



Σχολή Κοινωνικών Επιστημών
Τραπεζική, Χρηματοοικονομική και Χρηματοοικονομική
Τεχνολογία (Fintech)

Διπλωματική Εργασία

Ανάλυση Πιστωτικού Κινδύνου με Χρήση Τεχνητής
Νοημοσύνης: Θεωρητική Σύγκριση Παραδοσιακών και
Μηχανικών Μοντέλων Credit Scoring

Δημήτριος Χριστόπουλος

Επιβλέπων καθηγητής/Επιβλέπουσα καθηγήτρια: Δημήτριος Βασιλείου

Πάτρα, Ιούνιος 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.

Περίληψη

Η παρούσα εργασία επικεντρώνεται στην ανάλυση του πιστωτικού κινδύνου, εστιάζοντας στη θεωρητική σύγκριση παραδοσιακών και μηχανικών μοντέλων credit scoring. Αρχικά παρουσιάζεται η σημασία του πιστωτικού κινδύνου στο τραπεζικό σύστημα και ο ρόλος του credit scoring στη διαδικασία χορήγησης δανείων. Ακολούθως, αναπτύσσεται λεπτομερής ανάλυση των βασικών παραδοσιακών μοντέλων, όπως η Logistic Regression, το Z-score και οι credit scorecards, καθώς και των σύγχρονων AI-based μοντέλων, όπως τα Decision Trees, Random Forests, Gradient Boosting, XGBoost, κ.α.

Η εργασία αναδεικνύει ότι τα μοντέλα μηχανικής μάθησης μπορούν να προσφέρουν υψηλότερη προβλεπτική απόδοση, κυρίως λόγω της ικανότητάς τους να εντοπίζουν μη γραμμικές σχέσεις και σύνθετα μοτίβα στα δεδομένα. Ωστόσο, η χρήση τους συνοδεύεται από προκλήσεις που σχετίζονται με την ερμηνευσιμότητα, τη διαφάνεια, το overfitting, το model drift και την αλγοριθμική μεροληψία. Για τον λόγο αυτό, εξετάζεται και η σημασία του Explainable AI, με έμφαση στις τεχνικές SHAP και LIME.

Συνολικά, η εργασία καταλήγει ότι η τεχνητή νοημοσύνη δεν πρέπει να αντιμετωπίζεται ως πλήρης αντικατάσταση των παραδοσιακών μοντέλων, αλλά ως συμπληρωματικό εργαλείο που μπορεί να ενισχύσει την πιστωτική αξιολόγηση. Η υπεύθυνη ενσωμάτωσή της απαιτεί ισορροπία ανάμεσα στην προβλεπτική ακρίβεια, τη διαφάνεια, τη δικαιοσύνη, την κανονιστική συμμόρφωση και την ανθρώπινη εποπτεία.

Λέξεις – Κλειδιά

Πιστωτικός κίνδυνος, Ανάλυση πιστωτικού κινδύνου, Τεχνητή νοημοσύνη, Παραδοσιακά μοντέλα, Ερμηνευσιμότητα

Credit Risk Analysis Using Artificial Intelligence: A Theoretical Comparison of Traditional and Machine Credit Scoring Models

Dimitrios Christopoulos

Abstract

This thesis focuses on the analysis of credit risk, with emphasis on the theoretical comparison between traditional and machine learning credit scoring models. First, it presents the importance of credit risk in the banking system and the role of credit scoring in the loan approval process. Subsequently, it provides a detailed analysis of key traditional models, such as Logistic Regression, Z-score and credit scorecards, as well as modern AI-based models, including Decision Trees, Random Forests, Gradient Boosting, XGBoost, and others.

The thesis highlights that machine learning models can offer higher predictive performance, mainly due to their ability to identify non-linear relationships and complex patterns within data. However, their use is accompanied by challenges related to interpretability, transparency, overfitting, model drift and algorithmic bias. For this reason, the importance of Explainable AI is also examined, with emphasis on techniques such as SHAP and LIME.

Overall, the thesis concludes that artificial intelligence should not be regarded as a complete replacement for traditional models, but rather as a complementary tool that can enhance credit assessment. Its responsible integration requires a balance between predictive accuracy, transparency, fairness, regulatory compliance and human oversight.

Keywords

Credit risk, Credit risk analysis, Artificial Intelligence, Traditional models, Explainable AI

Πίνακας περιεχομένων

1. Εισαγωγή	9
1.1 Η σημασία του πιστωτικού κινδύνου στο τραπεζικό σύστημα	9
1.2 Ο ρόλος του credit scoring στη χορήγηση δανείων	9
1.3 Η εμφάνιση της τεχνητής νοημοσύνης στον χρηματοπιστωτικό τομέα	10
1.4 Ερευνητικός στόχος της εργασίας	10
2. Πιστωτικός Κίνδυνος	11
2.1 Γενική Επισκόπηση και Ιστορικό Πλαίσιο	11
2.2 Ορισμός και σημασία του πιστωτικού κινδύνου	12
2.3 Επιδράσεις μη εξυπηρετούμενων δανείων (NPLs)	13
2.4 Ο ρόλος των ρυθμιστικών αρχών: Basel II και Basel III	15
3. Παραδοσιακά Μοντέλα Credit Scoring	17
3.1 Ιστορική εξέλιξη του credit scoring	17
3.2 Βασικά μοντέλα	18
3.2.1 Logistic Regression	18
3.2.2 Z-score	19
3.2.3 Credit scoring scorecards	20
3.3 Συγκριτική Ανάλυση Παραδοσιακών Μοντέλων	21
3.4 Ο Ρόλος των Παραδοσιακών Μοντέλων Σήμερα	22
4. Μοντέλα Μηχανικής Μάθησης στην Αξιολόγηση Πιστωτικού Κινδύνου	24
4.1 Εισαγωγή στην Τεχνητή Νοημοσύνη και Μηχανική Μάθηση	24
4.2 Ανάλυση βασικών μοντέλων στον Πιστωτικό Κίνδυνο	25
4.2.1 Δέντρα Απόφασης (Decision Trees)	25
4.2.2 Τυχαία Δάση (Random Forests)	27
4.2.3 Gradient Boosting Machines (XGBoost & LightGBM)	29
4.2.4 Τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Networks)	30
4.3 Προετοιμασία Δεδομένων και Feature Engineering	31
4.3.1 Η σημασία της σωστής προετοιμασίας των Δεδομένων	31
4.3.2 Feature Engineering	31
4.3.3 Διαχείριση Ελλιπών Δεδομένων (Handling Missing Data)	32
4.3.4 Βελτιστοποίηση Υπερπαραμέτρων (Hyperparameter Tuning)	33
4.3.5 Κανονικοποίηση και Κλιμάκωση Δεδομένων	34
4.3.6 Σχέση με την Απόδοση των Μοντέλων	35

5. Σύγκριση Παραδοσιακών και AI-based Μοντέλων	35
5.1 Εισαγωγή	35
5.2 Απόδοση, Ανθεκτικότητα και Προσαρμοστικότητα	36
5.2.1 Προβλεπτική απόδοση	36
5.2.2 Ανθεκτικότητα	37
5.2.3 Προσαρμοστικότητα	38
5.3 Προβλήματα Overfitting και Bias	39
5.3.1 Overfitting	39
5.3.2 Bias και Fairness	40
5.4 Ερμηνευσιμότητα και Κανονιστική Συμμόρφωση	40
5.5 Συνολική Αξιολόγηση και Επιλογή Κατάλληλου Μοντέλου	41
6. Explainable AI και Διαφάνεια	43
6.1 Εισαγωγή	43
6.2 Το πρόβλημα των black-box μοντέλων	44
6.3 Τεχνικές SHAP και LIME: Θεωρητική Παρουσίαση	45
6.4 Η Σημασία του Explainable AI για τις Τραπεζικές Αποφάσεις	47
6.5 Περιορισμοί του Explainable AI	48
7. Συγκριτική Βιβλιογραφική Ανάλυση Παραδοσιακών και Μοντέλων Μηχανικής Μάθησης στο Credit Scoring	49
7.1 Μεθοδολογία Βιβλιογραφικής Έρευνας	49
7.2 Περιορισμοί της Βιβλιογραφίας	50
7.3 Μελέτες για Παραδοσιακά Μοντέλα Credit Scoring	51
7.4 Μελέτες για Μοντέλα Μηχανικής Μάθησης	52
7.5 Εμπειρικά Αποτελέσματα από τη Βιβλιογραφία	52
7.6 Συζήτηση Αποτελεσμάτων	64
8. Συμπεράσματα και Προτάσεις	68
8.1 Κύρια Ευρήματα από τη Θεωρητική Σύγκριση	68
8.2 Βασικά Ευρήματα από τη Βιβλιογραφική Ανάλυση	69
8.3 Πλεονεκτήματα και Περιορισμοί των Προσεγγίσεων	69
8.4 Προτάσεις για Υπεύθυνη Ενσωμάτωση AI στο Credit Scoring	70
8.5 Τελικό Συμπέρασμα	71
8.6 Προτάσεις Μελλοντικής Έρευνας	72
Βιβλιογραφία	73

Κατάλογος Πινάκων / Γραφημάτων

Γράφημα 2.1 Βασικές παράμετροι του πιστωτικού κινδύνου (Αναμενόμενη ζημία = $PD \times LGD \times EAD$)	13
Πίνακας 2.1 Οι κύριες επιπτώσεις των μη εξυπηρετούμενων δανείων στις τράπεζες	14
Πίνακας 2.2 Συνοπτική σύγκριση Basel II και Basel III	17
Πίνακας 3.1 Συγκριτική αξιολόγηση παραδοσιακών μοντέλων credit scoring	21
Πίνακας 3.2 Πλεονεκτήματα και περιορισμοί παραδοσιακών μοντέλων	22
Γράφημα 4.1 Βασικά μέρη Decision tree	26
Γράφημα 4.2 Λειτουργία Δέντρου Απόφασης ένα μόνο δέντρο.	28
Γράφημα 4.3 Λειτουργία Τυχαίου Δάσους	29
Πίνακας 5.1 Σύγκριση Μοντέλων Μηχανικής Μάθησης με το μοντέλο Logistic Regression ..	43
Πίνακας 7.1 Συγκριτικά εμπειρικά αποτελέσματα από τη βιβλιογραφία	64
Πίνακας 7.2 Μοντέλα που χρησιμοποιήθηκαν ανά περίοδο.	66
Γράφημα 7.1 Μοντέλα που χρησιμοποιήθηκαν με την πάροδο του χρόνου.	67
Πίνακας 7.3 Διάγραμμα μοντέλα που εμφανίστηκαν ανά περίοδο.	68
Πίνακας 8.1 Σύγκριση Μοντέλων Πιστωτικού Κινδύνου: πλεονεκτήματα και περιορισμοί ...	70

1. Εισαγωγή

1.1 Η σημασία του πιστωτικού κινδύνου στο τραπεζικό σύστημα

Ο πιστωτικός κίνδυνος αποτελεί έναν από τους σημαντικότερους κινδύνους που αντιμετωπίζει το τραπεζικό σύστημα. Αναφέρεται στην πιθανότητα ένας δανειολήπτης να μην μπορέσει να εκπληρώσει τις οικονομικές του υποχρεώσεις, είτε πρόκειται για αποπληρωμή δανείου είτε για εξυπηρέτηση άλλης μορφής πίστωσης. Η σωστή εκτίμηση του πιστωτικού κινδύνου είναι κρίσιμη, καθώς επηρεάζει άμεσα τη σταθερότητα των τραπεζών, την ποιότητα των δανειακών χαρτοφυλακίων και τη γενικότερη λειτουργία του χρηματοπιστωτικού συστήματος (Thomas et al., 2017).

Στο τραπεζικό περιβάλλον, η λανθασμένη αξιολόγηση του πιστωτικού κινδύνου μπορεί να οδηγήσει σε αύξηση των μη εξυπηρετούμενων δανείων, απώλειες κεφαλαίων και περιορισμό της δυνατότητας των τραπεζών να χρηματοδοτούν νοικοκυριά και επιχειρήσεις. Για τον λόγο αυτό, οι τράπεζες έχουν αναπτύξει οργανωμένες διαδικασίες αξιολόγησης της πιστοληπτικής ικανότητας, οι οποίες βασίζονται σε στατιστικά μοντέλα, ιστορικά δεδομένα και κανονιστικά πλαίσια διαχείρισης κινδύνου. Η σημασία του πιστωτικού κινδύνου ενισχύθηκε ακόμη περισσότερο μετά τις χρηματοπιστωτικές κρίσεις, καθώς έγινε σαφές ότι η ποιότητα των πιστωτικών αποφάσεων συνδέεται άμεσα με τη σταθερότητα του τραπεζικού συστήματος (Basel Committee on Banking Supervision [BCBS], 2019).

1.2 Ο ρόλος του credit scoring στη χορήγηση δανείων

Το credit scoring αποτελεί βασικό εργαλείο για την αξιολόγηση της πιστοληπτικής ικανότητας ενός πελάτη. Πρόκειται για μια ποσοτική διαδικασία μέσω της οποίας εκτιμάται η πιθανότητα ένας δανειολήπτης να αθετήσει τις υποχρεώσεις του. Τα μοντέλα credit scoring χρησιμοποιούν μεταβλητές όπως το εισόδημα, το ιστορικό πληρωμών, το επίπεδο χρέους, η επαγγελματική κατάσταση και άλλα χαρακτηριστικά, με σκοπό να παραχθεί μια βαθμολογία ή μια πιθανότητα αθέτησης (Probability of Default – PD) (Thomas et al., 2017).

Η χρήση του credit scoring στη χορήγηση δανείων έχει σημαντικά πλεονεκτήματα. Αρχικά, επιτρέπει στις τράπεζες να λαμβάνουν πιο γρήγορες και πιο συνεπείς αποφάσεις, μειώνοντας την εξάρτηση από την υποκειμενική κρίση των στελεχών. Επιπλέον, συμβάλλει στη βελτίωση της διαχείρισης κινδύνου, καθώς οι αιτήσεις δανείων μπορούν να αξιολογούνται με βάση κοινά και αντικειμενικά κριτήρια. Με αυτόν τον τρόπο, το credit scoring λειτουργεί ως μηχανισμός τυποποίησης της πιστωτικής απόφασης και ως εργαλείο καλύτερης κατανομής των χρηματοδοτικών πόρων (Siddiqi, 2012).

Παράλληλα, το credit scoring έχει ιδιαίτερη σημασία και για τους ίδιους τους δανειολήπτες. Ένα αποτελεσματικό και δίκαιο σύστημα αξιολόγησης μπορεί να διευκολύνει την πρόσβαση σε χρηματοδότηση για άτομα και επιχειρήσεις που παρουσιάζουν χαμηλό πιστωτικό κίνδυνο. Αντίθετα, ένα ανεπαρκές ή μεροληπτικό μοντέλο μπορεί να οδηγήσει σε

λανθασμένες απορρίψεις, υπερβολικά υψηλά επιτόκια ή αποκλεισμό συγκεκριμένων ομάδων από το χρηματοπιστωτικό σύστημα (Barocas & Selbst, 2016).

1.3 Η εμφάνιση της τεχνητής νοημοσύνης στον χρηματοπιστωτικό τομέα

Τα τελευταία χρόνια, η τεχνητή νοημοσύνη και η μηχανική μάθηση έχουν αρχίσει να επηρεάζουν σημαντικά τον χρηματοπιστωτικό τομέα. Στο πεδίο του credit scoring, τα παραδοσιακά μοντέλα, όπως η Logistic Regression και τα credit scorecards, εξακολουθούν να χρησιμοποιούνται ευρέως, όμως πλέον συγκρίνονται με πιο σύνθετες μεθόδους μηχανικής μάθησης. Τέτοιες μέθοδοι είναι τα Decision Trees, Random Forests, Gradient Boosting, XGBoost, Support Vector Machines και Neural Networks (Lessmann et al., 2015).

Η βασική συμβολή των AI-based μοντέλων είναι ότι μπορούν να εντοπίζουν μη γραμμικές σχέσεις και πολύπλοκα μοτίβα στα δεδομένα. Αυτό είναι ιδιαίτερα χρήσιμο σε περιβάλλοντα όπου οι τράπεζες διαθέτουν μεγάλο όγκο πληροφοριών για τη συμπεριφορά των πελατών. Τα μοντέλα μηχανικής μάθησης μπορούν να βελτιώσουν την προβλεπτική απόδοση, να ενισχύσουν την ακρίβεια στην εκτίμηση κινδύνου και να υποστηρίξουν πιο δυναμικές μορφές πιστωτικής αξιολόγησης (Lessmann et al., 2015).

Ωστόσο, η χρήση της τεχνητής νοημοσύνης δημιουργεί και σημαντικές προκλήσεις. Τα πιο σύνθετα μοντέλα συχνά χαρακτηρίζονται ως black-box models, δηλαδή ως μοντέλα των οποίων η εσωτερική λειτουργία δεν είναι εύκολα κατανοητή. Αυτό δημιουργεί ζητήματα διαφάνειας, κανονιστικής συμμόρφωσης, αλγοριθμικής μεροληψίας και δυνατότητας αιτιολόγησης των αποφάσεων. Για τον λόγο αυτό, η ενσωμάτωση της τεχνητής νοημοσύνης στο credit scoring πρέπει να γίνεται με υπευθυνότητα, ελέγχους και ανθρώπινη εποπτεία (Rudin, 2019; European Banking Authority [EBA], 2023).

1.4 Ερευνητικός στόχος της εργασίας

Η παρούσα εργασία οριοθετείται ως θεωρητική και βιβλιογραφική μελέτη και δεν περιλαμβάνει πρωτογενή εμπειρική έρευνα, εφαρμογή αλγορίθμων σε πραγματικό τραπεζικό σύνολο δεδομένων ή στατιστική επαλήθευση της απόδοσης συγκεκριμένων μοντέλων. Το στοιχείο αυτό αποτελεί βασικό περιορισμό της εργασίας, καθώς η σύγκριση των παραδοσιακών και των AI-based μοντέλων πραγματοποιείται με βάση τη διεθνή βιβλιογραφία, τις υφιστάμενες θεωρητικές προσεγγίσεις και το κανονιστικό πλαίσιο.

Ωστόσο, η σημασία του θέματος είναι ιδιαίτερα επίκαιρη, καθώς οι τράπεζες λειτουργούν σε ένα περιβάλλον αυξημένων εποπτικών απαιτήσεων, ανάγκης αποτελεσματικότερης διαχείρισης των μη εξυπηρετούμενων δανείων και νέων κανόνων για τη χρήση της τεχνητής νοημοσύνης, όπως ο Κανονισμός της Ευρωπαϊκής Ένωσης για την Τεχνητή Νοημοσύνη — EU AI Act. Το ερευνητικό κενό που επιχειρεί να καλύψει η εργασία εντοπίζεται στην ανάγκη μιας συγκριτικής θεωρητικής αποτίμησης των παραδοσιακών και των μηχανικών μοντέλων credit scoring, όχι μόνο ως προς την προβλεπτική τους ακρίβεια,

αλλά και ως προς την ερμηνευσιμότητα, τη διαφάνεια, τη συμμόρφωση με το κανονιστικό πλαίσιο και την υπεύθυνη χρήση τους στη λήψη πιστωτικών αποφάσεων.

Η εργασία δεν αντιμετωπίζει την τεχνητή νοημοσύνη ως απόλυτη αντικατάσταση των παραδοσιακών μεθόδων. Αντίθετα, επιδιώκει να αναδείξει ότι η επιλογή του κατάλληλου μοντέλου εξαρτάται από το πλαίσιο εφαρμογής, την ποιότητα των δεδομένων, τις απαιτήσεις του χρηματοπιστωτικού οργανισμού και το επίπεδο αποδεκτού κινδύνου. Με αυτόν τον τρόπο, η εργασία προσεγγίζει το credit scoring ως ένα πεδίο όπου η τεχνολογική καινοτομία πρέπει να συνδυάζεται με τη διαφάνεια και τη θεσμική ασφάλεια.

2. Πιστωτικός Κίνδυνος

2.1 Γενική Επισκόπηση και Ιστορικό Πλαίσιο

Ο πιστωτικός κίνδυνος αποτελεί έναν από τους πιο κρίσιμους και διαχρονικά σημαντικούς κινδύνους που αντιμετωπίζουν οι τράπεζες και γενικότερα οι χρηματοπιστωτικοί οργανισμοί. Ουσιαστικά, αναφέρεται στην πιθανότητα ένας δανειολήπτης ή αντισυμβαλλόμενος να μην εκπληρώσει πλήρως και έγκαιρα τις οικονομικές του υποχρεώσεις, σύμφωνα με τους όρους που έχουν συμφωνηθεί (Bessis, 2011). Η αθέτηση αυτή μπορεί να λάβει διάφορες μορφές, όπως καθυστέρηση δόσεων, μερική αποπληρωμή, αναδιάρθρωση του χρέους ή πλήρη αδυναμία εξόφλησης. Η βασική σημασία του πιστωτικού κινδύνου έγκειται στο ότι η χορήγηση πίστωσης αποτελεί τον πυρήνα της τραπεζικής δραστηριότητας. Συνεπώς, κάθε αδυναμία αποπληρωμής επηρεάζει άμεσα την ποιότητα του ενεργητικού, την κερδοφορία και την κεφαλαιακή επάρκεια μιας τράπεζας (Hull, 2015).

Η σημασία του πιστωτικού κινδύνου στο τραπεζικό σύστημα είναι μεγαλύτερη από εκείνη μιας απλής λειτουργικής ή λογιστικής παραμέτρου. Οι τράπεζες διακρατούν στο ενεργητικό τους κυρίως δάνεια προς νοικοκυριά, επιχειρήσεις και άλλους φορείς. Αυτό σημαίνει ότι η εύρυθμη λειτουργία τους εξαρτάται από τη συνεχή εισροή ταμειακών ροών από τόκους και αποπληρωμές κεφαλαίου (Saunders & Allen, 2010). Όταν αυτές οι ροές διαταράσσονται, η επίδραση δεν περιορίζεται στην κερδοφορία ενός μόνο προϊόντος, αλλά διαχέεται στο σύνολο της τραπεζικής λειτουργίας: επιβαρύνεται η ρευστότητα, μειώνεται η δυνατότητα νέων χορηγήσεων, αυξάνονται οι ανάγκες για προβλέψεις και ενδέχεται να απαιτηθεί ενίσχυση κεφαλαίων.

Για τον λόγο αυτό, η ορθή μέτρηση και διαχείριση του πιστωτικού κινδύνου δεν είναι απλώς μία τεχνική άσκηση, αλλά προϋπόθεση για τη σταθερότητα του τραπεζικού ιδρύματος και, κατ' επέκταση, του ίδιου του χρηματοπιστωτικού συστήματος. Η τραπεζική θεωρία και η σχετική βιβλιογραφία αντιμετωπίζουν τον πιστωτικό κίνδυνο ως κεντρικό άξονα του risk management, ακριβώς επειδή οι περισσότερες σοβαρές τραπεζικές ζημιές ιστορικά συνδέθηκαν με την υποβάθμιση της ποιότητας των χορηγήσεων και με

λανθασμένες εκτιμήσεις για την πιστοληπτική ικανότητα πελατών και αντισυμβαλλομένων (Saunders & Allen, 2010).

Η εμπειρία των διεθνών χρηματοπιστωτικών κρίσεων επιβεβαιώνει τη συστημική σημασία του πιστωτικού κινδύνου. Η κρίση του 2007–2009 οδήγησε σε εκτεταμένη αναθεώρηση του τρόπου με τον οποίο οι τράπεζες, οι επενδυτές και οι εποπτικές αρχές αντιλαμβάνονται την έκθεση σε πιστωτικό κίνδυνο. Η υποεκτίμηση της πιθανότητας αθέτησης, η υπερβολική εξάρτηση από αισιόδοξες παραδοχές και η ανεπαρκής απορρόφηση ζημιών ανέδειξαν ότι η λανθασμένη αξιολόγηση του πιστωτικού κινδύνου μπορεί να έχει πολύ ευρύτερες συνέπειες από τις ζημίες ενός χαρτοφυλακίου. Μπορεί να προκαλέσει αποσταθεροποίηση της διατραπεζικής αγοράς, απώλεια εμπιστοσύνης, περιορισμό της πιστωτικής επέκτασης και τελικά μακροοικονομική ύφεση (Acharya & Richardson, 2009).


2.2 Ορισμός και σημασία του πιστωτικού κινδύνου

Σε εννοιολογικό επίπεδο, ο πιστωτικός κίνδυνος μπορεί να οριστεί ως ο κίνδυνος απώλειας που προκύπτει όταν ένας οφειλέτης δεν καταβάλλει τα ποσά που οφείλει, είτε επειδή δεν μπορεί είτε επειδή δεν επιλέγει να το πράξει, σύμφωνα με τους όρους της σύμβασης. Ο ορισμός αυτός περιλαμβάνει όχι μόνο την πλήρη χρεοκοπία ή παύση πληρωμών, αλλά και πιο ήπιες μορφές δυσχέρειας, όπως επαναλαμβανόμενες καθυστερήσεις, υποχρεωτικές αναδιαρθρώσεις, παρατάσεις διάρκειας ή μερικές εισπράξεις (Hull, 2015). Στη σύγχρονη θεωρία του risk management, η έννοια του πιστωτικού κινδύνου δεν συνδέεται απλώς με το αν θα υπάρξει αθέτηση, αλλά και με το πότε θα συμβεί, πόσο μεγάλη θα είναι η έκθεση τη στιγμή εκείνη και ποιο μέρος αυτής της έκθεσης θα μπορέσει τελικά να ανακτηθεί.

Αυτή η προσέγγιση εξηγεί γιατί η σύγχρονη διαχείριση πιστωτικού κινδύνου βασίζεται σε τρεις κλασικές ποσοτικές παραμέτρους: Probability of Default (PD), Loss Given Default (LGD) και Exposure at Default (EAD). Η Probability of Default εκφράζει την πιθανότητα ένας δανειολήπτης να αθετήσει τις υποχρεώσεις του μέσα σε συγκεκριμένο χρονικό ορίζοντα, συνήθως ενός έτους. Η Loss Given Default αναφέρεται στο ποσοστό ζημίας που τελικά θα υποστεί η τράπεζα αν επέλθει αθέτηση, αφού ληφθούν υπόψη οι εισπράξεις από εξασφαλίσεις, ανακτήσεις ή άλλους μηχανισμούς. Η Exposure at Default αποτυπώνει το ύψος της έκθεσης τη στιγμή της αθέτησης, κάτι ιδιαίτερα σημαντικό σε προϊόντα όπου η έκθεση μπορεί να μεταβάλλεται, όπως πιστωτικές γραμμές ή κάρτες (Hull, 2015).

Οι τρεις αυτές έννοιες συνδυάζονται στη γνωστή σχέση της αναμενόμενης ζημίας, δηλαδή $Expected\ Loss = PD \times LGD \times EAD$, η οποία βρίσκεται στον πυρήνα τόσο της τραπεζικής διαχείρισης κινδύνου όσο και των εποπτικών πλαισίων της Βασιλείας. Η αξία της σχέσης αυτής είναι ότι επιτρέπει στις τράπεζες να μετατρέπουν ετερογενείς πληροφορίες για τον πελάτη, το προϊόν και τις εξασφαλίσεις σε μία συγκρίσιμη ποσοτική εκτίμηση

κινδύνου. Με τον τρόπο αυτό, οι αποφάσεις χορήγησης πίστωσης, τιμολόγησης επιτοκίου και καθορισμού ορίων δεν βασίζονται αποκλειστικά στη διαίσθηση ή στη χρηματοοικονομική εμπειρία των στελεχών, αλλά σε μία συστηματοποιημένη διαδικασία εκτίμησης ζημιών (Hull, 2015).



Γράφημα 2.1 Βασικές παράμετροι του πιστωτικού κινδύνου (Αναμενόμενη ζημία = $PD \times LGD \times EAD$)

Η σημασία του πιστωτικού κινδύνου δεν περιορίζεται στην τεχνική εκτίμηση μιας πιθανότητας. Στην πράξη, αποτελεί τη βάση πάνω στην οποία δομούνται κρίσιμες τραπεζικές αποφάσεις, όπως η έγκριση ή απόρριψη αιτήσεων δανείων, η τιμολόγηση του επιτοκίου, οι απαιτήσεις εξασφαλίσεων, τα πιστωτικά όρια και οι πολιτικές παρακολούθησης. Κάθε σφάλμα σε αυτήν την αξιολόγηση μπορεί να οδηγήσει είτε σε υπερβολική ανάληψη κινδύνου είτε σε υπερβολική συντηρητικότητα. Στην πρώτη περίπτωση, η τράπεζα αναλαμβάνει περισσότερη έκθεση από αυτήν που μπορεί να υποστηρίξει· στη δεύτερη, περιορίζει τη χρηματοδότηση σε βαθμό που επηρεάζει αρνητικά την αποδοτικότητα και την ικανότητά της να υποστηρίξει την οικονομική δραστηριότητα.

Συνεπώς, ο πιστωτικός κίνδυνος συνδέεται άμεσα τόσο με την ανθεκτικότητα των τραπεζών όσο και με την αποδοτική κατανομή κεφαλαίων στην οικονομία. Μια τράπεζα που διαθέτει αδύναμα συστήματα αξιολόγησης πιστωτικού κινδύνου μπορεί να εμφανίσει βραχυπρόθεσμα υψηλή πιστωτική επέκταση, αλλά μακροπρόθεσμα θα βρεθεί αντιμέτωπη με υψηλότερες ζημιές και κεφαλαιακή πίεση. Αντίθετα, ένα αποτελεσματικό σύστημα διαχείρισης πιστωτικού κινδύνου επιτρέπει την ισορροπία ανάμεσα στην ανάπτυξη χαρτοφυλακίου και στη διατήρηση αποδεκτού επιπέδου κινδύνου (Saunders & Allen, 2010).

2.3 Επιδράσεις μη εξυπηρετούμενων δανείων (NPLs)

Η πιο απλή και μετρήσιμη έννοια για να κατανοήσουμε τον πιστωτικό κίνδυνο, είναι τα μη εξυπηρετούμενα δάνεια, γνωστά ως Non-Performing Loans (NPLs). Συνήθως, ως NPL ορίζεται ένα δάνειο για το οποίο η καθυστέρηση πληρωμών υπερβαίνει ένα συγκεκριμένο όριο, συχνά τις 90 ημέρες, ή ένα δάνειο για το οποίο η τράπεζα κρίνει ότι η πλήρης αποπληρωμή είναι απίθανη χωρίς ρευστοποίηση εξασφαλίσεων ή άλλες διορθωτικές ενέργειες. Τα NPLs λειτουργούν ως δείκτης της ποιότητας του δανειακού χαρτοφυλακίου και, κατά συνέπεια, ως ένδειξη του βαθμού στον οποίο ο πιστωτικός κίνδυνος έχει ήδη μετατραπεί σε πραγματική ή εν δυνάμει ζημία (Beck, Jakubik, & Piloju, 2015).

Η αύξηση των NPLs επηρεάζει τη λειτουργία των τραπεζών σε πολλά επίπεδα τα οποία παρουσιάζονται στον πίνακα 2.1 που ακολουθεί. Πρώτον, υπονομεύει την κερδοφορία τους, διότι μειώνονται τα έσοδα από τόκους και αυξάνονται οι ανάγκες για προβλέψεις και απομειώσεις. Δεύτερον, επιβαρύνει τους δείκτες κεφαλαιακής επάρκειας, καθώς οι ζημίες μειώνουν τα ίδια κεφάλαια ή δεσμεύουν πρόσθετο κεφάλαιο για κάλυψη κινδύνου. Τρίτον, δημιουργεί λειτουργικό βάρος, επειδή η διαχείριση προβληματικών δανείων απαιτεί αναδιαρθρώσεις, δικαστικές ενέργειες, πωλήσεις εξασφαλίσεων και εξειδικευμένες μονάδες recovery. Τέταρτον, επηρεάζει αρνητικά την ικανότητα των τραπεζών να παρέχουν νέα πίστωση. Όταν ένα μεγάλο μέρος του ισολογισμού είναι επιβαρυνόμενο με NPLs, η τράπεζα γίνεται πιο διστακτική στην ανάληψη νέας έκθεσης, ακόμη και σε βιώσιμους πελάτες (Beck, Jakubik, & Piloju, 2015).

Μείωση κερδοφορίας	• Απώλεια εσόδων από τόκους και αυξημένες απομειώσεις.
Κεφαλαιακή πίεση	• Ανάγκη για υψηλότερες προβλέψεις και ενίσχυση ιδίων κεφαλαίων.
Περιορισμός νέων χορηγήσεων	• Μειωμένη δυνατότητα χρηματοδότησης της οικονομίας.
Λειτουργικό κόστος	• Αύξηση κόστους διαχείρισης, αναδιαρθρώσεων και νομικών ενεργειών.

Πίνακας 2.1 Οι κύριες επιπτώσεις των μη εξυπηρετούμενων δανείων στις τράπεζες

Η βιβλιογραφία υπογραμμίζει ότι τα NPLs δεν αποτελούν ένα μεμονωμένο τραπεζικό φαινόμενο, αλλά συνδέονται άρρηκτα με το ευρύτερο μακροοικονομικό περιβάλλον. Παράγοντες όπως η ανάπτυξη του ΑΕΠ, τα επιτόκια, η ανεργία, η πτώση της αγοραίας αξίας περιουσιακών στοιχείων και η επιδείνωση των συνθηκών ρευστότητας διαδραματίζουν καθοριστικό ρόλο στη διαμόρφωση των δεικτών NPLs. Με απλά λόγια, όταν η οικονομική δραστηριότητα επιβραδύνεται, τα εισοδήματα μειώνονται και το κόστος εξυπηρέτησης του χρέους αυξάνεται, περισσότεροι δανειολήπτες δυσκολεύονται να ανταποκριθούν στις υποχρεώσεις τους. Επομένως, ο πιστωτικός κίνδυνος δεν είναι μόνο θέμα ατομικών χαρακτηριστικών του πελάτη, αλλά και αντανάκλαση των συνολικών συνθηκών της οικονομίας (Louzis, Vouldis, & Metaxas, 2012).

Οι επιπτώσεις των NPLs δεν περιορίζονται στην τράπεζα που τα κατέχει. Όταν οι δείκτες προβληματικών δανείων αυξάνονται σε ολόκληρο το τραπεζικό σύστημα, περιορίζεται η ικανότητα της οικονομίας να χρηματοδοτείται. Οι τράπεζες γίνονται πιο επιφυλακτικές, αυστηροποιούν τα κριτήρια χορήγησης και δίνουν προτεραιότητα στην εξυγίανση υφιστάμενων χαρτοφυλακίων. Αυτό μπορεί να οδηγήσει σε πιστωτική συρρίκνωση, χαμηλότερες επενδύσεις και βραδύτερη οικονομική ανάκαμψη. Γι' αυτόν τον λόγο, τα NPLs θεωρούνται κρίσιμος δείκτης όχι μόνο μικροπροληπτικής αλλά και μακροπροληπτικής σημασίας.

Η ευρωπαϊκή εμπειρία μετά την κρίση χρέους ανέδειξε ιδιαίτερα τη σημασία των NPLs. Σε αρκετές χώρες, ο συνδυασμός ύφεσης, υψηλής ανεργίας και μείωσης διαθέσιμου εισοδήματος οδήγησε σε σημαντική αύξηση των προβληματικών δανείων. Η αντιμετώπιση του φαινομένου αυτού δεν απαιτεί μόνο τραπεζικά εργαλεία, αλλά και θεσμικό πλαίσιο για αναδιαρθρώσεις, δευτερογενείς αγορές δανείων, επαρκείς προβλέψεις και ενεργή εποπτική παρέμβαση. Άρα, η μελέτη των NPLs δεν είναι βοηθητικό στοιχείο του πιστωτικού κινδύνου, αλλά κεντρικός δείκτης της έντασης και της υλοποίησής του.

2.4 Ο ρόλος των ρυθμιστικών αρχών: Basel II και Basel III

Η μεγάλη σημασία του πιστωτικού κινδύνου οδήγησε στην ανάπτυξη διεθνών ρυθμιστικών πλαισίων που στοχεύουν να διασφαλίσουν ότι οι τράπεζες διαθέτουν επαρκή κεφάλαια και κατάλληλα συστήματα διαχείρισης κινδύνου. Το πιο σημαντικό από αυτά είναι το πλαίσιο της Επιτροπής της Βασιλείας για την Τραπεζική Εποπτεία. Η Basel II σηματοδότησε μια ουσιαστική αλλαγή σε σχέση με παλαιότερες προσεγγίσεις, επειδή εισήγαγε μεγαλύτερη ευαισθησία στον κίνδυνο και επέτρεψε στις τράπεζες, υπό όρους, να χρησιμοποιούν εσωτερικά μοντέλα για την εκτίμηση της κεφαλαιακής απαίτησης έναντι πιστωτικού κινδύνου.

Στο πλαίσιο αυτό, οι παράμετροι PD, LGD και EAD απέκτησαν κεντρικό ρόλο. Η Basel II οργανώθηκε γύρω από τρεις πυλώνες: ελάχιστες κεφαλαιακές απαιτήσεις, εποπτική ανασκόπηση και πειθαρχία της αγοράς μέσω γνωστοποιήσεων. Η συνεισφορά της ήταν ότι μετέτρεψε τη μέτρηση του πιστωτικού κινδύνου από γενική λογιστική εκτίμηση σε αυστηρά ποσοτικοποιημένη διαδικασία. Οι τράπεζες κλήθηκαν να αναπτύξουν συστήματα διαβάθμισης, μοντέλα πρόβλεψης και διαδικασίες επικύρωσης, ώστε οι εκτιμήσεις

κινδύνου να βασίζονται σε ιστορικά δεδομένα (Basel Committee on Banking Supervision, 2006).

Παρότι η Basel II βελτίωσε σημαντικά την εποπτία, η κρίση του 2007–2009 ανέδειξε τα όριά της. Στην διάρκεια της κρίσης φάνηκε ότι η ύπαρξη εξελιγμένων μοντέλων δεν αρκεί όταν υπάρχουν προβλήματα υπερβολικής μόχλευσης, χαμηλής ρευστότητας και υποεκτίμησης συσχετισμών κινδύνου. Ως απάντηση, η Basel III θεσπίστηκε ως ένα διεθνώς συμφωνημένο πλαίσιο που αναπτύχθηκε σε απάντηση στη χρηματοπιστωτική κρίση του 2007–2009 και αποσκοπεί στην ενίσχυση της ρύθμισης, της εποπτείας και της διαχείρισης κινδύνου των τραπεζών (Basel Committee on Banking Supervision, 2019).

Η Basel III αύξησε την ποιότητα και το ύψος των απαιτούμενων κεφαλαίων, εισήγαγε κεφαλαιακά buffers, ενίσχυσε την αντιμετώπιση της μόχλευσης και πρόσθεσε δείκτες ρευστότητας. Παρότι δεν αφορά μόνο τον πιστωτικό κίνδυνο, στην πράξη αυξάνει την ανθεκτικότητα των τραπεζών απέναντι στις ζημιές από αθετήσεις και ενθαρρύνει πιο συντηρητική και δομημένη διαχείριση κινδύνου. Επιπλέον, έδωσε έμφαση στην εσωτερική διακυβέρνηση κινδύνων, στην τεκμηρίωση των μοντέλων και στην ικανότητα των τραπεζών να αποδεικνύουν στις εποπτικές αρχές ότι οι μέθοδοι που χρησιμοποιούν είναι αξιόπιστες και κατάλληλες (Basel Committee on Banking Supervision, 2019).

Ο ρόλος των ρυθμιστικών αρχών, επομένως, δεν εξαντλείται στην επιβολή ενός ελάχιστου δείκτη κεφαλαίου. Διαμορφώνει το πλαίσιο μέσα στο οποίο οι τράπεζες αναπτύσσουν πιστωτικά μοντέλα, ορίζουν πολιτικές ανάληψης κινδύνου, ελέγχουν τις συγκεντρώσεις έκθεσης και αξιολογούν την επάρκεια των πρακτικών τους. Αυτό έχει ιδιαίτερη σημασία στη σύγχρονη εποχή, όπου οι τράπεζες στρέφονται ολοένα και περισσότερο προς τεχνικές τεχνητής νοημοσύνης και μηχανικής μάθησης. Όσο πιο σύνθετα και αποδοτικά γίνονται τα μοντέλα, τόσο περισσότερο αυξάνεται η ανάγκη για εποπτική τεκμηρίωση, διαφάνεια και νομιμότητα. Συνεπώς, η ρυθμιστική διάσταση όχι μόνο δεν είναι εξωτερική στην ανάλυση πιστωτικού κινδύνου, αλλά αποτελεί αναπόσπαστο μέρος της.

Στον πίνακα 2.2 που ακολουθεί παρουσιάζονται τα βασικά χαρακτηριστικά της Βασιλείας II και III.

Διάσταση	Basel II	Basel III
Κύρια έμφαση	Ευαισθησία στον κίνδυνο και εσωτερικά μοντέλα	Ανθεκτικότητα, ποιότητα κεφαλαίου και buffers
Πιστωτικός κίνδυνος	PD, LGD, EAD και IRB προσεγγίσεις	Ισχυρότερη κεφαλαιακή βάση για απορρόφηση ζημιών
Σταθερότητα συστήματος	Μικροπροληπτική προσέγγιση	Ενισχυμένη μακροπροληπτική διάσταση

Πίνακας 2.2 Συνοπτική σύγκριση Basel II και Basel III**3. Παραδοσιακά Μοντέλα Credit Scoring****3.1 Ιστορική εξέλιξη του credit scoring**

Η ανάπτυξη των μοντέλων credit scoring συνδέεται άμεσα με την ανάγκη των τραπεζών να μεταβούν από υποκειμενικές σε αντικειμενικές διαδικασίες αξιολόγησης πιστοληπτικής ικανότητας. (Thomas et al., 2002) Στα πρώτα στάδια της τραπεζικής πρακτικής, οι αποφάσεις σχετικά με τη χορήγηση δανείων στηρίζονταν κυρίως στην προσωπική εμπειρία των υπευθύνων και σε ποιοτικούς παράγοντες, όπως η φήμη του πελάτη ή η διαχρονική σχέση που είχε αναπτυχθεί με την τράπεζα. Η προσέγγιση αυτή, αν και λειτουργική σε περιορισμένες δανειοδοτικές ανάγκες, δεν μπορούσε να υποστηρίξει την αύξηση της ζήτησης για πίστωση ούτε να εξασφαλίσει συνέπεια στις αποφάσεις (Thomas et al., 2002).

Η πρώτη ουσιαστική αλλαγή σημειώθηκε τη δεκαετία του 1960, όταν η εφαρμογή στατιστικών μεθόδων ξεκίνησε να παίρνει τη θέση της καθαρά εμπειρικής προσέγγισης. Ορόσημο αποτέλεσε το μοντέλο Z-score, που ανέπτυξε ο Altman το 1968, το οποίο αποτέλεσε την πρώτη συστηματική προσπάθεια να ποσοτικοποιηθεί ο πιστωτικός κίνδυνος μέσα από χρηματοοικονομικούς δείκτες. Με αυτόν τον τρόπο, εισήχθη η έννοια της κατηγοριοποίησης των επιχειρήσεων σε διαφορετικά επίπεδα κινδύνου με βάση μετρήσιμα και αντικειμενικά χαρακτηριστικά, προσφέροντας μία πρώτη βάση για μια πιο επιστημονικά θεμελιωμένη αξιολόγηση.

Στη συνέχεια, η ανάπτυξη της Logistic Regression τη δεκαετία του 1970 και η ευρεία χρήση της από τη δεκαετία του 1980 και μετά, επέτρεψαν την εκτίμηση πιθανοτήτων αθέτησης με μεγαλύτερη ακρίβεια και στατιστική θεμελίωση (Hosmer et al., 2013). Η δυνατότητα ενσωμάτωσης πολλαπλών μεταβλητών και η ερμηνεία των αποτελεσμάτων καθιέρωσαν τη Logistic Regression ως βασικό εργαλείο credit scoring.

Η εξέλιξη αυτή συνέβαλε στην εμφάνιση των credit scorecards, οι οποίες αποτελούν σημαντικό βήμα προς την επιχειρησιακή εφαρμογή των στατιστικών μοντέλων. Τα scorecards επέτρεψαν τη μετατροπή των στατιστικών αποτελεσμάτων σε απλές βαθμολογίες, διευκολύνοντας τη χρήση τους από μη εξειδικευμένα στελέχη (Siddiqi, 2012). Σήμερα, τα παραδοσιακά μοντέλα αποτελούν τη βάση για τα σύγχρονα συστήματα αξιολόγησης, ενώ πολλές από τις έννοιες τους έχουν ενσωματωθεί σε πιο προηγμένα μοντέλα μηχανικής μάθησης (Lessmann et al., 2015).

3.2 Βασικά μοντέλα

Στην παρούσα ενότητα παρουσιάζονται πιο αναλυτικά τα σημαντικότερα παραδοσιακά μοντέλα credit scoring, τα οποία αποτέλεσαν τη βάση για τη σύγχρονη αξιολόγηση του πιστωτικού κινδύνου. Η ανάλυση παρακάτω επικεντρώνεται στα μοντέλα : Logistic Regression, Z-score, Credit scoring scorecards αναδεικνύοντας τα κύρια χαρακτηριστικά τους και την λειτουργική τους εφαρμογή.

3.2.1 Logistic Regression

Η Logistic Regression αποτελεί το πιο διαδεδομένο μοντέλο για την εκτίμηση της πιθανότητας αθέτησης. Η βασική της λειτουργία είναι η εκτίμηση της πιθανότητας να συμβεί ένα δυαδικό γεγονός, όπως η αθέτηση ή μη αθέτηση μιας δανειακής υποχρέωσης. Στο πλαίσιο της πιστωτικής αξιολόγησης, το μοντέλο χρησιμοποιεί ένα σύνολο ανεξάρτητων μεταβλητών, όπως εισόδημα, ηλικία, επαγγελματική κατάσταση, ιστορικό καθυστερήσεων και επίπεδο χρέους, με στόχο την εκτίμηση της πιθανότητας αθέτησης PD (Hosmer et al., 2013).

Η Logistic Regression εκφράζεται συνήθως με την ακόλουθη μορφή:

$$P(Y = 1 | X) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k)}}$$

Τύπος Logistic Regression για την εκτίμηση πιθανότητας αθέτησης

Στην παραπάνω σχέση, το $P(Y=1|X)$ εκφράζει την πιθανότητα αθέτησης, ενώ οι μεταβλητές $X_1, X_2, \dots, X_k$ αντιπροσωπεύουν τα χαρακτηριστικά του δανειολήπτη. Οι συντελεστές β δείχνουν την επίδραση κάθε μεταβλητής στην πιθανότητα αθέτησης. Η χρήση της λογιστικής συνάρτησης εξασφαλίζει ότι η εκτιμώμενη πιθανότητα λαμβάνει τιμές μεταξύ 0 και 1, γεγονός που καθιστά το μοντέλο κατάλληλο για πιστωτικές αποφάσεις (Hosmer et al., 2013).

Ένα από τα βασικά πλεονεκτήματα της Logistic Regression είναι η ερμηνευσιμότητά της. Οι συντελεστές του μοντέλου μπορούν να χρησιμοποιηθούν για να αναγνωριστούν οι βασικοί παράγοντες κινδύνου, δηλαδή οι μεταβλητές που αυξάνουν ή μειώνουν την πιθανότητα αθέτησης. Για παράδειγμα, ένα υψηλό επίπεδο χρέους σε σχέση με το εισόδημα μπορεί να αυξάνει την πιθανότητα αθέτησης, ενώ ένα σταθερό ιστορικό αποπληρωμών μπορεί να τη μειώνει. Η δυνατότητα αυτή καθιστά τη Logistic Regression

ιδιαίτερα χρήσιμη σε τραπεζικά περιβάλλοντα όπου απαιτείται αιτιολόγηση των αποφάσεων (Thomas et al., 2017).

Η Logistic Regression χρησιμοποιείται ευρέως και επειδή οι πιθανότητες αθέτησης που παράγει μπορούν να συνδεθούν με το εποπτικό πλαίσιο της Βασιλείας, ιδίως σε συστήματα εσωτερικών διαβαθμίσεων πιστωτικού κινδύνου. Επιπλέον, είναι στατιστικά σταθερή, σχετικά εύκολη στην εφαρμογή και λιγότερο απαιτητική υπολογιστικά σε σχέση με πιο σύνθετα μοντέλα μηχανικής μάθησης. Για τον λόγο αυτό, παραμένει βασικό εργαλείο τόσο στην ακαδημαϊκή βιβλιογραφία όσο και στην τραπεζική πρακτική (Lessmann et al., 2015).

Ωστόσο, η Logistic Regression παρουσιάζει και σημαντικούς περιορισμούς. Ο βασικότερος είναι ότι υποθέτει μια σχετικά γραμμική σχέση μεταξύ των ανεξάρτητων μεταβλητών και του λογαριθμικού λόγου πιθανοτήτων, δηλαδή των log-odds. Με τον όρο log-odds εννοείται ο λογάριθμος του λόγου της πιθανότητας να συμβεί ένα γεγονός προς την πιθανότητα να μη συμβεί. Αυτή η υπόθεση μπορεί να περιορίσει την ικανότητα του μοντέλου να αποτυπώσει σύνθετες μη γραμμικές σχέσεις και αλληλεπιδράσεις μεταξύ μεταβλητών (Hosmer et al., 2013).

Επιπλέον, η απόδοση της Logistic Regression εξαρτάται σε μεγάλο βαθμό από την ποιότητα των δεδομένων και την επιλογή των κατάλληλων μεταβλητών. Εάν οι μεταβλητές δεν έχουν επιλεγεί σωστά ή εάν υπάρχουν ακραίες τιμές ή ελλιπή δεδομένα, η αξιοπιστία του μοντέλου μπορεί να μειωθεί. Παρόλα αυτά, λόγω της ισορροπίας που προσφέρει μεταξύ ακρίβειας και ερμηνευσιμότητας, η Logistic Regression εξακολουθεί να θεωρείται ένα ισχυρό baseline μοντέλο για την αξιολόγηση πιο σύνθετων μεθόδων credit scoring (Lessmann et al., 2015).

3.2.2 Z-score

Το μοντέλο Z-score του Altman αποτελεί μία από τις πρώτες συστηματικές εφαρμογές πολυμεταβλητής ανάλυσης στην εκτίμηση πιστωτικού κινδύνου. Η πολυμεταβλητή ανάλυση αφορά τη χρήση στατιστικών μεθόδων που εξετάζουν ταυτόχρονα περισσότερες από μία μεταβλητές, προκειμένου να αποτυπωθούν σύνθετες σχέσεις μεταξύ οικονομικών δεικτών. Το Z-score αναπτύχθηκε αρχικά για την πρόβλεψη πτώχευσης επιχειρήσεων και βασίζεται σε γραμμικό συνδυασμό χρηματοοικονομικών δεικτών (Altman, 1968).

Η βασική λογική του Z-score είναι ότι η χρηματοοικονομική κατάσταση μιας επιχείρησης μπορεί να αξιολογηθεί μέσα από δείκτες που αποτυπώνουν τη ρευστότητα, την αποδοτικότητα, τη μόχλευση, τη φερεγγυότητα και τη δραστηριότητα. Με βάση αυτούς τους δείκτες, το μοντέλο παράγει μια συνολική βαθμολογία, η οποία χρησιμοποιείται για την ταξινόμηση της επιχείρησης σε κατηγορίες χαμηλού, μεσαίου ή υψηλού κινδύνου. Η συμβολή του μοντέλου ήταν ιδιαίτερα σημαντική, καθώς εισήγαγε μια πιο αντικειμενική και μετρήσιμη προσέγγιση στην πρόβλεψη πτώχευσης (Altman, 1968). Το βασικό πλεονέκτημα του Z-score είναι η απλότητα και η ευκολία εφαρμογής του. Μπορεί να χρησιμοποιηθεί

ακόμη και σε περιβάλλοντα όπου τα διαθέσιμα δεδομένα είναι περιορισμένα, αρκεί να υπάρχουν βασικά λογιστικά και χρηματοοικονομικά στοιχεία. Για τον λόγο αυτό, εξακολουθεί να χρησιμοποιείται ως εργαλείο αναφοράς ή benchmark, δηλαδή ως απλό σημείο σύγκρισης με νεότερα και πιο σύνθετα μοντέλα πιστωτικού κινδύνου (Altman, 1968).

Ωστόσο, το Z-score παρουσιάζει σημαντικούς περιορισμούς. Πρώτον, βασίζεται κυρίως σε ιστορικά λογιστικά δεδομένα, τα οποία ενδέχεται να μην αντανακλούν πλήρως την τρέχουσα οικονομική κατάσταση μιας επιχείρησης. Δεύτερον, το αρχικό μοντέλο αναπτύχθηκε για συγκεκριμένο οικονομικό και θεσμικό περιβάλλον, γεγονός που περιορίζει την άμεση εφαρμογή του σε διαφορετικές χώρες, κλάδους ή χρονικές περιόδους. Τρίτον, όπως και άλλα γραμμικά μοντέλα, δεν μπορεί να αποτυπώσει εύκολα μη γραμμικές σχέσεις μεταξύ μεταβλητών (Altman, 1968).

Παρά τους περιορισμούς του, το Z-score διατηρεί ιστορική και πρακτική σημασία. Αποτελεί ένα από τα πρώτα παραδείγματα ποσοτικοποίησης του πιστωτικού κινδύνου και συνέβαλε ουσιαστικά στη μετάβαση από την εμπειρική αξιολόγηση στη στατιστική προσέγγιση. Η απλότητά του το καθιστά χρήσιμο ως αρχικό εργαλείο αξιολόγησης, κυρίως σε επιχειρηματικό και εταιρικό επίπεδο.

3.2.3 Credit scoring scorecards

Οι credit scoring scorecards αποτελούν πρακτική εφαρμογή των στατιστικών μοντέλων credit scoring, κυρίως της Logistic Regression. Στόχος τους είναι η μετατροπή των στατιστικών αποτελεσμάτων σε ένα απλό και κατανοητό σύστημα βαθμολόγησης, το οποίο μπορεί να χρησιμοποιηθεί από τραπεζικά στελέχη για την αξιολόγηση αιτήσεων δανείων. Με τον τρόπο αυτό, ένα σύνθετο στατιστικό αποτέλεσμα μετατρέπεται σε μια συνολική πιστωτική βαθμολογία, η οποία διευκολύνει τη λήψη αποφάσεων (Siddiqi, 2012).

Η ανάπτυξη των scorecards βασίζεται συχνά σε τεχνικές προεπεξεργασίας δεδομένων, όπως το binning. Το binning είναι η διαδικασία με την οποία συνεχείς αριθμητικές μεταβλητές μετατρέπονται σε διακριτές κατηγορίες ή ομάδες. Για παράδειγμα, η ηλικία ενός πελάτη μπορεί να χωριστεί σε ομάδες, όπως 18–25, 26–35, 36–50 και άνω των 50 ετών. Η διαδικασία αυτή απλοποιεί τα δεδομένα, περιορίζει την επίδραση ακραίων τιμών και διευκολύνει την ερμηνεία των αποτελεσμάτων (Siddiqi, 2012).

Δύο σημαντικές τεχνικές που χρησιμοποιούνται συχνά στην ανάπτυξη scorecards είναι το Weight of Evidence και το Information Value. Το Weight of Evidence, γνωστό ως WoE, δείχνει τη σχέση μιας κατηγορίας μεταβλητής με την πιθανότητα αθέτησης. Με απλούστερους όρους, βοηθά να φανεί αν μια συγκεκριμένη ομάδα πελατών συνδέεται περισσότερο με καλούς ή κακούς δανειολήπτες. Το Information Value, γνωστό ως IV, χρησιμοποιείται για την αξιολόγηση της προβλεπτικής ισχύος μιας μεταβλητής. Όσο μεγαλύτερη είναι η τιμή του IV, τόσο μεγαλύτερη θεωρείται η δυνατότητα της μεταβλητής να διαχωρίζει τους δανειολήπτες υψηλού και χαμηλού κινδύνου (Siddiqi, 2012).

Το βασικό πλεονέκτημα των scorecards είναι η υψηλή ερμηνευσιμότητα. Κάθε μεταβλητή και κάθε κατηγορία μεταβλητής αντιστοιχεί σε συγκεκριμένη βαθμολογία,

γεγονός που καθιστά εύκολη την εξήγηση της τελικής απόφασης. Για παράδειγμα, ένας πελάτης μπορεί να λάβει χαμηλότερη βαθμολογία λόγω συχνών καθυστερήσεων των πληρωμών. Αυτή η διαφάνεια είναι ιδιαίτερα σημαντική σε περιβάλλοντα όπου απαιτείται συμμόρφωση με κανονισμούς και δυνατότητα αιτιολόγησης των αποφάσεων (Thomas et al., 2017).

Παρά τα πλεονεκτήματά τους, οι scorecards έχουν και περιορισμούς. Η διαδικασία binning μπορεί να οδηγήσει σε απώλεια πληροφορίας, καθώς οι συνεχείς μεταβλητές απλοποιούνται σε κατηγορίες. Επιπλέον, η ανάπτυξη scorecards συχνά βασίζεται σε εμπειρικές επιλογές, όπως ο τρόπος ομαδοποίησης των μεταβλητών ή η επιλογή των τελικών χαρακτηριστικών. Αυτό μπορεί να επηρεάσει την εγκυρότητα και την αξιοπιστία του μοντέλου, ιδίως όταν τα δεδομένα είναι σύνθετα ή μεταβάλλονται συχνά (Siddiqi, 2012).

3.3 Συγκριτική Ανάλυση Παραδοσιακών Μοντέλων

Η συγκριτική αξιολόγηση των παραδοσιακών μοντέλων είναι απαραίτητη για την κατανόηση των δυνατοτήτων και των περιορισμών τους. Η επιλογή του κατάλληλου μοντέλου δεν εξαρτάται μόνο από την προβλεπτική ακρίβεια, αλλά και από παράγοντες όπως η ερμηνευσιμότητα, η ποιότητα των διαθέσιμων δεδομένων, το είδος του δανείου, οι εποπτικές απαιτήσεις και η δυνατότητα εφαρμογής του μοντέλου στην πράξη (Lessmann et al., 2015).

Μοντέλο	Προβλεπτική ικανότητα	Ερμηνευσιμότητα	Απαιτήσεις δεδομένων	Κανονιστική συμμόρφωση
Logistic Regression	Υψηλή	Υψηλή	Μεσαίες	Πολύ υψηλή
Z-score	Μεσαία	Υψηλή	Χαμηλές	Υψηλή
Scorecards	Μεσαία	Πολύ υψηλή	Μεσαίες	Πολύ υψηλή

Πίνακας 3.1 Συγκριτική αξιολόγηση παραδοσιακών μοντέλων credit scoring

Ας δούμε λίγο πιο αναλυτικά τα 3 μοντέλα που παρουσιάστηκαν στον πίνακα 3.1. Η Logistic Regression παρουσιάζει την καλύτερη ισορροπία ανάμεσα στην προβλεπτική ικανότητα και την ερμηνευσιμότητα. Σε σχέση με το μοντέλο Z-score, μπορεί να ενσωματώσει περισσότερες μεταβλητές και να εκτιμήσει άμεσα την πιθανότητα αθέτησης. Σε σχέση με τις scorecards, διαθέτει ισχυρότερη “δομή”, αν και οι scorecards υπερέχουν ως προς την απλότητα και την επιχειρησιακή εφαρμογή (Hosmer et al., 2013; Siddiqi, 2012).

Το μοντέλο Z-score χαρακτηρίζεται από απλότητα και ταχύτητα εφαρμογής, αλλά η προβλεπτική του ικανότητα είναι πιο περιορισμένη. Είναι ιδιαίτερα χρήσιμο ως αρχικό

εργαλείο αξιολόγησης επιχειρηματικού κινδύνου, αλλά δεν είναι εξίσου κατάλληλο για σύγχρονα περιβάλλοντα όπου απαιτείται δυναμική αξιοποίηση μεγάλου όγκου δεδομένων. Επιπλέον, επειδή βασίζεται κυρίως σε λογιστικούς δείκτες, μπορεί να αποτυπώνει με καθυστέρηση την πραγματική οικονομική κατάσταση μιας επιχείρησης (Altman, 1968).

Οι scorecards προσφέρουν τη μεγαλύτερη ερμηνευσιμότητα και παραμένουν ιδιαίτερα δημοφιλείς στην τραπεζική πρακτική. Η βασική τους δύναμη είναι ότι μετατρέπουν την αξιολόγηση κινδύνου σε ένα απλό και κατανοητό σύστημα βαθμολόγησης. Ωστόσο, η απλοποίηση των δεδομένων μέσω binning μπορεί να μειώσει την προβλεπτική ακρίβεια, ιδιαίτερα όταν υπάρχουν σύνθετες σχέσεις μεταξύ μεταβλητών που δεν αποτυπώνονται εύκολα μέσα από προκαθορισμένες κατηγορίες (Siddiqi, 2012).

Μοντέλο	Πλεονεκτήματα	Περιορισμοί
Logistic Regression	Ισορροπία μεταξύ ακρίβειας και ερμηνευσιμότητας, εκτίμηση πιθανότητας αθέτησης, στατιστική σταθερότητα	Γραμμικότητα, περιορισμένη αποτύπωση σύνθετων αλληλεπιδράσεων, ανάγκη προσεκτικής επιλογής μεταβλητών
Z-score	Απλότητα, ταχύτητα εφαρμογής, χρήση βασικών χρηματοοικονομικών δεικτών	Δυσκολία στην προσαρμοστικότητα, εξάρτηση από ιστορικά λογιστικά δεδομένα, μειωμένη ακρίβεια σε σύνθετα περιβάλλοντα
Scorecards	Υψηλή διαφάνεια, κανονιστική αποδοχή, εύκολη επιχειρησιακή εφαρμογή	Απώλεια πληροφορίας λόγω binning, χειροκίνητες επιλογές στην ανάπτυξη, χαμηλότερη ακρίβεια σε σύνθετα datasets

Πίνακας 3.2 Πλεονεκτήματα και περιορισμοί παραδοσιακών μοντέλων

Συνολικά, η συγκριτική ανάλυση δείχνει ότι τα παραδοσιακά μοντέλα δεν πρέπει να αξιολογούνται αποκλειστικά με βάση την ακρίβεια. Η αξία τους βρίσκεται κυρίως στη διαφάνεια, στη σταθερότητα και στην ευκολία εφαρμογής. Για τον λόγο αυτό, εξακολουθούν να χρησιμοποιούνται ευρέως, ακόμη και σε περιβάλλοντα όπου υπάρχουν διαθέσιμες πιο σύνθετες τεχνικές μηχανικής μάθησης (Lessmann et al., 2015; Thomas et al., 2017).

3.4 Ο Ρόλος των Παραδοσιακών Μοντέλων Σήμερα

Στο σύγχρονο τραπεζικό περιβάλλον, τα παραδοσιακά μοντέλα credit scoring δεν έχουν αντικατασταθεί πλήρως από τα μοντέλα μηχανικής μάθησης. Αντίθετα, ο ρόλος τους έχει μετασχηματιστεί. Χρησιμοποιούνται συχνά ως μοντέλα αναφοράς, ως εργαλεία

ελέγχου και ως ερμηνεύσιμες βάσεις πάνω στις οποίες μπορούν να συγκριθούν ή να συμπληρωθούν πιο σύνθετες τεχνικές τεχνητής νοημοσύνης (Lessmann et al., 2015). Η βασική αιτία διατήρησης των παραδοσιακών μοντέλων είναι η ανάγκη για διαφάνεια και ερμηνευσιμότητα. Στον τραπεζικό τομέα, οι αποφάσεις δεν πρέπει απλώς να είναι ακριβείς, αλλά και τεκμηριωμένες. Οι τράπεζες πρέπει να μπορούν να εξηγήσουν γιατί ένας πελάτης εγκρίθηκε ή απορρίφθηκε, ποιοι παράγοντες επηρέασαν την αξιολόγηση και πώς διαμορφώθηκε η τελική πιστωτική βαθμολογία. Σε αυτό το σημείο, μοντέλα όπως η Logistic Regression και οι scorecards διατηρούν σημαντικό πλεονέκτημα έναντι πολλών “black-box” μοντέλων μηχανικής μάθησης (Thomas et al., 2017; Rudin, 2019).

Τα κανονιστικά πλαίσια, όπως η Βασιλεία II και η Βασιλεία III, δίνουν ιδιαίτερη έμφαση στην τεκμηρίωση, την επικύρωση και την παρακολούθηση των μοντέλων που χρησιμοποιούνται για την εκτίμηση πιστωτικού κινδύνου. Οι τράπεζες οφείλουν να αποδεικνύουν ότι τα μοντέλα τους είναι στατιστικά έγκυρα, ότι λειτουργούν με σταθερότητα και ότι τα αποτελέσματά τους μπορούν να ερμηνευθούν από εσωτερικούς και εξωτερικούς ελεγκτές. Η απαίτηση αυτή καθιστά τα παραδοσιακά μοντέλα ιδιαίτερα σημαντικά σε εποπτικά ελεγχόμενα περιβάλλοντα (Basel Committee on Banking Supervision [BCBS], 2019).

Παράλληλα, η ευρωπαϊκή νομοθεσία για την προστασία δεδομένων ενισχύει τη σημασία της διαφάνειας στις αυτοματοποιημένες αποφάσεις. Ο Γενικός Κανονισμός για την Προστασία Δεδομένων, γνωστός ως GDPR, προβλέπει δικαιώματα που σχετίζονται με την αυτοματοποιημένη επεξεργασία και τη δυνατότητα των υποκειμένων των δεδομένων να λαμβάνουν πληροφορίες σχετικά με τη λογική της επεξεργασίας. Στο πλαίσιο αυτό, τα παραδοσιακά μοντέλα είναι συχνά πιο εύκολα στην αιτιολόγηση σε σχέση με πιο σύνθετα και λιγότερο διαφανή AI-based μοντέλα (European Union, 2016).

Ωστόσο, η αύξηση της διαθεσιμότητας δεδομένων και οι εξελίξεις στην τεχνητή νοημοσύνη έχουν οδηγήσει στη σταδιακή ενσωμάτωση μοντέλων μηχανικής μάθησης στα συστήματα πιστωτικής αξιολόγησης. Τα μοντέλα αυτά μπορούν να βελτιώσουν την προβλεπτική ακρίβεια, ιδίως όταν υπάρχουν μεγάλα και σύνθετα datasets. Ως αποτέλεσμα, πολλές σύγχρονες προσεγγίσεις κινούνται προς υβριδικά συστήματα, όπου τα παραδοσιακά μοντέλα συνυπάρχουν με πιο προηγμένους αλγορίθμους (Lessmann et al., 2015). Τα hybrid models, δηλαδή τα υβριδικά μοντέλα, συνδυάζουν στοιχεία από διαφορετικές μεθοδολογικές προσεγγίσεις. Για παράδειγμα, μια τράπεζα μπορεί να χρησιμοποιεί Logistic Regression ως βασικό και ερμηνεύσιμο μοντέλο εκτίμησης πιθανότητας αθέτησης, ενώ παράλληλα να αξιοποιεί ένα μοντέλο μηχανικής μάθησης για τον εντοπισμό σύνθετων μοτίβων ή για τη βελτίωση της ακρίβειας σε συγκεκριμένες κατηγορίες πελατών. Με αυτόν τον τρόπο, επιδιώκεται η ισορροπία μεταξύ ακρίβειας και ερμηνευσιμότητας (Lessmann et al., 2015; Rudin, 2019).

Ένα ακόμη σημαντικό στοιχείο είναι η επιχειρησιακή διάσταση. Τα παραδοσιακά μοντέλα είναι συνήθως πιο εύκολα στην υλοποίηση, στη συντήρηση και στην επικύρωση. Οι τράπεζες διαθέτουν ήδη υποδομές, διαδικασίες και ανθρώπινο δυναμικό εξοικειωμένο με τη χρήση τους, γεγονός που μειώνει το κόστος μετάβασης και τον λειτουργικό κίνδυνο. Αντίθετα, τα μοντέλα μηχανικής μάθησης απαιτούν πιο εξειδικευμένο προσωπικό,

μεγαλύτερη υπολογιστική ισχύ και πιο σύνθετες διαδικασίες ελέγχου και παρακολούθησης (EBA, 2023).

Συνεπώς, ο σημερινός ρόλος των παραδοσιακών μοντέλων δεν είναι παθητικός ή ξεπερασμένος. Αντίθετα, αποτελούν βασικό πυλώνα της πιστωτικής αξιολόγησης, είτε ως αυτόνομα εργαλεία είτε ως μέρος ευρύτερων υβριδικών συστημάτων. Η αξία τους βρίσκεται στο ότι προσφέρουν σταθερότητα, διαφάνεια και θεσμική ασφάλεια σε ένα περιβάλλον όπου η τεχνητή νοημοσύνη δημιουργεί νέες δυνατότητες αλλά και νέες προκλήσεις.

4. Μοντέλα Μηχανικής Μάθησης στην Αξιολόγηση Πιστωτικού Κινδύνου

4.1 Εισαγωγή στην Τεχνητή Νοημοσύνη και Μηχανική Μάθηση

Η Τεχνητή Νοημοσύνη (Artificial Intelligence – AI) και ειδικότερα η Μηχανική Μάθηση (Machine Learning – ML) αποτελούν τα τελευταία χρόνια βασικούς πυλώνες μετασχηματισμού του χρηματοπιστωτικού κλάδου. Σε αντίθεση με τα παραδοσιακά στατιστικά μοντέλα, τα οποία βασίζονται σε προκαθορισμένα σενάρια για τη σχέση μεταξύ μεταβλητών, τα μοντέλα μηχανικής μάθησης έχουν τη δυνατότητα να «μαθαίνουν» από τα δεδομένα και να εντοπίζουν σύνθετα μοτίβα χωρίς την ανάγκη αυστηρών κανόνων (Bishop, 2006).

Στο πλαίσιο του πιστωτικού κινδύνου, η Τεχνητή Νοημοσύνη χρησιμοποιείται κυρίως για την πρόβλεψη της πιθανότητας αθέτησης (Probability of Default – PD), αλλά και σε πιο σύνθετες εφαρμογές όπως η ανίχνευση απάτης, η δυναμική τιμολόγηση και η διαχείριση χαρτοφυλακίων (Lessmann et al., 2015). Η αυξανόμενη διαθεσιμότητα δεδομένων, σε συνδυασμό με τη βελτίωση της υπολογιστικής ισχύος, έχει καταστήσει δυνατή την εφαρμογή αλγορίθμων που τα προηγούμενα χρόνια θεωρούνταν πρακτικά αδύνατο να εφαρμοστούν.

Η βασική διαφοροποίηση της μηχανικής μάθησης από τα παραδοσιακά μοντέλα έγκειται στην ικανότητά της να αποτυπώνει μη γραμμικές σχέσεις και αλληλεπιδράσεις μεταξύ μεταβλητών (Lessmann et al., 2015). Η χρήση AI μοντέλων επιτρέπει την αξιοποίηση μη παραδοσιακών δεδομένων (alternative data), όπως για παράδειγμα δεδομένα “συμπεριφοράς” πελατών, ψηφιακά ίχνη και δεδομένα συναλλαγών. Αυτό διευρύνει σημαντικά το πεδίο αξιολόγησης πιστωτικού κινδύνου, ιδιαίτερα για άτομα χωρίς ιστορικό δανεισμού (credit invisible population) (Rudin, 2019). Έστω ότι σε ένα σύνολο πιστωτικών δεδομένων, η επίδραση του εισοδήματος στον πιστωτικό κίνδυνο, εξαρτάται από την ηλικία ή το ιστορικό δανεισμού. Σχέσεις σαν και αυτές, είναι δύσκολο να αποτυπωθούν με

γραμμικά μοντέλα, αλλά μπορούν να εντοπιστούν αποτελεσματικά μέσω αλγορίθμων τεχνητής νοημοσύνης (Lessmann et al., 2015).

Ωστόσο, η αυξημένη πολυπλοκότητα των AI μοντέλων συνοδεύεται από προκλήσεις, κυρίως ως προς την ερμηνευσιμότητα και τη συμμόρφωση με τους κανονισμούς. Σε αντίθεση με τα παραδοσιακά μοντέλα, όπου κάθε παράμετρος έχει σαφή σημασία, τα μοντέλα AI λειτουργούν συχνά χωρίς διαφάνεια, γεγονός που δημιουργεί δυσκολίες στην αιτιολόγηση των αποφάσεων. Τέτοιες καταστάσεις χαρακτηρίζονται ως «μαύρα κουτιά» (black boxes) (Rudin, 2019).

4.2 Ανάλυση βασικών μοντέλων στον Πιστωτικό Κίνδυνο

Η βιβλιογραφία έχει αναδείξει μια σειρά από μοντέλα μηχανικής μάθησης που χρησιμοποιούνται ευρέως στο credit scoring. Τα σημαντικότερα από αυτά είναι τα Δέντρα Απόφασης - Decision Trees, Τυχαία Δάση - Random Forests, Gradient Boosting Machines (XGBoost ή LightGBM) και Artificial Neural Networks.

4.2.1 Δέντρα Απόφασης (Decision Trees)

Τα Δέντρα Απόφασης (DT) αποτελούν τη βάση για πολλές προηγμένες τεχνικές. Με μια πρώτη ματιά ένα Δέντρο Απόφασης μοιάζει με ένα διάγραμμα ροής. Αλλά στην ουσία είναι κάτι περισσότερο από ένα διάγραμμα. Είναι μια σειρά από αλγορίθμους μηχανικής μάθησης που χρησιμοποιούνται για την ταξινόμηση ή παλινδρόμηση δεδομένων, χωρίζοντάς τα, βάση ερωτήσεων καταλήγοντας σε ένα τελικό συμπέρασμα. (Stephanie Wells, 2025). Στην περίπτωση του πιστωτικού κινδύνου, λειτουργούν χωρίζοντας το δείγμα των δανειοληπτών σε διαδοχικούς κόμβους με βάση συγκεκριμένα κριτήρια (Quinlan, 1986).

Πιο αναλυτικά, στα δέντρα απόφασης χρησιμοποιείται ο δείκτης G, Gini Impurity όπου είναι μια υπολογιστική αποτελεσματική μέτρηση :

$$G = 1 - \sum_{i=1}^n p_i^2$$

η οποία εφαρμόζεται σε κάθε κόμβο απόφασης, με στόχο τη μεγιστοποίηση της καθαρότητας (purity) των υποσυνόλων. Όπου:

n: Ο αριθμός των διαφορετικών κλάσεων

p_i : Η πιθανότητα ένα στοιχείο να ανήκει σε μια συγκεκριμένη κλάση (Default ή Non-Default) (Quinlan, 1986).


Τα βασικά μέρη ενός DT είναι:



Ριζικός Κόμβος (Root Node): Είναι ο πρώτος κόμβος στην κορυφή του δέντρου, ο οποίος αντιπροσωπεύει ολόκληρο το σύνολο δεδομένων (dataset). Από αυτόν ξεκινούν όλες οι αποφάσεις.



Κόμβοι Απόφασης (Decision/Internal Nodes): Είναι οι ενδιάμεσοι κόμβοι που χωρίζουν τα δεδομένα σε υποσύνολα με βάση μια συγκεκριμένη συνθήκη ή χαρακτηριστικό (feature). Συχνά αναπαρίστανται με τετράγωνα.



Κόμβοι Ευκαιρίας (Chance Nodes): (Συχνά σε δέντρα αποφάσεων διοίκησης) Αντιπροσωπεύουν μια πιθανότητα ή αβεβαιότητα και συνήθως συμβολίζονται με κύκλο.



Φύλλα ή Τελικοί Κόμβοι (Leaf/Terminal Nodes): Είναι οι τελευταίοι κόμβοι στο τέλος κάθε κλάδου που δεν χωρίζονται περαιτέρω. Αντιπροσωπεύουν το τελικό αποτέλεσμα, την πρόβλεψη ή την ταξινόμηση (class label).



Κλαδιά (Branches): Συνδέουν τους κόμβους μεταξύ τους και αντιπροσωπεύουν το αποτέλεσμα ενός ελέγχου (π.χ. "Ναι" ή "Όχι", "True" ή "False").

Γράφημα 4.1 Βασικά μέρη Decision tree

Όπως επισημαίνουν οι Baesens et al. (2003), τα βασικά πλεονεκτήματα που προσφέρουν τα δέντρα απόφασης είναι η υψηλή ερμηνευσιμότητα και διαφάνεια, επιτρέποντας στους χρήστες να κατανοήσουν ακριβώς βάση ποιων χαρακτηριστικών πάρθηκε για παράδειγμα μια απόφαση. Επιπλέον μπορούν εύκολα να απεικονιστούν και να ερμηνευθούν καθώς η δομή τους είναι ιεραρχική και μοιάζει αρκετά με τον ανθρώπινο τρόπο λήψης απόφασης (Baesens et al, 2003). Από την άλλη, τα DT είναι ευάλωτα στο φαινόμενο της υπερπροσαρμογής (overfitting). Η τάση τους να αποστηθίζουν τα δεδομένα εκπαίδευσης αντί να μαθαίνουν γενικούς κανόνες συμπεριφοράς, ειδικά όταν τα δεδομένα προς περιέχουν θόρυβο ή είναι περιορισμένα, οδηγεί στη δημιουργία υπερβολικά πολύπλοκων δέντρων τα οποία εμφανίζουν χαμηλή ακρίβεια στις προβλέψεις (Baesens et al, 2003).

Για την αντιμετώπιση αυτού του φαινομένου, εφαρμόζονται τεχνικές κλαδέματος στα DT, όπως :

Το Pre-pruning: Περιορισμός του μέγιστου βάθους του δέντρου ή του ελάχιστου αριθμού δειγμάτων ανά φύλλο (hyperparameter tuning).

Και το Post-pruning: Κατασκευή του πλήρους δέντρου και στη συνέχεια αφαίρεση των κλάδων που προσφέρουν ελάχιστη βελτίωση στην πρόβλεψη (Baesens et al, 2003).

4.2.2 Τυχαία Δάση (Random Forests)

Για την αντιμετώπιση των περιορισμών των DT, ο Breiman (2001) εισήγαγε τα Random Forests, μια μέθοδο Ensemble Learning. Τα Random Forests αποτελούν έναν αλγόριθμο επιβλεπόμενης μηχανικής μάθησης που χρησιμοποιείται τόσο σε προβλήματα ταξινόμησης όσο και σε προβλήματα παλινδρόμησης. Η βασική αρχή της μεθόδου είναι ότι, αντί να βασίζεται σε ένα μόνο δέντρο απόφασης, κατασκευάζει ένα σύνολο από πολλά δέντρα και συνδυάζει τις επιμέρους προβλέψεις τους, με στόχο την παραγωγή πιο σταθερών και ακριβών αποτελεσμάτων (Kavlakoglu, Ray, 2025). Στην ταξινόμηση, η τελική πρόβλεψη προκύπτει συνήθως μέσω πλειοψηφικής ψήφου των δέντρων, ενώ στην παλινδρόμηση μέσω του μέσου όρου των επιμέρους εκτιμήσεων (Kavlakoglu, Ray, 2025).

Μηχανισμός: Κάθε δέντρο εκπαιδεύεται σε ένα τυχαίο υποσύνολο των δεδομένων και των χαρακτηριστικών. Η τελική απόφαση λαμβάνεται μέσω πλειοψηφίας (majority voting). Οι Khandani et al. (2010) απέδειξαν ότι τα Random Forests μπορούν να αυξήσουν την ακρίβεια πρόβλεψης κατά 15-25% σε σύγκριση με τη Logistic Regression, καθώς μειώνουν σημαντικά τη διακύμανση (variance) του σφάλματος.


Η λειτουργία των Random Forests στηρίζεται σε δύο βασικούς μηχανισμούς: το bootstrap aggregation (bagging) και την τυχαία επιλογή χαρακτηριστικών. Αρχικά, για κάθε δέντρο δημιουργείται ένα τυχαίο δείγμα εκπαίδευσης με ανάθεση από το αρχικό σύνολο δεδομένων. Στη συνέχεια, σε κάθε κόμβο του δέντρου εξετάζεται μόνο ένα τυχαίο υποσύνολο μεταβλητών για την επιλογή της καλύτερης διάσπασης. Με τον τρόπο αυτό μειώνεται η συσχέτιση ανάμεσα στα δέντρα και ενισχύεται η δυνατότητα του μοντέλου να γενικεύει σε νέα δεδομένα, περιορίζοντας το πρόβλημα της υπερεκπαίδευσης που συχνά εμφανίζεται στα DT (Kavlakoglu, Ray, 2025, TowardsMachineLearning).

Ένα από τα σημαντικότερα πλεονεκτήματα των Random Forests είναι ότι συνδυάζουν υψηλή απόδοση, σχετική ανθεκτικότητα στο overfitting και ευελιξία ως προς το είδος του προβλήματος που επιλύουν. Επιπλέον, μπορούν να παρέχουν εκτιμήσεις για τη σημασία των μεταβλητών, γεγονός ιδιαίτερα χρήσιμο όταν ο στόχος δεν είναι μόνο η πρόβλεψη αλλά και η κατανόηση των χαρακτηριστικών που συμβάλλουν περισσότερο στο τελικό αποτέλεσμα (Ray, 2025, TowardsMachineLearning). Παράλληλα, αναφέρονται ως πρακτική επιλογή επειδή συχνά επιτυγχάνουν ικανοποιητική επίδοση ακόμη και χωρίς εκτεταμένη παραμετροποίηση (Kavlakoglu, Ray, 2025).


Από την άλλη, ενώ όπως είπαμε και παραπάνω είναι συνήθως πιο ακριβή από ένα μεμονωμένο δέντρο απόφασης, είναι λιγότερο ερμηνεύσιμα, καθώς η τελική απόφαση προκύπτει από τη συλλογική λειτουργία πολλών δέντρων και όχι από μια απλή, ορατή δομή κανόνων. Επιπλέον, η εκπαίδευση και η αποθήκευση ενός μεγάλου αριθμού δέντρων μπορεί να αυξήσει το υπολογιστικό κόστος σε χρόνο και μνήμη, ιδιαίτερα σε μεγάλα σύνολα δεδομένων (Ray, 2025, TowardsMachineLearning). Επομένως, η επιλογή του αλγορίθμου πρέπει να λαμβάνει υπόψη όχι μόνο την προγνωστική ακρίβεια αλλά και την ανάγκη για ερμηνευσιμότητα και υπολογιστική αποδοτικότητα (Kavlakoglu, Ray, 2025).


Συνολικά, τα Random Forests θεωρούνται μία από τις πλέον αξιόπιστες μεθόδους ensemble learning, επειδή αξιοποιούν τη συνδυαστική δύναμη πολλών δέντρων απόφασης για να βελτιώσουν τη σταθερότητα και την ακρίβεια των προβλέψεων. Για τον λόγο αυτό χρησιμοποιούνται ευρέως ως ισχυρό baseline model σε εφαρμογές μηχανικής μάθησης, ιδιαίτερα όταν απαιτείται καλή προγνωστική επίδοση σε δεδομένα με σύνθετες και μη γραμμικές σχέσεις μεταξύ μεταβλητών (Kavlakoglu, Ray, 2025).

Ακολουθούν τα διαγράμματα 4.2 και 4.3 που περιγράφουν τον τρόπο λειτουργίας των μοντέλων Δέντρο Απόφασης και Τυχαίο Δάσος ώστε να γίνουν πιο κατανοητές οι διαφορές τους στον τρόπο λειτουργίας τους.



Γράφημα 4.2 Λειτουργία Δέντρου Απόφασης ένα μόνο δέντρο.





Γράφημα 4.3 Λειτουργία Τυχαίου Δάσους

4.2.3 Gradient Boosting Machines (XGBoost & LightGBM)

Τα Gradient Boosting Machines (GBM) ανήκουν στις μεθόδους ensemble learning και βασίζονται στη διαδοχική εκπαίδευση πολλών αδύναμων μοντέλων, συνήθως μικρών δέντρων απόφασης, έτσι ώστε κάθε νέο μοντέλο να διορθώνει τα σφάλματα του προηγούμενου. Η λογική του boosting είναι προσθετική: το τελικό μοντέλο δεν εκπαιδεύεται “μονομιάς”, αλλά χτίζεται βήμα-βήμα, με κάθε νέο δέντρο να βελτιστοποιεί μια συνάρτηση απώλειας σε σχέση με τις τρέχουσες προβλέψεις. Στον πυρήνα αυτού του μοντέλου βρίσκονται η σειριακή μάθηση-sequential learning, η ελαχιστοποίηση του loss function και η συρρίκνωση του learning rate, διαδικασίες οι οποίες περιορίζουν τη συμβολή κάθε νέου δέντρου ώστε να μειώνεται ο κίνδυνος υπερεκπαίδευσης (GeeksforGeeks, 2025, XGBoost developers, Chen & Guestrin, 2016).

Το μοντέλο XGBoost αποτελεί μια ιδιαίτερα βελτιστοποιημένη υλοποίηση gradient boosting, η οποία δεν ελαχιστοποιεί απλά το σφάλμα, αλλά εισάγει τις έννοιες του training loss και του regularization, όπου ελέγχεται πόσο καλά προσαρμόζεται το μοντέλο στα δεδομένα και μειώνει την πολυπλοκότητα του μοντέλου αποτρέποντας το overfitting. Η εκπαίδευση γίνεται προσθετικά, ένα δέντρο κάθε φορά, ενώ η αξιοποίηση πρώτης και δεύτερης παραγώγου της loss function επιτρέπει αποδοτική βελτιστοποίηση και υποστήριξη διαφορετικών τύπων προβλημάτων, όπως classification, regression και ranking (XGBoost developers, Chen & Guestrin, 2016). Το LightGBM, από την άλλη, είναι επίσης ένα gradient boosting μοντέλο βασισμένο σε δέντρα, αλλά έχει σχεδιαστεί με ακόμη μεγαλύτερη έμφαση στην ταχύτητα και την αποδοτικότητα μνήμης. Χρησιμοποιεί histogram-based learning, leaf-wise growth αντί για level-wise growth, ενώ εισάγει και τις τεχνικές Gradient-based One-Side Sampling (GOSS) και Exclusive Feature Bundling (EFB), ώστε να χειρίζεται πιο αποδοτικά μεγάλα και υψηλοδιάστατα σύνολα δεδομένων (Ke et al., 2017; LightGBM developers). Η leaf-wise στρατηγική μπορεί να μειώνει περισσότερο τη απώλεια, αλλά σε

μικρότερα datasets αυξάνει τον κίνδυνο overfitting αν δεν ελεγχθεί κατάλληλα το βάθος ή ο αριθμός των φύλλων (LightGBM developers, n.d.).

Στο πεδίο του πιστωτικού κινδύνου, τα μοντέλα gradient boosting είναι ιδιαίτερα αποδεκτά επειδή μπορούν να αποτυπώσουν μη γραμμικές σχέσεις, αλληλεπιδράσεις μεταβλητών και σύνθετα μοτίβα συμπεριφοράς δανειοληπτών, τα οποία συχνά διαφεύγουν από πιο γραμμικά μοντέλα. Σε μελέτη της BIS, τα credit-scoring μοντέλα που βασίζονται σε machine learning αποδείχθηκαν καλύτερα στην πρόβλεψη ζημιών και αθετήσεων σε σχέση με παραδοσιακά μοντέλα, ιδιαίτερα σε περιόδους αρνητικού σοκ της αγοράς στην προσφορά πίστωσης (Gambacorta et al., 2019). Ειδικότερα, οι Wang et al. (2022) ανέφεραν ότι το μοντέλο XGBoost επιλέχθηκε ως αποτελεσματικό μοντέλο για προσωπικό πιστωτικό κίνδυνο με καλή επίδοση σε AUC, accuracy και Type II error, ενώ οι Rao et al. (2023) έδειξαν ότι ένα βελτιωμένο σχήμα PSO-XGBoost υπερείχε έναντι απλού XGBoost και logistic regression σε πρόβλημα πιστωτικού κινδύνου προσωπικών δανείων αυτοκινήτου. Για πολύ μεγάλα και ανισόρροπα datasets δανεισμού, πρόσφατες LightGBM-based εφαρμογές δίνουν έμφαση ακριβώς στα ζητήματα class imbalance, scalability και interpretability, δηλαδή στα τρία σημεία που είναι ιδιαίτερα κρίσιμα και στην πιστοδοτική πράξη (Ying et al., 2025; Shi et al., 2022).

Εν κατακλείδι, τα XGBoost και LightGBM είναι συχνά από τις ισχυρότερες επιλογές για credit scoring πάνω σε δομημένα δεδομένα. Το XGBoost τείνει να προτιμάται όταν δίνεται μεγάλη έμφαση σε αυστηρό έλεγχο της πολυπλοκότητας και στη σταθερή απόδοση, ενώ το LightGBM είναι ιδιαίτερα χρήσιμο όταν ο όγκος δεδομένων και το υπολογιστικό κόστος καθίστανται καθοριστικοί παράγοντες. Και στις δύο περιπτώσεις, η αξία τους στον πιστωτικό κίνδυνο συνδέεται περισσότερο με την πρακτική ικανότητά τους να βελτιώνουν την ταξινόμηση μεταξύ χαμηλού και υψηλού κινδύνου αθέτησης (Chen & Guestrin, 2016; Ke et al., 2017; Gambacorta et al., 2019).

4.2.4 Τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Networks)

Τα Τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Networks, ANN) είναι μοντέλα μηχανικής μάθησης εμπνευσμένα από τη γενική ιδέα της λειτουργίας του εγκεφάλου, όπου η πληροφορία ρέει μέσα από διασυνδεδεμένους “νευρώνες” οργανωμένους σε επίπεδα, input layer, hidden layers και output layer. Η βασική διαδικασία μάθησης περιλαμβάνει διαδικασίες όπως forward propagation, υπολογισμό του σφάλματος μέσω μιας loss function, και στη συνέχεια backpropagation, ώστε να ενημερωθούν τα βάρη του δικτύου και να βελτιωθούν οι προβλέψεις σε διαδοχικές επαναλήψεις εκπαίδευσης (Business Analytics Newsletter, 2024; PyTorch Tutorials, 2025). Με αυτή τη δομή, τα ANN μπορούν να μάθουν πολύπλοκες και μη γραμμικές σχέσεις των δεδομένων, κάτι που τα καθιστά ευέλικτα σε ποικίλα προβλήματα πρόβλεψης και ταξινόμησης (Business Analytics Newsletter, 2024; PyTorch Tutorials, 2025).

Στον πιστωτικό κίνδυνο, τα ANN έχουν χρησιμοποιηθεί εδώ και δεκαετίες ως εναλλακτική στα παραδοσιακά credit-scoring μοντέλα, ακριβώς επειδή μπορούν να εντοπίσουν σύνθετα μοτίβα δανειοληπτικής συμπεριφοράς που δεν αποτυπώνονται εύκολα

από γραμμικές σχέσεις. Ο West (2000), σε κλασική μελέτη για credit scoring, έδειξε ότι διαφορετικές αρχιτεκτονικές νευρωνικών δικτύων μπορούν να προσφέρουν μικρές αλλά ουσιαστικές βελτιώσεις στην ακρίβεια ταξινόμησης, της τάξης του 0.5% έως 3%, αν και το πολυεπίπεδο perceptron- αντίληπτρο δεν ήταν πάντοτε η καλύτερη αρχιτεκτονική και το μοντέλο της logistic regression παρέμεινε πολύ ισχυρό σημείο αναφοράς. Παράλληλα, η μεταγενέστερη βιβλιογραφία και οι πιο πρόσφατες συστηματικές ανασκοπήσεις καταγράφουν ότι οι μέθοδοι machine learning και deep learning στο credit risk αντιμετωπίζουν συχνά ζητήματα συχνά σε θέματα διαφάνειας, ανισορροπίας κλάσεων, ασυνέπειας datasets και επιχειρησιακής ερμηνευσιμότητας, κάτι που είναι ιδιαίτερα σημαντικό σε ρυθμιζόμενα περιβάλλοντα όπως η τραπεζική πίστη (West, 2000; Shi et al., 2022).

Άρα, σε εφαρμογές πιστωτικού κινδύνου, τα ANN είναι πιο χρήσιμα όταν ο στόχος είναι η επεξεργασία σύνθετων και ισχυρά μη γραμμικών μοτίβων δεδομένων. Ωστόσο, σε σχέση με XGBoost ή LightGBM, το τίμημα είναι συνήθως η χαμηλότερη ερμηνευσιμότητα και η μεγαλύτερη ανάγκη για προσεκτική αρχιτεκτονική επιλογή, training και συμμόρφωσης στους θεσμούς. Για τον λόγο αυτό, ενώ τα Τεχνητά Νευρωνικά Δίκτυα (ANN) και οι άλλες τεχνικές βαθιάς μάθησης (deep learning) προσφέρουν εξαιρετική προγνωστική ικανότητα (predictive performance), θεωρούνται συχνά "μαύρα κουτιά" (black-box models), γεγονός που καθιστά δύσκολη την υιοθέτησή τους σε ρυθμιζόμενα περιβάλλοντα (West, 2000; Shi et al., 2022).

4.3 Προετοιμασία Δεδομένων και Feature Engineering

4.3.1 Η σημασία της σωστής προετοιμασίας των Δεδομένων

Η αποτελεσματικότητα των μοντέλων μηχανικής μάθησης στην αξιολόγηση του πιστωτικού κινδύνου εξαρτάται σε καθοριστικό βαθμό από την ποιότητα, τη δομή και την προεπεξεργασία των δεδομένων. Η βιβλιογραφία υπογραμμίζει ότι η απόδοση ενός μοντέλου δεν καθορίζεται αποκλειστικά από την επιλογή του αλγορίθμου, αλλά σε μεγάλο βαθμό από τα δεδομένα που χρησιμοποιούνται για την εκπαίδευσή του (García et al., 2015). Στο πλαίσιο αυτό, η διαδικασία προετοιμασίας δεδομένων (data preprocessing) και η κατασκευή χαρακτηριστικών (feature engineering) αποτελούν κρίσιμα στάδια της ανάλυσης.

Η σημασία της σωστής προετοιμασίας δεδομένων αποτυπώνεται και στη γνωστή αρχή "garbage in, garbage out", η οποία δηλώνει ότι ακόμη και τα πιο εξελιγμένα μοντέλα δεν μπορούν να αποδώσουν ικανοποιητικά όταν τα δεδομένα είναι ελλιπή, θορυβώδη ή μη αντιπροσωπευτικά. Στον τομέα του πιστωτικού κινδύνου, όπου οι αποφάσεις έχουν άμεσες οικονομικές και κοινωνικές συνέπειες, η διασφάλιση της ποιότητας των δεδομένων είναι ιδιαίτερα σημαντική.

4.3.2 Feature Engineering

Το feature engineering αναφέρεται στη διαδικασία δημιουργίας, επιλογής και μετασχηματισμού μεταβλητών, με στόχο τη βελτίωση της προβλεπτικής ικανότητας των μοντέλων. Στο credit scoring, η επιλογή των κατάλληλων χαρακτηριστικών αποτελεί κρίσιμο

παράγοντα ως προς την ορθή εξαγωγή αποτελεσμάτων, καθώς τα χαρακτηριστικά αυτά πρέπει να αποτυπώνουν όσο το δυνατόν πιο πιστά τη συμπεριφορά και την οικονομική κατάσταση του δανειολήπτη. Ένα χαρακτηριστικό παράδειγμα αποτελεί ο δείκτης Debt-to-Income (DTI), ο οποίος εκφράζει τον λόγο του συνολικού χρέους προς το εισόδημα. Ο δείκτης αυτός θεωρείται πιο ισχυρός από τις επιμέρους μεταβλητές, καθώς αποτυπώνει τη σχετική επιβάρυνση του δανειολήπτη και συνδέεται άμεσα με την ικανότητά του να εξυπηρετεί τις υποχρεώσεις του (Thomas et al., 2002).

Επιπλέον, η διαδικασία του feature engineering περιλαμβάνει τη δημιουργία σύνθετων δεικτών, όπως: credit utilization ratio (χρήση πιστωτικού ορίου), αριθμός καθυστερήσεων πληρωμών, μέση διάρκεια πιστωτικού ιστορικού, λόγος δανείου προς αξία εξασφάλισης (Loan-to-Value, LTV). Η χρήση τέτοιων χαρακτηριστικών επιτρέπει την αποτύπωση πιο σύνθετων πτυχών του πιστωτικού κινδύνου, οι οποίες δεν είναι εμφανείς μέσω απλών μεταβλητών. Σε πολλά μοντέλα εφαρμόζονται τεχνικές μετασχηματισμού μεταβλητών, όπως λογαριθμικοί μετασχηματισμοί ή κατηγοριοποίηση (binning), με στόχο τη βελτίωση της σχέσης μεταξύ μεταβλητών και στόχου. Στα credit scorecards, για παράδειγμα, η χρήση Weight of Evidence (WoE) επιτρέπει τη μετατροπή των μεταβλητών σε μορφή που είναι πιο κατάλληλη για στατιστική ανάλυση (Siddiqi, 2012).

Σύμφωνα με τον Domingos (2012), η σωστή επιλογή χαρακτηριστικών μπορεί να έχει μεγαλύτερη επίδραση στην απόδοση ενός μοντέλου από την επιλογή του ίδιου του αλγορίθμου, γεγονός που καθιστά το feature engineering κρίσιμο στάδιο της διαδικασίας.

4.3.3 Διαχείριση Ελλιπών Δεδομένων (Handling Missing Data)

Η ύπαρξη ελλιπών τιμών αποτελεί συχνό φαινόμενο σε υπό επεξεργασία δεδομένα πιστωτικού κινδύνου, ιδιαίτερα όταν τα δεδομένα προέρχονται από πολλαπλές πηγές ή περιλαμβάνουν πληροφορίες για διαφορετικές κατηγορίες δανειοληπτών. Η αντιμετώπιση των ελλιπών δεδομένων αποτελεί κρίσιμο ζήτημα, καθώς η λανθασμένη διαχείρισή τους μπορεί να οδηγήσει σε λανθασμένα αποτελέσματα και μειωμένη ακρίβεια. Η πιο απλή προσέγγιση είναι η διαγραφή των παρατηρήσεων με ελλείπουσες τιμές (listwise deletion). Ωστόσο, η μέθοδος αυτή οδηγεί σε απώλεια πληροφορίας και μπορεί να εισάγει “bias”-προκατάληψη, ιδιαίτερα όταν τα δεδομένα δεν είναι τυχαία ελλιπή (Little & Rubin, 2019).

Για τον λόγο αυτό, χρησιμοποιούνται πιο εξελιγμένες τεχνικές, όπως:

1) Mean/Median Imputation (Καταλογισμός Μέσου/Διαμέσου)

Πρόκειται για την αντικατάσταση των κενών τιμών με τον μέσο όρο ή τη διάμεσο των υπάρχουσών παρατηρήσεων της ίδιας μεταβλητής. Αν και είναι εύκολη στην εφαρμογή, θεωρείται πλέον παρωχημένη καθώς υποτιμά τη διασπορά (variance) και αλλοιώνει τις συσχετίσεις μεταξύ των δεδομένων (Little & Rubin, 2019).

2) Regression Imputation (Καταλογισμός με Παλινδρόμηση)

Σε αυτή τη μέθοδο, η μεταβλητή με τις ελλείπουσες τιμές αντιμετωπίζεται ως εξαρτημένη, ενώ οι υπόλοιπες μεταβλητές ως ανεξάρτητες. Ένα μοντέλο παλινδρόμησης προβλέπει τις

τιμές που λείπουν. Παρότι διατηρεί τις σχέσεις μεταξύ των μεταβλητών, μπορεί να οδηγήσει σε υπερβολικά "τέλεια" αποτελέσματα (overfitting), καθώς δεν λαμβάνει υπόψη το τυχαίο σφάλμα (Enders, 2010).

3) k-Nearest Neighbors Imputation (k-NN Imputation)

Ο αλγόριθμος k-NN εντοπίζει τις k πλησιέστερες παρατηρήσεις (γείτονες) με βάση μια μέτρηση απόστασης (π.χ. Ευκλείδεια απόσταση). Η ελλείπουσα τιμή συμπληρώνεται με τον μέσο όρο των τιμών αυτών των γειτόνων. Είναι μια μη παραμετρική μέθοδος που πλεονεκτεί όταν οι σχέσεις μεταξύ των δεδομένων είναι μη γραμμικές (Troynanskaya et al., 2001).

4) Multiple Imputation by Chained Equations (MICE)

Η μέθοδος MICE (ή Sequential Regression Multivariate Imputation) θεωρείται μία από τις πιο ισχυρές τεχνικές. Αντί να υπολογίζει μία μόνο τιμή, δημιουργεί πολλαπλά σύνολα δεδομένων (multiple imputations), αναλύοντας το καθένα ξεχωριστά και συνδυάζοντας τα αποτελέσματα. Λειτουργεί μέσω μιας σειράς επαναληπτικών μοντέλων παλινδρόμησης, επιτρέποντας σε κάθε μεταβλητή να μοντελοποιηθεί σύμφωνα με τη δική της κατανομή (van Buuren & Groothuis-Oudshoorn, 2011). Η μέθοδος αυτή επιτρέπει την εκτίμηση της αβεβαιότητας που προκύπτει από τις ελλείπουσες τιμές και οδηγεί σε πιο αξιόπιστα αποτελέσματα (Azur et al., 2011).

Επιπλέον, ορισμένα μοντέλα μηχανικής μάθησης, όπως το XGBoost, έχουν τη δυνατότητα να διαχειρίζονται απευθείας ελλείπουσες τιμές, επιλέγοντας αυτόματα τη βέλτιστη κατεύθυνση για τις παρατηρήσεις με missing values (Chen & Guestrin, 2016).

4.3.4 Βελτιστοποίηση Υπερπαραμέτρων (Hyperparameter Tuning)

Η απόδοση των AI-based μοντέλων εξαρτάται σε μεγάλο βαθμό από τις υπερπαραμέτρους (hyperparameters), οι οποίες καθορίζουν τη δομή και τη λειτουργία του μοντέλου. Σε αντίθεση με τις παραμέτρους που εκτιμώνται κατά την εκπαίδευση, οι υπερπαραμέτροι καθορίζονται πριν από την εκπαίδευση και επηρεάζουν τη συμπεριφορά του μοντέλου. Ως παραδείγματα υπερπαραμέτρων μπορούν να θεωρηθούν : το μέγιστο βάθος δέντρου (max_depth), ο αριθμός δέντρων (n_estimators), το learning rate (στο boosting) ή regularization parameters κ.α. Η επιλογή των κατάλληλων τιμών για τις υπερπαραμέτρους είναι κρίσιμη, καθώς επηρεάζει άμεσα την ισορροπία μεταξύ bias και variance. Για παράδειγμα, ένα πολύ βαθύ δέντρο μπορεί να οδηγήσει σε overfitting, ενώ ένα πολύ ρηχό δέντρο μπορεί να μην αποτυπώνει επαρκώς τα δεδομένα.

Η βελτιστοποίηση των υπερπαραμέτρων πραγματοποιείται μέσω μεθόδων όπως:

Grid Search: Είναι η πιο απλή και παραδοσιακή μέθοδος. Λειτουργεί ορίζοντας ένα προκαθορισμένο πλέγμα (grid) πιθανών τιμών για κάθε υπερπαραμέτρο και δοκιμάζοντας εξαντλητικά κάθε δυνατό συνδυασμό. Παρόλο που εγγυάται την εύρεση του καλύτερου συνδυασμού, μέσα στο ορισμένο πλέγμα είναι υπολογιστικά ακριβής και αναποτελεσματική όταν ο αριθμός των παραμέτρων αυξάνεται (Frazier, 2018).

Random Search: Αντί να δοκιμάζει κάθε συνδυασμό, η μέθοδος αυτή επιλέγει τυχαία δείγματα από το χώρο των υπερπαραμέτρων. Έρευνες έχουν δείξει ότι το Random Search είναι συχνά πιο αποτελεσματικό από το Grid Search, καθώς μπορεί να εντοπίσει βέλτιστες τιμές σε μικρότερο χρόνο, αποφεύγοντας την περιττή δαπάνη πόρων σε παραμέτρους που δεν επηρεάζουν σημαντικά το μοντέλο (Bergstra, J., & Bengio, Y., 2012).

Bayesian Optimization: Πρόκειται για μια πιο εξελιγμένη, πιθανοτική μέθοδο. Χρησιμοποιεί τα αποτελέσματα των προηγούμενων δοκιμών για να κατασκευάσει ένα "μοντέλο-αντικατάστατη" (surrogate model) που προβλέπει ποιος συνδυασμός υπερπαραμέτρων είναι πιθανότερο να βελτιώσει την απόδοση. Είναι ιδανική για περιπτώσεις όπου η εκπαίδευση του μοντέλου είναι πολύ χρονοβόρα, καθώς απαιτεί λιγότερες δοκιμές για να φτάσει στο βέλτιστο αποτέλεσμα Snoek, (J.Larochelle, H. Adams, 2012).

Συμπερασματικά, η Random Search έχει αποδειχθεί πιο αποδοτική από την Grid Search σε πολλές εφαρμογές, καθώς εξερευνά πιο αποτελεσματικά τον χώρο των παραμέτρων (Bergstra & Bengio, 2012). Ωστόσο η Bayesian Optimization αποτελεί μια ακόμα πιο εξελιγμένη προσέγγιση, καθώς χρησιμοποιεί προηγούμενα αποτελέσματα για να καθοδηγήσει τη διαδικασία αναζήτησης.

4.3.5 Κανονικοποίηση και Κλιμάκωση Δεδομένων

Σε πολλά μοντέλα μηχανικής μάθησης, ιδιαίτερα στα Neural Networks και τα Support Vector Machines, η κλίμακα των δεδομένων επηρεάζει σημαντικά την απόδοση. Η σωστή κλιμάκωση των δεδομένων είναι ένα από τα πιο κρίσιμα βήματα στην προεπεξεργασία, καθώς πολλοί αλγόριθμοι υπολογίζουν αποστάσεις (όπως ο Ευκλείδιος χώρος) ή βασίζονται στην κάθοδο κλίσης (gradient descent) για τη βελτιστοποίηση των παραμέτρων τους.

Για τον λόγο αυτό, εφαρμόζονται τεχνικές κανονικοποίησης, όπως:

Min-Max Scaling (Normalization): Η τεχνική Min-Max Scaling μετασχηματίζει τα δεδομένα έτσι ώστε να περιορίζονται σε ένα συγκεκριμένο εύρος, συνήθως μεταξύ 0 και 1. Είναι ιδιαίτερα χρήσιμη όταν η κατανομή των δεδομένων δεν είναι απαραίτητα κανονική (Gaussian) και όταν θέλουμε να διατηρήσουμε τις ακριβείς σχέσεις μεταξύ των τιμών, αλλά σε μια σταθερή κλίμακα. Είναι ιδανική για αλγόριθμους που δεν υποθέτουν κάποια συγκεκριμένη κατανομή, όπως τα Νευρωνικά Δίκτυα και οι k-Nearest Neighbors (k-NN) (Bishop, C. M., 2006). Επίσης είναι εξαιρετικά ευαίσθητη σε outliers (ακραίες τιμές). Αν υπάρχει μια πολύ μεγάλη τιμή, τα υπόλοιπα δεδομένα θα "συμπιεστούν" σε ένα πολύ μικρό εύρος, χάνοντας την πληροφορία τους (Bishop, C. M., 2006).

Standardization (Z-score Normalization): Το μοντέλο Standardization μετασχηματίζει τα δεδομένα έτσι ώστε να έχουν μέση τιμή (μ) ίση με 0 και τυπική απόκλιση (σ) ίση με 1. Αντί να περιορίζει τις τιμές σε ένα κλειστό εύρος, επικεντρώνεται στην κεντροποίηση της κατανομής. Είναι πολύ πιο ανθεκτική τεχνική, παρουσία outliers, σε σχέση με το Min-Max

scaling. Επιπλέον, είναι απαραίτητη για αλγόριθμους που υποθέτουν ότι τα δεδομένα ακολουθούν κανονική κατανομή, όπως η Γραμμική Παλινδρόμηση και οι Support Vector Machines (SVMs). Για αυτό το λόγο προτιμάται συχνά όταν οι αλγόριθμοι χρησιμοποιούν μεθόδους βελτιστοποίησης (gradient descent), καθώς βοηθά στη γρηγορότερη σύγκλιση του μοντέλου (Theodoridis, S., Koutroumbas, K., 2008).

Η κανονικοποίηση εξασφαλίζει ότι όλες οι μεταβλητές βρίσκονται στην ίδια κλίμακα, αποτρέποντας την υπερεκτίμηση μεταβλητών με μεγάλες τιμές (Hastie et al., 2009).

4.3.6 Σχέση με την Απόδοση των Μοντέλων

Η προετοιμασία δεδομένων και το feature engineering επηρεάζουν άμεσα:

- την ακρίβεια των προβλέψεων
- τη σταθερότητα του μοντέλου
- τη δυνατότητα γενίκευσης σε νέα δεδομένα

Στην πράξη, πολλές μελέτες έχουν δείξει ότι η βελτίωση των δεδομένων μπορεί να έχει μεγαλύτερη επίδραση από την επιλογή του αλγορίθμου (Domingos, 2012). Αυτό είναι ιδιαίτερα σημαντικό στο credit scoring, όπου η ποιότητα των δεδομένων μπορεί να επηρεάσει άμεσα την αξιοπιστία των αποφάσεων. Συνεπώς, η προετοιμασία δεδομένων δεν αποτελεί απλώς ένα προκαταρκτικό στάδιο, αλλά ένα θεμελιώδες μέρος της διαδικασίας ανάπτυξης μοντέλων μηχανικής μάθησης.

5. Σύγκριση Παραδοσιακών και AI-based Μοντέλων

5.1 Εισαγωγή

Στα προηγούμενα κεφάλαια παρουσιάστηκαν οι βασικές αρχές των παραδοσιακών μοντέλων πιστωτικής αξιολόγησης, καθώς και οι σύγχρονες προσεγγίσεις που βασίζονται στη μηχανική μάθηση και την τεχνητή νοημοσύνη. Η σύγκριση μεταξύ παραδοσιακών μοντέλων πιστωτικής αξιολόγησης και μοντέλων που βασίζονται στην τεχνητή νοημοσύνη αποτελεί ένα από τα σημαντικότερα ζητήματα στη σύγχρονη ανάλυση πιστωτικού κινδύνου. Η πιστωτική αξιολόγηση, γνωστή διεθνώς ως credit scoring, αφορά τη διαδικασία εκτίμησης της πιθανότητας, ένας δανειολήπτης να αθετήσει τις οικονομικές του υποχρεώσεις και να μην αποπληρώσει εγκαίρως ή πλήρως ένα δάνειο ή άλλη μορφή πίστωσης. Στο τραπεζικό και χρηματοπιστωτικό περιβάλλον, τα μοντέλα credit scoring χρησιμοποιούνται για την έγκριση ή απόρριψη αιτήσεων δανείων, τον καθορισμό επιτοκίων, την ταξινόμηση πελατών σε κατηγορίες κινδύνου και τη διαχείριση πιστωτικών χαρτοφυλακίων (Thomas et al., 2017).

Το παρόν κεφάλαιο εστιάζει στη συγκριτική αξιολόγηση των δύο αυτών κατηγοριών, με σκοπό να αναδειχθούν τα βασικά πλεονεκτήματα, οι περιορισμοί και οι προϋποθέσεις

αποτελεσματικής εφαρμογής των μοντέλων στο πεδίο του credit scoring. Η σύγκριση παραδοσιακών και AI-based μοντέλων δεν μπορεί να περιοριστεί αποκλειστικά στο ερώτημα π.χ. ποιο μοντέλο προβλέπει καλύτερα την αθέτηση. Αντίθετα, απαιτείται πολυδιάστατη αξιολόγηση που να περιλαμβάνει την προβλεπτική απόδοση, την ανθεκτικότητα, την προσαρμοστικότητα, την ερμηνευσιμότητα, τη συμμόρφωση με το κανονιστικό πλαίσιο, καθώς και τους κινδύνους overfitting και αλγοριθμικής μεροληψίας. Η ανάγκη αυτή είναι ιδιαίτερα σημαντική στον χρηματοπιστωτικό τομέα, όπου οι αποφάσεις των μοντέλων επηρεάζουν άμεσα την πρόσβαση των πολιτών και των επιχειρήσεων στη χρηματοδότηση (European Banking Authority [EBA], 2023).

Συνεπώς, το κεφάλαιο αυτό επιχειρεί να αποτυπώσει τις βασικές διαφορές μεταξύ παραδοσιακών και AI-based μοντέλων, αναδεικνύοντας ότι η επιλογή της κατάλληλης μεθόδου εξαρτάται από τον σκοπό της εφαρμογής, την ποιότητα των διαθέσιμων δεδομένων, τις απαιτήσεις ως προς την ερμηνευσιμότητα και το κανονιστικό πλαίσιο στο οποίο λειτουργεί ο χρηματοπιστωτικός οργανισμός (Thomas et al., 2017; Rudin, 2019).

5.2 Απόδοση, Ανθεκτικότητα και Προσαρμοστικότητα

5.2.1 Προβλεπτική απόδοση

Η προβλεπτική απόδοση ή predictive performance, αναφέρεται στην ικανότητα ενός μοντέλου να προβλέπει σωστά την πιθανότητα αθέτησης ενός δανειολήπτη. Στο credit scoring, η απόδοση ενός μοντέλου δεν αξιολογείται μόνο με βάση το ποσοστό σωστών προβλέψεων, αλλά και με πιο εξειδικευμένους δείκτες, όπως το AUC, το Gini coefficient, η ακρίβεια ταξινόμησης, η ευαισθησία και η ειδικότητα (Lessmann et al., 2015). Ο δείκτης AUC, δηλαδή Area Under the Curve, μετρά την ικανότητα ενός μοντέλου να διαχωρίζει τους δανειολήπτες υψηλού κινδύνου από τους δανειολήπτες χαμηλού κινδύνου. Όσο υψηλότερη είναι η τιμή του AUC, τόσο μεγαλύτερη είναι η ικανότητα διάκρισης του μοντέλου. Αντίστοιχα, ο δείκτης Gini coefficient χρησιμοποιείται ευρέως στον τραπεζικό κλάδο και συνδέεται άμεσα με το AUC, καθώς εκφράζει τη διαχωριστική ικανότητα του μοντέλου με τρόπο πιο οικείο για τις εφαρμογές πιστωτικού κινδύνου (Lessmann et al., 2015).

Τα παραδοσιακά μοντέλα, όπως η Logistic Regression, μπορούν να παρουσιάσουν ικανοποιητική προβλεπτική απόδοση όταν τα δεδομένα είναι σχετικά καθαρά, οι μεταβλητές είναι καλά επιλεγμένες και οι σχέσεις μεταξύ τους δεν είναι ιδιαίτερα σύνθετες. Η λογιστική παλινδρόμηση επιτρέπει την εκτίμηση της επίδρασης κάθε μεταβλητής στην πιθανότητα αθέτησης, γεγονός που την καθιστά χρήσιμη τόσο για πρόβλεψη όσο και για ερμηνεία. Ωστόσο, η βασική της αδυναμία είναι ότι δυσκολεύεται να αποτυπώσει πολύπλοκες μη γραμμικές σχέσεις χωρίς πρόσθετη προεπεξεργασία ή μετασχηματισμό των δεδομένων (Hosmer et al., 2013).

Απ' την άλλη, τα AI-based μοντέλα υπερτερούν συχνά στην πρόβλεψη επειδή μπορούν να εντοπίζουν μη γραμμικά μοτίβα και σύνθετες αλληλεπιδράσεις μεταξύ μεταβλητών. Για παράδειγμα, ένα Decision Tree, δηλαδή δέντρο απόφασης, χωρίζει το δείγμα σε διαδοχικές ομάδες με βάση συγκεκριμένους κανόνες. Έτσι, μπορεί να εντοπίσει ότι ένας πελάτης με σχετικά χαμηλό εισόδημα δεν είναι απαραίτητα υψηλού κινδύνου εάν έχει σταθερή εργασία, χαμηλό χρέος και άριστο ιστορικό πληρωμών (Hastie et al., 2009).

Τα Random Forests αποτελούν επέκταση των Decision Trees και βασίζονται στον συνδυασμό πολλών διαφορετικών δέντρων απόφασης. Κάθε δέντρο δημιουργεί μια επιμέρους πρόβλεψη και το τελικό αποτέλεσμα προκύπτει από τον συνδυασμό των προβλέψεων όλων των δέντρων. Η λογική αυτή μειώνει τον κίνδυνο ένα μεμονωμένο δέντρο να οδηγήσει σε ασταθές ή υπερβολικά προσαρμοσμένο αποτέλεσμα, αυξάνοντας έτσι τη συνολική ακρίβεια και σταθερότητα του μοντέλου (Hastie et al., 2009). Τα Gradient Boosting Machines αποτελούν επίσης ισχυρή κατηγορία ensemble models. Σε αυτά τα μοντέλα, οι αλγόριθμοι εκπαιδεύονται διαδοχικά, με κάθε νέο μοντέλο να προσπαθεί να διορθώσει τα λάθη του προηγούμενου. Με απλούστερους όρους, το μοντέλο «μαθαίνει» σταδιακά από τις προηγούμενες αδυναμίες του και βελτιώνει την προβλεπτική του ικανότητα. Αυτή η διαδικασία μπορεί να οδηγήσει σε πολύ υψηλή ακρίβεια, αλλά ταυτόχρονα αυξάνει την πολυπλοκότητα και τον κίνδυνο overfitting εάν δεν εφαρμοστούν κατάλληλοι μηχανισμοί ελέγχου (Lessmann et al., 2015).

Η βιβλιογραφία δείχνει ότι τα ensemble models, όπως Random Forests και Gradient Boosting, συχνά παρουσιάζουν καλύτερη απόδοση από τη Logistic Regression σε μεγάλα και σύνθετα datasets. Ωστόσο, η υπεροχή τους δεν είναι απόλυτη ούτε ανεξάρτητη από το πλαίσιο εφαρμογής. Σε μικρότερα ή πιο ομοιογενή σύνολα δεδομένων, τα παραδοσιακά μοντέλα μπορεί να παραμένουν ανταγωνιστικά, ενώ σε περιβάλλοντα αυξημένης κανονιστικής εποπτείας η ερμηνευσιμότητα μπορεί να θεωρείται εξίσου σημαντική με την ακρίβεια (Lessmann et al., 2015; Rudin, 2019).

5.2.2 Ανθεκτικότητα

Η ανθεκτικότητα ή robustness, αναφέρεται στην ικανότητα ενός μοντέλου να διατηρεί την απόδοσή του όταν εφαρμόζεται σε νέα δεδομένα, σε διαφορετικές χρονικές περιόδους ή σε μεταβαλλόμενες οικονομικές συνθήκες. Στο credit scoring, η ανθεκτικότητα είναι ιδιαίτερα κρίσιμη, επειδή ένα μοντέλο που αναπτύχθηκε σε μια συγκεκριμένη περίοδο μπορεί να χρησιμοποιηθεί για αρκετά χρόνια σε περιβάλλοντα όπου οι συνθήκες αγοράς, η ανεργία, τα επιτόκια και η συμπεριφορά των δανειοληπτών μεταβάλλονται συνεχώς (EBA, 2023).

Τα παραδοσιακά μοντέλα θεωρούνται συχνά πιο σταθερά λόγω της απλούστερης δομής τους και του μικρότερου αριθμού παραμέτρων. Η σταθερότητα αυτή μειώνει την πιθανότητα το μοντέλο να βασιστεί σε τυχαίες ιδιαιτερότητες του δείγματος εκπαίδευσης. Για παράδειγμα, ένα scorecard που βασίζεται σε λίγες καλά τεκμηριωμένες μεταβλητές είναι πιο εύκολο να παρακολουθηθεί, να ελεγχθεί και να προσαρμοστεί από ένα πολύπλοκο black-box μοντέλο (Thomas et al., 2017).

Αντίθετα, τα AI-based μοντέλα μπορεί να είναι πιο ευαίσθητα σε αλλαγές της κατανομής των δεδομένων. Το φαινόμενο αυτό είναι γνωστό ως *model drift* και περιγράφει τη σταδιακή μείωση της ακρίβειας ενός μοντέλου όταν οι σχέσεις που είχε μάθει κατά την εκπαίδευση δεν ισχύουν πλέον στον ίδιο βαθμό. Για παράδειγμα, ένα μοντέλο που εκπαιδεύτηκε σε περίοδο οικονομικής σταθερότητας μπορεί να παρουσιάσει μειωμένη αξιοπιστία σε περίοδο ύφεσης, υψηλού πληθωρισμού ή αύξησης των επιτοκίων (EBA, 2023).

Η αντιμετώπιση του *model drift* απαιτεί συστηματική παρακολούθηση, επαναξιολόγηση και, όταν είναι αναγκαίο, επανεκπαίδευση του μοντέλου. Τεχνικές όπως το *backtesting*, το *stress testing* και το *ongoing monitoring* είναι απαραίτητες για την αξιολόγηση της πραγματικής συμπεριφοράς ενός μοντέλου στον χρόνο. Το *backtesting* συγκρίνει τις προβλέψεις του μοντέλου με πραγματικά ιστορικά αποτελέσματα, ενώ το *stress testing* εξετάζει την απόδοσή του σε ακραία ή δυσμενή σενάρια (Basel Committee on Banking Supervision [BCBS], 2013). Η ανθεκτικότητα δεν εξαρτάται μόνο από τον αλγόριθμο, αλλά και από την ποιότητα των δεδομένων, τη διαδικασία ανάπτυξης, τη διακυβέρνηση του μοντέλου και τους μηχανισμούς ελέγχου. Για τον λόγο αυτό, οι εποπτικές αρχές δίνουν ιδιαίτερη έμφαση στη διαχείριση του κύκλου ζωής των μοντέλων, στη διαφάνεια των διαδικασιών και στην τεκμηρίωση των αλλαγών που πραγματοποιούνται σε μοντέλα πιστωτικού κινδύνου (BCBS, 2013; EBA, 2023).

5.2.3 Προσαρμοστικότητα

Η προσαρμοστικότητα ή *adaptability*, αφορά την ικανότητα ενός μοντέλου να ενσωματώνει νέα δεδομένα, νέες μεταβλητές και μεταβολές στη συμπεριφορά των δανειοληπτών. Τα AI-based μοντέλα παρουσιάζουν σημαντικό πλεονέκτημα σε αυτό το πεδίο, επειδή μπορούν να επανεκπαιδεύονται δυναμικά και να αξιοποιούν μεγαλύτερη ποικιλία δεδομένων σε σχέση με τα παραδοσιακά μοντέλα (Lessmann et al., 2015).

Ένα σημαντικό στοιχείο της προσαρμοστικότητας είναι η χρήση *alternative data*. Με τον όρο αυτό εννοούνται δεδομένα που δεν ανήκουν στις κλασικές τραπεζικές πληροφορίες, όπως το ιστορικό δανείων και πληρωμών, αλλά προέρχονται από άλλες πηγές. Τέτοια δεδομένα μπορεί να περιλαμβάνουν συναλλακτική συμπεριφορά, ψηφιακά ίχνη, μοτίβα κατανάλωσης ή δεδομένα από πλατφόρμες ηλεκτρονικού εμπορίου. Η χρήση τους μπορεί να είναι ιδιαίτερα χρήσιμη για άτομα με περιορισμένο πιστωτικό ιστορικό, όπως νέοι εργαζόμενοι, αυτοαπασχολούμενοι ή οικονομικά αποκλεισμένες ομάδες (Barocas & Selbst, 2016).

Ωστόσο, η χρήση των *alternative data* δημιουργεί σημαντικές προκλήσεις προστασίας προσωπικών δεδομένων, διαφάνειας και αμεροληψίας. Μια μεταβλητή που φαίνεται ουδέτερη μπορεί να λειτουργεί ως έμμεσος δείκτης κοινωνικής ή οικονομικής κατάστασης, γεωγραφικής προέλευσης, οδηγώντας σε ακούσιες διακρίσεις. Επομένως, η προσαρμοστικότητα των AI-based μοντέλων πρέπει να συνοδεύεται από αυστηρούς ελέγχους ποιότητας δεδομένων, *fairness testing* και σαφείς διαδικασίες τεκμηρίωσης (Barocas & Selbst, 2016).

Τα παραδοσιακά μοντέλα, από την άλλη πλευρά, είναι συνήθως λιγότερο ευέλικτα. Η ανακατασκευή ενός scorecard απαιτεί χειροκίνητη επιλογή μεταβλητών, επανεκτίμηση συντελεστών, στατιστικούς ελέγχους και έγκριση από αρμόδιες μονάδες κινδύνου και συμμόρφωσης. Αυτό δεν σημαίνει ότι τα παραδοσιακά μοντέλα είναι αναποτελεσματικά, αλλά ότι προσαρμόζονται πιο αργά σε ταχέως μεταβαλλόμενα δεδομένα και αγορές (Thomas et al., 2017).

5.3 Προβλήματα Overfitting και Bias

5.3.1 Overfitting

Το overfitting ή υπερπροσαρμογή, αποτελεί βασικό πρόβλημα των μοντέλων μηχανικής μάθησης. Εμφανίζεται όταν ένα μοντέλο μαθαίνει υπερβολικά καλά τις ιδιαιτερότητες του training dataset, δηλαδή του συνόλου δεδομένων εκπαίδευσης, αντί να μαθαίνει γενικεύσιμα μοτίβα που μπορούν να εφαρμοστούν σε νέα δεδομένα. Έτσι, το μοντέλο μπορεί να παρουσιάζει πολύ υψηλή απόδοση στα δεδομένα εκπαίδευσης, αλλά χαμηλότερη απόδοση σε πραγματικές συνθήκες εφαρμογής (Hastie et al., 2009).

Στο credit scoring, το overfitting μπορεί να έχει σοβαρές πρακτικές συνέπειες. Ένα υπέρ προσαρμοσμένο μοντέλο μπορεί να υποεκτιμήσει τον πραγματικό κίνδυνο ορισμένων πελατών ή αντίθετα, να χαρακτηρίσει ως υψηλού κινδύνου πελάτες που στην πραγματικότητα είναι συνεπείς. Αυτό μπορεί να οδηγήσει είτε σε αύξηση επισφαλειών είτε σε απώλεια πελατών και περιορισμό της χρηματοδότησης σε άτομα που θα μπορούσαν να εξυπηρετήσουν κανονικά τις υποχρεώσεις τους (Thomas et al., 2017). Οι βασικές αιτίες του overfitting περιλαμβάνουν την υπερβολική πολυπλοκότητα του μοντέλου, τον μεγάλο αριθμό μεταβλητών σε σχέση με το μέγεθος του δείγματος, την ύπαρξη θορύβου στα δεδομένα και την ανεπαρκή διαδικασία επικύρωσης. Για παράδειγμα, ένα μοντέλο που χρησιμοποιεί εκατοντάδες μεταβλητές σε ένα μικρό δείγμα πελατών μπορεί να εντοπίσει τυχαίες συσχετίσεις που δεν έχουν πραγματική προβλεπτική αξία (Hastie et al., 2009).

Για την αντιμετώπιση του overfitting χρησιμοποιούνται τεχνικές όπως η cross-validation, η regularization και το pruning.

-Η μέθοδος cross-validation, δηλαδή η διασταυρούμενη επικύρωση, χωρίζει τα δεδομένα σε διαφορετικά υποσύνολα ώστε να ελεγχθεί αν το μοντέλο αποδίδει σταθερά και όχι μόνο σε ένα συγκεκριμένο δείγμα.

-Η regularization, δηλαδή η κανονικοποίηση, περιορίζει την πολυπλοκότητα του μοντέλου μέσω πρόσθετων μαθηματικών περιορισμών.

-Το pruning, δηλαδή το κλάδεμα, εφαρμόζεται κυρίως στα δέντρα απόφασης και μειώνει το βάθος ή την πολυπλοκότητά τους ώστε να αποφευχθεί η υπερβολική προσαρμογή (Hastie et al., 2009).

Η ύπαρξη ανεξάρτητου test dataset, η περιοδική επανεκτίμηση του μοντέλου και η συνεχής παρακολούθηση της απόδοσής του είναι απαραίτητες πρακτικές για τη μείωση του κινδύνου overfitting. Ιδιαίτερα σε τραπεζικά περιβάλλοντα, όπου τα μοντέλα

χρησιμοποιούνται για κρίσιμες αποφάσεις, η αξιολόγηση δεν πρέπει να περιορίζεται στην αρχική φάση ανάπτυξης, αλλά να συνεχίζεται σε όλη τη διάρκεια ζωής του μοντέλου (EBA, 2023).

5.3.2 Bias και Fairness

Η αλγοριθμική μεροληψία, ή *algorithmic bias*, αποτελεί ένα από τα πιο κρίσιμα ζητήματα στη χρήση AI-based μοντέλων στο *credit scoring*. Με τον όρο *bias* περιγράφεται η συστηματική τάση ενός μοντέλου να παράγει αποτελέσματα που ευνοούν ή ζημιώνουν συγκεκριμένες ομάδες ατόμων. Στο πλαίσιο της πιστωτικής αξιολόγησης, αυτό μπορεί να οδηγήσει σε άδικη απόρριψη αιτήσεων, υψηλότερα επιτόκια ή περιορισμένη πρόσβαση σε χρηματοδότηση για ορισμένες κοινωνικές ομάδες (Barocas & Selbst, 2016). Η μεροληψία μπορεί να προέρχεται από τα δεδομένα εκπαίδευσης. Εάν τα ιστορικά δεδομένα αντανακλούν προηγούμενες κοινωνικές ή θεσμικές ανισότητες, το μοντέλο μπορεί να τις αναπαράγει ή ακόμη και να τις ενισχύσει. Αυτό σημαίνει ότι η χρήση αλγορίθμων δεν εξαλείφει αυτόματα την ανθρώπινη προκατάληψη, επειδή τα δεδομένα πάνω στα οποία εκπαιδεύονται οι αλγόριθμοι μπορεί να περιέχουν ήδη προκατειλημμένα μοτίβα (Barocas & Selbst, 2016).

Ένα ιδιαίτερα σημαντικό ζήτημα είναι οι *proxy variables*. Οι *proxy variables* είναι μεταβλητές που δεν αναφέρονται άμεσα σε ευαίσθητα χαρακτηριστικά, αλλά μπορούν να συνδέονται έμμεσα με αυτά. Για παράδειγμα, η γεωγραφική περιοχή κατοικίας μπορεί να λειτουργεί ως έμμεσος δείκτης εισοδήματος ή κοινωνικοοικονομικής κατάστασης. Έτσι, ακόμη και αν ένα μοντέλο δεν χρησιμοποιεί άμεσα μεταβλητές όπως φύλο, εθνικότητα ή θρησκεία, μπορεί να παράγει αποτελέσματα που οδηγούν σε έμμεσες διακρίσεις (Barocas & Selbst, 2016).

Η έννοια του *fairness*, δηλαδή της δικαιοσύνης ή αμεροληψίας, αφορά τις ενεργειές που διασφαλίζουν ότι το μοντέλο δεν δημιουργεί αδικαιολόγητες διακρίσεις μεταξύ διαφορετικών ομάδων. Στη βιβλιογραφία υπάρχουν διάφορες μετρικές *fairness*, όπως η ισότητα στα ποσοστά έγκρισης, η ισότητα στα ποσοστά σφαλμάτων και η ισότητα στην πιθανότητα εσφαλμένης απόρριψης. Ωστόσο, οι μετρικές αυτές δεν είναι πάντα συμβατές μεταξύ τους, γεγονός που καθιστά την έννοια του *fairness* όχι μόνο τεχνικό αλλά και ηθικό και κανονιστικό ζήτημα (Barocas & Selbst, 2016; Rudin, 2019).

Στο *credit scoring*, η αλγοριθμική μεροληψία μπορεί να οδηγήσει σε *discriminatory lending*, δηλαδή σε πρακτικές δανεισμού που εισάγουν άμεσες ή έμμεσες διακρίσεις. Μπορεί επίσης να οδηγήσει σε *financial exclusion*, δηλαδή σε αποκλεισμό ατόμων ή ομάδων από βασικές χρηματοπιστωτικές υπηρεσίες. Για τον λόγο αυτό, η χρήση AI-based μοντέλων πρέπει να συνοδεύεται από ελέγχους *fairness*, αξιολόγηση των μεταβλητών, ανάλυση των δεδομένων εκπαίδευσης και μηχανισμού ανθρώπινης εποπτείας (EBA, 2023).

5.4 Ερμηνευσιμότητα και Κανονιστική Συμμόρφωση

Ένα από τα βασικά σημεία διαφοροποίησης μεταξύ παραδοσιακών και AI-based μοντέλων πιστωτικής αξιολόγησης αφορά την ερμηνευσιμότητα και τη διαφάνεια. Τα

παραδοσιακά μοντέλα, όπως η Logistic Regression και τα credit scorecards, θεωρούνται περισσότερο κατανοητά, επειδή επιτρέπουν την παρακολούθηση της επίδρασης κάθε μεταβλητής στην τελική πιστωτική βαθμολογία. Για παράδειγμα, σε ένα scorecard είναι σχετικά εύκολο να εξηγηθεί γιατί ένας πελάτης λαμβάνει υψηλότερη ή χαμηλότερη βαθμολογία, με βάση παράγοντες όπως το εισόδημα, το ιστορικό πληρωμών ή το επίπεδο χρέους (Thomas et al., 2017).

Αντίθετα, αρκετά μοντέλα μηχανικής μάθησης χαρακτηρίζονται από μεγαλύτερη πολυπλοκότητα και συχνά αντιμετωπίζονται ως black-box models, δηλαδή ως «μαύρα κουτιά». Ο όρος αυτός χρησιμοποιείται για να περιγράψει μοντέλα των οποίων η εσωτερική λειτουργία δεν είναι εύκολα κατανοητή από τον άνθρωπο, ακόμη και όταν η προβλεπτική τους απόδοση είναι υψηλή. Το ζήτημα αυτό είναι ιδιαίτερα σημαντικό στο credit scoring, καθώς οι αποφάσεις των μοντέλων επηρεάζουν άμεσα την πρόσβαση των φυσικών προσώπων και των επιχειρήσεων στη χρηματοδότηση (Rudin, 2019).

Η ανάγκη ερμηνευσιμότητας γίνεται ακόμη πιο έντονη στο τραπεζικό περιβάλλον, όπου οι αποφάσεις πρέπει να είναι τεκμηριωμένες, ελέγξιμες και συμβατές με το ισχύον κανονιστικό πλαίσιο. Ένα μοντέλο που προβλέπει με υψηλή ακρίβεια την πιθανότητα αθέτησης δεν είναι απαραίτητα κατάλληλο για χρήση εάν δεν μπορεί να εξηγήσει επαρκώς τους λόγους μιας απόφασης. Συνεπώς, η διαφάνεια δεν αποτελεί μόνο τεχνικό χαρακτηριστικό, αλλά και προϋπόθεση υπεύθυνης χρήσης της τεχνητής νοημοσύνης στον χρηματοπιστωτικό τομέα (European Banking Authority [EBA], 2023).

Για την αντιμετώπιση αυτής της πρόκλησης έχει αναπτυχθεί το πεδίο του Explainable Artificial Intelligence, γνωστό ως Explainable AI ή XAI. Το XAI περιλαμβάνει μεθόδους και τεχνικές που επιδιώκουν να καταστήσουν πιο κατανοητές τις προβλέψεις των σύνθετων αλγορίθμων μηχανικής μάθησης. Τεχνικές όπως το SHAP και το LIME χρησιμοποιούνται ευρέως για την ερμηνεία των αποτελεσμάτων, χωρίς όμως να αναιρούν πλήρως τις προκλήσεις που δημιουργεί η χρήση black-box μοντέλων σε αποφάσεις υψηλού κινδύνου (Lundberg & Lee, 2017; Ribeiro et al., 2016).

Επομένως, ενώ το παρόν κεφάλαιο εξετάζει την ερμηνευσιμότητα ως ένα από τα βασικά κριτήρια σύγκρισης μεταξύ παραδοσιακών και AI-based μοντέλων, το επόμενο κεφάλαιο εστιάζει αναλυτικά στο Explainable AI, στο πρόβλημα των black-box μοντέλων, στις βασικές τεχνικές ερμηνείας και στη σημασία τους για τις τραπεζικές αποφάσεις.

5.5 Συνολική Αξιολόγηση και Επιλογή Κατάλληλου Μοντέλου

Η σύγκριση των παραδοσιακών και AI-based μοντέλων δείχνει ότι καμία προσέγγιση δεν είναι απόλυτα ανώτερη σε όλα τα σημεία. Τα παραδοσιακά μοντέλα διατηρούν ισχυρά πλεονεκτήματα ως προς την απλότητα, τη διαφάνεια, τη σταθερότητα και την κανονιστική αποδοχή. Είναι ιδιαίτερα κατάλληλα για περιβάλλοντα όπου τα δεδομένα είναι περιορισμένα, οι σχέσεις μεταξύ μεταβλητών είναι σχετικά απλές και η δυνατότητα εξήγησης της απόφασης αποτελεί βασική απαίτηση (Thomas et al., 2017).

Από την άλλη πλευρά, τα AI-based μοντέλα μπορούν να προσφέρουν υψηλότερη προβλεπτική απόδοση, ειδικά όταν υπάρχουν μεγάλα, σύνθετα και ετερογενή datasets. Η ικανότητά τους να αναγνωρίζουν μη γραμμικές σχέσεις και αλληλεπιδράσεις μπορεί να βελτιώσει σημαντικά την εκτίμηση πιστωτικού κινδύνου. Παρόλα αυτά, η αυξημένη πολυπλοκότητα απαιτεί ενισχυμένη διακυβέρνηση, συνεχή παρακολούθηση, ελέγχους fairness και σαφή τεκμηρίωση (Lessmann et al., 2015; EBA, 2023).

Στην πράξη, μια υβριδική προσέγγιση μπορεί να αποτελέσει την πιο ισορροπημένη λύση. Ένας χρηματοπιστωτικός οργανισμός μπορεί να χρησιμοποιεί AI-based μοντέλα για την ενίσχυση της προβλεπτικής ακρίβειας, ενώ παράλληλα εφαρμόζει τεχνικές Explainable AI, ελέγχους μεροληψίας και παραδοσιακά scorecards ως σημεία αναφοράς. Με αυτόν τον τρόπο, μπορεί να συνδυαστεί η αυξημένη απόδοση των προηγμένων αλγορίθμων με τη διαφάνεια και τη θεσμική ασφάλεια των παραδοσιακών μοντέλων (Lundberg & Lee, 2017; Rudin, 2019).

Στον πίνακα 5.1 που ακολουθεί, παρουσιάζονται συνοπτικά τα πλεονεκτήματα και τα μειονεκτήματα των βασικότερων μοντέλων. Πιο αναλυτικά, γίνεται μια σύγκριση μεταξύ του κύριου παραδοσιακού μοντέλου, Logistic Regression με AI-based μοντέλα.

Μοντέλο	Σύντομη περιγραφή	Κύριο πλεονέκτημα	Βασικός περιορισμός	Χρήση στον πιστωτικό κίνδυνο
Logistic Regression	Γραμμικό μοντέλο ταξινόμησης που εκτιμά την πιθανότητα αθέτησης.	Υψηλή ερμηνευσιμότητα και ισχυρή κανονιστική αποδοχή.	Περιορισμένη αποτύπωση σύνθετων μη γραμμικών σχέσεων.	Παραδοσιακό credit scoring μοντέλο και probability of default (PD).
Decision Tree	Μοντέλο κανόνων που χωρίζει διαδοχικά τα δεδομένα με βάση κάποια χαρακτηριστικά.	Εύκολη κατανόηση και οπτική ερμηνεία.	Αυξημένος κίνδυνος overfitting και αστάθεια.	Απλά μοντέλα έγκρισης ή αρχικής τμηματοποίησης πελατών.
Random Forest	Σύνολο πολλών δέντρων απόφασης που συνδυάζει τις προβλέψεις τους.	Καλή γενίκευση και μειωμένο overfitting σε σχέση με ένα μόνο δέντρο.	Μικρότερη ερμηνευσιμότητα από απλά μοντέλα.	Πρόβλεψη default και ταξινόμηση πελατών με δομημένα δεδομένα.
XGBoost	Boosted trees με regularization και πολύ ισχυρή απόδοση σε δομημένα δεδομένα.	Υψηλή προβλεπτική επίδοση σε credit scoring.	Μεγαλύτερη πολυπλοκότητα και ανάγκη προσεκτικής παραμετροποίησης.	Πρόβλεψη αθέτησης, ranking κινδύνου και probability of default (PD).
LightGBM	Αποδοτική υλοποίηση	Ταχύτητα εκπαίδευσης και	Μπορεί να υπερεκπαιδευτεί αν	Μεγάλα χαρτοφυλάκια

	gradient boosting για μεγάλα και πολυδιάστατα δεδομένα.	καλή κλιμάκωση.	δεν ρυθμίζεται σωστά.	δανείων και real- time scoring.
ANN	Νευρωνικό δίκτυο που μαθαίνει σύνθετα μοτίβα μέσω κρυφών επιπέδων.	Ισχυρή αποτύπωση σύνθετων και μη γραμμικών προτύπων.	Χαμηλή ερμηνευσιμότητα και δυσκολότερη κανονιστική τεκμηρίωση.	Advanced analytics και μοντελοποίηση σύνθετης συμπεριφοράς δανειοληπτών.

Πίνακας 5.1 Σύγκριση Μοντέλων Μηχανικής Μάθησης με το μοντέλο Logistic Regression

Η επιλογή του κατάλληλου μοντέλου λοιπόν, πρέπει να βασίζεται στον σκοπό χρήσης, στο μέγεθος και την ποιότητα των δεδομένων, στο επίπεδο αποδεκτού κινδύνου, στις απαιτήσεις των εποπτικών αρχών και στη δυνατότητα του οργανισμού να παρακολουθεί το μοντέλο σε όλη τη διάρκεια ζωής του. Ειδικά στον τομέα του credit scoring, όπου οι αποφάσεις επηρεάζουν άμεσα την πρόσβαση φυσικών προσώπων και επιχειρήσεων στη χρηματοδότηση, η τεχνολογική καινοτομία πρέπει να συνδυάζεται με υπευθυνότητα, διαφάνεια και δικαιοσύνη (European Union, 2024; EBA, 2023).

Συνολικά, η μελλοντική κατεύθυνση του credit scoring φαίνεται να βρίσκεται σε μια ισορροπημένη προσέγγιση, όπου η τεχνητή νοημοσύνη αξιοποιείται για τη βελτίωση της προβλεπτικής απόδοσης, αλλά υπό αυστηρούς όρους διαφάνειας, αμεροληψίας, προστασίας δεδομένων και ανθρωπίνης εποπτείας. Η τεχνολογία μπορεί να βελτιώσει σημαντικά τη διαχείριση πιστωτικού κινδύνου, αλλά μόνο όταν εντάσσεται σε ένα πλαίσιο υπεύθυνης και ελεγχόμενης χρήσης (European Union, 2024; Rudin, 2019).

6. Explainable AI και Διαφάνεια

6.1 Εισαγωγή

Η αυξανόμενη χρήση μοντέλων τεχνητής νοημοσύνης και μηχανικής μάθησης στην ανάλυση πιστωτικού κινδύνου έχει ενισχύσει σημαντικά τις δυνατότητες πρόβλεψης των χρηματοπιστωτικών οργανισμών. Ωστόσο, η μεγαλύτερη ακρίβεια στην πρόβλεψη συνοδεύεται συχνά από αυξημένη πολυπλοκότητα, γεγονός που καθιστά δυσκολότερη την κατανόηση του τρόπου με τον οποίο ένα μοντέλο καταλήγει σε μια συγκεκριμένη απόφαση. Το ζήτημα αυτό είναι ιδιαίτερα σημαντικό στο credit scoring, καθώς οι αποφάσεις που λαμβάνονται με τη βοήθεια αλγορίθμων μπορούν να επηρεάσουν άμεσα τους δανειολήπτες (Rudin, 2019).

Το Explainable Artificial Intelligence, γνωστό ως Explainable AI ή XAI, αναφέρεται στο σύνολο των μεθόδων που έχουν ως στόχο να καταστήσουν πιο κατανοητές και ερμηνεύσιμες τις προβλέψεις των μοντέλων τεχνητής νοημοσύνης. Η έννοια της εξηγήσιμης τεχνητής νοημοσύνης δεν περιορίζεται στην τεχνική περιγραφή ενός αλγορίθμου, αλλά

αφορά και τη δυνατότητα ενός οργανισμού να αιτιολογήσει μια απόφαση σε πελάτες, ελεγκτές, εποπτικές αρχές και εσωτερικά στελέχη διαχείρισης κινδύνου (Lundberg & Lee, 2017).

Στο πλαίσιο του πιστωτικού κινδύνου, η ανάγκη για Explainable AI είναι ιδιαίτερα έντονη, επειδή οι αποφάσεις που πρέπει να παρθούν δεν είναι ουδέτερες ή αμιγώς τεχνικές. Η απόρριψη μιας αίτησης δανείου, η επιβολή υψηλότερου επιτοκίου ή η ταξινόμηση ενός πελάτη ως υψηλού κινδύνου μπορεί να έχει σημαντικές οικονομικές και κοινωνικές συνέπειες. Για τον λόγο αυτό, η διαφάνεια των μοντέλων αποτελεί βασική προϋπόθεση για την υπεύθυνη χρήση της τεχνητής νοημοσύνης στον τραπεζικό τομέα (Barocas & Selbst, 2016).

Στο παρόν κεφάλαιο εξετάζεται το πρόβλημα των black-box μοντέλων, παρουσιάζονται θεωρητικά οι μέθοδοι SHAP και LIME και αναλύεται η σημασία της εξηγήσιμης τεχνητής νοημοσύνης για τις τραπεζικές αποφάσεις. Επιπλέον, γίνεται αναφορά στους περιορισμούς του Explainable AI, καθώς η ύπαρξη μιας τεχνικής εξήγησης δεν σημαίνει απαραίτητα ότι το μοντέλο είναι πλήρως διαφανές, δίκαιο ή κατάλληλο για κάθε εφαρμογή υψηλού κινδύνου (Rudin, 2019).

6.2 Το πρόβλημα των black-box μοντέλων

Τα black-box models, δηλαδή τα μοντέλα «μαύρου κουτιού», αποτελούν ένα από τα βασικά ζητήματα που προκύπτουν από τη χρήση προηγμένων αλγορίθμων μηχανικής μάθησης. Ο όρος χρησιμοποιείται για να περιγράψει μοντέλα των οποίων η εσωτερική διαδικασία λήψης απόφασης δεν είναι άμεσα κατανοητή από τον άνθρωπο. Με άλλα λόγια, μπορεί να είναι γνωστό ποια δεδομένα εισέρχονται στο μοντέλο και ποια πρόβλεψη παράγεται, αλλά να μην είναι σαφές πώς ακριβώς το μοντέλο κατέληξε σε αυτό το αποτέλεσμα (Rudin, 2019).

Στο credit scoring, το πρόβλημα αυτό είναι ιδιαίτερα κρίσιμο. Ένα μοντέλο μπορεί να προβλέπει ότι ένας πελάτης έχει υψηλή πιθανότητα αθέτησης, χωρίς όμως να είναι εύκολο να εξηγηθεί αν η πρόβλεψη αυτή οφείλεται στο εισόδημα, στο ιστορικό πληρωμών, στο ύψος του χρέους, στη διάρκεια εργασίας ή σε συνδυασμό πολλών παραγόντων. Η δυσκολία αυτή δημιουργεί πρακτικά προβλήματα, διότι οι τράπεζες και οι χρηματοπιστωτικοί οργανισμοί οφείλουν να μπορούν να τεκμηριώνουν τις αποφάσεις τους (Thomas et al., 2017).

Η αδιαφάνεια των black-box μοντέλων συνδέεται συχνά με αλγορίθμους όπως τα σύνθετα Neural Networks, τα Gradient Boosting Machines και ορισμένες μορφές ensemble models. Τα Neural Networks, δηλαδή τα νευρωνικά δίκτυα, αποτελούνται από πολλαπλά επίπεδα υπολογιστικών κόμβων που επεξεργάζονται τα δεδομένα με σύνθετο τρόπο. Παρότι μπορούν να εντοπίσουν πολύπλοκα μοτίβα, η ερμηνεία των εσωτερικών υπολογισμών τους είναι δύσκολη, ιδιαίτερα όταν το μοντέλο περιλαμβάνει μεγάλο αριθμό παραμέτρων (Hastie et al., 2009).

Τα ensemble models, όπως τα Random Forests και τα Gradient Boosting Machines, βασίζονται στον συνδυασμό πολλών επιμέρους μοντέλων. Η προσέγγιση αυτή μπορεί να βελτιώσει την προβλεπτική απόδοση, αλλά παράλληλα μειώνει τη διαφάνεια, καθώς η τελική πρόβλεψη προκύπτει από τη σύνθεση πολλών αποφάσεων. Έτσι, ενώ ένα απλό Decision Tree μπορεί να ερμηνευθεί σχετικά εύκολα, ένα Random Forest που αποτελείται από εκατοντάδες δέντρα είναι πολύ πιο δύσκολο να αναλυθεί με απλό και κατανοητό τρόπο (Lessmann et al., 2015).

Η ύπαρξη των black-box μοντέλων δημιουργεί και ζήτημα εμπιστοσύνης. Ένας πελάτης που απορρίπτεται από ένα τραπεζικό προϊόν μπορεί να ζητήσει να μάθει τους λόγους της απόρριψης. Αν ο οργανισμός δεν μπορεί να δώσει σαφή και τεκμηριωμένη απάντηση, τότε μειώνεται η εμπιστοσύνη τόσο προς το μοντέλο όσο και προς τον ίδιο τον χρηματοπιστωτικό φορέα. Η ανάγκη αιτιολόγησης είναι ακόμη πιο σημαντική όταν οι αποφάσεις επηρεάζουν θεμελιώδεις οικονομικές δυνατότητες, όπως η πρόσβαση σε στεγαστικά, επιχειρηματικά ή καταναλωτικά δάνεια (Barocas & Selbst, 2016).

Επιπλέον, η αδιαφάνεια δυσκολεύει τον εντοπισμό σφαλμάτων, περιπτώσεων έλλειψης αντικειμενικότητας και προβλημάτων συμμόρφωσης. Ένα black-box μοντέλο μπορεί να εμφανίζει υψηλή συνολική ακρίβεια, αλλά να παράγει δυσμενέστερα αποτελέσματα για συγκεκριμένες ομάδες πελατών. Εάν δεν υπάρχουν μηχανισμοί εξήγησης και ελέγχου, τέτοιες ανισότητες μπορεί να παραμείνουν μη ορατές για μεγάλο χρονικό διάστημα (Barocas & Selbst, 2016).

Για τον λόγο αυτό, το πρόβλημα των black-box μοντέλων δεν είναι μόνο τεχνικό. Έχει ταυτόχρονα ηθικό, κανονιστικό και οργανωτικό χαρακτήρα. Η χρήση ενός πολύπλοκου μοντέλου στον τομέα του credit scoring απαιτεί όχι μόνο υψηλή ακρίβεια, αλλά και δυνατότητα ελέγχου, εξήγησης και τεκμηρίωσης των αποτελεσμάτων του. Αυτή ακριβώς η ανάγκη αποτελεί τη βάση για την ανάπτυξη και εφαρμογή των μεθόδων Explainable AI (EBA, 2023).

6.3 Τεχνικές SHAP και LIME: Θεωρητική Παρουσίαση

Οι τεχνικές Explainable AI έχουν αναπτυχθεί με σκοπό να προσφέρουν εξηγήσεις για τις προβλέψεις σύνθετων μοντέλων μηχανικής μάθησης. Δύο από τις πιο γνωστές και ευρέως χρησιμοποιούμενες τεχνικές είναι το SHAP και το LIME. Και οι δύο μέθοδοι δεν αντικαθιστούν το ίδιο το μοντέλο, αλλά λειτουργούν συμπληρωματικά, προσπαθώντας να εξηγήσουν γιατί το μοντέλο παρήγαγε μια συγκεκριμένη πρόβλεψη (Lundberg & Lee, 2017; Ribeiro et al., 2016).

Το μοντέλο SHAP προέρχεται από τον όρο SHapley Additive exPlanations. Η μέθοδος βασίζεται στις τιμές Shapley, οι οποίες προέρχονται από τη θεωρία παιγνίων. Στη θεωρία αυτή, οι τιμές Shapley χρησιμοποιούνται για να κατανεμηθεί δίκαια η συμβολή κάθε συμμετέχοντα σε ένα συλλογικό αποτέλεσμα. Στο πλαίσιο της μηχανικής μάθησης, η ίδια

λογική εφαρμόζεται στις μεταβλητές ενός μοντέλου, ώστε να εκτιμηθεί πόσο συνέβαλε κάθε μεταβλητή σε μια συγκεκριμένη πρόβλεψη (Lundberg & Lee, 2017).

Με πιο απλό τρόπο, το SHAP προσπαθεί να απαντήσει στο ερώτημα: «Ποιοι παράγοντες οδήγησαν το μοντέλο να δώσει αυτή την πρόβλεψη;». Για παράδειγμα, σε ένα μοντέλο credit scoring, το SHAP μπορεί να δείξει ότι ο υψηλός λόγος του «χρέους προς εισόδημα» αύξησε την πιθανότητα αθέτησης, ενώ το σταθερό εισόδημα και το θετικό ιστορικό πληρωμών τη μείωσαν. Έτσι, η πρόβλεψη δεν εμφανίζεται απλώς ως τελικό αποτέλεσμα, αλλά συνοδεύεται από μια ανάλυση της συμβολής των βασικών μεταβλητών (Lundberg & Lee, 2017).

Ένα σημαντικό πλεονέκτημα του SHAP είναι ότι μπορεί να χρησιμοποιηθεί τόσο για τοπικές όσο και για συνολικές εξηγήσεις. Οι local explanations, δηλαδή τοπικές εξηγήσεις, αφορούν μία συγκεκριμένη πρόβλεψη για έναν συγκεκριμένο πελάτη. Αντίθετα, οι global explanations, δηλαδή συνολικές εξηγήσεις, δείχνουν ποιες μεταβλητές είναι γενικά πιο σημαντικές για το μοντέλο στο σύνολο των δεδομένων. Αυτή η διπλή δυνατότητα καθιστά το SHAP ιδιαίτερα χρήσιμο σε εφαρμογές πιστωτικού κινδύνου, όπου ενδιαφέρει τόσο η αιτιολόγηση μιας μεμονωμένης απόφασης όσο και η κατανόηση της συνολικής συμπεριφοράς του μοντέλου (Lundberg & Lee, 2017).

Το μοντέλο LIME προέρχεται από τον όρο Local Interpretable Model-agnostic Explanations. Η μέθοδος αυτή δημιουργήθηκε με σκοπό να εξηγεί μεμονωμένες προβλέψεις πολύπλοκων μοντέλων με τη βοήθεια απλούστερων και πιο ερμηνεύσιμων τοπικών μοντέλων. Ο όρος model-agnostic σημαίνει ότι η μέθοδος μπορεί να εφαρμοστεί σε διαφορετικούς τύπους μοντέλων, ανεξάρτητα από την εσωτερική τους δομή. Δηλαδή, μπορεί να χρησιμοποιηθεί τόσο σε Random Forests όσο και σε Neural Networks ή άλλα σύνθετα μοντέλα (Ribeiro et al., 2016).

Η βασική ιδέα του LIME είναι ότι, ακόμη και αν ένα μοντέλο συνολικά είναι πολύπλοκο, η συμπεριφορά του γύρω από μία συγκεκριμένη πρόβλεψη μπορεί να προσεγγιστεί από ένα απλούστερο μοντέλο. Για παράδειγμα, εάν ένα black-box μοντέλο απορρίψει έναν πελάτη, το LIME μπορεί να δημιουργήσει μια τοπική εξήγηση που δείχνει ποιες μεταβλητές επηρέασαν περισσότερο τη συγκεκριμένη απόφαση. Με αυτόν τον τρόπο, το LIME δεν προσπαθεί να εξηγήσει ολόκληρο το μοντέλο, αλλά να εξηγήσει τη συγκεκριμένη πρόβλεψη που ενδιαφέρει (Ribeiro et al., 2016).

Η διαφορά μεταξύ SHAP και LIME βρίσκεται κυρίως στη θεωρητική τους βάση και στον τρόπο παραγωγής των εξηγήσεων. Το SHAP βασίζεται σε μια πιο αυστηρή μαθηματική θεμελίωση μέσω των Shapley values, ενώ το LIME βασίζεται στη δημιουργία τοπικών, απλούστερων προσεγγιστικών μοντέλων (Lundberg & Lee, 2017). Και οι δύο τεχνικές μπορούν να είναι χρήσιμες στο credit scoring, αλλά η επιλογή τους εξαρτάται από τις ανάγκες του οργανισμού, το είδος του μοντέλου, το επίπεδο λεπτομέρειας που απαιτείται και το κατά πόσο η εξήγηση πρέπει να είναι κατανοητή από τεχνικούς ή μη τεχνικούς χρήστες (Ribeiro et al., 2016).

Παρά τη χρησιμότητά τους, οι τεχνικές SHAP και LIME δεν πρέπει να αντιμετωπίζονται ως πλήρης λύση στο πρόβλημα της αδιαφάνειας. Οι εξηγήσεις που

παράγουν είναι συχνά προσεγγιστικές και εξαρτώνται από τον τρόπο εφαρμογής τους. Επιπλέον, μια τεχνικά ορθή εξήγηση δεν σημαίνει απαραίτητα ότι η απόφαση είναι δίκαιη, ηθικά αποδεκτή ή κανονιστικά επαρκής. Για τον λόγο αυτό, οι μέθοδοι Explainable AI πρέπει να εντάσσονται σε ένα ευρύτερο πλαίσιο διακυβέρνησης μοντέλων και όχι να χρησιμοποιούνται απομονωμένα (Rudin, 2019; EBA, 2023).

6.4 Η Σημασία του Explainable AI για τις Τραπεζικές Αποφάσεις

Η σημασία του Explainable AI στον τραπεζικό τομέα είναι ιδιαίτερα μεγάλη, επειδή οι χρηματοπιστωτικοί οργανισμοί με τις αποφάσεις τους, επηρεάζουν άμεσα πελάτες, επιχειρήσεις και αγορές. Στο credit scoring, η απόφαση έγκρισης ή απόρριψης ενός δανείου πρέπει να είναι όχι μόνο ακριβής, αλλά και αιτιολογημένη. Η τράπεζα οφείλει να γνωρίζει ποιοι παράγοντες οδήγησαν σε μια συγκεκριμένη αξιολόγηση κινδύνου και να μπορεί να τεκμηριώσει την απόφαση αυτή εσωτερικά και εξωτερικά (Thomas et al., 2017).

Σε επίπεδο διαχείρισης κινδύνου, το Explainable AI βοηθά τους οργανισμούς να κατανοήσουν καλύτερα τη συμπεριφορά των μοντέλων τους. Ένα μοντέλο που εμφανίζει υψηλή ακρίβεια μπορεί να φαίνεται αποτελεσματικό, αλλά χωρίς εξηγήσεις είναι δύσκολο να εντοπιστεί αν βασίζεται σε οικονομικά λογικούς παράγοντες ή σε τυχαίες και ασταθείς συσχετίσεις. Η δυνατότητα ερμηνείας επιτρέπει στους αναλυτές να αξιολογούν αν οι προβλέψεις του μοντέλου συνάδουν με την οικονομική θεωρία, την εμπειρία του οργανισμού και τις πολιτικές πιστοδότησης (EBA, 2023).

Το Explainable AI είναι επίσης σημαντικό για την κανονιστική συμμόρφωση. Οι εποπτικές αρχές απαιτούν από τα χρηματοπιστωτικά ιδρύματα να διαθέτουν μηχανισμούς ελέγχου, τεκμηρίωσης και παρακολούθησης των μοντέλων που χρησιμοποιούν. Ειδικά όταν τα μοντέλα επηρεάζουν αποφάσεις πιστοδότησης, η έλλειψη διαφάνειας μπορεί να δημιουργήσει προβλήματα συμμόρφωσης και να αυξήσει τον λειτουργικό και νομικό κίνδυνο του οργανισμού (EBA, 2023).

Στην Ευρωπαϊκή Ένωση, η σημασία της διαφάνειας ενισχύεται και από το κανονιστικό πλαίσιο για την προστασία δεδομένων και την τεχνητή νοημοσύνη. Ο Γενικός Κανονισμός για την Προστασία Δεδομένων, δηλαδή ο GDPR, περιλαμβάνει διατάξεις για την αυτοματοποιημένη λήψη αποφάσεων, ενώ ο EU AI Act ταξινομεί ορισμένα συστήματα τεχνητής νοημοσύνης που χρησιμοποιούνται για την αξιολόγηση πιστοληπτικής ικανότητας ως υψηλού κινδύνου. Αυτό σημαίνει ότι απαιτούνται αυξημένα επίπεδα διαφάνειας, τεκμηρίωσης, ανθρώπινης εποπτείας και διαχείρισης δεδομένων (European Union, 2016; European Union, 2024).

Η “εξηγήσιμη” τεχνητή νοημοσύνη συμβάλλει επίσης στην προστασία των πελατών. Ένας πελάτης που απορρίπτεται από ένα δάνειο έχει συμφέρον να γνωρίζει τους βασικούς λόγους της απόφασης. Η παροχή μιας σαφούς εξήγησης μπορεί να ενισχύσει την εμπιστοσύνη προς τον οργανισμό και να επιτρέψει στον πελάτη να κατανοήσει ποια στοιχεία επηρέασαν αρνητικά την αξιολόγησή του. Για παράδειγμα, η εξήγηση μπορεί να

δείχνει ότι η απόφαση επηρεάστηκε από υψηλό επίπεδο υφιστάμενου χρέους, ανεπαρκές πιστωτικό ιστορικό ή συχνές καθυστερήσεις πληρωμών (Barocas & Selbst, 2016).

Παράλληλα, το Explainable AI μπορεί να βοηθήσει στον εντοπισμό αλγοριθμικής μεροληψίας. Μέσω της ανάλυσης των μεταβλητών που επηρεάζουν τις προβλέψεις, οι οργανισμοί μπορούν να διαπιστώσουν αν το μοντέλο βασίζεται σε μεταβλητές που λειτουργούν ως έμμεσοι δείκτες ευαίσθητων χαρακτηριστικών. Για παράδειγμα, μια μεταβλητή που σχετίζεται με τη γεωγραφική περιοχή μπορεί να συνδέεται έμμεσα με κοινωνικοοικονομικούς παράγοντες και να οδηγεί σε άνιση μεταχείριση ομάδων πελατών (Barocas & Selbst, 2016).

Επιπλέον, οι εξηγήσεις των μοντέλων είναι χρήσιμες και για την εσωτερική λογοδοσία. Τα στελέχη κινδύνου, οι εσωτερικοί ελεγκτές και οι επιτροπές πιστοδοτήσεων πρέπει να μπορούν να αξιολογούν αν ένα μοντέλο λειτουργεί σύμφωνα με την πολιτική του οργανισμού. Εάν το μοντέλο λαμβάνει αποφάσεις που δεν μπορούν να ερμηνευθούν ή να αιτιολογηθούν, τότε η διοίκηση δυσκολεύεται να αναλάβει ουσιαστική ευθύνη για τη χρήση του (EBA, 2023).

Συνεπώς, το Explainable AI δεν αποτελεί απλώς τεχνικό εργαλείο για αναλυτές δεδομένων, αλλά βασικό στοιχείο υπεύθυνης τραπεζικής διακυβέρνησης. Η αξία του βρίσκεται στο ότι συνδέει την τεχνική απόδοση των μοντέλων με τη διαφάνεια, τη λογοδοσία, την κανονιστική συμμόρφωση και την προστασία των πελατών. Στο πλαίσιο αυτό, η εξηγήσιμη τεχνητή νοημοσύνη λειτουργεί ως γέφυρα ανάμεσα στην καινοτομία και στην υπεύθυνη χρήση των αλγορίθμων στον χρηματοπιστωτικό τομέα (Rudin, 2019; EBA, 2023).

6.5 Περιορισμοί του Explainable AI

Παρότι το Explainable AI προσφέρει σημαντικά πλεονεκτήματα, δεν αποτελεί πλήρη λύση σε όλα τα προβλήματα που σχετίζονται με τη χρήση σύνθετων μοντέλων τεχνητής νοημοσύνης. Ένας βασικός περιορισμός είναι ότι πολλές τεχνικές εξήγησης λειτουργούν εκ των υστέρων, δηλαδή μετά την παραγωγή της πρόβλεψης. Αυτό σημαίνει ότι δεν κάνουν απαραίτητα το ίδιο το μοντέλο διαφανές, αλλά προσπαθούν να εξηγήσουν τη συμπεριφορά του με προσεγγιστικό τρόπο (Rudin, 2019).

Ένα ερμηνεύσιμο μοντέλο, όπως ένα απλό scorecard ή μια Logistic Regression, είναι κατανοητό από τη δομή του. Αντίθετα, ένα black-box μοντέλο παραμένει σύνθετο και αδιαφανές, ακόμη και αν χρησιμοποιηθούν εργαλεία όπως το SHAP ή το LIME για την ερμηνεία των αποτελεσμάτων του. Για τον λόγο αυτό, ορισμένοι ερευνητές υποστηρίζουν ότι σε αποφάσεις υψηλού κινδύνου πρέπει να προτιμώνται εξ αρχής ερμηνεύσιμα μοντέλα αντί να βασίζεται ο οργανισμός αποκλειστικά σε μεταγενέστερες εξηγήσεις (Rudin, 2019).

Ένας ακόμη περιορισμός είναι ότι οι εξηγήσεις μπορεί να είναι δύσκολες στην κατανόηση για μη τεχνικούς χρήστες. Για παράδειγμα, μια ανάλυση SHAP μπορεί να είναι χρήσιμη και κατανοητή για έναν αναλυτή δεδομένων ή έναν αναλυτή κινδύνου, αλλά όχι απαραίτητα για έναν πελάτη που θέλει να καταλάβει γιατί απορρίφθηκε η αίτησή του.

Συνεπώς, η εξήγηση πρέπει να προσαρμόζεται στο κοινό στο οποίο απευθύνεται, διαφορετικά μπορεί να παραμένει τεχνικά ορθή αλλά πρακτικά ανεπαρκής (Lundberg & Lee, 2017).

Επιπλέον, το Explainable AI δεν εξαλείφει από μόνο του την αλγοριθμική μεροληψία. Ένα μοντέλο μπορεί να συνοδεύεται από εξηγήσεις, αλλά εξακολουθεί να παράγει άδικα ή άνισα αποτελέσματα. Η ύπαρξη μιας εξήγησης δεν σημαίνει απαραίτητα ότι η απόφαση είναι ηθικά αποδεκτή ή ότι δεν δημιουργεί διακρίσεις. Για τον λόγο αυτό, οι τεχνικές XAI πρέπει να συνδυάζονται με ελέγχους fairness, αξιολόγηση των δεδομένων εκπαίδευσης και ανθρώπινη εποπτεία (Barocas & Selbst, 2016).

Ένα πρόσθετο ζήτημα είναι ότι διαφορετικές μέθοδοι εξήγησης μπορεί να παράγουν διαφορετικά αποτελέσματα για την ίδια πρόβλεψη. Για παράδειγμα, το SHAP και το LIME μπορεί να αναδείξουν διαφορετικές μεταβλητές ως πιο σημαντικές, επειδή βασίζονται σε διαφορετικές θεωρητικές προσεγγίσεις. Αυτό μπορεί να δημιουργήσει αβεβαιότητα σχετικά με το ποια εξήγηση πρέπει να θεωρηθεί πιο αξιόπιστη, ιδιαίτερα σε αποφάσεις όπου απαιτείται υψηλό επίπεδο τεκμηρίωσης (Lundberg & Lee, 2017; Ribeiro et al., 2016).

Τέλος, υπάρχει ο κίνδυνος το Explainable AI να χρησιμοποιηθεί επιφανειακά, ως μέσο τυπικής συμμόρφωσης και όχι ως ουσιαστικό εργαλείο κατανόησης και ελέγχου. Ένας οργανισμός μπορεί να παράγει τεχνικές εξηγήσεις χωρίς να εξετάζει σε βάθος αν το μοντέλο είναι κατάλληλο, δίκαιο και σταθερό. Για τον λόγο αυτό, το XAI πρέπει να εντάσσεται σε ένα ευρύτερο πλαίσιο μοντέλου διακυβέρνησης, το οποίο περιλαμβάνει τεκμηρίωση, περιοδική αξιολόγηση, ανεξάρτητο έλεγχο, παρακολούθηση απόδοσης και μηχανισμούς ανθρώπινης παρέμβασης (EBA, 2023).

Καταλαβαίνουμε λοιπόν πως το Explainable AI λειτουργεί ως κρίσιμος μηχανισμός σύνδεσης ανάμεσα στην τεχνολογική καινοτομία και στην υπεύθυνη χρηματοπιστωτική πρακτική. Στον τομέα του credit scoring, όπου οι αποφάσεις έχουν άμεσες οικονομικές και κοινωνικές συνέπειες, η διαφάνεια, η ερμηνευσιμότητα και η λογοδοσία είναι απαραίτητες προϋποθέσεις για την αξιόπιστη και δίκαιη χρήση των AI-based μοντέλων (European Union, 2024; Rudin, 2019).

7. Συγκριτική Βιβλιογραφική Ανάλυση Παραδοσιακών και Μοντέλων Μηχανικής Μάθησης στο Credit Scoring

7.1 Μεθοδολογία Βιβλιογραφικής Έρευνας

Η συγκριτική βιβλιογραφική ανάλυση των παραδοσιακών μοντέλων και των μοντέλων τεχνητής νοημοσύνης στο credit scoring αποτελεί σημαντικό μέρος της παρούσας εργασίας, καθώς επιτρέπει την αποτύπωση της εξέλιξης της επιστημονικής έρευνας στον τομέα της πιστωτικής αξιολόγησης.

Από τα μέσα της δεκαετίας του 1990 μέχρι σήμερα, η βιβλιογραφία έχει μετατοπιστεί σταδιακά από τις κλασικές στατιστικές τεχνικές, όπως η Logistic Regression σε πιο σύνθετες μεθόδους μηχανικής μάθησης, όπως τα μοντέλα που αναλύσαμε παραπάνω. Ωστόσο, η μετατόπιση αυτή δεν σημαίνει ότι τα παραδοσιακά μοντέλα έχουν εγκαταλειφθεί, καθώς εξακολουθούν να χρησιμοποιούνται ως βασικά μοντέλα αναφοράς λόγω της ερμηνευσιμότητας και της κανονιστικής τους αποδοχής (Hand & Henley, 1997; Thomas et al., 2017). Σύμφωνα με σύγχρονες συστηματικές ανασκοπήσεις επιβεβαιώνεται ότι η έρευνα στο credit scoring δεν εστιάζει πλέον μόνο στην ακρίβεια πρόβλεψης, αλλά και σε ζητήματα όπως η ερμηνευσιμότητα, η ποιότητα των δεδομένων, η αντιπροσωπευτικότητα των datasets, η αλγοριθμική μεροληψία και η κανονιστική συμμόρφωση. Η συστηματική ανασκόπηση των Noriega et al. (2023), για παράδειγμα, επισημαίνει ότι οι περισσότερες μελέτες χρησιμοποιούν

Στο παρόν κεφάλαιο παρουσιάζεται συγκριτική βιβλιογραφική ανάλυση δίνοντας προτεραιότητα σε προσβάσιμες πηγές που προέρχονται από ακαδημαϊκές μηχανές αναζήτησης και επιστημονικές βάσεις, όπως Google Scholar, ScienceDirect. Χρησιμοποιήθηκαν μελέτες με δωρεάν διαθέσιμο πλήρες κείμενο, όπως open-access άρθρα, preprints, πανεπιστημιακές διατριβές και institutional repository papers.

Τα βασικά κριτήρια επιλογής των μελετών ήταν :

- πρώτον, να αφορούν άμεσα το credit scoring, την πρόβλεψη πιστωτικού κινδύνου ή την πιθανότητα αθέτησης
- δεύτερον, να περιλαμβάνουν σύγκριση μεταξύ παραδοσιακών μοντέλων και μοντέλων μηχανικής μάθησης
- τρίτον, να χρησιμοποιούν μετρικές αξιολόγησης όπως για παράδειγμα accuracy ή AUC ή precision ή recall κ.α.
- και τέταρτον, να καταλήγουν σε κάποιο συμπέρασμα σχετικά με τα μοντέλα που συγκρίνονται.

Η χρονική περίοδος που εξετάστηκε καλύπτει κυρίως το διάστημα 1995–2026. Η περίοδος αυτή επιτρέπει την παρακολούθηση της εξέλιξης παλαιότερων μοντέλων όπως Logistic Regression και Neural Networks έως τις νεότερες προσεγγίσεις ensemble learning και explainable machine learning.

Συνοψίζοντας, η παρούσα βιβλιογραφική ανάλυση αποτελεί μια συγκριτική επισκόπηση επιλεγμένων μελετών, για τους λόγους που αναφέρθηκαν πιο πάνω, με στόχο να αναδείξει τις βασικές ερευνητικές τάσεις, επαναλαμβανόμενα ευρήματα και τους περιορισμούς της βιβλιογραφίας και όχι π.χ. να αποδείξει ποσοτικά την απόλυτη υπεροχή ενός μοντέλου.

7.2 Περιορισμοί της Βιβλιογραφίας

Παρά τη χρησιμότητα της συγκριτικής βιβλιογραφικής ανάλυσης, υπάρχουν ορισμένοι σημαντικοί περιορισμοί στην επιλογή βιβλιογραφίας που πρέπει να ληφθούν υπόψη. Σε συνέχεια λοιπόν των κριτηρίων επιλογής της βιβλιογραφίας που αναφέρθηκαν πιο πάνω:

- πρέπει να ληφθεί υπόψιν ότι όλες οι διαθέσιμες πηγές που μπορούν να χρησιμοποιηθούν σε μια σύγκριση τέτοιου χαρακτήρα, δεν είναι ελεύθερα προσβάσιμες. Άρα εξαιρείται ένα μεγάλο μέρος της πιθανής βιβλιογραφίας.

- επιπλέον πρέπει να εξεταστούν και να ληφθούν υπόψιν και οι πλατφόρμες όπου είναι δημοσιευμένες οι πιθανές βιβλιογραφικές πηγές, ως προς την εγκυρότητά τους.

Καθώς το πεδίο ο τομέας και η σύγκριση με την οποία ασχολείται η παρούσα εργασία είναι πολύ συγκεκριμένη.

7.3 Μελέτες για Παραδοσιακά Μοντέλα Credit Scoring

Τα παραδοσιακά μοντέλα credit scoring, αποτέλεσαν για πολλά χρόνια τη βασική επιλογή μεθόδου από τις τράπεζες και τα χρηματοπιστωτικά ιδρύματα. Η Logistic Regression χρησιμοποιήθηκε εκτεταμένα, επειδή παρέχει μια σαφή και σχετικά απλή εκτίμηση της πιθανότητας αθέτησης. Επίσης, επιτρέπει την ερμηνεία της επίδρασης κάθε μεταβλητής στο τελικό αποτέλεσμα. Παρόμοια, η Linear Discriminant Analysis αξιοποιήθηκε ιστορικά ως μέθοδος ταξινόμησης, αν και οι στατιστικές της παραδοχές την καθιστούν λιγότερο ευέλικτη σε σύνθετα πραγματικά δεδομένα (Hand & Henley, 1997). Στη βιβλιογραφία, η Logistic Regression χρησιμοποιείται συχνά ως baseline model, δηλαδή ως μοντέλο αναφοράς. Αυτό σημαίνει ότι τα νεότερα και πιο σύνθετα μοντέλα μηχανικής μάθησης αξιολογούνται συγκριτικά με αυτήν, ώστε να διαπιστωθεί αν η αύξηση της πολυπλοκότητας οδηγεί πράγματι σε ουσιαστική βελτίωση της απόδοσης. Ακόμη και σε πρόσφατες open-access μελέτες, όπως των Ginting et al. (2025), η Logistic Regression χρησιμοποιείται ως βασικό σημείο σύγκρισης έναντι των Random Forest, XGBoost και CatBoost.

Η αξία των παραδοσιακών μοντέλων όπως αναφέρθηκε και πιο πάνω, δεν περιορίζεται στην προβλεπτική τους απόδοση, αλλά η βασική τους δυναμική βρίσκεται στην ερμηνευσιμότητα και στη σταθερότητα που τα χαρακτηρίζει. Ωστόσο, η βιβλιογραφία δείχνει ότι τα παραδοσιακά μοντέλα έχουν περιορισμούς όταν τα δεδομένα παρουσιάζουν μη γραμμικές σχέσεις, σύνθετες αλληλεπιδράσεις ή υψηλή ανισορροπία μεταξύ καλών και κακών δανειοληπτών. Σε τέτοιες περιπτώσεις, τα μοντέλα μηχανικής μάθησης μπορούν να εντοπίσουν πιο σύνθετα μοτίβα, οδηγώντας συχνά σε υψηλότερη προβλεπτική ακρίβεια (Lessmann et al., 2015; Louzada et al., 2016).

Συνολικά, οι παραδοσιακές μέθοδοι εξακολουθούν να αποτελούν ισχυρή επιλογή όταν η διαφάνεια, η απλότητα και η κανονιστική αποδοχή είναι κεντρικές απαιτήσεις. Παρόλα αυτά, η σύγχρονη βιβλιογραφία δείχνει ότι, όταν ο κύριος στόχος είναι η μεγιστοποίηση της προβλεπτικής απόδοσης, τα μοντέλα μηχανικής μάθησης συχνά υπερέχουν.

7.4 Μελέτες για Μοντέλα Μηχανικής Μάθησης

Τα μοντέλα μηχανικής μάθησης εισήχθησαν στο credit scoring με στόχο την καλύτερη πρόβλεψη της πιθανότητας αθέτησης και την αντιμετώπιση των περιορισμών των παραδοσιακών στατιστικών μοντέλων. Αρχικά, σημαντική θέση στη βιβλιογραφία κατέλαβαν τα Neural Networks, τα οποία μπορούν να αποτυπώνουν μη γραμμικές σχέσεις μεταξύ μεταβλητών. Στη συνέχεια, παρατηρείται αύξηση προς τη χρήση των Support Vector Machines, Decision Trees, Random Forests και Gradient Boosting Models.

Τα Random Forests αποτελούν ensemble μέθοδο που συνδυάζει πολλά δέντρα απόφασης, με στόχο τη μείωση της αστάθειας ενός μεμονωμένου Decision Tree. Η μέθοδος αυτή είναι ιδιαίτερα χρήσιμη όταν τα δεδομένα περιλαμβάνουν πολλές μεταβλητές και πιθανές αλληλεπιδράσεις. Τα Gradient Boosting Models και το XGBoost λειτουργούν διαφορετικά, καθώς δημιουργούν διαδοχικά μοντέλα, όπου κάθε νέο μοντέλο προσπαθεί να διορθώσει τα λάθη του προηγούμενου. Η λογική αυτή οδηγεί συχνά σε πολύ υψηλή προβλεπτική απόδοση, αλλά απαιτεί προσεκτικό έλεγχο ώστε να αποφευχθεί το overfitting.

Πρόσφατες μελέτες επιβεβαιώνουν την αυξημένη απόδοση των ensemble models. Η μελέτη των Ginting et al. (2025), για παράδειγμα, συγκρίνει Logistic Regression, Random Forest, XGBoost και CatBoost στο credit scoring και αναφέρει ότι τα ensemble models, ειδικά XGBoost και CatBoost, υπερέχουν σε ακρίβεια.

Αντίστοιχα, η πρόσφατη μελέτη του 2026 που δημοσιεύθηκε στο FMDDB Transactions on Sustainable Finance and Data Science συγκρίνει Logistic Regression, Decision Tree, Random Forest, Gradient Boosting και XGBoost. Η μελέτη αξιολογεί τα μοντέλα με accuracy, precision, recall, F1-score, confusion matrix και ROC AUC, καταλήγοντας ότι τα ensemble models, και ειδικά το XGBoost, εμφανίζουν την πιο συνεπή και αποτελεσματική απόδοση.

Παρά τα πλεονεκτήματα των μοντέλων μηχανικής μάθησης, η βιβλιογραφία αναγνωρίζει ότι η υψηλότερη ακρίβεια δεν αρκεί από μόνη της. Η ερμηνευσιμότητα, η σταθερότητα, η ποιότητα των δεδομένων, η αντιμετώπιση αλγοριθμικής μεροληψίας και η δυνατότητα κανονιστικού ελέγχου παραμένουν κρίσιμες προϋποθέσεις για την πραγματική εφαρμογή των μοντέλων αυτών στον τραπεζικό τομέα.

7.5 Εμπειρικά Αποτελέσματα από τη Βιβλιογραφία

Στον πίνακα 7.1 παρουσιάζει τα αποτελέσματα της βιβλιογραφικής ανάλυσης για 40 μελέτες που επιλέχθηκαν. Στον πίνακα παρουσιάζονται κατά χρονολογική σειρά οι μελέτες, με ενδείξεις όπως: το παραδοσιακό μοντέλο credit scoring που χρησιμοποιήθηκε/συγκρίθηκε, το AI μοντέλο credit scoring που χρησιμοποιήθηκε /συγκρίθηκε, περιγραφή του ευρήματος που εντοπίστηκε και το μοντέλο που είχε την καλύτερη απόδοση.

A/A	Μελέτη	Έτος	Παραδοσιακό μοντέλο	AI / ML μοντέλο	Συνοπτικό εύρημα	Ένδειξη	Περίοδος	Ομαδοποίηση ένδειξης
1	Hand & Henley, Statistical Classification Methods in Consumer Credit Scoring: A Review	1997	Logistic Regression, Discriminant Analysis	Nearest neighbours, recursive partitioning	Τα παραδοσιακά στατιστικά μοντέλα εμφανίζονται ως βασική και αξιόπιστη βάση credit scoring.	Υπέρ παραδοσιακών	1995–2005	Παραδοσιακά
2	West, Neural Network Credit Scoring Models	2000	Logistic Regression, LDA	MLP, RBF, LVQ, MOE neural networks	Ορισμένα neural networks είχαν καλύτερη απόδοση, αλλά η Logistic Regression παρέμεινε ισχυρή εναλλακτική.	Μικτή	1995–2005	Μικτά
3	Bensic, Sarlija, & Zekic-Susac, Small Business Credit Scoring: A Comparison of Logistic Regression, Neural	2005	Logistic Regression	Neural Networks, CART	Η Logistic Regression εμφανίστηκε ανταγωνιστική, ενώ NN και CART είχαν επίσης ισχυρή απόδοση.	Μικτή	1995–2005	Μικτά

	Network and Decision Tree Models							
4	Abdou, Pointon, & El-Masry, On the Applicability of Credit Scoring Models in Egyptian Banks	2007	Discriminant Analysis, Probit, Logistic Regression	ML / AI models	Τα παραδοσιακά στατιστικά μοντέλα αξιολογήθηκαν και εφαρμόστηκαν σε τραπεζικό πλαίσιο.	Υπέρ παραδοσιακών	2006–2015	Παραδοσιακά
5	Abdou, Pointon, & El-Masry, Neural Nets versus Conventional Techniques in Credit Scoring in Egyptian Banking	2008	Logistic Regression, Probit, Discriminant Analysis	Probabilistic NN, Multilayer NN	Τα neural networks είχαν ισχυρή απόδοση, αλλά οι συμβατικές τεχνικές παρέμειναν ανταγωνιστικές.	Υπέρ AI	2006–2015	AI
6	Khandani, Kim, & Lo, Consumer Credit-Risk Models via Machine-Learning Algorithms	2010	Linear / logistic-type models	Nonlinear ML models	Τα AI μοντέλα βελτίωσαν την πρόβλεψη της delinquency/default σε σχέση με γραμμικές προσεγγίσεις.	Υπέρ AI	2006–2015	AI
7	Brown & Mues, An	2012	Logistic Regression	Random Forest,	Τα ensemble	Υπέρ AI	2006–2015	AI

	Experimental Comparison of Classification Algorithms for Imbalanced Credit Scoring Data Sets		on	GBM, SVM, NN	e models απέδωσαν πολύ καλά σε ανισορροπημένα δεδομένα.			
8	Kennedy, Credit Scoring Using Machine Learning	2013	Logistic Regression	Decision Trees, Random Forest, SVM	Τα AI μοντέλα προσφέρουν βελτίωση, αλλά η Logistic Regression παραμένει χρήσιμη βάση σύγκρισης.	Μικτή	2006–2015	Μικτά
9	Louzada, Ara, & Fernandes, Classification Methods Applied to Credit Scoring: Systematic Review and Overall Comparison	2016	Logistic Regression, Discriminant Analysis	Decision Trees, SVM, NN, ensemble models	Η βιβλιογραφία μετατοπίζεται προς AI, αλλά η Logistic Regression παραμένει βασικό benchmark.	Μικτή	2016–2020	Μικτά
10	Addo, Guegan, & Hassani, Credit Risk Analysis Using	2018	Logistic Regression	Random Forest, Gradient Boosting, Deep Learning	Τα AI και deep learning μοντέλα βελτίωσαν την πρόβλεψη	Υπέρ AI	2016–2020	AI

	Machine and Deep Learning Models				default.			
11	Nehrebecka, Predicting the Default Risk of Companies: Comparison of Logistic Regression and Support Vector Machines	2018	Logistic Regression	SVM	Τα SVM ήταν ανταγωνιστικά, αλλά η Logistic Regression διατηρεί πρακτικά πλεονεκτήματα.	Μικτή	2016–2020	Μικτά
12	Wang & Ni, A XGBoost Risk Model via Feature Selection and Bayesian Hyper-Parameter Optimization	2019	Logistic Regression ως benchmark	XGBoost	Το XGBoost με επιλογή χαρακτηριστικών και tuning βελτίωσε την απόδοση.	Υπέρ AI	2016–2020	AI
13	Alonso & Carbó, Understanding the Performance of Machine Learning Models to Predict Credit Default	2020	Logistic Regression, CART	Random Forest, XGBoost	Τα AI μοντέλα βελτιώνουν την απόδοση, αλλά απαιτούν εποπτικό πλαίσιο αξιολόγησης.	Υπέρ AI	2016–2020	AI

14	Papilas, Credit Scoring through Machine Learning and Artificial Intelligence	2020	Logistic Regression, binning process	Random Forest, XGBoost	Το XGBoost αναδείχθηκε ως ισχυρότερο ταξινομητής σε σχέση με παραδοσιακή προσέγγιση.	Υπέρ AI	2016–2020	AI
15	Liu et al., Classification of Imbalanced Credit Scoring Data Sets Based on Ensemble Learning	2021	Standard classifiers	Weighted-SMOTE Boosting / ensemble	Η αντιμετώπιση class imbalance βελτίωσε την πρόβλεψη defaults.	Υπέρ AI	2021–2026	AI
16	Kozodoi, Machine Learning for Credit Risk Analytics	2022	Scorecards, Logistic Regression	ML-based credit risk models	Τα AI μοντέλα βελτιώνουν την πρόβλεψη, αλλά απαιτούν fairness και model governance.	Υπέρ υβριδικού	2021–2026	Υβριδικά / XAI
17	Machado & Holmer, Credit Risk Modelling and Prediction: Logistic Regression versus Machine Learning Boosting	2022	Logistic Regression	XGBoost, CatBoost, boosting algorithms	Τα boosting μοντέλα είχαν καλύτερη απόδοση από τη Logistic Regression.	Υπέρ AI	2021–2026	AI

	Algorithms							
18	Dumitrescu, Hué, Hurlin, & Tokpavi, Machine Learning for Credit Scoring: Improving Logistic Regression with Non-Linear Decision-Tree Effects	2022	Logistic Regression	Penalized Logistic Tree Regression	Υβριδικό μοντέλο βελτιώνει τη Logistic Regression με decision-tree effects.	Υπέρ υβριδικού	2021–2026	Υβριδικά / ΧΑΙ
19	Tanavejwasin, Credit Risk Scoring Based on Machine Learning Models	2022	Decision Tree ως benchmark	Random Forest, LightGBM	Τα AI μοντέλα βελτίωσαν την ταξινόμηση καλών και κακών δανειοληπτών.	Υπέρ AI	2021–2026	AI
20	Chitambira, Credit Scoring Using Machine Learning Approaches	2022	Logistic Regression, Decision Trees	Random Forest, SVM, ensemble methods	Τα AI μοντέλα συγκρίνονται με μεθόδους που χρησιμοποιούνται στην τραπεζική ή πρακτική.	Υπέρ AI	2021–2026	AI
21	Gao, Construction of a Financial Default Risk Prediction	2022	Logistic Regression, SVM	LightGBM	Το LightGBM ξεπέρασε LR και SVM στην	Υπέρ AI	2021–2026	AI

	n Model Based on LightGBM				πρόβλεψη default.			
22	Noriega, Rivera, & Quispe-Herrera, Machine Learning for Credit Risk Prediction: A Systematic Literature Review	2023	Classical statistical models	ML / AI models	Οι AI μέθοδοι κυριαρχούν στην πρόσφατη βιβλιογραφία, αλλά υπάρχουν περιορισμοί στα datasets.	Υπέρ AI	2021–2026	AI
23	Dernsjö, A Gradient Boosting Tree Approach for Behavioural Credit Scoring	2023	Logistic Regression	Gradient Boosting Trees	Τα Gradient Boosting Trees ξεπέρασαν τη Logistic Regression.	Υπέρ AI	2021–2026	AI
24	Suleri, Interpretable Machine Learning for Credit Scoring	2023	Logistic Regression	Interpretable ML, PLTR	Τα ερμηνεύσιμα AI μοντέλα επιδιώκουν ισορροπία ακρίβειας και διαφάνειας.	Υπέρ υβριδικού	2021–2026	Υβριδικά / XAI
25	El Haouari, An Explainable Artificial Intelligence Credit Rating System	2023	Logistic Regression	Explainable AI models	Το XAI προτείνεται ως τρόπος ενίσχυσης εμπιστοσύνης και διαφάνειας.	Υπέρ AI με XAI	2021–2026	Υβριδικά / XAI

26	Taş, Comparis on of Machine Learning and Standard Credit Risk Models' Performa nces in Credit Risk Scoring of Buy Now Pay Later Custome rs	2023	Standard credit risk models	ML models	Τα AI μοντέλα είναι κατάλλη λα για fintech περιβάλλ οντα.	Υπέρ AI	2021– 2026	AI
27	Zedda, Credit Scoring: Does XGBoost Outperfo rm Logistic Regressi on? A Test on Italian SMEs	2024	Logistic Regressi on	XGBoost	Η υπεροχή του XGBoost δεν είναι απόλυτη σε όλους τους κλάδους.	Μικτή	2021– 2026	Μικτά
28	Chang, Credit Risk Predictio n Using Machine Learning and Deep Learning: A Study on Credit Card Custome rs	2024	Logistic Regressi on, Decision Tree	RF, AdaBoos t, XGBoost, LightGB M, DL	Τα AI μοντέλα βελτίωσ αν την πρόβλεψ η default.	Υπέρ AI	2021– 2026	AI
29	Hlongwa ne et al., A Novel	2024	Logistic Regressi on,	LightGB M, CatBoost	Τα AI μοντέλα υπερέχο	Υπέρ υβριδικό ύ με XAI	2021– 2026	Υβριδικά / XAI

	Framework for Enhancing Transparency in Credit Scoring		scorecards	, XGBoost / SHAP	υν συχνά, αλλά η διαφάνεια ενισχύεται με SHAP-based scorecards.			
30	Akinjole et al., Ensemble-Based Machine Learning Algorithm for Loan Default Risk Prediction	2024	Logistic Regression, Decision Tree, SVM	RF, XGBoost, AdaBoost, MLP	XGBoost και Random Forest εμφάνισαν ισχυρότερη απόδοση.	Υπέρ AI	2021–2026	AI
31	Nandipati, A Comparative Analysis between Logistic Regression, KNN, Decision Tree, Random Forest and XGBoost for Credit Approval Prediction	2024	Logistic Regression	KNN, Decision Tree, RF, XGBoost	Random Forest και XGBoost αναδείχθηκαν ως πιο αποτελεσματικά.	Υπέρ AI	2021–2026	AI
32	Chen, Interpretable Machine Learning for Imbalanced	2024	Logistic Regression	Random Forest, XGBoost, SHAP/LIME	Τα AI μοντέλα βελτιώνουν την απόδοση, αλλά το imbalanced	Υπέρ AI με XAI	2021–2026	Υβριδικά / XAI

	ed Credit Scoring Datasets				ε επηρεάζει τη σταθερότητα εξηγήσεων.			
33	Bhandary et al., Credit Card Default Prediction: An Empirical Analysis on Predictive Performance Using Statistical and Machine Learning Methods	2025	LDA, Logistic Regression	SVM, XGBoost, RF, DNN	Τα AI μοντέλα εμφάνισαν υψηλή προβλεπτική ικανότητα.	Υπέρ AI	2021–2026	AI
34	Ginting, Sembiring, & Zamzami, Comparison Analysis: Logistic Regression, Random Forest, XGBoost, and CatBoost in Credit Scoring	2025	Logistic Regression	RF, XGBoost, CatBoost	XGBoost και CatBoost ξεπέρασαν τη Logistic Regression, ειδικά με SMOTETomek.	Υπέρ AI	2021–2026	AI
35	Putra & Rumini, Comparative Study of Logistic	2025	Logistic Regression	Random Forest, XGBoost	Random Forest και XGBoost βελτίωσαν την	Υπέρ AI	2021–2026	AI

	Regressi on, Random Forest, and XGBoost for Bank Loan Approval Classifica tion				ταξινόμη ση αιτήσεων δανείου.			
36	Souadda et al., Optimizi ng Credit Risk Predictio n for Peer-to- Peer Lending: A Compara tive Study of Hyperpar ameter Tuning Methods	2025	Logistic Regressi on	RF, XGBoost, LightGB M	XGBoost και LightGB M πέτυχαν υψηλή απόδοση , με κρίσιμη σημασία του tuning.	Υπέρ AI	2021– 2026	AI
37	Zhang, Data- Driven Loan Default Predictio n: A Machine Learning Approac h	2025	Baseline statistica l comparis on	XGBoost, RF, LightGB M, GBM	Τα ensembl e models παρουσί ασαν ισχυρή απόδοση στην πρόβλεψ η loan default.	Υπέρ AI	2021– 2026	AI
38	Ding et al., Domain- Constrai ned Stacking Framewo rk for Credit Default Predictio	2025	Logistic Regressi on	RF, XGBoost, stacking ensembl e	Το stacking ensembl e αξιοποίη σε LR, RF και XGBoost με ισχυρή συμβολή	Υπέρ υβριδικό ύ	2021– 2026	Υβριδικά / ΧAI

	n				μη γραμμικ ών μοντέλω ν.			
39	Ayari, Gueteri, & Kraiem, Machine Learning Powered Financial Credit Scoring: A Systemat ic Literatur e Review	2025	Classical scoring models	ML- based credit scoring models	Η πρόσφατ η βιβλιογρ αφία δείχνει κυριαρχί α AI/ense mble μεθόδων , αλλά ανάγκη για interpret ability.	Υπέρ AI	2021– 2026	AI
40	Mathibel a, Predictiv e Modellin g of Credit Default Risk Using Machine Learning and Stacked Ensembl es	2026	Logistic Regressi on	RF, XGBoost, MLP, stacked ensembl e	To stacked ensembl e είχε την υψηλότε ρη συνολική απόδοση .	Υπέρ AI	2021– 2026	AI

Πίνακας 7.1 Συγκριτικά εμπειρικά αποτελέσματα από τη βιβλιογραφία

7.6 Συζήτηση Αποτελεσμάτων

Η βιβλιογραφία που εξετάστηκε παραπάνω παρουσιάζει ορισμένους σημαντικούς περιορισμούς. Οι μελέτες δεν βασίζονται στα ίδια datasets, ούτε εξετάζουν πάντοτε το ίδιο

οικονομικό, τραπεζικό ή κανονιστικό περιβάλλον. Σε αρκετές περιπτώσεις, τα αποτελέσματα προκύπτουν από δημόσια διαθέσιμα σύνολα δεδομένων ή από δεδομένα συγκεκριμένων αγορών, γεγονός που περιορίζει τη δυνατότητα άμεσης γενίκευσης των συμπερασμάτων. Επιπλέον, η απόδοση ενός μοντέλου credit scoring μπορεί να επηρεάζεται από το μέγεθος του δείγματος, την ποιότητα των μεταβλητών, την ύπαρξη ανισορροπίας μεταξύ καλών και κακών δανειοληπτών, καθώς και από τις μακροοικονομικές συνθήκες της περιόδου που εξετάζεται. Επομένως, η υπεροχή ενός AI-based μοντέλου σε μία μελέτη δεν σημαίνει απαραίτητα ότι το ίδιο μοντέλο θα έχει αντίστοιχη απόδοση σε διαφορετικό τραπεζικό σύστημα ή σε διαφορετική οικονομική συγκυρία (Lessmann et al., 2015; Schmitt, 2022).

Η παραπάνω διαπίστωση είναι ιδιαίτερα σημαντική για την ελληνική πραγματικότητα. Το ελληνικό τραπεζικό σύστημα έχει επηρεαστεί έντονα από περιόδους οικονομικής κρίσης, από τα υψηλά επίπεδα μη εξυπηρετούμενων δανείων και τις αυξημένες απαιτήσεις εποπτικής παρακολούθησης. Για τον λόγο αυτό, τα συμπεράσματα της διεθνούς βιβλιογραφίας δεν μπορούν να μεταφερθούν μηχανικά στην Ελλάδα χωρίς εμπειρική επαλήθευση σε ελληνικά τραπεζικά δεδομένα. Παράλληλα, η χρήση μοντέλων μηχανικής μάθησης στο credit scoring πρέπει να συμβαδίζει με τις κανονιστικές απαιτήσεις της EBA-Ευρωπαϊκής αρχής Τραπεζών και της ECB-Ευρωπαϊκής Κεντρικής Τράπεζας, οι οποίες δίνουν έμφαση στη διακυβέρνηση των μοντέλων, στην ποιότητα των δεδομένων, στην εσωτερική επικύρωση, στη διαφάνεια και στη δυνατότητα εποπτικού ελέγχου. Συνεπώς, η αξιολόγηση των AI-based μοντέλων δεν πρέπει να περιορίζεται μόνο στην προβλεπτική ακρίβεια, αλλά να περιλαμβάνει και ζητήματα ερμηνευσιμότητας, τεκμηρίωσης, σταθερότητας και συμμόρφωσης με το ευρωπαϊκό εποπτικό πλαίσιο (Bücker et al., 2020; EBA, 2023; ECB, 2024).

Ωστόσο, η συγκριτική ανάλυση των μελετών που παρουσιάστηκαν στον Πίνακα 7.1 δείχνει ότι η βιβλιογραφία του credit scoring έχει μεταβληθεί σημαντικά κατά την περίοδο 1997–2026. Τα αποτελέσματα χωρίστηκαν ανά περιόδους 1995-2005, 2006-2015, 2016-2020 και 2021-2026. Στις παλαιότερες μελέτες, τα παραδοσιακά στατιστικά μοντέλα, κυρίως η Logistic Regression αλλά και άλλα παραδοσιακά μοντέλα, αποτελούσαν το βασικό πλαίσιο αξιολόγησης πιστωτικού κινδύνου. Η χρήση τους συνδέθηκε με την ανάγκη για απλότητα, ερμηνευσιμότητα και στατιστική σταθερότητα, στοιχεία που τα καθιστούσαν ιδιαίτερα χρήσιμα στο τραπεζικό περιβάλλον.

Η πρώτη περίοδος της βιβλιογραφίας δείχνει ότι τα μοντέλα μηχανικής μάθησης, όπως τα Neural Networks, δεν οδήγησαν άμεσα σε πλήρη αντικατάσταση των παραδοσιακών μοντέλων. Αντίθετα, αρκετές μελέτες της περιόδου 1997–2008 κατέληγαν σε μικτά αποτελέσματα, καθώς τα νευρωνικά δίκτυα μπορούσαν να βελτιώσουν την ακρίβεια, αλλά η Logistic Regression παρέμενε ανταγωνιστική λόγω διαφάνειας και πρακτικής εφαρμογής. Αυτό δείχνει ότι η τεχνολογική υπεροχή ενός μοντέλου δεν αρκεί από μόνη της, εάν δεν συνοδεύεται από ερμηνευσιμότητα και επιχειρησιακή χρησιμότητα.

Από το 2010 και μετά, η βιβλιογραφία αρχίζει να στρέφεται πιο καθαρά προς τα μοντέλα μηχανικής μάθησης. Η χρήση μεγαλύτερων datasets, η αύξηση της υπολογιστικής ισχύος και η ανάγκη για καλύτερη πρόβλεψη σε ανισορροπημένα δεδομένα ενίσχυσαν τη σημασία μοντέλων όπως Random Forest, Gradient Boosting, XGBoost και LightGBM. Τα

μοντέλα αυτά εμφανίζονται συχνά να υπερέχουν σε μετρικές όπως AUC, accuracy, F1-score και recall, ιδίως όταν τα δεδομένα περιλαμβάνουν σύνθετες μη γραμμικές σχέσεις.


Η περίοδος 2021–2026 δείχνει ακόμη πιο έντονη κυριαρχία των AI-based μοντέλων. Το XGBoost, το Random Forest, το LightGBM εμφανίζονται επανειλημμένα ως ιδιαίτερα αποδοτικές επιλογές για την πρόβλεψη πιθανότητας αθέτησης. Παράλληλα, όμως, αυξάνεται και το ενδιαφέρον για explainable και υβριδικά μοντέλα, γεγονός που δείχνει ότι η βιβλιογραφία δεν εστιάζει πλέον μόνο στην προβλεπτική ακρίβεια, αλλά και στη διαφάνεια, τη σταθερότητα και τη δυνατότητα κανονιστικού ελέγχου.

Συνολικά, τα αποτελέσματα δείχνουν μια σαφή μεταβολή στον χρόνο. Τα παραδοσιακά μοντέλα αποτελούν την ιστορική και μεθοδολογική βάση του credit scoring, ενώ τα μοντέλα μηχανικής μάθησης εμφανίζονται ως η κυρίαρχη σύγχρονη ερευνητική κατεύθυνση. Ωστόσο, η Logistic Regression εξακολουθεί να διατηρεί σημαντική θέση ως baseline model, δηλαδή ως μοντέλο αναφοράς, απέναντι στο οποίο αξιολογούνται τα νεότερα και πιο σύνθετα μοντέλα. Επομένως, η βιβλιογραφία δεν δείχνει πλήρη αντικατάσταση των παραδοσιακών μοντέλων, αλλά σταδιακή μετάβαση προς υβριδικές και ελεγχόμενες μορφές χρήσης της τεχνητής νοημοσύνης.

Ακολουθούν πίνακες και γραφήματα με αποτυπώνουν πιο συνοπτικά και κατανοητά τα παραπάνω:

Περίοδος	AI	Μικτά	Παραδοσιακά	Υβριδικά / ΧAI
1995–2005	0	2	1	0
2006–2015	3	1	1	0
2016–2020	4	2	0	0
2021–2026	18	1	0	7

Πίνακας 7.2 Μοντέλα που χρησιμοποιήθηκαν ανά περίοδο.



Γράφημα 7.1 Μοντέλα που χρησιμοποιήθηκαν με την πάροδο του χρόνου.

Η εξέλιξη των μοντέλων στον χρόνο δείχνει ότι η βιβλιογραφία του credit scoring μετατοπίστηκε σταδιακά από τα παραδοσιακά στατιστικά μοντέλα, όπως η Logistic Regression, προς πιο σύνθετες μεθόδους μηχανικής μάθησης. Την περίοδο 1995–2005 κυριαρχούν κυρίως τα παραδοσιακά μοντέλα και τα πρώιμα Neural Networks. Από το 2006 έως το 2015 εμφανίζεται εντονότερη χρήση SVM, Random Forest και ensemble προσεγγίσεων. Μετά το 2016, η βιβλιογραφία στρέφεται περισσότερο σε boosting αλγορίθμους, όπως XGBoost και LightGBM, ενώ την περίοδο 2021–2026 ενισχύεται η παρουσία explainable και υβριδικών μοντέλων. Αυτό δείχνει ότι η σύγχρονη τάση δεν αφορά μόνο την αύξηση της προβλεπτικής ακρίβειας, αλλά και την ανάγκη διαφάνειας, ερμηνευσιμότητας και υπεύθυνης χρήσης των μοντέλων.

Row Labels	Logistic Regression	SVM	Neural / Deep Learning	Random Forest	XGBoost	LightGBM	CatBoost	Ensemble / Boosting	XAI
1995–2005	3	0	2	0	0	0	0	0	0
2006–2015	5	2	2	2	0	0	0	1	0
2016–2020	6	2	3	3	3	0	0	2	0
2021–	19	4	5	13	14	6	3	12	3

Πίνακας 7.3 Διάσημα μοντέλα που εμφανίστηκαν ανά περίοδο.

8. Συμπεράσματα και Προτάσεις

Πριν από την αναλυτική παρουσίαση των συμπερασμάτων, τα βασικά ευρήματα της εργασίας μπορούν να συνοψιστούν ως εξής:

1. Τα παραδοσιακά μοντέλα credit scoring, εξακολουθούν να διατηρούν σημαντική αξία στην αξιολόγηση πιστωτικού κινδύνου, κυρίως λόγω της ερμηνευσιμότητας, της διαφάνειας και της ευκολότερης κανονιστικής τεκμηρίωσης.
2. Τα AI-based μοντέλα και οι τεχνικές μηχανικής μάθησης παρουσιάζουν σημαντικές δυνατότητες βελτίωσης της προβλεπτικής απόδοσης, καθώς μπορούν να εντοπίζουν μη γραμμικές σχέσεις και σύνθετα μοτίβα στα δεδομένα των δανειοληπτών.
3. Η αυξημένη ακρίβεια των μοντέλων τεχνητής νοημοσύνης συνοδεύεται από προκλήσεις, όπως η μειωμένη ερμηνευσιμότητα, το φαινόμενο των black-box models, το overfitting, το model drift και η πιθανή αλγοριθμική μεροληψία.
4. Η σύγχρονη βιβλιογραφία δείχνει ότι το μέλλον του credit scoring δεν βρίσκεται στην πλήρη αντικατάσταση των παραδοσιακών μοντέλων, αλλά στη συμπληρωματική χρήση παραδοσιακών, AI-based και υβριδικών προσεγγίσεων.
5. Η επιλογή του κατάλληλου μοντέλου δεν πρέπει να βασίζεται αποκλειστικά στην προβλεπτική ακρίβεια, αλλά και στη διαφάνεια, στη δυνατότητα ελέγχου, στη συμμόρφωση με το κανονιστικό πλαίσιο και στην υπεύθυνη χρήση του μοντέλου στη λήψη πιστωτικών αποφάσεων.

8.1 Κύρια Ευρήματα από τη Θεωρητική Σύγκριση

Η παρούσα εργασία είχε ως στόχο τη θεωρητική και βιβλιογραφική ανάλυση της χρήσης παραδοσιακών και AI-based μοντέλων στην αξιολόγηση πιστωτικού κινδύνου. Μέσα από την εξέταση των παραδοσιακών τεχνικών credit scoring, των μοντέλων μηχανικής μάθησης, των ζητημάτων ερμηνευσιμότητας και της συγκριτικής βιβλιογραφίας, αναδείχθηκε ότι η τεχνητή νοημοσύνη προσφέρει σημαντικές δυνατότητες βελτίωσης της προβλεπτικής απόδοσης, αλλά ταυτόχρονα δημιουργεί νέες απαιτήσεις ως προς τη διαφάνεια, τη διακυβέρνηση και την υπεύθυνη χρήση των μοντέλων.

Από τη θεωρητική σύγκριση προκύπτει ότι τα παραδοσιακά μοντέλα, όπως η Logistic Regression και τα credit scorecards, εξακολουθούν να έχουν σημαντική αξία στην πιστωτική αξιολόγηση. Το βασικό τους πλεονέκτημα είναι η ερμηνευσιμότητα, καθώς επιτρέπουν στους αναλυτές, στις τράπεζες και στις εποπτικές αρχές να κατανοούν σχετικά εύκολα τον τρόπο με τον οποίο κάθε μεταβλητή επηρεάζει την τελική πιστωτική

βαθμολογία. Η διαφάνεια αυτή τα καθιστά ιδιαίτερα χρήσιμα σε περιβάλλοντα όπου η τεκμηρίωση των αποφάσεων αποτελεί βασική απαίτηση (Thomas et al., 2017).

Αντίθετα, τα μοντέλα μηχανικής μάθησης παρουσιάζουν σημαντικά πλεονεκτήματα σε επίπεδο προβλεπτικής απόδοσης. Μέθοδοι όπως τα Random Forests, Gradient Boosting, XGBoost και Neural Networks μπορούν να αναγνωρίζουν μη γραμμικές σχέσεις και σύνθετες αλληλεπιδράσεις μεταξύ μεταβλητών, κάτι που τα παραδοσιακά μοντέλα συχνά δυσκολεύονται να αποτυπώσουν. Η βιβλιογραφία δείχνει ότι τα ensemble models εμφανίζουν συχνά υψηλότερη απόδοση σε μετρικές όπως AUC, Gini coefficient, accuracy και F1-score (Lessmann et al., 2015; Ginting et al., 2025).

Ωστόσο, η αυξημένη απόδοση των AI-based μοντέλων συνοδεύεται από σημαντικές προκλήσεις. Η πολυπλοκότητα πολλών αλγορίθμων μειώνει την ερμηνευσιμότητα και δημιουργεί το πρόβλημα των black-box models. Επιπλέον, ζητήματα όπως το overfitting, το model drift και η αλγοριθμική μεροληψία μπορούν να επηρεάσουν αρνητικά την αξιοπιστία και τη δικαιοσύνη των αποφάσεων. Επομένως, η επιλογή μοντέλου δεν πρέπει να βασίζεται μόνο στην ακρίβεια, αλλά και στη σταθερότητα, τη διαφάνεια και τη δυνατότητα ελέγχου του μοντέλου (Barocas & Selbst, 2016; Rudin, 2019).

8.2 Βασικά Ευρήματα από τη Βιβλιογραφική Ανάλυση

Η συγκριτική βιβλιογραφική ανάλυση έδειξε ότι η έρευνα στο credit scoring έχει μετακινηθεί σταδιακά προς τη χρήση μοντέλων μηχανικής μάθησης. Οι περισσότερες εμπειρικές μελέτες που εξετάστηκαν καταλήγουν ότι τα AI-based μοντέλα παρουσιάζουν καλύτερη προβλεπτική απόδοση από τα παραδοσιακά στατιστικά μοντέλα, ιδιαίτερα όταν τα δεδομένα είναι μεγάλα, σύνθετα ή μη ισορροπημένα. Ωστόσο παρά την υπεροχή των μοντέλων μηχανικής μάθησης σε επίπεδο απόδοσης, η Logistic Regression εξακολουθεί να διατηρεί σημαντικό ρόλο ως baseline model. Χρησιμοποιείται συχνά ως σημείο αναφοράς για τη σύγκριση πιο σύνθετων μοντέλων, αλλά και ως πρακτική επιλογή σε περιβάλλοντα όπου η ερμηνευσιμότητα είναι κρίσιμη. Αυτό δείχνει ότι τα παραδοσιακά μοντέλα δεν έχουν καταργηθεί από τη σύγχρονη βιβλιογραφία, αλλά λειτουργούν συμπληρωματικά προς τις νεότερες μεθόδους (Thomas et al., 2017).

Ένα ακόμη σημαντικό εύρημα είναι η αυξανόμενη σημασία των υβριδικών προσεγγίσεων. Η σύγχρονη βιβλιογραφία δεν περιορίζεται πλέον στο ερώτημα αν τα AI-based μοντέλα είναι ακριβέστερα, αλλά εξετάζει πώς μπορούν να χρησιμοποιηθούν με τρόπο διαφανή, δίκαιο και ελέγξιμο. Η ανάπτυξη μεθόδων Explainable AI, όπως το SHAP και το LIME, καθώς και υβριδικών μοντέλων που συνδυάζουν μηχανική μάθηση με ερμηνεύσιμες στατιστικές δομές, δείχνει ότι το μέλλον του credit scoring συνδέεται με την ισορροπία ανάμεσα στην ακρίβεια και τη λογοδοσία (Lundberg & Lee, 2017; Ribeiro et al., 2016).

8.3 Πλεονεκτήματα και Περιορισμοί των Προσεγγίσεων

Τα παραδοσιακά μοντέλα παρουσιάζουν σημαντικά πλεονεκτήματα ως προς την απλότητα, τη διαφάνεια και την ευκολία ερμηνείας. Είναι κατάλληλα για οργανισμούς που χρειάζονται σαφή τεκμηρίωση των πιστωτικών αποφάσεων και επιθυμούν ένα μοντέλο που μπορεί να ελεγχθεί εύκολα από εσωτερικούς και εξωτερικούς φορείς. (Thomas et al., 2017).

Ο βασικός περιορισμός των παραδοσιακών μοντέλων είναι η μειωμένη ικανότητά τους να αποτυπώνουν σύνθετες μη γραμμικές σχέσεις. Σε περιπτώσεις όπου τα δεδομένα είναι μεγάλα, δυναμικά ή περιλαμβάνουν πολλές αλληλεπιδράσεις μεταξύ μεταβλητών, η Logistic Regression μπορεί να μην αξιοποιεί πλήρως την πληροφορία που περιέχεται στο dataset. Αυτό μπορεί να οδηγήσει σε χαμηλότερη προβλεπτική απόδοση σε σχέση με πιο σύγχρονα AI-based μοντέλα (Lessmann et al., 2015).

Αντίθετα, τα μοντέλα μηχανικής μάθησης έχουν ως βασικό πλεονέκτημα την υψηλότερη προβλεπτική ικανότητα και την προσαρμοστικότητα. Μπορούν να αξιοποιήσουν μεγάλο όγκο δεδομένων, να εντοπίσουν πολύπλοκα μοτίβα και να βελτιώσουν την εκτίμηση της πιθανότητας αθέτησης. Τα ensemble models, ειδικότερα, φαίνεται να αποτελούν ιδιαίτερα αποτελεσματική επιλογή για προβλήματα credit scoring, ιδίως όταν εφαρμόζονται με κατάλληλο validation και έλεγχο υπερπροσαρμογής (Brown & Mues, 2012; Ginting et al., 2025).

Παρόλα αυτά, τα AI-based μοντέλα έχουν σημαντικούς περιορισμούς. Η μειωμένη ερμηνευσιμότητα, ο κίνδυνος overfitting, η πιθανότητα αλγοριθμικής μεροληψίας και η ανάγκη συνεχούς παρακολούθησης αποτελούν βασικές προκλήσεις. Επίσης, η χρήση τους σε τραπεζικά περιβάλλοντα απαιτεί ισχυρή τεκμηρίωση, ανθρώπινη εποπτεία και συμμόρφωση με το κανονιστικό πλαίσιο, ιδιαίτερα όταν οι αποφάσεις επηρεάζουν την πρόσβαση των πολιτών σε χρηματοδότηση (EBA, 2023; European Union, 2024).

Κριτήριο	Παραδοσιακά (Logistic Regression)	AI-based (XGBoost / ANN)
Μαθηματική Σχέση	Γραμμική / Προσθετική	Μη Γραμμική / Σύνθετη
Διαχείριση Δεδομένων	Μικρά, Δομημένα Σύνολα	Big Data / Μη Δομημένα
Ερμηνευσιμότητα	Πλήρης	Περιορισμένη (Black Box)
Ακρίβεια (AUC)	Μέτρια	Πολύ Υψηλή
Κίνδυνος Overfitting	Πολύ Χαμηλός	Υψηλός (απαιτεί ρύθμιση)
Κίνδυνος Bias	Ελέγχμος	Κρυμμένος / Σύνθετος

Πίνακας 8.1 Σύγκριση Μοντέλων Πιστωτικού Κινδύνου: πλεονεκτήματα και περιορισμοί

8.4 Προτάσεις για Υπεύθυνη Ενσωμάτωση AI στο Credit Scoring

Η υπεύθυνη ενσωμάτωση της τεχνητής νοημοσύνης στο credit scoring απαιτεί μια ισορροπημένη προσέγγιση, η οποία δεν θα βασίζεται αποκλειστικά στην αναζήτηση υψηλότερης ακρίβειας. Οι χρηματοπιστωτικοί οργανισμοί πρέπει να αξιολογούν τα AI-

based μοντέλα με βάση ένα σύνολο κριτηρίων, όπως η προβλεπτική απόδοση, η ερμηνευσιμότητα, η σταθερότητα, η αμεροληψία, η ποιότητα των δεδομένων και η κανονιστική συμμόρφωση (EBA, 2023).

Πρώτη βασική πρόταση είναι η χρήση των παραδοσιακών μοντέλων ως μοντέλων αναφοράς. Η Logistic Regression και τα scorecards μπορούν να λειτουργούν ως baseline models, ώστε να αξιολογείται αν ένα πιο σύνθετο AI-based μοντέλο προσφέρει ουσιαστική βελτίωση. Εάν η αύξηση της απόδοσης είναι μικρή, αλλά η πολυπλοκότητα και η αδιαφάνεια αυξάνονται σημαντικά, τότε η χρήση ενός παραδοσιακού ή υβριδικού μοντέλου μπορεί να είναι πιο κατάλληλη επιλογή (Thomas et al., 2017; Rudin, 2019).

Δεύτερη πρόταση είναι η ενσωμάτωση τεχνικών Explainable AI, όπως το SHAP και το LIME, σε κάθε εφαρμογή σύνθετων μοντέλων μηχανικής μάθησης. Οι τεχνικές αυτές μπορούν να βοηθήσουν στην κατανόηση των προβλέψεων, στην εσωτερική τεκμηρίωση και στην επικοινωνία των βασικών λόγων μιας απόφασης. Ωστόσο, δεν πρέπει να χρησιμοποιούνται επιφανειακά, αλλά ως μέρος ενός ευρύτερου πλαισίου model governance (Lundberg & Lee, 2017; Ribeiro et al., 2016).

Τρίτη πρόταση είναι η συστηματική αξιολόγηση της αλγοριθμικής μεροληψίας. Οι οργανισμοί πρέπει να ελέγχουν αν το μοντέλο παράγει δυσμενέστερα αποτελέσματα για συγκεκριμένες ομάδες πελατών ή αν χρησιμοποιεί μεταβλητές που λειτουργούν ως έμμεσοι δείκτες ευαίσθητων χαρακτηριστικών. Η αξιολόγηση fairness πρέπει να αποτελεί μόνιμο μέρος της διαδικασίας ανάπτυξης, εφαρμογής και παρακολούθησης των μοντέλων (Barocas & Selbst, 2016).

Τέταρτη πρόταση είναι η συνεχής παρακολούθηση της απόδοσης των μοντέλων μετά την εφαρμογή τους. Τα μοντέλα credit scoring δεν πρέπει να θεωρούνται στατικά εργαλεία, καθώς οι οικονομικές συνθήκες, η συμπεριφορά των πελατών και τα δεδομένα μεταβάλλονται με την πάροδο του χρόνου. Για τον λόγο αυτό, απαιτείται τακτικό backtesting, stress testing, επανεκπαίδευση όπου χρειάζεται και έλεγχος για model drift (EBA, 2023).

Τέλος, η ανθρώπινη εποπτεία πρέπει να παραμένει βασικό στοιχείο της διαδικασίας πιστωτικής αξιολόγησης. Η τεχνητή νοημοσύνη μπορεί να υποστηρίξει τη λήψη αποφάσεων, αλλά δεν πρέπει να λειτουργεί ανεξέλεγκτα ή χωρίς δυνατότητα παρέμβασης. Ιδιαίτερα σε αποφάσεις υψηλού κινδύνου, όπως η έγκριση ή απόρριψη δανείου, η τελική ευθύνη πρέπει να παραμένει στον οργανισμό και στα αρμόδια στελέχη του (European Union, 2024).

8.5 Τελικό Συμπέρασμα

Η ανάλυση που προηγήθηκε δείχνει ότι η τεχνητή νοημοσύνη και η μηχανική μάθηση μπορούν να προσφέρουν σημαντική προστιθέμενη αξία στο credit scoring, κυρίως μέσω της βελτίωσης της προβλεπτικής απόδοσης και της δυνατότητας αξιοποίησης σύνθετων δεδομένων. Τα μοντέλα μηχανικής μάθησης, και ιδιαίτερα τα ensemble models, εμφανίζονται στη βιβλιογραφία ως ιδιαίτερα αποτελεσματικά εργαλεία για την εκτίμηση πιστωτικού κινδύνου. Ωστόσο, η υψηλή ακρίβεια δεν αρκεί από μόνη της για να καταστήσει

ένα μοντέλο κατάλληλο για τραπεζική χρήση. Στο credit scoring, οι αποφάσεις έχουν άμεσες οικονομικές και κοινωνικές συνέπειες, γεγονός που καθιστά απαραίτητη τη διαφάνεια, την ερμηνευσιμότητα, τη δικαιοσύνη και τη δυνατότητα ελέγχου. Για τον λόγο αυτό, τα AI-based μοντέλα πρέπει να εφαρμόζονται μέσα σε ένα πλαίσιο υπεύθυνης διακυβέρνησης, με συνεχή παρακολούθηση, τεχνικές Explainable AI και ανθρώπινη εποπτεία (Barocas & Selbst, 2016; Rudin, 2019).

Συνολικά, το μέλλον του credit scoring δεν φαίνεται να βρίσκεται στην πλήρη αντικατάσταση των παραδοσιακών μοντέλων από την τεχνητή νοημοσύνη, αλλά στη σύνθεση των δύο προσεγγίσεων. Τα παραδοσιακά μοντέλα προσφέρουν διαφάνεια και σταθερότητα, ενώ τα μοντέλα μηχανικής μάθησης προσφέρουν αυξημένη προβλεπτική ισχύ και προσαρμοστικότητα. Η πιο αποτελεσματική και υπεύθυνη κατεύθυνση είναι επομένως η ανάπτυξη υβριδικών, ερμηνεύσιμων και ελεγχόμενων συστημάτων credit scoring, τα οποία θα συνδυάζουν την τεχνολογική καινοτομία με τη θεσμική ασφάλεια και την προστασία των δανειοληπτών.

8.6 Προτάσεις Μελλοντικής Έρευνας

- Μια πρόταση για μελλοντική έρευνα αφορά την εμπειρική εφαρμογή παραδοσιακών, AI-based και υβριδικών μοντέλων credit scoring σε ελληνικά τραπεζικά δεδομένα. Η παρούσα εργασία είχε θεωρητικό και βιβλιογραφικό χαρακτήρα, επομένως μια επόμενη μελέτη θα μπορούσε να αξιοποιήσει ακόμα και πραγματικά δεδομένα δανειοληπτών από το ελληνικό τραπεζικό σύστημα αν ήταν εφικτό, ώστε να συγκρίνει την απόδοση μοντέλων όπως για παράδειγμα: Logistic Regression, Random Forests, XGBoost και Neural Networks με βάση μετρικές όπως AUC, Gini coefficient, accuracy και F1-score. Μια τέτοια εμπειρική προσέγγιση θα επέτρεπε την πρακτική επιβεβαίωση των θεωρητικών συμπερασμάτων και θα αναδείκνυε ποια μοντέλα είναι καταλληλότερα για τις ιδιαιτερότητες της ελληνικής αγοράς.
- Μια δεύτερη σημαντική πρόταση θα μπορούσε να είναι η συγκριτική ανάλυση μεταξύ διαφορετικών χωρών ή τραπεζικών συστημάτων. Η αποτελεσματικότητα ενός μοντέλου credit scoring μπορεί να επηρεάζεται από παράγοντες όπως η ποιότητα των δεδομένων, η οικονομική σταθερότητα, το επίπεδο μη εξυπηρετούμενων δανείων, οι κανονιστικές απαιτήσεις και η πιστωτική συμπεριφορά των δανειοληπτών. Επομένως, μια διακρατική σύγκριση μεταξύ χωρών της Ευρωπαϊκής Ένωσης ή μεταξύ ευρωπαϊκών και μη ευρωπαϊκών τραπεζικών συστημάτων θα μπορούσε να αναδείξει αν τα ίδια AI-based μοντέλα παρουσιάζουν αντίστοιχη απόδοση σε διαφορετικά οικονομικά και θεσμικά περιβάλλοντα.
- Τέλος, ιδιαίτερη σημασία έχει η μελλοντική έρευνα γύρω από τη δικαιοσύνη και τη μεροληψία των μοντέλων πιστωτικής αξιολόγησης. Η αξιολόγηση fairness metrics σε πραγματικά δεδομένα θα μπορούσε να δείξει αν τα AI-based μοντέλα παράγουν διαφοροποιημένα αποτελέσματα για συγκεκριμένες κοινωνικές ή οικονομικές ομάδες. Μελλοντικές μελέτες θα μπορούσαν να εξετάσουν δείκτες όπως

demographic parity, equal opportunity και equalized odds, ώστε να αξιολογηθεί όχι μόνο η ακρίβεια των μοντέλων, αλλά και η δίκαιη μεταχείριση των δανειοληπτών. Με αυτόν τον τρόπο, η μελλοντική έρευνα μπορεί να συμβάλει στη διαμόρφωση πιο αξιόπιστων, διαφανών και κοινωνικά υπεύθυνων συστημάτων credit scoring (Hardt et al., 2016).

Βιβλιογραφία

Barocas, S., & Selbst, A. D. (2016). Big data's disparate impact. California Law Review

Basel Committee on Banking Supervision. (2019). Guidelines: Minimum capital requirements for market risk. Bank for International Settlements.

European Banking Authority. (2023). Follow-up report on machine learning for IRB models. European Banking Authority.

Lessmann, S., Baesens, B., Seow, H. V., & Thomas, L. C. (2015). Benchmarking state-of-the-art classification algorithms for credit scoring: An update of research. *European Journal of Operational Research*

Rudin, C. (2019). Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature Machine Intelligence*

Siddiqi, N. (2012). Credit risk scorecards: Developing and implementing intelligent credit scoring. Wiley.

Thomas, L. C., Crook, J. N., & Edelman, D. B. (2017). Credit scoring and its applications

Acharya, V. V., & Richardson, M. (2009). Restoring financial stability: How to repair a failed system. Wiley.

Basel Committee on Banking Supervision. (2006). International convergence of capital measurement and capital standards: A revised framework - Comprehensive version. Bank for International Settlements.

Basel Committee on Banking Supervision. (2019). Basel III: Finalising post-crisis reforms. Bank for International Settlements.

Beck, R., Jakubik, P., & Piloju, A. (2015). Key determinants of non-performing loans: New evidence from a global sample. *Open Economies Review*

Bessis, J. (2011). Risk management in banking (3rd ed.). Wiley.

Hull, J. C. (2015). Risk management and financial institutions (4th ed.). Wiley.

Louzis, D. P., Vouldis, A. T., & Metaxas, V. L. (2012). Macroeconomic and bank-specific determinants of non-performing loans in Greece: A comparative study of mortgage, business and consumer loan portfolios. *Journal of Banking & Finance*

Saunders, A., & Allen, L. (2010). Credit risk management in and out of the financial crisis: New approaches to value at risk and other paradigms (3rd ed.). Wiley.

Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The Journal of Finance*

Basel Committee on Banking Supervision. (2019). Guidelines: Minimum capital requirements for market risk. Bank for International Settlements.

European Banking Authority. (2023). Follow-up report on machine learning for IRB models. European Banking Authority.

European Union. (2016). General Data Protection Regulation. Official Journal of the European Union.

- Hand, D. J., & Henley, W. E. (1997). Statistical classification methods in consumer credit scoring: A review. *Journal of the Royal Statistical Society: Series A*
- Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). *Applied logistic regression* (3rd ed.). Wiley.
- Lessmann, S., Baesens, B., Seow, H. V., & Thomas, L. C. (2015). Benchmarking state-of-the-art classification algorithms for credit scoring: An update of research. *European Journal of Operational Research*
- Rudin, C. (2019). Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature Machine Intelligence*
- Siddiqi, N. (2012). *Credit risk scorecards: Developing and implementing intelligent credit scoring*. Wiley.
- Thomas, L. C., Edelman, D. B., & Crook, J. N. (2002). *Credit scoring and its applications*. Society for Industrial and Applied Mathematics.
- Thomas, L. C., Crook, J. N., & Edelman, D. B. (2017). *Credit scoring and its applications* (2nd ed.). Society for Industrial and Applied Mathematics.
- Little & Rubin (2019) - *Statistical analysis with missing data*
- Enders (2010) - *Applied missing data analysis*
- Troyanskaya et al. (2001) - *Missing value estimation methods*
- van Buuren & Groothuis-Oudshoorn (2011) - *mice: Multivariate Imputation*
- Bergstra, J., & Bengio, Y. (2012). Random search for hyper-parameter optimization. *Journal of Machine Learning Research*
- Frazier, P. I. (2018). *A tutorial on Bayesian optimization*
- Snoek, J., Larochelle, H., & Adams, R. P. (2012). Practical Bayesian optimization of machine learning algorithms. *Advances in Neural Information Processing Systems*
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.
- Theodoridis, S., & Koutroumbas, K. (2008). *Pattern recognition*
- García, S., et al. (2015). *Data preprocessing in data mining*.
- Little, R. J., & Rubin, D. B. (2019). *Statistical Analysis with Missing Data*.
- Azur, M. J., et al. (2011). *Multiple imputation by chained equations*.
- Bergstra, J., & Bengio, Y. (2012). Random search for hyper-parameter optimization.
- Domingos, P. (2012). *A few useful things to know about machine learning*.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning*.
- Chen, T., & Guestrin, C. (2016). *XGBoost*.

Siddiqi, N. (2012). Credit Risk Scorecards.

A Comprehensive Guide to Random Forests, Debisree Ray (2025)

What is random forest?, Eda Kavlakoglu (2026)

Gradient Boosting in ML, 2025

What is Random Forest and how it works, Vivek Kumar

Business Analytics Newsletter. (2024, December 7). Artificial neural networks (ANNs). Business Analytics Review.

Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. arXiv.

Gambacorta, L., Huang, Y., Qiu, H., & Wang, J. (2019). How do machine learning and non-traditional data affect credit scoring? New evidence from a Chinese fintech firm (BIS Working Papers No. 834). Bank for International Settlements.

GeeksforGeeks. (2025, December 3). Gradient boosting in ML.

Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., & Liu, T.-Y. (2017). LightGBM: A highly efficient gradient boosting decision tree. Advances in Neural Information Processing Systems

LightGBM developers. (n.d.). Features. LightGBM documentation.

PyTorch Tutorials. (2025). Neural networks. PyTorch documentation.

Rao, C., Liu, Y., & Goh, M. (2023). Credit risk assessment mechanism of personal auto loan based on PSO-XGBoost model. Complex & Intelligent Systems

Shi, S., Tse, R., Luo, W., D'Addona, S., & Pau, G. (2022). Machine learning-driven credit risk: a systemic review. Neural Computing and Applications

Wang, K., Li, M., Cheng, J., Zhou, X., & Li, G. (2022). Research on personal credit risk evaluation based on XGBoost. Procedia Computer Science.

West, D. (2000). Neural network credit scoring models. Computers & Operations Research

XGBoost developers. (n.d.). Introduction to boosted trees. XGBoost documentation.

Ying, C., Shi, A., & Li, X. (2025). Hybrid boosted attention-based LightGBM framework for enhanced credit risk assessment in digital finance. Humanities and Social Sciences Communications

Barocas, S., & Selbst, A. D. (2016). Big data's disparate impact. California Law Review

Basel Committee on Banking Supervision. (2013). Principles for effective risk data aggregation and risk reporting. Bank for International Settlements.

European Banking Authority. (2023). Follow-up report on machine learning for IRB models. European Banking Authority.

European Union. (2016). General Data Protection Regulation, Article 22: Automated individual decision-making, including profiling.

European Union. (2024). Regulation (EU) 2024/1689 laying down harmonised rules on artificial intelligence. Official Journal of the European Union.

Hastie, T., Tibshirani, R., & Friedman, J. (2009). The elements of statistical learning: Data mining, inference, and prediction (2nd ed.). Springer.

Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). Applied logistic regression (3rd ed.). Wiley.

Lessmann, S., Baesens, B., Seow, H. V., & Thomas, L. C. (2015). Benchmarking state-of-the-art classification algorithms for credit scoring: An update of research. European Journal of Operational Research

Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. Advances in Neural Information Processing Systems

Rudin, C. (2019). Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. Nature Machine Intelligence

Thomas, L. C., Crook, J. N., & Edelman, D. B. (2017). Credit scoring and its applications (2nd ed.). Society for Industrial and Applied Mathematics.

Hand & Henley, (1997), Statistical Classification Methods in Consumer Credit Scoring: A Review

West, (2000), Neural Network Credit Scoring Models

Bensic, Sarlija, & Zekic-Susac, (2005), Small Business Credit Scoring: A Comparison of Logistic Regression, Neural Network and Decision Tree Models

Abdou, Pointon, & El-Masry, (2007), On the Applicability of Credit Scoring Models in Egyptian Banks

Abdou, Pointon, & El-Masry, (2008), Neural Nets versus Conventional Techniques in Credit Scoring in Egyptian Banking

Khandani, Kim, & Lo, (2010), Consumer Credit-Risk Models via Machine-Learning Algorithms

Brown & Mues, (2012), An Experimental Comparison of Classification Algorithms for Imbalanced Credit Scoring Data Sets

Kennedy, (2013), Credit Scoring Using Machine Learning

Louzada, Ara, & Fernandes, (2016), Classification Methods Applied to Credit Scoring: Systematic Review and Overall Comparison

Addo, Guegan, & Hassani, (2018), Credit Risk Analysis Using Machine and Deep Learning Models

Nehrebecka, (2018), Predicting the Default Risk of Companies: Comparison of Logistic Regression and Support Vector Machines

Wang & Ni, (2019), A XGBoost Risk Model via Feature Selection and Bayesian Hyper-Parameter Optimization

Alonso & Carbó, (2020), Understanding the Performance of Machine Learning Models to Predict Credit Default

Papilas, (2020), Credit Scoring through Machine Learning and Artificial Intelligence

Liu et al., (2021), Classification of Imbalanced Credit Scoring Data Sets Based on Ensemble Learning

Kozodoi, (2022), Machine Learning for Credit Risk Analytics

Machado & Holmer, (2022), Credit Risk Modelling and Prediction: Logistic Regression versus Machine Learning Boosting Algorithms

Dumitrescu, Hué, Hurlin, & Tokpavi, (2022), Machine Learning for Credit Scoring: Improving Logistic Regression with Non-Linear Decision-Tree Effects

Tanavejwasin, (2022), Credit Risk Scoring Based on Machine Learning Models

Chitambira, (2022), Credit Scoring Using Machine Learning Approaches

Gao, (2022), Construction of a Financial Default Risk Prediction Model Based on LightGBM

Noriega, Rivera, & Quispe-Herrera, (2023), Machine Learning for Credit Risk Prediction: A Systematic Literature Review

Dernsjö, (2023), A Gradient Boosting Tree Approach for Behavioural Credit Scoring

Suleri, (2023), Interpretable Machine Learning for Credit Scoring

El Haouari, (2023), An Explainable Artificial Intelligence Credit Rating System

Taş, (2023), Comparison of Machine Learning and Standard Credit Risk Models' Performances in Credit Risk Scoring of Buy Now Pay Later Customers

Zedda, (2024), Credit Scoring: Does XGBoost Outperform Logistic Regression? A Test on Italian SMEs

Chang, (2024), Credit Risk Prediction Using Machine Learning and Deep Learning: A Study on Credit Card Customers

Bücker, M., Szepannek, G., Gosiewska, A., & Biecek, P. (2020). Transparency, auditability and explainability of machine learning models in credit scoring.

European Banking Authority. (2023). Follow-up report on machine learning for IRB models. European Banking Authority.

European Central Bank. (2024). ECB guide to internal models. European Central Bank Banking Supervision.

Lessmann, S., Baesens, B., Seow, H.-V., & Thomas, L. C. (2015). Benchmarking state-of-the-art classification algorithms for credit scoring: An update of research. *European Journal of Operational Research*.

Schmitt, M. (2022). Deep learning vs. gradient boosting: Benchmarking state-of-the-art machine learning algorithms for credit scoring.

Hardt, M., Price, E., & Srebro, N. (2016). Equality of opportunity in supervised learning. *Advances in Neural Information Processing Systems*.

Υπεύθυνη Δήλωση Συγγραφέα:

Δηλώνω ρητά ότι, σύμφωνα με το άρθρο 8 του Ν.1599/1986, η παρούσα εργασία αποτελεί αποκλειστικά προϊόν προσωπικής μου εργασίας, δεν προσβάλλει κάθε μορφής δικαιώματα διανοητικής ιδιοκτησίας, προσωπικότητας και προσωπικών δεδομένων τρίτων, δεν περιέχει έργα/εισφορές τρίτων για τα οποία απαιτείται άδεια των δημιουργών/δικαιούχων και δεν είναι προϊόν μερικής ή ολικής αντιγραφής, οι πηγές δε που χρησιμοποιήθηκαν περιορίζονται στις βιβλιογραφικές αναφορές και μόνον και πληρούν τους κανόνες της επιστημονικής παράθεσης.