



ΕΛΛΗΝΙΚΗ ΔΗΜΟΚΡΑΤΙΑ  
Εθνικόν και Καποδιστριακόν  
Πανεπιστήμιον Αθηνών

— ΙΔΡΥΘΕΝ ΤΟ 1837 —

ΣΧΟΛΗ ΟΙΚΟΝΟΜΙΚΩΝ ΚΑΙ ΠΟΛΙΤΙΚΩΝ ΕΙΣΤΗΜΩΝ  
ΤΜΗΜΑ ΟΙΚΟΝΟΜΙΚΩΝ ΕΠΙΣΤΗΜΩΝ

Πρόγραμμα Μεταπτυχιακών Σπουδών  
«Εφαρμοσμένη Διαχείριση Κινδύνων»

**ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ**

**Χρήση Artificial Intelligence και Machine Learning από  
τα Χρηματοπιστωτικά Ιδρύματα**

ΟΝΟΜΑ ΦΟΙΤΗΤΗ : Αλέξανδρος Γκόλφης

ΕΠΙΒΛΕΠΩΝ ΚΑΘΗΓΗΤΗΣ : Φαίδων Καλφάογλου

ΑΘΗΝΑ

ΟΚΤΩΒΡΙΟΣ 2021



## Περίληψη

Η παρούσα Διπλωματική Εργασία πραγματεύεται την χρησιμότητα των νέων τεχνολογικών εργαλείων του Machine Learning και Artificial Intelligent στην ανάλυση και διαχείριση του Πιστωτικού Κινδύνου. Αρχικά, ορίζεται ο πιστωτικός κίνδυνος και αναλύονται οι διάφοροι μέθοδοι που χρησιμοποιούν τα Χρηματοπιστωτικά Ιδρύματα ώστε να αξιολογούν το ρίσκο του πελατολογίου τους. Στην συνέχεια, γίνεται αναφορά στον ορισμό των νέων τεχνολογιών αυτών και πιο συγκεκριμένα στις μεθόδους που δημιουργούν ένα μοντέλο Machine Learning καθώς όμως και τα οφέλη της Τεχνητής Νοημοσύνης όχι μόνο για το Τραπεζικό σύστημα αλλά και για τους καταναλωτές. Ακόμα, αναλύονται μερικά από τα οφέλη χρήσης των τεχνολογιών αυτών αλλά και τους κινδύνους που ελλοχεύουν. Τέλος, στο εμπειρικό κομμάτι, πραγματοποιείται μια ανάλυση σε δανειολήπτες της Αμερικής σχετικά με την πιθανότητά τους να αθετήσουν μια δανειακή σύμβαση και να διακόψουν την ομαλή αποπληρωμή του δανείου τους. Η ανάλυση βασίζεται στην μεθοδολογία του Random forest και παρουσιάζονται τα αποτελέσματα επιτυχίας του μοντέλου μας.

**Λέξεις Κλειδιά:** Πιστωτικός Κίνδυνος, Επιτροπή της Βασιλείας, Τεχνητή Νοημοσύνη, Μηχανική Μάθηση, Αναμενόμενη Απώλεια, Μη προσδοκώμενη Απώλεια, Τυχαίο Δάσος

## Abstract

This paper analyses credit rating systems through the implementation of new programming methods. First, an overview of credit risk and the financial institutions' monitoring systems are presented. Then the usage of new programming tools, Machine Learning and Artificial Intelligent are discussed. After these tools are examined, the paper gives an overview of both their advantages and disadvantages. The paper finds both numerous benefits, for customers and institutions, and multiple new challenges for the financial sector. Finally, the last section of the paper presents a case study for the United States. Within the usage of big data, customer's transactions, their payments and installment systems are analyzed. The random forest tool, as a machine learning method, is the most significant variable in our model.

**Keywords:** Financial institutions, Banking, Credit Risk, Credit Rating, Credit Scoring, Machine Learning, Artificial Intelligence, Random Forest.

## Περιεχόμενα

Κεφάλαιο 1 .....	8
1.1 Τί είναι ο πιστωτικός κίνδυνος.....	8
1.2 Η Επιτροπή της Βασιλείας .....	9
1.2.1 Πυλώνας I : Απαιτήσεις για ελάχιστο επίπεδο κεφαλαίου .....	9
1.2.2 Πυλώνας II : Διαδικασία Εποπτείας .....	10
1.2.3 Πυλώνας III : Πειθαρχία στους κανόνες της αγοράς.....	10
1.2.4 Οι αστοχίες της Επιτροπής της Βασιλείας και Βασιλεία III .....	10
1.3 Περίγραμμα των συστημάτων εσωτερικής αξιολόγησης .....	11
1.3.1 Ορισμός εσωτερικού συστήματος αξιολόγησης.....	11
1.3.2 Οφέλη από τη χρήση ενός εσωτερικού συστήματος αξιολόγησης.....	11
1.4 Αρχιτεκτονική εσωτερικών συστημάτων αξιολόγησης.....	13
1.4.1 Αξιολογήσεις δανειολήπτη και κατατάξεις.....	13
1.4.2 Πεδίο αξιολόγησης .....	14
1.4.3 Αξιολόγηση βαθμολογίας .....	15
1.5 Διαδικασία αξιολόγησης.....	16
1.5.1 Ανάθεση και έλεγχος των αξιολογήσεων.....	16
1.5.2 Ποσοτική και Ποιοτική Αξιολόγηση .....	16
1.5.3 Μοντέλα αξιολόγησης .....	17
1.5.4 Περίγραμμα μοντέλων αξιολόγησης .....	18
1.6 Εκτίμηση των στοιχείων κινδύνου .....	18
1.6.1 Πιθανότητα αθέτησης (PD).....	19
1.6.2 Απώλεια δεδομένης αθέτησης (LGD) .....	20
1.6.3 Έκθεση στην αθέτηση πληρωμής (EAD) .....	20
1.6.4 Expected Losses.....	21
1.7 Η επανεξέταση των στοιχείων κινδύνου .....	21
1.7.1 Σταθερότητα του PD σε προοπτικές χρονοσειρών .....	21
1.7.2 Χρήσεις εσωτερικών συστημάτων αξιολόγησης .....	22
1.8 Χρήσεις PD για κάθε βαθμό βαθμολογίας.....	22
1.9 Ποσοτικός προσδιορισμός πιστωτικού κινδύνου .....	22
1.9.1 Αναμενόμενη απώλεια (EL) και απροσδόκητη απώλεια (UL) .....	22
1.9.2 Υπολογισμός κινδύνου .....	24
1.10 Δοκιμές stress test.....	24
Κεφάλαιο 2 .....	25
2.1 Εισαγωγή στο Machine Learning.....	25
2.2 Τεχνητά Νευρωνικά Δίκτυα .....	26

2.2.1 Boosting .....	27
2.3 Ταξινόμηση KNN .....	27
2.4 Δέντρο αποφάσεων .....	28
2.5 Τυχαίο δάσος.....	29
2.6 Απλό μοντέλο Bayes .....	29
2.7 Ανάλυση παλινδρόμησης Logistics .....	30
Κεφάλαιο 3 .....	32
3.1 Εισαγωγή στην Τεχνητή Νοημοσύνη .....	32
3.2 Τεχνητή νοημοσύνη στο Τραπεζικό Σύστημα .....	33
3.2.1 Ορισμός Τεχνητής Νοημοσύνης .....	34
3.3 Η μέθοδος AI στο τραπεζικό σύστημα .....	34
3.4 Εφαρμογές AI στο Τραπεζικό Σύστημα .....	36
3.4.1 Ευκαιρίες για χρήση του AI στις εμπορικές τράπεζες.....	36
3.4.2 Αύξηση του ανταγωνισμού .....	37
3.4.3 Αλλαγή προτιμήσεων πελατών.....	37
3.5 Η χρήση του ML για τη μέτρηση του πιστωτικού κινδύνου.....	38
3.6 Μέτρηση ωφελειών από τη χρήση μοντέλων ML.....	39
3.7 Το εποπτικό κόστος της αξιολόγησης των Μοντέλων ML .....	41
3.8 Χρήση ML στην διαδικασία επικύρωσης συστημάτων IRB.....	42
Κεφάλαιο 4 .....	44
4.1 Εφαρμογές AI και ML εντός τραπεζών .....	44
4.2 Εφαρμογές στην πρώτη γραμμή .....	44
4.2.1 Εφαρμογές από την πρώτη και τη δεύτερη γραμμή.....	45
4.2.2 Εφαρμογές στη δεύτερη και τρίτη γραμμή.....	47
4.3 Οφέλη από τη χρήση AI και ML.....	48
4.4 Κίνδυνοι και προκλήσεις κατά τη χρήση AI και ML. ....	48
4.5 Θέματα μοντελοποίησης και δεδομένων .....	49
4.6 Προστασία των καταναλωτών και κίνδυνοι φήμης.....	49
4.7 Συμβάντα διαφάνειας, εκλεκτικότητας και κινδύνου .....	51
4.8 Τραπεζικές εργασίες.....	52
Κεφάλαιο 5 Μελέτη Περίπτωσης.....	53
5.1 Εισαγωγή .....	53
5.2 Ανάλυση Ερευνητικού Πεδίου .....	53
5.3 Data Split .....	54
5.4 Training.....	55
5.5 Prediction .....	56

5.6 Μετρήσεις αξιολόγησης για μη ισορροπημένα δεδομένα δοκιμών.....	56
5.6.1 Precision .....	57
5.6.2 Recall .....	57
5.6.3 F1-Score .....	57
5.7 Αποτελέσματα.....	57
5.7.1 Logistic Regression .....	57
5.7.2 KNN.....	58
5.7.3 SVM Support Vector Machine .....	59
5.7.4 Random Forest .....	60
5.8 Επιλογή ιδανικού μοντέλου .....	61
Επίλογος – Συμπεράσματα – Προοπτικές .....	63
Βιβλιογραφία .....	64
Ελληνική .....	64
Διεθνής .....	66
Διαδικτυακοί Τόποι – Ηλεκτρονικές Πηγές.....	68

# Κεφάλαιο 1

## 1.1 Τί είναι ο πιστωτικός κίνδυνος

Πιστωτικός κίνδυνος είναι ο κίνδυνος που οφείλεται στην αδυναμία ενός δανειστή να αποπληρώσει ένα δάνειο ή να εκπληρώσει μια συμβατική υποχρέωσή του. Ο πιστωτικός κίνδυνος δημιουργείται όταν η πιστοληπτική ικανότητα του αντισυμβαλλομένου είναι χαμηλή και άρα ευπρόσβλητη ακόμα και από πολύ μικρές οικονομικές μεταβολές. Ο εν λόγω κίνδυνος δύναται να χωριστεί σε τρεις διαστάσεις. Η πρώτη διάσταση είναι ο κίνδυνος αθέτησης όπου μετριέται η πιθανότητα να αθετήσει (Probability of Default-PD) κάποιος δανειολήπτης μια συγκεκριμένη πληρωμή. Η δεύτερη διάσταση είναι ο κίνδυνος έκθεσης ο οποίος περιγράφεται από το ποσό που οφείλει ο δανειστής κατά την στιγμή της αθέτησης (Exposure at Default – EAD). Τέλος, η τελευταία διάσταση είναι ο κίνδυνος ανάκτησης ο οποίος χωρίζεται σε δύο υποκατηγορίες οι οποίες ομαδοποιούν ποσοστά. Η πρώτη υποκατηγορία περιγράφει το ποσοστό του ποσού που κατάφερε να ανακτήσει ως προς την συνολική οφειλή ο δανειστής και ονομάζεται ποσοστό ανάκτησης (Recovery Rate), ενώ το ποσοστό του ποσού που δεν κατάφερε να ανακτηθεί ως προς την συνολική οφειλή ονομάζεται απώλεια δεδομένης της αθέτησης (Loss Given Default – LGD).

Στον κίνδυνο αυτό είναι εκτεθειμένα κυρίως τα χρηματοπιστωτικά Ιδρύματα τα οποία η κύρια αποστολή τους είναι η χρηματοδότηση των φυσικών και νομικών προσώπων. Ο πιστωτικός κίνδυνος παραμένει πρωταρχικής σημασίας για τους εν λόγω οργανισμούς και οι διαδικασίες αντιμετώπισής του διαρκώς εξελίσσονται. Αναπτύσσονται διαδικασίες και κανόνες, είτε από τους θεσμούς είτε από τις Εποπτικές Αρχές, οι οποίοι αποσκοπούν στο περιορισμό του πιστωτικού κινδύνου για το χρηματοπιστωτικό ίδρυμα και στην διασφάλιση της κεφαλαιακής του επάρκειας. Τα συστήματα που αναπτύσσουν στόχο έχουν να μετρήσουν τον πιστωτικό κίνδυνο του πελατολογίου τους με σκοπό την βέλτιστη διαχείρισή του.

Τα δύο συστήματα που έχουν αναπτυχθεί και θεσπιστεί είναι η μέθοδος του Credit Scoring και η μέθοδος του Credit Rating. Πιο συγκεκριμένα, η πρώτη μέθοδος χρησιμοποιείται στην χρηματοδότηση ιδιωτών και μικρών επιχειρήσεων και περιλαμβάνει ένα σύστημα αξιολόγησης που κατατάσσει τον πελάτη σε διάφορες κατηγορίες πιστωτικού κινδύνου. Το Score αυτό προκύπτει ύστερα από εισαγωγή μεταβλητών από τα αρμόδια στελέχη των ιδρυμάτων με σκοπό να ολοκληρωθεί η αξιολόγηση των πελατών. Η μέθοδος του Credit Rating σχετίζεται με την χρηματοδότηση πιο μεγάλων επιχειρήσεων η αξιολόγηση των οποίων στηρίζεται και σε στοιχεία που δεν συμπεριλαμβάνονται σε κάποιο σύστημα αξιολόγησης. Ακόμα, πραγματοποιείται μια πιο υποκειμενική εξέταση, καθώς και μια πιο ολιστική και συνεχή παρακολούθηση του πελάτη ή του δανειζόμενου.

Το 2001, τα χρηματοπιστωτικά ιδρύματα ξεκινούν να βελτιώνουν ταχέως τις τεχνικές διαχείρισης κινδύνων προκειμένου να αντιμετωπίσουν δραματικές αλλαγές στα προφίλ πιστωτικού κινδύνου τους. Οι ενέργειες αυτές θα υποστηριχθούν και από την Επιτροπή της Βασιλείας η οποία και θεσμοθετήθηκε ένα χρόνο πριν. Εκεί αναφέρονταν χαρακτηριστικά και η προετοιμασία των χρηματοπιστωτικών ιδρυμάτων για την υιοθέτηση του πλαισίου για τη διαμόρφωση των εσωτερικών πυλώνων και αρχών. Με αυτόν τον τρόπο, οδηγούνται τα χρηματοπιστωτικά ιδρύματα στην διαχείριση του πιστωτικού



κινδύνου μέσω εσωτερικών συστημάτων αξιολόγησης αλλά και στην εμφάνιση και βελτίωση αυτών.

Σημαντική παρατήρηση, ακόμα, αποτελεί ότι πραγματοποιείται έλεγχος του πιστωτικού κινδύνου τόσο σε ανάλυση πιστούχου όσο και σε χαρτοφυλακίου. Αναλυτικότερα, σχετικά με την ανάλυση που γίνεται στο πελατολόγιο υπολογίζεται τόσο ο κίνδυνος που αναλαμβάνει το χρηματοπιστωτικό ίδρυμα με την χορήγηση δανείων είτε καταναλωτικών, είτε στεγαστικών είτε επαγγελματικών δανείων, είτε και συνολικά σε επίπεδο συνολικού χαρτοφυλακίου. Η μέτρηση αυτή χρησιμοποιείται και στον υπολογισμό των κεφαλαιακών απαιτήσεων που θέσπισε η Επιτροπή της Βασιλείας.

## 1.2 Η Επιτροπή της Βασιλείας

Η επιτροπή της Βασιλείας συστάθηκε στα τέλη του 1974. Πιο συγκεκριμένα ιδρύθηκε την περίοδο που το διεθνές νομισματικό σύστημα μετέβη από το καθεστώς των σταθερών συναλλαγματικών ισοτιμιών, σε εκείνο της ελεύθερης διακύμανσης των συναλλαγματικών ισοτιμιών και στους κινδύνους που θα επέφεραν αυτοί. Έχει αποτελέσει το κατεξοχήν Forum διαμόρφωσης των κανόνων υπολογισμού και διακράτησης των κεφαλαιακών απαιτήσεων των διεθνών τραπεζών. Η Επιτροπή της Βασιλείας αποβλέπει στην διασφάλιση της σταθερότητας του διεθνούς χρηματοπιστωτικού συστήματος και στην διαμόρφωση ισοδύναμων όρων ανταγωνισμού. Στο πλαίσιο αυτό έχουν θεσπιστεί τρεις πυλώνες: i) οι απαιτήσεις για ελάχιστο επίπεδο κεφαλαίου ii) η διαδικασία της εποπτείας iii) η πειθαρχία στις απαιτήσεις της αγοράς. Τα συμπεράσματα και οι προτάσεις της, ωστόσο, δεν έχουν δεσμευτικό χαρακτήρα. Εμείς θα ασχοληθούμε ιδιαίτερα με τους κανόνες που έχουν θεσπιστεί για τον πρώτο κανόνα καθώς μας επηρεάζουν πολύ στην διαχείριση του πιστωτικού κινδύνου από τα χρηματοπιστωτικά ιδρύματα. Ωστόσο, επιγραμματικά θα αναφερθούμε και στους δύο ακόμα πυλώνες.

### 1.2.1 Πυλώνας I : Απαιτήσεις για ελάχιστο επίπεδο κεφαλαίου

Στόχος είναι να βελτιωθεί η ευαισθησία ως προς τον πιστωτικό κίνδυνο της διαδικασίας που αφορά τα κεφαλαιακά διαθέσιμα. Αυτό μπορεί να επιτευχθεί, απαιτώντας υψηλότερα επίπεδα κεφαλαίου από τους δανειζόμενους που φέρουν μεγαλύτερα επίπεδα πιστωτικού κινδύνου και αντίστροφα. Οι τρόποι που μπορεί ένα χρηματοπιστωτικό ίδρυμα να αναπτύξει αυτές τις δραστηριότητες είναι αυτοί που περιγράφονται παρακάτω.

Αρχικά, οι τράπεζες θα πρέπει να χρησιμοποιούν ξεχωριστά συστήματα μέτρησης του πιστωτικού κινδύνου των πελατών τους, πέραν των ήδη απλοποιημένων συστημάτων που έχουν αναπτύξει για τις δανειοδοτήσεις τους. Έτσι, και λόγω των μεγαλύτερων επιπέδων κινδύνου που αναλαμβάνουν, μπορούν με την έγκριση της εποπτικής αρχής να επιλέξουν ένα ή και τα δύο εσωτερικά μοντέλα αξιολόγησης των τραπεζικών κινδύνων που ενδείκνυνται για τον πιστωτικό κίνδυνο. Τέλος, ακολουθεί και η συμφωνία της Βασιλείας II η οποία ενθαρρύνει τις τράπεζες να εξομαλύνουν τις διαδικασίες μέτρησης των κεφαλαίων και να τις ενσωματώνουν στην διαχείριση του πιστωτικού κινδύνου.

### 1.2.2 Πυλώνας II : Διαδικασία Εποπτείας

Η διαδικασία της εποπτείας εστιάζει στις βασικές αρχές της λειτουργίας των τραπεζών σχετικά με την διαχείριση των κινδύνων. Αντικειμενικός στόχος είναι να εξασφαλιστεί ότι οι τράπεζες έχουν επαρκή κεφάλαια για να αντιμετωπίσουν τους μελλοντικούς κινδύνους αλλά και να ενθαρρύνουν τις τράπεζες να αναπτύσσουν συνεχώς τεχνικές διαχείρισης των ενδεχόμενων κινδύνων. Γίνεται, λοιπόν, αμέσως αντιληπτό ότι το κεφάλαιο σε καμία περίπτωση δεν πρέπει και δεν μπορεί να θεωρηθεί ως υποκατάστατο της συνεπούς και σωστής διαχείρισης των κινδύνων. Ωστόσο, η επιτροπή της Βασιλείας αναγνωρίζει τη σχέση που υπάρχει ανάμεσα στο κεφάλαιο το οποίο πρέπει να κρατείται ως διαθέσιμο στις τράπεζες και τη διαχείριση του κινδύνου.

### 1.2.3 Πυλώνας III : Πειθαρχία στους κανόνες της αγοράς

Με την θέσπιση του εν λόγω κανόνα έχουν ως στόχο να πραγματοποιήσουν την εναρμόνιση όλων των εμπλεκόμενων χώρων της αγοράς. Πιο συγκεκριμένα, θα επιδεικνύονται περισσότερα στοιχεία από τις τράπεζες όσο αναφορά τα διαθέσιμα προς επένδυση κεφάλαια, είτε οποιαδήποτε άλλη πληροφορία που σχετίζεται με την διαχείριση των κινδύνων. Ο λόγος είναι για να έχουν οι υφιστάμενοι ή και οι μελλοντικοί επενδυτές εικόνα της τράπεζας κατανοώντας και αξιολογώντας καλύτερα τους ενεχόμενους κινδύνους καθώς και τις μεθόδους διαχείρισής τους. Με τον τρόπο αυτό, θα έχει επέλθει ένα πιο υγιές περιβάλλον το οποίο θα μπορεί να εποπτεύεται και καλύτερα από τις Αρχές. Με άλλα λόγια, ο πυλώνας III στοχεύει στην ενίσχυση της πειθαρχίας της αγοράς μέσω της δημοσίευσης στοιχείων και πληροφοριών που κρίνονται αναγκαία από την επιτροπή της Βασιλείας.

### 1.2.4 Οι αστοχίες της Επιτροπής της Βασιλείας και Βασιλεία III

Τα χρηματοπιστωτικά ιδρύματα είχαν την δυνατότητα να αποκρύπτουν στοιχεία και να διαστρεβλώνουν την πραγματική εικόνα στις εκθέσεις τους σχετικά με τα κεφαλαιακά τους διαθέσιμα αλλά και τους κινδύνους που αντιμετώπιζαν. Το πρόβλημα που δημιουργήθηκε ήταν ότι οι επενδυτές και οι αγορές λάμβαναν στρεβλή εικόνα. Πιο συγκεκριμένα, η ποιότητα των κεφαλαίων που συνυπολογίζονταν στην κεφαλαιακή επάρκεια του χρηματοπιστωτικού ιδρύματος ήταν χαμηλότερη των προσδοκιών, με αποτέλεσμα σε περιόδους κρίσεων να αντιμετωπίζουν σημαντικά προβλήματα ρευστότητας. Τα προβλήματα που δημιουργήθηκαν ήρθαν στην επιφάνεια με την παγκόσμια χρηματοπιστωτική κρίση το 2008, οδηγώντας την Επιτροπή σε αναθεώρηση του Συμφώνου.

Η αναθεώρηση αυτή του Συμφώνου, ξεκίνησε να εφαρμόζεται σταδιακά από το 2013 μέχρι και το 2019. Στην Βασιλεία III θεσπίστηκαν νέοι κανόνες που θα οδηγήσουν στην βελτίωση της ποιότητας των κεφαλαιακών διαθεσίμων, σε καλύτερα αποθεματικά ρευστότητας καθώς και στην αύξηση της κάλυψης έναντι των διάφορων κινδύνων. Με τον τρόπο αυτό, λαμβάνεται υπόψιν και η επίδραση του εξωτερικού περιβάλλοντος που μέχρι

πρότινος είχε αποδειχθεί αναποτελεσματική. Η θέσπιση των πρόσθετων κεφαλαίων για τη διαχείριση των κινδύνων προέκυψαν από την αλληλεπίδραση του παγκόσμιου χρηματοπιστωτικού συστήματος.

Ως απόρροια των αποφάσεων της επιτροπής της Βασιλείας, στην συνέχεια θα αναλυθούν τα εσωτερικά συστήματα που κλήθηκαν να αναπτύξουν τα χρηματοπιστωτικά ιδρύματα προκειμένου να υπολογίσουν τον πιστωτικό κίνδυνο. Πιο συγκεκριμένα, θα αναπτυχθούν οι διαδικασίες του Credit Scoring και του Credit Rating.

### 1.3 Περίγραμμα των συστημάτων εσωτερικής αξιολόγησης

#### 1.3.1 Ορισμός εσωτερικού συστήματος αξιολόγησης

Ένα σύστημα εσωτερικής αξιολόγησης βοηθά τα χρηματοπιστωτικά ιδρύματα να διαχειρίζονται και να ελέγχουν τους πιστωτικούς κινδύνους που υφίστανται είτε μέσω του δανεισμού είτε και άλλων πράξεων, ομαδοποιώντας την πιστοληπτική ικανότητα των δανειστών και την ποιότητα των πιστωτικών συναλλαγών. Για μεγάλο χρονικό διάστημα, πολλά χρηματοπιστωτικά ιδρύματα διαχειρίστηκαν τους πιστωτικούς κινδύνους παρακολουθώντας μόνο την πιστοληπτική ικανότητα κάθε δανειολήπτη. Η διαδικασία λήψης αποφάσεων δανεισμού ήταν αρκετά απλή και επιφανειακή και συχνά λαμβάνονταν αποφάσεις αποδοχής ή απόρριψης. Ακόμα και αν οι δανειολήπτες χρεοκοπούσαν, οι ζημιές συχνά καλύπτονταν επαρκώς από την ασφάλεια ακινήτων.

Μετά την έκρηξη της οικονομικής ύφεσης, το πιστωτικό κόστος αυξήθηκε σημαντικά στα χρηματοπιστωτικά ιδρύματα λόγω του αυξανόμενου αριθμού χρεοκοπημένων δανειοληπτών και της πτώσης της αξίας των εξασφαλίσεων. Επομένως, ο έλεγχος πιστωτικού κινδύνου μετατράπηκε σε μια σημαντική διαχείριση που απαιτεί συνεχώς επανεξέταση. Επιπλέον, οι αλλαγές στο μακροοικονομικό περιβάλλον ανάγκασαν τα χρηματοπιστωτικά ιδρύματα να αναζητήσουν ένα πιο αξιόπιστο πλαίσιο διαχείρισης του πιστωτικού κινδύνου.


Ως εκ τούτου, χρησιμοποιήθηκε ευρέως η μέθοδος της διαχείρισης και στατιστικής ανάλυσης του πιστωτικού κινδύνου μέσω ενός εσωτερικού συστήματος αξιολόγησης. Τα περισσότερα χρηματοπιστωτικά ιδρύματα, συμπεριλαμβανομένων και των μικρών τραπεζών, άρχισαν να υιοθετούν εσωτερικά συστήματα αξιολόγησης για να κατηγοριοποιήσουν τους δανειολήπτες ειδικά μετά το 1998, όταν εισήχθη και η αξιολόγηση από τον Οργανισμό Χρηματοοικονομικών Υπηρεσιών (FSA).

#### 1.3.2 Οφέλη από τη χρήση ενός εσωτερικού συστήματος αξιολόγησης

Στην υπο-ενότητα αυτή θα καταγράψουμε μερικά από τα οφέλη των χρηματοπιστωτικών ιδρυμάτων από την εισαγωγή εσωτερικών συστημάτων αξιολόγησης. Πρώτον, ένα τέτοιο σύστημα επιτρέπει στις τράπεζες να λαμβάνουν αποτελεσματικά αποφάσεις δανεισμού και να διαχειρίζονται την εγκριτική ροή των δανείων με λιγότερη διοικητική εργασία. Δεύτερον, διευκολύνει την καταγραφή της πιστοληπτικής ικανότητας

των δανειστών και της ποιότητας των πιστωτικών συναλλαγών χρησιμοποιώντας ένα μόνο κριτήριο. Επιπλέον, η αξιολόγηση της πιστοληπτικής ικανότητας ολόκληρου του χαρτοφυλακίου καθίσταται δυνατή μέσω της παρακολούθησης των μεταβολών στο ποσοστό της έκθεσης σε πιστωτικό κίνδυνο και στον αριθμό των δανειζόμενων σε κάθε βαθμό αξιολόγησης. Γίνεται, επίσης, δυνατή η ποσοτικοποίηση του πιστωτικού κινδύνου μέσω εκτίμησης της πιθανότητας αθέτησης ανά βαθμό κατάταξης. Οι αναλύσεις αυτές με συνέπεια, πληρότητα και αντικειμενικότητα θα πρέπει να χρησιμεύσουν ως θεμέλια της ορθής διαχείρισης τραπεζών σχετικά με την αξιολόγηση του εν λόγω κινδύνου.

Η βελτίωση της διαχείρισης του πιστωτικού κινδύνου δεν είναι το μόνο όφελος από την χρήση ενός εσωτερικού συστήματος αξιολόγησης. Το σύστημα δίνει επίσης στα χρηματοπιστωτικά ιδρύματα περισσότερες ιδέες και καινοτομίες καθώς και μια πιο σταθερή βάση για στρατηγικές διαχείρισης του πελατειακού τους χαρτοφυλακίου. Χαρακτηριστικό παράδειγμα είναι, ο καθορισμός επιτοκίων δανεισμού σύμφωνα με τις αξιολογήσεις των δανειοληπτών ή την επέκταση της πελατειακής βάσης-στόχου που είναι η πιο κερδοφόρα από την άποψη του κινδύνου και της απόδοσης.



Το εσωτερικό σύστημα αξιολόγησης είναι η προϋπόθεση για τον προηγμένο έλεγχο του πιστωτικού κινδύνου οπότε κάθε χρηματοπιστωτικό ίδρυμα ήταν αναμενόμενο να αναπτύξει το δικό του εσωτερικό σύστημα αξιολόγησης. Κάθε χρηματοπιστωτικό ίδρυμα αντιμετωπίζει ένα διαφορετικό επιχειρηματικό περιβάλλον, επομένως κάθε σύστημα πρέπει να έχει και το δικό του σχέδιο. Για παράδειγμα, ένα πιο απλό πλαίσιο μπορεί να είναι κατάλληλο για πιο μικρά ιδρύματα. Τα χρηματοπιστωτικά ιδρύματα πρέπει να εισαγάγουν το δικό τους σύστημα ανάλογα με τα χαρακτηριστικά των χαρτοφυλακίων δανείων τους, τις λειτουργίες τους, τους στόχους του συστήματος αξιολόγησης, το περιβάλλον που δραστηριοποιούνται αλλά και άλλους παράγοντες. Προφανώς, τα ιδρύματα πρέπει να κάνουν τις απαραίτητες προσαρμογές με ευελιξία λόγω των αλλαγών στο επιχειρηματικό περιβάλλον.

## 1.4 Αρχιτεκτονική εσωτερικών συστημάτων αξιολόγησης

### 1.4.1 Αξιολογήσεις δανειολήπτη και κατατάξεις

Τα εσωτερικά συστήματα αξιολόγησης χρησιμοποιούνται για την εκχώρηση βαθμών είτε σε μεμονωμένους δανειολήπτες (αξιολογήσεις δανειολήπτη) με βάση την πιστοληπτική τους ικανότητα, είτε σε μεμονωμένες συναλλαγές δανείου (αξιολογήσεις πιστωτικής διευκόλυνσης) με βάση την έκθεση στον κίνδυνο. Οι αξιολογήσεις των δανειοληπτών επικεντρώνονται στον πιστωτικό κίνδυνο των πελατών, δηλαδή, εξετάζεται εάν οι οφειλέτες θα χρεοκοπήσουν ή όχι (η πιθανότητα αθέτησης). Ακολουθεί παράδειγμα αξιολόγησης με αντιστοιχία βαθμού κινδύνου και κατηγοριοποίησης δανειοληπτών.

Chart 2: An Example of Borrower Ratings

Borrower rating	Level	Borrower classification
1	Excellent	Normal
2	Prime	
3	Good	
4	Above standard	
5	Standard	
6	Below standard	
7	Needs attention (1)	Needs attention
8	Needs attention (2)	
9	In danger of bankruptcy	In danger of bankruptcy
10	Bankrupt	De facto bankrupt & bankrupt

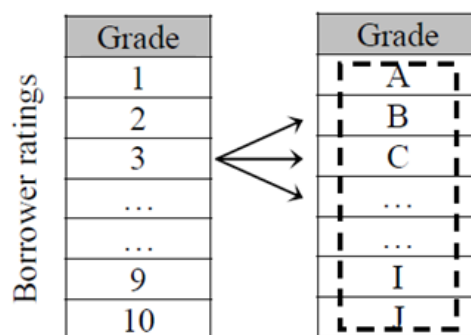
BANK OF JAPAN

Ο παραπάνω είναι και ο πιο συνηθισμένος τύπος συστήματος αξιολόγησης και χρησιμοποιείται από πολλά χρηματοπιστωτικά ιδρύματα. Οι αξιολογήσεις εστιάζουν επίσης και στα ανοίγματα κινδύνων κάθε συναλλαγής. Κατά τον καθορισμό των βαθμών, οι εν λόγω αξιολογήσεις λαμβάνουν υπόψη τις καλύψεις ή την εγγύηση που παρέχεται στα δάνεια κατά τη λήξη, όπως επίσης και στην πιστοληπτική ικανότητα των δανειστών. Με αυτό το σύστημα αξιολόγησης, μπορούν να ανατεθούν διαφορετικοί βαθμοί σε αιτήματα δανείων για κάποιον δανειολήπτη ανάλογα με το βαθμό έκθεσής του στον πιστωτικό κίνδυνο για κάθε συναλλαγή.

Κατά την αξιολόγηση ενός βαθμού πιστωτικού κινδύνου, η πιθανότητα αθέτησης (Probability of Default-PD) είναι ένα κριτήριο για τις αξιολογήσεις ενός δανειολήπτη. Το ποσοστό αναμενόμενης ζημίας (Expected Losses-EL), δηλαδή το PD πολλαπλασιαζόμενο με την προκαθορισμένη ζημία, χρησιμοποιείται για την μέτρηση των κινδύνων που σχετίζονται με μεμονωμένες συναλλαγές. Υπάρχουν δύο τύποι πιστωτικών αξιολογήσεων, οι οποίες είναι πιο περίπλοκες από τις μεμονωμένες αξιολογήσεις δανειοληπτών, δηλαδή, τα

μονοδιάστατα και τα δισδιάστατα συστήματα, όπως αυτά αποτυπώνονται στα παρακάτω πίνακάκια. Με τον όρο πιστωτική διευκόλυνση ορίζεται οποιαδήποτε χορήγηση δανείου ή το άνοιγμα χρεωστικού λογαριασμού για τον πελάτη αυτό, ή την χορήγηση οποιασδήποτε χρηματοδοτικής μίσθωσης (financial leasing) κ.α. Ένα μονοδιάστατο σύστημα βασίζει τις αξιολογήσεις της πιστωτικής διευκόλυνσης μόνο στις αξιολογήσεις του δανειολήπτη πραγματοποιώντας ανοδικές ή πτωτικές προσαρμογές στους βαθμούς, ανάλογα και με τις ανάγκες, για να αντικατοπτρίζει τα χαρακτηριστικά της σχετικής συναλλαγής.

(One-dimensional system)



BANK OF JAPAN

Ένα δισδιάστατο σύστημα συνδυάζει τις αξιολογήσεις του δανειολήπτη με ταυτόχρονη αξιολόγηση των χαρακτηριστικών των μεμονωμένων συναλλαγών του ή διάφορες αποπληρωμές δανείου του ανεξάρτητα από το προφίλ των δανειοληπτών.

Facility ratings (A to J) (Two-dimensional system)

Ratings based on LGD

Grade	1	2	3	...	7	8
1	A			I	J	
2	B					
3	C					
...	D					
...				...		
9	I					J
10						

BANK OF JAPAN

#### 1.4.2 Πεδίο αξιολόγησης

Αρχικά, αξιολογήσεις πρέπει να εκχωρούνται σε όλους τους δανειολήπτες και σε όλες τις συναλλαγές. Το σύστημα αξιολόγησης ενσωματώνει το προφίλ του εκάστοτε χρηματοπιστωτικού ιδρύματος ως προς την αξιολόγηση του πιστωτικού κινδύνου. Επομένως, το σύστημα πρέπει να εφαρμόζεται σε όλους τους πιστωτικούς κινδύνους με απόλυτη συνέπεια. Αυτό με τη σειρά του θα προάγει την ακρίβεια και την αποτελεσματικότητα στις μετρήσεις και στην κατάταξη των βαθμών. Ανάλογα με το μέγεθος και τη φύση των συναλλαγών, ωστόσο, μπορεί να είναι πολύ δύσκολο να

αντιστοιχηθούν όλοι οι βαθμοί με όλες τις συναλλαγές. Οι περιπτώσεις αυτές δεν πρέπει να θεωρούνται εξαιρέσεις, αλλά θα πρέπει να καθοριστούν διαφορετικά κριτήρια για μια τέτοια αντιμετώπιση. Ωστόσο, όλοι οι μεγάλοι δανειολήπτες και οι συναλλαγές τους πρέπει να αξιολογούνται.

Σε αντίθεση με την περίπτωση των εταιρικών δανείων, τα μικρού μεγέθους δάνεια, συμπεριλαμβανομένων και των καταναλωτικών δανείων για ιδιώτες και τα μη εξασφαλισμένα επιχειρηματικά δάνεια για μικρές επιχειρήσεις, θα μπορούσαν να ενταχθούν καλύτερα στη διαχείριση πιστωτικού κινδύνου βάσει ομαδοποίησης ανά τύπο προϊόντος (π.χ. στεγαστικά δάνεια αλλά και χορήγηση πιστωτικών καρτών) και χαρακτηριστικά δανειστών (π.χ., απασχόληση και ηλικία). Για να γίνει αντιληπτή η ακρίβεια των κινδύνων χρησιμοποιώντας στατιστικά δεδομένα, τα προφίλ κινδύνου των συναλλαγών σε κάθε ομάδα πρέπει να είναι ομοιογενή. Τέτοια ομοιογένεια μπορεί να διασφαλιστεί, για παράδειγμα, όχι μόνο με την αξιολόγηση της σταθερότητας των προεπιλεγμένων ποσοστών αλλά και άλλων διάφορων δεδομένων για παράγοντες κινδύνου της κάθε ομαδοποίησης.

#### 1.4.3 Αξιολόγηση βαθμολογίας

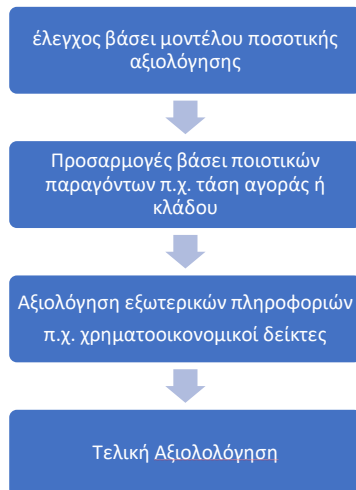
Η ύπαρξη του κατάλληλου αριθμού βαθμών και οι ορισμοί τους, επηρεάζουν επίσης την επάρκεια διαχείρισης του πιστωτικού κινδύνου. Ο αριθμός των βαθμών πρέπει να διασφαλίζει ότι οι δανειολήπτες και οι συναλλαγές που παρουσιάζουν παρόμοιο επίπεδο κινδύνου ομαδοποιούνται. Προφανώς, τα χρηματοπιστωτικά ιδρύματα που ασχολούνται με πολλούς δανειολήπτες και με διαφορετικό βαθμό, η πιστοληπτική ικανότητα πρέπει να έχει σχετικά μεγάλο αριθμό διαβαθμίσεων. Εάν συνεχίζουν οι δανειολήπτες να συγκεντρώνονται σε ένα συγκεκριμένο βαθμό, αυτό μπορεί να είναι ένδειξη ότι ο πιστωτικός κίνδυνος δεν αξιολογείται αποτελεσματικά και με ακρίβεια. Ο ορισμός του κάθε βαθμού θα πρέπει να αναθεωρείται σε τέτοιες περιπτώσεις.

Πάρα πολλοί βαθμοί για έναν μικρό αριθμό δανειοληπτών μπορεί, επίσης, να είναι ακατάλληλοι επειδή η ακρίβεια της εκτίμησης του πιστωτικού κινδύνου μπορεί να μειωθεί εάν ο αριθμός των δανειστών σε κάθε βαθμό είναι πολύ μικρός. Ακόμα, όταν ένα χαρτοφυλάκιο δεν έχει συγκεκριμένη συγκέντρωση σε έναν βαθμό κατά τη στιγμή της δημιουργίας του συστήματος αξιολόγησης, παράγοντες όπως οι αλλαγές στις κυκλικές επιχειρηματικές συναλλαγές μπορούν να προκαλέσουν τη μετατόπιση των βαθμών σε μία κατεύθυνση, η οποία στη συνέχεια να προκαλεί τη συγκέντρωση. Σε τέτοιες περιπτώσεις, θα πρέπει να εξεταστεί η αναθεώρηση των ορισμών των βαθμολογιών και ο αριθμός των βαθμών.

## 1.5 Διαδικασία αξιολόγησης

### 1.5.1 Ανάθεση και έλεγχος των αξιολογήσεων

Κατά τη διαδικασία της εσωτερικής αξιολόγησης, το τμήμα ανάλυσης πιστωτικού κινδύνου ή πιστοληπτικής ανάλυσης ορίζει τους βαθμούς σύμφωνα με την καθιερωμένη πολιτική και διαδικασίες. Η διαδικασία περιλαμβάνει γενικά τα ακόλουθα βήματα:



Αξίζει να σημειωθεί πως καθ' όλη τη διαδικασία πριν την τελική αξιολόγηση πραγματοποιείται συστηματικός περιοδικός έλεγχος. Η διεύθυνση εποπτικού ελέγχου του χρηματοπιστωτικού ιδρύματος επαναξιολογεί και αυτή την τελική αξιολόγηση και προτείνει τυχόν διορθώσεις ή αλλαγές ακόμα και βελτιώσεις.

Οι βαθμοί αξιολόγησης πρέπει πάντα να αντικατοπτρίζουν κατάλληλα τους κινδύνους που συνδέονται με τους δανειολήπτες. Οι αξιολογήσεις, επομένως, είναι απαραίτητες για να αντικατοπτρίζουν τις αλλαγές στην πιστοληπτική ικανότητα των δανειστών. Αυτές περιλαμβάνουν μερικές περιοδικές αναθεωρήσεις του χρόνου γνωστοποίησης των οικονομικών καταστάσεων καθώς και παράτυπες αναθεωρήσεις που πραγματοποιούνται όταν υπάρχουν σημαντικές μεταβολές στην πιστοληπτική ικανότητα των δανειστών, με χαρακτηριστικό παράδειγμα την αθέτηση υποχρέωσης ενός μεγάλου αντισυμβαλλομένου.

### 1.5.2 Ποσοτική και Ποιοτική Αξιολόγηση

Για τις αξιολογήσεις των δανειοληπτών, οι βαθμοί για κάθε δανειολήπτη συνήθως αποφασίζονται χρησιμοποιώντας ποσοτικές πληροφορίες, όπως οικονομικούς δείκτες σχετικά με την δραστηριότητά τους, και ποιοτικές πληροφορίες, όπως οι τάσεις του κλάδου. Ένα μοντέλο ποσοτικής αξιολόγησης χρησιμοποιείται συχνά για την αξιολόγηση μεμονωμένων δανειστών. Επιπλέον, σε πολλές περιπτώσεις, είναι προτιμότερο να



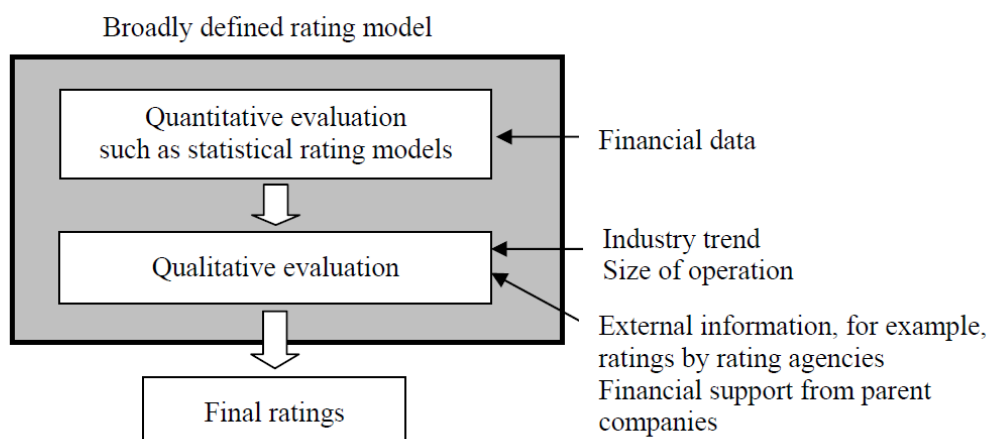
χρησιμοποιούνται ουσιαστικά χρηματοοικονομικά δεδομένα που να αντικατοπτρίζουν τις οικονομικές συνθήκες των δανειστών που δεν καταγράφονται στα λογιστικά δεδομένα, όπως η μη απόδοση περιουσιακών στοιχείων ή και μη πραγματοποιηθείσες ζημιές.

Εάν τα ποσοτικά χρηματοοικονομικά δεδομένα δεν επαρκούν για την ακριβή μέτρηση της πιστοληπτικής ικανότητας των δανειοληπτών, πρέπει να χρησιμοποιείται και η ποιοτική ανάλυση για την πραγματοποίηση των όποιων απαραίτητων προσαρμογών. Πιο συγκεκριμένα, οι ποιοτικοί παράγοντες μπορούν να εκφραστούν με βάση τις ακριβείς ομαδοποιήσεις βαθμολογιών που είτε προστίθενται είτε αφαιρούνται από βαθμολογίες που αντικατοπτρίζουν την ποσοτική αξιολόγηση, αλλά και αντιθέτως οι βαθμοί που βασίζονται στην ποσοτική αξιολόγηση μπορούν να αναβαθμιστούν ή να υποβαθμιστούν ώστε να αντικατοπτρίζουν τους ποιοτικούς παράγοντες.

Απαιτούνται, ακόμη, λεπτομερή κριτήρια προς επεξεργασία για την ποιοτική αξιολόγηση. Συνήθως είναι δύσκολο να εξασφαλιστούν αντικειμενικές κρίσεις στην ποιοτική αξιολόγηση. Τα κριτήρια, επομένως, πρέπει να είναι όσο το δυνατόν πιο συγκεκριμένα και να τεκμηριώνονται λεπτομερώς για την αποφυγή προβλημάτων. Επιπλέον, είναι απαραίτητο να διασφαλιστεί η κοινή κατανόηση μεταξύ των στελεχών οι οποίοι είναι αρμόδιοι για την αξιολόγηση της πιστοληπτικής ικανότητας σχετικά με τα κριτήρια ποιοτικής αξιολόγησης. Μία μέθοδος που μπορεί να διασφαλίσει αυτόν τον κανόνα είναι η πραγματοποίηση εσωτερικών σεμιναρίων εντός του χρηματοπιστωτικού ιδρύματος.

### 1.5.3 Μοντέλα αξιολόγησης

Ως μοντέλο αξιολόγησης μπορεί να οριστεί μια συστηματική διαδικασία ποσοτικής και ποιοτικής αξιολόγησης ή και ανάλυσης στην ανάθεση βαθμολογίας και αποτελεί το επίκεντρο των εσωτερικών συστημάτων αξιολόγησης. Αυτά τα μοντέλα χρησιμοποιούν οικονομικές και άλλες πληροφορίες, σχετικά με την πιστοληπτική ικανότητα των επιχειρήσεων, για τον προσδιορισμό αντικειμενικών αξιολογήσεων. Τα μοντέλα αξιολόγησης αναμένεται να προωθήσουν, την αποτελεσματικότητα στη διαδικασία αξιολόγησης των τμημάτων του Credit και του Risk, τη σταθερότητα αλλά και την αντικειμενικότητα στην αξιολόγηση πιστωτικού κινδύνου εντός του χρηματοπιστωτικού ιδρύματος μειώνοντας τις αποκλίσεις στην αξιολόγηση που πραγματοποιείται από το προσωπικό αξιολόγησης.



BANK OF JAPAN

#### 1.5.4 Περίγραμμα μοντέλων αξιολόγησης

Υπάρχουν πολλοί τύποι μοντέλων, συμπεριλαμβανομένων και αυτών που χρησιμοποιούν πληροφορίες σχετικά με τις οικονομικές συνθήκες των εταιρειών, δηλαδή μοντέλα στατιστικής αξιολόγησης, και μοντέλα βαθμολογίας. Η χρήση οικονομικών δεδομένων ποικίλλει. Σε ορισμένες περιπτώσεις, τα δεδομένα μπορούν να εισαχθούν απευθείας σε τύπους υπολογισμού από τα στελέχη των χρηματοπιστωτικών ιδρυμάτων. Σε άλλες περιπτώσεις, κάθε στοιχείο οικονομικών δεδομένων αναλύεται και μετατρέπεται σε πιστωτικά αποτελέσματα για ορισμένες κατηγορίες και στη συνέχεια όλα τα δεδομένα εισάγονται σε τύπους υπολογισμού από τα αρμόδια στελέχη των εκάστοτε διευθύνσεων.

Τα χρηματοπιστωτικά ιδρύματα μπορούν να χρησιμοποιούν οποιοδήποτε από αυτά τα μοντέλα. Για να εστιάσουν στην ακρίβεια της μέτρησης, μπορούν να χρησιμοποιήσουν διαφορετικά μοντέλα από διαφορετικές βιομηχανίες, διαφόρων μεγεθών και λειτουργιών, αλλά και κατηγορίες δανείων. Αρχικά, μπορούν να χρησιμοποιούν μόνο ένα μοντέλο για να διατηρήσουν τη συνέπεια. Από την άλλη πλευρά, υπάρχει ανησυχία ότι η ακρίβεια του μοντέλου μειώνεται καθώς ένα μεμονωμένο μοντέλο δεν είναι σε θέση να συλλάβει πλήρως τα χαρακτηριστικά των διαφορετικών βιομηχανιών και μεγεθών των εκάστοτε επιχειρήσεων. Κάθε χρηματοπιστωτικό ίδρυμα θα πρέπει να επιλέξει ένα μοντέλο που να είναι καταλληλότερο για αυτό, λαμβάνοντας υπόψη τα πλεονεκτήματα και τα μειονεκτήματα σε σχέση με το προφίλ κινδύνου του χαρτοφυλακίου δανείων του.

#### 1.6 Εκτίμηση των στοιχείων κινδύνου

Όπως προαναφέρθηκε, ένα από τα σημαντικά σημεία στην επικύρωση ενός μοντέλου αξιολόγησης, είναι να εξεταστεί εάν το μοντέλο αντικατοπτρίζει κατάλληλα τα στοιχεία κινδύνου στις αξιολογήσεις, για παράδειγμα, το Probability of Default για κάθε δανειολήπτη. Λόγω της επικύρωσης των ποσοτήτων πιστωτικού κινδύνου για τυχόν δανεισμό, το Loss Given Default αλλά και η EAD είναι επίσης βασικοί παράγοντες που πρέπει να αξιολογηθούν. Έτσι, αυτοί οι τρεις παράγοντες, που ονομάζονται «συστατικά

κινδύνου», παίζουν καθοριστικό ρόλο στην εκτίμηση των ποσοτήτων πιστωτικού κινδύνου για μεμονωμένα δάνεια. Στην συνέχεια θα βρείτε τις βασικές διαδικασίες για την εκτίμηση και την επικύρωση των τριών στοιχείων κινδύνου.

### 1.6.1 Πιθανότητα αθέτησης (PD)

Το PD ερμηνεύει την πιθανότητα να χρεοκοπήσει ο οφειλέτης εντός συγκεκριμένης περιόδου στο μέλλον. Κατά τον υπολογισμό του PD, ο ορισμός της αθέτησης πρέπει να αποσαφηνιστεί διευκρινίζοντας ποια είναι η συγκεκριμένη κατάσταση ενός δανειολήπτη που πρέπει να ληφθεί υπόψιν. Μια συνήθης πρακτική είναι να οριστεί η υποβάθμιση του δανειολήπτη σε μια συγκεκριμένη θέση βαθμολογίας ή ακόμα και σε κατώτερη.

Η επιλογή βαθμού αξιολόγησης για το προεπιλεγμένο κατώτατο όριο εξαρτάται από την πολιτική των επιχειρήσεων και τη διαχείριση των κινδύνων των χρηματοπιστωτικών ιδρυμάτων. Αρκετοί πελάτες ή και δανειολήπτες για ένα κριτήριο θεωρούνται, για παράδειγμα, αρκετά επίφοβοι με μεγάλη πιθανότητα αθέτησης και μπορούν να αξιολογηθούν και να λάβουν περιγραφή: δάνεια σε δανειολήπτες που «χρεοκόπησαν», είτε και, δανειολήπτες που χρειάζονται «ιδιαίτερη προσοχή».

Το σκεπτικό και για τις δυο αξιολογήσεις είναι ότι η χρεοκοπία είναι μια κατάσταση στην οποία η ανάκτηση ενός δανείου δεν επηρεάζεται πλέον μόνο από την πιστοληπτική ικανότητα των δανειστών, αλλά αντίθετα και από ανεξάρτητους παράγοντες, όπως η εξασφάλιση. Αυτή η προσέγγιση φαίνεται να κυριαρχεί μεταξύ των περισσότερων χρηματοπιστωτικών ιδρυμάτων.

Ένα άλλο παράδειγμα για τον ορισμό είναι ότι η χρεοκοπία είναι μια κατάσταση στην οποία τα χρηματοπιστωτικά ιδρύματα έχουν κίνητρο να αφαιρέσουν τα περιουσιακά στοιχεία του δανείου από τους ισολογισμούς τους ή να λάβουν δραστικά μέτρα για την αναζωογόνηση των δανειοληπτών μετά την επανεκτίμηση των δανείων ώστε να αντικατοπτρίζουν την τιμή της αγοράς. Σε αυτήν την περίπτωση, η αθέτηση των δανειοληπτών εξετάζεται με «ιδιαίτερη προσοχή».

Υπάρχουν διάφορες μέθοδοι για την εκτίμηση του PD. Ένας από αυτούς, είναι ο υπολογισμός των μακροπρόθεσμων μέσων όρων με βάση τα εσωτερικά δεδομένα, έως και τις εξωτερικές αξιολογήσεις και την προσέγγιση μοντέλου για την άμεση εκτίμηση του PD. Οι περισσότερες από τις μεθόδους υπόκεινται σε ανακρίβεια που προκύπτει από την έλλειψη οικονομικών δεδομένων. Επομένως, η συσσώρευση επαρκών στοιχείων σχετικά με την οικονομική κατάσταση είναι κρίσιμη για την εκτίμηση του PD. Όταν τα δείγματα εσωτερικών δεδομένων είναι πολύ μικρά για στατιστικά συμπεράσματα, μπορούν να χρησιμοποιηθούν και άλλα εξωτερικά δεδομένα από κάποια κοινόχρηστη βάση ως συμπληρωματικά. Ωστόσο, η διαφορά στον ορισμό της αθέτησης μεταξύ των εσωτερικών και εξωτερικών δεδομένων θα πρέπει να εξεταστεί προσεκτικά. Εάν υπάρχει μεγάλη απόκλιση αυτού του είδους μεταξύ των βάσεων δεδομένων, θα πρέπει να εφαρμοστεί μια απαραίτητη τροποποίηση προκειμένου να γίνουν οι εκτιμήσεις του PD με συντηρητικά κριτήρια.

### 1.6.2 Απώλεια δεδομένης αθέτησης (LGD)

Το Loss Given Default (LGD) αναφέρεται στο λόγο της αναμενόμενης ζημίας σε σχέση με τα πιστωτικά ανοίγματα κατά τη στιγμή της αθέτησης. Μπορεί να οριστεί από την οπτική γωνία του ποσοστού ανάκτησης με την ένδειξη «1 - ποσοστό ανάκτησης». Εδώ, οι απώλειες πρέπει να μετρηθούν με οικονομικούς όρους. Η εκτίμηση του LGD, επομένως, περιλαμβάνει όλα τα κόστη για τη διαδικασία είσπραξης, συμπεριλαμβανομένων και των πληρωμών σε εξυπηρετήσεις δανείων.

Όπως και στην περίπτωση του PD, τα μακροπρόθεσμα ιστορικά δεδομένα που σχετίζονται με αθετήσεις υποχρεώσεων είναι απαραίτητα. Τέτοια δεδομένα πρέπει να περιλαμβάνουν τις τιμές στο σύνολο του επιχειρηματικού κύκλου, λαμβάνοντας υπόψη το γεγονός ότι οι οικονομικές συνθήκες μπορούν να επηρεάσουν το ποσό μεταβάλλοντας με την σειρά τους την αξία της ασφάλειας και άλλων παραγόντων. Κατά τη δημιουργία μιας βάσης δεδομένων αναφοράς για την εκτίμηση, πρέπει να συγκεντρωθούν και άλλες πληροφορίες που ενδέχεται να επηρεάσουν το LGD. Αυτό περιλαμβάνει την παροχή εξασφάλισης, τον τύπο της εξασφάλισης, και το είδος της εξασφάλισης αλλά και χαρακτηριστικών δανειολήπτη, όπως η βιομηχανία, η γεωγραφία αλλά και η πιστοληπτική ικανότητα.

Είναι πολύ σημαντικό να παρακολουθούνται οι τάσεις και οι μεταβολές των τιμών των ακινήτων και να εξετάζονται πόσο καιρό χρειάζεται για την πώληση της ασφάλειας ακινήτων σε περίπτωση αθέτησης. Στο παρελθόν, τα χρηματοπιστωτικά ιδρύματα αντιμετώπισαν περισσότερες απώλειες από ό, τι αναμενόταν κατά την τελική αξιολόγηση μη εξυπηρετούμενων δανείων. Αυτό μπορεί να αποδοθεί σε αισιόδοξες εκτιμήσεις σχετικά με τις εξελίξεις στην αξία της εξασφάλισης ακινήτων αλλά και στον χρόνο που απαιτείται για την τελική διάθεση των δανείων. Αυτές οι πρόσθετες απώλειες θα πρέπει, οπωσδήποτε, να περιλαμβάνονται στην εκτίμηση του Loss Given Default. Εάν η αξία της εξασφάλισης ακινήτων αντανάκλα έντονα στην πιστοληπτική ικανότητα των δανειστών και ενδέχεται να μειωθεί σε περιόδους αθέτησης, η εκτίμηση της LGD θα πρέπει να λάβει υπόψη και αυτές τις παραδοχές.

### 1.6.3 Έκθεση στην αθέτηση πληρωμής (EAD)

Το EAD είναι το οφειλόμενο ποσό της πίστωσης κατά τη στιγμή της αθέτησης. Στα υπόλοιπα περιουσιακά στοιχεία, όπως δάνεια και ομόλογα, το EAD ισούται με το ποσό του κεφαλαίου ή τη λογιστική του αξία. Ωστόσο, απαιτείται εκτίμηση για τα εκτός ισολογισμού περιουσιακά στοιχεία, όπως γραμμές δέσμευσης, διότι το EAD ισούται με το τρέχον υπόλοιπο συν μια εκτίμηση πρόσθετων αναλήψεων έως τη στιγμή της αθέτησης.

Η συσχέτιση μεταξύ, του ποσού των εκτός ισολογισμού περιουσιακών στοιχείων και της πιστοληπτικής ικανότητας ενός δανειολήπτη, είναι ένας παράγοντας στον υπολογισμό του EAD. Αυτό, οφείλεται στο γεγονός ότι τα ανοίγματα τείνουν να αυξάνονται ταχέως καθώς η χρεοκοπία του οφειλέτη γίνεται πιο πιθανή. Τα χρηματοπιστωτικά ιδρύματα καταβάλουν μεγάλες προσπάθειες για τη δημιουργία μιας επαρκούς βάσης δεδομένων για τις συναλλαγές αυτές, καθώς τα δεδομένα δεν είναι κάπου διαθέσιμα. Έτσι, τα χρηματοπιστωτικά ιδρύματα πραγματοποιούν πιο συντηρητικές εκτιμήσεις.

## 1.6.4 Expected Losses

Οι προσδοκώμενες ζημιές, ή αλλιώς Expected Losses, αφορούν τη μέση ζημιά που αναμένουμε στο χαρτοφυλάκιό μας σε μακροπρόθεσμο ορίζοντα και δίνεται από τον παρακάτω τύπο:

$$EL = EAD \times PD \times LGD$$

Αξίζει να σημειωθεί ότι οι προσδοκώμενες ζημιές δεν αποτελούν κίνδυνο για τα χρηματοπιστωτικά ιδρύματα καθώς τα χρεώνουν μέσω του περιθωρίου κέρδους (spread) και τα απαιτούν από τους πελάτες τους, είτε τα καλύπτουν με προβλέψεις (provisioning). Για τον λόγο αυτό, στον υπολογισμό της Βασιλείας οι προσδοκώμενες ζημιές αφαιρούνται (-PD x LGD)

## 1.7 Η επανεξέταση των στοιχείων κινδύνου

Τα στοιχεία κινδύνου υπολογίζονται με βάση τα ιστορικά δεδομένα, συνεπώς η επικύρωση της επάρκειάς τους πρέπει να γίνεται σε συνεχή βάση. Επίσης, θα πρέπει να επιβεβαιώνεται η συνοχή μεταξύ της κλίμακας βαθμολογίας και του PD που εκτιμάται για κάθε βαθμό.

Το Backtesting είναι μια κοινή προσέγγιση της επικύρωσης του PD, η οποία αντιπροσωπεύει μια σύγκριση μεταξύ του εκτιμώμενου PD και του πραγματικού προεπιλεγμένου ποσοστού για κάθε στάδιο βαθμολογίας. Σε αντίθεση με την περίπτωση του κινδύνου αγοράς, όπου υπάρχουν καθημερινά δεδομένα για δοκιμή, η συχνότητα των ιστορικών δεδομένων σε αυτήν την περίπτωση, είναι συνήθως ετησία με δεδομένα που σχετίζονται με μελλοντικές αθετήσεις. Υπάρχει, ωστόσο, ο προβληματισμός πως η έλλειψη δεδομένων των μακροχρόνιων σειρών μπορεί να αποτελέσει σοβαρό ενδιασμό για την αξιοπιστία της δοκιμής βάσει στατιστικών συμπερασμάτων.

### 1.7.1 Σταθερότητα του PD σε προοπτικές χρονοσειρών

Υπάρχει βαθμολογία που υποθέτει ότι το πραγματικό προεπιλεγμένο ποσοστό για κάθε βαθμό αξιολόγησης είναι σταθερό με την πάροδο του χρόνου, χωρίς να υπόκειται σε αλλαγές με τον επιχειρηματικό κύκλο. Η χρήση της βαθμολογίας, επομένως, θα πρέπει να συνοδεύει την αξιολόγηση της σταθερότητας του PD κατά τον επιχειρηματικό κύκλο. Από την άλλη πλευρά, υπάρχει και η βαθμολογία η οποία υποθέτει ότι το πραγματικό προεπιλεγμένο ποσοστό για κάθε επίπεδο βαθμολογίας κυμαίνεται κάθε χρόνο, αντικατοπτρίζοντας τις επιρροές των μεταβολών με τον επιχειρηματικό κύκλο. Κατά συνέπεια, και σύμφωνα με τον δεύτερο τρόπο αξιολόγησης, το εκτιμώμενο PD πρέπει να περιλαμβάνει κάποιο περιθώριο για την αστάθεια που προκύπτει από τον επιχειρηματικό κύκλο. Από αυτήν την άποψη, είναι σημαντικό να διασφαλιστεί ότι το μέγεθος της διακύμανσης του πραγματικού προεπιλεγμένου ρυθμού βρίσκεται εντός αυτού του περιθωρίου. Εάν το πραγματικό προεπιλεγμένο επιτόκιο παρουσιάζει διακυμάνσεις που υπερβαίνουν το αποδεκτό περιθώριο, τότε η έρευνα θα πρέπει να προσδιορίσει εκ νέου.

## 1.7.2 Χρήσεις εσωτερικών συστημάτων αξιολόγησης

Τα εσωτερικά συστήματα αξιολόγησης παρέχουν στα χρηματοπιστωτικά ιδρύματα τη βάση όχι μόνο για την εξέταση της διαχείρισης πιστωτικού κινδύνου αλλά και για τις αποτελεσματικές δανειοδοτικές πράξεις και στρατηγικές. Δεν υπάρχει λόγος να εισαχθούν τέτοια συστήματα εάν τα χρηματοπιστωτικά ιδρύματα δεν μπορούν να κάνουν πλήρη χρήση των συστημάτων αξιολόγησής τους και για την εσωτερική διαχείριση κινδύνων και επιχειρηματικών δραστηριοτήτων. Ως εκ τούτου, τα εν λόγω ιδρύματα θα πρέπει να αναγνωρίσουν όχι μόνο τη σημασία της εισαγωγής ενός τέτοιου συστήματος αξιολόγησης αλλά και της μεγιστοποίησης της χρήσης του.

Για παράδειγμα, τα τμήματα πιστωτικής αξιολόγησης των δανειοδοτήσεων αναμένεται να χρησιμοποιούν τα συστήματα αυτά ως εργαλείο προσδιορισμού του κινδύνου και της τιμολόγησης. Επιπλέον, χρησιμοποιώντας τις πληροφορίες που προκύπτουν από τις αξιολογήσεις των εσωτερικών αυτών συστημάτων. Οι άλλες αρμόδιες διευθύνσεις μπορούν είτε να παρακολουθούν την ποιότητα των χαρτοφυλακίων των δανείων είτε και να καθορίζουν μια κατευθυντήρια γραμμή τιμολόγησης ανά βαθμό, μέχρι και να ποσοτικοποιούν τον πιστωτικό κίνδυνο και να εκτιμούν το πιστωτικό κόστος.

## 1.8 Χρήσεις PD για κάθε βαθμό βαθμολογίας

Τα ιδρύματα καθορίζουν συνήθως τα επιτόκια αναφοράς για κάθε δάνειο προσθέτοντας το πιστωτικό περιθώριο (επιτόκιο πιστωτικού κόστους και επιτόκιο κόστους κεφαλαίου) στο κόστος χρηματοδότησης, το λόγο δαπανών και το δείκτη απόδοσης στόχου. Μπορούν να εκτιμήσουν τα ποσοστά πιστωτικού κόστους χρησιμοποιώντας το PD για κάθε βαθμό. Ακόμα, χρησιμοποιούν το PD για κάθε βαθμό ώστε να εκτιμήσουν το ποσοστό κόστους κεφαλαίου που πρέπει να ληφθεί υπόψη για την τιμολόγηση. Η ευρεία χρήση της τιμολόγησης του δανείου με βάση τον ακριβή εκτιμώμενο πιστωτικό κίνδυνο είναι ζωτικής σημασίας για την αποτροπή μιας απροσδόκητης αύξησης των μη πραγματοποιηθεισών ζημιών που θα μπορούσαν τελικά να υλοποιηθούν ως μεγάλες απώλειες στο στάδιο της διάθεσης των δανείων.

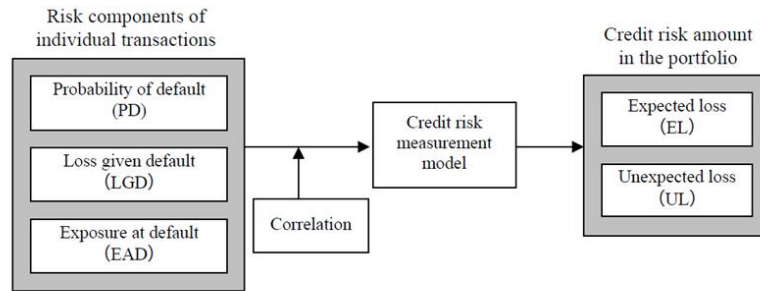
Τα ιδρύματα αξιολογούν την οικονομική αξία των δανείων με τη μέθοδο της προεξοφλημένης ταμειακής ροής (DCF), η οποία υπολογίζει την προεξοφλημένη αξία των μελλοντικών ταμειακών ροών αφού εξετάσει το μελλοντικό πιστωτικό κόστος. Αυτή η διαδικασία απαιτεί την εκτίμηση του πιστωτικού κόστους και επομένως το PD για κάθε βαθμό.

## 1.9 Ποσοτικός προσδιορισμός πιστωτικού κινδύνου

### 1.9.1 Αναμενόμενη απώλεια (EL) και απροσδόκητη απώλεια (UL)


Καθίσταται δυνατή η ποσοτικοποίηση του ποσού του πιστωτικού κινδύνου σε ολόκληρο το χαρτοφυλάκιο δανείων μόλις υπολογίσουμε όλα τα στοιχεία κινδύνου. Το

ποσό του πιστωτικού κινδύνου συνήθως εξηγείται από την αναμενόμενη ζημία (EL) και την απροσδόκητη ζημία (UL).



BANK OF JAPAN

Το EL είναι το μέσο ποσό απώλειας που προβλέπεται για μια συγκεκριμένη χρονική περίοδο, για παράδειγμα, ένα έτος. Το UL ορίζεται ως η μέγιστη απώλεια με συγκεκριμένη πιθανότητα μείον το EL.



ΚΩΝΣΤΑΝΤΙΝΟΣ ΛΟΙΖΟΣ

Η μέγιστη απώλεια (EL + UL) με επίπεδο εμπιστοσύνης 99 τοις εκατό για ένα έτος δανεισμού, υποδηλώνει ότι μια μεγαλύτερη απώλεια από αυτό το ποσοστό θα επηρέαζε τις τράπεζες μόνο μία φορά σε 100 χρόνια. Το EL αναμένεται να καλυφθεί από την παροχή δανείων-ζημιών ως απαραίτητο κόστος για την ανάληψη κινδύνων, ενώ η UL αναμένεται να καλυφθεί από κεφάλαιο ως πιθανή ζημία που σχετίζεται με ανάληψη κινδύνων.

Το μέγεθος του UL εξαρτάται από το χαρτοφυλάκιο πιστώσεων. Για παράδειγμα, το UL θα είναι μεγαλύτερο σε σχέση με το EL, δηλαδή, η δεξιά ουρά θα επεκταθεί περαιτέρω, όταν το βάρος των δανείων προς τους ίδιους τους δανειολήπτες είναι υψηλό ή όταν υπάρχει ισχυρή συσχέτιση μεταξύ του προφίλ των δανειστών. Αντίθετα, η UL τείνει να είναι μικρή εάν τα δάνεια μικρού μεγέθους επεκταθούν σε μεγάλο αριθμό δανειοληπτών ή εάν η προεπιλεγμένη συσχέτιση είναι μικρή.

## 1.9.2 Υπολογισμός κινδύνου

Το EL υπολογίζεται για κάθε δανειολήπτη χρησιμοποιώντας τον ακόλουθο τύπο. Το συνολικό EL του πιστωτικού χαρτοφυλακίου είναι το άθροισμα EL κάθε δανειολήπτη.

$$EL = EAD \times PD \times LGD$$

Ο υπολογισμός του UL απαιτεί όχι μόνο τα τρία στοιχεία κινδύνου (PD, LGD και EAD) που χρησιμοποιούνται για τον υπολογισμό EL, αλλά και την πιθανότητα κατανομής κάθε στοιχείου και της συσχέτισης μεταξύ των δανειστών. Υπό αυτήν την έννοια, ο υπολογισμός του UL είναι πιο δύσκολος από αυτόν για EL από τεχνικής άποψης. Επομένως, σε πολλές περιπτώσεις, χρησιμοποιείται για τον υπολογισμό του UL η μέθοδος προσομοίωσης Monte Carlo.

## 1.10 Δοκιμές stress test

Οι αβεβαιότητες συνεχίζουν να υφίστανται πάντα στον υπολογισμό των κινδύνων και για τον λόγο αυτό χρησιμοποιούνται διάφορα μοντέλα μέτρησης πιστωτικού κινδύνου. Αυτό συμβαίνει, επειδή ο υπολογισμός του κινδύνου είναι μια εκτίμηση που απαιτεί ορισμένες προϋποθέσεις. Απαιτούνται όχι μόνο στρες τεστ αλλά και άλλα μέτρα για την αντιμετώπιση αυτής της αβεβαιότητας. Το στρες τεστ είναι ένας τρόπος αξιολόγησης της επάρκειας της πολιτικής της διαχείρισης χαρτοφυλακίου και της οικονομικής ισχύος έναντι μιας συγκεκριμένης υποτιθέμενης αλλά και πιθανής μελλοντικής κατάστασης αβεβαιότητας, όπως μια ξαφνική αλλαγή στην κατάσταση της αγοράς. Παραδείγματα σεναρίων προσομοιώσεων περιλαμβάνουν τη μείωση ή την αύξηση του ΑΕΠ, την πτώση των τιμών των μετοχών και των ακινήτων, την επιδείνωση της επιχειρηματικής κατάστασης των μεγάλων δανειζόμενων και μεγάλες διακυμάνσεις στα στοιχεία κινδύνου του κλάδου. Τέλος, είναι σημαντικό στο σενάριο που θα δημιουργηθεί να λαμβάνονται υπόψη και αρκετά χαρακτηριστικά πιστωτικών χαρτοφυλακίων, όπως η βιομηχανία και το μέγεθος της λειτουργίας των δανειστών.

Τα αποτελέσματα των στρες τεστ πρέπει να χρησιμοποιούνται ενεργά από τη αρμόδια αρχή ή διεύθυνση, τα τμήματα διαχείρισης κινδύνου και το τμήμα ρίσκου για τη συζήτηση της διαχείρισης χαρτοφυλακίου για το εγγύς μέλλον. Ωστόσο, οι εξουσιοδοτημένες διευθύνσεις υποχρεούνται να προετοιμάσουν ένα στρες τεστ που να καλύπτει όλο το εύρος της έρευνας και να απαντάει στις υποθέσεις και τα σενάρια που τέθηκαν εξ αρχής. Μόνο τα αποτελέσματα τέτοιων δοκιμών θα ληφθούν σοβαρά υπόψη από τη διοίκηση ως σημαντικές πληροφορίες για τον καθορισμό ενός κατάλληλου επιπέδου κεφαλαιακής επάρκειας καθώς και των απαραίτητων μέτρων.



## Κεφάλαιο 2

### 2.1 Εισαγωγή στο Machine Learning

Η μηχανική μάθηση είναι μια μέθοδος που διδάσκει τους υπολογιστές να αναλύουν δεδομένα, να μαθαίνουν από αυτά και στη συνέχεια να κάνουν έναν προσδιορισμό ή πρόβλεψη σχετικά με νέα δεδομένα. Σε γενικές γραμμές, είναι ένα σύστημα που αυτοματοποιεί την κατασκευή αναλυτικών μοντέλων με ελάχιστη ανθρώπινη παρέμβαση.


Αντί να κωδικοποιεί με το χέρι ένα συγκεκριμένο σύνολο οδηγιών για να ολοκληρώσει μια συγκεκριμένη εργασία, το μηχάνημα «εκπαιδεύεται» χρησιμοποιώντας μεγάλες ποσότητες δεδομένων και αλγορίθμων για να μάθει πώς να εκτελεί την εργασία. Η μηχανική μάθηση συμπληρώνει τη στατιστική μάθηση. Και οι δύο προσπαθούν να βρουν και να μάθουν από μοτίβα και τάσεις μέσα σε μεγάλα σύνολα δεδομένων για να κάνουν προβλέψεις. Ο τομέας της μηχανικής μάθησης έχει μια μακρά παράδοση ανάπτυξης, αλλά οι πρόσφατες βελτιώσεις στην αποθήκευση δεδομένων και την υπολογιστική ισχύ τους έχουν καταστήσει πανταχού παρόμοιους σε πολλούς διαφορετικούς τομείς και εφαρμογές, πολλά από τα οποία είναι πολύ συνηθισμένα. Οι συστάσεις της Apple για το Siri, το Facebook και τις ταινίες Netflix βασίζονται σε κάποια μορφή μηχανικής μάθησης. Μία από τις πρώτες χρήσεις της μηχανικής μάθησης ήταν η μοντελοποίηση πιστωτικού κινδύνου, στόχος της οποίας είναι η χρήση οικονομικών δεδομένων για την πρόβλεψη του κινδύνου αθέτησης.

Όταν μια επιχείρηση υποβάλλει αίτηση για δάνειο, ο δανειστής πρέπει να αξιολογήσει εάν η επιχείρηση μπορεί να αποπληρώσει αξιόπιστα το κεφάλαιο και τους τόκους του δανείου. Οι δανειστές χρησιμοποιούν συνήθως μέτρα αποδοτικότητας και μόχλευσης για την εκτίμηση του πιστωτικού κινδύνου. Μια κερδοφόρα εταιρεία παράγει αρκετά ρευστά διαθέσιμα για να καλύψει έξοδα τόκων καθώς και το οφειλόμενο κεφάλαιο. Ωστόσο, μια εταιρεία με περισσότερη μόχλευση διαθέτει λιγότερα ίδια κεφάλαια για να αντιμετωπίσει τις διάφορες μεταβολές. Λαμβάνοντας υπόψη δύο αιτούντες δάνειο - ο ένας με υψηλή κερδοφορία και υψηλή μόχλευση και ο άλλος με χαμηλή κερδοφορία και χαμηλή μόχλευση, ποια εταιρεία έχει χαμηλότερο πιστωτικό κίνδυνο; Η πολυπλοκότητα της απάντησης σε αυτό το ερώτημα πολλαπλασιάζεται όταν οι τράπεζες ενσωματώνουν τις πολλές άλλες διαστάσεις που εξετάζουν κατά την εκτίμηση πιστωτικού κινδύνου. Αυτές οι πρόσθετες διαστάσεις περιλαμβάνουν συνήθως άλλες χρηματοοικονομικές πληροφορίες, όπως δείκτη ρευστότητας ή πληροφορίες συμπεριφοράς, όπως συμπεριφορά πληρωμής δανείου/εμπορικής πίστωσης. Η σύνοψη όλων αυτών των διαφόρων διαστάσεων σε ένα σκορ είναι δύσκολη, αλλά οι τεχνικές μηχανικής μάθησης βοηθούν στην επίτευξη αυτού του στόχου.

Ο κοινός στόχος πίσω από τη μηχανική μάθηση και τα παραδοσιακά εργαλεία στατιστικής μάθησης είναι να μάθουμε από δεδομένα. Και οι δύο προσεγγίσεις στοχεύουν στη διερεύνηση των υποκείμενων σχέσεων χρησιμοποιώντας ένα σύνολο δεδομένων εκπαίδευσης. Συνήθως, οι στατιστικές μέθοδοι μάθησης υποθέτουν τυπικές σχέσεις μεταξύ μεταβλητών με τη μορφή μαθηματικών εξισώσεων, ενώ οι μέθοδοι μηχανικής μάθησης μπορούν να μάθουν από δεδομένα χωρίς να απαιτούνται κανόνες προγραμματισμού. Ως

αποτέλεσμα αυτής της ευελιξίας, οι μέθοδοι μηχανικής μάθησης μπορούν να ταιριάξουν καλύτερα στα πρότυπα των δεδομένων. Το σχήμα 1 απεικονίζει αυτό το σημείο.

Σχήμα 1 Statistical Model Vs. Machine Learning

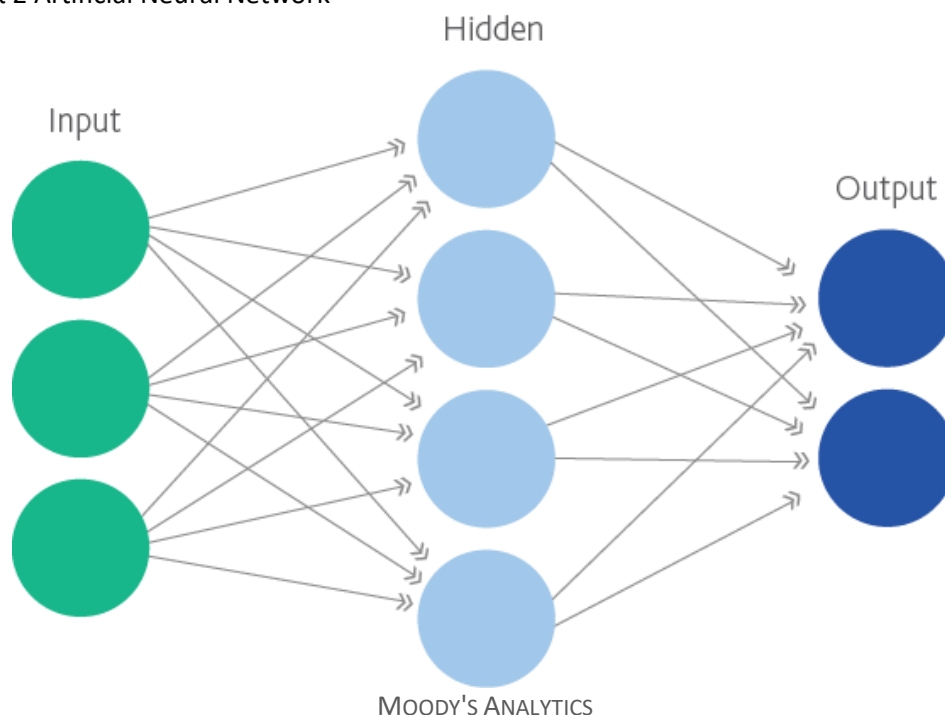


Σε αυτό το προσομοιωμένο παράδειγμα, το πρώτο γράφημα δείχνει την πραγματική κατανομή των σημείων δεδομένων σε σχέση με τα X και Y, ενώ τα σημεία με κόκκινο χρώμα ταξινομούνται ως προεπιλεγμένα. Κάποιος μπορεί να το συσχετίσει με έναν γεωγραφικό χάρτη, όπου ο άξονας X είναι γεωγραφικό μήκος και ο άξονας Y είναι γεωγραφικό πλάτος. Οι περιοχές με κόκκινο χρώμα αντιπροσωπεύουν δημογραφικά στοιχεία υψηλού κινδύνου, όπου βλέπουμε υψηλότερο ποσοστό συγκέντρωσης. Όπως ήταν αναμενόμενο, ένα γραμμικό στατιστικό μοντέλο δεν μπορεί να ταιριάξει σε αυτήν την περίπλοκη μη γραμμική συμπεριφορά. Το «random forest», μια ευρέως χρησιμοποιούμενη μέθοδος μηχανικής εκμάθησης, είναι αρκετά ευέλικτο για να εντοπίσει πολλά καίρια σημεία επειδή δεν περιορίζεται στην πρόβλεψη γραμμικών ή συνεχών σχέσεων. Ένα μοντέλο μηχανικής μάθησης, χωρίς περιορισμούς από κάποιες από τις υποθέσεις των κλασικών στατιστικών μοντέλων, μπορεί να δώσει πολύ καλύτερες γνώσεις που ένας ανθρώπινος αναλυτής δεν θα μπορούσε να συμπεράνει από τα δεδομένα. Μερικές φορές, η πρόβλεψη έρχεται σε έντονη αντίθεση με τα παραδοσιακά μοντέλα.

## 2.2 Τεχνητά Νευρωνικά Δίκτυα

Ένα τεχνητό νευρωνικό δίκτυο (ANN) είναι μια μαθηματική προσομοίωση ενός βιολογικού νευρωνικού δικτύου. Η απλή του μορφή φαίνεται στο σχήμα 2. Σε αυτό το παράδειγμα, υπάρχουν τρεις τιμές εισόδου και δύο τιμές εξόδου. Διαφορετικοί μετασχηματισμοί συνδέουν τις τιμές εισόδου με ένα κρυφό επίπεδο και το κρυφό επίπεδο με τις τιμές εξόδου. Χρησιμοποιείται αλγόριθμος back-propagation για να εκπαιδευθούν τα ANN στα υποκείμενα δεδομένα. Τα ANN μπορούν εύκολα να χειριστούν τις μη γραμμικές και αλληλεπιδραστικές επιδράσεις των επεξηγηματικών μεταβλητών λόγω της παρουσίας πολλών κρυφών στρωμάτων και νευρώνων.

Σχήμα 2 Artificial Neural Network



### 2.2.1 Boosting

Η ενίσχυση του πλήθους των δεδομένων με την μέθοδο Boosting είναι παρόμοια με το τυχαίο δάσος, αλλά τα υποκείμενα δέντρα απόφασης σταθμίζονται με βάση την απόδοσή τους. Εάν ένα δέντρο κατατάσσει εσφαλμένα τους κακοπληρωτές ως μη κακοπληρωτές ή το αντίστροφο, τα επόμενα δέντρα θα δώσουν μεγαλύτερο βάρος στις εσφαλμένα ταξινομημένες παρατηρήσεις. Αυτή η ιδέα της παροχής πρόσθετου βάρους (ή κατεύθυνσης κατά την αποστολή σε μια νέα ομάδα) σε περιοχές που δεν έχουν ταξινομηθεί είναι η διαφορά μεταξύ τυχαίων δασών και ενίσχυσης.

### 2.3 Ταξινόμηση KNN

Η KNN, μια μη παραμετρική μέθοδος μάθησης, διερευνάται για παλινδρόμηση και ταξινόμηση. Η δομή του μοντέλου εξαρτάται από το σύνολο δεδομένων και δεν υπάρχει υπόθεση για διανομές δεδομένων, επομένως, είναι μη παραμετρική. Αυτή η ιδιότητα είναι χρήσιμη επειδή τα σύνολα δεδομένων πραγματικού κόσμου δεν τηρούν πάντα τις θεωρητικές υποθέσεις. Ο αλγόριθμος υπονοεί ότι όλα τα σύνολα δεδομένων εκπαίδευσης χρησιμοποιούνται στη φάση των δοκιμών.

Αυτός ο τρόπος ταξινόμησης είναι απλός και διαισθητικός για κατανόηση. Κατά συνέπεια, χρησιμοποιείται ευρέως για ταξινόμηση λόγω του χαμηλού χρόνου υπολογισμού και της εύκολης ερμηνείας. Η KNN χρησιμοποιείται σε διάφορους τομείς στη βιομηχανία,

όπως στη χρηματοδότηση, στην υγειονομική περίθαλψη. Στη βαθμολόγηση πιστώσεων, τα χρηματοπιστωτικά και τραπεζικά ινστιτούτα αξιολογούν τις πιστωτικές πληροφορίες των πελατών τους και αποφασίζουν εάν οι πελάτες πληρούν τα κριτήρια της πιστωτικής χρηματοδότησης.

Τα πλεονεκτήματα της μεθόδου είναι ότι η φάση εκπαίδευσης του KNN είναι πολύ ταχύτερη από άλλες μεθόδους ταξινόμησης και είναι αρκετά διαισθητική και απλή, καθώς δεν περιέχει υποθέσεις. Το KNN μπορεί να είναι χρήσιμο σε περίπτωση διεξαγωγής προβλήματος πολλαπλών κλάσεων και προβλήματος παλινδρόμησης. Η αδυναμία αυτής της μεθόδου είναι ότι η δοκιμαστική φάση της ταξινόμησης K-πλησιέστερου γείτονα είναι πιο δαπανηρή και πιο αργή, καθώς απαιτεί μεγάλη μνήμη για την αποθήκευση ολόκληρων συνόλων δεδομένων εκπαίδευσης. Επιπλέον, το KNN είναι ευαίσθητο σε μεγέθη και ακραίες τιμές επειδή επιλέγει άμεσα τους γείτονες με βάση την απόσταση (Genesis, 2018). Τα χαρακτηριστικά μεγάλου μεγέθους θα ζυγίζουν περισσότερο από τα χαρακτηριστικά χαμηλού μεγέθους. Δεν είναι επίσης κατάλληλο για δεδομένα μεγάλων διαστάσεων και οι διαστάσεις απαιτούν μείωση για την αναβάθμιση της απόδοσης (Avinash, 2018). Επιπλέον, αυτή η μέθοδος δεν είναι σε θέση να αντιμετωπίσει το πρόβλημα τιμής που λείπει επίσης.

## 2.4 Δέντρο αποφάσεων

Τα Δέντρα Απόφασης είναι διαισθητικά για να απεικονίσουν την απόφαση. Είναι ένας τύπος μη παραμετρικής εποπτευόμενης μεθόδου μάθησης και εργαλείου υποστήριξης αποφάσεων που χρησιμοποιείται για παλινδρόμηση και ταξινόμηση. Με βάση το σύνολο δεδομένων, μπορεί να εντοπίσει και να εξαγάγει μια καμπύλη ημιτόνου με μια σειρά κανόνων εναλλακτικών αποφάσεων. Το μοντέλο είναι πιο κατάλληλο εάν το δέντρο είναι βαθύτερο, καθώς υπάρχουν πιο περίπλοκοι κανόνες απόφασης εναλλακτικών δρόμων.

Έχει δομή διαγράμματος ροής που μιμείται τη δραστηριότητα της ανθρώπινης σκέψης. Αυτός ο αλγόριθμος χρησιμοποιεί την αναπαράσταση δέντρου για να λύσει το πρόβλημα, τους εσωτερικούς κόμβους στο δέντρο για να αναπαραστήσει ένα χαρακτηριστικό και τους κόμβους για να αναπαραστήσει τις ετικέτες κλάσης. Ξεκινάμε από τη ρίζα του δέντρου, χωρίζοντας το δείγμα σε ομάδες ομοιογενών συνόλων σύμφωνα με τους πιο βασικούς διαχωριστές μεταβλητών εισόδου. Επαναλαμβάνουμε αυτή τη διαδικασία μέχρι να βρεθούν κόμβοι σε όλα τα κλαδιά του δέντρου. Ως εκ τούτου, είναι εύκολο και να τα απεικονίσουμε, και να τα κατανοήσουμε αλλά και να τα ερμηνεύσουμε (Rajesh, 2018).

Αυτή η μέθοδος είναι χρήσιμη για την κύρια μεταβλητή και την επιλογή χαρακτηριστικών και έχει τη δυνατότητα να χειρίζεται με μεγάλη ακρίβεια δεδομένα μεγάλου όγκου, απαιτώντας λίγη προετοιμασία των δεδομένων από τους χρήστες. Σε σύγκριση με τις άλλες μεθόδους, αυτή η μέθοδος απαιτεί ελάχιστο καθαρισμό δεδομένων, καθώς δεν επηρεάζεται από τις υπερβολικές τιμές. Επιπλέον, αυτή η μέθοδος μπορεί να αντιμετωπίσει τόσο ποσοτικά όσο και ποιοτικά δεδομένα και αυτή η ιδιότητα είναι ανώτερη από άλλες μεθόδους.

## 2.5 Τυχαίο δάσος

Το τυχαίο δάσος είναι ο πιο δημοφιλής αλγόριθμος. Συγκεκριμένα, συγκεντρώνει μεγάλες ποσότητες κλαδικών αποφάσεων από σύνολο δεδομένων εκπαίδευσης και χρησιμοποιεί επίσης ένα εργαλείο που ονομάζεται bagging για την εκτέλεση εργασιών ταξινόμησης και παλινδρόμησης (Krishni, 2018). Κάθε δέντρο απόφασης αντιπροσωπεύει μια πρόβλεψη κλάσης. Αυτή η μέθοδος συλλέγει τις ψήφους από αυτά τα δέντρα αποφάσεων και η κλάση με τις περισσότερες ψήφους θεωρείται η τελική κλάση (Savan, 2017).

Κατά την εκπαίδευση, κάθε βασικό μοντέλο δημιουργείται ανεξάρτητα με την εκμάθηση από διαφορετικά τυχαία υποδείγματα των δεδομένων. Χρησιμοποιώντας διαφορετικά υποδείγματα για την εκπαίδευση κάθε δέντρου αποφάσεων, ολόκληρο το «δάσος» θα έχει χαμηλή διακύμανση αλλά υψηλή εξειδίκευση παρά το γεγονός ότι κάθε δέντρο έχει υψηλή διακύμανση ως προς ένα συγκεκριμένο σύνολο μεγάλου όγκου δεδομένων κατάρτισης. Κατά τη διάρκεια των δοκιμών, οι προβλέψεις για κάθε δέντρο αποφάσεων υπολογίζονται κατά μέσο όρο για να προκύψουν οι συνολικές προβλέψεις.

Ο βασικός λόγος που αυτή η μέθοδος υπεραποδίδει από το δέντρο αποφάσεων, είναι ότι πολλά ασυσχέτιστα δέντρα αποφάσεων μπορούν να προστατεύσουν το ένα το άλλο από μεμονωμένα σφάλματα για να αντλήσουν τις προβλέψεις του συνόλου, επομένως το πρόβλημα υπερβολικής προσαρμογής μπορεί να μειωθεί και τα αποτελέσματα της πρόβλεψης είναι άριστα ως προς την ακρίβεια μεταξύ των τρεχουσών αλγορίθμων (Tonι, 2016). Έχει επίσης άλλα πλεονεκτήματα όπως, ότι το μοντέλο μπορεί να λειτουργήσει αποτελεσματικά σε μεγάλο αριθμό συνόλων δεδομένων και μπορεί να εκτιμήσει ποιες μεταβλητές είναι σημαντικές και στην ταξινόμηση (Saimadhu, 2017). Το τυχαίο δάσος υπεραποδίδει από τα γραμμικά μοντέλα επειδή μπορεί να πιάσει τη μη γραμμική σχέση μεταξύ της μεταβλητής και των χαρακτηριστικών. Το ελάττωμα της μεθόδου είναι ότι δεν μπορεί να λειτουργήσει με αραιά χαρακτηριστικά επειδή τα δέντρα αποφάσεων αποτελούν δομικά στοιχεία. Πρέπει λοιπόν να επεξεργαστούμε εκ των προτέρων τις εισόδους που ταιριάζουν στο μοντέλο.

## 2.6 Απλό μοντέλο Bayes

Ο τύπος Naive Bayes είναι ένας αξιόπιστος, γρήγορος και ακριβής γραμμικός τύπος και εστιάζει στον υπολογισμό της πιθανότητας υπό όρους.

Η συγκεκριμένη τεχνική ταξινόμησης που αναπτύσσεται με βάση το θεώρημα Bayes είναι κατάλληλη για εισόδους υψηλής διάστασης επειδή το θεώρημα του Bayes υποθέτει ότι οι μεταβλητές είναι ανεξάρτητες. Αυτή η υπόθεση απλοποιεί τον υπολογισμό, οπότε δεν θεωρείται πολύ περιοριστική. Παρά την απλότητά του, λοιπόν, συχνά υπερτερεί των εναλλακτικών υποδειγμάτων, ειδικά για μικρά μεγέθη δειγμάτων. Αυτή η φόρμουλα χρησιμοποιείται σε πολλά πεδία ωστόσο, πρακτικά, η ανεξαρτησία συχνά παραβιάζεται, επομένως οι παραβιάσεις αυτής της υπόθεσης και τα μη γραμμικά προβλήματα μπορούν να οδηγήσουν σε μη ορθά προσδοκόμενα συμπεράσματα (Sebastian, 2014).

Τα βασικά βήματα υπολογισμού είναι τα εξής: να ξεκινήσουμε, να υπολογίσουμε την προηγούμενη πιθανότητα για συγκεκριμένες διαδρομές εντός του κλάδου και να βρούμε την πιθανότητα για κάθε τάξη. Έπειτα, στη συνέχεια βάζουμε αυτές τις τιμές στον τύπο του Bayes και υπολογίζουμε την πιθανότητα, και στο τέλος συγκρίνουμε την τάξη που έχει τη μεγαλύτερη πιθανότητα, δεδομένου ότι η είσοδος ανήκει στην κατηγορία υψηλότερης πιθανότητας. Οι αλγόριθμοι του Naive Bayes είναι σε θέση να εκπαιδεύονται πολύ αποτελεσματικά σε ένα εποπτευόμενο μαθησιακό περιβάλλον. Αυτό το μοντέλο χρησιμοποιεί πάντα τη μέθοδο μέγιστης πιθανότητας για την εκτίμηση της παραμέτρου.

Ένα πλεονέκτημα του αφελούς Bayes είναι ότι απαιτεί μόνο λιγότερα δεδομένα εκπαίδευσης για την εκτίμηση των απαραίτητων παραμέτρων ταξινόμησης. Ωστόσο, η αδυναμία που σχετίζεται με αυτό είναι η υπόθεση των ανεξάρτητων παραμέτρων, επειδή στον πραγματικό κόσμο είναι δύσκολο να εκπληρωθεί αυτή η υπόθεση, καθώς τα σύνολα δεδομένων έχουν συνήθως συναφή χαρακτηριστικά (Rohith, 2018). Σε αυτή την περίπτωση, θα μειώσει σημαντικά την αποτελεσματικότητα της ταξινόμησης. Ένα άλλο μειονέκτημα είναι ότι πρέπει να γνωρίζει την προηγούμενη πιθανότητα που βασίζεται στην παραδοχή και η διαδικασία απαιτεί πολλές υποκειμενικές επιλογές μεταξύ μοντέλων παραδοχής, συμβάλλοντας σε μη αξιόπιστα αποτελέσματα πρόβλεψης (Gaugan, 2018).

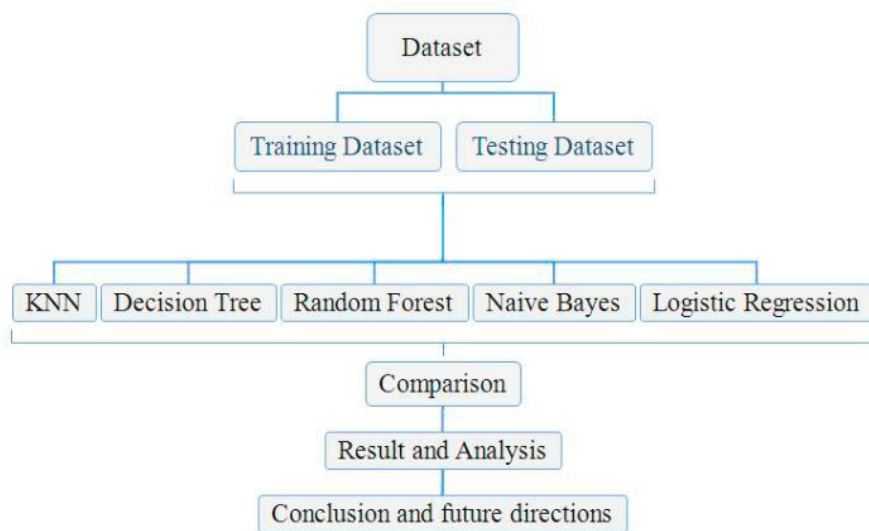
## 2.7 Ανάλυση παλινδρόμησης Logistics

Η Logistic Regression είναι μια ισχυρή παλινδρόμηση και στατιστική μέθοδος για το πρόβλημα ταξινόμησης, η οποία είναι απλή στην εκτέλεση και μπορεί να χρησιμοποιηθεί ως βάση για δυαδικά προβλήματα ταξινόμησης. Επιπλέον, η περιγραφή και η εκτίμηση της σχέσης μεταξύ μιας εξαρτημένης δυαδικής μεταβλητής και ανεξάρτητων μεταβλητών καθιστά αυτό το μοντέλο διδακτικό στο Deep Learning. Αυτές οι παραδοχές είναι πιθανώς οι ίδιες με αυτές που ισχύουν και στη γραμμική παλινδρόμηση.

Από τα αρχικά δεδομένα πρέπει να εκτιμήσουμε τους συντελεστές της εξίσωσης της παλινδρόμησης και συνήθως γίνεται με την εκτίμηση της μέγιστης πιθανότητας, η οποία χρησιμοποιείται συνήθως από τη μηχανική μάθηση (Machine Learning) παρά το γεγονός ότι πρέπει να κάνει υποθέσεις σχετικά με την κατανομή δεδομένων. Οι βελτιστοποιημένοι συντελεστές θα οδηγήσουν σε ένα μοντέλο που θα προβλέπει την τιμή της προεπιλεγμένης κλάσης κοντά στο 1 και η τιμή για τις άλλες κλάσεις θα είναι μηδέν. Ως εκ τούτου, οι αναλυτές επιδιώκουν την τιμή των συντελεστών που θα μπορούσαν να ελαχιστοποιήσουν το σφάλμα στις προβλεπόμενες πιθανότητες. Οι προβλέψεις γίνονται συνδέοντας αριθμούς στην εξίσωση που μόλις δημιουργήθηκε και υπολογίζοντας το αποτέλεσμα.

Αυτό το μοντέλο έχει ένα μεγάλο πλεονέκτημα έναντι άλλων μοντέλων, δεν είναι μόνο ένα μοντέλο ταξινόμησης, αλλά παρέχει επίσης πιθανότητες. Ωστόσο, αυτό το μοντέλο έχει τον περιορισμό του. Η ερμηνεία είναι δύσκολη αφού τα βάρη δεν είναι προσθετικά αλλά πολλαπλασιαστικά. Επιπλέον, αυτό το μοντέλο υποφέρει από πλήρη διαχωρισμό. Εάν ένα χαρακτηριστικό μπορεί να χωρίσει τέλεια τις δύο κατηγορίες, αυτό το μοντέλο δεν μπορεί ποτέ να εκπαιδευτεί επειδή το βάρος για αυτό το χαρακτηριστικό δεν θα συγκλίνει και το βέλτιστο βάρος θα είναι άπειρο. Αυτό είναι αντιφατικό καθώς αυτή η δυνατότητα υπολογισμού μπορεί να είναι πολύ χρήσιμη. Προκειμένου να λυθεί αυτό το

πρόβλημα, μπορούμε να ορίσουμε μια προηγούμενη κατανομή πιθανότητας βαρών (Christoph, 2019).



ELSEVIER YUELIN WANG, YIHAN ZHANG, YAN LU, XINRAN YU

## Κεφάλαιο 3

### 3.1 Εισαγωγή στην Τεχνητή Νοημοσύνη

Τα μαθηματικά θεμέλια για την ανάπτυξη της τεχνητής νοημοσύνης (AI) υπήρχαν από τη δεκαετία του 1950, αλλά η κύρια εφαρμογή της ήταν εφικτή μόνο πρόσφατα χάρη στην πρόοδο της υπολογιστικής ισχύς και στην ικανότητα αποθήκευσης μεγάλων όγκων δεδομένων, γνωστή και ως εποχή των Big Data. Μόνο από τη δεκαετία του 1980 τα εργαλεία μηχανικής μάθησης (ML) έγιναν δημοφιλή ως υποκατηγορία του AI που επικεντρώθηκε στη χρήση στατιστικών τεχνικών που επιτρέπουν στους υπολογιστές να μάθουν και να βελτιωθούν σε έναν τρόπο επεξεργασίας βασισμένο αποκλειστικά στην εμπειρία. Το ML ορίζεται ως μια επεξεργασία αφιερωμένη στη δημιουργία αλγορίθμων για την πραγματοποίηση προβλέψεων με βάση άλλες μεταβλητές ή την ταξινόμηση μεταβλητών με βάση ένα υποσύνολο περιορισμένων δεδομένων εισόδου (Athens and Imbens, 2018). Είναι σαφές πώς η ML δίνει προτεραιότητα στην αναζήτηση της δύναμης της πρόβλεψης. Θα μπορούσε να υποστηριχθεί ότι αυτό έρχεται σε αντίθεση με την έμφαση στη δοκιμαστική μοντελοποίηση και την αναζήτηση αιτιώδους σχέσης που κυριαρχεί στη χρήση πιο παραδοσιακών οικονομετρικών εργαλείων (Breiman 2001).

Πολλά εργαλεία ML χρησιμοποιούνται τόσο για σκοπούς πρόβλεψης όσο και ταξινόμησης και έχουν πολλαπλές εφαρμογές τη χρηματοπιστωτική βιομηχανία. Πρόσφατες έρευνες δείχνουν ότι τα πιστωτικά ιδρύματα υιοθετούν σταδιακά περισσότερες τεχνικές ML σε διάφορους τομείς διαχείρισης πιστωτικού κινδύνου, όπως ρυθμιστικό κεφάλαιο, προβλέψεις, πιστωτική βαθμολόγηση και παρακολούθηση (IIF 2019, Bank of England 2019). Ενώ τα μοντέλα ML υπερτερούν των παραδοσιακών ποσοτικών μοντέλων όσον αφορά τις προγνωστικές ικανότητες (Albanessi, 2019, Petropoulos, 2019) από την πλευρά των εποπτών, θέτουν επίσης νέες προκλήσεις, όπως και υψηλότερη αλγοριθμική πολυπλοκότητα, ως εγγενή συνέπεια της ύπαρξης λύσης για πιο πολύπλοκα προβλήματα (π.χ. μη γραμμικές σχέσεις). Ωστόσο, δεν είναι μόνο η αλγοριθμική πολυπλοκότητα που έχει σημασία για τους επόπτες, όσο και ότι οι περισσότεροι παράγοντες είναι αλληλένδετοι.

Αυτά δεν έχουν πάντα στατιστικό χαρακτήρα και ούτε περιλαμβάνουν ποσοτική μοντελοποίηση, αλλά επηρεάζουν το ρόλο των εποπτικών αρχών στο να διασφαλίζουν τη συγκρισιμότητα, την αξιοπιστία και τη ορθότητα των αποτελεσμάτων. Τα εποπτευόμενα πιστωτικά ιδρύματα πρέπει να εξισορροπήσουν τα πλεονεκτήματα και τα μειονεκτήματα των εργαλείων ML που εφαρμόζονται σε πραγματικά επιχειρηματικά προβλήματα. Αρχικά, η ύπαρξη όλων αυτών των παραγόντων μπορεί να εμποδίζει αυτά τα εργαλεία να διεισδύσουν περαιτέρω στη χρηματοπιστωτική βιομηχανία, όσο αναφορά στον τομέα του πιστωτικού κινδύνου, όπως άλλωστε αναφέρεται και από το Ινστιτούτο Διεθνών Χρηματοοικονομικών (IIF) (2019α).

Οι αρχές αντιμετωπίζουν την πρόκληση να επιτρέψουν στα χρηματοπιστωτικά ιδρύματα και τους πελάτες να μεγιστοποιήσουν τις ευκαιρίες που απορρέουν από την τεχνολογική πρόοδο και την οικονομική καινοτομία, τηρώντας παράλληλα τις αρχές της τεχνολογικής ουδετερότητας, της συμμόρφωσης με τις κανονιστικές ρυθμίσεις και της προστασίας των καταναλωτών. Οι εποπτικοί φορείς μπορούν να χρησιμοποιήσουν, για να



αξιολογήσουν το δίλημμα μεταξύ του κόστους και των οφελών, τα εργαλεία ML στη διαχείριση πιστωτικού κινδύνου. Με τον τρόπο αυτό, διευκολύνουν μια τεκμηριωμένη απόφαση σχετικά με την επάρκεια των μοντέλων, έτσι ώστε να υπάρχει μεγαλύτερη διαφάνεια στη διαδικασία αυτή έναντι των πιστωτικών ιδρυμάτων, με στόχο την άρση των εμποδίων στην καινοτομία. Αυτό το πλαίσιο θα περιλαμβάνει, πρώτον, τον υπολογισμό των οφελών και, δεύτερον, τη δημιουργία μιας συνάρτησης κόστους, η οποία θα υπόκειται όχι μόνο στις ιδιαιτερότητες κάθε τεχνικής ML και στην ανοχή κινδύνου του επόπτη αλλά και στον τρόπο με τον οποίο το ίδρυμα χρησιμοποιεί το μοντέλο.

### 3.2 Τεχνική νοημοσύνη στο Τραπεζικό Σύστημα

Τα τραπεζικά ιδρύματα χρησιμοποιούν την «Τεχνητή Νοημοσύνη» για αρκετά χρόνια, αν και αρχικά περιοριζόταν σε εξειδικευμένες εφαρμογές. Σήμερα, οι τεχνικές τεχνητής νοημοσύνης (Artificial Intelligence) υιοθετούνται γρήγορα για ένα νέο εύρος εφαρμογών στον κλάδο των τραπεζικών υπηρεσιών. Οι τράπεζες επενδύουν περισσότερο στην έρευνα και την ανάπτυξη εφαρμογών AI και η τεχνολογία έχει διαδραματίσει αναπόσπαστο ρόλο σε μια σειρά δραστηριοτήτων, από τη βελτίωση της εμπειρίας των πελατών έως την αποτελεσματικότερη διαχείριση της συμμόρφωσης. Αυτή η εξέλιξη οφείλεται στη βελτιωμένη πρόσβαση σε μεγάλα σύνολα δεδομένων και στην αύξηση της ισχύος επεξεργασίας δεδομένων. Υπήρξε αύξηση του ενδιαφέροντος των εποπτικών αρχών, των ρυθμιστικών αρχών και των υπευθύνων χάραξης πολιτικής τα τελευταία χρόνια, οι οποίοι εξέτασαν τον τρόπο με τον οποίο χρησιμοποιείται το AI, τόσο με οριζόντιο όσο και με κάθετο τρόπο.

Η διπλωματική εργασία στοχεύει στην παροχή περισσότερων πληροφοριών σχετικά με το πλαίσιο και τον τρόπο με τον οποίο η AI αναπτύσσεται και χρησιμοποιείται στον τραπεζικό τομέα. Στόχος είναι να παρέχει κάποια θεμέλια για μια ουσιαστική συζήτηση σχετικά με τη χρήση της τεχνητής νοημοσύνης στον τραπεζικό κλάδο και να οδηγήσει σε μια βαθύτερη κατανόηση της πρακτικής εφαρμογής της και των προκλήσεων που αντιμετωπίζουν οι τράπεζες σήμερα κατά την εφαρμογή λύσεων AI. Αναγνωρίζοντας πρώτα ότι το «AI» είναι στην πραγματικότητα μια πολυσυζητημένη λέξη που καλύπτει πολλές πραγματικότητες, παρουσιάζονται ορισμένα συγκεκριμένα παραδείγματα και περιπτώσεις χρήσης από τον τρόπο με τον οποίο το AI έχει χρησιμοποιηθεί (και θα μπορούσε να χρησιμοποιηθεί) στο μέλλον για να βελτιώσει την εμπειρία των καταναλωτών, τραπεζικές δραστηριότητες και αύξηση της ασφάλειας στον κλάδο μας. Αντλώντας από αυτά τα δύο πρώτα μέρη, στρίβουμε στη συνέχεια στις ευκαιρίες και τις προκλήσεις που προσφέρει η εξέλιξη της τεχνολογίας, ξεκινώντας με κάποια ηθικά ζητήματα. Από γενικές και πιο οριζόντιες εκτιμήσεις (που αφορούν όχι μόνο το ισχύον νομικό πλαίσιο αλλά και την ανταγωνιστικότητα των φορέων της ΕΕ), εστιάζουμε επιτέλους πιο συγκεκριμένα στα ζητήματα που επηρεάζουν τον τραπεζικό τομέα - τόσο όσον αφορά τις ευκαιρίες όσο και τους κινδύνους και τις προκλήσεις.

### 3.2.1 Ορισμός Τεχνητής Νοημοσύνης

Η Τεχνητή Νοημοσύνη ορίζεται συνήθως ως η ικανότητα μιας μηχανής να εκτελεί γνωστικές λειτουργίες που συνδέουμε με τα ανθρώπινα μυαλά, όπως η αντίληψη, η συλλογιστική, η μάθηση, η αλληλεπίδραση με το περιβάλλον, η επίλυση προβλημάτων και ακόμη και η άσκηση δημιουργικότητας. Ωστόσο, η Τεχνητή Νοημοσύνη (AI) είναι στην πραγματικότητα ένας συνδυασμός προηγμένων υπολογιστικών τεχνολογιών σε διάφορους βαθμούς ωριμότητας. Ορισμένες από αυτές τις τεχνολογίες υπάρχουν εδώ και δεκαετίες, ενώ άλλες είναι σχετικά νέες. Με την έλευση των Big Data, οι τεχνολογίες που αναφέρονται συνήθως στο "AI" εξελίσσονται γρήγορα. Είναι ωστόσο μια σταδιακή τεχνολογική εξέλιξη, μερικές φορές βασισμένη σε παλιές τεχνολογίες, η οποία κατέστη δυνατή τώρα με την πρόσβαση σε μεγάλους όγκους δεδομένων και νέες δυνατότητες επεξεργασίας αυτών των όγκων δεδομένων. Η διατύπωση «Τεχνητή Νοημοσύνη» βασίζεται σε όρους που μερικές φορές μπορεί να φαίνονται υπερβολικά χρησιμοποιημένοι καθώς χρησιμοποιείται γενικά για την κάλυψη πολλαπλών τεχνολογιών. Τις περισσότερες φορές, η χρήση αλγορίθμων περιορίζεται στη μίμηση σεναρίων, αναπαραγωγή και αυτοματοποίηση της επεξεργασίας επαναλαμβανόμενων εργασιών που μπορεί να εκτελέσει ένας άνθρωπος. Από το AI είναι γενικά «νοητικές τεχνολογίες που βασίζονται σε μεγάλους όγκους δομημένων ή μη δομημένων δεδομένων (μεγάλα δεδομένα)». Υπό αυτήν την έννοια, η «γνωστική νοημοσύνη» ορίζεται ως οποιαδήποτε μη δομημένη επεξεργασία δεδομένων, μοντελοποίηση που μιμείται ή / και επιτρέπει την αύξηση και την ενίσχυση των γνωστικών ικανοτήτων των ανθρώπων. Για παράδειγμα, ακολουθεί λίστα ορισμένων τομέων τεχνολογικής έρευνας:

Ακολουθούν κάποια παραδείγματα χρήσης αλλά και ανάπτυξης AI

- Επεξεργασία φυσικής γλώσσας: κατανοεί τη γλώσσα αποδίδοντας νόημα και σκοπό. Συχνά συνδέεται με την Αυτόματη Αναγνώριση Ομιλίας και το Κείμενο σε Ομιλία.
- Γνωστικός υπολογισμός: υποστήριξη στην πραγματοποίηση γνωστικών εργασιών και λήψης αποφάσεων. Αυτά είναι διαδραστικά, επαναληπτικά και βασισμένα σε στοιχεία συστήματα.
- Έξυπνη ανάλυση / επεξεργασία: προγνωστική ανάλυση και προσομοιώσεις. Αυτά παρέχουν υποστήριξη για αυτόματες ενέργειες βάσει κανόνα (π.χ. μηχανές προτάσεων).
- Βαθιά μάθηση και εκμάθηση ενίσχυσης: δομή που μεταφέρει το επίκεντρο της μηχανικής μάθησης από την αναγνώριση προτύπων σε μια διαδικασία διαδοχικής και βασισμένης στην εμπειρία λήψης αποφάσεων.

### 3.3 Η μέθοδος AI στο τραπεζικό σύστημα

Οι κύριοι επιχειρηματικοί τομείς εμπορικών τραπεζών είναι οι ακόλουθες τέσσερις πτυχές που καθιστούν τις εμπορικές τράπεζες μοναδικές: 1) υπηρεσίες προϊόντων που

προσφέρουν, 2) οι δραστηριότητες που εμπλέκονται 3) Τους πελάτες που στοχεύουν και 4) τις συνέπειες που επιφέρουν στις σχέσεις με τους πελάτες (Casu, 2016). Εμπορικές τράπεζες, όπως περιγράφεται από τους (Casu, 2016), είναι ιδρύματα που επικεντρώνονται στον δανεισμό, τη λήψη καταθέσεων και τις πληρωμές των συναλλαγών των καταναλωτών, καθιστώντας τους όχι μόνο τους κύριους φορείς του συστήματος πληρωμών αλλά και τους κύριους παρόχους πίστωσης σε επιχειρήσεις και νοικοκυριά.

Όλες αυτές οι περιοχές εστίασης των εμπορικών τραπεζών θα μπορούσαν να επωφεληθούν από τη χρήση του AI. Για να διασφαλιστεί ότι οι τράπεζες μπορούν να δανείσουν κερδοφόρα, πρέπει να αξιολογούν σωστά την πιστοληπτική ικανότητα των πελατών τους. Στο πλαίσιο της επεξεργασίας πληρωμών, είναι σημαντικό οι τράπεζες να διασφαλίσουν ότι η υποδομή πληρωμών, όπως οι αυτοματοποιημένες μηχανές ταμείων (ATM) για τις πληρωμές σε μετρητά και τους υπολογιστές για τη μεταποίηση ψηφιακών πληρωμών, είναι ασφαλή στη χρήση, λειτουργικά και εξυπηρετεί τα κατάλληλα διαστήματα. Αξίζει να σημειωθεί ότι οι πληρωμές άνευ μετρητών αυξήθηκαν τα τελευταία χρόνια, δίνοντας εμπορικές τράπεζες λεπτομερή στοιχεία σχετικά με τη συμπεριφορά αγορών των πελατών τους (Harasim, 2016).

Παρόλο που οι εμπορικές τράπεζες επικεντρώνονται στις δανειοδοτήσεις, τις καταθέσεις και την επεξεργασία πληρωμών, υπάρχουν δύο πρόσθετοι τομείς που οι εμπορικές τράπεζες δεν μπορούν να πάρουν από τις επιχειρηματικές δραστηριότητες. Πρώτον, οι εμπορικές τράπεζες πρέπει να εξασφαλίσουν τη συμμόρφωση με όλους τους σχετικούς νόμους και κανονισμούς. Οι εμπορικές τράπεζες πρέπει να συμμορφώνονται με διάφορα τραπεζικά ρυθμιστικά πλαίσια όπως οι πυλώνες της Βασιλείας (Τράπεζα Διεθνούς Διακανονισμού, 2017) που θέτει περιορισμούς στις δανειοδοτικές δραστηριότητες μιας εμπορικής τράπεζας και στις οδηγίες για τις υπηρεσίες πληρωμών (Ευρωπαϊκή Επιτροπή, 2015) που επηρεάζει όλες τις εταιρείες που παρέχουν πληρωμή λύσεις. Οι νομικές απαιτήσεις έχουν σημαντικό αντίκτυπο στο ποσό του κινδύνου που μπορούν να λάβουν οι εμπορικές τράπεζες καθώς και στις επιχειρησιακές διαδικασίες. Δεύτερον, οι εμπορικές τράπεζες πρέπει επίσης να πουλήσουν τα προϊόντα και τις υπηρεσίες τους στους πελάτες. Αυτό που δημιουργεί στη διοίκηση των πελατών (CRM) των εν λόγω ιδρυμάτων πρόκληση, είναι ότι τα προϊόντα που προσφέρονται από διαφορετικές εμπορικές τράπεζες είναι συχνά αρκετά ομοιογενείς. Αυτό καθιστά την αποτελεσματική στόχευση των πελατών καθοριστικό παράγοντα στην εμπορική τραπεζική. Ένας τρόπος για τις εμπορικές τράπεζες να κάνουν αυτό είναι μέσω της διαχείρισης της σχέσης με τους πελάτες τους.

Για τους πελάτες της τράπεζας, μια μεγάλη αλλαγή που έγινε πιθανώς να είναι η δυνατότητα να διαχειριστούν τους λογαριασμούς μέσω του Διαδικτύου και να πραγματοποιηθούν πληρωμές με βάση το Διαδίκτυο και την κάρτα τους (Harasim, 2016, Krueger και Leibold, 2008). Αυτές οι λειτουργίες είναι ενεργοποιημένες από ένα σύστημα πελάτη-διακομιστή, στο οποίο τα δεδομένα πελατών και οι πληροφορίες λογαριασμού αποθηκεύονται σε κεντρικό διακομιστή και οι πελάτες μπορούν να αποκτήσουν πρόσβαση μέσω του Διαδικτύου (Krueger και Leibold, 2008). Στο δανεισμό, υπάρχουν διάφορες εφαρμογές λογισμικού που διατίθενται στην εμπορική αγορά, είτε η μονάδα εμπορικών τραπεζών της SAP (SAP, 2019A), είτε διάφορα εσωτερικά όπως οι ρυθμιστικές λύσεις (REGTECH) όπου βοηθούν τις τράπεζες για την αντιμετώπιση θεμάτων που σχετίζονται με τη συμμόρφωση (Butler και O'Brien, 2019).

### 3.4 Εφαρμογές AI στο Τραπεζικό Σύστημα

Topic	Application	In practice
Stress testing	Improving stress testing models by using AI and ML	Limit the number of variables used in a scenario analysis
Model validation	Automated validation of models	Less human involvement in model validation processes
Market Risk	Monitoring traders	Surveillance of conduct breaches by traders
Capitalisation	Optimizing regulatory capital	Machine learning tools can increase efficiency and speed of capital optimization
Compliance	Transaction monitoring to detect money laundering	Detecting patterns of suspicious transactions
Credit approval	Automated credit approval	Analyse and interpret patterns that lead to credit approval to improve the credit approval process
Compliance	Fraud detection	Detecting anomalies or patterns in large volumes of transaction data
Market Risk	Portfolio management	Monitoring volatility from a portfolio management perspective

ALETTRE TAMMENGA

#### 3.4.1 Ευκαιρίες για χρήση του AI στις εμπορικές τράπεζες

Τα τελευταία χρόνια, αρκετές σημαντικές τάσεις έχουν θέσει το παραδοσιακό επιχειρηματικό μοντέλο των εμπορικών τραπεζών υπό πίεση. Πρώτον, η αύξηση του ανταγωνισμού έχει δείξει ότι οι τράπεζες δεν έχουν πλέον μονοπώλιο σε αρκετές από τις πιο κερδοφόρες επιχειρηματικές περιοχές τους (HU, 2005, McKinsey, 2016). Δεύτερον, η αλλαγή των προτιμήσεων των καταναλωτών επηρεάζει τόσο την αντίληψη της προσφοράς των τραπεζών και των επιλογών που μπορούν να έχουν οι τράπεζες για τη συντήρηση των πελατών τους (Jakšič και Marginč, 2015, McKinsey, 2016). Τρίτον, το ποσό των συναλλαγών ασκεί πίεση στις τρέχουσες διαδικασίες συμμόρφωσης στις τράπεζες (Butler και O'Brien, 2019, Martens, 2016). Τέταρτον, οι αλλαγές στη συμπεριφορά των ύποπτων συναλλαγών για ξέπλυμα «μαύρου χρήματος» αυξάνουν την ανάγκη για τις τράπεζες να ενισχύσουν τα μέτρα ασφαλείας τους. Πέμπτο, η κλίμακα του υπάρχοντος δικτύου καταστημάτων και η κλίμακα της υποδομής της πληροφορικής ασκεί πίεση στις τράπεζες, επειδή την καθιστά αυστηρότερη και πιο δαπανηρή από τις υπηρεσίες (Zapranis και Alexandridis, 2009). Τα ακόλουθα υποτιμήματα θα αναφερθούν λεπτομερέστερα σχετικά με τις συγκεκριμένες προκλήσεις καθώς και τις λύσεις που βασίζονται στην μέθοδο AI.

### 3.4.2 Αύξηση του ανταγωνισμού

Για ένα μεγάλο χρονικό διάστημα, οι εμπορικές τράπεζες είχαν τα περιφερειακά δυνατά τους σημεία και τις προστατευόμενες αγορές τους. Ωστόσο, αυτό άλλαξε με την ψηφιοποίηση και τη διαθεσιμότητα ηλεκτρονικών υπηρεσιών. Έρευνες καταλήγουν στο συμπέρασμα ότι «η απελευθέρωση στις βιομηχανίες χρηματοπιστωτικών υπηρεσιών και η εκτεταμένη αποδοχή των νέων τεχνολογιών οδηγεί σε αύξηση του ανταγωνισμού στην αγορά χρηματοδότησης». Περαιτέρω, όλο και περισσότεροι μη τραπεζικοί οργανισμοί στοχεύουν ενεργά στα πιο κερδοφόρα τμήματα τραπεζών (McKinsey, 2016). Αυτό σημαίνει ότι οι νέοι ανταγωνιστές προσφέρουν εξειδικευμένες υπηρεσίες που προορίζονταν προηγουμένως μόνο για τις τράπεζες, όπως οι εκτελέσεις των ηλεκτρονικών πληρωμών (PayPal), η επεξεργασία του λογαριασμού μου και των διάφορων αναγκών μου καθώς και αίτηση δανείων (My-Bank).

Πολλοί ανταγωνιστές, χρησιμοποιούν εφαρμογές του AI για να κάνουν τις υπηρεσίες τους πιο αποτελεσματικές, πιο ουσιαστικές και φθηνότερες (Reuters, 2018). Αυτή η αύξηση του ανταγωνισμού σημαίνει ότι οι πελάτες έχουν περισσότερες επιλογές σχετικά με το πού θέλουν να ανοίξουν τραπεζικούς λογαριασμούς, πώς θέλουν να πραγματοποιήσουν πληρωμές και που θα βγάλουν ένα δάνειο (Hornozí και Giles, 2004). Ωστόσο, υπάρχει ένας τρόπος για τις εμπορικές τράπεζες να υπερασπιστούν το μερίδιο τους χρησιμοποιώντας το AI στην οργάνωσή τους. Η BBVA, χρησιμοποίησε το AI ώστε να αποφασίσει για τη βέλτιστη τοποθέτηση των καταστημάτων της στην Ισπανία και να βοηθήσει τους πελάτες να βελτιώσουν τις μεθόδους για τον προϋπολογισμό τους, αλλά και να βελτιώσουν τη στόχευση του πελατολογίου (Alfaro, 2019). Τέλος, το AI μπορεί επίσης να βοηθήσει τις τράπεζες με την αλλαγή αυτή, για παράδειγμα, μειώνοντας το κόστος και την αυτοματοποίηση κυρίως σε manual διαδικασίες (Butler και O'Brien, 2019 Khandani, 2010).

### 3.4.3 Αλλαγή προτιμήσεων πελατών

Εκτός από την άνοδο του ανταγωνισμού, οι προτιμήσεις των τραπεζικών πελατών έχουν αλλάξει επίσης. «Οι πελάτες της Τράπεζας επιθυμούν όλο και περισσότερο να είναι εξουσιοδοτημένοι, συνεχώς συνδεδεμένοι και ευχαριστημένοι» (Jakšič και Marinč, 2015). Λόγω της αύξησης του ανταγωνισμού, οι δεσμοί μεταξύ τραπεζών και πελατών γίνονται προοδευτικά ασθενέστεροι και οι καταναλωτές τις μετατρέπουν όλο και περισσότερο σε εταιρείες με την πιο ελκυστική προσφορά (McKinsey, 2016). Αυτό σημαίνει ότι η αλλαγή των προτιμήσεων των καταναλωτών σε συνδυασμό με τον αυξανόμενο ανταγωνισμό τοποθετεί το επιχειρηματικό μοντέλο των τραπεζών σε αχαρτογράφητα νερά. Ωστόσο, αυτές οι αλλαγές στη συμπεριφορά των καταναλωτών δεν είναι μόνο μια πρόκληση για τις τράπεζες, αλλά θα μπορούσε επίσης να θεωρηθεί και ως ευκαιρία. Για παράδειγμα, η ανάλυση της χρηματοπιστωτικής συμπεριφοράς των πελατών με την ανάλυση των πληρωμών του μπορεί επίσης να βοηθήσει τις εμπορικές τράπεζες στο μάρκετινγκ. Οι προσεγγίσεις AI μπορούν να παρέχουν στις τράπεζες με τα κατάλληλα τεχνολογικά μέσα να εξαγάγουν πληροφορίες σχετικά με τη συμπεριφορά των πελατών τους. Δεδομένης της προθυμίας του πελάτη να δοκιμάσει νέα πράγματα, οι εμπορικές τράπεζες θα μπορούσαν

επίσης να έχουν τη δυνατότητα να διερευνήσουν πώς η εφαρμογή του AI στις βασικές επιχειρηματικές τους περιοχές είναι αποδεκτές. Οι τράπεζες μπορούν να χρησιμοποιήσουν πειραματικές μεθόδους για να διερευνήσουν την αποδοχή της AI.

### 3.5 Η χρήση του ML για τη μέτρηση του πιστωτικού κινδύνου

Σύμφωνα με το IIF (2019a), η πιο κοινή χρήση του ML στη χρηματοπιστωτική βιομηχανία είναι στον τομέα της βαθμολόγησης της πιστοληπτικής ικανότητας των πελατών. Από αυτήν την άποψη, τα πιστωτικά ιδρύματα φαίνεται να έχουν μετατοπίσει την προτιμώμενη χρήση τους από κανονιστικούς σκοπούς, όπως τον υπολογισμό του απαραίτητου διαθέσιμου κεφαλαίου, τις δοκιμές ακραίων καταστάσεων (Stress Test), ακόμη και τις προβλέψεις, σε επιχειρηματικές λύσεις, όπως αποφάσεις για χορήγηση νέας πίστωσης, παρακολούθηση εκκρεμών δανείων και αναχρηματοδότηση μη εξυπηρετούμενων ανοιγμάτων και συστήματα έγκαιρης προειδοποίησης κ.α..

Στην πραγματικότητα, έχει αποδειχθεί ότι το 37% των διεθνών ιδρυμάτων που διαβουλεύθηκαν, έχουν πλήρως λειτουργικά μοντέλα ML αφιερωμένα στην αυτοματοποίηση των διαδικασιών βαθμολόγησης πιστώσεων. Είναι ενδιαφέρον, ότι ένας από τους λόγους που ανέφεραν τα χρηματοπιστωτικά ιδρύματα ώστε να σταματήσουν την εφαρμογή αυτής της τεχνολογίας για το απαραίτητο διαθέσιμο κεφάλαιο είναι ότι «οι κανονιστικές απαιτήσεις δεν ευθυγραμμίζονται πάντα με την άμεση εφαρμογή των μοντέλων ML, λόγω του ότι τα ρυθμιστικά μοντέλα πρέπει να είναι απλά, ενώ τα μοντέλα ML μπορεί να είναι πιο περίπλοκα». Η κλίμακα της πρόκλησης της ευθυγράμμισης αυτών των τεχνικών με τον κανονισμό προληπτικής εποπτείας καθίσταται σαφής με την αναφερόμενη μείωση της χρήσης εργαλείων ML για τον υπολογισμό του ρυθμιστικού κεφαλαίου, η οποία μειώθηκε από 20% το 2018 σε 10% το 2019.

Μια πρόσφατη μελέτη (Ευρωπαϊκή Αρχή Τραπεζών, 2020) αναφέρει ένα παρόμοιο ποσοστό, με σχεδόν 10% των ευρωπαϊκών ιδρυμάτων να χρησιμοποιούν επί του παρόντος μοντέλα ML για κεφαλαιακούς σκοπούς. Αυτή η τελευταία έκθεση, επισημαίνει την ανάγκη να υπάρχουν περισσότερα ιστορικά στοιχεία για τη συμπεριφορά αυτών των μοντέλων σε διαφορετικά οικονομικά περιβάλλοντα, όπως η ύφεση, προκειμένου να ελεγχθεί εάν υπάρχουν ή όχι επαναλαμβανόμενες επιπτώσεις. Πρέπει να διασφαλίζεται ότι, οι πιθανότητες αθέτησης που χρησιμοποιούνται για την εκτίμηση των αξιολογήσεων έχουν μακροχρόνιο ορίζοντα, επιπλέον της εγγύησης της συνέπειας, της διαφάνειας και της συγκρισιμότητας μεταξύ των διαφορετικών εκτιμήσεων των πιστωτικών ιδρυμάτων.

Σε κάθε περίπτωση, παρατηρείται αύξηση του συνολικού αριθμού ιδρυμάτων με μοντέλα ML στην παραγωγή ή σε πιλοτικά έργα, συμπεριλαμβανομένου αυτού του είδους της τεχνολογίας την ατζέντα καινοτομίας και την επιχειρηματική στρατηγική τους (IIF 2019a). Η αύξηση της υιοθεσίας αυτής είναι, επίσης, εμφανής σε ένα ευρύ φάσμα γεωγραφικών περιοχών. Αναφέρεται ότι τα ιδρύματα που χρησιμοποιούν αυτό το είδος μοντέλου για διάφορους σκοπούς συνήθως επιτυγχάνουν πρότυπα υψηλής τεχνολογίας γενικά, ενώ εκείνα που χρησιμοποιούν περιορισμένα μοντέλα έχουν ένα πιο άνισο επίπεδο τεχνολογικής ανάπτυξης σε επίπεδο επιχειρηματικότητας. Αν και το ML χρησιμοποιείται στη μοντελοποίηση διαφορετικών υποκείμενων πιστωτικών ανοιγμάτων, η αλήθεια είναι ότι η πλειοψηφία των ιδρυμάτων αναφέρουν ότι τα χρησιμοποιούν κυρίως για πιστώσεις

λιανικής τραπεζικής. Συνήθως, αυτό μπορεί να συμβεί επειδή είναι ο τομέας του χρηματοπιστωτικού ιδρύματος όπου τα δεδομένα είναι πολλά περισσότερα. Στην πραγματικότητα, η μεγαλύτερη αύξηση σε ετήσια βάση είναι στον τομέα των ΜΜΕ (IIF 2019a).

Αξίζει να τονισθεί ακόμα, ότι η χρήση αυτής της τεχνολογίας στον χρηματοπιστωτικό κλάδο δεν περιορίζεται μόνο στα τραπεζικά ιδρύματα. Άλλοι τύποι ιδρυμάτων, όπως ασφαλιστικές εταιρείες ή διαχειριστές περιουσιακών στοιχείων έχουν αρχίσει να εφαρμόζουν αυτό το είδος μοντέλου, όπως αναφέρεται σε κοινή έρευνα των χρηματοπιστωτικών αρχών του Ηνωμένου Βασιλείου (Bank of England 2019a). Και πάλι εδώ, τα περισσότερα τραπεζικά ιδρύματα που απάντησαν στην έρευνα απάντησαν ότι χρησιμοποιούν ήδη ML, κυρίως για δανεισμό (δηλ. Πιστωτική βαθμολόγηση και τιμολόγηση). Ομοίως, σε ευρωπαϊκό επίπεδο, η χρήση του ML και των μεγάλων δεδομένων κερδίζει έδαφος στον κλάδο της Fintech βάσει μελετών που πραγματοποιήθηκαν από την Ευρωπαϊκή Αρχή Τραπεζών (EBA) (2017c και 2018).


Αυτό που διαφαίνεται, είναι ότι βρισκόμαστε σε μια πρώιμη φάση υιοθέτησης της τεχνολογίας AI και ML στην παροχή χρηματοπιστωτικών υπηρεσιών και ιδιαίτερα στη διαχείριση πιστωτικού κινδύνου. Ωστόσο, προς το παρόν η χρήση απλούστερων μοντέλων είναι κυρίαρχη στην αγορά επειδή τα χρηματοπιστωτικά ιδρύματα δίνουν προτεραιότητα στην ευκολία της ερμηνείας και της επεξηγήσεως των αποτελεσμάτων σε σχέση με τα πιθανά οφέλη από την προγνωστική ισχύ (EBA 2020). Τέλος, οι ρυθμοί ανάπτυξης που παρατηρήθηκαν στον αριθμό των ιδρυμάτων που μελετούν τη σκοπιμότητά τους στην αγορά δείχνουν το σαφές ενδιαφέρον τους για αυτήν την καινοτομία. Ωστόσο, παραμένει το ερώτημα, πώς ορίζουμε την καταλληλότητα των μοντέλων ML για να ικανοποιήσουμε τις ανάγκες των εποπτικών αρχών.

### 3.6 Μέτρηση ωφελειών από τη χρήση μοντέλων ML

Η διαθεσιμότητα των βάσεων δεδομένων υψηλής ποιότητας με μακροχρόνιες σειρές αποτελεί πρόκληση για την έρευνα σχετικά με τη διαχείριση του πιστωτικού κινδύνου, αλλά είναι απαραίτητο κιάλας να καταλήξουμε στο συμπέρασμα σχετικά με το κόστος και τα οφέλη από τη χρήση εργαλείων ML. Έχοντας αυτό υπόψη, θα ανατρέξουμε στην ενημερωμένη ακαδημαϊκή βιβλιογραφία σχετικά με την πρόβλεψη πιστωτικής αθέτησης, συγκρίνοντας την προγνωστική δύναμη των μοντέλων ML με τα παραδοσιακά ποσοτικά μοντέλα. Πιο συγκεκριμένα, μερικά έγγραφα που χρησιμοποιούν ως σημείο αναφοράς την υλικοτεχνική παλινδρόμηση ή το Logit. Αυτό μας βοηθάει να κατανοήσουμε την απόδοση των μοντέλων ML σε όρους προγνωστικής ισχύος καθώς αυξάνεται η αλγοριθμική πολυπλοκότητά τους.

Σε όλα τα έγγραφα, η μεταβλητή -στόχος για πρόβλεψη είναι η πιθανότητα αθέτησης (PD) των δανείων (στεγαστικά δάνεια, ανοίγματα λιανικής, εταιρικά δάνεια ή ένα μείγμα αυτών). Προκειμένου να αξιολογηθούν με ακρίβεια τα αποτελέσματα που ελήφθησαν από διαφορετικά μοντέλα και δείγματα, συγκρίναμε την ισχύ ταξινόμησης χρησιμοποιώντας τη μέτρηση Area Under the Curve-Receiver Operating Characteristic (AUC-ROC), εκτός δείγματος. Οι καμπύλες ROC δείχνουν τη σχέση μεταξύ του πραγματικού θετικού ποσοστού (TPR) και το ψευδώς θετικό ποσοστό (FPR) για όλα τα πιθανά όρια

ταξινόμησης. Η περιοχή που παραμένει κάτω από την καμπύλη ROC μετρά την προγνωστική δύναμη του ταξινομητή, όπως φαίνεται στο παρακάτω διάγραμμα.



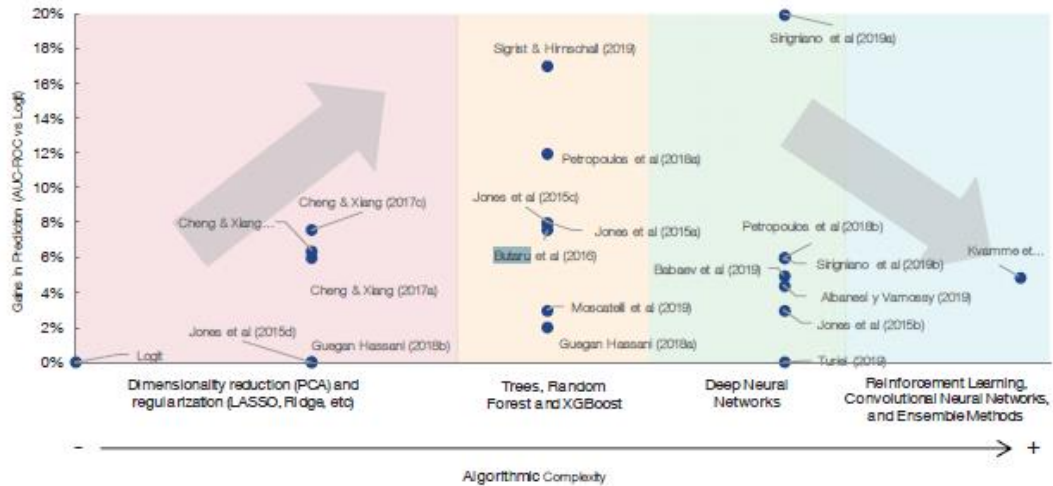
BANK OF ESPANA

$$TPR = \frac{TP}{TP + FN}$$

$$FPR = \frac{FP}{FP + TN}$$

Το επόμενο γράφημα, παρουσιάζει με περιεκτικό τρόπο όλες τις εργασίες που περιλαμβάνονται σε μια βιβλιογραφική ανασκόπηση. Στον οριζόντιο άξονα συγκρίνονται μελέτες και δημοσιεύσεις με βάση την τεχνική ML που χρησιμοποιήθηκε και την a priori αλγοριθμική πολυπλοκότητα. Στον κατακόρυφο άξονα μετριέται το κέρδος στην προβλεπτική ισχύ σε σχέση με τη διακριτική ισχύ που λαμβάνεται χρησιμοποιώντας ένα μοντέλο Logit στο ίδιο δείγμα. Ενώ όπως αναφέρθηκε και πιο πάνω, τα διάφορα μεγέθη του δείγματος και η φύση των υποκείμενων εκθέσεων και σχεδίων μοντέλων διαφέρουν μεταξύ των μελετών, όλες υπογραμμίζουν ότι οι πιο προηγμένες τεχνικές ML (π.χ. τυχαία δάση και βαθιά νευρωνικά δίκτυα) προβλέπουν καλύτερα από τα παραδοσιακά στατιστικά μοντέλα. Τα προγνωστικά κέρδη είναι πολύ ετερογενή, φτάνοντας έως και το 20% και δεν συμπεριφέρονται μονοτονικά καθώς προχωράμε προς πιο αλγοριθμικά πολύπλοκα μοντέλα.





BANK OF ESPANA

### 3.7 Το εποπτικό κόστος της αξιολόγησης των Μοντέλων ML

Όπως αναφέρθηκε και παραπάνω, η χρήση στατιστικών μοντέλων στις χρηματοπιστωτικές υπηρεσίες είναι πολύ διαδεδομένη (Fernández 2019), από τον υπολογισμό στο ρυθμιστικό κεφάλαιο έως τη βαθμολόγηση πιστώσεων, την παρακολούθηση των εκκρεμών δανείων και τον υπολογισμό των βέλτιστων προβλέψεων για τα μη εξυπηρετούμενα ανοίγματα. Επίσης, από την οπτική της προληπτικής εποπτείας, υπάρχουν διαφορετικές γωνίες ή τομείς που εμπλέκονται στη μελέτη προγνωστικών μοντέλων που χρησιμοποιούνται από τα πιστωτικά ιδρύματα, κυρίως αναφερόμενοι στις στατιστικές απαιτήσεις των μοντέλων, την αξιολόγηση του τεχνολογικού προφίλ κινδύνου και τα ζητήματα συμπεριφοράς της αγοράς. Ενώ ο ρυθμιστικός κατακερματισμός από την άποψη αυτή προσθέτει αξία και επιτρέπει την πλήρη κάλυψη των πιθανών κινδύνων που προκύπτουν από τη χρήση προγνωστικών μοντέλων, αποτελεί επίσης εμπόδιο στην απομόνωση των παραγόντων που καθορίζουν εάν ένα νέο ποσοτικό εργαλείο είναι συμβατό με το κανονιστικό και εποπτικό πλαίσιο.

Υπάρχουν βιβλία στη βιβλιογραφία που προσπαθούν να εξηγήσουν ποιοι παράγοντες έχουν σημασία για τους επόπτες κατά την αξιολόγηση μοντέλων ML ή AI. Ωστόσο, δεν έχει ακόμα αντιμετωπιστεί η πρόκληση του τρόπου ταξινόμησης και βαρύτητας καθενός από αυτούς τους παράγοντες, εκτιμώντας τον συνολικό αντίκτυπο για τον επόπτη, ο οποίος αυτή τη στιγμή συναντάει εμπόδια (IIF 2019b, Bank of England 2019, Ευρωπαϊκή Αρχή Τραπεζών 2020). Έχει καθιερωθεί, μια μεθοδολογία που επιτρέπει στους επόπτες να κατανοήσουν πώς να σταθμίσουν κάθε παράγοντα ανάλογα με το μοντέλο που χρησιμοποιείται. Για να γίνει αυτό, αξιοποιείται η επικύρωση των συστημάτων IRB για τον προσδιορισμό και την ταξινόμηση όλων των παραγόντων που ενδέχεται να συνιστούν κόστος για τους επόπτες. Παρόλο που η προσέγγιση IRB περιορίζεται στον υπολογισμό των ελάχιστων απαιτήσεων κεφαλαίου, έχει αντίκτυπο πέρα από αυτή τη χρήση, καθώς οι παράγοντες κινδύνου που υπολογίζονται χρησιμοποιώντας μοντέλα IRB πρέπει να ευθυγραμμιστούν με αυτούς που χρησιμοποιούνται εσωτερικά για οποιονδήποτε άλλο σκοπό. Στην παρακάτω ενότητα γίνεται αναφορά στο σύστημα IRB. Στην συνέχεια, θα αναφερθούμε στο πώς επικυρώνονται αυτά τα συστήματα αξιολόγησης και τη

συμβατότητά τους με τη χρήση του ML, προσδιορίζοντας τους παράγοντες που θα μπορούσαν να αντιπροσωπεύουν ένα κόστος για τον διαχειριστή.

Ο τραπεζικός κανονισμός, όπως αναφέραμε και σε προηγούμενο κεφάλαιο, απαιτεί από τα πιστωτικά ιδρύματα να διατηρούν ένα ελάχιστο υπόλοιπο ιδίων κεφαλαίων για να απορροφούν απρόσμενες ζημιές. Προκειμένου να καθοριστεί αυτό το ποσό, τα ιδρύματα μπορούν να χρησιμοποιήσουν είτε ένα σύνολο τυποποιημένων τύπων είτε στατιστικών μοντέλων για να εκτιμήσουν εσωτερικά το προφίλ κινδύνου (Ευρωπαϊκή Κεντρική Τράπεζα 2019β), επίσης γνωστά ως συστήματα εσωτερικής αξιολόγησης (IRB). Αυτά τα συστήματα πρέπει να πληρούν μια σειρά προληπτικών απαιτήσεων, οι οποίες πρέπει να εγκρίνονται από τον αρμόδιο οικονομικό επόπτη ή διαχειριστή.

Το σύστημα IRB δεν είναι ο μόνος τρόπος με τον οποίο τα ιδρύματα μπορούν να υπολογίσουν τις ρυθμιστικές κεφαλαιακές απαιτήσεις, αλλά είναι πράγματι μία από τις πιο χρησιμοποιούμενες προσεγγίσεις, ιδίως στη βασική του μορφή, όπου γενικά μόνο το PD είναι ένα στοιχείο που πρέπει να εκτιμηθεί από το χρηματοπιστωτικό ίδρυμα (Trucharte 2015). Για να εντάξουμε την ευρεία χρήση της προσέγγισης IRB, μπορούμε να ελέγξουμε την έρευνα που πραγματοποιήθηκε από την EBA (2017β) σχετικά με τις πρακτικές μοντελοποίησης IRB. Από το σύνολο των 102 ανταποκρινόμενων ιδρυμάτων, υπήρχαν 1.493 μοντέλα που αναφέρθηκαν με σκοπό την εκτίμηση της PD στα εσωτερικά τους συστήματα. Παρ' όλα αυτά, πρέπει να σημειωθεί ότι, μεταξύ των ιδρυμάτων που αναφέρθηκαν, ορισμένοι ανέφεραν τη χρήση των ποσοτικών μοντέλων σε ένα πολύ ευρύ φάσμα τομέων, ενώ άλλοι ανέφεραν τη χρήση του μοντέλου μόνο για έναν σκοπό. Ομοίως, ορισμένοι ανέφεραν ότι είχαν μόνο ένα μοντέλο, ενώ άλλοι υπέβαλαν έως και εκατό από αυτά στη μελέτη. Τα πιστωτικά ιδρύματα έχουν χρησιμοποιήσει ιστορικά στατιστικά εργαλεία όπως πολυμεταβλητή ανάλυση ή λογιστικές παλινδρόμηση, όπως το Logit ή το Probit, για να πραγματοποιήσουν τις ποσοτικές εκτιμήσεις στο σύστημα IRB (Bank for International Settlements 2001). Πράγματι, η αξιοσημείωτη επιτυχία αυτών των τεχνικών, όσον αφορά την αποτελεσματικότητα και την προγνωστική απόδοση, έχει τεκμηριωθεί (Banco de España 2016).

Ωστόσο, όπως φαίνεται, οι νέες τεχνικές ML θα μπορούσαν να προσφέρουν οφέλη όσον αφορά τα προγνωστικά κέρδη σε σχέση με το Logit και με το κόστος να είναι πιο σύνθετα. Αυτή η καινοτομία μπορεί να έχει σημαντικό αντίκτυπο στον χρηματοπιστωτικό κλάδο, ακόμη και σε μακροοικονομικό επίπεδο, καθώς η υιοθέτησή της σε επίπεδο αγοράς θα καθορίσει τον υπολογισμό των σταθμισμένων περιουσιακών στοιχείων (RWA) και τη μεταβλητότητά τους.

### 3.8 Χρήση ML στην διαδικασία επικύρωσης συστημάτων IRB

Τα πιστωτικά ιδρύματα είναι υπεύθυνα για την αξιολόγηση της απόδοσης των συστημάτων IRB. Ωστόσο, υπάρχουν σαφείς απαιτήσεις στο πλαίσιο της Βασιλείας όπως ο κανονισμός που έχει μεταφερθεί στο εθνικό δίκαιο, σχετικά με τον τρόπο με τον οποίο πρέπει να υλοποιηθεί αυτή η διαδικασία (Τράπεζα Διεθνών Διακανονισμών 2005). Από αυτή την άποψη, τα καθήκοντα του επόπτη περιλαμβάνουν και τη διασφάλιση της σωστής επικύρωσης των μοντέλων.

Κατά τη χρήση της θεμελιώδους προσέγγισης IRB, κατά γενικό κανόνα τα ιδρύματα θα πρέπει μόνο να εκτιμούν το PD, ενώ τα υπόλοιπα στοιχεία κινδύνου, όπως η ζημία λόγω αθέτησης (LGD), θα προκαθοριστούν από τον κανονισμό. Μόλις ο σχεδιασμός του στατιστικού μοντέλου εγκριθεί και η εκτίμηση είναι ευθυγραμμισμένη με τις απαιτήσεις του επόπτη, το αποτέλεσμα θα εισαχθεί σε ένα οικονομικό μοντέλο για τον υπολογισμό του ρυθμιστικού κεφαλαίου. Αυτό το μέρος της επικύρωσης είναι κυρίως ποσοτικό.

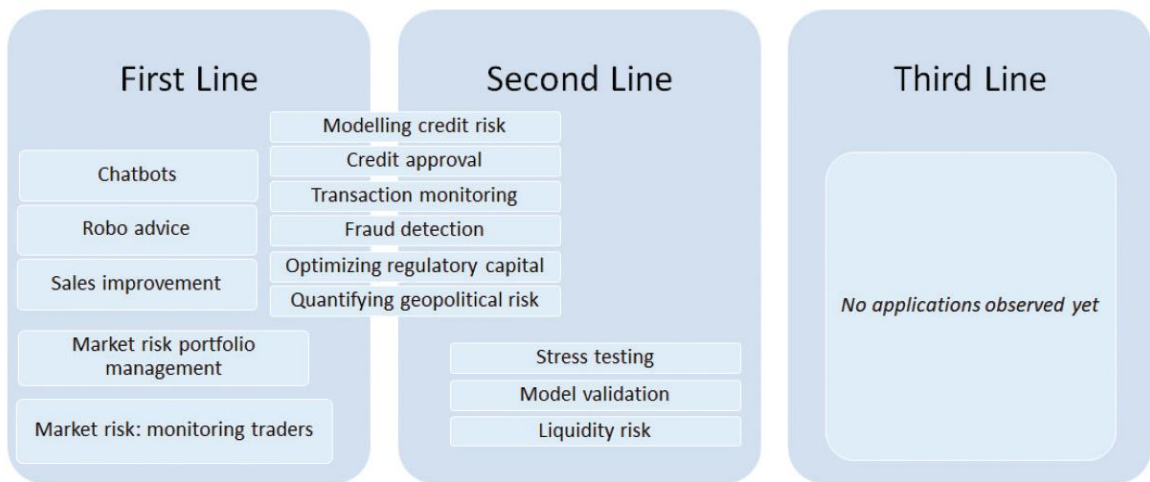
Παράλληλα, τα συστήματα IRB περιλαμβάνουν και ζητήματα όπως το απόρρητο και η ποιότητα των δεδομένων, την εσωτερική αναφορά, τη διακυβέρνηση και τον τρόπο επίλυσης προβλημάτων. Η σημασία αυτών των ζητημάτων θα εξαρτηθεί από τον σκοπό του μοντέλου (π.χ. βαθμολόγηση πιστώσεων ή τιμολόγηση). Αυτό το μέρος της επικύρωσης είναι ως επί το πλείστον ποιοτικό χαρακτηριστικό και εξαρτάται περισσότερο από την εξειδίκευση και τις ικανότητες του επόπτη. Αξίζει να μελετηθεί η συμβατότητα της χρήσης μοντέλων ML με το σχέδιο επικύρωσης IRB. Με αυτόν τον τρόπο, θα μπορούν να προσδιοριστούν τα πιθανά οφέλη και τα κόστη για τον επόπτη που απορρέουν από τη χρήση του ML στον τομέα πιστωτικό κίνδυνο.

## Κεφάλαιο 4

### 4.1 Εφαρμογές AI και ML εντός τραπεζών

Για να υπάρχει καλύτερη εικόνα για τους κινδύνους που συνδέονται με τη χρήση τεχνητής νοημοσύνης και ML, στο κεφάλαιο αυτό εξετάζουμε ορισμένες περιπτώσεις χρήσης τεχνητής νοημοσύνης και ML εντός τραπεζών στην προσπάθεια να καλύψουμε όλες τις λειτουργίες του.

Στο πινακάκι που ακολουθεί θα δείτε πιο αναλυτικά τις λειτουργίες ανά στάδιο.



ALETTE TAMMENGA

### 4.2 Εφαρμογές στην πρώτη γραμμή

Οι τεχνικές AI και ML χρησιμοποιούνται συχνά στην εξυπηρέτηση πελατών. Εφαρμογές όπως chatbots για π.χ. η υποστήριξη πελατών ή οι συμβουλές robo (ψηφιακές πλατφόρμες που παρέχουν αυτοματοποιημένες υπηρεσίες χρηματοοικονομικού σχεδιασμού βασισμένες σε αλγόριθμους με ελάχιστη έως καθόλου ανθρώπινη επίβλεψη) έχουν αυξηθεί τα τελευταία χρόνια. Μια μεγάλη ελεγκτική εταιρεία, έχει αναπτύξει μια πλατφόρμα ανάλυσης φωνής που χρησιμοποιεί βαθιά μάθηση και διάφορους αλγόριθμους ML για την παρακολούθηση και ανάλυση φωνητικών αλληλεπιδράσεων και τον εντοπισμό υψηλού κινδύνου μέσω επεξεργασίας φυσικής γλώσσας. Στη συνέχεια, οι αλληλεπιδράσεις χαρτογραφούνται σε πιθανά αρνητικά αποτελέσματα, όπως καταγγελίες ή ζητήματα συμπεριφοράς και η πλατφόρμα παρέχει στη συνέχεια λεπτομέρειες για το γιατί έχουν συμβεί (Deloitte 2018).

Αυτοματοποιημένες χρηματοοικονομικές συμβουλές που βασίζονται σε τεχνικές AI και ML παρατηρούνται επίσης σε έναν αυξανόμενο αριθμό χρηματοπιστωτικών ιδρυμάτων, αλλά είναι πιο διαδεδομένες για τίτλους παρά για τραπεζικά προϊόντα (González- Páramo 2017). Επίσης, ορισμένες τράπεζες χρησιμοποιούν AI και ML για να βελτιώσουν τον τρόπο πώλησής τους σε πελάτες. Τόσο τα δεδομένα της εξωτερικής αγοράς όσο και τα εσωτερικά δεδομένα για τους πελάτες χρησιμοποιούνται για την ανάπτυξη ρομποτικών

συμβουλευτικών κινδύνων που προσφέρουν προηγμένες γνώσεις σχετικά με τις ανάγκες των πελατών. Οι τεχνικές που διερευνώνται στοχεύουν να βοηθήσουν τις τράπεζες να προβλέψουν τη συμπεριφορά των πελατών, να εντοπίσουν τις ευκαιρίες της αγοράς, να αντλήσουν πληροφορίες από ειδήσεις και ιστότοπους και να προειδοποιήσουν τις πωλήσεις με βάση τους παράγοντες της αγοράς (Sherif 2019).

Στον τομέα του κινδύνου αγοράς, οι περιπτώσεις χρήσης ML από πλευράς διαχείρισης κινδύνου φαίνεται να είναι περιορισμένες και παρατηρούνται κυρίως σε λειτουργίες πρώτης γραμμής. Εδώ, η εστίαση είναι π.χ. αστάθεια της αγοράς ή κίνδυνος αγοράς από πλευράς χαρτοφυλακίου ή διαχείρισης επενδυτικού κινδύνου. Επίσης, το ML εφαρμόζεται όλο και περισσότερο στα χρηματοπιστωτικά ιδρύματα για την παρακολούθηση παραβιάσεων συμπεριφοράς από εμπόρους που εργάζονται για το ίδρυμα. Παραδείγματα τέτοιων παραβιάσεων περιλαμβάνουν αδίστακτες συναλλαγές, παραπλανητικές τιμές αναφοράς και διαπραγμάτευση εμπιστευτικών πληροφοριών - παραβιάσεις συναλλαγών που μπορούν να οδηγήσουν σε σημαντικό οικονομικό κόστος και φήμη για τα χρηματοπιστωτικά ιδρύματα (Van Liebergen 2017). Όσον αφορά τα παραπάνω, αυτές οι εφαρμογές εμφανίζονται καθαρά στην πρώτη γραμμή άμυνας.

#### 4.2.1 Εφαρμογές από την πρώτη και τη δεύτερη γραμμή

Η μοντελοποίηση πιστωτικού κινδύνου αποτελεί συνήθη πρακτική εδώ και αρκετά χρόνια. Στις τράπεζες, τέτοια μοντέλα αναπτύσσονται σε ένα τμήμα μοντελοποίησης που συχνά αποτελεί μέρος μιας λειτουργίας διαχείρισης κινδύνου, με τη συμμετοχή πολλών εξωτερικών χρηστών. Το μοντέλο χρησιμοποιείται από την επιχείρηση στην πρώτη γραμμή.

Η γενική προσέγγιση για την εκτίμηση πιστωτικού κινδύνου, είναι η εφαρμογή μιας τεχνικής ταξινόμησης σε δεδομένα πελατών του παρελθόντος, συμπεριλαμβανομένων και των παραβατικών πελατών, για την ανάλυση και αξιολόγηση της σχέσης μεταξύ των χαρακτηριστικών ενός πελάτη και της πιθανής αποτυχίας τους. Αυτό θα μπορούσε να χρησιμοποιηθεί για τον προσδιορισμό των ταξινομητών που μπορούν να εφαρμοστούν στην κατηγοριοποίηση νέων αιτούντων ή υφιστάμενων πελατών ως καλών ή κακών (Leo et al. 2019). Η ενίσχυση των υπαρχόντων μοντέλων με εφαρμογές ML αυξάνει την ποιότητα των μοντέλων και συνεπώς, οι ακριβείς προβλέψεις. Ο στόχος είναι να εντοπιστούν καλύτερα τα πρώτα σημάδια υποβάθμισης της πίστωσης σε έναν πελάτη ή τα σημάδια για μια ενδεχόμενη αθέτηση βάσει δεδομένων χρονικών σειρών των αθετήσεων. Όταν η ακρίβεια της πρόβλεψης της πιστοληπτικής ικανότητας αυξάνεται, το χαρτοφυλάκιο δανείων θα μπορούσε να αυξηθεί και να γίνει πιο κερδοφόρο. Οι τεχνικές ML μπορούν να χρησιμοποιηθούν αποτελεσματικά και για πρόβλεψη βασισμένη σε παλινδρόμηση. Πρωτίστως, πρότυπα πρόβλεψης για Πιθανότητα αθέτησης (PD), Προβλεπόμενη Απώλεια αθέτησης (LGD).

Ο Συντελεστής Μετατροπής (CCF) μπορεί να δείξει μεγαλύτερα επίπεδα ακρίβειας στην πρόβλεψη του ποσοτικού κινδύνου με μεγαλύτερο βαθμό ακρίβειας (Reddy 2018). Κυρίαρχες μέθοδοι για την ανάπτυξη μοντέλων σχετικά με το PD είναι η ταξινόμηση και η ανάλυση βιωσιμότητας, με την τελευταία να περιλαμβάνει την εκτίμηση για το αν ο πελάτης θα χρεοκοπήσει και τότε θα μπορούσε αυτό να συμβεί. Διαπιστώθηκε ότι οι αλγόριθμοι ταξινόμησης έχουν πολύ μεγαλύτερη ακρίβεια από την τυπική υλικοτεχνική

παλινδρόμηση στην αξιολόγηση της πιστοληπτικής ικανότητας. Επίσης, διαπιστώθηκε ότι προηγμένες μέθοδοι αποδίδουν εξαιρετικά καλά σε σύνολα δεδομένων πιστωτικής βαθμολόγησης όπως τα τεχνητά νευρωνικά δίκτυα (Leo et al. 2019). Για τον πιστωτικό κίνδυνο ενός καταναλωτή, η υπεραπόδοση των τεχνικών ML σε σύγκριση με τις παραδοσιακές τεχνικές αποδείχθηκε με βάση την έρευνα των Khandani et al. (2010) ότι ανέπτυξαν ένα μοντέλο ML για αθέτηση καταναλωτικής πίστης και παραβατικότητα, το οποίο αποδείχθηκε εκπληκτικά ακριβές στην πρόβλεψη πιστωτικών γεγονότων 3-12 μήνες νωρίτερα. Όταν δοκιμάστηκε σε πραγματικά δεδομένα δανεισμού, το μοντέλο οδήγησε σε εξοικονόμηση κόστους σε συνολικές απώλειες έως και 25% (Khandani et al. 2010). Στο δανεισμό MME, οι Figini et al. (2017), δείχνουν ότι μια πολυμεταβλητή τεχνική εξαίρεσης ML βελτίωσε την εκτίμηση πιστωτικού κινδύνου χρησιμοποιώντας δεδομένα που ομαδοποίησε από την UniCredit Bank (Figini et al. 2017). Οι τεχνικές στο ML μπορούν επίσης να ωφελήσουν την απαιτούμενη κατάτμηση των πελατών λιανικής σε ομάδες δανείων που εμφανίζουν ομοιογενή χαρακτηριστικά (Reddy 2018).

Στον τομέα του πιστωτικού κινδύνου, το ML χρησιμοποιείται όχι μόνο για την πρόβλεψη προβλημάτων πληρωμής ή αθέτησης πληρωμών, αλλά και για τη διαδικασία έγκρισης πίστωσης στην πρώτη γραμμή. Το ML θα μπορούσε εκτός από το να βοηθήσει στην ανάλυση και την ερμηνεία ενός μοτίβου που σχετίζεται με εγκρίσεις, θα μπορούσε ακόμα και να αναπτύξει έναν αλγόριθμο για να το προβλέπει με μεγαλύτερη συνέπεια (Reddy 2018).

Στο πεδίο του Λειτουργικού κινδύνου, ένα πεδίο όπου χρησιμοποιείται συχνά ML είναι η παρακολούθηση συναλλαγών ως μέρος της νομιμοποίησης εσόδων από παράνομες δραστηριότητες. Αυτό εκτελείται στην πρώτη γραμμή, με τη λειτουργία συμμόρφωσης της δεύτερης γραμμής να εμπλέκεται. Οι τεχνικές ML είναι σε θέση να ανιχνεύσουν μοτίβα γύρω από ύποπτες συναλλαγές βάσει ιστορικών δεδομένων. Οι αλγόριθμοι ομαδοποίησης προσδιορίζουν τους πελάτες με παρόμοια πρότυπα συμπεριφοράς και μπορούν να βοηθήσουν στην εύρεση ομάδων ατόμων που εργάζονται μαζί για να διαπράξουν ξέπλυμα χρήματος. Επίσης, η ανίχνευση απάτης μπορεί να βελτιωθεί χρησιμοποιώντας τεχνικές ML. Τα μοντέλα υπολογίζονται με βάση δείγματα δόλιων και νόμιμων συναλλαγών με μεθόδους ανίχνευσης υπό επίβλεψη, ενώ σε μη εποπτευόμενες μεθόδους εντοπισμού υπερβολικών ή ασυνήθιστων συναλλαγών προσδιορίζονται ως πιθανές περιπτώσεις απάτης. Και οι δύο επιδιώκουν να προβλέψουν την πιθανότητα απάτης σε μια δεδομένη συναλλαγή (Leo et al. 2019).

Η βελτιστοποίηση του ρυθμιστικού κεφαλαίου της τράπεζας με το ML είναι μια άλλη περίπτωση χρήσης. Τα εργαλεία AI και ML βασίζονται στα θεμέλια των υπολογιστικών δυνατοτήτων, των μεγάλων δεδομένων και των μαθηματικών εννοιών βελτιστοποίησης για να αυξήσουν την αποδοτικότητα, την ακρίβεια και την ταχύτητα της βελτιστοποίησης κεφαλαίου (FSB 2017). Η Deutsche Bank δημιούργησε ένα εργαλείο AI/ML για τον ποσοτικό προσδιορισμό του γεωπολιτικού κινδύνου και την πρόβλεψη της επίδρασής του στις χρηματοπιστωτικές αγορές εξορύσσοντας παγκόσμια οικονομικά νέα δημιουργώντας μια εικόνα του προφίλ πολιτικού κινδύνου μιας χώρας (Kaya 2019).

## 4.2.2 Εφαρμογές στη δεύτερη και τρίτη γραμμή

Ο κίνδυνος ρευστότητας έχει περιορισμένες περιπτώσεις χρήσης (Leo et al. 2019). Ένας από τους μεγαλύτερους διαχειριστές περιουσιακών στοιχείων έκλεισε πρόσφατα ένα πολλά υποσχόμενο μοντέλο κινδύνου ρευστότητας AI επειδή δεν μπόρεσαν να εξηγήσουν την απόδοση των μοντέλων στα ανώτερα διοικητικά στελέχη (Kilburn 2018). Σε μια μελέτη των Tavana et al. (2018), οι συγγραφείς πρότειναν μια μέθοδο αξιολόγησης των παραγόντων κινδύνου ρευστότητας με βάση το ML. Επικεντρώθηκαν στην έννοια της φερεγγυότητας ως ορισμού του κινδύνου ρευστότητας, εστιάζοντας σε θέματα πρόβλεψης κινδύνου ρευστότητας βάσει δανείων. «Παρουσιάστηκε μια μελέτη περίπτωσης που βασίστηκε σε πραγματικά τραπεζικά δεδομένα για να δείξει την αποτελεσματικότητα, την ακρίβεια, την ταχύτητα και την ευελιξία των μεθόδων εξόρυξης δεδομένων κατά τη μοντελοποίηση διφορούμενων περιστατικών που σχετίζονται με τη μέτρηση του κινδύνου ρευστότητας των τραπεζών. Οι εφαρμογές ML ήταν σε θέση να διακρίνουν τους πιο κρίσιμους παράγοντες κινδύνου και να μετρήσουν τον κίνδυνο με λειτουργική προσέγγιση και εκτίμηση κατανομής. Και τα δύο μοντέλα αξιολογήθηκαν μέσω των συγκεκριμένων διαδικασιών κατάρτισης και εκμάθησης και είπαν ότι επιστρέφουν πολύ σταθερά αποτελέσματα». (Tavana et al. 2018).

Η εφαρμογή AI και ML για μοντέλα διαχείρισης κινδύνων αναμένεται να αυξηθεί. Έχουν παρατηρηθεί μερικές περιπτώσεις χρήσης για επικύρωση μοντέλου, όπου οι αλγόριθμοι μάθησης χωρίς επίβλεψη βοηθούν τα μοντέλα των ελεγκτών στη συνεχή παρακολούθηση των εσωτερικών και κανονιστικών μοντέλων σε stress δοκιμές, καθώς μπορούν να βοηθήσουν στον προσδιορισμό αν αυτά τα μοντέλα λειτουργούν με αποδεκτές ανοχές ή αποκλίνουν από τον αρχικό τους σκοπό (FSB 2017). Η επικύρωση του μοντέλου πραγματοποιείται συχνά στην πράξη από μια ξεχωριστή συνάρτηση στη δεύτερη γραμμή.

Παρομοίως, οι τεχνικές AI και ML μπορούν επίσης να εφαρμοστούν στο stress test. Η αυξημένη χρήση των δοκιμών ακραίων σεναρίων μετά την οικονομική κρίση έχει δημιουργήσει προκλήσεις για τις τράπεζες καθώς εργάζονται για την ανάλυση μεγάλου όγκου δεδομένων για ρυθμιστικές δοκιμασίες ακραίων καταστάσεων. Σε μία περίπτωση χρήσης, τα εργαλεία AI και ML χρησιμοποιήθηκαν για τη μοντελοποίηση των επιχειρήσεων κεφαλαιαγοράς για δοκιμές ακραίων σεναρίων τραπεζών, με στόχο τον περιορισμό του αριθμού των μεταβλητών που χρησιμοποιούνται στην ανάλυση σεναρίων για τα μοντέλα «Απώλεια δεδομένης αθέτησης» και «Πιθανότητα αθέτησης». Χρησιμοποιώντας μεθόδους μάθησης χωρίς επίβλεψη για την ανασκόπηση μεγάλου όγκου δεδομένων, τα εργαλεία μπορούν να τεκμηριώσουν οποιαδήποτε ένσταση που σχετίζεται με την επιλογή μεταβλητών, οδηγώντας έτσι σε καλύτερα μοντέλα με μεγαλύτερη διαφάνεια (FSB 2017). Η έρευνα στον τομέα των δοκιμών καταπόνησης και της δέσμευσης κινδύνου φαίνεται περιορισμένη (Leo et al. 2019). Σε σύγκριση με την επικύρωση μοντέλου, η δοκιμή πίεσης πραγματοποιείται συχνά από μια ξεχωριστή συνάρτηση στη δεύτερη γραμμή.

Σύμφωνα με τους Leo et al. (2019), πολλοί από τους άλλους τομείς διαχείρισης μη χρηματοοικονομικού κινδύνου, διαχείρισης κινδύνου χώρας, διαχείρισης κινδύνων συμμόρφωσης-εκτός από χρήσεις που σχετίζονται με το ξέπλυμα χρήματος-και περιπτώσεις κινδύνου συμπεριφοράς δεν έχουν διερευνηθεί επαρκώς. Δεν έχουν παρατηρηθεί ακόμη εφαρμογές AI και ML στην τρίτη γραμμή.

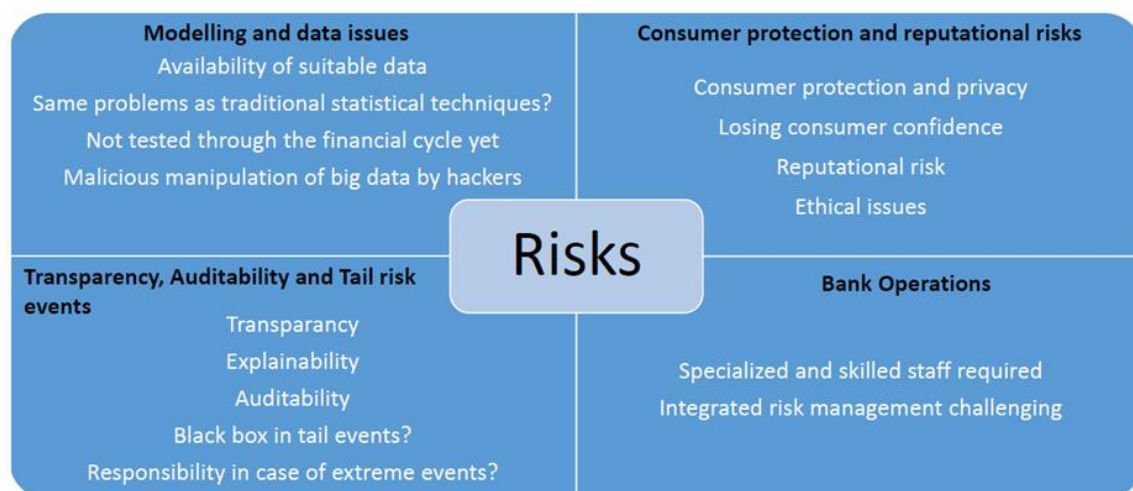
### 4.3 Οφέλη από τη χρήση AI και ML

Προφανώς, υπάρχει μια σειρά από οφέλη που προκύπτουν από τη χρήση AI και ML. Οι τεχνικές μπορούν να βελτιώσουν τη μηχανική επεξεργασία διαφόρων πράξεων σε χρηματοπιστωτικά ιδρύματα, αυξάνοντας έτσι τα έσοδα και μειώνοντας το κόστος (FSB 2017). Ο Kaya (2019) δείχνει ότι η τεχνητή νοημοσύνη είχε σημαντικό θετικό αντίκτυπο στην απόδοση των περιουσιακών στοιχείων των ευρωπαϊκών τραπεζών (ROA), τονίζοντας χαρακτηριστικά ότι: "Τα ISO της τεχνητής νοημοσύνης επηρεάζουν θετικά την απόδοση της επένδυσης σε στατιστικά σημαντικά επίπεδα και εξηγούν το 7% της διακύμανσης της κερδοφορίας των τραπεζών".

Αναμένεται ότι ο χρόνος για την ανάλυση δεδομένων και τη διαχείριση του κινδύνου θα μειωθεί, καθιστώντας τη διαχείριση κινδύνου πιο αποτελεσματική και λιγότερο δαπανηρή. Το AI και το ML μπορούν να χρησιμοποιηθούν για τη διαχείριση κινδύνων μέσω της έγκαιρης και ακριβέστερης εκτίμησης των κινδύνων. Για παράδειγμα, στο βαθμό που η τεχνητή νοημοσύνη και τα έσοδα επιτρέπουν τη λήψη αποφάσεων βάσει προηγούμενων συσχετίσεων μεταξύ των τιμών των διαφόρων περιουσιακών στοιχείων, τα χρηματοπιστωτικά ιδρύματα θα μπορούσαν να διαχειριστούν καλύτερα αυτούς τους κινδύνους. Επίσης, η εκπλήρωση των κανονιστικών απαιτήσεων θα μπορούσε να γίνει πιο αποτελεσματική με την αυτοματοποίηση εργασιών επαναλαμβανόμενων αναφορών και με την αυξημένη ικανότητα οργάνωσης, ανάκτησης και ομαδοποίησης μη συμβατικών δεδομένων, όπως έγγραφα (Aziz and Dowling 2019). Υπάρχουν όμως και κίνδυνοι και προκλήσεις που πρέπει να αντιμετωπιστούν, οι οποίες θα συζητηθούν στην επόμενη ενότητα.

### 4.4 Κίνδυνοι και προκλήσεις κατά τη χρήση AI και ML.

Στον πίνακα που ακολουθεί θα δείτε τους σημαντικότερους κινδύνους που ελλοχεύουν από την χρήση AI και ML.





## 4.5 Θέματα μοντελοποίησης και δεδομένων

Όπως αναφέρουν χαρακτηριστικά οι Aziz and Dowling (2019), η διαθεσιμότητα κατάλληλων δεδομένων είναι πολύ σημαντική. Οι τράπεζες δυσκολεύονται να οργανώσουν τα εσωτερικά δεδομένα που διαθέτουν. Τα δεδομένα είναι συνήθως διάσπαρτα σε διαφορετικά συστήματα και τμήματα σε όλη την τράπεζα. Επίσης, εσωτερικοί ή εξωτερικοί κανονισμοί θα μπορούσαν να αποτρέψουν την ανταλλαγή δεδομένων και η άτυπη γνώση εντός μιας τράπεζας συχνά δεν υπάρχει καθόλου σε σύνολα δεδομένων.

Καθώς η μέθοδος του ML βασίζει μεγάλο μέρος της μοντελοποίησης με βάση την εκμάθηση από τα διαθέσιμα δεδομένα, θα μπορούσε να είναι επιρρεπής στα ίδια προβλήματα που επηρεάζουν και τις παραδοσιακές στατιστικές μεθόδους.

Καθώς οι μέθοδοι μηχανικής εκμάθησης συγκρίνονται με τις παραδοσιακές στατιστικές τεχνικές, θα ήταν επωφελές να αξιολογηθεί και να κατανοηθεί πώς παρουσιάζονται τα προβλήματα που υπάρχουν στις παραδοσιακές στατιστικές μεθόδους έρευνας όταν αντιμετωπίζονται με τεχνικές ML (Leo et al. 2019). Ένα μοντέλο AI ML μπορεί να αποτύχει εάν δεν έχει εκπαιδευτεί σωστά για όλα τα ενδεχόμενα ή σε περίπτωση κακών δεδομένων εκπαίδευσης (Van der Burgt 2019).

Διαπιστώθηκε από τις αρχές επίσης, η έλλειψη πληροφοριών σχετικά με την απόδοση αυτών των μοντέλων σε διάφορους χρηματοοικονομικούς κύκλους. Τα εργαλεία που βασίζονται σε AI και ML ενδέχεται να χάσουν νέους τύπους κινδύνων και γεγονότων επειδή δεν θα μπορούσαν ενδεχομένως να «προπονηθούν» σε προηγούμενα γεγονότα. Η πρόσφατη ανάπτυξη στρατηγικών AI και ML σημαίνει ότι δεν έχουν δοκιμαστεί για την αντιμετώπιση του κινδύνου υπό μεταβαλλόμενες οικονομικές συνθήκες (FSB 2017).

Η DNB (Van der Burgt 2019) επισημαίνει ότι στον χρηματοπιστωτικό τομέα, λόγω πολιτισμικών και νομικών διαφορών, υπάρχουν πολύ συγκεκριμένα περιβάλλοντα δεδομένων, τα οποία συχνά αντιπροσωπεύουν μόνο τις εγχώριες αγορές. "Αυτό μπορεί να αποτελέσει πρόκληση για την ανάπτυξη συστημάτων τεχνητής νοημοσύνης που απαιτούν δεδομένα, ειδικά για σχετικά μικρές αγορές". Σύμφωνα με την DNB (Van der Burgt 2019), τα ιστορικά δεδομένα θα μπορούσαν γρήγορα να γίνουν λιγότερο αντιπροσωπευτικά λόγω των συνεχών αλλαγών στο δημοσιονομικό κανονιστικό πλαίσιο. Αυτό καθιστά τα δεδομένα μη χρήσιμα για εκπαίδευση συστημάτων με δυνατότητα τεχνητής νοημοσύνης.

## 4.6 Προστασία των καταναλωτών και κίνδυνοι φήμης

Στη συνέχεια, υπάρχει το ζήτημα της προστασίας των καταναλωτών. Όλη η επεξεργασία των προσωπικών δεδομένων πρέπει να επιτρέπεται από τον καταναλωτή και να υπόκειται σε πρότυπα απορρήτου και ασφάλειας (González-Páramo 2017). Δύο μέρη του Γενικού Κανονισμού για την Προστασία Δεδομένων (GDPR) σχετίζονται άμεσα με την μέθοδο ML: το δικαίωμα να μην γίνονται διακρίσεις και το δικαίωμα στην εξήγηση. Το άρθρο 22 του GDPR θέτει περιορισμούς στην αυτοματοποιημένη ατομική λήψη αποφάσεων που «επηρεάζει σημαντικά» τους χρήστες. Αυτό περιλαμβάνει επίσης τη δημιουργία προφίλ, δηλαδή αλγόριθμους που λαμβάνουν αποφάσεις βάσει προγνωστικών

επιπέδου χρήστη. Έτσι, εάν το αποτέλεσμα της απόφασης επηρεάζει σημαντικά (ή με νόμιμο τρόπο) τον χρήστη, απαγορεύεται να αποφασίζει με βάση μόνο την αυτοματοποιημένη επεξεργασία, συμπεριλαμβανομένου του προφίλ (εκτός από μερικές εξαιρέσεις που αναφέρονται). Επίσης, οι χρήστες μπορούν να ζητήσουν μια εξήγηση για μια αλγοριθμική απόφαση που τους επηρεάζει σημαντικά (Goodman 2017). Σύμφωνα με τον Kaya (2019), η παρέμβαση ανθρώπινων προγραμματιστών μπορεί να απαιτηθεί προκειμένου να συμμορφωθεί πλήρως με αυτούς τους κανόνες GDPR, κάτι που θεωρείται οπισθοδρόμηση για τα αναμενόμενα κέρδη απόδοσης της τεχνητής νοημοσύνης.

Ένας κίνδυνος που υπάρχει, ακόμα, είναι η απώλεια της εμπιστοσύνης των καταναλωτών και ο κίνδυνος φήμης που προκύπτουν από τις αποφάσεις της τεχνητής νοημοσύνης και της διακυβέρνησης που ενδέχεται να επηρεάσουν αρνητικά τους πελάτες. Οι προσπάθειες για βελτίωση της ερμηνευτικότητας των AI και ML μπορεί να είναι σημαντικές προϋποθέσεις όχι μόνο για τη διαχείριση κινδύνων, αλλά και για μεγαλύτερη εμπιστοσύνη από το ευρύ κοινό, καθώς και από ρυθμιστικές αρχές και εποπτικές αρχές σε κρίσιμες χρηματοπιστωτικές υπηρεσίες (FSB 2017). Το DNB (Van der Burgt 2019) επισημαίνει επίσης τις σοβαρές επιπτώσεις της φήμης που θα μπορούσαν να έχουν τα περιστατικά με AI.

Υπάρχουν, επίσης, ηθικά ζητήματα όταν χρησιμοποιούνται τα AI και ML. Η τεχνητή νοημοσύνη θα μπορούσε να υιοθετήσει κοινωνικές προκαταλήψεις. «Ακόμα κι αν όλα τα δεδομένα είναι αυστηρά προστατευμένα και η τεχνητή νοημοσύνη διατηρείται περιορισμένη στην προβλεπόμενη χρήση της, δεν υπάρχει καμία εγγύηση ότι η προοριζόμενη χρήση είναι αβλαβής για τους καταναλωτές. Οι προγνωστικοί αλγόριθμοι συχνά υποθέτουν ότι υπάρχει μια κρυφή αλήθεια που πρέπει να μάθουμε, η οποία θα μπορούσε να είναι το φύλο του καταναλωτή, το εισόδημα, η τοποθεσία, η πολιτική προτίμηση ή η προθυμία πληρωμής. Ωστόσο, μερικές φορές η μελλοντική «αλήθεια» εξελίσσεται και υπόκειται σε εξωτερική επιρροή.

Υπό αυτή την έννοια, ο αλγόριθμος μπορεί να σκοπεύει είτε να ανακαλύψει την αλήθεια είτε να καταλήξει να ορίζει την αλήθεια. Αυτό θα μπορούσε να είναι επιβλαβές, καθώς οι προγραμματιστές αλγορίθμων μπορούν να χρησιμοποιήσουν τους αλγορίθμους για να εξυπηρετήσουν το δικό τους συμφέρον και τα συμφέροντά τους - ας πούμε κερδίζοντας κέρδη, αναζητώντας πολιτική εξουσία ή οδηγώντας πολιτιστικές αλλαγές - θα μπορούσαν να έρθουν σε σύγκρουση με το συμφέρον των καταναλωτών»(Jin 2018). Στο Deep Learning, είναι πιο δύσκολο να διαφυλαχθεί ότι το μοντέλο δεν λαμβάνει ακούσια αποφάσεις που αντιβαίνουν στις σκληρές κωδικοποιήσεις, μέσω έμμεσων συμπερασμάτων (Aziz and Dowling 2019). Οι καταναλωτές ενδέχεται να αποκλείονται άδικα από την πρόσβαση σε πίστωση λόγω παρωχημένων ή ανακριβών δεδομένων ή λόγω λανθασμένων ή παράνομων αποτελεσμάτων που εξάγονται από αλγόριθμους (González-Páramo 2017). Η τεχνητή νοημοσύνη θα μπορούσε να υιοθετήσει κοινωνικές προκαταλήψεις. Σύμφωνα με τον Kaya (2019), υπάρχει επίσης ο κίνδυνος δυνητικά κακόβουλης χειραγώγησης μεγάλων δεδομένων από χάκερ AI που θα μπορούσε να καταστραφεί από κακόβουλη πρόθεση. Εάν οι χάκερ πλημμυρίσουν συστήματα με πλασματικά δεδομένα (π.χ. ψεύτικους λογαριασμούς στα μέσα κοινωνικής δικτύωσης και ψεύτικες ειδήσεις), ενδέχεται να επηρεάσουν τη λήψη αποφάσεων AI. Αυτό καθιστά απαραίτητη τη συνεχή παρακολούθηση από προγραμματιστές.

## 4.7 Συμβάντα διαφάνειας, εκλεκτικότητας και κινδύνου

Υπάρχει το θέμα της διαφάνειας. Όπως αναφέρθηκε παραπάνω, οι τεχνικές βαθιάς εκμάθησης ενδέχεται να δημιουργούν κίνδυνο από μόνοι τους, καθώς το σύστημα του «μαύρου κουτιού» εμποδίζει την αποτελεσματική εποπτεία του κινδύνου. Αυτές οι τεχνικές είναι συχνά αρκετά αδιαφανείς, οδηγώντας σε δυσκολίες όσον αφορά τη διαφάνεια, την ερμηνεία και τη δυνατότητα ελέγχου της διαχείρισης της τράπεζας καθώς και των ελεγκτών της. Μπορεί επίσης να προκαλέσει ζητήματα συμμόρφωσης με τους κανονισμούς σχετικά με την επίδειξη εγκυρότητας του μοντέλου σε ελεγκτές και ρυθμιστικές αρχές (Aziz and Dowling 2019). Οι πιο περίπλοκοι αλγόριθμοι τεχνητής νοημοσύνης οδηγούν σε αδυναμία των ανθρώπων να απεικονίσουν και να κατανοήσουν τα πρότυπα. Οι αλγόριθμοι τεχνητής νοημοσύνης ενημερώνονται με την πάροδο του χρόνου.

Αυτό θα μπορούσε να γίνει ακόμη πιο δύσκολο όταν ληφθούν υπόψη οι κανονισμοί που στοχεύουν στη δομή εσωτερικού ελέγχου που περιβάλλει τις χρηματοοικονομικές αναφορές (Sarbanes Oxley) και τις απαιτήσεις σχετικά με την αποτελεσματική συγκέντρωση δεδομένων κινδύνου και την αναφορά κινδύνων (BCBS 239). Η Sarbanes Oxley απαιτεί να υπάρχουν αποτελεσματικοί έλεγχοι για την οικονομική αναφορά, έτσι ώστε να γίνεται κάθε βήμα στη διαδικασία αναφοράς ετήσιων καταστάσεων και άλλων γνωστοποιήσεων ελεγχόμενων. Το BSBS239 προχωρά ένα βήμα παραπέρα απαιτώντας σαφή, τεκμηριωμένη και δοκιμασμένη σειρά δεδομένων για όλα τα δεδομένα κινδύνου που συγκεντρώνονται σε μια τράπεζα. Εάν η αιτιολογία ενός αλγορίθμου τεχνητής νοημοσύνης δεν μπορεί να κοινοποιηθεί, η συμμόρφωση με αυτούς τους κανονισμούς μπορεί να γίνει αποτελεσματική. Μια λύση σε αυτό μπορεί να είναι η συμμετοχή ανθρώπινων προγραμματιστών και εποπτών, επίσης αυτό μπορεί να ακυρώσει την αποδοτικότητα (Kaya 2019).

Επίσης, οι τεχνικές του λεγόμενου «μαύρου κουτιού» θα μπορούσαν να δημιουργήσουν επιπλοκές σε γεγονότα επαναλαμβανόμενου κινδύνου. Σύμφωνα με το Συμβούλιο Χρηματοπιστωτικής Σταθερότητας (2017), τα «μαύρα κουτιά» στη λήψη αποφάσεων θα μπορούσαν να δημιουργήσουν περίπλοκα ζητήματα, ειδικά κατά τη διάρκεια εκδηλώσεων ουράς. Ειδικότερα, μπορεί να είναι δύσκολο για τους χρήστες σε χρηματοπιστωτικά ιδρύματα - και για τις ρυθμιστικές αρχές - να κατανοήσουν πώς έχουν διατυπωθεί αποφάσεις, όπως αυτές για συναλλαγές και επενδύσεις. Επιπλέον, ο μηχανισμός επικοινωνίας που χρησιμοποιείται από τέτοια εργαλεία μπορεί να είναι ακατανόητος για τον άνθρωπο, δημιουργώντας έτσι ανάγκη παρακολούθησης για τους ειδικούς που χειρίζονται τέτοιες λύσεις. Σε περίπτωση αμφιβολίας, οι χρήστες τέτοιων εργαλείων AI και ML έχουν την δυνατότητα να απενεργοποιήσουν χειροκίνητα τα συστήματα.

## 4.8 Τραπεζικές εργασίες

Απαιτείται εξειδικευμένο προσωπικό για την εφαρμογή νέων τεχνικών όπως η AI και η ML. Μπορεί να είναι δύσκολο να προσελκυστεί κατάλληλο προσωπικό που διαθέτει αυτές τις ειδικές δεξιότητες. Σε επίπεδο διοικητικού συμβουλίου, πρέπει να υπάρχουν επαρκείς γνώσεις, ώστε να αξιολογεί τους κινδύνους της τεχνητής νοημοσύνης. Το προσωπικό δεύτερης γραμμής θα πρέπει να εκπαιδευτεί ώστε να κατανοεί τις προκλήσεις και τους κινδύνους που σχετίζονται με την τεχνητή νοημοσύνη. Το προσωπικό που εργάζεται με εφαρμογές τεχνητής νοημοσύνης θα πρέπει να έχει επίγνωση των πλεονεκτημάτων και των περιορισμών (Van der Burgt 2019).

Όταν υπάρχει μερική ή πλήρης αυτοματοποίηση της διαδικασίας από τη συλλογή δεδομένων έως τη λήψη αποφάσεων, η ανθρώπινη εποπτεία είναι απαραίτητη. Αυτό γίνεται πιο απαραίτητο καθώς αυξάνεται το επίπεδο αυτοματισμού ή όταν οι τεχνικές ML γίνονται πιο περιγραφικές.

Λαμβάνοντας υπόψη όλους τους κινδύνους που αναφέρθηκαν παραπάνω, φαίνεται προφανές ότι η χρήση της μεθόδου τεχνητής νοημοσύνης προκαλεί επιπλέον προκλήσεις στο πλαίσιο της κοινής φιλοδοξίας και της ολοκληρωμένης διαχείρισης κινδύνων εντός των τραπεζών. Οι περιπτώσεις χρήσης που διασκορπίζονται σε διάφορα μέρη της τράπεζας θα μπορούσαν να εμποδίσουν την ολοκληρωμένη διαχείριση κινδύνων και μια ολοκληρωμένη προσέγγιση αυτών των κινδύνων.

## Κεφάλαιο 5 Μελέτη Περίπτωσης

### 5.1 Εισαγωγή

Στο κεφάλαιο αυτό θα εφαρμόσουμε τις τεχνικές που αναφέρθηκαν στα προηγούμενα κεφάλαια της Διπλωματικής Εργασίας. Πιο συγκεκριμένα, θα χρησιμοποιήσουμε τεχνικές Machine Learning σε data δανειακών πελατών στην Αμερική.

Αρχικά, προτού ξεκινήσουμε θα διαχωρίσουμε (data split) το πλήθος των data σε 80-20. Ο διαχωρισμός αυτός θα γίνει ώστε να μπορέσουμε να εκπαιδεύσουμε τον κώδικα μας στο 80% του πλήθους των στοιχείων μας και στην συνέχεια να μπορούμε να τεστάρουμε τα αποτελέσματά μας στο υπόλοιπο 20%. Στην συνέχεια, θα πραγματοποιήσουμε έναν τυποποιημένο τρόπο καθαρισμού του αρχείου μας ώστε να μην έχουμε ενδείξεις «#N/A» σε κελιά και να μπορεί να τρέξει ο κώδικας. Στο στάδιο αυτό, αντικαθιστούμε μεταβλητές οι οποίες έχουν μηδενικές ή error με true τιμές ώστε να μπορέσουμε να προχωρήσουμε τον κώδικά μας. Σειρά παίρνει η εκπαίδευση του μοντέλου μας όπου θα μας οδηγήσει στην φάση της πρόβλεψης της αποπληρωμής των υφιστάμενων πελατών. Τέλος, θα πραγματοποιηθεί μια σύγκριση του αποτελέσματος ανάμεσα σε random forest, logistic regression καθώς και άλλες μεθόδους. Στις επόμενες ενότητες του κεφαλαίου θα βρείτε περεταίρω ανάλυση των εκάστοτε βημάτων.

### 5.2 Ανάλυση Ερευνητικού Πεδίου

Σαν βασική μας μεταβλητή έχουμε το «Loan Status» των πελατών καθώς αυτή θα επιθυμούσαμε να προβλέψουμε η οποία περιγράφει τα διάφορα στάδια των δανείων των πελατών.. Η μεταβλητή αυτή παίρνει τις παρακάτω 9 τιμές, όπως αυτές φαίνονται στο πινακάκι. Έχοντας ως στόχο να προβλέψουμε έναν καλό πελάτη και έναν κακό πελάτη μελλοντικά, οι τιμές ομαδοποιούνται σε binary δεδομένα κακός(0), καλός (1). Η έρευνα έχει ως στόχο να υποδείξει τις μεταβλητές οι οποίες επηρεάζουν το μοντέλο μας καθώς και το επίπεδο ακρίβειας που καταγράφει.

```
[ ] # explore the unique values in loan_status column
loan_data['loan_status'].value_counts(normalize = True)

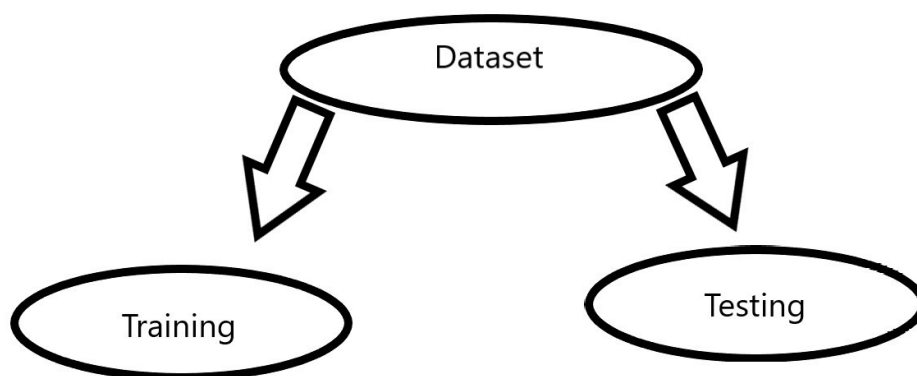
Current                0.480878
Fully Paid             0.396193
Charged Off            0.091092
Late (31-120 days)    0.014798
In Grace Period        0.006747
Does not meet the credit policy. Status:Fully Paid  0.004263
Late (16-30 days)     0.002612
Default                0.001784
Does not meet the credit policy. Status:Charged Off  0.001632
Name: loan_status, dtype: float64
```

Το γεγονός ότι το μοντέλο έχει περίπου 140 μεταβλητές δεν μας επιτρέπει να πάμε και να ξεχωρίσουμε μόνοι μας την μεταβλητή με την οποία θα πάμε να μελετήσουμε και που θα ξεχωρίσουμε από τις υπόλοιπες. Για τον λόγο αυτό, το μοντέλο μας θα πραγματοποιήσει την δική του έρευνα καθώς θα τρέξει όλες τις μεθόδους classification ώστε στην συνέχεια να μας υποδείξει την μέθοδο με την μεγαλύτερη ακρίβεια. Τέλος, θα

εμφανιστούν και τα ποσοστά συμμετοχής των περισσότερων μεταβλητών στο μοντέλο μας ώστε να διακρίνουμε ποιες έχουν τη μεγαλύτερη συμμετοχή στο αποτέλεσμα.

Στο σημείο αυτό, θα ήθελα να σας παρουσιάσω κάποιες από τις 154 μεταβλητές που περιέχονται στο dataset. «Installment, int\_rate, chargeoff\_within\_12\_mths, collection\_recovery\_fee, collections\_12\_mths\_ex\_med, last\_pymnt\_amnt, last\_pymnt\_d, loan\_amnt, loan\_status» είναι μερικές από τις μεταβλητές μας.

### 5.3 Data Split



NISCHAL MADIRAJU - TOWARDS


Στο στάδιο αυτό, ο προγραμματιστής χωρίζει τα δεδομένα του σε δύο ομάδες. Μία από τις πρώτες αποφάσεις που πρέπει να ληφθούν κατά την δημιουργία ενός μοντέλου είναι ο τρόπος χρήσης των υπάρχοντων δεδομένων. Μια κοινή τεχνική είναι να χωρίσουν τα δεδομένα σε δύο ομάδες που συνήθως αναφέρονται ως σύνολα εκπαίδευσης (training) και δοκιμών (testing). Το σετ εκπαίδευσης χρησιμοποιείται για την ανάπτυξη του μοντέλου καθώς και του συνόλου των χαρακτηριστικών. Ακόμα, αποτελούν τη βάση για την εκτίμηση παραμέτρων, τη σύγκριση μοντέλων και όλες τις άλλες δραστηριότητες που απαιτούνται για την επίτευξη ενός τελικού μοντέλου. Το σύνολο δοκιμών χρησιμοποιείται μόνο στο τέλος του μοντέλου για την εκτίμηση μιας τελικής, αμερόληπτης αξιολόγησης της απόδοσης του μοντέλου. Είναι κρίσιμο να μην χρησιμοποιηθεί το σετ δοκιμών πριν από αυτό το σημείο. Η εξέταση των αποτελεσμάτων των data στο testing set θα προκαλούσε μεροληψία στα αποτελέσματα αφού τα δεδομένα των test θα έχουν γίνει μέρος της διαδικασίας ανάπτυξης του μοντέλου.

Είναι εξαιρετικά δύσκολο να γίνει μια ενιαία κατευθυντήρια γραμμή σχετικά με το ποσοστό που θα έπρεπε να διαχωριστεί καθώς και τα χαρακτηριστικά τους. Το ποσοστό των δεδομένων μπορεί να δημιουργήσει αμεροληψία από πολλούς παράγοντες, συμπεριλαμβανομένου του μεγέθους της αρχικής δεξαμενής δειγμάτων και του συνολικού αριθμού προγνωστικών. Με μια μεγάλη συλλογή δειγμάτων, η κρισιμότητα αυτής της απόφασης μειώνεται μόλις περιληφθούν «αρκετά» δείγματα στο σετ εκπαίδευσης. Ο λόγος του αριθμού των δειγμάτων ( $n$ ) προς τον αριθμό των προγνωστικών ( $p$ ) είναι επίσης

σημαντικό να ληφθεί υπόψη. Θα έχουμε πολύ μεγαλύτερη ευελιξία στο διαχωρισμό των δεδομένων όταν το  $n$  είναι πολύ μεγαλύτερο από το  $p$ . Ωστόσο, όταν το  $n$  είναι μικρότερο από το  $p$ , τότε μπορούμε να αντιμετωπίσουμε δυσκολίες μοντελοποίησης ακόμη και αν το  $n$  είναι φαινομενικά μεγάλο.

Στην μελέτη περίπτωσης που πραγματοποιούμε, θα κρατήσουμε το 80% των δεδομένων μας έπειτα και από τον «καθαρισμό» που θα πραγματοποιήσουμε στο dataset. Απομονώνουμε τις 20 καλύτερες μεταβλητές με κριτήρια όπως (την στατιστική σημαντικότητα, το  $p$ -value, καθώς και τις συσχετίσεις τους).

## 5.4 Training



Ένα μοντέλο εκπαίδευσης είναι ένα σύνολο δεδομένων που χρησιμοποιείται για την εκπαίδευση ενός αλγορίθμου ML. Αποτελείται από τα δείγματα δεδομένων εξόδου και τα αντίστοιχα σύνολα δεδομένων εισόδου που επηρεάζουν την έξοδο. Το μοντέλο εκπαίδευσης χρησιμοποιείται για την εκτέλεση των δεδομένων εισόδου μέσω του αλγορίθμου για συσχέτιση της επεξεργασμένης εξόδου με την έξοδο δείγματος. Το αποτέλεσμα αυτής της συσχέτισης χρησιμοποιείται για την τροποποίηση του μοντέλου.

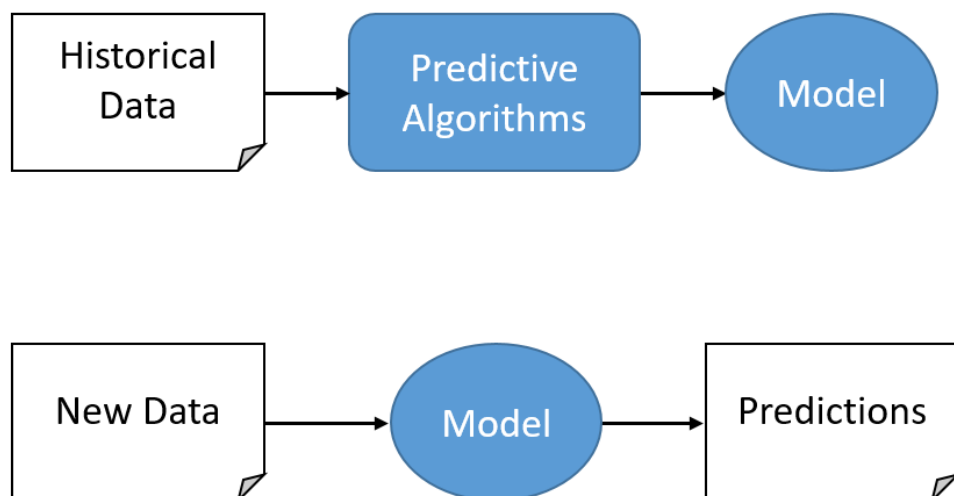
Αυτή η επαναληπτική διαδικασία βοηθάει το μοντέλο να γίνει κατάλληλο. Η ακρίβεια του συνόλου δεδομένων εκπαίδευσης ή του συνόλου δεδομένων επικύρωσης είναι κρίσιμης σημασίας για την ακρίβεια του μοντέλου.

Το μοντέλο εκπαίδευσης στο Machine Learning είναι η διαδικασία τροφοδοσίας ενός αλγορίθμου ML με δεδομένα που βοηθούν στον εντοπισμό και την εκμάθηση καλών τιμών για όλα τα χαρακτηριστικά που εμπλέκονται. Υπάρχουν διάφοροι τύποι μοντέλων μηχανικής μάθησης, εκ των οποίων τα πιο συνηθισμένα είναι η εποπτευόμενη και η χωρίς επίβλεψη μάθηση.

Η εποπτευόμενη μάθηση είναι δυνατή όταν τα δεδομένα εκπαίδευσης περιέχουν τόσο τις τιμές εισόδου όσο και εξόδου. Κάθε σύνολο δεδομένων που έχει τις εισόδους και την αναμενόμενη έξοδο ονομάζεται εποπτικό σήμα. Η εκπαίδευση γίνεται με βάση την απόκλιση του επεξεργασμένου αποτελέσματος από το τεκμηριωμένο αποτέλεσμα όταν οι εισροές τροφοδοτούνται στο μοντέλο.

Η χωρίς επίβλεψη μάθηση περιλαμβάνει τον καθορισμό προτύπων στα δεδομένα. Στη συνέχεια, χρησιμοποιούνται πρόσθετα δεδομένα για την προσαρμογή μοτίβων ή συμπλεγμάτων. Αυτή είναι επίσης μια επαναληπτική διαδικασία που βελτιώνει την ακρίβεια με βάση τη συσχέτιση με τα αναμενόμενα μοτίβα ή ομάδες. Δεν υπάρχει σύνολο δεδομένων εξόδου αναφοράς σε αυτήν τη μέθοδο.

## 5.5 Prediction



LOGI ANALYTICS

Η προγνωστική μοντελοποίηση (predictive modelling) χρησιμοποιεί στατιστικά στοιχεία με σκοπό την πρόβλεψη αποτελεσμάτων. Η προγνωστική μοντελοποίηση είναι μια μορφή τεχνολογίας εξόρυξης δεδομένων, η οποία αναλύοντας ιστορικά και τρέχοντα δεδομένα δημιουργεί ένα μοντέλο που βοηθά στην πρόβλεψη μελλοντικών αποτελεσμάτων. Στην προγνωστική μοντελοποίηση, συλλέγονται δεδομένα, διαμορφώνεται ένα στατιστικό μοντέλο, γίνονται προβλέψεις και το μοντέλο επικυρώνεται (ή αναθεωρείται) καθώς διατίθενται επιπλέον δεδομένα. Η μέθοδος της προγνωστικής μοντελοποίησης χρησιμοποιείται συνήθως για την πρόβλεψη μελλοντικών συμπεριφορών, όμως εφαρμόζεται επίσης σε οποιονδήποτε τύπο άγνωστου συμβάντος, ανεξάρτητα από το πότε συνέβη.

## 5.6 Μετρήσεις αξιολόγησης για μη ισορροπημένα δεδομένα δοκιμών

Εάν έχουμε ισχυρή ανισορροπία στα δεδομένα δοκιμής, έχουμε ακόμα τρόπους να κατανοήσουμε πόσο καλά αποδίδει το μοντέλο μας εκτός της μέτρησης της ακρίβειας. Η ακρίβεια, είναι στην πραγματικότητα μόνο ένα μέτρο του λάθους ή του σωστού για κάθε παρατήρηση. Δεν λαμβάνει υπόψη πόσες από κάθε κατηγορία περιλαμβάνονται στα δεδομένα, ενώ λειτουργεί καλύτερα με σχετικά ισορροπημένα δεδομένα (ή σε περιπτώσεις όπου οι σωστές προβλέψεις είναι πιο σημαντικές ανεξάρτητα από την κατανομή των διαφόρων αποτελεσμάτων στο στόχο. Ας δούμε τρεις μετρήσεις που είναι αποτελεσματικές στο πλαίσιο του αλγορίθμου δυαδικής ταξινόμησης (είναι επίσης σχετικές για μη δυαδικά προβλήματα, παρ' όλο που τα δυαδικά προβλήματα παρέχουν την ευκολότερη μέθοδο απεικόνισης).



### 5.6.1 Precision

Το precision είναι ένα καλό μέτρο για τον προσδιορισμό, όταν το κόστος του False Positive είναι υψηλό. Για παράδειγμα, η ανίχνευση ανεπιθύμητων μηνυμάτων ηλεκτρονικού ταχυδρομείου. Αυτό επιτυγχάνεται διαιρώντας τον αριθμό των σωστών θετικών προβλέψεων επί του συνολικού αριθμού θετικών προβλέψεων (αληθινό θετικό διαιρούμενο με άθροισμα ψευδώς θετικών και πραγματικών θετικών).

### 5.6.2 Recall

Το Recall μοιάζει πολύ με το Precision. Ο παρονομαστής στο recall, ωστόσο, αποτελείται από αληθινά θετικά και ψευδώς αρνητικά, ενώ στον αριθμητή παραμένουν τα αληθινά θετικά. Αυτό μετατοπίζει την εστίασή μας από το πόσο σημαντική είναι η θετική βαθμολογία, στην κατανόηση του πόσο αποτελεσματικό είναι το μοντέλο μας στον εντοπισμό οποιασδήποτε θετικής περίπτωσης. Καθώς ο αριθμός των ψευδώς αρνητικών αυξάνεται, δεν υπάρχει αύξηση στον αριθμητή των πραγματικών θετικών και η ανάκληση γίνεται όλο και χαμηλότερη. Στην πραγματικότητα υπάρχει μια μέτρια αντιστάθμιση μεταξύ βελτιστοποίησης του Precision και του Recall.

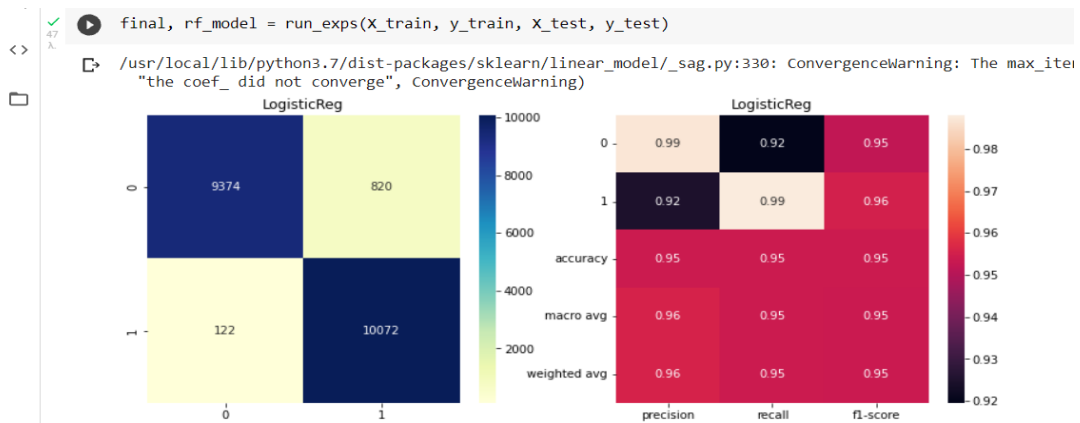

### 5.6.3 F1-Score

Το F1-Score είναι ο τέλειος τρόπος με τον οποίο μπορούμε να έχουμε καλύτερη αίσθηση της απόδοσης του μοντέλου όταν έχουμε άνισα δεδομένα, καθώς η ακρίβεια από μόνη της δεν είναι καλή μέτρηση. Το F1-Score είναι ένας αρμονικός μέσος όρος (η μέγιστη τιμή είναι ο αριθμητικός μέσος όρος) της βαθμολογίας Precision και Recall. Έχοντας αυτό το μείγμα, το μοντέλο μας δίνει μια ισχυρή ιδέα για το πόσο καλά λειτουργεί.

## 5.7 Αποτελέσματα

### 5.7.1 Logistic Regression


Η Logistic Regression λειτουργεί κάπως πολύ παρόμοια με τη γραμμική παλινδρόμηση. Υπολογίζει επίσης τη γραμμική έξοδο, ακολουθούμενη από μια συνάρτηση συγκέντρωσης πάνω στην έξοδο παλινδρόμησης. Η Σιγμοειδής συνάρτηση είναι ευρέως χρησιμοποιούμενη λειτουργία στην μέθοδο αυτή.

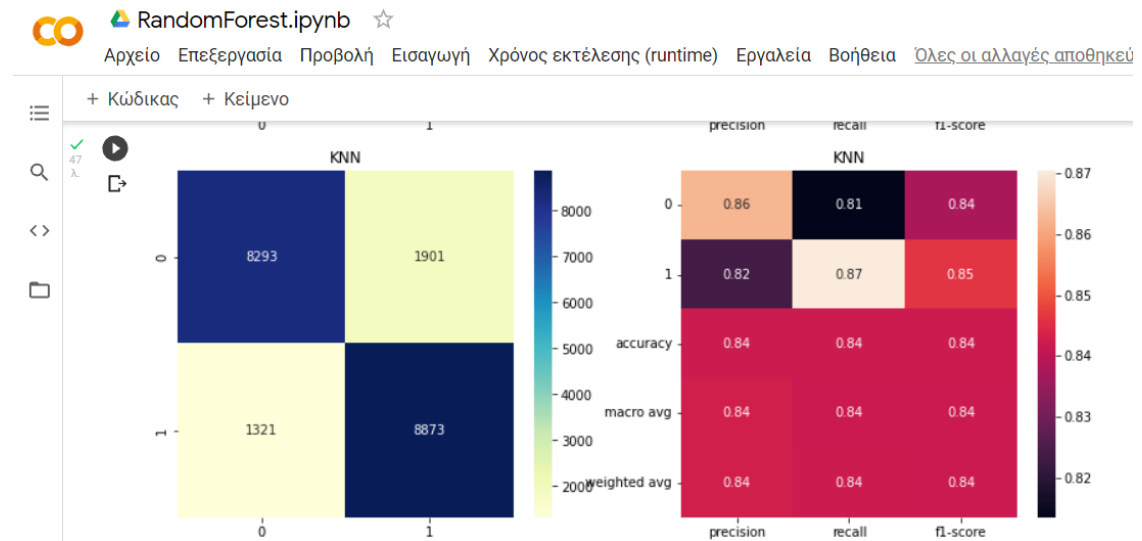


Το μοντέλο μας με την μέθοδο Logistic Regression κατέγραψε 95% ακρίβεια. (πολύ καλό accurate score)

### 5.7.2 KNN

Η βασική λογική πίσω από το KNN είναι να εξερευνήσει τις γειτονικές τιμές και να υποθέσει ότι το σημείο δεδομένων δοκιμής είναι παρόμοιο με αυτά ώστε να προβλέψει την έξοδο. Στην μέθοδο KNN, αναζητούμε τις κοντινές τιμές και με τον τρόπο αυτό καταλήγουμε στην πρόβλεψη.




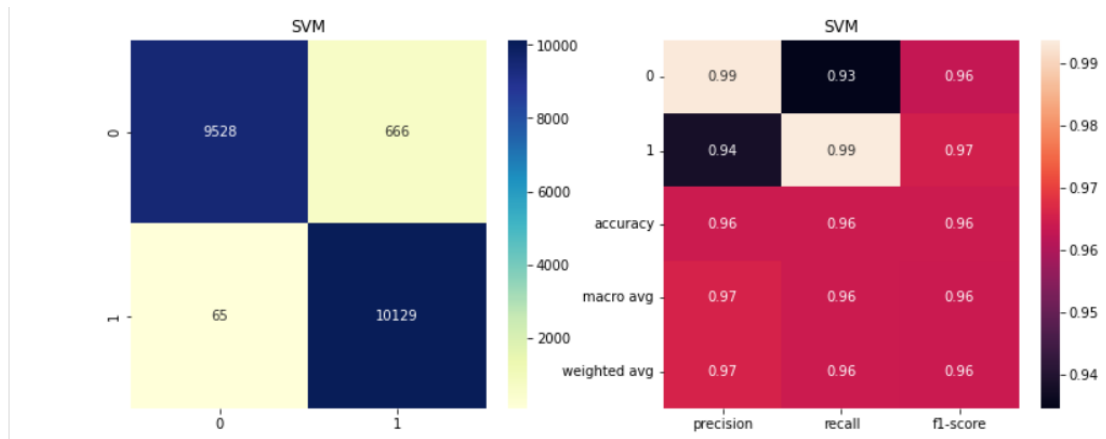


Το μοντέλο KNN κατέγραψε 84% ακρίβεια. (καλή τιμή)

### 5.7.3 SVM Support Vector Machine

Το SVM είναι ένα μοντέλο μηχανικής μάθησης που χρησιμοποιεί αλγόριθμους ταξινόμησης για προβλήματα ταξινόμησης δύο ομάδων. Χρησιμοποιώντας ένα μοντέλο SVM σε σύνολα δεδομένων εκπαίδευσης για κάθε κατηγορία, μπορούν να κατηγοριοποιήσουν το νέο.

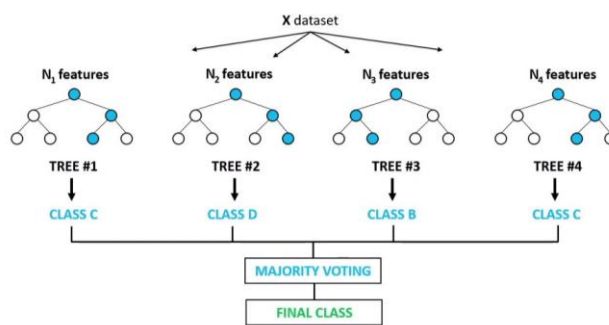





Το μοντέλο μας κατέγραψε 96% ακρίβεια στην εκτίμησή του. (πολύ καλό accurate score)

### 5.7.4 Random Forest

Η εν λόγω τεχνική μπορεί να χειριστεί μεγάλα δεδομένα με πολυάριθμες μεταβλητές που φτάνουν σε χιλιάδες. Μπορεί να διαχειριστεί τα σύνολα όταν μια κλάση είναι πιο σπάνια από άλλες κλάσεις στα δεδομένα. Η μέθοδος χειρίζεται επίσης τις μεταβλητές γρήγορα, καθιστώντας την κατάλληλη για πολύπλοκες εργασίες.



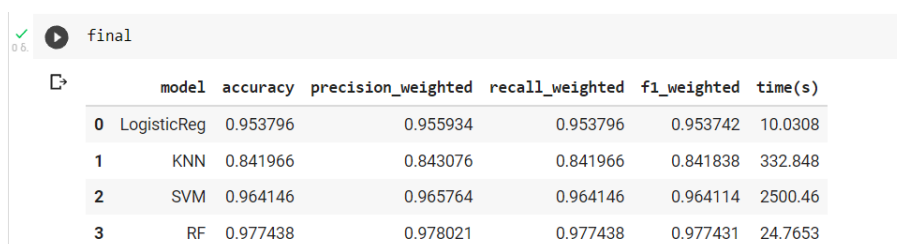
LOGISTIC REGRESSION VS RANDOM FOREST CLASSIFIER



Το ποσοστό ακρίβειας που πέτυχε η μέθοδος του Random Forest είναι 98%.

## 5.8 Επιλογή ιδανικού μοντέλου

Σαν καταλληλότερο μοντέλο για την αναζήτηση των εκτιμήσεων για τις ζητούμενες μεταβλητές επιλέγω την Random Forest μέθοδο. Ο λόγος είναι ότι παρουσιάζουν την μεγαλύτερη τιμή στον δείκτη της ακρίβειας των μοντέλων. Τα αποτελέσματα της έρευνάς μας παρουσιάζονται αναλυτικά στο παρακάτω πινακάκι. Όπως θα δείτε, λοιπόν, η εν λόγω μέθοδος έχει ακρίβεια 97%, όταν το χαμηλότερο ποσοστό το έλαβε η μέθοδος KNN με 83%. Σε περίπτωση που θέλουμε να λάβουμε υπόψιν μας και άλλες τιμές από το παρακάτω πινακάκι για να καταλήξουμε στην ορθότερη μέθοδο υπολογισμού, είναι και ο χρόνος που χρειάστηκε το κάθε μοντέλο για να τρέξει. Και σε αυτήν την περίπτωση όμως βλέπουμε ότι το Random Forest κατέγραψε με τον 2<sup>ο</sup> καλύτερο χρόνο το καλύτερο ποσοστό ακρίβειας.



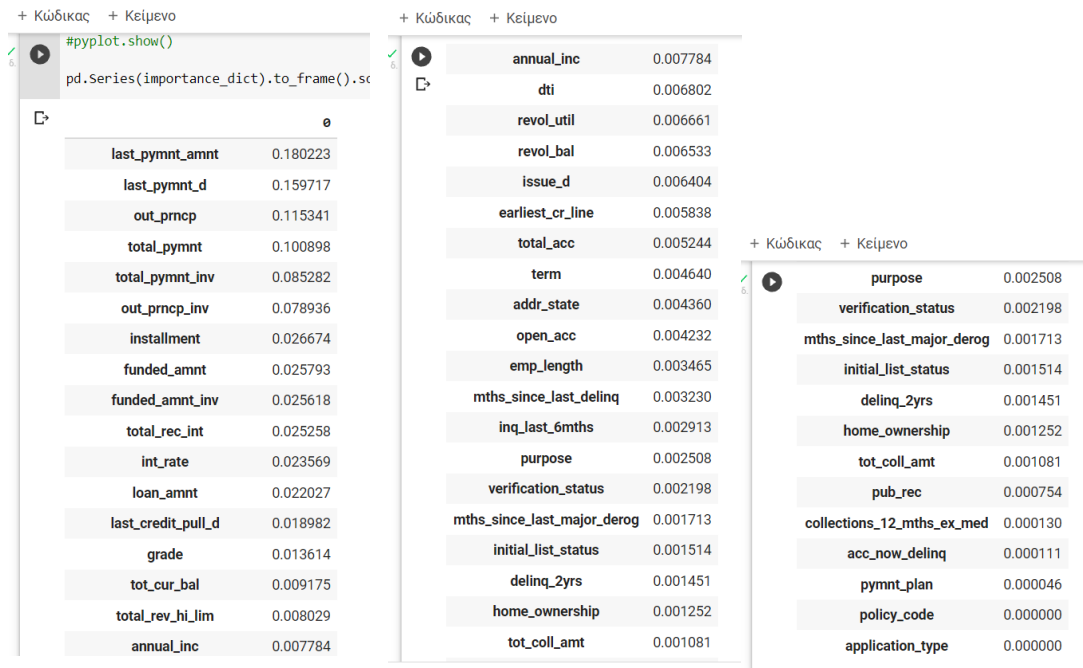
The screenshot shows a Jupyter Notebook cell with a play button icon and the text 'final'. Below it is a table with 7 columns: model, accuracy, precision\_weighted, recall\_weighted, f1\_weighted, and time(s). The table contains 4 rows of data for different models.

	model	accuracy	precision_weighted	recall_weighted	f1_weighted	time(s)
0	LogisticReg	0.953796	0.955934	0.953796	0.953742	10.0308
1	KNN	0.841966	0.843076	0.841966	0.841838	332.848
2	SVM	0.964146	0.965764	0.964146	0.964114	2500.46
3	RF	0.977438	0.978021	0.977438	0.977431	24.7653

Μερικά από τα πλεονεκτήματά της μεθόδου Random Forest είναι ότι:

- Μειώνει την υπερπροσαρμογή σε δέντρα αποφάσεων και συμβάλλει στη βελτίωση της ακρίβειας
- Είναι ευέλικτο τόσο σε προβλήματα ταξινόμησης όσο και σε παλινδρόμηση
- Λειτουργεί καλά τόσο με κατηγορικές όσο και με συνεχείς τιμές
- Αυτοματοποιεί τις τιμές που λείπουν από τα δεδομένα
- Η κανονικοποίηση των δεδομένων δεν απαιτείται καθώς χρησιμοποιεί προσέγγιση βασισμένη σε κανόνες.

Τέλος, ακολουθούν και οι πίνακες με τις μεταβλητές και την συνεισφορά τους στο αποτέλεσμα.



Την μεγαλύτερη συμμετοχή στο μοντέλο μας την έχει η μεταβλητή «Last payment amount» με 18%. Ακολουθεί η μεταβλητή «Last payment day» με ποσοστό 15% και ακολουθεί το «Remaining outstanding principal for total amount funded» που σχετίζεται με το υπολειπόμενο κεφάλαιο για να συμπληρωθεί το συνολικό χρηματοδοτούμενο ποσό.

Για τις παραπάνω μεταβλητές, την κάθε μια στο ποσοστό της, μπορεί να τις χρησιμοποιήσει και να τις συμπεριλάβει στην ανάλυση για να μπορέσει να κατηγοριοποιήσει τη χρηματοδοτική κατάσταση ενός πελάτη στο μέλλον.

## Επίλογος – Συμπεράσματα – Προοπτικές

Η έλευση των νέων τεχνολογιών έχει επιφέρει δραστικές αλλαγές στις διαδικασίες και στην λειτουργία των χρηματοπιστωτικών ιδρυμάτων. Είναι πολύ χαρακτηριστικό παράδειγμα ότι όλες οι τράπεζες ξεκινάνε και ανακοινώνουν τα εκάστοτε Transformation τους. Στον τρόπο λειτουργίας που περιγράφουν, οι μέθοδοι του Artificial Intelligent και του Machine Learning καταλαμβάνουν το κύριο κομμάτι εργασίας. Είναι ολοφάνερο πως η ανάπτυξη των υπολογιστικών μηχανημάτων καθώς και οι διάφορες λύσεις στον τρόπο αποθήκευσης των πολύ μεγάλων δεδομένων δημιούργησαν νέες ευκαιρίες. Πιο συγκεκριμένα, στην διαχείριση του πιστωτικού κινδύνου, οι νέες τεχνολογίες διευκολύνουν όλες τις επιθυμητές παραμετροποιήσεις που μπορεί να χρειαστούν. Ακόμα, συμβάλουν και στις διάφορες προβλέψεις των πελατολογίων τους, σχετικά με μελλοντικές ενέργειες σε τυχόν χρηματοδοτήσεις. Υπολογίζουν και κατατάσσουν τους πελάτες τους σε βαθμολογίες αναλόγως με την φερεγγυότητά τους καθώς και με άλλα πιο πολύπλοκα χαρακτηριστικά. Έχουν αναπτύξει μηχανισμούς και αλγόριθμους που επιτρέπουν γρήγορες αξιολογήσεις καθώς και εγκρίσεις στα δανειακά αιτήματα. Τέλος, βελτιώνουν και τις υπηρεσίες που παρέχουν στους πελάτες τους αναλόγως και με την συναλλακτική τους συμπεριφορά.

Ένας αλγόριθμος AI ή ML μπορεί να βελτιώνεται συνεχώς και να καλύπτει σχεδόν όλες τις ανάγκες που θέλει να εξυπηρετήσει ένας χρηματοπιστωτικός οργανισμός. Αυτό συμβαίνει καθώς η τεχνολογία εξελίσσεται ακόμα και επίσης τα δεδομένα πολλές φορές αλλάζουν. Οι διάφορες χρήσεις των εργαλείων και των μεθόδων παρουσιάζουν πολλά πλεονεκτήματα καθώς και μειονεκτήματα. Σχετικά με το ποιο πλήθος υπερισχύει είναι τελείως αντικειμενικό, αλλά η προσωπική μου άποψη είναι ότι τα πλεονεκτήματα είναι περισσότερα. Το μόνο που μπορούμε να περιμένουμε από τα μελλοντικά μας εργαλεία είναι ότι τα προβλήματα που θα κληθούν να δώσουν λύση, και που θα δώσουν, είναι πολλαπλάσια από αυτά που θα δημιουργήσουν.

## Βιβλιογραφία

### Ελληνική

Αγγελόπουλος, Π.(2011), Εισαγωγή στα Παράγωγα Χρηματοοικονομικά Προϊόντα, Εκδόσεις Σταμούλης, Αθήνα.

Αγγελόπουλος, Π.(2005), Τράπεζες και χρηματοπιστωτικό σύστημα: αγορές, προϊόντα, κίνδυνοι, Εκδόσεις Σταμούλη , Αθήνα.

Αλεξάκης, Π.(2006), Εισαγωγή στις τραπεζικές σπουδές, Έκδοση Ελληνική ένωση Τραπεζών, Ελληνικό Τραπεζικό Ινστιτούτο, Αθήνα.

Βασιλείου, Π.(2001), Στοχαστικά μοντέλα, Εκδόσεις Ζήτη ,Θεσσαλονίκη.

Γεωργούτσος, Δ. (2008), «Διαχείριση Κινδύνων και Κεφαλαιακή Επάρκεια Πιστωτικών Ιδρυμάτων», Οικονομικό Πανεπιστήμιο Αθηνών, Βιβλιοθήκη Δημοκριτίου Πανεπιστημίου Θράκης ,Κομοτηνή.

Γλύκας Μ, Ξηρογιάννης Γ, Σταϊκούρας Χ.(2006),Οργάνωση και Διοίκηση Χρηματοπιστωτικών Ιδρυμάτων, Εκδόσεις Παπαζήση, Αθήνα.

Κίοχος, Π.(2003), Διαχείριση Χαρτοφυλακίων & Χρηματοοικονομικών Κινδύνων, Εκδόσεις Σύγχρονη Εκδοτική, Αθήνα.

Κοκκομέλης, Κ. (1995), Τραπεζικές Υπηρεσίες προς Καταναλωτές, Ένωση Ελληνικών Τραπεζών ,Αθήνα.

Κοσκοφάς ,Ι.(2012), Διεθνείς Χρηματοοικονομικές Αγορές ,Εκδόσεις Σάκκουλα, Αθήνα.

Παπαδάκης, Ι. (2004), Ο ρόλος των τραπεζών και του κανονιστικού πλαισίου τους: Υποδείξεις της Οικονομικής θεωρίας, Εκδόσεις Σάκκουλα , Αθήνα.

Πατρινός, Δ.(1999), Τράπεζες και Χρηματοπιστωτική Πολιτική, Εκδόσεις Παπαζήση ΑΕΒΕ, Αθήνα.

Ρεπούσης, Σ. (2004), Τραπεζικές Πιστοδοτήσεις, Εκδόσεις Σάκουλα, Αθήνα.

Συριόπουλος Κ., Παπαδάμου Κ. (2014), Εισαγωγή στην Τραπεζική οικονομική και στις Κεφαλαιαγορές, Εκδόσεις Utopia, Αθήνα.

Σχοινιωτάκης Ν., Συλλιγάρδος Γ. (2010), Διαχείριση τραπεζικών και χρηματοοικονομικών κινδύνων: Θεωρία και Εφαρμογές ,Εκδόσεις Δίσιγμα, Αθήνα.

Σταμουργκέλης ,Ι. (2016), Ο ρόλος των Τραπεζών και του Ευρώ στην Ευρωπαϊκή και Ελληνική Κρίση, Εκδόσεις Παπαζήση, Αθήνα.

Φίλιππας, Ν.(2010),Αμοιβαία Κεφαλαία, Η ελληνική πραγματικότητα και οι σύγχρονες διεθνείς εξελίξεις ,Εκδόσεις Ελευθερουδάκης, Αθήνα.



Χοχλάκη Ε. (2002), Χρηματοοικονομική Διοίκηση και Τραπεζική Οικονομική, Τόμος Γ', Τραπεζική Οικονομική, Εκδόσεις Πετράκης Π.Ε. , Αθήνα

Χριστόπουλος Α, Ντόκας Ι. (2012), Θέματα Τραπεζικής και Χρηματοοικονομικής Θεωρίας, Εκδόσεις Κριτική, Αθήνα.

Χατζησεβαστού, Α. (2011), Εγγυητική επιστολή σε πρώτη ζήτηση, Εκδόσεις Σάκκουλα, Αθήνα.

Δ.Χ.Σ. (2010), Έκθεση για την Χρηματοπιστωτική Σταθερότητα, Τράπεζα της Ελλάδος, ΙΕΤΑ, Αθήνα.

Ψαράκης Κ. Ευτύχιος (2016), τραπεζικοί κίνδυνοι και εταιρική διακυβέρνηση, μια εμπειρική μελέτη των Ευρωπαϊκών τραπεζών, Βιβλιοθήκη Πολυτεχνίου Κρήτης, Κρήτη.

## Διεθνής

Basel Committee on Banking Supervision, 2016a. Reducing variation in credit risk-weighted assets – constraints on the use of internal model approaches (Consultative document No. d362). Bank for International Settlements, Basel.

Basel Committee on Banking Supervision, 2013. Regulatory Consistency Assessment Programme (RCAP) analysis of risk-weighted assets for credit risk in the banking book. Bank for Internat. Settlements, Basel.

Basel Committee on Banking Supervision, 2004. Basel II: International Convergence of Capital Measurement and Capital Standards: a Revised Framework. Bank for International Settlements, Basel.

Bruno, B., Nocera, G., Resti, A., 2016. Are risk-based capital requirements detrimental to corporate lending? Evidence from Europe, unpublished working paper. Bocconi University, Milano.

European Banking Authority, 2015a. The Future of the IRB Approach (Discussion paper No. EBA/DP/2015/01). European Banking Authority, London.

Le Leslé, V., Avramova, S., 2012. Revisiting risk-weighted assets. International monetary fund (IMF).

Ledo, M., 2012. Towards more consistent, albeit diverse, risk-weighted assets across banks. *Rivista de Estabilidad Financiera* 21, 43–61.

Basel Committee on Banking Supervision 2001, The Internal Ratings-Based Approach, Bank for International Settlements

Arndorfer I, Minto A (2015) The “four lines of defence model” for financial institutions. Financial Stability Institute, Occasional paper No 11.

Asermely D (2019) Model risk management – Special report 2019: Machine learning governance.

Aziz S, Dowling M (2019) Machine learning and AI for risk management. In Lynn T, Mooney J, Rosati P, Cummins M (eds.) *Disrupting Finance, FinTech and strategy in the 21st Century*.

EBA (European Banking Authority) (2017) Guidelines on internal governance under Directive 2013/36/EU. EBA/GL/2017/11.

FSB (Financial Stability Board) (2017) Artificial intelligence and machine learning in financial services: Market developments and financial stability implications.

Jin GZ (2018) Artificial intelligence and consumer privacy. NBER working paper, 24253. <http://www.nber.org/papers/w24253>

- Khandani AE, Kim AJ, Lo AW (2010) Consumer credit-risk models via machine-learning algorithms. *Journal of Banking & Finance* 34(11): 2767-2787.
- Mullainathan S, Spiess J (2017) Machine learning: An applied econometric approach. *Journal of Economic Perspectives* 31(2): 87- 106.
- Bessis, J. (2002), *Risk Management in Banking*. Chichester: John Wiley & Sons.
- Eng, William F.(1992), *Options: Trading Strategies that Work*, Dearborn Financial Publishing, Chicago.
- Ritchken,P. (1996), *Derivatives Markets: Theory, Strategy and Applications*, N.Y Harper Collins.
- Saunders A. (1999), “Credit Risk Measurement: New Approaches to Value at Risk and Other Paradigms”, John Wiley& Sons, Inc.
- Burton M, Nesiba R, and Brown B., (2010), *An introduction to Financial Markets and Institutions* , Second Edition , Routledge Publishers, NY, USA.
- Quagliariello M, (2009), *Stress-testing the Banking Systems : Methodologies and Applications*, Cambridge University Press.
- Mishkin S Frederic, (2004), *The economics of Money, Banking, and Financial Markets*, Seventh Edition, Columbia University, USA.
- Longin M Francois, *From value at risk to stress testing: The extreme value approach*, France.

## Διαδικτυακοί Τόποι – Ηλεκτρονικές Πηγές

<https://www.bis.org/fsi/fsipapers11.htm>

<https://www.fsb.org/2017/11/artificial-intelligence-and-machine-learning-in-financial-service/>

<https://www.kaggle.com/ethon0426/lending-club-20072020q1>

<https://www.risk.net/>

<https://www.kaggle.com/datasets?tags=13302-Classification>

<https://realpython.com/python-data-cleaning-numpy-pandas/>