



**ΠΟΛΥΤΕΧΝΕΙΟ
ΚΡΗΤΗΣ**

**Σχολή Μηχανικών
Παραγωγής και
Διοίκησης**

Διπλωματική Εργασία

**Ανασκόπηση των Εφαρμογών Ευφύων Υπολογιστικών Μεθόδων
στη Διαχείριση Χρηματοοικονομικών Κινδύνων**

Υπό

Αστέριος Μάριος Γιόβας AM: 2019010091

Επιβλέπων καθηγητής:

Μιχάλης Δούμπος

Χανιά, Σεπτέμβριος 2025

Περίληψη

Η παρούσα διπλωματική εργασία είχε ως αντικείμενο τη συστηματική βιβλιομετρική ανασκόπηση και ανάλυση των ευφύων υπολογιστικών μεθόδων (computational intelligence, CI), που εφαρμόζονται στη διαχείριση χρηματοοικονομικών κινδύνων. Αρχικά, παρουσιάζονται τα είδη χρηματοοικονομικών κινδύνων καθώς και οι αλγόριθμοι που αποτελούν τον πυρήνα των μεθόδων CI, ώστε να διαμορφωθεί το απαραίτητο θεωρητικό υπόβαθρο για την κατανόηση της έρευνας. Στη συνέχεια, πραγματοποιήθηκε βιβλιογραφική ανασκόπηση των μεθόδων CI που εφαρμόζονται στον χρηματοοικονομικό τομέα, αναλύοντας τις βασικές τεχνικές, τα πλεονεκτήματα και τις εφαρμογές τους. Έπειτα, για την επίτευξη των στόχων της έρευνας, ακολουθήθηκε η μεθοδολογία της συστηματικής βιβλιομετρικής ανασκόπησης (SBR), με τη συλλογή και ανάλυση επιστημονικών άρθρων από διεθνείς βάσεις δεδομένων, εφαρμόζοντας το πλαίσιο PRISMA. Η ανάλυση των δεδομένων πραγματοποιήθηκε με τη χρήση του λογισμικού R και του πακέτου Bibliometrix, με στόχο την καταγραφή των κυριότερων μεθόδων CI, των τύπων χρηματοοικονομικών κινδύνων που εξετάζονται, καθώς και των εργαλείων και τεχνικών αξιολόγησης που αξιοποιούνται στη βιβλιογραφία. Τέλος, τα αποτελέσματα ανέδειξαν την αυξανόμενη σημασία των μεθόδων CI στην βελτίωση της πρόβλεψης και της ανάλυσης κινδύνων, ενώ εντοπίστηκαν σημαντικά ερευνητικά κενά, τα οποία αποτελούν ευκαιρίες για περαιτέρω μελέτη. Η εργασία συμβάλλει στην χαρτογράφηση του ερευνητικού πεδίου και παρέχει χρήσιμες κατευθύνσεις για μελλοντικές προσεγγίσεις στον τομέα της διαχείρισης χρηματοοικονομικών κινδύνων.

Λέξεις κλειδιά: Τεχνητή Νοημοσύνη, Μηχανική Μάθηση, Βαθιά Μάθηση, Διαχείριση Κινδύνων, Χρηματοοικονομικός Κίνδυνος

Abstract

This dissertation focuses on the systematic bibliometric review and analysis of Computational Intelligence (CI) methods applied to financial risk management. Initially, the various types of financial risks are presented, along with the algorithms that constitute the core of CI techniques, in order to establish the necessary theoretical background for understanding the research. Subsequently, a literature review of CI methods applied in the financial sector was conducted, analyzing the main techniques, their advantages, and their applications. Then, to achieve the objectives of the study, the methodology of the Systematic Bibliometric Review (SBR) was adopted, involving the collection and analysis of scientific articles from international databases, following the PRISMA framework. The data analysis was carried out using the R software and the Bibliometrix package, aiming to record the most widely used CI methods, the types of financial risks examined, as well as the evaluation tools and techniques utilized in the literature. Finally, the findings highlight the growing importance of CI methods in improving risk prediction and analysis, while significant research gaps are identified, providing opportunities for further investigation. This study contributes to the mapping of the research field and offers valuable insights and directions for future approaches in financial risk management.

Keywords: Artificial Intelligence, Machine Learning, Deep Learning, Risk Management, Financial Risk

Περιεχόμενα

Κεφάλαιο 1 ^ο : Η έννοια του κίνδυνου και τα είδη χρηματοοικονομικών κινδύνων του	1
1.1 Ο Ορισμός του Κίνδυνου	1
1.2 Είδη του Κίνδυνου	1
1.3 Είδη χρηματοοικονομικών κινδύνων.....	2
1.3.1 Κίνδυνος Αγοράς	2
1.3.2 Πιστωτικός Κίνδυνος	4
1.3.3 Κίνδυνος Ρευστότητας.....	5
1.3.4 Επιτοκιακός Κίνδυνος	6
1.3.5 Λειτουργικός Κίνδυνος	7
1.3.6 Νομικός Κίνδυνος	7
1.3.7 Συναλλαγματικός Κίνδυνος	8
1.3.8 Κίνδυνος Χώρας.....	9
1.3.9 Κίνδυνος διακανονισμού πληρωμών	10
1.3.10 Κίνδυνος Αξιοπιστίας	10
1.4 Ανακεφαλαίωση	11
Κεφάλαιο 2 ^ο : Ανασκόπηση των Μεθόδων Υπολογιστικής Νοημοσύνης και Μηχανικής Μάθησης	12
2.1 Τι είναι η Υπολογιστική Νοημοσύνη.....	12
2.2 Η Σχέση της Υπολογιστικής Νοημοσύνης με τη Μηχανική Μάθηση.....	13
2.3 Ορισμός Μηχανικής Μάθησης.....	13
2.3.1 Κατηγορίες Μηχανικής Μάθησης	14
2.3.1.1 Εποπτευόμενη Μάθηση (Supervised Learning)	14
2.3.1.2 Γραμμική Παλινδρόμηση (Linear Regression)	15

2.3.2 Δέντρα Απόφασης και Τυχαία Δάση	15
2.3.2.1 Δέντρα Απόφασης (Decision Trees).....	16
2.3.2.2 Τυχαία Δάση (Random Forests).....	16
2.3.3 Άλλες Μέθοδοι Μάθησης και Μείωσης Διάστασης	17
2.3.3.1 Μηχανές Διανυσμάτων Υποστήριξης (Support Vector Machines-SVM).....	17
2.3.3.2 Μη Εποπτευόμενη Μάθηση (Unsupervised Learning).....	18
2.3.3.3 Ομαδοποίηση (Clustering: k-Means).....	19
2.3.3.4 Ανάλυση Κύριων Συνιστωσών (Principal Component Analysis – PCA)	19
2.3.4 Ενισχυτική Μάθηση (Reinforcement Learning).....	20
2.3.4.1 Q-Learning στη Διαχείριση Χρηματοοικονομικών Κίνδυνων	20
2.3.4.2 Deep Reinforcement Learning (DRL).....	21
2.4 Τεχνητά Νευρωνικά Δίκτυα (ANN)	22
2.4.1 Δομή των Νευρωνικών Δικτύων.....	22
2.4.2 Τεχνητός νευρώνας και βάρη	24
2.4.3 Συναρτήσεις Ενεργοποίησης (Activation Functions)	24
2.4.4 Τύποι Νευρωνικών δικτύων.....	25
2.4.4.1 Νευρωνικά Δίκτυα πολλών επιπέδων (Multi-Layer Perceptrons-MLP)	25
2.4.4.2 Αναδρομικά Νευρωνικά Δίκτυα (Recurrent Neural Networks – RNN).....	25
2.4.4.3 Συνελκτικά Νευρωνικά Δίκτυα (Convolutional Neural Networks – CNN)	26
2.5 Μέθοδοι Ασαφούς και Γκρίζας Λογικής	27
2.5.1 Ασαφής Λογική (Fuzzy Logic -FL).....	27
2.5.2 Προσεγγιστικά Σύνολα (Rough Sets- RS)	28
2.5.3 Θεωρία των Γκρίζων Συστημάτων (Grey System Theory- GST)	28
2.6 Εξελικτικοί Αλγόριθμοι (Evolutionary Computation-EA)	29

2.6.1 Αλγόριθμος εξελικτικής προσομοιωμένης ανάκτησης (<i>Evolutionary Simulated Annealing - ESA</i>)	30
2.6.2 Νοημοσύνη Σμήνους (<i>Swarm Intelligence-SI</i>)	30
2.6.2.1 Ο Αλγόριθμος Αποικίας Μυρμηγκιών (<i>Ant Colony Optimization - ACO</i>)	31
2.7 Υβριδικά Μοντέλα Υπολογιστικής Νοημοσύνης	31
2.7.1 Νευροασαφή Συστήματα (<i>Neuro-Fuzzy Systems- NFS</i>)	32
2.7.2 Ασαφή Γενετικά Μοντέλα (<i>Fuzzy Genetic Models- FGM</i>)	32
4.7.3 Νευρωνικά Γενετικά Μοντέλα (<i>Neuro-Genetic Models</i>)	33
2.8 Βιβλιογραφική ανασκόπηση	33
2.8.1 Αναλυτική παρουσίαση των επιλεγμένων άρθρων	35
2.8.2 Συμπεράσματα ανασκόπησης	38
Κεφάλαιο 3 ^ο :Μεθοδολογία Ανασκόπησης	40
3.1 Εισαγωγή στην μεθοδολογία	40
3.2 Ερευνητική Προσέγγιση	40
3.3 Διαδικασία Επιλογής Άρθρων	41
3.4 Δημιουργία Βάσης Δεδομένων	45
3.4 Στατιστική και Βιβλιομετρική Ανάλυση	47
3.5 Συνολική Ροή Μεθοδολογίας	48
Κεφάλαιο 4 ^ο : Αποτελέσματα της Βιβλιομετρικής Ανασκόπησης	50
4.1 Εισαγωγή	50
4.2 Αποτελέσματα Στατιστικής ανάλυσης	50
4.2.1 Εξέλιξη Δημοσιευτικής Δραστηριότητας Ανά Έτος	50
4.2.2 Κατάταξη Περιοδικών βάσει Πλήθους Δημοσιεύσεων	51
4.2.3: Κατάταξη Συγγραφέων Βάσει Πλήθους Δημοσιεύσεων	52

4.2.4 Κατάταξη χωράς βάσει πλήθος δημοσιεύσεων.....	53
4.2.5 Κατανομή Ιδρυμάτων βάσει πλήθος δημοσιεύσεων.....	54
4.3 Βιβλιομετρική Ανάλυση.....	55
4.3.1 Συχνότητα λέξεων-κλειδιών	55
4.3.2 Θεματικοί Χάρτες	56
4.3.2.1: Δίκτυο συν-εμφάνισης λέξεων-κλειδιών	56
4.3.2.2 Δίκτυο συν-εμφάνισης Χωρών.....	57
4.4 Ταξινόμηση Άρθρων Ανά Κατηγορία Κινδύνου.....	58
4.5: Κατανομή Άρθρων Ανά Μέθοδο Ευφυών Υπολογιστικών Συστημάτων.....	59
4.6 Αξιολόγηση Μεθόδων Ευφυούς Υπολογιστικής	61
4.6.1 Τα πιο χρησιμοποιημένα σύνολα δεδομένων.....	61
4.6.2: Μετρικές Αξιολόγησης Μοντέλων στη Διαχείριση Χρηματοοικονομικών Κινδύνων.....	63
4.7 Ερευνητικά κενά της βιβλιομετρικής ανασκόπησης	65
Κεφάλαιο 5: Συμπεράσματα και Μελλοντική Έρευνα	66
5.1 Κύρια Συμπεράσματα.....	66
5.2 Προτάσεις Μελλοντικής Έρευνας.....	67
Βιβλιογραφία.....	68

Εισαγωγή

Η ραγδαία εξέλιξη των χρηματοοικονομικών αγορών και η αυξανόμενη πολυπλοκότητα των παγκόσμιων οικονομιών, έχουν καταστήσει τη διαχείριση χρηματοοικονομικών κινδύνων έναν από τους πιο κρίσιμους τομείς μελέτης για επιχειρήσεις, τράπεζες, επενδυτές και ερευνητές. Η ανάγκη για έγκαιρη και ακριβή πρόβλεψη κινδύνων είναι σήμερα μεγαλύτερη από ποτέ, καθώς οι οργανισμοί επιδιώκουν να προστατεύσουν τα κεφάλαιά τους και να διασφαλίσουν τη βιωσιμότητά τους. Παράλληλα, η ραγδαία ανάπτυξη της τεχνητής νοημοσύνης (AI) και των ευφύων υπολογιστικών μεθόδων (Computational Intelligence - CI) έχει αλλάξει ριζικά τον τρόπο με τον οποίο προσεγγίζεται η ανάλυση και η διαχείριση σύνθετων χρηματοοικονομικών δεδομένων.

Η βιβλιογραφία αναδεικνύει σημαντικές εξελίξεις στην εφαρμογή των μεθόδων CI, ωστόσο εξακολουθούν να υπάρχουν κενά που αφορούν την συγκριτική αξιολόγηση διαφορετικών τεχνικών, τη συστηματική χαρτογράφηση των ερευνητικών τάσεων και τον εντοπισμό περιοχών με περιορισμένη ερευνητική δραστηριότητα. Η παρούσα εργασία επιχειρεί να καλύψει αυτό το κενό, παρέχοντας μία ολοκληρωμένη συστηματική βιβλιομετρική ανασκόπηση της υπάρχουσας γνώσης, εστιάζοντας τόσο στις εφαρμοζόμενες μεθόδους όσο και στις προοπτικές μελλοντικής έρευνας.

Ο σκοπός της διπλωματικής είναι να μελετήσει, ταξινομήσει και αναλύσει τις εφαρμογές των μεθόδων CI στη διαχείριση χρηματοοικονομικών κινδύνων, καταγράφοντας τις κυριότερες τεχνικές, τους τύπους κινδύνων που εξετάζονται, τις πηγές δεδομένων, τις μετρικές αξιολόγησης και τα εντοπισμένα ερευνητικά κενά. Οι στόχοι της έρευνας περιλαμβάνουν:

1. Την χαρτογράφηση των ερευνητικών τάσεων στον τομέα.
2. Την ταξινόμηση των μεθόδων CI και των περιοχών εφαρμογής τους.
3. Τον εντοπισμό βέλτιστων πρακτικών και πιθανών βελτιώσεων.
4. Την ανάδειξη ευκαιριών μελλοντικής έρευνας.

Η εργασία οργανώνεται σε πέντε κεφάλαια:

Στο 1^ο κεφάλαιο παρουσιάζονται οι έννοιες των χρηματοοικονομικών κινδύνων και το θεωρητικό πλαίσιο της έρευνας. Αρχικά, αναλύεται η έννοια του κινδύνου και τα βασικά είδη του. Στην συνέχεια, εξετάζονται οι σημαντικότεροι χρηματοοικονομικοί κίνδυνοι, όπως ο κίνδυνος αγοράς, ο πιστωτικός, ο κίνδυνος ρευστότητας, ο επιτοκιακός, ο λειτουργικός, ο νομικός, ο συναλλαγματικός, ο κίνδυνος χώρας, ο κίνδυνος διακανονισμού πληρωμών και ο κίνδυνος αξιοπιστίας. Το κεφάλαιο εστιάζει στην κατανόηση της φύσης αυτών των κινδύνων και της επίδρασής τους σε επενδυτές, επιχειρήσεις και χρηματοπιστωτικά ιδρύματα.

Στο 2^ο κεφάλαιο πραγματοποιείται μια ανασκόπηση των ευφύων υπολογιστικών μεθόδων και της μηχανικής μάθησης. Σε πρώτο στάδιο, δίνεται ο ορισμός της υπολογιστικής νοημοσύνης και των τεχνικών που την αποτελούν, ενώ στη συνέχεια εξετάζεται η μηχανική μάθηση, οι κατηγορίες της και οι βασικές μεθοδολογίες που χρησιμοποιούνται. Επιπλέον, αναλύονται τεχνικές ασαφούς λογικής και γκρίζας λογικής, οι εξελικτικοί αλγόριθμοι και τα υβριδικά μοντέλα. Τέλος, παρουσιάζεται η βιβλιογραφική ανασκόπηση επιλεγμένων μελετών, οι οποίες συγκεντρώθηκαν βάσει προκαθορισμένων κριτηρίων.

Το 3^ο κεφάλαιο περιγράφει τη μεθοδολογική προσέγγιση της έρευνας. Πιο συγκεκριμένα, εφαρμόστηκε η συστηματική βιβλιομετρική ανασκόπηση (SBR), η οποία καθόρισε τα βήματα της διαδικασίας. Στην πορεία, με την εφαρμογή της μεθόδου PRISMA, επιλέχθηκαν τα άρθρα από τις βάσεις δεδομένων Scopus και ScienceDirect. Κατόπιν, πραγματοποιήθηκε ανάλυση μέσω του λογισμικού R, αξιοποιώντας τις βιβλιοθήκες Bibliometrix και Biblioshiny.

Στο 4^ο κεφάλαιο γίνεται μια παρουσίαση των ευρημάτων της βιβλιομετρικής ανάλυσης, οι ερευνητικές τάσεις, οι κυρίαρχες μέθοδοι CI, οι κατηγορίες κινδύνων, τα πιο δημοφιλή σύνολα δεδομένων, οι μετρικές αξιολόγησης και τα εντοπισμένα ερευνητικά κενά.

Τέλος, το 5^ο κεφάλαιο περιλαμβάνει τα κύρια ευρήματα της μελέτης, αναλύονται οι πρακτικές εφαρμογές των αποτελεσμάτων και προτείνονται κατευθύνσεις για μελλοντική έρευνα.

Κεφάλαιο 1^ο: Η έννοια του κίνδυνου και τα είδη χρηματοοικονομικών κινδύνων του

1.1 Ο Ορισμός του Κίνδυνου

Κάθε οργανισμός λειτουργεί με σκοπό την επίτευξη προκαθορισμένων στόχων. Ωστόσο, η αποτελεσματικότητα επίτευξης αυτών διαφέρει μεταξύ των οργανισμών. Ορισμένοι, αποτυγχάνουν τόσο έντονα που τελικά αδυνατούν να συνεχίσουν την λειτουργία τους, ενώ άλλοι μπορεί να επιτυγχάνουν έως κάποιο βαθμό, αλλά όχι στο μέγιστο των δυνατοτήτων τους (Aven & Renn, 2009).

Στον χρηματοοικονομικό τομέα, ο κίνδυνος αποτελεί έναν κύριο παράγοντα που καθορίζει τις επιχειρηματικές αποφάσεις. Ωστόσο δεν υπάρχει ένας μοναδικός ορισμός του κίνδυνου, καθώς η έννοιά του μεταβάλλεται ανάλογα με το πλαίσιο στο οποίο εξετάζεται. Σε γενικές γραμμές, μπορούμε να ορίσουμε τον κίνδυνο με δύο βασικούς τρόπους (Berkhouch et al., 2019):

1. Ως ένα μέτρο της αβεβαιότητας.
2. Ως μια ένδειξη της πιθανότητας να προκύψει μια απώλεια ή ζημία.

Ο πρώτος ορισμός συνδέει τον κίνδυνο με την αβεβαιότητα, σχετικά με τα μελλοντικά αποτελέσματα. Απλούστερα αναφέρεται στη διαφορά που μπορεί να υπάρξει ανάμεσα στις προβλέψεις και στα πραγματικά αποτελέσματα. Στο πλαίσιο των επενδύσεων, αυτό μεταφράζεται στη διακύμανση των μελλοντικών ταμειακών ροών, κάτι που μπορεί να υπολογιστεί μέσω στατιστικών μέτρων, όπως η τυπική απόκλιση. Αξίζει να σημειωθεί ότι, η ύπαρξη κινδύνου δεν σημαίνει απαραίτητα αρνητικά αποτελέσματα, αφού οι αποκλίσεις μπορούν να είναι τόσο θετικές όσο και αρνητικές (Bidyuk & Kuznietsova, 2018).

Από την άλλη πλευρά, ο δεύτερος ορισμός εστιάζει αποκλειστικά στις αρνητικές συνέπειές του. Συγκεκριμένα, ο κίνδυνος περιγράφεται ως η πιθανότητα να συμβεί ένα δυσμενές γεγονός, όπως μια οικονομική απώλεια ή μια απόκλιση από το επιθυμητό αποτέλεσμα. Για παράδειγμα, μια ασφαλιστική εταιρεία αναλαμβάνει τον κίνδυνο αποζημιώσεων, ενώ μια τράπεζα εκτίθεται στον κίνδυνο αγοράς (Holton, 2004).

1.2 Είδη του Κίνδυνου

Ο κίνδυνος είναι μια εγγενής παράμετρος σε κάθε οικονομική δραστηριότητα, καθώς εκφράζει την αβεβαιότητα που συνοδεύει τις επιχειρηματικές αποφάσεις και τις αγοραίες συνθήκες. Ανάλογα με

την προέλευσή του και το αν μια επιχείρηση μπορεί να τον ελέγξει, διακρίνεται σε επιχειρηματικό και μη επιχειρηματικό.

- a. *Επιχειρηματικός κίνδυνος (Business risk)*: Πρόκειται για τον κίνδυνο που μια εταιρεία επιλέγει να αναλάβει στο πλαίσιο της στρατηγικής της, με σκοπό την ενίσχυση της ανταγωνιστικότητάς της και την αύξηση της αξίας για τους μετόχους της. Περιλαμβάνει παράγοντες όπως, η λανθασμένη στρατηγική μάρκετινγκ, οι αποτυχημένες επενδυτικές κινήσεις ή ακόμα και οι δυσκολίες στην προσαρμογή μεταβολών της αγοράς (Colbert, 1991).
- b. *Μη επιχειρηματικός κίνδυνος (Non-business risk)*: Αυτός ο κίνδυνος δεν επηρεάζεται από τις άμεσες αποφάσεις μιας επιχείρησης, αλλά σχετίζεται με το εξωτερικό περιβάλλον. Δύο βασικές κατηγορίες του είναι οι:
 - i. *Στρατηγικοί κίνδυνοι (Strategic risks)*: Αναφέρονται στις αρνητικές επιπτώσεις που μπορεί να έχει μια επιχείρηση, λόγω αλλαγών στο πολιτικό, οικονομικό ή κοινωνικό περιβάλλον. Για παράδειγμα, μια αλλαγή στην νομοθεσία ή η εμφάνιση μιας νέας τεχνολογίας μπορεί να επηρεάσει αρνητικά μια εταιρεία (Andersen, 2005).
 - ii. *Χρηματοοικονομικοί κίνδυνοι (Financial risks)*: Σχετίζονται με τις διακυμάνσεις στις χρηματοοικονομικές αγορές και τον τρόπο που αυτές επηρεάζουν τις οικονομικές συναλλαγές. Αυτοί οι κίνδυνοι περιλαμβάνουν την πιθανότητα απωλειών από επενδύσεις, την μεταβολή των επιτοκίων και τον κίνδυνο αθέτησης υποχρεώσεων από αντισυμβαλλόμενους (Chitta & Soni, 2023).

1.3 Είδη χρηματοοικονομικών κινδύνων

Οι χρηματοοικονομικοί κίνδυνοι συνδέονται με τις διακυμάνσεις στις χρηματοοικονομικές αγορές. Ένα χρηματοπιστωτικό ίδρυμα ενδέχεται να αντιμετωπίσει διάφορες μορφές κινδύνων, όπως τον κίνδυνο αγοράς, τον πιστωτικό κίνδυνο, τον κίνδυνο ρευστότητας, τον λειτουργικό κίνδυνο και τον επιτόκιο κίνδυνο. Επιπλέον, υπάρχουν και άλλες δευτερεύουσες κατηγορίες κινδύνων, όπως ο συναλλαγματικός κίνδυνος, ο κίνδυνος που σχετίζεται με την χώρα ή την τοποθεσία, ο νομικός κίνδυνος, καθώς και οι κίνδυνοι που αφορούν την αξιοπιστία, την αφερεγγυότητα και τον διακανονισμό πληρωμών.

1.3.1 Κίνδυνος Αγοράς

Ο κίνδυνος αγοράς (market risk) σχετίζεται με την αβεβαιότητα που προκύπτει από μεταβολές σε βασικούς οικονομικούς δείκτες, όπως τα επιτόκια, οι τιμές των μετοχών και οι συναλλαγματικές ισοτιμίες. Αυτές οι διακυμάνσεις επηρεάζουν άμεσα την λειτουργία της αγοράς, αφού οι τιμές των περιουσιακών στοιχείων (είτε του ενεργητικού είτε του παθητικού) εξαρτώνται από τις αλλαγές αυτές. Ιδιαίτερα στα χρηματοπιστωτικά ιδρύματα, ο κίνδυνος αγοράς είναι έντονος, όταν

διαπράττουν συναλλαγές σε χρηματοοικονομικά προϊόντα, αντί να τις πραγματοποιούν ως μακροπρόθεσμες επενδύσεις. Στον τομέα της χρηματοοικονομικής, ο κίνδυνος αγοράς αντανάκλα την πιθανότητα οι πραγματικές αποδόσεις ενός χαρτοφυλακίου να αποκλίνουν σημαντικά από τις αναμενόμενες λόγω απρόβλεπτων μεταβολών σε κρίσιμους χρηματοοικονομικούς παράγοντες (Chance, 2019).

Εξάλλου, ανάλογα με τον τρόπο διαχείρισης του, ο κίνδυνος αγοράς διακρίνεται σε:

- Απόλυτο κίνδυνο: Μετριέται σε νομισματικές μονάδες (π.χ., πιθανές απώλειες σε ευρώ).
- Σχετικό κίνδυνο: Συγκρίνεται με έναν δείκτη αναφοράς για να αξιολογηθεί η απόκλιση των αποδόσεων.

Μερικοί από τους σημαντικότερους παράγοντες που διαμορφώνουν τον κίνδυνο αγοράς είναι:

- Ο επιτοκιακός κίνδυνος, καθώς οι αλλαγές στα επιτόκια επηρεάζουν τις αποδόσεις επενδύσεων, όπως τα ομόλογα.
- Ο συναλλαγματικός κίνδυνος, όπου μια υποτίμηση νομίσματος μειώνει την αξία των επενδύσεων που είναι εκφρασμένες σε αυτό το νόμισμα.
- Ο κίνδυνος που σχετίζεται με τις μετοχές, λόγω των διακυμάνσεων στις χρηματιστηριακές αγορές.
- Ο κίνδυνος εμπορευμάτων, ο οποίος αφορά την επίδραση των τιμών βασικών αγαθών, όπως το πετρέλαιο και τα μέταλλα, στις επενδύσεις.

Η εκτίμηση του βασίζεται στον καθορισμό των παραγόντων που εξετάζονται, για παράδειγμα η συνολική αξία ενός χαρτοφυλακίου, τα έσοδα ή η απόδοση μιας επένδυσης. Για την ποσοτικοποίηση του κινδύνου χρησιμοποιείται η τυπική απόκλιση των αποδόσεων, λαμβάνοντας υπόψη τις μεταβολές των χρηματοοικονομικών δεικτών και τον βαθμό έκθεσης της επιχείρησης σε αυτές (Ruiz & Zeron, 2022).

Σε επίπεδο ταξινόμησης, ο κίνδυνος αγοράς διαχωρίζεται σε:

- Συστηματικό κίνδυνο, ο οποίος προέρχεται από απρόβλεπτες μεταβολές στο μακροοικονομικό περιβάλλον. Αυτές οι μεταβολές, όπως μια γεωπολιτική κρίση ή μια νέα κρατική ρύθμιση, επηρεάζουν το σύνολο της αγοράς και είναι δύσκολο να ελεγχθούν από τους επενδυτές.

- Μη συστηματικό κίνδυνο, ο οποίος αφορά συγκεκριμένες επιχειρήσεις ή κλάδους και μπορεί να μειωθεί μέσω στρατηγικών διαχείρισης κινδύνου (risk management), όπως η διαφοροποίηση του χαρτοφυλακίου ή η χρήση παράγωγων χρηματοοικονομικών προϊόντων (derivatives).

Σε κάθε περίπτωση, η διαχείριση του κινδύνου αγοράς είναι καθοριστική για τις επιχειρήσεις και τα χρηματοπιστωτικά ιδρύματα, καθώς τους επιτρέπει να μειώσουν τις πιθανές αρνητικές επιπτώσεις από τις διακυμάνσεις των αγορών (Wang et al., 2023).

1.3.2 Πιστωτικός Κίνδυνος

Ο πιστωτικός κίνδυνος (credit risk) αναφέρεται στον κίνδυνο απωλειών, που μπορεί να προκύψουν όταν ένας αντισυμβαλλόμενος δεν είναι σε θέση να εκπληρώσει τις οικονομικές του υποχρεώσεις. Πρόκειται για έναν από τους πιο σημαντικούς κινδύνους στον τραπεζικό τομέα, καθώς σχετίζεται άμεσα με την ικανότητα των δανειοληπτών να αποπληρώνουν τα δάνειά τους. Στις εμπορικές και στις τραπεζικές συναλλαγές η διαχείριση του πιστωτικού κινδύνου είναι κρίσιμη, καθώς μπορεί να επηρεάσει τόσο την σταθερότητα των τραπεζών όσο και την συνολική λειτουργία των αγορών (Choudhry et al., 2010).

Ακόμη, οι απώλειες που σχετίζονται με τον πιστωτικό κίνδυνο έχουν άμεση επίδραση στην αξία των επενδύσεων, καθώς αυξάνουν το κόστος αντικατάστασης των κεφαλαίων που χάνονται λόγω αφερεγγυότητας ενός δανειολήπτη. Επιπλέον, ο κίνδυνος αυτός αυξάνεται όταν υπάρχει υπερβολική συσσώρευση δανείων σε λίγους πελάτες ή επιχειρήσεις, καθώς μια αθέτηση πληρωμής μπορεί να δημιουργήσει σοβαρά προβλήματα ρευστότητας (Kadhim et al., 2023).

Για τη σωστή διαχείριση του πιστωτικού κινδύνου, τα χρηματοπιστωτικά ιδρύματα χρησιμοποιούν στρατηγικές, όπως η θέσπιση ανώτατων και κατώτατων ορίων στις χρηματοδοτήσεις και η απαίτηση εγγυήσεων από τους δανειολήπτες.

Ο πιστωτικός κίνδυνος διακρίνεται σε τέσσερις βασικές κατηγορίες :

- Κίνδυνος Αφερεγγυότητας:* Αναφέρεται στην πιθανότητα ένας πελάτης να μην μπορεί να αποπληρώσει τις οικονομικές του υποχρεώσεις όταν αυτές καθίστανται ληξιπρόθεσμες. Στις τράπεζες, αυτός ο κίνδυνος αφορά την πιθανότητα να μην υπάρχουν αρκετά κεφάλαια για να καλυφθούν οι ζημιές που προκύπτουν από μη εξυπηρετούμενα δάνεια.
- Κίνδυνος Έκθεσης:* Αντιπροσωπεύει το συνολικό ποσό που βρίσκεται σε κίνδυνο λόγω παροχής πιστώσεων. Εμφανίζεται κυρίως σε περιπτώσεις δανείων, επενδύσεων σε ομόλογα, παράγωγα χρηματοοικονομικά προϊόντα και εγγυητικές επιστολές.

- iii. *Κίνδυνος Ανάκτησης:* Αφορά την ικανότητα μιας τράπεζας να ανακτήσει ένα μέρος ή το σύνολο των κεφαλαίων της, εάν ένας οφειλέτης πτωχεύσει. Η πιθανότητα ανάκτησης εξαρτάται από το είδος και την αξία των εγγυήσεων που έχει λάβει η τράπεζα, καθώς και από την σειρά προτεραιότητας στην οποία κατατάσσεται ο πιστωτής έναντι των υπόλοιπων απαιτήσεων. Το ποσοστό των κεφαλαίων που μπορεί να ανακτηθεί ονομάζεται *recovery rate*.
- iv. *Κίνδυνος Περιθωρίου:* Σχετίζεται με πιθανές μεταβολές στα πιστωτικά περιθώρια (*credit spreads*) και τον τρόπο με τον οποίο αξιολογούνται οι πιστοδοτήσεις ανάλογα με τις συνθήκες της αγοράς. Οι αλλαγές στα πιστωτικά περιθώρια μπορούν να επηρεάσουν την τιμολόγηση των δανείων και να συνδέονται άμεσα με τον επιτοκιακό κίνδυνο και τη διάρκεια των χρεογράφων.

Αναμφισβήτητα ο πιστωτικός κίνδυνος αποτελεί έναν από τους σημαντικότερους κινδύνους στο τραπεζικό σύστημα, γι' αυτό και η συνεχής παρακολούθηση και η διαχείρισή του είναι κρίσιμες. Η εφαρμογή αποτελεσματικών στρατηγικών, όπως η διαφοροποίηση των δανείων και η χρήση τεχνικών ανάλυσης πιστωτικού κινδύνου, βοηθά τις τράπεζες να ελαχιστοποιήσουν τις πιθανές ζημιές και να εξασφαλίσουν τη σταθερότητά τους (Altman et al., 2005; Scott et al., 2024).

1.3.3 Κίνδυνος Ρευστότητας

Ο κίνδυνος ρευστότητας (*liquidity risk*) αναφέρεται στην πιθανότητα ένα χρηματοπιστωτικό ίδρυμα να μην μπορεί να ανταποκριθεί άμεσα στις οικονομικές του υποχρεώσεις ή να ρευστοποιήσει περιουσιακά στοιχεία χωρίς να υποστεί σημαντική ζημία. Αυτό μπορεί να συμβεί, είτε λόγω έλλειψης αγοραστικού ενδιαφέροντος είτε εξαιτίας περιορισμένης πρόσβασης σε κεφάλαια. Ουσιαστικά, ο κίνδυνος ρευστότητας προκύπτει όταν υπάρχει δυσαρμονία μεταξύ των απαιτήσεων και των υποχρεώσεων μιας εταιρείας, με αποτέλεσμα να καθίσταται δύσκολη η κάλυψη των άμεσων οικονομικών αναγκών. Σε τέτοιες περιπτώσεις, μια εταιρεία μπορεί να αναγκαστεί να πουλήσει περιουσιακά στοιχεία σε χαμηλότερη τιμή από την πραγματική τους αξία, προκειμένου να αντλήσει κεφάλαια (Davydov et al., 2020).

Ο κίνδυνος ρευστότητας διακρίνεται σε δύο βασικές κατηγορίες:

- a. *Κίνδυνος ρευστότητας αγοράς (market liquidity risk):* Αναφέρεται στην δυσκολία πώλησης ενός περιουσιακού στοιχείου σε σύντομο χρονικό διάστημα, σε τιμή που να αντανάκλα την πραγματική του αξία. Αυτό συμβαίνει συνήθως όταν η αγορά δεν έχει επαρκές βάθος ή όταν υπάρχει χαμηλό επενδυτικό ενδιαφέρον. Σε αυτές τις περιπτώσεις, το περιουσιακό στοιχείο μπορεί να ρευστοποιηθεί μόνο με σημαντική έκπτωση, προκαλώντας ζημία στον κάτοχό του.

Ένα χαρακτηριστικό παράδειγμα είναι η δυσκολία πώλησης τίτλων κατά την διάρκεια οικονομικών κρίσεων, όταν οι επενδυτές είναι απρόθυμοι να αγοράσουν.

- b. *Κίνδυνος χρηματοδότησης ρευστότητας (funding liquidity risk)*: Αφορά την πιθανότητα μια επιχείρηση ή ένα χρηματοπιστωτικό ίδρυμα να μην μπορεί να εξασφαλίσει τα απαραίτητα κεφάλαια για να καλύψει τις άμεσες ταμειακές του υποχρεώσεις. Αυτό μπορεί να προκύψει λόγω δυσκολιών στην δανειοδότηση, είτε επειδή οι επενδυτές και οι τράπεζες δεν είναι διατεθειμένοι να παρέχουν κεφάλαια είτε λόγω περιορισμένης πρόσβασης στις αγορές χρήματος. Σε ακραίες περιπτώσεις, η έλλειψη ρευστότητας μπορεί να οδηγήσει ακόμα και σε χρεοκοπία.

Αναλυτικότερα, ο κίνδυνος ρευστότητας είναι κρίσιμος τόσο για τις επιχειρήσεις όσο και για το χρηματοπιστωτικό σύστημα στο σύνολό του, αφού μπορεί να προκαλέσει αλυσιδωτές επιπτώσεις που επηρεάζουν την οικονομία, ιδιαίτερα σε περιόδους χρηματοοικονομικών κρίσεων. Για τον λόγο αυτό, οι επιχειρήσεις και τα χρηματοπιστωτικά ιδρύματα εφαρμόζουν στρατηγικές διαχείρισης ρευστότητας, όπως η διατήρηση επαρκών αποθεμάτων σε μετρητά, η διαφοροποίηση των πηγών χρηματοδότησης και η παρακολούθηση των ταμειακών ροών τους, ώστε να μειώσουν την έκθεσή τους στον συγκεκριμένο κίνδυνο (Brunnermeier & Pedersen, 2009).

1.3.4 Επιτοκιακός Κίνδυνος

Ο επιτοκιακός κίνδυνος αφορά τις αρνητικές επιπτώσεις που μπορεί να προκύψουν από μεταβολές στα επιτόκια. Οι αλλαγές αυτές επηρεάζουν την αξία των χρηματοοικονομικών τίτλων, υπό την προϋπόθεση ότι όλοι οι υπόλοιποι παράγοντες που διαμορφώνουν τις τιμές, παραμένουν σταθεροί. Παράλληλα, ο κίνδυνος αυτός συνδέεται και με το κόστος διακράτησης ενός στοιχείου του ενεργητικού, το οποίο μπορεί να είναι είτε θετικό είτε αρνητικό. Αυτό εξαρτάται από το αν το κόστος χρηματοδότησης είναι υψηλότερο ή χαμηλότερο από την απόδοση που προσφέρει το συγκεκριμένο στοιχείο (Staikouras, 2003).

Χαρακτηριστικό παράδειγμα επιτοκιακού κινδύνου αποτελούν τα δάνεια με κυμαινόμενο επιτόκιο. Όταν τα επιτόκια αυξάνονται, το κόστος εξυπηρέτησης του δανείου γίνεται μεγαλύτερο, γεγονός που μπορεί να επιβαρύνει σημαντικά τον δανειολήπτη. Αντίστοιχα, οι αυξομειώσεις των επιτοκίων μπορούν να οδηγήσουν σε απώλειες κεφαλαίου για τους κατόχους χρηματοοικονομικών τίτλων, όπως τα ομόλογα (Jobst & Zenios, 2005). Συγκεκριμένα, η αξία των ομολόγων προσαρμόζεται στις διακυμάνσεις των επιτοκίων της αγοράς. Σε ένα ανταγωνιστικό περιβάλλον, κάθε επένδυση θα πρέπει να αποδίδει συγκρίσιμα κέρδη σε σχέση με τις εναλλακτικές επιλογές που είναι διαθέσιμες.

Για παράδειγμα, αν ένα ομόλογο αποδίδει ετήσιο τόκο 8% και το επιτόκιο της αγοράς είναι επίσης 8%, η τιμή του ομολόγου θα διατηρείται στην ονομαστική του αξία. Ωστόσο, αν το επιτόκιο της αγοράς αυξηθεί στο 9%, το συγκεκριμένο ομόλογο θα καταστεί λιγότερο ελκυστικό, καθώς θα αποδίδει χαμηλότερο τόκο από τις νέες εκδόσεις ομολόγων. Αυτό θα οδηγήσει σε μείωση της αξίας του. Αντίθετα, αν το επιτόκιο της αγοράς μειωθεί στο 7%, το κουπόνι του 8% καθίσταται πιο ανταγωνιστικό, αυξάνοντας τη ζήτηση για το ομόλογο και, κατά συνέπεια, την τιμή του (Chen & Sakouba, 2021).

Επομένως είναι ξεκάθαρο ότι, οι κάτοχοι ομολόγων και γενικότερα οι επενδυτές που έχουν τοποθετήσεις σε χρηματοοικονομικά προϊόντα με σταθερές αποδόσεις εκτίθενται στον επιτοκιακό κίνδυνο, γιατί η αξία των τίτλων τους επηρεάζεται συνεχώς από τις διακυμάνσεις των επιτοκίων. Ως εκ τούτου, είναι σημαντικό οι επενδυτές και τα χρηματοπιστωτικά ιδρύματα να λαμβάνουν υπόψη τις πιθανές επιπτώσεις του επιτοκιακού κινδύνου στις επενδυτικές τους αποφάσεις και να αναπτύσσουν στρατηγικές για τη διαχείρισή του.

1.3.5 Λειτουργικός Κίνδυνος

Ο λειτουργικός κίνδυνος (operational risk) αφορά τα προβλήματα που μπορεί να προκύψουν λόγω ανεπαρκών εσωτερικών διαδικασιών, ανθρώπινων λαθών, αλλά και τεχνικών δυσλειτουργιών σε πληροφοριακά συστήματα. Εκτός από εσωτερικούς παράγοντες, τα εξωτερικά γεγονότα, όπως φυσικές καταστροφές ή τρομοκρατικές επιθέσεις, μπορούν επίσης να επηρεάσουν την λειτουργία μιας επιχείρησης, προκαλώντας προβλήματα στις συναλλαγές ή μειώνοντας την αξία των περιουσιακών της στοιχείων. Λειτουργικοί κίνδυνοι μπορούν να εκδηλωθούν με διάφορους τρόπους. Λόγου χάριν, μια σοβαρή βλάβη στα συστήματα μιας τράπεζας μπορεί να οδηγήσει σε προσωρινή διακοπή συναλλαγών, επηρεάζοντας τόσο τους πελάτες όσο και τη φήμη της. Επίσης, η κακή διαχείριση μιας εισηγμένης εταιρείας μπορεί να προκαλέσει σημαντικές οικονομικές απώλειες για τους επενδυτές της (Jednak et al., 2013).

Ο λειτουργικός κίνδυνος θεωρείται κρίσιμος παράγοντας για τη βιωσιμότητα των επιχειρήσεων, γι' αυτό και απαιτείται συνεχής παρακολούθηση και ανάπτυξη στρατηγικών διαχείρισης, όπως η υιοθέτηση εσωτερικών ελέγχων, η βελτίωση των διαδικασιών και η εφαρμογή προηγμένων τεχνολογικών λύσεων για τη μείωση λαθών και τεχνικών προβλημάτων (Girling, 2013).

1.3.6 Νομικός Κίνδυνος

Ο νομικός κίνδυνος (legal risk) αφορά την πιθανότητα μια επιχείρηση να υποστεί οικονομικές απώλειες λόγω νομικών ζητημάτων, είτε αυτά προκύπτουν από ασαφείς ή ελλιπώς εφαρμοσμένες νομικές διαδικασίες είτε από δυσμενείς νομικές εξελίξεις στη χώρα όπου δραστηριοποιείται. Σε πολλές περιπτώσεις, ο κίνδυνος αυτός έχει διεθνείς προεκτάσεις, καθώς το ρυθμιστικό πλαίσιο που

διέπει τις επιχειρήσεις και τις τραπεζικές δραστηριότητες διαφέρει σημαντικά από χώρα σε χώρα, δημιουργώντας αβεβαιότητα στις επενδύσεις (Hanani, 2022).

Ένας βασικός παράγοντας που εντείνει τον νομικό κίνδυνο είναι η λανθασμένη νομική καθοδήγηση ή η ελλιπής τεκμηρίωση, η οποία μπορεί να οδηγήσει σε νομικές κυρώσεις ή σε μείωση της αξίας των περιουσιακών στοιχείων μιας επιχείρησης. Επιπρόσθετα, ο νομικός κίνδυνος συνδέεται και με παράνομες πρακτικές, όπως η χρήση εσωτερικής πληροφόρησης (inside trading) και η χειραγώγηση τιμών (price manipulation), οι οποίες μπορούν να διαταράξουν τη λειτουργία της αγοράς και να οδηγήσουν σε σοβαρές νομικές συνέπειες για τις εταιρείες που εμπλέκονται.

Η αποτελεσματική διαχείριση του νομικού κινδύνου είναι ευθύνη της νομικής υπηρεσίας κάθε επιχείρησης, η οποία συνεργάζεται στενά με τη διοίκηση για να διασφαλίσει τη συμμόρφωση με το εκάστοτε νομικό και ρυθμιστικό πλαίσιο. Ιδιαίτερη σημασία δίνεται στη συνεχή παρακολούθηση των αλλαγών στη νομοθεσία, στη σωστή νομική τεκμηρίωση των συναλλαγών και στη διαμόρφωση στρατηγικών που μειώνουν τον κίνδυνο νομικών εμπλοκών (Girling, 2013).

1.3.7 Συναλλαγματικός Κίνδυνος

Ο συναλλαγματικός κίνδυνος (exchange rate risk) αποτελεί έναν από τους βασικούς κινδύνους αγοράς και σχετίζεται με τις διακυμάνσεις στις συναλλαγματικές ισοτιμίες. Αυτές οι διακυμάνσεις μπορούν να επηρεάσουν άμεσα τη συνολική καθαρή θέση ενός χρηματοπιστωτικού οργανισμού ή την αξία ενός χαρτοφυλακίου που περιλαμβάνει επενδύσεις σε ξένα νομίσματα (Hutson & Laing, 2014). Οι τράπεζες είναι ιδιαίτερα εκτεθειμένες στον συναλλαγματικό κίνδυνο, καθώς συμμετέχουν ενεργά στις τρέχουσες και προθεσμιακές αγορές συναλλάγματος, διακρατώντας θέσεις σε διαφορετικά νομίσματα. Οι μεταβολές στις συναλλαγματικές ισοτιμίες μπορούν να επηρεάσουν τις επενδύσεις και τα διαθέσιμά τους, είτε αυτά χρησιμοποιούνται για ιδία διαχείριση είτε για λογαριασμό πελατών. Ο συνολικός συναλλαγματικός κίνδυνος που αναλαμβάνει μια τράπεζα προκύπτει από το άθροισμα των επιμέρους κινδύνων που σχετίζονται με κάθε νόμισμα ξεχωριστά.

Για τον περιορισμό των πιθανών απωλειών, οι τράπεζες και οι επιχειρήσεις που δραστηριοποιούνται σε διεθνείς συναλλαγές εφαρμόζουν στρατηγικές διαχείρισης του συναλλαγματικού κινδύνου. Κάποιες από τις πιο συνηθισμένες τακτικές περιλαμβάνουν:

- Την προσαρμογή των συναλλαγματικών θέσεων, ώστε να μειώνεται η έκθεση σε νόμισμα με μεγάλη μεταβλητότητα.
- Την εξισορρόπηση των ποσών σε διαφορετικά νομίσματα, ώστε να μειώνεται ο αντίκτυπος από πιθανές διακυμάνσεις.

- Την στρατηγική ανάληψης κόστους ή ζημίας, με την οποία μια επιχείρηση μπορεί να κλείσει μια θέση σε συναλλάγμα προτού υποστεί μεγαλύτερες απώλειες ή να ανοίξει μια νέα που θα είναι πιο ευνοϊκή με βάση τις αγορές.

Η αποτελεσματική διαχείριση του συναλλαγματικού κινδύνου είναι απαραίτητη για τη σταθερότητα των τραπεζών και των επιχειρήσεων που συναλλάσσονται σε διεθνές επίπεδο, καθώς οι διακυμάνσεις στις ισοτιμίες μπορούν να επηρεάσουν δραστικά τα οικονομικά αποτελέσματά τους (Mathur & Knowles, 1985).

1.3.8 Κίνδυνος Χώρας

Ο κίνδυνος χώρας (country risk) αναφέρεται στην πιθανότητα μια επιχείρηση ή ένας επενδυτής να υποστεί ζημίες λόγω της οικονομικής, πολιτικής ή κοινωνικής κατάστασης μιας χώρας. Οι μεταβολές στο εσωτερικό περιβάλλον μιας χώρας μπορούν να επηρεάσουν αρνητικά την λειτουργία των επιχειρήσεων και τη σταθερότητα των επενδύσεων, ειδικά όταν αυτές δραστηριοποιούνται σε διεθνές επίπεδο (Iranzo, 2008).

Αυτός ο κίνδυνος προέρχεται από διάφορους παράγοντες, όπως:

- Πολιτικές εξελίξεις, όπως αλλαγές στη φορολογία, τις κρατικές δαπάνες ή την εμπορική πολιτική, καθώς και εκλογικές ανακατατάξεις που μπορεί να δημιουργήσουν αβεβαιότητα στην αγορά.
- Οικονομικές συνθήκες, όπως ο πληθωρισμός, οι διακυμάνσεις των επιτοκίων, το δημοσιονομικό έλλειμμα και το δημόσιο χρέος, τα οποία επηρεάζουν την επενδυτική δραστηριότητα.
- Κοινωνικούς παράγοντες, όπως κοινωνικές αναταραχές, απεργίες και εθνοτικές συγκρούσεις, που μπορεί να επηρεάσουν τη σταθερότητα του επιχειρηματικού περιβάλλοντος.

Ο κίνδυνος χώρας δεν επηρεάζει μόνο τις επιχειρήσεις, αλλά και τις διεθνείς τράπεζες και τους επενδυτές, ιδιαίτερα όσους δραστηριοποιούνται σε αναδυόμενες αγορές. Σε αυτές τις περιπτώσεις, η αβεβαιότητα λειτουργεί αποτρεπτικά για νέες επενδύσεις και μπορεί να μειώσει την κερδοφορία όσων έχουν ήδη τοποθετηθεί στην αγορά. (Iranzo, 2008)

Μια ειδική μορφή του κινδύνου χώρας είναι ο κίνδυνος κρατικής χρεοκοπίας (sovereign risk), που σχετίζεται με την ικανότητα μιας χώρας να αποπληρώσει το κρατικό της χρέος. Αυτός ο κίνδυνος περιλαμβάνει:

- Τον κίνδυνο αθέτησης πληρωμών, όπου το κράτος αδυνατεί να εξοφλήσει τις διεθνείς οικονομικές του υποχρεώσεις.
- Τον κίνδυνο μεταφοράς συναλλάγματος (transfer risk), όπου η κυβέρνηση επιβάλλει περιορισμούς στη μεταφορά κεφαλαίων εκτός της χώρας, δυσχεραίνοντας τις διεθνείς συναλλαγές.
- Γενικότερους οικονομικούς κινδύνους, που μπορεί να επηρεάσουν την ελκυστικότητα μιας χώρας για επενδύσεις.

Λόγω της σημασίας του, ο κίνδυνος χώρας λαμβάνεται σοβαρά υπόψη από εταιρείες και επενδυτές, οι οποίοι χρησιμοποιούν μεθόδους αξιολόγησης, όπως οι αναλύσεις πολιτικού και οικονομικού κινδύνου, ώστε να μειώσουν την έκθεσή τους σε απρόβλεπτες μεταβολές του διεθνούς περιβάλλοντος (Iranzo, 2008; Damodaran, 2015).

1.3.9 Κίνδυνος διακανονισμού πληρωμών

Ο κίνδυνος διακανονισμού (settlement risk) αναφέρεται στην πιθανότητα ένας από τους δύο αντισυμβαλλόμενους σε μια συναλλαγή να μην εκπληρώσει τις υποχρεώσεις του, αφού το άλλο μέρος έχει ήδη προχωρήσει στην πληρωμή. Ο κίνδυνος αυτός είναι ιδιαίτερα εμφανής στις συναλλαγές που περιλαμβάνουν συνάλλαγμα, όπου η μεταφορά χρημάτων από τη μία τράπεζα στην άλλη πραγματοποιείται μέσω των κεντρικών τραπεζών των αντίστοιχων νομισμάτων.

Ένα από τα πιο γνωστά ιστορικά παραδείγματα κινδύνου διακανονισμού είναι η περίπτωση της γερμανικής τράπεζας Herstatt, η οποία κατέρρευσε πριν ολοκληρωθεί η μεταφορά πληρωμών σε δολάρια προς αμερικανικές τράπεζες. Το γεγονός αυτό ανέδειξε τους κινδύνους που ελλοχεύουν κυρίως στη διατραπεζική αγορά, όπου οι συναλλαγές αφορούν μεγάλα ποσά. Αν μια τράπεζα αντιμετωπίσει πρόβλημα κατά τη διάρκεια μιας συναλλαγής, ενδέχεται να προκληθεί αλυσιδωτή αντίδραση, επηρεάζοντας και άλλες χρηματοπιστωτικές οντότητες (Mourlon, 2015).

1.3.10 Κίνδυνος Αξιοπιστίας

Ο κίνδυνος φήμης και αξιοπιστίας (reputation and reliability risk) εμφανίζεται όταν μια τράπεζα έχει ιστορικό επαναλαμβανόμενων αποτυχιών, είτε σε επίπεδο λειτουργικών συστημάτων είτε στην διαχείριση και τα χρηματοοικονομικά της προϊόντα. Τέτοιες αποτυχίες μπορούν να κλονίσουν την εμπιστοσύνη των συναλλασσόμενων, υπονομεύοντας την ίδια τη φύση των τραπεζικών εργασιών, οι οποίες βασίζονται σε μεγάλο βαθμό στη σταθερότητα και την αξιοπιστία των συμμετεχόντων στην αγορά (Barakat et al., 2017).

1.4 Ανακεφαλαίωση

Το παρόν κεφάλαιο επικεντρώθηκε στην έννοια του κινδύνου, καθώς και στην αλληλεπίδρασή του με τις διάφορες μορφές του, τόσο για τα χρηματοπιστωτικά ιδρύματα όσο και για τους επενδυτές και τις επιχειρήσεις. Αρχικά, πραγματοποιήθηκε μια γενική περιγραφή του κινδύνου, συνοδευόμενη από μια πρώτη κατηγοριοποίηση των διαφορετικών ειδών του. Στη συνέχεια, αναλύθηκε ο λόγος για τον οποίο τα χρηματοπιστωτικά ιδρύματα επιδιώκουν να αναλάβουν και να διαχειριστούν τους κινδύνους. Τέλος, παρουσιάστηκαν αναλυτικά όλοι οι τύποι χρηματοοικονομικών κινδύνων, με ιδιαίτερη έμφαση στους παράγοντες που τους εμφανίζουν.

Κεφάλαιο 2^ο: Ανασκόπηση των Μεθόδων Υπολογιστικής Νοημοσύνης και Μηχανικής Μάθησης

2.1 Τι είναι η Υπολογιστική Νοημοσύνη

Σύμφωνα με τους Duch et al. (2007), η νοημοσύνη ορίζεται ως «η ικανότητα εκμάθησης, κατανόησης και αντιμετώπισης νέων ή πολύπλοκων καταστάσεων». Αναλυτικότερα, ο όρος υπολογιστική νοημοσύνη εμφανίστηκε για πρώτη φορά το 1994, στο Παγκόσμιο Συνέδριο Υπολογιστικής Νοημοσύνης (*World Congress on Computational Intelligence*). Σε γενικές γραμμές αποτελεί έναν κλάδο της τεχνητής νοημοσύνης, ο οποίος εστιάζει στην ανάπτυξη αλγορίθμων και μεθοδολογιών, που επιτρέπουν στα υπολογιστικά συστήματα να προσαρμόζονται δυναμικά, να μαθαίνουν από δεδομένα και να επιλύουν πολύπλοκα προβλήματα.

Οι τεχνικές της CI είναι εμπνευσμένες από τη βιολογική και φυσική νοημοσύνη, οδηγώντας στην δημιουργία των λεγόμενων "*ευφυών συστημάτων*". Ένα βασικό χαρακτηριστικό, των συστημάτων είναι ότι μπορούν να λειτουργούν αποτελεσματικά χωρίς να απαιτείται αυστηρή μαθηματική μοντελοποίηση του προβλήματος. Παρακάτω θα αναφερθούν οι κύριοι πυλώνες της CI:

- i. *Νευρωνικά Δίκτυα (Neural Networks - NN)*: Πρόκειται για υπολογιστικά μοντέλα που μιμούνται την δομή και την λειτουργία του ανθρώπινου εγκεφάλου. Επίσης μαθαίνουν μέσω εμπειρίας και βρίσκουν εφαρμογή σε ένα ευρύ φάσμα προβλημάτων της μηχανικής μάθησης (Kumar et al., 2012).
- ii. *Εξελικτικοί Αλγόριθμοι (Evolutionary Algorithms - EA)*: Βασίζονται στις αρχές της φυσικής επιλογής και της γενετικής εξέλιξης, επιτρέποντας την εύρεση βέλτιστων λύσεων μέσω διαδικασιών όπως οι γενετικοί αλγόριθμοι και οι στρατηγικές εξέλιξης (Rhinehart et al., 2018).
- iii. *Ασαφής Λογική (Fuzzy Logic - FL)*: Χρησιμοποιείται για την αντιμετώπιση καταστάσεων όπου επικρατεί αβεβαιότητα ή έλλειψη ακριβών δεδομένων, επιτρέποντας μια προσέγγιση όμοια με τον ανθρώπινο τρόπο σκέψης. (Metaxiotis et al., 2004).

Με τη συνεχή εξέλιξη των αλγορίθμων και των εφαρμογών της, η CI καθίσταται ολοένα και πιο σημαντική σε τομείς όπως η χρηματοοικονομική ανάλυση, η ρομποτική και η βελτιστοποίηση σύνθετων συστημάτων. Συμπεραίνουμε λοιπόν ότι, η CI αποτελεί έναν ευρύ ερευνητικό κλάδο που περιλαμβάνει διάφορες μεθοδολογίες και προσεγγίσεις για την ανάπτυξη ευφυών συστημάτων. Ένας από τους πιο σημαντικούς και ταχέως εξελισσόμενους τομείς της είναι η *Μηχανική Μάθηση* (Machine Learning - ML). Η ML αποτελεί αναπόσπαστο κομμάτι πολλών τεχνικών της CI, αξιοποιώντας

αλγορίθμους που επιτρέπουν τα συστήματα να εντοπίζουν πρότυπα, να κάνουν προβλέψεις και να λαμβάνουν αποφάσεις (Arsić et al., 2021).

2.2 Η Σχέση της Υπολογιστικής Νοημοσύνης με τη Μηχανική Μάθηση

Όπως προαναφέρθηκε η ML είναι ένας υποκλάδος της υπολογιστικής νοημοσύνης, που εστιάζει στη δημιουργία αλγορίθμων, οι οποίοι επιτρέπουν στους υπολογιστές να μαθαίνουν από δεδομένα με αποτέλεσμα τη βελτίωση της απόδοσής τους. Παρότι η ML και η CI συχνά θεωρούνται ως ανεξάρτητοι τομείς, υπάρχει μια σημαντική αλληλοεπικάλυψη μεταξύ τους. Όπως:

- i. Οι αλγόριθμοι μηχανικής μάθησης, όπως τα νευρωνικά δίκτυα, βασίζονται σε τεχνικές που ανήκουν στην CI (Kumar et al., 2012).
- ii. Οι εξελικτικοί αλγόριθμοι μπορούν να χρησιμοποιηθούν για την βελτιστοποίηση υπερπαραμέτρων σε μοντέλα ML (Rhinehart et al., 2018).
- iii. Η θολή λογική μπορεί να συνδυαστεί με την ML για την αντιμετώπιση προβλημάτων όπου υπάρχει αβεβαιότητα και ασάφεια στα δεδομένα (Metaxiotis et al., 2004).

Αντίθετα, η ML εστιάζει κυρίως στην ανάλυση δεδομένων και στην ανάπτυξη μοντέλων πρόβλεψης, ενώ η CI περιλαμβάνει ένα ευρύτερο σύνολο τεχνικών που μιμούνται τις διεργασίες της φύσης. Παρ' όλα αυτά, η σύγκλιση των δύο πεδίων έχει οδηγήσει στην ανάπτυξη ισχυρών υβριδικών μεθόδων που συνδυάζουν και τις δυο μεθόδους για τη δημιουργία αποδοτικότερων και ευφυέστερων συστημάτων (Arsić et al., 2021).

2.3 Ορισμός Μηχανικής Μάθησης

Η ML αποτελεί θεμελιώδη κλάδο της τεχνητής νοημοσύνης, η οποία εστιάζει στην ανάπτυξη αλγορίθμων και υπολογιστικών μοντέλων που διαθέτουν την ικανότητα να μαθαίνουν από δεδομένα και να βελτιώνουν την απόδοσή τους. Αυτό γίνεται μέσω της εμπειρίας, χωρίς να απαιτείται ρητός προγραμματισμός. Σε αντίθεση με τις παραδοσιακές προσεγγίσεις, οι αλγόριθμοί της δεν βασίζονται σε έναν αυστηρά καθορισμένο κανόνα, αλλά αντλούν γνώση από μεγάλα σύνολα δεδομένων, από τα οποία αναγνωρίζουν μοτίβα και προσαρμόζονται σε νέα δεδομένα (Alnuaimi et al., 2024).

Επιπλέον οι μέθοδοι ML δεν βασίζονται σε στατιστική δειγματοληψία, όπως συμβαίνει στις κλασικές στατιστικές προσεγγίσεις, ούτε πραγματοποιούν ελέγχους υπόθεσης, αλλά μέσω μοντέλων αβεβαιότητας υποθέτουν συγκεκριμένες κατανομές στα δεδομένα. Αντίθετα, τα δεδομένα αναπαρίστανται μέσω δικτύων ή γραφημάτων, ενώ η αξιολόγηση των μοντέλων πραγματοποιείται με τη χρήση πιθανοτήτων και μετρικών απόδοσης (Purpala, 2025).

Ειδικότερα, για την εκπαίδευση ενός μοντέλου τα δεδομένα διαχωρίζονται σε δεδομένα εκπαίδευσης, τα οποία χρησιμοποιούνται για την μάθηση του αλγορίθμου, δεδομένα ελέγχου, που βοηθούν στην ρύθμιση των παραμέτρων του μοντέλου και δεδομένα επικύρωσης, τα οποία χρησιμοποιούνται για την τελική αξιολόγηση της απόδοσής του. Η διαδικασία μάθησης μπορεί να πραγματοποιηθεί είτε σε πραγματικό χρόνο (on-line), όπου το μοντέλο προσαρμόζεται συνεχώς στα νέα δεδομένα, είτε εκτός πραγματικού χρόνου (off-line), όπου η εκπαίδευση πραγματοποιείται σε προκαθορισμένα σύνολα δεδομένων πριν από την εφαρμογή του μοντέλου (Alnuaimi et al., 2024).

Μεταξύ των διαφόρων τεχνικών μηχανικής μάθησης, τα ANN ξεχωρίζουν λόγω της αυξημένης σημασίας τους και της εξαιρετικής τους ικανότητας να επεξεργάζονται μεγάλα και σύνθετα σύνολα δεδομένων. Ακόμη χρησιμοποιούνται ευρέως σε προβλήματα πρόβλεψης, ταξινόμησης και αναγνώρισης προτύπων, ενώ αποτελούν τη βάση για πιο προηγμένες προσεγγίσεις, όπως η DL (Mousavi et al., 2018). Επιπλέον, οι πρόσφατες εφαρμογές τους, ειδικά σε τομείς όπως η διαχείριση χρηματοοικονομικών κινδύνων και η πρόβλεψη αγορών, ενισχύουν ακόμη περισσότερο την σπουδαιότητά τους (Rezaei et al., 2025). Για τον λόγο αυτό, αφιερώνεται ειδική ενότητα στην ανάλυση της δομής, των αρχών λειτουργίας και των εφαρμογών τους.

2.3.1 Κατηγορίες Μηχανικής Μάθησης

Η ML περιλαμβάνει διάφορες προσεγγίσεις, οι οποίες διακρίνονται κυρίως με βάση τον τρόπο με τον οποίο τα μοντέλα εκπαιδεύονται και προσαρμόζονται στα δεδομένα. Οι βασικές κατηγορίες αναλύονται παρακάτω.

2.3.1.1 Εποπτευόμενη Μάθηση (Supervised Learning)

Η εποπτευόμενη μάθηση περιλαμβάνει την εκπαίδευση ενός αλγορίθμου χρησιμοποιώντας ένα σύνολο δεδομένων, όπου κάθε δείγμα συνοδεύεται από μια γνωστή κατηγορία ή τιμή. Το μοντέλο μαθαίνει να συσχετίζει τα χαρακτηριστικά των δεδομένων με τις αντίστοιχες κατηγορίες, ώστε να μπορεί να ταξινομεί νέα δεδομένα (Syed & Lokhande, 2024). Οι κατηγορίες αυτές είναι:

- i. *Ταξινόμηση (Classification)*: Αναφέρεται στην κατηγοριοποίηση των δεδομένων σε διακριτές κατηγορίες. Για παράδειγμα αλγόριθμοι που χρησιμοποιούνται για ταξινόμηση είναι τα νευρωνικά δίκτυα, τα δέντρα απόφασης και ο αλγόριθμος του Random Forest (Verma & Kumar, 2018).
- ii. *Παλινδρόμηση (Regression)*: Χρησιμοποιείται για την πρόβλεψη αριθμητικών τιμών, βασιζόμενη στη σχέση ανεξάρτητων και εξαρτημένων μεταβλητών. Οι τυπικές τεχνικές παλινδρόμησης περιλαμβάνουν την γραμμική παλινδρόμηση, τη λογιστική παλινδρόμηση και την πολυωνμική παλινδρόμηση (Verma & Kumar, 2018).

Ο τύπος των αλγορίθμων μηχανικής μάθησης μπορεί να ποικίλλει από γραμμική παλινδρόμηση και ταξινόμηση έως πολύπλοκα νευρο-ασαφή συστήματα. Στην ενότητα που ακολουθεί παρουσιάζονται δημοφιλείς αλγόριθμοι μηχανικής μάθησης.

2.3.1.2 Γραμμική Παλινδρόμηση (Linear Regression)

Η γραμμική παλινδρόμηση είναι ένας από τους πιο βασικούς και ευρέως εφαρμοσμένους αλγορίθμους στην CI και την ανάλυση δεδομένων. Πιο συγκεκριμένα, χρησιμοποιείται με στόχο την ανάλυση της σχέσης μεταξύ μιας εξαρτημένης μεταβλητής (target) και μίας ή περισσότερων ανεξάρτητων μεταβλητών (features). Αυτό γίνεται μέσω της προσαρμογής μιας ευθείας γραμμής που ελαχιστοποιεί το σφάλμα πρόβλεψης (Purpala, 2025).

Η γενική μορφή της απλής γραμμικής παλινδρόμησης δίνεται από την εξίσωση:

$$Y = \beta_0 + \beta_1 X + \varepsilon \quad (1)$$

όπου:

- Y είναι η εξαρτημένη μεταβλητή (π.χ., η απόδοση μιας μετοχής),
- X είναι η ανεξάρτητη μεταβλητή (π.χ., ένας μακροοικονομικός δείκτης),
- β_0, β_1 είναι οι παράμετροι που υπολογίζονται μέσω της μεθόδου των ελαχίστων τετραγώνων,
- ε είναι το σφάλμα.

Η γραμμική παλινδρόμηση χρησιμοποιείται εκτενώς στη χρηματοοικονομική ανάλυση για την πρόβλεψη αποδόσεων, την ανάλυση κινδύνου και την αξιολόγηση σχέσεων μεταξύ οικονομικών μεταβλητών (Verma & Kumar, 2018).

2.3.2 Δέντρα Απόφασης και Τυχαία Δάση

Τα δέντρα απόφασης και τα τυχαία δάση αποτελούν ισχυρές τεχνικές της εποπτευόμενης μάθησης που χρησιμοποιούνται ευρέως σε προβλήματα ταξινόμησης και παλινδρόμησης. Η δημοτικότητά τους, οφείλεται στην ικανότητα να αναγνωρίζουν πρότυπα, σε μεγάλα και πολύπλοκα σύνολα δεδομένων, με αποτέλεσμα να παρέχουν ερμηνεύσιμα αποτελέσματα και να προσφέρουν προβλέψεις υψηλής ακρίβειας. Στον χρηματοοικονομικό τομέα, οι μέθοδοι αυτοί βρίσκουν εφαρμογή σε πλήθος περιπτώσεων, όπως στην αξιολόγηση πιστωτικού κινδύνου, την ανίχνευση οικονομικής απάτης, την πρόβλεψη τιμών μετοχών και την διαχείριση επενδυτικών χαρτοφυλακίων. Στις επόμενες υποενότητες παρουσιάζονται τα χαρακτηριστικά, οι αλγόριθμοι, τα πλεονεκτήματα, οι περιορισμοί και οι κύριες χρηματοοικονομικές εφαρμογές των δέντρων απόφασης και των τυχαίων δασών.

2.3.2.1 Δέντρα Απόφασης (Decision Trees)

Τα δέντρα απόφασης είναι αλγόριθμοι που χρησιμοποιούνται τόσο για ταξινόμηση όσο και για παλινδρόμηση, βασιζόμενα σε μια διαδοχική διαδικασία λήψης αποφάσεων. Κάθε κόμβος του δέντρου αντιπροσωπεύει μια ερώτηση ή ένα κριτήριο διαχωρισμού, ενώ οι διακλαδώσεις αντιστοιχούν στις πιθανές απαντήσεις. Η διαδικασία αυτήν συνεχίζεται μέχρι να καταλήξει το μοντέλο σε ένα τελικό αποτέλεσμα, το οποίο μπορεί να είναι μια κατηγορία ή μια αριθμητική τιμή (Verma & Kumar, 2018).

Μία από τις βασικές εφαρμογές των δέντρων απόφασης, στην διαχείριση χρηματοοικονομικών κινδύνων, είναι η αξιολόγηση της φερεγγυότητας δανειοληπτών. Στην έρευνα *Decision Trees and Financial Variables* (IGI Global, 2017), αναλύεται η χρήση των δέντρων απόφασης για την ανάλυση δεδομένων, όπως το πιστωτικό ιστορικό, το εισόδημα και η ηλικία ενός πελάτη, με στόχο να εκτιμήσει την πιθανότητα αθέτησης πληρωμών. Επιπλέον, τα δέντρα απόφασης εφαρμόζονται και στην ανίχνευση ύποπτων συναλλαγών, αναγνωρίζοντας μοτίβα που μπορεί να σχετίζονται με οικονομική απάτη (Bramer, 2013).

2.3.2.2 Τυχαία Δάση (Random Forests)

Τα τυχαία δάση αποτελούν μια εξέλιξη των δέντρων απόφασης. Ειδικότερα στοχεύουν στη βελτίωση της ακρίβειας και της αξιοπιστίας των προβλέψεων. Αντί να στηρίζονται σε ένα μόνο δέντρο, δημιουργούν ένα σύνολο μ' αυτά, καθένα από τα οποία εκπαιδεύεται σε διαφορετικά υποσύνολα δεδομένων με αποτελέσματα να συνδυάζονται, βελτιώνοντας τη συνολική απόδοση του αλγορίθμου (Syed & Lokhande, 2024).

Η τεχνική αυτήν βρίσκει εφαρμογή σε διάφορους τομείς της χρηματοοικονομικής ανάλυσης. Για παράδειγμα, χρησιμοποιείται στην μοντελοποίηση του πιστωτικού κινδύνου, όπου επιτρέπει την ακριβέστερη αξιολόγηση των δανειοληπτών. Επιπρόσθετα, τα τυχαία δάση είναι ιδιαίτερα αποτελεσματικά για την πρόβλεψη χρηματιστηριακών τάσεων, καθώς μπορούν να ενσωματώσουν δεδομένα από πολλαπλές πηγές και να μειώσουν τον θόρυβο στις εκτιμήσεις (Purpala 2025).

Ένα σημαντικό πλεονέκτημα του αλγορίθμου, είναι η μειωμένη πιθανότητα υπέρ-προσαρμογής, καθώς η μέθοδος bagging (bootstrap aggregating) εξασφαλίζει ότι το μοντέλο δεν βασίζεται υπερβολικά σε συγκεκριμένα χαρακτηριστικά των δεδομένων εκπαίδευσης (Verma et al., 2018). Ωστόσο, η αυξημένη υπολογιστική απαίτηση και η περιορισμένη ερμηνεία του αποτελέσματος, σε σύγκριση με τα απλά δέντρα απόφασης, είναι δύο βασικοί παράγοντες που πρέπει να ληφθούν υπόψη κατά την επιλογή του αλγορίθμου. Η επιλογή μεταξύ των δύο αλγορίθμων εξαρτάται από τις απαιτήσεις της εκάστοτε εφαρμογής (Purpala, 2025).

2.3.3 Άλλες Μέθοδοι Μάθησης και Μείωσης Διάστασης

Εκτός από τις παραδοσιακές τεχνικές εποπτευόμενης μάθησης, όπως η γραμμική παλινδρόμηση και τα δέντρα απόφασης, έχουν αναπτυχθεί και προηγμένες μέθοδοι που αντιμετωπίζουν πολύπλοκα προβλήματα πρόβλεψης, ταξινόμησης και ανάλυσης δεδομένων. Οι τεχνικές αυτές περιλαμβάνουν τις Μηχανές Διανυσμάτων Υποστήριξης (Support Vector Machines – SVM), την Μη Εποπτευόμενη Μάθηση (Unsupervised Learning) με έμφαση στην Ομαδοποίηση (Clustering) και την Ανάλυση Κύριων Συνιστωσών (Principal Component Analysis – PCA) για μείωση διάστασης.

Αναλυτικότερα, οι μέθοδοι αυτοί χρησιμοποιούνται ευρέως στη διαχείριση χρηματοοικονομικών κινδύνων, καθώς επιτρέπουν την ανάλυση μεγάλων, πολυδιάστατων και μη γραμμικών δεδομένων, οι οποίοι συμβάλλουν στην βελτίωση ακρίβειας της πρόβλεψης και την ανίχνευση κρυφών σχέσεων, που δεν είναι εμφανείς με απλές στατιστικές προσεγγίσεις. Στις επόμενες υποενότητες, παρουσιάζονται αναλυτικά οι βασικές λειτουργίες τους, τα πλεονεκτήματα, οι περιορισμοί και οι σημαντικότερες εφαρμογές τους στον χρηματοοικονομικό τομέα.

2.3.3.1 Μηχανές Διανυσμάτων Υποστήριξης (Support Vector Machines-SVM)

Οι μηχανές διανυσμάτων υποστήριξης αποτελούν μια ισχυρή μεθοδολογία της μηχανικής μάθησης, που εφαρμόζεται κυρίως σε προβλήματα ταξινόμησης και παλινδρόμησης. Ο βασικός στόχος των SVM, είναι η εύρεση του βέλτιστου υπέρ-επιπέδου (optimal hyperplane), το οποίο διαχωρίζει τις κατηγορίες δεδομένων, μεγιστοποιώντας την απόσταση (margin) μεταξύ του υπέρ-επιπέδου και των πλησιέστερων σημείων κάθε κατηγορίας, των λεγόμενων support vectors (Verma & Kumar, 2018).

Σε ένα δυαδικό πρόβλημα ταξινόμησης, η SVM επιχειρεί να διαχωρίσει τα δεδομένα μέσω ενός γραμμικού υπέρ-επιπέδου, που περιγράφεται από την εξίσωση:

$$\mathbf{w} * \mathbf{x} + \mathbf{b} = 0 \quad (2)$$

όπου:

- \mathbf{w} συμβολίζει το διάνυσμα βαρών που καθορίζει τον προσανατολισμό του υπέρ-επιπέδου,
- \mathbf{x} είναι το διάνυσμα εισόδου, δηλαδή τα χαρακτηριστικά των δεδομένων,
- \mathbf{b} αποτελεί τον όρο μετατόπισης (bias).

Η επιλογή του βέλτιστου υπέρ-επιπέδου πραγματοποιείται έτσι ώστε το περιθώριο (margin) μεταξύ των διαφορετικών κατηγοριών να είναι το μέγιστο δυνατό. Όταν τα δεδομένα δεν επιδέχονται γραμμικό διαχωρισμό, οι SVM αξιοποιούν συναρτήσεις πυρήνα (kernel functions), όπως ο πολυωνυμικός πυρήνας (polynomial kernel) και ο πυρήνας ακτινικής βάσης (RBF kernel), με στόχο να

προβούν σε μετασχηματισμό του χώρου και να επιτύχουν αποτελεσματικότερο διαχωρισμό των δεδομένων.

Οι SVM έχουν βρει σημαντική εφαρμογή στον χρηματοοικονομικό τομέα και στην διαχείριση κινδύνων, καθώς επιτρέπουν την ανάλυση και τη μοντελοποίηση σύνθετων οικονομικών μεταβλητών.

Οι βασικές περιοχές εφαρμογής περιλαμβάνουν την:

- i. *Πρόβλεψη τιμών μετοχών*, ανάλυση ιστορικών δεδομένων και οικονομικών δεικτών για την εκτίμηση μελλοντικών μεταβολών στις αγορές (Purpala, 2025).
- ii. *Ανίχνευση οικονομικής απάτης*, ταξινόμηση συναλλαγών με βάση υποδείγματα που υποδηλώνουν ύποπτη ή κακόβουλη δραστηριότητα.
- iii. *Αξιολόγηση πιστωτικού κινδύνου*, κατηγοριοποίηση των δανειοληπτών σύμφωνα με την πιθανότητα αθέτησης των υποχρεώσεών τους, χρησιμοποιώντας ιστορικά οικονομικά στοιχεία.

Επιπλέον είναι σημαντικό να αναφερθεί ότι, οι SVM προσφέρουν σημαντικά πλεονεκτήματα, καθιστώντας τες ιδιαίτερα χρήσιμες σε πολύπλοκα προβλήματα ταξινόμησης και παλινδρόμησης. Ένα από τα βασικά τους πλεονεκτήματα είναι η διαχείριση σύνθετων δεδομένων, ιδιαίτερα όταν χρησιμοποιούνται μη γραμμικοί πυρήνες, επιτρέποντας την αναγνώριση πολύπλοκων σχέσεων στα δεδομένα. Ακόμη, μειώνουν τον κίνδυνο υπερπροσαρμογής (overfitting) μέσω της αρχής της μέγιστης απόστασης (margin maximization) διασφαλίζοντας καλύτερη γενίκευση του μοντέλου. Ένα εξίσου κρίσιμο πλεονέκτημα, είναι η ικανότητά τους να επεξεργάζονται δεδομένα υψηλών διαστάσεων, γεγονός που τις καθιστά ιδανικές για εφαρμογές στη χρηματοοικονομική ανάλυση (Syed et al., 2024).

Ωστόσο, η χρήση των SVM συνοδεύεται και από ορισμένα μειονεκτήματα. Πιο συγκεκριμένα, η εκπαίδευσή τους μπορεί να είναι ιδιαίτερα χρονοβόρα, ειδικά σε μεγάλα σύνολα δεδομένων, λόγω των υψηλών υπολογιστικών απαιτήσεων. Επίσης, όταν εφαρμόζονται μη γραμμικοί πυρήνες, η ερμηνεία των αποτελεσμάτων καθίσταται πιο δύσκολη. Τέλος, η απόδοση των SVM εξαρτάται σημαντικά από την επιλογή της κατάλληλης συνάρτησης πυρήνα, γεγονός που απαιτεί προσεκτική ρύθμιση των παραμέτρων του. Σε πολλές περιπτώσεις, η συνδυαστική χρήση των SVM με άλλες τεχνικές μηχανικής μάθησης μπορεί να οδηγήσει σε ακόμα πιο αξιόπιστα και αποδοτικά αποτελέσματα (Verma & Kumar, 2018).

2.3.3.2 Μη Εποπτευόμενη Μάθηση (Unsupervised Learning)

Στη μη εποπτευόμενη μάθηση, το μοντέλο καλείται να ανακαλύψει κρυφά μοτίβα και δομές στα δεδομένα χωρίς να υπάρχει εκ των προτέρων καθορισμένη κατηγοριοποίηση. Αντί να προβλέπει μια

συγκεκριμένη έξοδο, ο αλγόριθμος εντοπίζει σχέσεις και δομές μέσα στα δεδομένα, οργανώνοντας τις παρατηρήσεις με βάση τις ομοιότητές τους. Σύμφωνα με τους Naeem et al. (2023), οι τεχνικές μη εποπτευόμενης μάθησης, όπως η συσταδοποίηση (clustering), επιτρέπουν την ομαδοποίηση των δεδομένων, διευκολύνοντας την εξαγωγή πολύτιμων πληροφοριών χωρίς να απαιτείται εκ των προτέρων σήμανση των κατηγοριών. Παρακάτω θα παρουσιαστούν μερικοί από τους πιο γνωστούς αλγορίθμους μη εποπτευόμενης μάθησης.

2.3.3.3 Ομαδοποίηση (Clustering: k-Means)

Η ομαδοποίηση (clustering) αποτελεί μια από τις πιο θεμελιώδεις τεχνικές μη εποπτευόμενης μάθησης, μέσω της οποίας τα δεδομένα ταξινομούνται σε ομάδες με βάση τα κοινά χαρακτηριστικά τους. Ένας από τους πιο διαδεδομένους αλγορίθμους είναι ο k-means, ο οποίος εφαρμόζεται εκτεταμένα σε χρηματοοικονομικά δεδομένα (Naeem et al., 2023).

Ειδικότερα, ο αλγόριθμος k-means χωρίζει τα δεδομένα σε k ομάδες με τρόπο που ελαχιστοποιείται η ευκλείδεια απόσταση μεταξύ των σημείων κάθε ομάδας και του αντίστοιχου κεντροειδούς (centroid). Παρά την υψηλή του αποδοτικότητα σε μεγάλα σύνολα δεδομένων, η απόδοσή του εξαρτάται από την προκαθορισμένη επιλογή του αριθμού των ομάδων, κάτι που μπορεί να περιορίσει την ευελιξία του (Naeem et al., 2023).

Οι τεχνικές ομαδοποίησης βρίσκουν εκτεταμένες εφαρμογές στη χρηματοοικονομική, όπως η κατηγοριοποίηση πελατών βάσει προτιμήσεων και αγοραστικής συμπεριφοράς, η ανίχνευση ανωμαλιών σε συναλλαγές, χρήσιμη στην αναγνώριση οικονομικής απάτης και η διαμόρφωση επενδυτικών στρατηγικών μέσω ανάλυσης προτύπων συμπεριφοράς. Αυτές οι εφαρμογές καθιστούν το clustering σημαντικό εργαλείο στη λήψη τεκμηριωμένων αποφάσεων στη διαχείριση χρηματοοικονομικών κινδύνων (Naeem et al., 2023).

2.3.3.4 Ανάλυση Κύριων Συνιστωσών (Principal Component Analysis – PCA)

Σύμφωνα με τους Bisong et al. (2019), η PCA είναι μια τεχνική που χρησιμοποιείται για να μειώσει τον αριθμό των μεταβλητών σε ένα σύνολο δεδομένων, διατηρώντας παράλληλα όσο το δυνατόν περισσότερη πληροφορία. Αυτή η μέθοδος μπορεί να είναι εξαιρετικά χρήσιμη στη διαχείριση χρηματοοικονομικών κινδύνων, καθώς τα δεδομένα που σχετίζονται με την αγορά ή τις επενδύσεις, είναι συχνά πολυδιάστατα και περιλαμβάνουν πολλές μεταβλητές. Ακόμη, η PCA επιτρέπει την αναγνώριση των βασικών παραμέτρων (κύριων συνιστωσών) που καθορίζουν τη μεγαλύτερη διακύμανση στα δεδομένα και έτσι βοηθά στην αποδοτικότερη κατηγοριοποίηση, ανάλυση ή πρόβλεψη κινδύνου.

Η PCA χρησιμοποιείται ευρέως στη διαχείριση χρηματοοικονομικών κινδύνων, καθώς βοηθά στον εντοπισμό των σημαντικότερων παραγόντων που επηρεάζουν την απόδοση ενός χαρτοφυλακίου. Σύμφωνα με τους Celestin et al. (2025), η εφαρμογή της σε πολύπλοκα χρηματοοικονομικά δεδομένα έδειξε ότι οι τρεις πρώτες κύριες συνιστώσες μπορούν να εξηγήσουν περίπου το 75% της συνολικής διακύμανσης. Αυτό σημαίνει ότι η μέθοδος επιτρέπει στους αναλυτές να εστιάζουν στις πιο κρίσιμες μεταβλητές, μειώνοντας την πολυπλοκότητα των δεδομένων.

Παράλληλα, η μελέτη έδειξε ότι η χρήση της PCA βελτίωσε σημαντικά την ακρίβεια των μοντέλων ανάλυσης κινδύνου, ανεβάζοντας το adjusted R^2 από 0,62 σε 0,88, ενώ μείωσε και τον βαθμό έκθεσης σε κίνδυνο κατά 3,4%. Συνολικά, η PCA βοηθά στην βελτιστοποίηση της στρατηγικής διαχείρισης χαρτοφυλακίου, επιτρέποντας καλύτερη πρόβλεψη της συμπεριφοράς της αγοράς και την αποτελεσματικότερη αξιολόγηση επενδυτικών σεναρίων (Celestin et al., 2025).

2.3.4 Ενισχυτική Μάθηση (Reinforcement Learning)

Η RL αποτελεί έναν υποκλάδο της μηχανικής μάθησης που βασίζεται στη συνεχή αλληλεπίδραση ενός αλγορίθμου με το περιβάλλον του. Στο πλαίσιο αυτό, το σύστημα ή αλλιώς agent, λαμβάνει αποφάσεις και αξιολογεί τις συνέπειές τους μέσω ενός μηχανισμού επιβράβευσης ή τιμωρίας. Με βάση την ανατροφοδότηση που λαμβάνει, προσαρμόζει σταδιακά την στρατηγική της, ακολουθώντας την διαδικασία δοκιμής και σφάλματος (*trial-and-error*), με τελικό στόχο την μεγιστοποίηση της συνολικής ανταμοιβής. Η RL βρίσκει εφαρμογή σε πλήθος τομέων, όπως τα αυτόνομα ρομπότ, οι ευφυείς πράκτορες (*intelligent agents*) και τα συστήματα αυτοματοποιημένης λήψης αποφάσεων (Moussaoui et al., 2023).

2.3.4.1 Q-Learning στη Διαχείριση Χρηματοοικονομικών Κινδύνων

Ο Q-Learning είναι ένας δημοφιλής αλγόριθμος RL, ο οποίος χρησιμοποιείται για την εκμάθηση των βέλτιστων στρατηγικών δράσης, σε περιβάλλοντα όπου οι αποφάσεις πρέπει να λαμβάνονται διαδοχικά (Clifton & Laber, 2020). Στον τομέα της διαχείρισης χρηματοοικονομικών κινδύνων, το Q-Learning μπορεί να αξιοποιηθεί για την βελτιστοποίηση στρατηγικών επενδύσεων, όπως η δυναμική κατανομή κεφαλαίων ή η επιλογή χρηματοοικονομικών εργαλείων για το χαρτοφυλάκιο, με στόχο τη μείωση του κινδύνου και την βελτίωση των αποδόσεων (Garud, 2025).

Ο αλγόριθμος λειτουργεί μέσω της δημιουργίας ενός πίνακα Q (Q-table), στον οποίο καταγράφεται η "ποιότητα" ή η αξία κάθε πιθανής δράσης σε κάθε κατάσταση. Στη συνέχεια οι τιμές αυτές προσαρμόζονται σταδιακά μέσα από μια διαδικασία δοκιμής και σφάλματος (*trial-and-error*), βασιζόμενες στην ενίσχυση που λαμβάνει ο αλγόριθμος από τις συνέπειες των ενεργειών του. Σε χρηματοοικονομικό περιβάλλον, οι καταστάσεις μπορεί να αναπαριστούν επίπεδα κινδύνου ή συνθήκες αγοράς, ενώ οι δράσεις μπορεί να περιλαμβάνουν ενέργειες όπως αγορά, πώληση ή

αναδιάρθρωση του χαρτοφυλακίου. Για παράδειγμα, σε μελέτη για αυτόματη ανακατανομή χαρτοφυλακίου, η χρήση του Q-Learning απέδειξε ότι μπορεί να βελτιστοποιήσει την κατανομή των περιουσιακών στοιχείων βασιζόμενο σε σήματα επιβράβευσης από ιστορικά δεδομένα αγοράς (Singhavi et al., 2020).

Ένα από τα βασικά πλεονεκτήματα του Q-Learning είναι ότι δεν απαιτεί τη γνώση ενός πλήρους μοντέλου του περιβάλλοντος, γεγονός που το καθιστά ιδιαίτερα αποτελεσματικό σε δυναμικά και αβέβαια περιβάλλοντα, όπως οι χρηματοπιστωτικές αγορές. Χάρη σε αυτήν την ιδιότητα του, επιτρέπει στις εταιρείες να αναπτύσσουν προσαρμοστικές στρατηγικές, βελτιστοποιώντας την λήψη αποφάσεων και ενισχύοντας την ανθεκτικότητα απέναντι σε μεταβαλλόμενες οικονομικές συνθήκες (Moussaoui et al., 2023).

2.3.4.2 Deep Reinforcement Learning (DRL)

Η DRL αποτελεί έναν προηγμένο κλάδο της RL, ο οποίος συνδυάζει τις αρχές της RL με την υπολογιστική ισχύ και την ικανότητα των DNN να επεξεργάζονται μεγάλα και περίπλοκα σύνολα δεδομένων (Mousavi et al., 2018).

Η εκπαίδευση ενός συστήματος DRL βασίζεται στη βελτιστοποίηση των ενεργειών του μέσω συνεχούς ενίσχυσης που λαμβάνει από το περιβάλλον, αξιοποιώντας τη διαδικασία της δοκιμής και σφάλματος. Σε χρηματοοικονομικό πλαίσιο, οι αλγόριθμοι DRL αναπτύσσουν πολιτικές που βελτιώνουν διαρκώς τις επενδυτικές αποφάσεις, με στόχο την ελαχιστοποίηση των κινδύνων και τη μεγιστοποίηση των αποδόσεων (Garud, 2025).

1. Οι αλγόριθμοι DRL συνδυάζουν δύο βασικά στοιχεία: Την διερεύνηση και εκμετάλλευση για τη συνεχή βελτίωση των αποφάσεων.
2. Την ισχυρή ικανότητα των νευρωνικών δικτύων να μαθαίνουν πολύπλοκα πρότυπα μέσα από μεγάλες και ετερογενείς πηγές δεδομένων. Αυτό επιτρέπει την ανάπτυξη πολιτικών που προσαρμόζονται δυναμικά στις συνθήκες της αγοράς και στη συμπεριφορά του χαρτοφυλακίου (Zheng et al., 2020).

Για παράδειγμα, εφαρμογές DRL έχουν αξιοποιηθεί στην δυναμική διαχείριση χαρτοφυλακίου, επιτρέποντας στο σύστημα να προσαρμόζει αυτόματα τις αποφάσεις αγοράς, πώλησης ή ανακατανομής κεφαλαίων με βάση τις μεταβαλλόμενες συνθήκες της αγοράς (Singh et al., 2020). Πρόσφατες μελέτες δείχνουν ότι οι αλγόριθμοι DRL, όπως οι PPO, DDPG και TD3, μπορούν να βελτιστοποιήσουν την απόδοση των επενδύσεων, ενσωματώνοντας δεδομένα από πολλαπλές πηγές και λαμβάνοντας υπόψη τον χρηματοοικονομικό κίνδυνο (Rezaei et al., 2025).

Ωστόσο, παρά τα σημαντικά πλεονεκτήματα, η εφαρμογή της DRL αντιμετωπίζει αρκετές προκλήσεις. Μεταξύ αυτών περιλαμβάνονται η ανάγκη για μεγάλο όγκο δεδομένων εκπαίδευσης ή υψηλή υπολογιστική πολυπλοκότητα των μοντέλων, καθώς και οι δυσκολίες στην ερμηνεία των αποφάσεων, που λαμβάνονται ιδιαίτερα όταν χρησιμοποιούνται πολύπλοκοι νευρωνικοί πυρήνες (Mousavi et al., 2018).

Συνολικά, η χρήση της DRL στη διαχείριση χρηματοοικονομικών κινδύνων μπορεί να προσφέρει προηγμένα εργαλεία για την ανάπτυξη δυναμικών και ευέλικτων στρατηγικών, οι οποίες μπορούν να ανταποκριθούν αποτελεσματικά σε ασταθή και αβέβαια χρηματοοικονομικά περιβάλλοντα. Η επόμενη ενότητα εστιάζει στις αρχές και τις εφαρμογές των νευρωνικών δικτύων, τα οποία αποτελούν την βάση για τεχνικές όπως η βαθιά μάθηση.

2.4 Τεχνητά Νευρωνικά Δίκτυα (ANN)

Τα ANN αποτελούν μία από τις πιο ισχυρές και ευρέως χρησιμοποιούμενες μεθόδους της τεχνητής νοημοσύνης (artificial intelligence, AI) και της ML. Η ανάπτυξή τους βασίζεται στην προσπάθεια προσομοίωσης του τρόπου λειτουργίας του ανθρώπινου εγκεφάλου, με στόχο την αναγνώριση προτύπων, την πρόβλεψη αποτελεσμάτων και τη λήψη βέλτιστων αποφάσεων (Kashimpure et al., 2023). Τα ANN αποτελούνται από πολλαπλά επίπεδα διασυνδεδεμένων τεχνητών νευρώνων, τα οποία συνεργάζονται ώστε να επεξεργάζονται δεδομένα και να μαθαίνουν από αυτά, βελτιώνοντας σταδιακά την απόδοσή τους μέσω της διαδικασίας εκπαίδευσης. Ένα κρίσιμο στοιχείο στη λειτουργία τους είναι οι συναρτήσεις ενεργοποίησης (activation functions), οι οποίες προσδίδουν μη γραμμικότητα στο μοντέλο, καθιστώντας το ικανό να χειρίζεται σύνθετα προβλήματα (Kashimpure et al., 2023).


Για παράδειγμα, η ReLU χρησιμοποιείται συχνά στα κρυφά επίπεδα λόγω της υπολογιστικής αποδοτικότητάς της, ενώ η Sigmoid είναι ιδιαίτερα χρήσιμη για την παραγωγή πιθανοτικών αποτελεσμάτων σε προβλήματα ταξινόμησης (Sharma et al., 2020). Χάρη στις δυνατότητές τους, τα ANN έχουν βρει ευρεία εφαρμογή σε τομείς όπως η πρόβλεψη χρηματοοικονομικών κινδύνων, η ανίχνευση απάτης, η επεξεργασία εικόνας και η αναγνώριση φωνής, καθιστώντας τα ένα από τα πιο ισχυρά εργαλεία της σύγχρονης υπολογιστικής νοημοσύνης.

2.4.1 Δομή των Νευρωνικών Δικτύων

Τα ANN αποτελούν ένα είδος υπολογιστικών συστημάτων που έχουν αναπτυχθεί με σκοπό να επεξεργάζονται δεδομένα, ακολουθώντας σε μεγάλο βαθμό τον τρόπο λειτουργίας του ανθρώπινου εγκεφάλου. Η βασική τους δομή στηρίζεται στη συνεργασία πολλών τεχνητών «νευρώνων», οι οποίοι οργανώνονται σε διαδοχικά επίπεδα. Καθώς τα δεδομένα περνούν από το ένα επίπεδο στο άλλο,

υφίστανται σταδιακούς μετασχηματισμούς μέχρι να παραχθεί το τελικό αποτέλεσμα (Kashimpure et al., 2023).

Η λειτουργία των ANN βασίζεται στη δημιουργία συνδεδεμένων επιπέδων. Στην Εικόνα 2.1 φαίνεται ότι, κάθε επίπεδο περιλαμβάνει συγκεκριμένο αριθμό κόμβων, οι οποίοι ανταλλάσσουν πληροφορίες μέσω συνδέσεων με διαφορετικά «βάρη». Το πώς συνδέονται αυτά τα επίπεδα μεταξύ τους είναι κρίσιμο για την απόδοση του δικτύου, καθώς καθορίζει την ικανότητά του να αναγνωρίζει μοτίβα, να κατηγοριοποιεί δεδομένα και να επιλύει πολύπλοκα προβλήματα (Thorat et al., 2022; Kashimpure et al., 2023).



Εικόνα 2.1: Διάγραμμα απλού νευρωνικού δικτύου


Πηγή: (Pantridge et al., 2016)

Γενικά, ένα τυπικό νευρωνικό δίκτυο αποτελείται από τρία βασικά μέρη:

- *Επίπεδο Εισόδου (Input Layer):* Αποτελείται από τους κόμβους που λαμβάνουν τις πληροφορίες από το εξωτερικό περιβάλλον. Οι τιμές αυτές προωθούνται προς τα επόμενα επίπεδα για επεξεργασία (Thorat et al., 2022).
- *Κρυφά Επίπεδα (Hidden Layers):* Βρίσκονται ανάμεσα στο επίπεδο εισόδου και εξόδου και πραγματοποιούν τους κύριους υπολογισμούς. Ένα απλό δίκτυο μπορεί να έχει μία μόνο κρυφή στιβάδα, ενώ πιο σύνθετες αρχιτεκτονικές περιλαμβάνουν πολλαπλά κρυφά επίπεδα, κάτι που αυξάνει τη δυνατότητα του δικτύου να κατανοεί πιο σύνθετες σχέσεις στα δεδομένα (Thorat et al., 2022).

- *Επίπεδο Εξόδου (Output Layer)*: Είναι το τελικό επίπεδο, το οποίο παράγει το τελικό αποτέλεσμα του δικτύου, όπως μια πρόβλεψη ή μια ταξινόμηση, ανάλογα με το πρόβλημα που επιλύεται (Thorat et al., 2022).

Στην Εικόνα 2.2 παρουσιάζεται ένα απλοποιημένο παράδειγμα τεχνητού νευρωνικού δικτύου, όπου φαίνεται η ροή των δεδομένων από το επίπεδο εισόδου, μέσω των κρυφών επιπέδων, προς το επίπεδο εξόδου.



Εικόνα 2.2: Σχήμα απλού νευρωνικού Δικτύου

Πηγή: (Kashimpure et al., 2023)

2.4.2 Τεχνητός νευρώνας και θάρη

Κάθε τεχνητός νευρώνας (*perceptron*) λαμβάνει σήματα από άλλους νευρώνες μέσω εισόδων. Κάθε είσοδος έχει ένα συντελεστή βάρους (*weight*) που καθορίζει τη σημασία της. Το άθροισμα αυτών των βαρών περνά μέσα από μία συνάρτηση ενεργοποίησης, η οποία αποφασίζει αν το σήμα θα προχωρήσει στα επόμενα επίπεδα. Η παραπάνω Εικόνα 2.2 παρουσιάζει έναν απλοποιημένο τεχνητό νευρώνα (Pantridge & Spector, 2016).

2.4.3 Συναρτήσεις Ενεργοποίησης (Activation Functions)

Οι συναρτήσεις ενεργοποίησης είναι απαραίτητες στα ANN, διότι προσθέτουν μη γραμμικότητα. Χωρίς αυτές, το δίκτυο δεν θα μπορούσε να μάθει περίπλοκες σχέσεις μεταξύ των δεδομένων. Αυτοί οι υπολογισμοί επιτρέπουν στο ANN να αναγνωρίζει μοτίβα, που ένα απλό γραμμικό μοντέλο αδυνατεί να αποδώσει (Sharma et al., 2020).

Όσον αφορά τη χρήση τους στα διάφορα επίπεδα:

- Στα κρυφά επίπεδα, συνήθως χρησιμοποιείται η ReLU, καθώς υπολογίζεται εύκολα και βοηθάει στην αποφυγή του προβλήματός της, κάτι που κάνει την εκπαίδευση πιο αποτελεσματική.
- Στο επίπεδο εξόδου, χρησιμοποιείται συνήθως η Sigmoid, αφού μετατρέπει τις εξόδους σε τιμές πιθανότητας, οι οποίες είναι ιδανικές για προβλήματα κατηγοριών ή ταξινόμησης.

Η προσεκτική επιλογή της συνάρτησης ενεργοποίησης μπορεί να έχει σημαντικό αντίκτυπο τόσο στην ακρίβεια όσο και στην ταχύτητα με την οποία το δίκτυο “συγκλίνει” προς μια λύση (Sharma et al., 2020).

2.4.4 Τύποι Νευρωνικών δικτύων

Τα ANN διακρίνονται σε διάφορους τύπους ανάλογα με τη δομή τους, τον τρόπο με τον οποίο οι νευρώνες συνδέονται μεταξύ τους και τον σκοπό που εξυπηρετούν. Παρακάτω παρουσιάζονται οι βασικότερες κατηγορίες νευρωνικών δικτύων.

2.4.4.1 Νευρωνικά Δίκτυα πολλών επιπέδων (Multi-Layer Perceptrons-MLP)

Τα MLP αποτελούν τη βασική μορφή ενός τεχνητού νευρωνικού δικτύου εμπρόσθιας τροφοδότησης. Η αρχιτεκτονική τους περιλαμβάνει τουλάχιστον ένα επίπεδο εισόδου, ένα ή περισσότερα κρυφά επίπεδα και ένα επίπεδο εξόδου, ενώ κάθε νευρώνας χρησιμοποιεί μία συνάρτηση ενεργοποίησης για την επεξεργασία των δεδομένων. Παράλληλα, η κατασκευή τους βασίζεται στη χρήση της θεμελιώδους μονάδας perceptron, η οποία οργανώνεται σε πολλαπλά επίπεδα και συνδέεται με άλλα νευρωνικά στοιχεία ώστε να επιτυγχάνεται η εκμάθηση σύνθετων προτύπων.

Η διαδικασία εκμάθησης ξεκινά με την εισαγωγή ενός συνόλου δεδομένων στο επίπεδο εισόδου, τα οποία προωθούνται διαδοχικά προς το επίπεδο εξόδου. Σε περίπτωση που το παραγόμενο αποτέλεσμα δεν είναι το επιθυμητό, το σφάλμα υπολογίζεται και ανατροφοδοτείται προς τα πίσω μέσω της διαδικασίας backpropagation, επιτρέποντας την προσαρμογή των βαρών του δικτύου. Η διαδικασία αυτή επαναλαμβάνεται έως ότου το σφάλμα ελαχιστοποιηθεί, βελτιστοποιώντας την ακρίβεια του μοντέλου. Επιπλέον, κάθε νευρώνας ενός επιπέδου συνδέεται με όλους τους νευρώνες του επόμενου επιπέδου, κάτι που αυξάνει την δυνατότητα μάθησης και την δυναμική αναγνώρισης πολύπλοκων προτύπων (Gallagher, 2000).

2.4.4.2 Αναδρομικά Νευρωνικά Δίκτυα (Recurrent Neural Networks – RNN)

Σε αντίθεση με τα MLP, στα οποία η ροή της πληροφορίας είναι αποκλειστικά εμπρόσθια, τα RNN ενσωματώνουν μηχανισμούς μνήμης μέσω ανατροφοδότησης, επιτρέποντας την αποθήκευση προηγούμενων καταστάσεων του δικτύου. Αυτό τα καθιστά ιδιαίτερα κατάλληλα για τη

μοντελοποίηση χρονικών σειρών, όπου οι παρελθοντικές τιμές επηρεάζουν τις μελλοντικές προβλέψεις (Salehinejad et al., 2018).

Βασικό στοιχείο της λειτουργίας των RNN είναι οι μονάδες περιβάλλοντος (context units), οι οποίες αποθηκεύουν τις εξόδους προηγούμενων κρυφών νευρώνων και τις επανατροφοδοτούν στο δίκτυο ως επιπλέον εισόδους. Έτσι, σε αντίθεση με τα MLP, που απαιτούν μεγάλο αριθμό εισόδων για την αποτύπωση της ιστορικής πληροφορίας, τα RNN ενσωματώνουν δυναμικά τη χρονική εξάρτηση, μειώνοντας την πολυπλοκότητα του μοντέλου και τον αριθμό των παραμέτρων που απαιτούνται.

Παρά τη θεωρητική συνάφεια των RNN με στοχαστικά μοντέλα χρονοσειρών, όπως τα ARMA, η εφαρμογή τους σε οικονομικά και χρηματοοικονομικά προβλήματα παραμένει πιο περιορισμένη συγκριτικά με άλλα είδη νευρωνικών δικτύων. Ωστόσο, η ικανότητά τους να αποθηκεύουν και να αξιοποιούν πληροφορίες από το παρελθόν τα καθιστά ιδιαίτερα χρήσιμα σε προβλήματα πρόβλεψης και ανάλυσης δεδομένων που εμφανίζουν διαχρονικές εξαρτήσεις (Salehinejad et al., 2018).

2.4.4.3 Συνελικτικά Νευρωνικά Δίκτυα (Convolutional Neural Networks – CNN)

Τα CNN αξιοποιούν τις χωρικές σχέσεις στα δεδομένα μέσω της συνελικτικής πράξης. Βασικό τους στοιχείο είναι η χρήση φίλτρων, τα οποία εντοπίζουν χαρακτηριστικά όπως ακμές, υφές και σχήματα, επιτρέποντας στο δίκτυο να αναγνωρίζει αντικείμενα ανεξαρτήτως της θέσης ή του μεγέθους τους (Datta, 2020).

Ένα τυπικό CNN αποτελείται από:

- *Συνελικτικές στιβάδες (convolutional layers)*, όπου εφαρμόζονται τα φίλτρα για την εξαγωγή χαρακτηριστικών.
- *Στιβάδες συγκέντρωσης (pooling layers)*, οι οποίες μειώνουν τη χωρική διάσταση των δεδομένων, διατηρώντας τα πιο σημαντικά χαρακτηριστικά.
- *Επίπεδα πλήρως συνδεδεμένα (fully connected layers)*, τα οποία εκτελούν την τελική ταξινόμηση ή πρόβλεψη.

Η χρήση φίλτρων και στρωμάτων pooling μειώνει τον αριθμό των παραμέτρων που χρειάζεται να εκπαιδευθούν, βελτιστοποιεί την αναγνώριση χωρικών προτύπων και εξοικονομεί υπολογιστικούς πόρους. Αν και αρχικά σχεδιάστηκαν για την επεξεργασία εικόνων, η ικανότητά τους να εξάγουν σύνθετα χαρακτηριστικά, καθιστά τα CNN χρήσιμα και σε άλλες εφαρμογές, όπως η ανάλυση χρονοσειρών και η αναγνώριση προτύπων σε μη δομημένα δεδομένα (Datta, 2020).

2.5 Μέθοδοι Ασαφούς και Γκρίζας Λογικής

Η ασαφής λογική βασίζεται στην έννοια των ασαφών συνόλων, όπου ένα στοιχείο μπορεί να ανήκει μερικώς σε διαφορετικές κατηγορίες, επιτρέποντας την περιγραφή πολύπλοκων καταστάσεων που δεν μπορούν να εκφραστούν με απόλυτα δυαδικά κριτήρια. Από την άλλη πλευρά, η θεωρία γκρίζων συστημάτων επικεντρώνεται στην διαχείριση ελλιπών ή αβέβαιων δεδομένων, παρέχοντας μεθόδους πρόβλεψης και μοντελοποίησης ακόμη και όταν το διαθέσιμο δείγμα είναι περιορισμένο. Στις επόμενες υποενότητες παρουσιάζονται αναλυτικά οι βασικές αρχές της ασαφούς λογικής, των ασαφών συνόλων και της θεωρίας γκρίζων συστημάτων, καθώς και οι εφαρμογές τους (Metaxiotis et al., 2004).

2.5.1 Ασαφής Λογική (Fuzzy Logic -FL)

Η έννοια της ασαφής λογικής (Fuzzy Logic -FL) εισήχθη το 1965 από τον Lotfi Aliasker Zadeh, καθηγητή του Πανεπιστημίου Μπέρκλεϋ. Η θεωρητική της θεμελίωση βασίζεται στη Θεωρία Ασαφών Συνόλων (Fuzzy Set Theory), η οποία επεκτείνει τη δυαδική λογική, επιτρέποντας σε προτάσεις να έχουν βαθμό αλήθειας αντί να περιορίζονται στις απόλυτες τιμές "αληθές" ή "ψευδές". Με αυτόν τον τρόπο, τα δεδομένα ερμηνεύονται ως συνεχές φάσμα τιμών, προσεγγίζοντας πιο ρεαλιστικά τη φυσική αβεβαιότητα που παρατηρείται σε πολλά συστήματα. Στην κλασική θεωρία συνόλων, ένα στοιχείο είτε ανήκει είτε δεν ανήκει σε ένα σύνολο, κάτι που περιγράφεται με αριθμητικές τιμές 1 ή 0 αντίστοιχα. Στη Θεωρία Ασαφών Συνόλων όμως, ένα στοιχείο μπορεί να ανήκει μερικώς σε ένα σύνολο με βαθμό συμμετοχής που κυμαίνεται μεταξύ 0 και 1. Ο βαθμός αυτός καθορίζεται από τη συνάρτηση συμμετοχής (membership function), η οποία μπορεί να υπολογιστεί είτε εμπειρικά είτε βάσει στατιστικών δεδομένων (Sadollah, 2018).

Δύο από τις πιο διαδεδομένες μεθόδους εφαρμογής της FL είναι τα μοντέλα Mamdani και Sugeno:

- *Μοντέλο Mamdani*: Χρησιμοποιείται ευρέως σε συστήματα λήψης αποφάσεων που απαιτούν ερμηνεύσιμα αποτελέσματα, καθώς βασίζεται σε ασαφείς εξόδους που στη συνέχεια αποσαφηνίζονται σε αριθμητικές τιμές (Zaher et al., 2014).
- *Μοντέλο Sugeno*: Εφαρμόζεται όταν απαιτείται υψηλή υπολογιστική απόδοση και μεγαλύτερη ακρίβεια, καθώς οι έξοδοι του μοντέλου είναι αριθμητικές, επιτρέποντας ευκολότερη βελτιστοποίηση (Zaher et al., 2014).

Η βαθύτερη κατανόηση της ασαφούς λογικής απαιτεί τη μελέτη των ασαφών συνόλων, τα οποία αποτελούν τη θεωρητική βάση για τον ορισμό των συναρτήσεων συμμετοχής και την ανάπτυξη πολύπλοκων συστημάτων ασαφούς συμπερασμού που αξιοποιούνται σε πληθώρα εφαρμογών, από τη λήψη αποφάσεων έως τη διαχείριση κινδύνων (Sadollah, 2018; Zaher et al., 2014).

2.5.2 Προσεγγιστικά Σύνολα (Rough Sets- RS)

Η Θεωρία των Προσεγγιστικών Συνόλων (Rough Sets- RS), η οποία προτάθηκε από τον Zdzislaw Pawlak το 1982, αποτελεί μία ισχυρή μεθοδολογία για την διαχείριση ασαφούς, αβέβαιης ή ατελούς πληροφορίας. Παρά τις ομοιότητες με την FL, οι δύο προσεγγίσεις διαφέρουν ουσιαστικά. Ενώ η FL χρησιμοποιεί συναρτήσεις συμμετοχής για να εκφράσει τον βαθμό αλήθειας, τα προσεγγιστικά σύνολα βασίζονται αποκλειστικά στις διαθέσιμες πληροφορίες του συνόλου δεδομένων και δεν απαιτούν εξωτερικές παραμέτρους ή υποκειμενικές εκτιμήσεις (Pawlak et al., 1995).

Η προσέγγιση αυτήν στηρίζεται σε ένα μαθηματικό μοντέλο που αναπαριστά την σχέση μεταξύ αντικειμένων βάσει της διακριτικής δύναμης των χαρακτηριστικών τους. Στην RST, τα προσεγγιστικά σύνολα ορίζονται μέσω δύο βασικών εννοιών (Lin & Liu, 1994):

- *Κάτω προσέγγιση (Lower approximation):* Περιλαμβάνει όλα τα αντικείμενα που ανήκουν με βεβαιότητα σε μία κατηγορία.
- *Άνω προσέγγιση (Upper approximation):* Περιλαμβάνει αντικείμενα που ενδέχεται να ανήκουν σε μία κατηγορία.

Σύμφωνα με τους Pawlak et al. (1995), οι έννοιες της κάτω και άνω προσέγγισης επιτρέπουν την αναπαράσταση της αβεβαιότητας σε σύνολα δεδομένων, ενώ η περιοχή αμφιβολίας (boundary region) καθορίζει το ποια αντικείμενα δεν μπορούν να ταξινομηθούν με απόλυτη βεβαιότητα. Αυτό δίνει τη δυνατότητα στη θεωρία των προσεγγιστικών συνόλων να επεξεργάζεται δεδομένα χωρίς την ανάγκη προκαθορισμένων ορίων, καθιστώντας την ιδανική για σενάρια με ελλιπή ή ασαφή δεδομένα (Lin & Liu, 1994).

Σε αντίθεση με την ασαφή λογική, η οποία μοντελοποιεί βαθμούς συμμετοχής και προσεγγίζει την αβεβαιότητα μέσω συναρτήσεων, η θεωρία προσεγγιστικών συνόλων επικεντρώνεται στην διαχείριση της αβεβαιότητας απευθείας μέσα από τα δεδομένα χωρίς την ανάγκη εξωτερικών παραμέτρων, προσφέροντας έναν συμπληρωματικό μηχανισμό στην ανάλυση πολύπλοκων συστημάτων (Pawlak et al., 1995).

2.5.3 Θεωρία των Γκριζών Συστημάτων (Grey System Theory- GST)

Η θεωρία των γκριζών συστημάτων (Grey System Theory- GST) προτάθηκε για πρώτη φορά το 1988 από τον Julong Deng στο Huazhong University of Science and Technology στην Κίνα. Ο όρος «γκρίζο» αναφέρεται στην ύπαρξη μερικής πληροφορίας, καθώς τα «λευκά» συστήματα διαθέτουν πλήρη γνώση, ενώ τα «μαύρα» χαρακτηρίζονται από πλήρη αβεβαιότητα. Στην πράξη, τα περισσότερα συστήματα που συναντώνται στον χώρο της CI μπορούν να θεωρηθούν «γκρίζα», καθώς περιέχουν τόσο γνωστές όσο και άγνωστες πληροφορίες (Julong, 1989).

Τα συστήματα αυτά, διαφοροποιούνται από άλλες μεθόδους ανάλυσης της αβεβαιότητας, όπως η πιθανότητα, η στατιστική και η ασαφής λογική. Σε αντίθεση με την ασαφή λογική, η οποία ασχολείται κυρίως με γνωσιακή αβεβαιότητα και υποκειμενικές κρίσεις, η GST επικεντρώνεται στην ανάλυση μερικώς διαθέσιμων δεδομένων και χρησιμοποιεί ειδικές μαθηματικές τεχνικές για να παράγει αξιόπιστες προβλέψεις (Julong, 1989).

Μία από τις βασικές τεχνικές της θεωρίας είναι η Accumulated Generating Operation (AGO), η οποία μετασχηματίζει τα αρχικά δεδομένα σε μια πιο ομαλή ακολουθία, μειώνοντας τον θόρυβο και αναδεικνύοντας τις υποκείμενες τάσεις. Με βάση αυτήν τη διαδικασία, το πιο διαδεδομένο και ευρέως χρησιμοποιούμενο μοντέλο της GST είναι το GM(1,1) (*Grey Model First Order One Variable*), ένα μοντέλο πρώτης τάξης διαφορικής εξίσωσης με μία μεταβλητή, το οποίο χρησιμοποιείται εκτεταμένα σε εφαρμογές προβλεπτικής ανάλυσης, όπως η πρόβλεψη οικονομικών δεικτών, η εκτίμηση κινδύνων και η διαχείριση πόρων (Mu et al., 2004).

2.6 Εξελικτικοί Αλγόριθμοι (Evolutionary Computation-EA)

Οι Εξελικτικοί Αλγόριθμοι αποτελούν μια κατηγορία αλγορίθμων βελτιστοποίησης που εμπνέονται από τις αρχές της φυσικής εξέλιξης και της φυσικής επιλογής, όπως διατυπώθηκαν από τον Κάρολο Δαρβίνο. Χρησιμοποιούνται ευρέως για την επίλυση πολύπλοκων προβλημάτων όπου οι παραδοσιακές μέθοδοι βελτιστοποίησης είναι ανεπαρκείς ή δεν μπορούν να αποδώσουν ικανοποιητικά αποτελέσματα. Λόγω της ικανότητάς τους να εξερευνούν μεγάλους χώρους αναζήτησης, οι EA εφαρμόζονται σε πλήθος πεδίων, όπως μηχανική μάθηση, χρηματοοικονομική ανάλυση και πρόβλεψη κινδύνων (Zelinka & Richter, 2010).

Η βασική ιδέα των EAs στηρίζεται στη δημιουργία ενός πληθυσμού υποψήφιας λύσεων, οι οποίες εξελίσσονται διαδοχικά μέσω διαδικασιών που προσομοιώνουν τους βιολογικούς μηχανισμούς της φύσης. Στην εξέλιξη αυτήν χρησιμοποιούνται γενετικοί τελεστές όπως (Esquivel et al., 1998):

- *Επιλογή (Selection)*: Προσδιορίζει ποιες λύσεις θα “επιβιώσουν” και θα χρησιμοποιηθούν στην επόμενη γενιά.
- *Διασταύρωση (Crossover)*: Συνδυάζει χαρακτηριστικά από δύο “γονεϊκές” λύσεις για να παραχθούν νέες.
- *Μετάλλαξη (Mutation)*: Εισάγει τυχαίες αλλαγές για να αυξήσει τη διαφοροποίηση και να αποφεύγεται η πρόωρη σύγκλιση.

Η καταλληλότητα κάθε λύσης αξιολογείται μέσω μίας συνάρτησης καταλληλότητας (fitness function), η οποία εκφράζει τον βαθμό επίτευξης των στόχων του προβλήματος. Παράλληλα, τα χαρακτηριστικά

που επηρεάζουν τη συμπεριφορά μιας λύσης, γνωστά ως φαινότυποι (phenotypes), μπορούν να μεταβληθούν είτε μέσω αλλαγών στη γενετική της δομή είτε μέσω διαφοροποιημένης ανάπτυξης, καθορίζοντας έτσι την κατεύθυνση της εξέλιξης (Becerra & Lahoz-Beltra, 2020).

2.6.1 Αλγόριθμος εξελικτικής προσομοιωμένης ανάκτησης (Evolutionary Simulated Annealing - ESA)

Ο ESA αποτελεί μια υβριδική μέθοδο βελτιστοποίησης που συνδυάζει τις αρχές των εξελικτικών αλγορίθμων με την τεχνική της SA. Κύριος στόχος του, είναι η εύρεση βέλτιστων ή κοντά στο βέλτιστο λύσεων σε πολύπλοκα και μη γραμμικά προβλήματα μεγάλης κλίμακας (Barral et al., 1999).

Η SA αντλεί έμπνευση από τις φυσικές διεργασίες ανόπτησης των μετάλλων. Η διαδικασία περιλαμβάνει θέρμανση και προοδευτική ψύξη του υλικού, επιτρέποντας στο σύστημα να μεταβαίνει σταδιακά σε ενεργειακά σταθερές καταστάσεις. Στην υπολογιστική της εκδοχή, η SA χρησιμοποιείται για την αναζήτηση του παγκόσμιου βέλτιστου μιας συνάρτησης κόστους, επιτρέποντας την αποδοχή λιγότερο αποδοτικών λύσεων σε πρώιμα στάδια, ώστε να αποφευχθεί ο εγκλωβισμός σε τοπικά ελάχιστα (Delahaye et al., 2019).

Η καινοτομία του ESA σε σχέση με την κλασική SA είναι ότι λειτουργεί με έναν πληθυσμό λύσεων, αντί για μία μοναδική λύση. Ο αλγόριθμος ακολουθεί τα παρακάτω βασικά στάδια:

1. Δημιουργία αρχικού πληθυσμού υποψήφιων λύσεων.
2. Αξιολόγηση κάθε λύσης μέσω κατάλληλης συνάρτησης κόστους.
3. Επιλογή των πιο υποσχόμενων λύσεων.
4. Δημιουργία νέων λύσεων με τη χρήση μηχανισμών διασταύρωσης, μετάλλαξης και στρατηγικών SA.
5. Σταδιακή μείωση της πιθανότητας αποδοχής λιγότερο αποδοτικών λύσεων, ώστε να ενισχυθεί η σύγκλιση.

Χάρη στον συνδυασμό των δύο μεθόδων, ο ESA προσφέρει μεγαλύτερη ποικιλομορφία λύσεων και αποτελεσματικότερη εξερεύνηση του χώρου αναζήτησης (Barral et al., 1999).

2.6.2 Νοημοσύνη Σμήνους (Swarm Intelligence-SI)

Η SI αποτελεί έναν κλάδο της υπολογιστικής νοημοσύνης που εμπνέεται από την συλλογική συμπεριφορά αποκεντρωμένων και αυτό-οργανωμένων συστημάτων, όπως τα σμήνη πουλιών, τα κοπάδια ψαριών και οι αποικίες μυρμηγκιών (Dorigo et al., 2012). Η SI βασίζεται στην αρχή ότι, η αλληλεπίδραση απλών, ανεξάρτητων μονάδων μπορεί να οδηγήσει στην ανάπτυξη σύνθετης και

αποτελεσματικής συλλογικής συμπεριφοράς, χωρίς την ανάγκη κεντρικού ελέγχου. Τα μοντέλα αυτά προσομοιώνουν την διασπορά πληροφοριών, την συνεργασία και την εκμετάλλευση της συλλογικής εμπειρίας, ώστε να επιλύονται προβλήματα βελτιστοποίησης με αποδοτικό τρόπο (Dorigo et al., 2012).

Ένα σμήνος αποτελείται από έναν πληθυσμό απλών οντοτήτων που επικοινωνούν άμεσα ή έμμεσα και αλληλεπιδρούν τόσο μεταξύ τους όσο και με το περιβάλλον τους. Παρόλο που κάθε άτομο έχει απλή δομή και περιορισμένες δυνατότητες, η συλλογική συμπεριφορά που προκύπτει είναι πολύπλοκη και προσαρμοστική. Η έννοια της ανάδυσης (emergence) παίζει καθοριστικό ρόλο στη SI: οι συνεκτικές δομές, τα πρότυπα και οι στρατηγικές προκύπτουν δυναμικά μέσα από τις τοπικές αλληλεπιδράσεις των μελών, χωρίς να επιβάλλονται από κάποιον κεντρικό μηχανισμό ελέγχου (Zhang et al., 2013).

2.6.2.1 Ο Αλγόριθμος Αποικίας Μυρμηγκιών (Ant Colony Optimization - ACO)

Ο αλγόριθμος αποικίας μυρμηγκιών βασίζεται στην συμπεριφορά των μυρμηγκιών κατά την αναζήτηση τροφής. Τα μυρμηγκία εναποθέτουν φερομόνες στις διαδρομές τους, διευκολύνοντας τα υπόλοιπα μέλη της αποικίας να επιλέξουν τις βέλτιστες διαδρομές προς την τροφή. Αυτή η φυσική διαδικασία έχει εμπνεύσει αλγορίθμους βελτιστοποίησης που χρησιμοποιούνται σε προβλήματα όπως η βελτιστοποίηση διαδρομών στην χρηματοοικονομική ανάλυση (Nanda et al., 2013).

2.7 Υβριδικά Μοντέλα Υπολογιστικής Νοημοσύνης

Τα υβριδικά μοντέλα υπολογιστικής νοημοσύνης αποτελούν συνδυασμούς διαφορετικών τεχνικών και μεθοδολογιών, με στόχο την αξιοποίηση των πλεονεκτημάτων που προσφέρει κάθε επιμέρους προσέγγιση. Η ενσωμάτωση ετερογενών μεθόδων επιτρέπει την ανάπτυξη συστημάτων με αυξημένη ευελιξία, καλύτερη προσαρμοστικότητα και βελτιωμένη ικανότητα επίλυσης πολύπλοκων προβλημάτων. Ενδεικτικά, έχουν αναπτυχθεί συστήματα που συνδυάζουν νευρωνικά δίκτυα (artificial neural networks, ANN), ασαφή λογική και γενετικούς αλγορίθμους (genetic algorithms, GA), αξιοποιώντας τα ισχυρά χαρακτηριστικά κάθε μεθόδου (Tsakonas & Dounias, 2002).

Ειδικότερα, η υλοποίηση ενός υβριδικού μοντέλου μπορεί να γίνει με περισσότερους από έναν τρόπους, ανάλογα με τη σχέση που αναπτύσσεται μεταξύ των χρησιμοποιούμενων τεχνικών. Τα νευροασαφή συστήματα αποτελούν χαρακτηριστικό παράδειγμα υβριδικών μοντέλων, καθώς συνδυάζουν ANN και ασαφή λογική, επιτυγχάνοντας αυξημένη ευελιξία και αποδοτικότητα (Sharma et al, 2021), ενώ σε άλλες περιπτώσεις, ένα νευρωνικό δίκτυο αξιοποιεί ασαφείς μηχανισμούς, όπως έναν ασαφή αλγόριθμο για τη δυναμική προσαρμογή του ρυθμού μάθησης ή τη βελτιστοποίηση των βαρών (Thakur et al., 2021). Συνεπώς, το βασικό πλαίσιο ενός υβριδικού μοντέλου μπορεί να είναι είτε ασαφές με ενσωμάτωση νευρωνικών στοιχείων, είτε νευρωνικό με ενσωμάτωση ασαφών

μηχανισμών. Ακολουθούν οι τέσσερις κύριες κατηγορίες υβριδικών μοντέλων που συναντώνται στη βιβλιογραφία (Tsakonas & Dounias, 2002).

2.7.1 Νευροασαφή Συστήματα (Neuro-Fuzzy Systems- NFS)

Τα νευροασαφή συστήματα αποτελούν τα υβριδικά μοντέλα υπολογιστικής νοημοσύνης που συνδυάζουν τα ANN με την FL, επιτυγχάνοντας ταυτόχρονα ικανότητα μάθησης και διαχείριση της αβεβαιότητας. Η ενσωμάτωση αυτών των δύο τεχνολογιών επιτρέπει την ανάπτυξη ευέλικτων συστημάτων που μπορούν να επεξεργάζονται δεδομένα ακόμη και όταν αυτά είναι ασαφή ή αβέβαια. Στο πλαίσιο αυτό, τα ANN συμβάλλουν στην αυτόματη εξαγωγή προτύπων και στην βελτίωση της απόδοσης του μοντέλου μέσω διαδικασιών εκπαίδευσης, ενώ η FL παρέχει τη δυνατότητα χειρισμού μη καθορισμένων και αβέβαιων δεδομένων, ενσωματώνοντας τα ανθρώπινα χαρακτηριστικά της λογικής συλλογιστικής (Thakur, 2021)

Δύο από τα πιο γνωστά και ευρέως χρησιμοποιούμενα νευροασαφή συστήματα είναι:

- i. *ANFIS (Adaptive Neuro-Fuzzy Inference System)*: Πρόκειται για ένα υβριδικό σύστημα που συνδυάζει τη μαθησιακή ικανότητα των ΤΝΔ με την ικανότητα της ασαφούς λογικής να διαχειρίζεται την αβεβαιότητα. Το ANFIS χρησιμοποιείται ευρέως σε εφαρμογές όπως η πρόβλεψη και η αξιολόγηση δεδομένων σε πολύπλοκα περιβάλλοντα, χάρη στην υψηλή του προσαρμοστικότητα (Jang et al., 1993).
- ii. *FALCON (Fuzzy Adaptive Learning Control Network)*: Ένα προσαρμοστικό νευροασαφές δίκτυο που χρησιμοποιείται για ανάλυση δεδομένων και αναγνώριση προτύπων σε δυναμικά και μεταβαλλόμενα περιβάλλοντα. Η δομή του FALCON επιτρέπει την αποδοτική επεξεργασία πληροφοριών, ακόμη και όταν τα δεδομένα είναι ελλιπή ή παρουσιάζουν υψηλό βαθμό αβεβαιότητας (Jain et al., 2000).

2.7.2 Ασαφή Γενετικά Μοντέλα (Fuzzy Genetic Models- FGM)

Τα μοντέλα αυτά, βασίζονται στη συνεργασία ασαφούς λογικής και γενετικών αλγορίθμων, προκειμένου να επιλύσουν προβλήματα βελτιστοποίησης σε συνθήκες αβεβαιότητας. Οι γενετικοί αλγόριθμοι χρησιμοποιούνται για την αναζήτηση βέλτιστων λύσεων, ενώ η ασαφής λογική συμβάλλει στην αποτύπωση και διαχείριση μη καθορισμένων παραμέτρων. Τα FGA είναι η μέθοδος που εφαρμόζεται στην κατανομή και βελτιστοποίηση χαρτοφυλακίων, λαμβάνοντας υπόψη ασαφή κριτήρια απόδοσης και κινδύνου (Buckley et al., 1994), ενώ το FRBCS συνδυάζει γενετικούς αλγορίθμους και ασαφή λογική για την εξαγωγή κανόνων ταξινόμησης σε χρηματοοικονομικά δεδομένα, συμβάλλοντας στην ανάλυση πιστωτικού κινδύνου και διαχείριση επενδύσεων (Laha, 2007).

4.7.3 Νευρωνικά Γενετικά Μοντέλα (Neuro-Genetic Models)

Αυτή η κατηγορία περιλαμβάνει την ενσωμάτωση γενετικών αλγορίθμων στη διαδικασία εκπαίδευσης ή βελτιστοποίησης τεχνητών νευρωνικών δικτύων. Οι γενετικοί αλγόριθμοι λειτουργούν ως μηχανισμοί αναζήτησης για τη βέλτιστη δομή των νευρωνικών δικτύων, ενισχύοντας την ικανότητά τους να αναγνωρίζουν και να προβλέπουν τάσεις στις χρηματοοικονομικές αγορές (Kai et al., 1997). Τα Genetic Algorithm-Optimized Neural Networks, είναι ο συνδυασμός γενετικών αλγορίθμων και νευρωνικών δικτύων που εφαρμόζεται στην πρόβλεψη τιμών μετοχών και τα Neuro-Genetic Hybrid Systems είναι συστήματα που χρησιμοποιούνται για την αναγνώριση προτύπων και για την αξιολόγηση χρηματοοικονομικών κινδύνων, έχοντας ως στόχο την ενίσχυση και τη σταθερότητα των προβλέψεων μέσω εξελικτικών τεχνικών βελτιστοποίησης (Prema et al., 2016).

2.8 Βιβλιογραφική ανασκόπηση

Στο πλαίσιο της παρούσας εργασίας πραγματοποιήθηκε εκτεταμένη βιβλιογραφική ανασκόπηση, μελετώντας 84 επιστημονικά άρθρα που σχετίζονται με την εφαρμογή ευφύων υπολογιστικών μεθόδων στην διαχείριση χρηματοοικονομικών κινδύνων. Από τα άρθρα αυτά, επιλέχθηκαν έξι αντιπροσωπευτικές μελέτες, με στόχο την ανάδειξη των σημαντικότερων ερευνητικών προσεγγίσεων στο πεδίο. Η επιλογή των έξι μελετών βασίστηκε σε τρία κριτήρια: τη συνάφεια με το αντικείμενο, την αντιπροσωπευτικότητα διαφορετικών μεθόδων CI και τύπων κινδύνων και την σημαντικότητα των άρθρων στη διεθνή βιβλιογραφία. Επιλέχθηκαν μελέτες που παρουσιάζουν καινοτόμα μοντέλα, καλύπτουν διαφορετικούς χρηματοοικονομικούς κινδύνους, όπως τον πιστωτικό κίνδυνο, τον αγοραίο, τον επιχειρησιακό και τον κίνδυνο κυβερνοασφάλειας, που χρησιμοποιούν τις πιο σύγχρονες υπολογιστικές τεχνικές, όπως τα ANN, δίκτυα μακράς βραχυπρόθεσμης μνήμης (Long Short-Term Memory – LSTM), μηχανές διανυσμάτων υποστήριξης (Support Vector Machines – SVM) και γενετικούς αλγορίθμους (Genetic Algorithms – GA), FL και τα υβριδικά μοντέλα. Στον παρακάτω πίνακα παρουσιάζεται συνοπτικά το περιεχόμενο των επιλεγμένων μελετών.

Πίνακας 2.1: Συνοπτική Παρουσίαση των Μελετών

Τίτλος Άρθρου	Συγγραφείς & Έτος	Τύπος Κινδύνου	Μέθοδος CI
Machine learning in banking risk management:	<i>Valentin Lennart Heß, Bruno</i>	Market, Operational, Liquidity,	Artificial Neural Networks (ANN), Support Vector Machines (SVM),
Mapping a decade of evolution	<i>Damásio (2025)</i>	Reputational, Regulatory, Strategic, Model, Business	Recurrent Neural Networks (RNN), Convolutional Neural Networks (CNN), Decision Trees (DT), Random Forest (RF), Logistic Regression,

			Naïve Bayes, Bayesian Networks, Gradient Boosting, XGBoost, Deep Learning (DL), Reinforcement Learning (RL), Principal Component Analysis (PCA), Genetic Algorithms, K-Means, Fuzzy CNN, Outlier Detection, Semi-supervised Few-shot Learning
Towards data and analytics driven B2B-banking for green finance: A cross-selling use case study	Victor Chang, Nattareya Hahm, Qianwen Ariel Xu, P. Vijayakumar, Ling Liu (2024)	Credit Risk, Market Risk, Operational Risk	Random Forest, Neural Networks, Deep Neural Networks, Support Vector Machines, Logistic Regression, Autoencoders
Artificial Intelligence risk measurement	Paolo Giudici, Mattia Centurelli, Stefano Turchetta (2024)	Model Risk, Credit Risk, Financial Risk, Operational Risk, Cyber Risk	Random Forest, Logistic Regression, Neural Networks, Convolutional Neural Networks, Gradient Boosting, Support Vector Machines
A hybrid model integrating artificial neural network with multiple GARCH-type models and EWMA for performing the optimal volatility forecasting of market risk factors	Francisco Pérez-Hernández, Alvaro Arévalo-de-Pablos, María-del-Mar Camacho-Miñano (2024)	Market risk	Artificial Neural Networks, Long Short-Term Memory (LSTM), Support Vector Machine (SVM), GARCH-type models, EWMA
Operational research and artificial intelligence methods in banking	Michalis Doumpos, Constantin Zopounidis, Dimitrios Gounopoulos, Emmanouil Platanakis, Wenke Zhang (2023)	Credit risk, Market risk, Operational risk, Systemic risk	SVM, Neural Networks, DEA (Data Envelopment Analysis), Monte Carlo Simulation, Fuzzy Logic, Agent-Based Models, Ensemble Methods
An intelligent bankruptcy prediction model using a multilayer perceptron	Raffael Förch Brenes, Arne Johannssen, Nataliya Chukhrova (2022)	Credit Risk, Operational Risk	Multilayer Perceptron (MLP), Neural Networks, Backpropagation, Adam optimizer, Stochastic Gradient Descent (SGD)

2.8.1 Αναλυτική παρουσίαση των επιλεγμένων άρθρων

Συγκεκριμένα, θα παρουσιάσουμε κάθε άρθρο ξεχωριστά, προκειμένου να αναδείξουμε με τον πληρέστερο δυνατό τρόπο τα βασικά του ευρήματα, τη μεθοδολογία και τη συμβολή του στη σχετική βιβλιογραφία. Αρχικά η ερευνά των Heß et al. (2025), αναδεικνύει την εφαρμογή τεχνικών μηχανικής μάθησης στη διαχείριση τραπεζικών κινδύνων. Η ανάλυση βασίζεται σε 46 επιλεγμένες επιστημονικές μελέτες και καλύπτει ένα ευρύ φάσμα κινδύνων, όπως ο πιστωτικός, ο αγοραίας, ο λειτουργικός και ο κίνδυνος ρευστότητας. Η έρευνα παρουσιάζει τις κυριότερες τεχνικές που έχουν εφαρμοστεί, όπως τα ANN για την πρόβλεψη πιστωτικού κινδύνου, SVM και Random Forest για την ανίχνευση επιχειρησιακής αβεβαιότητας και LSTM για την ανάλυση των χρονικών τάσεων στην αγοραία μεταβλητότητα.

Ειδικότερα, τα ANN εκπαιδεύονται σε ιστορικά δεδομένα δανείων, επιτοκίων, πιστοληπτικών περιθωρίων, ώστε να προβλέψουν πιθανά όρια αθέτησης. Επιπλέον τα LSTM χρησιμοποιούνται για τη μοντελοποίηση της μεταβλητότητας των τιμών μετοχών και των επιτοκίων στο χρόνο, βελτιώνοντας τα stress test και τις προβλέψεις άμεσης αντίδρασης στις διακυμάνσεις των αγορών. Τα Random Forest και SVM εφαρμόζονται για ταξινόμηση περιπτώσεων υψηλού ή χαμηλού κινδύνου σε καταστάσεις λειτουργικών αποτυχιών ή απάτης, αξιολογώντας πολλές μεταβλητές διαχρονικά. Αυτές οι μέθοδοι ενισχύουν την πρόβλεψη κινδύνων και συμβάλλουν στην υιοθέτηση προληπτικών κινδύνων. Παρά τα συστημένα αυτά επιτεύγματα, επισημαίνεται ότι υπάρχει σημαντικό ερευνητικό κενό στη χρήση υβριδικών μοντέλων και σε εφαρμογές σε πραγματικά τραπεζικά δεδομένα, προτείνοντας κατευθύνσεις για μελλοντική έρευνα (Heß et al., 2025).

Έπειτα η ερευνά των Chang et al. (2024) εξετάζει την εφαρμογή προχωρημένων τεχνικών ανάλυσης δεδομένων και μηχανικής μάθησης στην τραπεζική B2B δραστηριότητα, με έμφαση στην πράσινη χρηματοδότηση. Μέσω ενός case study σε γερμανική τράπεζα, διαπιστώθηκε ότι:

- i. Η ανάλυση δεδομένων σε πραγματικό χρόνο συμβάλλει στην πρόωπη ανίχνευση αναξιοπιστίας σε προϊόντα cross-selling, μειώνοντας τον πιστωτικό κίνδυνο.
- ii. Μέσω μοντέλων ML, ενισχύθηκε η πρόβλεψη αποδόσεων τραπεζικών προϊόντων, προστατεύοντας από απώλειες λόγω κακής επιλογής πελατών ή προϊόντων.
- iii. Η αυτοματοποιημένη ανάλυση συμπεριφορικών δεδομένων (π.χ. αγοραστικές συνήθειες, χρονοσειρές συναλλαγών) βελτίωσε το risk scoring, ενισχύοντας τα προληπτικά μέτρα.
- iv. Παρά την επιτυχή εφαρμογή, σημειώθηκε ότι η κλιμάκωση των καινοτομιών χωρίς επιδράσεις σε κανονιστικά πλαίσια ή χωρίς επαρκή διαχείριση εγκυμονεί κινδύνους.

Επισημαίνεται ωστόσο, ότι η κλιμάκωση αυτών των καινοτομιών σε ευρύτερη κλίμακα ενέχει σημαντικούς κινδύνους, εάν δεν συνοδεύεται από επαρκή διαχείριση και ρυθμιστικά πλαίσια. Η έρευνα προσφέρει ουσιαστικές πολιτικές και τεχνικές προτάσεις για την υπεύθυνη υιοθέτηση ψηφιακής τεχνολογίας σε τραπεζικούς οργανισμούς με δεσμευμένη στρατηγική ESG (Chang et al., 2024).

Επιπρόσθετα, οι Giudici et al. (2024) παρουσιάζουν ένα πρωτοποριακό πλαίσιο αξιολόγησης των κινδύνων, που προκύπτουν από συστήματα AI στον χρηματοοικονομικό τομέα. Οι συγγραφείς πρότειναν ένα μετρήσιμο κριτήριο (risk-aware actual value), το οποίο λειτουργεί ως ένα εργαλείο αξιολόγησης της βιωσιμότητας και της καταλληλότητας για την ενσωμάτωση συστημάτων τεχνητής νοημοσύνης σε τραπεζικές και χρηματοοικονομικές υπηρεσίες.

Η αξιολόγηση CI κινδύνων μπορεί να διεξαχθεί μέσω της ανάλυσης παραμέτρων explainability και fairness, ώστε να εκτιμάται εάν το μοντέλο λαμβάνει αποφάσεις που είναι κατανοητές και δίκαιες για όλους τους χρήστες, με την ανάλυση ποσοτήτων εμπιστοσύνης (trust metrics), όπως αξιολόγηση με βάση την ακρίβεια, τη βιωσιμότητα και τη συνέπεια των προβλέψεων και τέλος, με την τεκμηρίωση της ρυθμιστικής συμμόρφωσης (regulatory compliance), ώστε τα μοντέλα να πληρούν απαιτήσεις όπως αυτές του Ευρωπαϊκού Κανονισμού για την AI. Με αυτό τον τρόπο, το risk-aware actual value παρέχει ποσοτικές μετρήσεις για την αξιολόγηση και διαχείριση των κινδύνων που συνοδεύουν την ανάπτυξη και λειτουργία μοντέλων CI, συμβάλλοντας στην ανάπτυξη ασφαλέστερων και πιο αξιόπιστων συστημάτων (Giudici et al., 2024).

Οι Hernández et al. (2024), παρουσιάζουν ένα αποτελεσματικό υβριδικό μοντέλο πρόβλεψης μεταβλητότητας (volatility forecasting) που συνδυάζει νευρωνικά δίκτυα με μοντέλα GARCH και EWMA (Exponentially Weighted Moving Average), αποδεικνύοντας σημαντική υπεροχή έναντι των παραδοσιακών econometric προσεγγίσεων. Η φιλοσοφία του υβριδικού σχήματος βασίζεται στη συμπλήρωση των GARCH και EWMA με σκοπό να, παρέχουν μια στατιστική βάση που λαμβάνει υπόψη πιθανές διακυμάνσεις, ενώ το ANN να αναγνωρίζει μη γραμμικά μοτίβα και δυναμικές αλληλεπιδράσεις.

Η εφαρμογή δοκιμάστηκε σε δεδομένα από το IBEX 35, τις μετοχές της Santander Bank, την ισοτιμία Euro/Dollar και τον δείκτη iTraxx Crossover 5-Year. Αυτό έχει ως αποτέλεσμα:

- i. Την βελτιωμένη ακρίβεια προβλέψεων κατά τη διάρκεια τόσο κρίσεων όσο και περιόδων σταθερότητας, χάρη στην ολοκληρωμένη κάλυψη της συμπεριφοράς της αγοράς.
- ii. Την αναγνώριση μη γραμμικών τάσεων και αιτιωδών σχέσεων που παραλείπονται από τους καθαρά στατιστικούς δείκτες.

- iii. Την πιο σταθερή ποσοτική αποτύπωση κινδύνων, ιδιαίτερα σε stress-test σενάρια, υποστηρίζοντας τον υπολογισμό του Value-at-Risk.

Το μοντέλο αυτό αποτελεί δείγμα για το πώς οι μέθοδοι CI αναβαθμίζουν την ποσοτική διαχείριση κινδύνου, παρέχοντας πιο αξιόπιστες προβλέψεις και καλύτερες πληροφορίες για τη λήψη αποφάσεων σε αγορές υψηλής μεταβλητότητας (Hernández et al., 2024).

Οι Doumpos et al. (2023) παρουσιάζουν μία συστηματική ανασκόπηση της δεκαετίας που αφορά την εφαρμογή μεθόδων επιχειρησιακής έρευνας (operational research, OR) και AI στον τραπεζικό τομέα. Η μελέτη τους καταγράφει τον τρόπο με τον οποίο τέτοιες μέθοδοι έχουν ενσωματωθεί τόσο σε ερευνητικά όσο και σε μεθοδολογικά μοντέλα.

Καλύπτουν θέματα όπως: α) η αξιολόγηση κινδύνου με χρήση ANN, SVM και Random Forest, ενισχύοντας την ικανότητα πρόγνωσης κινδύνων πιστωτικής ικανότητας, β) η τραπεζική απόδοση και αποτελέσματα αξιολόγησης εξαγορών και συγχωνεύσεων (M&A) με χρήση μοντέλων επιχειρησιακής έρευνας και ML για τη βελτιστοποίηση της αποδοτικότητας, γ) η κανονιστική εποπτεία και χρηματοοικονομική σταθερότητα, με εργαλεία ανάλυσης για την πρόβλεψη και αποτροπή κρίσεων και τέλος, η υιοθέτηση εφαρμογών Fintech, όπως αυτοματοποιημένες πλατφόρμες δανεισμού, αξιοποιώντας την AI για τη μείωση κινδύνου και την αύξηση της αποτελεσματικότητας. Η ανασκόπηση τονίζει ότι, ο συνδυασμός OR και AI ενισχύει σημαντικά την διαχείριση κινδύνου, βελτιστοποιεί αποφάσεις σε περίπλοκα τραπεζικά σενάρια και παρέχει κατευθύνσεις για μελλοντική έρευνα στον τομέα (Doumpos et al., 2023).

Στη μελέτη των Brenes et al. (2022) παρουσιάζεται ένα εξειδικευμένο μοντέλο ANN για την πρόβλεψη της πτώχευσης εταιρειών. Η διαδικασία ξεκινά με εκτενή βιβλιογραφική ανασκόπηση των υφιστάμενων μοντέλων για την πρόληψη εταιρικής αποτυχίας. Στη συνέχεια, οι συγγραφείς εξετάζουν τις ιδιότητες του ANN, μεταβάλλοντας παραμέτρους όπως τον αριθμό των στρωμάτων, των νευρώνων, τις συναρτήσεις ενεργοποίησης και τους αλγορίθμους βελτιστοποίησης.

Το μοντέλο αξιολογήθηκε σε δείγμα 95 ταϊβανικών εταιρειών με βάση χρηματοοικονομικούς δείκτες, χρησιμοποιώντας μετρικές όπως accuracy, specificity, sensitivity και precision. Τα αποτελέσματα έδειξαν ότι το ANN υπερέχει σημαντικά έναντι συμβατικών μεθόδων, όπως λογιστική παλινδρόμηση, προσφέροντας πιο αξιόπιστες προβλέψεις πτώχευσης. Επιπλέον, η έρευνα παρέχει κατευθυντήριες γραμμές σχετικά, για μοντέλα πρόβλεψης χρηματοοικονομικής αποτυχίας (Brenes et al., 2022).

Αυτό το παράδειγμα, δείχνει πως ένα μοντέλο βαθιάς μάθησης μπορεί να ενισχύσει την πρόβλεψη χρηματοοικονομικών κινδύνων, ειδικά σε περιβάλλοντα με σύνθετους χρηματοοικονομικούς δείκτες και υψηλή ανάγκη ακρίβειας (Brenes et al., 2022).

2.8.2 Συμπεράσματα ανασκόπησης

Η ανασκόπηση των έξι επιλεγμένων ερευνών αναδεικνύει τη ραγδαία εξέλιξη της εφαρμογής των ευφυών υπολογιστικών μεθόδων και της μηχανικής μάθησης στη διαχείριση χρηματοοικονομικών κινδύνων. Οι περισσότερες έρευνες δείχνουν ότι η αξιοποίηση τεχνικών όπως τα ANN, τα LSTM, οι SVM, τα RF, οι αλγόριθμοι Gradient Boosting και τα υβριδικά μοντέλα έχουν βελτιώσει σημαντικά την πρόβλεψη κινδύνων, την διαχείριση ρευστότητας, την εκτίμηση πιστωτικού κινδύνου και την ανάλυση της αγοραίας μεταβλητότητας.

Ειδικότερα, η μελέτη των Heß et al. (2025), αναδεικνύει τη χρήση τεχνικών ML για την πρόβλεψη πιστωτικού κινδύνου, την αναγνώριση επιχειρησιακής αβεβαιότητας και τη βελτιστοποίηση stress tests, ενώ η εργασία των Chang et al. (2024) δείχνει ότι η ανάλυση δεδομένων σε πραγματικό χρόνο μπορεί να ενισχύσει την πράσινη χρηματοδότηση, βελτιώνοντας την πρόβλεψη απόδοσης τραπεζικών προϊόντων και μειώνοντας τον πιστωτικό κίνδυνο. Επιπρόσθετα, ο Giudici et al. (2024) προτείνει το καινοτόμο κριτήριο risk-aware actual value για την αξιολόγηση της βιωσιμότητας και της αξιοπιστίας συστημάτων AI, προσφέροντας ένα εργαλείο μέτρησης κινδύνων που συνδέει την κανονιστική συμμόρφωση με την τεχνητή νοημοσύνη.

Επίσης, ο Hernández et al. (2024) παρουσιάζει ένα υβριδικό μοντέλο που βελτιώνει την πρόβλεψη αγοραίας μεταβλητότητας, επιτυγχάνοντας μεγαλύτερη ακρίβεια και πιο αξιόπιστες μετρήσεις Value-at-Risk. Η μελέτη των Doumpos et al. (2023) καταγράφει τις τάσεις της τελευταίας δεκαετίας στη χρήση μεθόδων OR και AI, καλύπτοντας ένα ευρύ φάσμα εφαρμογών, από την πρόβλεψη πιστωτικού κινδύνου έως τη βελτιστοποίηση στρατηγικών M&A και την ενσωμάτωση fintech εργαλείων στις τραπεζικές υπηρεσίες. Τέλος, ο Brenes et al. (2022) προτείνει ένα μοντέλο ANN για την πρόβλεψη πτώχευσης εταιρειών, επιτυγχάνοντας υψηλή ακρίβεια και προσφέροντας πρακτικές κατευθύνσεις για την βελτιστοποίηση παραμέτρων βαθιάς μάθησης.

Παρά τις σημαντικές προόδους που έχουν επιτευχθεί στον τομέα της διαχείρισης χρηματοοικονομικών κινδύνων μέσω ευφυών υπολογιστικών μεθόδων, εξακολουθούν να υφίστανται ορισμένα ερευνητικά κενά τα οποία περιορίζουν την περαιτέρω ανάπτυξη του πεδίου. Πιο συγκεκριμένα, παρατηρείται η περιορισμένη αξιοποίηση πραγματικών τραπεζικών δεδομένων στις περισσότερες μελέτες, γεγονός που δυσχεραίνει την εφαρμογή των αποτελεσμάτων σε πραγματικά περιβάλλοντα. Επιπλέον, η ανάπτυξη υβριδικών μοντέλων που συνδυάζουν πολλαπλές μεθόδους υπολογιστικής νοημοσύνης παραμένει ανεπαρκής, στερώντας από τα υπάρχοντα πλαίσια τη δυνατότητα βελτιωμένης απόδοσης. Παράλληλα, διαπιστώνεται η έλλειψη εξηγήσιμων μοντέλων τεχνητής νοημοσύνης, γεγονός που περιορίζει τη διαφάνεια και την εμπιστοσύνη στις αποφάσεις που λαμβάνονται από τα συστήματα αυτά. Τέλος, οι έρευνες γύρω από τα πράσινα χρηματοοικονομικά εργαλεία και την αξιολόγηση των κινδύνων ESG παραμένουν περιορισμένες, γεγονός που

αναδεικνύει την ανάγκη για περαιτέρω διερεύνηση και ανάπτυξη στο πλαίσιο της βιώσιμης τραπεζικής και επενδυτικής στρατηγικής.

Κεφάλαιο 3^ο: Μεθοδολογία Ανασκόπησης

3.1 Εισαγωγή στην μεθοδολογία

Για τις ανάγκες της παρούσας εργασίας υιοθετήθηκε η μεθοδολογία της συστηματικής βιβλιομετρικής ανασκόπησης (Systematic Bibliometric Review - SBR), η οποία συνδυάζει τη συστηματική συλλογή και την αξιολόγηση επιστημονικών δημοσιεύσεων. Αυτό επιτυγχάνεται με την ποσοτική ανάλυση βιβλιομετρικών δεδομένων, ώστε να μετρήσει και να οπτικοποιήσει τα δεδομένα. Η μέθοδος αυτήν, βασίζεται στην χρήση εξειδικευμένων εργαλείων, όπως το R bibliometrix και το Biblioshiny, τα οποία επιτρέπουν την επεξεργασία μεγάλου όγκου δεδομένων (Pulsiri et al., 2018). Σε αντίθεση με τις παραδοσιακές μεθόδους ανασκόπησης, η προσέγγιση αυτήν προσφέρει μεγαλύτερη ακρίβεια και συστηματικότητα, καθώς επιτρέπει την ποσοτική αποτύπωση της ερευνητικής δραστηριότητας και την ανίχνευση τάσεων, συνεργασιών και θεματικών κατευθύνσεων στο πεδίο (Pulsiri et al., 2018).

Σύμφωνα με τους Lin & Kumar. (2024), η διαδικασία μιας συστηματικής βιβλιομετρικής ανασκόπησης περιλαμβάνει τέσσερα βασικά στάδια:

- 1) Καθορισμός στόχων και εύρους της ανασκόπησης.
- 2) Επιλογή των κατάλληλων τεχνικών ανάλυσης.
- 3) Συλλογή των απαραίτητων δεδομένων.
- 4) Εκτέλεση της ανάλυσης και παρουσίαση των αποτελεσμάτων.

Στόχος της ανασκόπησης είναι να αναδειχθεί η εξέλιξη της επιστημονικής δραστηριότητας στον τομέα της εφαρμογής ευφύων υπολογιστικών μεθόδων στην διαχείριση των χρηματοοικονομικών κινδύνων. Η μέθοδος που εφαρμόστηκε, εξετάζει τις τάσεις δημοσιεύσεων, περιοδικών και συγγραφέων σε επιστημονικά άρθρα. Το εύρος της ανασκόπησης είναι ιδιαίτερα εκτενές, καθώς οι τεχνολογίες των CI εξελίσσονται ραγδαία, αποκτώντας όλο και μεγαλύτερη σημασία και ευρεία εφαρμογή στην σύγχρονη κοινωνία, με τον χρηματοοικονομικό τομέα να διαδραματίζει πρωταγωνιστικό ρόλο σε αυτήν (Sheth, 2023).

3.2 Ερευνητική Προσέγγιση

Η παρούσα εργασία βασίστηκε στη μεθοδολογία της συστηματικής βιβλιομετρικής ανασκόπησης, με σκοπό τη συγκέντρωση, την ανάλυση και την αποτίμηση της ερευνητικής δραστηριότητας, που αφορά την χρήση ευφύων υπολογιστικών μεθόδων στην διαχείριση χρηματοοικονομικών κινδύνων. Το

συγκεκριμένο επιστημονικό πεδίο παρουσιάζει αυξημένο αριθμό δημοσιεύσεων και για τον λόγο αυτό κρίθηκε απαραίτητη η συγκεκριμένη μεθοδολογία. Μέσω τις SBR επιτυγχάνεται: α) ο εντοπισμός και η συγκέντρωση των επιστημονικών άρθρων, β) η οργάνωση και η κατηγοριοποίηση των βιβλιογραφικών δεδομένων, γ) η ανάδειξη των σημαντικών ερευνητικών τάσεων και ο καθορισμός των περιοχών που εντοπίζονται ερευνητικά κενά (Pulsiri et al., 2018).

Πραγματοποιήθηκε αναζήτηση βιβλιογραφία στις επιστημονικές βάσεις δεδομένων που αναφέρονται αναλυτικά στην συνέχεια και εντοπίστηκαν 84 επιστημονικά άρθρα, τα οποία αποτέλεσαν το τελικό δείγμα της μελέτης. Κατόπιν, πραγματοποιήθηκε συνδυαστική ανάλυση του συνόλου των δεδομένων, εφαρμόζοντας τόσο ποσοτικές όσο και ποιοτικές τεχνικές επεξεργασίας, με τη χρήση του λογισμικού R και του εξειδικευμένου πακέτου Bibliometrix (Stapleton et al., 2020).

3.3 Διαδικασία Επιλογής Άρθρων

Για την υλοποίηση της παρούσας διπλωματικής εργασίας πραγματοποιήθηκε συστηματική αναζήτηση της βιβλιογραφίας, με σκοπό τη συλλογή επιστημονικών δημοσιεύσεων που εξετάζουν την εφαρμογή ευφύων υπολογιστικών μεθόδων στην διαχείριση χρηματοοικονομικών κινδύνων (Pulsiri et al., 2018). Η αναζήτηση έγινε στις βιβλιογραφικές βάσεις Scopus και κυρίως το ScienceDirect, καθώς διαθέτουν μεγάλη συλλογή επιστημονικών άρθρων και θεωρούνται αξιόπιστες (Stapleton et al., 2020). Για την επιλογή των κατάλληλων άρθρων χρησιμοποιήθηκαν συνδυασμοί λέξεων-κλειδιών και οι λογικοί τελεστές (*AND / OR*), ώστε να επιτευχθεί η μεγαλύτερη δυνατή κάλυψη του θέματος. Οι λέξεις-κλειδιά που χρησιμοποιήθηκαν στην αναζήτηση ήταν:

- ❖ "computational intelligence" *AND* "financial risk management"
- ❖ "machine learning" *AND* "credit risk"
- ❖ "neural networks" *AND* "market risk"
- ❖ "deep learning" *AND* "financial forecasting"
- ❖ "genetic algorithms" *AND* "portfolio optimization"
- ❖ "fuzzy logic" *AND* "financial decision making"
- ❖ "liquidity risk" *AND* "deep learning"
- ❖ "climate risk" *AND* "machine learning"
- ❖ "fraud detection" *AND* "autoencoder"
- ❖ "anomaly detection" *AND* "deep learning" *AND* "banking"
- ❖ "graph neural networks" *AND* "financial risk"
- ❖ "particle swarm optimization" *AND* "financial risk"
- ❖ "ant colony optimization" *AND* "portfolio risk"
- ❖ "metaheuristic algorithms" *AND* "banking risk"

- ❖ "hybrid models" AND "market risk"
- ❖ "artificial intelligence" AND "bankruptcy prediction"
- ❖ "fuzzy logic" AND "operational risk"

Η χρήση των παραπάνω συνδυασμών καλύπτουν ένα ευρύ φάσμα επιστημονικών δημοσιεύσεων, οι οποίες αφορούν την εφαρμογή ευφυών υπολογιστικών μεθόδων σε διαφορετικές κατηγορίες χρηματοοικονομικών κινδύνων (Staples et al., 2007).

Για την επιλογή και την οργάνωση των άρθρων ακολουθήθηκε η μεθοδολογία της PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses), βασισμένη στην αναλυτική καθοδήγηση του Explanation and Elaboration document (Page et al., 2021). Για να ενταχθεί ένα άρθρο στην τελική συλλογή, έπρεπε να πληροί συγκεκριμένα κριτήρια, ώστε να διασφαλιστεί η ποιότητα και η συνάφεια του υλικού με το αντικείμενο της εργασίας.

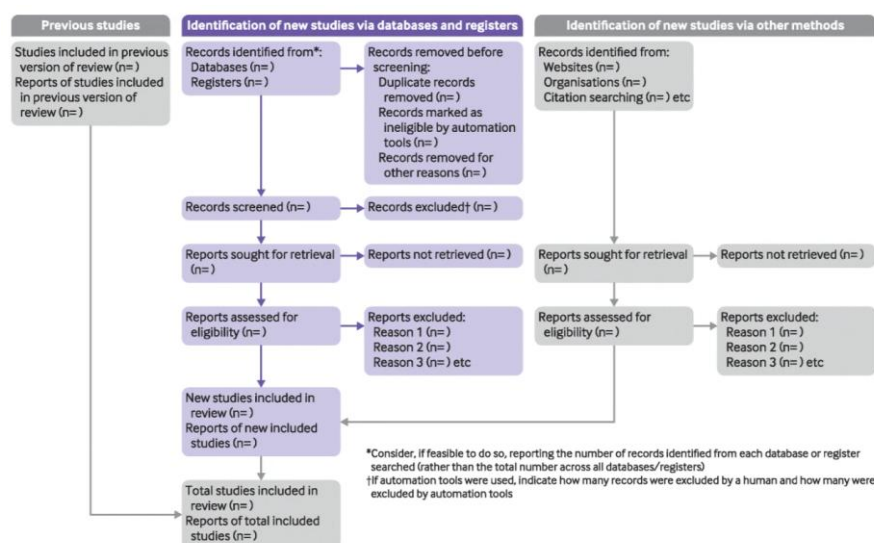
Στο επόμενο στάδιο, τα επιλεγμένα άρθρα κατηγοριοποιήθηκαν με βάση συγκεκριμένα κριτήρια, τα οποία περιλάμβαναν:

1. Τον τύπο του χρηματοοικονομικού κινδύνου που μελετάται σε κάθε άρθρο (Credit, Market, Operational και Liquidity)
2. Την ευφυή υπολογιστική μέθοδο που χρησιμοποιήθηκε για την ανάλυση (SVM, Neural Networks, Random Forest και LSTM)
3. Το είδος των δεδομένων που αξιοποιήθηκαν στο πλαίσιο της έρευνας
4. Τους δείκτες απόδοσης που εφαρμόστηκαν για την αξιολόγηση των προτεινόμενων μοντέλων (Accuracy, AUC, RMSE και άλλα).

Με αυτόν τον τρόπο, προκύπτει μια σαφής και ολοκληρωμένη εικόνα των βασικών ερευνητικών τάσεων στον τομέα, ενώ παράλληλα εντοπίζονται οι περιοχές που απαιτούν περαιτέρω διερεύνηση (Lu et al., 2012).

Παρά το γεγονός ότι η μεθοδολογία που ακολουθήθηκε βασίστηκε στις οδηγίες PRISMA, η παρούσα εργασία παρουσιάζει ορισμένους περιορισμούς. Πρώτον, η αναζήτηση περιορίστηκε σε δύο βάσεις (Scopus και ScienceDirect), γεγονός που ενδέχεται να έχει αποκλείσει σχετικές μελέτες από άλλες πηγές. Δεύτερον, η επιλογή της αγγλικής γλώσσας ως προϋπόθεση, μπορεί να έχει οδηγήσει σε παράλειψη ερευνών που δημοσιεύθηκαν σε άλλες γλώσσες. Επιπλέον, ο χρονικός περιορισμός (2014–2025) ενδέχεται να έχει αποκλείσει παλαιότερες μελέτες, που θα μπορούσαν να είναι χρήσιμες για το θεωρητικό υπόβαθρο. Τέλος, με βάση την Εικόνα 3.1 τα αποτελέσματα βασίζονται αποκλειστικά σε peer-reviewed άρθρα, κάτι που διασφαλίζει την ποιότητα, αλλά μπορεί να αποκλείει

ενδιαφέρουσες πρακτικές εφαρμογές ή grey literature, καθώς ήταν απαραίτητο να υπάρχει πλήρης πρόσβαση στο κείμενο (*full text*), ώστε να καταστεί δυνατή η περαιτέρω μελέτη και ανάλυσή του.



Εικόνα 3.1: Διαφορετικά στάδια συστηματικής ανασκόπησης (Πηγή: Page et al., 2021)

Από τη βιβλιογραφία αποκλείστηκαν όλα τα άρθρα που δεν σχετίζονταν άμεσα με το αντικείμενο της εργασίας ή παρουσίαζαν περιορισμένη επιστημονική αξία. Συγκεκριμένα, εξαιρέθηκαν δημοσιεύσεις όπως βιβλιοπαρουσιάσεις, σημειώσεις, περιλήψεις ή συνέδρια, καθώς δεν παρείχαν επαρκή δεδομένα. Επίσης, αφαιρέθηκαν διπλότυπες εγγραφές που εντοπίστηκαν μεταξύ των βάσεων δεδομένων, καθώς και άρθρα που δεν υπήρχε διαθέσιμο πλήρες κείμενο, γεγονός που καθιστούσε αδύνατη την περαιτέρω ανάλυσή τους (Page et al., 2021). Πραγματοποιήθηκε η διαδικασία των 27-στοιχείων check-list, όπως φαίνεται στην Εικόνα 3.2α, Εικόνα 3.2β, Εικόνα 3.2γ και Εικόνα 3.2δ των τεσσάρων-σταδίων flow diagram, που εξασφάλισε διαφάνεια και ακρίβεια σε κάθε φάση της μεθοδολογικής διαδικασίας, όπως φαίνεται στην Εικόνα 3.1. Αρχικά, κατά την πρώτη αναζήτηση, εντοπίστηκαν περίπου 350 άρθρα από τις βάσεις δεδομένων Scopus και ScienceDirect. Στη συνέχεια, εφαρμόστηκε ένα πρώτο φιλτράρισμα, όπου, με βάση τον τίτλο, την περίληψη και τις λέξεις-κλειδιά, ο αριθμός των άρθρων περιορίστηκε σε περίπου 120. Τέλος, μετά από αναλυτική μελέτη του πλήρους κειμένου, επιλέχθηκαν 84 άρθρα, τα οποία αποτέλεσαν το τελικό δείγμα που χρησιμοποιήθηκε για περαιτέρω ανάλυση.

Section and topic	Item #	Checklist item
Title		
Title	1	Identify the report as a systematic review.
Abstract		
Abstract	2	See the PRISMA 2020 for Abstracts checklist (Table 2).
Introduction		
Rationale	3	Describe the rationale for the review in the context of existing knowledge.
Objectives	4	Provide an explicit statement of the objective(s) or question(s) the review addresses.
Methods		
Eligibility criteria	5	Specify the inclusion and exclusion criteria for the review and how studies were grouped for the syntheses.
Information sources	6	Specify all databases, registers, websites, organisations, reference lists and other sources searched or consulted to identify studies. Specify the date when each source was last searched or consulted.
Search strategy	7	Present the full search strategies for all databases, registers and websites, including any filters and limits used.
Selection process	8	Specify the methods used to decide whether a study met the inclusion criteria of the review, including how many reviewers screened each record and each report retrieved, whether they worked independently, and if applicable, details of automation tools used in the process.
Data collection process	9	Specify the methods used to collect data from reports, including how many reviewers collected data from each report, whether they worked independently, any processes for obtaining or confirming data from study investigators, and if applicable, details of automation tools used in the process.
Data items	10a	List and define all outcomes for which data were sought. Specify whether all results that were compatible with each outcome domain in each study were sought (e.g. for all measures, time points, analyses), and if not, the methods used to decide which results to collect.
	10b	List and define all other variables for which data were sought (e.g. participant and intervention characteristics, funding sources). Describe any assumptions made about any missing or unclear information.

Εικονα 3.2α: Λίστα ελέγχου στοιχείων (μέρος α).

(Πηγή: Page et al., 2021)

Study risk of bias assessment	11	Specify the methods used to assess risk of bias in the included studies, including details of the tool(s) used, how many reviewers assessed each study and whether they worked independently, and if applicable, details of automation tools used in the process.
Effect measures	12	Specify for each outcome the effect measure(s) (e.g. risk ratio, mean difference) used in the synthesis or presentation of results.
Synthesis methods	13a	Describe the processes used to decide which studies were eligible for each synthesis (e.g. tabulating the study intervention characteristics and comparing against the planned groups for each synthesis (item #5)).
	13b	Describe any methods required to prepare the data for presentation or synthesis, such as handling of missing summary statistics, or data conversions.
	13c	Describe any methods used to tabulate or visually display results of individual studies and syntheses.
	13d	Describe any methods used to synthesise results and provide a rationale for the choice(s). If meta-analysis was performed, describe the model(s), method(s) to identify the presence and extent of statistical heterogeneity, and software package(s) used.
	13e	Describe any methods used to explore possible causes of heterogeneity among study results (e.g. subgroup analysis, meta-regression).
	13f	Describe any sensitivity analyses conducted to assess robustness of the synthesised results.
Reporting bias assessment	14	Describe any methods used to assess risk of bias due to missing results in a synthesis (arising from reporting biases).
Certainty assessment	15	Describe any methods used to assess certainty (or confidence) in the body of evidence for an outcome.

Εικονα 3.2β: Λίστα ελέγχου στοιχείων (μέρος β).

(Πηγή: Page et al., 2021)

Results		
Study selection	16a	Describe the results of the search and selection process, from the number of records identified in the search to the number of studies included in the review, ideally using a flow diagram (see Fig. 1).
	16b	Cite studies that might appear to meet the inclusion criteria, but which were excluded, and explain why they were excluded.
Study characteristics	17	Cite each included study and present its characteristics.
Risk of bias in studies	18	Present assessments of risk of bias for each included study.
Results of individual studies	19	For all outcomes, present, for each study: (a) summary statistics for each group (where appropriate) and (b) an effect estimate and its precision (e.g. confidence/credible interval), ideally using structured tables or plots.
Results of syntheses	20a	For each synthesis, briefly summarise the characteristics and risk of bias among contributing studies.
	20b	Present results of all statistical syntheses conducted. If meta-analysis was done, present for each the summary estimate and its precision (e.g. confidence/credible interval) and measures of statistical heterogeneity. If comparing groups, describe the direction of the effect.
	20c	Present results of all investigations of possible causes of heterogeneity among study results.
	20d	Present results of all sensitivity analyses conducted to assess the robustness of the synthesised results.
Reporting biases	21	Present assessments of risk of bias due to missing results (arising from reporting biases) for each synthesis assessed.
Certainty of evidence	22	Present assessments of certainty (or confidence) in the body of evidence for each outcome assessed.

Εικονα 3.2γ: Λίστα ελέγχου στοιχείων (μέρος γ).

(Πηγή: Page et al., 2021)

Discussion		
Discussion	23a	Provide a general interpretation of the results in the context of other evidence.
	23b	Discuss any limitations of the evidence included in the review.
	23c	Discuss any limitations of the review processes used.
	23d	Discuss implications of the results for practice, policy, and future research.
Other information		
Registration and protocol	24a	Provide registration information for the review, including register name and registration number, or state that the review was not registered.
	24b	Indicate where the review protocol can be accessed, or state that a protocol was not prepared.
	24c	Describe and explain any amendments to information provided at registration or in the protocol.
Support	25	Describe sources of financial or non-financial support for the review, and the role of the funders or sponsors in the review.
Competing interests	26	Declare any competing interests of review authors.
Availability of data, code, and other materials	27	Report which of the following are publicly available and where they can be found: template data collection forms; data extracted from included studies; data used for all analyses; analytic code; any other materials used in the review.

Εικονα 3.2δ: Λίστα ελέγχου στοιχείων (μέρος δ).

(Πηγή: Page et al., 2021)

3.4 Δημιουργία Βάσης Δεδομένων

Για την καλύτερη οργάνωση και επεξεργασία των στοιχείων που προέκυψαν από την διαδικασία επιλογής των άρθρων, δημιουργήθηκε μια δομημένη βάση δεδομένων σε μορφή Excel, σύμφωνα με τις πρακτικές που προτείνονται στην βιβλιογραφία (Deriviz, 2020). Σκοπός του Excel ήταν η συγκέντρωση όλων των απαραίτητων πληροφοριών για κάθε άρθρο, ώστε να διευκολυνθεί η ανάλυση, η κατηγοριοποίηση και η βιβλιομετρική επεξεργασία μέσω του πακέτου bibliometrix στο λογισμικό R.

	A	B	C	D	E	F
1						
2	AU	PR	TI	SO	DE	DI
3	Stefan Lessmann, Bart Baesens, Hsin-Vonn Seow, Lyn C. Thom	2015	Benchmarking state-of-the-art classification algorithms for credit scoring: An update	European Journal of Operati	Data mining, Credit scoring, OR in banking, Forecasting benchmark	https://doi.org/10.1016/j.ejor.2015.05.030
4	Elena Dumitrescu, Sullivan Hué, Christophe Hurlin, Sessi Tokpa	2022	Machine learning for credit scoring: Improving logistic regression with non-linear d	European Journal of Operati	Risk management, Credit s	https://doi.org/10.1016/j.ejor.2021.06.053
5	Apar Sathwani, Kay Giesecke, Justin Sirignano	2020	Deep Learning for Mortgage Risk	Journal of Financial Econom	Mortgage risk, Deep learni	https://doi.org/10.1093/jfinc/obaa025
6	Giorgio Visani, Enrico Bagli, Federico Chesani, Alessandro Polu	2022	Statistical stability indices for LIME: Obtaining reliable explanations for machine lea	Journal of the Operational R	Credit Scoring,machine lea	https://doi.org/10.1080/01605682.2020.186584
7	Farzan Soleymani, Eric Paquet	2020	Financial portfolio optimization with online deep reinforcement learning and restric	Expert Systems With Applic	Portfolio management, De	https://doi.org/10.1016/j.eswa.2020.113456
8	Dawei Cheng, Fangzhou Yang, Sheng Xiang, Jin Liu	2022	Financial time series forecasting with multi-modality graph neural network	Pattern Recognition	Graph neural network, Gra	https://doi.org/10.1016/j.patcog.2021.108218
9	Asaf Manela, Alan Moreira	2017	News implied volatility and disaster concerns	Journal of Financial Econom	Text-based analysis, Imple	http://dx.doi.org/10.1016/j.jfineco.2016.01.032
10	Philippe du Jardin	2021	Forecasting corporate failure using ensemble of self-organizing neural networks	European Journal of Operati	Risk analysis, Finance, Fore	https://doi.org/10.1016/j.ejor.2020.06.020

Εικόνα 3.3α: Δομή της βάσης δεδομένων με τα χαρακτηριστικά των άρθρων (μέρος α).

	G	H	I	J
1				
2	AB	Risk_Type	CI_Method	Dataset
3	This study presents an extensive bench	Credit Risk	Logistic Regression, Artificial Neural Networks (AP	8 datasets: Australian Credit (AC), German Credit (G
4	This paper introduces a new credit scor	Credit Risk	Penalised Logistic Tree Regression (PLTR), Random Four	real-world credit default datasets (including th
5	We examine the behavior of mortgage b	Mortgage Risk (mainly Credit Risk and Prepayment Risk)	Deep Learning (Deep Neural Networks, 5-layer arc	Freddie Mac, etc.)
6	The increasing use of machine learning (f	Credit	Gradient Boosting Trees, Logistic Regression	Real-life anonymised data from Italian financial inst
7	The process of continuously reallocating	Market risk, Settlement risk	Deep reinforcement learning (SARSA), Convolutio	Historical financial data from 23 companies (e.g., Ap
8	Financial time series analysis plays a cen	Market	Multi-Modality Graph Neural Network (MAGNN)	Micro-F1, Macro-F1, Weighted-F1, A Return (Asset Return), RMSE = 7.48 (VIX out-of-sample prediction), R ² = 19% (test sample).
9	We construct a text-based measure of ur	Market Risk, Rare Disaster Risk	Support Vector Regression (SVR), Machine Learni	Wall Street Journal front-page articles (1890–2009).
10	This paper introduces a method for forec	Credit Risk , Bankruptcy Risk	Self-Organizing Neural Networks (ESN), compared	Financial statements from French firms (Van Dijk da

Εικόνα 3.3β: Δομή της βάσης δεδομένων με τα χαρακτηριστικά των άρθρων (μέρος β).

	K	L	M	N	O
1					
2	Metrics	Affiliation	Countries		
3	AUC, H-measure, Brier Score, Kolmogorov-Smirnov statistic (KS), Partial Gini, PCC (Percentage Correctly Classified)	School of Business and Economics, Humboldt-University of Berlin, Unter	Germany; Belgium; United Kingdom; Malaysia		
4	PCC (Percentage of Correctly Classified), AUC (Area Under Curve), Brier Score, Kolmogorov-Smirnov (KS) statistic, Partial Gini Inde	EconomX-CNRS, University of Paris Nanterre, 200 Avenue de la Républiq	France; France; France		
5	Cross-entropy loss (negative log-likelihood)				
6	Transition prediction accuracy,Comparative out-of-sample fit across neural network depths,Empirical transition matrix vs model predictions, No specific "accuracy %" stated but strong empirical fit over baseline models (e.g., logistic regression)	Google Brain; Stanford University; University of Illinois	USA; USA; USA		
7	Gini Index (used for model comparison), VSI and CSI for explanation stability	Università degli Studi di Bologna, Bologna, BO, Italy, CRIF S.p.A, Bologna, I	Italy; Italy; Italy; Italy; Italy		
8	Return on Investment (RoI), Sharpe Ratio, Maximum Drawdown (MDD)	National Research Council, 1200 Montreal Road, Ottawa, ON K1K 2E1, Ca	Canada; Canada		
9	Micro-F1, Macro-F1, Weighted-F1, A Return (Asset Return), D Return (Daily Return), Sharpe Ratio	Department of Computer Science and Technology, Tongji University, Shan	China; China; Australia; China		
10	RMSE = 7.48 (VIX out-of-sample prediction), R ² = 19% (test sample), Return predictability (e.g., 3.3 percentage point increase in returns for 1 SD increase in NVIX)	Washington University, St. Louis, MO 63130, USA; Yale University, New H	USA; USA		
	Accuracy, Type I Error, Type II Error, Out-of-sample and out-of-time error	Edhec Business School, 393 Promenade des Anglais, BP 3116, 06202 Nice	France		
	AUC (Area Under Curve):0.817 (1 year before failure), 0.880 (2 years before failure), 0.795 (3 years before failure), Accuracy: 70.00% (1 year),				

Εικόνα 3.3γ: Δομή της βάσης δεδομένων με τα χαρακτηριστικά των άρθρων (μέρος γ).

- A. *AU (Authors)*: Ονόματα συγγραφέων του άρθρου.
- B. *PY (Publication Year)*: Έτος δημοσίευσης.
- C. *TI (Title)*: Τίτλος της μελέτης.
- D. *SO (Source)*: Επιστημονικό περιοδικό.
- E. *DE (Author Keywords)*: Λέξεις-κλειδιά που όρισαν οι συγγραφείς.
- F. *DI (DOI)*: Ψηφιακός αναγνωριστικός αριθμός του άρθρου.
- G. *AB (Abstract)*: Περίληψη του άρθρου.
- H. *Risk Type*: Κατηγορία χρηματοοικονομικού κινδύνου που εξετάζεται (Credit, Market, Operational, Liquidity Risk).
- I. *CI Method*: Ευφυής υπολογιστική μέθοδος που εφαρμόστηκε (SVM, Neural Networks, Random Forest, LSTM).
- J. *Dataset*: Είδος ή πηγή των δεδομένων που χρησιμοποιήθηκαν στην ανάλυση.
- K. *Metrics*: Δείκτες αξιολόγησης της απόδοσης των μεθόδων (Accuracy, AUC, RMSE, F1-score).
- L. *Affiliation*: Τον οργανισμό/πανεπιστήμιο με την οποία συνδέεται ο κάθε συγγραφέας.
- M. *Country*: Την χώρα προέλευσης του συγγραφέα.

Η δημιουργία της συγκεκριμένης βάσης, επέτρεψε τη συστηματική οργάνωση των άρθρων και των βασικών χαρακτηριστικών τους, διευκολύνοντας έτσι την διαχείριση των πληροφοριών. Παράλληλα, συνέβαλε στην αποτελεσματική κατηγοριοποίηση των μελετών, με βάση τον τύπο χρηματοοικονομικού κινδύνου, την εφαρμοζόμενη μέθοδο, το είδος των δεδομένων και τους δείκτες απόδοσης που χρησιμοποιήθηκαν. Επιπρόσθετα, η συγκέντρωση των στοιχείων σε ενιαία μορφή κατέστησε δυνατή την διεξαγωγή ανάλυσης μέσω στατιστικών και βιβλιομετρικών εργαλείων, όπως το R και το πακέτο bibliometrix, ενισχύοντας την αξιοπιστία και την ακρίβεια των αποτελεσμάτων (Zupic et al., 2013; Derviş, 2020).

3.4 Στατιστική και Βιβλιομετρική Ανάλυση

Μετά τη δημιουργία του Excel, πραγματοποιήθηκε στατιστική και βιβλιομετρική ανάλυση, με στόχο την εξαγωγή συμπερασμάτων σχετικά με τις ερευνητικές τάσεις στο πεδίο των ευφυών υπολογιστικών μεθόδων στην διαχείριση χρηματοοικονομικών κινδύνων. Η ανάλυση πραγματοποιήθηκε στο λογισμικό R, αξιοποιώντας το πακέτο bibliometrix και το Biblioshiny, τα οποία παρέχουν ολοκληρωμένα εργαλεία για την μελέτη επιστημονικών άρθρων και την οπτικοποίηση των αποτελεσμάτων (Derviş, 2020). Σε αντίθεση με τυπικές βιβλιομετρικές αναλύσεις, που γίνονται μέσω απευθείας εξαγωγής δεδομένων από βάσεις όπως το Scopus ή το Web of Science, στην παρούσα εργασία τα δεδομένα καταχωρήθηκαν χειροκίνητα στο Excel.

Το αρχείο Excel εισήχθη στο περιβάλλον R μέσω της βιβλιοθήκης *readxl*¹, ενώ στη συνέχεια τα δεδομένα καθαρίστηκαν, οργανώθηκαν και κατηγοριοποιήθηκαν χρησιμοποιώντας τις βιβλιοθήκες *dplyr*¹ (για καθαρισμό, επεξεργασία και φιλτράρισμα δεδομένων) και *tidyr*¹ (για αναδιάρθρωση δεδομένων σε μορφή κατάλληλη για ανάλυση). Για την ανάλυση των λέξεων-κλειδιών και την επεξεργασία κειμένων χρησιμοποιήθηκε η *stringr*¹, ενώ για την παραγωγή γραφημάτων αξιοποιήθηκε η *ggplot2*¹. Επιπλέον, οι βιβλιοθήκες *igraph*² (για δημιουργία και ανάλυση δικτύων συνεργασίας) και *ggraph*² (για οπτικοποίηση *graph networks*) χρησιμοποιήθηκαν για την ανάλυση και την απεικόνιση δικτύων συνεργασίας μεταξύ συγγραφέων και ερευνητικών οργανισμών (Aria et al., 2016).

Με τη χρήση των παραπάνω εργαλείων πραγματοποιήθηκε μια σειρά από αναλύσεις, με στόχο την κατανόηση της ερευνητικής δραστηριότητας στο πεδίο. Αρχικά, εξετάστηκε η στατιστική κατανομή των δημοσιεύσεων ανά έτος, ανά συγγραφέα, ανά πανεπιστήμιο και ανά επιστημονικό περιοδικό, ώστε να αποτυπωθεί η εξέλιξη της έρευνας στον χρόνο. Στη συνέχεια, πραγματοποιήθηκε ανάλυση λέξεων-κλειδιών, με σκοπό τον εντοπισμό των συχνότερα χρησιμοποιούμενων λέξεων και τη χαρτογράφηση των θεματικών τάσεων που επικρατούν στη βιβλιογραφία. Επιπλέον, υλοποιήθηκε ανάλυση βιβλιογραφικών αναφορών, προκειμένου να εντοπιστούν τα άρθρα, οι συγγραφείς και τα πανεπιστήμια με την μεγαλύτερη επιρροή στο πεδίο. Επιπρόσθετα, δημιουργήθηκαν δίκτυα συνεργασιών για την μελέτη των σχέσεων μεταξύ ερευνητικών ιδρυμάτων και λέξεων κλειδιών. Τέλος, κατασκευάστηκαν θεματικοί χάρτες, οι οποίοι προσφέρουν μία σαφή απεικόνιση των κυριότερων ερευνητικών ρευμάτων και των μεταξύ τους συσχετίσεων (Aria et al., 2016).

Στο πλαίσιο της ανάλυσης δημιουργήθηκαν οπτικοποιήσεις, όπως *word clouds*, *thematic maps* και *citation graphs*, οι οποίες προσφέρουν μια σαφή και κατανοητή απεικόνιση των κυρίαρχων ερευνητικών τάσεων στον τομέα της εφαρμογής ευφυών υπολογιστικών μεθόδων στη διαχείριση χρηματοοικονομικών κινδύνων. Τα αποτελέσματα της βιβλιομετρικής ανάλυσης παρουσιάζονται αναλυτικά στο Κεφάλαιο 4.

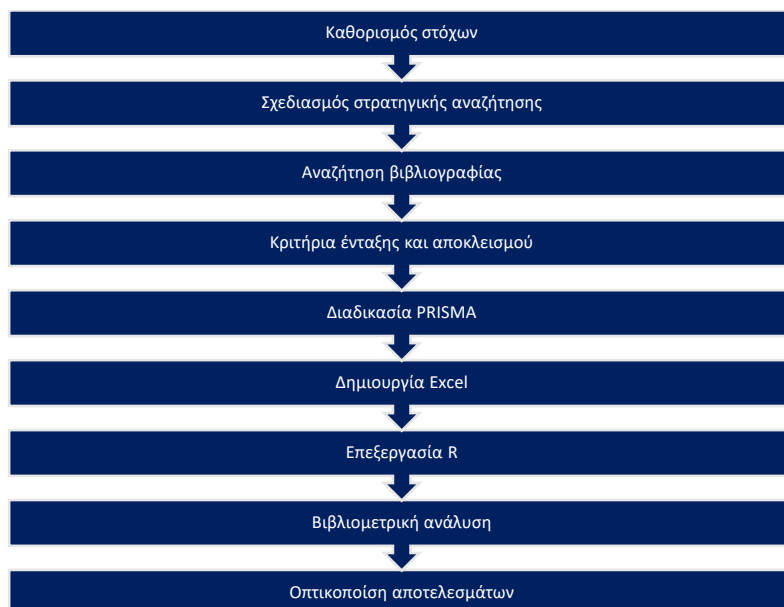
3.5 Συνολική Ροή Μεθοδολογίας

Η Εικόνα 3.4 παρουσιάζει συνοπτικά την μεθοδολογική προσέγγιση που ακολουθήθηκε στην παρούσα διπλωματική εργασία. Η διαδικασία βασίστηκε στη συστηματική SBR και στις κατευθυντήριες οδηγίες PRISMA (Page et al., 2021). Αρχικά, καθορίστηκαν οι στόχοι, ενώ στην συνέχεια σχεδιάστηκε η στρατηγική αναζήτησης και επιλέχθηκαν οι βάσεις δεδομένων Scopus και ScienceDirect. Μετά την εφαρμογή των κριτηρίων ένταξης και αποκλεισμού, επιλέχθηκαν τελικά 84 άρθρα τα οποία αποτέλεσαν το δείγμα της ανάλυσης. Επιπλέον, δημιουργήθηκε το Excel και τα δεδομένα εισήχθησαν

¹ <https://r4ds.hadley.nz/>

² <https://www.jessesadler.com/post/network-analysis-with-r/>

στο R για επεξεργασία. Η βιβλιομετρική ανάλυση και η οπτικοποίηση των αποτελεσμάτων πραγματοποιήθηκαν με τα εργαλεία bibliometrix, biblioshiny, ggplot2, igraph και ggraph, επιτρέποντας την παραγωγή στατιστικών στοιχείων, χαρτογραφήσεων θεματικών περιοχών και δικτύων συνεργασιών μεταξύ συγγραφέων και ερευνητικών οργανισμών.



Εικόνα 3.4: Συνολική ροή της μεθοδολογικής διαδικασίας

Κεφάλαιο 4^ο : Αποτελέσματα της Βιβλιομετρικής Ανασκόπησης


4.1 Εισαγωγή

Στο 4^ο Κεφάλαιο παρουσιάζονται τα αποτελέσματα της βιβλιομετρικής ανάλυσης που πραγματοποιήθηκε από το σύνολο των επιστημονικών άρθρων που επιλέχθηκαν. Η ανάλυση πραγματοποιήθηκε με την χρήση της γλώσσας R και αξιοποιήθηκαν βιβλιοθήκες του `readxl`, `dplyr`, `tidyr`, `stringr` για την εισαγωγή, επεξεργασία, καθαρισμό και κατηγοριοποίηση των δεδομένων, καθώς και η βιβλιοθήκη `ggplot2` για την παραγωγή γραφημάτων. Ακόμη, χρησιμοποιήθηκαν τα πακέτα `igraph` και `ggraph` για την ανάλυση και απεικόνιση δικτύων συνεργασίας μεταξύ συγγραφέων και ερευνητικών οργανισμών, ενώ το πακέτο `bibliometrix` υποστήριξε την εξαγωγή βιβλιομετρικών δεικτών και την χαρτογράφηση της επιστημονικής γνώσης (Aria et al., 2016). Τα αποτελέσματα παρουσιάζονται μέσα από στατιστικές αναλύσεις, πίνακες, γραφήματα και δικτυακές απεικονίσεις, ώστε να αναδειχθούν οι ερευνητικές τάσεις, οι δημοφιλείς μεθοδολογίες, τα κυρίαρχα θεματικά πεδία και τα πρότυπα συνεργασίας στην βιβλιογραφία.

4.2 Αποτελέσματα Στατιστικής ανάλυσης

4.2.1 Εξέλιξη Δημοσιευτικής Δραστηριότητας Ανά Έτος

Η τάση δημοσιεύσεων της ερευνάς, που σχετίζεται με τις ευφυείς υπολογιστικούς μεθόδους στον τομέα των χρηματοοικονομικών κινδύνων, παρουσιάζεται στο Σχήμα 4.1, όπου απεικονίζεται ο συνολικός αριθμός των άρθρων σε συνάρτηση με το έτος δημοσιεύσεις τους. Τα ευρήματα έδειξαν την αύξηση των δημοσιεύσεων την τελευταία δεκαετία, με κορύφωση την χρονική περίοδο 2019-2025. Αυτό υποδηλώνει ότι η εφαρμογή των ευφύων μεθόδων στο χρηματοοικονομικό αποτελεί αναδυόμενο τομέα.




Σχήμα 4.1 : Αριθμός Δημοσιεύσεων ανά έτος.

Στο παραπάνω σχήμα παρατηρείται ότι, τα πιο παραγωγικά έτη είναι το 2019 με 8 άρθρα, το 2020 με 10 άρθρα, τα έτη 2021 και 2022 με 8 άρθρα το καθένα καθώς και το 2023 με 9 άρθρα. Το 2024 καταγράφεται σημαντική αύξηση, καθώς οι δημοσιεύσεις διπλασιάζονται φτάνοντας τα 18 άρθρα. Τέλος, για το 2025 καταγράφονται ήδη 7 άρθρα μόνο κατά το πρώτο εξάμηνο του έτους, γεγονός που υποδηλώνει ότι ο συνολικός αριθμός δημοσιεύσεων αναμένεται να ξεπεράσει τα επίπεδα του προηγούμενου έτους.

4.2.2 Κατάταξη Περιοδικών βάσει Πλήθους Δημοσιεύσεων

Οι κορυφαίοι επιστημονικοί τίτλοι περιοδικών, που δημοσιεύουν έρευνες σχετικές με την εφαρμογή ευφυών υπολογιστικών μεθόδων στον χρηματοοικονομικό τομέα, παρουσιάζονται στο Σχήμα 4.2. Από την ανάλυση των αποτελεσμάτων προκύπτει ότι οι περισσότερες δημοσιεύσεις συγκεντρώνονται σε περιοδικά υψηλού κύρους, τα οποία εξειδικεύονται σε τομείς όπως η τεχνητή νοημοσύνη, η μηχανική μάθηση, η χρηματοοικονομική ανάλυση και τα συστήματα υποστήριξης αποφάσεων.




Σχήμα 4.2: Κατανομή Άρθρων Ανά Επιστημονικό Περιοδικό.

Στο Σχήμα 4.2 αποτυπώνονται τα δέκα κορυφαία περιοδικά με βάση το πλήθος των δημοσιεύσεων. Το περιοδικό Expert Systems with Applications καταλαμβάνει την πρώτη θέση, συγκεντρώνοντας 17 δημοσιεύσεις, γεγονός που το καθιστά βασικό σημείο αναφοράς της ερευνητικής κοινότητας στον τομέα. Ακολουθούν το European Journal of Operational Research με 8 δημοσιεύσεις και το Journal of Computational and Applied Mathematics με 4 δημοσιεύσεις, γεγονός που υποδεικνύει ότι η ερευνητική παραγωγή επικεντρώνεται σε συγκεκριμένα επιστημονικά φόρα.

4.2.3: Κατάταξη Συγγραφέων Βάσει Πλήθους Δημοσιεύσεων


Η ανάλυση της κατανομής των άρθρων ανά συγγραφέα αναδεικνύει τους ερευνητές με την μεγαλύτερη συνεισφορά στον τομέα. Όπως φαίνεται στο Σχήμα 4.3, οι δέκα πιο παραγωγικοί συγγραφείς ξεχωρίζουν ως οι βασικοί συντελεστές της ερευνητικής δραστηριότητας στον τομέα, έχοντας δημοσιεύσει τα περισσότερα άρθρα τα τελευταία χρόνια. Την πρώτη θέση στη λίστα καταλαμβάνουν ισόβαθμα οι ερευνητές Jardin, Wang και Baesens, με τρεις δημοσιεύσεις ο καθένας. Οι υπόλοιποι συγγραφείς παρουσιάζουν σταθερή ερευνητική συνεισφορά με δύο δημοσιεύσεις ο καθένας, κάτι που φανερώνει τη συνεργατική φύση της ερευνητικής κοινότητας στο συγκεκριμένο πεδίο.



Σχήμα 4.3: Κατανομή Άρθρων Ανά Συγγραφέα

4.2.4 Κατάταξη χώρας βάσει πλήθος δημοσιεύσεων

Στο Σχήμα 4.4 παρουσιάζεται η κατανομή των δημοσιεύσεων ανά χώρα, βάσει των 20 κορυφαίων χωρών με τον μεγαλύτερο αριθμό άρθρων. Παρατηρείται ότι, η Κίνα καταλαμβάνει την πρώτη θέση με 17 δημοσιεύσεις, ακολουθούμενη από τις Ηνωμένες Πολιτείες και την Ινδία με 11 δημοσιεύσεις η καθεμία. Στην τέταρτη θέση βρίσκεται το Ηνωμένο Βασίλειο με 10 δημοσιεύσεις, ενώ χώρες όπως η Γερμανία, η Γαλλία και η Αυστραλία εμφανίζουν από 7 άρθρα. Στην κατώτερη κλίμακα της κατάταξης, χώρες όπως η Ελλάδα, η Φινλανδία και η Κολομβία συνεισφέρουν από 2 άρθρα. Η συγκεκριμένη κατανομή υποδηλώνει ότι η ερευνητική δραστηριότητα γύρω από τον τομέα συγκεντρώνεται κυρίως σε χώρες με υψηλή τεχνολογική και ερευνητική ανάπτυξη, ενώ παρατηρείται παράλληλα μια διάχυση της γνώσης σε διαφορετικές γεωγραφικές περιοχές.




Σχήμα 4.4: Κατανομή άρθρων ανά χώρα.

4.2.5 Κατανομή Ιδρυμάτων βάσει πλήθους δημοσιεύσεων

Στο Σχήμα 4.5 απεικονίζονται τα δέκα κορυφαία πανεπιστήμια και ερευνητικά ιδρύματα με τις περισσότερες δημοσιεύσεις στον κλάδο. Παρατηρείται ότι, το University of Technology Sydney (Αυστραλία) και το Dongbei University of Finance and Economics (Κίνα) βρίσκονται στην κορυφή με 3 δημοσιεύσεις το καθένα. Ακολουθούν το Sharif University of Technology (Ιράν), το School of Business and Economics (Γερμανία) και το Market Risk CIB Boadilla (Ισπανία) με 2 δημοσιεύσεις αντίστοιχα.

Ενδιαφέρον αποτελεί το γεγονός ότι, στον κατάλογο εμφανίζονται ιδρύματα από πολλαπλές γεωγραφικές περιοχές (Αυστραλία, Κίνα, Ιράν, Γερμανία, Ισπανία, Γαλλία), γεγονός που καταδεικνύει τον διεθνή χαρακτήρα της ερευνητικής δραστηριότητας στον τομέα. Παράλληλα, η παρουσία δύο ισπανικών πανεπιστημίων (Complutense University of Madrid και Autonomous University of Madrid) και δύο κινεζικών ιδρυμάτων (Dongbei University και Collaborative Innovation Center of Financial Security) υπογραμμίζει την έντονη συγκέντρωση της έρευνας σε ορισμένες ακαδημαϊκές εστίες.



Σχήμα 4.5: Κατανομή των δέκα καλύτερων πανεπιστημίων.


4.3 Βιβλιομετρική Ανάλυση

Στην παρούσα υποενότητα παρουσιάζονται τα αποτελέσματα της βιβλιομετρικής ανάλυσης που πραγματοποιήθηκε από το σύνολο των επιστημονικών άρθρων. Στόχος είναι να δοθεί μια ολοκληρωμένη εικόνα των βασικών τάσεων, θεματικών περιοχών και ερευνητικών κατευθύνσεων που προκύπτουν από την μελέτη της βιβλιογραφίας στον τομέα.

Η ανάλυση υλοποιήθηκε μέσω του λογισμικού R, αξιοποιώντας το πακέτο Bibliometrix, το οποίο επιτρέπει την εξαγωγή στατιστικών δεικτών, την απεικόνιση συχνοτήτων, καθώς και τη χαρτογράφηση θεματικών περιοχών (Aria et al., 2016). Στο πλαίσιο αυτό, παρουσιάζονται ραβδογράμματα που αποτυπώνουν τη συχνότητα εμφάνισης λέξεων-κλειδιών, θεματικοί χάρτες που αναδεικνύουν τη συνάφεια μεταξύ διαφορετικών ερευνητικών θεμάτων, καθώς και άλλα διαγράμματα που βοηθούν στην κατανόηση της ερευνητικής δραστηριότητας.

4.3.1 Συχνότητα λέξεων-κλειδιών

Στο παρακάτω διάγραμμα παρουσιάζονται οι 15 συχνότερες λέξεις-κλειδιά που εντοπίστηκαν στα επιστημονικά άρθρα της ανασκόπησης. Παρατηρείται ότι, οι όροι machine learning με 24 εμφανίσεις και deep learning με 15 εμφανίσεις καταλαμβάνουν τις πρώτες θέσεις, γεγονός που υποδηλώνει την έντονη ερευνητική εστίαση στις τεχνικές αυτές. Ακολουθούν οι λέξεις credit scoring με 10 εμφανίσεις, risk management με 8 εμφανίσεις και credit risk με 7 εμφανίσεις, αναδεικνύοντας τη σημασία που αποδίδεται στη διαχείριση και αξιολόγηση χρηματοοικονομικών κινδύνων.



Σχήμα 4.6 : Λέξεις-Κλειδιά

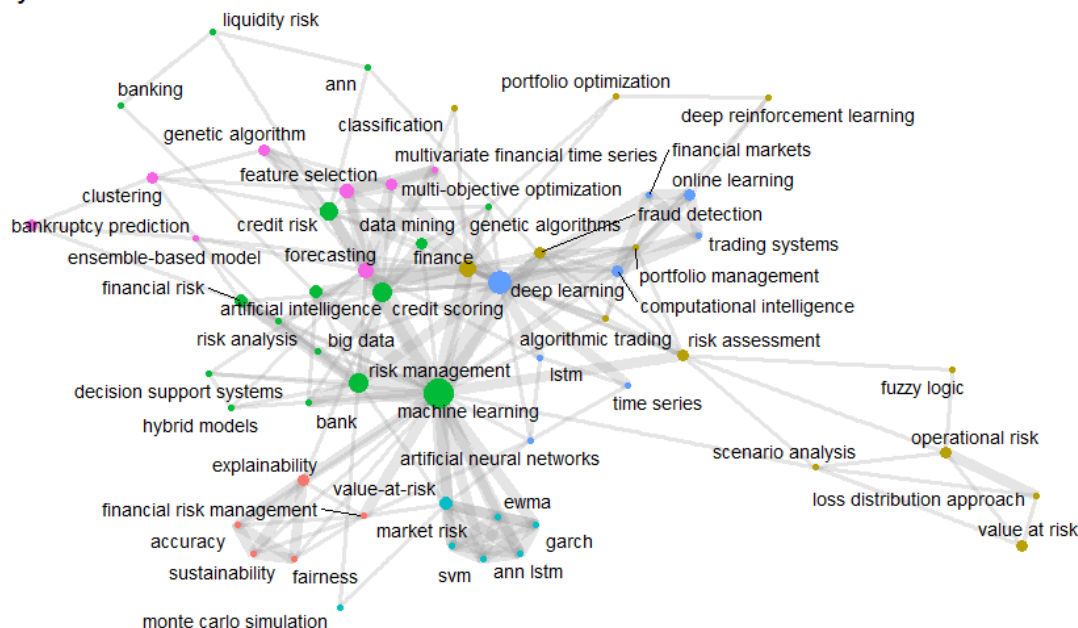
4.3.2 Θεματικοί Χάρτες

4.3.2.1: Δίκτυο συν-εμφάνισης λέξεων-κλειδιών

Στο Σχήμα 4.5 παρουσιάζεται το δίκτυο συν-εμφάνισης λέξεων-κλειδιών (Keyword Co-occurrence Network), το οποίο απεικονίζει τις θεματικές συσχετίσεις μεταξύ των εννοιών που προέκυψαν από τη βιβλιομετρική ανάλυση. Το μέγεθος κάθε κόμβου αντιστοιχεί στη συχνότητα εμφάνισης της λέξης-κλειδιού, ενώ το πάχος των γραμμών υποδηλώνει το βαθμό συνάφειας ανάμεσα στους όρους.

Παρατηρείται ότι, οι όροι *machine learning* και *deep learning* βρίσκονται στο κέντρο του δικτύου, γεγονός που υποδηλώνει τον καθοριστικό ρόλο τους στο ερευνητικό πεδίο. Οι λέξεις αυτές εμφανίζουν ισχυρούς δεσμούς με έννοιες όπως *credit scoring*, *risk management*, *feature selection* και *artificial intelligence*, αναδεικνύοντας τη σύνδεση των μεθόδων μηχανικής μάθησης με την αξιολόγηση χρηματοοικονομικών κινδύνων.

Keyword Co-occurrence Network



Σχήμα 4.5 : Δίκτυο συν-εμφάνισης λέξεων-κλειδιών με χρωματική ομαδοποίηση θεματικών clusters (μέγεθος κόμβου = συχνότητα, πάχος ακμής = ένταση συνεμφάνισης).

Επίσης, εντοπίζονται θεματικά clusters που αποτυπώνουν επιμέρους ερευνητικές κατευθύνσεις. Ένα πρώτο cluster σχετίζεται με την αξιολόγηση πιστοληπτικού κινδύνου και περιλαμβάνει όρους όπως *credit risk*, *credit scoring* και *risk assessment*. Ένα δεύτερο cluster εστιάζει στις τεχνικές βελτιστοποίησης, με βασικούς όρους όπως *genetic algorithms*, *portfolio optimization* και *multi-objective optimization*. Τέλος, αναδεικνύεται ένα τρίτο σύνολο όρων που σχετίζεται με την ανάλυση συστημάτων διαχείρισης κινδύνου, περιλαμβάνοντας έννοιες όπως *value-at-risk*, *loss distribution approach* και *decision support systems*.

Η απεικόνιση αυτή επιτρέπει την καλύτερη κατανόηση των ερευνητικών τάσεων και των διασυνδέσεων μεταξύ των κυρίαρχων θεμάτων, βοηθώντας στην ανάδειξη τόσο των κεντρικών περιοχών ενδιαφέροντος όσο και των θεμάτων που έχουν μελετηθεί σε μικρότερο βαθμό.

4.3.2.2 Δίκτυο συν-εμφάνισης Χωρών

Παρακάτω απεικονίζεται το Σχήμα 4.6 με τίτλο δίκτυο συνεργασιών μεταξύ χωρών, το οποίο βασίζεται στις συν-συγγραφές επιστημονικών δημοσιεύσεων. Παρατηρείται ότι, οι χώρες με την μεγαλύτερη ερευνητική δραστηριότητα, όπως η Κίνα, οι Ηνωμένες Πολιτείες, το Ηνωμένο Βασίλειο, η Γερμανία και η Ινδία, αποτελούν κεντρικούς κόμβους του δικτύου, με σημαντικό αριθμό συνεργασιών. Οι πιο έντονες γραμμές στο διάγραμμα υποδεικνύουν ισχυρές ερευνητικές συνεργασίες, με χαρακτηριστικά παραδείγματα την συνεργασία Κίνας και Ηνωμένου Βασιλείου, Ηνωμένων Πολιτειών και Κίνας, αλλά και Ηνωμένου Βασιλείου και Ινδίας.

$$0 \rightarrow \mathcal{L}' \rightarrow \mathcal{L} \rightarrow \mathcal{L}'' \rightarrow 0 \quad \text{and} \quad 0 \rightarrow \mathcal{L}' \rightarrow \mathcal{L} \rightarrow \mathcal{L}'' \rightarrow 0$$

μεθόδων μηχανικής μάθησης και βελτιστοποίησης μέσω λογιστικής, επιτρέποντας έτσι την ανάλυση και τον εντοπισμό κρίσιμων παραγόντων, που επηρεάζουν τη λειτουργία των χρηματοπιστωτικών οργανισμών και τραπεζών (Vanini et al., 2023).

Πίνακας 4.1: Κατανομή των άρθρων ανά τύπο χρηματοοικονομικού κινδύνου και τις συχνότερα χρησιμοποιούμενες μεθόδους Ευφυών Υπολογιστικών Συστημάτων

<i>Τύπος Κίνδυνου</i>	<i>#Άρθρων</i>	<i>%Συνόλου</i>	<i>Μέθοδος CI</i>
Credit Risk	42	49%	Other, ANN, SVM
Market Risk	29	35%	Other, LSTM, ANN
Operational Risk	8	10%	Other, ANN,DT
Liquidity Risk	3	4%	Other, Naïve Bayes, ANN
Systematic Risk	1	1%	Other, DT, Logistic Reg
Other/ Unspecified	1	1%	Other

Εν κατακλείδι, ο κίνδυνος ρευστότητας (Liquidity Risk), ο συστημικός κίνδυνος (Systemic Risk) και οι λοιποί κίνδυνοι συγκεντρώνουν πολύ μικρό ποσοστό του δείγματος με 4%, 1% και 1% αντίστοιχα. Η περιορισμένη παρουσία αυτών των άρθρων υποδηλώνει ότι πρόκειται για περιοχές με τη λιγότερη ερευνητική ενασχόληση, γεγονός που ενδεχομένως υποδηλώνει πιθανά ερευνητικά κενά και ευκαιρίες για μελλοντική μελέτη.

4.5: Κατανομή Άρθρων Ανά Μέθοδο Ευφυών Υπολογιστικών Συστημάτων

Η ενότητα αυτήν παρουσιάζει ποιες μέθοδοι υπολογιστικής νοημοσύνης χρησιμοποιούνται συχνότερα, με βάση την βιβλιογραφία που συλλέξαμε, καθώς και σε ποιους τύπους κινδύνου εστιάζει κάθε μέθοδος. Ο συνοδευτικός πίνακας αποτυπώνει τη συχνότητα χρήσης των μεθόδων και όχι την απόδοσή τους.

Πίνακας 4.2: Κατανομή των άρθρων ανά μέθοδο Ευφυών Υπολογιστικών Συστημάτων (CI) και τύπο χρηματοοικονομικού κινδύνου.

<i>Μέθοδος CI</i>	<i>#Άρθρων</i>	<i>%Συνόλου</i>	<i>Τύπος Κίνδυνου</i>
ANN	45	11%	Credit, Market
SVM	31	7%	Credit, Market
RF	19	4%	Credit, Market
LR	18	4%	Credit, Operational
DNN	17	4%	Market, Operational
LSTM	16	4%	Credit, Market

DT	13	3%	Credit, Operational
GA	10	2%	Credit, Market
GBM	10	2%	Credit, Market
XGBoost	9	2%	Credit, Liquidity

Στον Πίνακα 4.5³ παρουσιάζονται οι δέκα συχνότερες μέθοδοι υπολογιστικής νοημοσύνης με βάση τη βιβλιογραφία που συλλέξαμε και οι τύποι χρηματοοικονομικού κινδύνου στους οποίους εστιάζει κάθε μέθοδος. Παρατηρούμε ότι, τα ANN συγκεντρώνουν το μεγαλύτερο πλήθος εμφανίσεων με 11% του συνόλου. Ακολουθούν οι SVM με περίπου 7% του συνόλου και, κλείνοντας την τριάδα, τα RF με περίπου 4%. Στη δεκάδα περιλαμβάνονται επίσης οι Logistic Regression, DNN, LSTM, Decision Trees και μέθοδοι boosting (GBM, XGBoost).

Ως προς τους τύπους κινδύνου, οι πιο συχνοί ανά μέθοδο είναι κυρίως ο πιστωτικός και αγοράς. Επιπλέον, στις Logistic Regression και Decision Trees εμφανίζεται συχνά και ο λειτουργικός κίνδυνος. Η εικόνα αυτήν συνάδει με τη σχετική βιβλιογραφία, σύμφωνα με την οποία τα προβλήματα πιστωτικού και αγοραίου κινδύνου παραμένουν το βασικό πεδίο εφαρμογής, ενώ οι βαθιές αρχιτεκτονικές των DNN και LSTM κερδίζουν έδαφος κυρίως σε χρονοσειρές και σε πολύπλοκα, μη γραμμικά πρότυπα (Heß et al., 2025).

Σύμφωνα με την βιβλιογραφία, που έγινε η σχετική ανάλυση, παρατηρείται ότι, στην μελέτη των Niu et al. (2020), χρησιμοποιήθηκε LSTM για την πρόβλεψη τιμών χρηματιστηριακών δεικτών, πετυχαίνοντας σημαντική μείωση του RMSE και καλύτερη απόδοση σε προβλήματα κινδύνου αγοράς. Επιπροσθέτως, η ερευνά των Wang et al. (2025), ασχολείται με τον κίνδυνο αγοράς και παρουσιάζει δύο νέες προσεγγίσεις τις βαθιάς μάθησης για την εκτίμηση των Value at Risk (VaR) και Expected Shortfall (ES). Συνδυάζοντας τα μοντέλα με regularization-based τεχνικές, επιτυγχάνεται βελτιωμένη απόδοση σε backtesting, διευκολύνοντας την πιο αποτελεσματική κατανομή κεφαλαίων σύμφωνα με τις απαιτήσεις του Basel Capital Accord.

Ακόμα ένα παράδειγμα είναι και η μελέτη των Asmar et al. (2024), που εστιάζει στον λειτουργικό κίνδυνο στις ψηφιακές τράπεζες, προτείνοντας ένα πλαίσιο ενσωμάτωσης αλγορίθμων μηχανικής

³ Σημείωση: Ο πίνακας αποτυπώνει συχνότητα χρήσης και όχι απόδοση των μεθόδων. Όταν ένα άρθρο εφαρμόζει περισσότερες από μία μεθόδους, μετρείται μία φορά για κάθε μέθοδο (μοναδικό αναγνωριστικό: DOI ή τίτλος).


μάθησης όπως SVM, RNN, HMM, LOF για την ανίχνευση και πρόληψη κυβερνοαπειλών επιθέσεων. Το προτεινόμενο μοντέλο ενισχύει σημαντικά την κυβερνοασφάλεια, μειώνοντας τους κινδύνους παραβίασης δεδομένων και βελτιώνοντας την προστασία των τραπεζικών συναλλαγών.

Τέλος, η μελέτη των Pérez et al. (2024), πρότεινε ένα υβριδικό μοντέλο, που συνδυάζει νευρωνικά δίκτυα για την βέλτιστη πρόβλεψη μεταβλητότητας σε παράγοντες κίνδυνου αγοράς όπως μετοχές (Santander), δείκτες (IBEX 35), συναλλαγματικές ισοτιμίες και το iTraxx Crossover Index. Το μοντέλο απέδωσε βελτιωμένη εκτίμηση του κινδύνου σε περιόδους κρίσης και σταθερότητας σε σύγκριση με παραδοσιακά στατιστικά μοντέλα. Από την άλλη, η μελέτη των Larras et al. (2021), αξιοποίησε γενετικούς αλγορίθμους σε συνδυασμό με εμπειρική γνώση για την επιλογή χαρακτηριστικών, με εφαρμογή στην αξιολόγηση πιστωτικού κινδύνου, επιτυγχάνοντας βελτιστοποίηση της απόδοσης ταξινόμησης μέσω πιο ενημερωμένων και στοχευμένων μεταβλητών.

4.6 Αξιολόγηση Μεθόδων Ευφυούς Υπολογιστικής

4.6.1 Τα πιο χρησιμοποιημένα σύνολα δεδομένων

Στο Σχήμα 4.7 παρουσιάζονται τα δέκα πιο συχνά χρησιμοποιούμενα σύνολα δεδομένων στην βιβλιογραφία. Το Bank Loan Dataset καταλαμβάνει την πρώτη θέση με 18 εμφανίσεις, γεγονός που υποδεικνύει τη μεγάλη σημασία του στην ανάπτυξη και αξιολόγηση μοντέλων πρόβλεψης κινδύνου. Στη δεύτερη και τρίτη θέση ακολουθούν τα Stock Indices με 12 εμφανίσεις και το S&P500 με 11 εμφανίσεις, ενώ το German Credit Dataset έπεται με 10 εμφανίσεις. Παράλληλα, τα datasets όπως τα Real-world Financial Dataset, Australian Credit και Technical Indicators παρουσιάζουν μικρότερη αλλά αξιοσημείωτη συχνότητα χρήσης (6 έως 8 εμφανίσεις). Τέλος, τα Financial Time Series, Taiwan Default Dataset και Szfi εμφανίζονται στις χαμηλότερες θέσεις της κατάταξης, γεγονός που υποδηλώνει ότι χρησιμοποιούνται πιο στοχευμένα και σε εξειδικευμένες μελέτες.



Σχήμα 4.7: Τα δέκα πιο δημοφιλή σύνολα δεδομένων

Για παράδειγμα, το German Credit Dataset αξιολογήθηκε από τους Lessmann et al. (2015), όπου συγκρίθηκαν σύγχρονοι μέθοδοι ταξινόμησης στον τομέα της πιστοληπτικής αξιολόγησης. Ομοίως το ίδιο Dataset αξιοποιήθηκε από τον Harris (2015), όπου εφαρμόστηκε η νεότερη μέθοδος Clustered SVM για τη βελτίωση της πιστοληπτικής αξιολόγησης με υπολογιστικά αποδοτικότερο τρόπο. Από την άλλη, το Mortgage Loan Dataset με πάνω από 120 εκατομμύρια περιπτώσεις δανείων αξιοποιήθηκε από τους Sadhwani et al. (2021), όπου αναπτύχθηκε ένα μοντέλο βαθιάς μάθησης μοντέλο για την πρόβλεψη κινδύνων όπως καθυστερήσεις, αποπληρωμές και εκποιήσεις.

Επίσης, το Financial Time Series/Stock Indices dataset αξιοποιήθηκε από τους Seyfi et al. (2021), όπου παρουσιάστηκε μια γρήγορη και ακριβής μέθοδος υπολογισμού VaR και ES με βάση Gaussian Mixture Models. Με παρόμοιο σύνολο δεδομένων από τους Niu et al. (2020), παρουσιάστηκε ένα πλαίσιο, με δύο στάδια επιλογής χαρακτηριστικών, ενσωματωμένο σε μοντέλο βαθιάς μάθησης για ακριβή πρόβλεψη πολυδιάστατων χρονοσειρών.

Τέλος, το Credit Card Transaction Dataset αξιοποιήθηκε από τους Fanai et al. (2023), όπου εφαρμόζεται ένα διεργαστικό πλαίσιο, που συνδυάζει representation learning μέσω autoencoder με supervised deep classifiers για πιο αποτελεσματική ανίχνευση απάτης. Η συγκεκριμένη κατανομή δείχνει ότι η πλειονότητα των ερευνών βασίζεται σε δημόσια διαθέσιμα και ευρέως αναγνωρισμένα datasets, γεγονός που επιτρέπει την σύγκριση μεθόδων και αποτελεσμάτων μεταξύ διαφορετικών μελετών, ενώ ταυτόχρονα καταδεικνύει τις κυρίαρχες πηγές δεδομένων στον τομέα.

4.6.2: Μετρικές Αξιολόγησης Μοντέλων στη Διαχείριση Χρηματοοικονομικών Κινδύνων

Στη βιβλιογραφία αξιοποιούνται ποικίλες μετρικές αξιολόγησης για την αποτίμηση της απόδοσης των μοντέλων, ανάλογα με το είδος του προβλήματος. Η Accuracy⁴ μετρά το ποσοστό των σωστών προβλέψεων στο σύνολο των παρατηρήσεων και χρησιμοποιείται ευρέως σε προβλήματα ταξινόμησης. Η Precision⁴ υπολογίζει το ποσοστό των σωστών θετικών προβλέψεων μεταξύ όλων των προβλέψεων που ταξινομήθηκαν ως θετικές, υποδεικνύοντας την αξιοπιστία του μοντέλου, όταν εντοπίζει θετικές περιπτώσεις. Συμπληρωματικά, η Recall⁴ (ευαισθησία) μετρά το ποσοστό των πραγματικών θετικών περιπτώσεων που αναγνωρίζονται σωστά, δίνοντας έμφαση στην ικανότητα του μοντέλου να εντοπίζει όλες τις θετικές κατηγορίες. Το F1-score, ως αρμονικός μέσος των Precision και Recall, είναι ιδιαίτερα χρήσιμο όταν υπάρχει ανισορροπία μεταξύ κλάσεων. Η AUC⁴ (Area Under the Curve) αξιολογεί την ικανότητα του μοντέλου να διακρίνει σωστά μεταξύ θετικών και αρνητικών περιπτώσεων.

Η Specificity εστιάζει στο ποσοστό των αρνητικών περιπτώσεων που ταξινομούνται σωστά, συμπληρώνοντας την ερμηνεία του Recall. Για προβλήματα πρόβλεψης συνεχών μεταβλητών, οι μετρικές RMSE (Root Mean Squared Error), MAE (Mean Absolute Error) και MAPE (Mean Absolute Percentage Error) χρησιμοποιούνται ευρέως, καθώς μετρούν την απόκλιση των προβλέψεων από τις πραγματικές τιμές, με χαμηλότερες τιμές να υποδηλώνουν καλύτερη απόδοση (Fanta et al., 2024). Το Sharpe Ratio αποτελεί εξειδικευμένη μετρική για χρηματοοικονομικά μοντέλα, καθώς μετρά την απόδοση μιας επένδυσης σε σχέση με τον κίνδυνο, παρέχοντας ένδειξη για την αποδοτικότητα των χαρτοφυλακίων (Sharpe et al., 1994).

Στον Πίνακα 4.3 παρουσιάζονται οι δέκα συχνότερα μετρικές αξιολόγησης στην βιβλιογραφία. Η Accuracy αποτελεί την κυρίαρχη μετρική, εμφανιζόμενη σε 27 άρθρα με ποσοστό 5,9% του συνόλου, γεγονός που επιβεβαιώνει τη σημασία της στην αξιολόγηση της συνολικής απόδοσης των μοντέλων. Η μετρική RMSE ακολουθεί με 17 εμφανίσεις 3,7% του συνόλου, χρησιμοποιούμενη κυρίως για την εκτίμηση σφαλμάτων πρόβλεψης σε προβλήματα παλινδρόμησης. Οι Precision και Recall παρουσιάζονται με ίση συχνότητα με 12 εμφανίσεις η καθεμία και 2,6% του συνόλου, ενώ η μετρική AUC εμφανίζεται 9 εμφανίσεις του 2% του συνόλου.

Αξιοσημείωτη είναι επίσης η χρήση της MAPE με 8 εμφανίσεις και 1,8% του συνόλου και του Sharpe Ratio 8 εμφανίσεις. Επιπλέον, οι μετρικές F1-score με 7 εμφανίσεις και MAE με 7 εμφανίσεις, εμφανίζονται αρκετά συχνά, ειδικά σε μοντέλα ταξινόμησης και παλινδρόμησης αντίστοιχα. Τέλος, η Specificity καταγράφει 5 εμφανίσεις. Η συγκεκριμένη κατανομή αναδεικνύει ότι οι ερευνητές επιλέγουν μετρικές ανάλογα με το πρόβλημα που μελετούν, ενώ η Accuracy παραμένει η πιο

⁴ <https://developers.google.com/machine-learning/crash-course/classification/roc-and-auc>

δημοφιλής επιλογή, ακολουθούμενη από σφάλματα πρόβλεψης RMSE, MAPE, MAE και ισορροπημένες μετρικές ταξινόμησης F1-score, AUC, Precision, Recall.

Πίνακας 4.3: Κατανομή των δέκα συχνότερα χρησιμοποιούμενων μετρικών αξιολόγησης στα άρθρα της βιβλιογραφίας.

<i>Metrics</i>	<i># Εμφανισεις</i>	<i>% Συνολου</i>
Accuracy	27	5.9%
RMSE	17	3.7%
Precision	12	2.6%
Recall	12	2.6%
AUC	9	2%
MAPE	8	1.8%
Sharpe Ratio	8	1.8%
F1-score	7	1.5%
MAE	7	1.5%
Specificity	5	1.1%

Σύμφωνα με τη βιβλιογραφία της ανάλυσης, οι Lessmann et al. (2015), έκαναν συγκριτική αξιολόγηση πολλών σύγχρονων ταξινομητικών αλγορίθμων σε datasets πιστωτικού κινδύνου. Η μελέτη ανέδειξε ότι προηγμένα σύνολα μεθόδων, όπως Random Forest και Gradient Boosting, υπερέχουν σε μετρικές όπως Accuracy και AUC σε σχέση με παραδοσιακές τεχνικές, προσφέροντας πιο αξιόπιστη πρόβλεψη πιστοληπτικής ικανότητας σε διαφορετικά περιβάλλοντα.

Επιπλέον, οι Shah et al. (2022), παρουσιάζουν μια εκτενή ανασκόπηση υβριδικών μοντέλων (ARIMA + LSTM, CNN + LSTM, Bi-LSTM, CNN-BiLSTM), που χρησιμοποιούνται στην πρόβλεψη τιμών μετοχών. Η ανάλυση επικεντρώνεται στη σύγκριση των μοντέλων βάσει μετρικών όπως RMSE, MAE και MAPE, με τα υβριδικά μοντέλα να αποδεικνύονται πιο ακριβή και ικανά στην αποτύπωση χρόνιων και μη-γραμμικών μοτίβων στις χρηματοοικονομικές χρονοσειρές.

Παράλληλα, στη μελέτη των Chang et al. (2024), χρησιμοποιήθηκαν δεδομένα από το CRM και τις συναλλαγές της Bank A στη Γερμανία για την πρόβλεψη ευκαιριών cross-selling σε πελάτες πράσινης χρηματοδότησης. Εφαρμόστηκαν διάφοροι αλγόριθμοι μηχανικής μάθησης, όπως τυχαία δάση (Random Forest – RF), νευρωνικά δίκτυα (Artificial Neural Networks – ANN), βαθιά νευρωνικά δίκτυα (Deep Neural Networks – DNN), μηχανές διανυσμάτων υποστήριξης (Support Vector Machines – SVM), λογιστική παλινδρόμηση (Logistic Regression – LR) και αυτοκωδικοποιητές (Autoencoders – AE). Τα αποτελέσματα έδειξαν ότι ο Random Forest παρουσίασε την υψηλότερη απόδοση με Accuracy = 96,6%, F1-score = 95,6%, ROC-AUC = 97%, ενώ σημαντικοί παράγοντες επιτυχίας cross-selling

αναδείχθηκαν ο όγκος συναλλαγών, η ποικιλία προϊόντων και το επιχειρηματικό προφίλ των πελατών. Η μελέτη αναδεικνύει τη σημασία της υιοθέτησης προηγμένων τεχνικών data analytics στη διαχείριση πελατειακών σχέσεων και την ενίσχυση της πράσινης χρηματοδότησης.

4.7 Ερευνητικά κενά της βιβλιομετρικής ανασκόπησης

Η συστηματική ανάλυση της βιβλιογραφίας ανέδειξε ορισμένα σημαντικά ερευνητικά κενά, τα οποία προσφέρουν ευκαιρίες για περαιτέρω μελέτη στο πεδίο της εφαρμογής ευφύων υπολογιστικών μεθόδων στη διαχείριση χρηματοοικονομικών κινδύνων. Κάποια από τα κενά αυτά αναφέρονται παρακάτω:

- i. Διαπιστώνεται περιορισμένη χρήση υβριδικών μοντέλων που συνδυάζουν διαφορετικές μεθόδους, όπως ARIMA + LSTM ή CNN + LSTM, παρότι έχει αποδειχθεί ότι τέτοιες προσεγγίσεις επιτυγχάνουν υψηλότερη ακρίβεια σε προβλέψεις χρηματοοικονομικών δεικτών.
- ii. Η πλειονότητα των ερευνών επικεντρώνεται στον πιστωτικό κίνδυνο, ενώ οι τομείς του κινδύνου ρευστότητας και του συστηματικού κινδύνου παραμένουν λιγότερο συμμετέχοντες, γεγονός που δημιουργεί πεδίο για περαιτέρω διερεύνηση.
- iii. Καταγράφεται ανεπαρκής αξιοποίηση πραγματικών χρηματοοικονομικών δεδομένων, καθώς οι περισσότερες μελέτες βασίζονται σε δημόσια διαθέσιμα σύνολα δεδομένων, όπως German Credit Dataset περιορίζοντας τη γενίκευση των αποτελεσμάτων.
- iv. Σημαντικό κενό εντοπίζεται επίσης στην ανάπτυξη μεθόδων Explainable AI (XAI), οι οποίες θα βελτιώσουν τη διαφάνεια και την ερμηνευσιμότητα των προβλέψεων, καθιστώντας τα αποτελέσματα πιο αξιόπιστα και εφαρμόσιμα σε πραγματικά τραπεζικά περιβάλλοντα.
- v. Οι μελέτες δίνουν υπερβολική έμφαση στη μετρική Accuracy, ενώ μετρικές όπως το F1-score, το AUC, το Sharpe Ratio και η Specificity χρησιμοποιούνται ελάχιστα, περιορίζοντας έτσι την πληρότητα της αξιολόγησης των μοντέλων.

Τα παραπάνω κενά αναδεικνύουν την ανάγκη για πιο ολοκληρωμένες, υβριδικές και ερμηνεύσιμες προσεγγίσεις, με έμφαση στη χρήση πραγματικών δεδομένων και την ανάπτυξη μεθοδολογιών που θα ανταποκρίνονται καλύτερα στις προκλήσεις της σύγχρονης χρηματοοικονομικής διαχείρισης κινδύνου.

Κεφάλαιο 5: Συμπεράσματα και Μελλοντική Έρευνα

Η παρούσα διπλωματική εργασία είχε ως στόχο την συστηματική ανασκόπηση και βιβλιομετρική ανάλυση των εφαρμογών ευφύων υπολογιστικών μεθόδων στην διαχείριση χρηματοοικονομικών κινδύνων. Μέσω της ανάλυσης 84 επιστημονικών άρθρων από διεθνείς βάσεις δεδομένων (Scopus, ScienceDirect), διερευνήθηκαν: οι κυρίαρχες μέθοδοι CI, οι κατηγορίες χρηματοοικονομικών κινδύνων, οι μετρικές αξιολόγησης, οι πηγές δεδομένων, τα ερευνητικά δίκτυα και οι συνεργασίες, καθώς και τα κενά που παραμένουν στη διεθνή βιβλιογραφία. Η εργασία κατέληξε σε σημαντικά ποσοτικά και ποιοτικά συμπεράσματα, ενώ παράλληλα εντόπισε προοπτικές για μελλοντική έρευνα.

5.1 Κύρια Συμπεράσματα

Η ανάλυση των δεδομένων ανέδειξε πολλαπλά ευρήματα σχετικά με τις τάσεις και τις εφαρμογές των μεθόδων CI στην διαχείριση χρηματοοικονομικών κινδύνων:

- Παρατηρείται σημαντική αύξηση των δημοσιεύσεων την τελευταία πενταετία, με κορύφωση μετά το 2018, γεγονός που καταδεικνύει την αυξανόμενη σπουδαιότητα των μεθόδων CI.
- Η κυρίαρχη μέθοδος CI είναι τα ANN (η πιο δημοφιλής μέθοδος με 45 άρθρα και περίπου 11% του συνόλου), και ακολουθούν τα SVM και RF καταγράφοντας αυξανόμενη χρήση. Σημαντικό ποσοστό μελετών εφαρμόζει υβριδικά μοντέλα, συνδυάζοντας μεθόδων CI για τη βελτιστοποίηση των αποτελεσμάτων.
- Οι συχνότερες κατηγορίες χρηματοοικονομικών κινδύνων είναι ο πιστωτικός κίνδυνος που καταλαμβάνει το 49% των άρθρων, ενώ ακολουθούν ο κίνδυνος αγοράς, ο λειτουργικός κίνδυνος και ο κίνδυνος ρευστότητας.
- Οι μετρικές αξιολόγησης: Η Accuracy αποτελεί τη συχνότερα χρησιμοποιούμενη μετρική, ακολουθούμενη από RMSE, Precision, Recall, AUC και F1-score. Η επιλογή μετρικών διαφέρει ανάλογα με τον τύπο προβλήματος (ταξινόμηση, παλινδρόμηση, πρόβλεψη κινδύνου).
- Η πλειονότητα των μελετών χρησιμοποιεί δημόσια σ (UCI, Kaggle, Yahoo Finance). Παρατηρείται, ωστόσο, έλλειψη πρόσβασης σε πραγματικά τραπεζικά δεδομένα, γεγονός που περιορίζει τη γενίκευση των αποτελεσμάτων.
- Οι περισσότερες δημοσιεύσεις προέρχονται από Κίνα, ΗΠΑ, Ινδία και Ηνωμένο Βασίλειο. Η Ευρώπη παρουσιάζει αυξητική τάση, κυρίως μέσω πανεπιστημίων στη Γερμανία, Γαλλία και Ισπανία, ενώ οι διεθνείς συνεργασίες συμβάλλουν σημαντικά στην παραγωγή υψηλής ποιότητας έρευνας.

Οι μέθοδοι CI έχουν ενισχύσει ουσιαστικά την μοντελοποίηση κινδύνων, βελτιώνοντας την ακρίβεια

πρόβλεψης και την ανίχνευση κρυφών προτύπων. Παράλληλα, η αυξημένη υπολογιστική ισχύς, η ανάπτυξη προηγμένων αλγορίθμων και η διαθεσιμότητα δεδομένων έχουν επιταχύνει τη μετάβαση σε πιο έξυπνα, αυτόνομα χρηματοοικονομικά συστήματα.

5.2 Προτάσεις Μελλοντικής Έρευνας

Η βιβλιογραφική ανάλυση ανέδειξε σημαντικά ερευνητικά κενά, τα οποία μπορούν να καθοδηγήσουν μελλοντικές μελέτες:

- Ανάπτυξη υβριδικών μοντέλων που συνδυάζουν ANN, SVM, LSTM, RF, FL και GA για υψηλότερη ακρίβεια και την προσαρμοστικότητα.
- Ενσωμάτωση τεχνικών Explainable AI (XAI) για καλύτερη ερμηνευσιμότητα των αποτελεσμάτων και βελτίωση της λήψης αποφάσεων.
- Χρήση αυτόματης βελτιστοποίησης υπέρ-παραμέτρων με Bayesian Optimization, Genetic Algorithms ή Grid Search.
- Πρόσβαση σε πραγματικά τραπεζικά και χρηματοοικονομικά δεδομένα, ώστε να αυξηθεί η αξιοπιστία των ευρημάτων.
- Συνδυασμός πολλαπλών πηγών δεδομένων, όπως ESG reports, social media, ειδησεογραφικές πηγές.
- Χρήση τεχνικών αντιμετώπισης ανισορροπίας δεδομένων (SMOTE, cost-sensitive learning).
- Πεδία εφαρμογών στην πράσινη χρηματοοικονομική και ανάλυση ESG κινδύνων με μεθόδους CI.
- Ανάπτυξη μοντέλων CI για την ανίχνευση οικονομικής απάτης και ασφάλεια συναλλαγών σε πραγματικό χρόνο.
- Ενίσχυση διεπιστημονικών συνεργασιών μεταξύ ειδικών στη χρηματοοικονομική, τη μηχανική μάθηση και την επιστήμη δεδομένων.
- Ανάπτυξη διεθνών ερευνητικών συνεργασιών για πολυκεντρικά και υψηλής αξιοπιστίας αποτελέσματα.
- Δημιουργία ενιαίων πλαισίων αξιολόγησης για τη σύγκριση διαφορετικών μεθόδων CI.

Η εργασία ανέδειξε ότι οι ευφυείς υπολογιστικές μέθοδοι αποτελούν βασικό εργαλείο για τη διαχείριση χρηματοοικονομικών κινδύνων, βελτιώνοντας σημαντικά την πρόβλεψη, την ταξινόμηση και την ανάλυση σύνθετων δεδομένων. Παράλληλα, η αναγνώριση των υπαρχόντων ερευνητικών κενών δημιουργεί νέες ευκαιρίες για την ανάπτυξη πιο ακριβών, ερμηνεύσιμων και προσαρμοστικών συστημάτων. Η μελλοντική έρευνα, εστιάζοντας σε υβριδικές μεθόδους, Explainable AI και σε πραγματικά datasets, θα συμβάλλει καθοριστικά στη βελτίωση της αξιοπιστίας και της εφαρμογής των CI τεχνικών στη σύγχρονη χρηματοοικονομική.

Βιβλιογραφία

- Alnuaimi, A.F.A.H., Albaldawi, T.H.K., 2024. An overview of machine learning classification techniques. BIO Web Conf. 97, 00133. <https://doi.org/10.1051/bioconf/20249700133>
- Syed, I., Lokhande, V., 2024. An overview of the supervised machine learning. Int. Res. J. Mod. Eng. Technol. Sci. 6, 6355–6360. <https://doi.org/10.56726/IRJMETS51366>
- Andersen, T.J., 2005. A strategic risk management framework for multinational enterprise. SSRN Electron. J. <https://doi.org/10.2139/ssrn.982066>
- Anwulika Ogechukwu Scott, Prisca Amajuoyi, Kudirat Bukola Adeusi, 2024. Effective credit risk mitigation strategies: Solutions for reducing exposure in financial institutions. Magna Sci. Adv. Res. Rev. 12, 198–211. <https://doi.org/10.30574/msarr.2024.11.1.0084>
- Aria, M., Cuccurullo, C., 2016. Bibliometrix: Comprehensive science mapping analysis. <https://doi.org/10.32614/CRAN.package.bibliometrix>
- Kashimpure, R.L., 2023. Research paper on basic of artificial neural networks (ANNs, also shortened to neural networks (NNs) or neural nets). Int. Res. J. Mod. Eng. Technol. Sci. 5, 873–878. <https://doi.org/10.56726/IRJMETS43049>
- Asmar, M., Tuqan, A., 2024. Integrating machine learning for sustaining cybersecurity in digital banks. Heliyon 10, e37571. <https://doi.org/10.1016/j.heliyon.2024.e37571>
- Barakat, A., Ashby, S., Fenn, P., Bryce, C., 2017. Operational risk and reputation in financial institutions: Does media tone make a difference? SSRN Electron. J. <https://doi.org/10.2139/ssrn.3042727>
- Barral, D., Perrin, J.-P., Dombre, E., Liegeois, A., 1999. An evolutionary simulated annealing algorithm for optimizing robotic task point ordering, in: Proceedings of the 1999 IEEE International Symposium on Assembly and Task Planning (ISATP'99) (Cat. No.99TH8470). Presented at the 1999 IEEE International Symposium on Assembly and Task Planning (ISATP'99), IEEE, Porto, Portugal, pp. 157–162. <https://doi.org/10.1109/ISATP.1999.782952>
- Berkhouch, M., Lakhnati, G., Righi, M., 2019. Spectral risk measures and uncertainty. <https://doi.org/10.2139/ssrn.3390654>
- Bidyuk, P.I., Kuznietsova, N.V., 2018. Probabilistic-statistical method for risk assessment of financial losses. Res. Bull. Natl. Tech. Univ. Ukr. Kyiv Politech. Inst. 0, 7–17. <https://doi.org/10.20535/1810-0546.2018.2.128989>

- Bisong, E., 2019. Principal Component Analysis (PCA), in: Building machine learning and deep learning models on Google Cloud Platform. Apress, Berkeley, CA, pp. 319–324. https://doi.org/10.1007/978-1-4842-4470-8_26
- Bogojevic Arsic, V., 2021. Challenges of financial risk management: AI applications. *Manag. Sustain. Bus. Manag. Solut. Emerg. Econ.* <https://doi.org/10.7595/management.fon.2021.0015>
- Bramer, M., 2013. Avoiding overfitting of decision trees, in: Principles of Data Mining, Undergraduate Topics in Computer Science. Springer London, London, pp. 121–136. https://doi.org/10.1007/978-1-4471-4884-5_9
- Brenes, R.F., Johannssen, A., Chukhrova, N., 2022. An intelligent bankruptcy prediction model using a multilayer perceptron. *Intell. Syst. Appl.* 16, 200136. <https://doi.org/10.1016/j.iswa.2022.200136>
- Brunnermeier, M.K., Pedersen, L.H., 2009. Market liquidity and funding liquidity. *Rev. Financ. Stud.* 22, 2201–2238. <https://doi.org/10.1093/rfs/hhn098>
- Buckley, J.J., Hayashi, Y., 1994. Fuzzy genetic algorithm and applications. *Fuzzy Sets Syst.* 61, 129–136. [https://doi.org/10.1016/0165-0114\(94\)90228-3](https://doi.org/10.1016/0165-0114(94)90228-3)
- Cai, T., 2018. Financial risk management based on quantile regression model. *J. Discrete Math. Sci. Cryptogr.* 21, 1391–1396. <https://doi.org/10.1080/09720529.2018.1527483>
- Chang, V., Hahm, N., Xu, Q.A., Vijayakumar, P., Liu, L., 2024. Towards data and analytics driven B2B-banking for green finance: A cross-selling use case study. *Technol. Forecast. Soc. Change* 206, 123542. <https://doi.org/10.1016/j.techfore.2024.123542>
- Chen, Z., Sakouba, I., 2021. Impact of the number of bonds on bond portfolio exposure to interest rate risk. *Int. J. Finance Econ.* 26, 4777–4797. <https://doi.org/10.1002/ijfe.2040>
- Chitta, S., Soni, H., 2023. The impact of financial risk management on firm performance: A study in financial management practices. *Rev. Gest. E Secr. Manag. Adm. Prof. Rev.* 14, 18095–18110. <https://doi.org/10.7769/gesec.v14i10.2736>
- Choudhry, M., Ali, A., Baig, S., Croke, J., Hussain, J., Liu, Z., Pereira, R., Samy, S., SchläFer, T., Sempere-Roldan, D., Uhrig-Homburg, M., 2010. Structured credit products: Credit derivatives and synthetic securitisation second edition, 1st ed. Wiley. <https://doi.org/10.1002/9781118390504>

- Clifton, J., Laber, E., 2020. Q-Learning: Theory and applications. *Annu. Rev. Stat. Its Appl.* 7, 279–301.
<https://doi.org/10.1146/annurev-statistics-031219-041220>
- Climent, F., Momparler, A., Carmona, P., 2019. Anticipating bank distress in the Eurozone: An extreme gradient boosting approach. *J. Bus. Res.* 101, 885–896.
<https://doi.org/10.1016/j.jbusres.2018.11.015>
- Colbert, J.L., 1991. Understanding the relationship between business risk and Inherent risk. *Manag. Audit. J.* 6. <https://doi.org/10.1108/02686909110006543>
- Damodaran, A., 2015. Country risk: Determinants, measures and implications - The 2015 Edition. SSRN Electron. J. <https://doi.org/10.2139/ssrn.2630871>
- Darapaneni, N., Basu, A., Savla, S., Gururajan, R., Saquib, N., Singhavi, S., Kale, A., Bid, P., Paduri, A.R., 2020. Automated portfolio rebalancing using Q-learning, in: 2020 11th IEEE annual Ubiquitous Computing, Electronics & Mobile Communication Conference (UEMCON). Presented at the 2020 11th IEEE Annual Ubiquitous Computing, Electronics & Mobile Communication Conference (UEMCON), IEEE, New York, NY, USA, pp. 0596–0602.
<https://doi.org/10.1109/UEMCON51285.2020.9298035>
- Davydov, D., Vähämaa, S., Yasar, S., 2020. Bank liquidity creation and systemic risk. SSRN Electron. J. <https://doi.org/10.2139/ssrn.3560800>
- Li, Y., 2017. Deep reinforcement learning: An overview. arXiv: 1701.07274.
<https://doi.org/10.48550/arXiv.1701.07274>
- Delahaye, D., Chaimatanan, S., Mongeau, M., 2019. Simulated annealing: From basics to applications, in: Gendreau, M., Potvin, J.-Y. (Eds.), *Handbook of Metaheuristics*, International Series in Operations Research & Management Science. Springer International Publishing, Cham, pp. 1–35. https://doi.org/10.1007/978-3-319-91086-4_1
- Derviş, H., 2020. Bibliometric analysis using bibliometrix an R package. *J. Scientometr. Res.* 8, 156–160.
<https://doi.org/10.5530/jscires.8.3.32>
- Deutsch, H.-P., 2002. Fundamental risk factors of financial markets, in: *Derivatives and Internal Models*. Palgrave Macmillan UK, London, pp. 11–45. https://doi.org/10.1057/9780230502109_3
- Dorigo, M., Birattari, M., Blum, C., Christensen, A.L., Engelbrecht, A.P., Groß, R., Stützle, T. (Eds.), 2012. *Swarm intelligence, lecture notes in computer science*. Springer Berlin Heidelberg, Berlin, Heidelberg. <https://doi.org/10.1007/978-3-642-32650-9>

- Doumpos, M., Zopounidis, C., Gounopoulos, D., Platanakis, E., Zhang, W., 2023. Operational research and artificial intelligence methods in banking. *Eur. J. Oper. Res.* 306, 1–16. <https://doi.org/10.1016/j.ejor.2022.04.027>
- du Jardin, P., 2025. A quantification approach of changes in firms' financial situation using neural networks for predicting bankruptcy. *J. Forecast.* 44, 781–802. <https://doi.org/10.1002/for.3227>
- Duch, W., 2007. What is computational intelligence and where is it going?, in: Duch, W., Mańdziuk, J. (Eds.), *Challenges for Computational Intelligence*. Springer, Berlin, Heidelberg, pp. 1–13. https://doi.org/10.1007/978-3-540-71984-7_1
- Esquivel, S.C., Leiva, H.A., Gallardt, R.H., 1998. Selection mechanisms in evolutionary algorithms. *Fundam. Informaticae* 35, 17–33. <https://doi.org/10.3233/FI-1998-35123402>
- Fanai, H., Abbasimehr, H., 2023. A novel combined approach based on deep autoencoder and deep classifiers for credit card fraud detection. *Expert Syst. Appl.* 217, 119562. <https://doi.org/10.1016/j.eswa.2023.119562>
- Fanta, S., Amir, M., Riau, D.P., 2024. The role of protocols in facilitating the activities of regional heads secretariat at the central buton district. *Int. J. Sci. Res. Sci. Eng. Technol.* 11, 04–09. <https://doi.org/10.32628/IJSRSET2411135>
- Fu Kai, Xu Wenhua, 1997. Training neural network with genetic algorithms for forecasting the stock price index, in: 1997 IEEE International Conference on Intelligent Processing Systems (Cat. No.97TH8335). Presented at the 1997 IEEE international conference on intelligent processing systems, IEEE, Beijing, China, pp. 401–403. <https://doi.org/10.1109/ICIPS.1997.672809>
- Russo, M., Jain, L.C., 2000. *Fuzzy learning and applications*. CRC Press. <https://doi.org/10.1201/9780429177453>
- Gallagher, M.R., 2000. Multi-layer perceptron error surfaces: Visualization, structure and modelling (PhD Thesis). The University of Queensland. <https://doi.org/10.14264/157842>
- Gargantilla Becerra, A., Lahoz-Beltra, R., 2020. A microbial screening in silico method for the fitness step evaluation in evolutionary algorithms. *Appl. Sci.* 10, 3936. <https://doi.org/10.3390/app10113936>
- Rhinehart, R.R., 2018. Genetic algorithms and evolutionary computation. In: *Engineering Optimization: Applications, Methods, and Analysis*. Wiley–ASME Press, 243–250. https://doi.org/10.1115/1.861OPT_ch14

- Girling, P., 2013. Operational risk management: A complete guide to a successful operational risk framework, 1st ed. Wiley. <https://doi.org/10.1002/9781118755754>
- Giudici, P., Centurelli, M., Turchetta, S., 2024. Artificial intelligence risk measurement. *Expert Syst. Appl.* 235, 121220. <https://doi.org/10.1016/j.eswa.2023.121220>
- Hanani, T., 2022. The development of types and measurement of banking risk: A literature review. *Int. J. Bus. Humanit. Educ. Soc. Sci. IJBHES* 4, 78–82. <https://doi.org/10.46923/ijbhes.v4i2.194>
- Heß, V.L., Damásio, B., 2025. Machine learning in banking risk management: Mapping a decade of evolution. *Int. J. Inf. Manag. Data Insights* 5, 100324. <https://doi.org/10.1016/j.jjime.2025.100324>
- Holton, G.A., 2004. Defining risk. *Financ. Anal. J.* 60, 19–25. <https://doi.org/10.2469/faj.v60.n6.2669>
- Hutson, E., Laing, E., 2012. Foreign exchange exposure and multinationality. *SSRN Electron. J.* <https://doi.org/10.2139/ssrn.2187670>
- Sadler, J., 2017. Introduction to network analysis with R. Available at: <https://www.jessesadler.com/post/network-analysis-with-r/>
- Iranzo, S., 2008. Delving into country risk. *SSRN Electron. J.* <https://doi.org/10.2139/ssrn.1120723>
- Jang, J.-S.R., 1993. ANFIS: Adaptive-network-based fuzzy inference system. *IEEE Trans. Syst. Man Cybern.* 23, 665–685. <https://doi.org/10.1109/21.256541>
- Jednak, D., Jednak, J., 2013. Operational risk management in financial institutions. *Manag. - J. Theory Pract. Manag.* 18, 71–80. <https://doi.org/10.7595/management.fon.2013.0004>
- Jobst, N.J., Zenios, S.A., 2005. On the simulation of portfolios of interest rate and credit risk sensitive securities. *Eur. J. Oper. Res.* 161, 298–324. <https://doi.org/10.1016/j.ejor.2003.08.044>
- Kadhim, A.A., Kadhim, A.J., Kareem, A.D., 2023. Credit risks and capital risks and their impact on banking liquidity, Applied Research in al-Mansour Investment Bank and the Iraqi Investment Bank. *J. Corp. Finance Manag. Bank. Syst.* 29–38. <https://doi.org/10.55529/jcfmbs.33.29.38>
- Kaya, İ., Kahraman, C., Çebi, S., 2012. Computational intelligence techniques for risk management in decision making, in: Lu, J., Jain, L.C., Zhang, G. (Eds.), *Handbook on Decision Making, Intelligent Systems Reference Library*. Springer Berlin Heidelberg, Berlin, Heidelberg, pp. 9–38. https://doi.org/10.1007/978-3-642-25755-1_2

- Kumar, K., Thakur, G.S.M., 2012. Advanced applications of neural networks and artificial intelligence: A review. *Int. J. Inf. Technol. Comput. Sci.* 4, 57–68. <https://doi.org/10.5815/ijitcs.2012.06.08>
- Kumar, S., Rao, A., Dhochak, M., 2025. Hybrid ML models for volatility prediction in financial risk management. *Int. Rev. Econ. Finance* 98, 103915. <https://doi.org/10.1016/j.iref.2025.103915>
- Laha, A., 2007. Building contextual classifiers by integrating fuzzy rule based classification technique and k-nn method for credit scoring. *Adv. Eng. Inform.* 21, 281–291. <https://doi.org/10.1016/j.aei.2006.12.004>
- Lessmann, S., Baesens, B., Seow, H.-V., Thomas, L.C., 2015. Benchmarking state-of-the-art classification algorithms for credit scoring: An update of research. *Eur. J. Oper. Res.* 247, 124–136. <https://doi.org/10.1016/j.ejor.2015.05.030>
- Page, M.J., McKenzie, J.E., Bossuyt, P.M., Boutron, I., Hoffmann, T.C., Mulrow, C.D., Shamseer, L., Tetzlaff, J.M., Akl, E.A., Brennan, S.E., Chou, R., Glanville, J., Grimshaw, J.M., Hróbjartsson, A., Lalu, M.M., Li, T., Loder, E.W., Mayo-Wilson, E., McDonald, S., McGuinness, L.A., Stewart, L.A., Thomas, J., Tricco, A.C., Welch, V.A., Whiting, P. and Moher, D., 2021. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *Systematic Reviews*, 10(1), p.89. <https://doi.org/10.1186/s13643-021-01626-4>
- Lim, W.M., Kumar, S., 2024. Guidelines for interpreting the results of bibliometric analysis: A sensemaking approach. *Glob. Bus. Organ. Excell.* 43, 17–26. <https://doi.org/10.1002/joe.22229>
- Lin, T.Y., Liu, Q., 1994. Rough approximate operators: Axiomatic rough set theory, in: Ziarko, W.P. (Ed.), *Rough Sets, Fuzzy Sets and Knowledge Discovery, Workshops in Computing*. Springer London, London, pp. 256–260. https://doi.org/10.1007/978-1-4471-3238-7_31
- Manela, A., Moreira, A., 2017. News implied volatility and disaster concerns. *J. Financ. Econ.* 123, 137–162. <https://doi.org/10.1016/j.jfineco.2016.01.032>
- Mathur, I., Knowles, L.L., 1985. Foreign exchange risk management strategies of U.S. multinationals. *Scand. J. Manag. Stud.* 2, 41–59. [https://doi.org/10.1016/0281-7527\(85\)90013-1](https://doi.org/10.1016/0281-7527(85)90013-1)
- Chance, D.M., 2019. Measuring financial market risk. In: *Financial Risk Management: An End User Perspective*. World Scientific, 303–372. https://doi.org/10.1142/9789811201844_0007
- Metaxiotis, K., Psarras, J.E., Samouilidis, J.E., 2004. New applications of fuzzy logic in decision support systems. *Int. J. Manag. Decis. Mak.* 5, 47. <https://doi.org/10.1504/IJMDM.2004.005008>

- Mourlon-Druol, E., 2015. 'Trust is good, control is better': The 1974 Herstatt bank crisis and its implications for international regulatory reform. *Bus. Hist.* 57, 311–334. <https://doi.org/10.1080/00076791.2014.950956>
- Moussaoui, H., El Akkad, N., Benslimane, M., 2023. Reinforcement learning: A review. *Int. J. Comput. Digit. Syst.* 13, 1465–1483. <https://doi.org/10.12785/ijcds/1301118>
- Mu, H., Kondou, Y., Tonooka, Y., Zhou, W., Ning, Y., Sakamoto, K., 2004. Analyses on accuracy and sensitivity of grey energy model. *J. Jpn. Inst. Energy* 83, 908–915. <https://doi.org/10.3775/jie.83.908>
- Naeem, S., Ali, A., Anam, S., Ahmed, M.M., 2023. An unsupervised machine learning algorithms: Comprehensive review. *Int. J. Comput. Digit. Syst.* 13, 911–921. <https://doi.org/10.12785/ijcds/130172>
- Nanda, B.K., Das, G., 2013. Ant colony optimization. A computational intelligence technique. *Int. J. Comput. Commun. Technol.* 58–63. <https://doi.org/10.47893/IJCCT.2013.1169>
- Niu, T., Wang, J., Lu, H., Yang, W., Du, P., 2020. Developing a deep learning framework with two-stage feature selection for multivariate financial time series forecasting. *Expert Syst. Appl.* 148, 113237. <https://doi.org/10.1016/j.eswa.2020.113237>
- P, S., R, R., 2023. A review of convolutional neural networks, its variants and applications, in: 2023 International Conference on Intelligent Systems for Communication, IoT and Security (ICISCoIS). Presented at the 2023 International Conference on Intelligent Systems for Communication, IoT and Security (ICISCoIS), IEEE, Coimbatore, India, pp. 31–36. <https://doi.org/10.1109/ICISCoIS56541.2023.10100412>
- Pantridge, E.R., Spector, L., 2016. Evolution of layer based neural networks: Preliminary Report, in: Proceedings of the 2016 on Genetic and Evolutionary Computation Conference Companion. Presented at the GECCO '16: Genetic and Evolutionary Computation Conference, ACM, Denver Colorado USA, pp. 1015–1022. <https://doi.org/10.1145/2908961.2931664>
- Pawlak, Z., Grzymala-Busse, J., Slowinski, R., Ziarko, W., 1995. Rough sets. *Commun. ACM* 38, 88–95. <https://doi.org/10.1145/219717.219791>
- Altman, E.I., Resti, A., Sironi, A., 2003. Default recovery rates in credit risk modelling: A review of the literature and empirical evidence. *Econ. Notes* 33, 183–208. <https://doi.org/10.1111/j.0391-5026.2004.00129.x>

- Celestin, M., Vasuki, M., Sujatha, S., Kumar, A.D., 2025. Principal component analysis for simplifying multivariate financial data in portfolio risk analysis. *Brainae J. Bus. Sci. Technol.* **9**, 171–179. <https://doi.org/10.5281/zenodo.14880988>
- Pérez-Hernández, F., Arévalo-de-Pablos, A., Camacho-Miñano, M.-M., 2024. A hybrid model integrating artificial neural network with multiple GARCH-type models and EWMA for performing the optimal volatility forecasting of market risk factors. *Expert Syst. Appl.* **243**, 122896. <https://doi.org/10.1016/j.eswa.2023.122896>
- Pławiak, P., Abdar, M., Rajendra Acharya, U., 2019. Application of new deep genetic cascade ensemble of svm classifiers to predict the Australian credit scoring. *Appl. Soft Comput.* **84**, 105740. <https://doi.org/10.1016/j.asoc.2019.105740>
- Prema, K.V., Manish Agarwal, N., Murali Krishna, Agarwal, V., 2016. Stock market prediction using neuro-genetic model. *Indian J. Sci. Technol.* **8**. <https://doi.org/10.17485/ijst/2015/v8i35/71306>
- Pulsiri, N., Vatananan-Thesenvitz, R., 2018. Improving systematic literature review with automation and bibliometrics, in: 2018 Portland International Conference on Management of Engineering and Technology (PICMET). Presented at the 2018 Portland International Conference on Management of Engineering and Technology (PICMET), IEEE, Honolulu, HI, pp. 1–8. <https://doi.org/10.23919/PICMET.2018.8481746>
- Puppala, A., 2025. A comprehensive overview of machine learning models: Techniques, applications, and future directions. *Int. J. Multidiscip. Res.* **7**, 40603. <https://doi.org/10.36948/ijfmr.2025.v07i02.40603>
- Rada, R., Wimmer, H., 2017. Decision trees and financial variables: *Int. J. Decis. Support Syst. Technol.* **9**, 1–15. <https://doi.org/10.4018/IJDSST.2017010101>
- Rezaei, M., Nezamabadi-Pour, H., 2025. A taxonomy of literature reviews and experimental study of deepreinforcement learning in portfolio management. *Artif. Intell. Rev.* **58**, 94. <https://doi.org/10.1007/s10462-024-11066-w>
- Sadhwani, A., Giesecke, K., Sirignano, J., 2021. Deep learning for mortgage risk*. *J. Financ. Econom.* **19**, 313–368. <https://doi.org/10.1093/jjfinec/nbaa025>

- Sadollah, A., 2018. Introductory Chapter: Which membership function is appropriate in fuzzy system?, in: Sadollah, A. (Ed.), *Fuzzy Logic Based in Optimization Methods and Control Systems and Its Applications*. InTech. <https://doi.org/10.5772/intechopen.79552>
- Salehinejad, H., Sankar, S., Barfett, J., Colak, E., Valaee, S., 2018. Recent advances in recurrent neural networks. <https://doi.org/10.48550/arXiv.1801.01078>
- Samson, S., Reneke, J.A., Wiecek, M.M., 2009. A review of different perspectives on uncertainty and risk and an alternative modeling paradigm. *Reliab. Eng. Syst. Saf.* 94, 558–567. <https://doi.org/10.1016/j.ress.2008.06.004>
- Sapana Garud, 2025. Reinforcement learning for dynamic portfolio optimization in fintech. *J. Inf. Syst. Eng. Manag.* 10, 987–994. <https://doi.org/10.52783/jisem.v10i45s.9118>
- Seyfi, S.M.S., Sharifi, A., Arian, H., 2021. Portfolio value-at-risk and expected-shortfall using an efficient simulation approach based on gaussian mixture model. *Math. Comput. Simul.* 190, 1056–1079. <https://doi.org/10.1016/j.matcom.2021.05.029>
- Shah, J., Vaidya, D., Shah, M., 2022. A comprehensive review on multiple hybrid deep learning approaches for stock prediction. *Intell. Syst. Appl.* 16, 200111. <https://doi.org/10.1016/j.iswa.2022.200111>
- Sharma, Siddharth, Sharma, Simone, Athaiya, A., 2020. Activation functions in neural networks. *Int. J. Eng. Appl. Sci. Technol.* 04, 310–316. <https://doi.org/10.33564/IJEAST.2020.v04i12.054>
- Sharpe, W.F., 1994. The sharpe ratio. *J. Portf. Manag.* 21, 49–58. <https://doi.org/10.3905/jpm.1994.409501>
- Sheth, N., 2023. Future of artificial intelligence and machine learning systems in financial risk management and regulatory compliance. *Int. J. Softw. Hardw. Res. Eng.* 11. <https://doi.org/10.26821/IJSHRE.11.8.2023.110808>
- Staikouras, S.K., 2003. The interest rate risk exposure of financial intermediaries: A review of the theory and empirical evidence. *Financ. Mark. Inst. Instrum.* 12, 257–289. <https://doi.org/10.1111/1468-0416.t01-1-00002>
- Staples, M., Niazi, M., 2007. Experiences using systematic review guidelines. *J. Syst. Softw.* 80, 1425–1437. <https://doi.org/10.1016/j.jss.2006.09.046>

- Stapleton, J., Carter, C., Bredahl, L., 2020. Developing systematic search methods for the library literature: Methods and analysis. *J. Acad. Librariansh.* 46, 102190. <https://doi.org/10.1016/j.acalib.2020.102190>
- Thakur, A., 2021. Neuro-Fuzzy: Artificial neural networks & fuzzy logic. *Int. J. Res. Appl. Sci. Eng. Technol.* 9, 128–135. <https://doi.org/10.22214/ijraset.2021.37930>
- Thorat, M., Pandit, S., Balote, S., 2022. Artificial neural network: A brief study. *Asian J. Converg. Technol.* AJCT ISSN -2350-1146 8, 12–16. <https://doi.org/10.33130/AJCT.2022v08i03.003>
- Tsakonas, A., Dounias, G., 2002. Hybrid computational intelligence schemes in complex domains: An extended review, in: Vlahavas, I.P., Spyropoulos, C.D. (Eds.), *Methods and Applications of Artificial Intelligence*. Springer, Berlin, Heidelberg, pp. 494–511. https://doi.org/10.1007/3-540-46014-4_44
- Vanini, P., Rossi, S., Zvizdic, E., Domenig, T., 2023. Online payment fraud: From anomaly detection to risk management. *Financ. Innov.* 9, 66. <https://doi.org/10.1186/s40854-023-00470-w>
- Verma, P., Kumar, R., 2018. A literature survey on classification algorithms of machine learning. *Int. J. Comput. Appl.* 179, 47–50. <https://doi.org/10.5120/ijca2018917378>
- Wang, C., 2023. Practical significance of distinguishment between systematic/non-systematic risks. *BCP Bus. Manag.* 38, 935–941. <https://doi.org/10.54691/bcpbm.v38i.3799>
- Wang, S., Wang, Q., Lu, H., Zhang, D., Xing, Q., Wang, J., 2025. Learning about tail risk: Machine learning and combination with regularization in market risk management. *Omega* 133, 103249. <https://doi.org/10.1016/j.omega.2024.103249>
- Zaher, H., Kandil, A., Fahmy, R., 2014. Comparison of mamdani and sugeno fuzzy inference systems for prediction (with application to prices of fund in egypt). *Br. J. Math. Comput. Sci.* 4, 3014–3022. <https://doi.org/10.9734/BJMCS/2014/11644>
- Zelinka, I., Richter, H., 2010. Evolutionary algorithms for chaos researchers, in: Zelinka, I., Celikovsky, S., Richter, H., Chen, G. (Eds.), *Evolutionary Algorithms and Chaotic Systems*. Springer, Berlin, Heidelberg, pp. 37–88. https://doi.org/10.1007/978-3-642-10707-8_2
- Zhang, Y., Agarwal, P., Bhatnagar, V., Balochian, S., Yan, J., 2013. Swarm intelligence and its applications. *Sci. World J.* 2013, 528069. <https://doi.org/10.1155/2013/528069>

- Zupic, I., Cater, T., 2013. Bibliometric methods in management and organization: A review. Acad. Manag. Proc. 2013, 13426. <https://doi.org/10.5465/ambpp.2013.13426abstract>
- Aven, T., Renn, O., 2009. On risk defined as an event where the outcome is uncertain. J. Risk Res. 12, 1–11. <https://doi.org/10.1080/13669870802488883>
- Ruiz, I., Zeron, M., Market risk, 2022. , in: Machine learning for risk calculations. John Wiley & Sons, Ltd, pp. 241–274. <https://doi.org/10.1002/9781119791416.ch16>
- Chance, D.M., 2019. Measuring financial market risk, 2019b. , in: Financial Risk Management. WORLD SCIENTIFIC, pp. 303–372. https://doi.org/10.1142/9789811201844_0007
- Julong, D., 1989. Introduction to grey system theory. Measuring financial market risk, 2019. , in: Financial Risk Management. WORLD SCIENTIFIC, pp. 303–372. https://doi.org/10.1142/9789811201844_0007
- Datta, S., 2020. A review on convolutional neural networks, in: Bera, R., Pradhan, P.C., Liu, C.-M., Dhar, S., Sur, S.N. (Eds.), Advances in Communication, Devices and Networking. Springer, Singapore, pp. 445–452. https://doi.org/10.1007/978-981-15-4932-8_50