

ΣΧΟΛΗ ΚΟΙΝΩΝΙΚΩΝ ΕΠΙΣΤΗΜΩΝ
ΜΕΤΑΠΤΥΧΙΑΚΟ ΠΡΟΓΡΑΜΜΑ ΣΠΟΥΔΩΝ ΤΡΑΠΕΖΙΚΗ, ΛΟΓΙΣΤΙΚΗ ΚΑΙ
ΧΡΗΜΑΤΟΟΙΚΟΝΟΜΙΚΗ (ΤΛΧ)

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

**Συγκριτική Ανάλυση Μεθόδων Αριστοποίησης Χαρτοφυλακίου με
χρήση παραδοσιακών Μοντέλων και Μοντέλων Μηχανικής Μάθησης:
Εμπειρική Προσέγγιση με Κυλιόμενο Παράθυρο Πενταετίας 2020-2025**

ΑΝΤΩΝΟΠΟΥΛΟΣ ΚΩΝΣΤΑΝΤΙΝΟΣ (Α.Μ. 144378)

ΕΠΙΒΛΕΠΩΝ ΚΑΘΗΓΗΤΗΣ:
ΔΑΣΙΛΑΣ ΑΠΟΣΤΟΛΟΣ

ΑΘΗΝΑ
ΜΑΪΟΣ 2026

Η παρούσα εργασία αποτελεί πνευματική ιδιοκτησία του φοιτητή («συγγραφέας/δημιουργός») που την εκπόνησε. Στο πλαίσιο της πολιτικής ανοικτής πρόσβασης ο συγγραφέας/δημιουργός εκχωρεί στο ΕΑΠ, μη αποκλειστική άδεια χρήσης του δικαιώματος αναπαραγωγής, προσαρμογής, δημόσιου δανεισμού, παρουσίασης στο κοινό και ψηφιακής διάχυσής τους διεθνώς, σε ηλεκτρονική μορφή και σε οποιοδήποτε μέσο, για διδακτικούς και ερευνητικούς σκοπούς, άνευ ανταλλάγματος και για όλο το χρόνο διάρκειας των δικαιωμάτων πνευματικής ιδιοκτησίας. Η ανοικτή πρόσβαση στο πλήρες κείμενο για μελέτη και ανάγνωση δεν σημαίνει καθ' οιονδήποτε τρόπο παραχώρηση δικαιωμάτων διανοητικής ιδιοκτησίας του συγγραφέα/δημιουργού ούτε επιτρέπει την αναπαραγωγή, αναδημοσίευση, αντιγραφή, αποθήκευση, πώληση, εμπορική χρήση, μετάδοση, διανομή, έκδοση, εκτέλεση, «μεταφόρτωση» (downloading), «ανάρτηση» (uploading), μετάφραση, τροποποίηση με οποιονδήποτε τρόπο, τμηματικά ή περιληπτικά της εργασίας, χωρίς τη ρητή προηγούμενη έγγραφη συναίνεση του συγγραφέα/δημιουργού. Ο συγγραφέας/δημιουργός διατηρεί το σύνολο των ηθικών και περιουσιακών του δικαιωμάτων.

ΠΕΡΙΛΗΨΗ

Η παρούσα διπλωματική εργασία εξετάζει τη συγκριτική αποτελεσματικότητα παραδοσιακών μεθόδων αριστοποίησης χαρτοφυλακίου και μεθόδων μηχανικής μάθησης (ML), αξιοποιώντας πραγματικά χρηματοοικονομικά δεδομένα για την περίοδο 2020–2025. Σκοπός της μελέτης είναι να διερευνηθεί αν σύγχρονες τεχνικές μηχανικής μάθησης μπορούν να οδηγήσουν σε καλύτερη επενδυτική επίδοση σε σχέση με κλασικές προσεγγίσεις, όπως το ισοσταθμισμένο χαρτοφυλάκιο, το χαρτοφυλάκιο ελάχιστης διακύμανσης, το χαρτοφυλάκιο μέγιστου Sharpe ratio και το CAPM.

Η ανάλυση βασίζεται σε ημερήσιες προσαρμοσμένες τιμές κλεισίματος 24 επενδυτικών προϊόντων, τα οποία περιλαμβάνουν μετοχές, ETFs ομολόγων, ETFs ακινήτων, εμπορεύματα, διεθνείς μετοχικούς δείκτες και συναλλαγματικές ισοτιμίες. Η εμπειρική αξιολόγηση πραγματοποιείται με διαδικασία κυλιόμενου παραθύρου (rolling window), ώστε οι στρατηγικές να εκτιμώνται και να εφαρμόζονται με βάση μόνο την εκάστοτε διαθέσιμη ιστορική πληροφορία.

Στο πλαίσιο της μηχανικής μάθησης (ML) χρησιμοποιούνται μοντέλα ταξινόμησης, όπως Decision Tree, Random Forest, Support Vector Machine και XGBoost, με στόχο την πρόβλεψη της πιθανότητας θετικής επόμενης ημερήσιας απόδοσης. Οι προβλέψεις μετατρέπονται σε επενδυτικές αποφάσεις μέσω επιλογής των περιουσιακών στοιχείων με τις υψηλότερες προβλεπόμενες πιθανότητες. Η αξιολόγηση γίνεται με δείκτες όπως συνολική και ετησιοποιημένη απόδοση, μεταβλητότητα, Sharpe ratio, max drawdown, Sortino ratio και Calmar ratio.

Τα αποτελέσματα δείχνουν ότι οι μέθοδοι μηχανικής μάθησης μπορούν να προσφέρουν χρήσιμη πληροφόρηση, χωρίς όμως να εξασφαλίζουν πάντοτε ανώτερη επενδυτική επίδοση. Η εργασία καταλήγει ότι οι παραδοσιακές μέθοδοι παραμένουν ισχυρά και ερμηνεύσιμα εργαλεία, ενώ τα ML μοντέλα μπορούν να λειτουργήσουν συμπληρωματικά, υπό προσεκτική εφαρμογή και αυστηρή αξιολόγηση.

ABSTRACT

This postgraduate dissertation examines the comparative effectiveness of traditional portfolio optimization methods and machine learning (ML) methods, using real financial data for the period 2020–2025. The purpose of the study is to investigate whether modern machine learning techniques can lead to better investment performance compared with classical approaches, such as the equally weighted portfolio, the minimum variance portfolio, the maximum Sharpe ratio portfolio and the CAPM.

The analysis is based on daily adjusted closing prices of 24 investment products, including stocks, bond ETFs, real estate ETFs, commodities, international equity indices and foreign exchange rates. The empirical evaluation is carried out using a rolling window procedure, so that the strategies are estimated and applied based only on the historical information available at each point in time.

Within the machine learning framework, classification models are used, such as Decision Tree, Random Forest, Support Vector Machine and XGBoost, with the aim of predicting the probability of a positive next-day return. The predictions are converted into investment decisions by selecting the assets with the highest predicted probabilities. The evaluation is conducted using indicators such as total and annualized return, volatility, Sharpe ratio, max drawdown, Sortino ratio and Calmar ratio.

The results show that machine learning methods can provide useful information, without, however, always ensuring superior investment performance. The dissertation concludes that traditional methods remain robust and interpretable tools, while ML models can function complementarily, provided that they are applied carefully and evaluated rigorously.

ΠΙΝΑΚΑΣ ΠΕΡΙΕΧΟΜΕΝΩΝ

1	ΕΙΣΑΓΩΓΗ.....	5
1.1	Αντικείμενο και σκοπός της μελέτης.....	6
1.2	Ερευνητικά ερωτήματα και στόχοι.....	7
1.3	Δομή της διπλωματικής εργασίας.....	8
2	ΒΙΒΛΙΟΓΡΑΦΙΚΗ ΑΝΑΣΚΟΠΗΣΗ.....	10
2.1	Θεωρητικό υπόβαθρο της θεωρίας χαρτοφυλακίου	10
2.2	Το υπόδειγμα Markowitz και η θεωρία αποδοτικών χαρτοφυλακίων	11
2.3	Το Υπόδειγμα Αποτίμησης Περιουσιακών Στοιχείων (CAPM)	13
2.4	Εφαρμογές Μηχανικής Μάθησης στη βελτιστοποίηση χαρτοφυλακίου	14
2.5	Συγκριτικές εμπειρικές μελέτες.....	17
2.5.1	Case study: Optimal versus naive diversification	18
2.5.2	Case study: Empirical asset pricing via machine learning	18
2.5.3	Case study: Machine learning σε ευρωπαϊκές μετοχικές αγορές	19
3	ΔΕΔΟΜΕΝΑ ΚΑΙ ΜΕΘΟΔΟΛΟΓΙΑ	22
3.1	Εισαγωγή	22
3.2	Δεδομένα και περιγραφή δείγματος.....	23
3.3	Μεταβλητές, κατηγορίες περιουσιακών στοιχείων και δείκτες απόδοσης.....	26
3.4	Περιγραφή των μεθόδων	30
3.4.1	Παραδοσιακά Μοντέλα.....	30
3.4.2	Μοντέλα Μηχανικής Μάθησης.....	31
3.5	Διαδικασία rolling window και αξιολόγηση	33
3.6	Εργαλεία και λογισμικό	35
4	ΑΠΟΤΕΛΕΣΜΑΤΑ	38
4.1	Εισαγωγή	38
4.2	Υπολογισμός αποδόσεων και κινδύνου ανά μοντέλο	38
4.3	Συγκριτική ανάλυση αποτελεσμάτων	40
4.4	Ερμηνεία διαφορών μεταξύ παραδοσιακών και ML μεθόδων.....	44
4.5	Οπτικοποίηση αποτελεσμάτων και ανάλυση	46
4.5.1	Διάγραμμα 4.1.....	46

4.5.2	Διάγραμμα 4.2.....	46
4.5.3	Διάγραμμα 4.3.....	47
4.5.4	Διάγραμμα 4.4.....	48
4.6	Σύγκριση των ευρημάτων με προηγούμενες εμπειρικές μελέτες.....	50
5	ΣΥΜΠΕΡΑΣΜΑΤΑ ΚΑΙ ΠΡΟΤΑΣΕΙΣ	52
5.1	Συμπεράσματα	52
5.2	Περιορισμοί της ανάλυσης και ερμηνευτικές προφυλάξεις	54
5.3	Προτάσεις για μελλοντική έρευνα	56
	ΒΙΒΛΙΟΓΡΑΦΙΑ.....	58

ΚΑΤΑΛΟΓΟΣ ΠΙΝΑΚΩΝ

Πίνακας 2.1: Βασικές έννοιες θεωρίας χαρτοφυλακίου και χρήση τους στην εργασία	11
Πίνακας 2.2: Συγκριτική αποτύπωση παραδοσιακών και ML προσεγγίσεων	17
Πίνακας 2.3: Ενδεικτικά case studies από τη σχετική εμπειρική βιβλιογραφία.....	19
Πίνακας 3.1: Σύνολο επενδυτικών προϊόντων που αξιοποιήθηκαν	24
Πίνακας 3.2: Ενδεικτικά περιγραφικά στατιστικά για 5 αξιόγραφα	28
Πίνακας 3.3: Μέθοδοι και βασικές ρυθμίσεις της ανάλυσης	33
Πίνακας 3.4: Βασικές παράμετροι rolling-window αξιολόγησης.....	35
Πίνακας 3.5: Εργαλεία και βιβλιοθήκες λογισμικού	37
Πίνακας 4.1: Κύρια σύγκριση δεικτών απόδοσης, κινδύνου και χαρακτηριστικών κατανομής όλων των στρατηγικών	41
Πίνακας 4.2: Διαγνωστικός έλεγχος ταξινόμησης ML μοντέλων	42
Πίνακας 4.3: Ανάλυση ευαισθησίας αποτελεσμάτων υπό διαφορετικά κόστη συναλλαγών	49

ΚΑΤΑΛΟΓΟΣ ΕΙΚΟΝΩΝ

Εικόνα 3.1: Κανονικοποιημένες τιμές κλεισίματος	26
Εικόνα 3.2: Πίνακας συσχετίσεων ημερήσιων αποδόσεων	29
Εικόνα 4.1: Διάγραμμα σωρευτικών αποδόσεων παραδοσιακών στρατηγικών	46
Εικόνα 4.2: Διάγραμμα σωρευτικών αποδόσεων ML στρατηγικών	47
Εικόνα 4.3: Διάγραμμα σωρευτικής απόδοσης όλων των στρατηγικών	48
Εικόνα 4.4: Διάγραμμα σύγκρισης Sharpe ratio υπό διαφορετικά κόστη συναλλαγών	48

1 ΕΙΣΑΓΩΓΗ

Η αριστοποίηση χαρτοφυλακίου αποτελεί ένα από τα πιο κεντρικά ζητήματα της σύγχρονης χρηματοοικονομικής. Κάθε επενδυτής ή διαχειριστής κεφαλαίων καλείται να αποφασίσει πώς θα κατανείμει το διαθέσιμο κεφάλαιο μεταξύ διαφορετικών περιουσιακών στοιχείων, με στόχο να πετύχει ικανοποιητική απόδοση χωρίς να αναλάβει υπερβολικό κίνδυνο. Η δυσκολία του προβλήματος βρίσκεται στο ότι η απόδοση και ο κίνδυνος δεν εξετάζονται ανεξάρτητα. Ένα αξιόγραφο μπορεί να έχει υψηλή αναμενόμενη απόδοση, αλλά να συνοδεύεται από έντονες διακυμάνσεις. Αντίστοιχα, ένα πιο σταθερό αξιόγραφο μπορεί να μειώνει τον συνολικό κίνδυνο του χαρτοφυλακίου, αλλά να περιορίζει την τελική απόδοση. Επομένως, η ποιότητα μιας επενδυτικής στρατηγικής δεν κρίνεται μόνο από το πόσο κερδίζει στο τέλος της περιόδου, αλλά και από τη διαδρομή που ακολουθεί μέχρι να φτάσει εκεί.

Η σύγχρονη θεωρία χαρτοφυλακίου ξεκινά ουσιαστικά από την εργασία του Markowitz, ο οποίος έδειξε ότι η αξιολόγηση ενός χαρτοφυλακίου πρέπει να γίνεται με βάση τη σχέση αναμενόμενης απόδοσης και διακύμανσης, καθώς και με βάση τη συνδιακύμανση μεταξύ των επιμέρους τίτλων (Markowitz, 1952). Η συμβολή αυτή ήταν σημαντική γιατί μετέφερε την προσοχή από την επιλογή μεμονωμένων τίτλων στη συνολική συμπεριφορά του χαρτοφυλακίου. Με άλλα λόγια, ένα αξιόγραφο δεν αξιολογείται μόνο από τη δική του απόδοση ή μεταβλητότητα, αλλά και από το πώς επηρεάζει το συνολικό χαρτοφυλάκιο όταν συνδυάζεται με τα υπόλοιπα αξιόγραφα.

Στη συνέχεια, το Υπόδειγμα Αποτίμησης Περιουσιακών Στοιχείων, γνωστό ως CAPM, πρόσθεσε ένα πλαίσιο σύνδεσης της αναμενόμενης απόδοσης με τον συστηματικό κίνδυνο. Σύμφωνα με το CAPM, ο κίνδυνος που αποζημιώνεται από την αγορά δεν είναι ο συνολικός κίνδυνος ενός αξιογράφου, αλλά το μέρος του κινδύνου που δεν μπορεί να εξαλειφθεί μέσω διαφοροποίησης (Sharpe, 1964; Lintner, 1965). Παρά την κριτική που έχει δεχθεί εμπειρικά, το CAPM εξακολουθεί να αποτελεί βασικό θεωρητικό σημείο αναφοράς για την αποτίμηση κινδύνου και απόδοσης.

Τα τελευταία χρόνια, η ανάπτυξη της μηχανικής μάθησης δημιούργησε νέες δυνατότητες για την ανάλυση χρηματοοικονομικών δεδομένων. Οι αλγόριθμοι μηχανικής μάθησης μπορούν να επεξεργαστούν μεγάλο αριθμό μεταβλητών, να εντοπίσουν μη γραμμικές σχέσεις και να

προσαρμόζονται σε πιο σύνθετα μοτίβα σε σχέση με τις παραδοσιακές γραμμικές προσεγγίσεις. Στη χρηματοοικονομική, αυτό έχει ιδιαίτερο ενδιαφέρον, επειδή οι αγορές χαρακτηρίζονται από θόρυβο, αστάθεια και μεταβαλλόμενες σχέσεις μεταξύ των μεταβλητών. Ωστόσο, η χρήση ML δεν εγγυάται αυτόματα καλύτερα αποτελέσματα. Η τελική αξία ενός μοντέλου κρίνεται από το αν οι προβλέψεις του μπορούν να μετατραπούν σε επενδυτικές αποφάσεις με καλύτερη σχέση απόδοσης και κινδύνου.

Η παρούσα διπλωματική εργασία τοποθετείται ακριβώς σε αυτό το σημείο. Συγκρίνει παραδοσιακές μεθόδους αριστοποίησης χαρτοφυλακίου με μεθόδους μηχανικής μάθησης, όχι μόνο ως στατιστικά μοντέλα, αλλά ως πρακτικές στρατηγικές κατανομής κεφαλαίου. Η σύγκριση γίνεται σε πραγματικά δεδομένα προσαρμοσμένων τιμών κλεισίματος επενδυτικών προϊόντων για την περίοδο 2020-2025 και εφαρμόζεται με διαδικασία rolling window. Με αυτόν τον τρόπο, η εργασία προσπαθεί να προσεγγίσει πιο ρεαλιστικά τη διαδικασία λήψης επενδυτικών αποφάσεων, όπου οι αποφάσεις λαμβάνονται με βάση την πληροφορία που είναι διαθέσιμη εκείνη τη στιγμή.

1.1 Αντικείμενο και σκοπός της μελέτης

Αντικείμενο της μελέτης είναι η συγκριτική ανάλυση παραδοσιακών χρηματοοικονομικών μεθόδων και τεχνικών μηχανικής μάθησης στην αριστοποίηση χαρτοφυλακίου. Η εργασία εξετάζει κατά πόσο οι κλασικές προσεγγίσεις, όπως το υπόδειγμα Markowitz και το CAPM, μπορούν να αποδώσουν καλύτερα ή χειρότερα από αλγορίθμους όπως Decision Trees, Random Forest, Support Vector Machines και XGBoost. Η σύγκριση δεν γίνεται σε θεωρητικό επίπεδο μόνο, αλλά εφαρμόζεται σε εμπειρικό πλαίσιο με πραγματικά δεδομένα και κοινή περίοδο αξιολόγησης.

Ο σκοπός της εργασίας είναι να αξιολογηθεί εάν οι πιο σύγχρονες μέθοδοι μηχανικής μάθησης μπορούν να προσφέρουν ουσιαστικό πλεονέκτημα έναντι των παραδοσιακών μεθόδων, όταν χρησιμοποιούνται για τη δημιουργία χαρτοφυλακίων. Το ερώτημα δεν είναι απλώς αν ένα ML μοντέλο μπορεί να προβλέψει σωστά την κατεύθυνση της επόμενης ημερήσιας απόδοσης, αλλά αν αυτή η πρόβλεψη μπορεί να οδηγήσει σε καλύτερη επενδυτική στρατηγική. Για αυτόν τον λόγο, η εργασία εξετάζει τόσο δείκτες ταξινόμησης όσο και επενδυτικούς δείκτες απόδοσης και κινδύνου.

Η μελέτη εστιάζει στην πρακτική πλευρά της αριστοποίησης χαρτοφυλακίου. Οι στρατηγικές δεν αξιολογούνται μόνο με βάση in-sample προσαρμογή, αλλά μέσω rolling-window διαδικασίας. Σε κάθε βήμα, οι παράμετροι των παραδοσιακών μεθόδων και τα ML μοντέλα εκτιμώνται με βάση προηγούμενες παρατηρήσεις και στη συνέχεια εφαρμόζονται σε επόμενη περίοδο. Η λογική αυτή μειώνει τον κίνδυνο χρήσης μελλοντικής πληροφορίας και τοποθετεί την αξιολόγηση πιο κοντά σε μια πραγματική εφαρμογή.

Η περίοδος 2020-2025 στην οποία πραγματοποιείται η παρούσα ανάλυση περιλαμβάνει διαφορετικές συνθήκες στις διεθνείς χρηματοοικονομικές αγορές, με έμφαση στην αγορά των Η.Π.Α. και σε επενδυτικά προϊόντα που διαπραγματεύονται κυρίως σε αυτήν. Η περίοδος αυτή συνδέεται με μεταβλητότητα μετά την πανδημία, αλλαγές στο επιτοκιακό περιβάλλον, διακυμάνσεις σε μετοχές, ομόλογα, εμπορεύματα, ETFs ακινήτων, διεθνή μετοχικά ETFs και συναλλαγματικές ισοτιμίες. Επομένως, το δείγμα δίνει τη δυνατότητα να εξεταστεί αν οι στρατηγικές είναι σταθερές σε ένα διαφοροποιημένο επενδυτικό περιβάλλον, όπου οι σχέσεις μεταξύ διαφορετικών κατηγοριών επενδυτικών προϊόντων μεταβάλλονται.

1.2 Ερευνητικά ερωτήματα και στόχοι

Η εργασία οργανώνεται γύρω από ένα βασικό ερευνητικό ερώτημα το οποίο αφορά στο αν μπορούν οι μέθοδοι μηχανικής μάθησης να βελτιώσουν την απόδοση ενός χαρτοφυλακίου σε σχέση με τις παραδοσιακές μεθόδους, όταν η αξιολόγηση γίνεται σε κοινό rolling-window πλαίσιο. Το ερώτημα αυτό αναλύεται σε επιμέρους στόχους, ώστε η σύγκριση να είναι συγκεκριμένη και μετρήσιμη.

Πρώτος στόχος είναι η εφαρμογή παραδοσιακών μεθόδων χαρτοφυλακίου σε πραγματικά δεδομένα. Αυτό περιλαμβάνει το ισοσταθμισμένο χαρτοφυλάκιο, το χαρτοφυλάκιο ελάχιστης διακύμανσης, καθώς και ένα χαρτοφυλάκιο που προκύπτει από mean-variance βελτιστοποίηση με αντικειμενική συνάρτηση τη μεγιστοποίηση του Sharpe ratio. Επιπλέον, εξετάζεται το CAPM ως υπόδειγμα εκτίμησης αναμενόμενων αποδόσεων βάσει συστηματικού κινδύνου. Οι μέθοδοι αυτές καλύπτουν διαφορετικές προσεγγίσεις όπως η απλή διαφοροποίηση, η ελαχιστοποίηση του κινδύνου, η μεγιστοποίηση σχέσης απόδοσης-κινδύνου και η εκτίμηση αποδόσεων μέσω συστηματικού κινδύνου.

Δεύτερος στόχος είναι η εφαρμογή μοντέλων μηχανικής μάθησης (ML) ως εργαλείων επιλογής περιουσιακών στοιχείων. Τα ML μοντέλα εκπαιδεύονται ώστε να εκτιμούν την πιθανότητα θετικής επόμενης ημερήσιας απόδοσης. Στη συνέχεια, οι προβλέψεις μετατρέπονται σε στρατηγική χαρτοφυλακίου μέσω επιλογής των αξιογράφων με τις υψηλότερες προβλεπόμενες πιθανότητες. Έτσι, η μηχανική μάθηση δεν εξετάζεται μόνο ως τεχνική πρόβλεψης, αλλά ως μέρος μιας επενδυτικής διαδικασίας.

Τρίτος στόχος είναι η αξιολόγηση όλων των στρατηγικών με κοινά κριτήρια. Η εργασία δεν περιορίζεται στην τελική απόδοση. Χρησιμοποιεί ετησιοποιημένη απόδοση, μεταβλητότητα, Sharpe ratio, max drawdown, Sortino ratio και Calmar ratio. Για τα ML μοντέλα εξετάζονται επίσης accuracy, precision, recall και F1-score. Με αυτόν τον τρόπο, διαχωρίζεται η στατιστική ικανότητα πρόβλεψης από την τελική επενδυτική απόδοση.

Τέταρτος στόχος είναι η ερμηνεία των διαφορών μεταξύ των δύο ομάδων μεθόδων. Οι παραδοσιακές μέθοδοι βελτιστοποιούν άμεσα χαρακτηριστικά του χαρτοφυλακίου, ενώ τα ML μοντέλα παράγουν προβλέψεις που πρέπει να μετατραπούν σε επιλογές και βάρη. Αυτή η διαφορά είναι βασική για την κατανόηση των αποτελεσμάτων, επειδή ένα μοντέλο με σχετικά καλή ταξινόμηση δεν οδηγεί αναγκαστικά σε καλύτερο Sharpe ratio.

1.3 Δομή της διπλωματικής εργασίας

Η διπλωματική εργασία οργανώνεται σε πέντε κεφάλαια. Το πρώτο κεφάλαιο παρουσιάζει το αντικείμενο, τον σκοπό, τα ερευνητικά ερωτήματα και τη συνολική δομή της εργασίας. Στόχος του είναι να εισαγάγει τον αναγνώστη στο πρόβλημα της αριστοποίησης χαρτοφυλακίου και να εξηγήσει γιατί έχει νόημα η σύγκριση παραδοσιακών μεθόδων με μεθόδους μηχανικής μάθησης.

Το δεύτερο κεφάλαιο αποτελεί τη βιβλιογραφική ανασκόπηση. Αρχικά παρουσιάζεται το θεωρητικό υπόβαθρο της θεωρίας χαρτοφυλακίου και στη συνέχεια αναλύονται το υπόδειγμα Markowitz και το CAPM. Ακολουθεί επισκόπηση των εφαρμογών μηχανικής μάθησης στη χρηματοοικονομική και στη βελτιστοποίηση χαρτοφυλακίου. Το κεφάλαιο ολοκληρώνεται με συγκριτικές εμπειρικές μελέτες και τρία σύντομα case studies, τα οποία βοηθούν να φανεί πώς έχει εξεταστεί παρόμοιο ερευνητικό ερώτημα στη διεθνή βιβλιογραφία.

Το τρίτο κεφάλαιο παρουσιάζει τη μεθοδολογία της εμπειρικής ανάλυσης. Περιγράφονται τα δεδομένα, η χρονική περίοδος, οι κατηγορίες περιουσιακών στοιχείων, οι μεταβλητές, οι δείκτες αξιολόγησης, οι παραδοσιακές μέθοδοι και τα ML μοντέλα. Ιδιαίτερη έμφαση δίνεται στη διαδικασία rolling window, στη μηνιαία αναδιάρθρωση και στην αποφυγή χρήσης μελλοντικής πληροφορίας.

Το τέταρτο κεφάλαιο παρουσιάζει τα αποτελέσματα και τα βασικά ευρήματα. Εκεί συγκρίνονται οι στρατηγικές ως προς την απόδοση, τη μεταβλητότητα, το Sharpe ratio, το drawdown και τους υπόλοιπους δείκτες. Παράλληλα, εξετάζεται η διαφορά μεταξύ της προβλεπτικής επίδοσης των ML μοντέλων και της τελικής επενδυτικής τους επίδοσης. Το πέμπτο κεφάλαιο συνοψίζει τα συμπεράσματα, αναφέρει τους περιορισμούς της ανάλυσης και προτείνει κατευθύνσεις για μελλοντική έρευνα.

2 ΒΙΒΛΙΟΓΡΑΦΙΚΗ ΑΝΑΣΚΟΠΗΣΗ

Η βιβλιογραφική επισκόπηση έχει ως σκοπό να τοποθετήσει την εμπειρική ανάλυση της εργασίας μέσα στο ευρύτερο θεωρητικό και ερευνητικό πλαίσιο. Η αριστοποίηση χαρτοφυλακίου αποτελεί αντικείμενο μελέτης για πολλές δεκαετίες και έχει εξελιχθεί από τις κλασσικές προσεγγίσεις μέσης απόδοσης–διακύμανσης (mean-variance) μέχρι τις σύγχρονες εφαρμογές μηχανικής μάθησης. Η σύνδεση αυτών των δύο κόσμων είναι βασική για την παρούσα εργασία, επειδή η σύγκριση παραδοσιακών και ML μεθόδων πρέπει να στηρίζεται σε σαφές θεωρητικό υπόβαθρο.

2.1 Θεωρητικό υπόβαθρο της θεωρίας χαρτοφυλακίου

Η θεωρία χαρτοφυλακίου βασίζεται στην ιδέα ότι ο επενδυτής δεν πρέπει να αξιολογεί κάθε περιουσιακό στοιχείο απομονωμένα, αλλά ως μέρος ενός συνολικού συνδυασμού. Η απόδοση ενός χαρτοφυλακίου είναι συνάρτηση των αποδόσεων των επιμέρους αξιογράφων και των βαρών που κατανέμονται σε αυτά. Αντίστοιχα, ο κίνδυνος του χαρτοφυλακίου δεν ισούται απλώς με τον μέσο όρο των κινδύνων των επιμέρους αξιογράφων, αλλά εξαρτάται από τις μεταξύ τους συνδιακυμάνσεις. Αυτή η παρατήρηση αποτελεί τη βάση της διαφοροποίησης.

$$E(R_p) = \sum w_i E(R_i)$$

Η σχέση αυτή δείχνει ότι η αναμενόμενη απόδοση του χαρτοφυλακίου είναι το σταθμισμένο άθροισμα των αναμενόμενων αποδόσεων των επιμέρους περιουσιακών στοιχείων. Η δυσκολία βρίσκεται στο ότι η αύξηση της αναμενόμενης απόδοσης συνήθως συνοδεύεται από αύξηση του κινδύνου. Επομένως, ο επενδυτής καλείται να επιλέξει έναν συνδυασμό που να είναι συμβατός με την ανοχή του στον κίνδυνο.

$$\sigma_p^2 = \mathbf{w}' \Sigma \mathbf{w} = \sum_i \sum_j w_i w_j \sigma_{ij}$$

Η παραπάνω σχέση αποτυπώνει τη διακύμανση του χαρτοφυλακίου. Το κρίσιμο σημείο είναι η παρουσία του πίνακα συνδιακυμάνσεων. Εάν δύο αξιόγραφα έχουν χαμηλή ή αρνητική συσχέτιση, ο συνδυασμός τους μπορεί να μειώσει τη συνολική μεταβλητότητα του χαρτοφυλακίου. Αυτός είναι ο βασικός μηχανισμός μέσω του οποίου η διαφοροποίηση μειώνει τον κίνδυνο. Η διαφοροποίηση, όμως, δεν εξαφανίζει κάθε μορφή κινδύνου. Μπορεί

να μειώσει τον ειδικό ή μη συστηματικό κίνδυνο, αλλά ο συστηματικός κίνδυνος της αγοράς παραμένει.

Η αξιολόγηση μιας στρατηγικής χαρτοφυλακίου απαιτεί δείκτες που συνδυάζουν την απόδοση με τον κίνδυνο. Ο πιο γνωστός είναι το Sharpe ratio, το οποίο συγκρίνει την υπερβάλλουσα απόδοση με τη μεταβλητότητα. Ο Lo (2002) επισημαίνει ότι το Sharpe ratio είναι χρήσιμο αλλά πρέπει να ερμηνεύεται με προσοχή, επειδή οι αποδόσεις μπορεί να μην είναι ανεξάρτητες, κανονικά κατανοημένες ή σταθερές στον χρόνο. Για τον λόγο αυτό, η παρούσα εργασία δεν χρησιμοποιεί μόνο Sharpe ratio, αλλά και max drawdown, Sortino ratio και Calmar ratio, ώστε να αποτυπωθεί πληρέστερα ο κίνδυνος.

$$\text{Sharpe Ratio} = \frac{R_p - R_f}{\sigma_p}$$

Η έννοια του drawdown είναι ιδιαίτερα χρήσιμη σε πρακτικές εφαρμογές, επειδή δείχνει τη μέγιστη υποχώρηση της αξίας ενός χαρτοφυλακίου από προηγούμενο υψηλό. Δύο στρατηγικές μπορεί να έχουν παρόμοια ετησιοποιημένη μεταβλητότητα, αλλά η μία να έχει πολύ μεγαλύτερες ενδιάμεσες απώλειες. Για έναν επενδυτή ή διαχειριστή κεφαλαίων, αυτή η διαφορά είναι σημαντική, επειδή οι μεγάλες απώλειες επηρεάζουν τη δυνατότητα διακράτησης της στρατηγικής και την εμπιστοσύνη στη μεθοδολογία.

Έννοια	Σύντομη ερμηνεία	Ρόλος στην εργασία
Αναμενόμενη απόδοση	Μέση προσδοκώμενη απόδοση του χαρτοφυλακίου	Υπολογισμός και σύγκριση στρατηγικών
Διακύμανση/μεταβλητότητα	Μέτρο συνολικής αβεβαιότητας των αποδόσεων	Κεντρικός δείκτης κινδύνου
Συνδιακύμανση	Σχέση μεταβολών μεταξύ δύο αξιογράφων	Βάση διαφοροποίησης και Markowitz
Sharpe ratio	Υπερβάλλουσα απόδοση ανά μονάδα κινδύνου	Κύριο μέτρο risk-adjusted επίδοσης
Max drawdown	Μέγιστη υποχώρηση από προηγούμενο υψηλό	Έλεγχος μεγέθους ενδιάμεσων απωλειών

Πίνακας 2.1: Βασικές έννοιες θεωρίας χαρτοφυλακίου και χρήση τους στην εργασία

2.2 Το υπόδειγμα Markowitz και η θεωρία αποδοτικών χαρτοφυλακίων

Το υπόδειγμα Markowitz αποτελεί τη βάση της σύγχρονης θεωρίας χαρτοφυλακίου. Η βασική του ιδέα είναι ότι ο επενδυτής επιλέγει χαρτοφυλάκιο με βάση δύο μεγέθη: την αναμενόμενη απόδοση και τη διακύμανση. Η προσέγγιση αυτή ονομάζεται ανάλυση μέσης απόδοσης–

διακύμανσης (mean-variance analysis) και επιτρέπει την αναζήτηση χαρτοφυλακίων που είναι αποτελεσματικά, δηλαδή χαρτοφυλακίων που προσφέρουν τη μέγιστη δυνατή αναμενόμενη απόδοση για δεδομένο επίπεδο κινδύνου ή τον ελάχιστο δυνατό κίνδυνο για δεδομένη αναμενόμενη απόδοση (Markowitz, 1952).

Η έννοια του αποδοτικού συνόρου είναι κεντρική στο υπόδειγμα. Το αποδοτικό σύνορο περιλαμβάνει τα χαρτοφυλάκια που θεωρούνται βέλτιστα, επειδή δεν υπάρχει άλλο χαρτοφυλάκιο που να προσφέρει υψηλότερη απόδοση με τον ίδιο κίνδυνο ή χαμηλότερο κίνδυνο με την ίδια απόδοση. Ένα χαρτοφυλάκιο θεωρείται μη αποδοτικό όταν υπάρχει άλλο χαρτοφυλάκιο με υψηλότερη αναμενόμενη απόδοση για το ίδιο επίπεδο κινδύνου ή με χαμηλότερο κίνδυνο για την ίδια αναμενόμενη απόδοση. Με αυτή τη λογική, η επιλογή δεν αφορά απλώς το αξιόγραφο με την υψηλότερη απόδοση, αλλά τον καλύτερο συνδυασμό αξιογράφων.

Η μαθηματική διατύπωση του Markowitz βασίζεται στον πίνακα συνδιακυμάνσεων. Αυτό σημαίνει ότι τα οφέλη της διαφοροποίησης προκύπτουν από το πώς αλληλεπιδρούν οι αποδόσεις των επιμέρους τίτλων. Αν όλα τα αξιόγραφα είχαν τέλεια θετική συσχέτιση, η διαφοροποίηση θα είχε περιορισμένη αξία. Αντίθετα, όταν οι συσχετίσεις είναι χαμηλότερες, ο συνδυασμός διαφορετικών αξιογράφων μπορεί να μειώσει τη μεταβλητότητα χωρίς να μειώσει αναλογικά την αναμενόμενη απόδοση.

Στην πράξη, η εφαρμογή του Markowitz έχει και περιορισμούς. Οι μέσες αποδόσεις και οι συνδιακυμάνσεις πρέπει να εκτιμηθούν από ιστορικά δεδομένα και οι εκτιμήσεις αυτές περιέχουν σφάλμα. Η ευαισθησία αυτή έχει επισημανθεί και από τη Mynbayeva (2022), η οποία εξετάζει γιατί η επιλογή χαρτοφυλακίου κατά Markowitz μπορεί να αποτύχει όταν οι παράμετροι του υποδείγματος εκτιμώνται με σφάλμα. Το πρόβλημα είναι ιδιαίτερα έντονο για τις αναμενόμενες αποδόσεις, οι οποίες είναι συχνά ασταθείς και δύσκολο να προβλεφθούν. Έτσι, ένα χαρτοφυλάκιο που φαίνεται θεωρητικά βέλτιστο με βάση τα ιστορικά στοιχεία μπορεί στην πράξη να μην αποδώσει το ίδιο καλά εκτός δείγματος (out-of-sample). Η εμπειρία έχει δείξει ότι ακόμη και απλές στρατηγικές, όπως η ισοσταθμισμένη κατανομή $1/N$, μπορούν να είναι δύσκολο να ξεπεραστούν εκτός δείγματος όταν τα σφάλματα εκτίμησης είναι μεγάλα (DeMiguel, Garlappi and Uppal, 2009).

Παρά τους περιορισμούς αυτούς, το υπόδειγμα Markowitz παραμένει ιδιαίτερα σημαντικό. Προσφέρει ένα καθαρό πλαίσιο για την έννοια της διαφοροποίησης και επιτρέπει τη διατύπωση προβλημάτων βελτιστοποίησης με σαφείς περιορισμούς. Στην παρούσα εργασία, η λογική Markowitz εφαρμόζεται μέσω της στρατηγικής μέγιστου Sharpe ratio σε κυλιόμενο πλαίσιο αξιολόγησης (rolling window). Η στρατηγική αυτή δεν αναζητά απλώς χαμηλή μεταβλητότητα, αλλά προσπαθεί να μεγιστοποιήσει τη σχέση απόδοσης προς κίνδυνο.

Η σύνδεση του Markowitz με την παρούσα εμπειρική ανάλυση είναι άμεση. Στην εργασία αξιοποιούνται ιστορικές αποδόσεις μέσα σε rolling window, υπολογίζονται πίνακες συνδιακυμάνσεων και εκτιμώνται βάρη χαρτοφυλακίου με long-only περιορισμό. Η rolling-window εφαρμογή είναι σημαντική, επειδή οι σχέσεις μεταξύ αξιογράφων δε θεωρούνται σταθερές για όλη την πενταετία. Αντίθετα, οι εκτιμήσεις ανανεώνονται περιοδικά, ώστε το χαρτοφυλάκιο να προσαρμόζεται στις νεότερες πληροφορίες.

2.3 Το Υπόδειγμα Αποτίμησης Περιουσιακών Στοιχείων (CAPM)

Το CAPM αναπτύχθηκε ως συνέχεια της θεωρίας χαρτοφυλακίου και επιδιώκει να εξηγήσει τη σχέση ανάμεσα στην αναμενόμενη απόδοση ενός περιουσιακού στοιχείου και στον συστηματικό του κίνδυνο. Στη βασική του μορφή, το υπόδειγμα υποστηρίζει ότι η αναμενόμενη απόδοση ενός αξιογράφου ισούται με το risk-free rate συν ένα ασφάλιστρο κινδύνου, το οποίο εξαρτάται από το beta του αξιογράφου ως προς την αγορά (Sharpe, 1964; Lintner, 1965).

$$E(R_i) = R_f + \beta_i[E(R_m) - R_f]$$

$$\beta_i = \frac{Cov(R_i, R_m)}{Var R_m}$$

Το β (beta) μετρά την ευαισθησία της απόδοσης ενός αξιογράφου στις μεταβολές της αγοράς. Ένα beta μεγαλύτερο της μονάδας σημαίνει ότι το αξιόγραφο τείνει να κινείται πιο έντονα από την αγορά, ενώ beta μικρότερο της μονάδας υποδηλώνει χαμηλότερη ευαισθησία. Η βασική ιδέα είναι ότι ο επενδυτής αποζημιώνεται μόνο για τον κίνδυνο που δεν μπορεί να διαφοροποιηθεί. Ο ειδικός κίνδυνος ενός μεμονωμένου αξιογράφου μπορεί να μειωθεί μέσω διαφοροποίησης και επομένως, σύμφωνα με το CAPM, δεν πρέπει να συνδέεται με υψηλότερη αναμενόμενη απόδοση.

Το CAPM έχει μεγάλη θεωρητική σημασία επειδή προσφέρει μια απλή και σαφή σχέση μεταξύ κινδύνου και απόδοσης. Χρησιμοποιείται συχνά για την εκτίμηση κόστους κεφαλαίου, για την αξιολόγηση επενδυτικών αποφάσεων και για την ανάλυση αποδόσεων χαρτοφυλακίων. Ωστόσο, η εμπειρική του ισχύς έχει αμφισβητηθεί. Οι Fama and French (2004) σημειώνουν ότι, παρότι το CAPM αποτελεί θεμέλιο της asset pricing θεωρίας, οι εμπειρικές εφαρμογές του εμφανίζουν σημαντικές αδυναμίες, κυρίως επειδή η πραγματική σχέση κινδύνου και απόδοσης είναι πιο σύνθετη από αυτή που περιγράφει ένα μόνο beta.

Η κριτική προς το CAPM δεν σημαίνει ότι το υπόδειγμα είναι ελάσσονος σημασίας. Αντίθετα, σημαίνει ότι πρέπει να χρησιμοποιείται με κατανόηση των περιορισμών του. Για μια συγκριτική ανάλυση, το CAPM είναι χρήσιμο επειδή λειτουργεί ως κλασικό σημείο αναφοράς. Επιτρέπει να εξεταστεί αν μια απλή προσέγγιση βασισμένη στον συστηματικό κίνδυνο μπορεί να αποδώσει καλύτερα ή χειρότερα από πιο σύνθετες στρατηγικές.

Στην παρούσα εργασία, το CAPM δεν χρησιμοποιείται ως πλήρης περιγραφή της αγοράς, αλλά ως πρακτικός μηχανισμός εκτίμησης σχετικών αναμενόμενων αποδόσεων. Το beta κάθε αξιογράφου εκτιμάται ως προς το SPY, το οποίο λειτουργεί ως δείκτης αναφοράς (benchmark). Στη συνέχεια, οι CAPM-implied αποδόσεις αξιοποιούνται για τη δημιουργία rolling στρατηγικής. Με αυτόν τον τρόπο, το CAPM εντάσσεται στο ίδιο εμπειρικό πλαίσιο με τις υπόλοιπες στρατηγικές και αξιολογείται με τους ίδιους δείκτες.

Η σύγκριση Markowitz και CAPM είναι σημαντική γιατί οι δύο προσεγγίσεις δίνουν διαφορετική έμφαση. Το Markowitz επικεντρώνεται στην κατανομή του συνολικού χαρτοφυλακίου με βάση αποδόσεις και συνδιακυμάνσεις. Το CAPM δίνει έμφαση στον συστηματικό κίνδυνο κάθε αξιογράφου σε σχέση με την αγορά. Η παρούσα εργασία αξιοποιεί και τις δύο προσεγγίσεις ώστε να υπάρχει ισορροπία ανάμεσα σε κλασικές μεθόδους βελτιστοποίησης και σε θεωρητικά υποδείγματα αποτίμησης κινδύνου.

2.4 Εφαρμογές Μηχανικής Μάθησης στη βελτιστοποίηση χαρτοφυλακίου

Η μηχανική μάθηση έχει αποκτήσει σημαντική θέση στη χρηματοοικονομική έρευνα, κυρίως λόγω της δυνατότητάς της να χειρίζεται μεγάλο αριθμό μεταβλητών και να εντοπίζει μη γραμμικές σχέσεις. Σε αντίθεση με τα κλασικά μοντέλα, τα οποία συχνά στηρίζονται σε συγκεκριμένη μαθηματική μορφή, τα ML μοντέλα μπορούν να μάθουν πιο σύνθετες σχέσεις

από τα δεδομένα. Αυτό είναι χρήσιμο σε χρηματοοικονομικά περιβάλλοντα, όπου οι σχέσεις μεταξύ αποδόσεων, μεταβλητότητας, momentum και μακροοικονομικών συνθηκών μπορεί να είναι ασταθείς και μη γραμμικές.

Στη χρηματοοικονομική, η μηχανική μάθηση μπορεί να χρησιμοποιηθεί με διαφορετικούς τρόπους. Μπορεί να προβλέψει αποδόσεις, να ταξινομήσει αξιόγραφα με βάση πιθανή ανοδική ή καθοδική κίνηση, να εκτιμήσει κίνδυνο, να εντοπίσει καθεστώτα αγοράς ή να υποστηρίξει απευθείας την κατανομή κεφαλαίου. Η παρούσα εργασία ακολουθεί μια προσέγγιση ταξινόμησης: κάθε αξιόγραφο και κάθε ημέρα αντιστοιχίζεται σε μια δυαδική μεταβλητή στόχο, ανάλογα με το αν η επόμενη ημερήσια απόδοση είναι θετική ή όχι.

$$y_{i,t+1} = 1 \text{ αν } r_{i,t+1} > 0, \text{ διαφορετικά } y_{i,t+1} = 0$$

Η συγκεκριμένη διατύπωση έχει το πλεονέκτημα ότι μετατρέπει το πρόβλημα σε σαφές supervised learning πρόβλημα. Τα μοντέλα εκπαιδεύονται με χαρακτηριστικά που έχουν υπολογιστεί από ιστορικά δεδομένα και στη συνέχεια παράγουν πιθανότητες για τη θετική κλάση. Αυτές οι πιθανότητες χρησιμοποιούνται για την κατάταξη των αξιογράφων. Η τελική επενδυτική απόφαση προκύπτει από την επιλογή των αξιογράφων με τις υψηλότερες πιθανότητες.

Τα Decision Trees αποτελούν απλή και ερμηνεύσιμη μέθοδο ταξινόμησης. Χωρίζουν τα δεδομένα σε υποομάδες μέσω κανόνων που βασίζονται στις τιμές των χαρακτηριστικών. Η απλότητά τους είναι πλεονέκτημα, αλλά υπάρχει κίνδυνος υπερπροσαρμογής αν το δέντρο γίνει πολύ βαθύ. Για αυτόν τον λόγο χρησιμοποιούνται περιορισμοί όπως μέγιστο βάθος και ελάχιστος αριθμός παρατηρήσεων.

Το Random Forest, που εισήχθη από τον Breiman (2001), αντιμετωπίζει μέρος της αστάθειας των μεμονωμένων δέντρων συνδυάζοντας πολλά δέντρα. Κάθε δέντρο εκπαιδεύεται με στοιχεία τυχαιότητας και το τελικό αποτέλεσμα προκύπτει από τον συνδυασμό των επιμέρους προβλέψεων. Η λογική του ensemble μπορεί να μειώσει τη διακύμανση του μοντέλου και να βελτιώσει τη γενίκευση. Η βιβλιοθήκη scikit-learn περιγράφει επίσης το Random Forest ως meta-estimator που προσαρμόζει πολλά δέντρα σε υποδείγματα του dataset και χρησιμοποιεί μέσο όρο για τη βελτίωση της προβλεπτικής ακρίβειας (scikit-learn documentation, 2026).

Τα Support Vector Machines βασίζονται στην αναζήτηση ενός διαχωριστικού ορίου μεταξύ κατηγοριών. Στη βασική τους μορφή προσπαθούν να βρουν το υπερεπίπεδο που διαχωρίζει τις κατηγορίες με το μεγαλύτερο περιθώριο. Με τη χρήση kernels, όπως το RBF kernel, μπορούν να επεκταθούν σε μη γραμμικά προβλήματα ταξινόμησης (Cortes and Vapnik, 1995). Στην παρούσα εργασία, η χρήση SVM είναι χρήσιμη επειδή επιτρέπει την εξέταση μη γραμμικών σχέσεων μεταξύ χαρακτηριστικών και πιθανής κατεύθυνσης της απόδοσης.

Το XGBoost είναι μέθοδος gradient boosting που βασίζεται σε διαδοχικά δέντρα. Κάθε νέο δέντρο προσπαθεί να διορθώσει τα σφάλματα των προηγούμενων, ενώ η μέθοδος περιλαμβάνει μηχανισμούς regularization και αποδοτική υλοποίηση για μεγάλα σύνολα δεδομένων (Chen and Guestrin, 2016). Η επίσημη τεκμηρίωση του XGBoost το περιγράφει ως βελτιστοποιημένη βιβλιοθήκη gradient boosting, σχεδιασμένη για αποδοτικότητα, ευελιξία και φορητότητα (XGBoost documentation, 2026).

Η χρήση ML σε χαρτοφυλάκια έχει, όμως, σημαντικές προκλήσεις. Πρώτον, τα χρηματοοικονομικά δεδομένα έχουν υψηλό θόρυβο από την αγορά και οι σχέσεις μεταξύ μεταβλητών μπορεί να αλλάζουν στο χρόνο. Δεύτερον, υπάρχει κίνδυνος υπερπροσαρμογής, ιδιαίτερα όταν δοκιμάζονται πολλά μοντέλα, παράμετροι ή χαρακτηριστικά. Οι Bailey et al. (2015) αναλύουν το πρόβλημα του backtest overfitting και δείχνουν ότι μια στρατηγική μπορεί να φαίνεται ισχυρή σε ιστορικά δεδομένα αλλά να μην έχει πραγματική προβλεπτική αξία. Τρίτον, η καλή στατιστική πρόβλεψη δεν οδηγεί απαραίτητα σε καλή επενδυτική στρατηγική. Η πρόβλεψη πρέπει να μετατραπεί σε βάρη χαρτοφυλακίου, λαμβάνοντας υπόψη κίνδυνο, κόστη συναλλαγών και ορίζοντα διακράτησης.

Η βιβλιογραφία της μηχανικής μάθησης στη χρηματοοικονομική δείχνει ότι τα ML μοντέλα μπορούν να έχουν αξία όταν χρησιμοποιούνται προσεκτικά. Οι Gu, Kelly and Xiu (2020) παρουσιάζουν συγκριτική ανάλυση ML μεθόδων στο empirical asset pricing και δείχνουν ότι τα μοντέλα αυτά μπορούν να αξιοποιήσουν μεγάλο αριθμό μεταβλητών και μη γραμμικές σχέσεις. Πιο κοντά στη λογική της κατανομής χαρτοφυλακίου, οι Pinelis and Ruppert (2022) εξετάζουν τη χρήση μηχανικής μάθησης για τη διαμόρφωση επενδυτικής κατανομής (portfolio allocation), εφαρμόζοντας μοντέλα Random Forest για την εκτίμηση αναμενόμενων αποδόσεων και μεταβλητότητας. Η μελέτη αυτή συνδέεται με την παρούσα εργασία, επειδή δείχνει ότι η αξία των ML μοντέλων δεν εξαρτάται μόνο από την πρόβλεψη, αλλά και από το

πώς οι προβλέψεις μετατρέπονται σε επενδυτικές αποφάσεις. Ωστόσο, αυτό δεν σημαίνει ότι κάθε ML εφαρμογή θα υπερέχει. Η επιτυχία εξαρτάται από τα δεδομένα, τα χαρακτηριστικά, το στόχο της πρόβλεψης, την αποφυγή μελλοντικής πληροφορίας και την αυστηρή αξιολόγηση εκτός δείγματος (out-of-sample).

Προσέγγιση	Κύρια λογική	Πλεονέκτημα	Βασικός περιορισμός
Markowitz	Άμεση βελτιστοποίηση σχέσης απόδοσης-κινδύνου	Σαφές θεωρητικό και μαθηματικό πλαίσιο	Ευαισθησία σε σφάλματα εκτίμησης
CAPM	Σύνδεση αναμενόμενης απόδοσης με beta αγοράς	Απλότητα και ερμηνευσιμότητα	Περιορισμένη εμπειρική ισχύς ενός μόνο παράγοντα
Decision Tree / Random Forest	Ταξινόμηση με βάση κανόνες και ensembles	Μη γραμμικές σχέσεις και ερμηνευσιμότητα	Κίνδυνος υπερπροσαρμογής ή αστάθειας
SVM	Διαχωρισμός κατηγοριών με μέγιστο περιθώριο	Ικανότητα μη γραμμικής ταξινόμησης με kernels	Ευαισθησία σε scaling και παραμέτρους
XGBoost	Διαδοχικά δέντρα που διορθώνουν προηγούμενα σφάλματα	Ισχυρή προβλεπτική μέθοδος σε πολλά προβλήματα	Απαιτεί προσεκτικό tuning και έλεγχο overfitting

Πίνακας 2.2: Συγκριτική αποτύπωση παραδοσιακών και ML προσεγγίσεων

2.5 Συγκριτικές εμπειρικές μελέτες

Η εμπειρική βιβλιογραφία είναι ιδιαίτερα χρήσιμη για την παρούσα εργασία, επειδή δείχνει ότι η σύγκριση παραδοσιακών και πιο σύνθετων μεθόδων δεν έχει πάντα αυτονόητο αποτέλεσμα. Μια πιο πολύπλοκη μέθοδος δεν αποδίδει απαραίτητα καλύτερα σε πραγματικά δεδομένα. Αντίθετα, πολλές φορές η απλότητα, η σταθερότητα και η ανθεκτικότητα σε σφάλματα εκτίμησης είναι εξίσου σημαντικές με την αλγοριθμική πολυπλοκότητα.

Η μελέτη των DeMiguel, Garlappi and Urral (2009) είναι σημαντική γιατί συγκρίνει διάφορες μεθόδους mean-variance βελτιστοποίησης με τον απλό κανόνα $1/N$. Το βασικό συμπέρασμα είναι ότι καμία από τις εξεταζόμενες βελτιστοποιημένες στρατηγικές δεν υπερέχει σταθερά του $1/N$ out-of-sample ως προς δείκτες όπως Sharpe ratio, certainty-equivalent return και turnover. Το εύρημα αυτό δεν ακυρώνει τη θεωρία Markowitz, αλλά αναδεικνύει τη σημασία των σφαλμάτων εκτίμησης. Στην πράξη, μια θεωρητικά βέλτιστη στρατηγική μπορεί να χάσει το πλεονέκτημά της όταν οι παράμετροι εκτιμώνται σε πραγματικές συνθήκες.

Η μελέτη των Gu, Kelly and Xiu (2020) είναι αντιπροσωπευτική της σύγχρονης τάσης στη χρηματοοικονομική μηχανική μάθηση. Οι συγγραφείς πραγματοποιούν συγκριτική ανάλυση

ML μεθόδων στο πρόβλημα της εκτίμησης risk premia και δείχνουν ότι τα πιο ευέλικτα μοντέλα μπορούν να αξιοποιήσουν μεγάλο αριθμό προβλεπτικών μεταβλητών και μη γραμμικών αλληλεπιδράσεων. Η συμβολή της μελέτης είναι ότι δεν εξετάζει απλώς στατιστική ακρίβεια, αλλά συνδέει τις προβλέψεις με οικονομικά αποτελέσματα για τους επενδυτές.

Η εργασία των Drobetz and Otto (2021) εξετάζει την πρόβλεψη αποδόσεων στην ευρωπαϊκή αγορά με τη χρήση μηχανικής μάθησης. Το ενδιαφέρον της για την παρούσα εργασία είναι ότι μεταφέρει τη συζήτηση από την αμερικανική αγορά σε διαφορετικό γεωγραφικό πλαίσιο και δείχνει ότι η απόδοση των ML μοντέλων εξαρτάται από το σύνολο δεδομένων, την επιλογή χαρακτηριστικών και τη σωστή εκπαίδευση. Η μελέτη αυτή στηρίζει την ιδέα ότι η μηχανική μάθηση μπορεί να προσφέρει αξία, αλλά μόνο όταν εφαρμόζεται με πειθαρχημένη μεθοδολογία και αυστηρή αξιολόγηση.

Η παρούσα ανάλυση δεν ξεκινά με την υπόθεση ότι τα ML μοντέλα πρέπει απαραίτητα να ξεπεράσουν τις παραδοσιακές μεθόδους. Αντίθετα, εξετάζει εμπειρικά αν αυτό συμβαίνει στο συγκεκριμένο δείγμα και στο συγκεκριμένο rolling-window πλαίσιο. Η λογική αυτή δεν επιβάλλει την προσδοκία ότι τα ML μοντέλα ως πιο προηγμένα είναι και απαραίτητως καλύτερα στην επιλογή επενδυτικής στρατηγικής, αλλά εξετάζει τα αποτελέσματα που προκύπτουν από τη σύγκριση με κοινά κριτήρια.

2.5.1 Case study: Optimal versus naive diversification

Το πρώτο case study αφορά τη σύγκριση μεταξύ βελτιστοποιημένων mean-variance στρατηγικών και του απλού κανόνα $1/N$. Οι DeMiguel, Garlappi and Uppal (2009) έδειξαν ότι η πολυπλοκότητα της βελτιστοποίησης δεν αρκεί από μόνη της για να προσφέρει καλύτερη out-of-sample επίδοση. Το συμπέρασμα αυτό είναι σημαντικό για την παρούσα εργασία, γιατί εξηγεί γιατί το ισοσταθμισμένο χαρτοφυλάκιο πρέπει να υπάρχει ως σημείο αναφοράς. Αν μια σύνθετη μέθοδος δεν ξεπερνά μια απλή κατανομή, τότε η πολυπλοκότητα της μεθόδου δεν δικαιολογείται πρακτικά.

2.5.2 Case study: Empirical asset pricing via machine learning

Το δεύτερο case study αφορά τη μελέτη των Gu, Kelly and Xiu (2020), η οποία αποτελεί μία από τις πιο σημαντικές εμπειρικές εργασίες για τη χρήση μηχανικής μάθησης στην αποτίμηση

περιουσιακών στοιχείων. Η μελέτη δείχνει ότι ML μέθοδοι, ιδίως πιο ευέλικτες προσεγγίσεις, μπορούν να εντοπίσουν σχέσεις που δεν αποτυπώνονται εύκολα από γραμμικά μοντέλα. Η σύνδεση με την παρούσα εργασία είναι άμεση καθώς τα ML μοντέλα εξετάζονται όχι μόνο ως εργαλεία πρόβλεψης, αλλά ως εργαλεία που μπορούν να υποστηρίξουν οικονομικά σημαντικές επενδυτικές αποφάσεις.

2.5.3 Case study: Machine learning σε ευρωπαϊκές μετοχικές αγορές

Το τρίτο case study αφορά τη μελέτη των Drobetz and Otto (2021), η οποία εξετάζει την πρόβλεψη μετοχικών αποδόσεων στην Ευρώπη με ML μεθόδους. Η σημασία της έγκειται στο ότι δείχνει πως τα αποτελέσματα της μηχανικής μάθησης δεν πρέπει να θεωρούνται καθολικά. Η απόδοση των μοντέλων μπορεί να αλλάζει ανάλογα με την αγορά, την περίοδο, τις μεταβλητές και τη μεθοδολογία εκπαίδευσης. Για την παρούσα διπλωματική, αυτό ενισχύει την ανάγκη να παρουσιάζονται τα αποτελέσματα ως εμπειρικά ευρήματα για το συγκεκριμένο δείγμα και όχι ως γενικός κανόνας για όλες τις αγορές.

Case study	Πηγή	Κύριο εύρημα	Σύνδεση με την παρούσα εργασία
Optimal versus naive diversification	DeMiguel, Garlappi and Uppal (2009)	Ο κανόνας 1/N είναι δύσκολο να ξεπεραστεί out-of-sample λόγω σφαλμάτων εκτίμησης.	Δικαιολογεί τη χρήση Equal Weight ως απλού benchmark.
Empirical asset pricing via machine learning	Gu, Kelly and Xiu (2020)	Τα ML μοντέλα μπορούν να αξιοποιήσουν μη γραμμικότητες και μεγάλο αριθμό προβλεπτικών μεταβλητών.	Στηρίζει τη σύγκριση ML μοντέλων με παραδοσιακές μεθόδους.
European stock returns with ML	Drobetz and Otto (2021)	Η αξία του ML εξαρτάται από δεδομένα, χαρακτηριστικά και αυστηρή εκπαίδευση.	Ενισχύει την ανάγκη προσεκτικής out-of-sample αξιολόγησης.

Πίνακας 2.3: Ενδεικτικά case studies από τη σχετική εμπειρική βιβλιογραφία

Οι παραδοσιακές μέθοδοι έχουν ισχυρή θεωρητική βάση και παραμένουν χρήσιμες, ιδίως όταν εφαρμόζονται με περιορισμούς και rolling αξιολόγηση. Οι μέθοδοι μηχανικής μάθησης προσφέρουν ευελιξία και δυνατότητα εντοπισμού μη γραμμικών σχέσεων, αλλά απαιτούν προσεκτική εφαρμογή για να αποφευχθεί η υπερπροσαρμογή. Η παρούσα εργασία αξιοποιεί αυτή τη λογική και συγκρίνει τις δύο ομάδες μεθόδων σε κοινό πλαίσιο, χωρίς να θεωρεί εκ των προτέρων ότι η πιο σύνθετη μέθοδος είναι απαραίτητα η καλύτερη.

Με βάση αυτή τη βιβλιογραφική συζήτηση, η συμβολή της παρούσας ανάλυσης είναι ότι οργανώνει τη σύγκριση σε ένα ενιαίο και πρακτικό πλαίσιο. Οι μέθοδοι εφαρμόζονται στο ίδιο σύνολο διαθέσιμων αξιογράφων, στην ίδια χρονική περίοδο και με κοινά μέτρα αξιολόγησης. Έτσι, τα συμπεράσματα δεν στηρίζονται σε θεωρητική προτίμηση υπέρ κάποιας μεθόδου, αλλά στην εμπειρική συμπεριφορά των στρατηγικών. Η προσέγγιση αυτή συνδέει τη θεωρία του Markowitz και του CAPM με τις σύγχρονες ML εφαρμογές και προετοιμάζει τη μετάβαση στη μεθοδολογία του τρίτου κεφαλαίου.

Η σύγκριση παραδοσιακών και ML μεθόδων πρέπει συνεπώς να γίνει με ισορροπημένο τρόπο. Οι παραδοσιακές μέθοδοι έχουν το πλεονέκτημα της ερμηνευσιμότητας και της άμεσης σύνδεσης με τη θεωρία χαρτοφυλακίου. Οι ML μέθοδοι έχουν το πλεονέκτημα της ευελιξίας και της δυνατότητας αναγνώρισης πιο σύνθετων σχέσεων. Καμία από τις δύο κατηγορίες δεν είναι εκ των προτέρων ανώτερη. Η τελική αξιολόγηση εξαρτάται από τα δεδομένα, τον χρονικό ορίζοντα, τους περιορισμούς και τα κόστη συναλλαγών.

Ιδιαίτερο ενδιαφέρον έχει και η έννοια του χρονικού ορίζοντα. Η πρόβλεψη ημερήσιας απόδοσης είναι διαφορετικό πρόβλημα από την πρόβλεψη μηνιαίας ή τριμηνιαίας απόδοσης. Όσο μικρότερος είναι ο χρονικός ορίζοντας, τόσο μεγαλύτερος είναι συνήθως ο θόρυβος σε σχέση με τη χρήσιμη πληροφορία. Αντίθετα, μεγαλύτεροι ορίζοντες μπορεί να περιέχουν πιο σταθερές πληροφορίες, αλλά μειώνουν το πλήθος των παρατηρήσεων. Η παρούσα εργασία χρησιμοποιεί ημερήσιο στόχο και μηνιαία αναδιάρθρωση, επιλογή που είναι πρακτική για backtesting αλλά αναγνωρίζεται ως σημείο που μπορεί να επεκταθεί σε μελλοντική έρευνα.

Η βιβλιογραφία επισημαίνει επίσης τη σημασία της out-of-sample αξιολόγησης. Σε χρηματοοικονομικές εφαρμογές, ένα μοντέλο μπορεί να φαίνεται ιδιαίτερα επιτυχημένο όταν αξιολογείται στα δεδομένα εκπαίδευσης, αλλά να αποτυγχάνει όταν εφαρμόζεται σε νέες περιόδους. Αυτό συμβαίνει επειδή οι χρηματοοικονομικές χρονοσειρές είναι συχνά μη στάσιμες, δηλαδή τα στατιστικά τους χαρακτηριστικά μεταβάλλονται στο χρόνο. Η διαδικασία rolling window συνδέεται με αυτή την απαίτηση, καθώς επιτρέπει επαναλαμβανόμενη εκτίμηση και αξιολόγηση σε επόμενες περιόδους.

Η διάκριση αυτή είναι σημαντική και για την ερμηνεία των αποτελεσμάτων. Ένα ML μοντέλο μπορεί να εμφανίζει σχετικά καλό accuracy αλλά να επιλέγει αξιόγραφα που όταν τελικά

κινήθουν αρνητικά, έχουν μεγάλες απώλειες. Αντίστροφα, ένα μοντέλο με μέτριο accuracy μπορεί να είναι χρήσιμο εάν οι σωστές προβλέψεις του αντιστοιχούν σε οικονομικά σημαντικές θετικές αποδόσεις και οι λανθασμένες προβλέψεις του έχουν περιορισμένο κόστος. Επομένως, η αξιολόγηση των ML στρατηγικών δεν μπορεί να σταματά στους δείκτες ταξινόμησης. Πρέπει να ολοκληρώνεται με χαρτοφυλακιακούς δείκτες απόδοσης και κινδύνου.

Ένα ακόμη ζήτημα που προκύπτει από τη βιβλιογραφία είναι η διαφορά ανάμεσα στην πρόβλεψη και στη βελτιστοποίηση. Στα παραδοσιακά μοντέλα, η διαδικασία οδηγεί άμεσα σε βάρη χαρτοφυλακίου. Στα μοντέλα μηχανικής μάθησης, όμως, υπάρχει πρώτα ένα στάδιο πρόβλεψης και στη συνέχεια ένα στάδιο μετατροπής της πρόβλεψης σε επενδυτική απόφαση. Αυτό σημαίνει ότι η συνολική επιτυχία εξαρτάται όχι μόνο από το μοντέλο, αλλά και από τον κανόνα με τον οποίο οι προβλέψεις γίνονται κατανομή κεφαλαίου. Για αυτόν τον λόγο, στην παρούσα εργασία η επιλογή top-k χρησιμοποιείται ως καθαρός και διαφανής μηχανισμός μετατροπής των πιθανοτήτων σε χαρτοφυλάκιο.

3 ΔΕΔΟΜΕΝΑ ΚΑΙ ΜΕΘΟΔΟΛΟΓΙΑ

3.1 Εισαγωγή

Το παρόν κεφάλαιο παρουσιάζει τη μεθοδολογική προσέγγιση της εμπειρικής ανάλυσης. Η προσέγγιση αυτή δεν περιορίζεται σε μία στατική σύγκριση μοντέλων, αλλά βασίζεται σε ένα ενιαίο πλαίσιο με δοκιμές στα ιστορικά δεδομένα του δείγματος, μέσα στο οποίο οι παραδοσιακές μέθοδοι βελτιστοποίησης χαρτοφυλακίου και οι μέθοδοι μηχανικής μάθησης αξιολογούνται με τον ίδιο τρόπο. Ο σκοπός είναι η δημιουργία προβλέψεων οι οποίες μπορούν να βοηθήσουν στη λήψη επενδυτικών αποφάσεων με αποδεκτή σχέση απόδοσης και κινδύνου.

Η μεθοδολογία στηρίζεται σε τρεις βασικές αρχές

- Όλες οι στρατηγικές αξιολογούνται με τη μέθοδο rolling window. Κάθε φορά οι παράμετροι υπολογίζονται μόνο με βάση τις προηγούμενες ιστορικές τιμές κλεισίματος, δηλαδή με πληροφορίες που ήταν ήδη διαθέσιμες εκείνη τη στιγμή.
- Οι στρατηγικές συγκρίνονται στην ίδια περίοδο αξιολόγησης, ώστε να αποφεύγεται η στρέβλωση που θα προέκυπτε αν διαφορετικές μέθοδοι αξιολογούνταν σε διαφορετικά χρονικά διαστήματα.
- Η αξιολόγηση πραγματοποιείται με επενδυτικούς δείκτες όπως, η συνολική απόδοση, η ετησιοποιημένη μεταβλητότητα, το Sharpe ratio, το max drawdown, το Sortino ratio και το Calmar ratio, και όχι μόνο με δείκτες πρόβλεψης.

Η λογική της εργασίας συνδέεται άμεσα με την κλασική θεωρία χαρτοφυλακίου Markowitz (1952) η οποία έθεσε στο επίκεντρο την ταυτόχρονη αξιολόγηση αναμενόμενης απόδοσης, διακύμανσης και συνδιακύμανσης. Παράλληλα, το CAPM του Sharpe (1964) χρησιμοποιείται ως θεωρητικό υπόδειγμα που συνδέει την αναμενόμενη απόδοση ενός αξιογράφου με τον συστηματικό του κίνδυνο. Οι μέθοδοι αυτές συγκρίνονται με μεθόδους μηχανικής μάθησης οι οποίες δεν επιβάλλουν γραμμική σχέση μεταξύ χαρακτηριστικών και στόχου και μπορούν θεωρητικά, να αποτυπώσουν μη γραμμικές σχέσεις και αλληλεπιδράσεις στα δεδομένα (Gu, Kelly and Xiu, 2020).

Στην ενότητα αυτή, περιγράφονται τα δεδομένα, οι μεταβλητές, οι κατηγορίες των περιουσιακών στοιχείων, οι μέθοδοι που χρησιμοποιούνται, η διαδικασία rolling window και τα εργαλεία λογισμικού που χρησιμοποιήθηκαν. Η προσέγγιση έχει γνώμονα την πλήρη κατανόηση του αναγνώστη όσον αφορά στη λογική της διαδικασίας.

3.2 Δεδομένα και περιγραφή δείγματος

Η ανάλυση βασίζεται σε ημερήσιες προσαρμοσμένες τιμές κλεισίματος, οι οποίες περιλαμβάνονται στο συνοδευτικό αρχείο με τίτλο: *adjusted_close_5y_new.xlsx*. Η χρήση προσαρμοσμένων τιμών κλεισίματος είναι κατάλληλη για backtesting επειδή ενσωματώνει προσαρμογές που σχετίζονται με μερίσματα, splits ή άλλες εταιρικές πράξεις, επιτρέποντας πιο συνεπή υπολογισμό αποδόσεων. Η χρονική περίοδος του τελικού καθαρού δείγματος εκτείνεται από 01/10/2020 έως 29/09/2025, καλύπτοντας περίπου πέντε έτη ημερήσιων παρατηρήσεων.

Το αρχικό dataset περιείχε 1.302 γραμμές επενδυτικών προϊόντων όπου κάθε γραμμή αντιστοιχεί σε διαφορετική ημερομηνία. Μετά τον καθαρισμό, κατά τον οποίο αφαιρέθηκαν γραμμές με ελλιπείς τιμές σε ορισμένα προϊόντα, παρέμειναν 1.253 γραμμές τιμών. Συνεπώς, αφαιρέθηκαν 49 γραμμές (3,7% του δείγματος). Η απόφαση να αφαιρεθούν οι γραμμές με ελλείψεις, βασίζεται στο ότι με αυτόν τον τρόπο η εργασία αποφεύγει να εισάγει τεχνητά δεδομένα που θα μπορούσαν να επηρεάσουν τις συνδιακυμάνσεις, τις αποδόσεις και την εκπαίδευση των ML μοντέλων.

Μετά τον καθαρισμό, οι ημερήσιες αποδόσεις υπολογίζονται ως ποσοστιαίες μεταβολές των τιμών. Επειδή ο υπολογισμός ποσοστιαίας μεταβολής απαιτεί προηγούμενη τιμή, οι παρατηρήσεις ημερήσιων αποδόσεων είναι 1.252 και είναι οι αποδόσεις που αποτελούν τη βάση για τις περιγραφικές στατιστικές, τη δημιουργία χαρακτηριστικών μηχανικής μάθησης και τη rolling-window αξιολόγηση των χαρτοφυλακίων.

Το συνολικό χαρτοφυλάκιο περιλαμβάνει 24 αξιόγραφα που διαπραγματεύονται κυρίως στην αγορά των Η.Π.Α. και παρέχουν έκθεση και σε διεθνείς αγορές μέσω ETFs και συναλλαγματικών ισοτιμιών. Η σύνθεση του δείγματος περιλαμβάνει μετοχές, ETFs ομολόγων, ETFs ακινήτων, ETFs εμπορευμάτων, ETFs μετοχών διεθνών αγορών και συναλλαγματικές ισοτιμίες FOREX. Η επιλογή των συγκεκριμένων περιουσιακών στοιχείων έγινε με σκοπό τη

δημιουργία ενός διαφοροποιημένου δείγματος, το οποίο καλύπτει βασικές κατηγορίες επενδύσεων και επιτρέπει τη σύγκριση στρατηγικών χαρτοφυλακίου σε διαφορετικά προφίλ κινδύνου και απόδοσης. Συγκεκριμένα, επιλέχθηκαν μετοχές μεγάλης κεφαλαιοποίησης των Η.Π.Α., ETFs ομολόγων, ETFs ακινήτων, ETFs εμπορευμάτων, ETFs διεθνών μετοχικών αγορών και βασικές συναλλαγματικές ισοτιμίες. Η επιλογή βασίστηκε στην ευρεία χρήση και αναγνωρισιμότητα των συγκεκριμένων τίτλων, στη διαθεσιμότητα συνεχών ημερήσιων προσαρμοσμένων τιμών κλεισίματος για την περίοδο της ανάλυσης και στην ανάγκη να υπάρχουν περιουσιακά στοιχεία με διαφορετική συμπεριφορά ως προς την απόδοση, τη μεταβλητότητα και τη συσχέτιση. Με αυτόν τον τρόπο, το δείγμα δεν περιορίζεται σε μία μόνο αγορά ή κατηγορία τίτλων, αλλά επιτρέπει την αξιολόγηση των μεθόδων σε ένα πιο αντιπροσωπευτικό πλαίσιο διαφοροποιημένου χαρτοφυλακίου.

Τicker προϊόντων	Κατηγορία	Περιγραφή
AAPL	Μετοχή	Apple Inc.
MSFT	Μετοχή	Microsoft Corp.
JPM	Μετοχή	JPMorgan Chase & Co.
XOM	Μετοχή	Exxon Mobil Corp.
IEF	ETF ομολόγων	iShares 7-10 Year Treasury Bond ETF
TLT	ETF ομολόγων	iShares 20+ Year Treasury Bond ETF
LQD	ETF ομολόγων	iShares iBoxx Investment Grade Corporate Bond ETF
HYG	ETF ομολόγων	iShares iBoxx High Yield Corporate Bond ETF
VNQ	ETF ακινήτων	Vanguard Real Estate ETF
SCHH	ETF ακινήτων	Schwab U.S. REIT ETF
XLRE	ETF ακινήτων	Real Estate Select Sector SPDR Fund
IYR	ETF ακινήτων	iShares U.S. Real Estate ETF
GLD	ETF εμπορεύματος	SPDR Gold Shares
SLV	ETF εμπορεύματος	iShares Silver Trust
DBC	ETF εμπορεύματος	Invesco DB Commodity Index Tracking Fund
USO	ETF εμπορεύματος	United States Oil Fund
SPY	ETF μετοχών	SPDR S&P 500 ETF Trust
EFA	ETF μετοχών	iShares MSCI EAFE ETF
EEM	ETF μετοχών	iShares MSCI Emerging Markets ETF
IWM	ETF μετοχών	iShares Russell 2000 ETF
EURUSD=X	Συναλλαγματική ισοτιμία	EUR/USD
GBPUSD=X	Συναλλαγματική ισοτιμία	GBP/USD
JPY=X	Συναλλαγματική ισοτιμία	USD/JPY
AUDUSD=X	Συναλλαγματική ισοτιμία	AUD/USD

Πίνακας 3.1: Σύνολο επενδυτικών προϊόντων που αξιοποιήθηκαν


Η διαφοροποίηση στη δομή του δείγματος είναι σημαντική, επειδή η βελτιστοποίηση χαρτοφυλακίου βασίζεται στην αλληλεπίδραση διαφορετικών προφίλ κινδύνου και απόδοσης. Ένα χαρτοφυλάκιο που περιλαμβάνει μόνο μετοχές για παράδειγμα, θα είχε διαφορετική

συμπεριφορά από ένα χαρτοφυλάκιο που συνδυάζει μετοχές, ομόλογα, εμπορεύματα, real estate και συναλλαγματικές ισοτιμίες.

Ως δείκτης αναφοράς (benchmark) χρησιμοποιείται το SPY, δηλαδή το SPDR S&P 500 ETF Trust, ένα ETF που παρακολουθεί την πορεία του δείκτη S&P 500 και παρέχει ευρεία έκθεση στην αγορά μετοχών μεγάλης κεφαλαιοποίησης των Η.Π.Α. Στην κύρια ανάλυση το SPY περιλαμβάνεται στο χαρτοφυλάκιο και ταυτόχρονα χρησιμοποιείται ως benchmark. Η επιλογή αυτή σημειώνεται ρητά, επειδή δημιουργεί μία μεθοδολογική ιδιαιτερότητα: είναι ένα αξιόγραφο που μπορεί να επιλεγεί από τις στρατηγικές και λειτουργεί παράλληλα και ως σημείο σύγκρισης. Στην ανάλυση το θέμα αυτό αντιμετωπίζεται μέσω robustness check, όπου το SPY αφαιρείται από το χαρτοφυλάκιο και παραμένει μόνο ως benchmark.

Η επιλογή της περιόδου 2020-2025 είναι ιδιαίτερα χρήσιμη για εφαρμογή σε διπλωματική εργασία, διότι περιλαμβάνει έντονες μεταβολές στις συνθήκες αγοράς. Η περίοδος ξεκινά μετά το αρχικό σοκ της πανδημίας, περιλαμβάνει φάσεις υψηλής αβεβαιότητας, αυξημένων επιτοκίων, διακυμάνσεων σε ομόλογα και εμπορεύματα και σημαντική διαφοροποίηση μεταξύ μετοχικών και μη μετοχικών αξιογράφων. Επομένως, το δείγμα επιτρέπει να εξεταστεί πώς συμπεριφέρονται οι στρατηγικές όχι μόνο σε μία ανοδική αγορά, αλλά και σε περιβάλλοντα όπου οι σχέσεις κινδύνου και απόδοσης μεταβάλλονται.

Ενδεικτικά, παρατίθενται οι κανονικοποιημένες προσαρμοσμένες τιμές κλεισίματος των περιουσιακών στοιχείων του δείγματος εικόνα 3.1. Η κανονικοποίηση σημαίνει ότι όλες οι τιμές μετατρέπονται ώστε να ξεκινούν από την ίδια βάση, δηλαδή από την τιμή 1. Η τιμή αυτή δεν αποτελεί την πραγματική χρηματιστηριακή τιμή κάθε τίτλου, αλλά ένα κοινό σημείο εκκίνησης. Με αυτόν τον τρόπο γίνεται πιο εύκολα κατανοητό πόσο αυξήθηκε ή μειώθηκε κάθε περιουσιακό στοιχείο σε σχέση με την αρχική του τιμή. Για παράδειγμα, όταν μια γραμμή φτάνει στο 2, αυτό σημαίνει ότι η αξία της έχει διπλασιαστεί σε σχέση με την αρχή της περιόδου, ενώ όταν βρίσκεται κάτω από το 1 σημαίνει ότι έχει μειωθεί. Η διαδικασία αυτή είναι χρήσιμη προκειμένου η σύγκριση μεταβολής των προϊόντων που απαρτίζουν το δείγμα να είναι κατανοητή.



Εικόνα 3.1: Κανονικοποιημένες τιμές κλεισίματος

Η δομή του δείγματος καθιστά την εργασία πιο ουσιαστική από μια απλή εφαρμογή ταξινόμησης σε χρηματοοικονομικά δεδομένα. Επειδή το χαρτοφυλάκιο μπορεί να στραφεί ανάμεσα σε διαφορετικές κατηγορίες περιουσιακών στοιχείων, οι μέθοδοι συγκρίνονται ως προς την ικανότητά τους να διαχειρίζονται την κατανομή κεφαλαίου. Αυτό είναι ιδιαίτερα σημαντικό για τη σύγκριση παραδοσιακών και ML μεθόδων, αφού οι πρώτες αξιοποιούν άμεσα τη δομή συνδιακυμάνσεων, ενώ οι δεύτερες βασίζονται στην εκτίμηση πιθανοτήτων θετικής μελλοντικής απόδοσης.

3.3 Μεταβλητές, κατηγορίες περιουσιακών στοιχείων και δείκτες απόδοσης

Η βασική μεταβλητή που χρησιμοποιείται, είναι η ημερήσια προσαρμοσμένη τιμή κλεισίματος κάθε αξιογράφου. Από αυτές τις τιμές υπολογίζονται οι ημερήσιες αποδόσεις, οι οποίες αποτελούν το κοινό υπόβαθρο όλων των μεθόδων. Η χρήση ημερήσιων αποδόσεων επιτρέπει τη δημιουργία επαρκούς πλήθους παρατηρήσεων για το rolling-window backtest, ενώ ταυτόχρονα επιτρέπει τον υπολογισμό βραχυχρόνιων χαρακτηριστικών για τα ML μοντέλα.

Η απόδοση ενός αξιογράφου σε κάθε ημέρα υπολογίζεται ως η ποσοστιαία μεταβολή της τιμής του σε σχέση με την προηγούμενη ημέρα. Με αυτόν τον τρόπο, τα αξιόγραφα καθίστανται συγκρίσιμα ανεξάρτητα από το επίπεδο τιμής τους. Για παράδειγμα, μία μεταβολή ενός δολαρίου δεν έχει την ίδια σημασία για ένα αξιόγραφο με τιμή 20 δολάρια και

για ένα αξιόγραφο με τιμή 300 δολάρια, ενώ η ποσοστιαία μεταβολή αποτυπώνει την αναλογική μεταβολή της αξίας.

Οι ημερήσιες αποδόσεις χρησιμοποιούνται τόσο για την εκτίμηση παραδοσιακών παραμέτρων χαρτοφυλακίου όσο και για τη δημιουργία των χαρακτηριστικών των ML μοντέλων. Στις παραδοσιακές μεθόδους, η μέση απόδοση και ο πίνακας συνδιακυμάνσεων είναι οι βασικές εισροές. Στις μεθόδους μηχανικής μάθησης, οι αποδόσεις μετασχηματίζονται σε χαρακτηριστικά όπως βραχυχρόνιο momentum, κυλιόμενη μεταβλητότητα και απόσταση τιμής από κινητούς μέσους όρους.

Κατά την ανάλυση, χρησιμοποιείται μία ευρεία ομάδα δεικτών απόδοσης και κινδύνου. Συγκεκριμένα:

- Συνολική απόδοση: αποτυπώνει την τελική μεταβολή της αξίας του χαρτοφυλακίου στην περίοδο αξιολόγησης.
- Ετησιοποιημένη απόδοση: επιτρέπει συγκρισιμότητα σε ετήσια βάση, ενώ η ετησιοποιημένη μεταβλητότητα αποτελεί μέτρο συνολικού κινδύνου.
- Sharpe ratio: συνδέει την υπερβάλλουσα απόδοση με τη μεταβλητότητα και χρησιμοποιείται εκτενώς στη χρηματοοικονομική βιβλιογραφία, αν και η ερμηνεία του πρέπει να γίνεται με προσοχή όταν οι αποδόσεις δεν είναι κανονικές ή είναι συσχετισμένες (Lo, 2002).
- Max drawdown: προστίθεται επειδή η μεταβλητότητα δεν αποτυπώνει πλήρως την εμπειρία του επενδυτή. Δύο στρατηγικές μπορεί να έχουν παρόμοια ετησιοποιημένη τυπική απόκλιση αλλά πολύ διαφορετικές μέγιστες απώλειες από προηγούμενο υψηλό. Ειδικά σε επενδυτικά χαρτοφυλάκια, η διαδρομή της απόδοσης είναι σημαντική, διότι οι μεγάλες ενδιάμεσες απώλειες επηρεάζουν την ανοχή κινδύνου, τη ρευστότητα και την πρακτική εφαρμοσιμότητα της στρατηγικής.
- Sortino ratio: χρησιμοποιείται συμπληρωματικά επειδή εστιάζει στον καθοδικό κίνδυνο. Σε αντίθεση με το Sharpe ratio, το οποίο αντιμετωπίζει θετικές και αρνητικές αποκλίσεις με συμμετρικό τρόπο, το Sortino ratio τιμωρεί περισσότερο τις αρνητικές αποκλίσεις.


- Calmar ratio: συγκρίνει την ετησιοποιημένη απόδοση με το απόλυτο max drawdown και είναι χρήσιμο για τον προσδιορισμό της σχέσης τελικής απόδοσης προς τη μέγιστη ιστορική υποχώρηση.

Στο στάδιο της ανάλυσης, υπολογίζονται περιγραφικά στατιστικά για τις ημερήσιες αποδόσεις. Ενδεικτικά παρουσιάζονται πέντε αξιόγραφα (πίνακας 3.2) ως προς τη μέση ημερήσια απόδοση, την τυπική απόκλιση, την ελάχιστη και μέγιστη ημερήσια απόδοση, την ετησιοποιημένη απόδοση, την ετησιοποιημένη μεταβλητότητα και το Sharpe ratio. Η ενδεικτική αυτή παρουσίαση επιβεβαιώνει ότι τα αξιόγραφα έχουν διαφορετικά προφίλ απόδοσης και κινδύνου, στοιχείο απαραίτητο για ουσιαστική βελτιστοποίηση χαρτοφυλακίου.

Αξιόγραφο	Παρατηρήσεις	Μέση ημερήσια απόδοση	Ημερήσια τυπική απόκλιση	Ελάχιστη ημερήσια απόδοση	Μέγιστη ημερήσια απόδοση	Ετησιοποιημένη απόδοση	Ετησιοποιημένη μεταβλητότητα	Sharpe ratio
AAPL	1.252	0,001	0,018	-0,092	0,153	0,203	0,287	0,639
MSFT	1.252	0,001	0,016	-0,077	0,101	0,220	0,260	0,770
JPM	1.252	0,001	0,016	-0,075	0,135	0,296	0,253	1,094
XOM	1.252	0,001	0,018	-0,079	0,127	0,334	0,288	1,090
IEF	1.252	-0,000	0,005	-0,018	0,023	-0,020	0,077	-0,517

Πίνακας 3.2: Ενδεικτικά περιγραφικά στατιστικά για 5 αξιόγραφα

Επιπλέον, η συσχέτιση των αποδόσεων είναι εξίσου σημαντική με τη μεμονωμένη μεταβλητότητα. Στη θεωρία του Markowitz, το όφελος της διαφοροποίησης προκύπτει επειδή τα αξιόγραφα δεν κινούνται όλα απόλυτα μαζί. Ο πίνακας συσχετίσεων και το αντίστοιχο heatmap που προκύπτει από τους υπολογισμούς (εικόνα 3.2) βοηθούν να φανεί εάν υπάρχουν ομάδες αξιογράφων με έντονη θετική συσχέτιση ή εάν ορισμένες κατηγορίες, όπως ομόλογα ή εμπορεύματα, διαφοροποιούνται από τις μετοχές. Η πληροφορία αυτή είναι κρίσιμη για τις παραδοσιακές στρατηγικές που βασίζονται σε πίνακες συνδιακύμανσης.



Εικόνα 3.2: Πίνακας συσχετίσεων ημερήσιων αποδόσεων

Οι τιμές του συντελεστή συσχέτισης κυμαίνονται από -1 έως 1. Τιμές κοντά στο 1 υποδηλώνουν ισχυρή θετική συσχέτιση, δηλαδή τα δύο περιουσιακά στοιχεία τείνουν να κινούνται προς την ίδια κατεύθυνση. Τιμές γύρω από το 0 δείχνουν ασθενή ή μη γραμμική σχέση, ενώ αρνητικές τιμές υποδηλώνουν ότι τα δύο περιουσιακά στοιχεία τείνουν να κινούνται αντίθετα. Στο συγκεκριμένο heatmap, οι υψηλότερες θετικές συσχετίσεις εμφανίζονται με πιο έντονα θερμά χρώματα, ενώ η διαγώνιος λαμβάνει τιμή 1, καθώς κάθε περιουσιακό στοιχείο συσχετίζεται με τον εαυτό του.

3.4 Περιγραφή των μεθόδων

3.4.1 Παραδοσιακά Μοντέλα

Η εργασία συγκρίνει δύο διαφορετικές μεθόδους. Η πρώτη, περιλαμβάνει παραδοσιακές στρατηγικές χαρτοφυλακίου, οι οποίες στηρίζονται σε ιστορικές αποδόσεις, συνδιακυμάνσεις και στην περίπτωση του CAPM στον συστηματικό κίνδυνο ως προς τον δείκτη αναφοράς. Η δεύτερη μέθοδος περιλαμβάνει χρήση μοντέλων μηχανικής μάθησης, τα οποία εκπαιδεύονται για να εκτιμούν την πιθανότητα θετικής επόμενης ημερήσιας απόδοσης για κάθε αξιόγραφο.

Η χρήση παραδοσιακών μεθόδων είναι απαραίτητη επειδή παρέχει ένα σαφές θεωρητικό σημείο αναφοράς. Το χαρτοφυλάκιο μέγιστου Sharpe ratio (Maximum Sharpe Ratio) στο πλαίσιο της προσέγγισης μέσου-διακύμανσης (mean-variance) του Markowitz βασίζεται στην ιδέα ότι ο επενδυτής δεν ενδιαφέρεται για την απόδοση κάθε τίτλου ανεξάρτητα, αλλά για τη συμβολή του τίτλου στο συνολικό χαρτοφυλάκιο. Η προσέγγιση ελάχιστης διακύμανσης (minimum variance), από την άλλη πλευρά, εστιάζει στην ελαχιστοποίηση του κινδύνου χωρίς να δίνει κυρίαρχο ρόλο στην εκτίμηση των μέσων αποδόσεων, η οποία μπορεί να είναι ασταθής σε μικρά δείγματα.

Το ισοσταθμισμένο (Equal Weight) χαρτοφυλάκιο χρησιμοποιείται ως ένα απλό σημείο σύγκρισης. Σε αυτό, το κεφάλαιο κατανέμεται ισόποσα σε όλα τα περιουσιακά στοιχεία, χωρίς να γίνονται σύνθετοι υπολογισμοί για το ποιο αξιόγραφο θα έχει μεγαλύτερο ή μικρότερο βάρος. Παρότι είναι μια απλή στρατηγική, θεωρείται σημαντική, επειδή στην πράξη δεν είναι πάντα εύκολο να ξεπεραστεί από πιο πολύπλοκες μεθόδους. Αυτό συμβαίνει γιατί οι εκτιμήσεις για τις μελλοντικές αποδόσεις, τη μεταβλητότητα και τις σχέσεις μεταξύ των αξιογράφων μπορεί να περιέχουν σφάλματα ή αβεβαιότητα. Συνεπώς, το ισοσταθμισμένο

(Equal Weight) χαρτοφυλάκιο αποτελεί ένα χρήσιμο και αξιόπιστο benchmark για την αξιολόγηση των υπόλοιπων στρατηγικών. (DeMiguel, Garlappi and Urral, 2009).

Η στρατηγική CAPM Rolling χρησιμοποιεί την εκτίμηση beta κάθε αξιογράφου ως προς το SPY. Το CAPM υποθέτει ότι η αναμενόμενη απόδοση ενός αξιογράφου σχετίζεται με τον συστηματικό κίνδυνο και όχι με τον συνολικό κίνδυνο, καθώς ο μη συστηματικός κίνδυνος μπορεί να διαφοροποιηθεί. Παρότι η εμπειρική ισχύς του CAPM έχει δεχθεί κριτική, παραμένει βασικό υπόδειγμα στη χρηματοοικονομική εκπαίδευση και αποτελεί χρήσιμη παραδοσιακή σύγκριση για την παρούσα εργασία (Fama and French, 2004).

Στα παραδοσιακά χαρτοφυλάκια χρησιμοποιείται ο περιορισμός long-only. Αυτό σημαίνει ότι το χαρτοφυλάκιο μπορεί μόνο να αγοράζει περιουσιακά στοιχεία και όχι να παίρνει αρνητικές θέσεις, δηλαδή short selling. Επομένως, κάθε βάρος είναι θετικό ή μηδενικό και το άθροισμα όλων των βαρών ισούται με 1, δηλαδή με το 100% του διαθέσιμου κεφαλαίου. Με αυτόν τον τρόπο δεν χρησιμοποιείται μόχλευση και η κατανομή του κεφαλαίου παραμένει απλή και εύκολη στην ερμηνεία. Ο περιορισμός αυτός είναι κατάλληλος για την παρούσα εφαρμογή, καθώς αποφεύγονται υπερβολικές ή μη ρεαλιστικές κατανομές που μπορεί να προκύψουν λόγω αβεβαιότητας στις εκτιμήσεις των αποδόσεων και των κινδύνων.

3.4.2 Μοντέλα Μηχανικής Μάθησης

Οι μέθοδοι μηχανικής μάθησης χρησιμοποιούνται στην παρούσα εργασία ως μοντέλα ταξινόμησης, δηλαδή ως μέθοδοι που προσπαθούν να προβλέψουν σε ποια κατηγορία ανήκει κάθε παρατήρηση. Τα μοντέλα που χρησιμοποιούνται στην παρούσα ανάλυση είναι τα ακόλουθα:

- Decision Tree: βασίζεται σε απλούς κανόνες διαχωρισμού των δεδομένων, κάτι που το καθιστά εύκολο στην κατανόηση και στην ερμηνεία. Ωστόσο, αν το δέντρο γίνει πολύ αναλυτικό, υπάρχει κίνδυνος να προσαρμοστεί υπερβολικά στα δεδομένα εκπαίδευσης και να μην αποδίδει καλά σε νέα δεδομένα.
- Random Forest: το οποίο εισήχθη από τον Breiman (2001), αντιμετωπίζει σε μεγάλο βαθμό το πρόβλημα της βαθιάς ανάλυσης που υπάρχει στο Decision Tree, καθώς συνδυάζει πολλά διαφορετικά δέντρα απόφασης και χρησιμοποιεί στοιχεία τυχαιότητας κατά την εκπαίδευση, ώστε το τελικό αποτέλεσμα να είναι πιο σταθερό.

- Support Vector Machine (SVM): αναζητά το κατάλληλο όριο που διαχωρίζει καλύτερα τις κατηγορίες, ενώ με τη χρήση του RBF kernel μπορεί να αναγνωρίσει και πιο σύνθετες, μη γραμμικές σχέσεις στα δεδομένα (Cortes and Vapnik, 1995).
- XGBoost: αποτελεί μια σύγχρονη και ισχυρή μέθοδο που βασίζεται σε διαδοχικά δέντρα, όπου κάθε νέο δέντρο προσπαθεί να διορθώσει τα λάθη των προηγούμενων. Η μέθοδος αυτή έχει σχεδιαστεί ώστε να είναι αποδοτική και κατάλληλη για μεγάλα ή πιο απαιτητικά σύνολα δεδομένων (Chen and Guestrin, 2016).

Στην ανάλυση, τα ML μοντέλα δεν χρησιμοποιούνται για να προβλέψουν απευθείας βάρη χαρτοφυλακίου. Αντίθετα, χρησιμοποιούνται για να κατατάξουν τα αξιόγραφα με βάση την πιθανότητα θετικής επόμενης ημερήσιας απόδοσης. Σε κάθε ημερομηνία αναδιάρθρωσης επιλέγονται τα top-k αξιόγραφα, με βασική τιμή top-k ίση με 4, και σχηματίζεται ισοσταθμισμένο χαρτοφυλάκιο μεταξύ αυτών των αξιογράφων. Η επιλογή αυτή κρατά τη δημιουργία χαρτοφυλακίου απλή και απομονώνει την επίδραση της προβλεπτικής κατάταξης.

Η μετατροπή των πιθανοτήτων σε top-k ($k=4$) χαρτοφυλάκιο αποτελεί βασική επιλογή της μεθοδολογίας. Αντί οι πιθανότητες που παράγει κάθε μοντέλο να χρησιμοποιούνται απευθείας ως βάρη στο χαρτοφυλάκιο, σε κάθε χρονική στιγμή αναδιάρθρωσης επιλέγονται τα k περιουσιακά στοιχεία με τις υψηλότερες προβλεπόμενες πιθανότητες. Με τον τρόπο αυτό, κάθε μοντέλο αξιολογείται κυρίως ως προς την ικανότητά του να εντοπίζει τα αξιόγραφα που αναμένεται να έχουν σχετικά καλύτερη απόδοση. Η προσέγγιση αυτή καθιστά τη σύγκριση μεταξύ των μοντέλων πιο απλή και πιο δίκαιη, καθώς αποφεύγονται πιθανά προβλήματα από το γεγονός ότι διαφορετικά μοντέλα μπορεί να παράγουν πιθανότητες σε διαφορετική κλίμακα ή με διαφορετικό βαθμό ακρίβειας. Ωστόσο, η μέθοδος top-k βασίζεται κυρίως στη σειρά κατάταξης των αξιογράφων και όχι στο ακριβές μέγεθος των πιθανοτήτων που προβλέπει κάθε μοντέλο.

Οι παραδοσιακές μέθοδοι και τα ML μοντέλα διαφέρουν ως προς το τι βελτιστοποιούν. Το χαρτοφυλάκιο μέγιστου Sharpe ratio επιχειρεί να μεγιστοποιήσει άμεσα έναν δείκτη απόδοσης προσαρμοσμένης στον κίνδυνο. Το Minimum Variance ελαχιστοποιεί άμεσα τη μεταβλητότητα. Αντίθετα, τα ML μοντέλα βελτιστοποιούν μία συνάρτηση ταξινόμησης στο επίπεδο asset-day. Αυτή η διαφορά είναι κεντρική για την ερμηνεία των αποτελεσμάτων: ένα

μοντέλο με λίγο καλύτερο accuracy δεν είναι απαραίτητο ότι θα παράγει καλύτερο Sharpe ratio (πίνακας 3.3).

Μέθοδος	Τύπος	Ρόλος στην ανάλυση	Βασικός περιορισμός/ρύθμιση
Equal Weight Rolling	Παραδοσιακή	Ισοσταθμισμένο χαρτοφυλάκιο	Ίσο βάρος σε όλα τα αξιόγραφα
Minimum Variance Rolling	Παραδοσιακή	Ελαχιστοποίηση διακύμανσης	Long-only, βάρη αθροίζουν στη μονάδα
Maximum Sharpe Ratio Rolling	Παραδοσιακή	Μεγιστοποίηση Sharpe ratio	Risk-free rate 2%, long-only
CAPM Rolling	Παραδοσιακή	CAPM-implied expected returns	Beta ως προς SPY
Decision Tree	ML	Ταξινόμηση θετικής επόμενης απόδοσης	max_depth=5, min_samples_leaf=20
Random Forest	ML	Ensemble ταξινόμηση	n_estimators=100, max_depth=5
SVM	ML	Μη γραμμική ταξινόμηση με RBF kernel	StandardScaler + SVC probability=True
XGBoost	ML	Gradient boosting ταξινομητής	n_estimators=100, max_depth=3, learning_rate=0.05

Πίνακας 3.3: Μέθοδοι και βασικές ρυθμίσεις της ανάλυσης

Στη χρηματοοικονομική η αποτελεσματικότητα των μεθόδων ML δεν εξαρτάται μόνο από τον αλγόριθμο που χρησιμοποιείται, αλλά και από το πώς έχει στηθεί συνολικά η ανάλυση. Ιδιαίτερη σημασία έχει το πρόβλημα να είναι σωστά ορισμένο, να μην χρησιμοποιείται κατά λάθος πληροφορία από το μέλλον και η αξιολόγηση να γίνεται σε δεδομένα που δεν έχουν χρησιμοποιηθεί στην εκπαίδευση του μοντέλου, δηλαδή out-of-sample (López de Prado, 2018). Στην παρούσα εργασία, η λογική αυτή ακολουθείται μέσα από τη χρονική εκπαίδευση των μοντέλων, τη χρήση rolling windows και την αξιολόγηση όλων των στρατηγικών στην ίδια περίοδο σύγκρισης. Παράλληλα, τα αποτελέσματα εξετάζονται με προσοχή, χωρίς να θεωρείται εκ των προτέρων ότι οι μέθοδοι μηχανικής μάθησης πρέπει απαραίτητα να αποδίδουν καλύτερα από τις παραδοσιακές προσεγγίσεις.

3.5 Διαδικασία rolling window και αξιολόγηση

Η διαδικασία rolling window είναι ένα από τα πιο σημαντικά στοιχεία της παρούσας εργασίας. Σε αντίθεση με μια στατική in-sample ανάλυση, όπου τα ίδια δεδομένα χρησιμοποιούνται για εκτίμηση και αξιολόγηση, το rolling-window πλαίσιο προσομοιώνει πιο ρεαλιστικά τη διαδικασία λήψης επενδυτικών αποφάσεων. Σε κάθε ημερομηνία αναδιάρθρωσης, η στρατηγική χρησιμοποιεί μόνο τις προηγούμενες παρατηρήσεις και εφαρμόζεται στις επόμενες ημέρες.

Το βασικό παράθυρο εκτίμησης είναι 252 χρηματιστηριακές ημέρες, δηλαδή περίπου ένα ημερολογιακό έτος συναλλακτικών ημερών. Η επιλογή αυτή ισορροπεί ανάμεσα σε δύο ανάγκες. Από τη μία πλευρά, χρειάζεται αρκετή ιστορική πληροφορία για να εκτιμηθούν σταθερά μέσες αποδόσεις, μεταβλητότητες, συνδιακυμάνσεις και ML χαρακτηριστικά. Από την άλλη πλευρά, πολύ μεγάλο ιστορικό παράθυρο θα μπορούσε να κάνει τις εκτιμήσεις λιγότερο ευαίσθητες σε πρόσφατες αλλαγές του περιβάλλοντος αγοράς.

Η περίοδος αναδιάρθρωσης είναι 21 χρηματιστηριακές ημέρες, δηλαδή περίπου ένας μήνας. Αυτή η επιλογή καθιστά το backtest πρακτικά ρεαλιστικό, διότι αποφεύγει την υπερβολικά συχνή συναλλακτική δραστηριότητα που θα αύξανε τα κόστη και το θόρυβο. Παράλληλα, επιτρέπει στις στρατηγικές να αναπροσαρμόζονται αρκετά συχνά ώστε να ανταποκρίνονται σε μεταβολές της αγοράς.

Για τις παραδοσιακές στρατηγικές, σε κάθε rebalance date χρησιμοποιούνται οι προηγούμενες 252 ημερήσιες αποδόσεις. Από αυτές εκτιμώνται ο πίνακας συνδιακυμάνσεων, οι μέσες αποδόσεις ή τα beta ανάλογα με τη μέθοδο. Τα βάρη που προκύπτουν εφαρμόζονται στην επόμενη περίοδο διακράτησης. Η διαδικασία επαναλαμβάνεται σε όλο το δείγμα, παράγοντας σειρά ημερήσιων αποδόσεων για κάθε στρατηγική.

Για τα ML χαρτοφυλάκια εφαρμόζεται ειδική χρονική σύμβαση για την αποφυγή look-ahead bias. Σε κάθε ημερομηνία αναδιάρθρωσης t , το μοντέλο εκπαιδεύεται χρησιμοποιώντας δεδομένα έως το $t-2$, χρησιμοποιεί τα χαρακτηριστικά της ημέρας $t-1$ ως σήμα πρόβλεψης και σχηματίζει χαρτοφυλάκιο στην ημέρα t . Σκοπός αυτής της προσέγγισης είναι η αποφυγή της χρήσης χαρακτηριστικών ή στόχων από την ίδια ή μελλοντική ημέρα κάτι το οποίο θα δημιουργούσε μη ρεαλιστικά αποτελέσματα.

Η κύρια περίοδος αξιολόγησης των παραδοσιακών στρατηγικών ξεκινά στις 04/10/2021 και ολοκληρώνεται στις 29/09/2025, με 1.000 παρατηρήσεις ημερήσιων αποδόσεων. Τα monthly-rebalanced ML χαρτοφυλάκια ξεκινούν στις 05/10/2021 και ολοκληρώνονται στις 29/09/2025, με 999 παρατηρήσεις. Για την τελική σύγκριση, όλες οι στρατηγικές ευθυγραμμίζονται στην κοινή περίοδο 05/10/2021 έως 29/09/2025.

Η αξιολόγηση δεν περιορίζεται στο τελικό cumulative return. Η εργασία εξετάζει ταυτόχρονα μεταβλητότητα, drawdown, Sharpe ratio, Sortino ratio και Calmar ratio. Αυτή η πολυδιάστατη

αξιολόγηση είναι αναγκαία, επειδή οι στρατηγικές μπορεί να παρουσιάζουν διαφορετικά trade-offs. Μία στρατηγική μπορεί να έχει υψηλότερη συνολική απόδοση, αλλά και σημαντικά υψηλότερη μεταβλητότητα ή βαθύτερο drawdown. Αντίστοιχα, μία στρατηγική χαμηλού κινδύνου μπορεί να έχει χαμηλή απόδοση αλλά καλύτερη συμπεριφορά σε περιόδους πτώσης.

Το notebook περιλαμβάνει επίσης ανάλυση κόστους συναλλαγών με διαφορετικά σενάρια. Η ενσωμάτωση των transaction costs κάνει την αξιολόγηση πιο ρεαλιστική, καθώς κάθε αναδιάρθρωση του χαρτοφυλακίου μπορεί να συνεπάγεται κόστος. Αυτό είναι ιδιαίτερα σημαντικό για στρατηγικές με υψηλό turnover, οι οποίες αλλάζουν συχνά θέσεις. Επομένως, μια στρατηγική που φαίνεται αποδοτική πριν από τα κόστη μπορεί να εμφανίσει χαμηλότερη απόδοση μετά την εφαρμογή τους, ειδικά στην περίπτωση των ML top-k στρατηγικών.

Παράμετρος	Τιμή στο notebook	Σημασία
Rolling window	252 χρηματιστηριακές ημέρες	Περίπου ένα έτος ιστορικής εκτίμησης
Rebalance period	21 χρηματιστηριακές ημέρες	Περίπου μηνιαία αναδιάρθρωση
Trading days για ετησιοποίηση	252	Μετατροπή ημερήσιων μεγεθών σε ετήσια
Risk-free rate	2% ετησίως	Υπολογισμός υπερβάλλουσας απόδοσης
Default top-k	4 assets	Επιλογή των τεσσάρων υψηλότερων ML σημάτων
Κοινή περίοδος σύγκρισης	05/10/2021 - 29/09/2025	Ενιαία βάση αξιολόγησης
Αριθμός στρατηγικών	9	4 παραδοσιακές, 4 ML και SPY Buy & Hold

Πίνακας 3.4: Βασικές παράμετροι rolling-window αξιολόγησης

3.6 Εργαλεία και λογισμικό

Η εμπειρική ανάλυση υλοποιείται σε Python μέσω Jupyter Notebook. Η επιλογή αυτή είναι κατάλληλη για ερευνητικές εφαρμογές portfolio optimization, διότι συνδυάζει κώδικα, αποτελέσματα, πίνακες, γραφήματα και επεξηγηματικό κείμενο στο ίδιο περιβάλλον. Με αυτόν τον τρόπο, η διαδικασία παραμένει αναπαραγώγιμη και μπορεί να ελεγχθεί.

Η βιβλιοθήκη pandas χρησιμοποιείται για τη φόρτωση και τον χειρισμό των δεδομένων. Στο notebook χρησιμοποιείται για την ανάγνωση του dataset, τη διαχείριση ημερομηνιών, τον υπολογισμό αποδόσεων, τη δημιουργία πινάκων αποτελεσμάτων και την αποθήκευση outputs. Η pandas είναι κατάλληλη για τέτοιου είδους εργασίες επειδή παρέχει δομές δεδομένων όπως DataFrame και εργαλεία χρονοσειρών (pandas documentation, 2026).

Η βιβλιοθήκη NumPy χρησιμοποιείται για αριθμητικούς υπολογισμούς, διανυσματικές πράξεις, υπολογισμό βαρών και υποστήριξη των μαθηματικών συναρτήσεων που απαιτούνται

στη βελτιστοποίηση. Η βιβλιοθήκη αποτελεί βασικό υπόβαθρο επιστημονικού υπολογισμού στην Python και παρέχει αποτελεσματικές πράξεις πινάκων και arrays (NumPy documentation, 2026).

Η βιβλιοθήκη `scipy.optimize` χρησιμοποιείται για την επίλυση των προβλημάτων βελτιστοποίησης του χαρτοφυλακίου ελάχιστης διακύμανσης (Minimum Variance) και του χαρτοφυλακίου μέγιστου Sharpe ratio (Maximum Sharpe Ratio). Η βελτιστοποίηση χαρτοφυλακίου περιλαμβάνει περιορισμούς, όπως μη αρνητικά βάρη και άθροισμα βαρών ίσο με ένα, οπότε απαιτείται αριθμητικός αλγόριθμος που μπορεί να χειριστεί `constrained optimization`.

Η βιβλιοθήκη `scikit-learn` χρησιμοποιείται στην εργασία για την εφαρμογή βασικών μοντέλων μηχανικής μάθησης, όπως το Decision Tree, το Random Forest και το SVM. Επιπλέον, αξιοποιείται για την προεπεξεργασία των δεδομένων, κυρίως μέσω του `StandardScaler`, ο οποίος φέρνει τα χαρακτηριστικά σε κοινή κλίμακα, καθώς και για την εξαγωγή διαγνωστικών μέτρων ταξινόμησης. Ιδιαίτερα στην περίπτωση του SVM, η χρήση Pipeline εξασφαλίζει ότι η κανονικοποίηση των χαρακτηριστικών γίνεται με τον ίδιο τρόπο τόσο κατά την εκπαίδευση όσο και κατά την πρόβλεψη. Με αυτόν τον τρόπο αποφεύγονται ασυνέπειες στη διαδικασία και η εφαρμογή του μοντέλου γίνεται πιο σωστά και οργανωμένα. (scikit-learn documentation, 2026).

Το XGBoost χρησιμοποιείται για την υλοποίηση gradient boosting ταξινομητή. Η βιβλιοθήκη έχει σχεδιαστεί για αποδοτική εκπαίδευση δέντρων ενίσχυσης και χρησιμοποιείται ευρέως σε προβλήματα supervised learning. Στο notebook το XGBoost εφαρμόζεται με περιορισμένο βάθος δέντρων και learning rate 0,05, ώστε να αποφευχθεί υπερβολική προσαρμογή στο ιστορικό δείγμα (XGBoost documentation, 2026).

Η `matplotlib` χρησιμοποιείται για την παραγωγή όλων των διαγραμμάτων που ενσωματώνονται στην εργασία. Τα διαγράμματα αποθηκεύονται από το notebook και εμφανίζονται ως outputs, γεγονός που επιτρέπει τη χρήση τους στο τελικό κείμενο χωρίς να δημιουργηθούν νέα γραφήματα. Αυτό είναι σημαντικό για τη συνέπεια μεταξύ notebook και γραπτής διπλωματικής.

Το notebook οργανώνει τα outputs σε φακέλους για figures, Excel tables, CSV tables, diagnostics, main results, transaction costs, robustness checks και audit outputs.

Εργαλείο/βιβλιοθήκη	Χρήση στο notebook
Python / Jupyter Notebook	Ενιαίο περιβάλλον κώδικα, τεκμηρίωσης και αποτελεσμάτων
pandas	Φόρτωση δεδομένων, καθαρισμός, αποδόσεις, πίνακες αποτελεσμάτων
NumPy	Αριθμητικοί υπολογισμοί και πράξεις πινάκων
matplotlib	Δημιουργία και αποθήκευση διαγραμμάτων
scipy.optimize	Βελτιστοποίηση παραδοσιακών χαρτοφυλακίων
scikit-learn	Decision Tree, Random Forest, SVM, preprocessing και metrics
XGBoost	Gradient boosting ταξινομητής
pathlib / os	Διαχείριση φακέλων και αποθήκευση outputs

Πίνακας 3.5: Εργαλεία και βιβλιοθήκες λογισμικού

4 ΑΠΟΤΕΛΕΣΜΑΤΑ

4.1 Εισαγωγή

Το Κεφάλαιο 4 παρουσιάζει και ερμηνεύει τα εμπειρικά αποτελέσματα του notebook. Η ανάλυση οργανώνεται σε τέσσερα επίπεδα:

- αποδόσεις και οι δείκτες κινδύνου ανά μοντέλο
- συγκριτική αξιολόγηση των στρατηγικών
- ερμηνεία των διαφορών μεταξύ παραδοσιακών και ML μεθόδων
- σχολιασμός των διαγραμμάτων που παράγονται από το notebook

Η παρουσίαση των αποτελεσμάτων ακολουθεί την αρχή ότι η καλύτερη στρατηγική δεν είναι απαραίτητα αυτή με τη μεγαλύτερη συνολική απόδοση. Σε εφαρμογή επενδυτικών αποφάσεων, η απόδοση πρέπει να αξιολογείται σε σχέση με τον κίνδυνο, τη μεταβλητότητα, το drawdown και τη σταθερότητα της πορείας του χαρτοφυλακίου. Για τον λόγο αυτό, το Sharpe ratio έχει κεντρικό ρόλο, αλλά δεν χρησιμοποιείται μόνο του. Η αξιολόγηση συμπληρώνεται με δείκτες όπως το Sortino ratio, το Calmar ratio, καθώς και με στατιστικά χαρακτηριστικά της κατανομής των αποδόσεων όπως η ασυμμετρία (skewness) και η κύρτωση (kurtosis), ώστε να υπάρχει πιο ολοκληρωμένη εικόνα για τη συμπεριφορά των στρατηγικών. Οι δείκτες αυτοί δεν εξετάζουν μόνο τη μέση απόδοση ή τον συνολικό κίνδυνο, αλλά βοηθούν να φανεί καλύτερα πόσο έντονες είναι οι απώλειες, πόσο μεγάλες είναι οι διακυμάνσεις και αν οι αποδόσεις παρουσιάζουν ακραίες τιμές. Όλα τα αποτελέσματα που ακολουθούν προέρχονται από το Jupiter notebook.

4.2 Υπολογισμός αποδόσεων και κινδύνου ανά μοντέλο

Η πρώτη ομάδα αποτελεσμάτων αφορά στις παραδοσιακές στρατηγικές χαρτοφυλακίου. Οι στρατηγικές αυτές είναι:

- Ισοσταθμισμένο Χαρτοφυλάκιο (Equal Weight Rolling)
- Χαρτοφυλάκιο ελάχιστης διακύμανσης (Minimum Variance Rolling)
- Μέγιστο Sharpe ratio (Maximum Sharpe Ratio Rolling)
- CAPM Rolling

Η αξιολόγηση τους βασίζεται στη σειρά ημερήσιων αποδόσεων που προκύπτει από το rolling-window backtest. Τα αποτελέσματα των παραδοσιακών στρατηγικών παρουσιάζονται συγκριτικά στον ενιαίο Πίνακα 4.1, μαζί με τις ML στρατηγικές και το SPY.

Η στρατηγική μέγιστου Sharpe ratio (Maximum Sharpe Ratio Rolling) εμφανίζει το υψηλότερο Sharpe ratio μεταξύ των παραδοσιακών στρατηγικών. Αυτό είναι μεθοδολογικά αναμενόμενο, επειδή η στρατηγική έχει σχεδιαστεί ώστε να μεγιστοποιεί ακριβώς τη σχέση μέγιστης απόδοσης προς κίνδυνο. Ωστόσο, το γεγονός ότι παραμένει ισχυρή και στην out-of-sample rolling αξιολόγηση είναι σημαντικό, καθώς οι mean-variance μέθοδοι είναι συχνά ευαίσθητες σε σφάλματα εκτίμησης των αναμενόμενων αποδόσεων, της μεταβλητότητας και των συνδιακυμάνσεων.

Η στρατηγική Minimum Variance Rolling έχει τη χαμηλότερη μεταβλητότητα και το μικρότερο max drawdown. Αυτό δείχνει ότι πετυχαίνει τον βασικό στόχο της, δηλαδή την ελαχιστοποίηση κινδύνου. Παράλληλα όμως, η συνολική και ετησιοποιημένη απόδοσή της είναι χαμηλή, με αποτέλεσμα το Sharpe ratio να μην είναι ανταγωνιστικό έναντι των καλύτερων στρατηγικών. Αυτό δείχνει ότι η υπερβολική έμφαση στη μείωση κινδύνου μπορεί να οδηγήσει σε περιορισμένη απόδοση.

Η στρατηγική Equal Weight Rolling παρουσιάζει ενδιάμεση συμπεριφορά. Δεν απαιτεί εκτίμηση μέσων αποδόσεων ή βελτιστοποίηση, όμως προσφέρει διαφοροποίηση σε όλο το προς επένδυση χαρτοφυλάκιο. Ως benchmark, δείχνει τι μπορεί να προκύψει από μια απλή και διαφανή κατανομή χωρίς σύνθετες παραδοχές.

Η στρατηγική CAPM Rolling εμφανίζει χαμηλότερη επίδοση από τη στρατηγική μέγιστου Sharpe ratio (Maximum Sharpe Ratio Rolling) και την ισοσταθμισμένη στρατηγική (Equal Weight Rolling), και άρα η χρήση CAPM-implied αποδόσεων στο συγκεκριμένο πλαίσιο δεν οδηγεί στην καλύτερη τελική σχέση απόδοσης-κινδύνου.

Η δεύτερη ομάδα αποτελεσμάτων αφορά στα ML χαρτοφυλάκια. Σε αυτές τις στρατηγικές, τα μοντέλα δεν προβλέπουν απευθείας την απόδοση χαρτοφυλακίου, αλλά επιλέγουν αξιόγραφα με βάση την πιθανότητα θετικής επόμενης ημερήσιας απόδοσης. Τα αποτελέσματα των ML στρατηγικών παρουσιάζονται στον ενιαίο συγκριτικό Πίνακα 4.1, ώστε να είναι άμεσα συγκρίσιμα με τις παραδοσιακές στρατηγικές και το SPY.

Μεταξύ των ML στρατηγικών, το SVM Monthly ML παρουσιάζει την καλύτερη συνολική επίδοση ενώ το Sharpe ratio ανέρχεται σε 0,581. Ωστόσο, η ετησιοποιημένη μεταβλητότητα του SVM είναι αρκετά υψηλότερη από την αντίστοιχη μεταβλητότητα της στρατηγικής μέγιστου Sharpe ratio (Maximum Sharpe Ratio Rolling).

Το Random Forest και το Decision Tree εμφανίζουν μέτριες επιδόσεις. Καμία από τις δύο στρατηγικές δεν παράγει καλύτερο Sharpe ratio από το SVM στο συγκεκριμένο backtest. Το Decision Tree έχει παρόμοια συνολική απόδοση με το CAPM Rolling, αλλά η μεταβλητότητά του είναι υψηλότερη. Το XGBoost παρουσιάζει την ασθενέστερη επίδοση μεταξύ των ML στρατηγικών, με πολύ χαμηλό Sharpe ratio και υψηλό max drawdown.

Τα αποτελέσματα αυτά επιβεβαιώνουν ότι η μεγαλύτερη αλγοριθμική πολυπλοκότητα δεν εγγυάται καλύτερη επενδυτική επίδοση. Το XGBoost είναι ένα ισχυρό μοντέλο για πολλά προβλήματα, όμως στην παρούσα εφαρμογή η διαθέσιμη πληροφορία, ο ορίζοντας πρόβλεψης και η top-k διαδικασία δεν οδήγησαν σε ανώτερη απόδοση.

4.3 Συγκριτική ανάλυση αποτελεσμάτων

Η κύρια σύγκριση πραγματοποιείται στον ενιαίο πίνακα (πίνακας 4.1) στρατηγικών, όπου όλες οι αποδόσεις έχουν ευθυγραμμιστεί στην κοινή περίοδο 05/10/2021 έως 29/09/2025. Η συνολική απόδοση αφορά τη σωρευτική απόδοση κάθε στρατηγικής σε ολόκληρη την κοινή περίοδο αξιολόγησης ενώ η ασυμμετρία (skewness) και η κύρτωση (kurtosis) υπολογίζονται από την κατανομή των ημερήσιων αποδόσεων κάθε στρατηγικής στην ίδια περίοδο. Η ύπαρξη κοινής περιόδου είναι κρίσιμη, διότι επιτρέπει άμεση σύγκριση μεταξύ παραδοσιακών στρατηγικών, ML στρατηγικών και του benchmark SPY.

Στρατηγική	Συνολική απόδοση	Ετησιοποιημένη απόδοση	Ετησιοποιημένη μεταβλητότητα	Sharpe ratio	Max drawdown	Sortino ratio	Calmar ratio	Skewness	Kurtosis
Maximum Sharpe Ratio Rolling	0,486	0,105	0,091	0,935	-0,122	1,474	0,861	-0,530	2,846
SPY (Benchmark)	0,638	0,133	0,180	0,625	-0,245	1,020	0,541	0,364	9,193
SVM Monthly ML	0,494	0,106	0,149	0,581	-0,207	1,034	0,515	0,111	3,179
Equal Weight Rolling	0,351	0,079	0,106	0,556	-0,165	1,025	0,478	0,067	5,462
CAPM Rolling	0,311	0,071	0,114	0,446	-0,194	0,778	0,365	-0,841	4,268
Random Forest Monthly ML	0,342	0,077	0,159	0,359	-0,215	0,679	0,359	0,448	9,682

Decision Tree Monthly ML	0,312	0,071	0,144	0,354	-0,198	0,735	0,357	0,269	4,125
Minimum Variance Rolling	0,120	0,029	0,040	0,225	-0,054	0,978	0,535	-0,571	2,827
XGBoost Monthly ML	0,099	0,024	0,165	0,025	-0,248	0,194	0,097	0,285	14,797

Πίνακας 4.1: Κύρια σύγκριση δεικτών απόδοσης, κινδύνου και χαρακτηριστικών κατανομής όλων των στρατηγικών

Η στρατηγική μέγιστου Sharpe ratio (Maximum Sharpe Ratio Rolling) είναι η καλύτερη συνολικά με Sharpe ratio 0,935. Η επίδοση αυτή υπερβαίνει όχι μόνο τις ML στρατηγικές, αλλά και το SPY Buy & Hold. Αυτό σημαίνει ότι η στρατηγική δεν έχει την υψηλότερη συνολική απόδοση, αλλά προσφέρει την καλύτερη σχέση απόδοσης προς μεταβλητότητα στην κοινή περίοδο αξιολόγησης.

Το SPY Buy & Hold έχει την υψηλότερη συνολική απόδοση, ίση με 0,638, και ετησιοποιημένη απόδοση 0,133. Ωστόσο, η ετησιοποιημένη μεταβλητότητά του είναι 0,180 και το max drawdown -0,245. Αυτό μας δείχνει ότι η παθητική έκθεση στην αμερικανική αγορά ήταν αποδοτική στην περίοδο εξέτασης, αλλά συνοδεύτηκε από υψηλότερο κίνδυνο σε σχέση με τη στρατηγική μέγιστου Sharpe ratio (Maximum Sharpe Ratio Rolling).

Το SVM Monthly ML είναι η καλύτερη ML στρατηγική και βρίσκεται πολύ κοντά στη στρατηγική Maximum Sharpe Ratio Rolling ως προς τη συνολική απόδοση. Η συνολική του απόδοση είναι 0,494, λίγο μεγαλύτερη από τη συνολική απόδοση 0,486 της στρατηγικής μέγιστου Sharpe ratio. Ωστόσο, το Sharpe ratio του SVM είναι 0,581, πολύ χαμηλότερο από το 0,935 της στρατηγικής μέγιστου Sharpe ratio. Η διαφορά αυτή οφείλεται κυρίως στη μεγαλύτερη μεταβλητότητα του SVM.

Η σύγκριση δείχνει ότι το ερώτημα δεν είναι αν το ML μπορεί να παράγει απόδοση, αλλά αν μπορεί να παράγει ανώτερη προσαρμοσμένη στον κίνδυνο απόδοση. Στο συγκεκριμένο δείγμα, η απάντηση είναι ότι το SVM είναι ανταγωνιστικό σε απόλυτη απόδοση, αλλά δεν υπερέχει σε risk-adjusted όρους. Τα υπόλοιπα ML μοντέλα υστερούν περισσότερο, είτε λόγω χαμηλότερης απόδοσης είτε λόγω υψηλότερης μεταβλητότητας και drawdown.

Η Minimum Variance Rolling στρατηγική έχει τη χαμηλότερη μεταβλητότητα και το μικρότερο max drawdown. Αυτή η στρατηγική μπορεί να θεωρηθεί πιο αμυντική επιδιώκοντας σταθερότητα με μικρή απόδοση. Η ύπαρξή της στο σύνολο στρατηγικών είναι χρήσιμη, επειδή

δείχνει ότι διαφορετικές μέθοδοι εξυπηρετούν διαφορετικούς επενδυτικούς στόχους. Ένας επενδυτής που δίνει απόλυτη προτεραιότητα στη μείωση κινδύνου μπορεί να αξιολογούσε τη Minimum Variance διαφορετικά από έναν επενδυτή που επιδιώκει μέγιστο Sharpe ratio.

Ο Πίνακας 4.2 παρουσιάζει τους διαγνωστικούς δείκτες ταξινόμησης των μοντέλων μηχανικής μάθησης. Οι δείκτες αυτοί χρησιμοποιούνται για να αξιολογηθεί πόσο καλά κάθε μοντέλο προβλέπει τη σωστή κατηγορία της επόμενης ημερήσιας απόδοσης. Στην παρούσα ανάλυση, η μεταβλητή στόχος λαμβάνει δύο τιμές: target = 1 όταν η επόμενη απόδοση ενός περιουσιακού στοιχείου είναι θετική και target = 0 όταν δεν είναι θετική. Επομένως, η θετική κλάση αντιστοιχεί στις περιπτώσεις όπου το target ισούται με 1. Η ακρίβεια ταξινόμησης (Accuracy) δείχνει το συνολικό ποσοστό σωστών προβλέψεων. Η θετική ακρίβεια (Precision) δείχνει πόσες από τις προβλέψεις του μοντέλου για θετική επόμενη απόδοση ήταν πράγματι σωστές. Η ανάκληση (Recall) δείχνει πόσες από τις πραγματικές περιπτώσεις θετικής επόμενης απόδοσης κατάφερε να εντοπίσει το μοντέλο. Ο δείκτης F1 (F1-score) συνδυάζει τη θετική ακρίβεια και την ανάκληση και παρέχει μια συνολική εικόνα της ικανότητας του μοντέλου να αναγνωρίζει σωστά τη θετική κλάση. Το πραγματικό ποσοστό θετικής κλάσης δείχνει το ποσοστό των περιπτώσεων στο δείγμα αξιολόγησης όπου η επόμενη ημερήσια απόδοση ήταν όντως θετική. Το προβλεπόμενο ποσοστό θετικής κλάσης δείχνει το ποσοστό των περιπτώσεων στις οποίες το μοντέλο προέβλεψε θετική επόμενη απόδοση. Η σύγκριση των δύο αυτών ποσοστών βοηθά να φανεί αν ένα μοντέλο τείνει να προβλέπει συχνότερα ή σπανιότερα θετικές αποδόσεις σε σχέση με τις πραγματικές. Οι δείκτες αυτοί δεν αξιολογούν άμεσα την επενδυτική απόδοση, αλλά την ικανότητα στατιστικής ταξινόμησης των ML μοντέλων.

Μοντέλο	Accuracy	Precision θετικής κλάσης	Recall θετικής κλάσης	F1 θετικής κλάσης	Πραγματικό ποσοστό θετικής κλάσης	Προβλεπόμενο ποσοστό θετικής κλάσης	Αριθμός προβλέψεων	Ημερομηνίες rebalancing
Decision Tree	0,532	0,502	0,598	0,546	0,470	0,560	1.152	48
Random Forest	0,499	0,475	0,603	0,531	0,470	0,598	1.152	48
SVM	0,528	0,499	0,618	0,552	0,470	0,583	1.152	48
XGBoost	0,529	0,499	0,638	0,560	0,470	0,602	1.152	48

Πίνακας 4.2: Διαγνωστικός έλεγχος ταξινόμησης ML μοντέλων

Τα αποτελέσματα του Πίνακα 4.2 δείχνουν ότι οι διαφορές μεταξύ των ML μοντέλων είναι σχετικά περιορισμένες ως προς την ακρίβεια ταξινόμησης, αλλά διαφοροποιούνται ως προς τη

θετική ακρίβεια (precision), την ανάκληση (recall) και τον δείκτη F1. Το Decision Tree εμφανίζει την υψηλότερη ακρίβεια ταξινόμησης, ίση με 0,532. Αυτό σημαίνει ότι είχε το μεγαλύτερο συνολικό ποσοστό σωστών προβλέψεων μεταξύ των ML μοντέλων. Ωστόσο, η επενδυτική του επίδοση δεν είναι η καλύτερη μεταξύ των ML στρατηγικών, γεγονός που δείχνει ότι η μεγαλύτερη στατιστική ακρίβεια δεν οδηγεί απαραίτητα σε καλύτερο επενδυτικό αποτέλεσμα.

Το Random Forest εμφανίζει ακρίβεια ταξινόμησης 0,499, δηλαδή χαμηλότερη από τα υπόλοιπα μοντέλα, αλλά παρουσιάζει ανάκληση θετικής κλάσης 0,603. Αυτό σημαίνει ότι το μοντέλο αναγνωρίζει αρκετές από τις περιπτώσεις όπου η επόμενη απόδοση είναι θετική. Ωστόσο, η ικανότητα αυτή δεν μεταφράζεται απαραίτητα σε αποτελεσματικότερο χαρτοφυλάκιο, επειδή δεν έχει σημασία μόνο αν η πρόβλεψη είναι σωστή, αλλά και πόσο μεγάλη είναι η απόδοση ή η απώλεια που ακολουθεί.

Το SVM εμφανίζει ακρίβεια ταξινόμησης 0,528 και δείκτη F1 ίσο με 0,552. Παρότι δεν έχει την υψηλότερη ακρίβεια ταξινόμησης, παρουσιάζει την καλύτερη επενδυτική επίδοση μεταξύ των ML στρατηγικών. Το αποτέλεσμα αυτό δείχνει ότι στην εφαρμογή, η ποιότητα ενός ML μοντέλου δεν μπορεί να αξιολογηθεί μόνο με διαγνωστικούς δείκτες ταξινόμησης. Δεν αρκεί το μοντέλο να κάνει σωστές προβλέψεις, σημασία έχει οι σωστές επιλογές να δίνουν αρκετά καλές αποδόσεις και οι λάθος επιλογές να μη δημιουργούν μεγάλες απώλειες.

Το XGBoost εμφανίζει ακρίβεια ταξινόμησης 0,529, την υψηλότερη ανάκληση θετικής κλάσης, ίση με 0,638, και τον υψηλότερο δείκτη F1, ίσο με 0,560. Παρότι το μοντέλο έχει σχετικά καλά αποτελέσματα στους δείκτες ταξινόμησης, η στρατηγική που βασίζεται σε αυτό έχει τη χαμηλότερη επενδυτική επίδοση μεταξύ των ML μοντέλων. Αυτό δείχνει ότι ένα μοντέλο μπορεί να εντοπίζει πολλές περιπτώσεις θετικής επόμενης απόδοσης, χωρίς οι προβλέψεις αυτές να οδηγούν απαραίτητα σε καλύτερη σχέση απόδοσης και κινδύνου σε επίπεδο χαρτοφυλακίου.

Συνολικά η σχέση μεταξύ ταξινόμησης και επενδυτικής επίδοσης δεν είναι γραμμική. Υποθέτοντας ενδεικτικά το classification error ως $1 - \text{Accuracy}$, τότε τα σφάλματα των μοντέλων μηχανικής μάθησης κυμαίνονται περίπου από 46,8% έως 50,1%. Με άλλα λόγια, τα μοντέλα κάνουν αρκετά συχνά λανθασμένες ταξινομήσεις, γεγονός που δείχνει πόσο δύσκολη είναι η πρόβλεψη των ημερήσιων αποδόσεων. Αυτό είναι αναμενόμενο σε χρηματοοικονομικά δεδομένα, καθώς οι αγορές περιέχουν πολύ «θόρυβο», οι χρήσιμες

πληροφορίες είναι συχνά δύσκολο να διακριθούν στις καθημερινές διακυμάνσεις της αγοράς και οι σχέσεις μεταξύ των μεταβλητών μπορεί να αλλάζουν με τον χρόνο. Επομένως, τα αποτελέσματα πρέπει να ερμηνεύονται με προσοχή και να αξιολογούνται αυστηρά εκτός δείγματος, χωρίς να βασίζονται μόνο σε υψηλές επιδόσεις μέσα στο δείγμα εκπαίδευσης (Bailey et al., 2014).

4.4 Ερμηνεία διαφορών μεταξύ παραδοσιακών και ML μεθόδων

Η βασική διαφορά μεταξύ των παραδοσιακών μεθόδων και των μεθόδων μηχανικής μάθησης είναι το τι προσπαθεί να πετύχει κάθε προσέγγιση. Οι παραδοσιακές μέθοδοι δουλεύουν απευθείας πάνω στο χαρτοφυλάκιο και προσπαθούν να βρουν την κατανομή των βαρών που μειώνει τον κίνδυνο ή βελτιώνει τη σχέση απόδοσης-κινδύνου, όπως για παράδειγμα το Sharpe ratio. Αντίθετα, τα μοντέλα μηχανικής μάθησης δεν υπολογίζουν απευθείας τα βάρη του χαρτοφυλακίου. Πρώτα προσπαθούν να προβλέψουν, σε επίπεδο κάθε αξιογράφου και κάθε ημέρας, αν η επόμενη απόδοση θα ανήκει στη θετική κλάση. Στη συνέχεια, οι προβλέψεις αυτές πρέπει να μετατραπούν σε επενδυτική απόφαση, δηλαδή σε επιλογή αξιογράφων και σε κατανομή χαρτοφυλακίου. Επομένως, υπάρχει ένα επιπλέον στάδιο μεταξύ της πρόβλεψης και της τελικής στρατηγικής. Σε αυτό το στάδιο, μέρος της πληροφορίας που παράγει το μοντέλο μπορεί να μην αξιοποιηθεί πλήρως.

Η στρατηγική Maximum Sharpe Ratio Rolling επωφελείται από το ότι η αντικειμενική της συνάρτηση είναι ευθυγραμμισμένη με τον δείκτη αξιολόγησης. Εφόσον το τελικό κριτήριο είναι το Sharpe ratio, μια στρατηγική που αναζητά άμεσα υψηλό Sharpe ratio έχει φυσικό πλεονέκτημα. Βέβαια, αυτό δεν εγγυάται out-of-sample επιτυχία. Το γεγονός ότι η στρατηγική παραμένει πρώτη στην κοινή περίοδο δείχνει ότι, στο συγκεκριμένο δείγμα, οι εκτιμήσεις του rolling window παρείχαν επαρκώς χρήσιμη πληροφορία για την κατανομή βαρών.

Τα ML μοντέλα αντιμετωπίζουν δύο πρόσθετες δυσκολίες. Η πρώτη είναι η πρόβλεψη της ημερήσιας κατεύθυνσης, η οποία είναι ιδιαίτερα θορυβώδης. Η δεύτερη είναι η χρονική απόκλιση μεταξύ στόχου και διακράτησης. Το target του notebook αφορά την επόμενη ημερήσια απόδοση, ενώ το χαρτοφυλάκιο διακρατείται για 21 χρηματιστηριακές ημέρες. Αυτή η ασυμφωνία αποτελεί σημαντικό περιορισμό και πιθανή εξήγηση για το γιατί η προβλεπτική ικανότητα δεν μεταφράζεται πάντα σε ανώτερο Sharpe ratio.

Το SVM φαίνεται να λειτουργήσει καλύτερα όσον αφορά στο μη γραμμικό έλεγχο στο συγκεκριμένο σύνολο. Επίσης, η καλύτερη συνολική απόδοση του SVM συνοδεύεται από υψηλή μεταβλητότητα και βαθύ drawdown. Αυτό δείχνει ότι το μοντέλο μπορεί να επέλεξε αξιόγραφα με ισχυρότερη πιθανότητα απόδοσης, αλλά και μεγαλύτερο κίνδυνο.

Το Random Forest δεν υπερείχε παρά τη θεωρητική του ανθεκτικότητα. Μία πιθανή ερμηνεία, με βάση αποκλειστικά τη δομή της παρούσας ανάλυσης, είναι ότι τα διαθέσιμα χαρακτηριστικά και το μέγεθος του rolling window δεν ήταν αρκετά για να αξιοποιήσει πλήρως το ensemble πλεονέκτημά του. Επίσης, επειδή το μοντέλο εφαρμόζεται επαναλαμβανόμενα σε μικρά rolling datasets, η σταθερότητα των προβλέψεων μπορεί να επηρεάζεται από την περιορισμένη παρελθοντική πληροφορία.

Το XGBoost είχε τη χαμηλότερη επενδυτική επίδοση, παρά το γεγονός ότι γενικά θεωρείται ισχυρή μέθοδος. Αυτό μας οδηγεί στο συμπέρασμα ότι ένα ισχυρό machine learning εργαλείο δεν αποδίδει αυτόματα σε κάθε χρηματοοικονομικό πρόβλημα. Η επιτυχία εξαρτάται από τον ορισμό του στόχου, τη σχέση στόχου και επενδυτικού ορίζοντα, το πλήθος δεδομένων, την επιλογή χαρακτηριστικών και την προσαρμογή όλων των παραμέτρων.

Το SPY (benchmark) έχει την υψηλότερη συνολική απόδοση, αλλά όχι το καλύτερο Sharpe ratio. Αυτό δείχνει ότι σε ανοδικό περιβάλλον, η απλή παθητική έκθεση μπορεί να κερδίσει σε απόλυτη απόδοση. Παρ' όλα αυτά, μια βελτιστοποιημένη στρατηγική μπορεί να έχει καλύτερο προφίλ κινδύνου.

Η ανάλυση transaction costs προσθέτει μια ακόμη διάσταση στην ερμηνεία. Οι ML στρατηγικές που αλλάζουν συχνά top-k αξιόγραφα έχουν πιθανώς υψηλότερο turnover. Αν το κόστος συναλλαγών αυξηθεί, το πλεονέκτημα τους μπορεί να μειωθεί. Αντίθετα, στρατηγικές με πιο σταθερά βάρη ή χαμηλότερο turnover είναι περισσότερο ανθεκτικές σε κόστη.

Συνολικά, στο συγκεκριμένο δείγμα, με τα συγκεκριμένα χαρακτηριστικά, το συγκεκριμένο target και το συγκεκριμένο top-k σχήμα, οι ML μέθοδοι δεν ξεπέρασαν την καλύτερη παραδοσιακή στρατηγική σε όρους Sharpe ratio.

Η παρούσα ανάλυση αναδεικνύει ότι η βελτιστοποίηση χαρτοφυλακίου με τις παραδοσιακές μεθόδους παραμένει ισχυρή όταν εφαρμόζεται με rolling-window πειθαρχία και κατάλληλους περιορισμούς. Παράλληλα, δείχνει ότι τα ML μοντέλα μπορούν να προσφέρουν ανταγωνιστικά


σήματα, ιδίως στην περίπτωση του SVM, αλλά χρειάζονται προσεκτικό σχεδιασμό και αξιολόγηση.

4.5 Οπτικοποίηση αποτελεσμάτων και ανάλυση

Για την πληρέστερη κατανόηση των αποτελεσμάτων, η ανάλυση συμπληρώνεται με διαγράμματα σωρευτικών αποδόσεων τα οποία απεικονίζουν την πορεία των στρατηγικών κατά την εξεταζόμενη περίοδο.

4.5.1 Διάγραμμα 4.1

Παρουσιάζονται οι σωρευτικές αποδόσεις των παραδοσιακών στρατηγικών. Η σύγκριση δείχνει τη σχετική πορεία των στρατηγικών Equal Weight, Minimum Variance, Maximum Sharpe Ratio και CAPM Rolling. Η Minimum Variance έχει πιο ομαλή συμπεριφορά, αλλά περιορισμένη ανοδική δυναμική. Η στρατηγική Maximum Sharpe Ratio εμφανίζει καλύτερη ισορροπία μεταξύ ανόδου και ελεγχόμενου κινδύνου.




Εικόνα 4.1: Διάγραμμα σωρευτικών αποδόσεων παραδοσιακών στρατηγικών

4.5.2 Διάγραμμα 4.2

Παρουσιάζονται οι σωρευτικές αποδόσεις των ML στρατηγικών από όπου διαφαίνεται ότι οι ML στρατηγικές δεν κινούνται όλες με τον ίδιο τρόπο. Το SVM ξεχωρίζει θετικά, ενώ το XGBoost υστερεί σε σχέση με τα υπόλοιπα μοντέλα. Η διαφορά αυτή επιβεβαιώνει ότι τα ML μοντέλα δεν πρέπει να αντιμετωπίζονται ως ενιαία κατηγορία. Κάθε αλγόριθμος έχει


διαφορετικές ιδιότητες και διαφορετική ευαισθησία στα χαρακτηριστικά και στο μέγεθος του δείγματος.



Εικόνα 4.2: Διάγραμμα σωρευτικών αποδόσεων ML στρατηγικών

4.5.3 Διάγραμμα 4.3


Παρουσιάζονται και συγκρίνονται όλες οι βασικές στρατηγικές μαζί με το benchmark SPY. Η συνύπαρξη παραδοσιακών, ML και benchmark στρατηγικών στο ίδιο γράφημα καθιστά ορατό το trade-off μεταξύ απόλυτης απόδοσης και ομαλότητας. Η υψηλή τελική επίδοση του SPY πρέπει να ερμηνευθεί μαζί με τη μεγαλύτερη μεταβλητότητα και το drawdown του, ενώ η στρατηγική Maximum Sharpe Ratio εμφανίζεται πιο αποτελεσματική με βάση την προσαρμογή στον κίνδυνο.



Εικόνα 4.3: Διάγραμμα σωρευτικής απόδοσης όλων των στρατηγικών

4.5.4 Διάγραμμα 4.4

Παρουσιάζεται η επίδραση των transaction costs στο Sharpe ratio. Η σημασία του διαγράμματος είναι η σύζευξη της θεωρητικής απόδοσης στην πρακτική εφαρμογή. Σε πραγματικές συνθήκες, κάθε συναλλαγή συνεπάγεται πρόσθετο κόστος. Επομένως, στρατηγικές με υψηλότερο turnover μπορεί να χάσουν μέρος της ελκυστικότητάς τους όταν εφαρμοστούν κόστη συναλλαγών.



Εικόνα 4.4: Διάγραμμα σύγκρισης Sharpe ratio υπό διαφορετικά κόστη συναλλαγών

Συμπληρωματικά, πραγματοποιείται ανάλυση ευαισθησίας (sensitivity analysis) ως προς τα κόστη συναλλαγών. Στόχος είναι να εξεταστεί κατά πόσο τα βασικά αποτελέσματα των

στρατηγικών παραμένουν σταθερά όταν μεταβάλλεται το κόστος συναλλαγών. Ο Πίνακας 4.3 παρουσιάζει τα αριθμητικά αποτελέσματα για τρία εναλλακτικά σενάρια κόστους, 0,05%, 0,10% και 0,20%, και δείχνει πώς μεταβάλλονται η συνολική απόδοση, η ετησιοποιημένη απόδοση, η ετησιοποιημένη μεταβλητότητα, το Sharpe ratio και το max drawdown.

Κόστος συναλλαγών	Στρατηγική	Συνολική απόδοση	Ετησιοποιημένη απόδοση	Ετησιοποιημένη μεταβλητότητα	Sharpe ratio	Max drawdown
0,05%	Equal Weight Rolling	0,351	0,079	0,106	0,556	-0,165
0,05%	Minimum Variance Rolling	0,116	0,028	0,040	0,206	-0,054
0,05%	Maximum Sharpe Ratio Rolling	0,471	0,102	0,091	0,904	-0,124
0,05%	CAPM Rolling	0,304	0,069	0,114	0,433	-0,195
0,05%	Decision Tree Monthly ML	0,275	0,063	0,144	0,300	-0,201
0,05%	Random Forest Monthly ML	0,293	0,067	0,159	0,296	-0,218
0,05%	SVM Monthly ML	0,438	0,096	0,149	0,510	-0,210
0,05%	XGBoost Monthly ML	0,061	0,015	0,165	-0,030	-0,267
0,05%	SPY Buy & Hold	0,638	0,133	0,180	0,625	-0,245
0,10%	Equal Weight Rolling	0,351	0,079	0,106	0,556	-0,165
0,10%	Minimum Variance Rolling	0,113	0,027	0,040	0,187	-0,055
0,10%	Maximum Sharpe Ratio Rolling	0,456	0,099	0,091	0,872	-0,126
0,10%	CAPM Rolling	0,296	0,068	0,114	0,419	-0,197
0,10%	Decision Tree Monthly ML	0,239	0,056	0,144	0,247	-0,204
0,10%	Random Forest Monthly ML	0,246	0,057	0,159	0,233	-0,222
0,10%	SVM Monthly ML	0,385	0,086	0,149	0,440	-0,213
0,10%	XGBoost Monthly ML	0,024	0,006	0,165	-0,084	-0,285
0,10%	SPY Buy & Hold	0,638	0,133	0,180	0,625	-0,245
0,20%	Equal Weight Rolling	0,351	0,079	0,106	0,556	-0,165
0,20%	Minimum Variance Rolling	0,107	0,026	0,040	0,115	-0,056
0,20%	Maximum Sharpe Ratio Rolling	0,426	0,094	0,091	0,810	-0,129
0,20%	CAPM Rolling	0,281	0,064	0,114	0,391	-0,199
0,20%	Decision Tree Monthly ML	0,170	0,040	0,144	0,142	-0,210
0,20%	Random Forest Monthly ML	0,157	0,038	0,160	0,109	-0,243
0,20%	SVM Monthly ML	0,284	0,065	0,150	0,301	-0,219
0,20%	XGBoost Monthly ML	-0,045	-0,012	0,166	-0,191	-0,319
0,20%	SPY Buy & Hold	0,638	0,133	0,180	0,625	-0,245

Πίνακας 4.3: Ανάλυση ευαισθησίας αποτελεσμάτων υπό διαφορετικά κόστη συναλλαγών

Η σημασία του κόστους συναλλαγών συνδέεται και με τη μελέτη των Chen et al. (2020), οι οποίοι εξετάζουν πώς η ύπαρξη κόστους συναλλαγών μπορεί να επηρεάσει τη διαδικασία βελτιστοποίησης χαρτοφυλακίου. Η μελέτη τους δείχνει ότι όταν λαμβάνονται υπόψη τα κόστη συναλλαγών, οι συχνές ή μεγάλες αλλαγές στη σύνθεση του χαρτοφυλακίου μπορεί να περιορίσουν την τελική απόδοση. Στην παρούσα εργασία, τα κόστη συναλλαγών εξετάζονται μέσω ανάλυσης ευαισθησίας, ώστε να αξιολογηθεί αν η επίδοση των στρατηγικών παραμένει σταθερή όταν λαμβάνεται υπόψη ένα πιο ρεαλιστικό κόστος από τις αλλαγές στη σύνθεση του χαρτοφυλακίου.

Συμπερασματικά, η τελική εικόνα από τους πίνακες και τα διαγράμματα είναι συνεπής. Το SPY ως benchmark υπερέχει σε συνολική απόδοση, η στρατηγική Maximum Sharpe Ratio υπερέχει σε Sharpe ratio, και το SVM υπερέχει συγκριτικά με τα υπόλοιπα ML μοντέλα.

4.6 Σύγκριση των ευρημάτων με προηγούμενες εμπειρικές μελέτες

Η σύγκριση των αποτελεσμάτων της παρούσας εργασίας με προηγούμενες εμπειρικές μελέτες δείχνει ότι τα ευρήματα κινούνται σε λογική κατεύθυνση και δεν αποκλίνουν από τη σχετική βιβλιογραφία. Ένα βασικό συμπέρασμα της ανάλυσης είναι ότι οι πιο σύνθετες μέθοδοι δεν οδηγούν απαραίτητα σε καλύτερη επενδυτική επίδοση. Στην παρούσα εργασία, η στρατηγική μέγιστου Sharpe ratio εμφανίζει ισχυρή επίδοση σε όρους σχέσης απόδοσης και κινδύνου, ενώ τα μοντέλα μηχανικής μάθησης παρέχουν χρήσιμη πληροφόρηση, χωρίς όμως να υπερέχουν σταθερά έναντι των παραδοσιακών στρατηγικών.

Το εύρημα αυτό συνδέεται με τη μελέτη των DeMiguel, Garlappi and Uppal (2009), οι οποίοι έδειξαν ότι η απλή στρατηγική $1/N$ μπορεί να είναι δύσκολο να ξεπεραστεί σε out-of-sample αξιολόγηση. Η σημασία της μελέτης αυτής είναι ότι αναδεικνύει πως τα πιο σύνθετα μοντέλα βελτιστοποίησης επηρεάζονται έντονα από τα σφάλματα εκτίμησης των αναμενόμενων αποδόσεων και των συνδιακυμάνσεων. Για τον λόγο αυτό, το ισοσταθμισμένο χαρτοφυλάκιο δεν αποτελεί απλώς μια απλή βάση σύγκρισης, αλλά ένα ουσιαστικό benchmark για την αξιολόγηση πιο σύνθετων στρατηγικών.

Αντίστοιχα, οι Hwang, Xu and In (2018) εξετάζουν τη σύγκριση μεταξύ naive και optimal diversification, δίνοντας έμφαση όχι μόνο στην απόδοση αλλά και στον κίνδυνο ακραίων απωλειών. Η προσέγγιση αυτή συνδέεται με την παρούσα εργασία, καθώς η αξιολόγηση των στρατηγικών δεν βασίζεται μόνο στη συνολική απόδοση, αλλά και σε δείκτες κινδύνου όπως η μεταβλητότητα, το max drawdown, το Sortino ratio και το Calmar ratio. Με αυτόν τον τρόπο, η τελική εικόνα κάθε στρατηγικής προκύπτει από τον συνδυασμό απόδοσης και κινδύνου και όχι μόνο από το τελικό αποτέλεσμα.

Η εικόνα που προκύπτει από την παρούσα εργασία είναι πιο συγκρατημένη σε σύγκριση με τα ευρήματα των Gu, Kelly and Xiu (2020), οι οποίοι δείχνουν ότι τα μοντέλα μηχανικής μάθησης μπορούν να έχουν σημαντική αξία στο empirical asset pricing. Η διαφοροποίηση αυτή μπορεί να εξηγηθεί από το μικρότερο δείγμα της παρούσας ανάλυσης, το διαφορετικό σύνολο περιουσιακών στοιχείων, τον ημερήσιο στόχο πρόβλεψης και τον απλό κανόνα top-k που χρησιμοποιείται για τη μετατροπή των προβλέψεων σε χαρτοφυλάκιο. Επομένως, τα αποτελέσματα δείχνουν ότι η πρόβλεψη με τη χρήση μοντέλων μηχανικής μάθησης δε σημαίνει αυτομάτως και καλύτερη κατανομή χαρτοφυλακίου, καθώς η υπεροχή τους δεν

μπορεί να θεωρηθεί δεδομένη σε κάθε δείγμα ή χρονική περίοδο, αλλά εξαρτάται από τα δεδομένα, τη μεθοδολογία και τον τρόπο με τον οποίο οι προβλέψεις μετατρέπονται σε βάρη χαρτοφυλακίου.

Παρόμοια ερμηνεία προκύπτει και από τη μελέτη των Drobetz and Otto (2021), οι οποίοι εξετάζουν τη χρήση μηχανικής μάθησης στην ευρωπαϊκή μετοχική αγορά. Η μελέτη τους δείχνει ότι η αποτελεσματικότητα των μοντέλων μηχανικής μάθησης εξαρτάται από την αγορά, τα χαρακτηριστικά των δεδομένων, τη διαδικασία εκπαίδευσης και τον έλεγχο υπερπροσαρμογής. Όπως και στην παρούσα ανάλυση, τα μοντέλα μηχανικής μάθησης δεν αξιολογούνται μόνο ως εργαλεία πρόβλεψης, αλλά κυρίως ως εργαλεία που πρέπει να οδηγήσουν σε πρακτικές επενδυτικές αποφάσεις.

Η ανάγκη προσεκτικής αξιολόγησης ενισχύεται και από τη βιβλιογραφία για το backtesting. Οι Bailey et al. (2015) επισημαίνουν ότι μια στρατηγική μπορεί να φαίνεται επιτυχημένη σε ιστορικά δεδομένα, χωρίς απαραίτητα να έχει πραγματική προβλεπτική αξία. Αντίστοιχα, οι Arnott, Harvey and Markowitz (2019) τονίζουν ότι στην εποχή της μηχανικής μάθησης απαιτείται αυστηρό πλαίσιο αξιολόγησης των επενδυτικών στρατηγικών. Για τον λόγο αυτό, στην παρούσα ανάλυση εφαρμόζεται rolling-window διαδικασία, ώστε τα μοντέλα να αξιολογούνται με βάση πληροφορίες που θα ήταν διαθέσιμες τη στιγμή λήψης της επενδυτικής απόφασης.

Συνολικά, τα αποτελέσματα της εργασίας δείχνουν ότι οι παραδοσιακές μέθοδοι παραμένουν ισχυρές και ερμηνεύσιμες, ενώ τα μοντέλα μηχανικής μάθησης μπορούν να λειτουργήσουν συμπληρωματικά. Η βασική διαπίστωση δεν είναι ότι η μία κατηγορία μεθόδων είναι απόλυτα καλύτερη από την άλλη, αλλά ότι η αποτελεσματικότητα κάθε στρατηγικής εξαρτάται από τα δεδομένα, τον χρονικό ορίζοντα, τον τρόπο μετατροπής των προβλέψεων σε βάρη χαρτοφυλακίου και την αυστηρότητα της αξιολόγησης. Έτσι, τα ευρήματα της παρούσας εργασίας ενισχύουν την ανάγκη για προσεκτική χρήση των μοντέλων μηχανικής μάθησης στη διαχείριση χαρτοφυλακίου, ιδιαίτερα όταν αυτά συγκρίνονται με απλές και καλά θεμελιωμένες παραδοσιακές στρατηγικές.

5 ΣΥΜΠΕΡΑΣΜΑΤΑ ΚΑΙ ΠΡΟΤΑΣΕΙΣ

5.1 Συμπεράσματα

Η παρούσα εργασία εξέτασε τη συγκριτική αποτελεσματικότητα παραδοσιακών μεθόδων βελτιστοποίησης χαρτοφυλακίου και μεθόδων μηχανικής μάθησης σε ένα κοινό rolling-window περιβάλλον. Η ανάλυση βασίστηκε σε ημερήσιες προσαρμοσμένες τιμές κλεισίματος για 24 αξιόγραφα για την περίοδο από 01/10/2020 έως 29/09/2025. Οι στρατηγικές αξιολογήθηκαν στην ίδια περίοδο 05/10/2021 έως 29/09/2025, ώστε η σύγκριση να είναι χρονικά συνεπής.

Το βασικό συμπέρασμα είναι ότι η στρατηγική Maximum Sharpe Ratio Rolling προσφέρει την καλύτερη σχέση απόδοσης-κινδύνου στο συγκεκριμένο δείγμα. Με Sharpe ratio 0,935, υπερέχει όλων των ML στρατηγικών καθώς επίσης και του SPY που ορίστηκε ως benchmark. Αυτό το αποτέλεσμα δείχνει ότι η κλασική mean-variance λογική, όταν εφαρμόζεται με rolling-window διαδικασία, και κοινό πλαίσιο αξιολόγησης, μπορεί να παραμείνει εξαιρετικά ανταγωνιστική.

Το SPY ως benchmark πέτυχε την υψηλότερη συνολική απόδοση, ίση με 0,638. Ωστόσο, η υψηλή αυτή απόδοση συνοδεύτηκε από μεγαλύτερη ετησιοποιημένη μεταβλητότητα και μεγαλύτερο max drawdown. Η διάκριση αυτή είναι κομβικής σημασίας καθώς αν ο στόχος ήταν αποκλειστικά η τελική απόδοση, το SPY θα ήταν η καλύτερη επιλογή. Στην παρούσα ανάλυση όμως που ο στόχος είναι η βελτιστοποίηση χαρτοφυλακίου με βάση την απόδοση ανά μονάδα κινδύνου, η στρατηγική Maximum Sharpe Ratio Rolling είναι ισχυρότερη.

Από τις ML στρατηγικές, το SVM Monthly ML υπερείχε. Η συνολική του απόδοση ήταν 0,494 και η ετησιοποιημένη του απόδοση 0,106. Παρ' όλα αυτά, το Sharpe ratio του ήταν χαμηλότερο από της στρατηγικής Maximum Sharpe Ratio Rolling. Το αποτέλεσμα αυτό δείχνει ότι το SVM μοντέλο είχε χρήσιμο επενδυτικό σήμα, αλλά η υψηλότερη μεταβλητότητα περιορίσε την προσαρμοσμένη στον κίνδυνο επίδοσή του.

Τα Decision Tree και Random Forest παρουσίασαν μέτριες επιδόσεις, ενώ το XGBoost είχε την ασθενέστερη επίδοση. Το γεγονός αυτό έχει ιδιαίτερη σημασία, επειδή δείχνει ότι η χρήση ισχυρότερων ή πιο σύνθετων ML αλγορίθμων δε συνεπάγεται αυτόματα καλύτερο

αποτέλεσμα. Σε χρηματοοικονομικά δεδομένα, η ποιότητα των χαρακτηριστικών, ο ορίζοντας πρόβλεψης, το μέγεθος του δείγματος και ο τρόπος μετατροπής προβλέψεων σε χαρτοφυλάκιο είναι εξίσου σημαντικά με την επιλογή του αλγορίθμου.

Οι δείκτες ταξινόμησης έδειξαν ότι τα ML μοντέλα έχουν περιορισμένη ικανότητα πρόβλεψης, με accuracy κοντά στο 50% κάτι το οποίο δείχνει τη δυσκολία του προβλήματος. Η πρόβλεψη της επόμενης ημερήσιας απόδοσης είναι ένα από τα πιο θορυβώδη προβλήματα στη χρηματοοικονομική. Ακόμη και μικρή βελτίωση πρόβλεψης μπορεί να έχει αξία, αλλά δεν είναι βέβαιο ότι θα μεταφραστεί σε καλύτερο χαρτοφυλάκιο.

Ένα σημαντικό εύρημα είναι η απόκλιση ανάμεσα στην επίδοση πρόβλεψης και στην επενδυτική επίδοση. Το μοντέλο με το υψηλότερο accuracy δεν ήταν το μοντέλο με την καλύτερη επενδυτική απόδοση. Αυτό υπογραμμίζει ότι σε εργασίες portfolio optimization η αξιολόγηση των ML μοντέλων πρέπει να γίνεται λαμβάνοντας υπόψη και επενδυτικά κριτήρια και όχι μόνο με δείκτες ταξινόμησης. Η ερώτηση δεν είναι μόνο αν το μοντέλο προβλέπει σωστά, αλλά αν οι προβλέψεις του δημιουργούν χαρτοφυλάκιο με καλύτερη σχέση απόδοσης-κινδύνου.

Η ανάλυση για τα κόστη συναλλαγών δείχνει ότι η πρακτική εφαρμοσιμότητα των στρατηγικών εξαρτάται και από το turnover. Στρατηγικές που απαιτούν συχνές αλλαγές θέσεων είναι πιο ευαίσθητες στα κόστη συναλλαγών. Η συμπερίληψη αυτής της διάστασης καθιστά τα συμπεράσματα πιο ρεαλιστικά και αποτρέπει την υπερεκτίμηση στρατηγικών που φαίνονται ελκυστικές μόνο πριν από τα κόστη.

Συμπερασματικά, οι μέθοδοι μηχανικής μάθησης έχουν ενδιαφέρον και μπορούν να προσφέρουν ανταγωνιστικά σήματα πρόβλεψης, όπως φαίνεται από την περίπτωση του SVM. Ωστόσο, στο συγκεκριμένο dataset και με τη συγκεκριμένη μεθοδολογία, δεν ξεπέρασαν την καλύτερη παραδοσιακή στρατηγική σε όρους Sharpe ratio. Η κλασική αριστοποίηση δεν πρέπει να θεωρείται ξεπερασμένη αλλά αντίθετα να παραμένει ισχυρό εργαλείο όταν εφαρμόζεται με προσοχή και ελέγχεται.

5.2 Περιορισμοί της ανάλυσης και ερμηνευτικές προφυλάξεις

Παρότι τα αποτελέσματα είναι καθαρά και η μεθοδολογία οργανωμένη, η ανάλυση πρέπει να ερμηνευθεί υπό συγκεκριμένους περιορισμούς.

- Ο πρώτος περιορισμός αφορά το μέγεθος και τη σύνθεση του επιλεγμένου dataset. Το δείγμα περιλαμβάνει 24 αξιόγραφα τα οποία καλύπτουν διαφορετικές κατηγορίες περιουσιακών στοιχείων, αλλά δεν αντικατοπτρίζουν το σύνολο της αγοράς. Συνεπώς, τα συμπεράσματα αφορούν στο συγκεκριμένο χαρτοφυλάκιο και δεν πρέπει να γενικεύονται μηχανικά σε κάθε πιθανό χαρτοφυλάκιο.
- Ο δεύτερος περιορισμός αφορά στην περίοδο (2020-2025) που επιλέχθηκε. Η περίοδος αυτή είναι χρήσιμη επειδή περιλαμβάνει σημαντικές μεταβολές στην αγορά, αλλά παραμένει πενταετής. Τα αποτελέσματα θα μπορούσαν να διαφοροποιηθούν αν η ανάλυση κάλυπτε μεγαλύτερο ιστορικό δείγμα, διαφορετικό καθεστώς επιτοκίων ή περισσότερους οικονομικούς κύκλους. Για παράδειγμα, μια στρατηγική που αποδίδει καλά σε περίοδο ισχυρής μετοχικής αγοράς μπορεί να συμπεριφερθεί διαφορετικά σε παρατεταμένη ύφεση ή σε αγορά όπου οι συσχετίσεις μεταξύ αξιογράφων αυξάνονται απότομα.
- Ο τρίτος περιορισμός αφορά στον ορίζοντα πρόβλεψης των ML μοντέλων. Το target ορίζεται ως η κατεύθυνση της επόμενης ημερήσιας απόδοσης, ενώ το χαρτοφυλάκιο διακρατείται για περίπου έναν μήνα. Η επιλογή αυτή είναι λειτουργική και επιτρέπει επαρκές πλήθος παρατηρήσεων για ταξινόμηση, αλλά δημιουργεί απόσταση μεταξύ του σήματος και της επενδυτικής περιόδου. Επομένως, η μέτρια επίδοση των ML μοντέλων δεν πρέπει να ερμηνευθεί ως αδυναμία των αλγορίθμων.
- Ο τέταρτος περιορισμός αφορά στα χαρακτηριστικά. Τα χαρακτηριστικά που χρησιμοποιούνται είναι τεχνικά και βασίζονται κυρίως σε ιστορικές αποδόσεις, μεταβλητότητα, momentum, κινητούς μέσους όρους και συμπεριφορά του SPY ως ορισθέν benchmark. Δεν ενσωματώνονται μακροοικονομικές μεταβλητές, θεμελιώδη στοιχεία, αποτιμήσεις ή δείκτες ρευστότητας. Αυτό κάνει το μοντέλο καθαρό και αναπαραγωγίσιμο, αλλά περιορίζει το εύρος πληροφορίας που μπορεί να αξιοποιήσει η μηχανική μάθηση.

- Ο πέμπτος περιορισμός αφορά τη διαδικασία επιλογής top-k. Η επιλογή των τεσσάρων αξιογράφων με την υψηλότερη προβλεπόμενη πιθανότητα θετικής απόδοσης είναι απλή και διαφανής, αλλά δεν λαμβάνει υπόψη τη συσχέτιση μεταξύ των επιλεγμένων αξιογράφων, ούτε το μέγεθος της αναμενόμενης απόδοσης, ούτε τη διακύμανση κάθε αξιογράφου. Συνεπώς, ένα ML μοντέλο μπορεί να επιλέξει αξιόγραφα με υψηλή πιθανότητα θετικής απόδοσης αλλά ταυτόχρονα υψηλή μεταβλητότητα ή μεγάλη μεταξύ τους συσχέτιση. Αυτό εξηγεί γιατί ένα ML χαρτοφυλάκιο μπορεί να έχει καλή συνολική απόδοση αλλά χαμηλότερο Sharpe ratio.
- Ο έκτος περιορισμός αφορά την ερμηνεία του Sharpe ratio. Αν και το Sharpe ratio είναι ο κεντρικός δείκτης σύγκρισης, δεν είναι τέλειο μέτρο κινδύνου. Υποθέτει ότι η μεταβλητότητα είναι κατάλληλη σύνοψη του κινδύνου και μπορεί να επηρεαστεί από μη κανονικότητα, ασυμμετρία, υπερβάλλουσα κύρτωση ή αυτοσυσχέτιση αποδόσεων. Για τον λόγο αυτό, στην παρούσα ανάλυση το Sharpe ratio συμπληρώνεται με max drawdown, Sortino ratio, Calmar ratio, skewness και kurtosis. Η πολυμετρική αξιολόγηση μειώνει τον κίνδυνο λανθασμένου συμπεράσματος από έναν μόνο δείκτη.
- Ο έβδομος περιορισμός αφορά την απουσία φορολογικών επιπτώσεων, bid-ask spreads ανά αξιόγραφο και περιορισμών ρευστότητας. Η ανάλυση κόστους συναλλαγών βελτιώνει την έλλειψη των παραπάνω, αλλά δεν μπορεί να θεωρηθεί ως ένα πλήρες μοντέλο. Σε πραγματικές συνθήκες, το κόστος συναλλαγής δεν είναι ίδιο για όλα τα αξιόγραφα και μπορεί να αυξάνεται σε περιόδους πίεσης στην αγορά. Επομένως, η εφαρμογή των στρατηγικών σε πραγματικό χαρτοφυλάκιο θα απαιτούσε πρόσθετη προσαρμογή.

Η εργασία απαντά στο ερώτημα που θέτει με βάση το συγκεκριμένο dataset, τις συγκεκριμένες παραμέτρους και τη συγκεκριμένη διαδικασία backtesting. Δεν ισχυρίζεται ότι δίνει καθολική απάντηση για κάθε αγορά ή κάθε ML μοντέλο. Η ισχυρότερη συμβολή της παρούσας ανάλυσης είναι ότι δημιουργεί ένα συγκρίσιμο πλαίσιο. Μέσα σε αυτό το πλαίσιο, η παραδοσιακή βελτιστοποίηση και η μηχανική μάθηση αξιολογούνται με τους ίδιους κανόνες και στην ίδια περίοδο. Αυτό επιτρέπει το ασφαλές συμπέρασμα ότι η μηχανική μάθηση έχει δυνατότητες, αλλά δεν αρκεί να εφαρμοστεί μηχανικά σε χρηματοοικονομικές χρονοσειρές.

Χρειάζεται σωστή διατύπωση στόχου, πειθαρχημένη χρονική αξιολόγηση και σύνδεση της πρόβλεψης με τον τελικό επενδυτικό δείκτη.

5.3 Προτάσεις για μελλοντική έρευνα

Μία πρώτη κατεύθυνση μελλοντικής έρευνας αφορά στην επέκταση της χρονικής περιόδου που επιλέχθηκε. Παρότι η περίοδος 2020-2025 είναι πλούσια σε γεγονότα αγοράς, παραμένει σχετικά περιορισμένη για να εξαχθούν πλήρως γενικευμένα συμπεράσματα. Μεγαλύτερο ιστορικό δείγμα θα επέτρεπε αξιολόγηση σε περισσότερους κύκλους αγοράς, συμπεριλαμβανομένων περιόδων διαφορετικών επιτοκίων, πληθωρισμού και μακροοικονομικών συνθηκών.

Μία δεύτερη επέκταση αφορά στον ορισμό της μεταβλητής στόχου των ML μοντέλων. Στην παρούσα ανάλυση ο στόχος είναι η θετική επόμενη ημερήσια απόδοση. Μελλοντικά, θα μπορούσε να εξεταστεί target που ευθυγραμμίζεται με τον ορίζοντα διακράτησης των 21 ημερών, όπως η σωρευτική απόδοση του επόμενου μήνα ή η σχετική κατάταξη των αξιογράφων στην επόμενη περίοδο. Αυτό θα μείωνε την απόκλιση μεταξύ πρόβλεψης και επενδυτικής απόφασης.

Μία τρίτη κατεύθυνση είναι η συστηματικότερη βελτιστοποίηση παραμέτρων. Στην παρούσα εργασία χρησιμοποιούνται προκαθορισμένες ρυθμίσεις μοντέλων με στόχο την απλότητα και τη συγκρισιμότητα. Μελλοντική εργασία θα μπορούσε να εφαρμόσει χρονικά ορθή διαδικασία validation, όπως nested rolling validation ή purged cross-validation, ώστε να αναζητηθούν καλύτερες παράμετροι.

Επιπλέον, θα μπορούσε να εμπλουτιστεί το σύνολο χαρακτηριστικών. Τα χαρακτηριστικά της παρούσας ανάλυσης βασίζονται σε αποδόσεις, μεταβλητότητα, momentum, κινητούς μέσους και μεταβλητές αγοράς. Σε επόμενη εργασία, θα μπορούσαν να προστεθούν μακροοικονομικές μεταβλητές, spreads ομολόγων ή factor exposures. Βεβαίως, κάθε επέκταση θα πρέπει να γίνεται με προσοχή ώστε όλα τα δεδομένα να είναι διαθέσιμα τη χρονική στιγμή της πρόβλεψης.

Μια άλλη σημαντική επέκταση είναι η διαφορετική μετατροπή των ML προβλέψεων σε βάρη χαρτοφυλακίου. Στην παρούσα ανάλυση τα top-k αξιόγραφα σταθμίζονται ισομερώς. Μία πρόταση θα ήταν τα βάρη να είναι ανάλογα με τις προβλεπόμενες πιθανότητες, να περιορίζονται από risk parity λογική ή να εισάγονται σε δεύτερο στάδιο mean-variance optimization. Έτσι θα εξεταζόταν αν η μηχανική μάθηση μπορεί να λειτουργήσει όχι ως πλήρης αντικατάσταση, αλλά ως συμπλήρωμα της παραδοσιακής βελτιστοποίησης.

Μελλοντική εργασία θα μπορούσε ακόμη να εξετάσει αυστηρότερα μοντέλα κόστους συναλλαγών. Στο notebook εφαρμόζονται σταθερά σενάρια κόστους συναλλαγών. Σε πιο προχωρημένη εφαρμογή, τα κόστη θα μπορούσαν να εξαρτώνται από το asset class, τη ρευστότητα, το spread ή το μέγεθος συναλλαγής. Αυτό θα έφερνε την αξιολόγηση ακόμη πιο κοντά σε πραγματικό περιβάλλον.

Τέλος, θα είχε ενδιαφέρον να συγκριθούν υβριδικές μέθοδοι. Για παράδειγμα, ένα ML μοντέλο θα μπορούσε να παράγει expected returns ή ranks, ενώ η τελική κατανομή βαρών να προκύπτει από constrained optimization. Μια τέτοια προσέγγιση θα συνέδεε πιο στενά την κλασική θεωρία χαρτοφυλακίου με τη σύγχρονη μηχανική μάθηση.

Συνοψίζοντας, η παρούσα εργασία παρέχει μια βάση για περαιτέρω έρευνα. Το σημαντικότερο επόμενο βήμα δεν είναι απλώς η προσθήκη πιο σύνθετων μοντέλων, αλλά η καλύτερη ευθυγράμμιση μεταξύ στόχου πρόβλεψης, ορίζοντα διακράτησης, τρόπου κατασκευής χαρτοφυλακίου και τελικής αξιολόγησης. Αυτή η ευθυγράμμιση είναι πιθανό να καθορίσει αν η μηχανική μάθηση μπορεί να προσφέρει ουσιαστικό πλεονέκτημα έναντι των παραδοσιακών μεθόδων.

ΒΙΒΛΙΟΓΡΑΦΙΑ

- Arnott, R., Harvey, C.R. and Markowitz, H. (2019) 'A backtesting protocol in the era of machine learning', *Journal of Financial Data Science*, pp. 64–74. Available at: [https://people.duke.edu/~charvey/Research/Published Papers/P138 A backtesting protocol.pdf](https://people.duke.edu/~charvey/Research/Published%20Papers/P138%20A%20backtesting%20protocol.pdf)
- Bailey, D.H., Ger, S., López de Prado, M., Sim, A. and Wu, K. (2014) 'Statistical overfitting and backtest performance': <https://sdm.lbl.gov/oapapers/ssrn-id2507040-bailey.pdf>
- Bailey, D.H. and López de Prado, M. (2012) 'The Sharpe Ratio Efficient Frontier', *Journal of Risk*, 15(2), pp. 3-44. Διαθέσιμο στο: <https://www.davidhbailey.com/dhbpapers/sharpe-frontier.pdf>
- Bailey, D.H., Borwein, J., López de Prado, M. and Zhu, Q.J. (2015) The probability of backtest overfitting: <https://www.davidhbailey.com/dhbpapers/backtest-prob.pdf>
- Breiman, L. (2001) 'Random Forests', *Machine Learning*, pp. 5-32: <https://www.stat.berkeley.edu/~breiman/randomforest2001.pdf>
- Cortes, C. and Vapnik, V. (1995) 'Support-Vector Networks', *Machine Learning*, pp. 1-24: <https://web.engr.oregonstate.edu/~huanlian/teaching/ML/2018spring/extra/svn-1995.pdf>
- Chen, P., Lezmi, E., Roncalli, T. and Xu, J. (2020) 'A note on portfolio optimization with quadratic transaction costs': <https://arxiv.org/pdf/2001.01612>
- Chen, T. and Guestrin, C. (2016) 'XGBoost: A Scalable Tree Boosting System', *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*: <https://arxiv.org/pdf/1603.02754>
- DeMiguel, V., Garlappi, L. and Uppal, R. (2009) 'Optimal Versus Naive Diversification: How Inefficient is the 1/N Portfolio Strategy?', *Review of Financial Studies*, pp. 1915-1953: <https://users.nber.org/~confer/2006/si2006/ap/uppal.pdf>
- Drobetz, W. and Otto, T. (2021) Empirical asset pricing via machine learning: Evidence from the European stock market: <https://www.econstor.eu/bitstream/10419/287592/1/s41260-021-00237-x.pdf>
- Fama, E.F. and French, K.R. (2004) 'The Capital Asset Pricing Model: Theory and Evidence', *Journal of Economic Perspectives*, 18(3), pp. 25-46: <https://mba.tuck.dartmouth.edu/bespeneckbo/default/AFA611-Eckbo%20web%20site/AFA611-S6B-FamaFrench-CAPM-JEP04.pdf>
- Gu, S., Kelly, B. and Xiu, D. (2020) 'Empirical Asset Pricing via Machine Learning', *Review of Financial Studies*, pp. 2223-2273: <https://dachxiu.chicagobooth.edu/download/ML.pdf>
- Hwang, I., Xu, S. and In, F. (2018) 'Naive versus optimal diversification: Tail risk and performance', *European Journal of Operational Research*, 265(1), pp. 372–388. Available at: <https://www.sciencedirect.com/science/article/abs/pii/S0377221717307099?via%3Dihub>

Lo, A.W. (2002) 'The Statistics of Sharpe Ratios', *Financial Analysts Journal*, pp. 36-52: https://www.academia.edu/57966785/The_Statistics_of_Sharpe_Ratios?sm=b&rhid=40328662582

Lintner, J. (1965) The valuation of risk assets and the selection of risky investments in stock portfolios and capital budgets. *The Review of Economics and Statistics*, pp. 13-37: <https://finance.martinsewell.com/capm/Lintner1965a.pdf>

López de Prado, M. (2018) *Advances in Financial Machine Learning*. Hoboken: Wiley. Public preview/table of contents used for methodological orientation: <https://ebookcentral-proquest-com.proxy.eap.gr/lib/eapgr/reader.action?docID=5240570&query=Advances%2520in%2520Financial%2520Machine%2520Learning&c=RVBVQg&ppg=118>

Markowitz, H. (1952) Portfolio selection. *The Journal of Finance*, pp. 77-91: <https://finance.martinsewell.com/capm/Markowitz1952.pdf>

Mynbayeva, E. (2022) 'Why estimation alone causes Markowitz portfolio selection to fail', *European Journal of Operational Research*, pp. 81–96.: https://centaur.reading.ac.uk/107072/1/HS%20article_Ver_3.pdf

NumPy Developers (2026) NumPy Documentation: <https://numpy.org/doc/>

Pandas Development Team (2026) pandas User Guide: https://pandas.pydata.org/docs/user_guide/index.html

Pinelis, M. and Ruppert, D. (2022) 'Machine learning portfolio allocation', *The Journal of Finance and Data Science*, 8, pp. 35–54.: <https://www.sciencedirect.com/science/article/pii/S2405918821000155>

Sharpe, W.F. (1964) Capital asset prices: A theory of market equilibrium under conditions of risk. *The Journal of Finance*, pp. 425-442: <https://finance.martinsewell.com/capm/Sharpe1964.pdf>

Scikit-learn Developers (2026) scikit-learn User Guide: https://scikit-learn.org/stable/user_guide.html

XGBoost Developers (2026) XGBoost Python API Reference: https://xgboost.readthedocs.io/en/latest/python/python_api.html