon_t)$ $b_t = b_{t-1} + b(l_{t-1} + b_{t-1})\epsilon_t$ $s_t = s_{t-m}(1 + \gamma\epsilon_t)$
Προσθετική Damped	$Y_t = (l_{t-1} + \phi b_{t-1})(1 + \epsilon_t)$ $l_t = (l_{t-1} + \phi b_{t-1})(1 + a\epsilon_t)$ $b_t = \phi b_{t-1} + b(l_{t-1} + \phi b_{t-1})\epsilon_t$	$Y_t = (l_{t-1} + \phi b_{t-1} + s_{t-m})(1 + \epsilon_t)$ $l_t = l_{t-1} + \phi b_{t-1} + a(l_{t-1} + \phi b_{t-1} + s_{t-m})\epsilon_t$ $b_t = b_{t-1} + b(l_{t-1} + \phi b_{t-1} + s_{t-m})\epsilon_t$ $s_t = s_{t-m} + \gamma(l_{t-1} + \phi b_{t-1} + s_{t-m})\epsilon_t$	$Y_t = (l_{t-1} + \phi b_{t-1})s_{t-m}(1 + \epsilon_t)$ $l_t = (l_{t-1} + \phi b_{t-1})(1 + a\epsilon_t)$ $b_t = b_{t-1} + b(l_{t-1} + \phi b_{t-1})\epsilon_t$ $s_t = s_{t-m}(1 + \gamma\epsilon_t)$

corrected Akaike information criterion και  $BIC$  - Bayesian information criterion (Schwarz, 1978), τα οποία ορίζονται ως εξής:

$$\begin{aligned} AIC &= -2 \log L + 2k, \\ AIC_C &= AIC + 2 \frac{k(k+1)}{T-k-1}, \text{ και} \\ BIC &= AIC + k(\log T - 2), \end{aligned}$$

όπου  $L$  η πιθανοφάνεια του μοντέλου και  $k$  ο συνολικός αριθμός παραμέτρων και αρχικών καταστάσεων που έχουν εκτιμηθεί, με:

$$L = n \log \left( \sum_{t=1}^n \frac{e_t^2}{kx_{t-1}^2} \right) + 2 \sum_{t=1}^n \log |kx_{t-1}|.$$

#### 4.1.6 Μέθοδος $\theta$ (Theta method)

Η μέθοδος Theta ( $\theta$ ) αποτελεί μια στατιστική μέθοδο προβλέψεων που αναπτύχθηκε στη Μονάδα Προβλέψεων και Στρατηγικής της Σχολής Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών του Ε.Μ.Π. και βασίζεται σε μια διαφορετική προσέγγιση της αποσύνθεσης. Η συγκεκριμένη μέθοδος πρόβλεψης δημιουργήθηκε από τους Assimakopoulos & Nikolopoulos (2000) και βασίζεται στη μεταβολή των τοπικών καμπυλοτήτων μιας χρονοσειράς μέσα από μία παράμετρο  $\theta$ , η οποία εφαρμόζεται απευθείας (πολλαπλασιαστικά) στις διαφορές δεύτερης τάξης των παρατηρήσεων κάθε χρονοσειράς. Η καινούργια χρονοσειρά που δημιουργείται διατηρεί την μέση τιμή και κλίση (παλινδρόμησης) της αρχικής χρονοσειράς αλλά όχι και τις τοπικές καμπυλότητες. Οι χρονοσειρές που παράγονται με αυτή την διαδικασία ονομάζονται γραμμές  $\theta$  (Theta Lines) και υπολογίζονται ως εξής:

$$Y_t^\theta = \theta Y_t'' = \theta(Y_t - 2Y_{t-1} + Y_{t-2}).$$

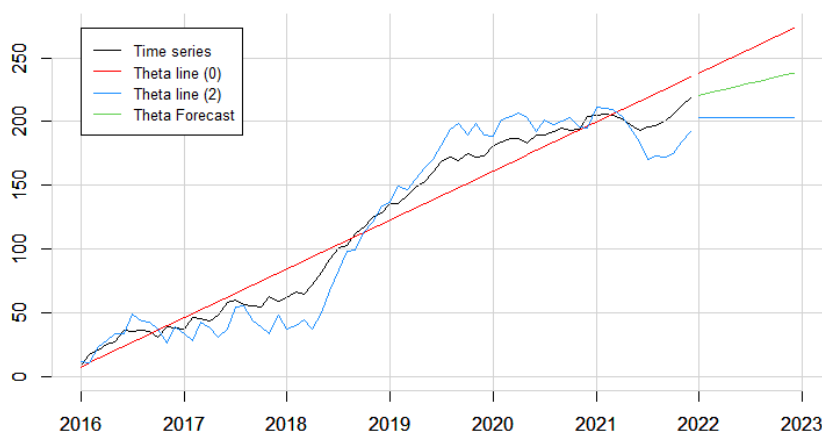
Όπως περιγράφουν οι Πετρόπουλος & Ασημακόπουλος (2011), εάν οι τοπικές καμπυλότητες υποβαθμιστούν σταδιακά, τότε η χρονοσειρά που προκύπτει είναι “ξεφουσκωμένη”. Όσο μικρότερη είναι η τιμή της παραμέτρου  $\theta$  τόσο μεγαλύτερος είναι ο βαθμός μείωσης των καμπυλοτήτων, με τη χρονοσειρά που προκύπτει από την οριακή τιμή  $\theta = 0$  να ισοδυναμεί με την ευθεία της απλής γραμμικής παλινδρόμησης. Η παράμετρος  $\theta$  μπορεί να πάρει και αρνητικές τιμές, με τη χρονοσειρά που προκύπτει από την τιμή  $\theta = -1$  να αντιστοιχεί στη συμμετρική της αρχικής χρονοσειράς ως προς την ευθεία της γραμμικής παλινδρόμησης. Αντίθετα, εάν οι τοπικές καμπυλότητες ενισχυθούν σταδιακά, τότε η χρονοσειρά που προκύπτει είναι “διογκωμένη”, γεγονός που επιτυγχάνεται για τιμές  $\theta > 1$ .

Η συγκεκριμένη μέθοδος αποσυνθέτει την αρχική χρονοσειρά σε δύο ή περισσότερες γραμμές  $\theta$  και κάθε μία από αυτές προεκτείνεται ξεχωριστά συνδυάζοντας στο τέλος τις προβλέψεις. Η προέκταση αυτή μπορεί να γίνει με την ίδια ή διαφορετικές μεθόδους πρόβλεψης, ενώ μπορεί επίσης να γίνει συνδυασμός γραμμών  $\theta$  για διαφορετικό ορίζοντα

πρόβλεψης. Ένα απλό παράδειγμα της διαδικασίας αυτής είναι το εξής:

$$Y_t = \frac{1}{2}(Y_t^{\theta=0} + Y_t^{\theta=2}),$$

όπου  $Y_t^{\theta=0}$  είναι η τιμή της γραμμής  $\theta$  με παράμετρο 0 για την περίοδο  $t$  και  $Y_t^{\theta=2}$  είναι η τιμή της γραμμής  $\theta$  με παράμετρο 2 για την περίοδο  $t$ , οι οποίες συνήθως προεκτείνονται μέσω της απλής γραμμικής παλινδρόμησης και της απλής εκθετικής εξομάλυνσης, όπως αυτές αναλύθηκαν στα προηγούμενα Κεφάλαια, αντίστοιχα. Ο συνδυασμός των δύο παραγόμενων προβλέψεων δίνει την τελική πρόβλεψη της μεθόδου  $\theta$ , όπως φαίνεται στο Σχήμα 4.1.



Σχήμα 4.1: Διαδικασία πρόβλεψης της κλασσικής μεθόδου  $\theta$ , κάνοντας χρήση δύο γραμμών με παραμέτρους  $\theta = 0$  και  $\theta = 2$ .

Τα βήματα που ακολουθούνται για την παραγωγή προβλέψεων με τη κλασσική μέθοδο  $\theta$  συνοψίζονται παρακάτω:

1. **Έλεγχος εποχιακότητας:** Κάθε χρονοσειρά ελέγχεται για στατιστικά σημαντική εποχιακή συμπεριφορά.
2. **Αποεποχικοποίηση:** Η χρονοσειρά αποεποχικοποιείται με την κλασσική μέθοδο πολλαπλασιαστικής αποσύνθεσης.
3. **Αποσύνθεση:** Κάθε χρονοσειρά αποσυντίθεται σε δύο γραμμές  $\theta$ , με  $\theta = 0$  και  $\theta = 2$ .
4. **Πρόβλεψη:** Η γραμμή  $\theta = 0$  προεκτείνεται με απλή γραμμική παλινδρόμηση (LRL) ενώ η γραμμή  $\theta = 2$  με απλή εκθετική εξομάλυνση (SES).
5. **Συνδυασμός:** Οι προηγούμενες προβλέψεις συνδυάζονται με ίσα βάρη.
6. **Εποχικοποίηση:** Οι τελικές προβλέψεις εποχικοποιούνται, χρησιμοποιώντας τους δείκτες εποχιακότητας του δεύτερου βήματος. Σε περίπτωση που η χρονοσειρά δεν είχε κριθεί εποχιακή στο πρώτο βήμα το εν λόγω στάδιο παραλείπεται.



Οι Hyndman & Billah (2003) προσπάθησαν να αποδείξουν ότι η κλασική μέθοδος  $\theta$  μπορεί να αντικατασταθεί από το μοντέλο της απλής εκθετικής εξομάλυνσης πραγματοποιώντας μία μετατόπιση στις προβλέψεις αυτού ίση με το μισό της κλίση της γραμμής  $Y_t^0$ . Η εν λόγω προσέγγιση ονομάστηκε SES with drift, ή αλλιώς ses-d, και μάλιστα στην ίδια εργασία πραγματοποιήθηκε μία προσπάθεια μεταβολής του βαθμού κατά τον οποίο μετατοπίζεται η πρόβλεψη της SES ούτως ώστε να επιτευχθεί καλύτερη ακρίβεια. Τα αποτελέσματα ήταν αρκετά κοντά σε αυτά της κλασικής μεθόδου  $\theta$  και σημαντική διαφοροποίηση μεταξύ των δύο προσεγγίσεων αποτέλεσε ο υπολογισμός του επιπέδου της ευθείας της απλής γραμμικής παλινδρόμησης επί της γραμμής  $Y_t^2$  και όχι επί των αρχικών δεδομένων. Η εν λόγω μελέτη, παρά το γεγονός ότι ο αρχικός ισχυρισμός δεν είναι απολύτως αληθής (Nikolopoulos & Assimakopoulos, 2005), αποδεικνύει τη γραμμική φύση των προβλέψεων της μεθόδου  $\theta$ , η οποία γέννησε την απορία του πόσο καλύτερα θα μπορούσε να αποδώσει η συγκεκριμένη μέθοδος αν υπήρχε η δυνατότητα προέκτασης της χρονοσειράς και με μη γραμμικό τρόπο, γεγονός που εξετάστηκε εκτενώς από τον Σπηλιώτης (2017) με ενθαρρυντικά αποτελέσματα.

## 4.2 Διαδεδομένες τεχνικές πρόβλεψης χρονοσειρών διακοπτόμενης ζήτησης

Κατά το παρελθόν, οι μέθοδοι εκθετικής εξομάλυνσης χρησιμοποιούνταν συχνά προκειμένου να προβλεφθούν χρονοσειρές διακοπτόμενης φύσης. Ωστόσο, το γεγονός ότι οι μέθοδοι αυτοί δίνουν μεγαλύτερο βάρος στα πιο πρόσφατα δεδομένα δημιουργεί προβλήματα, μιας και οι παραγόμενες προβλέψεις είναι μέγιστες μετά από εμφάνιση ζήτησης και ελάχιστες ακριβώς πριν από περίοδο μη μηδενικής ζήτησης. Η αδυναμία αυτή, οδήγησε στην αναζήτηση νέων μεθόδων και τεχνικών για την αποτελεσματικότερη πρόβλεψη χρονοσειρών με έντονη παρουσία μηδενικών τιμών.

Η πρώτη μέθοδος που δημιουργήθηκε αποκλειστικά για χρονοσειρές διακοπτόμενης φύσης είναι η μέθοδος Croston (1972). Από τότε διάφορες τεχνικές έχουν εμφανιστεί στη βιβλιογραφία, όπως παραλλαγές της Croston, τεχνικές που χρησιμοποιούν τυχαία αναδειγματοληψία (bootstrapping), μέθοδοι χρονικής συνάθροισης των παρατηρήσεων και νευρωνικά δίκτυα, με μικτά αποτελέσματα σχετικά με την επίδοσή τους, η οποία εξαρτάται από το πλήθος και είδος των εξεταζόμενων χρονοσειρών αλλά και τον τρόπο με τον οποίο εξετάζεται η ακρίβεια των προβλέψεων. Παρακάτω αναλύονται οι πιο διαδεδομένες μέθοδοι προβλέψεων χρονοσειρών διακοπτόμενης ζήτησης.

### 4.2.1 Μέθοδος Croston

Ο Croston (1972) δήλωσε ότι η χρήση παραδοσιακών μεθόδων πρόβλεψης, όπως η απλή εκθετική εξομάλυνση (SES), ίσως είναι ακατάλληλη για την παραγωγή προβλέψεων σε χρονοσειρές διακοπτόμενης ζήτησης, καθώς μπορεί να οδηγήσουν σε μη βελτιστές αποφάσεις σχετικές με τη διαδικασία αποθεματοποίησης. Πρότεινε, έτσι, μία καινούρια τεχνική, η οποία θα μπορούσε να διαχειριστεί τις δυσκολίες των συγκεκριμένων χρονοσειρών. Στην ουσία, η τεχνική χωρίζει τη χρονοσειρά σε δύο, όπου η πρώτη

αποτελείται αποκλειστικά από τις μη μηδενικές τιμές και η δεύτερη από τα διαστήματα μεταξύ των διαδοχικών μη μηδενικών παρατηρήσεων. Έπειτα, κάθε χρονοσειρά προβλέπεται χρησιμοποιώντας την SES και η τελική πρόβλεψη της αρχικής χρονοσειράς είναι η διαίρεση των δύο επιμέρους τιμών, ως εξής:

$$F = \frac{F_{demands}}{F_{intervals}}$$

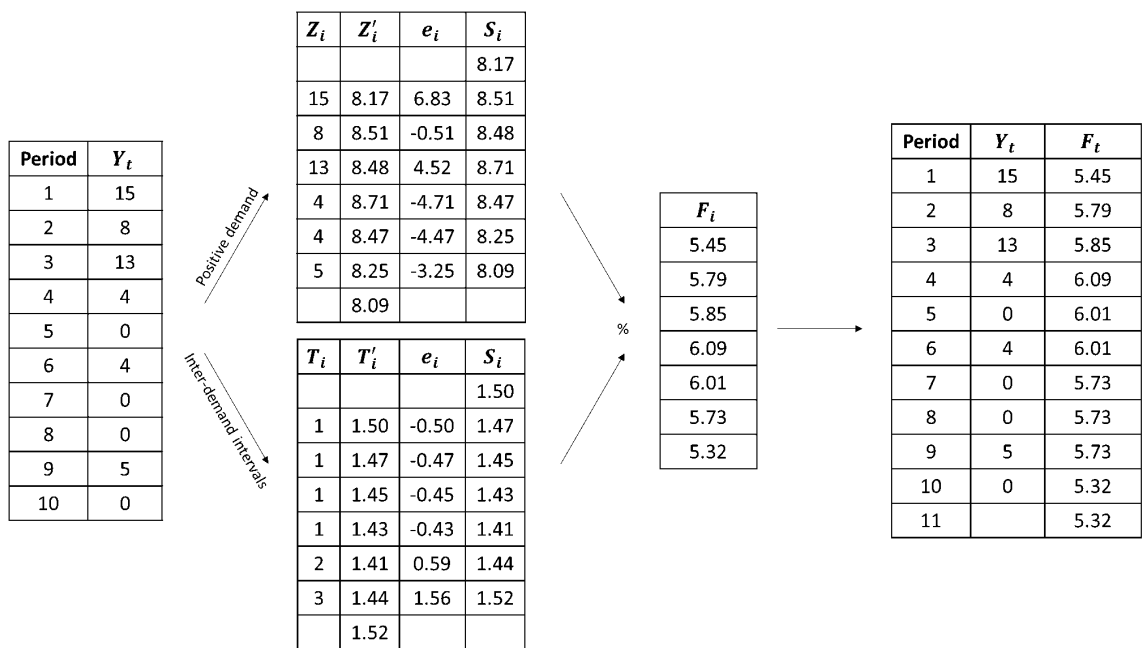
Οι προβλέψεις ανανεώνονται μόνο με την εμφάνιση μη μηδενικής τιμής και οι εξισώσεις που περιγράφουν την τεχνική αυτή φαίνονται παρακάτω:

$$F_i = \frac{Z'_i}{T'_i}, \text{ όπου } \begin{cases} Z'_i = Z'_{i-1} + a(Z_i - Z'_{i-1}) \text{ και} \\ T'_i = T'_{i-1} + b(T_i - T'_{i-1}), \end{cases}$$

όπου  $T_i$  είναι το μεσοδιάστημα μεταξύ των διαδοχικών μη μηδενικών παρατηρήσεων και επομένως  $T'_i$  η πρόβλεψη του μεγέθους αυτού,  $Z_i$  η  $i$ -οστή ζήτηση και αντίστοιχα  $Z'_i$  η πρόβλεψη και  $a$  και  $b$  οι συντελεστές εξομάλυνσης. Να σημειωθεί εδώ ότι η  $i$ -οστή ζήτηση αναφέρεται στην  $i$ -οστή κατά σειρά μη μηδενική παρατήρηση της χρονοσειράς και διαφέρει από την παρατήρηση τη στιγμή  $t$ , η οποία μπορεί να είναι και μηδενική.

Στην κλασσική μέθοδο οι συντελεστές  $a$  και  $b$  παίρνουν την ίδια τιμή, και ισούνται με 0.1, ωστόσο στη βιβλιογραφία εμφανίζονται διάφορες διαδικασίες βελτιστοποίησης των συντελεστών αυτών κατά τις οποίες οι συντελεστές είτε βελτιστοποιούνται μαζί ( $a = b$ ) είτε ξεχωριστά ( $a \neq b$ ) στο διάστημα  $[0, 1]$ .

Παρακάτω παρουσιάζονται αναλυτικά τα βήματα που ακολουθούνται για την εξαγωγή προβλέψεων με τη μέθοδο Croston για μία χρονοσειρά διακοπτόμενης φύσης, έχοντας επιλέξει  $a = b = 0.05$  και  $S_0$  τη μέση τιμή των παρατηρήσεων κάθε μεγέθους κάθε φορά:



### 4.2.2 Παραλλαγές της μεθόδου Croston

Μετά την αρχική της μορφή, αρκετές παραλλαγές της τεχνικής του Croston έχουν εμφανιστεί, άλλες με μεγαλύτερη και άλλες με μικρότερη επιτυχία.

Οι πιο γνωστές είναι οι μέθοδοι SBA, modified Croston, SBJA και TSB, ενώ πιο πρόσφατες είναι οι modified SBA και modified TSB. Η TSB δεν εμφανίζει προκατάληψη, οδηγώντας σε καλές επιδόσεις, καθώς παρέχει πάντα ενημερωμένες προβλέψεις, ακόμη και μετά από μεγάλα διαστήματα μηδενικής ζήτησης, ωστόσο σε ορισμένες περιπτώσεις οι SBA και SBJA μπορεί να εμφανίσουν μικρότερα σφάλματα, ακριβώς λόγω της ενημέρωσης της πιθανότητας ζήτησης σε κάθε περίοδο. Με τη σειρά της, η modified SBA, αποτελεί μια επέκταση της SBA, η οποία ενημερώνει τις προβλέψεις και σε περιόδους μηδενικής ζήτησης, έχοντας δείξει αρκετά καλές επιδόσεις, ενώ η modified TSB προσπαθεί να συνδυάσει τα πλεονεκτήματα τόσο της μεθόδου TSB όσο και της μεθόδου modified SBA. Οι μέθοδοι αυτές παρουσιάζονται αναλυτικά στη συνέχεια του Κεφαλαίου.

#### 4.2.2.1 Μέθοδος SBA (Syntetos-Boylan Approximation)

Οι Syntetos & Boylan (2001) υποστήριξαν ότι η κλασική μέθοδος του Croston εμφανίζει προκατάληψη, την οποία και υπολόγισαν περίπου στο  $100 \frac{b}{2-b} (1 - \frac{1}{p})$ , όπου  $b$  είναι ο συντελεστής εξομάλυνσης που χρησιμοποιείται για την ενημέρωση των διαστημάτων μεταξύ της ζήτησης και  $p$  η μέση τιμή των εκτιμήσεων εκθετικής εξομάλυνσης των διαστημάτων μεταξύ της ζήτησης. Στη συνέχεια πρότειναν μία διόρθωση της κλασικής μεθόδου, κατά την οποία η πρόβλεψη πολλαπλασιάζεται με τον όρο  $1 - \frac{b}{2}$ , όπως φαίνεται παρακάτω (Syntetos & Boylan, 2005):

$$F_i = \left(1 - \frac{b}{2}\right) \frac{Z'_i}{T'_i}, \text{ όπου}$$

$$\begin{cases} Z'_i = Z'_{i-1} + a(Z_i - Z'_{i-1}) \text{ και} \\ T'_i = T'_{i-1} + b(T_i - T'_{i-1}). \end{cases}$$

#### 4.2.2.2 Μέθοδος modified Croston (mCroston) και προσαρμογές

Την ίδια περίοδο με τη μέθοδο SBA εμφανίστηκε και η μέθοδος modified Croston των Levén & Segerstedt (2004), στην οποία γίνεται μια προσπάθεια απλοποίησης της Croston, εισάγοντας στην ουσία την πληροφορία της σποραδικότητας της ζήτησης μέσα στην εξίσωση εκθετικής εξομάλυνσης με την οποία πραγματοποιείται η πρόβλεψη των μη μηδενικών τιμών.

Οι εξισώσεις που περιγράφουν τη μέθοδο αυτή είναι οι εξής:

$$F_i = Z'_i, \text{ όπου}$$

$$Z'_i = Z'_{i-1} + a \left( \frac{Z_i}{TP_i - TP_{i-1}} - Z'_{i-1} \right) \text{ με } Z'_{Var_i} = Z'_{Var_{i-1}} + b \left( \frac{(Z_i - (TP_i - TP_{i-1})Z'_{i-1})^2}{TP_i - TP_{i-1}} - Z'_{Var_{i-1}} \right),$$

όπου  $Z'_{Var_i}$  η προβλεπόμενη απόκλιση της προβλεπόμενης ζήτησης.

Ενώ στην αρχή υποστηρίζεται ότι και η μέθοδος αυτή εξαλείφει την προκατάληψη της

Croston, στη συνέχεια οι Boylan & Syntetos (2007) διαπίστωσαν ότι η μέθοδος εξομάλυνσης για την εκτίμηση της διακύμανσης βασίζεται σε έναν μη έγκυρο στατιστικό δείκτη απόδοσης και ότι η προτεινόμενη μέθοδος παράγει και αυτή προβλέψεις με προκατάληψη. Το παραπάνω συμπέρασμα, σε συνδυασμό με πληθώρα μελετών που οδηγούσαν σε παρόμοια αποτελέσματα οδήγησε τους συγγραφείς να αναφέρουν χαρακτηριστικά ότι η συγκεκριμένη μέθοδος “δεν είναι μια καλή ιδέα” (Segerstedt & Levén, 2020). Εμφανίζονται, έτσι, τρεις διορθώσεις-παραλλαγές της μεθόδου αυτής, οι οποίες βασίζονται στο επιχείρημα ότι η modified Croston είχε σχεδιαστεί εξ αρχής λανθασμένα, μιας και, εκ του αποτελέσματος, η επίδοσή της δεν είναι καλύτερη από την επίδοση της κλασική μεθόδου Croston. Δημιουργούνται οι μέθοδοι forward modified Croston (Wallström & Segerstedt, 2010), average modified Croston και average forward modified Croston (Segerstedt & Levén, 2020), οι οποίες στην ουσία μεταβάλλουν με διαφορετικούς τρόπους τον παράγοντα  $\frac{Z_i}{TP_i - TP_{i-1}}$  της αρχικής εξίσωσης, ως εξής:

- Μέθοδος forward modified Croston:  $\frac{Z_{i-1}}{TP_i - TP_{i-1}}$
- Μέθοδος average modified Croston:  $\frac{Z_i + Z_{i-1}}{TP_i - TP_{i-2}}$
- Μέθοδος average forward modified Croston:  $\frac{Z_{i-1} + Z_{i-2}}{TP_i - TP_{i-2}}$

#### 4.2.2.3 Μέθοδος SBJA (Shale-Boylan-Johnston Approximation)

Οι Shale et al. (2006), ακολουθώντας τα βήματα των Syntetos & Boylan (2005) πρότειναν μία διαφορετική διόρθωση της κλασικής μεθόδου Croston, κατά την οποία η πρόβλεψη πολλαπλασιάζεται με τον όρο  $1 - \frac{b}{2-b}$ , όπως φαίνεται παρακάτω:

$$F_i = \left(1 - \frac{b}{2-b}\right) \frac{Z'_i}{T'_i}, \text{ όπου}$$

$$\begin{cases} Z'_i = Z'_{i-1} + a(Z_i - Z'_{i-1}) \text{ και} \\ T'_i = T'_{i-1} + b(T_i - T'_{i-1}). \end{cases}$$

#### 4.2.2.4 Μέθοδος TSB (Teunter-Syntetos-Babai)

Όπως αναφέρθηκε παραπάνω, οι προβλέψεις που παράγουν οι μέθοδοι Croston και SBA, ανανεώνονται μόνο κατά την εμφάνιση μη μηδενικής παρατήρησης, έτσι οι Teunter et al. (2011) πρότειναν μία μέθοδο η οποία εισήγαγε τη χρήση της πιθανότητας εμφάνισης μη μηδενικής ζήτησης αντικαθιστώντας το μέρος που αφορά στα μεσοδιαστήματα μεταξύ των διαδοχικών μη μηδενικών παρατηρήσεων. Οι εξισώσεις που περιγράφουν την συγκεκριμένη μέθοδο είναι οι εξής:

$$F_i = p'_i Z'_i, \text{ όπου}$$

$$\begin{cases} Z'_i = Z'_{i-1} + a(Z_i - Z'_{i-1}) \text{ και } p'_i = p'_{i-1} + b(1 - p'_{i-1}), \text{ όταν } Y_t > 0 \\ Z'_i = Z'_{i-1} \text{ και } p'_i = p'_{i-1} + b(0 - p'_{i-1}), \text{ όταν } Y_t = 0, \end{cases}$$

όπου  $p'_i$  η  $i$ -οστή προβλεπόμενη πιθανότητα εμφάνισης μη μηδενικής ζήτησης. Υπενθυμίζεται η διαφοροποίηση μεταξύ  $t$  και  $i$ , όπου το πρώτο αναφέρεται σε χρονική

περίοδο ενώ το δεύτερο σε αύξοντα αριθμό. Στην περίπτωση όπου η σειρά δεν εμφανίζει μηδενικές παρατηρήσεις, το  $t$  ταυτίζεται με το  $i$ .

#### 4.2.2.5 Μέθοδος modified SBA (mSBA)

Στη μέθοδο SBA, οι μηδενικές παρατηρήσεις δεν συμβάλλουν στη διαδικασία πρόβλεψης, από την άποψη ότι οι προβλέψεις παραμένουν σταθερές όσο δεν εμφανίζεται μη μηδενική ζήτηση. Ως αποτέλεσμα, οι Babai et al. (2019) πρότειναν τη μέθοδο mSBA, κατά την οποία τα μεσοδιαστήματα μεταξύ μη μηδενικών παρατηρήσεων αντιμετωπίζονται διαφορετικά ανάλογα με την πραγματική και την προβλεπόμενη τιμή της προηγούμενης περιόδου. Οι εξισώσεις της συγκεκριμένης μεθόδου είναι οι εξής:

$$F_i = \left(1 - \frac{b}{2}\right) \frac{Z'_i}{T'_i}, \text{ όπου}$$

$$\begin{cases} \text{όταν } Y_t > 0 : Z'_i = Z'_{i-1} + a(Z_i - Z'_{i-1}) \text{ και } T'_i = T'_{i-1} + b(T_i - T'_{i-1}) \\ \text{όταν } Y_t = 0 : \begin{cases} Z'_i = Z'_{i-1} \\ T'_i = \begin{cases} T'_{i-1} + b(T_i - T'_{i-1}), & \text{όταν } T_i > T'_{i-1} \\ T'_{i-1}, & \text{όταν } T_i \leq T'_{i-1} \end{cases} \end{cases} \end{cases}$$

#### 4.2.2.6 Μέθοδος modified TSB (mTSB)

Οι Yang et al. (2021) προσπαθώντας να συνδιάσουν τα πλεονεκτήματα των TSB και mSBA, οι οποίες είχαν εμφανίσει θετικά αποτελέσματα, πρότειναν τη μέθοδο mTSB, η οποία αποτελεί έναν συνδυασμό των δύο προηγούμενων. Οι εξισώσεις της mTSB είναι οι εξής:

$$F_i = p'_i Z'_i, \text{ όπου}$$

$$\begin{cases} \text{όταν } Y_t > 0 : Z'_i = Z'_{i-1} + a(Z_i - Z'_{i-1}) \text{ και } p'_i = p'_{i-1} + b(1 - p'_{i-1}) \\ \text{όταν } Y_t = 0 : \begin{cases} Z'_i = Z'_{i-1} \\ p'_i = \begin{cases} p'_{i-1} + b(1 - p'_{i-1}), & \text{όταν } p_i > p'_{i-1} \\ p'_{i-1} + b(0 - p'_{i-1}), & \text{όταν } p_i \leq p'_{i-1} \end{cases} \end{cases} \end{cases}$$

### 4.2.3 Αυτοπαλινδρομούμενα μοντέλα κινητού μέσου όρου (AutoRegressive Moving Average)

#### 4.2.3.1 Μοντέλα ARMA

Τα αυτοπαλινδρομούμενα μοντέλα κινητού μέσου όρου (autoregressive moving average - ARMA) χρησιμοποιούνται για την περιγραφή στατικών στοχαστικών διεργασιών. Κάθε ARMA(p,q) μοντέλο απαρτίζεται από δύο μέρη, το αιτιοκρατικό μέρος που περιλαμβάνει τους αυτοπαλινδρομούμενους όρους τάξης  $p$  και το στοχαστικό μέρος με τους κινητούς μέσους όρους τάξης  $q$  (Whittle, 1951).

- Διεργασία AR(p):  $X_t = c + \sum_{i=1}^p \phi_i X_{t-i} + \epsilon_t$ , όπου  $c$  είναι μια σταθερά,  $\phi_i$  οι παράμετροι του μοντέλου και  $\epsilon_t$  ο θόρυβος

- Διεργασία MA(q):  $X_t = \mu + \sum_{i=1}^q \theta_i \epsilon_{t-i} + \epsilon_t$ , όπου  $\mu$  είναι μια σταθερά και  $\theta_i$  οι παράμετροι του μοντέλου.

Μαζί δίνουν το ολοκληρωμένο μοντέλο ARMA ως εξής:

$$X_t = c + \epsilon_t + \sum_{i=1}^p \phi_i X_{t-i} + \sum_{i=1}^q \theta_i \epsilon_{t-i}$$

Πιο αναλυτικά, το μοντέλο λαμβάνει για κάθε παρατήρηση της χρονοσειράς ως εξαρτώμενες τις προηγούμενες  $p$  παρατηρήσεις και τα προηγούμενα  $q$  υπολείμματα (residuals). Για χρονοσειρές διακοπτόμενης φύσης, ωστόσο, τα συγκεκριμένα μοντέλα κρίνονται ως ακατάλληλα μιας και επιτρέπουν την εμφάνιση αρνητικών τιμών, με αποτέλεσμα να απαιτείται προσαρμογή που προσθέτει αυτόν τον περιορισμό. Δύο παραλλαγές των μοντέλων ARMA που χρησιμοποιούνται συχνά σε διακοπτόμενες χρονοσειρές είναι τα μοντέλα Discrete ARMA και Integer-valued ARMA που παρουσιάζονται στη συνέχεια.

#### 4.2.3.2 Μοντέλα DARMA (Discrete ARMA)

Τα μοντέλα DARMA (Jacobs & Lewis, 1978) λαμβάνουν τιμές σε ένα διακριτό σύνολο, σύμφωνα με τα αποτελέσματα ορισμένων τυχαίων μεταβλητών. Η διαδικασία που ακολουθείται κατά την εφαρμογή των συγκεκριμένων μοντέλων επεξηγείται καλύτερα μέσω ενός παραδείγματος, με το μοντέλο DAR(1) να είναι μία αρκετά απλή εκδοχή τους και το οποίο περιγράφεται παρακάτω.

Εάν  $Y_t$  είναι η τιμή της χρονοσειράς την περίοδο  $t$ ,  $\{V_t\}$  είναι τυχαίες ανεξάρτητες μεταβλητές Bernoulli(a) και  $\{Z_t\}$  ανεξάρτητες και όμοια κατανομημένες τυχαίες μεταβλητές (i.i.d. random variables), τότε:

$$Y_t = V_t Y_{t-1} + (1 - V_t) Z_t$$

Με άλλα λόγια, σύμφωνα με το συγκεκριμένο μοντέλο, κάθε παρατήρηση της χρονοσειράς δεν μοντελοποιείται ως σταθμισμένος μέσος όρος μορφής SES δύο ποσοτήτων (της προηγούμενης τιμής ή της τιμής μιας τυχαίας διακριτής τιμής), αλλά ως μια τυχαία επιλογή μεταξύ των δύο. Παρομοίως, ένα μοντέλο DARMA(p,q) αποτελεί μία τυχαία επιλογή μεταξύ των όρων αυτοπαλινδρόμησης και κινητού μέσου όρου.

Το κύριο μειονέκτημα των μοντέλων DARMA, που καθιστά πολύ περιορισμένες τις εφαρμογές τους, είναι ότι η υλοποίηση της διαδικασίας δημιουργεί πολλές επαναλαμβανόμενες σταθερές τιμές, ιδιαίτερα όταν η αυτοσυσχέτιση της χρονοσειράς είναι υψηλή.

#### 4.2.3.3 Μοντέλα INARMA (INteger-valued ARMA)

Τα μοντέλα INARMA (McKenzie, 1986) λαμβάνουν τα προηγούμενα μέρη αυτοπαλινδρόμησης και κινητών μέσων όρων, τους συρρικνώνουν και προσθέτουν κάποιους τυχαίους μη αρνητικούς ακέραιους αριθμούς, ως εξής:

$$Y_t = \sum_{i=1}^p a_i \circ Y_{t-i} + \sum_{i=1}^q b_i \circ Z_{t-i} + Z_t,$$

όπου

$$b \circ Z = \sum_{i=1}^Z X_i, \text{ και } Z \sim \text{Bernoulli}(b).$$

Πιο αναλυτικά, η παραπάνω διαδικασία ονομάζεται διωνυμική συρρίκνωση, με την παράμετρο συρρίκνωσης  $b \in (0, 1)$  να εφαρμόζεται στην τυχαία μεταβλητή  $Z$ , και τη σειρά  $X_i$  να είναι ανεξάρτητη και όμοια κατανομημένη δυαδική τυχαία μεταβλητή με  $P(X_i = 1) = b$ . Με τον τρόπο αυτό, η πράξη  $b \circ Z$  μπορεί να οδηγήσει μόνο σε ακέραιες τιμές μεταξύ 0 και  $Z$ , και η κατανομή της είναι διωνυμική που εξαρτάται από την τιμή του  $Z$ .

Στα συγκεκριμένα μοντέλα, μόλις επιλεγούν οι παράμετροι, ένας τρόπος για να υπολογιστούν οι προβλέψεις είναι να υπολογιστεί η υπό όρους αναμενόμενη τιμή της διαδικασίας, η οποία βασίζεται στην ελαχιστοποίηση του μέσου τετραγωνικού σφάλματος, το οποίο θα αναλυθεί στη συνέχεια του Κεφαλαίου.

Περισσότερες πληροφορίες για τα αυτοπαλινδρούμενα μοντέλα κινητού μέσου όρου (ARMA), τα μοντέλα DARMA αλλά και την επίδοση των μοντέλων INARMA σε χρονοσειρές διακοπτόμενης ζήτησης μπορούν να βρεθούν στην διδακτορική διατριβή της Mohammadpour (2013).

#### 4.2.4 Τεχνικές Bootstrapping

Οι τεχνικές Bootstrapping (Efron, 1979) υπολογίζουν την κατανομή της ζήτησης κατά το χρόνο παράδοσης, λαμβάνοντας δείγματα της ζήτησης από τις ιστορικές παρατηρήσεις. Η αναδειγματοληψία αυτή μπορεί να γίνει με πολλούς διαφορετικούς τρόπους, μιας και μπορεί να πραγματοποιηθεί με ή χωρίς αντικατάσταση, τυχαία ή περιορισμένη σε διαδοχικούς μήνες (Teunter & Duncan, 2009). Είναι, έτσι, αρκετά χρήσιμες τεχνικές σε περιπτώσεις έλλειψης μεγάλου πλήθους παρατηρήσεων και έντονης ασάθειας του επιπέδου της ζήτησης.

Οι συγκεκριμένες τεχνικές διαχωρίζονται σε παραμετρικές (parametric bootstrapping) και μη παραμετρικές (non-parametric bootstrapping). Η πρώτη αφορά σε μια τεχνική προσομοίωσης που χρησιμοποιεί εκτιμώμενες παραμέτρους κατανομής για τη δημιουργία δεδομένων ζήτησης κατά το χρόνο παράδοσης, θεωρώντας ωστόσο την ύπαρξη κάποιας κατανομής (π.χ. κανονική, λογαριθμική). Από την άλλη πλευρά, οι μη παραμετρικές μέθοδοι δεν υποθέτουν την ύπαρξη κάποιας κατανομής, αλλά συλλέγουν δείγματα των παρελθοντικών παρατηρήσεων και χρησιμοποιούν την εμπειρική τους κατανομή.

Έτσι, στη βιβλιογραφία εμφανίζονται αρκετές παραλλαγές των συγκεκριμένων τεχνικών, όπως αυτές των Bookbinder & Lordahl (1989), Snyder (2002), Willemain et al. (2004), Porras Musalem (2005), πολλές από τις οποίες έχουν το μειονέκτημα ότι είναι αρκετά πολύπλοκες.

Παρακάτω περιγράφεται η διαδικασία που ακολουθείται κατά την μέθοδο bootstrapping των Willemain et al. (2004) η οποία εμφανίζει βελτίωση στην ακρίβεια των προβλέψεων σε σχέση με τις μεθόδους Croston και SES, μιας και αποτυπώνει αρκετά καλά την

αυτοσυσχέτιση μεταξύ των εμφανίσεων θετικής ζήτησης, ιδίως σε περιπτώσεις όπου το ποσοστό των μηδενικών παρατηρήσεων είναι υψηλό (Pedrosa et al., 2011).

Αρχικά, η συγκεκριμένη μέθοδος αξιολογεί τις εμπειρικές πιθανότητες μετάβασης μεταξύ των μηδενικών και μη μηδενικών παρατηρήσεων. Να σημειωθεί εδώ ότι οι πιθανότητες μετάβασης αφορούν σε διάφορες αλλαγές στην κατάσταση ενός συστήματος που αναπαριστά μία διαδικασία ή αλυσίδα Markov (Gagnieu, 2017). Με βάση αυτές τις πιθανότητες μετάβασης, δημιουργείται μια ακολουθία μηδενικών/μη μηδενικών τιμών για ολόκληρο τον ορίζοντα πρόβλεψης. Οι τιμές των μη μηδενικών προβλέψεων υπολογίζονται χρησιμοποιώντας τη διαδικασία jittering, η οποία επιτρέπει μεγαλύτερη διακύμανση γύρω από μεγαλύτερες παρατηρήσεις.

Έστω  $X^*$  μια ιστορική τιμή ζήτησης επιλεγμένη τυχαία και  $Z$  οι τιμές του αντιστρόφου της τυπικής κανονικής κατανομής επίσης επιλεγμένες τυχαία, τότε η προβλεπόμενη μη μηδενική τιμή  $S$  υπολογίζεται ως εξής:

$$S = \begin{cases} INT\{X^* + Z \sqrt{X^*}\}, & \text{εάν } S > 0 \\ X^*, & \text{αλλιώς.} \end{cases}$$

Σε πρόσφατη έρευνά τους, οι Syntetos et al. (2015), στην οποία χρησιμοποίησαν δύο, αρκετά περιορισμένα, εβδομαδιαία σύνολα δεδομένων εταιρειών λιανικής, δεν μπόρεσαν να διακρίνουν εάν υπάρχει αξία ή όχι στην χρήση της μεθόδου bootstrapping των Willemain et al. (2004), μιας και η συγκεκριμένη μέθοδος χαρακτηρίζεται από μεγάλη πολυπλοκότητα, ενώ την ίδια στιγμή πιο απλές μέθοδοι, οι οποίες ως επακόλουθο απαιτούν λιγότερους υπολογιστικούς πόρους, αποδίδουν αρκετά καλά.

#### 4.2.5 Τεχνικές πρόβλεψης μέσω χρονικής συνάθροισης (Temporal aggregation)

Μία άλλη τεχνική διαχείρισης των χρονοσειρών διακοπτόμενης ζήτησης που μπορεί να ακολουθηθεί προκειμένου να αποφεύγεται η ασυνέχεια των δεδομένων όσων αφορά τις μηδενικές τιμές, είναι η μη επικαλυπτόμενη συνάθροιση (aggregation) των δεδομένων σε περιόδους μικρότερης συχνότητας, η οποία εξετάστηκε πρώτη φορά σε χρονοσειρές αργής κίνησης από τους Willemain et al. (1994). Αν για παράδειγμα υπάρχουν μηνιαία δεδομένα, και σε κάποιους μήνες η ζήτηση ήταν μηδενική τότε θα μπορούσε να εφαρμοστεί η συνάθροιση σε τριμηνιαίο επίπεδο, θέτοντας το επίπεδο συνάθροισης ίσο με τρεις περιόδους. Με μία τέτοια συνάρτηση, ενδέχεται να μειωθεί, ή ακόμα και να επαλειφθεί, η ασυνέχεια λόγω ύπαρξης μηδενικών παρατηρήσεων. Επίσης η διακύμανση της προκύπτουσας νέας χρονοσειράς αναμένεται να είναι μικρότερη, έχοντας χρησιμοποιήσει ουσιαστικά μη επικαλυπτόμενο κινητό μέσο όρο για εξομάλυνση. Ο κατάλληλος καθορισμός του επιπέδου συνάθροισης (aggregation level) θα οδηγήσει σε χρονοσειρά συνεχούς ζήτησης, χωρίς μηδενικές τιμές, στην οποία θα μπορεί πλέον να εφαρμοστεί οποιαδήποτε τεχνική πρόβλεψης δεδομένων κατάλληλη για συνεχή ζήτηση για την παραγωγή προβλέψεων στο επίπεδο συνάθροισης.

Η χρησιμότητα των εξαγομένων συναθροισμένων προβλέψεων, ωστόσο, μπορεί να



αμφισβητηθεί, καθώς τα δεδομένα παρακολουθούνται και ελέγχονται σε υψηλότερη χρονική συχνότητα, με σκοπό την εξυπηρέτηση διαφόρων λειτουργικών αναγκών. Κρίνεται λοιπόν αναγκαία η διάσπαση (disaggregation) των υπολογισμένων προβλέψεων ώστε να υπολογιστούν οι τελικές προβλέψεις χρονικής συχνότητας ίσης με του αρχικού επιπέδου.

Αρκετά διαδεδομένες μέθοδοι συνάθροισης αποτελούν οι ADIDA, iADIDA και iMAPA, οι οποίες περιγράφονται αναλυτικά στη συνέχεια.

#### **4.2.5.1 Μέθοδος ADIDA (Aggregate-Disaggregate Intermittent Demand Approach)**

Η μέθοδος ADIDA (Nikolopoulos et al., 2011) απαρτίζεται από 3 στάδια ως εξής:

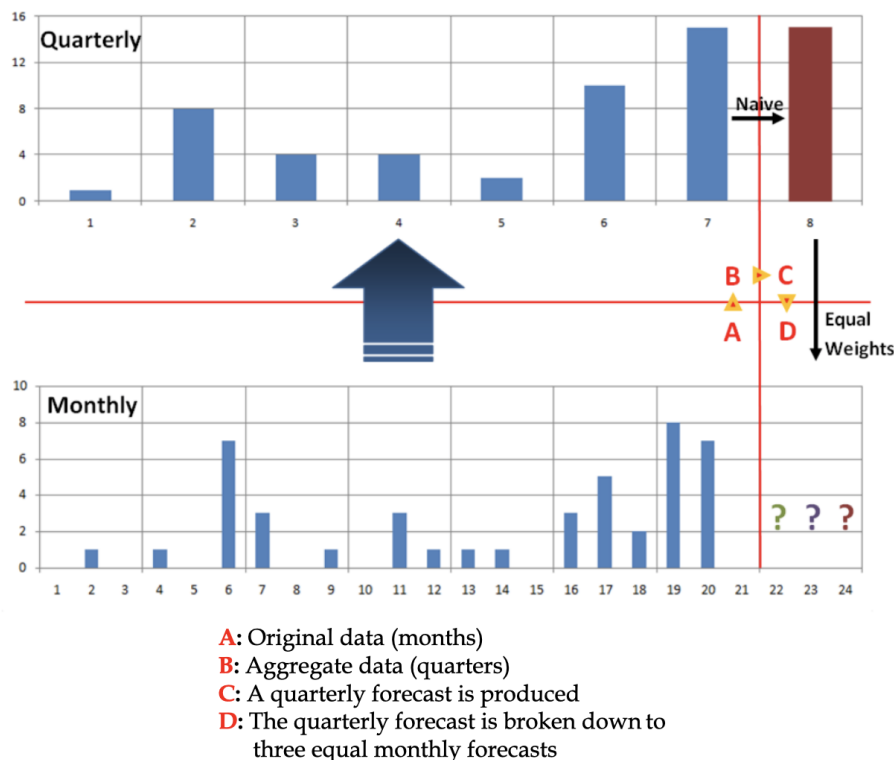
1. Συνάθροιση των δεδομένων με κατάλληλο επίπεδο συνάθροισης
2. Πρόβλεψη της συναθροισμένης χρονοσειράς
3. Διαχωρισμός των προβλέψεων που παρήχθησαν στο προηγούμενο βήμα

Πιο αναλυτικά, το πρώτο στάδιο αφορά στη λήψη απόφασης για το είδος της συνάθροισης, δηλαδή την επιλογή του αριθμού των παρατηρήσεων που θα συναθροίζονται κάθε φορά και το αν οι τιμές που υπολογίζονται θα είναι επικαλυπτόμενες ή όχι. Η συγκεκριμένη μέθοδος χρησιμοποιεί “blocks” ίσου μεγέθους και μη επικαλυπτόμενα, συνήθως με μέγεθος ίσο με το μέσο διάστημα μεταξύ της ζήτησης (ADI). Σε ένα σύστημα διαχείρισης αποθεμάτων, ωστόσο, θα είχε νόημα το επίπεδο συνάθροισης να λαμβάνει τον αριθμό των περιόδων που απαιτούνται από τη στιγμή που θα γίνει μια παραγγελία μέχρι τα προϊόντα να γίνουν διαθέσιμα (lead time) συν μία περίοδο. Οι Nikolopoulos et al. (2011) απέδειξαν ότι ο συγκεκριμένος ορισμός του επιπέδου συνάθροισης επιφέρει στατιστικά σημαντική μείωση των δεικτών σφάλματος. Το δεύτερο στάδιο της μεθόδου είναι η πρόβλεψη της επόμενης τιμής της συναθροισμένης σειράς, η οποία μπορεί να γίνει με διάφορες μεθόδους πρόβλεψης όπως η SES, ή ακόμα και η Naive. Τέλος, η πρόβλεψη θα πρέπει να αναλυθεί σε χρονικές περιόδους της αρχικής χρονοσειράς, το οποίο μπορεί να γίνει χρησιμοποιώντας είτε ίσα βάρη είτε βάρη με βάση την αναλογία των προηγούμενων παρατηρήσεων σε κάθε “block”.

Η παραπάνω διαδικασία απεικονίζεται στο Σχήμα 4.2, όπου, σύμφωνα με τη μέθοδο ADIDA, μία μηνιαία χρονοσειρά διακοπτόμενης ζήτησης δημιουργεί μία τριμηνιαία χρονοσειρά, η επόμενη τιμή προβλέπεται μέσω της μεθόδου Naive και οι προβλέψεις της αρχικής μηνιαίας χρονοσειράς υπολογίζονται με ίσα βάρη.

#### **4.2.5.2 Μέθοδος iADIDA (inverse ADIDA)**

Η μέθοδος ADIDA εστιάζει στην πρόβλεψη των συγκεντρωτικών μη μηδενικών παρατηρήσεων, προσφέροντας, έτσι, μια βελτίωση στην απόδοση η οποία προέρχεται από την μείωση της διακύμανσης των μεσοδιαστημάτων μεταξύ διαδοχικών μη μηδενικών παρατηρήσεων που παρατηρείται στην αρχική χρονοσειρά. Στην περίπτωση όπου δεν λαμβάνεται υπόψη ένας μηχανισμός διαχωρισμού στο τελευταίο στάδιο αυτού του πλαισίου, τότε η ADIDA προσπαθεί να απαντήσει στο ερώτημα “πόσα τεμάχια θα πουληθούν σε ένα προκαθορισμένο χρονικό διάστημα;”.



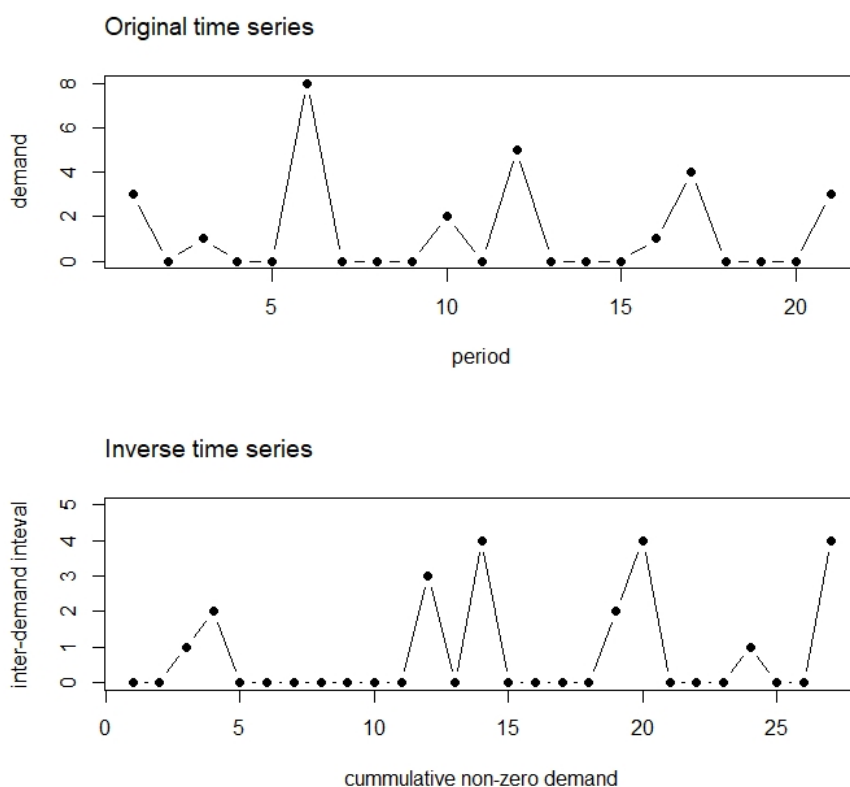
Σχήμα 4.2: Απεικόνιση των βημάτων που ακολουθούνται κατά την πρόβλεψη μιας χρονοσειράς με τη μέθοδο ADIDA. (Πηγή: Nikolopoulos et al. (2011))

Ωστόσο, εστιάζοντας στην ελαχιστοποίηση της διακύμανσης της πραγματικής ζήτησης και προβλέποντας τον αντίστοιχο χρονικά μεταβαλλόμενο αριθμό περιόδων που θα συμβεί αυτή η σταθερή ζήτηση, θα μπορούσε να απαντηθεί το ερώτημα “πότε πρέπει να παραγγείλω ξανά μια νέα παλέτα/πλήθος τεμαχίων;”. Με αυτόν τον τρόπο δημιουργήθηκε η inverse ADIDA (Petrooulos et al., 2016) η οποία χρησιμοποιεί τα διαστήματα μεταξύ της ζήτησης και τη συσσωρευμένη (cumulative) ζήτηση για να κατασκευάσει την αντίστροφη (inverse) χρονοσειρά στην οποία εφαρμόζεται η κλασσική μέθοδος ADIDA. Στο Σχήμα 4.3 απεικονίζονται η αρχική και η αντίστροφη χρονοσειρά και στον Πίνακα 4.5 παρουσιάζεται η διαδικασία που ακολουθείται για τη δημιουργία της αντίστροφης χρονοσειράς σύμφωνα με τη συγκεκριμένη μέθοδο.

#### 4.2.5.3 Μέθοδος iMAPA (Multiple Aggregation Prediction Algorithm for intermittent demand)

Ένας άλλος τρόπος εφαρμογής της χρονικής συνάθροισης αποτελεί η μέθοδος iMAPA (Petrooulos & Kourentzes, 2014), παραλλαγή της μεθόδου MAPA (Kourentzes et al., 2014) σχεδιασμένη ειδικά για χρονοσειρές διακοπτόμενης ζήτησης. Σε αντίθεση με την ADIDA, η οποία εξετάζει μόνο ένα επίπεδο συνάθροισης, η μέθοδος iMAPA εξετάζει πολλαπλά επίπεδα, στοχεύοντας στην αποτύπωση διαφορετικής δυναμικής των δεδομένων, προχωρώντας με τη λήψη του μέσου όρου των προβλέψεων που παράγονται.

Έτσι, για παράδειγμα μία μηνιαία χρονοσειρά διακοπτόμενης ζήτησης δημιουργεί μία τριμηνιαία χρονοσειρά, μία εξαμηνιαία, μία ετήσια κ.ο.κ., και η συγκεκριμένη μέθοδος



Σχήμα 4.3: Χρονοσειρά διακοπτόμενης φύσης (επάνω) και η αντίστροφη της (κάτω) σύμφωνα με το μεθοδολογικό πλαίσιο της iADIDA.

Πίνακας 4.5: Η διαδικασία δημιουργία της αντίστροφης χρονοσειράς σύμφωνα με το μεθοδολογικό πλαίσιο της iADIDA.

Period	Non-zero demand	Inter-demand interval	Cumulative non-zero demand
1	3	1	3
3	1	2	4
6	8	3	12
10	2	4	14
12	5	2	19
16	1	4	20
17	4	1	24
21	3	4	27

προβλέπει κάθε χρονοσειρά ξεχωριστά και χρησιμοποιεί ίσα βάρη για να διαχωρίσει τις προβλέψεις στο επίπεδο συνάθροισης της αρχικής χρονοσειράς. Τέλος ο συνδιασμός των επιμέρους προβλέψεων πραγματοποιείται πάλι με ίσα βάρη καθώς έχει αποδειχθεί ως μία καλή στρατηγική σε προηγούμενες μελέτες σύμφωνα με τους Petropoulos & Kourentzes (2014).

### 4.3 Πιθανοτικές προβλέψεις (Probabilistic forecasting)

Η έννοια της πρόβλεψης έχει καταστεί ταυτόσημη με την παραγωγή σημειακών (ντετερμινιστικών) προβλέψεων, όπου ένα μοντέλο ή μία μέθοδος πρόβλεψης, όπως αναλύθηκαν παραπάνω, χρησιμοποιεί τις ιστορικές παρατηρήσεις ενός μεγέθους και υπολογίζει μία ή περισσότερες αναμενόμενες τιμές στο μέλλον, ανάλογα με τον ορίζοντα πρόβλεψης που έχει επιλεχθεί, εξάγοντας, έτσι, διακριτές τιμές για κάθε μελλοντική χρονική στιγμή. Βασικό μειονέκτημα των σημειακών προβλέψεων αποτελεί το γεγονός ότι δεν παρέχουν κάποια πληροφορία για τη διασπορά των παρατηρήσεων, και πιο συγκεκριμένα για την πιθανή διασπορά γύρω από τις αναμενόμενες τιμές. Υπάρχουν, όμως, ορισμένες κατηγορίες προβλέψεων οι οποίες λαμβάνουν υπόψη τον παράγοντα της αβεβαιότητας, συμπεριλαμβάνοντάς την, με τη μορφή διασποράς, στις εξαγόμενες τιμές.

Οι συγκεκριμένες κατηγορίες περιλαμβάνουν, μεταξύ άλλων, τις πιθανοτικές προβλέψεις, οι οποίες προβλέπουν την πυκνότητα της μελλοντικής κατανομής, τους δείκτες ρίσκου (risk indexes) οι οποίοι βρίσκουν το αναμενόμενο επίπεδο του προβλεπτικού σφάλματος και τις προβλέψεις σεναρίων (scenario forecasting) οι οποίες δημιουργούν διάφορα σενάρια σημειακών προβλέψεων για την ίδια χρονική περίοδο του μέλλοντος με σκοπό να βρουν τους συσχετισμούς χρονικών διαστημάτων.


Στη συνέχεια του παρόντος Υποκεφαλαίου θα πραγματοποιηθεί μία εισαγωγή στις πιθανοτικές προβλέψεις (probabilistic forecasts), οι οποίες έχουν την ικανότητα να ποσοτικοποιούν την αβεβαιότητα σε μία πρόβλεψη (Gneiting & Katzfuss, 2014), παρέχοντας πληροφορίες για τη μελλοντική πιθανότητα ενός ή περισσότερων γεγονότων, με τις πιο διαδεδομένες να είναι οι εξής:

- Προβλέψεις συνόλου (Ensemble forecasts)
- Προβλέψεις ποσοστημορίων (Quantile forecasts)
- Διαστήματα πρόβλεψης (Prediction intervals)
- Προβλεπόμενες κατανομές (Density forecasts)


Σε αυτό το σημείο αξίζει να οριστεί η έννοια των ποσοστημορίων (quantiles), τα οποία διαιρούν την κατανομή ενός μεγέθους σε διαστήματα, όπως φαίνεται στο Σχήμα 4.4. Έστω συνάρτηση αθροιστικής πυκνότητας πιθανότητας  $F$  μιας τυχαίας μεταβλητής  $x$ , τότε το quantile  $q_t$  ορίζεται μοναδικά ως η τιμή του  $x$  τέτοια ώστε  $P(P_t < x) = \tau$  ή ισοδύναμα  $q_t^\tau = F_t^{-1}(\tau)$ , στο διάστημα  $[0, 1]$ .

Επίσης, ως διαστήματα πρόβλεψης ορίζονται το ανώτερο και κατώτερο όριο της διακύμανσης των προβλέψεων σε μία χρονική περίοδο του ορίζοντα πρόβλεψης για δεδομένο διάστημα εμπιστοσύνης, όπως απεικονίζεται στο Σχήμα 4.5. Αντίστοιχα, το διάστημα πρόβλεψης (prediction interval)  $I_{t+k}$  που παράγεται τη χρονική στιγμή  $t$  για τη χρονική στιγμή  $t + k$ , ορίζεται από το ανώτερο και το κατώτερο όριο που δίνονται από τα ακραία quantiles, δηλαδή  $\hat{I}_{t+k}^\beta = [\hat{q}_{t+k}^{\alpha_l}, \hat{q}_{t+k}^{\alpha_u}]$ .

Στη βιβλιογραφία συναντώνται διάφορες τεχνικές παραγωγής πιθανοτικών προβλέψεων για την ίδια μέθοδο σημειακών προβλέψεων, οι οποίες διαχωρίζονται ως προς τον τρόπο



Σχήμα 4.4: Διαίρεση της κατανομής σε ποσοστημόρια.



Σχήμα 4.5: Μορφή μελλοντικών προβλέψεων με απεικόνιση των prediction intervals (μπλε γραμμές).

υπολογισμού της διακύμανσης γύρω από τις σημειακές προβλέψεις (Spiliotis et al., 2021). Η βασικότερη διαφορά έγκειται στην υπόθεση ως προς την κατανομή των σφαλμάτων των σημειακών προβλέψεων στο γνωστό μέρος της χρονοσειράς που εξετάζεται (in-sample σφάλματα), όπου εμφανίζονται η κανονική κατανομή (Normal distribution), η κατανομή Poisson αλλά και η αρνητική διωνυμική κατανομή (Negative Binomial distribution). Η συγκεκριμένη κατανομή όμως πέρα από θεωρητική, όπως αυτές που αναφέρθηκαν, μπορεί να είναι και εμπειρική, δηλαδή να μην πραγματοποιείται κάποια υπόθεση αλλά να υπολογίζεται από τα ιστορικά δεδομένα (kernel density estimate). Οι παραπάνω τεχνικές μπορούν να υπολογιστούν χρησιμοποιώντας τα in-sample σφάλματα, τα οποία αναλύονται λεπτομερώς στη συνέχεια του Κεφαλαίου, ή μέσω μιας διαδικασίας προσομοίωσης η οποία επιτρέπει την προσέγγιση των out-sample σφαλμάτων, τα οποία μπορούν να προσομοιωθούν εφαρμόζοντας μια διαδικασία στην οποία η αρχική σειρά χωρίζεται σε  $N$  παράθυρα εκπαίδευσης και δοκιμής.

Μία εναλλακτική τεχνική χρησιμοποιεί όλα τα in-sample σφάλματα σε μία τεχνική bootstrap, η οποία προσομοιώνει διάφορα “μονοπάτια”, επιλέγοντας κάθε φορά τυχαία ένα εκ των σφαλμάτων. Κατασκευάζονται έτσι πολυάριθμα μελλοντικά μονοπάτια τα οποία διαφοροποιούνται όσο αυξάνεται ο ορίζοντας πρόβλεψης, με τις τελικές πιθανοτικές προβλέψεις να χρησιμοποιούν τα ποσοστημόρια των κατασκευασμένων αυτών μονοπατιών.

Όπως είναι εμφανές, σε αντίθεση με τις προηγούμενες, η συγκεκριμένη τεχνική μπορεί να παράξει διαστήματα τα οποία μεταβάλλονται με τον ορίζοντα πρόβλεψης.

Οι πιθανοτικές προβλέψεις αναδεικνύουν την προτεραιοποίηση των αποφάσεων βάσει των αναμενόμενων, πλην αβέβαιων, αποτελεσμάτων τους. Αρκετά στατιστικά μοντέλα έχουν τη δυνατότητα να παράγουν πιθανοτικές προβλέψεις, καθώς, αντί να παράγουν μία τιμή ως το “καλύτερο” αποτέλεσμα, η πιθανοτική τους πρόβλεψη αποτελείται, όπως υποδηλώνει και το όνομά τους, από πιθανότητες που αναθέτουν σε κάθε πιθανό αποτέλεσμα. Στην ουσία όλα τα μελλοντικά συμβάντα παραμένουν πιθανά, χωρίς ωστόσο να είναι ισοπίθανα τα ενδεχόμενα να πραγματοποιηθούν. Έτσι η πρόβλεψη για παράδειγμα μίας τιμής  $y$  στο ποσοστιακό ποσοστό  $q$ , υποδηλώνει ότι υπάρχει  $q\%$  πιθανότητα η πραγματική τιμή του μεγέθους να είναι ίση με  $y$ .

Όπως αναφέρθηκε, αυτό αποτελεί και την ειδοποιό διαφορά των πιθανοτικών με τις ντετερμινιστικές προβλέψεις και ταυτόχρονα το πλεονέκτημά τους έναντι αυτών, καθώς στην πρώτη περίπτωση η πρόβλεψη περιλαμβάνει περισσότερη πληροφορία, δεδομένου του γεγονότος ότι εμπεριέχει την έννοια των εναλλακτικών. Μία ντετερμινιστική πρόβλεψη είναι δυνατόν να εξαχθεί μέσω της πιθανοτικής, αν ληφθεί η διάμεσος (median) της τελευταίας, το αντίστροφο ωστόσο, δηλαδή η εξαγωγή της πιθανοτικής από τη ντετερμινιστική πρόβλεψη είναι αδύνατο.

Παρά το γεγονός ότι οι πιθανοτικές προβλέψεις μπορούν να θεωρηθούν ανώτερες από τις σημειακές, η υιοθέτησή τους έγινε αρκετά αργά, μιας και η αναγνώρισή τους αυξήθηκε σημαντικά μόνο τα τελευταία χρόνια. Σημαντικός παράγοντας αποτέλεσε η ανάγκη για περισσότερους υπολογιστικούς πόρους και ειδικά εργαλεία λογισμικού, τα οποία δεν ήταν διαθέσιμα κατά το παρελθόν.

Καθίσταται σαφές, έτσι, ότι οι πιθανοτικές προβλέψεις μπορούν να αποτελέσουν σημαντικά εργαλεία στη διάθεση των επιχειρήσεων και των οργανισμών, καθώς επιτρέπουν την ποσοτικοποίηση της έννοιας του ρίσκου κατά τη διαδικασία εξαγωγής προβλέψεων. Ως εκ τούτου μπορούν να συμβάλουν στη λήψη ορθολογικότερων αποφάσεων στις οποίες πέρα από την τιμή της πρόβλεψης, καθιστούν δυνατή την αξιολόγηση της πιθανότητας η εν λόγω πρόβλεψη να αποτελέσει εν τέλει την πραγματική τιμή, καθώς και την ενδεχόμενη τάση διαφόρων γεγονότων τα οποία μπορεί επηρεάσουν τη τιμή μόνο ανοδικά ή μόνο καθοδικά. Στον κλάδο της διαχείρισης αποθεμάτων, η συγκεκριμένη κατηγορία προβλέψεων συνήθως χρησιμοποιείται τόσο για τον πρωταρχικό της ρόλο, τη πρόβλεψη της ζήτησης, όσο και ως εναλλακτική στην υιοθέτηση στρατηγικής αποθέματος ασφαλείας, μιας και η αβεβαιότητα μπορεί εύκολα να ενσωματωθεί στις προβλέψεις (Spiliotis et al., 2021). Ωστόσο, η έρευνα που έχει πραγματοποιηθεί στον τομέα των πιθανοτικών προβλέψεων πωλήσεων προϊόντων είναι μάλλον περιορισμένη (Fildes et al., 2022; Trapero et al., 2019).

#### 4.4 Επιλογή της καταλληλότερης μεθόδου πρόβλεψης

Παρά το γεγονός ότι, λόγω της τεχνολογικής εξέλιξης, η εξαγωγή των προβλέψεων είναι μια εύκολη διαδικασία, η επιλογή της καταλληλότερης μεθόδου πρόβλεψης παραμένει αρκετά δύσκολη. Οι μέθοδοι που συναντώνται στη βιβλιογραφία μπορούν να διαχωριστούν ανάλογα με τις εφαρμογές τους αλλά και τα κύρια χαρακτηριστικά τους, με τους βασικούς

παράγοντες που λαμβάνονται υπόψη κατά την επιλογή της κατάλληλης μεθόδου πρόβλεψης να είναι ο χρονικός ορίζοντας, το πρότυπο συμπεριφοράς των δεδομένων, το κόστος, η αξιοπιστία και η απλότητα.

Με άλλα λόγια, το χρονικό διάστημα στο μέλλον στο οποίο θα αναφέρονται οι προβλέψεις, αλλά και το πλήθος των επιθυμητών περιόδων, τα ποιοτικά χαρακτηριστικά των χρονοσειρών υπό εξέταση, ο όγκος των δεδομένων και η επιθυμητή επίδοση σε σχέση και με το υπολογιστικό κόστος αποτελούν τα πρωταρχικά σημεία κατά την επιλογή μιας μεθόδου.

Ο εντοπισμός της καλύτερης μεθόδου πρέπει να συνοδεύεται από τον υπολογισμό του μικρότερου σφάλματος. Στη βιβλιογραφία εμφανίζονται δύο τύποι σφαλμάτων, το *in-sample* και το *out-sample*, όπως παρουσιάζεται αναλυτικά και στο Υποκεφάλαιο 4.5, όπου το πρώτο χρησιμοποιεί τα ίδια δεδομένα που χρησιμοποιήθηκαν για την κατασκευή της μεθόδου πρόβλεψης, ενώ το δεύτερο χρησιμοποιεί δεδομένα που δεν ήταν διαθέσιμα κατά την κατασκευή.

Είναι αναμενόμενο τα *in-sample* σφάλματα να είναι πιο αισιόδοξα από εκείνα που υπολογίζονται με τη χρήση ενός νέου συνόλου δεδομένων. Ο λόγος που συμβαίνει αυτό είναι ότι η μέθοδος μπορεί να συντονιστεί στον θόρυβο που συναντάται σε ένα σύνολο, ο οποίος όμως δεν υφίσταται ή έχει διαφορετική μορφή σε ένα άλλο, με αποτέλεσμα η ακρίβεια να μειώνεται. Το φαινόμενο αυτό ονομάζεται υπερπροσαρμογή *overfitting* και συναντάται, επίσης, στα μοντέλα μηχανικής μάθησης, όπως αναφέρεται στο Υποκεφάλαιο 6.2.3. Δεν είναι σπάνιο, έτσι, κάποιες φορές να παραμετροποιούνται τα μοντέλα μη βέλτιστα σε ένα σύνολο δεδομένων προκειμένου να εμφανίζουν μεγαλύτερη προσαρμοστικότητα και να έχουν δυνητικά καλύτερη επίδοση σε νέες χρονοσειρές.

Το *out-sample* σφάλμα συνήθως υπολογίζεται με την τεχνική της κυλιόμενης πρόβλεψης (*rolling forecasting*) στις διαθέσιμες “άγνωστες” παρατηρήσεις (Tashman, 2000). Η τεχνική αυτή σχετίζεται με το πλήθος των παρατηρήσεων που λαμβάνονται υπόψη για την εξαγωγή της πρόβλεψης και με τον χειρισμό της “νέας”, πιο πρόσφατης παρατήρησης, που δεν είχε ληφθεί υπόψη αλλά εισέρχεται πλέον ως νέα πληροφορία. Οι δύο εναλλακτικές της διαδικασίας αυτής, κυλιόμενη πρόβλεψη σταθερού παραθύρου (*fixed window rolling forecasting*) και κυλιόμενη πρόβλεψη αυξανόμενου παραθύρου (*increasing window rolling forecasting*), απεικονίζονται στο Σχήμα 4.6.

Ένας άλλος διαχωρισμός της συγκεκριμένης τεχνικής αφορά στην επαναχρησιμοποίηση των παρατηρήσεων, υιοθετώντας έτσι επικαλυπτόμενα (*overlapping*) ή μη επικαλυπτόμενα παράθυρα (*non-overlapping windows*), όπως φαίνεται στο Σχήμα 4.7.

Στις περισσότερες περιπτώσεις, ωστόσο, διαφορετικές τεχνικές και μέθοδοι μπορούν να συμβάλλουν στον εντοπισμό διαφορετικών χαρακτηριστικών της ίδιας χρονοσειράς, κρίνοντας έτσι ότι περισσότερες από μία πρέπει να ληφθούν υπόψη κατά τον υπολογισμό των τελικών προβλέψεων (Clemen, 1989). Ο συνδυασμός αυτός μπορεί να υλοποιηθεί με αρκετούς τρόπους, ο πιο διαδεδομένος από τους οποίους είναι η τοποθέτηση ενός βάρους σε κάθε μέθοδο που έχει επιλεχθεί, αλλά ακόμα και η πιο απλή του μορφή, ο απλός μη σταθμισμένος μέσος όρος, δηλαδή η επίλογη του ίδιου βάρους για κάθε μέθοδο, έχει οδηγήσει σε καλύτερες επιδόσεις, εμφανίζοντας σφάλματα ακόμα και 6% μικρότερα, από τις μεμονωμένες μεθόδους (Armstrong, 2001).

Οι πιο διαδεδομένες τεχνικές συνδυασμού προβλέψεων, πέρα από τις κλασσικές

**Increasing window rolling forecasting**

Time	Data					Forecasts			
$t = 1$	$Y_1$	$Y_2$	$Y_3$	$Y_4$	$Y_5$	$F_1$	$F_2$		
$t = 2$	$Y_1$	$Y_2$	$Y_3$	$Y_4$	$Y_5$	$Y_6$	$F_1$	$F_2$	
$t = 3$	$Y_1$	$Y_2$	$Y_3$	$Y_4$	$Y_5$	$Y_6$	$Y_7$	$F_1$	$F_2$
$t = 4$	$Y_1$	$Y_2$	$Y_3$	$Y_4$	$Y_5$	$Y_6$	$Y_7$	$Y_8$	$F_1$

**Fixed window rolling forecasting**

Time	Data					Forecasts			
$t = 1$	$Y_1$	$Y_2$	$Y_3$	$Y_4$	$Y_5$	$F_1$	$F_2$		
$t = 2$		$Y_2$	$Y_3$	$Y_4$	$Y_5$	$Y_6$	$F_1$	$F_2$	
$t = 3$			$Y_3$	$Y_4$	$Y_5$	$Y_6$	$Y_7$	$F_1$	$F_2$
$t = 4$				$Y_4$	$Y_5$	$Y_6$	$Y_7$	$Y_8$	$F_1$

Σχήμα 4.6: Η τεχνική της κυλιόμενης πρόβλεψης (rolling forecasting), αυξανόμενου παραθύρου (επάνω) και σταθερού παραθύρου (κάτω).

**Overlapping windows**

Time	Data					Forecasts			
$t = 1$									
$t = 2$									
$t = 3$									
$t = 4$									

**Non-overlapping windows**

Time	Data					Forecasts			
$t = 1$									
$t = 2$									
$t = 3$									
$t = 4$									

Σχήμα 4.7: Η τεχνική του επικαλυπτόμενου (overlapping) παραθύρου (επάνω) και του μη επικαλυπτόμενου (non-overlapping) παραθύρου (κάτω).

προσεγγίσεις που χρησιμοποιούν τη μέση ή την διάμεση τιμή των διαθέσιμων προβλέψεων, κάνουν χρήση παλινδρόμησης προκειμένου να υπολογίσουν τα βέλτιστα βάρη κάθε μεθόδου, προσπαθώντας να ελαχιστοποιήσουν έναν επιλεγμένο δείκτη. Τα βάρη αυτά μπορούν να προκύψουν από τα σφάλματα των επιμέρους μεθόδων, την κατάταξη των μεθόδων ως προς τα σφάλματα, κάποια Bayesian διαδικασία, προσεγγίσεις συνδυασμού πληροφοριών ή ακόμα και από προσεγγίσεις που χρησιμοποιούν τα ιδιοδιανύσματα των σφαλμάτων (Hsiao & Wan, 2014). Πιο σύγχρονες τεχνικές, όπως αυτή των Montero-Manso



et al. (2020), μπορούν να επιλέξουν τα βάρη χρησιμοποιώντας αλγορίθμους μηχανικής μάθησης οι οποίοι λαμβάνουν ως εισόδους, πέρα από τα σφάλματα των μεθόδων, συγκεκριμένα χαρακτηριστικά των χρονοσειρών που εξετάζονται (feature-based), ενώ πιο παραδοσιακές προσεγγίσεις περιλαμβάνουν ανθρωπογενείς κανόνες, δηλαδή ο συνδυασμός των διαθέσιμων μεθόδων προκύπτει από ανθρώπινες επιλογές ή κανόνες που έχουν ορίσει άτομα με εμπειρία και γνώση του κλάδου (rule-based).

## 4.5 Κριτήρια απόδοσης μοντέλων πρόβλεψης

Η απόδοση των μοντέλων πρόβλεψης μπορεί να υπολογιστεί από στατιστικούς δείκτες, οι οποίοι, σε αντίθεση με τους δείκτες της βασικής στατιστικής ανάλυσης των χρονοσειρών που αναλύθηκαν στο Κεφάλαιο 3, απαιτούν τόσο την πραγματική σειρά των παρατηρήσεων όσο και μια σειρά πρόβλεψης που προκύπτει από την εφαρμογή κάποιου μοντέλου επί της πραγματικής σειράς.

Παρακάτω δίνονται οι ορισμοί και οι εξισώσεις των πιο διαδεδομένων στατιστικών δεικτών όπως παρουσιάζονται και από τους Πετρόπουλος & Ασημακόπουλος (2011) και Σπηλιώτης (2017).

Ως σφάλμα τη στιγμή  $t$  ορίζεται η αλγεβρική διαφορά μεταξύ της πραγματικής τιμής της χρονοσειράς και της πρόβλεψης ως εξής:

$$e_t = Y_t - F_t$$

Πίνακας 4.6: Παρατηρήσεις χρονοσειράς και προβλέψεις προς στατιστική ανάλυση απόδοσης προβλέψεων.

Period	Series	Forecasts	Part
1	$Y_1$	$F_1$	In-sample
2	$Y_2$	$F_1$	
3	$Y_3$	$F_1$	
⋮	⋮	⋮	
t-1	$Y_{t-1}$	$F_{t-1}$	
t	$Y_t$	$F_t$	
t+1		$F_{t+1}$	Out-of-sample
⋮		⋮	
t+h		$F_{t+h}$	

Προτού γίνουν διαθέσιμες οι πραγματικές παρατηρήσεις της χρονοσειράς  $Y_{t+1}$  έως  $Y_{t+h}$ , η τιμή του σφάλματος μπορεί να υπολογιστεί αποκλειστικά για τις τιμές in-sample. Αφού παρέλθει κατάλληλο χρονικό διάστημα και τα δεδομένα έχουν γίνει διαθέσιμα, μπορεί να υπολογιστεί και το σφάλμα για τις τιμές out-of-sample, άρα μπορεί να υπολογιστεί τόσο το σφάλμα του μοντέλου πρόβλεψης όσο και το πραγματικό σφάλμα. Παρακάτω παρουσιάζονται οι πιο διαδεδομένοι στατιστικοί δείκτες σφάλματος, οι οποίοι είναι εκφρασμένοι έτσι ώστε να αναφέρονται στο σφάλμα του μοντέλου πρόβλεψης, αλλά με κατάλληλες αλλαγές στις περιόδους που συμμετέχουν στον υπολογισμό μπορούν να

αναφερθούν και στο πραγματικό σφάλμα.

### **Μέσο σφάλμα (Mean Error)**

Υπολογίζεται από τον απλό προσημασμένο μέσο όρο των σφαλμάτων και εκφράζει ένα μέτρο συστηματικότητας του σφάλματος. Όσο η τιμή αυτού είναι κοντά στο μηδέν, τόσο τα σφάλματα είναι τυχαία και όχι συστηματικά. Αν ο δείκτης παίρνει θετικές τιμές, δηλώνει απαισιοδοξία στις προβλέψεις, μιας και οι προβλέψεις ήταν κατά μέσο όρο μικρότερες των πραγματικών τιμών. Από την άλλη, αρνητικές τιμές του δείκτη δηλώνουν αισιοδοξία. Συχνά ο δείκτης αναφέρεται και ως μεροληψία (bias) και υπολογίζεται από τον εξής τύπο:

$$ME = \frac{1}{n} \sum_{t=1}^n (Y_t - F_t)$$

### **Μέσο απόλυτο σφάλμα (Mean Absolute Error)**

Αποτελεί ένα μέτρο της ακρίβειας της πρόβλεψης έναντι των πραγματικών τιμών διατηρώντας τις μονάδες μέτρησης της αρχικής χρονοσειράς. Εκφράζει τη μέση αστοχία της πρόβλεψης, χωρίς να δίνεται σημασία στην κατεύθυνση της πρόβλεψης. Όσο μεγαλύτερη είναι η τιμή του δείκτη, τόσο μικρότερη προκύπτει η ακρίβεια της μεθόδου που εφαρμόστηκε. Αρνητικό του εν λόγω δείκτη είναι ότι εξαρτάται από την κλίμακα της χρονοσειράς και συνεπώς δεν μπορεί να χρησιμοποιηθεί για να εξαγάγει συμπεράσματα σε σειρές πολλών χρονοσειρών.

$$MAE = \frac{1}{n} \sum_{t=1}^n |Y_t - F_t|$$

### **Μέσο τετραγωνικό σφάλμα (Mean Squared Error)**

Όπως και το απόλυτο σφάλμα, αποτελεί μέτρο της ακρίβειας πρόβλεψης, το οποίο όμως δίνει πολύ μεγαλύτερο βάρος στα μεγάλα σφάλματα. Αυτό γίνεται δεδομένου ότι τα σφάλματα τετραγωνίζονται και συνεπώς σφάλματα με μικρές τιμές λαμβάνουν μικρότερο βάρος κατά τον υπολογισμό του. Χρησιμοποιείται ευρέως για τον υπολογισμό των βέλτιστων παραμέτρων εξομάλυνσης και την προσαρμογή μοντέλων πρόβλεψης.

$$MSE = \frac{1}{n} \sum_{t=1}^n (Y_t - F_t)^2$$

### **Ρίζα μέσου τετραγωνικού σφάλματος (Root Mean Squared Error)**

Υπολογίζεται άμεσα από την τετραγωνική ρίζα του μέσου τετραγωνικού σφάλματος. Έχει τις ίδιες ιδιότητες με αυτό, αλλά είναι εκφρασμένο στις μονάδες της αρχικής χρονοσειράς προκειμένου να γίνεται πιο κατανοητό.

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - F_t)^2}$$

### **Μέσο απόλυτο ποσοστιαίο σφάλμα (Mean Absolute Percentage Error)**

Συχνά είναι απαραίτητος ο υπολογισμός των σφαλμάτων πρόβλεψης σε ποσοστιαία μορφή. Αυτό είναι ιδιαίτερα χρήσιμο όταν θέλουμε για παράδειγμα να συγκρίνουμε την ακρίβεια μιας μεθόδου πρόβλεψης που έχει εφαρμοσθεί σε περισσότερες από μία

χρονοσειρές διαφορετικού επιπέδου μέσης τιμής ή όταν οι πραγματικές τιμές είναι ιδιαίτερα υψηλές. Το μέσο απόλυτο ποσοστιαίο σφάλμα είναι εκφρασμένο επί τοις εκατό και λαμβάνει τιμές μεγαλύτερες ή ίσες του μηδενός, με τις μικρότερες τιμές να υποδηλώνουν και καλύτερη απόδοση της μεθόδου πρόβλεψης. Στην πραγματικότητα αποτελεί δηλαδή μία ποσοστιαία έκφραση του απόλυτου σφάλματος, με το μειονέκτημα βέβαια ότι οδηγεί σε απροσδιοριστίες για μηδενικές τιμές και σε ακραίες τιμές για τιμές μικρότερες της μονάδας.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - F_t}{Y_t} \right| \cdot 100(\%)$$

#### **Συμμετρικό μέσο απόλυτο ποσοστιαίο σφάλμα (Symmetric Mean Absolute Percentage Error)**

Αποτελεί μια παραλλαγή του μέσου απόλυτου ποσοστιαίου σφάλματος και υπολογίζεται ως εξής:

$$sMAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - F_t}{\left(\frac{Y_t + F_t}{2}\right)} \right| \cdot 100(\%)$$

Σε αντίθεση με το μέσο απόλυτο σφάλμα, το απόλυτο του σφάλματος δε διαιρείται απλώς με την πραγματική τιμή, αλλά με το ημίθροισμα της πραγματικής τιμής και της πρόβλεψης. Με την αλλαγή αυτή, ο δείκτης αυτός αποκτά και πάνω όριο και πλέον μπορεί να πάρει τιμές στο διάστημα [0%,200%]. Έτσι λύνονται τα προβλήματα απροσδιοριστίας και ακραίων τιμών που αναφέρθηκαν στην περίπτωση του απόλυτου ποσοστιαίου σφάλματος. Ένα πρόβλημα βέβαια με το συγκεκριμένο δείκτη είναι ότι οι αισιόδοξες και οι απαισιόδοξες προβλέψεις δεν μεταχειρίζονται αντίστοιχα. Έτσι, μοντέλα με την ίδια απόλυτη ακρίβεια αλλά διαφορετική προκατάληψη θα έχουν διαφορετικές τιμές σφάλματος, με τις αισιόδοξες προβλέψεις να υπερτερούν. Ο εν λόγω δείκτης είναι από τους πιο διαδεδομένους στις τεχνικές προβλέψεων και λόγω των πλεονεκτημάτων του χρησιμοποιείται ιδιαίτερα σε διαγωνισμούς προβλέψεων.

#### **Σχετικά σφάλματα (Relative Measures)**

Συχνά ζητούμενο δεν είναι η αξιολόγηση της απόλυτης ακρίβειας πρόβλεψης, αλλά η εξακρίβωση του κατά πόσο μία μέθοδος είναι πιο αποτελεσματική από μία άλλη. Τέτοια περίπτωση μπορεί να είναι η μελέτη αντικατάστασης μίας μεθόδου πρόβλεψης σε μία επιχείρηση με μία καινούργια. Έτσι, λόγω των προβλημάτων και των περιορισμών που συνεπάγονται τα σφάλματα που παρουσιάστηκαν νωρίτερα, ένας ασφαλής τρόπος μέτρησης της απόδοσης μίας μεθόδου είναι ο υπολογισμός του σχετικού της σφάλματος ως προς μία μέθοδο αναφοράς (benchmark). Για λόγους απλότητας, και όταν δεν υπάρχει προφανής απάντηση, ως μέθοδο αναφοράς τίθεται η απλοϊκή μέθοδος ή μία άλλη η οποία χαρακτηρίζεται από σχετική απλότητα. Σκοπός είναι να εξακριβωθεί αν η συγκρινόμενη μέθοδος, που είναι και πιο πολύπλοκη, οδηγεί σε βελτίωση της προβλεπτικής ικανότητας. Αν δηλαδή αξίζει να θυσιάσουμε υπολογιστικό κόστος προκειμένου να γίνουμε πιο ακριβείς. Το σχετικό σφάλμα ορίζεται με τη χρήση ενός μέτρου ακρίβειας (error metric - EM) ως εξής:

$$Rel_{EM} = \frac{EM_t}{EM_t^{benchmark}}$$

Έτσι, σε περίπτωση που το ζητούμενο είναι η ακρίβεια, ως δείκτη μπορούμε να χρησιμοποιήσουμε το μέσο απόλυτο σφάλμα, ενώ αν το ζητούμενο είναι η αμεροληψία, το μέσο σφάλμα. Το σχετικό σφάλμα με τιμές μικρότερες της μονάδας φανερώνει ότι η συγκρινόμενη μέθοδος υπερτερεί της μεθόδου αναφοράς, ενώ με τιμές μεγαλύτερες της μονάδας το αντίθετο. Έτσι, μία τιμή π.χ. 0.8 φανερώνει ότι η συγκρινόμενη μέθοδος είναι κατά μέσο όρο κατά 20% καλύτερη από αυτήν της αναφοράς.

#### **Μέσο απόλυτο κανονικοποιημένο σφάλμα (Mean Absolute Scaled Error)**

Οι Hyndman & Koehler (2006), προκειμένου να αντιμετωπίσουν τις περιπτώσεις απροσδιοριστίας των δεικτών MAPE και sMAPE αλλά και να δώσουν την ίδια βαρύτητα στα μικρά και τα μεγάλα σφάλματα, σε αντίθεση με τους δείκτες MSE και RMSE, πρότειναν τον ακόλουθο στατιστικό δείκτη για τη μέτρηση της ακρίβειας πρόβλεψης:

$$MASE = \frac{\frac{1}{n} \sum_{t=1}^n |Y_t - F_t|}{\frac{1}{n-1} \sum_{t=2}^n |Y_t - Y_{t-1}|}$$

Πρόκειται στην ουσία για υποπερίπτωση του σχετικού σφάλματος κατά την οποία κανονικοποιούμε με τη μέση τιμή των διαφορών πρώτου βαθμού της χρονοσειράς, με την πρόβλεψη δηλαδή της απλοϊκής μεθόδου.

Σε αυτό το σημείο αναφέρεται ότι, αν και θεωρητικά δεν μπορεί να τεκμηριωθεί, το κανονικοποιημένο σφάλμα έχει ως κάτω όριο το 0.5. Το εν λόγω συμπέρασμα έχει αποδειχτεί εμπειρικά μέσα από μελέτες που πραγματοποιήθηκαν σε μεγάλα δείγματα χρονοσειρών διαφόρων τύπων και χαρακτηριστικών και οι οποίες έδειξαν ότι υπό φυσιολογικές συνθήκες μία μέθοδος δεν μπορεί πρακτικά να είναι καλύτερη πάνω από 2 φορές από την απλοϊκή. Αντίθετα, αν είναι αποτελεσματική, η τιμή του σφάλματος αναμένεται να είναι κοντά στο 0.7 και σπάνια να υπερβαίνει το 0.9. Αυτό συμβαίνει λόγω της τυχαιότητας των χρονοσειρών η οποία έχει ως αποτέλεσμα να μην μία μέθοδος να υπερτερεί μίας άλλης, αλλά ποτέ να μην πετυχαίνει τέτοια ακρίβεια που να εκμηδενίζει την απόδοση της αναφοράς. Έτσι, αν μία αντικειμενικά αποτελεσματικότερη μέθοδος πετύχει μεμονωμένα ακρίβεια μικρότερη από 0.5 ή μεγαλύτερη του 0.9, το εν λόγω αποτέλεσμα οφείλεται πιθανότατα σε τύχη.

#### **Ρίζα μέσου τετραγωνικού κανονικοποιημένου σφάλματος (Root Mean Squared Scaled Error)**

Ο δείκτης RMSSE έχει παρόμοια χαρακτηριστικά με τον δείκτη MASE, με βασική διαφορά το αυξημένο βάρος που δίνεται στα μεγαλύτερα σφάλματα λόγω των τετράγωνων των διαφορών προβλέψεων και παρατηρήσεων. Η μαθηματική διατύπωση του δείκτη έχει ως εξής:

$$RMSSE = \sqrt{\frac{\frac{1}{n} \sum_{t=1}^n (Y_t - F_t)^2}{\frac{1}{n-1} \sum_{t=2}^n (Y_t - Y_{t-1})^2}}$$

Ο συγκεκριμένος δείκτης χρησιμοποιείται ευρέως σε διάφορες εφαρμογές, καθώς αντιμετωπίζει με συμμετρικό τρόπο τα αρνητικά και θετικά σφάλματα, έχει καθορισμένη μέση τιμή και πεπερασμένη απόκλιση. Επίσης, είναι ο δείκτης που χρησιμοποιήθηκε στον

διαγωνισμό M5, που θα αναλυθεί παρακάτω, μιας και η αντιπροσωπευτικότητα των αποτελεσμάτων του τον καθιστά ιδανικό όταν εξετάζονται σύνολα χρονοσειρών διαφορετικών επιπέδων.

### Theil's U-Statistic

Ο Theil (1966) πρότεινε ένα δείκτη σφάλματος, ο οποίος συνδυάζει χαρακτηριστικά σχετικών σφαλμάτων, δίνοντας παράλληλα μεγαλύτερο βάρος στα μεγαλύτερα σφάλματα, καθώς μεγάλα σφάλματα για μια επιχείρηση συνεπάγονται και ισοδύναμα μεγάλη ζημιά. Ο στατιστικός αυτός δείκτης επιτρέπει τη συγκριτική συσχέτιση της ακρίβειας των προβλέψεων με τις προβλέψεις της μεθόδου Naive και ταυτόχρονα τετραγωνίζει τα σφάλματα, ούτως ώστε να δίνεται μεγαλύτερο βάρος στις μεγάλες αποκλίσεις. Η μαθηματική διατύπωση του δείκτη έχει ως εξής:

$$U = \sqrt{\frac{\sum_{t=2}^n \left( \frac{|Y_t - F_t|}{|Y_{t-1}|} \right)^2}{\sum_{t=2}^n \left( \frac{|Y_t - Y_{t-1}|}{|Y_{t-1}|} \right)^2}}$$

- Αν  $U = 1$ , τότε η μέθοδος Naive είναι εξίσου ακριβής με την μέθοδο πρόβλεψης που εφαρμόστηκε.
- Αν  $U < 1$ , τότε η μέθοδος πρόβλεψης που εφαρμόστηκε έχει καλύτερη απόδοση από πλευράς ακρίβειας σε σχέση με τη μέθοδο Naive (όσο μικρότερη τιμή, τόσο καλύτερη απόδοση).
- Αν  $U > 1$ , τότε η μέθοδος πρόβλεψης που εφαρμόστηκε έχει χειρότερη απόδοση από πλευράς ακρίβειας σε σχέση με τη μέθοδο Naive, οπότε δεν υπάρχει λόγος να εφαρμοσθεί (όσο μεγαλύτερη τιμή, τόσο χειρότερη απόδοση).

### Percentage Better

Μια συσχετιστική προσέγγιση, που επιτρέπει την σύγκριση διαφορετικών μεθόδων που έχουν εφαρμοσθεί σε μεγάλο πλήθος χρονοσειρών διαφορετικών επιπέδων, είναι η χρήση του ποσοστού για το οποίο μια μέθοδος βάσει ενός δείκτη EM είναι ακριβέστερη έναντι μιας μεθόδου αναφοράς για ένα συγκεκριμένο δείκτη σφάλματος. Ο δείκτης ορίζεται ως εξής:

$$\text{Percentage Better} = \text{mean}(I\{EM_t < EM_t^{\text{benchmark}}\}) \cdot 100(\%)$$

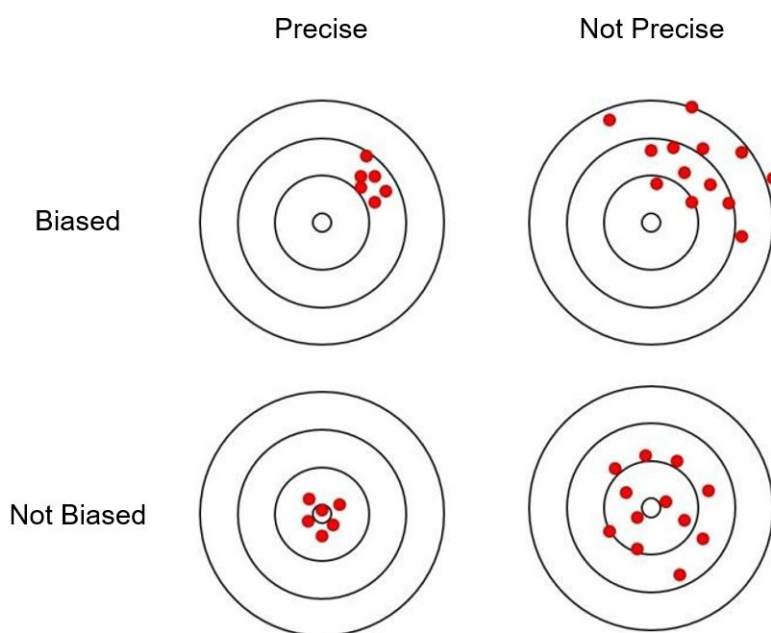
Το μειονέκτημα του παραπάνω δείκτη είναι ότι δε δίνει καμία αίσθηση του επιπέδου βελτίωσης. Έτσι, αν μία μέθοδος υπερτερεί της αναφοράς οριακά στο μεγαλύτερο ποσοστό των περιπτώσεων, αλλά υστερεί σημαντικά στο υπόλοιπο, ο δείκτης θα ισχυρισθεί ότι η μέθοδος είναι σαφώς καλύτερη.

Σε αυτό το σημείο αξίζει να αναφερθεί η διαφορά μεταξύ ακρίβειας (precision) προβλέψεων και της προκατάληψής τους (bias).

- Η προκατάληψη αντιπροσωπεύει το ιστορικό μέσο σφάλμα. Οι προβλέψεις μπορεί να είναι κατά μέσο όρο, πολύ υψηλές (οι προβλέψεις να υπερεκτιμούν τη ζήτηση) ή πολύ χαμηλές (οι προβλέψεις να υποεκτιμούν τη ζήτηση), με αποτέλεσμα να είναι ξεκάθαρη η συνολική κατεύθυνση του σφάλματος.

- Η ακρίβεια μετρά την διαφορά μεταξύ της πρόβλεψης και της πραγματικής παρατηρήσεις, με αποτέλεσμα η ακρίβεια μιας πρόβλεψης να δίνει μια ιδέα για το μέγεθος των σφαλμάτων αλλά όχι τη συνολική τους κατεύθυνση.

Όπως είναι αναμενόμενο, το πιο επιθυμητό είναι οι παραγόμενες προβλέψεις να είναι ακριβείς (precise) χωρίς να εμφανίζουν προκατάληψη (not biased), όπως φαίνεται και στο Σχήμα 4.8.



Σχήμα 4.8: Απεικόνιση των εννοιών της προκατάληψης (bias) και της ακριβείας (precision).

## 4.6 Ακρίβεια προβλέψεων και συστήματα διαχείρισης αποθεμάτων

Από αυτή την πληθώρα δεικτών, που παρουσιάστηκαν παραπάνω, οι οποίοι μπορούν να υπολογίσουν τα σφάλματα των μεθόδων πρόβλεψης, προκύπτει ότι είναι πιθανό διαφορετικές μέθοδοι να εμφανίζουν τα μικρότερα σφάλματα, όταν αυτά υπολογίζονται με διαφορετικούς δείκτες με αποτέλεσμα να επιλεγεί λανθασμένα μία μη βέλτιστη μέθοδος για την εξεταζόμενη εφαρμογή (Koutsandreas et al., 2022). Στο ίδιο μήκος κύματος, θεωρώντας ως δείκτη την απόδοση του αποθέματος, δεν προκύπτει ξεκάθαρη σχέση μεταξύ ακρίβειας πρόβλεψης και βελτιστοποίηση του μοντέλου διαχείρισης αποθεμάτων (Goltsos et al., 2022). Με τον τρόπο αυτό, η μέθοδος πρόβλεψης της ζήτησης η οποία επιτυγχάνει την ελαχιστοποίηση του κόστους αποθεματοποίησης δεν είναι απαραίτητα αυτή με την καλύτερη ακρίβεια πρόβλεψης (Tratar, 2010; Kourentzes et al., 2020). Σε ορισμένες περιπτώσεις, οι πιθανές δαπανηρές ελλείψεις αποθέματος, που μπορεί να προκληθούν από προβληματικές παραδοχές ελέγχου των αποθεμάτων σε σχέση με την κατανομή των σφαλμάτων πρόβλεψης, μπορούν να αποφευχθούν από θετική μεροληψία (bias) στις προβλέψεις (Babai et al., 2014). Ωστόσο το συμπέρασμα ότι η μεροληψία των προβλέψεων

μπορεί να βελτιώσει την απόδοση του συστήματος διαχείρισης αποθεμάτων είναι προβληματική και ενδεικτική εύθραυστων υποθέσεων (Taylor, 2007; Syntetos & Boylan, 2008).

Επιπλέον, ακόμη και όταν η ακρίβεια της πρόβλεψης και οι βελτιώσεις στην απόδοση του αποθέματος είναι προς την ίδια κατεύθυνση, αυτές μπορεί να διαφέρουν ως προς το μέγεθος. Οι Syntetos et al. (2010), χρησιμοποιώντας δεδομένα του κλάδου των ανταλλακτικών, βρήκαν ότι μια μείωση της τάξης του 1% στην ακρίβεια πρόβλεψης μπορεί να μεταφραστεί σε μείωση 10-15% στο κόστος αποθεματοποίησης, δημιουργώντας, έτσι, περαιτέρω αμφιβολίες ως προς τον βαθμό που οι στατιστικοί δείκτες ακρίβειας των προβλέψεων μπορούν να βοηθήσουν στην εξήγηση της απόδοσης των συστημάτων διαχείρισης του αποθέματος. Στην ίδια κατεύθυνση, οι Spiliotis et al. (2021), χρησιμοποιώντας δεδομένα εταιρείας λιανικής, κατέληξαν στο συμπέρασμα ότι αν και οι ακριβείς μέθοδοι πρόβλεψης είναι πιο πιθανό να οδηγήσουν σε επιθυμητά επίπεδα εξυπηρέτησης πελατών και χαμηλό κόστος αποθεματοποίησης, είναι επίσης δυνατό λιγότερο εξελιγμένα μοντέλα, μικρότερης ακρίβειας, να οδηγήσουν σε καλύτερα αποτελέσματα διαχείρισης αποθεμάτων. Οι Pinçe et al. (2021) πραγματοποίησαν μια ενδελεχή περιγραφή των μεθόδων πρόβλεψης χρονοσειρών διακοπόμενης ζήτησης που συναντώνται στη βιβλιογραφία, αναλύοντας επίσης τους διάφορους δείκτες που χρησιμοποιούνται για τον υπολογισμό της απόδοσής τους, οι οποίοι μπορεί να σχετίζονται είτε με την ακρίβεια των παραγόμενων προβλέψεων είτε με την επίδοση του αποθέματος που συνεπάγονται, προσπαθώντας να εντοπίσουν την μέθοδο που θα πρέπει να προτιμάται σε κάθε περίπτωση. Ωστόσο, και σε αυτή την περίπτωση οι ερευνητές συμπέραναν ότι τα δύο είδη δεικτών θα πρέπει να χρησιμοποιούνται μαζί για να παρέχουν μια πιο ολοκληρωμένη εικόνα των επιδόσεων των διαφόρων μεθόδων πρόβλεψης, καθώς μπορούν να οδηγήσουν σε διαφορετικά αποτελέσματα απόδοσης, παρά το γεγονός ότι εφαρμόζονται στις ίδιες μεθόδους και τα ίδια σύνολα δεδομένων.

Συμπερασματικά, η υπόθεση ότι η βελτίωση της ακρίβειας της πρόβλεψης της ζήτησης θα μεταφραστεί σε κέρδη σχετικά με το απόθεμα δεν φαίνεται να ισχύει καθολικά και δείχνει να εξαρτάται από την εγκυρότητα διαφόρων υποθέσεων κατά τους υπολογισμούς της διαχείρισης των αποθεμάτων. Αυτό που τονίζουν τα παραπάνω είναι η περιορισμένη κατανόηση των αλληλεπιδράσεων μεταξύ των μεγεθών αυτών. Με άλλα λόγια, η σχέση μεταξύ της ακρίβειας των παραγόμενων προβλέψεων ζήτησης και της χρησιμότητάς τους, όταν εξετάζεται η απόδοση ως προς τη διαχείριση αποθεμάτων, παραμένει πολύπλοκη (Ali et al., 2012; Kourentzes et al., 2021). Δεν μπορεί, έτσι, ακόμα να υπολογιστεί η επίπτωση, θετική ή αρνητική, που μπορεί να έχει στα κέρδη της εταιρείας η παραγωγή προβλέψεων μικρότερου σφάλματος.

“Η μάθηση μέσω της δράσης, η αλληλοδιδασκτική μέθοδος διδασκαλίας και η προσομοίωση μέσω υπολογιστή αποτελούν μέρος της ίδιας εξίσωσης.”

– *Nicholas Negroponte*



## Κεφάλαιο 5

# Παραγωγή τεχνητών χρονοσειρών και προσομοίωση αποθέματος

---

Για να επιβεβαιωθούν, και να εμπλουτιστούν, τα συμπεράσματα της παρούσας διατριβής, πρωταρχικής σημασίας αποτελεί η εφαρμογή του προτεινόμενου μεθοδολογικού πλαισίου σε μεγάλα και διαφορετικά σύνολα δεδομένων. Για να αποκτηθεί ένα τέτοιο σετ μπορεί κανείς να στραφεί σε χρονοσειρές που χρησιμοποιούνται ευρέως στην επιστημονική κοινότητα για την αξιολόγηση τεχνικών προβλέψεων και άλλων μεθοδολογιών, στη συλλογή νέων από εξωτερικούς φορείς ή στην παραγωγή τεχνητών μέσω διαδικασιών προσομοίωσης (simulation) και αναδειγματοληψίας (bootstrapping).

Από τα πιο συχνά χρησιμοποιούμενα σετ δεδομένων για την αξιολόγηση μεθόδων και τεχνικών πρόβλεψης είναι οι χρονοσειρές των διαγωνισμών M (Makridakis Competitions), έχοντας χρησιμοποιηθεί σε τόσες μελέτες που αποτελούν, πλέον, ειδικά στον τομέα των προβλέψεων, το βασικότερο σημείο αναφοράς προκειμένου να εξακριβωθεί η επίδοση οποιασδήποτε νέας μεθόδου.

Στο παρόν Κεφάλαιο παρουσιάζεται η μεθοδολογία που ακολουθήθηκε προκειμένου να παραχθούν τεχνητές χρονοσειρές ποικίλων χαρακτηριστικών και ομοιόμορφα κατανεμημένων ως προς αυτά, καθώς επίσης και ορισμένα σετ δεδομένων από διαγωνισμούς προβλέψεων.

### 5.1 Ανασκόπηση γεννητριών παραγωγής τεχνητών χρονοσειρών

Για να παραχθεί ένα σύνολο δεδομένων με χρονοσειρές ποικίλων ποιοτικών χαρακτηριστικών και διαφορετικής έντασης αυτών, βασικό βήμα αποτελεί ο καθορισμός και η ποσοτικοποίηση των χαρακτηριστικών. Προφανώς, διαφορετικά χαρακτηριστικά θα ληφθούν υπόψη για την παραγωγή τεχνητών χρονοσειρών συνεχούς φύσης, με εποχιακότητα ή τάση, και διαφορετικά για την παραγωγή χρονοσειρών διακοπτόμενης φύσης.

Όπως αναφέρθηκε στο Υποκεφάλαιο 3.2, κάθε χρονοσειρά μπορεί να αναλυθεί στα τέσσερα βασικά ποιοτικά της χαρακτηριστικά, δηλαδή την εποχιακότητα, την τάση, τον κύκλο και την τυχαιότητα, οπότε κατα αντιστοιχία είναι εφικτό να κατασκευαστεί μία νέα χρονοσειρά χρησιμοποιώντας αυτά τα επιμέρους χαρακτηριστικά. Σχετική μελέτη, η οποία

παρουσιάζει προσεγγίσεις παραγωγής τόσο συνεχών όσο και διακοπτόμενων χρονοσειρών είναι αυτή των Petropoulos et al. (2014). Η διαδικασία παραγωγής προϋποθέτει ένα ντετερμινιστικό, πολλαπλασιαστικό μοντέλο όπου κάθε συστατικό του εφαρμόζεται ανεξάρτητα, όπως προτείνεται και από τους Miller & Williams (2003), αλλά εισάγεται επιπλέον η συνιστώσα της κυκλικότητας.

Έτσι, μία νέα σειρά μπορεί να παραχθεί αξιοποιώντας την εξίσωση της κλασσικής πολλαπλασιαστική μεθόδου αποσύνθεσης ως εξής:

$$Y_t = S_t \cdot T_t \cdot C_t \cdot R_t$$

Η λογική της γεννήτριας βασίζεται στην υπόθεση ότι δεδομένης μίας τάσης, εποχιακότητας, κυκλικότητας και τυχαιότητας συγκεκριμένης έντασης, μπορεί κανείς να παράξει μία νέα χρονοσειρά ως το γινόμενο τους. Προσθέτοντας στην εξίσωση τον όρο  $L$  ο οποίος αφορά στο αρχικό επίπεδο της σειράς μπορεί να δημιουργηθεί μία σειρά με συγκεκριμένα χαρακτηριστικά και μέσο επίπεδο  $L$  ως εξής:

$$Y_t = L \cdot S_t \cdot T_t \cdot C_t \cdot R_t$$

Ακολουθώντας αντίστοιχη λογική, οι Petropoulos et al. (2014) πρότειναν επίσης μία διαδικασία παραγωγής τεχνητών χρονοσειρών διακοπτόμενης ζήτησης, στην οποία ως επιμέρους συστατικά χρησιμοποιήθηκαν η εμφάνιση ή όχι μη μηδενική ζήτησης ( $I$ ) και το μέγεθος των μη μηδενικών ζητήσεων ( $D$ ) ως εξής:

$$Y_t = I_t \cdot D_t$$

Η διαδικασία που ακολουθείται για την παραγωγή μίας σειράς διακοπτόμενης ζήτησης παρουσιάζεται αναλυτικά στη συνέχεια του Κεφαλαίου.

Άλλη ενδιαφέρουσα προσέγγιση παραγωγής τεχνητών χρονοσειρών αποτελεί η μελέτη των Kang et al. (2020), οι οποίοι πρότειναν ένα πλαίσιο κατασκευής χρονοσειρών, ονόματι GRATIS (GeneRAting Time Series), ποικίλων αλλά ελεγχόμενων χαρακτηριστικών κάνοντας χρήση μίγματος αυτοπαλινδρούμενων μοντέλων (MAR). Μεταβάλλοντας τις παραμέτρους των μοντέλων MAR, το συγκεκριμένο πλαίσιο είναι σε θέση να παράγει σειρές επιλεγμένων κάθε φορά χαρακτηριστικών.

## 5.2 Γεννήτρια παραγωγής τεχνητών χρονοσειρών

Μιας και η παρούσα εργασία εστιάζει στις χρονοσειρές διακοπτόμενης ζήτησης, παρακάτω θα αναλυθεί η διαδικασία παραγωγής τεχνητών χρονοσειρών αποκλειστικά αυτής της κατηγορίας.

Η συγκεκριμένη μεθοδολογία λαμβάνει υπόψη, ως χαρακτηριστικά, τη μέση τιμή των διαστημάτων μεταξύ των ζητήσεων ( $ADI$ ) και τον τετραγωνικό συντελεστή της μεταβλητότητας της ζήτησης ( $CV^2$ ) σε ακολουθία και της μελέτης των Syntetos et al. (2005). Επιπλέον, εισάγει στην διαδικασία και το μήκος της χρονοσειράς, δηλαδή το πλήθος των παρατηρήσεων. Έτσι, αποτελεί απλά επέκταση της μεθοδολογίας που χρησιμοποιείται για την παραγωγή

συνεχών χρονοσειρών.

Προκειμένου να παραχθεί μία χρονοσειρά επιλεγμένου πλήθους παρατηρήσεων ( $l$ ) και επιπέδου  $ADI$ , κατασκευάζεται ένα διάνυσμα το οποίο καθορίζει την εμφάνιση μη μηδενικών παρατηρήσεων ως μία κατανομή Bernoulli (Croston, 1972; Syntetos & Boylan, 2001), με  $p = \frac{1}{ADI}$ . Το αποτέλεσμα αυτού του βήματος είναι ένα δυαδικό διάνυσμα ( $I_t$ ) μήκους  $l$ . Το μέγεθος των μη μηδενικών ζητήσεων είναι τυχαίο αριθμού μιας αρνητικής διωνυμικής κατανομής (negative binomial distribution) (Syntetos et al., 2011) στους οποίους προστίθεται η μονάδα προκειμένου να μην υπάρχουν μηδενικές τιμές. Ο αριθμός των επιτυχημένων δοκιμών ( $n$ ) και η πιθανότητα επιτυχίας ( $p$ ) μπορεί να εκφραστεί ως εξής:

$$n = \frac{\mu p}{1 - p} \text{ και } p = \frac{\mu}{CV^2(\mu + 1)^2},$$

όπου  $CV^2$  είναι το επιλεγμένο επίπεδο του τετραγωνικού συντελεστή της μεταβλητότητας της ζήτησης και  $\mu$  είναι η μέση τιμή. Έτσι, οι  $l$  παραγόμενες τιμές της αρνητικής διωνυμικής κατανομής δημιουργούν το διάνυσμα  $d_t$ , με αποτέλεσμα οι μη μηδενικές ζητήσεις να προκύπτουν ως  $D_t = d_t + 1$ .

Οι τελικές τιμές της παραγόμενης χρονοσειράς προκύπτουν ως εξής:

$$Y_t = \begin{cases} I_t \cdot D_t, & \text{για } t = 1, \dots, l \text{ όταν } CV^2 > 0 \\ \text{round}(\mu), & \text{για } t = 1, \dots, l \text{ όταν } CV^2 = 0 \end{cases}$$

Με τον τρόπο αυτό, επιλέγοντας τις κατάλληλες τιμές  $ADI$  και  $CV^2$ , σε συνδυασμό με την κατηγοριοποίηση χρονοσειρών σύμφωνα με τους Syntetos et al. (2005), ακολουθώντας την παραπάνω μεθοδολογία μπορεί να κατασκευαστεί μία χρονοσειρά smooth, lumpy, erratic ή intermittent με μήκος  $l$  και μη μηδενικές παρατηρήσεις γύρω από την τιμή  $\mu$ .

### 5.2.1 Υλοποίηση γεννήτριας και παραγωγή χρονοσειρών

Έχοντας ορίσει πλέον τα απαραίτητα χαρακτηριστικά και τη διαδικασία παραγωγής, σειρά έχει η παραγωγή των χρονοσειρών. Αυτές αποφασίστηκε να έχουν μήκος 548 παρατηρήσεων (1.5 έτος ημερήσιων δεδομένων) καθώς έτσι εξασφαλίζονται επαρκές τιμές για την πειραματική διαδικασία, χωρίς ωστόσο να αυξάνεται δραματικά το υπολογιστικό κόστος. Επίσης επιλέχθηκε το σύνολο δεδομένων να αποτελείται από τον ίδιο αριθμό χρονοσειρών των τεσσάρων κατηγοριών (smooth, lumpy, erratic, intermittent), σύμφωνα με τους Syntetos et al. (2005), όπως αναλύθηκε στο Κεφάλαιο 3.6.4, προκειμένου αυτό να είναι όσο το δυνατόν λιγότερο προκατειλημμένο.

Η παραγωγή των τεχνητών χρονοσειρών πραγματοποιείται σε οκτώ βήματα που παρουσιάζονται παρακάτω. Έτσι, προκειμένου να γίνει πιο εύκολα αντιληπτή η διαδικασία παραγωγής χρονοσειρών, δίνεται ως παράδειγμα η εφαρμογή της μεθοδολογίας για κατασκευή μίας ομάδας τεσσάρων χρονοσειρών.

**Βήμα 1<sup>ο</sup>:** Επιλέγονται τα όρια για τις τιμές των  $CV^2$ ,  $ADI$  και  $\mu$ . Στην παρούσα εργασία αυτά είναι τα  $[0.1, 2]$ ,  $[1, 7]$  και  $[10, 100]$  αντίστοιχα. Οι συγκεκριμένες τιμές δεν επιλέχθηκαν αυθαίρετα, αλλά αποτελούν τα στρογγυλοποιημένα όρια των τιμών του 11ου επιπέδου συνάθροισης του συνόλου δεδομένων του διαγωνισμού M5, το οποίο

χρησιμοποιείται στη συνέχεια της παρούσας διατριβής, όπως παρουσιάζεται στο Υποκεφάλαιο 5.4.

**Βήμα 2<sup>ο</sup>:** Επιλέγεται το μήκος των χρονοσειρών ( $l$ ), δηλαδή ο αριθμός των παρατηρήσεων της κάθε μίας, εδώ 548.

**Βήμα 3<sup>ο</sup>:** Παράγεται τυχαία ένας αριθμός  $CV^2$  για κάθε χρονοσειρά, εντός των ορίων που έχουν τεθεί στο Βήμα 1, με 2 εκ των σειρών να βρίσκονται κάτω από την τιμή-όριο 0.49 και 2 πάνω από αυτή.

**Βήμα 4<sup>ο</sup>:** Παράγεται τυχαία ένας αριθμός  $ADI$  για κάθε χρονοσειρά, εντός των ορίων που έχουν τεθεί, 2 εκ των οποίων βρίσκονται κάτω από την τιμή-όριο 1.32 και 2 πάνω από αυτή.

**Βήμα 5<sup>ο</sup>:** Παράγεται τυχαία ένας αριθμός  $\mu$  για κάθε χρονοσειρά, εντός των ορίων που έχουν τεθεί.

**Βήμα 6<sup>ο</sup>:** Υπολογίζεται το διάνυσμα  $I_t$  κάθε χρονοσειράς, σύμφωνα με τις επιμέρους τιμές  $ADI$  και  $l$ .

**Βήμα 7<sup>ο</sup>:** Υπολογίζεται το διάνυσμα  $D_t$  κάθε χρονοσειράς, σύμφωνα με τις επιμέρους τιμές  $CV^2$ ,  $l$  και  $\mu$ .

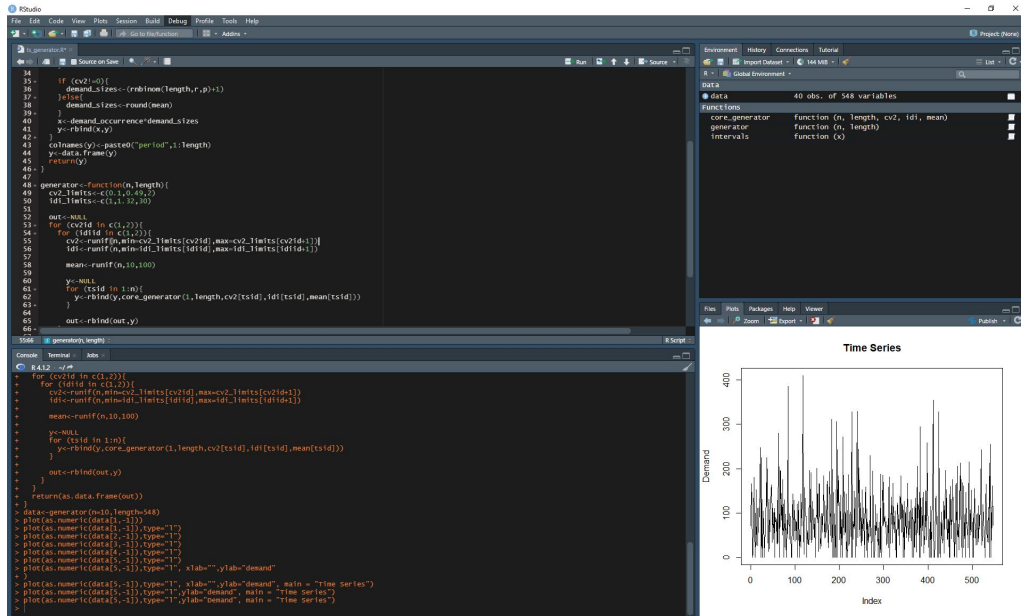
**Βήμα 8<sup>ο</sup>:** Υπολογίζονται οι τελικές χρονοσειρές ως το γινόμενο  $I_t \cdot D_t$ .

Όπως είναι εμφανές, η γεννήτρια που προτείνεται βασίζεται σε μία σύνθετη μεθοδολογία η οποία απαιτεί αρκετούς υπολογισμούς, με αποτέλεσμα να απαιτείται η ανάπτυξη της σε προγραμματιστικό περιβάλλον.

Για τον σκοπό αυτό χρησιμοποιήθηκε η γλώσσα προγραμματισμού R (R Development Core Team, 2008), η οποία έχει γίνει ιδιαίτερα γνωστή τα τελευταία χρόνια στον τομέα της στατιστικής ανάλυσης κυρίως λόγω της open-source λογικής της η οποία επιτρέπει αφενός τη δωρεάν χρήση της και αφετέρου την ελεύθερη κυκλοφορία και επαναχρησιμοποίηση πακέτων και συναρτήσεων από τα μέλη της κοινότητάς της. Αυτό έχει ως αποτέλεσμα πολλές από τις διεργασίες που επιθυμεί να πραγματοποιήσει ένας αναλυτής να είναι ήδη διαθέσιμες μειώνοντας έτσι σημαντικά τον χρόνο και την προσπάθεια για την ολοκλήρωση οποιασδήποτε ανάλυσης. Μάλιστα, πολλές από αυτές τις συναρτήσεις γίνονται διαθέσιμες από ακαδημαϊκούς αυξάνοντας έτσι την αξιοπιστία των αποτελεσμάτων. Το επίσημο ολοκληρωμένο περιβάλλον ανάπτυξης της R, με την ονομασία RStudio, απεικονίζεται ενδεικτικά στο Σχήμα 5.1.

Για την υλοποίηση της γεννήτριας χρονοσειρών διακοπτόμενης ζήτησης δεν αξιοποιήθηκε ωστόσο κάποιο από τα έτοιμα στατιστικά πακέτα της R πέραν των βασικών πακέτων κορμού της συγκεκριμένης γλώσσας, καθώς κρίθηκε σκόπιμο για λόγους σαφήνειας και ακριβείας οι διάφορες μέθοδοι να αναπτυχθούν από την αρχή. Στη συνέχεια παρατίθενται τα βασικά μέρη του κώδικα που αναπτύχθηκε για την υλοποίηση της γεννήτριας.

```
# Generate n demand time series given their length, cv2, adi and mean
core_generator <- function(n, lng, cv2, idi, avg){
  y <- NULL
  for (tsid in 1:n){
    p <- (avg)/(cv2*((avg + 1)^2))
    r <- (avg*p)/(1-p)
```



Σχήμα 5.1: Το γραφικό περιβάλλον της R, RStudio.

```
# check if first value is zero
demand_occurrence <- rbinom(lng, 1, 1/idi)
while ((demand_occurrence[1] == 0) |
(sum(demand_occurrence[(length(demand_occurrence)*2/3):length(demand_occurrence)]) <
((length(demand_occurrence)*1/3)*0.05) )){
  demand_occurrence <- rbinom(lng, 1, 1/idi)
}

if (cv2! = 0){
  demand_sizes <- rnbino(m(lng, r, p) + 1
}else{
  demand_sizes <- round(avg)
}
x <- demand_occurrence*demand_sizes
y <- rbind(x, y)
}
colnames(y) <- paste0("period", 1:lng)
y <- data.frame(y)
return(y)
}

# Generate n demand time series with given length from each of the four categories of demand
generator <- function(n, lng){
  cv2_limits <- c(0.1, 0.49, 2)
  idi_limits <- c(1, 1.32, 30)

  out <- NULL
  for (cv2id in c(1, 2)){
    for (idiid in c(1, 2)){
      cv2 <- runif(n, min = cv2_limits[cv2id], max = cv2_limits[cv2id + 1])
      idi <- runif(n, min = idi_limits[idiid], max = idi_limits[idiid + 1])
    }
  }
}
```

```

avg <- runif(n, 10, 100)

y <- NULL
for (tsid in 1:n){
  y <- rbind(y, core_generator(1, lng, cv2[tsid], idi[tsid], avg[tsid]))
}

out <- rbind(out, y)
}
}
return(as.data.frame(out))
}

# Generate 1000 series with length 548 each, 250 from each of the four categories of demand
# (smooth, lumpy, erratic, intermittent)
series <- generator(n = 250, lng = 548)

```

Όπως αναφέρθηκε παραπάνω, η γέννηση των τεχνητών χρονοσειρών πραγματοποιείται θεωρώντας ότι αυτές αποτελούνται από 548 παρατηρήσεις προκειμένου να υπάρχει επαρκές δείγμα παρατηρήσεων ανά σειρά. Για λόγους πληρότητας και ομοιομορφίας επιλέχθηκε επίσης να παράγεται ισάριθμο πλήθος χρονοσειρών για κάθε πιθανή κατηγορία χρονοσειρών, έτσι δεδομένου ότι υπάρχουν τέσσερις κατηγορίες ζήτησης, για παραγωγή  $n = 2.500$  χρονοσειρών ανά κατηγορία προκύπτουν συνολικά  $4 \cdot n = 4 \cdot 2.500 = 10.000$  χρονοσειρές.

### 5.2.2 Παρουσίαση των παραγόμενων χρονοσειρών

Όπως αναφέρθηκε παραπάνω, βασικός σκοπός της γεννήτριας χρονοσειρών είναι να παράγει ένα σύνολο το οποίο θα περιλαμβάνει ικανοποιητικό πλήθος οποιουδήποτε τύπου χρονοσειράς, οι οποίες θα είναι κατανομημένες στις τέσσερις κατηγορίες της ζήτησης.


Με τον τρόπο με τον οποίο ορίστηκαν, μετρήθηκαν και αναπαραστάθηκαν τα χαρακτηριστικά, αναμένει κανείς πράγματι τα αποτελέσματα της γεννήτριας που αναπτύχθηκε να είναι ιδιαίτερος αντιπροσωπευτικά. Όπως φαίνεται στον Πίνακα 5.1 και στο Σχήμα 5.2, οι παραγόμενες χρονοσειρές είναι ισάριθμα κατανομημένες στις κατηγορίες, με 2.502 εξ αυτών να χαρακτηρίζονται ως *intermittent*, 2.575 *lumpy*, 2.426 *smooth* και 2.497 *erratic*, με τα αντίστοιχα ποσοστά να είναι 25,02%, 25,75%, 24,26% και 24,97%, δηλαδή όλα εξ αυτών πολύ κοντά στο 25%. Επίσης, βάσει των ορίων που τέθηκαν για τις τιμές των *ADI*,  $CV^2$  και  $\mu$ , οι χρονοσειρές εμφανίζουν τα εν λόγω χαρακτηριστικά εντός των αντίστοιχων ορίων.

Πίνακας 5.1: Χαρακτηριστικά παραγόμενων χρονοσειρών.

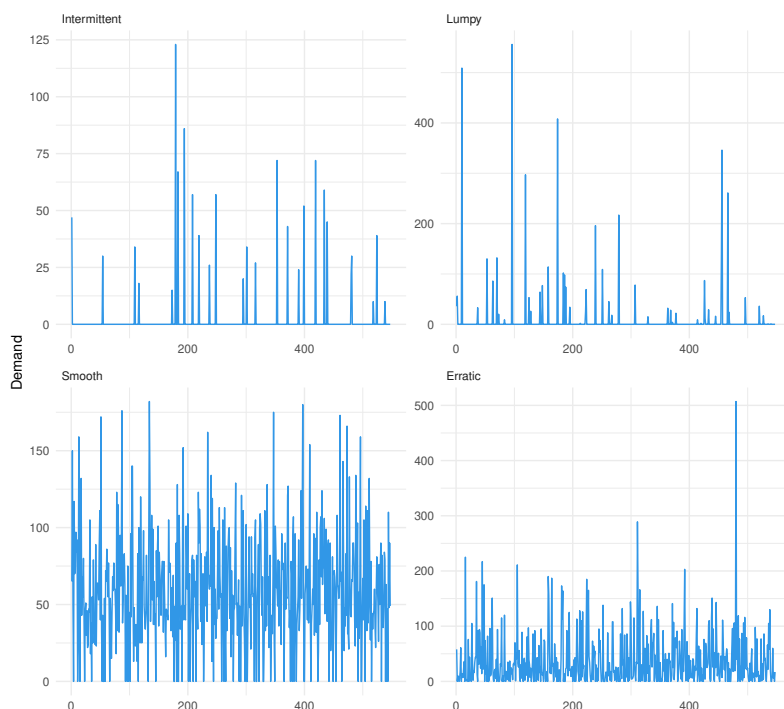
	Κατηγορίες Ζήτησης				Total
	Intermittent	Lumpy	Smooth	Erratic	
Πλήθος χρονοσειρών	2.502	2.575	2.426	2.497	10.000

	Χαρακτηριστικά χρονοσειρών			
	ADI	CV <sup>2</sup>	Average value	Observations
Min	1,00	0,07	1,31	548
Median	1,35	0,51	23,85	548
Max	9,60	4,19	111,67	548

Σχήμα 5.2: Κατηγοριοποίηση των παραγόμενων χρονοσειρών με βάση το ADI και το CV<sup>2</sup>.

Στο Σχήμα 5.3 απεικονίζονται κάποια χαρακτηριστικά παραδείγματα παραγόμενων χρονοσειρών, μία από κάθε εκ των τεσσάρων κατηγοριών προτύπων ζήτησης.



Σχήμα 5.3: Ενδεικτικές χρονοσειρές του παραγόμενου συνόλου δεδομένων.

### 5.3 Διαγωνισμοί προβλέψεων M

Οι διαγωνισμοί προβλέψεων αποτελούν οργανωμένες προσπάθειες που έχουν γίνει κατά καιρούς προκειμένου να εξαχθούν εμπειρικά συμπεράσματα σχετικά με την επίδοση των μεθόδων πρόβλεψης. Βασίζονται στη συλλογή πληθώρας χρονοσειρών διαφορετικής ή παραπλήσιας φύσης - τόσο ως προς την κατηγορία (π.χ. μακροοικονομικά δεδομένα) όσο και τα χαρακτηριστικά τους (π.χ. εποχιακές χρονοσειρές) - και την εφαρμογή γνωστών και νέων μεθόδων σε αυτές για την παραγωγή προβλέψεων σε συγκεκριμένα διαστήματα για τα οποία οι πραγματικές τιμές δεν είναι εξαρχής διαθέσιμες. Οι μέθοδοι αξιολογούνται στη συνέχεια με χρήση προκαθορισμένων δεικτών σφαλμάτων ως προς την ακρίβεια, την προκατάληψη και την ευστάθειά τους ή και ως προς άλλα μεγέθη που μπορεί να σχετίζονται με την επίδοσή τους. Η επίδοση κάθε μεθόδου κρίνεται συγκρίνοντάς την είτε με αυτή των υπολοίπων μεθόδων που συμμετέχουν στο διαγωνισμό, είτε με αυτή απλοϊκών μεθόδων πρόβλεψης (π.χ. της Naïve) που αποτελούν συνήθως σημεία αναφοράς λόγω της απλότητας και της μικρότερης θεωρητικά αναμενόμενης ακρίβειάς τους.

Αν και πολλοί στατιστικολόγοι συνεχίζουν να αμφισβητούν τα αποτελέσματα των διαγωνισμών λόγω της μη θεωρητικής τεκμηρίωσής τους, εν τούτοις στην επιστημονική κοινότητα των προβλέψεων έχουν γίνει πλήρως αποδεκτά, με τα δεδομένα τους να αποτελούν σημείο αναφοράς και μελέτης για όλους τους ερευνητές. Εξέχοντα ρόλο στην καθιέρωση και στην αποδοχή των διαγωνισμών αποτέλεσαν τα σχεδόν πανομοιότυπα συμπεράσματα που εξήχθησαν μέσω των διαγωνισμών M, τα οποία και συνεχίζουν να επαληθεύονται εμπειρικά μέσω άλλων πιο σύγχρονων μελετών.

Οι διαγωνισμοί M οι οποίοι έχουν λάβει χώρα μέχρι στιγμής είναι οι εξής:



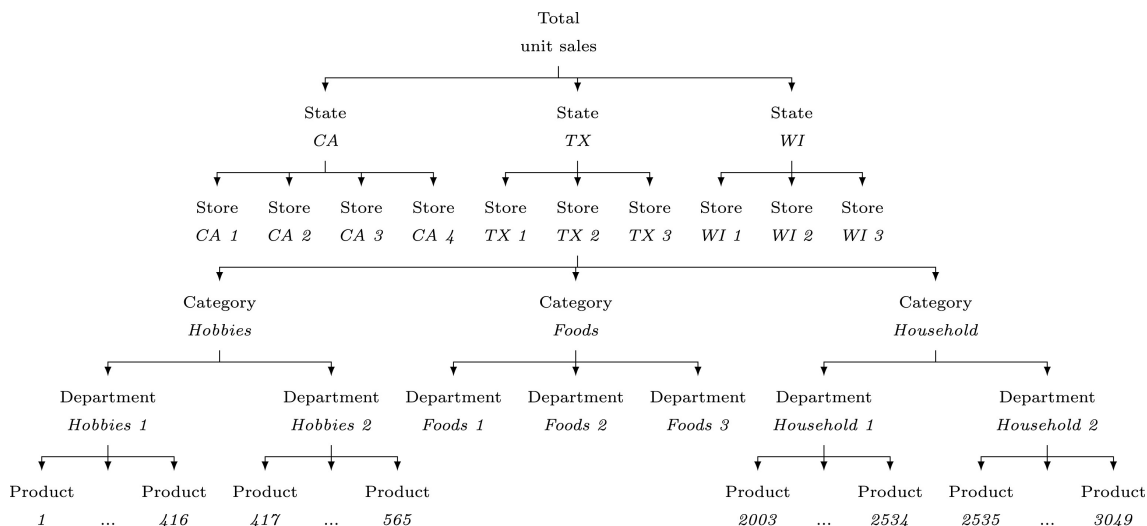
- M Competition (Makridakis et al., 1982),
- M2 Competition (Makridakis et al., 1993),
- M3 Competition (Makridakis & Hibon, 2000),
- M4 Competition (Makridakis et al., 2020),
- M5 Competition (Makridakis et al., 2022),

και τα συμπεράσματα στα οποία κατέληξαν συνοψίζονται παρακάτω:

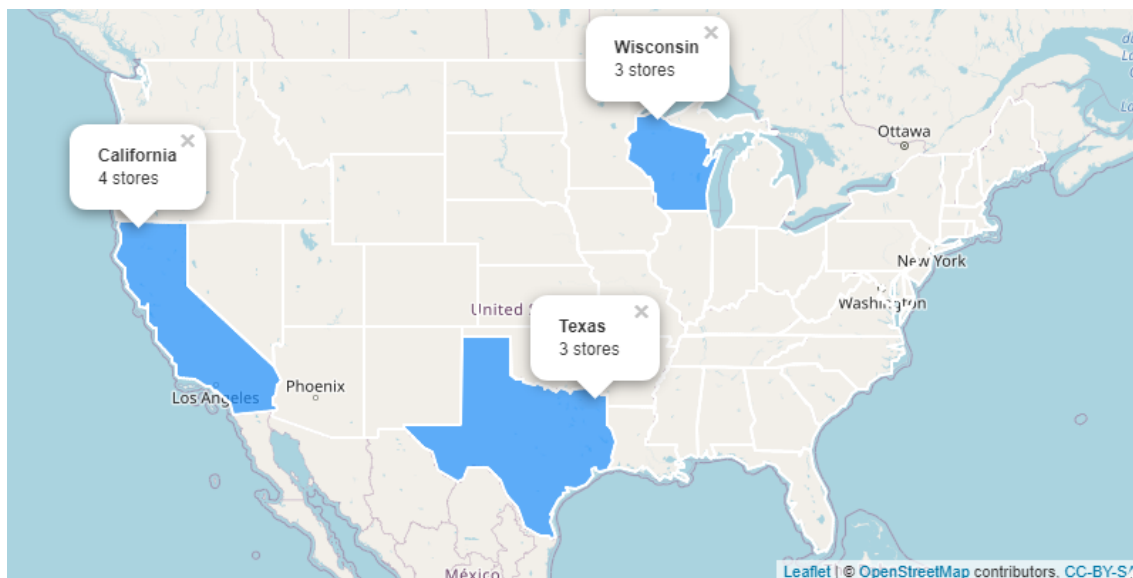
- στη γενική περίπτωση οι πιο απλές μέθοδοι εμφανίζουν καλύτερη απόδοση προβλεπτικά, ή τουλάχιστον οι πιο πολύπλοκες μέθοδοι δεν μπορούν να εγγυηθούν και καλύτερες προβλέψεις,
- με την αύξηση του ορίζοντα πρόβλεψης αυξάνονται τα σφάλματα πρόβλεψης,
- ανάλογα το κριτήριο απόδοσης που χρησιμοποιείται ενδέχεται να αλλάζει και η κατάταξη μεταξύ των μεθόδων που συμμετέχουν στο διαγωνισμό,
- οι αμιγώς στατιστικές ή machine learning μέθοδοι εμφανίζουν μέτρια επίδοση,
- ο συνδυασμός απλών μεθόδων αποτελεί συνήθως καλύτερη επιλογή από την πρόβλεψη με τις επιμέρους μεθόδους ξεχωριστά, και ο συνδυασμός στατιστικών και machine learning μεθόδων ή η χρήση υβριδικών προσεγγίσεων εμφανίζει ακόμα μεγαλύτερη βελτίωση της ακρίβειας, και
- η χρήση της πληροφορίας από συγκεντρωτικά στοιχεία των σειρών για τη βελτίωση της ακρίβειας των μεμονωμένων χρονοσειρών προσδίδει αξία.

Ο διαγωνισμός M5 (Makridakis et al., 2022) ακολούθησε τους προηγούμενους τέσσερεις διαγωνισμούς M, σκοπός των οποίων αποτελούσε ο εντοπισμός, από εμπειρικά στοιχεία, του τρόπου με τον οποίο επιτυγχάνεται η βελτίωση της απόδοσης των προβλέψεων και η προώθηση της θεωρίας και πρακτικής των προβλέψεων γενικότερα. Ο συγκεκριμένος διαγωνισμός επικεντρώθηκε στην πρόβλεψη δεδομένων λιανικών πωλήσεων, χρησιμοποιώντας 42.840 χρονοσειρές οι οποίες αντιπροσωπεύουν ιεραρχικές πωλήσεις προϊόντων της μεγαλύτερης εταιρείας λιανικής στον κόσμο, της Walmart, σχολιάζοντας επίσης την αβεβαιότητα των παραγόμενων προβλέψεων.

Στο Σχήμα 5.4 απεικονίζεται η ομαδοποίηση των χρονοσειρών που χρησιμοποιήθηκαν, οι οποίες προέρχονται από 3.049 διαφορετικά προϊόντα, 3 κατηγοριών (Hobbies, Foods, Household) και 10 καταστημάτων από 3 πολιτείες των ΗΠΑ (California, Texas, Wisconsin). Η κατανομή των καταστημάτων αυτών στον χάρτη των ΗΠΑ φαίνεται στο Σχήμα 5.5. Με τον τρόπο αυτό, οι συμμετέχοντες έπρεπε να παρέχουν προβλέψεις τόσο για τις επιμέρους χρονοσειρές που αφορούν σε κάθε προϊόν κάθε καταστήματος (30.490 χρονοσειρές), όσο και για κάθε επιπλέον χρονοσειρά των διαφόρων επιπέδων συνάθροισης, όπως αυτά παρουσιάζονται στον Πίνακα 5.2.



Σχήμα 5.4: Ομαδοποιημένες χρονοσειρές που χρησιμοποιούνται στον διαγωνισμό M5. Τα δεδομένα συγκεντρώνονται σε 12 επίπεδα συνάθροισης χρησιμοποιώντας πληροφορίες είτε τοποθεσίας είτε σχετικές με το προϊόν.




Σχήμα 5.5: Απεικόνιση των πολιτειών προέλευσης των δεδομένων του διαγωνισμού M5 στο χάρτη των ΗΠΑ.

Πίνακας 5.2: Πλήθος χρονοσειρών του διαγωνισμού M5 ανά επίπεδο συνάθροισης (aggregation level).

Level	Description	Aggregation level	Series
1	Unit sales of all products, aggregated for all stores/states	Total	1
2	Unit sales of all products, aggregated for each state	State	3
3	Unit sales of all products, aggregated for each store	Store	10
4	Unit sales of all products, aggregated for each category	Category	3
5	Unit sales of all products, aggregated for each department	Department	7
6	Unit sales of all products, aggregated for each state and category	State-category	9
7	Unit sales of all products, aggregated for each state and department	State-department	21
8	Unit sales of all products, aggregated for each store and category	Store-category	30
9	Unit sales of all products, aggregated for each store and department	Store-department	70
10	Unit sales of product $i$ , aggregated for all stores/states	Product	3.049
11	Unit sales of product $i$ , aggregated for each state	Product-state	9.147
12	Unit sales of product $i$ , aggregated for each store	Product-store	30.490
<b>Total</b>			42.840

Ο διαγωνισμός M5 παρείχε στους συμμετέχοντες επιπλέον εξωγενείς πληροφορίες, όπως πληροφορίες σχετικές με το ημερολόγιο, τις τιμές πώλησης και τις προωθητικές δραστηριότητες της εταιρείας καθιστώντας το σύνολο δεδομένων του διαγωνισμού αυτού αρκετά πλούσιο.


Ένα επιπλέον χαρακτηριστικό που διαφοροποιεί τον M5 από τους προηγούμενους M διαγωνισμούς είναι η ύπαρξη χρονοσειρών διακοπτόμενης ζήτησης στο εξεταζόμενο σύνολο δεδομένων, που εντοπίζονται στα επίπεδα (levels) 10, 11 και 12, όπως φαίνεται πιο αναλυτικά και στο Σχήμα 5.6



Σχήμα 5.6: Κατηγοριοποίηση των χρονοσειρών του διαγωνισμού M5 με βάση το ADI και το  $CV^2$ , σύμφωνα με την κατηγοριοποίηση των Syntetos et al. (2005), ανά επίπεδο συνάθροισης. (Πηγή: Makridakis et al. (2022))

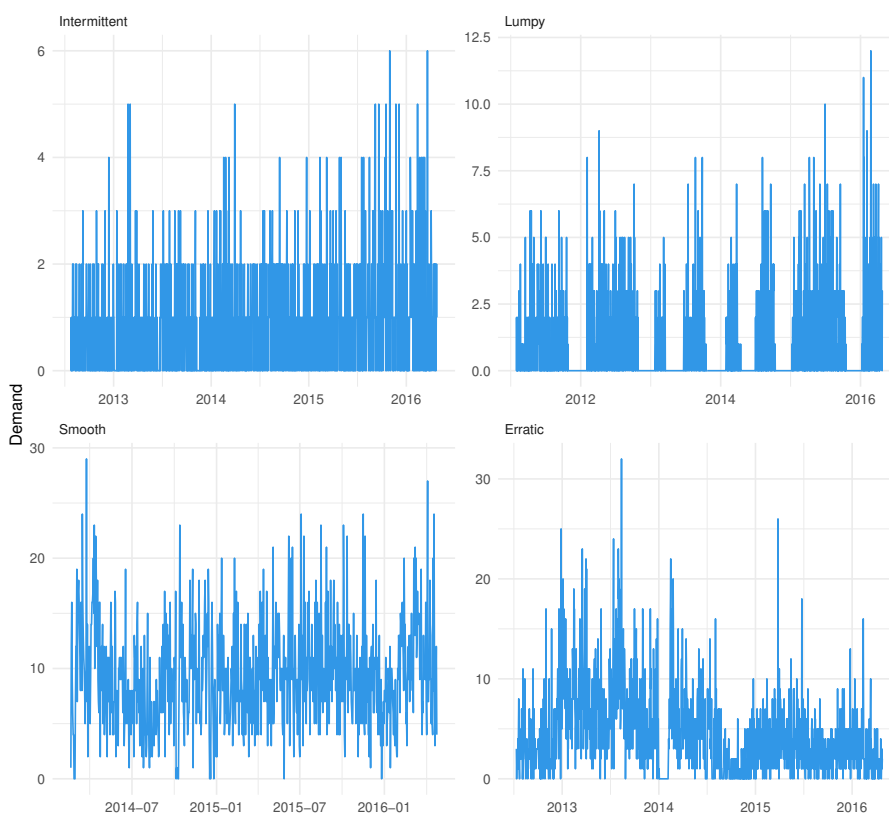
Το πλήρες σύνολο δεδομένων περιλαμβάνει 26.956 intermittent, 6.416 lumpy, 1.791 erratic και 7.677 smooth χρονοσειρές, ενώ αντίστοιχα, το επίπεδο συνάθροισης (aggregation level) προϊόν-κατάστημα (product-store - level 12) περιλαμβάνει 22.339 intermittent, 5.206 lumpy, 883 erratic και 2.062 smooth σειρές. Οι χρονοσειρές του τελευταίου επιπέδου συνάθροισης απεικονίζονται σε λογαριθμική κλίμακα, για

διευκόλυνση της οπτικοποίησης, στο διάγραμμα διασποράς  $ADI - CV^2$  του Σχήματος 5.7, σε αντιστοιχία με την κατηγοριοποίηση χρονοσειρών σύμφωνα με τους Syntetos et al. (2005), που παρουσιάστηκε αναλυτικά στο Υποκεφάλαιο 3.6.4.



Σχήμα 5.7: Κατηγοριοποίηση των χρονοσειρών του επιπέδου συνάθροισης 12 του διαγωνισμού M5 με βάση το ADI και το  $CV^2$ , σύμφωνα με την κατηγοριοποίηση των Syntetos et al. (2005).

Τέλος, στο Σχήμα 5.8 απεικονίζονται τέσσερις χαρακτηριστικές χρονοσειρές του συνόλου δεδομένων, όπου κάθε μία ανήκει σε διαφορετική κατηγορία ζήτησης.



Σχήμα 5.8: Ευδεικτικές χρονοσειρές του συνόλου δεδομένων του διαγωνισμού M5.

## 5.4 Αντιπροσωπευτικότητα των παραγόμενων χρονοσειρών

Η εφαρμογή μιας μεθοδολογίας σε πολλά διαφορετικά σύνολα δεδομένων αποτελεί μια χρονοβόρα και κοστοβόρα διαδικασία, με αποτέλεσμα τις περισσότερες φορές να επιλέγεται ένα ή δύο σύνολα. Προκειμένου, έτσι, να υποστηριχτεί η καθολικότητα των αποτελεσμάτων, είθισται να εξετάζεται η αντιπροσωπευτικότητα του συνόλου δεδομένων που χρησιμοποιήθηκε ως προς τον κλάδο τον οποίο το σύνολο αυτό αναπαριστά. Για παράδειγμα, στην περίπτωση του διαγωνισμού M5, που αφορά σε ζήτηση προϊόντων λιανικής, προκειμένου να υποστηριχτεί η καθολικότητα των συμπερασμάτων που προέκυψαν θα πρέπει να εξεταστεί το κατά πόσο χρονοσειρές με παρόμοια ποιοτικά χαρακτηριστικά συναντώνται σε διάφορες εταιρείες λιανικής.

Σε αυτή την κατεύθυνση, οι Kang et al. (2017) πρότειναν μια διαδικασία υπολογισμού συγκεκριμένων χαρακτηριστικών των χρονοσειρών, ανάλυση των κύριων συνιστωσών των χαρακτηριστικών αυτών με τη μέθοδο PCA (Principle Component Analysis) (Pearson, 1901) και στη συνέχεια απεικόνιση τους σε διδιάστατο χώρο. Στηριζόμενοι στην υπόθεση ότι τα χαρακτηριστικά των χρονοσειρών είναι περισσότερα από τα ποιοτικά χαρακτηριστικά αυτών, όπως αναλύθηκαν στο Κεφάλαιο 3, έθεσαν ως μεταβλητές ανάλυσης την εποχιακότητα, την τάση, την τυχασιότητα, την αυτοσυσχέτιση των παρατηρήσεων, την στασιμότητα, ή αλλιώς σταθερότητα της διακύμανσης καθώς και τη συχνότητα.

Ακολούθησε πληθώρα μελετών σύγκρισης χρονοσειρών μέσω της απεικόνισης των

χαρακτηριστικών αυτών, όπως αυτές των Spiliotis et al. (2020), Kang et al. (2020) και Theodorou et al. (2021b) στις οποίες, ενώ η αρχική ιδέα παραμένει, μεταβάλλονται τα χαρακτηριστικά τα οποία λαμβάνονται υπόψη και η μέθοδος μείωσης των διαστάσεων των επιλεγμένων χαρακτηριστικών, με τις πιο συνηθισμένες να είναι οι μέθοδοι PCA και t-SNE (t-Stochastic Neighbor Embedding) (Van der Maaten & Hinton, 2008).

Εδώ αξίζει να σημειωθεί η διαφορά μεταξύ των μεθοδολογιών PCA και t-SNE. Η μέθοδος PCA αποτελεί μία γραμμική μέθοδο συμπίεσης δεδομένων, η οποία συνίσταται από τον επαναπροσδιορισμό των συντεταγμένων ενός συνόλου δεδομένων σε ένα άλλο σύστημα συντεταγμένων, ενώ η μέθοδος t-SNE είναι μια μη γραμμική τεχνική μείωσης διαστάσεων, κατάλληλη για την ενσωμάτωση δεδομένων πολλών διαστάσεων και οπτικοποίησή τους σε δισδιάστατο ή τρισδιάστατο χώρο.

Ένας σημαντικός περιορισμός οποιασδήποτε γραμμικής μεθόδου μείωσης διαστάσεων είναι ότι δίνει μεγαλύτερη έμφαση στη διατήρηση ανόμοιων σημείων δεδομένων σε μεγάλη απόσταση μεταξύ τους στον χώρο χαμηλών διαστάσεων. Αλλά για να αναπαρασταθούν δεδομένα πολλών διαστάσεων μη γραμμικής πολλαπλότητας, είναι επίσης σημαντικό παρόμοια σημεία δεδομένων να τοποθετούνται κοντά μεταξύ τους. Όταν υπάρχουν, έτσι, πολλά χαρακτηριστικά και μη γραμμικές συσχετίσεις, η χρήση ενός γραμμικού μετασχηματισμού των χαρακτηριστικών μπορεί να είναι παραπλανητική. Ως εκ τούτου, στις περιπτώσεις αυτές προτιμάται η μέθοδος t-SNE, καθώς μια μη γραμμική τεχνική είναι ικανή να διατηρεί τόσο την τοπική όσο και την ολική δομή των δεδομένων.


Στο Σχήμα 5.9 παρουσιάζονται τα αποτελέσματα των παραπάνω δύο μεθόδων για το ίδιο σύνολο δεδομένων, το οποίο αποτελείται από τις παραγόμενες χρονοσειρές, όπως παρουσιάστηκαν στο Υποκεφάλαιο 5.2.2, χρησιμοποιώντας τα εξής χαρακτηριστικά:

- τυχαιότητα (spectral entropy)
- τάση (strength of trend)
- αυτοσυσχέτιση των παρατηρήσεων (first order autocorrelation)
- στασιμότητα (Box-Cox transformation parameter lambda)
- σποραδικότητα (ADI)
- αστάθεια του μεγέθους της ζήτησης ( $CV^2$ )

Στην ουσία, τέσσερα από τα παραπάνω έξι χαρακτηριστικά αποτελούν τα ίδια με αυτά που χρησιμοποιήθηκαν στην μελέτη των Kang et al. (2017), έχοντας εξαιρέσει τη συχνότητα και την εποχιακότητα, και έχουν προστεθεί το ADI και το  $CV^2$  τα οποία αντικατοπτρίζουν καλύτερα την διακοπτόμενη φύση των χρονοσειρών.

Και στις δύο προσεγγίσεις, όταν δύο σύνολα δεδομένων καλύπτουν τον ίδιο χώρο, προκύπτει το συμπέρασμα ότι εμφανίζουν παρόμοιες τιμές στα εξεταζόμενα χαρακτηριστικά, και κατά συνέπεια μία συνάφεια.

Κάνοντας χρήση του πακέτου stats, το οποίο ανήκει στον βασικό κορμό της γλώσσας R, και του πακέτου Rtsne (Krijthe, 2015), μπορεί να πραγματοποιηθεί ανάλυση των κύριων συνιστωσών των χαρακτηριστικών ενός συνόλου δεδομένων με χρήση των μεθόδων PCA και t-SNE, αντίστοιχα, όπως φαίνεται παρακάτω.



Σχήμα 5.9: Σύγκριση των αποτελεσμάτων των μεθοδολογιών *t-SNE* (αριστερά) και *PCA* (δεξιά) στο ίδιο σύνολο δεδομένων, χρησιμοποιώντας τα ίδια χαρακτηριστικά.

```
# Load necessary libraries
library('stats')
library('Rtsne')

# implementation of PCA method for data set named 'dataset'
pca <- prcomp(dataset, scale = T)

# implementation of t-SNE method for data set named 'dataset'
tsne <- Rtsne(dataset, dims = 2, perplexity = 30, verbose = FALSE, max_iter = 2000)
```

Να σημειωθεί εδώ ότι, στο εξής, ως σύνολο δεδομένων του διαγωνισμού M5 αποκαλείται αποκλειστικά το 11ο επίπεδο συνάθροισης του εν λόγω συνόλου, το οποίο αναπαριστά πωλήσεις ανά προϊόν και πολιτεία των ΗΠΑ. Αυτό συμβαίνει καθώς, όπως αναφέρθηκε, η παρούσα διατριβή εστιάζει στη λειτουργία μιας αποθήκης, με το συγκεκριμένο επίπεδο συνάθροισης να προσεγγίζει καλύτερα τη συγκεκριμένη λειτουργία, υποθέτοντας, ωστόσο, ότι σε κάθε πολιτεία του συνόλου λειτουργεί μία αποθήκη η οποία εξυπηρετεί τα αντίστοιχα καταστήματα. Για τον λόγο αυτό, όπως αναφέρθηκε στο Υποκεφάλαιο 5.2.1, τα όρια των μεταβλητών που χρησιμοποιήθηκαν στη γεννήτρια παραγωγής χρονοσειρών επιλέχθηκαν από το συγκεκριμένο μέρος του συνόλου δεδομένων του διαγωνισμού M5.

Ακολουθώντας τα παραπάνω, πραγματοποιήθηκε μια σύγκριση μεταξύ του συνόλου των τεχνητών χρονοσειρών, του συνόλου του M5 και ενός συνόλου δεδομένων (Greek retail firm), το οποίο παρασχέθηκε γενναιόδωρα από μια μεγάλη ελληνική αλυσίδα σούπερ μάρκετ, και περιλαμβάνει τις ημερήσιες πωλήσεις προϊόντων, τα οποία ανήκουν σε 80 διαφορετικές κατηγορίες και πωλούνται σε 227 καταστήματα σε όλη την Ελλάδα. Τα δεδομένα (7.248 χρονοσειρές) παρέχονται σε επίπεδο αποθήκης και καλύπτουν περίπου 748 ημέρες, από τον Απρίλιο του 2018 έως τον Μάιο του 2020. Να σημειωθεί εδώ ότι η περίοδος αυτή δεν συμπίπτει με την περίοδο που εξετάζεται στο σύνολο του M5, εμπεριέχοντας επίσης το πρώτο κύμα της πανδημίας του COVID-19 και τις αντίστοιχες επιπτώσεις του lockdown που επιβλήθηκε.

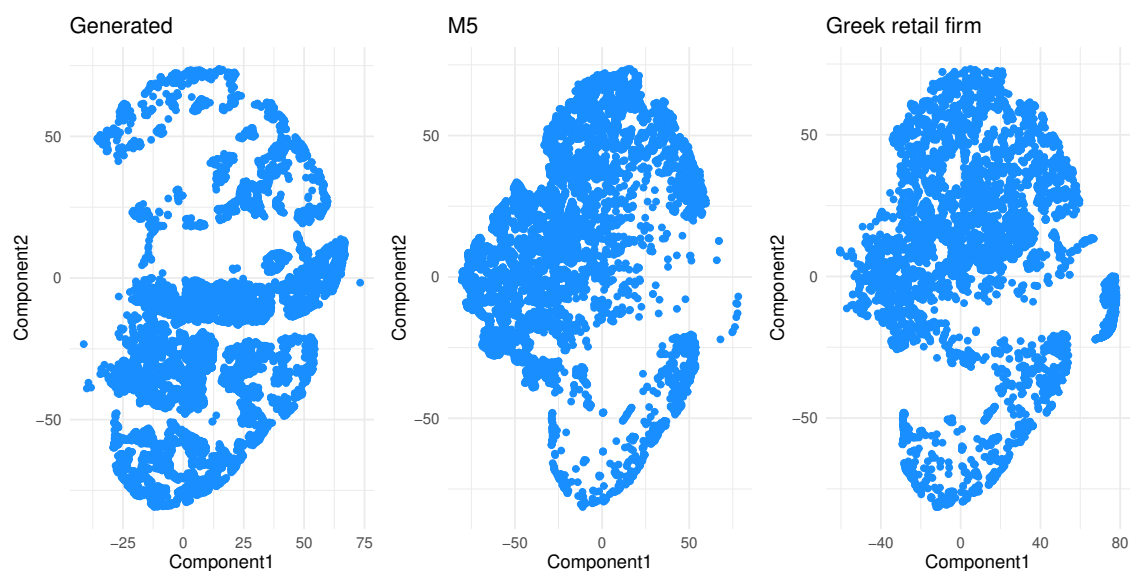
Το επιπλέον σύνολο δεδομένων παρουσιάζεται για λόγους πληρότητας, προσπαθώντας να καταστούν πιο ξεκάθαρες οι χρονοσειρές ζήτησης που συναντώνται στον κλάδο της λιανικής. Ωστόσο, δεν θα χρησιμοποιηθεί στη συνέχεια της παρούσας διατριβής, μιας και σύμφωνα με τους Theodorou et al. (2021b) το σύνολο του M5 είναι αρκετά αντιπροσωπευτικό του συγκεκριμένου κλάδου.

Έτσι, εφαρμόστηκαν οι μέθοδοι t-SNE και PCA χρησιμοποιώντας μόνο τα εξής χαρακτηριστικά:

- αυτοσυσχέτιση των παρατηρήσεων (first order autocorrelation - AR)
- σποραδικότητα (ADI)
- αστάθεια του μεγέθους της ζήτησης ( $CV^2$ ),

μιας και οι τεχνητές χρονοσειρές δεν εμφανίζουν τάση ή εποχιακότητα, και η στασιμότητα και η τυχειότητα εμπεριέχονται στους δείκτες ADI και  $CV^2$ .


Στα Σχήματα 5.10 και 5.11 φαίνονται τα αποτελέσματα των τριών συνόλων, τεχνητές χρονοσειρές, M5 και ελληνική αλυσίδα καταστημάτων, για τις μεθόδους t-SNE και PCA αντίστοιχα. Παρατηρείται ότι, ενώ στη γενική περίπτωση τα τρία σύνολα δεδομένων καλύπτουν παρόμοιο χώρο, υπάρχουν αρκετές περιπτώσεις χρονοσειρών οι οποίες παρουσιάζουν τιμές στα εξεταζόμενα χαρακτηριστικά οι οποίες συναντώνται μόνο σε ένα από αυτά. Χαρακτηριστικά παραδείγματα αποτελούν οι “ουρές” του συνόλου δεδομένων του M5 προς τα αριστερά και του συνόλου δεδομένων της ελληνικής αλυσίδας καταστημάτων προς τα κάτω στο Σχήμα 5.11. Αντίθετα, το σύνολο δεδομένων των τεχνητών χρονοσειρών εμφανίζει μια ομοιομορφία στον χώρο τον οποίο καλύπτει.



Σχήμα 5.10: Απεικόνιση της έντασης των χαρακτηριστικών των χρονοσειρών τριών συνόλων δεδομένων στον χώρο με χρήση t-SNE. Απεικονίζεται το σύνολο δεδομένων τεχνητών χρονοσειρών (αριστερά), το σύνολο δεδομένων του διαγωνισμού M5 (μέση) και το σύνολο δεδομένων μιας ελληνικής αλυσίδας σούπερ μάρκετ (δεξιά).

Στο Σχήμα 5.12 γίνεται μια προσπάθεια επεξήγησης των αξόνων που προέκυψαν από τη μεθοδολογία PCA και εντοπισμού χρονοσειρών που ανήκουν σε σημεία του χώρου όπου δεν





Σχήμα 5.11: Απεικόνιση της έντασης των χαρακτηριστικών των χρονοσειρών τριών συνόλων δεδομένων στον χώρο με χρήση PCA. Απεικονίζεται το σύνολο δεδομένων τεχνητών χρονοσειρών (αριστερά), το σύνολο δεδομένων του διαγωνισμού M5 (μέση) και το σύνολο δεδομένων μιας ελληνικής αλυσίδας σουπερ μάρκετ (δεξιά).

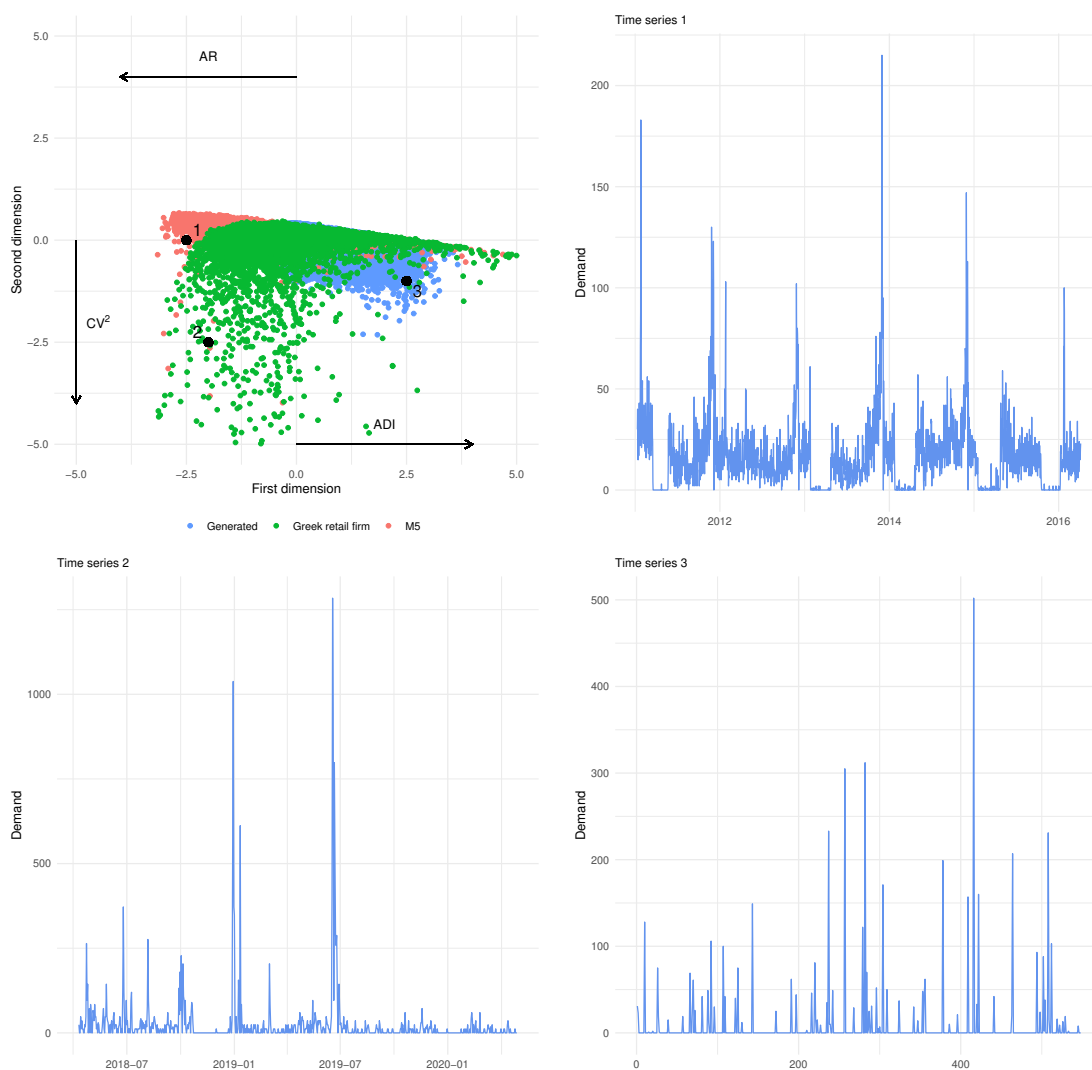
υπάρχει επικάλυψη μεταξύ των τριών συνόλων, με σκοπό την καλύτερη κατανόηση των διαφορών που υπάρχουν μεταξύ τους. Έτσι, βάσει και του Πίνακα 5.3, φαίνεται χαρακτηριστικά ότι οι σειρές που βρίσκονται προς το δεξί μέρος του χώρου εμφανίζουν μεγάλη σποραδικότητα και αυτές που βρίσκονται προς το αριστερό μέρος εμφανίζουν μεγάλη αυτοσυσχέτιση, ενώ προς το κάτω μέρος κινούνται οι σειρές με μεγάλη τιμή  $CV^2$ . Αυτό είναι εμφανές και στα τρία παραδείγματα χρονοσειρών, time series 1, time series 2 και time series 3, τα οποία ανήκουν στα σύνολα δεδομένων του M5, της ελληνικής αλυσίδας σουπερ μάρκετ και των τεχνητών χρονοσειρών αντίστοιχα. Το πρώτο παράδειγμα χρονοσειράς (time series 1) που ανήκει στο σύνολο του M5, εμφανίζει μεγάλη αυτοσυσχέτιση μεταξύ των παρατηρήσεών της, το δεύτερο παράδειγμα (time series 2) που ανήκει στο σύνολο της αλυσίδας καταστημάτων εμφανίζει αρκετά μεγάλο  $CV^2$ , ενώ το τρίτο παράδειγμα (time series 2) που ανήκει στις τεχνητές χρονοσειρές εμφανίζει ταυτόχρονα μεγάλο ADI και μεγάλο  $CV^2$ .

Πίνακας 5.3: Παρουσίαση των δύο κύριων συστατικών (principal components) όπως προέκυψαν από τη μέθοδο PCA.

	<b>Component 1</b>	<b>Component 2</b>
ADI	0.699	-0.117
$CV^2$	-0.133	-0.991
AR	-0.702	0.071

Από τα παραπάνω αποτελέσματα συμπεραίνεται ότι το σύνολο των τεχνητών χρονοσειρών υπολείπεται μόνο στο χαρακτηριστικό της αυτοσυσχέτισης, μιας και οι τιμές των ADI και  $CV^2$  καλύπτουν το μεγαλύτερο μέρος των αντίστοιχων χαρακτηριστικών των άλλων συνόλων. Η παρατήρηση αυτή, αν και μικρής σημασίας, είναι αναμενόμενη καθώς η

γεννήτρια παραγωγής των τεχνητών χρονοσειρών, που παρουσιάστηκε αναλυτικά στο Υποκεφάλαιο 5.2.1 και χρησιμοποιήθηκε για την παραγωγή του συνόλου δεδομένων των τεχνητών χρονοσειρών, χρησιμοποιεί μόνο τα χαρακτηριστικά της σποραδικότητας και της αστάθειας της ζήτησης, χωρίς να λαμβάνει υπόψη της κατά τη δημιουργία μιας χρονοσειράς την αυτοσυσχέτιση των παραγόμενων παρατηρήσεων.



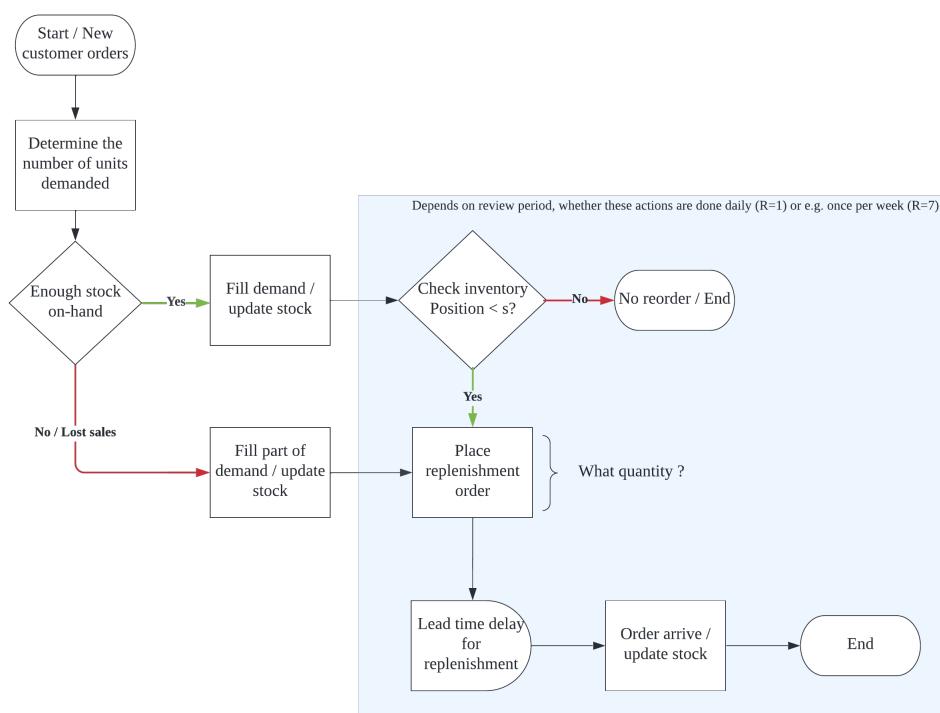
Σχήμα 5.12: Επεξήγηση του παραγόμενου χώρου της μεθοδολογίας PCA, με ταυτόχρονη παρουσίαση τριών παραδειγμάτων χρονοσειρών από συγκεκριμένα σημεία του χώρου.

## 5.5 Προσομοίωση της διαδικασίας αποθεματοποίησης

Το Σχήμα 5.13 περιγράφει τη διαδικασία που ακολουθείται για τη διαχείριση του αποθέματος ενός προϊόντος σε μία αποθήκη χρησιμοποιώντας μία πολιτική αποθεματοποίησης με χαμένες πωλήσεις, όπως αναλύθηκε στο Υποκεφάλαιο 2.10. Κάθε μέρα, εφόσον υπάρχει αρκετό απόθεμα καλύπτεται η ζήτηση ενώ, στην αντίθετη περίπτωση δημιουργούνται χαμένες πωλήσεις, εξυπηρετώντας ίσως ένα μέρος αυτής. Αν χρησιμοποιείται μία πολιτική συνεχούς εξέτασης του αποθέματος, τότε, κάθε μέρα,

ανάλογα με τα αποτελέσματα του προηγούμενου βήματος, ελέγχεται αν το επίπεδο του αποθέματος βρίσκεται κάτω από το επίπεδο αναπαραγγελίας και πραγματοποιείται μία παραγγελία στον προμηθευτή. Αν χρησιμοποιείται μία πολιτική περιοδικής εξέτασης, ο έλεγχος του αποθέματος και η τοποθέτηση της παραγγελίας πραγματοποιούνται ανά συγκεκριμένες περιόδους. Επίσης, η παραγγελία καταφθάνει στην αποθήκη και είναι διαθέσιμη να εξυπηρετήσει τη ζήτηση μετά από ένα χρονικό διάστημα παράδοσης (lead time) το οποίο μπορεί να παίρνει διάφορες τιμές ή να περιλαμβάνει και κάποια αβεβαιότητα, ανάλογα το προϊόν και τον προμηθευτή.

Τα παραπάνω περιγράφουν τη διαδικασία αποθεματοποίησης, με τα επιμέρους στοιχεία της, όμως, όπως το πως υπολογίζεται η ποσότητα της παραγγελίας και ποιο το επίπεδο αναπαραγγελίας να εξαρτώνται από την πολιτική αποθεματοποίησης που χρησιμοποιείται κάθε φορά. Με τον τρόπο αυτό, για δεδομένη πολιτική αποθεματοποίησης και δεδομένα ζήτησης είναι δυνατή η προσομοίωση λειτουργίας μιας αποθήκης για διάστημα ίσο με τα δεδομένα ζήτησης.



Σχήμα 5.13: Διάγραμμα ροής για την προσομοίωση της διαδικασίας αποθεματοποίησης.


Στον Πίνακα 5.4 και το Σχήμα 5.14 παρουσιάζονται τα αποτελέσματα μιας προσομοίωσης χρησιμοποιώντας την πολιτική  $(R, s, S)$  χωρίς απόθεμα ασφαλείας, στην οποία η ενδεχόμενη μη εξυπηρετούμενη ζήτηση χάνεται, με  $R = 1$ ,  $s = 5$  και  $S = 100$ , αρχικό απόθεμα  $Inventory_0 = 30$  και τυχαία ζήτηση  $(Demand_t)$  για διάστημα 35 ημερών, ενώ ο προμηθευτής εξυπηρετεί κάθε παραγγελία με καθυστέρηση μιας ημέρας  $(L = 1)$ . Βάσει της προσομοίωσης προκύπτει ότι για τη συγκεκριμένη χρονοσειρά ζήτησης και πολιτική αποθεματοποίησης, σε διάστημα 35 ημερών δημιουργούνται 12 χαμένες πωλήσεις, με 2 ημέρες στις οποίες το διαθέσιμο απόθεμα εκμηδενίζεται και

πραγματοποιούνται 4 παραγγελίες στον προμηθευτή ενώ το μέσο ημερήσιο απόθεμα στην αποθήκη είναι περίπου 52 τεμάχια προϊόντος.

Κατά συνέπεια, μπορούν να εξαχθούν χρήσιμες πληροφορίες σχετικά με τα επιμέρους κόστη που ενδέχεται να δημιουργηθούν αλλά και το επίπεδο εξυπηρέτησης πελατών σε αντίστοιχες περιπτώσεις, δηλαδή με όμοια ζήτηση και ίδια πολιτική αποθεματοποίησης.

Πίνακας 5.4: Παράδειγμα προσομοίωσης της διαδικασίας αποθεματοποίησης κάνοντας χρήση της πολιτικής (R, s, S) χωρίς απόθεμα ασφαλείας και με χαμένες πωλήσεις.

Day	R	s	S	L	Inventory	Demand	Order	Day	R	s	S	L	Inventory	Demand	Order
0	1	5	100	1	30			18	1	5	100	1	21	18	0
1	1	5	100	1	20	10	0	19	1	5	100	1	6	15	0
2	1	5	100	1	3	17	97	20	1	5	100	1	4	2	96
3	1	5	100	1	97	3	0	21	1	5	100	1	86	14	0
4	1	5	100	1	91	6	0	22	1	5	100	1	83	3	0
5	1	5	100	1	77	14	0	23	1	5	100	1	70	13	0
6	1	5	100	1	70	7	0	24	1	5	100	1	55	15	0
7	1	5	100	1	67	3	0	25	1	5	100	1	46	9	0
8	1	5	100	1	53	14	0	26	1	5	100	1	31	15	0
9	1	5	100	1	36	17	0	27	1	5	100	1	21	10	0
10	1	5	100	1	31	5	0	28	1	5	100	1	9	12	0
11	1	5	100	1	18	13	0	29	1	5	100	1	-10	19	100
12	1	5	100	1	-2	20	100	30	1	5	100	1	98	2	0
13	1	5	100	1	89	11	0	31	1	5	100	1	98	0	0
14	1	5	100	1	80	9	0	32	1	5	100	1	91	7	0
15	1	5	100	1	60	20	0	33	1	5	100	1	90	1	0
16	1	5	100	1	56	4	0	34	1	5	100	1	82	8	0
17	1	5	100	1	39	17	0	35	1	5	100	1	69	13	0



Σχήμα 5.14: Παράδειγμα προσομοίωσης της διαδικασίας αποθεματοποίησης χρησιμοποιώντας τα στοιχεία του Πίνακα 5.4.

Οι προσομοιώσεις αυτές, έτσι, αποτελούν χρήσιμα εργαλεία στα χέρια των υπεύθυνων λήψης αποφάσεων, καθώς τους δίνουν τη δυνατότητα να πειραματιστούν προκειμένου να αποκτήσουν αρκετά ξεκάθαρη εικόνα για πληθώρα ενδεχόμενων καταστάσεων αλλά τους

δίνουν τη δυνατότητα επίσης να βελτιστοποιήσουν τη χρησιμοποιούμενη πολιτική αποθεματοποίησης κρατώντας σταθερά τα δεδομένα ζήτησης.

Η απόδοση ενός τέτοιου μοντέλου προσομοίωσης εξαρτάται κυρίως από τον αριθμό των παραμέτρων ή παραγόντων που δρουν και αλληλεπιδρούν με έναν πολύπλοκο τρόπο. Ωστόσο, με τις προσομοιώσεις, οι σχέσεις μεταξύ των παραμέτρων ή ρυθμίσεων και των κριτηρίων απόδοσης που προκύπτουν δεν είναι ξεκάθαρες. Επομένως, η προσομοίωση γίνεται μια επαναλαμβανόμενη δοκιμαστική διαδικασία στην οποία χρησιμοποιείται ένα σύνολο παραμέτρων εισόδου για την πρόβλεψη ενός ή περισσότερων κριτηρίων απόδοσης. Εάν επιτευχθούν οι επιθυμητές επιδόσεις, έχει επιτευχθεί ένας καλός σχεδιασμός συστήματος, εναλλακτικά η διαδικασία επαναλαμβάνεται μέχρι να επιτευχθεί μία ικανοποιητική επίδοση. Δυστυχώς, η επαναληπτική φύση αυτής της διαδικασίας μπορεί να οδηγήσει σε αρκετά υψηλό υπολογιστικό κόστος και σε δυσκολίες στην ερμηνεία και την πρόβλεψη των αποτελεσμάτων.

“Δεν έχουμε καλύτερους αλγορίθμους, έχουμε απλά περισσότερα δεδομένα.”

– *Peter Norvig*

## Κεφάλαιο 6

### Μηχανική μάθηση

---

Η μηχανική μάθηση (machine learning - ML) αποτελεί υπό-πεδίο της επιστήμης υπολογιστών που αναπτύχθηκε από τη μελέτη της αναγνώρισης προτύπων και της υπολογιστικής θεωρίας μάθησης στην τεχνητή νοημοσύνη (artificial intelligence - AI). Είναι στενά συνδεδεμένη, και συχνά συγχέεται, με την υπολογιστική στατιστική, που είναι ένας κλάδος ο οποίος επίσης επικεντρώνεται στην πρόβλεψη μέσω της χρήσης των υπολογιστών. Η μηχανική μάθηση εφαρμόζεται σε μια σειρά από υπολογιστικές εργασίες, όπου τόσο ο σχεδιασμός όσο και ο προγραμματισμός των αλγορίθμων επίλυσής τους είναι συχνά ανέφικτος.

Στο πέρασμα του χρόνου έχουν διατυπωθεί διάφοροι ορισμοί της μηχανικής μάθησης, ο πιο επίσημος και κοινά αποδεκτός από τους οποίους είναι του Mitchell (1997) ο οποίος διατυπώνεται ως εξής: “Ένα πρόγραμμα υπολογιστή λέγεται ότι μαθαίνει από εμπειρία  $E$  ως προς μια κλάση εργασιών  $T$  και ένα μέτρο επίδοσης  $P$ , αν η επίδοσή του σε εργασίες της κλάσης  $T$ , όπως αποτιμάται από το μέτρο  $P$ , βελτιώνεται με την εμπειρία  $E$ ”.

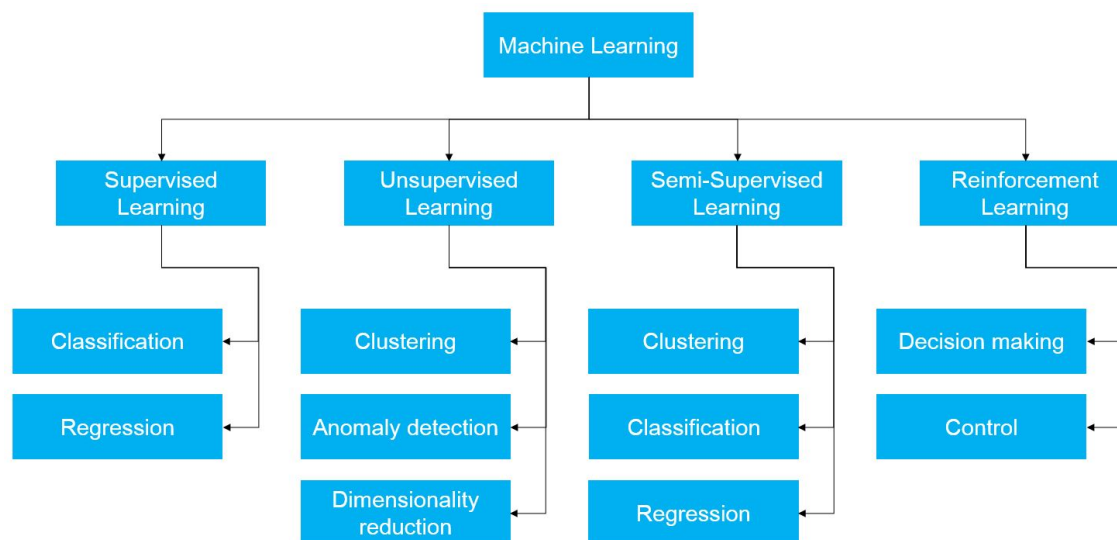
Εδώ είναι σημαντικό να αναφερθεί η διάκριση μεταξύ της τεχνητής νοημοσύνης και της μηχανικής μάθησης, μιας και η τεχνητή νοημοσύνη είναι η επιστήμη η οποία έχει στόχο την ανάπτυξη ευφυών συστημάτων τα οποία είναι ικανά να σκέφτονται και να ενεργούν σαν τον άνθρωπο, ενώ η μηχανική μάθηση αποτελεί πεδίο της τεχνητής νοημοσύνης και ασχολείται με την ανάπτυξη μεθόδων που παρέχουν την δυνατότητα σε συστήματα να μαθαίνουν αυτόνομα, βάσει των διαθέσιμων δεδομένων.

Στο παρόν Κεφάλαιο παρουσιάζονται τα είδη της μηχανικής μάθησης, εμβαθύνοντας σε ένα από αυτά, τη μηχανική μάθηση με επίβλεψη, αναφέρονται τα πιο γνωστά μοντέλα και οι πιο διαδεδομένοι αλγόριθμοί της, καταλήγοντας στο ερευνητικό πρόβλημα της μεταφοράς μάθησης (transfer learning).

#### 6.1 Είδη μηχανικής μάθησης

Μία εκ των κατηγοριοποιήσεων της μηχανικής μάθησης προσδιορίζει τέσσερεις βασικές κατηγορίες αλγορίθμων (Russell & Norvig, 2010), κάθε μία από τις οποίες αφορά σε διαφορετικά είδη προβλημάτων. Οι κατηγορίες αυτές είναι η επιτηρούμενη μάθηση, η μη επιτηρούμενη μάθηση, η ημι-επιτηρούμενη μάθηση και η ενισχυτική μάθηση, οι οποίες παρουσιάζονται συνοπτικά στη συνέχεια και απεικονίζονται στο Σχήμα 6.1.

##### **Επιτηρούμενη μάθηση (supervised learning)**



Σχήμα 6.1: Κατηγορίες μηχανικής μάθησης.

Τα μοντέλα που δημιουργούνται μέσω επιτηρούμενης ή επιβλεπόμενης μάθησης, ή αλλιώς μέσω μάθησης με επίβλεψη ή με επιτήρηση, (supervised learning), είναι κατάλληλα για την επίλυση προβλημάτων ταξινόμησης (classification) και παλινδρόμησης (regression). Η πρώτη κατηγορία προβλημάτων αφορά στην ταξινόμηση δειγμάτων εισόδου σε δύο ή περισσότερες κλάσεις, ενώ η δεύτερη στην εκτίμηση της τιμής μίας ή περισσότερων εξαρτημένων μεταβλητών.

Στόχος της επιτηρούμενης μάθησης είναι να συσχετίσει τα δεδομένα εισόδου με κάποιο επιθυμητό αποτέλεσμα το οποίο είναι η έξοδος του εκάστοτε μοντέλου μηχανικής μάθησης, με βασική προϋπόθεση τα δεδομένα εκπαίδευσης να διαθέτουν τις αναμενόμενες τιμές εξόδου (labels) για κάθε τιμή εισόδου (inputs).

#### **Μη επιτηρούμενη μάθηση (unsupervised learning)**

Τα μοντέλα που δημιουργούνται μέσω μη επιτηρούμενης μάθησης είναι κατάλληλα για την επίλυση προβλημάτων συσταδοποίησης (clustering), ανίχνευσης ανωμαλιών (anomaly detection) και μείωσης διαστάσεων (dimensionality reduction).

Στόχος της συγκεκριμένης κατηγορίας μηχανικής μάθησης είναι η αναζήτηση δομής στα δεδομένα η οποία μπορεί να εξηγή βέλτιστα τις διαφοροποιήσεις που παρατηρούνται σε αυτά. Έτσι, τα δεδομένα εκπαίδευσης, σε αντίθεση με την επιτηρούμενη μάθηση, δεν διαθέτουν τις τιμές εξόδου για κάθε είσοδο.

#### **Ημι-επιτηρούμενη μάθηση (semi-supervised learning)**

Η συγκεκριμένη κατηγορία μηχανικής μάθησης αποτελεί μια επέκταση των δύο προηγούμενων τεχνικών μάθησης και χρησιμοποιείται όταν ένας περιορισμένος αριθμός των αναμενόμενων τιμών εξόδου είναι διαθέσιμος.

#### **Ενισχυτική μάθηση (reinforcement learning)**

Η ενισχυτική μάθηση αποτελεί μια τεχνική με την οποία το σύστημα προσπαθεί να μάθει αλληλοεπιδρώντας με το περιβάλλον, έτσι τα μοντέλα που δημιουργούνται μέσω ενισχυτικής μάθησης μπορούν να χρησιμοποιηθούν σε εφαρμογές στις οποίες ο στόχος είναι μια σειρά από ενέργειες που οδηγούν σε μια κατάσταση ελαχίστου κόστους (ή μέγιστης ανταμοιβής).



## 6.2 Μηχανική μάθηση με επιτήρηση

Στην παρούσα εργασία θα χρησιμοποιηθούν αλγόριθμοι μηχανικής μάθησης με επιτήρηση, επομένως στη συνέχεια του Κεφαλαίου θα αναλυθούν οι πιο διαδεδομένοι αλγόριθμοι και τεχνικές αυτής της κατηγορίας. Οι πιο δημοφιλείς τύποι μοντέλων επιτηρούμενης μάθησης είναι οι μηχανές διανυσμάτων υποστήριξης, τα δέντρα αποφάσεων, τα τυχαία δάση, οι αλγόριθμοι ενίσχυσης κλίσης και τα νευρωνικά δίκτυα (Ayodele, 2010). Παρακάτω παρουσιάζονται αναλυτικά τα δέντρα αποφάσεων και ο συνδυασμός αυτών με τη βοήθεια αλγορίθμων ενίσχυσης κλίσης, τα οποία και χρησιμοποιούνται στην παρούσα διατριβή, ενώ πραγματοποιείται μία αναφορά στις μηχανές διανυσμάτων υποστήριξης και τα νευρωνικά δίκτυα για λόγους πληρότητας.

### 6.2.1 Μηχανές διανυσμάτων υποστήριξης (Support Vector Machines)

Οι μηχανές διανυσμάτων υποστήριξης (Support Vector Machines - SVM) (Cortes & Vapnik, 1995) είναι μία μη-πιθανοτική, δυαδική, κατά βάση γραμμική μέθοδος ταξινόμησης και απαιτεί επισημασμένα δεδομένα για τα λειτουργήσει. Επεκτάσεις αυτής της μεθόδου, μπορούν να την καταστήσουν κατάλληλη και για μη γραμμικά δεδομένα, όπως είναι για παράδειγμα το τέχνασμα του πυρήνα (kernel trick).

Οι συγκεκριμένες μηχανές κατασκευάζουν ένα υπερ-επίπεδο (hyperlane) στον χώρο των δεδομένων, το οποίο διαχωρίζει βέλτιστα τις διαφορετικές κλάσεις δεδομένων, καθιστώντας τις ικανές να χρησιμοποιηθούν για την επίλυση προβλημάτων ταξινόμησης (classification) αλλά και παλινδρόμησης (regression).

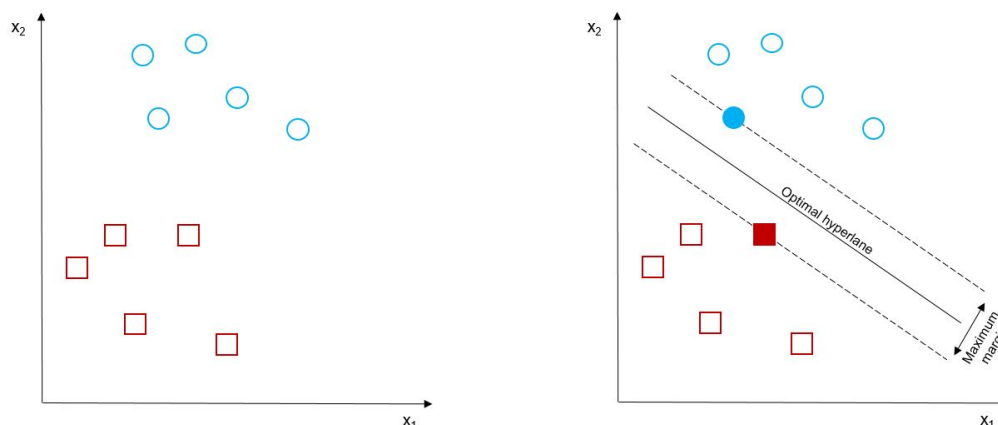
Τα SVM ασχολούνται με την έννοια του “περιθωρίου” (margin) που τοποθετούν σε κάθε πλευρά του υπερ-επίπεδου που χωρίζει δύο κατηγορίες δεδομένων. Η μεγιστοποίηση του περιθωρίου και επομένως η δημιουργία της μεγαλύτερης δυνατής απόστασης μεταξύ του διαχωριστικού υπερ-επίπεδου και των παρατηρήσεων σε κάθε πλευρά του έχει αποδειχθεί ότι μειώνει το αναμενόμενο σφάλμα γενίκευσης (Kotsiantis et al., 2007).

Να σημειωθεί εδώ ότι το σφάλμα γενίκευσης (generalization error), ή σφάλμα out-of-sample ή ρίσκο (risk), στη μηχανική μάθηση είναι ένα μέτρο της ακρίβειας ενός αλγόριθμου σε τιμές δεδομένων που δεν είχαν εμφανιστεί προηγουμένως στα δεδομένα εκπαίδευσης. Στην ουσία, το συγκεκριμένο σφάλμα ταυτίζεται με το σφάλμα out-of-sample όπως αυτό παρουσιάστηκε στο Υποκεφάλαιο 4.5.

Στο Σχήμα 6.2 απεικονίζεται το υπερ-επίπεδο και το περιθώριο που έχει υπολογιστεί από μία μηχανή διανυσμάτων υποστήριξης η οποία έχει εκπαιδευτεί με παρατηρήσεις δύο κλάσεων (κόκκινα τετράγωνα και γαλάζιοι κύκλοι).

### 6.2.2 Νευρωνικά δίκτυα (Neural Networks)

Η πολυπλοκότητα με την οποία ο ανθρώπινος εγκέφαλος δύναται να οργανώσει τις πληροφορίες που λαμβάνει, η προσαρμοστικότητά του στο περιβάλλον και η εν γένει διαφορετικότητά του σε σχέση με έναν ψηφιακό υπολογιστή οδήγησε στην κατασκευή των τεχνητών νευρωνικών δικτύων. Σύμφωνα με τον Simon (2009) ένα νευρωνικό δίκτυο ορίζεται ως εξής: “Ένα νευρωνικό δίκτυο είναι ένας τεράστιος παράλληλος επεξεργαστής με



Σχήμα 6.2: Το υπερ-επίπεδο και το μέγιστο περιθώριο ενός SVM που έχει εκπαιδευτεί με παρατηρήσεις δύο κλάσεων.

κατανεμημένη αρχιτεκτονική, ο οποίος αποτελείται από απλές μονάδες επεξεργασίας και έχει από τη φύση του τη δυνατότητα να αποθηκεύει εμπειρική γνώση και να την καθιστά διαθέσιμη για χρήση”. Μοιάζει, έτσι, με τον ανθρώπινο εγκέφαλο σε δύο σημεία :

1. Το δίκτυο προσλαμβάνει γνώση από το περιβάλλον του, μέσω μιας διαδικασίας μάθησης
2. Η ισχύς των συνδέσεων μεταξύ των νευρώνων, που αποκαλείται συναπτικό βάρος, χρησιμοποιείται για την αποθήκευση της γνώσης που αποκτάται

Δομική μονάδα των νευρωνικών δικτύων αποτελεί ο νευρώνας, το οποίο προτάθηκε ως ένας δυαδικός ταξινομητής, αλλά μπορεί να χρησιμοποιηθεί για ταξινόμηση αλλά και γραμμική ή μη γραμμική παλινδρόμηση (Rosenblatt, 1957). Ένας νευρώνας έχει  $n$  εισόδους, κάθε μία από τις οποίες πολλαπλασιάζεται με μία συνιστώσα του βάρους, το οποίο ουσιαστικά αποτελεί το εσωτερικό γινόμενο του διανύσματος εισόδου με το διάνυσμα των βαρών, και μετασχηματίζεται μέσω της βηματικής συνάρτησης ενεργοποίησης αφού προστεθεί πρώτα σε αυτό μία σταθερά γνωστή ως προκατάληψη. Η έξοδος του νευρώνα  $k$  ( $y_k$ ) περιγράφεται από τις παρακάτω εξισώσεις :

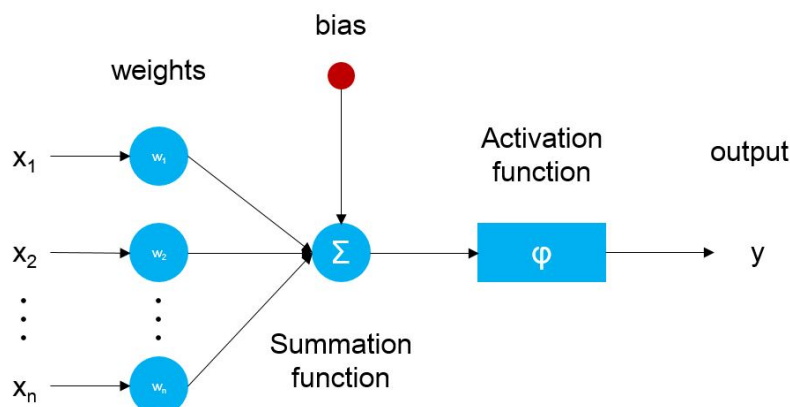
$$u_k = \sum_{j=1}^m w_{kj} x_j$$

$$y_k = \phi(u_k + b_k),$$

όπου  $x_j$  τα σήματα εισόδου,  $u_k$  η έξοδος του γραμμικού συνδυαστή,  $w_{kj}$  τα συναπτικά βάρη του νευρώνα  $k$  για τις αντίστοιχες εισόδους  $j$ ,  $\phi(\cdot)$  η συνάρτηση ενεργοποίησης και  $b_k$  η προκατάληψη (πόλωση).

Στο Σχήμα 6.3 παρουσιάζεται ένα βασικό μοντέλο νευρώνα, όπως περιγράφηκε παραπάνω.

Όπως αναφέρθηκε, το εσωτερικό γινόμενο των διανυσμάτων της εισόδου και των βαρών ενός νευρώνα μετασχηματίζεται μέσω μιας συνάρτησης πριν αυτό φτάσει στην έξοδο και τροφοδοτήσει τα επόμενα επίπεδα νευρώνων. Η συνάρτηση αυτή καλείται συνάρτηση



Σχήμα 6.3: Απεικόνιση μοντέλου νευρώνα.

ενεργοποίησης (activation function) και έχει αποδειχθεί ότι διαδραματίζει σημαντικό ρόλο στην επίδοση ενός νευρωνικού δικτύου (Wang et al., 2020). Οι βασικότερες συναρτήσεις είναι η ταυτοτική, η σιγμοειδής, η συνάρτηση υπερβολικής εφαπτομένης, η συνάρτηση ReLU και η Leaky ReLU.

Ο τρόπος με τον οποίο διάφοροι νευρώνες τοποθετούνται μέσα σε ένα νευρωνικό δίκτυο και επικοινωνούν μεταξύ τους ονομάζεται αρχιτεκτονική του νευρωνικού δικτύου, γεγονός που επηρεάζει άμεσα τον αλγόριθμο μάθησης που χρησιμοποιείται για την εκπαίδευσή του. Οι πιο δημοφιλείς κατηγορίες αρχιτεκτονικών είναι οι εξής:

- δίκτυα εμπρόσθιας τροφοδότησης (feedforward)
- αναδρομικά δίκτυα (recurrent)
- συνελκτικά δίκτυα (convolutional)

Εδώ αξίζει να αναφερθεί και η τεχνική “back propagation”, η οποία συναντάται πολύ συχνά κατά την εκπαίδευση νευρωνικών δικτύων. Η συγκεκριμένη τεχνική, πιο αναλυτικά “backward propagation of errors”, δηλαδή αντίστροφη διάδοση σφαλμάτων, στην ουσία είναι ένα αλγόριθμος για επιτηρούμενη μάθηση τεχνητών νευρωνικών δικτύων με χρήση καθοδικής κλίσης (gradient descent). Για δεδομένο τεχνητό νευρωνικό δίκτυο και συνάρτηση σφάλματος, η μέθοδος αυτή υπολογίζει την κλίση της συνάρτησης σφάλματος σε σχέση με τα βάρη του νευρωνικού δικτύου. Ο όρος “αντίστροφη” αναφέρεται στο γεγονός ότι ο υπολογισμός της κλίσης προχωρά προς τα πίσω μέσω του δικτύου, με την κλίση του τελικού επιπέδου των βαρών να υπολογίζεται πρώτα και την κλίση του πρώτου επιπέδου βαρών να υπολογίζεται τελευταία.

### 6.2.3 Δέντρα αποφάσεων (Decision trees)

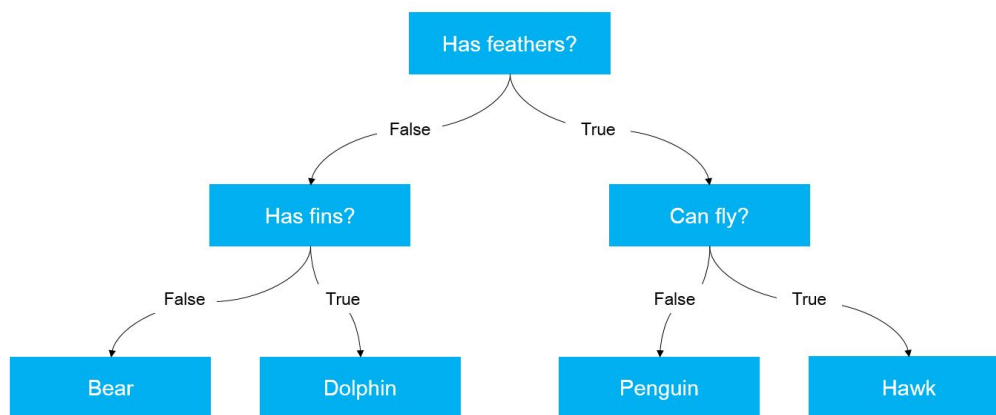
Τα δέντρα αποφάσεων (Decision Trees - DT) (Hunt et al., 1966) συνιστούν μοντέλα μηχανικής μάθησης τα οποία παράγουν προβλέψεις κατασκευάζοντας κάποιους απλούς κανόνες απόφασης με βάση τα διαθέσιμα ιστορικά δεδομένα, και αποτελούνται από τα εξής στοιχεία:

- έναν κόμβο ρίζας (root node),
- εσωτερικούς κόμβους απόφασης (decision nodes), και
- φύλλα (leaf nodes).

Με τον τρόπο αυτό, στην ρίζα του δέντρου περιλαμβάνεται το σύνολο του πληθυσμού των εγγραφών (samples), σε κάθε εσωτερικό κόμβο απόφασης ο πληθυσμός διχοτομείται σύμφωνα με το εκάστοτε κριτήριο απόφασης και το δέντρο καταλήγει στα φύλλα τα οποία αποτελούν και την τελική πρόβλεψη για κάθε εγγραφή.

Η λειτουργικότητα αλλά και η πολυπλοκότητα των δέντρων αποφάσεων επηρεάζεται άμεσα από το κριτήριο βελτιστοποίησης, το μέγιστο δυνατό βάθος του δέντρου (max depth), δηλαδή το μεγαλύτερο σε μήκος μονοπάτι από τη ρίζα στα φύλλα, τον ελάχιστο πληθυσμό δειγμάτων στον κόμβο που απαιτείται προκειμένου να επιτραπεί η διχοτόμηση (min samples split) και τον ελάχιστο πληθυσμό δειγμάτων στα φύλλα προκειμένου αυτά να δημιουργηθούν (min samples leaf).

Στο Σχήμα 6.4 απεικονίζεται ένα πολύ απλό δέντρο αποφάσεων το οποίο, λαμβάνοντας υπόψη ένα ζώο, χρησιμοποιεί ως κόμβο ρίζας την ερώτηση εάν αυτό έχει φτερά και ως εσωτερικούς κόμβους απόφασης τις ερωτήσεις εάν έχει πτερύγια και αν μπορεί να πετάξει προκειμένου να το κατατάξει στα τέσσερα φύλλα του τα οποία είναι η αρκούδα, το δελφίνι, ο πιγκουίνος και το γεράκι.



Σχήμα 6.4: Παράδειγμα δέντρου αποφάσεων..

Πιο αναλυτικά, τα δέντρα αποφάσεων μπορούν να χρησιμοποιηθούν τόσο στην περίπτωση της ταξινόμησης όσο και της παλινδρόμησης, αξιοποιώντας την ίδια θεωρία λειτουργίας, τη σειριακή διχοτόμηση του αρχικού πληθυσμού των παρατηρήσεων, για αυτό και συχνά αναφέρονται ως Classification and Regression Trees (CART). Προφανώς η προβλεπτική ακρίβεια ορίζεται διαφορετικά στις δύο αυτές κατηγορίες προβλημάτων, καθώς στην πρώτη αναζητούνται κανόνες για την ορθότερη ταξινόμηση των παρατηρήσεων, ενώ στη δεύτερη αναζητούνται κανόνες για την ελαχιστοποίηση του τετραγωνικού σφάλματος.

Στη σημείο αυτό αξίζει να αναφερθούν τα μεγέθη τα οποία υπολογίζονται κατά την ανάπτυξη ενός δέντρου αποφάσεων. Αυτά είναι η εντροπία (entropy), το κέρδος πληροφορίας (gain) και ο δείκτης Gini.

Η εντροπία αποτελεί τη ποσότητα της πληροφορίας που χρειάζεται προκειμένου να αποφασιστεί αν μία παρατήρηση ενός συνόλου  $S$  ανήκει σε μία κλάση. Όσο μικρότερη η εντροπία, τόσο πιο εύκολη είναι η διάκριση των παρατηρήσεων και για δύο κλάσεις του συνόλου  $S$ , πληθυσμών  $p$  και  $n$  αντίστοιχα υπολογίζεται ως εξής:

$$E_S = -\frac{p}{p+n} \log_2\left(\frac{p}{p+n}\right) - \frac{n}{p+n} \log_2\left(\frac{n}{p+n}\right),$$

και γενικεύοντας για  $k$  κλάσεις πληθυσμού  $p_i$  η κάθε μία:

$$E_S = -\sum_{i=1}^k p_i \log_2\left(\frac{p_i}{p}\right), \text{ όπου } p = \sum_{i=1}^k p_i$$

Το κέρδος πληροφορίας υπολογίζει κατά πόσο η χρήση μίας επιπλέον πληροφορίας (ανεξάρτητη μεταβλητή  $x$ ) βοηθάει στη μείωση της αρχικής εντροπίας του συνόλου  $S$ . Έτσι, η μεταβλητή  $x$  η οποία μεγιστοποιεί το κέρδος πληροφορίας επιλέγεται για τον περαιτέρω διαχωρισμό του. Για το διαχωρισμό του αρχικού συνόλου  $S$  βάσει της μεταβλητής  $x$  σε δύο σύνολα  $S_1$  και  $S_2$  πληθυσμών  $P_1$  και  $P_2$ , αντίστοιχα, το κέρδος πληροφορίας υπολογίζεται ως εξής:

$$Gain_x = E_S - \frac{P_1}{P_1 + P_2} E_{S_1} - \frac{P_2}{P_1 + P_2} E_{S_2}$$

Ο δείκτης Gini, με τη σειρά του, απεικονίζει το ποσοστό των παρατηρήσεων ενός συνόλου  $S$  τα οποία ανήκουν στην ίδια κλάση, και παίρνει μηδενική τιμή όταν όλες οι παρατηρήσεις ανήκουν στην ίδια κλάση και τιμή 0.5 όταν αυτές ισοκατανέμονται μεταξύ των κλάσεων. Συνεπώς, η μεταβλητή  $x$  που ελαχιστοποιεί το δείκτη Gini επιλέγεται για τον περαιτέρω διαχωρισμό του συνόλου  $S$ .

Για ένα σύνολο παρατηρήσεων  $S$ , συνολικού πληθυσμού  $p = \sum_{i=1}^k p_i$  και  $k$  κλάσεων πληθυσμών  $p_1, p_2, \dots, p_k$  αντίστοιχα, ο δείκτης Gini υπολογίζεται ως εξής:

$$Gini_S = 1 - \sum_{i=1}^k \left(\frac{p_i}{p}\right)^2$$

Με τον τρόπο αυτό, για το διαχωρισμό του  $S$  βάσει μιας μεταβλητής  $x$  σε δύο σύνολα  $S_1$  και  $S_2$  πληθυσμού  $p_1$  και  $p_2$  αντίστοιχα ο συγκεκριμένος δείκτης υπολογίζεται ως εξής:

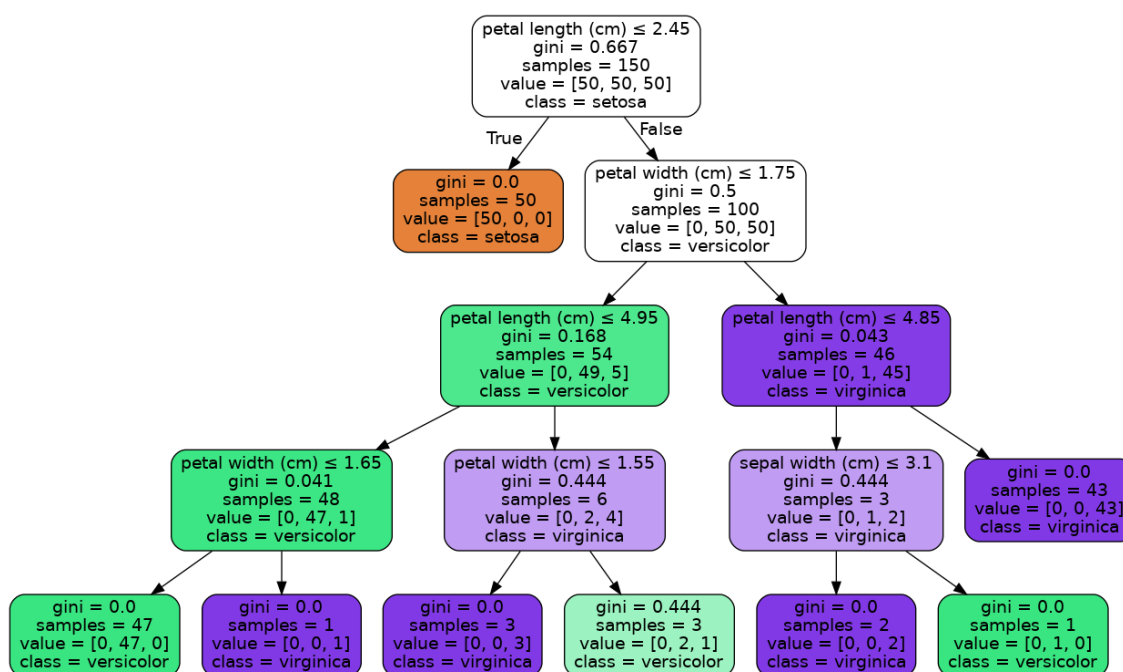
$$Gini_x = Gini_{S_1} \frac{p_1}{p_1 + p_2} + Gini_{S_2} \frac{p_2}{p_1 + p_2}$$

Οι προηγούμενοι δείκτες αφορούν κυρίως τα δέντρα ταξινόμησης. Στα δέντρα παλινδρόμησης ο πιο ευρέως χρησιμοποιούμενος δείκτης, όπως αναφέρθηκε και παραπάνω, είναι το τετραγωνικό σφάλμα και πιο συγκεκριμένα το άθροισμα των τετραγωνικών σφαλμάτων (sum of squared error - SSE). Υποθέτοντας, έτσι, ότι το σύνολο δεδομένων πρέπει να διχοτομηθεί σε δύο σύνολα  $S_1$  και  $S_2$ , τότε αυτά θα επιλεγθούν έτσι ώστε να ελαχιστοποιούν τον δείκτη SSE ο οποίος ορίζεται ως εξής:

$$SSE = \sum_{i \in S_1} (y_i - \bar{y}_1)^2 + \sum_{i \in S_2} (y_i - \bar{y}_2)^2,$$

όπου  $\bar{y}_1$  και  $\bar{y}_2$  είναι οι μέσες τιμές των συνόλων  $S_1$  και  $S_2$  αντίστοιχα. Ο τρόπος με τον οποίο αναπτύσσεται ένα δέντρο παλινδρόμησης είναι αποφασίζοντας αυτόματα για τις μεταβλητές διαχωρισμού και τα σημεία διαχωρισμού τα οποία οδηγούν στην μεγαλύτερη δυνατή μείωση του SSE. Επίσης, σε αυτή την περίπτωση δένδρων, η τιμή της πρόβλεψης είναι κάθε φορά η μέση τιμή του συνόλου στο οποίο κατατάσσονται τα νέα δεδομένα, δηλαδή στην περίπτωση των δύο συνόλων ισούται με  $\bar{y}_1$  ή  $\bar{y}_2$ .

Στο Σχήμα 6.5 απεικονίζεται ένα δέντρο αποφάσεων, που έχει κατασκευαστεί χρησιμοποιώντας το σύνολο δεδομένων iris, στο οποίο έχει οριστεί ως μέγιστο βάθος (max depth) η τιμή τέσσερα. Φαίνεται ότι βάσει των μεταβλητών petal length, petal width και sepal width πραγματοποιείται η διχοτόμηση των αρχικών 150 παρατηρήσεων στα 8 φύλλα. Όσο η τιμή Gini ενός φύλλου είναι μεγαλύτερη του μηδενός και το συγκεκριμένο κλαδί δεν έχει φτάσει το μέγιστο βάθος, η διχοτόμηση συνεχίζεται, βάσει της μεταβλητής η οποία εμφανίζει το μεγαλύτερο κέρδος πληροφορίας.



Σχήμα 6.5: Παράδειγμα οπτικοποίησης δέντρου αποφάσεων χρησιμοποιώντας το ευρέως χρησιμοποιούμενο σύνολο δεδομένων iris.

Το παράδειγμα του Σχήματος 6.5 μπορεί να αναπαραχθεί χρησιμοποιώντας τις παρακάτω εντολές της γλώσσας προγραμματισμού R. Στην ουσία, κάνοντας χρήση των πακέτων rpart (Therneau & Atkinson, 2019) και rpart.plot (Milborrow, 2021) μπορεί κανείς να κατασκευάσει ένα δέντρο αποφάσεων παρέχοντας ένα σύνολο δεδομένων και ορίζοντας την εξαρτημένη και τις ανεξάρτητες μεταβλητές, μαζί με συγκεκριμένες παραμέτρους οι οποίες διαφοροποιούν τη λειτουργικότητα και την πολυπλοκότητα του δέντρου.

```

# Load necessary libraries
library('rpart')
library('rpart.plot')

```

```

# Use the 'iris' data set
df <- iris

# Create a decision tree using all the available data, as target the 'Species' column and all the other
# columns as independent variables
tree <- rpart(Species ~ ., df)

# Plot the generated decision tree
rpart.plot(tree)

# Create out-of-sample data
outsample <- data.frame('Sepal.Length' = 6.2,
                        'Sepal.Width' = 3.1,
                        'Petal.Length' = 5.9,
                        'Petal.Width' = 2.4)

# Predict the 'Species' of the outsample data given its independent variables
predict(tree, outsample)

```

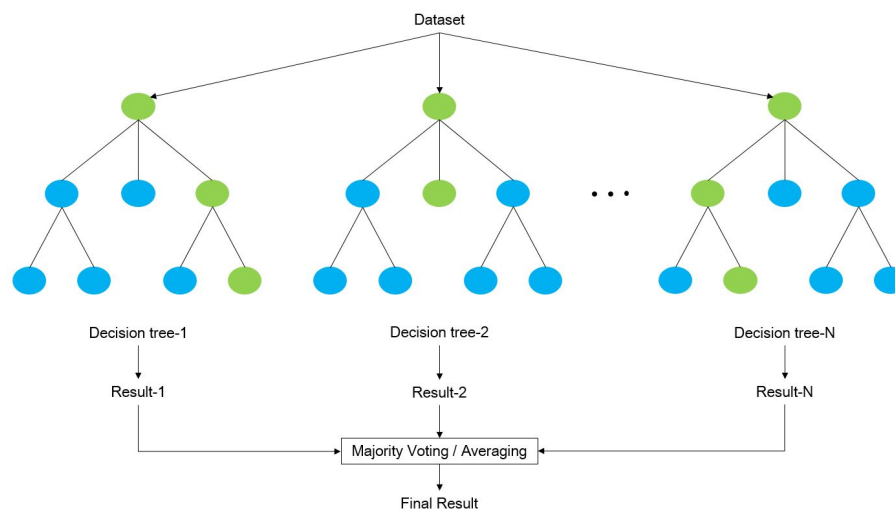
Παρά το γεγονός ότι οι συγκεκριμένοι αλγόριθμοι χρησιμοποιούνται εκτεταμένως, έχουν περιορισμένες δυνατότητες μοντελοποίησης. Έτσι, η χρήση ενός μόνο απλού δέντρου δεν προτείνεται, ιδιαίτερα σε πολύπλοκα προβλήματα, αλλά πρέπει να προτιμάται ο συνδυασμός δέντρων αποφάσεων, με διάφορες τεχνικές οι οποίες παρουσιάζονται στη συνέχεια του Κεφαλαίου και οι οποίες μπορούν να οδηγήσουν σε σημαντικά καλύτερα αποτελέσματα. Πολλοί από τους αλγορίθμους δέντρων αποφάσεων απαιτούν τα χαρακτηριστικά τα οποία λαμβάνουν την τελική απόφαση, να έχουν μόνο διακριτές τιμές, και τις περισσότερες φορές κάθε κόμβος εστιάζει μόνο σε ένα χαρακτηριστικό, ενώ παράλληλα εμφανίζουν αυξημένη ευαισθησία ως προς τα δεδομένα εκπαίδευσης, τα συσχετισμένα χαρακτηριστικά και το θόρυβο με αποτέλεσμα να επηρεάζονται σημαντικά από ακραίες τιμές.

### 6.2.3.1 Τυχαία δάση (Random forests)

Τα τυχαία δάση (Random Forests - RF) (Ho, 1995) αποτελούν μια εκ των επιλογών ως προς τον συνδυασμό των απλών δέντρων αποφάσεων. Τα δέντρα τα οποία λαμβάνονται υπόψη σε τέτοιους αλγορίθμους συνδυασμού αναφέρονται συχνά ως *weak learners*, δηλαδή “αδύναμοι μαθητές”, καθώς από μόνα τους είναι αρκετά ρηχά και συνεπώς δεν προλαβαίνουν να αναπτύξουν σύνθετους κανόνες εκμάθησης. Στον συγκεκριμένο αλγόριθμο τα επιμέρους δέντρα αναπτύσσονται ανεξάρτητα και συνδιάζονται απλά, συνήθως λαμβάνοντας υπόψη τη μέση τιμή τους για τη δημιουργία του τελικού δέντρου.

Κάθε *weak learner* που συμμετέχει σε ένα Random Forest εκπαιδεύεται με μοναδικό τρόπο, και κατά συνέπεια προσφέρει μια διαφορετική “οπτική”, καθώς κάθε ένας εκπαιδεύεται με ολόκληρο το αρχικό σύνολο δεδομένων αλλά διαφορετικές μεταβλητές εισόδου (features), τυχαία επιλεγμένες από τις διαθέσιμες, συνήθως μικρότερου πλήθους. Έτσι, στην ουσία εφαρμόζεται η θεωρία του *wisdom of crowds*, σύμφωνα με την οποία η συλλογική γνώμη μιας ομάδας επιφέρει καλύτερα αποτελέσματα από ότι ενός μεμονωμένου ειδικού μέρους αυτής.

Στο Σχήμα 6.6 απεικονίζεται ένα παράδειγμα αλγορίθμου Random Forests.



Σχήμα 6.6: Παράδειγμα οπτικοποίησης αλγορίθμου τυχαίων δασών κλίσης (Random Forests).

### 6.2.3.2 Ενίσχυση κλίσης (Gradient Boosting)

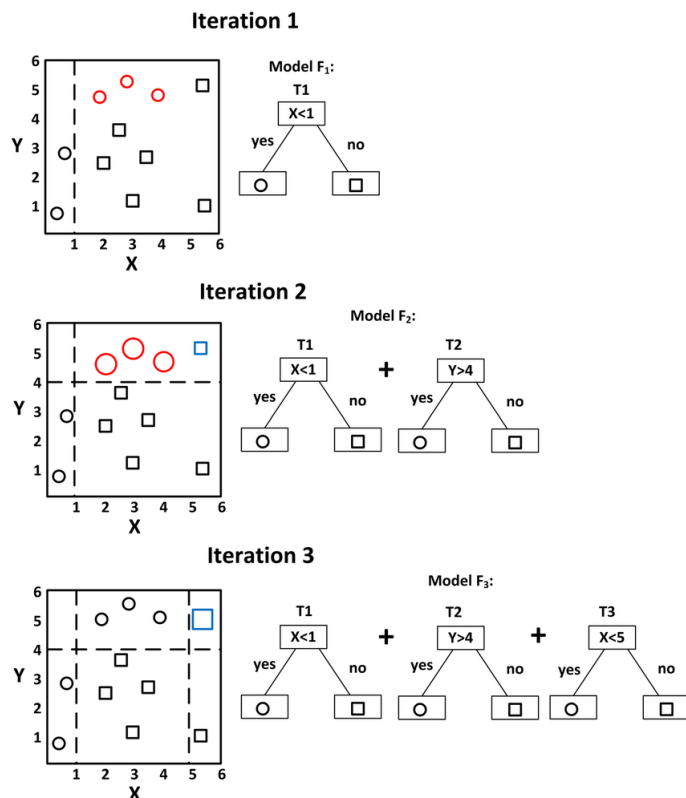
Οι αλγόριθμοι ενίσχυσης κλίσης (Gradient Boosting - GB) (Friedman, 2001) αποτελούν μία ακόμα επιλογή για τον συνδυασμό των απλών δέντρων αποφάσεων.

Σε αντίθεση με τα Random Forests, στην περίπτωση του Gradient Boosting τα δέντρα αποφάσεων δεν αναπτύσσονται ανεξάρτητα, αλλά συνδυάζονται σειριακά με αποτέλεσμα να ενισχύεται σταδιακά η γνώση των weak learners που κατά το προηγούμενο βήμα εμφάνισαν το μεγαλύτερο σφάλμα. Η ενίσχυση αυτή γίνεται μέσω της προσθήκης ενός επιπλέον weak learner στο αντίστοιχο φύλλο του προηγούμενου weak learner. Έτσι, το τελικό δέντρο που δημιουργείται διορθώνει τα λάθη του και καταλήγει σε πιο ακριβή αποτελέσματα, όπως απεικονίζεται και στο Σχήμα 6.7. Έτσι, κάθε νέο δέντρο δεν “προβλέπει” την ανεξάρτητη μεταβλητή, όπως στις προηγούμενες τεχνικές, αλλά το σφάλμα των προηγούμενων δέντρων. Σε κάθε βήμα, το αποτέλεσμα ενός GB είναι ένας σταθμισμένος μέσος όρος των αποτελεσμάτων που παρέχονται από το αρχικό δέντρο και το επόμενο δέντρο που εισάγεται. Αυτή η διαδικασία ονομάζεται ενίσχυση, και συνεχίζεται με κάθε νέο δέντρο που έχει σχεδιαστεί για τη βελτίωση του προηγούμενου μοντέλου.

Παρά το γεγονός ότι ο συγκεκριμένος αλγόριθμος μπορεί να δώσει αρκετά λεπτομερείς λύσεις σε πολύπλοκα προβλήματα, είναι ευάλωτος στην υπερπροσαρμογή (overfitting). Δημοφιλείς εφαρμογές των αλγορίθμων Gradient Boosting αποτελούν το XGBoost (Chen & Guestrin, 2016) και το LightGBM, το οποίο παρουσιάζεται στη συνέχεια του Κεφαλαίου.

Να σημειωθεί εδώ ότι υπερπροσαρμογή ή υπερμοντελοποίηση (overfitting) ονομάζεται το φαινόμενο που παρατηρείται όταν ένα μοντέλο έχει προσαρμοστεί σε ένα συγκεκριμένο σύνολο δεδομένων σε τέτοιο βαθμό ώστε να μην μπορεί να προσαρμοστεί σε νέα δεδομένα ή να προβλέψει νέες παρατηρήσεις αξιόπιστα. Ακριβώς το αντίθετο φαινόμενο από την υπερπροσαρμογή αποτελεί η ατελής μάθηση ή υποπροσαρμογή (underfitting), κατά το οποίο ένα μοντέλο το οποίο δεν είναι αρκετά σύνθετο, μπορεί να αποτύχει να





Σχήμα 6.7: Παράδειγμα οπτικοποίησης αλγορίθμου ενίσχυσης κλίσης (Gradient Boosting). (Πηγή: Zhang et al. (2018))

μοντελοποιήσει επιτυχώς τα δεδομένα εκπαίδευσης και να μη μπορεί να γενικεύσει σε νέα δεδομένα.

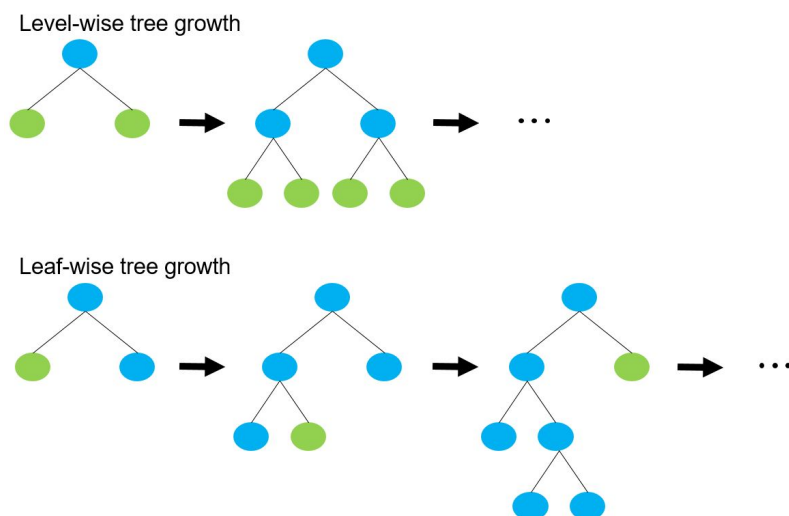
### 6.2.3.3 Light Gradient Boosting Machine (LightGBM)

Το LightGBM είναι ένα δωρεάν και ανοιχτού κώδικα πλαίσιο ενίσχυσης κλίσης μηχανικής μάθησης που αναπτύχθηκε από τη Microsoft (Ke et al., 2017). Το συγκεκριμένο πλαίσιο βασίζεται σε αλγόριθμους δέντρων αποφάσεων και χρησιμοποιείται ευρέως σε προβλήματα τόσο classification όσο και regression εστιάζοντας στην απόδοση και την επεκτασιμότητα.

Το συγκεκριμένο πλαίσιο χρησιμοποιεί έναν αλγόριθμο ανάπτυξης δέντρων με βάση τα φύλλα (leaf-wise), σε αντίθεση με άλλα δημοφιλή πλαίσια τα οποία χρησιμοποιούν αλγόριθμους οι οποίοι αναπτύσσουν δέντρα κατά βάθος (level-wise), ενώ παράλληλα αξιοποιεί έναν αποδοτικό αλγόριθμο διαχωρισμού των τιμών που βασίζεται στην ανάλυση των ιστογραμμάτων των εν λόγω τιμών. Σε σύγκριση με την ανάπτυξη κατά βάθος, ο αλγόριθμος με βάση τα φύλλα μπορεί να συγκλίνει πολύ πιο γρήγορα. Ωστόσο, αυτή η ανάπτυξη μπορεί να οδηγήσει σε overfitting εάν δεν χρησιμοποιηθεί με τις κατάλληλες παραμέτρους. Στο LightGBM το τελικό αποτέλεσμα είναι ο σταθμισμένος μέσος όρος των αποτελεσμάτων που προκύπτουν από όλα τα κατασκευασμένα δέντρα, καθένα από τα οποία είναι υπεύθυνο για τη μοντελοποίηση του σφάλματος του προηγούμενου δέντρου, σύμφωνα με τη λογική των αλγορίθμων ενίσχυσης κλίσης.

Στο Σχήμα 6.8 απεικονίζεται η προσέγγιση ανάπτυξης δέντρων με βάση τα φύλλα σε

σύγκριση με την ανάπτυξη κατά βάθος.



Σχήμα 6.8: Απεικόνιση αλγορίθμου ανάπτυξης δέντρου με βάση τα φύλλα (leaf-wise, κάτω), σε αντίθεση με έναν αλγόριθμο ο οποίος αναπτύσσει ένα δέντρο κατά βάθος (level-wise, επάνω).

Το πρόβλημα που περιγράφηκε στο Υποκεφάλαιο 6.2.3, για το οποίο κατασκευάστηκε ένα δέντρο αποφάσεων κάνοντας χρήση του πακέτου `rpart` της R, μπορεί να αντιμετωπιστεί κάνοντας χρήση του πλαισίου `LightGBM`, εφαρμόζοντας το πακέτο `lightgbm` (Ke et al., 2020) επίσης της γλώσσας R. Παρακάτω φαίνονται οι εντολές οι οποίες κατασκευάζουν ένα μοντέλο. Να σημειωθεί ότι χρησιμοποιείται και το πακέτο `Matrix` (Bates & Maechler, 2021) προκειμένου τα δεδομένα να πάρουν κατάλληλη μορφή για να μπορέσουν να χρησιμοποιηθούν από το πακέτο `lightgbm`.

```
# Load necessary libraries
library('lightgbm')
library('Matrix')

# Use the 'iris' data set
df <- iris

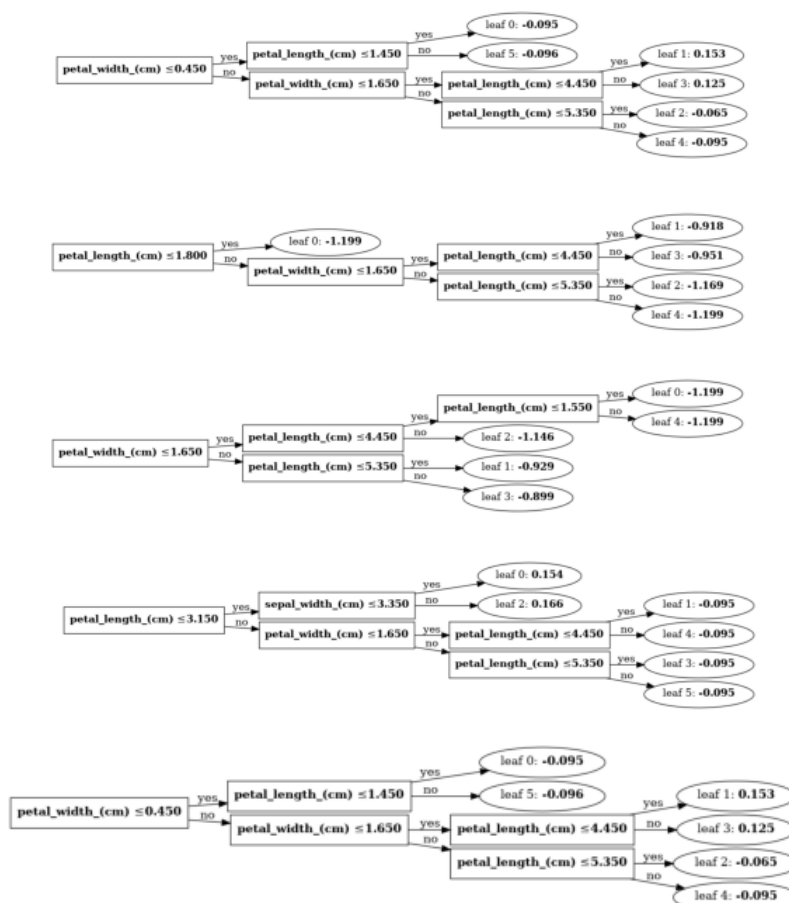
# Create a decision tree using all the available data, as target the 'Species' column and all the other
# columns as independent variables
x_train <- Matrix(as.matrix(df[, -5]), sparse = TRUE)
y_train <- as.numeric(df[, 5])
lgb.train <- lgb.Dataset(data = x_train, label = y_train)

lgb.grid <- list(objective = 'regression', metric = 'rmse')
lgb.model <- lgb.train(params = lgb.grid, data = lgb.train)

# Create out-of-sample data
outsample <- data.frame('Sepal.Length' = 6.2,
                        'Sepal.Width' = 3.1,
                        'Petal.Length' = 5.9,
                        'Petal.Width' = 2.4)
outsample <- Matrix(as.matrix(outsample), sparse = TRUE)
```

```
# Predict the 'Species' of the outsample data given its independent variables
predict(lgb.model, outsample)
```

Στο Σχήμα 6.9 απεικονίζονται τα πέντε πρώτα δέντρα που προέκυψαν από την παραπάνω εφαρμογή του LightGBM στο σύνολο δεδομένων iris.



Σχήμα 6.9: Παράδειγμα οπτικοποίησης πέντε δέντρων αποφάσεων του μοντέλου LightGBM που κατασκευάστηκε για να ταξινομήσει τις παρατηρήσεις του συνόλου δεδομένων iris.

Όπως αναφέρεται και στις οδηγίες χρήσης του lightgbm, για να προκύψουν καλά αποτελέσματα από ένα πλαίσιο το οποίο χρησιμοποιεί leaf-wise ανάπτυξη, και να αποφευχθεί η υπερπροσαρμογή, πρέπει να δοθεί προσοχή στις παρακάτω παραμέτρους:

- *learning\_rate*: Ελέγχει πόσο γρήγορα το δέντρο προσαρμόζεται σε ένα συγκεκριμένο πρόβλημα.
- *max\_depth*: Χρησιμοποιείται για να περιοριστεί ρητά το βάθος του δέντρου.
- *num\_leaves*: Αποτελεί την κύρια παράμετρο ελέγχου της πολυπλοκότητας του δέντρου. Θεωρητικά, ορίζοντας  $num\_leaves = 2^{max\_depth}$  μπορούμε να λάβουμε τον ίδιο αριθμό φύλλων με το δέντρο κατά βάθος. Ωστόσο, αυτή η απλή επιλογή δεν είναι καλή στην πράξη. Ο λόγος είναι ότι ένα δέντρο με βάση τα φύλλα είναι συνήθως πολύ

πιο βαθύ από ένα δέντρο το οποίο αναπτύσσεται κατά βάθος. Το απεριόριστο βάθος μπορεί να προκαλέσει υπερπροσαρμογή. Έτσι, όταν προσπαθούμε να βελτιστοποιήσουμε το *num\_leaves*, θα πρέπει να το αφήσουμε να είναι μικρότερο από  $2^{max\_depth}$

- *min\_data\_in\_leaf*: Αποτελεί μία πολύ σημαντική παράμετρο για την αποφυγή της υπερπροσαρμογής σε ένα δέντρο το οποίο αναπτύσσεται με βάση τα φύλλα. Η βέλτιστη τιμή του εξαρτάται από τον αριθμό των δειγμάτων εκπαίδευσης και την τιμή της παραμέτρου *num\_leaves*. Η ρύθμισή της σε μεγάλη τιμή μπορεί να αποφύγει την πολύ βαθιά ανάπτυξη ενός δέντρου, αλλά μπορεί να προκαλέσει υποπροσαρμογή (underfitting).

Το LightGBM διαθέτει αρκετά πλεονεκτήματα σε σύγκριση με άλλους αλγόριθμους μηχανικής μάθησης, τα πιο σημαντικά από τα οποία είναι ότι επιτρέπει τον αποτελεσματικό χειρισμό πολλαπλών χαρακτηριστικών διαφορετικών τύπων χωρίς να απαιτείται η προεπεξεργασία των εν λόγω δεδομένων, χρειάζεται τη βελτιστοποίηση ενός σχετικά μικρού αριθμού παραμέτρων, όπως αναλύθηκαν παραπάνω, ενώ ταυτόχρονα είναι αρκετά γρήγορο στον υπολογισμό σε σύγκριση με άλλες μεθόδους ενίσχυσης κλίσης. Αποτελεί, έτσι, μία βολική προσέγγιση, κατάλληλη για πειραματισμούς και ανάπτυξη λύσεων που μπορούν να γενικευθούν με ακρίβεια σε μεγάλο αριθμό σειρών με διασταυρούμενες συσχετίσεις. Το LightGBM, επίσης, μπορεί να θεωρηθεί η πιο χρησιμοποιούμενη μέθοδος σε διαγωνισμούς προβλέψεων της πλατφόρμας Kaggle, μιας και οι νικητές των διαγωνισμών “Corporación Favorita Grocery Sales Forecasting” και “Recruit Restaurant Visitor Forecasting” έχτισαν τις προσεγγίσεις τους χρησιμοποιώντας αυτήν τη μέθοδο, ενώ και στον διαγωνισμό M5 χρησιμοποιήθηκε κατά κόρον (Bojer & Meldgaard, 2021).

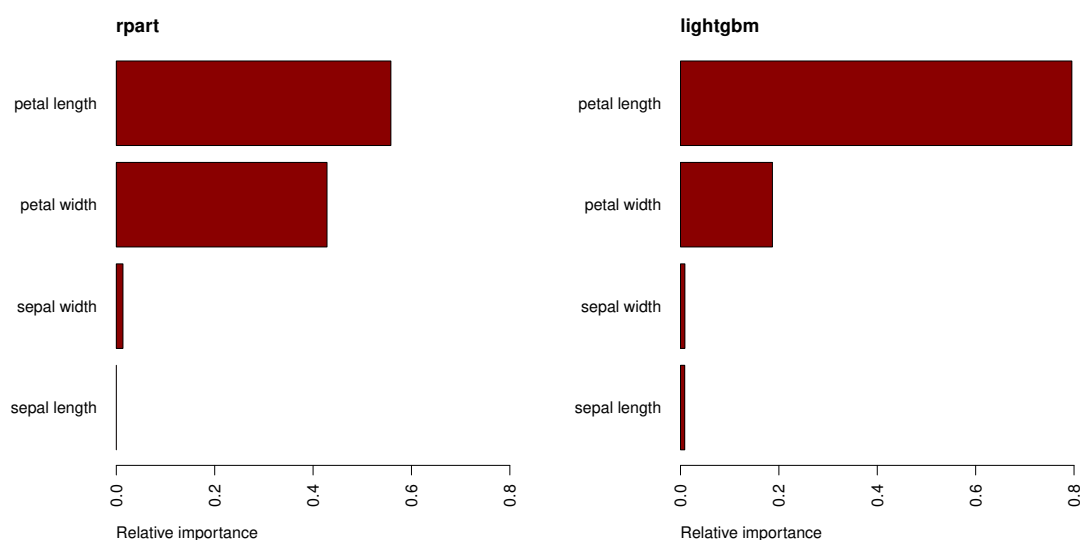
### 6.3 Σημαντικότητα ανεξάρτητων μεταβλητών (Feature importance)

Κατά την ανάπτυξη μοντέλων μηχανικής μάθησης, σημαντικό στάδιο αποτελεί η επιλογή και η αξιολόγηση των ανεξάρτητων μεταβλητών (features) που είναι διαθέσιμες προς χρήση από τα εν λόγω μοντέλα. Η σημαντικότητα της κάθε ανεξάρτητης μεταβλητής μπορεί να υπολογιστεί μέσω συγκεκριμένων διαδικασιών οι οποίες ονομάζονται feature importance κατά τις οποίες υπολογίζεται ένα σκορ για κάθε feature του μοντέλου. Η κεντρική προϋπόθεση κατά τη χρήση μιας τέτοιας τεχνικής είναι ότι τα δεδομένα μπορεί να εμπεριέχουν ορισμένα features τα οποία είναι περιττά ή άσχετα, και επομένως μπορούν να αφαιρεθούν χωρίς ιδιαίτερη απώλεια πληροφορίας.

Υπάρχουν, έτσι, διαφορετικοί τρόποι υπολογισμού της σημαντικότητας αυτής των ανεξάρτητων μεταβλητών, οι οποίοι διαφέρουν ανάλογα με τον αλγόριθμο που χρησιμοποιείται κάθε φορά. Ωστόσο, ένα γενικό μέτρο της σημαντικότητας μιας μεταβλητής αποτελεί το άθροισμα της βελτίωσης στο συνολικό δείκτη Gini (ή RMSE) που παράγεται από τους κόμβους στους οποίους εμφανίζεται.

Στο Σχήμα 6.10 απεικονίζεται η σημαντικότητα των ανεξάρτητων μεταβλητών του δέντρου

αποφάσεων που κατασκευάστηκε στο Υποκεφάλαιο 6.2.3 και του μοντέλου LightGBM που κατασκευάστηκε στο Υποκεφάλαιο 6.2.3.3.



Σχήμα 6.10: Σημαντικότητα των ανεξάρτητων μεταβλητών που χρησιμοποιήθηκαν στο δέντρο αποφάσεων του Υποκεφαλαίου 6.2.3 (αριστερά) και στο μοντέλο LightGBM του Υποκεφαλαίου 6.2.3.3 (δεξιά).

Είναι εμφανές ότι και οι δυο προσεγγίσεις θεωρούν ως το πιο σημαντικό feature το `petal.length`, και ακολουθεί το `petal.width`, με τα `sepal.width` και `sepal.length` να εμφανίζονται ως περιττά. Ωστόσο, το LightGBM μοντέλο θεωρεί τη συνεισφορά του `petal.length` πολύ μεγαλύτερη από ότι το απλό δέντρο.

Κάνοντας χρήση των πακέτων της γλώσσας R που ήδη χρησιμοποιήθηκαν, παρακάτω φαίνεται πως υπολογίζεται το feature importance του δέντρου αποφάσεων και του μοντέλου LightGBM, που απεικονίζονται στο Σχήμα 6.10.

```
# Load necessary libraries
library('rpart')
library('lightgbm')

# Feature importance of 'tree' decision tree created previously
tree$variable.importance

# Feature importance of 'lgb.model' LightGBM model created previously
lgb.importance(lgb.model, percentage = TRUE)
```

Τα πιο συχνά χρησιμοποιούμενα μέτρα της σημαντικότητας μιας μεταβλητής είναι το κέρδος (gain), η κάλυψη (coverage) και η συχνότητα (frequency). Το gain υποδηλώνει τη σχετική συνεισφορά της αντίστοιχης μεταβλητής στο μοντέλο, με την έννοια της βελτίωσης της ακρίβειας, και υπολογίζεται λαμβάνοντας υπόψη τη μείωση του σφάλματος που επιφέρει κάθε μεταβλητή σε αυτό. Μια υψηλότερη τιμή αυτού του μέτρου σε σύγκριση με άλλη μεταβλητή υποδηλώνει ότι η πρώτη είναι πιο σημαντική για τη παραγωγή μιας πρότασης. Το coverage απεικονίζει τον σχετικό αριθμό παρατηρήσεων που σχετίζονται με τη συγκεκριμένη μεταβλητή, ενώ το frequency αποτελεί το ποσοστό που αντιπροσωπεύει τον

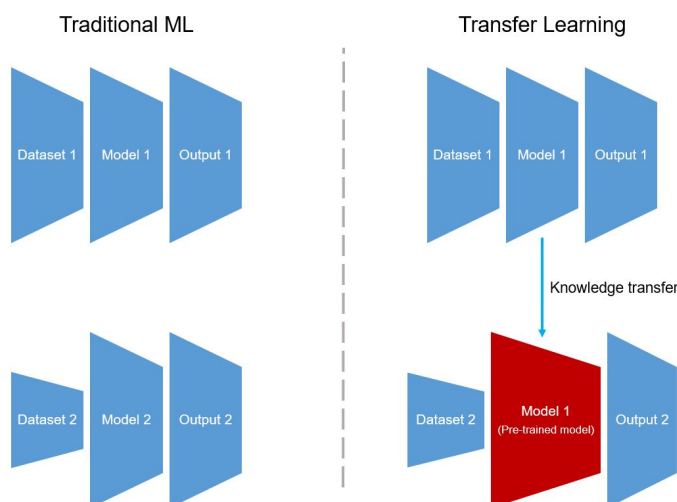
σχετικό αριθμό φορών που εμφανίζεται η συγκεκριμένη μεταβλητή στα δέντρα του μοντέλου. Σε κάθε περίπτωση, το gain απεικονίζει τη βελτίωση της ακρίβειας που φέρνει η μεταβλητή στο μοντέλο με αποτέλεσμα να προτιμάται πιο συχνά από τα άλλα μέτρα.

## 6.4 Μεταφορά μάθησης (Transfer learning)

Από τα σημαντικότερα προβλήματα της μηχανικής μάθησης αποτελεί η ανάγκη ύπαρξης ενός μεγάλου και αντιπροσωπευτικού συνόλου δεδομένων, με το οποίο το μοντέλο θα εκπαιδευτεί. Ένας από τους τρόπους αντιμετώπισης του προβλήματος αυτού είναι με χρήση μεταφοράς μάθησης (transfer learning), κατά την οποία ένα μοντέλο εκπαιδεύεται με δεδομένα ενός συγκεκριμένου περιβάλλοντος προέλευσης με σκοπό να εφαρμοστεί σε ένα άλλο περιβάλλον στόχο. Το περιβάλλον προέλευσης ονομάζεται source domain, ενώ το περιβάλλον στόχος target domain.

Το μοντέλο εκπαιδεύεται στο περιβάλλον προέλευσης με τρόπο τέτοιο ώστε να επιτελεί ορθά την εργασία προέλευσης (source task) και καλείται έπειτα να επιτελέσει ορθά μια εργασία στόχο (target task). Αντί, λοιπόν, το μοντέλο να εκπαιδεύεται εκ του μηδενός για να επιτελέσει την εργασία στόχο, εκπαιδεύεται αρχικά με βάση την εργασία προέλευσης και η γνώση αυτή μεταφέρεται, και αρκετές φορές εμπλουτίζεται από το περιβάλλον στόχο, προκειμένου το μοντέλο να επιτελέσει την εργασία στόχο.

Στο Σχήμα 6.11 φαίνεται η διαφορά μεταξύ των διαδικασιών που ακολουθούνται κατά την παραδοσιακή μηχανική μάθηση και των τεχνικών μεταφοράς μάθησης. Φαίνεται ξεκάθαρα πως οι παραδοσιακές τεχνικές προσπαθούν να μάθουν κάθε εργασία από την αρχή, ενώ οι τεχνικές μεταφοράς μάθησης προσπαθούν να μεταφέρουν τη γνώση από ορισμένες προηγούμενες εργασίες σε μια εργασία στόχο, όταν η τελευταία έχει λιγότερα αξιοποιήσιμα δεδομένα εκπαίδευσης.



Σχήμα 6.11: Διαφορές της διαδικασίας μάθησης που ακολουθείται στην παραδοσιακή μηχανική μάθηση (αριστερά) και με χρήση μεταφοράς μάθησης (δεξιά).

Η μεταφορά μάθησης, έτσι, συνιστά ένα είδος μάθησης με πολλαπλά οφέλη σε σχέση με

την παραδοσιακή μηχανική μάθηση για τους εξής λόγους:

- η αρχική επίδοση του μοντέλου προέλευσης στην εργασία στόχο πριν συμβεί οποιαδήποτε επανεκπαίδευση είναι υψηλότερη από την επίδοση ενός τυχαία αρχικοποιημένου μοντέλου για την ίδια εργασία,
- το εν λόγω μοντέλο συγκλίνει γρηγορότερα, άρα απαιτείται λιγότερος χρόνος μέχρι να ολοκληρωθεί η επανεκπαίδευσή του, και
- το μοντέλο συγκλίνει σε υψηλότερα επίπεδα επίδοσης.

Η συγκεκριμένη τεχνική έχει πρόσφατα αποδειχθεί πολύ αποτελεσματική, σύμφωνα με τη βιβλιογραφία, για τη βελτίωση της επίδοσης τεχνικών πρόβλεψης (Gautam, 2022; Ye & Dai, 2022), συμπεριλαμβανομένων και εφαρμογών που αφορούν σε χρονοσειρές διακοπόμενης ζήτησης, μεταξύ άλλων (Wellens et al., 2021), ειδικά όταν τα πρότυπα ζήτησης του συνόλου δεδομένων αναφοράς είναι όμοια με εκείνα του συνόλου στόχου (Ye & Dai, 2021), καθώς επίσης και για τη βελτίωση της απόδοσης μοντέλων βαθιάς ενισχυτικής μάθησης (Deep reinforcement learning) που χρησιμοποιούν στοιχεία από υπάρχοντες ευριστικές μεθόδους βελτιστοποίησης πολιτικών διαχείρισης αποθεμάτων (De Moor et al., 2022).

Εκτός από τη βελτίωση της απόδοσης, η μεταφορά μάθησης μπορεί, επίσης, να μειώσει σημαντικά το υπολογιστικό κόστος και τις απαιτήσεις δεδομένων, καθώς τα μοντέλα που χρησιμοποιούνται είναι προ-εκπαιδευμένα και έτοιμα για χρήση σε οποιοδήποτε σύνολο ενδιαφέροντος με σημαντικά μικρό υπολογιστικό κόστος, επιτρέποντας την εφαρμογή τους ακόμη και σε περιπτώσεις όπου τα ιστορικά δεδομένα του συνόλου στόχου είναι αρκετά περιορισμένα.

Η μεταφοράς μάθησης, όπως αναφέρθηκε, αφορά στην προεκπαίδευση ενός μοντέλου, με χρήση ενός τμήματος ή ολόκληρου του συνόλου δεδομένων που έρχεται από το περιβάλλον προέλευσης, προκειμένου να εκτελέσει την εργασία στόχου, με το μοντέλο αυτό να επανεκπαιδεύεται ή όχι με τμήμα του συνόλου δεδομένων στόχου. Οι διάφορες τεχνικές που συναντώνται στη βιβλιογραφία διαφοροποιούνται ως προς τον τρόπο επανεκπαίδευσης του εν λόγω μοντέλου, προκειμένου να βελτιωθεί η προβλεπτική του ακρίβεια. Είναι εμφανές ότι μεταφορά μάθησης υφίσταται είτε το μοντέλο επανεκπαιδευτεί με τα δεδομένα του περιβάλλοντος στόχου είτε όχι. Περισσότερες τεχνικές εμφανίζονται στη χρήση νευρωνικών δικτύων, όπου συναντώνται οι όροι ευνοϊκό ξεκίνημα (warm start), φραγμένες εποχές (bounded epochs) και πάγωμα επιπέδων (layers freezing) μεταξύ άλλων.

Στα δέντρα αποφάσεων, από την άλλη, οι τεχνικές μεταφοράς μάθησης, είναι πιο απλές και αρκετά πιο περιορισμένες. Η πιο διαδεδομένη είναι η τεχνική της επανεκπαίδευσης (re-train), ή ίσως πιο σωστά η τεχνική της επέκτασης της εκπαίδευσης, κατά την οποία το μοντέλο που έχει προκύψει από τα δεδομένα προέλευσης συνεχίζει την εκπαίδευσή του με τα δεδομένα του περιβάλλοντος στόχου, χωρίς να επιβάλλεται να παραμείνει σταθερή η δομή των δένδρων που έχουν δημιουργηθεί. Ωστόσο, βάσει της πεποίθησης ότι τα δέντρα αποφάσεων για όμοια προβλήματα και σύνολα δεδομένων θα πρέπει να παρουσιάζουν όμοια δομή, στη βιβλιογραφία εντοπίζονται τεχνικές οι οποίες διατηρούν αναλλοίωτη τη δομή των κατασκευασμένων δέντρων (structure transfer) και χρησιμοποιούν

τα δεδομένα στόχο για να προσαρμόσουν ελάχιστα (fine-tune) τα διάφορα βάρη του μοντέλου (Segev et al., 2016). Πιο σύνθετες προσεγγίσεις περιλαμβάνουν τεχνικές επέκτασης/μείωσης της δομής (structure expansion/reduction), στις οποίες δύο τοπικοί μετασχηματισμοί μιας δομής δέντρων συνδυάζονται κατάλληλα, στο μετασχηματισμό επέκτασης οι κανόνες που δημιουργήθηκαν από τα δεδομένα προέλευσης εξειδικεύονται, ενώ στο μετασχηματισμό μείωσης οι κανόνες γενικεύονται. Με τον τρόπο αυτό οι συγκεκριμένοι μετασχηματισμοί μπορούν να εσιτιάσουν καλύτερα στα δεδομένα στόχου διατηρώντας υψηλό βαθμό συσχέτισης τόσο μεταξύ τους όσο και με το αρχικό μοντέλο λόγω των αμετάβλητων τμημάτων τους.

Αν και τα οφέλη του transfer learning, όπως αναφέρθηκε, είναι πολλαπλά, δεν είναι απίθανη η αρνητική μεταφορά (negative transfer), δηλαδή η αρνητική επιρροή της μεταφοράς μάθησης στις επιδόσεις του μοντέλου. Κάτι τέτοιο θα μπορούσε να οφείλεται σε μια κακή συσχέτιση μεταξύ των περιβάλλοντων, αλλά και των συνόλων, εκπαίδευσης και στόχου.

## 6.5 Μηχανική μάθηση και συστήματα διαχείρισης αποθεμάτων

Η θεωρία της διαχείρισης αποθεμάτων αποτελεί έναν από τους τομείς του εμπορίου που έχουν ερευνηθεί διεξοδικά. Παρά το γεγονός, όμως, ότι σχεδόν όλες οι εταιρείες παραγωγής και εμπορίας, και ιδιαίτερα οι μεγάλες επιχειρήσεις, προσπαθούν να εφαρμόσουν επιστημονικές μεθόδους, υιοθετώντας τις νέες τεχνολογίες, για την καλύτερη διαχείριση του αποθέματός τους, η χρήση τέτοιων μεθόδων συχνά περιορίζεται σε μερικά μόνο βασικά εργαλεία (Nenes et al., 2010).

Τα τελευταία λίγα χρόνια η εισαγωγή της μηχανικής μάθησης στη διαχείριση αποθεμάτων αυξάνεται, με τις πρόσφατες τεχνολογικές εξελίξεις να υποστηρίζουν ότι διάφορες εφαρμογές αλγορίθμων μηχανικής μάθησης μπορούν να βοηθήσουν καταλυτικά στην αποτελεσματικότητα, την παραγωγικότητα και συνολικότερα την κερδοφορία και ευημερία των επιχειρήσεων. Πιο συγκεκριμένα, η μηχανική μάθηση μπορεί να συμβάλλει, πιθανώς μεταξύ άλλων, στη διαχείριση και βελτίωση των λειτουργιών μιας αποθήκης στους εξής τομείς:

- Αυτοματοποίηση παρακολούθησης αποθεμάτων (inventory monitoring)
- Εξόρυξη δεδομένων (data mining)
- Έλεγχος και αυτοματισμός ρομπότ (robot automation)
- Μείωση σφαλμάτων στην πρόβλεψη της ζήτησης (demand forecasting)
- Βελτίωση της εμπειρίας πελατών (customer experience)

Δεν αποτελεί έκπληξη, έτσι, το γεγονός ότι κολοσσοί, όπως η Amazon και η Coca Cola έχουν ξεκινήσει ήδη να υιοθετούν τις συγκεκριμένες τεχνολογίες σε μερικούς κλάδους των δραστηριοτήτων τους. Χαρακτηριστικό παράδειγμα αποτελούν τα καταστήματα “Amazon Go”, στα οποία εφαρμόζεται ένας συνδυασμός μηχανικής μάθησης, καμερών και αναγνώρισης εικόνας (image recognition), επιτρέποντας στους αγοραστές να



πραγματοποιούν τις αγορές τους χωρίς να περνούν από κάποιο ταμείο. Η Coca Cola, με τη σειρά της, έχει εισάγει τη χρήση παρόμοιας τεχνολογίας ανάλυσης εικόνας για τις ανάγκες ελέγχου των αποθεμάτων της, σχεδόν εξαλείφοντας τα κόστη που συνεπάγεται ο έλεγχος αυτός, όπως παρουσιάστηκε στο Υποκεφάλαιο 2.5.


Προσπάθειες χρήσης της μηχανικής μάθησης στον συγκεκριμένο κλάδο παρατηρούνται και στη βιβλιογραφία. Προσπαθώντας να εφαρμόσει αλγορίθμους μηχανικής μάθησης συγκεκριμένα στη βελτιστοποίηση μιας πολιτικής διαχείρισης αποθεμάτων περιοδικής εξέτασης, η Sustrova (2016) εξέτασε τις δυνατότητες εφαρμογής νευρωνικών δικτύων στο σύστημα παραγγελιών μιας εταιρείας, αναπτύσσοντας εννέα μοντέλα με διαφορετικές αρχιτεκτονικές, στοχεύοντας τη βελτιστοποίηση του μεγέθους της παραγγελίας, χρησιμοποιώντας ως εισόδους την τρέχουσα ζήτηση, τη προβλεπόμενη ζήτηση των επόμενων και των μεθεπόμενων τριών μηνών, το τρέχον επίπεδο αποθέματος, το κόστος αγοράς και το κόστος μεταφοράς κάθε προϊόντος. Η μελέτη, ωστόσο αφορούσε σε ένα αρκετά μικρό σύνολο μηνιαίων δεδομένων, 29 μόνο εγγραφών εισόδων-εξόδων, και αγνοούσε παραμέτρους όπως ο χρόνος παράδοσης, η αβεβαιότητα και το επίπεδο εξυπηρέτησης πελατών στόχου.

Οι Inprasit & Tanachutiwat (2018) επικεντρώθηκαν στην κατασκευή, την εκπαίδευση και τη δοκιμή ενός νευρωνικού δικτύου για τον υπολογισμό του αποθέματος ασφαλείας και του σημείου αναπαραγγελίας κάθε προϊόντος, ενός συνόλου δεδομένων 4.580 εγγραφών, χρησιμοποιώντας ως εισόδους το χρόνο παράδοσης και τη διακύμανσή του, τη ζήτηση και τη διακύμανσή της και το επίπεδο εξυπηρέτησης πελατών στόχο, παρουσιάζοντας ενθαρρυντικά αποτελέσματα.

Ο Müller (2020), βασιζόμενος στην εργασία του Ban (2020), ο οποίος ανέπτυξε μία προσέγγιση επίλυσης του σταθερού προβλήματος του εφημεριδοπώλη η οποία βασίζεται σε δεδομένα, και προσαρμόζοντας την ιδέα των Bertsimas & Kallus (2020), οι οποίοι πρότειναν την ενσωμάτωση των δύο βημάτων, διαδοχική εκτίμηση και βελτιστοποίηση, σε ένα ενιαίο μοντέλο, χρησιμοποίησε μοντέλα μηχανικής μάθησης και χαρακτηριστικά δεδομένων, σε ένα πρόβλημα αποθεματοποίησης πολλαπλών περιόδων, προκειμένου να κατασκευάσει συναρτήσεις βάρους για τα ιστορικά δεδομένα ζήτησης. Με άλλα λόγια, μοντέλα μηχανικής μάθησης χρησιμοποιήθηκαν για το ζύγισμα των ιστορικών δειγμάτων ζήτησης, ένα βήμα το οποίο είναι απαραίτητο και ταυτόχρονα αρκετά χρονοβόρο κατά τη διαδικασία βελτιστοποίησης των παραμέτρων  $s$  και  $S$  της πολιτικής  $(s, S)$ , ακολουθώντας την πρόταση του Ban (2020) στην επίλυση των εξισώσεων ελαχιστοποίησης στις οποίες κατέληξε ο Scarf (1959).

Σε μία πρόσφατη, και διαφορετική εφαρμογή, οι Namir et al. (2022) πρότειναν ένα μοντέλο το οποίο συνδυάζει στατιστικές μεθόδους πρόβλεψης χρονοσειρών, αλγορίθμους μηχανικής μάθησης και συνδυαστική βελτιστοποίηση (combinatorial optimization), προκειμένου να εντοπίσουν τις ευκαιρίες αγοράς αποθεμάτων με χαμηλότερο κόστος και πώλησης ή διατήρησης ενός τμήματος του αποθέματος για τη δημιουργία πρόσθετων κερδών για την επιχείρηση. Προβλέποντας, έτσι, τη ζήτηση ενός προϊόντος, κάθε φορά, και την αξία αυτού, δηλαδή το κόστος αγοράς αποθέματος από τους προμηθευτές, το εν λόγω μοντέλο δύναται να βοηθήσει στη λήψη αποφάσεων σχετικές με την αγορά, πώληση ή διατήρηση αποθέματος με στόχο τη μεγιστοποίηση του κέρδους.

Μία εναλλακτική χρήση της μηχανικής μάθησης στο πλαίσιο της διαχείρισης αποθεμάτων είναι μέσω της κατασκευής μεταμοντέλων. Όπως αναφέρθηκε στο Υποκεφάλαιο 5.5 μέσω προσομοιώσεων είναι δυνατή η βελτιστοποίηση της διαδικασίας αποθεματοποίησης, με κύρια προβλήματα το υψηλό υπολογιστικό κόστος που συνεπάγεται η επαναλαμβανόμενη φύση τους και οι δυσκολίες στην ερμηνεία των αποτελεσμάτων. Στη βιβλιογραφία, προκειμένου να ξεπεραστούν τα προβλήματα αυτά, συναντάται η έννοια του μεταμοντέλου προσομοίωσης (simulation metamodel), το οποίο στην ουσία μοντελοποιεί το μοντέλο προσομοίωσης και είναι σε θέση να απλοποιήσει τη βελτιστοποίηση της προσομοίωσης με την ντετερμινιστική του φύση και τον σημαντικά μικρότερο χρόνο εκτέλεσης σε σχέση με τις αρχικές προσομοιώσεις (Barton, 1998). Πιο συγκεκριμένα, ένα μεταμοντέλο είναι ένα μοντέλο, όπως για παράδειγμα ένα στατιστικό μοντέλο ή ένα μοντέλο μηχανικής μάθησης, το οποίο συνδέει τις εισόδους των διαφορετικών επαναλήψεων ενός μοντέλου προσομοίωσης με τα αποτελέσματα αυτών, αποτελώντας έτσι μια προσέγγιση της προσομοίωσης. Επιπρόσθετα, σύμφωνα με τη βιβλιογραφία, στις περισσότερες περιπτώσεις, τα μεταμοντέλα που κάνουν χρήση μηχανικής μάθησης υπερτερούν των εναλλακτικών (Fonseca et al., 2003; Hachicha, 2011). Με τον τρόπο αυτό, η χρήση της τεχνικής των μεταμοντέλων προσομοίωσης σε συνδυασμό με αλγορίθμους μηχανική μάθηση θα μπορούσαν να συνεισφέρουν σημαντικά στη θεωρία αποθεμάτων και πιο συγκεκριμένα στη βελτιστοποίηση των συστημάτων διαχείρισης αποθεμάτων.



Σχήμα 6.12: Απεικόνιση μοντελοποίησης ενός μεταμοντέλου προσομοίωσης.

Η κατασκευή ενός μεταμοντέλου περιλαμβάνει τα ακόλουθα βήματα, τα οποία συνοψίζονται και στο Σχήμα 6.12:

1. δημιουργία τιμών εισόδου,
2. εκτέλεση προσομοιώσεων για τη δημιουργία δεδομένων εξόδου,
3. χρήση των δεδομένων εισόδου και εξόδου των προσομοιώσεων για να εκπαιδευτεί ένα νέο μοντέλο.

Όπως είναι εμφανές, τα δύο πρώτα βήματα αφορούν στο σχεδιασμό και την εκτέλεση ενός πειράματος, ενώ το τρίτο βήμα ασχολείται με τη δημιουργία ενός αξιόπιστου συσχετισμού μεταξύ των τιμών εισόδου και εξόδου που προέκυψαν από το εν λόγω πείραμα. Προφανώς, η στρατηγική που ακολουθείται κατά τον σχεδιασμό των πειραμάτων έχει άμεσο αντίκτυπο στην ποιότητα και την ακρίβεια του μεταμοντέλου που προκύπτει (Fang et al., 2005), με

τα μεγαλύτερα προβλήματα, πέρα από την πραγματοποίηση διαφόρων παραδοχών κατά την εκτέλεση της προσομοίωσης, προέρχονται από την μη ενδεικτική επιλογή των τιμών εισόδου, οι οποίες μπορεί να επιλεχθούν λανθασμένα από μόνο ένα μικρό δείγμα των τιμών που συναντώνται στην πραγματικότητα ή να δίνουν μεγάλη έμφαση σε ένα συγκεκριμένο εύρος.

Εξ όσων γνωρίζουμε, στη βιβλιογραφία δεν συναντάται η χρήση μεταμοντέλων μηχανικής μάθησης, τα οποία χρησιμοποιούν χαρακτηριστικά χρονοσειρών, για την προσομοίωση της διαδικασίας αποθεματοποίησης πολλών περιόδων, για ένα προκαθορισμένο χρονικό διάστημα, με σκοπό τη βελτιστοποίηση των παραμέτρων της πολιτικής που χρησιμοποιείται. Με την παρούσα διδακτορική διατριβή, έτσι, γίνεται μία προσπάθεια να εξερευνηθεί το συγκεκριμένο κενό.

## **6.6 Μηχανική μάθηση και προβλέψεις χρονοσειρών διακοπτόμενης ζήτησης**

Για την παραγωγή προβλέψεων χρονοσειρών, πέρα από τα κλασικά στατιστικά μοντέλα, ορισμένα από τα οποία παρουσιάστηκαν στο Κεφάλαιο 4, στη βιβλιογραφία συναντάται και η χρήση αλγορίθμων μηχανικής μάθησης. Ωστόσο, παρά το γεγονός ότι οι συγκεκριμένοι αλγόριθμοι έχουν προσελκύσει το ενδιαφέρον σε διάφορους κλάδους, όπως αναφέρθηκε παραπάνω, με αξιόλογα αποτελέσματα σε πολλούς από αυτούς, στον κλάδο των προβλέψεων χρονοσειρών η εμφάνιση αυτών των αλγορίθμων παραμένει περιορισμένη. Στην κατηγορία των χρονοσειρών διακοπτόμενης ζήτησης, πιο συγκεκριμένα, οι οποίες χαρακτηρίζονται από έντονη σποραδικότητα και αστάθεια, η μηχανική μάθηση έχει κάνει την εμφάνισή της αρκετά πρόσφατα και έχει καταστεί αντικείμενο έντονης αντιπαράθεσης, καθώς εμφανίζονται ανάμεικτα συμπεράσματα ως προς την απόδοση των παραγόμενων προβλέψεων (Crone et al., 2011). Το σημαντικότερο, ίσως, πλεονέκτημα των συγκεκριμένων αλγορίθμων έγκειται στο γεγονός ότι επιτρέπουν μία εντελώς μη γραμμική εκτίμηση των προβλέψεων χωρίς να κάνουν κάποια υπόθεση για την κατανομή των τιμών, με αποτέλεσμα να μην περιορίζουν τα πραγματικά δεδομένα. Ωστόσο, η συγκεκριμένη στρατηγική απαιτεί μεγάλο όγκο δεδομένων, καθιστώντας τη ακόμα και ακατάλληλη σε περιπτώσεις χρονοσειρών με λίγες παρατηρήσεις, σύνθετα μοτίβα, και αρκετές μηδενικές τιμές (Kourentzes, 2013).

Από τις πρώτες μελέτες που εμφανίζονται στη βιβλιογραφία είναι αυτή των Carmo & Rodrigues (2004), οι οποίοι σύγκριναν την απόδοση νευρωνικών δικτύων με στατιστικές μεθόδους χρησιμοποιώντας ένα σύνολο δέκα χρονοσειρών, παρουσιάζοντας ενθαρρυντικά αποτελέσματα. Με τη σειρά τους, οι Gutierrez et al. (2008) και Mukhopadhyay et al. (2012) πρότειναν ένα απλουστευμένο μοντέλο Multi-Layer Perceptron (MLP), το οποίο χρησιμοποιεί τη ζήτηση της αμέσως προηγούμενης περιόδου και τον αριθμό των περιόδων που χωρίζουν τις δύο τελευταίες μη μηδενικές παρατηρήσεις ως εισόδους. Ο Kourentzes (2013) σχολίασε τους περιορισμούς της συγκεκριμένης προσέγγισης και πρότεινε μια ενδιαφέρουσα εναλλακτική, η οποία βασίζεται στην στρατηγική αποσύνθεσης της μεθόδου Croston, αλλά προβλέπει το μέγεθος της ζήτησης και τα διαστήματα μεταξύ της ζήτησης ταυτόχρονα, επιτρέποντας έτσι μεγαλύτερη ευελιξία. Η προσέγγιση αυτή παρουσίασε

μέτρια απόδοση όσον αφορά στην ακρίβεια και την προκατάληψη των παραγόμενων προβλέψεων, αλλά οδήγησε σε υψηλότερα επίπεδα εξυπηρέτησης πελατών από την κλασική μέθοδο Croston και κάποιες παραλλαγές της. Οι Nasiri Pour et al. (2008) εισήγαγαν δύο άλλες εναλλακτικές για την εφαρμογή νευρωνικών δικτύων στην πρόβλεψη της ζήτησης. Η πρώτη προσέγγιση ακολουθεί τις προτάσεις των Gutierrez et al. (2008), αλλά επεκτείνει τα χαρακτηριστικά που χρησιμοποιούνται ως είσοδοι προκειμένου να μεγιστοποιήσει τις πληροφορίες που εξετάζονται, ενώ η δεύτερη συνδυάζει ένα νευρωνικό δίκτυο που προβλέπει τις εμφανίσεις μη μηδενικών παρατηρήσεων με μια αναδρομική μέθοδο που εκτιμά το μέγεθος των παρατηρήσεων αυτών. Πιο πρόσφατα, οι Lolli et al. (2017) εξέτασαν την απόδοση της τεχνικής back propagation, αποδεικνύοντας ότι βελτιώνει την ακρίβεια των προβλέψεων, αν και αυξάνει το υπολογιστικό κόστος, οι Boutselis & McNaught (2019) απέδειξαν την υπεροχή των νευρωνικών δικτύων έναντι των προβλέψεων λογιστικής παλινδρόμησης προσαρμοσμένων από ειδικούς, χρησιμοποιώντας ένα σύνολο δεδομένων ανταλλακτικών, ενώ οι Nikolopoulos et al. (2016) πρότειναν την εφαρμογή προσεγγίσεων πλησιέστερου γείτονα (nearest neighbors) σε δεδομένα εφοδιαστικής αλυσίδας, διερευνώντας τις συνθήκες κάτω από τις οποίες αυτές λειτουργούν επαρκώς.

Δύο σημαντικές παρατηρήσεις που μπορούν να εξαχθούν από τη βιβλιογραφία είναι αφενός ότι αρκετές μελέτες εστιάζουν στη χρήση νευρωνικών δικτύων, πολλές φορές αγνοώντας τα ενδεχόμενα πλεονεκτήματα της χρήσης διαφορετικών αλγορίθμων, όπως Regression Trees (RTs) ή Support Vector Regression (SVR), και αφετέρου ότι τα προτεινόμενα μοντέλα εκπαιδεύονται, συνήθως, ανεξάρτητα για κάθε χρονοσειρά, αγνοώντας την βελτίωση στην απόδοση που συνεπάγεται η χρήση πλήθους σειρών κατά την εκπαίδευση (Smyl, 2020; Bojer & Meldgaard, 2021), τεχνική η οποία ονομάζεται cross-learning.

Οι Spiliotis et al. (2022) εντόπισαν τις παραπάνω παρατηρήσεις και εξέτασαν την απόδοση διαφόρων μεθόδων μηχανικής μάθησης, οι οποίες χρησιμοποίησαν είτε κάθε χρονοσειρά ανεξάρτητα είτε όλες τις διαθέσιμες σειρές κατά την εκπαίδευσή τους, και τις σύγκριναν με εκείνη διαφόρων στατιστικών μεθόδων, χρησιμοποιώντας ένα πλούσιο σύνολο δεδομένων ημερήσιων σειρών ζήτησης. Σύμφωνα με τα αποτελέσματα της εν λόγω μελέτης, οι μέθοδοι μηχανικής μάθησης μπορούν να παρέχουν προβλέψεις με σημαντικά λιγότερη προκατάληψη και μεγαλύτερη ακρίβεια από τις στατιστικές, ενώ η τεχνική cross-learning μπορεί να βελτιώσει αρκετά την απόδοση πρόβλεψης των νευρωνικών δικτύων, ιδιαίτερα όταν επιπρόσθετα με τις παρατηρήσεις των σειρών χρησιμοποιούνται διάφορα χαρακτηριστικά τους, αλλά και να οδηγήσει σε μειωμένο υπολογιστικό κόστος. Ωστόσο, η συγκεκριμένη τεχνική είχε αρνητικό αντίκτυπο στις υπόλοιπες μεθόδους μηχανικής μάθησης που εξετάστηκαν, υποδεικνύοντας ότι πρέπει να χρησιμοποιούνται διαφορετικές προσεγγίσεις μοντελοποίησης με βάση τις ιδιαιτερότητες της μεθόδου πρόβλεψης που ακολουθείται κάθε φορά. Σύμφωνα με τους ερευνητές, προκειμένου να γενικευτούν τα παραπάνω συμπεράσματα, θα πρέπει να εξεταστούν και άλλα, πιο διευρυμένα, σύνολα δεδομένων τα οποία εμπεριέχουν χρονοσειρές με εποχιακότητα, έντονη σποραδικότητα αλλά και με μεγαλύτερο μήκος, ενώ θα πρέπει να εξεταστούν επίσης επιπλέον χαρακτηριστικά χρονοσειρών κατά την εφαρμογή της τεχνικής cross-learning, όπως η αυτοσυσχέτιση των σειρών και η κανονικότητα μεταξύ άλλων.

Τέλος, εκτός από την χρήση των αλγορίθμων μηχανικής μάθησης για την παραγωγή προβλέψεων χρησιμοποιώντας μόνο τις διαθέσιμες παρατηρήσεις των χρονοσειρών ή τα χαρακτηριστικά αυτών, η μηχανική μάθηση εμφανίζεται και ως μια εναλλακτική προσέγγιση για τον συνυπολογισμό επιπρόσθετων πληροφοριών κατά τη συγκεκριμένη διαδικασία, με πιο συχνά χρησιμοποιούμενες τις πληροφορίες που αφορούν σε δεδομένα προωθητικών ενεργειών (Ali et al., 2009; Abolghasemi et al., 2020).

“Ουσιαστικά, όλα τα μοντέλα είναι λανθασμένα, αλλά κάποια από αυτά είναι χρήσιμα.”

– *George E. P. Box*

## Κεφάλαιο 7

### Προτεινόμενο μεθοδολογικό πλαίσιο

---

Στα προηγούμενα Κεφάλαια κατέστη σαφές ότι η διαδικασία λήψης της βέλτιστης, ή μιας σχεδόν βέλτιστης απόφασης σχετική με τις ερωτήσεις, που αφορούν στη διαχείρισης αποθεμάτων, όπως αναλύθηκαν στο Υποκεφάλαιο 2.1, είναι αρκετά δύσκολη.

Ενώ αριθμητικές προσεγγίσεις, όπως μέθοδοι βασισμένες στον δυναμικό προγραμματισμό οι οποίες περιγράφηκαν στο Υποκεφάλαιο 2.12, μπορούν να χρησιμοποιηθούν για την υποστήριξη τέτοιων αποφάσεων, όταν οι διαστάσεις του προβλήματος βελτιστοποίησης αυξάνονται (π.χ. ως προς τον αριθμό των χρονοσειρών και των παραμέτρων της πολιτικής αποθεματοποίησης που ακολουθείται), οι τεχνικές αυτές μπορεί να γίνουν εξαιρετικά χρονοβόρες, καθιστώντας τες από ξεπερασμένες έως μη λειτουργικές. Επιπλέον, οι περισσότερες από αυτές τις προσεγγίσεις εκ της φύσεώς τους δεν βασίζονται σε δεδομένα, κάνοντας ισχυρές υποθέσεις σχετικά με την κατανομή της ζήτησης και τη διαδικασία παραγγελιοδότησης που χρησιμοποιείται, και επηρεάζονται σημαντικά από πιθανές ελλείψεις δεδομένων.

Μια πολλά υποσχόμενη εναλλακτική στις αριθμητικές προσεγγίσεις είναι η χρήση αλγορίθμων μηχανικής μάθησης που είναι ικανοί να μαθαίνουν από μεγάλα σύνολα δεδομένων και να εφαρμόζουν τις γνώσεις που αποκομίζουν, προκειμένου να προσεγγίσουν το κόστος αποθεματοποίησης για συγκεκριμένες ανεξάρτητες μεταβλητές, παρέχοντας ακριβείς προτάσεις. Παρά την υιοθέτησή τους και την εξαιρετική τους απόδοση σε διάφορες εφαρμογές, η εμφάνιση των αλγορίθμων ML παραμένει περιορισμένη στις ρυθμίσεις των παραμέτρων των διαφόρων πολιτικών αποθεματοποίησης, με αποτέλεσμα στη βιβλιογραφία να συνιστάται περαιτέρω έρευνα στο συγκεκριμένο πεδίο.

Στο παρόν Κεφάλαιο παρουσιάζεται αναλυτικά ένα καινοτόμο μεθοδολογικό πλαίσιο το οποίο αξιοποιεί αλγορίθμους μηχανικής μάθησης με σκοπό τη βελτιστοποίηση των διαδικασιών αποθεματοποίησης, αναλύονται τα βασικά στοιχεία που το απαρτίζουν και περιγράφεται ο αλγόριθμος υλοποίησής του.

#### 7.1 Στοιχεία του μεθοδολογικού πλαισίου

Προτείνουμε ένα πλαίσιο το οποίο κάνει χρήση μεγάλου όγκου δεδομένων και μπορεί να χρησιμοποιηθεί για τη βελτιστοποίηση της διαδικασίας αποθεματοποίησης στο επίπεδο της αποθήκης. Με το προτεινόμενο πλαίσιο, χρησιμοποιείται ένα σύνολο δεδομένων αναφοράς, προκειμένου να συσχετιστούν το πρότυπο της ζήτησης και οι βασικές

παράμετροι της πολιτικής αποθεματοποίησης με την απόδοση του αποθέματος, δηλαδή τα επιμέρους κόστη που δημιουργούνται, όπως κόστη που συνεπάγονται οι χαμένες πωλήσεις, η διατήρηση αποθεμάτων και η τοποθέτηση παραγγελιών. Στη συνέχεια, η γνώση αυτή αξιοποιείται σε ένα σύνολο δεδομένων στόχο, παρέχοντας ακριβείς προτάσεις σχετικά με τις παραμέτρους πολιτικής αποθέματος που θα πρέπει να χρησιμοποιούνται για τη βελτιστοποίηση της πολιτικής σε κάθε χρονοσειρά. Ουσιαστικά, οι σειρές αναφοράς μπορεί να μην είναι οι ίδιες με τις στοχευόμενες, επιτρέποντας έτσι τη μεταφορά μάθησης και τη βελτιστοποίηση σε περιπτώσεις όπου οι ιστορικές παρατηρήσεις είναι περιορισμένες.

Το σημαντικότερο, ίσως, χαρακτηριστικό του εν λόγω πλαισίου είναι η προσαρμοστικότητα του και η εν γένει ανεκτικότητα στην τροποποίηση, μιας και είναι ανεξάρτητο από κάποιο συγκεκριμένο μοντέλο, τόσο όσον αφορά στη μέθοδο πρόβλεψης της ζήτησης που περιλαμβάνει, όσο και στην πολιτική αποθεματοποίησης που λαμβάνει υπόψη αλλά και στη μέθοδο μηχανικής μάθησης που αξιοποιεί για να κάνει τους απαραίτητους συσχετισμούς.

Στη συνέχεια του Κεφαλαίου περιγράφεται αναλυτικά ο αλγόριθμος του προτεινόμενου μεθοδολογικού πλαισίου και τα επιμέρους στοιχεία του, όπως αυτά επιλέχθηκαν για τη συνέχεια της παρούσας διατριβής.

Όπως αναφέρθηκε, είναι αναγκαία η ύπαρξη μεγάλου όγκου δεδομένων. Για να δημιουργηθούν τα δεδομένα αυτά, τα οποία διαθέτουν πληροφορίες σχετικές τόσο με τη χρονοσειρά ζήτησης των εξεταζόμενων προϊόντων, όσο και με την επίπτωση στο απόθεμα και την εμπειρία των πελατών κάτω από διάφορες πολιτικές αποθεματοποίησης, μπορούν να πραγματοποιηθούν προσομοιώσεις λειτουργίας μιας αποθήκης και εν συνεχεία να αξιοποιηθούν τα αποτελέσματά τους. Είναι εμφανές, έτσι, ότι για να δημιουργηθεί το σύνολο δεδομένων εκπαίδευσης πρέπει να αποφασιστούν μια σειρά από επιμέρους στοιχεία, τα οποία βρίσκονται στο κέντρο του μεθοδολογικού πλαισίου, τα οποία παρουσιάζονται παρακάτω.

Πιο αναλυτικά, παρακάτω παρουσιάζονται η μέθοδος που χρησιμοποιείται για την πρόβλεψη των χρονοσειρών διακοπτόμενης ζήτησης, τα χαρακτηριστικά που χρησιμοποιούνται για να εντοπιστούν τα μοτίβα των χρονοσειρών αυτών, η πολιτική αποθεματοποίησης που λαμβάνεται υπόψη και τα στοιχεία που απαρτίζουν το συνολικό κόστος αποθεματοποίησης. Επίσης παρουσιάζονται τα μοντέλα μηχανικής μάθησης, που είναι υπεύθυνα για την πρόβλεψη των επιμέρους στοιχείων κόστους, δηλαδή των συσχετισμό των μεταβλητών που έχουν προκύψει από τις προσομοιώσεις.

#### **Χαρακτηριστικά χρονοσειρών**

Προκειμένου να εξαχθεί η πληροφορία που αφορά στα διάφορα μοτίβα των χρονοσειρών διακοπτόμενης ζήτησης, οι οποίες απεικονίζουν τη ζήτηση ενός προϊόντος στο χρόνο κάθε φορά, χρησιμοποιήθηκαν η μέση τιμή των διαστημάτων μεταξύ των ζητήσεων (*ADI*) και ο τετραγωνικός συντελεστής μεταβλητότητας της ζήτησης ( $CV^2$ ), όπως ορίστηκαν στο Υποκεφάλαιο 3.5, βάσει των οποίων προκύπτει η κατηγοριοποίηση των χρονοσειρών σε *smooth*, *erratic*, *lumpy* και *intermittent* σύμφωνα με την κατηγοριοποίηση σύμφωνα με τους Syntetos et al. (2005), η οποία αναλύθηκε στο Υποκεφάλαιο 3.6.4. Επιπλέον, για να ενισχυθεί η γενίκευση της εν λόγω μεθοδολογίας, κατά τη δημιουργία των μοντέλων μηχανικής μάθησης, χρησιμοποιήθηκε και η μέση τιμή των χρονοσειρών (*mean demand*),



με τρόπο με τον οποίο θα αναλυθεί στη συνέχεια.

### Πρόβλεψη ζήτησης

Για να υπολογιστούν οι προβλέψεις των χρονοσειρών διακοπόμενης ζήτησης, επιλέχθηκε η μέθοδος Croston, η οποία περιγράφηκε αναλυτικά στο Υποκεφάλαιο 4.2.1. Ο λόγος επιλογής της συγκεκριμένης μεθόδου είναι το γεγονός ότι θεωρείται η πιο συνηθισμένη επιλογή για πρόβλεψη χρονοσειρών διακοπόμενης ζήτησης, εμφανίζοντας αρκετά καλά αποτελέσματα ακόμα και όταν συγκρίνεται με άλλες πιο πολύπλοκες και σύγχρονες μεθόδους και τεχνικές. Να σημειωθεί εδώ ότι για τους συντελεστές εξομάλυνσης  $a$  και  $b$  των επιμέρους προβλεπόμενων μεγεθών, δηλαδή των μεσοδιαστημάτων μεταξύ των διαδοχικών μη μηδενικών παρατηρήσεων και της ζήτησης, της μεθόδου Croston, επιλέχθηκε η τιμή  $0.1$  ( $a = b = 0.1$ ).

### Πολιτική αποθεματοποίησης

Ως πολιτική αποθεματοποίησης επιλέχθηκε η πολιτική  $(R, s, S)$ , όπως αυτή αναλύθηκε στο Υποκεφάλαιο 2.10.2.2, μιας και η συγκεκριμένη πολιτική αποτελεί μία εκ των πιο διαδεδομένων πολιτικών αποθεματοποίησης, υποθέτοντας ότι η μη εξυπηρετούμενη ζήτηση χάνεται, και ότι οι παραγγελίες παραδίδονται με μία σταθερή καθυστέρηση  $L$  ημερών, μιας και οι συγκεκριμένες υποθέσεις αναπαριστούν καλύτερα την πραγματικότητα. Επίσης, για το απόθεμα ασφαλείας επιλέχθηκε η μέθοδος του Greasley, όπως αυτή αναλύθηκε στο Υποκεφάλαιο 2.9.

Σύμφωνα με τις επιλογές αυτές, η διαδικασία αποθεματοποίησης ενός προϊόντος μπορεί να αναπαρασταθεί χρησιμοποιώντας τις παρακάτω εξισώσεις (Strijbosch & Moors, 2002):

$$S_t = \max(s_t, \sum_{w=t}^{t+m} \hat{D}_w),$$

$$s_t = \sum_{w=t}^{t+R+L} \hat{D}_w + SS_t,$$

όπου  $S_t$  είναι το επίπεδο αποθέματος στόχος τη χρονική στιγμή  $t$ , το οποίο μπορεί να επιτευχθεί μέσω μιας παραγγελίας ποσότητας  $Q_t$ ,  $m$  είναι ο αριθμός των περιόδων που καλύπτονται από μία αναπλήρωση και  $s_t$  το αντίστοιχο σημείο αναπαραγγελίας. Το σημείο αναπαραγγελίας υπολογίζεται με βάση την αναμενόμενη ζήτηση  $\hat{D}$  για τις επόμενες περιόδους  $R + L$ , στην οποία προστίθεται το απόθεμα ασφαλείας  $SS$ .

Το τελευταίο, κάνοντας χρήση της μεθόδου του Greasley, λαμβάνει υπόψη την επιλεγμένη πιθανότητα εξυπηρέτησης πελατών-επίπεδο εξυπηρέτησης στόχο ( $TSL$ ) και την τυπική απόκλιση των ιστορικών δεδομένων ζήτησης μέχρι την περίοδο  $t$  ( $\sigma_{D_t}$ ), ως εξής:

$$SS_t = Z\sigma_{D_t} \sqrt{R+L},$$

όπου το  $Z$  υπολογίζεται χρησιμοποιώντας την αντίστροφη αθροιστική συνάρτηση της κανονικής κατανομής, ως  $Z = \Phi^{-1}(TSL)$ .

Η ποσότητα παραγγελίας  $Q_t$ , η οποία επιτρέπει το επίπεδο αποθέματος ( $I_t$ ) να ανέλθει στο επίπεδο στόχο  $S_t$ , ισούται με  $S_t - I_t$  όταν το απόθεμα είναι μικρότερο από το επίπεδο αναπαραγγελίας  $s_t$  και μηδενική στις άλλες περιπτώσεις, ως εξής:

$$Q_t = \begin{cases} S_t - I_t, & \text{όπου } I_t \leq s_t \\ 0, & \text{όπου } I_t > s_t. \end{cases}$$

Να σημειωθεί εδώ ότι το επίπεδο αναπαραγγελίας  $s$  μπορεί να είναι μεγαλύτερο από το άθροισμα της προβλεπόμενης ζήτησης για  $m \leq R + L$  περιόδους. Σε τέτοιες περιπτώσεις, το επίπεδο αποθέματος στόχος ( $S_t$ ) είναι ίσο με το σημείο αναπαραγγελίας και η πολιτική μετατρέπεται σε μία ειδική περίπτωση της πολιτικής  $(R, s, S)$  την πολιτική  $(R, S)$ .

Από τις παραπάνω εξισώσεις προκύπτει ότι οι μόνες μεταβλητές που χρήζουν βελτιστοποίησης είναι οι  $R, L$  και  $TSL$ . Αν και σε πολλές περιπτώσεις ο χρόνος παράδοσης ( $L$ ) θεωρείται εξωγενής παράμετρος, που καθορίζεται κυρίως από τον προμηθευτή και επηρεάζεται ακόμα και από παράγοντες που σχετίζονται με την απόσταση μεταξύ προμηθευτή και εταιρείας, μπορεί επίσης να προσδιοριστεί από την εταιρεία, π.χ. μέσω μιας συμφωνίας μεταξύ των δύο πλευρών (service level agreement - SLA). Στην παρούσα διατριβή, έτσι, το  $L$  θεωρείται εσωτερική παράμετρος της πολιτικής αποθεματοποίησης, και τα πειράματα διεξάγονται αναλόγως. Ομοίως, αν και το σύνολο παραμέτρων που βελτιστοποιούνται καθορίζεται από την επιλεγμένη πολιτική, στη γενική περίπτωση, το προτεινόμενο μεθοδολογικό πλαίσιο, δύναται να εξετάσει διαφορετικές πολιτικές, με αποτέλεσμα διαφορετικά σύνολα παραμέτρων.

Για το υπόλοιπο της παρούσας διατριβής, οι μεταβλητές  $R, L$  και  $TSL$  θα αποκαλούνται “υπερπαράμετροι πολιτικής αποθεματοποίησης” (“inventory policy hyperparameters”) για λόγους απλότητας.

### Συνολικό κόστος αποθεματοποίησης

Για τον υπολογισμό του συνολικού κόστους αποθεματοποίησης λήφθηκαν υπόψη τα επιμέρους κόστη που προκύπτουν από τη διατήρηση αποθέματος, τα κόστη που σχετίζονται με την έλλειψη αποθεμάτων και τα κόστη τοποθέτησης των παραγγελιών, όπως αναλύθηκαν στο Υποκεφάλαιο 2.5. Ορίζοντας, έτσι, ως  $C_H$  το κόστος διατήρησης αποθεμάτων (holding cost),  $C_{LS}$  το κόστος έλλειψης αποθεμάτων (lost sales cost) και  $C_O$  το κόστος τοποθέτησης παραγγελίας (ordering cost), το συνολικό κόστος αποθεματοποίησης ( $C_{Tot}$ ),  $N$  προϊόντων για το χρονικό διάστημα  $t = 1$  έως  $t = T$  μπορεί να υπολογιστεί ως εξής:

$$\begin{aligned} C_{Tot} &= C_H + C_{LS} + C_O \\ &= \frac{h}{T} \sum_{i=1}^N \sum_{t=1}^T I_{i,t} p_i + b \sum_{i=1}^N \sum_{t=1}^T LS_{i,t} p_i + k \sum_{i=1}^N \sum_{t=1}^T NO_{i,t} \\ &= \sum_{i=1}^N \left( \frac{h}{T} \sum_{t=1}^T I_{i,t} p_i + b \sum_{t=1}^T LS_{i,t} p_i + k \sum_{t=1}^T NO_{i,t} \right), \end{aligned}$$

όπου  $h$  είναι το κόστος διατήρησης μιας μονάδας προϊόντος ως ποσοστό της αξίας του προϊόντος,  $b$  το κόστος έλλειψης ως ποσοστό της αξίας του προϊόντος,  $p$  η αξία του προϊόντος αυτού και  $k$  το κόστος πραγματοποίησης μιας παραγγελίας. Επίσης,  $I_{i,t}$ ,  $LS_{i,t}$  και  $NO_{i,t}$  είναι το επίπεδο του αποθέματος, οι χαμένες πωλήσεις και το πλήθος των παραγγελιών τη στιγμή  $t$  για το προϊόν  $i$ , αντίστοιχα, τα οποία θα αποκαλούνται “στοιχεία κόστους αποθέματος” (“inventory cost elements”) στο υπόλοιπο της παρούσας διατριβής

για λόγους απλότητας. Παρομοίως, οι μεταβλητές  $h, b$  και  $k$  θα αποκαλούνται “υπερπαραμέτροι κόστους αποθέματος” (“inventory cost hyperparameters”).

Στη συνέχεια της παρούσας εργασίας, για τις υπερπαραμέτρους κόστους αποθέματος χρησιμοποιούνται οι εξής τιμές:

- $h = 1\%$
- $b = 25\%$
- $k = 0.50\text{€}$

Οι συγκεκριμένες τιμές επιλέχθηκαν εντός των ορίων που εμφανίζονται στη βιβλιογραφία, όπως αυτά αναλύθηκαν στο Υποκεφάλαιο 2.5. Επιπλέον, δεδομένου ότι η παρούσα μελέτη εστιάζει σε εταιρείες λιανικής, και γίνεται χρήση δεδομένων που αφορούν στην εταιρεία Walmart, επιλέχθηκε το περιθώριο κέρδους της συγκεκριμένης εταιρείας ( $25\%^1$ ) για την υπερπαραμέτρο  $b$ .

Αν και η επιλογή των τιμών αυτών μπορεί να επηρεάσει τα αποτελέσματα, οι επιλεγμένες τιμές είναι αρκετά αντιπροσωπευτικές για εταιρείες λιανικής. Ωστόσο, αυτές οι τιμές αποτελούν στην ουσία υπερπαραμέτρους του προτεινόμενου μεθοδολογικού πλαισίου, που σημαίνει ότι μπορούν εύκολα να προσαρμοστούν ώστε να αντιπροσωπεύουν με μεγαλύτερη ακρίβεια τη διαδικασία διαχείρισης αποθεμάτων οποιασδήποτε εταιρείας.

#### **Μοντέλα πρόβλεψης των στοιχείων κόστους**

Για την πρόβλεψη των στοιχείων κόστους αποθέματος, χρησιμοποιηθήκαν μοντέλα LightBMG, όπως αυτά παρουσιάστηκαν αναλυτικά στο Υποκεφάλαιο 6.2.3.3, δίνοντάς τους ένα συγκεκριμένο σύνολο υπερπαραμέτρων πολιτικής αποθεματοποίησης και συγκεκριμένες τιμές χαρακτηριστικών χρονοσειράς ως είσοδο, μιας και τα εν λόγω μοντέλα έχουν αποδειχθεί ιδιαίτερα επιτυχή σε διάφορες εφαρμογές, ξεπερνώντας πολλούς άλλους αλγορίθμους ML.

Με τον τρόπο αυτό, εκπαιδεύτηκαν τρία διαφορετικά μοντέλα LightGBM, όσα και τα στοιχεία κόστους αποθέματος, έχοντας διαφορετική εξαρτημένη μεταβλητή ( $I, LS$  και  $NO$ ) αλλά τα ίδια features ( $ADI, CV^2, R, L$  και  $TSL$ ), σύμφωνα με τις επιλογές που έγιναν προηγουμένως. Όπως αναφέρθηκε παραπάνω, για να ενισχυθεί η γενίκευση των μοντέλων, οι εξαρτημένες μεταβλητές  $I$  και  $LS$  κανονικοποιήθηκαν πριν την εκπαίδευση των μοντέλων, διαιρώντας τις με τη μέση τιμή των χρονοσειρών ζήτησης του προϊόντος στο οποίο αντιστοιχούν κάθε φορά. Η εξαρτημένη μεταβλητή  $NO$  δεν κανονικοποιήθηκε καθώς αφορά στο πλήθος των παραγγελιών που πραγματοποιήθηκαν και δεν εξαρτάται από το μέσο επίπεδο των παρατηρήσεων της ζήτησης, όπως οι άλλες δύο ανεξάρτητες μεταβλητές.

Επιπλέον, οι βασικές παράμετροι των μοντέλων LightGBM, οι οποίες παρουσιάστηκαν εκτενώς στο Υποκεφάλαιο 6.2.3.3, δηλαδή το *learning\_rate* και το *num\_leaves*, βελτιστοποιήθηκαν προκειμένου να βελτιωθεί περαιτέρω η ακρίβεια των προβλέψεων. Για να γίνει αυτό, το σύνολο δεδομένων χωρίστηκε τυχαία σε ένα σύνολο εκπαίδευσης και ένα επαλήθευσης, αποτελούμενο από το 80% και το 20% των παρατηρήσεων αντίστοιχα που

<sup>1</sup>Δεδομένου ότι η παρούσα μελέτη εστιάζει σε εταιρείες λιανικής, το περιθώριο κέρδους της Walmart (<https://www.statista.com/statistics/269414/gross-profit-margin-of-walmart-worldwide-since-2006/>) μπορεί να χρησιμοποιηθεί ως ρεαλιστικό σημείο αναφοράς.

ήταν αρχικά διαθέσιμες. Στη συνέχεια, χρησιμοποιήθηκε μια προσέγγιση αναζήτησης πλέγματος για τον προσδιορισμό της καταλληλότερης τιμής για κάθε παράμετρο από ένα εύρος [0,05, 0,5] και [10, 130], αντίστοιχα.

## 7.2 Αλγόριθμος βελτιστοποίησης

Η προτεινόμενη προσέγγιση, που θα ονομάζεται στο εξής “βελτιστοποίηση ανεξάρτητη από μοντέλο για έλεγχο του αποθέματος” (“Model-independent Optimization for Inventory Control” ή αλλιώς “MOIC”), παρουσιάζεται στη συνέχεια και συνοψίζεται στο διάγραμμα ροής του Σχήματος 7.1.

Συνοπτικά, ο αλγόριθμος αποτελείται από δύο φάσεις. Στην πρώτη (off-line phase) κατασκευάζονται τα απαραίτητα δεδομένα μέσω προσομοιώσεων με τα οποία στη συνέχεια εκπαιδεύονται τα μοντέλα μηχανικής μάθησης, ενώ στη δεύτερη (on-line phase) τα εν λόγω μοντέλα μπορούν να χρησιμοποιηθούν προκειμένου να εντοπιστεί το βέλτιστο σύνολο υπερπαραμέτρων πολιτικής αποθεματοποίησης για κάθε χρονοσειρά του συνόλου δεδομένων στόχου. Ακολούθως παρουσιάζονται αναλυτικά τα βήματα κάθε φάσης.

### **Off-line phase**

Έστω σύνολο δεδομένων αναφοράς (reference set) αποτελούμενο από  $K_1$  χρονοσειρές οι οποίες απεικονίζουν τη ζήτηση  $K_1$  προϊόντων, κάθε μία με  $n$  ιστορικές παρατηρήσεις. Στην παρούσα διατριβή χρησιμοποιούνται ημερήσιες σειρές.

#### **Βήμα 1°**

Για κάθε χρονοσειρά, υπολογίζονται τα χαρακτηριστικά της προκειμένου να κατηγοριοποιηθούν ως προς το μοτίβο της ζήτησης. Στην παρούσα διατριβή αυτό πραγματοποιείται μέσω των δεικτών  $ADI$  και  $CV^2$ , όπως περιγράφηκε στο Υποκεφάλαιο 7.1.

#### **Βήμα 2°**

Επιλέγεται μία πολιτική αποθεματοποίησης και παράγονται  $M$  σύνολα υπερπαραμέτρων πολιτικής αποθεματοποίησης. Στην παρούσα διατριβή, επιλέχθηκε η πολιτική  $(R, s, S)$  και δημιουργήθηκαν 9.000 σύνολα υπερπαραμέτρων, 30 τιμές  $R$ , 30 τιμές  $L$  και 10 τιμές  $TSL$ , στα διαστήματα  $[1,60]$ ,  $[1,60]$  και  $[0.90,1]$  αντίστοιχα.

#### **Βήμα 3°**

Σε κάθε χρονοσειρά εφαρμόζεται ένα μοντέλο πρόβλεψης, στην παρούσα διατριβή επιλέχθηκε η μέθοδος Croston, και παράγονται οι αντίστοιχες προβλέψεις.

#### **Βήμα 4°**

Για να υπολογιστεί η επίδοση ως προς την αποθεματοποίηση για κάθε από τα  $M$  σύνολα υπερπαραμέτρων πολιτικής αποθεματοποίησης που δημιουργήθηκαν στο βήμα (2), ορίζεται η εξίσωση συνολικού κόστους αποθεματοποίησης. Στην παρούσα διατριβή χρησιμοποιήθηκε η εξίσωση όπως ορίστηκε στο Υποκεφάλαιο 7.1.

#### **Βήμα 5°**

Διεξάγονται προσομοιώσεις διαχείρισης αποθεμάτων για διάστημα ενός ημερολογιακού έτους, υπολογίζοντας για κάθε χρονοσειρά και σετ υπερπαραμέτρων πολιτικής αποθεματοποίησης τα αντίστοιχα στοιχεία κόστους αποθέματος. Στην παρούσα διατριβή υπολογίζονται τα  $I$ ,  $LS$  και  $NO$ .

#### **Βήμα 6°**

Ένα ξεχωριστό μοντέλο ML κατασκευάζεται για να προβλέπει τα στοιχεία κόστους αποθέματος, έτσι, στην παρούσα διατριβή κατασκευάζονται τρία LightGBM μοντέλα. Το σύνολο εκπαίδευσης κάθε μοντέλου αποτελείται από  $K_1 \times M$  παρατηρήσεις και συγκεκριμένα features, το πλήθος των οποίων εξαρτάται από τις αποφάσεις που λήφθηκαν στα βήματα (1) και (2), δηλαδή τα χαρακτηριστικά των χρονοσειρών και τις υπερπαραμέτρους πολιτικής αποθεματοποίησης. Στην παρούσα διατριβή οι εξαρτημένες μεταβλητές (*I*, *LS* και *NO*) προβλέπονται χρησιμοποιώντας πέντε ανεξάρτητες μεταβλητές (*ADI*, *CV<sup>2</sup>*, *R*, *L* και *TSL*).

### **On-line phase**

Έστω σύνολο δεδομένων στόχου (target series) αποτελούμενο από  $K_2$  χρονοσειρές οι οποίες απεικονίζουν τη ζήτηση  $K_2$  προϊόντων, για το οποίο είναι επιθυμητή η βελτιστοποίηση του αποθέματος.

#### **Βήμα 7<sup>ο</sup>**

Υπολογίζονται τα χαρακτηριστικά των χρονοσειρών του συνόλου στόχου, ομοίως με το βήμα (1).

#### **Βήμα 8<sup>ο</sup>**

Επιλέγεται ένα σύνολο υπερπαραμέτρων πολιτικής αποθεματοποίησης  $M$ , με παρόμοιο τρόπο με το βήμα (2).

#### **Βήμα 9<sup>ο</sup>**

Χρησιμοποιώντας τα μοντέλα ML που εκπαιδεύτηκαν στο βήμα (6) και λαμβάνοντας υπόψη τις τιμές των ανεξάρτητων μεταβλητών, όπως ορίστηκαν στα βήματα (7) και (8), προβλέπονται τα στοιχεία κόστους αποθέματος για κάθε σειρά και σετ υπερπαραμέτρων πολιτικής αποθεματοποίησης.

#### **Βήμα 10<sup>ο</sup>**

Κάνοντας χρήση των αποτελεσμάτων του βήματος (9), της εξίσωσης συνολικού κόστους αποθεματοποίησης του βήματος (4) και επιλέγοντας συγκεκριμένες τιμές για τις υπερπαραμέτρους κόστους αποθέματος, στην παρούσα διατριβή  $h$ ,  $b$  και  $k$ , εκτιμάται το συνολικό κόστος αποθεματοποίησης ανά περίπτωση.

#### **Βήμα 11<sup>ο</sup>**

Βάσει των αποτελεσμάτων του βήματος (10), εντοπίζεται το “βέλτιστο” σετ υπερπαραμέτρων πολιτικής αποθεματοποίησης για κάθε χρονοσειρά, σύμφωνα με την εξίσωση του βήματος (4) και τις επιλογές του βήματος (10).

Οι δύο προαναφερθείσες φάσεις του προτεινόμενου μεθοδολογικού πλαισίου παρουσιάζονται στη συνέχεια και με χρήση ψευδογλώσσας.

Να σημειωθεί εδώ πολλά μέρη, συμπεριλαμβανομένων των βασικών στοιχείων του προτεινόμενου μεθοδολογικού πλαισίου, όπως αυτά παρουσιάστηκαν στο Υποκεφάλαιο 7.1, μπορούν να τροποποιηθούν ανάλογα με τους στόχους του υπεύθυνου λήψης αποφάσεων και τις ιδιαιτερότητες της εταιρείας λιανικής κάθε φορά. Για παράδειγμα, μπορεί κανείς να εξετάσει διαφορετικά ή περισσότερα χαρακτηριστικά χρονοσειρών για την κατηγοριοποίηση της ζήτησης και την ομαδοποίηση των σειρών. Ομοίως, διαφορετικές μέθοδοι πρόβλεψης από αυτές της Croston μπορούν να χρησιμοποιηθούν για την πρόβλεψη της ζήτησης και την εκτίμηση της αβεβαιότητας. Επιπλέον, ανάλογα με την πολιτική αποθεματοποίησης που λαμβάνεται υπόψη, μπορούν να προκύψουν διαφορετικές υπερπαραμέτρους πολιτικής

Σχεδιάγραμμα της off-line φάσης του προτεινόμενου μεθοδολογικού πλαισίου σε ψευδογλώσσα

### **Off-line Phase**

**Require:** *reference\_set, inv\_policy, total\_inv\_cost\_equation, characteristics*

```

1: data ← preprocess(reference_set) #format, duration, filtering of data
2: inv_policy_hyperparams ← {si ← sample(values1, constraints1)} #set samples

3: for ts ∈ data do
4:   stats ← characteristics(ts) #calculate ts characteristics
5:   for s ∈ inv_policy_hyperparams do
6:     fc ← forecast(ts, s) #produce forecasts
7:     simulation_infos ← simulation(inv_policy, s, fc) #conduct simulations
8:     inv_cost_elements ∈ simulation_infos
9:     c ← inv_cost_elements #measure individual cost elements
10:    infos ← {infos, {stats, s, c}} #save info for sample s
11:   end for
12:   info ← {info, infos} #save ts info
13: end for

14: for k ∈ inv_cost_elements do
15:   MLk ← train(k, info) #train ML model
16:   MLSET ← {MLSET, MLk} #save constructed model
17: end for

```

Σχεδιάγραμμα της on-line φάσης του προτεινόμενου μεθοδολογικού πλαισίου σε ψευδογλώσσα

### **On-line Phase**

**Require:** *target\_series, inv\_policy, total\_inv\_cost\_equation, characteristics*

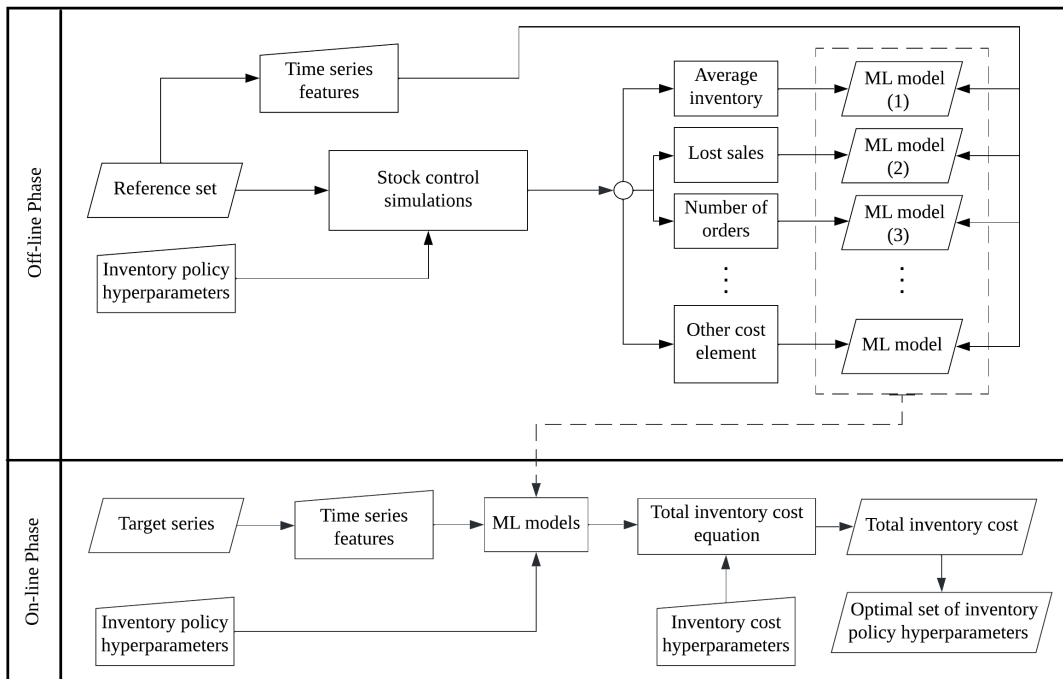
```

1: data ← preprocess(target_series)
2: inv_policy_hyperparams ← {si ← sample(values1, constraints1)}
3: inv_cost_hyperparams ← {ci ← select(values2, constraints2)}

4: for ts ∈ data do
5:   stats ← characteristics(ts)
6:   for s ∈ inv_policy_hyperparams do
7:     predicted_inv_cost_elements ← MLSET(ts, s) #predict individual cost elements
8:     infos ← {infos, predicted_inv_cost_elements}
9:   end for
10:  info ← {info, infos}
11: end for

12: total_inv_cost ← combine(inv_cost_hyperparams, info) #calculate total inventory cost
13: iphtsopt ← rank(total_inv_cost) #select optimal values per ts

```



Σχήμα 7.1: Διάγραμμα ροής του προτεινόμενου μεθοδολογικού πλαισίου, αποτελούμενο από μία off-line και μία on-line φάση.

αποθεματοποίησης οι οποίες χρήζουν βελτιστοποίηση ή, σε ένα πιο γενικό σενάριο, διάφορες πολιτικές αποθεματοποίησης μπορούν να συγκριθούν μεταξύ τους ως προς την απόδοση, έτσι ώστε να εντοπιστεί η πιο αποτελεσματική. Το συνολικό κόστος αποθεματοποίησης και οι αντίστοιχες υπερπαραμέτροι κόστους αποθέματος μπορούν επίσης να προσαρμοστούν ανάλογα με την εξεταζόμενη εφαρμογή. Τέλος, διαφορετικά μοντέλα ML μπορούν να χρησιμοποιηθούν για τη μοντελοποίηση των συσχετίσεων μεταξύ των εξαρτημένων μεταβλητών και των features των μοντέλων.

Ένα επιπλέον σημαντικό χαρακτηριστικό του συγκεκριμένου αλγορίθμου αφορά στα σύνολα δεδομένων που χρησιμοποιούνται στις δύο φάσεις του. Οι σειρές που χρησιμοποιούνται στην off-line φάση μπορεί να είναι είτε οι ίδιες είτε διαφορετικές από αυτές που εξετάζονται στην on-line φάση. Στην πρώτη περίπτωση, το MOIC θα χρησιμοποιηθεί για τη βελτιστοποίηση της αποθεματοποίησης μαθαίνοντας από τους συσχετισμούς που εντοπίστηκαν στις ιστορικές παρατηρήσεις των εξεταζόμενων χρονοσειρών, ενώ στην δεύτερη περίπτωση θα βελτιστοποιηθεί η αποθεματοποίηση των χρονοσειρών του συνόλου δεδομένων στόχου μέσω της εκμάθησης των βέλτιστων πρακτικών σε χρονοσειρές ενός άλλου συνόλου δεδομένων αναφοράς.

“Υπάρχουν δύο πιθανές εξελίξεις: Αν το αποτέλεσμα επαληθεύει την υπόθεση, θα έχεις κάνει μια μέτρηση. Αν το αποτέλεσμα δεν συμφωνεί με την υπόθεση, τότε θα έχεις κάνει μια ανακάλυψη.”

– *Enrico Fermi*



## Κεφάλαιο 8

# Πειραματική διάταξη - Παρουσίαση και ανάλυση αποτελεσμάτων

---

Στο παρόν Κεφάλαιο περιγράφεται αναλυτικά η πειραματική διαδικασία, όπως αυτή εφαρμόστηκε στην παρούσα διδακτορική διατριβή, προκειμένου να εξεταστεί η αποτελεσματικότητα του προτεινόμενου μεθοδολογικού πλαισίου, ενώ πραγματοποιείται και η παρουσίαση και ανάλυση των αποτελεσμάτων. Περιλήψεις των παρακάτω αναλυτικών αποτελεσμάτων, και της μεθοδολογίας που ακολουθήθηκε, έχουν δημοσιευτεί σε έγκριτα επιστημονικά περιοδικά και έχουν παρουσιαστεί σε επιστημονικά συνέδρια (Theodorou et al., 2019, 2021a, 2022b,a,c).

### 8.1 Δεδομένα

Προκειμένου να αξιολογηθεί η απόδοση του προτεινόμενου πλαισίου, λαμβάνεται υπόψη το σύνολο δεδομένων του διαγωνισμού M5, το οποίο περιλαμβάνει τις πωλήσεις 3.049 προϊόντων της εταιρείας Walmart σε 10 από τα καταστήματά της, καλύπτοντας μια περίοδο 1.969 ημερών (από 29-01-2011 έως 19-06-2016), όπως παρουσιάστηκε αναλυτικά στο Υποκεφάλαιο 5.3. Αν και το σύνολο δεδομένων αρχικά αποτελείται από δώδεκα επίπεδα συνάθροισης, ομαδοποιώντας τις σειρές ιεραρχικά με βάση την τοποθεσία (πολιτεία ή/και κατάσταση των ΗΠΑ) και τον τύπο (κατηγορία ή/και τμήμα) των προϊόντων που πωλούνται, η παρούσα διατριβή εστιάζει στο 11ο επίπεδο συνάθροισης, που αναπαριστά τις πωλήσεις ανά προϊόν και πολιτεία. Αυτό συμβαίνει καθώς το προτεινόμενο μεθοδολογικό πλαίσιο σχεδιάστηκε για τη βελτιστοποίηση της απόδοσης του αποθέματος στο επίπεδο της αποθήκης, γεγονός που σημαίνει ότι η ζήτηση πρέπει να αφορά σε ομάδες καταστημάτων που βρίσκονται στην ίδια περιοχή. Προφανώς, γίνεται η υπόθεση ότι η συγκεκριμένη εταιρεία λιανικής έχει τρεις αποθήκες, η κάθεμία από τις οποίες βρίσκεται σε διαφορετική περιοχή (πολιτείες Καλιφόρνια, Τέξας και Ουισκόνσιν) και εξυπηρετεί τις παραγγελίες συγκεκριμένων καταστημάτων (4 στην Καλιφόρνια και 3 στο Τέξας και 3 στο Ουισκόνσιν).

Από τις 9.147 χρονοσειρές που είναι διαθέσιμες στο επίπεδο προϊόντος-πολιτείας, 643 αφαιρέθηκαν από το σύνολο δεδομένων που χρησιμοποιήθηκε στα πειράματα, με αποτέλεσμα το τελικό σύνολο να αποτελείται από 8.504 σειρές. Αυτό έγινε για να διασφαλιστεί ότι όλες οι σειρές που εξετάστηκαν στις προσομοιώσεις περιλάμβαναν παρατηρήσεις τουλάχιστον δύο ολόκληρων ημερολογιακών ετών, καθώς το πρώτο έτος

εξυπηρετεί την υλοποίηση της off-line φάσης του MOIC, δηλαδή την εκπαίδευση των μοντέλων ML, ενώ το τελευταίο έτος εξυπηρετεί την υλοποίηση της on-line φάσης, στην οποία πραγματοποιείται και η αξιολόγηση της απόδοσης του πλαισίου.

Να σημειωθεί εδώ ότι εκτός από τα δεδομένα πωλήσεων, το σύνολο δεδομένων του διαγωνισμού M5 παρέχει και πληροφορίες σχετικές με την τιμή κάθε είδους ( $p_i$ ). Αυτές οι πληροφορίες είναι απαραίτητες για τον υπολογισμό του συνολικού κόστους αποθεματοποίησης και επομένως περιλαμβάνονται στα πειράματα που πραγματοποιήθηκαν.

Εκτός από το σύνολο του M5, λαμβάνεται υπόψη και ένα σύνολο τεχνητών χρονοσειρών που μπορεί να χρησιμεύσει ως εναλλακτικό σύνολο αναφοράς κατά την υλοποίηση της off-line φάσης του πλαισίου. Εκτός από την αξιολόγηση των δυνατοτήτων της μεταφοράς μάθησης του πλαισίου, η χρήση τεχνητών δεδομένων ως συνόλου αναφοράς έχει ένα επιπλέον πιθανό πλεονέκτημα σε σύγκριση με τα πραγματικά. Τα πραγματικά δεδομένα ζήτησης δεν εκφράζουν απαραίτητα την άνευ όρων ζήτηση στην αποθήκη, καθώς μπορεί να υπόκεινται σε πιθανές εξαντλήσεις αποθεμάτων, που είναι αρκετά εμφανείς, ειδικά σε εταιρείες λιανικής. Ως αποτέλεσμα, θεωρητικά, τα μοντέλα ML που έχουν εκπαιδευτεί σε πραγματικά δεδομένα ενδέχεται να υποτιμούν τη ζήτηση, και κατά συνέπεια να οδηγούν σε μη βέλτιστες προτάσεις.

Η παραγωγή του εν λόγω συνόλου τεχνητών χρονοσειρών πραγματοποιήθηκε με τη χρήση της γεννήτριας παραγωγής τεχνητών χρονοσειρών που αναλύθηκε στο Υποκεφάλαιο 5.2.1, και περιλαμβάνει 10.000 σειρές, όμοια κατανεμημένες στα τέσσερα μοτίβα ζήτησης (smooth, erratic, lumpy, intermittent), οι οποίες καλύπτουν μια περίοδο 548 ημερών.

Ενδελεχής παρουσίαση των δύο συνόλων δεδομένων που χρησιμοποιούνται στη συνέχεια της παρούσας διατριβής, αλλά και αναλυτική σύγκριση αυτών πραγματοποιείται στο Υποκεφάλαιο 5.4.

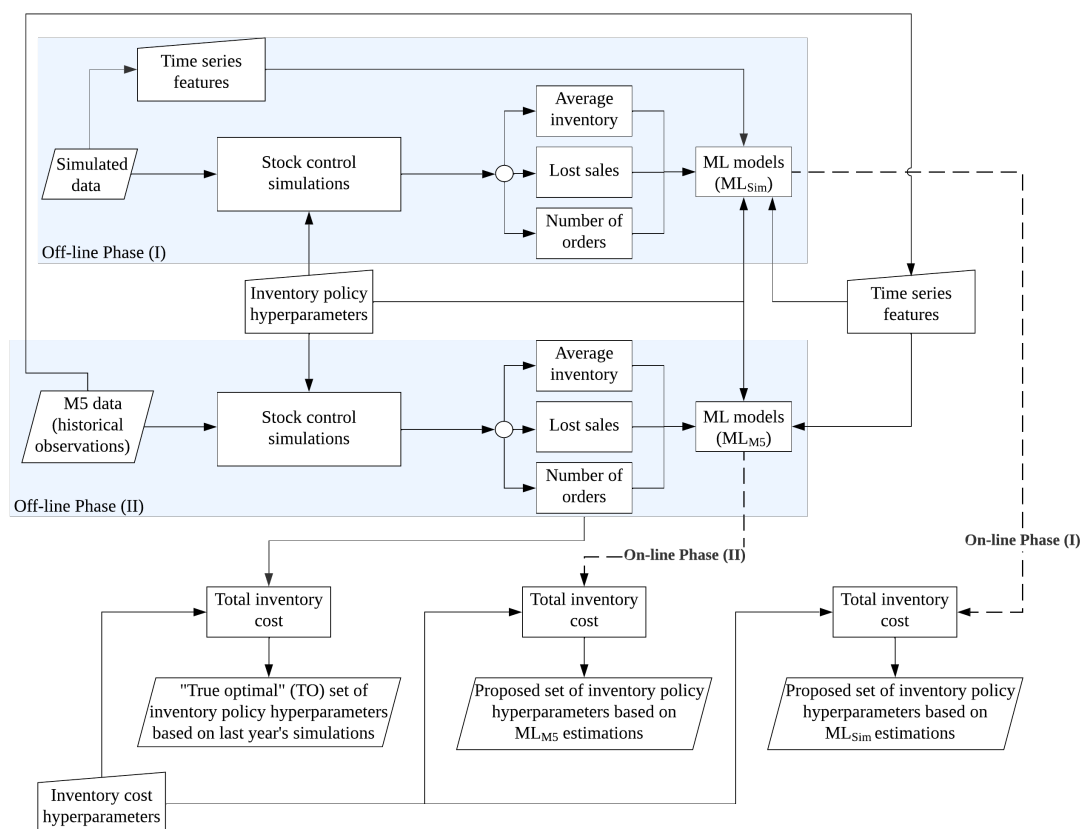
## 8.2 Πειραματική διάταξη

Προκειμένου τα εξαγόμενα συμπεράσματα να είναι αντικειμενικά, λαμβάνοντας υπόψη ενδεχόμενη εμφάνιση τάσης και εποχιακότητας στα δεδομένα, το MOIC αξιολογήθηκε χρησιμοποιώντας το τελευταίο έτος του συνόλου δεδομένων του διαγωνισμού M5, όπως αναφέρθηκε παραπάνω, διατηρώντας τα υπόλοιπα ιστορικά δεδομένα του M5 ή το πλήρες σύνολο τεχνητών χρονοσειρών για εκπαίδευση.

Ακολουθώντας τα βήματα του αλγορίθμου που παρουσιάστηκε στο Υποκεφάλαιο 7.2 εκπαιδεύτηκαν δύο σαιτ μοντέλων LightGBM, με το πρώτο, που ονομάζεται  $ML_{Sim}$ , να προβλέπει τα στοιχεία κόστους αποθέματος έχοντας εκπαιδευτεί με τις τεχνητές χρονοσειρές, ενώ το δεύτερο, που ονομάζεται  $ML_{M5}$ , έχοντας εκπαιδευτεί με τα ιστορικά δεδομένα του M5. Λαμβάνοντας υπόψη τα χαρακτηριστικά των χρονοσειρών των ιστορικών δεδομένων του M5, καθώς και τις επιλεγμένες υπερπαραμέτρους κόστους αποθέματος, κάθε σαιτ μοντέλων ( $ML_{Sim}$  και  $ML_{M5}$ ) εφαρμόστηκε για διάφορα σαιτ υπερπαραμέτρων πολιτικής αποθεματοποίησης και εντόπισε ένα μοναδικό σαιτ ως “βέλτιστο” για κάθε σειρά. Επομένως, και οι δύο φάσεις του MOIC, off-line και on-line, εφαρμόζονται δύο φορές, με τις εφαρμογές off-line phase (I) και on-line phase (I) να αναφέρονται στην εκπαίδευση των

μοντέλων  $ML_{Sim}$  και τις εφαρμογές off-line phase (II) και on-line phase (II) να αναφέρονται στην εκπαίδευση των μοντέλων  $ML_{M5}$ . Η αναπαράσταση της διαδικασίας αυτής παρουσιάζεται αναλυτικά στο Σχήμα 8.1.

Για λόγους σύγκρισης, εξετάστηκαν επίσης δύο σημεία αναφοράς (benchmarks). Το πρώτο benchmark αναφέρεται στις “πραγματικά βέλτιστες” (true optimal - TO) υπερπαραμέτρους πολιτικής αποθεματοποίησης κάθε σειράς του M5, οι οποίες οδήγησαν στο μικρότερο συνολικό κόστος αποθεματοποίησης στα ιστορικά δεδομένα. Ουσιαστικά, αυτό το σημείο αναφοράς υποδεικνύει ποια θα ήταν η απόδοση της εταιρείας το επόμενο έτος, εάν βελτιστοποιούσε την διαδικασία αποθεματοποίησης με βάση το σετ υπερπαραμέτρων πολιτικής αποθεματοποίησης που θα λειτουργούσε καλύτερα το προηγούμενο έτος. Το δεύτερο σημείο αναφοράς περιλαμβάνει ένα σταθερό σύνολο υπερπαραμέτρων πολιτικής αποθεματοποίησης (fixed set of hyperparameters - FSH). Οι επιλεγμένες τιμές αυτών των υπερπαραμέτρων ήταν οι  $R = 7, L = 3$  και  $TSL = 0,95$ , οι οποίες είναι αρκετά κοντά στους πραγματικούς μέσους όρους που χρησιμοποιούνται στον συγκεκριμένο κλάδο. Έτσι, σύμφωνα με τις τιμές αυτές, η εταιρεία λιανικής εξετάζει το απόθεμά της μία φορά την εβδομάδα, ο προμηθευτής εκπληρώνει τις παραγγελίες, εάν υπάρχουν, εντός 3 ημερών και οι εξαντλήσεις αποθέματος στοχοθετούνται να συμβαίνουν στο 5% της συνολικής χρονικής περιόδου.




Σχήμα 8.1: Διάγραμμα ροής της πειραματικής διάταξης: εφαρμογή του προτεινόμενου μεθοδολογικού πλαισίου.

Αν και, εκ πρώτης όψης, φαίνεται ότι οι τιμές του σημείου αναφοράς FSH έχουν επιλεχθεί

αυθαίρετα, όντας πιθανώς μακριά από τις βέλτιστες, στην πραγματικότητα το επιλεγμένο σετ τιμών είναι ιδιαίτερα ανταγωνιστικό.

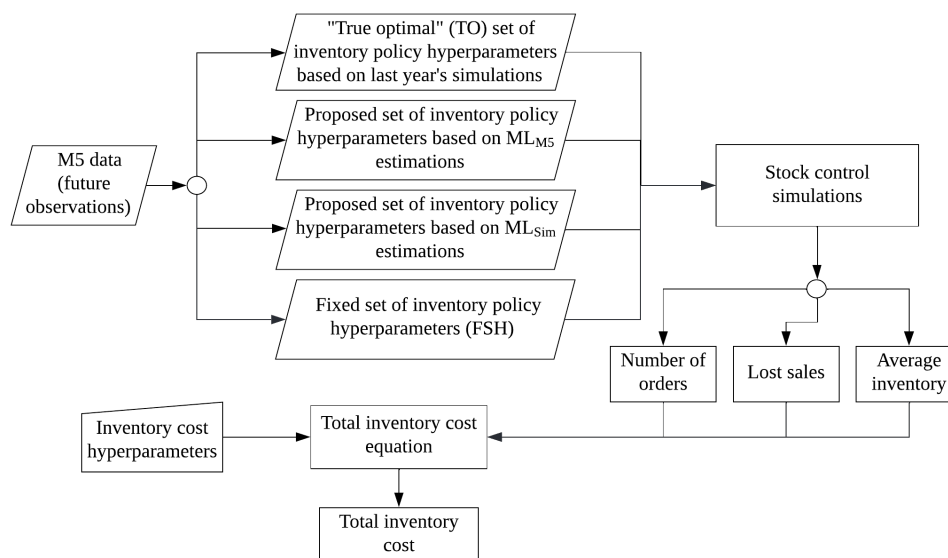
Στο Σχήμα 8.2 απεικονίζεται η διασπορά του συνολικού κόστους αποθεματοποίησης ( $C_{Tot}$ ) όταν χρησιμοποιούνται διάφορες παραλλαγές του  $FSH$  (οι ίδιες τιμές υπερπαραμέτρων επιλέγονται για όλα τα προϊόντα) για την αναπλήρωση όλων των προϊόντων που περιλαμβάνονται στο σύνολο δεδομένων του M5. Πιο συγκεκριμένα, απεικονίζονται τα αποτελέσματα των προσομοιώσεων για τα ιστορικά δεδομένα του M5 (έτος πριν από αυτό που χρησιμοποιήθηκε για αξιολόγηση). Το συγκεκριμένο σχήμα δείχνει ξεκάθαρα ότι το σετ τιμών που επιλέχθηκε για την εφαρμογή του σημείου αναφοράς  $FSH$  στην παρούσα διατριβή ( $R = 7, L = 3, TSL = 0,95$ ) συγκαταλέγεται στις καλύτερες επιδόσεις. Επιπλέον, καταδεικνύει ότι ο δεύτερος δείκτης αναφοράς που χρησιμοποιείται, το  $TO$ , είναι ικανός να προσδιορίσει αποτελεσματικά το καταλληλότερο σετ τιμών για κάθε προϊόν ξεχωριστά. Συμπεραίνεται, έτσι, ότι η βελτιστοποίηση των παραμέτρων κάθε προϊόντος ξεχωριστά έχει μεγάλη αξία, μιας και παρατηρείται σημαντική μείωση του συνολικού κόστους σε σχέση με την υιοθέτηση των ίδιων τιμών για το σύνολο των προϊόντων. Ωστόσο, η παραπάνω διαδικασία είναι αρκετά χρονοβόρα και κοστοβόρα, καθιστώντας τη πολλές φορές ασύμφορη ή υπολογιστικά ανέφικτη, σε περιπτώσεις όπου το πλήθος των προϊόντων είναι μεγάλο. Από αυτή την άποψη, και τα δύο σημεία αναφοράς μπορούν να θεωρηθούν λογικά και ανταγωνιστικά.



Σχήμα 8.2: Απόδοση ως προς το συνολικό κόστος αποθεματοποίησης διαφόρων συνόλων υπερπαραμέτρων πολιτικής αποθεματοποίησης στις ιστορικές παρατηρήσεις του συνόλου δεδομένων M5.

Όπως φαίνεται στο Σχήμα 8.3, για κάθε χρονοσειρά του συνόλου δεδομένων του M5, πραγματοποιήθηκαν προσομοιώσεις διαχείρισης αποθεμάτων για το τελευταίο έτος των διαθέσιμων δεδομένων, λαμβάνοντας υπόψη τα σετ υπερπαραμέτρων πολιτικής αποθεματοποίησης που προέκυψαν από τα σετ μοντέλων  $ML_{Sim}$  και  $ML_{M5}$  καθώς επίσης και από τα δύο benchmarks,  $TO$  και  $FSH$ . Δεδομένης της εξίσωσης συνολικού κόστους αποθεματοποίησης και δεδομένων των επιλεγμένων υπερπαραμέτρων κόστος αποθέματος,

υπολογίστηκε το συνολικό κόστος αποθεματοποίησης για κάθε περίπτωση.



Σχήμα 8.3: Διάγραμμα ροής της πειραματικής διάταξης: αξιολόγηση της απόδοσης του προτεινόμενου μεθοδολογικού πλαισίου.

### 8.3 Αποτελέσματα μεθοδολογίας για τα δεδομένα του διαγωνισμού M5


Πριν παρουσιαστούν και αναλυθούν τα αποτελέσματα της πειραματικής διαδικασίας, στη Σχήμα 8.4 παρουσιάζεται η σημαντικότητα των ανεξάρτητων μεταβλητών (feature importance), όπως αυτή ορίστηκε στο Υποκεφάλαιο 6.3, των τριών LightGBM μοντέλων των σετ μοντέλων  $ML_{Sim}$  και  $ML_{M5}$ , αντίστοιχα.

Στο σετ μοντέλων  $ML_{Sim}$  παρατηρείται ότι το  $CV^2$  και το  $ADI$  είναι σχεδόν σε όλα τα μοντέλα οι πιο σημαντικές μεταβλητές, με το μοντέλο που προβλέπει το πλήθος των παραγγελιών να εκτιμά περισσότερο το  $R$ , κάτι που είναι αναμενόμενο, μιας και σε μια συγκεκριμένη χρονική περίοδο το χρονικό διάστημα που πρέπει να μεσολαβεί μεταξύ δύο παραγγελιών καθορίζει και το πλήθος των συνολικών παραγγελιών. Τα ευρήματα αυτά υποδηλώνουν τα εξής:

- τα στοιχεία κόστους αποθέματος επηρεάζονται περισσότερο από τα πρότυπα της ζήτησης παρά από τις υπερπαραμέτρους της πολιτικής αποθεματοποίησης που χρησιμοποιούνται,
- η μεταβλητότητα και η σποραδικότητα της ζήτησης μπορούν να επηρεάσουν σημαντικά τις χαμένες πωλήσεις και το επίπεδο του αποθέματος,
- ο αριθμός των παραγγελιών επηρεάζεται κυρίως από το χρόνο μεταξύ δύο διαδοχικών παραγγελιών, και

- το επίπεδο εξυπηρέτησης στόχος είναι περισσότερο χρήσιμο στον προσδιορισμό των χαμένων πωλήσεων.

Ωστόσο, διαφορετικά συμπεράσματα μπορούν να εξαχθούν εστιάζοντας στη σημαντικότητα των μεταβλητών του σετ μοντέλων  $ML_{M5}$ . Στην περίπτωση αυτή, ορισμένες από τις υπερπαραμέτρους της πολιτικής αποθεματοποίησης (π.χ.  $R$  και  $L$ ) είναι παρόμοιες ή ακόμη και πιο σημαντικές από το  $ADI$  και το  $CV^2$ , υποδεικνύοντας ότι η επιλογή διαφορετικών τιμών για τις υπερπαραμέτρους μπορεί να επηρεάσει σημαντικά το συνολικό κόστος αποθεματοποίησης. Οι διαφορές αυτές αποδεικνύουν ότι τα μοντέλα που εκπαιδεύονται σε διαφορετικά σύνολα δεδομένων αναφοράς αναγνωρίζουν διαφορετικές συσχετίσεις μεταξύ των δεδομένων και, κατά συνέπεια, εκτιμούν διαφορετικά τις ανεξάρτητες μεταβλητές με αποτέλεσμα να προσδιορίζουν διαφορετικές πρακτικές αποθεματοποίησης ως “βέλτιστες”.



Σχήμα 8.4: Σημαντικότητα μεταβλητών (feature importance) των τριών LightGBM μοντέλων που αποτελούν το σετ μοντέλων  $ML_{Sim}$  (επάνω) και το  $ML_{M5}$  (κάτω).

Στον Πίνακα 8.1 συνοψίζονται τα αποτελέσματα των δύο προσεγγίσεων στις οποίες εφαρμόστηκε το MOIC ( $ML_{Sim}$  και  $ML_{M5}$ ) και των benchmarks. Παρουσιάζεται το πραγματοποιηθέν συνολικό κόστος αποθεματοποίησης ( $C_{Tot}$ ) κάθε στρατηγικής παραγγελιοδότησης, καθώς και τα επιμέρους κόστη που το απαρτίζουν, δηλαδή το κόστος διατήρησης αποθεμάτων ( $C_H$ ), το κόστος έλλειψης αποθεμάτων ( $C_{LS}$ ) και το κόστος τοποθέτησης παραγγελιών ( $C_O$ ). Παρουσιάζεται, επίσης, το μέσο πραγματοποιηθέν επίπεδο

εξυπηρέτησης πελατών ( $\overline{SL}$ ) κάθε στρατηγικής.

Φαίνεται χαρακτηριστικά ότι και οι δύο προσεγγίσεις του MOIC αποδίδουν καλύτερα από τα επιλεγμένα benchmarks, τόσο σε επίπεδο συνολικού κόστους αποθεματοποίησης όσο και σε επίπεδο εξυπηρέτησης πελατών, με την προσέγγιση που περιλαμβάνει μεταφορά μάθησης να εμφανίζει τα καλύτερα αποτελέσματα. Συγκεκριμένα, η προσέγγιση  $ML_{Sim}$  μειώνει το συνολικό κόστος σε σχέση με το  $TO$  κατά περίπου 27%, ενώ βελτιώνει το επίπεδο εξυπηρέτησης κατά 2%. Σύμφωνα με τις προσομοιώσεις, οι περισσότερες από αυτές τις εξοικονομήσεις προέρχονται από λιγότερες χαμένες πωλήσεις και χαμηλότερο κόστος διατήρησης αποθεμάτων. Επιπλέον, σε σύγκριση με το  $ML_{M5}$ , το  $ML_{Sim}$  μειώνει το κόστος κατά περίπου 16%, ενώ αυξάνει το επίπεδο εξυπηρέτησης κατά 1% (και πάλι μειώνοντας τις χαμένες πωλήσεις και τις ημέρες αποθέματος). Γίνεται προφανές ότι η προσέγγιση της μεταφοράς μάθησης είναι κατά μέσο όρο πιο αποτελεσματική στην ενορχήστρωση της διαδικασίας αναπλήρωσης του αποθέματος, δίνοντας αρκετές παραγγελίες για να καλύψει τη ζήτηση, χωρίς ωστόσο να υπερβάλλει. Διαπιστώνεται επίσης ότι η προσέγγιση  $TO$  αποδίδει παρόμοια με τη στρατηγική  $FSH$ , είναι ελαφρώς καλύτερη από άποψη συνολικού κόστους, αλλά χειρότερη από άποψη επιπέδου εξυπηρέτησης. Αυτό οφείλεται στο γεγονός ότι, σύμφωνα με τη στρατηγική  $FSH$ , οι παραγγελίες γίνονται σε πολύ τακτική βάση, μειώνοντας έτσι τις χαμένες πωλήσεις σε κάποιο βαθμό, αλλά σε βάρος του σημαντικά υψηλότερου κόστους τοποθέτησης παραγγελιών. Ενδιαφέρον είναι το γεγονός ότι, αν και τα αποτελέσματα  $FSH$  υποδηλώνουν πιο συχνές παραγγελίες από το  $ML_{Sim}$ , η τελευταία προσέγγιση εξακολουθεί να οδηγεί σε λιγότερες χαμένες πωλήσεις. Αυτό μπορεί να αποδοθεί στα πρότυπα της ζήτησης του συνόλου δεδομένων του διαγωνισμού M5. Λόγω της αβεβαιότητας που υπάρχει όταν η ζήτηση είναι ασταθής ή/και διακοπτόμενη, οι πιο συχνές παραγγελίες δεν εγγυώνται απαραίτητα καλύτερη απόδοση του αποθέματος. Το συμπέρασμα αυτό συμφωνεί και με τα αποτελέσματα του Σχήματος 8.4, υπογραμμίζοντας τη σημασία των  $ADI$  και  $CV^2$  στη διαδικασία παραγγελιοδότησης.

Πίνακας 8.1: Απόδοση των εξεταζόμενων στρατηγικών διαχείρισης αποθεμάτων (προσεγγίσεις του MOIC και σημεία αναφοράς) ως προς το συνολικό κόστος αποθεματοποίησης και το επίπεδο εξυπηρέτησης πελατών. Τα αποτελέσματα αναφέρονται στις 8.504 σειρές του συνόλου δεδομένων M5.

Προσέγγιση	$C_H$	$C_{LS}$	$C_O$	$C_{Tot}$	$\overline{SL}$
$ML_{M5}$	36.705	286.658	<b>34.189</b>	357.552	0,97
$ML_{Sim}$	27.745	<b>213.850</b>	57.433	<b>299.027</b>	<b>0,98</b>
$TO$	39.183	333.522	39.232	411.937	0,96
$FSH$	<b>10.820</b>	246.502	188.850	446.172	0,97

Προκειμένου να διερευνηθεί περαιτέρω η απόδοση του προτεινόμενου μεθοδολογικού πλαισίου, εξετάστηκαν τα ίδια αποτελέσματα ανά κατηγορία προτύπου ζήτησης, τα οποία και συνοψίζονται στον Πίνακα 8.2. Ομοίως με ολόκληρο το σύνολο δεδομένων, η  $ML_{Sim}$  υπερτερεί όλων των άλλων στρατηγικών, τόσο ως προς το συνολικό κόστος αποθεματοποίησης όσο και ως προς το επίπεδο εξυπηρέτησης. Διαπιστώνεται, επίσης, ότι οι ποσοστιαίες βελτιώσεις της προσέγγισης  $ML_{Sim}$  σε σχέση με μια άλλη προσέγγιση είναι

μεγαλύτερες για τις ασταθείς (erratic) και ομαλές (smooth) χρονοσειρές, κάτι που ήταν αναμενόμενο δεδομένου ότι αυτές οι κατηγορίες σειρών κινούνται πιο γρήγορα και, ως εκ τούτου, συμβάλλουν περισσότερο στα έσοδα και τα κόστη μιας εταιρείας λιανικής. Σε σύγκριση με το  $ML_{M5}$ , το  $ML_{Sim}$  φαίνεται ότι μειώνει το κόστος κατά περίπου 8% όταν χρησιμοποιείται για τον έλεγχο σποραδικών (intermittent) και ακανόνιστων (lumpy) σειρών και κατά περίπου 21% όταν χρησιμοποιείται για την αναπλήρωση ασταθών (erratic) και ομαλών (smooth) σειρών. Αυτές οι βελτιώσεις ανέρχονται σε περίπου 21% και 28% όταν το  $ML_{Sim}$  συγκρίνεται με το  $TO$ , αντίστοιχα. Προκύπτει, έτσι, ότι το MOIC μπορεί να οδηγήσει σε αξιοσημείωτες βελτιώσεις, ανεξάρτητα από τον τύπο των μοτίβων ζήτησης που εμφανίζει το σύνολο δεδομένων.

Πίνακας 8.2: Απόδοση των εξεταζόμενων στρατηγικών διαχείρισης αποθεμάτων (προσεγγίσεις του MOIC και σημεία αναφοράς) ως προς το συνολικό κόστος αποθεματοποίησης και το επίπεδο εξυπηρέτησης πελατών. Τα αποτελέσματα παρουσιάζονται ανά κατηγορία προτύπων ζήτησης.

Προσέγγιση	$C_{Tot}$				$\overline{SL}$			
	Erratic	Intermittent	Lumpy	Smooth	Erratic	Intermittent	Lumpy	Smooth
$ML_{M5}$	40.130	113.395	40.336	163.690	0,98	0,97	0,96	0,98
$ML_{Sim}$	<b>33.092</b>	<b>105.652</b>	<b>36.665</b>	<b>123.619</b>	<b>0,98</b>	<b>0,97</b>	<b>0,97</b>	<b>0,99</b>
$TO$	42.415	133.170	46.702	189.649	0,97	0,96	0,95	0,97
$FSH$	44.655	171.611	55.616	174.289	0,98	0,97	0,96	0,99


Επιπρόσθετα, εξετάστηκαν τα ίδια αποτελέσματα αλλά σε επίπεδο αποθήκης, τα οποία παρουσιάζονται στον Πίνακα 8.3. Και σε αυτή την περίπτωση η προσέγγιση  $ML_{Sim}$  υπερτερεί τόσο των benchmarks όσο και της προσέγγισης που δεν κάνει χρήση μεταφοράς μάθησης, σε απόλυτη αντιστοιχία με την εξέταση των αποτελεσμάτων στο σύνολο χρονοσειρών και της κάθε κατηγορίας ζήτησης ξεχωριστά.

Πίνακας 8.3: Απόδοση των εξεταζόμενων στρατηγικών διαχείρισης αποθεμάτων (προσεγγίσεις του MOIC και σημεία αναφοράς) ως προς το συνολικό κόστος αποθεματοποίησης και το επίπεδο εξυπηρέτησης πελατών. Τα αποτελέσματα παρουσιάζονται ανά περιοχή/αποθήκη.

Προσέγγιση	$C_{Tot}$			$\overline{SL}$		
	CA	TX	WI	CA	TX	WI
$ML_{M5}$	149.599	91.560	116.392	0,97	0,97	0,97
$ML_{Sim}$	<b>119.090</b>	<b>79.519</b>	<b>100.418</b>	<b>0,98</b>	<b>0,98</b>	<b>0,98</b>
$TO$	170.930	105.109	135.898	0,96	0,96	0,96
$FSH$	157.422	131.570	157.180	0,98	0,97	0,97

Για τη διερεύνηση της σταθερότητας, ή ευστάθειας, των παραπάνω αποτελεσμάτων σε επίπεδο χρονοσειράς-προϊόντος, στο Σχήμα 8.5 παρουσιάζονται οι κατανομές του συνολικού κόστους αποθεματοποίησης και του επιπέδου εξυπηρέτησης των 8.504 σειρών του συνόλου δεδομένων M5. Φαίνεται ξεκάθαρα ότι η προσέγγιση  $ML_{Sim}$  οδηγεί στις πιο “στενές” κατανομές με τις καλύτερες μέσες τιμές (mean) και διάμεσες τιμές (median). Επιπλέον, αν οι κατανομές των προσεγγίσεων  $FSH$  και  $ML_{M5}$  είναι σχετικά όμοιες, η τελευταία είναι καλύτερη ως προς τη μέση τιμή και την διάμεση τιμή του  $C_{Tot}$  και του  $\overline{SL}$ , υπογραμμίζοντας τα οφέλη του MOIC. Παρόμοια συμπεράσματα μπορούν να εξαχθούν και από τα Σχήματα 8.6 και 8.7, τα οποία αναλύουν τα αποτελέσματα ανά κατηγορία προτύπου



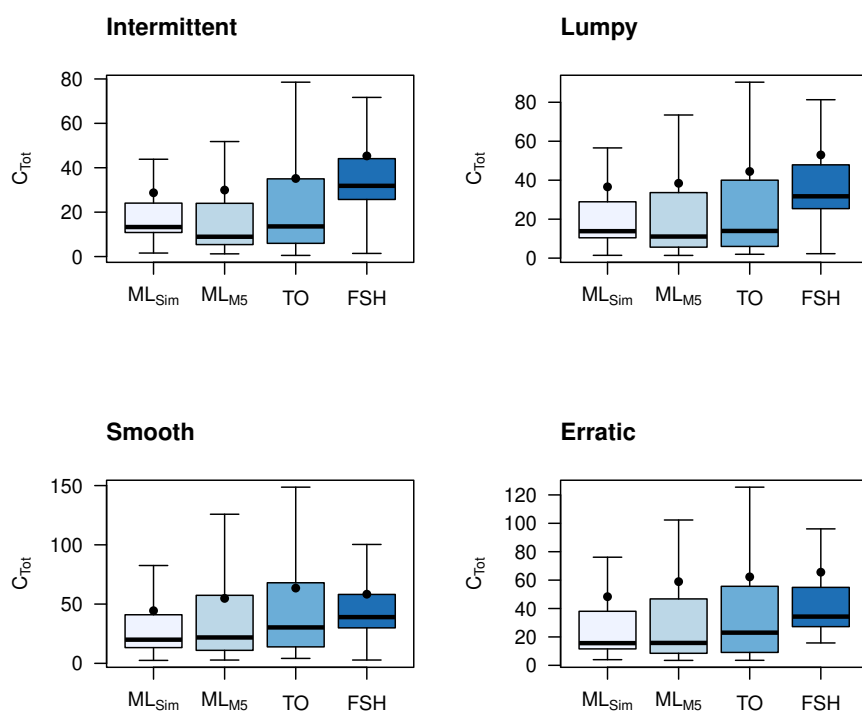


Σχήμα 8.5: Απόδοση των εξεταζόμενων στρατηγικών διαχείρισης αποθεμάτων (προσεγγίσεις του MOIC και σημεία αναφοράς). Τα “κουτιά” αντιπροσωπεύουν την κατανομή του συνολικού κόστους αποθεματοποίησης (αριστερά) και του επιπέδου εξυπηρέτησης πελατών (δεξιά) των 8.504 σειρών του συνόλου δεδομένων M5.

ζήτησης και ανά πολιτεία των ΗΠΑ (αποθήκη). Αντλώντας από τα παραπάνω, συμπεραίνεται ότι η απόδοση του MOIC είναι καλύτερη, τόσο κατά μέσο όρο στο σύνολο της εταιρείας όσο και όταν λαμβάνονται υπόψη διάφορα είδη ή αποθήκες της εν λόγω εταιρείας ξεχωριστά.

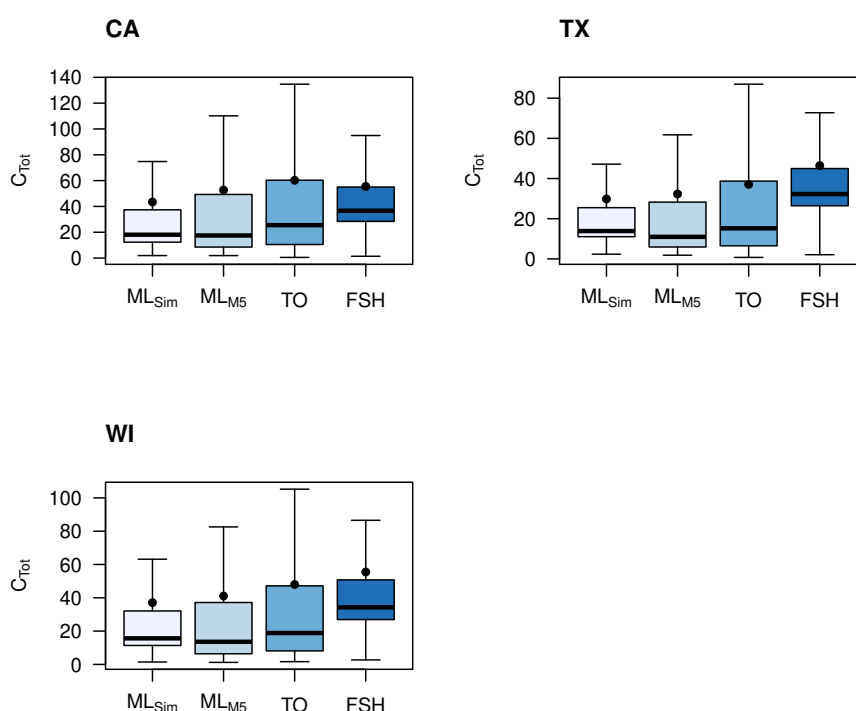
Σε αυτό το σημείο πρέπει να σχολιαστεί το γεγονός ότι συστηματικά το  $ML_{Sim}$  εμφανίζει καλύτερα αποτελέσματα από το  $ML_{M5}$ . Ο λόγος για τον οποίο το  $ML_{Sim}$  (μοντέλα που εκπαιδεύονται με τεχνητά δεδομένα) αποδίδει καλύτερα από τα  $ML_{M5}$  (μοντέλα που εκπαιδεύονται με τα ίδια δεδομένα που προβλέπονται) μπορεί να αποδοθεί στο γεγονός ότι, το σύνολο δεδομένων M5 αντιπροσωπεύει τις πραγματοποιημένες πωλήσεις των προϊόντων και όχι την άνευ όρων ζήτησή τους (unconditional demand). Δεδομένου ότι το μοτίβο της άνευ όρων ζήτησης μπορεί να διαταραχθεί στην πράξη από εξάντληση των αποθεμάτων, μη βέλτιστη αναπλήρωσή τους ή καθυστερήσεις παράδοσης, το σύνολο εκπαίδευσης των μοντέλων  $ML_{M5}$  μπορεί να διακατέχεται από προκατάληψη, αναγκάζοντας σε προτάσεις οι οποίες έχουν υποτιμήσει τη ζήτηση. Επιπλέον, το σύνολο δεδομένων του M5 αποτελείται κυρίως από ομαλές (smooth) και σποραδικές (intermittent) χρονοσειρές, πράγμα που σημαίνει ότι το  $ML_{M5}$  μπορεί να παρέχει μη βέλτιστα αποτελέσματα για τις υποεκπροσωπούμενες κατηγορίες ζήτησης, ακανόνιστες (lumpy) και ασταθείς (erratic) σειρές. Αυτό δεν ισχύει για το  $ML_{Sim}$  το οποίο έχει εκπαιδευτεί με ένα ισορροπημένο σύνολο δεδομένων, όσον αφορά στις κατηγορίες μοτίβων ζήτησης, λαμβάνοντας υπόψη σειρές των οποίων το μοτίβο δεν έχει διαταραχθεί. Για το σκοπό αυτό, τα μοντέλα της προσέγγισης  $ML_{Sim}$  πραγματοποιούν πιο ολοκληρωμένες γενικεύσεις και οδηγούν σε καλύτερες προτάσεις.

Όπως αναφέρθηκε στο Κεφάλαιο 7, το προτεινόμενο πλαίσιο είναι ανεξάρτητο από την πολιτική αποθεματοποίησης που χρησιμοποιείται. Για να επεξηγηθεί αυτό το χαρακτηριστικό, τα προηγούμενα πειράματα επαναλήφθηκαν χρησιμοποιώντας την πολιτική (s, S), μια ειδική περίπτωση της πολιτικής (R, s, S). Σύμφωνα με την πολιτική



Σχήμα 8.6: Απόδοση των εξεταζόμενων στρατηγικών διαχείρισης αποθεμάτων (προσεγγίσεις του MOIC και σημεία αναφοράς), όπου τα “κουτιά” αντιπροσωπεύουν την κατανομή του συνολικού κόστους αποθεματοποίησης ανά κατηγορία προτύπου ζήτησης.

( $s, S$ ), όπως παρουσιάστηκε αναλυτικά στο Υποκεφάλαιο 2.10, το απόθεμα παρακολουθείται καθημερινά και μπορεί να πραγματοποιηθεί μία παραγγελία ανά πάσα στιγμή. Αυτή η πολιτική είναι ιδιαίτερα δημοφιλής μεταξύ των λιανοπωλητών, καθώς είναι πιο εύκολο να βελτιστοποιηθεί και επιτρέπει την άμεση τοποθέτηση παραγγελιών. Επομένως, όταν πρόκειται για το προτεινόμενο μεθοδολογικό πλαίσιο, η διαδικασία βελτιστοποίησης της πολιτικής ( $s, S$ ) είναι παρόμοια με αυτή που διεξάγεται για την πολιτική ( $R, s, S$ ), με την εξαίρεση ότι οι υπερπαραμέτροι της πολιτικής αποθεματοποίησης του πρώτου είναι λιγότερες σε πλήθος, μιας και δεν χρειάζεται να βελτιστοποιηθεί το  $R$ . Τα αποτελέσματα των εν λόγω πειραμάτων παρουσιάζονται στον Πίνακα 8.4. Όπως φαίνεται, τα βασικά ευρήματά της παρούσας διατριβής, που προέκυψαν από τα πειράματα της πολιτικής ( $R, s, S$ ), συμφωνούν με αυτά που προέκυψαν από την πολιτική ( $s, S$ ). Αυτό επαληθεύει το γεγονός ότι το προτεινόμενο πλαίσιο μπορεί πράγματι να εφαρμοστεί με επιτυχία σε διαφορετικές πολιτικές αποθεματοποίησης. Εξίσου σημαντικό είναι το ότι αυτή η ιδιότητα του MOIC επιτρέπει την πραγματοποίηση γρήγορων συγκρίσεων μεταξύ διαφορετικών πολιτικών, δηλαδή την επιλογή της καταλληλότερης πολιτικής πέρα από την επιλογή των βέλτιστων υπερπαραμέτρων ανά πολιτική. Η μόνη αξιοσημείωτη διαφορά μεταξύ του Πίνακα 8.1 και του Πίνακα 8.4 είναι ότι οι βελτιώσεις σε σχέση με το σημείο αναφοράς  $TO$  είναι σημαντικά μικρότερες. Αυτό συμβαίνει καθώς στην πολιτική ( $s, S$ ) οι υπερπαραμέτροι, και κατά συνέπεια οι εναλλακτικές λύσεις, είναι λιγότερες, κάτι που σημαίνει ότι η εργασία που ανατίθεται στα μοντέλα είναι πολύ πιο απλή και, ως εκ τούτου,



Σχήμα 8.7: Απόδοση των εξεταζόμενων στρατηγικών διαχείρισης αποθεμάτων (προσεγγίσεις του MOIC και σημεία αναφοράς), όπου τα “κουτιά” αντιπροσωπεύουν την κατανομή του συνολικού κόστους αποθεματοποίησης ανά αποθήκη/πολιτεία των ΗΠΑ.


το περιθώριο βελτίωσης σχετικά μικρότερο.

Πίνακας 8.4: Απόδοση των εξεταζόμενων στρατηγικών διαχείρισης αποθεμάτων (προσεγγίσεις του MOIC και σημεία αναφοράς) ως προς το συνολικό κόστος αποθεματοποίησης και το επίπεδο εξυπηρέτησης πελατών. Τα αποτελέσματα αναφέρονται στις 8.504 σειρές του συνόλου δεδομένων M5, έχοντας χρησιμοποιήσει την πολιτική (s, S).

Προσέγγιση	$C_H$	$C_{LS}$	$C_O$	$C_{Tot}$	$\overline{SL}$
$ML_{M5}$	39,582	438,810	254,818	733,210	0.96
$ML_{Sim}$	40,242	440,578	<b>252,227</b>	<b>733,047</b>	0.96
TO	27,138	<b>364,314</b>	344,048	735,500	0.96
FSH	<b>4,611</b>	421,083	910,814	1,336,508	0.96

Ως ένα επιπλέον βήμα στην παρούσα ανάλυση των αποτελεσμάτων του προτεινόμενου μεθοδολογικού πλαισίου, εξετάζεται η εξοικονόμηση που μπορεί αυτό να προσφέρει όσον αφορά στον υπολογιστικό χρόνο σε σχέση με κλασικές τεχνικές βελτιστοποίησης των πολιτικών διαχείρισης των αποθεμάτων. Δεδομένου ότι οι παραδοσιακές βελτιστοποιήσεις ελέγχου αποθέματος μπορούν να γίνουν ιδιαίτερα εντατικές, το υπολογιστικό κόστος δεν πρέπει να αγνοηθεί, ειδικά όταν εκτελείται για χιλιάδες ή εκατομμύρια είδη σε τακτική βάση, όπως αναφέρθηκε και στο Υποκεφάλαιο 2.12.

Το Σχήμα 8.8 απεικονίζει τον χρόνο που απαιτείται για την προσομοίωση της



Σχήμα 8.8: Απαιτούμενος χρόνος βελτιστοποίησης της διαδικασίας αποθεματοποίησης για 850 προϊόντα χρησιμοποιώντας προσομοιώσεις και χρησιμοποιώντας το προτεινόμενο μεθοδολογικό πλαίσιο.

λειτουργίας μιας αποθήκης 850 ειδών σε πολλαπλά σει (έως 9.000) υπερπαραμέτρων πολιτικής αποθεματοποίησης, είτε εφαρμόζοντας την αντίστοιχη πολιτική αποθεματοποίησης απευθείας στο ιστορικά δεδομένα ή χρησιμοποιώντας το πλαίσιο MOIC. Είναι εμφανές ότι όταν οι δοκιμές είναι εξαντλητικές (850 σειρές  $\times$  9.000 σει υπερπαραμέτρων), οι παραδοσιακές προσομοιώσεις ολοκληρώνονται μετά από 28 ημέρες. Αντίθετα, οι εκτιμήσεις του MOIC ολοκληρώνονται σε λιγότερο από 12 ώρες. Ως αποτέλεσμα, προσεγγίζοντας τη βέλτιστη στρατηγική διαχείρισης αποθεμάτων μέσω του MOIC είναι περίπου 70 φορές ταχύτερο από τη διεξαγωγή προσομοιώσεων, γεγονός που συνεπάγεται σημαντική εξοικονόμηση υπολογιστικών πόρων. Οι υπολογιστικοί χρόνοι υπολογίστηκαν χρησιμοποιώντας ένα σύστημα με τα εξής χαρακτηριστικά: 4 πυρήνες (cores) και 8 λογικούς επεξεργαστές (logical processors) στα 3,60 GHz, 16 GB RAM, 1 TB HDD, Microsoft Windows 10.

Ο λόγος για τον οποίο προκύπτουν οι σημαντικές διαφορές που αναφέρθηκαν ως προς τον χρόνο υπολογισμού μεταξύ του προτεινόμενου μεθοδολογικού πλαισίου και της μεθόδου προσομοίωσης είναι ότι η πρώτη βασίζεται σε προεκπαιδευμένα και λειτουργικά μοντέλα. Μόλις εκπαιδευτεί ένα μοντέλο ML, η εξαγωγή αποτελεσμάτων μπορεί να εκτελεστεί ιδιαίτερα γρήγορα, υπερτερώντας υπολογιστικά κάθε μεθόδου προσομοίωσης, ίσου αριθμού επαναλήψεων. Το συγκεκριμένο εύρημα επισημαίνει ότι μόλις ολοκληρωθεί η off-line φάση του MOIC, έχοντας εκπαιδεύσει τα μοντέλα με το ίδιο ή κάποιο άλλο σύνολο δεδομένων, ο χρόνος που απαιτείται για την εκτίμηση του συνολικού κόστους αποθεματοποίησης, για οποιοδήποτε σει υπερπαραμέτρων πολιτικής αποθεματοποίησης και χρονοσειρά, είναι σημαντικά μικρότερος από τη διεξαγωγή μιας προσομοίωσης, καθιστώντας το προτεινόμενο πλαίσιο ένα ισχυρό εργαλείο τόσο για τη δοκιμή διαφόρων σεναρίων όσο και για τον εντοπισμό σχεδόν βέλτιστων τιμών.

Συνοπτικά η μελέτη των αποτελεσμάτων στο συγκεκριμένο δείγμα δεδομένων και βάσει

των επιλεγμένων τιμών για τις μεταβλητές του προτεινόμενου μεθοδολογικού πλαισίου μας οδηγεί στα παρακάτω βασικά συμπεράσματα :

- Η προτεινόμενη μεθοδολογία δύναται να χρησιμοποιηθεί για τη βελτιστοποίηση μιας πολιτικής αποθεματοποίησης.
- Η προτεινόμενη μεθοδολογία παρουσιάζει εξαιρετικά σταθερά αποτελέσματα ανεξάρτητα από τα μοτίβα ζήτησης που εμφανίζονται στις χρονοσειρές στόχο και πιθανές διαφορές μεταξύ των αποθηκών που ελέγχθηκαν, με συνέπεια ότι μπορεί να χρησιμοποιηθεί από πληθώρα εταιρειών λιανικής.
- Η εκπαίδευση των μοντέλων μηχανικής μάθησης της προτεινόμενης μεθοδολογίας με “πραγματική” ζήτηση προσδίδει αξία έναντι στην εκπαίδευσή τους με δεδομένα πωλήσεων.
- Η εκπαίδευση των μοντέλων με ένα πιο πλήρες σύνολο δεδομένων από τις χρονοσειρές στόχου είναι ευεργετική ως προς τα αποτελέσματα.
- Αφού έχουν εκπαιδευτεί τα μοντέλα της μεθοδολογίας, η βελτιστοποίηση μιας πολιτικής αποθεματοποίησης μπορεί να πραγματοποιηθεί σε σημαντικά μικρό χρονικό διάστημα.
- Με την εφαρμογή της προτεινόμενης μεθοδολογίας το συνολικό κόστος αποθεματοποίησης μπορεί να μειωθεί σημαντικά, διατηρώντας το επίπεδο εξυπηρέτησης πελατών σε υψηλά επίπεδα.

## **8.4 Ακρίβεια προβλέψεων και συνολικό κόστος αποθεματοποίησης**

Έχοντας ολοκληρώσει τον έλεγχο της απόδοσης του προτεινόμενου πλαισίου σε πραγματικά δεδομένα, στο συγκεκριμένο Υποκεφάλαιο πραγματοποιείται μία προσπάθεια σύγκρισης της βελτίωσης που μπορεί να επιφέρει μια αλλαγή της μεθόδου πρόβλεψης της ζήτησης στο κόστος αποθεματοποίησης και το επίπεδο εξυπηρέτησης πελατών σε σχέση με τη βελτίωση που συνεπάγεται η βελτιστοποίηση των παραμέτρων της χρησιμοποιούμενης πολιτικής αποθεματοποίησης. Με τον τρόπο αυτό, γίνεται μία προσπάθεια να δοθεί μία απάντηση στην εξής εύλογη απορία: “είναι προτιμότερο να προσπαθήσω να βρω τη μέθοδο με τη μεγαλύτερη ακρίβεια ή να προσαρμόσω τη πολιτική αποθεματοποίησης που χρησιμοποιώ;”

Για τη διαδικασία αυτή, πραγματοποιήθηκαν προσομοιώσεις ελέγχου του αποθέματος κατά τις οποίες, εκτός από τη μέθοδο Croston, χρησιμοποιήθηκαν οι μέθοδοι ADIDA, ETS, iMAPA, SNaive και TSB για τις ανάγκες πρόβλεψης της ζήτησης και οι στατιστικοί δείκτες απόδοσης ME, MAE, RMSE και RMSSE, όπως αναλύθηκαν στα Υποκεφάλαια 4.2 και 4.5 αντίστοιχα. Έτσι, για το τελευταίο έτος του συνόλου των 8504 χρονοσειρών του M5, οι οποίες χρησιμοποιήθηκαν σε ολόκληρη τη πειραματική διαδικασία, χρησιμοποιήθηκαν στις προσομοιώσεις οι υπερπαραμέτροι πολιτικής αποθεματοποίησης του benchmark *FSH* και

της προσέγγισης μεταφοράς μάθησης του MOIC,  $ML_{Sim}$ , με σκοπό να ποσοτικοποιηθεί ως προς το απόθεμα η αλλαγή της μεθόδου πρόβλεψης σε δυο σενάρια, ένα αφελές -μη βέλτιστο- και ένα σχεδόν βέλτιστο. Κατά συνέπεια, προέκυψαν 102.048 ημερήσιες προσομοιώσεις ελέγχου αποθέματος (8.504 σειρές  $\times$  2 προσεγγίσεις  $\times$  6 μέθοδοι πρόβλεψης) στις οποίες, για κάθε χρονοσειρά, ανάλογα τις υπερπαραμέτρους πολιτικής αποθεματοποίησης κάθε φορά προβλεπόταν η ζήτηση με μία εκ των μεθόδων πρόβλεψης.


Να σημειωθεί εδώ ότι ο ορίζοντας πρόβλεψη, και κατά συνέπεια το σφάλμα πρόβλεψης εξαρτάται από τις υπερπαραμέτρους πολιτικής αποθεματοποίησης. Κατά συνέπεια, αν και οι δύο προσεγγίσεις αναφέρονται σε χρονικό διάστημα ενός έτους και για τις ίδιες σειρές, το γεγονός ότι οι προβλέψεις υπολογίζονται σε διαφορετικές στιγμές μέσα στο χρόνο και αφορούν σε διαφορετικό πλήθος ημερών ανά προσέγγιση και χρονοσειρά αποδεικνύει ότι τα αποτελέσματα των σφαλμάτων δεν μπορούν να συγκριθούν όταν αυτά αφορούν σε διαφορετική προσέγγιση ( $FSH$  και  $ML_{Sim}$ ), πάρα μόνο όταν αφορούν σε μεθόδους της ίδιας προσέγγισης. Αυτό, όμως, δεν ισχύει για το συνολικό κόστος αποθεματοποίησης, τα επιμέρους κόστη, και το επίπεδο εξυπηρέτησης πελατών.

Τα αποτελέσματα αυτής της εξαντλητικής πειραματικής διαδικασίας παρουσιάζονται στον Πίνακα 8.5.

Πίνακας 8.5: Απόδοση των εξεταζόμενων στρατηγικών διαχείρισης αποθεμάτων και μεθόδων πρόβλεψης ως προς την ακρίβεια προβλέψεων, το συνολικό κόστος αποθεματοποίησης και το επίπεδο εξυπηρέτησης πελατών.

Προσέγγιση	Μέθοδος	ME	MAE	RMSE	RMSSE	$C_H$	$C_{LS}$	$C_O$	$C_{Tot}$	$\overline{SL}$
$FSH$	ADIDA	-0.141	2.08	2.82	0.871	10882	191970	185584	388436	0.979
	Croston	-0.239	2.34	3.04	0.914	10820	246502	188850	446172	0.974
	ETS	0.014	2.11	2.84	0.873	<b>10328</b>	226865	185667	422861	0.977
	iMAPA	-0.158	2.08	2.81	0.869	10953	185968	182395	379316	0.980
	SNaive	<b>0.010</b>	2.65	3.74	1.180	10643	295309	<b>156961</b>	462913	0.972
	TSB	-0.141	<b>2.06</b>	<b>2.80</b>	<b>0.867</b>	10938	<b>174155</b>	181155	<b>366248</b>	<b>0.981</b>
$ML_{Sim}$	ADIDA	<b>0.001</b>	<b>2.06</b>	<b>2.81</b>	<b>0.859</b>	<b>26914</b>	194120	57048	278082	<b>0.981</b>
	Croston	-0.165	2.27	2.96	0.891	27745	213850	57433	299027	0.980
	ETS	<b>0.001</b>	2.16	2.92	0.876	26996	201097	57054	285146	0.980
	iMAPA	-0.002	<b>2.06</b>	2.82	<b>0.859</b>	26957	195138	56644	278739	<b>0.981</b>
	SNaive	-0.009	2.70	3.78	1.184	27436	260194	<b>53333</b>	340963	0.971
	TSB	-0.005	2.07	2.83	0.864	26943	<b>192632</b>	56261	<b>275835</b>	<b>0.981</b>

Όπως φαίνεται χαρακτηριστικά στο Σχήμα 8.9 η επιλογή της Croston δεν είναι η καλύτερη δυνατή. Και στις δύο περιπτώσεις, οι μέθοδοι ADIDA, iMAPA, TSB και ETS αποδίδουν καλύτερα από την Croston τόσο σε επίπεδο κόστους όσο και ακρίβειας προβλέψεων. Από την άλλη, η μέθοδος SNaive, εμφανίζει τη χειρότερη απόδοση και στις δύο κατηγορίες δεικτών. Ωστόσο, η σχέση ακρίβειας προβλέψεων και συνολικού κόστους αποθεματοποίησης δεν φαίνεται να είναι γραμμική. Δηλαδή, βάσει αποτελεσμάτων, και στις δύο προσεγγίσεις, μία μείωση του σφάλματος δεν συνεπάγεται κάποια πολλαπλάσια μείωση του κόστους.



Σχήμα 8.9: Απεικόνιση του  $RMSSE$  ως προς το  $C_{Tot}$  των εξεταζόμενων μεθόδων πρόβλεψης κατά την προσέγγιση του  $FSH$  (επάνω) και του  $ML_{Sim}$  (κάτω).


Κατά τη χρήση των υπερπαραμέτρων της προσέγγισης  $FSH$ , αν και η μεγάλη διαφορά ακρίβειας πρόβλεψης μεταξύ Croston και SNaive δεν δημιουργεί τόσο μεγάλη διαφορά στο κόστος, παρατηρείται ότι γενικά η βελτίωση της ακρίβειας πρόβλεψης μειώνει το κόστος, με τη μέθοδο που έχει το μικρότερο σφάλμα (TSB) να εμφανίζει και το μικρότερο συνολικό κόστος αποθεματοποίησης. Η συγκεκριμένη μείωση σε σχέση με τη Croston αγγίζει το 5% στο  $RMSSE$  και 18% στο  $C_{Tot}$ . Εντυπωσιακό, παράλληλα, είναι το γεγονός ότι η ETS, αν και 4.5% καλύτερη από την Croston όσον αφορά στο  $RMSSE$ , και αρκετά κοντά στην TSB, έχει μόλις 5% μικρότερο  $C_{Tot}$  από την Croston. Από την άλλη, συγκρίνοντας τη Croston με την SNaive φαίνεται ότι στην συγκεκριμένη περίπτωση χειρότερη ακρίβεια κατά 29% μεταφράζεται σε μία ισχνή αύξηση του κόστους κατά 4%.

Κατά τη χρήση των υπερπαραμέτρων της προσέγγισης  $ML_{Sim}$ , προκύπτει μια διαφορετική εικόνα. Ενώ όσο μικραίνει το σφάλμα σε σχέση με τη Croston μικραίνει και το κόστος, παρατηρείται ότι οι δυο καλύτερες προβλεπτικά μέθοδοι (ADIDA και iMAPA) δεν εμφανίζουν και το μικρότερο κόστος, το οποίο έχει υπολογιστεί με την TSB. Επίσης, χαρακτηριστικό είναι ότι η ETS, μία πιο πολύπλοκη μέθοδος από τις υπόλοιπες, δεν εμφανίζει ούτε τις βέλτιστες προβλέψεις, γεγονός που έρχεται να συμφωνήσει με τη βιβλιογραφία, ούτε το μικρότερο κόστος αποθεματοποίησης. Σε αυτή την περίπτωση, οι μεγαλύτερες βελτιώσεις από την Croston είναι 4% όσον αφορά στο  $RMSSE$  και μόλις 8% όσον αφορά στο  $C_{Tot}$ , οι

οποίες επιτυγχάνονται με τις μεθόδους ADIDA ή iMAPA και TSB αντίστοιχα. Από την άλλη, παράγοντας προβλέψεις κατά 33% πιο ανακριβείς μπορεί να οδηγήσει σε μία σημαντική αύξηση του  $C_{Tot}$  της τάξης του 14%.

Σε κάθε περίπτωση, η εφαρμογή μιας μεθόδου με μικρό σφάλμα είναι επιθυμητή μιας και συνεπάγεται καλύτερα αποτελέσματα όσον αφορά στο κόστος αποθεματοποίησης, χωρίς όμως να είναι εφικτή η ποσοτικοποίηση αυτής της βελτίωσης και χωρίς η συγκεκριμένη σχέση να μπορεί να χαρακτηριστεί από καθολικότητα, μιας και χειρότερες προβλεπτικά μέθοδοι είναι πιθανό να παρουσιάσουν μικρότερο κόστος.


Τα αποτελέσματα του επιπέδου εξυπηρέτησης πελατών δεν έρχονται σε αντιδιαστολή με τα παραπάνω. Η μόνη διαφορά που παρατηρείται είναι ότι, βάσει αποτελεσμάτων, μια καλύτερη προβλεπτικά μέθοδος αναμένεται να επιφέρει και μεγαλύτερο επίπεδο εξυπηρέτησης, όπως φαίνεται στο Σχήμα 8.10.



Σχήμα 8.10: Απεικόνιση του RMSSE ως προς το  $\overline{SL}$  των εξεταζόμενων μεθόδων πρόβλεψης κατά την προσέγγιση του FSH (επάνω) και του  $ML_{Sim}$  (κάτω).

Συμπερασματικά, σε απόλυτη ακολουθία με τη βιβλιογραφία, τα αποτελέσματα των προσομοιώσεων υποδηλώνουν ότι οι πιο ακριβείς προβλέψεις δεν εγγυώνται πάντα την καλύτερη απόδοση του αποθέματος. Με άλλα λόγια, αν και οι ακριβείς μέθοδοι πρόβλεψης είναι πιο πιθανό να οδηγήσουν σε πιο επιθυμητά επίπεδα εξυπηρέτησης πελατών και χαμηλότερο κόστος αποθεματοποίησης, είναι ακόμα δυνατό λιγότερο εξελιγμένα μοντέλα να οδηγήσουν σε καλύτερο έλεγχο των αποθεμάτων.





Σχήμα 8.11: Ταξινόμηση του συνολικού κόστους αποθεματοποίησης όπως προέκυψε από τις εξεταζόμενες μεθόδους πρόβλεψης και στρατηγικές διαχείρισης αποθεμάτων.

Κατά τη σύγκριση των ίδιων μεθόδων όταν αυτές εφαρμόζονται σε διαφορετικές συνθήκες, δηλαδή διαφορετική πολιτική, οι βελτιώσεις είναι ακόμα μεγαλύτερες. Χαρακτηριστικά, η Croston και η TSB εμφανίζουν μικρότερο συνολικό κόστος αποθεματοποίησης κατά 33% και 25%, αντίστοιχα, όταν χρησιμοποιούνται στα πλαίσια των αποτελεσμάτων της προσέγγισης  $ML_{Sim}$  σε σχέση με τη  $FSH$ .

Είναι εμφανές ότι αν και οι υπερπαραμέτροι της πολιτικής αποθεματοποίησης της προσέγγισης  $ML_{Sim}$  βελτιστοποιήθηκαν κάνοντας χρήση της μεθόδου Croston, όταν αυτές εφαρμόζονται με μία διαφορετική μέθοδο πρόβλεψης η απόδοση του αποθέματος είναι αρκετά καλή, στην περίπτωση, προφανώς, που η επιλεγμένη μέθοδος χαρακτηρίζεται από καλή ακρίβεια παραγόμενων προβλέψεων. Επιπροσθέτως, όπως φαίνεται χαρακτηριστικά στο Σχήμα 8.11 ακόμα και η μέθοδος με το χαμηλότερο συνολικό κόστος αποθεματοποίησης της προσέγγισης  $FSH$  παρουσιάζει μεγαλύτερο κόστος από τη χειρότερη μέθοδο, όσον αφορά το κόστος, της προσέγγισης  $ML_{Sim}$ . Με άλλα λόγια σύμφωνα με τις προσομοιώσεις, η μείωση του συνολικού κόστους αποθεματοποίησης που συνεπάγεται η αλλαγή σε μία μέθοδο με μικρότερο σφάλμα, διατηρώντας ίδιες τις παραμέτρους της πολιτικής αποθεματοποίησης είναι μικρότερη από τη μείωση που συνεπάγεται η αλλαγή των εν λόγω παραμέτρων.

Πιο αναλυτικά, σε ένα περιβάλλον μη βελτιστοποιημένων παραμέτρων πολιτικής αποθεματοποίησης, παρατηρείται ότι, η αλλαγή της μεθόδου πρόβλεψης σε μία μέθοδο η οποία εμφανίζει βελτιωμένη ακρίβεια μπορεί να οδηγήσει σε μείωση του συνολικού κόστους αποθεματοποίησης της τάξης του 18%, ενώ η βελτιστοποίηση των παραμέτρων, διατηρώντας σταθερή τη μέθοδο πρόβλεψης μπορεί να οδηγήσει σε μείωση του συνολικού κόστους της τάξης του 33%. Επιπρόσθετα, παρατηρείται ότι, σε ένα περιβάλλον σχεδόν βέλτιστων παραμέτρων η αλλαγή της μεθόδου πρόβλεψης επιφέρει μικρότερη βελτίωση από ότι σε ένα περιβάλλον μη βελτιστοποιημένων παραμέτρων.

Κατά συνέπεια, μπορεί να δοθεί μία απάντηση στο ερώτημα που διατυπώθηκε στην αρχή του Υποκεφαλαίου, σχετικά με το αν είναι προτιμότερη η εύρεση της μεθόδου με τη μεγαλύτερη ακρίβεια ή η προσαρμογή της πολιτικής αποθεματοποίησης. Παρά το γεγονός ότι και τα δύο σενάρια είναι σε θέση να βελτιώσουν το συνολικό κόστος αποθεματοποίησης και το επίπεδο εξυπηρέτησης, ο εντοπισμός και η υιοθέτηση βέλτιστων ή σχεδόν βέλτιστων παραμέτρων της εφαρμοζόμενης πολιτικής αποθεματοποίησης ενδέχεται να εμφανίσει τη μεγαλύτερη βελτίωση.

Συνοπτικά η μελέτη των αποτελεσμάτων στο συγκεκριμένο δείγμα δεδομένων, βάσει των επιλεγμένων τιμών για τις μεταβλητές του προτεινόμενου μεθοδολογικού πλαισίου και των επιλεγμένων μεθόδων πρόβλεψης της ζήτησης μας οδηγεί στα παρακάτω βασικά συμπεράσματα:

- Είναι πιθανό διαφορετικές μέθοδοι προβλέψεις να παρουσιάζουν τη μεγαλύτερη ακρίβεια όταν εξετάζονται οι ίδιες χρονοσειρές αλλά διαφορετικές ρυθμίσεις, υπό την έννοια της χρονικής στιγμής που παράγονται οι εν λόγω προβλέψεις και του ορίζοντα πρόβλεψης.
- Η βελτίωση της ακρίβειας των παραγόμενων προβλέψεων είναι πάντα ωφέλιμη.
- Η βελτίωση της ακρίβειας των παραγόμενων προβλέψεων δεν συνεπάγεται πάντα τη μείωση του συνολικού κόστους αποθεματοποίησης.
- Η βελτίωση της ακρίβειας των παραγόμενων προβλέψεων έχει μικρότερη σημασία όταν η πολιτική αποθεματοποίησης είναι ήδη βελτιστοποιημένη.
- Τα οφέλη που προκύπτουν από τη βελτιστοποίηση της πολιτικής αποθεματοποίησης υπερτερούν των οφελών που προκύπτουν από τη βελτίωση της ακρίβειας των προβλέψεων.

## 8.5 Ευαισθησία του συνολικού κόστους αποθεματοποίησης ως προς τους παράγοντες που το διαμορφώνουν

Ενδιαφέρον εμφανίζει η επίπτωση των υπερπαραμέτρων κόστους αποθέματος στο συνολικό κόστος αποθεματοποίησης. Όπως αναλύθηκε στο Υποκεφάλαιο 7.1, το συνολικό κόστος αποθεματοποίησης, στην παρούσα διατριβή, αποτελείται από το κόστος διατήρησης αποθεμάτων, το κόστος έλλειψης αποθεμάτων και το κόστος τοποθέτησης παραγγελιών, με αποτέλεσμα το συνολικό κόστος ενός προϊόντος  $i$  να υπολογίζεται από τον εξής τύπο:

$$C_{Tot}^i = \frac{h}{T} \sum_{t=1}^T I_{i,t} p_i + b \sum_{t=1}^T LS_{i,t} p_i + k \sum_{t=1}^T NO_{i,t}$$

Οι όροι  $I$ ,  $LS$  και  $NO$  μπορούν να προκύψουν από τις προσομοιώσεις αποθέματος που πραγματοποιούνται κάθε φορά, ενώ από την άλλη, οι όροι  $h$ ,  $k$ ,  $b$  και  $p$  δεν επηρεάζονται από τις προσομοιώσεις, αλλά στην ουσία αποτελούν μεταβλητές. Έτσι, παρά το γεγονός ότι στην παρούσα διατριβή πραγματοποιήθηκε μία τεκμηριωμένη επιλογή τιμών για τους

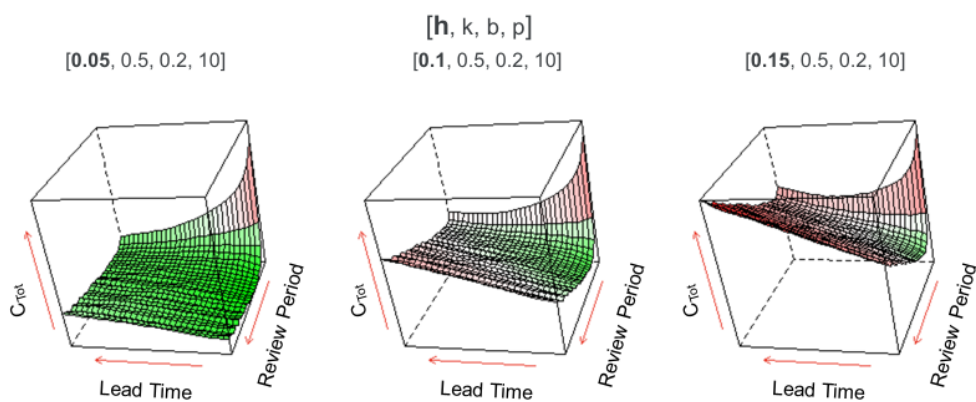
συγκεκριμένους όρους, μπορούν να πάρουν οποιαδήποτε τιμή, εντός κάποιων λογικών πλαισίων, αντικατοπτρίζοντας τον τρόπο λειτουργίας της επιχείρησης καθώς και τα χαρακτηριστικά του προϊόντος που εξετάζεται. Για τον λόγο αυτό, όπως αναλύθηκε και στο Κεφάλαιο 7, οι όροι  $h$ ,  $k$ ,  $b$  και  $p$  ονομάστηκαν υπερπαραμέτροι του πλαισίου. Η μεταβολή των τιμών που λαμβάνουν οι εν λόγω υπερπαραμέτροι, καθώς και η αλλαγή των παραμέτρων της πολιτικής αποθεματοποίησης που χρησιμοποιείται στις προσομοιώσεις, δηλαδή η αλλαγή των  $R$ ,  $L$  ή  $TSL$ , επιφέρουν αλλαγές στο συνολικό κόστος αποθεματοποίησης ( $C_{Tot}$ ).

Ακολούθως παρουσιάζεται το  $C_{Tot}$  σε σχέση με το  $L$  και το  $R$ , έχοντας επιλέξει την τιμή 0.95 για το  $TSL$ , όπου κάθε φορά μεταβάλλεται μια εκ των υπερπαραμέτρων  $h$ ,  $k$ ,  $b$  ή  $p$ , ενώ διατηρούνται σταθερές οι υπόλοιπες. Οι τρισδιάστατοι χώροι που προκύπτουν αφορούν στη μέση τιμή των αποτελεσμάτων των προσομοιώσεων των τεχνητών χρονοσειρών, που χρησιμοποιήθηκαν για την προσέγγιση της μεταφοράς μάθησης του πλαισίου της παρούσας διατριβής.


Στο Σχήμα 8.12 απεικονίζονται οι τρισδιάστατοι χώροι που δημιουργούνται ( $C_{Tot} - L - R$ ) για το σύνολο των σειρών, όπου, όπως αναφέρθηκε το  $TSL$  παραμένει σταθερό, όπως επίσης σταθερές παραμένουν οι τιμές  $k$ ,  $b$  και  $p$ , ενώ μεταβάλλεται η υπερπαραμέτρος κόστους αποθέματος  $h$ , η οποία αποτελεί το κόστος διατήρησης μιας μονάδας προϊόντος ως ποσοστό της αξίας του προϊόντος. Φαίνεται χαρακτηριστικά ότι όσο το  $h$  αυξάνεται, το  $C_{Tot}$  αυξάνει σημαντικά στις περιπτώσεις όπου εμφανίζονται μεγάλα  $R$  και  $L$ , ενώ παραμένει σχεδόν σταθερό όταν τα μεγέθη αυτά λαμβάνουν μικρές τιμές. Αυτό συμβαίνει καθώς όταν παρεμβάλλεται μεγάλο χρονικό διάστημα μεταξύ των ελέγχων του αποθέματος, και κατά συνέπεια των παραγγελιών προς τους προμηθευτές, και οι προμηθευτές καθυστερούν αρκετά να παραδώσουν τις παραγγελίες, αναμένεται και το μέσο διαθέσιμο απόθεμα ( $\bar{I}$ ) να είναι αυξημένο, καθιστώντας το κόστος διατήρησης αποθεμάτων το κυρίαρχο κόστος αποθεματοποίησης. Έτσι, όταν αυξάνεται το  $h$ , στα σημεία όπου αναμένεται μεγάλο  $\bar{I}$ , αυξάνεται σημαντικά το συνολικό κόστος αποθεματοποίησης.

Αντίθετα, όπως φαίνεται στο Σχήμα 8.13, όσο αυξάνεται το  $k$ , δηλαδή το κόστος πραγματοποίησης μιας παραγγελίας, το  $C_{Tot}$  επηρεάζεται περισσότερο στις περιπτώσεις όπου εμφανίζονται μικρές τιμές  $R$  και  $L$ . Αυτό είναι απόρροια του γεγονότος ότι όταν το απόθεμα ελέγχεται συχνά, και μπορούν επίσης συχνά να τοποθετούνται παραγγελίες προς τους προμηθευτές, ενώ οι προμηθευτές με τη σειρά τους δεν καθυστερούν να εξυπηρετήσουν τις παραγγελίες, αναμένεται να αυξάνεται και το πλήθος των παραγγελιών προς τους προμηθευτές, αυξάνοντας, έτσι, τον όρο  $NO$  και κατ'επέκταση το κόστος τοποθέτησης παραγγελιών. Έτσι, όταν αυξάνεται το  $k$ , στα σημεία όπου αναμένεται μεγάλο  $NO$ , αυξάνεται σημαντικά το συνολικό κόστος αποθεματοποίησης.

Παρόμοιες μεταβολές με το  $k$  επιφέρει στο συνολικό κόστος και η αύξηση του ποσοστιαίου κόστους έλλειψης  $b$ , όπως φαίνεται στο Σχήμα 8.14. Το  $C_{Tot}$ , έτσι, αυξάνει περισσότερο όταν οι τιμές των  $R$  και  $L$  είναι μικρές, με τη προσθήκη ότι ολόκληρος ο χώρος τείνει να μετακινείται προς τα πάνω όσο μεγαλώνει το  $b$ , ανεξάρτητα από τα  $R$  και  $L$ . Αυτό συμβαίνει καθώς μέρος της ζήτησης είναι πιθανό να μην εξυπηρετηθεί ανεξάρτητα από το πόσο συχνά ελέγχεται το απόθεμα ή πόσο καθυστερεί να παραδοθεί μία παραγγελία από τους προμηθευτές, αλλά λόγω του μοτίβου και της αβεβαιότητας της ζήτησης. Έτσι, μία




Σχήμα 8.12: Επίπτωση της μεταβολής της υπερπαραμέτρου κόστους αποθέματος  $h$  στο συνολικό κόστος αποδεματοποίησης.



Σχήμα 8.13: Επίπτωση της μεταβολής της υπερπαραμέτρου κόστους αποθέματος  $k$  στο συνολικό κόστος αποδεματοποίησης.

αύξηση του  $b$  έχει επίπτωση στο  $C_{Tot}$  σε όλες τις περιπτώσεις του χώρου, η οποία είναι πιο αισθητή εκεί όπου είναι πιο πιθανό να προκύψουν ελλείψεις αποθέματος.

Στην περίπτωση όπου αυξάνεται το  $p$ , δηλαδή η αξία του προϊόντος, όπως φαίνεται στο




Σχήμα 8.14: Επίπτωση της μεταβολής της υπερπαραμέτρου κόστους αποθέματος  $b$  στο συνολικό κόστος αποθεματοποίησης.

Σχήμα 8.15 παρατηρείται μία γενική μετατόπιση του επιπέδου του  $C_{Tot}$  σε όλα τα σημεία του χώρου, με μια ακόμη μεγαλύτερη αύξηση τόσο για μικρές όσο και μεγάλες τιμές  $R$  και  $L$ . Αυτό συμβαίνει καθώς η μεταβλητή  $p$  επηρεάζει τόσο το κόστος διατήρησης αποθεμάτων όσο και το κόστος έλλειψης αποθεμάτων, τα στοιχεία των οποίων,  $\bar{I}$  και  $LS$ , είναι πιθανό να επιβαρύνονται περισσότερο για μεγάλες τιμές  $R$  και  $L$  και μικρές τιμές αντίστοιχα.


Από τα παραπάνω εξάγεται το συμπέρασμα ότι, εφόσον το συνολικό κόστος αποθεματοποίησης ορίζεται με τον τρόπο που έχει ορισθεί στην παρούσα διατριβή, μία εταιρεία μπορεί στη γενική περίπτωση να αποκλείσει κάποιους συνδυασμούς τιμών  $R$  και  $L$  εφόσον είναι σε θέση να γνωρίζει με σχετική ακρίβεια τις τιμές των υπερπαραμέτρων  $h$ ,  $k$ ,  $b$  και  $p$ . Ωστόσο, όταν εξετάζεται και η υπερπαραμέτρος πολιτικής αποθεματοποίησης  $TSL$ , σε συνδυασμό και με το μοτίβο των διαθέσιμων χρονοσειρών, τα εν λόγω συμπεράσματα περιπλέκονται.

Όπως είναι αναμενόμενο, το συνολικό κόστος αποθεματοποίησης επηρεάζεται τόσο από τις συνθήκες λειτουργίας της εταιρείας, όσο και από τη ζήτηση, δηλαδή τα μοτίβα των χρονοσειρών. Για το λόγο αυτό, στη συνέχεια, παρατίθενται τρισδιάστατοι χώροι, οι οποίοι παρουσιάζουν το  $C_{Tot}$  σε σχέση με το  $L$  και το  $R$ , έχοντας επιλέξει σταθερές τιμές για τις υπερπαραμέτρους κόστους ( $h = 0.1, k = 0.5, b = 0.2, p = 10$ ), όπου κάθε φορά μεταβάλλεται η τιμή του  $TSL$  και το μοτίβο ζήτησης. Οι τρισδιάστατοι χώροι που προκύπτουν αφορούν στη μέση τιμή των αποτελεσμάτων των προσομοιώσεων των τεχνητών χρονοσειρών μίας εκ των τεσσάρων κατηγοριών ζήτησης κάθε φορά.

Εκ πρώτης όψεως, φαίνεται ότι για τις ίδιες υπερπαραμέτρους κόστους και τα ίδια επίπεδα εξυπηρέτησης στόχου, το συνολικό κόστος αποθεματοποίησης επηρεάζεται διαφορετικά από την αλλαγή του χρόνου παράδοσης και της περιόδου ελέγχου του




Σχήμα 8.15: Επίπτωση της μεταβολής της υπερπαραμέτρου κόστους αποθέματος  $p$  στο συνολικό κόστος αποδεδαιτοποίησης.



Σχήμα 8.16: Επίπτωση της μεταβολής της υπερπαραμέτρου πολιτικής αποδεδαιτοποίησης TSL στο συνολικό κόστος αποδεδαιτοποίησης για σειρές της κατηγορίας erratic.

αποθέματος, όταν εξετάζονται διαφορετικά μοτίβα ζήτησης. Όπως χαρακτηριστικά φαίνεται στα Σχήματα 8.16, 8.17, 8.18, 8.19, στη μέση περίπτωση οι lumpy και intermittent χρονοσειρές τείνουν να δημιουργούν μικρότερο συνολικό κόστος σε μεγάλες τιμές  $R$  και  $L$




Σχήμα 8.17: Επίπτωση της μεταβολής της υπερπαραμέτρου πολιτικής αποθεματοποίησης  $TSL$  στο συνολικό κόστος αποθεματοποίησης για σειρές της κατηγορίας *lumpy*.

από ότι οι *erratic* και οι *smooth*.


Όπως αναφέρθηκε, όχι μόνο τα χαρακτηριστικά των χρονοσειρών, αλλά και το επίπεδο εξυπηρέτησης στόχος επηρεάζει το συνολικό κόστος. Παρατηρείται ότι για όλες τις κατηγορίες μοτίβων ζήτησης, ένα μεγαλύτερο  $TSL$  συνεπάγεται ένα σχετικά μικρότερο κόστος. Ωστόσο, αυτό μπορεί να υποστηριχτεί μόνο για το επιλεγμένο σύνολο υπερπαραμέτρων κόστους αποθεματοποίησης,  $h$ ,  $k$ ,  $b$  και  $p$ . Στην περίπτωση όπου, το  $b$ , το οποίο επιβαρύνει το κόστος χαμένων πωλήσεων είναι μικρότερο από 0.2 και το  $h$  που επιβαρύνει το κόστος διατήρησης αποθεμάτων είναι μεγαλύτερο από 0.1, είναι αρκετά πιθανό το παραπάνω συμπέρασμα να είναι εντελώς λανθασμένο, μιας και ένα μεγαλύτερο  $TSL$ , συνεπάγεται λιγότερες χαμένες πωλήσεις, αλλά μεγαλύτερο μέσο απόθεμα.

Από τα παραπάνω γίνεται ακόμα πιο ξεκάθαρη η πολυπλοκότητα που εμπεριέχει η βελτιστοποίηση της διαδικασίας αποθεματοποίησης, καθώς και η αναγκαιότητα δημιουργίας παραμετροποιήσιμων εργαλείων τα οποία βρίσκονται σε θέση να λαμβάνουν υπόψη τα χαρακτηριστικά κάθε επιχείρησης η οποία ενδιαφέρεται να τα χρησιμοποιήσει.

Ένα εξίσου σημαντικό μέτρο απόδοσης της διαδικασίας αποθεματοποίησης είναι το επίπεδο εξυπηρέτησης πελατών που έχει επιτευχθεί. Στην πραγματικότητα, το επίπεδο εξυπηρέτησης εμπεριέχει μόνο την πληροφορία των χαμένων πωλήσεων, επομένως το βέλτιστο χρονικό διάστημα μεταξύ των ελέγχων του αποθέματος ( $R$ ) και ο χρόνος παράδοσης ( $L$ ) διαφέρουν από αυτά που προτείνονται όταν χρησιμοποιείται το συνολικό κόστος αποθεματοποίησης, το οποίο περιλαμβάνει τις χαμένες πωλήσεις μόνο σε ένα από τα τρία στοιχεία του. Στο Σχήμα 8.20 απεικονίζεται ο τρόπος που επηρεάζεται το μέσο επίπεδο εξυπηρέτησης πελατών που έχει επιτευχθεί ( $\overline{SL}$ ) για τα διάφορα μοτίβα ζήτησης, μεταβάλλοντας τα  $R$ ,  $L$  και  $TSL$ . Στην συγκεκριμένη περίπτωση τα αποτελέσματα δεν



Σχήμα 8.18: Επίπτωση της μεταβολής της υπερπαραμέτρου πολιτικής αποθεματοποίησης TSL στο συνολικό κόστος αποθεματοποίησης για σειρές της κατηγορίας smooth.



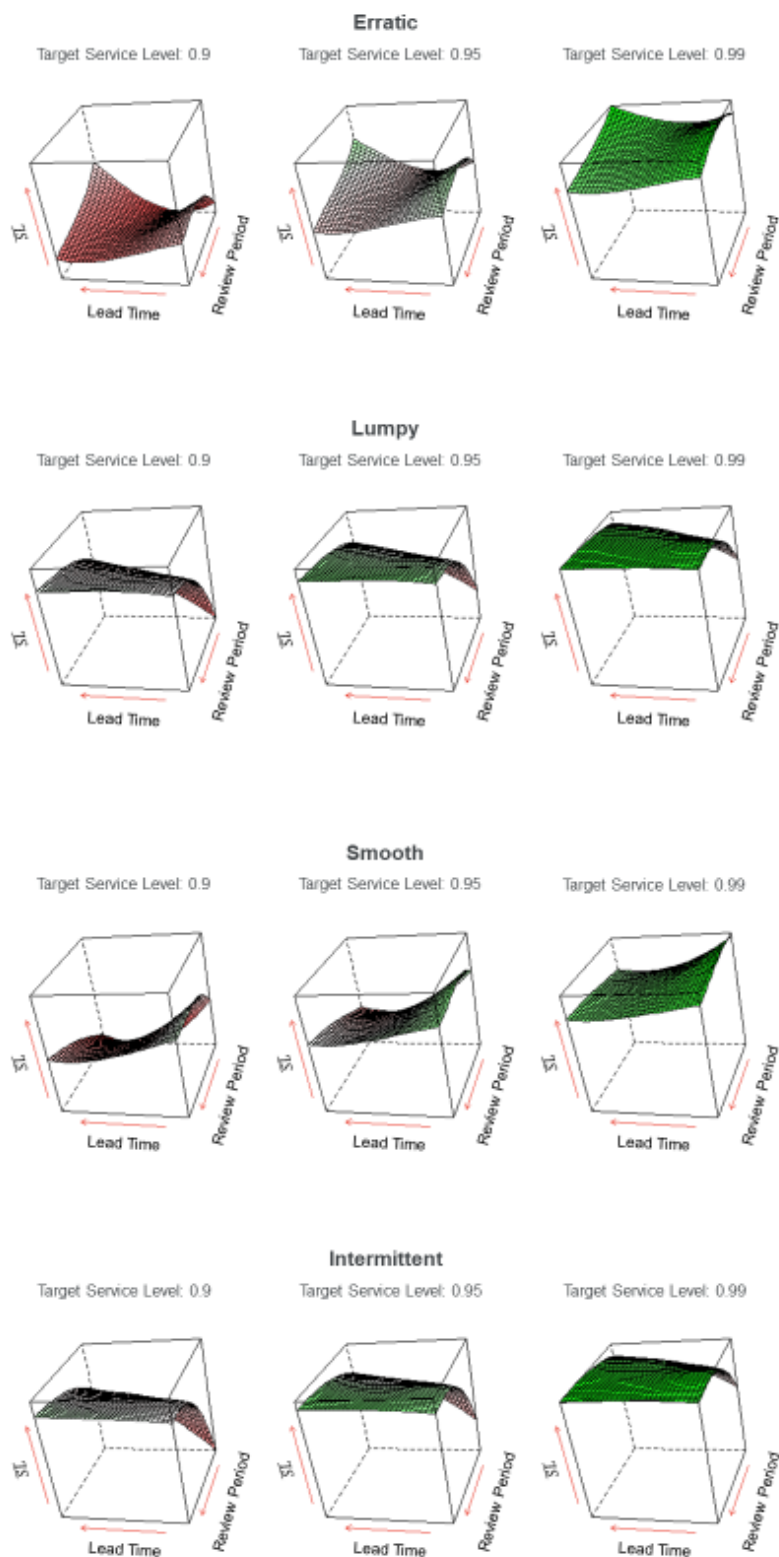
Σχήμα 8.19: Επίπτωση της μεταβολής της υπερπαραμέτρου πολιτικής αποθεματοποίησης TSL στο συνολικό κόστος αποθεματοποίησης για σειρές της κατηγορίας intermittent.

επηρεάζονται από τις τιμές που λαμβάνουν οι υπερπαραμέτροι κόστους αποθεματοποίησης, καθώς το  $\overline{SL}$  δεν εξαρτάται από αυτές.

Τα κύρια συμπεράσματα που μπορούν να εξαχθούν είναι αφενός ότι μία μεγαλύτερη



στοχοθέτηση επιπέδου εξυπηρέτησης επιτυγχάνει και ένα μεγαλύτερο επίπεδο, με τις παραμέτρους της πολιτικής αποθεματοποίησης ωστόσο να παίζουν σημαντικό ρόλο στην απόσταση μεταξύ του στόχου και του αποτελέσματος, και αφετέρου ότι το αποτέλεσμα συγκλίνει στον στόχο υπό διαφορετικές προϋποθέσεις για κάθε διαφορετική κατηγορία μοτίβου ζήτησης. Πιο αναλυτικά, για τις erratic σειρές μπορεί να μεγιστοποιηθεί το  $\overline{SL}$  επιλέγοντας πολλαπλά σειρές τιμών  $R$  και  $L$ , ενώ για τις lumpy και τις intermittent αυτό πραγματοποιείται με επιλογή κυρίως μεγάλων τιμών  $R$ . Αντιθέτως, στην περίπτωση των smooth σειρών, η μεγιστοποίηση του  $\overline{SL}$  μπορεί να επιτευχθεί με επιλογή κυρίως μικρών τιμών  $L$ .



Σχήμα 8.20: Επίπτωση της μεταβολής της υπερπαραμέτρου πολιτικής αποθεματοποίησης TSL στο πραγματοποιηθέν επίπεδο εξυπηρέτησης πελατών (SL) για κάθε κατηγορία μοτίβου ζήτησης.



“Η λειτουργία ενός καλού λογισμικού είναι να κάνει το σύνθετο να φαίνεται απλό.”  
– *Grady Booch*

## Κεφάλαιο 9

# Πληροφοριακό σύστημα

---

Στο παρόν Κεφάλαιο παρουσιάζεται το πληροφοριακό σύστημα που αναπτύχθηκε στο πλαίσιο της παρούσας διδακτορικής διατριβής, το οποίο περιλαμβάνει τα μοντέλα μηχανικής μάθησης τα οποία εκπαιδεύτικαν με τα τεχνητά δεδομένα, σύμφωνα με το προτεινόμενο μεθοδολογικό πλαίσιο, και δύναται να παρέχει προτάσεις βελτιστοποίησης της επιλεγμένης πολιτικής αποθεματοποίησης.

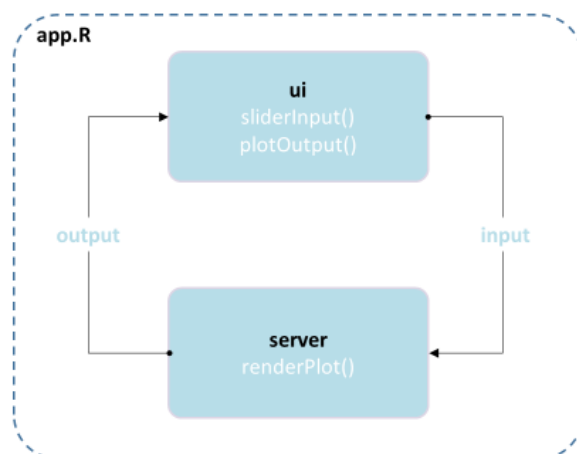
### 9.1 Ανάπτυξη και λειτουργικότητα

Η γλώσσα προγραμματισμού που χρησιμοποιήθηκε για την υλοποίηση του συστήματος είναι η R, αξιοποιώντας το πακέτο `shiny` (Chang et al., 2021). Το συγκεκριμένο πακέτο διευκολύνει τη δημιουργία διαδραστικών εφαρμογών (interactive applications) απευθείας από τη γλώσσα R, η οποία στην αρχική της μορφή δεν προοριζόταν για τέτοιου είδους υλοποιήσεις. Μπορεί κανείς, έτσι, με το πακέτο `shiny` και τις επεκτάσεις του, να κατασκευάσει αυτόνομες εφαρμογές (standalone apps), ιστοσελίδες (websites), να ενσωματώσει τα αποτελέσματα διεργασιών που έχουν πραγματοποιηθεί στην R σε έγγραφα, τα οποία μπορούν να διαμοιραστούν, καθώς και να κατασκευάσει πίνακες οργάνων (dashboards). Τα παραπάνω μπορούν επίσης να επεκταθούν χρησιμοποιώντας επιπλέον γλώσσες προγραμματισμού οι οποίες έχουν δημιουργηθεί εξ αρχής για τέτοιου είδους υλοποιήσεις, όπως η HTML και η JavaScript, αλλά και να εμπλουτιστούν ή να πραγματοποιηθούν εικαστικές παρεμβάσεις σε αυτά μέσω CSS και αντίστοιχων γλωσσών φύλλων ύφους (style sheet languages).

Το `shiny`, έτσι, δίνει τη δυνατότητα δημιουργίας ισχυρών εφαρμογών εξ ολοκλήρου στην R, χωρίς να απαιτείται η εγκατάσταση κάποιου εξωτερικού λογισμικού, όπως ο Apache, και ο προγραμματιστής μπορεί να κατασκευάσει τόσο το front-end όσο και το back-end χρησιμοποιώντας την ίδια γλώσσα προγραμματισμού και στη συνέχεια το εν λόγω πακέτο να μεταγλωττίσει τον κώδικα στις γλώσσες HTML, CSS και JavaScript, οι οποίες απαιτούνται προκειμένου η εφαρμογή να εμφανίζεται και να ανταποκρίνεται στις αλληλεπιδράσεις με τον τελικό χρήστη.

Το `shiny` συνοδεύεται από μια βιβλιοθήκη αντιδραστικού προγραμματισμού (reactive programming library) που χρησιμοποιείται για τη δομή της λογικής της εφαρμογής. Με τη χρήση αυτής της βιβλιοθήκης, η αλλαγή μιας τιμής εισόδου προκαλεί την εκ νέου εκτέλεση των σωστών τμημάτων του κώδικα R, κάτι που με τη σειρά του προκαλεί την ενημέρωση των

εξόδων που εξαρτώνται από την εν λόγω είσοδο. Το μοντέλο αντιδραστικού προγραμματισμού, έτσι, εξαλείφει την ανάγκη για πρόσθετο κώδικα χειρισμού συμβάντων (event handling code). Επιπλέον, όλα τα μέρη της εφαρμογής δύναται να βρίσκονται σε ένα μοναδικό αρχείο (app.R), όπως φαίνεται στο Σχήμα 9.1, όπου οι διάφορες εισοδοι και εξοδοι αλληλοεπιδρούν μεταξύ τους.



Σχήμα 9.1: Δομή μιας εφαρμογής shiny που αποτελείται αποκλειστικά από το αρχείο app.R.

Η εγκατάστασή του πακέτου shiny γίνεται από την κονσόλα της R, με την προϋπόθεση ότι υπάρχει σύνδεση στο διαδίκτυο, αντίστοιχα με όλα τα πακέτα της συγκεκριμένης γλώσσας προγραμματισμού, με την εξής εντολή:

```
# Install libraries
install.packages('shiny')
```

Παρακάτω φαίνεται η βασική δομή ενός αρχείου app.R, το οποίο καθορίζει τόσο την γραφική διεπαφή του χρήστη, όσο και την λειτουργικότητα της εφαρμογής, όπως προαναφέρθηκε.

```
# Load necessary libraries
library('shiny')

# Front-end
ui <- fluidPage( )

# Back-end
server <- function(input, output) { }

# Start the app
shinyApp(ui = ui, server = server)
```


Στο συγκεκριμένο πακέτο, υπάρχουν τρία είδη αντικειμένων αντιδραστικού προγραμματισμού:

- οι αντιδραστικές πηγές (reactive sources)
- τα αντιδραστικά τελικά σημεία (reactive endpoints)

- οι αντιδραστικοί αγωγοί (reactive conductor)

Η απλούστερη δομή ενός αντιδραστικού προγράμματος περιλαμβάνει απλώς μια πηγή και ένα τελικό σημείο. Σε μια εφαρμογή shiny, η πηγή είναι συνήθως η είσοδος μέσω μιας διεπαφής προγράμματος περιήγησης (φυλλομετρητής - browser), όπως για παράδειγμα, όταν επιλέγεται ένα στοιχείο, πληκτρολογείται μία είσοδος ή γίνεται κλικ σε ένα κουμπί, με αυτές τις ενέργειες να ορίζουν τις τιμές που θα λάβουν συγκεκριμένες αντιδραστικές πηγές. Ένα αντιδραστικό τελικό σημείο είναι συνήθως κάτι που εμφανίζεται στο παράθυρο του προγράμματος περιήγησης του χρήστη, όπως μια γραφική παράσταση ή ένας πίνακας τιμών, τα οποία περιλαμβάνουν αυτούσιες τις τιμές εισόδου ή απεικονίζουν τα αποτελέσματα μιας συγκεκριμένης διεργασίας η οποία εξαρτάται από τις εν λόγω τιμές εισόδου.

Είναι δυνατό, επίσης, να τοποθετηθούν αντιδραστικά στοιχεία μεταξύ των πηγών και των τελικών σημείων, όπως φαίνεται στο Σχήμα 9.2, τα οποία ονομάζονται αντιδραστικοί αγωγοί και επιτρέπουν την ενθυλάκωση χρονοβόρων και υπολογιστικά ακριβών λειτουργιών ή μπορούν να αποτελέσουν μέρος ενός επιπλέον βήματος το οποίο απαιτεί τιμές περισσότερων από μια πηγές.



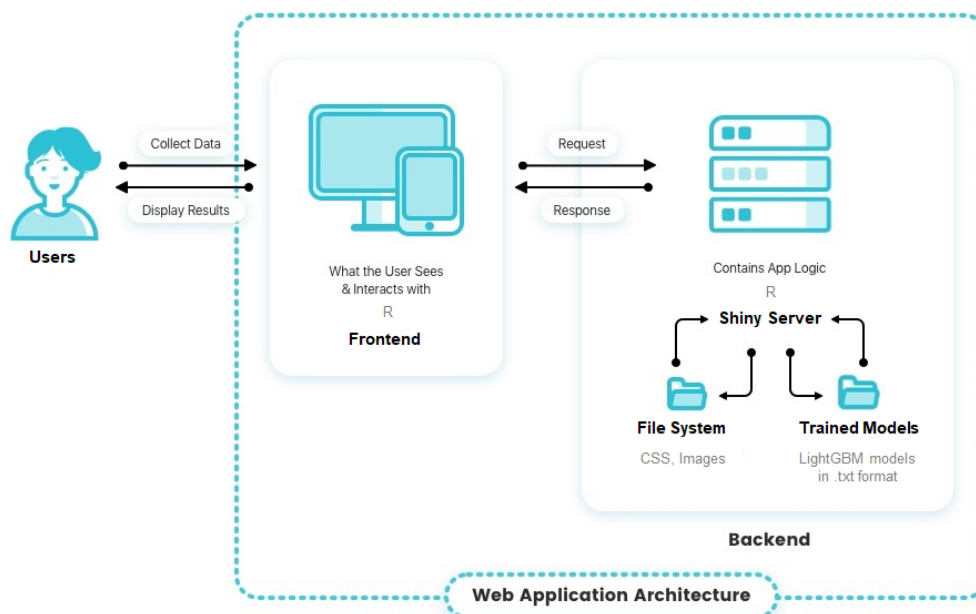
Σχήμα 9.2: Αντιδραστικά (reactive) στοιχεία που συναντώνται στο πακέτο shiny της R.

Λαμβάνοντας υπόψη τα παραπάνω, και δεδομένου ότι ολόκληρη η πειραματική διαδικασία της παρούσας διδακτορικής διατριβής υλοποιήθηκε αποκλειστικά στην γλώσσα R, ήταν επόμενο να επιλεγεί η συγκεκριμένη προσέγγιση κατασκευής ενός ολοκληρωμένου συστήματος, το οποίο θα περιλαμβάνει τα κύρια βήματα του μεθοδολογικού πλαισίου που αναπτύχθηκε, εξηγώντας τα μέσω παραδειγμάτων, και θα αποτελεί ένα σύστημα υποστήριξης αποφάσεων βελτιστοποίησης της διαδικασίας αποθεματοποίησης με έναν εύκολα κατανοητό τρόπο για τον τελικό χρήστη.

## 9.2 Αρχιτεκτονική συστήματος

Η αρχιτεκτονική κάθε εφαρμογής, ιδιαίτερα μιας διαδικτυακής εφαρμογής, έχει βαρύνουσα σημασία, μιας και καθορίζει το πραγματικό επίπεδο απόδοσής της καθώς και τις ανάγκες της σε πόρους. Το σύστημα που κατασκευάστηκε στο πλαίσιο της παρούσας διατριβής σχεδιάστηκε ως μία απλοποιημένη φυσική αρχιτεκτονική τριών επιπέδων, δηλαδή αποτελείται από τα επίπεδα παρουσίασης, λογικής και δεδομένων, με τη διαφορά ότι δεν χρησιμοποιείται κάποια βάση δεδομένων για την αποθήκευσή τους, αλλά μόνο ένας φάκελος ο οποίος περιέχει τα προεκπαιδευμένα μοντέλα μηχανικής μάθησης τα οποία απαιτούνται για τη βελτιστοποίηση οποιασδήποτε χρονοσειράς, σύμφωνα με το

προτεινόμενο μεθοδολογικό πλαίσιο. Η αρχιτεκτονική του συστήματος απεικονίζεται στο Σχήμα 9.3.



Σχήμα 9.3: Αρχιτεκτονική του υλοποιημένου συστήματος υποστήριξης αποφάσεων.

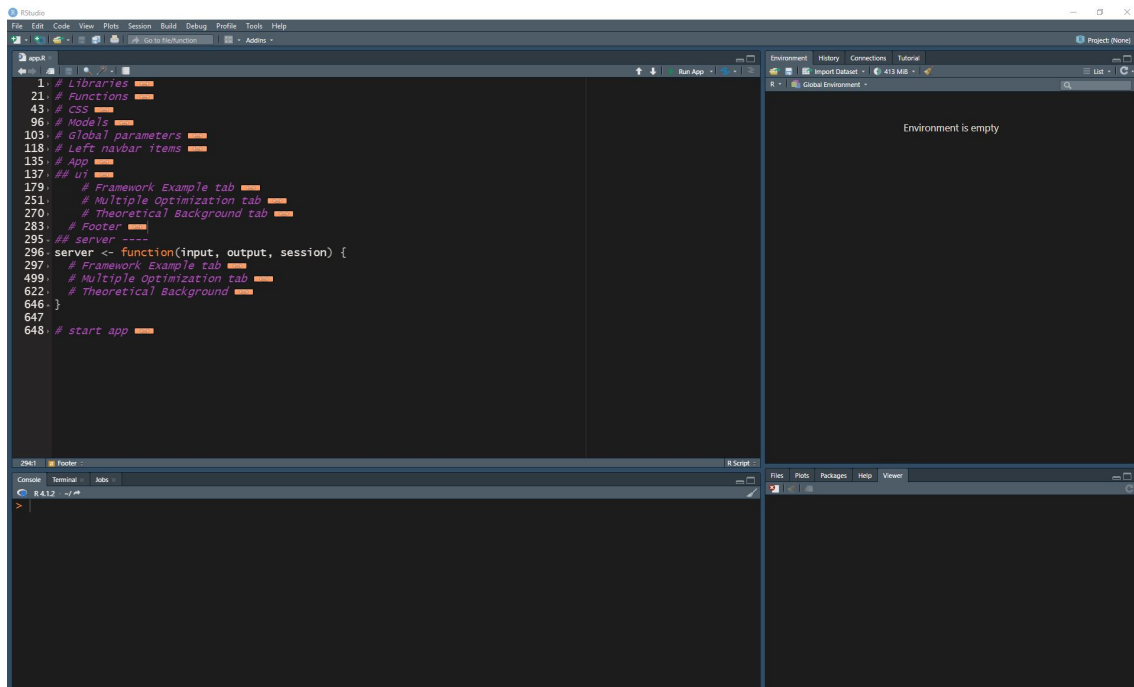
Όπως είναι εύκολα κατανοητό, το εν λόγω σύστημα περιλαμβάνει μόνο την προσέγγιση του μεθοδολογικού πλαισίου που κάνει χρήση μεταφοράς μάθησης, όπου τα μοντέλα μηχανικής μάθησης έχουν εκπαιδευτεί από τις τεχνητές χρονοσειρές που παρήχθησαν από τη γεννήτρια παραγωγής χρονοσειρών. Αυτό συμβαίνει καθώς η διαδικασία εκτέλεσης των απαραίτητων προσομοιώσεων αποθεματοποίησης για ένα νέο σύνολο δεδομένων και η εκ νέου εκπαίδευση μοντέλων που εκτιμούν τα στοιχεία κόστους αποθεματοποίησης είναι αρκετά χρονοβόρες, καθιστώντας μη αποδοτικό το να πραγματοποιούνται εντός της εφαρμογής που στόχο έχει να παρέχει γρήγορα κατανοητές προτάσεις στους υπεύθυνους λήψης αποφάσεων.

Όπως αναφέρθηκε, το επίπεδο παρουσίασης (front-end) και το επίπεδο λογικής (back-end) υλοποιήθηκαν σε ένα μόνο αρχείο. Στο Σχήμα 9.4 απεικονίζεται το ολοκληρωμένο περιβάλλον ανάπτυξης RStudio, με το αρχείο `app.R` που είναι υπεύθυνο για όλες τις λειτουργίες του συστήματος.

Το σύστημα είναι προσβάσιμο από τους τελικούς χρήστες μέσω οποιουδήποτε προγράμματος περιήγησης και φιλοξενείται στην πλατφόρμα `shinyapps.io`. Αν και η φιλοξενία (hosting) του εν λόγω συστήματος θα μπορούσε να πραγματοποιηθεί από οποιαδήποτε πλατφόρμα φιλοξενίας ή ακόμα και να χρησιμοποιείται αποκλειστικά μέσω ενός υπολογιστή ο οποίος έχει το σύνολο των αρχείων του υλοποιημένου συστήματος, επιλέχθηκε η πλατφόρμα `shinyapps.io` για την ευκολία στη χρήση της, την ασφάλεια και τη δυνατότητα επεκτασιμότητας που παρέχει καθώς και το γεγονός ότι η δωρεάν έκδοσή της καλύπτει πλήρως της ανάγκες του συστήματος ενώ ταυτόχρονα είναι κατασκευασμένη και συντηρείται από τα μέλη της ομάδας της γλώσσας προγραμματισμού R, του περιβάλλοντος ανάπτυξης RStudio και του πακέτου `shiny`.

Το `shinyapps.io` αποτελεί μία πλατφόρμα αυτοεξυπηρέτησης ως υπηρεσία (self-service





Σχήμα 9.4: Απεικόνιση του αρχείου `app.R` στο περιβάλλον RStudio.

platform as a service - PaaS) η οποία διευκολύνει το διαμοιρασμό εφαρμογών στο διαδίκτυο γρήγορα και εύκολα. Πολλοί πελάτες χρησιμοποιούν την εν λόγω πλατφόρμα για να αποδείξουν κάποιες έννοιες, να δημιουργήσουν ένα πρωτότυπο ή απλώς να το τρέξουν για σύντομο χρονικό διάστημα, ενώ άλλοι τη χρησιμοποιούν ως αποκλειστικό σημείο φιλοξενίας.

Η υπηρεσία εκτελείται στο cloud, σε κοινόχρηστους εξυπηρετητές (shared servers) που λειτουργούν από το RStudio. Κάθε εφαρμογή είναι αυτόνομη και μπορεί να λειτουργήσει είτε με δεδομένα που αποστέλλονται μαζί με την εφαρμογή είτε με δεδομένα που αντλούνται από βάσεις δεδομένων οι οποίες φιλοξενούνται σε άλλους servers.

Για την τελική διαμόρφωση μιας εφαρμογής απαιτείται ένα περιβάλλον ανάπτυξης της γλώσσας R, όπως το RStudio και η πιο πρόσφατη έκδοση του πακέτου `rsconnect` (Atkins et al., 2021), καθώς και η δημιουργία του αντίστοιχου λογαριασμού στην πλατφόρμα `shinyapps.io`.

### 9.3 Παρουσίαση συστήματος

Η εφαρμογή αποτελείται από τρεις (3) σελίδες (tabs), οι οποίες φέρουν τους εξής τίτλους:

- Stock Control Simulation
- MOIC Demo
- MOIC Implementation

Πιο αναλυτικά, στην εφαρμογή εμφανίζονται τρεις σελίδες κάθε μία από τις οποίες παρουσιάζει ένα μέρος του μεθοδολογικού πλαισίου που κατασκευάστηκε στο πλαίσιο της παρούσας διατριβής. Στην πρώτη απεικονίζεται μία χρονοσειρά ζήτησης και τα

αποτελέσματα μιας προσομοίωσης της διαδικασίας αποθεματοποίησης, για την εν λόγω σειρά, στην δεύτερη απεικονίζονται οι δύο λειτουργίες του πλαισίου, οι οποίες είναι η σύγκριση διαφορετικών σεναρίων αποθεματοποίησης και η βελτιστοποίηση μίας πολιτικής για μία σειρά ζήτησης συγκεκριμένων χαρακτηριστικών, και στην τρίτη ο χρήστης μπορεί να αποστείλει τα απαραίτητα δεδομένα και να πραγματοποιήσει τη διαδικασία βελτιστοποίησης για πληθώρα προϊόντων - σειρών ζήτησης - ταυτόχρονα, τα οποία μπορεί να αποτελούν το σύνολο ή μέρος των κωδικών μιας αποθήκης.

Στο επάνω μέρος κάθε σελίδας, όπως φαίνεται στο Σχήμα 9.5, υπάρχει η μπάρα πλοήγησης (navigation bar), στην οποία ο χρήστης μπορεί να επιλέξει τη σελίδα που επιθυμεί να επισκεφτεί, ενώ ταυτόχρονα επισημαίνεται η σελίδα που ο χρήστης βρίσκεται κάθε στιγμή. Επίσης, εμφανίζονται κάποια κουμπιά ανακατεύθυνσης σε περισσότερες πληροφορίες του μεθοδολογικού πλαισίου (Details) και του δημιουργού του (Info) και ένα κουμπί το οποίο δίνει τη δυνατότητα αντιγραφής (Share) του συνδέσμου πλοήγησης (url link) της εφαρμογής.



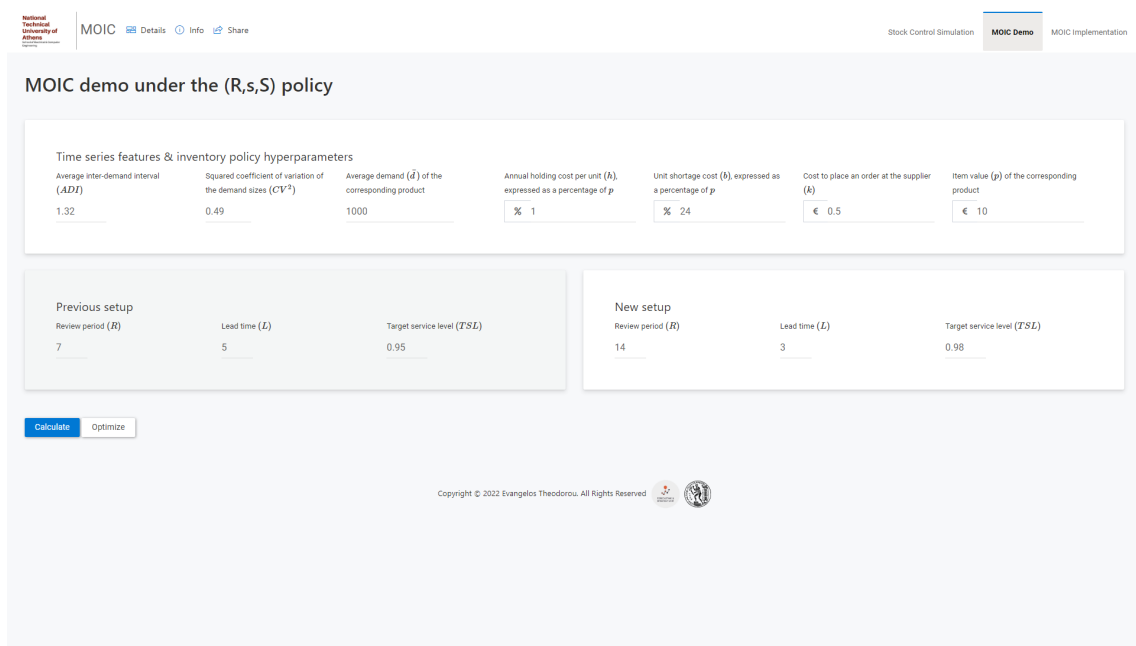
Σχήμα 9.5: Παρουσίαση της μπάρας πλοήγησης (navigation bar) της εφαρμογής.

Όπως χαρακτηριστικά φαίνεται στο Σχήμα 9.6, στη σελίδα “Stock Control Simulation”, η οποία αποτελεί και την αρχική σελίδα της εφαρμογής (Home Page), εμπεριέχεται η γεννήτρια τεχνητών χρονοσειρών, όπως παρουσιάστηκε στο Κεφάλαιο 5, μέσω της οποίας ο χρήστης μπορεί να κατασκευάσει μία ημερήσια χρονοσειρά ζήτησης επιλέγοντας τις κατάλληλες τιμές  $ADI$ ,  $CV^2$  και  $\bar{d}$ . Δηλαδή, ο χρήστης μπορεί να κατασκευάσει και να δει γραφικά μία χρονοσειρά με συγκεκριμένες τιμές για το μέσο διάστημα μεταξύ δύο θετικών παρατηρήσεων, τη διακύμανση των θετικών παρατηρήσεων και τη μέση τιμή της χρονοσειράς. Ακολούθως, για την κατασκευασμένη χρονοσειρά ζήτησης πραγματοποιείται μία προσομοίωση αποθεματοποίησης ενός έτους, όπου γίνεται χρήση της πολιτικής  $(R, s, S)$ , με τη ζήτηση να προβλέπεται με την μέθοδο Croston, όπως σχολιάστηκε αναλυτικά κατά την παρουσίαση του πλαισίου στο Κεφάλαιο 7. Ο χρήστης μπορεί να επιλέξει συγκεκριμένες τιμές για τις παραμέτρους  $R$ ,  $L$  και  $TSL$  της πολιτικής που χρησιμοποιείται και να δει γραφικά τα αποτελέσματα της προσομοίωσης, και πιο συγκεκριμένα το επίπεδο αποθέματος (Inventory), τις παραγγελίες προς τους προμηθευτές (Orders) και το σύνολο της ζήτησης (Cumulative Demand) μεταξύ των ελέγχων του αποθέματος. Με την λειτουργικότητα αυτή, γίνεται εύκολα κατανοητό στον χρήστη με ποιον τρόπο τα χαρακτηριστικά της ζήτησης και οι παράμετροι της πολιτικής αποθεματοποίησης επηρεάζουν τη λειτουργία της επιχείρησης και τα κόστη που αυτά δημιουργούν, υπό την έννοια της διατήρησης αποθέματος, απώλειας πωλήσεων ή πραγματοποίησης παραγγελιών προς τους προμηθευτές.

Στη σελίδα “MOIC Demo”, όπως φαίνεται και στο Σχήμα 9.7, εμπεριέχεται η ουσία του μεθοδολογικού πλαισίου, στην οποία ο χρήστης μπορεί να δοκιμάσει τη λειτουργία του, να εξοικειωθεί με τις εισόδους που απαιτεί αλλά και τα αποτελέσματά του, εξετάζοντας ένα μόνο προϊόν κάθε φορά.



Σχήμα 9.6: Παρουσίαση της σελίδας “Stock Control Simulation” της εφαρμογής.



Σχήμα 9.7: Παρουσίαση της σελίδας “MOIC Demo” της εφαρμογής.

Πιο αναλυτικά, ο χρήστης μπορεί να εισάγει τιμές τόσο για τα χαρακτηριστικά της ζήτησης του προϊόντος που θέλει να εξετάσει, όσο και για τις υπερπαραμέτρους κόστους αποθεματοποίησης, όπως αυτοί ορίστηκαν στο Κεφάλαιο 7. Οι εν λόγω εισοδοί απεικονίζονται στο Σχήμα 9.8, και αποτελούν τις κύριες εισόδους του πλαισίου MOIC.

Time series features & inventory policy hyperparameters						
Average inter-demand interval (ADI)	Squared coefficient of variation of the demand sizes (CV <sup>2</sup> )	Average demand ( $\bar{d}$ ) of the corresponding product	Annual holding cost per unit (h), expressed as a percentage of p	Unit shortage cost (b), expressed as a percentage of p	Cost to place an order at the supplier (k)	Item value (p) of the corresponding product
1.32	0.49	1000	% 1	% 24	€ 0.5	€ 10

Σχήμα 9.8: Παρουσίαση των εισόδων του μεθοδολογικού πλαισίου όπως εμφανίζονται στην εφαρμογή.

Στην περίπτωση που ο χρήστης επιθυμεί να συγκρίνει δύο σενάρια της πολιτικής, μπορεί να ορίσει ένα αρχικό (Previous Setup) και ένα νέο σενάριο (New Setup), όπως φαίνεται στο Σχήμα 9.9.

Previous setup			New setup		
Review period (R)	Lead time (L)	Target service level (TSL)	Review period (R)	Lead time (L)	Target service level (TSL)
7	5	0.95	14	3	0.98

Σχήμα 9.9: Επιλογή σεναρίων του μεθοδολογικού πλαισίου μέσω της εφαρμογής.

Επιλέγοντας το κουμπί “Calculate”, όπως φαίνεται στο Σχήμα 9.10, το σύστημα προσεγγίζει το συνολικό κόστος αποθεματοποίησης των δύο σεναρίων και παρουσιάζει τις διαφορές τους, ενώ ταυτόχρονα απεικονίζει γραφικά την επίπτωση που θα είχε η αλλαγή μία εκ των υπερπαραμέτρων πολιτικής αποθεματοποίησης ( $R$ ,  $L$ ,  $TSL$ ) κάθε φορά στο συνολικό κόστος αποθεματοποίησης.

Από την άλλη πλευρά, επιλέγοντας το κουμπί “Optimize”, το σύστημα προσεγγίζει τις τιμές των υπερπαραμέτρων πολιτικής αποθεματοποίησης οι οποίες, σύμφωνα με τα μοντέλα μηχανικής μάθησης, αναμένεται να οδηγήσουν στο χαμηλότερο συνολικό κόστος αποθεματοποίησης. Η συγκεκριμένη λειτουργία απεικονίζεται στο Σχήμα 9.11.

Με άλλα λόγια, για δεδομένη χρονοσειρά ζήτησης και υπερπαραμέτρους κόστους, ο χρήστης έχει τη δυνατότητα να συγκρίνει δύο σενάρια μιας πολιτικής αποθεματοποίησης, καθώς και να βελτιστοποιήσει τη συγκεκριμένη πολιτική ως προς το κόστος.

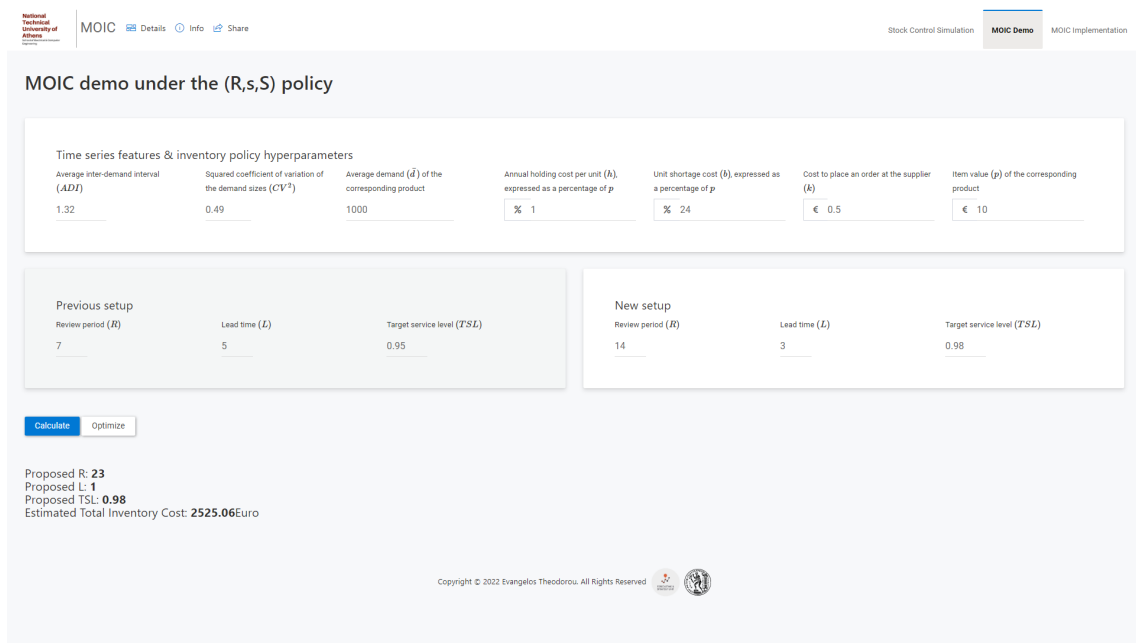
Στη σελίδα “MOIC Implementation”, όπως φαίνεται και στο Σχήμα 9.12, εμπεριέχεται η πλήρης λειτουργία του προτεινόμενου μεθοδολογικού πλαισίου, βάσει της οποίας ο χρήστης δύναται να βελτιστοποιήσει ταυτόχρονα πλήθος προϊόντων, παρέχοντας τις απαραίτητες εισόδους για κάθε ένα από αυτά.

Οι παράμετροι αποστέλλονται στην εφαρμογή μέσω ενός αρχείου csv (Comma-separated values file), το οποίο έχει συγκεκριμένη μορφή, ως προς το πλήθος και την σειρά των στηλών, το οποίο ακολούθως απεικονίζεται εντός της εφαρμογής, όπως φαίνεται στο Σχήμα 9.13, προκειμένου ο χρήστης να έχει τη δυνατότητα να ελέγξει, για μία ακόμη φορά, τα δεδομένα που εισήγαγε.

Στη συνέχεια, επιλέγοντας το κουμπί “Optimize”, ξεκινά η διαδικασία βελτιστοποίησης της πολιτικής αποθεματοποίησης για τις σειρές και τις υπερπαραμέτρους κόστους που ο

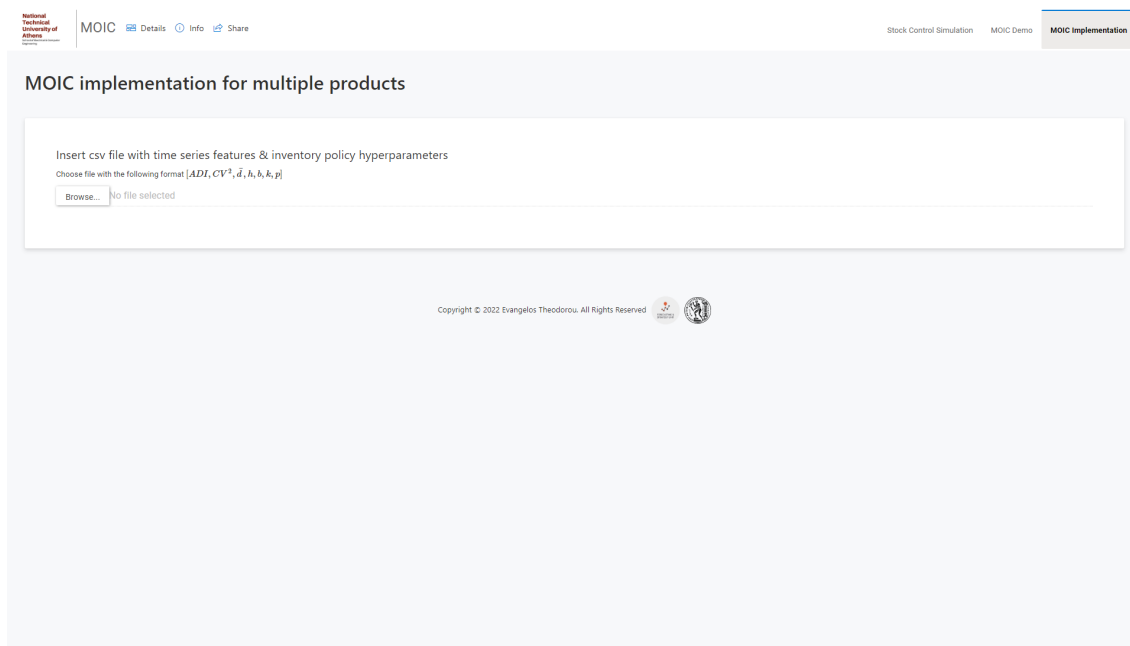


Σχήμα 9.10: Παρουσίαση των συγκριτικών αποτελεσμάτων των επιλεγμένων σεναρίων μέσω της εφαρμογής.

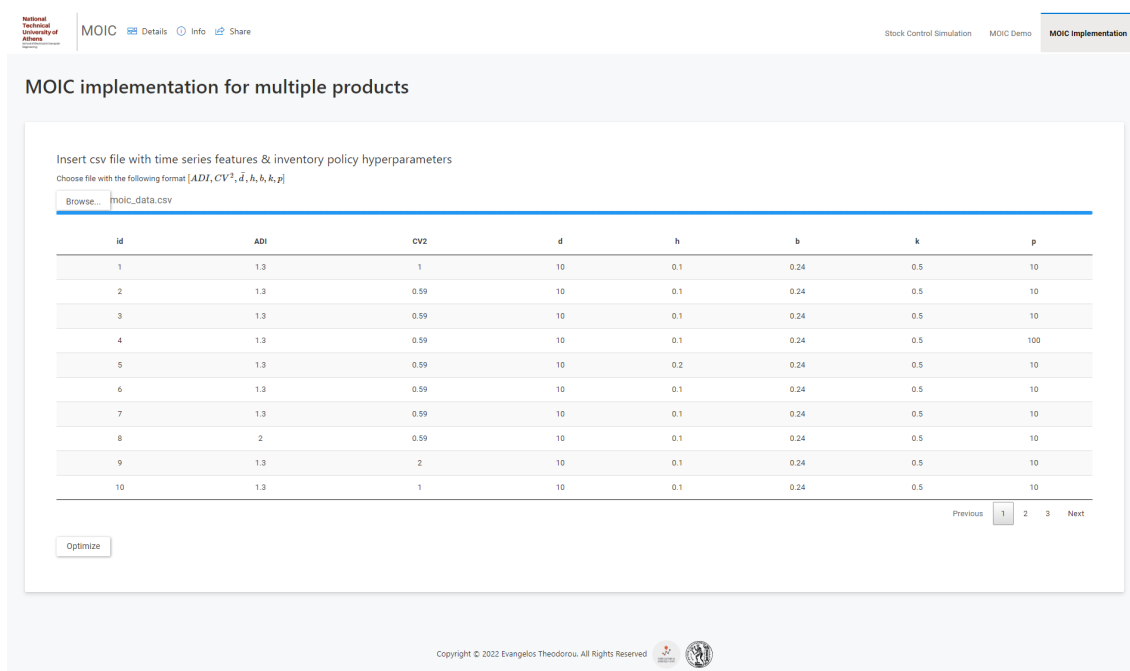


Σχήμα 9.11: Παρουσίαση των αποτελεσμάτων βελτιστοποίησης μέσω της εφαρμογής.

χρήστης εισήγαγε, με τα αποτελέσματα αυτής να απεικονίζονται εντός της εφαρμογής, ενώ δίνεται και η δυνατότητα εξαγωγής τους σε αρχείο csv.



Σχήμα 9.12: Παρουσίαση της σελίδας “MOIC Implementation” της εφαρμογής.



Σχήμα 9.13: Απεικόνιση των δεδομένων εισαγωγής στη σελίδα “MOIC Implementation” της εφαρμογής.

Όπως φαίνεται χαρακτηριστικά στο Σχήμα 9.15, το σύστημα κατασκευάστηκε λαμβάνοντας υπόψη τις πρόσφατες τάσεις στο σχεδιασμό διαδικτυακών εφαρμογών, ακολουθώντας συγκεκριμένα σύγχρονα πρότυπα. Η εμφάνιση της εφαρμογής βασίστηκε στο πλαίσιο Fluent UI της Microsoft, το οποίο αποτελεί μια συλλογή πλαισίων για τη δημιουργία εμφανισιακά απλών αλλά παράλληλα όμορφων σύνθετων εφαρμογών. Μιας και, όπως αναφέρθηκε, το σύστημα υλοποιήθηκε στη γλώσσα προγραμματισμού R, χρησιμοποιώντας το πακέτο shiny, προκειμένου να εφαρμοστεί το πλαίσιο Fluent UI,

MOIC implementation for multiple products

Insert csv file with time series features & inventory policy hyperparameters  
Choose file with the following format [ADI, CV<sup>2</sup>, d, h, b, k, p]

Browse... moic\_data.csv

id	ADI	CV2	d	h	b	k	p
1	1.3	1	10	0.1	0.24	0.5	10
2	1.3	0.59	10	0.1	0.24	0.5	10
3	1.3	0.59	10	0.1	0.24	0.5	10
4	1.3	0.59	10	0.1	0.24	0.5	100
5	1.3	0.59	10	0.2	0.24	0.5	10
6	1.3	0.59	10	0.1	0.24	0.5	10
7	1.3	0.59	10	0.1	0.24	0.5	10
8	2	0.59	10	0.1	0.24	0.5	10
9	1.3	2	10	0.1	0.24	0.5	10
10	1.3	1	10	0.1	0.24	0.5	10

Previous 1 2 3 Next

Optimize

id	Proposed_R	Proposed_L	Proposed_TSL	Approximated_TotalInventoryCost
1	7	1	0.98	37.9
2	7	1	0.98	37.9
3	7	1	0.98	37.9
4	3	1	0.98	304.05
5	5	1	0.98	47.7
6	7	1	0.98	37.9
7	7	1	0.98	37.9
8	11	1	0.98	32.15
9	5	1	0.98	35.83
10	7	1	0.98	37.9

Previous 1 2 3 Next

Download

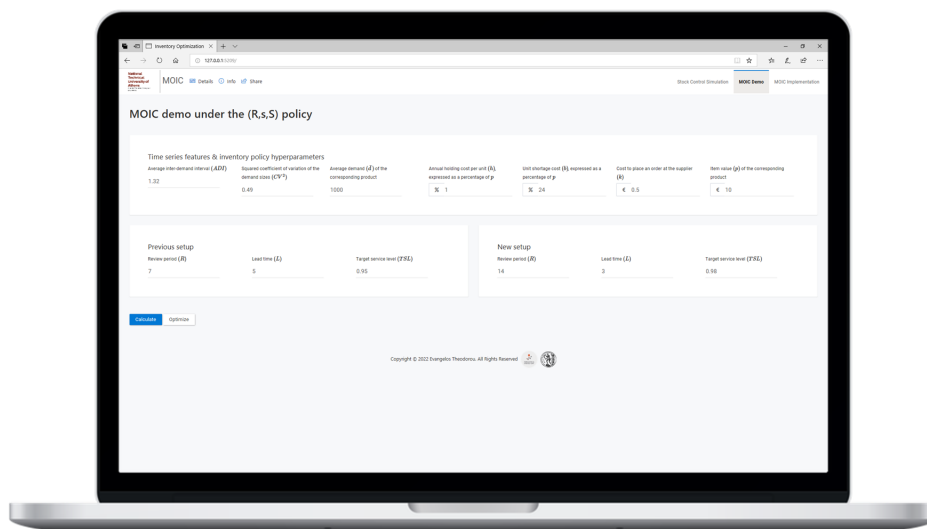
Copyright © 2022 Evangelos Theodorou. All Rights Reserved

Σχήμα 9.14: Απεικόνιση των αποτελεσμάτων της βελτιστοποίησης στη σελίδα “MOIC Implementation” της εφαρμογής.

χρησιμοποιήθηκε, επίσης, το πακέτο `shiny.fluent` (Rogala & Zyla, 2022), το οποίο δίνει τη δυνατότητα χρήσης των συστατικών του Fluent UI σε shiny εφαρμογές.

Από τα παραπάνω συμπεραίνει κανείς ότι το ολοκληρωμένο σύστημα που κατασκευάστηκε στο πλαίσιο της παρούσας διδακτορικής διατριβής εμπεριέχει όλες τις δυνατότητες του προτεινόμενου μεθοδολογικού πλαισίου όντας, έτσι, ένα εύκολα κατανοητό και αρκετά ισχυρό σύστημα υποστήριξης αποφάσεων το οποίο κάνει χρήση αλγορίθμων μηχανικής μάθησης. Επίσης, ο τρόπος που έχει κατασκευαστεί η συγκεκριμένη εφαρμογή καθιστά εύκολες ενδεχόμενες μελλοντικές προεκτάσεις ή αλλαγές, όπως για παράδειγμα η αλλαγή των προεκπαιδευμένων μοντέλων μηχανικής μάθησης `lightGBM` με κάποια άλλα μοντέλα τα οποία θα επιδείξουν μεγαλύτερη προβλεπτική ακρίβεια στο μέλλον.

Είναι σημαντικό να αναφερθεί ότι στην εφαρμογή εμπεριέχεται μόνο η προσέγγιση του προτεινόμενου πλαισίου η οποία κάνει χρήση μεταφοράς γνώσης. Παρά το γεγονός ότι εκ των αποτελεσμάτων αποδεικνύεται ότι η συγκεκριμένη προσέγγιση επιφέρει καλύτερα αποτελέσματα, πρέπει να τονιστεί ότι δεν είναι δυνατή η ύπαρξη και της έταιρης προσέγγισης, η οποία χρησιμοποιεί το ίδιο σύνολο δεδομένων για την εκπαίδευση των μοντέλων με αυτό που προβλέπεται, καθώς σε αυτή την περίπτωση τα μοντέλα θα πρέπει να



Σχήμα 9.15: Εμφάνιση της διαδικτυακής εφαρμογής.

εκπαιδευτούν με τα δεδομένα που εισάγει ο χρήστης κάθε φορά, μια διαδικασία η οποία είναι πολύ χρονοβόρα και δεν είναι εφικτό να πραγματοποιηθεί σε μία διαδικτυακή εφαρμογή, καθώς απαιτεί σημαντικά πολλούς υπολογιστικούς πόρους ενώ ταυτόχρονα κάνει την εφαρμογή μη χρηστική αφού θα είναι μη λειτουργική για το διάστημα της εκπαίδευσης.





“Οι άνθρωποι σκέφτονται τη ζωή ως ένα δράμα γεμάτο λήψη αποφάσεων, ποιο θα είναι, όμως, το νόημα της ανθρώπινης ζωής εάν οι περισσότερες αποφάσεις λαμβάνονται από αλγορίθμους;”

– *Yuval Noah Harari*

## Κεφάλαιο 10

### Συμπεράσματα και προεκτάσεις

---

Στο παρόν Κεφάλαιο πραγματοποιείται μία ανασκόπηση της διδακτορικής διατριβής, και πιο συγκεκριμένα του προτεινόμενου μεθοδολογικού πλαισίου και του ολοκληρωμένου συστήματος που κατασκευάστηκε, αναφέρονται τα βασικότερα συμπεράσματα που δύναται να εξαχθούν από τα αποτελέσματα της πειραματικής διαδικασίας, όπως αυτή παρουσιάστηκε εκτενώς στα προηγούμενα κεφάλαια, δίνοντας, έτσι, μια πληρέστερη και ταυτόχρονα σαφέστερη εικόνα για τη συμβολή της παρούσας διατριβής στην ακαδημαϊκή κοινότητα και τον επιχειρησιακό κόσμο.

#### 10.1 Ανασκόπηση

Στο πλαίσιο της παρούσας διατριβής αναπτύχθηκε μία μεθοδολογία με στόχο την βελτιστοποίηση των πολιτικών αποθεματοποίησης, η οποία, σε αντίθεση με τις μαθηματικές προσεγγίσεις που μπορούν να χρησιμοποιηθούν στο εν λόγω πρόβλημα, πραγματοποιεί ελάχιστες υποθέσεις για τη φύση της ζήτησης και βασίζεται σε δεδομένα.

Προκειμένου να επιτευχθεί ο στόχος αυτός, εξετάστηκαν αρχικά διάφορες πολιτικές αποθεματοποίησης και εντοπίστηκαν οι παράμετροί τους που επηρεάζουν άμεσα το συνολικό κόστος αποθεματοποίησης, καθώς και τα επιμέρους στοιχεία του κόστους που το απαρτίζουν. Σε συνδυασμό με τα παραπάνω εξετάστηκαν οι τρόποι κατηγοριοποίησης των χρονοσειρών ζήτησης που συναντώνται στη βιβλιογραφία και εντοπίστηκαν τα χαρακτηριστικά των χρονοσειρών που καταδεικνύουν καλύτερα τα διάφορα μοτίβα εμφάνισης της ζήτησης. Ο εντοπισμός και η οργάνωση των παραπάνω, είναι καθοριστικής σημασίας για την κατασκευή μιας γενικευμένης μεθοδολογίας η οποία θα είναι σε θέση να συμπεριλάβει τα παραπάνω στοιχεία με σωστό τρόπο και να εξάγει αξιόπιστες προτάσεις.

Με τον τρόπο αυτό, προτάθηκε ένα μεθοδολογικό πλαίσιο το οποίο βασίζεται σε αποτελέσματα προσομοιώσεων αποθεματοποίησης και χρησιμοποιεί προηγμένους αλγόριθμους μηχανικής μάθησης προκειμένου να κάνει τις κατάλληλες συνδέσεις μεταξύ των χαρακτηριστικών της ζήτησης και των παραμέτρων της πολιτικής αποθεματοποίησης που έχει επιλεγεί, από τη μία, και των αποτελεσμάτων των προσομοιώσεων, από την άλλη, τα οποία προσμετρούνται κατά τον υπολογισμό του συνολικού κόστους αποθεματοποίησης, όπως το πλήθος των παραγγελιών προς τους προμηθευτές ή το μέσο απόθεμα, μεταξύ άλλων. Όπως είναι εμφανές, οι αλγόριθμοι μηχανικής μάθησης κατασκευάζονται κατάλληλα ώστε να προσεγγίζουν τις διαδικασίες που πραγματοποιούνται από τις

προσομοιώσεις, καθιστώντας τα αποτελέσματά τους προσεγγίσεις των αποτελεσμάτων της προσομοίωσης.

Κατά την πειραματική διαδικασία, ως αλγόριθμοι μηχανικής μάθησης, επιλέχθηκαν μοντέλα δένδρων παλινδρόμησης ενίσχυσης κλίσης, τα οποία έχουν παρουσιάσει εξαιρετικές επιδόσεις και σημαντικά μικρούς χρόνους εκτέλεσης, καθιστώντας τα ιδιαίτερα δημοφιλή, και δύο πολιτικές αποθεματοποίησης, προκειμένου να εξεταστεί τόσο η εφαρμογή της προτεινόμενης μεθοδολογίας όσο και η αποτελεσματικότητά της σε διαφορετικές πολιτικές. Επίσης, παρά το γεγονός ότι η αξιολόγηση πραγματοποιήθηκε σε πραγματικά δεδομένα πωλήσεων της μεγαλύτερης εταιρείας λιανικής στον κόσμο, παρήχθησαν τεχνητά δεδομένα ζήτησης με σκοπό την εξέταση της επίπτωσης των δεδομένων εκπαίδευσης των αλγορίθμων μηχανικής μάθησης στα αποτελέσματα του πλαισίου. Συγκρίθηκαν, έτσι δύο προσεγγίσεις της μεθοδολογίας, όπου στην πρώτη τα μοντέλα εκπαιδεύονται με τεχνητά κατασκευασμένα δεδομένα, ενώ στη δεύτερη εκπαιδεύονται με ένα μέρος των πραγματικών δεδομένων, και ακολούθως και οι δύο προσεγγίσεις αξιολογούνται στο τελευταίο έτος των πραγματικών δεδομένων, το οποίο, προφανώς, δεν συμμετείχε στην εκπαίδευση των μοντέλων της δεύτερης προσέγγισης.

Από τα παραπάνω συμπεραίνει κανείς ότι η πειραματική διαδικασία ήταν εκτενής, το προτεινόμενο πλαίσιο αξιολογήθηκε σε δεδομένα μιας πραγματικής εταιρείας και, επίσης, εξετάστηκε η λογική της μεταφοράς γνώσεων από ένα σύνολο δεδομένων σε ένα άλλο, που στόχο είχε να επιβεβαιώσει ότι η μεθοδολογία μπορεί να χρησιμοποιηθεί ως ένα ισχυρό εργαλείο το οποίο είναι σε θέση γρήγορα και χωρίς ανάγκη επιπλέον εκπαίδευσής του να παράξει αξιόπιστες προτάσεις, κατάλληλες να βρεθούν στην υπηρεσία των υπεύθυνων λήψης αποφάσεων.

Η προτεινόμενη μεθοδολογία κατασκευάστηκε βάσει της λογικής που σκιαγραφήθηκε παραπάνω με σκοπό να ξεπεράσει τα δύο βασικά προβλήματα που προκύπτουν κατά τη βελτιστοποίηση μιας πολιτικής αποθεματοποίησης. Τα προβλήματα αυτά είναι πρώτον ο χρόνος που απαιτούν οι μαθηματικές και άλλες υβριδικές προσεγγίσεις και δεύτερον η εξάλειψη των υποθέσεων σχετικά με τη φύση της ζήτησης που οι εν λόγω προσεγγίσεις πραγματοποιούν προκειμένου να είναι δυνατή η επίλυση του προβλήματος βελτιστοποίησης που αντιμετωπίζεται κάθε φορά. Όπως έγινε σαφές στα προηγούμενα κεφάλαια, οι συγκεκριμένες προσεγγίσεις είναι μη εφαρμόσιμες σε συνθήκες όπου η ζήτηση είναι στοχαστική και η διακύμανσή της δεν χαρακτηρίζεται από σταθερότητα στη διάρκεια του χρόνου. Με τον τρόπο αυτό, το προτεινόμενο μεθοδολογικό πλαίσιο, το οποίο έρχεται να υπερκεράσει τα παραπάνω προβλήματα, δοκιμάστηκε και φάνηκε ότι είναι ικανό να παράξει προτάσεις μεγάλης ακρίβειας σε σημαντικά μικρό χρόνο, ενώ ταυτόχρονα, εκ των αποτελεσμάτων αποδεικνύεται η σταθερότητά του σε διαφορετικές πολιτικές αποθεματοποίησης.

Ως ένα τελικό στάδιο της παρούσας διατριβής, η μεθοδολογία ενσωματώθηκε σε ένα ολοκληρωμένο σύστημα, υπό την μορφή της διαδικτυακής εφαρμογής, κατασκευάζοντας, έτσι, ένα σύστημα υποστήριξης αποφάσεων μεγάλης κλίμακας το οποίο κάνει χρήση αλγορίθμων μηχανικής μάθησης και δίνει τη δυνατότητα βελτιστοποίησης της επιλεγμένης πολιτικής για ένα ή περισσότερα προϊόντα, ενώ παράλληλα παρουσιάζει αναλυτικά τα σημαντικότερα μέρη της μεθοδολογίας προκειμένου να εξοικειώσει τον χρήστη με τη

λειτουργία της. Πιο αναλυτικά, εντός της εφαρμογής αναδεικνύεται η έννοια των χαρακτηριστικών των χρονοσειρών διακοπτόμενης ζήτησης και οπτικοποιούνται τα αποτελέσματα μιας προσομοίωσης αποθεματοποίησης για δεδομένη σειρά και πολιτική, καθώς επίσης παρουσιάζονται οι εισοδοί του μεθοδολογικού πλαισίου και δίνεται η δυνατότητα σύγκρισης των αποτελεσμάτων δύο επιλεγμένων συνόλων παραμέτρων της πολιτικής. Το σημαντικότερο μέρος του συστήματος αποτελεί η δυνατότητα ταυτόχρονης βελτιστοποίησης πλήθους προϊόντων, το οποίο αποτελεί και το κύριο μέρος της προτεινόμενης μεθοδολογίας, όντας έτσι ένα γενικευμένο εργαλείο το οποίο δύναται να παράξει σχεδόν βέλτιστες προτάσεις για το σύνολο των προϊόντων μιας αποθήκης με έναν εύκολα κατανοητό και γρήγορο τρόπο, χωρίς, επίσης, να απαιτεί μεγάλο όγκο δεδομένων από τον τελικό χρήστη.

## 10.2 Συμβολή και στοιχεία καινοτομίας

Η συνεισφορά της παρούσας διατριβής στην επιστήμη έγκειται, πρωτίστως, στο γεγονός ότι εξετάστηκε η χρησιμοποίηση αλγορίθμων μηχανικής μάθησης στο πρόβλημα της βελτιστοποίησης των πολιτικών αποθεματοποίησης και προτάθηκε ένα γενικευμένο μεθοδολογικό πλαίσιο το οποίο ενσωματώνει την παραπάνω ιδέα με αξιόλογα αποτελέσματα, ενώ η συνεισφορά της προς τους επαγγελματίες του κλάδου της επιχειρησιακής έρευνας προέρχεται από την δημιουργία ενός συστήματος υποστήριξης αποφάσεων που εμπεριέχει το προτεινόμενο πλαίσιο. Επίσης, τα στοιχεία καινοτομίας είναι πολυάριθμα και εντοπίζονται κυρίως στον τρόπο με τον οποίο χρησιμοποιούνται τα μοντέλα μηχανικής μάθησης, καθώς καλούνται να συσχετίσουν μεγέθη με έναν ευφάνταστο και πολύ συγκεκριμένο τρόπο.

Η συμβολή και τα στοιχεία καινοτομίας της παρούσας διατριβής παρουσιάζονται αναλυτικά παρακάτω:

- Εισάγεται μια προσέγγιση η οποία βασίζεται σε δεδομένα ως εναλλακτική στις μαθηματικές προσεγγίσεις για την αντιμετώπιση του προβλήματος της βελτιστοποίησης της πολιτικής αποθεματοποίησης. Η συγκεκριμένη προσέγγισή είναι γενικής και ευέλικτης φύσης, μπορεί να εφαρμοστεί σε πολύπλοκες πολιτικές και κάνει ελάχιστες υποθέσεις σχετικά με τις κατανομές της ζήτησης. Ως αποτέλεσμα, μπορεί εύκολα να τροποποιηθεί ως προς τις παραμέτρους ώστε να ταιριάζει καλύτερα στην εφαρμογή που εξετάζεται κάθε φορά.
- Η προτεινόμενη προσέγγιση εκμεταλλεύεται προηγμένες μεθόδους μηχανικής μάθησης, και πιο συγκεκριμένα μοντέλα δέντρων παλινδρόμησης ενίσχυσης κλίσης, για να προσεγγίσει διάφορες πτυχές της απόδοσης της διαδικασίας αποθεματοποίησης, όπως το μέσο απόθεμα, το πλήθος των χαμένων πωλήσεων και των παραγγελιών προς τους προμηθευτές, λαμβάνοντας υπόψη τα χαρακτηριστικά της ζήτησης και τις βασικές παραμέτρους της πολιτικής αποθεματοποίησης.
- Η απόδοση της προτεινόμενης μεθοδολογίας αξιολογείται εμπειρικά διενεργώντας μεγάλο πλήθος πειραμάτων σε ένα μεγάλο, πραγματικό σύνολο δεδομένων της

βιομηχανίας λιανικής και χρησιμοποιώντας ενδεικτικά σημεία αναφοράς.

- Αναδεικνύεται το γεγονός ότι, μόλις ολοκληρωθεί η φάση εκπαίδευσης των μοντέλων μηχανικής μάθησης, η προτεινόμενη προσέγγιση μπορεί να προσεγγίσει την απόδοση της διαδικασίας αποθεματοποίησης σε ένα κλάσμα του χρόνου που θα απαιτούσε μια τυπική, αναλυτική μέθοδος. Το συγκεκριμένο εύρημα καθιστά την προτεινόμενη προσέγγιση ένα ισχυρό εργαλείο για γρήγορη βελτιστοποίηση και λήψη αποφάσεων.
- Εκ των αποτελεσμάτων παρατηρείται ότι τα προτεινόμενα μοντέλα μηχανικής μάθησης μπορούν να εφαρμοστούν με τρόπο μεταφοράς μάθησης από ένα άλλο σύνολο δεδομένων με εξαιρετικά αποτελέσματα, ένα εύρημα που επιτρέπει την εκμετάλλευσή τους σε μεγάλη κλίμακα, ακόμη και από μικρού μεγέθους εταιρείες λιανικής, οι οποίες μπορεί να μην έχουν ούτε τα δεδομένα ούτε την εμπειρία που απαιτούνται για εκπαίδευση και εφαρμογή των μοντέλων.

Η παρούσα διατριβή, έτσι, έχει τη δυνατότητα να παράσχει πρακτικές λύσεις οι οποίες μπορούν να εφαρμοστούν από οργανισμούς διαφόρων τομέων για τη βελτίωση των πρακτικών τους, την αύξηση της κερδοφορίας και της ικανοποίησης των πελατών. Επιπλέον, μπορεί να συμβάλει ουσιαστικά στην ακαδημαϊκή βιβλιογραφία, με τη δυνατότητα να ανοίξει δρόμους για περαιτέρω έρευνα.

Επιπλέον, η παρούσα διατριβή θα μπορούσε να έχει θετικό αντίκτυπο και στην ανθρωπότητα με διάφορους τρόπους. Για παράδειγμα, βελτιώνοντας τις διαδικασίες αποθεματοποίησης, οι έμποροι λιανικής θα μπορούν να μειώσουν το αποτύπωμα άνθρακα ελαχιστοποιώντας τις ανάγκες μεταφοράς, οδηγώντας σε ένα πιο βιώσιμο μέλλον. Επιπλέον, η αποφυγή πλεονασματικών αποθεμάτων, μέσω της βελτιστοποίησης της αποθεματοποίησης, μπορεί να συμβάλει στη μείωση της σπατάλης ελαχιστοποιώντας την ποσότητα των απούλητων ευπαθών αγαθών, τα οποία τις περισσότερες φορές δεν φτάνουν ποτέ στον τελικό καταναλωτή. Η χρήση συστημάτων πρόβλεψης και διαχείρισης αποθεμάτων μπορεί επίσης να βοηθήσει τα νοσοκομεία και τις εγκαταστάσεις υγειονομικής περίθαλψης να βελτιστοποιήσουν τα επίπεδα αποθέματός τους και να διασφαλίσουν ότι ιατρικές προμήθειες και εξοπλισμός είναι διαθέσιμα όταν χρειάζεται. Αυτό μπορεί κατά συνέπεια να βοηθήσει από τη μία πλευρά σε περιπτώσεις έλλειψης σημαντικών ιατρικών προμηθειών, απαραίτητες για τους ασθενείς, αλλά και από την άλλη πλευρά στη μείωση του κόστους υγειονομικής περίθαλψης, προς όφελος τελικά της κοινωνίας στο σύνολό της. Τα παραπάνω μπορεί να έχουν δυναμικά αλυσιδωτές αντιδράσεις στην οικονομία, καθώς οι επιχειρήσεις μπορούν να μειώσουν τα έξοδά τους, να αυξήσουν τα κέρδη τους και να επενδύσουν σε άλλους τομείς, αυξάνοντας την κοινωνική και περιβαλλοντική τους ευθύνη, καθώς θα είχαν περισσότερα κεφάλαια για να το κάνουν.

### **10.3 Συμπεράσματα διατριβής**

Τα αποτελέσματα της πειραματικής διαδικασίας της παρούσας διατριβής δημιουργούν πολλά και ενδιαφέροντα συμπεράσματα. Ένα πρώτο συμπέρασμα είναι πως η χρήση αλγορίθμων μηχανικής μάθησης για την προσέγγιση των αποτελεσμάτων της διαδικασίας

αποθεματοποίησης κάτω από συγκεκριμένες συνθήκες κάθε φορά, και κατ' επέκταση η χρήση της συγκεκριμένης προσέγγισης για τη βελτιστοποίηση της πολιτικής αποθεματοποίησης, είναι προς τη θετική κατεύθυνση, παρουσιάζοντας ενθαρρυντικά αποτελέσματα.

Όσον αφορά στην εκπαίδευση των εν λόγω αλγορίθμων, στη γενική περίπτωση φαίνεται ότι η χρησιμοποίηση ενός πλήρους συνόλου δεδομένων ζήτησης το οποίο εμπεριέχει μεγάλο πλήθος χρονοσειρών ζήτησης όλων των πιθανών μοτίβων, και αναπαριστά την πραγματική ζήτηση και όχι τις πωλήσεις, έχει σημαντική θετική επίπτωση στα αποτελέσματα, ακόμα και στην περίπτωση όπου τα δεδομένα αυτά προέρχονται από διαφορετικό σύνολο δεδομένων από αυτό που εξετάζεται. Με τον τρόπο αυτό, γίνεται ξεκάθαρη η θετική επίδραση της μεταφοράς γνώσης από ένα αμερόληπτο σύνολο δεδομένων σε ένα άλλο.

Ένα ακόμα πλεονέκτημα αποτελεί το γεγονός πως, σύμφωνα με τα αποτελέσματα, τα οφέλη της χρήσης αλγορίθμων μηχανικής μάθησης είναι εμφανή σε διαφορετικές πολιτικές αποθεματοποίησης, επιβεβαιώνοντας, έτσι, το επιχείρημα ότι το προτεινόμενο μεθοδολογικό πλαίσιο είναι προσαρμόσιμο στις συνθήκες που επικρατούν κάθε φορά. Τα οφέλη αυτά είναι, επίσης, σταθερά ανεξάρτητα από το μοτίβο ζήτησης ή το σύνολο των προϊόντων που εξετάζονται.

Φυσικά, όπως είναι αναμενόμενο, αφού έχει ολοκληρωθεί η διαδικασία εκπαίδευσης των αλγορίθμων μηχανικής μάθησης της μεθοδολογίας, η εφαρμογή τους και κατά συνέπεια η προσέγγιση των αποτελεσμάτων της διαδικασίας αποθεματοποίησης μιας χρονοσειράς ζήτησης υπό μία πολιτική αποθεματοποίησης είναι σημαντικά γρηγορότερη από την πραγματοποίηση μιας προσομοίωσης με τα ίδια χαρακτηριστικά. Το γεγονός αυτό, αποτέλεσε και έναν από τους βασικότερους λόγους για τους οποίους εξετάστηκε η προτεινόμενη προσέγγιση, μιας και με τον τρόπο αυτό, και σε συνδυασμό με τα οφέλη της μεταφοράς μάθησης, δίνει τη δυνατότητα κατασκευής ενός ισχυρού και ταυτόχρονα γρήγορου εργαλείου για την υποστήριξη αποφάσεων στον συγκεκριμένο κλάδο.

Πιο συγκεκριμένα, εξετάζοντας την επίδοση της προτεινόμενης μεθοδολογίας, χρησιμοποιώντας την πολιτική αποθεματοποίησης  $(R, s, S)$  και τα δεδομένα του διαγωνισμού M5, προέκυψε ότι δύναται να μειώσει το συνολικό κόστος αποθεματοποίησης, όπως αυτό ορίστηκε στην παρούσα διατριβή, κατά 27% αυξάνοντας παράλληλα το επίπεδο εξυπηρέτησης πελατών κατά 2%. Η συγκεκριμένη μεθοδολογία, επίσης, επιφέρει 16% μικρότερο κόστος και 1% μεγαλύτερη εξυπηρέτηση πελατών στην περίπτωση όπου τα μοντέλα μηχανικής μάθησης εκπαιδεύτηκαν με ένα διαφορετικό, αλλά ταυτόχρονα πιο πλήρες, σύνολο δεδομένων από το σύνολο δεδομένων στόχο, δηλαδή αυτό του διαγωνισμού M5. Αφού τα μοντέλα μηχανικής μάθησης της προτεινόμενης προσέγγισης έχουν εκπαιδευτεί, η προσέγγιση του συνολικού κόστους αποθεματοποίησης μέσω του μεθοδολογικού πλαισίου, για συγκεκριμένες παραμέτρους αποθεματοποίησης και χρονοσειρά ζήτησης, είναι μέχρι και 70 φορές πιο γρήγορη από τον υπολογισμό του κόστους μέσω προσομοίωσης.

Από την εξέταση διαφορετικών μεθόδων πρόβλεψης της ζήτησης σε βελτιστοποιημένες και μη βελτιστοποιημένες πολιτικές αποθεματοποίησης, εκ των αποτελεσμάτων, πηγάζουν τρία χρήσιμα συμπεράσματα. Φυσικά, και σε απόλυτη ακολουθία με τη βιβλιογραφία, παρατηρείται ότι η βελτίωση της ακρίβειας των προβλέψεων δεν συνεπάγεται πάντα κάποια

ανάλογη βελτίωση στο συνολικό κόστος αποθεματοποίησης ή το επίπεδο εξυπηρέτησης πελατών. Παρά το παραπάνω συμπέρασμα, στη γενική περίπτωση η μείωση του προβλεπτικού σφάλματος είναι ευεργετική, αλλά μικρότερης σημασίας όσο πιο κοντά στη βέλτιστη είναι η πολιτική αποθεματοποίησης. Ακόμα πιο σημαντικό συμπέρασμα προκύπτει από τη σύγκριση της μείωσης του συνολικού κόστους αποθεματοποίησης όταν μπορεί να επιλεγεί μόνο μία εκ των βελτιώσεων της ακρίβειας των προβλέψεων ή της βελτιστοποίησης της πολιτικής αποθεματοποίησης. Φαίνεται ξεκάθαρα ότι τα οφέλη που προκύπτουν από τη βελτιστοποίηση της πολιτικής αποθεματοποίησης υπερτερούν αυτών που προκύπτουν από τη βελτίωση της ακρίβειας των προβλέψεων, χωρίς όμως να εξετάζεται το υπολογιστικό ή άλλο κόστος που μπορεί να επιφέρει η μία και η άλλη εναλλακτική. Πιο αναλυτικά, από μία αρχική κατάσταση μη βέλτιστης πολιτικής αποθεματοποίησης και μεθόδου πρόβλεψης σχετικά καλής ακρίβειας, είναι δυνατό να προκύψει μειωμένο κόστος κατά 18% εάν εντοπιστεί μία πιο ακριβής μέθοδος κατά 5%, ενώ αν εντοπιστούν οι σχεδόν βέλτιστες παράμετροι της πολιτικής αποθεματοποίησης, διατηρώντας ίδια την μέθοδο πρόβλεψης, είναι δυνατό να προκύψει μειωμένο κόστος κατά 33%.

Συνοπτικά, με την εφαρμογή της προτεινόμενης μεθοδολογίας μπορεί κανείς να επιλέξει με σχετική ασφάλεια τις βέλτιστες παραμέτρους πολιτικής αποθεματοποίησης για την εξεταζόμενη χρονοσειρά ζήτησης και τις επιμέρους συνθήκες που διέπουν την λειτουργία της εταιρείας και της αποθήκης του.

#### 10.4 Προεκτάσεις διατριβής

Αν και η προτεινόμενη μεθοδολογία αποδεικνύεται πως μπορεί να εντοπίσει τις βέλτιστες ή σχεδόν βέλτιστες τιμές των παραμέτρων μιας πολιτικής αποθεματοποίησης, ενώ ταυτόχρονα είναι σημαντικά γρηγορότερη από τις κλασσικές προσομοιώσεις, υπάρχουν αρκετές προεκτάσεις τόσο της μεθοδολογίας όσο και του κατασκευασμένου συστήματος προκειμένου να καταστούν ακόμα πιο αποδοτικά και να αποδώσουν μεγαλύτερο όφελος σε εταιρείες και υπευθύνους λήψης αποφάσεων.

Μια πρώτη επέκταση της μεθοδολογίας θα ήταν η εξέταση διαφορετικών αλγορίθμων μηχανικής μάθησης για την προσέγγιση των επιμέρους στοιχείων κόστους αποθεματοποίησης προκειμένου να εντοπιστεί εκείνος με τη μεγαλύτερη προβλεπτική ακρίβεια. Ενδιαφέρον επίσης θα είχε η ενσωμάτωση όλων των διεργασιών σε ένα μοντέλο, όπως για παράδειγμα σε ένα νευρωνικό δίκτυο με πολλαπλές εξόδους, ούτως ώστε να μην συντηρείται ένα διαφορετικό μοντέλο για κάθε στοιχείο κόστους αλλά μόνο ένα το οποίο μπορεί να είναι σε θέση να πραγματοποιείσαι ακόμα πιο σύνθετες συσχετίσεις μεταξύ των δεδομένων.

Μια άλλη προέκταση της διατριβής θα μπορούσε να είναι η επέκταση του μεθοδολογικού πλαισίου προκειμένου να είναι σε θέση να συμπεριλάβει ταυτόχρονα πολλαπλές πολιτικές αποθεματοποίησης, προφανώς διευρύνοντας το πλήθος των εισόδων των μοντέλων επιτρέποντας παραμέτρους που μπορεί να συναντώνται στη μία πολιτική αλλά όχι στην άλλη αλλά και παραμέτρους που υποδεικνύουν κάθε πολιτική. Με τον τρόπο αυτό το μεθοδολογικό πλαίσιο θα γινόταν ακόμα πιο γενικευμένο καθώς θα μπορούσε όχι μόνο να βελτιστοποιεί μία πολιτική αποθεματοποίησης κάθε φορά αλλά και να συγκρίνει



διαφορετικές πολιτικές προτείνοντας την βέλτιστη, γεγονός που στο πλαίσιο της παρούσας διατριβής πραγματοποιήθηκε για δύο πολιτικές, κάθε μία από τις οποίες βελτιστοποιήθηκε ξεχωριστά, χωρίς να έχουν συμπεριληφθεί ταυτόχρονα στην εκπαίδευση των μοντέλων μηχανικής μάθησης.

Μεγάλο ενδιαφέρον θα εμφάνιζε επίσης η εφαρμογή πιο σύνθετων τεχνικών μεταφοράς μάθησης, από αυτή που χρησιμοποιήθηκε στο πλαίσιο της διατριβής, κατά τις οποίες τα μοντέλα που έχουν εκπαιδευτεί με τις τεχνητές χρονοσειρές επανεκπαιδεύονται με το σύνολο δεδομένων που προβλέπεται και συντονίζονται καλύτερα στις χρονοσειρές υπό εξέταση. Η συγκεκριμένη προσέγγιση, ωστόσο, αν και θεωρητικά αναμένεται να έχει καλύτερη επίδοση είναι αρκετά πιο απαιτητική ως προς τους υπολογιστικούς πόρους και καθίσταται μη εφαρμόσιμη σε περιπτώσεις όπου οι σειρές στόχου είναι λίγες σε πλήθος ή μικρές σε μήκος, και ενδέχεται να έχει αντίθετα αποτελέσματα σε περιπτώσεις όπου δεν συναντώνται σειρές όλων των μοτίβων ζήτησης.

Η επέκταση της πειραματικής διαδικασίας με εξέταση επιπρόσθετων συνόλων δεδομένων εταιρειών λιανικής, αλλά και πολιτικών αποθεματοποίησης, θα είχε και αυτή με τη σειρά της αρκετό ενδιαφέρον, κυρίως λόγω του ότι θα επιβεβαιωνόταν σε μεγαλύτερο βαθμό η επίδοση του προτεινόμενου μεθοδολογικού πλαισίου σε διαφορετικές συνθήκες. Ωστόσο, η πρόσβαση σε πραγματικά δεδομένα ζήτησης είναι αρκετά περιορισμένη, καθιστώντας το συγκεκριμένο εγχείρημα μία δύσκολη διαδικασία.

Τέλος, η εφαρμογή που κατασκευάστηκε στο πλαίσιο της παρούσας διδακτορικής διατριβής και εμπεριέχει το προτεινόμενο μεθοδολογικό πλαίσιο θα μπορούσε να επεκταθεί περιλαμβάνοντας τις παραπάνω προεκτάσεις, προφανώς όπου αυτό είναι εφικτό, καθιστώντας τη ακόμα πιο πλήρη και πιο ισχυρή ως σύστημα υποστήριξης αποφάσεων.



## Βιβλιογραφία

---

- Abolghasemi, M., Beh, E., Tarr, G., & Gerlach, R. (2020). Demand forecasting in supply chain: The impact of demand volatility in the presence of promotion. *Computers & industrial engineering*, *142*, 106380.
- Akaike, H., Petrov, B. N., & Csaki, F. (1973). Information theory and an extension of the maximum likelihood principle. In Proceedings of the 2nd International Symposium on Information Theory. Armenia, USSR.
- Alfares, H. K., & Elmorra, H. H. (2005). The distribution-free newsboy problem: Extensions to the shortage penalty case. *International Journal of Production Economics*, *93-94*, 465-477.
- Ali, M. M., Boylan, J. E., & Syntetos, A. A. (2012). Forecast errors and inventory performance under forecast information sharing. *International Journal of Forecasting*, *28*, 830-841.
- Ali, Ö. G., Sayın, S., Van Woensel, T., & Fransoo, J. (2009). Sku demand forecasting in the presence of promotions. *Expert Systems with Applications*, *36*, 12340-12348.
- Alicke, K. (2005). *Planung und Betrieb von Logistiknetzwerken*. Springer.
- Altay, N., & Litteral, L. A. (2011). Service Parts Management. In *Demand Forecasting and Inventory Control, 1st Edition., XIV*. Springer.
- Altay, N., Litteral, L. A., & Rudisill, F. (2012). Effects of correlation on intermittent demand forecasting and stock control. *International Journal of Production Economics*, *135*, 275-283.
- Anderson, D. R., Sweeney, D. J., Williams, T. A., Camm, J. D., & Cochran, J. J. (2018). *An introduction to management science: quantitative approach*. Cengage learning.
- Archibald, B. C., & Silver, E. A. (1978). (s, s) policies under continuous review and discrete compound poisson demand. *Management Science*, *24*, 899-909.
- Armstrong, J. S. (2001). Combining forecasts. In *Principles of forecasting* (pp. 417-439). Springer.
- Assimakopoulos, V., & Nikolopoulos, K. (2000). The theta model: a decomposition approach to forecasting. *International journal of forecasting*, *16*, 521-530.

- Atkins, A., McPherson, J., & Allaire, J. (2021). *rsconnect: Deployment Interface for R Markdown Documents and Shiny Applications*. R package version 0.8.25.
- Axsäter, S. (1996). Using the deterministic EOQ formula in stochastic inventory control. *Management Science*, 42, 830–834.
- Ayodele, T. O. (2010). Types of machine learning algorithms. *New advances in machine learning*, 3, 19–48.
- Babai, M., Dallery, Y., Boubaker, S., & Kalai, R. (2019). A new method to forecast intermittent demand in the presence of inventory obsolescence. *International Journal of Production Economics*, 209, 30–41.
- Babai, M. Z., Syntetos, A., & Teunter, R. (2014). Intermittent demand forecasting: An empirical study on accuracy and the risk of obsolescence. *International Journal of Production Economics*, 157, 212–219.
- Babai, M. Z., Syntetos, A. A., & Teunter, R. (2010). On the empirical performance of (T, s, S) heuristics. *European Journal of Operational Research*, 202, 466–472.
- Ban, G.-Y. (2020). Confidence intervals for data-driven inventory policies with demand censoring. *Operations Research*, 68, 309–326.
- Barton, R. R. (1998). Simulation metamodels. In *1998 Winter Simulation Conference. Proceedings (Cat. No. 98CH36274)* (pp. 167–174). IEEE volume 1.
- Bates, D., & Maechler, M. (2021). *Matrix: Sparse and Dense Matrix Classes and Methods*. R package version 1.3-4.
- Bell, C. E. (1970). Improved algorithms for inventory and replacement-stocking problems. *SIAM Journal on Applied Mathematics*, 18, 558–566.
- Bellman, R., Glicksberg, I., & Gross, O. (1955). On the optimal inventory equation. *Management Science*, 2, 83–104.
- Berling, P., & Rosling, K. (2005). The effects of financial risks on inventory policy. *Management Science*, 51, 1804–1815.
- Bertsimas, D., & Kallus, N. (2020). From predictive to prescriptive analytics. *Management Science*, 66, 1025–1044.
- Bijvank, M. (2009). *Service Inventory Management: solution techniques for inventory systems without backorders*. Ph.D. thesis Vrije Universiteit, Amsterdam Netherlands.
- Bijvank, M., & Vis, I. F. (2011). Lost-sales inventory theory: A review. *European Journal of Operational Research*, 215, 1–13.
- Bojer, C. S., & Meldgaard, J. P. (2021). Kaggle forecasting competitions: An overlooked learning opportunity. *International Journal of Forecasting*, 37, 587–603.

- Bookbinder, J. H., & Lordahl, A. E. (1989). Estimation of inventory re-order levels using the bootstrap statistical procedure. *IIE transactions*, *21*, 302–312.
- Boutselis, P., & McNaught, K. (2019). Using bayesian networks to forecast spares demand from equipment failures in a changing service logistics context. *International Journal of Production Economics*, *209*, 325–333.
- Boylan, J. E., & Syntetos, A. A. (2007). The accuracy of a modified croston procedure. *International Journal of Production Economics*, *107*, 511–517.
- Boylan, J. E., Syntetos, A. A., & Karakostas, G. C. (2008). Classification for forecasting and stock control: a case study. *Journal of the operational research society*, *59*, 473–481.
- Brown, R. G. (1959). *Statistical forecasting for inventory control*. McGraw-Hill, New York.
- Carmo, J. L., & Rodrigues, A. J. (2004). Adaptive forecasting of irregular demand processes. *Engineering Applications of Artificial Intelligence*, *17*, 137–143.
- Chang, W., Cheng, J., Allaire, J., Sievert, C., Schloerke, B., Xie, Y., Allen, J., McPherson, J., Dipert, A., & Borges, B. (2021). *shiny: Web Application Framework for R*. R package version 1.7.1.
- Chen, T., & Guestrin, C. (2016). Xgboost: A scalable tree boosting system. (pp. 785–794). In Proceedings of the 22nd SIGKDD International Conference on Knowledge Discovery and Data Mining.
- Christ, M., Braun, N., Neuffer, J., & Kempa-Liehr, A. W. (2018). Time Series Feature Extraction on basis of Scalable Hypothesis tests (tsfresh – a Python package). *Neurocomputing*, *307*, 72 – 77.
- Christou, I., Skouri, K., & Lagodimos, A. G. (2020). Fast evaluation of a periodic review inventory policy. *Computers & Industrial Engineering*, *144*, 106389.
- Clemen, R. T. (1989). Combining forecasts: A review and annotated bibliography. *International Journal of Forecasting*, *5*, 559–583.
- Cleveland, R. B., Cleveland, W. S., McRae, J. E., & Terpenning, I. J. (1990). STL: A seasonal-trend decomposition. *J. Off. Stat*, *6*, 3–73.
- Cleveland, W. S., Dunn, D. M., & Terpenning, I. J. (1978). SABL: A resistant seasonal adjustment procedure with graphical methods for interpretation and diagnosis. In *Seasonal analysis of economic time series* (pp. 201–241). NBER.
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine learning*, *20*, 273–297.
- Crone, S. F., Hibon, M., & Nikolopoulos, K. (2011). Advances in forecasting with neural networks? Empirical evidence from the NN3 competition on time series prediction. *International Journal of forecasting*, *27*, 635–660.

- Croston, J. D. (1972). Forecasting and Stock Control for Intermittent Demands. *Journal of the Operational Research Society*, 23, 289–303.
- Davis, T. (1993). Effective supply chain management. *Sloan management review*, 34, 35–35.
- De Moor, B. J., Gijbrecchts, J., & Boute, R. N. (2022). Reward shaping to improve the performance of deep reinforcement learning in perishable inventory management. *European Journal of Operational Research*, 301, 535–545.
- Dhoka, D. K., & Choudary, Y. L. (2013). XYZ inventory classification & challenges. *IOSR Journal of Economics and Finance*, 2, 23–26.
- Dickie, H. F. (1951). ABC inventory analysis shoots for dollars not pennies. *Factory Management and Maintenance*, 109, 92–94.
- Eaves, A., & Kingsman, B. (2004). Forecasting for the ordering and stock-holding of spare parts. *Journal of The Operational Research Society*, 55, 431–437.
- Efron, B. (1979). Bootstrap methods: Another look at the jackknife. *The Annals of Statistics*, 7, 126.
- Emmanuel Ebikake, O. (2014). Safety Stock Provision Amid Fluctuating Demand In The UK Automotive Industry. In *Logistics Research Network*.
- Fang, K.-T., Li, R., & Sudjianto, A. (2005). *Design and modeling for computer experiments*. Chapman and Hall/CRC.
- Federgruen, A., & Zheng, Y. S. (1992). An efficient algorithm for computing an optimal (r, Q) policy in continuous review stochastic inventory systems. *Operations research*, 40, 808–813.
- Federgruen, A., & Zipkin, P. (1984). An efficient algorithm for computing optimal (s, S) policies. *Operations research*, 32, 1268–1285.
- Fildes, R., Ma, S., & Kolassa, S. (2022). Retail forecasting: Research and practice. *International Journal of Forecasting*, 38, 1283–1318. Special Issue: M5 competition.
- Fonseca, D. J., Navarrese, D. O., & Moynihan, G. P. (2003). Simulation metamodeling through artificial neural networks. *Engineering applications of artificial intelligence*, 16, 177–183.
- Friedman, J. H. (2001). Greedy function approximation: a gradient boosting machine. *Annals of statistics*, (pp. 1189–1232).
- Gagniuc, P. A. (2017). *Markov chains: From theory to implementation and experimentation*. John Wiley & Sons.
- Gardner, E. S. (1990). Evaluating Forecast Performance in an Inventory Control System. *Management Science*, 36, 490–499.

- Gardner, E. S. (2006). Exponential smoothing: The state of the art—Part II. *International Journal of Forecasting*, 22, 637–666.
- Gardner Jr, E. S. (1985). Exponential smoothing: The state of the art. *Journal of forecasting*, 4, 1–28.
- Gardner Jr, E. S., & McKenzie, E. (1989). Note—Seasonal exponential smoothing with damped trends. *Management Science*, 35, 372–376.
- Gautam, Y. (2022). Transfer learning for covid-19 cases and deaths forecast using lstm network. *ISA Transactions*, 124, 41–56.
- Gneiting, T., & Katzfuss, M. (2014). Probabilistic Forecasting. *Annual Review of Statistics and Its Application*, 1, 125–151.
- Goltsos, T. E., Syntetos, A. A., Glock, C. H., & Ioannou, G. (2022). Inventory - forecasting: Mind the gap. *European Journal of Operational Research*, 299, 397–419.
- Greasley, A. (2013). *Operations management*. 3rd ed. John Wiley & Sons Limited, England.
- Gudehus, T., & Kotzab, H. (2012). *Comprehensive logistics*. Springer Science & Business Media.
- Gutierrez, R. S., Solis, A. O., & Mukhopadhyay, S. (2008). Lumpy demand forecasting using neural networks. *International journal of production economics*, 111, 409–420.
- Hachicha, W. (2011). A simulation metamodelling based neural networks for lot-sizing problem in MTO sector. *International Journal of Simulation Modelling*, 10, 191–203.
- Hadley, G., & Whitin, T. (1963). *Analysis of Inventory systems*. Prentice-Hall, Englewood Cliffs.
- Harris, F. W. (1913). How many parts to make at once. *Factory, The Magazine of Management*, 10, 135–136.
- Hax, A., & Candea, D. (1984). *Production and Inventory Management*. Prentice-Hall, Englewood Cliffs.
- Heath, D. C., & Jackson, P. L. (1994). Modeling the evolution of demand forecasts with application to safety stock analysis in production/distribution systems. *IIE Transactions*, 26, 17–30.
- Heizer, J., & Render, B. (2013). *Operations management, global edition*. Pearson Education.
- Hemalatha, S., & Annadurai, K. (2020). *Inventory models involving lead time crashing cost as an exponential function with ordering cost reduction dependent on lead time*. Materials Today: Proceedings.

- Herrmann, F. (2011). *Operative Planung in IT-Systemen für die Produktionsplanung und -steuerung: Wirkung, Auswahl und Einstellhinweise von Verfahren und Parametern*. Springer-Verlag.
- Ho, T. K. (1995). Random decision forests. In *Proceedings of 3rd international conference on document analysis and recognition* (pp. 278–282). IEEE volume 1.
- Holt, C. C. (1957). Forecasting seasonals and trends by exponentially weighted averages (onr memorandum no. 52). *Carnegie Institute of Technology, Pittsburgh USA*, 10.
- Hsiao, C., & Wan, S. K. (2014). Is there an optimal forecast combination? *Journal of Econometrics*, 178, 294–309.
- Hu, W. T., Kim, S. L., & Banerjee, A. (2009). An inventory model with partial backordering and unit backorder cost linearly increasing with the waiting time. *European Journal of Operational Research*, 197, 581–587.
- Hunduza, A. (2020). *Dynamic Safety Stock Considerations - A simulation based comparative analysis*. Jacobs University Technical Reports.
- Hunt, E. B., Marin, J., & Stone, P. J. (1966). *Experiments in induction*. Academic press.
- Hyndman, R., Kang, Y., Montero-Manso, P., Talagala, T., Wang, E., Yang, Y., & O'Hara-Wild, M. (2020). *tsfeatures: Time Series Feature Extraction*. R package version 1.0.2.
- Hyndman, R., Koehler, A. B., Ord, J. K., & Snyder, R. D. (2008). *Forecasting with exponential smoothing: the state space approach*. Springer Science & Business Media.
- Hyndman, R. J., & Billah, B. (2003). Unmasking the Theta method. *International Journal of Forecasting*, 19, 287–290.
- Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International journal of forecasting*, 22, 679–688.
- Inprasit, T., & Tanachutiwat, S. (2018). Reordering point determination using machine learning technique for inventory management. In *2018 International Conference on Engineering, Applied Sciences, and Technology (ICEAST)* (pp. 1–4). IEEE.
- Jacobs, P. A., & Lewis, P. A. (1978). Discrete time series generated by mixtures. I: Correlational and runs properties. *Journal of the Royal Statistical Society: Series B (Methodological)*, 40, 94–105.
- Johnson, E. L. (1968). On (s, S) policies. *Management Science*, 15, 80–101.
- Johnston, F. R., & Boylan, J. E. (1996). Forecasting for Items with Intermittent Demand. *The Journal of the Operational Research Society*, 47, 113–121.
- Johnston, F. R., Shale, E. A., Kapoor, S., True, R., & Sheth, A. (2011). Breadth of range and depth of stock: forecasting and inventory management at Euro Car Parts Ltd. *Journal of the Operational Research Society*, 62, 433–441.



- Kang, Y., Hyndman, R. J., & Li, F. (2020). GRATIS: GeneRATING Time Series with diverse and controllable characteristics. *Statistical Analysis and Data Mining: The ASA Data Science Journal*, 13, 354–376.
- Kang, Y., Hyndman, R. J., & Smith-Miles, K. (2017). Visualising forecasting algorithm performance using time series instance spaces. *International Journal of Forecasting*, 33, 345–358.
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., & Liu, T.-Y. (2017). Lightgbm: A highly efficient gradient boosting decision tree. In I. Guyon, U. V. Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan, & R. Garnett (Eds.), *Advances in Neural Information Processing Systems*. Curran Associates, Inc. volume 30.
- Ke, G., Soukhavong, D., Lamb, J., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., & Liu, T.-Y. (2020). *lightgbm: Light Gradient Boosting Machine*. R package version 3.1.1.
- Kendall, M. G. et al. (1946). *The advanced theory of statistics*. 2nd Ed. Charles Griffin and Co. Ltd., London.
- King, P. L. (2011). Crack the code: Understanding safety stock and mastering its equations. *APICS magazine*, 21, 33–36.
- Kostenko, A. V., & Hyndman, R. J. (2006). A note on the categorization of demand patterns. *Journal of the Operational Research Society*, 57, 1256–1257.
- Kotsiantis, S. B., Zaharakis, I., Pintelas, P. et al. (2007). Supervised machine learning: A review of classification techniques. *Emerging artificial intelligence applications in computer engineering*, 160, 3–24.
- Kourentzes, N. (2013). Intermittent demand forecasts with neural networks. *International Journal of Production Economics*, 143, 198–206.
- Kourentzes, N., Petropoulos, F., & Trapero, J. R. (2014). Improving forecasting by estimating time series structural components across multiple frequencies. *International Journal of Forecasting*, 30, 291–302.
- Kourentzes, N., Svetunkov, I., & Trapero, J. R. (2021). Connecting forecasting and inventory performance: a complex task. Available at SSRN 3878176.
- Kourentzes, N., Trapero, J. R., & Barrow, D. K. (2020). Optimising forecasting models for inventory planning. *International Journal of Production Economics*, 225, 107597.
- Koutsandreas, D., Spiliotis, E., Petropoulos, F., & Assimakopoulos, V. (2022). On the selection of forecasting accuracy measures. *Journal of the Operational Research Society*, 73, 937–954.
- Krijthe, J. H. (2015). *Rtsne: T-distributed stochastic neighbor embedding using Barnes-Hut implementation*. R package version 0.13.

- Krupp, J. A. (1994). Are ABC codes an obsolete technology. *APICS-The Performance Advantage*, 4, 34-35.
- Küenle, C., & Küenle, H. (1977). Durchschnittsoptimale strategien in markovschen entscheidungsmodellea bei unbeschränkten kosten. *Mathematische Operationsforschung und Statistik. Series Optimization*, 8, 549-564.
- Kuiper, J. (1978). A survey and comparative analysis of various methods of seasonal adjustment. In *Seasonal analysis of economic time series* (pp. 59-94). NBER.
- Lagodimos, A., Christou, I., & Skouri, K. (2012). Computing globally optimal (s,S,T) inventory policies. *Omega*, 40, 660-671.
- Lambert, D. M., & Stock, J. R. (1993). *Strategic logistics management* volume 3. Irwin Homewood, IL.
- Ledolter, J. (1989). The effect of additive outliers on the forecasts from ARIMA models. *International Journal of Forecasting*, 5, 231-240.
- Levén, E., & Segerstedt, A. (2004). Inventory control with a modified Croston procedure and Erlang distribution. *International Journal of Production Economics*, 90, 361-367. Production Control and Scheduling.
- Liao, Y., Banerjee, A., & Yan, C. (2011). A distribution-free newsvendor model with balking and lost sales penalty. *International Journal of Production Economics*, 133, 224-227.
- Lodree Jr, E. J. (2007). Advanced supply chain planning with mixtures of backorders, lost sales, and lost contract. *European Journal of Operational Research*, 181, 168-183.
- Lolli, F., Gamberini, R., Regattieri, A., Balugani, E., Gatos, T., & Gucci, S. (2017). Single-hidden layer neural networks for forecasting intermittent demand. *International Journal of Production Economics*, 183, 116-128.
- Van der Maaten, L., & Hinton, G. (2008). Visualizing data using t-SNE. *Journal of machine learning research*, 9.
- Makridakis, S., Andersen, A., Carbone, R., Fildes, R., Hibon, M., Lewandowski, R., Newton, J., Parzen, E., & Winkler, R. (1982). The accuracy of extrapolation (time series) methods: Results of a forecasting competition. *Journal of forecasting*, 1, 111-153.
- Makridakis, S., Chatfield, C., Hibon, M., Lawrence, M., Mills, T., Ord, K., & Simmons, L. F. (1993). The M2-competition: A real-time judgmentally based forecasting study. *International Journal of forecasting*, 9, 5-22.
- Makridakis, S., & Hibon, M. (2000). The M3-Competition: results, conclusions and implications. *International journal of forecasting*, 16, 451-476.
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2020). The M4 Competition: 100,000 time series and 61 forecasting methods. *International Journal of Forecasting*, 36, 54-74.

- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2022). The M5 competition: Background, organization, and implementation. *International Journal of Forecasting*, 38, 1325-1336.
- Makridakis, S., Wheelwright, S., & McGee, V. (1983). *Forecasting: Methods and Applications (Second Edition)*. John Wiley & Sons, New York.
- McKenzie, E. (1986). Autoregressive moving-average processes with negative-binomial and geometric marginal distributions. *Advances in Applied probability*, 18, 679-705.
- McKenzie, S. K. (1984). Concurrent seasonal adjustment with census X-11. *Journal of Business & Economic Statistics*, 2, 235-249.
- Milborrow, S. (2021). *rpart.plot: Plot "rpart" Models: An Enhanced Version of "plot.rpart"*. R package version 3.1.0.
- Miller, D. M., & Williams, D. (2003). Shrinkage estimators of time series seasonal factors and their effect on forecasting accuracy. *International Journal of Forecasting*, 19, 669-684.
- Millstein, M. A., Yang, L., & Li, H. (2014). Optimizing ABC inventory grouping decisions. *International Journal of Production Economics*, 148, 71-80.
- Mitchell, T. M. (1997). *Machine Learning*. New York: McGraw-Hill.
- Mohammadipour, M. (2013). *Intermittent demand forecasting with integer autoregressive moving average models*. Ph.D. thesis Brunel University, London.
- Montero-Manso, P., Athanasopoulos, G., Hyndman, R. J., & Talagala, T. S. (2020). FFORMA: Feature-based forecast model averaging. *International Journal of Forecasting*, 36, 86-92.
- Montgomery, D. C., Bazaraa, M., & Keswani, A. K. (1973). Inventory models with a mixture of backorders and lost sales. *Naval Research Logistics Quarterly*, 20, 255-263.
- Mukhopadhyay, S., Solis, A. O., & Gutierrez, R. S. (2012). The accuracy of non-traditional versus traditional methods of forecasting lumpy demand. *Journal of Forecasting*, 31, 721-735.
- Müller, S. (2020). *Data-driven inventory optimization*. Ph.D. thesis Universität Mannheim, Mannheim Germany.
- Nagurney, A. (2006). *Supply chain network economics: dynamics of prices, flows and profits*. Edward Elgar Publishing.
- Naidu, D. S. (2002). *Optimal control systems*. CRC press.
- Namir, K., Labriji, H. et al. (2022). Decision Support Tool for Dynamic Inventory Management using Machine Learning, Time Series and Combinatorial Optimization. *Procedia Computer Science*, 198, 423-428.

- Nasiri Pour, A., Rostami-Tabar, B., & Rahimzadeh, A. (2008). A hybrid neural network and traditional approach for forecasting lumpy demand. *Proceedings of the World Academy of Science, Engineering and Technology*, 2.
- Nenes, G., Panagiotidou, S., & Tagaras, G. (2010). Inventory management of multiple items with irregular demand: A case study. *European Journal of Operational Research*, 205, 313–324.
- Nikolopoulos, K. (2021). We need to talk about intermittent demand forecasting. *European Journal of Operational Research*, 291, 549–559.
- Nikolopoulos, K., & Assimakopoulos, V. (2005). Theta model: decomposition approach or just SES with drift? In Proceedings of the 25th International Symposium on Forecasting. San Antonio, USA.
- Nikolopoulos, K., Syntetos, A. A., Boylan, J. E., Petropoulos, F., & Assimakopoulos, V. (2011). An aggregate-disaggregate intermittent demand approach (ADIDA) to forecasting: an empirical proposition and analysis. *Journal of the Operational Research Society*, 62, 544–554.
- Nikolopoulos, K. I., Babai, M. Z., & Bozos, K. (2016). Forecasting supply chain sporadic demand with nearest neighbor approaches. *International Journal of Production Economics*, 177, 139–148.
- Pearson, K. (1901). On lines and planes of closest fit to systems of points in space. *The London, Edinburgh, and Dublin philosophical magazine and journal of science*, 2, 559–572.
- Pedrosa, G. C., Conceição, S. V., & Miranda, D. M. (2011). Comparison of a new bootstrapping method with parametric approach considering stochastic lead time. In Proceedings of the 17th International Conference of Industrial Engineering and Operations Management.
- Pegels, C. C. (1969). Exponential forecasting: Some new variations. *Management Science*, (pp. 311–315).
- Petropoulos, F., Apiletti, D., Assimakopoulos, V., Babai, M. Z., Barrow, D. K., Ben Taieb, S., Bergmeir, C., Bessa, R. J., Bijak, J., Boylan, J. E., Browell, J., Carnevale, C., Castle, J. L., Cirillo, P., Clements, M. P., Cordeiro, C., Cyrino Oliveira, F. L., De Baets, S., Dokumentov, A., Ellison, J., Fiszeder, P., Franses, P. H., Frazier, D. T., Gilliland, M., Gönül, M. S., Goodwin, P., Grossi, L., Grushka-Cockayne, Y., Guidolin, M., Guidolin, M., Gunter, U., Guo, X., Guseo, R., Harvey, N., Hendry, D. F., Hollyman, R., Januschowski, T., Jeon, J., Jose, V. R. R., Kang, Y., Koehler, A. B., Kolassa, S., Kourentzes, N., Leva, S., Li, F., Litsiou, K., Makridakis, S., Martin, G. M., Martinez, A. B., Meeran, S., Modis, T., Nikolopoulos, K., Önköl, D., Paccagnini, A., Panagiotelis, A., Panapakidis, I., Pavia, J. M., Pedio, M., Pedregal, D. J., Pinson, P., Ramos, P., Rapach, D. E., Reade, J. J., Rostami-Tabar, B., Rubaszek, M., Sermpinis, G., Shang,

- H. L., Spiliotis, E., Syntetos, A. A., Talagala, P. D., Talagala, T. S., Tashman, L., Thomakos, D., Thorarinsdottir, T., Todini, E., Trapero Arenas, J. R., Wang, X., Winkler, R. L., Yusupova, A., & Ziel, F. (2022). Forecasting: theory and practice. *International Journal of Forecasting*, 38, 705–871.
- Petropoulos, F., & Kourentzes, N. (2014). Forecast Combinations for Intermittent Demand. *Journal of the Operational Research Society*, 66.
- Petropoulos, F., Kourentzes, N., & Nikolopoulos, K. (2016). Another look at estimators for intermittent demand. *International Journal of Production Economics*, 181, 154–161.
- Petropoulos, F., Makridakis, S., Assimakopoulos, V., & Nikolopoulos, K. (2014). ‘Horses for Courses’ in demand forecasting. *European Journal of Operational Research*, 237, 152–163.
- Pinçe, C., Turrini, L., & Meissner, J. (2021). Intermittent demand forecasting for spare parts: A critical review. *Omega*, 105, 102513.
- Plinere, D., Borisov, A. et al. (2015). Case study on inventory management improvement. *Information Technology and Management Science*, 18, 91–96.
- Porras Musalem, E. (2005). *Inventory theory in practice: Joint replenishments and spare parts control (Chapter 6)*. Ph.D. thesis Erasmus University Rotterdam (Tinbergen Institute), The Netherlands.
- Priniotakis, G., & Argyropoulos, P. (2018). Inventory management concepts and techniques. *IOP Conference Series: Materials Science and Engineering*, 459, 012060.
- R Development Core Team (2008). R: A language and environment for statistical computing. R Foundation for Statistical Computing. Vienna, Austria.
- Ravinder, H., & Misra, R. B. (2014). ABC analysis for inventory management: Bridging the gap between research and classroom. *American journal of business education*, 7, 257–264.
- Reichmann, W. J. et al. (1962). *Use and abuse of statistics*. Oxford University Press.
- Reid, R. D., & Sanders, N. R. (2019). *Operations management: an integrated approach*. John Wiley & Sons.
- Reynolds, M. (1994). Spare parts inventory management. *APICS-the Performance Advantage*, 1, 42–46.
- Rogala, M., & Zyla, K. (2022). *shiny.fluent: Microsoft Fluent UI for Shiny Apps*. R package version 0.2.1.
- Rosenblatt, F. (1957). *The perceptron, a perceiving and recognizing automaton*. Cornell Aeronautical Laboratory.

- Ross, I. M. (2015). *A primer on Pontryagin's principle in optimal control*. Collegiate publishers.
- Russell, S., & Norvig, P. (2010). *Artificial Intelligence: A Modern Approach*. (3rd ed.). Prentice Hall.
- Russell, S., & Taylor, W. (2010). *Operations Management Creating Value*. John Wiley & Sons, Inc.
- Sahin, I., & Sinha, D. (1987). On asymptotic approximations for (s, S) policies. *Stochastic Analysis and Applications*, 5, 189-212.
- Sanders, R. (1987). The Pareto principle: its use and abuse. *Journal of Services Marketing*, 1, 37-40.
- Sani, B., & Kingsman, B. G. (1997). Selecting the best periodic inventory control and demand forecasting methods for low demand items. *Journal of the operational research society*, 48, 700-713.
- Scarf, H. (1959). *The optimality of (s, S) policies in the dynamic inventory problem*. Chapter 13 in *Mathematical Methods in the Social Sciences*. Eds. K. Arrow, S. Karlin, and P. Suppes. Stanford University Press, CA.
- Schneider, H. (1978). Methods for determining the re-order point of an (s, S) ordering policy when a service level is specified. *Journal of the Operational Research Society*, 29, 1181-193.
- Schwarz, G. (1978). Estimating the dimension of a model. *The annals of statistics*, (pp. 461-464).
- SCMDojo (2017). *Safety Stock Formula And Safety Stock Calculation-The Ultimate Guide*. [online] Available at: <http://www.scmdojo.com/safety-stock-formula> [Accessed December 2021].
- Seaman, B. (2018). Considerations of a retail forecasting practitioner. *International Journal of Forecasting*, 34, 822 - 829.
- Segerstedt, A., & Levén, E. (2020). A study of different Croston-like forecasting methods. Retrieved from <http://urn.kb.se/resolve?urn=urn:nbn:se:ltu:diva-78088>.
- Segev, N., Harel, M., Mannor, S., Crammer, K., & El-Yaniv, R. (2016). Learn on source, refine on target: A model transfer learning framework with random forests. *IEEE transactions on pattern analysis and machine intelligence*, 39, 1811-1824.
- Shale, E. A., Boylan, J. E., & Johnston, F. (2006). Forecasting for intermittent demand: the estimation of an unbiased average. *Journal of the Operational Research Society*, 57, 588-592.
- Shang, K. H., & Zhou, S. X. (2010). Optimal and Heuristic Echelon (r, nQ, T) Policies in Serial Inventory Systems with Fixed Costs. *Operations Research*, 58, 414-427.

- Silver, E. A. (1973). A heuristic for selecting lot size quantities for the case of a deterministic time-varying demand rate and discrete opportunities for replenishment. *Prod. Inventory Manage.*, 2, 64–74.
- Silver, E. A. (1981). Operations Research in Inventory Management: A Review and Critique. *Operations Research*, 29, 628–645.
- Silver, E. A., Pyke, D. F., Peterson, R. et al. (1998). *Inventory management and production planning and scheduling* volume 3. Wiley New York.
- Simon, H. (2009). *Neural networks and learning machines*. Pearson Education.
- Slack, N., Chambers, S., & Johnston, R. (2010). *Operations management*. Pearson Education.
- Smyl, S. (2020). A hybrid method of exponential smoothing and recurrent neural networks for time series forecasting. *International Journal of Forecasting*, 36, 75–85.
- Snyder, R. (2002). Forecasting sales of slow and fast moving inventories. *European Journal of Operational Research*, 140, 684–699.
- Spiliotis, E., Kouloumos, A., Assimakopoulos, V., & Makridakis, S. (2020). Are forecasting competitions data representative of the reality? *International Journal of Forecasting*, 36, 37–53.
- Spiliotis, E., Makridakis, S., Kaltsounis, A., & Assimakopoulos, V. (2021). Product sales probabilistic forecasting: An empirical evaluation using the M5 competition data. *International Journal of Production Economics*, 240, 108237.
- Spiliotis, E., Makridakis, S., Semoglou, A.-A., & Assimakopoulos, V. (2022). Comparison of statistical and machine learning methods for daily SKU demand forecasting. *Operational Research*, 22, 3037–3061.
- Strijbosch, L., & Moors, J. (2002). *Simulating an (R,s,S) Inventory System*. Technical Report Econometrics. Pagination: 13.
- Sustrova, T. (2016). An Artificial Neural Network Model for a Wholesale Company's Order-Cycle Management. *International Journal of Engineering Business Management*, 8, 2.
- Syntetos, A., Babai, M., Davies, J., & Stephenson, D. (2010). Forecasting and stock control: A study in a wholesaling context. *International Journal of Production Economics*, 127, 103–111.
- Syntetos, A. A., Babai, M. Z., Lengu, D., & Altay, N. (2011). Distributional assumptions for parametric forecasting of intermittent demand. In N. Altay, & L. A. Litteral (Eds.), *Service Parts Management: Demand Forecasting and Inventory Control* (pp. 31–52). London: Springer London.

- Syntetos, A. A., Babai, Z., Boylan, J. E., Kolassa, S., & Nikolopoulos, K. (2016). Supply chain forecasting: Theory, practice, their gap and the future. *European Journal of Operational Research*, 252, 1–26.
- Syntetos, A. A., & Boylan, J. E. (2001). On the bias of intermittent demand estimates. *International journal of production economics*, 71, 457–466.
- Syntetos, A. A., & Boylan, J. E. (2005). The accuracy of intermittent demand estimates. *International Journal of forecasting*, 21, 303–314.
- Syntetos, A. A., & Boylan, J. E. (2006a). On the stock control performance of intermittent demand estimators. *International Journal of Production Economics*, 103, 36–47.
- Syntetos, A. A., & Boylan, J. E. (2006b). Smoothing and adjustments of demand forecasts for inventory control. *IFAC Proceedings Volumes*, 39, 173–178. 12th IFAC Symposium on Information Control Problems in Manufacturing.
- Syntetos, A. A., & Boylan, J. E. (2008). Demand forecasting adjustments for service-level achievement. *IMA Journal of Management Mathematics*, 19, 175–192.
- Syntetos, A. A., Boylan, J. E., & Croston, J. D. (2005). On the categorization of demand patterns. *Journal of the Operational Research Society*, 56, 495–503.
- Syntetos, A. A., Zied Babai, M., & Gardner, E. S. (2015). Forecasting intermittent inventory demands: simple parametric methods vs. bootstrapping. *Journal of Business Research*, 68, 1746–1752.
- Tashman, L. J. (2000). Out-of-sample tests of forecasting accuracy: an analysis and review. *International Journal of Forecasting*, 16, 437–450.
- Taylor, J. W. (2003). Exponential smoothing with a damped multiplicative trend. *International journal of Forecasting*, 19, 715–725.
- Taylor, J. W. (2007). Forecasting daily supermarket sales using exponentially weighted quantile regression. *European Journal of Operational Research*, 178, 154–167.
- Teunter, R. H., & Duncan, L. (2009). Forecasting intermittent demand: a comparative study. *Journal of the Operational Research Society*, 60, 321–329.
- Teunter, R. H., Syntetos, A. A., & Zied Babai, M. (2011). Intermittent demand: Linking forecasting to inventory obsolescence. *European Journal of Operational Research*, 214, 606–615.
- Theil, H. (1966). *Applied Economic Forecasting*. Chicago: Rand McNally.
- Theodorou, E., Spiliotis, E., & Assimakopoulos, V. (2019). Supply chain management: Bridging the gap between business and academia. In Proceedings of the 39th International Symposium on Forecasting. Thessaloniki, Greece.



- Theodorou, E., Spiliotis, E., & Assimakopoulos, V. (2020). Footfall forecasting as a workforce optimization tool. In Proceedings of the 40th International Symposium on Forecasting. Online.
- Theodorou, E., Spiliotis, E., & Assimakopoulos, V. (2021a). Evaluating the impact of business practices on inventory performance. In Proceedings of the 41st International Symposium on Forecasting. Online.
- Theodorou, E., Spiliotis, E., & Assimakopoulos, V. (2022a). Better forecasts or more appropriate stock control policies? *Foresight: The International Journal of Applied Forecasting*, Issue 68, 40–44.
- Theodorou, E., Spiliotis, E., & Assimakopoulos, V. (2022b). A data-driven stock control optimization framework. In Proceedings of the 42nd International Symposium on Forecasting. Oxford, England.
- Theodorou, E., Spiliotis, E., & Assimakopoulos, V. (2022c). Optimizing inventory control through a data-driven and model-independent framework. *EURO Journal on Transportation and Logistics*, 12, 100103.
- Theodorou, E., Wang, S., Kang, Y., Spiliotis, E., Makridakis, S., & Assimakopoulos, V. (2021b). Exploring the representativeness of the M5 competition data. *International Journal of Forecasting*, 38, 1500–1506.
- Therneau, T., & Atkinson, B. (2019). *rpart: Recursive Partitioning and Regression Trees*. R package version 4.1-15.
- Thornton, G. (2006). *Διεθνή Πρότυπα Χρηματοοικονομικής Πληροφορόρησης-IFRS: αναλυτική παρουσίαση*. Τόμοι Α, Β, Γ, Εκδόσεις Grand Thornton, Αθήνα.
- Tijms, H. C., & Groenevelt, H. (1984). Simple approximations for the reorder point in periodic and continuous review (s, S) inventory systems with service level constraints. *European journal of operational research*, 17, 175–190.
- Torabi, S. A., Hatefi, S. M., & Pay, B. S. (2012). ABC inventory classification in the presence of both quantitative and qualitative criteria. *Computers & Industrial Engineering*, 63, 530–537.
- Trapero, J. R., Cardos, M., & Kourentzes, N. (2019). Empirical safety stock estimation based on kernel and GARCH models. *Omega*, 84, 199–211.
- Tratar, L. F. (2010). Joint optimisation of demand forecasting and stock control parameters. *International Journal of Production Economics*, 127, 173–179.
- Visentin, A., Prestwich, S., Rossi, R., & Tarim, S. A. (2021). Computing optimal (R,s,S) policy parameters by a hybrid of branch-and-bound and stochastic dynamic programming. *European Journal of Operational Research*, 294, 91–99.

- Wagner, H. M., & Whitin, T. M. (1958). Dynamic version of the economic lot size model. *Management science*, 5, 89-96.
- Wald, A. (1936). Calculation and elimination of seasonal fluctuations [Berechnung und ausschaltung von seasonschwankungen], Julius Springer, Vienna, Chapter 1; English translation in DF Hendry and MS Morgan, eds., 1995. *The Foundations of Econometric Analysis*, (pp. 175-79).
- Wallström, P., & Segerstedt, A. (2010). Evaluation of forecasting error measurements and techniques for intermittent demand. *International Journal of Production Economics*, 128, 625-636.
- Wang, Y., Li, Y., Song, Y., & Rong, X. (2020). The influence of the activation function in a convolution neural network model of facial expression recognition. *Applied Sciences*, 10, 1897.
- Wellens, A. P., Udenio, M., & Boute, R. N. (2021). Transfer learning for hierarchical forecasting: Reducing computational efforts of M5 winning methods. *International Journal of Forecasting*, 38, 1482-1491.
- Wen, Y., & Yin, C. (2019). Solution of Hamilton-Jacobi-Bellman equation in optimal reinsurance strategy under dynamic VaR constraint. *Journal of Function Spaces*, 2019.
- Whittle, P. (1951). *Hypothesis testing in time series analysis* volume 4. Almqvist & Wiksells boktr.
- Willemain, T. R., Smart, C. N., & Schwarz, H. F. (2004). A new approach to forecasting intermittent demand for service parts inventories. *International Journal of forecasting*, 20, 375-387.
- Willemain, T. R., Smart, C. N., Shockor, J. H., & DeSautels, P. A. (1994). Forecasting intermittent demand in manufacturing: a comparative evaluation of croston's method. *International journal of forecasting*, 10, 529-538.
- Williams, T. (1984). Stock Control with Sporadic and Slow-Moving Demand. *Journal of The Operational Research Society*, 35, 939-948.
- Wilson, R. H. (1934). A scientific routine for stock control. *Harvard Business Review*, 13, 116-129.
- Winters, P. R. (1960). Forecasting sales by exponentially weighted moving averages. *Management science*, 6, 324-342.
- Yang, C. T. (2014). An inventory model with both stock-dependent demand rate and stock-dependent holding cost rate. *International Journal of Production Economics*, 155, 214-221.
- Yang, Y., Ding, C., Lee, S., Yu, L., & Ma, F. (2021). A modified teunter-syntetos-babai method for intermittent demand forecasting. *Journal of Management Science and Engineering*, 6, 53-63.

- Ye, R., & Dai, Q. (2021). Implementing transfer learning across different datasets for time series forecasting. *Pattern Recognition*, 109, 107617.
- Ye, R., & Dai, Q. (2022). A relationship-aligned transfer learning algorithm for time series forecasting. *Information Sciences*, 593, 17-34.
- Zaycoff, R. (1936). *Über die Zerlegung statistischer Zeitreihen in drei Komponenten*. Publication No. 4. Sophia: State University of Sophia, Statistical Institute for Economic Research.
- Zhang, Z., Mayer, G., Dauvilliers, Y., Plazzi, G., Pizza, F., Fronczek, R., Santamaria, J., Partinen, M., Overeem, S., Peraita-Adrados, M., Silva, A., Sonka, K., Río, R., Heinzer, R., Wierzbicka, A., Young, P., Högl, B., Bassetti, C., Manconi, M., & Khatami, R. (2018). Exploring the clinical features of narcolepsy type 1 versus narcolepsy type 2 from european narcolepsy network database with machine learning. *Scientific Reports*, 8.
- Zheng, Y. S. (1992). On properties of stochastic inventory systems. *Management science*, 38, 87-103.
- Zheng, Y.-S., & Federgruen, A. (1991). Finding optimal (s, S) policies is about as simple as evaluating a single policy. *Operations research*, 39, 654-665.
- Zipkin, P. H. (2000). *Foundations of inventory management*. McGraw-Hill, New York.
- Κακούρης, Α. (2013). *Διοίκηση επιχειρησιακών λειτουργιών*. Εκδόσεις Προπομπός, Αθήνα.
- Πετρόπουλος, Ρ., & Ασημακόπουλος, Β. (2011). *Επιχειρησιακές προβλέψεις*. Εκδόσεις Συμμετρία, Αθήνα.
- Σπηλιώτης, Ε. (2017). *Ανάπτυξη πλαισίου αυτοματοποιημένης προέκτασης χρονοσειρών μέσω της γενίκευσης της μεθόδου πρόβλεψης θ*. Ph.D. thesis Εθνικό Μετσόβιο Πολυτεχνείο, Αθήνα.
- Στειακάκης, Ε., & Κωφίδης, Ν. (2017). *Διοίκηση Παραγωγής και Υπηρεσιών*. Εκδόσεις Τζιόλα, Θεσσαλονίκη.



# **Παραρτήματα**

---



## A. Ανάπτυξη σε R

---

### A.1 Συνάρτηση υπολογισμού χαρακτηριστικών χρονοσειράς

```
# Calculate intervals of series x
intervals <- function(x){
  y <- c()
  k <- 1
  counter <- 0
  for (tmp in (1:length(x))){
    if(x[tmp] == 0){
      counter <- counter + 1
    }else{
      k <- k + 1
      y[k] <- counter
      counter <- 1
    }
  }
  y <- y[y > 0]
  y[is.na(y)] <- 1

  return(y)
}

# Calculate non zero observations of series x
demand <- function(x){
  y <- x[x != 0]

  return(y)
}

# Calculate important characteristics of series tsid of dataset named data
statistics <- function(data, tsid){
  input <- data[tsid, ]
  id <- input$id
  input$id <- NULL
  input <- as.numeric(input)
  if (max(input, na.rm = T) > 0){
    input <- input[min(which(input != 0)):length(input)] #remove leading zeros
  }else{
    input <- 0
  }

  lngth <- length(input)
  D <- demand(input)
}
```

```

ADI <- mean(intervals(input))
CV2 <- (sd(D)/mean(D))^2
Min <- min(input)
Low25 <- as.numeric(quantile(input, 0.25))
Mean <- mean(input)
Median <- median(input)
Up25 <- as.numeric(quantile(input, 0.75))
Max <- max(input)
pz <- length(input[input == 0])/length

if (!is.na(CV2) & !is.na(ADI)){
  if (ADI > 1.32){
    if (CV2 > 0.49){
      Type <- "Lumpy"
    }else{
      Type <- "Intermittent"
    }
  }else{
    if (CV2 > 0.49){
      Type <- "Erratic"
    }else{
      Type <- "Smooth"
    }
  }
}else{
  Type <- NA
}

matrix_s <- data.frame(id, lngth, ADI, CV2, pz, Type, Min, Low25, Mean, Median, Up25, Max)

return(matrix_s)
}

```

## A.2 Συνάρτηση υπολογισμού αποθέματος ασφαλείας σύμφωνα με τη μέθοδο του Greasley (2013)

```

# Calculate safety stock given a target service level (SL), the standard deviation of demand (sd)
# and the lead time (L)
# Note that for periodic review policies, the value 'R+L' is used instead of 'L'
SS <- function(SL, sd, L){
  if( any(SL <= 0 | SL >= 1) ) stop('SL not between 0 and 1')
  z <- qnorm(SL, 0, 1)
  rst <- z*sd*sqrt(L)
  rs <- round(rst, 2)

  return(rs)
}

```



---

### A.3 Συνάρτηση παραγωγής προβλέψεων σύμφωνα με τη μέθοδο του Croston (1972)

```
# Fit and produce forecasts for horizon h using simple exponential smoothing method to time series
# x, with a smoothing parameter value of a
SES <- function(a, x, h, job){
  y <- c()
  y[1] <- x[1] #initialization

  for (t in 1:(length(x))){
    y[t+1] <- a*x[t]+(1-a)*y[t]
  }

  fitted <- head(y, (length(y)-1))
  forecast <- rep(tail(y, 1), h)
  if (job == "train"){
    return(mean((fitted - x)^2))
  }else if (job == "fit"){
    return(fitted)
  }else{
    return(list(fitted = fitted, mean = forecast))
  }
}

# Produce forecasts for horizon h using classic or optimized Croston's method to time series x
Croston <- function(x, h, type){
  if (type == "classic"){
    mult <- 1
    a1 = a2 <- 0.1
  }else if (type == "optimized"){
    mult <- 1
    a1 <- optim(c(0), SES, x = demand(x), h = 1, job = "train",
               lower = 0.1, upper = 0.3, method = "L-BFGS-B")$par

    a2 <- optim(c(0), SES, x = intervals(x), h = 1, job = "train",
               lower = 0.1, upper = 0.3, method = "L-BFGS-B")$par
  }
  yd <- SES(a = a1, x = demand(x), h = 1, job = "forecast")$mean
  yi <- SES(a = a2, x = intervals(x), h = 1, job = "forecast")$mean
  forecast <- rep(as.numeric(yd/yi), h)*mult
  return(forecast)
}
```

### A.4 Συνάρτηση προσομοίωσης της διαδικασίας αποθεματοποίησης κάνοντας χρήση της πολιτικής $(R, s, S)$

```
# Conduct simulation using the (R,s,S) policy
RsS <- function(initial_stock, actual_demand, FT, L, SL, S = NULL){
  fh <- FT+L
```

```

periods <- length(actual_demand)

known_periods <- periods-365
known_demand <- head(actual_demand, known_periods)

orders = sent = backorders = forecasts = frst_diffs <- rep(0, known_periods)
s <- rep(initial_stock, known_periods)

for (periodid in c((known_periods+1):periods)){
  sent <- c(sent, min(actual_demand[periodid], s[periodid - 1]))

  if (periodid %in% round(seq(periods, 1, by = -(FT)))){
    known_demand <- head(actual_demand, periodid)
    ss <- SS(SL, sd(known_demand), (L+FT))
    if (is.null(S) || S == 0){
      forecast <- try(mean(Croston(known_demand, fh, "classic")), silent = T)
      if (class(forecast) == "try-error"){forecast <- 0}
      Q <- sum(forecast) + ss
    }else{
      Q <- S
    }

    r <- sum(forecast) + ss

    forecasts <- c(forecasts, head(forecast, FT))
    frst_diffs <- c(frst_diffs, rep(mean(diff(known_demand)), FT))

    orders <- c(orders,
               ifelse(r >= s[periodid - 1],
                      round(max(Q - s[periodid-1] + sent[periodid] -
                                sum(orders[max(periodid-L, 1):(periodid-1)]), 0)),
                      0))
  }else{
    orders <- c(orders, 0)
  }

  if (periodid <= L){
    s <- c(s, s[periodid - 1] - sent[periodid])
  }else{
    s <- c(s, s[periodid - 1] - sent[periodid] + orders[periodid - L])
  }
}

index <- c(1:min(which(s>0)))
inv <- s[-index] ; ord <- orders[-index]

return(c(
  FT, #review period
  L, #lead time
  SL, #target service level
  sum(sent[-index])/sum(actual_demand[-index]), #fill rate
  mean( sent[-index][actual_demand[-index]>0]/

```

```

    actual_demand[-index][actual_demand[-index]>0]
  ), #service level
  mean(s[-index]), #mean inventory
  max(s[-index]), #max inventory
  sum(sum(actual_demand[-index])-sum(sent[-index])), #lost sales
  length(inv[inv == 0]), #out of stock days
  mean(inv)/mean(actual_demand[-index]), #inventory days
  sum(ord), #sum orders
  length(ord[ord>0]), #number of orders
  sum(actual_demand[-index]), #sum demand
  sum(forecasts[-index]) #sum forecasts

# #Error Metrics
# mean(actual_demand[-index]-forecasts[-index]), #ME
# mean(abs(actual_demand[-index]-forecasts[-index])), #MAE
# sqrt(mean((actual_demand[-index]-forecasts[-index])^2)) #RMSE
))
}

```



## B. Λίστα Δημοσιεύσεων

---

### B.1 Δημοσιεύσεις σε επιστημονικά περιοδικά

- **Theodorou, E.**, Spiliotis, E., Assimakopoulos, V. (2022). Optimizing inventory control through a data-driven and model-independent framework. *EURO Journal on Transportation and Logistics*, 12: 100103 (*Impact Factor: 1.739 - CiteScore: 4.1*)
- **Theodorou, E.**, Spiliotis, E. (2022). Better forecasts or more appropriate stock control policies? *Foresight: The International Journal of Applied Forecasting*, Issue 68, 40-44
- **Theodorou, E.**, Wang, S., Kang, Y., Spiliotis, E., Makridakis, S., Assimakopoulos, V. (2021). Exploring the representativeness of the M5 competition data. *International Journal of Forecasting*, 38 (4), 1500-1506 (*Impact Factor: 7.022 - CiteScore: 7.9*)

### B.2 Ανακοινώσεις σε επιστημονικά συνέδρια

- **Theodorou, E.**, Spiliotis, E., Assimakopoulos, V. (2023). Forecasting accuracy and inventory performance: Evidence on their relationship from the M5 competition data. 43rd International Symposium on Forecasting - ISF 2023, June 25-28, 2023, Charlottesville, Virginia USA (*accepted*)
- **Theodorou, E.**, Spiliotis, E., Assimakopoulos, V. (2022). A data-driven stock control optimization framework. 42nd International Symposium on Forecasting - ISF 2022, July 10-13, 2022, Oxford, England
- Makri, E., **Theodorou, E.** (2022). Currency and money: Introducing the child to the world of economics through the digital applications of the Numismatic Museum. 1st International Scientific Conference - Education in the 21st century: Contemporary challenges and concerns, May 13-15, 2022, Ioannina, Greece
- **Theodorou, E.**, Spiliotis, E., Assimakopoulos, V. (2021). Evaluating the impact of business practices on inventory performance. 41st International Symposium on Forecasting - ISF 2021, June 27-30, 2021, online
- **Theodorou, E.**, Spiliotis, E., Assimakopoulos, V. (2020). Football forecasting as a workforce optimization tool. 40th International Symposium on Forecasting - ISF 2020, October 26-28, 2020, online

- 
- **Theodorou, E.**, Spiliotis, E., Assimakopoulos, V. (2019). Supply Chain Management: Bridging the gap between business and academia. 39th International Symposium on Forecasting - ISF 2019, June 16-19, 2019, Thessaloniki, Greece

---