



ΣΧΟΛΗ ΕΠΙΣΤΗΜΩΝ ΔΙΟΙΚΗΣΗΣ ΕΠΙΧΕΙΡΗΣΕΩΝ
ΤΜΗΜΑ ΛΟΓΙΣΤΙΚΗΣ ΚΑΙ ΧΡΗΜΑΤΟΟΙΚΟΝΟΜΙΚΗΣ
ΠΡΟΓΡΑΜΜΑ ΜΕΤΑΠΤΥΧΙΑΚΩΝ ΣΠΟΥΔΩΝ ΣΤΗΝ
ΕΦΑΡΜΟΣΜΕΝΗ ΛΟΓΙΣΤΙΚΗ ΚΑΙ ΕΛΕΓΚΤΙΚΗ

Διπλωματική Εργασία

ΕΦΑΡΜΟΓΕΣ ΤΗΣ ΤΕΧΝΗΤΗΣ ΝΟΗΜΟΣΥΝΗΣ ΣΤΗ
ΧΡΗΜΑΤΟΟΙΚΟΝΟΜΙΚΗ ΑΝΑΛΥΣΗ ΚΑΙ ΕΛΕΓΚΤΙΚΗ

της

ANNA ΡΙΓΑΝΗ

Επιβλέπων Καθηγητής: Ευστράτιος Λιβάνης

Υποβλήθηκε ως απαιτούμενο για την απόκτηση του Μεταπτυχιακού Διπλώματος
στην Εφαρμοσμένη Λογιστική και Ελεγκτική

ΙΑΝΟΥΑΡΙΟΣ 2021

ΠΕΡΙΛΗΨΗ

Η παρούσα διπλωματική εργασία πραγματοποιήθηκε για την απόκτηση του μεταπτυχιακού τίτλου σπουδών της Εφαρμοσμένης Λογιστικής και Ελεγκτικής. Η εργασία διαπραγματεύεται το, κατά την χρονική στιγμή της συγγραφής αυτής, ιδιαίτερα ενδιαφέρον από επιστημονικής και επιχειρηματικής πλευράς θέματος των τεχνικών της Τεχνητής Νοημοσύνης που βρίσκουν εφαρμογή στην χρηματοοικονομική ανάλυση και ελεγκτική. Η εργασία ξεκινά με την καθιερωμένη βιβλιογραφική επισκόπηση που σκοπό έχει να αναδείξει τις υφιστάμενες πρακτικές στον κλάδο της Χρηματοοικονομικής και Ελεγκτικής αναφορικά με την Τεχνητή Νοημοσύνη. Στην συνέχεια ακολουθεί η παρουσίαση βασικών μεθόδων που χρησιμοποιούνται στην ανάπτυξη προβλεπτικών μοντέλων για την επίλυση προβλημάτων της δίτιμης ταξινόμησης (binary classification). Τα προηγούμενα βρίσκουν εφαρμογή μέσα από σχετική εμπειρική μελέτη με δεδομένα, η οποία υλοποιήθηκε με την χρήση κατάλληλου λογισμικού ανοικτού κώδικα και συγκεκριμένα της γλώσσας R και το πακέτο caret.

ABSTRACT

The present thesis was carried out for the acquirement of the Master's degree in Applied Accounting and Auditing. This paper discusses the interest the scientific and business community show about the techniques of Artificial Intelligence in the Financial and Audit field. The paper starts with a literature review and highlight the existing practices and applications of the Artificial Intelligence in the field of Finance and Auditing. The next step is the presentation of the basic methods that we can use for the development binary classification models. In the end, we used these models in order to realize an empirical approach. The empirical approach was implemented using open-source software, specifically we used the programming language R and the caret package.

ΠΙΝΑΚΑΣ ΠΕΡΙΕΧΟΜΕΝΩΝ

ΠΕΡΙΛΗΨΗ	ii
ABSTRACT	iii
ΠΙΝΑΚΑΣ ΠΕΡΙΕΧΟΜΕΝΩΝ	iv
ΠΕΡΙΕΧΟΜΕΝΑ ΠΙΝΑΚΩΝ	vi
ΠΕΡΙΕΧΟΜΕΝΑ ΔΙΑΓΡΑΜΜΑΤΩΝ	vii
ΚΕΦΑΛΑΙΟ 1 ^ο	1
ΕΙΣΑΓΩΓΗ.....	1
ΚΕΦΑΛΑΙΟ 2 ^ο	3
ΒΙΒΛΙΟΓΡΑΦΙΚΗ ΕΠΙΣΚΟΠΗΣΗ	3
2.1 Εισαγωγή.....	3
2.2 Επισκόπηση Βιβλιογραφίας.....	3
ΚΕΦΑΛΑΙΟ 3 ^ο	17
ΤΕΧΝΗΤΗ ΝΟΗΜΟΣΥΝΗ	17
3.1 Εισαγωγή στην Τεχνητή Νοημοσύνη.....	17
3.2 Τι είναι η Τεχνητή Νοημοσύνη.....	17
3.3 Ιστορική εξέλιξη της Τεχνητής Νοημοσύνης.....	18
3.4 Εφαρμογές της Τεχνητής Νοημοσύνης	19
3.4.1 Έμπειρα Συστήματα	19
3.4.2 Ρομποτική	19
3.4.3 Επίλυση Προβλημάτων	20
3.4.4 Νευρωνικά Δίκτυα	20
3.4.5 Ευφυείς Πράκτορες.....	21
3.5 Τεχνητή Νοημοσύνη και Big Data.....	22
ΚΕΦΑΛΑΙΟ 4 ^ο	24
ΤΕΧΝΗΤΗ ΝΟΗΜΟΣΥΝΗ ΚΑΙ ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ	24
4.1 Εισαγωγή.....	24
4.2 Διαχείριση Εφοδιαστικής Αλυσίδας	24

4.3 Ταμειακές Ροές	26
4.4 Προβλέψεις Τιμών Χρηματιστηρίου	27
4.5 Ελεγκτική.....	28
ΚΕΦΑΛΑΙΟ 5^ο	32
ΤΕΧΝΗΤΗ ΝΟΗΜΟΣΥΝΗ ΚΑΙ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ	32
5.1 Λογιστική Παλινδρόμηση.....	35
5.2 Δένδρο Απόφασης	37
5.3 Τυχαία Δάση	38
5.4 Τεχνητά Νευρωνικά Δίκτυα	39
5.5 Μπαιεζιανή Μάθηση	40
5.6 Μηχανές Διανυσμάτων Υποστήριξης.....	41
ΚΕΦΑΛΑΙΟ 6^ο	43
ΕΜΠΕΙΡΙΚΗ ΜΕΛΕΤΗ.....	43
6.1 Εισαγωγή.....	43
6.2 Λογιστική Παλινδρόμηση.....	46
6.3 Δέντρα Απόφασης.....	48
6.4 Δέντρα Απόφασης με <i>Bagging</i>	50
6.5 Τυχαία Δάση	51
6.6 Δέντρα Απόφασης με <i>Boosting</i>	53
6.7 Μηχανές Διανυσμάτων Υποστήριξης.....	56
6.8 Νευρωνικά Δίκτυα	57
6.9 Συγκριτική ανάλυση επίδοσης μοντέλων	59
ΚΕΦΑΛΑΙΟ 7^ο	62
ΣΥΜΠΕΡΑΣΜΑΤΑ.....	62
ΒΙΒΛΙΟΓΡΑΦΙΑ.....	64
ΠΑΡΑΡΤΗΜΑ	69

ΠΕΡΙΕΧΟΜΕΝΑ ΠΙΝΑΚΩΝ

Πίνακας 1 Πίνακας Σύγχυσης (Confusion Matrix)	34
Πίνακας 2 Μεταβλητές του Μοντέλου	43
Πίνακας 3 Μετρικές μετά την εκπαίδευση	47
Πίνακας 4 Πίνακας Σύγχυσης.....	47
Πίνακας 5 Μετρικές μετά την πρόβλεψη	47
Πίνακας 6 Μετρικές μετά την εκπαίδευση	48
Πίνακας 7 Πίνακας Σύγχυσης.....	49
Πίνακας 8 Μετρικές μετά την πρόβλεψη	49
Πίνακας 9 Μετρικές μετά την εκπαίδευση	50
Πίνακας 10 Πίνακας Σύγχυσης.....	50
Πίνακας 11 Μετρικές μετά την πρόβλεψη	50
Πίνακας 12 Μετρικές μετά την εκπαίδευση	51
Πίνακας 13 Πίνακας Σύγχυσης.....	52
Πίνακας 14 Μετρικές μετά την πρόβλεψη	52
Πίνακας 15 Μετρικές μετά την εκπαίδευση	54
Πίνακας 16 Πίνακας Σύγχυσης.....	55
Πίνακας 17 Μετρικές μετά την πρόβλεψη	55
Πίνακας 18 Μετρικές μετά την εκπαίδευση	56
Πίνακας 19 Πίνακας Σύγχυσης.....	56
Πίνακας 20 Μετρικές μετά την πρόβλεψη	56
Πίνακας 21 Μετρικές μετά την εκπαίδευση	57
Πίνακας 22 Πίνακας Σύγχυσης.....	58
Πίνακας 23 Μετρικές μετά την πρόβλεψη	58
Πίνακας 24 Συνολικό άθροισμα AUC και Accuracy	61

ΠΕΡΙΕΧΟΜΕΝΑ ΔΙΑΓΡΑΜΜΑΤΩΝ

Διάγραμμα 1 Παράδειγμα καμπύλης ROC.....	35
Διάγραμμα 2 Μορφή Λογιστικής Παλινδρόμησης.....	36
Διάγραμμα 3 Εύρεση τιμής παραμέτρου CP που μεγιστοποιεί την μετρική ROC.....	49
Διάγραμμα 4 Μεγιστοποίηση τιμής ROC.....	52
Διάγραμμα 5 Μεγιστοποίηση τιμής ROC.....	55
Διάγραμμα 6 Μεγιστοποίηση τιμής ROC.....	58
Διάγραμμα 7 Απόδοση τεχνικών με βάση το AUC.....	59
Διάγραμμα 8 Απόδοση τεχνικών με βάση το Accuracy	60

ΚΕΦΑΛΑΙΟ 1^ο

ΕΙΣΑΓΩΓΗ

Η Τεχνητή Νοημοσύνη εξελίσσεται ως η βασική τεχνολογία του μέλλοντος. Η Τεχνητή Νοημοσύνη τα τελευταία χρόνια παρουσιάζει σημαντική εξέλιξη και είναι αρκετές οι φόρες που έχει βρεθεί στο επίκεντρο των συζητήσεων. Ωστόσο το σημαντικό είναι να κατανοηθεί η πραγματική της συνεισφορά στην τεχνολογική πρόοδο. Η τεχνολογία εξελίσσεται με ταχύτατους ρυθμούς και η Τεχνητή Νοημοσύνη είναι ένας από τους λόγους της εξέλιξης. Η συνεισφορά της Τεχνητής Νοημοσύνης στην καθημερινότητα είναι μεγάλη όπως για παράδειγμα στις διαδικτυακές αγορές, στην διαδικτυακή αναζήτηση, στην αυτόματη μετάφραση, στα έξυπνα σπίτια, στον χώρο της κυβερνοασφάλειας, στην καταπολέμηση της παραπληροφόρησης, στα αυτόνομα αυτοκίνητα. Η Τεχνητή Νοημοσύνη μπορεί να μεταμορφώσει την Οικονομία και την ζωή των ανθρώπων. Την συναντάμε σε χώρους όπως της Υγείας, της Γεωργίας, των Μεταφορών, της Διοίκησης, της Οικονομίας, των Επιχειρήσεων και της Ασφάλειας. Επομένως είναι κατανοητό ότι η Τεχνητή Νοημοσύνη αποτελεί σημαντικό κομμάτι του ψηφιακού μετασχηματισμού, με την προϋπόθεση ότι έχουν ληφθεί υπόψιν ορισμένα ζητήματα που συνδέονται με την Τεχνητή Νοημοσύνη τα οποία μπορεί να αποτελούν μελλοντική απειλή.

Η παρούσα εργασία έχει ως σκοπό την παρουσίαση των Εφαρμογών της Τεχνητής Νοημοσύνης στην Χρηματοοικονομική Ανάλυση και στην Ελεγκτική και την πραγματοποίηση μιας εμπειρικής μελέτης με την χρήση προβλεπτικών μεθόδων ταξινόμησης, η οποία έχει στόχο την πρόβλεψη εάν ένας μελλοντικός πελάτης τραπεζής έχει πιστοληπτική ικανότητα και έτσι μπορεί να του δοθεί δάνειο.

Αρχικά, πραγματοποιείται μια βιβλιογραφική επισκόπηση των εφαρμογών της Τεχνητής Νοημοσύνης που απασχολούν την επιστημονική κοινότητα. Στην συνέχεια, ορίζεται η Τεχνητή Νοημοσύνη και παρουσιάζονται οι πιο σημαντικές εφαρμογές της. Συνεχίζοντας, αναλύεται πως η Τεχνητή Νοημοσύνη συμβάλλει στην Επιχειρηματικότητα και ποιοι μέθοδοι χρησιμοποιούνται κυρίως. Έπειτα γίνεται παρουσίαση των σημαντικότερων τεχνικών της Μηχανικής Μάθησης, η οποία

αποτελεί κομμάτι της Τεχνητής Νοημοσύνη. Τέλος, πραγματοποιείται μια εμπειρική μελέτη με χρήση τεχνικών της Μηχανικής Μάθησης και παρουσιάζονται τα ανάλογα συμπεράσματα.

ΚΕΦΑΛΑΙΟ 2^ο

ΒΙΒΛΙΟΓΡΑΦΙΚΗ ΕΠΙΣΚΟΠΗΣΗ

2.1 Εισαγωγή

Στο κεφάλαιο αυτό παρουσιάζεται η σύγχρονη επιστημονική αρθρογραφία της Διπλωματικής Εργασίας. Σκοπός του παρόντος κεφαλαίου είναι η μελέτη και η παρουσίαση επιστημονικών άρθρων και μελετών που αφορούν τις Εφαρμογές της Τεχνητής Νοημοσύνης στην Χρηματοοικονομική Ανάλυση, στην Λογιστική της Ελεγκτικής καθώς και στην Εταιρική Αποτυχία και διαχείριση Κεφαλαίου Κίνησης μιας επιχείρησης, ώστε ο αναγνώστης να μπορέσει να κατανοήσει πως οι σύγχρονες εφαρμογές της Τεχνητής Νοημοσύνης συσχετίζονται με αυτούς τους τομείς και όσο είναι δυνατό να πλησιάσει τα θέματα που απασχολούν την επιστημονική κοινότητα. Τα σημαντικότερα ευρήματα από την αρθρογραφία που μελετήθηκαν, παρατίθενται παρακάτω.

2.2 Επισκόπηση Βιβλιογραφίας

Η φύση διαφόρων σχέσεων αρκετές φορές εμφανίζει μη γραμμικότητα αυτό το εντοπίζεται ακόμη πιο συχνά σε θέματα που έχουν να κάνουν με την διαχείριση καταστάσεων. Στον κλάδο της Διοικητικής Λογιστικής συχνά πρέπει να ληφθούν αποφάσεις οι οποίες είναι μη γραμμικές. Η λήψη αποφάσεων είναι ένα πολύ σημαντικό κομμάτι που απαιτεί την προσεκτική και σωστή ανάλυση των πληροφοριών. Οι νέες τεχνολογίες που βασίζονται στις τεχνικές της Τεχνητής Νοημοσύνης μπορούν να αποτελούν υποστηρικτικά εργαλεία στον κλάδο της Διοικητικής Λογιστικής και μπορούν να προσφέρουν λύσεις σε προβλήματα που δεν μπορούν να λυθούν με τις παραδοσιακές λογικές και αναλυτικές τεχνικές. Έτσι, οι Mirzaey και Hojatpour (2017) στην ερευνά τους προσπάθησαν να προσδιορίσουν την λειτουργία των τεχνικών αυτών για την λήψη αποφάσεων οικονομικής φύσης. Τα αποτελέσματα έδειξαν ότι η χρήση

των τεχνικών της Τεχνητής Νοημοσύνης μπορούν να βελτιώσουν την αποδοτικότητα ενός πληροφοριακού συστήματος λογιστικής και συγκεκριμένα να βοηθήσουν σε διαδικασίες όπως πρόβλεψη τιμής, προβλέψεις χρηματιστηρίου και σε ελεγκτικές αναλύσεις.

Ο Bahrammirzaee (2010) στην έρευνα του έκανε μια συγκριτική μελέτη τριών τεχνικών Τεχνητής Νοημοσύνης οι οποίες είναι τα νευρωνικά δίκτυα , τα έμπειρα συστήματα και τα υβριδικά συστήματα τεχνητής νοημοσύνης σε μια χρηματοοικονομική αγορά. Ο συγγραφέας χώρισε την χρηματοοικονομική αγορά σε τρεις κατηγορίες για να κάνει την σύγκριση οι οποίες είναι η πιστοληπτική ικανότητα, η διαχείριση χαρτοφυλακίου και οι οικονομικές προβλέψεις. Τα αποτελέσματα έδειξαν ότι σε σημαντικό βαθμό η ακρίβεια αυτών των τεχνικών είναι ανώτερη από τις κλασσικές στατιστικές μεθόδους όσο αφορά τα χρηματοοικονομικά προβλήματα και κυρίως τα μη γραμμικά μοντέλα και μπορούν να τις αντικαταστήσουν. Ωστόσο, η εφαρμογή αυτών των τεχνικών προτείνεται μόνο για παραμετρικές μορφές μη γραμμικών προβλημάτων.

Η γρήγορη ανάπτυξη του κλάδου της Πληροφορικής και οι ανάγκες της οικονομίας οδήγησαν στην εφαρμογή των τεχνικών της Τεχνητής Νοημοσύνης σε πολλούς τομείς της οικονομίας. Οι Luo et al. (2018) εξετάζουν τις εφαρμογές της Τεχνητής Νοημοσύνης στον κλάδο της Λογιστικής στην Κίνα και αναλύουν τα προβλήματα που υπάρχουν για την ανάπτυξη και την σωστή χρήση των εφαρμογών αυτών και προτείνουν λύσεις. Η χρήση των εφαρμογών της Τεχνητής Νοημοσύνης στην Λογιστική θα αντικαταστήσει τις κλασσικές μεθόδους και αδιαμφισβήτητα θα φέρει καινοτόμες αλλαγές αλλά θα ενισχύσει και την ανταγωνιστικότητα μεταξύ των επιχειρήσεων. Σύμφωνα με τους συγγραφείς οι εφαρμογές της Τεχνητής Νοημοσύνης στην Κίνα στον τομέα της Λογιστικής βρίσκονται ακόμη στα πρώτα στάδια. Οι εφαρμογές έχουν εισαχθεί στο επίπεδο των οικονομικών αναφορών και όχι στο επίπεδο των οικονομικών αναλύσεων. Για να γίνει χρήση των εφαρμογών της Τεχνητής Νοημοσύνης σε όλα τα επίπεδα πρέπει να γίνουν οι κατάλληλες προσαρμογές και να αποκτηθεί η κατάλληλη εμπειρία. Ακόμη οι επιχειρήσεις για να κάνουν χρήση της τεχνολογίας της Τεχνητής Νοημοσύνης πρέπει να επενδύσουν σε ένα σύστημα Τεχνητής Νοημοσύνης με ιδιαίτερα χαρακτηριστικά τα οποία θα έχουν εφαρμογή στον κλάδο της Λογιστικής. Μια τέτοια επένδυση όμως έχει υψηλό κόστος και απόδοση σε βάθος χρόνου γι' αυτό πολλές επιχειρήσεις δεν προτιμούν μακροχρόνιες επενδύσεις με αποτέλεσμα ο ρυθμός ανάπτυξης των εφαρμογών της Τεχνητής Νοημοσύνης να είναι

αργός. Επίσης, οι λογιστές θα πρέπει να είναι σε θέση να αντιμετωπίσουν ιδιαίτερες καταστάσεις άρα χρειάζονται λογιστές με υψηλό επίπεδο εκπαίδευσης όχι μόνο στην επιστήμη της Λογιστικής αλλά και στην επιστήμη της Πληροφορικής. Τέλος, τα πανεπιστήμια στην Κίνα αντιμετωπίζουν πρόβλημα στην διασύνδεση του θεωρητικού κομματιού με το πρακτικό έτσι οι απόφοιτοι δεν μπορούν να ανταπεξέλθουν στις ανάγκες της αγοράς. Στην συνέχεια οι συγγραφείς προτείνουν λύσεις για την αντιμετώπιση αυτών των προβλημάτων. Αρχικά οι κυβερνήσεις πρέπει να δίνουν κίνητρα στις επιχειρήσεις για την χρήση των εφαρμογών της Τεχνητής Νοημοσύνης. Οι επιχειρήσεις από την άλλη πρέπει να επενδύουν σε μακροχρόνιες επενδύσεις γιατί έτσι θα εξασφαλίσουν πιο βιώσιμες προοπτικές ανάπτυξης. Τα πανεπιστήμια να βελτιώσουν το επίπεδο γνώσεων που παρέχουν και τέλος, οι λογιστές θα πρέπει να ενδιαφέρονται περισσότερο για την βελτίωση των επαγγελματικών τους δεξιοτήτων. Οι συγγραφείς ήρθαν στο συμπέρασμα ότι είναι απαραίτητο κάθε χώρα, επιχείρηση, πανεπιστήμιο και κάθε άτομο ξεχωριστά να συνεργαστούν ώστε να λυθούν τα προβλήματα που υπάρχουν. Η συνεργασία είναι το κλειδί για να αναπτυχθούν οι εφαρμογές της Τεχνητής Νοημοσύνης στον κλάδο της Λογιστικής.

Ο πιστωτικός κίνδυνος είναι ένας από τους πιο κρίσιμους κινδύνους που έρχονται αντιμέτωπα τα χρηματοπιστωτικά ιδρύματα. Η επιτυχία τους στηρίζεται στην ικανότητα αντιμετώπισης τέτοιων κινδύνων. Ένας από τους τρόπους ανάλυσης του πιστωτικού κινδύνου είναι η αξιολόγηση της πιστοληπτικής ικανότητας. Οι Ghodselahe και Amirmadhi (2011) στην έρευνα τους σχεδίασαν ένα υβριδικό μοντέλο για την αξιολόγηση της πιστοληπτικής ικανότητας. Το μοντέλο εφαρμόζει συλλογική μάθηση (ensemble learning) για την λήψη αποφάσεων που αφορούν τους πιστωτικούς κινδύνους. Η συλλογική μάθηση έχει αποδεχθεί αποτελεσματική μέθοδος για την επίτευξη υψηλής απόδοσης. Το μοντέλο συνδυάζει τεχνικές ταξινόμησης και τεχνικές ομαδοποίησης και ως βάση εκπαίδευσης χρησιμοποιεί μηχανές διανυσμάτων υποστήριξης, νευρωνικά δίκτυα και δέντρα αποφάσεων. Σύμφωνα με τους συγγραφείς η χρήση του καλύτερου μοντέλου ταξινόμησης είναι πολύ σημαντικό γιατί έστω και μια μικρή μεταβολή να γίνει στην πιστοληπτική ικανότητα μπορεί να δημιουργήσει σημαντικές απώλειες. Οι συγγραφείς χρησιμοποίησαν ένα πραγματικό σύνολο δεδομένων, την Γερμανική βάση δεδομένων που είναι διαθέσιμη στο UCI, Machine Learning Repository. Τα αποτελέσματα έδειξαν ότι το προτεινόμενο υβριδικό μοντέλο έδωσε καλύτερα αποτελέσματα σε σχέση με άλλα μοντέλα υβριδικής μάθησης όπως το bagging, boosting και stacking. Εφαρμόζοντας το υβριδικό μοντέλο κατέληξαν ότι

οι μηχανές διανυσμάτων υποστήριξης (SVM) έχουν καλύτερη απόδοση και ακρίβεια σε σχέση με τα νευρωνικά δίκτυα και με τα δέντρα αποφάσεων. Επομένως κατέληξαν στο συμπέρασμα ότι η αξιολόγηση της πιστοληπτικής ικανότητας με την χρήση SVM ως βάση ταξινόμησης μπορεί να χρησιμοποιηθεί για την βελτίωση της ακρίβειας σε σημαντικό βαθμό.

Οι Chukwudi et al. (2018) επηρεαζόμενοι από το πόσο γρήγορα οι εφαρμογές της Τεχνητής Νοημοσύνης έχουν επιφέρει αλλαγές στον χρηματοοικονομικό τομέα καθώς και ότι στο μέλλον η επιρροή αναμένεται να είναι ακόμη μεγαλύτερη γιατί έτσι θα επιτευχθεί μεγαλύτερη αποδοτικότητα αλλά και εξοικονόμηση πόρων πραγματοποιήσαν μια έρευνα με σκοπό να εξετάσουν την επιρροή της Τεχνητής Νοημοσύνης στην απόδοση των λογιστικών λειτουργιών και διαδικασιών που βρίσκονται στην Νοτιοανατολική Νιγηρία. Η έρευνα πραγματοποιήθηκε μεταξύ 193 λογιστών και διευθυντών που εργάζονται σε ελεγκτικές εταιρείες. Η επιλογή αυτή δεν ήταν τυχαία καθώς οι εργαζόμενοι στις ελεγκτικές εταιρείες θεωρούνται οι κατάλληλοι ώστε να δώσουν τις πληροφορίες που χρειάζονται. Οι ερευνητές δημιούργησαν ένα ερωτηματολόγιο ώστε να συλλέξουν τις πληροφορίες που χρειαζόντουσαν. Με ανάλυση παλινδρόμησης έλεγξαν τα δεδομένα και σε επίπεδο σημαντικότητας 5%. Η αρχική υπόθεση ήταν οι εφαρμογές της Τεχνητής Νοημοσύνης δεν ασκεί επίδραση στην απόδοση των λογιστικών λειτουργιών ενώ η εναλλακτική ότι ασκούν επίδραση στην απόδοση των λογιστικών λειτουργιών. Συγκεκριμένα επικεντρώθηκαν στα Έμπειρα Συστήματα (Experts Systems) και στους Ευφυείς Πράκτορες (Intelligent agents). Από την ανάλυση προέκυψε ότι τόσο τα Έμπειρα Συστήματα όσο και οι Ευφυείς Πράκτορες ασκούν σημαντική επίδραση στην λειτουργία των λογιστικών λειτουργιών. Σύμφωνα με τους ερευνητές η Τεχνητή Νοημοσύνη στον κλάδο της Λογιστικής αποτελεί ένα πολύ χρήσιμο εργαλείο το οποίο αναπτύσσεται με ταχείς ρυθμούς και μπορεί να επιφέρει σημαντικές αλλαγές. Έκτος ότι μπορούμε να αποκτήσουμε υψηλότερη ακρίβεια μπορεί να μας δώσει την δυνατότητα να προσεγγίσουμε με διαφορετικό τρόπο ορισμένα οικονομικά προβλήματα. Επίσης σύμφωνα με τους ερευνητές στις επόμενες δεκαετίες τα έμπειρα συστήματα θα αντικαταστήσουν τον άνθρωπο για την λήψη αποφάσεων και ορισμένες κουραστικές και επαναλαμβανόμενες λειτουργίες θα γίνονται αυτόματα από αυτά. Τέλος, οι εφαρμογές της Τεχνητής Νοημοσύνης είναι ένας τρόπος ώστε λογιστές, ελεγκτές και επαγγελματίες να βελτιώσουν την επωνυμία τους και την ποιότητα της εργασίας τους

επομένως πρέπει ενημερώνονται και να εκπαιδεύονται συνεχώς για τις νέες τεχνολογίες και για θέματα που αφορούν τις εφαρμογές της Τεχνητής Νοημοσύνης.

Η Sustrova (2016) με σκοπό να εξετάσει την χρησιμότητα των εφαρμογών της Τεχνητής Νοημοσύνης στον κλάδο της Διοίκησης Επιχειρήσεων και κυρίως στον τομέα της εφοδιαστικής αλυσίδας σχεδίασε αρκετά νευρωνικά δίκτυα με διαφορετική αρχιτεκτονική το καθένα ώστε να επιτευχθεί το βέλτιστο επίπεδο αποθέματος και για να βελτιωθεί το σύστημα παραγγελιών σε μια επιχείρηση. Ως δεδομένα εισόδου/εξόδου χρησιμοποιήθηκαν στοιχεία από μια εταιρεία λιανικής πώλησης υλικών υποδομής. Η εταιρεία κάνει εισαγωγές από την Ασία με χρόνο παράδοσης περίπου 60 ημέρες. Τα δεδομένα αφορούν τις μηνιαίες αγορές προϊόντων με την μεγαλύτερη κινητικότητα. Επίσης σύμφωνα με την συγγραφέα πολύ σημαντικό ρόλο παίζει κάθε πότε πραγματοποιούνται οι παραγγελίες. Στην συγκεκριμένη εταιρεία οι παραγγελίες πραγματοποιούνται κάθε τρεις μήνες. Ως είσοδο επιλέχθηκαν 6 μεταβλητές οι οποίες είναι οι πιο σημαντικές για την λήψη αποφάσεων που αφορούν την πραγματοποίηση μιας παραγγελίας και ως έξοδο θα είναι η βέλτιστη ποσότητα παραγγελίας. Τα δεδομένα αναλύθηκαν, επεξεργάστηκαν και κανονικοποιήθηκαν με το MS Office Excel ενώ με το Mathworks MATLAB Neural Network Tool έγιναν οι προβλέψεις. Τα αποτελέσματα έδειξαν ότι η βέλτιστη αρχιτεκτονική Νευρωνικού Δικτύου είναι η 6-12-1, δηλαδή 6 μεταβλητές εισόδου, 12 κρυφοί νευρώνες και 1 έξοδος. Η απόδοση αξιολογήθηκε με τον συντελεστή παλινδρόμησης R^2 και το μέσο τετραγωνικό σφάλμα. Επομένως σύμφωνα με την ερευνήτρια το μοντέλο που αναπτύχθηκε μπορεί να χρησιμοποιηθεί για την εύρεση της βέλτιστης ποσότητας παραγγελίας αλλά για να συμβάλει στην πιο σωστή λειτουργία της πολιτικής διαχείρισης αποθεμάτων.

Σύμφωνα με τους Kusuma et al. (2019) η πρόβλεψη των τιμών του χρηματιστηρίου είναι αρκετά δύσκολη επειδή υπάρχουν πολλοί παράγοντες που τις επηρεάζουν. Οι ερευνητές σχεδίασαν ένα σύστημα στήριξης αποφάσεων το οποίο θα παρέχει στους χρήστες προβλέψεις για τις μελλοντικές τιμές. Το σύστημα αναπτύχθηκε με την χρήση τεχνικών της Τεχνητής Νοημοσύνης και με διαγράμματα candlestick. Το μοντέλο το οποίο εκπαιδευσαν οι ερευνητές αφορούσε το χρηματιστήριο της Ταϊβάν και της Ινδονησίας. Το μοντέλο έδωσε ικανοποιητικά αποτελέσματα με 92,2% και 92,1 % ακρίβεια στο χρηματιστήριο της Ταϊβάν και Ινδονησίας αντίστοιχα στην σύγκριση που έγινε με άλλες μεθόδους πρόβλεψης.

Ως αυτό το σημείο παρατηρήσαμε ότι ένας μεγάλος αριθμός ερευνητών έχουν ασχοληθεί με τις εφαρμογές της Τεχνητής Νοημοσύνης όσο αφορά το κομμάτι των επιχειρήσεων και της ανάπτυξης τεχνολογίας για τον κλάδο της Χρηματοοικονομικής. Ωστόσο ένα πλήθος ερευνητών έχουν ασχοληθεί για το πως η Τεχνητή Νοημοσύνη μπορεί να επηρεάσει τον κλάδο της Ελεγκτικής.

Σύμφωνα με τον συγγραφέα Botez (2018) η ποιότητα του έργου της ελεγκτικής μπορεί να βελτιωθεί σημαντικά με την ανάλυση των δεδομένων (Data Analytics). Η ανάλυση δεδομένων είναι μια διαδικασία εξόρυξης δεδομένων με σκοπό να εξάγουμε χρήσιμα συμπεράσματα με την χρήση ειδικών συστημάτων και λογισμικών. Στον κλάδο της Ελεγκτικής η ανάλυση δεδομένων βρίσκεται ακόμη στα πρώτα στάδια. Κατά τον συγγραφέα η χρήση νέων τεχνολογιών θα φέρουν μεγάλες αλλαγές. Ήδη πολλές εταιρείες με την χρήση εφαρμογών της Τεχνητής Νοημοσύνης κατασκευάζουν τις δικές τους εφαρμογές και συστήματα. Ειδικά στον κλάδο της Ελεγκτικής όπου οι ελεγκτές έρχονται αντιμέτωποι με μεγάλο όγκο πληροφοριών από διαφορετικούς πελάτες, οι οποίοι πελάτες έχουν διαφορετικές ανάγκες, η ανάλυση δεδομένων θα δώσει την δυνατότητα η έρευνα να γίνει πιο αποτελεσματική και ολοκληρωμένη σε σύγκριση με τις παραδοσιακές μεθόδους. Επίσης με την Τεχνητή Νοημοσύνη οι ελεγκτές θα μπορούσαν να έχουν δικές τους εφαρμογές προσαρμοσμένες στις ανάγκες τους ώστε να βελτιωθεί η ποιότητα της εργασίας τους. Για παράδειγμα η ανάλυση των οικονομικών καταστάσεων θα γίνει πιο εύκολη και θα μπορούν να αντλούν πιο συγκεκριμένες πληροφορίες. Όμως δεδομένου ότι η ανάλυση δεδομένων βρίσκεται ακόμη στα πρώτα στάδια όλα αυτά αποτελούν κυρίως υποθέσεις. Τέλος, ο συγγραφέας τονίζει ότι ανεξάρτητα της μεγάλης τεχνολογικής ανάπτυξης δεν πρέπει να ξεχνάμε ότι η επιτυχία εξαρτάται σε σημαντικό βαθμό από τον ανθρώπινο παράγοντα γιατί έτσι κι αλλιώς όλα αυτά είναι εφαρμογές που κατασκευάζονται από τον άνθρωπο και απευθύνονται σε ανθρώπους.

Τα τελευταία χρόνια η χρήση νέων τεχνολογιών σε πολλούς κλάδους έχει αυξηθεί σημαντικά, αυτό το παρατηρούμε και στον κλάδο της Ελεγκτικής και κυρίως με την χρήση τεχνικών της Τεχνητής Νοημοσύνης όπως η μηχανική μάθηση (machine learning). Με αφορμή την όλο και πιο συχνή χρήση των τεχνικών αυτών οι ερευνητές Tariq et al. (2017) προσπαθούν να εξετάσουν ποιες από αυτές τις τεχνικές είναι οι πιο υποσχόμενες. Τα αποτελέσματα έδειξαν ότι ανερχόμενες τεχνολογίες όπως υπολογιστική νέφος (cloud), έξυπνα συμβόλαια (smart contracts), block chain και αποθήκευση μεγάλου όγκου δεδομένων μπορούν να συμβάλλουν στην εξέλιξη του

κλάδου της ελεγκτικής. Ειδικά η Μηχανική Μάθηση μπορεί να βελτιώσει την ποιότητα των αναλύσεων. Επίσης οι ερευνητές μελέτησαν αν πολλές διαδικασίες θα αυτοματοποιηθούν με την χρήση των τεχνικών της Τεχνητής Νοημοσύνης και κατέληξαν ότι σταδιακά στον μέλλον πολλές εργασίες θα αυτοματοποιηθούν. Οι ερευνητές επικεντρώθηκαν κυρίως στους σκοπούς που εξυπηρετούν οι τεχνολογίες αυτές και σύμφωνα με αυτούς μελλοντικές έρευνες θα μπορούσαν να επικεντρωθούν στο γιατί είναι απαραίτητη η χρήση των τεχνολογιών αυτών. Ακόμη οι ερευνητές προτείνουν μερικά ερωτήματα για μελλοντική έρευνα όπως πιο είναι το κόστος και τα πλεονεκτήματα από την υιοθέτηση των τεχνολογιών της Τεχνητής Νοημοσύνης, αν η αυτοματοποίηση θα οδηγήσει σε αντικατάσταση των ελεγκτών ή απλά θα ενισχύσει το έργο τους κτλ. Τέλος, οι ερευνητές καταλήγουν ότι οι ελεγκτές θα πρέπει να εξετάσουν τα πλεονεκτήματα των νέων τεχνολογιών γιατί έτσι το επάγγελμα της ελεγκτικής θα μπορέσει να γίνει πιο αποτελεσματικό, εύκολο και αποδοτικό.

Οι Luo et al. (2018) στην εργασία τους αναλύουν πως η τεχνολογία της Τεχνητής Νοημοσύνης έχει επηρεάσει τον κλάδο Ελεγκτικής και προτείνουν τρόπους στρατηγικής που μπορούν να ακολουθήσουν οι ελεγκτικές εταιρείες ώστε να παρέχουν πιο ποιοτικές υπηρεσίες. Σύμφωνα με τους συγγραφείς η Τεχνητή Νοημοσύνη φέρνει αλλαγές στον κλάδο της Ελεγκτικής αλλάζοντας τον τρόπο λειτουργίας τους και εισάγοντας νέες μεθόδους. Με την χρήση νέων τεχνολογιών, όπως την ανάλυση μεγάλων δεδομένων, την υπολογιστική νέφους εκτός από την Τεχνητή Νοημοσύνη μπορεί να επιτευχθεί υψηλότερη ακρίβεια έτσι ώστε να μειώνεται ο ελεγκτικός κίνδυνος. Με την χρήση των εφαρμογών της Τεχνητής Νοημοσύνης διαδικασίες όπως δειγματοληψία, συλλογή δεδομένων και δημιουργία εκθέσεων ελέγχου θα αυτοματοποιηθεί. Φυσικά οι συγγραφείς τονίζουν πως για να γίνουν όλα αυτά θα πρέπει να αντιμετωπιστούν ορισμένες δυσκολίες που προκύπτουν. Αυτό μπορεί να γίνει με αναβαθμίσεις του λογισμικού, των τεχνικών υποδομών και με την εκπαίδευση των λογιστών και ελεγκτών. Επίσης τονίζουν ότι το θέμα της ασφάλειας πρέπει να αντιμετωπιστεί πολύ προσεκτικά καθώς οι ελεγκτικές εταιρείες διαχειρίζονται μεγάλο όγκο ευαίσθητων δεδομένων. Οι συγγραφείς προτείνουν οι ελεγκτικές εταιρείες να επενδύσουν σε ένα ολοκληρωμένο ελεγκτικό σύστημα Τεχνητής Νοημοσύνης (AI auditing system). Το οποίο θα αποτελείται από ένα σύστημα στήριξης αποφάσεων (Decision Support System, DSS), από ένα πληροφοριακό σύστημα διαχείρισης πληροφοριών (Information Management System, IMS) και από ένα κεντρικό σύστημα διαχείρισης και ελέγχου (Centralized management and Control System, CAM). Με την

ύπαρξη ενός τέτοιου συστήματος θα αντιμετωπιστούν θέματα που έχουν να κάνουν με την ασφάλεια, ταυτοποίηση και δικαιώματα εισόδου κάθε ελεγκτή και κατά επέκταση θα διασφαλίζεται ακόμη περισσότερο η ασφάλεια των οικονομικών πληροφοριών του κάθε πελάτη.

Ο Taha (2012) προσπαθεί να εξετάσει την χρήση των Νευρωνικών Δικτύων στον κλάδο της Ελεγκτικής καθώς και ποια είναι τα πλεονεκτήματα και τα μειονεκτήματα από την χρήση τους. Ακόμη επισημαίνει τις διαφορές μεταξύ ενός έξυπνου συστήματος και ενός Νευρωνικού Δικτύου. Σύμφωνα με τον συγγραφέα με τα Νευρωνικά Δίκτυα έχουμε την δυνατότητα επίλυσης δύσκολων προβλημάτων και μπορούμε να διαχειριστούμε περίπλοκα ασαφή δεδομένα. Τα Νευρωνικά Δίκτυα στηρίζονται στην επαγωγική λογική ενώ τα έμπειρα συστήματα στην αφαιρετική. Επίσης τα Νευρωνικά Δίκτυα χαρακτηρίζονται από ευελιξία σε σύγκριση με τα έμπειρα συστήματα και έχουν και υψηλή ταχύτητα επεξεργασίας. Ακόμη τα Νευρωνικά Δίκτυα δίνουν την δυνατότητα παράλληλης επεξεργασίας των δεδομένων. Ένα σημαντικό μειονέκτημα των Νευρωνικών Δικτύων είναι ότι δεν ερμηνεύουν τα αποτελέσματα που μας δίνουν σε αντίθεση με τα έμπειρα συστήματα. Επιπλέον τα έμπειρα συστήματα αποθηκεύουν τις πληροφορίες σε μια βάση δεδομένων ενώ τα Νευρωνικά Δίκτυα σε νευρωνικά κελία. Με την χρήση των Νευρωνικών Δικτύων σύμφωνα με τον συγγραφέα μπορούμε να πραγματοποιήσουμε πιο αποτελεσματικούς φρολογικούς ελέγχους, να προβλέψουμε μια πτώχευση, να εκτιμήσουμε κινδύνους, να σχεδιάσουμε πιο εύκολα το ελεγκτικό έργο και να κατηγοριοποιούμε τους πελάτες σε κατάλληλες κατηγορίες.

Αντίστοιχα ο Omoteso (2012) στην έρευνα του παρουσιάζει την πορεία της Τεχνητής Νοημοσύνης και στηριζόμενος στην βιβλιογραφική του επισκόπηση ανακαλύπτει κάποια κενά που μπορούν να είναι αφορμές για μελλοντικές έρευνες. Όπως το πως η Τεχνητή Νοημοσύνη μπορεί να επηρεάσει τον εσωτερικό έλεγχο και αν θα είναι αποτελεσματική η χρήση τους από μικρές και μεσαίες ελεγκτικές εταιρίες.

Οι ελεγκτές καθημερινά έρχονται αντιμέτωποι με μεγάλο όγκο δεδομένων από πολλές διαφορετικές πηγές, ωστόσο η έλλειψη κατάλληλων τεχνολογιών και μέσων δυσκολεύει το έργο τους. Σύμφωνα με τους Sun και Vasarhelyi (2018) η χρήση νέων τεχνολογιών όπως η μηχανική μάθηση μπορεί να βοηθήσει στην επίτευξη υψηλότερης ποιότητας του ελεγκτικού έργου. Οι ερευνητές αναλύουν την χρησιμότητα του deep learning, όπου αποτελεί μια τεχνική της μηχανικής μάθησης η οποία στηρίζεται σε τεχνολογίες της Τεχνητής Νοημοσύνης, όσο αφορά την ανάλυση δεδομένων. Οι

ερευνητές υποστηρίζουν ότι η εις βάθος μάθηση (deep learning) αποτελεί μια αποτελεσματική και αποδοτική προσέγγιση ώστε να εξάγουμε χρήσιμα στοιχεία από διάφορες πηγές δεδομένων όπως από συμβόλαια, email, δημοσιεύσεις από μέση κοινωνικής δικτύωσης, άρθρα κτλ. Η τεχνική του deep learning μπορεί να υποστηρίξει το έργο του ελεγκτή σε όλες τις φάσεις του ελέγχου. Οι ελεγκτές για να αξιοποιήσουν αυτή την τεχνολογία μπορούν να χρησιμοποιήσουν ήδη προσχεδιασμένα πακέτα όπως το Neural Language Understanding από την εταιρία IBM Watson ή να χρησιμοποιήσουν έτοιμες βιβλιοθήκες όπως την Tensor Flow της Google η οποία εκπαιδεύει το νευρωνικό δίκτυο ώστε να λυθεί ένα συγκεκριμένο ελεγκτικό πρόβλημα.

Οι Gepp et al. (2018) μέσω της εργασίας τους κατέληξαν ότι οι τεχνικές των μεγάλων δεδομένων (Big Data) στον κλάδο της Ελεγκτικής δεν είναι τόσο διαδεδομένες. Οι συγγραφείς αποσκοπούν να κάνουν πιο κατανοητή την χρήση των Big Data. Οι συγγραφείς προτείνουν τον συνδυασμό πολλαπλών τεχνικών από το να εφαρμόζονται μεμονωμένα μοντέλα. Από την χρήση των Big Data θα προκύψουν πολλά θετικά στον κλάδο της Ελεγκτικής ειδικά όταν γίνει συνδυασμός με τις ήδη υπάρχουσες μεθόδους και με την βοήθεια των ειδικών. Οι ελεγκτές θα ήταν ωφέλιμο να χρησιμοποιούν τις τεχνικές των Big Data ανεξάρτητα αν οι πελάτες τους τις κάνουν χρήση. Οι έλεγχοι για παράδειγμα θα γίνουν πιο αποτελεσματικοί και ο εντοπισμός οικονομικών απατών θα βελτιωθεί. Επίσης, από την βιβλιογραφική τους επισκόπηση κατέληξαν ότι υπάρχουν πολλοί τομείς όπου θα μπορούσαν να αξιοποιήσουν τις τεχνικές των Big Data όπως στο κομμάτι της πληροφόρησης σε πραγματικό χρόνο, σε συνεργατικές πλατφόρμες και σε ομότιμες αγορές. Πλέον πολλές ελεγκτικές εταιρίες συγκαταλέγουν στις υπηρεσίες τους την ανάλυση δεδομένων. Οι συγγραφείς προτείνουν να γίνει μια μελέτη που να επικεντρώνεται στις ανάγκες των ελεγκτικών εταιριών τόσο των μεγάλων όσο και των μικρών και με τα ευρήματα να κατευθυνθούν οι μελλοντικές έρευνες ώστε όλες αυτές οι τεχνικές να γίνουν πιο αποτελεσματικές.

Οι Sledgianowski et al. (2017) προτείνουν μια μέθοδο ώστε να διευκολύνουν τους εκπαιδευτικούς στην ένταξη στο πρόγραμμα σπουδών λογιστικών προγραμμάτων νέων αντικειμένων όπως τα Πληροφοριακά Συστήματα, Big Data, Business Analytics. Η έρευνα αποκάλυψε ότι υπάρχει έλλειψη πόρων για την ενσωμάτωση αυτών των τεχνολογιών. Οι συγγραφείς προτείνουν αρχικά όλοι οι εκπαιδευτικοί να συνεργαστούν μεταξύ τους για την ένταξη τους. Στην συνέχεια να δημιουργήσουν ένα οικονομικό πλάνο το οποίο θα μπορέσει να καλύπτει τις νέες ανάγκες που θα προκύψουν και σταδιακά να αρχίζουν να εντάσσονται οι νέες τεχνολογίες για

παράδειγμα σε ένα μόνο πρόγραμμα στην αρχή. Η συνεργασία αποτελεί το κλειδί ώστε να ανακαλυφθούν τα κενά που υπάρχουν και η ενσωμάτωση να γίνει πιο ομαλά. Με την ένταξη αυτών των τεχνολογιών θα αναβαθμιστεί η ποιότητα των σπουδών και οι γνώσεις που θα έχουν οι φοιτητές.

Οι Dowling και Leech (2014) συγκέντρωσαν αρχειοθετημένα στοιχεία και στοιχεία από συνεντεύξεις που πραγματοποίησαν που αφορούσαν ελεγκτές που εργάζονται σε μια ελεγκτική εταιρία που ανήκει στις Big 4 οι οποίοι ελεγκτές χρησιμοποιούν ένα νέο ελεγκτικό σύστημα. Η μέση εμπειρία του κάθε ελεγκτή ήταν επτά χρόνια και ο κάθε ελεγκτής εργάζεται σε διαφορετικούς κλάδους. Σχεδόν όλοι οι ελεγκτές έχουν χρησιμοποιήσει το νέο σύστημα για ένα χρόνο. Βρισκόμενοι στον δεύτερο χρόνο χρήσης του νιώθουν πιο σίγουροι και άνετοι να το χρησιμοποιούν. Το σύστημα αυτό αναπτύχθηκε ώστε να εξασφαλιστεί ότι όλοι οι ελεγκτές τηρούν τα πρότυπα. Στην συγκεκριμένη έρευνα οι συγγραφείς θέλουν να δουν αν ένα τέτοιο ελεγκτικό σύστημα αλλάζει τον τρόπο συμπεριφοράς των ελεγκτών. Τα αποτελέσματα έδειξαν ότι οι ελεγκτές πλέον είναι πιο αποτελεσματικοί και αποδοτικοί εξαιτίας της real-time σύνδεσης που υπάρχει και των υποχρεωτικών εισόδων/εξόδων από το σύστημα.

Η επιλογή ενός ελεγκτή από μια επιχείρηση είναι άμεσα συνδεδεμένη με την ποιότητα του ελεγκτικού έργου και μπορεί να εξαρτηθεί και από πολλούς άλλους παράγοντες. Οι Kirkos, Spathis και Manolopoulos (2009) στην έρευνα τους χρησιμοποιούν τεχνικές της Τεχνητής Νοημοσύνης ώστε να εξετάσουν από τι εξαρτάται η πρόσληψη ενός ελεγκτή από μια εταιρία που ανήκει στις Big 4 ή όχι. Οι τεχνικές αυτές συγκρίνονται και με την τεχνική της λογιστικής παλινδρόμησης. Οι ερευνητές χρησιμοποιούν μεθόδους ταξινόμησης οι οποίες είναι Δέντρα Αποφάσεων (C4.5 αλγόριθμος), Πολυεπίπεδα perceptron (MLP) και η αναζήτηση κοντινότερων γειτόνων (k-NNs). Τα δεδομένα προήλθαν από την βάση δεδομένων FAME (Financial Analysis Made Easy). Το δείγμα αποτελείται από 338 παρατηρήσεις που σχετίζονται με Βρετανικές και Ιρλανδικές επιχειρήσεις. Η μελέτη αυτή είναι η πρώτη που ανέπτυξε μοντέλο ικανό να ταξινομήσει προσλήψεις ελεγκτών. Ως πηγή εισόδου χρησιμοποιούνται χρηματοοικονομικοί δείκτες και μεταβλητές που σχετίζονται με τα προσόντα των ελεγκτών. Τα τέσσερα μοντέλα κατάφεραν να ταξινομήσουν το δείγμα και να δώσουν ικανοποιητικό ποσοστό ακριβείας. Το C4.5, MLP και η λογιστική παλινδρόμηση συμφωνούν ότι υπάρχει συσχέτιση μεταξύ της πρόσληψης ενός ελεγκτή με το κόστος. Το C4.5 υπερέχει σε σχέση με τα υπόλοιπα μοντέλα. Συγκεκριμένα τα ποσοστά

ακριβείας είναι C4.5 82,12%, MLP 77,27%, k-NNs 69,09% και logistic regression 76,66%.

Οι ελεγκτικές εταιρίες στην σημερινή εποχή έρχονται αντιμέτωπες συχνά με καταστάσεις που αφορούν την διαχείριση οικονομικών απατών. Σύμφωνα με τους Kirkos et al. (2007) οι τεχνικές εξόρυξης δεδομένων (Data Mining) έχουν προηγμένες δυνατότητες ταξινόμησης και πρόβλεψης και έτσι μπορεί να διευκολυνθεί το έργο των ελεγκτών. Οι ερευνητές στην έρευνα τους εξετάζουν την αποτελεσματικότητα τριών τεχνικών για τον εντοπισμό απατών στις οικονομικές καταστάσεις. Οι μέθοδοι που εξετάζουν είναι τα Δέντρα Αποφάσεων (Decision Trees), Νευρωνικά Δίκτυα (Neural Networks) και Δίκτυα Bayes (Bayesian Belief Networks). Τα αποτελέσματα ήταν σύμφωνα και με προηγούμενες έρευνες ότι δηλαδή οι δημοσιευμένες οικονομικές καταστάσεις μπορεί να περιέχουν παραποιημένα οικονομικά στοιχεία. Ακόμη ένας μικρός αριθμός χρηματοοικονομικών δεικτών καθορίζει σε υψηλό βαθμό το αποτέλεσμα της ταξινόμησης. Οι δείκτες αυτοί σε συνδυασμό με τις τεχνικές αυτές μπορούν να οδηγήσουν σε υψηλό ποσοστό ακρίβειας της ταξινόμησης. Το δίκτυο Bayes πέτυχε την καλύτερη απόδοση με ποσοστό 90,3%, στην συνέχεια ακολουθεί το NN με 80% και τέλος το DT με 73,6%. Η μεθοδολογία της έρευνας μπορεί να χρησιμοποιηθεί από ελεγκτές, από τις φορολογικές αρχές, από επενδυτές, από οικονομικούς αναλυτές, από χρηματοπιστωτικά ιδρύματα. Ειδικά τα αποτελέσματα της έρευνας είναι πολύ χρήσιμα για τους ελεγκτές καθώς μπορούν να βοηθήσουν στην διαχείριση, αντιμετώπιση και ανίχνευση παραποιημένων στοιχείων στις χρηματοοικονομικές καταστάσεις.

Οι Fanning και Cogger (1998) χρησιμοποιούν της εφαρμογές της Τεχνητής Νοημοσύνης για να κατασκευάσουν ένα μοντέλο για τον εντοπισμό οικονομικών απατών. Συγκεκριμένα έκαναν χρήση του εργαλείου AutoNet. Εντόπισαν δύο μεταβλητές που σχετίζονται με απάτη στις οικονομικές καταστάσεις. Οι εφαρμογές της Τεχνητής Νοημοσύνης σύμφωνα με τους συγγραφείς είναι πιο αποτελεσματικές για τον εντοπισμό οικονομικών απατών σε σύγκριση με τις κλασσικές στατιστικές μεθόδους. Με το AutoNet μπορούν να αναπτυχθούν πολύ γρήγορα μοντέλα για να πραγματοποιηθούν αναλύσεις. Εναλλακτικό εργαλείο είναι το Adaptive Logit Networks. Το δείγμα που εκπαιδευσαν αφορούσε τα έτη 1972-1984. Σύμφωνα με τους συγγραφείς οι ελεγκτές πολλές φορές έχουν περιορισμένο χρόνο και η ύπαρξη προκαθορισμένων μεταβλητών θα τους βοηθήσει να εντοπίσουν οικονομικές απάτες και θα διευκολυνθεί η εργασία τους.

Σύμφωνα με τους Ukpong, Udoh και Essien (2019) η Τεχνητή Νοημοσύνη αποτελεί ένα εργαλείο το οποίο μπορεί να επιφέρει τρομερές αλλαγές. Οι ερευνητές στην εργασία τους εξετάζουν τα προβλήματα που υπάρχουν στον κλάδο της Λογιστικής και της Ελεγκτικής και για πιο λόγο είναι αναγκαία η χρήση νέων τεχνολογιών στην Νιγηρία. Στην μελέτη συμμετείχαν μέτοχοι για παράδειγμα τραπεζών και καθηγητές του πανεπιστημίου Akwa Ibom State. Για την συλλογή δεδομένων χρησιμοποιήθηκε ερωτηματολόγιο. Οι ερωτήσεις που τέθηκαν ήταν δυο. Η πρώτη ποια τα σχέδια των μετόχων για να αναπτυχθούν οι τράπεζες στην Αφρική και η δεύτερη ποια κομμάτια της ελεγκτικής θα ευνοηθούν από την Τεχνητή Νοημοσύνη. Τα αποτελέσματα έδειξαν ότι οι τράπεζες στο μέλλον θα λειτουργούν σαν πλατφόρμες, ως διανομείς και ως συσσωρευτές. Επίσης, έδειξαν οι η Τεχνητή Νοημοσύνη διευκολύνει πολλές διαδικασίες της Ελεγκτικής όπως την εκτίμηση κινδύνου, την αξιολόγηση του εσωτερικού ελέγχου, στον ελεγκτικό προγραμματισμό και στην αξιολόγηση στοιχείων και λογαριασμών. Με την χρήση της Τεχνητής Νοημοσύνης θα αναβαθμιστεί η ποιότητα του ελεγκτικού έργου και θα γίνει πιο αποτελεσματικό. Στην Αφρική η χρήση της Τεχνητής Νοημοσύνης βρίσκεται ακόμη στα πρώτα στάδια και αντιμετωπίζεται διστακτικά. Οι συγγραφείς προτείνουν να αναπτυχθεί ένα σχέδιο ώστε να προωθηθεί η τεχνολογία της Τεχνητής Νοημοσύνης από τους εκπαιδευτικούς φορείς όσο και από τους επαγγελματικούς.

Οι Axelsen, Green και Ridley (2017) εξετάζουν τον ρόλο των ελεγκτικών πληροφοριακών συστημάτων όσο αφορά τον έλεγχο του Δημοσίου Τομέα. Αρχικά έκαναν μια έρευνα για να δουν πως οι ελεγκτές αντιλαμβάνονται τα Πληροφοριακά Συστήματα. Απευθύνθηκαν σε 55 ελεγκτές από την Αυστραλία, Καναδά, Νέα Ζηλανδία και Αγγλία. Από την έρευνα προέκυψε ότι εάν στο σύνολο της μια ελεγκτική εταιρία κάνει χρήση των πληροφοριακών συστημάτων οι ελεγκτές τα ενσωματώνουν στην εργασία τους. Το πιο σημαντικό όμως είναι ότι ακόμη ο ρόλος των Πληροφοριακών Συστημάτων για τον τομέα της ελεγκτικής είναι υποβαθμισμένος και τον συγγέουν με το τμήμα Πληροφορικής. Επομένως βγαίνει το συμπέρασμα ότι οι ελεγκτές πρέπει να εκπαιδευτούν περισσότερο όσο αφορά τις νέες τεχνολογίες.

Τέλος ένας αριθμός ερευνητών έχει ασχοληθεί με τις εφαρμογές της Τεχνητής Νοημοσύνης και πως αυτές συνδέονται με την Εταιρική Αποτυχία και με την διαχείριση Κεφαλαίου Κίνησης μιας επιχείρησης.

Η διαχείριση των ταμειακών ροών είναι ένας από τους πιο σημαντικούς δείκτες δραστηριότητας μιας επιχείρησης και παίζει σημαντικό ρόλο στην λήψη αποφάσεων.

Η οικονομική διεύθυνση μιας επιχείρησης αποσκοπεί στον καλύτερο τρόπο διαχείρισης των ταμειακών διαθεσίμων και σύμφωνα με την Šuleř (2016) αυτό μπορεί να γίνει με την χρήση ενός συστήματος Τεχνητής Νοημοσύνης. Η ερευνήτρια προσπαθεί να εντοπίσει το κατάλληλο νευρωνικό δίκτυο για την διαχείριση της ρευστότητας. Ως μοντέλο χρησιμοποιήθηκε η επιχείρηση Hornback. Αρχικά κατασκευάστηκαν 1000 νευρωνικά δίκτυα και από αυτά 5 κρίθηκαν ως πιο κατάλληλα. Στην συνέχεια πραγματοποιήθηκε ανάλυση ευαισθησίας και φάνηκε ότι αυτά τα δίκτυα μπορούν αποτελεσματικά να χρησιμοποιηθούν για την πρόβλεψη μελλοντικών ταμειακών ροών. Οι τύποι των νευρωνικών δικτύων είναι: Γραμμικά νευρωνικά δίκτυα (Linear neural networks), Γενικευμένα νευρωνικά δίκτυα (Generalized regression - GRNN), Ακτινική συνάρτηση βάσης (Radial basic function-RBF), Πολυεπίπεδη perceptron τριών στρωμάτων (MLP), Πολυεπίπεδη perceptron τεσσάρων στρωμάτων (MLP). Generalized regression. Για την επιλογή του βέλτιστου δικτύου για την πρόβλεψη των ταμειακών ροών έγινε αξιολόγηση της κάθε ταμειακής ροής ξεχωριστά στο κάθε δίκτυο. Από τους πέντε τύπους πιο αξιόπιστη και χρήσιμη δομή κατέληξε ότι είναι η GRNN με πέντε νευρώνες στο πρώτο κρυφό επίπεδο και οχτώ στο δεύτερο, s10 1:10-5-8-7:7, για να κάνει προβλέψεις ταμειακών ροών και ακολουθεί το RBF s5 1:5-3-7:7 κυρίως για να προβλέπει το ύψος των μετρητών και ισοδύναμων μετρητών στο τέλος κάθε λογιστικής περιόδου. Τα υπόλοιπα μοντέλα αποδείχθηκαν μη ακριβείς. Επομένως τα νευρωνικά δίκτυα μπορούν να χρησιμοποιηθούν αποτελεσματικά και επιτυχημένα από τις επιχειρήσεις για την πρόβλεψη των ταμειακών ροών. Ωστόσο η κάθε εταιρία πρέπει να αναπτύξει την δίκια της μοναδική δομή νευρωνικού δικτύου η οποία θα ανταποκρίνεται στις ανάγκες της.

Εξετάζοντας τις οικονομικές καταστάσεις μια επιχείρησης οι μελλοντικοί επενδυτές μπορούν να εξάγουν χρήσιμα συμπεράσματα αλλά πολλές φορές παρουσιάζουν ψευδή οικονομικά στοιχεία με αποτέλεσμα να παραπληροφορούν και οι αποφάσεις των επενδυτών να μην είναι ορθές. Με αφορμή αυτό οι Chen και Du (2009) κατασκεύασαν ένα μοντέλο πρόβλεψης της οικονομικής αποτυχίας χρησιμοποιώντας εφαρμογές της Τεχνητής Νοημοσύνης και της εξόρυξης δεδομένων (data mining). Στην προσέγγιση με την Τεχνητή Νοημοσύνη χρησιμοποιήθηκε ο αλγόριθμος BPN ενώ στο κομμάτι του data mining χρησιμοποιήθηκαν τεχνικές ομαδοποίησης (clustering) για να προβλέψουν την αποτυχία. Ως δείγμα χρησιμοποιήσαν στοιχεία από 68 εταιρίες που βρίσκονται στο Ταιβάν εισηγμένες στο χρηματιστήριο και οι μεταβλητές που επιλέχθηκαν προέρχονται από επίσημες οικονομικές καταστάσεις και σχετίζονται με

οικονομικές προβλέψεις, επιλέχθηκαν 37 δείκτες. Επίσης το σύνολο των δεδομένων το χώρισαν σε 2, 4, 6 και 8 περιόδους πριν εμφανιστεί οικονομική κρίση. Το λογισμικό που χρησιμοποιήθηκε ήταν το SPSS. Η σύγκριση των δύο τεχνικών έγινε με την σύγκριση του ποσοστού ακριβείας, του ποσοστού σφάλματος τύπου II και με την ανάλυση παραγόντων. Τα αποτελέσματα έδειξαν ότι όσο περισσότερη ανάλυση παραγόντων κάνουμε η ακρίβεια των μοντέλων μειωνόταν. Όταν οι 37 δείκτες χρησιμοποιήθηκαν χωρίς ανάλυση τα μοντέλα έκαναν καλύτερες προβλέψεις με εξαίρεση την όγδοη περίοδο για τον BPN και την δεύτερη για το clustering καθώς και ότι όσο πιο κοντά ήμαστε στην κρίση η πρόβλεψη γίνεται πιο ακριβής, αυξάνεται δηλαδή το ποσοστό ακριβείας. Τέλος, οι επενδυτές ενδιαφέρονται και για το ποσοστό σφάλματος τύπου II ώστε να πάρουν αποφάσεις. Παρατηρήθηκε ότι με το clustering υπάρχει πιο υψηλό ποσοστό σφάλματος σε σύγκριση με τον αλγόριθμο BPN έτσι η επιτυχία της πρόβλεψης επηρεάζεται σημαντικά.

Ο τρόπος διαχείρισης του κεφαλαίου κίνησης καθορίζει σε σημαντικό βαθμό της ανταγωνιστικότητα μιας επιχείρησης στην αγορά. Οι Song et al. (2012) στην εργασία τους εξετάζουν πως η δυναμικότητα και η ρευστότητα του κεφαλαίου κίνησης επηρεάζουν τον ανταγωνισμό στον κλάδο της βιομηχανίας. Τα δεδομένα προέρχονται από την βάση δεδομένων CSMAR. Οι προβλέψεις έγιναν με δύο μεθόδους με την γενικευμένη μέθοδο ροπών (Generalized method of moments-GMM) και με τον αλγόριθμο οπισθοδρομικής διάδοσης (BP Neural network). Τα συμπεράσματα που προέκυψαν είναι τα παρακάτω. Η δυναμικότητα του κεφαλαίου κίνησης επηρεάζει θετικά στην δημιουργία ανταγωνισμού για την αγορά ενός προϊόντος ενώ η ρευστότητα του κεφαλαίου κίνησης έχει αρνητική σχέση με τον ανταγωνισμό. Τα ρευστά διαθέσιμα και τα αποθέματα σε επίπεδο σημαντικότητας 1% είναι θετικά συσχετισμένα με τον ανταγωνισμό. Επίσης οι εισπρακτέοι λογαριασμοί σε επίπεδο σημαντικότητας 10% έχουν ισχυρή σχέση με τον ανταγωνισμό. Όταν μια εταιρία έχει υψηλή ρευστότητα μπορεί εύκολα να καλύψει τα χρέη της αλλά έχει και την δυνατότητα επένδυσης για την εξέλιξη της επιχείρησης. Όσο αφορά την πρόβλεψη του ανταγωνισμού χρησιμοποιήθηκε ο αλγόριθμος οπισθοδρομικής διάδοσης και όχι η γραμμική παλινδρόμηση γιατί μεταξύ ανταγωνισμού και κεφαλαίου κίνησης υπάρχουν μη γραμμικές σχέσεις. Τα αποτελέσματα πρόβλεψης με τον BP έδειξαν ότι το συνολικό αποτέλεσμα της πρόβλεψης είναι καλό.

ΚΕΦΑΛΑΙΟ 3^ο

ΤΕΧΝΗΤΗ ΝΟΗΜΟΣΥΝΗ

3.1 Εισαγωγή στην Τεχνητή Νοημοσύνη

Από την αρχαιότητα ήδη ο άνθρωπος προσπαθεί να κατανοήσει τον τρόπο με τον οποίο σκέφτεται και πράττει καθώς και τα αποτελέσματα των πράξεων του. Σε αυτό στηρίζεται και η επιστήμη της Τεχνητής Νοημοσύνης η οποία σύμφωνα με τους Russell και Norvig (2005) επιχειρεί όχι μόνο να κατανοήσει αλλά και να κατασκευάσει νοήμονες οντότητες.

Η Τεχνητή Νοημοσύνη αποτελεί μια από τις πιο πρόσφατες τεχνολογίες με τον όρο να εμφανίζεται το 1956. Η Τεχνητή Νοημοσύνη μπορεί να συμβάλει στην μάθηση, στην αντίληψη, στην απόδειξη μαθηματικών θεωρημάτων ουσιαστικά σε οτιδήποτε μπορεί να φανταστεί ο ανθρώπινος νους.

3.2 Τι είναι η Τεχνητή Νοημοσύνη

Η ακριβής ορολογία της Τεχνητής Νοημοσύνης σε αντίθεση με άλλες ορολογίες δεν έχει μια ακριβή διατύπωση. Αρκετοί επιστήμονες έχουν διατυπώσει τον δικό τους ορισμό. Σύμφωνα με τους Barr και Feigenbaum η Τεχνητή Νοημοσύνη είναι ο τομέας της επιστήμης των υπολογιστών που ασχολείται με τη σχεδίαση ευφών υπολογιστικών συστημάτων, δηλαδή συστημάτων που επιδεικνύουν χαρακτηριστικά που σχετίζουμε με την νοημοσύνη στην ανθρώπινη συμπεριφορά. Ένας πιο περιεκτικός ορισμός είναι αυτός του J.McCarthy κατά τον οποίο Τεχνητή Νοημοσύνη είναι η επιστήμη και μεθοδολογία της δημιουργίας νοούντων μηχανών.

3.3 Ιστορική εξέλιξη της Τεχνητής Νοημοσύνης

Το 1943 θεωρείται η χρονιά που δημοσιεύθηκε η πρώτη εργασία που αφορούσε την Τεχνητή Νοημοσύνη από τους Warren McCulloch και Walter Pitts, οι οποίοι πρότειναν ένα μοντέλο τεχνητών νευρώνων με δύο δυνατές καταστάσεις. Ενεργός ή ανενεργός νευρώνας ανάλογα με το ερέθισμα που δέχεται ο νευρώνας από τους γειτονικούς νευρώνες και έτσι μεταβαίνει στην αντίστοιχη κατάσταση. Το 1950, ο μαθηματικός Alan Turing, προτείνει τη δοκιμή Turing. Μια απλή δοκιμασία που θα μπορούσε να εξακριβώσει εάν μια μηχανή διαθέτει ευφυΐα. Η δοκιμή Turing διατυπώθηκε στο άρθρο “Computing Machinery and Intelligence”. Λίγο αργότερα το 1956 παρουσιάστηκε το πρόγραμμα Logic Theorist (LT) το οποίο στηριζόταν σε κανόνες της λογικής και σε ευρετικούς αλγορίθμους αναζήτησης για να επιλύει μαθηματικά προβλήματα.

Οι επόμενες σημαντικές στιγμές ήταν το 1958 όπου ο McCarthy ανέπτυξε την γλώσσα προγραμματισμού Lisp, η οποία έγινε η κυρίαρχη γλώσσα προγραμματισμού της Τεχνητής Νοημοσύνης. Την ίδια χρονιά αναπτύχθηκαν οι γενετικοί αλγόριθμοι και το 1962 ο Rosenblatt παρουσίασε το βελτιωμένο νευρωνικό δίκτυο perceptron. Στα τέλη της δεκαετίας του 1960 ξεκίνησε μια εποχή κρίσης για την Τεχνητή Νοημοσύνη καθώς μέχρι τότε τα εργαλεία της μπορούσαν να επιλύουν μόνο πολύ απλά προβλήματα. Ωστόσο από τα μέσα του 1970 η κατάσταση άρχισε να βελτιώνεται με την εμφάνιση των έμπειρων συστημάτων. Επίσης την ίδια περίοδο εμφανίστηκε και η γλώσσα προγραμματισμού Prolog.

Την δεκαετία του 1980 άρχισαν να αναπτύσσονται πιο ισχυρά προγράμματα με περισσότερες δυνατότητες όπως τα δίκτυα Hopfield. Από την δεκαετία του 1990 και μετά εξαιτίας της μεγάλης χρήσης του διαδικτύου άρχισαν να αναπτύσσονται οι ευφυείς πράκτορες. Ως πράκτορας από τους Russell και Norvig (2005) ορίζεται οτιδήποτε μπορεί να θεωρηθεί ότι αντιλαμβάνεται το περιβάλλον του μέσω αισθητήρων και επενεργεί σε αυτό το περιβάλλον μέσω μηχανισμών δράσης. Οι πράκτορες παρέχουν βοήθεια στους χρήστες ώστε να γίνουν κάποιες διαδικασίες όπως συλλογή ή ανάλυση τεράστιου όγκου δεδομένων. Οι ευφυΐες πράκτορες έχουν παίξει σημαντικό ρόλο στην Τεχνητή Νοημοσύνη και από πολλούς επιστήμονες η Τεχνητή Νοημοσύνη ορίζεται ως η επιστήμη που μελετά την σχεδίαση ευφυών πρακτόρων.

3.4 Εφαρμογές της Τεχνητής Νοημοσύνης

Η Τεχνητή Νοημοσύνη με την ανάπτυξη που έχει γνωρίσει δίνει πάρα πολλές δυνατότητες σε πολλούς διαφορετικούς τομείς. Παρακάτω παρουσιάζονται μερικές από τις πιο σημαντικές εφαρμογές της Τεχνητής Νοημοσύνης.

3.4.1 Έμπειρα Συστήματα

Σύμφωνα με τον Feigenbaum έμπειρο σύστημα είναι ένα έξυπνο πρόγραμμα το οποίο για να λύσει κάποιο πρόβλημα που είναι αρκετά δύσκολο και απαιτεί σημαντική εμπειρία για την επίλυσή του χρησιμοποιεί ειδική γνώση και διαδικασίες εξαγωγής συμπερασμάτων. Η γνώση που είναι απαραίτητη για την λειτουργία σε αυτό το επίπεδο μαζί με τις διαδικασίες εξαγωγής συμπερασμάτων μπορεί να θεωρηθούν σαν ένα μοντέλο εμπειρίας των καλύτερων ειδικών του χώρου.

Τα πρώτα έμπειρα συστήματα εμφανίστηκαν το 1970. Ένα έμπειρο σύστημα έχει την παρακάτω δομή. Αποτελείται από μια βάση γνώσης η οποία επικοινωνεί με μια μηχανή εξαγωγής συμπερασμάτων και από την άλλη πλευρά υπάρχει και ένα περιβάλλον διαλόγου (interface) ώστε να μπορεί να επικοινωνεί με τους χρήστες. Τα έμπειρα συστήματα προσφέρουν σημαντική ευελιξία καθώς μπορούν πολύ εύκολα να αναθεωρήσουν την γνώση που ήδη έχουν.

3.4.2 Ρομποτική

Ο όρος ρομποτική χρησιμοποιήθηκε για πρώτη φορά από τον Asimov (1950). Τα ρομποτ είναι ευφυείς πράκτορες που εκτελούν εργασίες με χειρισμούς του φυσικού κόσμου σύμφωνα με τους Russell και Norvig (2005). Η ρομποτική αποτελεί συνδυασμό πολλών επιστημών όπως της Πληροφορικής, της Μηχανολογίας, του Προγραμματισμού και της Τεχνητής Νοημοσύνης.

Η τεχνολογία της ρομποτικής βρίσκει εφαρμογή σε πεδία όπως της Βιομηχανίας, Γεωργίας, Μεταφοράς, Ιατρικής καθώς και σε πολλά άλλα πεδία.

3.4.3 Επίλυση Προβλημάτων

Ένα από τα πρώτα βήματα επίλυσης ενός προβλήματος αρχικά είναι η κατανόησή του και στην συνέχεια ο ορισμός του. Ένα πρόβλημα αποτελείται από μια αρχική κατάσταση, τις ενέργειες όπου μπορούμε να εκτελέσουμε και από την τελική επιθυμητή κατάσταση. Αυτή η διαδικασία ονομάζεται επίλυση προβλήματος και μπορεί να πραγματοποιηθεί με την χρήση πρακτόρων. Η επίλυση προβλημάτων αποτελούσε έναν από τους αρχικούς στόχους της Τεχνητής Νοημοσύνης.

Τα προβλήματα χωρίζονται σε δυο κατηγορίες σε απλά προβλήματα (toy problems) και σε πραγματικά προβλήματα (real world problems). Για την επίλυση των προβλημάτων πραγματοποιείται αναζήτηση στο χώρο καταστάσεων, μια από τις τεχνικές που χρησιμοποιείται είναι το δένδρο αναζήτησης (search tree). Για την αξιολόγηση ενός αλγορίθμου ως προς την απόδοση υπάρχουν τέσσερα κριτήρια η πληρότητα, η βέλτιστη συμπεριφορά, η χρονική πολυπλοκότητα και η χωρική πολυπλοκότητα.

3.4.4 Νευρωνικά Δίκτυα

Ως νευρωνικό δίκτυο ορίζεται σύμφωνα με τους Heksander και Morton (1990) ένας τεράστιος παράλληλος επεξεργαστής με κατανεμημένη αρχιτεκτονική, ο οποίος αποτελείται από απλές μονάδες επεξεργασίας και έχει από την φύση του τη δυνατότητα να αποθηκεύει εμπειρική γνώση και να την καθιστά διαθέσιμη για χρήση.

Μοιάζει με τον ανθρώπινο εγκέφαλο σε δυο σημεία. Πρώτον το δίκτυο προσλαμβάνει τη γνώση από το περιβάλλον του, μέσω μιας διαδικασίας μάθησης και δεύτερον η ισχύς των συνδέσεων μεταξύ νευρώνων, που αποκαλείται συναπτικό βάρος, χρησιμοποιείται για την αποθήκευση της γνώσης που αποκτείνεται. Με πιο απλά λόγια θα λέγαμε ότι ένα νευρωνικό δίκτυο είναι μηχανή προσομοίωσης της λειτουργίας του ανθρώπινου εγκεφάλου σύμφωνα με τον Haykin (2010).

Η δομή του τεχνητού νευρωνικού δικτύου προσπαθεί να μιμηθεί την δομή του βιολογικού νευρωνικού δικτύου. Έτσι, ένα τεχνητό νευρωνικό δίκτυο αποτελείται από ένα σύνολο νευρώνων που αλληλοεπιδρούν μεταξύ τους και ονομάζονται συνάψεις. Το νευρωνικό δίκτυο έχει την δυνατότητα να προσαρμόζεται ανάλογα με τις αλλαγές που γίνονται στο περιβάλλον του. Επομένως τα νευρωνικά δίκτυα είναι πολύ εύκολο να επαν-εκπαιδευτούν.

Ο κύριος στόχος χρήσης ενός τεχνητού νευρωνικού δικτύου είναι η επίλυση προβλημάτων για να γίνει όμως αυτό προηγούμενος το νευρωνικό δίκτυο θα πρέπει να εκπαιδευτεί. Η διαδικασία μέσω της οποίας επιτυγχάνεται η μάθηση σύμφωνα με τον Haykin (2010) αποκαλείται αλγόριθμος μάθησης και η λειτουργία του είναι να τροποποιεί τα συναπτικά βάρη του δικτύου με τον κατάλληλο τρόπο για την επίτευξη του επιθυμητού στόχου.

Τα νευρωνικά δίκτυα σήμερα χρησιμοποιούνται σε πολλά πεδία και βρίσκουν πολλές εφαρμογές για παράδειγμα στην Ιατρική (αναγνώριση και ανάλυση των ακτινών Χ, ανάλυση ομιλίας σε ακουστικά βαρηκοΐας κωφών ατόμων), σε Επιχειρήσεις (επιλογή κατάλληλου προσωπικού), στην Βιολογία (καλύτερη κατανόηση εγκεφάλου), στα Χρηματοοικονομικά (ανάλυση επικινδυνότητας δανείων, αξιολόγηση επενδύσεων, ανάλυση χαρτοφυλακίων, αναγνώριση πλαστογραφίας), στην Βιομηχανία (έλεγχος γραμμής παραγωγής, αυτοματοποίηση ρομπότ και συστημάτων ελέγχου).

3.4.5 Ευφυείς Πράκτορες

Ευφυής πράκτορας, στην Τεχνητή Νοημοσύνη, είναι μια οντότητα που αντιλαμβάνεται το περιβάλλον μέσω αισθητήρων και δρα στο περιβάλλον μέσω μηχανισμών δράσης. Σύμφωνα με τους Russell και Norvig (2005) κάθε πράκτορας αντιλαμβάνεται τις ενέργειες του αλλά όχι πάντα τις επιπτώσεις του. Υπάρχουν πολλά είδη πρακτόρων όπως άνθρωποι, ρομποτικοί, λογισμικοί. Η επιτυχία ενός πράκτορα εξαρτάται από την γνώση που έχει λάβει, από τις πράξεις που μπορεί να κάνει και από αυτά που έχει αντιληφθεί ο πράκτορας. Ο κύριος στόχος της Τεχνητής Νοημοσύνης είναι να δημιουργεί προγράμματα τα οποία όσο είναι να δυνατόν μπορούν να δίνουν ορθολογικά αποτελέσματα.

3.5 Τεχνητή Νοημοσύνη και Big Data

Χαρακτηριστικό της σημερινής εποχής είναι η συνεχής τεχνολογική ανάπτυξη και πρόοδος παράλληλα όμως και η αύξηση του όγκου των δεδομένων που συλλέγονται. Η σημασία των δεδομένων που συλλέγονται είναι πολύ σημαντική και έτσι όλο και περισσότερες τεχνολογίες όπως η τεχνητή νοημοσύνη και η μηχανική μάθηση ασχολούνται με αυτά. Τα δεδομένα μεγάλης κλίμακας ή αλλιώς Big Data απασχολούν όλο και ένα περισσότερο τους επιστήμονες. Είναι φανερό ότι είναι δύσκολη η διαχείριση όλων αυτών των πληροφοριών που προέρχονται από διαφορετικές πηγές αλλά εμφανίζονται σε πολλές διαφορετικές μορφές. Οι Chen et al. (2014) χαρακτήρισαν τα Big Data ως σύνολο δεδομένων τα οποία δεν μπορεί να αντιληφθεί και διαχειριστεί η παραδοσιακή πληροφορική και τα εργαλεία λογισμικού σε ανεκτό επίπεδο χρόνου.

Σύμφωνα με τους Khanduja et al. (2017) ο ορισμός που έχει επικρατήσει είναι του Gartner ο οποίος πρότεινε το μοντέλο των 3V. Σύμφωνα με αυτό το μοντέλο τα δεδομένα χαρακτηρίζονται από Όγκο (Volume), Ταχύτητα (Velocity) και Ποικιλία (Variety). Ο όρος όγκος αναφέρεται στο σύνολο των δεδομένων που πρέπει κάποιος να διαχειριστεί, ο όρος ταχύτητα αναφέρεται στην ταχύτητα με την οποία εισέρχονται τα νέα δεδομένα και με ο όρος ποικιλία αναφέρεται στον διαφορετικό τύπο δεδομένων.

Από τα παραπάνω γίνεται κατανοητό ότι το πεδίο των Big Data είναι διαφορετικό από αυτό της Τεχνητής Νοημοσύνης ωστόσο υπάρχει μια έντονη σχέση μεταξύ τους καθώς το ένα πεδίο συμπληρώνει το άλλο με σκοπό την ανάπτυξη τους. Η Τεχνητή Νοημοσύνη με τις εφαρμογές που διαθέτει βοηθάει στην επεξεργασία των δεδομένων και η πληθώρα αυτή των δεδομένων δίνει πολλές πληροφορίες με σκοπό την εξέλιξη των συστημάτων της Τεχνητής Νοημοσύνης αλλά και την ανάπτυξη νέων.

Σύμφωνα με τους Khanduja et al. (2017) τα δεδομένα αυξάνονται με εκθετικό ρυθμό έτσι δημιουργήθηκε η ανάγκη για την διαχείριση και την επεξεργασία τους με αποτέλεσμα την δημιουργία ενός νέου όρου αυτού της εξόρυξης δεδομένων (data mining). Η εξόρυξη των δεδομένων είναι η διαδικασία εύρεσης πληροφοριών από μεγάλες βάσεις δεδομένων με την χρήση κατάλληλων αλγορίθμων. Για την εξόρυξη

δεδομένων χρησιμοποιούνται επίσης τεχνικές της Τεχνητής Νοημοσύνης και της Στατιστικής.

Όπως αναφέρθηκε παραπάνω η Τεχνητή Νοημοσύνη βρίσκει εφαρμογή σε πολλά πεδία έτσι αν συνδυαστούν και τα Big Data τα αποτελέσματα θα βελτιωθούν και οι χρήστες θα έχουν πιο ακριβή δεδομένα. Εφαρμόζοντας την Τεχνητή Νοημοσύνη στα μεγάλης κλίμακας δεδομένα είναι δυνατό να εντοπιστούν αστοχίες των δεδομένων, να γίνουν προβλέψεις και με την χρήση της Τεχνητής Νοημοσύνης να εντοπιστούν επαναλαμβανόμενα μοτίβα που ο άνθρωπος δεν μπορεί. Ένα ακόμη σημαντικό θέμα είναι η αξιοπιστία και η ποιότητα των δεδομένων. Εάν δεν είναι αξιόπιστα οι πληροφορίες δεν έχουν κανένα νόημα. Το πρόβλημα αυτό μπορεί να λυθεί με τεχνικές της μηχανικής μάθησης η οποία μπορεί να εντοπίζει διπλές καταχωρήσεις, κενές καταχωρήσεις και να κανονικοποιεί τα δεδομένα με την χρήση αλγορίθμων.

Ο σκοπός του συνδυασμού της Τεχνητής Νοημοσύνης και των Big Data είναι να βοηθήσει τον άνθρωπο και να απλοποιήσει κάποιες εργασίες. Για παράδειγμα πολλοί ερευνητές έχουν στραφεί χρησιμοποιώντας την Τεχνητή Νοημοσύνη στην δημιουργία εφαρμογών που θα αναλύουν μη δομημένα δεδομένα όπως την φήμη μιας εταιρείας, στοιχεία των χρηματοοικονομικών καταστάσεων και θα κατηγοριοποιούν τα δεδομένα ώστε να είναι άμεσα αξιοποιήσιμα από τους χρήστες.

ΚΕΦΑΛΑΙΟ 4^ο

ΤΕΧΝΗΤΗ ΝΟΗΜΟΣΥΝΗ ΚΑΙ ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ

4.1 Εισαγωγή

Με την Τεχνητή Νοημοσύνη δόθηκε η δυνατότητα δημιουργίας «έξυπνων μηχανών» οι οποίες θα μπορούν να μαθαίνουν, να σκέφτονται και μιμούνται τις ενέργειες των ανθρώπων.

Όπως αναφέρθηκε και παραπάνω η Τεχνητή Νοημοσύνη ήδη από τα τέλη του 1970 έκανε αισθητή την παρουσία της στον χώρο και ότι μπορεί να μας δώσει πολλές ευκαιρίες ώστε να βελτιωθούν κάποιες διαδικασίες. Η Τεχνητή Νοημοσύνη μπορεί να βρει εφαρμογή και να βελτιώσει πολλούς κλάδους ένας από τους είναι και ο κλάδος της επιχειρηματικότητας. Με τις εφαρμογές της Τεχνητής Νοημοσύνης για παράδειγμα οι χρήστες θα μπορούν να παίρνουν πιο εύκολα αποφάσεις για σημαντικά ζητήματα, να αναγνωρίζονται επαναλαμβανόμενα επιχειρηματικά μοτίβα, να εντοπίζονται απάτες, να γίνονται προβλέψεις και αναλύονται χρηματοοικονομικές καταστάσεις.

4.2 Διαχείριση Εφοδιαστικής Αλυσίδας

Με βάση τα παραπάνω ένας τομέας που φαίνεται ότι μπορεί να εξελιχθεί σημαντικά είναι η Διαχείριση Εφοδιαστικής Αλυσίδας (Supply Chain Management) καθώς μπορεί να λύσει πολλά πρακτικά προβλήματα που υπάρχουν.

Σύμφωνα με τους Chopra και Meindl (2015) μια Εφοδιαστική Αλυσίδα αποτελείται από όλα εκείνα τα στάδια με σκοπό να εκπληρωθούν οι απαιτήσεις ενός πελάτη είτε άμεσα είτε έμμεσα. Οι λειτουργίες της Εφοδιαστικής Αλυσίδας αφορούν εκτός από την παραλαβή και την εκπλήρωση απαιτήσεων την ανάπτυξη νέων προϊόντων, την διαφήμιση, τη διανομή, τα οικονομικά και την εξυπηρέτηση των

πελατών. Η Εφοδιαστική Αλυσίδα συνδέεται άμεσα με την συνεχή ροή πληροφοριών, προϊόντων και κεφαλαίων μεταξύ διαφορετικών τμημάτων. Οι αποφάσεις σχεδιασμού, προγραμματισμού και λειτουργίας σύμφωνα με τους Chopra και Meindl (2015) παίζουν σημαντικό ρόλο στην επιτυχία ή στην αποτυχία μιας εταιρείας. Για να παραμείνουν ανταγωνιστικές, η Εφοδιαστική Αλυσίδα πρέπει να προσαρμόζεται στις νέες τεχνολογίες και προσδοκίες των πελατών. Έτσι προκύπτει το συμπέρασμα ότι η Τεχνητή Νοημοσύνη μπορεί να συμβάλλει σημαντικά για την επιτυχία μιας εταιρείας. Για παράδειγμα μια από τις πρώτες εφαρμογές της Τεχνητής Νοημοσύνης στον τομέα του εφοδιασμού αναπτύχθηκε το 1991 όπου την χρησιμοποίησαν οι Αμερικάνικες Δυνάμεις στην κρίση στον Περσικό κόλπο. Η εφαρμογή αυτή ήταν ένα εργαλείο δυναμικής ανάλυσης και επανασχεδιασμού (Dynamic Analysis and Replanning Tool, DART) το οποίο έκανα αυτοματοποιημένο σχεδιασμό του εφοδιασμού και χρονοπρογραμματισμού των μεταφορών. Χάρη στην Τεχνητή Νοημοσύνη το πλάνο παραγόταν μέσα σε λίγες ώρες ενώ με τις κλασικές μεθόδους θα χρειαζόντουσαν εβδομάδες.

Η εποχή μας χαρακτηρίζεται από υψηλές απαιτήσεις αλλά παράλληλα και από υψηλή αβεβαιότητα, υψηλότερο εφοδιαστικό κίνδυνο και υψηλότερο ανταγωνισμό. Οι εφοδιαστικές αλυσίδες ασχολούνται επίσης με την απογραφή, με την διαχείριση αποθεμάτων, μεταφορά εξοπλισμού. Λειτουργίες οι οποίες για να πετύχουν σύμφωνα με τον Hokey (2010) χρειάζονται πολλά δεδομένα και πληροφορίες. Η Τεχνητή Νοημοσύνη μπορεί να βοηθήσει στην καλύτερη διαχείριση των πληροφοριών αλλά και στην λήψη αποφάσεων. Η Kodak για παράδειγμα ανέπτυξε ένα ευφυή σύστημα για την επιλογή της βέλτιστης διαδρομής παραλαβής μιας παραγγελίας από την αποθήκη.

Γενικά διάφορες τεχνικές έχουν χρησιμοποιηθεί σύμφωνα με τον Hokey (2010) για να βελτιωθούν οι λειτουργίες της Εφοδιαστικής Αλυσίδας. Ο Hokey (2010) αναφέρει ότι τα ευφυή συστήματα μπορούν να βοηθήσουν στον έλεγχο και διαχείριση αποθεμάτων και αναφέρεται σε ένα έξυπνο το οποίο ονομάστηκε Inventory Management Assistant (IMA) και αναπτύχθηκε από τον Allen το 1986 το οποίο έκαναν χρήση οι Αμερικανικές Αεροπορικές Δυνάμεις. Το σύστημα αυτό βελτίωσε την διαχείριση των αποθεμάτων από 8 έως 18% μειώνοντας τα λάθη που γινόντουσαν. Επίσης οι εφαρμογές της Τεχνητής Νοημοσύνης έχουν σημειώσει μεγάλη επιτυχία στον σχεδιασμό δικτύων μεταφοράς με την χρήση γενετικών αλγορίθμων.

Ένα ακόμη σημαντικό ζήτημα το οποίο πρέπει να χειριστεί μια εφοδιαστική αλυσίδα είναι η διαχείριση των αγορών και των προμηθευτών. Πολλοί ερευνητές έχουν

σχεδιάσει διάφορα συστήματα όπου συμβάλλουν στην καλύτερη διαχείριση. Κυρίως τα συστήματα που στηρίζονται σε πράκτορες (agent based systems) μπορούν να βοηθήσουν στην διαχείριση παρέχοντας στους χρήστες μια σειρά από στρατηγικές αποφάσεις. Επιπλέον για τις εταιρείες πολύ χρήσιμες είναι οι πληροφορίες που σχετίζονται με την μελλοντική ζήτηση των προϊόντων. Τεχνικές που στηρίζονται σε πράκτορες και γενετικούς αλγορίθμους μπορούν να κάνουν τις μελλοντικές προβλέψεις ζήτησης πιο ακριβής. Οι προβλέψεις αυτές μπορούν να αφορούν νέα και παλιά προϊόντα ή και προβλέψεις για νέα, καινοτόμα προϊόντα που ακόμη δεν κυκλοφορούν στην αγορά και δεν έχουμε ιστορικό δεδομένων.

Τέλος, είναι γνωστό ότι τα διάφορα τμήματα μιας Εφοδιαστικής Αλυσίδας διαμοιράζονται μεταξύ τους πληροφορίες όπως προβλέψεις ζήτησης, διανομές προϊόντων κλπ. Με τεχνικές όπως η Εξόρυξη Δεδομένων μπορεί να γίνει πιο αποτελεσματική η ταξινόμηση, η ανάλυση των πληροφοριών αλλά και να δημιουργηθούν προφίλ πελατών, προμηθευτών, τάσεις πωλήσεων, εξόδων, εσόδων. Η εξόρυξη δεδομένων έχει βοηθήσει εταιρείες όπως την Amazon και το e-Bay.

4.3 Ταμειακές Ροές

Ένα από τα πιο σημαντικά κομμάτια μιας χρηματοοικονομικής ανάλυσης είναι οι ταμειακές ροές. Οι ταμειακές ροές έχουν ζωτική σημασία για μια επιχείρηση καθώς τα μετρητά είναι απαραίτητα για την λειτουργία της. Οι ταμειακές ροές σχετίζονται με την κερδοφορία και με την απόδοση μιας επιχείρησης. Ανεπάρκεια στις ταμειακές ροές μπορεί να οδηγήσει μέχρι και την χρεοκοπία. Επομένως η βιωσιμότητα μιας επιχείρησης εξαρτάται από την σωστή διαχείριση των ταμειακών ροών και κατά επέκταση στις προβλέψεις των ταμειακών ροών έτσι ώστε να επιτευχθεί ο κατάλληλος οικονομικός προγραμματισμός.

Με την ύπαρξη ενός συστήματος προβλέψεων μια επιχείρηση θα μπορεί να προβλέψει για παράδειγμα αν οι πωλήσεις ή τα έσοδα επαρκούν για να εκπληρώσει τις υποχρεώσεις της, ένας μελλοντικός επενδυτής θα μπορεί να πάρει πιο εύκολα επενδυτικές αποφάσεις και ακόμη τα χρηματοπιστωτικά ιδρύματα μπορούν να χρησιμοποιήσουν αυτά τα συστήματα για την λήψη αποφάσεων που έχουν να κάνουν με την χορήγηση δανείων σύμφωνα με τους Hongjiu et al. (2012).

Ωστόσο κάπου εδώ τίθεται το ερώτημα για το πιο σύστημα πρόβλεψης είναι το πιο αποδοτικό. Έχουν αναπτυχθεί πολλοί μέθοδοι, τόσο με τις παραδοσιακές τεχνικές όσο και με την χρήση της Τεχνητής Νοημοσύνης. Πολλοί είναι οι ερευνητές που έχουν χρησιμοποιήσει εφαρμογές της Τεχνητής Νοημοσύνης για να πετύχουν τους στόχους τους. Οι Hongjiu et al. (2012) στην βιβλιογραφική τους επισκόπηση αναφέρουν τους Chua et al. (1997) οι οποίοι χρησιμοποίησαν ένα Νευρωνικό Δίκτυο για να αξιολογήσουν την απόδοση προϋπολογισμών, τους Lowe et al. (1993) οι οποίοι χρησιμοποίησαν ευφυή συστήματα ώστε οι χρήστες να μπορούν να διαχειρίζονται τις ταμειακές ροές και τους Lokmic και Smith (2000) οι οποίοι χρησιμοποίησαν τις μεθόδους οπισθοδιάδοσης για να προβλέψουν τις ταμειακές ροές.

4.4 Προβλέψεις Τιμών Χρηματιστηρίου

Ένα από τα πιο σημαντικά ζητήματα που απασχολούν τους μελλοντικούς επενδυτές και χρηματιστές είναι η πρόβλεψη τιμών των μετοχών του χρηματιστηρίου. Οι μετοχές που διαπραγματεύονται στο χρηματιστήριο επηρεάζονται από διάφορους παράγοντες, ποιοτικούς και ποσοτικούς, με αποτέλεσμα να δημιουργούνται δυσκολίες στις προβλέψεις. Οι παράγοντες αυτοί μπορεί να είναι η οικονομική κατάσταση της χώρας, ο πληθωρισμός, η φορολογία, τα επιτόκια, οι ισοτιμίες νομισμάτων, η πολιτική κατάσταση της χώρας, η παραπληροφόρησης του κοινού, τα διεθνή γεγονότα.

Στο παρελθόν οι επενδυτές με βάση την προσωπική τους εμπειρία έκαναν τις επιλογές τους σήμερα όμως εξαιτίας της ανάπτυξης των αγορών και του μεγάλου όγκου συναλλαγών αυτό είναι αδύνατο. Αυτό οδήγησε όλο και περισσότερους ερευνητές να ασχοληθούν με αυτό το πρόβλημα με την χρήση διάφορων τεχνικών όπως εφαρμογές της Στατιστικής αλλά και της Τεχνητής Νοημοσύνης.

Οι Strader et al. (2020) κατέληξαν ότι για πρόβλεψη αριθμοδεικτών του χρηματιστηρίου η καλύτερη τεχνική είναι τα Νευρωνικά Δίκτυα και ότι με την χρήση μηχανών διανυσμάτων υποστήριξης (Support Vector Machines) μπορεί να προσδιοριστεί αποτελεσματικά εάν ο συνολικός δείκτης του χρηματιστηρίου θα αυξηθεί ή θα μειωθεί. Επίσης με τους γενετικούς αλγορίθμους μπορούμε να πάρουμε αποφάσεις που έχουν να κάνουν με ποιες μετοχές να συμπεριλάβουμε στο χαρτοφυλάκιο, οι οποίες θα έχουν την καλύτερη απόδοση.

Οι Egeli, Ozturan et al. (2003) στην έρευνα τους κατέληξαν επίσης ότι οι προβλέψεις με την χρήση των Νευρωνικών Δικτύων είναι πιο ακριβής σε σύγκριση με την μέθοδο των κινητών μέσων και ότι μεταξύ των διάφορων Νευρωνικών Δικτύων το καταλληλότερο δίκτυο είναι το Generalized feed-forward (GFF).

Οι Torres και Alvarez (2019) χρησιμοποίησαν το λογισμικό WEKA (Waikato Environment for Knowledge Analysis) το οποίο αναπτύχθηκε στο Πανεπιστήμιο Waikato της Νέας Ζηλανδίας. Το WEKA αποτελείται από ένα σύνολο αλγορίθμων μάθησης και εργαλείων για ανάλυση δεδομένων και για προβλέψεις. Οι ερευνητές κατέληξαν ότι το WEKA είναι πολύ χρήσιμο εργαλείο για πρόβλεψη των μελλοντικών τιμών του χρηματιστηρίου.

Οι περισσότεροι ερευνητές καταλήγουν στο συμπέρασμα ότι υπάρχουν πολλά πλεονεκτήματα από την χρήση της Τεχνητής Νοημοσύνης για τις προβλέψεις δεικτών του χρηματιστηρίου καθώς πλέον με τις νέες τεχνικές μπορούμε να διαχειριστούμε πιο αποτελεσματικά τα δεδομένα ωστόσο ο Zekic (1998) τονίζει ότι υπάρχουν και κάποιοι περιορισμοί όπως ότι δεν υπάρχει ακόμη πλήρης αξιοπιστία των εφαρμογών και ότι για κάθε πρόβλημα δεν είναι γνωστό ποια μέθοδο πρέπει να επιλεγεί. Τους περιορισμούς αυτούς τους θέτει ως θέμα για μελλοντική έρευνα. Η εύρεση της κατάλληλης μεθόδου αποτελεί μια από τις μεγαλύτερες προκλήσεις για τους σημερινούς ερευνητές.

4.5 Ελεγκτική

Η Ελεγκτική αποτελεί έναν από τους πιο σημαντικούς κλάδους της Λογιστικής. Η ελεγκτική (Νεγκακής και Ταχυνάκης, 2017) ασχολείται με την διατύπωση αρχών και κανόνων που αφορούν την ομαλή διεξαγωγή οικονομικών ελέγχων. Αντικείμενο της συνιστά ο έλεγχος των διαδικασιών και των μεθόδων που εφαρμόστηκαν από την οικονομική μονάδα κατά την διάρκεια του διαχειριστικού έτους και διενεργείται από πρόσωπα ανεξάρτητα προς την οικονομική μονάδα.

Εξαιτίας της συνεχόμενης τεχνολογικής ανάπτυξης είναι αναμενόμενο ότι νέες τεχνολογίες όπως αυτή της Τεχνητής Νοημοσύνης έχουν την ικανότητα να επηρεάσουν την επιστήμη της Λογιστικής και κατ' επέκταση και την Ελεγκτική. Ένας από τους βασικούς παράγοντες ώστε να επιτευχθούν τα καλύτερα δυνατά αποτελέσματα είναι η

εκπαίδευση του ανθρωπίνου δυναμικού στον τομέα της πληροφορικής τεχνολογίας. Οι νέοι ελεγκτές κατά την διάρκεια των σπουδών τους είναι απαραίτητο να ενημερώνονται και να εκπαιδεύονται για τις νέες τεχνολογίες, εκτός από τις γνώσεις την Λογιστικής, οι οποίες μπορούν να συνδυαστούν με τον κλάδο της Ελεγκτικής όπως τονίζουν στην εργασία τους οι Wang και Lin (2020).

Με την χρήση της Τεχνητής Νοημοσύνης βελτιώνεται η παραγωγικότητα, έχουμε υψηλότερο βαθμό ακρίβειας, άμεση πρόσβαση σε δεδομένα. Δεν είναι τυχαίο ότι πολλές μεγάλες βιομηχανικές και ελεγκτικές εταιρείες (Google, Microsoft, Inc., KPMG, Deloitte, EY) έχουν επενδύσει μεγάλα ποσά για να αναβαθμίσουν τις τεχνικές τους με την χρήση Τεχνητής Νοημοσύνης. Ο υπεύθυνος καινοτομίας της Deloitte θεωρεί πως με την χρήση της Τεχνητής Νοημοσύνης η διαδικασία της ελεγκτικής θα γίνει εξυπνότερη, πιο αποτελεσματική και πιο διορατική. Προφανώς η Τεχνητή Νοημοσύνη δεν θα αντικαταστήσει το ανθρώπινο έργο αλλά θα βελτιώσει την ποιότητα του έργου του ελεγκτή.

Η Τεχνητή Νοημοσύνη και η Μηχανική Μάθηση μπορούν να προσθέσουν αξία στο έργο του λογιστή. Από την παραγωγή χρήσιμων στοιχείων για την λήψη αποφάσεων έως την ανίχνευση απάτης, την εκτίμηση κινδύνων, την κατανόηση θεμάτων φορολογίας, την αποτελεσματικότητα του ελέγχου και την αποτελεσματικότερη ανάλυση χρηματοοικονομικών και μη πληροφοριών. Για να πραγματοποιηθούν όλα αυτά είναι απαραίτητη ωστόσο η ύπαρξη καταρτισμένων και έμπειρων επιστημόνων καθώς σε αντίθεση με την μηχανές αυτοί είναι που διαθέτουν την “κοινή λογική”.

Πιο συγκεκριμένα η Τεχνητή Νοημοσύνη μπορεί να βοηθήσει στις παρακάτω ελεγκτικές διαδικασίες και να τις μετατρέψει σε διαδικασίες υψηλής απόδοσης σύμφωνα με τους Issa, Sun και Vasarhelyi (2017) οι οποίοι πρότειναν τον παρακάτω σχεδιασμό:

1. *Φάση Προγραμματισμού (Pre-Planning Plan)*: Στην φάση αυτή περιλαμβάνεται η απόκτηση στοιχείων για τους πελάτες και για τις εταιρείες τους. Η Τεχνητή Νοημοσύνη συλλέγει μεγάλα δεδομένα από πολλές διαφορετικές πηγές. Στην συνέχεια η Τεχνητή Νοημοσύνη θα αναγνωρίσει τις οργανωτικές δομές του πελάτη και τις λειτουργικές μεθόδους καθώς και τα λογιστικά και οικονομικά συστήματα τους. Τέλος, η Τεχνητή Νοημοσύνη θα εκτιμήσει τον αρχικό κίνδυνο που σχετίζεται με τον πελάτη.

2. *Συμβατική Φάση (Contracting Phase)*: Χρησιμοποιώντας τα αποτελέσματα της προηγούμενης φάσης η Τεχνητή Νοημοσύνη θα εκτιμήσει τις ώρες και τους φόρους που απαιτούνται για την συνεργασία και στην συνέχεια δημιουργείται το συμβόλαιο το οποίο το υπογράφουν ο ελεγκτής και ο πελάτης.
3. *Κατανόηση Εσωτερικού Ελέγχου και προσδιορισμός παραγόντων κινδύνου (Understanding Internal Controls and Identifying Risk Factors)*: Στην φάση αυτή γίνεται σχεδιασμός όλων των πτυχών της δέσμευσης ελέγχου. Χρησιμοποιώντας τεχνικές εξόρυξης διεργασιών και αναγνώρισης κειμένου η Τεχνητή Νοημοσύνη αναλύει τα δεδομένα που παρέχονται από τους πελάτες. Επίσης, η Τεχνητή Νοημοσύνη χρησιμοποιεί μεθόδους αναγνώρισης και απεικόνισης μοτίβων για τον εντοπισμό λαθών. Τέλος, όλες αυτές οι πληροφορίες εξετάζονται με σκοπό τον εντοπισμό απατών και παράνομων πράξεων.
4. *Εκτίμηση Κινδύνου Ελέγχου (Control Risk Assessment)*: Στην φάση αυτή περιλαμβάνεται ο σχεδιασμός του συστήματος εσωτερικού ελέγχου και η εφαρμογή του. Το σύστημα στηρίζεται στην Τεχνητή Νοημοσύνη και εξετάζει συνεχώς τον πλήρη αριθμό αρχείων για να εντοπίσει απάτες και να τις αναφέρει εάν υπάρχουν. Επιπλέον, η Τεχνητή Νοημοσύνη εφαρμόζει εξόρυξη διεργασιών σε όλο τον πληθυσμό των αρχείων ώστε να διασφαλίσει ότι το σύστημα εσωτερικού ελέγχου έχει σχεδιαστεί και λειτουργεί σωστά. Οι εγγραφές παράγονται αυτόματα ώστε να διασφαλίζεται η αξιοπιστία των δεδομένων.
5. *Δοκιμές (Substantive Tests)*: Η διαφορά μεταξύ ενός παραδοσιακού ελέγχου με έναν έλεγχο που στηρίζεται σε Τεχνητή Νοημοσύνη είναι ξεκάθαρος σε αυτή την φάση. Η προέλευση και η ποιότητα των δεδομένων εξετάζονται άμεσα κατά την συλλογή τους. Η Τεχνητή Νοημοσύνη μπορεί να εξετάζει το σύνολο των δεδομένων σε συνεχή βάση, με τον τρόπο αυτό μειώνεται η πιθανότητα μη εντοπισμού σφάλματος και ο χρόνος εντοπισμού σφάλματος.
6. *Αξιολόγηση των δεδομένων (Evaluation of Evidence)*: Η φάση αυτή συμπεριλαμβάνεται στην προηγούμενη φάση, με σκοπό την διασφάλιση της ποιότητας των δεδομένων πριν από την διεξαγωγή των δοκιμών.
7. *Έκθεση Ελέγχου (Audit Report)*: Η φάση αυτή αποτελεί το τελικό βήμα στην διαδικασία ελέγχου στην οποία εξετάζονται τα αποτελέσματα των προηγούμενων φάσεων με αποτέλεσμα να εξαχθεί το τελικό συμπέρασμα. Το

συμπέρασμα του ελεγκτή, σύμφωνα με τους παραδοσιακούς ελέγχους είναι μια κατηγορηματική γνώμη (μη διαφοροποιημένη γνώμη, με επιφύλαξη, αρνητική γνώμη και αδυναμία έκφρασης γνώμης) προς την εταιρία του πελάτη.

Όπως αναφέρθηκε και παραπάνω πολλές ελεγκτικές εταιρίες επενδύουν στις νέες τεχνολογίες. Ένα έργο που αναπτύχθηκε από την KPMG είναι το KPMG Ignite, μια πλατφόρμα εκπαίδευσης των συστημάτων με σκοπό να διενεργούνται προβλέψεις και να παίρνονται αποφάσεις. Πιο συγκεκριμένα, η πλατφόρμα μπορεί να αναλύσει μεγάλο όγκο δεδομένων, να εξάγει συμπεράσματα, να χρησιμοποιεί τεχνικές επεξεργασίας φυσικής γλώσσας ώστε να εξάγει συμπεράσματα, να δημιουργεί εικονικούς βοηθούς ώστε να βελτιωθεί η εξυπηρέτηση των πελατών. Η KPMG παρουσίασε μια μελέτη περίπτωσης που αφορούσε την βελτιστοποίηση των προβλέψεων απόδοσης καταστημάτων εταιρείας λιανικής και προέκυψε ότι με την χρήση τους KPMG Ignite οι εκτιμήσεις του πελάτη βελτιώθηκαν κατά 200% σε σχέση με την παλαιότερη προσέγγιση.

Ένα ακόμη παράδειγμα αποτελεί το σύστημα που αναπτύχθηκε στην Γαλλία που αποτελεί μέρος του ελεγκτικού μηχανισμού για την αποκάλυψη υποθέσεων φοροδιαφυγής. Η πλατφόρμα αναπτύχθηκε από το Υπουργείο Οικονομίας και την Γαλλική φορολογική υπηρεσία. Επενδύθηκαν περίπου 20 εκατομμύρια ευρώ και το έργο αυτό ονομάζεται “Mission requêtes et valorisation” (MRV). Το MRV βασίζεται σε λογισμικό Τεχνητής Νοημοσύνης και στοχεύει στον εντοπισμό αματιών και αποστέλλει ανά τρίμηνο στα αρμόδια τμήματα ελέγχου έναν όγκο φακέλων που καθορίζεται από τους στόχους ελεγκτών που έχουν τεθεί από την υπηρεσία. Καλύπτει τα περισσότερα φορολογικά αντικείμενα και η διαδικασία συνεχούς εκμάθησης του επιτρέπει να παρέχει, για κάθε φορολογούμενο φυσικό ή νομικό πρόσωπο, μια κίνηση που δείχνει το μέγεθος κινδύνου φορολογικού παραβάσεων. Με τους πρώτους ελέγχους που πραγματοποιήθηκαν έγινε ανάκτηση 250 εκατομμυρίων ευρώ από φόρους και 59 εκατομμυρίων ευρώ από πρόστιμα.

Από όλα τα παραπάνω καταλήγουμε στο συμπέρασμα ότι η Τεχνητή Νοημοσύνη είναι ικανή να αλλάξει τον κλάδο της Ελεγκτικής. Φυσικά η Τεχνητή Νοημοσύνη δεν έρχεται να αντικαταστήσει τον ελεγκτή αλλά να ενισχύσει την ποιότητα του έργου του με αποτέλεσμα ο ελεγκτής να έχει τον χρόνο να ασχοληθεί με ειδικά ζητήματα τα οποία απαιτούν την κρίση και την εμπειρία του.

ΚΕΦΑΛΑΙΟ 5^ο

ΤΕΧΝΗΤΗ ΝΟΗΜΟΣΥΝΗ ΚΑΙ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Η Μηχανική Μάθηση (Machine Learning) είναι ένας κλάδος της Τεχνητής Νοημοσύνης. Η Μηχανική Μάθηση ασχολείται με την μελέτη και κατασκευή αλγορίθμων οι οποίοι μαθαίνουν από τα δεδομένα και πραγματοποιούν προβλέψεις σχετικά με αυτά. Οι ερευνητές με την χρήση των μοντέλων που αναπτύσσουν μπορούν να καταλήξουν σε σημαντικά συμπεράσματα και να ανακαλύψουν τις σχέσεις που υπάρχουν μεταξύ των δεδομένων. Ο Mitchell (1997) πρότεινε έναν ορισμό ο οποίος χρησιμοποιείται ευρέως «Ένα πρόγραμμα υπολογιστή θεωρείται ότι μαθαίνει από την εμπειρία E σε σχέση με μια κατηγορία εργασιών T και μια μετρική απόδοσης P , αν η απόδοση του σε εργασίες T , όπως μετριούνται από την P , βελτιώνονται με την εμπειρία E ».

Η Μηχανική Μάθηση ανάλογα με τον τρόπο μάθησης χωρίζεται σε δύο κατηγορίες. Αυτές είναι:

- Επιβλεπόμενη Μάθηση, είναι η μάθηση στην οποία το μοντέλο εκπαιδεύετε χρησιμοποιώντας γνωστά χαρακτηριστικά, δηλαδή για μερικά δεδομένα είναι γνωστή η σωστή απάντηση, επομένως υπάρχει καθοδήγηση για την εκπαίδευση του μοντέλου
- Μη επιβλεπόμενη Μάθηση, είναι η μάθηση στην οποία χρησιμοποιούνται δεδομένα τα οποία δεν είναι γνωστά ή ταξινομημένα και έτσι ο αλγόριθμος χρησιμοποιεί τα δεδομένα αυτά χωρίς εκπαίδευση και πρέπει να ανακαλύψει μόνος του τυχόν μοτίβα.

Με την μηχανική μάθηση μπορούν να πραγματοποιηθούν προβλέψεις για διάφορα προβλήματα. Οι ερευνητές χωρίζουν τα προβλήματα σε προβλήματα ταξινόμησης (στόχος είναι η πρόβλεψη μια κατηγορικής μεταβλητής) και σε προβλήματα παλινδρόμησης (στόχος είναι η πρόβλεψη ενός πραγματικού αριθμού). Στην συνέχεια του κεφαλαίου θα παρουσιαστούν οι μέθοδοι που ανήκουν στις παραπάνω κατηγορίες όπως η Λογιστική Παλινδρόμηση, τα Νευρωνικά Δίκτυα, τα Δέντρα Αποφάσεων.

Το πρώτο βήμα είναι η εύρεση ενός αρχικού συνόλου δεδομένων το οποίο χωρίζεται σε δύο μέρη, στο σετ εκπαίδευσης (training data) και στο σετ ελέγχου

(testing data). Στο σετ εκπαίδευσης εφαρμόζονται οι τεχνικές της μηχανικής μάθησης που έχουν επιλεγθεί και εκπαιδεύεται το μοντέλο και στο σετ ελέγχου, το οποίο είναι ανεξάρτητο από το σετ εκπαίδευσης, αξιολογείται το μοντέλο. Ο βασικός στόχος του εκπαιδευμένου μοντέλου είναι να μπορεί να πραγματοποιεί προβλέψεις σε νέα δεδομένα. Με την ύπαρξη του σετ ελέγχου αποφεύγεται το φαινόμενο της υπερπροσαρμογής (overfitting) καθώς αν στηριζόμασταν στα αποτελέσματα του σετ εκπαίδευσης, τα νέα αποτελέσματα θα ταυτιζόντουσαν με τα δεδομένα που χρησιμοποιήθηκαν για την εκπαίδευση του μοντέλου. Επομένως τα δεδομένα που υπάρχουν στα δυο σετ πρέπει να είναι εντελώς ανεξάρτητα.

Ένα από τα πιο σημαντικά ζητήματα είναι η επιλογή της κατάλληλης μεθόδου, η οποία ταιριάζει περισσότερο στις ανάγκες του προβλήματός που εξετάζεται. Πολλές φορές η μέθοδος που επιλέγεται δίνει σωστά αποτελέσματα αλλά δεν δίνει την δυνατότητα να πραγματοποιηθούν αποτελεσματικές προβλέψεις. Πρέπει να λαμβάνεται υπόψιν το bias και το Variance του μοντέλου. Το ιδανικό μοντέλο έχει χαμηλό bias και χαμηλό variance και έτσι μπορεί να προβλέψει με ακρίβεια.

Ο διαχωρισμός των δεδομένων αρκετές φορές είναι αρκετά δύσκολος, δηλαδή πιο σύνολο δεδομένων θα αποτελεί το σετ εκπαίδευσης και πιο το σετ ελέγχου. Το Cross Validation αποτελεί ένα τρόπο διαχωρισμού των δεδομένων μας. Το Cross Validation χωρίζει το σύνολο των δεδομένων μας σε ισομερή τμήματα, n . Ως σετ εκπαίδευσης επιλέγει το $n-1$ και ως σετ ελέγχου το ένα μέρος που απέμεινε. Η διαδικασία αυτή επαναλαμβάνεται κυλιόμενα για όλα τα τμήματα και τέλος προσθέτει τα αποτελέσματα των επαναλήψεων.

Ωστόσο πως θα ληφθεί η απόφαση για το ποια μέθοδος είναι η βέλτιστη. Αυτό μπορεί να επιτευχθεί με την κατασκευή ενός πίνακα σύγχυσης (Confusion Matrix). Αρχικά τα δεδομένα χωρίζονται στο σετ εκπαίδευσης και στο σετ ελέγχου με την χρήση της τεχνικής του Cross Validation. Στην συνέχεια εκπαιδεύεται το σετ εκπαίδευσης με όλους τις μεθόδους που έχουν επιλεγθεί και ύστερα αξιολογείται η κάθε μέθοδος στο σετ ελέγχου. Τέλος, συνοψίζονται τα αποτελέσματα που προέκυψαν από το σετ ελέγχου για την κάθε μέθοδο σε έναν πίνακα (Confusion Matrix). Ένα παράδειγμα τέτοιου πίνακα είναι το παρακάτω:

Πίνακας 1 Πίνακας Σύγχυσης (Confusion Matrix)

	ΠΡΑΓΜΑΤΙΚΕΣ ΤΙΜΕΣ		
		ΕΙΝΑΙ ΥΠΕΡΒΑΡΟΣ	ΔΕΝ ΕΙΝΑΙ ΥΠΕΡΒΑΡΟΣ
<i>ΤΙΜΕΣ ΠΟΥ ΠΡΟΒΛΕΨΑΜΕ</i>	ΕΙΝΑΙ ΥΠΕΡΒΑΡΟΣ	TRUE POSITIVE	FALSE NEGATIVE
	ΔΕΝ ΕΙΝΑΙ ΥΠΕΡΒΑΡΟΣ	FALSE POSITIVE	TRUE NEGATIVE

- True Positive (TP)– Αληθής θετικές περιπτώσεις
Το μοντέλο πρόβλεψε true και όντως η πραγματική τιμή είναι true
- True Negative (TN) – Αληθής αρνητικές περιπτώσεις
Το μοντέλο πρόβλεψε false και όντως η πραγματική τιμή είναι false
- False Positive (FP) – Ψευδής θετικές περιπτώσεις
Το μοντέλο πρόβλεψε false και η πραγματική τιμή είναι true
- False Negative (FN) – Ψευδής αρνητικές περιπτώσεις
Το μοντέλο πρόβλεψε true και η πραγματική τιμή είναι false

Με την κατασκευή ενός Confusion Matrix ελέγχεται τι προέβλεψε σωστά και τι όχι ο αλγόριθμος. Έτσι, με την βοήθεια του Cross Validation και ενός Confusion Matrix μπορεί να πραγματοποιηθεί σύγκριση των μεθόδων ταξινόμησης και ποια από αυτές είναι η πιο αποτελεσματική.


Αρκετές φορές δεν είναι ξεκάθαρη η επιλογή της κατάλληλης μεθόδου, τότε χρησιμοποιούνται και κάποια άλλα κριτήρια, τις τιμές της ευαισθησίας (sensitivity), της εξειδίκευσης (specificity) και της ακρίβειας (precision) . Οι παραπάνω μετρικές δίνονται από τους παρακάτω τύπους:

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

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

$$Precision = \frac{TP}{TP + FP}$$

Μια ακόμη τεχνική αξιολόγησης της ταξινόμησης αλλά και γραφικής αναπαράστασης είναι η καμπύλη ROC (Receiver Operator Characteristic). Ο κάθετος άξονας απεικονίζει το ποσοστό των True Positive (TP) ή αλλιώς την τιμή της Ευαισθησίας (Sensitivity) και ο οριζόντιος άξονας το ποσοστό των False Positive (FP) ή αλλιώς την τιμή 1- Εξειδίκευση (specificity).




Διάγραμμα 1 Παράδειγμα καμπύλης ROC

Επίσης κάτι άλλο σημαντικό στις καμπύλες ROC είναι η περιοχή που βρίσκεται κάτω από την καμπύλη (Area under curve, AUC). Η περιοχή αυτή βοηθάει στην επιλογή της βέλτιστης καμπύλης ROC. Όσο μεγαλύτερο είναι το εμβαδόν κάτω από την καμπύλη ROC σε σύγκριση με μια άλλη καμπύλη ROC τόσο καλύτερα. Στο παραπάνω σχήμα παρατηρείται ότι η κίτρινη καμπύλη θα δώσει καλύτερες προβλέψεις σε σχέση με την μωβ καμπύλη. Γενικά όσο πιο ψηλά βρίσκεται η καμπύλη τόσο καλύτερα.

5.1 Λογιστική Παλινδρόμηση

Η Λογιστική Παλινδρόμηση (Logistic Regression) ανήκει στην κατηγορία της επιβλεπόμενης μάθησης και αποτελεί μέθοδο ταξινόμησης. Η Λογιστική Παλινδρόμηση δημιουργεί ένα μοντέλο ταξινόμησης με βάση την θεωρία των πιθανοτήτων σε περιπτώσεις δυαδικής μεταβλητής εξόδου. Είναι τεχνική που μπορεί να χρησιμοποιηθεί τόσο στον κλάδο της Στατιστικής όσο και στον κλάδο της Μηχανικής Μάθησης.

Η Λογιστική Παλινδρόμηση είναι παρόμοια με την γραμμική παλινδρόμηση, αλλά προβλέπει εάν κάτι είναι αληθές ή όχι και όχι συνεχείς τιμές. Για παράδειγμα προβλέπει εάν ένα email είναι ανεπιθύμητη αλληλογραφία ή όχι, εάν ένα άτομο είναι υπέρβαρο ή όχι. Η Λογιστική Παλινδρόμηση έχει την παρακάτω μορφή:



Διάγραμμα 2 Μορφή Λογιστικής Παλινδρόμησης

Η καμπύλη παίρνει τιμές από το 0 έως το 1, άρα εκφράζει την πιθανότητα να συμβεί ένα γεγονός ή όχι. Στην Λογιστική Παλινδρόμηση χρησιμοποιούνται συνεχή και διακριτά δεδομένα, γεγονός που την κάνει πολύ καλή μέθοδο.

Όπως αναφέρθηκε ο άξονας Y παίρνει τιμές από 0 έως 1 για να λυθεί αυτό το πρόβλημα ο άξονας Y μετατρέπεται σε άξονα που δείχνει τις τιμές των $\log(\text{odds}) = \log\left(\frac{p}{1-p}\right)$ και έτσι τώρα οι τιμές των μεταβλητών είναι στην μορφή $\log(\text{odds})$.

Για την εξαγωγή του συμπεράσματος εάν το μοντέλο που έχει προκύψει είναι αποτελεσματικό εξετάζονται οι τιμές των R^2 και του p -value. Οι τιμές αυτές αποτελούν μέτρα καλής προσαρμογής.

5.2 Δένδρο Απόφασης

Τα Δένδρα Αποφάσεων (Decision Tree) αποτελούν επίσης μέθοδο ταξινόμησης επιβλεπόμενης μάθησης. Ένα δένδρο απόφασης είναι ένας γράφος και αποτελείται από έναν αρχικό κόμβο (ρίζα), εσωτερικούς κόμβους και εξωτερικούς κόμβους (φύλλα). Κάθε κόμβος συνδέεται με έναν άλλον με κατευθυνόμενες ακμές. Σε κάθε ακμή αντιστοιχεί μια συνθήκη ελέγχου. Ένα δένδρο αποφάσεων λαμβάνει ως είσοδο ένα σύνολο χαρακτηριστικών και επιστρέφει μια απόφαση. Τα στοιχεία εισόδου μπορούν να είναι είτε διακριτές είτε συνεχή τιμές.

Ένα από τα πιο σημαντικά πράγματα που πρέπει να ληφθούν υπόψη κατά την κατασκευή ενός δένδρου απόφασης είναι πιο από το σύνολο των χαρακτηριστικών θα τοποθετηθεί στην ρίζα ώστε το δένδρο που θα προκύψει να πετύχει όσο το δυνατό γίνεται καλύτερη ταξινόμηση. Άρα μας ενδιαφέρει το βάθος του τελικού δένδρου. Για να καθοριστεί πως θα γίνει η επιλογή της ρίζας και πως θα επιτευχθεί ο σωστός διαχωρισμός χρησιμοποιείται ο δείκτης Gini impurity. Ο δείκτης Gini impurity δίνεται από τον τύπο $1 - \sum_{i=1}^n (P_i)^2$, όπου P_i είναι πιθανότητα εμφάνισης του χαρακτηριστικού στο σύνολο των δεδομένων και παίρνει τιμές μεταξύ του 0 και 1. Ο δείκτης Gini εφαρμόζεται για όλα τα χαρακτηριστικά και επιλέγεται εκείνο με την μικρότερη τιμή. Η ίδια διαδικασία εφαρμόζεται και στους εσωτερικούς κόμβους ώστε να επιτευχθεί ο καλύτερος διαχωρισμός και να δημιουργηθεί το κατάλληλο δένδρο.

Στα δένδρα απόφασης εμφανίζεται συχνά το πρόβλημα της υπερ-προσαρμογής (overfit), δηλαδή το δένδρο είναι ικανό να διαχειριστεί τα αρχικά δεδομένα αλλά δεν είναι ικανό να πραγματοποιήσει αποτελεσματικές προβλέψεις. Για να αποφευχθεί αυτό το πρόβλημα πρέπει ο διαχωρισμός κάθε φορά να πετυχαίνει την μεγαλύτερη μείωση του δείκτη Gini.

Ένα ακόμη πρόβλημα είναι ότι αρκετές φορές το αρχικό σύνολο των δεδομένων έχει ελλείψεις τιμές (Missing data). Ένας τρόπος επίλυσης είναι η συμπλήρωση της κενής τιμής με την τιμή που χρησιμοποιείται πιο πολύ για το συγκεκριμένο χαρακτηριστικό. Για παράδειγμα έστω ότι έχουμε 20 άτομα και τις απαντήσεις του για το εάν είναι υπέρβαρα ή όχι. Εάν για το 15^ο άτομο έχουμε κενό και η πλειοψηφία των απαντήσεων είναι ναι θα συμπληρώσουμε την κενή τιμή με ναι. Ένας άλλος τρόπος

είναι να ελεγχθεί ποια χαρακτηριστικά από το σύνολο των δεδομένων έχουν υψηλή συσχέτιση και έτσι θα προκύψει ποια τιμή πρέπει να τοποθετηθεί στο κενό πεδίο.

Τα Δένδρα Αποφάσεων είναι κατάλληλα για την ταξινόμηση των δεδομένων μας αλλά δεν είναι τόσο αποτελεσματικά στην ταξινόμηση νέων δειγμάτων, το πρόβλημα αυτό το αντιμετωπίζουμε με την χρήση των τυχαίων δασών (Random Forests).

5.3 Τυχαία Δάση

Τα Τυχαία Δάση (Random Forest) κατασκευάζονται όπως και τα Δένδρα Αποφάσεων αλλά συνδυάζουν την απλότητα των δένδρων αποφάσεων και έχουν και την ευελιξία να δίνουν περισσότερη ακρίβεια. Το πρώτο βήμα για την κατασκευή ενός Random Forest είναι η δημιουργία ενός συνόλου δειγμάτων με την τεχνική bootstrap sampling ή αλλιώς επιλογή στην τύχη με εναπόθεση και λειτουργεί ως εξής. Έστω ότι έχουμε ένα κουτί με 5 μπάλες [A, B, Γ, Δ, E]. Αρχικά επιλέγουμε από το καλάθι την μπάλα E και στην συνέχεια την ξανά τοποθετούμε στο κουτί. Έπειτα ξανά επιλέγεται μια μπάλα στην τύχη και μετά την ξανά τοποθετούμε στο κουτί. Η διαδικασία επαναλαμβάνεται μέχρι να προκύψει το επιθυμητό αποτέλεσμα.

Χρησιμοποιώντας τεχνικές σαν αυτή δίνεται η δυνατότητα να σπάει το αρχικό σύνολο δεδομένων σε πιο πολλά σετ εκπαίδευσης. Γι' αυτό και χρησιμοποιείται το bootstrap στα τυχαία δάση καθώς ο στόχος είναι η δημιουργία πολλών διαφορετικών δένδρων αποφάσεων. Επομένως αφού επιλεγεί το σύνολο δειγμάτων σχηματίζεται το κάθε δένδρο απόφασης με την μόνη διαφορά ότι σε κάθε βήμα για την επιλογή του χαρακτηριστικού που θα τοποθετηθεί στην ρίζα επιλέγεται ένα τυχαίο υποσύνολο μεταβλητών. Στην συνέχεια η ίδια διαδικασία ξανά εκτελείται αφού πρώτα με την βοήθεια του bootstrap έχει επιλεγεί το νέο δείγμα. Με αυτόν τον τρόπο προκύπτει μεγάλη ποικιλία δένδρων, η ποικιλία είναι που κάνει τα τυχαία δάση να είναι τόσο αποτελεσματικά.

Όταν προκύπτουν νέα στοιχεία για τα δεδομένα, για παράδειγμα εάν κάποιος είναι υπέρβαρος ή όχι, γίνεται σύγκριση των νέων στοιχείων με τα αποτελέσματα του κάθε δένδρου και εξάγονται τα κατάλληλα συμπεράσματα. Η τεχνική αυτή, χρήση

δηλαδή του bootstrap ώστε να δημιουργούνται πολλά δείγματα και από το σύνολο των δένδρων που έχουν δημιουργηθεί να προκύψει η τελική απόφαση ονομάζεται bagging.

Μια ακόμη λεπτομέρεια για την τεχνική του bootstrap είναι ότι όταν δημιουργεί το δείγμα από το αρχικό σύνολο επιτρέπει τις διπλό εγγραφές, με αποτέλεσμα κάποιες εγγραφές να μην συμπεριληφθούν στο δείγμα που δημιουργήθηκε. Οι εγγραφές αυτές που δεν συμπεριλήφθηκαν ονομάζονται “Out of Bag dataset”. Οι εγγραφές αυτές μπορούν να χρησιμοποιηθούν για να ελεγχθεί η εγκυρότητα των αποτελεσμάτων της ταξινόμησης. Αυτό γίνεται εάν καταμετρηθεί το σύνολο των εγγραφών που ήταν Out of Bag και ταξινομήθηκαν σωστά. Οι εγγραφές που δεν ταξινομήθηκαν σωστά ονομάζονται εγγραφές “Out of Bag Error”.

5.4 Τεχνητά Νευρωνικά Δίκτυα

Τα Νευρωνικά Δίκτυα (Neural Networks) αποτελούν μια από τις πιο δημοφιλείς και αποδοτικές μεθόδους μάθησης. Ένα Νευρωνικό Δίκτυο αποτελείται από κόμβους και συνδέσεις. Οι κόμβοι ανάμεσα στον κόμβο εισόδου και κόμβο εξόδου ονομάζονται κρυφό επίπεδο. Οι συνδέσεις εξυπηρετούν ώστε να μεταβιβαστεί από τον ένα κόμβο στον άλλον η συνάρτηση ενεργοποίησης και επίσης ο σύνδεσμος μας πληροφορεί για ένα βάρος, το οποίο δείχνει το πρόσημο της σύνδεσης. Επομένως κάθε κόμβος υπολογίζει πρώτα ένα άθροισμα το οποίο αποτελείται από το βάρος και την τιμή της συνάρτησης ενεργοποίησης και το αποτέλεσμα αυτό μεταβιβάζεται στην έξοδο. Υπάρχουν αρκετά είδη συναρτήσεων ενεργοποίησης όπου μπορούμε να επιλέξουμε οι πιο γνωστές είναι η σιγμοειδής συνάρτηση και η συνάρτηση καταφλίου.

Όπως και σε άλλες μεθόδους έτσι και στα νευρωνικά δίκτυα η εκπαίδευση γίνεται με το διαχωρισμό του αρχικού δείγματος σε ένα σετ εκπαίδευσης και σε ένα σετ ελέγχου. Στο σετ εκπαίδευσης επιλέγεται ο κατάλληλος αλγόριθμος και στην συνέχεια εκπαιδεύεται το δίκτυο. Στο σετ ελέγχου ελέγχεται η απόδοση του εκπαιδευμένου δικτύου. Κατά την φάση ελέγχου δίνονται στο δίκτυο νέα δεδομένα τα οποία δεν έχει συναντήσει πιο πριν και ελέγχουμε αν τα ταξινομεί σωστά.

Τα Νευρωνικά Δίκτυα παρουσιάζουν αρκετά πλεονεκτήματα. Αρχικά ένας νευρώνας μπορεί να είναι είτε γραμμικός είτε όχι. Επίσης παρουσιάζει μεγάλη προσαρμοστικότητα καθώς μπορεί να προσαρμόζει τα βάρη του ανάλογα με τις

αλλαγές που γίνονται στο περιβάλλον του. Τέλος, η παράλληλη φύση του νευρωνικού δικτύου το κάνει πολύ γρήγορο στους υπολογισμούς.

5.5 Μπαϊεζιανή Μάθηση

Το θεώρημα του Bayes ανήκει στην κατηγορία των πιθανοτικών μεθόδων και εξετάζει την πιθανότητα να συμβεί ένα γεγονός με βάση την γνώση που έχουμε ήδη γι' αυτό το γεγονός από το παρελθόν. Η πιθανότητα δίνεται από τον τύπο :

$$P(A|B) = \frac{P(B|A) * P(A)}{P(B)}$$

όπου $P(A|B)$ η εκ των υστέρων πιθανότητα να πραγματοποιηθεί το γεγονός A, με την προϋπόθεση ότι το γεγονός B έχει πραγματοποιηθεί ή αλλιώς posterior πιθανότητα.

Στην Μηχανική Μάθηση οι μέθοδοι ταξινόμησης που στηρίζονται στο θεώρημα του Bayes στηρίζονται στην υπόθεση ανεξαρτησίας μεταξύ των χαρακτηριστικών και κυρίως χρησιμοποιείται ο απλοϊκός ταξινομητής Bayes (Naïve Bayes - NB). Ο απλοϊκός ταξινομητής Bayes υποθέτει ότι η παρουσία ενός χαρακτηριστικού σε μια κατηγορία δεν σχετίζεται με την ύπαρξη των υπολοίπων χαρακτηριστικών και η πιθανότητα δίνεται από τον τύπο:

$$P(x_1, \dots, x_n | Y) = \prod_{i=1}^n P(x_i | Y)$$

για n διαφορετικά κατηγορικά χαρακτηριστικά. Αυτό που μας ενδιαφέρει είναι να βρούμε την κατηγορία που εμφανίζεται πιο συχνά ή αλλιώς την μέγιστη posterior πιθανότητα του $P(Y)$.

Ο αλγόριθμος μάθησης αρχικά δημιουργεί έναν πίνακα συχνοτήτων από όλες τις κατηγορίες, μετά δημιουργεί έναν πίνακα με τις αντίστοιχες πιθανότητες και τέλος υπολογίζει την μέγιστη πιθανότητα. Όπως σε όλες τις τεχνικές Μηχανικής Μάθησης, αρχικά χωρίζει το σύνολο των δεδομένων στο σετ εκπαίδευσης και στο σετ ελέγχου. Στην συνέχεια εκπαιδεύεται το μοντέλο και στο τέλος αξιολογούνται τα αποτελέσματα.

Ο απλοϊκός ταξινομητής Bayes κατασκευάζεται εύκολα και είναι ιδιαίτερα χρήσιμος για δεδομένα μικρού ή μεσαίου μεγέθους. Είναι ιδανικός για παραδείγματα όπως ταξινόμηση κειμένου και ταξινόμηση ανεπιθύμητης αλληλογραφίας. Ακόμη υπάρχουν και κάποιες παραλλαγές του Naïve Bayes ανάλογα με τον τύπο των

δεδομένων. Όταν τα δεδομένα είναι συνεχή χρησιμοποιείται ο Gaussian Naïve Bayes και όταν είναι διακριτά ο Bernoulli Naïve Bayes και ο Multinomial Naïve Bayes.

Τέλος, ένα από τα σημεία που πρέπει να τονιστούν είναι πως διαχειρίζεται τις κενές τιμές. Πολλές φορές στο σετ εκπαίδευσης κάποιο χαρακτηριστικό δεν εμφανίζεται από το συνολικό αριθμό χαρακτηριστικών οπότε προκύπτει μηδενική πιθανότητα με αποτέλεσμα σε μια μελλοντική πρόβλεψη εάν εμφανιστεί αυτό το χαρακτηριστικό να έχουμε λάθος πρόβλεψη. Το πρόβλημα αυτό αντιμετωπίζεται εάν στο σετ εκπαίδευσης προσθέσουμε σε κάθε χαρακτηριστικό μια παράμετρο, στην παράμετρο αυτή συνήθως αναφέρονται με το γράμμα α . Έτσι όταν υπολογίζεται η πιθανότητα δεν θα προκύψει η μηδενική πιθανότητα. Η παράμετρος α λαμβάνεται υπόψιν μόνο για το συγκεκριμένο χαρακτηριστικό που είχε κενή τιμή. Η διαδικασία αυτή ονομάζεται εξομάλυνση κατηγορικών δεδομένων (Smooth categorical data) ή Laplace Smoothing.

5.6 Μηχανές Διανυσμάτων Υποστήριξης

Μια ακόμη γνωστή τεχνική που εφαρμόζει η Μηχανική Μάθηση για ταξινόμηση είναι η χρήση των Μηχανών Διανυσμάτων Υποστήριξης (Support Vector Machines, SVM). Οι Μηχανές Διανυσμάτων Υποστήριξης/ SVM είναι μια διανυσματική μέθοδος μάθησης με στόχο την εύρεση ενός επιπέδου διαχωρισμού μεταξύ δύο χαρακτηριστικών/ κλάσεων. Με άλλα λόγια προβάλλουν σε έναν πολυδιάστατο χώρο σημεία που ανήκουν στο σετ εκπαίδευσης και εντοπίζουν το υπερεπίπεδο το οποίο διαχωρίζει με τον καλύτερο τρόπο τα σημεία σε δύο ομάδες. Τα διανύσματα τα οποία ορίζουν το υπερεπίπεδο ονομάζονται διανύσματα υποστήριξης (support vector).

Οι SVM χρησιμοποιούν δυαδικές τιμές για την ταξινόμηση. Αρχικά αν για παράδειγμα τα δεδομένα βρίσκονται στο επίπεδο μετακινούνται σε μεγαλύτερη διάσταση και αφού αλλάξει η διάσταση επιλέγουμε έναν ταξινομητή που χωρίζει τα δεδομένα σε δυο ομάδες με τον βέλτιστο τρόπο. Ο στόχος είναι να γίνει αντιστοίχιση των αρχικών χαρακτηριστικών σε έναν χώρο περισσότερων διαστάσεων από τον αρχικό, οπότε σε αυτόν τον χώρο τα χαρακτηριστικά είναι διαχωρίσιμα και έτσι μπορούν να ταξινομηθούν. Οι SVM διευκολύνουν στην ταξινόμηση χαρακτηριστικών τα οποία δεν είναι ξεκάθαρο πως μπορούν να ταξινομηθούν και αποτελούν μια

αναπαράσταση των δεδομένων στον χώρο. Οι SVM χρησιμοποιούν έναν αλγόριθμο εκπαίδευσης και έτσι αναπαριστούν μη γραμμικές σχέσεις στον χώρο.

Για να πραγματοποιηθεί η μετάβαση από έναν χώρο διαστάσεων σε έναν χώρο μεγαλύτερης διάστασης χρησιμοποιούνται οι συναρτήσεις Kernel. Οι δύο πιο συνηθισμένες συναρτήσεις είναι η πολυωνυμική συνάρτηση (polynomial kernel) και η ακτινική συνάρτηση βάσης (radial basis function, rbf).

Η πολυωνυμική συνάρτηση είναι της μορφής $K\left(\vec{x}, \vec{z}\right) = \left(1 + \vec{x}^T \vec{z}\right)^d$. Εάν $d=1$ έχουμε γραμμική συνάρτηση, εάν $d=2$ τετραγωνική συνάρτηση. Η συνάρτηση αυτή αντιστοιχεί σε έναν χώρο όπου οι διαστάσεις του είναι εκθετικές ως προς το d . Η πολυωνυμική συνάρτηση συγκρίνει τις σχέσεις που υπάρχουν μεταξύ των παρατηρήσεων.

Η ακτινική συνάρτηση είναι της μορφής $K\left(\vec{x}, \vec{z}\right) = e^{-\left(\vec{x}-\vec{z}\right)^2 / (2\sigma^2)}$ και μεταφέρει τα δεδομένα σε έναν χώρο απείρων διαστάσεων, γεγονός που δεν επιτρέπει την αναπαραστασή της.

ΚΕΦΑΛΑΙΟ 6^ο

ΕΜΠΕΙΡΙΚΗ ΜΕΛΕΤΗ

6.1 Εισαγωγή

Στην παρούσα ενότητα, σε συνέχεια του θεωρητικού σκέλους, πραγματοποιείται μια σειρά πειραμάτων που έχει σκοπό την ανάπτυξη προβλεπτικών μοντέλων δυαδικής(δί-τιμης) ταξινόμησης (binary classification). Για τον σκοπό αυτό χρησιμοποιήθηκε ένα γνωστό σετ δεδομένων στον χώρο της μηχανικής μάθησης(machine learning) από τον χώρο των χρηματοοικονομικών.

Τα δεδομένα προήλθαν από το UC Irvine Machine Learning Repository ([https://archive.ics.uci.edu/ml/datasets/statlog+\(german+credit+data\)](https://archive.ics.uci.edu/ml/datasets/statlog+(german+credit+data))). Το σετ των δεδομένων αποτελείται από 1000 παρατηρήσεις και από 21 μεταβλητές. Η μεταβλητή στόχος για την δημιουργία των μοντέλων είναι η μεταβλητή class. Στόχος μας είναι να προβλέψουμε αν ο ενδιαφερόμενος πελάτης έχει πιστοληπτική ικανότητα και μπορεί η τράπεζα να του χορηγήσει δάνειο ή το αντίθετο.

Πίνακας 2 Μεταβλητές του Μοντέλου

Όνομα μεταβλητής	Τιμές που λαμβάνει
checking_status (χρηματικό ποσό που υπάρχει σε κάποιον τρεχούμενο λογαριασμό σε γερμανικά μάρκα)	<0 >=200 0<=x<200 No checking
duration	[4-72]
Credit_history	All paid Critical/other existing credit Delayed previously Existing paid No credits/all paid

Purpose (σκοπός λήψης χρηματοοικονομικής βοήθειας)	Radio/tv New car Furniture/equipment Used car Business Education (other)
Credit_amount (χρηματικό ποσό δανείου)	[250-18424] in german Marks
Saving_Status (ποσό αποταμιεύσεων)	<100 ≥100 100≤x<500 500≤x<1000
Employment (έτη εργασίας)	<1 ≥7 1≤x<4 4≤x<7 unemployed
Installment_commitment (ποσό δόσεων)	1 2 3 4
Personal_Status	Female div/sep/mar Male div/sep Male mar/wid Male single
Other_parties	Co applicant (συν-αιτών) Guarantor(εγγυητής) none
Residence_Since (έτη διαμονής)	1 2 3 4

Property_magnitude	Car Life insurance No know property Real estate
Age	[19-75]
Other_payment_plans	Bank None Stores
Housing	For free Own Rent
Existing_credits (υπάρχοντα δάνεια)	1 2 3 4
Job	High qualif/self emp/ mgmt
Num_dependents	1 2
Own_telephone	None Yes (εγγεγραμμένο στο όνομα του πελάτη)
Foreign_Worker	No Yes
Class(πιστοληπτική ικανότητα)	Bad Good

Για την ανάπτυξη και ανάλυση των μοντέλων χρησιμοποιήθηκε η γλώσσα προγραμματισμού R. Η γλώσσα R διαθέτει μια ιδιαίτερα μεγάλη συλλογή από αλγορίθμους που υλοποιούν προβλεπτικά μοντέλα όλων των κατηγοριών. Πιο συγκεκριμένα χρησιμοποιήθηκε η δημοφιλής βιβλιοθήκη “caret” γνωστή για την διεπαφή της που δίνει πρόσβαση με έναν ενιαίο τρόπο στα προγνωστικά μοντέλα που υλοποιούνται από τρίτες βιβλιοθήκες. Έτσι ο χρήστης δεν χρειάζεται να γνωρίζει όλες τις διαφορετικές παραμέτρους που απαιτούν διαφορετικές μέθοδοι από διαφορετικές

βιβλιοθήκες ενώ αντίθετα επικεντρώνεται στην γνώση των απαιτούμενων εντολών μιας μόνο βιβλιοθήκη.

Η βιβλιοθήκη caret μπορεί να χρησιμοποιηθεί για την συνολική δημιουργία ενός προβλεπτικού μοντέλου όπως αυτή περιλαμβάνει την προεπεξεργασία των δεδομένων πριν την μοντελοποίηση, τις μεθόδους που μπορεί να χρησιμοποιήσει ο χρήστης ώστε να εκπαιδεύσει ένα σετ δεδομένων καθώς και την μέτρηση της επίδοσης του μοντέλου με την χρήση μετρικών για την σύγκριση μοντέλων εσωτερικά αλλά και εξωτερικά με άλλα μοντέλα.

Στην συνέχεια ακολουθεί η υλοποίηση μιας σειρά πειραμάτων που έχει σκοπό να καλύψει αρκετές κατηγορίες μεθόδων που σχετίζονται με την δημιουργία μοντέλων δίτιμης κατηγοριοποίησης αλλά και να συγκρίνει τις επιδόσεις των διαφορετικών μοντέλων προς την κατεύθυνση της επιλογής του καταλληλότερου για την επίλυσή του προβλήματος του χαρακτηρισμού της πιστοληπτικής ικανότητας ενός δυνητικού δανειολήπτη.

Σε όλα τα πειράματα χρησιμοποιήθηκε η ίδια μέθοδος δειγματοληψίας επάνω στο σετ εκπαίδευσης και αυτή ήταν η μέθοδος repeated 10-fold cross validation με 5 επαναλήψεις. Αυτό σημαίνει ότι το σετ εκπαίδευσης διαχωρίζεται σε 9+1 μέρη όπου οι γραμμές του σετ δεδομένων τοποθετούνται κατά μοναδικό τρόπο(χωρίς επαναδειγματοληψία). Πρόκειται για τον τρόπο επαναδειγματοληψίας με το μεγαλύτερο υπολογιστικό κόστος όμως και αντίστοιχα με την καλύτερη αναλογία σφάλματος-διακύμανσης. Όλα τα πειράματα υλοποιήθηκαν με την χρήση του ίδιου 8-πύρηνου επεξεργαστή Intel i7-8550u ενώ επίσης χρησιμοποιήθηκε παράλληλη εργασία για την παραγωγή των μοντέλων μέσα από την βιβλιοθήκη doParallel.

6.2 Λογιστική Παλινδρόμηση

Το πρώτο πείραμα που εκτελείται αφορά την παραγωγή ενός μοντέλου με την μέθοδο της λογιστικής παλινδρόμησης. Στον παρακάτω πίνακα ακολουθούν τα αποτελέσματα βασικών μετρικών για το μοντέλο που προκύπτει από τα δεδομένα εκπαίδευσης.

Πίνακας 3 Μετρικές μετά την εκπαίδευση

ROC	0.774
Sensitivity	0.532
Specificity	0.856
Accuracy	0.759

Σύμφωνα με τον πίνακα 3 η ακρίβεια των προβλέψεων και για τις δύο κλάσεις της μεταβλητής στόχου στο σετ εκπαίδευσης είναι περίπου 76% ενώ ο δείκτης ROC που αποτελεί την αναλογία ποσοστών μεταξύ επιτυχόντων θετικών και μη επιτυχόντων θετικών προβλέψεων είναι περίπου 77%. Γενικά, τα μοντέλα που δομούνται με την μέθοδο της λογιστικής παλινδρόμησης παρουσιάζουν συνήθως χαμηλότερη ακρίβεια από τις υπόλοιπες μεθόδους αλλά και μικρή διακύμανση στην ακρίβεια όταν σε αυτά εφαρμοστούν τα δεδομένα από το σετ ελέγχου χαρακτηρίζοντάς τα ως μοντέλα με χαμηλή ευαισθησία σε νέα δεδομένα.

Στην συνέχεια ακολουθεί ο πίνακας σύγκρισης όπως αυτός προκύπτει μετά την εφαρμογή στο εκτιμημένο μοντέλων των δεδομένων του σετ ελέγχου.

Πίνακας 4 Πίνακας Σύγκρισης

Prediction	Bad	Good
Bad	41	32
Good	49	178

Στον πίνακα 5 παρουσιάζονται οι τιμές των μετρικών απόδοσης του μοντέλου μετά την δημιουργία του πίνακα σύγκρισης. Σύμφωνα με τον πίνακα 5 η ακρίβεια του μοντέλου όπως αυτή προκύπτει μετά την εφαρμογή των δεδομένων του σετ ελέγχου είναι της τάξης του 73%.

Πίνακας 5 Μετρικές μετά την πρόβλεψη

Sensitivity	0.455
Specificity	0.847
Accuracy	0.73

6.3 Δέντρα Απόφασης

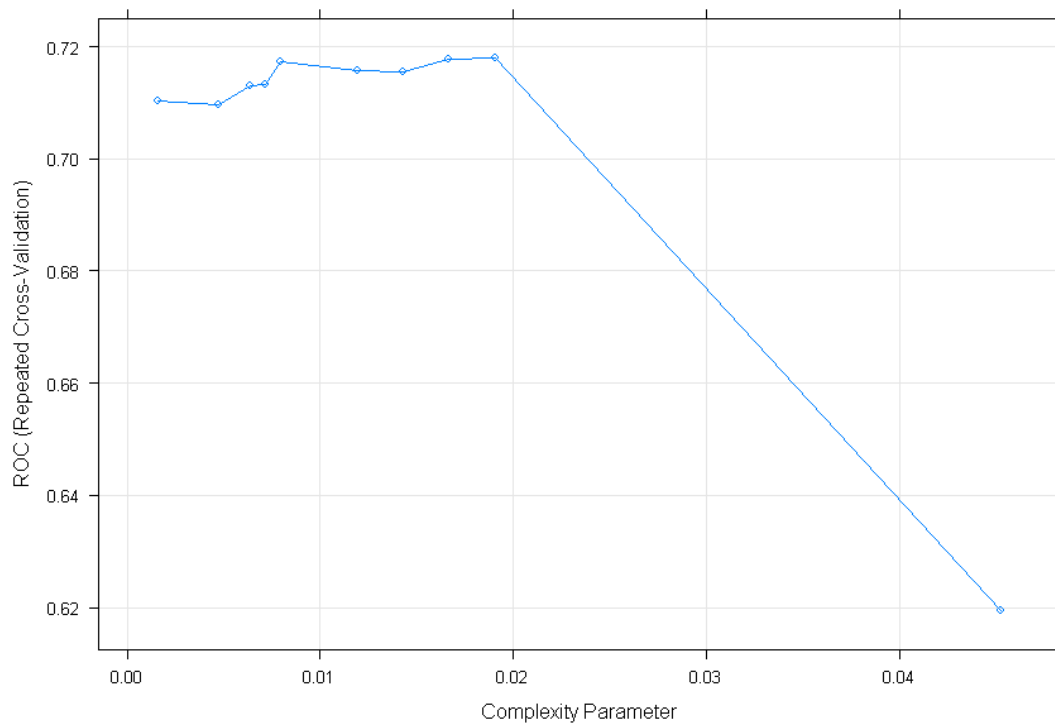
Το δεύτερο πείραμα που εκτελείται αφορά την παραγωγή ενός μοντέλου με την μέθοδο των δέντρων απόφασης (Decision Trees). Στο πακέτο caret διατίθενται εντολές για την εύρεση της βέλτιστης τιμής των παραμέτρων για μοντέλα που υποστηρίζουν κάτι τέτοιο μέσω του ορισμού τιμής της παραμέτρου tuneLength. Η επιλογή που πραγματοποιήθηκε ήταν η τυχαία επιλογή από το caret 10 τιμών για την παράμετρο cp (complexity parameter).

Στον πίνακα που ακολουθεί βλέπουμε τα αποτελέσματα βασικών μετρικών για το μοντέλο που προκύπτει για τα δεδομένα εκπαίδευσης. Μετά την παραγωγή προβλέψεων από το εκπαιδευμένο μοντέλο ακολουθεί ο πίνακας σύγκρισης που αφορά την εφαρμογή των δεδομένων ελέγχου επάνω στο μοντέλο.

Πίνακας 6 Μετρικές μετά την εκπαίδευση

Cp	ROC	Sensitivity	Specificity	Accuracy
0.001	0.710	0.416	0.809	0.698
0.004	0.709	0.404	0.830	0.707
0.006	0.713	0.410	0.838	0.712
0.007	0.713	0.415	0.840	0.714
0.007	0.717	0.432	0.837	0.718
0.011	0.715	0.447	0.844	0.720
0.014	0.715	0.453	0.842	0.718
0.016	0.717	0.425	0.855	0.720
0.019	0.718	0.417	0.860	0.725
0.045	0.619	0.234	0.908	0.722

Στην συνέχεια ακολουθεί διάγραμμα το οποίο δείχνει σε ποια τιμή της παραμέτρου μεγιστοποιείται μια επιλεγείσα μετρική απόδοσης. Στο συγκεκριμένο διάγραμμα ως μετρική απόδοσης επιλέχθηκε η ROC.



Διάγραμμα 3 Εύρεση τιμής παραμέτρου CP που μεγιστοποιεί την μετρική ROC

Από το παραπάνω διάγραμμα φαίνεται ότι η τιμή της μετρικής ROC μεγιστοποιείται όταν η τιμή του cp είναι 0.019. Μάλιστα για την ίδια τιμή της παραμέτρου πολυπλοκότητας μεγιστοποιείται και ο δείκτης ακρίβειας.

Στην συνέχεια κατά αντιστοιχία με το μοντέλο της λογιστικής παλινδρόμησης έχουμε την παραγωγή του πίνακα σύγχυσης για το μοντέλων των δέντρων απόφασης και ο πίνακας 8 δίνει ακρίβεια των προβλέψεων ίση με 0.7 επάνω στο σετ ελέγχου.

Πίνακας 7 Πίνακας Σύγχυσης

Prediction	Bad	Good
Bad	30	26
Good	60	184

Πίνακας 8 Μετρικές μετά την πρόβλεψη

Sensitivity	0.333
Specificity	0.876
Accuracy	0.7

6.4 Δέντρα Απόφασης με Bagging

Το τρίτο πείραμα που εκτελείται αφορά την παραγωγή ενός μοντέλου με την μέθοδο των δέντρων αποφάσεων με την χρήση της τεχνικής Bagging. Συνήθως με την τεχνική αυτή εξασφαλίζονται κατά μέσο όρο καλύτερες προβλέψεις σε σχέση με το αν δεν εφαρμοζόταν. Από την άλλη πλευρά με την χρήση μεθόδων επαναδειγματοληψίας η τεχνική του bagging αποδυναμώνεται σε όρους επιδόσεων.

Στον πίνακα 9 παρουσιάζονται οι τιμές των βασικών μετρικών απόδοσης για το μοντέλο που προκύπτει από το σετ εκπαίδευσης.

Πίνακας 9 Μετρικές μετά την εκπαίδευση

ROC	0.757
Sensitivity	0.452
Specificity	0.853
Accuracy	0.738

Πίνακας 10 Πίνακας Σύγκρισης

Prediction	Bad	Good
Bad	40	31
Good	50	179

Πίνακας 11 Μετρικές μετά την πρόβλεψη

Sensitivity	0.444
Specificity	0.852
Accuracy	0.73

Από τον πίνακα σύγκρισης και τους δείκτες απόδοσης που υπολογίζονται από τις τιμές του βλέπουμε ότι το μοντέλο που κατασκευάστηκε έχει ακρίβεια συνολικής πρόβλεψης ίσο με 73%. Συνεπώς η χρήση της τεχνικής bagging δεν πέτυχε στο συγκεκριμένο σετ δεδομένων να βελτιώσει τους δείκτες απόδοσης.

6.5 Τυχαία Δάση


Το τέταρτο πείραμα που εκτελείται αφορά την παραγωγή ενός μοντέλου με την μέθοδο των τυχαίων δασών (Random Forests). Συχνά η χρήση των τυχαίων δασών οδηγεί σε βελτίωση των δεικτών απόδοσης του προβλεπτικού μοντέλου. Παράλληλα όμως τα τυχαία δάση διατηρούν το μειονέκτημα της υπερπροσαρμογής στα δεδομένα όπως εξάλλου συμβαίνει και με τα δέντρα απόφασης.

Στον πίνακα που ακολουθεί βλέπουμε τις τιμές βασικών μετρικών απόδοσης για το μοντέλο που προκύπτει από τα δεδομένα εκπαίδευσης σε συνδυασμό με τις διαφορετικές τυχαίες τιμές της παραμέτρου *mtry* που επιλέγονται από το λογισμικό.

Πίνακας 12 Μετρικές μετά την εκπαίδευση

mtry	ROC	Sensitivity	Specificity
2	0.769	0.068	0.998
7	0.787	0.340	0.937
13	0.785	0.393	0.910
19	0.783	0.411	0.900
25	0.781	0.437	0.891
30	0.780	0.438	0.886
36	0.778	0.441	0.881
42	0.775	0.455	0.876
48	0.775	0.441	0.876
54	0.773	0.449	0.871

Με τον δείκτη ROC προσδιορίστηκε το καλύτερο μοντέλο και επιλέχθηκε αυτό με την μεγαλύτερη τιμή, με την παράμετρο *mtry* να ισούται $mtry = 7$. Επίσης υπολογίστηκε η συνολική απόδοση του μοντέλου, $Accuracy = 0,761$.



Διάγραμμα 4 Μεγιστοποίηση τιμής ROC

Στο πακέτο caret εφόσον κάποιο μοντέλο περιλαμβάνει τον προσδιορισμό παραμέτρων τότε μπορεί μέσω διαγράμματος να δοθεί γραφικά ο συνδυασμός τιμών των παραμέτρων που μεγιστοποιούν μια επιλεγείσα μετρική απόδοσης. Στο συγκεκριμένο μοντέλο έχει επιλεγθεί να αναπαρασταθούν οι τιμές της παραμέτρου που μεγιστοποιούν τον δείκτη ROC που αναφέρεται στα δεδομένα εκπαίδευσης.

Πίνακας 13 Πίνακας Σύγχυσης

Prediction	Bad	Good
Bad	40	26
Good	50	184

Πίνακας 14 Μετρικές μετά την πρόβλεψη

Sensitivity	0.4444
Specificity	0.8762
Accuracy	0.7467

Από τον πίνακα 14 λαμβάνεται η πληροφόρηση για την προσαρμογή του μοντέλου σε νέα δεδομένα όπως αυτό εκφράζεται μέσα από την χρήση του σετ ελέγχου. Η συνολική ακρίβεια του μοντέλου παρουσιάζεται αυξημένη σε σχέση με τα απλά δέντρα απόφασης πράγμα το οποίο είναι αναμενόμενο. Αξίζει να σημειωθεί ότι η εκπαίδευση ενός μοντέλου με τυχαία δάση απαιτεί αυξημένη υπολογιστική ισχύ το οποίο μεταφράζεται και σε μεγαλύτερο απαιτούμενο χρόνο για την κατασκευή του μοντέλου.

6.6 Δέντρα Απόφασης με Boosting

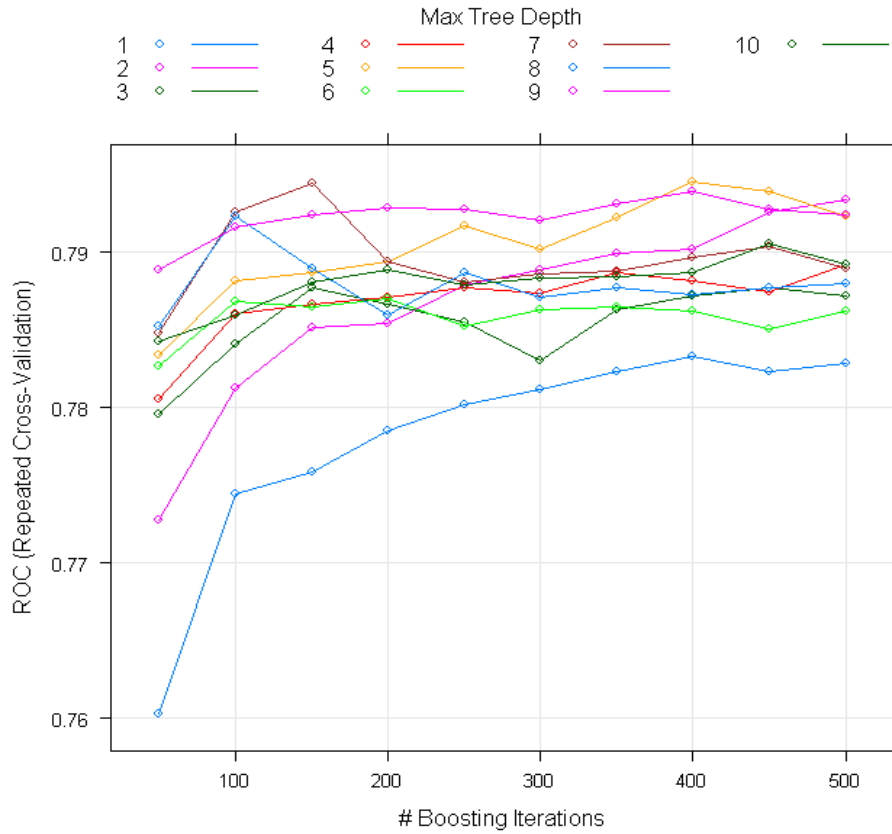
Το πέμπτο πείραμα που εκτελείται αφορά την παραγωγή ενός μοντέλου με την μέθοδο των δέντρων αποφάσεων με την χρήση της τεχνικής Boosting. Η τεχνική boosting αποτελεί μια σαφή προσπάθεια βελτίωσης των αποτελεσμάτων της μοντελοποίησης καθώς στοχεύει στην βελτίωση των σημείων όπου το μοντέλο δεν σημειώνει υψηλή ακρίβεια προβλέψεων. Τις περισσότερες φορές ένα μοντέλο που χρησιμοποιεί την τεχνική boosting πετυχαίνει καλύτερα αποτελέσματα καθώς δεν μπορεί να δώσει χειρότερη εκτίμηση σε σχέση με αυτή που δίνει το αντίστοιχης μεθόδου απλό μοντέλο. Παρόλα αυτά η χρήση της τεχνικής συνοδεύεται από την ανάγκη για αυξημένη υπολογιστική ισχύ και μεγαλύτερη χρονική διάρκεια δημιουργίας του μοντέλου σε σχέση με τα υπόλοιπα.

Στον πίνακα που ακολουθεί βλέπουμε τα αποτελέσματα βασικών μετρικών για το μοντέλο που προκύπτει από τα δεδομένα εκπαίδευσης.

Πίνακας 15 Μετρικές μετά την εκπαίδευση

Interaction Depth	N.trees	ROC	Sensitivity	Specificity	Accuracy
1	50	0.760	0.198	0.953	...
1	100	0.774	0.321	0.905	...
...					
2	50	0.772	0.321	0.909	...
2	100	0.781	0.425	0.888	...
...					
5	400	0.794	0.517	0.864	0.753
...					
8	300	0.787	0.495	0.867	...
...					
10	500	0.789	0.516	0.865	...

Με τον δείκτη ROC προσδιορίστηκε το βέλτιστο μοντέλο και επιλέχθηκε αυτό με την μεγαλύτερη τιμή, με την παράμετρο Number of Trees να ισούται $N.trees = 400$ και την παράμετρο Interaction Depth να ισούται με $interaction.depth = 5$.



Διάγραμμα 5 Μεγιστοποίηση τιμής ROC

Πίνακας 16 Πίνακας Σύγκυσης

Prediction	Bad	Good
Bad	41	24
Good	49	186

Πίνακας 17 Μετρικές μετά την πρόβλεψη

Sensitivity	0.455
Specificity	0.885
Accuracy	0.773

Από τον πίνακα σύγκυσης φαίνεται ότι η ακρίβεια των προβλέψεων του μοντέλου ανήλθε στο 77% περίπου, εμφανώς αυξημένου σε σχέση με τις προηγούμενες υλοποιήσεις.

6.7 Μηχανές Διανυσμάτων Υποστήριξης

Το έκτο πείραμα που εκτελείται αφορά την παραγωγή ενός μοντέλου με την μέθοδο Διανυσματικές Μηχανές Υποστήριξης (SVM). Πρέπει να σημειωθεί ότι η μέθοδος που χρησιμοποιήθηκε για την κατασκευή του μοντέλου με τις διανυσματικές μηχανές υποστήριξης ήταν η γραμμική. Σε αντιστοιχία με τα προηγούμενα μοντέλα ακολουθεί ο πίνακας με τις τιμές των βασικών μετρικών απόδοσης του μοντέλου που προκύπτουν για τα δεδομένα εκπαίδευσης.

Πίνακας 18 Μετρικές μετά την εκπαίδευση

ROC	0.786
Sensitivity	0.395
Specificity	0.919
Accuracy	0.755

Πίνακας 19 Πίνακας Σύγκυσης

Prediction	Bad	Good
Bad	33	29
Good	57	181

Πίνακας 20 Μετρικές μετά την πρόβλεψη

Sensitivity	0.368
Specificity	0.861
Accuracy	0.716

Σύμφωνα με τον πίνακα σύγκυσης το μοντέλο που κατασκευάστηκε με την μέθοδο των διανυσματικών μηχανών υποστήριξης σημείωσε ακρίβεια προβλέψεων στο 78%.

6.8 Νευρωνικά Δίκτυα

Το έβδομο πείραμα που εκτελείται αφορά την παραγωγή ενός μοντέλου με την μέθοδο των Νευρωνικών Δικτύων (Neural Network). Στον πίνακα που ακολουθεί βλέπουμε τα αποτελέσματα βασικών μετρικών για το μοντέλο που προκύπτει για τα δεδομένα εκπαίδευσης. Μετά την παραγωγή προβλέψεων από το εκπαιδευμένο μοντέλο ακολουθεί ο πίνακας σύγκρισης που αφορά την εφαρμογή των δεδομένων ελέγχου επάνω στο μοντέλο.

Πίνακας 21 Μετρικές μετά την εκπαίδευση

Size	Decay	ROC	Sensitivity	Specificity	Accuracy
1	0.00000	0.50386	0.01238	0.99510	...
1	0.00010	0.50696	0.009523	0.99673	...
...					
5	0.00023	0.58809	0.219047	0.90734	...
5	0.000237	0.58809	0.219047	0.90734	...
...					
9	0.10000	0.77049	0.524761	0.84000	0.745
...					
13	0.01778	0.74256	0.539047	0.79102	...
...					
17	0.10000	0.76000	0.510476	0.84081	...
...					

Με τον δείκτη ROC προσδιορίστηκε το βέλτιστο μοντέλο και επιλέχθηκε αυτό με την μεγαλύτερη τιμή, με την παράμετρο Size να ισούται Size = 9 και την παράμετρο Decay να ισούται με decay = 0,1.

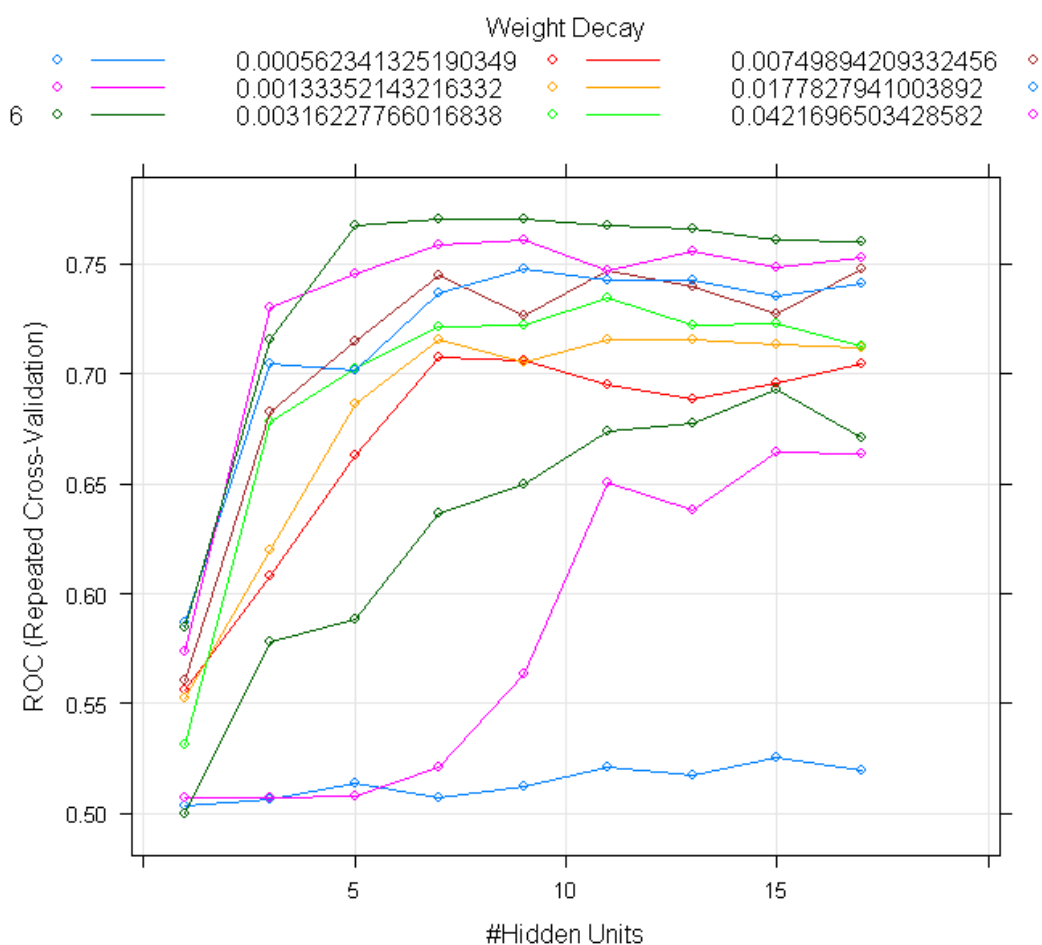
Πίνακας 22 Πίνακας Σύγκυσης

Prediction	Bad	Good
Bad	40	30
Good	50	180

Πίνακας 23 Μετρικές μετά την πρόβλεψη

Sensitivity	0.444
Specificity	0.857
Accuracy	0.753

Τα νευρωνικά δίκτυα για τις επιλεγμένες τιμές παραμέτρων όπως προκύπτει από τον πίνακα σύγκυσης επιτυγχάνουν ακρίβεια προβλέψεων στο σετ ελέγχου της τάξης του 75% γεγονός που τα κατατάσσει ανάμεσα στα πιο αποτελεσματικά σε όρους συνολικής πρόβλεψης

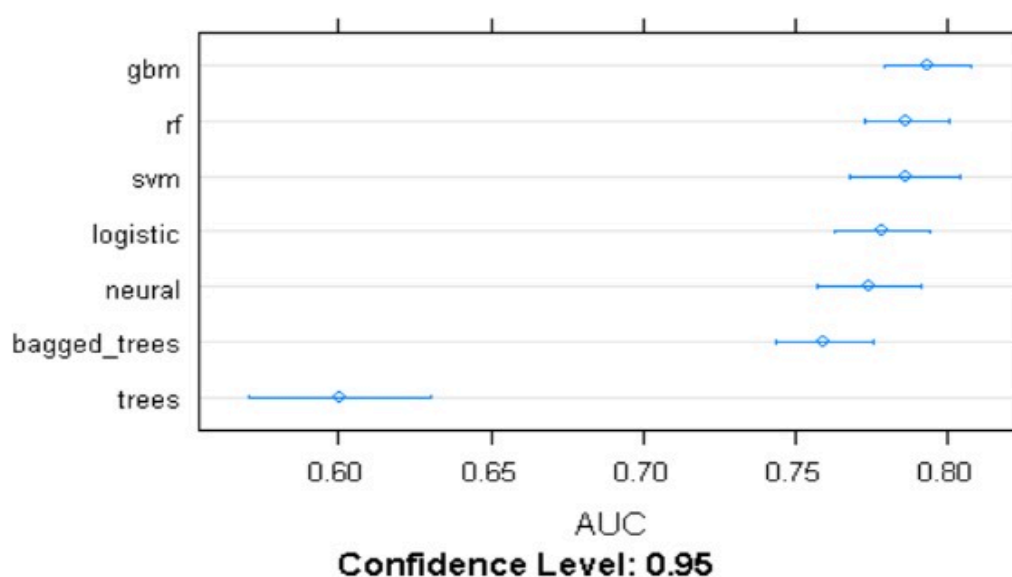


Διάγραμμα 6 Μεγιστοποίηση τιμής ROC

6.9 Συγκριτική ανάλυση επίδοσης μοντέλων


Κατά την διενέργεια συγκριτικής ανάλυσης των επιδόσεων των προβλεπτικών μοντέλων θα πρέπει να σημειωθεί και να τονιστεί ότι οι συγκρίσεις θα πρέπει να πραγματοποιηθούν επάνω στην βάση των ίδιων ακριβώς σετ δεδομένων εκπαίδευσης και ελέγχου ώστε η σύγκριση να μπορεί να έχει κοινή βάση. Το πακέτο caret μέσα από την συνάρτηση `resamples()` δίνει την δυνατότητα αυτόματης επαναδειγματοληψίας και ελέγχου των προβλέψεων για τα υλοποιημένα μοντέλα. Πιο συγκεκριμένα λαμβάνεται ένας αριθμός κοινών δειγμάτων από τα αρχικά δεδομένα για όλα τα μοντέλα και πραγματοποιείται επανεκτίμηση των βασικών μετρικών απόδοσης για κάθε μοντέλο. Συνεπώς και ανάλογα με τον αριθμό των δειγμάτων της επαναδειγματοληψίας κάθε μοντέλο έχει μια κατανομή παρατηρήσεων για τις μετρικές απόδοσης του. Είναι σύνηθες ως αποτελεσματικότερο μοντέλο να επιλέγεται αυτό που έχει τόσο την μεγαλύτερη μέση τιμή για μια μετρική απόδοσης (πχ ακρίβεια (accuracy)) αλλά και την μικρότερη τυπική απόκλιση για την ίδια μετρική. Είναι συχνό να συνεκτιμώνται η μετρική accuracy σε συνδυασμό με την μετρική AUC για την τελική επιλογή του βέλτιστου μοντέλου.

Το πακέτο caret δίνει την δυνατότητα οπτικοποίησης των αποτελεσμάτων της συνάρτησης `resamples`.



Διάγραμμα 7 Απόδοση τεχνικών με βάση το AUC

Στο διάγραμμα 7 φαίνεται πως η μέθοδος gbm (boosting method) σημειώνει την μεγαλύτερη μέση τιμή της μετρικής AUC ενώ παράλληλα έχει την ίδια περίπου τυπική απόκλιση με το μοντέλο των τυχαίων δασών που κατατάσσεται στην δεύτερη θέση.



Διάγραμμα 8 Απόδοση τεχνικών με βάση το Accuracy

Κατά αντίστοιχο τρόπο με το διάγραμμα 7 παρατηρείται ότι στο διάγραμμα 8 όπου η μετρική απόδοσης είναι η συνολική ακρίβεια ενός μοντέλου, η μέθοδος που επιτυγχάνει την καλύτερη επίδοση είναι αυτή των τυχαίων δασών. Όμως από τα 2 διαγράμματα δεν μπορεί να εξαχθεί άμεσα οπτικά η πληροφορία για το βέλτιστο μοντέλο. Αν θεωρήσουμε ότι οι 2 δείκτες απόδοσης έχουν το ίδιο βάρος για την τελική επιλογή του βέλτιστου μοντέλου και είναι εκφρασμένα στις ίδιες μονάδες μέτρησης τότε μπορούμε να ορίσουμε ως βέλτιστο το μοντέλο το οποίο θα έχει το μέγιστο άθροισμα των δεικτών Accuracy και AUC.

Πίνακας 24 Συνολικό άθροισμα AUC και Accuracy

Μοντέλο	Άθροισμα (AUC,Accuracy)
Λογιστική παλινδρόμηση	1.5373
Δέντρα απόφασης	1.3025
Δέντρα με τεχνική bagging	1.4979
Τυχαία δάση	1.5463
Gradient Stochastic Boosting	1.5478
Support vector machines	1.5413
Neural Networks	1.5150

Σύμφωνα με τα στοιχεία του παραπάνω πίνακα ως βέλτιστο μοντέλο μπορεί να επιλεγεί οριακά η μέθοδος του Gradient Stochastic Boosting με τις μεθόδους Τυχαία δάση και Support vector machines να ακολουθούν. Σε κάθε περίπτωση όμως δεν πρέπει να μην λαμβάνεται υπόψη και ο χρόνος που απαιτήθηκε για την κατασκευή ενός μοντέλου από τον υπολογιστή. Στην περίπτωση αυτή η λογιστική παλινδρόμηση επίσης αποτελεί μια πολύ καλή επιλογή δεδομένης της πολύ γρηγορότερης κατασκευής του μοντέλου της σε σχέση με τα υπόλοιπα μοντέλα τα οποία απαιτήσαν πολλαπλάσιο χρόνο. Σε κάθε περίπτωση οι επιπλέον παράμετροι πρέπει με κάποιον τρόπο να προσμετρώνται σε συνδυασμό με το πρόβλημα που μοντελοποιείται.

ΚΕΦΑΛΑΙΟ 7^ο

ΣΥΜΠΕΡΑΣΜΑΤΑ

Στην παρούσα θέση αρχικά πραγματοποιήθηκε η σχετική με το ερευνώμενο αντικείμενο βιβλιογραφική ανασκόπηση και πιο συγκεκριμένα με τις εφαρμογές της Τεχνητής Νοημοσύνης στον κλάδο της Χρηματοοικονομικής και της Ελεγκτικής. Η προσέγγιση του διεπιστημονικού αυτού πεδίου πραγματοποιήθηκε με τρόπο ώστε ο αναγνώστης να κατανοήσει την συμβολή της Τεχνητής Νοημοσύνης σε αυτούς τους κλάδους αλλά και να αναδειχθούν οι υφιστάμενες τάσεις και μεθοδολογίες.

Μέσα από την ανασκόπηση καθίσταται κατανοητό ότι η Τεχνητή Νοημοσύνη αποτελεί έναν επιστημονικό κλάδο που εξελίσσεται με ταχύτατους ρυθμούς και μπορεί να αναβαθμίσει και να αυτοματοποιήσει πολλές σημαντικές λειτουργίες που σήμερα χρειάζονται κόπο και χρόνο για να υλοποιηθούν. Επιπλέον καθίσταται εμφανές πως οι μέθοδοι και οι τεχνικές που εφαρμόζονται έχουν σημαντικό αντίκτυπο οικονομικό και συνεπώς επιχειρησιακό δημιουργώντας την ανάγκη οι εταιρείες, οι δημόσιες υπηρεσίες, τα χρηματοπιστωτικά ιδρύματα να κατανοήσουν και να αφομοιώσουν τις εξελίξεις μέσα από άμεση τεχνολογική εξέλιξη αλλά και την υιοθέτηση καινοτομιών . Για να πραγματοποιηθεί αυτή η εξέλιξη, όπως τονίζεται και από την βιβλιογραφία, προηγείται η κατάλληλη εκπαίδευση των ατόμων και η αναβάθμιση των υπολογιστικών δομών και συστημάτων. Τα παραπάνω αντανακλούν σε ένα οικονομικό κόστος το οποίο όμως θα δώσει βραχυπρόθεσμα συγκριτικό πλεονέκτημα ενώ μακροπρόθεσμα μπορεί να συντελέσει αποφασιστικά στην διατήρηση της κερδοφορίας των επιχειρήσεων-οργανισμών. Ειδικά στον κλάδο της Χρηματοοικονομικής και Ελεγκτικής οι λογιστές/ ελεγκτές θα μπορούν να παίρνουν πιο εύκολα αποφάσεις για σημαντικά ζητήματα, να αναγνωρίζονται επαναλαμβανόμενα επιχειρηματικά μοτίβα, να εντοπίζονται απάτες, να γίνονται προβλέψεις και αναλύονται χρηματοοικονομικές καταστάσεις.

Από την βιβλιογραφία ακόμη προέκυψε ότι η Τεχνητή Νοημοσύνη και οι εφαρμογές της καλούνται να αντιμετωπίσουν επιτυχώς το ζήτημα της ασφαλούς

διαχείρισης και επεξεργασίας εμπιστευτικών προσωπικών δεδομένων με την θέσπιση κανόνων διασφάλισης και αποτροπής πιθανών διαρροών.

Στην συνέχεια μελετήθηκε το κομμάτι της Τεχνίτης Νοημοσύνης όπως αυτό ορίζεται μέσα από την έννοια της Μηχανικής Μάθησης. Η Μηχανική Μάθηση είναι ένα πολύ χρήσιμο εργαλείο καθώς δίνει την δυνατότητα της πρόβλεψης. Πολλοί επιστήμονες την αποκαλούν Τέχνη της Πρόβλεψης καθώς με την εφαρμογή των μεθόδων της δίνεται η δυνατότητα να πραγματοποιηθούν ιδιαίτερα χρήσιμες προβλέψεις. Αφού πραγματοποιήθηκε η παρουσίαση των πιο βασικών μεθόδων της Μηχανικής Μάθησης για την δημιουργία μοντέλων ταξινόμησης για την επίλυση προβλημάτων δίτιμης ταξινόμησης, πραγματοποιήθηκε αντίστοιχη εμπειρική μελέτη.

Η εμπειρική μελέτη είχε στόχο να προβλέψει αν ένας υποψήφιος πελάτης τράπεζας είναι αξιόπιστος ώστε να του χορηγηθεί δάνειο και προέκυψε ότι οι περισσότερες μέθοδοι δίνουν ικανοποιητικά αποτελέσματα ενώ ως βέλτιστη μέθοδος επιλέχθηκε το μοντέλο που υλοποιήθηκε με την χρήση της τεχνικής Boosting. Τελικά και έπειτα από την παρουσίαση του πειραματικού σκέλους καθίσταται κατανοητό πόσο χρήσιμο εργαλείο συνιστά η χρήση της Τεχνητής Νοημοσύνης και των εφαρμογών της καθώς μπορούν να προσδώσουν σημαντικά οφέλη και να μειώσουν τον κίνδυνο σε πολλές περιπτώσεις. Τέλος, είναι καλό να τονιστεί ότι η Μηχανική Μάθηση δεν δύναται να προσφέρει απαντήσεις σε όλα τα προβλήματα καθώς πριν την εφαρμογή των μεθόδων της θα πρέπει να αναλυθούν και να επεξεργαστούν προσεκτικά τα δεδομένα που έχει κάποιος στην κατοχή του αλλά και να επιλεγθεί προσεκτικά η μέθοδος που ταιριάζει στο κάθε πρόβλημα.

Το σημαντικό ωστόσο είναι ότι έχουμε πλέον στα χέρια μας χρήσιμες τεχνολογίες οι οποίες μπορούν να αναβαθμίσουν την ποιότητα του έργου ενός Λογιστή και Ελεγκτή. Η Τεχνητή Νοημοσύνη έχει την ικανότητα να μεταμορφώσει τον Χρηματοοικονομικό κλάδο αφού πρώτα γίνουν οι κατάλληλες αλλαγές.

ΒΙΒΛΙΟΓΡΑΦΙΑ

- Akerkar, R. (2019). Artificial Intelligence for Business. Springerbriefs In Business. doi: 10.1007/978-3-319-97436-1
- Axelsen, M., Green, P., & Ridley, G. (2017). Explaining the information systems auditor role in the public sector financial audit. *International Journal Of Accounting Information Systems*, 24, 15-31. doi: 10.1016/j.accinf.2016.12.003
- Bahrammirzaee, A. (2010). A comparative survey of artificial intelligence applications in finance: artificial neural networks, expert system and hybrid intelligent systems. *Neural Computing And Applications*, 19(8), 1165-1195. doi: 10.1007/s00521-010-0362-z
- Bishop, c. (2016). Pattern recognition and machine learning.
- Botez, D. (2018). Recent Challenge for Auditors: Using Data Analytics in the Audit of the Financial Statements. *BRAIN. Broad Research In Artificial Intelligence And Neuroscience*, 9(4), 61-71.
- Chen, M., Mao, S., & Liu, Y. (2014). Big Data: A Survey. *Mobile Networks And Applications*, 19(2), 171-209. doi: 10.1007/s11036-013-0489-0
- Chen, W., & Du, Y. (2009). Using neural networks and data mining techniques for the financial distress prediction model. *Expert Systems With Applications*, 36(2), 4075-4086. doi: 10.1016/j.eswa.2008.03.020
- Chukwudi, O., Echefu, S., Boniface, U., & Victoria, C. (2018). Effect of Artificial Intelligence on the Performance of Accounting Operations among Accounting Firms in South East Nigeria. *Asian Journal Of Economics, Business And Accounting*, 7(2), 1-11. doi: 10.9734/ajeba/2018/41641
- Dowling, C., & Leech, S. (2013). A Big 4 Firm's Use of Information Technology to Control the Audit Process: How an Audit Support System is Changing Auditor Behavior. *Contemporary Accounting Research*, 31(1), 230-252. doi: 10.1111/1911-3846.12010
- Dunham, M. (2003). Data mining introductory and advanced topics. Upper Saddle River, N.J.: Prentice Hall/Pearson Education.
- Egeli, B., Ozturan, M. and Badur, B. (2003) Stock Market Prediction Using Artificial Neural Networks. *Proceedings of the 3rd International Conference on Business, Hawaii*, 18-21 June 2003, 1-8

- Fanning, K., & Cogger, K. (1998). Neural network detection of management fraud using published financial data. *International Journal Of Intelligent Systems In Accounting, Finance & Management*, 7(1), 21-41.
- Gepp, A., Linnenluecke, M., O'Neill, T., & Smith, T. (2018). Big data techniques in auditing research and practice: Current trends and future opportunities. *Journal Of Accounting Literature*, 40, 102-115. doi: 10.1016/j.acclit.2017.05.003
- Ghodselahi, A., & Amirmadhi, A. (2011). Application of Artificial Intelligence Techniques for Credit Risk Evaluation. *International Journal Of Modeling And Optimization*, 243-249. doi: 10.7763/ijmo.2011.v1.43
- Hansen, J., & Messier, W. (1986). A knowledge-based expert system for auditing advanced computer systems. *European Journal Of Operational Research*, 26(3), 371-379. doi: 10.1016/0377-2217(86)90139-6
- Heckerman, D. (2008). A Tutorial on Learning with Bayesian Networks. *Innovations In Bayesian Networks*, 33-82. doi: 10.1007/978-3-540-85066-3_3
- Hongjiu, L., Rieg, R., & Yanrong, H. (2012). Performance comparison of artificial intelligence methods for predicting cash flow. *Neural Network World*, 22(6), 549-564. doi: 10.14311/nnw.2012.22.034
- Issa, H., Sun, T., & Vasarhelyi, M. (2016). Research Ideas for Artificial Intelligence in Auditing: The Formalization of Audit and Workforce Supplementation. *Journal Of Emerging Technologies In Accounting*, 13(2), 1-20. doi: 10.2308/jeta-10511
- James, G., & Witten, D. (2013). *An introduction to statistical learning: with applications in R*. New York [etc.]: Springer.
- Khanduja, V., Arora, A., & Garg, S. (2017). Applications of big data in real world: It's not what you know. It's what you do with what you know. 2017 International Conference On Computing, Communication And Automation (ICCCA). doi: 10.1109/ccaa.2017.8229792
- Kirkos, E., Spathis, C., & Manolopoulos, Y. (2007). Data Mining techniques for the detection of fraudulent financial statements. *Expert Systems With Applications*, 32(4), 995-1003. doi: 10.1016/j.eswa.2006.02.016

- Kirkos, E., Spathis, C., & Manolopoulos, Y. (2009). Audit-firm group appointment: an artificial intelligence approach. *Intelligent Systems In Accounting, Finance & Management*, 17(1), 1-17. doi: 10.1002/isaf.310
- Kuhn, M., & Johnson, K. (2016). *Applied predictive modeling*. New York: Springer.
- Kusuma, R.M., Ho, T., Kao, W., Ou, Y., & Hua, K. (2019). Using Deep Learning Neural Networks and Candlestick Chart Representation to Predict Stock Market.
- Liaw, A., & Wiener, M. (2007). Classification and Regression by randomForest.
- Luo, J., Hu, Z., & Wang, L. (2018). Research on CPA Auditing Reform Strategy Under the Background of Artificial Intelligence. *Proceedings Of The 2018 2Nd International Conference On Management, Education And Social Science (ICMESS 2018)*. doi: 10.2991/icmess-18.2018.207
- Min, H. (2010). Artificial intelligence in supply chain management: theory and applications. *International Journal Of Logistics Research And Applications*, 13(1), 13-39. doi: 10.1080/13675560902736537
- Mirzaey, M., Behdad, M., & Hojatpour, Y. (2017). Applications of Artificial Neural Networks in Information System of Management Accounting.
- Najafabadi, M., Villanustre, F., Khoshgoftaar, T., Seliya, N., Wald, R., & Muharemagic, E. (2015). Deep learning applications and challenges in big data analytics. *Journal Of Big Data*, 2(1). doi: 10.1186/s40537-014-0007-7
- O'Leary, D. (2013). Artificial Intelligence and Big Data. *IEEE Intelligent Systems*, 28(2), 96-99. doi: 10.1109/mis.2013.39
- Omoteso, K. (2012). The application of artificial intelligence in auditing: Looking back to the future. *Expert Systems With Applications*, 39(9), 8490-8495. doi: 10.1016/j.eswa.2012.01.098
- Prediction Studies: Review and Research Directions. 28(4), 22.
- Sledgianowski, D., Gomaa, M., & Tan, C. (2017). Toward integration of Big Data, technology and information systems competencies into the accounting curriculum. *Journal Of Accounting Education*, 38, 81-93. doi: 10.1016/j.jaccedu.2016.12.008
- Song, Z., Liu, D., & Chen, S. (2012). A Decision Engineering Method to Identify the Competitive Effects of Working Capital: A Neural Network

Model. Systems Engineering Procedia, 5, 326-333. doi: 10.1016/j.sepro.2012.04.051

- Strader, T. J., Rozycki, J. J., & Root, T. H. (2020). Machine Learning Stock Market
- Šuleř, P. (2016) 'Cash Management of a Company Using Neural Networks', *Littera Scripta*, 9(3), p. 16.
- Sun, T., & Vasarhelyi, M. (2018). Embracing Textual Data Analytics in Auditing with Deep Learning. *The International Journal Of Digital Accounting Research*, 49-67. doi: 10.4192/1577-8517-v18_3
- Sustrova, T. (2016). An Artificial Neural Network Model for a Wholesale Company's Order-Cycle Management. *International Journal Of Engineering Business Management*, 8, 2. doi: 10.5772/63727
- Taha, R. O. H. (2012) The Possibility of using Artificial Neural Networks in Auditing -Theoretical Analytical Paper, (47), p. 14.
- Tariq, S. (2017). Co2 emissions from Pakistan and India and their relationship with economic variables. *Applied Ecology And Environmental Research*, 15(4), 1301-1312. doi: 10.15666/aeer/1504_13011312
- Torres P., E., Hernández-Álvarez, M., Torres Hernández, E., & Yoo, S. (2019). Stock Market Data Prediction Using Machine Learning Techniques. *Advances In Intelligent Systems And Computing*, 539-547. doi: 10.1007/978-3-030-11890-7_52
- Ukpong, E., Udoh, I., & Essien, I. (2019). Artificial Intelligence: Opportunities, Issues and Applications in Banking, Accounting, and Auditing in Nigeria. *Asian Journal Of Economics, Business And Accounting*, 1-6. doi: 10.9734/ajeba/2019/v10i130099
- Wang, Z., & Lin, Y. (2020). Talent Training Model of Auditing under the Background of Artificial Intelligence. *Journal Of Physics: Conference Series*, 1533, 032075. doi: 10.1088/1742-6596/1533/3/032075
- Zekić, M. (1998). Neural Network Applications in Stock Market Predictions. *Proceedings Of The 9Th International Conference On Information And Intelligent Systems '98*.

- Zijm, H., & Klumpp, M. (2015). Logistics and Supply Chain Management: Developments and Trends. Logistics And Supply Chain Innovation, 1-20. doi: 10.1007/978-3-319-22288-2_1
- Chopra Sunil, Meindl Peter (2014). Διοίκηση Εφοδιαστικής Αλυσίδας
- Christopher Manning, Prabhakar Raghavan, Hinrich Schutze (2012). Εισαγωγή στην ανάκτηση πληροφοριών
- Haykin, S. (2010). Νευρωνικά δίκτυα και μηχανική μάθηση.
- Stuart Russell, Peter Norvig, (2004). Τεχνητή Νοημοσύνη - Μια Σύγχρονη Προσέγγιση, 2η Αμερικάνικη Έκδοση, Κλειδάριθμος
- Ι. Βλαχάβας, Π. Κεφαλάς, Ν. Βασιλειάδης, Φ. Κόκκορας, Η. Σακελλαρίου. (2011). Τεχνητή Νοημοσύνη - Γ' Έκδοση
- Λουλάκης, Μ., (2015). Στοχαστικές Διαδικασίες. [ηλεκτρ. βιβλ.] Αθήνα: Σύνδεσμος Ελληνικών Ακαδημαϊκών Βιβλιοθηκών. Διαθέσιμο στο: <http://hdl.handle.net/11419/6003>.
- Νεγκάκης Χρήστος & Ταχυνάκης Παναγιώτης (2017). Ελεγκτική Εσωτερικός Έλεγχος Εφαρμογές και θεωρία
- https://issuu.com/accountancygreece/docs/ag_35
- <https://ncube.com/blog/big-data-and-ai>
- <https://www.cfo.com/auditing/2015/06/artificial-intelligence-can-boost-audit-quality/>
- <https://www.europarl.europa.eu/news/el/headlines/society/20200918STO87404/techniti-noimosuni-eukairies-kai-apeiles>
- <https://www.taxheaven.gr/news/47183/tehnith-nohmosynh-kai-emmeses-technikes-forologikoy-elegxoy>

ΠΑΡΑΡΤΗΜΑ

Παρακάτω παρατίθεται ο κώδικας για κάθε μοντέλο:

```
library(caret)
library(doParallel)
library(parallel)
library(MLeval)
library(tictoc)
set.seed(430)
index = createDataPartition(gcredit$class, p = 0.70, list = FALSE)
train_data = gcredit[index, ]
test_data = gcredit[-index, ]
#####Model1:Logistic regression
cluster <- makeCluster(detectCores() - 1) # convention to leave 1 core for OS
registerDoParallel(cluster)
tic()
model1 = train(
  form = class ~ .,
  data = train_data,
  trControl = trainControl(method = "repeatedcv", classProbs =
TRUE,summaryFunction=twoClassSummary,number =10,repeats=5,savePredictions
= TRUE,allowParallel = TRUE),
  method = "glm",
  family = "binomial",
  metric="ROC"
)
toc()
stopCluster(cluster)
print(model1)
varImp(model1)
model_prediction1<-predict(model1,test_data)
cf1=confusionMatrix(model_prediction1,test_data$class)
```

```
#Model2:Decision trees
cluster <- makeCluster(detectCores() - 1) # convention to leave 1 core for OS
registerDoParallel(cluster)
tic()
model2 = train(
  form = class ~ .,
  data = train_data,
  trControl = trainControl(method = "repeatedcv", number
=10,repeats=5,savePredictions = TRUE,summaryFunction=twoClassSummary,
classProbs=T),
  method = "rpart",tuneLength = 10,metric = "ROC")
toc()
```

```

stopCluster(cluster)
print(model2)
plot(model2)
model_prediction2<-predict(model2,test_data,type="prob")
cf2=confusionMatrix(model_prediction2,test_data$class)

#Model3:Bagged Tree
cluster <- makeCluster(detectCores() - 1) # convention to leave 1 core for OS
registerDoParallel(cluster)
tic()
model3 = train(
  form = class ~ .,
  data = train_data,
  trControl = trainControl(method = "repeatedcv", number =10,repeats=5,classProbs =
TRUE,savePredictions = TRUE,summaryFunction=twoClassSummary),
  method = "treebag",tuneLength = 10,metric="ROC")
toc()
stopCluster(cluster)
print(model3)
model_prediction3<-predict(model3,test_data)
cf3=confusionMatrix(model_prediction3,test_data$class)

#Model4:Random forest
cluster <- makeCluster(detectCores() - 1) # convention to leave 1 core for OS
registerDoParallel(cluster)
tic()
model4 = train(
  form = class ~ .,
  data = train_data,
  trControl = trainControl(method = "repeatedcv", number
=10,repeats=5,savePredictions = TRUE,classProbs =
TRUE,summaryFunction=twoClassSummary),
  method = "rf",tuneLength = 10,metric="ROC")
toc()
stopCluster(cluster)
print(model4)
model_prediction4<-predict(model4,test_data)
cf4<-confusionMatrix(model_prediction,test_data$class)

#Model5:Boosting model gbm
cluster <- makeCluster(detectCores() - 1) # convention to leave 1 core for OS
registerDoParallel(cluster)
tic()
model5 = train(
  form = class ~ .,
  data = train_data,
  trControl = trainControl(method = "repeatedcv", number
=10,repeats=5,savePredictions = TRUE,classProbs =
TRUE,summaryFunction=twoClassSummary),
  method = "gbm",tuneLength = 10,metric="ROC")

```

```

toc()
stopCluster(cluster)
print(model5)
model_prediction5<-predict(model5,test_data)
cf5<-confusionMatrix(model_prediction5,test_data$class)

#Model6:Support Vector Machines
cluster <- makeCluster(detectCores() - 1) # convention to leave 1 core for OS
registerDoParallel(cluster)
tic()
model6 = train(
  form = class ~ .,
  data = train_data,
  trControl = trainControl(method = "repeatedcv",number
=10,repeats=5,savePredictions = TRUE,classProbs =
TRUE,summaryFunction=twoClassSummary),
  method = "svmLinear",tuneLength=10,metric="ROC")
toc()
stopCluster(cluster)
print(model6)
plot(model6)
model_prediction6<-predict(model6,test_data)
cf6<-confusionMatrix(model_prediction6,test_data$class)

#####Model8:Neural Networks
cluster <- makeCluster(detectCores() - 1) # convention to leave 1 core for OS
registerDoParallel(cluster)
tic()
model8 = train(
  form = class ~ .,
  data = train_data,
  method = "nnet",tuneLength = 10,metric="ROC",
  trControl = trainControl(method = "repeatedcv", number
=10,repeats=5,savePredictions = TRUE,allowParallel = TRUE,classProbs =
TRUE,summaryFunction=twoClassSummary)
)
toc()
stopCluster(cluster)
print(model8)
plot(model8)
model_prediction8<-predict(model8,test_data)
cf8=confusionMatrix(model_prediction8,test_data$class)

#ROC curves
plots=evalm(list(model1,model2,model3,model4,model5,model6,model8),

```

```
gnames = c("Logistic", "Decision Trees", "Bagged trees",  
"Random forest", "Gradient stochastic boosting", "Support Vector  
Machines", "Neural network"),  
rlinehick=0.8, fsize=10, bins=3,  
plots= c("prg",  
"pr", "r", "cc"))
```