



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

ΤΟΜΕΑΣ ΗΛΕΚΤΡΙΚΩΝ ΒΙΟΜΗΧΑΝΙΚΩΝ ΔΙΑΤΑΞΕΩΝ ΚΑΙ ΣΥΣΤΗΜΑΤΩΝ ΑΠΟΦΑΣΕΩΝ

**Προδιαγραφική Αναλυτική Δεδομένων με Διαδραστική
Ενισχυτική Μάθηση στη Λήψη Αποφάσεων**

**(Prescriptive Analytics with Interactive Reinforcement
Learning in Decision Making)**

ΔΙΔΑΚΤΟΡΙΚΗ ΔΙΑΤΡΙΒΗ

Αικατερίνη Ι. Λεπενιώτη

Αθήνα, Οκτώβριος 2022



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ
ΥΠΟΛΟΓΙΣΤΩΝ

ΤΟΜΕΑΣ ΗΛΕΚΤΡΙΚΩΝ ΒΙΟΜΗΧΑΝΙΚΩΝ ΔΙΑΤΑΞΕΩΝ ΚΑΙ ΣΥΣΤΗΜΑΤΩΝ
ΑΠΟΦΑΣΕΩΝ

Προδιαγραφική Αναλυτική Δεδομένων με Διαδραστική Ενισχυτική Μάθηση στη Λήψη Αποφάσεων

(Prescriptive Analytics with Interactive Reinforcement Learning in Decision Making)

Αικατερίνη Ι. Λεπενιώτη
Διδακτορική Διατριβή

Τριμελής Συμβουλευτική Επιτροπή:

Γρηγόριος Μέντζας, Καθηγητής Ε.Μ.Π. (επιβλέπων)

Ιωάννης Ψαρράς, Καθηγητής Ε.Μ.Π.

Δημήτριος Ασκούνης, Καθηγητής Ε.Μ.Π.

Εγκρίθηκε από την επταμελή εξεταστική επιτροπή την 25^η Οκτωβρίου 2022

Επταμελής Εξεταστική Επιτροπή:

Γρηγόριος Μέντζας
Καθηγητής Ε.Μ.Π.

Ιωάννης Ψαρράς
Καθηγητής Ε.Μ.Π.

Δημήτριος Ασκούνης
Καθηγητής Ε.Μ.Π.

Δημήτριος Αποστόλου
Καθηγητής
Πανεπιστημίου Πειραιώς

Ιωάννης Βεργινάδης
Επ. Καθηγητής Ο.Π.Α

Γεώργιος Τσιχριντζής
Καθηγητής
Πανεπιστημίου Πειραιώς

Χάρης Δούκας
Αν. Καθηγητής Ε.Μ.Π.

Αθήνα, Οκτώβριος 2022

.....

Αικατερίνη Ι. Λεπενιώτη

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

Copyright © **Αικατερίνη Ι. Λεπενιώτη, 2022**

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.

Στον σύζυγό μου, Νίκο

Πίνακας Περιεχομένων

1	Εισαγωγή	23
1.1	Κίνητρο.....	23
1.2	Συνεισφορά.....	25
1.3	Σχέση με Ευρωπαϊκά Έργα.....	27
1.4	Δομή Διατριβής.....	29
2	Ανασκόπηση Βιβλιογραφίας	31
2.1	Επιχειρηματική Αναλυτική Δεδομένων	31
2.1.1	Εισαγωγή.....	31
2.1.2	Αναλυτική Δεδομένων Μεγάλης Κλίμακας	41
2.1.3	Μηχανική Μάθηση στην Επιχειρηματική Αναλυτική.....	48
2.1.4	Επιχειρηματική Αναλυτική στη Λήψη Αποφάσεων.....	52
2.2	Προβλεπτική και Προδιαγραφική Αναλυτική Δεδομένων	60
2.2.1	Εισαγωγή.....	60
2.2.2	Μεθοδολογία Ανασκόπησης	66
2.2.3	Ανάλυση και Συζήτηση.....	70
2.2.4	Σύνθεση Αποτελεσμάτων και Ερευνητικές Προκλήσεις.....	91
3	Πρόταση Διατριβής	103
3.1	Ερευνητικά Ερωτήματα	103
3.1.1	Υποστήριξη προδιαγραφικής αναλυτικής	103
3.1.2	Μοντελοποίηση προβλημάτων προδιαγραφικής αναλυτικής	106
3.1.3	Πολλαπλά κριτήρια και στόχοι σε προβλήματα προδιαγραφικής αναλυτικής	107
3.1.4	Αξιοποίηση προτίμησης του ανθρώπου στην προδιαγραφική αναλυτική.....	108
3.2	Πρόταση Διατριβής.....	111
4	Πλαίσιο Διατριβής	117
4.1	Κύκλος Ζωής Προδιαγραφικής Αναλυτικής Δεδομένων	117
4.2	Πλαίσιο Προδιαγραφικής Αναλυτικής Δεδομένων	127
4.2.1	Κατασκευή προδιαγραφικού μοντέλου.....	133
4.2.2	Επίλυση προδιαγραφικού μοντέλου	141
4.2.3	Προσαρμογή προδιαγραφικού μοντέλου.....	143
5	Μέθοδος Προδιαγραφικής Αναλυτικής Δεδομένων με Διαδραστική Ενισχυτική Μάθηση	147
5.1	Ανασκόπηση βιβλιογραφίας.....	147
5.1.1	Ενισχυτική Μάθηση	147
5.1.2	Ενισχυτική Μάθηση Πολλαπλών Κριτηρίων.....	152
5.1.3	Διαδραστική Ενισχυτική Μάθηση	155
5.2	Μέθοδος	165
5.2.1	Κατασκευή Προδιαγραφικού Μοντέλου	169
5.2.2	Επίλυση Προδιαγραφικού Μοντέλου.....	174

5.2.3	Προσαρμογή Προδιαγραφικού Μοντέλου	176
6	Πληροφοριακό Σύστημα.....	181
6.1	Αρχιτεκτονική.....	181
6.1.1	Επίπεδο Αλληλεπίδρασης Χρήστη	182
6.1.2	Επίπεδο Λογικής	184
6.1.3	Επίπεδο Αποθήκευσης Δεδομένων	192
6.2	Υλοποίηση.....	201
6.2.1	Βιβλιοθήκες.....	201
6.3	Παράδειγμα Χρήσης	208
7	Περίπτωση Εφαρμογής – Χρηματιστηριακές Επενδύσεις	219
7.1	Εισαγωγή.....	219
7.2	Ανασκόπηση Βιβλιογραφίας	221
7.3	Εφαρμογή Μεθόδου	226
7.4	Αξιολόγηση	233
7.4.1	Πειραματική Διαδικασία.....	233
7.4.2	Σύγκριση με άλλες μεθόδους	236
7.4.3	Σύγκριση στρατηγικών.....	240
8	Συμπεράσματα και Μελλοντικές Επεκτάσεις	247
8.1	Συμπεράσματα.....	247
8.2	Μελλοντικές Επεκτάσεις.....	248
9	Αναφορές.....	253
10	Δημοσιεύσεις	279

Πίνακας Εικόνων

Εικόνα 2-1 Επιστημονικοί τομείς Επιχειρηματικής Αναλυτικής (προσαρμ. Mortenson et al., 2015)	33
Εικόνα 2-2 Στάδια αναλυτικής δεδομένων (προσαρμ. https://www.gartner.com/en/newsroom/press-releases/2014-10-21-gartner-says-advanced-analytics-is-a-top-business-priority)	37
Εικόνα 2-3 Χαρακτηριστικά Δεδομένων Μεγάλης Κλίμακας (προσαρμ. Hariri, et al., 2019)	42
Εικόνα 2-4 Είδη δεδομένων μεγάλης κλίμακας (προσαρμ. Deshpande et al., 2019).	45
Εικόνα 2-5 Διαδικασία Λήψης Αποφάσεων (προσαρμ. Simon, H. A. 2013)	54
Εικόνα 2-6 Προσαρμοσμένη Διαδικασία Λήψης Απόφασης με Αναλυτική Δεδομένων (προσαρμ. Sharda et al., 2014)	55
Εικόνα 2-7 Δομικά στοιχεία λήψης αποφάσεων με αναλυτική δεδομένων (προσαρμ. Elgendy, et al., 2021).....	56
Εικόνα 2-8 Πυλώνες Προδιαγραφικής Αναλυτικής Δεδομένων	61
Εικόνα 2-9 Η επιχειρηματική αξία της αναλυτικής δεδομένων ως προς το χρόνο (προσαρμ. Krumeich et al., 2016).....	66
Εικόνα 2-10 Ταξινόμηση μεθόδων προβλεπτικής αναλυτικής δεδομένων	71
Εικόνα 2-11 Ταξινόμηση μεθόδων προδιαγραφικής αναλυτικής δεδομένων	72
Εικόνα 2-12 Διάγραμμα Venn μεθόδων βιβλιογραφίας.....	77
Εικόνα 3-1 Πρόταση Διατριβής.....	114
Εικόνα 4-1 Κύκλος Ζωής Προδιαγραφικής Αναλυτικής Δεδομένων	119
Εικόνα 4-2 Φάσεις ανάλυσης δεδομένων	123
Εικόνα 4-3 Πλαίσιο προδιαγραφικής αναλυτικής δεδομένων	131
Εικόνα 5-1 Ενισχυτική Μάθηση.....	148
Εικόνα 5-2 Ταξινόμηση μεθόδων ενισχυτικής μάθησης (προσαρμοσμένη: Zhang, και Yu, 2020)	150

Εικόνα 5-3 Ενισχυτική Μάθηση Πολλαπλών Κριτηρίων	153
Εικόνα 5-4 Πηγές ανάδρασης ανθρώπου (Lin et al., 2020).....	160
Εικόνα 5-5 Διαδραστική Ενισχυτική Μάθηση	161
Εικόνα 5-6 Προτεινόμενη προσέγγιση για επαυξημένη από τον άνθρωπο προδιαγραφική αναλυτική δεδομένων με IMORL.....	166
Εικόνα 5-7 Μαρκοβιανή Διαδικασία Απόφασης Πολλαπλών Κριτηρίων για τη Φάση Κατασκευής του Προδιαγραφικού Μοντέλου	172
Εικόνα 6-1 Αρχιτεκτονική συστήματος.....	182
Εικόνα 6-2 Αρχιτεκτονική μηχανής κανόνων.....	185
Εικόνα 6-3 Περιβάλλον ενισχυτικής μάθησης προτεινόμενης μεθόδου	189
Εικόνα 6-4 Διάγραμμα ακολουθίας της φάσης εκτέλεσης του συστήματος.....	190
Εικόνα 6-5 Διάγραμμα οντοτήτων-σχέσεων βάσης δεδομένων.....	196
Εικόνα 6-6 Παράδειγμα εγγράφου Συλλογής Περιβάλλοντος Ενισχυτικής Μάθησης RLEnv.....	199
Εικόνα 6-7 Παράδειγμα εγγράφου Συλλογής Δεδομένων Ενισχυτικής Μάθησης RLData	200
Εικόνα 6-8 Παράδειγμα εγγράφου Συλλογής Ανάδρασης Feedback	200
Εικόνα 6-9 Διάγραμμα Τεχνικής Αρχιτεκτονικής Προτεινόμενης Μεθόδου.....	201
Εικόνα 6-10 Αρχική οθόνη συστήματος	209
Εικόνα 6-11 Οθόνη παραμετροποίησης βασικών παραμέτρων μεθόδου	210
Εικόνα 6-12 Οθόνη διαχείρισης αντικειμένων διαδικασίας λήψης απόφασης	211
Εικόνα 6-13 Οθόνη διαχείρισης υποψήφιων προδραστικών ενεργειών	212
Εικόνα 6-14 Οθόνη διαχείρισης μελλοντικών γεγονότων και τύπων γεγονότων.....	213
Εικόνα 6-15 Οθόνη διαχείρισης κανόνων απόφασης.....	214
Εικόνα 6-16 Παρακολούθηση προδιαγραφών	215
Εικόνα 6-17 Αλλαγή κατάστασης προδιαγραφής	216

Εικόνα 6-18 Προβολή αναλυτικών τιμών προδιαγραφικού μοντέλου	217
Εικόνα 6-19 Γραφική απεικόνιση προδιαγραφικού μοντέλου	217
Εικόνα 6-20 Πρόγραμμα Ενεργειών	218
Εικόνα 6-21 Υλοποίηση προτεινόμενων ενεργειών	218
Εικόνα 7-1 Μέση απόδοση και ρίσκο ανά επενδυτική στρατηγική, για την risk-seeking επενδυτική στρατηγική.....	239
Εικόνα 7-2 Εξέλιξη ποσοστού αρνητικής ανάδρασης για τα διαφορετικά προφίλ χρηστών	242
Εικόνα 7-3 Εξέλιξη ποσοστού αρνητικής ανάδρασης για τους risk-averse χρήστες	243
Εικόνα 7-4 Εξέλιξη ποσοστού αρνητικής ανάδρασης για τους risk seeking χρήστες	243

Πίνακας Πινάκων

Πίνακας 2-1 Αριθμός επιστημονικών αναφορών.....	69
Πίνακας 2-2 Κατανομή αναφορών ανά έτος.....	70
Πίνακας 2-3 Ταξινόμηση αναφορών σύμφωνα με τις μεθόδους προβλεπτικής αναλυτικής δεδομένων.....	78
Πίνακας 2-4 Ταξινόμηση αναφορών σύμφωνα με τις μεθόδους προδιαγραφικής αναλυτικής δεδομένων.....	80
Πίνακας 2-5 Ταξινόμηση αναφορών ανά πεδίο εφαρμογής προδιαγραφικής αναλυτικής δεδομένων.....	81
Πίνακας 2-6 Ερευνητικές Προκλήσεις	102
Πίνακας 3-1 Ερευνητικά Ερωτήματα.....	111
Πίνακας 5-1 Σημειογραφία μεθόδου	168
Πίνακας 5-2 Περίγραμμα προτεινόμενης μεθόδου	169
Πίνακας 6-1 Πρότυπο προδραστικών κανόνων στη γλώσσα της Drools	205
Πίνακας 7-1 Παραμετροποίηση μεθόδου στο πρόβλημα των χρηματιστηριακών επενδύσεων	227
Πίνακας 7-2 Παράμετροι αλγορίθμου επίλυσης προδιαγραφικού μοντέλου.....	234
Πίνακας 7-3 Ενδεικτικός υπολογισμός απόδοσης και ρίσκου	236
Πίνακας 7-4 Ενδεικτικές προδιαγραφές παραγόμενες από τις συγκρινόμενες επενδυτικές στρατηγικές.....	238
Πίνακας 7-5 Σύγκριση προτεινόμενων ενεργειών για τις διαφορετικές επενδυτικές στρατηγικές.....	240
Πίνακας 7-6 Σύνοψη ποσοστού αρνητικής ανάδρασης για τα διαφορετικά προφίλ χρηστών	244
Πίνακας 7-7 Σύνοψη προτεινόμενων ενεργειών για τα διαφορετικά προφίλ χρηστών	245

Γλωσσάριο

Όροι στα Αγγλικά	Όροι στα Ελληνικά
Active Learning	Ενεργή Μάθηση
Actor-critic	Μέθοδος δράστη-κριτή
Adaptive Robust Optimization	Προσαρμοστική Εύρωστη Βελτιστοποίηση
Application Programming Interface - API	Διεπαφή Προγραμματισμού Εφαρμογών
Approval	Έγκριση
Artificial Intelligence	Τεχνητή Νοημοσύνη
Asset Health Management	Διαχείριση Κατάστασης Εξοπλισμού
Autonomic Networking	Αυτόνομη Δικτύωση
Backward Chaining	Προς-τα-Πίσω Αλυσίδωση
Batch	Παρτίδα
Bayesian Belief Network	Μπεϋζιανό Δίκτυο Πεποίθησης
Bayesian Optimization	Μπεϋζιανή Βελτιστοποίηση
Behavioral Economics	Συμπεριφορική Οικονομική
Behavioral Science	Συμπεριφορική Επιστήμη
Big Data	Δεδομένα Μεγάλης Κλίμακας
Binary Linear Programming	Δυαδικός Γραμμικός Προγραμματισμός
Binary Quadratic Non-Linear Programming	Δυαδικός Τετραγωνικός Μη Γραμμικός Προγραμματισμός
Business Analytics	Επιχειρηματική Αναλυτική
Choice	Επιλογή
Classification	Ταξινόμηση
Clustering	Ομαδοποίηση
Complex Event Processing - CEP	Επεξεργασία Πολύπλοκων Γεγονότων

Computer Vision	Υπολογιστική Όραση
Conditional Stochastic Optimization	Δεσμευμένη Στοχαστική Βελτιστοποίηση
Configuration	Παραμετροποίηση
Constrained Bayesian Optimization	Περιορισμένη Μπεϋζιανή Βελτιστοποίηση
Constraint programming	Προγραμματισμός περιορισμών
Corrective feedback	Διορθωτική ανάδραση
Dashboard	Πίνακας ελέγχου
Data Mining	Εξόρυξη Δεδομένων
Decision Trees	Δένδρα Αποφάσεων
Deep Learning	Βαθιά Μηχανική Μάθηση
Deep Neural Networks	Βαθιών Νευρωνικών Δικτύων
Deep Reinforcement Learning	Βαθιά Ενισχυτική Μάθηση
Design	Σχεδιασμός
Descriptive Analytics	Περιγραφική Αναλυτική Δεδομένων
Diagnostic analytics	Διαγνωστική Αναλυτική Δεδομένων
Dimensionality curse	Κατάρα της διαστατικότητας
Dimensionality Reduction	Μείωση διαστατικότητας
Disaggregation Analysis	Αναλυτική-Συνθετική Προσέγγιση
Discrete-time MDP	Μαρκοβιανές Διαδικασίες Απόφασης Διακριτού Χρόνου
Discretization	Διακριτοποίηση
Documentation	Τεκμηρίωση
Domain Specific Language - DSL	Γλώσσα συγκεκριμένου γνωστικού πεδίου
Equilibrium	Ισορροπία
Evaluative feedback	Αξιολογική ανάδραση

Event bus	Δίαυλος γεγονότων
Evolutionary algorithm	Εξελικτικός αλγόριθμος
Evolutionary Computation	Εξελικτική Υπολογιστική
Exchange Traded Funds	Διαπραγματεύσιμα Αμοιβαία Κεφαλαία
Expected return	Αναμενόμενη απόδοση
Expected risk	Αναμενόμενο ρίσκο
Expected utility	Οικονομική χρησιμότητα
Experiment tracking	Παρακολούθηση πειραμάτων
Expert System	Σύστημα Εμπειρογνωμοσύνης
Extract, Transform, Load – ETL	Εξαγωγή, Μετασχηματισμός, Φόρτωση
Feedback	Ανάδραση
Foreign key	Ξένο κλειδί
Forward Chaining	Προς-τα-Εμπρός Αλυσίδωση
Graph-based analytics	Αναλυτική Δεδομένων Βασισμένη σε Γράφους
Hidden Markov Model	Κρύφο Μαρκοβιανό Μοντέλο
Hierarchical Reinforcement Learning - HRL	Ιεραρχική Ενισχυτική Μάθηση
Human-Centered Reinforcement Learning	Ανθρωποκεντρική Ενισχυτική Μάθηση
Hybrid Chaining	Υβριδική Αλυσίδωση
Image Processing	Επεξεργασία Εικόνας
Imperfect observation	Ατελής παρατήρηση
Implementation	Υλοποίηση
Incident ticket	Καταγεγραμμένο συμβάν
Incremental Learning	Προσαυξητική Μάθηση
Inference Engine	Μηχανή Συμπερασμού

Information and Communication Technologies - ICT	Τεχνολογίες Πληροφορικής και Επικοινωνίας
Integer Programming	Ακέραιος Προγραμματισμός
Intelligence	Ευφυΐα
Interactive Reinforcement Learning - IRL	Διαδραστική Ενισχυτική Μάθηση
Interactive Multi-Objective Reinforcement Learning - IMORL	Διαδραστική Ενισχυτική Μάθηση Πολλαπλών Κριτηρίων
Internet of Things - IoT	Διαδίκτυο των Αντικειμένων
Intervention	Παρέμβαση
Key Performance Indicators - KPI	Κρίσιμοι Δείκτες Απόδοσης
k-means clustering	k-means Ομαδοποίηση
Label	Ετικέτα
Linear Programming	Γραμμικός Προγραμματισμός
Log file	Αρχείο καταγραφής γεγονότων
Logic-based Model	Μοντέλο Λογικής
Long Short-Term Memory - LSTM	Δίκτυο Μακράς Βραχύχρονης Μνήμης
Goal Programming	Προγραμματισμός Στόχων
Global Optimization	Ολική Βελτιστοποίηση
Machine Learning	Μηχανική Μάθηση
Management Science	Διοικητική Επιστήμη
Mathematical Programming	Μαθηματικός Προγραμματισμός
Markov Decision Processes - MDP	Μαρκοβιανή Διαδικασία Απόφασης
Metadata	Μεταδεδομένα
Metaheuristics	Μεταερευρητικές
Mixed Integer Linear Programming	Μεικτός Ακέραιος Γραμμικός Προγραμματισμός

MLOps	Λειτουργίες Μηχανικής Μάθησης
Model-free method	Μέθοδος ανεξάρτητη μοντέλου
Model-based method	Μέθοδος βασισμένη σε μοντέλο
Model Planning	Σχεδίαση μοντέλου
Model Building	Κατασκευή μοντέλου
Modern Portfolio Theory - MPT	Σύγχρονη Θεωρία Χαρτοφυλακίου
Monitoring	Παρακολούθηση
Multi-Objective Markov Decision Process	Μαρκοβιανή Διαδικασία Απόφασης Πολλαπλών Κριτηρίων
Multi-Objective Reinforcement Learning - MORL	Ενισχυτική Μάθηση Πολλαπλών Κριτηρίων
Multiobjective mathematical programming - MMP	Πολυκριτηριακός Μαθηματικός Προγραμματισμός
Natural Language Processing	Επεξεργασία Λόγου
Non-Linear Programming	Μη-Γραμμικός Προγραμματισμός
Numerization	Ποσοτικοποίηση
Objective	Κριτήριο
Objective function	Συνάρτηση βελτιστοποίησης
Off-policy	Μέθοδος χωρίς πολιτική
Online Learning	Επιγραμμική Μάθηση
On-policy	Μέθοδος με πολιτική
Operational Research	Επιχειρησιακή Έρευνα
Outranking Relation	Σχέση Υπεροχής
Pattern Matching	Αντιστοίχιση Προτύπων
Particle Swarm Optimization	Βελτιστοποίηση Σμήνους Σωματιδίων
Planning	Προγραμματισμός
Policy-based	Βασισμένη σε πολιτική

Policy-dependent Feedback	Ανάδραση εξαρτώμενη από πολιτική
Policy Gradient	Κλίση πολιτικής
Policy Shaping	Διαμόρφωση πολιτικής
Predictive Analytics	Προβλεπτική Αναλυτική Δεδομένων
Prescription	Προδιαγραφή
Prescriptive Analytics	Προδιαγραφική Αναλυτική Δεδομένων
Prescriptive Maintenance Planning	Προδιαγραφικός Σχεδιασμός Συντήρησης
Probabilistic Models	Πιθανολογικά Μοντέλα
Process Mining	Εξόρυξη Διαδικασιών
Processor	Επεξεργαστής
Prospect Theory	Θεωρία Προοπτικής
Random Forest	Τυχαία Δένδρα
Ranking	Κατάταξη
Real-Time Streaming	Ροή Δεδομένων Πραγματικού Χρόνου
Recurrent Neural Network	Τεχνητό Ανατροφοδοτούμενο Νευρωνικό Δίκτυο
Reinforcement Learning	Ενισχυτική Μάθηση
Regression	Παλινδρόμηση
Rejection	Απόρριψη
Return Over Investment - ROI	Απόδοση της Επένδυσης
Reward Shaping	Διαμόρφωση ανταμοιβής
Risk-adjusted return	Απόδοση Σταθμισμένου Ρίσκου
Rule-based System	Σύστημα Κανόνων
Rule firing	Πυροδότηση κανόνα
Server	Εξυπηρετητής
Simulation	Προσομοίωση

Sink	Τερματικός κόμβος
Source	Πηγή
Speech Recognition	Αναγνώριση Φωνής
Statistical Analysis	Στατιστική Ανάλυση
Statistical bootstrap	Στατιστική δειγματοληψία
Stochastic Optimization	Στοχαστική Βελτιστοποίηση
Stream Processing	Επεξεργασία Ροών Δεδομένων
Supervised Learning	Επιβλεπόμενη Μάθηση
Temporal Difference - TD	Χρονική Διαφορά
Topic	Κανάλι
Transfer Learning	Μεταφορά Μάθησης
Trial and error	Εμπειρική μέθοδος
Uncertainty	Αβεβαιότητα
Unsupervised Learning	Μη-επιβλεπόμενη Μάθηση
Utility functions-based approaches	Μέθοδοι Χρησιμότητας
Utility maximization	Μεγιστοποίηση της χρησιμότητας
Validity	Εγκυρότητα
Value	Αξία
Value-based	Βασισμένη σε συνάρτηση τιμής
Variability	Μεταβλητότητα
Variety	Ποικιλία
Velocity	Ταχύτητα
Veracity	Φιλαλήθεια
Viability	Βιωσιμότητα
Volume	Όγκος

Περίληψη

Η προδιαγραφική αναλυτική δεδομένων θεωρείται ως το επόμενο βήμα εξέλιξης και ωρίμανσης της αναλυτικής δεδομένων, η οποία, μέσω της βέλτιστης και έγκαιρης λήψης αποφάσεων, οδηγεί στην βελτιστοποίηση της επιχειρηματικής απόδοσης.

Προς αυτήν την κατεύθυνση, η παρούσα διατριβή εστιάζει στην αξιοποίηση των αποτελεσμάτων της προβλεπτικής αναλυτικής σε συνδυασμό με την οδηγούμενη από δεδομένα λήψη αποφάσεων, τους αλγορίθμους μηχανικής μάθησης και τις τεχνολογίες δεδομένων μεγάλης κλίμακας προκειμένου να υποστηρίξει την επίλυση πολύπλοκων προβλημάτων προδιαγραφικής αναλυτικής δεδομένων διαφόρων γνωστικών πεδίων. Για το σκοπό αυτό, διαμορφώνει ένα πλαίσιο προδιαγραφικής αναλυτικής, το οποίο μπορεί να καθοδηγήσει την ανάπτυξη διαφόρων προδιαγραφικών μεθόδων, ικανών να παρέχουν προσαρμοσμένες, αυτοματοποιημένες, περιοριζόμενες, βέλτιστες και έγκαιρες αποφάσεις.

Το αναπτυχθέν πλαίσιο πραγματώνεται μέσω της μεθόδου προδιαγραφικής αναλυτικής που αποτελεί την βασική συνεισφορά της παρούσας διατριβής. Η προτεινόμενη μέθοδος βασίζεται στον τομέα της Διαδραστικής Ενισχυτικής Μάθησης Πολλαπλών Κριτηρίων (Interactive Multi-Objective Reinforcement Learning). Μοντελοποιεί δυναμικά το πρόβλημα απόφασης και παράγει βελτιστοποιημένες προτάσεις, λαμβάνοντας υπόψιν περισσότερα από ένα κριτήρια βελτιστοποίησης, ενώ παράλληλα, μέσω της διαδραστικής αλληλεπίδρασης, ενσωματώνει την προτίμηση του αποφασίζοντα στη διαδικασία απόφασης.

Ακολούθως, αναπτύσσεται πληροφοριακό σύστημα το οποίο υλοποιεί την προτεινόμενη προσέγγιση. Η προτεινόμενη μέθοδος εφαρμόζεται στο πεδίο των χρηματιστηριακών επενδύσεων. Εκεί, αξιολογείται η απόδοσή της συγκριτικά με παραδοσιακές μεθόδους επενδυτικών αποφάσεων και η προσαρμοστικότητά της σύμφωνα με τις προτιμήσεις του ανθρώπου για διαφορετικά επενδυτικά προφίλ.

Λέξεις-κλειδιά: Προδιαγραφική Αναλυτική, Ενισχυτική Μάθηση Πολλαπλών Κριτηρίων, Διαδραστική Ενισχυτική Μάθηση

Abstract

Prescriptive analytics is often considered as the next step towards increasing data analytics maturity and leading to optimized decision making ahead of time for business performance improvement.

The current thesis focuses on the utilization of the predictive analytics outcomes in combination with the data-driven decision making, machine learning algorithms and big data technologies to support complex prescriptive analytics problems of various domains. To that end, it develops a prescriptive analytics framework that can guide the development of various prescriptive methods. These methods can support decision making by providing adaptive, automated, constrained, optimal, and time-dependent decisions.

The proposed framework is realized through the prescriptive analytics method that consists the main contribution of the current thesis. The proposed method employs Interactive Multi-Objective Reinforcement Learning algorithms. It models the decision making problem dynamically and generates optimized decisions, taking into consideration multiple objectives, while at the same time, through interactive interaction, incorporates the decision maker's preference into the decision process.

Furthermore, the method has been implemented as an information system. The system has been employed in a stock market case study in order to evaluate the proposed approach's performance against the traditional stock trading decision methods and its adaptability according to the user's preference for different trading profiles.

Keywords: Prescriptive Analytics, Multi-Objective Reinforcement Learning, Interactive Reinforcement Learning

Ευχαριστίες

Η παρούσα διδακτορική διατριβή αντιπροσωπεύει μια μεγάλη προσωπική προσπάθεια που δε θα μπορούσε να πραγματοποιηθεί χωρίς την συνδρομή πολλών ανθρώπων στους οποίους θα ήθελα να εκφράσω τις πιο θερμές μου ευχαριστίες.

Πρώτα απ' όλους θα ήθελα να ευχαριστήσω ολόψυχα τον επιβλέποντά μου Καθηγητή κ. Γ. Μέντζα για τη συνεχή παρακολούθηση και καθοδήγηση, καθ' όλη τη διάρκεια της ερευνητικής μου προσπάθειας. Αισθάνομαι ιδιαίτερα ευγνώμων που με τίμησε με την εμπιστοσύνη του και με καθοδήγησε σε αυτό το δημιουργικό ταξίδι, καθώς πέρα από ένας εξαιρετικός ακαδημαϊκός είναι ένας ευγενής και γενναιόδωρος άνθρωπος.

Θα ήθελα να ευχαριστήσω και τα άλλα δύο μέλη της τριμελούς συμβουλευτικής επιτροπής, τους Καθηγητές κ. Ι. Ψαρρά και κ. Δ. Ασκούνη, καθώς και τον Καθηγητή κ. Δ. Αποστόλου, τον Επ. Καθηγητή κ. Ι. Βεργινάδη, τον Καθηγητή κ. Γ. Τσιχριντζή, και τον Αν. Καθηγητή κ. Χ. Δούκα για την συμμετοχή τους στην επιτροπή εξέτασης της διατριβής. Ιδιαίτερα, θα ήθελα να εκφράσω την ευγνωμοσύνη μου προς τον Καθηγητή κ. Δ. Αποστόλου, για την καθοδήγηση και τις πολύτιμες συμβουλές, την ουσιαστική του υποστήριξη και τις ευκαιρίες που μου προσέφερε.

Επιπλέον, θέλω να ευχαριστήσω όλους τους συναδέλφους που στελεχώνουν το Εργαστήριο Διοίκησης Πληροφοριακών Συστημάτων και ειδικότερα τους ερευνητές Αλέξανδρο Μπουσδέκη και Ματθαίο Φικάρδο για την αρμονική συνεργασία και συμβολή τους στην προσπάθεια μου.

Ακόμη, θα ήθελα να ευχαριστήσω μέσα από την καρδιά μου την οικογένειά μου, για την ηθική και έμπρακτη υποστήριξή τους. Ευχαριστώ την μητέρα μου Πετρούλα, που με τη φροντίδα της και το παράδειγμά της μου μαθαίνει πως να είμαι μια δυνατή γυναίκα, τον πατέρα μου Γιάννη για την εμπιστοσύνη του στις ικανότητές μου και την διαρκή ώθηση για εξέλιξη και την αδερφή μου Δέσποινα που με στηρίζει σε κάθε βήμα της ζωής μου.

Τέλος, ευχαριστώ τον αγαπημένο μου σύζυγο Νίκο, για την απεριόριστη υπομονή και αγάπη που μου προσφέρει και την καθημερινή βοήθειά του καθ' όλη τη διάρκεια της εκπόνησης της διδακτορικής μου διατριβής.

1 Εισαγωγή

1.1 Κίνητρο

Η εξέλιξη του τομέα της τεχνητής νοημοσύνης (Artificial Intelligence) ανοίγει νέους δρόμους και προοπτικές στις επιχειρήσεις, δίνοντάς τους τη δυνατότητα να διαχειρίζονται μεγάλους όγκους δεδομένων, προκειμένου να αντλούν προβλέψεις σχετικά με τις μελλοντικές επιδόσεις και να αποκτούν κρίσιμη για τη λήψη αποφάσεων γνώση έγκαιρα. Σε πολλές περιπτώσεις αναλυτικής δεδομένων, οι παραδοσιακές στατιστικές μέθοδοι έχουν αντικατασταθεί με μεθόδους μηχανικής μάθησης (Machine Learning), οι οποίες φαίνονται ικανές να εκτελέσουν απαιτητικές αναλύσεις και να παρέχουν ακριβείς και χρήσιμες εξειδικευμένες πληροφορίες, με γρήγορο και επεκτάσιμο τρόπο (Hariri, et al., 2019). Η χρήση της μηχανικής μάθησης για τη λήψη αποφάσεων ήταν μία από τις πιο σημαντικές εφαρμογές της τεχνητής νοημοσύνης με υψηλά πιθανά οφέλη (Duan et al., 2019).

Σε αυτό το πλαίσιο, η αναλυτική δεδομένων διακρίνεται σε τρεις κύριες κατηγορίες που χαρακτηρίζονται από διαφορετικά επίπεδα πολυπλοκότητας, αξίας και ευφυΐας (Šikšnys, και Pedersen, 2016): (i) την περιγραφική αναλυτική δεδομένων, με την οποία απαντώνται οι ερωτήσεις «Τι έχει συμβεί;», «Γιατί συνέβη;», και «Τι συμβαίνει τώρα;», (ii) την προβλεπτική αναλυτική δεδομένων, με την οποία απαντώνται οι ερωτήσεις «Τι θα συμβεί;» και «Γιατί θα συμβεί;» στο μέλλον και (iii) την προδιαγραφική αναλυτική δεδομένων, με την οποία απαντώνται οι ερωτήσεις «Τι πρέπει να κάνω;» και «Γιατί να το κάνω;». Η περιγραφική και η προβλεπτική αναλυτική δεδομένων έχουν κερδίσει το ερευνητικό ενδιαφέρον, ενώ η αξία της προδιαγραφικής αναλυτικής δεδομένων, έχει προσφάτως αρχίσει να αναγνωρίζεται, καθιστώντας την ως το ωριμότερο και πιο προσοδοφόρο επίπεδο αναλυτικής δεδομένων, το οποίο οδηγεί σε βελτιστοποιημένη προδραστική λήψη αποφάσεων.

Σκοπός της προδιαγραφικής αναλυτικής δεδομένων είναι η βελτιστοποίηση των αποφάσεων που λαμβάνονται εγκαίρως, προκειμένου να προληφθούν γεγονότα που έχουν προβλεφθεί, αξιοποιώντας δεδομένα μεγάλης κλίμακας (Šikšnys, και Pedersen, 2016; den Hertog, και Postek, 2016; [j1]). Στην πλειονότητα των αναφορών που παρουσιάζονται στη βιβλιογραφία, η προδιαγραφική αναλυτική δεδομένων

αντιμετωπίζεται με παραδοσιακά μοντέλα βελτιστοποίησης, τα οποία αναπτύσσονται από έμπειρους και εξειδικευμένους ανθρώπους και αφορούν συγκεκριμένα προβλήματα λήψης απόφασης.

Επιπλέον, η έλλειψη προδιαγραφικών μοντέλων και μεθόδων ικανών να προσαρμοστούν δυναμικά σύμφωνα με τις ανθρώπινες προτιμήσεις και την τεχνογνωσία του εκάστοτε γνωστικού πεδίου [j1] είναι εμφανής. Σε αυτήν την κατεύθυνση, η συνύπαρξη του ανθρώπου με την τεχνητή νοημοσύνη αναδεικνύεται ως ένας καινοτόμος ερευνητικός τομέας (Duan et al., 2019; Wilson, και Daugherty, 2018). Αν και η συμβολή των πλήρως αυτόνομων συστημάτων τεχνητής νοημοσύνης είναι καθοριστική σε ορισμένους τομείς εφαρμογών όπου ο άνθρωπος δεν μπορεί να είναι φυσικά παρών (π.χ. υποβρύχια ή βαθιά εξερεύνηση του διαστήματος), πολλοί τομείς εφαρμογών αντιμετωπίζονται πιο αποτελεσματικά και αξιόπιστα όταν αυτά συνεργάζονται με τον άνθρωπο. Σε τέτοιες περιπτώσεις η τεχνητή νοημοσύνη συμπληρώνει τις ανθρώπινες δυνατότητες και επαυξάνει τις ανθρώπινες αποφάσεις και ενέργειες αντί να τις αντικαθιστά (Wilson, και Daugherty, 2018; Miller, 2018; Jarrahi, 2018). Αν και η ανάγκη για μια συνεργατική αλληλεπίδραση μεταξύ της τεχνητής νοημοσύνης και των ανθρώπων με στόχο τη συνεργασία με τη βέλτιστη συμπληρωματικότητα (Miller, 2018; Jarrahi, 2018; IEEE Standards Association, 2018), είναι εμφανής, τα δυναμικά, αβέβαια και χρονικά μεταβλητά περιβάλλοντα και επιχειρηματικά πλαίσια θέτουν προκλήσεις σε αυτήν την αλληλεπίδραση (Kamar, 2016; Dellermann, et al., 2019).

Αντίστοιχες προκλήσεις που οφείλονται κυρίως στον μεγάλο χώρο καταστάσεων των διαδοχικών διαδικασιών λήψης αποφάσεων και στην ελλιπή γνώση του περιβάλλοντος (Wang, Y, et al., 2018) παρουσιάζονται και στην προδιαγραφική αναλυτική δεδομένων [j1]. Η ενισχυτική μάθηση (Reinforcement Learning) έχει αναγνωριστεί ως μια πολλά υποσχόμενη μέθοδος για την προδραστική λήψη αποφάσεων (Wang, Y, et al., 2018), η οποία αντιστοιχεί στην βασισμένη σε γεγονότα προδιαγραφική αναλυτική δεδομένων (Engel et al., 2012). Η ενισχυτική μάθηση, παράλληλα με την επιβλεπόμενη μάθηση (Supervised Learning) και τη μη-επιβλεπόμενη μάθηση (Unsupervised Learning) αποτελούν τους τρεις βασικούς τομείς της μηχανικής μάθησης (Sutton, και Barto, 2018). Στην ενισχυτική μάθηση

συμμετέχουν πράκτορες οι οποίοι μαθαίνουν πώς να επιλύουν διαδοχικά προβλήματα λήψης αποφάσεων χρησιμοποιώντας τις έννοιες των καταστάσεων, των ενεργειών και της ανταμοιβής (Sutton, και Barto, 2018). Ωστόσο, η αναπαράσταση και η λύση του προβλήματος με χρήση αυτών των εννοιών, σε ένα περιβάλλον που βασίζεται σε μεγάλα δεδομένα, καθώς και η ενσωμάτωση των αποτελεσμάτων προβλεπτικής αναλυτικής δεδομένων, αποτελούν ερευνητικές προκλήσεις. Στις περισσότερες προσεγγίσεις μοντελοποιείται η φυσική διαδικασία που εκτελείται, γεγονός που καθιστά αδύνατη την αξιοποίηση αυτών των προσεγγίσεων σε διαφορετικά προβλήματα και εφαρμογές με απλό τρόπο (Mnih, et al., 2015).

Επιπροσθέτως, η πολυπλοκότητα των πραγματικών συνθηκών των προβλημάτων λήψης αποφάσεων που συνήθως καλείται να επιλύσει η προδιαγραφική αναλυτική δεδομένων υπαγορεύει την ταυτόχρονη βελτιστοποίηση πολλαπλών στόχων, ανοίγοντας το δρόμο για τη χρήση αλγορίθμων ενισχυτικής μάθησης πολλαπλών κριτηρίων (Multi-Objective Reinforcement Learning). Τέλος, η ανάγκη για βέλτιστη συνεργασία ανθρώπου-μηχανικής μάθησης καθοδηγεί την έρευνα προς την αξιοποίηση αλγορίθμων διαδραστικής ενισχυτικής μάθησης (Interactive Reinforcement Learning), οι οποίες δίνουν τη δυνατότητα στον άνθρωπο να αλληλοεπιδράσει με τον προδιαγραφικό μηχανισμό, παρέχοντας την προτίμησή του, μέσω ανάδρασης πάνω τις παραγόμενες προδιαγραφές, χωρίς την ανάγκη της αναλυτικής μοντελοποίησής της.

1.2 Συνεισφορά

Βασικό αντικείμενο της διατριβής είναι η ανάπτυξη δυναμικών μεθόδων προδιαγραφικής αναλυτικής δεδομένων οι οποίες αξιοποιούν δεδομένα μεγάλης κλίμακας, σε συνδυασμό με τα αποτελέσματα της προβλεπτικής αναλυτικής δεδομένων και αλγορίθμους μηχανικής μάθησης. Μέσω αυτών, επιτρέπεται η παραγωγή βελτιστοποιημένων, έγκαιρων και οδηγούμενων από δεδομένα προτάσεων, λαμβάνοντας υπόψιν πολλαπλά κριτήρια βελτιστοποίησης. Παράλληλα, οι παραγόμενες προτάσεις διαμορφώνονται σύμφωνα με τις προτιμήσεις του

ανθρώπου, μέσω της ενσωμάτωσης της ανθρώπινης ανάδρασης στον προδιαγραφικό μηχανισμό.

Για το σκοπό αυτό πραγματοποιήθηκε ενδεδειγμένη βιβλιογραφική επισκόπηση στις μεθόδους και τους αλγόριθμους προβλεπτικής και προδιαγραφικής αναλυτικής δεδομένων που έχουν προταθεί μέχρι στιγμής και στοχεύουν στην παραγωγή προτάσεων σε προβλήματα απόφασης. Με αυτήν τη διαδικασία, εντοπίστηκαν οι ερευνητικές προκλήσεις του τομέα που αποτέλεσαν το έναυσμα για την ανάπτυξη της πρότασης της παρούσας διατριβής.

Στην παρούσα διατριβή προτείνεται ένα πλαίσιο προδιαγραφικής αναλυτικής δεδομένων ικανό να καθοδηγήσει την ανάπτυξη διαφορετικών προδιαγραφικών μεθόδων οι οποίες ενσωματώνουν την διαδραστική ενισχυτική μάθηση πολλαπλών κριτηρίων (Interactive Multi-Objective Reinforcement Learning - IMORL). Η IMORL διευκολύνει τη διαδραστική εκπαίδευση του προδιαγραφικού μηχανισμού σύμφωνα με τις προτιμήσεις του χρήστη, οι οποίες δύναται να μην είναι σταθερές, ποσοτικοποιήσιμες, ή διαθέσιμες μέσω ιστορικών δεδομένων, χωρίς να απαιτείται ο ρητός ορισμός τους, ικανοποιώντας παράλληλα τα επιλεγμένα κριτήρια βελτιστοποίησης.

Στη συνέχεια, ακολουθώντας το πλαίσιο αναπτύσσεται και υλοποιείται η προτεινόμενη μέθοδος προδιαγραφικής αναλυτικής δεδομένων της διατριβής, που υλοποιεί τα επιμέρους βήματα του προτεινόμενου πλαισίου. Πιο συγκεκριμένα, η μέθοδος που παρουσιάζεται, υποστηρίζει τη δυναμική μοντελοποίηση ενός προβλήματος προδιαγραφικής αναλυτικής με πολλαπλά κριτήρια βελτιστοποίησης, επιτρέποντας την εφαρμογή της σε προβλήματα διαφορετικών γνωστικών πεδίων. Επιπλέον, παρέχει μια προσέγγιση ενσωμάτωσης της ανάδρασης του χρήστη μέσω της τεχνικής της διαμόρφωσης πολιτικής (Policy Shaping) της Διαδραστικής Ενισχυτικής Μάθησης με την οποία η αρνητική ή η θετική ανάδραση του χρήστη πάνω στις παραγόμενες προδιαγραφές μπορεί να διαμορφώσει αντιστοίχως τον προδιαγραφικό μηχανισμό της μεθόδου.

Ακολούθως, αναπτύσσεται πληροφοριακό σύστημα το οποίο υλοποιεί την προτεινόμενη μέθοδο προδιαγραφικής αναλυτικής με τη μορφή διαδικτυακής εφαρμογής. Το υλοποιηθέν πληροφοριακό σύστημα δίνει τη δυνατότητα δυναμικής

παραμετροποίησης της μεθόδου έτσι ώστε να είναι δυνατή η χρήση του για την επίλυση διαφόρων προβλημάτων προδιαγραφικής αναλυτικής.

Μέσω αυτής της υλοποίησης, η προτεινόμενη μέθοδος εφαρμόζεται στο πεδίο των χρηματιστηριακών επενδύσεων όπου αξιολογείται η απόδοσή της συγκριτικά με κλασσικές μεθόδους επενδυτικών αποφάσεων, καθώς και η προσαρμοστικότητα της για διαφορετικά προφίλ χρηστών.

Συνοπτικά, η συνεισφορά της παρούσας εργασίας μπορεί να χωριστεί σε τέσσερα μέρη:

Πρώτον, διερευνά την αξιοποίηση της μηχανικής μάθησης, των τεχνολογιών δεδομένων μεγάλης κλίμακας και της ανάδρασης του χρήστη στην προδιαγραφική αναλυτική δεδομένων, με στόχο την οδηγούμενη από δεδομένα λήψη αποφάσεων.

Δεύτερον, προτείνει ένα πλαίσιο ανάπτυξης μεθόδων προδιαγραφικής αναλυτικής, οι οποίες αξιοποιούν τα αποτελέσματα της προβλεπτικής αναλυτικής δεδομένων, τις τεχνολογίες δεδομένων μεγάλης κλίμακας και τον τομέα της διαδραστικής ενισχυτικής μάθησης πολλαπλών κριτηρίων, προκειμένου να επιλύσουν προβλήματα λήψης απόφασης πολλαπλών κριτηρίων βελτιστοποίησης ενσωματώνοντας παράλληλα την προτίμηση του χρήστη.

Τρίτον, προτείνει μια μέθοδο προδιαγραφικής αναλυτικής, η οποία υλοποιεί τα βήματα του προτεινόμενου πλαισίου και την δυναμική μοντελοποίηση του προβλήματος, καθιστώντας την εφαρμόσιμη σε διαφορετικά προβλήματα διαφόρων γνωστικών πεδίων.

Τέταρτον, σχεδιάζει και αναπτύσσει ένα πληροφοριακό σύστημα το οποίο υλοποιεί την προτεινόμενη μέθοδο προδιαγραφικής αναλυτικής, μέσω του οποίου η πρόταση της διατριβής εφαρμόζεται και αξιολογείται στον τομέα των χρηματιστηριακών επενδύσεων.

1.3 Σχέση με Ευρωπαϊκά Έργα

Η παρούσα διδακτορική διατριβή έχει εν μέρει υποστηριχθεί από την Ευρωπαϊκή Επιτροπή μέσω του ερευνητικού έργου UPTIME και του ερευνητικού έργου COALA:

- **Έργο UPTIME (Unified Predictive Maintenance system):**

Το ερευνητικό έργο UPTIME είναι ένα έργο καινοτομίας που ανήκει στην έρευνα των Εργοστασίων του Μέλλοντος H2020-FOF-2017 (Horizon 2020 – Factories-Of-the-Future), FOF-09-2017, με ζητούμενο την καινοτόμο σχεδίαση και ανάπτυξη τεχνολογιών προβλεπτικής συντήρησης για αυξημένη λειτουργική διάρκεια των συστημάτων παραγωγής. Βασικός σκοπός του έργου είναι η σχεδίαση ενός ενοποιημένου πλαισίου προβλεπτικής συντήρησης, συνοδευόμενο από το ενοποιημένο πληροφοριακό σύστημα το οποίο επιτρέπει την υλοποίηση στρατηγικών προβλεπτικής συντήρησης στην βιομηχανία παραγωγής.

Μεγάλο μέρος της έρευνας που περιλαμβάνεται στην παρούσα διατριβή αναπτύχθηκε στο πλαίσιο του UPTIME. Σε αυτό περιλαμβάνεται η ανάπτυξη του πλαισίου της διατριβής, της προτεινόμενης μεθόδου προδιαγραφικής αναλυτικής δεδομένων καθώς και η υλοποίηση του αντίστοιχου πληροφοριακού συστήματος. Επιπροσθέτως, στα πλαίσια του UPTIME, η προτεινόμενη μέθοδος με την παρούσα υλοποίηση εφαρμόστηκε και αξιολογήθηκε στο πεδίο της προβλεπτικής συντήρησης.

- **Έργο COALA (COgnitive Assisted agile manufacturing for a LABor force supported by trustworthy Artificial Intelligence):**

Το ερευνητικό έργο COALA είναι ένα έργο καινοτομίας που ανήκει στην έρευνα των Τεχνολογιών Πληροφορικής και Επικοινωνιών H2020-ICT-2020 (Horizon 2020 - Information and Communication Technologies). Σκοπός του έργου είναι η παροχή μιας τεχνολογικής λύσης που μπορεί να προσφέρει γνωστική βοήθεια αποτελούμενη από τη σύνθεση αξιόπιστων στοιχείων τεχνητής νοημοσύνης, βασιζόμενη σε έναν ψηφιακό ευφυή βοηθό με δυνατότητα φωνής ως διεπαφή. Μέσω αυτού, η προσφερόμενη λύση θα υποστηρίξει τους εργαζόμενους που χρησιμοποιούν εργαλεία ανάλυσης καθώς και τους νέους εκπαιδευόμενους εργαζόμενους. Επιπροσθέτως, εκτός από την τεχνολογική λύση, το έργο αυτό στοχεύει στην ανάπτυξη μιας εκπαιδευτικής λύσης που εστιάζει στην οικοδόμηση των ικανοτήτων των εργαζομένων μέσω της συνεργασίας ανθρώπου με τεχνητή νοημοσύνη.

Στα πλαίσια του έργου αυτού ερευνήθηκε ο κύκλος ζωής της προδιαγραφικής αναλυτικής δεδομένων, αποτυπώθηκαν τα αντίστοιχα βήματα και αναπτύχθηκε

κατάλληλη πλατφόρμα αναλυτικής δεδομένων, ικανή να ενσωματώσει την προτεινόμενη μέθοδο, διευκολύνοντας την αξιοποίησή της σε διαφορετικά προβλήματα και επιστημονικούς τομείς.

1.4 Δομή Διατριβής

Η διδακτορική διατριβή δομείται ως εξής:

- Στο κεφάλαιο 1 παρουσιάζεται η παρούσα εισαγωγή.
- Στο κεφάλαιο 2 αναπτύσσεται βιβλιογραφική εισαγωγή στον τομέα της επιχειρηματικής αναλυτικής και ενδελεχής βιβλιογραφική επισκόπηση στις μεθόδους και τους αλγόριθμους προβλεπτικής και προδιαγραφικής αναλυτικής δεδομένων.
- Στο κεφάλαιο 3 καταγράφονται και αναλύονται τα ερευνητικά ερωτήματα τα οποία επιχειρεί να απαντήσει η παρούσα διατριβή και παρουσιάζεται μια συνοπτική περιγραφή της προτεινόμενης πρότασης.
- Στο κεφάλαιο 4 αναπτύσσεται το πλαίσιο της διατριβής το οποίο καθοδηγεί την ανάπτυξη μεθόδων προδιαγραφικής αναλυτικής δεδομένων βασισμένων στην διαδραστική ενισχυτική μάθηση πολλαπλών κριτηρίων.
- Στο κεφάλαιο 5 παρουσιάζεται συνοπτική βιβλιογραφική ανασκόπηση των διαφορετικών τομέων της ενισχυτικής μάθησης και η προτεινόμενη μέθοδος προδιαγραφικής αναλυτικής που αναπτύσσεται σύμφωνα με το πλαίσιο της διατριβής.
- Στο κεφάλαιο 6 περιγράφεται το πληροφοριακό σύστημα το οποίο υλοποιεί την προτεινόμενη μέθοδο.
- Στο κεφάλαιο 7 παρουσιάζεται η εφαρμογή και η αξιολόγηση της προτεινόμενης μεθόδου στον τομέα των χρηματιστηριακών επενδύσεων.
- Στο κεφάλαιο 8 συγκεντρώνονται τα συμπεράσματα, οι περιορισμοί και οι μελλοντικές επεκτάσεις της παρούσας διατριβής.

- Στο κεφάλαιο 9 συγκεντρώνονται οι αναφορές στις οποίες βασίζεται η παρούσα διατριβή.
- Στο κεφάλαιο 10 καταγράφεται ο κατάλογος των δημοσιεύσεων που πραγματοποιήθηκαν κατά την εκπόνησή της.

2 Ανασκόπηση Βιβλιογραφίας

2.1 Επιχειρηματική Αναλυτική Δεδομένων

2.1.1 Εισαγωγή

Οι επιχειρήσεις ιδιωτικού και δημόσιου τομέα διαρκώς συγκεντρώνουν και συντηρούν μεγάλα σύνολα δεδομένων που αφορούν τις διαδικασίες, τη λειτουργία, τους πελάτες, τα προϊόντα ή τις υπηρεσίες που παρέχουν. Η επιχειρηματική αναλυτική παρουσιάζεται ως ο τομέας με τον οποίο τα δεδομένα αυτά μπορούν να μεταφραστούν σε πληροφορία χρήσιμη για τον καθορισμό των μελλοντικών ενεργειών που θα εκτελέσει ο οργανισμός. Σύμφωνα με την εργασία του Bayrak, (2015), η επιχειρηματική αναλυτική ορίζεται ως «ένα ευρύ σύνολο εφαρμογών, τεχνολογιών και διαδικασιών για την συλλογή, αποθήκευση, πρόσβαση και ανάλυση δεδομένων το οποίο μπορεί να βοηθήσει τον οργανισμό να λάβει καλύτερες αποφάσεις». Πιο συγκεκριμένα, ως επιχειρηματική αναλυτική (Business Analytics) νοείται η εκτεταμένη χρήση δεδομένων, που συλλέγονται από ετερογενείς πηγές δεδομένων, η στατιστική και ποσοτική ανάλυση, τα επεξηγηματικά και προγνωστικά μοντέλα και η διαχείριση βασισμένη σε γεγονότα για την καθοδήγηση της λήψης αποφάσεων και της υλοποίησης των αντίστοιχων ενεργειών (Davenport, και Harris, 2017; Soltanpoor, και Sellis, 2016).

Από οργανωτικής σκοπιάς, παρουσιάζεται η μετάβαση από την παραδοσιακή διαισθητική λήψη αποφάσεων βασισμένη στην γνώση και την εμπειρία του αποφασίζοντα (Delen, και Ram, 2018), στην οδηγούμενη από γεγονότα, και κατά συνέπεια δεδομένα, λήψη αποφάσεων. Η αναγνώριση ότι η οδηγούμενη από τα δεδομένα λήψη αποφάσεων είναι ζωτικής σημασίας σε κάθε επίπεδο ενός οργανισμού, έχει ως αποτέλεσμα την ευρεία εφαρμογή της καθώς και την εμφάνιση της αυτοεξυπηρετούμενης (self-service) αναλυτικής και της επιχειρηματικής ευφυΐας (Acito, και Khatri, 2014).

Η εφαρμογή της επιχειρηματικής αναλυτικής μπορεί να επηρεάσει ριζικά μια επιχείρηση καθώς επιτρέπει την οδηγούμενη από δεδομένα λήψη αποφάσεων που αφορά στρατηγικές και επιχειρησιακές αποφάσεις. Επιπλέον, δίνει τη δυνατότητα ενσωμάτωσης στη λήψη αποφάσεων δεδομένων προερχόμενων από διαφορετικές

πηγές, από τις οποίες συνδυαστικά μπορεί να παραχθεί μια πιο καθολική και εμπειριστατωμένη οπτική του οργανισμού και των συναλλασσόμενων με αυτόν. Τα αποτελέσματα της αναλυτικής αξιοποιούνται στη λήψη αποφάσεων που εκτελείται από ανθρώπους αλλά και από πλήρως αυτοματοποιημένα συστήματα (Davenport, και Harris, 2017). Βοηθούν τους οργανισμούς να λαμβάνουν πιο έγκυρες και ενημερωμένες αποφάσεις, έγκαιρα και βέλτιστα, δημιουργώντας έτσι μεγαλύτερη επιχειρηματική αξία για τον οργανισμό (Hindle, et al., 2020). Η εφαρμογή της αναλυτικής δεδομένων σε επιχειρηματικά προβλήματα μπορεί σαφώς να συνεισφέρει στην αύξηση εσόδων, μείωση κόστους και στην επιτυχή διαχείριση ρίσκου (Acito, και Khatri, 2014).

Μεγάλο μέρος της βιβλιογραφίας που ασχολείται με την επιχειρηματική αναλυτική αναζητά τους επιστημονικούς τομείς που αποτελούν και υλοποιούν την επιχειρηματική αναλυτική. Η επιχειρηματική αναλυτική εφαρμόζεται συνήθως σε τομείς της επιχείρησης στους οποίους υπάρχει διαθέσιμη ποσοτική πληροφορία, όπως τα οικονομικά, το μάρκετινγκ και ο στρατηγικός σχεδιασμός. Με αυτό τον τρόπο, μπορεί να συμβάλει στη μείωση κόστους, στη μείωση του απαιτούμενου χρόνου ολοκλήρωσης των διαδικασιών της επιχείρησης και στη βελτίωση των παρεχόμενων προϊόντων και υπηρεσιών μιας επιχείρησης (Bayrak, 2015). Οι βιβλιογραφικές εργασίες εστιάζουν σε ποικίλα σύνολα επιστημονικών αντικειμένων. Μεταξύ αυτών προτείνονται η διαχείριση δεδομένων, τα συστήματα βάσεων δεδομένων, η εξόρυξη δεδομένων, η επεξεργασία φυσικής γλώσσας, η βελτιστοποίηση, η στατιστική ανάλυση, η επιστήμη υπολογιστών, τα εφαρμοσμένα μαθηματικά, η επιχειρησιακή έρευνα και η επιστήμη διοίκησης. Σε κάποιες αναφορές, η επιχειρηματική αναλυτική θεωρείται ως ένας συνδυασμός αυτών των τομέων καθώς αξιοποιεί τους ορισμούς και τις μεθόδους τους. Αντιθέτως, σε άλλες εξισώνεται με την επιχειρησιακή έρευνα και την επιστήμη διοίκησης καθώς έχει ως στόχο την βελτίωση της επιχειρησιακής λειτουργίας και της λήψης αποφάσεων.

Η εργασία των Mortenson et al. (2015) υποστηρίζει ότι η επιχειρηματική αναλυτική αξιοποιεί μεθόδους από τους τομείς της επιστήμης δεδομένων, της επιχειρησιακής έρευνας, της μηχανικής μάθησης και των πληροφοριακών συστημάτων. Οι συγγραφείς καταγράφουν την εξέλιξη του τομέα της αναλυτικής από

το 1910, αναλύουν αναφορές από παραδοσιακούς επιστημονικούς τομείς που συνεισφέρουν στον τομέα της αναλυτικής και συζητούν τις διαφορετικές οπτικές που αυτές παρουσιάζουν. Στην ανάλυση αυτή, οι τομείς εντάσσονται σε μία ή περισσότερες από τις τρεις κατηγορίες (Εικόνα 2-1):

- **Τεχνολογία:** εμπεριέχει τα διάφορα εργαλεία υλικού, λογισμικού και δικτύων τα οποία υποστηρίζουν την επεξεργασία δεδομένων.
- **Ποσοτικές μέθοδοι:** οι εφαρμοσμένες ποσοτικές μέθοδοι που χρησιμοποιούνται για την ανάλυση επιχειρηματικών δεδομένων, όπως η στατιστική, η μηχανική μάθηση, η οικονομετρία, η επιχειρησιακή έρευνα (operational research) και η επιστήμη διοίκησης (management science).
- **Λήψη αποφάσεων:** αποτελείται από τα εργαλεία, τις θεωρίες και εφαρμογές που χρησιμοποιούνται για να υποστηρίξουν και να εξηγήσουν την διαδικασία λήψης αποφάσεων. Η λήψη αποφάσεων απασχολεί πολλούς ανεξάρτητους επιστημονικούς τομείς, όπως η ψυχολογία, η συμπεριφορική επιστήμη, η επιχειρησιακή έρευνα και η αλληλεπίδραση ανθρώπου-μηχανής.



Εικόνα 2-1 Επιστημονικοί τομείς Επιχειρηματικής Αναλυτικής (προσαρμ. Mortenson et al., 2015)

Σύμφωνα με το πλαίσιο αρχιτεκτονικής της επιχειρηματικής αναλυτικής δεδομένων που προτείνεται στην εργασία των Raghurathi και Raghurathi (2021), τα στοιχεία που αξιοποιούνται στην υλοποίηση της ταξινομούνται σε τέσσερις οντότητες που αλληλοεπιδρούν μεταξύ τους και επηρεάζουν την ποιότητα της επιχειρηματικής αναλυτικής δεδομένων:

- **Πηγές δεδομένων:** διακρίνονται σε εσωτερικές και εξωτερικές πηγές δεδομένων. Στις εσωτερικές πηγές δεδομένων εντάσσονται τα δεδομένα που παράγονται από τις εφαρμογές επιχειρηματικής τεχνολογίας που χρησιμοποιεί η επιχείρηση. Από την άλλη πλευρά, στις εξωτερικές πηγές δεδομένων, εντάσσονται ανοικτά σύνολα δεδομένων τα οποία είναι δημόσια και υποστηρίζουν τα δεδομένα που συλλέγονται εσωτερικά. Μεταξύ άλλων, τέτοια σύνολα δεδομένων προέρχονται από τις κυβερνήσεις, τους πελάτες ή τους προμηθευτές μιας επιχείρησης ή άλλους σχετικούς οργανισμούς. Τα δεδομένα διαφορετικής ποιότητας που προέρχονται ετερογενείς πηγές δεδομένων απαιτούν κατάλληλη οργάνωση και διαχείριση. Για την επίλυση αυτού του προβλήματος εφαρμόζονται διαδικασίες ακεραιότητας, καθαρισμού και κανονικοποίησης δεδομένων.
- **Μετασχηματισμοί δεδομένων:** Για την εφαρμογή της επιχειρηματικής αναλυτικής δεδομένων, απαιτείται η κατάλληλη επεξεργασία και ο μετασχηματισμός των δεδομένων. Μιας και η επιχειρηματική αναλυτική καλείται σε πραγματικό χρόνο σε αρκετές περιπτώσεις, τα νέα διαθέσιμα δεδομένα καταφθάνουν σταδιακά. Το γεγονός αυτό, επηρεάζει τη σχεδίαση της διαδικασίας επεξεργασίας των δεδομένων καθώς η ανάπτυξη επεκτάσιμης και αποδοτικής φόρτωσης και ενημέρωσης των προς ανάλυση δεδομένων απαιτεί προνοητικότητα. Συνήθως τα βήματα που ακολουθούνται εντάσσονται στο τρίπτυχο εξαγωγή, μετασχηματισμός, φόρτωση (Extract, Transform, Load - ETL).
- **Πλατφόρμες και εργαλεία:** Ανάλογα με τις απαιτήσεις της περίπτωσης εφαρμογής της επιχειρηματικής αναλυτικής, η ανάλυση των (προετοιμασμένων) δεδομένων μπορεί να υλοποιηθεί χρησιμοποιώντας κάποια από τα διαθέσιμα εργαλεία στατιστικής ή προχωρημένης

επιχειρηματικής ευφυΐας. Τα εργαλεία επιχειρηματικής ευφυΐας έχουν ως βασικό αντικείμενο την οπτικοποίηση των αποτελεσμάτων της αναλυτικής. Σε πιο εξειδικευμένες εφαρμογές αναπτύσσονται πολύπλοκες, κατά περίπτωση αναλύσεις με την βοήθεια κάποιας προγραμματιστικής γλώσσας, όπως η Python.

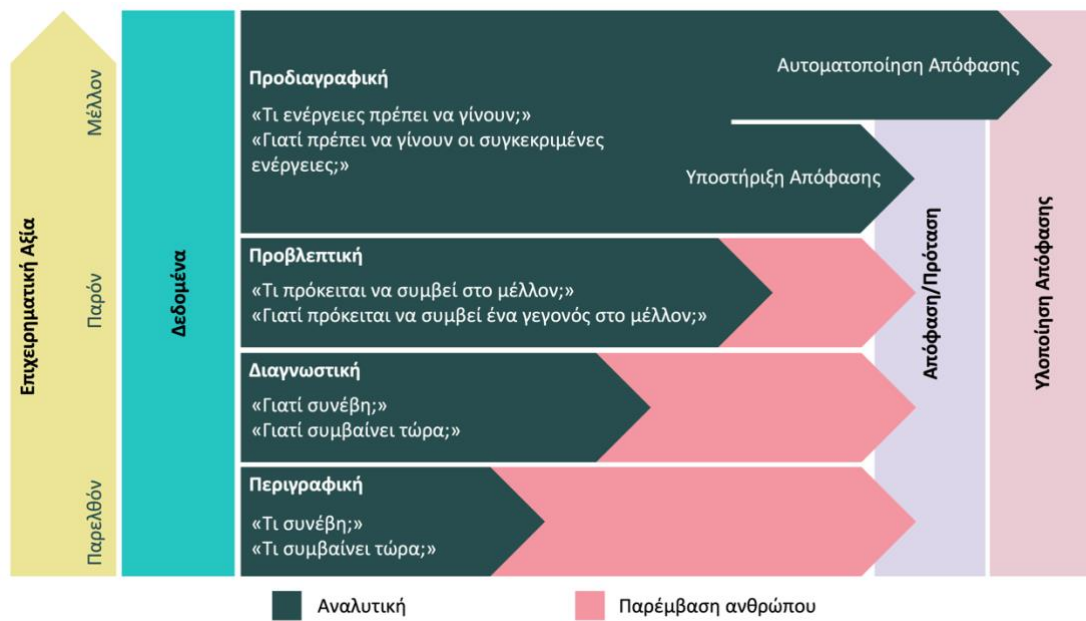
- **Ολοκληρωμένες εφαρμογές επιχειρηματικής αναλυτικής δεδομένων:** Όλα τα προηγούμενα βήματα, στοχεύουν στην εφαρμογή της επιχειρηματικής αναλυτικής δεδομένων μέσω της οποίας μπορεί να υποστηριχθεί η διοικητική λήψη αποφάσεων της επιχείρησης. Στην αγορά είναι διαθέσιμες ολοκληρωμένες εφαρμογές επιχειρηματικής αναλυτικής δεδομένων, οι οποίες διευκολύνουν την εφαρμογή αυτή και υποστηρίζουν το χρήστη. Η υποστήριξη που προσφέρουν κινείται σε δύο κατευθύνσεις: (i) στην ανάπτυξη των ζητούμενων αναλύσεων και (ii) στην διοικητική λήψη αποφάσεων βάσει των αποτελεσμάτων τους. Κάτι τέτοιο συνήθως παρέχει αναλυτικές και δυναμικές οπτικοποιήσεις των δεδομένων αλλά και των αποτελεσμάτων της αναλυτικής δεδομένων. Επιπλέον, τέτοια λύσεις δίνουν τη δυνατότητα κατασκευής εξειδικευμένων πινάκων ελέγχου (dashboards) και βοηθούν στην αναγνώριση και παρακολούθηση των κρίσιμων δεικτών της επιχείρησης.

Στην πλειονότητα των εφαρμογών της, η επιχειρηματική αναλυτική συσχετίζεται με την ανάπτυξη περιγραφικών αναλύσεων. Πέρα από μια απλή ανάλυση ακατέργαστων δεδομένων προερχόμενα από μεγάλα σύνολα δεδομένων, η επιχειρηματική αναλυτική έχει εξελιχθεί έτσι ώστε να μπορεί να προσφέρει στους οργανισμούς ένα ανταγωνιστικό πλεονέκτημα (Mikalef et al., 2018; Vidgen et al., 2017). Βασική ερευνητική πρόκληση του τομέα είναι η ανάπτυξη μοντέλων ικανών να παρέχουν κρίσιμες πληροφορίες που αφορούν τη μελλοντική απόδοση της επιχείρησης καθώς και να υποστηρίξουν τη λήψη αποφάσεων που εκτελείται σε αυτήν. Η επιχειρηματική αναλυτική κατηγοριοποιείται σε τρία στάδια τα οποία χαρακτηρίζονται από διαφορετικά επίπεδα δυσκολίας, αξίας και ευφυΐας (Akerkar, 2013; Krumeich et al., 2016; Šikšnys, και Pedersen, 2016):

- (i) Περιγραφική αναλυτική δεδομένων (Descriptive Analytics), με την οποία απαντώνται τα ερωτήματα «Τι έχει συμβεί; Γιατί έχει συμβεί;» καθώς και

«Τι συμβαίνει τώρα;». Στην περιγραφική αναλυτική δεδομένων εντάσσεται η διαγνωστική αναλυτική δεδομένων (Diagnostic Analytics) με την οποία απαντώνται ερωτήσεις σχετικά με την αιτία των γεγονότων, όπως για παράδειγμα «Γιατί συνέβη ένα γεγονός» (Soltanpoor, και Sellis, 2016). Η διαγνωστική αναλυτική δεδομένων βοηθά τους οργανισμούς και τις επιχειρήσεις να κατανοήσουν τους λόγους εκδήλωσης ενός γεγονότος που συνέβη στο παρελθόν καθώς και τις συσχετίσεις που εμφανίζονται ανάμεσα σε δεδομένα διαφορετικής προέλευσης και πληροφορίας (Soltanpoor, και Sellis, 2016). Αντίστοιχα με παρόμοιες επιστημονικές εργασίες (Krumeich et al., 2016; Šikšnyš, και Pedersen, 2016), στην παρούσα διδακτορική διατριβή, η διαγνωστική αναλυτική νοείται ως ένα υποσύνολο της περιγραφικής αναλυτικής. Η επιλογή αυτή γίνεται προκειμένου να διατηρηθεί η συνοχή των τριών βασικών επιπέδων αναλυτικής έτσι ώστε καθένα από αυτά να μπορεί να απαντήσει εξίσου τις ερωτήσεις που αφορούν την ποιότητα («Τι») και την αιτία («Γιατί»). Επιπλέον, στην περιγραφική αναλυτική δεδομένων παρουσιάζεται και ο διαχωρισμός μεταξύ παρελθοντικών γεγονότων («Τι συνέβη») και παρόντων γεγονότων («Τι συμβαίνει τώρα»).

- (ii) Προβλεπτική αναλυτική δεδομένων (Predictive Analytics) με την οποία απαντώνται τα ερωτήματα «Τι πρόκειται να συμβεί στο μέλλον» και «Γιατί πρόκειται να συμβεί ένα γεγονός στο μέλλον»
- (iii) Προδιαγραφική αναλυτική δεδομένων (Prescriptive Analytics) με την οποία απαντώνται τα ερωτήματα «Τι ενέργειες πρέπει να γίνουν» και «Γιατί πρέπει να γίνουν οι συγκεκριμένες ενέργειες».



Εικόνα 2-2 Στάδια αναλυτικής δεδομένων (προσαρμ. <https://www.gartner.com/en/newsroom/press-releases/2014-10-21-gartner-says-advanced-analytics-is-a-top-business-priority>)

Οι τεχνολογικές εξελίξεις σε συνδυασμό με τη μείωση του κόστους υπολογιστικών μονάδων, αποθήκευσης δεδομένων και δικτυακών πόρων, επιτρέπουν σε συνεχώς περισσότερες επιχειρήσεις να αναπτύξουν διαδικασίες συλλογής και αποθήκευσης δεδομένων μεγάλης κλίμακας που αφορούν τη λειτουργία της επιχείρησης. Ως αποτέλεσμα, οι επιχειρήσεις έχουν άμεσα διαθέσιμα σύνολα δεδομένων που εσωκλείουν χρήσιμη πληροφορία για αυτές (Delen και Ram, 2018). Η αυτοματοποίηση της συλλογής δεδομένων καθώς και οι εξελιγμένες τεχνολογίες συλλογής δεδομένων, όπως για παράδειγμα οι αισθητήρες, έχουν αυξήσει την ποσότητα και έχουν βελτιώσει την ποιότητα των δεδομένων που συλλέγονται από μία επιχείρηση. Μια επιχείρηση μπορεί να συνδυάσει τα δεδομένα που συλλέγει με ανοιχτά, διαθέσιμα σύνολα δεδομένων προερχόμενα από διαφορετικές πηγές που διαδικτύου. Εκτός από τις εξελίξεις στις τεχνολογίες συλλογής δεδομένων, σημαντική εξέλιξη παρουσιάζει και ο τομέας της επεξεργασίας δεδομένων. Επιπροσθέτως, οι τεχνικές δυνατότητες που παρέχονται από το υλισμικό, παράλληλα με τις εξελιγμένες εφαρμογές επεξεργασίας δεδομένων καθιστούν δυνατή την επεξεργασία δεδομένων μεγάλης κλίμακας και υψηλής πολυπλοκότητας σε λογικά χρονικά πλαίσια, ή ακόμα και σε πραγματικό χρόνο (Delen και Ram, 2018).

Προς αντίστοιχη κατεύθυνση, η εξέλιξη του τομέα της διοίκησης επιχειρήσεων τις τελευταίες δεκαετίες έχει βοηθήσει στην αναγνώριση της αξίας των διαθέσιμων δεδομένων και την άμεση συσχέτισή τους με την επιχειρηματική στρατηγική. Μεγάθη αξιολόγησης της επιχειρηματικής απόδοσης, όπως οι κρίσιμοι δείκτες απόδοσης (Key Performance Indicators - KPI), αποτελούν αναπόσπαστο κομμάτι της διοίκησης μιας επιχείρησης. Ήδη από τη δεκαετία του 1990, πληθώρα τέτοιων μετρικών, οι οποίες ξεφεύγουν από το αυστηρό οικονομικό πλαίσιο της επιχείρησης, εκτός από εργαλεία ελέγχου της απόδοσης της επιχείρησης, χρησιμοποιούνται για τον σχεδιασμό της μελλοντικής στρατηγικής της επιχείρησης (Acito, F., και Khatri, V. 2014). Οι εξελίξεις αυτές καθιστούν εφικτή την εφαρμογή προχωρημένων τεχνικών αναλυτικής, οι οποίες απαιτούν μεγάλα σύνολα δεδομένων και είναι ικανές να προσφέρουν χρήσιμη και αξιόπιστη γνώση, με έναν αποδοτικό ως προς το κόστος τρόπο (Mikalef et al., 2020). Έτσι, διευκολύνεται η ανάπτυξη και η εφαρμογή της επιχειρηματικής αναλυτικής σε περισσότερες επιχειρήσεις.

Η προσφορά της επιχειρηματικής αναλυτικής αναγνωρίζεται από τη βιβλιογραφία και τις επιχειρήσεις που την εφαρμόζουν, όμως υπάρχουν ακόμα προκλήσεις οι οποίες καθυστερούν την διάδοση και την ευρεία εφαρμογή της. Οι Davenport και Harris (2017) υποστηρίζουν ότι για να μπορέσουν οι επιχειρήσεις να εκμεταλλευτούν στο μέγιστο βαθμό την επιχειρηματική αναλυτική και τα διαθέσιμα δεδομένα, θα πρέπει να επενδύσουν στην ανεύρεση και υιοθέτηση της ανάλογης κουλτούρας, του κατάλληλου δυναμικού και της κατάλληλης τεχνολογίας.

Σύμφωνα με τους Delen και Ram (2018), οι βασικές προκλήσεις που εμποδίζουν την υιοθέτηση της επιχειρηματικής αναλυτικής είναι:

- **Εξειδίκευση:** για να υλοποιηθεί από έναν οργανισμό απαιτούνται εξειδικευμένα στελέχη που κατανοούν την αξία και την πληροφορία των δεδομένων της επιχείρησης, τις τεχνικές της αναλυτικής δεδομένων και κατέχουν τις τεχνικές ικανότητες για να τις υλοποιήσουν.
- **Κουλτούρα:** τα στελέχη των επιχειρήσεων πρέπει να αναγνωρίζουν τη σημασία της συλλογής και ανάλυσης των επιχειρηματικών δεδομένων, τα πλεονεκτήματα της οδηγούμενης από δεδομένα λήψης αποφάσεων και να είναι σε θέση να αντικαταστήσουν ή να προσαρμόσουν τις παραδοσιακές

επιχειρηματικές διαδικασίες τους έτσι ώστε να συμπεριλάβουν την επιχειρηματική αναλυτική στις διαδικασίες της επιχείρησης.

- **Απόδοση:** Η δυσκολία στην ποσοτικοποίηση της αξίας που συνεισφέρει η εφαρμογή της επιχειρηματικής αναλυτικής σε μια επιχείρηση, σε συνδυασμό με το συχνά μεγάλο κόστος και τους απαιτητικούς πόρους που αυτή χρειάζεται, αποτελούν τροχοπέδη στην εφαρμογή της. Συχνά τα στελέχη πρέπει να τεκμηριώσουν τα κόστη και να αποδείξουν λογιστικά τα οφέλη της εφαρμογής της. Αυτό αποτελεί ένα βασικό πρόβλημα, καθώς η δυνατότητα πλήρους μεταμόρφωσης μιας κλασσικής επιχείρησης σε έναν πιο δυνατό και κερδοφόρο οργανισμό εξαιτίας της επιχειρηματικής αναλυτικής δεν είναι σε όλους εμφανής.
- **Δεδομένα:** Μιας και η ύπαρξη δεδομένων αποτελεί βασική προϋπόθεση για την εφαρμογή της επιχειρηματικής αναλυτικής, απαιτείται η υλοποίηση της διαδικασίας συλλογής επιχειρηματικών δεδομένων. Η διαδικασία αυτή μπορεί να απαιτεί επιπλέον πόρους, όπως για παράδειγμα αισθητήρες ή κάμερες, και εξειδικευμένο προσωπικό. Σε δεύτερο χρόνο, η αναλυτική δεδομένων μεγάλης κλίμακας, τα οποία είναι πιθανό να συλλέγει η επιχείρηση, παρουσιάζει επιπρόσθετες προκλήσεις που πρέπει να διευθετηθούν, έτσι ώστε η εφαρμογή της επιχειρηματικής αναλυτικής να είναι επιτυχής και να αποφέρει τα ζητούμενα, αξιόπιστα αποτελέσματα.
- **Τεχνολογία:** Σε λιγότερο τεχνολογικούς παραδοσιακά τομείς, το κόστος του ψηφιακού μετασχηματισμού αποτελεί αποτρεπτικό παράγοντα υιοθέτησης της επιχειρηματικής αναλυτικής.
- **Ασφάλεια και ιδιωτικότητα:** Η ασφάλεια και η ιδιωτικότητα είναι ίσως η πιο πολυσυζητημένη πλευρά της αναλυτικής δεδομένων. Οι συνεχείς επιθέσεις που στοχεύουν στην παραβίαση των δεδομένων μιας επιχείρησης, όπως και σε κάθε τεχνολογική επιχειρηματική εφαρμογή, επηρεάζουν την εφαρμογή της επιχειρηματικής αναλυτικής σε έναν οργανισμό. Ο οργανισμός θα πρέπει να υιοθετήσει ασφαλείς πρακτικές επεξεργασίας, πρόσβασης και διασύνδεσης των δεδομένων του. Επιπλέον, η αναλυτική δεδομένων προσωπικού χαρακτήρα, εφόσον εφαρμόζεται σε δεδομένα χρηστών, μπορεί

να οδηγήσει, έμμεσα ή άμεσα, ηθελημένα ή μη, στην παραβίαση των προσωπικών δεδομένων των συμμετεχόντων χρηστών. Για το λόγο αυτό, αναπτύσσονται διεθνή νομοθετικά πλαίσια και κανονισμοί, τα οποία πρέπει να υιοθετούνται σε κάθε εφαρμογή επιχειρηματικής αναλυτικής.

Μέχρι τώρα η εφαρμογή της επιχειρηματικής αναλυτικής θεωρείται εδραιωμένη πρακτική για παραδοσιακούς επιχειρηματικούς τομείς όπως τα οικονομικά/τραπεζικά και οι πωλήσεις (Acito, και Khatri, 2014; Delen και Ram, 2018). Σε αυτούς τους τομείς, η χρήσιμη πληροφορία ποσοτικοποιείται και υπάρχουν τα αντίστοιχα δεδομένα, σε δομημένη μορφή, εύκολη προς ανάλυση. Τα επόμενα βήματα της επιχειρηματικής αναλυτικής εστιάζουν σε εφαρμογές που αξιοποιούν μη δομημένα δεδομένα όπως βίντεο, εικόνες και ήχο, τα οποία αποτελούν το μεγαλύτερο μέρος της ψηφιακής διαθέσιμης πληροφορίας σε νέους επιστημονικούς τομείς. Ένα χαρακτηριστικό παράδειγμα είναι η εφαρμογή της επιχειρηματικής αναλυτικής στον τομέα της ιατροφαρμακευτικής περίθαλψης και η σημαντική αλλαγή που αυτή επιφέρει στις διαδικασίες που ακολουθούνται αλλά και στις υπηρεσίες που παρέχονται (Ward, et al. 2014). Μέσω της επιχειρηματικής αναλυτικής μπορεί να ενισχυθεί η επιστημονική έρευνα ενός ιατρικού/ νοσηλευτικού ιδρύματος, να εξατομικευθεί η εξυπηρέτηση των ασθενών καθώς και να βελτιστοποιηθεί ο προγραμματισμός και η κατανομή των διαθέσιμων εργαζομένων και χώρων σύμφωνα με τις προβλεπόμενες ανάγκες του οργανισμού.

Επιπροσθέτως, η εφαρμογή τεχνικών αναλυτικής εντός μιας επιχείρησης μπορεί να επεκταθεί από το οικονομικό τμήμα και το τμήμα πωλήσεων, σε όλα τα λειτουργικά τμήματα μιας επιχείρησης. Ένα παράδειγμα είναι η αξιοποίηση της επιχειρηματικής αναλυτικής από το τμήμα ανθρώπινου δυναμικού μιας επιχείρησης, όπου η μπορεί να συμβάλει στη διαχείριση αδειών και παραιτήσεων, στην βελτιστοποίηση των παροχών στους εργαζομένους της επιχείρησης, ακόμη και στην εκπαίδευση του προσωπικού μιας επιχείρησης.

2.1.2 Αναλυτική Δεδομένων Μεγάλης Κλίμακας

Οι σύγχρονες τεχνολογικές εξελίξεις επιτρέπουν την πολύ γρήγορη παραγωγή και συλλογή δεδομένων μεγάλης κλίμακας (big data). Τα δεδομένα μεγάλης κλίμακας προσφέρουν πολλές και σημαντικές δυνατότητες στην αναλυτική δεδομένων και αυξάνουν την επιχειρηματική αξία που αυτή προσφέρει σε μια επιχείρηση.

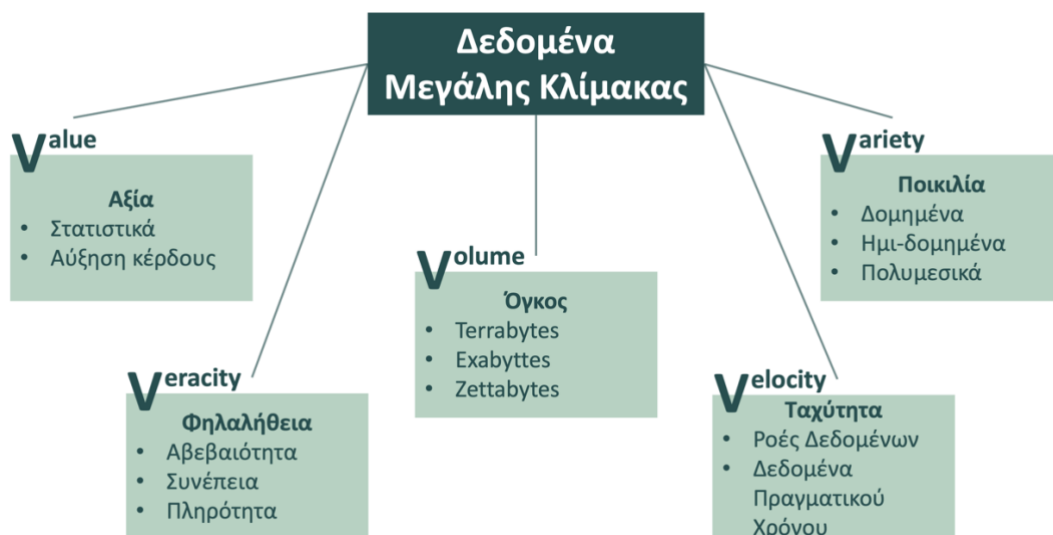
Με τα δεδομένα μεγάλης κλίμακας μπορούν να υλοποιηθούν πιο πολύπλοκες αναλύσεις και να κατασκευαστούν πιο αξιόπιστα μοντέλα. Τέτοια σύνολα, αναπαριστούν πληροφορία μεγαλύτερης λεπτομέρειας και εμπεριέχουν πολλά παραδείγματα που αντιστοιχούν σε ποικίλες καταστάσεις του εξεταζόμενου προβλήματος. Επιπροσθέτως, τα δεδομένα μεγάλης κλίμακας δίνουν την δυνατότητα εξαγωγής αθροιστικής γνώσης για έναν πληθυσμό ή συγκριτικά με έναν πληθυσμό. Για παράδειγμα στην ιατρική, εξετάζοντας μεγαλύτερο αριθμό δειγμάτων μπορεί να κατανοηθεί καλύτερα και να προβλεφθεί πιο αξιόπιστα η εξέλιξη μιας πανδημίας. Αντιστοίχως, στον ίδιο τομέα, η απομονωμένη ανάλυση του ιστορικού ενός ασθενούς μπορεί να οδηγήσει σε διαφορετικά συμπεράσματα από την συγκριτική ανάλυση με τα δεδομένα ασθενών με αντίστοιχη εξέλιξη και παθήσεις.

Από τα παραπάνω συμπεραίνεται ότι τα δεδομένα μεγάλης κλίμακας επιτρέπουν την συλλογή περισσότερων δεδομένων που περιέχουν περισσότερη χρήσιμη πληροφορία. Όμως, η ποιότητα και η χρηστικότητα της πληροφορίας αυτής δεν είναι εξασφαλισμένη. Μεγαλύτερα σύνολα δεδομένων είναι πιθανόν να περιέχουν μεγαλύτερο βαθμό ασάφειας και περισσότερες ασυνήθιστες παρατηρήσεις. Για την επιτυχή αξιοποίηση των δεδομένων μεγάλης κλίμακας θα πρέπει να διευθετηθούν τα προβλήματα ιδιωτικότητας, ασφάλειας, αποθήκευσης και επεξεργασίας, επεκτασιμότητας, ανοχής σε σφάλματα και ποιότητας των δεδομένων (Katal, et al., 2013).

Για να αξιοποιήσει πλήρως τα δεδομένα μεγάλης κλίμακας, ένας οργανισμός πρέπει να αναγνωρίσει τους τομείς της επιχείρησης στους οποίους μπορεί να επωφεληθεί από την οδηγούμενη από τα δεδομένα λήψη αποφάσεων, να σχεδιάσει και να εκτελέσει μεθοδικά έργα αναλυτικής δεδομένων και να συγκεντρώσει τους απαιτούμενους πόρους που θα μπορέσουν να μετατρέψουν τα δεδομένα σε αποφάσεις (Mikalef et al., 2020). Επιπλέον, τα δεδομένα μεγάλης κλίμακας

παρουσιάζουν συγκεκριμένα χαρακτηριστικά τα οποία προσθέτουν προκλήσεις στην αναλυτική δεδομένων. Με την πάροδο του χρόνου, με την ανάπτυξη και υιοθέτηση των δεδομένων μεγάλης κλίμακας και της αναλυτικής δεδομένων τέτοιου μεγέθους, ανακύπτουν νέα χαρακτηριστικά και προκλήσεις, με τα οποία ασχολείται ο ερευνητικός τομέας των δεδομένων μεγάλης κλίμακας.

Σύμφωνα με την βιβλιογραφία, τα δεδομένα μεγάλης κλίμακας χαρακτηρίζονται από πέντε βασικές ιδιότητες, οι οποίες επηρεάζουν την αποτελεσματικότητα της αναλυτικής δεδομένων: (i) όγκος (volume), (ii) ταχύτητα (velocity), (iii) ποικιλία (variety), (iv) φιλαλήθεια (veracity) και (v) αξία (value). Σε αυτά τα βασικά χαρακτηριστικά συχνά προστίθενται επιπλέον η μεταβλητότητα (variability), η εγκυρότητα (validity) και η βιωσιμότητα (viability) (Hariri, et al., 2019).



Εικόνα 2-3 Χαρακτηριστικά Δεδομένων Μεγάλης Κλίμακας (προσαρμ. Hariri, et al., 2019)

- **Όγκος:** Ο όγκος αναφέρεται στο μαζικό μέγεθος των δεδομένων που παράγονται και συλλέγονται, όμως ο ποσοτικός ορισμός ενός συνόλου δεδομένων ως σύνολο μεγάλης κλίμακας δεν είναι διακριτός. Αν και είναι σύνηθες σύνολα μεγέθους exabyte ή zettabyte να θεωρούνται ως σύνολα μεγάλης κλίμακας, οι προκλήσεις των δεδομένων μεγάλης κλίμακας παρουσιάζονται και σε μικρότερα σύνολα δεδομένων. Ο μεγάλος όγκος δεδομένων μπορεί να περιγράψει καλύτερα το περιβάλλον και τον πληθυσμό στον οποίο αναφέρονται τα δεδομένα και κατά συνέπεια μπορεί να βελτιώσει την αξιοπιστία των αποτελεσμάτων της αναλυτικής δεδομένων (Duan, και

Xiong, 2015). Επιπλέον, τα σύνολα μεγάλης κλίμακας εμπεριέχουν περισσότερα χαρακτηριστικά και παράγοντες που ανοίγουν τον δρόμο για την εφαρμογή πιο πολύπλοκων μοντέλων, αλγορίθμων και αναλύσεων που θα αξιοποιούν περισσότερη πληροφορία για να παράγουν τα ζητούμενα προβλεπτικά ή προδιαγραφικά αποτελέσματα.

- **Ποικιλία:** Η ποικιλία είναι το χαρακτηριστικό το οποίο αναφέρεται στους διαφορετικούς τύπους δεδομένων που μπορεί να περιέχονται σε ένα σύνολο δεδομένων μεγάλης κλίμακας (Hariri et al., 2019). Τα δεδομένα μπορεί να είναι δομημένα, ημι-δομημένα ή μη δομημένα δεδομένα. Ως δομημένα χαρακτηρίζονται τα δεδομένα που είναι καλώς ορισμένα, οργανωμένα και ταξινομημένα και αποθηκεύονται σε παραδοσιακά συστήματα βάσεων δεδομένων. Ημι-δομημένα χαρακτηρίζονται τα δεδομένα τα οποία έχουν κάποια οργάνωση, χωρίς να ακολουθούν τον αυστηρό ορισμό των σχεσιακών δομών. Στον αντίποδα αυτών βρίσκονται τα μη δομημένα δεδομένα. Ως τέτοια χαρακτηρίζονται τα σύνολα δεδομένων που δεν έχουν κάποιο προκαθορισμένο μοντέλο ή δεν οργανώνονται με τους προκαθορισμένους τρόπους. Τυπικά, ως μη δομημένα σύνολα θεωρούνται τα δεδομένα ελεύθερου κειμένου ή πολυμεσικού χαρακτήρα. Η αναλυτική συνόλων αποτελούμενων από διαφορετικούς τύπους δεδομένων, προερχόμενων από ετερογενείς πηγές, απαιτεί επιπλέον διαδικασίες μετασχηματισμού, μορφοποίησης και ομογενοποίησης των δεδομένων πριν την εφαρμογή μοντέλων και αλγορίθμων (Duan, και Xiong, 2015).
- **Ταχύτητα:** Η ταχύτητα αναφέρεται στον ρυθμό με τον οποίο παράγονται τα δεδομένα, τα οποία τυπικά παράγονται σε παρτίδες (batch), σε σχεδόν πραγματικό χρόνο, σε πραγματικό χρόνο ή με τη μορφή ροών δεδομένων (Hariri et al., 2019). Η ταχύτητα επηρεάζεται τόσο από το είδος της πηγής που παράγει τα δεδομένα, όσο και από τον αριθμό των πηγών παραγωγής δεδομένων. Για παράδειγμα, οι αισθητήρες παράγουν πολύ πιο γρήγορα νέες μετρήσεις σε σχέση με ένα απλό λογιστικό σύστημα μιας μικρής επιχείρησης. Αντίστοιχα, σε ένα κοινωνικό δίκτυο, αν υποθέσουμε ότι καταγράφεται όλη η αλληλεπίδραση του χρήστη, κάθε χρήστης παράγει πολλά και γρήγορα δεδομένα, γεγονός το οποίο πολλαπλασιάζεται με τον μεγάλο αριθμό

χρηστών που χρησιμοποιούν ένα δημοφιλές κοινωνικό δίκτυο. Όσο αυξάνεται η ταχύτητα με την οποία παράγονται τα δεδομένα, τόσο περισσότερες προκλήσεις παρουσιάζονται στην ανάλυσή τους και στην ενσωμάτωση της αναλυτικής δεδομένων σε εφαρμογές όπως συστήματα προτάσεων ή διαφημιστικές δημοπρασίες. Μάλιστα σε κάποιους τομείς όπως οι ιατρικές εφαρμογές, η όποια καθυστέρηση στην επεξεργασία και ανάλυση των δεδομένων είναι κρίσιμη, καθώς τα σχετικά μοντέλα πρέπει να εκτελούνται συνεχώς και να λαμβάνουν τις βέλτιστες αποφάσεις σε σχεδόν πραγματικό χρόνο (Duan, και Xiong, 2015).

- **Φιλαλήθεια:** Η φιλαλήθεια εστιάζει στην ποιότητα των δεδομένων, τα οποία μπορεί να περιέχουν θόρυβο, αβεβαιότητα, ασάφεια ή να είναι ελλιπή. Οι διαφορετικές πηγές παραγωγής δεδομένων και η ποικιλία των δεδομένων επηρεάζουν την ποιότητα των δεδομένων και κατά συνέπεια την ακρίβεια και την αξιοπιστία της αναλυτικής δεδομένων μεγάλης κλίμακας (Hariri, et al., 2019).
- **Αξία:** Το χαρακτηριστικό της αξίας αναφέρεται στη χρήσιμη πληροφορία που περιέχεται στα δεδομένα και μπορεί να αξιοποιηθεί στη λήψη αποφάσεων. Για παράδειγμα, τα δεδομένα πωλήσεων της Amazon, εκτός των λειτουργικών σκοπών που επιτελούν, αναλύονται και αξιοποιούνται προκειμένου να παράγουν βελτιωμένες προτάσεις αγορών στους χρήστες ανάλογα με τις προτιμήσεις τους. Με τον τρόπο αυτό αποφέρουν περισσότερες πωλήσεις και μεγαλύτερη αφοσίωση χρηστών (Hariri, et al., 2019).

Γενικότερα, η αναλυτική δεδομένων μεγάλης κλίμακας παρουσιάζει δύο ευκαιρίες. Αρχικά, τα αποτελέσματα της αναλυτικής αναμένεται να είναι πιο αξιόπιστα και στατιστικά βέβαια. Αυτό οφείλεται στο γεγονός ότι τα μεγάλα σύνολα δεδομένων περιέχουν περισσότερα παραδείγματα, διαφορετικές περιπτώσεις και πιο ακριβή καταγραφή του περιβάλλοντος. Επιπλέον, οι αλγόριθμοι αναλυτικής δεδομένων μπορούν να βελτιωθούν, να λάβουν υπόψιν περισσότερα χαρακτηριστικά και παράγοντες που επηρεάζουν τα αποτελέσματά τους, προσφέροντας μια πανοραμική σκοπιά στο προς εξέταση πρόβλημα (Duan, και Xiong, 2015).



Εικόνα 2-4 Είδη δεδομένων μεγάλης κλίμακας (προσαρμ. Deshrande et al., 2019)

Τα δεδομένα που παράγονται από διαφορετικές πηγές, διαφέρουν ως προς το μέγεθος, τη διαθεσιμότητα, το περιεχόμενο και τις αναπαραστάσεις που χρησιμοποιούν. Στην Εικόνα 2-4 παρουσιάζονται τα διαφορετικά είδη δεδομένων μεγάλης κλίμακας, όπως ταξινομούνται στην εργασία των (Deshrande, et al., 2019). Βασικό ρόλο στην παραγωγή δεδομένων μεγάλης κλίμακας αποτελούν πηγές δεδομένων οι οποίες συλλέγουν δεδομένα χρηστών. Μεταξύ άλλων, η συμπεριφορά των χρηστών στα κοινωνικά δίκτυα, η χρήση των κινητών συσκευών των χρηστών, σε συνδυασμό με το διαδίκτυο των αντικειμένων, τα γεωγραφικά δεδομένα τοποθεσίας και τα πολυμεσικά δεδομένα που διαμοιράζονται, αποτελούν σημαντικές πηγές παραγωγής δεδομένων μεγάλης κλίμακας.

Η εφαρμογή της επιχειρηματικής αναλυτικής πάνω σε δεδομένα μεγάλης κλίμακας προϋποθέτει την επίλυση των τεχνολογικών προκλήσεων που παρουσιάζονται στην διαχείριση και ανάλυση των δεδομένων μεγάλης κλίμακας οι οποίες μεταξύ άλλων αφορούν τη συλλογή, την αποθήκευση, τη μεταφορά, το διαμοιρασμό, την αναζήτηση, την ανάλυση και οπτικοποίηση των δεδομένων μεγάλης κλίμακας (Duan, και Xiong, 2015).

Στην εργασία των (Duan, και Xiong, 2015), εξετάζονται οι προκλήσεις της αναλυτικής δεδομένων μεγάλης κλίμακας που αφορούν την υποδομή που απαιτείται για την υλοποίηση ενός συστήματος συλλογής, αποθήκευσης και επεξεργασίας δεδομένων μεγάλης κλίμακας:

- **Συλλογή δεδομένων:** αναπτύσσονται συνεχώς νέες τεχνικές και συσκευές συλλογής και καταγραφής περισσότερων και διαφορετικών τύπων δεδομένων (εικόνες, κάμερες, αισθητήρες, γεωγραφικά δεδομένα, δεδομένα GPS κ.ά.). Πέρα από την επιτυχή τεχνολογική διασύνδεση με τις νέες συσκευές συλλογής δεδομένων, απαιτείται η κατάλληλη μοντελοποίηση και διαχείριση των νέων τύπων δεδομένων που αυτές παράγουν.
- **Αποθήκευση δεδομένων:** τα παραδοσιακά συστήματα αποθήκευσης δεδομένων, όπως οι σχεσιακές βάσεις δεδομένων εμφανίζουν δυσκολία στην επεκτασιμότητα που απαιτείται για την υποστήριξη δεδομένων μεγάλης κλίμακας και στην έγκαιρη επεξεργασία που απαιτεί η ανταπόκριση εφαρμογών πραγματικού χρόνου. Ως απάντηση σε αυτές τις προκλήσεις, αναπτύσσονται νέες τεχνολογίες αποθήκευσης δεδομένων, όπως για παράδειγμα οι NoSQL βάσεις δεδομένων. Επιπροσθέτως, αναπτύσσονται κατακεντρωμένα συστήματα αποθήκευσης αρχείων και συνόλων δεδομένων, προκειμένου να υποστηρίζεται μεγαλύτερη επεκτασιμότητα.
- **Παράλληλη υπολογιστική κατακεντρωμένων συστημάτων:** Εκτός από τα κατακεντρωμένα συστήματα αποθήκευσης, η επεξεργασία δεδομένων μεγάλης κλίμακας ευνοείται από τα κατακεντρωμένα συστήματα επεξεργασίας δεδομένων. Αυτά εστιάζουν σε συγκεκριμένες τεχνικές οι οποίες παραλληλίζουν τις ενέργειες επεξεργασίας στα διαθέσιμα μηχανήματα. Τεχνολογίες όπως το MapReduce, ένα επεκτάσιμο κατακεντρωμένο επεξεργαστικό μοντέλο, καθιστούν δυνατή την παράλληλη επεξεργασία ενός συνόλου δεδομένων.
- **Δικτύωση:** Οι δικτυακές εγκαταστάσεις πρέπει να μπορούν να υποστηρίξουν κατακεντρωμένες εφαρμογές δεδομένων μεγάλης κλίμακας, στα οποία οι απαιτήσεις μεταφοράς μεγάλου όγκου δεδομένων μεταξύ υποσυστημάτων που βρίσκονται σε διαφορετικές γεωγραφικές τοποθεσίες είναι αυξημένες.

Μέσω της επιχειρηματικής αναλυτικής, οι επιχειρήσεις μπορούν να αξιοποιήσουν νέους τύπους δεδομένων, όπως ηχητικά δεδομένα, αρχεία κειμένου, αρχεία καταγραφής γεγονότων (log files), εικόνες και βιντεοληπτικό υλικό. Η χρήσιμη πληροφορία που περιέχεται σε τέτοιου είδους αρχεία δεν ήταν διαθέσιμη στις

επιχειρήσεις μέχρι πρόσφατα και πιθανώς να επηρεάζει δραστικά τη λήψη αποφάσεων της επιχείρησης. Τα σύνολα δεδομένων μεγάλης κλίμακας που συλλέγονται πλέον τείνουν να περιέχουν κυρίως μη δομημένα δεδομένα. Για το λόγο αυτό παρουσιάζουν επιπλέον προκλήσεις, καθώς οι παραδοσιακές μέθοδοι αναλυτικής δεδομένων δεν μπορούν να τα επεξεργαστούν επιτυχώς. Οι προκλήσεις που οφείλονται στο μη δομημένο χαρακτήρα των δεδομένων συνήθως αντιμετωπίζονται με δύο τρόπους: (i) είτε με τον μετασχηματισμό των δεδομένων σε δομημένη μορφή, (ii) είτε με την ανάπτυξη νέων μεθόδων οι οποίες μπορούν να διαχειριστούν επιτυχώς μη δομημένα δεδομένα (Duan, και Xiong, 2015).

Για να μπορέσουν οι παραδοσιακές μέθοδοι αναλυτικής δεδομένων να εφαρμοστούν σε δεδομένα μεγάλης κλίμακας θα πρέπει να διαχειριστούν επιτυχώς τις προκλήσεις που παρουσιάζονται εξαιτίας των χαρακτηριστικών των συνόλων αυτών. Ο όγκος των δεδομένων μεγάλης κλίμακας αποτελεί μια πρόκληση για τις παραδοσιακές μεθόδους αναλυτικής δεδομένων, καθώς οι περισσότερες από αυτές είναι κεντροποιημένες και μη επεκτάσιμες. Συχνά, κατά τον ορισμό των μεθόδων αυτών θεωρείται δεδομένη η εκτέλεση της μεθόδου σε ένα μόνο μηχάνημα, όπου ολόκληρο το σύνολο δεδομένων είναι άμεσα προσπελάσιμο στη μνήμη και διαθέσιμο προς επεξεργασία. Ένα δεύτερο πρόβλημα είναι η στατικότητα των παραδοσιακών μεθόδων η οποία αποτρέπει την δυναμική προσαρμογή τους σε διαφορετικές περιπτώσεις, μιας και συνήθως δεν αναλύουν τα εισερχόμενα δεδομένα on-the-fly. Λύση σε αυτό το πρόβλημα μπορεί να αποτελεί η προσαυξητική μάθηση (incremental learning). Αυτή η τεχνική μπορεί να διαχειριστεί επιτυχώς το πρόβλημα της ταχύτητας των δεδομένων μεγάλης κλίμακας. Επιπροσθέτως, οι παραδοσιακές μέθοδοι αναλυτικής δεδομένων δέχονται δεδομένα ομοιόμορφης δομής, έχοντας ως αποτελέσματα την αδυναμία εφαρμογής τους σε προβλήματα στα οποία τα δεδομένα έχουν διαφορετικό είδος, μεταβαλλόμενη δομή ή είναι ελλιπή.

Οι παραδοσιακές μέθοδοι αναλυτικής δεδομένων θα πρέπει να προσαρμοστούν ή να επανασχεδιαστούν προκειμένου να διαχειρίζονται επιτυχώς τις παραπάνω προκλήσεις (Tsai, et al., 2015). Στη βιβλιογραφία αποτυπώνονται αρκετές τεχνικές προχωρημένης αναλυτικής δεδομένων και στρατηγικές οι οποίες μπορούν διαχειριστούν κάποιες από αυτές τις προκλήσεις και να μετασχηματίσουν ένα

πρόβλημα σε πολλαπλά προβλήματα μικρότερου μεγέθους. Με τον τρόπο αυτό μπορούν να οδηγήσουν σε καλύτερες αποφάσεις, μείωση κόστους και πιο αποδοτική επεξεργασία δεδομένων μεγάλης κλίμακας. Μεταξύ αυτών των μεθόδων προτείνονται η μηχανική μάθηση και η εξόρυξη δεδομένων, οι στρατηγικές της παραλληλοποίησης (parallelization), της μεθόδου «διαίρει και βασίλευε», της προσαυξητικής μάθησης, της δειγματοληψίας κ.ά. (Hariri, et al., 2019).

2.1.3 Μηχανική Μάθηση στην Επιχειρηματική Αναλυτική

Η Μηχανική Μάθηση (Machine Learning) είναι ο τομέας της Επιστήμης των Υπολογιστών που ασχολείται με τους αλγορίθμους και τις τεχνικές αυτοματοποίησης της επίλυσης πολύπλοκων προβλημάτων τα οποία είναι δύσκολο να επιλυθούν με παραδοσιακές μεθόδους προγραμματισμού (Rebala, et al., 2019). Στις παραδοσιακές μεθόδους προγραμματισμού παρέχονται οι προδιαγραφές του προγράμματος, όπως συγκεκριμένα βήματα ή κανόνες, οι οποίες επιτρέπουν τη λύση του προβλήματος. Αντιθέτως, στη μηχανική μάθηση το πρόγραμμα που επιλύει το πρόβλημα, παράγεται αξιοποιώντας παραδείγματα που αποτελούν λύσεις του προβλήματος, μαθαίνοντας από τα διαθέσιμα δεδομένα. Τα δεδομένα αυτά συνήθως αποτελούν ηλεκτρονικά σύνολα δεδομένων τα οποία συλλέγονται και διατίθενται προς ανάλυση.

Σε σχέση με τη στατιστική μοντελοποίηση, η οποία χρησιμοποιείται για την ανάλυση δεδομένων, η μηχανική μάθηση υπερέχει καθώς δεν παρουσιάζει τόσο ισχυρούς περιορισμούς και μπορεί να διαχειριστεί δεδομένα που περιέχουν θόρυβο ή είναι ελλιπή. Επιπλέον, είναι κατάλληλη για την ανάλυση μη δομημένων δεδομένων, όπως πολυμεσικά δεδομένα ή ελεύθερο κείμενο (Raghurathi, και Raghurathi, 2021). Αυτή η προσέγγιση προτιμάται σε προβλήματα στα οποία η μοντελοποίηση ή τα βήματα που αποτελούν τη λύση του προβλήματος δεν υπάρχουν, δεν μπορούν να οριστούν με σαφήνεια ή πρακτικά δεν μπορούν να απαριθμηθούν.

Στόχος της μηχανικής μάθησης είναι η ανάπτυξη αποδοτικών και αξιόπιστων αλγορίθμων επίλυσης προβλημάτων, με ένα γενικευμένο τρόπο. Η αποδοτικότητα

ενός τέτοιου μοντέλου εκτιμάται με μετρικές ποιότητας όπως ο χρόνος εκτέλεσης, η πολυπλοκότητα του αλγορίθμου καθώς και το επαρκές μέγεθος δεδομένων μέσω του οποίου ο αλγόριθμος θα εκπαιδευτεί κατάλληλα. Ως εκ τούτου, η επιτυχία ενός αλγορίθμου μηχανικής μάθησης, εξαρτάται από τα δεδομένα εκπαίδευσης τα οποία χρησιμοποιεί. Επιπλέον, οι αλγόριθμοι μηχανικής μάθησης χρησιμοποιούνται όλο και περισσότερο προκειμένου να εξάγουν χρήσιμη πληροφορία και να παράγουν λύσεις αξιοποιώντας τα διαθέσιμα δεδομένα, όπως προβλέψεις, επιτρέποντας την υποστήριξη της λήψης αποφάσεων σε πραγματικό χρόνο. Για το λόγο αυτό η μηχανική μάθηση είναι άρρηκτα συνδεδεμένη με την αναλυτική δεδομένων και τη στατιστική (Mohri et al., 2018).

Τα συστήματα που βασίζονται στη μηχανική μάθηση μπορούν να παράγουν προβλέψεις ενώ παράλληλα εκπαιδεύονται χρησιμοποιώντας έναν πολύ μεγάλο αριθμό παρατηρήσεων. Αναπόφευκτα, η μηχανική μάθηση θεωρείται η επόμενη ημέρα της αναλυτικής δεδομένων (Ongsulee et al., 2018). Οι εφαρμογές της μηχανικής μάθησης και η ανάλυση των δεδομένων που αυτή παρέχει, δίνουν στις επιχειρήσεις τη δυνατότητα να κατανοούν καλύτερα τους πελάτες τους, να εντοπίζουν πιθανές ευκαιρίες κέρδους και μελλοντικά προβλήματα.

Η μηχανική μάθηση μπορεί να αποτελέσει τη λύση πολλών πρακτικών προβλημάτων βρίσκοντας εφαρμογή σε διαφορετικούς τομείς. Μεταξύ άλλων, η μηχανική μάθηση μπορεί να επιλύσει προβλήματα ταξινόμησης εγγράφων ή κειμένων, να συμβάλλει στην επεξεργασία φυσικής γλώσσας και σε εφαρμογές επεξεργασίας λόγου (Natural Language Processing), στην ανάπτυξη εφαρμογών υπολογιστικής όρασης (Computer Vision) αλλά και σε εφαρμογές βιοπληροφορικής (Rebala et al., 2019).

Το πρώτο βήμα για την αξιοποίηση των αλγορίθμων μηχανικής μάθησης στην ανάλυση δεδομένων, είναι η αξιολόγηση και η αναγνώριση του προβλήματος το οποίο καλούνται να επιλύσουν. Στον τομέα της μηχανικής μάθησης έχουν μελετηθεί εκτενώς πέντε βασικές κατηγορίες προβλημάτων: (i) η ταξινόμηση (classification), (ii) η παλινδρόμηση (regression), (iii) η κατάταξη (ranking), (iv) η ομαδοποίηση (clustering) και (v) η μείωση διαστατικότητας (dimensionality reduction) (Rebala et

al., 2019). Η ταξινόμηση αφορά προβλήματα στα οποία καλούμαστε να ταξινομήσουμε ένα αντικείμενο σε μία συγκεκριμένη κλάση αντικειμένων.

Χαρακτηριστικό παράδειγμα της ταξινόμησης είναι η αναγνώριση της πληροφορίας που αποτυπώνεται σε μια εικόνα. Για παράδειγμα, αν παρουσιάζεται κάποιο ζώο επιχειρείται η αναγνώριση του είδους του ζώου απεικονίζεται, με τη βοήθεια της μηχανικής μάθησης. Ένα αντίστοιχο παράδειγμα είναι η ταξινόμηση ενός κειμένου σε μια κατηγορία ανάλογα με το περιεχόμενό του. Χαρακτηριστικά μπορεί να εξετάζεται κατά πόσον αφορά ένα πολιτικό άρθρο, ένα αθλητικό άρθρο, ένα νομικό έγγραφο κ.ό.κ. Μέσω της μηχανικής μάθησης σε αυτήν την κατηγορία των προβλημάτων, μας δίνεται η δυνατότητα να ταξινομήσουμε τα αντικείμενα ως προς έναν μεγάλο αριθμό κατηγοριών.

Η δεύτερη πιο συνηθισμένη κατηγορία προβλημάτων μηχανικής μάθησης είναι τα προβλήματα παλινδρόμησης. Σε αυτά, το μοντέλο μηχανικής μάθησης καλείται να προβλέψει μία τιμή για κάθε αντικείμενο. Χαρακτηριστικά παραδείγματα παλινδρόμησης είναι η πρόβλεψη της μελλοντικής τιμής μιας μετοχής ή της συμπεριφοράς των οικονομικών δεικτών του χρηματιστηρίου.

Η τρίτη κατηγορία προβλημάτων είναι τα προβλήματα κατάταξης, όπου το μοντέλο καλείται να ανακαλύψει την σειρά κατάταξης μεταξύ των διαθέσιμων αντικειμένων, δοθέντων κάποιων κριτηρίων. Η αξιολόγηση των πιο σχετικών σελίδων που θα επιστραφούν στα αποτελέσματα της διαδικτυακής αναζήτησης είναι ένα τυπικό πρόβλημα κατάταξης.

Στα προβλήματα ομαδοποίησης το μοντέλο μηχανικής μάθησης καλείται να ομαδοποιήσει τα διαθέσιμα αντικείμενα σε ομογενή υποσύνολα του αρχικού συνόλου. Η ομαδοποίηση είναι ιδιαίτερα χρήσιμη για πολύ μεγάλα σύνολα δεδομένων για τα οποία δεν γνωρίζουμε την κατηγορία στην οποία ανήκουν. Παραδείγματα ομαδοποίησης συναντώνται συχνά στην ανάλυση των κοινωνικών δικτύων, όπου σκοπός είναι η ανακάλυψη φυσικών κοινοτήτων μεταξύ των χρηστών.

Η μείωση της διαστατικότητας αφορά τα προβλήματα που έχουν ως ζητούμενο τον μετασχηματισμό των αρχικών αναπαραστάσεων των δεδομένων σε αναπαραστάσεις χαμηλότερης διάστασης. Η επίλυση προβλημάτων διαστατικότητας

είναι ιδιαίτερα χρήσιμη στην υπολογιστική όραση. Σε αυτό τον τομέα, εικόνες μικρότερων διαστάσεων που περιέχουν την ίδια χρήσιμη πληροφορία με τις αρχικές, επεξεργάζονται και αναλύονται πιο εύκολα και γρήγορα.

Ο τομέας της μηχανικής μάθησης διαχωρίζεται σε τρεις πυλώνες: (i)την επιβλεπόμενη (supervised learning), (ii)τη μη επιβλεπόμενη (unsupervised learning) και (iii)την ενισχυτική μάθηση (reinforcement learning). Οι βασικές διαφορές τους αφορούν το είδος των δεδομένων εκπαίδευσης που είναι διαθέσιμα, τη σειρά, τη μέθοδο αφομοίωσης των δεδομένων εκπαίδευσης και το είδος των δεδομένων ελέγχου που χρησιμοποιούνται για την αξιολόγηση του αλγορίθμου (Rebala et al., 2019).

Στην επιβλεπόμενη μάθηση τα διαθέσιμα δεδομένα αποτελούν εγγραφές χαρακτηρισμένες από ετικέτες (labels) οι οποίες χρησιμοποιούνται προκειμένου το μοντέλο μηχανικής μάθησης να εκπαιδευτεί στην εκτίμηση της ετικέτας καινούριων εγγραφών που δεν έχει ξανασυναντήσει. Η επιβλεπόμενη μάθηση συσχετίζεται συνήθως με προβλήματα ταξινόμησης, προβλήματα παλινδρόμησης και προβλήματα κατάταξης.

Στη μη επιβλεπόμενη μάθηση χρησιμοποιούνται δεδομένα εκμάθησης χωρίς ετικέτες με στόχο να εκτιμηθούν τα νέα δεδομένα. Βασικά προβλήματα της μη επιβλεπόμενης μάθησης είναι η ομαδοποίηση και η μείωση διαστατικότητας.

Στην ενισχυτική μάθηση, το μοντέλο μηχανικής μάθησης εκπαιδεύεται ενεργά αλληλοεπιδρώντας με το περιβάλλον από το οποίο, αναλόγως με τις ενέργειες που επιλέγει, λαμβάνει κάποια ανταμοιβή. Ο σκοπός του αλγορίθμου είναι, μέσω δοκιμών, να εντοπίσει την ακολουθία ενεργειών που θα του αποφέρουν τη μέγιστη δυνατή ανταμοιβή. Εκτός από τους τρεις αυτούς πυλώνες, στη βιβλιογραφία εντοπίζονται επιπλέον διαφορετικά σενάρια μάθησης όπως η επιγραμμική μάθηση (online learning) και η ενεργή μάθηση (active learning) (Rebala et al., 2019).

Συνήθως, η περιγραφική αναλυτική δεδομένων υλοποιείται με τη βοήθεια της στατιστικής επιστήμης, της στατιστικής μοντελοποίησης και της οπτικοποίησης των δεδομένων. Από την άλλη, οι αλγόριθμοι τεχνητής νοημοσύνης χρησιμοποιούνται για τα πιο εξελιγμένα στάδια επιχειρηματικής αναλυτικής. Πολλές τεχνικές μηχανικής

μάθησης αποτελούν λύσεις προχωρημένης αναλυτικής δεδομένων μεγάλης κλίμακας, μιας και υπερέχουν σε ταχύτητα, αξιοπιστία και ακρίβεια όταν είναι διαθέσιμα σύνολα δεδομένων μεγάλης κλίμακας (Hariri, et al., 2019).

Ο συνδυασμός της αναλυτικής δεδομένων μεγάλης κλίμακας με τη μηχανική μάθηση φαίνεται πολλά υποσχόμενος, εφόσον διευθετηθούν οι προκλήσεις που παρουσιάζει. Στην εκπαίδευση ενός μοντέλου μηχανικής μάθησης η οποία βασίζεται σε μη δομημένα, ελλιπή ή με θόρυβο δεδομένα, εισέρχεται αβεβαιότητα η οποία μεταφέρεται στα παραγόμενα αποτελέσματα του μοντέλου. Η ποιότητα των δεδομένων είναι κρίσιμος παράγοντας για την αξιοπιστία των περισσότερων τεχνικών εξόρυξης δεδομένων και μηχανικής μάθησης, καθώς αυτές δεν θα μπορούν να εξάγουν τα βέλτιστα αποτελέσματα χρησιμοποιώντας μεροληπτικά δεδομένα (Hariri et al., 2019).

Η προχωρημένη επιχειρηματική αναλυτική δεδομένων φαίνεται να αποτελεί ανταγωνιστικό πλεονέκτημα και έναν κρίσιμο παράγοντα για την επιβίωση και την ευημερία των επιχειρήσεων, καθώς οι επιχειρήσεις θα μπορούν να λαμβάνουν αποφάσεις και να καθοδηγούν τις ενέργειές τους βασισμένες στα διαθέσιμα δεδομένα. Ωστόσο, ελάχιστες επιχειρήσεις υιοθετούν τεχνικές προχωρημένης επιχειρηματικής αναλυτικής. Το γεγονός αυτό πιθανώς οφείλεται στο ότι η προχωρημένη αναλυτική δεδομένων μεγάλης κλίμακας και η εφαρμογή μεθόδων μηχανικής μάθησης προς αυτήν την κατεύθυνση, εκτός από τις προκλήσεις υλοποίησης, παρουσιάζουν εκτεταμένες επιπτώσεις στη διοίκηση των επιχειρήσεων (Kraus, et al., 2020).

2.1.4 Επιχειρηματική Αναλυτική στη Λήψη Αποφάσεων

Η προχωρημένη αναλυτική δεδομένων μεγάλης κλίμακας καθοδηγεί και επιτρέπει την επιχειρηματική αλλαγή. Με τον όρο λήψη αποφάσεων νοείται η διαδικασία επιλογής ανάμεσα σε δύο ή περισσότερες εναλλακτικές ενέργειες, οι οποίες υλοποιούν έναν ή περισσότερους σκοπούς (Sharda, et al., 2014). Η λήψη αποφάσεων αποτελεί βασικό ερευνητικό αντικείμενο πολλών επιστημονικών τομέων, μεταξύ των οποίων η νευροεπιστήμη, η επιστήμη διοίκησης και η επιστήμη

υπολογιστών, οι οποίοι τη μελετούν από διαφορετικές οπτικές (Johnson, και Busemeyer, 2010). Οι κανονιστικές προσεγγίσεις εστιάζουν στον τρόπο εξαγωγής των βέλτιστων αποφάσεων, αναπαριστώντας αλγεβρικά το πρόβλημα. Για παράδειγμα, η θεωρία μεγιστοποίησης της χρησιμότητας (utility maximization) στα οικονομικά και η έννοια της ισορροπίας (equilibrium) στη θεωρία παιγνίων, περιγράφουν πως θα πρέπει να συμπεριφέρονται οι λογικοί πράκτορες, μεμονωμένα ή σε ομάδες (Von Neumann, και Morgenstern, 1944). Από την άλλη πλευρά, οι περιγραφικές θεωρίες εισάγουν γνωστούς περιορισμούς της ανθρώπινης συμπεριφοράς στη διαδικασία λήψης αποφάσεων. Χαρακτηριστικό παράδειγμα αποτελεί η θεωρία προοπτικής (prospect theory), η οποία μπορεί επιτυχώς να εξηγήσει τις αποτυχίες της θεωρίας της αναμενόμενης χρησιμότητας στην περιγραφή της ανθρώπινης λήψης αποφάσεων υπό αβεβαιότητα (Kahneman, 1979). Πρόσφατα, οι δύο παραδοσιακές προσεγγίσεις της λήψης αποφάσεων συγχωνεύτηκαν με επιπλέον επιστημονικούς τομείς (Lee, 2013), φέρνοντας στο επίκεντρο τη σημασία της μάθησης στην λήψη αποφάσεων.

Περνώντας από τον άνθρωπο στις επιχειρήσεις, μία πρόσφατη τάση στην επιχειρηματική λήψη αποφάσεων είναι η αξιοποίηση των δεδομένων μεγάλης κλίμακας τα οποία οι επιχειρήσεις έχουν πλέον στη διάθεσή τους. Η ανάλυση και επεξεργασία των δεδομένων μεγάλης κλίμακας μπορεί να προσφέρει σημαντική γνώση στις επιχειρήσεις, οδηγώντας τις σε καλύτερες επιχειρηματικές αποφάσεις (LaValle, et al., 2011). Οι υπεύθυνοι της λήψης αποφάσεων ενός οργανισμού συνεχώς αναζητούν τρόπους με τους οποίους μπορούν να λάβουν πιο ενημερωμένες αποφάσεις και με τη βοήθεια της αναλυτικής δεδομένων μεγάλης κλίμακας μπορούν να ενισχύσουν την παραδοσιακή διαδικασία λήψης απόφασης (Elgendy, και Elragal, 2016).

Η λήψη αποφάσεων μπορεί να βελτιωθεί δραματικά με τη βοήθεια της αναλυτικής δεδομένων, ελαχιστοποιώντας τα ρίσκα και προσφέροντας πληροφορία ζωτικής σημασίας η οποία εμπεριέχεται στα διαθέσιμα στην επιχείρηση δεδομένα μεγάλης κλίμακας και δεν μπορεί να εξαχθεί με άλλο τρόπο. Στο ίδιο πλαίσιο, η αναλυτική δεδομένων μπορεί είτε να υποστηρίξει την λήψη αποφάσεων ή και να

αυτοματοποιήσει τη λήψη αποφάσεων. Επιπλέον, με τις διαθέσιμες τεχνολογίες μπορεί να αυτοματοποιηθεί και η υλοποίηση των αντίστοιχων ενεργειών.

Η διαδικασία λήψης απόφασης, σύμφωνα με το πλέον αναγνωρισμένο πλαίσιο, το οποίο ορίστηκε το 1977 και περιγράφεται στην εργασία του Simon, H. A. (2013), αποτελείται από τέσσερις φάσεις: τη φάση ευφυΐας (intelligence), σχεδιασμού (design), επιλογής (choice), υλοποίησης (implementation), με την παρακολούθηση (monitoring) συχνά να θεωρείται η πέμπτη φάση (Sharda, et al., 2014), όπως παρουσιάζονται στην Εικόνα 2-5.

Η διαδικασία ξεκινά με την φάση της ευφυΐας, στην οποία ερευνάται το περιβάλλον, καθορίζεται το πρόβλημα απόφασης και αναγνωρίζονται οι στόχοι του οργανισμού και τα κριτήρια που αφορούν αυτό το πρόβλημα. Στη φάση σχεδιασμού, κατασκευάζεται ένα μοντέλο, το οποίο αποτελεί μια απλοποιημένη ή αφηρημένη αναπαράσταση του πραγματικού περιβάλλοντος και συνήθως εμπεριέχει τις εναλλακτικές αποφάσεις. Στα μοντέλα απόφασης τυπικά περιέχονται: (i) οι μεταβλητές απόφασης, με τις οποίες περιγράφεται το σύνολο των εναλλακτικών από το οποίο καλούμαστε να επιλέξουμε, (ii) ένα σύνολο από μεταβλητές-αποτελέσματα που περιγράφουν το στόχο και τα κριτήρια του προβλήματος λήψης απόφασης, καθώς και (iii) ένα σύνολο από παραμέτρους οι οποίες περιγράφουν το περιβάλλον. Στη φάση της επιλογής, επιλέγεται η προτεινόμενη λύση του μοντέλου η οποία υλοποιείται στην φάση της υλοποίησης.

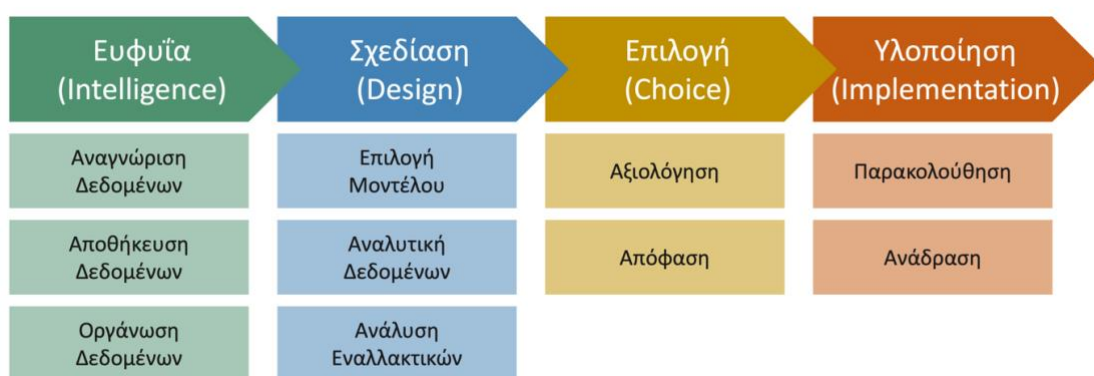
Ως λύση του μοντέλου νοείται το σύνολο των τιμών των μεταβλητών απόφασης για μια συγκεκριμένη εναλλακτική. Η επίλυση του μοντέλου απόφασης δεν συνεπάγεται απαραίτητως την επίλυση του προβλήματος το οποίο αυτό αναπαριστά. Η επίλυση ενός μοντέλου απόφασης αφορά την αναζήτηση της κατάλληλης ενέργειας και παραδοσιακά εκτελείται με αναλυτικές τεχνικές και αλγορίθμους, οι οποίοι αξιολογούν κάθε εναλλακτική.



Εικόνα 2-5 Διαδικασία Λήψης Αποφάσεων (προσαρμ. Simon, H. A. 2013)

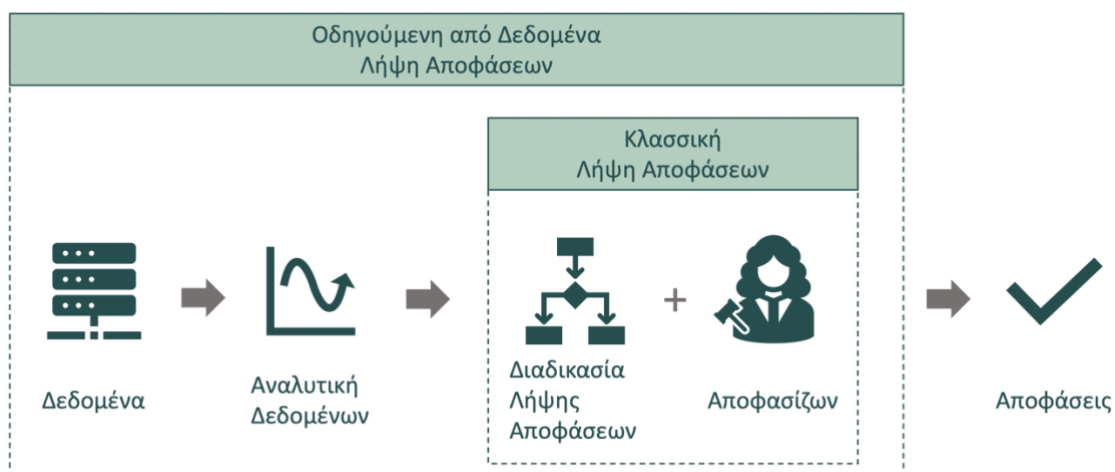
Το παραπάνω πλαίσιο της διαδικασίας λήψης απόφασης εξελίσσεται με τη βοήθεια της αναλυτικής δεδομένων, έτσι ώστε να καλύπτει την οδηγούμενη από δεδομένα λήψη αποφάσεων. Ως οδηγούμενη από δεδομένα λήψη αποφάσεων ορίζεται η συστηματική συλλογή, ανάλυση, διερεύνηση και ερμηνεία των διαθέσιμων δεδομένων, συνήθως εφαρμόζοντας τεχνικές αναλυτικής δεδομένων και αλγορίθμους μηχανικής μάθησης, που οδηγούν σε πιο ενημερωμένες αποφάσεις. Η οδηγούμενη από δεδομένα λήψη αποφάσεων χαρακτηρίζεται από διαφορετικούς βαθμούς συμμετοχής του αποφασίζοντα και των διαθέσιμων δεδομένων στην διαδικασία.

Η πλήρης αυτοματοποίηση της λήψης απόφασης παραμένει ένα ανοικτό ερώτημα. Αναλόγως με τον βαθμό συμμετοχής του αποφασίζοντα και των δεδομένων στην υλοποιηθείσα διαδικασία, η αναλυτική δεδομένων μπορεί να επαυξήσει τη λήψη αποφάσεων, έτσι ώστε η απόφαση να προκύπτει από τον συνδυασμό της εμπειρίας και της διαίσθησης του αποφασίζοντα με τα διαθέσιμα αποτελέσματα αναλυτικής (Elgendy, et al., 2021). Στην προσαρμογή του πλαισίου που περιγράφεται από (Elgendy, και Elragal, 2016), και μια απλοποιημένη μορφή της παρουσιάζεται στην Εικόνα 2-6, τα δεδομένα αξιοποιούνται με τέτοιο τρόπο ώστε να εξάγουν τη χρήσιμη πληροφορία από τα διαθέσιμα δεδομένα μεγάλης κλίμακας και να βοηθούν τον αποφασίζοντα να πάρει πιο ενημερωμένες και αξιόπιστες αποφάσεις, διατηρώντας όμως τον ρόλο του.



Εικόνα 2-6 Προσαρμοσμένη Διαδικασία Λήψης Απόφασης με Αναλυτική Δεδομένων (προσαρμ. Sharda et al., 2014)

Η οδηγούμενη από δεδομένα λήψη αποφάσεων μπορεί να αντιμετωπίσει τις περιορισμένες γνωστικές ικανότητες του ανθρώπου, την έλλειψη της απαιτούμενης πληροφορίας ή την περιορισμένη δυνατότητα επεξεργασίας του συνόλου των διαθέσιμων δεδομένων τα οποία θα οδηγούσαν στη βέλτιστη απόφαση (Elgendy, et al., 2021). Υπό αυτήν τη σκοπιά, η αναλυτική δεδομένων στην οποία βασίζεται η οδηγούμενη από δεδομένα λήψη αποφάσεων, δεν παράγει αποφάσεις υψηλού επιπέδου. Αντιθέτως εστιάζει σε χαμηλότερου, λειτουργικού επιπέδου αποφάσεις, οι οποίες θα ταξινομήσουν, συσχετίσουν, φιλτράρουν και εκτιμήσουν τα διαθέσιμα δεδομένα, παράγοντας έξοδο που θα χρησιμοποιηθεί από τους αποφασίζοντες ως εργαλείο για την επιλογή των βέλτιστων αποφάσεων. Έτσι, η οδηγούμενη από δεδομένα λήψη αποφάσεων επεκτείνει την κλασική λήψη αποφάσεων, προσθέτοντας τα δεδομένα και την αναλυτική δεδομένων στα βασικά δομικά στοιχεία της, όπως φαίνεται στην Εικόνα 2-7 (Elgendy, et al., 2021).



Εικόνα 2-7 Δομικά στοιχεία λήψης αποφάσεων με αναλυτική δεδομένων (προσαρμ. Elgendy, et al., 2021)

Η επιστήμη δεδομένων μεταξύ άλλων περιλαμβάνει τις αρχές, διαδικασίες και τεχνικές με τις οποίες μπορούν να εξηγηθούν και να αξιολογηθούν διαφορετικά φαινόμενα, μέσα από την κατά προτίμηση αυτόματη, ανάλυση δεδομένων. Ο κύριος σκοπός της επιστήμης δεδομένων είναι να συμβάλλει στη βελτίωση της λήψης αποφάσεων, αξιοποιώντας τα διαθέσιμα δεδομένα, η οποία αποτελεί και το κυρίαρχο ενδιαφέρον σε έναν οργανισμό (Provost, και Fawcett, 2013). Η προχωρημένη αναλυτική δεδομένων αποτελεί το βασικό ερευνητικό αντικείμενο της οδηγούμενης από δεδομένα λήψης αποφάσεων, καθώς μέσω των εξελιγμένων

αλγορίθμων και τεχνικών της μπορεί να παρέχει τη μέγιστη δυνατή χρήσιμη πληροφορία, που εμπεριέχεται στα διαθέσιμα δεδομένα.

Τα πλεονεκτήματα της οδηγούμενης από δεδομένα λήψης αποφάσεων έχουν αποτυπωθεί και αναλυθεί σε αρκετές μελέτες διαφόρων ερευνητικών πεδίων, όπως για παράδειγμα στην εκπαίδευση (Mandinach, και Jackson, 2012; Hora et al., 2017) και τη βιομηχανία (Bousdekis et al., 2021; Long, 2018). Μεταξύ αυτών, η εργασία των Brynjolfsson et al., 2011, παρουσιάζει μια ενδιαφέρουσα μελέτη, η οποία επιχειρεί να ποσοτικοποιήσει την συνεισφορά της οδηγούμενης από δεδομένα λήψης αποφάσεων στην αποδοτικότητα μιας επιχείρησης. Σύμφωνα με αυτήν, οι επιχειρήσεις βαθμολογούνται ανάλογα με το εύρος χρήσης δεδομένων που χρησιμοποιούν για τη λήψη αποφάσεων στο σύνολο της επιχείρησης. Παράλληλα, επιχειρείται η στατιστική απόδειξη της υπόθεσης ότι η αποδοτικότητα μιας επιχείρησης αυξάνεται αναλογικά με την αύξηση της αξιοποίησης των δεδομένων για τη λήψη αποφάσεων.

Στην εργασία των Svensson και Taghavianfar (2020), καταγράφονται οι προκλήσεις και τα πλεονεκτήματα για την οδηγούμενη από δεδομένα επιχείρηση, και αναγνωρίζεται η σημαντική βελτίωση των επιχειρηματικών αποφάσεων. Επιπλέον, οι συγγραφείς υποστηρίζουν ότι συνδυάζοντας δεδομένα από εσωτερικές και εξωτερικές πηγές, η οδηγούμενη από δεδομένα λήψη αποφάσεων αποφέρει πιο έγκυρες, έγκαιρες, ακριβείς, στοχευμένες και γρήγορες αποφάσεις, μείωση του χρόνου λήψης απόφασης, ενώ επιτυγχάνει μια ευρύτερα πιο αποδοτική διαδικασία λήψης αποφάσεων.

Επιπρόσθετα με τα παραπάνω, με την οδηγούμενη από δεδομένα λήψη αποφάσεων, περισσότερη διαθέσιμη πληροφορία, πιο ακριβής, η οποία δεν βασίζεται στην υποκειμενικότητα του ανθρώπου, εισέρχεται στη διαδικασία λήψης αποφάσεων του οργανισμού. Οι τεχνικές αναλυτικής δεδομένων σε συνδυασμό με την εφαρμογή αλγορίθμων τεχνητής νοημοσύνης συνεισφέρουν στη λήψη αποφάσεων αντικειμενική γνώση από το περιβάλλον απόφασης η οποία δεν είναι διαθέσιμη διαφορετικά. Με το συνδυασμό αυτών των δύο τομέων μπορούν να αντιμετωπιστούν προβλήματα που αξιοποιούν δεδομένα μεγάλης κλίμακας και μεγάλης ταχύτητας, στα οποία η ανάλυση και λήψη απόφασης από τον άνθρωπο

αποτελεί μια χρονοβόρα ή και αδύνατη διαδικασία, καθώς δεν θα μπορεί να παρακολουθήσει και να αξιολογήσει έγκαιρα το σύνολο της διαθέσιμης πληροφορίας. Με αυτό τον τρόπο, η οδηγούμενη από δεδομένα λήψη αποφάσεων ανοίγει τον δρόμο για την αυτοματοποίηση της διαδικασίας και κατά συνέπεια τη λήψη αποφάσεων.

Ως αυτοματοποιημένη λήψη αποφάσεων ορίζονται οι περιπτώσεις στις οποίες αλγόριθμοι και μέθοδοι τεχνητής νοημοσύνης επιστρατεύονται για τη συλλογή, την επεξεργασία, τη μοντελοποίηση και την χρήση δεδομένων για την λήψη αυτοματοποιημένων αποφάσεων (Araujo et al., 2020). Η αυτοματοποιημένη λήψη αποφάσεων δεν αφορά μόνο την τεχνολογία και τους αλγόριθμους που χρησιμοποιούνται για την υλοποίησή της. Εμπεριέχει και άλλες πλευρές, που επηρεάζουν τον κοινωνικό, πολιτικό, ηθικό, οικονομικό αντίκτυπο που αυτή επιφέρει. Η αυτοματοποιημένη λήψη αποφάσεων υλοποιείται με διαφορετικές μορφές, όπως με τη μορφή κάποιου τεχνολογικού συστήματος, όπως ένας αλγόριθμος, ένα σύστημα προτάσεων, ή ένα σύστημα υποστήριξης αποφάσεων. Μέσω αυτών, παράγονται προτάσεις και επικοινωνούνται στους υπεύθυνους απόφασης, προκειμένου είτε να τους καθοδηγήσει προς μία συγκεκριμένη κατεύθυνση, είτε να υλοποιήσει την διαδικασία απόφασης και να λάβει αποφάσεις εκ μέρους του οργανισμού χωρίς τη συμμετοχή του ανθρώπου. Με τον τρόπο αυτό, οι υπεύθυνοι για την λήψη των αποφάσεων αλληλοεπιδρούν και εξαρτώνται σε διαφορετικούς βαθμούς από τα διάφορα αυτοματοποιημένα συστήματα υποστήριξης αποφάσεων. Για παράδειγμα, σε ένα σύστημα προτάσεων, η επιλογή της επόμενης πρότασης διαμορφώνεται πλήρως από τις ενέργειες του χρήστη, και η απόφασή του αν θα δεχθεί ή θα απορρίψει την παραγόμενη πρόταση αποτελεί καθοριστικό παράγοντα στην εκπαίδευση του συστήματος παραγωγής προτάσεων. Στον αντίποδα αυτής της περίπτωσης, σε συστήματα πλήρους αυτοματοποίησης της διαδικασίας λήψης αποφάσεων, η απόφαση επιλέγεται χωρίς την συμμετοχή του ανθρώπου (Araujo et al., 2020).

Ήδη μεγάλος αριθμός επιχειρήσεων έχει επιλέξει να αυτοματοποιήσει μέρος των αποφάσεων που λαμβάνει με τη βοήθεια των τεχνολογιών αναλυτικής δεδομένων και μηχανικής μάθησης. Η τάση αυτή είναι τόσο εμφανής καθώς η αυτοματοποίηση

της λήψης αποφάσεων ξεφεύγει πλέον από τα όρια του επιχειρηματικού κόσμου και εφαρμόζεται ήδη στην καθημερινή ζωή. Στην καθημερινότητα πλέον χρησιμοποιούνται ρομποτικές συσκευές ικανές να καθαρίζουν αυτόνομα και αυτοκίνητα ικανά να πλοηγηθούν χωρίς την καθοδήγηση κάποιου οδηγού (Zanzotto, 2019).

Ένα μεγάλο μέρος της σχετικής με την αυτοματοποιημένη λήψη αποφάσεων βιβλιογραφίας ασχολείται με τις συνέπειες που έχει η υιοθέτηση της αυτοματοποιημένης λήψης αποφάσεων, τους περιορισμούς και τα ρίσκα που ενέχει, εστιάζοντας σε μεγάλο ποσοστό στο κατά πόσο η αυτοματοποιημένη λήψη αποφάσεων μπορεί να είναι προκατειλημμένη (Araujo, et al., 2020).

Σε κάποιες περιπτώσεις, η αξιολόγηση από τον χρήστη θεωρείται ως λύση στα υπολογιστικά λάθη της μηχανικής μάθησης, καθώς η εμπειρία και η διαίσθηση του χρήστη δύναται να επιδιορθώσει τυχόν αστοχίες. Η παρέμβαση του ανθρώπου σε αυτές τις περιπτώσεις λειτουργεί ως έλεγχος ποιότητας ο οποίος εξασφαλίζει ενάντια στα πιθανά λάθη των αυτοματοποιημένων συστημάτων. Παρόλα αυτά, είναι απίθανο οι αλγόριθμοι μηχανικής μάθησης στο άμεσο μέλλον να έχουν χαμηλότερη απόδοση ακόμα και σε θέματα όπως η αποφυγή διακρίσεων σε σχέση με τους ανθρώπους. Σε αυτές τις περιπτώσεις, όπου το σύστημα αποφασίζει καλύτερα από τον άνθρωπο, η παρέμβαση του ανθρώπου πιθανώς να μειώσει την αποτελεσματικότητα του συστήματος και να οδηγήσει στην εκδήλωση ανεπιθύμητων καταστάσεων και ρίσκων. Ένας σημαντικός παράγοντας που αποτρέπει την αλληλεπίδραση του ανθρώπου με τα συστήματα μηχανικής μάθησης είναι η δυσκολία της μοντελοποίησης και της υλοποίησης της παρέμβασης του ανθρώπου στο σύστημα. Ένας ακόμη αποτρεπτικός παράγοντας για την ενσωμάτωση της παρέμβασης του χρήστη σε ένα αυτοματοποιημένο σύστημα λήψης αποφάσεων είναι η ευχρηστία της αλληλεπίδρασης μεταξύ του συστήματος και του ανθρώπου (Almada, 2019).

2.2 Προβλεπτική και Προδιαγραφική Αναλυτική Δεδομένων

2.2.1 Εισαγωγή

Μέχρι σήμερα, η πλειοψηφία των εγχειρημάτων επιχειρηματικής αναλυτικής εστιάζουν στην περιγραφική και προβλεπτική αναλυτική δεδομένων και κατά κύριο λόγο βασίζονται στην εξόρυξη δεδομένων, στην τεχνητή νοημοσύνη και την προσομοίωση (Larose, και Larose, 2015; den Hertog, και Postek, 2016; Habeeb et al., 2018).

Συγκριτικά με την περιοχή της περιγραφικής και προβλεπτικής αναλυτικής δεδομένων, η περιοχή της προδιαγραφικής αναλυτικής είναι λιγότερο ώριμη (Hagerty, 2017), ενώ πρόσφατα έχει αρχίσει να συγκεντρώνει το ερευνητικό ενδιαφέρον (Larson, και Chang, 2016). Η προδιαγραφική αναλυτική θεωρείται ως το επόμενο βήμα εξέλιξης και ωρίμανσης της αναλυτικής δεδομένων η οποία θα οδηγήσει μέσω της βέλτιστης και έγκαιρης λήψης αποφάσεων στην βελτιστοποίηση της επιχειρηματικής απόδοσης (den Hertog, και Postek, 2016; Hagerty, 2017). Οι νέες τεχνολογίες πληροφορικής και επικοινωνίας (Information and Communication Technologies - ICT), όπως το διαδίκτυο των αντικειμένων (Internet of Things - IoT), οι ροές δεδομένων πραγματικού χρόνου (real-time streaming) καθώς και οι επιχειρηματικές λειτουργίες που βασίζονται σε δεδομένα, έχουν ενισχύσει την προδιαγραφική αναλυτική δεδομένων. Μέσω αυτών, οι επιχειρήσεις μπορούν να παράγουν ακριβείς προδιαγραφές (prescriptions), οι οποίες διευκολύνουν την αξιόπιστη και αποτελεσματική λήψη αποφάσεων. Οι εξελίξεις αυτές καθοδηγούν την κοινότητα της επιχειρησιακής έρευνας προς την ανάπτυξη μεθόδων και αλγορίθμων οι οποίοι θα μπορούν να αξιοποιούν τις νέες τεχνολογίες και να εργάζονται σε αρμονία με την προδιαγραφική αναλυτική δεδομένων.

Η προοπτική της προδιαγραφικής αναλυτικής δεδομένων είναι αρκετά ελκυστική. Υπόσχεται στους φορείς λήψης αποφάσεων ότι όχι μόνο θα μπορέσουν να δούνε στο μέλλον τις κρίσιμες διαδικασίες τους και να αναγνωρίσουν ευκαιρίες και πιθανά προβλήματα, αλλά ότι επιπλέον θα τους υποδείξει τη βέλτιστη ενέργεια με την οποία θα μπορέσουν να εκμεταλλευτούν ή να αποφύγουν ένα τέτοιο γεγονός (Basu, 2013).

Σύμφωνα με το άρθρο του Basu (2013), για να μπορέσει μια λύση προδιαγραφικής αναλυτικής δεδομένων να αποδώσει επιτυχώς επιχειρηματική αξία σε μια επιχείρηση στο παρόν και στο μέλλον θα πρέπει να ικανοποιεί τους πέντε πυλώνες που αποτυπώνονται στην Εικόνα 2-8:



Εικόνα 2-8 Πυλώνες Προδιαγραφικής Αναλυτικής Δεδομένων

- **Προσαρμοστικοί αλγόριθμοι:** Μια επιχειρηματική διαδικασία ενδέχεται να μεταβάλλεται διαρκώς. Η προδιαγραφική αναλυτική δεδομένων θα πρέπει να μπορεί να προσαρμοστεί και να προτείνει εκ νέου τις κατάλληλες αποφάσεις, σύμφωνα με τις εκάστοτε αλλαγές. Η προδιαγραφική αναλυτική οφείλει να υποστηρίζει την αναπροσαρμογή όλων των παρεχόμενων αλγορίθμων και να παράγει καινοτόμα πρωτόκολλα, καθώς ο όγκος και η ταχύτητα των δεδομένων αυξάνονται ραγδαία. Κάτι τέτοιο απαιτεί υψηλή προσαρμοστικότητα προκειμένου να βοηθήσει τις επιχειρηματικές διαδικασίες τις οποίες αφορά η προδιαγραφική αναλυτική με έναν συνεχή τρόπο.
- **Ενσωμάτωση προβλέψεων και προδιαγραφών:** Οι προβλέψεις, τα αποτελέσματα της προβλεπτικής αναλυτικής δεδομένων, και οι προδιαγραφές, πρέπει να μπορούν να συνεργαστούν παράλληλα ώστε η προδιαγραφική αναλυτική να εκπληρώσει το στόχο της. Η ενσωμάτωση των αποτελεσμάτων αυτών αποτελεί βασικό παράγοντα για την ευρεία υιοθέτηση και την αναγνώριση της προσφερόμενης αξίας της προδιαγραφικής αναλυτικής δεδομένων.

- Υβριδικά δεδομένα:** Οι περισσότερες επιχειρήσεις βασίζονται σε δομημένα δεδομένα, ενώ όλο και περισσότερο αρχίζουν να παράγονται και να συλλέγονται μη δομημένα δεδομένα. Ως υβριδικά δεδομένα ορίζεται ο συνδυασμός δομημένων και μη δομημένων δεδομένων. Τα υβριδικά σύνολα δεδομένων καθιστούν δυνατή την αξιοποίηση όλων των πιθανώς διαθέσιμων δεδομένων από μια επιχείρηση κατά τη λήψη αποφάσεων. Η πρακτική αυτή μπορεί να οδηγήσει στις καλύτερες δυνατές αποφάσεις, καθώς στη διαδικασία λήψης απόφασης θα συμμετέχει το σύνολο των δεδομένων της επιχείρησης και κατ' επέκταση όλη η γνώση που είναι διαθέσιμη και επηρεάζει την επιχείρηση. Η δυνατότητα επεξεργασίας τέτοιων δεδομένων δίνει στην προδιαγραφική αναλυτική τη δύναμη να μετασχηματίσει μια επιχείρηση. Με την εξέλιξη της αναλυτικής δεδομένων και περνώντας σε πιο ώριμα επίπεδα αναλυτικής δεδομένων, μπορούν να αξιοποιηθούν νέες τεχνολογίες όπως η υπολογιστική όραση (computer vision), η αναγνώριση φωνής (speech recognition), η επεξεργασία εικόνας (image processing) κ.ά., για τα οποία τα υβριδικά δεδομένα αποτελούν την κατάλληλη είσοδο.
- Προδιαγραφές και συνέπειες:** Οι προδιαγραφές που προτείνουν προδραστικές ενέργειες χρησιμοποιούν διαφορετικές μεθόδους ή συνδυασμούς μεθόδων που συνήθως εμπεριέχουν μεθόδους προσομοίωσης και βελτιστοποίησης, και έχουν διαφορετικές απαιτήσεις και πολυπλοκότητα. Για να είναι δυνατή η παραγωγή πιο αποδοτικών και έγκαιρων προδιαγραφών, η προδιαγραφική αναλυτική θα πρέπει να συνδυάζει μεθόδους βελτιστοποίησης με την επιχειρηματική λογική.
- Μηχανισμός ανάδρασης:** Μια εφαρμογή προδιαγραφικής αναλυτικής δεδομένων θα πρέπει να γνωρίζει εάν και πότε οι ενέργειες που προτείνει υλοποιούνται. Μιας και οι προδιαγραφές συνήθως αποτελούν χρονικά ευαίσθητα πλάνα τα οποία εξαρτώνται από ένα ή περισσότερα προβλεφθέντα γεγονότα, η αγνόηση μιας προδιαγραφής θα έχει αντίκτυπο στα επόμενα δεδομένα εισόδου. Στην ιδανική περίπτωση της προδιαγραφικής αυτοματοποίησης, οι ενέργειες υλοποιούνται αυτόματα. Όμως στις περισσότερες περιπτώσεις της παρούσας κατάστασης η υλοποίηση των προδιαγραφών απαιτεί την ανθρώπινη παρέμβαση.

Αντίθετα με την προδιαγραφική αναλυτική, στη βιβλιογραφία παρουσιάζονται αρκετές μελέτες ανασκόπησης με κύριο αντικείμενο την περιγραφική αναλυτική δεδομένων (Sun et al., 2013; Tsai et al., 2015; Batrinca, και Treleaven, 2015; Duan, και Xion, 2015) και την προβλεπτική αναλυτική δεδομένων (Mishra, και Silakari, 2012; Lu et al., 2017). Η παρούσα διατριβή εξετάζει την βιβλιογραφία που αφορά την προδιαγραφική αναλυτική, στην παρακάτω βιβλιογραφική ανασκόπηση. Η συγκεκριμένη βιβλιογραφική ανασκόπηση έχει τρεις στόχους:

- (i) Να ερευνήσει την υπάρχουσα βιβλιογραφία αναφορικά με την προδιαγραφική αναλυτική και τις προτεινόμενες μεθόδους υλοποίησής της,
- (ii) να αποσαφηνίσει τον ερευνητικό τομέα της προδιαγραφικής αναλυτικής,
- (iii) να αξιολογήσει τις υπάρχουσες εργασίες έτσι ώστε να αποκαλυφθούν οι υφιστάμενες ερευνητικές προκλήσεις,
- (iv) να παρέχει καθοδήγηση για την περαιτέρω έρευνα της παρούσας διδακτορικής διατριβής.

Η προδιαγραφική αναλυτική αποτελεί τον πιο εξελιγμένο τομέα της επιχειρηματικής αναλυτικής και μπορεί να προσφέρει την υψηλότερη δυνατή ευφυΐα και αξία στις επιχειρήσεις (Šikšnyš, και Pedersen, 2016). Σκοπός της προδιαγραφικής αναλυτικής είναι να προτείνει («προδιαγράψει») την καλύτερη απόφαση που πρέπει να ληφθεί προκειμένου να αξιοποιηθούν οι μελλοντικές προβλέψεις, χρησιμοποιώντας σύνολα δεδομένων μεγάλης κλίμακας (Šikšnyš, και Pedersen, 2016). Για την επίτευξη αυτού του σκοπού, η προδιαγραφική αναλυτική δεδομένων ενσωματώνει τα αποτελέσματα της προβλεπτικής αναλυτικής και αξιοποιεί αλγορίθμους από τους τομείς της τεχνητής νοημοσύνης, της βελτιστοποίησης και των συστημάτων εμπειρογνωμοσύνης (expert systems) σε ένα πιθανολογικό πλαίσιο, προκειμένου να παρέχει προσαρμόσιμες, αυτοματοποιημένες, περιοριζόμενες, βέλτιστες και χρονικά εξαρτώμενες αποφάσεις (Engel et al., 2012; Basu, 2013; Hagerty, 2017).

Η προδιαγραφική αναλυτική εμπεριέχει δύο επίπεδα αλληλεπίδρασης με τον άνθρωπο: την υποστήριξη της λήψης απόφασης μέσω της παραγωγής προτάσεων και την αυτοματοποίηση της λήψης απόφασης και της υλοποίησης των προτεινόμενων

ενεργειών (Hagerty, 2017). Η αποτελεσματικότητα των προδιαγραφών που παράγονται εξαρτάται από το κατά πόσο τα μοντέλα επιτυγχάνουν να ενσωματώσουν τα διαθέσιμα δομημένα και μη δομημένα δεδομένα, να αναπαραστήσουν το γνωστικό αντικείμενο και να αποτυπώσουν τις επιπτώσεις των εναλλακτικών αποφάσεων που εξετάζονται (Basu, 2013; Šikšnyš, και Pedersen, 2016).

Η Εικόνα 2-9 αποτυπώνει την επιχειρηματική αξία των τριών επιπέδων της επιχειρηματικής αναλυτικής ως προς τον χρόνο. Ξεκινώντας από την αριστερή πλευρά, η περιγραφική αναλυτική στοχεύει στο να αναγνωρίσει τι συμβαίνει την δεδομένη χρονική στιγμή. Αυτό επιτυγχάνεται μέσω της συλλογής και ανάλυσης παραμέτρων, σχετιζόμενων με τις αιτίες κάποιου μελλοντικού γεγονότος που επιθυμούμε να διαχειριστούμε κατάλληλα, είτε επιδιώκοντας είτε αποφεύγοντας την εκδήλωσή του. Με την περιγραφική αναλυτική δεδομένων καθίσταται δυνατός ο εντοπισμός προτύπων που προμηνύουν ένα πιθανό μελλοντικό επιχειρησιακό πρόβλημα ή κάποια μελλοντική ευκαιρία την οποία επιθυμεί η επιχείρηση να αξιοποιήσει.

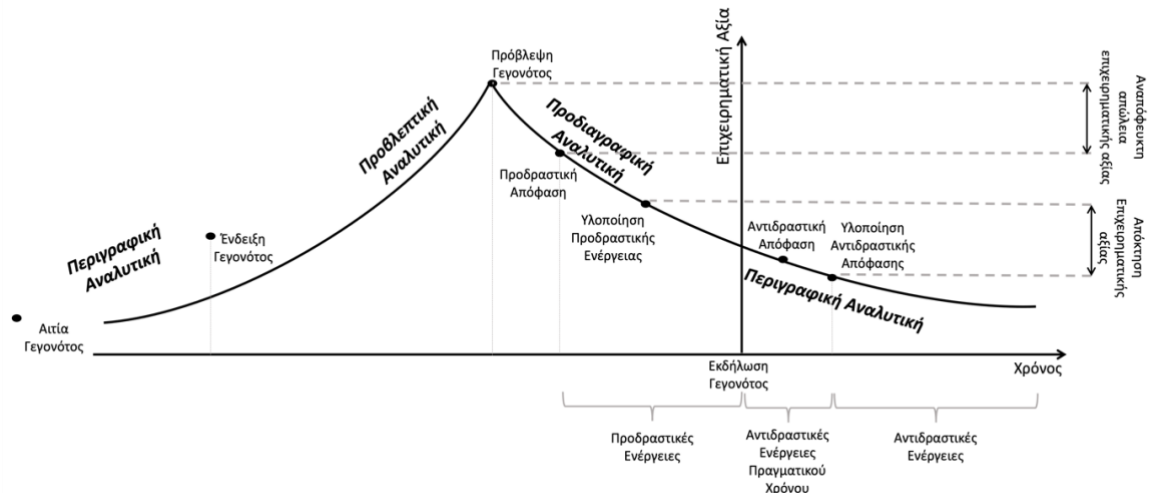
Χρησιμοποιώντας αυτά τα δεδομένα ως βάση, η προβλεπτική αναλυτική δεδομένων μπορεί να επιτρέψει στην επιχείρηση να προβλέψει αν ένα συγκεκριμένο γεγονός πρόκειται να συμβεί, τότε πρόκειται να συμβεί καθώς επίσης να εκτιμήσει και τους λόγους για τους οποίους είναι πιθανό να συμβεί. Όπως φαίνεται στην Εικόνα 2-9, τα αποτελέσματα της προβλεπτικής αναλυτικής προσφέρουν σημαντική επιχειρηματική αξία, η οποία είναι άμεσα εξαρτώμενη από τις αποφάσεις που θα ληφθούν και τις ενέργειες που θα εκτελεστούν βάσει των συγκεκριμένων αποτελεσμάτων. Κατά συνέπεια, στην περίπτωση που οι άνθρωποι καλούνται να λάβουν αυτές τις αποφάσεις, η προσφέρουσα επιχειρηματική αξία εξαρτάται από τις γνώσεις και την εμπειρία τους. Η προδιαγραφική αναλυτική αναλαμβάνει την παραγωγή προδραστικών αποφάσεων που βασίζονται στα αποτελέσματα της προβλεπτικής αναλυτικής. Ο συνδυασμός της προβλεπτικής με την προδιαγραφική αναλυτική οδηγεί στην πλήρη αξιοποίηση της προβλεπτικής αναλυτικής και στην βελτιστοποιημένη, έγκαιρη λήψη επιχειρηματικών αποφάσεων.

Στην πραγματικότητα, δεν είναι δυνατό να πετύχουμε τη μέγιστη δυνατή αξία της προβλεπτικής αναλυτικής μιας και ο χρόνος εξαγωγής των προβλεπτικών

αποτελεσμάτων μέχρι την λήψη της απόφασης είναι συνήθως περιορισμένος. Αυτό οδηγεί αναπόφευκτα στη μείωση της επιχειρηματικής αξίας μεταξύ της πρόβλεψης ενός γεγονότος και της λήψης της σχετικής προδραστικής απόφασης. Το μέγεθος του διαθέσιμου χρονικού διαστήματος ποικίλει καθώς εξαρτάται από το υπολογιστικό περιβάλλον και το γνωστικό πεδίο που αφορά η ανάλυση. Σε κάθε περίπτωση, η ελαχιστοποίηση αυτού του χρονικού διαστήματος είναι υψίστης σημασίας, προκειμένου οι βέλτιστες αποφάσεις να ληφθούν έγκαιρα και να διατηρηθεί η περισσότερη δυνατή προσφερόμενη επιχειρηματική αξία.

Ανάμεσα στην λήψη της απόφασης και στην υλοποίηση της προτεινόμενης ενέργειας, παρεμβάλλεται ένα απαιτούμενο για την προετοιμασία της ενέργειας χρονικό διάστημα. Επιπλέον, μία ενέργεια δύναται να παρέχει βέλτιστα αποτελέσματα εφόσον υλοποιηθεί σε συγκεκριμένη χρονική στιγμή πριν την εμφάνιση του προβλεπόμενου γεγονότος, στην οποία η αναμενόμενη παραγόμενη χρησιμότητα ή απώλεια θα είναι η βέλτιστη.

Τη στιγμή της εκδήλωσης του γεγονότος, η περιγραφική αναλυτική εφαρμόζεται προκειμένου να παρέχει χρήσιμες πληροφορίες αναφορικά με το γεγονός καθώς και τις αιτίες εκδήλωσής του. Σε αυτήν την περίπτωση, η περιγραφική αναλυτική ενδέχεται να αφορά τόσο ενέργειες πραγματικού χρόνου όσο και μακροχρόνιες ενέργειες. Για τον λόγο αυτό, η έγκαιρη αναγνώριση της παρούσας κατάστασης μιας επιχείρησης και η έγκαιρη πρόβλεψη ενός σημαντικού γεγονότος είναι κρίσιμες αναφορικά με την πιθανή απώλεια της επιχειρηματικής αξίας.



Εικόνα 2-9 Η επιχειρηματική αξία της αναλυτικής δεδομένων ως προς το χρόνο (προσαρμ. Krumeich et al., 2016)

2.2.2 Μεθοδολογία Ανασκόπησης

Στην παράγραφο αυτή, περιγράφεται η μεθοδολογία της συστηματικής βιβλιογραφικής ανασκόπησης, η οποία βασίζεται στην προτεινόμενη μεθοδολογία των Tranfield et al. (2003). Η συγκεκριμένη μεθοδολογία έχει χρησιμοποιηθεί ευρέως σε βιβλιογραφικές ανασκοπήσεις που ασχολούνται με τον τομέα της αναλυτικής δεδομένων μεγάλης κλίμακας, της επιχειρησιακής έρευνας και της διοικητικής επιστήμης (Howick, και Ackermann, 2011; Seifert, et al., 2013; Nguyen, et al., 2017; Barbosa, et al., 2018), ενώ ανάλογες μεθοδολογίες έχουν προταθεί σε αντίστοιχα γνωστικά πεδία (Duan, et al., 2019; Ismagilova, et al., 2019; Koivisto, και Hamari, 2019; Senyo, et al., 2019; Tamilmanni, et al., 2019).

Στην παρούσα βιβλιογραφική ανασκόπηση ερευνήθηκε η βιβλιογραφία χρησιμοποιώντας τον όρο αναζήτησης «prescriptive analytics». Αν και ο συγκεκριμένος όρος ήταν αρκετά γενικός, στην χρονική στιγμή διενέργειας της ανασκόπησης, ο περιορισμένος αριθμός σχετικών με την προδιαγραφική αναλυτική ερευνητικών αναφορών τον καθιστά επαρκή για την βιβλιογραφική ανασκόπηση που παρουσιάζεται σε αυτό το κεφάλαιο. Στην έρευνα συμπεριλήφθηκαν οι εξής επιστημονικές βάσεις: ACM, ArXiv, Emerald, IEEE, ScienceDirect και SpringerLink.

Το σύνολο αποτελεσμάτων περιορίστηκε έτσι ώστε να περιέχονται αναφορές αποκλειστικά προερχόμενες από επιστημονικά περιοδικά, εργασίες συνεδρίων και

βιβλία. Αναφορές όπως white papers και διαδικτυακά άρθρα απομακρύνθηκαν από τα αποτελέσματα, καθώς η ποιότητα του περιεχομένου τους μπορεί να επηρεάσει την εγκυρότητα των αποτελεσμάτων της παρούσας βιβλιογραφικής ανασκόπησης.

Τα βήματα της διαδικασίας που ακολουθήθηκε είναι τα εξής:

- 1. Επιλέχθηκαν οι επιστημονικές αναφορές** προς ανασκόπηση που ικανοποιούν τα κριτήρια της βιβλιογραφικής μελέτης που παρουσιάζονται στην παρούσα παράγραφο. Μιας και εξ' ορισμού η προδιαγραφική αναλυτική λαμβάνει ως είσοδο τα αποτελέσματα αλγορίθμων προβλεπτικής αναλυτικής, η πλειοψηφία των εργασιών εμπειρείχαν επίσης μεθόδους προβλεπτικής αναλυτικής.
- 2. Για το λόγο αυτό, οι μέθοδοι που προτείνονται για την προβλεπτική αναλυτική διαχωρίστηκαν από τις μεθόδους που προτείνονται για προδιαγραφική αναλυτικής σε κάθε μια από τις επιλεγμένες επιστημονικές αναφορές.**
- 3. Οι προτεινόμενες μέθοδοι προβλεπτικής αναλυτικής και προδιαγραφικής αναλυτικής κατηγοριοποιήθηκαν σε 7 κατηγορίες:** Πιθανολογικά Μοντέλα (Probabilistic Models), Μηχανική Μάθηση/Εξόρυξη Δεδομένων (Machine Learning / Data Mining), Στατιστική Ανάλυση (Statistical Analysis), Μαθηματικός Προγραμματισμός (Mathematical Programming), Εξελικτική Υπολογιστική (Evolutionary Computation), Προσομοίωση (Simulation), Μοντέλα Λογικής (Logic-based Models).
- 4. Ακολούθησε η αναγνώριση των μεθόδων και των συνδυασμών τους** που ανευρίσκονται στη βιβλιογραφία για την προβλεπτική και την προδιαγραφική αναλυτική, καθώς οι περισσότερες από τις επιλεγμένες εργασίες αξιοποιούν συνδυασμούς μεθόδων. Από αυτές, η ανασκόπηση επικεντρώνεται στις μεθόδους που προτείνονται για την υλοποίηση της προδιαγραφικής αναλυτικής.
- 5. Εν συνεχεία, σε μια προσπάθεια να αναγνωριστούν τα πεδία που έχουν συγκεντρώσει το μεγαλύτερο και το μικρότερο ενδιαφέρον ως προς την προδιαγραφική αναλυτική, καθώς και τις μεθόδους που έχουν χρησιμοποιηθεί σε καθένα από αυτά, οι επιλεγμένες επιστημονικές**

αναφορές κατηγοριοποιούνται ανάλογα με το επιστημονικό πεδίο στο οποίο αναφέρονται.

6. Για κάθε κατηγορία μεθόδων και τους αντίστοιχους συνδυασμούς παρουσιάζεται αναλυτική συζήτηση για το πως έχουν χρησιμοποιηθεί στο πλαίσιο της προδιαγραφικής αναλυτικής σε κάθε επιστημονική αναφορά, το πρόβλημα το οποίο επιχειρούν να λύσουν καθώς και την βασική συνεισφορά της εργασίας. Επιπλέον, διακρίνονται οι πολλά υποσχόμενες μεθόδους από τις προσεγγίσεις.
7. Η βιβλιογραφική ανασκόπηση καταλήγει σε μια σύνθεση στην οποία παρουσιάζεται μια συζήτηση των ερευνητικών προκλήσεων, ενώ παρέχονται και πιθανές μελλοντικές ερευνητικές κατευθύνσεις.

Το πρωτόκολλο επιλογής των αναφορών που συμπεριλαμβάνονται στην παρούσα μελέτη ολοκληρώθηκε σε τρεις φάσεις, προκειμένου να απομονωθούν οι σχετικές αναφορές. Ο αριθμός των αναφορών κάθε επιπέδου παρουσιάζεται ανά επιστημονική βάση αναφορών στον Πίνακα 2-1.

Στην πρώτη φάση, αναζητήθηκαν οι επιλεγμένες επιστημονικές βάσεις για αναφορές που περιέχουν τον όρο αναζήτησης στην πλήρη εγγραφή της αναφοράς, συμπεριλαμβανομένου του πλήρους κειμένου της δημοσίευσης, χωρίς κάποιον επιπλέον περιορισμό. Η πρώτη φάση της έρευνας οδήγησε σε 917 αναφορές. Σε αυτήν την αναζήτηση, εντοπίστηκε μία σχεδόν εκθετική αύξηση του όρου «prescriptive analytics» τα τελευταία έτη. Η τάση αυτή αντικατοπτρίζει το αυξανόμενο ερευνητικό ενδιαφέρον για την προδιαγραφική αναλυτική και ενισχύει την ανάγκη για την παρούσα βιβλιογραφική ανασκόπηση.

Πηγή	Αριθμός αναφορών		
	Πρώτη φάση	Δεύτερη φάση	Τρίτη φάση
<i>ACM</i>	15	11	6
<i>ArXiv</i>	5	5	4
<i>Emerald</i>	42	1	0

<i>IEEE</i>	260	40	17
<i>ScienceDirect</i>	186	23	8
<i>SpringerLink</i>	409	20	21
<i>Σύνολο</i>	917	99	56

Πίνακας 2-1 Αριθμός επιστημονικών αναφορών

Μιας και η πρώτη φάση της αναζήτησης εμπειρείχε εργασίες οι οποίες δεν συνεισφέρουν απαραίτητως στο πεδίο της προδιαγραφικής αναλυτικής, διεξήχθη μια δεύτερη φάση προκειμένου να εντοπιστούν εργασίες οι οποίες περιέχουν τον όρο αναζήτησης στα μεταδεδομένα (metadata) της εγγραφής, και πιο συγκεκριμένα στον τίτλο, την περίληψη, τις λέξεις-κλειδιά της εγγραφής της εργασίας στην επιστημονική βάση. Η αναζήτηση αυτή απέφερε 99 εργασίες, όπως φαίνεται στον Πίνακα 2-1.

Ομοίως με την πρώτη φάση, στα αποτελέσματα της δεύτερης φάσης συμμετείχαν εργασίες οι οποίες δεν συνεισφέρουν στον τομέα της προδιαγραφικής αναλυτικής αλλά αναφέρουν τον όρο σε εισαγωγικά κείμενα. Αυτό οδήγησε στην τρίτη φάση της αναζήτησης κατά την οποία οι επιλεγμένες αναφορές αναλύθηκαν και απομονώθηκαν εκείνες οι οποίες ικανοποιούσαν τρία κριτήρια:

- (i) Η εργασία συνεισφέρει στο πεδίο της προδιαγραφικής αναλυτικής
- (ii) Η δημοσίευση έγινε στο χρονικό διάστημα μεταξύ 01/2010 και 01/2019
- (iii) Η δημοσίευση αφορά επιστημονικό περιοδικό, βιβλίο ή δημοσίευση συνεδρίου

Η Τρίτη φάση οδήγησε σε 56 εργασίες εκ των οποίων οι 19 αποτελούν δημοσιεύσεις σε επιστημονικά περιοδικά, 36 δημοσιεύσεις σε συνέδρια και 1 κεφάλαιο βιβλίου.

Η κατανομή του αριθμού εργασιών ανά έτος δημοσίευσης παρουσιάζεται στον Πίνακα 2-2, όπου το αυξανόμενο ερευνητικό ενδιαφέρον για την προδιαγραφική αναλυτική είναι εμφανές. Τα αποτελέσματα της τρίτης φάσης δεν περιορίστηκαν σε συγκεκριμένα περιοδικά ή συνέδρια, ενώ οι επιλεγμένες εργασίες αναφέρονται σε διαφορετικά ερευνητικά πεδία.

Year	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019
Papers	1	0	0	2	8	7	9	12	15	2

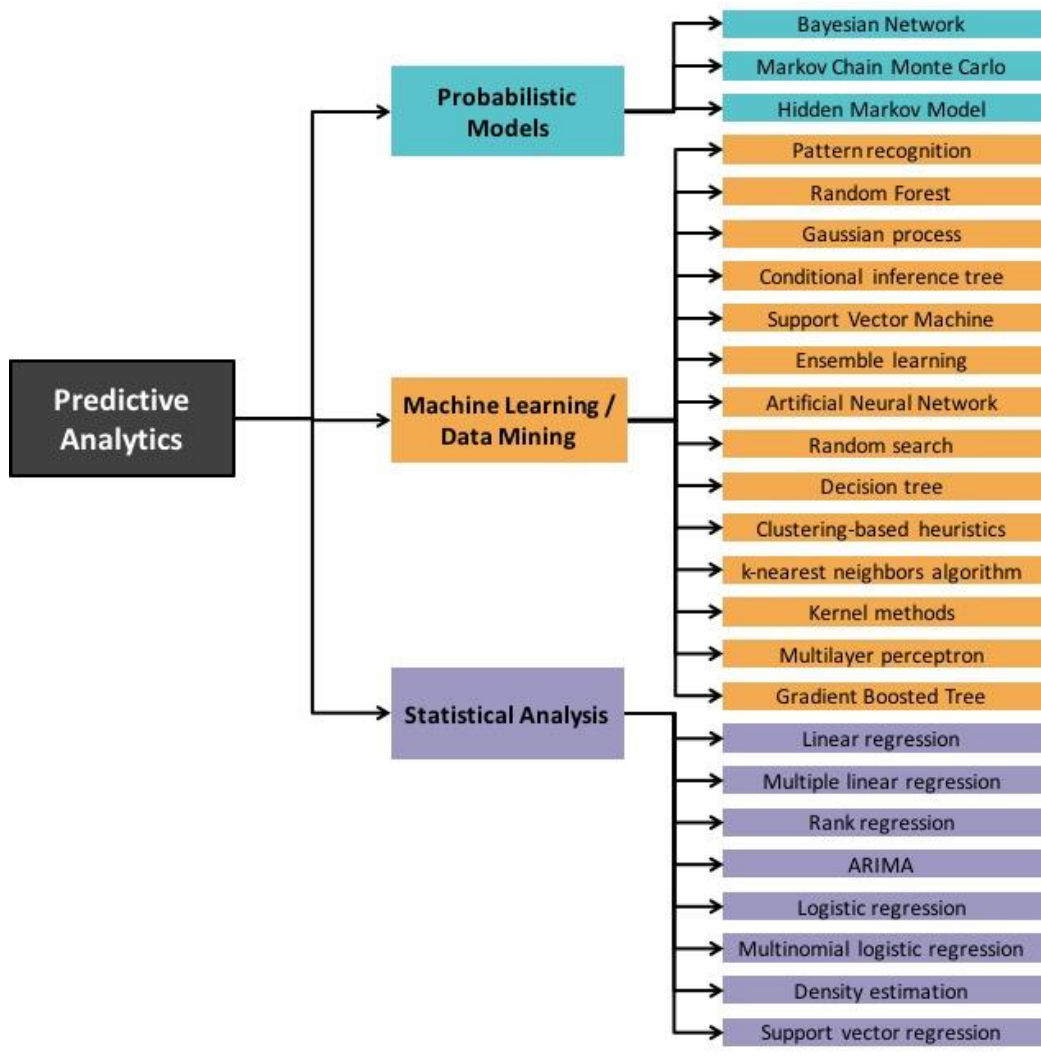
Πίνακας 2-2 Κατανομή αναφορών ανά έτος

2.2.3 Ανάλυση και Συζήτηση

2.2.3.1 Ταξινόμηση μεθόδων

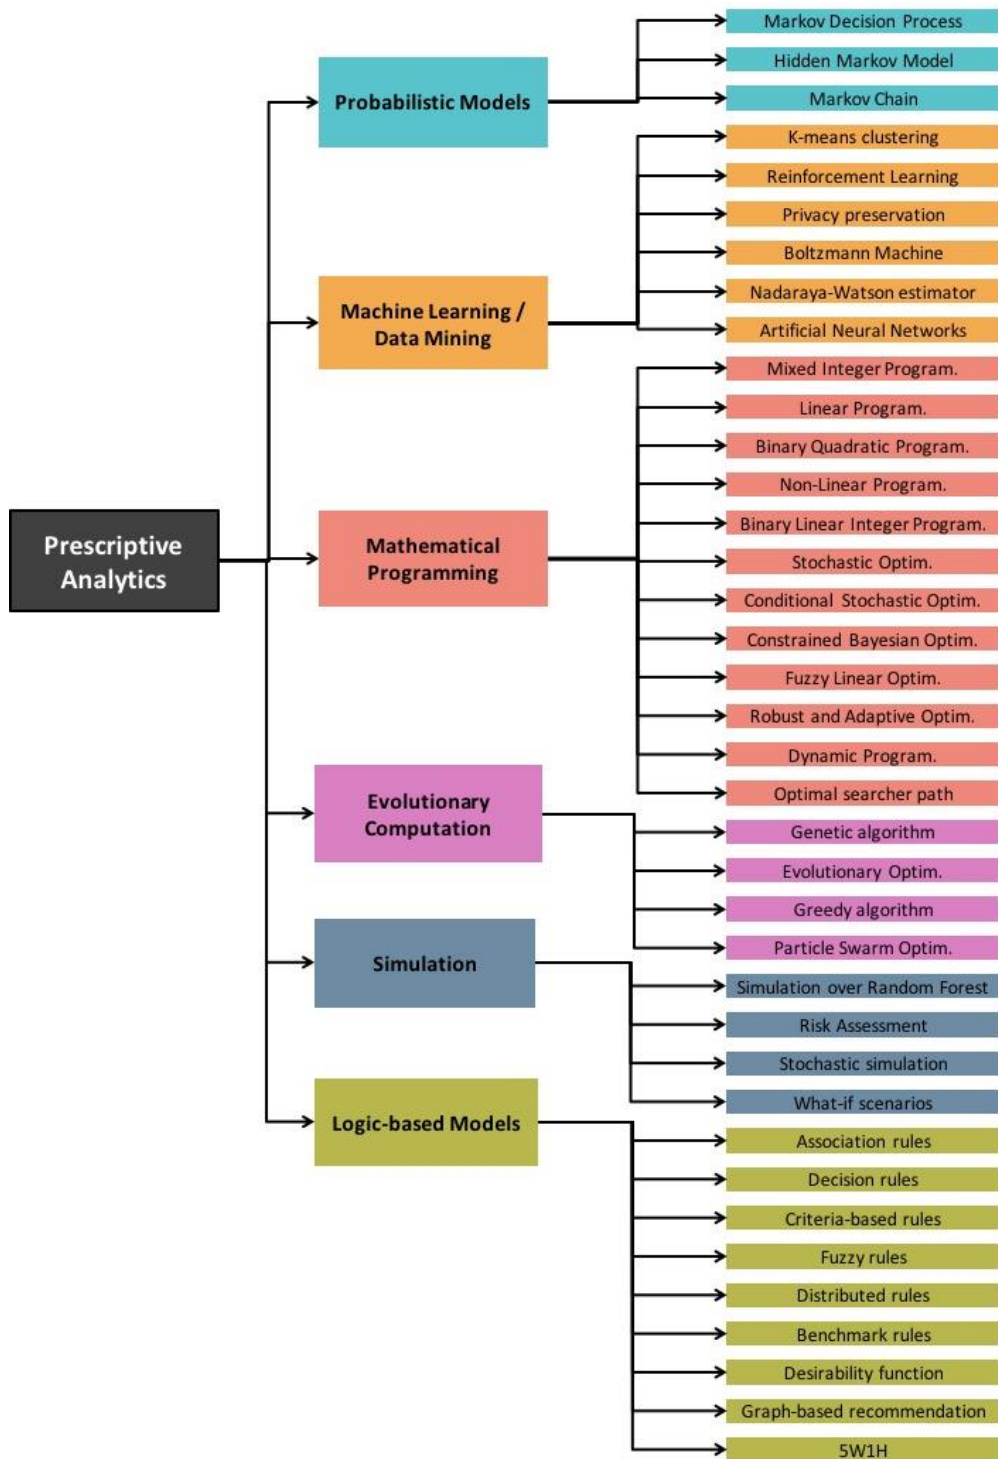
Όπως αναφέρθηκε στην προηγούμενη παράγραφο, η προδιαγραφική αναλυτική βασίζεται στα παραγόμενα αποτελέσματα της προβλεπτικής αναλυτικής. Για το λόγο αυτό, η πλειοψηφία των αναφορών που εξετάστηκαν προτείνει τόσο μεθόδους προβλεπτικής όσο και μεθόδους προδιαγραφικής αναλυτικής, με στόχο να παρέχει την απαιτούμενη είσοδο για την προδιαγραφική αναλυτική. Σε αυτήν την παράγραφο, παρουσιάζονται οι μέθοδοι που προτείνονται από τις επιλεγμένες βιβλιογραφικές αναφορές για τους δύο τύπους αναλυτικής δεδομένων.

Στην Εικόνα 2-10 παρουσιάζεται η ταξινόμηση των μεθόδων προβλεπτικής αναλυτικής της επιλεγμένης βιβλιογραφίας. Οι μέθοδοι αυτές έχουν ταξινομηθεί σε τρεις κατηγορίες: Πιθανολογικά Μοντέλα, Μηχανική Μάθηση/Εξόρυξη Δεδομένων και Στατιστική Ανάλυση.



Εικόνα 2-10 Ταξινόμηση μεθόδων προβλεπτικής αναλυτικής δεδομένων

Στην Εικόνα 2-11 απεικονίζεται η ταξινόμηση των μεθόδων προδιαγραφικής αναλυτικής οι οποίες έχουν αναγνωρισθεί από τις επιλεγμένες αναφορές και έχουν ταξινομηθεί σε έξι κατηγορίες: Πιθανολογικά Μοντέλα, Μηχανική Μάθηση/Εξόρυξη Δεδομένων, Μαθηματικός Προγραμματισμός, Εξελικτική Υπολογιστική, Προσομοίωση και Μοντέλα Λογικής.



Εικόνα 2-11 Ταξινόμηση μεθόδων προδιαγραφικής αναλυτικής δεδομένων

2.2.3.1.1 Πιθανολογικά Μοντέλα

Ένα πιθανολογικό μοντέλο ποσοτικοποιεί την αβεβαιότητα, με σκοπό να αποτυπώσει την δυναμική σε μια κατανομή πάνω στις προβλέψεις του μοντέλου για

τις μεταβάσεις κατάστασης ανάμεσα σε δείγματα προερχόμενα από παρτίδες δεδομένων (Martinez et al., 2009; Martinez et al., 2013). Με αυτήν τη λογική, σε αυτήν την κατηγορία εντάσσονται μοντέλα που αναπαριστούν τις αβέβαιες σχέσεις αιτίου-αιτιατού, όπως για παράδειγμα τις σχέσεις μεταξύ αιτίου και αποτελέσματος. Στην προβλεπτική και προδιαγραφική αναλυτική, τα πιθανολογικά μοντέλα χρησιμοποιούνται για τον υπολογισμό της πιθανότητας εκδήλωσης συγκεκριμένων γεγονότων. Έτσι, αντικαθιστούν την ανάγκη παρακολούθησης των πραγματικών δεδομένων προς αναζήτηση των γεγονότων καθώς και δεδομένων που συμμορφώνονται με ένα σύνολο κανόνων καθορισμένων από την ανάλυση ιστορικών δεδομένων.

2.2.3.1.2 Μηχανική Μάθηση

Η μηχανική μάθηση αναφέρεται σε αλγορίθμους οι οποίοι βασίζονται σε μοντέλα και συμπερασματολογία εξαγόμενη από την επεξεργασία δεδομένων χωρίς τη χρήση ρητών οδηγιών (Nasrabadi, 2007). Οι αλγόριθμοι μηχανικής μάθησης κατασκευάζουν ένα μαθηματικό μοντέλο που περιγράφει το δείγμα δεδομένων, το οποίο καλείται «σύνολο δεδομένων εκπαίδευσης» (training data). Το μοντέλο αυτό είναι ικανό να παράγει προβλέψεις ή αποφάσεις χωρίς να έχει ρητά προγραμματιστεί να εκτελεί την συγκεκριμένη ενέργεια. Η μηχανική μάθηση θεωρείται υποσύνολο της τεχνητής νοημοσύνης.

Ως εξόρυξη δεδομένων ορίζεται η διαδικασία ανακάλυψης προτύπων μέσα από μεγάλα σύνολα δεδομένων με στόχο να εξαχθεί πληροφορία και να μετασχηματιστεί σε μια κατανοητή δομή, κατάλληλη για περαιτέρω χρήση (Chakrabarti et al., 2006; John, 2010). Η μηχανική μάθηση περιλαμβάνει εργασίες ανάλυσης, βάσεων δεδομένων, διαχείρισης και προ-επεξεργασίας δεδομένων, μελέτες μοντέλων και συμπερασμού, μετρικές ενδιαφέροντος, θέματα πολυπλοκότητας, μετα-επεξεργασίας των ανακαλυφθέντων δομών, οπτικοποίησης και συνεχούς ενημέρωσης (Chakrabarti et al., 2006). Μιας και η μηχανική μάθηση και η εξόρυξη δεδομένων αποτελούν στενά συσχετιζόμενες έννοιες (Chakrabarti et al., 2006), οι αντίστοιχες ανευρεθείσες μέθοδοι εντάσσονται σε μία κοινή κατηγορία. Ουσιαστικά, χρησιμοποιώντας μεθόδους μηχανικής μάθησης και εξόρυξης δεδομένων, μπορούν

να κατασκευαστούν αλγόριθμοι που θα χρησιμοποιηθούν για την εξαγωγή χρήσιμης και μη άμεσα διαθέσιμης πληροφορίας από τα αρχικά δεδομένα.

Στην προβλεπτική αναλυτική, οι μέθοδοι αυτής της κατηγορίας χρησιμοποιούνται για την εξαγωγή πληροφοριών οι οποίες μπορούν να προβλέψουν ένα μελλοντικό γεγονός ή αποτέλεσμα, αξιοποιώντας ιστορικά δεδομένα και πρότυπα. Στην προδιαγραφική αναλυτική, αξιοποιούνται για την αναζήτηση της απόφασης που σχετίζεται με την βέλτιστη ενέργεια που μπορεί να εκτελεστεί σε μία συγκεκριμένη κατάσταση.

2.2.3.1.3 Στατιστική Ανάλυση

Η στατιστική ανάλυση αποτελεί το πεδίο της επιστήμης των μαθηματικών το οποίο ασχολείται με την συλλογή, την οργάνωση, την ανάλυση, την επεξήγηση και την παρουσίαση των δεδομένων (Dodge, 2006; Romijn, 2014). Η στατιστική ανάλυση ασχολείται με όλες τις πλευρές των δεδομένων, συμπεριλαμβάνοντας την σχεδίαση της συλλογής δεδομένων με τη μορφή σχεδίασης ερευνών (survey) και πειραματικών μελετών, και επιλύει προβλήματα συσχετιζόμενα με έναν στατιστικό πληθυσμό ή τη διαδικασία ενός στατιστικού μοντέλου (Romijn, 2014). Στην προβλεπτική αναλυτική, η στατιστική ανάλυση χρησιμοποιείται για την εξαγωγή πληροφορίας από τα δεδομένα με τη μορφή πρόβλεψης τάσης ή συμπεριφορικών προτύπων.

2.2.3.1.4 Μαθηματικός Προγραμματισμός

Ο μαθηματικός προγραμματισμός ασχολείται με την βέλτιστη κατανομή των πεπερασμένων πόρων ανάμεσα σε ανταγωνιστικές δραστηριότητες, υπό τον έλεγχο ενός συνόλου περιορισμών επιβεβλημένων από τη φύση του υπό εξέταση προβλήματος. Με την ευρύτερη έννοια, ο μαθηματικός προγραμματισμός μπορεί να οριστεί ως η μαθηματική αναπαράσταση που στοχεύει στον προγραμματισμό ή την σχεδίαση της βέλτιστης δυνατής κατανομής λιγοστών πόρων. Θεωρείται ένας τομέας των μαθηματικών, της διοικητικής επιστήμης και της επιχειρησιακής έρευνας που συμβάλλει στην λήψη καλύτερων αποφάσεων οδηγώντας σε βελτιωμένες ή σχεδόν βέλτιστες λύσεις σε πολύπλοκα προβλήματα απόφασης (Chong, και Zak, 2008).

2.2.3.1.5 Εξελικτική Υπολογιστική

Στην επιστήμη των υπολογιστών η εξελικτική υπολογιστική αποτελεί μια οικογένεια αλγορίθμων οι οποίοι είναι εμπνευσμένοι από την βιολογική εξέλιξη και επιλύουν το πρόβλημα της ολικής βελτιστοποίησης (global optimization) (Bäck et al., 1997). Οι εξελικτικοί αλγόριθμοι βασίζονται στην έννοια του πληθυσμού και την εμπειρική μέθοδο (trial and error) και προσομοιάζουν μεταερευτικές (metaheuristics) και μεθόδους στοχαστικής βελτιστοποίησης. Αρχικά παράγεται ένα σύνολο από υποψήφιες λύσεις (πληθυσμός) το οποίο ενημερώνεται, επαναληπτικά. Με κάθε ενημέρωση, το αρχικό σύνολο λύσεων εξελίσσεται, με μικρές τυχαίες αλλαγές (μεταλλάξεις). Στόχος των μεταλλάξεων είναι να παραχθεί μία νέα γενιά (generation) η οποία θα αποτελείται από τις επικρατούσες λύσεις του προβλήματος. Στο πλαίσιο της προδιαγραφικής αναλυτικής δεδομένων, η εξελικτική υπολογιστική χρησιμοποιείται για την επίλυση πολύπλοκων προβλημάτων απόφασης σε περιβάλλοντα πλούσια σε δεδομένα, όπου οι ακριβείς βέλτιστες λύσεις δεν είναι δυνατόν να απομονωθούν.

2.2.3.1.6 Προσομοίωση

Η προσομοίωση αναφέρεται στη διαδικασία μοντελοποίησης ενός υπάρχοντος ή υποθετικού συστήματος σε έναν υπολογιστή, που επιτρέπει τη μελέτη του τρόπου λειτουργίας του συστήματος (Jerry, 2005). Μεταβάλλοντας τις παραμέτρους των μαθηματικών μοντέλων και αξιοποιώντας τη γνώση του ειδικού, είναι δυνατή η παραγωγή προβλέψεων σχετικά με την συμπεριφορά του συστήματος και η υποστήριξη των αποφάσεων που πρέπει να ληφθούν. Στην προδιαγραφική αναλυτική, η προσομοίωση χρησιμοποιείται προκειμένου να βελτιώσει την αποτελεσματικότητα των αποφάσεων που λαμβάνουν οι άνθρωποι ή οι εφαρμογές λογικής. Για το λόγο αυτό, η προσομοίωση αποδεικνύεται χρήσιμη καθώς μπορεί να χρησιμοποιηθεί για την δοκιμή νέων ιδεών που σχετίζονται με επιχειρηματικές αποφάσεις και ενέργειες που μπορούν να μειώσουν το ρίσκο που παρουσιάζει ένα σύστημα ή μια διαδικασία. Επιπροσθέτως, μπορεί να χρησιμοποιηθεί για την αξιολόγηση των αποτελεσμάτων που θα έχουν νέες μεταβολές σε υπάρχουσες διαδικασίες και συστήματα. Η προσομοίωση παρουσιάζεται σε εργασίες

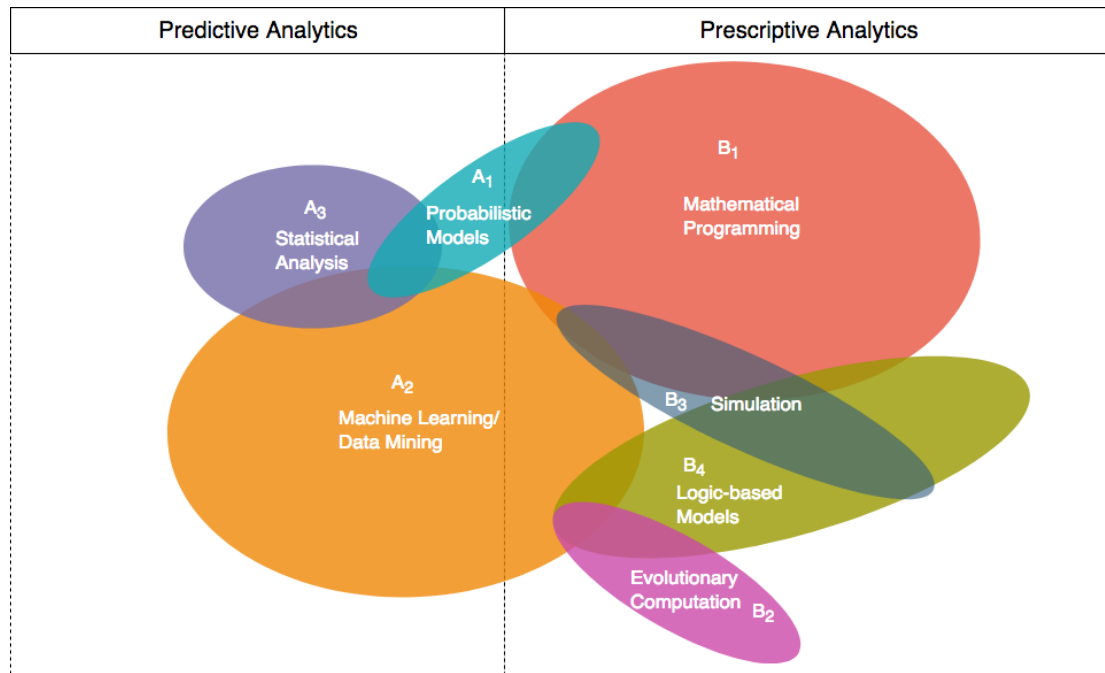
προδιαγραφικής αναλυτικής οι οποίες ασχολούνται με την ασφάλεια υποδομών, την ποιότητα και τη σχεδίαση προϊόντων.

2.2.3.1.7 Μοντέλα Λογικής

Τα μοντέλα λογικής είναι υποθετικές περιγραφές της αλυσίδας αίτιου και αιτιατού οι οποίες οδηγούν σε ένα ζητούμενο αποτέλεσμα. Στο πλαίσιο των πληροφοριακών συστημάτων, τα μοντέλα λογικής περιλαμβάνουν συστήματα κανόνων και αναπαραστάσεις εξειδικευμένης γνώσης, με σκοπό την υποστήριξη της λήψης αποφάσεων.

Οι περισσότερες από τις επιλεγμένες προς μελέτη εργασίες αξιοποιούν κάποιο συνδυασμό μεθόδων προκειμένου να παράγουν μία λύση για το υπό εξέταση πρόβλημα. Ταυτόχρονα, οι ίδιες μέθοδοι αξιοποιούνται για την επίλυση διαφορετικών ερευνητικών προκλήσεων. Η Εικόνα 2-12 παρουσιάζει το διάγραμμα Venh στο οποίο αποτυπώνονται οι κατηγορίες μεθόδων και οι ανευρεθέντες συνδυασμοί τους αναφορικά με την προβλεπτική και προδιαγραφική αναλυτική, όπως εντοπίζονται στις επιλεγμένες αναφορές.

Το διάγραμμα διαχωρίζεται σε δύο επιμέρους περιοχές για τις μεθόδους της προβλεπτικής και για της μεθόδους της προδιαγραφικής αναλυτικής δεδομένων. Κάθε στοιχείο του διαγράμματος αντιστοιχεί σε μία από τις κατηγορίες μεθόδων, ενώ το μέγεθος του στοιχείου αναπαριστά τον αριθμό των σχετικών εργασιών που βασίζονται στις συγκεκριμένες μεθόδους. Οι τομές των γραφικών στοιχείων του διαγράμματος αποτυπώνουν τους συνδυασμούς των κατηγοριών που αναφέρονται στη βιβλιογραφία.



Εικόνα 2-12 Διάγραμμα Venn μεθόδων βιβλιογραφίας

Ο Πίνακας 2-3 και ο Πίνακας 2-4 παρουσιάζουν αναλυτικά τις βιβλιογραφικές αναφορές που αντιστοιχούν σε κάθε γραφικό στοιχείο του διαγράμματος της Εικόνα 2-12 ως προς την προβλεπτική και την προδιαγραφική αναλυτική αντιστοίχως.

Προβλεπτική Αναλυτική Δεδομένων			
	Κατηγορία Μεθόδων	Αναφορές	Σύνολο
A1	Πιθανολογικά Μοντέλα	Ayhan et al., 2018	1
A2	Μηχανική Μάθηση/Εξόρυξη Δεδομένων	Kawas et al., 2013; Gröger et al., 2014; Mendes et al., 2014; Bertsimas και Kallus, 2014; Lo, και Pachamanova, 2015; Aref et al., 2015; von Bischhoffshausen et al., 2015; Christ et al., 2016; Bertsimas, και Van Parys, 2017; de Aguiar et al., 2017; Schwartz et al., 2017; Ito, και Fujimaki, 2017; Anderson, 2017; Giurgiu et al., 2017; Stein et al., 2018; Thammaboosadee, και Wongpitak, 2018; Dey et al., 2019; Harikumar et al., 2018b; Laude, 2018; Srinivas, και Ravindran, 2018; Huang et al., 2018; Jank et al., 2018	22

A3	Στατιστική Ανάλυση	Baur et al., 2014; Ceravolo και Zavatarelli, 2015; Du et al., 2016; Matyas et al., 2017	4
A2 ∩A 3	Μηχανική Μάθηση/Εξόρυξη Δεδομένων AND Στατιστική Ανάλυση	Goyal et al., 2016; Hupfeld et al., 2016	2
A1 ∩A 3	Πιθανολογικά Μοντέλα AND Στατιστική Ανάλυση	Shroff et al., 2014	1
A1 ∩A 2∩ A3	Πιθανολογικά Μοντέλα AND Μηχανική Μάθηση/Εξόρυξη Δεδομένων AND Στατιστική Ανάλυση	Wang et al., 2018	1

Πίνακας 2-3 Ταξινόμηση αναφορών σύμφωνα με τις μεθόδους προβλεπτικής αναλυτικής δεδομένων

Προδιαγραφική Αναλυτική Δεδομένων			
	Κατηγορίες Μεθόδων	Αναφορές	Σύνολο
A1	Πιθανολογικά Μοντέλα	-	0
A2	Μηχανική Μάθηση/Εξόρυξη	Revathy, και Mukesh, 2018	1
B1	Μαθηματικός Προγραμματισμός	Kawas et al., 2013; Baur et al., 2014; Bertsimas και Kallus, 2014; Chalamalla et al., 2014; Lo, και Pachamanova, 2015; Aref et al., 2015; von Bischhoffshausen et al., 2015; Goyal et al., 2016; Wu, και Yang, 2017; Ghoniem et al., 2017; Ito, και Fujimaki, 2017; Bertsimas, και Van Parys, 2017; Harikumar et al., 2018a; Harikumar et al., 2018b; Huang et al., 2018; Berk et al., 2018; Dey et al., 2019	17
B2	Εξελικτική Υπολογιστική	Dey et al., 2019	1
B3	Προσομοίωση	Giurgiu et al., 2017; Wang et al., 2018; Jank et al., 2018	3

B4	Μοντέλα Λογικής	Song et al., 2013; Gröger et al., 2014; Song et al., 2014; Lee et al., 2014; Cho et al., 2015; Ceravolo και Zavatarelli, 2015; Du et al., 2016; Matyas et al., 2017; Ramannavar και Sidnal, 2018; Du et al., 2018; Srinivas, και Ravindran, 2018	11
A1 \cap B 1	Πιθανολογικά Μοντέλα AND Μαθηματικός Προγραμματισμός	Jiang et al., 2010; Ayhan et al., 2018	2
A2 \cap B 4	Μηχανική Μάθηση/Εξόρυξη AND Μοντέλα Λογικής	Gröger et al. 2014; Mendes et al. 2014	2
A2 \cap B 2	Μηχανική Μάθηση/Εξόρυξη AND Εξελικτική Υπολογιστική	Thammaboosadee και Wongpitak, 2018	1
B1 \cap B 3	Μαθηματικός Προγραμματισμός AND Προσομοίωση	Hupfeld et al., 2016; Stein et al., 2018	2
B3 \cap B 4	Προσομοίωση AND Μοντέλα Λογικής	Srinivas, και Ravindran, 2018	1
A2 \cap B 2 \cap B4	Μηχανική Μάθηση/Εξόρυξη AND Εξελικτική Υπολογιστική AND Μοντέλα Λογικής	Laude, 2018	1
A2 \cap B 1 \cap B4	Μαθηματικός Προγραμματισμός AND Μηχανική Μάθηση/Εξόρυξη AND Μοντέλα Λογικής	Ghosh et al., 2016	1
A2 \cap B	Μηχανική Μάθηση/Εξόρυξη AND Μαθηματικός	Shroff et al., 2014	1

1∩ B3	Προγραμματισμός Προσομοίωση	AND	
----------	--------------------------------	------------	--

Πίνακας 2-4 Ταξινόμηση αναφορών σύμφωνα με τις μεθόδους προδιαγραφικής αναλυτικής δεδομένων

Επιπλέον, στον Πίνακα 2-5 συγκεντρώνονται οι βιβλιογραφικές αναφορές ανά κατηγορία μεθόδων και πεδίο εφαρμογής.

Πεδίο Εφαρμογής	Σύνολο	Κατηγορίες	Αναφορές
Βιομηχανική Παραγωγή	12	B1	Goyal et al., 2016, Anderson, 2017
		B2	Dey et al., 2019
		B4	Gröger et al., 2014; Ceravolo και Zavatarelli, 2015; Matyas et al., 2017
		A2∩B2	Thammaboosadee και Wongpitak, 2018
		B1∩B3	Krumeich et al., 2016; Brodsky et al., 2017; Stein et al., 2018
		B1∩B4	Ringsquandl et al., 2016
		A2∩B1∩B3	Shroff et al., 2014
Πωλήσεις/Marketing	14	B1	Kawas et al., 2013; Baur et al., 2014; Bertsimas and Kallus, 2014; Lo και Pachamanova, 2015; Hong et al., 2015; Aref et al., 2015; von Bischoffshausen et al., 2015; Ito και Fujimaki, 2017; Bertsimas, και Van Parys, 2017; Huang et al., 2018
		B3	Jank et al., 2018
		B4	Du et al., 2018
		B1∩B3	Hupfeld et al., 2016
		A2∩B1∩B3	Shroff et al., 2014
Εκπαίδευση/Ερευνα	7	B1	Harikumar et al., 2018a

		B4	Song et al., 2013; Song et al., 2014; Lee et al., 2014; Cho et al., 2015; Du et al., 2016
Υγεία/Κοινωνική Πολιτική	6	A2	Schwartz et al., 2017
		B1	Harikumar et al., 2018a; Harikumar et al., 2018b
		B4	Srinivas, και Ravindran, 2018
		A2∩B4	de Aguiar et al., 2017; Osmani et al., 2017
Ανθρώπινο Δυναμικό	3	B1	Berk et al., 2018
		B4	Ramannavar και Sidnal, 2018
		A1∩B1	Jiang et al., 2010
Μεταφορές	3	B1	Wu and Yang, 2017; Achenbach, και Spinler, 2018
		A1∩B1	Ayhan et al., 2018
Επιχειρηματική Στρατηγική	3	B3	Wang et al., 2018
		B4	Ghosh et al., 2016
Μηχανική Δεδομένων/Πληροφορικά Συστήματα	3	A2	Revathy, και Mukesh, 2018
		B1	Chalamalla et al., 2014
		B3	Giurgiu et al., 2017
Σχεδίαση Χωρητικότητας	1	B1	Ghoniem et al., 2017
Μέσα Κοινωνικής Δικτύωσης	1	B4	Mendes et al., 2014
Γεωργία	1	A2∩B2∩ B4	Laude, 2018

Πίνακας 2-5 Ταξινόμηση αναφορών ανά πεδίο εφαρμογής προδιαγραφικής αναλυτικής δεδομένων

2.2.3.2 Ανάλυση Εργασιών και Συζήτηση

Σε αυτήν την παράγραφο, αναπτύσσονται αναλυτικά οι μέθοδοι που εντοπίστηκαν στη βιβλιογραφική μελέτη της παρούσας διδακτορικής διατριβής, με έμφαση στις μεθόδους της προδιαγραφικής αναλυτικής.

2.2.3.2.1 Μαθηματικός Προγραμματισμός

Όπως παρουσιάζεται στην Εικόνα 2-12 και στον Πίνακα 2-4, ο μαθηματικός προγραμματισμός έχει χρησιμοποιηθεί εντατικά στο πλαίσιο της προδιαγραφικής αναλυτικής. Η πλειοψηφία των επιλεγμένων εργασιών προτείνουν μεθόδους και αλγορίθμους βελτιστοποίησης. Οι μέθοδοι βελτιστοποίησης έχουν κερδίσει το ερευνητικό ενδιαφέρον στον τομέα της προδιαγραφικής αναλυτικής όπου χρησιμοποιούνται προκειμένου να προτείνουν τις βέλτιστες λύσεις ως προς κάποιο κριτήριο βελτιστοποίησης. Στις περισσότερες αναφορές, το κριτήριο βελτιστοποίησης αναπαριστά το επιχειρησιακό κόστος, το οποίο ζητείται να ελαχιστοποιηθεί (Achenbach, και Spinler, 2018).

Από τους επιμέρους τομείς του μαθηματικού προγραμματισμού, ο **γραμμικός προγραμματισμός** (linear programming) και οι επεκτάσεις του εμφανίζονται ως οι πιο δημοφιλείς μέθοδοι βελτιστοποίησης στην προδιαγραφική αναλυτική. Ο γραμμικός προγραμματισμός είναι μία τεχνική βελτιστοποίησης που βασίζεται σε μία γραμμική συνάρτηση βελτιστοποίησης (objective function), η οποία υπόκειται σε γραμμικούς και μη-γραμμικούς περιορισμούς (Sierksma, και Zwols, 2015). Ειδικότερα, ο γραμμικός ακέραιος προγραμματισμός (linear integer programming) έχει χρησιμοποιηθεί στην προδιαγραφική αναλυτική για την εύρεση ενός εφικτού συνδυασμού περιβαλλοντικών εναλλακτικών που ελαχιστοποιεί τις εκπομπές των στόλων μεταφοράς (Wu, και Yang, 2017). Αντιστοίχως, προτείνεται για την σχεδίαση των ενεργειών του τμήματος πωλήσεων βάσει των προβλέψεων του αντίκτυπου των πωλήσεων (Bischoffshausen et al., 2015). Στη βιβλιογραφία της προδιαγραφικής αναλυτικής, υπό το πρίσμα των πληροφοριακών συστημάτων, ο γραμμικός ακέραιος προγραμματισμός έχει προταθεί για την επανασχεδίαση του συνόλου των τεχνολογιών ανάπτυξης επιχειρηματικού λογισμικού αξιοποιώντας ένα ενιαίο δηλωτικό προγραμματιστικό μοντέλο που θα υποστηρίζει και θα αυτοματοποιεί τις αποφάσεις μέσω του μαθηματικού προγραμματισμού (Aref et al., 2015). Επιπλέον, ο

γραμμικός προγραμματισμός έχει χρησιμοποιηθεί για την σχεδίαση της κατανομής της χωρητικότητας σε αθλητικά γεγονότα (Ghoniem et al.,2017) αλλά και για την βέλτιστη διατίμηση ξενοδοχειακών δωματίων, αναφορικά με τις τιμές που πρόκειται να δημοσιευθούν από διαφορετικούς ταξιδιωτικούς πράκτορες (Baur et al.,2014).

Ο τομέας του μεικτού ακέραιου γραμμικού προγραμματισμού (mixed integer linear programming) διαφέρει από τον γραμμικό ακέραιο προγραμματισμό στους περιορισμούς που επιδέχεται η συνάρτηση βελτιστοποίησης. Στον μεικτό ακέραιο γραμμικό προγραμματισμό κάποιες μεταβλητές απαιτείται να αποτελούν ακέραιους, ενώ άλλες μπορούν να είναι μη-ακέραιοι αριθμοί. Αυτό το γεγονός καθιστά τον μεικτό ακέραιο γραμμικό προγραμματισμό κατάλληλο για την εφαρμογή σε προβλήματα απόφασης όπως η κατανομή των ομάδων πωλήσεων σε πιθανούς πελάτες με στόχο τη μεγιστοποίηση των επιχειρηματικών εσόδων και του κέρδους (Kawas et al., 2013). Σε αυτήν την περίπτωση, η προδιαγραφική αναλυτική ενσωματώνει προβλέψεις που έχουν εξαχθεί από τα ιστορικά δεδομένα πωλήσεων προκειμένου να αποτυπώσει την συμπεριφορική σχέση μεταξύ του μεγέθους και της σύστασης μιας ομάδας πωλητών με τα έσοδα που αυτή αποφέρει για τους διαφορετικούς τύπους πελατών, τηρώντας τους εκάστοτε επιχειρηματικούς περιορισμούς. Ο δυναδικός γραμμικός προγραμματισμός (binary linear programming) έχει προταθεί σε περιπτώσεις όπου οι μεταβλητές έχουν δυαδική μορφή. Ένα παράδειγμα παρουσιάζεται για την περίπτωση που ζητείται η παραγωγή προτάσεων προϊόντων ή υπηρεσιών σε πελάτες (Lo, και Pachamanova, 2015). Σε αυτήν την ερευνητική εργασία, το πρόβλημα διαμορφώνεται ως ένα μοντέλο βελτιστοποίησης πολλαπλών επιλογών με δυαδικές μεταβλητές απόφασης.

Ο **μη-γραμμικός προγραμματισμός** στον οποίο οι συναρτήσεις περιορισμού ή η συνάρτηση βελτιστοποίησης δεν είναι γραμμικές, προτάθηκε από τους Goyal et al. (2016) για τη λήψη αποφάσεων στη διαχείριση της κατάστασης εξοπλισμού (asset health management). Πιο συγκεκριμένα, οι συγγραφείς προτείνουν μια μέθοδο βασισμένη στον μεικτό ακέραιο μη γραμμικό προγραμματισμό για την χρονοδρομολόγηση και την σχεδίαση της προληπτικής, προδραστικής και επιδιορθωτικής συντήρησης εξοπλισμού σε ένα ηλεκτρικό δίκτυο, η οποία υπόκειται σε οικονομικούς περιορισμούς.

Η εργασία των Ito και Fujimaki (2017) προτείνει ένα μοντέλο προδιαγραφικής αναλυτικής βασισμένο στον δυναμικό τετραγωνικό μη γραμμικό προγραμματισμό (binary quadratic non-linear programming) για την επιλογή βέλτιστων τιμολογιακών στρατηγικών, οι οποίες μεγιστοποιούν το μελλοντικό κέρδος σε μια πελατοκεντρική τιμολογιακή προσέγγιση. Επιπλέον, η εργασία των Huang et al., (2018) εστιάζει στην επιλογή της βέλτιστης τοποθεσίας για την επέκταση καταστημάτων λιανικής πώλησης που επιχειρούν στην πώληση πρόσθετων προϊόντων-αξεσουάρ, η ζήτηση των οποίων εξαρτάται από τη ζήτηση των βασικών προϊόντων. Στην εργασία αυτή, οι συγγραφείς μοντελοποίησαν το πρόβλημα ως ένα πρόβλημα μη γραμμικού δυναμικού τετραγωνικού προγραμματισμού ανεξάρτητο από το μη γραμμικό προβλεπτικό μοντέλο.

Μια παραδοσιακή τεχνική λήψης απόφασης σε καταστάσεις αβεβαιότητας (uncertainty) είναι η **στοχαστική βελτιστοποίηση (stochastic optimization)** (Birge, και Louveaux, 2011). Η στοχαστική βελτιστοποίηση αναφέρεται σε μια συλλογή μεθόδων που στοχεύουν στην ελαχιστοποίηση ή τη μεγιστοποίηση μιας συνάρτησης βελτιστοποίησης σε περιβάλλον τυχαιότητας και για το λόγο αυτό αξιοποιείται σε προβλήματα λήψης απόφασης με αβεβαιότητα (Kawas et al., 2013; Bertsimas, και Kallus, 2014). Οι Bertsimas και Kallus (2014) όρισαν την προδιαγραφική αναλυτική από την πλευρά της επιχειρησιακής έρευνας ως ένα πρόβλημα δεσμευμένης στοχαστικής βελτιστοποίησης (conditional stochastic optimization) δοθέντων ατελών παρατηρήσεων (imperfect observations), όπου οι κοινές συναρτήσεις κατανομής πιθανότητας που περιγράφουν το πρόβλημα παραμένουν άγνωστες. Παρόλα αυτά, η εφαρμογή της στοχαστικής βελτιστοποίησης παραμένει δύσκολη (Berk et al., 2019). Τα προβλήματα πολλαπλής περιοδικότητας υποφέρουν από την κατάρα της διαστατικότητας (dimensionality curse). Αν και με τη βοήθεια των εξισώσεων Bellman μπορούν να υπολογιστούν οι βέλτιστες λύσεις, οι εξισώσεις αυτές επεκτείνονται εκθετικά σε μέγεθος αναλογικά με τη διάσταση του χώρου καταστάσεων (Berk et al., 2019). Επιπλέον, οι απαραίτητες για την επίλυση του προβλήματος κατανομές πιθανότητας είναι δύσκολο να προσεγγιστούν χωρίς τη διάθεση άφθονων δεδομένων. Κάτι τέτοιο αποτελεί έναν συνήθη φραγμό για τις επιχειρήσεις που ξεκινούν να εφαρμόζουν προβλεπτικές και προδιαγραφικές αναλύσεις.

Η προσαρμοστική εύρωστη βελτιστοποίηση (adaptive robust optimization) παρουσιάζεται στη βιβλιογραφία ως λύση σε προβλήματα προδιαγραφικής αναλυτικής δεδομένων. Αποτελεί μια βελτιωμένη έκδοση της στατικής εύρωστης βελτιστοποίησης στην οποία η διαχείριση της αβεβαιότητας δεν αναθέεται στην κατανομή πιθανότητας αλλά αντιμετωπίζεται ως συνάρτηση ελλειψοειδούς, πολυέδρου ή όποιας άλλης μορφής εξυπηρετεί την εξεταζόμενη περίπτωση. Η προσαρμοστική εύρωστη βελτιστοποίηση είναι εμπνευσμένη από την τεχνική εκκίνησης της στατιστικής δειγματοληψίας (statistical bootstrap). Εστιάζει σε προβλήματα βελτιστοποίησης στα οποία αναζητείται ένα συγκεκριμένο μέγεθος ευρωστίας έναντι της αβεβαιότητας που αναπαρίσταται ως ντετερμινιστική μεταβλητότητα στην τιμή των παραμέτρων του ίδιου του προβλήματος ή/και της λύσης του. Επιπλέον, ο χαρακτηρισμός των συνόλων δεδομένων που εμπεριέχουν αβεβαιότητα μπορεί να βασίζεται σε δεδομένα και είναι συχνά ερμηνεύσιμος (Bertsimas et al., 2011). Ως εκ τούτου, οι Bertsimas και Van Parys (2017) πρότειναν μια γενική, εύρωστη και προσαρμοστική λύση βελτιστοποίησης. Περαιτέρω, οι Berk et al. (2019) συμμετείχαν στον ορισμό ενός εργαλείου βελτιστοποίησης του προβλήματος προγραμματισμού του ανθρώπινου δυναμικού προκειμένου να μοντελοποιήσουν την αβεβαιότητα πρόβλεψης που ενσωματώνεται στο πρόβλημα βελτιστοποίησης. Στόχος τους ήταν να πάρουν δυναμικά αποφάσεις πρόσληψης οι οποίες θα μεγιστοποιούν το κέρδος ενώ θα παραμένουν όσο το δυνατόν πιο ευέλικτες.

Τέλος, μια μέθοδος βελτιστοποίησης που προτείνεται από τη βιβλιογραφία είναι η **μπεϋζιανή βελτιστοποίηση (bayesian optimization)**. Η μπεϋζιανή βελτιστοποίηση είναι μία τεχνική που βελτιστοποιεί αποδοτικά πολλαπλές, συνεχείς παραμέτρους με υπολογιστικά κοστοβόρες αξιολογήσεις συνάρτησης. Συνήθως, η διαδικασία ξεκινάει με την αξιολόγηση ενός μικρού αριθμού τυχαία επιλεγμένων τιμών συνάρτησης και την προσαρμογή ενός μοντέλου παλινδρόμησης μιας διαδικασίας Gauss στα αποτελέσματα (Letham et al., 2018). Είναι ικανή να επιλύσει διάφορα προβλήματα βελτιστοποίησης στα οποία οι παραδοσιακές μέθοδοι αριθμητικής ανάλυσης και οι καθολικοί βελτιστοποιητές δεν επαρκούν (Gardner et al., 2014). Οι Harikumar et al. (2018a) αξιοποίησαν την τεχνική αυτή σε συνδυασμό με τον προγραμματισμό

περιορισμών (constraint programming), προτείνοντας την περιορισμένη μπεϋζιανή βελτιστοποίηση (constrained bayesian optimization), για την επίλυση ενός ένθετου ολικού προβλήματος βελτιστοποίησης με σκοπό την εγγύηση της ιδιωτικότητας των δεδομένων. Επιπλέον, οι Harikumar et al. (2018b) πρότειναν μια υποσχόμενη μέθοδο προδιαγραφικής αναλυτικής που στοχεύει στην ανακάλυψη της ελάχιστης μεταβολής που πρέπει να γίνει προκειμένου ένα περιβάλλον να μετατοπιστεί από μια ανεπιθύμητη κατάσταση σε μια επιθυμητή. Υπό αυτήν την έννοια, η προτεινόμενη μέθοδος αποτελεί μια γενικευμένη μέθοδο, και για το λόγο αυτό φαίνεται ικανή να εφαρμοστεί σε διαφορετικά προβλήματα και γνωστικά αντικείμενα.

2.2.3.2.2 Εξελικτική Υπολογιστική

Η εξελικτική υπολογιστική μπορεί να δώσει αποδοτικά προσεγγιστικές λύσεις, σε προβλήματα όπου η εύρεση βέλτιστης λύσης μέσω του μαθηματικού προγραμματισμού είναι πολύπλοκη (Duan, και Xiong, 2015). Οι μέθοδοι της εξελικτικής υπολογιστικής έχουν εδραιωθεί ως εργαλεία βελτιστοποίησης, μιας και αποδεικνύονται ισχυροί καθολικοί βελτιστοποιητές (Jin, 2005). Προσεγγίσεις αυτού του κλάδου, όπως για παράδειγμα οι γενετικοί αλγόριθμοι, έχουν μελετηθεί ως εργαλεία προδιαγραφικής αναλυτικής στην εργασία των Dey et al., (2019). Η εργασία αυτή προτείνει έναν γενετικό αλγόριθμο για την αναζήτηση της σύστασης μετάλλων με σκοπό την επίτευξη μιας συγκεκριμένης ιδιότητας, βάσει της πρόβλεψης χαρακτηριστικών του μετάλλου, όπως η αντοχή, η αγωγιμότητα και η σκληρότητα.

2.2.3.2.3 Προσομοίωση

Μια ακόμη σημαντική κατηγορία μεθόδων που προτείνονται στην προδιαγραφική αναλυτική είναι η προσομοίωση (Shao et al., 2014). Οι Giurgiu et al. (2017) πρότειναν μια μέθοδο βασισμένη στην προσομοίωση πάνω στο μοντέλο των τυχαίων δένδρων (random forest) προκειμένου να προτείνουν τις κατάλληλες ενέργειες βελτίωσης σε μηχανήματα εξυπηρετητών (servers), χρησιμοποιώντας την πληροφορία που είναι διαθέσιμη σε καταγεγραμμένα συμβάντα (incident tickets). Επιπροσθέτως, η στοχαστική προσομοίωση αξιοποιήθηκε από τους Jank et al. (2018) με σκοπό τη μεγιστοποίηση του οφέλους από το σύνολο προϊόντων μιας επιχείρησης, σε συμφωνία με τα κριτήρια της επιχείρησης. Από μια άλλη οπτική, οι Wang et al. (2018) πρότειναν μια μέθοδο στοχαστικής προσομοίωσης πάνω σε ένα μπεϋζιανό

δίκτυο πεποίθησης (bayesian belief network) για να υλοποιήσουν μια διαδικασία οδηγούμενης από δεδομένα λήψης απόφασης βάσει των διαθέσιμων κρίσιμων δεικτών απόδοσης (KPIs). Η προσέγγιση αυτή, προτείνει μια μέθοδο διαφορετική από αυτή που ακολουθείται όταν η λήψη απόφασης οδηγείται από τον ειδικό ή τις μεθόδους πολυκριτηριακής λήψης αποφάσεων.

2.2.3.2.4 Μηχανική Μάθηση/Εξόρυξη Δεδομένων

Οι αλγόριθμοι μηχανικής μάθησης/εξόρυξης δεδομένων έχουν προταθεί ευρέως για την προβλεπτική αναλυτική δεδομένων τα τελευταία χρόνια. Στην παρούσα ανασκόπηση εντοπίσαμε ένα άρθρο το οποίο βασίζεται αποκλειστικά στην χρήση αλγορίθμων μηχανικής μάθησης και εξόρυξης δεδομένων (Revathy, και Mukesh, 2018) για τη διενέργεια της προδιαγραφικής αναλυτικής. Οι συγγραφείς προτείνουν μια προσέγγιση βασισμένη στην **k-means ομαδοποίηση** (k-means clustering) με στόχο την επίλυση του προβλήματος της προσαρμοστικής τοποθέτησης δεδομένων σε κατανεμημένους κόμβους με έναν ασφαλή τρόπο, έτσι ώστε να λαμβάνεται υπόψιν το κατά πόσον τα δεδομένα εμπεριέχουν ευαίσθητη πληροφορία. Επιπλέον, οι Shroff et al. (2014) πρότειναν ένα πλαίσιο βασισμένο στην **ενισχυτική μάθηση**, δηλαδή στην εκμάθηση συμπεριφοράς ενός πράκτορα μέσα από δοκιμές αλληλεπίδρασης με ένα δυναμικό περιβάλλον (Kaelbling et al., 1996), την οποία ενσωμάτωσαν με τεχνικές προσομοίωσης και βελτιστοποίησης για την περίπτωση της επιγραμμικής (online) εκπαίδευσης.

2.2.3.2.5 Μοντέλα Λογικής

Τα μοντέλα λογικής και κυρίως τα **συστήματα κανόνων**, έχουν προταθεί επανειλημμένως στην βιβλιογραφία της προδιαγραφικής αναλυτικής, μιας και ενσωματώνουν επαρκώς την γνώση του ειδικού στα μοντέλα προδιαγραφικής αναλυτικής. Οι Ceravolo και Zavatarelli (2015) ανέπτυξαν μια διαδικασία απόκτησης γνώσης ως μια έρευνα πάνω στις εκτελέσεις μιας διαδικασίας. Η προδιαγραφική βάση γνώσης αξιολογεί τα αποτελέσματα των επιχειρηματικών κανόνων ή κριτηρίων τα οποία συσχετίζονται με μια επιχειρηματική διαδικασία και εντοπίζει απροσδόκητα πρότυπα. Η εργασία των Matyas et al. (2017) πρότεινε μια διαδικαστική προσέγγιση για την υλοποίηση του προδιαγραφικού σχεδιασμού συντήρησης (prescriptive maintenance planning). Η προσέγγιση βασίζεται σε κανόνες οι οποίοι αντιστοιχούν

σε μαθηματικές συναρτήσεις και αφορούν κάθε μηχανικό συστατικό. Επιπροσθέτως, λαμβάνουν υπόψιν την πρόβλεψη της φθοράς των μηχανημάτων, την υπό συνθήκη παρακολούθηση και τις διαφορετικές παραλλαγές, για την ποιότητα των προϊόντων.

Οι Ramannavar και Sidnal (2018) πρότειναν μια κατανεμημένη αρχιτεκτονική στην οποία ενσωματώνεται η προχωρημένη αναλυτική δεδομένων με στόχο την αντιστοίχιση μιας θέσης εργασίας σε βιογραφικά υποψηφίων αξιοποιώντας σημασιολογικές τεχνολογίες. Για την περιγραφή μιας συγκεκριμένης θέσης εργασίας, κάθε βιογραφικό βαθμολογείται ως προς δύο άξονες, το κατά πόσο καλύπτει την θέση και την κατανοητότητα, οι οποίοι αναπαρίστανται από τον αριθμό των εννοιών που εμφανίζονται στο βιογραφικό μέσα από μια προκαθορισμένη κλάση εννοιών και τον αριθμό ενοτήτων και υπο-ενοτήτων που καλύπτονται από το βιογραφικό. Το άρθρο των Du et al. (2016) εστιάζει στην παρουσίαση και την επεξήγηση των προτάσεων που γίνονται σε μια χρονική ακολουθία γεγονότων μέσω μιας διεπαφής προδιαγραφικής αναλυτικής. Οι συγγραφείς ανέπτυξαν το σύστημα EventAction, με το οποίο εντοπίζονται παρόμοιες εγγραφές, εκτιμώνται τα αποτελέσματα της τρέχουσας εγγραφής, σύμφωνα με την κατανομή αποτελεσμάτων παρόμοιων εγγραφών, και προτείνονται οι ενέργειες που επιτυγχάνουν τα επιθυμητά αποτελέσματα. Η προσέγγιση αυτή εφαρμόζεται σε μια περίπτωση εκπαίδευσης και σε μια περίπτωση ψηφιακού μάρκετινγκ (Du et al., 2018). Στην δεύτερη περίπτωση, οι συγγραφείς αξιολόγησαν την αποτελεσματικότητα του εργαλείου τους βάσει του κατά πόσο βοήθησε τους εργαζόμενους μέσα από τις προτάσεις εξατομικευμένων στρατηγικών προώθησης (μάρκετινγκ) που τους παρείχε. Ακόμα, η μεθοδολογία 5W1H (What to do, with whom, where, how/when) έχει προταθεί ως μέθοδος προδιαγραφικής αναλυτικής, μέσω της υλοποίησής της σε ένα πληροφοριακό σύστημα με σκοπό την παροχή προτάσεων και συμβουλών αναφορικά με τις ερευνητικές κατευθυντήριες ερευνητών (Song et al., 2014; Lee et al., 2014; Song et al., 2013; Cho et al., 2015).

2.2.3.2.6 Συνδυασμός Μεθόδων

Όπως παρουσιάζεται στην Εικόνα 2-12 και στον Πίνακα 2-4, στη βιβλιογραφία καταγράφονται ποικίλοι συνδυασμοί των προαναφερθέντων κατηγοριών ως μέθοδοι προδιαγραφικής αναλυτικής. Οι Shroff et al. (2014) πρότειναν ένα πλαίσιο το οποίο

συνδυάζει μεθόδους μαθηματικού προγραμματισμού, προσομοίωσης και μηχανικής μάθησης και βασίζεται στην ενισχυτική μάθηση. Οι Srinivas, και Ravindran (2018) πρότειναν μια μέθοδο η οποία συνδυάζει τον μαθηματικό προγραμματισμό με μοντέλα λογικής. Πιο συγκεκριμένα, προτείνουν ένα μοντέλο προδιαγραφικής αναλυτικής που περιλαμβάνει κανόνες χρονοπρογραμματισμού οι οποίοι αξιολογούνται με τη βοήθεια τεχνικών προσομοίωσης. Τα μοντέλα προσομοίωσης χρησιμοποιούνται για την παραγωγή του προγράμματος, ενώ υπολογίζουν το βαθμό αξιολόγησης του παραγόμενου προγράμματος. Με αυτό τον τρόπο, επιτυγχάνουν τη βελτίωση της απόδοσης ενός συστήματος κρατήσεων ιατρικών επισκέψεων, λαμβάνοντας υπόψιν την ικανοποίηση των ασθενών και την αξιοποίηση των διαθέσιμων πόρων.

Η εργασία των Thammaboosadee και Wongpitak (2018) πρότεινε την χρήση της εξελικτικής υπολογιστικής και της μηχανικής μάθησης. Αξιοποιώντας την k-means ομαδοποίηση, στοχεύει στον προσδιορισμό της κατανομής του ηλεκτρολογικού εξοπλισμού λαμβάνοντας υπόψιν την συμπεριφορά των πελατών και την πολιτική της επιχείρησης. Επιπροσθέτως, η εργασία του Laude, (2018) εστιάζει στην εφαρμογή της προδιαγραφικής αναλυτικής σε αυτοματοποιημένα συστήματα γεωργίας. Σε αυτήν, οι συγγραφείς κατασκεύασαν μια μηχανή προδιαγραφικής αναλυτικής. Η μηχανή αυτή συναθροίζει πληροφορίες που υποδεικνύουν τις απαιτούμενες ενέργειες και παράγει ένα σύνολο από γεγονότα. Η μηχανή επιτυγχάνει το σκοπό της μέσα από διαφορετικούς συνδυασμούς συνόλων μεθόδων, βελτιστοποίησης σμήνους σωματιδίων (particle swarm optimization) και ασαφούς γραμμικού προγραμματισμού ή ασαφών συστημάτων κανόνων.

Το άρθρο των Gröger et al. (2014) συνδύασε μεθόδους εξόρυξης δεδομένων και μοντέλων λογικής. Πιο συγκεκριμένα, συνδυάζει τεχνικές εξόρυξης δεδομένων και κανόνες παραγόμενους από δένδρα αποφάσεων (decision trees), προκειμένου να προτείνει ενέργειες βελτιστοποίησης μια επιχειρηματικής διαδικασίας. Σε αυτήν την εργασία, οι συγγραφείς παρουσίασαν επίσης μια μελέτη περίπτωσης στο πεδίο της βιομηχανικής παραγωγής. Στην συνέχεια της μελέτης τους, απέδειξαν ότι η προτεινόμενη προσέγγιση κινείται πέρα από τα συνηθισμένα όρια της βελτιστοποίησης επιχειρηματικών διαδικασιών, που συνήθως βασίζεται σε

βελτιστοποίηση αναγνωρισμένων προτύπων, προτάσεις με μεθόδους εξόρυξης διαδικασιών (process mining) και υποστήριξη αποφάσεων βάσει ρίσκου. Η συγκεκριμένη αναφορά αποτελεί μια σημαντική συνεισφορά καθώς αξιοποιεί τον τομέα της προδιαγραφικής αναλυτικής για να μετασχηματίσει τα αποτελέσματα της ανάλυσης σε υλοποιήσιμες ενέργειες χωρίς να αφήνει αυτό το βήμα εξ' ολοκλήρου στην κρίση του χρήστη. Ακόμα, η συγκεκριμένη προσέγγιση συνδυάζει δεδομένα επιχειρηματικών διαδικασιών με επιχειρησιακά δεδομένα, ενώ έχει τη δυνατότητα να συμβάλλει προδραστικά στη βελτίωση της διαδικασίας κατά την εκτέλεσή της.

Υπό ένα διαφορετικό πρίσμα, το άρθρο των Mendes et al. (2014) ασχολήθηκε με τις λέξεις που επιλέγουν οι χρήστες του κοινωνικού δικτύου Twitter και πώς αυτή η επιλογή επηρεάζει την διάδοση των μηνυμάτων στους υπόλοιπους χρήστες. Με την προσέγγιση που περιγράφουν, προτείνουν αλλαγές λέξεων κατά τη διαμόρφωση ενός μηνύματος προκειμένου αυτό το μήνυμα να αποφέρει περισσότερες αναδημοσιεύσεις. Για το σκοπό αυτό, χρησιμοποιούν γενικευμένα γραμμικά μοντέλα, όπως μια ευέλικτη γενίκευση της κλασσικής γραμμικής παλινδρόμησης. Η προτεινόμενη μέθοδος επιτρέπει στις παραμέτρους απόκρισης να ακολουθούν κατανομή διαφορετική της κανονικής, ενσωματώνοντας τα σε ένα σύστημα κανόνων. Ένα πλεονέκτημα των γενικευμένων γραμμικών μοντέλων είναι η διαφάνεια και η φιλικότητα που προσφέρουν στον χρήστη, μιας και τα βάρη των συναρτήσεων μπορούν εύκολα να αναπαρασταθούν σε μια διεπαφή χρήστη, προσφέροντας στο χρήστη τη δυνατότητα να διαφωνεί με τις προτάσεις του μοντέλου.

Στο άρθρο των Ghosh et al. (2016) προτείνεται ο συνδυασμός μεθόδων μαθηματικού προγραμματισμού, μηχανικής μάθησης και μοντέλων λογικής, με στόχο τον ορισμό, την παρακολούθηση, την ταξινόμηση και την αξιολόγηση ενός συνόλου κρίσιμων δεικτών απόδοσης (KPIs). Οι επιλεγμένοι δείκτες αφορούν την επιχειρησιακή αποδοτικότητα της ανάθεσης επιχειρηματικών διαδικασιών σε εξωτερικούς συνεργάτες. Σε αυτήν την προσέγγιση, χρησιμοποιείται η συναθροιστική μέθοδο Kemeny rank προκειμένου να παρέχεται μια συναθροιστική βαθμονομημένη λίστα που ελαχιστοποιεί τον αριθμό των διαφωνιών που προκύπτουν ανάμεσα σε ζεύγη πελατών. Οι μέθοδοι που προτείνονται από τη συγκεκριμένη εργασία συνδυάζουν την ακέραιη γραμμική βελτιστοποίηση και συστήματα κανόνων.

Στην εργασία των Jiang et al. (2010) συνδυάζεται ο μαθηματικός προγραμματισμός με πιθανολογικά μοντέλα για να κατασκευαστεί μια εφαρμογή επιχειρηματικής ευφυΐας με δυνατότητες προβλεπτικής και προδιαγραφικής αναλυτικής. Στο άρθρο των Ayhan et al. (2018) αναπτύσσεται μια μέθοδος προδιαγραφικής αναλυτικής για τον εντοπισμό και την αντιμετώπιση συγκρούσεων αεροσκαφών μεγάλων αποστάσεων. Σε αυτό, προτείνεται μια προσέγγιση η οποία μαθαίνει από περιγραφικά πρότυπα τις ιστορικές τροχιές και αξιοποιώντας συναφή καιρικά δεδομένα κατασκευάζει ένα κρυφό μαρκοβιανό μοντέλο (Hidden Markov Model) χρησιμοποιώντας μια παραλλαγή του αλγορίθμου Viterbi. Το προτεινόμενο σύστημα αποφεύγει τον όγκο αεροσκαφών στον οποίο εντοπίζονται συγκρούσεις και παράγει νέες βέλτιστες τροχιές.

2.2.4 Σύνθεση Αποτελεσμάτων και Ερευνητικές Προκλήσεις

Σύμφωνα με την παρούσα βιβλιογραφική ανασκόπηση, είναι εμφανής η άνοδος του ενδιαφέροντος για την προδιαγραφική αναλυτική. Πιο συγκεκριμένα, το ενδιαφέρον εστιάζεται σε μοντέλα προδιαγραφικής αναλυτικής τα οποία μπορούν να λειτουργήσουν σε πραγματικό χρόνο και σε περιβάλλοντα υπολογιστικής με ροές δεδομένων, όπως για παράδειγμα στο πλαίσιο του διαδικτύου των αντικειμένων. Επιπροσθέτως, η ευρεία διαθεσιμότητα συνόλων δεδομένων μεγάλης κλίμακας, προερχόμενα από ετερογενείς πηγές δεδομένων, ανοίγει το δρόμο για την ελαχιστοποίηση της ανθρώπινης κρίσης στη λήψη αποφάσεων, η οποία χαρακτηρίζεται από υποκειμενικότητα, καθώς και για την αξιοποίηση της πληροφορίας που μπορεί να ανακαλυφθεί με την επεξεργασία των δεδομένων. Με την άφιξη νέων δεδομένων, θα είναι δυνατή η κατασκευή και η δυναμική ενημέρωση μοντέλων προδιαγραφικής αναλυτικής. Κάτι τέτοιο δηλώνει την ανάγκη για δυναμικά μοντέλα προδιαγραφικής αναλυτικής που θα μπορούν να υποστηρίξουν πολλές διαφορετικές περιπτώσεις και γνωστικά αντικείμενα και θα υλοποιούνται από συστήματα που θα ικανοποιούν τις αντίστοιχες απαιτήσεις.

Μια επιπλέον ερευνητική τάση είναι η εφαρμογή των μεθόδων και εργαλείων τεχνητής νοημοσύνης υπό το πρίσμα της προδιαγραφικής αναλυτικής (Lee et al., 2018). Μέχρι τώρα, η έρευνα έχει εστιάσει κυρίως στο εννοιολογικό επίπεδο των

δυνατοτήτων που προσφέρει αυτή η εφαρμογή (Soltanpoor, και Sellis, 2016; Nechifor et al., 2015; Shroff et al., 2014; Bertsimas, και Van Parys, 2017; Anderson, 2017; Giurgiu et al., 2017). Παρόλο που η περιγραφική και προδιαγραφική αναλυτική παρουσιάζουν μεγάλη εξέλιξη τα τελευταία χρόνια προς αυτές τις κατευθύνσεις, η προδιαγραφική αναλυτική βρίσκεται ακόμη στην αρχή της. Για παράδειγμα, η παρούσα ανασκόπηση υποδεικνύει ότι μόνο μερικές από τις προηγμένες τεχνικές που ασχολούνται με την αβεβαιότητα των ροών δεδομένων θα μπορούσαν να αξιοποιηθούν για την προδιαγραφική αναλυτική. Μιας και το παρόν κεφάλαιο έχει ως στόχο να συνεισφέρει στην ανάπτυξη του τομέα της προδιαγραφικής αναλυτικής, παρακάτω παρουσιάζεται μια σύνθεση των προκλήσεων που προκύπτουν από την παρούσα βιβλιογραφική ανασκόπηση και εντοπίζονται κατευθύνσεις για περαιτέρω έρευνα.

Offline ή σε πραγματικό χρόνο επεξεργασία δεδομένων

Σύμφωνα με την παρούσα βιβλιογραφική ανασκόπηση, η επεξεργασία πραγματικού χρόνου δεν έχει ερευνηθεί πλήρως στον τομέα της προδιαγραφικής αναλυτικής. Το 64% των μελετών που εξετάστηκαν ασχολούνται με μοντέλα τα οποία κατασκευάζονται και εκτελούνται offline, δηλαδή σε χρόνο διαφορετικό και ανεξάρτητο από την εκτέλεση των σχετικών ενεργειών και της συλλογής δεδομένων. Παρόλα αυτά, η υιοθέτηση του διαδικτύου των αντικειμένων από τις επιχειρήσεις οδηγεί στην αυξανόμενη απαίτηση για συστήματα πραγματικού χρόνου. Ένα εμπόδιο σε αυτήν την κατεύθυνση είναι οι τεχνικές προκλήσεις που υπάρχουν στην ανάπτυξη επεκτάσιμων και αποδοτικών πληροφοριακών συστημάτων τα οποία ενσωματώνουν δεδομένα μεγάλης κλίμακας, π.χ. δεδομένα αισθητήρων (Biegler et al., 2015; Yaqoob et al., 2016). Επιπρόσθετα σε αυτό, παρουσιάζεται και η ανάγκη για αναδρομικούς αλγόριθμους προδιαγραφικής αναλυτικής, οι οποίοι θα μπορούν να επεξεργάζονται δεδομένα με χρονικά εξαρτώμενα χαρακτηριστικά και κατά συνέπεια να επιλύουν πολύπλοκα και απαιτητικά προβλήματα. Η αναδρομή εστιάζει στην επίλυση προβλημάτων τα οποία εξαρτώνται από λύσεις των επιμέρους τμημάτων του προβλήματος.

Ερευνητική Πρόκληση 1: *Η ανάπτυξη πληροφοριακών συστημάτων πραγματικού χρόνου, βασισμένα σε δεδομένα μεγάλης κλίμακας και η ανάπτυξη αναδρομικών*

αλγορίθμων, μπορεί να διευκολύνει την εφαρμογή και υιοθέτηση της προδιαγραφικής αναλυτικής για πολύπλοκα και απαιτητικά προβλήματα.

Οι υπολογιστικές προκλήσεις είναι ακόμη πιο δύσκολες όταν η προβλεπτική και προδιαγραφική αναλυτική πρέπει να αναπτυχθούν για κατανεμημένες πλατφόρμες (Biegler et al., 2015). Στις πλατφόρμες αυτής της μορφής, τα δομικά στοιχεία τοποθετούνται σε διαφορετικά υπολογιστικά δίκτυα, επικοινωνούν και συντονίζουν τις ενέργειές τους με την ανταλλαγή μηνυμάτων (Tanenbaum, και Van Steen, 2007). Σύμφωνα με την παρούσα βιβλιογραφική ανασκόπηση, μόνο μία μελέτη (Hong et al., 2015) προτείνει την υλοποίηση μιας προσέγγισης προδιαγραφικής αναλυτικής σε μια κατανεμημένη πλατφόρμα παράλληλης υπολογιστικής. Η προδιαγραφική αναλυτική μπορεί να επωφεληθεί από την κατανεμημένη υπολογιστική η οποία μπορεί να διευκολύνει την επεξεργασία δομημένων ή μη δομημένων δεδομένων μεγάλης κλίμακας.

Ερευνητική Πρόκληση 2: *Η προδιαγραφική αναλυτική μπορεί να επωφεληθεί από την κατανεμημένη υπολογιστική η οποία διευκολύνει την επεξεργασία δεδομένων μεγάλης κλίμακας.*

Διάφορες ερευνητικές κοινότητες έχουν καταλήξει στην επεξεργασία ροών δεδομένων ως το προγραμματιστικό μοντέλο που επιτρέπει την αποδοτική και παράλληλη υπολογιστική (Hirzel et al., 2014). Υπό αυτό το πρίσμα, οι τεχνολογίες επεξεργασίας πολύπλοκων γεγονότων (Complex Event Processing - CEP) μπορούν να συνδράμουν σημαντικά. Ο συγκεκριμένος τομέας παρακολουθεί και επεξεργάζεται ροές πληροφορίας (δεδομένα) τα οποία σχετίζονται με γεγονότα, συνδυάζοντας πολλαπλές πηγές, προκειμένου να συμπεράνει νέα γεγονότα ή πρότυπα που αποκαλύπτουν σημαντικά γεγονότα. Ένα τέτοιο παράδειγμα είναι ο εντοπισμός μιας ευκαιρίας ή μιας απειλής, όπου με τον τρόπο αυτό δίνεται η δυνατότητα αντίδρασης σε αυτά (Schmerken, 2008; Luckham, 2011; Etzion et al., 2011; Bates, 2012).

Ερευνητική Πρόκληση 3: *Η επεξεργασία ροών δεδομένων και η επεξεργασία πολύπλοκων γεγονότων μπορούν να επιτρέψουν την ανάπτυξη λύσεων προδιαγραφικής αναλυτικής σε περιβάλλοντα με δεδομένα πραγματικού χρόνου.*

Ντετερμινιστικά ή πιθανολογικά μοντέλα

Οι προσεγγίσεις, οι αλγόριθμοι και οι μέθοδοι προδιαγραφικής αναλυτικής διαχειρίζονται την αβεβαιότητα που προέρχεται από τρεις βασικές πηγές: (i) την αβεβαιότητα των προβλέψεων, η οποία υπολογίζεται από την αξιολόγηση των προβλέψεων που προκύπτουν από τους αλγορίθμους προβλεπτικής αναλυτικής δεδομένων, (ii) την αβεβαιότητα της ποιότητας των δεδομένων και (iii) την υποκειμενικότητα που εμπεριέχεται στην ανθρώπινη κρίση κατά την κατασκευή ενός μοντέλου προδιαγραφικής αναλυτικής. Το 76% των εξεταζόμενων ερευνών της βιβλιογραφικής ανασκόπησης θεωρεί την αβεβαιότητα ως έναν κρίσιμο παράγοντα για την επιτυχημένη προδιαγραφική αναλυτική. Όμως, οι αντίστοιχες μελέτες, συνήθως περιορίζονται στα πλαίσια των τεχνικών του καθαρισμού δεδομένων με τις οποίες επιχειρείται η διαχείριση των ελλιπών συνόλων δεδομένων. Για το λόγο αυτό, τα προδιαγραφικά μοντέλα που αναπαριστούν τη διαδικασία λήψης απόφασης αντιπροσωπεύουν κατά κύριο λόγο ντετερμινιστικά μοντέλα.

Η αξιολόγηση των προβλεπτικών αλγορίθμων έχει κερδίσει την προσοχή της ερευνητικής κοινότητας, αφήνοντας αναπάντητο το ερώτημα του πως θα περάσουμε από μία καλή πρόβλεψη σε μία καλή απόφαση (Bertsimas, και Kallus, 2014). Από τη μέχρι τώρα δημοσιευμένη βιβλιογραφία προκύπτει ότι η διαχείριση των ελλιπών δεδομένων, των δεδομένων που περιέχουν θόρυβο, η απομόνωση και η μοντελοποίηση της εξειδικευμένης έμπειρης γνώσης ενός προβλήματος, καθώς και η αβεβαιότητα μιας διαδικασίας λήψης απόφασης, αποτελούν τρεις ερευνητικούς τομείς οι οποίοι αναπτύσσονται παράλληλα με την προδιαγραφική αναλυτική, χωρίς μια διάφανη συσχέτιση μεταξύ τους. Αυτό το γεγονός διαφαίνεται ακόμη πιο σημαντικό όταν ζητείται η προδιαγραφική αναλυτική πραγματικού χρόνου κατά την οποία απαιτούνται έγκαιρες αποφάσεις στην καθημερινή λειτουργία των επιχειρήσεων.

Ερευνητική Πρόκληση 4: *Είναι απαραίτητη η αναγνώριση και διαχείριση της αβεβαιότητας που συναθροίζεται από την αβεβαιότητα των προβλέψεων, τα ελλιπή και με θόρυβο δεδομένα και την υποκειμενικότητα της ανθρώπινης κρίσης που συμμετέχει στη διαδικασία λήψης απόφασης.*

Λόγω της αβέβαιης φύσης της προδιαγραφικής αναλυτικής, τα περισσότερα προβλήματα μπορούν να μοντελοποιηθούν με πιθανολογικές δομές. Τα

πιθανολογικά γραφικά μοντέλα, και κυρίως τα μπευζιανά δίκτυα, έχουν αναφερθεί ως ισχυρά εργαλεία αναπαράστασης της γραφικής δομής των σχέσεων των τυχαίων μεταβλητών ως προς τις μεταξύ τους εξαρτήσεις (Gudivada et al., 2016). Για το λόγο αυτό μπορούν να ενισχύσουν τα προδιαγραφικά μοντέλα.

Από την άλλη πλευρά, μοντέλα όπως οι μαρκοβιανές διαδικασίες απόφασης (Markov Decision Processes - MDP), οι οποίες έχουν προταθεί για την προδραστική λήψη απόφασης αναπαριστούν την ίδια τη διαδικασία απόφασης αντί για την φυσική διαδικασία (Bousdekis et al., 2018). Έτσι, μπορούν να αξιοποιηθούν στην προδιαγραφική αναλυτική για την διαχείριση της αβεβαιότητας. Μια μαρκοβιανή διαδικασία απόφασης είναι μια στοχαστική διαδικασία ελέγχου, διακριτού χρόνου, η οποία παρέχει ένα μαθηματικό πλαίσιο μοντελοποίησης της διαδικασίας απόφασης σε περιπτώσεις όπου το αποτέλεσμα είναι εν μέρει τυχαίο και εν μέρει εξαρτάται από τον υπεύθυνο λήψης απόφασης (Meyn, 2008). Οι μαρκοβιανές διαδικασίες απόφασης φαίνονται χρήσιμες για τη μελέτη προβλημάτων βελτιστοποίησης τα οποία επιλύονται με την χρήση δυναμικού προγραμματισμού και ενισχυτικής μάθησης. Γενικότερα, σε σύγκριση με τα φυσικά μοντέλα, όπως για παράδειγμα η προσομοίωση της φυσικής διαδικασίας του εξοπλισμού μιας βιομηχανικής γραμμής παραγωγής, τα πιθανολογικά γενετικά μοντέλα επιτρέπουν τη χρήση στατιστικών προβλεπτικών μοντέλων για την αναζήτηση της βέλτιστης παραμετροποίησης (Shroff et al., 2014).

Ερευνητική Πρόκληση 5: *Η αβεβαιότητα της προδιαγραφικής αναλυτικής, μπορεί να αναπαρασταθεί με τη βοήθεια πιθανολογικών δομών και μοντέλων.*

Επιπροσθέτως, τα τελευταία χρόνια παρουσιάζονται κάποιες προσπάθειες σύνδεσης της πιθανολογικής λογικής και της αβεβαιότητας σε μηχανές επεξεργασίας πολύπλοκων δεδομένων, έτσι ώστε να μπορούν να αντιδρούν σε προβλέψεις σχετικές με μελλοντικά γεγονότα, πριν αυτά εκδηλωθούν (Engel et al., 2012; Wang et al., 2013; Cugola et al., 2015; Mousheimish et al., 2016; Lee, και Jung, 2017). Παρόλα αυτά, στη βιβλιογραφία καταγράφεται περιορισμένος αριθμός άρθρων με αντικείμενο την ενσωμάτωση των πιθανολογικών αποτελεσμάτων σε τέτοια συστήματα (Christ et al. 2016). Για το λόγο αυτό, ακολουθώντας τις προσεγγίσεις οι οποίες χρησιμοποιούν την επεξεργασία πολύπλοκων γεγονότων για την αναγνώριση

σημαντικών προτύπων και καταστάσεων με στόχο την έγκαιρη αντίδραση σε αυτά, η προδιαγραφική αναλυτική θα μπορούσε να επωφεληθεί από την ανάπτυξη αυτού του τομέα. Με αυτό τον τρόπο, επιτρέπεται η αξιοποίηση αυτών των τεχνολογιών, για να προδιαγράψει τις κατάλληλες ενέργειες με έναν προδραστικό τρόπο, σύμφωνα με τις προβλέψεις που γίνονται. Προς αυτήν την κατεύθυνση, η μηχανική μάθηση σε συνδυασμό με τις τεχνολογίες επεξεργασίας πολύπλοκων γεγονότων μπορεί να εμπλουτίσει την διαθέσιμη βάση γνώσης με πληροφορίες πέρα από την γνώση των ειδικών του επιστημονικού πεδίου του προβλήματος.

Ερευνητική Πρόκληση 6: *Η προδιαγραφική αναλυτική μπορεί να επωφεληθεί από τον συνδυασμό της πιθανολογικής λογικής με μηχανές επεξεργασίας πολύπλοκων γεγονότων (CEP).*

Μοντέλα γνώσης πεδίου ή μοντέλα βασισμένα στα δεδομένα

Αν και η αξιοποίηση των τεχνολογιών δεδομένων μεγάλης κλίμακας έχει προσθέσει σημαντική επιχειρηματική αξία σε όλες τις πλευρές μιας επιχείρησης, η ενσωμάτωση της αναλυτικής δεδομένων μεγάλης κλίμακας με την διαδικασία λήψης απόφασης παραμένει μια αναπάντητη πρόκληση (Akter et al., 2019). Η προδιαγραφική αναλυτική έχει τη δυνατότητα να παίζει καθοριστικό ρόλο προς αυτήν την κατεύθυνση. Σύμφωνα με την βιβλιογραφική έρευνα, 82% των εξεταζόμενων εργασιών αφορούν προδιαγραφικά μοντέλα τα οποία αναπτύσσονται αποκλειστικά και μόνο σύμφωνα με την γνώση του ειδικού του εκάστοτε επιστημονικού πεδίου ή προβλήματος. Παρόλα αυτά, τέτοια μοντέλα αναπόφευκτα συμπεριλαμβάνουν την υποκειμενικότητα, ή την πιθανώς ελλιπή πρότερη γνώση του ειδικού, ενώ η ανάπτυξή τους είναι πολύπλοκη, επίπονη και συχνά αδύνατη, μιας και η αποτύπωση της εμπειρίας του ειδικού σε ένα μοντέλο μπορεί να μην είναι εφικτή.

Η ευρεία διάθεση συνόλων δεδομένων μεγάλης κλίμακας θα μπορούσε να βοηθήσει στην αντιμετώπιση αυτών των προβλημάτων. Όμως, κάτι τέτοιο παραμένει αρκετά πρώιμο ερευνητικά. Η εξέλιξη των εφαρμογών δεδομένων μεγάλης κλίμακας ανοίγει το δρόμο για την ανάπτυξη προδιαγραφικών μοντέλων τα οποία θα βασίζονται λιγότερο στη γνώση και την εμπειρία των ειδικών και περισσότερο στα διαθέσιμα δεδομένα και τα αποτελέσματα της αναλυτικής πάνω σε αυτά. Οι δυνατότητες που θα προσέφερε κάτι τέτοιο μπορούν να ενισχυθούν με την

εφαρμογή αλγορίθμων εξόρυξης δεδομένων, μηχανικής μάθησης και τεχνητής νοημοσύνης. Έχουν καταγραφεί αρκετές μελέτες που αφορούν αλγορίθμους περιγραφικής και προβλεπτικής αναλυτικής δεδομένων βασισμένους σε αυτούς τους τομείς (Tsai et al., 2015; Larson, και Chang, 2016). Ωστόσο, οι ερευνητικές εργασίες που επιχειρούν κάτι ανάλογο για την προδιαγραφική αναλυτική είναι ελάχιστες. Στα περισσότερα άρθρα που εξετάστηκαν, η προδιαγραφική αναλυτική βασίζεται στη διαμόρφωση ενός προβλήματος βελτιστοποίησης το οποίο αποτελείται από μια συνάρτηση βελτιστοποίησης κατασκευασμένη σύμφωνα με τη γνώση του ειδικού και τη διαθέσιμη γνώση του επιστημονικού πεδίου που αναφέρεται.

Ερευνητική Πρόκληση 7: *Τα προδιαγραφικά μοντέλα έχουν τη δυνατότητα να βασιστούν λιγότερο στη γνώση του ειδικού και περισσότερο στην αναλυτική δεδομένων μεγάλης κλίμακας.*

Μια βέλτιστη πρακτική θα ήταν ο συνδυασμός της γνώσης που εξάγεται από τις τεχνικές μηχανικής μάθησης και εξόρυξης δεδομένων με την γνώση και εμπειρία των ειδικών του επιστημονικού πεδίου. Με το συνδυασμό των δύο διαφορετικών πηγών γνώσης, μπορούν να ενισχυθούν οι δυνατότητες κάθε πλευράς και να καλυφθούν οι αδυναμίες της. Κάτι τέτοιο μπορεί να οδηγήσει σε μοντέλα λήψης απόφασης τα οποία θα περιέχουν τη μέγιστη δυνατή γνώση και θα είναι ικανά να παράγουν πιο έγκυρες αποφάσεις και να καλύψουν περισσότερες πιθανές περιπτώσεις.

Ερευνητική Πρόκληση 8: *Ο συνδυασμός της γνώσης που παράγεται από αλγορίθμους μηχανικής μάθησης πάνω στα διαθέσιμα δεδομένα, με την γνώση και την εμπειρία των ειδικών του επιστημονικού πεδίου μπορεί να οδηγήσει σε αποδοτικά προδιαγραφικά μοντέλα.*

Όπως αναφέρθηκε νωρίτερα, εκτός από τις μεθόδους και αλγορίθμους που συνοπτικά αναφέρονται στις προηγούμενες παραγράφους, στη βιβλιογραφία που εξετάστηκε εντοπίσαμε εννοιολογικές προσεγγίσεις που σηματοδοτούν την ανάπτυξη προηγμένων μοντέλων προδιαγραφικής αναλυτικής. Σε όλες τις εννοιολογικές προσεγγίσεις που εξετάστηκαν, τονίζονται οι δυνατότητες που προσφέρουν τα δεδομένα μεγάλης κλίμακας στην προδιαγραφική αναλυτική ως προς την κατεύθυνση κατά την οποία ο ρόλος του ανθρώπου μετασχηματίζεται από εκείνον του αποφασίζοντα σε εκείνον του επιβλέποντα της συνολικής διαδικασίας

της αναλυτικής δεδομένων. Προς αυτήν την κατεύθυνση, έχουν προταθεί η στοχαστική προσομοίωση και οι επιχειρηματικοί κανόνες (Soltanpoor, και Sellis, 2016), η επεξεργασία πολύπλοκων γεγονότων (Krumeich et al., 2016), η αυτόνομη δικτύωση (autonomic networking) (Nechifor et al., 2015) και η βασισμένη σε γράφους αναλυτική δεδομένων (graph-based analytics) (Ringsquandl et al., 2016) σε ένα υπολογιστικό περιβάλλον ροών δεδομένων, ως οι βασικοί κινητήριοι παράγοντες για την περαιτέρω εξέλιξη της προδιαγραφικής αναλυτικής σε διάφορα πεδία εφαρμογής. Επιπροσθέτως, παρουσιάζονται αρκετές προσπάθειες σχεδίασης εννοιολογικών αρχιτεκτονικών για την αναλυτική δεδομένων πραγματικού χρόνου με κυρίαρχο ενδιαφέρον στην προδιαγραφική αναλυτική (Tan et al., 2016; Brodsky et al., 2017; Pospieszny, 2017; Deshpande et al., 2019).

Η τεχνητή νοημοσύνη αντιπροσωπεύει ένα σημαντικό συστατικό των ψηφιακών συστημάτων, καθώς μεταξύ άλλων, επιδρά καταλυτικά στον τρόπο με τον οποίο λαμβάνουμε αποφάσεις (Duan et al., 2019). Αυτό έχει ως αποτέλεσμα την αυξανόμενη ζήτηση για πληροφοριακά συστήματα που υλοποιούν αλγορίθμους τεχνητής νοημοσύνης και μηχανικής μάθησης για τη λήψη αποφάσεων (Duan et al., 2019). Για να μπορεί ένα τέτοιο σύστημα να αξιοποιηθεί σε διαφορετικά προβλήματα, με διαφορετικές συνθήκες, θα πρέπει οι υλοποιημένες μέθοδοι και αλγόριθμοι να μπορούν να εφαρμοστούν σε διαφορετικά επιστημονικά αντικείμενα. Η χρήση των αλγορίθμων τεχνητής νοημοσύνης μπορεί να δώσει στην προδιαγραφική αναλυτική τη δυνατότητα ανάπτυξης πιο δυναμικών, βασισμένων σε δεδομένα μεθόδων, οι οποίες μπορεί να μην εξαρτώνται από ένα επιστημονικό πεδίο αλλά να βρίσκουν εφαρμογές με μεγάλη ευκολία σε διαφορετικά προβλήματα.

Ερευνητική Πρόκληση 9: *Η υιοθέτηση της προδιαγραφικής αναλυτικής προϋποθέτει την ανάπτυξη δυναμικών προδιαγραφικών μοντέλων, η οποία καθίσταται δυνατή με την αξιοποίηση της τεχνητής νοημοσύνης και της μηχανικής μάθησης.*

Κάποιες από τις εξέχουσες μεθόδους μηχανικής μάθησης έχουν προταθεί με αποδοτικά αποτελέσματα για την επίλυση διαφόρων προβλημάτων λήψης απόφασης, όπως τα νευρωνικά δίκτυα (Domingos et al., 2017), τα μπευζιανά δίκτυα (Said et al., 2016), τα ασαφή σύνολα (Pal, και Ceglarek, 2013) και τα μαρκοβιανά μοντέλα (Bousdekis et al., 2018).

Στατικά ή δυναμικά προδιαγραφικά μοντέλα

Η συνεχής αλλαγή είναι ένα αναπόσπαστο χαρακτηριστικό των σύγχρονων εφαρμογών, καθώς η ευέλικτη και προσαρμοστική απόκριση μιας επιχείρησης παίζει σημαντικό ρόλο στην επιτυχία της. Οι μηχανισμοί προσαρμοστικότητας σύμφωνα με την ανάδραση των χρηστών είναι μια αρκετά μελετημένη ερευνητική περιοχή ως προς την εφαρμογή της σε περιγραφικούς και προβλεπτικούς αλγορίθμους. Αντιθέτως η υλοποίηση τέτοιων μηχανισμών στην προδιαγραφική αναλυτική έχει ερευνηθεί ελάχιστα. Μιας και οι σημερινές επιχειρήσεις λειτουργούν σε πολύπλοκα και δυναμικά περιβάλλοντα, με πολλές και ετερογενείς πηγές δεδομένων και πληροφορίας, η προσαρμοστικότητα των προδιαγραφικών μοντέλων αποτελεί ένα σημαντικό χαρακτηριστικό. Ένα δυναμικό προδιαγραφικό μοντέλο αναφέρεται στην δυνατότητα προσαρμογής του μοντέλου στο εκάστοτε πρόβλημα, έτσι ώστε το μοντέλο να είναι έγκυρο κάθε φορά που παρουσιάζονται νέες απαιτήσεις ή ανακαλύπτεται επιπλέον γνώση.

Η προσαρμοστικότητα των προδιαγραφικών μοντέλων μπορεί να οριστεί με τη μορφή τροποποιημένων αποφάσεων, αλλαγμένων προτάσεων ή νέων προτεινόμενων ενεργειών (Soltanpoor, και Sellis, 2016). Οι μηχανισμοί ανάδρασης χρήστη θα πρέπει να παρακολουθούν τις παραγόμενες προδιαγραφές παράλληλα με τα νέα, μη υφιστάμενα γεγονότα που εκδηλώνονται σε ένα σύστημα (Soltanpoor, και Sellis, 2016). Η προσαρμοστικότητα των προβλεπτικών αλγορίθμων αναγνωρίζεται ως ένας σημαντικός για την αξιοπιστία του συστήματος παράγοντας από τη βιβλιογραφία. Όμως, η υλοποίησή της με περιορισμένες δυνατότητες προτείνεται μόνο στο 29% των προτεινόμενων αλγορίθμων των εργασιών που εξετάστηκαν, ενώ δεν καταγράφεται η υλοποίησή της σε κάποιο πληροφοριακό σύστημα.

Αξιοσημείωτες εργασίες που επιχειρούν την αξιοποίηση όλων των δυνατοτήτων ενός περιβάλλοντος πλούσιο σε δεδομένα είναι οι εργασίες των Nechifor et al. (2015) και Soltanpoor και Sellis (2016), παρόλο που περιγράφουν εννοιολογικές προσεγγίσεις. Οι περισσότερες από τις σχετικές εργασίες ερευνούν επεκτάσεις σε προδιαγραφικά μοντέλα τα οποία εξαρτώνται από το επιστημονικό πεδίο του προβλήματος. Συνήθως, αναπτύσσονται από κάποιον εξειδικευμένο χρήστη και στοχεύουν στην παραγωγή τιμών που έχουν προηγουμένως εκτιμηθεί από τον

χρήστη. Η αξία της συνεισφοράς ενός κλειστού βρόγχου στον οποίο οι παραγόμενες προδιαγραφές οδηγούνται πίσω σε ένα σύστημα ελέγχου της διαδικασίας αναγνωρίζεται στην εργασία των Gröger et al. (2014). Παράλληλα, η εργασία των (Shroff et al., 2014) περιλαμβάνει προσαρμοστικές κλειστού βρόγχου προσεγγίσεις προδιαγραφικής αναλυτικής.

Ερευνητική Πρόκληση 10: *Οι μηχανισμοί προσαρμοστικότητας των προδιαγραφικών προσεγγίσεων είναι κρίσιμος παράγοντας για την αξιοποίησή τους σε δυναμικά περιβάλλοντα.*

Οι μηχανισμοί προσαρμοστικότητας στοχεύουν στη βελτίωση της απόδοσης και της αξιοπιστίας των προδιαγραφικών μοντέλων κάτι το οποίο αποκτά ακόμη περισσότερη σημασία όταν εφαρμόζεται σε περιβάλλοντα πραγματικού χρόνου και είναι ιδιαίτερα κρίσιμο όταν οι προδιαγραφές υλοποιούνται αυτόματα. Παρόλα αυτά, εξαιτίας των προκλήσεων και της κρίσιμης επιρροής που μπορεί να έχει σε μια επιχείρηση, η κατεύθυνση προς την αυτοματοποίηση των αποφάσεων δεν έχει ακόμη ερευνηθεί. Από τις μελέτες που εξετάστηκαν μόνο μία ασχολείται με την αυτοματοποίηση των προδιαγραφών σε εννοιολογικό επίπεδο (Nechifor et al., 2015).

Μια μεγάλη πρόκληση στον τομέα της αυτοματοποίησης των αποφάσεων αποτελεί το γεγονός ότι η αβεβαιότητα και η πιθανολογική φύση της προδιαγραφικής αναλυτικής μπορεί να οδηγήσει στην υλοποίηση ακατάλληλων για την κάθε περίπτωση ενεργειών. Επιπροσθέτως, κάποια πολύπλοκα πεδία εφαρμογής δεν είναι αρκετά ώριμα για να διαχειριστούν την αυτοματοποίηση των αποφάσεων. Για παράδειγμα, η αυτόματη αναπαραγωγή ενός ακατάλληλου βίντεο μπορεί να ενέχει μικρό ρίσκο. Αντιθέτως η ακατάλληλη παραμετροποίηση ενός βιομηχανικού συστήματος μπορεί να έχει επιβλαβή για την επιχείρηση αποτελέσματα. Στην πρώτη περίπτωση οι αρνητικές επιπτώσεις θα αφορούν την προσωρινή ενόχληση του χρήστη, ενώ στη δεύτερη μια πιθανή αστοχία του βιομηχανικού εξοπλισμού που μπορεί να οδηγήσει σε πολύ υψηλά κόστη ή ακόμη και ατυχήματα μέσα στην επιχείρηση.

Ερευνητική Πρόκληση 11: *Η προδιαγραφική αναλυτική οδηγεί στην αυτοματοποίηση των αποφάσεων, εφόσον οι προκλήσεις της αβεβαιότητας, της δυναμικότητας και της πολυπλοκότητας απαντηθούν κατάλληλα.*

Συνοπτικά οι προτεινόμενες ερευνητικές προκλήσεις παρουσιάζονται στον Πίνακα 2-6.

Προκλήσεις	Ερευνητικές Προκλήσεις
<p>Offline ή σε πραγματικό χρόνο επεξεργασία δεδομένων</p>	<p><u>Ερευνητική Πρόκληση 1:</u> Η ανάπτυξη πληροφοριακών συστημάτων πραγματικού χρόνου, βασισμένα σε δεδομένα μεγάλης κλίμακας και η ανάπτυξη αναδρομικών αλγορίθμων, μπορεί να διευκολύνει την εφαρμογή και υιοθέτηση της προδιαγραφικής αναλυτικής για πολύπλοκα και απαιτητικά προβλήματα.</p> <p><u>Ερευνητική Πρόκληση 2:</u> Η προδιαγραφική αναλυτική μπορεί να επωφεληθεί από την κατανομημένη υπολογιστική η οποία διευκολύνει την επεξεργασία δεδομένων μεγάλης κλίμακας.</p> <p><u>Ερευνητική Πρόκληση 3:</u> Η επεξεργασία ροών δεδομένων και η επεξεργασία πολύπλοκων γεγονότων μπορούν να επιτρέψουν την ανάπτυξη λύσεων προδιαγραφικής αναλυτικής σε περιβάλλοντα με δεδομένα πραγματικού χρόνου.</p>
<p>Ντετερμινιστικά ή πιθανολογικά μοντέλα</p>	<p><u>Ερευνητική Πρόκληση 4:</u> Είναι απαραίτητη η αναγνώριση και διαχείριση της αβεβαιότητας που συναθροίζεται από την αβεβαιότητα των προβλέψεων, τα ελλιπή και με θόρυβο δεδομένα και την υποκειμενικότητα της ανθρώπινης κρίσης που συμμετέχει στη διαδικασία λήψης απόφασης.</p> <p><u>Ερευνητική Πρόκληση 5:</u> Η αβεβαιότητα της προδιαγραφικής αναλυτικής, μπορεί να αναπαρασταθεί με τη βοήθεια πιθανολογικών δομών και μοντέλων</p> <p><u>Ερευνητική Πρόκληση 6:</u> Η προδιαγραφική αναλυτική μπορεί να επωφεληθεί από τον συνδυασμό της πιθανολογικής λογικής με μηχανές επεξεργασίας πολύπλοκων γεγονότων (CEP).</p>

<p>Μοντέλα γνώσης πεδίου ή μοντέλα βασισμένα στα δεδομένα</p>	<p><u>Ερευνητική Πρόκληση 7:</u> Τα προδιαγραφικά μοντέλα έχουν τη δυνατότητα να βασιστούν λιγότερο στη γνώση του ειδικού και περισσότερο στην αναλυτική δεδομένων μεγάλης κλίμακας.</p> <p><u>Ερευνητική Πρόκληση 8:</u> Ο συνδυασμός της γνώσης που παράγεται από αλγορίθμους μηχανικής μάθησης πάνω στα διαθέσιμα δεδομένα, με την γνώση και την εμπειρία των ειδικών του επιστημονικού πεδίου μπορεί να οδηγήσει σε αποδοτικά προδιαγραφικά μοντέλα.</p> <p><u>Ερευνητική Πρόκληση 9:</u> Η υιοθέτηση της προδιαγραφικής αναλυτικής προϋποθέτει την ανάπτυξη δυναμικών προδιαγραφικών μοντέλων, η οποία καθίσταται δυνατή με την αξιοποίηση της τεχνητής νοημοσύνης και της μηχανικής μάθησης.</p>
<p>Στατικά ή δυναμικά προδιαγραφικά μοντέλα</p>	<p><u>Ερευνητική Πρόκληση 10:</u> Οι μηχανισμοί προσαρμοστικότητας των προδιαγραφικών προσεγγίσεων είναι κρίσιμος παράγοντας για την αξιοποίησή τους σε δυναμικά περιβάλλοντα.</p> <p><u>Ερευνητική Πρόκληση 11:</u> Η προδιαγραφική αναλυτική οδηγεί στην αυτοματοποίηση των αποφάσεων, εφόσον οι προκλήσεις της αβεβαιότητας, της δυναμικότητας και της πολυπλοκότητας απαντηθούν κατάλληλα.</p>

Πίνακας 2-6 Ερευνητικές Προκλήσεις

3 Πρόταση Διατριβής

3.1 Ερευνητικά Ερωτήματα

Σε αυτήν την παράγραφο παρουσιάζονται τα ερευνητικά ερωτήματα της παρούσας διδακτορικής διατριβής.

3.1.1 Υποστήριξη προδιαγραφικής αναλυτικής

Αν και η προδιαγραφική αναλυτική παρουσιάζεται σε μεγάλο κομμάτι της βιβλιογραφίας, δεν εμφανίζεται ένας ενιαίος, αυστηρός και καθολικά αναφερόμενος ορισμός της. Πολλές βιβλιογραφικές αναφορές βασίζονται στον αφηρημένο ορισμό της προδιαγραφικής αναλυτικής που παρουσιάζεται στην παράγραφο 1.1, και επιχειρούν την ανάπτυξη προσεγγίσεων εξειδικευμένων για το εξεταζόμενο πρόβλημα. Μιας και η προδιαγραφική αναλυτική παρουσιάζεται ως λύση σε προβλήματα διαφορετικών επιστημονικών τομέων, αρκετές βιβλιογραφικές αναφορές επιχειρούν την καταγραφή και ταξινόμηση των επιστημονικών αντικειμένων που μπορούν να την αξιοποιήσουν. Συγκεκριμένες βιβλιογραφικές αναφορές επιχειρούν το μαθηματικό ορισμό του προβλήματος της προδιαγραφικής αναλυτικής (Bertsimas, και Kallus, 2014) προκειμένου να παρέχουν ένα ενιαίο μοντέλο, ικανό να εφαρμοστεί σε διαφορετικά προβλήματα. Παρόλα αυτά, οι περισσότερες εργασίες της βιβλιογραφίας δε λαμβάνουν υπόψιν τις προαναφερόμενες γενικευμένες μοντελοποιήσεις των προβλημάτων, καθώς μοντελοποιούν το πρόβλημα προδιαγραφικής αναλυτικής κατά περίπτωση έτσι ώστε να είναι δυνατή η επίλυσή του με τις προτεινόμενες μεθόδους.

Αντιστοίχως, με την απουσία ενός ρητού ορισμού των προβλημάτων προδιαγραφικής αναλυτικής αλλά και τις διαφορετικές προσεγγίσεις της διαδικασίας αναλυτικής δεδομένων, τα βήματα που υλοποιούν την προδιαγραφική αναλυτική δεν ορίζονται μονοσήμαντα. Ως εκ τούτου, δεν εντοπίζεται ένας προτυποποιημένος τρόπος ανάπτυξης και εφαρμογής μεθόδων προδιαγραφικής αναλυτικής.

Επίσης, στην πρόκληση αυτή συμβάλλει η αδιευκρίνιστη σχέση και η αλληλεπίδραση της προβλεπτικής αναλυτικής. Αν και η βιβλιογραφία υποδεικνύει την προϋπόθεση υλοποίησης της προβλεπτικής αναλυτικής δεδομένων για την δυνατότητα εφαρμογής προδιαγραφικής αναλυτικής, εντούτοις, δεν παρέχει

προτυποποιημένους τρόπους διασύνδεσης και αξιοποίησης των προβλεπτικών αποτελεσμάτων. Επιπροσθέτως, τα αποτελέσματα της προβλεπτικής αναλυτικής δεδομένων εμπεριέχουν εξ' ορισμού αβεβαιότητα. Η ενσωμάτωσή τους σε μια προσέγγιση προδιαγραφικής αναλυτικής, μεταφέρει την αβεβαιότητα αυτή στις παραγόμενες προδραστικές αποφάσεις. Κατά συνέπεια, όσο καλύτερα μπορέσει μια προσέγγιση να διαχειριστεί αυτήν την αβεβαιότητα τόσο πιο έγκαιρες και αξιόπιστες αποφάσεις θα μπορεί να παράγει. Η ανάπτυξη και αξιολόγηση μεθόδων οδηγούμενης από δεδομένα λήψης αποφάσεων που να μπορούν παράλληλα να ενσωματώσουν τα αποτελέσματα της προβλεπτικής αναλυτικής δεδομένων απορροφώντας την αβεβαιότητα που αυτά επιφέρουν, αποτελούν ένα ανοικτό ερευνητικό θέμα.

Η προδιαγραφική αναλυτική μπορεί να αποτελέσει τη λύση σε πολλά προβλήματα διαφορετικών γνωστικών τομέων, αξιοποιώντας κάποια από τα διαφορετικού είδους δεδομένα, τα οποία δύναται να είναι διαθέσιμα. Η παρούσα διδακτορική διατριβή εστιάζει στην υποστήριξη προβλημάτων προδραστικής λήψης αποφάσεων, στα οποία τα διαθέσιμα δεδομένα μεγάλης κλίμακας ή/και μεγάλης ταχύτητας εμπεριέχουν την απαραίτητη για τη λήψη αποφάσεων πληροφορία. Σε αυτά τα προβλήματα, η εφαρμογή της προδιαγραφικής αναλυτικής μπορεί να ανοίξει το δρόμο για την αυτοματοποίηση της οδηγούμενης από δεδομένα προδραστικής λήψης αποφάσεων.

Το επιχείρημα αυτό ενισχύεται με την αξιοποίηση της μηχανικής μάθησης στην προδιαγραφική ανάλυση. Η εφαρμογή της μηχανικής μάθησης στον τομέα της λήψης αποφάσεων είναι μία από τις σημαντικότερες εφαρμογές στην ιστορία της μηχανικής μάθησης, με σκοπό είτε να υποστηρίξει τους υπεύθυνους λήψης αποφάσεων, είτε να τους αντικαταστήσει (Duan et al., 2019). Μεταξύ άλλων, η εφαρμογή της μηχανικής μάθησης σε προβλήματα προδιαγραφικής αναλυτικής, αναλύεται στο κεφάλαιο 2, όπου εξετάζεται η σχετική βιβλιογραφία, εντοπίζονται οι προκλήσεις της προδιαγραφικής αναλυτικής, παρουσιάζονται οι αλγόριθμοι και οι μέθοδοι προδιαγραφικής αναλυτικής καθώς και οι τομείς εφαρμογής της προδιαγραφικής αναλυτικής που εντοπίζονται στην βιβλιογραφία.

Σύμφωνα με τη μελέτη αυτή (Εικόνα 2-12), η εφαρμογή της μηχανικής μάθησης σε προβλήματα προβλεπτικής αναλυτικής δεδομένων είναι πιο ώριμη, ενώ η αξιοποίησή της για την επίλυση προβλημάτων προδιαγραφικής αναλυτικής έχει ξεκινήσει να ερευνάται. Όπως φαίνεται από τη βιβλιογραφία, η προδιαγραφική αναλυτική απαντάται συνήθως με παραδοσιακές μεθόδους βελτιστοποίησης και συστήματα εμπειρογνωμοσύνης. Κάτι τέτοιο αιτιολογείται λόγω του ότι στις περισσότερες περιπτώσεις δεν υπάρχουν διαθέσιμα δεδομένα άμεσα συσχετισμένα με τη λήψη αποφάσεων. Κατά συνέπεια η οδηγούμενη από δεδομένα λήψη απόφασης δεν είναι εφαρμόσιμη και η λήψη αποφάσεων βασίζεται σε προκαθορισμένα, στατικά μοντέλα και την εμπειρία των ειδικών. Από τις προτεινόμενες μεθόδους μηχανικής μάθησης, η ενισχυτική μάθηση παρουσιάζει σημαντικές προοπτικές αξιοποίησης για την υλοποίηση μεθόδων προδιαγραφικής αναλυτικής, καθώς εξ' ορισμού εστιάζει στις διαδικασίες λήψης αποφάσεων.

Επιπλέον, οι τεχνολογίες δεδομένων μεγάλης κλίμακας εξελίσσονται διαρκώς, επιτρέποντας την συλλογή, συσχέτιση και επεξεργασία δεδομένων από πολλαπλές ετερογενείς πηγές παραγωγής δεδομένων. Το γεγονός αυτό μπορεί να καταστήσει ικανή την συγκέντρωση, αναγνώριση και συνολική διαχείριση των δεδομένων που θα επιτρέψουν την επιτυχή εφαρμογή της προδιαγραφικής αναλυτικής.

Με αφορμή τα παραπάνω, η παρούσα διατριβή εξετάζει πώς η αξιοποίηση της ενισχυτικής μάθησης σε συνδυασμό με τις τεχνολογίες αναλυτικής δεδομένων μεγάλης κλίμακας και τους αλγορίθμους προβλεπτικής αναλυτικής μπορούν να συνδυαστούν για την επίλυση προβλημάτων προδιαγραφικής αναλυτικής, να συνεισφέρουν νέες δυνατότητες και να καθορίσουν εκ νέου τον τομέα της προδιαγραφικής αναλυτικής. Στο κεφάλαιο 4, στην παράγραφο 4.1, συνοψίζεται ο κύκλος ζωής που προτείνεται για την εφαρμογή της προδιαγραφικής αναλυτικής, ενώ στην παράγραφο 4.2 παρουσιάζεται το προτεινόμενο πλαίσιο της διατριβής, που επιτρέπει την ανάπτυξη διαφορετικών μεθόδων προδιαγραφικής αναλυτικής, μέσω της αξιοποίησης της ενισχυτικής μάθησης.

3.1.2 Μοντελοποίηση προβλημάτων προδιαγραφικής αναλυτικής

Πρωταρχικό βήμα σε κάθε μέθοδο προδιαγραφικής αναλυτικής είναι η μοντελοποίηση του προβλήματος βάσει της διαθέσιμης έμπειρης γνώσης, των διαθέσιμων δεδομένων και των αλγορίθμων που θα χρησιμοποιηθούν για την επίλυσή του. Όπως αναφέρεται στην βιβλιογραφική ανασκόπηση, 82% των εξεταζόμενων εργασιών προτείνουν προδιαγραφικά μοντέλα τα οποία αναπτύσσονται από τον ειδικό του επιστημονικού τομέα. Σε αυτά αξιοποιείται αποκλειστικά η γνώση του ειδικού, αγνοώντας άλλα διαθέσιμα δεδομένα ή τα αποτελέσματα της προβλεπτικής αναλυτικής δεδομένων. Ένα προδιαγραφικό μοντέλο που αναπτύσσεται από τον ειδικό συνήθως βασίζεται σε παραδοσιακές μεθόδους βελτιστοποίησης, αγνοώντας την επιπρόσθετη γνώση που προσφέρει στη διαδικασία μοντελοποίησης η εφαρμογή αλγορίθμων μηχανικής μάθησης πάνω σε δεδομένα ετερογενών πηγών. Με αυτό τον τρόπο τα μοντέλα που αναπτύσσονται είναι πιθανό να είναι λιγότερο αποδοτικά καθώς η μοντελοποίηση του ειδικού αποτυπώνει την δική του επιμέρους γνώση, προτίμηση ή διαίσθηση σχετικά με το πρόβλημα. Όπως είναι αναμενόμενο, η γνώση αυτή μπορεί να είναι ελλιπής ή λανθασμένη και να μην καλύπτει όλες τις περιπτώσεις του εξεταζόμενου προβλήματος. Επιπροσθέτως, τα προδιαγραφικά μοντέλα αυτών των προσεγγίσεων έχουν περιορισμένες δυνατότητες προσαρμογής και επέκτασης σε διαφορετικές περιπτώσεις του ίδιου προβλήματος καθώς και περιορισμένες δυνατότητες εφαρμογής σε προβλήματα διαφορετικών επιστημονικών πεδίων.

Η αντιμετώπιση των προκλήσεων αυτών αποτελεί αντικείμενο της έρευνας της παρούσας διατριβής μιας και μπορεί να επιτρέψει την αυτοματοποίηση της προδιαγραφικής αναλυτικής και κατ' επέκταση την ανάπτυξη πληροφοριακών συστημάτων τα οποία μπορούν να υποστηρίξουν και να αυτοματοποιήσουν πολλαπλές διαδικασίες λήψης αποφάσεων.

Η ενισχυτική μάθηση μπορεί να βοηθήσει σημαντικά στην ανάπτυξη μεθόδων δυναμικής μοντελοποίησης προβλημάτων προδιαγραφικής αναλυτικής και να υποστηρίξει προβλήματα μεγάλου όγκου δεδομένων και αποφάσεων υψηλής πολυπλοκότητας. Σύμφωνα με την βιβλιογραφία που αναλύεται στην παράγραφο 5.1, η ενισχυτική μάθηση μπορεί να αξιοποιηθεί σε δύο τύπους προβλημάτων: σε

προβλήματα βασισμένα σε μοντέλο και σε προβλήματα ανεξάρτητα μοντέλου. Με την ενισχυτική μάθηση μπορούμε να αξιοποιήσουμε τη γνώση του ειδικού σε συνδυασμό με τα διαφορετικά δεδομένα που επηρεάζουν τη διαδικασία λήψης αποφάσεων, συμπεριλαμβανομένων των προβλεπτικών αποτελεσμάτων, προκειμένου να κατασκευάσουμε ένα δυναμικό και αποδοτικό μοντέλο προδιαγραφικής αναλυτικής, ικανό να επιλύει διαφορετικές περιπτώσεις ενός ή περισσότερων προβλημάτων. Στην παρούσα εργασία, η μοντελοποίηση του προβλήματος με την εφαρμογή της ενισχυτικής μάθησης βασίζεται στις Μαρκοβιανές Διαδικασίες Απόφασης.

Στο Κεφάλαιο 4 της διατριβής προτείνεται ένα νέο πλαίσιο προδιαγραφικής αναλυτικής, βασισμένο στην ενισχυτική μάθηση, μέσω του οποίου μπορεί να υποστηριχθεί η ανάπτυξη μεθόδων ικανών να μοντελοποιήσουν και να επιλύσουν προβλήματα προδιαγραφικής αναλυτικής διαφορετικών περιπτώσεων. Στην προτεινόμενη μέθοδο που αναπτύσσεται σύμφωνα με το πλαίσιο και περιγράφεται αναλυτικά στο κεφάλαιο 4, παρουσιάζονται τα βήματα ανάπτυξης του προδιαγραφικού μοντέλου με τη μορφή μιας μαρκοβιανής διαδικασίας απόφασης. Με την προτεινόμενη μοντελοποίηση, υποστηρίζεται η ενσωμάτωση των προβλεπτικών αποτελεσμάτων, των διαθέσιμων δεδομένων του προβλήματος, της γνώσης του ειδικού καθώς και η μοντελοποίηση των επιλεγμένων κριτηρίων βελτιστοποίησης σύμφωνα με τα οποία αναμένεται να λαμβάνονται οι αποφάσεις. Με τον τρόπο αυτό, η προτεινόμενη μέθοδος μπορεί να κατασκευάσει δυναμικά προδιαγραφικά μοντέλα ικανά να αντιμετωπίσουν προβλήματα διαφορετικών επιστημονικών αντικειμένων.

3.1.3 Πολλαπλά κριτήρια και στόχοι σε προβλήματα προδιαγραφικής αναλυτικής

Σε αρκετά προβλήματα προδιαγραφικής αναλυτικής εμφανίζεται η ανάγκη ικανοποίησης πολλαπλών κριτηρίων και στόχων από τις παραγόμενες αποφάσεις. Το πρόβλημα αυτό απασχολεί σημαντικό μέρος της βιβλιογραφίας της λήψης αποφάσεων και αναπόφευκτα εγείρει το ερευνητικό ενδιαφέρον του τομέα της προδιαγραφικής αναλυτικής. Αρκετές βιβλιογραφικές αναφορές προσεγγίζουν την ενσωμάτωση ποικίλων κριτηρίων βελτιστοποίησης με διαφορετικό τρόπο κατά περίπτωση, ανάλογα με το εξεταζόμενο πρόβλημα. Η μοντελοποίηση των πολλαπλών

κριτηρίων του προβλήματος καθώς και η μέθοδος διαχείρισής τους αποτελούν μία κρίσιμη σχεδιαστική επιλογή η οποία θα επηρεάσει τη μορφή των παραγόμενων προδιαγραφών και θα προσδιορίσει το είδος της πληροφορίας που αυτές περιέχουν. Αντίθετα με τις παραδοσιακές μεθόδους λήψης αποφάσεων στις οποίες βασικό ρόλο στην επιλογή της τελικής απόφασης κατέχει ο αποφασίζων, η κατάλληλη μοντελοποίηση μπορεί να επιτρέψει την ανεξαρτητοποίηση της μεθόδου από τη συνεχή επίβλεψη του αποφασίζοντα, διευκολύνοντας έτσι την αυτοματοποίηση της επίλυσης του συγκεκριμένου προβλήματος προδιαγραφικής αναλυτικής.

Η παρούσα διατριβή ερευνά τους τρόπους μοντελοποίησης και ενσωμάτωσης πολλαπλών κριτηρίων βελτιστοποίησης σε προβλήματα προδιαγραφικής αναλυτικής. Στοχεύει να ερευνήσει τους τρόπους με τους οποίους μπορούν να επιλυθούν απαιτητικά προβλήματα προδιαγραφικής αναλυτικής τα οποία ικανοποιούν ταυτόχρονα πολλαπλούς στόχους. Επιπλέον εστιάζει σε μεθόδους που δεν εξαρτώνται από την παρέμβαση του αποφασίζοντα, παράγοντας μία λύση η οποία ικανοποιεί κατά το βέλτιστο δυνατό τρόπο τα επιλεγμένα κριτήρια, διευκολύνοντας έτσι την αυτοματοποίηση της διαδικασίας επίλυσης. Για το σκοπό αυτό, στο πλαίσιο που παρουσιάζεται στο κεφάλαιο 4 προτείνεται η αξιοποίηση του τομέα της ενισχυτικής μάθησης πολλαπλών κριτηρίων, ενώ στην προτεινόμενη μέθοδο που αναπτύσσεται στο κεφάλαιο 5 αναλύεται η εφαρμογή της για την κατασκευή και επίλυση προδιαγραφικών μοντέλων πολλαπλών κριτηρίων.

3.1.4 Αξιοποίηση προτίμησης του ανθρώπου στην προδιαγραφική αναλυτική

Οι εφαρμογές της μηχανικής μάθησης μπορούν να υποστηρίξουν τη λήψη αποφάσεων υιοθετώντας διαφορετικούς ρόλους. Για παράδειγμα, παρέχοντας βοήθεια, αξιολόγηση, δεύτερη γνώμη, εξειδικευμένες συμβουλές, καθοδήγηση αλλά ακόμα και αναλαμβάνοντας την αυτοματοποίηση της λήψης και της εκτέλεσης των αποφάσεων (Duan et al., 2019). Η πρόσφατη έρευνα καταλήγει ότι τα συστήματα αυτοματοποιημένης λήψης αποφάσεων με τεχνητή νοημοσύνη αδυνατούν να υποκαταστήσουν πλήρως τον άνθρωπο. Τα συστήματα αυτά διαθέτουν την υπολογιστική ικανότητα για την εξαγωγή της χρήσιμης πληροφορίας από τα διαθέσιμα δεδομένα και τον προσδιορισμό αποφάσεων σύμφωνα με λογικούς

κανόνες και παραμέτρους. Ωστόσο, δε διαθέτουν το αίσθημα ευθύνης, τη δυνατότητα αξιολόγησης του ρίσκου, τη διαίσθηση ή την κοινή λογική, προσόντα τα οποία έχει ο άνθρωπος, και τα οποία σε συνδυασμό με τη διαθέσιμη σε αυτόν γνώση χρησιμοποιεί για να λαμβάνει τις ζητούμενες αποφάσεις.

Η παρούσα διατριβή ασχολείται με τον ρόλο της ανάδρασης του ανθρώπου στην προδιαγραφική αναλυτική και τους τρόπους αξιοποίησής της. Η προτίμηση ενός ανθρώπου μπορεί να μεταβάλλεται, να εξαρτάται από πολλές παραμέτρους και να μη μπορεί να μοντελοποιηθεί με κάποια από τις υπάρχουσες μεθόδους μοντελοποίησης. Επιπλέον, η προτίμηση του ανθρώπου μπορεί να μην είναι ποσοτικοποιήσιμη, να μην εμπεριέχεται στα διαθέσιμα δεδομένα αλλά σαφώς να επηρεάζει τις προδραστικές αποφάσεις που καλείται να παράγει η μέθοδος. Η ανάδραση του ανθρώπου πάνω στις παραγόμενες προδιαγραφές εμπεριέχει την προτίμησή του, πάνω στο εξεταζόμενο πρόβλημα, χωρίς να απαιτεί τον ρητό ορισμό της. Η παρούσα μελέτη εστιάζει στους τρόπους μοντελοποίησης της αξιολογικής ανάδρασης (evaluative feedback) του ανθρώπου. Επιπροσθέτως, εξετάζει πώς αυτή μπορεί να συνδυαστεί με τα πολλαπλά κριτήρια προκειμένου να σχεδιαστεί μια προδιαγραφική μέθοδος ικανή να παράγει προδιαγραφές που ικανοποιούν τόσο τους επιλεγμένους στόχους όσο και την προτίμηση του ανθρώπου.

Πιο συγκεκριμένα, το πλαίσιο που παρουσιάζει η παρούσα διατριβή και η προδιαγραφική μέθοδος που αναπτύχθηκε, εστιάζουν στους πιθανούς τρόπους προτυποποίησης και ενσωμάτωσης της προτίμησης του ανθρώπου στη διαδικασία λήψης αποφάσεων. Στην πρόταση της διατριβής, η προτίμηση του ανθρώπου λαμβάνεται υπόψιν και αναπροσαρμόζει την προδιαγραφική μέθοδο, μέσω της ενσωμάτωσης της αξιολόγησης των παραγόμενων προδιαγραφών που παρέχει ο άνθρωπος.

Στον Πίνακα 3-1 συγκεντρώνονται τα ερευνητικά ερωτήματα στα οποία εστιάζει η παρούσα διδακτορική διατριβή.

Ερώτημα	Επιμέρους Ερωτήματα
---------	---------------------

<p>Υποστήριξη προδιαγραφικής αναλυτικής</p>	<ul style="list-style-type: none"> - Σε ποια προβλήματα μπορεί να εφαρμοστεί η προδιαγραφική αναλυτική - Ποια βήματα ακολουθούνται στην προδιαγραφική αναλυτική - Πως συνδέεται η προβλεπτική με την προδιαγραφική αναλυτική - Πως αξιοποιείται η μηχανική μάθηση στην προδιαγραφική αναλυτική - Ποιες μέθοδοι/αλγόριθμοι έχουν προταθεί από την βιβλιογραφία - Πως αναπτύσσονται δυναμικές μέθοδοι προδιαγραφικής αναλυτικής, βασισμένες στην αξιοποίηση της μηχανικής μάθησης
<p>Μοντελοποίηση προβλημάτων προδιαγραφικής αναλυτικής</p>	<ul style="list-style-type: none"> - Πως μπορεί να αξιοποιηθεί η ενισχυτική μάθηση για τη μοντελοποίηση και επίλυση προβλημάτων προδιαγραφικής αναλυτικής - Ποια βήματα/μεθοδολογία μπορούν να υλοποιήσουν την δυναμική μοντελοποίηση και την επίλυση προβλημάτων προδιαγραφικής αναλυτικής
<p>Πολλαπλά κριτήρια και στόχοι σε προβλήματα προδιαγραφικής αναλυτικής</p>	<ul style="list-style-type: none"> - Πως μοντελοποιούνται τα διαφορετικά κριτήρια και στόχοι του προβλήματος - Πως μπορούν να επιλυθούν απαιτητικά προβλήματα προδιαγραφικής αναλυτικής ικανοποιώντας ταυτόχρονα πολλαπλούς στόχους: <ul style="list-style-type: none"> - χωρίς την ανάγκη της παρέμβασης του αποφασίζοντα για την παροχή

	<p>της προτίμησής του ως προς τα απαιτούμενα κριτήρια</p> <ul style="list-style-type: none"> - παράγοντας μία λύση που ικανοποιεί πολλαπλά κριτήρια - αυτοματοποιώντας τη διαδικασία επίλυσης
Αξιοποίηση προτίμησης του ανθρώπου στην προδιαγραφική αναλυτική	<ul style="list-style-type: none"> - Ποιος είναι ο ρόλος της ανάδρασης του ανθρώπου και πως αξιοποιείται στην προδιαγραφική αναλυτική - Πως μοντελοποιείται η αξιολογική ανάδραση του ανθρώπου - Πως μπορεί η προδιαγραφική αναλυτική να λάβει υπόψιν τις προτιμήσεις του ειδικού χωρίς τον ρητό ορισμό τους - Πως μπορεί η προδιαγραφική αναλυτική να προδιαγράψει αποφάσεις που ακολουθούν τις προτιμήσεις του ειδικού και παράλληλα ικανοποιούν τους ζητούμενους στόχους. - Πως μπορεί να προτυποποιηθεί η διαδικασία συλλογής και ενσωμάτωσης της ανάδρασης του ανθρώπου

Πίνακας 3-1 Ερευνητικά Ερωτήματα

3.2 Πρόταση Διατριβής

Σκοπός της παρούσας διατριβής είναι η ανάπτυξη ενός πλαισίου προδιαγραφικής αναλυτικής και της αντίστοιχης προτεινόμενης μεθόδου, ώστε να απαντηθούν τα παραπάνω ερευνητικά ερωτήματα.

Το πλαίσιο της διατριβής έχει στόχο να καθοδηγήσει την ανάπτυξη διαφορετικών προδιαγραφικών μεθόδων οι οποίες ικανοποιούν όλα τα παρακάτω:

- Επίλυση προβλημάτων μεγάλου χώρου καταστάσεων,
- Υποστήριξη προβλημάτων λήψης αποφάσεων με πολλές, πιθανώς μεταβαλλόμενες και συγκρουόμενες εναλλακτικές,
- Μοντελοποίηση της διαδικασίας λήψης αποφάσεων με επεκτάσιμα και προσαρμόσιμα μοντέλα τα οποία ενδέχεται μεταβάλλονται με την πάροδο του χρόνου.
- Εφαρμογή της οδηγούμενης από δεδομένα λήψης αποφάσεων,
- Αξιοποίηση των αποτελεσμάτων της προβλεπτικής αναλυτικής δεδομένων στη λήψη αποφάσεων,
- Ενσωμάτωση περισσότερων δεδομένων περιβάλλοντος στη διαδικασία λήψης αποφάσεων. Συνδυασμός της γνώσης του ειδικού με τα διαθέσιμα δεδομένα που επηρεάζουν τη λήψη αποφάσεων.
- Παραγωγή προδραστικών αποφάσεων, βελτιστοποιημένων ως προς πολλαπλά κριτήρια ακολουθώντας παράλληλα την προτίμηση του ειδικού, χωρίς αυτή να ορίζεται ρητά εκ των προτέρων, μιας και ο προδιαγραφικός μηχανισμός προσαρμόζεται από την ανάδραση του ειδικού.

Όταν η προτεινόμενη μέθοδος καλείται να παράγει μια απόφαση είναι καλύτερα ενημερωμένη και παραμετροποιημένη σύμφωνα με την τρέχουσα κατάσταση του περιβάλλοντος και των παραμέτρων που το περιγράφουν. Παράλληλα λαμβάνει υπόψιν τις προβλέψεις που είναι διαθέσιμες σχετικά με τη μελλοντική κατάσταση του περιβάλλοντος. Οι αποφάσεις που παράγονται με αυτό τον τρόπο εκμεταλλεύονται όχι μόνο τη μέγιστη δυνατή πληροφορία του παρόντος αλλά και την πληροφορία που είναι διαθέσιμη για το μέλλον. Κάθε απόφαση που παράγεται είναι προσαρμοσμένη αποκλειστικά για τη δεδομένη κατάσταση, μιας και το προδιαγραφικό μοντέλο που ορίζεται σύμφωνα με την προτεινόμενη μοντελοποίηση λαμβάνει υπόψιν όλες τις παραπάνω πληροφορίες και προσαρμόζεται στα δεδομένα αυτά.

Επιπλέον, το πλαίσιο και η προτεινόμενη μέθοδος δεν αναπτύσσονται σε ένα επιστημονικό πεδίο, αντιθέτως μπορούν να βρουν εφαρμογή σε πολλά προβλήματα,

διαφορετικών επιστημονικών τομέων. Στο πλαίσιο της παρούσας διατριβής, η προτεινόμενη μέθοδος που αναπτύσσεται στο κεφάλαιο 5, εφαρμόζεται στο πεδίο των χρηματιστηριακών επενδύσεων.

Ακολουθώντας τα ευρήματα της βιβλιογραφικής ανασκόπησης του Κεφαλαίου 2, η βασική συνεισφορά της διατριβής είναι ένα πλαίσιο για την προδιαγραφική αναλυτική το οποίο βασίζεται στη διαδραστική ενισχυτική μάθηση πολλαπλών κριτηρίων. Μέσω της αξιοποίησης του τομέα της ενισχυτικής μάθησης, των τεχνολογιών δεδομένων μεγάλης κλίμακας και των εξελίξεων της προβλεπτικής αναλυτικής, επιτρέπει την οδηγούμενη από δεδομένα συνεργασία ανθρώπου-τεχνητής νοημοσύνης για τη βελτιστοποίηση και αυτοματοποίηση της λήψης αποφάσεων.

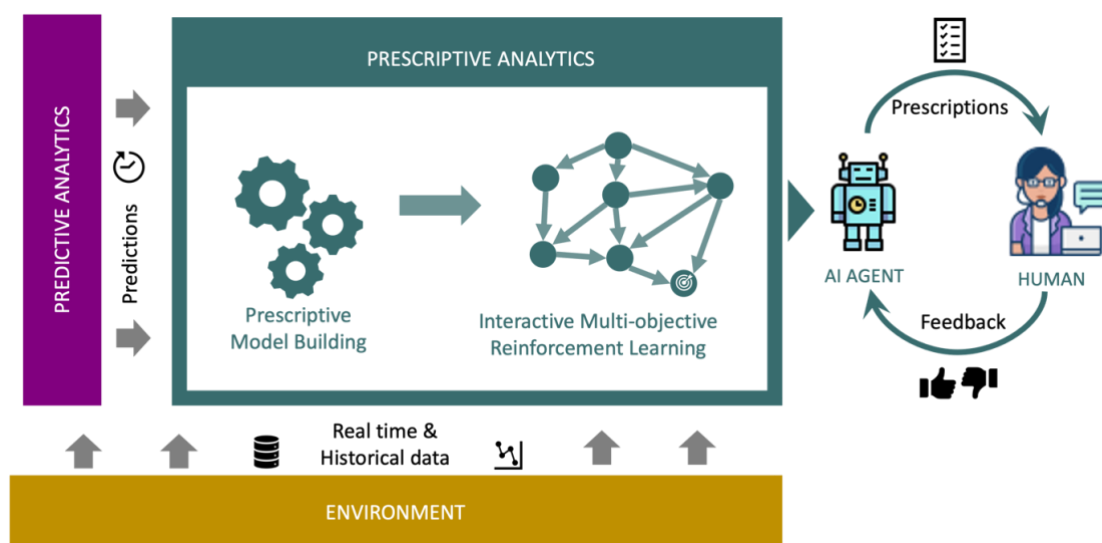
Με τη βοήθεια της ενισχυτικής μάθησης μπορούν να επιλυθούν προβλήματα πολλών παραμέτρων με αντιστοίχως πολύπλοκο περιβάλλον ή ακόμα και με δυναμικά μεταβαλλόμενα περιβάλλοντα (Padakandla, 2021). Επιπλέον, με την αξιοποίηση αλγορίθμων ενισχυτικής μάθησης μπορούμε να επιλύσουμε προβλήματα προδιαγραφικής αναλυτικής που βασίζονται σε δεδομένα ροών μεγάλης ταχύτητας και να υποστηρίξουμε την λήψη αποφάσεων σε πραγματικό χρόνο. Επιπροσθέτως, επιτρέπεται η διαχείριση μεγάλου αριθμού ταυτόχρονων προδιαγραφικών προβλημάτων και, αυτοματοποιώντας την προτεινόμενη προσέγγιση, η λήψη πολλών παράλληλων αποφάσεων. Κάτι τέτοιο μπορεί να οδηγήσει στην εκμετάλλευση πολλών μελλοντικών γεγονότων, στην αποφυγή ανεπιθύμητων γεγονότων ταυτόχρονα, και στην επίλυση προβλημάτων μεγάλης κλίμακας που απαιτούν γρήγορες και μαζικές αποφάσεις.

Η παραδοσιακή ενισχυτική μάθηση δεν μπορεί να ικανοποιήσει τέτοιες απαιτήσεις καθώς η βέλτιστη συμπεριφορά του πράκτορα προκύπτει από τον εκ των προτέρων καθορισμό της συνάρτησης ανταμοιβής. Οι περισσότεροι άνθρωποι αδυνατούν να σχεδιάσουν ή να προγραμματίσουν τη συνάρτηση ανταμοιβής μιας και δεν έχουν την κατάλληλη γνώση. Η διαδραστική ενισχυτική μάθηση αποτελεί έναν νέο τομέα της ενισχυτικής μάθησης που μπορεί να επιτρέψει την εκπαίδευση των πρακτόρων ενισχυτικής μάθησης σύμφωνα με τις προτιμήσεις του ανθρώπου (Arzate, και Igarashi, 2020; Griffith et al., 2013). Ένας άνθρωπος μπορεί να μην έχει

τις γνώσεις που απαιτούνται για τον προγραμματισμό ενός πράκτορα ενισχυτικής μάθησης όμως κατέχει χρήσιμη πληροφορία και εμπειρία που αφορούν το πρόβλημα απόφασης. Η ταυτόχρονη αξιοποίηση αυτής της πληροφορίας και η σύνθεσή της με τις τεχνικές της διαδραστικής ενισχυτικής μάθησης μπορεί να μειώσει τον χρόνο αναζήτησης και να επιταχύνει τη διαδικασία εκμάθησης του πράκτορα.

Επιπλέον, με την ενσωμάτωση της ανάδρασης του χρήστη στον προδιαγραφικό μηχανισμό, κατασκευάζουμε προδιαγραφικά μοντέλα που δεν εξαρτώνται από έναν συγκεκριμένο άνθρωπο αλλά από πολλούς εμπειρογνώμονες, δεν απαιτούν τη ρητή αποτύπωση των προτιμήσεων των ανθρώπων και προσαρμόζονται κατάλληλα καθώς αυτές μεταβάλλονται. Η διαδραστική ενισχυτική μάθηση σε συνδυασμό με τη βελτιστοποίηση πολλαπλών κριτηρίων που προσφέρει η εφαρμογή της ενισχυτικής μάθησης πολλαπλών κριτηρίων, επιτυγχάνει μία ισορροπία μεταξύ της αντικειμενικά βέλτιστης απόφασης για το εξεταζόμενο πρόβλημα και της προτίμησης του αποφασίζοντα.

Στην Εικόνα 3-1 αποτυπώνεται συνοπτικά η προσέγγιση της διατριβής.



Εικόνα 3-1 Πρόταση Διατριβής

Στην προσέγγιση της διατριβής, θεωρούμε ένα πρόβλημα λήψης αποφάσεων στο οποίο υπάρχουν διαθέσιμα δεδομένα που περιγράφουν το περιβάλλον του προβλήματος και αντιστοιχούν είτε σε δεδομένα πραγματικού χρόνου ή σε ιστορικά δεδομένα. Ο οργανισμός αξιοποιεί τα δεδομένα αυτά με την ανάπτυξη τεχνικών προβλεπτικής αναλυτικής δεδομένων προκειμένου να παράγει προβλέψεις σχετικά

με τη μελλοντική συμπεριφορά του περιβάλλοντος. Κάποια από τα προβλεπτικά αποτελέσματα μπορούν να καθοδηγήσουν την προδραστική λήψη αποφάσεων ούτως ώστε ο οργανισμός να λάβει έγκυρες και ενήμερες αποφάσεις, βασισμένες στα διαθέσιμα δεδομένα. Τα αποτελέσματα της προβλεπτικής αναλυτικής που επηρεάζουν τη λήψη αποφάσεων σε συνδυασμό με τα δεδομένα του προβλήματος δίνονται ως είσοδος στην προσέγγιση της προδιαγραφικής αναλυτικής που αναπτύσσει η παρούσα διατριβή. Η πρόταση της διατριβής αναλαμβάνει την κατασκευή του προδιαγραφικού μηχανισμού ο οποίος βασίζεται στην διαδραστική ενισχυτική μάθηση πολλαπλών κριτηρίων. Ο προδιαγραφικός μηχανισμός κατασκευάζει έναν πράκτορα ενισχυτικής μάθησης, ο οποίος παράγει προδιαγραφές που αποτελούν τις προτεινόμενες αποφάσεις επίλυσης του εξεταζόμενου προβλήματος.

Ο άνθρωπος λαμβάνει τις προδιαγραφές και παρέχει την ανάδρασή του, με την οποία αξιολογεί την προτεινόμενη απόφαση του πράκτορα. Ο προδιαγραφικός μηχανισμός αναπροσαρμόζεται σύμφωνα με την λαμβανόμενη ανάδραση του χρήστη, προκειμένου να παράγει αποφάσεις που επιλύουν το εξεταζόμενο πρόβλημα ικανοποιώντας παράλληλα τις προτιμήσεις ή τη γνώση του ανθρώπου, οι οποίες εκφράζονται έμμεσα από την παρεχόμενη ανάδρασή του.

4 Πλαίσιο Διατριβής

4.1 Κύκλος Ζωής Προδιαγραφικής Αναλυτικής Δεδομένων

Στην παρούσα παράγραφο παρουσιάζονται τα βήματα που αποτελούν τον κύκλο ζωής της προδιαγραφικής αναλυτικής. Ο στόχος είναι να προσδιοριστούν σαφώς τα απαιτούμενα βήματα της διαδικασίας εφαρμογής της προχωρημένης αναλυτικής δεδομένων, και κατ' επέκταση της προδιαγραφικής αναλυτικής. Βάσει αυτών μπορούμε να διασφαλίσουμε ότι το πλαίσιο της διατριβής συμβαδίζει με τις επιχειρηματικές απαιτήσεις της αναλυτικής δεδομένων και να τεκμηριώσουμε τη συνέπειά του με αυτές.

Για να προσδιορίσουμε τον κύκλο ζωής της προδιαγραφικής αναλυτικής, ξεκινάμε με την αναγνώριση των βημάτων του κύκλου ζωής της αναλυτικής δεδομένων. Στη βιβλιογραφία παρουσιάζονται αρκετές διαφορετικές περιγραφές και προτάσεις του κύκλου ζωής της αναλυτικής ή της διαδικασίας αναλυτικής δεδομένων (Erl et al. 2015; SAS 2016; Storey και Song 2017; Seddon et al. 2017; Prat, 2019). Οι εργασίες αυτές εξετάζουν τον κύκλο ζωής της αναλυτικής δεδομένων από διαφορετικές σκοπιές και ακολουθούν διαφορετικά πρότυπα, με την πλειοψηφία να βασίζεται στο CRISP-DM μοντέλο της διαδικασίας εξόρυξης δεδομένων (Shearer, 2000). Η αναλυτική δεδομένων, όπως και η εξόρυξη δεδομένων δεν είναι μια τεχνολογία καθολικά εφαρμόσιμη με την ίδια μορφή, αλλά είναι μια πολύπλοκη διαδικασία, εξατομικευμένη για κάθε έργο, η οποία απαιτεί τη συμμετοχή διαφόρων εργαλείων και ανθρώπινων πόρων. Η επιτυχία ενός έργου αναλυτικής δεδομένων εξαρτάται όχι μόνο από τα διαθέσιμα δεδομένα αλλά κατά κανόνα από την επιλογή κατάλληλων εργαλείων και εξειδικευμένων αναλυτών.

Το Cross Industry Standard Process for Data Mining (CRISP-DM) είναι ένα μοντέλο διαδικασίας το οποίο παρέχει το πλαίσιο για τη διεξαγωγή έργων εξόρυξης δεδομένων ανεξαρτήτως του τομέα και των τεχνολογιών που θα χρησιμοποιηθούν (Wirth, και Hipp, 2000). Το μοντέλο αυτό συμβάλλει στην καλύτερη κατανόηση και διαχείριση της πολύπλοκης διαδικασίας της εξόρυξης δεδομένων, καθώς προσφέρει καθοδήγηση στους αναλυτές προκειμένου να εξοικειωθούν με τα βήματα της διαδικασίας και να εξασφαλίσουν την ποιότητα του έργου που αναπτύσσουν. Το

CRISP-DM αποτελείται από έξι φάσεις, την φάση της κατανόησης της επιχείρησης (Business Understanding), την φάση της κατανόησης των δεδομένων (Data Understanding), την φάση της προετοιμασίας των δεδομένων (Data Preparation), την φάση της μοντελοποίησης (Modeling), της αξιολόγησης (Evaluation) και της εφαρμογής (Deployment).

Η φάση της κατανόησης της επιχείρησης εστιάζει στην κατανόηση των στόχων και των απαιτήσεων του προς ανάπτυξη έργου εξόρυξης δεδομένων και οριοθετεί ένα πρώτο πλάνο του έργου. Η φάση αυτή ξεκινά με τη συλλογή των δεδομένων και τις απαραίτητες ενέργειες έτσι ώστε ο αναλυτής να εξοικειωθεί με τα διαθέσιμα δεδομένα, να εντοπίσει πιθανά προβλήματα και να εκτιμήσει την πληροφορία που μπορεί να εξάγει από αυτά. Η φάση της προετοιμασίας των δεδομένων στοχεύει στην κατασκευή του τελικού συνόλου δεδομένων, συνθέτοντας και μετασχηματίζοντας τα αρχικά δεδομένα, το οποίο θα έχει την κατάλληλη μορφή για περαιτέρω ανάλυση. Την φάση της προετοιμασίας ακολουθεί η μοντελοποίηση των μετασχηματισμένων δεδομένων, που αντιπροσωπεύει την βασική φάση υλοποίησης της εξόρυξης δεδομένων. Τα παραγόμενα μοντέλα αξιολογούνται ως προς την ποιότητα των αποτελεσμάτων τους στη φάση της αξιολόγησης. Στη συνέχεια, με τη φάση της εφαρμογής, οι αντίστοιχες αναλύσεις ενσωματώνονται στο επιχειρησιακό περιβάλλον του οργανισμού.

Το μοντέλο CRISP-DM τροποποιείται και επεκτείνεται από πολλές μελέτες της βιβλιογραφίας προκειμένου να εστιάσει στην υλοποίηση της αναλυτικής δεδομένων. Υπό το πρίσμα της ευρύτερης αναλυτικής δεδομένων και των δεδομένων μεγάλης κλίμακας, οι Song, I. Y., και Zhu (2016) επεκτείνουν το μοντέλο CRISP-DM, αντικαθιστώντας το βήμα της μοντελοποίησης με δύο βήματα: την σχεδίαση του μοντέλου (Model Planning) και την κατασκευή του μοντέλου (Model Building). Με τον τρόπο αυτό διαχωρίζουν την έρευνα και την επιλογή του κατάλληλου αλγορίθμου, τεχνικών και παραμέτρων από την ανάπτυξή του για την συγκεκριμένη μελέτη. Επιπλέον, εισάγουν το βήμα της ανασκόπησης και παρακολούθησης (Review & Monitoring) μετά τη φάση της εφαρμογής. Σε μια πιο πρόσφατη μελέτη, οι Raghurathi, και Raghurathi (2021) προτείνουν μια μεθοδολογία επιχειρηματικής αναλυτικής δεδομένων αποτελούμενη από τέσσερα βασικά στάδια, η οποία είναι

ανεξάρτητη από το βασικό μοντέλο CRISP-DM. Τα στάδια της μεθοδολογίας είναι η σχεδίαση ιδέας (Concept Design), η προτεινόμενη προσέγγιση (Proposal), η υλοποίηση (Implementation) και η παρουσίαση και αξιολόγηση (Presentation and Evaluation).

Στην παρούσα παράγραφο, περιγράφεται ο κύκλος ζωής της προδιαγραφικής αναλυτικής, ο οποίος αναπτύσσεται συνθέτοντας τα προαναφερθέντα μοντέλα προκειμένου να παρέχει μια υψηλού επιπέδου οπτική του κύκλου ζωής της προδιαγραφικής αναλυτικής. Στην Εικόνα 4-1 παρουσιάζεται ο κύκλος ζωής οκτώ βημάτων,. Ο προτεινόμενος κύκλος ζωής αποτελείται από τα εξής βήματα:



Εικόνα 4-1 Κύκλος Ζωής Προδιαγραφικής Αναλυτικής Δεδομένων

Βήμα 1 – Καθορισμός Επιχειρηματικών Στόχων:

Στην πρώτη φάση του κύκλου ζωής αναγνωρίζεται το πρόβλημα το οποίο επιθυμούμε να επιλύσουμε με την υλοποίηση της αναλυτικής δεδομένων, έτσι ώστε να επιτευχθεί ο αντίστοιχος επιχειρηματικός στόχος. Ως επιχειρηματικός στόχος νοείται ένας στόχος της επιχείρησης τον οποίο προσδοκά να επιτύχει σε ένα

συγκεκριμένο χρονικό πλαίσιο. Οι επιχειρηματικοί στόχοι εντάσσονται σε διάφορες κατηγορίες ανάλογα με τον επιχειρηματικό τομέα της επιχείρησης και μπορεί να αφορούν τα οικονομικά της επιχείρησης, τη λειτουργία της ή ακόμη και το πελατολόγιο της. Κοινή συνισταμένη των επιχειρηματικών στόχων μιας επιχείρησης είναι ότι η υλοποίησή τους συνεισφέρει στην ευρύτερη εξέλιξη της επιχείρησης. Οι επιχειρηματικοί στόχοι ενδέχεται να εκφράζονται από μετρήσιμα μεγέθη που αφορούν την επιχείρηση ή να μην είναι εφικτός ο προσδιορισμός τους με τη βοήθεια κάποιου μεγέθους. Παραδείγματα επιχειρηματικών στόχων είναι η αύξηση του συνολικού κέρδους της επιχείρησης, η αύξηση της δημοτικότητας μια επιχείρησης, η επέκταση της επιχειρηματικής δραστηριότητας της επιχείρησης σε περισσότερες χώρες κ.ό.κ.

Σε αυτό το βήμα καθορίζονται οι ερωτήσεις που καλείται να απαντήσει η προς ανάπτυξη εφαρμογή της αναλυτικής δεδομένων. Συνήθως εξετάζονται ερωτήσεις σχετικές με το πρόβλημα προς επίλυση, όπως ποια είναι η φύση του προβλήματος, γιατί είναι κρίσιμο αυτό το πρόβλημα για την επιχείρηση, και πως η αναλυτική δεδομένων μπορεί να επιλύσει αυτό το πρόβλημα (Raghupathi, και Raghupathi, 2021).

Βήμα 2 – Καθορισμός και Συλλογή Δεδομένων:

Στη δεύτερη φάση ο οργανισμός καλείται να αναγνωρίσει τα δεδομένα που περιέχουν την πληροφορία που είναι ικανή να απαντήσει τις καθορισμένες ερωτήσεις και εν συνεχεία να υλοποιήσει τις διαδικασίες συλλογής τους. Η επιλογή και η συλλογή των κατάλληλων δεδομένων είναι μια κρίσιμη απόφαση η οποία επιφέρει σημαντικά διαχειριστικά κόστη σχετικά με την παραγωγή, συλλογή, επεξεργασία και διατήρηση των συνόλων δεδομένων. Τα κόστη αυτά αυξάνουν στην περίπτωση της συλλογής και διαχείρισης δεδομένων μεγάλης κλίμακας. Χαρακτηριστικό παράδειγμα τέτοιου κόστους είναι η επιλογή της χρήσης αισθητήρων ως βασική πηγή δεδομένων, η οποία προϋποθέτει την υιοθέτηση αισθητήρων σε μια γραμμή παραγωγής. Η τοποθέτηση αισθητήρων αποτελεί μια κοστοβόρα και χρονοβόρα διαδικασία καθώς εκτός από την αρχική εγκατάσταση απαιτεί εξειδικευμένο προσωπικό για την διαχείριση των αισθητήρων και των αντίστοιχων δεδομένων.

Επιπλέον, τα παραδοσιακά συστήματα επιχειρηματικής ευφυΐας υποθέτουν ότι ο χρήστης γνωρίζει τις ερωτήσεις που επιθυμεί να απαντήσει καθώς και το είδος και τη δομή της αντίστοιχης ανάλυσης. Κατ' επέκταση ο χρήστης αποφασίζει ποια δεδομένα είναι χρήσιμα για κάθε ανάλυση. Αντιθέτως, σε συστήματα δεδομένων μεγάλης κλίμακας, η μηχανική μάθηση μπορεί να υποδείξει τα κατάλληλα δεδομένα για την εκάστοτε ανάλυση, εφαρμόζοντας στατιστικές μεθόδους πάνω στα διαθέσιμα δεδομένα. Η εργασία του Pape (2016) ασχολείται με το πρόβλημα επιλογής των κατάλληλων δεδομένων που πρέπει μια επιχείρηση να συλλέγει και να αποθηκεύει για να εφαρμόσει την επιχειρηματική αναλυτική δεδομένων. Πιο συγκεκριμένα, προτείνει ένα πλαίσιο ποσοτικοποίησης της αξίας των δεδομένων το οποίο βασίζεται στον προσδιορισμό των συσχετίσεων των διαθέσιμων δεδομένων με τις διαδικασίες και τις αποφάσεις του οργανισμού.

Βήμα 3 – Οργάνωση και Συγχώνευση Δεδομένων:

Αφού έχουν προσδιοριστεί τα σχετικά σύνολα δεδομένων και έχουν συλλεχθεί από τις αντίστοιχες πηγές δεδομένων, ακολουθεί η οργάνωση και η συγχώνευση των δεδομένων, προκειμένου να κατασκευαστούν τα κατάλληλα σύνολα δεδομένων τα οποία συνθέτουν την χρήσιμη πληροφορία για το δεδομένο πρόβλημα. Μία από τις μεγαλύτερες προκλήσεις στην συγχώνευση δεδομένων από ετερογενείς πηγές είναι η επιτυχής διαχείριση της σημασιολογικής ετερογένειας των δεδομένων. Σε αυτό το βήμα αξιοποιούνται εργαλεία τα οποία ασχολούνται με το συντακτικό και τη σημασιολογία των δεδομένων. Η αποδοτική συγχώνευση δεδομένων διαφορετικών πηγών έχει ως στόχο να αυξήσει την πληρότητα και την περιεκτικότητα των προς ανάλυση συνόλων δεδομένων (Bleiholder, και Naumann, 2009).

Βήμα 4 – Προετοιμασία Δεδομένων:

Στο βήμα αυτό, η επιχείρηση ασχολείται με την προετοιμασία των δεδομένων προκειμένου τα διαθέσιμα σύνολα δεδομένων να μετασχηματιστούν κατάλληλα για τη μετέπειτα ανάλυσή τους και να εκτιμηθεί η ποιότητά τους. Η αξιολόγηση της ποιότητας των δεδομένων συνήθως βασίζεται σε τεχνικές όπως η απομάκρυνση των μη έγκυρων, κενών ή ακραίων εγγραφών και του θορύβου. Μεγάλο μέρος της βιβλιογραφίας που σχετίζεται με την προετοιμασία των δεδομένων αφορά την

εξαγωγή χαρακτηριστικών (feature extraction), τη μείωση χαρακτηριστικών (feature reduction) και την παραγωγή νέων χαρακτηριστικών (feature generation).

Οι τεχνικές προετοιμασίας δεδομένων διαχωρίζονται σε μεθόδους προετοιμασίας δομημένων δεδομένων και μεθόδους προετοιμασίας μη δομημένων δεδομένων (Schmidt et al., 2016). Πέρα από την απομάκρυνση ή αντικατάσταση ελλιπών τιμών, σε σύνολα δομημένων δεδομένων συχνά εφαρμόζονται μέθοδοι προετοιμασίας των περιεχόμενων χαρακτηριστικών τους. Δύο από τις πιο συχνές μεθόδους είναι η ποσοτικοποίηση (numerization) και η διακριτοποίηση (discretization) ενός χαρακτηριστικού, με τις οποίες ένα κατηγορικό χαρακτηριστικό μπορεί να μετασχηματιστεί σε ένα ποσοτικό χαρακτηριστικό και αντίστροφα. Στα αριθμητικά χαρακτηριστικά συχνά εφαρμόζεται η μέθοδος της κανονικοποίησης, με την οποία οι τιμές των χαρακτηριστικών μετασχηματίζονται σε μία κοινή μονάδα μέτρησης.

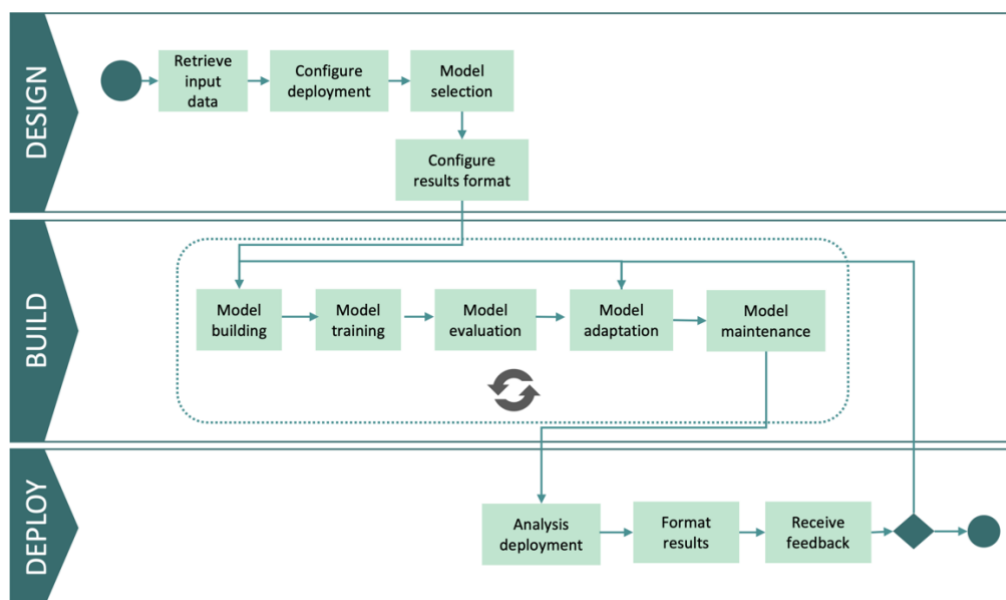
Τα μη δομημένα δεδομένα τυπικά οργανώνονται σε πολλαπλά ανεξάρτητα αρχεία τα οποία περιέχουν κείμενο ή εικόνες. Στην περίπτωση του κειμένου η προετοιμασία των δεδομένων ξεκινά με την διαδικασία μετατροπής του κειμένου σε διακριτά σύμβολα (tokenization), την εκκαθάριση του κειμένου από συμβολικούς χαρακτήρες, όπως σημεία στίξης και την διάσπαση του κειμένου σε λέξεις. Σε αυτές τις περιπτώσεις κατασκευάζεται ένα μοντέλο λέξεων, σύμφωνα με το οποίο κάθε έγγραφο αναπαρίσταται από ένα σύνολο από λέξεις με τις αντίστοιχες συχνότητές τους. Η προ-επεξεργασία των μη δομημένων συνόλων δεδομένων ενέχει προβλήματα λόγω της μεγάλης διάστασης των δεδομένων και της αραιής κατανομής των όρων, καθιστώντας δύσκολη την ανάπτυξη του αντίστοιχου λεξικού. Τα προβλήματα αυτά αντιμετωπίζονται με τεχνικές όπως η αφαίρεση των πιο σπάνιων όρων από το λεξικό, η απομάκρυνση των βοηθητικών λέξεων που δεν εμπεριέχουν κάποια σημασία (stop words) κ.ά.

Βήμα 5 – Ανάλυση Δεδομένων:

Αποτελεί το βασικό βήμα της αναλυτικής δεδομένων όπου με την εφαρμογή στατιστικών, μαθηματικών ή προηγμένων μοντέλων μηχανικής μάθησης, αναλύονται τα δεδομένα του προηγούμενου βήματος. Το βήμα της ανάλυσης δεδομένων υλοποιείται συνήθως από πολύπλοκες διαδικασίες επεξεργασίας δεδομένων και

εφαρμογής αλγορίθμων. Για τον καθορισμό των διαδικασιών της ανάλυσης που επιτυγχάνει τους επιχειρηματικούς στόχους, αξιοποιώντας τα διαθέσιμα δεδομένα, αναπτύσσονται πειραματικές διαδικασίες μέσω των οποίων εντοπίζουν την βέλτιστη αναλυτική διαδικασία που επιλύει το ζητούμενο πρόβλημα. Στις περιπτώσεις προχωρημένης αναλυτικής δεδομένων, η βέλτιστη διαδικασία ανάλυσης παράγει ένα ή περισσότερα αναλυτικά μοντέλα. Την κατασκευή και την αξιολόγηση των αναλυτικών μοντέλων ακολουθεί η ενεργοποίηση των μοντέλων μέσω της οποίας παράγονται τα ζητούμενα αποτελέσματα.

Στην Εικόνα 4-2 παρουσιάζονται οι φάσεις της σχεδίασης, της κατασκευής και της ενεργοποίησης μιας ενδεικτικής διαδικασίας ανάλυσης, η οποία εστιάζει στην υλοποίηση της προδιαγραφικής αναλυτικής. Σε αυτήν, εμπεριέχονται τα αναλυτικά βήματα ανάπτυξης, αναπροσαρμογής και συντήρησης του αντίστοιχου αναλυτικού μοντέλου, τα οποία διαρκώς επαναλαμβάνονται, έπειτα από την επιτυχή ενεργοποίησή του. Η φάση της ενεργοποίησης και η διαχείριση των ενεργών αναλυτικών μοντέλων μιας επιχείρησης αποτελεί μια πολύπλοκη εργασία, την οποία πρέπει να εκτελεί συνεχώς και με συνέπεια η επιχείρηση προκειμένου να διαθέτει πιο ενημερωμένα και έγκαιρα αποτελέσματα αναλυτικής.



Εικόνα 4-2 Φάσεις ανάλυσης δεδομένων

Βήμα 6 – Διάχυση Αποτελεσμάτων:

Στη συνέχεια τα αποτελέσματα της ανάλυσης επικοινωνούνται και παρουσιάζονται στους συμμετέχοντες οι οποίοι ενδιαφέρονται για την απάντηση των ερωτήσεων που επιχειρεί να απαντήσει η δεδομένη ανάλυση. Η διάχυση των αποτελεσμάτων γίνεται με διαφορετικούς τρόπους ανάλογα με τις απαιτήσεις και τον τρόπο διεπαφής του κάθε συμμετέχοντα. Στις περισσότερες περιπτώσεις εφαρμογής της αναλυτικής δεδομένων τα αποτελέσματά της διαχέονται προς δύο κατευθύνσεις, προς τους ενδιαφερόμενους χρήστες και προς εφαρμογές λογισμικού.

Στην πρώτη κατεύθυνση, οι χρήστες ενημερώνονται σχετικά με την παραχθείσα νέα πληροφορία που εμπεριέχουν τα αποτελέσματα της αναλυτικής δεδομένων. Η οπτικοποίηση των αποτελεσμάτων προς τους συμμετέχοντες μπορεί να τους υποστηρίξει ώστε να κατανοήσουν την εξειδικευμένη πληροφορία που αυτά εμπεριέχουν και να λάβουν πιο ενημερωμένες και έγκυρες επιχειρηματικές αποφάσεις. Για παράδειγμα τα στελέχη μιας επιχείρησης μπορούν να επιβλέπουν τη συνολική πορεία της επιχείρησης, να ενημερώνονται σχετικά με προβλεπόμενα γεγονότα ή με την προβλεπόμενη πορεία της επιχείρησης, ή τις επιπτώσεις των μελλοντικών αποφάσεων που θα κληθούν να λάβουν. Χαρακτηριστικές περιπτώσεις αυτής της κατεύθυνσης είναι η παρακολούθηση των πωλήσεων λιανικής, η επίβλεψη αισθητήρων αλλά και η πρόβλεψη σφαλμάτων σε μια γραμμή παραγωγής.

Από μια διαφορετική οπτική, η λήψη αποφάσεων και η υλοποίηση των αντίστοιχων ενεργειών συχνά αντιμετωπίζεται ανεξάρτητα από την αναλυτική δεδομένων (Seddon et al., 2017). Παρόλα αυτά, με τις εξελίξεις του τομέα της προδιαγραφικής αναλυτικής, της μηχανικής μάθησης και των τεχνολογιών δεδομένων μεγάλης κλίμακας, η λήψη αποφάσεων αυτοματοποιείται όλο και περισσότερο. Υπό αυτό το πρίσμα, τα αποτελέσματα της αναλυτικής δεδομένων ενσωματώνονται σε αυτοματοποιημένα συστήματα λογισμικού. Παράδειγμα αυτής της κατεύθυνσης αποτελεί η ενσωμάτωση των προδιαγραφικών αποτελεσμάτων σε συστήματα παραγωγής προτάσεων προς τους πελάτες ενός διαδικτυακού καταστήματος σχετικά με τις επόμενες αγορές τους.

Βήμα 7 – Ερμηνεία Αποτελεσμάτων:

Στο επόμενο βήμα, τα αποτελέσματα της αναλυτικής δεδομένων ερμηνεύονται ως απαντήσεις στις ερωτήσεις που καθορίστηκαν στο πρώτο βήμα και

μετασχηματίζονται σύμφωνα με το επιχειρηματικό πλαίσιο του προβλήματος. Ο μετασχηματισμός των αποτελεσμάτων αναλυτικής δεδομένων σε απαντήσεις στις επιχειρηματικές ερωτήσεις της πρώτης φάσης σε κάποιες περιπτώσεις είναι τετριμμένος, γίνεται όμως πιο πολύπλοκος όταν η ανάλυση βασίζεται σε προηγμένες μεθόδους και αλγόριθμους.

Τα αποτελέσματα προχωρημένης αναλυτικής δεδομένων που αναπαριστούν προβλέψεις ή προδιαγραφές σχετικές με τη μελλοντική πορεία ενός οργανισμού, εμπεριέχουν εξ' ορισμού αβεβαιότητα καθώς το περιβάλλον και τα γεγονότα στα οποία αναφέρονται δεν είναι γνωστά στο σύνολό τους στο παρόν. Επιπλέον, οι διαθέσιμες αναλυτικές μέθοδοι δεν έχουν τη δυνατότητα να παράγουν προβλέψεις ή προδιαγραφές με απόλυτη βεβαιότητα. Επιπροσθέτως, ο παραλήπτης των αποτελεσμάτων που καλείται να ερμηνεύσει τα αποτελέσματα της προχωρημένης αναλυτικής λαμβάνοντας υπόψιν τις πιθανές και άγνωστες σε αυτόν συνθήκες στις οποίες το προβλεπόμενο γεγονός θα εκδηλωθεί, προσθέτει επιπλέον αβεβαιότητα στην ερμηνεία των αποτελεσμάτων. Αυτό οφείλεται στο ότι τείνει να τα ερμηνεύσει ενεργοποιώντας την διαίσθησή του και την προηγούμενη διαθέσιμη γνώση του.

Βήμα 8 – Αξιολόγηση και Βελτίωση:

Μετά τη διάχυση και την ερμηνεία των αποτελεσμάτων της αναλυτικής δεδομένων, η συνολική υλοποίηση, εφαρμογή και ανάλυση των δεδομένων αξιολογείται από τους χρήστες. Η εφαρμογή που αναπτύχθηκε εξετάζεται ως προς το κατά πόσον απάντησε τις ερωτήσεις που τέθηκαν στο πρώτο βήμα του κύκλου ζωής αλλά και πόσο συνέβαλε στην επίτευξη των συσχετιζόμενων επιχειρηματικών στόχων. Η επιτυχής αξιολόγηση της συνολικής διαδικασίας που αναπτύχθηκε προϋποθέτει επίσης την επικύρωση της σκοπιμότητας, της χρησιμότητας και της αναγκαιότητας της. Τα αποτελέσματα της αξιολόγησης χρησιμοποιούνται για τον επαναπροσδιορισμό και την βελτίωση της αναπτυχθείσας διαδικασίας αναλυτικής δεδομένων. Το γεγονός αυτό απαιτεί τη συστηματική καταγραφή τους και την εφαρμογή μεθόδων και τεχνικών ποσοτικοποίησής τους, προκειμένου να είναι δυνατή η σύγκριση διαφορετικών περιπτώσεων.

Οι φάσεις του κύκλου ζωής της αναλυτικής δεδομένων μπορεί να επαναλαμβάνονται αρκετές φορές σε διαφορετικές εκτελέσεις, μεμονωμένα ή με τη

μορφή υπο-διαδικασίας. Για παράδειγμα, το πρώτο βήμα καθορισμού του επιχειρηματικού στόχου μπορεί να υλοποιείται από τους ειδικούς της επιχείρησης και στη συνέχεια τα βήματα της ανάλυσης και της αξιολόγησης μπορεί να επαναλαμβάνονται έως ότου επιτευχθεί ο επιχειρηματικός στόχος με τον βέλτιστο δυνατό τρόπο. Οι διαφορετικές επαναλήψεις αυτών των βημάτων μπορεί να οφείλονται στην αναζήτηση των καταλληλότερων και αποδοτικότερων αλγορίθμων με τους οποίους οι αντίστοιχες επιχειρηματικές ερωτήσεις μπορούν να απαντηθούν επαρκώς.

Επιπροσθέτως, μια επιχείρηση έχει ταυτόχρονα πολλαπλούς επιχειρηματικούς στόχους τους οποίους μπορεί να ικανοποιήσει με τη βοήθεια της αναλυτικής δεδομένων. Ως εκ τούτου, σε μια επιχείρηση συνήθως υλοποιούνται παράλληλα πολλαπλές διαφορετικές και πιθανώς ανεξάρτητες μεταξύ τους διαδικασίες αναλυτικής δεδομένων, η πολυπλοκότητα των οποίων αυξάνεται με την αύξηση των δεδομένων, της πολυπλοκότητας των βημάτων της ανάλυσης και των αλγορίθμων μηχανικής μάθησης που αξιοποιούνται. Όλα τα παραπάνω καθιστούν την κατασκευή, τη διαχείριση και την συντήρηση των διαφορετικών υλοποιήσεων αναλυτικής δεδομένων μιας επιχείρησης μία απαιτητική και χρονοβόρα διαδικασία, η οποία εμποδίζει την ευρεία εφαρμογή της αναλυτικής.

Προς αυτήν την κατεύθυνση, η έρευνα έχει εστιάσει στην ανάπτυξη συστημάτων διαχείρισης και παρακολούθησης πειραμάτων (experiment tracking). Σκοπός των συστημάτων αυτών είναι η οργάνωση και διαχείριση των πειραματικών αναλύσεων που εκτελούνται σε έναν οργανισμό, είτε αυτός αφορά μια επιχείρηση είτε ένα ερευνητικό κέντρο. Παραδείγματα αυτών των συστημάτων αποτελούν το TensorBoard (<https://www.tensorflow.org/tensorboard>) και το Guild AI (<https://guild.ai/>). Μεταξύ άλλων, τα εργαλεία αυτά διευκολύνουν την οπτικοποίηση της απόδοσης των μοντέλων μηχανικής μάθησης και κατ' επέκταση την αξιολόγησή τους, ενώ παρέχουν έναν τρόπο οργάνωσης και αυτοματοποίησης των πειραματικών αναλύσεων που αναπτύσσονται κατά την υλοποίηση της αναλυτικής δεδομένων.

Πέρα από την ανάπτυξη των βέλτιστων πειραματικών αναλύσεων, σημαντικό κόπο έχει η διαχείριση των εξαγόμενων μοντέλων, η ενεργοποίησή τους και η διασύνδεσή τους με άλλα επιχειρησιακά εργαλεία. Μια λύση σε αυτές τις προκλήσεις

επιχειρούν να δώσουν τα εργαλεία λειτουργιών μηχανικής μάθησης (MLOps). Με μικρότερη τεχνική προσπάθεια, τα εργαλεία αυτά αναλαμβάνουν την διαχείριση των μοντέλων και αναλύσεων μηχανικής μάθησης αφού αναλαμβάνουν την οργάνωση, ενεργοποίηση και συντήρησή τους, μέσα από ένα ενιαίο σύστημα. Ένα χαρακτηριστικό παράδειγμα αυτών των εργαλείων είναι το ModelDB (Vartak et al., 2016), το οποίο επιχειρεί να απαντήσει τις προκλήσεις της διαχείρισης μοντέλων μηχανικής μάθησης (Vartak, και Madden, 2018).

Ένα ακόμη πιο εξελιγμένο σύστημα αυτής της κατεύθυνσης είναι το MLflow (<https://mlflow.org/>), το οποίο ενσωματώνει σε ένα σύστημα τις προαναφερθείσες λειτουργικότητες της παρακολούθησης πειραμάτων και της διαχείρισης έργων και μοντέλων μηχανικής μάθησης. Πρόκειται για μια πλατφόρμα ανοικτού κώδικα που στοχεύει στην πλήρη διαχείριση του κύκλου ζωής της μηχανικής μάθησης, συμπεριλαμβανόμενης της πειραματικής διαδικασίας, της εύκολης αναπαραγωγής πειραμάτων και της ενεργοποίησης των μοντέλων μηχανικής μάθησης μέσα από ένα ενιαίο σύστημα διαχείρισης (Zaharia et al., 2018).

Το πλαίσιο προδιαγραφικής αναλυτικής που παρουσιάζει η παρούσα διατριβή παρέχει τις κατάλληλες κατευθύνσεις για την ανάπτυξη προδιαγραφικών μεθόδων σύμφωνων με τον κύκλο ζωής της προδιαγραφικής αναλυτικής, οι οποίες υλοποιούν το βήμα κατασκευής της ανάλυσης της Εικόνα 4-2. Βασικός στόχος του πλαισίου είναι η ανάπτυξη μεθόδων που αξιοποιούν τη μηχανική μάθηση και τα διαθέσιμα δεδομένα, προκειμένου να ικανοποιήσουν επιτυχώς τους επιλεγμένους στόχους της επιχείρησης μέσω των παραγόμενων προδιαγραφών τους.

4.2 Πλαίσιο Προδιαγραφικής Αναλυτικής Δεδομένων

Στην παρούσα παράγραφο περιγράφεται το πλαίσιο προδιαγραφικής αναλυτικής με διαδραστική ενισχυτική μάθηση πολλαπλών κριτηρίων.

Σκοπός του πλαισίου είναι να ορίσει τα βήματα για την ανάπτυξη μεθόδων προδιαγραφικής αναλυτικής που αξιοποιούν την διαδραστική ενισχυτική μάθηση πολλαπλών κριτηρίων προκειμένου να υλοποιήσουν τους στόχους της διατριβής που περιγράφονται στην παράγραφο 3.2. Ακολουθώντας το πλαίσιο της διατριβής είναι

δυνατή η ανάπτυξη μεθόδων που επιλύουν διαφορετικά προβλήματα απόφασης, διαφόρων ερευνητικών τομέων. Επιπλέον, το ίδιο πλαίσιο υποστηρίζει την ανάπτυξη μεθόδων μεγάλης ευελιξίας, με δυνατότητες προσαρμογής σε περισσότερα του ενός προβλήματα ή τομέα. Εστιάζοντας κατά κύριο λόγο στην αξιοποίηση της διαδραστικής ενισχυτικής μάθησης πολλαπλών κριτηρίων, το πλαίσιο αυτό, δίνει τη δυνατότητα κατασκευής δυναμικών προδιαγραφικών μεθόδων, οι οποίοι επιλύουν προβλήματα απόφασης πολλαπλών κριτηρίων βελτιστοποίησης, υποστηρίζοντας ταυτόχρονα την βελτίωση ή την αναπροσαρμογή του μοντέλου σύμφωνα με την ανάδραση του χρήστη.

Το πλαίσιο της διατριβής αναπτύσσει μεθόδους με δύο πηγές δυνατότητες προσαρμογής:

- Τη δυναμική, οδηγούμενη από δεδομένα μοντελοποίηση και την εφαρμογή της ενισχυτικής μάθησης, μέσω των οποίων το εξεταζόμενο πρόβλημα μπορεί να παρουσιάζει μεταβλητή μοντελοποίηση με πολλά δεδομένα. Βάσει αυτών και με την αξιοποίηση επιπλέον εξειδικευμένων μεθόδων ενισχυτικής μάθησης, υποστηρίζονται μεταβαλλόμενα περιβάλλοντα με μεταβλητή ανταμοιβή, καταστάσεις ή/και ενέργειες. Το πλαίσιο είναι δυναμικό καθώς στην προτεινόμενη μοντελοποίηση, η ανταμοιβή και τα κριτήρια βελτιστοποίησης καθορίζονται σε κάθε στιγμιότυπο του προβλήματος από τα διαθέσιμα δεδομένα συνδυαστικά με τα αποτελέσματα της προβλεπτικής αναλυτικής δεδομένων.
- Την ανάδραση του ανθρώπου μέσω της οποίας έμμεσα εκφράζεται η προτίμηση του ανθρώπου καθώς και πιθανές μεταβολές του περιβάλλοντος, οι οποίες δεν αποτυπώνονται στα διαθέσιμα δεδομένα και το σύστημα δύναται να ενημερωθεί έμμεσα για αυτές μόνο μέσω της παρεχόμενης ανάδρασης.

Με τον τρόπο αυτό, κάθε μεταβολή των παραπάνω ενσωματώνεται στην προδιαγραφική μέθοδο, διατηρώντας έτσι το σύστημα διαρκώς ενημερωμένο. Έτσι το πλαίσιο οδηγεί στην κατασκευή μεθόδων ικανών να παράγουν έγκυρες προδιαγραφές για κάθε στιγμιότυπο του εξεταζόμενου προβλήματος.

Στο αναπτυσσόμενο πλαίσιο συμμετέχουν δύο διαφορετικοί ρόλοι, ο αναλυτής δεδομένων και ο τελικός χρήστης. Ο αναλυτής δεδομένων αναλαμβάνει την υλοποίηση και την εφαρμογή του πλαισίου. Το αποτέλεσμα της δουλειάς του θα

υποστηρίζει τη λήψη αποφάσεων του τελικού χρήστη. Ο αναλυτής δεδομένων θα πρέπει να κατέχει γνώσεις μηχανικής μάθησης και αναλυτικής δεδομένων, καθώς και βασικές γνώσεις του επιστημονικού τομέα του προβλήματος ούτως ώστε να συμβάλλει στη μοντελοποίηση του περιβάλλοντος ενισχυτικής μάθησης της μεθόδου, όπως αυτή αναλύεται στην παράγραφο 5.2.

Το πλαίσιο διαμορφώνεται σε δύο διαστάσεις, τις φάσεις του προδιαγραφικού μοντέλου και τις σχεδιαστικές επιλογές σύμφωνα με τις οποίες μπορούν να αναπτυχθούν διαφορετικές μέθοδοι προδιαγραφικής αναλυτικής.

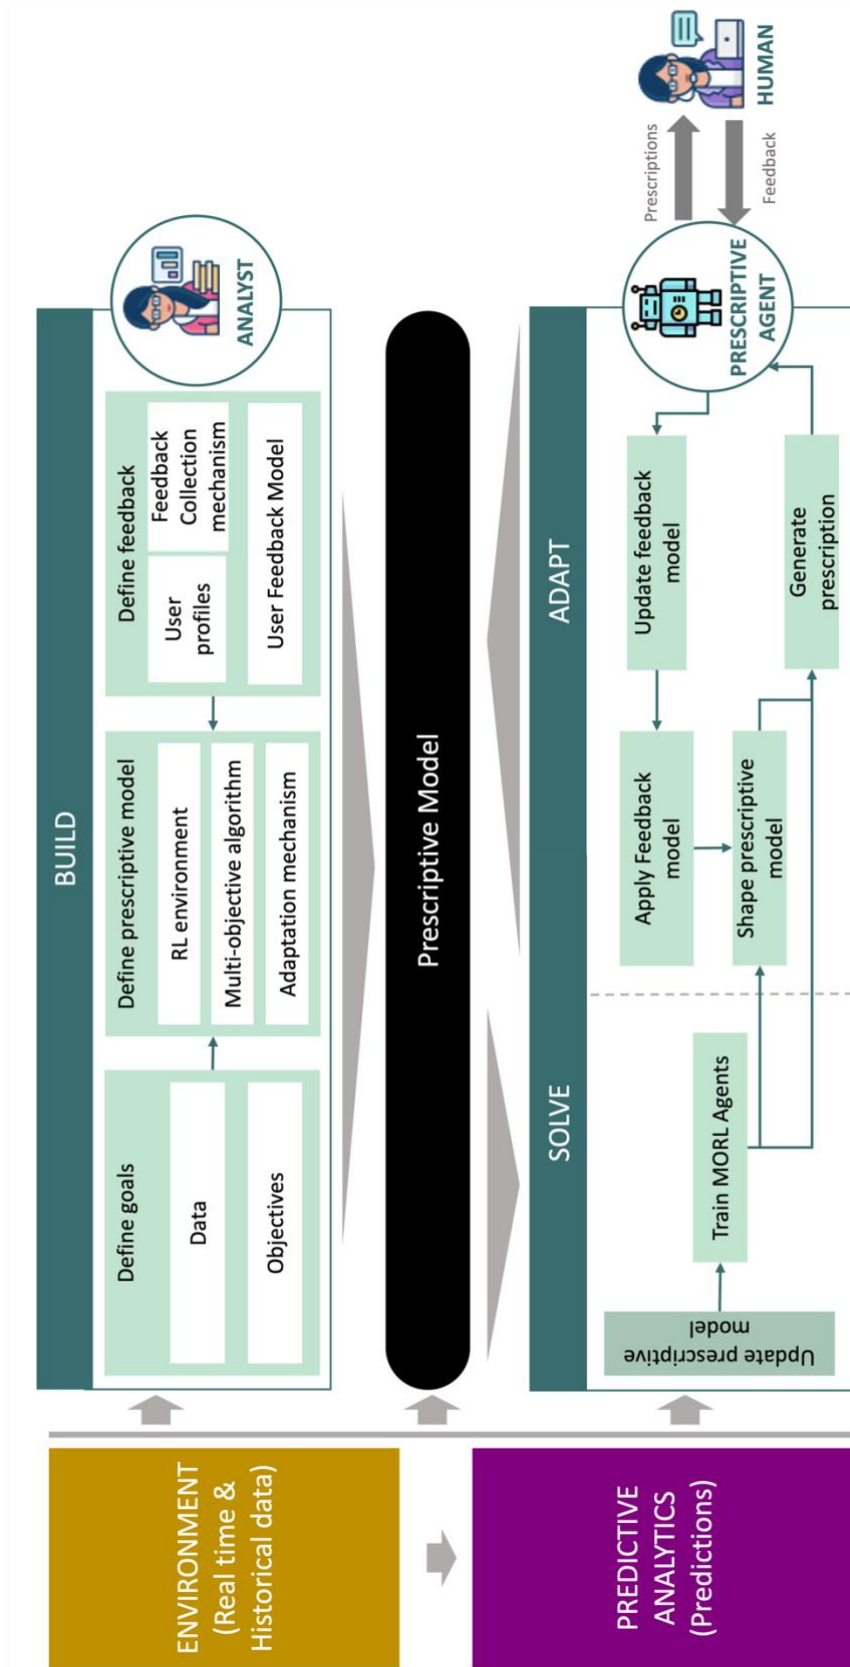
Η βάση του πλαισίου είναι το προδιαγραφικό μοντέλο το οποίο αναπτύσσεται σε τρεις φάσεις. Ως προδιαγραφικό μοντέλο ορίζεται το μοντέλο προδραστικής απόφασης του προβλήματος το οποίο συνδυάζει τα αποτελέσματα της προβλεπτικής αναλυτικής δεδομένων με τα διαθέσιμα δεδομένα του προβλήματος. Στόχος του προδιαγραφικού μοντέλου είναι η παραγωγή έγκαιρων προδιαγραφών, ικανών να καθοδηγήσουν τη μελλοντική συμπεριφορά και να προδιαγράψουν τις βέλτιστες μελλοντικές αποφάσεις για το εξεταζόμενο πρόβλημα. Ο προδιαγραφικός μηχανισμός που κατασκευάζεται από το πλαίσιο της διατριβής αποτελείται από τις φάσεις ανάπτυξης και διαχείρισης του προδιαγραφικού μοντέλου.

Οι φάσεις του προδιαγραφικού μοντέλου είναι η κατασκευή του προδιαγραφικού μοντέλου (παράγραφος 4.2.1), η επίλυση του προδιαγραφικού μοντέλου που εξάγει ένα εκπαιδευμένο μοντέλο ικανό να παράγει βελτιστοποιημένες αποφάσεις (παράγραφος 4.2.2) και η προσαρμογή του προδιαγραφικού μοντέλου (παράγραφος 4.2.3) με την οποία ενσωματώνεται η ανάδραση του ανθρώπου και αναπροσαρμόζεται ο προδιαγραφικός μηχανισμός έτσι ώστε οι παραγόμενες προδιαγραφές να εκφράζουν την προτίμηση του ανθρώπου. Οι τρεις φάσεις αντιπροσωπεύουν τις βασικές υπο-διαδικασίες ανάπτυξης και ενημέρωσης του προδιαγραφικού μοντέλου που αποτελεί τον πυρήνα της αναπτυσσόμενης προδιαγραφικής μεθόδου διαδραστικής ενισχυτικής μάθησης πολλαπλών κριτηρίων.

Σε κάθε φάση του πλαισίου, ο υπεύθυνος ανάπτυξης της προδιαγραφικής μεθόδου δύναται να προσδιορίσει συγκεκριμένες επιλογές, οι οποίες ικανοποιούν το εξεταζόμενο πρόβλημα και αντιστοιχούν στο περιβάλλον και τα δεδομένα που επιθυμεί να αξιοποιήσει. Με τις σχεδιαστικές επιλογές που εμπεριέχονται, παρέχεται

μεγάλη ευελιξία στη σχεδίαση της προδιαγραφικής μεθόδου. Το πλαίσιο υποστηρίζει την κατασκευή μιας προδιαγραφικής μεθόδου που θα ικανοποιεί τα ζητούμενα της παραγράφου 3.2, χωρίς να περιορίζει τις αναπτυσσόμενες μεθόδους με συγκεκριμένες υποθέσεις, δεδομένα και αλγορίθμους. Έτσι μπορούν να κατασκευαστούν διαφορετικές προδιαγραφικές μέθοδοι για το ίδιο πρόβλημα, διαφορετικές προδιαγραφικές μέθοδοι για διαφορετικά προβλήματα αλλά ακόμα και προδιαγραφικές μέθοδοι προσαρμοσμένες στο να διαχειρίζονται διαφορετικά προβλήματα.

Το πλαίσιο της διατριβής παρουσιάζεται στην Εικόνα 4-3 και αναλύεται στις επόμενες παραγράφους.



Εικόνα 4-3 Πλαίσιο προδιαγραφικής αναλυτικής δεδομένων

Σημαντικό ρόλο στην ανάπτυξη μιας προδιαγραφικής μεθόδου κατέχει η επιλογή των δεδομένων που είναι διαθέσιμα από το περιβάλλον του προβλήματος καθώς και η επιλογή των αλγορίθμων προβλεπτικής αναλυτικής δεδομένων που μπορούν να εφαρμοστούν. Αυτή η επιλογή αφορά τα στοιχεία του αριστερού τμήματος της Εικόνα 4-3, γίνεται πριν την έναρξη των φάσεων του πλαισίου της διατριβής και επηρεάζει σαφώς την προσφερόμενη αξία, την επιτυχία και την αξιοπιστία των αποτελεσμάτων της αναπτυσσόμενης προδιαγραφικής μεθόδου.

Τα διαθέσιμα δεδομένα θα πρέπει να αναπαριστούν το περιβάλλον τους προβλήματος στον υψηλότερο δυνατό βαθμό λεπτομέρειας έτσι ώστε να είναι δυνατή η αξιοποίηση της μέγιστης πληροφορίας από την προδιαγραφική μέθοδο. Επιπλέον, τα διαθέσιμα δεδομένα μπορεί να προέρχονται από ετερογενείς πηγές δεδομένων, εσωτερικές ή εξωτερικές και να διαθέτουν διαφορετικές διαδικασίες συλλογής δεδομένων. Ο τρόπος ενσωμάτωσης των διαθέσιμων δεδομένων του περιβάλλοντος και η ενορχήστρωση της διαδικασίας συλλογής τους σαφώς επηρεάζει την εγκυρότητα των παραγόμενων προδιαγραφών, μιας και ο αναπτυσσόμενος προδιαγραφικός μηχανισμός ενδέχεται να μην είναι συνεχώς ενήμερος για το σύνολο των διαθέσιμων δεδομένων.

Επιπροσθέτως, η συσχέτιση της προβλεπτικής αναλυτικής δεδομένων με την προδιαγραφική αναλυτική δεν είναι μονοσήμαντα καθορισμένη στην σχετική βιβλιογραφία. Το πλαίσιο της διατριβής παρέχει υψηλό βαθμό ελευθερίας στον τρόπο διασύνδεσής τους καθώς και στην αξιοποίηση των αποτελεσμάτων της προβλεπτικής αναλυτικής δεδομένων ως είσοδο στην προδιαγραφική αναλυτική (den Hertog, και Postek, 2016). Επιπλέον, η αβεβαιότητα η οποία διαδίδεται με αυτό τον τρόπο από τα παραγόμενα προβλεπτικά αποτελέσματα στις παραγόμενες προδιαγραφές, δεν είναι μονοσήμαντα προσδιοριζόμενη. Κάτι τέτοιο τονίζει την ανάγκη ανάπτυξης ισχυρών και αξιόπιστων μοντέλων προβλεπτικής αναλυτικής δεδομένων, ούτως ώστε η είσοδος της προδιαγραφικής μεθόδου να περιέχει την ελάχιστη δυνατή αβεβαιότητα.

Σύμφωνα με το πλαίσιο, τα αποτελέσματα της προβλεπτικής αναλυτικής δεδομένων δύναται να αξιοποιηθούν με δύο τρόπους: (α) στην αρχική

μοντελοποίηση του προδιαγραφικού μοντέλου και (β) κατά την ενεργοποίηση της παραγωγής προδιαγραφών.

4.2.1 Κατασκευή προδιαγραφικού μοντέλου

Η μοντελοποίηση στην επιστήμη και τα μαθηματικά ασχολείται με την σκόπιμη περιγραφή, επεξήγηση ή σύλληψη μιας ιδέας, μέσω της κατασκευής μοντέλων πολύπλοκων συστημάτων (Sriraman, και Lesh, 2006). Πολλές επιστημονικές εφαρμογές βασίζονται στην κατασκευή και χρήση μοντέλων. Ο όρος μοντέλο αναφέρεται σε μια δομή που κατασκευάζεται με σκοπό την αποτύπωση των χαρακτηριστικών ενός αντικείμενου και μπορεί να αφορά ένα πραγματικό αντικείμενο, όπως ένα αεροπλάνο ή να αποτελεί ένα αφηρημένο μοντέλο, όπως τη διαδικασία επίλυσης ενός προβλήματος (Williams, 2013). Κατά την κατασκευή ενός μοντέλου αρχικά αναλύεται το προς επίλυση πρόβλημα ή το αναπτυσσόμενο αντικείμενο και καθορίζονται τα χαρακτηριστικά και οι συσχετίσεις που επηρεάζουν και καθοδηγούν το σκοπό της μοντελοποίησης. Ένα μοντέλο αποτελεί μία ευρύτερη δομή που μπορεί να χρησιμοποιηθεί σε διαφορετικές περιπτώσεις του ίδιου προβλήματος, με διαφορετικά δεδομένα.

Εστιάζοντας στη μοντελοποίηση προβλημάτων λήψης αποφάσεων, αρχικά καθορίζεται το πρόβλημα απόφασης, τα κριτήρια με τα οποία θα ληφθεί η απόφαση, και αναγνωρίζονται τα δεδομένα τα οποία εμπεριέχουν τη σχετική πληροφορία. Στη συνέχεια, σε συνδυασμό με την εξειδικευμένη γνώση του ειδικού κατασκευάζεται ένα μοντέλο αναπαράστασης του προς επίλυση προβλήματος απόφασης.

Η επιχειρησιακή έρευνα ασχολείται με τη μοντελοποίηση προβλημάτων βελτιστοποίησης που αναπαρίστανται από μαθηματικά μοντέλα. Σε αυτά, τα βασικά χαρακτηριστικά περιγράφονται με τη μορφή μαθηματικών σχέσεων (εξισώσεις, περιορισμοί κ.ό.κ), οι οποίες αντιστοιχούν σε συσχετίσεις του πραγματικού περιβάλλοντος του προβλήματος. Συνηθισμένοι τύποι μοντέλων είναι τα μοντέλα μαθηματικού προγραμματισμού, τα μοντέλα προσομοίωσης, τα μοντέλα χρονοσειρών καθώς και τα οικονομετρικά μοντέλα. Στις περισσότερες περιπτώσεις ένα πρακτικό πρόβλημα μπορεί να μοντελοποιηθεί με παραπάνω από έναν τρόπο,

ακολουθώντας είτε τις συνηθισμένες μεθόδους μοντελοποίησης, είτε καινοτόμες ή ευρετικές μεθόδους (Williams, 2013).

Η κλασσική διαδικασία κατασκευής ενός μοντέλου βελτιστοποίησης ή μαθηματικού προγραμματισμού εκτελείται συνήθως από κάποιον ειδήμονα στον τομέα της βελτιστοποίησης ή των μαθηματικών σε συνδυασμό με τους ειδήμονες του επιστημονικού πεδίου του προς εξέταση προβλήματος (den Hertog, και Postek, 2016). Η διαδικασία αυτή απαιτεί αρκετό χρόνο για την κατανόηση του προβλήματος και του περιβάλλοντος, την επιλογή του κατάλληλου τύπου μοντέλου και την ενορχήστρωσή των αντίστοιχων ενεργειών, που θα παράγει το μοντέλο το οποίο επιλύει το εξεταζόμενο πρόβλημα. Η χειροκίνητη κατασκευή ενός τέτοιου μοντέλου, απαιτεί συχνό επαναπροσδιορισμό προκειμένου να αποτυπώνει πιθανές μεταβολές του περιβάλλοντος του προβλήματος γεγονός που προϋποθέτει επιπλέον προσπάθεια από τους υπεύθυνους κατασκευής του. Επιπροσθέτως, κατά την ανάπτυξη ενός μοντέλου, οι πραγματικές συνθήκες ενός προβλήματος ενδέχεται να μην μοντελοποιούνται επιτυχώς με κάποια μαθηματική μορφή και κατά συνέπεια να το παραγόμενο μοντέλο να μην αποτυπώνει επιτυχώς το εξεταζόμενο πρόβλημα.

Στον αντίποδα της χειροκίνητης μοντελοποίησης βρίσκεται η οδηγούμενη από δεδομένα κατασκευή του μοντέλου, η οποία σύμφωνα με την βιβλιογραφία, μπορεί να συμπεράνει το μοντέλο βελτιστοποίησης από ιστορικές παρατηρήσεις των ανάλογων αποφάσεων (Mikalef et al., 2018). Κατά συνέπεια μπορεί να αντιμετωπίσει τα αντίστοιχα προβλήματα, παρέχοντας ένα δυναμικό, συνεχώς ενημερωμένο και άμεσα προσαρμόσιμο μοντέλο.

Στο παρόν πλαίσιο, το εξεταζόμενο πρόβλημα αντιπροσωπεύει ένα πρόβλημα προδιαγραφικής αναλυτικής, το οποίο μοντελοποιείται με τη μορφή ενός περιβάλλοντος ενισχυτικής μάθησης. Μέσω αυτής, αναπτύσσεται ένας προδιαγραφικός μηχανισμός που επιλύει κάθε στιγμιότυπο του εξεταζόμενου προβλήματος. Στον πυρήνα του προδιαγραφικού μηχανισμού βρίσκεται το προδιαγραφικό μοντέλο. Η κατασκευή του προδιαγραφικού μοντέλου μπορεί να βασίζεται στην εξειδικευμένη γνώση ενός ειδήμονα του επιστημονικού πεδίου του προβλήματος, σε διαθέσιμα δεδομένα τα οποία εμπεριέχουν κρίσιμη για την επίλυση του προβλήματος πληροφορία, ή σε συνδυασμό αυτών των δύο.

Στη φάση της κατασκευής του προδιαγραφικού μοντέλου παρέχονται τρεις βασικές σχεδιαστικές κατευθύνσεις: (i) ο ορισμός στόχων, (ii) ο ορισμός του προδιαγραφικού μοντέλου και (iii) η μοντελοποίηση της ανάδρασης του ανθρώπου. Οι παρακάτω κατευθύνσεις μπορούν να καθοδηγήσουν την διαδικασία ανάπτυξης διαφορετικών προδιαγραφικών μοντέλων για ανεξάρτητα προβλήματα προδιαγραφικής αναλυτικής σε διάφορους επιστημονικούς τομείς, εξασφαλίζοντας ότι το αναπτυσσόμενο προδιαγραφικό μοντέλο θα περιέχει όλα τα απαραίτητα στοιχεία που απαιτούνται έτσι ώστε η παραγόμενη προδιαγραφική μέθοδος να επιτυγχάνει τους σκοπούς που αναφέρονται στην παράγραφο 3.2.

4.2.1.1 Ορισμός στόχων

Η πρώτη και κρισιμότερη σχεδιαστική επιλογή για την κατασκευή του προδιαγραφικού μοντέλου είναι ο ορισμός των στόχων, η οποία συσχετίζεται με το πρώτο βήμα του κύκλου ζωής της προδιαγραφικής αναλυτικής που αναλύεται στην παράγραφο 4.1. Με αυτήν την επιλογή η επιχείρηση καλείται να καθορίσει τους επιχειρηματικούς στόχους τους οποίους επιθυμεί να ικανοποιούν οι παραγόμενες προδιαγραφές της αναπτυσσόμενης μεθόδου. Για την ενσωμάτωση των στόχων στην προτεινόμενη προσέγγιση απαιτείται η αναπαράσταση και η ποσοτικοποίησή τους. Αρχικά αναλύονται και συσχετίζονται τα διαθέσιμα δεδομένα περιβάλλοντος και τα διαθέσιμα αποτελέσματα προβλεπτικής αναλυτικής δεδομένων που μπορούν να καθοδηγήσουν τις παραγόμενες προδιαγραφές. Οι επιχειρηματικοί στόχοι ενδέχεται να είναι αδύνατο να μεταφραστούν σε μετρήσιμα μεγέθη. Στην συγκεκριμένη σχεδιαστική επιλογή, επιχειρείται η αποτύπωση των επιχειρηματικών στόχων με τη μορφή μετρήσιμων κριτηρίων βελτιστοποίησης. Βάσει των δεδομένων που είναι διαθέσιμα, τα κριτήρια αυτά μπορούν να χρησιμοποιηθούν για την αξιολόγηση των εναλλακτικών αποφάσεων που είναι υποψήφιος για την επίλυση του αντίστοιχου προβλήματος απόφασης και κατ' επέκταση την ικανοποίηση των καθορισμένων επιχειρηματικών στόχων.

Αποτέλεσμα της σχεδιαστικής επιλογής είναι ο σαφής προσδιορισμός και η ενορχήστρωση των διαθέσιμων δεδομένων και η αποτύπωση των επιχειρηματικών

στόχων με τη μορφή μετρήσιμων κριτηρίων βελτιστοποίησης, τα οποία χρησιμοποιούνται για την κατασκευή του προδιαγραφικού μοντέλου της μεθόδου.

4.2.1.2 Ορισμός προδιαγραφικού μοντέλου

Η δεύτερη σχεδιαστική επιλογή της φάσης κατασκευής του προδιαγραφικού μοντέλου εστιάζει στον καθορισμό του προδιαγραφικού μοντέλου, ο οποίος απαρτίζεται από τρεις επιμέρους επιλογές: (i) τον ορισμό του περιβάλλοντος ενισχυτικής μάθησης, (ii) την επιλογή του αλγορίθμου ενισχυτικής μάθησης πολλαπλών κριτηρίων και (iii) τον μηχανισμό προσαρμογής του προδιαγραφικού μοντέλου σύμφωνα με την προσλαμβανόμενη ανάδραση του ανθρώπου.

Κατά τον καθορισμό του περιβάλλοντος ενισχυτικής μάθησης της προδιαγραφικής μεθόδου προσδιορίζονται τα συστατικά του περιβάλλοντος. Σε αυτά περιέχονται οι καταστάσεις του περιβάλλοντος και η πληροφορία που αυτές αναπαριστούν, οι ενέργειες του πράκτορα με τις οποίες περνάει από μια κατάσταση σε μια άλλη, η συνάρτηση μετάβασης που καθορίζει ποιες μεταβάσεις και με ποιες ενέργειες είναι εφικτές καθώς και η συνάρτηση ανταμοιβής του πράκτορα. Σε αρμονία με τον ορισμό της ενισχυτικής μάθησης, το περιβάλλον ενισχυτικής μάθησης που αποτυπώνει το πρόβλημα απόφασης αναμένεται να έχει μία αρχική κατάσταση από την οποία θα ξεκινά ο πράκτορας ενισχυτικής μάθησης και μία ή περισσότερες τελικές καταστάσεις που αντιστοιχούν στην επίτευξη των καθορισμένων στόχων. Σε αυτό το βήμα επιλέγεται ο τρόπος ενσωμάτωσης των σχετικών διαθέσιμων δεδομένων του πραγματικού περιβάλλοντος του προβλήματος καθώς και των προβλεπτικών αποτελεσμάτων στο προδιαγραφικό μοντέλο. Με τον τρόπο αυτό, τα διαθέσιμα δεδομένα αξιοποιούνται στον καθορισμό των οντοτήτων του περιβάλλοντος (καταστάσεις, ενέργειες, συνάρτηση ανταμοιβής).

Επιπλέον, κατά τον καθορισμό του περιβάλλοντος ενισχυτικής μάθησης επιλέγεται ο τρόπος διαχείρισης κριτηρίων απόφασης και αναπαράστασής τους στο περιβάλλον ενισχυτικής μάθησης. Ενδεικτικές προσεγγίσεις του τρόπου διαχείρισης των κριτηρίων απόφασης προτείνουν την ενσωμάτωση των κριτηρίων βελτιστοποίησης σε μία μονοδιάστατη συνάρτηση ανταμοιβής η οποία θα κατέχει τη μορφή μιας συνθετικής συνάρτησης βελτιστοποίησης. Άλλες μέθοδοι, όπως η προτεινόμενη μέθοδος της παραγράφου 5.2, προσδίδουν στην ανταμοιβή τη μορφή

διανύσματος, θεωρώντας μια ένα-προς-ένα σχέση μεταξύ των διαστάσεων της και των κριτηρίων βελτιστοποίησης.

Το περιβάλλον ενισχυτικής μάθησης αποτελεί την βάση του αλγορίθμου ενισχυτικής μάθησης που θα κληθεί να επιλύσει το εξεταζόμενο πρόβλημα. Ένα περιβάλλον ενισχυτικής μάθησης μπορεί να επιλυθεί με τη βοήθεια διαφορετικών αλγορίθμων ενισχυτικής μάθησης. Στη συνέχεια αυτού του βήματος, γίνεται η επιλογή του αλγορίθμου ενισχυτικής μάθησης πολλαπλών κριτηρίων, η οποία εστιάζει όχι μόνο στον αλγόριθμο ενισχυτικής μάθησης που θα επιλύσει το πρόβλημα αλλά και στον προσδιορισμό του τρόπου με τον οποίο θα αξιολογηθούν τα επιλεγμένα κριτήρια απόφασης. Ενδεικτικοί αλγόριθμοι ενισχυτικής μάθησης πολλαπλών κριτηρίων που μπορούν να αξιοποιηθούν σε αυτό το βήμα περιγράφονται συνοπτικά στην παράγραφο 5.1.2. Ο αλγόριθμος ενισχυτικής μάθησης πολλαπλών κριτηρίων που επιλέγεται μπορεί να παράγει προδιαγραφές που επιλύουν με βέλτιστο τρόπο το εξεταζόμενο πρόβλημα απόφασης ως προς τα καθορισμένα κριτήρια βελτιστοποίησης.

Για να μπορέσουν οι παραγόμενες προδιαγραφές να προσεγγίσουν την προτίμηση του ανθρώπου, το πλαίσιο προτείνει την ενσωμάτωση της παρεχόμενης από τον άνθρωπο ανάδρασης στον προδιαγραφικό μηχανισμό, αναπροσαρμόζοντας το προδιαγραφικό μοντέλο που ορίζεται μέχρι αυτό το σημείο. Για την επιτυχή υλοποίηση της αναπροσαρμογής αρχικά απαιτείται ο προσδιορισμός του είδους της ανάδρασης που αναμένεται να λαμβάνει το προδιαγραφικό μοντέλο και ο τρόπος προσαρμογής των παραγόμενων προδιαγραφών βάσει αυτής. Ανάλογα με τη μοντελοποίηση της ανάδρασης και του τρόπου ενσωμάτωσής της, ο προδιαγραφικός μηχανισμός της αναπτυσσόμενης μεθόδου θα επηρεάζεται λιγότερο ή περισσότερο από την παρεχόμενη ανάδραση του ανθρώπου. Το πλαίσιο της διατριβής εστιάζει στις δυνατότητες προσαρμογής του προδιαγραφικού μηχανισμού σύμφωνα με την ανάδραση του ανθρώπου που υποστηρίζουν οι τεχνικές διαδραστικής ενισχυτικής μάθησης και περιγράφονται στην παράγραφο 5.1.3.

Ο καθορισμός της ανάδρασης, των ανθρώπων που παρέχουν την ανάδραση και η μοντελοποίηση της ανάδρασης που θα ενσωματωθεί με τον επιλεγμένο αλγόριθμο διαδραστικής ενισχυτικής μάθησης γίνεται στο επόμενο βήμα.

4.2.1.3 Μοντελοποίηση της ανάδρασης του ανθρώπου

Η τρίτη σχεδιαστική επιλογή αφορά (i) τον καθορισμό της ανάδρασης που παρέχει ο άνθρωπος πάνω στις παραγόμενες προδιαγραφές, (ii) των ανθρώπων που παρέχουν την ανάδραση, (iii) του μηχανισμού συλλογής ανάδρασης και (iv) του μοντέλου της ανάδρασης που με τις επιλεγμένες μεθόδους διαδραστικής ενισχυτικής μάθησης του προηγούμενου βήματος και της αλληλεπίδρασης με τον πράκτορα που επιτρέπει την ενσωμάτωσή της στον προδιαγραφικό μηχανισμό.

Η ανάδραση του ανθρώπου καθορίζεται από τον τρόπο με τον οποίο αυτή παράγεται από τους ανθρώπους και το είδος της πληροφορίας που αντιπροσωπεύει. Ο άνθρωπος μπορεί να εκφράσει την ανάδρασή του μέσα από διαφορετικές βιολογικές αλληλεπιδράσεις, όπως για παράδειγμα συναισθήματα, εκφράσεις προσώπου, χειρονομίες και φυσική γλώσσα. Συνήθως η ανάδραση συλλέγεται με τη βοήθεια απλών μηχανισμών, όπως το πάτημα ενός κουμπιού ή το κλικ ενός ποντικιού ηλεκτρονικού υπολογιστή. Σε περιπτώσεις που η ανάδραση εκφράζεται με εκφράσεις προσώπου ή φυσική γλώσσα χρησιμοποιούνται ανάλογα εργαλεία όπως βιντεοληπτικά όργανα. Οι πηγές ανάδρασης περιγράφονται στην παράγραφο 5.1.3.

Η ανάδραση μπορεί να αντιπροσωπεύει την άποψη ή τη γνώση του ειδικού, διοχετεύοντας διαφορετικού είδους πληροφορία στον προδιαγραφικό μηχανισμό. Για το λόγο αυτό, σε κάθε περίπτωση ανάπτυξης μιας προδιαγραφικής μεθόδου ακολουθώντας το πλαίσιο της διατριβής, θα πρέπει να καθορίσουμε το είδος της ανάδρασης που αναμένουμε να λάβουμε από τους συμμετέχοντες. Η ανάδραση αυτή μπορεί να έχει μια αξιολογική μορφή, περίπτωση στην οποία μπορεί να αναπαριστά την θετική ή αρνητική αξιολόγηση του ανθρώπου πάνω στην παραγόμενες προδιαγραφές. Εναλλακτικά μπορεί να αποτελεί μια βαθμολογία που αναπαριστά πόσο επιτυχείς ή όχι ήταν οι προδιαγραφές, σύμφωνα με τον άνθρωπο.

Σε διαφορετικές περιπτώσεις η ανάδραση μπορεί να έχει τη μορφή καθοδήγησης ή υποδείξεων από τον άνθρωπο προς τον πράκτορα ενισχυτικής μάθησης που παράγει τις προδιαγραφές. Αντίστοιχες προσεγγίσεις της βιβλιογραφίας θεωρούν ανάδραση που υποδεικνύει την προτιμώμενη ή σωστή ενέργεια που θα έπρεπε ο πράκτορας να επιλέξει αντί της προτεινόμενης.

Η μοντελοποίηση της ανάδρασης του ανθρώπου ολοκληρώνεται με τρία βήματα, (i) την κατηγοριοποίηση των χρηστών, (ii) τον ορισμό του μηχανισμού συλλογής ανάδρασης και (iii) την κατασκευή του μοντέλου ανάδρασης του ανθρώπου.

Η κατηγοριοποίηση των χρηστών σε προφίλ βάσει επιλεγμένων χαρακτηριστικών παρέχει ευελιξία στη μοντελοποίηση της ανάδρασης μιας και η ανάδραση διαφορετικών προφίλ δύναται να επηρεάζει διαφορετικά την προσαρμογή του προδιαγραφικού μοντέλου. Τα χαρακτηριστικά που προσδιορίζουν τις ομάδες, ο αριθμός των ομάδων και το πλήθος των χρηστών που ταξινομούνται σε αυτές καθορίζονται σύμφωνα με το περιβάλλον, το είδος του προβλήματος και τους διαθέσιμους χρήστες. Η επιλογή της ταξινόμησης των χρηστών σε ομάδες σύμφωνα με συγκεκριμένα χαρακτηριστικά διευκολύνει την προσθήκη νέων χρηστών στο σύνολο των ανθρώπων που παρέχουν ανάδραση στον προδιαγραφικό μηχανισμό. Αξίζει να σημειωθεί, ότι το πλαίσιο της διατριβής είναι δυναμικό ως προς τη μοντελοποίηση των χρηστών και μπορεί να διαμορφώσει πολλές διαφορετικές προδιαγραφικές μεθόδους για το ίδιο πρόβλημα οι οποίες μοντελοποιούν και διαχειρίζονται διαφορετικά την παρεχόμενη ανάδραση. Δύο προδιαγραφικές μέθοδοι που αναπτύσσονται με τα ίδια βήματα του πλαισίου μέχρι αυτό το σημείο, μπορούν να διαχειρίζονται με διαφορετικό τρόπο διαφορετικού είδους ανάδραση από τις διαφορετικές επιλεγμένες κατηγορίες χρηστών.

Η επιτυχής ενσωμάτωση της ανάδρασης του ανθρώπου στον προδιαγραφικό μηχανισμό της αναπτυσσόμενης μεθόδου καθώς και η αξιόπιστη αναπροσαρμογή του βασίζονται στα χαρακτηριστικά της συλλεχθείσας ανάδρασης. Σε αυτήν τη διαδικασία σημαντικό ρόλο παίζει το πλήθος, ο ρυθμός, η ακρίβεια και η ποικιλία της ανάδρασης που λαμβάνεται υπόψιν. Κατά την κατασκευή του προδιαγραφικού μηχανισμού είναι απαραίτητο να γνωρίζουμε πόσο συχνά αναμένουμε να λαμβάνουμε την ανάδραση του χρήστη, καθώς και κατά πόσο η ανάδραση είναι απαιτούμενη για κάθε παραγόμενη προδιαγραφή. Στις περιπτώσεις που λαμβάνουμε επιλεκτικά ανάδραση σε συγκεκριμένες μόνο προδιαγραφές από το σύνολο των παραγόμενων προδιαγραφών, η αναπροσαρμογή του προδιαγραφικού μηχανισμού μπορεί να τον μετατρέψει σε έναν μεροληπτικό μηχανισμό που δεν εκφράζει την πραγματική συνολική προτίμηση των συμμετεχόντων χρηστών. Η αξιοπιστία της

λαμβανόμενης ανάδρασης αφορά το κατά πόσο εμπιστευόμαστε την γνώση των ανθρώπων που παρέχουν την ανάδραση και κατά συνέπεια το κατά πόσο θεωρούμε ότι αυτοί οι άνθρωποι γνωρίζουν την βέλτιστη επίλυση του συγκεκριμένου προβλήματος.

Ανάλογα με το εξεταζόμενο πρόβλημα, ενδέχεται να επιθυμούμε την κατασκευή ενός προδιαγραφικού μηχανισμού που να μπορεί να υποστηρίξει διαφορετικά προφίλ ανθρώπων. Για να επιτύχουμε κάτι τέτοιο θα πρέπει να κατασκευάσουμε έναν μηχανισμό συλλογής ανάδρασης ο οποίος θα εμπεριέχει ανθρώπους διαφορετικών προφίλ. Επιπλέον, ιδανικά θα θέλαμε να περιέχει ικανοποιητικό αριθμό ανθρώπων για κάθε προφίλ. Όλα τα παραπάνω χαρακτηριστικά ανάδρασης πρέπει να ληφθούν υπόψιν κατά την σχεδίαση και υλοποίηση του μηχανισμού συλλογής ανάδρασης, έτσι ώστε να μπορέσουμε να διασφαλίσουμε την ποιότητα και την καθολικότητα της πληροφορίας που περιέχεται στην παρεχόμενη ανάδραση. Μέσω αυτής, ο προδιαγραφικός μηχανισμός θα μπορέσει να προσεγγίσει την γνώση των εμπλεκόμενων ανθρώπων με τον βέλτιστο τρόπο.

Το είδος της ανάδρασης, τα χαρακτηριστικά παραγωγής ανάδρασης σε συνδυασμό με τους επιλεγμένους αλγορίθμους διαδραστικής ενισχυτικής μάθησης καθοδηγούν το τρόπο με τον οποίο μπορούμε να μοντελοποιήσουμε την ανάδραση του ανθρώπου προκειμένου να στην ενσωματώσουμε στο προδιαγραφικό μοντέλο που κατασκευάζουμε. Στις περισσότερες τεχνικές διαδραστικής ενισχυτικής μάθησης ως μοντέλο ανάδρασης χρήστη νοείται μια μαθηματική φόρμουλα η οποία μεταφράζει την προτίμηση του χρήστη πάνω στις εναλλακτικές ενέργειες ενισχυτικής μάθησης λαμβάνοντας υπόψιν τα χαρακτηριστικά της παρεχόμενης ανάδρασης και αξιοποιείται από τις μεθόδους διαδραστικής ενισχυτικής μάθησης για την διαμόρφωση του επιλεγμένου αλγορίθμου.

Αντίστοιχα με τη μοντελοποίηση των χρηστών, το ίδιο πρόβλημα προδιαγραφικής αναλυτικής μπορεί να επιλυθεί με πολλές διαφορετικές μεθόδους προδιαγραφικής αναλυτικής κατασκευασμένες σύμφωνα με το παρόν πλαίσιο, οι οποίες μπορούν να βασίζονται στους ίδιους αλγορίθμους ενισχυτικής μάθησης πολλαπλών κριτηρίων, μοντελοποιώντας διαφορετικού είδους ανάδραση (π.χ. βαθμολόγηση ή καθοδήγηση

του πράκτορα), ή/και χρησιμοποιώντας διαφορετικούς μηχανισμούς προσαρμογής του προδιαγραφικού μοντέλου.

Με την ολοκλήρωση των βημάτων κατασκευής του προδιαγραφικού μοντέλου και τον καθορισμό των αντίστοιχων σχεδιαστικών επιλογών, κατασκευάζεται το αρχικό προδιαγραφικό μοντέλο της αντίστοιχης μεθόδου, το οποίο αποτελεί τον πυρήνα του πλαισίου της διατριβής. Για να μπορέσει η αναπτυσσόμενη μέθοδος να παράγει τις ζητούμενες προδιαγραφές, το μοντέλο εκπαιδεύεται, εκτελείται και αναπροσαρμόζεται στις επόμενες φάσεις του πλαισίου.

4.2.2 Επίλυση προδιαγραφικού μοντέλου

Το αρχικό προδιαγραφικό μοντέλο που παράγεται κατά την φάση της κατασκευής δίνεται ως είσοδος στην φάση της επίλυσης του προδιαγραφικού μοντέλου. Η φάση αυτή προσομοιάζει την επίλυση μαθηματικών μοντέλων βελτιστοποίησης και επιχειρησιακής έρευνας καθώς και την επίλυση των μαρκοβιανών διαδικασιών απόφασης.

Στο πλαίσιο της διατριβής, η επίλυση του προδιαγραφικού μοντέλου ξεκινά με την εκπαίδευση πρακτόρων ενισχυτικής μάθησης πολλαπλών κριτηρίων πάνω στο περιβάλλον ενισχυτικής μάθησης του προδιαγραφικού μοντέλου. Σε αυτό το βήμα, οι προκαθορισμένοι αλγόριθμοι ενισχυτικής μάθησης πολλαπλών κριτηρίων αναλαμβάνουν την εκπαίδευση των πρακτόρων. Οι πράκτορες μέσω της εκπαίδευσης μαθαίνουν την βέλτιστη πολιτική για το συγκεκριμένο περιβάλλον ενισχυτικής μάθησης με την οποία μπορούν να καθοδηγήσουν τις ενέργειες που επιλέγουν. Με τον τρόπο αυτό, μπορούν να αποκτήσουν τη μέγιστη αθροιστική ανταμοιβή και κατ' επέκταση να προδιαγράψουν τις συσχετιζόμενες (βέλτιστες) αποφάσεις, ως προς τα επιλεγμένα κριτήρια βελτιστοποίησης.

Η επιλογή των δεδομένων, των αλγορίθμων και το είδος της παραγόμενης πληροφορίας της προδιαγραφικής αναλυτικής επηρεάζουν τη μοντελοποίηση του προδιαγραφικού προβλήματος. Αντιστοίχως, η απόδοση των επιλεγμένων προβλεπτικών αλγορίθμων και η ακρίβεια των αποτελεσμάτων τους εμπεριέχουν αβεβαιότητα η οποία μεταφέρεται στις παραγόμενες προδιαγραφές. Ανάλογα με τις

σχεδιαστικές επιλογές της πρώτης φάσης, τα αποτελέσματα της προβλεπτικής αναλυτικής δεδομένων ενδέχεται να εμπεριέχονται στον καθορισμό του προδιαγραφικού μοντέλου ή να ενεργοποιούν την παραγωγή των προδιαγραφών.

Στην περίπτωση που τα προβλεπτικά αποτελέσματα εμπεριέχονται στο προδιαγραφικό μοντέλο, για παράδειγμα αποτελούν μία παράμετρο των προκαθορισμένων συναρτήσεων ανταμοιβής ή των επιλεγμένων κριτηρίων βελτιστοποίησης, το προδιαγραφικό μοντέλο θα πρέπει να ενημερωθεί κάθε φορά που λαμβάνονται νέα προβλεπτικά αποτελέσματα. Η ενημέρωση του προδιαγραφικού μοντέλου συνεπάγεται την ενημέρωση του αντίστοιχου περιβάλλοντος εκμάθησης και κατ' επέκταση απαιτείται η εκ νέου εκπαίδευση των πρακτόρων ενισχυτικής μάθησης που θα επιλύσουν το μοντέλο.

Αντιθέτως, τα προβλεπτικά αποτελέσματα μπορούν να χρησιμοποιηθούν μόνο για να ενεργοποιήσουν την παραγωγή προδιαγραφών, όπως για παράδειγμα η περίπτωση που ζητείται η παραγωγή προδιαγραφικών ενεργειών για την αποφυγή ενός μελλοντικού γεγονότος αστοχίας του εξοπλισμού μιας επιχείρησης, κατά τη χρονική στιγμή που παράγεται η συγκεκριμένη πρόβλεψη. Σε αυτήν την περίπτωση, το προδιαγραφικό μοντέλο που έχει κατασκευαστεί από την πρώτη φάση του πλαισίου δεν χρειάζεται ενημέρωση και εκ νέου εκπαίδευση, οπότε εκτελείται η αρχική εκπαίδευση του πράκτορα. Η προαιρετική εκτέλεση του βήματος της ενημέρωσης του προδιαγραφικού μοντέλου και ακολούθως η επανεκπαίδευση των αντίστοιχων πρακτόρων, σημειώνονται στην Εικόνα 4-3 με διαφορετικό χρώμα προκειμένου να τονίσει τον προαιρετικό κατά περίπτωση χαρακτήρα αυτού του βήματος.

Το βήμα της εκπαίδευσης των πρακτόρων περιλαμβάνει τους επιλεγμένους αλγόριθμους διαχείρισης πολλαπλών κριτηρίων βελτιστοποίησης, σύμφωνα με τους οποίους τα επιμέρους βήματα ενδέχεται να διαφέρουν. Για παράδειγμα, στην περίπτωση μοντελοποίησης των πολλαπλών κριτηρίων βελτιστοποίησης σε μία συνθετική συνάρτηση βελτιστοποίησης, αντίστοιχη της συνάρτησης ανταμοιβής του περιβάλλοντος ενισχυτικής μάθησης, το βήμα της εκπαίδευσης αναφέρεται στην εκπαίδευση του πράκτορα ενισχυτικής μάθησης με την παραδοσιακή έννοια της εκπαίδευσης. Από την άλλη, στην περίπτωση που τα κριτήρια μοντελοποιούνται ως

διαφορετικές διαστάσεις του διανύσματος ανταμοιβής, το βήμα της εκπαίδευσης θα μπορούσε να αφορά την εκπαίδευση διαφορετικών πρακτόρων ενισχυτικής μάθησης, καθένας από τους οποίους εκπαιδεύεται στο ίδιο περιβάλλον ενισχυτικής μάθησης, λαμβάνοντας υπόψιν την ανταμοιβή που αντιστοιχεί στο δικό του κριτήριο βελτιστοποίησης. Στην συνέχεια θα μπορούσε να υλοποιηθεί το επιπλέον βήμα ενσωμάτωσης των επιμέρους πολιτικών σε μία πολιτική στην οποία συνδυάζονται οι επιμέρους λύσεις. Επιπλέον, σε αυτές τις περιπτώσεις μπορούν να χρησιμοποιηθούν επιπρόσθετοι αλγόριθμοι ενισχυτικής μάθησης, όπως η ενισχυτική μάθηση πολλαπλών πρακτόρων, που διευκολύνουν και επιταχύνουν τη διαδικασία εκμάθησης.

Την εκπαίδευση των πρακτόρων ενισχυτικής μάθησης ακολουθεί η φάση της προσαρμογής του προδιαγραφικού μοντέλου σύμφωνα με την διαθέσιμη ανάδραση του ανθρώπου. Η φάση επίλυσης του προδιαγραφικού μοντέλου καταλήγει σε ένα προδιαγραφικό μοντέλο ικανό να παράγει προδιαγραφές. Στην πρώτη εκτέλεση της προδιαγραφικής μεθόδου που αναπτύσσεται, η φάση της επίλυσης, προωθεί το προδιαγραφικό μοντέλο στην φάση της προσαρμογής. Σε αυτήν τη φάση, δεν εκτελείται κάποια ενέργεια πάνω στο προδιαγραφικό μοντέλο καθώς δεν υπάρχει διαθέσιμη ανάδραση από τον άνθρωπο. Ως εκ τούτου, οι προδιαγραφές που παράγονται στις πρώτες εκτελέσεις της μεθόδου μέχρις ότου γίνει διαθέσιμη η ανάδραση του ανθρώπου σε κάποια από αυτές, προέρχονται απευθείας από το προδιαγραφικό μοντέλο που εξάγεται από την φάση της επίλυσης και αντιστοιχούν στις αποφάσεις που βελτιστοποιούν τα επιλεγμένα κριτήρια βελτιστοποίησης.

4.2.3 Προσαρμογή προδιαγραφικού μοντέλου

Το προδιαγραφικό μοντέλο της αναπτυσσόμενης μεθόδου μπορεί να τροποποιηθεί σε δύο περιπτώσεις ανάλογα με τις σχεδιαστικές επιλογές που έχουν γίνει. Στην πρώτη περίπτωση μπορεί να τροποποιηθεί εξαιτίας των νέων δεδομένων και προβλεπτικών αποτελεσμάτων τα οποία ενσωματώνονται σε αυτό με τη μορφή παραμέτρων. Κάτι τέτοιο απαιτεί την ενημέρωση του μοντέλου και την επανεκπαίδευση των πρακτόρων ενισχυτικής μάθησης, όπως αυτή αναφέρεται στην φάση της επίλυσης του προδιαγραφικού μοντέλου. Στη δεύτερη περίπτωση το

μοντέλο αναπροσαρμόζεται έπειτα από την παροχή ανάδρασης από τον άνθρωπο ο οποίος αξιολογεί τις παραγόμενες προδιαγραφές, περίπτωση που αποτελεί το βασικό αντικείμενο της φάσης προσαρμογής του προτεινόμενου πλαισίου.

Μετά την φάση της επίλυσης του προδιαγραφικού μοντέλου, η προδιαγραφική μέθοδος παράγει βελτιστοποιημένες αποφάσεις χρησιμοποιώντας το εκπαιδευμένο προδιαγραφικό μοντέλο ενισχυτικής μάθησης πολλαπλών κριτηρίων. Όταν ο άνθρωπος λάβει αυτές τις προδιαγραφές και τις αξιολογήσει, ξεκινά η αναπροσαρμογή του προδιαγραφικού μοντέλου. Η νέα ανάδραση που λαμβάνει ο μηχανισμός αναλύεται, αποθηκεύεται και συσχετίζεται με τις προηγούμενες αναδράσεις που είναι διαθέσιμες. Βάσει αυτών, ενημερώνεται το μοντέλο ανάδρασης του ανθρώπου το οποίο στη συνέχεια εφαρμόζεται στο βήμα της διαμόρφωσης του προδιαγραφικού μοντέλου.

Η αναπροσαρμογή του προδιαγραφικού μοντέλου ουσιαστικά αναφέρεται στην εφαρμογή της επιλεγμένης μεθόδου διαδραστικής ενισχυτικής μάθησης, σύμφωνα με την οποία το μοντέλο ανάδρασης του ανθρώπου ενσωματώνεται στον επιλεγμένο αλγόριθμο ενισχυτικής μάθησης πολλαπλών κριτηρίων. Έπειτα από έναν αριθμό αναπροσαρμογών, το βήμα αυτό οδηγεί σε ένα ενημερωμένο ως προς τις προτιμήσεις του ανθρώπου προδιαγραφικό μοντέλο, το οποίο θα παράγει προδιαγραφές που ισορροπούν μεταξύ των κριτηρίων βελτιστοποίησης και της ανάδρασης του ανθρώπου. Ο αριθμός των επαναλήψεων αξιολόγησης που θα οδηγήσουν στο σημείο ισορροπίας εξαρτάται από τις σχεδιαστικές επιλογές με τις οποίες αναπτύχθηκε η συγκεκριμένη μέθοδος. Σε κάθε επανάληψη προσαρμογής του προδιαγραφικού μοντέλου, ο προδιαγραφικός μηχανισμός ενημερώνεται για την δεδομένη προτίμηση του ανθρώπου, την οποία λαμβάνει υπόψιν για τις επόμενες προδιαγραφές που θα παράγει.

Η σχεδίαση του πλαισίου της διατριβής δεν προϋποθέτει την αξιολόγηση κάθε παραγόμενης προδιαγραφής. Αντιθέτως, το προδιαγραφικό μοντέλο αναπροσαρμόζεται κάθε φορά που λαμβάνει νέα αξιολόγηση, ενώ χάρις στο βήμα της διαμόρφωσης του προδιαγραφικού μοντέλου, συνεχίζει να παρέχει ενημερωμένες προδιαγραφές ως προς τις διαθέσιμες αξιολογήσεις που έχει λάβει μέχρι εκείνη τη στιγμή.

Έπειτα από την διαμόρφωση του προδιαγραφικού μοντέλου, η προδιαγραφική μέθοδος καταλήγει στο βήμα της παραγωγής προδιαγραφών, είτε στην περίπτωση παροχής νέας αξιολόγησης από τον άνθρωπο, είτε στην περίπτωση της διαμόρφωσης βάσει της υπάρχουσας ανάδρασης. Οι παραγόμενες προδιαγραφές επικοινωνούνται στον άνθρωπο, ο οποίος έχει τη δυνατότητα να παρέχει την αξιολόγησή του, εκφράζοντας εκ νέου την προτίμησή του πάνω στον ενημερωμένο προδιαγραφικό μηχανισμό. Οι φάσεις της επίλυσης και της προσαρμογής του προδιαγραφικού μοντέλου επαναλαμβάνονται συνεχώς όταν υπάρχουν νέα διαθέσιμα δεδομένα ή παρέχεται ανάδραση από τον άνθρωπο. Με τον τρόπο αυτό, η αναπτυσσόμενη μέθοδος διατηρείται συνεχώς ενήμερη και προσαρμόζεται στις νέες συνθήκες του προβλήματος, ακολουθώντας την προτίμηση του ανθρώπου, έτσι ώστε να παράγει βέλτιστες και ταυτόχρονα προτιμώμενες προδιαγραφές.

5 Μέθοδος Προδιαγραφικής Αναλυτικής Δεδομένων με Διαδραστική Ενισχυτική Μάθηση


5.1 Ανασκόπηση βιβλιογραφίας

5.1.1 Ενισχυτική Μάθηση

Στην ενισχυτική μάθηση, το υπό εξέταση πρόβλημα αναπαρίσταται από ένα περιβάλλον αποτελούμενο από ένα σύνολο καταστάσεων, ένα σύνολο ενεργειών και τους πράκτορες εκμάθησης. Σε κάθε κατάσταση οι πράκτορες μπορούν να εκτελέσουν κάποια ενέργεια, με την οποία θα μεταβούν σε μια άλλη κατάσταση. Με κάθε ενέργεια οι πράκτορες λαμβάνουν ανάδραση από το περιβάλλον, με τη μορφή ανταμοιβής. Σκοπός των πρακτόρων είναι να μάθουν την ακολουθία ενεργειών με τις οποίες θα φτάσουν σε μία συγκεκριμένη κατάσταση-στόχο, αποκομίζοντας παράλληλα τη μέγιστη δυνατή ανταμοιβή. Η εκμάθηση των πρακτόρων δεν είναι επιβλεπόμενη ή καθοδηγούμενη. Αντιθέτως, οι πράκτορες μαθαίνουν τις ενέργειες που μπορούν να εκτελέσουν προκειμένου να φτάσουν στην ζητούμενη κατάσταση μέσα από δοκιμές (Sutton, και Barto, 2018).

Ένα ακολουθιακό πρόβλημα λήψης απόφασης μπορεί να μοντελοποιηθεί με τη μορφή μιας μαρκοβιανής διαδικασίας απόφασης (Markov Decision Process – MDP), η οποία αποτελείται από πέντε δομικά στοιχεία: τον πράκτορα, το περιβάλλον, τις καταστάσεις, τις ενέργειες και την ανταμοιβή. Οι μαρκοβιανές διαδικασίες απόφασης μοντελοποιούν αποτελεσματικά ακολουθιακά προβλήματα αποφάσεων. Σε αυτά, ο αποφασίζων καλείται να παρατηρήσει μια διαδικασία και να λάβει διαδοχικές αποφάσεις σε κάθε βήμα της διαδικασίας, πριν λάβει την τελική απόφαση (Alagoz, et al., (2010); Roijers, et al., 2013). Το πρόβλημα ορίζεται με μια πλειάδα $\langle S, A, T, R, \gamma \rangle$, όπου S είναι το σύνολο καταστάσεων, A είναι το σύνολο ενεργειών, T είναι η συνάρτηση πιθανότητας της μετάβασης από μία κατάσταση σε μία άλλη, μέσω μιας δεδομένης ενέργειας $T : S \times A \times S \rightarrow [0,1]$, R είναι η συνάρτηση ανταμοιβής $R : S \times A \times S \rightarrow R$ και $\gamma \in [0,1]$ είναι ο «εκπτώτικός» παράγοντας, ο οποίος υποδεικνύει πως η ανταμοιβή του παρόντος επηρεάζει την ανταμοιβή των επόμενων βημάτων. Ο πράκτορας μέσω των δοκιμών που εκτελεί πάνω στο δοθέν περιβάλλον, υιοθετεί μια συμπεριφορά την οποία αναπαριστούμε με τη μορφή μιας

πολιτικής $\pi : S \times A$, όπου $\pi(s, a) = P(a_t = a | s_t = s)$ είναι η πιθανότητα να επιλέξει να εκτελέσει την ενέργεια $a \in A$ όταν βρίσκεται στην κατάσταση s . Στόχος του πράκτορα είναι μέσα από δοκιμές να μάθει την βέλτιστη πολιτική π^* με την οποία θα μεγιστοποιήσει την εκτιμώμενη αθροιστική ανταμοιβή. Το βασικό πλαίσιο της ενισχυτικής μάθησης αποτυπώνεται στην Εικόνα 5-1. Υποθέτοντας ότι το περιβάλλον στη χρονική στιγμή t βρίσκεται στην κατάσταση S_t , ο πράκτορας εκτελεί μια ενέργεια A_t με την οποία κατά τη χρονική στιγμή $t + 1$ η κατάσταση περιβάλλοντος μετασχηματίζεται από την S_t στην $S_{(t+1)}$. Με αυτήν την ενέργεια ο πράκτορας περνώντας στην κατάσταση $S_{(t+1)}$, λαμβάνει την ανταμοιβή $R_{(t+1)}$. Η πολιτική του πράκτορα ενημερώνεται με αυτήν την ανταμοιβή και ο πράκτορας εκτελεί μια νέα ενέργεια $A_{(t+1)}$ με την οποία μεταβαίνει από την κατάσταση $S_{(t+1)}$ σε μια επόμενη κατάσταση. Η μάθηση της βέλτιστης πολιτικής γίνεται με την συνεχή αλληλεπίδραση του πράκτορα με το περιβάλλον, μέσω της οποίας θα μεγιστοποιήσει εμπειρικά την αθροιστική ανταμοιβή που λαμβάνει.

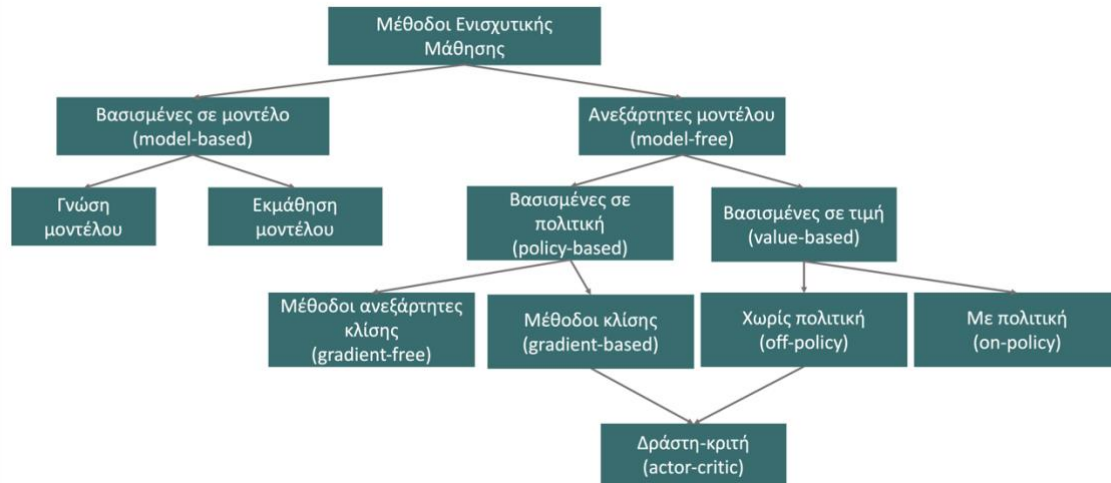


Εικόνα 5-1 Ενισχυτική Μάθηση

Οι μέθοδοι της ενισχυτικής μάθησης ταξινομούνται με διαφορετικούς τρόπους. Μία από τις βασικότερες ταξινομήσεις είναι ο χαρακτηρισμός τους ως μέθοδοι ανεξάρτητες μοντέλου (model-free) και μέθοδοι βασισμένες σε μοντέλο (model-based). Με τον όρο μοντέλο στην ενισχυτική μάθηση νοείται μια αναπαράσταση της υπάρχουσας γνώσης που αφορά το περιβάλλον ενισχυτικής μάθησης. Η γνώση αυτή αντιστοιχίζεται με την πλειάδα $\langle S, A, T, R, \gamma \rangle$, της μαρκοβιανής διαδικασίας απόφασης που μοντελοποιεί το περιβάλλον, το σύνολο της οποίας, εξαιρουμένης συνήθως της συνάρτησης ανταμοιβής R και της συνάρτησης πιθανότητας μετάβασης T , είναι γνωστά εκ των προτέρων (Zhang, H., και Yu, 2020). Στις βασισμένες σε μοντέλο μεθόδους, ο πράκτορας ενισχυτικής μάθησης μέσω επαναληπτικής αλληλεπίδρασης με το περιβάλλον μαθαίνει τις συναρτήσεις R και T ,

ολοκληρώνοντας έτσι την γνώση του για τη μαρκοβιανή διαδικασία απόφασης, με την οποία μπορεί να εφαρμόσει αλγορίθμους προγραμματισμού (planning). Οι μέθοδοι αυτής της κατηγορίας διακρίνονται περαιτέρω σε μεθόδους στις οποίες είναι διαθέσιμο το μοντέλο και σε μεθόδους που απαιτούν την εκμάθηση του μοντέλου.

Στις μεθόδους που είναι ανεξάρτητες μοντέλου, το περιβάλλον δεν μοντελοποιείται αυστηρά και ο πράκτορας ενισχυτικής μάθησης, μέσω της αλληλεπίδρασης με το περιβάλλον, εστιάζει στην εύρεση της βέλτιστης πολιτικής, αναζητώντας απευθείας τη μέγιστη ανταμοιβή. Η κατηγορία των μεθόδων που δεν εξαρτώνται από κάποιο μοντέλο είναι ιδιαίτερα ανεπτυγμένη στη βιβλιογραφία, ενώ οι μέθοδοι που παρουσιάζονται σε αυτή διακρίνονται σε τρεις κατηγορίες: τις βασισμένες σε πολιτική μεθόδους (policy-based), τις βασισμένες σε συνάρτηση τιμής μεθόδους (value-based) και στις μεθόδους δράστη-κριτή (actor-critic) (Lin, et al., 2020). Οι βασισμένες σε πολιτική μέθοδοι βελτιστοποιούν την πολιτική που μαθαίνει ο πράκτορας απευθείας. Στις βασισμένες σε συνάρτηση τιμής μεθόδους ο πράκτορας βελτιστοποιεί μια συνάρτηση τιμής της κατάστασης $V^\pi(s)$ και την συνάρτηση τιμής της ενέργειας $Q^\pi(s, a)$, από όπου εξάγει την βέλτιστη πολιτική. Οι βασισμένες σε συνάρτηση τιμής μέθοδοι ταξινομούνται περαιτέρω σύμφωνα με την προσέγγιση που ακολουθούν ως προς την πολιτική του πράκτορα σε μεθόδους με πολιτική (on-policy) και σε μεθόδους χωρίς πολιτική (off-policy). Στην πρώτη κατηγορία εντάσσονται οι μέθοδοι που απαιτούν από τον ίδιο τον πράκτορα να αλληλοεπιδρά με το περιβάλλον και διατηρούν μία μόνο πολιτική. Χαρακτηριστική μέθοδος αυτής της κατηγορίας είναι η μέθοδος Sarsa. Στην κατηγορία μεθόδων χωρίς πολιτική εντάσσονται οι μέθοδοι που συνδυάζουν πολιτικές διαφόρων πρακτόρων για να καταλήξουν στη βέλτιστη πολιτική, με βασική μέθοδο της κατηγορίας τη μέθοδο Q-learning (Zhang, H., και Yu, 2020). Οι μέθοδοι δράστη-κριτή συνδυάζουν τις δύο αυτές μεθόδους προκειμένου να προσεγγίσουν και να βελτιστοποιήσουν τόσο την πολιτική όσο και την συνάρτηση τιμής. Στην Εικόνα 5-2 απεικονίζεται η ταξινόμηση των βασικών μεθόδων ενισχυτικής μάθησης.



Εικόνα 5-2 Ταξινόμηση μεθόδων ενισχυτικής μάθησης (προσαρμοσμένη: Zhang, και Yu, 2020)

Η εφαρμογή της ενισχυτικής μάθησης ξεκινά με τη μοντελοποίηση του προβλήματος που επιχειρούμε να λύσουμε, έτσι ώστε να οριστούν εύστοχα το περιβάλλον και ο πράκτορας της ενισχυτικής μάθησης (Li, Y., 2019). Όπως και στις υπόλοιπες περιπτώσεις μηχανικής μάθησης, τα επαρκή δεδομένα παίζουν καθοριστικό ρόλο στην εφαρμογή των τεχνικών ενισχυτικής μάθησης, καθώς μπορούν να συμβάλλουν στην ανάπτυξη ενός αξιόπιστου μοντέλου και να προσθέσουν περισσότερη γνώση σχετικά με το περιβάλλον της ενισχυτικής μάθησης και την ανταμοιβή του πράκτορα. Αν και η ενισχυτική μάθηση υπόσχεται λιγότερο κόπο στην προετοιμασία και τη μηχανική των δεδομένων, η εφαρμογή της σε πραγματικές συνθήκες και προβλήματα υποδεικνύει σημαντική προσπάθεια και κατανόηση και γνώση του επιστημονικού τομέα του προβλήματος. Στην εργασία των (Li, Y., 2019) παρουσιάζονται αρκετοί επιστημονικοί τομείς στους οποίους βρίσκει εφαρμογή η ενισχυτική μάθηση για την επίλυση προβλημάτων, μεταξύ των οποίων εμφανίζονται τα συστήματα προτάσεων (recommender systems), ο τομέας της ενέργειας, των χρηματοοικονομικών, της ιατροφαρμακευτικής περίθαλψης, της ρομποτικής και των μεταφορών.

Οι Wang, et al. (2020) παρουσιάζουν μια αναλυτική έρευνα των αλγορίθμων ενισχυτικής μάθησης που έχουν προταθεί από τη βιβλιογραφία για διαφορετικές εφαρμογές ασύρματων δικτύων. Ένας μεγάλος αριθμός προσεγγίσεων οι οποίες αποτελεσματικά βελτιστοποιούν αποφάσεις ευαίσθητες ως προς το κόστος, με

σκοπό τη μεγιστοποίηση του συνολικού οφέλους σε μια χρονική περίοδο αναφέρονται στη βιβλιογραφία (Pednault, et al., 2002, July).

Αντιστοίχως η εργασία των Peters, et al. (2013) παρουσιάζει εφαρμογές ενισχυτικής μάθησης στην αγορά ηλεκτρικής ενέργειας με σκοπό την ανεύρεση πολιτικών που μεγιστοποιούν το κέρδος μακροχρόνια. Στην πρότασή τους, οι συγγραφείς χρησιμοποιούν την ενισχυτική μάθηση με την προσέγγιση συνάρτησης, ενώ οι πράκτορες μπορούν να διαχειριστούν οικονομικά σήματα από το περιβάλλον και να εκπαιδευτούν σε χώρους καταστάσεων μεγάλης διάστασης οι οποίοι προκύπτουν από τα σήματα αυτά. Η εργασία των (Leonetti, et al., 2016) αναπτύσσει την προσέγγιση πεδίου (domain approximation) για την ενισχυτική μάθηση, μια μέθοδο η οποία αξιοποιεί μεθόδους σχεδιασμού έτσι ώστε να περιορίσει την συμπεριφορά του πράκτορα σε λογικές επιλογές με σκοπό την προσαρμογή της ενισχυτικής μάθησης σύμφωνα με το διαθέσιμο περιβάλλον και την βελτίωση της αξιοπιστίας της διαδικασίας λήψης αποφάσεων.

Η εργασία των García, et al. (2012) παρουσιάζει μια προσέγγιση για την εφαρμογή της ενισχυτικής μάθησης με επιχειρηματικούς προσομοιωτές, αποδεικνύοντας την δυναμική της ενισχυτικής μάθησης σε διαφορετικά προβλήματα επιχειρηματικής λήψης αποφάσεων. Σε αυτήν την εργασία τονίζεται η δυνατότητα εφαρμογής της ενισχυτικής μάθησης σε ένα γενικευμένο πεδίο στο οποίο συμμετέχουν εκατοντάδες παράμετροι που επηρεάζουν την συμπεριφορά του πεδίου. Επιπλέον, τονίζεται η πιθανή συνύπαρξη της συνεργασίας και του ανταγωνισμού διαφορετικών πρακτόρων, και η ανάγκη καθορισμού πολλαπλών συνεχών μεταβλητών απόφασης για την λήψη μιας επιχειρηματικής απόφασης.

Οι προσεγγίσεις της ενισχυτικής μάθησης που παρουσιάζονται στη βιβλιογραφία εστιάζουν κατά κύριο λόγο σε προβλήματα στα οποία το περιβάλλον ενισχυτικής μάθησης παραμένει σταθερό. Η εφαρμογή της ενισχυτικής μάθησης για την επίλυση προβλημάτων σε πραγματικές συνθήκες τονίζει τις αδυναμίες που έχουν οι παραδοσιακοί αλγόριθμοι ενισχυτικής μάθησης, μιας και σε αρκετές περιπτώσεις οι συνθήκες δεν είναι σταθερές και ο πράκτορας ενισχυτικής μάθησης αποτυγχάνει να προσαρμοστεί στις μεταβαλλόμενες συνθήκες του πραγματικού περιβάλλοντος. Τέτοιες περιπτώσεις χαρακτηρίζονται από δυναμικά ή μη στατικά περιβάλλοντα

ενισχυτικής μάθησης και αποτελούν μια νέα κατεύθυνση της ενισχυτικής μάθησης. Ο Padakandla (2021) εξετάζει τη βιβλιογραφία της ενισχυτικής μάθησης που ασχολείται με δυναμικά μεταβαλλόμενα περιβάλλοντα, παρέχει τον ορισμό των δυναμικών και μη-στατικών περιβαλλόντων ενισχυτικής μάθησης και συγκεντρώνει τους αλγορίθμους που διαχειρίζονται τέτοιου είδους προβλήματα. Σύμφωνα με αυτήν την εργασία, η δυναμικότητα και η στατικότητα ενός περιβάλλοντος εξαρτώνται από τη μορφή των συναρτήσεων μετάβασης και ανταμοιβής. Προσδιορίζει ένα περιβάλλον ως μη-στατικό όταν η συνάρτηση μετάβασης και η συνάρτηση ανταμοιβής είναι μεταβαλλόμενες στην πάροδο του χρόνου.

5.1.2 Ενισχυτική Μάθηση Πολλαπλών Κριτηρίων

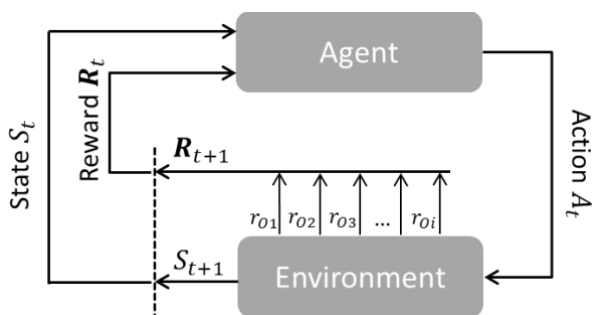
Στα περισσότερα ακολουθιακά προβλήματα λήψης αποφάσεων, μια ανταμοιβή η οποία συσχετίζεται με μία παρατήρηση, αναφέρεται, έμμεσα ή άμεσα, σε ένα κριτήριο βελτιστοποίησης (Smelser, και Baltes, 2001). Η απαίτηση για την επίλυση ακολουθιακών προβλημάτων λήψης αποφάσεων ικανοποιώντας πολλαπλά κριτήρια βελτιστοποίησης είναι αναμενόμενη σε πραγματικές εφαρμογές και αποτελεί μία ερευνητική πρόκληση της έρευνας της βασισμένης σε αποφάσεις μάθησης και προγραμματισμού, η οποία εστιάζει κατά κύριο λόγο σε προβλήματα ενός κριτηρίου βελτιστοποίησης (Roijers, et al., 2013; Liu, et al., 2014).

Οι μαρκοβιανές διαδικασίες απόφασης πολλαπλών κριτηρίων (Multi-Objective Markov Decision Process) προτείνονται από τη βιβλιογραφία για την επίλυση τέτοιων προβλημάτων. Στα μοντέλα αυτού του τύπου η συνάρτηση πιθανότητας μετάβασης και η συνάρτηση ανταμοιβής γνωστές θεωρούνται γνωστές. Σε περιπτώσεις που αυτή η γνώση δεν είναι διαθέσιμη η ενισχυτική μάθηση πολλαπλών κριτηρίων (Multi-Objective Reinforcement Learning) επιτρέπει την βελτιστοποίηση της αλληλεπίδρασης ενός πράκτορα με το περιβάλλον της ενισχυτικής μάθησης λαμβάνοντας υπόψιν πολλαπλά κριτήρια βελτιστοποίησης κατά την εκπαίδευση του πράκτορα (Roijers, et al., 2013).

Στην βιβλιογραφία καταγράφονται αρκετές προσεγγίσεις ενισχυτικής μάθησης που μοντελοποιούν το ακολουθιακό πρόβλημα λήψης αποφάσεων ως ένα πρόβλημα

ενισχυτικής μάθησης πολλαπλών κριτηρίων και αντιμετωπίζουν τα πολλαπλά κριτήρια βελτιστοποίησης ορίζοντας ταυτόχρονες ανταμοιβές (Liu, et al., 2014). Η διαφορά της ενισχυτικής μάθησης πολλαπλών κριτηρίων με την ενισχυτική μάθηση ενός κριτηρίου έγκειται στην ενσωμάτωση δύο ή περισσότερων κριτηρίων βελτιστοποίησης τα οποία ο πράκτορας ενισχυτικής μάθησης καλείται να βελτιστοποιήσει, βελτιστοποιώντας το διάνυσμα ανταμοιβής που είναι διαθέσιμο σε κάθε βήμα (Liu, et al., 2014). Υπό αυτό το πρίσμα, η ενισχυτική μάθηση πολλαπλών κριτηρίων είναι ο συνδυασμός της βελτιστοποίησης πολλαπλών κριτηρίων και των τεχνικών ενισχυτικής μάθησης για την επίλυση ακολουθιακών προβλημάτων λήψης αποφάσεων πολλαπλών κριτηρίων (Liu, et al., 2014).

Το βασικό πλαίσιο της ενισχυτικής μάθησης πολλαπλών κριτηρίων παρουσιάζεται στην Εικόνα 5-3. Σε σύγκριση με τον μηχανισμό μάθησης της παραδοσιακής ενισχυτικής μάθησης που παρουσιάζεται στην Εικόνα 5-1, η ενισχυτική μάθηση πολλαπλών κριτηρίων ενσωματώνει τα κριτήρια βελτιστοποίησης ορίζοντας την ανταμοιβή ως ένα διάνυσμα συναρτήσεων ανταμοιβής R_t , οι διαστάσεις του οποίου αντιστοιχούν στα διαφορετικά κριτήρια. Με τον τρόπο αυτό, σε κάθε κατάσταση του περιβάλλοντος S_t αντιστοιχίζονται περισσότερα από ένα κριτήρια $O_{i \in I}$, καθένα εκ των οποίων έχει διαφορετική ανταμοιβή $r_{O1}, r_{O2}, r_{O3}, \dots, r_{Oi}$. Στην ενισχυτική μάθηση πολλαπλών κριτηρίων ο στόχος βελτιστοποίησης κάθε κριτηρίου μπορεί να διαφέρει καθώς για κάποια κριτήρια μπορεί να απαιτείται η μεγιστοποίησή τους και παράλληλα για άλλα να απαιτείται η ελαχιστοποίησή τους.



Εικόνα 5-3 Ενισχυτική Μάθηση Πολλαπλών Κριτηρίων

Στις περισσότερες προσεγγίσεις ενισχυτικής μάθησης πολλαπλών κριτηρίων, η ταυτόχρονη βελτιστοποίηση των κριτηρίων αντιμετωπίζεται είτε με τον συνδυασμό των ανταμοιβών των κριτηρίων σε μία συνθετική συνάρτηση ανταμοιβής, είτε με τον

συνδυασμό των πολιτικών που καταλήγουν σε ένα Pareto σύνολο λύσεων (Liu, et al., 2014).

Οι προτεινόμενες προσεγγίσεις που βασίζονται στην κυριαρχία Pareto φαίνονται μη αποδοτικές στην διαχείριση προβλημάτων μεγάλου αριθμού κριτηρίων βελτιστοποίησης, στα οποία όλες οι πιθανές λύσεις μπορεί να είναι βέλτιστες ως προς κάποιο κριτήριο (Tozer, et al., 2017). Σε αυτές τις περιπτώσεις, απαιτείται η αλληλεπίδραση με τον αποφασίζοντα ή η εκ των προτέρων γνώση της δομής του προβλήματος προκειμένου να είναι διαθέσιμη η καθοδήγηση για την διαχείριση των βέλτιστων λύσεων. Στην εργασία των Khamis, και Goma, (2014) προτείνεται η βελτιστοποίηση πολλαπλών δεικτών απόδοσης με την οποία θα επιτευχθεί μια συνεπής παραμετροποίηση των φωτεινών σηματοδοτών κυκλοφορίας, σε κάθε διασταύρωση. Σε αυτήν, μοντελοποιείται το πρόβλημα ελέγχου φωτεινών σηματοδοτών κυκλοφορίας ως ένα πρόβλημα ενισχυτικής μάθησης πολλαπλών κριτηρίων στο οποίο πολλαπλοί πράκτορες ενισχυτικής μάθησης δρουν αυτόνομα χωρίς κάποια αλληλεπίδραση με τον άνθρωπο.

Οι Tozer, et al. (2017) εξετάζουν λύσεις επίλυσης προβλημάτων εύρεσης μονοπατιού με πολλαπλά αλληλοσυγκρουόμενα κριτήρια και εισαγάγουν τον ορισμό ενός αλγορίθμου ενισχυτικής μάθησης πολλαπλών κριτηρίων ανεξάρτητου μοντέλου, το οποίο ονομάζουν ως voting Q-learning. Υποστηρίζουν ότι είναι ικανό να ανακαλύψει το σύνολο των βέλτιστων πολιτικών σε ένα αρχικά άγνωστο περιβάλλον με πολλαπλά αλληλοσυγκρουόμενα κριτήρια βελτιστοποίησης. Προτείνουν την αξιοποίηση μεθόδων ψηφοφορίας, προερχόμενων από την θεωρία κοινωνικής επιλογής, με τις οποίες καθορίζουν ένα σύνολο από Pareto βέλτιστες πολιτικές. Το σύνολο αυτό προσδιορίζεται με την συνάθροιση των προτιμήσεων που υποδηλώνονται από την αξιολόγηση των συνθηκών περιβάλλοντος για κάθε κριτήριο. Η εργασία των Yang, et al. (2019) προτείνει έναν αλγόριθμο ενισχυτικής μάθησης πολλαπλών κριτηρίων με γραμμικές προτιμήσεις, που στοχεύει στην διευκόλυνση της προσαρμογής σε νέες εργασίες με λίγες δοκιμές. Μετά την αρχική φάση εκμάθησης, οι πράκτορες που ορίζονται μπορούν να εκτελέσουν την βέλτιστη πολιτική υπό τις δοθείσες προτιμήσεις, ή να εξάγουν αυτόματα τις υποκείμενες προτιμήσεις, βασιζόμενοι σε μικρό αριθμό δειγμάτων.

Οι Roijers, et al. (2018) στην εργασία τους προτείνουν μια προσέγγιση διαδραστικής ενισχυτικής μάθησης πολλαπλών κριτηρίων, στην οποία, σε αντίθεση με παλαιότερες προσεγγίσεις, οι συναρτήσεις χρησιμότητας του χρήστη δεν ορίζονται βάσει αυστηρών υποθέσεων, αλλά επιτρέπει τις μη γραμμικές προτιμήσεις αξιοποιώντας τη μη παραμετρική μπεϋζιανή μάθηση. Η εργασία των Meisheri, et al. (2019) προτείνει μία προσέγγιση βελτιστοποίησης πολλαπλών κριτηρίων για την λήψη αποφάσεων με διασυνδεδεμένο τρόπο (online decisions) σε συστήματα πολλών διαστάσεων. Με την προσέγγιση αυτή λαμβάνουν υπόψιν ταυτόχρονα την γραμμική συμπεριφορά ειδικού επιπέδου του συστήματος και τη μη γραμμική, στοχαστική συμπεριφορά του συστήματος γενικού επιπέδου, η οποία υπόκειται σε περιορισμούς. Το πρόβλημα λήψης αποφάσεων μοντελοποιείται ως ένα πρόβλημα ενισχυτικής μάθησης το οποίο επιλύεται με τεχνικές οδηγούμενες από δεδομένα.

5.1.3 Διαδραστική Ενισχυτική Μάθηση

Η Διαδραστική Ενισχυτική Μάθηση (Interactive Reinforcement Learning) ή ανθρωποκεντρική ενισχυτική μάθηση (Human-Centered Reinforcement Learning) επεκτείνει την ενισχυτική μάθηση δίνοντας τη δυνατότητα σε ανθρώπους χωρίς προηγούμενη γνώση μηχανικής μάθησης να εκπαιδεύσουν διαισθητικά πράκτορες ενισχυτικής μάθησης, μαθαίνοντάς τους πως να εκτελούν κάποιες ενέργειες (Thomaz, et al., 2005; Cruz, et al., 2018; Li, G., et al., 2019). Με τη συνεργασία του ανθρώπου με τους πράκτορες ενισχυτικής μάθησης επιτυγχάνεται μεγαλύτερος βαθμός αλληλεπίδρασης. Ο άνθρωπος μπορεί να κατευθύνει την βέλτιστη συμπεριφορά του πράκτορα εκπαιδεύοντάς τον διαδραστικά σύμφωνα με τις προτιμήσεις του, παραμερίζοντας την προγραμματισμένη βέλτιστη συμπεριφορά του πράκτορα (Li, G., 2019).

Η διαδραστική ενισχυτική μάθηση μπορεί να επιταχύνει τη σύγκλιση σε προβλήματα κλασσικής ενισχυτικής μάθησης αξιοποιώντας την εξειδικευμένη ή μη, γνώση του ανθρώπου, την εμπειρία του και τις προτιμήσεις του (Cruz, et al., 2018). Η επίλυση κάποιων σχετικά προβλημάτων, όπως η εκπαίδευση βιντεοπαιχνιδιών απαιτεί πολύ μεγάλο αριθμό δεδομένων εκπαίδευσης, προκειμένου ένας πράκτορας ενισχυτικής μάθησης εξάγει μια καλή πολιτική. Η καθοδήγηση του πράκτορα από τον

άνθρωπο μπορεί να συμβάλλει στη βελτίωση της απόδοσης και να χαλαρώσει την ανάγκη για πολλά δεδομένα εκπαίδευσης, καθώς εμπεριέχει εξειδικευμένη γνώση που μπορεί να επιταχύνει τη διαδικασία μάθησης.

Η μελέτη των Zhang, R, et al. (2019) ταξινομεί τους διαφορετικούς τύπους ανθρώπινης καθοδήγησης που παρουσιάζονται στη βιβλιογραφία της διαδραστικής ενισχυτικής μάθησης σύμφωνα με τον τρόπο αλληλεπίδρασης του πράκτορα ενισχυτικής μάθησης με τον άνθρωπο. Μεταξύ άλλων, υποστηρίζει ότι ο πράκτορας μπορεί να μιμηθεί τον άνθρωπο, να μάθει μέσω της ανάδρασης, της ανθρώπινης προτίμησης, ή ακόμα και της αναγνώρισης της ανθρώπινης προσοχής. Η πιο συνηθισμένη μορφή καθοδήγησης είναι η μοντελοποίηση της γνώσης του ειδικού σε μια πολιτική, βάσει της οποίας ο άνθρωπος εκτελεί τις κατάλληλες ενέργειες που επιλύουν το πρόβλημα με τον επιθυμητό τρόπο, υποδεικνύοντας στον πράκτορα τις ενέργειες που πρέπει να επιλέξει. Προσεγγίσεις που αφορούν την καθοδήγηση μέσω της επίδειξης ή τη μιμητική μάθηση ορίζουν την ανθρώπινη καθοδήγηση με αυτήν τη μορφή (Zhang, R, et al., 2019). Από την άλλη πλευρά, αρκετά προβλήματα δεν μπορούν να επιλυθούν από τον άνθρωπο, είτε λόγω πολυπλοκότητας είτε λόγω αδυναμίας εκτέλεσης των ενεργειών που εμπεριέχουν. Σύμφωνα με τη βιβλιογραφία, σε περιπτώσεις στις οποίες η εξειδικευμένη γνώση δεν μπορεί να ενσωματωθεί στην επίλυση του προβλήματος με τη μορφή μιας πολιτικής ή δεν είναι δυνατή η συνολική μοντελοποίησή της, ο άνθρωπος μπορεί να καθοδηγήσει τον πράκτορα παρέχοντας ανάδραση για τις ενέργειες και την απόδοση του πράκτορα ενισχυτικής μάθησης.

Η ανάδραση διαχωρίζεται σε δύο κατηγορίες, την αξιολογική ανάδραση (evaluative feedback) και την διορθωτική ανάδραση (corrective feedback) (Najar, και Chetouani, 2021). Στις περισσότερες προσεγγίσεις αξιολογικής ανάδρασης, η ανάδραση ορίζεται ως ένα βαθμωτό μέγεθος το οποίο υποδεικνύει πόσο επιθυμητή ήταν η ενέργεια που επέλεξε ο πράκτορας. Αξιολογεί ουσιαστικά την ποιότητα της συμπεριφοράς του πράκτορα και χρησιμοποιείται προκειμένου να βελτιώσει την πολιτική του πράκτορα (Lin, et al., 2020; Li, G., et al., 2019).

Η καθοδήγηση βάσει ανάδρασης είναι διαθέσιμη πολύ πιο εύκολα, μπορεί να αξιοποιηθεί σε πολλά διαφορετικά προβλήματα και δεν απαιτεί την ρητή μοντελοποίηση της ανθρώπινης γνώσης. Επιπλέον, επιτρέπει την ενσωμάτωση αυτής

με τη μορφή της διαίσθησης ή της εμπειρίας του ανθρώπου, ενώ μπορεί να χρησιμοποιηθεί σε συνδυασμό με τη μιμητική μάθηση. Οι μέθοδοι που ενσωματώνουν την αξιολογική ανάδραση του ανθρώπου στη διαδραστική ενισχυτική μάθηση ταξινομούνται περαιτέρω σε τέσσερις κατηγορίες (Zhang, R., et al., 2019): τις μεθόδους διαμόρφωσης πολιτικής (Policy Shaping), τις μεθόδους διαμόρφωσης ανταμοιβής (Reward Shaping), τις μεθόδους παρέμβασης (Intervention), και τις μεθόδους στις οποίες η ανάδραση εξαρτάται από πολιτική (Policy-dependent Feedback):

- Διαμόρφωση πολιτικής: Μεταφράζει την ανάδραση που παρέχει ο άνθρωπος σε ετικέτες πάνω στην πολιτική του πράκτορα. Η ανάδραση χαρακτηρίζει δυαδικά τις ενέργειες του πράκτορα, παίρνοντας τιμές «Σωστό» και «Λάθος», οι οποίες δηλώνουν εάν η ενέργεια ήταν η βέλτιστη ή όχι. Στις προσεγγίσεις αυτού του τύπου, εφόσον η παροχή ανάδρασης από τον άνθρωπο είναι συνεπής, μετά από την επιτυχή εκμάθηση, η πολιτική του πράκτορα ταυτίζεται με τις βέλτιστες επιλογές του ανθρώπου. Χαρακτηριστικό παράδειγμα της κατηγορίας αυτής είναι η εργασία των Griffith et al. (2013), όπου η θετική και αρνητική ανάδραση του ανθρώπου μοντελοποιείται με τη μορφή πολιτικής, βασισμένη στην διωνυμική κατανομή και στη συνέχεια ενσωματώνεται στην πολιτική του πράκτορα, διαμορφώντας έτσι την πολιτική του πράκτορα βάσει της παρεχόμενης ανάδρασης.
- Διαμόρφωση ανταμοιβής: Η ανάδραση του ανθρώπου μοντελοποιείται με τη μορφή μιας συνάρτησης τιμής, σήματος ή άλλης συνάρτησης ανθρώπινης ανταμοιβής και ενσωματώνεται στην συνάρτηση ανταμοιβής. Η συνάρτηση αυτή σε κάποιες προσεγγίσεις αντικαθιστά πλήρως την συνάρτηση ανταμοιβής του περιβάλλοντος ενισχυτικής μάθησης (Knox, και Stone, 2009). Σε άλλες περιπτώσεις η συνάρτηση ανάδρασης συνδυάζεται με την συνάρτηση ανταμοιβής του περιβάλλοντος ενισχυτικής μάθησης, κατασκευάζοντας έτσι μία συνθετική συνάρτηση ανταμοιβής που περιέχει την ανθρώπινη ανάδραση (Knox, και Stone, 2010).
- Παρέμβαση: Σε αυτές τις προσεγγίσεις, ο άνθρωπος επιβλέπει την διαδικασία μάθησης του πράκτορα και τον καθοδηγεί προκειμένου να αποφύγει

ανεπιθύμητες ενέργειες. Οι καταστάσεις και οι αντίστοιχες ενέργειες που υποδεικνύονται ως ανεπιθύμητες μπορούν να χρησιμοποιηθούν για την εκπαίδευση ενός δυαδικού ταξινομητή ο οποίος θα εντοπίζει και σταματάει την εκδήλωση αυτών των ενεργειών.

- Ανάδραση εξαρτώμενη από πολιτική: Μια εναλλακτική προσέγγιση θεωρεί ότι η ανάδραση που δίνεται από τον χρήστη για κάθε ενέργεια που εκτελεί ο πράκτορας, έχει άμεση εξάρτηση από την πολιτική που ακολουθεί ο πράκτορας. Στην εργασία των MacGlashan, et al. (2017, July), η ανάδραση του ανθρώπου μοντελοποιείται με μία συνάρτηση πλεονεκτήματος με την οποία αξιολογείται πόσο κοντά ή πόσο μακριά είναι πολιτική που ακολουθεί ο πράκτορας από την ζητούμενη. Η συνάρτηση αυτή συγκλίνει στο μηδέν όσο η πολιτική του πράκτορα προσεγγίζει τη ζητούμενη από τον άνθρωπο πολιτική.

Ο άνθρωπος μπορεί να δώσει ανάδραση με πολλούς διαφορετικούς τρόπους, με αποτέλεσμα η μοντελοποίηση της ανάδρασης σε κάθε πρόβλημα να εξαρτάται από την πηγή ανάδρασης, την πληροφορία που αυτή αποτυπώνει, τον μηχανισμό συλλογής ανάδρασης και την αλληλεπίδρασή του με τους αλγορίθμους ενισχυτικής μάθησης. Η πλειοψηφία των μελετών βασίζονται στη συλλογή της ανάδρασης του ανθρώπου με τη βοήθεια απλών μηχανισμών, όπως το πάτημα ενός κουμπιού ή το κλικ ενός ποντικιού ηλεκτρονικού υπολογιστή. Σε πραγματικές εφαρμογές η ανάδραση μπορεί να δοθεί από τον χρήστη μέσα από διαφορετικές βιολογικές αλληλεπιδράσεις, όπως για παράδειγμα συναισθήματα, εκφράσεις προσώπου, χειρονομίες και φυσική γλώσσα. Η μάθηση μέσω ανάδρασης παρεχόμενης με αυτούς τους τρόπους φαίνεται ιδιαίτερα χρήσιμη στον τομέα της Αλληλεπίδρασης Ανθρώπου-Ρομπότ (Human Robot Interaction), κάνοντας πιο αποτελεσματική την επικοινωνία των ρομπότ με τον άνθρωπο και την αλληλεπίδρασή τους πιο φυσική.

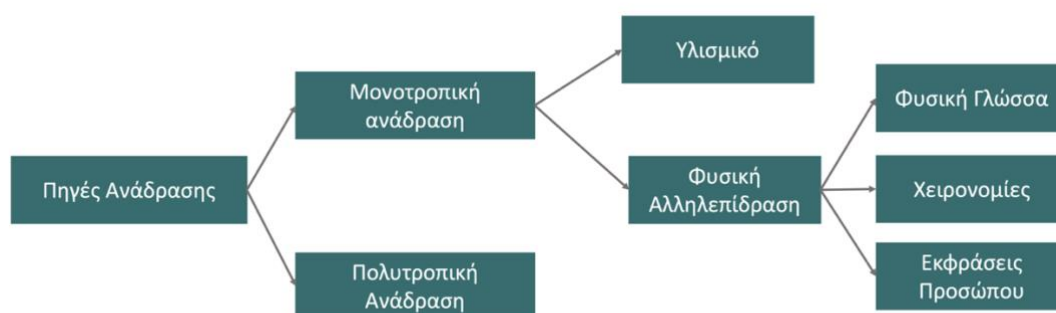
Στην εργασία των Lin, et al. (2020) ταξινομούνται οι διαφορετικές πηγές ανάδρασης της διαδραστικής ενισχυτικής μάθησης όπως φαίνονται στην Εικόνα 5-4. Στο πρώτο επίπεδο κατηγοριοποίησης οι συγγραφείς διαχωρίζουν της πηγές ανάδρασης σε μονοτροπικές και πολυτροπικές. Στις μονοτροπικές εντάσσουν τις πηγές που επιτρέπουν την επικοινωνία με έναν μόνο τρόπο και στις πολυτροπικές

εντάσσουν τις πηγές που επιτρέπουν την παροχή ανάδρασης με παραπάνω από έναν τρόπους.

Οι μονοτροπικές πηγές ανάδρασης συνήθως υλοποιούνται είτε αξιοποιώντας κάποια μορφή υλισμικού είτε με τη μορφή φυσικής αλληλεπίδρασης με τον άνθρωπο. Παράδειγμα της συλλογής με τη βοήθεια υλισμικού είναι οι περιπτώσεις στις οποίες ο άνθρωπος καλείται να δώσει ανάδραση χρησιμοποιώντας το πληκτρολόγιο ή το ποντίκι του υπολογιστή ή κάποια άλλη συσκευή, πατώντας συγκεκριμένα κουμπιά που αντιστοιχούν στην ανάδραση που θέλει να δώσει. Η συλλογή με αυτό τον τρόπο είναι πολύ συγκεκριμένη, ακριβής και εύκολη καθώς τα δεδομένα ανάδρασης που συλλέγονται με αυτό τον τρόπο είναι δομημένα. Παρόλα αυτά ο άνθρωπος αργεί να αντιδράσει καθώς πρέπει να μεταφράσει τη διαισθητική ανάδρασή του σε ρητή επιλέγοντας την κατάλληλη ενέργεια, γεγονός που προσθέτει καθυστέρηση στη συλλογή της ανάδρασης και κατά συνέπεια στην εκπαίδευση του πράκτορα. Επιπλέον σε αυτήν την περίπτωση, ο άνθρωπος θα πρέπει να είναι εξοικειωμένος και κατάλληλα εκπαιδευμένος για τη χρήση της υλισμικής διεπαφής. Εναλλακτικά η ανάδραση του ανθρώπου μπορεί να παρέχεται με φυσική αλληλεπίδραση, κατά κανόνα μέσω της φυσικής γλώσσας, χειρονομιών και εκφράσεων προσώπου. Με αυτούς τους τρόπους συλλογής η αλληλεπίδραση με τον άνθρωπο είναι πιο φυσική και η διαισθητική του ανάδραση συλλέγεται πιο άμεσα, μιας και δεν απαιτείται από τον άνθρωπο η ρητή μετάφραση της ανάδρασης σε κάποια ενέργεια. Έτσι, μειώνεται ο χρόνος συλλογής της ανάδρασης, ενώ επιπροσθέτως, δεν απαιτούνται εξειδικευμένες τεχνικές ικανότητες από τον άνθρωπο. Από την άλλη πλευρά, τα δεδομένα ανάδρασης αποτελούν σύνολα μη δομημένων δεδομένων, γεγονός που καθιστά την επεξεργασία τους τεχνολογικά και αλγοριθμικά πιο απαιτητική. Η ταξινόμηση της ανάδρασης μέσα από δεδομένα τέτοιου είδους δεν είναι σαφώς καθορισμένη και εμπεριέχει αβεβαιότητα. Για παράδειγμα μία έκφραση προσώπου δεν μπορεί να χαρακτηριστεί με απόλυτη ακρίβεια καθώς μπορεί να διαφέρει από άνθρωπο σε άνθρωπο και επηρεάζεται από τα χαρακτηριστικά προσώπου του ανθρώπου. Αντίστοιχα, και στην περίπτωση της φυσικής γλώσσας, δεν εκφράζονται όλοι οι άνθρωποι με τον ίδιο τρόπο και θα πρέπει

να αναγνωρίσουμε το είδος της ανάδρασης (π.χ. θετική ή αρνητική) μέσα από το παρεχόμενο κείμενο.


Εκτός από τις μονοτροπικές πηγές ανάδρασης παρατηρούνται και πολυτροπικές πηγές οι οποίες συνδυάζουν διαφορετικούς τρόπους παροχής ανάδρασης. Οι πολυτροπικές πηγές ανάδρασης παρουσιάζουν μεγαλύτερη διαθεσιμότητα, αφού όταν κάποιος τρόπος αλληλεπίδρασης δεν είναι διαθέσιμος, η ανάδραση μπορεί να ληφθεί και να υποστηριχθεί από τους υπόλοιπους. Τα δεδομένα που συλλέγονται σε τέτοιες περιπτώσεις είναι πιο πλούσια σε πληροφορία διαφορετικών ειδών. Οι διαφορετικές πηγές ανάδρασης αλληλοσυμπληρώνουν και εμπλουτίζουν την ανάδραση που συλλέγεται. Τα μειονεκτήματα των πολυτροπικών πηγών ανάδρασης είναι η απαιτητική τεχνολογική ανάπτυξη του μηχανισμού συλλογής ανάδρασης που μπορεί να υποστηρίξει πολλαπλές αναπαραστάσεις ανάδρασης (π.χ. χειρονομίες και λόγος μαζί) και η απαιτητική μοντελοποίηση και επεξεργασία των δεδομένων που προέρχονται από διαφορετικές πηγές.



Εικόνα 5-4 Πηγές ανάδρασης ανθρώπου (Lin et al., 2020)

Ο σκοπός της διαδραστικής ενισχυτικής μάθησης είναι η ενσωμάτωση της αξιολογικής ανάδρασης μέσω της οποίας οι αλγόριθμοι ενισχυτικής μάθησης μπορούν να βελτιστοποιηθούν με ελάχιστη προσπάθεια από τον άνθρωπο, ενώ αυτός συμμετέχει στη διαδικασία (Cruz, et al., 2018; Littman, 2015). Ο άνθρωπος μπορεί να μην είναι ειδικός στην επίλυση του προβλήματος που επιχειρούμε να λύσουμε με τη βοήθεια της ενισχυτικής μάθησης, όμως μπορεί να κατέχει διαισθητική ή εμπειρική γνώση σχετικά με την λύση του προβλήματος με τη βοήθεια της οποία ο πράκτορας μπορεί να μειώσει τον χρόνο αναζήτησης και να επιταχύνει

τη μάθηση (Li, G., et al., 2019; Knox, και Stone, 2011). Το βασικό πλαίσιο της διαδραστικής ενισχυτικής μάθησης παρουσιάζεται στην Εικόνα 5-5. Σε σχέση με τον μηχανισμό μάθησης της ενισχυτικής μάθησης που παρουσιάζεται στην Εικόνα 5-1, η διαδραστική ενισχυτική μάθηση ενσωματώνει την ανάδραση του ανθρώπου H_t , η οποία μετασχηματίζεται σε $H_{(t+1)}$ τη χρονική στιγμή $t + 1$. Επιπροσθέτως, η ενέργεια A_t που επιλέγεται από τον πράκτορα, σε συνδυασμό με την κατάσταση S_t του περιβάλλοντος επικοινωνούνται στον άνθρωπο. Ο πράκτορας βελτιστοποιεί την πολιτική του αλληλοεπιδρώντας συνεχώς με το περιβάλλον και τον άνθρωπο έως ότου μάθει την βέλτιστη πολιτική που συνδυάζει την ανταμοιβή του περιβάλλοντος με την ανάδραση του ανθρώπου.



Εικόνα 5-5 Διαδραστική Ενισχυτική Μάθηση

Η παρούσα εργασία εστιάζει στην αξιοποίηση της αξιολογικής ανάδρασης που δίνει ο άνθρωπος πάνω στις ενέργειες που επιλέγει ο πράκτορας. Μία από τις βασικότερες προκλήσεις είναι η κατάλληλη μετάφραση της ανθρώπινης ανάδρασης μιας και αυτή η μετάφραση θα καθορίσει τον τρόπο με τον οποίο θα αξιοποιηθεί η ανάδραση για να βελτιώσει την πολιτική του πράκτορα, σε περιβάλλοντα βασισμένα σε μαρκοβιανή διαδικασία απόφασης (Cruz, et al., 2018).

Όλα τα παραπάνω υποδηλώνουν ότι για να είναι επιτυχής η ενσωμάτωση της ανάδρασης του ανθρώπου σε εφαρμογές διαδραστικής ενισχυτικής μάθησης, πέρα από την επιλογή και ανάπτυξη των κατάλληλων αλγορίθμων, απαιτείται ο προσεκτικός σχεδιασμός του μηχανισμού συλλογής και επεξεργασίας της ανάδρασης του ανθρώπου. Κατά την ανάπτυξη του μηχανισμού αυτού πρέπει να ληφθεί υπόψη η καθυστέρηση στην παροχή ανάδρασης η οποία επηρεάζει καθοριστικά την

απόδοση των εφαρμογών διαδραστικής ενισχυτικής μάθησης. Επιπλέον, η διεπαφή και ο τρόπος αλληλεπίδρασης με τον άνθρωπο πρέπει να σχεδιαστεί κατάλληλα. Η κούραση που προκαλεί και η δυσκολία χρήσης της διεπαφής μπορεί να αποτρέψει τον άνθρωπο από την παροχή ανάδρασης ή να επηρεάζει το είδος της ανάδρασης που δίνει. Για παράδειγμα ένας απογοητευμένος χρήστης είναι πιθανότερο να δώσει αρνητική ανάδραση εξαιτίας της αρνητικής εντύπωσης που έχει για τη διεπαφή. Εκτός από τον σχεδιασμό μιας εύχρηστης διεπαφής παροχής ανάδρασης, είναι σημαντικό να δίνεται στον άνθρωπο κίνητρο για να παρέχει την ανάδραση. Η συμβολή που έχει η ανάδραση του ανθρώπου στα αποτελέσματα μιας εφαρμογής διαδραστικής ενισχυτικής μάθησης δεν είναι απαραίτητα κατανοητή από τον άνθρωπο. Ακόμη και στις περιπτώσεις που ο άνθρωπος αναγνωρίζει την αξία της ανάδρασης, μπορεί να μην επιλέγει να αλληλοεπιδράσει και να βρίσκει την αλληλεπίδραση αδιάφορη ή βαρετή (Arzate, και Igarashi, 2020).

Τα τελευταία έτη, η διαδραστική ενισχυτική μάθηση έχει κερδίσει το ερευνητικό ενδιαφέρον του τομέα της ενισχυτικής μάθησης. Οι (Knox, και Stone, 2012) προτείνουν το πλαίσιο TAMER στο οποίο εντάσσονται προσεγγίσεις ενισχυτικής μάθησης που κατευθύνουν τη σχεδίαση των πρακτόρων με στόχο τη διαμόρφωση της συμπεριφοράς τους χρησιμοποιώντας σήματα αποδοχής ή απόρριψης. Η προτεινόμενη προσέγγιση δίνει τη δυνατότητα επαύξησης της παραδοσιακής ενισχυτικής μάθησης με την ενσωμάτωση της ανθρώπινης ανάδρασης, σε προβλήματα βασισμένα στη μάθηση ανταμοιβής της μαρκοβιανής διαδικασίας απόφασης του περιβάλλοντος. Επιπλέον, διευκολύνει τη μεταφορά γνώσης από τον άνθρωπο στον πράκτορα οδηγώντας σε πιο γρήγορη μάθηση με λιγότερες δοκιμές. Στη βιβλιογραφία παρουσιάζονται πολλές επεκτάσεις του προτεινόμενου πλαισίου TAMER, το οποίο αποτελεί τη βάση αρκετών ερευνητικών εργασιών. Οι Griffith et al. (2013) προτείνουν μια μπεϋζιανή προσέγγιση διαμόρφωσης πολιτικής μέσω της ανθρώπινης ανάδρασης. Σε αυτήν, επιχειρείται η μεγιστοποίηση της πληροφορίας που προέρχεται από την ανάδραση του ανθρώπου, η οποία έχει τη μορφή ετικετών πάνω στην πολιτική του πράκτορα. Η προσέγγιση αυτή φαίνεται να υπερισχύει παρόμοιων προσεγγίσεων, ενώ παράλληλα φαίνεται αποδοτική σε περιπτώσεις σπάνιας και ασυνεπούς ανάδρασης.

Η μελέτη των Krening και Feigh (2018) εξετάζει την σχεδίαση της μεθόδου αλληλεπίδρασης ενός μπεϋζιανού q-learning αλγορίθμου και πως αυτή επηρεάζει την εμπειρία μάθησης του πράκτορα μέσω ανάδρασης, από την σκοπιά του ανθρώπου. Τα αποτελέσματα της μελέτης δείχνουν έναν πράκτορα ο οποίος μαθαίνει από συμβουλές ενεργειών και δημιουργεί μια καλύτερη εμπειρία χρήστη, συγκριτικά με έναν πράκτορα ο οποίος μαθαίνει από έναν δυαδικό κριτή. Η σύγκριση γίνεται σύμφωνα με την απογοήτευση, την αντιληπτή απόδοση, τη διαφάνεια, την αμεσότητα και την αντιληπτή ευφυΐα όπως αυτές γίνονται αντιληπτές από τον χρήστη. Επιπλέον, στην ίδια μελέτη αναγνωρίζονται και καταγράφονται εννέα χαρακτηριστικά τα οποία επηρεάζουν την εμπειρία αλληλεπίδρασης του ανθρώπου με τον πράκτορα. Μεταξύ αυτών, συμπεριλαμβάνονται η συμμόρφωση με την είσοδο, η ενδυνάμωση, η διαφάνεια, η αμεσότητα, η ντετερμινιστική αλληλεπίδραση, η πολυπλοκότητα των οδηγιών, η ακρίβεια του λογισμικού αναγνώρισης ομιλίας και η εύρωστη και ευέλικτη φύση του αλγορίθμου αλληλεπίδρασης.

Η εργασία των Cruz, et al. (2016) συγκρίνει τρεις διαφορετικές μεθόδους διαδραστικής ενισχυτικής μάθησης βασισμένες στην ρομποτική προσομοίωση τυπικών οικιακών δραστηριοτήτων καθαριότητας. Οι συγκρινόμενες μέθοδοι ήταν η ενισχυτική μάθηση, η ενισχυτική μάθηση με συμφραζόμενες δυνατότητες (contextual affordances) με σκοπό την αποφυγή των καταστάσεων αποτυχίας, και ήδη εκπαιδευμένα ρομπότ τα οποία παίρνουν τον ρόλο του εκπαιδευτή ενός δεύτερου ρομπότ. Η έρευνα αυτή δείχνει ότι η χρήση της διαδραστικής ενισχυτικής μάθησης οδηγεί σε διαφορετική απόδοση με διαφορετικά επίπεδα αλληλεπίδρασης και συνέπειας ανάδρασης. Σύμφωνα με τα αποτελέσματα της έρευνας, η συνέπεια της ανθρώπινης ανάδρασης αποτελεί έναν κρίσιμο παράγοντα για την απόδοση του αλγορίθμου, καθώς οποιοσδήποτε ασυνέπειες προσθέτουν καθυστερήσεις στην διαδικασία μάθησης.

Παρακινούμενοι από το γεγονός ότι η μάθηση από ανταμοιβή παραγόμενη από ανθρώπους-εκπαιδευτές παρουσιάζει πολλές δυνατότητες στην εκπαίδευση αυτόνομων πρακτόρων, οι Li, G, et al. (2018) ασχολούνται με την επιρροή της κοινωνιο-ανταγωνιστικής ανάδρασης του πράκτορα στην συμπεριφορά του

ανθρώπου-εκπαιδευτή και στη μάθηση του πράκτορα. Η εργασία των (Raza και Williams, 2020) προτείνει μια μέθοδο αντικατάστασης της παραδοσιακής μεθόδου ανάθεσης ανταμοιβής με την ανάθεση ενεργειών στη διαδραστική ενισχυτική μάθηση. Η σύγκριση μεταξύ της ανάθεσης ενεργειών με την ανάθεση ανταμοιβής έδειξε ότι η ανάθεση ενεργειών βελτιώνει σημαντικά την ικανότητα του χρήστη να διδάξει την ζητούμενη συμπεριφορά. Τα αποτελέσματα της έρευνας έδειξαν ότι και οι δύο τρόποι ανάθεσης γίνονται αντιληπτοί ως φυσικοί και εύχρηστοι. Επιπροσθέτως, η ανάθεση ανταμοιβής αντιμετωπίζεται ως γνωστικά πιο απαιτητική, καθώς προϋποθέτει την επαναλαμβανόμενη ανάθεση ανταμοιβής.

Από την πλευρά του χρήστη, η ανυπακοή του πράκτορα στις υποδείξεις του χρήστη δημιουργεί εκνευρισμό, ενώ οι χρήστες προτιμούν να ελέγχουν απευθείας την συμπεριφορά του πράκτορα. Οι πρόσφατες εξελίξεις στον τομέα της τεχνητής νοημοσύνης και η εμφάνιση της βαθιάς μηχανικής μάθησης επηρεάζουν σαφώς την διαδραστική ενισχυτική μάθηση. Παράδειγμα αυτών ασχολείται με την ανάπτυξη υπολογιστικών μοντέλων τα οποία αποτελούνται από πολλαπλά υπολογιστικά επίπεδα κατάλληλα για τη μάθηση αναπαραστάσεων των δεδομένων, με πολλαπλά επίπεδα αφαίρεσης (LeCun, et al., 2015).

Υπό αυτό το πρίσμα, η εργασία των Arumugam, et al. (2019) προτείνει την εφαρμογή των βαθιών νευρωνικών δικτύων (Deep Neural Networks) για την ενίσχυση της ανθρώπινης ανάδρασης με τη μορφή ενός κριτή της τρέχουσας συμπεριφοράς ενός πράκτορα. Οι Christiano et al. (2017) αναπτύσσουν μια προσέγγιση βαθιάς μηχανικής μάθησης για τη μεταφορά πολύπλοκων στόχων στον πράκτορα, όπου οι στόχοι βασίζονται στις προτιμήσεις του ανθρώπου πάνω σε ζεύγη τμημάτων τροχιάς. Η εργασία των Zhang, Q, et al. (2020) προτείνει μία μέθοδο βαθιάς διαδραστικής ενισχυτικής μάθησης για την επιλογή μονοπατιών των αυτόνομων υποβρύχιων οχημάτων. Σε αυτήν, η μάθηση βασίζεται σε ταυτόχρονο συνδυασμό της ανθρώπινης ανταμοιβής με την ανταμοιβή του περιβάλλοντος.

Παρά τα υποσχόμενα αποτελέσματα προσεγγίσεων βαθιάς διαδραστικής ενισχυτικής μάθησης, σε σχέση με την εκτίμηση της βέλτιστης απόδοσης, η απουσία επεξηγηματικών προσεγγίσεων θέτει σημαντικά εμπόδια στο να κατορθωθεί η βέλτιστη συνέργεια ανθρώπου-μηχανής (Heuillet, et al., 2021). Αυτό είναι ιδιαίτερα

σημαντικό στη διαδραστική ενισχυτική μάθηση, όπου ο άνθρωπος είναι ένα κομβικό μέρος της διαδικασίας μάθησης και της απόδοσης των αλγορίθμων (Huber et al., 2019, September).

5.2 Μέθοδος

Βασική συνεισφορά της παρούσας διδακτορικής διατριβής αποτελεί η προτεινόμενη προσέγγιση επαυξημένης από τον άνθρωπο προδιαγραφικής αναλυτικής δεδομένων. Η προσέγγιση βασίζεται στην διαδραστική ενισχυτική μάθηση πολλαπλών κριτηρίων (IMORL) για τη μοντελοποίηση και επίλυση της ακολουθιακής διαδικασίας λήψης απόφασης που ενσωματώνει την ανθρώπινη ανάδραση. Ο στόχος της προσέγγισης είναι να προδιαγράψει τις βέλτιστες ενέργειες οι οποίες βελτιστοποιούν ταυτόχρονα πολλά διαφορετικά κριτήρια, και παράλληλα ικανοποιούν τις προτιμήσεις του ανθρώπου. Η διαδικασία λήψης απόφασης μοντελοποιείται με έναν δυναμικό τρόπο προκειμένου να εγγυάται την επεκτασιμότητα και την εφαρμοσιμότητα της προσέγγισης σε ένα μεγάλο εύρος προβλημάτων και πεδίων εφαρμογής.

Για να μπορέσει να ικανοποιήσει την πολυκριτηριακή φύση της λήψης απόφασης και να διαχειριστεί την ανθρώπινη συμμετοχή σε αυτή, η προτεινόμενη προσέγγιση βασίζεται στον μηχανισμό εκπαίδευσης της IMORL. Η IMORL συνδυάζει την διαδραστική ενισχυτική μάθηση με την ενισχυτική μάθηση πολλαπλών κριτηρίων. Η προτεινόμενη μέθοδος παρουσιάζεται στην Εικόνα 5-6.

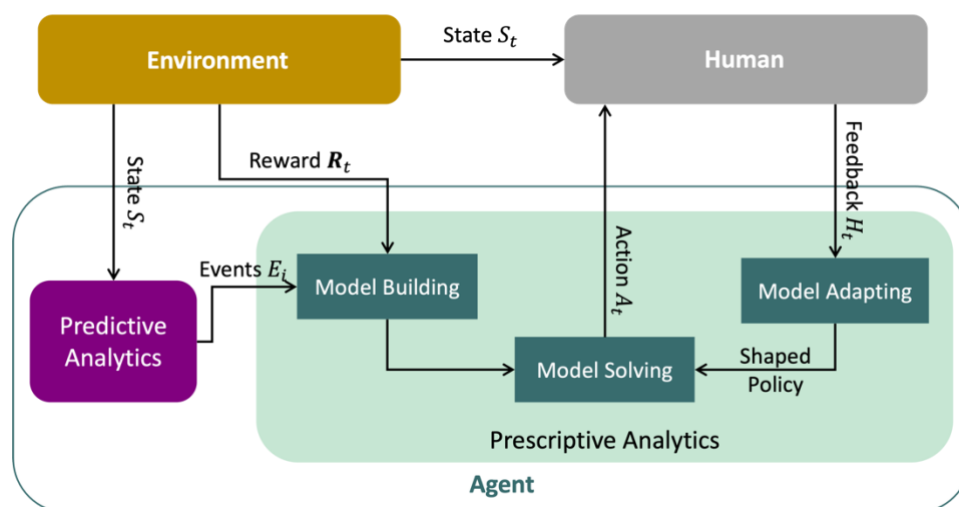
Ο **Πράκτορας (Agent)** εμπεριέχει το μοντέλο προβλεπτικής και το μοντέλο προδιαγραφικής αναλυτικής. Μιας και εξ' ορισμού η προδιαγραφική αναλυτική λαμβάνει ως είσοδο τα εξαγόμενα αποτελέσματα της προβλεπτικής αναλυτικής δεδομένων [j1] το πρόβλημα της προδιαγραφικής αναλυτικής ορίζεται σε ένα περιβάλλον ροών δεδομένων όπου τα προδιαγραφικά μοντέλα ενεργοποιούνται από τις προβλέψεις που αφορούν μελλοντικά γεγονότα. Η ανάπτυξη των βημάτων προβλεπτικής αναλυτικής δεδομένων που απαιτούνται ως προϋπόθεση για την ενεργοποίηση της παρούσας προδιαγραφικής μεθόδου μπορεί να γίνει με πολλές

μεθόδους και αλγορίθμους που έχουν προταθεί από τη βιβλιογραφία (Hariri, et al., 2019; Mikalef, et al., 2018; Fawaz, et al., 2019; Močarníková, et al., 2020).

Η προτεινόμενη μέθοδος στοχεύει στην παραγωγή προδιαγραφών οι οποίες αποτελούνται από ένα υποσύνολο ενεργειών $Presc = (A_1, A_2, \dots, A_f)$ των υποψήφιων λύσεων. Οι ενέργειες αυτές βελτιστοποιούν τα κριτήρια (objectives) $O_{i \in I}$, αποφεύγοντας παράλληλα την εκδήλωση κάποιου ανεπιθύμητου μελλοντικού γεγονότος ή αξιοποιώντας την εκδήλωση ενός επιθυμητού μελλοντικού γεγονότος. Ταυτόχρονα, η μέθοδος ενσωματώνει τις προτιμήσεις του ανθρώπου έτσι ώστε να παρέχει μη επεμβατική υποστήριξη στον άνθρωπο. Θεωρούμε ένα προβλεπτικό μοντέλο M το οποίο υλοποιεί κάποιον αλγόριθμο προβλεπτικής αναλυτικής δεδομένων. Οι παραγόμενες από το μοντέλο αυτό προβλέψεις ενεργοποιούνται όταν το **Περιβάλλον (Environment)** βρίσκεται σε μια **Κατάσταση (State)** S_t που αντιπροσωπεύει το σύνολο των μελλοντικών **Γεγονότων (Events)** E_i, \dots, E_j τα οποία στοχεύουμε να αποφύγουμε ή να εκμεταλλευτούμε:

$$M = Pr((E_i, \dots, E_j, \dots) | (E_1, E_2, E_3, \dots, E_{i-1}))$$

Ακολούθως, οι προβλέψεις ενεργοποιούν το μέρος της προδιαγραφικής αναλυτικής που εμπεριέχεται στον Πράκτορα, το οποίο με τη σειρά του αλληλοεπιδρά με τον **Άνθρωπο (Human)**.



Εικόνα 5-6 Προτεινόμενη προσέγγιση για επαυξημένη από τον άνθρωπο προδιαγραφική αναλυτική δεδομένων με IMORL

Ακολουθώντας το πλαίσιο της διατριβής, η προτεινόμενη μέθοδος αποτελείται από τρία επιμέρους δομικά στοιχεία:

- (i) Κατασκευή Προδιαγραφικού Μοντέλου (Prescriptive Model Building)
- (ii) Επίλυση Προδιαγραφικού Μοντέλου (Prescriptive Model Solving)
- (iii) Προσαρμογή Προδιαγραφικού Μοντέλου (Prescriptive Model Adapting)

Ο Πίνακας 5-1 συνοψίζει τη σημειογραφία που χρησιμοποιείται στις επόμενες παραγράφους, ενώ ο Πίνακας 5-2 παρέχει ένα περίγραμμα της προτεινόμενης προσέγγισης.

Notation	Description
E	Event stream, an infinite linearly ordered stream of past, present and future events
M	Event predictor that generates the event predictions
$Pred$	Prediction of the future events that need to be eliminated or exploited
$O_i, i \in I$	Optimization objectives
$O_i(t), n \in \mathbb{N}$	Objectives' observations collected as historical data
$\{A_m\}, m \in J, J \in \mathbb{N}$	Finite sets of actions that can be planned and implemented simultaneously, have an impact over the optimization objectives and can possibly affect the manifestation of future events
H_{Presc}	Evaluative human feedback, defined as a step function, with several levels of negative or positive feedback
$\{S_i\}, i \in I$	RL State space
$\{a_j\}, j \in J$	RL Action space
S_G	Goal state, the state that the agent is trying to reach during the episodes in which all the undesired events have been avoided and the desired events have occurred
S_F	Undesired state, an optional state that the agent will try to avoid. Represents the state in which the undesired events have occurred, and the opportunity of the desired future events has been missed.

S_N	Starting state, where all the past and present events have occurred, while the desired and undesired events have been predicted
$S_{\{A_m\}}$	States representing the events that correspond to the implementation of the actions included in the subset $\{A_m\}, m \in J, J \in \mathbb{N}$
$\pi_{O_i}(s, a)$	Objective's optimal policy
$\pi_{MOopt}(s, a)$	Multi-objective optimal policy
$\pi_{FOpt}(s, a)$	Human feedback policy
L	Feedback likelihood
C	Feedback consistency
$\pi_{opt}(s, a)$	Shaped optimal policy
$Presc$	Prescription of the appropriate set of actions among the candidate solutions

Πίνακας 5-1 Σημειογραφία μεθόδου

Method: Human-Augmented Prescriptive Analytics

1. Define current state, objectives and desired and undesired future events $E, O_i, i \in I, \{A_m\}, m \in J, J \in \mathbb{N}$

2. Observe objectives from historical data

$$\mathbf{O}_i(t) = (o_1^i, o_2^i, \dots, o_n^i), \quad n \in \mathbb{N}$$

3. Receive predictions for upcoming future events

$$Pred = Pr((E_i, \dots, E_j, \dots) | (E_1, E_2, E_3, \dots, E_{i-1}))$$

4. Prescriptive Model Building

(i) Define state space $\{S_i\}, i \in I$, action space $\{a_j\}, j \in J$, starting state S_N , goal state S_G and optional undesired future state S_F that will constitute the MDP model

(ii) Use historical objectives' observations $\mathbf{O}_i(t), n \in \mathbb{N}$ to define the reward function $\mathbf{R} : S \times A \times S \rightarrow \mathbb{R}_n$

5. Prescriptive Model Solving

(i) Calculate optimal policy $\pi_{O_i}(s, a)$ for each **objective** $O_i, i \in I$, with an actor-critic algorithm

(ii) Calculate the multi-objective optimal policy $\pi_{MOopt}(s, a)$, given that the objectives are independent to each other:

$$\pi_{MOopt}(s, a) = \prod_{i \in I} \pi_{O_i}(s, a)$$

6. Prescriptive Model Adapting

(i) Calculate the feedback policy $\pi_{Fopt}(s, a)$ with given feedback:

For each RL action calculate the probability:

$$Pr_H(a) = C^{A_{s,a}} + (1 - C)^{\sum_{j \neq a} A_{s,j}}$$

(ii) Shape multi-objective policy:

$$\pi_{opt}(s, a) = \pi_{MOopt}(s, a) * \pi_{Fopt}(s, a)$$

7. Return prescription $Presc = (A_1, A_2, \dots, A_f)$

8. Collect feedback for the generated prescription

$$H_{Presc} = \begin{cases} H^- \in \mathbb{R}^-, & \text{negative feedback} \\ 0, & \text{neutral} \\ H^+ \in \mathbb{R}^+, & \text{positive feedback} \end{cases}$$

Πίνακας 5-2 Περίγραμμα προτεινόμενης μεθόδου

5.2.1 Κατασκευή Προδιαγραφικού Μοντέλου

Σε αυτήν τη φάση, μοντελοποιείται η ροή γεγονότων, τα κριτήρια βελτιστοποίησης, οι ενέργειες και η ανάδραση του ανθρώπου ακολούθως.

Ροή Γεγονότων: Θεωρούμε τη μη πεπερασμένη ροή γεγονότων $E = \langle E_1, E_2, E_3, \dots, E_i, \dots, E_j, \dots, E_k, \dots, E_l, \dots \rangle, i < j < k < l \in \mathbb{N}$. Κάθε γεγονός E_i είναι μια πλειάδα ορισμένη από τον τύπο του γεγονότος και τα συσχετιζόμενα χαρακτηριστικά του. Τα γεγονότα της ροής είναι γραμμικά ταξινομημένα ως προς το

χρόνο και χαρακτηρίζονται από το χρόνο εκδήλωσής τους σε παρελθοντικά γεγονότα, παροντικά γεγονότα και μελλοντικά γεγονότα.

Κριτήρια βελτιστοποίησης: Θεωρούμε ένα πρόβλημα που στοχεύει στην βελτιστοποίηση κάποιων ανεξάρτητων και πιθανώς αντικρουόμενων μεταξύ τους κριτηρίων βελτιστοποίησης $O_{i \in I}$. Υποθέτουμε ότι οι παρατηρήσεις αυτών των κριτηρίων συναρτήσει χρόνου $O_i(t) = (o_1^i, o_2^i, \dots, o_n^i)$, $n \in \mathbb{N}$, για παρελθοντικά και παροντικά γεγονότα, είναι γνωστές και διαθέσιμες από το περιβάλλον του προβλήματος, μαζί με τις αντίστοιχες ανταμοιβές, ενώ οι μελλοντικές τιμές τους μπορούν να εκτιμηθούν με τη βοήθεια της προβλεπτικής αναλυτικής δεδομένων. Η υπό συνθήκη ανεξαρτησία των κριτηρίων βελτιστοποίησης μπορεί να επιβεβαιωθεί είτε μέσω της γνώσης του επιστημονικού πεδίου του προβλήματος, είτε με στατιστικές μεθόδους.

Ενέργειες (Actions): Θεωρούμε ότι υπάρχει ένα πεπερασμένο σύνολο ενεργειών $\{A_m\}, m \in J, J \in \mathbb{N}$, οι οποίες καθορίζονται είτε με την καθοδήγηση του ειδικού του προβλήματος είτε με την επεξεργασία των ιστορικών δεδομένων των υλοποιημένων ενεργειών. Οι ενέργειες αυτές μπορούν να χρονο-προγραμματιστούν και να υλοποιηθούν ταυτόχρονα και η υλοποίησή τους επιδρά στις τιμές των κριτηρίων βελτιστοποίησης. Επιπλέον, έχει τη δυνατότητα να επηρεάσει την εκδήλωση των μελλοντικών γεγονότων. Όταν μια ενέργεια υλοποιείται ή χρονο-προγραμματίζεται, τότε μετασχηματίζεται σε γεγονός.

Ανάδραση Ανθρώπου (Human feedback): Στην παρούσα προσέγγιση η ανθρώπινη ανάδραση αναπαρίσταται από μία βαθμωτή συνάρτηση η οποία περιέχει διαφορετικά επίπεδα θετικής ή αρνητικής ανάδρασης H_{Presc} . Τα επίπεδα αυτά αντιστοιχούν στα διαφορετικά επίπεδα ικανοποίησης ή δυσαρέσκειας σχετικά με τις ενέργειες που περιέχονται στις παραγόμενες προδιαγραφές και προτείνονται για τη δεδομένη κατάσταση. Η ανάδραση που παρέχει ο άνθρωπος αναπροσαρμόζει τον προδιαγραφικό μηχανισμό, έτσι ώστε να προσεγγίσει περισσότερο την προτίμηση του ανθρώπου διατηρώντας παράλληλα τη βελτιστοποίηση των προκαθορισμένων κριτηρίων.

Το προδιαγραφικό μοντέλο αντιπροσωπεύει ένα ακολουθιακό πρόβλημα λήψης απόφασης με πολλαπλά κριτήρια βελτιστοποίησης. Για το λόγο αυτό, μοντελοποιείται ως μία μαρκοβιανή διαδικασία απόφασης πολλαπλών κριτηρίων, η οποία αποτελεί το περιβάλλον του προβλήματος ενισχυτικής μάθησης.

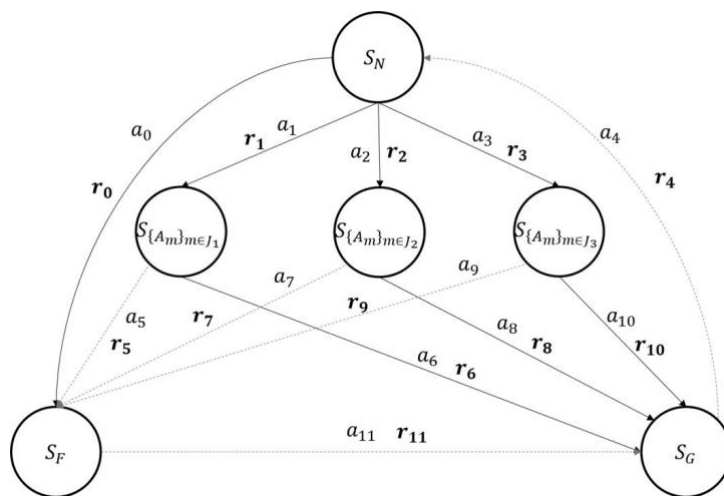
Σε αυτό το περιβάλλον, οι πιθανές καταστάσεις, οι ενέργειες και οι μεταβάσεις τις οποίες δύναται να κάνει ο πράκτορας σε κάθε επεισόδιο ορίζονται παρακάτω. Το προδιαγραφικό μοντέλο ορίζεται από την πλειάδα (S, A, T, \mathbf{R}) . Ο χώρος καταστάσεων S αντιστοιχεί σε συγκεκριμένα σύνολα γεγονότων που εμπεριέχονται στην ροή γεγονότων. Ο χώρος των ενεργειών A περιέχει τις υποψήφιες προδραστικές ενέργειες. Η συνάρτηση μεταβάσεων $T : S \times A \times S \rightarrow \mathbb{R}$ αντιπροσωπεύει την πιθανότητα μετάβασης του πράκτορα στην επόμενη κατάσταση s_{t+1} , δοθείσης της τρέχουσας κατάστασης του πράκτορα s_t , μέσω της ενέργειας a_t . Οι μεταβάσεις $\{a_i\}$ της μαρκοβιανής διαδικασίας απόφασης αντιπροσωπεύουν τις δυνατές ενέργειες ενισχυτικής μάθησης, με τις οποίες ο πράκτορας μεταβαίνει από μία κατάσταση σε μια άλλη. Η συνάρτηση ανταμοιβής $\mathbf{R} : S \times A \times S \rightarrow \mathbb{R}$ αναπαριστά την ανταμοιβή (ή την ποινή) που θα λάβει ο πράκτορας μετά τη μετάβασή του από την κατάσταση s_t στην κατάσταση s_{t+1} , εκτελώντας την ενέργεια a_t .

Οι διακριτοί χώροι καταστάσεων και ενεργειών $\{S_i\}, i \in I, \{a_j\}, j \in J$ της Μαρκοβιανής Διαδικασίας Απόφασης ορίζονται ως εξής. Το μοντέλο έχει μία κατάσταση εκκίνησης S_N , από όπου ο πράκτορας ξεκινά κάθε επεισόδιο, μια επιθυμητή κατάσταση S_G , στην οποία επιθυμεί να καταλήξει ο πράκτορας κατά τη διάρκεια του επεισοδίου. Επιπλέον, το μοντέλο περιέχει μία ή περισσότερες προαιρετικές καταστάσεις S_F τις οποίες ο πράκτορας προσπαθεί να αποφύγει.

Κάθε επεισόδιο της διαδικασίας μάθησης του πράκτορα ενισχυτικής μάθησης ολοκληρώνεται όταν ο πράκτορας φτάσει στην επιθυμητή κατάσταση ή στην ανεπιθύμητη κατάσταση. Η κατάσταση S_N αντιστοιχεί στην κατάσταση στην οποία θεωρούμε ότι όλα τα παρελθοντικά και παροντικά γεγονότα $(E_1, E_2, E_3, \dots, E_{i-1})$ έχουν εκδηλωθεί, ενώ τα επιθυμητά μελλοντικά γεγονότα (E_i, \dots, E_{j-1}) , και τα μελλοντικά ανεπιθύμητα γεγονότα (E_j, \dots, E_k) , έχουν προβλεφθεί. Η κατάσταση S_F αντιστοιχεί στην κατάσταση στην οποία τα ανεπιθύμητα γεγονότα έχουν εκδηλωθεί και η ευκαιρία εκμετάλλευσης των πιθανών μελλοντικών επιθυμητών γεγονότων έχει

χαθεί. Η κατάσταση S_G αντιπροσωπεύει τη μελλοντική κατάσταση κατά την οποία η εκδήλωση όλων των ανεπιθύμητων μελλοντικών γεγονότων (E_j, \dots, E_k) έχει αποφευχθεί και τα επιθυμητά μελλοντικά γεγονότα (E_i, \dots, E_{j-1}) έχουν εκδηλωθεί. Από την αρχική κατάσταση S_N ορίζουμε εξερχόμενες μεταβάσεις προς τις καταστάσεις $S_{\{A_m\}}, \{A_m\}, m \in J, J \in \mathbb{N}$. Καθεμία από αυτές τις καταστάσεις αντιστοιχεί στα γεγονότα που αντιπροσωπεύουν την υλοποίηση του συσχετιζόμενου με αυτήν υποσυνόλου ενεργειών $\{A_m\}, m \in J, J \in \mathbb{N}$. Για κάθε ένα από τα εναλλακτικά σύνολα ενεργειών ορίζουμε μία μοναδική κατάσταση, όπως φαίνεται στην Εικόνα 5-7. Από τις καταστάσεις $S_{\{A_m\}}$ ορίζουμε εξερχόμενες μεταβάσεις προς τις καταστάσεις S_F και S_G . Όλες οι υπόλοιπες μεταβάσεις του μοντέλου φαίνονται στην Εικόνα 5-7. Μιας και ένα ανεπιθύμητο μελλοντικό γεγονός μπορεί να έχει προβλεφθεί επιτυχώς αλλά να μην αποφευχθεί επιτυχώς με τις υλοποιηθείσες προδραστικές ενέργειες, έχουμε προσθέσει εξερχόμενες μεταβάσεις από τις καταστάσεις $S_{\{A_m\}}$ προς την κατάσταση S_F .

Για να μπορέσει η μέθοδος να διαχειριστεί πολλαπλά, πιθανώς αντικρουόμενα κριτήρια βελτιστοποίησης, η συνάρτηση ανταμοιβής $R : S \times A \times S \rightarrow \mathbb{R}_n$ ορίζεται ως ένα διάνυσμα n διαστάσεων, όπου κάθε διάσταση αντιστοιχεί στην ανταμοιβή ενός κριτηρίου βελτιστοποίησης. Η συνάρτηση ανταμοιβής με αυτό τον τρόπο ενθυλακώνει τα κριτήρια βελτιστοποίησης και αναθέτει το διάνυσμα ανταμοιβής στις αντίστοιχες ενέργειες.



Εικόνα 5-7 Μαρκοβιανή Διαδικασία Απόφασης Πολλαπλών Κριτηρίων για τη Φάση Κατασκευής του Προδιαγραφικού Μοντέλου

Για κάθε γεγονός που έχει προβλεφθεί, ένα διαφορετικό προδιαγραφικό μοντέλο θα κατασκευαστεί, αποθηκευτεί και ανακτηθεί. Η λύση της μαρκοβιανής διαδικασίας απόφασης είναι μια πολιτική στην οποία οι καταστάσεις αντιστοιχούν με τις πιθανότητες επιλογής της κάθε πιθανής ενέργειας και προκύπτουν από την αξιολόγηση της αναμενόμενης χρησιμότητας. Η αναμενόμενη χρησιμότητα ορίζεται ως η προσδοκώμενη αξία της τυχαίας μεταβλητής που καθορίζεται από το άθροισμα των ανταμοιβών που συγκεντρώνονται με την δεδομένη πολιτική (Puterman, 2014). Χρησιμοποιώντας μια πολιτική, ο πράκτορας μπορεί να επιλέξει την βέλτιστη ενέργεια που δύναται να εκτελέσει σε κάθε κατάσταση. Όμως, η ανταμοιβή που κερδίζει ακολουθώντας μια δεδομένη πολιτική δεν είναι γνωστή εκ των προτέρων, εξαιτίας των αβέβαιων μεταβάσεων του πράκτορα. Με αυτήν τη λογική, η αναμενόμενη χρησιμότητα, χρησιμοποιείται ως μια μετρική αξιολόγησης πολιτικών (Engel, et al., 2012).

Η μοντελοποίηση που παρουσιάζεται στην Εικόνα 5-7 αποτελεί την απλούστερη μορφή μοντελοποίησης της προτεινόμενης μεθόδου και χρησιμοποιείται για την καλύτερη κατανόησή της. Η προτεινόμενη μέθοδος μπορεί να υποστηρίξει πολύπλοκα περιβάλλοντα και προβλήματα, στα οποία εμπεριέχονται πολλά ανεπιθύμητα γεγονότα και διαφορετικά επιθυμητά γεγονότα.

Επιπλέον στην παρούσα περιγραφή, οι εναλλακτικές ενέργειες/αποφάσεις αναπαριστούν σύνολα ενεργειών με την απλούστερη μορφή τους να αποτελείται από μία μεμονωμένη ενέργεια. Με την προτεινόμενη μοντελοποίηση τα εναλλακτικά σύνολα ενεργειών μπορούν να αντικατασταθούν με υπο-γραφήματα τα οποία αναπαριστούν υπο-διαδικασίες της μαρκοβιανής διαδικασίας απόφασης. Η ενισχυτική μάθηση και η προτεινόμενη προσέγγιση σε συνδυασμό με τις εξελιγμένες υπολογιστικές τεχνολογίες που είναι διαθέσιμες μπορούν να υποστηρίξουν προβλήματα τα οποία αναπαρίστανται από πολύπλοκα περιβάλλοντα που περιέχουν πολλά διαφορετικά ανεπιθύμητα γεγονότα και εναλλακτικά υπο-γραφήματα ενεργειών. Σε αυτές τις περιπτώσεις ο πράκτορας μπορεί να ξεκινά από διαφορετική κατάσταση και να ολοκληρώνει τη δοκιμή του φτάνοντας σε διαφορετική τερματική κατάσταση. Για την επίλυση τέτοιων προβλημάτων, οι προτεινόμενοι αλγόριθμοι ενισχυτικής μάθησης μπορούν να συνδυαστούν με τις τεχνικές της ενισχυτικής

μάθησης πολλαπλών πρακτόρων και τις τεχνικές της Ιεραρχικής Ενισχυτικής Μάθησης.

Η προτεινόμενη μοντελοποίηση αναπαριστά ένα τμήμα του συνολικού περιβάλλοντος, το οποίο αποτελείται από τις διαφορετικές μαρκοβιανές αυτής της μορφής, όπου καθεμιά από τις οποίες αναπαριστά μία δεδομένη απόφαση. Ο ορίζοντας απόφασης κάθε επιμέρους μαρκοβιανής είναι πεπερασμένος. Όπως ορίζεται, μία επιμέρους μαρκοβιανή της προτεινόμενης μοντελοποίησης αναπαριστά τη διαδικασία απόφασης. Κάτι τέτοιο συνεπάγεται ότι σε διαφορετικές διαδικασίες απόφασης, και καταστάσεις του περιβάλλοντος, οι διαθέσιμες εναλλακτικές ενέργειες που αντιστοιχούν στις εναλλακτικές αποφάσεις διαφέρουν. Αντιστοίχως, διαφέρει και η ανταμοιβή που λαμβάνει ο πράκτορας με την εκτέλεση αυτών των ενεργειών. Επιπροσθέτως, ανάλογα με την επιλεγμένη μοντελοποίηση, καθεμιά από τις εναλλακτικές ενέργειες του πράκτορα ενδέχεται να παρουσιάζει μεταβαλλόμενη ανταμοιβή στην πάροδο του χρόνου. Σε αυτήν την περίπτωση, το περιβάλλον του προβλήματος αντιστοιχεί σε ένα μη-στατικό περιβάλλον ενισχυτικής μάθησης. Οι μέθοδοι που μπορούν να διαχειριστούν τέτοιου είδους περιβάλλοντα (Padakandla, 2021), μπορούν να συνδυαστούν με την προτεινόμενη μέθοδο έτσι ώστε να υποστηρίξουν τη μοντελοποίηση αντίστοιχων προβλημάτων.

5.2.2 Επίλυση Προδιαγραφικού Μοντέλου

Στην φάση της επίλυσης του προδιαγραφικού μοντέλου, υιοθετείται η ενισχυτική μάθηση πολλαπλών κριτηρίων προκειμένου ο πράκτορας να φτάσει στην επιθυμητή κατάσταση μεγιστοποιώντας την αθροιστική ανταμοιβή που αντιστοιχεί στα διαφορετικά κριτήρια βελτιστοποίησης. Ο πράκτορας μαθαίνει με δοκιμές, δηλαδή προσπαθεί να ανακαλύψει την βέλτιστη ακολουθία ενεργειών μετάβασης αλληλοεπιδρώντας με το άγνωστο προς αυτόν περιβάλλον. Για κάθε κατάσταση, η συνάρτηση ανταμοιβής ορίζεται ως ένα διάνυσμα αποτελούμενο από τα κριτήρια βελτιστοποίησης που επιθυμούμε να μεγιστοποιήσουμε ή να ελαχιστοποιήσουμε. Σε αυτήν τη βάση, η βέλτιστη πολιτική $\pi_{O_i}(s, a)$ για κάθε κριτήριο βελτιστοποίησης $O_i \in I$

υπολογίζεται με μια προσέγγιση policy gradient, χρησιμοποιώντας τη μέθοδο δράστη-κριτή (Konda, και Tsitsiklis, 2000).

Η προσέγγιση policy gradient στοχεύει στην απευθείας μοντελοποίηση και βελτιστοποίηση της πολιτικής. Η πολιτική συνήθως μοντελοποιείται ως μια παραμετρική συνάρτηση $\pi_\theta(a|s)$ ως προς την παράμετρο θ . Η τιμή της συνάρτησης ανταμοιβής εξαρτάται από αυτήν την πολιτική και ο αλγόριθμος εφαρμόζεται προκειμένου να βελτιστοποιήσει την παράμετρο θ ώστε να μεγιστοποιηθεί η ανταμοιβή.

Σε αυτήν την προσέγγιση η συνάρτηση ανταμοιβής ορίζεται ως:

$$J(\theta) = \sum_{s \in \mathcal{S}} d^\pi(s) V^\pi(s) = \sum_{s \in \mathcal{S}} d^\pi(s) \sum_{a \in \mathcal{A}} \pi_\theta(a|s) Q^\pi(s, a) \quad (1)$$

όπου $d^\pi(s)$ είναι η κατανομή της μαρκοβιανής αλυσίδας για την πολιτική π_θ (on-policy state Η $d^\pi(s) = \lim_{t \rightarrow \infty} P(s_t = s | s_0, \pi_\theta)$ είναι η πιθανότητα της ισότητας $s_t = s$ όταν ο πράκτορας ξεκινά από μια κατάσταση s_0 και ακολουθεί την πολιτική π_θ για t βήματα.

Σύμφωνα με το θεώρημα policy gradient (Sutton, et al., 2000), η παράγωγος της συνάρτησης βελτιστοποίησης μπορεί να διαμορφωθεί ως εξής:

$$\nabla_\theta J(\theta) \propto \nabla_\theta \sum_{s \in \mathcal{S}} d^\pi(s) \sum_{a \in \mathcal{A}} Q^\pi(s, a) \nabla_\theta \pi_\theta(a|s) \quad (2)$$

Η βέλτιστη πολιτική παράγεται από την συνάρτηση ανταμοιβής και την εκτέλεση των μεθόδων δράστη-κριτή, όπου εκτός από την πολιτική, εντοπίζεται και η συνάρτηση τιμής, η οποία επιτρέπει την ενημέρωση της πολιτικής. Οι μέθοδοι δράστη-κριτή έχουν ξεχωριστή δομή μνήμης για να αναπαριστούν ρητά την πολιτική ανεξάρτητα από τη συνάρτηση τιμής (Konda, και Tsitsiklis, 2000). Η δομή που αναλαμβάνει την πολιτική καλείται δράστης, μιας και χρησιμοποιείται για την επιλογή των ενεργειών μετάβασης. Η εκτίμηση της συνάρτησης τιμής καλείται κριτής, καθώς αξιολογεί τις ενέργειες μετάβασης που εκτελούνται από το δράστη. Η μάθηση γίνεται βάσει πολιτικής: ο κριτής πρέπει να αξιολογήσει οποιαδήποτε πολιτική ακολουθείται από τον δράστη. Στην παρούσα μέθοδο έχει τη μορφή σφάλματος χρονικών διαφορών (Temporal Difference - TD). Αυτό το βαθμωτό σήμα είναι η

μοναδική έξοδος του κριτή και καθορίζει όλη τη διαδικασία μάθησης και για τον δράστη και για τον κριτή. Το αποτέλεσμα της επίλυσης του προδιαγραφικού μοντέλου αποτελείται από ένα σύνολο προδραστικών ενεργειών, οι οποίες προκύπτουν ακολουθώντας τη βέλτιστη πολιτική και εν συνεχεία επικοινωνούνται στον άνθρωπο.

Σύμφωνα με τα παραπάνω η μέθοδος δράστη-κριτή αποτελείται από δύο επιμέρους μοντέλα:

(i) Τον **Κριτή (Critic)**, ο οποίος ενημερώνει τις παραμέτρους της συνάρτησης τιμής w , συνάρτηση η οποία μπορεί να είναι συνάρτηση τιμής ενέργειας (action-value) $Q_w(a|s)$ ή συνάρτηση τιμής κατάστασης $V_w(s)$

(ii) Τον **Δράστη (Actor)**, ο οποίος ενημερώνει τις παραμέτρους θ για την πολιτική $\pi_\theta(a|s)$, υπό την καθοδήγηση του κριτή.

Αφού υπολογιστεί η βέλτιστη πολιτική $\pi_{O_i}(s, a)$ για κάθε κριτήριο βελτιστοποίησης, χρησιμοποιώντας έναν αλγόριθμο δράστη-κριτή, ορίζουμε την βέλτιστη πολιτική πολλαπλών κριτηρίων ως:

$$\pi_{MOopt}(s, a) = \prod_{i \in I} \pi_{O_i}(s, a) \quad (3)$$

5.2.3 Προσαρμογή Προδιαγραφικού Μοντέλου

Μια βασική συνεισφορά της προτεινόμενης προσέγγισης είναι η προσαρμογή του προδιαγραφικού μοντέλου. Το προδιαγραφικό μοντέλο αναπροσαρμόζεται σύμφωνα με την αξιολογική ανάδραση του ανθρώπου, προκειμένου να παράγει προδιαγραφές οι οποίες θα συγκλίνουν με τις προτιμήσεις του. Η προτίμηση του ανθρώπου στην παρούσα προσέγγιση δεν χρειάζεται να αναπαρασταθεί και να μοντελοποιηθεί εξαντλητικά, καθώς θεωρούμε ότι η ανάδραση που παρέχει ο άνθρωπος εμπεριέχει έμμεσα αυτήν την πληροφορία. Με τη μέθοδο αυτή, η ανάδραση του ανθρώπου επαυξάνει τον πράκτορα ενισχυτικής μάθησης, και κατά συνέπεια την προδιαγραφική αναλυτική την οποία υλοποιεί, η οποία παραδοσιακά βασίζεται εξ' ολοκλήρου στη μάθηση με σήματα ανταμοιβής. Για κάθε προδιαγραφή που παράγεται, λαμβάνεται προαιρετική ανάδραση του χρήστη με τη μορφή σήματος αποδοχής ή απόρριψης πάνω στις προτεινόμενες ενέργειες. Η ανάδραση του χρήστη

θεωρείται ως μια ανεξάρτητη μεταβλητή, η οποία στη φάση προσαρμογής του προδιαγραφικού μοντέλου θα μοντελοποιηθεί σαν κατανομή πιθανότητας και θα ενσωματωθεί στην βέλτιστη πολιτική που παρήγαγε η φάση της επίλυσης του προδιαγραφικού μοντέλου. Ο μηχανισμός προσαρμογής που χρησιμοποιείται από την παρούσα μέθοδο εντάσσεται στις μεθόδους διαμόρφωσης πολιτικής (Griffith, et al., 2013), οι οποίες ορίζουν την αντιμετώπιζον την ανάδραση του χρήστη ως μια συμβουλή για την πολιτική του πράκτορα.

Ακολουθώντας τη μέθοδο που περιγράφεται στην εργασία των (Griffith, et al., 2013), ο μηχανισμός προσαρμογής που προτείνεται μοντελοποιεί την κατανομή της ανάδρασης για να εκτιμήσει την δεσμευμένη κατανομή σύμφωνα με την πολιτική του εκπαιδευτή. Η κατανομή ανάδρασης βασίζεται σε δύο χαρακτηριστικά της ανάδρασης του ανθρώπου:

(i) *Συνέπεια Ανάδρασης (Consistency) C*, που εκφράζει το επίπεδο γνώσης του ανθρώπου αναφορικά με το κατά πόσο είναι βέλτιστη μια ενέργεια. Αντιστοιχεί στην πιθανότητα η αξιολόγηση μιας ενέργειας να είναι η σωστή ως προς το αν η ενέργεια είναι η βέλτιστη δυνατή, για τον συγκεκριμένο εκπαιδευτή,

(ii) *Πιθανότητα Ανάδρασης (Likelihood) L*, που αναπαριστά την πιθανότητα λήψης ανάδρασης από τον άνθρωπο, ενώ ο άνθρωπος παρακολουθεί τον πράκτορα κατά τη διάρκεια της μάθησης. Το χαρακτηριστικό αυτό είναι σημαντικό, καθώς ο άνθρωπος μπορεί να μην αλληλοεπιδράσει μετά από κάθε ενέργεια του πράκτορα.

Η συνέπεια και η πιθανότητα ανάδρασης αποτελούν σημαντικούς παράγοντες στον ορισμό της κατανομής που αναπαριστά την ανάδραση του χρήστη. Μπορούν να συμβάλλουν στην πρόληψη λανθασμένων προτάσεων που μπορεί να προκύψουν στην περίπτωση που δοθεί ανακριβής ανατροφοδότηση από κάποιον άνθρωπο. Επιπλέον, μπορούν να υποστηρίξουν περιπτώσεις στις οποίες ο άνθρωπος δεν είναι σωστά ενημερωμένος σχετικά με το αντικείμενο του προβλήματος για το οποίο καλείται να δηλώσει την προτίμησή του.

Βάσει αυτών των χαρακτηριστικών, η φάση της προσαρμογής του προδιαγραφικού μοντέλου αξιολογεί την σημαντικότητα και την ακρίβεια της

παρεχόμενης ανατροφοδότησης και στη συνέχεια την ενσωματώνει στη βέλτιστη πολιτική που έχει εξαχθεί με τη βοήθεια της ενισχυτικής μάθησης.

Η ανάδραση του χρήστη μεταφράζεται σε μία βαθμωτή συνάρτηση η οποία περιλαμβάνει διαφορετικά επίπεδα θετικής και αρνητικής ανάδρασης:

$$H_{Presc} = \begin{cases} H^- \in \mathbb{R}^-, & \text{negative feedback} \\ 0, & \text{neutral} \\ H^+ \in \mathbb{R}^+, & \text{positive feedback} \end{cases} \quad (4)$$

Ο αλγόριθμος που παρουσιάζουμε κάνει την υπόθεση ότι η ακρίβεια κάθε ανάδρασης είναι υπό συνθήκη ανεξάρτητη και οδηγεί στην πιθανότητα $Pr_H(a)$ μια ενέργεια $a \in A$ να είναι βέλτιστη:

$$Pr_H(a) = C^{\Delta_{s,a}} + (1 - C)^{\sum_{j \neq a} \Delta_{s,j}} \quad (5)$$

όπου $\Delta_{s,a}$ είναι η διαφορά των θετικών και των αρνητικών αναδράσεων που έχουν ληφθεί για το συγκεκριμένο ζεύγος κατάστασης s και ενέργειας a .

Σύμφωνα με τα παραπάνω, θεωρούμε την πολιτική της ανάδρασης $\pi_{FOpt}(s, a)$, μια κατανομή πιθανότητας, παραγόμενη από την Εξίσωση (5) επαναληπτικά πάνω στο σύνολο των εναλλακτικών ενεργειών. Η πολιτική αυτή αξιοποιεί τα παρελθοντικά δεδομένα ανάδρασης και τα χαρακτηριστικά τους και μοντελοποιεί επαρκώς την ανάδραση του ανθρώπου. Για το λόγο αυτό, η τιμή της $\pi_{FOpt}(s, a)$ αναπαριστά την πιθανότητα να εκτελεστεί η επιλογή s, a ακολουθώντας την κατανομή ανάδρασης. Αυτή η πολιτική συνιστά την βέλτιστη Μπευζιανή πολιτική ανάδρασης, δοθέντων των ετικετών ανάδρασης H_{Presc} , των τιμών των χαρακτηριστικών ανάδρασης C και L , υπό την προϋπόθεση ότι μόνο μία ενέργεια μετάβασης είναι βέλτιστη για κάθε κατάσταση. Αυτό προκύπτει από την εφαρμογή του κανόνα του Bayes σε συνδυασμό με την πολιτική ανάδρασης και την επιβολή της συνθήκης ανεξαρτησίας που προκύπτει από την υπόθεση ότι σε κάθε κατάσταση υπάρχει μόνο μία βέλτιστη ενέργεια.

Υποθέτοντας ότι η πολιτική ανάδρασης είναι ανεξάρτητη από την πολιτική πολλαπλών κριτηρίων που υπολογίστηκε στην προηγούμενη φάση, μπορούμε να υπολογίσουμε την συνδυαστική βέλτιστη πολιτική $\pi_{opt}(s, a)$, η οποία βελτιστοποιεί τα κριτήρια βελτιστοποίησης ταυτόχρονα με την ανάδραση του ανθρώπου ως εξής:

$$\pi_{opt}(s, a) = \pi_{MOopt}(s, a) * \pi_{FOpt}(s, a) \quad (6)$$

Η διαμορφωμένη πολιτική που προκύπτει αποθηκεύεται και ενσωματώνεται στην επίλυση του προδιαγραφικού μοντέλου την επόμενη φορά που το συγκεκριμένο προδιαγραφικό μοντέλο ενεργοποιείται από κάποιο προβλεπτικό γεγονός.

Έπειτα από αρκετές επαναλήψεις, το προδιαγραφικό μοντέλο είναι ικανό να παρέχει μη επεμβατική υποστήριξη στον άνθρωπο, λαμβάνοντας παράλληλα υπόψιν τους περιορισμούς του περιβάλλοντος. Η παραγόμενη προδιαγραφή θα αντιπροσωπεύει το σημείο ισορροπίας ανάμεσα στην προτίμηση του ανθρώπου πάνω στις εναλλακτικές προδραστικές ενέργειες και τη βέλτιστη ενέργεια που βελτιστοποιεί τα προκαθορισμένα κριτήρια βελτιστοποίησης του προβλήματος, εξασφαλίζοντας ότι και οι δύο αυτές πλευρές λαμβάνονται υπόψιν ισοδύναμα. Με αυτό τον τρόπο, η προτεινόμενη μέθοδος επιτυγχάνει της συνεργασία ανθρώπου-τεχνητής νοημοσύνης, αξιοποιώντας τις προβλέψεις για το μέλλον αντί για την παρούσα κατάσταση.

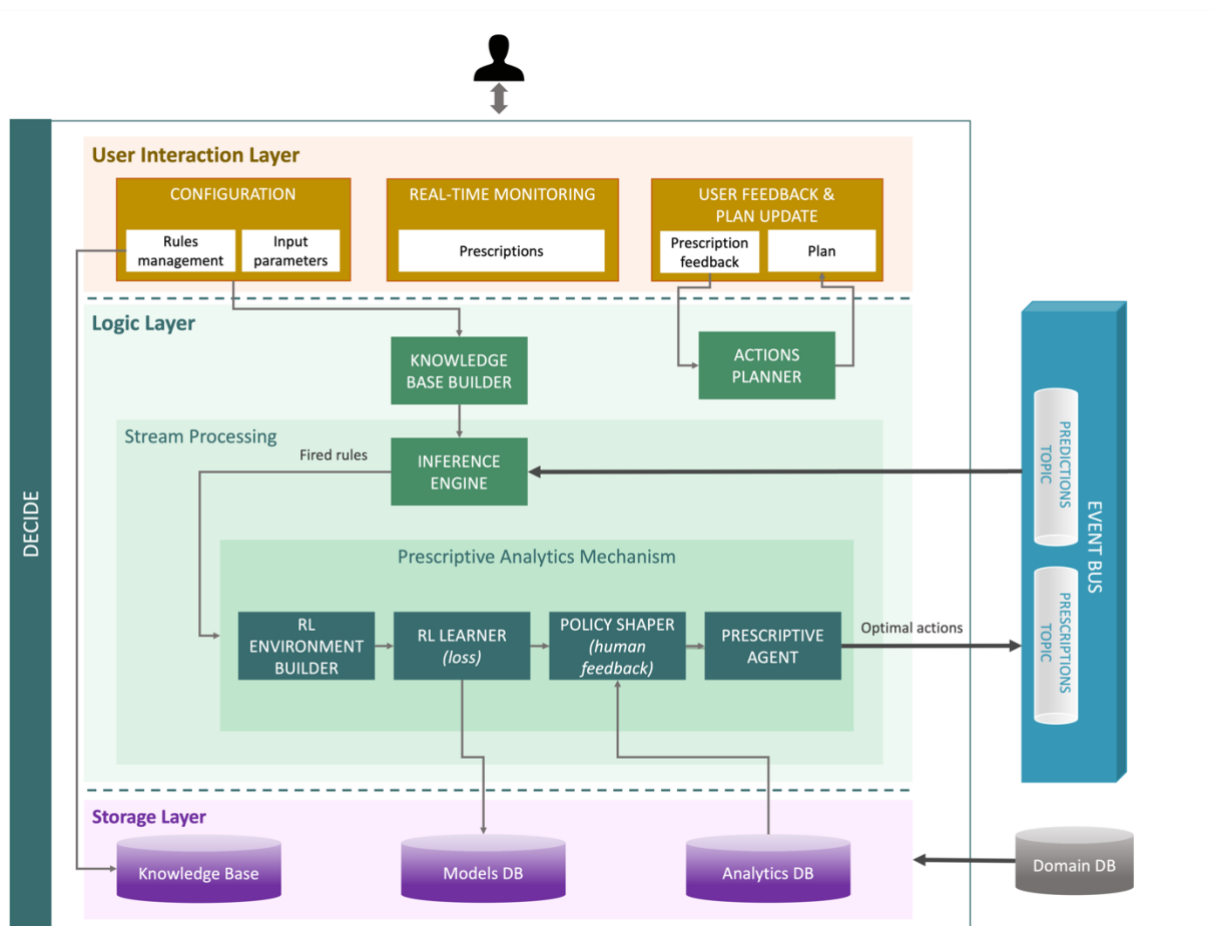
6 Πληροφοριακό Σύστημα

Στο παρόν κεφάλαιο παρουσιάζεται το πληροφοριακό σύστημα που υλοποιεί την προτεινόμενη μέθοδο του κεφαλαίου 5 με τη μορφή μιας διαδικτυακής εφαρμογής. Η μέθοδος μπορεί να διαχειριστεί ταυτόχρονα προβλέψεις σχετιζόμενες με πολλά διαφορετικά γεγονότα τα οποία συσχετίζονται με διαφορετικές, μεταβλητού αριθμού ενέργειες, που στοχεύουν στην αξιοποίηση ή την αποφυγή των προβλεπόμενων γεγονότων. Η αναπαράσταση των συσχετίσεων μεταξύ των προβλεπόμενων γεγονότων και των προδιαγραφικών ενεργειών γίνεται δυναμικά για το προς επίλυση πρόβλημα κατασκευάζοντας ένα σύστημα κανόνων.

Το αναπτυχθέν πληροφοριακό σύστημα αξιοποιεί τα συστήματα κανόνων (rule-based systems) για την αποτύπωση και τη μοντελοποίηση του προβλήματος, τις τεχνολογίες επεξεργασίας ροών δεδομένων (stream processing) και των διαύλων γεγονότων (event bus). Μέσω αυτών, υλοποιεί την διαδικασία λήψης αποφάσεων σε πραγματικό χρόνο και επιτρέπει την ευρύτερη διασύνδεση και άμεση αξιοποίηση των παραγόμενων προδιαγραφών από άλλα συστήματα.

6.1 Αρχιτεκτονική

Η αρχιτεκτονική του συστήματος παρουσιάζεται στην Εικόνα 6-1. Αποτελείται από τρία επίπεδα: το Επίπεδο Αλληλεπίδρασης με τον Χρήστη, το Επίπεδο Λογικής και το Επίπεδο Αποθήκευσης Δεδομένων, τα οποία περιγράφονται στις παραγράφους 6.1.1 , 6.1.2 και 6.1.3 αντιστοίχως.



Εικόνα 6-1 Αρχιτεκτονική συστήματος

6.1.1 Επίπεδο Αλληλεπίδρασης Χρήστη

Το επίπεδο αλληλεπίδρασης χρήστη αντιστοιχεί στην γραφική διεπαφή που εμπεριέχεται στο σύστημα και αποτελεί το κύριο σημείο αλληλεπίδρασης με τους χρήστες.

Το επίπεδο αλληλεπίδρασης χρήστη παρέχει τρεις βασικές λειτουργικότητες:

- **Παραμετροποίηση (Configuration):** Κατά τη φάση σχεδιασμού, ο χρήστης μπορεί να παραμετροποιήσει το εργαλείο έτσι ώστε:
 - Να διαμορφώσει την βάση γνώσης, δηλαδή να ορίσει και να επεξεργαστεί τους λογικούς κανόνες στους οποίους θα βασιστεί η μέθοδος απόφασης,
 - Να παραμετροποιήσει το σύστημα σύμφωνα με το εκάστοτε πρόβλημα, όπως για παράδειγμα να ορίσει τα κριτήρια βελτιστοποίησης και τις παραμέτρους ενισχυτικής μάθησης και

- Να ορίσει τις παραμέτρους εισόδου για τις σχετιζόμενες οντότητες, όπως για παράδειγμα, τις εναλλακτικές ενέργειες, τα επιθυμητά ή ανεπιθύμητα γεγονότα καθώς και τις τιμές των κριτηρίων για κάθε ενέργεια και για κάθε επιθυμητό ή ανεπιθύμητο γεγονός.
- **Επίβλεψη πραγματικού χρόνου (Real-time Monitoring):** Κατά τη φάση εκτέλεσης, ο χρήστης έχει τη δυνατότητα να επιβλέπει και να παρακολουθεί μέσω της αντίστοιχης γραφικής διεπαφής:
 - Τις παραγόμενες προδιαγραφές (prescriptions) οι οποίες υποδεικνύουν τις προτεινόμενες βέλτιστες ενέργειες, και παράγονται βάσει των διαθέσιμων προβλέψεων. Οι προτεινόμενες ενέργειες παρουσιάζονται στον χρήστη με τη μορφή πίνακα προκειμένου να παρέχουν με έναν φιλικό προς τον χρήστη τρόπο, περισσότερες λεπτομέρειες σχετικά με τη διαδικασία λήψης απόφασης που εκτελέστηκε από το σύστημα και οδήγησε στην προτεινόμενη προδιαγραφή.
- **Ανάδραση Χρήστη και Ενημέρωση Πλάνου (User Feedback & Plan Update):**
Σε συνέχεια της παραγωγής των προδιαγραφών:
 - Ο χρήστης έχει τη δυνατότητα να δώσει ανατροφοδότηση σχετικά με την παραγόμενη προδιαγραφή, με τη μορφή έγκρισης (approve) ή απόρριψης (reject). Η ανατροφοδότηση του χρήστη εμπεριέχει έμμεσα την εξειδικευμένη γνώση και εμπειρία του πάνω στο συγκεκριμένο πρόβλημα. Επιπλέον, εμπεριέχει πιθανούς περιορισμούς που δύναται να γνωρίζει ο χρήστης αλλά να μην έχουν καταγραφεί στο σύστημα. Όταν μια προδιαγραφή εγκριθεί, μετατρέπεται σε απόφαση. Σε κάθε περίπτωση, η ανατροφοδότηση του χρήστη αξιοποιείται για τη διαμόρφωση του προδιαγραφικού μηχανισμού.
 - Το πλάνο ενεργειών ενημερώνεται με κάθε νέα απόφαση. Το πλάνο ενεργειών έχει ως σκοπό τη διευκόλυνση της παρακολούθησης και υλοποίησης των αποφάσεων και αποτελεί την ουρά των ενεργειών που πρόκειται να υλοποιηθούν. Όταν οι ενέργειες που

προδιαγράφονται από μια απόφαση υλοποιηθούν, ο χρήστης μπορεί να κατατάξει την απόφαση ως «Ολοκληρωμένη».

6.1.2 Επίπεδο Λογικής

Το επίπεδο λογικής υλοποιεί την επιχειρηματική λογική η οποία ενεργοποιείται κατ' απαίτηση και εμπεριέχει τον πυρήνα της προτεινόμενης προσέγγισης προδιαγραφικής αναλυτικής. Το επίπεδο αυτό αποτελείται επιμέρους από τον Κατασκευαστή Βάσης Γνώσης (Knowledge Base Builder), τον Προγραμματιστή Ενεργειών (Action Planner) και το υπο-σύστημα της επεξεργασίας ροών δεδομένων (Stream Processing).

Στην παρούσα υλοποίηση, η διαδικαστική γνώση του προς επίλυση προβλήματος μοντελοποιείται δυναμικά με ένα σύστημα κανόνων, προκειμένου να είναι δυνατή η αναγνώριση και η συμμετοχή διαφορετικών οντοτήτων, ενεργειών και επιθυμητών ή ανεπιθύμητων μελλοντικών γεγονότων. Τα συστήματα επιχειρηματικών κανόνων προσθέτουν επιπλέον λειτουργικότητα στις μηχανές κανόνων που προορίζονται για επιχειρηματική χρήση, προσφέροντας δυνατότητες καταγραφής, διαχείρισης, επίβλεψης, ανάλυσης και ενεργοποίησης κανόνων στους τελικούς χρήστες. Με τον όρο μηχανή κανόνων συνήθως ορίζεται οποιοδήποτε σύστημα χρησιμοποιεί κανόνες με μορφή που να μπορεί να εφαρμοστεί σε δεδομένα και να οδηγήσει σε συμπεράσματα από αυτά (Proctor et al., 2008).

Ένα σύστημα κανόνων είναι πλήρες κατά Turing με έμφαση στην αναπαράσταση γνώσης για την έκφραση προτασιακής και πρώτου βαθμού λογικής με έναν συνοπτικό, μονοσήμαντο και δηλωτικό τρόπο. Τον πυρήνα του συστήματος αποτελεί η μηχανή συμπερασμού (Inference Engine) η οποία παρουσιάζει επεκτασιμότητα σε υψηλό βαθμό κανόνων και γεγονότων. Η μηχανή συμπερασμού συγκρίνει τα γεγονότα με τα δεδομένα των κανόνων για να εξάγει συμπεράσματα που θα οδηγήσουν σε ενέργειες. Ένας κανόνας είναι συνήθως μια δομή δύο στοιχείων λογικής πρώτου βαθμού που αναπαριστά γνώση:

when <conditions>

then <actions>;

Η διαδικασία με την οποία ταυτοποιούνται νέα ή υφιστάμενα γεγονότα με τους κανόνες του συστήματος καλείται Αντιστοίχιση Προτύπων (Pattern Matching) και εκτελείται από τη μηχανή συμπερασμού. Ενδεικτικοί αλγόριθμοι υλοποίησης αυτής της διαδικασίας είναι οι αλγόριθμοι Rete (Forgy, 1989), Treat (Miranker, 1987) και Leaps (Miranker et al., 1990).

Στην Εικόνα 6-2 παρουσιάζεται η τυπική αρχιτεκτονική μιας μηχανής κανόνων.



Εικόνα 6-2 Αρχιτεκτονική μηχανής κανόνων

Τα συστήματα κανόνων προσφέρουν τα παρακάτω πλεονεκτήματα:

- **Δηλωτικός προγραμματισμός:** Τα συστήματα κανόνων δίνουν τη δυνατότητα να ορίσουμε το τι πρέπει να γίνει χωρίς να ορίσουμε τον τρόπο με τον οποίο πρέπει να εκτελεστεί μια ενέργεια. Με αυτό το χαρακτηριστικό οι κανόνες μπορούν να δώσουν λύση σε δύσκολα προβλήματα στα οποία η λύση αυτή μπορεί εύκολα να επαληθευτεί. Επιπλέον μέσω των κανόνων παρέχεται μια επεξήγηση του πως κατασκευάστηκε μια λύση και πως οδηγηθήκαμε σε μία απόφαση, εν αντιθέσει με άλλα συστήματα τεχνητής νοημοσύνης.
- **Διαχωρισμός Λογικής και Δεδομένων:** Με τη βοήθεια των κανόνων η λογική μιας εφαρμογής διαχωρίζεται από τα δεδομένα και τη διαχείρισή τους. Με τον τρόπο αυτό η λογική διατηρείται σε ξεχωριστά αρχεία και κατά συνέπεια μπορεί πιο εύκολα να συντηρηθεί και να τροποποιηθεί χωρίς να επηρεάσει το σύνολο της εφαρμογής.

- **Ταχύτητα και Κλιμάκωση:** Οι αλγόριθμοι αντιστοίχισης προτύπων που υλοποιούνται από μηχανές συμπερασμού είναι ιδιαίτερα αποτελεσματικοί σε σύνολα δεδομένων που παρουσιάζουν μικρές αλλαγές, μιας και η μηχανή κανόνων μπορεί να θυμηθεί τις προηγούμενες αντιστοιχίσεις.
- **Κεντριοποιημένη Βάση Γνώσης:** Με την αποτύπωση του πεδίου γνώσης με τη χρήση κανόνων, δημιουργείται μια κεντρική βάση γνώσης, η οποία είναι εκτελέσιμη. Αυτό σημαίνει ότι υπάρχει ένα ενιαίο σημείο αλήθειας, το οποίο χάρις στην ευανάγνωστη μορφή των κανόνων θα μπορούσε να χρησιμοποιηθεί και ως τεκμηρίωση (documentation) σε κάποιες περιπτώσεις.
- **Ενσωμάτωση σε εργαλεία ανάπτυξης λογισμικού:** Εργαλεία ανάπτυξης λογισμικού, όπως για παράδειγμα το Eclipse IDE δίνουν τη δυνατότητα ενσωμάτωσης, διαχείρισης και αποσφαλμάτωσης αρχείων κανόνων σε συνεργασία με τα συστήματα κανόνων. Κάτι τέτοιο διευκολύνει τη διαδικασία ανάπτυξης εφαρμογών βασισμένων σε συστήματα κανόνων, καθώς η εγκυρότητα των δεδομένων, των κανόνων και της υλοποιούμενης λογικής ελέγχεται εύκολα και άμεσα.
- **Κατανοητοί κανόνες:** Σε αρκετές περιπτώσεις όπου στους κανόνες αξιοποιούνται προγραμματιστικές οντότητες κατανοητές από τον αναγνώστη, οι κανόνες προσομοιάζουν φυσικοί γλώσσα. Αυτό οδηγεί στην καλύτερη επικοινωνία και κατανόηση μεταξύ των συμμετεχόντων στην ανάπτυξη της εφαρμογής ανεξάρτητα του υποβάθρου και επιστημονικής κατάρτισής τους.

Ένα σύστημα κανόνων με τα παραπάνω χαρακτηριστικά διευκολύνει την υλοποίηση της προτεινόμενης μεθόδου καθώς προσφέρει μία δυναμική και εύχρηστη αναπαράσταση της γνώσης του ειδικού. Με αυτό τον τρόπο, η προτεινόμενη μέθοδος να μπορεί να εφαρμοστεί σε διαφορετικά πεδία γνώσης και προβλήματα, όπου η απαιτούμενη γνώση μοντελοποιείται εύκολα από τον ειδικό.

Ο κατασκευαστής βάσης γνώσης αναλαμβάνει την δυναμική κατασκευή του συστήματος κανόνων, σύμφωνα με τη γνώση που παρέχει ο ειδικός που επιθυμεί να επιλύσει το εκάστοτε πρόβλημα, ο οποίος κατέχει την εξειδικευμένη γνώση που περιγράφει το επιστημονικό πεδίο του προβλήματος. Η γνώση αυτή γίνεται διαθέσιμη στην προτεινόμενη υλοποίηση μέσω της γραφικής διεπαφής που

περιγράφεται στην παράγραφο 6.1.1. Σε αυτήν ο ειδικός μπορεί να προσδιορίσει τις οντότητες που συμμετέχουν στο πρόβλημα, τις εναλλακτικές ενέργειες που μπορούν να αποτρέψουν ή να αξιοποιήσουν ένα επιθυμητό ή ανεπιθύμητο γεγονός και να κατασκευάσει τους προδραστικούς κανόνες συσχέτισης μεταξύ τους. Οι προδραστικοί κανόνες του συστήματος έχουν τη μορφή:

$$\text{IF } \{E_i\} \text{ THEN } \{A_j\}$$

με την οποία δηλώνουν ότι εάν προβλεφθεί η εκδήλωση των γεγονότων $\{E_i\}$ τότε οι προδραστικές ενέργειες που μπορούν να διαχειριστούν έγκαιρα την εκδήλωση των γεγονότων αυτών είναι το σύνολο $\{A_j\}$. Ο ειδικός μπορεί μέσω της παρεχόμενης διεπαφής να προσθέσει όσους προδραστικούς κανόνες επιθυμεί προκειμένου να καταγράψει πλήρως τη γνώση που απαιτεί η επίλυση του προβλήματος. Οι κανόνες που εισάγονται δύναται να αφορούν τα ίδια ή διαφορετικά, διασταυρούμενα υποσύνολα γεγονότων και ενεργειών.

Σημειώνεται πως αν και στην παρούσα υλοποίηση οι προδραστικοί κανόνες κατασκευάζονται από τον ειδικό, η προτεινόμενη μέθοδος θα μπορούσε να εφαρμοστεί και σε περιπτώσεις όπου οι προδραστικοί κανόνες παράγονται με αναλύσεις ιστορικών δεδομένων του προς επίλυση προβλήματος.

Ο προγραμματιστής ενεργειών αποτελεί το δομικό στοιχείο του επιπέδου το οποίο θα αναλάβει τον προγραμματισμό των ενεργειών που έχουν προταθεί από το σύστημα.

Το υποσύστημα της επεξεργασίας ροών δεδομένων αποτελείται από τη μηχανή συμπερασμού (Inference Engine) και τον πυρήνα του μηχανισμού προδιαγραφικής αναλυτικής (Prescriptive Analytics Mechanism).

Η μηχανή συμπερασμού είναι υπεύθυνη για τον έλεγχο αλήθειας των κανόνων που εμπεριέχονται στο σύστημα κανόνων. Για κάθε κανόνα επαληθεύει τον ισχυρισμό του και τον θέτει ως υποψήφιο προς εκτέλεση. Η εκτέλεση ενός κανόνα καλείται πυροδότηση κανόνα (rule firing). Όταν ο κανόνας εκτελείται, τα συμπεράσματα του κανόνα εξάγονται μέσα στη μνήμη εργασίας και γίνονται διαθέσιμα στα επόμενα βήματα της διαδικασίας. Η μηχανή συμπερασμού ενεργοποιείται κάθε φορά που παράγεται μία καινούρια πρόβλεψη. Οι κανόνες που

πυροδοτούνται αποτελούν την είσοδο για την δυναμική κατασκευή του προδιαγραφικού μοντέλου του προβλήματος, το οποίο αποτελεί τη βάση του περιβάλλοντος ενισχυτικής μάθησης.

Ο πυρήνας του προδιαγραφικού μηχανισμού περιέχει τέσσερα δομικά στοιχεία: τον κατασκευαστή περιβάλλοντος ενισχυτικής μάθησης (RL Environment Builder), τον εκπαιδευτή ενισχυτικής μάθησης (RL Learner), τον διαμορφωτή πολιτικής (Policy shaper) και τον προδιαγραφικό πράκτορα (Prescriptive Agent).

Ο κατασκευαστής περιβάλλοντος ενισχυτικής μάθησης, όπως υποδηλώνει και το όνομα του δομικού στοιχείου, αναλαμβάνει να κατασκευάσει ένα νέο περιβάλλον ενισχυτικής μάθησης δυναμικά, ακολουθώντας το προδραστικό μοντέλο λήψης αποφάσεων που περιγράφεται στην προσέγγιση των (Engel et al., 2012). Το συγκεκριμένο μοντέλο βασίζεται στη χρήση των μαρκοβιανών διαδικασιών απόφασης, οι οποίες αποτελούν μια εξιδανικευμένη αναπαράσταση του προβλήματος ενισχυτικής μάθησης (Sutton, και Barto, 2018).

Θεωρώντας μια απλουστευμένη περίπτωση, στην οποία επιχειρούμε να αποφύγουμε την εκδήλωση του ανεπιθύμητου γεγονότος ϵ , ο ειδικός έχει καταχωρήσει μεταξύ άλλων τρεις κανόνες οι οποίοι πυροδοτούνται με την πρόβλεψη του συγκεκριμένου ανεπιθύμητου γεγονότος. Οι κανόνες που πυροδοτούνται για το συγκεκριμένο γεγονός υποδεικνύουν τις υποψήφιες εναλλακτικές ενέργειες που μπορεί να υλοποιήσει ο ειδικός προκειμένου να αποφύγει την εκδήλωση του γεγονότος και περιγράφονται ως:

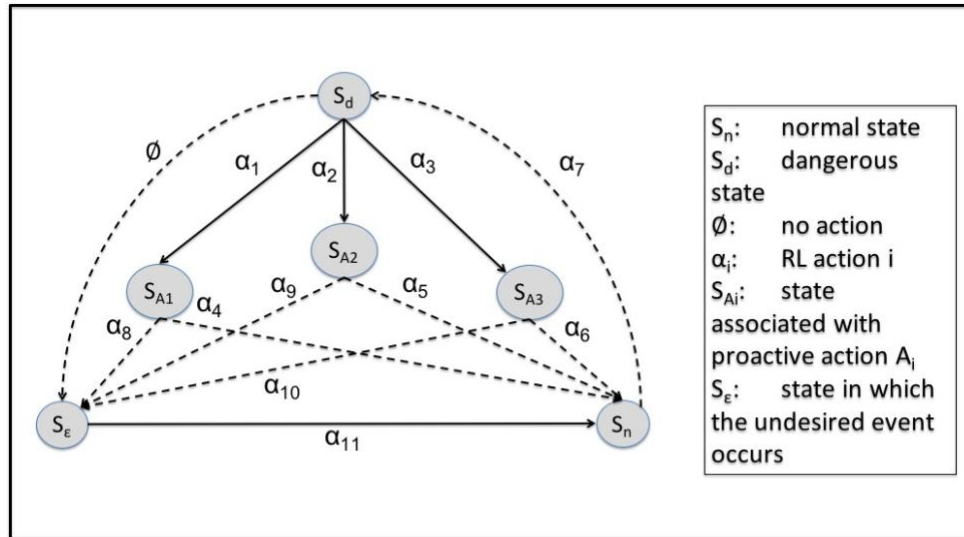
IF ϵ THEN A1

IF ϵ THEN A2

IF ϵ THEN A3

Σύμφωνα με αυτούς τους κανόνες, ο κατασκευαστής περιβάλλοντος ενισχυτικής μάθησης κατασκευάζει το περιβάλλον της Εικόνα 6-3, στο οποίο παρουσιάζονται οι καταστάσεις $\{S_n, S_d, SA_1, SA_2, SA_3, S_\epsilon\}$ και οι ενέργειες του πράκτορα $\{\alpha_1, \dots, \alpha_{11}\}$. Σε αυτό το περιβάλλον, ο πράκτορας ενισχυτικής μάθησης δοκιμάζει διαφορετικές ακολουθίες ενεργειών, μεταβαίνοντας από μία κατάσταση σε μια άλλη, μέχρις ότου φτάσει στην επιθυμητή κατάσταση μέσω της ακολουθίας που του παρέχει τη

βέλτιστη δυνατή αμοιβή. Κάθε προσπάθεια, η οποία καλείται επεισόδιο, ξεκινά ανεξάρτητα από την προηγούμενη προσπάθεια και ολοκληρώνεται όταν ο πράκτορας φτάσει σε μια τερματική κατάσταση. Η διαδικασία των δοκιμών αντιστοιχεί στην εκπαίδευση του πράκτορα και εκτελείται από τον εκπαιδευτή ενισχυτικής μάθησης.

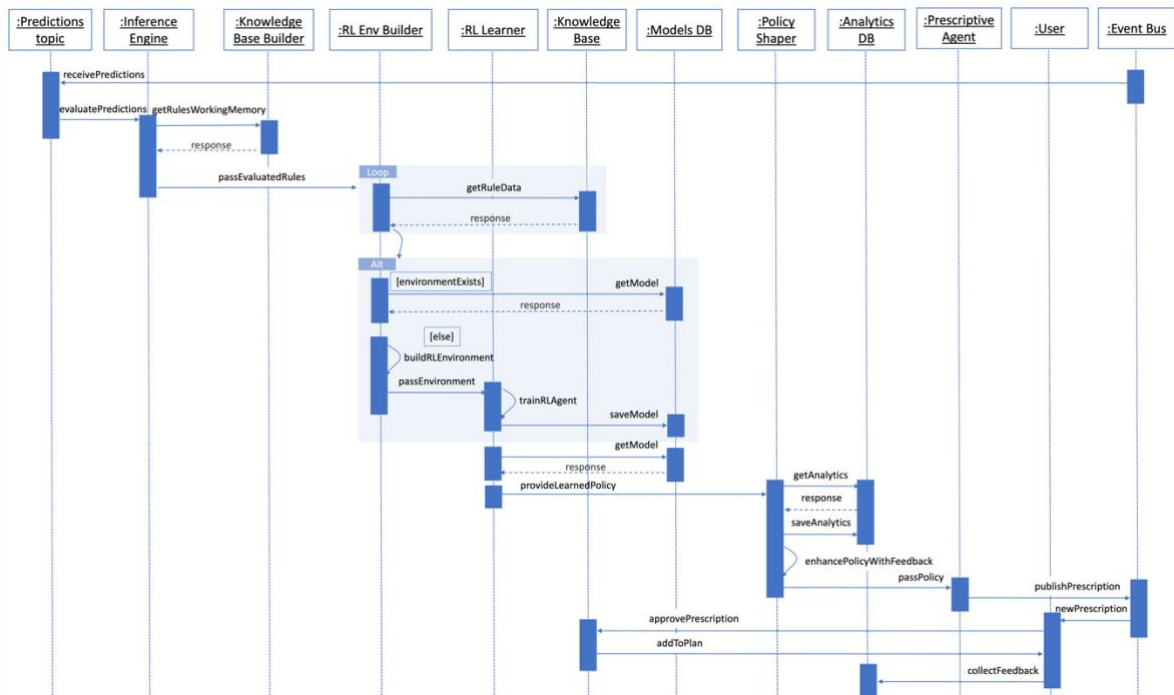


Εικόνα 6-3 Περιβάλλον ενισχυτικής μάθησης προτεινόμενης μεθόδου

Μετά την ολοκλήρωση της εκπαίδευσης, ο πράκτορας έχει εντοπίσει την ακολουθία προς την επιθυμητή κατάσταση με την οποία συγκεντρώνει τη μέγιστη ανταμοιβή. Η γνώση αυτή αντικατοπτρίζεται στην πολιτική του πράκτορα για το συγκεκριμένο περιβάλλον. Η πολιτική αυτή παράγει την προδιαγραφή με την βέλτιστη ακολουθία ενεργειών, την οποία το σύστημα μέσω του προδιαγραφικού πράκτορα επικοινωνεί στον χρήστη και στα διασυνδεδεμένα συστήματα. Ο διαμορφωτής πολιτικής του προδιαγραφικού μηχανισμού αναλαμβάνει να ενημερώσει και να ενσωματώσει την ανάδραση του χρήστη στην πολιτική του πράκτορα.

Μέσω της επεξεργασίας ρών δεδομένων, το επίπεδο λογικής αλληλοεπιδρά με τον δίαυλο γεγονότων προκειμένου να λάβει ροές προβλεπτικών αποτελεσμάτων σχετιζόμενα με μελλοντικά γεγονότα και να παρέχει τις εξαγόμενες προδιαγραφές σχετιζόμενες με τις βέλτιστες δυνατές ενέργειες που απαντούν στις προβλέψεις.

Η διαδικασία που ακολουθείται στην φάση εκτέλεσης αποτυπώνεται με τη μορφή διαγράμματος ακολουθίας στην Εικόνα 6-4.



Εικόνα 6-4 Διάγραμμα ακολουθίας της φάσης εκτέλεσης του συστήματος

Οι προβλέψεις πραγματικού χρόνου λαμβάνονται μέσω του μεσολαβητή και του καναλιού προβλέψεων (**Predictions topic**) και δίνονται ως είσοδος στη **μηχανή συμπερασμού** μέσω της λειτουργίας *evaluatePredictions*. Η μηχανή συμπερασμού αρχικά εκτελεί την ενέργεια *getRulesWorkingMemory* προκειμένου να ανακτήσει από τη μνήμη εργασίας που έχει συσχετιστεί με τον **κατασκευαστή βάσης γνώσης**, τους κανόνες που έχουν εισαχθεί από τον χρήστη. Ο κατασκευαστής βάσης γνώσης κατασκευάζει το σύστημα κανόνων σύμφωνα με την παραμετροποίηση του χρήστη κατά την φάση σχεδίασης. Οι ανακτηθέντες κανόνες αξιολογούνται και πυροδοτούνται οι κανόνες που σχετίζονται με τις ληφθείσες προβλέψεις, οι οποίοι περιέχουν τα σύνολα εναλλακτικών ενεργειών που σχετίζονται με τις συγκεκριμένες προβλέψεις.

Οι πυροδοτηθέντες κανόνες δίνονται ως είσοδος στον **κατασκευαστή περιβάλλοντος ενισχυτικής μάθησης** μέσω της λειτουργίας *passEvaluatedRules*. Εκεί, κατασκευάζεται ο χώρος καταστάσεων, ενεργειών καθώς και οι αντίστοιχες ανταμοιβές του περιβάλλοντος ενισχυτικής μάθησης. Στη συνέχεια, ο πράκτορας ενισχυτικής μάθησης εκπαιδεύεται πάνω στο συγκεκριμένο περιβάλλον, από όπου

προκύπτει το μοντέλο που αντιστοιχεί στη βέλτιστη πολιτική ως προς τα επιλεγμένα κριτήρια.

Το μοντέλο αυτό αποθηκεύεται στην **βάση μοντέλων (Models DB)**. Προκειμένου να αποφευχθεί πιθανή επανάληψη των ίδιων διαδικασιών, ο κατασκευαστής περιβάλλοντος ενισχυτικής μάθησης επιχειρεί αρχικά να ανακτήσει, εφόσον υπάρχει, το μοντέλο που αντιστοιχεί στην υπό εξέταση περίπτωση του προβλήματος, από την αποθήκη δεδομένων. Η ύπαρξη ενός τέτοιου μοντέλου υποδηλώνει ότι ο RL πράκτορας έχει εκπαιδευτεί στο παρελθόν στο ίδιο περιβάλλον. Αν δεν υπάρχουν νέες ενημερώσεις πάνω στα δεδομένα του περιβάλλοντος, για παράδειγμα μεταβολή κάποιου κριτηρίου ή κανόνα, τότε το μοντέλο του περιβάλλοντος χρησιμοποιείται ως έχει. Στην περίπτωση που το περιβάλλον κατασκευάζεται για πρώτη φορά, ο κατασκευαστής περιβάλλοντος ενισχυτικής μάθησης, μοντελοποιεί το νέο περιβάλλον σύμφωνα με τους πυροδοτειθέντες κανόνες. Με τη λειτουργία *passEnvironment* περνάει το περιβάλλον ως είσοδο στον **εκπαιδευτή ενισχυτικής μάθησης**. Με τη σειρά του αυτό το δομικό στοιχείο εκπαιδεύει τον RL πράκτορα (λειτουργία *trainRLAgent*) και αποθηκεύει την παραχθείσα βέλτιστη πολιτική στην αποθήκη δεδομένων (*saveModel*).

Μετά την ανάκτηση ή τη δημιουργία του μοντέλου, ο εκπαιδευτής ενισχυτικής μάθησης παρέχει το εκπαιδευμένο μοντέλο ως είσοδο στον **διαμορφωτή πολιτικής**. Ο διαμορφωτής πολιτικής είναι υπεύθυνος για την ενσωμάτωση της ανάδρασης του χρήστη στην πολιτική του πράκτορα. Για το σκοπό αυτό, ξεκινά ανακτώντας τις διαθέσιμες καταγραφές ανάδρασης του χρήστη από προηγούμενες προδιαγραφές. Η πληροφορία αυτή αποθηκεύεται στη **βάση αναλυτικής δεδομένων (Analytics DB)** μέσω της λειτουργίας *getAnalytics*. Ο διαμορφωτής πολιτικής διαχειρίζεται κατάλληλα όποια ενημέρωση πρέπει να γίνει πάνω σε αυτά τα δεδομένα και αποθηκεύει τις αλλαγές στην ίδια αποθήκη (*saveAnalytics*). Η διαμόρφωση του μοντέλου ανάλογα με την ανάδραση του χρήστη εκτελείται από τη λειτουργία *enhancePolicyWithFeedback*.

Η βέλτιστη πολιτική προωθείται στον **προδιαγραφικό πράκτορα** μέσω της λειτουργίας *passPolicy*. Ο προδιαγραφικός πράκτορας ακολουθώντας τη βέλτιστη πολιτική παράγει την προδιαγραφή στην απαιτούμενη μορφή και την δημοσιεύει στο

κανάλι προδιαγραφών (**Prescription topic**) του δίαυλου γεγονότων (*publishPrescription*). Η νέα προδιαγραφή επικοινωνείται στον χρήστη μέσα από την διεπαφή χρήστη με τη λειτουργία *newPrescription*. Ο χρήστης μπορεί πλέον να αλληλοεπιδράσει με τη νέα προδιαγραφή, παρέχοντας ανάδραση με τη μορφή αποδοχής ή απόρριψης της προτεινόμενης προδιαγραφής. Η ανάδραση συλλέγεται με την λειτουργία *collectFeedback* και αποθηκεύεται στην αποθήκη δεδομένων AnalyticsDB. Στην περίπτωση θετικής ανάδρασης τα δεδομένα του συστήματος ενημερώνονται μέσω της λειτουργίας *approvePrescription*, ενώ μετά την κατάλληλη επεξεργασία από τον Προγραμματιστή Ενεργειών, η προδιαγραφή προστίθεται στο πλάνο αποφάσεων εκτελώντας τη λειτουργία *addToPlan*.

6.1.3 Επίπεδο Αποθήκευσης Δεδομένων

Το επίπεδο αποθήκευσης δεδομένων του συστήματος είναι υπεύθυνο για τη συνολική διαχείριση των δεδομένων και αποτελείται από μία σχεσιακή βάση δεδομένων SQL, την **βάση γνώσης (Knowledge Base)** και δύο μη σχεσιακού τύπου βάσεις NoSQL, και πιο συγκεκριμένα εγγραφοστρεφείς βάσεις, την **βάση μοντέλων (Models DB)** και την **βάση αναλυτικής (Analytics DB)**. Το επίπεδο αποθήκευσης δεδομένων δύναται να επικοινωνεί με επιπλέον εξωτερικές βάσεις (**Domain DB**), στις οποίες αποθηκεύεται εξειδικευμένη γνώση αναφορικά με το επιστημονικό πεδίο και τις συνθήκες του προβλήματος, όταν αυτή είναι απαραίτητη για την εφαρμογή της προτεινόμενης μεθόδου.

Οι σχεσιακές βάσεις δεδομένων δομούνται σύμφωνα με ένα μοντέλο αποτελούμενο από διαφορετικούς πίνακες δεδομένων οι οποίοι αλληλοσυνδέονται με σχέσεις ξένων κλειδιών (*foreign keys*). Κατά συνέπεια, για να απαντηθεί ένα ερώτημα ή να εισαχθεί μια νέα καταχώρηση σε μια σχεσιακή βάση δεδομένων, διατρέχεται μεγάλος αριθμός πινάκων οι οποίοι συνδυάζονται προκειμένου να συγκεντρώσουν ή να δημιουργήσουν την ζητούμενη πληροφορία. Σε αντίθεση με αυτό, οι εγγραφοστρεφείς βάσεις δεδομένων, οι οποίες αποτελούν μια υπο-κλάση των βάσεων ζεύγους-κλειδιού (*key-value*), δεν ακολουθούν κάποιο αυστηρό σχήμα δεδομένων, αλλά χρησιμοποιούν πρότυπα εγγράφων όπως XML, JSON, YAML κ.ά. για να αποθηκεύσουν όλη την απαιτούμενη πληροφορία σχετικά με ένα αντικείμενο, σε

ένα έγγραφο, το οποίο μπορεί να ακολουθεί διαφορετική δομή από τα υπόλοιπα έγγραφα της βάσης.

Μιας και οι σχεσιακές βάσεις απαιτούν τον προκαθορισμό του σχήματος πριν την κατασκευή της βάσης δεδομένων, οποιαδήποτε αλλαγή του σχήματος μετά την εισαγωγή δεδομένων, μπορεί να οδηγήσει σε προβλήματα. Αντιθέτως, οι εγγραφοστρεφείς βάσεις, καταρρίπτουν αυτό τον περιορισμό και υποστηρίζουν ένα δυναμικό σχήμα. Αυτή η δυνατότητα είναι χρήσιμη για εφαρμογές μεγάλων και διαφορετικών δεδομένων στις οποίες ζητείται η προσθήκη εγγράφων διαφορετικής δομής χωρίς να απαιτείται κάποια τροποποίηση στα υπάρχοντα δεδομένα ή την ίδια την εφαρμογή και την υλοποίησή της.

Συνοπτικά, οι NoSQL βάσεις δεδομένων παρουσιάζουν τα εξής πλεονεκτήματα (Gurta et al., 2012):

- Υποστήριξη δεδομένων μεγάλης κλίμακας
- Υψηλές επιδόσεις εγγραφής
- Γρήγορη πρόσβαση κλειδιού-τιμής
- Ευέλικτο σχήμα, ευέλικτες βάσεις δεδομένων και εύκολη μετατροπή σχήματος
- Εύκολη χρήση για τους προγραμματιστές
- Υποστήριξη κατανεμημένων συστημάτων

Σύμφωνα με τους Han et al. (2011), τα NoSQL συστήματα ταξινομούνται σε τρεις κατηγορίες:

- **Βάσεις κλειδιού-τιμής (key-value databases):** Σε αυτές κάθε τιμή αντιστοιχεί σε ένα κλειδί. Οι βάσεις αυτές με μια πολύ απλή δομή, παρέχουν ταχύτητα πολύ υψηλότερη από τις σχεσιακές βάσεις δεδομένων και υποστηρίζουν μαζική αποθήκευση με υψηλή παραλληλισμότητα. Ενδεικτικός εκπρόσωπος αυτών των βάσεων είναι η Redis.
- **Βασισμένες σε στήλες (column-oriented databases):** Οι βάσεις αυτής της κατηγορίας οργανώνουν τα δεδομένα σε πίνακες χωρίς να υποστηρίζουν την συσχέτιση πινάκων. Τα δεδομένα αποθηκεύονται ανά στήλη, όπου κάθε στήλη αποτελεί ένα ευρετήριο της βάσης δεδομένων. Αυτό έχει ως αποτέλεσμα τη

μείωση των εισόδων/εξόδων (I/O) του συστήματος καθώς σε κάθε ερώτημα να διατρέχονται μόνο όσες στήλες απαιτούνται. Παράλληλα, οι βάσεις αυτής της μορφής υποστηρίζουν ταυτόχρονα ερωτήματα. Ενδεικτική βάση αυτής της κατηγορίας είναι η Cassandra.

- **Εγγραφοστρεφείς βάσεις (document-oriented databases):** Οι εγγραφοστρεφείς βάσεις δεδομένων μοιάζουν με τις βάσεις κλειδιού-τιμής, με τη διαφορά ότι η τιμή είναι ένα σημασιολογικό αντικείμενο αποθηκευμένο σε μορφή XML ή JSON. Οι βάσεις αυτής της κατηγορίας υποστηρίζουν δευτερογενή ευρετήρια ως προς την τιμή, τα οποία δεν υποστηρίζονται από τις βάσεις κλειδιού-τιμής. Ενδεικτικά συστήματα αυτού του τύπου είναι η MongoDB.

Όπως περιγράφεται από τους Han et al. (2011), οι σύγχρονες εφαρμογές διαχείρισης δεδομένων μεγάλης κλίμακας απαιτούν:

- Υψηλή υποστήριξη παράλληλων καταχωρίσεων και ανακτήσεων δεδομένων με χαμηλή καθυστέρηση
- Αποδοτική αποθήκευση δεδομένων μεγάλης κλίμακας και υποστήριξη
- Υψηλή διαθεσιμότητα και επεκτασιμότητα
- Χαμηλό λειτουργικό και διαχειριστικό κόστος

Με αυτές τις προϋποθέσεις, οι σχεσιακές βάσεις δεδομένων παρουσιάζουν χαμηλή ταχύτητα εγγραφής και ανάκτησης δεδομένων, περιορισμένη χωρητικότητα και δυσκολία επεκτασιμότητας. Για τους παραπάνω λόγους, οι NoSQL βάσεις δεδομένων διευκολύνουν την αναλυτική δεδομένων μεγάλης κλίμακας και κυρίως τις εφαρμογές μηχανικής και ενισχυτικής μάθησης, παρέχοντας αυξημένη επεκτασιμότητα και υψηλές επιδόσεις (Konstantinou et al., 2011).

6.1.3.1 Βάση Γνώσης

Η βάση γνώσης χρησιμοποιείται για την αποθήκευση της γνώσης του προβλήματος μετασχηματισμένη κατάλληλα στις οντότητες που υποδεικνύει η προτεινόμενη μέθοδος καθώς και των αντίστοιχων προδραστικών κανόνων. Η Βάση Γνώσης αποτελεί μια σχεσιακή βάση δεδομένων, αντίστοιχη του μοντέλου των δεδομένων του προβλήματος, τα οποία αποθηκεύονται και ανακτώνται από τα υπόλοιπα δομικά στοιχεία της αρχιτεκτονικής. Στην Εικόνα 6-5 παρουσιάζονται οι

οντότητες του μοντέλου δεδομένων της βάσης γνώσης με τη μορφή ενός διαγράμματος κλάσεων UML. Παρακάτω περιγράφονται οι βασικές οντότητες και οι μεταξύ τους συσχετίσεις.

assets. Η οντότητα αυτή διατηρεί την πληροφορία που αφορά όλα τα αντικείμενα που συμμετέχουν στη λήψη απόφασης, τα οποία ουσιαστικά αναπαριστούν τα αντικείμενα στα οποία θα εκτελεστεί μια ενέργεια, θα εκδηλωθεί ή θα προβλεφθεί ένα γεγονός. Ένα τέτοιο αντικείμενο θα μπορούσε να είναι ένα μηχάνημα στο οποίο προβλέπουμε ότι θα εκδηλωθεί ένα γεγονός αστοχίας. Τα αντικείμενα αυτού του πίνακα προσδιορίζονται μοναδικά με τη βοήθεια του πεδίου *asset_id*.

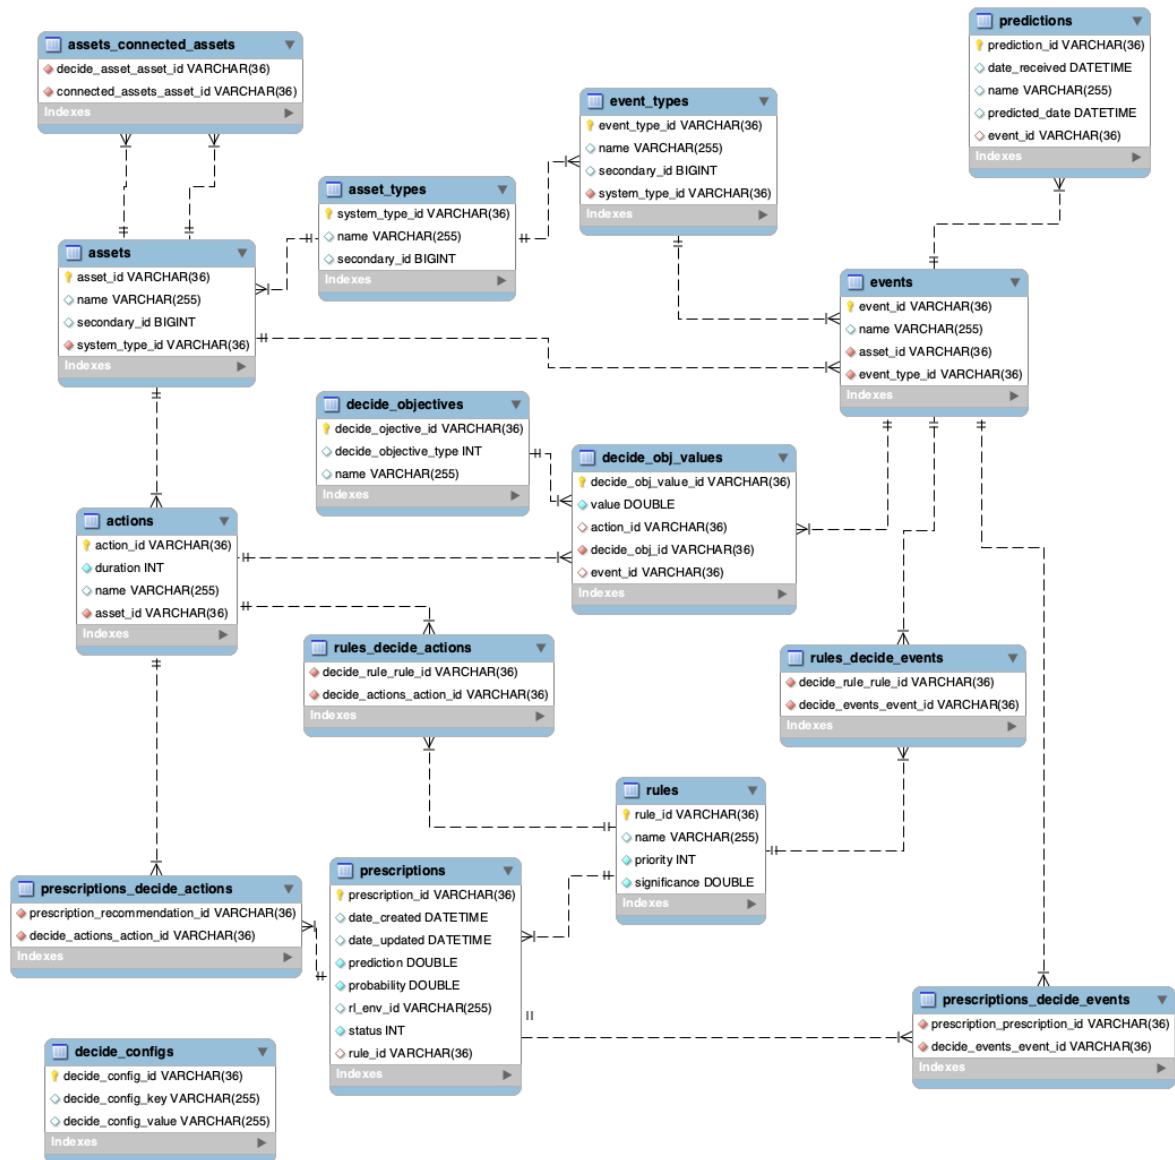
assets_connected_assets. Η οντότητα αυτή αναπαριστά τις δομικές εξαρτήσεις που έχουν τα αντικείμενα που συμμετέχουν στη λήψη απόφασης. Η συσχέτιση των αντικειμένων γίνεται μέσω των πεδίων *decide_asset_asset_id* και *connected_assets_asset_id*, όπου αποθηκεύεται το *asset_id* των δύο συσχετιζόμενων αντικειμένων. Μέσω αυτής της συσχέτισης, μπορεί να αναπαρασταθεί οποιαδήποτε συσχέτιση μεταξύ των συμμετεχόντων αντικειμένων.

asset_types. Η οντότητα *asset_types* διατηρεί επιπλέον πληροφορία για τα αντικείμενα που συμμετέχουν στη λήψη αποφάσεων, συνεισφέρει στην κατηγοριοποίηση των αντικειμένων και κατά συνέπεια των γεγονότων που αναφέρονται σε αυτά.

event_types. Η οντότητα αυτή αντιστοιχεί στους τύπους γεγονότων για τα οποία επιθυμούμε να αποφύγουμε ή να βοηθήσουμε την εκδήλωσή τους. Στην παρούσα υλοποίηση οι τύποι αυτοί συσχετίζονται με τους τύπους των αντικειμένων *asset_types*.

events. Στον πίνακα *events* αποθηκεύονται τα γεγονότα τα οποία είναι πιθανόν να συμβούν και επιθυμούμε να αποφύγουμε ή να υποβοηθήσουμε. Η παρούσα υλοποίηση θεωρεί ένα γεγονός ως την υλοποίηση (*instance*) ενός τύπου γεγονότος (*event_type_id*) πάνω σε ένα συγκεκριμένο αντικείμενο (*asset_id*). Με την οντότητα αυτή διευκολύνεται η επικοινωνία ανάμεσα στις εισερχόμενες προβλέψεις και τους προκαθορισμένους κανόνες. Κάθε γεγονός προσδιορίζεται μοναδικά μέσω του *event_id*.

actions. Η οντότητα actions διατηρεί την απαιτούμενη πληροφορία που αφορά τις υποψήφιες ενέργειες που δύναται να προταθούν προς υλοποίηση. Κάθε ενέργεια προσδιορίζεται μοναδικά με το *action_id* και συσχετίζεται με ένα ή περισσότερα αντικείμενα (*asset_id*).



Εικόνα 6-5 Διάγραμμα οντοτήτων-σχέσεων βάσης δεδομένων

predictions. Στον πίνακα predictions αποθηκεύονται οι λεπτομέρειες των προβλέψεων των μελλοντικών γεγονότων που έχουν ληφθεί και έχουν προωθηθεί για επεξεργασία στις επιμέρους λειτουργικότητες. Το πεδίο *date_received* δηλώνει την ημερομηνία λήψης της πρόβλεψης, ενώ τα πεδία *predicted_date* και *occurrence_time* δηλώνουν την ημερομηνία και την ώρα στην οποία προβλέπεται να

εκδηλωθεί το προβλεπόμενο γεγονός. Το πεδίο *event_id* υποδεικνύει το γεγονός το οποίο προβλέπεται να εκδηλωθεί.

rules. Στον πίνακα *rules* αποθηκεύονται οι κανόνες που εισάγονται από τον ειδήμονα του προβλήματος και συσχετίζουν τα πιθανά γεγονότα με τις υποψήφιες προδραστικές ενέργειες. Κάθε κανόνας ορίζεται από ένα σύνολο πιθανών γεγονότων τα οποία διαμορφώνουν το υποθετικό μέρος του κανόνα και από ένα σύνολο προδραστικών ενεργειών. Όταν η εκδήλωση ενός γεγονότος προβλεφθεί, οι αναφερόμενοι σε αυτό κανόνες ενεργοποιούνται και προωθούνται στις υπόλοιπες λειτουργικότητες για την κατασκευή του μοντέλου ενισχυτικής μάθησης.

rules_decide_events. Η οντότητα αυτή αποθηκεύει την συσχέτιση των γεγονότων με τον κανόνα στον οποίο συμμετέχουν.

rules_decide_actions. Η οντότητα αυτή αποθηκεύει την συσχέτιση των ενεργειών με τον κανόνα στον οποίο συμμετέχουν.

prescriptions. Στον πίνακα *prescriptions* αποθηκεύονται οι πληροφορίες των παραγόμενων προδιαγραφών. Το πεδίο *prescription_id* χρησιμοποιείται ως μοναδικό αναγνωριστικό κάθε προδιαγραφής. Η οντότητα αυτή χρησιμοποιείται για την παραγωγή και διαχείριση προδιαγραφών καθώς αποτελεί το σημείο σύνδεσης του περιβάλλοντος ενισχυτικής μάθησης (*rl_env_id*) και της επιρροής της ανάδρασης του χρήστη (*status*) που αφορούν την κάθε προδιαγραφή. Μέσω αυτής της οντότητας επίσης καθορίζεται το Πλάνο Ενεργειών το οποίο κατασκευάζεται από τις προδιαγραφές που έχουν εγκριθεί από τον χρήστη. Οι τιμές που μπορεί να πάρει το πεδίο *status* είναι: PENDING, APPROVED, REJECTED, COMPLETED, OVERDUE και EXPIRED. Επιπλέον, τα πεδία *date_created* και *date_updated* υποδηλώνουν την ημερομηνία παραγωγής και επεξεργασίας της προδιαγραφής αντίστοιχα.

prescriptions_decide_actions. Ο πίνακας *prescriptions_decide_actions* είναι ένας βοηθητικός πίνακας στον οποίο αποθηκεύεται η σχέση των παραγόμενων προδιαγραφών με τις επιμέρους ενέργειες που προτείνονται από την προδιαγραφή.

Στο σύνολο των προαναφερθέντων πινάκων ακολουθείται το πρότυπο Universally Unique Identifier (UUID) για την παραγωγή των μοναδικών αναγνωριστικών των οντοτήτων. Η διαχείριση των εγγραφών των παραπάνω σχέσεων είναι δυνατή μέσω

της διεπαφής χρήστη που προσφέρει η παρούσα υλοποίηση, καθώς και μέσω της REST διεπαφής που έχει υλοποιηθεί.

6.1.3.2 Βάση Μοντέλων

Η Βάση Μοντέλων συγκεντρώνει τα δεδομένα που αφορούν τα περιβάλλοντα ενισχυτικής μάθησης. Στο παρόν σύστημα υλοποιείται ως μια εγγραφοστρεφής βάση δεδομένων, αποτελούμενη από δύο συλλογές. Η πρώτη είναι η συλλογή εγγράφων περιβάλλοντος ενισχυτικής μάθησης **RLEnv**, τα έγγραφα της οποίας έχουν τη δομή που παρουσιάζεται στην Εικόνα 6-6. Κάθε έγγραφο αυτής της συλλογής συγκεντρώνει τις πληροφορίες περιβάλλοντος ενισχυτικής μάθησης το οποίο κατασκευάστηκε κατά την άφιξη μιας νέας πρόβλεψης, το γεγονός της πρόβλεψης (*predictedEventsIds*), τους κανόνες που ενεργοποιήθηκαν και χρησιμοποιήθηκαν για την κατασκευή του περιβάλλοντος ενισχυτικής μάθησης (*ruleIds*), την εξαγόμενη πολιτική του πράκτορα από την διαδικασία ενισχυτικής μάθησης πολλαπλών κριτήριων (*rlPolicy*), την κατανομή πιθανότητας της ανάδρασης που μέχρι τη στιγμή του υπολογισμού έχει ληφθεί αναφορικά με το συγκεκριμένο περιβάλλον (*feedbackPolicy*), καθώς και την πιο πρόσφατα διαμορφωμένη από την ανάδραση του χρήστη συνολική πολιτική (*shapedPolicy*). Η δομή αυτή συγκεντρώνει όλες τις απαραίτητες πληροφορίες για την εύκολη και γρήγορη ανάκτηση του περιβάλλοντος, γεγονός που διευκολύνει την επαναχρησιμοποίησή του, στην περίπτωση που ληφθεί μια αντίστοιχη πρόβλεψη.

```

_id: ObjectId("615f08efa667220f800dc62c")
ruleIds: Array
  0: "9c540baf-277d-11ec-ae9-0242ac180002"
  1: "fail_occurred"
  2: "9c50c7eb-277d-11ec-ae9-0242ac180002"
  3: "9c571dbb-277d-11ec-ae9-0242ac180002"
dateCreated: "Thu Oct 7 17:00:00 EET 2021"
dateUpdated: "2021-10-07T17:49:25.681288"
rlPolicy: Object
  0: Array
    0: Object
      ga: Object
        aId: 0
        _class: "burlap.domain.singleagent.graphdefined.GraphDefinedDomain$GraphActionT..."
        pSelection: 4.6065859933763245e-46
      1: Object
      2: Object
      3: Object
    1: Array
    2: Array
    3: Array
    4: Array
    5: Array
  feedbackPolicy: Object
    9c540baf-277d-11ec-ae9... : 0.5
    fail_occurred: 0.5
    9c50c7eb-277d-11ec-ae9... : 0.09999999999999999
    9c571dbb-277d-11ec-ae9... : 0.012195121951219506
  shapedPolicy: Object
    9c540baf-277d-11ec-ae9... : 2.8559941887592916e-44
    fail_occurred: 2.3032929966881622e-46
    9c50c7eb-277d-11ec-ae9... : 0.004865393393370645
    9c571dbb-277d-11ec-ae9... : 1.3886956874047048e-44
    _class: "imu.decide.model.deciderl.RLEnv"
  predictedEventsIds: Array
    0: "9c4b5196-277d-11ec-ae9-0242ac180002"

```

Εικόνα 6-6 Παράδειγμα εγγράφου Συλλογής Περιβάλλοντος Ενισχυτικής Μάθησης RLEnv

6.1.3.3 Βάση Αναλυτικής Δεδομένων

Αντίστοιχα με την βάση μοντέλων, στο πληροφοριακό σύστημα αναπτύχθηκε η βάση αναλυτικής δεδομένων, μια εγγραφοστρεφής βάση δεδομένων, στην οποία αποθηκεύονται τα επιμέρους δεδομένα της διαδικασίας μάθησης που συνδέονται με την παραγόμενη προδιαγραφή και την ανάδραση του χρήστη. Η βάση αναλυτικής δεδομένων αποτελείται από δύο συλλογές δεδομένων, την συλλογή δεδομένων ενισχυτικής μάθησης **RLData** και την συλλογή ανάδρασης χρήστη **Feedback**. Στη συλλογή RLData αποθηκεύονται έγγραφα τα οποία συσχετίζονται με τις παραγόμενες προδιαγραφές (*recommendationId*) και έχουν τη δομή που φαίνεται στην Εικόνα 6-7. Σε κάθε έγγραφο αυτής της συλλογής, αποθηκεύεται ο κανόνας που επιλέχθηκε και η διαμορφωμένη συνολική πολιτική του πράκτορα (*shapedPolicy*) που προέκυψε

έπειτα από τη διαμόρφωση της πολιτικής που εξάχθηκε από την ενισχυτική μάθηση πολλαπλών κριτηρίων βάσει της μέχρι εκείνης της στιγμής διαθέσιμης ανάδρασης.

```
_id: ObjectId("615f08f4a667220f800dc631")
recommendationId: "60562b38-ed5f-4155-97e6-c17b8ea0c933"
shapedPolicy: Object
  9c540baf-277d-11ec-ae9... : Object
    actionNames: Array
      0: "Sell"
    probability: 5.617685462822706e-59
    cost: 0
    positiveFeedback: 0
    totalFeedback: 0
    event_occurred: Object
      actionNames: Array
        0: "No action"
      probability: 2.632523230605683e-73
      cost: 0
      positiveFeedback: 0
      totalFeedback: 0
      9c50c7eb-277d-11ec-ae9... : Object
        actionNames: Array
          0: "Buy"
        probability: 1.9880364624773863e-59
        cost: 0
        positiveFeedback: 0
        totalFeedback: 1
      9c571dbb-277d-11ec-ae9... : Object
ruleId: "9c571dbb-277d-11ec-ae9-0242ac180002"
_class: "imu.decide.model.deciderL.RLData"
```

Εικόνα 6-7 Παράδειγμα εγγράφου Συλλογής Δεδομένων Ενισχυτικής Μάθησης RLData

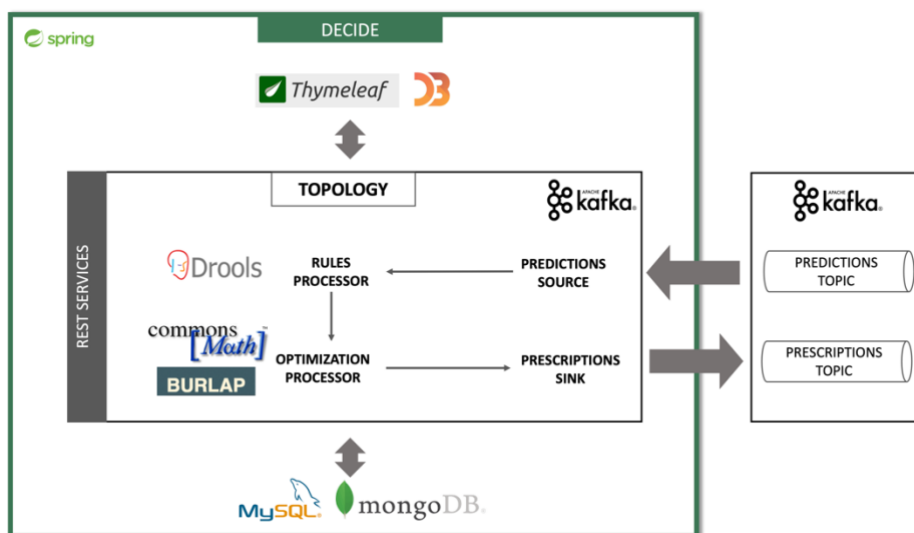
Όπως περιγράφεται στο κεφάλαιο 5, η έγκριση ή η απόρριψη μιας προδιαγραφής από τον χρήστη μεταφράζεται σε θετική ή αρνητική ανάδραση πάνω στις ενέργειες της παραχθείσας προδιαγραφής. Στην συλλογή ανάδρασης αποθηκεύεται κάθε ανάδραση του χρήστη με τη δομή εγγράφου που παρουσιάζεται στην Εικόνα 6-8. Σε κάθε έγγραφο αποθηκεύεται η προδιαγραφή που αφορά η ανάδραση (*reccomendationId*), ο κανόνας που εμπεριέχει τις ενέργειες που προτάθηκαν (*ruleId*) και το είδος της ανάδρασης που δόθηκε από τον χρήστη (*feedback*). Με τη βοήθεια αυτών των εγγραφών υπολογίζονται τα στατιστικά ανάδρασης, δηλαδή ο αριθμός των θετικών και των αρνητικών αναδράσεων, που αφορούν την προδιαγραφή που προέκυψε από ένα συγκεκριμένο περιβάλλον ενισχυτικής μάθησης.

```
_id: ObjectId("615f08f4a667220f800dc632")
rLEnvId: "615f08efa667220f800dc62c"
recommendationId: "60562b38-ed5f-4155-97e6-c17b8ea0c933"
ruleId: "9c571dbb-277d-11ec-ae9-0242ac180002"
feedback: "ACCEPTED"
_class: "imu.decide.model.deciderL.Feedback"
```

Εικόνα 6-8 Παράδειγμα εγγράφου Συλλογής Ανάδρασης Feedback

6.2 Υλοποίηση

Το πληροφοριακό σύστημα αναπτύχθηκε σε Java 9, αξιοποιώντας τα εργαλεία Apache Maven, το Docker και το framework Spring. Η χρήση αυτών των εργαλείων διευκολύνει την υλοποίηση και εξασφαλίζει τη διαθεσιμότητα των εξαρτώμενων βιβλιοθηκών. Το εργαλείο Docker και η βιβλιοθήκη Spring (version 2.0.1) ειδικότερα χρησιμοποιήθηκαν με σκοπό να ελαχιστοποιήσουμε τις απαιτούμενες ενέργειες αρχικοποίησης και εγκατάστασης της προγραμματιστικής υποδομής, να επιτραπεί η αυτόματη παραμετροποίηση του περιβάλλοντος της διαδικτυακής εφαρμογής και να κατασκευαστεί μια ανεξάρτητη εφαρμογή η οποία μπορεί εύκολα να εγκατασταθεί σε διαφορετικά μηχανήματα. Στην Εικόνα 6-9 παρουσιάζεται μια σύνοψη του πληροφοριακού συστήματος που υλοποιεί την προτεινόμενη μέθοδο.



Εικόνα 6-9 Διάγραμμα Τεχνικής Αρχιτεκτονικής Προτεινόμενης Μεθόδου

6.2.1 Βιβλιοθήκες

Στην παρούσα παράγραφο αναλύονται τα εργαλεία, οι βιβλιοθήκες και οι διεπαφές προγραμματισμού εφαρμογών (Application Programming Interface - API) που χρησιμοποιήθηκαν για την υλοποίηση του συστήματος που περιγράφεται στο παρόν κεφάλαιο.

Επίπεδο αλληλεπίδρασης Χρήστη

Το επίπεδο αλληλεπίδρασης χρήστη αναπτύχθηκε χρησιμοποιώντας τις τεχνολογίες διαδικτύου HTML, CSS και Javascript με τη βοήθεια της μηχανής προτύπων Thymeleaf (version 3.0.9). Το εικαστικό κομμάτι της διεπαφής που αναπτύχθηκε βασίστηκε στο πρότυπο ανοιχτού κώδικα Tabler το οποίο είναι διαθέσιμο στην σελίδα <https://github.com/tabler/tabler>. Για να μπορέσουμε να χρησιμοποιήσουμε το εικαστικό κομμάτι αυτού του προτύπου μέσα στη μηχανή προτύπων Thymeleaf, τροποποιήσαμε κατάλληλα το πρότυπο Tabler. Αυτό το πρότυπο εισαγάγει τις βιβλιοθήκες jQuery 3.2.1 και C3 της Javascript. Η C3 μια βιβλιοθήκη επαναχρησιμοποιήσιμων γραφημάτων που βασίζεται στη βιβλιοθήκη D3. Επιπλέον εμπεριέχει το πακέτο Bootstrap v4.0.0, το οποίο βασίζεται στην CSS και διευκολύνει την ανάπτυξη του εικαστικού μέρους της εφαρμογής.

Η πληροφορία που παρουσιάζεται στην διεπαφή χρήστη της διαδικτυακής εφαρμογής του πληροφοριακού συστήματος που αναπτύχθηκε οργανώνεται στις παρακάτω σελίδες:

- **Αρχική Σελίδα (Home):** Η αρχική σελίδα του συστήματος αντιστοιχεί σε έναν πίνακα ελέγχου (Dashboard) που περιέχει την επισκόπηση των πιο πρόσφατων δεδομένων. Για τα γραφήματα αυτής της οθόνης χρησιμοποιήθηκε η βιβλιοθήκη C3.
- **Αντικείμενα (Assets):** Σε αυτήν την οθόνη ο χρήστης μπορεί να ενημερωθεί, να εισάγει και να παραμετροποιήσει τα αντικείμενα που λαμβάνουν μέρος στην διαδικασία λήψης απόφασης και κατά συνέπεια στην διαδικασία της προδιαγραφικής αναλυτικής που υλοποιείται από το συγκεκριμένο σύστημα.
- **Παραμετροποίηση Προδιαγραφικών Μοντέλων (Prescriptive Model Configuration):** Σε αυτήν την οθόνη δίνεται στον χρήστη η δυνατότητα διαχείρισης των επιθυμητών και ανεπιθύμητων γεγονότων που στοχεύουμε να επηρεάσουμε την εκδήλωσή τους, των προδραστικών ενεργειών η υλοποίηση των οποίων επηρεάζει αυτήν την εκδήλωση καθώς και των κανόνων απόφασης, οι οποίοι ενσωματώνουν την αιτιολογική συσχέτιση των επιθυμητών και ανεπιθύμητων γεγονότων με τις διαθέσιμες προδραστικές ενέργειες.

- **Παρακολούθηση Πραγματικού Χρόνου (Monitoring):** Με αυτήν την οθόνη ο χρήστης μπορεί να παρακολουθεί τις παραγόμενες προδιαγραφές σε πραγματικό χρόνο, χωρίς να απαιτείται η συνεχής ανανέωση της σελίδας. Από αυτήν την οθόνη ο χρήστης ενημερώνεται για την άφιξη μιας νέας προδιαγραφής, η παραγωγή της οποίας ενεργοποιήθηκε αυτόματα με τη λήψη ενός νέου μηνύματος πρόβλεψης κάποιου γεγονότος. Το μήνυμα πρόβλεψης παράγεται από τις υπηρεσίες προβλεπτικής αναλυτικής δεδομένων οι οποίες διασυνδέονται με το παρόν πληροφοριακό σύστημα. Στη συνέχεια, η προδιαγραφή επικοινωνείται αυτόματα με την υπηρεσία προδιαγραφικής αναλυτικής που υλοποιεί η παρούσα εφαρμογή. Ο χρήστης μπορεί να εγκρίνει, να απορρίψει ή να σημειώσει ως «Υλοποιημένη» τη νέα προδιαγραφή. Η λειτουργικότητα συνεχούς ενημέρωσης υλοποιείται με την τεχνολογία websockets και τη βοήθεια του πακέτου υποστήριξης websocket της βιβλιοθήκης Spring (version 2.0.1) η οποία βασίζεται στο Streaming Text Oriented Messaging Protocol (STOMP). Από την πλευρά του περιηγητή, οι ενημερώσεις λαμβάνονται με τη χρήση της javascript βιβλιοθήκης SockJS (version 0.3.4). Στην ίδια οθόνη παρέχονται στο χρήστη οπτικές επεξηγήσεις αιτιολόγησης της επιλογής της παραγόμενης προδιαγραφής. Με τη βοήθεια των βιβλιοθηκών C3 και D3 της javascript, δίνεται στο χρήστη η γραφική αναπαράσταση της μαρκοβιανής διαδικασίας απόφασης του προδιαγραφικού μοντέλου.
- **Πλάνο Ενεργειών (Plan):** Στη σελίδα αυτή συγκεντρώνονται οι ενέργειες που ο χρήστης έχει εγκρίνει και προσθέσει στη λίστα των προς υλοποίηση ενεργειών.

Επίπεδο Λογικής

Ο Κατασκευαστής Βάσης Γνώσης και η Μηχανή Συμπερασμού της αρχιτεκτονικής έχουν αναπτυχθεί ως κλάσεις Java οι οποίες αξιοποιούν τη μηχανή κανόνων Drools (έκδοση 7.7.0). Η μηχανή Drools είναι ένα σύστημα διαχείρισης επιχειρηματικών κανόνων η οποία παρέχει μια μηχανή κανόνων, ένα διαδικτυακό εργαλείο συγγραφής κανόνων και μια εφαρμογή διαχείρισης κανόνων (Drools Workbench).

Παράλληλα, παρέχει πλήρη υποστήριξη εκτέλεσης των μοντέλων αποφάσεων και των σημειολογικών μοντέλων. Η μηχανή συμπερασμού της Drools βασίζεται σε μια βελτιωμένη έκδοση της υλοποίησης του αλγορίθμου Rete. Πιο συγκεκριμένα, η Drools υλοποιεί και επεκτείνει τον αλγόριθμο Rete με την έκδοση ReteOO του αλγορίθμου, η οποία είναι βελτιστοποιημένη για αντικειμενοστραφή συστήματα (Proctor et al., 2008). Αντίθετα από τις δύο εναλλακτικές μεθόδους εκτέλεσης κανόνων που συνήθως υλοποιούνται από ένα σύστημα κανόνων, την προς-τα-εμπρός αλυσίδωση (Forward Chaining) και την προς-τα-πίσω αλυσίδωση (Backward Chaining), η Drools υλοποιεί την υβριδική αλυσίδωση (Hybrid Chaining), η οποία αποτελεί συνδυασμό των δύο μεθόδων.

Στην παρούσα υλοποίηση οι κανόνες με τη μορφή που περιγράφεται στην παράγραφο 6.1.2, παρέχονται από τον χρήστη μέσω της web διεπαφής ή με χρήση της διεπαφής REST. Κατά τη φάση της εκτέλεσης, αναπτύσσονται δυναμικά από τη μηχανή Drools χρησιμοποιώντας ένα πρότυπο κανόνων (Drools template) το οποίο συμμορφώνεται με την προκαθορισμένη μορφή των προδραστικών κανόνων.

Για την συγγραφή των αρχείων προτύπων κανόνων, η Drools παρέχει μια «native» γλώσσα κανόνων, η οποία αποφεύγει τα σημεία στίξης και υποστηρίζει τη φυσική γλώσσα ή γλώσσες συγκεκριμένων γνωστικών πεδίων (Domain Specific Language - DSL) μέσω επεκτάσεων. Με αυτό τον τρόπο, τα πρότυπα κανόνων να ανταποκρίνονται στο γνωστικό πεδίο του προβλήματος. Στην παρούσα υλοποίηση, το πρότυπο των προδραστικών κανόνων που παρουσιάζεται στον Πίνακας 6-1, αναπτύχθηκε στο αρχείο **rule_template.drl** χρησιμοποιήσαμε την προσφερόμενη γλώσσα κανόνων σε συνδυασμό με κώδικα Java.

```
template header

rule_id
rule_events
rule_events_str

package imu.decide.rules;

import imu.decide.utils.kafka.PredictionWindow;
import java.util.ArrayList;
import java.util.List;

global java.util.List candidateRules;
global java.util.List remainingEvents;

template "proactive rules"

rule "proactive_rule_{rule_id}"
when
```

```

$pw: PredictionWindow( predictions.keySet() @rule_events))
then
candidateRules.add("@{rule_id}");

List<String> ruleEventsFound = new ArrayList<String>(){{@rule_events_str}};
for( String eventId : $pw.getPredictions().keySet() ){
    if (!ruleEventsFound.contains(eventId)) {
        if(!remainingEvents.contains(eventId)) {
            remainingEvents.add(eventId);
        }
    }
}

end

end template

```

Πίνακας 6-1 Πρότυπο προδραστικών κανόνων στη γλώσσα της Drools

Η υλοποίηση του υποσυστήματος επεξεργασίας ροών δεδομένων του επιπέδου λογικής βασίζεται στη χρήση του εργαλείου Apache Kafka.

Το εργαλείο αυτό είναι οριζόντια επεκτάσιμο, ανεκτικό σε λάθη, γρήγορο, και έχει ήδη χρησιμοποιηθεί σε παραγωγικά συστήματα αρκετών εταιριών. Η παρούσα υλοποίηση αναμένεται να ελαχιστοποιήσει το χρόνο επεξεργασίας και επικοινωνίας, οδηγώντας σε ένα σύστημα με υψηλότερη διαθεσιμότητα και συνέπεια κατά τη διασύνδεσή του με άλλα συστήματα. Η επικοινωνία της εφαρμογής με το Kafka υλοποιήθηκε με τη βοήθεια της βιβλιοθήκης Spring for Apache Kafka (spring-kafka, version 2.1.5).

Πιο συγκεκριμένα, το υποσύστημα επεξεργασίας ροών δεδομένων υλοποιείται με τη μορφή μιας τοπολογίας Kafka, χρησιμοποιώντας τις δύο διεπαφές Kafka Streams και Kafka Processor APIs (version 1.0.1).

Ως τοπολογία ορίζεται έναν άκυκλο γράφο αποτελούμενο από πηγές (sources), επεξεργαστές (processors) και τερματικούς κόμβους (sinks). Ως πηγή ορίζεται ένας κόμβος του γραφήματος ο οποίος καταναλώνει δεδομένα από ένα Kafka topic και τα προωθεί στους επόμενους κόμβους του γραφήματος. Ως επεξεργαστής ορίζεται ένας κόμβος του γραφήματος, ο οποίος λαμβάνει τις εγγραφές εισόδου από τους προηγούμενους κόμβους, επεξεργάζεται τα δεδομένα τους και προαιρετικά προωθεί τις νέες εγγραφές σε έναν ή περισσότερους επόμενους κόμβους της τοπολογίας. Ως τερματικός κόμβος ορίζεται ένας κόμβος του γραφήματος που λαμβάνει εγγραφές από τους προγενέστερους κόμβους και εγγράφει τα δεδομένα σε κάποιο Kafka topic. Η χρήση μιας τοπολογίας μας επιτρέπει να κατασκευάσουμε τον δικό μας άκυκλο

γράφο, αποτελούμενο από όποιον συνδυασμό τέτοιων κόμβων ικανοποιούν οι απαιτήσεις του συστήματός μας. Με τη βοήθεια της διεπαφής Kafka Streams API, υλοποιούμε την τοπολογία μέσα από μια οντότητα `KafkaStreams` η οποία αναλαμβάνει την κατανάλωση, την επεξεργασία και την παραγωγή εγγραφών σύμφωνα με την προκαθορισμένη τοπολογία.

Η τοπολογία που αναπτύχθηκε στην συγκεκριμένη υλοποίηση αποτελείται από μία πηγή δεδομένων, δύο επεξεργαστές ροών δεδομένων και έναν τερματικό κόμβο. Η πηγή της τοπολογίας αντιστοιχεί στο `topic` των εισερχόμενων προβλέψεων που παράγονται από τους αλγορίθμους προβλεπτικής αναλυτικής δεδομένων και εισέρχονται στην τοπολογία με τη μορφή ροής δεδομένων. Ο πρώτος επεξεργαστής ροών δεδομένων με όνομα `Rules Processor`, λαμβάνει τα μηνύματα προβλέψεων που καταφθάνουν στην πηγή και υλοποιεί τη λειτουργικότητα της μηχανής συμπερασμού που περιγράφεται στην παράγραφο 6.1.2.

Όταν μια νέα πρόβλεψη φθάνει στην ροή, προστίθεται στο παράθυρο εκκρεμών προβλέψεων, το οποίο εμπεριέχει τις προβλέψεις για τις οποίες εκκρεμεί η επεξεργασία τους. Σύμφωνα με τις προβλέψεις του παραθύρου, αξιολογούνται όλοι οι κανόνες που βρίσκονται στη μνήμη εργασίας της μηχανής συμπερασμού. Οι κανόνες που ενεργοποιούνται για αυτό το παράθυρο προβλέψεων, επιστρέφουν τα μοναδικά αναγνωριστικά `UUID` τους, τα οποία προστίθενται στη λίστα υποψήφιων κανόνων, ενώ όποιες προβλέψεις παραμένουν αναπάντητες, διατηρούνται στο παράθυρο προβλέψεων για επεξεργασία σε επόμενο χρόνο. Η λίστα των υποψήφιων κανόνων προωθείται στον δεύτερο επεξεργαστή ροών δεδομένων της τοπολογίας.

Ο δεύτερος επεξεργαστής ροών δεδομένων, ο επεξεργαστής βελτιστοποίησης, είναι υπεύθυνος για την υλοποίηση της μεθόδου που προτείνεται από την παρούσα διατριβή και αντιστοιχεί στα υποσυστήματα του κατασκευαστή περιβάλλοντος ενισχυτικής μάθησης (`RL Environment Builder`), εκπαιδευτή ενισχυτικής μάθησης (`RL Learner`), του διαμορφωτή πολιτικής (`Policy Shaper`) και του προδιαγραφικού πράκτορα (`Prescriptive Agent`). Ο επεξεργαστής αυτός λαμβάνει τη λίστα των υποψήφιων κανόνων και αρχικά ανακτά τα δεδομένα που συσχετίζονται με τους κανόνες αυτούς από τη βάση γνώσης και στη συνέχεια εκτελεί τον προδιαγραφικό μηχανισμό. Η υλοποίηση του περιβάλλοντος ενισχυτικής μάθησης και των

αντίστοιχων αλγορίθμων βασίστηκε στη βιβλιοθήκη Brown-UMBC Reinforcement Learning and Planning (BURLAP). Η βιβλιοθήκη BURLAP είναι μια βιβλιοθήκη Java που επιτρέπει τη χρήση και ανάπτυξη αλγορίθμων προγραμματισμού και μάθησης ενός ή πολλαπλών πρακτόρων. Η βιβλιοθήκη αυτή επιλέχθηκε για τέσσερις λόγους:

- (i) Διαθέτει έτοιμες υλοποιήσεις για διαφορετικούς αλγορίθμους, όπως αλγόριθμοι δράστη-κριτή, οι οποίοι ταιριάζουν στην προτεινόμενη μέθοδο
- (ii) Δίνει τη δυνατότητα δυναμικού καθορισμού και ανάπτυξης προσαρμοσμένων και πολύπλοκων περιβαλλόντων ενισχυτικής μάθησης, σε χρόνο εκτέλεσης
- (iii) Υλοποιείται με java και παρέχει την κατάλληλη διεπαφή κώδικα γεγονός που διευκολύνει την ενσωμάτωσή της στην εφαρμογή που αναπτύξαμε
- (iv) Παρέχεται με άδεια Apache 2.0 license.

Στον επεξεργαστή βελτιστοποίησης, τα δεδομένα των υποψήφιων κανόνων χρησιμοποιούνται για την δυναμική μοντελοποίηση του περιβάλλοντος ενισχυτικής μάθησης, με τη μορφή ενός OO-MDP domain της βιβλιοθήκης.

Πάνω σε αυτήν την οντότητα, διατίθενται υλοποιήσεις αλγορίθμων q-learning και policy gradient, οι οποίες αξιοποιούνται από την παρούσα εφαρμογή για την παραγωγή της βέλτιστης πολιτικής πολλαπλών κριτηρίων. Το τελευταίο βήμα το οποίο παράγει την διαμορφωμένη βάση ανάδρασης πολιτική υλοποιείται από απλούς πολλαπλασιασμούς πινάκων. Ο επεξεργαστής βελτιστοποίησης παράγει ένα αντικείμενο προδιαγραφής το οποίο περιέχει το σύνολο των ενεργειών που προτείνονται από τη βέλτιστη διαμορφωμένη πολιτική. Το αντικείμενο αυτό προωθείται προς τον τερματικό κόμβο της τοπολογίας, ο οποίος θα δημοσιεύει τα δεδομένα του στο κατάλληλο Kafka topic, έτσι ώστε οι προδιαγραφές να είναι άμεσα διαθέσιμες σε οποιαδήποτε εφαρμογή επιθυμεί να τις καταναλώσει.

Επίπεδο Αποθήκευσης Δεδομένων

Η διαχείριση των δεδομένων του επιπέδου αποθήκευσης δεδομένων υλοποιήθηκε με χρήση της βιβλιοθήκης Spring Data. Πιο συγκεκριμένα, χρησιμοποιήσαμε τη

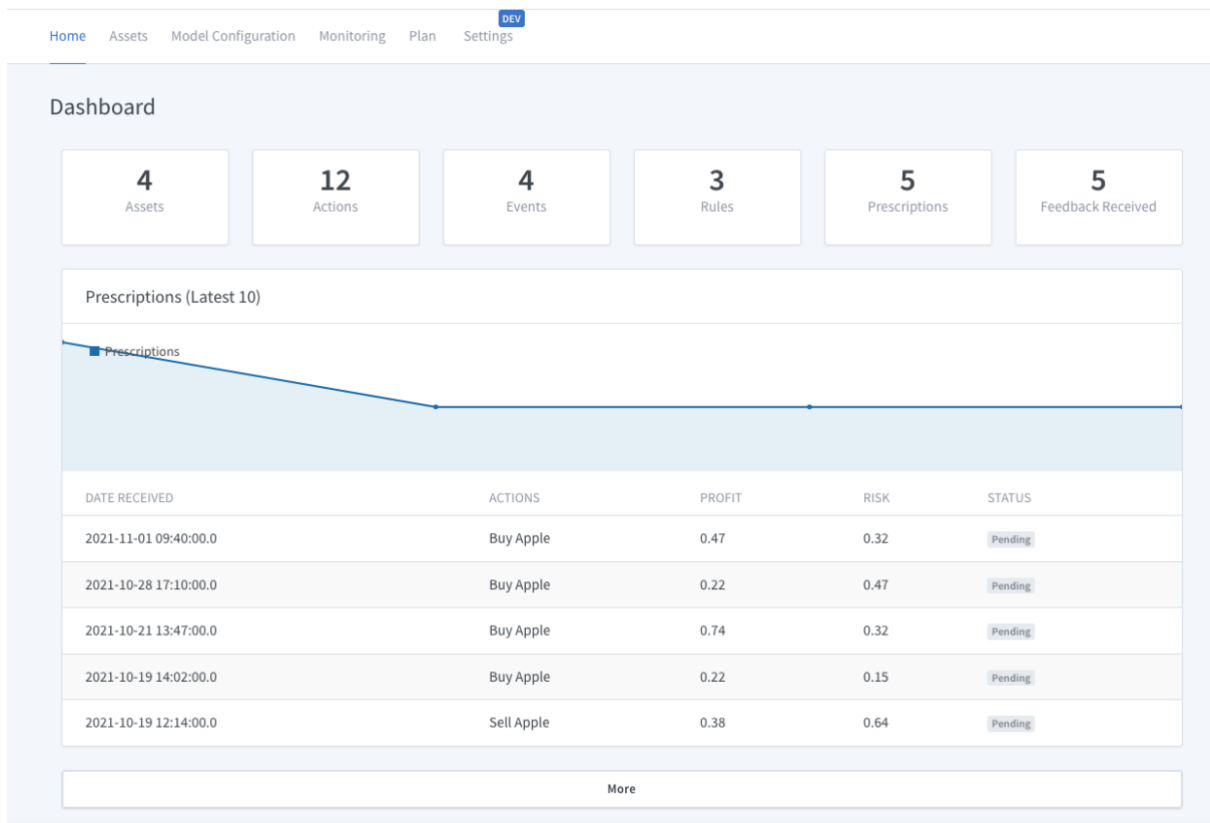
βιβλιοθήκη Spring Data JPA για την αποθήκευση και ανάκτηση των δεδομένων στη σχεσιακή MySQL βάση δεδομένων (βάση γνώσης) και τη βιβλιοθήκη Spring Data MongoDB για την αλληλεπίδραση με τις εγγραφοστρεφείς MongoDB βάσεις δεδομένων αυτού του επιπέδου.

6.3 Παράδειγμα Χρήσης

Στην παρούσα παράγραφο παρουσιάζουμε ένα σενάριο χρήσης του πληροφοριακού συστήματος που περιγράφεται στις προηγούμενες παραγράφους. Για την καλύτερη κατανόηση του αναγνώστη χρησιμοποιούμε ως πεδίο εφαρμογής τη λήψη αποφάσεων σε χρηματιστηριακές επενδύσεις.

Σκοπός της συγκεκριμένης εφαρμογής είναι η πρόταση των κατάλληλων προδραστικών ενεργειών πάνω σε χρηματιστηριακές μετοχές που συμμετέχουν στο χαρτοφυλάκιο του χρήστη, οι οποίες θα αποφέρουν το μέγιστο δυνατό κέρδος με το ελάχιστο δυνατό ρίσκο επένδυσης, πριν από ένα μελλοντικό γεγονός. Οι προτάσεις αυτές παράγονται αξιοποιώντας τις προβλέψεις τιμών των επενδύσεων, οι οποίες εξάγονται από αλγόριθμους προβλεπτικής αναλυτικής δεδομένων. Για να είναι εφικτή η εφαρμογή της προτεινόμενης μεθόδου με την παρούσα υλοποίηση σε κάποιο πρόβλημα, θα πρέπει να οριστούν σαφώς το είδος, η πληροφορία και η μορφή των προβλέψεων, οι οποίες θα επικοινωνούνται σε κάποιο topic του Kafka, και μέσω αυτού θα εισέρχονται στο σύστημα επεξεργασίας ροών δεδομένων της παρούσας υλοποίησης.

Η αρχική σελίδα της διαδικτυακής εφαρμογής φαίνεται στην Εικόνα 6-10.



Εικόνα 6-10 Αρχική οθόνη συστήματος

Κατά το χρόνο σχεδίασης, ο χρήστης παραμετροποιεί την προτεινόμενη μέθοδο μέσα από τις σελίδες Assets, Model Configuration και Settings.

Το πρώτο βήμα σε αυτήν τη φάση είναι η παραμετροποίηση της ίδιας της μεθόδου, η οποία γίνεται από τη σελίδα Settings, που παρουσιάζεται στην Εικόνα 6-11. Σε αυτήν την οθόνη δίνεται η δυνατότητα επιλογής των κριτηρίων βελτιστοποίησης όπου στο συγκεκριμένο σενάριο επιλέχθηκε η μεγιστοποίηση κέρδους από μια ενέργεια πάνω σε ένα πακέτο μετοχών που είναι διαθέσιμο στο χαρτοφυλάκιο και η ελαχιστοποίηση του αντίστοιχου ρίσκου.

Home Assets Model Configuration Monitoring Plan Settings ^{DEV}

Settings

Select Optimization Config

Config Key

Config Value

[Reset](#) [Submit](#)

Configs

KEY	VALUE		
riskStrategy	risk-seeker	Edit	Delete
fileName	/Users/katerina/Desktop/results/prescriptions_aapl_risk-seeker_expert_10_100_1.txt	Edit	Delete
decision_method	RL	Edit	Delete
consistency	0.9	Edit	Delete

Select objectives

Objective Name

Goal Type

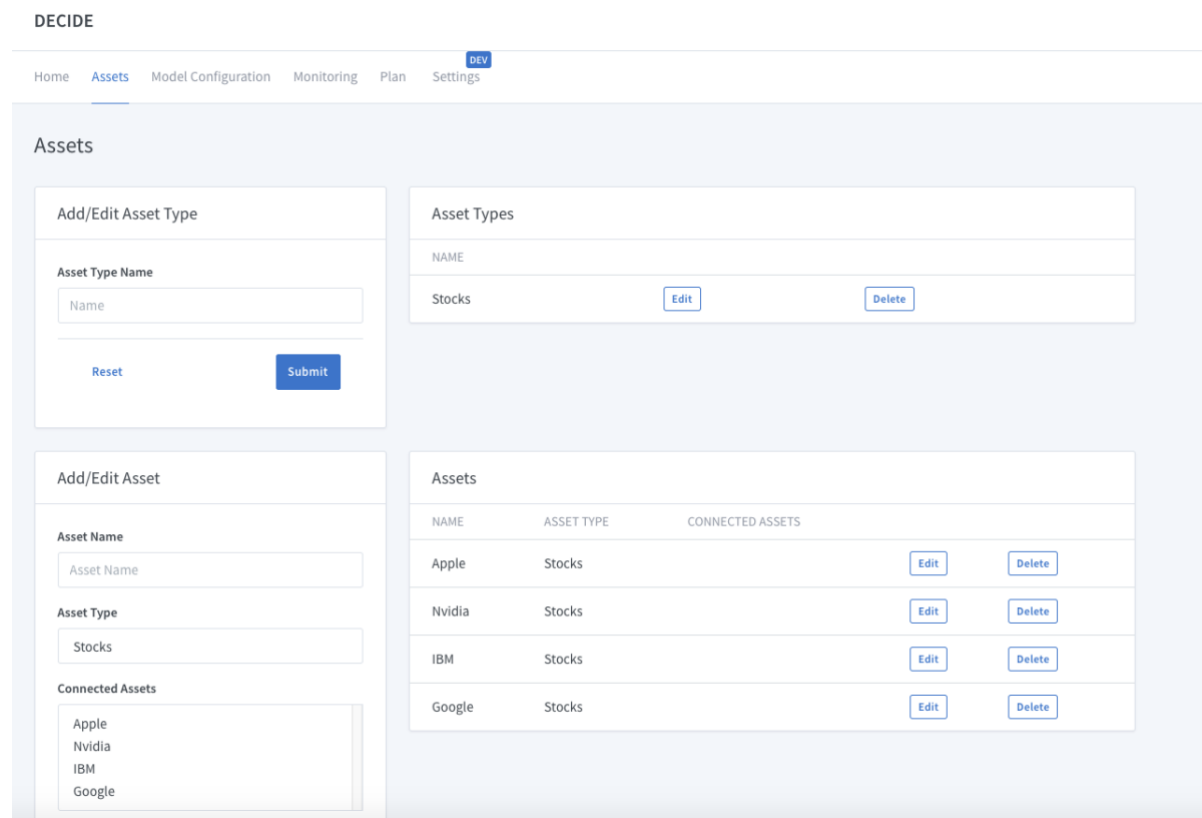
[Reset](#) [Submit](#)

Objectives

KEY	VALUE		
profit	MAX	Edit	Delete
risk	MIN	Edit	Delete

Εικόνα 6-11 Οθόνη παραμετροποίησης βασικών παραμέτρων μεθόδου

Αφού επιλέξει τις βασικές παραμέτρους της μεθόδου, ο χρήστης μπορεί να συνεχίσει με τον ορισμό των αντικειμένων. Στη σελίδα Assets ο χρήστης μπορεί να ορίσει τους τύπους αντικειμένων και τα διαφορετικά αντικείμενα που θα συμμετέχουν στη διαδικασία λήψης απόφασης, όπως φαίνεται στην Εικόνα 6-12.



Εικόνα 6-12 Οθόνη διαχείρισης αντικειμένων διαδικασίας λήψης απόφασης

Για το πρόβλημα των χρηματιστηριακών επενδύσεων που παρουσιάζεται στο συγκεκριμένο σενάριο χρήσης, θεωρήσαμε έναν τύπο αντικειμένων, τις μετοχές, και τέσσερα αντικείμενα αυτού του τύπου, τη μετοχή της Apple, τη μετοχή της Nvidia, τη μετοχή της IBM και τη μετοχή της Google. Η δυνατότητα παραμετροποίησης των αντικειμένων που συμμετέχουν παρέχεται μέσα από τη σελίδα Assets της διαδικτυακής εφαρμογής αλλά και μέσα από την διεπαφή προγραμματισμού εφαρμογών REST API που έχει υλοποιηθεί.

Αφού ο χρήστης ορίσει τα αντικείμενα της εφαρμογής, προχωράει στον ορισμό των επιθυμητών και ανεπιθύμητων γεγονότων, των υποψήφιων προδραστικών ενεργειών και των κανόνων απόφασης, μέσω της σελίδας Model Configuration, όπως φαίνεται στις παρακάτω εικόνες. Ξεκινώντας από τις υποψήφιες προδραστικές ενέργειες, που παρουσιάζονται στην Εικόνα 6-13, ο χρήστης ορίζει τις εναλλακτικές προδραστικές ενέργειες για καθένα από τα αντικείμενα που τον ενδιαφέρουν, στη συγκεκριμένη περίπτωση για καθεμιά από τις προκαθορισμένες μετοχές. Για κάθε υποψήφια ενέργεια η προτεινόμενη μέθοδος απαιτεί τις τιμές των κριτηρίων

βελτιστοποίησης που έχουμε ορίσει κατά την παραμετροποίηση της μεθόδου. Στο σενάριο αυτής της παραγράφου, ορίσαμε τρεις εναλλακτικές ενέργειες για καθεμιά από τις τέσσερις μετοχές: την ενέργεια αγοράς νέων μεριδίων της μετοχής (Buy), την ενέργεια πώλησης μεριδίων της μετοχής που βρίσκονται ήδη στο χαρτοφυλάκιο του χρήστη (Sell) και την ενέργεια διατήρησης των μεριδίων της μετοχής που βρίσκονται ήδη στην ιδιοκτησία του χρήστη (Hold). Οι τιμές των κριτηρίων κέρδους και ρίσκου κάθε μιας από αυτές τις ενέργειες, βασίζεται στην πρόβλεψη της τιμής της μετοχής και μεταβάλλεται με κάθε νέα πρόβλεψη.

DECIDE

Home Assets Model Configuration Monitoring Plan Settings DEV

Model Configuration

Add/Edit Actions

Action Name

Asset

profit

risk

[Reset](#) [Submit](#)

Actions

NAME	ASSET	FEEDBACK RECEIVED	PROFIT	RISK		
Buy Apple	Apple	8✓ 8✗ 3○	0.16	0.43	Edit	Delete
Sell Apple	Apple	2✓ 3✗ 2○	0.19	0.47	Edit	Delete
Hold Apple	Apple	2✓ 7✗ 3○	0.0	0.0	Edit	Delete
Buy Nvidia	Nvidia	3✓ 1✗ 2○	0.34	0.22	Edit	Delete
Sell Nvidia	Nvidia	0✓ 3✗ 7○	0.27	0.16	Edit	Delete
Hold Nvidia	Nvidia	2✓ 0✗ 0○	0.63	0.41	Edit	Delete
Buy IBM	IBM	1✓ 8✗ 4○	0.0	0.0	Edit	Delete
Sell IBM	IBM	1✓ 8✗ 4○	0.43	0.58	Edit	Delete
Hold IBM	IBM	1✓ 4✗ 4○	0.93	0.87	Edit	Delete
Buy Google	Google	5✓ 1✗ 7○	0.18	0.22	Edit	Delete
Sell Google	Google	4✓ 5✗ 5○	0.98	0.32	Edit	Delete
Hold Google	Google	3✓ 1✗ 4○	100.0	0.56	Edit	Delete

Εικόνα 6-13 Οθόνη διαχείρισης υποψήφιας προδραστικών ενεργειών

Στην ίδια σελίδα, ο χρήστης εισάγει και διαχειρίζεται τους τύπους των επιθυμητών και ανεπιθύμητων γεγονότων όπως φαίνεται στην Εικόνα 6-14.

The screenshot shows a web application interface for managing future events and event types. It is divided into four main sections:

- Add/Edit Event Type:** A form with fields for 'Name' (containing 'Name') and 'Asset Type' (containing 'Stocks'). It includes 'Reset' and 'Submit' buttons.
- Event Types:** A table with columns 'NAME' and 'ASSET TYPE'. It contains one row: 'Miss Opportunity' with 'Stocks' as the asset type. There are 'Edit' and 'Delete' buttons for this row.
- Add/Edit Event:** A form with fields for 'Name' (containing 'Failure Name'), 'Event Type' (containing 'Miss Opportunity'), 'Asset' (containing 'Apple'), and 'profit' (containing '0.0').
- Events:** A table with columns 'NAME', 'EVENT TYPE', 'ASSET', 'PROFIT', and 'RISK'. It contains four rows of event data, each with 'Edit' and 'Delete' buttons:

NAME	EVENT TYPE	ASSET	PROFIT	RISK
Miss Opportunity Apple	Miss Opportunity	Apple	-100.0	100.0
Miss Opportunity Nvidia	Miss Opportunity	Nvidia	-100.0	100.0
Miss Opportunity IBM	Miss Opportunity	IBM	-100.0	100.0
Miss Opportunity Google	Miss Opportunity	Google	-100.0	100.0

Εικόνα 6-14 Οθόνη διαχείρισης μελλοντικών γεγονότων και τύπων γεγονότων

Για το σενάριο που παρουσιάζουμε ορίστηκε ένας τύπος ανεπιθύμητου γεγονότος «Miss Opportunity», ο οποίος αντιστοιχεί με την περίπτωση του να εμφανιστεί μια ευκαιρία επένδυσης η οποία είναι διακριτή μέσα από την πρόβλεψη της μελλοντικής τιμής της μετοχής και να μην μπορέσει ο χρήστης να εκμεταλλευτεί αυτήν την ευκαιρία. Αντιστοίχως ορίζουμε τέσσερα ανεπιθύμητα γεγονότα αυτού του τύπου, ένα για κάθε μετοχή, τα οποία θα αξιοποιήσουμε για την κατασκευή των κανόνων απόφασης του συστήματος. Η διαχείριση των κανόνων απόφασης γίνεται στη συνέχεια της ίδιας σελίδα (Model Configuration), όπως φαίνεται στην Εικόνα 6-15.

The screenshot shows a web interface for managing decision rules. At the top left, there are input fields for 'profit' and 'risk', both set to '0.0', with 'Reset' and 'Submit' buttons below them. Below this is the 'Add/Edit Rule' form, which includes a 'Rule Name' field, a list of 'Events' (Miss Opportunity Apple, Nvidia, IBM, Google), and a list of 'Actions' (Buy Apple, Sell Apple, Hold Apple, Buy Nvidia). To the right is a 'Rules' table with three rows, each representing a rule with its name, events, actions, and edit/delete buttons.

NAME	EVENTS	ACTIONS		
RULE 1	Miss Opportunity Apple	Buy Apple	Edit	Delete
RULE 2	Miss Opportunity Apple	Sell Apple	Edit	Delete
RULE 3	Miss Opportunity Apple	Hold Apple	Edit	Delete

Εικόνα 6-15 Οθόνη διαχείρισης κανόνων απόφασης

Στο σενάριο των χρηματιστηριακών επενδύσεων επιλέξαμε να εισάγουμε τρεις εναλλακτικούς κανόνες απόφασης, έναν για κάθε υποψήφια προδραστική ενέργεια, καθώς με την πρόβλεψη ενός γεγονότος που αναπαριστά μια μελλοντική ευκαιρία επένδυσης, ο χρήστης μπορεί να επιλέξει να αγοράσει μερίδια της μετοχής, να πουλήσει όσα μερίδια κατέχει ή να διατηρήσει τη θέση του.

Κατά το χρόνο εκτέλεσης της συνολικής υλοποίησης, οι αλγόριθμοι προβλεπτικής αναλυτικής δεδομένων επεξεργάζονται τα διαθέσιμα σε αυτούς δεδομένα τιμών των επιλεγμένων μετοχών και παράγουν προβλέψεις σχετικά με τη μελλοντική τιμή κάθε μετοχής. Με κάθε νέα πρόβλεψη, το υποσύστημα επεξεργασίας ροών δεδομένων που περιγράφεται στην προηγούμενη παράγραφο ενεργοποιείται και, εφόσον υπάρχουν οι αντίστοιχοι κανόνες απόφασης, παράγεται μια νέα προδιαγραφή. Ο χρήστης ενημερώνεται για τις νέες και τις υπάρχουσες προδιαγραφές μέσα από τη σελίδα Monitoring της διαδικτυακής εφαρμογής, που παρουσιάζεται στην Εικόνα 6-16, ενώ παρέχεται η δυνατότητα ενημέρωσης των νέων προδιαγραφών μέσω του REST API αλλά και της κατανάλωσης του κατάλληλου Kafka topic.

Monitoring

Prescriptions							
DATE RECEIVED	ACTIONS	PROFIT	RISK	STATUS	ACTIONS		
2021-11-01 09:40:00.0	Buy Apple	0.47	0.32	Pending	Actions ▾	Visualization	Show Details ↗
2021-10-28 17:10:00.0	Buy Apple	0.22	0.47	Pending	Actions ▾	Visualization	Show Details ↗
2021-10-21 13:47:00.0	Buy Apple	0.74	0.32	Pending	Actions ▾	Visualization	Show Details ↗
2021-10-19 14:02:00.0	Buy Apple	0.22	0.15	Pending	Actions ▾	Visualization	Show Details ↗
2021-10-19 12:14:00.0	Sell Apple	0.38	0.64	Pending	Actions ▾	Visualization	Show Details ↗

Prev 1 2 Next

Εικόνα 6-16 Παρακολούθηση προδιαγραφών

Για κάθε νέα προδιαγραφή ο χρήστης βλέπει τις προτεινόμενες ενέργειες, την κατάσταση της προδιαγραφής και τις τιμές των κριτηρίων βελτιστοποίησης που αποφέρουν οι προτεινόμενες ενέργειες. Στην ίδια σελίδα, για κάθε προδιαγραφή μπορεί να δώσει ανατροφοδότηση, εγκρίνοντας (approve) ή απορρίπτοντας (reject) την προδιαγραφή, από το μενού Ενεργειών της εγγραφής, τροποποιώντας έτσι την κατάσταση της προδιαγραφής, όπως παρουσιάζεται στην Εικόνα 6-17.

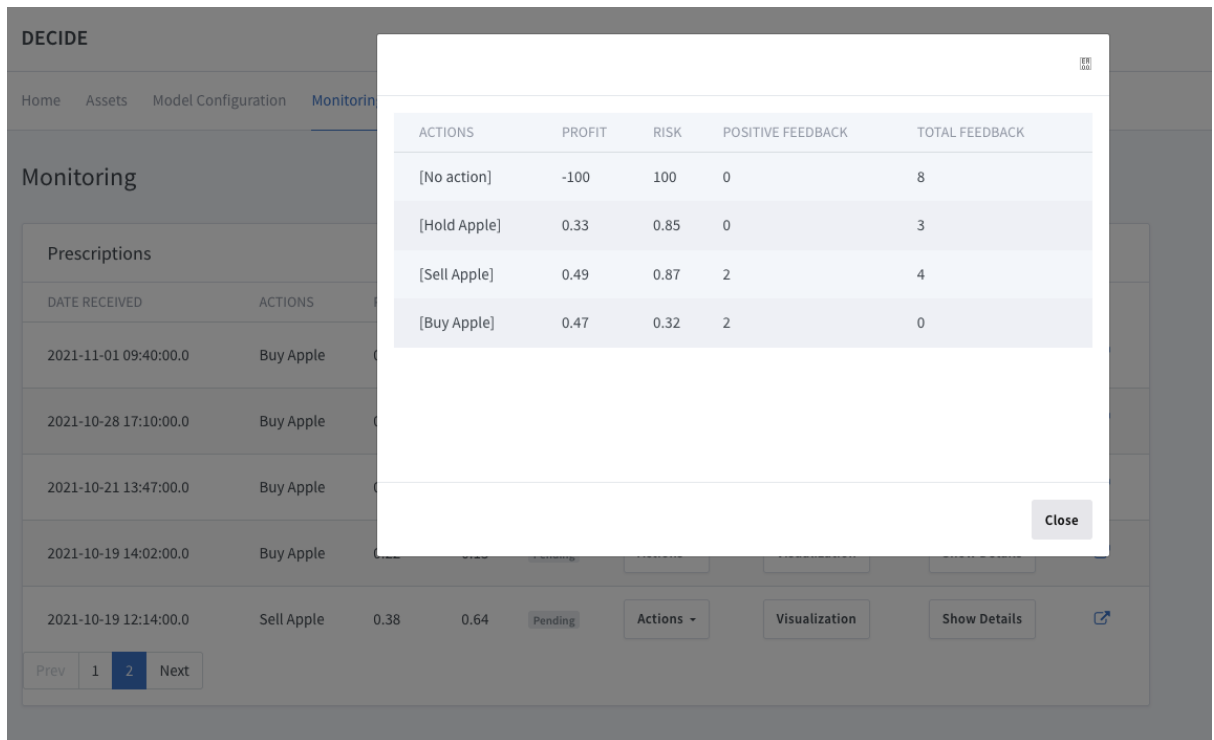
Monitoring

Prescriptions							
DATE RECEIVED	ACTIONS	PROFIT	RISK	STATUS	ACTIONS		
2021-11-01 09:40:00.0	Buy Apple	0.47	0.32	Approved	Actions -	Visualization	Show Details ↗
2021-10-28 17:10:00.0	Buy Apple	0.22	0.47	Rejected	Actions -	Visualization	Show Details ↗
2021-10-21 13:47:00.0	Buy Apple	0.74	0.32	Approved	Actions -	Visualization	Show Details ↗
2021-10-19 14:02:00.0	Buy Apple	0.22	0.15	Pending	Actions -	Visualization	Show Details ↗
2021-10-19 12:14:00.0	Sell Apple	0.38	0.64	Pending	Actions -	Visualization	Show Details ↗

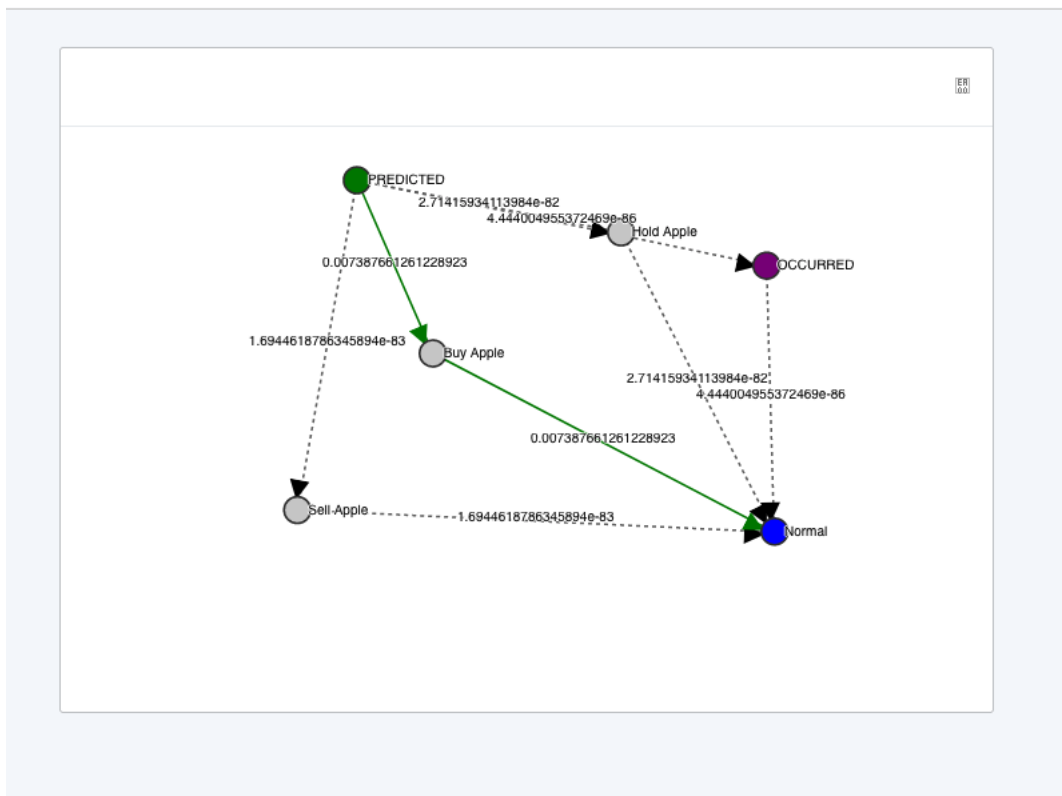
Prev 1 2 Next

Εικόνα 6-17 Αλλαγή κατάστασης προδιαγραφής

Ακολούθως, από το μενού Show Details μπορεί να ενημερωθεί για τις αναλυτικές τιμές του μοντέλου, όπως παρουσιάζονται στην Εικόνα 6-18, ενώ από το μενού Visualization μπορεί να δει τη γραφική απεικόνιση του προδιαγραφικού μοντέλου, όπως φαίνεται στην Εικόνα 6-19.



Εικόνα 6-18 Προβολή αναλυτικών τιμών προδιαγραφικού μοντέλου



Εικόνα 6-19 Γραφική απεικόνιση προδιαγραφικού μοντέλου

Όταν μια προδιαγραφή εγκριθεί από τον χρήστη, εισάγεται στο Πρόγραμμα Ενεργειών του συστήματος με τις προς υλοποίηση και τις υλοποιημένες

προδιαγραφές, το οποίο είναι διαθέσιμο στο χρήστη μέσω της σελίδας Plan, που παρουσιάζεται στην Εικόνα 6-20. Για κάθε προδιαγραφή του προγράμματος ενεργειών, ο χρήστης μπορεί να υποδείξει στο σύστημα την ολοκλήρωση των προτεινόμενων ενεργειών, σημειώνοντας την προδιαγραφή ως «Ολοκληρωμένη», όπως παρουσιάζεται στην Εικόνα 6-21

DECIDE

Home Assets Model Configuration Monitoring **Plan** Settings DEV

Plan

Approved Prescriptions					
DATE RECEIVED	ACTIONS	PROFIT	RISK	STATUS	ACTIONS
2021-11-01 09:40:00.0	Buy Apple	0.47	0.32	Approved	Actions ▾
2021-10-21 13:47:00.0	Buy Apple	0.74	0.32	Approved	Actions ▾

Prev 1 2 Next

Εικόνα 6-20 Πρόγραμμα Ενεργειών

DECIDE

Home Assets Model Configuration Monitoring **Plan** Settings DEV

Plan

Approved Prescriptions					
DATE RECEIVED	ACTIONS	PROFIT	RISK	STATUS	ACTIONS
2021-11-01 09:40:00.0	Buy Apple	0.47	0.32	Completed	Actions ▾
2021-10-21 13:47:00.0	Buy Apple	0.74	0.32	Approved	Actions ▾

Prev 1 2 Next

Εικόνα 6-21 Υλοποίηση προτεινόμενων ενεργειών

7 Περίπτωση Εφαρμογής – Χρηματιστηριακές Επενδύσεις

7.1 Εισαγωγή

Σε αυτό το κεφάλαιο παρουσιάζεται η εφαρμογή της προτεινόμενης μεθόδου στον χρηματιστηριακό τομέα. Ένα από τα βασικά ερευνητικά θέματα του τομέα αυτού είναι η διαχείριση και βελτιστοποίηση χαρτοφυλακίου. Η λήψη των κατάλληλων αποφάσεων μπορεί να επιφέρει μακροπρόθεσμα κέρδη και καλύτερη ανοχή στο πιθανό ρίσκο για έναν πελάτη, μια εταιρία ή έναν επενδυτικό οργανισμό. Μεταξύ άλλων, η διαχείριση χαρτοφυλακίου ασχολείται με τις χρηματιστηριακές επενδύσεις, όπου απαιτούνται έγκαιρες αποφάσεις, οδηγούμενες από δεδομένα μεγάλης κλίμακας και ταχύτητας. Για το λόγο αυτό, οι επενδύσεις αποτελούν μια ιδανική περίπτωση μελέτης για την ανάθεση της διαδικασίας λήψης απόφασης σε συστήματα τεχνητής νοημοσύνης. Επιπλέον, κάτι τέτοιο τεκμηριώνεται από το γεγονός ότι περισσότερες από τις μισές επενδυτικές συναλλαγές εκτελούνται από συστήματα τεχνητής νοημοσύνης (O'Leary, 2013).

Το πρόβλημα διαχείρισης χαρτοφυλακίου αποτελεί εξ' ορισμού ένα πρόβλημα βελτιστοποίησης πολλαπλών κριτηρίων. Στις περισσότερες περιπτώσεις, οι στόχοι βελτιστοποίησης αναπαρίστανται με κάποια μορφή μεγιστοποίησης της απόδοσης των επιλεγμένων επενδύσεων σε συνδυασμό με την ελαχιστοποίηση του ρίσκου που αυτές έχουν. Μια τέτοια μοντελοποίηση συνήθως αποκλείει άλλα πιθανά κριτήρια βελτιστοποίησης τα οποία μπορεί ο εκάστοτε διαχειριστής επιθυμεί να συμπεριλάβει στη διαδικασία λήψης απόφασης και πιθανώς αντιπροσωπεύουν τα δικά του συμφέροντα, τη γνώση του ή τις προτιμήσεις του. Για παράδειγμα ένας αναλυτής μπορεί να θεωρήσει τα κόστη συναλλαγών ως ένα κριτήριο απόφασης, το οποίο συσχετίζεται με την συνολική απόδοση και κατ' επέκταση να επιλέξει την ενσωμάτωσή του στην συνάρτηση βελτιστοποίησης της απόδοσης. Από την άλλη πλευρά όμως, κάποια κριτήρια που επηρεάζουν την απόφαση, όπως η ελαχιστοποίηση του αριθμού των συναλλαγών ή η ελαχιστοποίηση του αριθμού των επιλεγμένων επενδυτικών αγαθών διαφαίνονται ανεξάρτητα από το κριτήριο της απόδοσης και ενδέχεται να αποτελούν υποκειμενικά κριτήρια για κάποιον μόνο επενδυτή. Για τους λόγους αυτούς η προτεινόμενη προσέγγιση δίνει τη δυνατότητα

μοντελοποίησης και καθοδήγησης της προδιαγραφικής μεθόδου σύμφωνα με την προτίμηση του αναλυτή που την υλοποιεί.

Στη βιβλιογραφία παρουσιάζονται πολλές εργασίες που αφορούν την αξιοποίηση τεχνικών και αλγορίθμων μηχανικής μάθησης για την ανάλυση και την πρόβλεψη των τιμών των μετοχών (Bustos, και Romares-Quimbaya, 2020). Σε αυτές προτείνονται αλγόριθμοι διαφόρων κλάδων, όπως αλγόριθμοι στατιστικής ανάλυσης και αλγόριθμοι πρόβλεψης χρονοσειρών (Shah et al., 2019). Η πρόβλεψη της μελλοντικής τιμής μιας μετοχής είναι ένα δημοφιλές ερευνητικό αντικείμενο, λόγω της πολυπλοκότητας και της διαφορετικότητας της πληροφορίας που είναι διαθέσιμη και δύναται να οδηγήσει σε βέλτιστες προβλέψεις (Nelson et al., 2017). Οι προβλέψεις αυτές αποτελούν ένα ουσιώδες εργαλείο για τους επενδυτές, καθώς μπορούν να συμβάλλουν στην λήψη έγκαιρων, κατάλληλων και μικρότερου ρίσκου αποφάσεων με τις οποίες θα επιτευχθούν μεγαλύτερα κέρδη (Gandhmal, και Kumar, 2019). Βασικό ρόλο σε αυτό παίζει η δυναμική, μη γραμμική και μεγάλης πολυπλοκότητας φύση των προβλέψεων (Nabirour et al., 2020). Αυτά τα χαρακτηριστικά, δυσκολεύουν την οδηγούμενη από τις προβλέψεις λήψη αποφάσεων, εξαιτίας της αβεβαιότητας, των χρονικών περιορισμών και των διαφορετικών στρατηγικών που επιλέγουν να ακολουθήσουν οι συμμετέχοντες σε αυτήν.

Σε αντίθεση με την προβλεπτική αναλυτική δεδομένων του χρηματιστηριακού τομέα, σύμφωνα με την βιβλιογραφία, η εφαρμογή τεχνικών μηχανικής μάθησης στη λήψη αποφάσεων φαίνεται ένα αρκετά πρώιμο ερευνητικό πρόβλημα. Από τις προτεινόμενες μεθόδους, η ενισχυτική μάθηση φαίνεται κατάλληλη για την ενσωμάτωση των προβλέψεων των τιμών των μετοχών στη διαδικασία λήψης απόφασης της κατασκευής ενός χαρτοφυλακίου (Almahdi, και Yang, 2017; Fischer, 2018; Sato, 2019; García-Galicia et al., 2019). Οι δυνατότητες της ενισχυτικής μάθησης στον τομέα των χρηματιστηριακών επενδύσεων δεν έχουν πλήρως αποτυπωθεί από την υπάρχουσα βιβλιογραφία (Meng, και Khushi, 2019). Η πλειονότητα της βιβλιογραφίας εστιάζει κυρίως σε αυτόνομες μεθόδους και συστήματα, τα οποία βασίζονται αποκλειστικά στα διαθέσιμα δεδομένα, χωρίς να λαμβάνουν υπόψιν την εμπειρία, την γνώση ή την προτίμηση του αποφασίζοντα (Cabrera et al., 2019).

Συνοψίζοντας, παρατηρούμε ότι στη βιβλιογραφία παρουσιάζονται πολλές μελέτες προβλεπτικής αναλυτικής χρηματιστηριακών δεδομένων, η οποία εξ' ορισμού βασίζεται αποκλειστικά στα διαθέσιμα δεδομένα. Στον αντίποδα βλέπουμε πολύ λιγότερες εργασίες που αφορούν τη λήψη αποφάσεων στις χρηματιστηριακές επενδύσεις και κινούνται σε δύο παράλληλες κατευθύνσεις. Στη μία κατεύθυνση εντάσσονται τα υπάρχοντα, και εν μέρει παραδοσιακά πλέον, συστήματα εμπειρογνομosύνης, τα οποία βασίζονται αποκλειστικά στην εξειδικευμένη γνώση του τομέα ή των συμμετεχόντων για να υποστηρίξουν τη διαδικασία απόφασης. Στην δεύτερη κατεύθυνση εντάσσονται οι προτεινόμενες προσεγγίσεις μηχανικής μάθησης, και πιο συγκεκριμένα οι προσεγγίσεις εφαρμογής αλγορίθμων ενισχυτικής μάθησης στον τομέα των χρηματιστηριακών επενδύσεων, οι οποίες βασίζονται αποκλειστικά στα διαθέσιμα δεδομένα και αγνοούν τη διαθέσιμη γνώση της πρώτης κατεύθυνσης.

Μιας και η ανάδραση του ανθρώπου αποτελεί ένα αναπόσπαστο κομμάτι της διαδικασίας διαχείρισης χαρτοφυλακίου (Xidonas et al., 2012), η εφαρμογή της προτεινόμενης μεθόδου μπορεί να χαλαρώσει τις απαιτήσεις προκαθορισμού των κριτηρίων απόφασης και να επιτρέψει στον διαχειριστή χαρτοφυλακίου να μοντελοποιήσει το πρόβλημα διαχείρισης σύμφωνα με τις προτιμήσεις του. Κατά συνέπεια, η προτεινόμενη μέθοδος συνδυάζει χρήσιμη πληροφορία από δύο διαφορετικές πηγές, τον εμπειρογνώμονα και τα διαθέσιμα δεδομένα. Με τον τρόπο αυτό, παράγει προδραστικές επενδυτικές αποφάσεις που μπορούν να οδηγήσουν στη μεγιστοποίηση της απόδοσης και την ελαχιστοποίηση του ρίσκου, στο ποσοστό που αυτές είναι δυνατές από την αξιοποίηση της συνδυαστικής αυτής γνώσης.

7.2 Ανασκόπηση Βιβλιογραφίας

Στις εργασίες των Xidonas et al. (2012) και Sarmas et al. (2020) γίνεται ανασκόπηση της βιβλιογραφίας των πολυκριτηριακών μεθόδων λήψης απόφασης πάνω στο πρόβλημα διαχείρισης χαρτοφυλακίου. Οι συγγραφείς εντοπίζουν και κατηγοριοποιούν τις εξέχουσες στη βιβλιογραφία μεθόδους λήψης απόφασης. Οι κατηγορίες των μεθόδων που αναγνωρίζονται για το πρόβλημα διαχείρισης

χαρτοφυλακίου είναι ο πολυκριτηριακός μαθηματικός προγραμματισμός (Multiobjective mathematical programming - MMP), ο προγραμματισμός στόχων (Goal Programming), οι σχέσεις υπεροχής (Outranking relations), οι μέθοδοι χρηστικότητα (Utility functions-based approaches), η αναλυτική-συνθετική προσέγγιση (Disaggregation analysis) και οι εξελικτικοί αλγόριθμοι (Evolutionary algorithms).

Στον τομέα των χρηματιστηριακών επενδύσεων και γενικότερα των οικονομικών αγορών παράγονται δεδομένα πολύ μεγάλου όγκου με πολύ μεγάλη ταχύτητα, καθώς κάθε δευτερόλεπτο ανταλλάσσονται μετοχές και χρηματιστηριακά αγαθά σε πολλαπλές αγορές. Τα δυναμικά αυτά δεδομένα μεγάλης κλίμακας είναι χρήσιμα για εταιρίες που επιχειρούν στον χρηματιστηριακό τομέα. Μπορούν να τις βοηθήσουν να εντοπίσουν επενδυτικές ευκαιρίες ή απειλές πρόωρα έτσι ώστε να μπορέσουν να αντιδράσουν έγκαιρα σε αυτές (Mohamed, και Al-Jaroodi, 2014).

Το ρόλο αυτό αναλαμβάνουν να καλύψουν πολλά αυτοματοποιημένα συστήματα επενδύσεων, τα οποία καλούνται να διαχειριστούν και να αναλύσουν έγκαιρα τον τεράστιο όγκο δεδομένων που διαρκώς μεταβάλλεται. Όμως, οι οικονομικές αγορές δεν είναι ντετερμινιστικές και τα διαθέσιμα δεδομένα στα οποία θα βασιστεί ένα τέτοιο σύστημα παρουσιάζουν θόρυβο και έλλειψη στατικότητας (Cararuzo et al., 2018). Η προδιαγραφική αναλυτική και η προτεινόμενη μέθοδος μπορούν να αποτελέσουν τη λύση. Ένα σύστημα βασισμένο σε αυτές μπορεί να ανταπεξέλθει στην ταχύτητα των δεδομένων, σε αντίθεση με την παραδοσιακή ανάλυση που απαιτεί προσπάθεια από εξειδικευμένους ανθρώπους και χρόνο κατά περίπτωση. Επιπλέον σε αντιδιαστολή με συστήματα παραδοσιακών μεθόδων, μπορεί να διαχειριστεί και να αυτοματοποιήσει τη δυναμικότητα του συγκεκριμένου προβλήματος. Μέσω αυτής της προσέγγισης μπορούν να εκτελεστούν πολλαπλές συναλλαγές πάνω σε διαφορετικά επενδυτικά αγαθά. Σε αντίθεση με τον άνθρωπο που μπορεί να παρακολουθεί και να αξιολογεί περιορισμένο αριθμό διαθέσιμων επενδυτικών γεγονότων, ένα σύστημα που αξιοποιεί το σύνολο των διαθέσιμων δεδομένων και τα αναλύει έγκαιρα μπορεί να υποστηρίξει και να λάβει υπόψιν πολύ περισσότερη πληροφορία. Επιπροσθέτως, ένα τέτοιο σύστημα μπορεί να διαχειριστεί και να συγχωνεύσει δεδομένα διαφορετικής μορφής και είδους, τα

οποία ενδέχεται να αφορούν όχι μόνο χρηματιστηριακά και οικονομικά δεδομένα αλλά και δεδομένα ειδήσεων ή αναρτήσεις κοινωνικών δικτύων που μπορεί έμμεσα να υποδηλώνουν το μέλλον μιας μετοχής. Με τον τρόπο αυτό, η κρυμμένη πληροφορία που εμπεριέχεται μέσα στα διαθέσιμα δεδομένα, μπορεί να εξαχθεί με τεχνικές αναλυτικής δεδομένων και αλγορίθμους μηχανικής μάθησης. Σε αυτήν την περίπτωση το σύστημα θα υλοποιεί την οδηγούμενη από δεδομένα λήψη αποφάσεων η οποία θα γίνεται αξιοποιώντας τη μέγιστη δυνατή διαθέσιμη πληροφορία.

Η ενισχυτική μάθηση μπορεί επιτυχώς να συνδυάσει τις προβλέψεις με την κατασκευή του χαρτοφυλακίου σε ένα βήμα, ευθυγραμμίζοντας το πρόβλημα της μηχανικής μάθησης με τους στόχους του επενδυτή. Ταυτόχρονα, η ενισχυτική μάθηση επιτρέπει την εύκολη εισαγωγή επενδυτικών περιορισμών στη διαδικασία λήψης απόφασης, οι οποίοι υπάρχουν στη φυσική αγορά, όπως τα κόστη συναλλαγών, η ρευστότητα της αγοράς καθώς και επιπλέον κριτήρια και περιορισμούς που επιθυμεί ο επενδυτής να λάβει υπόψιν του (Fischer, 2018).

Η εργασία των Nevmynaka et al. (2006) αποτελεί μία από τις πρώτες αναφορές χρήσης της ενισχυτικής μάθησης για την διεξαγωγή βελτιστοποιημένων επενδυτικών ενεργειών. Παρουσιάζει το πρώτο σύστημα εμπειρογνωμοσύνης μεγάλης κλίμακας και επιβεβαιώνει πειραματικά τη συνεισφορά της ενισχυτικής μάθησης στον χρηματιστηριακό κλάδο. Η εργασία των Cararuco, et al. (2018) περιγράφει ένα σύστημα βραχυπρόθεσμης κερδοσκοπίας στην αγορά συναλλάγματος, υλοποιημένο με χρήση νευρωνικών δικτύων και q-learning αλγορίθμων. Το Q-network της προσέγγισης αλληλοεπιδρά με ένα περιβάλλον προσομοίωσης της αγοράς για να εκτελέσει την εκπαίδευση και τον έλεγχο σε συνθήκες παρόμοιες με εκείνες της πραγματικής αγοράς. Στη μοντελοποίηση που ακολουθείται από τη συγκεκριμένη εργασία, οι ενέργειες αναπαριστούν τις πιθανές επενδυτικές ενέργειες της θέσης του επενδυτή κατά το άνοιγμα ή το κλείσιμο της αγοράς. Βάσει προβλέψεων, επιχειρείται η παραγωγή προτάσεων που παρουσιάζουν καλύτερες προοπτικές. Η εργασία αυτή αξιοποιεί ιστορικά δεδομένα της αγοράς, με τη μορφή των ticks, των μικρότερων δηλαδή ενημερώσεων των τιμών των μετοχών. Στα δεδομένα των μετοχών

περιέχονται η τιμή προσφοράς (bid price), η τιμή πώλησης (ask price), και ο όγκος μονάδων που επενδύθηκε για καθεμία από αυτές.

Το μεγάλο ερευνητικό ενδιαφέρον για την εφαρμογή της ενισχυτικής μάθησης στη λήψη επενδυτικών αποφάσεων έχει οδηγήσει σε αρκετές επιπλέον βιβλιογραφικές αναφορές, οι οποίες αξιολογούνται και εξετάζονται από εργασίες βιβλιογραφικής ανασκόπησης. Η βιβλιογραφία παρουσιάζει πολλές προσεγγίσεις εφαρμογής της ενισχυτικής μάθησης για την επίλυση αντίστοιχων επενδυτικών προβλημάτων λήψης απόφασης, στις οποίες προτείνονται διαφορετικές παραλλαγές μεθόδων ενισχυτικής μάθησης. Όπως αναφέρεται στην εργασία του (Fischer, 2018), οι αλγόριθμοι ενισχυτικής μάθησης δίνουν τη δυνατότητα ενσωμάτωσης των οικονομικών προβλέψεων στη διαδικασία λήψης αποφάσεων που αφορά το πρόβλημα της κατασκευής χαρτοφυλακίου, λαμβάνοντας υπόψιν διάφορους σημαντικούς περιορισμούς, όπως για παράδειγμα τα κόστη συναλλαγών και την ρευστότητα της αγοράς. Παράλληλα, επιτρέπουν την αποτύπωση των κριτηρίων απόφασης του επενδυτή κατά τον ορισμό του προβλήματος μηχανικής μάθησης.

Η εργασία των Meng, και Khushi (2019) εξετάζει τη βιβλιογραφία σχετικά με την εφαρμογή της ενισχυτικής μάθησης για την παραγωγή προβλέψεων ή επενδυτικών προτάσεων σε χρηματιστήρια ή αγορές συναλλάγματος. Σε αυτήν την εργασία εξετάστηκαν 27 άρθρα, τα οποία ταξινομήθηκαν σύμφωνα με τον σκοπό του άρθρου, σύμφωνα με τρεις κατευθύνσεις: (i) αν αφορούσε την πρόβλεψη ή την παραγωγή αποφάσεων, (ii) αν αφορούσε χρηματιστηριακή αγορά ή αγορά συναλλάγματος και (iii) κατά πόσο πρότεινε ένα επενδυτικό σύστημα. Για κάθε άρθρο που συμμετείχε στην έρευνα καταγράφηκε το είδος των δεδομένων εισόδου, κατά κύριο λόγο παρελθοντικά δεδομένα, οι τεχνικές που προτείνει, και τα αποτελέσματα που παρουσιάζει. Σύμφωνα με τους συγγραφείς, το σύνολο των άρθρων που εξετάστηκαν βασίζονται σε κάποια μη ρεαλιστικές παραδοχές, όπως η απουσία κόστους συναλλαγών και η απουσία προβλημάτων ρευστότητας. Από την εργασία αυτή προκύπτει το συμπέρασμα ότι όταν η ενισχυτική μάθηση εφαρμόζεται σε ένα κατάλληλο πλαίσιο μπορεί να βελτιώσει ουσιαστικά την επίδοση σε σχέση με παραδοσιακά μοντέλα. Η βελτίωση αυτή παρουσιάζεται όταν η επίδοση βασίζεται στην ακρίβεια των προβλέψεων ή την επενδυτική κερδοφορία και εφόσον δεν

εμφανίζονται μεγάλες αλλαγές στα πρότυπα τιμών που χρησιμοποιούνται για την εκπαίδευση του συστήματος σε σχέση με τα δεδομένα που χρησιμοποιούνται για την αξιολόγηση του συστήματος. Η συγκεκριμένη εργασία αναγνωρίζει ότι η εφαρμογή της ενισχυτικής μάθησης στις χρηματιστηριακές αγορές ξεκίνησε πρόσφατα να ερευνάται. Όμως, καταλήγει στο συμπέρασμα ότι απαιτείται περαιτέρω έρευνα για να μπορέσει η ενισχυτική μάθηση να αποδειχθεί ως μια αξιόπιστη μέθοδος σε αυτόν τον τομέα.

Η εργασία του Sato (2019) ερευνά το κατά πόσον μπορεί να υπάρχει μία καθολική λύση για το πρόβλημα βελτιστοποίησης χαρτοφυλακίου και πώς αυτό το πρόβλημα μπορεί να μοντελοποιηθεί χρησιμοποιώντας μαρκοβιανές διαδικασίες απόφασης διακριτού χρόνου (discrete-time MDP). Το προς εξέταση σύστημα είναι ένα χαρτοφυλάκιο αποτελούμενο από διαφορετικά επενδυτικά στοιχεία και στόχος είναι η εξέταση των βαρών τους. Για την επίλυση του προβλήματος με αυτήν τη μοντελοποίηση, προτείνεται η εφαρμογή αλγορίθμων ενισχυτικής μάθησης ανεξαρτήτων μοντέλου, στην οποία δεν απαιτείται η εκ των προτέρων γνώση της δυναμικής κάθε επενδυτικού στοιχείου. Επιπλέον, η εργασία αυτή εξετάζει και τις δύο κατηγορίες μεθόδων ενισχυτικής μάθησης, αλγόριθμοι τιμής (value-based) και αλγόριθμοι κλίσης πολιτικής (policy gradient) και εντοπίζει τα ανοιχτά ερωτήματα και τις προκλήσεις τις οποίες αντιμετωπίζουν οι επενδυτές που επιλέγουν να εφαρμόσουν αλγόριθμους ενισχυτικής μάθησης ανεξάρτητους μοντέλου στο χαρτοφυλάκιο τους.

Ιδιαίτερο ενδιαφέρον παρουσιάζει ο τρόπος μοντελοποίησης της δυναμικότητας του χρηματιστηριακού περιβάλλοντος στη μοντελοποίηση των αντίστοιχων αλγορίθμων ενισχυτικής μάθησης, αν και αποτελεί ακόμη ένα πρώιμο ερευνητικό αντικείμενο. Σε αυτήν την κατεύθυνση, οι García-Galicia et al. (2019) εστιάζουν στην εφαρμογή των αλγορίθμων ενισχυτικής μάθησης που στοχεύουν σε προβλήματα συνεχούς χρόνου αλλά διακριτών καταστάσεων, για την επίλυση του προβλήματος της διαχείρισης χαρτοφυλακίου. Οι πιο πρόσφατες εργασίες που αφορούν την αξιοποίηση της ενισχυτικής μάθησης για το πρόβλημα αυτό εστιάζουν σε πιθανές εφαρμογές βαθιάς ενισχυτικής μάθησης (Deep Reinforcement Learning) (Xiong, Z et al., 2018; Zhang et al., 2020b; Hirchoua et al., 2021), μεταξύ των οποίων

παρουσιάζονται και σχετικές ανασκοπήσεις της βιβλιογραφίας (Millea, 2021; Pricore et al., 2021).

7.3 Εφαρμογή Μεθόδου

Θεωρούμε ότι οι διαχειριστές επενδύσεων έχουν επιλέξει ένα σύνολο από μετοχές και παρακολουθούν την εξέλιξή τους με στόχο να εντοπίσουν έγκαιρα επενδυτικές ευκαιρίες. Το σύνολο μετοχών μπορεί να αποτελείται από οποιονδήποτε συνδυασμό από μετοχές που περιλαμβάνονται ήδη στο χαρτοφυλάκιο του επενδυτή και μετοχές στις οποίες επιθυμεί να επενδύσει στο μέλλον. Ο στόχος της προτεινόμενης μεθόδου είναι να αξιοποιήσει τις προβλέψεις της μελλοντικής τιμής των μετοχών για μια συγκεκριμένη ημέρα και, βάσει αυτών, να προδιαγράψει την βέλτιστη επενδυτική ενέργεια που μπορεί να αποφέρει τη βέλτιστη απόδοση με το μικρότερο πιθανό ρίσκο. Οι παραγόμενες επενδυτικές προδιαγραφές παράγονται έπειτα από την ενσωμάτωση των προτιμήσεων του χρήστη, αναφορικά με τα κριτήρια βελτιστοποίησης, στον προδιαγραφικό μηχανισμό της μεθόδου. Οι προτιμήσεις του χρήστη αντιπροσωπεύουν την επενδυτική στρατηγική που ακολουθεί, την οποία η μέθοδος αξιοποιεί χωρίς να απαιτεί τον εκ των προτέρων ρητό προσδιορισμό της. Στις παρακάτω παραγράφους περιγράφεται η περίπτωση μελέτης ακολουθώντας τις τρεις φάσεις του πλαισίου που αναπτύσσεται στο κεφάλαιο 4: Κατασκευή Προδιαγραφικού Μοντέλου, Επίλυση Προδιαγραφικού Μοντέλου και Προσαρμογή Προδιαγραφικού Μοντέλου.

Κατασκευή Προδιαγραφικού Μοντέλου

Στη φάση κατασκευής, το προδιαγραφικό μοντέλο αναλυτικής δεδομένων παραμετροποιείται σύμφωνα με τις απαιτήσεις του προβλήματος χρηματιστηριακών επενδύσεων που εξετάζεται. Ο Πίνακας 7-1 παρουσιάζει την αντιστοίχιση των παραμέτρων και των οντοτήτων της προτεινόμενης μεθόδου στο πρόβλημα των χρηματιστηριακών επενδύσεων, οι οποίες περιγράφονται αναλυτικά παρακάτω.

	Σημειογραφία	Περιγραφή
Γεγονότα Πρόβλεψης	E_i	Μελλοντική τιμή μετοχή έπειτα από X ημέρες, $price_{t+X}^*$
Ενέργειες	A_1	Αγορά μεριδίων μετοχής, εφόσον η μετοχή δεν περιέχεται στο υπάρχον χαρτοφυλάκιο, με σκοπό την πώληση την προβλεπόμενη ημερομηνία
	A_2	Πώληση των μεριδίων της μετοχής που περιέχονται στο χαρτοφυλάκιο, την προβλεπόμενη ημερομηνία
	A_3	Διατήρηση θέσης για την επιλεγμένη μετοχή, μέχρι την επιλεγμένη ημερομηνία
Κριτήρια	O_1	Απόδοση R_{A_i}
Βελτιστοποίησης	O_2	Αναμενόμενο Ρίσκο $Risk_{A_i}$

Πίνακας 7-1 Παραμετροποίηση μεθόδου στο πρόβλημα των χρηματιστηριακών επενδύσεων

Όταν μια νέα πρόβλεψη E_i για την τιμή μιας μετοχής σε μια επιλεγμένη ημερομηνία παράγεται από το προβλεπτικό μοντέλο M , ενεργοποιείται η διαδικασία κατασκευής προδιαγραφικού μοντέλου. Στη μοντελοποίηση που αναπτύσσεται για την παρούσα περίπτωση, θεωρούμε τις εναλλακτικές ενέργειες τις οποίες δύναται να εκτελέσει ένας επενδυτής:

- (i) **buy (A_1)**: να αγοράσει μερίδια της μετοχής την τρέχουσα ημέρα με σκοπό να τα πουλήσει μετά την επιλεγμένη μελλοντική ημερομηνία, εφόσον το χαρτοφυλάκιο του δεν εμπεριέχει ήδη μερίδια αυτής της μετοχής,

- (ii) **sell (A_2):** να πουλήσει τα μερίδια της μετοχής που έχει ήδη στη διάθεσή του, στην επιλεγμένη μελλοντική ημερομηνία, εφόσον το χαρτοφυλάκιό του εμπεριέχει μερίδια αυτής της μετοχής,
- (iii) **hold (A_3):** να διατηρήσει τη θέση του ως προς αυτήν τη μετοχή, μέχρι την πάροδο της επιλεγμένης μελλοντικής ημερομηνίας.

Σύμφωνα με τις βασικές παραδοχές της σύγχρονης θεωρίας χαρτοφυλακίου, οι συσχετίσεις που παρουσιάζονται ανάμεσα σε διαφορετικά στοιχεία είναι συγκεκριμένες και διαχρονικές, ενώ εξαρτώνται από τις συστημικές μεταξύ τους σχέσεις. Παραδείγματα τέτοιων συσχετίσεων αποτελούν οι σχέσεις μεταξύ χωρών, όπου η προκήρυξη πολέμου σε μία χώρα επηρεάζει άμεσα τις συσχετιζόμενες χώρες. Η ελαχιστοποίηση του ρίσκου των επενδυτικών στοιχείων που επιλέγει ένας επενδυτής να εισάγει στο χαρτοφυλάκιό του συνήθως αντιμετωπίζεται με τη διατήρηση ενός διαφοροποιούμενου χαρτοφυλακίου, το οποίο εμπεριέχει στοιχεία με διαφορετικό ρίσκο και απόδοση (Xidonas et al., 2012). Η προτεινόμενη μέθοδος δύναται να διαχειριστεί πιθανές συσχετίσεις μεταξύ των μετοχών ή να αντιμετωπίσει σύνολα μετοχών ως πιθανά επενδυτικές ευκαιρίες. Ακολουθώντας μια διαφορετική μοντελοποίηση, στην παρούσα εφαρμογή της προτεινόμενης μεθόδου επιλέγεται η αντιμετώπιση κάθε μετοχής ανεξάρτητα. Η επιλογή αυτή γίνεται καθώς η καταγραφή και η ανάλυση πιθανών συσχετίσεων θα προσέθετε πολυπλοκότητα και θα δυσκόλευε την παρουσίαση και την αξιολόγηση της προτεινόμενης μεθόδου.

Για την κατασκευή του χώρου καταστάσεων του περιβάλλοντος ενισχυτικής μάθησης χρησιμοποιούνται οι παραπάνω υποψήφια επενδυτικές ενέργειες. Η τρέχουσα ημερήσια τιμή της μετοχής και η πρόβλεψη της τιμής της μετοχής για την επιλεγμένη μελλοντική ημερομηνία χρησιμοποιούνται ως δεδομένα εισόδου. Κάθε υποψήφια ενέργεια συσχετίζεται με ένα διάνυσμα ανταμοιβής το οποίο εμπεριέχει τα επιλεγμένα κριτήρια βελτιστοποίησης και αποτυπώνει και το πως αυτά επηρεάζονται από την υλοποίηση της συγκεκριμένης ενέργειας. Τα περισσότερα κριτήρια βελτιστοποίησης που παρατηρούνται στη λήψη απόφασης χρηματιστηριακών επενδύσεων εντάσσονται σε δύο βασικά κριτήρια, την αναμενόμενη απόδοση (expected return) της μετοχής και το αναμενόμενο ρίσκο (expected risk). Αν και η προτεινόμενη μέθοδος επιτρέπει την εισαγωγή επιπλέον

κριτηρίων βελτιστοποίησης στην λήψη αποφάσεων, στην παρούσα μελέτη επιλέχθηκαν τα δύο βασικά κριτήρια βελτιστοποίησης που συναντώνται στην πλειονότητα των σχετικών εργασιών, η **μεγιστοποίηση της απόδοσης (O_1)** και η **ελαχιστοποίηση του ρίσκου (O_2)**. Η επιλογή των κριτηρίων συμβαδίζει με τις βασικές παραδοχές της σύγχρονης θεωρίας χαρτοφυλακίου, οι οποίες θεωρούν ότι όλοι οι επενδυτές στοχεύουν στη μεγιστοποίηση της οικονομική χρηστικότητα (expected utility), δηλαδή επιθυμούν να κερδίσουν όσο περισσότερα χρήματα είναι δυνατόν ενώ παράλληλα αποφασίζουν λογικά, αποφεύγοντας επενδυτικές αποφάσεις με μεγάλο ρίσκο (Xidonas et al., 2012).

Σύμφωνα με τη βιβλιογραφία, η αποδοτική και ακριβής μοντελοποίηση της μακροπρόθεσμης και βραχυπρόθεσμης απόδοσης, σε συνδυασμό με τη μοντελοποίηση του επενδυτικού ρίσκου συνήθως οδηγούν σε πολύπλοκες οικονομικές αναλύσεις οι οποίες βασίζονται σε πολλές ετερογενείς παραμέτρους και δεδομένα (Meng, και Khushi, 2019). Η εφαρμογή της προτεινόμενης μεθόδου στο πρόβλημα των χρηματιστηριακών επενδύσεων παράγει χρήσιμη γνώση για την υποστήριξη των επενδυτικών αποφάσεων, χρησιμοποιώντας αποκλειστικά τα δεδομένα τιμών των μετοχών και συνδυάζοντάς τα με τη γνώση του επενδυτή. Οι ορισμοί των συναρτήσεων ανταμοιβής για τα δύο επιλεγμένα κριτήρια βελτιστοποίησης που παρουσιάζονται παρακάτω, αποτελούν μια απλοποιημένη μοντελοποίηση της περίπτωσης χρηματιστηριακών επενδύσεων που μελετάται. Η προτεινόμενη μέθοδος, όπως αναλύεται στο κεφάλαιο 5, μπορεί να εφαρμοστεί σε διαφορετικά προβλήματα, διαφόρων γνωστικών πεδίων. Κατά συνέπεια, μπορεί να εφαρμοστεί με διαφορετικές μοντελοποιήσεις που πιθανώς ικανοποιούν διαφορετικές απαιτήσεις, ακόμη και για το ίδιο πρόβλημα.

Επιπλέον, οι μοντελοποιήσεις ενός κριτηρίου που ενσωματώνουν την απόδοση και το ρίσκο ταυτόχρονα, βασίζονται σε μετρικές απόδοσης σταθμισμένου ρίσκου (risk-adjusted return), όπως για παράδειγμα ο λόγος Sharpe (Sharpe ratio), ή σε μετρικές αστάθειας (volatility), όπως ο παράγοντας beta (beta factor) (Meng, και Khushi, 2019) και δεν αξιοποιούν τα αποτελέσματα της προβλεπτικής αναλυτικής. Σε αντίθεση με αυτό, η προτεινόμενη προσέγγιση διαχωρίζει τα δύο κριτήρια βελτιστοποίησης σε δύο ανεξάρτητες συναρτήσεις ανταμοιβής και αρχικά

βελτιστοποιεί κάθε κριτήριο ξεχωριστά, προκειμένου η μοναδική παραγόμενη προτεινόμενη επενδυτική απόφαση να βελτιστοποιεί ταυτόχρονα και τα δύο κριτήρια βελτιστοποίησης. Επιπροσθέτως, εξαιτίας αυτού του διαχωρισμού, η προτεινόμενη μέθοδος μπορεί να εκτιμήσει το ρίσκο που υπάρχει σε μια επενδυτική ενέργεια, αξιοποιώντας ταυτόχρονα τα διαθέσιμα ιστορικά δεδομένα και τα αποτελέσματα των προβλεπτικών αλγορίθμων.

Η ανταμοιβή του κριτηρίου της απόδοσης O_1 ορίζεται μέσω της απόδοσης της επένδυσης (Return Over Investment - ROI) που μπορεί να αποφέρει κάθε υποψήφια ενέργεια, εφόσον υλοποιηθεί στην επιλεγμένη μελλοντική ημέρα, δεδομένης της εκδήλωσης της πρόβλεψης στην οποία βασίζεται. Η απόδοση της ενέργειας A_i υπολογίζεται ως:

$$R_{A_i} = \frac{price_b - price_{t+x}^*}{price_b} \quad (7)$$

όπου $price_b$ είναι η τιμή αγοράς των μεριδίων της μετοχής και $price_{t+x}^*$ είναι η προβλεπόμενη τιμή για την επιλεγμένη ημερομηνία. Αυτό ο ορισμός της ανταμοιβής του κριτηρίου απόδοσης παρέχει στον επενδυτή την ευελιξία να εστιάσει στη μακροχρόνια ή στην βραχυπρόθεσμη απόδοση της υπό εξέταση μετοχής κατ' επιλογή, επιλέγοντας την κατάλληλη μελλοντική ημερομηνία.

Αντίστοιχα, η συνάρτηση ανταμοιβής του κριτηρίου O_2 εφαρμόζεται στις τρεις υποψήφιες ενέργειες A_1, A_2, A_3 . Για κάθε ενέργεια, ορίζουμε τρία πιθανά σενάρια που μπορούν να εκδηλωθούν συναρτήσει της προβλεπόμενης τιμής, με τα οποία επιδιώκουμε να διαχειριστούμε την αβεβαιότητα που εισάγει η πρόβλεψη στην λήψη της επενδυτικής απόφασης. Χρησιμοποιούμε την ακρίβεια της πρόβλεψης σε συνδυασμό με τα διαθέσιμα ιστορικά δεδομένα τιμής, προκειμένου να ορίσουμε ένα σενάριο χειρότερης περίπτωσης (worst case scenario), ένα σενάριο βέλτιστης περίπτωσης (best case scenario), και ένα σενάριο μια μετριοπαθούς περίπτωσης (average case scenario). Τα σενάρια αυτά χρησιμοποιούνται ως βάση για την εκτίμηση του αναμενόμενου ρίσκου που εμπεριέχει κάθε υποψήφια ενέργεια. Το πρώτο βήμα για τον ορισμό του ρίσκου είναι ο υπολογισμός της απόδοσης των τριών σεναρίων σύμφωνα με την Εξίσωση (7). Βάσει αυτής, στη συνέχεια υπολογίζουμε την αναμενόμενη απόδοση (expected return) ER_{A_i} της ενέργειας A_i :

$$ER_{A_i} = Pr_{wc} * R_{wc} + Pr_{bc} * R_{bc} + Pr_{ac} * R_{ac} \quad (8)$$

Στην Εξίσωση (8) οι $Pr_{wc}, Pr_{bc}, Pr_{ac}$ είναι οι πιθανότητες εκδήλωσης των τριών σεναρίων αντιστοίχως, τις οποίες υπολογίζουμε χρησιμοποιώντας τις εμφανίσεις τους στα ιστορικά δεδομένα. R_{wc}, R_{bc}, R_{ac} είναι η αντίστοιχη απόδοση κάθε σεναρίου, όπως υπολογίζεται από την Εξίσωση (7). Το αναμενόμενο ρίσκο (expected risk) $Risk_{A_i}$ ορίζεται μέσω της τυπικής απόκλισης της αναμενόμενης απόδοσης (Almahdi, και Yang, 2017) των σεναρίων, για κάθε υποψήφια ενέργεια A_i :

$$Risk_{A_i} = \sqrt{\sum_{c \in \{wc, bc, ac\}} (Pr_c * (R_c - ER_{A_i})^2)} \quad (9)$$

Επίλυση Προδιαγραφικού Μοντέλου

Στην περίπτωση χρηματιστηριακών επενδύσεων που εξετάζεται στον παρόν κεφάλαιο, η επίλυση του προδιαγραφικού μοντέλου γίνεται μέσω ενός πράκτορα ενισχυτικής μάθησης αποτελούμενο από έναν δράστη με πολιτική οριζόμενη από μια κατανομή Boltzmann πάνω στις προτιμήσεις των ενεργειών που ο δράστης μπορεί να εκτελέσει και έναν κριτή με τη μορφή ενός αλγορίθμου μάθησης TD-lambda (Agostinelli, et al., 2018). Όπως περιγράφεται στην παράγραφο 5.2.2, αρχικά ο πράκτορας εκπαιδεύεται για κάθε κριτήριο ανεξάρτητα. Στη συνέχεια, οι παραγόμενες πολιτικές ενσωματώνονται μέσω πολλαπλασιασμού, εφόσον τα κριτήρια βελτιστοποίησης είναι ανεξάρτητα. Στην παρούσα μελέτη, ο υπολογισμός των κριτηρίων μέσω των αντίστοιχων συναρτήσεων ανταμοιβών που ορίστηκαν για τα δύο κριτήρια, εμπεριέχει το ίδιο αρχικό χαρακτηριστικό (την τιμή της μετοχής). Για να επιβεβαιώσουμε την ανεξαρτησία των κριτηρίων βελτιστοποίησης, όπως ορίζονται από τις Εξισώσεις (7), (9), εξετάσαμε τον συντελεστή συσχέτισης Pearson και εκτελέσαμε τον στατιστικό έλεγχο τιμής p-value. Με αυτήν τη διαδικασία καταλήξαμε σε συντελεστή συσχέτισης Pearson με τιμή 0.016 και p-value ίση με 0.8709. Τα αποτελέσματα αυτά δηλώνουν ότι δεν παρουσιάζεται στατιστικά σημαντική συσχέτιση ανάμεσα στα δύο επιλεγμένα κριτήρια.

Προσαρμογή Προδιαγραφικού Μοντέλου

Η ανάδραση σε κάθε πρόβλημα διαχείρισης χαρτοφυλακίου μπορεί να προέρχεται από χρήστες, διαφορετικούς μεταξύ τους, οι οποίοι διακρίνονται από δύο βασικά χαρακτηριστικά: από την επενδυτική εμπειρία και γνώση του χρήστη και την επενδυτική στρατηγική που επιλέγει να ακολουθήσει. Στην προτεινόμενη μέθοδο, η επενδυτική εμπειρία του χρήστη αναπαρίσταται μέσω των χαρακτηριστικών της συνέπειας της ανάδρασης και της πιθανότητας της ανάδρασης.

Οι χρήστες κατηγοριοποιούνται σε μία ενιαία κλίμακα τριών επιπέδων ως προς την εμπειρία τους: (i) στους έμπειρους χρήστες (experienced users), (ii) στους χρήστες ενδιάμεσου επιπέδου (intermediate users) και (iii) στους αρχάριους χρήστες (beginners). Σε κάθε επίπεδο αντιστοιχίζεται συγκεκριμένη τιμή της συνέπειας ανάδρασης και της πιθανότητας ανάδρασης. Οι τιμές αυτές υποδεικνύουν το μέγεθος της επίδρασης που θα έχει η παρεχόμενη ανάδραση από χρήστες του επιπέδου κατά την προσαρμογή του προδιαγραφικού μηχανισμού. Επιπλέον, οι χρήστες επιλέγουν μια διαφορετική επενδυτική στρατηγική την οποία θεωρούν πιο επικερδή και λιγότερο επικίνδυνη, βάσει της εμπειρίας τους.

Η σύγχρονη θεωρία χαρτοφυλακίου βασίζεται στις παραδοχές ότι όλοι οι επενδυτές στοχεύουν κατά κύριο λόγο στη μεγιστοποίηση της οικονομικής χρηστικότητας και οι επενδύσεις τους θεωρείται ότι καθοδηγούνται από τη λογική και την αποφυγή του ρίσκου. Όμως, η συμπεριφορική οικονομική (Behavioral Economics) δείχνει ότι κάτι τέτοιο δεν είναι πάντα αληθές (Xidonas et al., 2012). Η παραδοχή αποκλείει από οποιαδήποτε σχετική μελέτη επενδυτές οι οποίοι μπορεί να ακολουθούν μια διαφορετική επενδυτική στρατηγική ή να έχουν διαφορετικούς στόχους. Για παράδειγμα, ένας επενδυτής μπορεί συστηματικά να αναζητά τις επενδυτικές ενέργειες οι οποίες θα του αποφέρουν τη μέγιστη απόδοση σε κάθε περίπτωση, αγνοώντας το συσχετιζόμενο ρίσκο. Παράλληλα, ένας άλλος επενδυτής μπορεί συστηματικά να επιλέγει τις επενδύσεις που παρουσιάζουν το μικρότερο δυνατό ρίσκο.

Σε αντίθεση με τη σχετική βιβλιογραφία (Fifield et al., 2005; Marshall et al., 2006; Feuerriegel, και Prendinger, 2016), η προτεινόμενη μέθοδος στην περίπτωση των χρηματιστηριακών επενδύσεων δεν απαιτεί εκ των προτέρων τον ρητό και στατικό

ορισμό της επενδυτικής στρατηγικής ή των γενικότερων προτιμήσεων του χρήστη. Η πρόθεση των χρηστών συμπεραίνεται έμμεσα από το σύστημα κατά την εκτέλεση της μεθόδου και χρησιμοποιείται για την προσαρμογή του προδιαγραφικού μηχανισμού αξιοποιώντας την παρεχόμενη ανάδραση. Με τον τρόπο αυτό, η μέθοδος ακολουθεί τις διακυμάνσεις που μπορεί να παρουσιάζει η στρατηγική του χρήστη, διατηρώντας έτσι την χρησιμότητά της για τον χρήστη σε βάθος χρόνου.

Έπειτα από κάθε επανάληψη της μεθόδου, ο χρήστης παρέχει την ανάδραση H_{Presc} , με τη μορφή έγκρισης ή απόρριψης, που υποδεικνύει η εμπειρία και η στρατηγική του αναφορικά με τις προτεινόμενες από τη μέθοδο ενέργειες A_i (αγορά, πώληση, διατήρηση θέσης). Με κάθε ανάδραση, το προδιαγραφικό μοντέλο επανεκπαιδύεται και αναπροσαρμόζεται προκειμένου να παρέχει προδιαγραφές οι οποίες όχι μόνο θα είναι βέλτιστες ως προς τα επιλεγμένα κριτήρια βελτιστοποίησης αλλά θα συγκλίνουν και με τις προτιμήσεις του χρήστη, τη στρατηγική και την εμπειρία του.

7.4 Αξιολόγηση

7.4.1 Πειραματική Διαδικασία

Η πειραματική διαδικασία που αναπτύχθηκε στην παρούσα μελέτη, βασίστηκε στην υλοποίηση που περιγράφεται αναλυτικά στο Κεφάλαιο 6.

Το σύνολο δεδομένων που χρησιμοποιήθηκε αποτελεί ένα μέρος του ανοιχτού συνόλου δεδομένων τιμών διαφορετικών μετοχών, το οποίο είναι διαθέσιμο στην πλατφόρμα Kaggle (<https://www.kaggle.com/borismarjanovic/price-volume-data-for-all-us-stocks-etfs>). Το αρχικό σύνολο δεδομένων περιέχει 7195 αρχεία παρελθοντικών δεδομένων τιμών όλων των μετοχών των Ηνωμένων Πολιτειών Αμερικής καθώς και δεδομένα διαπραγματεύσιμων αμοιβαίων κεφαλαίων (Exchange Traded Funds) τα οποία είναι διαθέσιμα στο Χρηματιστήριο Νέας Υόρκης (New York Stock Exchange), στο Χρηματιστήριο NASDAQ (Nasdaq Stock Market) και στο Χρηματιστήριο NYSE American.

Η πειραματική διαδικασία της παρούσας μελέτης εστίασε στα δεδομένα της τιμής κλεισίματος της μετοχής της τεχνολογικής εταιρίας Apple, για το χρονικό διάστημα

από 07-07-2004 μέχρι 31-01-2008 τα οποία έχουν συγκεντρωθεί με ημερήσια δειγματοληψία. Η ημερήσια τιμή μιας μετοχής ενσωματώνει τη συμπεριφορά της μετοχής σχεδόν σε πραγματικό χρόνο. Τα πειράματα της παρούσας μελέτης αποτελούνται από μία επαναληπτική διαδικασία πάνω σε 770 ημέρες του προαναφερθέντος χρονικού διαστήματος. Σε κάθε επανάληψη, η τιμή κλεισίματος της επιλεγμένης ημέρας συσχετίζεται με τα τρέχοντα γεγονότα που περιγράφονται στην προτεινόμενη μέθοδο. Το επιθυμητό γεγονός που επιθυμούμε να εκμεταλλευτούμε συσχετίζεται με την τιμή κλεισίματος που θα έχει η μετοχή 100 ημέρες μετά την επιλεγμένη ημέρα.

Βάσει της ημερήσιας τιμής κλεισίματος $price_1, price_2, \dots, price_t$ της επιλεγμένης μετοχής, ένας προβλεπτικός αλγόριθμος παράγει μια πρόβλεψη αναφορικά με την τιμή της μετοχής στην επιλεγμένη μελλοντική ημέρα $price_{t+x}^*$. Για το σκοπό αυτό χρησιμοποιήσαμε ένα δίκτυο μακράς βραχύχρονης μνήμης (Long Short-Term Memory - LSTM), το οποίο εντάσσεται στην κατηγορία των Τεχνητών ανατροφοδοτούμενων νευρωνικών δικτύων (Recurrent Neural Networks) του τομέα της βαθιάς μηχανικής μάθησης (Deep Learning). Η επιλογή αυτή βασίστηκε στην αντίστοιχη βιβλιογραφία στην οποία τα συγκεκριμένα δίκτυα επιδεικνύουν υψηλές επιδόσεις σε περιπτώσεις πρόβλεψης χρηματιστηριακών μετοχών, με ακρίβεια πρόβλεψης 80% (Selvin et al., 2017). Η υλοποίηση του αλγορίθμου δράστη-κριτή βασίστηκε στις εξής παραμέτρους:

Μέγιστος αριθμός επεισοδίων	50000
Εκπτωτικός παράγοντας γ (discount factor)	0.99
Ρυθμός εκμάθησης (learning rate)	0.4
Παράγοντας λάμδα	0.4
Μέγιστος αριθμός βημάτων	2000
Αριθμός επεισοδίων	10000

Πίνακας 7-2 Παράμετροι αλγορίθμου επίλυσης προδιαγραφικού μοντέλου

Για την αξιολόγηση της ανάδρασης του χρήστη και των τρόπων με τους οποίους αυτή επηρεάζει την προτεινόμενη μέθοδο, εξετάσαμε 9 διαφορετικές κατηγορίες χρηστών. Εφόσον η συλλογή της αντίστοιχης ανάδρασης από διαφορετικούς χρήστες καθιστά την αξιολόγηση σε πραγματικές συνθήκες δύσκολη, προσομοιώσαμε τις διαφορετικές κατηγορίες χρηστών σύμφωνα με τα δύο προαναφερθέντα χαρακτηριστικά, την επενδυτική εμπειρία και γνώση του χρήστη και την επενδυτική στρατηγική που επιλέγει να ακολουθήσει. Οι χρήστες που προσομοιώθηκαν κατηγοριοποιήθηκαν σε τρία επίπεδα επενδυτικής εμπειρίας: (i) τους έμπειρους χρήστες, (ii) τους χρήστες ενδιάμεσου επιπέδου και (iii) στους αρχάριους. Ως επενδυτικές στρατηγικές ορίσαμε τρεις εναλλακτικές στρατηγικές οι οποίες διαφοροποιούνται ως προς την αξία που δίνει ο χρήστης στο ρίσκο κάθε επένδυσης. Η πρώτη στρατηγική που ορίστηκε είναι η στρατηγική αποφυγής ρίσκου (risk-averse), η οποία αντιπροσωπεύει χρήστες που έχουν ως πρωταρχικό στόχο βελτιστοποίησης την ελαχιστοποίηση του ρίσκου, με οποιαδήποτε συνέπεια μπορεί να έχει αυτή στην απόδοση της επιλεγμένης επένδυσης. Η δεύτερη στρατηγική είναι η στρατηγική της αναζήτησης ρίσκου (risk-seeking), η οποία αντιπροσωπεύει κάθε χρήστη που έχει ως προτεραιότητα τη μεγιστοποίηση της απόδοσης της προτεινόμενης επένδυσης, αγνοώντας το ρίσκο που τη συνοδεύει. Η τελευταία στρατηγική είναι η ουδέτερη ως προς το ρίσκο στρατηγική (risk-neutral). Θεωρούμε ότι αυτήν ακολουθούν οι χρήστες που συστηματικά επιλέγουν επενδύσεις με τον βέλτιστο συνδυασμό των δύο κριτηρίων, ο οποίος επιτυγχάνει τη μεγιστοποίηση της απόδοσης και την ελαχιστοποίηση του ρίσκου, όπως αυτές προκύπτουν από την προτεινόμενη μέθοδο.

Αντίστοιχα με τα επίπεδα εμπειρίας, οι χρήστες που προσομοιώθηκαν αντιστοιχίστηκαν σε μία από τις τρεις στρατηγικές, οδηγώντας σε ένα σύνολο 9 διαφορετικών κατηγοριών χρηστών που προκύπτουν από τους δυνατούς συνδυασμούς των δύο χαρακτηριστικών. Για κάθε κατηγορία χρηστών ορίσαμε μια διαδικασία προσομοίωσης της ανάδρασης η οποία αντικατοπτρίζει την εμπειρία και τη στρατηγική της κατηγορίας αυτής στην παρεχόμενη ανάδραση.

Ο Πίνακας 7-3 παρουσιάζει πέντε ενδεικτικές επαναλήψεις, τυχαία επιλεγμένες κατά μήκος του αρχικού συνόλου δεδομένων, μαζί με τις υπολογισθείσες τιμές των κριτηρίων απόδοσης και ρίσκου για τις εναλλακτικές επενδυτικές ενέργειες, όπως

αυτές υπολογίζονται από την προτεινόμενη μέθοδο για έναν έμπειρο χρήστη. Στον πίνακα αυτόν, η «Ημερομηνία» αναπαριστά την ημερομηνία συλλογής της ημερήσιας τιμής κλεισίματος η οποία καταγράφεται στη στήλη «Τιμή», όπως αυτή προέρχεται από το αρχικό σύνολο δεδομένων. Η «Πρόβλεψη Τιμής» παρουσιάζει την τιμή που προβλέπεται από το προβλεπτικό LSTM δίκτυο για την επιλεγμένη μελλοντική ημερομηνία, έπειτα από 100 ημέρες. Για κάθε ημέρα από αυτές που παρουσιάζονται στον πίνακα, υπολογίσαμε τα ποσοστά απόδοσης και αναμενόμενου ρίσκου για τις δύο εναλλακτικές ενέργειες, την Αγορά και την Πώληση, σύμφωνα με τους ορισμούς που αναπτύσσονται στην παράγραφο 7.3.

Ημερομηνία	Τιμή	Πρόβλεψη Τιμής	Αγορά		Πώληση	
			Απόδοση	Ρίσκο	Απόδοση	Ρίσκο
19/05/06	8.261	8.743	5.83%	29.8%	-6.9%	24.5%
02/06/06	7.896	11.45	45%	76.8%	17.6%	41.8%
19/06/06	7.325	9.128	24.6%	51.3%	-3.9%	24.5%
11/10/07	20.776	17.416	-16.2%	31.2%	21.5%	46.2%
31/01/08	17.337	19.081	10%	32.7%	13.1%	35.2%

Πίνακας 7-3 Ενδεικτικός υπολογισμός απόδοσης και ρίσκου

7.4.2 Σύγκριση με άλλες μεθόδους

Η απόδοση και η αποτελεσματικότητα της προτεινόμενης μεθόδου ως ένας αλγόριθμος παραγωγής επενδυτικών αποφάσεων, αξιολογείται μέσω της σύγκρισης με τρεις κλασσικές επενδυτικές στρατηγικές που παρουσιάζονται στη σχετική βιβλιογραφία. Η πρώτη κατηγορία επενδυτικών στρατηγικών η οποία υλοποιήθηκε για την πειραματική σύγκριση της μεθόδου είναι η κατηγορία των στρατηγικών κανόνων φίλτρων (filter rule strategy). Σύμφωνα με αυτήν τη μέθοδο, η απόφαση

επένδυσης βασίζεται σε ένα σύνολο κανόνων οι οποίοι φιλτράρουν την τιμή της μετοχής και αναλόγως της αύξησης που προβλέπεται να παρουσιάσει, υποδεικνύουν την αγορά ή την πώληση μεριδίων της μετοχής.

Στην παρούσα μελέτη υλοποιήθηκε μία παραλλαγή αυτής της μεθόδου στην οποία λαμβάνοντας υπόψιν την προβλεπόμενη τιμή της μετοχής για την επιλεγμένη μελλοντική ημερομηνία, προτείνεται η αγορά μεριδίων της μετοχής εφόσον προβλέπεται αύξηση της τάξεως του 0.01% στην τιμή της μετοχής. Αντίστοιχα, προτείνεται η πώληση των διαθέσιμων στο χαρτοφυλάκιο μεριδίων της μετοχής, όταν προβλέπεται μείωση της τάξεως του 0.01% στην τιμή της μετοχής. Μια δεύτερη παραλλαγή αυτής της μεθόδου υλοποιήθηκε με όριο ενεργοποίησης στη μεταβολή της τιμής της μετοχής της τάξεως του 0.1%. Και οι δύο αυτές παραλλαγές αξιοποιούν την τιμή της μετοχής, όπως και η προτεινόμενη μέθοδος, εστιάζοντας όμως στο κέρδος που μπορεί να αποφέρει η αντίστοιχη επένδυση, αγνοώντας το ενδεχόμενο ρίσκο που αντιστοιχεί σε αυτήν.

Προκειμένου να είναι δυνατή η σύγκριση της προτεινόμενης μεθόδου με την αντίστοιχη βιβλιογραφία για το συνδυασμό των κριτηρίων που έχουν επιλεγεί, αναπτύχθηκε μια τρίτη επενδυτική στρατηγική. Αυτή χρησιμοποιεί τους υπολογισμούς της προτεινόμενης μεθόδου για την απόδοση και το αναμενόμενο ρίσκο των τριών εναλλακτικών επενδυτικών ενεργειών και βασίζεται στην παραδοσιακή μέθοδο βελτιστοποίησης του σταθμισμένου μέσου όρου των δύο κριτηρίων. Σε αυτήν τη μέθοδο, η προβλεπόμενη απόδοση και το αναμενόμενο ρίσκο της επένδυσης που αντιστοιχεί σε κάθε εναλλακτική ενέργεια, ενσωματώνονται σε μία συνθετική συνάρτηση βελτιστοποίησης με βάρος 0.7 για το κριτήριο της απόδοσης και 0.3 για το κριτήριο του ρίσκου. Η επιλογή των συγκεκριμένων βαρών έγινε έτσι ώστε η μέθοδος να προσομοιώσει τη στρατηγική που ακολουθείται από χρήστες της risk-seeking κατηγορίας και να καταστεί δυνατή η σύγκριση με την εφαρμογή της προτεινόμενης μεθόδου για αυτήν την κατηγορία χρηστών. Οι τρεις επενδυτικές στρατηγικές και η προτεινόμενη μέθοδος υλοποιήθηκαν και εφαρμόστηκαν ανεξάρτητα πάνω στο ίδιο σύνολο τιμών και τις ίδιες προβλέψεις.

Έπειτα από την ολοκλήρωση των πειραματικών επαναλήψεων για καθεμία από τις τέσσερις επενδυτικές στρατηγικές υπολογίστηκε η μέση απόδοση και το μέσο αναμενόμενο ρίσκο.

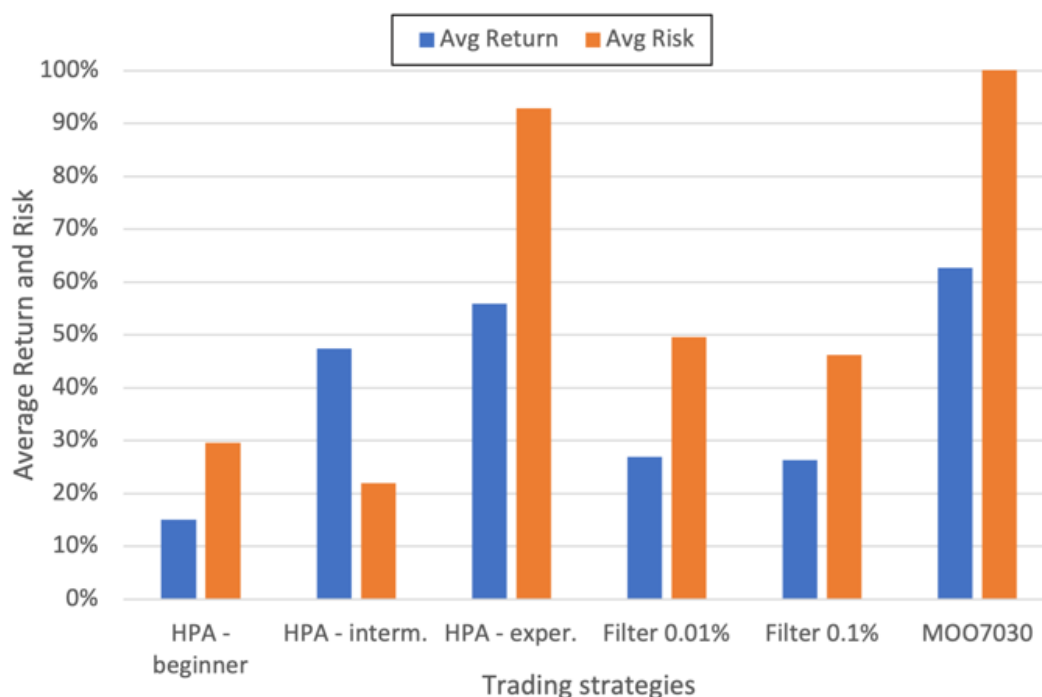
Ακολουθώντας το παράδειγμα του Πίνακα 7-3, ο Πίνακας 7-4 παρουσιάζει τις ενέργειες που προτάθηκαν από καθεμιά από τις συγκρινόμενες επενδυτικές στρατηγικές. Με τη συντομογραφία HPA (Human-augmented Prescriptive Analytics) δηλώνουμε τις προδιαγραφές της προτεινόμενης μεθόδου της παρούσας διατριβής, στις στήλες Filter 0.01% και Filter 0.1% παρουσιάζονται οι προδιαγραφές που προτείνουν οι στρατηγικές κανόνων φίλτρων ενώ στη στήλη MOO7030 παρουσιάζονται οι προδιαγραφές που παρήχθησαν χρησιμοποιώντας την στρατηγική που βασίζεται στην πολυκριτηριακή μέθοδο βελτιστοποίησης.

Ημερομηνία	HPA	Filter 0.01%	Filter 0.1%	MOO7030
19/05/2006	Hold	Buy	Hold	Hold
02/06/2006	Sell	Buy	Buy	Buy
19/06/2006	Buy	Buy	Buy	Buy
11/10/2007	Sell	Hold	Hold	Sell
31/01/2008	Sell	Buy	Buy	Hold

Πίνακας 7-4 Ενδεικτικές προδιαγραφές παραγόμενες από τις συγκρινόμενες επενδυτικές στρατηγικές

Το πρώτο πείραμα της διαδικασίας αξιολόγησης εστίασε στη σύγκριση της ποσοστιαίας μέσης απόδοσης και του ποσοστιαίου μέσου ρίσκου όπως αυτό υπολογίζεται μετά την ολοκλήρωση των επαναλήψεων στο σύνολο των 770 ημερών. Σε αυτό το πείραμα συγκρίνουμε τη μέση απόδοση και το μέσο ρίσκο που υπολογίζεται από τις διαφορετικές επενδυτικές στρατηγικές και τα τρία επίπεδα εμπειρίας χρηστών. Οι χρήστες που συμπεριλήφθηκαν ακολουθούν μια στρατηγική αντίστοιχη με την risk-seeking στρατηγική της προτεινόμενης μεθόδου. Τα αποτελέσματα αυτής της σύγκρισης παρουσιάζονται στην Εικόνα 7-1.

Σε αντίθεση με τις συγκρινόμενες επενδυτικές στρατηγικές, η προτεινόμενη μέθοδος οδηγεί σε διαφορετικές μέσες τιμές συνολικής απόδοσης και ρίσκου για τους διαφορετικούς τύπους χρηστών καθώς ανά περίπτωση προσαρμόζεται στην προσωποποιημένη επενδυτική στρατηγική του χρήστη. Με την προτεινόμενη μέθοδο, για τον έμπειρο χρήστη, η μέση τιμή της απόδοσης βελτιώνεται σε σχέση με τις στρατηγικές κανόνων φίλτρων, παρουσιάζοντας υψηλότερο μέσο ρίσκο. Σε σύγκριση με την πολυκριτηριακή μέθοδο, η προτεινόμενη μέθοδος παρουσιάζει χαμηλότερη μέση απόδοση επένδυσης, η οποία όμως συνοδεύεται με χαμηλότερο μέσο ρίσκο. Το πιο σημαντικό συμπέρασμα από αυτήν τη σύγκριση είναι ότι για τον χρήστη ενδιάμεσου επιπέδου εμπειρίας, ο οποίος ακολουθεί την risk-seeking επενδυτική στρατηγική, η προτεινόμενη μέθοδος αποφέρει μεγαλύτερο ποσοστό μέσης απόδοσης από ότι ρίσκου, το οποίο παρατηρείται αποκλειστικά για τη συγκεκριμένη μέθοδο, καθώς σε όλες τις υπόλοιπες περιπτώσεις το ποσοστό ρίσκου υπερέχει του ποσοστού απόδοσης.



Εικόνα 7-1 Μέση απόδοση και ρίσκο ανά επενδυτική στρατηγική, για την risk-seeking επενδυτική στρατηγική

Επιπροσθέτως, για το ίδιο πείραμα, ο Πίνακας 7-5 δείχνει το ποσοστό προτάσεων των εναλλακτικών επενδυτικών ενεργειών, όπως αυτές προτάθηκαν από τις συγκρινόμενες μεθόδους, στο σύνολο των πειραματικών επαναλήψεων.

Στρατηγική		Buy	Sell	Hold
Filter 0.01%		75%	0%	25%
Filter 0.1%		63.4%	0%	36.5%
MOO7030		9.6%	78.9%	11.4%
	Αρχάριος	30.5%	13.2%	56.1%
HPA	Μέσου Επιπέδου	19.6%	64.9%	15.3%
	Έμπειρος	9.2%	84.7%	6%

Πίνακας 7-5 Σύγκριση προτεινόμενων ενεργειών για τις διαφορετικές επενδυτικές στρατηγικές

Από τα αποτελέσματα αυτά βλέπουμε ότι οι στρατηγικές κανόνων φίλτρων, στο συγκεκριμένο πείραμα, τείνουν να προτείνουν κυρίως την ενέργεια αγοράς μεριδίων της μετοχής και η πολυκριτηριακή μέθοδος προτείνει κυρίως την ενέργεια της πώλησης. Η προτεινόμενη μέθοδος παρουσιάζει μεταβλητά ποσοστά προδιαγραφών ανά ενέργεια, τα οποία μεταβάλλονται σύμφωνα με την εμπειρία του χρήστη και την αντίστοιχη ανάδραση που προσομοιώθηκε ακολουθώντας τα χαρακτηριστικά του.

7.4.3 Σύγκριση στρατηγικών

Το επόμενο πείραμα της διαδικασίας αξιολόγησης εστιάζει στην αλληλεπίδραση μεταξύ του χρήστη και της προτεινόμενης μεθόδου. Σκοπός είναι να αξιολογήσουμε την επίδραση που έχουν διαφορετικές συμπεριφορές χρηστών στις παραγόμενες προδιαγραφές και να εξετάσουμε την εξέλιξη της σύγκλισης των παραγόμενων προδιαγραφών προς τις προτιμήσεις του χρήστη, οι οποίες έμμεσα εισάγονται από την παρεχόμενη ανάδραση.

Ως βασική μετρική σύγκρισης για το πείραμα αυτό χρησιμοποιήθηκε το ποσοστό αρνητικής ανάδρασης, δηλαδή ο ρυθμός με τον οποίο αυξάνεται ή μειώνεται η απόρριψη των παραγόμενων προδιαγραφών από τον χρήστη. Η εξέλιξη του

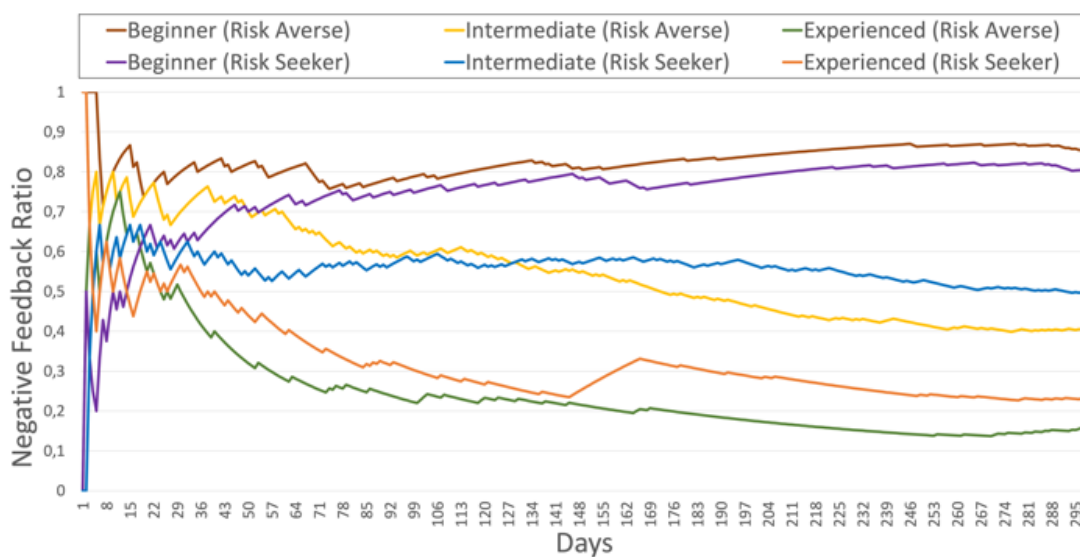
ποσοστού αρνητικής ανάδρασης χρήστη, στο σύνολο των επαναλήψεων που εκτελούνται σε αυτό το πείραμα, θεωρείται ως μία μετρική αποδοχής των επενδυτικών προτάσεων από την πλευρά του χρήστη. Μιας και το σύστημα εκπαιδεύεται αξιοποιώντας την παρεχόμενη ανάδραση, ο αριθμός των απορριπτόμενων προδιαγραφών αναμένεται να μειώνεται με την πάροδο του χρόνου και την αύξηση των επαναλήψεων, υποδηλώνοντας με αυτήν τη μείωση ότι το σύστημα επιτυγχάνει την έγκυρη αναπαράσταση των προτιμήσεων του χρήστη στις παραγόμενες προδιαγραφές.

Η Εικόνα 7-2 συγκεντρώνει την εξέλιξη του ποσοστού αρνητικής ανάδρασης για τους έξι χρήστες διαφορετικού επιπέδου εμπειρίας και διαφορετικής επενδυτικής στρατηγικής βάσει ρίσκου, τους χρήστες που ακολουθούν μια risk seeking στρατηγική και τους χρήστες που ακολουθούν μια risk averse στρατηγική. Σε αυτό το διάγραμμα δεν συμπεριλαμβάνονται τα υπόλοιπα τρία προφίλ χρηστών που ακολουθούν τη στρατηγική που επιλέγει την ενέργεια με το βέλτιστο συνδυασμό απόδοσης και ρίσκου. Η στρατηγική αυτή συνάδει με την προεπιλεγμένη στρατηγική του προδιαγραφικού μηχανισμού. Κατά συνέπεια η προσομοίωση της ανάδρασης αυτών των χρηστών είναι συνεχώς θετική.

Για όλους τους τύπους χρηστών που συμμετέχουν στο πείραμα, το ποσοστό αρνητικής ανάδρασης συγκλίνει σε ένα συγκεκριμένο σημείο για κάθε προφίλ χρηστών. Το σημείο σύγκλισης αντιπροσωπεύει το σημείο ισορροπίας ανάμεσα στις προτιμήσεις του χρήστη πάνω στις υποψήφιες ενέργειες, οι οποίες εκφράζονται μέσω της επιλεγμένης στρατηγικής που ακολουθεί, και το κατά πόσο κάθε ενέργεια είναι βέλτιστη ως προς τα προεπιλεγμένα κριτήρια της απόδοσης και του ρίσκου.

Όταν το ποσοστό αρνητικής ανάδρασης φτάσει σε αυτό το σημείο, στη συνέχεια των επαναλήψεων διατηρεί αυτήν την τιμή, υποδηλώνοντας ότι ο χρήστης από εκείνο το σημείο και έπειτα παρέχει περίπου τον ίδιο αριθμό θετικών και αρνητικών αναδράσεων. Αυτό μας οδηγεί να συμπεράνουμε ότι το σύστημα έχει εκπαιδευτεί επαρκώς σύμφωνα με τις προτιμήσεις του χρήστη εξακολουθώντας να λαμβάνει υπόψιν το κατά πόσο μια λύση είναι βέλτιστη ως προς τα κριτήρια βελτιστοποίησης. Κάθε ομάδα χρηστών η οποία χαρακτηρίζεται από διαφορετικό επίπεδο εμπειρίας

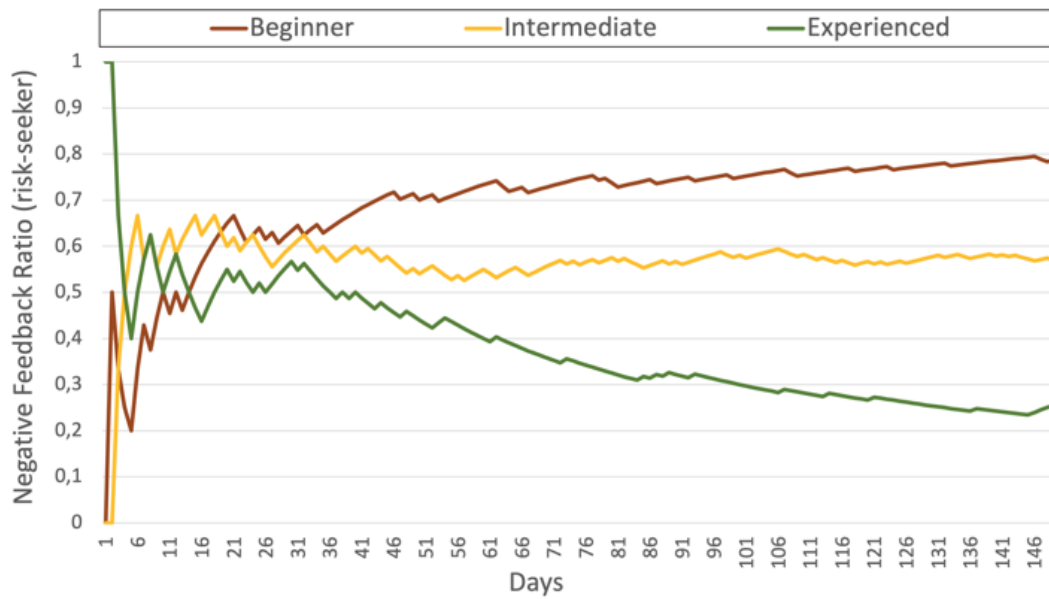
και ακολουθεί διαφορετική επενδυτική στρατηγική, ως προς το ρίσκο, συγκλίνει σε ένα διαφορετικό σημείο ισορροπίας, με διαφορετικό ρυθμό εξέλιξης.



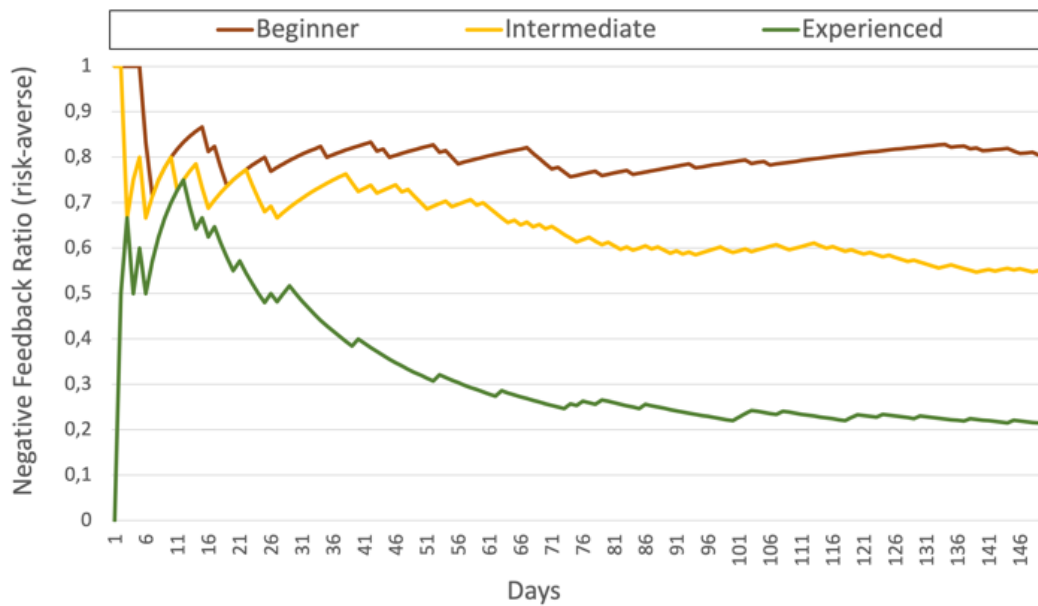
Εικόνα 7-2 Εξέλιξη ποσοστού αρνητικής ανάδρασης για τα διαφορετικά προφίλ χρηστών

Η Εικόνα 7-3 και η Εικόνα 7-4 εστιάζουν απομονωμένα στην εξέλιξη του ποσοστού αρνητικής ανάδρασης για τους χρήστες που ακολουθούν μια risk averse στρατηγική και για τους χρήστες που ακολουθούν μια risk seeking στρατηγική, αντιστοίχως. Από αυτές τις εικόνες, είναι εμφανές το γεγονός ότι το επίπεδο εμπειρίας και η επιλεγμένη επενδυτική στρατηγική του χρήστη επηρεάζουν το σημείο σύγκλισης που αντιστοιχεί στη βέλτιστη ισορροπία μεταξύ της βέλτιστης λύσης και των προτιμήσεων του χρήστη του συγκεκριμένου προφίλ.

Το κατά πόσον το σημείο ισορροπίας του ποσοστού αρνητικής ανάδρασης είναι υψηλό ή χαμηλό καθώς και το πόσο γρήγορα επιτυγχάνεται αυτό το σημείο, εξαρτάται περισσότερο από το επίπεδο εμπειρίας του χρήστη παρά από την επιλεγμένη επενδυτική στρατηγική. Και για τις δύο επενδυτικές στρατηγικές που εξετάζονται σε αυτό το πείραμα, ο έμπειρος χρήστης επιτυγχάνει με αργό ρυθμό το χαμηλότερο ποσοστό αρνητικής ανάδρασης. Το ποσοστό αυτό φαίνεται να είναι παρόμοιο για τις δύο επενδυτικές στρατηγικές, υποδηλώνοντας ότι ο έμπειρος χρήστης αναμένεται να παρέχει λιγότερες αρνητικές αναδράσεις σε βάθος χρόνου. Ακολούθως, ο αρχάριος χρήστης που ακολουθεί οποιαδήποτε από τις δύο στρατηγικές, φτάνει σε πολύ υψηλότερο σημείο ισορροπίας, πολύ πιο γρήγορα.



Εικόνα 7-3 Εξέλιξη ποσοστού αρνητικής ανάδρασης για τους risk-averse χρήστες



Εικόνα 7-4 Εξέλιξη ποσοστού αρνητικής ανάδρασης για τους risk seeking χρήστες

Ο Πίνακας 7-6 παρουσιάζει τα βασικά χαρακτηριστικά της εξέλιξης του ποσοστού αρνητικής ανάδρασης στο σύνολο των επαναλήψεων του παρόντος πειράματος, τη μέγιστη και ελάχιστη τιμή καθώς και το σημείο σύγκλισης για τα έξι διαφορετικά προφίλ χρηστών που εξετάζονται από το συγκεκριμένο πείραμα. Τα στοιχεία του πίνακα οδηγούν στο συμπέρασμα ότι η προτεινόμενη μέθοδος εξασφαλίζει την

βελτιστοποίηση των επιλεγμένων κριτηρίων της απόδοσης και του ρίσκου, δεδομένου ότι σε αντίθετη περίπτωση το ποσοστό αρνητικής ανάδρασης θα έφτανε στο μηδέν, δηλώνοντας ότι η μέθοδος ικανοποιεί αποκλειστικά τις προτιμήσεις του χρήστη, στο σύνολό τους. Ο Πίνακας 7-6 βοηθά επίσης στην κατανόηση της διαφοράς που παρουσιάζει το σημείο σύγκλισης με τη μέγιστη και την ελάχιστη τιμή για τα διαφορετικά προφίλ χρηστών.

	Αρχάριος	Ενδιάμεσου επιπέδου	Έμπειρος
Risk-averse			
Min	71.4%	30.7%	12.9%
Max	100%	100%	75%
Σημείο σύγκλισης	88.9%	31.5%	13%
Risk-seeker			
Min	33.3%	37.7%	21.3%
Max	83.8%	66.6%	100%
Σημείο σύγκλισης	83.2%	38.1%	21.7%

Πίνακας 7-6 Σύνοψη ποσοστού αρνητικής ανάδρασης για τα διαφορετικά προφίλ χρηστών

Ο Πίνακας 7-7 συνοψίζει τα ποσοστά προδιαγραφών για κάθε υποψήφια επενδυτική ενέργεια, στο σύνολο των πειραματικών επαναλήψεων. Από τα αποτελέσματα αυτά εξάγεται το συμπέρασμα ότι η επιλεγμένη στρατηγική ως προς το ρίσκο, η οποία εκφράζεται έμμεσα από την ανάδραση του χρήστη, γίνεται σεβαστή και ενσωματώνεται στην προτεινόμενη μέθοδο. Σε συνδυασμό με το επίπεδο επενδυτικής εμπειρίας του χρήστη, η επιλεγμένη στρατηγική καθοδηγεί διαφορετικά τις παραγόμενες προδιαγραφές για το κάθε προφίλ χρηστών.

	Αρχάριος	Ενδιάμεσου Επιπέδου	Έμπειρος
Risk-averse			
Αγορά	44.2%	14.2%	5.8%
Πώληση	44.7%	17.3%	7.1%
Διατήρηση Θέσης	11%	68.4%	86.9%
Risk-seeker			
Αγορά	30.5%	19.6%	9.2%
Πώληση	13.2%	64.9%	84.7%
Διατήρηση Θέσης	56.1%	15.3%	6%

Πίνακας 7-7 Σύνοψη προτεινόμενων ενεργειών για τα διαφορετικά προφίλ χρηστών

8 Συμπεράσματα και Μελλοντικές Επεκτάσεις

8.1 Συμπεράσματα

Αν και η περιγραφική και προβλεπτική αναλυτική δεδομένων έχουν κερδίσει την ερευνητική προσοχή, η προδιαγραφική αναλυτική πρόσφατα έχει αρχίσει να κερδίζει το ερευνητικό ενδιαφέρον ως το επόμενο βήμα στον τομέα της αναλυτικής δεδομένων. Η προδιαγραφική αναλυτική μπορεί να προσφέρει πιο εξειδικευμένες πληροφορίες που μπορούν να οδηγήσουν σε πιο ενημερωμένη, βασισμένη σε δεδομένα προδραστική λήψη αποφάσεων. Σύμφωνα με τη βιβλιογραφική ανασκόπηση που πραγματοποιήθηκε στο πλαίσιο της παρούσας διατριβής, στην πλειονότητα των εργασιών, η προδιαγραφική αναλυτική αντιμετωπίζεται συνήθως με μοντέλα βελτιστοποίησης τα οποία αναπτύσσονται για συγκεκριμένα γνωστικά πεδία και προβλήματα. Επιπροσθέτως, είναι εμφανής η έλλειψη μοντέλων ικανών να προσαρμοστούν δυναμικά σύμφωνα με τις ανθρώπινες προτιμήσεις και την τεχνογνωσία. Από την άλλη πλευρά, ο τομέας της μηχανικής μάθησης και πιο συγκεκριμένα ο τομέας της ενισχυτικής μάθησης, διαφαίνεται ως ένας αρκετά υποσχόμενος τομέας με δυνατότητες εφαρμογής σε προβλήματα προδιαγραφικής αναλυτικής. Η παρούσα διατριβή προτείνει μια δυναμική προσέγγιση επαυξημένης από τον άνθρωπο προδιαγραφικής αναλυτικής, η οποία αξιοποιεί τον τομέα της διαδραστικής ενισχυτικής μάθησης πολλαπλών κριτηρίων προκειμένου να επιτευχθεί βελτιστοποιημένη συνεργασία ανθρώπου-μηχανής στην προδραστική λήψη αποφάσεων.

Η προτεινόμενη προσέγγιση αξιοποιεί τα αποτελέσματα τις προβλεπτικής αναλυτικής δεδομένων, ενσωματώνοντας τις προβλέψεις στην διαδικασία λήψης απόφασης, και αναπροσαρμόζεται σύμφωνα με την ανάδραση του ανθρώπου. Εξαιτίας αυτών των επιλογών, η εφαρμογή της προτεινόμενης μεθόδου παρέχει τρία κύρια πλεονεκτήματα: (i) Το σύστημα είναι πάντα ενημερωμένο και εναρμονισμένο με τις προτιμήσεις του ανθρώπου μέσω της απλής ανάδρασης με τη μορφή έγκρισης ή απόρριψης των προτεινόμενων ενεργειών, κατά την οποία δεν απαιτείται η δομημένη και ρητή αναπαράσταση των προτιμήσεών του. (ii) Ο μηχανισμός λήψης αποφάσεων και οι προδιαγραφές που παράγονται, μέσω της συνεχούς προσαρμογής

του προδιαγραφικού μοντέλου, ακολουθούν την εξέλιξη της στρατηγικής ή των προτιμήσεων του χρήστη, διατηρώντας την ίδια υλοποίηση, χωρίς να απαιτείται εκ νέου επαναδιαμόρφωση. (iii) Ο μηχανισμός λήψης αποφάσεων παρέχει προδιαγραφές οι οποίες, με την πάροδο του χρόνου, συγκλίνουν στο σημείο επιθυμητής ισορροπίας ανάμεσα στα επιλεγμένα κριτήρια βελτιστοποίησης και της στρατηγικής ή των προτιμήσεων του χρήστη.

Η προτεινόμενη μέθοδος προδιαγραφικής αναλυτικής υλοποιήθηκε με τη μορφή ενός πληροφοριακού συστήματος προκειμένου να επιτρέψει την εφαρμογή της σε προβλήματα προδιαγραφικής αναλυτικής διαφορετικών γνωστικών πεδίων. Στο πλαίσιο της διατριβής, η προτεινόμενη προσέγγιση εφαρμόστηκε και αξιολογήθηκε στο πεδίο των χρηματιστηριακών επενδύσεων.

Τα αποτελέσματα της αξιολόγησης δείχνουν ότι η ενσωμάτωση της ανάδρασης του ανθρώπου στην προδιαγραφική αναλυτική οδηγεί σε μια βελτιστοποιημένη συνεργασία ανθρώπου-τεχνητής νοημοσύνης. Μέσω αυτής, είναι δυνατή η ικανοποίηση τόσο των στόχων του προβλήματος βελτιστοποίησης όσο και των προτιμήσεων του ανθρώπου. Επιπλέον, η πρόταση της διατριβής μπορεί να υποστηρίξει προβλήματα τα οποία βασίζονται στην προτίμηση περισσότερων του ενός ειδικών, με διαφορετικά επίπεδα τεχνογνωσίας και διαφορετικές στρατηγικές.

8.2 Μελλοντικές Επεκτάσεις

Για να είναι εφικτή η εφαρμογή της πρότασης της διατριβής είναι απαιτούμενη η διαθεσιμότητα των δεδομένων που εμπεριέχουν τη ζητούμενη πληροφορία. Η κατασκευή και η συλλογή των κατάλληλων δεδομένων που μπορούν να αποφέρουν την προηγμένη και εξειδικευμένη πληροφορία μέσω της προβλεπτικής και προδιαγραφικής αναλυτικής αποτελεί μια κρίσιμη για την επιτυχία της εφαρμογής διαδικασία που πρέπει να ακολουθήσει μια επιχείρηση.

Επιπροσθέτως, η αποδοτική δειγματοληψία των δεδομένων θα πρέπει να είναι κατάλληλα διαμορφωμένη έτσι ώστε το αναπτυσσόμενο μοντέλο προδιαγραφικής αναλυτικής που βασίζεται στην ενισχυτική μάθηση να έχει ικανό πλήθος δεδομένων εκμάθησης του περιβάλλοντος, τα οποία θα καλύπτουν τις περισσότερες πιθανές

περιπτώσεις του εξεταζόμενου προβλήματος. Ως εκ τούτου, η εφαρμογή μιας τέτοιας προσέγγισης επιφέρει σημαντικά κόστη, με κυρίαρχα τα κόστη συλλογής, επεξεργασίας και συνεχούς διασφάλισης της ποιότητας των διαθέσιμων δεδομένων, τα οποία πρέπει να ληφθούν υπόψιν.

Η μετάβαση σε πραγματικές συνθήκες προϋποθέτει την αντιμετώπιση των εννέα βασικών προκλήσεων που επιφέρει η εφαρμογή της ενισχυτικής μάθησης: (i) την εκμάθηση του πραγματικού συστήματος μέσα από περιορισμένο αριθμό δεδομένων, (ii) τις καθυστερήσεις του συστήματος, (iii) τη μεγάλη διάσταση των χώρων καταστάσεων και ενεργειών που αντιστοιχούν στο πρόβλημα, (iv) την ικανοποίηση των περιορισμών του περιβάλλοντος, (v) την πιθανώς μερική παρατηρησιμότητα, (vi) τη μη-στατικότητα, (vii) μια ενδεχομένως ανεπαρκώς ορισμένη συνάρτηση ανταμοιβής, (viii) την παραγωγή αποτελεσμάτων σε πραγματικό χρόνο και (ix) τη δυνατότητα επεξήγησης της πολιτικής του πράκτορα (Dulac-Arnold, et al., 2021).

Η πρόταση της διατριβής σε συνδυασμό με τις εξελιγμένες υπολογιστικές τεχνολογίες που είναι διαθέσιμες μπορούν να υποστηρίξουν προβλήματα προδιαγραφικής αναλυτικής τα οποία αναπαρίστανται από πολύπλοκα περιβάλλοντα που περιέχουν πολλά διαφορετικά ανεπιθύμητα γεγονότα και εναλλακτικά υπο-γραφήματα ενεργειών. Υπό αυτό το πρίσμα, θα μπορούσαν να επιλυθούν προβλήματα που εμπεριέχουν πολλαπλούς, διαφορετικής σημαντικότητας σκοπούς της επιχείρησης. Τέτοιου είδους προβλήματα μπορούν να επιλυθούν με την επέκταση της προτεινόμενης μεθόδου με τεχνικές της ιεραρχικής ενισχυτικής μάθησης (Hierarchical Reinforcement Learning - HRL). Η ιεραρχική ενισχυτική μάθηση βασίζεται στην ανάπτυξη ιεραρχικών πολιτικών. Με αυτήν τη λογική, επιτρέπει σε πολιτικές ανώτερου επιπέδου να εστιάζουν σε υψηλότερου επιπέδου στόχους, με τις υπο-πολιτικές τους να αναλαμβάνουν τον λεπτομερή έλεγχο των απαιτούμενων ενεργειών (Arulkumaran et al., 2017).

Οι παραδοσιακές μέθοδοι ενισχυτικής μάθησης υποθέτουν την δυνατότητα πλήρους παρατηρησιμότητας του περιβάλλοντος του προβλήματος. Κάτι τέτοιο όμως δεν είναι πάντα εφικτό σε πραγματικές συνθήκες. Για την αντιμετώπιση τέτοιων προβλημάτων, θα μπορούσε να ερευνηθεί η αξιοποίηση των μερικώς

παρατηρήσιμων μαρκοβιανών διαδικασιών απόφασης στη μοντελοποίηση της προτεινόμενης μεθόδου.

Επιπλέον, σε προβλήματα μεγάλου χώρου καταστάσεων και ενεργειών απαιτείται σημαντικός χρόνος εκπαίδευσης, ο οποίος επηρεάζει τον χρόνο παραγωγής προδιαγραφών. Η έγκαιρη παραγωγή προδιαγραφών αποτελεί μία κρίσιμη συνθήκη για την επιτυχία της προδιαγραφικής αναλυτικής. Μια προδιαγραφή που λαμβάνεται έπειτα από την εκδήλωση των προβλεπόμενων γεγονότων προσφέρει ελάχιστη αξία στην επιχείρηση. Για την διαχείριση τέτοιων προβλημάτων και την παραλληλοποίηση της αξιολόγησης των υποψήφιων πολιτικών, μπορεί να ερευνηθεί ο συνδυασμός της πρότασης της διατριβής με τις τεχνικές της ενισχυτικής μάθησης πολλαπλών πρακτόρων και τη μεταφορά μάθησης (Transfer Learning).

Ένα ακόμη σύνολο κρίσιμων προκλήσεων για την επιτυχή εφαρμογή της πρότασης της διατριβής αποτελούν οι προκλήσεις που συσχετίζονται με την ανάδραση του ανθρώπου. Η ανάπτυξη συστημάτων συνεργασίας ανθρώπου τεχνητής νοημοσύνης ενδέχεται να παρουσιάζει απρόσμενη συμπεριφορά η οποία μπορεί να είναι ενοχλητική, προσβλητική ή ακόμη και επικίνδυνη για τους ανθρώπους. Σε κατεύθυνση ανάλογη με αυτήν της πρότασης της διατριβής, οι διαδραστικές προσεγγίσεις ενισχυτικής μάθησης πρέπει να επιδεικνύουν επεξηγήσιμη συμπεριφορά, σύμφωνη με τις προθέσεις του ανθρώπου και να επιτρέπουν την ξεκάθαρη με αυτόν επικοινωνία.

Ακολούθως, η πρόταση της διατριβής επηρεάζεται σαφώς από την κούραση και την επίδραση που αυτή έχει στους ανθρώπους και κατ' επέκταση στην ποιότητα και την ποσότητα της ανάδρασης που αυτοί παρέχουν. Έχει παρατηρηθεί ότι οι άνθρωποι τείνουν να μειώνουν την ποσότητα ανάδρασης που δίνουν με την πάροδο του χρόνου και παράλληλα να παρέχουν ανάδραση χαμηλότερης ποιότητας. Επιπροσθέτως, η γνώση που κατέχει ο άνθρωπος σχετικά με το περιβάλλον του προβλήματος στο οποίο καλείται να δώσει την ανάδραση επηρεάζει εξίσου την ποιότητα και την εγκυρότητα της πληροφορίας που θα ενσωματωθεί στο προδιαγραφικό μοντέλο. Η πρόταση της διατριβής βασίζεται στην αξιοποίηση της αξιολογικής ανάδρασης από τον άνθρωπο, η οποία επηρεάζεται από την γνώση και την διάθεση του ανθρώπου

να παρέχει ανάδραση. Κατά συνέπεια, θα πρέπει να αναπτυχθούν περαιτέρω πειράματα προκειμένου να καταγραφεί, να ποσοτικοποιηθεί και να αξιολογηθεί η επίδραση των χαρακτηριστικών της ανάδρασης στην προτεινόμενη προσέγγιση.

Οι εξελίξεις στην ρομποτική και την έρευνα της τεχνητής νοημοσύνης μπορεί σύντομα να οδηγήσουν στην αντικατάσταση του χειρονακτικού εργατικού δυναμικού από αντίστοιχα μηχανήματα. Αντιθέτως, στη λήψη αποφάσεων απαιτείται αντίληψη, κριτική ικανότητα και λογική, στις οποίες, συνήθως υπερέχει ο άνθρωπος, γεγονός που δυσκολεύει την αυτοματοποίησή της (Whittlestone et al., 2021). Περαιτέρω επεκτάσεις της πρότασης της διατριβής οι οποίες αντιμετωπίζουν τις προκλήσεις της ανθρώπινης αλληλεπίδρασης και επιτρέπουν την γενίκευση της μεθόδου σε περισσότερα γνωστικά πεδία μπορούν να οδηγήσουν στην αυτοματοποιημένη προδιαγραφική αναλυτική και κατά συνέπεια την αυτοματοποίηση της οδηγούμενης από δεδομένα λήψης αποφάσεων.

Η μελλοντική έρευνα της παρούσας πρότασης θα επικεντρωθεί στη διερεύνηση της επίδρασης της σπανιότητας και της ακρίβειας της ανθρώπινης ανατροφοδότησης στην αξιοπιστία της προτεινόμενης προσέγγισης. Πέρα από αυτό, η μελλοντική εργασία θα προσανατολιστεί προς τις ακόλουθες κατευθύνσεις: Πρώτον, η προτεινόμενη προσέγγιση θα εφαρμοστεί και αξιολογηθεί στο πλαίσιο διαφορετικών γνωστικών τομέων. Κάποια προκαταρκτικά αποτελέσματα αυτής της προσπάθειας έχουν ήδη καταγραφεί στους τομείς της προβλεπτικής συντήρησης [c4] και της εφοδιαστικής (logistics) [c5]. Δεύτερον, το ανεπτυγμένο πληροφοριακό σύστημα θα ενσωματωθεί σε έναν έξυπνο ψηφιακό βοηθό προκειμένου να διευκολυνθεί η αλληλεπίδραση ανθρώπου-προδιαγραφικής αναλυτικής μέσω φωνής έτσι ώστε να υποστηριχθεί η συνεργασία ανθρώπου-μηχανής.

9 Αναφορές

Achenbach, A., & Spinler, S. (2018). Prescriptive analytics in airline operations: Arrival time prediction and cost index optimization for short-haul flights. *Operations Research Perspectives*, 5, 265-279.

Acito, F., & Khatri, V. (2014). Business analytics: Why now and what next?. *Business Horizons*, 57(5), 565-570.

Agostinelli, F., Hocquet, G., Singh, S., & Baldi, P. (2018). From reinforcement learning to deep reinforcement learning: An overview. *Braverman readings in machine learning. key ideas from inception to current state*, 298-328.

Akerkar, B. (2013). Advanced data analytics for business. In Akerkar B (ed) *Big data computing*. CRC Press, Boca Raton, pp 373–397.

Akter, S., Bandara, R., Hani, U., Wamba, S. F., Foropon, C., & Papadopoulos, T. (2019). Analytics-based decision-making for service systems: A qualitative study and agenda for future research. *International Journal of Information Management*, 48, 85-95.

Alagoz, O., Hsu, H., Schaefer, A. J., & Roberts, M. S. (2010). Markov decision processes: a tool for sequential decision making under uncertainty. *Medical Decision Making*, 30(4), 474-483.

Almada, M. (2019, June). Human intervention in automated decision-making: Toward the construction of contestable systems. In *Proceedings of the Seventeenth International Conference on Artificial Intelligence and Law* (pp. 2-11).

Almahdi, S., & Yang, S. Y. (2017). An adaptive portfolio trading system: A risk-return portfolio optimization using recurrent reinforcement learning with expected maximum drawdown. *Expert Systems with Applications*, 87, 267-279.

Anderson, R. N. (2017, December). 'Petroleum Analytics Learning Machine' for optimizing the Internet of Things of today's digital oil field-to-refinery petroleum system. In *Big Data (Big Data), 2017 IEEE International Conference on* (pp. 4542-4545). IEEE.

Araujo, T., Helberger, N., Kruike-meier, S., & de Vreese, C. H. (2020). In AI we trust? Perceptions about automated decision-making by artificial intelligence. *AI & SOCIETY*, 35(3), 611-623.

Aref, M., ten Cate, B., Green, T. J., Kimelfeld, B., Olteanu, D., Pasalic, E., ... & Washburn, G. (2015, May). Design and implementation of the LogicBlox system. In *Proceedings of the 2015 ACM SIGMOD International Conference on Management of Data* (pp. 1371-1382). ACM.

Arulkumaran, K., Deisenroth, M. P., Brundage, M., & Bharath, A. A. (2017). A brief survey of deep reinforcement learning. arXiv preprint arXiv:1708.05866.

Arumugam, D., Lee, J. K., Saskin, S., & Littman, M. L. (2019). Deep reinforcement learning from policy-dependent human feedback. arXiv preprint arXiv:1902.04257.

Arzate Cruz, C., & Igarashi, T. (2020, July). A survey on interactive reinforcement learning: design principles and open challenges. In *Proceedings of the 2020 ACM designing interactive systems conference* (pp. 1195-1209).

Ayhan, S., Costas, P., & Samet, H. (2018, November). Prescriptive analytics system for long-range aircraft conflict detection and resolution. In *Proceedings of the 26th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems* (pp. 239-248). ACM.

Bäck, T., Fogel, D. B., & Michalewicz, Z. (1997). *Handbook of evolutionary computation*. CRC Press.

Bailer-Jones, C., & Smith, K. (2011). Combining probabilities. *Data Processing and Analysis Consortium (DPAS), GAIA-C8-TN-MPIA-CBJ-053*.

Barbosa, M. W., Vicente, A. D. L. C., Ladeira, M. B., & Oliveira, M. P. V. D. (2018). Managing supply chain resources with Big Data Analytics: a systematic review. *International Journal of Logistics Research and Applications*, 21(3), 177-200.

Basu, A. T. A. N. U.: Five pillars of prescriptive analytics success. *Analytics magazine* 8, 8-12 (2013).

Bates, J. (2012). John Bates of Progress explains how complex event processing works and how it can simplify the use of algorithms for finding and capturing trading opportunities. Fix Global Trading, retrieved May, 14.

Batrinca, B., & Treleaven, P. C. (2015). Social media analytics: a survey of techniques, tools and platforms. *Ai & Society*, 30(1), 89-116.

Baur, A., Klein, R., & Steinhardt, C. (2014). Model-based decision support for optimal brochure pricing: applying advanced analytics in the tour operating industry. *OR spectrum*, 36(3), 557-584.

Bayrak, T. (2015). A review of business analytics: A business enabler or another passing fad. *Procedia-Social and Behavioral Sciences*, 195, 230-239.

Berk, L., Bertsimas, D., Weinstein, A. M., & Yan, J. (2019). Prescriptive analytics for human resource planning in the professional services industry. *European Journal of Operational Research*, 272(2), 636-641.

Bertsimas, D., & Kallus, N. (2014). From predictive to prescriptive analytics. arXiv preprint arXiv:1402.5481.

Bertsimas, D., & Van Parys, B. (2017). Bootstrap Robust Prescriptive Analytics. arXiv preprint arXiv:1711.09974.

Bertsimas, D., Brown, D. B., & Caramanis, C. (2011). Theory and applications of robust optimization. *SIAM review*, 53(3), 464-501.

Biegler, L. T., Yang, X., & Fischer, G. A. G. (2015). Advances in sensitivity-based nonlinear model predictive control and dynamic real-time optimization. *Journal of Process Control*, 30, 104-116.

Birge, J. R., & Louveaux, F. (2011). Introduction to stochastic programming. Springer Science & Business Media.

Bleiholder, J., & Naumann, F. (2009). Data fusion. *ACM computing surveys (CSUR)*, 41(1), 1-41.

Bousdekis, A., Lepenioti, K., Apostolou, D., & Mentzas, G. (2021). A Review of Data-Driven Decision-Making Methods for Industry 4.0 Maintenance Applications. *Electronics*, 10(7), 828.

Bousdekis, A., Papageorgiou, N., Magoutas, B., Apostolou, D., & Mentzas, G. (2018). Enabling condition-based maintenance decisions with proactive event-driven computing. *Computers in Industry*, 100, 173-183.

Brodsky, A., Shao, G., Krishnamoorthy, M., Narayanan, A., Menascé, D., & Ak, R. (2017). Analysis and optimization based on reusable knowledge base of process performance models. *The International Journal of Advanced Manufacturing Technology*, 88(1-4), 337-357.

Brynjolfsson, E., Hitt, L. M., & Kim, H. H. (2011). Strength in numbers: How does data-driven decisionmaking affect firm performance?. Available at SSRN 1819486.

Bustos, O., & Pomares-Quimbaya, A. (2020). Stock market movement forecast: A systematic review. *Expert Systems with Applications*, 156, 113464.

Cabrera, D., Rubilar, R., & Cubillos, C. (2019). Resilience in the decision-making of an artificial autonomous system on the stock market. *IEEE Access*, 7, 145246-145258.

Carapuço, J., Neves, R., & Horta, N. (2018). Reinforcement learning applied to Forex trading. *Applied Soft Computing*, 73, 783-794.

Ceravolo, P., & Zavatarelli, F. (2015, May). Knowledge acquisition in process intelligence. In *Information and Communication Technology Research (ICTRC), 2015 International Conference on* (pp. 218-221). IEEE.

Chakrabarti, S., Ester, M., Fayyad, U., Gehrke, J., Han, J., Morishita, S., ... & Wang, W. (2006). Data mining curriculum: A proposal (Version 1.0). *Intensive Working Group of ACM SIGKDD Curriculum Committee*, 140.

Chalamalla, A., Ilyas, I. F., Ouzzani, M., & Papotti, P. (2014, June). Descriptive and prescriptive data cleaning. In *Proceedings of the 2014 ACM SIGMOD international conference on Management of data* (pp. 445-456). ACM.

Chauhan, D., & Bansal, K. L. (2017). Using the Advantages of NoSQL: A case study on MongoDB. *International Journal on Recent and Innovation Trends in Computing and Communication*, 5(2), 90-93.

Cho, M., Song, S. K., Weber, J., Jung, H., & Lee, M. (2015). Prescriptive Analytics for Planning Research-Performance Strategy. In *Computer Science and its Applications* (pp. 1123-1129). Springer, Berlin, Heidelberg.

Chong, E. K. P., & Zak, S. H. (2008). *An Introduction to Optimization* (Wiley-Interscience Series in Discrete Mathematics and Optimization).

Christ, M., Krumeich, J., & Kempa-Liehr, A. W. (2016, September). Integrating predictive analytics into complex event processing by using conditional density estimations. In *Enterprise Distributed Object - Computing Workshop (EDOCW), 2016 IEEE 20th International* (pp. 1-8). IEEE.

Christiano, P. F., Leike, J., Brown, T., Martic, M., Legg, S., & Amodei, D. (2017). Deep reinforcement learning from human preferences. *Advances in neural information processing systems*, 30.

Cruz, F., Magg, S., Weber, C., & Wermter, S. (2016). Training agents with interactive reinforcement learning and contextual affordances. *IEEE Transactions on Cognitive and Developmental Systems*, 8(4), 271-284.

Cruz, F., Magg, S., Nagai, Y., & Wermter, S. (2018). Improving interactive reinforcement learning: What makes a good teacher?. *Connection Science*, 30(3), 306-325.

Cugola, G., Margara, A., Matteucci, M., & Tamburrelli, G. (2015). Introducing uncertainty in complex event processing: model, implementation, and validation. *Computing*, 97(2), 103-144.

Davenport, T., & Harris, J. (2017). *Competing on analytics: Updated, with a new introduction: The new science of winning*. Harvard Business Press.

de Aguiar, M., Greve, F., & Costa, G. (2017, July). PrescStream: A Framework for Streaming Soft Real-Time Predictive and Prescriptive Analytics. In *International Conference on Computational Science and Its Applications* (pp. 325-341). Springer, Cham.

Delen, D., & Ram, S. (2018). Research challenges and opportunities in business analytics. *Journal of Business Analytics*, 1(1), 2-12.

den Hertog, D., & Postek, K. (2016). Bridging the gap between predictive and prescriptive analytics-new optimization methodology needed. Technical report, Tilburg University, Netherlands, 2016. Available at: http://www.optimization-online.org/DB_HTML/2016/12/5779.html.

Deshpande, P. S., Sharma, S. C., & Peddoju, S. K. (2019). Predictive and prescriptive analytics in big-data era. In *Security and data storage aspect in cloud computing* (pp. 71-81). Springer, Singapore.

Dodge, Y. (Ed.). (2006). *The Oxford dictionary of statistical terms*. Oxford University Press.

Domingos, E. F., Burguillo, J. C., & Lenaerts, T. (2017). Reactive Versus Anticipative Decision Making in a Novel Gift-Giving Game. In *AAAI* (pp. 4399-4405).

Dey, S., Gupta, N., Pathak, S., Kela, D. H., & Datta, S. (2019). Data-Driven Design Optimization for Industrial Products. In *Optimization in Industry* (pp. 253-267). Springer, Cham.

Du, F., Malik, S., Koh, E., & Theocharous, G. (2018, April). Interactive Campaign Planning for Marketing Analysts. In *Extended Abstracts of the 2018 CHI Conference on Human Factors in Computing Systems* (p. LBW006). ACM.

Du, F., Plaisant, C., Spring, N., & Shneiderman, B. (2016, October). EventAction: Visual analytics for temporal event sequence recommendation. In *Visual Analytics Science and Technology (VAST), 2016 IEEE Conference on* (pp. 61-70). IEEE.

Duan, Y., Edwards, J. S., & Dwivedi, Y. K. (2019). Artificial intelligence for decision making in the era of Big Data—evolution, challenges and research agenda. *International Journal of Information Management*, 48, 63-71.

Duan, L., & Xiong, Y. (2015). Big data analytics and business analytics. *Journal of Management Analytics*, 2(1), 1-21.

Dulac-Arnold, G., Levine, N., Mankowitz, D. J., Li, J., Paduraru, C., Gowal, S., & Hester, T. (2021). Challenges of real-world reinforcement learning: definitions, benchmarks and analysis. *Machine Learning*, 110(9), 2419-2468.

- Elgendy, N., & Elragal, A. (2016). Big data analytics in support of the decision making process. *Procedia Computer Science*, 100, 1071-1084.
- Elgendy, N., Elragal, A., & Päivärinta, T. (2021). DECAS: a modern data-driven decision theory for big data and analytics. *Journal of Decision Systems*, 1-37.
- Engel, Y., Etzion, O., Feldman, Z.: A basic model for proactive event-driven computing. *Proceedings of the 6th ACM International Conference on Distributed Event-Based Systems - DEBS '12*. (2012).
- Erl T, Khattak W, Buhler P (2015) *Big data fundamentals: concepts, drivers & techniques*. Prentice Hall, Upper Saddle River.
- Etzion, O., Niblett, P., & Luckham, D. C. (2011). *Event processing in action*. Greenwich: Manning.
- Fawaz, I. Hassan et al. (Mar. 2019). Deep learning for time series classification: a review. *Data Mining and Knowledge Discovery*.
- Feuerriegel, S., & Prendinger, H. (2016). News-based trading strategies. *Decision Support Systems*, 90, 65-74.
- Fifield, S. G., Power, D. M., & Donald Sinclair, C. (2005). An analysis of trading strategies in eleven European stock markets. *The European Journal of Finance*, 11(6), 531-548.
- Fischer, T. G. (2018). Reinforcement learning in financial markets-a survey (No. 12/2018). *FAU Discussion Papers in Economics*.
- Forgy, C. L. (1989). Rete: A fast algorithm for the many pattern/many object pattern match problem. In *Readings in Artificial Intelligence and Databases* (pp. 547-559). Morgan Kaufmann.
- García, J., Borrajo, F., & Fernández, F. (2012). Reinforcement learning for decision-making in a business simulator. *International Journal of Information Technology & Decision Making*, 11(05), 935-960.)
- García-Galicia, M., Carsteanu, A. A., & Clempner, J. B. (2019). Continuous-time reinforcement learning approach for portfolio management with time penalization. *Expert Systems with Applications*, 129, 27-36.

Gandhmal, D. P., & Kumar, K. (2019). Systematic analysis and review of stock market prediction techniques. *Computer Science Review*, 34, 100190.

Gardner, J. R., Kusner, M. J., Xu, Z. E., Weinberger, K. Q., & Cunningham, J. P. (2014, June). Bayesian Optimization with Inequality Constraints. In *ICML* (pp. 937-945).

Ghoniem, A., Ali, A. I., Al-Salem, M., & Khallouli, W. (2017). Prescriptive analytics for FIFA World Cup lodging capacity planning. *Journal of the Operational Research Society*, 68(10), 1183-1194.

Ghosh, R., Gupta, A., Chattopadhyay, S., Banerjee, A., & Dasgupta, K. (2016, June). CoCOA: a framework for comparing aggregate client operations in BPO services. In *Services Computing (SCC), 2016 IEEE International Conference on* (pp. 539-546). IEEE.

Giurgiu, I., Wiesmann, D., Bogojeska, J., Lanyi, D., Stark, G., Wallace, R. B., ... & Hidalgo, A. A. (2017). On the adoption and impact of predictive analytics for server incident reduction. *IBM Journal of Research and Development*, 61(1), 9-98.

Goyal, A., Aprilia, E., Janssen, G., Kim, Y., Kumar, T., Mueller, R., ... & Zhang, R. (2016). Asset health management using predictive and prescriptive analytics for the electric power grid. *IBM Journal of Research and Development*, 60(1), 4-1.

Griffith, S., Subramanian, K., Scholz, J., Isbell, C. L., & Thomaz, A. L. (2013). Policy shaping: Integrating human feedback with reinforcement learning. *Advances in neural information processing systems*, 26.

Gröger, C., Schwarz, H., & Mitschang, B. (2014, May). Prescriptive analytics for recommendation-based business process optimization. In *International Conference on Business Information Systems* (pp. 25-37). Springer, Cham.

Gudivada, V. N., Irfan, M. T., Fathi, E., & Rao, D. L. (2016). Cognitive analytics: Going beyond big data analytics and machine learning. In *Handbook of statistics* (Vol. 35, pp. 169-205). Elsevier.

Gupta, R., Gupta, H., & Mohania, M. (2012, December). Cloud computing and big data analytics: what is new from databases perspective?. In *International conference on big data analytics* (pp. 42-61). Springer, Berlin, Heidelberg.

Habeeb, R. A. A., Nasaruddin, F., Gani, A., Hashem, I. A. T., Ahmed, E., & Imran, M. (2018). Real-time big data processing for anomaly detection: A Survey. *International Journal of Information Management*.

Hagerty, J. (2017). *planning guide for data and Analytics*. Gartner Inc, 13.

Han, J., Haihong, E., Le, G., & Du, J. (2011, October). Survey on NoSQL database. In *2011 6th international conference on pervasive computing and applications* (pp. 363-366). IEEE.

Harikumar, H., Rana, S., Gupta, S., Nguyen, T., Kaimal, R., & Venkatesh, S. (2018a, November). Differentially Private Prescriptive Analytics. In *2018 IEEE International Conference on Data Mining (ICDM)* (pp. 995-1000). IEEE.

Harikumar, H., Rana, S., Gupta, S., Nguyen, T., Kaimal, R., & Venkatesh, S. (2018b, June). Prescriptive Analytics Through Constrained Bayesian Optimization. In *Pacific-Asia Conference on Knowledge Discovery and Data Mining* (pp. 335-347). Springer, Cham.

Hariri, R. H., Fredericks, E. M., & Bowers, K. M. (2019). Uncertainty in big data analytics: survey, opportunities, and challenges. *J Big Data*.

Heuillet, A., Couthouis, F., & Díaz-Rodríguez, N. (2021). Explainability in deep reinforcement learning. *Knowledge-Based Systems*, 214, 106685.

Hindle, G., Kunc, M., Mortensen, M., Oztekin, A., & Vidgen, R. (2020). Business analytics: Defining the field and identifying a research agenda. *European Journal of Operational Research*, 281(3), 483-490.

Hirchoua, B., Ouhbi, B., & Frikh, B. (2021). Deep reinforcement learning based trading agents: Risk curiosity driven learning for financial rules-based policy. *Expert Systems with Applications*, 170, 114553.

Hirzel, M., Soulé, R., Schneider, S., Gedik, B., & Grimm, R. (2014). A catalog of stream processing optimizations. *ACM Computing Surveys (CSUR)*, 46(4), 46.

Hong, S., Shin, S., Kim, Y. M., Seon, C. N., ho Um, J., & Song, S. K. (2015, August). Design of Marketing Scenario Planning Based on Business Big Data Analysis. In *International Conference on HCI in Business* (pp. 585-592). Springer, Cham.

Hora, M. T., Bouwma-Gearhart, J., & Park, H. J. (2017). Data driven decision-making in the era of accountability: Fostering faculty data cultures for learning. *The Review of Higher Education*, 40(3), 391-426.

Howick, S., & Ackermann, F. (2011). Mixing OR methods in practice: Past, present and future directions. *European Journal of Operational Research*, 215(3), 503-511.

Huang, T., Bergman, D., & Gopal, R. (2018). Predictive and Prescriptive Analytics for Location Selection of Add-on Retail Products. arXiv preprint arXiv:1804.01182.

Huber, T., Schiller, D., & André, E. (2019, September). Enhancing explainability of deep reinforcement learning through selective layer-wise relevance propagation. In *Joint German/Austrian Conference on Artificial Intelligence (Künstliche Intelligenz)* (pp. 188-202). Springer, Cham.

Hupfeld, D., Maccioni, R., Sesemann, R., & Ravazzolo, D. (2016). Fleet asset capacity analysis and revenue management optimization using advanced prescriptive analytics. *Journal of Revenue and Pricing Management*, 15(6), 516-522.

Ito, S., & Fujimaki, R. (2017, August). Optimization beyond prediction: Prescriptive price optimization. In *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 1833-1841). ACM.

Ismagilova, E., Hughes, L., Dwivedi, Y. K., & Raman, K. R. (2019). Smart cities: Advances in research—An information systems perspective. *International Journal of Information Management*, 47, 88-100.

Jank, M. H., Dölle, C., & Schuh, G. (2018, November). Product Portfolio Design Using Prescriptive Analytics. In *Congress of the German Academic Association for Production Technology* (pp. 584-593). Springer, Cham.

Jerry, B. (2005). *Discrete event system simulation*. Pearson Education India.

Jiang, C., Jensen, D. L., Cao, H., & Kumar, T. (2010, July). Building business intelligence applications having prescriptive and predictive capabilities. In *International Conference on Web-Age Information Management* (pp. 376-385). Springer, Berlin, Heidelberg.

Jiang, Z., Xu, D., & Liang, J. (2017). A deep reinforcement learning framework for the financial portfolio management problem. arXiv preprint arXiv:1706.10059.

Johnson, J. G., & Busemeyer, J. R. (2010). Decision making under risk and uncertainty. *Wiley Interdisciplinary Reviews: Cognitive Science*, 1(5), 736-749.

Kahneman, D. (1979). Prospect theory: An analysis of decisions under risk. *Econometrica*, 47, 278.

Katal, A., Wazid, M., & Goudar, R. H. (2013, August). Big data: issues, challenges, tools and good practices. In 2013 Sixth international conference on contemporary computing (IC3) (pp. 404-409). IEEE.

Kawas, B., Squillante, M. S., Subramanian, D., & Varshney, K. R. (2013, December). Prescriptive analytics for allocating sales teams to opportunities. In Data Mining Workshops (ICDMW), 2013 IEEE 13th International Conference on (pp. 211-218). IEEE.

Koivisto, J., & Hamari, J. (2019). The rise of motivational information systems: A review of gamification research. *International Journal of Information Management*, 45, 191-210.

Konda, V. R., & Tsitsiklis, J. N. (2000). Actor-critic algorithms. In *Advances in neural information processing systems* (pp. 1008-1014).

Konstantinou, I., Angelou, E., Boumpouka, C., Tsoumakos, D., & Koziris, N. (2011, October). On the elasticity of nosql databases over cloud management platforms. In *Proceedings of the 20th ACM international conference on Information and knowledge management* (pp. 2385-2388).

Khamis, M. A., & Gomaa, W. (2014). Adaptive multi-objective reinforcement learning with hybrid exploration for traffic signal control based on cooperative multi-agent framework. *Engineering Applications of Artificial Intelligence*, 29, 134-151.

Knox, W. B., & Stone, P. (2009, September). Interactively shaping agents via human reinforcement: The TAMER framework. In *Proceedings of the fifth international conference on Knowledge capture* (pp. 9-16.),

Knox, W. B., & Stone, P. (2010, May). Combining manual feedback with subsequent MDP reward signals for reinforcement learning. In *Proceedings of the 9th*

International Conference on Autonomous Agents and Multiagent Systems: volume 1-
Volume 1 (pp. 5-12).

Knox, W. B., & Stone, P. (2011, July). Augmenting reinforcement learning with human feedback. In ICML 2011 Workshop on New Developments in Imitation Learning (July 2011) (Vol. 855, p. 3).

Knox, W. B., & Stone, P. (2012, June). Reinforcement learning from simultaneous human and MDP reward. In AAMAS (pp. 475-482).

Kraus, M., Feuerriegel, S., & Oztekin, A. (2020). Deep learning in business analytics and operations research: Models, applications and managerial implications. *European Journal of Operational Research*, 281(3), 628-641.

Krening, S., & Feigh, K. M. (2018). Interaction algorithm effect on human experience with reinforcement learning. *ACM Transactions on Human-Robot Interaction (THRI)*, 7(2), 1-22.

Krumeich, J., Werth, D., & Loos, P. (2016). Prescriptive control of business processes. *Business & Information Systems Engineering*, 58(4), 261-280.

Larose, D. T., & Larose, C. D. (2015). *Data mining and predictive analytics*. John Wiley & Sons.

Larson, D., & Chang, V. (2016). A review and future direction of agile, business intelligence, analytics and data science. *International Journal of Information Management*, 36(5), 700-710.

Laude, H. (2018). France's Governmental Big Data Analytics: From Predictive to Prescriptive Using R. In *Federal Data Science* (pp. 81-94). Academic Press.

LaValle, S., Lesser, E., Shockley, R., Hopkins, M. S., & Kruschwitz, N. (2011). Big data, analytics and the path from insights to value. *MIT sloan management review*, 52(2), 21-32.

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.

Lee, D. (2013). Decision making: from neuroscience to psychiatry. *Neuron*, 78(2), 233-248.

Lee, M., Cho, M., Gim, J., Jeong, D. H., & Jung, H. (2014, June). Prescriptive analytics system for scholar research performance enhancement. In International conference on human-computer interaction (pp. 186-190). Springer, Cham.

Lee, J., Davari, H., Singh, J., & Pandhare, V. (2018). Industrial artificial intelligence for industry 4.0-based manufacturing systems. *Manufacturing letters*, 18, 20-23.

Lee, O. J., & Jung, J. E. (2017). Sequence clustering-based automated rule generation for adaptive complex event processing. *Future Generation Computer Systems*, 66, 100-109.

Leonetti, M., Iocchi, L., & Stone, P. (2016). A synthesis of automated planning and reinforcement learning for efficient, robust decision-making. *Artificial Intelligence*, 241, 103-130.

Letham, B., Karrer, B., Ottoni, G., & Bakshy, E. (2018). Constrained Bayesian optimization with noisy experiments. *Bayesian Analysis*.

Li, G., Gomez, R., Nakamura, K., & He, B. (2019). Human-centered reinforcement learning: A survey. *IEEE Transactions on Human-Machine Systems*, 49(4), 337-349.

Li, G., Whiteson, S., Knox, W. B., & Hung, H. (2018). Social interaction for efficient agent learning from human reward. *Autonomous Agents and Multi-Agent Systems*, 32(1), 1-25.

Li, Y. (2019). Reinforcement learning applications. arXiv preprint arXiv:1908.06973.

Li, Y., Zheng, W., & Zheng, Z. (2019). Deep Robust Reinforcement Learning for Practical Algorithmic Trading. *IEEE Access*, 7, 108014-108022.

Liang, Z., Chen, H., Zhu, J., Jiang, K., & Li, Y. (2018). Adversarial deep reinforcement learning in portfolio management. arXiv preprint arXiv:1808.09940.

Lin, J., Ma, Z., Gomez, R., Nakamura, K., He, B., & Li, G. (2020). A review on interactive reinforcement learning from human social feedback. *IEEE Access*, 8, 120757-120765.

Littman, M. L. (2015). Reinforcement learning improves behaviour from evaluative feedback. *Nature*, 521(7553), 445-451.

- Liu, C., Xu, X., & Hu, D. (2014). Multiobjective reinforcement learning: A comprehensive overview. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 45(3), 385-398.
- Lo, V. S., & Pachamanova, D. A. (2015). From predictive uplift modeling to prescriptive uplift analytics: A practical approach to treatment optimization while accounting for estimation risk. *Journal of Marketing Analytics*, 3(2), 79-95.
- Lu, D. W. (2017). Agent inspired trading using recurrent reinforcement learning and lstm neural networks. arXiv preprint arXiv:1707.07338.
- Lu, J., Chen, W., Ma, Y., Ke, J., Li, Z., Zhang, F., & Maciejewski, R. (2017). Recent progress and trends in predictive visual analytics. *Frontiers of Computer Science*, 11(2), 192-207.
- Luckham, D. C. (2011). *Event processing for business: organizing the real-time enterprise*. John Wiley & Sons.
- MacGlashan, J., Ho, M. K., Loftin, R., Peng, B., Wang, G., Roberts, D. L., ... & Littman, M. L. (2017, July). Interactive learning from policy-dependent human feedback. In *International Conference on Machine Learning* (pp. 2285-2294). PMLR.
- Mandinach, E. B., & Jackson, S. S. (2012). *Transforming teaching and learning through data-driven decision making*. Corwin Press.
- Marshall, B. R., Young, M. R., & Rose, L. C. (2006). Candlestick technical trading strategies: Can they create value for investors?. *Journal of Banking & Finance*, 30(8), 2303-2323.
- Martin, I. W., & Wagner, C. (2019). What is the Expected Return on a Stock?. *The Journal of Finance*, 74(4), 1887-1929.
- Martinez, E. C., Cristaldi, M. D., & Grau, R. J. (2009). Design of dynamic experiments in modeling for optimization of batch processes. *Industrial & Engineering Chemistry Research*, 48(7), 3453-3465.
- Martínez, E. C., Cristaldi, M. D., & Grau, R. J. (2013). Dynamic optimization of bioreactors using probabilistic tendency models and Bayesian active learning. *Computers & Chemical Engineering*, 49, 37-49.

Matyas, K., Nemeth, T., Kovacs, K., & Glawar, R. (2017). A procedural approach for realizing prescriptive maintenance planning in manufacturing industries. *CIRP Annals*, 66(1), 461-464.

Meisheri, H., Baniwal, V., Sultana, N. N., Ravindran, B., & Khadilkar, H. (2019). Reinforcement learning for multi-objective optimization of online decisions in high-dimensional systems. *arXiv preprint arXiv:1910.00211*.

Meng, T. L., & Khushi, M. (2019). Reinforcement Learning in Financial Markets. *Data*, 4(3), 110.

Meyn, S. (2008). *Control techniques for complex networks*. Cambridge University Press.

Mendes, P. N., Gruhl, D., Drews, C., Kau, C., Lewis, N., Nagarajan, M., ... & Welch, S. (2014, October). Sonora: a prescriptive model for message authoring on Twitter. In *International conference on Web information systems engineering* (pp. 17-31). Springer, Cham.

Mikalef, P., Pappas, I. O., Krogstie, J., & Giannakos, M. (2018). Big data analytics capabilities: a systematic literature review and research agenda. *Information Systems and e-Business Management*, 16(3), 547-578.

Mikalef, P., Pappas, I., Krogstie, J., & Pavlou, P. A. (Eds.). (2020). *Big data and business analytics: A research agenda for realizing business value*. Elsevier.

Millea, A. (2021). Deep reinforcement learning for trading—A critical survey. *Data*, 6(11), 119.

Miranker, D. P. (1987). *TREAT: a new and efficient match algorithm for AI production systems* (Doctoral dissertation, Columbia University).

Miranker, D. P., & Brant, D. A. (1990, February). An algorithmic basis for integrating production systems and large databases. In [1990] *Proceedings. Sixth International Conference on Data Engineering* (pp. 353-360). IEEE.

Mishra, N., & Silakari, S. (2012). Predictive analytics: a survey, trends, applications, opportunities & challenges. *International Journal of Computer Science and Information Technologies*, 3(3), 4434-4438.

Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G., ... & Hassabis, D. (2015). Human-level control through deep reinforcement learning. *nature*, 518(7540), 529-533.).

Močarníková, K., & Greguš, M. (2020). Conceptualization of Predictive Analytics by Literature Review. *Data-Centric Business and Applications*, 205-234.

Modigliani, F., & Pogue, G. A. (1973). An introduction to risk and return concepts and evidence.

Mohamed, N., & Al-Jaroodi, J. (2014, July). Real-time big data analytics: Applications and challenges. In *2014 international conference on high performance computing & simulation (HPCS)* (pp. 305-310). IEEE.

Mohri, M., Rostamizadeh, A., & Talwalkar, A. (2018). *Foundations of machine learning*. MIT press.

Mortenson, M. J., Doherty, N. F., & Robinson, S. (2015). Operational research from Taylorism to Terabytes: A research agenda for the analytics age. *European Journal of Operational Research*, 241(3), 583-595.

Mousheimish, R., Taher, Y., & Zeitouni, K. (2016, October). Autocep: automatic learning of predictive rules for complex event processing. In *International Conference on Service-Oriented Computing* (pp. 586-593). Springer, Cham.

Nabipour, M., Nayyeri, P., Jabani, H., Mosavi, A., & Salwana, E. (2020). Deep learning for stock market prediction. *Entropy*, 22(8), 840.

Najar, A., & Chetouani, M. (2021). Reinforcement learning with human advice: a survey. *Frontiers in Robotics and AI*, 8.

Nasrabadi, N. M. (2007). Pattern recognition and machine learning. *Journal of electronic imaging*, 16(4), 049901.

Nechifor, S., Puiu, D., Tarnauca, B., & Moldoveanu, F. (2015, May). Prescriptive analytics based autonomic networking for urban streams services provisioning. In *Vehicular Technology Conference (VTC Spring), 2015 IEEE 81st* (pp. 1-5). IEEE.

Nelson, D. M., Pereira, A. C., & De Oliveira, R. A. (2017, May). Stock market's price movement prediction with LSTM neural networks. In 2017 International joint conference on neural networks (IJCNN) (pp. 1419-1426). IEEE.

Nevmyvaka, Y., Feng, Y., & Kearns, M. (2006, June). Reinforcement learning for optimized trade execution. In Proceedings of the 23rd international conference on Machine learning (pp. 673-680).

Nguyen, T., Li, Z. H. O. U., Spiegler, V., Ieromonachou, P., & Lin, Y. (2017). Big data analytics in supply chain management: A state-of-the-art literature review. *Computers & Operations Research*.

O'Leary, D. E. (2013). Artificial intelligence and big data. *IEEE intelligent systems*, 28(2), 96-99.

Ongsulee, P., Chotchaung, V., Bamrunsi, E., & Rodcheewit, T. (2018, November). Big data, predictive analytics and machine learning. In 2018 16th International Conference on ICT and Knowledge Engineering (ICT&KE) (pp. 1-6). IEEE.

Osmani, V., Forti, S., Mayora, O., & Conforti, D. (2017). Enabling Prescription-based Health Apps. arXiv preprint arXiv:1706.09407.

Padakandla, S. (2021). A survey of reinforcement learning algorithms for dynamically varying environments. *ACM Computing Surveys (CSUR)*, 54(6), 1-25.

Pal, A., & Ceglarek, D. (2013). Modeling of decision making process for product service failure diagnosis. *Procedia CIRP*, 11, 32-37.

Pape, T. (2016). Prioritising data items for business analytics: Framework and application to human resources. *European Journal of Operational Research*, 252(2), 687-698.

Pednault, E., Abe, N., & Zadrozny, B. (2002, July). Sequential cost-sensitive decision making with reinforcement learning. In Proceedings of the eighth ACM SIGKDD international conference on Knowledge discovery and data mining (pp. 259-268).

Peters, M., Ketter, W., Saar-Tsechansky, M., & Collins, J. (2013). A reinforcement learning approach to autonomous decision-making in smart electricity markets. *Machine learning*, 92(1), 5-39.

Pospieszny, P. (2017, October). Software estimation: towards prescriptive analytics. In Proceedings of the 27th International Workshop on Software Measurement and 12th International Conference on Software Process and Product Measurement (pp. 221-226). ACM.

Prat, N., 2019. Augmented analytics. *Business & Information Systems Engineering*, 61(3), pp.375-380.

Pricope, T. V. (2021). Deep reinforcement learning in quantitative algorithmic trading: A review. arXiv preprint arXiv:2106.00123.

Proctor, M., Neale, M., Lin, P., & Frandsen, M. (2008). Drools documentation. *JBoss*, 5(05), 2008.

Provost, F., & Fawcett, T. (2013). Data science and its relationship to big data and data-driven decision making. *Big data*, 1(1), 51-59.

Puterman, M. L. (2014). *Markov decision processes: discrete stochastic dynamic programming*. John Wiley & Sons.

Raghupathi, W., & Raghupathi, V. (2021). Contemporary Business Analytics: An Overview. *Data*, 6(8), 86.

Ramannavar, M., & Sidnal, N. S. (2018). A Proposed Contextual Model for Big Data Analysis Using Advanced Analytics. In *Big Data Analytics* (pp. 329-339). Springer, Singapore.

Raza, S. A., & Williams, M. A. (2020). Human feedback as action assignment in interactive reinforcement learning. *ACM Transactions on Autonomous and Adaptive Systems (TAAS)*, 14(4), 1-24.

Rebala, G., Ravi, A., & Churiwala, S. (2019). *An introduction to machine learning*. Springer.

Revathy, P., & Mukesh, R. (2018). HadoopSec: Sensitivity-aware Secure Data Placement Strategy for Big Data/Hadoop Platform using Prescriptive Analytics. *GSTF Journal on Computing (JoC)*, 6(2), 5-5.

Ringsquandl, M., Lamparter, S., & Lepratti, R. (2016, October). Graph-based predictions and recommendations in flexible manufacturing systems. In *Industrial*

Electronics Society, IECON 2016-42nd Annual Conference of the IEEE (pp. 6937-6942). IEEE.

Roberts, M. E., Stewart, B. M., Tingley, D., Lucas, C., Leder-Luis, J., Gadarian, S. K., ... & Rand, D. G. (2014). Structural Topic Models for Open-Ended Survey Responses. *American Journal of Political Science*, 58(4), 1064-1082.

Roijers, D. M., Vamplew, P., Whiteson, S., & Dazeley, R. (2013). A survey of multi-objective sequential decision-making. *Journal of Artificial Intelligence Research*, 48, 67-113.

Roijers, D. M., Zintgraf, L. M., Libin, P., & Nowé, A. (2018). Interactive multi-objective reinforcement learning in multi-armed bandits for any utility function. In *ALA workshop at FAIM (Vol. 8.)*

Romijn, J. W. (2014). "Philosophy of statistics". *Stanford Encyclopedia of Philosophy*.

Said, A. B., Shahzad, M. K., Zamai, E., Hubac, S., & Tollenaere, M. (2016). Towards proactive maintenance actions scheduling in the Semiconductor Industry (SI) using Bayesian approach. *IFAC-PapersOnLine*, 49(12), 544-549.

Sarmas, E., Xidonas, P., & Doukas, H. (2020). *Multicriteria Portfolio Construction with Python*. Springer.

SAS (2016) Managing the analytical life cycle for decisions at scale. https://www.sas.com/content/dam/SAS/en_us/doc/whitepaper1/manage-analytical-life-cycle-continuous-innovation-106179.pdf. Accessed 20 Feb 2021.

Sato, Y. (2019). Model-Free Reinforcement Learning for Financial Portfolios: A Brief Survey. arXiv preprint arXiv:1904.04973.

Schmerken, I. (2008). Deciphering the myths around complex event processing. *Wall Street & Technology*.

Schmidt, A., Atzmueller, M., & Hollender, M. (2016). Data preparation for big data analytics: Methods and experiences. In *Enterprise Big Data Engineering, Analytics, and Management* (pp. 157-170). IGI Global.

Schwartz, I. M., York, P., Nowakowski-Sims, E., & Ramos-Hernandez, A. (2017). Predictive and prescriptive analytics, machine learning and child welfare risk

assessment: The Broward County experience. *Children and Youth Services Review*, 81, 309-320.

Seddon PB, Constantinidis D, Tamm T, Dod H (2017) How does business analytics contribute to business value? *Inf Syst J* 27(3):237–269

Seifert, D., Seifert, R. W., & Protopappa-Sieke, M. (2013). A review of trade credit literature: Opportunities for research in operations. *European Journal of Operational Research*, 231(2), 245-256.

Selvin, S., Vinayakumar, R., Gopalakrishnan, E. A., Menon, V. K., & Soman, K. P. (2017, September). Stock price prediction using LSTM, RNN and CNN-sliding window model. In *2017 international conference on advances in computing, communications and informatics (icacci)* (pp. 1643-1647). IEEE.

Senyo, P. K., Liu, K., & Effah, J. (2019). Digital business ecosystem: literature review and a framework for future research. *International Journal of Information Management*, 47, 52-64.

Shearer, C. (2000). The CRISP-DM Model: The New Blueprint for Data Mining. *Journal of Data Warehousing*, 5(4), 13-22.

Shroff, G., Agarwal, P., Singh, K., Kazmi, A. H., Shah, S., & Sardeshmukh, A. (2014, July). Prescriptive information fusion. In *Information Fusion (FUSION), 2014 17th International Conference on* (pp. 1-8). IEEE.

Shah, D., Isah, H., & Zulkernine, F. (2019). Stock market analysis: A review and taxonomy of prediction techniques. *International Journal of Financial Studies*, 7(2), 26.

Sharda, R., Delen, D., Turban, E., Aronson, J., & Liang, T. (2014). *Business intelligence and analytics. System for Decesion Support*.

Sierksma, G., & Zwols, Y. (2015). *Linear and integer optimization: theory and practice*. Chapman and Hall/CRC.

Šikšnys L., Pedersen T.B.: Prescriptive Analytics. In: Liu L., Özsu M. (eds) *Encyclopedia of Database Systems*. Springer, New York, NY (2016).

Simon, H. A. (2013). *Administrative behavior*. Simon and Schuster.

Smelser, N. J., & Baltes, P. B. (Eds.). (2001). *International encyclopedia of the social & behavioral sciences* (Vol. 11). Amsterdam: Elsevier.

Soltanpoor, R., Sellis, T.: Prescriptive Analytics for Big Data. In: Cheema MA, Zhang W, Chang L (eds) 27th Australasian Database Conference: ADC 2016. *Databases Theory and Applications*, LNCS vol. 9877, pp 245–25. Springer International Publishing, Sydney, NSW (2016).

Song, I. Y., & Zhu, Y. (2016). Big data and data science: what should we teach?. *Expert Systems*, 33(4), 364-373.

Song, S. K., Jeong, D. H., Kim, J., Hwang, M., Gim, J., & Jung, H. (2014). Research advising system based on prescriptive analytics. In *Future Information Technology* (pp. 569-574). Springer, Berlin, Heidelberg.

Song, S. K., Kim, D. J., Hwang, M., Kim, J., Jeong, D. H., Lee, S., ... & Sung, W. (2013, December). Prescriptive analytics system for improving research power. In *Computational Science and Engineering (CSE), 2013 IEEE 16th International Conference on* (pp. 1144-1145). IEEE.

Srinivas, S., & Ravindran, A. R. (2018). Optimizing outpatient appointment system using machine learning algorithms and scheduling rules: A prescriptive analytics framework. *Expert Systems with Applications*, 102, 245-261.

Sriraman, B., & Lesh, R. A. (2006). Modeling conceptions revisited. *ZDM*, 38(3), 247-254.

Stein, N., Meller, J., & Flath, C. M. (2018). Big data on the shop-floor: sensor-based decision-support for manual processes. *Journal of Business Economics*, 1-24.

Storey VC, Song I-Y (2017) Big data technologies and management: What conceptual modeling can do. *Data Knowl Eng* 108:50–67.

Sun, G. D., Wu, Y. C., Liang, R. H., & Liu, S. X. (2013). A survey of visual analytics techniques and applications: State-of-the-art research and future challenges. *Journal of Computer Science and Technology*, 28(5), 852-867.

Sutton, R. S., McAllester, D. A., Singh, S. P., & Mansour, Y. (2000). Policy gradient methods for reinforcement learning with function approximation. In *Advances in neural information processing systems* (pp. 1057-1063).

Sutton, R. S., & Barto, A. G. (2018). *Reinforcement learning: An introduction*. MIT press.

Svensson, R. B., & Taghavianfar, M. (2020, September). Toward Becoming a Data-Driven Organization: Challenges and Benefits. In *International Conference on Research Challenges in Information Science* (pp. 3-19). Springer, Cham.

Tamilmani, K., Rana, N. P., Prakasam, N., & Dwivedi, Y. K. (2019). The battle of Brain vs. Heart: A literature review and meta-analysis of “hedonic motivation” use in UTAUT2. *International Journal of Information Management*, 46, 222-235.

Tan, J. S., Ang, A. K., Lu, L., Gan, S. W., & Corral, M. G. (2016, November). Quality Analytics in a Big Data supply chain: Commodity data analytics for quality engineering. In *Region 10 Conference (TENCON), 2016 IEEE* (pp. 3455-3463). IEEE.

Tanenbaum, A. S., & Van Steen, M. (2007). *Distributed systems: principles and paradigms*. Prentice-Hall.

Thammaboosadee, S., & Wongpitak, P. (2018, October). An Integration of Requirement Forecasting and Customer Segmentation Models towards Prescriptive Analytics For Electrical Devices Production. In *2018 International Conference on Information Technology (InCIT)* (pp. 1-5). IEEE.

Thomaz, A. L., Hoffman, G., & Breazeal, C. (2005). Real-time interactive reinforcement learning for robots. In *AAAI 2005 workshop on human comprehensible machine learning* (pp. 9-13).

Tozer, B., Mazzuchi, T., & Sarkani, S. (2017). Many-objective stochastic path finding using reinforcement learning. *Expert Systems with Applications*, 72, 371-382.

Tranfield, D., Denyer, D., & Smart, P. (2003). Towards a methodology for developing evidence-informed management knowledge by means of systematic review. *British journal of management*, 14(3), 207-222.

Tsai, C. W., Lai, C. F., Chao, H. C., & Vasilakos, A. V. (2015). Big data analytics: a survey. *Journal of Big Data*, 2(1), 21.

Vartak, M., & Madden, S. (2018). Modeldb: Opportunities and challenges in managing machine learning models. *IEEE Data Eng. Bull.*, 41(4), 16-25.

Vartak, M., Subramanyam, H., Lee, W. E., Viswanathan, S., Husnoo, S., Madden, S., & Zaharia, M. (2016, June). ModelDB: a system for machine learning model management. In *Proceedings of the Workshop on Human-In-the-Loop Data Analytics* (pp. 1-3).

Vidgen, R., Shaw, S., & Grant, D. B. (2017). Management challenges in creating value from business analytics. *European Journal of Operational Research*, 261(2), 626-639.

von Bischhoffshausen, J. K., Paatsch, M., Reuter, M., Satzger, G., & Fromm, H. (2015, July). An information system for sales team assignments utilizing predictive and prescriptive analytics. In *Business Informatics (CBI), 2015 IEEE 17th Conference on* (Vol. 1, pp. 68-76). IEEE.

Von Neumann, J., & Morgenstern, O. (1944). *Theory of games and economic behavior* Princeton. Princeton University Press, 1947, 1953.

Wang, C. H., Cheng, H. Y., & Deng, Y. T. (2018). Using Bayesian belief network and time-series model to conduct prescriptive and predictive analytics for computer industries. *Computers & Industrial Engineering*, 115, 486-494.

Wang, J., Jiang, C., Zhang, H., Ren, Y., Chen, K. C., & Hanzo, L. (2020). Thirty years of machine learning: The road to Pareto-optimal wireless networks. *IEEE Communications Surveys & Tutorials*, 22(3), 1472-1514.

Wang, Y. H., Cao, K., & Zhang, X. M. (2013). Complex event processing over distributed probabilistic event streams. *Computers & Mathematics with Applications*, 66(10), 1808-1821.

Ward, M. J., Marsolo, K. A., & Froehle, C. M. (2014). Applications of business analytics in healthcare. *Business horizons*, 57(5), 571-582.

Whittlestone, J., Arulkumaran, K., & Crosby, M. (2021). The societal implications of deep reinforcement learning. *Journal of Artificial Intelligence Research*, 70, 1003-1030.

Williams, H. P. (2013). *Model building in mathematical programming*. John Wiley & Sons.

Wirth, R., & Hipp, J. (2000, April). CRISP-DM: Towards a standard process model for data mining. In *Proceedings of the 4th international conference on the practical applications of knowledge discovery and data mining (Vol. 1, pp. 29-40)*.

Wu, P. J., & Yang, C. K. (2017, May). The green fleet optimization model for a low-carbon economy: A prescriptive analytics. In *Applied System Innovation (ICASI), 2017 International Conference on (pp. 107-110)*. IEEE.

Xidas, P., Mavrotas, G., Krintas, T., Psarras, J., & Zopounidis, C. (2012). Multicriteria portfolio management. In *Multicriteria Portfolio Management (pp. 5-21)*. Springer, New York, NY.

Xiong, Z., Liu, X. Y., Zhong, S., Yang, H., & Walid, A. (2018). Practical deep reinforcement learning approach for stock trading. *arXiv preprint arXiv:1811.07522*.

Yang, R., Sun, X., & Narasimhan, K. (2019). A generalized algorithm for multi-objective reinforcement learning and policy adaptation. *Advances in Neural Information Processing Systems*, 32.

Yaqoob, I., Hashem, I. A. T., Gani, A., Mokhtar, S., Ahmed, E., Anuar, N. B., & Vasilakos, A. V. (2016). Big data: From beginning to future. *International Journal of Information Management*, 36(6), 1231-1247.

Yu, P., Lee, J. S., Kulyatin, I., Shi, Z., & Dasgupta, S. (2019). Model-based deep reinforcement learning for dynamic portfolio optimization. *arXiv preprint arXiv:1901.08740*.

Zaharia, M., Chen, A., Davidson, A., Ghodsi, A., Hong, S. A., Konwinski, A., ... & Zumar, C. (2018). Accelerating the machine learning lifecycle with MLflow. *IEEE Data Eng. Bull.*, 41(4), 39-45.

Zhang, H., & Yu, T. (2020). Taxonomy of reinforcement learning algorithms. In *Deep Reinforcement Learning* (pp. 125-133). Springer, Singapore.

Zhang, Q., Lin, J., Sha, Q., He, B., & Li, G. (2020). Deep interactive reinforcement learning for path following of autonomous underwater vehicle. *IEEE Access*, 8, 24258-24268.

Zhang, Z., Zohren, S., & Roberts, S. (2020b). Deep reinforcement learning for trading. *The Journal of Financial Data Science*, 2(2), 25-40.

Zhang, R., Torabi, F., Guan, L., Ballard, D. H., & Stone, P. (2019). Leveraging human guidance for deep reinforcement learning tasks. *arXiv preprint arXiv:1909.09906*.

Zanzotto, F. M. (2019). Human-in-the-loop artificial intelligence. *Journal of Artificial Intelligence Research*, 64, 243-252.

10 Δημοσιεύσεις

Περιοδικά

[j1] Lepenioti, K., Bousdekis, A., Apostolou, D., & Mentzas, G. (2020). Prescriptive analytics: Literature review and research challenges. *International Journal of Information Management*, 50, 57-70. (Impact Factor: 14.098)

[j2] Bousdekis, A., Lepenioti, K., Apostolou, D., & Mentzas, G. (2021). A Review of Data-Driven Decision-Making Methods for Industry 4.0 Maintenance Applications. *Electronics*, 10(7), 828. (Impact Factor: 2.397)

[j3] Lepenioti, K., Bousdekis, A., Apostolou, D., & Mentzas, G. (2021). Human-augmented Prescriptive Analytics with Interactive Multi-Objective Reinforcement Learning. *IEEE Access*. (Impact Factor: 3.367)

[j4] von Stietencron, M., Hribernik, K., Lepenioti, K., Bousdekis, A., Lewandowski, M., Apostolou, D., & Mentzas, G. (2021). Towards logistics 4.0: an edge-cloud software framework for big data analytics in logistics processes. *International Journal of Production Research*, 1-19. (Impact Factor: 8.568)

[j5] Bousdekis, A., Lepenioti, K., Apostolou, D., & Mentzas, G. (2022). Data Analytics in Quality 4.0: Literature Review and Future Research Directions. *International Journal of Computer Integrated Manufacturing* (Impact Factor: 3.205)

Συνέδρια

[c1] Lepenioti, K., Bousdekis, A., Apostolou, D., & Mentzas, G. (2018, July). Prescriptive analytics: a survey of approaches and methods. In *International Conference on Business Information Systems* (pp. 449-460). Springer, Cham. (NTUA Thomaideio Award 2018)

[c2] Bousdekis, A., Lepenioti, K., Apostolou, D., & Mentzas, G. (2019). Decision making in predictive maintenance: literature review and research agenda for industry 4.0. *IFAC-PapersOnLine*, 52(13), 607-612.

[c3] Bousdekis, A., Lepenioti, K., Ntalaperas, D., Vergeti, D., Apostolou, D., & Boursinos, V. (2019, June). A RAMI 4.0 view of predictive maintenance: software architecture, platform and case study in steel industry. In International Conference on Advanced Information Systems Engineering (pp. 95-106). Springer, Cham. (NTUA Thomaideio Award 2019)

[c4] Lepenioti, K., Pertselakis, M., Bousdekis, A., Louca, A., Lampathaki, F., Apostolou, D., ... & Anastasiou, S. (2020, June). Machine learning for predictive and prescriptive analytics of operational data in smart manufacturing. In International Conference on Advanced Information Systems Engineering (pp. 5-16). Springer, Cham.

[c5] von Stietencron, M., Lewandowski, M., Lepenioti, K., Bousdekis, A., Hribernik, K., Apostolou, D., & Mentzas, G. (2020, August). Streaming Analytics in Edge-Cloud Environment for Logistics Processes. In IFIP International Conference on Advances in Production Management Systems (pp. 245-253). Springer, Cham.

[c6] Fouka, A., Bousdekis, A., Lepenioti, K., & Mentzas, G. (2021, June). Real-Time Equipment Health State Prediction with LSTM Networks and Bayesian Inference. In International Conference on Advanced Information Systems Engineering (pp. 155-166). Springer, Cham.

[c7] Karlis, V., Lepenioti, K., Bousdekis, A., & Mentzas, G. (2021, July). Stock Trend Prediction by Fusing Prices and Indices with LSTM Neural Networks. In 2021 12th International Conference on Information, Intelligence, Systems & Applications (IISA) (pp. 1-7). IEEE.

[c8] Mentzas, G., Lepenioti, K., Bousdekis, A., & Apostolou, D. (2021, September). Data-Driven Collaborative Human-AI Decision Making. In Conference on e-Business, e-Services and e-Society (pp. 120-131). Springer, Cham.

[c9] Bousdekis, A., Wellsandt, S., Bosani, E., Lepenioti, K., Apostolou, D., Hribernik, K., & Mentzas, G. (2021, September). Human-AI Collaboration in Quality Control with Augmented Manufacturing Analytics. In IFIP International Conference on Advances in Production Management Systems (pp. 303-310). Springer, Cham.

[c10] Fikardos, M., Lepenioti, K., Bousdekis, A., Bosani, E., Apostolou, D., Mentzas, G. (2022). An Automated Machine Learning Framework for Predictive Analytics in Quality

Control. In IFIP International Conference on Advances in Production Management Systems. Springer, Cham.

[c11] Wellsandt, S., Foosherian, M., Lepenioti, K., Fikardos, M., Mentzas, G., Thoben, KD. (2022). Supporting Data Analytics in Manufacturing with a Digital Assistant. In IFIP International Conference on Advances in Production Management Systems. Springer, Cham.

[c12] Fouka A., Lepenioti K., Bousdekis A., Mentzas G. (2022). A Machine Learning Framework for Li-Ion Battery Lifetime Prognostics. In 2022 13th International Conference on Information, Intelligence, Systems & Applications (IISA). IEEE.