



ΕΛΛΗΝΙΚΗ ΔΗΜΟΚΡΑΤΙΑ
Εθνικόν και Καποδιστριακόν
Πανεπιστήμιον Αθηνών
— ΙΔΡΥΘΕΝ ΤΟ 1837 —

ΣΧΟΛΗ ΟΙΚΟΝΟΜΙΚΩΝ ΚΑΙ ΠΟΛΙΤΙΚΩΝ
ΕΠΙΣΤΗΜΩΝ ΤΜΗΜΑ ΕΠΙΚΟΙΝΩΝΙΑΣ ΚΑΙ ΜΕΣΩΝ
ΜΑΖΙΚΗΣ ΕΝΗΜΕΡΩΣΗΣ
Π.Μ.Σ.: ΨΗΦΙΑΚΑ ΜΕΣΑ ΕΠΙΚΟΙΝΩΝΙΑΣ ΚΑΙ
ΠΕΡΙΒΑΛΛΟΝΤΑ ΑΛΛΗΛΕΠΙΔΡΑΣΗΣ

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ
της **ΝΙΚΟΛΕΤΑΣ ΓΙΑΝΝΟΥΚΑΚΟΥ**
Α.Μ.: 7983092200003

**Αποκαλύπτοντας την προκατάληψη: Μια συγκριτική
ανάλυση των τεχνικών μηχανικής μάθησης στην παγκόσμια
αγορά ψηφιακής τραπεζικής και οι ηθικές επιπτώσεις τους**

Επιβλέποντες:

α) ΚΩΝΣΤΑΝΤΙΝΟΣ ΜΟΥΡΛΑΣ (Αναπληρωτής Καθηγητής, Τμήμα Επικοινωνίας
και ΜΜΕ)

β) ΑΙΚΑΤΕΡΙΝΗ ΣΩΤΗΡΑΚΟΥ PhD (Επιστημονική Συνεργάτης Προγράμματος,
Τμήμα Επικοινωνίας και ΜΜΕ)

Αθήνα, 25/02/2024

Ευχαριστίες

Θα ήθελα να ευχαριστήσω την Κάτια, τον Ιάσων, τον Αλέξη, την οικογένειά μου και όλους μου τους φίλους που με βοήθησαν και με στήριξαν στην διαδικασία εκπόνησης της παρούσας εργασίας.

Περίληψη

Η υιοθέτηση τεχνικών τεχνητής νοημοσύνης και μηχανικής μάθησης στα χρηματοπιστωτικά ιδρύματα έχει μεταμορφώσει τις παραδοσιακές τους λειτουργίες, φέρνοντας επανάσταση στην αξιολόγηση του πιστωτικού κινδύνου αλλά και στις εσωτερικές διαδικασίες των οργανισμών.

Η παρούσα εργασία πραγματοποιεί μια συγκριτική ανάλυση των τεχνικών μηχανικής μάθησης που χρησιμοποιούνται στην παγκόσμια ψηφιακή τραπεζική αγορά, εστιάζοντας στις προγνωστικές τους δυνατότητες και στις ηθικές τους εκτιμήσεις. Εξετάζοντας τους αλγορίθμους λογιστικής παλινδρόμησης, δέντρων αποφάσεων και τυχαίου δάσους, αξιολογείται η αποτελεσματικότητά τους στην πρόβλεψη αποφάσεων χορήγησης χρηματοπιστωτικών προϊόντων, ενώ παράλληλα διερευνώνται οι πιθανές προκαταλήψεις που ενυπάρχουν στα μοντέλα.

Αξιοποιώντας ένα σύνολο δεδομένων από τον χρηματοπιστωτικό τομέα, αναλύεται τον αντίκτυπο δημογραφικών μεταβλητών, όπως το φύλο και η οικογενειακή κατάσταση στα αποτελέσματα της έγκρισης δανείων. Τα ευρήματά αποκαλύπτουν διαφορετικά επίπεδα σημασίας των χαρακτηριστικών στους διάφορους αλγορίθμους, υπογραμμίζοντας τη σημασία της προκατάληψης και της δικαιοσύνης στα μοντέλα μηχανικής μάθησης. Μέσω αυτής της ανάλυσης, επισημαίνονται οι ηθικές επιπτώσεις της αλγοριθμικής λήψης αποφάσεων στις χρηματοπιστωτικές υπηρεσίες υποστηρίζοντας διαφανείς και υπεύθυνες πρακτικές για τον μετριασμό των προκαταλήψεων και την ευημερία του τραπεζικού κλάδου.

Λέξεις Κλειδιά: Μηχανική μάθηση, Τεχνητή νοημοσύνη, Ψηφιακή τραπεζική, Μεροληψία, Δικαιοσύνη, Ηθικές επιπτώσεις, Έγκριση δανείων, Λογιστική παλινδρόμηση, Δέντρα αποφάσεων, Τυχαίο δάσος, Σύνολο δεδομένων

Abstract

The adoption of artificial intelligence and machine learning techniques in financial institutions has transformed their traditional operations, revolutionizing both credit risk assessment and the internal processes of the institutions.

This paper performs a comparative analysis of machine learning techniques used in the global digital banking market, focusing on their predictive capabilities and ethical considerations. By examining logistic regression, decision tree and random forest algorithms, we evaluate their effectiveness in predicting financial product approval decisions, while exploring the potential biases inherent in the models.

Using a dataset from the financial sector, the impact of demographic variables, such as gender and marital status, on loan approval outcomes is analyzed. The findings reveal different levels of importance of attributes in different algorithms, highlighting the importance of interpretability and fairness in machine learning models. Through this analysis, the ethical implications of algorithmic decision making in financial services are highlighted, supporting transparent and accountable practices to mitigate bias and promote financial inclusion.

Keywords: Machine learning, Artificial intelligence, Digital banking, Bias, Justice, Ethical implications, Ethical implications, Loan approval, Accounting regression, Decision trees, Random forest, Data set

Κατάλογος Εικόνων

| | |
|--|-----|
| Εικόνα 1. Μεροληψία στους αλγόριθμους μηχανικής μάθησης και στην τεχνητή νοημοσύνη | 13 |
| Εικόνα 2. Τρόπος λειτουργίας αλγόριθμου εποπτευόμενης μηχανικής μάθησης | 21 |
| Εικόνα 3. Τρόπος διεξαγωγής μη εποπτευόμενης μηχανικής μάθησης | 22 |
| Εικόνα 4. Παραδείγματα εποπτευόμενης και μη εποπτευόμενης μηχανικής μάθησης..... | 22 |
| Εικόνα 5. Παράδειγμα ημι-εποπτευόμενης μηχανικής μάθησης | 23 |
| Εικόνα 6. Διάγραμμα εφαρμογής πιστωτικής αξιολόγησης με εφαρμογή Λογιστικής Παλινδρόμησης σε μοντέλο Μηχανικής Μάθησης..... | 38 |
| Εικόνα 7. Εντοπισμός παγκόσμιας ηλεκτρονικής απάτης για την περίοδο 2016-2022 | 40 |
| Εικόνα 8. Δείγμα πηγών δεδομένων που συλλέγονται από ψηφιακές τράπεζες | 47 |
| Εικόνα 9. Το Zen της Python..... | 67 |
| Εικόνα 10. Κατανομή των δεδομένων | 80 |
| Εικόνα 11. Σχήμα των δεδομένων & αποτύπωση κενών τιμών | 80 |
| Εικόνα 12. Αντικατάσταση κενών τιμών..... | 81 |
| Εικόνα 13. Τελική μορφή των δεδομένων πριν την ανάλυση | 81 |
| Εικόνα 14. Σχέση εγκεκριμένων και μη εγκεκριμένων δανείων..... | 83 |
| Εικόνα 15. Κατανομή ποσών των δανείων | 84 |
| Εικόνα 16. Κατανομή εισοδήματος αιτούντων | 86 |
| Εικόνα 16. Διανομή έγκρισης και απόρριψης δανείων συγκριτικά με το εισόδημα | 87 |
| Εικόνα 17. Οικογενειακή κατάσταση αιτούντων | 88 |
| Εικόνα 18. Σύγκριση οικογενειακής κατάστασης και κατάστασης αιτούντων | 89 |
| Εικόνα 18. Κατανομή περιοχών ακινήτων των δανείων | 91 |
| Εικόνα 19. Έγκριση δανείου ανά περιοχή ακινήτου | 92 |
| Εικόνα 20. Απόρριψη δανείων ανά περιοχή..... | 93 |
| Εικόνα 20. Διάρκεια δανείων | 94 |
| Εικόνα 21. Αυτοαπασχόληση αιτούντων | 96 |
| Εικόνα 22. Σύγκρισης έγκρισης δανείων και εξαρτώμενων μελών | 97 |
| Εικόνα 23. Σύγκρισης έγκρισης δανείων και πιστωτικού ορίου | 98 |
| Εικόνα 24. Κατανομή του φύλου συγκριτικά με την έγκριση δανείων..... | 99 |
| Εικόνα 25. Απεικόνιση της γραμμικής παλινδρόμησης..... | 102 |
| Εικόνα 26. Παράδειγμα δέντρου απόφασης..... | 104 |
| Εικόνα 27. Παράδειγμα τυχαίου δάσους..... | 106 |
| Εικόνα 28. Το σχήμα των δεδομένων..... | 108 |
| Εικόνα 29. Μετατροπή στηλών τύπου «object» σε αριθμητικά δεδομένα | 110 |
| Εικόνα 30. Το σύνολο των δεδομένων μετά την μετατροπή των κατηγορικών μεταβλητών σε αριθμητικές | 110 |
| Εικόνα 31. Πίνακας σύγχυσης του μοντέλου λογιστικής παλινδρόμησης..... | 116 |
| Εικόνα 32. Συσχέτιση σημαντικότητας χαρακτηριστικών για την έγκριση των δανείων | 119 |
| Εικόνα 33. Απεικόνιση ενός τυχαίου δέντρου απόφασης | 122 |
| Εικόνα 34. Σημαντικότητα χαρακτηριστικών για την χορήγηση δανείου στο μοντέλο Decision Trees | 125 |
| Εικόνα 35. Σημαντικότητα χαρακτηριστικών για την χορήγηση δανείου στο μοντέλο Random Forest | 130 |
| Εικόνα 36. Σύγκριση απόδοσης των τριών μοντέλων..... | 131 |

Κατάλογος Πινάκων

| | |
|---|----|
| Πίνακας 1: Εφαρμογές Μηχανικής Μάθησης..... | 27 |
| Πίνακας 2: Τεχνολογικά Ορόσημα στην Ψηφιακή Τραπεζική | 33 |
| Πίνακας 3: Περιγραφή των δεδομένων..... | 78 |

Περιεχόμενα

| | |
|--|-----------|
| ΕΥΧΑΡΙΣΤΙΕΣ | 2 |
| ΠΕΡΙΛΗΨΗ | 3 |
| ABSTRACT | 4 |
| ΚΑΤΑΛΟΓΟΣ ΕΙΚΟΝΩΝ | 5 |
| ΚΑΤΑΛΟΓΟΣ ΠΙΝΑΚΩΝ | 6 |
| ΠΕΡΙΕΧΟΜΕΝΑ | 7 |
| 1. ΕΙΣΑΓΩΓΗ | 10 |
| 1.1 Ανάλυση του προβλήματος | 12 |
| 1.2 Ερωτήματα και στόχοι της έρευνας | 15 |
| 2. ΓΝΩΣΤΙΚΟ ΥΠΟΒΑΘΡΟ | 17 |
| 2.1 Μηχανική μάθηση | 17 |
| 2.1.1 Ιστορική Αναδρομή στην εξέλιξη της μηχανικής μάθησης..... | 18 |
| 2.1.2 Ορισμός μηχανικής μάθησης | 19 |
| 2.1.3 Τύποι μηχανικής μάθησης..... | 20 |
| 2.1.5 Εφαρμογές της μηχανικής μάθησης..... | 25 |
| 2.2 Ψηφιακή Τραπεζική | 28 |
| 2.2.1 Ιστορική Αναδρομή στην εξέλιξη της ψηφιακής τραπεζικής..... | 28 |
| 2.2.2 Ορισμός της ψηφιακής τραπεζικής..... | 30 |
| 2.2.3 Τεχνολογικά ορόσημα στην ψηφιακή τραπεζική..... | 32 |
| 2.3 Τεχνητή Νοημοσύνη και Μηχανική Μάθηση στην Ψηφιακή Τραπεζική | 34 |
| 2.3.1 Ενσωμάτωση της τεχνητής νοημοσύνης στην ψηφιακή τραπεζική..... | 34 |
| 2.3.2 Εξατομίκευση και εμπειρία πελατών | 34 |
| 3. ΑΝΑΛΥΣΗ ΤΟΥ ΠΡΟΒΛΗΜΑΤΟΣ | 41 |
| 3.1 Πλαίσιο των δεδομένων και των αλγορίθμων μηχανικής μάθησης | 42 |
| 3.1.1 Χαρακτηριστικά των δεδομένων..... | 42 |
| 3.1.2 Πηγές άντλησης δεδομένων..... | 45 |
| 3.1.3 Χρήση των αλγορίθμων μηχανικής μάθησης στην τραπεζική..... | 47 |
| 3.2 Μεροληψία και προκατάληψη στα δεδομένα και στους αλγορίθμους μηχανικής μάθησης | 49 |
| 3.2.1 Τύποι μεροληψίας στα σύνολα δεδομένων..... | 49 |
| 3.2.2 Τύποι μεροληψίας στους αλγορίθμους μηχανικής μάθησης..... | 52 |
| 3.2.2 Προκλήσεις στην ανίχνευση της μεροληψίας..... | 55 |
| 3.3 Δεοντολογικά ζητήματα στην τεχνητή νοημοσύνη, την μηχανική μάθηση και τον τραπεζικό τομέα | 57 |
| 3.3.1 Απόρρητο των δεδομένων και εμπιστοσύνη των πελατών..... | 57 |
| 3.3.2 Διαφάνεια και λογοδοσία | 58 |
| 3.3.3 Δικαιοσύνη..... | 60 |

| | |
|---|------------|
| 3.3.4 Κανονιστικό πλαίσιο..... | 61 |
| 3.3.5 Διακρίσεις..... | 63 |
| 4. ΜΕΘΟΔΟΛΟΓΙΑ ΤΗΣ ΕΡΕΥΝΑΣ | 65 |
| 4.1 Σύνοψη του προβλήματος..... | 65 |
| 4.2 Χρήσιμα Βοηθήματα | 66 |
| 4.2.1 Η γλώσσα προγραμματισμού Python | 66 |
| 4.2.2 Η κοινότητα Kaggle..... | 68 |
| 4.2.3 Η πλατφόρμα Google Colab..... | 69 |
| 4.3 Μεθοδολογία..... | 70 |
| 4.4 Επιλογή και εξόρυξη δεδομένων | 72 |
| 4.4.1 Αναζήτηση δεδομένων στο πεδίο του προβλήματος..... | 72 |
| 4.4.2 Η εταιρία Dream Housing Finance..... | 73 |
| 4.4.3 Περιγραφή του προβλήματος..... | 74 |
| 5. ΑΝΑΛΥΣΗ ΔΕΔΟΜΕΝΩΝ ΚΑΙ ΑΝΙΧΝΕΥΣΗ ΜΕΡΟΛΗΨΙΑΣ | 75 |
| 5.1 Περιγραφές και χαρακτηριστικά των συνόλων δεδομένων | 75 |
| 5.2 Επεξεργασία και καθαρισμός δεδομένων | 79 |
| 5.3 Διερευνητική ανάλυση δεδομένων | 82 |
| 5.3.1 Κατανομή εγκεκριμένων και μη εγκεκριμένων δανείων | 83 |
| 5.3.2 Κατανομή ποσών δανείων..... | 84 |
| 5.3.3 Κατανομή εισοδήματος αιτούντων..... | 86 |
| 5.3.3 Διανομή έγκρισης και απόρριψης δανείων συγκριτικά με το εισόδημα..... | 87 |
| 5.3.4 Οικογενειακή κατάσταση αιτούντων..... | 88 |
| 5.3.5 Κατανομή περιοχών..... | 91 |
| 5.3.6 Διάρκεια δανείων..... | 94 |
| 5.3.7 Αυτοαπασχόληση αιτούντων..... | 96 |
| 5.3.8 Σύγκρισης έγκρισης δανείων και εξαρτώμενων μελών..... | 97 |
| 5.3.9 Σύγκρισης έγκρισης δανείων και πιστωτικού ορίου..... | 98 |
| 5.3.9 Κατανομή του φύλου συγκριτικά με την έγκριση δανείων..... | 99 |
| 5.4 Μοντέλα και τεχνικές μηχανικής μάθησης..... | 101 |
| 5.5 Ανάλυση αλγόριθμου μηχανικής μάθησης..... | 107 |
| 5.5.1 Δημιουργία του μοντέλου Λογιστικής Παλινδρόμησης (Logistic Regression) | 111 |
| 5.5.2 Δημιουργία του μοντέλου Δέντρων Αποφάσεων (Decision Trees)..... | 119 |
| 5.5.2 Δημιουργία του μοντέλου Τυχαίου Δάσους (Random Forest)..... | 126 |
| 5.5.4 Σύγκριση των μοντέλων..... | 130 |
| 6. ΑΠΟΤΕΛΕΣΜΑΤΑ: ΗΘΙΚΕΣ ΕΠΙΠΤΩΣΕΙΣ ΚΑΙ ΣΥΣΤΑΣΕΙΣ | 132 |
| 6.1 Αποτελέσματα ανάλυσης | 132 |
| 6.2 Στρατηγικές για υπεύθυνη τεχνητή νοημοσύνη και μηχανική μάθηση στον τραπεζικό τομέα..... | 136 |

| | |
|---|------------|
| 7. ΣΥΜΠΕΡΑΣΜΑΤΑ ΚΑΙ ΜΕΛΛΟΝΤΙΚΕΣ ΚΑΤΕΥΘΥΝΣΕΙΣ | 141 |
| 7.1 Σύνοψη των ευρημάτων..... | 141 |
| 7.2 Περιορισμοί και τομείς για μελλοντική έρευνα | 143 |
| ΒΙΒΛΙΟΓΡΑΦΙΑ | 146 |

1. Εισαγωγή

Η έλευση της ψηφιακής τραπεζικής σηματοδοτεί ένα ορόσημο στον ψηφιακό μετασχηματισμό στην ιστορία του χρηματοπιστωτικού τομέα. Στην εποχή αυτή, τα παραδοσιακά τραπεζικά πρότυπα αναδιαμορφώνονται συνεχώς από την ενσωμάτωση καινοτόμων ψηφιακών τεχνολογιών, παρουσιάζοντας νέες ευκαιρίες και προκλήσεις στον κλάδο. Η εμφάνιση της ψηφιακής τραπεζικής μπορεί να αναχθεί στα τέλη του 20ού αιώνα, όταν οι τεχνολογικές εξελίξεις άρχισαν να αναδιαμορφώνουν το χρηματοπιστωτικό τοπίο.

Η ψηφιακή τραπεζική, η οποία χαρακτηρίζεται από την ψηφιοποίηση των χρηματοπιστωτικών υπηρεσιών, απέχει από τα συμβατικά τραπεζικά μοντέλα, όπως τη διέλευση των πελατών για βασικές τραπεζικές εργασίες στα φυσικά καταστήματα. Από την ευελιξία των ηλεκτρονικών συναλλαγών έως την έλευση των τραπεζικών εφαρμογών για κινητά τηλέφωνα και υπολογιστές, η αλλαγή αυτή έχει επαναπροσδιορίσει τον τρόπο με τον οποίο οι ιδιώτες και οι επιχειρήσεις διαχειρίζονται τα οικονομικά τους. Στο επίκεντρο αυτού του μετασχηματισμού βρίσκεται η υιοθέτηση της τεχνητής νοημοσύνης και της μηχανικής μάθησης, οι οποίες επιφέρουν αυξημένη αποτελεσματικότητα στον σχεδιασμό των τραπεζικών μοντέλων και του ρίσκου, εξατομίκευση στην εμπειρία του πελάτη και λήψη αποφάσεων βάσει μεγάλων δεδομένων.

Στο τραπεζικό πλαίσιο, είτε πρόκειται για ιστορικό συναλλαγών, είτε για πιστοποίηση των προσωπικών στοιχείων των πελατών, τα μοντέλα μηχανικής μάθησης ευνοούν τις τράπεζες με την ταχύτερη επεξεργασία και ανάλυση των διαθέσιμων δεδομένων ώστε να έχουν βαθύτερη κατανόηση στις ανάγκες των πελατών και να προσφέρουν εξατομικευμένες λύσεις και υπηρεσίες, αλλά και να βελτιώσουν τις εσωτερικές τους διαδικασίες στον σχεδιασμό των τραπεζικών προϊόντων και παροχών. Με τη μηχανική μάθηση στον τραπεζικό τομέα, τα χρηματοπιστωτικά ιδρύματα μπορούν επίσης να μεγιστοποιήσουν την ανίχνευση απάτης, να βελτιστοποιήσουν την πιστοληπτική πολιτική και να βελτιώσουν τις διαδικασίες συμμόρφωσης στο ισχύον κανονιστικό πλαίσιο.

Στον αντίποδα, η ενσωμάτωση αλγορίθμων μηχανικής μάθησης σε παγκόσμιο επίπεδο στην ψηφιακή τραπεζική, εισάγει τόσο δυνατότητες όσο και ανησυχίες, κυρίως στο πεδίο του ηθικού πλαισίου που χρησιμοποιούνται τα δεδομένα των πελατών, καθώς και στο ποσοστό που οι μέθοδοι και οι αλγόριθμοι είναι σχεδιασμένοι να αποκλείουν κάποια κριτήρια και να εφαρμόζουν διακρίσεις σε βασικές τραπεζικές εργασίες όπως η δανειοδότηση, ο σχηματισμός εξατομικευμένου χαρτοφυλακίου και σε πρακτικές που αφορούν τον εντοπισμό απάτης και της κυβερνοασφάλειας.


Εμβαθύνοντας στις τεχνικές μηχανικές μάθησης και στον τρόπο με τον οποίο εφαρμόζονται στα τραπεζικά προϊόντα και υπηρεσίες, θα ενισχυθεί η διερεύνηση της προκατάληψης και των προβλημάτων που εντοπίζονται σε αυτές. Με την κατανόηση των βασικών ψηφιακών λύσεων που χρησιμοποιούνται τις τελευταίες δεκαετίες στην ψηφιακή τραπεζική καθώς και με εστίαση στα ανοιχτά δεδομένα των τραπεζών σε παγκόσμιο επίπεδο, μπορούμε να αντιληφθούμε καλύτερα τις ηθικές επιπτώσεις που υπάρχουν στην εφαρμογή της μηχανικής μάθησης, θέτοντας τα θεμέλια για επακόλουθες προτάσεις βελτιώσεων και πιθανές λύσεις.

1.1 Ανάλυση του προβλήματος

Η ενσωμάτωση της τεχνητής νοημοσύνης στην ψηφιακή τραπεζική φέρνει στο προσκήνιο ένα φάσμα ηθικών προβληματισμών. Η χρήση όλο και περισσότερων αλγόριθμων μηχανικής μάθησης για τον σχεδιασμό χορήγησης δανείων, πιστωτικών καρτών και άλλων τραπεζικών προϊόντων καθώς και στην βελτίωση εσωτερικών διαδικασιών, προκύπτει μια κρίσιμη ανάγκη να εξεταστούν διεξοδικά οι ηθικές επιπτώσεις αυτών των τεχνολογιών. Η πρωταρχική ανησυχία έγκειται στη διασφάλιση ότι η μηχανική μάθηση στην ψηφιακή τραπεζική ευθυγραμμίζεται με τις αρχές της δικαιοσύνης, της διαφάνειας και της λογοδοσίας.

Οι υφιστάμενες ηθικές προκλήσεις που έχουν παρατηρηθεί τις τελευταίες δεκαετίες στο πλαίσιο της ψηφιακής τραπεζικής αλλά και της παγκόσμιας οικονομίας ενισχύονται τόσο σε επίπεδο από την υιοθέτηση της μηχανικής μάθησης. Η προστασία της ιδιωτικότητας των δεδομένων και η ανάπτυξη σχέσεων εμπιστοσύνης μεταξύ πελατών και τράπεζας είναι πλέον στενά συνυφασμένες με την επιλογή των κατάλληλων μεθόδων μηχανικής μάθησης. Η κατανόηση και η αντιμετώπιση αυτών των προκλήσεων αποτελεί επιτακτική ανάγκη για την τήρηση των αρχών προστασίας των προσωπικών δεδομένων και τη διατήρηση της εμπιστοσύνης του κοινού.

Η παρουσία της προκατάληψης παρατηρείται ως μία από τις σημαντικότερες ηθικές προκλήσεις στις εφαρμογές μηχανικής μάθησης για ψηφιακές τραπεζικές συναλλαγές. Η μεροληψία στους αλγόριθμους μπορεί να εκδηλωθεί με διάφορες μορφές, όπως το φύλο, η κοινωνικοοικονομική κατάσταση και τα δημογραφικά στοιχεία. Το φύλο ως παράδειγμα αυτών, έχει υπάρξει πρωταρχικό στοιχείο προκατάληψης τα τελευταία χρόνια στους αλγόριθμους μηχανικής μάθησης όχι μόνο στον τραπεζικό τομέα αλλά και σε άλλους τομείς.



Εικόνα 1. Μεροληψία στους αλγόριθμους μηχανικής μάθησης και στην τεχνητή νοημοσύνη

https://www.researchgate.net/figure/Scopus-indexed-articles-for-different-gender-related-terms_fig1_363063840

Η ακούσια ενσωμάτωση προκαταλήψεων στα μοντέλα μηχανικής μάθησης μπορεί να οδηγήσει σε αποτελέσματα που εμφανίζουν ποικίλες διακρίσεις, επιδεινώνοντας τις υφιστάμενες κοινωνικές ανισότητες. Επιπλέον, οι εν λόγω αλγόριθμοι είναι πιθανό να συμβάλουν στον οικονομικό αποκλεισμό και να διαβρώσουν την εμπιστοσύνη του κοινού στις ψηφιακές τραπεζικές υπηρεσίες.

Στην χορήγηση δανείων ή την παροχή άλλων τραπεζικών προϊόντων όπως πιστωτικές κάρτες οι τράπεζες χρησιμοποιούν αλγόριθμους μηχανικής μάθησης προκειμένου να παρέχουν αυτές τις υπηρεσίες αυτοματοποιημένα μέσω των ψηφιακών τους καναλιών. Στην περίπτωση των χορηγήσεων σε ιδιώτες πελάτες, τα προαναφερόμενα κριτήρια εφαρμόζονται για να προβλεφθεί το αποτέλεσμα της αίτησης. Το πρόβλημα εμφανίζεται όταν η αίτηση χορήγησης του δανείου απορρίπτεται βασισμένη σε κάποιο κριτήριο που έχει εφαρμοστεί στον αλγόριθμο. Ο τρόπος με τον οποίο συνυπολογίζεται το εκάστοτε κριτήριο μπορεί να προσθέσει στοιχεία προκατάληψης και να μεταβάλει το αποτέλεσμα.

Η συγκεκριμένη πρακτική ενδέχεται να εμφανίσει προβλήματα τόσο στους δυνητικούς δανειολήπτες όσο και στα χρηματοπιστωτικά ιδρύματα. Οι πελάτες δεν θα έχουν τη δυνατότητα να αποκτήσουν το δάνειο που επιθυμούν και οι τράπεζες ενδέχεται να απορρίψουν κάποια αίτηση η οποία πιθανώς να επέφερε κέρδος, χαρακτηρίζοντας το δάνειο ως μη εξυπηρετούμενο.

Η εξέταση και η διερεύνηση των χρησιμοποιούμενων αυτών μοντέλων θα διαλευκάνει την πολυπλοκότητα της προκατάληψης στην εφαρμογή της μηχανικής μάθησης σε αυτές τις περιπτώσεις παροχής ψηφιακών τραπεζικών υπηρεσιών.

1.2 Ερωτήματα και στόχοι της έρευνας

Ο πρωταρχικός σκοπός της παρούσας διπλωματικής εργασίας είναι να διερευνήσει σε βάθος τις διάφορες τεχνικές μηχανικής μάθησης που χρησιμοποιούνται στην παγκόσμια αγορά ψηφιακής τραπεζικής. Με την ανάλυση των αλγορίθμων και των προσεγγίσεων που χρησιμοποιούνται από τα χρηματοπιστωτικά ιδρύματα παγκοσμίως, η έρευνα αποσκοπεί στην απόκτηση μιας ολοκληρωμένης κατανόησης των πρακτικών μηχανικής μάθησης στον κλάδο.

Ένας άλλος κρίσιμος στόχος της παρούσας διατριβής είναι ο εντοπισμός και η εξέταση των προκαταλήψεων που υπάρχουν μέσω ανάλυσης των διαθέσιμων συνόλων δεδομένων που χρησιμοποιούνται στην ψηφιακή τραπεζική. Με την ενδεδειγμένη εξέταση των δεδομένων, η έρευνα επιδιώκει να ρίξει φως σε πιθανές δημογραφικές ανισότητες, προκαταλήψεις και άλλες πηγές που θα μπορούσαν να επηρεάσουν τις διαδικασίες λήψης αποφάσεων των χρηματοπιστωτικών ιδρυμάτων.

Μέσω μιας συγκριτικής ανάλυσης, η παρούσα διπλωματική εργασία αποσκοπεί στην αξιολόγηση διαφορετικών μεθόδων και κριτηρίων που εφαρμόζονται στις μεθόδους μηχανικής μάθησης. Με τη διερεύνηση διαφόρων προσεγγίσεων για τη μέτρηση της προκατάληψης, η έρευνα επιδιώκει να καθορίσει τον βαθμό της σε σύνολα δεδομένων ψηφιακής τραπεζικής.

Η παρούσα έρευνα επιδιώκει να διερευνήσει τις ηθικές επιπτώσεις της χρήσης τεχνικών μηχανικής μάθησης στον ψηφιακό τραπεζικό κλάδο. Αποκαλύπτοντας προκαταλήψεις και κατανοώντας τον αντίκτυπό τους στην παροχή ψηφιακών τραπεζικών υπηρεσιών και προϊόντων, η διατριβή αποσκοπεί στην ανάδειξη των πιθανών συνεπειών για τους πελάτες, τη χρηματοπιστωτική ένταξη και την προστασία της ιδιωτικότητας των δεδομένων.

Επιπλέον, έχει ως στόχο να προσφέρει πρακτικές συστάσεις και κατευθυντήριες γραμμές για τον μετριασμό των προκαταλήψεων στα μοντέλα μηχανικής μάθησης στον τομέα της ψηφιακής τραπεζικής. Προτείνοντας εφαρμόσιμες λύσεις, η έρευνα επιδιώκει να δώσει τη δυνατότητα στα χρηματοπιστωτικά ιδρύματα να

αντιμετωπίσουν αποτελεσματικά τις προκαταλήψεις και να δημιουργήσουν πιο δίκαιες υπηρεσίες για την ποικιλόμορφη πελατειακή τους βάση.

Μέσω αυτών των σκοπών, η διατριβή φιλοδοξεί να συμβάλει ουσιαστικά στον τομέα της ψηφιακής τραπεζικής, της μηχανικής μάθησης και της ηθικής, προωθώντας τελικά την ανάπτυξη πιο δίκαιων και υπεύθυνων εφαρμογών τεχνητής νοημοσύνης στον παγκόσμιο κλάδο χρηματοπιστωτικών υπηρεσιών.

2. Γνωστικό υπόβαθρο

2.1 Μηχανική μάθηση

Η μηχανική μάθηση είναι ένα σημαντικό εργαλείο για τον στόχο της μόχλευσης των τεχνολογιών γύρω από την τεχνητή νοημοσύνη. Μέχρι τα τέλη της δεκαετίας του 1970, η μηχανική μάθηση ήταν μέρος της εξέλιξης της τεχνητής νοημοσύνης. Στη συνέχεια, άρχισε να εξελίσσεται από μόνη της.

Η μηχανική μάθηση αποτελεί τη διαδικασία εκπαίδευσης των υπολογιστών ώστε να χρησιμοποιούν τα δεδομένα και την εμπειρία όπως ο ανθρώπινος εγκέφαλος (Gör, 2014).

Ο κύριος στόχος της μηχανικής μάθησης είναι η δημιουργία μοντέλων που μπορούν να εκπαιδευτούν για να βελτιώνονται, να αντιλαμβάνονται τα πολύπλοκα μοτίβα και να βρίσκουν λύσεις στα νέα προβλήματα χρησιμοποιώντας τα διαθέσιμα δεδομένα (Tantuğ ve Türkmenoğlu, 2015).

2.1.1 Ιστορική Αναδρομή στην εξέλιξη της μηχανικής μάθησης

Οι έρευνες της τεχνητής νοημοσύνης ξεκίνησαν τη δεκαετία του 1950 (Erdem, 2014). Εκείνα την χρονική περίοδο, ο Alan Turing πραγματοποίησε το τεστ Τούρινγκ προκειμένου να ελέγξει την ικανότητα μιας μηχανής να μιμηθεί έναν άνθρωπο. Ο στόχος του τεστ Τούρινγκ ήταν να μετρήσει την ικανότητα της μηχανής να έρθει σε επαφή με έναν άνθρωπο κατά τη διάρκεια μιας συνέντευξης. Εάν η μηχανή είχε λιγότερο ακριβή απόδοση από τον άνθρωπο, ήταν επιτυχής. Το 1956, ο όρος «τεχνητή νοημοσύνη» χρησιμοποιήθηκε για πρώτη φορά σε ένα θερινό σχολείο που διοργάνωσε ο Marvin Minsky από το Ινστιτούτο Τεχνολογίας της Μασαχουσέτης, τον John McCarthy από το πανεπιστήμιο του Stanford και τους Allen Newell και Herbert Simon από το Πανεπιστήμιο Carnegie-Mellon. Μέχρι τότε χρησιμοποιούνταν ο όρος του Alan Turing, "μηχανική νοημοσύνη" (Çelik, Özer, 2018).

Το 1959, ο Arthur Samuel δημιούργησε το πρόγραμμα ντάμας, και έκτοτε η μηχανική μάθηση εδραιώθηκε ως όρος και ξεκίνησε η μετέπειτα εξέλιξή της. Φτάνοντας στη δεκαετία του 1980, υπήρξαν κάποιες μελέτες για τον αφηρημένο νου, την πληροφορία που βασίζεται σε συστήματα, τα οποία ονομάστηκαν "χειμώνας της τεχνητής νοημοσύνης". Στη δεκαετία του 1990, δόθηκε ιδιαίτερη σημασία στις μελέτες για τη μηχανική νοημοσύνη και τη μηχανική μάθηση λόγω της εξέλιξης και της αυξημένης ζήτησης στη βιομηχανία των ηλεκτρονικών παιχνιδιών. Σήμερα, η τεχνητή νοημοσύνη και η μηχανική μάθηση χρησιμοποιούνται σε πολλές έρευνες και ποικίλους τομείς όπως η ιατρική, η κυβερνοασφάλεια, η τραπεζική, η ενέργεια καθώς και στον τομέα της αγοράς ακινήτων (Topal, 2017).

2.1.2 Ορισμός μηχανικής μάθησης

Από την αρχή της εμφάνισής της, έχουν δοθεί πολλαπλοί ορισμοί για την έννοια της μηχανικής μάθησης. Με μία απλουστευμένη προσέγγιση, η μηχανική μάθηση αποτελεί κομμάτι της τεχνητής νοημοσύνης και της επιστήμης των υπολογιστών που επικεντρώνεται στη χρήση δεδομένων μέσω αλγορίθμων με σκοπό να επιτυγχάνει σε σημαντικό βαθμό τον τρόπο εκμάθησης του ανθρώπου, βελτιώνοντας σταδιακά την ακρίβειά του.

Η μηχανική μάθηση είναι ένα σημαντικό στοιχείο του αναπτυσσόμενου τομέα της επιστήμης των δεδομένων. Μέσω της χρήσης στατιστικών μεθόδων, οι αλγόριθμοι εκπαιδεύονται για να κάνουν ταξινομήσεις ή προβλέψεις και να αποκαλύπτουν βασικές πληροφορίες σε έργα εξόρυξης δεδομένων. Αυτές οι γνώσεις οδηγούν στη λήψη αποφάσεων στο πλαίσιο εφαρμογών και επιχειρήσεων, επηρεάζοντας βασικές μετρήσεις ανάπτυξης. (IBM, 2020).

2.1.3 Τύποι μηχανικής μάθησης

Οι αλγόριθμοι μηχανικής μάθησης οργανώνονται με βάση το επιθυμητό αποτέλεσμα του αλγορίθμου. Οι κύριοι τύποι μηχανικής μάθησης αποτελούνται από:

1. την εποπτευόμενη μηχανική μάθηση,
2. την μη εποπτευόμενη μηχανική μάθηση,
3. την ημι-εποπτευόμενη μηχανική μάθηση,
4. την ενισχυτική μηχανική μάθηση (NVIDIA, 2023).

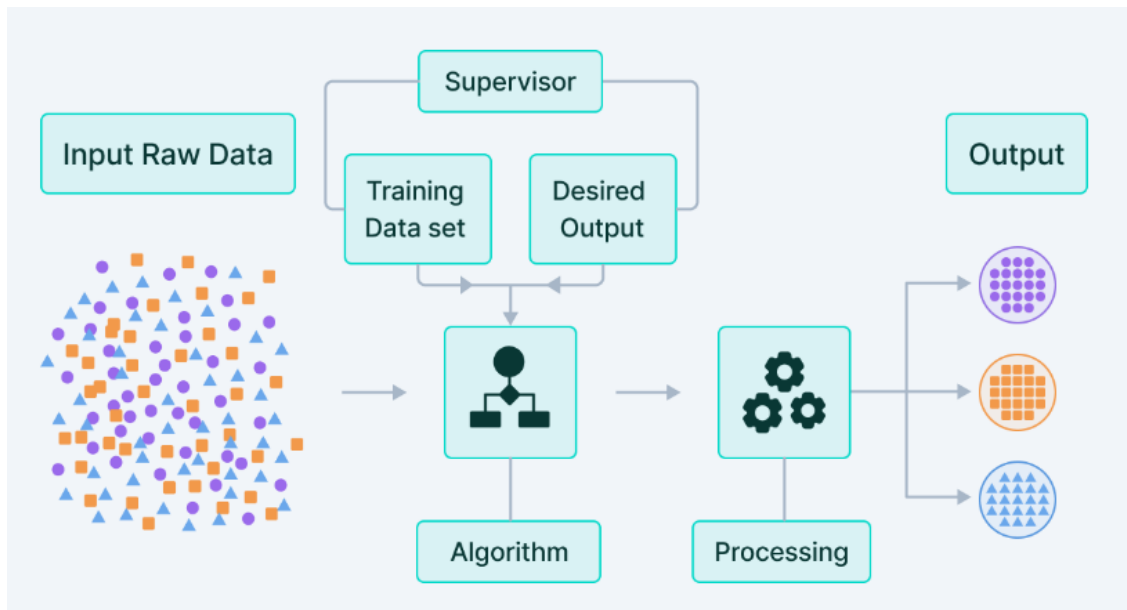
Εποπτευόμενη μηχανική μάθηση

Η εποπτευόμενη μηχανική μάθηση, ορίζεται από τη χρήση συνόλων δεδομένων για την εκπαίδευση αλγορίθμων με σκοπό την ταξινόμηση δεδομένων ή την ακριβή πρόβλεψη των αποτελεσμάτων (IBM, 2020). Υπάρχουν δύο υποκατηγορίες εποπτευόμενης μάθησης: η ταξινόμηση και η παλινδρόμηση.

1. **Ταξινόμηση:** Αφορά την κατανομή των δεδομένων στις κατηγορίες που ορίζονται στο σύνολό τους, σύμφωνα με τα συγκεκριμένα χαρακτηριστικά τους.
2. **Παλινδρόμηση:** Ορίζεται ως η πρόβλεψη ή εξαγωγή συμπερασμάτων για συγκεκριμένα χαρακτηριστικά των δεδομένων με βάση ορισμένα από αυτά.

Στον πραγματικό κόσμο, η εποπτευόμενη μάθηση μπορεί να παρομοιαστεί με μία εξέταση ή άσκηση υπό επίβλεψη, στην οποία κάποιος πρέπει να κρίνει το αποτέλεσμα ως ορθό ή λανθασμένο. Η εποπτευόμενη μάθηση ωφελεί τους οργανισμούς στο επίπεδο επίλυσης πολλών πραγματικών προβλημάτων σε κλίμακα, όπως η ταξινόμηση των ανεπιθύμητων μηνυμάτων ηλεκτρονικού ταχυδρομείου σε ξεχωριστό φάκελο στα συνολικά εισερχόμενα μηνύματα. Ορισμένες μέθοδοι που χρησιμοποιούνται στην εποπτευόμενη μάθηση περιλαμβάνουν τα νευρωνικά δίκτυα, τις απλές bayes, τη

γραμμική παλινδρόμηση, την λογιστική παλινδρόμηση, το τυχαίο δάσος και τη μηχανή διανυσμάτων υποστήριξης.




Εικόνα 2. Τρόπος λειτουργίας αλγόριθμου εποπτευόμενης μηχανικής μάθησης

https://www.researchgate.net/figure/Working-flow-of-SML-process-in-healthcare_fig1_373514707

Μη εποπτευόμενη μηχανική μάθηση

Στην μη εποπτευόμενη μηχανική μάθηση τα δεδομένα εξόδου δεν δίνονται στον αλγόριθμο, ενώ εκείνος σχεδιάζεται για να δώσει απαντήσεις σε ερωτήματα για τα οποία δεν υπάρχει δυνατότητα να δώσουν απαντήσεις οι αναλυτές. Η διαδικασία πραγματοποιείται χρησιμοποιώντας τις σχέσεις και τις συνδέσεις μεταξύ των δεδομένων, αφού αυτά έχουν επισημανθεί. Τα μοντέλα μη εποπτευόμενης μηχανικής μάθησης δεν έχουν δεδομένα εκπαίδευσης, ενώ καλούνται να εντοπίσουν μοτίβα και πιθανές συσχετίσεις μεταξύ των δεδομένων.




Εικόνα 3. Τρόπος διεξαγωγής μη εποπτευόμενης μηχανικής μάθησης

<https://medium.com/analytics-vidhya/up-detr-unsupervised-pre-training-for-object-detection-with-transformers-a-review-c4b996e12a9c>

Συγκρίνοντας την εποπτευόμενη με την μη εποπτευόμενη μηχανική μάθηση, στην πρώτη τα μοντέλα αναλύουν τα εισαγόμενα δεδομένα, στα οποία έχουν ήδη δοθεί τιμές πρόβλεψης, προκειμένου να δοθούν μέσω αυτών προκαθορισμένα αποτελέσματα. Στην μη εποπτευόμενη μηχανική μάθηση δεν υπάρχουν προκαθορισμένες τιμές πρόβλεψης και ανάλογα με τα δεδομένα που δίνονται, ο αλγόριθμος είναι πιθανό να πραγματοποιήσει κάποια μέθοδο από τις παρακάτω:

- ομαδοποίηση (αναζήτηση δεδομένων που είναι παρόμοια μεταξύ τους),
- ανίχνευση ανωμαλιών (επισήμανση ακραίων στοιχείων σε ένα σύνολο δεδομένων),
- συσχέτιση (πρόβλεψη συσχέτισης χαρακτηριστικών).



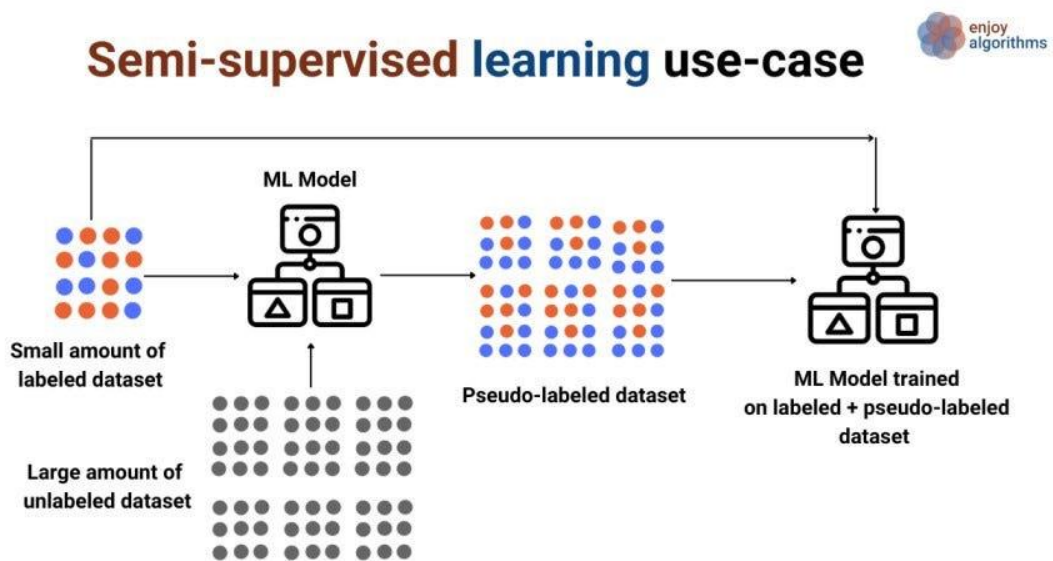
Εικόνα 4. Παραδείγματα εποπτευόμενης και μη εποπτευόμενης μηχανικής μάθησης

http://users.ics.aalto.fi/harri/thesis/valpola_thesis/node34.html

Ημι-εποπτευόμενη μηχανική μάθηση

Η ημι-εποπτευόμενη μηχανική μάθηση αποτελεί έναν συνδυασμό των δύο προηγούμενων τύπων μηχανικής μάθησης.

Στην περίπτωση αυτή, το σύνολο δεδομένων περιέχει δεδομένα τόσο προ-επισημασμένα όσο και μη. Η εφαρμογή της εστιάζει σε περιπτώσεις όπου η προ-επίσημανση των δεδομένων αποτελεί μία χρονοβόρα διαδικασία.



Εικόνα 5. Παράδειγμα ημι-εποπτευόμενης μηχανικής μάθησης

https://medium.com/@gayatri_sharma/a-gentle-introduction-to-semi-supervised-learning-7afa5539beea

Η ημι-εποπτευόμενη μηχανική μάθηση επεκτείνεται σε τομείς, όπως η εξόρυξη χωρικών δεδομένων, η επεξεργασία φυσικής γλώσσας, ο μεγάλος όγκος συνόλων δεδομένων όπως η δικτυακή κίνηση, η αναγνώριση ομιλίας κ.α. Οι περισσότερες εφαρμογές εστιάζουν στην ακρίβεια ως μία από τις μετρικές για τον προσδιορισμό της απόδοσης του αλγορίθμου. Όμως, η ακρίβεια μπορεί να μην επαρκεί για την ταξινόμηση δεδομένων με χρήση ημι-εποπτευόμενης μηχανικής μάθησης. Περαιτέρω, πρέπει να εστιάσουμε και σε άλλες μετρικές όπως η ανάκληση και η ακρίβεια (Pulabaigari & Reddy YC, 2018).

Σε τέτοιες περιπτώσεις, τα μη προ-επισημασμένα δεδομένα, τα οποία είναι ανεπαρκή, χρησιμοποιούνται για την εξαγωγή πληροφοριών σχετικά με αυτά. Αυτή η μέθοδος

ονομάζεται εποπτευόμενη μηχανική μάθηση. Η διαφορά μεταξύ της ημι-εποπτευόμενης μηχανικής μάθησης και της εποπτευόμενης μηχανικής μάθησης είναι το σύνολο δεδομένων με ετικέτες. Στην εποπτευόμενη μηχανική μάθηση, τα προ-επισημασμένα δεδομένα είναι περισσότερα από τα δεδομένα προς πρόβλεψη. Αντίθετα, στην ημι-εποπτευόμενη μηχανική μάθηση, τα δεδομένα με ετικέτες είναι λιγότερα από τα δεδομένα προς πρόβλεψη (Kizilkaya ve Oğuzlar, 2018).

2.1.5 Εφαρμογές της μηχανικής μάθησης

Τα τελευταία χρόνια, η μηχανική μάθηση έχει αναδειχθεί σε μετασχηματιστική δύναμη σε μια πληθώρα κλάδων, φέρνοντας επανάσταση στον τρόπο με τον οποίο προσεγγίζουμε την επίλυση προβλημάτων και τη λήψη αποφάσεων. Από την ιατρική έως τα χρηματοοικονομικά, το ηλεκτρονικό εμπόριο και τη γεωργία, η εφαρμογή της μηχανικής μάθησης αναδιαμορφώνει τις παραδοσιακές πρακτικές και ξεκλειδώνει πρωτοφανείς δυνατότητες. Αξιοποιώντας τη δύναμη των αλγορίθμων για την ανάλυση μεγάλων συνόλων δεδομένων, την εξαγωγή μοτίβων και την πραγματοποίηση προβλέψεων, οι επιχειρήσεις και οι οργανισμοί αποκτούν πολύτιμες δυνατότητες, ενισχύουν την αποδοτικότητα και παρέχουν πιο εξατομικευμένες εμπειρίες.

Στον παρακάτω πίνακα γίνεται παράθεση δημοφιλών πρακτικών μηχανικής μάθησης με παραδείγματα εφαρμογών σε διάφορους τομείς, στην πράξη.

| Εφαρμογές Μηχανικής Μάθησης | Περιγραφή |
|---------------------------------------|--|
| Αναγνώριση & Ανάλυση Προφορικού Λόγου | Τα πιο εξελιγμένα συστήματα αναγνώρισης ομιλίας στις μέρες μας χρησιμοποιούν αλγόριθμους μηχανικής μάθησης σε ορισμένες μορφές. Για παράδειγμα, το σύστημα Sphinx μαθαίνει και καταγράφει ήχους και λέξεις από ομιλίες. Διάφορες μεθοδολογίες εκμάθησης νευρωνικών δικτύων για την ερμηνεία κρυφών μοντέλων Markov είναι επίσης εξαιρετικά αποτελεσματικές για την αυτόματη προσαρμογή ήχων, λεξικών και θορύβων κ.λπ. |
| Ρομποτική & Τεχνητή Νοημοσύνη | Η μηχανική μάθηση θεωρείται ως η πιο βέλτιστη μέθοδος επίλυσης προβλημάτων. Η ενσωμάτωση βασικών γνώσεων και δεδομένων εκπαίδευσης σε μοντέλα μηχανικής μάθησης, δίνουν τα εφόδια στην επιστήμη της ρομποτικής και της τεχνητής νοημοσύνης σε επίπεδα επόμενης γενιάς. |
| | |

| | |
|---|---|
| <p>Μέθοδοι Bayes</p> | <p>Το θεώρημα του Bayes είναι μια από τις πιο δημοφιλείς μεθόδους για τον υπολογισμό των υπό συνθήκη πιθανοτήτων δεδομένου του συνόλου των υποθέσεων. Μπορεί να χρησιμοποιηθεί για την επίλυση σύνθετων προβλημάτων επιστήμης δεδομένων και ανάλυσης με την ενσωμάτωση διαφόρων μοντέλων και αλγορίθμων μηχανικής μάθησης. Ορισμένα παραδείγματα προβλημάτων του πραγματικού κόσμου που μπορούν να επιλυθούν με τη χρήση μεθόδων Bayes, όπως:</p> <ul style="list-style-type: none"> • Προτάσεις στο Netflix • Αυτόματη ορθογραφική διόρθωση • Ανίχνευση απάτης με πιστωτικές κάρτες • Ταξινόμηση σελίδων μηχανών αναζήτησης (π.χ. Google) • Αναγνώριση βιομετρικών στοιχείων • Πρόβλεψη κλιματικών αλλαγών • Συστήματα διαπραγμάτευσης μετοχών |
| <p>Ψηφιακά μέσα & μέσα κοινωνικής δικτύωσης</p> | <p>Οι ταξινομητές Naïve Bayes έχουν εφαρμοστεί με επιτυχία τόσο σε μηχανές αναζήτησης όσο και στα ψηφιακά μέσα κοινωνικής δικτύωσης.</p> <ul style="list-style-type: none"> • Το Facebook χρησιμοποιεί το Naïve Bayes για να αναλύσει τις ενημερώσεις κατάστασης που εκφράζουν θετικά και αρνητικά συναισθήματα. • Κατηγοριοποίηση εγγράφων: Η Google χρησιμοποιεί τον αλγόριθμο Naïve Bayes για την κατηγοριοποίηση εγγράφων. • Η ομαδοποίηση K-means χρησιμοποιείται από μηχανές αναζήτησης όπως η Google και η Yahoo για την ομαδοποίηση ιστοσελίδων με βάση την ομοιότητα. • Το Apriori χρησιμοποιείται από ιστότοπους όπως το Amazon ή το Flipkart για να συστήσει ποια αντικείμενα αγοράζονται συχνά μαζί. • Μια άλλη κοινή εφαρμογή του Apriori είναι η αυτόματη συμπλήρωση της Google. Όταν ένα άτομο πληκτρολογεί μια λέξη, η μηχανή αναζήτησης της Google αναζητά άλλες σχετικές λέξεις που ταιριάζουν με τη λέξη που πληκτρολογήθηκε προηγουμένως. • Η ανάλυση συναισθήματος σε μέσα κοινωνικής δικτύωσης είναι μια τυπική μέθοδος μηχανικής μάθησης που χρησιμοποιείται σε αυτές τις περιπτώσεις. |

| | |
|---|---|
| <p style="text-align: center;">Ιατρική</p> | <p>Το σύστημα πρόβλεψης TRISS (Trauma & Injury Severity Score), χρησιμοποιείται ευρέως για την πρόβλεψη της θνησιμότητας σε τραυματισμένους ασθενείς και αναπτύχθηκε αρχικά από τους Boyd & Al. χρησιμοποιώντας λογιστική παλινδρόμηση.</p> <p>Ποικίλες ιατρικές κλίμακες εφαρμόζονται για την εκτίμηση της σοβαρότητας ενός ασθενούς, οι οποίες έχουν αναπτυχθεί με τη χρήση λογιστικής παλινδρόμησης.</p> |
| <p style="text-align: center;">Φιλτράρισμα Μηνυμάτων Ηλεκτρονικού Ταχυδρομείου (ανεπιθύμητη αλληλογραφία)</p> | <p>Όταν γίνεται λήψη νέων μηνυμάτων ηλεκτρονικού ταχυδρομείου στα εισερχόμενα, το μοντέλο που βασίζεται στη μηχανική μάθηση αναζητά, συγκρίνει και βασίζεται σε προηγούμενα μηνύματα spam. Εάν τα νέα μηνύματα ηλεκτρονικού ταχυδρομείου ταιριάζουν με κάποιο από αυτά, θα επισημανθούν ως ανεπιθύμητα. Εάν όχι, θα μεταφερθούν στα εισερχόμενα του χρήστη. Αυτό είναι ένα παράδειγμα του τρόπου με τον οποίο η μηχανική μάθηση μπορεί να χρησιμοποιηθεί για το φιλτράρισμα των ανεπιθύμητων μηνυμάτων. Αρχικά, το μοντέλο θα απομνημονεύσει απλώς όλα τα μηνύματα που ο χρήστης έχει ταξινομήσει ως ανεπιθύμητα.</p> |

Πίνακας 1: Εφαρμογές Μηχανικής Μάθησης

Η διάχυτη επιρροή της μηχανικής μάθησης εκτείνεται πέρα από τις τεχνικές της δυνατότητες, διαπερνώντας σχεδόν κάθε πτυχή του σύγχρονου κόσμου μας. Καθώς παρατηρείται η αξιοσημείωτη επίδρασή της στις διαγνώσεις θεμάτων Ιατρικής, στις οικονομικές προβλέψεις, στις εξατομικευμένες συστάσεις και όχι μόνο, γίνεται φανερό ότι η μηχανική μάθηση δεν είναι απλώς ένα τεχνολογικό εργαλείο αλλά ένας καταλύτης για βαθύτατο κοινωνικό μετασχηματισμό.

Η συνεχής εξέλιξη της μηχανικής μάθησης υπόσχεται να συνεχίσει να ανοίγει νέους δρόμους, να επιλύει σύνθετες προκλήσεις και να επαναπροσδιορίζει τα όρια του εφικτού. Με το πέρασμα των εξελίξεων, η ανάλυση των στις ηθικών αντικτύπων ενέχει ζωτικής σημασίας, εξασφαλίζοντας την υπεύθυνη και αμερόληπτη ανάπτυξη αυτών των τεχνολογιών.

2.2.1 Ιστορική Αναδρομή στην εξέλιξη της ψηφιακής τραπεζικής

Η έλευση των ψηφιακών τεχνολογιών στα χρηματοπιστωτικά ιδρύματα έθεσε τα θεμέλια στον ψηφιακό μετασχηματισμό τους. Από τις στοιχειώδεις απαρχές της ψηφιακής τραπεζικής έως την εποχή των έξυπνων εφαρμογών για κινητά και των καινοτομιών FinTech, η εξέλιξη αντανακλά όχι μόνο στις τεχνολογικές εξελίξεις αλλά και στις μεταβαλλόμενες προσδοκίες και συμπεριφορές των πελατών. Η εμφάνιση της ψηφιακής τραπεζικής υπερβαίνει την απλή τεχνολογική πρόοδο, αποκαλύπτοντας μια ανάγκη προσαρμογής και συνεχούς αναζήτησης για οικονομική ένταξη και αποτελεσματικότητα σε έναν ολοένα και πιο διασυνδεδεμένο ψηφιακό κόσμο.

Ο τραπεζική ηγήθηκε της πρώιμης εμπορικής υιοθέτησης των ψηφιακών μέσων τη δεκαετία του 1960, με την εισαγωγή καινοτόμων εφευρέσεων για την εποχή, όπως αυτές των πιστωτικών καρτών και των ATM, να διατίθενται για πρώτη φορά στο κοινό τη δεκαετία του 1970. Οι πρώτες ψηφιακές συναλλαγές μέσω διαδικτύου πραγματοποιήθηκαν τη δεκαετία του 1980 με τη μετάβαση στην ηλεκτρονική τραπεζική και το internet banking να εκτυλίσσεται τη δεκαετία του 1990 (Gail Kelly, 2014).

Στα τέλη της ίδιας δεκαετίας ξεκίνησε η υιοθέτηση μίας καινούργιας τραπεζικής εμπειρίας μέσω κινητών τηλεφώνων, η οποία αναφερόταν ως τραπεζική μέσω SMS (SMS banking) και είχε ως κύρια λειτουργία την επικοινωνία μεταξύ τράπεζας και πελάτη για ενημερωτικούς κυρίως σκοπούς.

Σύμφωνα με την εταιρία παροχής ψηφιακών οικονομικών υπηρεσιών Finanteq, η πρώτη τραπεζική εφαρμογή για κινητά τηλέφωνα διατέθηκε στο κοινό από την Τράπεζα της Σκωτίας το 2007, ωστόσο με περιορισμένες δυνατότητες.

Το 2008 η αυστραλιανή τράπεζα Westpac διέθεσε στο κοινό την πρώτη εφαρμογή mobile banking για smartphone στην Αυστραλία, ενώ χρειάστηκαν λιγότερο από 30 μήνες και μικρή προώθηση της εφαρμογής για να υιοθετήσουν τη νέα τεχνολογία 1 εκατομμύριο πελάτες. Έκτοτε, τα ποσοστά υιοθέτησης από τους πελάτες έχουν

εκτοξευθεί στα ύψη, ενώ πάνω από το μισό του συνόλου των συναλλαγών των πελατών της Westpac πραγματοποιούνται μέσω κινητών τηλεφώνων.

Έκτοτε, η ενσωμάτωση των ψηφιακών υπηρεσιών στα χρηματοπιστωτικά ιδρύματα σε παγκόσμιο επίπεδο αυξήθηκε ραγδαία με νέες και καινοτόμες λύσεις στην ψηφιοποίηση της εμπειρίας του πελάτη να εμφανίζονται στο προσκήνιο.

Η άνοδος των νεοσύστατων επιχειρήσεων FinTech τις τελευταίες δύο δεκαετίες αποτέλεσε επιπρόσθετη κινητήρια δύναμη πίσω από την ψηφιακή τραπεζική επανάσταση. Ο όρος προέρχεται από τις λέξεις Financial Technology και πρόκειται για ευέλικτες και καινοτόμες εταιρείες, οι οποίες εισήγαγαν πληθώρα καινοτόμων χρηματοπιστωτικών υπηρεσιών, αμφισβητώντας τα καθιερωμένα πρότυπα και ενισχύοντας τον ανταγωνισμό.

Οι πλατφόρμες δανεισμού peer-to-peer, τα chatbots και οι αυτοματοποιημένες λύσεις πληρωμών σε ψηφιακή μορφή έγιναν αναπόσπαστα στοιχεία στις προσφερόμενες υπηρεσίες των τραπεζών. Στη συνέχεια εμφανίστηκαν στο προσκήνιο η τεχνολογία blockchain και τα κρυπτονομίσματα, με επιτομή την άνοδο του κρυπτονομίσματος Bitcoin, εισάγοντας εναλλακτικές λύσεις πληρωμών που αμφισβήτησαν τις παραδοσιακές έννοιες των παραδοσιακών νομισμάτων και των συστημάτων πληρωμών.

Επιπλέον, με την εμφάνιση των τεχνολογιών αυτών δόθηκε όλο και μεγαλύτερη έμφαση στην εμπειρία του χρήστη και την εξατομίκευση. Η τεχνητή νοημοσύνη και οι αλγόριθμοι μηχανικής μάθησης έχουν αξιοποιηθεί για την ανάλυση της συμπεριφοράς των πελατών, επιτρέποντας στις τράπεζες να προσφέρουν εξατομικευμένες υπηρεσίες. Η ενσωμάτωση νέων μεθόδων ταυτοποίησης των πελατών όπως τα βιομετρικά στοιχεία για τον έλεγχο ταυτότητας στην ολοκλήρωση ψηφιακών συναλλαγών, το δακτυλικό αποτύπωμα και η αναγνώριση προσώπου (Face ID), προσφέρουν επιπρόσθετη ασφάλεια μετατρέποντας τη ψηφιακή τραπεζική πιο ασφαλή από ποτέ.

Φτάνοντας στο σήμερα, η πορεία από την ψηφιακή τραπεζική στο περίπλοκο οικοσύστημα των καινοτομιών εταιριών FinTech υπογραμμίζει τη δυναμική φύση του

χρηματοπιστωτικού τομέα και τη συνεχή επιδίωξη της αποτελεσματικότητας, της προσβασιμότητας και της πελατοκεντρικότητας στην ψηφιακή εποχή.

2.2.2 Ορισμός της ψηφιακής τραπεζικής

Για την ψηφιακή τραπεζική έχουν δοθεί διάφοροι ορισμοί κατά καιρούς, λόγω της συνεχούς εξέλιξής της, οι οποίοι εστιάζουν σε διαφορετικά στοιχεία

Σύμφωνα με την εταιρία χρηματοοικονομικών υπηρεσιών SDK Finance, η ψηφιακή τραπεζική αποτελεί την ψηφιοποίηση των προσφερόμενων παραδοσιακών τραπεζικών προϊόντων, διαδικασιών και δραστηριοτήτων για την εξυπηρέτηση των πελατών μέσω πολλαπλών ψηφιακών καναλιών (What is digital banking?, 2023).

Ενδεικτικά, η ψηφιακή τραπεζική περιλαμβάνει τις ακόλουθες λειτουργικότητες και υπηρεσίες, οι οποίες είναι διαθέσιμες οποιαδήποτε χρονική στιγμή μέσω πολλαπλών ψηφιακών μέσων όπως τα ATM, ο υπολογιστής, τα κινητά τηλέφωνα και περαιτέρω συμβατές έξυπνες συσκευές, χωρίς να απαιτείται η παρουσία του πελάτη στο τραπεζικό κατάστημα:

- Λήψη ιστορικού τραπεζικών κινήσεων
- Ανάλυση μετρητών
- Μεταφορά χρημάτων
- Απόκτηση νέων και διαχείριση υφιστάμενων τραπεζικών προϊόντων
- Πληρωμές λογαριασμών σε οργανισμούς
- Ενημέρωση προσωπικών στοιχείων πελάτη

Με τη διάθεση των παραπάνω στο τραπεζικό κοινό, η ψηφιακή τραπεζική καθιστά όλες τις παραδοσιακές υπηρεσίες ευκολότερα προσβάσιμες, κατανοητές και διαχειρίσιμες.

Με απλουστευμένα λόγια, η ψηφιακή τραπεζική εστιάζει στην αλληλεπίδραση μεταξύ πελάτη και τράπεζας, καθώς είναι ένας τομέας που διέπεται από την καινοτομία στις

χρηματοπιστωτικές υπηρεσίες με αλληλένδετο τον τομέα της πληροφορικής και της τεχνολογίας (Volosovych & Baraniuk 2020).

Τον Δεκέμβριο 2022, σε έρευνα των Wahyu Avianto, και Wahyu Ari Wibowo αναφέρεται ότι η ψηφιακή τραπεζική συνδέεται άμεσα με τον ψηφιακό μετασχηματισμό των τραπεζών. Συνεπώς πρέπει να οριστεί η έννοια του ψηφιακού μετασχηματισμού στα χρηματοπιστωτικά ιδρύματα, η οποία θεωρείται ως η αιχμή της τεχνολογικής επανάστασης και χαρακτηρίζεται από την ταχεία ανάπτυξη και καινοτομία των ψηφιακών υπηρεσιών, τον εκθετικό ρυθμό της αλλαγής που μεταβάλλουν τις συμβατικές τραπεζικές πρακτικές (Krasonikolakis et al., 2020).

Η βασική ιδέα της ψηφιακής τραπεζικής περιλαμβάνει την ολοκληρωμένη διαχείριση των οικονομικών των πελατών των τραπεζών μέσω ψηφιακών μέσων, εξαλείφοντας την ανάγκη επίσκεψής τους σε φυσικά καταστήματα.

2.2.3 Τεχνολογικά ορόσημα στην ψηφιακή τραπεζική

Η ψηφιακή τραπεζική έχει γνωρίσει σημαντικά τεχνολογικά ορόσημα τα οποία έχουν μεταμορφώσει τον τρόπο παροχής χρηματοπιστωτικών υπηρεσιών. Στον παρακάτω πίνακα αποτυπώνονται σημαντικές εξελίξεις, από την εμφάνισή της έως σήμερα:

| Χρονολογία | Τεχνολογικό Ορόσημο |
|-------------------|--|
| 1960-1970 | Οι τράπεζες Barclays, Chemical & Lloyds Bank διέθεσαν τα πρώτα ATM προς χρήση σε διάφορες πόλεις της Αμερικής. |
| 1980-1990 | Η πιστωτική ένωση Stanford Federal Credit Union προσέφερε για πρώτη φορά τραπεζικές υπηρεσίες μέσω τηλεφώνου, εισάγοντας την ευκαιρία σε άλλες τράπεζες στην υιοθέτηση της συγκεκριμένης πρακτικής. |
| 1990-2000 | Η πρώτη εφαρμογή της ψηφιακής τραπεζική μέσω διαδικτύου πραγματοποιήθηκε το 1995 από την Presidential Bank εδραιώνοντας το διαδίκτυο ως βασικό μέσο για την παροχή τραπεζικών υπηρεσιών. |
| 2000-2010 | <p>Το 2008, η αυστραλιανή τράπεζα Westpac λάνσαρε την πρώτη εφαρμογή mobile banking για smartphone στην Αυστραλία.</p> <p>Το 2009, η USAA Federal Savings Bank εισήγαγε την πρώτη υπηρεσία κατάθεσης επιταγών μέσω κινητού τηλεφώνου, επιτρέποντας στους πελάτες να φωτογραφίζουν μια επιταγή και να πιστώνεται αυτόματα στον λογαριασμό τους.</p> |

| | |
|--------------------|--|
| <p>2010-2020</p> | <p>Το 2014, η Tencent εγκαινίασε το WEBank και η Ant Financial το MYBank, συμβάλλοντας στην άνοδο της ψηφιακής τραπεζικής στην Κίνα.</p> <p>Μεταξύ του 2016 και του 2017, ψηφιακές τράπεζες όπως οι Monzo, Revolut, Atom και Starling ξεκίνησαν στο Ηνωμένο Βασίλειο, προσφέροντας καινοτόμες τραπεζικές εμπειρίες αποκλειστικά διαθέσιμες μέσω εφαρμογών σε κινητά τηλέφωνα και έξυπνες συσκευές.</p> |
| <p>2020-σήμερα</p> | <p>Το 2020, το Facebook εγκαινίασε τη Facebook Bank, προσφέροντας συγκρίσεις δαπανών σε όλα τα κοινωνικά δίκτυα, υποστηριζόμενες από το δικό του κρυπτονόμισμα.</p> |

Πίνακας 2: Τεχνολογικά Ορόσημα στην Ψηφιακή Τραπεζική

2.3 Τεχνητή Νοημοσύνη και Μηχανική Μάθηση στην Ψηφιακή Τραπεζική

2.3.1 Ενσωμάτωση της τεχνητής νοημοσύνης στην ψηφιακή τραπεζική

Η ενσωμάτωση της τεχνητής νοημοσύνης και της μηχανικής μάθησης σηματοδοτεί μια μετασχηματιστική φάση στην εξέλιξη της ψηφιακής τραπεζικής. Εμβαθύνοντας στον αντίκτυπο αυτών των τεχνολογιών, εξετάζοντας πώς έχουν επαναπροσδιορίσει τις εμπειρίες των πελατών, έχουν βελτιώσει τη λειτουργική αποτελεσματικότητα την καινοτομία στα χρηματοπιστωτικά ιδρύματα, θα εξετάσουμε πώς οι τράπεζες τις αξιοποιούν και τις ενσωματώνουν στις προσφερόμενες υπηρεσίες τους καθώς και στις εσωτερικές λειτουργίες τους.

2.3.2 Εξατομίκευση και εμπειρία πελατών

Η βελτίωση της εμπειρίας των πελατών αποτελεί από τα πιο σημαντικά ενδιαφέροντα στις τραπεζικές δραστηριότητες και στον τρόπο με τον οποίο οι τράπεζες προσφέρουν τις υπηρεσίες τους. Εφαρμόζοντας τεχνικές μηχανικής μάθησης και τεχνητής νοημοσύνης, πραγματοποιείται επαναπροσδιορισμός των αλληλεπιδράσεων με το πελατολόγιο, κατευθύνοντας τον χρηματοπιστωτικό κλάδο προς μία κατεύθυνση όπου η τραπεζική δεν θα είναι απλώς συναλλακτική αλλά μια βαθιά εξατομικευμένη και ανταποκρινόμενη εμπειρία.

Εξατομίκευση

Εστιάζοντας στην εξατομίκευση, διάφορες μέθοδοι συστάσεων προτείνονται για χρήση όχι μόνο στον τραπεζικό κλάδο αλλά και σε ευρύτερους κλάδους παροχής

υπηρεσιών όπως το ηλεκτρονικό εμπόριο, βασισμένοι σε κανόνες συνεργατικού φιλτραρίσματος με εφαρμογές μηχανικής μάθησης.

Στην πράξη, οι προτιμήσεις και το συναισθηματικό αντίκτυπο του δυνητικού χρήστη ή αγοραστή για τις διάφορες πτυχές μιας συγκεκριμένης υπηρεσίας έχουν μεγάλη σημασία για την αξία και για τη δημιουργία εξατομικευμένων συστάσεων.

Σε μια μελέτη που διεξήχθη το 2016, ένας βελτιωμένος αλγόριθμος της Slope One προτάθηκε για εφαρμογή στον τομέα των ψηφιακών πωλήσεων. Πρόκειται για έναν συνδυασμό αλγορίθμων για χρήση στο συνεργατικό φιλτράρισμα με βάση αξιολογήσεις του χρήστη, ο οποίος πρωτοεμφανίστηκε από τους Daniel Lemire και Anna Maclachlan το 2005. Σε άλλες έρευνες, παρατηρήθηκε ότι όταν μεγάλος αριθμός πελατών οι οποίοι επιλέγουν έναν μικρό αριθμό προϊόντων από μια συγκεκριμένη εταιρεία εμφανίζονται καλύτερα αποτελέσματα στην ομαδοποίησή τους και συνεπώς αυτό οδηγεί σε μία βελτιωμένη προσέγγιση για την αντιμετώπιση και αύξηση των πωλήσεων. Με βάση τη διαδικασία συν-ομαδοποίησης, εντοπίστηκαν ομάδες πελατών με παρόμοιες αγοραστικές συνήθειες και με αποτέλεσμα τη σύσταση προϊόντων που ήταν πιο πιθανό να αγοράσουν. Η έκφανση της διαδικασίας κατάγεται πράγματι αποτελεσματική στην παροχή λύσεων για το υποβληθέν προϊόν και στο ζήτημα της σύστασης των κατάλληλων προϊόντων (Meriem & Madani, 2019).

Στον τομέα της ψηφιακής τραπεζικής, οι αλγόριθμοι μηχανικής μάθησης αναλύουν τεράστια σύνολα δεδομένων, συμπεριλαμβανομένου του ιστορικού συναλλαγών, των μοτίβων δαπανών και των αλληλεπιδράσεων, σχολίων και αξιολογήσεων των χρηστών. Αυτή η βαθύτερη κατανόηση επιτρέπει στις τράπεζες να δημιουργούν εξαιρετικά εξατομικευμένες προσφερόμενες υπηρεσίες, προσαρμοσμένες στις ατομικές προτιμήσεις και ανάγκες των πελατών.

Οι μηχανές συστάσεων με τεχνητή νοημοσύνη προτείνουν δυναμικά προϊόντα και υπηρεσίες, προωθώντας μια πιο ελκυστική και εξατομικευμένη εμπειρία πελάτη. Είτε πρόκειται για προτάσεις επενδυτικών χαρτοφυλακίου, πιστωτικών καρτών, καταθετικών λογαριασμών ή αποταμιευτικών προγραμμάτων, η εφαρμογή των συγκεκριμένων τεχνικών μηχανικής μάθησης επιτρέπει την προσαρμογή των

υπηρεσιών και την εμφάνιση των κατάλληλων προτάσεων με γνώμονα τις συνεχώς μεταβαλλόμενες ανάγκες των πελατών.

Εικονικοί βοηθοί (Chatbots)

Μία άλλη πτυχή στην εξατομίκευση και στην βελτίωση της εμπειρίας του πελάτη στον τραπεζικό κλάδο είναι η εμφάνιση των Chatbots ως ευφυείς βοηθοί στην εξυπηρέτηση και επίλυση προβλημάτων. Η χρήση τους παρατηρείται συχνά σε βιομηχανίες με γνώμονα τον καταναλωτή, όπως οι τράπεζες, οι τηλεπικοινωνίες και το ηλεκτρονικό εμπόριο. Τα ευφυή Chatbots, που υποστηρίζονται από την επεξεργασία φυσικής γλώσσας και τη μηχανική μάθηση, παρέχουν υποστήριξη πελατών όλο το εικοσιτετράωρο και συνεχή ενημέρωση για τα οικονομικά τους όπως για την τρέχουσα κατάσταση χαρτοφυλακίου ή την έκβαση αιτήσεων για την απόκτηση ψηφιακών τραπεζικών προϊόντων. Επιπλέον έχουν τη δυνατότητα να ξεκινήσουν συμβάλλουν στην απλούστευση των διαδικασιών ως προς τη διενέργεια τραπεζικών συναλλαγών αφού παρέχουν οδηγίες για κοινές τραπεζικές εργασίες σε πραγματικό χρόνο.

Οι προηγμένοι αυτοί εικονικοί βοηθοί ξεπερνούν τις αυτοματοποιημένες απαντήσεις, εμπλέκονται σε διαδραστικές συζητήσεις και προσαρμόζουν το ύφος της επικοινωνίας τους ανάλογα με το πλαίσιο. Οι απαντήσεις προσαρμόζονται στο γλωσσικό επίπεδο του πελάτη (οικείο ή τυπικό), βασιζόμενες σε μία συνεχή ανάλυση της συνομιλίας μέσω των ανάλογων τεχνικών μηχανικής μάθησης. Αυτή η αλληλεπίδραση που ομοιάζεται σε σημαντικό βαθμό με την ανθρώπινη και ενισχύει τη δέσμευση στην ικανοποίηση των χρηστών.

Τα χρηματοπιστωτικά ιδρύματα επωφελούνται σε δεύτερο επίπεδο από την υιοθέτηση των εικονικών βοηθών στις ψηφιακές πλατφόρμες τους, καθώς επιλέγουν να αναλύσουν τις συνομιλίες που πραγματοποιούνται μεταξύ των Chatbots και των χρηστών, προκειμένου να αποκτήσουν πληροφορίες για τις προτιμήσεις του πελατολογίου τους και να προχωρήσουν σε περαιτέρω εξατομίκευση των υπηρεσιών και των προϊόντων τους.

Μια γερμανική τράπεζα ανέλυσε περισσότερες από ένα εκατομμύριο συνομιλίες για να αυξήσει τις εξατομικευμένες προτάσεις στο πελατολόγιό της. Η «Erica», το

προσφερόμενο Chatbot από μία από τις τράπεζες κολοσσούς της Αμερικής, Bank of America, αποτελεί από τα πιο επιτυχημένα και δημοφιλή παραδείγματα χρήσης εικονικών βοηθών στον παγκόσμιο τραπεζικό κλάδο με σημαντικό ποσοστό επιτυχίας στην βοήθεια επίλυσης τραπεζικών προβλημάτων (Meriem & Madani, 2019).

Μία άλλη αξιοσημείωτη αναφορά αποτελεί η διάθεση του εικονικού βοηθού SIA (SBI Intelligent Assistant), από την ινδική τράπεζα SBI το οποίο παρέχει βοήθεια στους πελάτες σε καθημερινές τραπεζικές εργασίες με εξέχουσα ομοιότητα του τρόπου των εκπροσώπων στα φυσικά καταστήματα των τραπεζών (Kaur, Sahdev & Sharma, 2020).

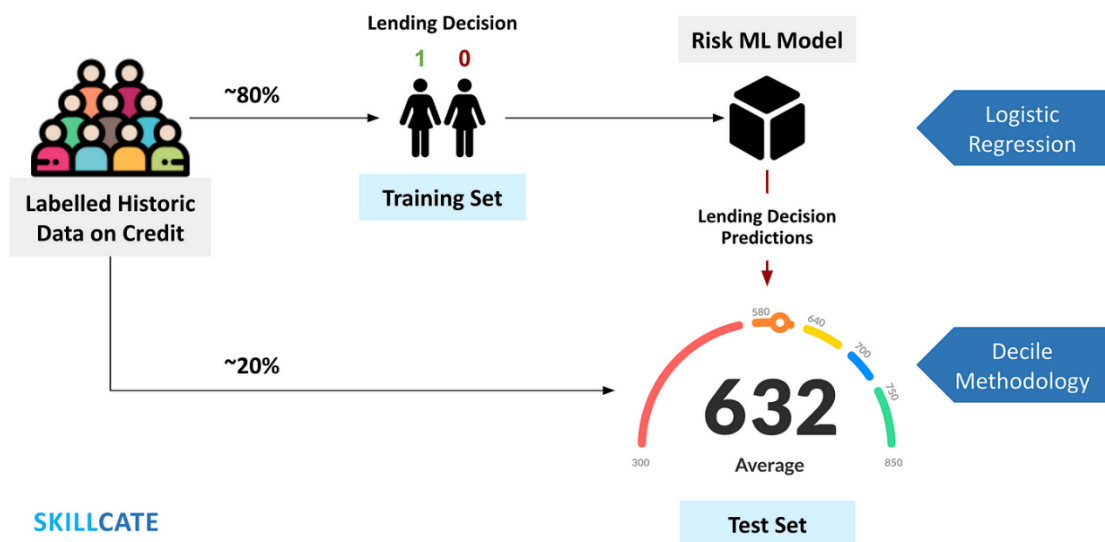
Credit scoring (πιστωτική βαθμολόγηση)

Ο τομέας της πιστωτικής βαθμολόγησης ειδικεύεται στην ανάπτυξη εμπειρικών μοντέλων για την υποστήριξη της λήψης αποφάσεων στο λιανικό εμπόριο και τον χρηματοπιστωτικό τομέα. Η πιστωτική βαθμολογία αποτελεί μια εκτίμηση βάσει μοντέλου για την αξιολόγηση πιθανότητας αναφορικά με έναν δυνητικό δανειολήπτη να παρουσιάσει κάποια ανεπιθύμητη συμπεριφορά στο μέλλον. Στην αξιολόγηση αιτήσεων για δάνεια ή πιστωτικά προϊόντα, για παράδειγμα, οι δανειστές χρησιμοποιούν μοντέλα πρόβλεψης, που ονομάζονται «κάρτες βαθμολογίας», για να εκτιμήσουν πόσο πιθανό είναι ένας αιτών να αθετήσει τις υποχρεώσεις αποπληρωμής. Μία από τις πιο ολοκληρωμένες συγκρίσεις ταξινομητών μέχρι σήμερα είναι η μελέτη συγκριτικής αξιολόγησης του Baesens. Ειδικότερα, οι ταξινομητές ετερογενών συνόλων παρουσιάζουν θετικά αποτελέσματα με εφαρμογή τεχνικών όπως Λογιστική Παλινδρόμηση, Ελάχιστη Απόλυτη Συρρίκνωση και τελεστής επιλογής (Lasso), δένδροειδής μάθηση όπως το Random Forest και Boosting strategies, νευρωνικά δίκτυα, μηχανές διανυσμάτων υποστήριξης.

Αξιοσημείωτο είναι το γεγονός ότι αν και όλα τα μοντέλα θα μπορούσαν να χρησιμοποιηθούν για την επίτευξη των ίδιων εργασιών, ο τρόπος εκτέλεσης των υπολογισμών δεν είναι πανομοιότυπος ενώ διαφέρουν και σε φιλοσοφικό επίπεδο. Στην λογιστική παλινδρόμηση, τα δεδομένα επιλέγονται έτσι ώστε να εντοπίζεται συσχέτιση, τα άλλα μοντέλα δεν είναι απαραίτητο να απαιτούν τη συσχέτιση. Μέθοδοι όπως το Random Forest έχουν τη δυνατότητα να καταγράφουν μη γραμμικές

εξαρτήσεις, ενώ τα νευρωνικά δίκτυα βασίζονται εξ ολοκλήρου στην οικοδόμηση και τη σύλληψη σχέσεων μεταξύ μεταβλητών (Meriem & Madani, 2019).

Οι τράπεζες χρησιμοποιούν συστήματα βασισμένα στις προαναφερθείσες τεχνικές μηχανικής μάθησης για να ενισχύσουν τη λήψη πιο τεκμηριωμένων, ασφαλέστερων και κερδοφόρων αποφάσεων για δάνεια και πιστώσεις. Επί του παρόντος, πολλές τράπεζες εξακολουθούν να περιορίζονται υπερβολικά στη χρήση των πιστωτικών βαθμολογιών, του πιστωτικού ιστορικού, των αναφορών πελατών και των τραπεζικών συναλλαγών για να καθορίσουν αν ένα άτομο ή μια επιχείρηση είναι αξιόχρεο ή όχι.



Εικόνα 6. Διάγραμμα εφαρμογής πιστωτικής αξιολόγησης με εφαρμογή Λογιστικής Παλινδρόμησης σε μοντέλο Μηχανικής Μάθησης

<https://medium.com/@skillcate/credit-scoring-project-using-logistic-regression-c1e88bd7cf25>

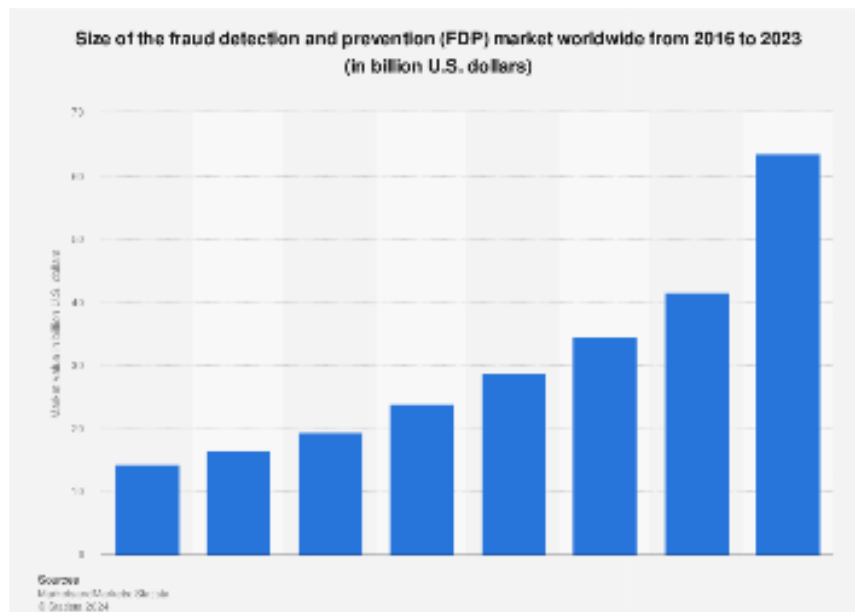
Εκτός από τη χρήση των διαθέσιμων δεδομένων, τα συστήματα λήψης αποφάσεων για δάνεια που βασίζονται στην τεχνητή νοημοσύνη και οι αλγόριθμοι μηχανικής μάθησης πραγματοποιούν διερεύνηση συμπεριφορικής συσχέτισης και μοτίβων με στόχο να καθορίσουν την πιθανότητα ενός πελάτη με περιορισμένο πιστωτικό ιστορικό να αποτελέσει έναν πιστωτικό πελάτη με θετικό πρόσημο καθώς και την εύρεση πελατολογίου του οποίου τα μοτίβα μπορεί να αυξήσουν την πιθανότητα αθέτησης.

Ανίχνευση ηλεκτρονικής απάτης και θέματα κυβερνοασφάλειας

Η καινοτόμος ενσωμάτωση της τεχνητής νοημοσύνης και της μηχανικής μάθησης στον τραπεζικό τομέα προσδίδει ασφάλεια και εγγύτητα, ενώ τον καθιστά επωφελή στην καταπολέμηση της νομιμοποίησης εσόδων από παράνομες δραστηριότητες.

Ένα σημαντικό ποσοστό του κλάδου εφαρμόζει τεχνικές μηχανικής μάθησης για τον εντοπισμό κάθε ύποπτης ή ασυνήθιστης συναλλαγής που μπορεί να σχετίζεται με παράνομες δραστηριότητες, ξέπλυμα χρήματος ή υποκλοπές ευαίσθητων προσωπικών δεδομένων. Η υιοθέτησή τους θωρακίζει τα συστήματα ασφαλείας των τραπεζών, των επιχειρήσεων και των ιδιωτών πελατών για την αποτροπή επιθέσεων στον κυβερνοχώρο.

Η τεχνητή νοημοσύνη είναι πολύ αποτελεσματική στην εύρεση μοτίβων σε πραγματικό χρόνο. Χρησιμοποιεί πρόσθετους δείκτες συμπεριφοράς για να εντοπίζει ύποπτη δραστηριότητα και να προσφέρει προτάσεις για τον περιορισμό του κινδύνου. Εκτός από τον χρηματοπιστωτικό τομέα, κλάδοι όπως το ηλεκτρονικό εμπόριο, η ανάλυση δεδομένων και η πληροφορική εφαρμόζουν τις συγκεκριμένες τεχνικές μηχανικής μάθησης για τον εντοπισμό ηλεκτρονικής απάτης. Για παράδειγμα, η Feedzai, μια εταιρεία επιστήμης δεδομένων, χρησιμοποιεί αλγόριθμους για τον εντοπισμό απάτης στο ηλεκτρονικό εμπόριο.



<https://www.statista.com/statistics/786778/worldwide-fraud-detection-and-prevention-market-size/>

Η ανίχνευση απάτης είναι ένας από τους τομείς που έχει λάβει τεράστια ώθηση στην παροχή ακριβών και εύστοχων αποτελεσμάτων με την παρέμβαση της τεχνητής νοημοσύνης. Η απάτη αποτελεί μείζον ζήτημα στον χρηματοπιστωτικό τομέα και η ανίχνευσή της είναι ένας από τους κρίσιμους τομείς όπου τα συστήματα τεχνητής νοημοσύνης έχουν σημειώσει ευρεία ανάπτυξη.

Ένα από τα δημοφιλέστερα παραδείγματα επιτυχημένης εφαρμογής τεχνικών ανάλυσης δεδομένων στον τραπεζικό κλάδο είναι το σύστημα ανίχνευσης ηλεκτρονικής απάτης FICO της Falcon, το οποίο βασίζεται σε ένα νευρωνικό δίκτυο για την ανάπτυξη εξελιγμένων συστημάτων τεχνητής νοημοσύνης, τα οποία έχουν εμπιστευτεί ψηφιακές τράπεζες και εταιρίες παροχής οικονομικών υπηρεσιών παγκόσμιου βεληνεκούς όπως η Venmo, η Cashapp και η FedNow (Kaur, Sahdev & Sharma, 2020).

Στον εγχώριο τραπεζικό κλάδο, μία από τις τέσσερις συστημικές τράπεζες, η Alpha Bank, χρησιμοποιεί το καινοτόμο σύστημα Actimize της εταιρίας ανάπτυξης AML εργαλείων NICE για την προστασία των ψηφιακών συναλλαγών από το ηλεκτρονικό έγκλημα.

Η ανίχνευση ηλεκτρονικής απάτης μέσω της τεχνητής νοημοσύνης έχει σημειώσει σημαντική πρόοδο τα τελευταία 20 χρόνια και αναμένεται να αναπτυχθεί περαιτέρω τόσο στον εγχώριο όσο και στον παγκόσμιο τραπεζικό κλάδο.

3. Ανάλυση του προβλήματος

Στον διαρκώς εξελισσόμενο τομέα των χρηματοπιστωτικών υπηρεσιών με εφαρμογή της τεχνητής νοημοσύνης και της μηχανικής μάθησης, η διασταύρωση της δεοντολογίας και της ηθικής σε συνδυασμό με τα δεδομένα και τους αλγορίθμους μηχανικής μάθησης αποτελεί κρίσιμο σημείο.

Καθώς τα χρηματοπιστωτικά ιδρύματα εμβαθύνουν στη χρήση της τεχνητής νοημοσύνη για τον εξορθολογισμό των λειτουργιών και τη βελτίωση της εμπειρίας των πελατών, αναδύονται οι εξής προβληματισμοί:

- ο ηθικός χειρισμός ευαίσθητων δεδομένων,
- η ηθική προσέγγιση και η μεροληψία στους αλγορίθμους μηχανικής μάθησης
- η τήρηση και η εφαρμογή του κανονιστικού πλαισίου
- η δικαιοσύνη, οι διακρίσεις και η διαφάνεια στην εκτέλεση των διαδικασιών.

Η παρούσα ενότητα ξεκινά μια διαφοροποιημένη διερεύνηση των άνωθι ηθικών προβληματισμών εστιάζοντας σε τρεις βασικούς άξονες:

- τα δεδομένα
- τους αλγόριθμους και τις τεχνικές μηχανικής μάθησης
- τους ανθρώπινους και εξωγενείς παράγοντες.

3.1 Πλαίσιο των δεδομένων και των αλγορίθμων μηχανικής μάθησης

Προτού διερευνηθούν οι σημαντικές ηθικές προκλήσεις και προβληματισμοί στην εφαρμογή της τεχνητής νοημοσύνης και της μηχανικής μάθησης στον χρηματοπιστωτικό κλάδο, θα εξετάσουμε το πλαίσιο, τα χαρακτηριστικά της χρήσης των δεδομένων και των αλγορίθμων αυτών.

3.1.1 Χαρακτηριστικά των δεδομένων

Για την ορθή εκπαίδευση των αλγορίθμων μηχανικής μάθησης, τα καταλληλά και σωστά δεδομένα αποτελούν βασική προϋπόθεση. Τα δεδομένα πρέπει να είναι ακριβή καθώς και να διέπονται από ποικιλία ώστε ο αλγόριθμος να είναι εφικτό να εντοπίσει μοτίβα και να εξάγει ορθά αποτελέσματα. Σε περίπτωση που υπάρχουν προβλήματα στα δεδομένα που εισάγονται σε έναν αλγόριθμο, θα υπάρξουν τότε τα αποτελέσματα εξόδου δεν θα πληρούν τα κριτήρια ορθότητας.

Τρεις πτυχές των δεδομένων που επηρεάζουν την απόδοση των αλγορίθμων είναι οι εξής:

- **Μέγεθος δείγματος δεδομένων:** Το μέγεθος δείγματος αποτελεί το σύνολο μεμονωμένων δεδομένων. Τα σύνολα δεδομένων τα οποία είναι ανεπαρκή σε όγκο είναι πιθανό να οδηγήσουν σε αποτυχία του αλγορίθμου. Η εμφάνιση προβλημάτων όπως η αδυναμία εντοπισμού μοτίβων να προκαλέσουν μεροληψία στα αποτελέσματα. Ορισμένες κατηγορίες αλγορίθμων απαιτούν σημαντικά μεγαλύτερο όγκο δεδομένων σε σχέση με άλλες.

Ένα κρίσιμο βήμα για την εκπαίδευση ενός αλγορίθμου, για παράδειγμα η χρήση του για την κατανόηση των σχέσεων μεταξύ ενός παράγοντα, όπως η αθέτηση δανείου, καθώς και ενός συνόλου χαρακτηριστικών, όπως συμπεριλαμβανομένου του πιστωτικού βαθμού, είναι ο διαχωρισμός του συνόλου δεδομένων σε

τουλάχιστον δύο μέρη. Συνήθως, οι αλγόριθμοι μαθαίνουν πρώτα σε ένα σύνολο δεδομένων εκπαίδευσης και στη συνέχεια τα αποτελέσματα εφαρμόζονται σε ένα σύνολο δεδομένων δοκιμής (test) για να ελεγχθεί η εγκυρότητά τους. Αυτή η προσέγγιση βοηθά στην αποφυγή διαφόρων δυσλειτουργιών που μπορεί να προκύψουν κατά τη δημιουργία μοντέλων, όπως η υπερπροσαρμογή, η οποία περιορίζει τη δυνατότητα γενίκευσής τους σε πραγματικές συνθήκες. Στο πλαίσιο του μεγέθους του δείγματος, ένα ικανοποιητικό μέγεθος του συνόλου των δεδομένων παίζει καταλυτικό ρόλο ώστε να δημιουργηθούν έγκυρα σύνολα δεδομένων εκπαίδευσης και δοκιμής.

- **Διαστάσεις δεδομένων (data dimensions):** Οι διαστάσεις δεδομένων είναι τα πεδία δεδομένων, γνωστά ως χαρακτηριστικά ή μεταβλητές (π.χ. ηλικία, φύλο, εισόδημα). Όταν το πεδίο των σχετικών χαρακτηριστικών είναι ελλιπές, η αλγοριθμική απόδοση δεν αποφέρει τα επιθυμητά αποτελέσματα.

Για παράδειγμα, εάν ο στόχος είναι να προβλεφθεί εάν ένας δυνητικός δανειολήπτης θα αθετήσει την αποπληρωμή μίας χορήγησης στεγαστικού δανείου, ένα εύρος πιθανών χαρακτηριστικών (π.χ. συναλλακτική ιστορικότητα, επίπεδα εισοδήματος, επίπεδα άλλων χρεών, επαγγελματική δραστηριότητα) θα ήταν απαραίτητο να καλυφθεί στα πεδία δεδομένων. Εάν ορισμένα χαρακτηριστικά υπολείπονται, όπως το εισόδημα ή το ιστορικό συναλλαγών, η ακρίβεια πρόβλεψης μπορεί να μειωθεί, ενδεχομένως σημαντικά. Ταυτόχρονα, μη συναφή χαρακτηριστικά μπορεί να μειώσουν την απόδοση του μοντέλου. Για παράδειγμα, η συμπερίληψη του εάν ένας πελάτης υποστηρίζει μια συγκεκριμένη ποδοσφαιρική ομάδα είναι απίθανο να προσθέσει στην ακρίβεια πρόβλεψης ενώ προσδίδει δυσκολίες στο στάδιο της εκπαίδευσης του αλγόριθμου. Αυτές οι μεταβλητές θα πρέπει να φιλτράρονται από τα δεδομένα χρησιμοποιώντας προσεγγίσεις επιλογής χαρακτηριστικών.

Εκτός από τα χαρακτηριστικά που υπάρχουν στα μη επεξεργασμένα δεδομένα, η χρήση της γνώσης του τομέα μπορεί να βοηθήσει στη δημιουργία νέων χαρακτηριστικών που προσθέτουν περαιτέρω στην ακρίβεια πρόβλεψης. Για

παράδειγμα, η χρήση των ταχυδρομικών κωδικών στα μη επεξεργασμένα δεδομένα θα μπορούσε να δημιουργήσει νέα χαρακτηριστικά, όπως τα "πλησιέστερες πόλεις" ή "απόσταση από το κέντρο της πόλης". Αυτή η διαδικασία αναφέρεται ως future engineering.

- **Ποιότητα δεδομένων:** Τα ανακριβή δεδομένα θα επηρεάσουν σημαντικά την απόδοση του εκάστοτε μοντέλου μηχανικής μάθησης. Τα σφάλματα συνήθως περιλαμβάνουν τυπογραφικά λάθη ή λανθασμένη επισήμανση πληροφοριών, ελλιπείς τιμές σε ορισμένα πεδία δεδομένων και δεδομένα σε ασυνεπείς μορφές (π.χ. ένας αριθμός αποθηκεύεται ως κείμενο). Για την προετοιμασία των δεδομένων πριν από τη μοντελοποίηση θα πρέπει να διεξάγονται κατάλληλες προσεγγίσεις καθαρισμού και υπολογισμού δεδομένων (Algorithmic bias and financial services, KPMG 2021).

3.1.2 Πηγές άντλησης δεδομένων

Οι πηγές άντλησης συνόλων δεδομένων μπορούν να χωριστούν σε δύο κύριες κατηγορίες (Algorithmic bias and financial services, KPMG 2021):

- **Εσωτερικά δεδομένα:** Πρόκειται για τα δεδομένα που δημιουργούνται και συλλέγονται εντός του οργανισμού.

Τα εσωτερικά δεδομένα διατηρούνται τόσο σε επίπεδο πελάτη όσο και σε επίπεδο οργανισμού. Ο συγκεκριμένος τύπος δεδομένων περιλαμβάνει δεδομένα back-office, όπως αρχείο ανθρώπινων πόρων, συντήρηση λειτουργιών, οικονομικά και δεδομένα διακυβέρνησης.

Σε δεύτερο επίπεδο, ένα ακόμη είδος δεδομένων είναι εκείνα που παράγονται απευθείας από τους πελάτες, όπως τα logs από τις εισόδους στις τραπεζικές πλατφόρμες, το ιστορικό ψηφιακών συναλλαγών ή το πώς ένας χρήστης ανταποκρίθηκε σε μια προωθητική ενέργεια. Τα εν λόγω δεδομένα μπορεί να έχουν δομημένη μορφή (π.χ. πίνακες αποθηκευμένοι σε βάσεις δεδομένων σε μορφή γραμμής ή στήλης), ημιδομημένα ή μη δομημένα (π.χ. έντυπα έγγραφα ή αρχεία κλήσεων).

- **Εξωτερικά δεδομένα:** Αποτελούν πληροφορίες που αντλούνται εκτός του περιβάλλοντος του οργανισμού.

Σε αυτή την κατηγορία εμπίπτουν τα **ανοικτά δεδομένα (open data)**, με κύριο χαρακτηριστικό τους την ελεύθερη πρόσβαση σε αυτά, καθώς και την ελεύθερη χρήση και τον διαμοιρασμό τους. Παραδείγματα αυτών των δεδομένων περιλαμβάνουν δημογραφικά στοιχεία, οικονομικές και κυβερνητικές πληροφορίες και φορολογικά στοιχεία. Τα δεδομένα αυτά συχνά διαθέτουν άδεια χρήσης, η οποία επιτρέπει τη χρήση, συμπεριλαμβανομένης της μετατροπής, της τροποποίησης, της επαναχρησιμοποίησης και της αναδιανομής των δεδομένων, ακόμη και εμπορικά. Για την πρόσβαση σε αυτά είναι πιθανό να επιβάλλονται χρεώσεις για την κάλυψη του κόστους δημιουργίας, συντήρησης και αναδημοσίευσής τους.

Τα **δεδομένα επί πληρωμή (paid data)**, τα οποία είναι διαθέσιμα από τρίτους παρόχους δεδομένων με κάποιο κόστος, όπως εταιρίες κινητής τηλεφωνίας, αποτελούν ακόμη μία υποκατηγορία των εξωτερικών δεδομένων.

Τα **κοινόχρηστα δεδομένα (trust-based shared data)**, αποτελούν δεδομένα που μοιράζονται μεταξύ οργανισμών. Για παράδειγμα, δέκα μεγάλες φαρμακευτικές εταιρείες, συμπεριλαμβανομένων των Johnson & Johnson, της AstraZeneca και της GSK, συμφώνησαν τον Ιούνιο του 2019 σε μια στρατηγική συνεργασίας κοινοποίησης δεδομένων, με σκοπό την εκπαίδευση των αλγόριθμων μηχανικής μάθησης, για την επιτάχυνση δημιουργίας νέων φαρμάκων.

Τα **κοινωνικά δεδομένα (social data)**, συλλέγονται από πλατφόρμες κοινωνικής δικτύωσης. Περιέχουν αναρτήσεις χρηστών και περαιτέρω σχετικές πληροφορίες, όπως ο αριθμός των κοινοποιήσεων, τα hashtags, τα σχόλια, καθώς και ο χρόνος της ανάρτησης. Η πρόσβαση στα κοινωνικά δεδομένα είναι συχνά ελεύθερη, αλλά ενδέχεται να απαιτούνται άδειες χρήσης που υπόκεινται σε πνευματικά δικαιώματα.

Έχοντας αναλύσει τις παραπάνω κατηγορίες συλλεγόμενων δεδομένων, στην παρακάτω εικόνα απεικονίζονται ενδεικτικά πηγές δεδομένων, τις οποίες χρησιμοποιούν οι χρηματοπιστωτικοί οργανισμοί για να συλλέξουν δεδομένα:



Εικόνα 8. Δείγμα πηγών δεδομένων που συλλέγονται από ψηφιακές τράπεζες

<https://www.womensworldbanking.org/insights/algorithmic-bias-financial-inclusion-and-gender/>

3.1.3 Χρήση των αλγόριθμων μηχανικής μάθησης στην τραπεζική

Στο Κεφάλαιο 2 παρατέθηκαν οι τομείς, οι υπηρεσίες και οι διαδικασίες στις οποίες οι τράπεζες ενσωματώνουν τεχνικές μηχανικής μάθησης. Πως όμως οι αλγόριθμοι των μοντέλων χρησιμοποιούνται στην πράξη και ωφελούν τα τραπεζικά ιδρύματα;

Οι αλγόριθμοι μηχανικής μάθησης εφαρμόζονται όλο και περισσότερο με τρόπους που ενημερώνουν τις επιχειρηματικές αποφάσεις και αυτοματοποιούν τις διαδικασίες των τραπεζών. Παρακάτω, διερευνούμε τρεις γενικές περιπτώσεις χρήσης τους (Algorithmic bias and financial services, KPMG 2021):

- **Αλγόριθμοι βελτίωσης λήψης αποφάσεων:** Οι αλγόριθμοι μπορούν να χρησιμοποιηθούν για την επεξεργασία πολύ μεγάλων συνόλων δεδομένων. Ως αποτέλεσμα, μπορούν να παρέχουν ποικίλα συμπεράσματα, ενημερώνοντας τις

αποφάσεις με τρόπους που χωρίς αυτή την επεξεργασία δεν θα ήταν δυνατές. Οι εφαρμογές τους στις χρηματοπιστωτικές υπηρεσίες περιλαμβάνουν την αξιολόγηση της πιστοληπτικής ικανότητας, τη στρατηγική της αγοράς, την τιμολόγηση και τη βελτιστοποίηση κεφαλαίου. Με την εφαρμογή τους είναι εφικτό να πραγματοποιηθεί αξιολόγηση πολλαπλών παραγόντων και μεταβλητών με αποτέλεσμα να διευκολύνουν τις διαδικασίες λήψης αποφάσεων.

- **Αλγόριθμοι μείωσης ανθρώπινης προσπάθειας:** Χρησιμοποιούνται σε συγκεκριμένες εργασίες όπως εκείνες που απαιτούν πολλαπλές επαναλήψεις. Η υιοθέτησή τους έχει σε πολλές περιπτώσεις ως αποτέλεσμα την εξοικονόμηση κόστους. Τεχνικές όπως η **επεξεργασία φυσικής γλώσσας (NLP)** και η **ανάλυση συναισθημάτων (sentiment analysis)** αποτελούν από τις πιο δημοφιλείς τεχνικές μηχανικής μάθησης, οι οποίες βοηθούν τους χρηματοπιστωτικούς οργανισμούς να εξοικονομήσουν χρόνο και να αποκτήσουν ευκολία στην ανάλυση δύσκολα επεξεργάσιμων δεδομένων των χρηστών.
- **Αλγόριθμοι επίλυσης σύνθετων ζητημάτων:** Μπορούν να εφαρμοστούν για την επίλυση σύνθετων προβλημάτων που προηγουμένως θεωρούνταν είτε πολύ δύσκολα είτε πολύ σύνθετα για τον άνθρωπο. Όπως εξετάστηκε και στο κεφάλαιο 2, η ανίχνευση απάτης αποτελούσε επί μακρόν ένα δύσκολο και χρονοβόρο έργο για τους ανθρώπους, ιδίως αν ληφθεί υπόψιν ο διαρκώς αυξανόμενος αριθμός συνόλων δεδομένων που, σε συνδυασμό, πρέπει να εξεταστούν. Ωστόσο, οι αλγόριθμοι ανίχνευσης ασυνήθιστων ενεργειών που βασίζονται στην μηχανική μάθηση χρησιμοποιούνται όλο και περισσότερο για την επεξεργασία δεδομένων σε πραγματικό χρόνο, από ένα τεράστιο φάσμα πηγών, και την ανακάλυψη κρυφών συσχετίσεων μεταξύ των δραστηριοτήτων των χρηστών και πιθανής απάτης.

3.2 Μεροληψία και προκατάληψη στα δεδομένα και στους αλγορίθμους μηχανικής μάθησης

Στην κοινότητα της μηχανικής μάθησης, ο όρος προκατάληψη αναφέρεται στη διαφορά μεταξύ της αναμενόμενης τιμής ενός εκτιμητή και της πραγματικής τιμής της εκτιμώμενης μεταβλητής.

Στην έρευνα των Gu και Oelke ως προς τα είδη προκατάληψης που περικλείουν τον κλάδο, επικεντρώθηκαν στην προκατάληψη ως τη διαφορά μεταξύ της κατανομής δειγματοληψίας και της κατανομής πληθυσμού (Gu & Oelke, 2019).

3.2.1 Τύποι μεροληψίας στα σύνολα δεδομένων

Η μεροληψία στα δεδομένα μπορεί να προέρχεται από διάφορες πηγές. Οι κύριοι τύποι μεροληψίας που εντοπίζονται σε αυτές είναι οι ακόλουθοι (Algorithmic bias and financial services, KPMG 2021):

- **Ιστορική προκατάληψη:** Εντοπίζεται στα δεδομένα λόγω ιστορικών παραγόντων. Για παράδειγμα, η παραδοχή ότι οι κάτοικοι μιας συγκεκριμένης περιοχής είχαν ιστορικά σχετικά υψηλότερα ποσοστά αθέτησης δανείων από τον εθνικό μέσο όρο, θα μπορούσε να επηρεάσει τις αποφάσεις χορήγησης δανείων για τη συγκεκριμένη ομάδα και να οδηγήσει σε υψηλότερο ποσοστό απορριφθέντων αιτήσεων δανείων. Η πάροδος του χρόνου αποτελεί έναν παράγοντα πιθανής ενίσχυσης τέτοιων προκαταλήψεων. Σε περιπτώσεις επικράτησης υψηλότερων ποσοστών αθέτησης δανείων στα ιστορικά δεδομένα μπορεί να μειώσει περαιτέρω την πιστωτική βαθμολογία των αιτούντων, αυξάνοντας έτσι την πιθανότητα απόρριψης των μελλοντικών αιτήσεων δανείων, πράγμα που αποτελεί στοιχείο δεδομένων που μπορεί να χρησιμοποιηθεί σε μελλοντικές επαναλήψεις του αλγορίθμου. Αυτό είναι γνωστό ως «βρόχος ανατροφοδότησης».
- **Μεροληψία του δείγματος:** Μπορεί να εντοπιστεί στα δεδομένα είτε επειδή το μέγεθος του δείγματος δεν είναι επαρκές ή/και διακατέχεται από στρεβλότητα προς διάφορες ομάδες που δεν είναι αντιπροσωπευτικές του συνολικού πληθυσμού.

Λαμβάνοντας υπόψιν ένα μικρό σύνολο δεδομένων στο οποίο οι περισσότεροι αιτούντες τυχαίνει να προέρχονται από μια συγκεκριμένη περιοχή, ο αλγόριθμος μπορεί να απορρίψει αιτήσεις δανείων για τα άτομα που προέρχονται από αυτήν.

- **Ανθρώπινη προκατάληψη:** Παρατηρείται συχνά στα σύνολα δεδομένων που χρησιμοποιούνται στα μοντέλα επιβλεπόμενης μηχανικής μάθησης. Οι συγκεκριμένοι αλγόριθμοι ουσιαστικά μαθαίνουν ό,τι τους έχουν διδάξει οι άνθρωποι. Ως αποτέλεσμα, μπορούν να μεταφέρουν όλες τις συνειδητές ή ασυνειδητές προκαταλήψεις από την ανθρώπινη κρίση. Για παράδειγμα, εάν ένας αλγόριθμος χρησιμοποιεί τις αποφάσεις ενός ασφαλιστή ως ετικέτες για την αξιολόγηση του κινδύνου τραπεζικών ασφαλιστικών προγραμμάτων, μπορεί να αναπαράγει τυχόν προκαταλήψεις που επικρατούν στις αποφάσεις του εισηγητή.
- **Μεροληψία μέτρησης:** Προκύπτει λόγω του τρόπου μέτρησης, συλλογής ή/και αποθήκευσης των δεδομένων. Η κύμανση εμφανίζεται από τον τρόπο στρωγγυλοποίησης των δεκαδικών αριθμών στα συστήματα μέχρι συστηματικά σφάλματα καταγραφής δεδομένων, λόγω ελαττωματικού εξοπλισμού ή δυσλειτουργίας. Η μεροληψία μέτρησης εφαρμόζεται συνήθως συστηματικά σε όλα τα σχετικά δεδομένα. Ωστόσο, σε ορισμένες περιπτώσεις, μπορεί να επηρεάσει εσφαλμένα μια συγκεκριμένη ομάδα περισσότερο από άλλες ομάδες, όπως όταν οι μέθοδοι συλλογής δεδομένων είναι φτωχότερες σε μια περιοχή σε σύγκριση με μια άλλη.
- **Μεροληψία συσχέτισης:** Εμφανίζεται όταν οι μεταβλητές που χρησιμοποιούνται στο πλαίσιο ενός αλγορίθμου συσχετίζονται, είτε μεμονωμένα είτε σε συνδυασμό με άλλες μεταβλητές, με δυνητικά ευαίσθητα χαρακτηριστικά όπως η χρήση μιας γεωγραφικής μεταβλητής, όπως η γεωγραφική περιοχή, η οποία συσχετίζεται με συγκεκριμένες εθνικότητες. Στις περισσότερες περιπτώσεις, είναι δύσκολο να προσδιοριστεί αν μια μεταβλητή συσχετίζεται με σταθερά χαρακτηριστικά και αν πρέπει να συμπεριληφθεί στην εκπαίδευση αλγορίθμων. Έτσι, ο απλός αποκλεισμός των προστατευόμενων χαρακτηριστικών των ατόμων στα δεδομένα

μπορεί να μην εξαλείψει ή ακόμη και να μετριάσει τον πιθανό αντίκτυπο της μεροληψίας σε συγκεκριμένες ομάδες. Στον αντίποδα, ο ορισμός των σταθερών χαρακτηριστικών στα δεδομένα πραγματοποιείται, ώστε να μπορούν να συγκεντρωθούν επαρκή μέτρα προκατάληψης και αποτελεσματικότητας των μεθόδων μετριασμού της.

- **Αναδύμενη προκατάληψη:** Αναφέρεται σε μια προκατάληψη που αναδύεται κάποια περίοδο μετά τη χρήση ενός αλγορίθμου, συχνά ως αποτέλεσμα της μεταβολής της κοινωνικής γνώσης, του πληθυσμού ή των πολιτισμικών αξιών. Ως αποτέλεσμα, τα δεδομένα που επιλέγονται και χρησιμοποιούνται στο πλαίσιο του αλγορίθμου ενδέχεται να μην αντικατοπτρίζουν την ανάδυση της νεότερων πληροφοριών ή των κοινωνικών αξιών του οργανισμού.

3.2.2 Τύποι μεροληψίας στους αλγορίθμους μηχανικής μάθησης

Από τον σχεδιασμό μέχρι την υλοποίηση ενός μοντέλου μέχρι και το πλαίσιο που εφαρμόζεται, η μεροληψία και η προκατάληψη μπορεί να εμφανιστεί σε πολλαπλά στάδια. Παραθέτοντας τους τύπους μεροληψίας που παρατηρούνται, κατανοούμε βαθύτερα τις αιτίες εμφάνισής τους.

Εκτός από τη μεροληψία στα ίδια τα δεδομένα, η μεροληψία μπορεί επίσης να εισαχθεί κατά τον **σχεδιασμό** ενός αλγορίθμου. Τα αποτελέσματα των αλγορίθμων μπορεί να είναι διαφορετικά ακόμη και όταν έχουν χρησιμοποιηθεί τα ίδια δεδομένα εισόδου. Οι προκαταλήψεις στον αλγοριθμικό σχεδιασμό περιλαμβάνουν:

- **Προκατάληψη στην αντικειμενικότητα:** Μπορεί να προκύψει από τον ίδιο τον στόχο του αλγορίθμου. Σε περιπτώσεις σχεδιασμού ψηφιακά προσφερόμενων τραπεζικών προϊόντων και υπηρεσιών, ένας αλγόριθμος που χρησιμοποιείται για την εκτίμηση του κινδύνου αθέτησης των υποχρεώσεων των ενυπόθηκων δανειοληπτών μπορεί να στοχεύει στη μεγιστοποίηση του συνολικού ποσοστού επιτυχίας των προβλέψεων. Ωστόσο, η υπερβολική ή ελλιπή καταγραφή συγκεκριμένων ομάδων θα μπορούσε να σημαίνει ότι ο αλγόριθμος είναι πιο ακριβής για ορισμένες ομάδες από ό,τι για άλλες. Με αυτόν τον τρόπο, επηρεάζονται τα αποτελέσματά τους, παρόλο που η συνολική ακρίβεια μεγιστοποιείται για όλες τις ομάδες.
- **Μεροληψία στάθμισης:** Αντικατοπτρίζει το γεγονός ότι δίνεται διαφορετική βαρύτητα σε ορισμένα χαρακτηριστικά σε έναν αλγόριθμο, και αν αυτά δεν εφαρμοστούν σωστά, μπορεί να επηρεαστούν τα αποτελέσματα. Για παράδειγμα, ένας αλγόριθμος που χρησιμοποιείται για την εκτίμηση των ασφαλιστρών αυτοκινήτου μπορεί να χρησιμοποιεί χαρακτηριστικά όπως η ηλικία ενός ατόμου και ο τόπος διαμονής του, αλλά αυτά μπορεί να μην έχουν την ίδια βαρύτητα. Μελέτες διαπίστωσαν ότι οι αλγόριθμοι που χρησιμοποιούνταν από πολλές ασφαλιστικές εταιρείες αυτοκινήτων στις ΗΠΑ βασίζονταν περισσότερο σε πιστωτικές βαθμολογίες παρά σε αρχεία οδήγησης. Αυτό σήμαινε ότι ένας μεμονωμένος οδηγός που είχε μόνο μία θετική πιστωτική βαθμολόγηση πλήρως

κατά μέσο περισσότερα δολάρια ετησίως από ό,τι παρόμοιοι οδηγοί με τα υψηλότερη πιστωτική βαθμολόγηση.

- **Μεροληψία αξιολόγησης:** Προκύπτει από τις μεθόδους που χρησιμοποιούνται για την αξιολόγηση των μοντέλων. Όπως αναλύθηκε προηγουμένως σε αυτήν την ενότητα, ο διαχωρισμός των δεδομένων σε σύνολα δεδομένων εκπαίδευσης και δοκιμής αποτελεί κοινή πρακτική για τον έλεγχο της απόδοσης των αλγορίθμων. Ο ακατάλληλος διαχωρισμός των δεδομένων, ωστόσο, μπορεί να οδηγήσει στη δειγματοληπτική μεροληψία που περιεγράφηκε νωρίτερα, δημιουργώντας ένα υπόδειγμα δεδομένων το οποίο έχει περάσει από το να μην έχει μεροληψία, στην εισαγωγή της στο μοντέλο.

Εξετάζοντας την έρευνα των Mehrabi και Morstatter (2021), οι οποίοι εστίασαν στη διερεύνηση της προκατάληψης και το πώς αυτή εμφανίζεται στα μοντέλα μηχανικής μάθησης θα αναλύσουμε την προσέγγισή τους στην αλγοριθμική προκατάληψη σε μία διαφορετική πτυχή της: προκατάληψη που εισάγεται **από τον αλγόριθμο προς τον χρήστη**.

Οι αλγόριθμοι μηχανικής μάθησης διαμορφώνουν και κατευθύνουν σε σημαντικό βαθμό τη συμπεριφορά του χρήστη. Κατά συνέπεια, τυχόν προκαταλήψεις στους αλγορίθμους μπορεί να αποφέρουν μεροληψίες στη συμπεριφορά του. Παρακάτω παρατίθενται, οι προκαταλήψεις ως αποτέλεσμα αλγοριθμικών κατευθύνσεων και επηρεάζουν ως συνέπεια τη συμπεριφορά του χρήστη.

- **Μεροληψία αλληλεπίδρασης χρήστη.** Η προκατάληψη της αλληλεπίδρασης χρήστη ενεργοποιείται από δύο πηγές, το User Interface της πλατφόρμας και του ίδιου του χρήστη, επιβάλλοντας την αυτό-επιλεγόμενη μεροληπτική συμπεριφορά και αλληλεπίδρασή του. Σε αυτήν την κατηγορία εντοπίζονται οι εξής υποκατηγορίες μεροληψίας:
 - **Μεροληψία παρουσίασης (presentation bias).** Η προκατάληψη παρουσίασης είναι αποτέλεσμα του τρόπου απεικόνισης των πληροφοριών στο εκάστοτε UI μίας πλατφόρμας. Για παράδειγμα, στην περιήγηση σε μία

ιστοσελίδα οι χρήστες έχουν τη δυνατότητα να επιλέξουν μόνο στο περιεχόμενο που είναι διαθέσιμο οπτικά σε αυτούς, το οποίο αποτελεί τη δυνατότητα που τους δίνει το μοντέλο που έχει σχεδιαστεί για την ιστοσελίδα. Συμπερασματικά, διάφορες δυνατότητες δεν είναι εφικτό να αξιοποιηθούν από τους χρήστες, εκτός από εκείνες που έχουν τη δυνατότητα να δουν.

- **Μεροληψία κατάταξης (ranking bias).** Η ιδέα ότι τα αποτελέσματα που βρίσκονται στην κορυφή της κατάταξης είναι τα πιο σχετικά και σημαντικά θα οδηγήσει στην προσέλκυση περισσότερων αλληλεπιδράσεων με αυτά από τους χρήστες σε σχέση με τα υπόλοιπα. Αυτή η προκατάληψη επηρεάζει τις μηχανές αναζήτησης και εφαρμογές crowdsourcing.

3.2.2 Προκλήσεις στην ανίχνευση της μεροληψίας

Η ανίχνευση και η αντιμετώπιση των προκαταλήψεων που προκαλούνται από την τεχνητή νοημοσύνη και την μηχανική μάθηση στα τραπεζικά συστήματα είναι ένα πολύπλοκο έργο. Ορισμένες από τις προκλήσεις περιλαμβάνουν:

Φύση του μαύρου κουτιού (black box nature): Οι αλγόριθμοι λειτουργούν συχνά ως «μαύρα κουτιά», καθιστώντας δύσκολη την κατανόηση του σκεπτικού πίσω από συγκεκριμένες αποφάσεις. Αυτή η έλλειψη επεξηγηματικότητας εμποδίζει την ικανότητα εντοπισμού και αντιμετώπισης πιθανών προκαταλήψεων στο σύστημα (James Craggs, 2021).

Ποιότητα δεδομένων: Τα μοντέλα τεχνητής νοημοσύνης καθορίζουν την φερεγγυότητά με βάση τα δεδομένα στα οποία εκπαιδεύονται. Τα ελλιπή ή μη αντιπροσωπευτικά σύνολα δεδομένων μπορούν να περιορίσουν την αντικειμενικότητα ενώ οι προκαταλήψεις στις ομάδες ανάπτυξης που εκπαιδεύουν τέτοια συστήματα μπορούν να διαιωνίσουν τον κύκλο της ανισότητας.

Αλγοριθμική προκατάληψη: Η προκατάληψη στη χρήση της τεχνητής νοημοσύνης είναι πιθανό να οδηγήσει σε συστηματικές και άδικες διακρίσεις στις αποφάσεις των αλγορίθμων, οι οποίες προκαλούνται από την εγγενή προκατάληψη των δεδομένων. Αυτό μπορεί να έχει ως αποτέλεσμα δυσανάλογες επιπτώσεις σε ορισμένες ομάδες περισσότερο από άλλες όπως αναλύθηκε εκτενώς στην προηγούμενη ενότητα.

Ενίσχυση των υφιστάμενων προκαταλήψεων: Η τεχνητή νοημοσύνη μπορεί να ενισχύσει τις υπάρχουσες ανθρώπινες προκαταλήψεις, καθιστώντας δυσκολότερο τον εντοπισμό τους όταν όλα είναι συγκεχυμένα στον υπολογισμό.

Ο εντοπισμός και ο μετριασμός της μεροληψίας δεν αποτελεί μία απλή διαδικασία όπως θα μπορούσαμε να παρομοιάσουμε με τη διαγραφή της στήλης με την ένδειξη «φύλο» σε ένα σύνολο δεδομένων. Οι σιωπηρές προκαταλήψεις εξακολουθούν να παραμένουν εξαιτίας της προκατάληψης της δειγματοληψίας, της επισήμανσης, του αποτελέσματος ή άλλων προκαταλήψεων, δημιουργώντας μια κατάσταση στην οποία για παράδειγμα οι γυναίκες έχουν άδικα περισσότερες πιθανότητες από τους άνδρες.

Με άλλα λόγια, οι φερέγγυες γυναίκες μπορεί να έχουν περισσότερες πιθανότητες σε άρνησης χορήγησης ενός δανείου από ό,τι οι φερέγγυοι άνδρες. Αυτές οι προκαταλήψεις δεν είναι πάντα ορατές με την πρώτη ματιά, αλλά αποτελούν σημαντικές προκλήσεις για την επιδίωξη της δικαιοσύνης μέσω της μηχανικής μάθησης και της τεχνητής νοημοσύνης (Women's World Banking, 2021).

3.3 Δεοντολογικά ζητήματα στην τεχνητή νοημοσύνη, την μηχανική μάθηση και τον τραπεζικό τομέα

3.3.1 Απόρρητο των δεδομένων και εμπιστοσύνη των πελατών

Οι ηθικές εκτιμήσεις που περιβάλλουν την ιδιωτικότητα των δεδομένων εκτείνονται πέρα από τη συμμόρφωση με τις κανονιστικές διατάξεις, περικλείουν τη δέσμευση για διαφάνεια, ενημέρωση των χρηστών και καλλιέργεια ενός ασφαλούς και αξιόπιστου ψηφιακού τραπεζικού συστήματος. Εστιάζοντας στην ισορροπία μεταξύ της αξιοποίησης των δεδομένων και της προστασίας των χρηστών, θα διερευνηθεί το ηθικό πλαίσιο που διέπει τη σχέση μεταξύ της ιδιωτικότητας των δεδομένων και της εμπιστοσύνης των πελατών. Η ηθική μεταχείριση των δεδομένων δεν αποτελεί απλώς νομική απαίτηση, αλλά ακρογωνιαίο λίθο για την καλλιέργεια ευήμερων σχέσεων με τους χρήστες της ψηφιακής τραπεζικής με τεχνικές τεχνητής νοημοσύνης και μηχανικής μάθησης.

Σύμφωνα με τον οργανισμό OECD, οι οικονομικές και προσωπικές πληροφορίες των χρηστών των ψηφιακών τραπεζικών υπηρεσιών πρέπει να προστατεύονται μέσω κατάλληλων μηχανισμών ελέγχου και προστασίας. Οι μηχανισμοί αυτοί καθορίζουν τους σκοπούς για τους οποίους τα δεδομένα μπορούν να συλλέγονται, να υποβάλλονται σε επεξεργασία, να αποθηκεύονται, να χρησιμοποιούνται και να κοινοποιούνται (ιδίως σε τρίτους).

Επίσης, όπως περιγράφεται στις προσεγγίσεις πολιτικής για την προστασία του κοινού χρηματοπιστωτικού ενδιαφέροντος, οι υπεύθυνοι χάραξης πολιτικής και οι εποπτικοί φορείς που είναι αρμόδιοι για την προστασία των χρηματοπιστωτικών καταναλωτών θα πρέπει να διασφαλίσουν ότι το νομικό, κανονιστικό και εποπτικό πλαίσιο για την προστασία τους διαθέτει κατάλληλες εγγυήσεις και μέτρα σχετικά με την προστασία των δεδομένων και της ιδιωτικής ζωής των, συμπεριλαμβανομένου του ορισμού των «δεδομένων προσωπικού χαρακτήρα».

Η συνεργασία με τις αρχές προστασίας δεδομένων για τη διασφάλιση και την εφαρμογή των νόμων και κανονισμών για την προστασία των δεδομένων στους

παρόχους χρηματοπιστωτικών υπηρεσιών αποτελεί αναπόσπαστο κομμάτι στις δραστηριότητες των τραπεζικών ιδρυμάτων.

Η διασφάλιση της διάθεσης ισχυρών συστημάτων διακυβέρνησης, λογοδοσίας, διαχείρισης κινδύνων και ελέγχου σχετικά με τη χρήση ψηφιακών δυνατοτήτων είναι απαραίτητο να διέπονται από διαφάνεια, ιδίως στους τομείς της τεχνητής νοημοσύνης, των αλγορίθμων και της τεχνολογίας μηχανικής μάθησης (OECD, 2019).

3.3.2 Διαφάνεια και λογοδοσία

Η διαφάνεια και η λογοδοσία αποτελούν απαραίτητες έννοιες για τη διασφάλιση ότι η χρήση της τεχνητής νοημοσύνης και της μηχανικής μάθησης στον τραπεζικό τομέα είναι δεοντολογική και ευθυγραμμισμένη με το ισχύον κανονιστικό πλαίσιο. Τα μοντέλα που χρησιμοποιούνται για τη πιστωτική βαθμολόγηση, την έγκριση δανείων και την αξιολόγηση κινδύνων, η διαφάνεια κατέχουν ζωτική σημασία για την κατανόηση των κρίσιμων παραγόντων και μεταβλητών που επηρεάζουν τη διαδικασία λήψης αποφάσεων. Ως αποτέλεσμα, ο μετριασμός του κινδύνου μεροληψίας και διακρίσεων στις αυτοματοποιημένες διαδικασίες οι οποίες περικλείονται από την TN και την ML εξαρτάται σε μεγάλο βαθμό από την κατανόηση του από το κοινό.

Σε έκθεση της αγγλικής τράπεζας Barclays σχετικά με τη μεροληψία στη λήψη αλγοριθμικών αποφάσεων στις χρηματοπιστωτικές υπηρεσίες το 2021, παρατέθηκε η σημασία της διαφάνειας στους πελάτες όσον αφορά την αλγοριθμική λήψη αποφάσεων τηρώντας της αρχές του Γ.Κ.Π.Δ. που παρέχει ένα ολοκληρωμένο πλαίσιο για την αντιμετώπιση αυτής της πρόκλησης. Για παράδειγμα, σύμφωνα με το άρθρο 22 του Γ.Κ.Π.Δ., όταν μια επιχείρηση λαμβάνει μια πλήρως αυτοματοποιημένη απόφαση που έχει σημαντικές επιπτώσεις σε ένα άτομο, οφείλει να θεσπίσει διασφαλίσεις για την προστασία του ατόμου, ιδίως συμπεριλαμβανομένου του δικαιώματος να λάβει ανθρώπινη παρέμβαση, να εκφράσει την άποψή του και να αμφισβητήσει την απόφαση. Επιπλέον, το άτομο έχει δικαίωμα σε επεξήγηση της απόφασης από τον οργανισμό.

Ωστόσο, το επίπεδο κατανόησης των αλγορίθμων ποικίλλει μεταξύ του κοινού, ενώ ο μέσος πελάτης θα πρέπει να εκπαιδευτεί στις συγκεκριμένες πρακτικές. Επομένως, είναι σημαντικό να εμπλακούν όλοι οι ενδιαφερόμενοι φορείς για την ευαισθητοποίηση σχετικά με τη φύση και τα οφέλη των αλγορίθμων που βοηθούν τα άτομα και τους οργανισμούς να λαμβάνουν καλύτερες αποφάσεις.

Για τους πελάτες και την ευρύτερη κοινωνία, οι όποιες προσπάθειες ευαισθητοποίησης θα πρέπει να τονίζουν την ικανότητα των αλγοριθμικών αποφάσεων ώστε να επιτύχουν θετικό αποτέλεσμα, όπως οι τρόποι δημιουργίας υψηλού πιστωτικού ιστορικού ώστε να είναι σε θέση να έχουν πρόσβαση σε πίστωση στην καλύτερη τιμή στο μέλλον. Για τις ρυθμιστικές αρχές, κάθε δέσμευση είναι σημαντικό να επιδιώκει να καταδείξει την αξιοπιστία και τη σταθερότητα των αλγοριθμικών αποφάσεων για την οικοδόμηση εμπιστοσύνης.

Στον αντίποδα, κάθε συμμετοχή του κοινού πρέπει να λαμβάνει υπόψιν τις ακόλουθες προκλήσεις:

- Περιορισμένη κατανόηση των αλγορίθμων λήψης αποφάσεων
- Έλεγχος της χρήσης των δεδομένων για τη λήψη αποφάσεων από το κοινό
- Συμβιβασμοί μεταξύ ερμηνευσιμότητας και ακρίβειας
- Ποικιλομορφία στα επίπεδα σκεπτικισμού απέναντι στους αλγορίθμους και στις αντιδράσεις απέναντι στις αποφάσεις που λαμβάνονται από αλγορίθμους, ιδίως σε περίπτωση δυσμένειας
- Χαρακτηρισμός των αλγορίθμων ως στατιστικοί και απρόσωποι
- Αυξημένη ευαισθησία των πελατών γύρω από την αυτοματοποίηση.

3.3.3 Δικαιοσύνη

Η καταπολέμηση των προκαταλήψεων και των διακρίσεων έχει μακρά ιστορία στη φιλοσοφία και την ψυχολογία και, πρόσφατα, στη μηχανική μάθηση. Ωστόσο, για να μπορέσει κανείς να καταπολεμήσει τις διακρίσεις και να επιτύχει τη δικαιοσύνη, θα πρέπει πρώτα να ορίσει τη δικαιοσύνη. Οι επιστήμες της φιλοσοφίας και της ψυχολογίας έχουν προσπαθήσει να ορίσουν την έννοια της δικαιοσύνης πολύ πριν από την επιστήμη των υπολογιστών. Το γεγονός ότι δεν υφίσταται καθολικός ορισμός της δικαιοσύνης δείχνει τη δυσκολία επίλυσης αυτού του προβλήματος. Οι διαφορετικές προσεγγίσεις σε ποικίλες κουλτούρες προσδίδουν προτίμηση σε πολλαπλούς τρόπους θεώρησης της δικαιοσύνης, γεγονός που καθιστά δυσκολότερη την εύρεση ενός μόνο ορισμού που έχει χαρακτηριστεί ως αποδεκτός καθολικά.

Στην επιστήμη των υπολογιστών, όπου το μεγαλύτερο μέρος των ενεργειών για την πρόταση νέων περιορισμών δικαιοσύνης για αλγορίθμους προέρχονται από τη Δύση, και πολλές από αυτές τις ενέργειες χρησιμοποιούν τα ίδια σύνολα δεδομένων και προβλήματα για να δείξουν πώς οι περιορισμοί τους, δεν υπάρχει ακόμη σαφής καταληκτικός ορισμός σχετικά με το ποιοι περιορισμοί είναι οι καταλληλότεροι για αυτά τα προβλήματα.

Έχοντας αναλύσει τις παραπάνω προκλήσεις, έχουν προταθεί πολλοί ορισμοί της δικαιοσύνης για την αντιμετώπιση διαφόρων ζητημάτων αλγοριθμικής μεροληψίας και διακρίσεων που συζητήθηκαν στην προηγούμενη ενότητα.

Προσεγγίζοντας τη δικαιοσύνη από την σκοπιά της πληροφορικής είναι σημαντικό να παραθέσουμε τους παρακάτω ορισμούς.

Ορισμός 1 (Δικαιοσύνη μέσω ευαισθητοποίησης). *«Ένας αλγόριθμος είναι δίκαιος εάν δίνει παρόμοιες προβλέψεις σε παρόμοια άτομα»* (Berk et al, 2021).

Με άλλα λόγια, οποιαδήποτε δύο άτομα που είναι παρόμοια σε σχέση με μία συγκεκριμένη μέτρηση ομοιότητας, η οποία έχει οριστεί για μια συγκεκριμένη ενέργεια, θα πρέπει να λαμβάνουν παρόμοιο αποτέλεσμα.

Ορισμός 2 (Δικαιοσύνη μέσω άγνοιας). «Ένας αλγόριθμος είναι δίκαιος εφόσον τυχόν προστατευόμενα χαρακτηριστικά X δεν χρησιμοποιούνται ρητά στη διαδικασία λήψης αποφάσεων» (Kusner et al., 2017).

Ορισμός 3 (Ισότητα μεταχείρισης). «Η ισότητα μεταχείρισης επιτυγχάνεται όταν η αναλογία ψευδών αρνητικών και ψευδών θετικών αποτελεσμάτων είναι η ίδια για τις δύο κατηγορίες προστατευόμενων ομάδων» (Berk et al, 2021).

Με απλουστευμένα λόγια, η βασική ιδέα της δικαιοσύνης στην μηχανική μάθηση είναι η απουσία οποιασδήποτε προκατάληψης ή ευνοιοκρατίας έναντι ενός ατόμου ή μιας ομάδας με βάση τα εγγενή ή επίκτητα χαρακτηριστικά τους στο πλαίσιο της λήψης αποφάσεων.

3.3.4 Κανονιστικό πλαίσιο

Το παγκόσμιο και εγχώριο κανονιστικό πλαίσιο που περιβάλλει τον τραπεζικό κλάδο αποτελείται από πολλαπλές ρυθμιστικές αρχές, οργανισμούς επιβολής, επιθεωρήσεις και διαμεσολαβητές με ένα ευρύ φάσμα αρμοδιοτήτων, εξουσιών και ευθυνών. Οι αλγόριθμοι με βάση τα δεδομένα δεν αντικαθιστούν απαραίτητα άλλους μηχανισμούς λήψης αποφάσεων εξ ολοκλήρου, αλλά αντίθετα εντάσσονται στις υφιστάμενες διαδικασίες λήψης αποφάσεων. Επομένως, το υφιστάμενο κανονιστικό πλαίσιο προσαρμόζεται προκειμένου να αντιμετωπιστούν οι προκαταλήψεις και οι διακρίσεις σε έναν όλο και περισσότερο καθοδηγούμενο από δεδομένα κόσμο.

Η βασική νομοθεσία που διέπει τις διακρίσεις είναι ο **νόμος περί ισότητας του 2010**. Ο νόμος παρέχει ένα νομικό πλαίσιο για την προστασία των δικαιωμάτων των ατόμων και προβλέπει νόμο περί διακρίσεων για την προστασία των ατόμων από άδικη μεταχείριση, μεταξύ άλλων μέσω αλγοριθμικών διακρίσεων.

Τα θεμελιώδη δικαιώματα κατά των διακρίσεων καθορίζονται επίσης στο **νόμο περί ανθρωπίνων δικαιωμάτων του 1998**. Όταν μια απόφαση λαμβάνεται από έναν οργανισμό βάσει καταγεγραμμένων πληροφοριών, ο **νόμος περί προστασίας δεδομένων του 2018** και ο Γενικός Κανονισμός Προστασίας Δεδομένων (Γ.Κ.Π.Δ.)

είναι επίσης σχετικοί. Η εν λόγω νομοθεσία ελέγχει τον τρόπο με τον οποίο χρησιμοποιούνται οι προσωπικές πληροφορίες από οργανισμούς, επιχειρήσεις ή την κυβέρνηση και καθορίζει τις αρχές προστασίας δεδομένων, οι οποίες περιλαμβάνουν τη διασφάλιση της νόμιμης, δίκαιης και διαφανούς χρήσης των προσωπικών πληροφοριών. Η νομοθεσία για την προστασία των δεδομένων αποκτά μεγαλύτερη σημασία στην περίπτωση της αλγοριθμικής λήψης αποφάσεων, όπου οι αποφάσεις βασίζονται εγγενώς στα δεδομένα και ισχύουν ειδικές ρήτρες σχετικά με την αυτοματοποιημένη επεξεργασία και την κατάρτιση προφίλ.

Αυτές οι ρυθμιστικές αρχές του τομέα έχουν σαφή ρόλο να διαδραματίσουν: η αλγοριθμική μεροληψία είναι τελικά ένα ζήτημα του τρόπου λήψης αποφάσεων από τους οργανισμούς, και η λήψη αποφάσεων είναι εγγενώς τομεακή. Στους τομείς όπου η αλγοριθμική λήψη αποφάσεων είναι ήδη σημαντική, οι αρμόδιοι φορείς επιβολής της νομοθεσίας εξετάζουν τα ζητήματα που εγείρονται από τα μοντέλα αλγοριθμικής λήψης αποφάσεων, διεξάγουν ειδική έρευνα και αυξάνουν τις εσωτερικές τους δεξιότητες και ικανότητες για να ανταποκριθούν.

Εστιάζοντας στον Γ.Κ.Π.Δ., εκείνος παρέχει πληροφορίες σχετικά με τη χρήση αλγοριθμικών αποφάσεων στις χρηματοπιστωτικές υπηρεσίες. Βασικά ζητήματα για τους οργανισμούς χρηματοπιστωτικού ενδιαφέροντος είναι ο εντοπισμός και ο μετριασμός της μεροληψίας, καθώς και η διαφάνεια και η διακυβέρνηση. Οι απαιτήσεις του Γ.Κ.Π.Δ. για αμεροληψία, διαφάνεια και νόμιμη βάση για την επεξεργασία καλύπτουν ουσιαστικά τους βασικούς κινδύνους για τα άτομα. Στον αντίποδα, οι κανονισμοί τείνουν να είναι ουδέτεροι ως προς την τεχνολογία, γεγονός που χαρακτηρίζεται ως κατανοητό για να αποφευχθεί η παύση εφαρμογής των κανονισμών όταν χρησιμοποιούνται νέες τεχνολογίες, αλλά ταυτόχρονα είναι σημαντικό οι κανονισμοί να συντάσσονται με γνώμονα τις τεχνολογίες και πιο συγκεκριμένα τις «περιπτώσεις χρήσης».

Καθώς εξελίσσονται πιο σύνθετες περιπτώσεις χρήσης, είναι σημαντικό οι κανονιστικές αρχές να συνεργάζονται για την παροχή περαιτέρω καθοδήγησης αντί για περαιτέρω κανονιστική ρύθμιση (Barclays, 2021).

3.3.5 Διακρίσεις

Έχοντας εξετάσει το κανονιστικό πλαίσιο τίθεται το ερώτημα πως αυτό ορίζει τις διακρίσεις και προστατεύει τα άτομα κατά την εφαρμογή τους σε τραπεζικές δραστηριότητες με εφαρμογή μοντέλων μηχανικής μάθησης.

Ο **νόμος περί ισότητας** του 2010 προστατεύει νομικά τους ανθρώπους από τις διακρίσεις και ορίζει εννέα «προστατευόμενα χαρακτηριστικά», βάσει των οποίων η διάκριση χαρακτηρίζεται παράνομη:

- *Ηλικία*
- *Αναπηρία*
- *Αλλαγή Φύλου*
- *Γάμος και Σύμφωνο Συμβίωσης*
- *Εγκυμοσύνη και Μητρότητα*
- *Εθνικότητα*
- *Θρησκεία ή πεποιθήσεις*
- *Φύλο*
- *Σεξουαλικός προσανατολισμός*

Ο νόμος απαγορεύει τις άμεσες διακρίσεις, τις έμμεσες διακρίσεις, τη θυματοποίηση και την παρενόχληση με βάση αυτά τα χαρακτηριστικά. Καθιερώνει επίσης την απαίτηση να γίνονται εύλογες προσαρμογές για τα άτομα με αναπηρία και επιτρέπει, αλλά δεν απαιτεί, «θετική δράση» για να καταστεί δυνατή ή να ενθαρρυνθεί η συμμετοχή μειονεκτουσών ομάδων. Ο νόμος θεσπίζει επίσης το καθήκον ισότητας του δημόσιου και ιδιωτικού τομέα, το οποίο απαιτεί από όλους τους φορείς να καταδικάζουν την ανισότητα μέσω των δραστηριοτήτων τους.

Ο **νόμος περί ανθρωπίνων δικαιωμάτων** (1998) απαγορεύει ρητά τις διακρίσεις στο άρθρο 14:

«Η απόλαυση των δικαιωμάτων και των ελευθεριών που ορίζονται στην παρούσα Σύμβαση εξασφαλίζεται χωρίς διακρίσεις λόγω φύλου, φυλής, χρώματος, γλώσσας, θρησκείας, πολιτικών ή άλλων πεποιθήσεων, εθνικής ή κοινωνικής καταγωγής, ένταξης σε εθνική μειονότητα, περιουσίας, γέννησης ή άλλης κατάστασης».

Πρόκειται για ένα ευρύτερο σύνολο χαρακτηριστικών, που αποτρέπει ιδίως τις διακρίσεις λόγω γλώσσας, πολιτικών πεποιθήσεων και περιουσίας. Αυτό συνεπάγεται ότι οι κυβερνητικοί φορείς και οι οργανισμοί δεν μπορούν να πραγματοποιήσουν διακρίσεις με βάση αυτά τα χαρακτηριστικά όταν χορηγούν ή προστατεύουν δικαιώματα όπως το δικαίωμα σε δίκαιη δίκη (άρθρο 6) ή η ελευθερία της έκφρασης (άρθρο 10).

4. Μεθοδολογία της έρευνας

4.1 Σύνοψη του προβλήματος

Η ενσωμάτωση της τεχνητής νοημοσύνης και της μηχανικής μάθησης στον τραπεζικό τομέα έχει επιφέρει σημαντικές εξελίξεις, προσφέροντας λύσεις σε διάφορες προκλήσεις. Η υιοθέτηση αυτών των τεχνολογιών έχει επίσης εγείρει δεοντολογικές ανησυχίες καθώς και ζητήματα προκατάληψης και μεροληψίας. Μια βιβλιογραφική ανασκόπηση ανέδειξε διάφορα προβληματικά πεδία, όπως η πιθανότητα μεροληψίας στα αλγοριθμικά μοντέλα που χρησιμοποιούνται για την αξιολόγηση του πιστοληπτικού ιστορικού, την έγκριση δανείων και την εκτίμηση κινδύνου. Η μεροληψία εμφανίζεται και στα σύνολα δεδομένων και μπορεί να καθοριστεί είτε από την εξαγωγή τους ή την επεξεργασία τους.

Εστιάζοντας στο κανονιστικό πλαίσιο και στην ανάλυση των διακρίσεων και της δικαιοσύνης αναλύθηκε η σημασία τήρησης του κανονιστικού πλαισίου. Εξετάζοντας το ισχύον νομοθετικό πλαίσιο και συγκεκριμένα το νόμο περί ισότητας του 2010 και το νόμο περί ανθρωπίνων δικαιωμάτων του 1998, χαρακτηριστικά όπως το φύλο, η ηλικία, και η οικογενειακή κατάσταση θα πρέπει να μένουν ακλόνητα στις διαδικασίες λήψης αποφάσεων του δημόσιου και ιδιωτικού τομέα.

Αποσκοπώντας στην διερεύνηση μίας μελέτης περίπτωσης από τον πραγματικό κόσμο, θα εστιάσουμε στα συγκεκριμένα χαρακτηριστικά προκειμένου να επιτευχθεί η ανίχνευση της μεροληψίας και της προκατάληψης στις τραπεζικές δραστηριότητες μέσω της ανάλυσης δεδομένων και της εφαρμογής των κατάλληλων μοντέλων μηχανικής μάθησης.

Στο παρόν κεφάλαιο, θα εξετάσουμε ένα σύνολο δεδομένων με τη χρήση της γλώσσας προγραμματισμού Python για να ελέγξουμε τον πιθανό αντίκτυπο των μοντέλων στην αντιμετώπιση αυτών των προκλήσεων.

4.2 Χρήσιμα Βοηθήματα

4.2.1 Η γλώσσα προγραμματισμού Python

Η Python είναι μια ευέλικτη και ισχυρή γλώσσα προγραμματισμού που χρησιμοποιείται ευρέως σε διάφορους τομείς, όπως η επιστήμη των δεδομένων, η ανάπτυξη ιστοσελίδων και η αυτοματοποίηση. Είναι γνωστή για την απλότητα, την αναγνωσιμότητα και την εκτεταμένη τυποποιημένη βιβλιοθήκη της, καθιστώντας την ιδανική επιλογή τόσο για αρχάριους όσο και για έμπειρους προγραμματιστές. Χρησιμοποιείται συχνά ως γλώσσα σεναρίων (scripting language), καθώς είναι επίσης κατάλληλη για την ανάπτυξη λογισμικού μεγάλης κλίμακας. Η σχεδιαστική φιλοσοφία της Python δίνει έμφαση στην αναγνωσιμότητα του κώδικα με την αξιοσημείωτη χρήση σημαντικών εσοχών.

Όπως αναφέρεται στον επίσημο ιστότοπο της Python, *«Η Python είναι μια γλώσσα προγραμματισμού που σας επιτρέπει να εργάζεστε γρήγορα και να ενσωματώνετε συστήματα πιο αποτελεσματικά.»* (Welcome to Python.org)

Γιατί όμως η Python αποτελεί βασικό εργαλείο της μηχανικής μάθησης;

Είναι απλή και ευανάγνωστη: Το συντακτικό της Python είναι σαφές και εύκολα κατανοητό, γεγονός που την καθιστά εξαιρετική γλώσσα για αρχάριους.

Είναι εύκολη στην ερμηνεία: Ο κώδικας της Python εκτελείται γραμμή προς γραμμή, γεγονός που επιτρέπει την εύκολη εύρεση σφαλμάτων και την ταχεία ανάπτυξη.

Διαθέτει πολλές βιβλιοθήκες: Η Python συνοδεύεται από μια μεγάλη συλλογή βιβλιοθηκών όπως οι NumPy, SciPy, PyTorch και scikit-learn, έχουν σχεδιαστεί για χρήση στη μηχανική μάθηση.

Υπάρχουν πολυάριθμοι διαθέσιμοι πόροι για την εκμάθηση της Python, όπως διαδικτυακά σεμινάρια, βιβλία και διαδραστικές πλατφόρμες εκμάθησης. Ο επίσημος

ιστότοπος της Python παρέχει ένα ολοκληρωμένο σεμινάριο για αρχάριους, το οποίο καλύπτει τις θεμελιώδεις έννοιες και τα χαρακτηριστικά της γλώσσας.

The Zen of Python

```
Beautiful is better than ugly.  
Explicit is better than implicit.  
Simple is better than complex.  
Complex is better than complicated.  
Flat is better than nested.  
Sparse is better than dense.  
Readability counts.  
Special cases aren't special enough to break the rules.  
Although practicality beats purity.  
Errors should never pass silently.  
Unless explicitly silenced.  
In the face of ambiguity, refuse the temptation to guess.  
There should be one-- and preferably only one --obvious way to do it.  
Although that way may not be obvious at first unless you're Dutch.  
Now is better than never.  
Although never is often better than *right* now.  
If the implementation is hard to explain, it's a bad idea.  
If the implementation is easy to explain, it may be a good idea.  
Namespaces are one honking great idea -- let's do more of those!
```

Εικόνα 9. Το Zen της Python

<https://www.linkedin.com/pulse/zen-python-tim-peters-count-also-real-life-manfred-buchmann/>

4.2.2 Η κοινότητα Kaggle

Το Kaggle αποτελεί μια διαδικτυακή πλατφόρμα που φιλοξενεί διαγωνισμούς και έργα επιστήμης δεδομένων. Παρέχει πρόσβαση σε μια τεράστια βάση συνόλων δεδομένων, εργαλείων και πόρων, επιτρέποντας στους χρήστες να αναπτύξουν τις δεξιότητές τους στην επιστήμη δεδομένων και τη μηχανική μάθηση. Το Kaggle ιδρύθηκε το 2010 από τον Anthony Goldbloom και την ομάδα του, με στόχο τη δημιουργία μιας πλατφόρμας για τους λάτρεις της επιστήμης των δεδομένων να μοιράζονται τη δουλειά τους, να μαθαίνουν ο ένας από τον άλλον και να ανταγωνίζονται σε προκλήσεις.

Βασικά χαρακτηριστικά της πλατφόρμας Kaggle

Διαγωνισμοί: Το Kaggle φιλοξενεί τακτικούς διαγωνισμούς, όπου οι συμμετέχοντες μπορούν να δοκιμάσουν τις δεξιότητες και τις γνώσεις τους επιλύοντας πραγματικά προβλήματα χρησιμοποιώντας τεχνικές επιστήμης δεδομένων και μηχανικής μάθησης.

Σύνολα δεδομένων: Το Kaggle προσφέρει ένα ευρύ φάσμα συνόλων δεδομένων, συμπεριλαμβανομένων εκείνων που σχετίζονται με τον τραπεζικό τομέα, τα οποία μπορούν να χρησιμοποιηθούν για έρευνα, ανάλυση και ανάπτυξη μοντέλων.

Εργαλεία και πόροι: Το Kaggle παρέχει διάφορα εργαλεία και πόρους, όπως βιβλιοθήκες και σεμινάρια, για την υποστήριξη των χρηστών στα έργα τους στον τομέα της επιστήμης δεδομένων και της μηχανικής μάθησης.

Τον Ιούνιο του 2017, το Kaggle ξεπέρασε το 1 εκατομμύριο εγγεγραμμένους χρήστες και, από τον Οκτώβριο του 2023, πάνω από 15 εκατομμύρια χρήστες είναι εγγεγραμμένοι στην πλατφόρμα.

4.2.3 Η πλατφόρμα Google Colab

Το Google Colab αποτελεί μια διαδικτυακή πλατφόρμα η οποία παρέχει περιβάλλον για έργα επιστήμης δεδομένων και μηχανικής μάθησης. Προσφέρει πρόσβαση σε ισχυρούς υπολογιστικούς πόρους και δημοφιλή εργαλεία συνεργασίας όπως το TensorFlow και το PyTorch.

Βασικά χαρακτηριστικά της πλατφόρμας Google Colab

Δωρεάν πρόσβαση σε υπολογιστικούς πόρους: Το Google Colab παρέχει δωρεάν πρόσβαση σε ισχυρούς υπολογιστικούς πόρους, όπως GPUs και TPUs, καθιστώντας το ιδανική πλατφόρμα για έργα επιστήμης δεδομένων και μηχανικής μάθησης.

Εργαλεία συνεργασίας: Το Google Colab επιτρέπει στους χρήστες να μοιράζονται σημειωματάρια και να συνεργάζονται με άλλους σε πραγματικό χρόνο, καθιστώντας το ένα εξαιρετικό εργαλείο για ομαδικά έργα.

Ενσωμάτωση σε δημοφιλή εργαλεία: Το Google Colab είναι ενσωματωμένο με δημοφιλή εργαλεία όπως το TensorFlow και το PyTorch, διευκολύνοντας τους ερευνητές να πειραματιστούν με διαφορετικά μοντέλα χωρίς να ανησυχούν για την εγκατάσταση και τη διαμόρφωση αυτών των εργαλείων.

Στη μελέτη περίπτωσης μας, θα χρησιμοποιήσουμε το Google Colab για να αναλύσουμε το σύνολο δεδομένων και να αναπτύξουμε μοντέλα μηχανικής μάθησης για τον εντοπισμό της προκατάληψης και της μεροληψίας σε πραγματικά σύνολα δεδομένων.

4.3 Μεθοδολογία

Η επιλογή της μεθοδολογίας που θα χρησιμοποιηθεί είναι καθοριστικής σημασίας, αναλύοντας μία μελέτη περίπτωσης από τον πραγματικό κόσμο. Η συνολική διάρκεια της μελέτης καθώς και η ποιότητά της θα επηρεαστούν από την προσέγγιση.

Αρχικά, αφού καθοριστεί η έκταση του προβλήματος, θα πρέπει να γίνει αναζήτηση ενός συνόλου δεδομένων. Οι πληροφορίες πρέπει να σχετίζονται άμεσα με αιτούντες κάποιου χρηματοοικονομικού προϊόντος όπως κάποιο δάνειο ή πιστωτική κάρτα. Στην παρούσα έρευνα θα γίνει προσέγγιση της μεθοδολογίας με εξαγωγή δεδομένων σχετικά με αιτήσεις δανείων και διάφορους παράγοντες και χαρακτηριστικά που τις επηρεάζουν. Υπάρχουν δύο μέθοδοι για την απόκτηση δεδομένων:

- λήψη πληροφοριών από τους ίδιους τους δανειολήπτες
- συλλογή πληροφοριών από κάποιο χρηματοπιστωτικό ίδρυμα

Με τη συλλογή πληροφοριών μετά από συναντήσεις με οφειλέτες δανείων, η πρώτη περίπτωση μπορεί να καταστεί εφικτή. Τα δεδομένα πρέπει στη συνέχεια να εισαχθούν σε μια βάση δεδομένων ή σε ένα σύστημα πληροφοριών. Πρόκειται για μια χρονοβόρα διαδικασία.

Η προσέγγιση μιας τράπεζας που χορηγεί δάνεια αποτελεί το δεύτερο σενάριο. Απαιτεί πολύ λίγο χρόνο και προσπάθεια, καθώς τα χρηματοπιστωτικά ιδρύματα παρακολουθούν τα στοιχεία των πελατών τους μέσω βάσεων δεδομένων. Μια τράπεζα μπορεί να παρέχει τα στοιχεία μεγάλου αριθμού πελατών με λίγες ώρες εργασίας αντί να χρειάζεται να πραγματοποιήσει συναντήσεις για να πάρει πληροφορίες. Περαιτέρω περιπλέκει τα πράγματα η συμπερίληψη ενός αριθμού ατόμων που δεν έχουν λάβει δάνειο ή που δεν επιθυμούν να αποκαλύψουν τα προσωπικά τους στοιχεία.

Η αναζήτηση ανοικτών δεδομένων, είτε προέρχονται από πολίτες, εταιρίες ή από κυβερνήσεις (gov data), αποτελεί μια ενδιάμεση λύση.

Εκτός από την αναζήτηση σχετικών δεδομένων, η διαδικασία περιλαμβάνει τον προσδιορισμό του κατά πόσον ο τομέας του προβλήματος είναι γνωστός και κατά

πόσον υπάρχουν άτομα που θα μπορούσαν να είναι πρόθυμα να παράσχουν πληροφορίες, έννοιες ή λύσεις.

Η ανάλυση των δεδομένων ακολουθεί μετά την απόκτησή τους. Είναι απαραίτητο να γνωρίζει κανείς τις παραμέτρους, τα χαρακτηριστικά και το πιθανό εύρος τιμών τους.

Τα δεδομένα θα υποβληθούν στη συνέχεια σε διερευνητική ανάλυση. Στη συνέχεια, μπορούν να προσφέρουν επαρκείς πληροφορίες για να αποφασιστεί ποια είναι περισσότερο ή λιγότερο σημαντικά όταν συνδυάζονται με συγκρίσιμα διαγράμματα μέσω της πλατφόρμας Google Colab.

Εστιάζοντας στους κύριους άξονες της παρούσας έρευνας οι οποίοι είναι η αντίχνευση της μεροληψίας, η μέτρηση της δικαιοσύνης και της προκατάληψης θα ακολουθήσει ανάλυση των δεδομένων μέσω των κατάλληλων μοντέλων μηχανικής μάθησης. Η μεθοδολογία ολοκληρώνεται με αυτό το βήμα.

4.4 Επιλογή και εξόρυξη δεδομένων

4.4.1 Αναζήτηση δεδομένων στο πεδίο του προβλήματος

Ένα συμπέρασμα προέκυψε μετά από μια ολοκληρωμένη αναζήτηση πληροφοριών σε ανοικτά δεδομένα χρηματοπιστωτικών ιδρυμάτων και εταιριών χρηματοπιστωτικού ενδιαφέροντος. Η κοινότητα Kaggle αποτελεί την πλέον κατάλληλη πηγή εξόρυξης δεδομένων αφού παρέχει δωρεάν ή/και δημόσια σύνολα δεδομένων. Επιπλέον, μέσω της πλατφόρμας μπορούν να τεθούν προβλήματα μηχανικής μάθησης.

Η πλατφόρμα Kaggle προσφέρει δεδομένα αιχμής με ρυθμό που είναι ταχύτερος και ακριβέστερος από άλλους. Πολυάριθμοι τομείς, όπως τα χρηματοοικονομικά, το λιανικό εμπόριο και η ιατρική, έχουν γνωρίσει επιτυχία μέσω της κοινότητας, στην επίλυση πραγματικών ζητημάτων. Οι διαγωνισμοί επιστήμης δεδομένων και οι συμβουλευτικές υπηρεσίες είναι δύο από τις κύριες προσφερόμενες δυνατότητές της Kaggle. (Highlights, Kaggle, 2022)

Οι συμμετέχοντες στο Kaggle μπορούν να έχουν πρόσβαση και να δημοσιεύουν τα δικά τους σύνολα δεδομένων καθώς και εκείνα άλλων συμμετεχόντων. Οι επιστήμονες δεδομένων είναι σε θέση να εξετάσουν και να αναλύσουν αυτόν τον όγκο δεδομένων κατασκευάζοντας διαφορετικά μοντέλα, επειδή είναι πλέον διαθέσιμα. Η κατανόηση της συμπεριφοράς των δεδομένων και, η δυνατότητα πρόβλεψης γεγονότων καθίστανται εφικτές χάρη στα μοντέλα.

Η εταιρία Dream Housing Finance εντοπίστηκε κατά την αναζήτηση δεδομένων από χρηματοπιστωτικά ιδρύματα. Αυτή η επιχείρηση επέλεξε να χρησιμοποιήσει την Kaggle ως μέσο διάθεσης δεδομένων προς χρήση από απλούς χρήστες της πλατφόρμας με σκοπό τη διεξαγωγή ενός διαγωνισμού για την επίλυση ενός προβλήματος. Στην πραγματικότητα έχει καταστήσει προσβάσιμο ένα σημαντικό σύνολο δεδομένων σχετικά με τους πελάτες των δανειοληπτών της.

Μέσα στις παραμέτρους του προβλήματος αυτής της διπλωματικής εργασίας είναι τα δεδομένα για τα οποία η Dream Housing Finance έχει δώσει δημόσια πρόσβαση και θα χρησιμοποιηθούν για τη συγκεκριμένη μελέτη περίπτωσης.

4.4.2 Η εταιρία Dream Housing Finance

Η Dream Housing Finance αποτελεί μία εταιρεία που ασχολείται με όλα τα είδη στεγαστικών δανείων και έχει παρουσία σε όλες τις αστικές, ημιαστικές και αγροτικές περιοχές της Αμερικής. Η εταιρεία έχει αποτελέσει αντικείμενο αρκετών έργων επιστήμης δεδομένων, συμπεριλαμβανομένης της ανάλυσης πρόβλεψης δανείων και της πρόβλεψης ρίσκου για την πιστοληπτική ικανότητα χορήγησης δανείων. Η διαδικασία επιλογής δανείου της εταιρείας αυτοματοποιείται με βάση τα στοιχεία του πελάτη που παρέχονται κατά τη συμπλήρωση των ψηφιακών εγγράφων της αίτησης. Στόχος αυτών των έργων είναι η ανάπτυξη μοντέλων μηχανικής μάθησης που μπορούν να προβλέπουν με ακρίβεια την χορήγηση δανείων και να αυτοματοποιούν τη διαδικασία έγκρισής τους.

Η διερευνητική ανάλυση δεδομένων του συνόλου δεδομένων πραγματοποιήθηκε για την ανάλυση του πλαισίου του προβλήματος και τον εντοπισμό προτύπων και τάσεων στα δεδομένα. Το σύνολο δεδομένων που χρησιμοποιήθηκε σε αυτά τα έργα είναι δημόσια διαθέσιμο και περιλαμβάνει πληροφορίες σχετικά με ποσά δανείων, επιτόκια, στοιχεία δανειολήπτη και άλλες σχετικές μεταβλητές. Τα έργα έχουν φιλοξενηθεί σε διάφορες πλατφόρμες, συμπεριλαμβανομένων των κοινοτήτων της Kaggle και του GitHub, και έχουν χρησιμοποιηθεί για την παρουσίαση των δυνατοτήτων της επιστήμης δεδομένων και της μηχανικής μάθησης στον τραπεζικό τομέα.

4.4.3 Περιγραφή του προβλήματος

Σε συνεργασία με την εταιρία ανάλυσης δεδομένων Analytics Vidhya, η εταιρία Dream Housing Finance προχώρησε στη διεξαγωγή ενός διαγωνισμού με τη δημοσίευση στοιχείων σχετικά με τα δάνεια στα οποία παρέχει βοήθεια σε Ιδιώτες πελάτες να αποκτήσουν.

Τα δεδομένα που συλλέχθηκαν και δημοσιεύθηκαν έχουν ορισμένα χαρακτηριστικά που σχετίζονται με δημογραφικές πληροφορίες σχετικά με τους πελάτες αντλήθηκαν από τις βάσεις δεδομένων της εταιρίας. Ο σκοπός του διαγωνισμού είναι να προσδιοριστεί η «επιλεξιμότητα» των δανείων με βάση τα αναφερόμενα δεδομένα. Τα αποτελέσματα του έργου αναρτήθηκαν προκειμένου να βαθμολογηθούν οι προβλέψεις, οι οποίες απέσπασαν ποσοστό ακρίβειας 79%, το οποίο ανταποκρίθηκε στις προσδοκίες της εταιρίας.

Η μέτρηση επιτυχίας του διαγωνισμού για την αξιολόγηση ήταν η «ακρίβεια» (accuracy). Για το λόγο αυτό το σύνολο δεδομένων εξισορροπήθηκε με σκοπό τα βέλτιστα αποτελέσματα με αυτή τη μετρική επιτυχίας.

5. Ανάλυση δεδομένων και ανίχνευση μεροληψίας

5.1 Περιγραφές και χαρακτηριστικά των συνόλων δεδομένων

Το σύνολο δεδομένων που διατίθενται για τη μελέτη, περιλαμβάνει ένα αρχείο, με τιμές διαχωρισμένες με κόμμα (csv: comma separated values), το αρχείο loan_data_set.csv.

Οι πληροφορίες που δίνονται στο παραπάνω σύνολο δεδομένων, μπορεί να είναι άλλες λιγότερο και άλλες περισσότερο σημαντικές στο να ανιχνευθεί η μεροληψία και η προκατάληψη ως προς συγκεκριμένα χαρακτηριστικά.

Τα δεδομένα της μελέτης εμπεριέχουν 614 γραμμές και 13 στήλες. Στον παρακάτω πίνακα γίνεται μία περιγραφική αναφορά σε όλες τις μεταβλητές που παρέχει το σύνολο δεδομένων.

| Περιγραφή | Μεταβλητή | Ερμηνεία |
|-----------|--|--|
| Loan_ID | Μοναδικός αριθμός αίτησης για κάθε δάνειο. | Ο μοναδικός αριθμός αίτησης δανείου εξυπηρετεί στον ταχύ εντοπισμό της σε διάφορα συστήματα. |
| Gender | Δείχνει το φύλο του αιτούντος για τη χορήγηση δανείου. | Αν και το φύλο δεν θα πρέπει να επηρεάζει τις αποφάσεις δανειοδότησης, η ανάλυση αυτής της μεταβλητής μπορεί να αποκαλύψει πιθανές προκαταλήψεις στη διαδικασία δανειοδότησης. |

| | | |
|-----------------|--|--|
| | | |
| Married | Διαδικός δείκτης της οικογενειακής κατάστασης του αιτούντος. | Οι έγγαμοι αιτούντες είναι πιθανό να θεωρούνται πιο ασφαλείς οικονομικά. |
| Dependents | Προσδιορίζει τον αριθμό των εξαρτώμενων μελών που δηλώνει ο αιτών. | Ο αριθμός των εξαρτώμενων προσώπων επηρεάζει το διαθέσιμο εισόδημα του αιτούντος, επηρεάζοντας την ικανότητά του να ανταποκρίνεται στις δανειακές υποχρεώσεις. |
| Education | Δείχνει το μορφωτικό επίπεδο του αιτούντος. | Το μορφωτικό επίπεδο είναι ένας κοινωνικοοικονομικός παράγοντας που μπορεί να επηρεάσει έμμεσα ή άμεσα την οικονομική του κατάσταση. |
| Self_Employed | Διαδικός δείκτης για το αν ο αιτών είναι αυτοαπασχολούμενος. | Η κατάσταση αυτοαπασχόλησης μπορεί να επηρεάσει τη σταθερότητα του εισοδήματος, επηρεάζοντας ενδεχομένως την έγκριση δανείου. |
| ApplicantIncome | Αντιπροσωπεύει το εισόδημα του αιτούντος για τη χορήγηση δανείου. | Η μεταβλητή αυτή συμβάλλει στη μέτρηση της οικονομικής ικανότητάς του |

| | | |
|-------------------|---|--|
| | | αιτούντος, επηρεάζοντας την ικανότητά του να αποπληρώσει το δάνειο. |
| CoapplicantIncome | Δείχνει το εισόδημα του συνυποψηφίου (εάν υπάρχει). | Η μεταβλητή αυτή παρέχει πληροφορίες σχετικά με το πρόσθετο εισόδημα του συνυποψηφίου δανειοδότησης, επηρεάζοντας τη συνολική οικονομική κατάσταση που εξετάζεται κατά τη διάρκεια της αίτησης δανείου. |
| LoanAmount | Δηλώνει το χρηματικό ποσό που ζητήθηκε για το δάνειο. | Το μέγεθος του δανείου που έχει χορηγηθεί είναι το ποσό που αντιστοιχεί στο ποσό του δανείου. Σηματοδοτεί τη συνολική οικονομική απαίτηση του αιτούντος και αποτελεί κρίσιμο παράγοντα για τον προσδιορισμό του κινδύνου και της σκοπιμότητας του δανείου. |
| Loan_Amount_Term | Προσδιορίζει τη διάρκεια του δανείου. | Αυτή η κατηγορική μεταβλητή ενημερώνει για το χρονικό πλαίσιο κατά το οποίο το δάνειο είναι διαρθρωμένο για αποπληρωμή, επηρεάζοντας το μηνιαίο ποσό αποπληρωμής. |

| | | |
|----------------|--|---|
| | | |
| Credit_History | Διαδικός δείκτης του κατά πόσον το πιστωτικό ιστορικό του αιτούντος πληροί τις κατευθυντήριες γραμμές. | Ένα θετικό πιστωτικό ιστορικό επηρεάζει σημαντικά την έγκριση δανείου, καθιστώντας τη μεταβλητή αυτή βασικό παράγοντα για την αξιολόγηση της πιστοληπτικής ικανότητας ενός αιτούντος. |
| Property_Area | Αντιπροσωπεύει την αστική, ημιαστική ή αγροτική τοποθεσία του ακινήτου για το οποίο πραγματοποιείται η αίτηση του δανείου. | Η τοποθεσία του ακινήτου είναι ένας κρίσιμος προσδιοριστικός παράγοντας, ο οποίος αντανάκλα τον κίνδυνο που συνδέεται με το ακίνητο και τις τοπικές οικονομικές συνθήκες. |
| Loan_Status | Διαδικός δείκτης για το αν το δάνειο εγκρίθηκε ή όχι. | Η τελική μεταβλητή αποτελέσματος, η οποία αντικατοπτρίζει την επιτυχία ή την αποτυχία της αίτησης δανείου με βάση διάφορους παράγοντες. |

Πίνακας 3: Περιγραφή των δεδομένων

Το παρεχόμενο σύνολο δεδομένων δανείων περιλαμβάνει ένα μείγμα αριθμητικών και κατηγορικών μεταβλητών, καθεμία από τις οποίες προσφέρει μοναδικές πληροφορίες για το οικονομικό προφίλ των αιτούντων. Οι αριθμητικές μεταβλητές, όπως "ApplicantIncome", "CoapplicantIncome", "LoanAmount" και "Loan_Amount_Term", παρέχουν μια ποσοτική εικόνα της οικονομικής ικανότητας

των αιτούντων και των δανειακών απαιτήσεων. Εν τω μεταξύ, οι κατηγορικές μεταβλητές, όπως "Gender", "Married", "Dependents", "Education", "Self_Employed", "Property_Area" και "Credit_History", παρουσιάζουν κοινωνικοοικονομικά χαρακτηριστικά ζωτικής σημασίας για την κατανόηση του ιστορικού των αιτούντων. Η δυαδική μεταβλητή "Loan_Status" χρησιμεύει ως το τελικό αποτέλεσμα, αντικατοπτρίζοντας την έγκριση ή την απόρριψη του δανείου.

Κατά τη διάκριση πιθανών προκαταλήψεων και δικαιοσύνης στα εγκεκριμένα δάνεια, ορισμένες μεταβλητές αποκτούν εξέχουσα σημασία. Το πιστωτικό ιστορικό ("Credit_History") αναδεικνύεται σε κρίσιμο προσδιοριστικό παράγοντα, επηρεάζοντας άμεσα την έγκριση δανείου. Άλλοι κοινωνικοοικονομικοί παράγοντες, όπως "ApplicantIncome", "Education" και "Property_Area", θα μπορούσαν ακούσια να εισάγουν μεροληψία, αν δεν εξεταστούν προσεκτικά.

Η αξιολόγηση αυτών των μεταβλητών, ιδίως στο πλαίσιο του φύλου, της οικογενειακής κατάστασης και των εξαρτώμενων προσώπων, καθίσταται υψίστης σημασίας για την αποκάλυψη τυχόν συστημικών προκαταλήψεων στις διαδικασίες έγκρισης δανείων. Μέσω της συνολικής ανάλυσης, τα πρότυπα εντός αυτών των μεταβλητών μπορούν να αποκαλύψουν ανισότητες που θα μπορούσαν να υποδείξουν την παρουσία προκαταλήψεων και να καθοδηγήσουν μέτρα για τη διασφάλιση της δικαιοσύνης στις εγκρίσεις δανείων.

5.2 Επεξεργασία και καθαρισμός δεδομένων

Έπειτα από εκτενή περιγραφή των χαρακτηριστικών των δεδομένων, στο επόμενο στάδιο είναι απαραίτητη η επεξεργασία τους προκειμένου να επιτευχθεί η σωστή ανάλυσή τους.

Το πρώτο αναγκαίο βήμα είναι η εισαγωγή τους στην πλατφόρμα Google Colab, την οποία θα χρησιμοποιήσουμε. Αφού έχουμε προχωρήσει σε ανέβασμα (uploading) των δεδομένων σε σχετικό φάκελο στο Google Drive, εισάγουμε τα δεδομένα.

```

from google.colab import drive
drive.mount("/content/drive")

path1='/content/drive/MyDrive/Colab Notebooks'

df= pd.read_csv('/content/drive/MyDrive/loan_data_set.csv')
df.head()

```

Στη συνέχεια γίνεται εμφάνιση των δεδομένων προκειμένου να γίνει κατανοητή η κατανομή τους.

```

df= pd.read_csv('/content/drive/MyDrive/loan_data_set.csv')
df.head()

```

| | Loan_ID | Gender | Married | Dependents | Education | Self_Employed | ApplicantIncome | CoapplicantIncome | LoanAmount | Loan_Ar |
|---|----------|--------|---------|------------|--------------|---------------|-----------------|-------------------|------------|---------|
| 0 | LP001002 | Male | No | 0 | Graduate | No | 5849 | 0.0 | NaN | |
| 1 | LP001003 | Male | Yes | 1 | Graduate | No | 4583 | 1508.0 | 128.0 | |
| 2 | LP001005 | Male | Yes | 0 | Graduate | Yes | 3000 | 0.0 | 66.0 | |
| 3 | LP001006 | Male | Yes | 0 | Not Graduate | No | 2583 | 2358.0 | 120.0 | |
| 4 | LP001008 | Male | No | 0 | Graduate | No | 6000 | 0.0 | 141.0 | |

Εικόνα 10. Κατανομή των δεδομένων

Ακολουθεί η αποτύπωση του σχήματος των δεδομένων, καθώς και ο έλεγχος κενών τιμών.

```

# Έλεγχος κενών τιμών
print("Σύνολο δεδομένων: "+str(df.shape))
print("Κενές τιμές: \n"+str(df.isnull().sum()))

```

```

Σύνολο δεδομένων: (614, 13)
Κενές τιμές:
Loan_ID          0
Gender            13
Married           3
Dependents       15
Education         0
Self_Employed    32
ApplicantIncome  0
CoapplicantIncome 0
LoanAmount       22
Loan_Amount_Term 14
Credit_History   50
Propertv Area    0

```

Εικόνα 11. Σχήμα των δεδομένων & αποτύπωση κενών τιμών

Παρατηρείται ότι υπάρχουν 614 γραμμές και 13 στήλες στο σύνολο των δεδομένων. Αναφορικά με τις κενές τιμές, αυτές εντοπίζονται στις περισσότερες στήλες για αυτό κρίνεται απαραίτητη η αντικατάστασή τους.

```
# α. λίστα με κενές τιμές
missing_values = ["n/a", "na", "--", 999,9999]
# β. Replace
df.replace(to_replace = missing_values, value = np.nan, inplace = True)
# γ. Drop NaNs
df.dropna(inplace=True)
# δ. Reindex για να μην μείνουν κενά στο index
df.reset_index(drop=True, inplace=True)
# Έλεγχος τιμών
print("Σύνολο δεδομένων: "+str(df.shape))
```

Σύνολο δεδομένων: (480, 13)

Εικόνα 12. Αντικατάσταση κενών τιμών

Στο επόμενο στάδιο επεξεργασίας των δεδομένων είναι απαραίτητη η αφαίρεση των διπλών εγγραφών καθώς και των στηλών που δεν χρήζουν επεξεργασίας στην μελέτη με στόχο την αποτελεσματικότερη μορφή των δεδομένων για την ανάλυσή τους.

```
# Έλεγχος duplicates
df.duplicated().sum()

# Αφαίρεση duplicates
df = df.drop_duplicates()
```

```
df = df.drop('Loan_ID', axis=1)
df.head()
```

| | Gender | Married | Dependents | Education | Self_Employed | ApplicantIncome | CoapplicantIncome | LoanAmount | Loan_Amount_Term |
|---|--------|---------|------------|--------------|---------------|-----------------|-------------------|------------|------------------|
| 0 | Male | Yes | 1 | Graduate | No | 4583 | 1508.0 | 128.0 | 360.0 |
| 1 | Male | Yes | 0 | Graduate | Yes | 3000 | 0.0 | 66.0 | 360.0 |
| 2 | Male | Yes | 0 | Not Graduate | No | 2583 | 2358.0 | 120.0 | 360.0 |
| 3 | Male | No | 0 | Graduate | No | 6000 | 0.0 | 141.0 | 360.0 |
| 4 | Male | Yes | 2 | Graduate | Yes | 5417 | 4196.0 | 267.0 | 360.0 |

Εικόνα 13. Τελική μορφή των δεδομένων πριν την ανάλυση

Έχοντας ολοκληρώσει την επεξεργασία και τον καθαρισμό των δεδομένων, το τελικό σχήμα αποτελείται από 480 γραμμές και 12 στήλες, έχοντας αφαιρέσει τη στήλη "Loan_ID1". Στην επόμενη ενότητα διενεργείται μία αρχική διερευνητική ανάλυση των δεδομένων με οπτικοποίηση διάφορων αποτελεσμάτων.

5.3 Διερευνητική ανάλυση δεδομένων


Αυτό το υποκεφάλαιο αποτελεί μια εξερευνητική ανάλυση των δεδομένων, με στόχο την ανάδειξη των σημαντικών παραγόντων μέσω οπτικών αναπαραστάσεων. Χρησιμοποιείται η πλατφόρμα Google Colab για την εκτέλεση της ανάλυσης.

Αρχικά, φορτώνονται τα δεδομένα, και στη συνέχεια χρησιμοποιούνται ερωτήματα για να δημιουργηθούν γραφήματα που απεικονίζουν τις σχέσεις μεταξύ των μεταβλητών.

Το κεφάλαιο χωρίζεται σε υποενότητες, καθεμία από τις οποίες ανταποκρίνεται σε ένα ερώτημα και παρέχει ανάλογα γραφήματα και αναλύσεις.

5.3.1 Κατανομή εγκεκριμένων και μη εγκεκριμένων δανείων

Σχέση εγκεκριμένων & μη εγκεκριμένων δανείων




Εικόνα 14. Σχέση εγκεκριμένων και μη εγκεκριμένων δανείων

Το διάγραμμα παρέχει μια σαφή επισκόπηση της σχέσης μεταξύ εγκεκριμένων ("Y") και μη εγκεκριμένων ("N") δανείων. Είναι προφανές ότι η πλειονότητα των δανείων στο σύνολο δεδομένων έχει εγκριθεί. Το διάγραμμα αναδεικνύει αποτελεσματικά την κατανομή της κατάστασης έγκρισης του δανείου, παρουσιάζοντας τα σχετικά ποσοστά των εγκεκριμένων και μη εγκεκριμένων δανείων. Αυτό υποδηλώνει μια γενικά θετική τάση στην έγκριση δανείων στο συγκεκριμένο σύνολο δεδομένων.

Ωστόσο, για μία πιο αποχρωματισμένη ανάλυση, θα ήταν ωφέλιμο να εμβαθύνουμε σε συγκεκριμένους παράγοντες που επηρεάζουν τις αποφάσεις για δάνεια, όπως το εισόδημα, το πιστωτικό ιστορικό ή άλλα σχετικά χαρακτηριστικά. Αυτή η αρχική παρατήρηση θέτει τις βάσεις για μια πιο εμπειριστατωμένη διερεύνηση του συνόλου

δεδομένων για την αποκάλυψη μοτίβων και παραγόντων που συμβάλλουν στα αποτελέσματα της έγκρισης δανείων.

5.3.2 Κατανομή ποσών δανείων

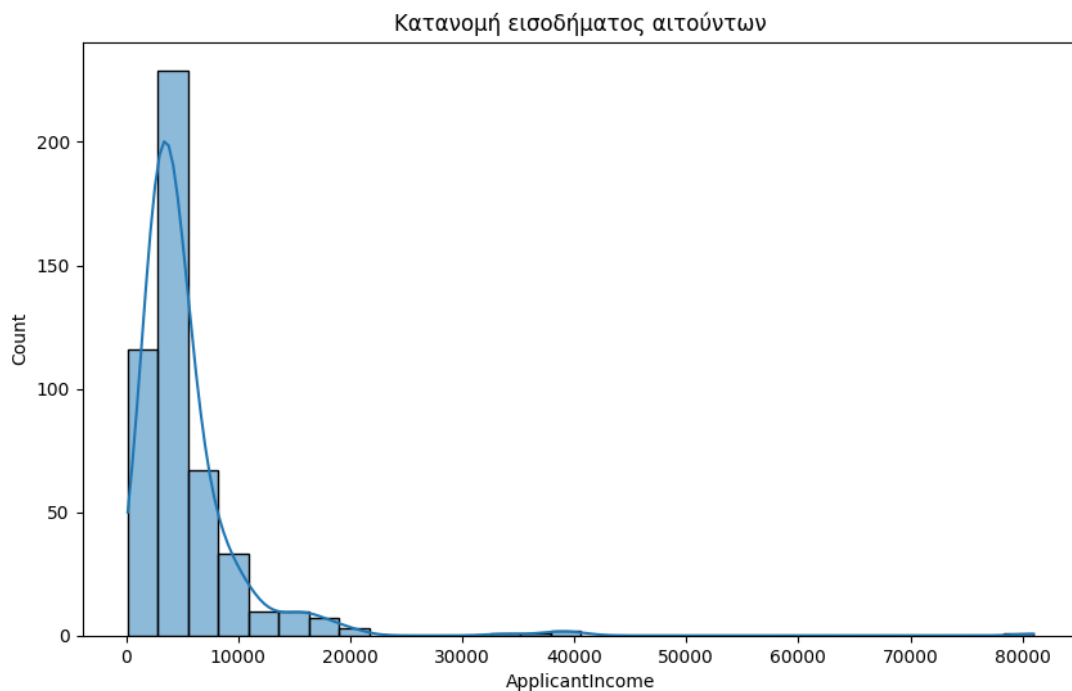


Εικόνα 15. Κατανομή ποσών των δανείων

Το παραπάνω ιστόγραμμα προσφέρει μια οπτική αναπαράσταση της κατανομής των ποσών δανείων στο σύνολο δεδομένων. Αξίζει να σημειωθεί ότι η κατανομή είναι δεξιά κεκλιμένη, υποδεικνύοντας ότι η πλειονότητα των δανείων εμπίπτει σε χαμηλότερα ποσά, ενώ η μεγάλη ουρά στα δεξιά υποδηλώνει λιγότερες περιπτώσεις υψηλότερων ποσών δανείων. Η εξέχουσα κορυφή υποδηλώνει ένα ευρύ φάσμα ποσών δανείων που εμφανίζονται συχνότερα, υποδηλώνοντας συγκέντρωση δανείων γύρω από συγκεκριμένες τιμές. Η παρουσία ακραίων τιμών, που είναι ορατή στην εκτεταμένη ουρά, υποδηλώνει περιπτώσεις δανείων με εξαιρετικά υψηλά ποσά, γεγονός που δικαιολογεί περαιτέρω έλεγχο για την ολοκληρωμένη κατανόηση αυτών των εξαιρετικών περιπτώσεων.

Η συνοδευτική εκτίμηση πυκνότητας πυρήνα παρέχει μια εξομαλυμένη απεικόνιση της διασποράς της κατανομής, επιτρέποντας τη συνεχή αξιολόγηση των ποσών των δανείων. Αυτές οι αρχικές παρατηρήσεις παρέχουν πολύτιμες πληροφορίες για τις επακόλουθες αναλύσεις, οι οποίες μπορεί να περιλαμβάνουν την τμηματοποίηση των δεδομένων με βάση μεταβλητές όπως το εισόδημα, το πιστωτικό ιστορικό ή ο σκοπός του δανείου για την αποκάλυψη πρόσθετων προτύπων και παραγόντων που επηρεάζουν τα ποσά των δανείων.

5.3.3 Κατανομή εισοδήματος αιτούντων



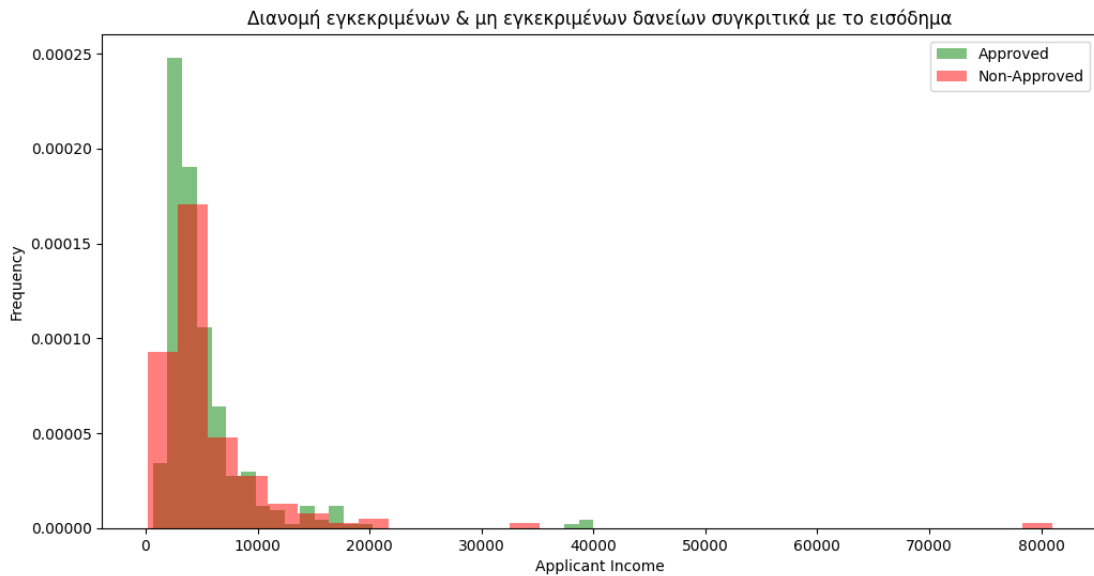
Εικόνα 16. Κατανομή εισοδήματος αιτούντων

Το παραπάνω ιστόγραμμα παρουσιάζει μια οπτική επισκόπηση της κατανομής των εισοδημάτων των αιτούντων εντός του συνόλου δεδομένων. Από την αναπαράσταση αυτή μπορούν να εξαχθούν διάφορες αξιοσημείωτες παρατηρήσεις.

Πρώτον, η κατανομή φαίνεται να έχει δεξιά κλίση, υποδεικνύοντας ότι η πλειονότητα των αιτούντων έχει σχετικά χαμηλότερα εισοδήματα, με μια μεγαλύτερη ουρά στα δεξιά που υποδηλώνει την παρουσία λίγων ατόμων με υψηλότερα εισοδήματα.

Δεύτερον, η εξέχουσα κορυφή στο ιστόγραμμα υποδηλώνει την ύπαρξη κοινών εισοδηματικών περιοχών μεταξύ των αιτούντων, γεγονός που υποδηλώνει ότι ένα σημαντικό τμήμα του συνόλου δεδομένων εμπίπτει σε συγκεκριμένα εισοδηματικά κλιμάκια.

5.3.3 Διανομή έγκρισης και απόρριψης δανείων συγκριτικά με το εισόδημα

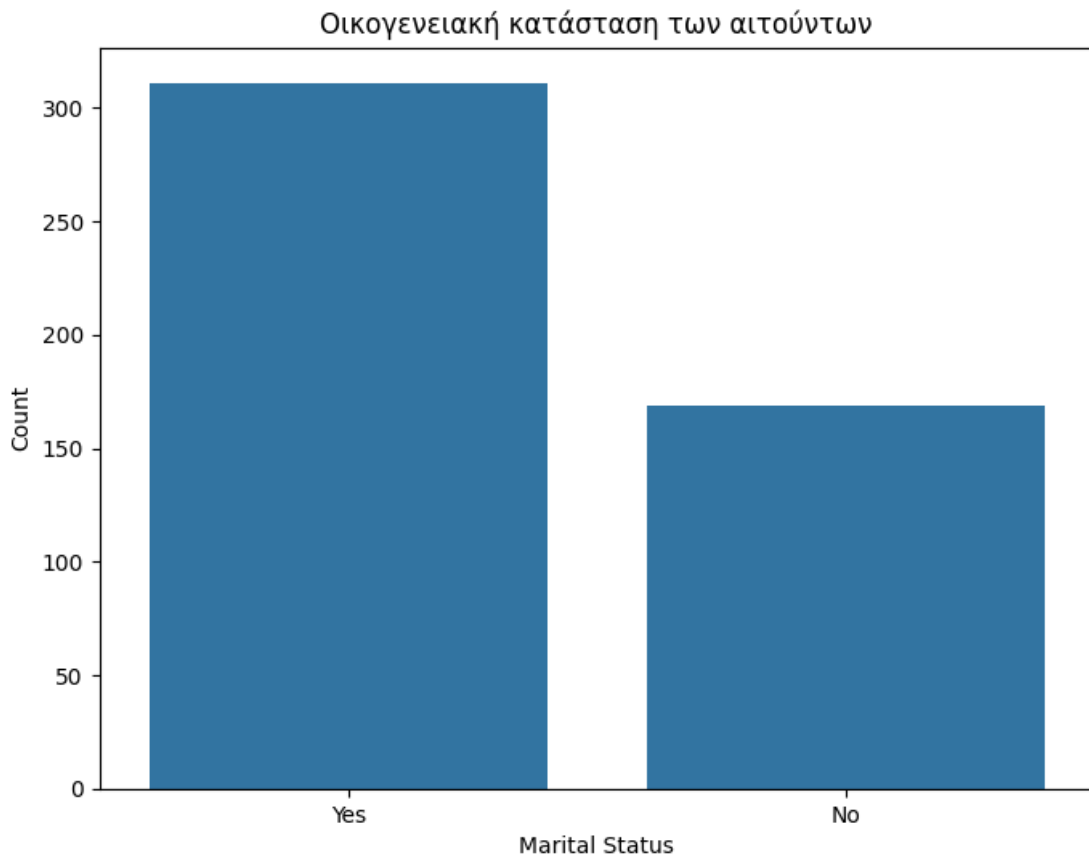


Εικόνα 16. Διανομή έγκρισης και απόρριψης δανείων συγκριτικά με το εισόδημα

Το παραπάνω ιστόγραμμα παρέχει μια συγκριτική ανάλυση της κατανομής του εισοδήματος για τα εγκεκριμένα και τα μη εγκεκριμένα δάνεια. Οι πράσινες ράβδοι απεικονίζουν την κατανομή των εισοδημάτων για τα εγκεκριμένα δάνεια, ενώ οι κόκκινες ράβδοι απεικονίζουν την κατανομή για τα μη εγκεκριμένα δάνεια.

Είναι αξιοσημείωτο ότι η πλειονότητα τόσο των εγκεκριμένων όσο και των μη εγκεκριμένων δανείων φαίνεται να έχει χαμηλότερα εισοδήματα, με μια πιθανή στροφή προς τα δεξιά, που υποδηλώνει λίγα άτομα με υψηλότερα εισοδήματα. Αυτή η απεικόνιση προσφέρει έναν συνοπτικό τρόπο αντιπαραβολής των εισοδηματικών προφίλ των αιτούντων με βάση την κατάσταση έγκρισης του δανείου.

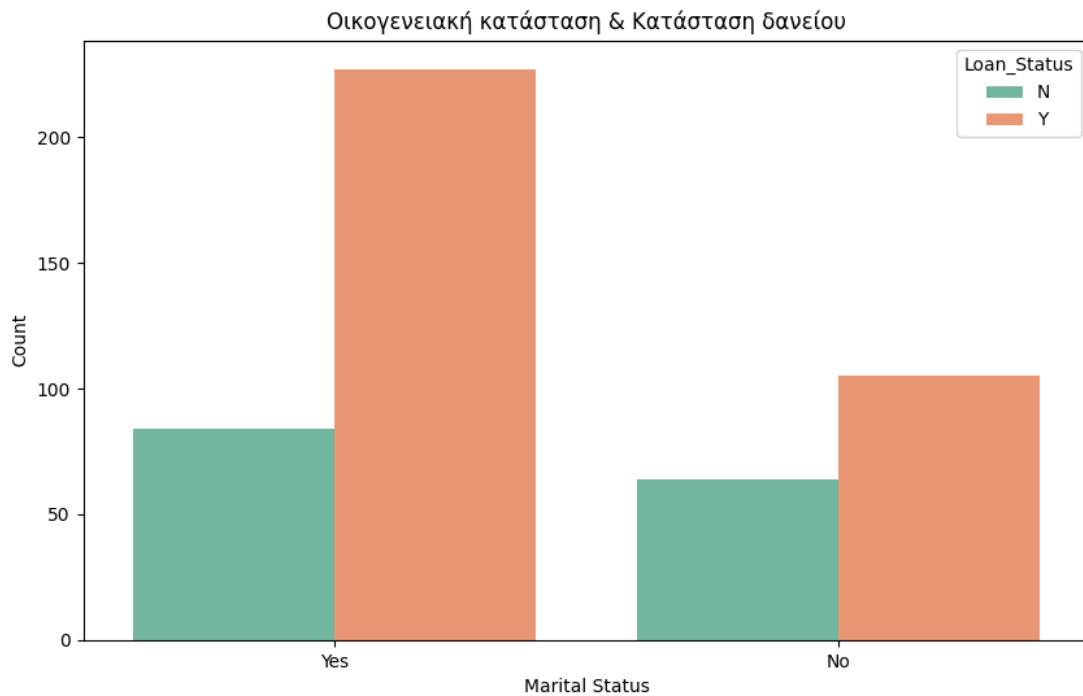
5.3.4 Οικογενειακή κατάσταση αιτούντων



Εικόνα 17. Οικογενειακή κατάσταση αιτούντων

Το διάγραμμα καταμέτρησης που απεικονίζει την οικογενειακή κατάσταση των αιτούντων αποκαλύπτει μια αξιοσημείωτη επικράτηση των παντρεμένων ατόμων στο σύνολο των δεδομένων. Αυτό ευθυγραμμίζεται με τις συμβατικές προσδοκίες, καθώς τα παντρεμένα ζευγάρια συχνά διεκπεραιώνουν από κοινού διάφορες οικονομικές προσπάθειες, συμπεριλαμβανομένης της ιδιοκτησίας σπιτιού, της εκπαίδευσης ή των οικογενειακών δαπανών.

Ο υψηλότερος αριθμός των έγγαμων αιτούντων υποδηλώνει τη δυναμική σημασία της οικογενειακής κατάστασης στον επηρεασμό των οικονομικών αποφάσεων και της ανάγκης για δάνεια. Η παρατήρηση αυτή έχει συνέπειες για τα χρηματοπιστωτικά ιδρύματα που διενεργούν αξιολογήσεις κινδύνου, καθώς η οικογενειακή κατάσταση θα μπορούσε να είναι βασικός παράγοντας που επηρεάζει την οικονομική σταθερότητα και την ικανότητα αποπληρωμής των δανείων ενός αιτούντος.




Εικόνα 18. Σύγκριση οικογενειακής κατάστασης και κατάστασης αιτούντων

Το παραπάνω διάγραμμα παρέχει μια οπτική σύγκριση της κατάστασης έγκρισης δανείων με βάση την οικογενειακή κατάσταση των αιτούντων. Από την αναπαράσταση αυτή μπορούν να εξαχθούν ορισμένες βασικές παρατηρήσεις. Αρχικά, εντός της κατηγορίας των παντρεμένων, υπάρχει ένας σημαντικός αριθμός τόσο εγκεκριμένων όσο και μη εγκεκριμένων δανείων, υποδεικνύοντας ένα ποικίλο οικονομικό τοπίο μεταξύ των παντρεμένων ατόμων. Ενδιαφέρον παρουσιάζει το γεγονός ότι για τους άγαμους, ο αριθμός των εγκεκριμένων δανείων εμφανίζεται σχετικά υψηλότερος από τον αριθμό των μη εγκεκριμένων δανείων. Αυτό υποδηλώνει ότι η οικογενειακή κατάσταση μπορεί να επηρεάζει την πιθανότητα έγκρισης δανείου, με τους άγαμους αιτούντες να εμφανίζουν κάπως υψηλότερο ποσοστό έγκρισης. Ωστόσο, για την εξαγωγή πιο οριστικών συμπερασμάτων, θα ήταν απαραίτητη μια βαθύτερη εμβάθυνση στο σύνολο δεδομένων, λαμβάνοντας ενδεχομένως υπόψη παράγοντες όπως το εισόδημα, το είδος της απασχόλησης ή το πιστωτικό ιστορικό.

Επιπλέον, η οπτικοποίηση υπογραμμίζει τη σημασία της οικογενειακής κατάστασης ως δυνητικού παράγοντα στις διαδικασίες έγκρισης δανείων. Τα χρηματοπιστωτικά ιδρύματα ενδέχεται να χρειαστεί να προσαρμόσουν τις αξιολογήσεις κινδύνου τους ώστε να λαμβάνουν υπόψη τα διαφορετικά οικονομικά προφίλ τόσο των παντρεμένων

όσο και των άγαμων αιτούντων. Περαιτέρω διερεύνηση, ίσως μέσω στατιστικών αναλύσεων, μπορεί να ρίξει φως στη στατιστική σημασία αυτών των παρατηρούμενων τάσεων και να συμβάλει σε μια πιο διαφοροποιημένη κατανόηση του τρόπου με τον οποίο η οικογενειακή κατάσταση αλληλεπιδρά με τα αποτελέσματα της έγκρισης δανείων.

5.3.5 Κατανομή περιοχών

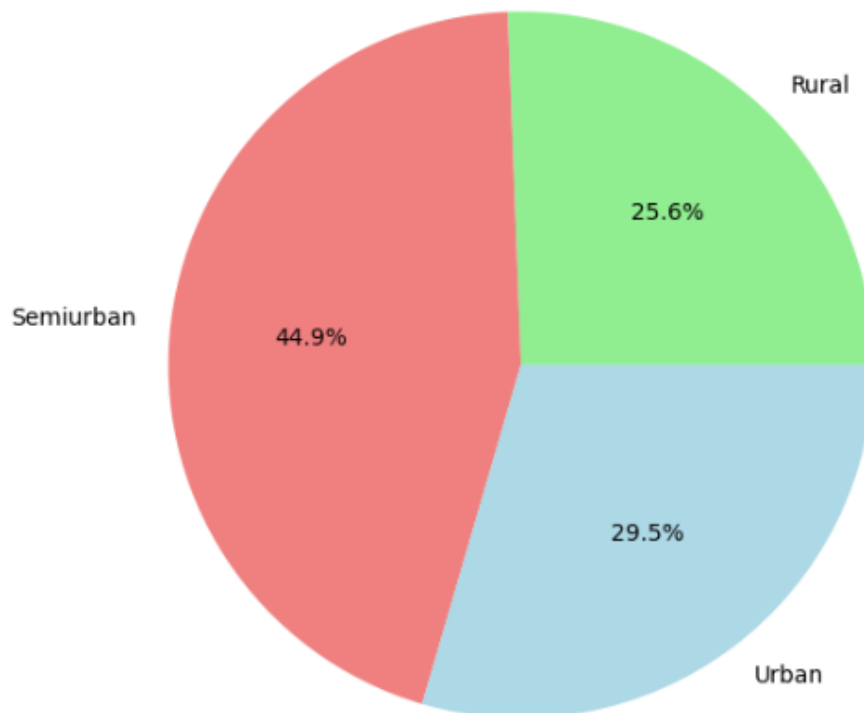


Εικόνα 18. Κατανομή περιοχών ακινήτων των δανείων

Το κυκλικό διάγραμμα απεικονίζει την κατανομή των περιοχών ιδιοκτησίας μεταξύ των αιτούντων δάνεια, επισημαίνοντας τρεις κύριες κατηγορίες: "Αστική", "Ημιαστική" και "Αγροτική". Αξίζει να σημειωθεί ότι η πλειονότητα των αιτούντων φαίνεται να προέρχεται από "ημιαστικές" περιοχές, αποτελώντας σημαντικό μέρος της πίτας. Οι "αστικές" περιοχές συνεισφέρουν επίσης σημαντικά, ενώ οι "αγροτικές" περιοχές αντιπροσωπεύουν ένα μικρότερο αλλά και πάλι αξιοσημείωτο κλάσμα. Αυτή η κατανομή παρέχει πληροφορίες σχετικά με τη γεωγραφική ποικιλομορφία των αιτούντων δάνεια, υποδεικνύοντας ότι ένα σημαντικό ποσοστό κατοικεί σε ημιαστικές περιοχές. Η παρατήρηση αυτή θα μπορούσε να έχει επιπτώσεις για τα χρηματοπιστωτικά ιδρύματα που προσαρμόζουν τα δανειακά προϊόντα και τις υπηρεσίες τους ώστε να ανταποκρίνονται στις συγκεκριμένες ανάγκες και τα πλαίσια των αιτούντων από διαφορετικές περιοχές ιδιοκτησίας.

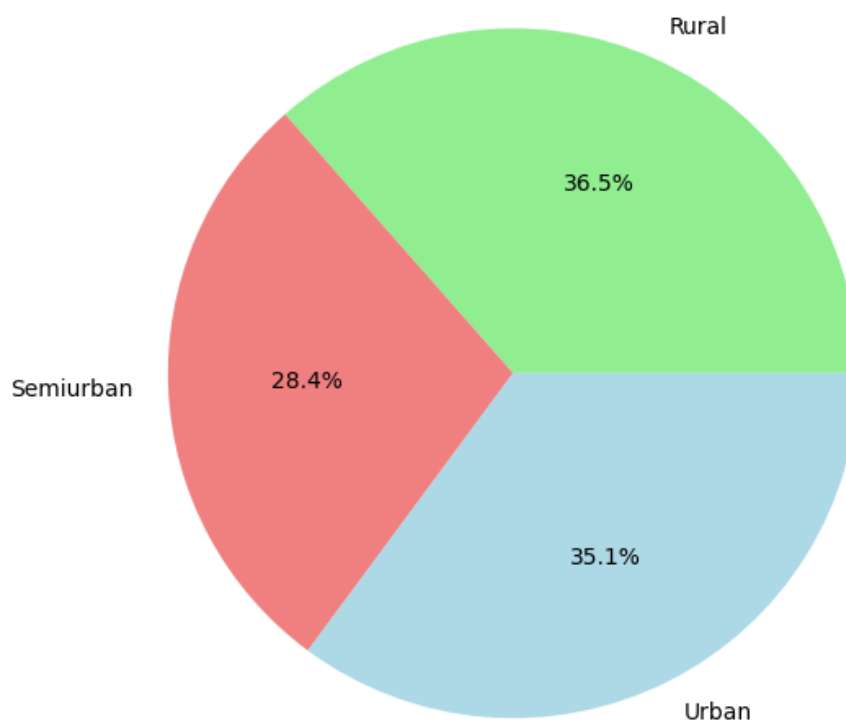
Επιπλέον, η κατανόηση της κατανομής των περιοχών ιδιοκτησίας είναι ζωτικής σημασίας για την αξιολόγηση του κοινωνικοοικονομικού τοπίου των αιτούντων. Τα χρηματοπιστωτικά ιδρύματα μπορούν να εξετάσουν το ενδεχόμενο να προσαρμόσουν τα μοντέλα αξιολόγησης κινδύνου και τις στρατηγικές μάρκετινγκ με βάση τα μοναδικά χαρακτηριστικά που σχετίζονται με τους αιτούντες από διαφορετικές περιοχές. Η κυριαρχία των "ημιαστικών" περιοχών προκαλεί ερωτήματα σχετικά με τις συγκεκριμένες οικονομικές δραστηριότητες ή τους παράγοντες του τρόπου ζωής που επικρατούν σε αυτές τις περιοχές και ενδέχεται να επηρεάσουν τη συμπεριφορά αναζήτησης δανείων.

Έγκριση δανείου ανά περιοχή ακινήτου



Εικόνα 19. Έγκριση δανείου ανά περιοχή ακινήτου

Απόρριψη δανείου ανά περιοχή ακινήτου



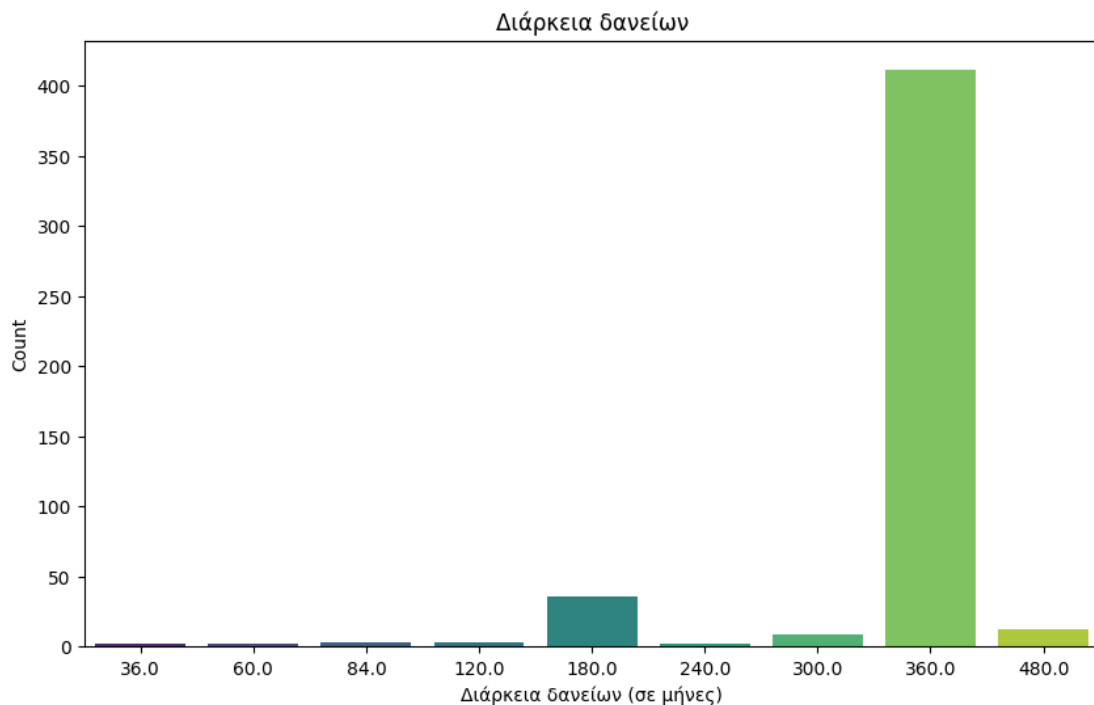
Εικόνα 20. Απόρριψη δανείων ανά περιοχή

Τα δύο παραπάνω διαγράμματα προσφέρουν μια μοναδική οπτική για τα αποτελέσματα της έγκρισης δανείων με βάση την περιοχή των ακινήτων. Στο διάγραμμα που απεικονίζει τα εγκεκριμένα δάνεια, η κατανομή είναι αρκετά σταθερή σε όλες τις περιοχές ιδιοκτησίας, με το "ημιαστικό" να προηγείται, ακολουθούμενο στενά από το "αστικό" και το "αγροτικό". Η ισορροπία αυτή υποδηλώνει ότι τα ποσοστά έγκρισης δανείων είναι σχετικά ομοιόμορφα στις διάφορες περιοχές ιδιοκτησίας. Αντίθετα, το κυκλικό διάγραμμα που αντιπροσωπεύει τα απορριφθέντα δάνεια αποκαλύπτει ενδιαφέρουσες διακυμάνσεις. Ειδικότερα, το ποσοστό των απορριφθέντων δανείων είναι σχετικά υψηλότερο στις "αγροτικές" περιοχές σε σύγκριση με τις "ημιαστικές" και "αστικές". Η παρατήρηση αυτή προκαλεί την περιέργεια για τις ειδικές προκλήσεις ή τους παράγοντες που συμβάλλουν σε υψηλότερο ποσοστό απόρριψης δανείων σε αγροτικές περιοχές.

Αυτές οι απεικονίσεις μεταφέρουν μια διαφοροποιημένη οπτική σχετικά με την αλληλεπίδραση μεταξύ της περιοχής ακινήτου και των αποτελεσμάτων έγκρισης

δανείου. Η ομοιόμορφη κατανομή των εγκεκριμένων δανείων υποδηλώνει ένα γενικά συνεπές τοπίο δανεισμού, ενώ το υψηλότερο ποσοστό απόρριψης στις αγροτικές περιοχές προτρέπει σε περαιτέρω διερεύνηση των κοινωνικοοικονομικών δυναμικών που επηρεάζουν τις εγκρίσεις δανείων. Τα χρηματοπιστωτικά ιδρύματα θα μπορούσαν να λάβουν υπόψη τους τα ευρήματα αυτά κατά τη χάραξη στοχευμένων στρατηγικών για διαφορετικές περιοχές ιδιοκτησίας, αναγνωρίζοντας τους ξεχωριστούς παράγοντες που θα μπορούσαν να επηρεάσουν τα αποτελέσματα των αιτήσεων δανείων.

5.3.6 Διάρκεια δανείων



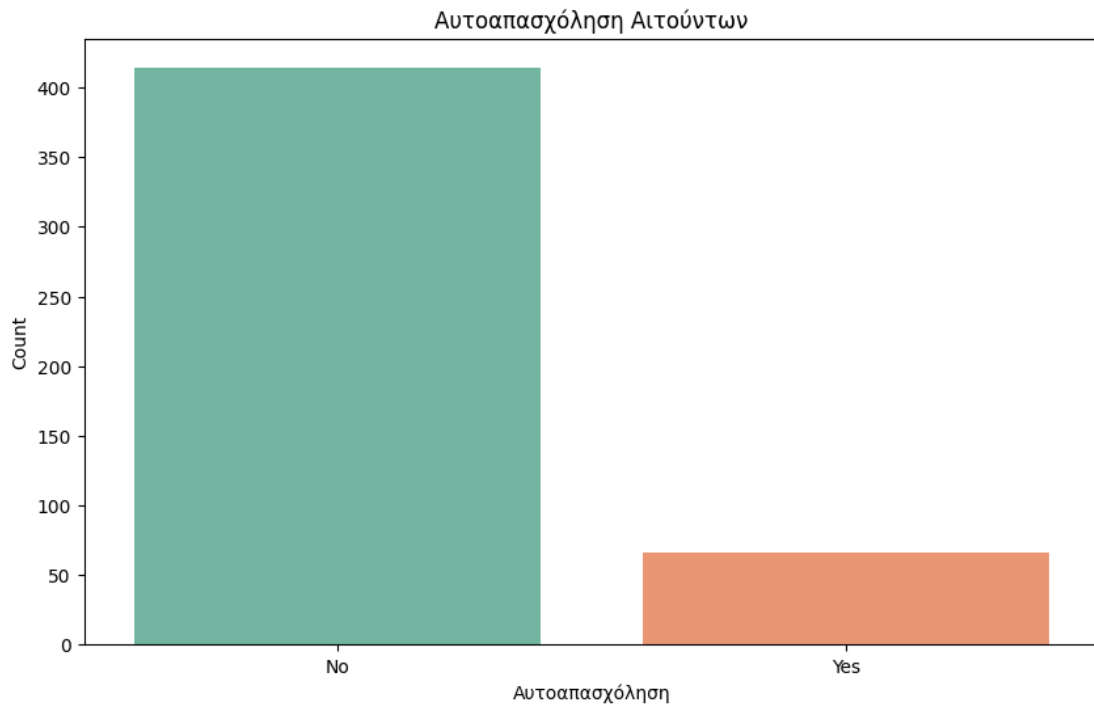
Εικόνα 20. Διάρκεια δανείων

Το ραβδόγραμμα παρέχει μια σαφή απεικόνιση της διάρκειας των δανείων στο σύνολο των δεδομένων, παρουσιάζοντας την κατανομή των ποσών των δανείων σε διάφορα χρονικά πλαίσια που υπολογίζονται σε μήνες. Η πλειονότητα των δανείων έχει τυπική διάρκεια, η οποία πιθανώς αντιστοιχεί στις συμβατικές δομές δανείων που προσφέρονται συνήθως από τα χρηματοπιστωτικά ιδρύματα. Είναι προφανές ότι τα δάνεια μικρότερης διάρκειας είναι λιγότερο διαδεδομένα, ενώ τα δάνεια μεγαλύτερης διάρκειας συμβάλλουν επίσης στη συνολική κατανομή. Η παρατήρηση αυτή

υποδηλώνει ότι οι δανειολήπτες εντός του συνόλου δεδομένων επιλέγουν γενικά τυποποιημένες ή πιο παραδοσιακές διάρκειες δανείων, ενδεχομένως επηρεαζόμενοι από παράγοντες όπως η ικανότητα αποπληρωμής, οι οικονομικοί στόχοι ή η φύση των ζητούμενων δανείων.

Η κατανόηση της κατανομής της διάρκειας των δανείων είναι ζωτικής σημασίας για τα χρηματοπιστωτικά ιδρύματα όσον αφορά την προσαρμογή των δανειακών προϊόντων ώστε να ευθυγραμμίζονται με τις προτιμήσεις και τους οικονομικούς στόχους των δανειοληπτών. Η επικράτηση των δανείων τυπικής διάρκειας υπογραμμίζει τη σημασία της προσφοράς ευέλικτων αλλά και τυποποιημένων δομών δανείων για την εξυπηρέτηση ενός ποικίλου φάσματος δανειοληπτών. Επιπλέον, η κατανομή προκαλεί έρευνες σχετικά με τους παράγοντες που επηρεάζουν τις επιλογές των δανειοληπτών όσον αφορά τις διάρκειες των δανείων.

5.3.7 Αυτοαπασχόληση αιτούντων

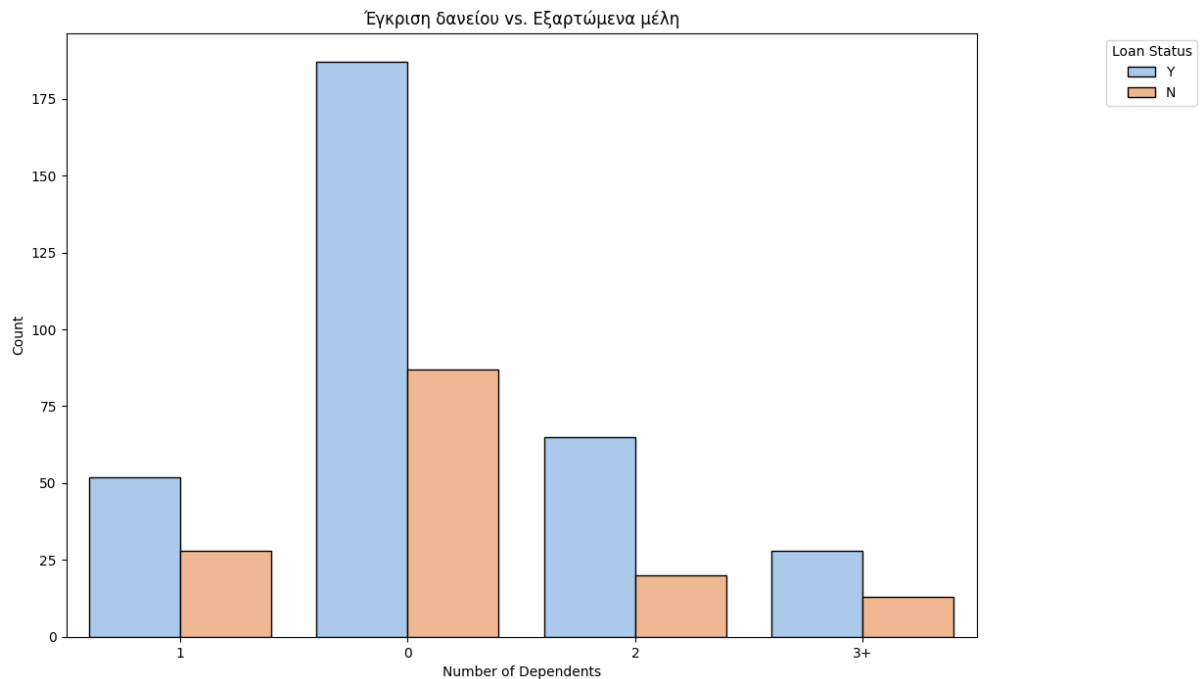


Εικόνα 21. Αυτοαπασχόληση αιτούντων

Το διάγραμμα παρέχει μια απεικόνιση της κατάστασης απασχόλησης των αιτούντων, εστιάζοντας ειδικά στην αυτοαπασχόληση. Αξίζει να σημειωθεί ότι η πλειονότητα των αιτούντων στο σύνολο δεδομένων φαίνεται να είναι μη αυτοαπασχολούμενοι, όπως υποδεικνύεται από την υψηλότερη καταμέτρηση της κατηγορίας "Όχι". Η παρατήρηση αυτή ευθυγραμμίζεται με τις ευρύτερες τάσεις της απασχόλησης, όπου παραδοσιακά ένα σημαντικό μέρος του πληθυσμού απασχολείται στην επίσημη απασχόληση και όχι στην αυτοαπασχόληση.

Η παρουσία ενός αξιοσημείωτου αριθμού στην κατηγορία "Ναι" υποδηλώνει σημαντική εκπροσώπηση των αυτοαπασχολούμενων ατόμων που αναζητούν δάνεια. Οι γνώσεις που προκύπτουν από αυτή την απεικόνιση προτρέπουν τα χρηματοπιστωτικά ιδρύματα να προσαρμόσουν τα δανειακά τους προϊόντα και τις στρατηγικές αξιολόγησης κινδύνου ώστε να λαμβάνουν υπόψη τους τα ποικίλα οικονομικά προφίλ που σχετίζονται τόσο με τους αυτοαπασχολούμενους όσο και με τους μη αυτοαπασχολούμενους αιτούντες.

5.3.8 Σύγκρισης έγκρισης δανείων και εξαρτώμενων μελών

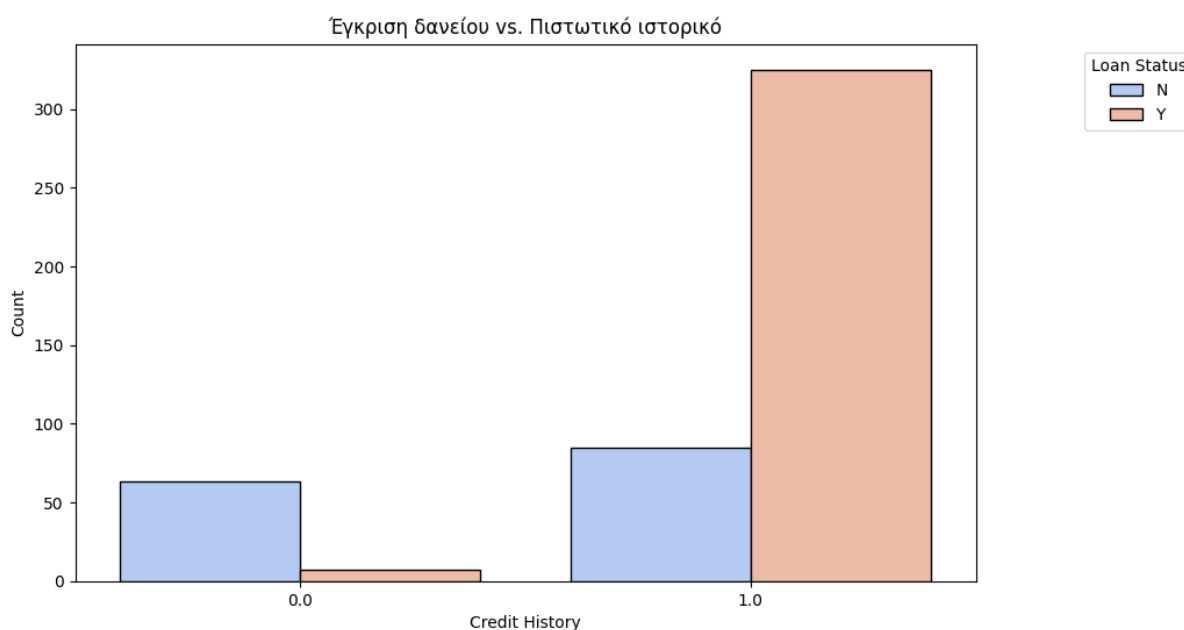


Εικόνα 22. Σύγκρισης έγκρισης δανείων και εξαρτώμενων μελών

Η παράθεση του διαγράμματος παρουσιάζει την κατάσταση έγκρισης δανείων όσον αφορά τον αριθμό των εξαρτώμενων μελών μεταξύ των αιτούντων. Αναδύεται ένα σαφές μοτίβο καθώς ο αριθμός των εγκεκριμένων δανείων φαίνεται να μειώνεται σταδιακά με την αύξηση του αριθμού των εξαρτώμενων μελών. Αντίθετα, ο αριθμός των απορριφθέντων δανείων παρουσιάζει σταδιακή αύξηση με την αύξηση του αριθμού των εξαρτώμενων προσώπων. Το μοτίβο αυτό υποδηλώνει μια πιθανή συσχέτιση μεταξύ του αριθμού των εξαρτώμενων προσώπων και των αποτελεσμάτων της έγκρισης δανείων.

Η οπτική απεικόνιση υποδηλώνει ότι οι αιτούντες με λιγότερα εξαρτώμενα μέλη ενδέχεται να έχουν σχετικά υψηλότερη πιθανότητα έγκρισης δανείου σε σύγκριση με εκείνους με μεγαλύτερο αριθμό εξαρτώμενων μελών. Η τάση αυτή υπογραμμίζει τη σημασία της συνεκτίμησης των οικογενειακών ευθυνών κατά τη διαδικασία έγκρισης δανείου, καθώς ένας μεγαλύτερος αριθμός εξαρτώμενων μελών θα μπορούσε να επηρεάσει την αναλογία χρέους προς εισόδημα ενός αιτούντος και, κατά συνέπεια, την ικανότητά του να ανταποκριθεί στις υποχρεώσεις αποπληρωμής του δανείου.

5.3.9 Σύγκρισης έγκρισης δανείων και πιστωτικού ορίου




Εικόνα 23. Σύγκρισης έγκρισης δανείων και πιστωτικού ορίου

Το ομαδοποιημένο ραβδόγραμμα παρέχει μια απεικόνιση της σχέσης μεταξύ του πιστωτικού ιστορικού και της κατάστασης έγκρισης δανείου. Αποκαλύπτει μια ξεχωριστή τάση κατά την οποία οι αιτούντες με θετικό πιστωτικό ιστορικό ("1") έχουν σημαντικά περισσότερες πιθανότητες να εγκριθεί το δάνειό τους σε σύγκριση με εκείνους με αρνητικό πιστωτικό ιστορικό ("0"). Η οπτική αντίθεση στα ύψη των ράβδων υπογραμμίζει τον καθοριστικό ρόλο που διαδραματίζει το πιστωτικό ιστορικό στα αποτελέσματα της έγκρισης δανείων. Αυτή η σαφής διάκριση υποδηλώνει ότι το θετικό πιστωτικό ιστορικό χρησιμεύει ως κρίσιμος καθοριστικός παράγοντας που επηρεάζει την απόφαση δανειοδότησης, με ισχυρή τάση προς την έγκριση δανείων για άτομα με ευνοϊκό πιστωτικό ιστορικό.

Αντίθετα, ένα αρνητικό πιστωτικό ιστορικό φαίνεται να μειώνει σημαντικά την πιθανότητα έγκρισης δανείου. Το εύρημα αυτό υπογραμμίζει τη θεμελιώδη σημασία της πιστοληπτικής ικανότητας στη διαδικασία έγκρισης δανείων, σηματοδοτώντας στα χρηματοπιστωτικά ιδρύματα την επιτακτική ανάγκη να δώσουν προτεραιότητα στην αξιολόγηση του πιστωτικού ιστορικού ως βασικό παράγοντα στην αξιολόγηση του κινδύνου. Ο οπτικός αντίκτυπος αυτού του διαγράμματος υπογραμμίζει τη σημασία

της διατήρησης θετικού πιστωτικού ιστορικού για τους αιτούντες δάνεια, καθώς ενισχύει σημαντικά τις προοπτικές τους να εξασφαλίσουν έγκριση δανείου.

5.3.9 Κατανομή του φύλου συγκριτικά με την έγκριση δανείων



Εικόνα 24. Κατανομή του φύλου συγκριτικά με την έγκριση δανείων

Η γραφική παράσταση με δύο γραμμές που απεικονίζει τα αποτελέσματα της έγκρισης δανείων ανά φύλο περιλαμβάνει μια διαφοροποιημένη αφήγηση. Είναι διακριτό ότι τόσο οι άνδρες όσο και οι γυναίκες αιτούντες παρουσιάζουν συγκρίσιμη κατανομή μεταξύ εγκεκριμένων και μη εγκεκριμένων δανείων. Η παρατήρηση αυτή σηματοδοτεί μια επίφαση ουδετερότητας του φύλου στις αποφάσεις έγκρισης δανείων εντός του συνόλου δεδομένων. Ωστόσο, μια βαθύτερη διερεύνηση του συνόλου δεδομένων, ενδεχομένως με τη χρήση στατιστικών αναλύσεων, θα ήταν επιβεβλημένη για να εξακριβωθεί η στατιστική σημασία αυτής της φαινομενικής ισορροπίας και να αποκαλυφθούν τυχόν λεπτές προκαταλήψεις που μπορεί να υπάρχουν.

Επιπλέον, αυτή η οπτική αναπαράσταση υπογραμμίζει τη σημασία της διαφάνειας και της δικαιοσύνης στις πρακτικές δανειοδότησης. Ενώ το διάγραμμα υποδηλώνει μια

δίκαιη κατανομή, η πολυπλοκότητα της δυναμικής των φύλων στη λήψη χρηματοοικονομικών αποφάσεων απαιτεί μια ενδελεχή εξέταση. Τα χρηματοπιστωτικά ιδρύματα μπορούν να αξιοποιήσουν τέτοιες οπτικοποιήσεις ως σημείο εκκίνησης για την εξέταση των διαδικασιών έγκρισης των δανείων τους, διασφαλίζοντας ότι ευθυγραμμίζονται με τις αρχές της δικαιοσύνης και της ισότητας. Η ενσωμάτωση του φύλου ως παράγοντα στο ευρύτερο πλαίσιο των υπεύθυνων πρακτικών δανειοδότησης διασφαλίζει ότι τα ιδρύματα προωθούν ένα χρηματοπιστωτικό περιβάλλον χωρίς αποκλεισμούς, όπου όλοι οι αιτούντες, ανεξαρτήτως φύλου, έχουν ισότιμη ευκαιρία πρόσβασης σε δάνεια.

5.4 Μοντέλα και τεχνικές μηχανικής μάθησης

Στο πλαίσιο της μελέτης, τα μοντέλα και οι τεχνικές μηχανικής μάθησης που επιλέχθηκαν για την ανάλυση των δεδομένων αναφορικά με τις εγκρίσεις δανείων, με ιδιαίτερη έμφαση στον εντοπισμό και τον μετριάσμό πιθανών προκαταλήψεων που σχετίζονται με το φύλο και την οικογενειακή κατάσταση, θα αξιοποιηθούν και θα αναλυθούν ως προς την αποτελεσματικότητά τους.

Ακολουθεί μία θεωρητική περιγραφή των επιλεγμένων τεχνικών μηχανικής μάθησης πριν την εφαρμογή τους στα δεδομένα, με σκοπό την βαθύτερη κατανόηση τους.

Αφού αναλύθηκαν στο Κεφάλαιο 1 οι τύποι μηχανικής μάθησης, η εστίαση στην εποπτευόμενη μηχανική μάθηση ανέδειξε τα κατάλληλα μοντέλα τα οποία θα χρησιμοποιηθούν στη μελέτη και ανήκουν στην κατηγορία αυτή.

Γραμμική παλινδρόμηση (Linear Regression):

Η γραμμική παλινδρόμηση ανήκει στην κατηγορία των αλγορίθμων μηχανικής μάθησης που χρησιμοποιούνται για να ανακαλύψουν σχέσεις και εξαρτήσεις μεταξύ μεταβλητών. Συγκεκριμένα, αναπαριστά μια μαθηματική σχέση μεταξύ μιας εξαρτημένης μεταβλητής (γνωστή ως η "ετικέτα" ή ο "στόχος") και μίας ή περισσότερων ανεξάρτητων μεταβλητών, χρησιμοποιώντας μια γραμμική συνάρτηση.


Στην παλινδρόμηση, ο στόχος είναι να προβλέψουμε τιμές για μία συνεχή μεταβλητή-στόχο, ενώ στην ταξινόμηση, προβλέπουμε μια ετικέτα από ένα πεπερασμένο σύνολο κατηγοριών.

Το μοντέλο για μια πολλαπλή παλινδρόμηση περιλαμβάνει ένα γραμμικό συνδυασμό των ανεξάρτητων μεταβλητών εισόδου. Αυτό μπορεί να παρασταθεί μαθηματικά ως εξής:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + e$$

Στην πράξη, το μοντέλο υπολογίζεται χρησιμοποιώντας ένα σύνολο δεδομένων εκπαίδευσης, όπου κάθε παρατήρηση έχει μια γνωστή ετικέτα.

Η γραμμική παλινδρόμηση είναι ένας τύπος αλγορίθμου μάθησης που εμπίπτει στην κατηγορία μάθησης με επίβλεψη. Αυτό σημαίνει ότι κατά τη φάση της εκπαίδευσης, το μοντέλο μαθαίνει από ένα σύνολο δεδομένων όπου κάθε σημείο δεδομένων είναι επισημασμένο (γνωστά αποτελέσματα). Στη συνέχεια, το εκπαιδευμένο μοντέλο μπορεί να εφαρμοστεί σε νέα, αθέατα δεδομένα για την πρόβλεψη αποτελεσμάτων.



Εικόνα 25. Απεικόνιση της γραμμικής παλινδρόμηση

Nasteski, Vladimir. 2017. 'An overview of the supervised machine learning methods'.

<https://doi.org/10.20544/HORIZONS.B.04.1.17.P05>

Στο εικόνα 25, απεικονίζεται η διαδικασία όπου το μοντέλο (εμφανίζεται με την κόκκινη γραμμή) κατασκευάζεται με βάση τα δεδομένα εκπαίδευσης (εμφανίζεται με μπλε). Κάθε ένα από αυτά τα σημεία δεδομένων συνοδεύεται από μια γνωστή ετικέτα (τιμές στον άξονα y). Ο στόχος είναι να προσαρμοστεί το μοντέλο με τέτοιο τρόπο ώστε να ελαχιστοποιεί την επιλεγμένη συνάρτηση απωλειών, προσαρμόζοντας αποτελεσματικά τα σημεία όσο το δυνατόν πιο κοντά. Αφού εκπαιδευτεί, το μοντέλο αυτό μπορεί στη συνέχεια να χρησιμοποιηθεί για την πρόβλεψη αποτελεσμάτων για νέα σημεία δεδομένων όπου είναι γνωστές μόνο οι τιμές εισόδου (x), επιτρέποντάς μας να συμπεράνουμε τα αντίστοιχα προβλεπόμενα αποτελέσματα (y) (Nasteski, Vladimir, 2017).

Αυτό το μοντέλο θα εφαρμοστεί στην ανάλυση πρόβλεψης δανείων για την κατανόηση της σχέσης μεταξύ των ανεξάρτητων μεταβλητών, συμπεριλαμβανομένου του φύλου και της οικογενειακής κατάστασης, και την έκβαση έγκρισης του δανείου. Η εστίαση

θα δοθεί στον εντοπισμό πιθανών στρεβλώσεων που σχετίζονται με αυτές τις μεταβλητές στις προβλέψεις για το αποτέλεσμα της απόφασης.

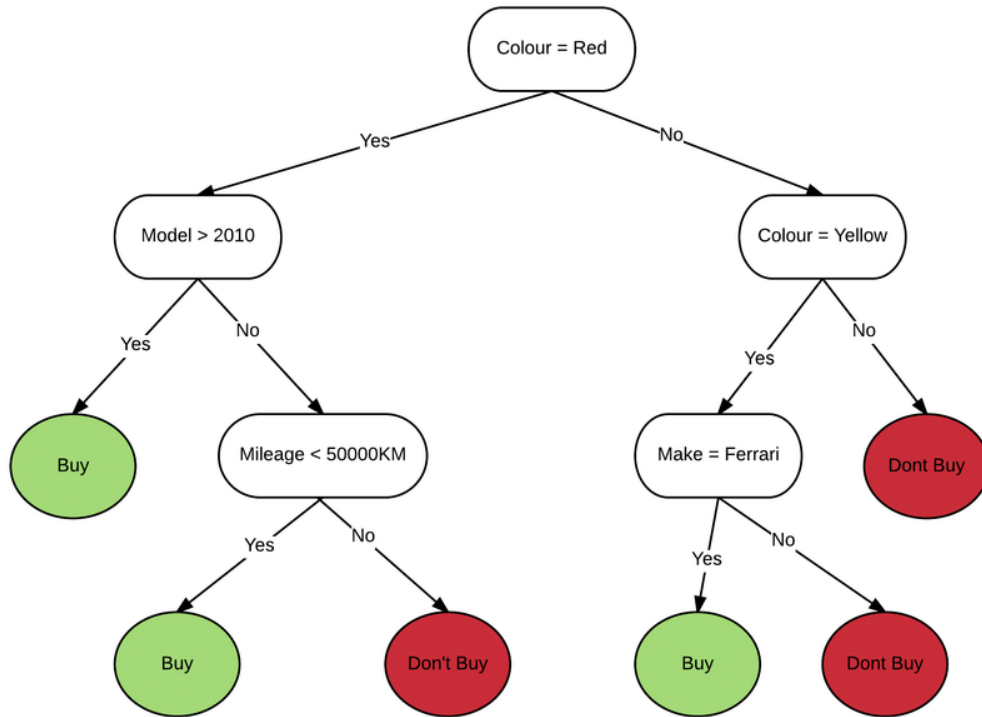
Δέντρα αποφάσεων (Decision Trees):

Ένα δέντρο απόφασης είναι ένας αλγόριθμος ταξινόμησης που διαιρεί το σύνολο δεδομένων σε υποσύνολα με βάση ορισμένα χαρακτηριστικά. Αποτελείται από κόμβους, οι οποίοι σχηματίζουν μια δενδρική δομή με έναν κόμβο-ρίζα στην κορυφή. Κάθε κόμβος, εκτός από τη ρίζα, έχει μία εισερχόμενη ακμή και μπορεί να έχει πολλαπλές εξερχόμενες ακμές. Οι κόμβοι κατηγοριοποιούνται σε εσωτερικούς κόμβους, οι οποίοι εκτελούν δοκιμές σε χαρακτηριστικά, και σε φύλλα, τα οποία αντιπροσωπεύουν το τελικό αποτέλεσμα ή την απόφαση.

Σε ένα δέντρο αποφάσεων, κάθε εσωτερικός κόμβος αξιολογεί ένα συγκεκριμένο χαρακτηριστικό, χωρίζοντας το σύνολο δεδομένων σε υποσύνολα με βάση τις τιμές του χαρακτηριστικού. Για τα κατηγορικά χαρακτηριστικά, κάθε υποσύνολο αντιστοιχεί σε μια μοναδική τιμή χαρακτηριστικού, ενώ για τα αριθμητικά χαρακτηριστικά, τα υποσύνολα βασίζονται σε εύρος τιμών. Κάθε κόμβος φύλλου αντιστοιχεί σε μια κλάση ή κατηγορία, που αντιπροσωπεύει το προβλεπόμενο αποτέλεσμα.

Για να ταξινομήσετε μια περίπτωση, ξεκινάτε από τον κόμβο ρίζας και διασχίζετε το δέντρο, ακολουθώντας τη διαδρομή που καθορίζεται από τις δοκιμές χαρακτηριστικών σε κάθε κόμβο. Τελικά, φτάνετε σε έναν κόμβο φύλλου, ο οποίος παρέχει την προβλεπόμενη κατηγορία για την περίπτωση.

Σε πρακτικές εφαρμογές, τα δέντρα αποφάσεων είναι χρήσιμα για την πρόβλεψη αποτελεσμάτων ή τη λήψη αποφάσεων με βάση χαρακτηριστικά εισόδου. Για παράδειγμα, μπορούν να χρησιμοποιηθούν για την πρόβλεψη της συμπεριφοράς των πελατών ή για την ταξινόμηση δυνητικών πελατών σε διαφορετικά τμήματα με βάση τα χαρακτηριστικά τους.



Εικόνα 26. Παράδειγμα δέντρου απόφασης <https://www.edrawmax.com/decision-tree/>

Όταν πρόκειται για αριθμητικά χαρακτηριστικά, τα δέντρα αποφάσεων μπορούν να απεικονιστούν ως ένα σύνολο δεδομένων, κάθε ένα από τα οποία είναι κάθετο σε έναν από τους άξονες. Οι υπεύθυνοι λήψης αποφάσεων συνήθως προτιμούν τα απλούστερα δέντρα αποφάσεων επειδή συχνά θεωρούνται πιο κατανοητά και περιεκτικά (Nasteski, Vladimir, 2017).

Τα δέντρα αποφάσεων θα χρησιμοποιηθούν για την κατάτμηση των δεδομένων των αιτούντων με βάση διάφορες παραμέτρους, συμπεριλαμβανομένου του φύλου και της οικογενειακής κατάστασης, για την πρόβλεψη της έγκρισης δανείων. Η ανάλυση περιλαμβάνει την αξιολόγηση της πιθανής μεροληψίας στη διαδικασία λήψης αποφάσεων που σχετίζεται με αυτούς τους παράγοντες.

Τυχαίο δάσος (Random Forest):

Σημαντικές εξελίξεις στην ακρίβεια της ταξινόμησης έχουν επιτευχθεί με την κατασκευή συνόλων δέντρων και τη συγκέντρωση των προβλέψεών τους για τον

προσδιορισμό της πιο συχνής κλάσης. Αυτά τα σύνολα χρησιμοποιούν συχνά τεχνικές τυχαιοποίησης προκειμένου να ρυθμίζουν την δημιουργία κάθε μεμονωμένου δέντρου.

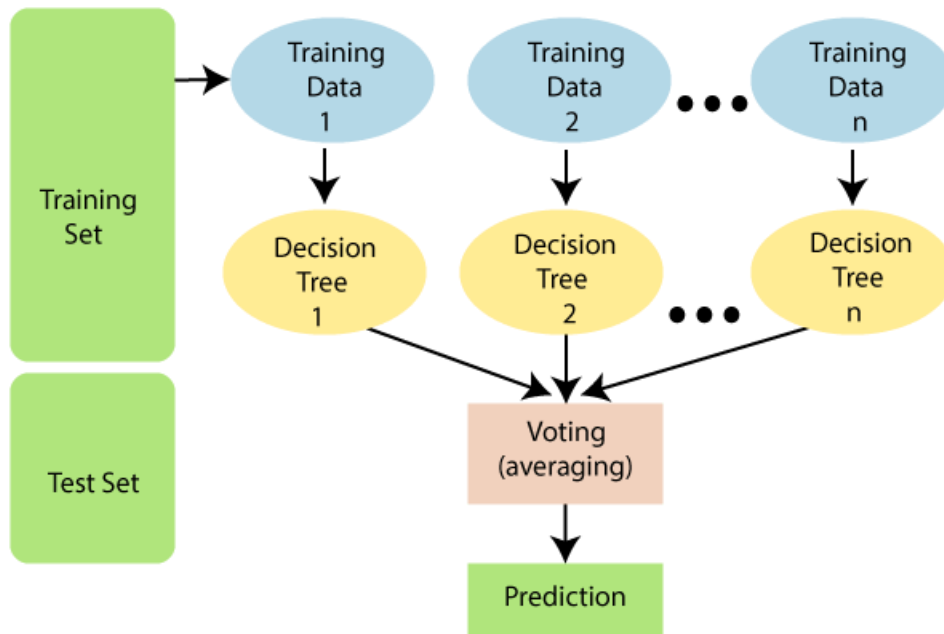
Μια προσέγγιση, γνωστή ως “bagging” (Breiman, 1996), περιλαμβάνει την τυχαία επιλογή υποσυνόλων από το σύνολο δεδομένων εκπαίδευσης για την ανάπτυξη κάθε δέντρου. Μια άλλη τεχνική, που ονομάζεται τυχαία επιλογή διαχωρισμού (Dietterich, 1998), περιλαμβάνει την τυχαία επιλογή διαχωρισμού μεταξύ των K καλύτερων επιλογών σε κάθε κόμβο. Ο Breiman (1999) πρότεινε τη δημιουργία νέων συνόλων εκπαίδευσης ανακατεύοντας τις εξόδους στο αρχικό σύνολο εκπαίδευσης.

Εναλλακτικά, ορισμένες μέθοδοι περιλαμβάνουν την επιλογή του συνόλου εκπαίδευσης από ένα τυχαίο σύνολο σταθμισμένων παραδειγμάτων, όπως συζητήθηκε από τον Ho (1998) στο πλαίσιο της μεθόδου τυχαίου υποδιαστήματος. Σε μια θεμελιώδη εργασία για την αναγνώριση χαρακτήρων, οι Amit και Geman (1997) διερεύνησαν έναν μεγάλο αριθμό γεωμετρικών χαρακτηριστικών και έκαναν αναζήτηση σε μια τυχαία επιλογή αυτών των χαρακτηριστικών για να βρουν τον καλύτερο διαχωρισμό σε κάθε κόμβο.

Η βασική πτυχή που μοιράζονται όλες αυτές οι προσεγγίσεις είναι η δημιουργία ενός τυχαίου διάνυσματος για κάθε δέντρο, που συμβολίζεται ως k , το οποίο είναι ανεξάρτητο από τα τυχαία διανύσματα $1, \dots, k-1$ αλλά ακολουθεί την ίδια κατανομή. Αυτό το τυχαίο διάνυσμα χρησιμοποιείται στη συνέχεια για την ανάπτυξη ενός δέντρου χρησιμοποιώντας το σύνολο εκπαίδευσης και το k , με αποτέλεσμα έναν ταξινομητή $h(x, k)$ όπου x είναι ένα διάνυσμα εισόδου.

Για παράδειγμα, στην τεχνική “bagging”, το τυχαίο διάνυσμα παράγεται μετρώντας τις εμφανίσεις N από βέλη που κατευθύνονται τυχαία σε N κουτιά, όπου το N αντιπροσωπεύει τον αριθμό των δεδομένων στο σύνολο εκπαίδευσης. Στην τυχαία επιλογή διάσπασης, το διάνυσμα αποτελείται από πολλούς ανεξάρτητους τυχαίους ακέραιους αριθμούς που κυμαίνονται από 1 έως K . Τα χαρακτηριστικά και οι διαστάσεις του διανύσματος εξαρτώνται από το ρόλο του στην κατασκευή του δέντρου.

Μόλις δημιουργηθεί ένας μεγάλος αριθμός δέντρων, αυτά ψηφίζουν συλλογικά για την πιο κοινή κλάση. Αυτές οι μέθοδοι αναφέρονται ως **τυχαία δάση**.



Εικόνα 27. Παράδειγμα τυχαίου δάσους <https://www.javatpoint.com/machine-learning-random-forest-algorithm>

Ορισμός τυχαίου δάσους. «Ένα τυχαίο δάσος αποτελεί έναν ταξινομητή ο οποίος περιλαμβάνει μια συλλογή δομημένων ταξινομητών σε δενδρική μορφή $\{h(x, k), k = 1, \dots\}$ όπου οι $\{k\}$ είναι ανεξάρτητα κατανομημένα τυχαία διανύσματα και κάθε δέντρο δίνει μια μοναδιαία ψήφο για την πιο δημοφιλή κλάση στην είσοδο x .» (Breiman, L. Random Forests. Machine Learning σελ. 6, 2001).

Το τυχαίο δάσος, ως μέθοδος αλγοριθμικής εκμάθησης, χρησιμοποιείται για τη βελτίωση της ακρίβειας και της αξιοπιστίας του μοντέλου πρόβλεψης έγκρισης δανείων, με ιδιαίτερη έμφαση στον εντοπισμό και τον μετριασμό της προκατάληψης που σχετίζεται με το φύλο και την οικογενειακή κατάσταση στις αιτήσεις για το αποτέλεσμα των αιτήσεων των δανείων.

5.5 Ανάλυση αλγόριθμου μηχανικής μάθησης

Αφού έχει ολοκληρωθεί η πρωταρχική ανάλυση των δεδομένων και η παράθεση των μοντέλων μηχανικής μάθησης που θα χρησιμοποιηθούν είναι απαραίτητο να γίνει εισαγωγή των κατάλληλων βιβλιοθηκών προκειμένου να επιτευχθεί η μηχανική μάθηση.

Αρχικά θα γίνει φόρτωση της βιβλιοθήκης NumPy (np), η οποία χαρακτηρίζεται ως μια ισχυρή βιβλιοθήκη Python που χρησιμοποιείται για αριθμητικούς υπολογισμούς. Παρέχει υποστήριξη για μεγάλους, πολυδιάστατους πίνακες, μαζί με μια συλλογή μαθηματικών συναρτήσεων για τη λειτουργία τους.

Η δημοφιλής βιβλιοθήκη Pandas της Python είναι κατάλληλη για χειρισμό και ανάλυση δεδομένων. Προσφέρει δομές δεδομένων και λειτουργίες για το χειρισμό αριθμητικών πινάκων και χρονοσειρών, με πιο σημαντική τη δομή DataFrame, η οποία είναι μια δισδιάστατη δομή δεδομένων με ετικέτες και στήλες δυνητικά διαφορετικών τύπων. Η βιβλιοθήκη διαθέτει λειτουργίες για ανάγνωση και εγγραφή δεδομένων από διάφορες μορφές αρχείων, όπως csv ή excel, καθαρισμό δεδομένων, επιλογή και ομαδοποίηση.

Η Matplotlib είναι μια ολοκληρωμένη βιβλιοθήκη για τη δημιουργία στατικών, διαδραστικών και κινούμενων απεικονίσεων στην γλώσσα Python. Η ενότητα pyplot παρέχει μια διεπαφή για τη δημιουργία γραφικών παραστάσεων και οπτικοποιήσεων.

Επιτρέπει στους χρήστες να δημιουργούν διάφορους τύπους γραφικών παραστάσεων, όπως γραμμικά διαγράμματα, διαγράμματα διασποράς, ραβδογράμματα, ιστογράμματα και να τα προσαρμόζουν με διαφορετικά στυλ, χρώματα, ετικέτες κ.λπ.

Το Seaborn είναι μια βιβλιοθήκη οπτικοποίησης στατιστικών δεδομένων που βασίζεται στην Matplotlib. Παρέχει μια διεπαφή υψηλού επιπέδου για τη δημιουργία ελκυστικών και κατατοπιστικών στατιστικών γραφικών.

Παράλληλα, απλοποιεί τη διαδικασία δημιουργίας σύνθετων οπτικοποιήσεων παρέχοντας λειτουργίες για την απεικόνιση των σχέσεων μεταξύ μεταβλητών σε

σύνολα δεδομένων, όπως διαγράμματα διασποράς, box plots, violin plots, heatmaps και άλλα. Προσφέρει επίσης ενσωματωμένα θέματα και παλέτες χρωμάτων για την ενίσχυση της οπτικής ελκυστικότητας των γραφημάτων.

```
import numpy as np

import pandas as pd

import matplotlib.pyplot as plt

import seaborn as sns
```

Πριν τη δημιουργία των μοντέλων μηχανικής μάθησης είναι αναγκαία κάποια περαιτέρω επεξεργασία στα δεδομένα. Στην παρακάτω εικόνα απεικονίζεται το σχήμα των δεδομένων.

```
df.shape
```

```
df.info()
```

```
<class 'pandas.core.frame.DataFrame'>
Int64Index: 480 entries, 0 to 479
Data columns (total 12 columns):
#   Column                Non-Null Count  Dtype
---  -
0   Gender                 480 non-null   object
1   Married                480 non-null   object
2   Dependents             480 non-null   object
3   Education              480 non-null   object
4   Self_Employed         480 non-null   object
5   ApplicantIncome       480 non-null   int64
6   CoapplicantIncome     480 non-null   float64
7   LoanAmount            480 non-null   float64
8   Loan_Amount_Term      480 non-null   float64
9   Credit_History         480 non-null   float64
10  Property_Area         480 non-null   object
11  Loan_Status           480 non-null   object
dtypes: float64(4), int64(1), object(7)
memory usage: 48.8+ KB
```

Εικόνα 28. Το σχήμα των δεδομένων

Κατά την εξέταση της δομής των δεδομένων, παρατηρείται ένα σύνολο που αποτελείται από 480 εγγραφές σε 12 στήλες. Οι τύποι δεδομένων στις στήλες είναι διαφορετικοί: 4 στήλες είναι τύπου «float64», μία στήλη είναι τύπου «int64» και οι υπόλοιπες 7 στήλες είναι τύπου «object».

Για να καταστεί δυνατή η επεξεργασία, αυτές οι στήλες τύπου «object» πρέπει να μετατραπούν σε αριθμητική μορφή.

Για τη μετατροπή, χρησιμοποιείται η συνάρτηση LabelEncoder από τη βιβλιοθήκη scikit-learn, οπότε απαιτείται η εισαγωγή της.

```
from sklearn.preprocessing import LabelEncoder
```

Κάθε μετατροπή στήλης απαιτεί την ενσάρκωση ενός αντικειμένου LabelEncoder. Επιπλέον, αρχικοποιείται μια μηδενική αριθμητική μεταβλητή που χρησιμεύει ως μετρητής, ο οποίος αυξάνεται κατά ένα για κάθε επιτυχή μετατροπή μιας στήλης τύπου "αντικειμένου" σε αριθμητική μορφή.

```
# NaN values

for column in df.select_dtypes(include=['object']).columns:

    df[column].fillna(df[column].mode()[0], inplace=True)

label_encoder = LabelEncoder()

# Επανάληψη κάθε κατηγορικής στήλης και εφαρμογή label encoding

for column in df.select_dtypes(include=['object']).columns:

    # Προσαρμογή κωδικοποιητή ετικέτας και μετασχηματισμός της στήλης

    df[column] = label_encoder.fit_transform(df[column])

print(df.head())
```

| | Gender | Married | Dependents | Education | Self_Employed | ApplicantIncome | \ |
|---|--------|---------|------------|-----------|---------------|-----------------|---|
| 0 | 1 | 1 | 1 | 0 | 0 | 4583 | |
| 1 | 1 | 1 | 0 | 0 | 1 | 3000 | |
| 2 | 1 | 1 | 0 | 1 | 0 | 2583 | |
| 3 | 1 | 0 | 0 | 0 | 0 | 6000 | |
| 4 | 1 | 1 | 2 | 0 | 1 | 5417 | |

| | CoapplicantIncome | LoanAmount | Loan_Amount_Term | Credit_History | \ |
|---|-------------------|------------|------------------|----------------|---|
| 0 | 1508.0 | 128.0 | 360.0 | 1.0 | |
| 1 | 0.0 | 66.0 | 360.0 | 1.0 | |
| 2 | 2358.0 | 120.0 | 360.0 | 1.0 | |
| 3 | 0.0 | 141.0 | 360.0 | 1.0 | |
| 4 | 4196.0 | 267.0 | 360.0 | 1.0 | |

| | Property_Area | Loan_Status |
|---|---------------|-------------|
| 0 | 0 | 0 |
| 1 | 2 | 1 |
| 2 | 2 | 1 |
| 3 | 2 | 1 |
| 4 | 2 | 1 |

Εικόνα 29. Μετατροπή στηλών τύπου «object» σε αριθμητικά δεδομένα

Ακολουθεί μία ματιά στα δεδομένα μετά την μετατροπή των κατηγορικών μεταβλητών.

| | Gender | Married | Dependents | Education | Self_Employed | ApplicantIncome | CoapplicantIncome | LoanAmount | Loan_Amount_Term | Credit_History | Property_Area | Loan_Status |
|---|--------|---------|------------|-----------|---------------|-----------------|-------------------|------------|------------------|----------------|---------------|-------------|
| 0 | 1 | 1 | 1 | 0 | 0 | 4583 | 1508.0 | 128.0 | 360.0 | 1.0 | 0 | 0 |
| 1 | 1 | 1 | 0 | 0 | 1 | 3000 | 0.0 | 66.0 | 360.0 | 1.0 | 2 | 1 |
| 2 | 1 | 1 | 0 | 1 | 0 | 2583 | 2358.0 | 120.0 | 360.0 | 1.0 | 2 | 1 |
| 3 | 1 | 0 | 0 | 0 | 0 | 6000 | 0.0 | 141.0 | 360.0 | 1.0 | 2 | 1 |
| 4 | 1 | 1 | 2 | 0 | 1 | 5417 | 4196.0 | 267.0 | 360.0 | 1.0 | 2 | 1 |
| 5 | 1 | 1 | 0 | 1 | 0 | 2333 | 1516.0 | 95.0 | 360.0 | 1.0 | 2 | 1 |
| 6 | 1 | 1 | 3 | 0 | 0 | 3036 | 2504.0 | 158.0 | 360.0 | 0.0 | 1 | 0 |
| 7 | 1 | 1 | 2 | 0 | 0 | 4006 | 1526.0 | 168.0 | 360.0 | 1.0 | 2 | 1 |
| 8 | 1 | 1 | 1 | 0 | 0 | 12841 | 10968.0 | 349.0 | 360.0 | 1.0 | 1 | 0 |
| 9 | 1 | 1 | 2 | 0 | 0 | 3200 | 700.0 | 70.0 | 360.0 | 1.0 | 2 | 1 |

Εικόνα 30. Το σύνολο των δεδομένων μετά την μετατροπή των κατηγορικών μεταβλητών σε αριθμητικές.

5.5.1 Δημιουργία του μοντέλου Λογιστικής Παλινδρόμησης (Logistic Regression)

Όπως έχει ήδη αναφερθεί στόχος της ανάλυσής μας είναι να διερευνηθεί ο βαθμός συσχέτισης της χορήγησης των δανείων σε σχέση με τα χαρακτηριστικά των αιτούντων ως προς το φύλο και την οικογενειακή κατάσταση.

Η λογιστική παλινδρόμηση επιλέχθηκε ως μια δημοφιλής στατιστική τεχνική που χρησιμοποιείται για δυαδικές εργασίες ταξινόμησης, με σκοπό την πρόβλεψη της κατάστασης έγκρισης δανείου με βάση διάφορα χαρακτηριστικά των αιτούντων. Η λογιστική παλινδρόμηση είναι κατάλληλη για σενάρια όπου η εξαρτημένη μεταβλητή, στην προκειμένη περίπτωση, η κατάσταση του δανείου (εγκεκριμένο ή μη εγκεκριμένο), είναι κατηγορική.

Για τη δημιουργία του μοντέλου, ήταν αναγκαίο να εισαχθούν και να χρησιμοποιηθούν οι ακόλουθες βιβλιοθήκες και ενότητες:

```
from sklearn.model_selection import train_test_split
```

Το «train_test_split» επιτρέπει το διαχωρισμό του συνόλου δεδομένων σε υποσύνολα εκπαίδευσης και δοκιμής. Με το διαχωρισμό των δεδομένων, μπορούμε να εκπαιδεύσουμε το μοντέλο μας σε ένα μέρος του συνόλου δεδομένων και να αξιολογήσουμε την απόδοσή του σε αθέατα δεδομένα για να εκτιμήσουμε τις δυνατότητες γενίκευσης.

```
from sklearn.preprocessing import StandardScaler
```

Η συγκεκριμένη τεχνική προεπεξεργασίας χρησιμοποιείται για την τυποποίηση των χαρακτηριστικών αφαιρώντας τη μέση τιμή και κλιμακώνοντάς τα σε μοναδιαία διακύμανση. Η τυποποίηση διασφαλίζει ότι κάθε χαρακτηριστικό συμβάλλει εξίσου στη διαδικασία εκμάθησης του μοντέλου, αποτρέποντας τα χαρακτηριστικά με μεγαλύτερες κλίμακες να κυριαρχούν στον αλγόριθμο.

```
from sklearn.linear_model import LogisticRegression
```

Η λογιστική παλινδρόμηση αποτελεί μια στατιστική τεχνική που χρησιμοποιείται για εργασίες δυαδικής ταξινόμησης. Μοντελοποιεί την πιθανότητα να ανήκει μια περίπτωση σε μια συγκεκριμένη κλάση με βάση μία ή περισσότερες ανεξάρτητες μεταβλητές (χαρακτηριστικά). Το μοντέλο λογιστικής παλινδρόμησης μαθαίνει τη σχέση μεταξύ των χαρακτηριστικών εισόδου και του δυαδικού αποτελέσματος εκτιμώντας συντελεστές για κάθε χαρακτηριστικό.

```
from sklearn.metrics import accuracy_score, classification_report
```

Οι παραπάνω συναρτήσεις χρησιμοποιούνται για την αξιολόγηση της απόδοσης του μοντέλου λογιστικής παλινδρόμησης.

Το «accuracy_score» υπολογίζει την ακρίβεια του μοντέλου, η οποία είναι το ποσοστό των σωστά προβλεπόμενων περιπτώσεων επί του συνολικού αριθμού των περιπτώσεων.

Το classification_report παρέχει μια λεπτομερή σύνοψη των διαφόρων μετρικών ταξινόμησης, όπως η ακρίβεια, η ανάκληση, το F1-score και η υποστήριξη για κάθε κλάση. Βοηθά στην αξιολόγηση της απόδοσης του μοντέλου σε διάφορες κλάσεις και στον εντοπισμό τυχόν ανισορροπιών ή αποκλίσεων στις προβλέψεις.

Όλα τα παραπάνω διευκολύνουν συλλογικά τη δημιουργία, την αξιολόγηση και την ερμηνεία του μοντέλου λογιστικής παλινδρόμησης για την πρόβλεψη της κατάστασης έγκρισης δανείου.

Ανάπτυξη του μοντέλου

Το μοντέλο λογιστικής παλινδρόμησης εκπαιδεύτηκε χρησιμοποιώντας το σύνολο δεδομένων που αποτελείται από πληροφορίες για τους αιτούντες, όπως το φύλο, η οικογενειακή κατάσταση, το επίπεδο εκπαίδευσης, τα στοιχεία του εισοδήματος, το πιστωτικό ιστορικό και η περιοχή ιδιοκτησίας, μεταξύ άλλων. Αυτά τα χαρακτηριστικά χρησιμοποιήθηκαν για την πρόβλεψη της πιθανότητας έγκρισης δανείου.

Κατά την εκπαίδευση του μοντέλου λογιστικής παλινδρόμησης, λάβαμε συντελεστές για κάθε χαρακτηριστικό, που αντιπροσωπεύουν την επίδρασή τους στην πιθανότητα έγκρισης δανείου. Οι θετικοί συντελεστές υποδηλώνουν θετική συσχέτιση με την έγκριση δανείου, ενώ οι αρνητικοί συντελεστές υποδηλώνουν αρνητική συσχέτιση.

```
X = df.drop(columns=["Loan_Status"])

y = df["Loan_Status"]

X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.8,
random_state=42)

# Preprocessing: Standardize numerical features

scaler = StandardScaler()

X_train_scaled = scaler.fit_transform(X_train)

X_test_scaled = scaler.transform(X_test)

# Fit το μοντέλο

log_reg_model = LogisticRegression()

log_reg_model.fit(X_train_scaled, y_train)
```

```

y_pred = log_reg_model.predict(X_test_scaled)

accuracy = accuracy_score(y_test, y_pred)

print("Accuracy:", accuracy)

print("Classification Report:")

print(classification_report(y_test, y_pred))

```

Απόδοση του μοντέλου

Η απόδοση του μοντέλου λογιστικής παλινδρόμησης αξιολογήθηκε χρησιμοποιώντας μετρικές όπως η ακρίβεια, η ανάκληση και το F1-score. Αυτές οι μετρικές παρέχουν πληροφορίες σχετικά με την ικανότητα του μοντέλου να ταξινομεί σωστά την κατάσταση έγκρισης δανείου με βάση τα παρεχόμενα χαρακτηριστικά.

Accuracy: 0.7994791666666666

Classification Report:

| | precision | recall | f1-score | support |
|--------------|-----------|--------|----------|---------|
| 0 | 0.87 | 0.41 | 0.55 | 118 |
| 1 | 0.79 | 0.97 | 0.87 | 266 |
| accuracy | | | 0.80 | 384 |
| macro avg | 0.83 | 0.69 | 0.71 | 384 |
| weighted avg | 0.81 | 0.80 | 0.77 | 384 |

Η συνολική ακρίβεια του μοντέλου είναι 79,99%, υποδεικνύοντας ότι προβλέπει σωστά την κατάσταση έγκρισης δανείου για 79,99% των περιπτώσεων στο σύνολο δεδομένων δοκιμής.

Συνολικά, ενώ το μοντέλο παρουσιάζει καλές επιδόσεις σε ορισμένες πτυχές, όπως η ακρίβεια για την κατηγορία "0" και η ανάκληση για την κατηγορία "1", υπάρχουν περιθώρια βελτίωσης, ιδίως όσον αφορά την ανάκληση για την κατηγορία "0", ώστε να καταγράφονται περισσότερα εγκεκριμένα δάνεια.

Confusion matrix

```
from sklearn.metrics import accuracy_score, classification_report,
confusion_matrix

# confusion matrix

conf_matrix = confusion_matrix(y_test, y_pred)

plt.figure(figsize=(8, 6))

sns.heatmap(conf_matrix, annot=True, cmap='Blues', fmt='g', cbar=False)

plt.xlabel('Predicted labels')

plt.ylabel('True labels')

plt.title('Confusion Matrix - Logistic Regression')


plt.xticks(ticks=[0.5, 1.5], labels=['Y', 'N'])

plt.yticks(ticks=[0.5, 1.5], labels=['Y', 'N'])

plt.show()
```

Το παρεχόμενο απόσπασμα κώδικα απεικονίζει τον πίνακα σύγχυσης για την αξιολόγηση της απόδοσης του μοντέλου λογιστικής παλινδρόμησης. Ο πίνακας σύγχυσης είναι ένα κρίσιμο εργαλείο για την αξιολόγηση της ακρίβειας του μοντέλου

ταξινόμησης, εμφανίζοντας τις μετρήσεις των αληθώς θετικών, αληθώς αρνητικών, ψευδώς θετικών και ψευδώς αρνητικών προβλέψεων.



Εικόνα 31. Πίνακας σύγκρισης του μοντέλου λογιστικής παλινδρόμησης

Χρησιμοποιώντας τη λειτουργία `heatmap` της `Matplotlib`, ο πίνακας σύγκρισης παρουσιάζεται ως ένα χρωματιστό πλέγμα, με κάθε κελί να αντιπροσωπεύει τον αριθμό των περιπτώσεων που ταξινομούνται σε συγκεκριμένες κατηγορίες. Οι ετικέτες του άξονα x και του άξονα y υποδηλώνουν τις προβλεπόμενες και τις αληθείς ετικέτες, αντίστοιχα, ενώ ο τίτλος του χάρτη θερμότητας παρέχει πλαίσιο. Ερμηνεύοντας την κατανομή των μετρήσεων στον πίνακα, αποκτούμε πληροφορίες σχετικά με την ικανότητα του μοντέλου να ταξινομεί με ακρίβεια τις περιπτώσεις σε διαφορετικές κατηγορίες, όπως τα εγκεκριμένα "Y" και τα μη εγκεκριμένα δάνεια "N".

Συσχέτιση μεταβλητών για την έγκριση των δανείων

```
model = LogisticRegression()

model.fit(X_train, y_train)

# Extract feature importances from coefficients

importances = pd.DataFrame(data={

    'Attribute': X_train.columns,

    'Importance': model.coef_[0]

})

# Sort the importances by absolute value

importances['Abs_Importance'] = importances['Importance'].abs()

importances = importances.sort_values(by='Abs_Importance',
ascending=False).reset_index(drop=True)

# Plot the importances

plt.figure(figsize=(10, 8))

plt.bar(x=importances['Attribute'], height=importances['Importance'],
color='#87CEEB')

plt.title('Feature Importances from Coefficients', size=10)

plt.xlabel('Attribute')


plt.ylabel('Importance')

plt.xticks(rotation='vertical')

plt.show()
```

Το παρεχόμενο απόσπασμα κώδικα δείχνει την εξαγωγή και την οπτικοποίηση των εισαγωγών των χαρακτηριστικών από ένα μοντέλο λογιστικής παλινδρόμησης. Αρχικά, ένα μοντέλο λογιστικής παλινδρόμησης ενσαρκώνεται και εκπαιδεύεται στο σύνολο δεδομένων εκπαίδευσης. Στη συνέχεια, η σημαντικότητα προκύπτει από τους συντελεστές του εκπαιδευμένου μοντέλου. Αυτές οι εισαγωγές οργανώνονται σε ένα DataFrame, όπου κάθε γραμμή αντιστοιχεί σε ένα χαρακτηριστικό στο σύνολο δεδομένων, μαζί με την αντίστοιχη τιμή σημαντικότητας. Για να διασφαλιστεί η σαφήνεια στην ερμηνεία, οι εισαγόμενες τιμές ταξινομούνται με βάση τις απόλυτες τιμές τους σε φθίνουσα σειρά.

Τέλος, οι εισαγωγές των χαρακτηριστικών απεικονίζονται με τη χρήση ραβδογράμματος, με τα χαρακτηριστικά να απεικονίζονται στον άξονα x και τις αντίστοιχες εισαγωγές τους στον άξονα y. Αυτή η οπτικοποίηση προσφέρει πολύτιμες πληροφορίες σχετικά με το ποια χαρακτηριστικά συμβάλλουν πιο σημαντικά στις προβλέψεις του μοντέλου λογιστικής παλινδρόμησης, βοηθώντας στην επιλογή χαρακτηριστικών και στην ερμηνεία του μοντέλου.



Εικόνα 32. Συσχέτιση σημαντικότητας χαρακτηριστικών για την έγκριση των δανείων

5.5.2 Δημιουργία του μοντέλου Δέντρων Αποφάσεων (Decision Trees)

Για τη δημιουργία του μοντέλου δέντρων απόφασης, έγινε χρήση ενός βασικού στοιχείου από τη βιβλιοθήκη scikit-learn:

```
from sklearn.tree import DecisionTreeClassifier, plot_tree
```

Το «DecisionTreeClassifier» είναι η κλάση που χρησιμοποιείται για τη δημιουργία του μοντέλου δέντρων απόφασης. Υλοποιεί έναν αλγόριθμο δέντρων απόφασης για εργασίες ταξινόμησης. Το δέντρο απόφασης χωρίζει το σύνολο δεδομένων σε υποσύνολα με βάση τις τιμές των χαρακτηριστικών εισόδου και προβλέπει τη μεταβλητή-στόχο με βάση αυτά τα χωρίσματα. Μαθαίνει κανόνες απόφασης από τα δεδομένα εκπαίδευσης για να κάνει προβλέψεις σε νέα, αθέατα δεδομένα.

Επιπλέον, η συνάρτηση «plot_tree» χρησιμοποιείται για την οπτικοποίηση του μοντέλου δέντρου αποφάσεων μετά την εκπαίδευσή του. Αυτή η οπτικοποίηση βοηθά στην κατανόηση της δομής του δέντρου αποφάσεων και του τρόπου με τον οποίο λαμβάνει αποφάσεις με βάση τα χαρακτηριστικά εισόδου.

Ανάπτυξη του μοντέλου

```
X = df.drop('Loan_Status', axis=1)

y = df['Loan_Status']

# Split

X_train_dt, X_test_dt, y_train_dt, y_test_dt = train_test_split(X, y,
test_size=0.8, random_state=42)

# class weighting

dt_model = DecisionTreeClassifier(max_depth=8, class_weight='balanced') #
Set max_depth & class_weight

dt_model.fit(X_train_dt, y_train_dt)

# Visualize

plt.figure(figsize=(12, 8))
```



```
plot_tree(dt_model, feature_names=X.columns, class_names=['N', 'Y'],
filled=True, rounded=True)

plt.title("Decision Tree")

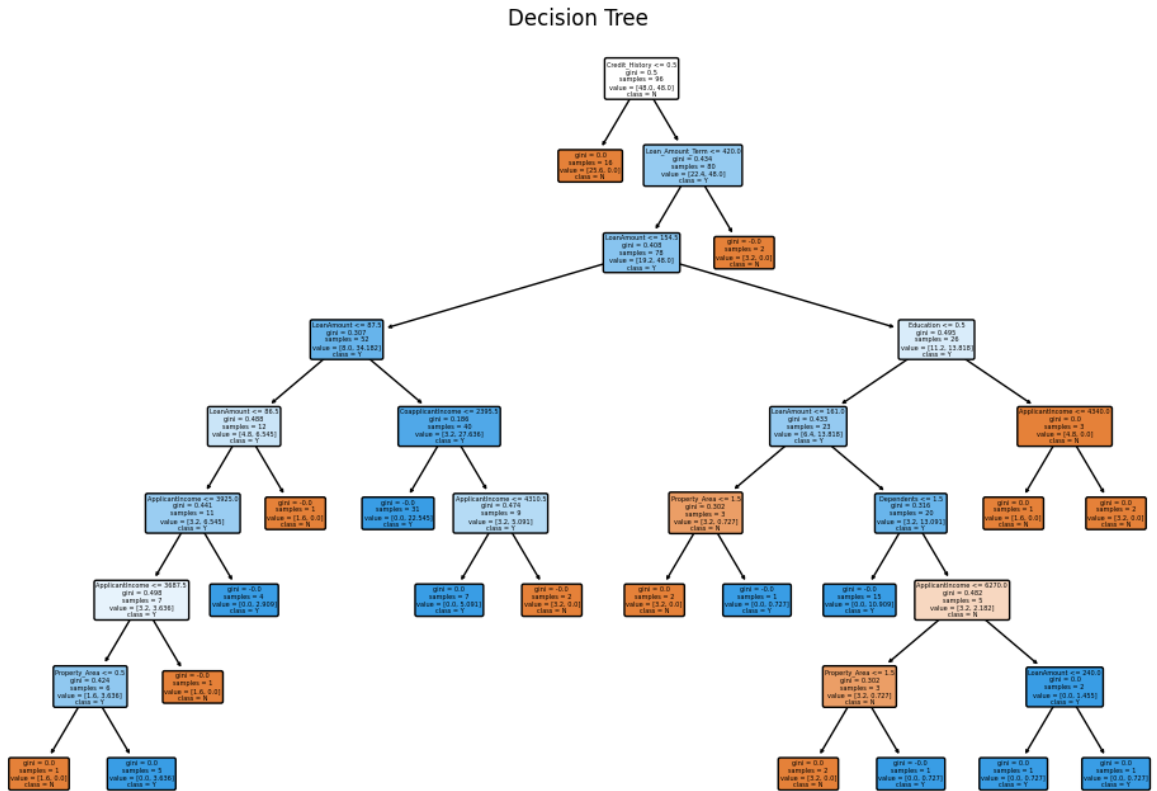
plt.show()
```

Το πρώτο βήμα περιελάμβανε τον διαχωρισμό του συνόλου δεδομένων σε χαρακτηριστικά (X) και τη μεταβλητή-στόχο (y), όπου η μεταβλητή-στόχος αντιπροσωπεύει την κατάσταση του δανείου. Στη συνέχεια το σύνολο δεδομένων διαχωρίστηκε σε σύνολα εκπαίδευσης και δοκιμής χρησιμοποιώντας τη συνάρτηση «train_test_split», διαθέτοντας το 80% των δεδομένων για δοκιμή για να αξιολογήσουμε την απόδοση του μοντέλου.

Για την αντιμετώπιση της ανισορροπίας των κλάσεων στη μεταβλητή-στόχο, χρησιμοποιήσαμε την παράμετρο «class_weight=balanced» κατά την ενστάλαξη του «DecisionTreeClassifier». Αυτή η παράμετρος προσαρμόζει τα βάρη που αποδίδονται σε κάθε κλάση κατά την εκπαίδευση του μοντέλου, δίνοντας μεγαλύτερο βάρος στην κλάση της μειονότητας, στην προκειμένη περίπτωση "N" για τα μη εγκεκριμένα δάνεια, για να μετριάσει τον αντίκτυπο της ανισορροπίας των κλάσεων στην απόδοση του μοντέλου.

Το μοντέλο δέντρου απόφασης εκπαιδεύτηκε με μέγιστο βάθος 8 για να ελεγχθεί η πολυπλοκότητα του δέντρου και να αποφευχθεί η υπερπροσαρμογή. Αφού εκπαιδεύτηκε, η διαδικασία λήψης αποφάσεων του μοντέλου απεικονίστηκε με τη χρήση της συνάρτησης «plot_tree» από τη βιβλιοθήκη scikit-learn. Αυτή η οπτικοποίηση παρέχει πληροφορίες σχετικά με τον τρόπο με τον οποίο το μοντέλο χωρίζει τον χώρο των χαρακτηριστικών και λαμβάνει αποφάσεις με βάση τα χαρακτηριστικά εισόδου.

Η ικανότητά του «DecisionTreeClassifier» να χειρίζεται την ανισορροπία των κλάσεων και να παρέχει ερμηνεύσιμα αποτελέσματα τον καθιστά κατάλληλο για την ανάλυσή της διαδικασίας έγκρισης δανείων.



Εικόνα 33. Απεικόνιση ενός τυχαίου δέντρου απόφασης

Απόδοση του μοντέλου

Η αξιολόγηση του μοντέλου θα πραγματοποιηθεί με τη χρήση των μετρικών που χρησιμοποιήθηκαν προηγουμένως στο μοντέλο λογιστικής παλινδρόμησης.

Classification Report for Decision Tree Model:

| | precision | recall | f1-score | support |
|---|-----------|--------|----------|---------|
| N | 0.58 | 0.48 | 0.53 | 118 |
| Y | 0.79 | 0.84 | 0.81 | 266 |

| | | | | |
|--------------|------|------|------|-----|
| accuracy | | | 0.73 | 384 |
| macro avg | 0.68 | 0.66 | 0.67 | 384 |
| weighted avg | 0.72 | 0.73 | 0.72 | 384 |

Accuracy for Decision Tree Model: 0.7317708333333334

Για την κλάση "N" (μη εγκεκριμένα δάνεια), το μοντέλο πέτυχε ακρίβεια 0,58, που σημαίνει ότι όταν προβλέπει ένα δάνειο ως μη εγκεκριμένο, είναι σωστό στο 58% των περιπτώσεων. Η βαθμολογία ανάκλησης (recall) 0,48 υποδηλώνει ότι το μοντέλο αναγνωρίζει σωστά το 48% όλων των μη εγκεκριμένων δανείων στο σύνολο δεδομένων. Η βαθμολογία F1, η οποία συνδυάζει την ακρίβεια και την ανάκληση, είναι 0,53, γεγονός που αντικατοπτρίζει μια ισορροπία μεταξύ ακρίβειας και ανάκλησης για την κατηγορία "N".

Ομοίως, για την κλάση "Y" (εγκεκριμένα δάνεια), το μοντέλο εμφανίζει ακρίβεια 0,79, υποδεικνύοντας ότι το 79% των δανείων που προβλέπονται ως εγκεκριμένα είναι πράγματι εγκεκριμένα. Η βαθμολογία ανάκλησης 0,84 υποδηλώνει ότι το μοντέλο καταγράφει το 84% όλων των εγκεκριμένων δανείων στο σύνολο δεδομένων. Η βαθμολογία F1 για την κλάση "Y" είναι 0,81, υποδεικνύοντας υψηλό επίπεδο ακρίβειας στην πρόβλεψη εγκεκριμένων δανείων.

Συνοψίζοντας, ενώ το μοντέλο δέντρου αποφάσεων επιδεικνύει ισχυρή απόδοση στην πρόβλεψη εγκεκριμένων δανείων (κλάση "Y"), η απόδοσή του στην πρόβλεψη μη εγκεκριμένων δανείων (κλάση "N") είναι σχετικά ασθενέστερη, όπως αντικατοπτρίζεται στις χαμηλότερες βαθμολογίες ακρίβειας και ανάκλησης για την εν λόγω κλάση.

Σημαντικότητα χαρακτηριστικών

```
import matplotlib.pyplot as plt

importances = dt_model.feature_importances_

feature_names = X.columns

# Σορτάρισμα σε descending order
sorted_indices = importances.argsort()[::-1]
sorted_importances = importances[sorted_indices]
sorted_feature_names = feature_names[sorted_indices]

plt.figure(figsize=(10, 6))

plt.barh(range(len(sorted_importances)), sorted_importances,
         tick_label=sorted_feature_names)

plt.xlabel('Feature Importance')

plt.ylabel('Feature')

plt.title('Feature Importances from Decision Tree Model')

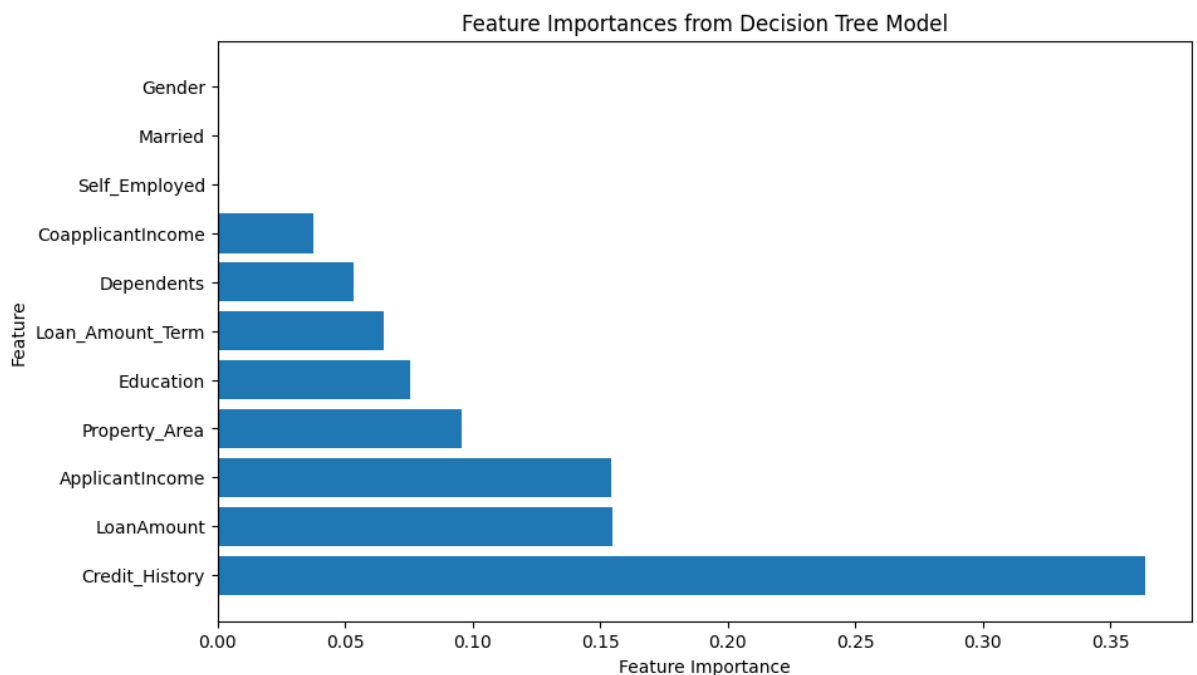
plt.show()
```

Οι εισαγωγές χαρακτηριστικών υπολογίζονται χρησιμοποιώντας το χαρακτηριστικό «feature_importances_» του εκπαιδευμένου μοντέλου δέντρου αποφάσεων.

Έπειτα, τα feature importances ταξινομούνται σε φθίνουσα σειρά για να επισημανθούν τα πιο σημαντικά χαρακτηριστικά.

Τέλος, οι ταξινομημένες εισαγωγές χαρακτηριστικών απεικονίζονται ως οριζόντιες ράβδοι χρησιμοποιώντας τη συνάρτηση `plt.barh()` της Matplotlib. Ο άξονας y αναπαριστά τα χαρακτηριστικά, ενώ ο άξονας x αναπαριστά τη σημαντικότητά τους.

Αυτή η απεικόνιση παρέχει πληροφορίες σχετικά με το ποια χαρακτηριστικά έχουν μεγαλύτερη επιρροή στη διαδικασία λήψης αποφάσεων του μοντέλου δέντρου αποφάσεων, βοηθώντας στην επιλογή χαρακτηριστικών και στην ερμηνεία του μοντέλου.



Εικόνα 34. Σημαντικότητα χαρακτηριστικών για την χορήγηση δανείου στο μοντέλο Decision Trees

5.5.2 Δημιουργία του μοντέλου Τυχαίου Δάσους (Random Forest)

Για τη δημιουργία του μοντέλου είναι αναγκαία η εισαγωγή του RandomForestClassifier από τη βιβλιοθήκη scikit-learn, η οποία σηματοδοτεί ένα καίριο βήμα στην αξιοποίηση τεχνικών μάθησης συνόλων για την προγνωστική μοντελοποίηση.

```
from sklearn.model_selection import train_test_split

from sklearn.ensemble import RandomForestClassifier

from sklearn.metrics import accuracy_score, classification_report

X = df.drop(columns=["Loan_Status"])

y = df["Loan_Status"]

X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.8,
random_state=42)

class_counts = y_train.value_counts()

class_weights = {label: 1 / count for label, count in class_counts.items()}

rf_model = RandomForestClassifier(random_state=42,
class_weight=class_weights)

rf_model.fit(X_train, y_train)

y_pred_rf = rf_model.predict(X_test)
```

```

accuracy_rf = accuracy_score(y_test, y_pred_rf)

print("Random Forest Accuracy:", accuracy)

print("Random Forest Classification Report:")

print(classification_report(y_test, y_pred_rf))

```

Random Forest Accuracy: 0.7994791666666666

Random Forest Classification Report:

| | precision | recall | f1-score | support |
|--------------|-----------|--------|----------|---------|
| 0 | 0.81 | 0.41 | 0.54 | 118 |
| 1 | 0.78 | 0.96 | 0.86 | 266 |
| accuracy | | | 0.79 | 384 |
| macro avg | 0.80 | 0.68 | 0.70 | 384 |
| weighted avg | 0.79 | 0.79 | 0.76 | 384 |

Το μοντέλο Random Forest εκπαιδεύτηκε για να προβλέψει την έκβαση της δανειοδότησης με βάση διάφορα χαρακτηριστικά εισόδου. Η διαδικασία ξεκίνησε με το διαχωρισμό του συνόλου δεδομένων σε σύνολα εκπαίδευσης και δοκιμής χρησιμοποιώντας τη συνάρτηση «train_test_split» από τη βιβλιοθήκη scikit-learn. Το σύνολο δεδομένων αποτελούνταν από χαρακτηριστικά εισόδου (X) και τη μεταβλητή-στόχο, την κατάσταση του δανείου (y).

Για να αντιμετωπιστεί η ανισορροπία των κλάσεων, όπου η μία κλάση κυριαρχεί στην άλλη όσον αφορά τη συχνότητα, ανατέθηκαν βάρη κλάσεων σε κάθε κλάση ανάλογα με τις αντίστροφες συχνότητές τους χρησιμοποιώντας τα δεδομένα εκπαίδευσης. Αυτό

επιτεύχθηκε με τον υπολογισμό των αριθμών των κλάσεων και στη συνέχεια με την ανάθεση βαρών αντιστρόφως ανάλογων προς αυτούς τους αριθμούς.

Στη συνέχεια, ο ταξινομητής Random Forest ενεργοποιήθηκε με συγκεκριμένες παραμέτρους. Χρησιμοποιήθηκε ο «RandomForestClassifier» από το scikit-learn, με μια καθορισμένη τυχαία κατάσταση και τα υπολογισμένα βάρη των κλάσεων για να ληφθεί υπόψη η ανισορροπία τους. Στη συνέχεια, το μοντέλο προσαρμόστηκε στα δεδομένα εκπαίδευσης χρησιμοποιώντας τη μέθοδο «fit».

Μετά την εκπαίδευση, το μοντέλο χρησιμοποιήθηκε για την πραγματοποίηση προβλέψεων στα δεδομένα δοκιμής και η ακρίβεια των προβλέψεων αξιολογήθηκε με τη χρήση της συνάρτησης «accuracy_score». Επιπλέον, δημιουργήθηκε μια λεπτομερής αναφορά ταξινόμησης χρησιμοποιώντας το «classification_report», παρέχοντας πληροφορίες σχετικά με την ακρίβεια, την ανάκληση και το F1-score για κάθε κλάση, καθώς και τη συνολική ακρίβεια του μοντέλου.

```
import matplotlib.pyplot as plt

importances2 = rf_model.feature_importances_

feature_names = X.columns

# Sort in descending order

sorted_indices = importances.argsort()[::-1]

sorted_importances = importances[sorted_indices]

sorted_feature_names = feature_names[sorted_indices]

plt.figure(figsize=(10, 6))

plt.barh(range(len(sorted_importances)), sorted_importances,
         tick_label=sorted_feature_names)

plt.xlabel('Feature Importance')
```




```
plt.ylabel('Feature')  
  
plt.title('Feature Importances from Random Forest')  
  
plt.show()
```

Το παραπάνω απόσπασμα κώδικα χρησιμοποιήθηκε για την οπτικοποίηση των εισαγόμενων χαρακτηριστικών που προκύπτουν από το μοντέλο Random Forest. Μετά την εκπαίδευση του μοντέλου για την πρόβλεψη της κατάστασης του δανείου με βάση διάφορα χαρακτηριστικά εισόδου, οι εισαγωγές χαρακτηριστικών παρέχουν πληροφορίες σχετικά με τη σημασία κάθε χαρακτηριστικού για την πραγματοποίηση προβλέψεων.

Πραγματοποιείται ανάλυση του χαρακτηριστικού «feature_importances_» του εκπαιδευμένου μοντέλου Random Forest για να ανακτηθεί ο βαθμός σημαντικότητας που αποδίδονται σε κάθε χαρακτηριστικό. Η μέτρηση της σπουδαιότητας αντιπροσωπεύει τη συμβολή κάθε χαρακτηριστικού στην προβλεπτική απόδοση του μοντέλου.

Χρησιμοποιώντας το Matplotlib, δημιουργείται ένα οριζόντιο ραβδόγραμμα για την οπτικοποίηση της εισαγωγής των χαρακτηριστικών. Ο άξονας y αναπαριστά τα χαρακτηριστικά, ενώ ο άξονας x αναπαριστά τις αντίστοιχες βαθμολογίες σημαντικότητας. Το μήκος κάθε ράβδου υποδηλώνει τη σημασία του αντίστοιχου χαρακτηριστικού, με τις μεγαλύτερες ράβδους να υποδηλώνουν μεγαλύτερη σημασία.

Η απεικόνιση αυτή παρέχει μια οπτική αναπαράσταση της σχετικής σημασίας κάθε χαρακτηριστικού στο μοντέλο Random Forest. Οι πληροφορίες αυτές μπορεί να είναι πολύτιμες για την επιλογή χαρακτηριστικών, την κατανόηση της συμπεριφοράς του μοντέλου και τον εντοπισμό κρίσιμων παραγόντων που επηρεάζουν τις προβλέψεις για την κατάσταση του δανείου.



Εικόνα 35. Σημαντικότητα χαρακτηριστικών για την χορήγηση δανείου στο μοντέλο Random Forest

5.5.4 Σύγκριση των μοντέλων

Ως τελικό στάδιο της ανάλυσης μηχανικής μάθησης κρίνεται αναγκαίο να συγκρίνουμε την απόδοση των τριών μοντέλων που δημιουργήθηκαν.

Γι' αυτό το σκοπό δημιουργείται η λίστα «accuracy_scores» η οποία περιέχει τις βαθμολογίες ακρίβειας κάθε μοντέλου, οι οποίες απεικονίζονται στον άξονα y. Η λίστα «models» περιέχει τα ονόματα των μοντέλων, τα οποία απεικονίζονται στον άξονα x.

```
import matplotlib.pyplot as plt

accuracy_scores = [accuracy, accuracy_dt, accuracy_rf]


models = ['Logistic Regression', 'Decision Tree', 'Random Forest']

plt.figure(figsize=(10, 6))

plt.bar(models, accuracy_scores, color=['blue', 'green', 'orange'])

plt.xlabel('Models')
```

```
plt.ylabel('Accuracy')  
  
plt.title('Accuracy Comparison of Models')  
  
plt.ylim(0.5, 1)  
  
plt.show()
```



Εικόνα 36. Σύγκριση απόδοσης των τριών μοντέλων

Η πλήρης ανάλυση του κώδικα μηχανικής μάθησης είναι διαθέσιμη στον παρακάτω σύνδεσμο:

[Πλήρης κώδικας διπλωματικής](#)

6. Αποτελέσματα: Ηθικές επιπτώσεις και συστάσεις

6.1 Αποτελέσματα ανάλυσης

Πρωταρχικός σκοπός της παρούσας μελέτης περίπτωσης ήταν η διερεύνηση συσχέτισης του φύλου και της οικογενειακής κατάστασης με την έκβαση της χορήγησης δανείων. Μέσω της μηχανικής μάθησης τα τρία μοντέλα ανέδειξαν κάποια βασικά ευρήματα.

Εξετάζοντας το διάγραμμα συσχέτισης σημαντικότητας χαρακτηριστικών για την έγκριση των δανείων της λογιστικής παλινδρόμησης, αποκαλύπτεται ότι το πιστωτικό ιστορικό αναδεικνύεται ως ο παράγοντας με τη μεγαλύτερη επιρροή στην πρόβλεψη της έγκρισης δανείου, όπως υποδεικνύεται από την υψηλότερη τιμή σημαντικότητας. Αυτό υποδηλώνει ότι το πιστωτικό ιστορικό των αιτούντων επηρεάζει σημαντικά τις αποφάσεις δανειοδότησης, ευθυγραμμιζόμενο με τις συμβατικές πρακτικές όπου ένα θετικό πιστωτικό ιστορικό συχνά ενισχύει την επιλεξιμότητα των δανείων.

Επιπλέον, η εξέταση αναδεικνύει το φύλο και την οικογενειακή κατάσταση ως σχετικά σημαντικές μεταβλητές, αν και με χαμηλότερες τιμές σημαντικότητας σε σύγκριση με το πιστωτικό ιστορικό. Ενώ το φύλο επιδεικνύει μέτρια επίδραση, με τιμή σημαντικότητας ελαφρώς πάνω από 0,5, η οικογενειακή κατάσταση ακολουθεί από κοντά με ελαφρώς χαμηλότερη βαθμολογία σημαντικότητας. Παρά τη χαμηλότερη σημασία τους σε σύγκριση με το πιστωτικό ιστορικό, η παρουσία τους μεταξύ των κορυφαίων προβλεπτικών παραγόντων υποδηλώνει πιθανή σημασία στις αποφάσεις έγκρισης δανείων.

Από την άλλη πλευρά, το διάγραμμα σημαντικότητας χαρακτηριστικών για την χορήγηση δανείου στο μοντέλο τυχαίων δέντρων αναδεικνύει τους βασικούς προσδιοριστικούς παράγοντες που επηρεάζουν τις αποφάσεις έγκρισης δανείων. Μεταξύ των εξεταζόμενων χαρακτηριστικών, το πιστωτικό ιστορικό αναδεικνύεται ως ο παράγοντας με τη μεγαλύτερη επιρροή, υποδεικνύοντας τον κρίσιμο ρόλο του στην αξιολόγηση της πιστοληπτικής ικανότητας του δανειολήπτη. Ακολουθούν το ποσό του

δανείου, και το εισόδημα του αιτούντος, αντίστοιχα, υπογραμμίζοντας περαιτέρω τη σημασία τους στη διαδικασία δανειοδότησης. Τα ευρήματα αυτά υπογραμμίζουν τη σημασία της αξιόπιστης αξιολόγησης του πιστωτικού ιστορικού και της συνετής αξιολόγησης των οικονομικών μεγεθών, όπως το ποσό του δανείου και το εισόδημα του αιτούντος, για τον καθορισμό των αποτελεσμάτων της έγκρισης του δανείου.

Στο τρίτο διάγραμμα, της σημαντικότητας χαρακτηριστικών για την χορήγηση δανείου στο μοντέλο τυχαίου δάσους, επιβεβαιώνεται η σημασία συγκεκριμένων μεταβλητών στον καθορισμό της έγκρισης δανείου, ευθυγραμμιζόμενη με τα ευρήματα του προηγούμενου μοντέλου. Για άλλη μια φορά, το πιστωτικό ιστορικό αναδεικνύεται ως ο παράγοντας με τη μεγαλύτερη επιρροή, υπογραμμίζοντας τον κομβικό του ρόλο στην αξιολόγηση της πιστοληπτικής ικανότητας του δανειολήπτη και της επιλεξιμότητας του δανείου. Ακολουθούν το ποσό του δανείου και το εισόδημα του αιτούντος, αναδεικνύοντας περαιτέρω τον σημαντικό αντίκτυπό τους στα αποτελέσματα της δανειοδότησης. Αυτά τα συνεπή ευρήματα σε διάφορες τεχνικές μοντελοποίησης υπογραμμίζουν την αξιοπιστία και την ανθεκτικότητα των προσδιορισθέντων παραγόντων επιρροής.

Η διαφοροποίηση της σημασίας των χαρακτηριστικών στα τρία μοντέλα θα μπορούσε να αποδοθεί σε διάφορους παράγοντες, συμπεριλαμβανομένων των εγγενών διαφορών στις μεθοδολογίες και τις υποκείμενες παραδοχές τους. Ενώ η λογιστική παλινδρόμηση, ως γραμμικό μοντέλο, αποδίδει συντελεστές σε κάθε χαρακτηριστικό με βάση τον αντίκτυπό τους στο προβλεπόμενο αποτέλεσμα, υποθέτει γραμμική σχέση μεταξύ των χαρακτηριστικών και της μεταβλητής-στόχου. Παρά το γεγονός αυτό, η λογιστική παλινδρόμηση μπορεί να αποδώσει τα πιο ακριβή αποτελέσματα λόγω της ικανότητάς της να αποτυπώνει αποτελεσματικά τις γραμμικές σχέσεις.

Από την άλλη πλευρά, τα δέντρα απόφασης, συμπεριλαμβανομένου του μοντέλου τυχαίου δάσους, διαμερίζουν το χώρο των χαρακτηριστικών με βάση το κέρδος πληροφορίας ή τη μείωση των άχρηστων πληροφοριών σε κάθε διαχωρισμό, επιτρέποντάς τους να συλλάβουν πιο αποτελεσματικά μη γραμμικές σχέσεις και αλληλεπιδράσεις μεταξύ των χαρακτηριστικών. Ωστόσο, τα δέντρα αποφάσεων είναι επιρρεπή στην υπερπροσαρμογή, ιδίως με σύνολα δεδομένων υψηλής διάστασης ή με

θόρυβο, γεγονός που μπορεί να επηρεάσει τη σταθερότητα των κατατάξεων σπουδαιότητας των χαρακτηριστικών.

Με βάση τη σύγκριση των αποτελεσμάτων ακρίβειας και των αναφορών ταξινόμησης των τριών μοντέλων, είναι προφανές ότι τα μοντέλα τυχαίου δάσους και λογιστικής παλινδρόμησης πέτυχαν τα υψηλότερα αποτελέσματα ακρίβειας, και τα δύο με περίπου 0,80. Ωστόσο, με μια πιο προσεκτική εξέταση, παρατηρούμε κάποιες διαφορές στις μετρήσεις των επιδόσεών τους.

Το μοντέλο τυχαίου δάσους επέδειξε ισορροπημένες βαθμολογίες ακρίβειας και ανάκλησης και για τις δύο κλάσεις, με ελαφρώς χαμηλότερη ακρίβεια για την κλάση 0 σε σύγκριση με την κλάση 1. Αυτό δείχνει ότι το μοντέλο αναγνώρισε σωστά ένα σημαντικό μέρος της θετικής κλάσης (1), διατηρώντας παράλληλα ένα αξιοσέβαστο επίπεδο ακρίβειας. Ωστόσο, η ακρίβεια για την κλάση 0 είναι σχετικά χαμηλότερη, γεγονός που υποδηλώνει κάποια περιθώρια βελτίωσης στον σωστό εντοπισμό περιπτώσεων της αρνητικής κλάσης (0).

Από την άλλη πλευρά, το μοντέλο λογιστικής παλινδρόμησης πέτυχε υψηλότερη ακρίβεια για την κλάση 0, υποδηλώνοντας υψηλότερο ποσοστό σωστά αναγνωρισμένων περιπτώσεων της αρνητικής κλάσης, αλλά ελαφρώς χαμηλότερη ανάκληση σε σύγκριση με το μοντέλο τυχαίου δάσους. Αυτό υποδηλώνει ότι ενώ το μοντέλο λογιστικής παλινδρόμησης ήταν πιο ακριβές στον εντοπισμό περιπτώσεων της αρνητικής κλάσης, ενδέχεται μην παρείχε πλήρως ακριβές προβλέψεις για κάποιες θετικές περιπτώσεις.

Το μοντέλο δέντρου απόφασης, ενώ πέτυχε παρόμοιο σκορ ακρίβειας με το τυχαίο δάσος, επέδειξε ελαφρώς χαμηλότερη ακρίβεια και ανάκληση και για τις δύο κλάσεις σε σύγκριση με τα άλλα δύο μοντέλα. Ωστόσο, διατήρησε μια ισορροπημένη απόδοση και για τις δύο κλάσεις.

Συμπερασματικά, ενώ και τα τρία μοντέλα πέτυχαν σχετικά υψηλές βαθμολογίες ακρίβειας, η επιλογή μεταξύ τους μπορεί να εξαρτάται από τις ειδικές απαιτήσεις της εκάστοτε εργασίας. Τα μοντέλα τυχαίου δάσους και προσφέρουν ισορροπημένες μετρήσεις απόδοσης, με το μοντέλο τυχαίου δάσους να παρουσιάζει ελαφρώς

καλύτερη ανάκληση για τη θετική κατηγορία, ενώ το μοντέλο λογιστικής παλινδρόμησης παρουσιάζει υψηλότερη ακρίβεια για την αρνητική κατηγορία. Το μοντέλο δέντρου απόφασης παρέχει μια απλούστερη ερμηνεία, αλλά μπορεί να θυσιάσει κάποιες επιδόσεις σε σύγκριση με τα άλλα δύο μοντέλα.

Παρά τις διαφορές αυτές, η διερεύνησή αναδεικνύει την αξία της χρήσης διαφορετικών τεχνικών μοντελοποίησης για την απόκτηση ολοκληρωμένων γνώσεων σε πολύπλοκα σύνολα δεδομένων. Ο καθοριστικός ρόλος της μηχανικής μάθησης εδραιώνεται στην αποκάλυψη αξιοποιήσιμων πληροφοριών από τεράστια και περίπλοκα σύνολα δεδομένων. Αξιοποιώντας προηγμένους αλγορίθμους και τεχνικές, οι οργανισμοί μπορούν να βελτιώσουν τις διαδικασίες λήψης αποφάσεων, να βελτιστοποιήσουν την κατανομή των πόρων και να μειώσουν αποτελεσματικά τους κινδύνους. Καθώς συνεχίζουμε να περιηγούμαστε στην εποχή των μεγάλων δεδομένων, η σημασία της μηχανικής μάθησης στην προώθηση της τεκμηριωμένης λήψης αποφάσεων και στην προώθηση της καινοτομίας δεν μπορεί να υπερεκτιμηθεί.

6.2 Στρατηγικές για υπεύθυνη τεχνητή νοημοσύνη και μηχανική μάθηση στον τραπεζικό τομέα

Έχοντας ολοκληρώσει την βιβλιογραφική ανασκόπηση του προβλήματος αναδείχθηκε η διαπίστωση ότι η ενσωμάτωση της τεχνητής νοημοσύνης και της μηχανικής μάθησης στον τραπεζικό τομέα εγείρει μια πληθώρα ηθικών προβληματισμών, που κυμαίνονται από την αλγοριθμική προκατάληψη και τις διακρίσεις έως την προστασία και τη διαφάνεια των δεδομένων. Αναγνωρίζεται ολοένα και περισσότερο η ανάγκη για υπεύθυνες πρακτικές και αλγοριθμικά μοντέλα, δίνοντας προτεραιότητα στις ηθικές αρχές, τις ανθρώπινες αξίες και την κοινωνική ευημερία.

Διερευνώντας τις στρατηγικές για την προώθηση της υπεύθυνης εφαρμογής τεχνητής νοημοσύνης και της μηχανικής μάθησης στον τραπεζικό κλάδο, η προσπάθεια για την αντιμετώπιση βασικών ηθικών προκλήσεων και για τον μετριασμό της προκατάληψης και της μεροληψίας στη λήψη αποφάσεων είναι αναγκαία. Από την ανάπτυξη ολοκληρωμένων ηθικών πλαισίων έως την εφαρμογή μέτρων αλγοριθμικής διαφάνειας, δικαιοσύνης και προστασίας της ιδιωτικότητας, οι τράπεζες πρέπει να περιηγηθούν σε ηθικές εκτιμήσεις για να οικοδομήσουν εμπιστοσύνη, να διατηρήσουν την ακεραιότητα και να διασφαλίσουν ισότιμη πρόσβαση στις χρηματοπιστωτικές υπηρεσίες.

Εμβαθύνοντας στην έννοια της δικαιοσύνης, στρέφουμε την προσοχή μας στην παροχή πρακτικών συστάσεων για οργανισμούς και χρηματοπιστωτικά ιδρύματα που επιδιώκουν να επιτύχουν ισορροπία μεταξύ αλγοριθμικής δικαιοσύνης και αποτελεσματικότητας στις πρακτικές δανεισμού. Σε ένα ευρύ επίπεδο, η προσπάθεια αυτή μπορεί να κατανεμηθεί σε διαφορετικούς τομείς, καθένας από τους οποίους απαιτεί προσεκτική εξέταση και προληπτική δράση.

Ανάπτυξη ηθικού πλαισίου

Η ανάπτυξη ολοκληρωμένων ηθικών πλαισίων είναι αναγκαίο να αποτελούνται από κατευθυντήριες γραμμές, αρχές και βέλτιστες πρακτικές για τη λήψη ηθικών αποφάσεων, δίνοντας έμφαση στη διαφάνεια, τη δικαιοσύνη, τη λογοδοσία και την προστασία της ιδιωτικής ζωής.

Τα δεοντολογικά πλαίσια παρέχουν στις τράπεζες σαφείς κατευθύνσεις για τον σχεδιασμό, την εφαρμογή και την παρακολούθηση των διαδικασιών που βασίζονται στην μηχανική μάθηση. Παράλληλα, συμβάλλουν στον μετριασμό των κινδύνων όπως η μεροληψία, οι διακρίσεις και η παραβίαση της έκθεσης προσωπικών δεδομένων, ενώ προάγουν την εμπιστοσύνη μεταξύ των πελατών και των υπόλοιπων ενδιαφερομένων μερών.

Η διασφάλιση της συμμόρφωσης και της τήρησης αυτών των πλαισίων από τα διάφορα ενδιαφερόμενα μέρη του τραπεζικού κλάδου απαιτεί συνεχή παρακολούθηση και μηχανισμούς επιβολής τους, προκειμένου να διασφαλιστεί η τήρησή τους.

Προκειμένου αυτό να επιτευχθεί κρίνεται απαραίτητη η σύσταση μίας διεπιστημονικής ομάδας σε κάθε τραπεζικό ίδρυμα η οποία θα πρέπει να αποτελείται από εμπειρογνώμονες σε νομικά και επιχειρηματικά ζητήματα καθώς και ειδικούς μηχανικής μάθησης οι οποίοι συνεργάζονται στενά και συστηματικά. Οι νομικοί σύμβουλοι διαδραματίζουν πρωταρχικό ρόλο στον εντοπισμό νομικών κανονισμών και περιορισμών, στον καθορισμό προτύπων συμμόρφωσης και στην παροχή κατευθύνσεων σχετικά με τις μελλοντικές κανονιστικές επιπτώσεις. Οι επιχειρηματικοί εμπειρογνώμονες ευθυγραμμίζουν τους ορισμούς της δικαιοσύνης με τους στρατηγικούς τους στόχους του οργανισμού, για παράδειγμα, σε περίπτωση που ένα ίδρυμα στοχεύει στην εξυπηρέτηση πελατών με χαμηλό εισόδημα, πρέπει να δώσει προτεραιότητα στη δικαιοσύνη για αυτό το δημογραφικό στοιχείο. Οι ειδικοί μηχανικής μάθησης είναι υπεύθυνοι για την ανάπτυξη ή την προσαρμογή των αλγοριθμικών μοντέλων ώστε να ανταποκρίνονται στο συνολικό πλαίσιο που περιγράφεται από τους νομικούς και τους επιχειρηματικούς εμπειρογνώμονες. Παρόλο που κάθε ομάδα έχει διακριτές αρμοδιότητες, η συνεργασία διασφαλίζει τον ολοκληρωμένο έλεγχο των μοντέλων σε πολλαπλές διαστάσεις.

Η ανάπτυξη εσωτερικών μηχανισμών στα χρηματοπιστωτικά ιδρύματα για δίκαιους αλγορίθμους αποτελεί μια πειστική επιχειρηματική υπόθεση με μακροπρόθεσμα οφέλη. Τα αλγοριθμικά μοντέλα που διέπονται από μηχανισμούς ελαχιστοποίησης της μεροληψίας συμβάλλουν στην επίτευξη αμοιβαία επωφελών αποτελεσμάτων με την πάροδο του χρόνου, ενώ οι βραχυπρόθεσμοι αλγόριθμοι μεγιστοποίησης του κέρδους μπορεί να αποκλείσουν ακούσια τμήματα πελατών, οδηγώντας σε μειωμένες ευκαιρίες για μελλοντικά έσοδα. Επιπλέον, οι πελάτες έχουν όλο και μεγαλύτερη κοινωνική συνείδηση και προτιμούν να συνεργάζονται με οργανισμούς που ευθυγραμμίζονται με τις αξίες τους. Καθώς οι αγορές εξελίσσονται και οι πελάτες αποκτούν περισσότερες επιλογές, μπορεί να στραφούν προς δίκαιους θεσμούς, ενισχύοντας τη σημασία της δικαιοσύνης στη λήψη αλγοριθμικών αποφάσεων (“Algorithmic Bias, Financial Inclusion, and Gender, Women’s”, World Banking 2021).

Αλγοριθμική διαφάνεια

Η διαφάνεια στους αλγορίθμους τεχνητής νοημοσύνης περιλαμβάνει την παροχή σαφών εξηγήσεων για τον τρόπο με τον οποίο οι αλγόριθμοι λαμβάνουν αποφάσεις και εκτελούν προβλέψεις. Οι τράπεζες θα πρέπει να επιδιώκουν να καταστήσουν τα μοντέλα τους διαφανή, δημοσιοποιώντας πληροφορίες σχετικά με τις πηγές δεδομένων, τις αρχιτεκτονικές των μοντέλων, τη σημασία των χαρακτηριστικών και τις διαδικασίες λήψης αποφάσεων.

Η αλγοριθμική διαφάνεια ενισχύει την εμπιστοσύνη, τη λογοδοσία και την κατανόηση από τους καταναλωτές των τραπεζικών υπηρεσιών που βασίζονται στην τεχνητή νοημοσύνη. Επιτρέπει στους πελάτες να αξιολογούν τη δικαιοσύνη και την αξιοπιστία των αλγοριθμικών αποφάσεων και τους δίνει τη δυνατότητα να κάνουν ενημερωμένες επιλογές για τις χρηματοοικονομικές τους συναλλαγές.

Δικαιοσύνη και μετριασμός των προκαταλήψεων

Η αντιμετώπιση της δικαιοσύνης και της μεροληψίας στους αλγορίθμους τεχνητής νοημοσύνης περιλαμβάνει τον εντοπισμό και τον μετριασμό της μεροληψίας που μπορεί να οδηγήσουν σε αποτελέσματα που εισάγουν διακρίσεις για ορισμένες δημογραφικές ομάδες. Τα ιδρύματα πρέπει να εστιάσουν στην εφαρμογή μέτρων για

τη διασφάλιση της δικαιοσύνης, της ισότητας και της συμμετοχικότητας στον σχεδιασμό των λειτουργιών τους που βασίζονται στα μοντέλα μηχανικής μάθησης, όπως η εκπαίδευση μοντέλων με επίγνωση της δικαιοσύνης, η ανίχνευση προκαταλήψεων και ο αλγοριθμικός έλεγχος.

Η ηγεσία, είτε σε εκτελεστικό επίπεδο είτε στο πλαίσιο μιας διαλειτουργικής ομάδας εργασίας, πρέπει να αφιερώσει χρόνο και πόρους για να καθορίσει πού βρίσκεται ο οργανισμός της στο φάσμα μεταξύ δικαιοσύνης και αποτελεσματικότητας. Οι αποφάσεις αυτές θα πρέπει να είναι σκόπιμες και να λαμβάνονται από την ίδια την ηγεσία και όχι να ανατίθενται αποκλειστικά στους επιστήμονες δεδομένων ή στο αλγοριθμικό μοντέλο. Τα βασικά σημεία λήψης αποφάσεων περιλαμβάνουν τον καθορισμό του εύρους των ετικετών στα δεδομένα των πελατών, τον προσδιορισμό τυχόν προστατευόμενων χαρακτηριστικών που πρέπει να αποκλειστούν από το μοντέλο ή να χρησιμοποιηθούν για την αξιολόγηση της δικαιοσύνης και τον προσδιορισμό της σημασίας αυτών των προστατευόμενων χαρακτηριστικών. Επιπλέον, είναι αναγκαίο να καθοριστούν στρατηγικές για την παρακολούθηση του κατά πόσον ο αλγόριθμος τηρεί αυτές τις καθορισμένες παραμέτρους κατά τη διαδικασία λήψης αποφάσεων. Η τακτική υποβολή εκθέσεων από την επιστημονική ομάδα δεδομένων σχετικά με την αποτελεσματικότητα αυτών των στρατηγικών μετριάσμού είναι απαραίτητη. Τέλος, η ηγεσία θα πρέπει να έχει πρόσβαση στις απαραίτητες πληροφορίες ώστε να λαμβάνει τεκμηριωμένες αποφάσεις σχετικά με τη μελλοντική κατεύθυνση του αλγορίθμου.

Προστασία της ιδιωτικότητας των δεδομένων

Η προστασία των προσωπικών δεδομένων των καταναλωτών είναι υψίστης σημασίας στις τραπεζικές συναλλαγές με τεχνητή νοημοσύνη και μηχανική μάθηση, όπου τεράστιες ποσότητες ευαίσθητων προσωπικών δεδομένων υποβάλλονται σε επεξεργασία για τη λήψη οικονομικών αποφάσεων. Οι τράπεζες θα πρέπει να δώσουν προτεραιότητα σε τεχνικές διατήρησης της ιδιωτικότητας, όπως η ανωνυμοποίηση δεδομένων, η κρυπτογράφηση και η διαφορική ιδιωτικότητα, για να διασφαλίσουν τις πληροφορίες των πελατών από μη εξουσιοδοτημένη πρόσβαση, κατάχρηση και παραβιάσεις δεδομένων.

Όπως αναφέρει και η τράπεζα Barclays σε σχετική έκθεσή της, η διαφάνεια και η σαφήνεια στα δεδομένα που συλλέγονται και των σκοπούμενων χρήσεων τους παίζουν καταλυτικό ρόλο για να διασφαλιστεί ότι οι καταναλωτές κατανοούν τα οφέλη που λαμβάνουν ως αντάλλαγμα. Αυτό τους επιτρέπει να λαμβάνουν τεκμηριωμένες αποφάσεις σχετικά με την αξία της ανταλλαγής αυτής για αυτούς.

Ανθρωποκεντρικός σχεδιασμός

Ο ανθρωποκεντρικός σχεδιασμός υπογραμμίζει τη σημασία της συνεκτίμησης των ανθρώπινων αξιών, προτιμήσεων και αναγκών κατά την ανάπτυξη και την εξάπλωση τραπεζικών υπηρεσιών με βάση την αλγοριθμική προσέγγιση μηχανικής μάθησης. Οι τράπεζες θα πρέπει να δίνουν προτεραιότητα στις αρχές του σχεδιασμού με επίκεντρο τον χρήστη, στις δοκιμές ευχρηστίας και στην ανατροφοδότηση των πελατών, ώστε να διασφαλίζεται ότι αυτές οι τεχνολογίες ενισχύουν και δεν αντικαθιστούν τις ανθρώπινες αλληλεπιδράσεις στις διαδικασίες λήψης αποφάσεων.

Παράλληλα, προάγει τον πελατοκεντρισμό, την ενσυναίσθηση και την εμπιστοσύνη στις τραπεζικές υπηρεσίες. Δίνοντας προτεραιότητα στην εμπειρία του χρήστη και την ανθρώπινη ευημερία, οι τράπεζες μπορούν να δημιουργήσουν λύσεις οι οποίες χαρακτηρίζονται ως διαισθητικές, προσβάσιμες και χωρίς αποκλεισμούς για διαφορετικούς πληθυσμούς χρηστών.

Έχοντας αναλύσει όλα τα παραπάνω παραθέτουμε κάποια καίρια ερωτήματα με τα οποία η ηγεσία πρέπει να προχωρά στην εφαρμογή των στρατηγικών της αποφάσεων:

- *Πώς οι ομάδες κινδύνου και οι επικεφαλές των επιχειρήσεων αναγνωρίζουν και επιβλέπουν τους κινδύνους AI/ML στον ψηφιακό μετασχηματισμό και στις υλοποιήσεις που αφορούν τον πελάτη;*
- *Ποιες μέθοδοι είναι πιο αποτελεσματικές για τον εντοπισμό νέων κινδύνων AI/ML καθώς αυτοί αναδύονται; Ποιος φέρει την τελική ευθύνη για τον χειρισμό των κινδύνων AI/ML;*
- *Πώς προσαρμόζονται οι στρατηγικές ψηφιακού μετασχηματισμού ώστε να ληφθούν υπόψη τα διακριτά πλεονεκτήματα της γενεσιουργού τεχνητής νοημοσύνης; Ποια είναι η στρατηγική για την επέκταση της χρήσης της; (“What banking directors should ask about AI and machine learning risks”, EY 2023)*

7. Συμπεράσματα και μελλοντικές κατευθύνσεις

7.1 Σύνοψη των ευρημάτων

Τα βασικά συμπεράσματα προέκυψαν τόσο από την μελέτη περίπτωσης που αναλύθηκε αλλά και από τη βιβλιογραφική ανασκόπηση που πραγματοποιήθηκε.

Ο πρωταρχικός στόχος αυτής της ανάλυσης ήταν να εξετάσει κατά πόσον το φύλο και η οικογενειακή κατάσταση λαμβάνονται υπόψη ως παράγοντες στις αποφάσεις έγκρισης δανείων.

Παρά το γεγονός ότι το φύλο και η οικογενειακή κατάσταση δεν αναδείχθηκαν ως κορυφαίοι παράγοντες πρόβλεψης της έγκρισης δανείου στην ανάλυση της σημασίας των χαρακτηριστικών, η συμπερίληψή τους στην ανάλυση είναι απαραίτητη για τη διασφάλιση της δικαιοσύνης και της ισότητας στις πρακτικές δανειοδότησης.

Αν και οι μεταβλητές αυτές μπορεί να μην είναι οι πρωταρχικοί παράγοντες των αποφάσεων έγκρισης δανείων, η εξέτασή τους συμβάλλει στον μετριασμό πιθανών προκαταλήψεων και διασφαλίζει τη συμμόρφωση με τις κανονιστικές απαιτήσεις που σχετίζονται με δίκαιες πρακτικές δανειοδότησης.

Με τη διενέργεια τέτοιων αναλύσεων, τα πιστωτικά ιδρύματα μπορούν να επιδείξουν τη δέσμευσή τους για την προώθηση της δικαιοσύνης, της διαφάνειας και των ίσων ευκαιριών στην πρόσβαση σε πιστώσεις για όλες τις δημογραφικές ομάδες, ενισχύοντας έτσι την εμπιστοσύνη μεταξύ των δανειοληπτών και των ενδιαφερομένων μερών

Λαμβάνοντας υπόψιν τα κύρια σημεία της βιβλιογραφικής έρευνας, εστιάζουμε στα κάτωθι κύρια σημεία και συμπεράσματα:

- **Επιπτώσεις της μηχανικής μάθησης στην ψηφιακή τραπεζική:** Η ανασκόπηση αναδεικνύει τον σημαντικό αντίκτυπο της μηχανικής μάθησης στη διαμόρφωση του τοπίου της ψηφιακής τραπεζικής. Διάφορες μελέτες

υπογραμμίζουν τις δυνατότητες των αλγορίθμων μηχανικής μάθησης στην ενίσχυση της εμπειρίας των πελατών, τη βελτίωση της λειτουργικής αποδοτικότητας και τη δυνατότητα παροχής εξατομικευμένων χρηματοπιστωτικών υπηρεσιών.

- **Προκλήσεις και ηθικές επιπτώσεις:** Παρά τα πολλά υποσχόμενα οφέλη, η βιβλιογραφία αποκαλύπτει επίσης διάφορες προκλήσεις και ηθικές επιπτώσεις που συνδέονται με την υιοθέτηση της μηχανικής μάθησης στην ψηφιακή τραπεζική. Αυτές περιλαμβάνουν ανησυχίες σχετικά με την προστασία της ιδιωτικής ζωής, την ασφάλεια των δεδομένων, την αλγοριθμική μεροληψία και τη δικαιοσύνη στις διαδικασίες λήψης αποφάσεων.
- **Αλγοριθμική μεροληψία και δικαιοσύνη:** Μία από τις βασικές ανησυχίες που εντοπίστηκαν είναι η παρουσία αλγοριθμικής μεροληψίας στα μοντέλα μηχανικής μάθησης που χρησιμοποιούνται στην ψηφιακή τραπεζική. Οι μελέτες υπογραμμίζουν τη σημασία της αντιμετώπισης της προκατάληψης και της διασφάλισης της δικαιοσύνης στις αλγοριθμικές διαδικασίες λήψης αποφάσεων για την αποφυγή αποτελεσμάτων που εισάγουν διακρίσεις και την προώθηση της χρηματοπιστωτικής ευημερίας.
- **Ρυθμιστικά πλαίσια και κατευθυντήριες γραμμές:** Η επισκόπηση υπογραμμίζει την ανάγκη για ισχυρά ρυθμιστικά πλαίσια και κατευθυντήριες γραμμές που θα διέπουν τη χρήση της μηχανικής μάθησης στην ψηφιακή τραπεζική. Οι ρυθμιστικοί φορείς και οι υπεύθυνοι χάραξης πολιτικής καλούνται να αναπτύξουν ολοκληρωμένες κατευθυντήριες γραμμές που να αντιμετωπίζουν ζητήματα όπως η διαφάνεια, η λογοδοσία και η δικαιοσύνη στην αλγοριθμική λήψη αποφάσεων.

7.2 Περιορισμοί και τομείς για μελλοντική έρευνα

Ολοκληρώνοντας την παρούσα έρευνα, είναι σημαντικό να αναφερθούν οι περιορισμοί της μελέτης καθώς και να προσδιοριστούν κατευθύνσεις για μελλοντική έρευνα. Παρά τον ολοκληρωμένο χαρακτήρα της έρευνάς μας, παραμένουν ορισμένοι περιορισμοί και ευκαιρίες για περαιτέρω διερεύνηση. Αναγνωρίζοντας αυτούς τους περιορισμούς και προτείνοντας τομείς για μελλοντική έρευνα, στόχο αποτελεί η παροχή μιας ολοκληρωμένης προοπτικής για την τρέχουσα κατάσταση που επικρατεί στον παγκόσμιο και εγχώριο τραπεζικό κλάδο σε θέματα τεχνητής νοημοσύνης και μηχανικής μάθησης με σκοπό την περεταίρω διερεύνηση της προκατάληψης και της μεροληψίας και τη συνέχιση της έρευνας στα θέματα που συζητήθηκαν.

Παρά τα πολύτιμα ευρήματα που αποκτήθηκαν από την παρούσα μελέτη, θα πρέπει να αναγνωριστούν διάφοροι περιορισμοί.

Το πεδίο εφαρμογής της παρούσας μελέτης περιορίστηκε στην ανασκόπηση της υπάρχουσας βιβλιογραφίας και των περιπτώσιολογικών μελετών. Περαιτέρω εμπειρική έρευνα και συλλογή πρωτογενών δεδομένων μπορεί να παράσχει πρόσθετες γνώσεις σχετικά με τις ηθικές επιπτώσεις της μηχανικής μάθησης στην ψηφιακή τραπεζική. Τα διαθέσιμα ανοικτά δεδομένα που χρησιμοποιήθηκαν εντοπίστηκαν μετά από εκτενή έρευνα, αφού υπήρχε υψηλός περιορισμός σε αυτό το πεδίο. Τα χρηματοπιστωτικά ιδρύματα λόγω των αυστηρών πλαισίων στην ιδιωτικότητα των προσωπικών δεδομένων αντιμετωπίζουν αποκλεισμούς στη διάθεσή τους σε δημόσιο επίπεδο.

Μία άλλη πτυχή της έρευνας ανέδειξε ότι τα ευρήματα ενδέχεται να μην μπορούν να γενικευτούν σε όλα τα τραπεζικά πλαίσια ή περιοχές. Η μελλοντική έρευνα θα πρέπει να εξετάσει τους ποικίλους ρυθμιστικούς, πολιτιστικούς και κοινωνικοοικονομικούς παράγοντες που επηρεάζουν την υιοθέτηση και τον αντίκτυπο των τεχνολογιών τεχνητής νοημοσύνης στον τραπεζικό τομέα. Λόγω των ποικίλων νομοκανονιστικών πλαισίων σε διαφορετικούς τόπους και χώρες, τα αποτελέσματα εξάγονται με διαφορετικό αντίκτυπο.

Για να αντιμετωπιστούν αυτοί οι περιορισμοί και να προωθηθεί η γνώση σε αυτόν τον τομέα, παρατίθενται οι ακόλουθοι τομείς για μελλοντική έρευνα.

Η διεξαγωγή εμπειρικών μελετών καθορίζει την αξιολόγηση των ηθικών επιπτώσεων των τεχνολογιών τεχνητής νοημοσύνης και μηχανικής μάθησης σε συγκεκριμένα τραπεζικά πλαίσια, συμπεριλαμβανομένων των αντιλήψεων, των στάσεων και των συμπεριφορών των πελατών απέναντι στις καινοτόμες αυτές τραπεζικές υπηρεσίες. Προτείνεται, εφόσον αυτό είναι εφικτό, η διεξαγωγή ποιοτικών ερευνών σε συνεργασία με διακεκριμένα στελέχη στον τομέα και σε χώρες όπου η εξέλιξη των τεχνολογιών αυτών είναι ταχεία και θα είναι δυνατό να αντληθούν πιο ακριβή συμπεράσματα από άτομα που δρουν και εργάζονται συστηματικά για την ενσωμάτωση αυτών των τεχνολογιών στα τραπεζικά προϊόντα και υπηρεσίες.

Όπως διαπιστώθηκε και στην παρούσα μελέτη, η ανάπτυξη και αξιολόγηση ηθικών πλαισίων και κατευθυντήριων γραμμών για την υπεύθυνη χρήση των αλγοριθμικών αυτών μοντέλων στον τραπεζικό τομέα κατέχει ύψιστη σημασία, λαμβάνοντας υπόψη τις απόψεις διαφόρων ενδιαφερόμενων μερών, συμπεριλαμβανομένων των ρυθμιστικών αρχών, των τραπεζών, των καταναλωτών και των φορέων χάραξης πολιτικής. Η συνεργασία με τους κατάλληλους φορείς για τον καθορισμό των ηθικών πλαισίων θα συντελέσει στη διασφάλιση της τήρησης των κανονισμών και της διαφάνειας στην εφαρμογή των μοντέλων αυτών. Επιπλέον, η εξέταση της αποτελεσματικότητας των υφιστάμενων κανονιστικών πλαισίων με ειδικούς όσον αφορά την αντιμετώπιση των ηθικών ανησυχιών που σχετίζονται με την τεχνητή νοημοσύνη και την μηχανική μάθηση στον τραπεζικό τομέα και η πρόταση συστάσεων για την ενίσχυση της κανονιστικής συμμόρφωσης και εποπτείας αποτελεί ακόμη ένα πεδίο μελλοντικής έρευνας.

Παράλληλα, η διερεύνηση του αντίκτυπου των εν λόγω τεχνολογιών στη χρηματοπιστωτική ένταξη, την ευημερία των καταναλωτών και τον ανταγωνισμό της αγοράς στον τραπεζικό τομέα, με έμφαση στον εντοπισμό πιθανών κινδύνων και οφελών για διάφορες ομάδες πληθυσμού χρήζει διερεύνησης σε διαφορετικά πλαίσια και περιβάλλοντα.

Αντιμετωπίζοντας αυτούς τους περιορισμούς και επιδιώκοντας νέες κατευθύνσεις για μελλοντική έρευνα, προωθείται η κατανόηση των ηθικών επιπτώσεων της μηχανικής μάθησης στην ψηφιακή τραπεζική καθώς και στρατηγικές για τη διασφάλιση της υπεύθυνης και ηθικής χρήσης της μηχανικής μάθησης στον τραπεζικό τομέα.

Εν κατακλείδι, ολοκληρώθηκε η εξέταση της τρέχουσας κατάστασης των ηθικών κινδύνων της εφαρμογής τεχνητής νοημοσύνης και μηχανικής μάθησης στο πλαίσιο του ψηφιακού μετασχηματισμού των χρηματοπιστωτικών οργανισμών παγκοσμίως. Μέσα από τη πολυεπίπεδη διερεύνηση εμφάνισης της αλγοριθμικής προκατάληψης και μεροληψίας και του τρόπου αντιμετώπισής τους από το σύνολο των εμπλεκόμενων, καθώς και της ευθύνης για τη διαχείρισή τους, αποκτήθηκαν πολύτιμες γνώσεις σχετικά με τις προκλήσεις και τις ευκαιρίες που υπάρχουν σε αυτόν τον εξελισσόμενο τομέα.

Αναδύθηκε η σημασία της διαφάνειας στην επικοινωνία και τη λήψη αποφάσεων, τονίζοντας την ανάγκη οι οργανισμοί να καθορίσουν συνειδητά τη στάση τους όσον αφορά τη δικαιοσύνη και την εφαρμογή και διατήρηση ορισμένων αρχών για την αντιμετώπιση των ηθικών ζητημάτων. Κοιτάζοντας μπροστά, είναι σαφές ότι η συνεχής έρευνα και επαγρύπνηση θα είναι απαραίτητες για την αντιμετώπιση των νέων κινδύνων καθώς αυτοί αναδύονται και για την προσαρμογή των σχεδίων ψηφιακού μετασχηματισμού ώστε να αξιοποιηθούν υπεύθυνα τα οφέλη.

Καθώς οι τράπεζες συνεχίζουν να περιηγούνται στην αλγοριθμική πολυπλοκότητα της μηχανικής μάθησης, είναι επιτακτική ανάγκη να παραμείνουν προληπτικές στην προσέγγισή τους για τη διαχείριση των κινδύνων και να παρακολουθούν τις εξελίξεις στον τομέα, ώστε να διασφαλίσουν την ηθική και υπεύθυνη ανάπτυξη αυτών των τεχνολογιών.

Βιβλιογραφία και Αρθρογραφία

- ‘AI in finance | OECD Business and Finance Outlook 2021 : AI in Business and Finance’, OECD iLibrary. Ημερομηνία πρόσβασης 19 Ιανουάριος 2024. <https://www.oecd-ilibrary.org/sites/39b6299a-en/index.html?itemId=%2Fcontent%2Fcomponent%2F39b6299a-en#section-d1e3854>.
- ‘Keeping on Track: Fairness and Bias in AI Banking Systems | LinkedIn’. Ημερομηνία πρόσβασης 14 Ιανουάριος 2024. <https://www.linkedin.com/pulse/keeping-track-fairness-bias-ai-banking-systems-james-craggs/>.
- ‘Understanding Bias in Machine Learning’. Ημερομηνία πρόσβασης 13 Ιανουάριος 2024. <https://arxiv.org/abs/1909.01866>.
- ‘2000-Present: A History of America’s Banks and The ABA’. Ημερομηνία πρόσβασης 1 Ιανουάριος 2024. <https://www.aba.com/about-us/our-story/aba-history/2000-present>.
- ‘ΕΘΝΙΚΗ ΝΟΜΟΘΕΣΙΑ’. *Γενική Γραμματεία Ισότητας και Ανθρωπίνων Δικαιωμάτων* (blog). Ημερομηνία πρόσβασης 14 Ιανουάριος 2024. <https://isotita.gr/nomothesia/ethniki-nomothesia/>.
- ‘Προστασία δεδομένων στην ΕΕ - Ευρωπαϊκή Επιτροπή’. 2021. 4 Ιούνιος 2021. https://commission.europa.eu/law/law-topic/data-protection/data-protection-eu_el.
- ‘A Survey on Bias and Fairness in Machine Learning | ACM Computing Surveys’. Ημερομηνία πρόσβασης 13 Ιανουάριος 2024. <https://dl.acm.org/doi/10.1145/3457607>.
- ‘About NICE’. Ημερομηνία πρόσβασης 11 Ιανουάριος 2024. <https://www.nice.com/company/about-us>.
- ‘AI Discrimination and Bias in Financial Services’, EY. Ημερομηνία πρόσβασης 12 Ιανουάριος 2024. https://www.ey.com/en_us/forensic-integrity-services/ai-discrimination-and-bias-in-financial-services.

‘Ankara Üniversitesi Dil ve Tarih-Coğrafya Fakültesi Dergisi » Makale » ALAN TURİNG’İN TOPLUMBİLİMSEL DÜŞÜNÜ: TOPLUMSAL BİR DÜŞ OLARAK YAPAY ZEKÂ’.
Hμερομηνία πρόσβασης 10 Δεκέμβριος 2023.
<https://dergipark.org.tr/tr/pub/dtcfdergisi/issue/66796/1044708>.

‘Artificial Intelligence & Machine Learning in Banking’. 2021. 30 Σεπτέμβριος 2021.
<https://www.zucisystems.com/blog/future-of-ai-and-machine-learning-in-banking/>.

Kaur, D., Sahdev, S., Sharma, D., & Siddiqui, L. (2020). Banking 4.0: ‘The Influence of Artificial Intelligence on the Banking Industry & How AI Is Changing the Face of Modern Day Banks’. *Mechanical Engineering eJournal*. <https://doi.org/10.34218/ijm.11.6.2020.049>.

‘Banking Risks from AI and Machine Learning’, EY. Ημερομηνία πρόσβασης 19 Ιανουάριος 2024.
https://www.ey.com/en_us/board-matters/banking-risks-from-ai-and-machine-learning.

Berk, Richard, Hoda Heidari, Shahin Jabbari, Michael Kearns, και Aaron Roth. 2021. ‘Fairness in Criminal Justice Risk Assessments: The State of the Art’. *Sociological Methods & Research* 50 (1): 3–44. <https://doi.org/10.1177/0049124118782533>.

‘Bias in Algorithmic Decision making in Financial Services Barclays Response. Ημερομηνία πρόσβασης 13 Ιανουάριος 2024.
https://www.google.com/search?q=Bias+in+Algorithmic+Decision+making+in+Financial+Services+Barclays+Response%5C&oq=Bias+in+Algorithmic+Decision+making+in+Financial+Services++Barclays+Response%5C&gs_lcrp=EgZjaHJvbWUyBggAEEUYOdIBBzk1N2owajeoAgCwAgA&sourceid=chrome&ie=UTF-8.

Breiman, Leo. 2001. ‘Random Forests. *Machine Learning* 45, 5–32’. *Machine Learning* 45 (1): 5–32. <https://doi.org/10.1023/A:1010933404324>.

Castaneda, Juliana, Assumpta Jover, Laura Calvet, Sergi Yanes, Angel A. Juan, και Milagros Sainz. 2022. ‘Dealing with Gender Bias Issues in Data-Algorithmic Processes: A Social-Statistical Perspective’. *Algorithms* 15 (9): 303. <https://doi.org/10.3390/a15090303>.

Çelik, Özer. 2018. ‘A Research on Machine Learning Methods and Its Applications’. *Journal of Educational Technology and Online Learning* 1 (3): 25–40.
<https://doi.org/10.31681/jetol.457046>.

- ‘Chapter 1 | Python For Everyone | Trinket’. Ημερομηνία πρόσβασης 17 Ιανουάριος 2024.
<https://books.trinket.io/pfe/01-intro.html>.
- ‘Chapter 1: Python Basics’. Ημερομηνία πρόσβασης 17 Ιανουάριος 2024.
<https://www.tomasbeuzen.com/python-programming-for-data-science/chapters/chapter1-basics.html>.
- ‘Data-Centric AI: The Underdog Game Changer in AI’. Ημερομηνία πρόσβασης 19 Ιανουάριος 2024. <https://kaggle.com/code/muhammadirfanakbar/data-centric-ai-the-underdog-game-changer-in-ai>.
- Dwork, Cynthia, Moritz Hardt, Toniann Pitassi, Omer Reingold, και Richard Zemel. 2012. ‘Fairness through Awareness’. Στο *Proceedings of the 3rd Innovations in Theoretical Computer Science Conference*, 214–26. Cambridge Massachusetts: ACM.
<https://doi.org/10.1145/2090236.2090255>.
- Figuroa Domejean, Oswaldo. 2020. ‘Project: Loan Prediction’, Οκτώβριος.
- Gensler, Gary, και Lily Bailey. 2020. ‘Deep Learning and Financial Stability’. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3723132>.
- ‘Google Colab: Comprehensive Guide for Data Science and ML | Mike Urmeneta, Ed.D.’ 2023. 20 Μάιος 2023. <https://allthingy.com/google-colab-comprehensive-guide-for-data-science-and-ml/>.
- ‘History of digital banking: The rise of digitisation and digital banks’. χ.χ. Ημερομηνία πρόσβασης 1 Ιανουάριος 2024. <https://www.retailbankerinternational.com/comment/history-digital-banking/>.
- January 2013, 15th. 2013. ‘The Irresistible Rise of Digital Banking - FinTech Futures: Global Fintech News & Intelligence’. 15 Ιανουάριος 2013.
<https://www.fintechfutures.com/2013/01/the-irresistible-rise-of-digital-banking/>.
- Jeanette, Eric. 2018. ‘About Us - Dream Home Financing’. 26 Απρίλιος 2018.
<https://dreamhomefinancing.com/AboutUs.aspx>.

- Johnson, Kristin N., Frank A. Pasquale, και Jennifer Elisa Chapman (formerly Smith). 2019. ‘Artificial Intelligence, Machine Learning, and Bias In Finance: Toward Responsible Innovation’. *Information Systems & Economics eJournal*.
<https://consensus.app/papers/intelligence-machine-learning-bias-finance-toward-johnson/5718aee204d7533aa1ed7dbe5af8262b/>.
- ‘Kaggle’. 2023. Στο *Wikipedia*.
<https://en.wikipedia.org/w/index.php?title=Kaggle&oldid=1192054330>.
- Kaminskyi, Andrii, Maryna Nehrey, και Larysa Zomchak. 2021. ‘Machine learning methods application for consumer banking’. *SHS Web of Conferences* 107 (Μάιος): 12001.
<https://doi.org/10.1051/shsconf/202110712001>.
- Kelly, Sonja, και Mehrdad Mirpourian. ‘Algorithmic Bias, Financial Inclusion, and Gender’.
<https://www.womensworldbanking.org/insights/algorithmic-bias-financial-inclusion-and-gender/>
- ‘Loan Data Set’. Ημερομηνία πρόσβασης 20 Ιανουάριος 2024.
<https://www.kaggle.com/datasets/burak3ergun/loan-data-set>.
- Malyshev, Alex. 2023. ‘What Is Digital Banking? Meaning, Types and Benefits | SDK.Finance’.
SDK.Finance - White-Label Digital Banking Software (blog). 7 Νοέμβριος 2023.
<https://sdk.finance/what-is-digital-banking/>.
- MEGARGEL, Alan, Venky SHANKARARAMAN, και Terence P. C. FAN. 2018. ‘SOA maturity influence on digital banking transformation’. *IDRBT Journal of Banking Technology* 2 (2): 1–27.
- Melnychenko, Svitlana, Svitlana Volosovych, και Yurii Baraniuk. 2020. ‘DOMINANT IDEAS OF FINANCIAL TECHNOLOGIES IN DIGITAL BANKING’. *Baltic Journal of Economic Studies* 6 (1): 92–99. <https://doi.org/10.30525/2256-0742/2020-6-1-92-99>.
- Nasteski, Vladimir. 2017. ‘An overview of the supervised machine learning methods’.
HORIZONS.B 4 (Δεκέμβριος): 51–62. <https://doi.org/10.20544/HORIZONS.B.04.1.17.P05>.
- OECD. 2019a. *Artificial Intelligence in Society*. OECD. <https://doi.org/10.1787/eedfee77-en>.

OECD Business and Finance Outlook 2019: Strengthening Trust in Business. OECD Business and Finance Outlook. OECD. <https://doi.org/10.1787/af784794-en>.

‘Product Recommendation Algorithms in the Age of Omnichannel Retailing – An Intuitive Clustering Approach’. χ.χ. Ημερομηνία πρόσβασης 3 Ιανουάριος 2024.
https://www.researchgate.net/publication/321633756_Product_Recommendation_Algorithms_in_the_Age_of_Omnichannel_Retailing_-_An_Intuitive_Clustering_Approach.

C A Padmanabha Reddy, Y, P Viswanath, και B Eswara Reddy. 2018. ‘Semi-supervised learning: a brief review’. *International Journal of Engineering & Technology* 7 (1.8): 81.
<https://doi.org/10.14419/ijet.v7i1.8.9977>.

‘Proceedings of the 30th International Conference on Neural Information Processing Systems | Guide Proceedings’. Ημερομηνία πρόσβασης 14 Ιανουάριος 2024.
<https://dl.acm.org/doi/proceedings/10.5555/3157096>.

‘Protected characteristics | EHRC’. Ημερομηνία πρόσβασης 14 Ιανουάριος 2024.
<https://www.equalityhumanrights.com/equality/equality-act-2010/protected-characteristics?return-url=https%3A%2F%2Fwww.equalityhumanrights.com%2Fsearch%3Fkeys%3Dprotected%2Bcharateristics>.

‘Review into Bias in Algorithmic Decision-Making’, Centre for Data Ethics and Innovation.
<https://www.gov.uk/government/publications/cdei-publishes-review-into-bias-in-algorithmic-decision-making>

Shanti, Riris, Wahyu Avianto, και Wahyu Ari Wibowo. 2022. ‘A Systematic Review on Banking Digital Transformation’. *Jurnal Ad’ministrare* 9 (2): 543–52.
<https://doi.org/10.26858/ja.v9i2.40584>.

Shinde, Pramila P., και Seema Shah. 2018. ‘A Review of Machine Learning and Deep Learning Applications’. Στο *2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBEA)*, 1–6. <https://doi.org/10.1109/ICCUBEA.2018.8697857>.

‘Slope One’. 2023. Στο *Wikipedia*.
https://en.wikipedia.org/w/index.php?title=Slope_One&oldid=1169363625.

- Sorbet, Anna. 2022. 'History of Mobile Banking – How It All Started? | Finanteq'. FINANTEQ MOBILE BANKING SOLUTIONS. 24 Νοέμβριος 2022. <https://finanteq.com/blog/fintech-trends/history-of-mobile-banking-how-it-all-started/>.
- Tabiaa, Meriem, και Abdellah Madani. 2019. 'The deployment of Machine Learning in eBanking: A Survey'. Στο *2019 Third International Conference on Intelligent Computing in Data Sciences (ICDS)*, 1–7. <https://doi.org/10.1109/ICDS47004.2019.8942379>.
- 'The Digital Revolution in Banking - Gail Kelly - Google Books'. χ.χ. Ημερομηνία πρόσβασης 23 Δεκέμβριος 2023. https://books.google.gr/books/about/The_Digital_Revolution_in_Banking.html?id=JgsbrgEACAAJ&redir_esc=y.
- Tsafack Chetsa, Ghislain Landry. 2021. 'SAIF in Action: A Case Study'. Στο *Towards Sustainable Artificial Intelligence: A Framework to Create Value and Understand Risk*, επιμέλεια Ghislain Landry Tsafack Chetsa, 67–82. Berkeley, CA: Apress. https://doi.org/10.1007/978-1-4842-7214-5_6.
- 'Equality and Human Rights Commission| EHRC'. Ημερομηνία πρόσβασης 14 Ιανουάριος 2024. <https://www.equalityhumanrights.com/equality-act/protected-characteristics>.
- 'Welcome to Python.Org'. 2024. Python.Org. 12 Ιανουάριος 2024. <https://www.python.org/>.
- 'What Is Machine Learning?' NVIDIA Data Science Glossary. Ημερομηνία πρόσβασης 11 Δεκέμβριος 2023. <https://www.nvidia.com/en-us/glossary/data-science/machine-learning/>.
- 'What Is Machine Learning? | IBM'. χ.χ. Ημερομηνία πρόσβασης 10 Δεκέμβριος 2023. <https://www.ibm.com/topics/machine-learning>.
- Zhang, Yagang, επιμ. 2010. *New Advances in Machine Learning*. InTech. <https://doi.org/10.5772/225>.