



ΠΑΝΕΠΙΣΤΗΜΙΟ ΠΕΙΡΑΙΩΣ
UNIVERSITY OF PIRAEUS



Εφαρμογή τεχνικών μηχανικής μάθησης γράφων για ανίχνευση απάτης συναλλαγών

Δη-Ιδρυματικό Μεταπτυχιακό
Παν. Πειραιώς – ΕΚΕΦΕ Δημόκριτος
«ΤΕΧΝΗΤΗ ΝΟΗΜΟΣΥΝΗ»

ΠΑΣΧΑΛΗΣ ΓΕΩΡΓΙΟΣ

1. Περιεχόμενα

.....	1
1. Περιεχόμενα	3
2. Εισαγωγή	13
2.1. Θεμελιώδεις Αρχές της Θεωρίας Γράφων.....	13
2.2. Μηχανική Μάθηση σε Δεδομένα Γράφων.....	14
3. Θεωρητική Ανάλυση	15
3.1. Κατηγορίες Γραφών	16
• Μη Κατευθυνόμενοι Γράφοι:	16
• Κατευθυνόμενοι Γράφοι (Διγράμματα):.....	16
• Γράφοι με Βάρη:	16
• Γράφοι χωρίς Βάρη:.....	16
• Bipartite Γράφοι (Διμερής Γράφος):	17
• Multigraph (Πολύγραφος):	17
3.2. Ιδιότητες και Μετρήσεις Γράφων	17
• Βαθμός:.....	17
• Διαδρομή:	17
• Κύκλος:	18
• Συνδεσιμότητα:.....	18
• Clustering Coefficient:.....	18
• Μετρήσεις Κεντρικότητας:	18
3.3. Αλγόριθμοι για ανάλυση Γράφων	19
• Αναζήτηση κατά Βάθος (Depth-First Search - DFS) [10]:.....	19
• Αναζήτηση κατά Πλάτος (Breadth-First Search - BFS) [10]:	19
• Αλγόριθμος του Dijkstra [10]:	19
• Αλγόριθμος του Bellman-Ford [10]:.....	20
• Αλγόριθμος του Floyd-Warshall [10]:.....	20
• Αλγόριθμοι Ελαχίστης Κάλυψης Δέντρου (MST - Minimum Spanning Tree) [10]:	20
• Αλγόριθμοι Ροής Δικτύου [10]:.....	20
• Αλγόριθμοι Εύρεσης Κοινοτήτων [11]:	21
• Αλγόριθμοι Τυχαίας Διαδρομής (Random Walks) [12]:.....	21
3.4. Παραδοσιακές Μέθοδοι Ανάλυσης Γράφων	22
3.5. Ανάλυση Κεντρικότητας (Centrality Analysis)	22
3.6. Ανάλυση Συνδεσιμότητας (Connectivity Analysis)	22
3.7. Αναγνώριση Κοινοτήτων (Community Detection)	23
3.8. Εξερεύνηση Δομής Δικτύου (Network Structure Exploration)	23
3.9. Αναλυτική Μέθοδοι Ροής (Flow Analysis Methods)	24
3.10. Μηχανική Μάθηση στην Ανάλυση Γράφων.....	25
3.11. Graph Neural Networks (GNNs)	25
3.12. Graph Convolutional Networks (GCNs)	26

3.13.	Graph Attention Networks (GATs)	26
3.14.	Graph Autoencoders.....	27
3.15.	Node2Vec και Άλλες Μέθοδοι Ενσωμάτωσης (Embedding Methods)	27
4.	Μεθοδολογία	29
4.1.	Μέθοδοι Συλλογής Δεδομένων	29
	• Πρόσβαση σε Υφιστάμενες Βάσεις Δεδομένων	30
	• Δημόσια Διαθέσιμα Σύνολα Δεδομένων	30
	• Συνεργασία με Οικονομικά Ιδρύματα	30
4.2.	Προεπεξεργασία Δεδομένων	31
	• Καθαρισμός Δεδομένων και Αντιμετώπιση Ελλιπών Τιμών.....	31
	• Κανονικοποίηση και Κλιμάκωση Δεδομένων	31
	• Αναπαράσταση Δεδομένων ως Γράφοι.....	32
	• Εξαγωγή και Μείωση Χαρακτηριστικών.....	32
	• Αντιμετώπιση Ανισορροπίας Δεδομένων.....	32
4.3.	Εξαγωγή Χαρακτηριστικών	32
	• Ανάλυση Δομής Γράφου.....	33
	• Μετασχηματισμός Δεδομένων.....	33
	• Χρήση Προηγμένων Μεθόδων Εξαγωγής Χαρακτηριστικών.....	33
4.4.	Αντιμετώπιση της Ανισορροπίας Δεδομένων [14]	34
	• Υπερδειγματοληψία (Oversampling).....	34
4.5.	Υποδειγματοληψία (Undersampling)	34
	• Synthetic Minority Over-sampling Technique (SMOTE) [17]	35
4.6.	Feature Engineering	37
	• Δημιουργία Νέων Χαρακτηριστικών	37
	• Ανάλυση Δικτύου και Γραφών.....	37
	• Χρήση Εξωτερικών Πηγών Δεδομένων.....	37
	• Αντιμετώπιση Προκλήσεων.....	38
4.7.	Μέθοδοι Αξιολόγησης	39
	• Διάσπαση Δεδομένων (Data Splitting).....	39
	• Μέτρα Αξιολόγησης Απόδοσης [18].....	39
	• Διασταυρούμενη Επικύρωση (Cross-Validation)	40
	• Ανάλυση Σφάλματος (Error Analysis)	40
4.8.	Επιλογή Μοντέλου	41
	• Κατανόηση του Προβλήματος και των Δεδομένων.....	41
	• Επιλογή Αρχικών Υποψήφιων Μοντέλων.....	41
	• Εκπαίδευση και Βελτιστοποίηση Υποψήφιων Μοντέλων.....	41
	• Αξιολόγηση Μοντέλων	41
	• Ενσωμάτωση και Δοκιμή στο Πραγματικό Περιβάλλον	42
5.	Ανάλυση Προβλήματος: Ανίχνευση Απάτης με Αλγορίθμους Μηχανικής Μάθησης σε Γράφους	43
5.1.	Ανίχνευση Απάτης Σε Οικονομικές Συναλλαγές	43
5.2.	Χαρακτηριστικά Υποπτων Συναλλαγών	44

5.3.	Παραδείγματα Στο Πραγματικό Κόσμο	45
5.4.	Εφαρμογές Ανίχνευσης Απάτης.....	46
	• Τραπεζικά και Χρηματοοικονομικά Συστήματα.....	46
	• Ασφαλιστικά Συστήματα	46
	• Ηλεκτρονικό Εμπόριο	46
5.5.	Μηχανική Μάθηση και Ανίχνευση Απάτης: Ο ρόλος το γράφων.	46
5.6.	Συστήματα Ανάλυσης Γραφών	47
5.7.	Αλγόριθμοι Μηχανικής Μάθησης σε Γράφους για Ανίχνευση Απάτης.....	47
	• Νευρωνικά Δίκτυα Γραφών (GNNs).....	47
	• Δίκτυα Συνέλιξης σε Γράφους (GCNs)	48
	• Δίκτυα Προσοχής σε Γράφους (GATs)	48
	• Αυτόκωδικοποιητές Γράφων	48
	• Node2Vec και Άλλες Μέθοδοι Ενσωμάτωσης.....	48
5.8.	Εφαρμογές και Οφέλη.....	49
	• Παράδειγμα Σενάριου	49
5.9.	Συμπέρασμα	49
6.	Αρχιτεκτονική Συστήματος, Αλγόριθμοι και Τεχνικές.....	50
6.1.	Ανίχνευση Απάτης σε Οικονομικές Συναλλαγές.....	50
6.2.	Δεδομένα	50
6.3.	Σύστημα	52
	• Υποσύστημα Εισαγωγής και Εξαγωγής Δεδομένων	52
	• Υποσύστημα Δημιουργίας Γράφου	52
	• Υποσύστημα Επεξεργασίας Δεδομένων	53
	• Υποσύστημα Κατηγοριοποιήσεις	53
6.4.	Γραφιστική Αναπαράσταση Συστήματος.....	53
6.5.	Αλγόριθμοι.....	55
	• Graph Convolution Networks - GCNs.....	55
	• Graph Sage.....	55
	• Graph Attention Network	55
6.6.	Τεχνικές.....	55
7.	Πειραματική Ανάλυση.....	57
7.1.	Περιγραφή Πειραμάτων.....	57
7.2.	Αρχιτεκτονική Μοντέλων	58
	• G2Sage	58
	• G4Sage	58
	• G2GraphSage	59
	• GCN2Conv	59
	• GCN4Conv	59
	• G2Gat.....	60
7.3.	Ανάλυση Μοντέλων	61
	• G2Sage_100	61

•	G2Sage_200.....	62
•	G2Sage_400.....	63
•	G4Sage_100.....	65
•	G4Sage_200.....	67
•	G4Sage_400.....	69
•	G2GraphSAGE_100.....	71
•	G2GraphSage_200.....	73
•	G2GraphSage_400.....	75
•	GCN2Conv_100.....	77
•	GCN2Conv_200.....	79
•	GCN2Conv_400.....	81
•	GCN4Conv_100.....	83
•	GCN4Conv_200.....	85
•	GCN4Conv_400.....	86
•	G2Gat_20.....	88
•	G2Gat_100.....	89
7.4.	Σύγκριση Εποχών Εκπαίδευσης ανά Αρχιτεκτονική	91
•	G2Sage.....	91
•	G4Sage.....	91
•	G2GraphSAGE.....	91
•	GCN2Conv.....	91
•	GCN4Conv.....	91
7.5.	Σύγκριση Χρόνων Εκπαίδευσης.....	91
•	100 Εποχές Εκπαίδευσης.....	91
•	200 Εποχές Εκπαίδευσης.....	92
•	400 Εποχές Εκπαίδευσης.....	92
7.6.	Σύγκριση Χρόνων Συλλογισμού	93
•	Συνολικός Χρόνος Συλλογισμού.....	93
•	Χρόνος Συλλογισμού για κάθε αρχιτεκτονική ανά εποχές εκπαίδευσης. Πως η εκπαίδευση επηρεάζει το συλλογισμό.....	93
7.7.	Σύγκριση Ίδιων Κατηγοριών με διαφορετική αρχιτεκτονική.....	95
•	GraphSAGE.....	95
•	GCNConv.....	96
7.8.	Σύγκριση Διαφορετικών Αρχιτεκτονικών.....	97
•	100 Εποχές Εκπαίδευσης.....	97
•	200 Εποχές Εκπαίδευσης.....	98
•	400 Εποχές Εκπαίδευσης.....	98
•	Γενική Σύγκριση Μοντέλων με τα καλύτερα αποτελέσματα.....	98
7.9.	Σύγκριση με Classifier χωρίς χρήση embeddings	99
8.	Συμπεράσματα.....	100
9.	Bibliography.....	102

Πίνακες

Πίνακας 1 Περιγραφή Δεδομένων	50
Πίνακας 2 Στοιχεία Παραλήπτη	51
Πίνακας 3 Στοιχεία Συναλλαγής	51
Πίνακας 4 Λίστα Πειραμάτων	57
Πίνακας 5 Αρχιτεκτονική G2Sage	58
Πίνακας 6 Αρχιτεκτονική G4Sage	58
Πίνακας 7 Αρχιτεκτονική G2GraphSage	59
Πίνακας 8 Αρχιτεκτονική GCN2Conv	59
Πίνακας 9 Αρχιτεκτονική GCN4Conv	60
Πίνακας 10 Αρχιτεκτονική G2Gat	60
Πίνακας 11 Πίνακας Σύγχυσης G2Sage_100	62
Πίνακας 12 Πίνακας Σύγχυσης G2Sage_200	63
Πίνακας 13 Precision, Recal, F1 Score1 για το G2Sage_200	63
Πίνακας 14 Πίνακας Σύγχυσης G2Sage_400	64
Πίνακας 15 Precision, Recal, F1 Score1 για το G2Sage_400	65
Πίνακας 16 Πίνακας Σύγχυσης G4Sage_100	66
Πίνακας 17 Precision, Recal, F1 Score1 για το G4Sage_100	67
Πίνακας 18 Πίνακας Σύγχυσης G4Sage_200	68
Πίνακας 19 Precision, Recal, F1 Score1 για το G4Sage_200	69
Πίνακας 20 Πίνακας Σύγχυσης G4Sage_400	70
Πίνακας 21 Precision, Recal, F1 Score1 για το G4Sage_200	71
Πίνακας 22 Πίνακας Σύγχυσης G2GraphSage_100	72
Πίνακας 23 Precision, Recal, F1 Score1 για το G2GraphSage_100	73
Πίνακας 24 Πίνακας Σύγχυσης G2GraphSage_200	74
Πίνακας 25 Precision, Recal, F1 Score1 για το G2GraphSage_200	75
Πίνακας 26 Πίνακας Σύγχυσης G2GraphSage_400	76
Πίνακας 27 Precision, Recal, F1 Score1 για το G2GraphSage_400	77
Πίνακας 28 Πίνακας Σύγχυσης GCN2Conv_100	78
Πίνακας 29 Precision, Recal, F1 Score1 για το GCN2Conv_100	79
Πίνακας 30 Πίνακας Σύγχυσης GCN2Conv_200	80
Πίνακας 31 Precision, Recal, F1 Score1 για το GCN2Conv_200	81
Πίνακας 32 Πίνακας Σύγχυσης GCN2Conv_400	82
Πίνακας 33 Precision, Recal, F1 Score1 για το GCN2Conv_400	83
Πίνακας 34 Πίνακας Σύγχυσης GCN4Conv_100	84
Πίνακας 35 Precision, Recal, F1 Score1 για το GCN4Conv_100	85
Πίνακας 36 Πίνακας Σύγχυσης GCN4Conv_200	86
Πίνακας 37 Precision, Recal, F1 Score1 για το GCN4Conv_200	86
Πίνακας 38 Πίνακας Σύγχυσης GCN4Conv_400	87
Πίνακας 39 Precision, Recal, F1 Score1 για το GCN4Conv_400	88
Πίνακας 40 Πίνακας Σύγχυσης G2Gat_20	89
Πίνακας 41 Πίνακας Σύγχυσης G2Gat_100	90

Πίνακας 42 Precision, Recall, F1 Score για το GCN4Conv_400	91
Πίνακας 43 Χρόνος Εκπαίδευσης Μοντέλων, για εκπαίδευση 100 Εποχών.....	91
Πίνακας 44 Χρόνος Εκπαίδευσης Μοντέλων, για εκπαίδευση 200 Εποχών.....	92
Πίνακας 45 Χρόνος Εκπαίδευσης Μοντέλων, για εκπαίδευση 200 Εποχών.....	92
Πίνακας 46 Χρόνοι Συλλογισμού	93
Πίνακας 47 Χρόνος Συλλογισμού G2Sage	93
Πίνακας 48 Χρόνος Συλλογισμού G4Sage	94
Πίνακας 49 Χρόνος Συλλογισμού G2GraphSAGE.....	94
Πίνακας 50 Χρόνος Συλλογισμού GCN2Conv.....	94
Πίνακας 51 Χρόνος Συλλογισμού GCN2Conv.....	94
Πίνακας 52 Χρόνος Συλλογισμού GCN2Conv.....	95
Πίνακας 53 Confusion Matrix των μοντέλων GraphSAGE.....	95
Πίνακας 54 ROC AUC των μοντέλων GraphSAGE	96
Πίνακας 55 Confusion Matrix των μοντέλων GCNConv.....	96
Πίνακας 56 ROC AUC των μοντέλων GCNConv	96
Πίνακας 57 Συγκεντρωτικά αποτελέσματα	97
Πίνακας 58 ROC AUC Score μοντέλων που εκπαιδεύτηκαν σε 100 εποχές	97
Πίνακας 59 ROC AUC Score μοντέλων που εκπαιδεύτηκαν σε 200 εποχές	98
Πίνακας 60 ROC AUC Score μοντέλων που εκπαιδεύτηκαν σε 400 εποχές	98
Πίνακας 61 Συγκεντρωτικά αποτελέσματα μοντέλων	98
Πίνακας 62 Σύγκριση αποτελεσμάτων μεταξύ SC_100 και G2GraphSAGE_400	99

Εικόνες

Εικόνα 1 Αρχιτεκτονική Συστήματος.....	54
--	----

Γραφήματα

Γράφημα 1 Παράδειγμα Γράφου	52
Γράφημα 2 Ρυθμός Μεταβολής Απώλειας ανά Εποχή G2Sage_100	61
Γράφημα 3 Ρυθμός Μεταβολής Απώλειας ανά Εποχή G2Sage_200	62
Γράφημα 4 Ρυθμός Μεταβολής Απώλειας ανά Εποχή G2Sage_400	64
Γράφημα 5 Ρυθμός Μεταβολής Απώλειας ανά Εποχή G4Sage_100	66
Γράφημα 6 Ρυθμός Μεταβολής Απώλειας ανά Εποχή G4Sage_200	68
Γράφημα 7 Ρυθμός Μεταβολής Απώλειας ανά Εποχή G4Sage_400	70
Γράφημα 8 Ρυθμός Μεταβολής Απώλειας ανά Εποχή G2GraphSage_100	72
Γράφημα 9 Ρυθμός Μεταβολής Απώλειας ανά Εποχή G2GraphSage_200	74
Γράφημα 10 Ρυθμός Μεταβολής Απώλειας ανά Εποχή G2GraphSage_400	76
Γράφημα 11 Ρυθμός Μεταβολής Απώλειας ανά Εποχή GCN2Conv_100.....	78
Γράφημα 12 Ρυθμός Μεταβολής Απώλειας ανά Εποχή GCN2Conv_200.....	80
Γράφημα 13 Ρυθμός Μεταβολής Απώλειας ανά Εποχή GCN2Conv_400.....	82
Γράφημα 14 Ρυθμός Μεταβολής Απώλειας ανά Εποχή GCN4Conv_100.....	84
Γράφημα 15 Ρυθμός Μεταβολής Απώλειας ανά Εποχή GCN4Conv_200.....	85
Γράφημα 16 Ρυθμός Μεταβολής Απώλειας ανά Εποχή GCN4Conv_400.....	87
Γράφημα 17 Ρυθμός Μεταβολής Απώλειας ανά Εποχή G2Gat_20	88
Γράφημα 18 Ρυθμός Μεταβολής Απώλειας ανά Εποχή G2Gat_100	90

Εξισώσεις

Εξίσωση 1 Τύπος Υπολογισμού Ακρίβειας.....	39
Εξίσωση 2 Τύπος Υπολογισμού Ακρίβειας Κατηγορίας	39
Εξίσωση 3 Τύπος Υπολογισμού Ανάκλησης.....	39
Εξίσωση 4 Τύπος Υπολογισμού F1 Score	40
Εξίσωση 5 Τύπος Υπολογισμού Καμπύλης ROC AUC.....	40

Abstract

Η ανίχνευση απάτης στις οικονομικές συναλλαγές αποτελεί κρίσιμο ζήτημα στον τομέα των χρηματοοικονομικών, καθώς η ταχεία ανάπτυξη της τεχνολογίας έχει αυξήσει τη συχνότητα και την πολυπλοκότητα των δόλιων δραστηριοτήτων. Οι παραδοσιακές μέθοδοι ανάλυσης δεδομένων συχνά αποδεικνύονται ανεπαρκείς για την αντιμετώπιση της αυξανόμενης πολυπλοκότητας αυτών των προβλημάτων. Σε αυτό το πλαίσιο, οι αλγόριθμοι μηχανικής μάθησης για γραφήματα (Graph Machine Learning) αναδεικνύονται ως μια καινοτόμος και ισχυρή προσέγγιση για την ανίχνευση απάτης, καθώς επιτρέπουν την αξιοποίηση των δομικών χαρακτηριστικών και των σχέσεων μεταξύ των δεδομένων.

Η παρούσα διατριβή εξετάζει την εφαρμογή των αλγορίθμων μηχανικής μάθησης για γραφήματα στην ανίχνευση απάτης στις οικονομικές συναλλαγές. Αναλύονται σύγχρονες τεχνικές όπως η Graph Neural Networks (GNNs), η Graph Convolutional Networks (GCNs), ενώ παράλληλα διερευνώνται τα πλεονεκτήματα και οι περιορισμοί τους σε πραγματικά σενάρια. Μέσα από την ενσωμάτωση χαρακτηριστικών όπως η τοπολογία του γραφήματος, η ανάλυση των συσχετίσεων και η δυναμική των δεδομένων, η διατριβή παρουσιάζει ένα πλαίσιο που στοχεύει στη βελτίωση της ακρίβειας και της αποτελεσματικότητας στην ανίχνευση δόλιων συναλλαγών.

Τα αποτελέσματα της έρευνας υποδεικνύουν ότι οι αλγόριθμοι μηχανικής μάθησης για γραφήματα μπορούν να αναδείξουν κρυμμένα μοτίβα απάτης, προσφέροντας ένα ισχυρό εργαλείο για την αντιμετώπιση της απάτης στις οικονομικές συναλλαγές. Η μελέτη καταλήγει με συστάσεις για μελλοντική έρευνα και πιθανές εφαρμογές σε βιομηχανικά περιβάλλοντα.

2. Εισαγωγή

2.1. Θεμελιώδεις Αρχές της Θεωρίας Γράφων

Η θεωρία γράφων αποτελεί έναν από τους πιο σημαντικούς και εκτεταμένους κλάδους των μαθηματικών και της επιστήμης των υπολογιστών. Η θεωρία αυτή εξετάζει τις σχέσεις και τις συνδέσεις μεταξύ αντικειμένων, που συχνά αναπαρίστανται με τη μορφή γράφων. Ένας γράφος συνίσταται από κόμβους (ή κορυφές) και ακμές (ή συνδέσεις), και μπορεί να μοντελοποιήσει περίπλοκα συστήματα και φαινόμενα σε διάφορους τομείς, όπως τα κοινωνικά δίκτυα, τα βιολογικά δίκτυα, τα συστήματα συναλλαγών και πολλά άλλα. Στην πιο απλή τους μορφή, οι κόμβοι αναπαριστούν οντότητες και οι ακμές τις συνδέσεις ή τις σχέσεις μεταξύ αυτών των οντοτήτων.

Για παράδειγμα, σε ένα κοινωνικό δίκτυο, κάθε κόμβος μπορεί να αντιπροσωπεύει έναν άνθρωπο, ενώ κάθε ακμή αποτυπώνει μια φιλία, αλληλεπίδραση ή κάποια άλλη μορφή σχέσης, όπως οικογενειακή ή επαγγελματική. Αντίστοιχα, σε ένα βιολογικό δίκτυο, οι κόμβοι μπορεί να αντιπροσωπεύουν γονίδια ή πρωτεΐνες, και οι ακμές τις αλληλεπιδράσεις μεταξύ αυτών των μορίων. Η θεωρία γράφων παρέχει τα εργαλεία και τις μεθόδους για την ανάλυση τέτοιων δικτύων και τη διερεύνηση των ιδιοτήτων τους.

Η μελέτη των γράφων, γνωστή ως "Θεωρία Γράφων", χρονολογείται από τον 18ο αιώνα, με την πρώτη σημαντική συμβολή να προέρχεται από τον Ελβετό μαθηματικό Λέοναρντ Όιλερ [1]. Ο Όιλερ έθεσε τα θεμέλια της θεωρίας γραφών μέσα από την εργασία του για την επίλυση του διάσημου μαθηματικού γρίφου των "Γεφυρών του Königsberg". Το πρόβλημα αυτό αφορούσε το αν ήταν δυνατόν να διασχίσει κανείς όλες τις γέφυρες της πόλης του Königsberg μία μόνο φορά χωρίς να ξαναπεράσει από καμία. Ο Όιλερ, χρησιμοποιώντας μια αναπαράσταση του προβλήματος ως γράφο, κατέδειξε ότι δεν υπάρχει λύση, και έτσι έθεσε τα θεμέλια για την ανάπτυξη της θεωρίας γραφών.

Με την πάροδο των χρόνων, η θεωρία γραφών εξελίχθηκε και επεκτάθηκε για να συμπεριλάβει πιο σύνθετες έννοιες και εφαρμογές. Οι κατευθυνόμενοι γράφοι (όπου οι ακμές έχουν κατεύθυνση) και οι μη κατευθυνόμενοι γράφοι (όπου οι ακμές δεν έχουν κατεύθυνση) αποτελούν βασικές κατηγορίες. Επίσης, οι γράφοι μπορούν να έχουν βάρη στις ακμές, που αντιπροσωπεύουν το κόστος ή την ισχύ των συνδέσεων. Πιο σύνθετες έννοιες περιλαμβάνουν τους κύκλους, τις διαδρομές, τη συνδεσιμότητα και τις κοινότητες μέσα σε ένα γράφο.

Η θεωρία γραφών έχει αποκτήσει σημαντική σημασία και εφαρμογές στη σύγχρονη εποχή, καθώς η υπολογιστική ισχύς έχει αυξηθεί και οι μεγάλες συλλογές δεδομένων έχουν γίνει κοινές. Οι γράφοι χρησιμοποιούνται πλέον για να δώσουν λύσεις σε περίπλοκα προβλήματα που δεν μπορούν να λυθούν με παραδοσιακούς τρόπους αναπαράστασης δεδομένων. Αυτές οι εφαρμογές περιλαμβάνουν την ανάλυση κοινωνικών δικτύων, την ανίχνευση απατών, τη βελτίωση των συστημάτων συστάσεων, και την ανακάλυψη φαρμάκων μέσω της ανάλυσης βιολογικών δικτύων.

2.2. Μηχανική Μάθηση σε Δεδομένα Γράφων

Η ανάγκη για την εφαρμογή μηχανικής μάθησης σε δεδομένα γραφών προέκυψε από την πολυπλοκότητα και τη δομή αυτών των δεδομένων. Οι παραδοσιακές μέθοδοι αναπαράστασης δεδομένων συχνά αποτυγχάνουν να αποδώσουν την πολύπλοκη και διασυνδεδεμένη φύση των πληροφοριών που εμπεριέχονται σε γράφους. Η μηχανική μάθηση, και ιδιαίτερα οι προηγμένες μέθοδοι όπως τα νευρωνικά δίκτυα για δεδομένα γραφών, προσφέρουν ισχυρά εργαλεία για την ανάλυση και την εξαγωγή πληροφορίας από αυτές τις περίπλοκες δομές.

Τα νευρωνικά δίκτυα γραφών [2] (Graph Neural Networks, GNNs), τα συνελικτικά δίκτυα γραφών [3] (Graph Convolutional Networks, GCNs), τα δίκτυα προσοχής με γράφους [4] (Graph Attention Networks, GATs), οι γραφο-αυτοκωδικοποιητές [5] (Graph Autoencoders) και οι μέθοδοι ενσωμάτωσης όπως το Node2Vec [6] είναι μερικές από τις τεχνικές που έχουν αναπτυχθεί για να αξιοποιήσουν την πληροφορία που περιέχεται σε γράφους. Αυτές οι μέθοδοι επιτρέπουν την αναπαράσταση των δεδομένων με τέτοιο τρόπο ώστε να αποκαλύπτονται οι κρυμμένες δομές και τα πρότυπα που δεν είναι εμφανή με παραδοσιακές μεθόδους.

Η ανάλυση τέτοιων δεδομένων έχει σημαντικές εφαρμογές στην κοινωνία, όπως η πρόβλεψη μοριακών αλληλεπιδράσεων για την ανακάλυψη φαρμάκων, η βελτίωση των συστημάτων συστάσεων και η ανάλυση και ανίχνευση απάτης σε χρηματοοικονομικές συναλλαγές. Οι τεχνικές μηχανικής μάθησης για δεδομένα γραφών συνεχίζουν να εξελίσσονται, προσφέροντας νέες δυνατότητες και εφαρμογές σε πολλούς τομείς της επιστήμης και της τεχνολογίας.

Το θέμα της συγκεκριμένης μεταπτυχιακής διατριβής είναι η εξερεύνηση και ανάπτυξη προηγμένων τεχνικών μηχανικής μάθησης προσαρμοσμένων για δεδομένα γραφών, με έμφαση στην ανίχνευση απάτης σε χρηματοοικονομικές συναλλαγές. Αυτό περιλαμβάνει την αναπαράσταση των δεδομένων των συναλλαγών ως γράφους, τον ορισμό των κόμβων και των ακμών, την εξαγωγή των χαρακτηριστικών των δεδομένων, και την εφαρμογή και αξιολόγηση διάφορων μοντέλων μηχανικής μάθησης.

Ο επόμενος στόχος είναι η ανάλυση των δεδομένων που θα παραχθούν με πληθώρα μοντέλων ώστε να γίνει σύγκριση και ανάλυση των μοντέλων ως προς τα αποτελέσματα, τον χρόνο εκπαίδευσης και εξαγωγής αποτελεσμάτων, καθώς και την απόδοση σε μεγάλα σύνολα δεδομένων. Στόχος είναι να καταλήξουμε στο πιο αποδοτικό μοντέλο μηχανικής μάθησης, αναλύοντας τα πλεονεκτήματα και τα μειονεκτήματα κάθε προσέγγισης. Είναι πολύ σημαντικό να σημειωθούν και οι προκλήσεις που θα πρέπει να ληφθούν υπόψη, όπως η ανισοροπία των δεδομένων και η προστασία της ιδιωτικότητας. Συνολικά, η διατριβή εστιάζει στη δημιουργία εφαρμόσιμων τεχνικών που θα μπορούν να ενσωματωθούν σε υπάρχοντα συστήματα συναλλαγών για την ανίχνευση και την πρόληψη απάτης.

3. Θεωρητική Ανάλυση

Η θεωρία γράφων [7] είναι ένας κλάδος των μαθηματικών που ασχολείται με τη μελέτη των γράφων, οι οποίοι είναι μαθηματικές δομές που χρησιμοποιούνται για να μοντελοποιούν σχέσεις μεταξύ αντικειμένων. Ένας γράφος G ορίζεται ως ένα διατεταγμένο ζεύγος (V, E) όπου V είναι ένα σύνολο κορυφών (ή κόμβων) και E είναι ένα σύνολο ακμών (ή συνδέσεων) μεταξύ ενός ζεύγους κορυφών. Όπως προαναφέρθηκε αυτός η θεωρία γράφων έχει τις ρίζες της στο έργο του Λέοναρντ Όιλερ [1] το 1736. Κατά τους αιώνες, η θεωρία γράφων έχει εξελιχθεί σημαντικά, παρέχοντας έναν πλούσιο θεωρητικό θεμέλιο και πρακτικά εργαλεία για την αντιμετώπιση πολύπλοκων προβλημάτων σε διάφορους κλάδους.

Οι γράφοι χρησιμοποιούνται εκτενώς για να αναπαραστήσουν και να αναλύσουν πολύπλοκα δίκτυα σε διάφορους τομείς όπως η επιστήμη των υπολογιστών, η βιολογία, οι κοινωνικές επιστήμες και οι μεταφορές. Στην επιστήμη των υπολογιστών, οι γράφοι είναι κρίσιμοι για τις δομές δεδομένων και τους αλγόριθμους, επιτρέποντας αποτελεσματικές λύσεις για προβλήματα που αφορούν τη συνδεσιμότητα των δικτύων, τις συντομότερες διαδρομές και την οργάνωση των δεδομένων. Για παράδειγμα, στη θεωρία δικτύων, οι γράφοι μοντελοποιούν τη δομή του Διαδικτύου, διευκολύνοντας τη βελτιστοποίηση της δρομολόγησης δεδομένων και την ανίχνευση αδυναμιών του δικτύου. Στη βιολογία, οι γράφοι αναπαριστούν μοριακές δομές και γενετικά δίκτυα, βοηθώντας στην κατανόηση των βιολογικών διαδικασιών και στην ανακάλυψη νέων φαρμάκων. Οι κοινωνικοί επιστήμονες χρησιμοποιούν τους γράφους για να αναλύσουν τα κοινωνικά δίκτυα, εντοπίζοντας επιδραστικά άτομα και μελετώντας τη διάδοση πληροφοριών ή ασθενειών. Στις μεταφορές, οι γράφοι μοντελοποιούν οδικά δίκτυα, βελτιστοποιώντας τη ροή της κυκλοφορίας και τον προγραμματισμό αποτελεσματικών διαδρομών. Ενώ στην οικονομία οι γράφοι χρησιμοποιούνται για να μοντελοποιήσουν την οικονομική κίνηση μεταξύ λογαριασμών ή οντοτήτων (εταιρειών, ανθρώπων) ώστε να μπορεί να εντοπιστεί ιστορικότητα και αυξημένη ασφάλεια.

Η ευελιξία των γράφων προκύπτει από την ικανότητά τους να αναπαριστούν ένα ευρύ φάσμα οντοτήτων και τις αλληλεπιδράσεις τους. Οι κορυφές (ή κόμβοι) μπορούν να αναπαραστήσουν διάφορα αντικείμενα, όπως άτομα, πόλεις, πρωτεΐνες ή ιστοσελίδες, ενώ οι ακμές αποτυπώνουν τις σχέσεις ή τις αλληλεπιδράσεις μεταξύ αυτών των αντικειμένων, όπως φιλικές σχέσεις, δρόμοι, χημικοί δεσμοί ή υπερσύνδεσμοι [8]. Αυτή η αφαίρεση επιτρέπει την εφαρμογή της θεωρίας γράφων σε πολλά προβλήματα του πραγματικού κόσμου, καθιστώντας την ένα ανεκτίμητο εργαλείο τόσο για θεωρητική έρευνα όσο και για πρακτικές εφαρμογές. Καθώς τα δεδομένα γίνονται ολοένα πιο πολύπλοκα και διασυνδεδεμένα, η σημασία της θεωρίας γράφων συνεχίζει να αυξάνεται, οδηγώντας σε εξελίξεις στην τεχνολογία, την επιστήμη και τη μηχανική.

Η σημασία της θεωρίας γράφων ενισχύεται περαιτέρω από την ενσωμάτωσή της με τις σύγχρονες μεθόδους υπολογισμού και ανάλυσης. Η ανάπτυξη αποδοτικών αλγορίθμων για τη διάσχιση γράφων, όπως η αναζήτηση σε βάθος (DFS) και η αναζήτηση σε πλάτος (BFS), έχει επιτρέψει τη συστηματική εξερεύνηση μεγάλων δικτύων. Προχωρημένοι αλγόριθμοι για την εύρεση συντομότερων διαδρομών, όπως οι αλγόριθμοι του Dijkstra

και του Bellman-Ford, είναι καθοριστικοί στην εφοδιαστική, τα συστήματα πλοήγησης και το σχεδιασμό δικτύων. Επιπλέον, η εμφάνιση της μηχανικής μάθησης και της τεχνητής νοημοσύνης έχει ανοίξει νέους δρόμους για τη θεωρία γράφων, με αλγορίθμους μάθησης βασισμένους σε γράφους, όπως τα Γραφήματα Νευρωνικών Δικτύων (GNNs), να προσφέρουν εξελιγμένα εργαλεία για την αναγνώριση προτύπων και την πρόβλεψη σε πολύπλοκα δίκτυα. Η συνεχής εξέλιξη της θεωρίας γράφων και των εφαρμογών της υπογραμμίζει τη σημασία της στην αντιμετώπιση των σύγχρονων προκλήσεων και την προώθηση της καινοτομίας σε πολλαπλούς τομείς.

3.1. Κατηγορίες Γραφών

- Μη Κατευθυνόμενοι Γράφοι:
 - **Ορισμός:** Σε έναν μη κατευθυνόμενο γράφο, οι ακμές δεν έχουν κατεύθυνση. Δηλαδή, η ακμή (u,v) είναι ίδια με την ακμή (v,u) . Αυτό σημαίνει ότι η σχέση μεταξύ των κορυφών είναι αμφίδρομη. [9] [8]
 - **Εφαρμογές:** Αυτοί οι γράφοι χρησιμοποιούνται για να αναπαραστήσουν αμφίδρομες σχέσεις, όπως η φιλία στα κοινωνικά δίκτυα, η συνεργασία σε ακαδημαϊκές δημοσιεύσεις και οι αμοιβαίες συνδέσεις στα δίκτυα επικοινωνίας.
- Κατευθυνόμενοι Γράφοι (Διγράμματα):
 - **Ορισμός:** Σε έναν κατευθυνόμενο γράφο, οι ακμές έχουν κατεύθυνση, που υποδηλώνεται με ένα βέλος. Η ακμή (u,v) είναι διαφορετική από την ακμή (v,u) . Αυτό σημαίνει ότι η σχέση μεταξύ των κορυφών έχει μια συγκεκριμένη κατεύθυνση. [9] [8]
 - **Εφαρμογές:** Οι κατευθυνόμενοι γράφοι είναι χρήσιμοι σε σενάρια όπου οι σχέσεις έχουν κατεύθυνση, όπως οι υπερσύνδεσμοι ιστοσελίδων, οι χρηματοοικονομικές συναλλαγές και τα δίκτυα παραπομπών.
- Γράφοι με Βάρη:
 - **Ορισμός:** Αυτοί οι γράφοι έχουν βάρη που σχετίζονται με τις ακμές, που αντιπροσωπεύουν το κόστος, το μήκος ή την ικανότητα της σύνδεσης. [9] [8]
 - **Εφαρμογές:** Οι γράφοι με βάρη είναι απαραίτητοι σε εφαρμογές όπως τα δίκτυα μεταφορών όπου οι αποστάσεις ή οι χρόνοι ταξιδιού είναι σχετικοί, τα προβλήματα ροής δικτύου και η κατανομή πόρων.
- Γράφοι χωρίς Βάρη:
 - **Ορισμός:** Σε γράφους χωρίς βάρος, όλες οι ακμές θεωρούνται ίσες, χωρίς να αποδίδεται ιδιαίτερο κόστος σε αυτές. [9] [8]

- **Εφαρμογές:** Αυτοί είναι απλούστερα μοντέλα για σχέσεις όπου η ισχύς ή η ικανότητα της σύνδεσης δεν αποτελεί παράγοντα, όπως απλές κοινωνικές συνδέσεις ή βασικές τοπολογίες δικτύων.
- **Bipartite Γράφοι (Διμερής Γράφος):**
 - **Ορισμός:** Ένας διμερής γράφος είναι ένας γράφος του οποίου οι κορυφές μπορούν να χωριστούν σε δύο διακριτά και ανεξάρτητα σύνολα U και V , ώστε κάθε ακμή να συνδέει μια κορυφή στο U με μια στο V . [9] [8]
 - **Εφαρμογές:** Αυτοί οι γράφοι χρησιμοποιούνται ευρέως για τη μοντελοποίηση σχέσεων μεταξύ δύο διαφορετικών κατηγοριών αντικειμένων, όπως σε συστήματα συστάσεων (π.χ. χρήστες και ταινίες), αναθέσεις εργασιών και προβλήματα ζεύξης.
- **Multigraph (Πολύγραφος):**
 - **Ορισμός:** Ένας πολύγραφος είναι ένας γράφος που μπορεί να έχει πολλαπλές ακμές (παράλληλες ακμές) μεταξύ του ίδιου ζεύγους κορυφών. [9] [8]
 - **Εφαρμογές:** Αυτά χρησιμοποιούνται σε δίκτυα μεταφορών όπου μπορεί να υπάρχουν πολλαπλές διαδρομές μεταξύ δύο τοποθεσιών και στη μοντελοποίηση δικτύων όπου υπάρχουν πολλαπλοί τύποι σχέσεων μεταξύ κόμβων καθώς και σε δίκτυα οικονομικών συναλλαγών.

3.2. Ιδιότητες και Μετρήσεις Γράφων

- **Βαθμός:**
 - **Ορισμός:** Ο βαθμός μιας κορυφής είναι ο αριθμός των ακμών που συνδέονται με αυτήν. Σε κατευθυνόμενους γράφους, διακρίνουμε μεταξύ εισερχόμενου βαθμού (αριθμός εισερχόμενων ακμών) και εξερχόμενου βαθμού (αριθμός εξερχόμενων ακμών). [9] [8]
 - **Εφαρμογές:** Οι μετρήσεις βαθμού κεντρικότητας καθορίζουν τη σημασία των κόμβων σε κοινωνικά δίκτυα. οι κόμβοι με υψηλό βαθμό μπορεί να είναι επιδραστικά άτομα ή κόμβοι σε δίκτυα μεταφορών.
- **Διαδρομή:**
 - **Ορισμός:** Μια διαδρομή σε έναν γράφο είναι μια ακολουθία ακμών που συνδέει μια ακολουθία διακριτών κορυφών. Το μήκος της διαδρομής είναι ο αριθμός των ακμών που περιέχει ή σε περίπτωση ενός γράφου με βάρη τότε είναι το σύνολο των βάρων. [9] [8]
 - **Εφαρμογές:** Οι αλγόριθμοι εύρεσης διαδρομών είναι κρίσιμοι για τη δρομολόγηση, τα συστήματα πλοήγησης και την ανάλυση ροής δικτύου.

- **Κύκλος:**
 - **Ορισμός:** Ένας κύκλος είναι μια διαδρομή που ξεκινά και τελειώνει στην ίδια κορυφή, με όλες τις άλλες κορυφές να είναι διακριτές. [9] [8]
 - **Εφαρμογές:** Η ανίχνευση κύκλων χρησιμοποιείται στο σχεδιασμό κυκλωμάτων, την ανάλυση βρόχων ανατροφοδότησης σε συστήματα και την ανίχνευση δόλιων βρόχων σε χρηματοοικονομικά δίκτυα.
- **Συνδεσιμότητα:**
 - **Ορισμός:** Ένας γράφος είναι συνδεδεμένος αν υπάρχει μια διαδρομή μεταξύ οποιουδήποτε ζεύγους κορυφών. Σε κατευθυνόμενους γράφους, ένας ισχυρά συνδεδεμένος γράφος είναι αυτός όπου υπάρχει μια κατευθυνόμενη διαδρομή από οποιαδήποτε κορυφή σε κάθε άλλη κορυφή. [9] [8]
 - **Εφαρμογές:** Η ανάλυση της συνδεσιμότητας του δικτύου είναι σημαντική για την εξασφάλιση της ανθεκτικότητας των δικτύων επικοινωνίας, τη μελέτη της διάδοσης της πληροφορίας ή των ασθενειών και τη διασφάλιση της αποδοτικότητας των μεταφορικών δικτύων.
- **Clustering Coefficient:**
 - **Ορισμός:** Αυτή η μέτρηση ποσοτικοποιεί τον βαθμό στον οποίο οι κορυφές σε έναν γράφο τείνουν να συμπλέκονται μεταξύ τους, απλούστερα ο συντελεστής αυτός μας δείχνει ποσό ομαδοποιημένος είναι ένας γράφος. [9] [8]
 - **Εφαρμογές:** Είναι ιδιαίτερα χρήσιμη στην ανάλυση κοινωνικών δικτύων για τον εντοπισμό σφιχτά δεμένων ομάδων, στα βιολογικά δίκτυα για την εύρεση λειτουργικών μονάδων και στην ανίχνευση δομών κοινοτήτων.
- **Μετρήσεις Κεντρικότητας:**
 - **Κεντρικότητα Βαθμού:** Μετρά τον αριθμό των άμεσων συνδέσεων που έχει ένας κόμβος. [9] [8]
 - **Κεντρικότητα Ενδιάμεσου Σημείου:** Ποσοτικοποιεί τον αριθμό των φορών που ένας κόμβος λειτουργεί ως γέφυρα κατά μήκος της συντομότερης διαδρομής μεταξύ δύο άλλων κόμβων. [8] [9]
 - **Κεντρικότητα Εγγύτητας:** Μετρά πόσο κοντά είναι ένας κόμβος σε όλες τις άλλες κορυφές του δικτύου. [9] [8]

- **Εφαρμογές:** Ο εντοπισμός επιδραστικών κόμβων σε κοινωνικά δίκτυα, βασικά σημεία υποδομών σε δίκτυα μεταφορών και κρίσιμων κόμβων σε δίκτυα επικοινωνιών.

3.3. Αλγόριθμοι για ανάλυση Γράφων

Η θεωρία γράφων περιλαμβάνει ένα σύνολο αλγορίθμων που αναπτύχθηκαν για την επίλυση ποικίλων προβλημάτων που σχετίζονται με τη δομή και τις ιδιότητες των γράφων. Αυτοί οι αλγόριθμοι είναι θεμελιώδεις για την κατανόηση και την ανάλυση των δικτύων και χρησιμοποιούνται ευρέως σε εφαρμογές που κυμαίνονται από τη βελτιστοποίηση διαδρομών και την ανίχνευση κοινοτήτων έως τη μηχανική μάθηση και τη βιοπληροφορική. Παρακάτω παρουσιάζονται μερικοί από τους πιο σημαντικούς αλγορίθμους στη θεωρία γράφων:

- Αναζήτηση κατά Βάθος (Depth-First Search - DFS) [10]:
 - **Περιγραφή:** Ο DFS είναι ένας αλγόριθμος στρατηγικής αναζήτησης που ξεκινά από μια αρχική κορυφή και εξερευνά όσο το δυνατόν περισσότερο κατά μήκος κάθε κλάδου πριν κάνει πίσω.
 - **Εφαρμογές:** Χρησιμοποιείται για την εύρεση συνδεδεμένων συνιστωσών, την ανίχνευση κύκλων και την επίλυση προβλημάτων όπως το λαβύρινθο.
 - **Πολυπλοκότητα:** $O(V+E)$
- Αναζήτηση κατά Πλάτος (Breadth-First Search - BFS) [10]:
 - **Περιγραφή:** Ο BFS είναι ένας αλγόριθμος στρατηγικής αναζήτησης που ξεκινά από μια αρχική κορυφή και εξερευνά όλες τις γειτονικές κορυφές πριν προχωρήσει στα επόμενα επίπεδα γειτόνων.
 - **Εφαρμογές:** Χρησιμοποιείται για την εύρεση της συντομότερης διαδρομής σε μη κατευθυνόμενους γράφους και για την επίλυση προβλημάτων που απαιτούν την εξέταση όλων των γειτόνων πρώτα.
 - **Πολυπλοκότητα:** $O(V+E)$
- Αλγόριθμος του Dijkstra [10]:
 - **Περιγραφή:** Αυτός ο αλγόριθμος βρίσκει τη συντομότερη διαδρομή από έναν αρχικό κόμβο σε όλους τους άλλους κόμβους ενός γράφου με μη αρνητικά βάρη ακμών.
 - **Εφαρμογές:** Χρησιμοποιείται σε δίκτυα μεταφορών για την εύρεση των πιο σύντομων διαδρομών, στα δίκτυα επικοινωνιών για τη δρομολόγηση δεδομένων και σε προβλήματα βελτιστοποίησης.

- **Πολυπλοκότητα:** $O((V + E)\log V)$
- Αλγόριθμος του Bellman-Ford [10]:
 - **Περιγραφή:** Αυτός ο αλγόριθμος βρίσκει τη συντομότερη διαδρομή από έναν αρχικό κόμβο σε όλους τους άλλους κόμβους, επιτρέποντας αρνητικά βάρη ακμών και ανιχνεύοντας αρνητικούς κύκλους.
 - **Εφαρμογές:** Χρησιμοποιείται σε οικονομικές εφαρμογές όπου μπορούν να εμφανιστούν αρνητικά βάρη (π.χ. κέρδος ή ζημία), και στην ανάλυση δρομολογήσεων με κόστος.
 - **Πολυπλοκότητα:** $O(VE)$
- Αλγόριθμος του Floyd-Warshall [10]:
 - **Περιγραφή:** Αυτός ο αλγόριθμος υπολογίζει τις συντομότερες διαδρομές μεταξύ όλων των ζευγών κόμβων σε έναν γράφο.
 - **Εφαρμογές:** Χρησιμοποιείται σε εφαρμογές που απαιτούν την εύρεση των βέλτιστων διαδρομών μεταξύ πολλαπλών ζευγών κόμβων, όπως τα δίκτυα επικοινωνιών και οι προσομοιώσεις κυκλοφορίας.
 - **Πολυπλοκότητα:** $O(V^3)$
- Αλγόριθμοι Ελαχίστης Κάλυψης Δέντρου (MST - Minimum Spanning Tree) [10]:
 - **Περιγραφή:** Αλγόριθμοι όπως του Kruskal και του Prim βρίσκουν ένα υποσύνολο των ακμών που σχηματίζουν ένα δέντρο που καλύπτει όλους τους κόμβους με το ελάχιστο δυνατό συνολικό βάρος.
 - **Εφαρμογές:** Χρησιμοποιούνται σε προβλήματα σχεδιασμού δικτύων, όπως η δημιουργία αποδοτικών δικτύων ηλεκτρικής ενέργειας, υδραυλικών δικτύων και δικτύων υπολογιστών.
 - **Πολυπλοκότητα:**
 - Kruskal: $O(E\log E)$
 - Prim: $O((V + E)\log V)$
- Αλγόριθμοι Ροής Δικτύου [10]:
 - **Περιγραφή:** Αλγόριθμοι όπως του Ford-Fulkerson και του Edmonds-Karp υπολογίζουν τη μέγιστη ροή από ένα αρχικό κόμβο σε ένα τελικό σε ένα δίκτυο.

- **Εφαρμογές:** Χρησιμοποιούνται στη βελτιστοποίηση ροής πόρων, όπως το νερό και το πετρέλαιο, και στην ανάλυση κοινωνικών δικτύων για την κατανόηση της διάδοσης πληροφορίας ή ασθενειών.
- **Πολυπλοκότητα:**
 - Ford-Fulkerson: $O(|f|E)$
 - Edmonds-Karp: $O(VE^2)$
- Αλγόριθμοι Εύρεσης Κοινοτήτων [11]:
 - **Περιγραφή:** Αυτοί οι αλγόριθμοι, όπως ο αλγόριθμος Lounvain και οι αλγόριθμοι ανάλυσης ανθεκτικότητας, αναγνωρίζουν υποομάδες μέσα σε ένα δίκτυο που είναι πιο πυκνά συνδεδεμένες μεταξύ τους.
 - **Εφαρμογές:** Χρησιμοποιούνται στην ανάλυση κοινωνικών δικτύων για τον εντοπισμό ομάδων με κοινά ενδιαφέροντα ή συμπεριφορές και στη βιολογία για την αναγνώριση λειτουργικών μονάδων σε γενετικά δίκτυα.
 - **Πολυπλοκότητα:** $O(V \log V)$
- Αλγόριθμοι Τυχαίας Διαδρομής (Random Walks) [12]:
 - **Περιγραφή:** Τυχαία περάσματα σε γράφους χρησιμοποιούνται για τη μοντελοποίηση και την ανάλυση της διάδοσης πληροφοριών ή ουσιών μέσα στο δίκτυο.
 - **Εφαρμογές:** Χρησιμοποιούνται στη μηχανική μάθηση για την αναγνώριση προτύπων, στη βιολογία για την κατανόηση της διάδοσης ουσιών μέσα σε κύτταρα και στην ανάλυση κοινωνικών δικτύων για την κατανόηση της διάδοσης της πληροφορίας.

Οι αλγόριθμοι αυτοί αποτελούν τη βάση της ανάλυσης των γράφων και της ανάπτυξης εφαρμογών που βασίζονται σε γράφους. Με τη συνεχή ανάπτυξη της θεωρίας γράφων και των σχετικών τεχνολογιών, οι αλγόριθμοι αυτοί θα συνεχίσουν να παίζουν κρίσιμο ρόλο στη βελτίωση της κατανόησης και της διαχείρισης των πολύπλοκων δικτύων που αποτελούν την υποδομή του σύγχρονου κόσμου. [10]

3.4. Παραδοσιακές Μέθοδοι Ανάλυσης Γράφων

Η παραδοσιακή ανάλυση γράφων περιλαμβάνει ένα σύνολο τεχνικών και μεθόδων που χρησιμοποιούνται για την κατανόηση και την ανάλυση της δομής και των ιδιοτήτων των γράφων. Αυτές οι μέθοδοι είναι βασικές για την κατανόηση της συμπεριφοράς των δικτύων και χρησιμοποιούνται σε ποικίλες εφαρμογές, από την κοινωνιολογία και την επιστήμη των υπολογιστών μέχρι τη βιολογία και την ανάλυση οικονομικών δεδομένων. Ακολουθεί μια εκτενής ανάλυση μερικών από τις πιο σημαντικές παραδοσιακές μεθόδους ανάλυσης γράφων:

3.5. Ανάλυση Κεντρικότητας (Centrality Analysis)

Η ανάλυση κεντρικότητας [13] στοχεύει στον εντοπισμό των πιο σημαντικών κόμβων σε έναν γράφο, βάσει διαφόρων μέτρων κεντρικότητας:

- **Βαθμός Κεντρικότητας (Degree Centrality):** Μετρά τον αριθμό των ακμών που συνδέονται με έναν κόμβο. Ένας κόμβος με υψηλό βαθμό κεντρικότητας θεωρείται σημαντικός λόγω του μεγάλου αριθμού των συνδέσεών του. Στους κατευθυνόμενους γράφους, διακρίνεται σε in-degree και out-degree κεντρικότητα.
- **Κεντρικότητα Εγγύτητας (Closeness Centrality):** Βασίζεται στην μέση απόσταση ενός κόμβου από όλους τους άλλους κόμβους στο γράφο. Ένας κόμβος με υψηλή κεντρικότητα εγγύτητας μπορεί να φτάσει γρήγορα σε άλλους κόμβους, υποδεικνύοντας την αποτελεσματικότητα στην επικοινωνία ή την διάδοση πληροφοριών.
- **Κεντρικότητα Μεσότητας (Betweenness Centrality):** Μετρά τον αριθμό των φορές που ένας κόμβος βρίσκεται στη συντομότερη διαδρομή μεταξύ δύο άλλων κόμβων. Κόμβοι με υψηλή κεντρικότητα μεσότητας λειτουργούν συχνά ως γέφυρες ή σημαντικοί μεσολαβητές στην επικοινωνία.
- **Κεντρικότητα Διάνυσματος (Eigenvector Centrality):** Ανιχνεύει την επιρροή ενός κόμβου με βάση τη σύνδεσή του με άλλους σημαντικούς κόμβους. Ένας κόμβος συνδεδεμένος με άλλους κόμβους υψηλής κεντρικότητας διάνυσματος έχει και ο ίδιος υψηλή κεντρικότητα διάνυσματος.

3.6. Ανάλυση Συνδεσιμότητας (Connectivity Analysis)

Η ανάλυση συνδεσιμότητας [8] εξετάζει πώς οι κόμβοι ενός γράφου συνδέονται μεταξύ τους και πόσο εύκολο είναι να μετακινηθεί κανείς από έναν κόμβο σε έναν άλλο. Βασικές μέθοδοι περιλαμβάνουν:

- **Συνδεδεμένες Συνιστώσες (Connected Components):** Προσδιορίζει υποσύνολα κορυφών που συνδέονται άμεσα μεταξύ τους, χωρίς να υπάρχουν ακμές εκτός αυτών των υποσυνόλων. Σε μη κατευθυνόμενους γράφους, κάθε κόμβος σε μια συνδεδεμένη συνιστώσα μπορεί να φτάσει σε οποιονδήποτε άλλο κόμβο της ίδιας συνιστώσας μέσω μιας διαδρομής.

- **Ισχυρές και Ασθενείς Συνιστώσες (Strongly and Weakly Connected Components):** Σε κατευθυνόμενους γράφους, μια ισχυρή συνιστώσα είναι μια υποομάδα κόμβων όπου υπάρχει κατευθυνόμενη διαδρομή μεταξύ κάθε ζεύγους κόμβων. Μια ασθενής συνιστώσα είναι μια υποομάδα όπου οι κόμβοι θα ήταν συνδεδεμένοι εάν αφαιρούνταν οι κατευθύνσεις των ακμών.
- **Επίπεδο Συνδεσιμότητας (K-Connectedness):** Μετρά πόσοι κόμβοι ή ακμές πρέπει να αφαιρεθούν για να καταστεί ένας γράφος μη συνδεδεμένος ή για να αυξηθεί ο αριθμός των συνδεδεμένων συνιστωσών. Ένας k-συνδεδεμένος γράφος απαιτεί την αφαίρεση τουλάχιστον k κόμβων για να διασπαστεί.

3.7. Αναγνώριση Κοινοτήτων (Community Detection)

Η αναγνώριση κοινοτήτων [10] στοχεύει στον εντοπισμό ομάδων κόμβων που είναι πιο πυκνά συνδεδεμένοι μεταξύ τους σε σχέση με το υπόλοιπο γράφο. Μερικές από τις δημοφιλείς μεθόδους περιλαμβάνουν:

- **Αλγόριθμος Louvain:** Βασισμένος στη βελτιστοποίηση της διαμόρφωσης (modularity), ο αλγόριθμος αυτός βρίσκει κοινότητες μεγιστοποιώντας την πυκνότητα των ακμών εντός των κοινοτήτων σε σχέση με τις ακμές εκτός αυτών.
- **Αλγόριθμος Girvan-Newman:** Επαναληπτικός αλγόριθμος που αφαιρεί τις ακμές με την υψηλότερη κεντρικότητα μεσότητας, διαχωρίζοντας σταδιακά τον γράφο σε μικρότερες κοινότητες.
- **Αλγόριθμος Infomap:** Χρησιμοποιεί την έννοια της τυχαίας διαδρομής και της συσσώρευσης πληροφορίας για να εντοπίσει κοινότητες, αποσκοπώντας στη δημιουργία μιας κωδικοποίησης που περιγράφει την τυχαία βόλτα μέσα στον γράφο.

3.8. Εξερεύνηση Δομής Δικτύου (Network Structure Exploration)

Η ανάλυση της δομής του δικτύου [8] εξετάζει την συνολική δομή του γράφου και τις διάφορες ιδιότητές του. Κάποιες από τις βασικές έννοιες περιλαμβάνουν:

- **Κατανομή Βαθμών (Degree Distribution):** Αναλύει την κατανομή των βαθμών των κόμβων ενός γράφου. Σε πολλά φυσικά και κοινωνικά δίκτυα, η κατανομή των βαθμών ακολουθεί νόμο δύναμης (power law), υποδηλώνοντας την ύπαρξη λίγων κόμβων με πολύ υψηλό βαθμό και πολλών κόμβων με χαμηλό βαθμό.
- **Διαμέτρημα και Διάμεσος Διαδρομής (Diameter and Average Path Length):** Το διαμέτρημα είναι το μέγιστο μήκος της συντομότερης διαδρομής μεταξύ δύο κόμβων. Η διάμεσος διαδρομής είναι ο μέσος όρος των αποστάσεων μεταξύ όλων των ζευγών κόμβων.

- **Clustering Coefficient:** Μετρά την πιθανότητα οι γείτονες ενός κόμβου να είναι επίσης γείτονες μεταξύ τους. Ένας υψηλός συντελεστής συσσωρευτικότητας υποδηλώνει την ύπαρξη "κοινοτήτων" ή "κοινωνικών κύκλων" μέσα στον γράφο.
- **Κόμπων και Διοδίων (Hubs and Authorities):** Οι κόμπωι είναι κόμβωι με υψηλό βαθμό, ενώ οι δίοδοι είναι κόμβωι που συνδέονται με πολλούς κόμβωυς υψηλού βαθμού. Η αναγνώριση των κόμπων και των διοδών βοηθά στην κατανόηση της επιρροής και της δομής του γράφου.

3.9. Αναλυτική Μέθοδοι Ροής (Flow Analysis Methods)

Η ανάλυση ροής [8] επικεντρώνεται στη μελέτη της κίνησης ή της ροής μέσα από έναν γράφο, κάτι που είναι σημαντικό σε δίκτυα όπως οι επικοινωνίες, οι μεταφορές και τα logistics:

- **Αλγόριθμοι Ροής Μέγιστης Χωρητικότητας (Max-Flow Algorithms):** Οι αλγόριθμοι αυτοί, όπως ο Ford-Fulkerson και ο Edmonds-Karp, υπολογίζουν τη μέγιστη ροή που μπορεί να περάσει από την πηγή στην κατάληξη σε έναν γράφο με χωρητικότητες στις ακμές.
- **Αλγόριθμοι Ελάχιστης Τομής (Min-Cut Algorithms):** Αυτοί οι αλγόριθμοι βρίσκουν τον τρόπο να χωριστεί ένας γράφος σε δύο ή περισσότερα μέρη με ελάχιστο κόστος. Η ελάχιστη τομή είναι χρήσιμη για την κατανόηση της ευθραυστότητας ενός δικτύου και την αναγνώριση των "ασθενών σημείων" του.
- **Αλγόριθμοι Ροής Κόστους (Cost-Flow Algorithms):** Επικεντρώνονται στην εξεύρεση της ροής με το χαμηλότερο συνολικό κόστος, κάτι που είναι κρίσιμο σε εφαρμογές logistics και οικονομικών δικτύων.

Αυτές οι παραδοσιακές μέθοδοι ανάλυσης γράφων προσφέρουν τα θεμέλια για την κατανόηση της πολυπλοκότητας και της δυναμικής των δικτύων, παρέχοντας τα εργαλεία για την ανάλυση και τη βελτιστοποίηση της απόδοσης σε ποικίλες εφαρμογές.

3.10. Μηχανική Μάθηση στην Ανάλυση Γράφων

Η μηχανική μάθηση σε γράφους έχει εξελιχθεί ραγδαία τα τελευταία χρόνια, παρέχοντας εργαλεία και μεθόδους για την ανάλυση πολύπλοκων και διασυνδεδεμένων δεδομένων. Η μηχανική μάθηση σε γράφους αξιοποιεί τις σχέσεις μεταξύ κόμβων και γράφων για να προσφέρει προγνωστική και αναλυτική ισχύ σε ποικίλες εφαρμογές, όπως η κοινωνική δικτύωση, η ανίχνευση απάτης σε οικονομικές συναλλαγές, η βιολογία και η επιστήμη των υλικών. Με την ανάπτυξη νέων τεχνικών, όπως τα Graph Neural Networks (GNNs), τα Graph Convolutional Networks (GCNs), και τα Graph Attention Networks (GATs), η ικανότητά μας να εξαγάγουμε πολύτιμες πληροφορίες από τα δεδομένα γραφικών έχει αυξηθεί σημαντικά.

Αυτές οι τεχνικές μηχανικής μάθησης επιτρέπουν την κατανόηση και την πρόβλεψη σύνθετων προτύπων και δομών που δεν θα ήταν εύκολα ανιχνεύσιμες με παραδοσιακές μεθόδους ανάλυσης δεδομένων. Ειδικότερα, οι γράφοι επιτρέπουν την αναπαράσταση δεδομένων με τρόπο που διατηρεί τις εγγενείς τους σχέσεις, κάτι που είναι κρίσιμο για εφαρμογές όπως η ανίχνευση κοινοτήτων σε κοινωνικά δίκτυα, η πρόβλεψη συνδέσεων, και η ανάλυση μοριακών δομών. Η κατανόηση και η αξιοποίηση αυτών των σύγχρονων τεχνικών μηχανικής μάθησης σε γράφους μπορεί να οδηγήσει σε βελτιωμένες λύσεις για πολύπλοκα προβλήματα πραγματικού κόσμου.

3.11. Graph Neural Networks (GNNs)

Τα Graph Neural Networks (GNNs) [2] είναι μια κατηγορία αλγορίθμων μηχανικής μάθησης που λειτουργούν απευθείας σε γράφους. Οι GNNs επιτρέπουν την αναπαράσταση και την εκμάθηση χαρακτηριστικών κόμβων και ακμών μέσω διαδοχικών ενημερώσεων που διαδίδονται στο γράφο. Οι βασικές αρχές των GNNs είναι:

1. **Αρχικοποίηση Χαρακτηριστικών Κόμβων (Node Feature Initialization):** Κάθε κόμβος ξεκινά με ένα σύνολο χαρακτηριστικών, τα οποία μπορεί να είναι δεδομένα που αντιπροσωπεύουν ιδιότητες του κόμβου.
2. **Πέρασμα Μηνυμάτων (Message-Passing):** Σε κάθε επανάληψη, οι κόμβοι ανταλλάσσουν πληροφορίες με τους γείτονές τους. Η διαδικασία αυτή επιτρέπει τη συλλογή πληροφορίας από τοπικές γειτονιές.
3. **Ενημέρωση Χαρακτηριστικών (Feature Update):** Τα μηνύματα από τους γείτονες συνδυάζονται για να ενημερωθούν τα χαρακτηριστικά των κόμβων.
4. **Συγκέντρωση (Aggregation):** Οι ενημερωμένες πληροφορίες συνοψίζονται για να δημιουργηθούν οι τελικές αναπαραστάσεις των κόμβων.

Οι GNNs είναι πολύ αποτελεσματικοί για προβλήματα όπως η κατηγοριοποίηση κόμβων, η πρόβλεψη συνδέσεων και η κατηγοριοποίηση ολόκληρων γράφων.

3.12. Graph Convolutional Networks (GCNs)

Τα Graph Convolutional Networks (GCNs) [3] είναι μια ειδική κατηγορία των GNNs που εφαρμόζουν τη διαδικασία της συνέλιξης (convolution) σε γράφους. Η βασική ιδέα πίσω από τα GCNs είναι η επέκταση των παραδοσιακών συνελκτικών νευρωνικών δικτύων (CNNs) για τη διαχείριση μη ευκλείδειων δεδομένων όπως οι γράφοι. Οι κύριες ιδιότητες των GCNs περιλαμβάνουν:

1. **Συνέλιξη σε Γράφους (Graph Convolution):** Η συνέλιξη εφαρμόζεται στους κόμβους και τους γείτονές τους, επιτρέποντας την ενσωμάτωση τοπικών και γειτονικών πληροφοριών.
2. **Πολλαπλά Στρώματα (Multiple Layers):** Τα GCNs αποτελούνται από πολλά συνελκτικά στρώματα που επιτρέπουν τη συλλογή πληροφορίας από απομακρυσμένες γειτονιές του γράφου.
3. **Κανονικοποίηση (Normalization):** Η συνέλιξη στους γράφους κανονικοποιείται για να διασφαλιστεί ότι οι συνεισφορές των γειτόνων στα χαρακτηριστικά ενός κόμβου είναι αναλογικά σταθερές.

Τα GCNs έχουν εφαρμογές σε πολλούς τομείς, όπως η ανίχνευση κοινοτήτων, η πρόβλεψη συνδέσεων, και η κατηγοριοποίηση μοριακών δομών.

3.13. Graph Attention Networks (GATs)

Τα Graph Attention Networks (GATs) [4] είναι μια επέκταση των GNNs που χρησιμοποιούν μηχανισμούς προσοχής (attention mechanisms) για να ενισχύσουν τη διαδικασία της ενημέρωσης χαρακτηριστικών. Τα GATs επιτρέπουν στους κόμβους να μετρούν τις εισροές από τους γείτονές τους βάσει της σημασίας τους. Οι βασικές αρχές των GATs περιλαμβάνουν:

1. **Μηχανισμός Προσοχής (Attention Mechanism):** Κατά την ανταλλαγή πληροφοριών, κάθε κόμβος υπολογίζει έναν συντελεστή προσοχής για κάθε γείτονα, καθορίζοντας πόση σημασία θα δώσει στις εισερχόμενες πληροφορίες.
2. **Προσαρμοστικότητα (Adaptability):** Οι συντελεστές προσοχής είναι προσαρμόσιμοι και μαθαίνονται κατά την εκπαίδευση του δικτύου, επιτρέποντας την καλύτερη προσαρμογή στις ανάγκες των δεδομένων.
3. **Ενσωμάτωση (Aggregation):** Οι προσαρμοσμένοι συντελεστές προσοχής χρησιμοποιούνται για τη ζύγιση και την ενσωμάτωση των μηνυμάτων από τους γείτονες.

Οι GATs είναι ιδιαίτερα χρήσιμοι σε προβλήματα όπου η σημασία των σχέσεων μεταξύ κόμβων ποικίλλει και χρειάζεται να ληφθεί υπόψη κατά την ανάλυση του γράφου.

3.14. Graph Autoencoders

Οι Graph Autoencoders [5] είναι ένας τύπος νευρωνικών δικτύων που χρησιμοποιούνται για την αναπαράσταση και την ανακατασκευή γράφων. Η βασική ιδέα είναι να μάθουν χαμηλής διάστασης ενσωματώσεις (embeddings) των κόμβων που μπορούν να χρησιμοποιηθούν για αναπαράσταση και ανακατασκευή του γράφου. Οι κύριες αρχές των Graph Autoencoders περιλαμβάνουν:

1. **Κωδικοποίηση (Encoding):** Οι κόμβοι κωδικοποιούνται σε χαμηλής διάστασης χώρους μέσω ενός νευρωνικού δικτύου.
2. **Αποκωδικοποίηση (Decoding):** Οι χαμηλής διάστασης ενσωματώσεις χρησιμοποιούνται για την ανακατασκευή του αρχικού γράφου.
3. **Απώλεια Ανακατασκευής (Reconstruction Loss):** Ο αλγόριθμος εκπαιδεύεται ώστε να ελαχιστοποιεί την απώλεια ανακατασκευής, η οποία μετρά τη διαφορά μεταξύ του αρχικού και του ανακατασκευασμένου γράφου.

Οι Graph Autoencoders χρησιμοποιούνται σε εφαρμογές όπως η μείωση διαστάσεων, η ανίχνευση ανωμαλιών και η συμπίεση δεδομένων.

3.15. Node2Vec και Άλλες Μέθοδοι Ενσωμάτωσης (Embedding Methods)

Οι μέθοδοι ενσωμάτωσης γράφων στοχεύουν στη μετατροπή των κόμβων σε συνεχή διανύσματα που διατηρούν τις εγγενείς δομικές ιδιότητες του γράφου. Το Node2Vec [6] είναι μια από τις πιο δημοφιλείς μεθόδους ενσωμάτωσης και βασίζεται στη δημιουργία τυχαίων περασμάτων (random walks) στους κόμβους για την εκμάθηση των ενσωματώσεων. Οι κύριες αρχές των μεθόδων ενσωμάτωσης περιλαμβάνουν:

1. **Δημιουργία Τυχαίων Περασμάτων (Random Walk Generation):** Πραγματοποιούνται τυχαία περάσματα στους κόμβους του γράφου για τη συλλογή των αλληλεπιδράσεων μεταξύ τους.
2. **Βελτιστοποίηση Λέξεων (Word2Vec Optimization):** Οι αλληλεπιδράσεις από τα τυχαία περάσματα χρησιμοποιούνται ως είσοδοι για αλγορίθμους βελτιστοποίησης λέξεων, όπως το Word2Vec, για την εκμάθηση των ενσωματώσεων.
3. **Προσαρμοστικότητα (Adaptability):** Οι μέθοδοι ενσωμάτωσης μπορούν να προσαρμοστούν για να διατηρούν συγκεκριμένες δομικές ιδιότητες, όπως η κοινότητα και η απόσταση μεταξύ κόμβων.

Οι μέθοδοι ενσωμάτωσης είναι χρήσιμες για ποικίλες εφαρμογές, όπως η κατηγοριοποίηση κόμβων, η πρόβλεψη συνδέσεων και η ανάλυση δικτύου.

Συνολικά, οι τεχνικές μηχανικής μάθησης σε γράφους παρέχουν ισχυρά εργαλεία για την ανάλυση και την εκμάθηση από σύνθετα και διασυνδεδεμένα δεδομένα. Οι μέθοδοι αυτές συνεχίζουν να εξελίσσονται, προσφέροντας νέες δυνατότητες και εφαρμογές σε πολλούς τομείς της επιστήμης και της τεχνολογίας.

4. Μεθοδολογία

Η μεθοδολογία αποτελεί τον πυρήνα κάθε επιστημονικής έρευνας, καθώς καθορίζει τα βήματα και τις τεχνικές που θα χρησιμοποιηθούν για την επίτευξη των στόχων της μελέτης. Σε αυτή τη διατριβή, η μεθοδολογία περιλαμβάνει τη συστηματική συλλογή και ανάλυση δεδομένων συναλλαγών, την αναπαράστασή τους ως γράφους, και την εφαρμογή προηγμένων τεχνικών μηχανικής μάθησης για την ανίχνευση απάτης. Αρχικά, θα γίνει συλλογή δεδομένων από διάφορες πηγές, όπως τράπεζες και οικονομικά ιδρύματα, εξασφαλίζοντας την ανωνυμοποίηση και την προστασία της ιδιωτικότητας των δεδομένων. Αυτά τα δεδομένα θα περιλαμβάνουν πληροφορίες σχετικά με τις συναλλαγές, όπως ποσά, χρονικά σημεία, και πληροφορίες για τους συμμετέχοντες. Στη συνέχεια, τα δεδομένα θα μετατραπούν σε μορφή γράφου, όπου οι κόμβοι θα αντιπροσωπεύουν τους συμμετέχοντες στις συναλλαγές και οι ακμές θα αντιπροσωπεύουν τις συναλλαγές μεταξύ τους. Αυτή η αναπαράσταση θα επιτρέψει την ανάλυση των σχέσεων και των προτύπων που εμφανίζονται στις συναλλαγές, αποκαλύπτοντας πιθανές περιπτώσεις απάτης.

Μετά τη μετατροπή των δεδομένων σε γράφους, θα ακολουθήσει η εφαρμογή και η εκπαίδευση διαφόρων αλγορίθμων μηχανικής μάθησης για την ανίχνευση απάτης. Οι αλγόριθμοι αυτοί περιλαμβάνουν νευρωνικά δίκτυα γράφων (Graph Neural Networks, GNNs), συνελικτικά δίκτυα γράφων (Graph Convolutional Networks, GCNs), δίκτυα προσοχής σε γράφους (Graph Attention Networks, GATs), και γραφο-αυτοκωδικοποιητές (Graph Autoencoders). Κάθε μοντέλο θα εκπαιδευτεί χρησιμοποιώντας ένα σύνολο εκπαίδευσης και θα αξιολογηθεί χρησιμοποιώντας ένα σύνολο δοκιμής για την αξιολόγηση της ακρίβειας, της ευαισθησίας και της εξειδίκευσής του. Η ανάλυση των αποτελεσμάτων θα περιλαμβάνει τη σύγκριση των μοντέλων ως προς την απόδοσή τους στην ανίχνευση απάτης, τον χρόνο εκπαίδευσης και την ικανότητά τους να διαχειρίζονται μεγάλα σύνολα δεδομένων. Επιπλέον, θα ληφθούν υπόψη και οι προκλήσεις που συνδέονται με την ανισορροπία των δεδομένων, δηλαδή την παρουσία πολύ λιγότερων περιπτώσεων απάτης σε σχέση με τις κανονικές συναλλαγές, και θα εξεταστούν τεχνικές για την αντιμετώπιση αυτών των προκλήσεων, όπως η χρήση τεχνικών υπερδειγματοληψίας ή υποδειγματοληψίας. Τέλος, θα διερευνηθούν τρόποι ενσωμάτωσης των ανεπτυγμένων μοντέλων σε υπάρχοντα συστήματα συναλλαγών, με στόχο την αποτελεσματική και αξιόπιστη ανίχνευση απάτης σε πραγματικό χρόνο.

4.1. Μέθοδοι Συλλογής Δεδομένων

Η συλλογή δεδομένων αποτελεί ένα κρίσιμο στάδιο σε κάθε ερευνητικό έργο, καθώς τα δεδομένα αποτελούν τη βάση για όλες τις αναλύσεις και τα συμπεράσματα που θα προκύψουν. Στην περίπτωση της παρούσας διατριβής, η οποία επικεντρώνεται στην ανίχνευση απάτης σε χρηματοοικονομικές συναλλαγές, η συλλογή δεδομένων πρέπει να

είναι προσεκτικά σχεδιασμένη για να εξασφαλίσει την ακρίβεια και την πληρότητα των δεδομένων. Η διαδικασία συλλογής δεδομένων μπορεί να περιλαμβάνει διάφορες μεθόδους, όπως η πρόσβαση σε υπάρχουσες βάσεις δεδομένων, η συνεργασία με οικονομικά ιδρύματα, και η χρήση δημόσια διαθέσιμων συνόλων δεδομένων.

- Πρόσβαση σε Υφιστάμενες Βάσεις Δεδομένων

Μία από τις κύριες πηγές δεδομένων για την έρευνα αυτή είναι οι υπάρχουσες βάσεις δεδομένων από τράπεζες και άλλα χρηματοοικονομικά ιδρύματα. Αυτές οι βάσεις δεδομένων περιέχουν λεπτομερείς πληροφορίες για συναλλαγές, όπως τα ποσά, τις ημερομηνίες, τους λογαριασμούς που εμπλέκονται, και άλλες σχετικές πληροφορίες. Η πρόσβαση σε αυτές τις βάσεις δεδομένων απαιτεί συνήθως συνεργασία με τα εν λόγω ιδρύματα και συμφωνίες για την προστασία της ιδιωτικότητας και την ανωνυμοποίηση των δεδομένων. Η ανωνυμοποίηση είναι κρίσιμη για την προστασία των προσωπικών πληροφοριών των πελατών και την τήρηση των κανονισμών προστασίας δεδομένων. Τα δεδομένα που συλλέγονται με αυτόν τον τρόπο θα χρησιμοποιηθούν για την εκπαίδευση και την αξιολόγηση των αλγορίθμων μηχανικής μάθησης.

- Δημόσια Διαθέσιμα Σύνολα Δεδομένων

Εκτός από τις ιδιωτικές βάσεις δεδομένων, υπάρχουν και δημόσια διαθέσιμα σύνολα δεδομένων που μπορούν να χρησιμοποιηθούν για την έρευνα. Αυτά τα σύνολα δεδομένων συχνά δημοσιεύονται από ερευνητικά ιδρύματα, κυβερνητικούς οργανισμούς, ή διαγωνισμούς ανίχνευσης απάτης, όπως το διαγωνισμό Kaggle. Αυτά τα σύνολα δεδομένων περιλαμβάνουν συχνά ανωνυμοποιημένες πληροφορίες για συναλλαγές και είναι πολύτιμα για την αρχική εκπαίδευση των αλγορίθμων και τη σύγκριση των αποτελεσμάτων με άλλες μεθόδους. Η χρήση δημόσιων δεδομένων επιτρέπει επίσης τη διασφάλιση της αναπαραγωγιμότητας των αποτελεσμάτων και τη σύγκριση με άλλες μελέτες στον ίδιο τομέα.

- Συνεργασία με Οικονομικά Ιδρύματα

Η συνεργασία με οικονομικά ιδρύματα είναι απαραίτητη για την πρόσβαση σε εξειδικευμένα και τρέχοντα δεδομένα συναλλαγών. Αυτή η συνεργασία μπορεί να περιλαμβάνει συμφωνίες με τράπεζες, πιστωτικούς οργανισμούς, ή άλλες χρηματοοικονομικές υπηρεσίες για την παροχή δεδομένων σε ανώνυμη μορφή. Η συνεργασία αυτή προσφέρει την ευκαιρία να δουλέψει κανείς με πραγματικά και ενημερωμένα δεδομένα, που περιλαμβάνουν τις τελευταίες τάσεις και μοτίβα απάτης. Η

πρόσβαση σε πραγματικά δεδομένα είναι κρίσιμη για την ανάπτυξη και την αξιολόγηση αποτελεσματικών μοντέλων ανίχνευσης απάτης που θα μπορούν να εφαρμοστούν σε πραγματικό περιβάλλον.

Η συλλογή δεδομένων, λοιπόν, αποτελεί ένα πολυσύνθετο και καθοριστικό στάδιο της έρευνας, που απαιτεί προσεκτικό σχεδιασμό και συνεργασία με διάφορους φορείς. Μέσω της προσεκτικής επιλογής των πηγών δεδομένων και της εξασφάλισης της ποιότητάς τους, η έρευνα θα μπορέσει να αναπτύξει ακριβείς και αξιόπιστους αλγορίθμους ανίχνευσης απάτης που θα έχουν πρακτική εφαρμογή στον χρηματοοικονομικό τομέα.

4.2. Προεπεξεργασία Δεδομένων

Η προεπεξεργασία δεδομένων είναι ένα κρίσιμο βήμα στην ανάλυση δεδομένων και την ανάπτυξη αλγορίθμων μηχανικής μάθησης, καθώς εξασφαλίζει την ποιότητα και την καταλληλότητα των δεδομένων για τη διαδικασία της μάθησης. Στην παρούσα διατριβή, η οποία επικεντρώνεται στην ανίχνευση απάτης σε χρηματοοικονομικές συναλλαγές, η προεπεξεργασία δεδομένων περιλαμβάνει διάφορα στάδια, από τον καθαρισμό των δεδομένων και την αντιμετώπιση των ελλιπών τιμών, μέχρι την κανονικοποίηση και τη μετατροπή των δεδομένων σε μορφή κατάλληλη για αναπαράσταση ως γράφοι.

- **Καθαρισμός Δεδομένων και Αντιμετώπιση Ελλιπών Τιμών**

Ο καθαρισμός των δεδομένων είναι το πρώτο βήμα της προεπεξεργασίας και περιλαμβάνει την αφαίρεση ή τη διόρθωση λανθασμένων ή μη έγκυρων καταχωρήσεων. Τα δεδομένα συναλλαγών μπορεί να περιέχουν λάθη λόγω ανθρώπινου σφάλματος ή τεχνικών προβλημάτων κατά τη συλλογή τους. Η αντιμετώπιση των ελλιπών τιμών είναι επίσης ζωτικής σημασίας, καθώς οι ελλιπείς τιμές μπορούν να επηρεάσουν την ακρίβεια των αλγορίθμων μηχανικής μάθησης. Οι τεχνικές για την αντιμετώπιση των ελλιπών τιμών περιλαμβάνουν την αντικατάσταση των ελλιπών τιμών με μέσες ή μεσαίες τιμές, την πρόβλεψη των ελλιπών τιμών μέσω άλλων διαθέσιμων δεδομένων, ή την αφαίρεση των καταχωρήσεων με ελλιπείς τιμές.

- **Κανονικοποίηση και Κλιμάκωση Δεδομένων**

Η κανονικοποίηση και η κλιμάκωση των δεδομένων είναι απαραίτητες για να εξασφαλιστεί ότι τα δεδομένα είναι συγκρίσιμα και μπορούν να επεξεργαστούν αποτελεσματικά από τους αλγορίθμους μηχανικής μάθησης. Αυτό περιλαμβάνει τη μετατροπή των δεδομένων σε μια κοινή κλίμακα, έτσι ώστε οι τιμές διαφορετικών χαρακτηριστικών να έχουν παρόμοια τάξη μεγέθους. Η κανονικοποίηση μπορεί να γίνει με διάφορους τρόπους, όπως η μετατροπή των τιμών σε εύρος μεταξύ 0 και 1, ή η χρήση της τυπικής βαθμολογίας (z-score) που κανονικοποιεί τα δεδομένα βάσει της μέσης τιμής και της τυπικής απόκλισης.

- Αναπαράσταση Δεδομένων ως Γράφοι

Μετά τον καθαρισμό και την κανονικοποίηση, τα δεδομένα πρέπει να αναπαρασταθούν ως γράφοι για την εφαρμογή των αλγορίθμων μηχανικής μάθησης σε δεδομένα γραφών. Στην περίπτωση των χρηματοοικονομικών συναλλαγών, οι κόμβοι του γράφου μπορούν να αντιπροσωπεύουν τους πελάτες ή τους λογαριασμούς, ενώ οι ακμές μπορούν να αντιπροσωπεύουν τις συναλλαγές μεταξύ αυτών. Η αναπαράσταση αυτή επιτρέπει την ανάλυση των σχέσεων και των μοτίβων που εμφανίζονται στις συναλλαγές, και διευκολύνει την ανίχνευση μη φυσιολογικών δραστηριοτήτων που μπορεί να υποδηλώνουν απάτη. Για παράδειγμα, η συχνότητα και η κατεύθυνση των συναλλαγών, καθώς και τα ποσά των συναλλαγών, μπορούν να χρησιμοποιηθούν ως χαρακτηριστικά του γράφου.

- Εξαγωγή και Μείωση Χαρακτηριστικών

Η εξαγωγή χαρακτηριστικών είναι ένα κρίσιμο στάδιο στην προεπεξεργασία, κατά το οποίο εξάγονται σημαντικές πληροφορίες από τα δεδομένα για τη βελτίωση της απόδοσης των αλγορίθμων μηχανικής μάθησης. Στην ανίχνευση απάτης, τα χαρακτηριστικά αυτά μπορεί να περιλαμβάνουν την ανάλυση της δομής του γράφου, όπως ο βαθμός των κόμβων, η κεντρικότητα. Επιπλέον, μπορεί να χρησιμοποιηθούν τεχνικές μείωσης χαρακτηριστικών, όπως η ανάλυση κύριων συνιστωσών (PCA), για να μειωθεί η διάσταση των δεδομένων και να βελτιωθεί η απόδοση των μοντέλων.

- Αντιμετώπιση Ανισορροπίας Δεδομένων

Η ανισορροπία των δεδομένων είναι μια κοινή πρόκληση στην ανίχνευση απάτης, καθώς οι περιπτώσεις απάτης είναι συνήθως πολύ λιγότερες σε σχέση με τις κανονικές συναλλαγές. Για να αντιμετωπιστεί αυτή η ανισορροπία, μπορούν να χρησιμοποιηθούν τεχνικές όπως η υπερδειγματοληψία των περιπτώσεων απάτης, η υποδειγματοληψία των κανονικών συναλλαγών, ή η χρήση τεχνικών όπως το Synthetic Minority Over-sampling Technique (SMOTE) που δημιουργεί συνθετικά παραδείγματα των λιγότερο αντιπροσωπευμένων κατηγοριών.

Η προεπεξεργασία των δεδομένων, λοιπόν, αποτελεί ένα πολυσύνθετο και καθοριστικό στάδιο για την επιτυχία της ανίχνευσης απάτης σε χρηματοοικονομικές συναλλαγές. Μέσω της προσεκτικής και συστηματικής προεπεξεργασίας, τα δεδομένα καθίστανται κατάλληλα για την εφαρμογή προηγμένων τεχνικών μηχανικής μάθησης, εξασφαλίζοντας την ακρίβεια και την αξιοπιστία των αποτελεσμάτων.

4.3. Εξαγωγή Χαρακτηριστικών

Η εξαγωγή χαρακτηριστικών αποτελεί ένα από τα πιο κρίσιμα βήματα στην ανάπτυξη αλγορίθμων μηχανικής μάθησης, καθώς καθορίζει ποια δεδομένα θα χρησιμοποιηθούν για την εκπαίδευση και την αξιολόγηση των μοντέλων. Η εξαγωγή χαρακτηριστικών περιλαμβάνει τον εντοπισμό και την επιλογή των πιο αντιπροσωπευτικών και σχετικών

δεδομένων που θα βοηθήσουν στην αναγνώριση ανώμαλων και ύποπτων δραστηριοτήτων. Οι τεχνικές εξαγωγής χαρακτηριστικών μπορεί να περιλαμβάνουν την ανάλυση της δομής του γράφου, τη μετασχηματισμό των δεδομένων και τη χρήση προηγμένων μεθόδων για την εξαγωγή πληροφοριών από πολύπλοκα και μεγάλα σύνολα δεδομένων.

- Ανάλυση Δομής Γράφου

Ένας από τους βασικούς τρόπους εξαγωγής χαρακτηριστικών από δεδομένα γραφών είναι η ανάλυση της δομής του γράφου. Οι χαρακτηρισμοί αυτοί μπορεί να περιλαμβάνουν μετρικές όπως:

- **Βαθμός Κόμβου:** Ο αριθμός των ακμών που συνδέονται με έναν κόμβο. Οι κόμβοι με υψηλό βαθμό μπορεί να αντιπροσωπεύουν πελάτες με πολλές συναλλαγές, ενώ οι κόμβοι με χαμηλό βαθμό μπορεί να είναι λιγότερο ενεργοί.

- **Κεντρικότητα:** Μετρικές όπως η κεντρικότητα βαθμού, η ενδιάμεση κεντρικότητα και η εγγύτητα μπορούν να χρησιμοποιηθούν για να κατανοηθεί η σημασία ή η επιρροή ενός κόμβου μέσα στο δίκτυο συναλλαγών.

- Μετασχηματισμός Δεδομένων

Οι μετασχηματισμοί δεδομένων είναι απαραίτητοι για να δημιουργήσουν επιπρόσθετα χαρακτηριστικά που μπορεί να μην είναι άμεσα εμφανή από τα αρχικά δεδομένα. Για παράδειγμα, μπορούμε να δημιουργήσουμε νέα χαρακτηριστικά συνδυάζοντας υπάρχοντα δεδομένα συναλλαγών:

- **Συνολική Αξία Συναλλαγών:** Ο συνολικός όγκος ή αξία των συναλλαγών για κάθε κόμβο σε μια δεδομένη χρονική περίοδο.

- **Συχνότητα Συναλλαγών:** Ο αριθμός των συναλλαγών που εκτελούνται από έναν κόμβο σε μια συγκεκριμένη χρονική περίοδο, που μπορεί να αποκαλύψει ύποπτες συμπεριφορές αν παρουσιάζει ξαφνικές αυξήσεις.

- **Απόσταση Συναλλαγών:** Η ανάλυση των γεωγραφικών ή χρονικών αποστάσεων μεταξύ συναλλαγών για να εντοπιστούν ασυνήθιστα μοτίβα που μπορεί να υποδηλώνουν απάτη.

- Χρήση Προηγμένων Μεθόδων Εξαγωγής Χαρακτηριστικών

Προηγμένες μέθοδοι, όπως οι αλγόριθμοι ενσωμάτωσης γραφών (graph embeddings), μπορούν να χρησιμοποιηθούν για να εξάγουν πολυδιάστατα χαρακτηριστικά που αποτυπώνουν την πολυπλοκότητα και τη δομή του γράφου σε χαμηλότερη διάσταση. Αυτές οι μέθοδοι περιλαμβάνουν:

- **Node2Vec:** Ένας αλγόριθμος που μαθαίνει χαμηλής διάστασης ενσωματώσεις για κόμβους σε γράφους, διατηρώντας την πληροφορία της γειτνίασης και των τυχαίων περιπάτων.

- **DeepWalk:** Μια μέθοδος που βασίζεται σε τυχαίους περιπάτους για την εκμάθηση ενσωματώσεων, επιτρέποντας την αναπαράσταση των κόμβων σε χαμηλότερη διάσταση.

- **Graph Neural Networks (GNNs)**: Προηγμένα νευρωνικά δίκτυα που μπορούν να μάθουν αντιπροσωπευτικές ενσωματώσεις για κόμβους και ακμές, ενσωματώνοντας πληροφορίες από τη δομή του γράφου.

4.4. Αντιμετώπιση της Ανισορροπίας Δεδομένων [14]

- Υπερδειγματοληψία (Oversampling)

Η υπερδειγματοληψία περιλαμβάνει την αύξηση του αριθμού των δειγμάτων της μειονεκτικής κατηγορίας, ώστε να εξισορροπηθεί η κατανομή των δεδομένων. Υπάρχουν διάφορες μέθοδοι υπερδειγματοληψίας, με πιο δημοφιλείς τις εξής:

- Απλή Υπερδειγματοληψία (Simple Oversampling)
 - Η απλούστερη μέθοδος υπερδειγματοληψίας είναι η τυχαία αντιγραφή υπαρχόντων δειγμάτων της μειονεκτικής κατηγορίας.
 - **Πλεονεκτήματα**: Απλή και εύκολη στην εφαρμογή.
 - **Μειονεκτήματα**: Μπορεί να οδηγήσει σε υπερπροσαρμογή (overfitting) καθώς τα ίδια δείγματα επαναλαμβάνονται.
- Adaptive Synthetic Sampling (ADASYN) [15]
 - Το ADASYN είναι μια παραλλαγή του SMOTE που δημιουργεί περισσότερα συνθετικά δείγματα για τα δεδομένα της μειονεκτικής κατηγορίας που βρίσκονται σε δύσκολα σημεία ή κοντά στα όρια της πλειονεκτικής κατηγορίας.
 - **Πλεονεκτήματα**: Εστιάζει σε περιοχές όπου τα δεδομένα είναι πιο αραιά και χρειάζονται περισσότερη αντιπροσώπευση.
 - **Μειονεκτήματα**: Πιο περίπλοκη διαδικασία και μπορεί επίσης να εισαγάγει θόρυβο.

4.5. Υποδειγματοληψία (Undersampling)

Η υποδειγματοληψία περιλαμβάνει τη μείωση του αριθμού των δειγμάτων της πλειονεκτικής κατηγορίας, ώστε να εξισορροπηθεί η κατανομή των δεδομένων. Υπάρχουν διάφορες μέθοδοι υποδειγματοληψίας, όπως οι εξής:

- Τυχαία Υποδειγματοληψία (Random Undersampling)
 - Η τυχαία υποδειγματοληψία περιλαμβάνει την τυχαία αφαίρεση δειγμάτων από την πλειονεκτική κατηγορία μέχρι να επιτευχθεί ισορροπία.
 - **Πλεονεκτήματα**: Απλή και εύκολη στην εφαρμογή.
 - **Μειονεκτήματα**: Μπορεί να απομακρύνει σημαντικές πληροφορίες από τα δεδομένα, μειώνοντας την απόδοση του μοντέλου.
- Cluster-based Undersampling
 - Αυτή η μέθοδος χρησιμοποιεί αλγορίθμους συμπλέγματος για να εντοπίσει και να αφαιρέσει τα λιγότερο σημαντικά δείγματα από την πλειονεκτική κατηγορία.
 - **Πλεονεκτήματα**: Μειώνει την πιθανότητα απομάκρυνσης σημαντικών πληροφοριών.
 - **Μειονεκτήματα**: Πιο περίπλοκη διαδικασία και απαιτεί περισσότερο υπολογιστικό χρόνο.
- NearMiss [16]

- Η μέθοδος NearMiss επιλέγει τα δείγματα της πλειονεκτικής κατηγορίας που βρίσκονται πιο κοντά στη μειονεκτική κατηγορία, διατηρώντας τα πιο σημαντικά δείγματα και αφαιρώντας τα λιγότερο σημαντικά.
- **Πλεονεκτήματα:** Διατηρεί περισσότερες πληροφορίες που είναι κρίσιμες για τη διάκριση μεταξύ των κατηγοριών.
- **Μειονεκτήματα:** Μπορεί να είναι πιο περίπλοκη και να απαιτεί περισσότερη παραμετροποίηση.

- Synthetic Minority Over-sampling Technique (SMOTE) [17]

Το Synthetic Minority Over-sampling Technique (SMOTE) είναι μια τεχνική επεξεργασίας δεδομένων που χρησιμοποιείται για την αντιμετώπιση της ανισορροπίας δεδομένων σε προβλήματα μηχανικής μάθησης. Η ανισορροπία δεδομένων συμβαίνει όταν οι κατηγορίες της εξαρτημένης μεταβλητής δεν αντιπροσωπεύονται ισομερώς, κάτι που μπορεί να προκαλέσει σημαντικά προβλήματα στην απόδοση των μοντέλων μηχανικής μάθησης. Για παράδειγμα, στην ανίχνευση απάτης, οι νόμιμες συναλλαγές (κανονική κατηγορία) είναι συνήθως πολύ περισσότερες από τις συναλλαγές απάτης (μειονεκτική κατηγορία).

Πώς λειτουργεί το SMOTE

Το SMOTE δημιουργεί συνθετικά δείγματα για την μειονεκτική κατηγορία (fraudulent transactions) προκειμένου να εξισορροπήσει την κατανομή των δεδομένων. Η διαδικασία λειτουργεί ως εξής:

Επιλογή Δείγματος: Για κάθε δείγμα της μειονεκτικής κατηγορίας, το SMOTE επιλέγει τυχαία έναν ή περισσότερους γειτονικούς δείκτες από την ίδια κατηγορία.

Δημιουργία Συνθετικών Δειγμάτων: Δημιουργούνται νέα συνθετικά δείγματα κατά μήκος των γραμμών που ενώνουν το αρχικό δείγμα με τους επιλεγμένους γειτονικούς δείκτες. Η δημιουργία συνθετικών δειγμάτων βασίζεται στη διανυσματική διαφορά μεταξύ των δειγμάτων και στον πολλαπλασιασμό αυτής της διαφοράς με έναν τυχαίο αριθμό μεταξύ 0 και 1.

Διαδικασία SMOTE

Η διαδικασία για τη δημιουργία νέων συνθετικών δειγμάτων μπορεί να περιγραφεί μαθηματικά ως εξής:

Για κάθε δείγμα x_i στη μειονεκτική κατηγορία, βρείτε τους k -πλησιέστερους γείτονες χρησιμοποιώντας μια μέθοδο απόστασης (π.χ. Ευκλείδειος απόσταση).

Επιλέξτε έναν τυχαίο γείτονα x_{zi} από τους k -πλησιέστερους γείτονες.

Δημιουργήστε ένα νέο συνθετικό δείγμα χρησιμοποιώντας την εξής εξίσωση:

$$\text{synthetic sample} = x_i + \lambda \cdot (x_{zi} - x_i)$$

όπου λ είναι ένας τυχαίος αριθμός μεταξύ 0 και 1.

Πλεονεκτήματα και Μειονεκτήματα του SMOTE

Πλεονεκτήματα:

- Βελτιώνει την Ισορροπία Δεδομένων: Εξισορροπεί την κατανομή των κατηγοριών, μειώνοντας την πιθανότητα μεροληψίας του μοντέλου προς την πλειοψηφική κατηγορία.
- Αποφεύγει την Υπερπροσαρμογή: Σε αντίθεση με την απλή υπερδειγματοληψία, που απλώς αντιγράφει υπάρχοντα δείγματα, το SMOTE δημιουργεί νέα, μοναδικά δείγματα, αποφεύγοντας την υπερπροσαρμογή.
- Αυξάνει την Απόδοση: Συμβάλλει στη βελτίωση της απόδοσης των ταξινομητών, ιδιαίτερα σε μέτρα όπως η ανάκληση και η F1-score, που είναι κρίσιμα για ανισορροπημένα σύνολα δεδομένων.

Μειονεκτήματα:

- Πιθανότητα Θορύβου: Η δημιουργία συνθετικών δειγμάτων μπορεί να εισαγάγει θόρυβο, αν τα αρχικά δείγματα περιέχουν ανωμαλίες ή είναι λάθος χαρακτηρισμένα.
- Πολυπλοκότητα Υπολογισμού: Η διαδικασία δημιουργίας συνθετικών δειγμάτων μπορεί να είναι υπολογιστικά απαιτητική, ειδικά για μεγάλα σύνολα δεδομένων με πολλούς διαστάσεις.

Εφαρμογή σε Ανίχνευση Απάτης

Στην ανίχνευση απάτης, το SMOTE μπορεί να χρησιμοποιηθεί για την εξισορρόπηση των δεδομένων συναλλαγών, δημιουργώντας συνθετικές συναλλαγές απάτης. Αυτό βοηθά στη βελτίωση της ικανότητας του μοντέλου να εντοπίζει ύποπτες συναλλαγές και να μειώνει τον αριθμό των ψευδώς αρνητικών αποτελεσμάτων (false negatives). Η διαδικασία συνήθως περιλαμβάνει τα εξής βήματα:

Εφαρμογή SMOTE: Εφαρμογή της τεχνικής SMOTE στα δεδομένα εκπαίδευσης για τη δημιουργία ενός πιο ισορροπημένου συνόλου δεδομένων.

Εκπαίδευση Μοντέλου: Εκπαίδευση του μοντέλου με τα συνθετικά δεδομένα για τη βελτίωση της ευαισθησίας και της ακρίβειας.

Αξιολόγηση Μοντέλου: Χρήση των μετρικών αξιολόγησης για την εκτίμηση της απόδοσης του μοντέλου και την προσαρμογή του αναλόγως.

Το SMOTE αποτελεί ένα ισχυρό εργαλείο στη φαρέτρα των δεδομενικών επιστημόνων και αναλυτών μηχανικής μάθησης, ιδίως όταν αντιμετωπίζουν την πρόκληση των ανισόρροπων δεδομένων στην ανίχνευση απάτης. Με την προσεκτική εφαρμογή και παρακολούθηση, μπορεί να βελτιώσει σημαντικά την απόδοση των μοντέλων και την αξιοπιστία των προβλέψεων τους.

Συνολικά, η εξαγωγή χαρακτηριστικών είναι μια διαδικασία που απαιτεί προσεκτική ανάλυση και σχεδιασμό για να εξασφαλιστεί ότι τα χαρακτηριστικά που εξάγονται είναι αντιπροσωπευτικά και βοηθούν στην αναγνώριση των περιπτώσεων απάτης. Μέσω της εφαρμογής προηγμένων τεχνικών και μεθόδων, η εξαγωγή χαρακτηριστικών μπορεί να βελτιώσει σημαντικά την ακρίβεια και την αποτελεσματικότητα των αλγορίθμων μηχανικής μάθησης στην ανίχνευση απάτης.

4.6. Feature Engineering

Η δημιουργία χαρακτηριστικών (feature engineering) είναι μια διαδικασία μεγάλης σημασίας στην ανάπτυξη μοντέλων μηχανικής μάθησης, ειδικά σε περίπλοκες εφαρμογές όπως η ανίχνευση απάτης σε χρηματοοικονομικές συναλλαγές. Πρόκειται για τη διαδικασία δημιουργίας νέων χαρακτηριστικών από τα αρχικά δεδομένα με τέτοιο τρόπο ώστε να αναδειχθούν οι πληροφορίες που θα βοηθήσουν το μοντέλο να μάθει καλύτερα και να κάνει πιο ακριβείς προβλέψεις. Στην ανίχνευση απάτης, αυτό μπορεί να περιλαμβάνει την κατασκευή χαρακτηριστικών που αποκαλύπτουν ύποπτες συμπεριφορές, μοτίβα συναλλαγών και σχέσεις μεταξύ διαφορετικών οντοτήτων μέσα στο δίκτυο συναλλαγών.

- Δημιουργία Νέων Χαρακτηριστικών

- Χρονικά Χαρακτηριστικά: Χαρακτηριστικά που σχετίζονται με τον χρόνο των συναλλαγών, όπως η ώρα της ημέρας, η ημέρα της εβδομάδας, ή η απόσταση μεταξύ διαδοχικών συναλλαγών. Αυτά τα χαρακτηριστικά μπορούν να βοηθήσουν στην ανίχνευση ύποπτων μοτίβων, όπως ασυνήθιστες ώρες συναλλαγών.
- Στατιστικά Χαρακτηριστικά: Δημιουργία χαρακτηριστικών που περιγράφουν στατιστικές ιδιότητες των συναλλαγών, όπως η μέση τιμή, η διακύμανση, η μέγιστη και η ελάχιστη τιμή συναλλαγών μέσα σε ένα συγκεκριμένο χρονικό διάστημα. Αυτά τα χαρακτηριστικά μπορούν να αποκαλύψουν ανώμαλες δραστηριότητες.
- Συγκεντρωτικά Χαρακτηριστικά: Χαρακτηριστικά που συγκεντρώνουν πληροφορίες από πολλές συναλλαγές, όπως ο αριθμός των συναλλαγών που πραγματοποιούνται από έναν λογαριασμό μέσα σε μια εβδομάδα ή ο συνολικός όγκος των συναλλαγών. Αυτά τα χαρακτηριστικά μπορούν να βοηθήσουν στην κατανόηση των συνήθων μοτίβων συναλλαγών για κάθε λογαριασμό.

- Ανάλυση Δικτύου και Γράφων

- Δομικά Χαρακτηριστικά Γράφου: Δημιουργία χαρακτηριστικών που βασίζονται στη δομή του γράφου των συναλλαγών, όπως ο βαθμός κόμβου, η κεντρικότητα, και η συνοχή των υπογραφών. Αυτά τα χαρακτηριστικά μπορούν να αποκαλύψουν τις σχέσεις και τις αλληλεπιδράσεις μεταξύ διαφορετικών λογαριασμών.
- Κυκλικές Δομές: Ανάλυση και δημιουργία χαρακτηριστικών που περιλαμβάνουν κυκλικές δομές στο γράφο, όπως τριγωνικοί κλεισίματα ή μεγαλύτεροι κύκλοι, που μπορεί να υποδηλώνουν συντονισμένες δραστηριότητες απάτης.
- Μετασχηματισμοί Γράφου: Εφαρμογή μετασχηματισμών γραφών, όπως η δημιουργία υπογραφών ή η μετατροπή του γράφου σε διαφορετικές αναπαραστάσεις, για να αποκαλυφθούν λεπτομερείς σχέσεις και μοτίβα που δεν είναι άμεσα εμφανή από την αρχική δομή του γράφου.

- Χρήση Εξωτερικών Πηγών Δεδομένων

- Εμπλουτισμός Δεδομένων: Ενσωμάτωση δεδομένων από εξωτερικές πηγές για να εμπλουτιστούν τα χαρακτηριστικά των συναλλαγών. Για παράδειγμα, δεδομένα από

κοινωνικά δίκτυα, δεδομένα πίστωσης, ή άλλα σχετικά δεδομένα που μπορούν να παρέχουν επιπρόσθετες πληροφορίες για τους λογαριασμούς και τις συναλλαγές.

- Γεωγραφικά Δεδομένα: Χρήση γεωγραφικών δεδομένων για να δημιουργηθούν χαρακτηριστικά που σχετίζονται με την τοποθεσία των συναλλαγών, όπως η απόσταση μεταξύ του σημείου εκκίνησης και του σημείου τερματισμού μιας συναλλαγής, ή η συχνότητα των συναλλαγών σε διαφορετικές περιοχές.

- Αντιμετώπιση Προκλήσεων

- Ανισορροπία Δεδομένων: Δημιουργία χαρακτηριστικών που αντιμετωπίζουν την ανισορροπία των δεδομένων, χρησιμοποιώντας τεχνικές όπως η δημιουργία συνθετικών χαρακτηριστικών για τις λιγότερο αντιπροσωπευμένες κατηγορίες.

- Αντιμετώπιση Θορύβου: Δημιουργία χαρακτηριστικών που μειώνουν την επίδραση του θορύβου στα δεδομένα, εφαρμόζοντας φίλτρα ή τεχνικές εξομάλυνσης για να αφαιρεθούν οι ανωμαλίες και οι τυχαίες διακυμάνσεις που δεν σχετίζονται με την απάτη.

Η δημιουργία χαρακτηριστικών αποτελεί ένα δυναμικό και δημιουργικό στάδιο στην ανάπτυξη μοντέλων μηχανικής μάθησης, καθώς απαιτεί συνδυασμό της γνώσης του πεδίου εφαρμογής, της στατιστικής ανάλυσης, και της εφευρετικότητας για να δημιουργηθούν χαρακτηριστικά που θα βοηθήσουν στην επίλυση του προβλήματος της ανίχνευσης απάτης. Μέσω της προσεκτικής και συστηματικής δημιουργίας χαρακτηριστικών, μπορούμε να ενισχύσουμε την απόδοση των μοντέλων και να εξασφαλίσουμε ότι τα αποτελέσματα είναι όσο το δυνατόν πιο ακριβή και αξιόπιστα.

4.7. Μέθοδοι Αξιολόγησης

Η αξιολόγηση των αλγορίθμων μηχανικής μάθησης αποτελεί κρίσιμο βήμα για να εξασφαλιστεί η ακρίβεια, η αποτελεσματικότητα και η αξιοπιστία των μοντέλων που χρησιμοποιούνται. Οι κατάλληλες μέθοδοι αξιολόγησης επιτρέπουν τη σύγκριση διαφορετικών μοντέλων και τη βελτιστοποίηση των παραμέτρων τους. Παρακάτω παρουσιάζονται οι κύριες μέθοδοι αξιολόγησης που μπορούν να χρησιμοποιηθούν σε αυτή τη διατριβή.

- Διάσπαση Δεδομένων (Data Splitting)

Η διάσπαση των δεδομένων σε σύνολα εκπαίδευσης, επαλήθευσης και δοκιμών είναι το πρώτο βήμα για την αξιόπιστη αξιολόγηση ενός μοντέλου. Συνήθως, τα δεδομένα χωρίζονται ως εξής:

- Εκπαίδευση (Training Set): Το σύνολο των δεδομένων που χρησιμοποιείται για την εκπαίδευση του μοντέλου.
- Επαλήθευση (Validation Set): Το σύνολο των δεδομένων που χρησιμοποιείται για τη βελτιστοποίηση των παραμέτρων του μοντέλου και την αποφυγή υπερεκπαίδευσης (overfitting).
- Δοκιμή (Test Set): Το σύνολο των δεδομένων που χρησιμοποιείται για την τελική αξιολόγηση του μοντέλου και δεν έχει χρησιμοποιηθεί στη διαδικασία εκπαίδευσης ή επαλήθευσης.

- Μέτρα Αξιολόγησης Απόδοσης [18]

Τα κύρια μέτρα αξιολόγησης απόδοσης που χρησιμοποιούνται για την ανίχνευση απάτης περιλαμβάνουν:

- Ακρίβεια (Accuracy): Το ποσοστό των σωστών προβλέψεων του μοντέλου σε σχέση με το σύνολο των προβλέψεων. Όμως, σε περιπτώσεις ανισορροπίας δεδομένων, όπως η ανίχνευση απάτης, η ακρίβεια μπορεί να είναι παραπλανητική.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$

Εξίσωση 1 Τύπος Υπολογισμού Ακρίβειας

- Ακρίβεια Κατηγορίας (Precision): Το ποσοστό των σωστών θετικών προβλέψεων σε σχέση με το σύνολο των θετικών προβλέψεων.

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

Εξίσωση 2 Τύπος Υπολογισμού Ακρίβειας Κατηγορίας

- Ανάκληση (Recall): Το ποσοστό των σωστών θετικών προβλέψεων σε σχέση με το σύνολο των πραγματικών θετικών περιπτώσεων.

$$\text{Recall} = \frac{TP}{TP + FN}$$

Εξίσωση 3 Τύπος Υπολογισμού Ανάκλησης

- Βαθμολογία F1 (F1 Score): Ο αρμονικός μέσος όρος της ακρίβειας και της ανάκλησης, που παρέχει μια ισορροπημένη αξιολόγηση της απόδοσης του μοντέλου.

$$F1 \text{ Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

Εξίσωση 4 Τύπος Υπολογισμού F1 Score

- Καμπύλη ROC και AUC (Receiver Operating Characteristic and Area Under the Curve): Η καμπύλη ROC είναι ένα γράφημα που δείχνει την απόδοση του μοντέλου σε διάφορα κατώφλια πρόβλεψης, ενώ η AUC είναι μια ενιαία μέτρηση της συνολικής απόδοσης του μοντέλου.

$$AUC = \int_0^1 TPR(FPR) d(FPR)$$

Εξίσωση 5 Τύπος Υπολογισμού Καμπύλης ROC AUC

- Διασταυρούμενη Επικύρωση (Cross-Validation)

Η διασταυρούμενη επικύρωση είναι μια τεχνική που χρησιμοποιείται για να εκτιμηθεί η απόδοση ενός μοντέλου σε ένα σύνολο δεδομένων, κατανεμημένο σε διάφορα τμήματα (folds). Η πιο κοινή μορφή διασταυρούμενης επικύρωσης είναι η k-fold cross-validation, όπου τα δεδομένα χωρίζονται σε k ίσα τμήματα, και το μοντέλο εκπαιδεύεται και αξιολογείται k φορές, κάθε φορά χρησιμοποιώντας ένα διαφορετικό τμήμα ως σύνολο δοκιμών και τα υπόλοιπα ως σύνολο εκπαίδευσης. Αυτή η διαδικασία βοηθά στη μείωση της μεροληψίας που μπορεί να προκύψει από τη διάσπαση των δεδομένων σε ένα μόνο σύνολο εκπαίδευσης και δοκιμής.

- Ανάλυση Σφάλματος (Error Analysis)

Η ανάλυση σφάλματος περιλαμβάνει την εξέταση των περιπτώσεων όπου το μοντέλο αποτυγχάνει να κάνει σωστές προβλέψεις, προκειμένου να εντοπιστούν τα μοτίβα ή οι χαρακτηριστικές ιδιότητες που οδηγούν σε λανθασμένες προβλέψεις. Αυτό μπορεί να περιλαμβάνει:

- False Positives (FP): Συναλλαγές που έχουν χαρακτηριστεί εσφαλμένα ως απάτη.

- False Negatives (FN): Συναλλαγές που δεν έχουν χαρακτηριστεί ως απάτη ενώ είναι.

Η ανάλυση σφάλματος μπορεί να βοηθήσει στη βελτίωση του μοντέλου, εντοπίζοντας τις αδυναμίες του και παρέχοντας ενδείξεις για πρόσθετα χαρακτηριστικά ή προσαρμογές που μπορεί να βελτιώσουν την απόδοσή του.

Η επιλογή της κατάλληλης μεθόδου αξιολόγησης και η προσεκτική ανάλυση των αποτελεσμάτων είναι καθοριστικής σημασίας για την ανάπτυξη αποτελεσματικών μοντέλων ανίχνευσης απάτης. Με τη χρήση πολλαπλών μεθόδων και μέτρων αξιολόγησης, μπορούμε να εξασφαλίσουμε ότι τα μοντέλα μας είναι όσο το δυνατόν πιο ακριβή και αξιόπιστα σε πραγματικές συνθήκες.

4.8. Επιλογή Μοντέλου

Η διαδικασία επιλογής ενός κατάλληλου μοντέλου μηχανικής μάθησης περιλαμβάνει διάφορα βήματα και παράγοντες που πρέπει να ληφθούν υπόψη. Κάθε βήμα είναι κρίσιμο για την ανάπτυξη ενός αποτελεσματικού και αξιόπιστου συστήματος που μπορεί να ανιχνεύσει ύποπτες δραστηριότητες με υψηλή ακρίβεια και ελάχιστο κόστος λανθασμένων συναγερμών. Ακολουθεί μια αναλυτική περιγραφή της διαδικασίας επιλογής μοντέλου.

- Κατανόηση του Προβλήματος και των Δεδομένων

Η πρώτη φάση της επιλογής μοντέλου περιλαμβάνει την εις βάθος κατανόηση του προβλήματος της ανίχνευσης απάτης και της φύσης των δεδομένων που θα χρησιμοποιηθούν. Αυτό περιλαμβάνει:

- Ανάλυση Δεδομένων: Εξέταση των χαρακτηριστικών των δεδομένων συναλλαγών, όπως ο αριθμός των χαρακτηριστικών, η κατανομή των τιμών και η παρουσία ανισορροπίας μεταξύ κατηγοριών (π.χ., κανονικές συναλλαγές έναντι απάτης).
- Κατανόηση Επιχειρησιακών Αναγκών: Κατανόηση των επιχειρησιακών απαιτήσεων, όπως η ταχύτητα απόκρισης του μοντέλου, η ανεκτικότητα σε λανθασμένους συναγερμούς, και η ανάγκη για διαφάνεια στις αποφάσεις του μοντέλου.

- Επιλογή Αρχικών Υποψήφιων Μοντέλων

Με βάση την κατανόηση του προβλήματος και των δεδομένων, επιλέγονται τα αρχικά υποψήφια μοντέλα. Περιλαμβάνουν τόσο απλά όσο και πιο σύνθετα μοντέλα, όπως:

- Απλά Μοντέλα: Λογιστική Παλινδρόμηση (Logistic Regression), Δέντρα Απόφασης (Decision Trees), και k-NN.
- Σύνθετα Μοντέλα: Δάση Τυχαίων Δέντρων (Random Forests), SVM (Support Vector Machines), και Ενισχυμένα Δέντρα Αποφάσεων (Gradient Boosting Trees).
- Μοντέλα Βασισμένα σε Δίκτυα: Νευρωνικά Δίκτυα Γράφων (Graph Neural Networks), Δίκτυα Συνελίξης σε Γράφους (Graph Convolutional Networks), και άλλες προσεγγίσεις με ενσωμάτωση γράφων.

- Εκπαίδευση και Βελτιστοποίηση Υποψήφιων Μοντέλων

Κάθε υποψήφιο μοντέλο εκπαιδεύεται χρησιμοποιώντας το σύνολο εκπαίδευσης και αξιολογείται χρησιμοποιώντας το σύνολο επαλήθευσης. Κατά την εκπαίδευση, εφαρμόζονται διάφορες τεχνικές βελτιστοποίησης:

- Επιλογή Υπερπαραμέτρων: Χρήση τεχνικών όπως το cross-validation και το grid search για την επιλογή των βέλτιστων υπερπαραμέτρων κάθε μοντέλου.
- Εξισορρόπηση Δεδομένων: Χρήση τεχνικών όπως η υπερδειγματοληψία (oversampling) και η υποδειγματοληψία (undersampling) για την αντιμετώπιση της ανισορροπίας των δεδομένων.

- Αξιολόγηση Μοντέλων

Η αξιολόγηση των μοντέλων γίνεται με τη χρήση πολλαπλών μέτρων απόδοσης, όπως περιγράφεται στην προηγούμενη ενότητα:

- Ακρίβεια, Ανάκληση και F1 Score: Αξιολόγηση της ικανότητας του μοντέλου να ανιχνεύει απάτες και να μειώνει τα ψευδώς θετικά αποτελέσματα.

- Καμπύλες ROC και AUC: Χρήση των καμπύλων ROC και της περιοχής κάτω από την καμπύλη (AUC) για την αξιολόγηση της συνολικής απόδοσης του μοντέλου.
- Χρόνος Απόκρισης και Αποδοτικότητα: Εκτίμηση της υπολογιστικής αποδοτικότητας του μοντέλου, δηλαδή του χρόνου που απαιτείται για την εκπαίδευση και την εξαγωγή προβλέψεων.

- Ενσωμάτωση και Δοκιμή στο Πραγματικό Περιβάλλον

Το μοντέλο ή τα μοντέλα που αποδίδουν καλύτερα στα στάδια της αξιολόγησης επιλέγονται για ενσωμάτωση σε ένα πραγματικό περιβάλλον. Σε αυτό το στάδιο, η απόδοση του μοντέλου παρακολουθείται συνεχώς για να εξασφαλιστεί ότι λειτουργεί αποτελεσματικά και αξιόπιστα σε πραγματικές συνθήκες.

- Δοκιμές Παραγωγής: Πραγματοποίηση δοκιμών σε πραγματικά δεδομένα για την εκτίμηση της απόδοσης του μοντέλου σε πραγματικές συνθήκες.
- Ανατροφοδότηση και Βελτιστοποίηση: Συλλογή ανατροφοδότησης από την απόδοση του μοντέλου σε πραγματικές συνθήκες και συνεχή βελτιστοποίηση του μοντέλου βάσει των νέων δεδομένων και αναγκών.

Η διαδικασία επιλογής μοντέλου είναι συνεχής και δυναμική, απαιτώντας τακτική αναθεώρηση και προσαρμογή των μοντέλων με βάση τις μεταβαλλόμενες ανάγκες και τα δεδομένα. Μέσω της προσεκτικής επιλογής και αξιολόγησης μοντέλων, μπορούμε να εξασφαλίσουμε την ανάπτυξη αποτελεσματικών συστημάτων ανίχνευσης απάτης που θα βοηθήσουν στην προστασία των χρηματοοικονομικών συστημάτων και των πελατών τους.

5. Ανάλυση Προβλήματος: Ανίχνευση Απάτης με Αλγορίθμους Μηχανικής Μάθησης σε Γράφους

Η ανίχνευση απάτης είναι μια σημαντική πρόκληση που αντιμετωπίζουν πολλές βιομηχανίες, ειδικά αυτές που σχετίζονται με χρηματοοικονομικές συναλλαγές, ασφαλιστικές υπηρεσίες, και ηλεκτρονικό εμπόριο. Η απάτη μπορεί να πάρει διάφορες μορφές, όπως πλαστές πιστωτικές κάρτες, ψεύτικες ασφαλιστικές απαιτήσεις, και απάτες σε διαδικτυακές συναλλαγές. Οι επιπτώσεις της απάτης είναι σοβαρές, οδηγώντας σε σημαντικές οικονομικές ζημιές και απώλεια εμπιστοσύνης από τους πελάτες.

Η πολυπλοκότητα των παράνομων δραστηριοτήτων απαιτεί προηγμένες μεθόδους ανίχνευσης. Οι παραδοσιακές προσεγγίσεις συχνά αποτυγχάνουν λόγω της εξελισσόμενης φύσης της απάτης. Συνεπώς, οι σύγχρονες τεχνικές, ιδίως αυτές που αξιοποιούν τη μηχανική μάθηση (ML) και τους αλγορίθμους σε γράφους, έχουν καταστεί απαραίτητες για την αποτελεσματική ανίχνευση της απάτης.

5.1. Ανίχνευση Απάτης Σε Οικονομικές Συναλλαγές

Η ανίχνευση απάτης σε οικονομικές συναλλαγές αναφέρεται στη διαδικασία αναγνώρισης και πρόληψης δόλιων δραστηριοτήτων που σχετίζονται με χρηματοοικονομικές συναλλαγές. Αυτός ο τύπος απάτης αποτελεί σημαντικό κίνδυνο για τις επιχειρήσεις, τα χρηματοπιστωτικά ιδρύματα και τους καταναλωτές, καθώς μπορεί να οδηγήσει σε οικονομικές απώλειες, ζημία στη φήμη και κυρώσεις από τις ρυθμιστικές αρχές. Οι παράνομες δραστηριότητες στις οικονομικές συναλλαγές μπορούν να λάβουν διάφορες μορφές, συμπεριλαμβανομένων μη εξουσιοδοτημένων πληρωμών, κλοπής στοιχείων ταυτοποίησης, νομιμοποίησης εσόδων από παράνομες δραστηριότητες και παραβίαση χρηματοοικονομικών συστημάτων. Με την αύξηση των ψηφιακών συναλλαγών και του ηλεκτρονικού εμπορίου, έχουν αναπτυχθεί πιο εξελιγμένες τεχνικές, καθιστώντας την ανίχνευση απάτης πιο κρίσιμη από ποτέ.

Ένας από τους πιο κοινούς τύπους οικονομικής απάτης είναι εκείνη των πληρωμών. Αυτό περιλαμβάνει την απάτη με πιστωτικές κάρτες, όπου κλεμμένα στοιχεία καρτών χρησιμοποιούνται για τη διενέργεια μη εξουσιοδοτημένων συναλλαγών. Η απάτη επιστροφής χρημάτων (chargeback fraud), γνωστή και ως "φιλική απάτη", συμβαίνει όταν ένας πελάτης ψευδώς ισχυρίζεται ότι μια νόμιμη αγορά ήταν μη εξουσιοδοτημένη για να λάβει επιστροφή χρημάτων. Η απάτη κατάληψης λογαριασμού (account takeover fraud) αποτελεί επίσης σημαντικό πρόβλημα, όπου μέσω κυβερνοεπίθεσης αποκτάτε πρόσβαση στον λογαριασμό ενός χρήστη και πραγματοποιούνται συναλλαγές. =

Η νομιμοποίηση εσόδων από παράνομες δραστηριότητες αποτελεί μια ακόμη μορφή οικονομικής απάτης, που περιλαμβάνει τη μετατροπή παράνομων εσόδων σε φαινομενικά νόμιμα έσοδα. Οι απατεώνες χρησιμοποιούν τεχνικές όπως η διαστρωμάτωση συναλλαγών (layering transactions), όπου κεφάλαια μεταφέρονται σε πολλούς λογαριασμούς για να αποκρύψουν την προέλευσή τους, ή εικονικές εταιρείες (shell companies), οι οποίες είναι ψεύτικες επιχειρήσεις που διενεργούν παράνομες συναλλαγές. Η απάτη δεν περιορίζεται μόνο στους καταναλωτές, καθώς και οι επιχειρήσεις μπορούν να είναι είτε θύματα είτε δράστες. Οι ψεύτικοι έμποροι (fake merchants) είναι δόλιες επιχειρήσεις που δημιουργούνται για να διενεργούν συναλλαγές με κλεμμένες πληροφορίες καρτών.

Για την αντιμετώπιση αυτών των απειλών, εφαρμόζονται διάφορες τεχνικές ανίχνευσης απάτης. Τα παραδοσιακά συστήματα ανίχνευσης βασισμένα σε κανόνες χρησιμοποιούν προκαθορισμένους κανόνες για τον εντοπισμό ύποπτων συναλλαγών. Για παράδειγμα, μια συναλλαγή που υπερβαίνει ένα ορισμένο ποσό μέσα σε σύντομο χρονικό διάστημα ή προέρχεται από ασυνήθιστη τοποθεσία μπορεί να ενεργοποιήσει μια ειδοποίηση. Ωστόσο, καθώς οι απατεώνες εξελίσσουν συνεχώς τις τακτικές τους, η τεχνητή νοημοσύνη και η μηχανική μάθηση έχουν καταστεί απαραίτητες για την ανίχνευση απάτης. Τα μοντέλα εποπτευόμενης μηχανικής μάθησης εκπαιδεύονται με ιστορικά δεδομένα απάτης για την αναγνώριση προτύπων, ενώ οι τεχνικές μη εποπτευόμενης μάθησης ανιχνεύουν ανωμαλίες χωρίς να βασίζονται σε προκαθορισμένες περιπτώσεις απάτης. Τα νευρωνικά δίκτυα ενισχύουν περαιτέρω τις δυνατότητες ανίχνευσης, καθώς μπορούν να αναγνωρίζουν σύνθετα πρότυπα συναλλαγών και να προσαρμόζονται σε νέες απειλές.

Η ανάλυση συμπεριφοράς παίζει επίσης καθοριστικό ρόλο στην ανίχνευση απάτης. Αναλύοντας τη συμπεριφορά των χρηστών, όπως τις συνήθειες σύνδεσης και τα πρότυπα δαπανών, τα συστήματα ανίχνευσης απάτης μπορούν να εντοπίζουν ανωμαλίες που μπορεί να υποδηλώνουν δόλια δραστηριότητα. Για παράδειγμα, αν ένας πελάτης που συνήθως πραγματοποιεί μικρές αγορές ξαφνικά ξεκινήσει μεγάλες διεθνείς συναλλαγές, το σύστημα μπορεί να το χαρακτηρίσει ως ύποπτο. Η παρακολούθηση σε πραγματικό χρόνο ενισχύει περαιτέρω την ανίχνευση απάτης, καθώς επιτρέπει την άμεση ανάλυση των συναλλαγών και την παραγωγή ειδοποιήσεων για δραστηριότητες υψηλού κινδύνου. Επιπλέον, η εφαρμογή βιομετρικού ελέγχου ταυτότητας, όπως η αναγνώριση δακτυλικών αποτυπωμάτων ή προσώπου, καθώς και ο έλεγχος ταυτότητας δύο παραγόντων (2FA), προσθέτουν επιπλέον επίπεδα ασφαλείας για την αποτροπή μη εξουσιοδοτημένων συναλλαγών. Η πρόληψη της απάτης απαιτεί έναν συνδυασμό τεχνολογικών και στρατηγικών μέτρων. Ο καθορισμός ορίων συναλλαγών μπορεί να βοηθήσει στη μείωση του κινδύνου, ενώ ο έλεγχος ταυτότητας πολλαπλών παραγόντων ενισχύει την ασφάλεια απαιτώντας πολλαπλά στάδια επαλήθευσης. Οι επιχειρήσεις και τα χρηματοπιστωτικά ιδρύματα διατηρούν επίσης λίστες αποκλεισμού απατεώνων (fraud blacklists) για να αποκλείουν γνωστούς παραβάτες βάσει ιστορικών δεδομένων. Η παρακολούθηση τοποθεσίας μέσω γεωεντοπισμού είναι μια ακόμη αποτελεσματική μέθοδος, καθώς μπορεί να εντοπίσει συναλλαγές από ασυνήθιστες τοποθεσίες και να απαιτήσει πρόσθετη επαλήθευση. Η συνεργασία και η ανταλλαγή δεδομένων μεταξύ χρηματοπιστωτικών ιδρυμάτων ενισχύουν περαιτέρω τις προσπάθειες ανίχνευσης απάτης, επιτρέποντας την ανταλλαγή πληροφοριών σχετικά με αναδυόμενα μοτίβα απάτης.

Παρά τις προόδους στην ανίχνευση απάτης σε οικονομικές συναλλαγές, εξακολουθούν να υπάρχουν προκλήσεις. Ένα σημαντικό ζήτημα είναι τα ψευδώς θετικά (false positives), όπου νόμιμες συναλλαγές επισημαίνονται λανθασμένα ως δόλιες, προκαλώντας ταλαιπωρία στους πελάτες. Επιπλέον, καθώς οι απατεώνες συνεχώς εξελίσσουν τις μεθόδους τους, τα συστήματα ανίχνευσης πρέπει να προσαρμόζονται ώστε να παραμένουν αποτελεσματικά.

Συμπερασματικά, η ανίχνευση απάτης στις οικονομικές συναλλαγές είναι ζωτικής σημασίας για την προστασία επιχειρήσεων και καταναλωτών από οικονομικές απώλειες και κινδύνους απάτης.

5.2. Χαρακτηριστικά Ύποπτων Συναλλαγών

Οι παράνομες συναλλαγές συνήθως παρουσιάζουν ύποπτα χαρακτηριστικά που υποδηλώνουν μη εξουσιοδοτημένη ή παραπλανητική δραστηριότητα. Τα συστήματα ανίχνευσης απάτης αναλύουν μοτίβα, ανωμαλίες και δείκτες κινδύνου για τον εντοπισμό πιθανής απάτης. Για παράδειγμα, εάν πραγματοποιηθεί μια συναλλαγή από άγνωστη συσκευή ή τοποθεσία που δεν

ταιριάζει με τη συνήθη συμπεριφορά του χρήστη, μπορεί να χαρακτηριστεί ως ύποπτη και στην συνέχεια να ερευνηθεί περεταίρω για πιθανή παράνομη δραστηριότητα.

Ένα άλλο προειδοποιητικό σημάδι είναι οι συναλλαγές που παρουσιάζουν ασυνήθιστα μοτίβα δαπανών. Τα συστήματα ανίχνευσης απάτης αναλύουν τις συνήθειες αγορών ενός χρήστη, συμπεριλαμβανομένης της συχνότητας των συναλλαγών, των ποσών και των τοποθεσιών. Εάν ένας πελάτης που συνήθως πραγματοποιεί μικρές αγορές ξαφνικά αγοράσει ένα ακριβό προϊόν ή πραγματοποιήσει πολλαπλές συναλλαγές μεγάλης αξίας μέσα σε σύντομο χρονικό διάστημα, ειδικά από διαφορετικούς εμπόρους ή τοποθεσίες, το σύστημα μπορεί να το θεωρήσει ως απάτη. Οι απατεώνες συχνά προσπαθούν να μεγιστοποιήσουν το κέρδος τους πριν αποκλειστεί η κλεμμένη κάρτα ή ο λογαριασμός, γεγονός που οδηγεί σε γρήγορες διαδοχικές συναλλαγές που ενεργοποιούν ειδοποιήσεις. Παρομοίως, συναλλαγές που προέρχονται από ασυνήθιστες τοποθεσίες ή διευθύνσεις IP μπορεί να υποδηλώνουν απάτη, ειδικά εάν οι προηγούμενες συναλλαγές ενός χρήστη περιορίζονταν σε μια περιοχή και ξαφνικά εμφανίζεται μια νέα συναλλαγή από μια τοποθεσία υψηλού κινδύνου ή άλλη χώρα χωρίς ιστορικό ταξιδιών.

Οι ασυμφωνίες στις λεπτομέρειες των συναλλαγών αποτελούν επίσης βασικό δείκτη απάτης. Εάν η διεύθυνση χρέωσης, η διεύθυνση αποστολής, ο αριθμός τηλεφώνου ή το email δεν ταιριάζουν με τα στοιχεία του κατόχου της κάρτας, μπορεί να είναι σημάδι μη εξουσιοδοτημένης δραστηριότητας. Για παράδειγμα, εάν μια αγορά πραγματοποιείται με πιστωτική κάρτα που έχει εκδοθεί στην Ελλάδα, αλλά η διεύθυνση αποστολής βρίσκεται σε άλλη χώρα όπου ο κάτοχος της κάρτας δεν έχει προηγούμενο ιστορικό αγορών, η συναλλαγή μπορεί να χαρακτηριστεί ως ύποπτη. Τα συστήματα ανίχνευσης απάτης βασίζονται επίσης σε λίστες αποκλεισμένων συσκευών ή λογαριασμών για να αποτρέψουν επαναλαμβανόμενους δράστες. Εάν γίνει μια συναλλαγή από μια συσκευή, ένα email ή μια διεύθυνση IP που σχετίζεται με προηγούμενες δόλιες δραστηριότητες, είναι πιο πιθανό να χαρακτηριστεί ως απάτη. Επιπλέον, συναλλαγές που προέρχονται από ασυνήθιστες ή ανώνυμες διευθύνσεις IP, όπως αυτές που χρησιμοποιούν VPN, δίκτυα TOR ή διακομιστές μεσολάβησης (proxy servers), μπορεί να υποδηλώνουν απάτη, καθώς οι απατεώνες συχνά προσπαθούν να αποκρύψουν την πραγματική τους τοποθεσία για να παρακάμψουν τα μέτρα ασφαλείας.

Ορισμένοι τύποι συναλλαγών υψηλού κινδύνου, όπως οι αγορές εικονικών προϊόντων, δωροκαρτών ή κρυπτονομισμάτων, στοχεύονται συχνά από απατεώνες, καθώς μπορούν εύκολα να μεταπωληθούν ή να μεταφερθούν χωρίς ανιχνευσιμότητα. Εάν ένας λογαριασμός που προηγουμένως δεν είχε ιστορικό τέτοιων αγορών ξαφνικά αρχίσει να αγοράζει μεγάλες ποσότητες από αυτά τα προϊόντα, μπορεί να εγείρει υποψίες. Η απάτη ελέγχου καρτών (card testing fraud) είναι ένα ακόμη σύνηθες σχήμα, όπου οι απατεώνες πραγματοποιούν αρχικά μικρές συναλλαγές για να ελέγξουν εάν μια κλεμμένη πιστωτική κάρτα εξακολουθεί να είναι ενεργή πριν προχωρήσουν σε μεγάλες δόλιες αγορές. Εάν ένα σύστημα ανιχνεύσει ένα μοτίβο μικρών, επαναλαμβανόμενων συναλλαγών που ακολουθούνται από ασυνήθιστα μεγάλες συναλλαγές, μπορεί να το ταυτοποιήσει ως απάτη.

5.3. Παραδείγματα Στο Πραγματικό Κόσμο

Μια από τις πιο συνηθισμένες μορφές απάτης είναι η απάτη με πιστωτικές κάρτες. Ένα παράδειγμα από τον πραγματικό κόσμο είναι η χρήση κλεμμένων πιστωτικών καρτών για την πραγματοποίηση αγορών. Οι εγκληματίες μπορούν να αποκτήσουν τα στοιχεία των καρτών μέσω phishing, malware, ή παραβιάσεις δεδομένων. Οι τράπεζες και οι πάροχοι

πιστωτικών καρτών πρέπει να ανιχνεύουν και να προλαμβάνουν τέτοιες απάτες για να προστατεύσουν τους πελάτες τους και να μειώσουν τις οικονομικές ζημιές.

5.4. Εφαρμογές Ανίχνευσης Απάτης

- Τραπεζικά και Χρηματοοικονομικά Συστήματα
 - Συναλλαγές Πιστοποιητικών Καρτών: Η ανίχνευση απάτης σε πραγματικό χρόνο για τις συναλλαγές με πιστωτικές κάρτες είναι κρίσιμη. Οι τράπεζες χρησιμοποιούν αλγόριθμους μηχανικής μάθησης για να αναλύσουν τις συναλλαγές και να ανιχνεύσουν ύποπτες δραστηριότητες. Αυτοί οι αλγόριθμοι μπορούν να εντοπίσουν ασυνήθιστα πρότυπα αγορών, όπως μεγάλες αγορές σε σύντομο χρονικό διάστημα ή αγορές σε διάφορες γεωγραφικές τοποθεσίες.
 - Αίτησης Δανείων: Η ανίχνευση απάτης στις αιτήσεις δανείων βοηθά τις τράπεζες να εντοπίσουν ψεύτικα ή παραποιημένα στοιχεία και να προστατεύσουν τον εαυτό τους από δανειολήπτες που δεν έχουν την πρόθεση ή τη δυνατότητα να αποπληρώσουν τα δάνεια.
- Ασφαλιστικά Συστήματα
 - Άπατες Αποζημίωσης: Στον τομέα της ασφάλισης, η απάτη μπορεί να πάρει τη μορφή ψεύτικων ή διογκωμένων αξιώσεων. Οι εταιρείες ασφάλισης χρησιμοποιούν αλγόριθμους μηχανικής μάθησης για να αναλύσουν τα δεδομένα των αξιώσεων και να ανιχνεύσουν ανωμαλίες που μπορεί να υποδεικνύουν απάτη.
 - Άπατες στην Πολιτική: Επίσης, η απάτη μπορεί να συμβεί κατά την έκδοση των ασφαλιστικών συμβολαίων, όπου οι πελάτες παρέχουν ψευδή στοιχεία για να λάβουν χαμηλότερα ασφάλιστρα. Οι εταιρείες ασφάλισης χρησιμοποιούν αναλυτικές τεχνικές για να επαληθεύσουν την ακρίβεια των παρεχόμενων στοιχείων.
- Ηλεκτρονικό Εμπόριο
 - Απάτη Διαδικτυακών Πληρωμών: Οι εταιρείες που δραστηροποιούνται με διαδικτυακό εμπόριο αντιμετωπίζουν τον κίνδυνο απάτης στις πληρωμές. Οι αλγόριθμοι μηχανικής μάθησης αναλύουν τις συναλλαγές σε πραγματικό χρόνο για να ανιχνεύσουν ύποπτη δραστηριότητα, όπως η χρήση κλεμμένων πιστωτικών καρτών ή η υποβολή ψευδών παραγγελιών.
 - Κλοπή Λογαριασμού: Άτομα που προσπαθούν να διαπράξουν απάτη μπορούν να αποκτήσουν πρόσβαση στους λογαριασμούς των πελατών και να πραγματοποιήσουν μη εξουσιοδοτημένες συναλλαγές. Οι τεχνικές ανίχνευσης απάτης παρακολουθούν την συμπεριφορά των χρηστών για να εντοπίσουν ασυνήθιστες ενέργειες και να προστατεύσουν τους λογαριασμούς.

5.5. Μηχανική Μάθηση και Ανίχνευση Απάτης: Ο ρόλος το γράφων.

Η μηχανική μάθηση έχει αναδειχθεί ως ένα από τα πιο ισχυρά εργαλεία για την ανίχνευση απάτης σε διάφορους τομείς. Με την ικανότητά της να επεξεργάζεται και να αναλύει τεράστια σύνολα δεδομένων, η μηχανική μάθηση μπορεί να αποκαλύψει μοτίβα και ανωμαλίες που δεν είναι εμφανή μέσω παραδοσιακών μεθόδων. Η ανίχνευση απάτης είναι κρίσιμη σε βιομηχανίες όπως οι χρηματοοικονομικές υπηρεσίες, οι ασφάλειες και το ηλεκτρονικό εμπόριο, όπου οι οικονομικές απώλειες και οι κίνδυνοι για τη φήμη μπορούν να είναι καταστροφικοί. Τα συστήματα ανίχνευσης απάτης βασισμένα σε μηχανική

μάθηση μπορούν να μάθουν από τα δεδομένα ιστορικών συναλλαγών, να προσαρμόζονται σε νέες τάσεις και να εντοπίζουν ύποπτες δραστηριότητες σε πραγματικό χρόνο.

Τα παραδοσιακά συστήματα ανίχνευσης απάτης βασίζονται σε προκαθορισμένους κανόνες και στατιστικές μεθόδους, οι οποίες συχνά αποτυγχάνουν να πιάσουν νέες και εξελισσόμενες τακτικές απάτης. Αντίθετα, οι αλγόριθμοι μηχανικής μάθησης, όπως τα νευρωνικά δίκτυα, τα δέντρα αποφάσεων και οι μέθοδοι ενίσχυσης, μπορούν να εκπαιδευτούν σε μεγάλα σύνολα δεδομένων για να εντοπίζουν απάτες με μεγαλύτερη ακρίβεια και αποτελεσματικότητα.

5.6. Συστήματα Ανάλυσης Γραφών

Οι γράφοι αποτελούν μια ιδανική δομή δεδομένων για την αναπαράσταση και ανάλυση των σχέσεων μεταξύ οντοτήτων. Στο πλαίσιο της ανίχνευσης απάτης, οι γράφοι μπορούν να μοντελοποιούν διάφορους τύπους αλληλεπιδράσεων και συναλλαγών, αποκαλύπτοντας περίπλοκα μοτίβα που υποδεικνύουν ύποπτες συμπεριφορές. Για παράδειγμα:

- Κόμβοι μπορούν να αναπαριστούν οντότητες όπως τραπεζικούς λογαριασμούς, πιστωτικές κάρτες ή άτομα.

- Ακμές μπορούν να αναπαριστούν συναλλαγές, σχέσεις ή αλληλεπιδράσεις μεταξύ αυτών των οντοτήτων.

Μετασχηματίζοντας τα δεδομένα συναλλαγών σε δομή γράφου, καθίσταται δυνατή η εφαρμογή αλγορίθμων βασισμένων σε γράφους για την ανίχνευση ανωμαλιών και μοτίβων που υποδηλώνουν παράνομες δραστηριότητες.

Παράδειγμα από τον Πραγματικό Κόσμο: Ανίχνευση Απάτης σε Πιστωτικές Κάρτες

Ας εξετάσουμε ένα σενάριο όπου πρέπει να ανιχνεύσουμε συναλλαγές πιστωτικών καρτών. Οι παραδοσιακές μέθοδοι μπορεί να αναλύουν κάθε συναλλαγή μεμονωμένα, παραλείποντας το ευρύτερο πλαίσιο. Χρησιμοποιώντας μια προσέγγιση βασισμένη σε γράφους, μπορούμε να κατασκευάσουμε έναν γράφο όπου:

- Κάθε κόμβος αντιπροσωπεύει μια πιστωτική κάρτα.

- Κάθε ακμή αντιπροσωπεύει μια συναλλαγή μεταξύ πιστωτικών καρτών ή μεταξύ μιας πιστωτικής κάρτας και ενός εμπόρου.

Αυτή η δομή επιτρέπει την ανίχνευση ύποπτων μοτίβων, όπως μια πιστωτική κάρτα που εμπλέκεται σε πολλαπλές συναλλαγές σε διαφορετικές τοποθεσίες σε σύντομο χρονικό διάστημα, υποδεικνύοντας πιθανή απάτη.

5.7. Αλγόριθμοι Μηχανικής Μάθησης σε Γράφους για Ανίχνευση Απάτης

- Νευρωνικά Δίκτυα Γραφών (GNNs)

- Περιγραφή: Τα GNNs γενικεύουν τα νευρωνικά δίκτυα σε δεδομένα γράφων. Μεταδίδουν πληροφορίες κατά μήκος των ακμών του γράφου, επιτρέποντας σε κάθε κόμβο να συγκεντρώνει πληροφορίες από τους γείτονές του.

- Εφαρμογή: Στην ανίχνευση απάτης, τα GNNs μπορούν να εντοπίσουν περίπλοκα μοτίβα λαμβάνοντας υπόψη ολόκληρο το δίκτυο συναλλαγών και σχέσεων. Είναι ιδιαίτερα αποτελεσματικά στη σύλληψη των λεπτών εξαρτήσεων μεταξύ οντοτήτων που μπορεί να υποδεικνύουν παράνομη συμπεριφορά.

- Πολυπλοκότητα: Συνήθως $O(V + E)$ ανά επίπεδο, όπου V είναι ο αριθμός των κόμβων και E είναι ο αριθμός των ακμών.

- Δίκτυα Συνέλιξης σε Γράφους (GCNs)

- Περιγραφή: Τα GCNs είναι ένας τύπος GNN που εφαρμόζουν συνελεκτικές λειτουργίες σε γράφους, επιτρέποντας στο δίκτυο να μάθει τοπικά μοτίβα και αναπαραστάσεις κόμβων βάσει των γειτόνων τους.

- Εφαρμογή: Τα GCNs μπορούν να εντοπίσουν τοπικά και ημι-παγκόσμια μοτίβα σε δίκτυα συναλλαγών, καθιστώντας τα κατάλληλα για τον εντοπισμό ομάδων παράνομων δραστηριοτήτων.

- Πολυπλοκότητα: Συνήθως $O(E)$ ανά επίπεδο.

- Δίκτυα Προσοχής σε Γράφους (GATs)

- Περιγραφή: Τα GATs επεκτείνουν τα GCNs εισάγοντας μηχανισμούς προσοχής. Αναθέτουν διαφορετικά βάρη στις ακμές, επιτρέποντας στο δίκτυο να επικεντρώνεται στα πιο σημαντικά μέρη του γράφου.

- Εφαρμογή: Στην ανίχνευση απάτης, τα GATs μπορούν να δώσουν έμφαση σε κρίσιμες συναλλαγές και σχέσεις, βελτιώνοντας την ακρίβεια της ανίχνευσης εντοπίζοντας τις πιο ύποπτες συνδέσεις.

- Πολυπλοκότητα: Συνήθως $O(E)$ ανά επίπεδο, με επιπλέον επιβάρυνση για τον υπολογισμό των συντελεστών προσοχής.

- Αυτόκωδικοποιητές Γράφων

- Περιγραφή: Οι γραφικοί αυτόκωδικοποιητές είναι μοντέλα μη εποπτευόμενης μάθησης που μαθαίνουν να κωδικοποιούν τις δομές των γραφημάτων σε ένα χαμηλής διάστασης χώρο και στη συνέχεια να τα αποκωδικοποιούν ξανά. Μπορούν να χρησιμοποιηθούν για την ανίχνευση ανωμαλιών συγκρίνοντας τους ανακατασκευασμένους γραφήματα με τα αρχικά.

- Εφαρμογή: Με την ανακατασκευή δικτύων συναλλαγών, οι γραφικοί αυτόκωδικοποιητές μπορούν να εντοπίσουν αποκλίσεις από την κανονική συμπεριφορά, σηματοδοτώντας πιθανά περιστατικά απάτης.

- Πολυπλοκότητα: Η πολυπλοκότητα εξαρτάται από την αρχιτεκτονική, αλλά συνήθως περιλαμβάνει πολλαπλές περαστικές διεργασίες μέσω του γράφου, καθιστώντας την $O(V^2)$ για μια απλοϊκή υλοποίηση.

- Node2Vec και Άλλες Μέθοδοι Ενσωμάτωσης

- Περιγραφή: Το Node2Vec είναι μια τεχνική ενσωμάτωσης κόμβων που μαθαίνει χαμηλής διάστασης αναπαραστάσεις για τους κόμβους προσομοιώνοντας τυχαίους περιπάτους στο γράφο. Άλλες μέθοδοι ενσωμάτωσης περιλαμβάνουν τα DeepWalk και LINE.

- Εφαρμογή: Αυτές οι ενσωματώσεις μπορούν να συλλάβουν τις δομικές ιδιότητες του γράφου και να χρησιμοποιηθούν ως χαρακτηριστικά σε επόμενα μοντέλα μηχανικής μάθησης για την ανίχνευση απάτης.

- Πολυπλοκότητα: Συνήθως $O(V + E)$ για τη δημιουργία τυχαίων περιπάτων και την εκπαίδευση των ενσωματώσεων.

5.8. Εφαρμογές και Οφέλη

1. **Ανίχνευση Απάτης σε Πραγματικό Χρόνο:** Οι αλγόριθμοι σε γράφους μπορούν να επεξεργάζονται και να αναλύουν συναλλαγές σε πραγματικό χρόνο, εντοπίζοντας ύποπτες δραστηριότητες καθώς συμβαίνουν. Αυτό είναι κρίσιμο για την αποτροπή ολοκλήρωσης παράνομων συναλλαγών.
2. **Βελτιωμένη Αναγνώριση Μοτίβων:** Με την αξιοποίηση των σχέσεων που υπάρχουν στους γράφους, τα μοντέλα μηχανικής μάθησης μπορούν να εντοπίσουν περίπλοκα μοτίβα απάτης που δεν είναι εμφανή μέσω παραδοσιακών μεθόδων ανάλυσης.
3. **Κλιμακωσιμότητα:** Οι μέθοδοι βασισμένες σε γράφους μπορούν να κλιμακωθούν σε μεγάλα σύνολα δεδομένων, καθιστώντας τις κατάλληλες για βιομηχανίες που χειρίζονται τεράστια ποσά δεδομένων συναλλαγών.
4. **Προσαρμοστικότητα:** Τα μοντέλα μηχανικής μάθησης μπορούν να ενημερώνονται συνεχώς με νέα δεδομένα, επιτρέποντας τους να προσαρμόζονται στις εξελισσόμενες τακτικές απάτης.

- **Παράδειγμα Σενάριου**

Φανταστείτε ένα χρηματοπιστωτικό ίδρυμα που παρακολουθεί συναλλαγές μεταξύ εκατομμυρίων λογαριασμών. Κατασκευάζοντας έναν γράφο συναλλαγών:

- Οι κόμβοι αντιπροσωπεύουν λογαριασμούς.
- Οι ακμές αντιπροσωπεύουν συναλλαγές, σημειωμένες με χαρακτηριστικά όπως ποσό συναλλαγής, χρόνος και τοποθεσία.

Χρησιμοποιώντας ένα GNN, το ίδρυμα μπορεί να:

- Συγκεντρώσει πληροφορίες από πολλαπλές συναλλαγές για να ανιχνεύσει ύποπτα μοτίβα.
- Εντοπίσει ομάδες λογαριασμών που εμπλέκονται σε ύποπτες ή παράνομες δραστηριότητες.
- Δημιουργήσει ειδοποιήσεις για περαιτέρω διερεύνηση από ανθρώπινους αναλυτές.

5.9. Συμπέρασμα

Οι αλγόριθμοι μηχανικής μάθησης σε γράφους παρέχουν μια ισχυρή προσέγγιση για την ανίχνευση απάτης, αξιοποιώντας την εγγενή σχεσιακή δομή των δεδομένων συναλλαγών για να αποκαλύψουν περίπλοκα μοτίβα απάτης. Ενσωματώνοντας αυτές τις προηγμένες τεχνικές, οι οργανισμοί μπορούν να βελτιώσουν σημαντικά τις δυνατότητες ανίχνευσης απάτης, προστατεύοντας τους εαυτούς τους και τους πελάτες τους από οικονομικές απώλειες.

6. Αρχιτεκτονική Συστήματος, Αλγόριθμοι και Τεχνικές

6.1. Ανίχνευση Απάτης σε Οικονομικές Συναλλαγές

Το σύστημα έχει στόχο την ανίχνευση απάτης μεταξύ οικονομικών συναλλαγών. Από την πλευρά της τεχνητής νοημοσύνης το πρόβλημα αυτό αντιμετωπίζεται ως πρόβλημα κατηγοριοποιήσεων, με δυο κεντρικές κατηγορίες «Νόμιμη» και «Μη Νόμιμη» συναλλαγή. Υπάρχουν και άλλες κατηγορίες που μπορούν να εισαχθούν για τις συναλλαγές ώστε να γίνει πιο γενική ανάλυση. Με την κατηγορία «Μη Νόμιμη» συναλλαγή χαρακτηρίζονται οι συναλλαγές εκείνες που πρέπει να εξεταστούν από άνθρωπο, στην πραγματικότητα η συγκεκριμένη κατηγορία ανιχνεύει τις ύποπτες συναλλαγές. Ένα βασικό χαρακτηριστικό του συγκεκριμένου ζητήματος είναι ανομοιομορφία των δεδομένων. Η κατηγοριοποίηση συναλλαγών σε «Νόμιμες» είναι πολύ συχνότερη από τις «Μη Νόμιμες», με αποτέλεσμα τα δεδομένα να χρειάζονται επιπλέον επεξεργασία για την σωστή εκπαίδευση του συστήματος, ώστε να μην υπάρχει τάση επιλογής της κυρίαρχης κατηγορίας.

6.2. Δεδομένα

Για το πειραματικό μέρος της εργασίας θα χρησιμοποιηθούν δεδομένα από υπάρχων οικονομικές συναλλαγές τα οποία έχουν ήδη κατηγοριοποιηθεί. Το σύνολο δεδομένων που θα χρησιμοποιηθεί είναι το SAML-D [19]. Το SAML-D είναι ένα σύνολο δεδομένων που δημιουργήθηκε από το πανεπιστήμιο του Bournemouth μέσω τεχνικών δεδομένων, καθώς η πρόσβαση και συλλογή δεδομένων οικονομικών συναλλαγών έχει ιδιαίτερες δυσκολίες για λόγους προσωπικών δεδομένων. Στο σύνολο των δεδομένων υπάρχουν 9,504,852 συναλλαγές από τις οποίες το 0.10% είναι ύποπτες, επίσης υπάρχουν 12 πληροφορίες για κάθε συναλλαγή, με τα στοιχεία να περιλαμβάνουν, των αποστολέα, τον παραλήπτη, το είδος της συναλλαγής (ηλεκτρονική, κατάθεση), το ποσό, το νόμισμα αποστολής και παράληψης κτλ. Υπάρχουν επίσης δυο διαφορετική τύποι κατηγοριοποιήσεις, ο τύπος που περιέχει 12 νόμιμες και 17 ύποπτες κατηγορίες κινήσεων αλλά και η δυαδική τιμή για ύποπτο / μη ύποπτο. Πιο αναλυτικά η συλλογή δεδομένων περιέχει τα παρακάτω χαρακτηριστικά τα οποία.

Πίνακας 1 Περιγραφή Δεδομένων

Όνομα	Περιγραφή
<i>Time</i>	Η ώρα που εκτελέστηκε η συναλλαγή
<i>Date</i>	Η ημερομηνία που εκτελέστηκε η συναλλαγή
<i>Sender Account</i>	Ο αριθμός λογαριασμού του αποστολέα
<i>Receiver Account</i>	Ο αριθμός λογαριασμού του παραλήπτη
<i>Amount</i>	Το πόσο της συναλλαγής
<i>Sender Account</i>	Το νόμισμα του λογαριασμού του αποστολέα
<i>Currency</i>	
<i>Receiver Account</i>	Το νόμισμα του λογαριασμού του παραλήπτη
<i>Currency</i>	
<i>Sender Bank Location</i>	Η τοποθεσία της τράπεζας του αποστολέα

<i>Receiver Bank Location</i>	Η τοποθεσία της τράπεζας του παραλήπτη
<i>Payment Type</i>	Ο τύπος της συναλλαγής

Τα χαρακτηριστικά για κάθε εγγραφή μπορούν να ομαδοποιηθούν σε μια από τις 3 παρακάτω κατηγορίες, «Στοιχεία Συναλλαγής», «Στοιχεία Παραλήπτη», «Στοιχεία Αποστολέα», ο συγκεκριμένος διαχωρισμός είναι πολύ βασικός από τεχνικής άποψης καθώς για το σχηματισμό γράφου θα πρέπει τα στοιχεία της κάθε κατηγορίας να ακολουθήσουν τη δική τους κατηγορία.

Πίνακας 2 Στοιχεία Παραλήπτη

Παραλήπτης/Αποστολέας

Αριθμός Λογαριασμού
Νόμισμα Λογαριασμού
Τοποθεσία Τράπεζας

Πίνακας 3 Στοιχεία Συναλλαγής


Συναλλαγή

Ποσό
Ώρα
Ημερομηνία
Τύπος

Ο διαχωρισμός των δεδομένων θα γίνει με τη μορφή του παρακάτω πίνακα.

<i>Κατηγορία</i>	<i>Διαχωρισμός</i>
<i>Train Set</i>	70% - 80%
<i>Validation Set</i>	10% - 15%
<i>Test Set</i>	10% - 15%

Τα δεδομένα δεν είναι πλήρως σχηματισμένα σε μορφή γράφου και θα πρέπει να γίνει προ επεξεργασία τους ώστε να φτάσουν στην τελική μορφή. Στο Γράφο που θα σχηματιστεί τα οι παραλήπτες και οι αποστολείς θα αποτελούν τους κόμβους, ενώ οι συναλλαγές μεταξύ τους τις ακμές, τα αντίστοιχα χαρακτηριστικά σύμφωνα με την προηγούμενη κατηγοριοποίηση θα είναι και τα στοιχεία κάθε μέρους. Ο γράφος θα είναι κατευθυνόμενος από την πλευρά του αποστολέα στο παραλήπτη. Ακολουθεί σχηματιστεί απεικονίσει τις δομές του γράφου.



Γράφημα 1 Παράδειγμα Γράφου

6.3. Σύστημα

Το σύστημα αποτελείται από μια σειρά εργαλείων που το καθένα είναι υπεύθυνο για μια σειρά από λειτουργίες από την εισαγωγή δεδομένων, μετατροπή τους σε γράφο, προ επεξεργασία τους, κατηγοριοποιήσεις τους και εξαγωγής αποτελέσματος. Ακολουθεί ανάλυση για κάθε εργαλείο του συστήματος.

- Υποσύστημα Εισαγωγής και Εξαγωγής Δεδομένων

Το εργαλείο εισαγωγής και εξαγωγής δεδομένων είναι υπεύθυνο για την επιτυχή ανάγνωση της συλλογής δεδομένων διαχωρισμού της σε 3 υποσυλλογές για εκπαίδευση, αξιολογήσει και τελική δοκιμή. Επίσης το συγκεκριμένο υποσύστημα θα πρέπει να μετατρέψει τις επιμέρους υποσυλλογές σε μορφή τέτοια ώστε να μπορούν να επεξεργαστούν από τα υπόλοιπα συστήματα.

Δυνατότητες του συγκεκριμένου συστήματος είναι:

1. Ανάγνωση Δεδομένων
2. Εγγραφή Ανάλυσης Αποτελέσματος
3. Διαχωρισμός Δεδομένων σε υποσυλλογές

- Υποσύστημα Δημιουργίας Γράφου

Το υποσύστημα δημιουργίας γράφου διαχωρίζει τα δεδομένα και σχηματίζει το γράφο που αργότερα θα δοθεί στο σύστημα κατηγοριοποιήσεις. Θα πρέπει να αναλύσει τα δεδομένα χωρίζοντας τα σε ακμές και κόμβους, και να προσθέσει τα στοιχεία για το καθένα.

Από τις βασικές λειτουργίες του συστήματος είναι να μπορεί να διαχωρίζει αποτελεσματικά τους κόμβους και να μπορεί να δημιουργήσει όλες τις ακμές μεταξύ τους και τις πολλαπλές ακμές που θα δέχεται ένας κόμβος χωρίς διπλότυπα.

- Υποσύστημα Επεξεργασίας Δεδομένων

Η συλλογή εργαλείων για προ επεξεργασία των δεδομένων είναι ένα οριζόντιο σύστημα, που θα συμβάλει σε διάφορες φάσεις τις λειτουργίας του συστήματος, είτε με κύριο ρόλο, όπως η προ επεξεργασία των δεδομένων, είτε με βοηθητικό ρόλο, όπως η μετατροπή της κατηγοριοποιήσεις σε ανθρώπινος αναγνώσιμη μορφή.

Βασικές λειτουργίες του συστήματος είναι οι λειτουργίες για την προεξεργασία των δεδομένων, τα οποία μπορεί να τα κανονικοποιεί και να χειρίζεται θέματα όπως το ανισοκατανομή των δεδομένων με λειτουργίες όπως το undersampling, oversampling κτλ.. Επίσης το σύστημα έχει δυνατότητες για δημιουργία παραπάνω χαρακτηριστικών αν αυτό είναι απαραίτητο.

- Υποσύστημα Κατηγοριοποιήσεις

Το υποσύστημα κατηγοριοποιήσεις είναι η κύρια υπολογιστική μηχανή του συστήματος, καθώς εκείνο με την χρήση του επιλεγμένου μοντέλου τεχνητής νοημοσύνης θα δέχεται το γράφο και θα εξάγει αποτελέσματα γι' αυτόν.


Το κύριο χαρακτηριστικό του συγκεκριμένου συστήματος, είναι διαχείριση διάφορων μοντέλων μηχανικής και βαθιάς μάθησης, η εκπαίδευση τους, χρήση τους για συλλογισμό αλλά και η αποθήκευση τους για μελλοντική χρήση.

Χαρακτηριστικά μοντέλα που υποστηρίζονται από το σύστημα είναι:

1. Graph Neural Networks (GNNs)
2. Graph Convolutional Networks (GCNs)
3. Graph Attention Network

6.4. Γραφιστική Αναπαράσταση Συστήματος

Ακολουθεί γραφιστική αναπαράσταση του συστήματος:



Εικόνα 1 Αρχιτεκτονική Συστήματος

6.5. Αλγόριθμοι

- Graph Convolution Networks - GCNs

Τα Graph Convolution Networks έχουν την ικανότητα εκμετάλλευσης τόσο της τοπολογικής πληροφορίας όσο και των χαρακτηριστικών των κόμβων, επιτρέποντας τη μάθηση αναπαραστάσεων που λαμβάνουν υπόψη τις σχέσεις μεταξύ των δεδομένων. Τα GCNs χρησιμοποιούν έναν μηχανισμό διάδοσης πληροφορίας, όπου κάθε κόμβος ενημερώνει την αναπαράστασή του συνδυάζοντας πληροφορίες από τους γειτονικούς του κόμβους μέσω ενός σταθμισμένου σχήματος συσσωμάτωσης. Αυτή η προσέγγιση επιτρέπει την αποτελεσματική εξαγωγή χαρακτηριστικών από μη δομημένα δεδομένα και καθιστά τα GCNs ιδιαίτερα χρήσιμα σε εφαρμογές όπως η ταξινόμηση κόμβων, η πρόβλεψη συνδέσεων και η ανίχνευση ανωμαλιών σε δίκτυα.

- Graph Sage

Η μέθοδος GraphSAGE (Graph Sample and Aggregate) είναι μια παραλλαγή των Graph Neural Networks (GNNs) που εστιάζει στη δειγματοληψία και συσσώρευση πληροφοριών από γειτονικούς κόμβους, επιτρέποντας την αποτελεσματική εκπαίδευση σε μεγάλα και δυναμικά γραφήματα. Αντί να επεξεργάζεται ολόκληρο το γράφημα ταυτόχρονα, όπως τα κλασικά GCNs, το GraphSAGE δειγματοληπτει έναν καθορισμένο αριθμό γειτόνων για κάθε κόμβο και εφαρμόζει συναρτήσεις συσώρευσης (aggregation functions), όπως mean, LSTM-based ή max-pooling, για τη δημιουργία μιας πλούσιας αναπαράστασης. Αυτή η προσέγγιση καθιστά τη μέθοδο επεκτάσιμη και ικανή να γενικεύσει σε νέους κόμβους χωρίς να απαιτεί εκ νέου εκπαίδευση του μοντέλου, γεγονός που την καθιστά ιδιαίτερα χρήσιμη σε εφαρμογές με δυναμικά ή μεγάλου όγκου δεδομένα.

- Graph Attention Network

Τα Graph Attention Networks (GATs) αποτελούν μια εξελιγμένη κατηγορία γραφικών νευρωνικών δικτύων που χρησιμοποιούν μηχανισμούς προσοχής (attention mechanisms) για την προσαρμοστική στάθμιση των γειτονικών κόμβων κατά τη διαδικασία της συσσώρευσης πληροφορίας. Αντί να δίνουν ίσο βάρος σε όλους τους γείτονες, όπως τα παραδοσιακά Graph Convolutional Networks (GCNs), τα GATs μαθαίνουν να εκχωρούν δυναμικά συντελεστές προσοχής στους κόμβους με βάση τη σημασία τους, επιτρέποντας πιο εκφραστικές και ευέλικτες αναπαραστάσεις. Επιπλέον, υποστηρίζουν μη κατευθυνόμενα και κατευθυνόμενα γραφήματα, ενώ η χρήση πολυκεφαλικής προσοχής (multi-head attention) βελτιώνει τη σταθερότητα και την ικανότητα του μοντέλου να συλλαμβάνει πολύπλοκες σχέσεις. Τα GATs χρησιμοποιούνται ευρέως σε εφαρμογές όπως η ταξινόμηση κόμβων, η πρόβλεψη συνδέσεων και η ανίχνευση ανωμαλιών, προσφέροντας βελτιωμένη απόδοση σε προβλήματα όπου η σημασία των γειτόνων ενός κόμβου ποικίλει.

6.6. Τεχνικές

Όπως περιγραφικά στο κεφάλαιο 6.2 η συλλογή δεδομένων περιλαμβάνει από 9,504,852 συναλλαγές, από τις οποίες το 0,10% έχουν χαρακτηριστεί ως παράνομες (Το πρόβλημα θα αναλυθεί στο κεφάλαιο 7.2.2.). Η συλλογή αποτελείται από 12 χαρακτηριστικά. Τα χαρακτηριστικά αυτά χρησιμοποιήθηκαν για την δημιουργία ποιοτικών τιμών για την ανάλυση τους από τους αλγόριθμους που περιεγράφηκαν στο κεφάλαιο 7.1.. Συνολικά τα δεδομένα μετατράπηκαν ώστε να περιέχουν 36

χαρακτηρίστηκα τα οποία που περιέχουν πληροφορία για το είδος της συναλλαγής, το ποσό, χρονικά χαρακτηριστικά καθώς και γεωγραφικά.

Το πρόβλημα τις ανισορροπίας είναι πολύ σύνηθες στις συλλογές δεδομένων για οικονομικές συναλλαγές όταν το ζητούμενο πρόβλημα είναι η ανίχνευση απάτης. Στην συγκεκριμένη συλλογή το πρόβλημα αυτό είναι πολύ έντονο καθώς τα δεδομένα παράνομων συναλλαγών είναι σχεδόν 0.10% του συνολικού αριθμού.

Για το λόγο αυτό χρησιμοποιήθηκε η τεχνική SMOTE που περιεγράφηκε στο κεφάλαιο 4.5.1. ώστε να δημιουργηθούν τεχνικά δεδομένα και να εξισορροπήσει το δείγμα, αλλά και η τεχνική των βαρών ώστε να «αποδυναμωθεί» η πολυπληθής κλάση.

Καθώς η συλλογή δεδομένων δεν περιείχε μεγάλο αριθμό ποιοτικών χαρακτηριστικών χρειάστηκε να γίνει υπολογισμός νέων χαρακτηριστικών και μετατροπή χαρακτηριστικών όπως τα χρονικά σε μορφή που μπορεί να χρησιμοποιηθεί σε υπολογισμούς.

7. Πειραματική Ανάλυση

Για το πειραματικό κομμάτι τις εργασίες σχεδιάστηκαν μοντέλα νευρωνικών δικτύων που επικεντρώνονται κυρίως στο κομμάτι της δημιουργίας embeddings, δηλαδή την ανάλυση των συσχετίσεων μεταξύ των κόμβων του γράφου. Φυσικά καθώς το πρόβλημα της εύρεσης υποπτων συναλλαγών είναι ένα πρόβλημα κατηγοριοποίησης τα παραπάνω νευρωνικά δίκτυα ενισχύθηκαν από δίκτυα κατηγοριοποίησης (classifiers). Πολύ σημαντικό ρολό είχε και η προ-επεξεργασία των δεδομένων για την δημιουργία χαρακτηριστικών τόσο για τους κόμβους του γράφου όσο και για τις ακμές, αλλά και η δημιουργία βαρών για την εξισορρόπησή της μεγάλης ανισορροπίας των δεδομένων.

7.1. Περιγραφή Πειραμάτων

Εκτελέστηκε πλήθος πειραμάτων που αφορούσε τόσο την δομή του μοντέλου καθώς και τις εποχές εκπαίδευσης του στο γράφο. Τα δεδομένα σε κάθε πείραμα ήταν ακριβώς τα ίδια ώστε οι διαφορές που αποτυπώθηκαν να είναι παρόμοιες για όλο το πλήθος πειραμάτων. Τα πειράματα που εκτελέστηκαν παρουσιάζονται στο παρακάτω πίνακα.

Όνομα Μοντέλου	Κατηγορία	Ειδική Κατηγορία	Εποχές Εκπαίδευσης
G2Sage_100	Graph Sage	G2Sage	100
G2Sage_200	Graph Sage	G2Sage	200
G2Sage_400	Graph Sage	G2Sage	400
G4Sage_100	Graph Sage	G4Sage	100
G4Sage_200	Graph Sage	G4Sage	200
G4Sage_400	Graph Sage	G4Sage	400
G2GraphSage_100	Graph Sage	G2GraphSage	100
G2GraphSage_200	Graph Sage	G2GraphSage	200
G2GraphSage_400	Graph Sage	G2GraphSage	400
GCN2Conv_100	Graph Convolutional	GCN2Conv	100
GCN2Conv_200	Graph Convolutional	GCN2Conv	200
GCN2Conv_400	Graph Convolutional	GCN2Conv	400
GCN4Conv_100	Graph Convolutional	GCN4Conv	100
GCN4Conv_200	Graph Convolutional	GCN4Conv	200
GCN4Conv_400	Graph Convolutional	GCN4Conv	400
G2Gat_20	Graph GAT	G2Gat	20
G2Gat_100	Graph GAT	G2Gat	100

Πίνακας 4 Λίστα Πειραμάτων

Παρατηρούμε ότι τα μοντέλα που εκπαιδεύτηκαν χωρίζονται σε 3 μεγάλες κατηγορίες νευρωνικών δικτύων οι οποίες αναλύθηκαν σε θεωρητικό μέρος στο Κεφάλαιο 5. Αλλά και

σε πέντε ειδικές υποκατηγορίες αναλόγως την δομή τους. Οι υποκατηγορίες αυτές θα παρουσιαστούν παρακάτω.

7.2. Αρχιτεκτονική Μοντέλων

- G2Sage

Το Μοντέλο G2Sage αποτελείται από 2 στρώματα SageConv τα οποία χρησιμοποιούνται για την δημιουργία embeddings για της σύνδεσης των κόμβων του γράφου, στη συνέχεια γίνεται συνδυασμός αυτής της πληροφορίας με τα χαρακτηριστικά των κόμβων και ώστε να χρησιμοποιηθεί ως είσοδος σε 2 Γραμμικά στρώματα για την κατηγοριοποίηση των ακμών. Παρακάτω φαίνεται η αναπαράσταση της δομής αυτής και χαρακτηριστικών της.

<i>Layer Name</i>	<i>Layer Type</i>	<i>Activation Function</i>	<i>Input Dimension</i>	<i>Output Dimension</i>	<i>Scope</i>
<i>sage1</i>	SageConv	Relu	4	64	Embeddings
<i>sage2</i>	SAGEConv	Relu	64	64	Embeddings
<i>concat</i>	Matrix Concatenation		64	212	Embeddings and Edge Features
<i>linear1</i>	Linear	Relu	212	64	Classification
<i>linear2</i>	Linear		64	2	Classification

Πίνακας 5 Αρχιτεκτονική G2Sage

- G4Sage

Το μοντέλο G4Sage αποτελείται από τέσσερα στρώματα SageConv για την δημιουργία embeddings για της γειτονικές σχέσεις των κόμβων. Η πληροφορία αυτή προστίθεται στα χαρακτηριστικά που έχουν συγκεντρωθεί για κάθε ακμή του γράφου και στην συνέχεια επεξεργάζεται από δύο γραμμικά στρώματα για την κατηγοριοποίηση της ακμής.

<i>Layer Name</i>	<i>Layer Type</i>	<i>Activation Function</i>	<i>Input Dimension</i>	<i>Output Dimension</i>	<i>Scope</i>
<i>sage1</i>	SageConv	Relu	4	64	Embeddings
<i>sage2</i>	SAGEConv	Relu	64	128	Embeddings
<i>sage3</i>	SAGEConv	Relu	128	64	Embeddings
<i>sage4</i>	SAGEConv	Relu	64	64	Embeddings
<i>concat</i>	Matrix Concatenation		64	212	Embeddings and Edge Features
<i>linear1</i>	Linear	Relu	212	64	Classification
<i>linear2</i>	Linear		64	2	Classification

Πίνακας 6 Αρχιτεκτονική G4Sage

- G2GraphSage

Το μοντέλο G2GraphSage αποτελείται από δύο στρώματα GraphSage για την δημιουργία embeddings των κόμβων του γράφου. Η πληροφορία αυτή συμπληρώνει τα χαρακτηριστικά για κάθε ακμή του γράφου και στην συνέχεια επεξεργάζεται από δύο γραμμικά στρώματα για την κατηγοριοποίηση της ακμής. Η κύρια διαφορά του από το SageConv είναι ότι ο GraphSage αποτελεί ένα είδος framework στην βιβλιοθήκη PyTorch Geometric το οποίο εσωτερικά χειρίζεται SageConv χωρίς ο χρήστης να χρειάζεται να υπολογίζει τις μεταξύ τους εναλλαγές

Layer Name	Layer Type	Activation Function	Input Dimension	Output Dimension	Layer s	Scope
sage concat	GraphSage	-	4	64	2	Embeddings
	Matrix Concatenation		64	212		Embeddings and Edge Features
linear 1	Linear	Relu	212	64		Classification
linear 2	Linear		64	2		Classification

Πίνακας 7 Αρχιτεκτονική G2GraphSage

- GCN2Conv

Το μοντέλο GCN2Conv απαρτίζεται από 2 στρώματα GCN τα οποία είναι υπεύθυνα για την δημιουργία embeddings για την για τους κόμβους του γράφου, στην συνέχεια τα αποτελέσματα αυτά συνδυάζονται με τα χαρακτηριστικά των ακμών ώστε να δοθεί συνολικά η πληροφορία στα δυο γραμμικά στρώματα κατηγοριοποίησης.

Layer Name	Layer Type	Activation Function	Input Dimension	Output Dimension	Scope
conv1	GCNConv	Relu	4	64	Embeddings
conv2	GCNConv	Relu	64	64	Embeddings
concat	Matrix Concatenation		64	212	Embeddings and Edge Features
linear1	Linear	Relu	212	64	Classification
linear2	Linear		64	2	Classification

Πίνακας 8 Αρχιτεκτονική GCN2Conv

- GCN4Conv

Η αρχιτεκτονική του μοντέλου GCN4Conv είναι μια εξέλιξη της αρχιτεκτονικής GCN2Conv, αποτελείται από 4 συνελλεκτικά δίκτυα για την δημιουργία χαρακτηριστικών ενσωμάτωσης των κόμβων στο γράφο, και στην συνέχεια αντίστοιχα με το GCN2Conv γίνεται συνδιασμός των χαρακτηριστικών ενσωμάτωσης με τα χαρακτηριστικά των ακμών και δίνονται σε δυο στρώματα γραμμικών δικτύων ώστε να γίνει κατηγοριοποίηση τους.

<i>Layer Name</i>	<i>Layer Type</i>	<i>Activation Function</i>	<i>Input Dimension</i>	<i>Output Dimension</i>	<i>Scope</i>
<i>conv1</i>	GCNConv	Relu	4	64	Embeddings
<i>conv2</i>	GCNConv	Relu	64	128	Embeddings
<i>conv3</i>	GCNConv	Relu	128	64	Embeddings
<i>conv4</i>	GCNConv	Relu	64	64	Embeddings
<i>concat</i>	Matrix Concatenation		64	212	Embeddings and Edge Features
<i>linear1</i>	Linear	Relu	212	64	Classification
<i>linear2</i>	Linear		64	2	Classification

Πίνακας 9 Αρχιτεκτονική GCN4Conv

- G2Gat

Το μοντέλο G2Gat χρησιμοποιεί ένα διαφορετικό κομμάτι των νευρωνικών δικτύων τους μηχανισμούς προσοχής για την δημιουργία embeddings, πιο συγκεκριμένα περιέχει δυο layers από GATs ώστε να αναλύσει τους κόμβους και στην συνέχεια αφού συγκεντώσει τα στοιχεία για τους κόμβους και τους τα χαρακτηριστικά των ακμών τότε μέσω ενός γραμμικού δικτύου κατηγοριοποιεί τα δεδομένα.


<i>Layer Name</i>	<i>Layer Type</i>	<i>Activation Function</i>	<i>Input Dimension</i>	<i>Output Dimension</i>	<i>Head</i>	<i>Scope</i>
<i>gat1</i>	GATConv	Relu	4	64	8	Embeddings
<i>gat2</i>	GATConv	Relu	512	64	1	Embeddings
<i>concat</i>	Matrix Concatenation		64	212		Embeddings and Edge Features
<i>linear</i>	Linear		212	2		Classification

Πίνακας 10 Αρχιτεκτονική G2Gat

7.3. Ανάλυση Μοντέλων

- G2Sage_100

Το μοντέλο G2Sage_100 εκπαιδεύτηκε για 100 εποχές και με ρυθμό μάθησης 0,01. Ο συνολικός χρόνος εκπαίδευσης του μοντέλου ήταν 17 λεπτά και 46 δευτερόλεπτα. Το Γράφημα 2 αποτυπώνει το ρυθμό μείωσης της απώλειας του μοντέλου ανά εποχή εκπαίδευσης.



Γράφημα 2 Ρυθμός Μεταβολής Απώλειας ανά Εποχή G2Sage_100

Παρατηρούμε από το γράφημα ότι το μοντέλο σταδιακά μειώνει την απώλεια του, στην αρχή υπάρχουν έντονες αλλαγές σε κάθε επεισόδιο ενώ μετά τις 50 εποχές ο ρυθμός μείωσης της απώλειας σταθεροποιείται.

Στην συνέχεια έγινε αξιολόγηση του μοντέλου σε νέο σύνολο δεδομένων, το οποίο δεν χρησιμοποιήθηκε στην εκπαίδευση. Το σύνολο δεδομένων αυτό είχε συνολικά 6.653.397 συναλλαγές από τις οποίες η 6989 ήταν χαρακτηρισμένες ως ύποπτες. Το G2Sage_100 χρειάστηκε 5 δευτερόλεπτα και 298 χιλιοστά του δευτερολέπτου για να αποφασίσει για κάθε συναλλαγή αν αυτή είναι ύποπτη ή όχι. Παρακάτω ακολουθεί ο πίνακας σύγκρισης των αποτελεσμάτων.


		Predicted	
		Νόμιμη	Ύποπτη
Actual	Νόμιμη	126.746	6.519.662
	Ύποπτη	56	6933

Πίνακας 11 Πίνακας Σύγχυσης G2Sage_100

Παρατηρούμε ότι το μοντέλο G2Sage_100 δεν κατάφερε να επιλύσει το πρόβλημα και μάλιστα έχει επιτυχία στις απαντήσεις του 2,01%, ενώ η τιμή ROC είναι 50,55% δηλαδή το μοντέλο απαντάει τυχαία. Δεν έχει σημασία να αναλύσουμε περεταίρω μετρικές στο πρόβλημα, καθώς βλέπουμε ότι το μοντέλο αυτό δεν έχει καταφέρει να κατανοήσει καθόλου τις διαφορές νόμιμων και ύποπτων συναλλαγών.

- G2Sage_200

Το μοντέλο G2Sage_200 εκπαιδεύτηκε για 200 εποχές και με ρυθμό μάθησης 0,01. Ο συνολικός χρόνος εκπαίδευσης του μοντέλου ήταν 32 λεπτά και 27 δευτερόλεπτα. Το Γράφημα 3 αποτυπώνει το ρυθμό μείωσης της απώλειας του μοντέλου ανά εποχή εκπαίδευσης.



Γράφημα 3 Ρυθμός Μεταβολής Απώλειας ανά Εποχή G2Sage_200

Παρατηρούμε από το γράφημα ότι το μοντέλο σταδιακά μειώνει την απώλεια του, στην αρχή υπάρχουν έντονες αλλαγές σε κάθε επεισόδιο ενώ μετά τις 55 εποχές ο ρυθμός μείωσης της απώλειας σταθεροποιείται και σταθερά μέχρι της 200 εποχές μειώνεται

Στην συνέχεια έγινε αξιολόγηση του μοντέλου σε νέο σύνολο δεδομένων, το οποίο δεν χρησιμοποιήθηκε στην εκπαίδευση. Το σύνολο δεδομένων αυτό είχε συνολικά 6.653.397 συναλλαγές από τις οποίες η 6989 ήταν χαρακτηρισμένες ως ύποπτες. Το G2Sage_200 χρειάστηκε 4 δευτερόλεπτα και 13 χιλιοστά του δευτερολέπτου για να αποφασίσει για κάθε συναλλαγή αν αυτή είναι ύποπτη ή όχι. Παρακάτω ακολουθεί ο πίνακας σύγχυσης των αποτελεσμάτων.

		Predicted	
		Νόμιμη	Ύποπτη
Actual	Νόμιμη	4.050.601	2.595.807
	Ύποπτη	83	6906

Πίνακας 12 Πίνακας Σύγχυσης G2Sage_200

Παρατηρούμε ότι το μοντέλο G2Sage_200 δεν κατάφερε να επιλύσει πλήρως το πρόβλημα αλλά κατάφερα να αξιολογήσει σωστά το 60,98% των συναλλαγών. Η τιμή ROC ήταν στο 79,88%, αυτό σημαίνει ότι το μοντέλο δεν έχει κατανοήσει πλήρως το πρόβλημα αλλά μπορεί να διακρίνει βασικές διαφορές μεταξύ των συναλλαγών. Παρακάτω ακολουθεί πίνακας για τις τιμές Precision Recall και F1 Score για το μοντέλο G2Sage_200.


	Precision	Recall	F1
Νόμιμες	1	0,61	0,76
Ύποπτες	0	0,99	0,01

Πίνακας 13 Precision, Recal, F1 Score για το G2Sage_200

Από το Πίνακας 13 παρατηρούμε ότι το μοντέλο έχει ακρίβεια σχεδόν 1 για τις νόμιμες συναλλαγές ενώ σχεδόν 0 για τις ύποπτες συναλλαγές. Καταλαβαίνουμε λοιπόν ότι το μοντέλο είναι ακριβές στο πότε μια συναλλαγή είναι νόμιμη αλλά καθόλου ακριβές όταν μια συναλλαγή είναι ύποπτη, αφού κατηγοριοποιείσαι 2.595.807 νόμιμες συναλλαγές ως ύποπτες. Αντιθέτως το μοντέλο είναι πολύ καλό στο να ανιχνεύει τις ύποπτες συναλλαγές καθώς κατάφερε να εντοπίσει το 99% από αυτές από τις 6989 ύποπτες συναλλαγές το μοντέλο κατάφερε να εντοπίσει τις 6906 συναλλαγές ενώ έχασε μόλις της 83.

- G2Sage_400

Το μοντέλο G2Sage_400 εκπαιδεύτηκε για 400 εποχές και με ρυθμό μάθησης 0,01. Ο συνολικός χρόνος εκπαίδευσης του μοντέλου ήταν 1 ώρα 3 λεπτά και 37 δευτερόλεπτα. Το Γράφημα 4 αποτυπώνει το ρυθμό μείωσης της απώλειας του μοντέλου ανά εποχή εκπαίδευσης.



Γράφημα 4 Ρυθμός Μεταβολής Απώλειας ανά Εποχή G2Sage_400

Παρατηρούμε από το γράφημα ότι το μοντέλο σταδιακά μειώνει την απώλεια του, στην αρχή υπάρχουν έντονες αλλαγές σε κάθε επεισόδιο ενώ μετά τις 75 εποχές ο ρυθμός μεταβολής της απώλειας σταθεροποιείται και σταθερά μέχρι της 240 εποχές μειώνεται. Εκεί βλέπουμε μια εναλλαγή και μια τοπική αύξηση, που στην συνέχεια διορθώνεται και η απώλεια συνεχίζει να μειώνεται μέχρι τις 400 εποχές.

Στην συνέχεια έγινε αξιολόγηση του μοντέλου σε νέο σύνολο δεδομένων, το οποίο δεν χρησιμοποιήθηκε στην εκπαίδευση. Το σύνολο δεδομένων αυτό είχε συνολικά 6.653.397 συναλλαγές από τις οποίες η 6989 ήταν χαρακτηρισμένες ως ύποπτες. Το G2Sage_400 χρειάστηκε 3 δευτερόλεπτα και 910 χιλιοστά του δευτερολέπτου για να αποφασίσει για όλες τις συναλλαγές αν είναι ύποπτες ή όχι. Παρακάτω ακολουθεί ο πίνακας σύγχυσης των αποτελεσμάτων.

		Predicted	
		Νόμιμη	Ύποπτη
Actual	Νόμιμη	6.310.374	336.034
	Ύποπτη	544	6445

Πίνακας 14 Πίνακας Σύγχυσης G2Sage_400

Παρατηρούμε ότι το μοντέλο G2Sage_400 κατάφερε να αξιολογήσει σωστά το 94,94% των συναλλαγών. Η τιμή ROC ήταν στο 93,58%, αυτό σημαίνει ότι το μοντέλο κατανοεί τις διαφορές μεταξύ νόμιμων και ύποπτων συναλλαγών. Παρακάτω ακολουθεί πίνακας για τις τιμές Precision Recall και F1 Score για το μοντέλο G2Sage_400.


	Precision	Recall	F1
Νόμιμες	1	0,95	0,97
Ύποπτες	0,02	0,92	0,04

Πίνακας 15 Precision, Recall, F1 Score για το G2Sage_400

Από το Πίνακας 15 παρατηρούμε ότι το μοντέλο G2Sage_400 έχει ακρίβεια σχεδόν 1 για τις νόμιμες συναλλαγές ενώ σχεδόν 0,02 για τις ύποπτες συναλλαγές. Καταλαβαίνουμε λοιπόν ότι το μοντέλο είναι ακριβές στο πότε μια συναλλαγή είναι νόμιμη αλλά καθόλου ακριβές όταν μια συναλλαγή είναι ύποπτη, γι' αυτό κατηγοριοποιείσαι 336.034 νόμιμες συναλλαγές ως ύποπτες. Αντιθέτως το μοντέλο είναι πολύ καλό στο να ανιχνεύει τις ύποπτες συναλλαγές καθώς κατάφερε να εντοπίσει το 92% από τις 6989 ύποπτες αλλά και το 95% από τις νόμιμες.

- G4Sage_100

Το μοντέλο G2Sage_100 εκπαιδεύτηκε για 100 εποχές και με ρυθμό μάθησης 0,01. Ο συνολικός χρόνος εκπαίδευσης του μοντέλου ήταν 25 λεπτά και 56 δευτερόλεπτα. Το Γράφημα 5 αποτυπώνει το ρυθμό μείωσης της απώλειας του μοντέλου ανά εποχή εκπαίδευσης.



Γράφημα 5 Ρυθμός Μεταβολής Απώλειας ανά Εποχή G4Sage_100

Παρατηρούμε από το γράφημα ότι το μοντέλο σταδιακά μειώνει την απώλεια του, ενώ από την αρχή η απώλεια μειώνεται το μοντέλο χρειάζεται μεγάλο αριθμό εποχών για να καταφέρει να σταθεροποιήσει το ρυθμό μεταβολής, ο οποίος μετά την εποχή 70 σταματάει να μεταλλάσσεται.

Στην συνέχεια έγινε αξιολόγηση του μοντέλου σε νέο σύνολο δεδομένων, το οποίο δεν χρησιμοποιήθηκε στην εκπαίδευση. Το σύνολο δεδομένων αυτό είχε συνολικά 6.653.397 συναλλαγές από τις οποίες η 6989 ήταν χαρακτηρισμένες ως ύποπτες. Το G4Sage_100 χρειάστηκε 6 δευτερόλεπτα και 383 χιλιοστά του δευτερολέπτου για να αποφασίσει για όλες τις συναλλαγές αν είναι ύποπτες ή όχι. Παρακάτω ακολουθεί ο πίνακας σύγκρισης των αποτελεσμάτων.

		Predicted	
		Νόμιμη	Ύποπτη
Actual	Νόμιμη	6.389.401	257.007
	Ύποπτη	1.779	5.210

Πίνακας 16 Πίνακας Σύγκρισης G4Sage_100

Παρατηρούμε ότι το μοντέλο G4Sage_100 κατάφερε να αξιολογήσει σωστά το 96,1% των συναλλαγών, αριθμός σχετικά πλασματικός καθώς είχε μεγάλη επιτυχία μόνο στις νόμιμες

συναλλαγές, που είναι το μεγαλύτερο μέρος του συνόλου δεδομένων. Η τιμή ROC ήταν στο 85,34%, αυτό σημαίνει ότι το μοντέλο κατανοεί τις διαφορές μεταξύ νόμιμων και ύποπτων συναλλαγών μέχρι ένα βαθμό, αλλά όχι πλήρως. Παρακάτω ακολουθεί πίνακας για τις τιμές Precision Recall και F1 Score για το μοντέλο G4Sage_100.


	Precision	Recall	F1
Νόμιμες	1	0,96	0,98
Ύποπτες	0,02	0,75	0,04

Πίνακας 17 Precision, Recall, F1 Score για το G4Sage_100

Από το Πίνακα 17 παρατηρούμε ότι το μοντέλο G4Sage_100 έχει ακρίβεια σχεδόν 1 για τις νόμιμες συναλλαγές ενώ σχεδόν 2% από τις συναλλαγές που χαρακτηρίστηκαν ήταν στην πραγματικότητα. Επίσης το μοντέλο μπορεί με να εντοπίσει το 75% των ύποπτων συναλλαγών και το 96% των νόμιμων συναλλαγών, έτσι μπορούμε να συμπεράνουμε ότι το μοντέλο έχει μια τάση να κατηγοριοποιεί ως ύποπτες τις συναλλαγές που είναι νόμιμες.

- G4Sage_200

Το μοντέλο G4Sage_200 εκπαιδεύτηκε για 200 εποχές και με ρυθμό μάθησης 0,01. Ο συνολικός χρόνος εκπαίδευσης του μοντέλου ήταν 52 λεπτά και 18 δευτερόλεπτα. Το Γράφημα 6 αποτυπώνει το ρυθμό μείωσης της απώλειας του μοντέλου ανά εποχή εκπαίδευσης.



Γράφημα 6 Ρυθμός Μεταβολής Απώλειας ανά Εποχή G4Sage_200

Παρατηρούμε από το γράφημα ότι το μοντέλο σταδιακά μειώνει την απώλεια του, και σχετικά συγκλίνει γρήγορα προς μικρούς αριθμούς απώλειας. Επίσης παρατηρούμε ότι μετά τις 55 εποχές το μοντέλο σταθεροποιεί το ρυθμό μεταβολής της απώλειας μέχρι και τις 200 εποχές που σταματάει η εκπαίδευση του.

Στην συνέχεια έγινε αξιολόγηση του μοντέλου σε νέο σύνολο δεδομένων, το οποίο δεν χρησιμοποιήθηκε στην εκπαίδευση. Το σύνολο δεδομένων αυτό είχε συνολικά 6.653.397 συναλλαγές από τις οποίες η 6989 ήταν χαρακτηρισμένες ως ύποπτες. Το G4Sage_200 χρειάστηκε 6 δευτερόλεπτα και 934 χιλιοστά του δευτερολέπτου για να αποφασίσει για όλες τις συναλλαγές αν είναι ύποπτες ή όχι. Παρακάτω ακολουθεί ο πίνακας σύγκρισης των αποτελεσμάτων.

		Predicted	
		Νόμιμη	Ύποπτη
Actual	Νόμιμη	6.481.198	165.210
	Ύποπτη	729	6260

Πίνακας 18 Πίνακας Σύγκρισης G4Sage_200

Παρατηρούμε ότι το μοντέλο G4Sage_200 κατάφερε να αξιολογήσει σωστά το 97,51% των συναλλαγών. Επίσης σημειώνει ένα ROC AUC Score 93,54%, από το roc score

καταλαβαίνουμε ότι το μοντέλο κατανοεί σε πολύ μεγάλο βαθμό της διαφορές μεταξύ νόμιμων και ύποπτων συναλλαγών . Παρακάτω ακολουθεί πίνακας για τις τιμές Precision Recall και F1 Score για το μοντέλο G4Sage_200.


	Precision	Recall	F1
Νόμιμες	1	0,98	0,99
Ύποπτες	0,04	0,90	0,07

Πίνακας 19 Precision, Recal, F1 Scorel για το G4Sage_200

Από το Πίνακας 17 παρατηρούμε ότι το μοντέλο G4Sage_200 έχει ακρίβεια σχεδόν 100% για τις νόμιμες συναλλαγές ενώ σχεδόν 4% από τις συναλλαγές που χαρακτηρίστηκαν ήταν στην πραγματικότητα. Επίσης το μοντέλο μπορεί με να εντοπίσει το 90% των ύποπτων συναλλαγών και το 98% των νόμιμων συναλλαγών, έτσι μπορούμε να συμπεράνουμε ότι το μοντέλο έχει είναι ικανό να εντοπίζει τις ύποπτες συναλλαγές, αλλά επίσης να κατηγοριοποιεί νόμιμες συναλλαγές ως ύποπτες.

- G4Sage_400

Το μοντέλο G4Sage_200 εκπαιδεύτηκε για 400 εποχές και με ρυθμό μάθησης 0,01. Ο συνολικός χρόνος εκπαίδευσης του μοντέλου ήταν 1ώρα 44 λεπτά και 20 δευτερόλεπτα. Το Γράφημα 7 αποτυπώνει το ρυθμό μείωσης της απώλειας του μοντέλου ανά εποχή εκπαίδευσης.



Γράφημα 7 Ρυθμός Μεταβολής Απώλειας ανά Εποχή G4Sage_400

Παρατηρούμε από το γράφημα ότι το μοντέλο σταδιακά μειώνει την απώλεια του, και σχετικά συγκλίνει γρήγορα προς μικρούς αριθμούς απώλειας. Επίσης παρατηρούμε ότι μετά τις 65 εποχές το μοντέλο σταθεροποιεί το ρυθμό μεταβολής της απώλειας μέχρι και τις 400 εποχές που σταματάει η εκπαίδευση του.

Στην συνέχεια έγινε αξιολόγηση του μοντέλου σε νέο σύνολο δεδομένων, το οποίο δεν χρησιμοποιήθηκε στην εκπαίδευση. Το σύνολο δεδομένων αυτό είχε συνολικά 6.653.397 συναλλαγές από τις οποίες η 6989 ήταν χαρακτηρισμένες ως ύποπτες. Το G4Sage_400 χρειάστηκε 6 δευτερόλεπτα και 227 χιλιοστά του δευτερολέπτου για να αποφασίσει για όλες τις συναλλαγές αν είναι ύποπτες ή όχι. Παρακάτω ακολουθεί ο πίνακας σύγχυσης των αποτελεσμάτων.

		Predicted	
		Νόμιμη	Ύποπτη
Actual	Νόμιμη	6626819	19589
	Ύποπτη	2165	4824

Πίνακας 20 Πίνακας Σύγχυσης G4Sage_400

Παρατηρούμε ότι το μοντέλο G4Sage_400 κατάφερε να αξιολογήσει σωστά το 99,67% των συναλλαγών. Επίσης σημειώνει ένα ROC AUC Score 84,346%, από το roc score

καταλαβαίνουμε ότι το μοντέλο αναλύει σε ένα βαθμό της δομή των δεδομένων. Παρακάτω ακολουθεί πίνακας για τις τιμές Precision Recall και F1 Score για το μοντέλο G4Sage_400.


	Precision	Recall	F1
Νόμιμες	1	1	1
Ύποπτες	0,2	0,69	0,31

Πίνακας 21 Precision, Recall, F1 Score για το G4Sage_200

Από το Πίνακα 21 παρατηρούμε ότι το μοντέλο G4Sage_400 έχει ακρίβεια σχεδόν 100% για τις νόμιμες συναλλαγές ενώ το 20% από τις συναλλαγές που χαρακτηρίστηκαν ύποπτες ήταν στην πραγματικότητα. Επίσης το μοντέλο μπορεί να εντοπίσει το 69% των ύποπτων συναλλαγών και το 100% των νόμιμων συναλλαγών, έτσι μπορούμε να συμπεράνουμε ότι το συγκεκριμένα μοντέλο διαχωρίζει της νόμιμες συναλλαγές αλλά δεν μπορεί να διαχωρίσει καλά της ύποπτες και πολλές φορές θεωρεί νόμιμες ως ύποπτες αλλά χάνει και το 31% των ύποπτων συναλλαγών αφού τις θέτει ως νόμιμες.

- G2GraphSAGE_100

Το μοντέλο G2GraphSAGE_100 εκπαιδεύτηκε για 100 εποχές και με ρυθμό μάθησης 0,01. Ο συνολικός χρόνος εκπαίδευσης του μοντέλου ήταν 20 λεπτά και 24 δευτερόλεπτα. Το Γράφημα 8 αποτυπώνει το ρυθμό μείωσης της απώλειας του μοντέλου ανά εποχή εκπαίδευσης.



Γράφημα 8 Ρυθμός Μεταβολής Απώλειας ανά Εποχή G2GraphSage_100

Παρατηρούμε από το γράφημα ότι το μοντέλο μειώνει γρήγορα την συνολική απώλεια ανα εποχή. Επίσης παρατηρούμε ότι μετά τις 40 εποχές το μοντέλο σταθεροποιεί το ρυθμό μεταβολής της απώλειας μέχρι και τις 100 εποχές που σταματάει η εκπαίδευση του.

Στην συνέχεια έγινε αξιολόγηση του μοντέλου σε νέο σύνολο δεδομένων, το οποίο δεν χρησιμοποιήθηκε στην εκπαίδευση. Το σύνολο δεδομένων αυτό είχε συνολικά 6.653.397 συναλλαγές από τις οποίες η 6989 ήταν χαρακτηρισμένες ως ύποπτες. Το G2GraphSAGE_100 χρειάστηκε 8 δευτερόλεπτα και 947 χιλιοστά του δευτερολέπτου για να αποφασίσει για όλες τις συναλλαγές αν είναι ύποπτες ή όχι. Παρακάτω ακολουθεί ο πίνακας σύγχυσης των αποτελεσμάτων.

		Predicted	
		Νόμιμη	Ύποπτη
Actual	Νόμιμη	6215979	430429
	Ύποπτη	2514	4475

Πίνακας 22 Πίνακας Σύγχυσης G2GraphSage_100

Παρατηρούμε ότι το μοντέλο G2GraphSAGE_100 κατάφερε να αξιολογήσει σωστά το 93,49% των συναλλαγών. Επίσης σημειώνει ένα ROC AUC Score 78,78%, από το roc score καταλαβαίνουμε ότι το μοντέλο αναλύει σε ένα βαθμό της δομή των δεδομένων

αλλά όχι αρκετά καλά ώστε να επιλύσει το πρόβλημα. Παρακάτω ακολουθεί πίνακας για τις τιμές Precision Recall και F1 Score για το μοντέλο G2GraphSAGE_100.


	Precision	Recall	F1
Νόμιμες	1	0,94	0,97
Υποπτες	0,01	0,64	0,03

Πίνακας 23 Precision, Recall, F1 Score για το G2GraphSage_100

Από το Πίνακας 23 παρατηρούμε ότι το μοντέλο G2GraphSAGE_100 έχει ακρίβεια σχεδόν 100% για τις νόμιμες συναλλαγές, δηλαδή σχεδόν όλες οι συναλλαγές που κατατάσσει ως νόμιμες είναι όντως νόμιμες, ενώ μόλις το 1% από τις συναλλαγές που χαρακτηρίστηκαν ύποπτες ήταν στην πραγματικότητα. Επίσης το μοντέλο μπορεί να εντοπίσει το 64% των ύποπτων συναλλαγών, δηλαδή από το σύνολο των ύποπτων συναλλαγών το μοντέλο βρήκε το 64% και το σχεδόν 94% των νόμιμων συναλλαγών, έτσι μπορούμε να συμπεράνουμε ότι το συγκεκριμένα μοντέλο διαχωρίζει της νόμιμες συναλλαγές αλλά δεν μπορεί να διαχωρίσει καλά της ύποπτες.

- G2GraphSage_200

Το μοντέλο G2GraphSAGE_200 εκπαιδεύτηκε για 200 εποχές και με ρυθμό μάθησης 0,01. Ο συνολικός χρόνος εκπαίδευσης του μοντέλου ήταν 40 λεπτά και 31 δευτερόλεπτα. Το αποτυπώνει το ρυθμό μείωσης της απώλειας του μοντέλου ανά εποχή εκπαίδευσης.



Γράφημα 9 Ρυθμός Μεταβολής Απώλειας ανά Εποχή G2GraphSage_200

Παρατηρούμε από το γράφημα ότι το μοντέλο μειώνει γρήγορα την συνολική απώλεια ανα εποχή. Αλλά χρειάζεται πάνω από 115 εποχές προκειμένου να αρχίσει να σταθεροποιεί το ρυθμό μεταβολής της απώλειας του.

Στην συνέχεια έγινε αξιολόγηση του μοντέλου σε νέο σύνολο δεδομένων, το οποίο δεν χρησιμοποιήθηκε στην εκπαίδευση. Το σύνολο δεδομένων αυτό είχε συνολικά 6.653.397 συναλλαγές από τις οποίες η 6989 ήταν χαρακτηρισμένες ως ύποπτες. Το G2GraphSAGE_200 χρειάστηκε 6 δευτερόλεπτα και 873 χιλιοστά του δευτερολέπτου για να αποφασίσει για όλες τις συναλλαγές αν είναι ύποπτες ή όχι. Παρακάτω ακολουθεί ο πίνακας σύγχυσης των αποτελεσμάτων.

		Predicted	
		Νόμιμη	Ύποπτη
Actual	Νόμιμη	6282846	363562
	Ύποπτη	434	6555

Πίνακας 24 Πίνακας Σύγχυσης G2GraphSage_200

Παρατηρούμε ότι το μοντέλο G2GraphSAGE_200 κατάφερε να αξιολογήσει σωστά το 94,53% των συναλλαγών. Επίσης σημειώνει ένα ROC AUC Score 94,16%, από το roc score καταλαβαίνουμε ότι το μοντέλο αναλύει σε μεγάλο βαθμό την δομή του

προβλήματος και μπορεί να κατηγοριοποιεί το μεγαλύτερο ποσοστό των δεδομένων στην κατηγορία που ανήκουν. Παρακάτω ακολουθεί πίνακας για τις τιμές Precision Recall και F1 Score για το μοντέλο G2GraphSAGE_200.


	Precision	Recall	F1
Νόμιμες	1	0,95	0,97
Ύποπτες	0,01	0,94	0,03

Πίνακας 25 Precision, Recall, F1 Score για το G2GraphSage_200

Από το Πίνακας 25 παρατηρούμε ότι το μοντέλο G2GraphSAGE_200 έχει ακρίβεια σχεδόν 100% για τις νόμιμες συναλλαγές, δηλαδή σχεδόν όλες οι συναλλαγές που κατατάσσει ως νόμιμες είναι όντως νόμιμες, ενώ μόλις το 1% από τις συναλλαγές που χαρακτηρίστηκαν ύποπτες ήταν στην πραγματικότητα. Επίσης το μοντέλο μπορεί να εντοπίσει το 94% των ύποπτων συναλλαγών, δηλαδή από το σύνολο των ύποπτων συναλλαγών το μοντέλο βρήκε το 94% και το σχεδόν 95% των νόμιμων συναλλαγών, άρα παρατηρούμε ότι το μοντέλο μπορεί να ανιχνεύσει το μεγαλύτερο ποσοστό των συναλλαγών στην κατηγορία που ανήκουν αλλά έχει τάση να κατηγοριοποιεί συναλλαγές που είναι νόμιμες ως ύποπτες.

- G2GraphSage_400

Το μοντέλο G2GraphSAGE_400 εκπαιδεύτηκε για 400 εποχές και με ρυθμό μάθησης 0,01. Ο συνολικός χρόνος εκπαίδευσης του μοντέλου ήταν 1 ώρα 13 λεπτά και 50 δευτερόλεπτα. Το Γράφημα 10 αποτυπώνει το ρυθμό μείωσης της απώλειας του μοντέλου ανά εποχή εκπαίδευσης.



Γράφημα 10 Ρυθμός Μεταβολής Απώλειας ανά Εποχή G2GraphSage_400

Παρατηρούμε από το γράφημα ότι το μοντέλο μειώνει γρήγορα την συνολική απώλεια ανά εποχή και μετά σχεδόν από 50 εποχές σταθεροποιεί το ρυθμό μεταβολής της απώλειας του.

Στην συνέχεια έγινε αξιολόγηση του μοντέλου σε νέο σύνολο δεδομένων, το οποίο δεν χρησιμοποιήθηκε στην εκπαίδευση. Το σύνολο δεδομένων αυτό είχε συνολικά 6.653.397 συναλλαγές από τις οποίες η 6989 ήταν χαρακτηρισμένες ως ύποπτες. Το G2GraphSAGE_400 χρειάστηκε 5 δευτερόλεπτα και 876 χιλιοστά του δευτερολέπτου για να αποφασίσει για όλες τις συναλλαγές αν είναι ύποπτες ή όχι. Παρακάτω ακολουθεί ο πίνακας σύγκρισης των αποτελεσμάτων.

		Predicted	
		Νόμιμη	Ύποπτη
Actual	Νόμιμη	6111935	534473
	Ύποπτη	187	6802

Πίνακας 26 Πίνακας Σύγκρισης G2GraphSage_400

Παρατηρούμε ότι το μοντέλο G2GraphSAGE_400 κατάφερε να αξιολογήσει σωστά το 91,96s% των συναλλαγών. Επίσης σημειώνει ένα ROC AUC Score 94,64%, από το roc score καταλαβαίνουμε ότι το μοντέλο αναλύει σε μεγάλο βαθμό την δομή του

προβλήματος και μπορεί να κατηγοριοποιεί το μεγαλύτερο ποσοστό των δεδομένων στην κατηγορία που ανήκουν. Παρακάτω ακολουθεί πίνακας για τις τιμές Precision Recall και F1 Score για το μοντέλο G2GraphSAGE_400.


	Precision	Recall	F1
Νόμιμες	1	0,92	0,96
Ύποπτες	0,01	0,97	0,02

Πίνακας 27 Precision, Recall, F1 Score για το G2GraphSage_400

Από το Πίνακας 27 παρατηρούμε ότι το μοντέλο G2GraphSAGE_200 έχει ακρίβεια σχεδόν 100% για τις νόμιμες συναλλαγές, δηλαδή σχεδόν όλες οι συναλλαγές που κατατάσσει ως νόμιμες είναι όντως νόμιμες, ενώ μόλις το 1% από τις συναλλαγές που χαρακτηρίστηκαν ύποπτες ήταν στην πραγματικότητα. Επίσης το μοντέλο μπορεί να εντοπίσει το 97% των ύποπτων συναλλαγών, δηλαδή από το σύνολο των ύποπτων συναλλαγών το μοντέλο βρήκε τις 6802 και το σχεδόν 95% των νόμιμων συναλλαγών, άρα παρατηρούμε ότι το μοντέλο μπορεί να ανιχνεύσει το μεγαλύτερο ποσοστό των συναλλαγών στην κατηγορία που ανήκουν αλλά έχει τάση να κατηγοριοποιεί συναλλαγές που είναι νόμιμες ως ύποπτες.

- GCN2Conv_100

Το μοντέλο GCN2Conv_100 εκπαιδεύτηκε για 100 εποχές και με ρυθμό μάθησης 0,01. Ο συνολικός χρόνος εκπαίδευσης του μοντέλου ήταν 21 λεπτά και 57 δευτερόλεπτα. Το Γράφημα 11 αποτυπώνει το ρυθμό μείωσης της απώλειας του μοντέλου ανά εποχή εκπαίδευσης.



Γράφημα 11 Ρυθμός Μεταβολής Απώλειας ανά Εποχή GCN2Conv_100

Παρατηρούμε από το γράφημα ότι το μοντέλο μειώνει γρήγορα την συνολική απώλεια ανά εποχή και μετά σχεδόν από 50 εποχές σταθεροποιεί το ρυθμό μεταβολής της απώλειας του.

Στην συνέχεια έγινε αξιολόγηση του μοντέλου σε νέο σύνολο δεδομένων, το οποίο δεν χρησιμοποιήθηκε στην εκπαίδευση. Το σύνολο δεδομένων αυτό είχε συνολικά 6.653.397 συναλλαγές από τις οποίες η 6989 ήταν χαρακτηρισμένες ως ύποπτες. Το GCN2Conv_100 χρειάστηκε 6 δευτερόλεπτα και 201 χιλιοστά του δευτερολέπτου για να αποφασίσει για όλες τις συναλλαγές αν είναι ύποπτες ή όχι. Παρακάτω ακολουθεί ο πίνακας σύγχυσης των αποτελεσμάτων.

		Predicted	
		Νόμιμη	Ύποπτη
Actual	Νόμιμη	3306592	3339816
	Ύποπτη	1481	5508

Πίνακας 28 Πίνακας Σύγχυσης GCN2Conv_100

Παρατηρούμε ότι το μοντέλο GCN2Conv_100 κατάφερε να αξιολογήσει σωστά το 49,78% των συναλλαγών. Επίσης σημειώνει ένα ROC AUC Score 64,28%, από το roc score καταλαβαίνουμε ότι το μοντέλο δεν μπορεί να κατανοήσει το πρόβλημα. Παρακάτω

ακολουθεί πίνακας για τις τιμές Precision Recall και F1 Score για το μοντέλο GCN2Conv_100.


	Precision	Recall	F1
Νόμιμες	1	0,5	0,66
Υποπτες	0	0,79	0

Πίνακας 29 Precision, Recall, F1 Score για το GCN2Conv_100

Από το Πίνακα 29 παρατηρούμε ότι το μοντέλο GCN2Conv_100 έχει ακρίβεια σχεδόν 100% για τις νόμιμες συναλλαγές, δηλαδή σχεδόν όλες οι συναλλαγές που κατατάσσει ως νόμιμες είναι όντως νόμιμες, ενώ από τις συναλλαγές που κατατάσσονται ως ύποπτες το ποσοστό που είναι όντως ύποπτες είναι πλησιάζει το 0% δηλαδή οι τιμές που είναι λάθος κατηγοριοποιημένες ως ύποπτες αλλά είναι νόμιμες καλύπτουν όλο το πλήθος. Επίσης το μοντέλο μπορεί να εντοπίσει το 79% των ύποπτων συναλλαγών, δηλαδή από το σύνολο των ύποπτων συναλλαγών το μοντέλο βρήκε τις 5508. Αλλά σχεδόν το σχεδόν 50% των νόμιμων συναλλαγών.

- GCN2Conv_200

Το μοντέλο GCN2Conv_200 εκπαιδεύτηκε για 200 εποχές και με ρυθμό μάθησης 0,01. Ο συνολικός χρόνος εκπαίδευσης του μοντέλου ήταν 44 λεπτά και 57 δευτερόλεπτα. Το Γράφημα 12 αποτυπώνει το ρυθμό μείωσης της απώλειας του μοντέλου ανά εποχή εκπαίδευσης.



Γράφημα 12 Ρυθμός Μεταβολής Απώλειας ανά Εποχή GCN2Conv_200

Παρατηρούμε από το γράφημα ότι το μοντέλο μειώνει σταδιακά την συνολική απώλεια ανά εποχή και μετά σχεδόν από 50 εποχές σταθεροποιεί το ρυθμό μεταβολής της απώλειας του.

Στην συνέχεια έγινε αξιολόγηση του μοντέλου σε νέο σύνολο δεδομένων, το οποίο δεν χρησιμοποιήθηκε στην εκπαίδευση. Το σύνολο δεδομένων αυτό είχε συνολικά 6.653.397 συναλλαγές από τις οποίες η 6989 ήταν χαρακτηρισμένες ως ύποπτες. Το GCN2Conv_200 χρειάστηκε 6 δευτερόλεπτα και 469 χιλιοστά του δευτερολέπτου για να αποφασίσει για όλες τις συναλλαγές αν είναι ύποπτες ή όχι. Παρακάτω ακολουθεί ο πίνακας σύγχυσης των αποτελεσμάτων.

		Predicted	
		Νόμιμη	Ύποπτη
Actual	Νόμιμη	6062371	584037
	Ύποπτη	5278	1711

Πίνακας 30 Πίνακας Σύγχυσης GCN2Conv_200

Παρατηρούμε ότι το μοντέλο GCN2Conv_200 κατάφερε να αξιολογήσει σωστά το 91,14% των συναλλαγών. Επίσης σημειώνει ένα ROC AUC Score 57,85%, η τιμή είναι τόσο χαμηλή γιατί το μοντέλο έχει κατατάξει λάθος το μεγαλύτερο αριθμό από τις ύποπτες

συναλλαγές. Παρακάτω ακολουθεί πίνακας για τις τιμές Precision Recall και F1 Score για το μοντέλο GCN2Conv_100.


	Precision	Recall	F1
Νόμιμες	1	0,91	0,95
Ύποπτες	0	0,24	0,01

Πίνακας 31 Precision, Recall, F1 Score για το GCN2Conv_200

Από το Πίνακα 31 παρατηρούμε ότι το μοντέλο GCN2Conv_200 έχει ακρίβεια σχεδόν 100% για τις νόμιμες συναλλαγές, δηλαδή σχεδόν όλες οι συναλλαγές που κατατάσσει ως νόμιμες είναι όντως νόμιμες, ενώ από τις συναλλαγές που κατατάσσονται ως ύποπτες το ποσοστό που είναι όντως ύποπτες είναι πλησιάζει το 0% δηλαδή οι τιμές που είναι λάθος κατηγοριοποιημένες ως ύποπτες αλλά είναι νόμιμες καλύπτουν όλο το πλήθος. Επίσης το μοντέλο δεν κατηγοριοποιεί καθόλου τις ύποπτες συναλλαγές καθώς μόλις το 24% από στο σύνολο τους δόθηκε σωστή τιμή.

- GCN2Conv_400

Το μοντέλο GCN2Conv_400 εκπαιδεύτηκε για 400 εποχές και με ρυθμό μάθησης 0,01. Ο συνολικός χρόνος εκπαίδευσης του μοντέλου ήταν 1ώρα 24 λεπτά και 18 δευτερόλεπτα. Το Γράφημα 13 αποτυπώνει το ρυθμό μείωσης της απώλειας του μοντέλου ανά εποχή εκπαίδευσης.



Γράφημα 13 Ρυθμός Μεταβολής Απώλειας ανά Εποχή GCN2Conv_400

Παρατηρούμε από το γράφημα ότι το μοντέλο μειώνει σταδιακά την συνολική απώλεια ανά εποχή αλλά χρειάζεται σχεδόν από 180 εποχές σταθεροποιεί το ρυθμό μεταβολής της απώλειας του.

Στην συνέχεια έγινε αξιολόγηση του μοντέλου σε νέο σύνολο δεδομένων, το οποίο δεν χρησιμοποιήθηκε στην εκπαίδευση. Το σύνολο δεδομένων αυτό είχε συνολικά 6.653.397 συναλλαγές από τις οποίες η 6989 ήταν χαρακτηρισμένες ως ύποπτες. Το GCN2Conv_400 χρειάστηκε 5 δευτερόλεπτα και 861 χιλιοστά του δευτερολέπτου για να αποφασίσει για όλες τις συναλλαγές αν είναι ύποπτες ή όχι. Παρακάτω ακολουθεί ο πίνακας σύγχυσης των αποτελεσμάτων.

		Predicted	
		Νόμιμη	Ύποπτη
Actual	Νόμιμη	5948330	698078
	Ύποπτη	3124	3865

Πίνακας 32 Πίνακας Σύγχυσης GCN2Conv_400

Παρατηρούμε ότι το μοντέλο GCN2Conv_400 κατάφερε να αξιολογήσει σωστά το 89,46% των συναλλαγών. Επίσης σημειώνει ένα ROC AUC Score 72,40%, η τιμή υποδεικνύει ότι το μοντέλο έχει κατανοήσει ένα μέρος του προβλήματος αλλά όχι πλήρως. Παρακάτω

ακολουθεί πίνακας για τις τιμές Precision Recall και F1 Score για το μοντέλο GCN2Conv_400.


	Precision	Recall	F1
Νόμιμες	1	0,89	0,94
Υπόπτες	0,01	0,55	0,01

Πίνακας 33 Precision, Recall, F1 Score για το GCN2Conv_400

Από το Πίνακας 33 παρατηρούμε ότι το μοντέλο GCN2Conv_400 κατηγοριοποιεί σωστά το 89% των συναλλαγών που είναι νόμιμες, ενώ για τις ύποπτες συναλλαγές το ποσοστό αυτό πέφτει στο 55%, οπότε ο αλγόριθμος κατηγοριοποιεί λάθος το 45% των ύποπτων συναλλαγών, βέβαια αυτό το ποσοστό δεν επηρεάζει την ακρίβεια του μοντέλου ως προς τις νόμιμες συναλλαγές, καθώς είναι πολύ μικρό το πλήθος σε σχέση με το σύνολο των νόμιμων συναλλαγών.

- GCN4Conv_100

Το μοντέλο GCN4Conv_100 εκπαιδεύτηκε για 100 εποχές και με ρυθμό μάθησης 0,01. Ο συνολικός χρόνος εκπαίδευσης του μοντέλου ήταν 36 λεπτά και 24 δευτερόλεπτα. Το Γράφημα 14 αποτυπώνει το ρυθμό μείωσης της απώλειας του μοντέλου ανά εποχή εκπαίδευσης.



Γράφημα 14 Ρυθμός Μεταβολής Απώλειας ανά Εποχή GCN4Conv_100

Παρατηρούμε από το γράφημα ότι το μοντέλο μειώνει σταδιακά την συνολική απώλεια ανά εποχή αλλά μέσα στις 100 εποχές δεν κατάφερε να σταθεροποιήσει το ρυθμό μεταβολής της απώλειας του.

Στην συνέχεια έγινε αξιολόγηση του μοντέλου σε νέο σύνολο δεδομένων, το οποίο δεν χρησιμοποιήθηκε στην εκπαίδευση. Το σύνολο δεδομένων αυτό είχε συνολικά 6.653.397 συναλλαγές από τις οποίες η 6989 ήταν χαρακτηρισμένες ως ύποπτες. Το GCN4Conv_100 χρειάστηκε 7 δευτερόλεπτα και 473 χιλιοστά του δευτερολέπτου για να αποφασίσει για όλες τις συναλλαγές αν είναι ύποπτες ή όχι. Παρακάτω ακολουθεί ο πίνακας σύγχυσης των αποτελεσμάτων.

		Predicted	
		Νόμιμη	Ύποπτη
Actual	Νόμιμη	914658	5731750
	Ύποπτη	522	6467

Πίνακας 34 Πίνακας Σύγχυσης GCN4Conv_100

Παρατηρούμε ότι το μοντέλο GCN4Conv_100 κατάφερε να αξιολογήσει σωστά μόλις το 13,84% των συναλλαγών. Επίσης σημειώνει ένα ROC AUC Score 53,15%, η τιμή υποδεικνύει ότι το μοντέλο δεν έχει κατανοήσει το πρόβλημα, και απαντά σχεδόν με

τυχαία. Παρακάτω ακολουθεί πίνακας για τις τιμές Precision Recall και F1 Score για το μοντέλο GCN4Conv_100.


	Precision	Recall	F1
Νόμιμες	1	0,14	0,34
Ύποπτες	0,01	0,93	0

Πίνακας 35 Precision, Recall, F1 Score για το GCN4Conv_100

Από το Πίνακα 35 παρατηρούμε ότι το μοντέλο GCN4Conv_100 κατηγοριοποιεί σωστά το 14% των συναλλαγών που είναι νόμιμες, ενώ για τις ύποπτες συναλλαγές το ποσοστό αυτό αυξάνεται στο 93%, το μοντέλο δεν κατάφερε να αξιολογήσει καθόλου τις νόμιμες συναλλαγές.

- GCN4Conv_200

Το μοντέλο GCN4Conv_200 εκπαιδεύτηκε για 200 εποχές και με ρυθμό μάθησης 0,01. Ο συνολικός χρόνος εκπαίδευσης του μοντέλου ήταν 1 ώρα 9 λεπτά και 39 δευτερόλεπτα. Το Γράφημα 15 αποτυπώνει το ρυθμό μείωσης της απώλειας του μοντέλου ανά εποχή εκπαίδευσης.



Γράφημα 15 Ρυθμός Μεταβολής Απώλειας ανά Εποχή GCN4Conv_200

Παρατηρούμε από το γράφημα ότι το μοντέλο μειώνει σταδιακά την συνολική απώλεια ανά εποχή αλλά χρειάζεται στις 125 εποχές για να αρχίσει να σταθεροποιεί το ρυθμό μεταβολής της απώλειας.

Στην συνέχεια έγινε αξιολόγηση του μοντέλου σε νέο σύνολο δεδομένων, το οποίο δεν χρησιμοποιήθηκε στην εκπαίδευση. Το σύνολο δεδομένων αυτό είχε συνολικά 6.653.397 συναλλαγές από τις οποίες η 6989 ήταν χαρακτηρισμένες ως ύποπτες. Το GCN4Conv_200 χρειάστηκε 8 δευτερόλεπτα και 380 χιλιοστά του δευτερολέπτου για να αποφασίσει για όλες τις συναλλαγές αν είναι ύποπτες ή όχι. Παρακάτω ακολουθεί ο πίνακας σύγκρισης των αποτελεσμάτων.

		Predicted	
		Νόμιμη	Ύποπτη
Actual	Νόμιμη	690444	5955964
	Ύποπτη	337	6652

Πίνακας 36 Πίνακας Σύγκρισης GCN4Conv_200

Παρατηρούμε ότι το μοντέλο GCN4Conv_200 κατάφερε να αξιολογήσει σωστά μόλις το 10,48% των συναλλαγών. Επίσης σημειώνει ένα ROC AUC Score 52,78%, η τιμή υποδεικνύει ότι το μοντέλο δεν έχει κατανοήσει το πρόβλημα, και απαντά σχεδόν τυχαία. Παρακάτω ακολουθεί πίνακας για τις τιμές Precision Recall και F1 Score για το μοντέλο GCN4Conv_200.


	Precision	Recall	F1
Νόμιμες	1	0,1	0,19
Ύποπτες	0	0,95	0

Πίνακας 37 Precision, Recal, F1 Score1 για το GCN4Conv_200

Από το Πίνακας 37 παρατηρούμε ότι το μοντέλο GCN4Conv_200 κατηγοριοποιεί σωστά το 10% των συναλλαγών που είναι νόμιμες, ενώ για τις ύποπτες συναλλαγές το ποσοστό αυτό αυξάνεται στο 95%, το μοντέλο δεν κατάφερε να αξιολογήσει καθόλου τις νόμιμες συναλλαγές.

- GCN4Conv_400

Το μοντέλο GCN4Conv_200 εκπαιδεύτηκε για 200 εποχές και με ρυθμό μάθησης 0,01. Ο συνολικός χρόνος εκπαίδευσης του μοντέλου ήταν 1 ώρα 9 λεπτά και 39 δευτερόλεπτα. Το Γράφημα 15 αποτυπώνει το ρυθμό μείωσης της απώλειας του μοντέλου ανά εποχή εκπαίδευσης.



Γράφημα 16 Ρυθμός Μεταβολής Απώλειας ανά Εποχή GCN4Conv_400

Παρατηρούμε από το γράφημα ότι το μοντέλο μειώνει σταδιακά την συνολική απώλεια ανά εποχή αλλά χρειάζεται στις 220 εποχές για να αρχίσει να σταθεροποιεί το ρυθμό μεταβολής της απώλειας.

Στην συνέχεια έγινε αξιολόγηση του μοντέλου σε νέο σύνολο δεδομένων, το οποίο δεν χρησιμοποιήθηκε στην εκπαίδευση. Το σύνολο δεδομένων αυτό είχε συνολικά 6.653.397 συναλλαγές από τις οποίες η 6989 ήταν χαρακτηρισμένες ως ύποπτες. Το GCN4Conv_400 χρειάστηκε 7 δευτερόλεπτα και 849 χιλιοστά του δευτερολέπτου για να αποφασίσει για όλες τις συναλλαγές αν είναι ύποπτες ή όχι. Παρακάτω ακολουθεί ο πίνακας σύγχυσης των αποτελεσμάτων.

		Predicted	
		Νόμιμη	Ύποπτη
Actual	Νόμιμη	1980462	4665946
	Ύποπτη	738	6251

Πίνακας 38 Πίνακας Σύγχυσης GCN4Conv_400

Παρατηρούμε ότι το μοντέλο GCN4Conv_400 κατάφερε να αξιολογήσει σωστά μόλις το 29,86% των συναλλαγών. Επίσης σημειώνει ένα ROC AUC Score 59,62%, η τιμή υποδεικνύει ότι το μοντέλο δεν έχει κατανοήσει το πρόβλημα, και απαντά σχεδόν τυχαία.

Παρακάτω ακολουθεί πίνακας για τις τιμές Precision Recall και F1 Score για το μοντέλο GCN4Conv_400.


	Precision	Recall	F1
Νόμιμες	1	0,3	0,46
Ύποπτες	0	0,89	0

Πίνακας 39 Precision, Recal, F1 Score για το GCN4Conv_400

Από το Πίνακα 37 παρατηρούμε ότι το μοντέλο GCN4Conv_400 κατηγοριοποιεί σωστά το 30% των συναλλαγών που είναι νόμιμες, ενώ για τις ύποπτες συναλλαγές το ποσοστό αυτό αυξάνεται στο 89%, το μοντέλο δεν κατάφερε να αξιολογήσει το συντριπτικό μέρος των νόμιμων συναλλαγών.

- G2Gat_20

Το μοντέλο G2Gat_20 εκπαιδεύτηκε για 20 εποχές και με ρυθμό μάθησης 0,01. Ο συνολικός χρόνος εκπαίδευσης του μοντέλου ήταν 1 ώρα 2 λεπτά και 31 δευτερόλεπτα. Το Γράφημα 17 αποτυπώνει το ρυθμό μείωσης της απώλειας του μοντέλου ανά εποχή εκπαίδευσης.



Γράφημα 17 Ρυθμός Μεταβολής Απώλειας ανά Εποχή G2Gat_20

Παρατηρούμε από το γράφημα δεν σταθεροποιεί ποτέ το ρυθμό μεταβολής της απώλειας.

Στην συνέχεια έγινε αξιολόγηση του μοντέλου σε νέο σύνολο δεδομένων, το οποίο δεν χρησιμοποιήθηκε στην εκπαίδευση. Το σύνολο δεδομένων αυτό είχε συνολικά 6.653.397 συναλλαγές από τις οποίες η 6989 ήταν χαρακτηρισμένες ως ύποπτες. Το G2Gat_20 χρειάστηκε 1 λεπτό 4 δευτερόλεπτα και 582 χιλιοστά του δευτερολέπτου για να αποφασίσει για όλες τις συναλλαγές αν είναι ύποπτες ή όχι. Παρακάτω ακολουθεί ο πίνακας σύγχυσης των αποτελεσμάτων.


		Predicted	
		Νόμιμη	Ύποπτη
Actual	Νόμιμη	243518	6402890
	Ύποπτη	217	6772

Πίνακας 40 Πίνακας Σύγχυσης G2Gat_20

Παρατηρούμε ότι το μοντέλο G2Gat_20 κατάφερε να αξιολογήσει σωστά μόλις το 3,7s6% των συναλλαγών. Επίσης σημειώνει ένα ROC AUC Score 50,28%, η τιμή υποδεικνύει ότι το μοντέλο δεν έχει κατανοήσει το πρόβλημα, και απαντά πάντα τυχαία. Λόγο τον χαμηλών μετρικών δεν θα γίνει περεταίρω ανάλυση του συγκεκριμένου μοντέλου.

- G2Gat_100

Το μοντέλο GCN4Conv_200 εκπαιδεύτηκε για 200 εποχές και με ρυθμό μάθησης 0,01. Ο συνολικός χρόνος εκπαίδευσης του μοντέλου ήταν 4 ώρες 53 λεπτά και 34 δευτερόλεπτα. Το Γράφημα 18 αποτυπώνει το ρυθμό μείωσης της απώλειας του μοντέλου ανά εποχή εκπαίδευσης.



Γράφημα 18 Ρυθμός Μεταβολής Απώλειας ανά Εποχή G2Gat_100

Παρατηρούμε από το γράφημα ότι το μοντέλο μειώνει σταδιακά την συνολική απώλεια ανά εποχή αλλά χρειάζεται στις 60 εποχές για να αρχίσει να σταθεροποιεί το ρυθμό μεταβολής της απώλειας.

Στην συνέχεια έγινε αξιολόγηση του μοντέλου σε νέο σύνολο δεδομένων, το οποίο δεν χρησιμοποιήθηκε στην εκπαίδευση. Το σύνολο δεδομένων αυτό είχε συνολικά 6.653.397 συναλλαγές από τις οποίες η 6989 ήταν χαρακτηρισμένες ως ύποπτες. Το G2Gat_100 χρειάστηκε 1 λεπτό 11 δευτερόλεπτα και 581 χιλιοστά του δευτερολέπτου για να αποφασίσει για όλες τις συναλλαγές αν είναι ύποπτες ή όχι. Παρακάτω ακολουθεί ο πίνακας σύγχυσης των αποτελεσμάτων.

		Predicted	
		Νόμιμη	Ύποπτη
Actual	Νόμιμη	5309661	1336747
	Ύποπτη	658	6331

Πίνακας 41 Πίνακας Σύγχυσης G2Gat_100

Παρατηρούμε ότι το μοντέλο G2Gat_100 κατάφερε να αξιολογήσει σωστά μόλις το 79,90% των συναλλαγών. Επίσης σημειώνει ένα ROC AUC Score 85,42%, η τιμή

υποδεικνύει ότι το μοντέλο κατανοεί σε μεγάλο βαθμό τις διαφορές μεταξύ των κλάσεων αλλά όχι απόλυτα. Παρακάτω ακολουθεί πίνακας για τις τιμές Precision Recall και F1 Score για το μοντέλο G2Gat_100.

	Precision	Recall	F1
Νόμιμες	1	0,8	0,89
Ύποπτες	0	0,91	0,01

Πίνακας 42 Precision, Recal, F1 Score για το GCN4Conv_400

Από το Πίνακας 42 παρατηρούμε ότι το μοντέλο GCN4Conv_400 κατηγοριοποιεί σωστά το 80% των συναλλαγών που είναι νόμιμες, ενώ για τις ύποπτες συναλλαγές το ποσοστό αυτό αυξάνεται στο 91%. Οπότε το μοντέλο κατηγοριοποιεί το μεγαλύτερο πλήθος και των δύο κλάσεων σωστά σε σχέση με το σύνολο τους.

7.4. Σύγκριση Εποχών Εκπαίδευσης ανά Αρχιτεκτονική

- G2Sage
- G4Sage
- G2GraphSAGE
- GCN2Conv
- GCN4Conv

7.5. Σύγκριση Χρόνων Εκπαίδευσης

Πολύ σημαντική ένδειξη για τα μοντέλα τεχνητής νοημοσύνης είναι ο χρόνος εκπαίδευσης. Παρακάτω ακολουθεί σύγκριση για το χρόνο εκπαίδευσης που χρειάστηκε κάθε αρχιτεκτονική, για να μπορούν τα μοντέλα να αξιολογηθούν κατάλληλα, η σύγκριση γίνεται μόνο σε μοντέλα που είχαν τις ίδιες εποχές εκπαίδευσης.

- 100 Εποχές Εκπαίδευσης

	G2Sage	G4Sage	G2GraphSA	GCN2Con	GCN4Con	G2Gat_10
	e	e	GE	v	v	0
Συνολικός Χρόνος Εκπαίδευσης	17' 46''	25' 56''	20' 24''	21' 57''	36' 24''	4h 53' 34''
Μέσος Χρόνος Εκπαίδευσης Εποχής	10''	15''	12''	13''	21''	3' 7''

Πίνακας 43 Χρόνος Εκπαίδευσης Μοντέλων, για εκπαίδευση 100 Εποχών

Όπως παρατηρούμε από το Πίνακας 43 το μοντέλο με την που εκπαιδεύτηκε πιο γρήγορα ήταν εκείνο με την αρχιτεκτονική G2Sage, ενώ το αμέσως επόμενο είναι εκείνο με την παρόμοιο αρχιτεκτονική G2GraphSage, η διαφορά των δύο μοντέλων, ενώ υπάρχει παρόμοια αρχιτεκτονική βρίσκεται στις εσωτερικές υλοποιήσεις που γίνονται από την βιβλιοθήκη PyTorch, σχετικά κοντά σε χρόνο εκπαίδευσης ήταν και το μοντέλο GCN2Conv. Στην συνέχεια ακολουθούν τα μοντέλα με 4 στρώματα όπως το G4Sage και έπειτα το GCN4Conv, τελευταίο χρονικά βρίσκεται το μοντέλο G2Gat και μάλιστα με

τεράστια χρονική διαφορά, αυτό συμβαίνει λόγω τις αρχιτεκτονικής των GAT μοντέλων που χρησιμοποιούν μηχανισμούς προσοχής και Multi-Head Attention υλοποιήσεις. Το πρώτο συμπέρασμα που μπορούμε να εξαγάγουμε είναι ότι ο αριθμός στρωμάτων σε κάθε δίκτυο επηρεάζει πολύ το χρόνο εκπαίδευσης του, καθώς κάθε στρώμα απαιτεί και υπολογιστικό κόστος. Δεύτερο συμπέρασμα από την συγκεκριμένη σύγκριση είναι ότι η μέθοδος SAGE είναι ταχύτερη παρόμοιας αρχιτεκτονικής αλλά με στρώματα GCN, αυτό φυσικά επηρεάζεται έντονα από το μέγεθος του γράφου.

- 200 Εποχές Εκπαίδευσης

	G2Sage	G4Sage	G2GraphSAGE	GCN2Conv	GCN4Conv
<i>Συνολικός Χρόνος Εκπαίδευσης</i>	32' 27"	52' 18"	40' 31"	44' 57"	1h 9' 39"
<i>Μέσος Χρόνος Εκπαίδευσης Εποχής</i>	9"	15"	11"	13"	21"

Πίνακας 44 Χρόνος Εκπαίδευσης Μοντέλων, για εκπαίδευση 200 Εποχών

Από το Πίνακας 44 παρατηρούμε πως η αρχιτεκτονική G2Sage και για τις 200 εποχές εκπαίδευσης είναι ταχύτερη, ενώ η αμέσως επόμενη αρχιτεκτονική είναι η G2GraphSAGE, στην συνέχεια ακολουθούν η GCN2Conv, η G4Sage και στο τέλος η GCN4Conv. Για το της 200 εποχές η αρχιτεκτονική G2Gat δεν εκπαιδεύτηκε λόγω του μεγάλου χρόνου εκπαίδευσης. Παρατηρούμε ότι η σειρά στους χρόνους εκπαίδευσης έμεινε η ίδια, αλλά τα μοντέλα G2GraphSAGE και G2Sage μείωσαν το μέσο χρόνο εκπαίδευσης εποχής.

- 400 Εποχές Εκπαίδευσης

	G2Sage	G4Sage	G2GraphSAGE	GCN2Conv	GCN4Conv
<i>Συνολικός Χρόνος Εκπαίδευσης</i>	1h 3' 37"	1h 44' 20"	1h 13' 50"	1h 24' 18"	2h 16' 56"
<i>Μέσος Χρόνος Εκπαίδευσης Εποχής</i>	9"	15"	12"	13"	20"

Πίνακας 45 Χρόνος Εκπαίδευσης Μοντέλων, για εκπαίδευση 200 Εποχών

Από το Πίνακας 45 παρατηρούμε πως η αρχιτεκτονική G2Sage και για τις 200 εποχές εκπαίδευσης είναι ταχύτερη, ενώ η αμέσως επόμενη αρχιτεκτονική είναι η G2GraphSAGE, στην συνέχεια ακολουθούν η GCN2Conv, η G4Sage και στο τέλος η GCN4Conv. Για το της 400 εποχές η αρχιτεκτονική G2Gat δεν εκπαιδεύτηκε λόγω του μεγάλου χρόνου εκπαίδευσης. Παρατηρούμε ότι η σειρά στους χρόνους εκπαίδευσης έμεινε η ίδια, αλλά τα μοντέλα G2GraphSAGE αύξησε το μέσο χρόνο εκπαίδευσης εποχής, αντιθέτως το μοντέλο GCN4Conv μείωσε το χρόνο εκπαίδευσης του ανά εποχή.

7.6. Σύγκριση Χρόνων Συλλογισμού

- Συνολικός Χρόνος Συλλογισμού

Μοντέλο	Χρόνος Συλλογισμού
G2Sage_400	3s 910ms
G2Sage_200	4s 13ms
G2Sage_100	5s 298ms
GCN2Conv_400	5s 861ms
G2GraphSage_400	5s 876ms
GCN2Conv_100	6s 201ms
G4Sage_400	6s 227ms
G4Sage_100	6s 383ms
GCN2Conv_200	6s 469ms
G2GraphSage_200	6s 873ms
G4Sage_200	6s 934ms
GCN4Conv_100	7s 473ms
GCN4Conv_400	7s 849ms
GCN4Conv_200	8s 380ms
G2GraphSage_100	8s 947ms
G2Gat_20	1m 4s 582ms
G2Gat_100	1m 11s 581ms

Πίνακας 46 Χρόνοι Συλλογισμού

O Error! Reference source not found. περιγράφει το χρόνο συλλογισμού κάθε μοντέλου στο ίδιο σύνολο δεδομένων, και είναι ταξινομημένος από το ελάχιστο χρόνο στο μέγιστο. Το ταχύτερο μοντέλο στο συλλογισμό είναι αυτό της αρχιτεκτονικής G2Sage που εκπαιδεύτηκε για 400 εποχές. Παρατηρούμε επίσης ότι τα μοντέλα GAT είναι με διαφορά το πιο αργό και στο επίπεδο συλλογισμού εκτός από της εκπαίδευσης που αναλύθηκε στο κεφάλαιο 8.5.1.. Επίσης, παρατηρούμε ότι η κατηγορία G2Sage καταλαμβάνει συνολικά τους γρηγορότερους χρόνους συλλογισμού σε όλες της μορφές εκπαίδευσης που έλαβε.

- Χρόνος Συλλογισμού για κάθε αρχιτεκτονική ανά εποχές εκπαίδευσης. Πως η εκπαίδευση επηρεάζει το συλλογισμό.

G2Sage

	100 Εποχές	200 Εποχές	400 Εποχές
Χρόνος Συλλογισμού	5s 298ms	4s 13ms	3s 910ms

Πίνακας 47 Χρόνος Συλλογισμού G2Sage

Παρατηρούμε από το Πίνακας 47 ότι όσο αυξάνονται οι εποχές εκπαίδευσης τόσο η αρχιτεκτονική G2Sage μειώνει το χρόνο που χρειάζεται για να κατηγοριοποιήσει το σύνολο συναλλαγών.

G4Sage

	100 Εποχές	200 Εποχές	400 Εποχές
Χρόνος Συλλογισμού	6s 383ms	6s 934ms	6s 227ms

Πίνακας 48 Χρόνος Συλλογισμού G4Sage

Παρατηρούμε από το Πίνακας 48 ότι ασχέτως με την αύξηση των εποχών εκπαίδευσης του G4Sage, οι χρόνοι συλλογισμού είναι αρκετά κοντά με την μέγιστη διαφορά να είναι μεταξύ των μοντέλων 200 εποχών και 400 εποχών εκπαίδευσης στα 707 χιλιοστών του δευτερολέπτου για το σύνολο των δεδομένων.

G2GraphSAGE

	100 Εποχές	200 Εποχές	400 Εποχές
Χρόνος Συλλογισμού	8s 947ms	6s 873ms	5s 876ms

Πίνακας 49 Χρόνος Συλλογισμού G2GraphSAGE

Παρατηρούμε από το Πίνακας 49 ότι ο αριθμός εποχών επηρεάζει το χρόνο συλλογισμού του μοντέλου. Όσο αυξάνεται ο αριθμός εποχών τόσο ο χρόνος συλλογισμού μειώνεται.

GCN2Conv

	100 Εποχές	200 Εποχές	400 Εποχές
Χρόνος Συλλογισμού	6s 201ms	6s 469ms	5s 861ms

Πίνακας 50 Χρόνος Συλλογισμού GCN2Conv

Παρατηρούμε από το Πίνακας 50 ότι ο αριθμός εποχών δεν επηρεάζει το χρόνο συλλογισμού του μοντέλου. Το μοντέλο έχει σχετικά σταθερό χρόνο συλλογισμού με την μέγιστη διαφορά να μην ξεπερνάει τα 608 χιλιοστά του δευτερολέπτου.

GCN4Conv

	100 Εποχές	200 Εποχές	400 Εποχές
Χρόνος Συλλογισμού	7s 473ms	8s 380ms	7s 849ms

Πίνακας 51 Χρόνος Συλλογισμού GCN4Conv

Παρατηρούμε από το Πίνακας 51 ότι ο αριθμός εποχών δεν επηρεάζει το χρόνο συλλογισμού του μοντέλου. Το μοντέλο έχει σχετικά σταθερό χρόνο συλλογισμού με την μέγιστη διαφορά να μην ξεπερνάει τα 907 χιλιοστά του δευτερολέπτου.

	20 Εποχές	100 Εποχές
Χρόνος Συλλογισμού	1m 4s 582ms	1m 11s 581ms

Πίνακας 52 Χρόνος Συλλογισμού GCN2Conv

Παρατηρούμε από το Πίνακα 52 ότι ο αριθμός εποχών επηρεάζει το χρόνο συλλογισμού του μοντέλου. Με την αύξηση των εποχών εκπαίδευσης το μοντέλο αυξάνει και το χρόνο συλλογισμού του.

Πως αυξάνει το μέγεθος της εκπαίδευσης το Χρόνο Συλλογισμού?

Μετά την ανάλυση το αποτελεσμάτων για κάθε αρχιτεκτονική, συμπεραίνουμε ότι δεν μπορεί να αποδειχθεί κάποια σταθερή σχέση μεταξύ του μεγέθους εκπαίδευσης και του χρόνου συλλογισμού. Όμως αναλόγως την αρχιτεκτονική κατηγορία του μοντέλου, παρατηρούμε ότι υπάρχουν φανερές αναλογίες, τα μοντέλα GraphSAGE μειώνουν τα χρόνο συλλογισμού τους όσο περισσότερο εκπαιδεύονται, αντιθέτως τα μοντέλα με συνέλιξη έχουν σταθερό χρόνο συλλογισμού ασχέτως από το μέγεθος εκπαίδευσης που έλαβαν.

7.7. Σύγκριση Ίδιων Κατηγοριών με διαφορετική αρχιτεκτονική

Προκειμένου να εξάγουμε συμπεράσματα για την σημασία των αρχιτεκτονικών στα προβλήματα με δεδομένα γράφων θα γίνει σύγκριση των μοντέλων με βάση την κατηγορία της αρχιτεκτονικής. Εδώ πρέπει να σημειωθεί ότι λόγω της φύσης του προβλήματος, μας ενδιαφέρει περισσότερο το recall των μοντέλων, δηλαδή η ικανότητα των μοντέλων να ανιχνεύουν όλο το πλήθος μίας κλάσης. Επίσης λόγω της μεγάλης ανισορροπίας των δεδομένων, θεωρούμε ως κατάλληλη μετρική σύγκρισης την τιμή ROC AUC.

- GraphSAGE

Παραπάνω παρουσιάστηκαν διαφορετικά μοντέλα και τεχνικές υλοποίησης της μεθόδου GraphSAGE. Στην συνέχεια θα γίνει σύγκριση το συγκεκριμένων μοντέλων, ως προς την επίδοσή τους σε ένα συγκεκριμένο σύνολο δεδομένων.

G2Sage_100		G2Sage_200		G2Sage_400	
126746	6519662	405060	2595807	6310374	336034
56	6933	83	6906	544	6445
G4Sage_100		G4Sage_200		G4Sage_400	
6389401	257007	6481198	165210	6626819	19589
1779	5210	729	6260	2165	4824
G2GraphSage_100		G2GraphSage_200		G2GraphSage_400	
6215979	430429	6282846	363562	6111935	534473
2514	4475	434	6555	187	6802

Πίνακας 53 Confusion Matrix των μοντέλων GraphSAGE

G2Sage_100	G2Sage_200	G2Sage_400	G4Sage_100	G4Sage_200	G4Sage_400	G2GraphSage_100	G2GraphSage_200	G2GraphSage_400
50,55%	79,88%	93,58%	85,34%	93,54%	84,36%	78,78%	94,16%	94,64%

Πίνακας 54 ROC AUC των μοντέλων GraphSAGE

Ο παραπάνω πίνακας (βλ. Πίνακας 53) παρουσιάζει τους πίνακες σύγχυσης των μοντέλων και ο Πίνακας 54 την τιμή ROC AUC των μοντέλων. Αρχικά με βάση την τιμή ROC AUC των μοντέλων, παρατηρούμε ότι το G2Sage_100 απαντά τυχαία στο πρόβλημα και δεν είχε κατανοήσει την δομή και τις διαφορές των δεδομένων, από το confusion matrix του συγκεκριμένου μοντέλου παρατηρούμε ότι το μοντέλο είχε την τάση να κατατάσσει τις περισσότερες συναλλαγές ως ύποπτες. Αντιθέτως την καλύτερη τιμή ROC AUC την είχε το μοντέλο G2GraphSAGE_400 από το πίνακα σύγχυσης του συγκεκριμένου μοντέλου παρατηρούμε το μοντέλο κατατάσσει σωστά το μεγαλύτερο πλήθος των κλάσεων, αλλά εμφανίζει αδυναμία στα δεδομένα που κατηγοριοποιεί ως ύποπτα, η μεγάλη διαφορά σε αυτή την τιμή συμβαίνει διότι το πλήθος της κλάσης «νόμιμη συναλλαγή» είναι πολύ μεγαλύτερο από το πλήθος της κλάσης «ύποπτη συναλλαγή». Επίσης πολύ κοντά σε αποτελέσματα είναι τα μοντέλα G2Sage_400, G4Sage_200 και G2GraphSAGE_200.

- GCNConv

Παραπάνω παρουσιάστηκαν διαφορετικά μοντέλα της μεθόδου GCNConv. Στην συνέχεια θα γίνει σύγκριση το συγκεκριμένων μοντέλων, ως προς την επίδοσή τους σε ένα συγκεκριμένο σύνολο δεδομένων.

GCN2Conv_100		GCN2Conv_200		GCN2Conv_400	
3306592	3339816	6062371	584037	5948330	698078
1481	5508	5278	1711	3124	3865
GCN4Conv_100		GCN4Conv_200		GCN4Conv_400	
914658	5731750	690444	5955964	1980462	4665946
522	6467	337	6652	738	6251

Πίνακας 55 Confusion Matrix των μοντέλων GCNConv

GCN2Conv_100	GCN2Conv_200	GCN2Conv_400	GCN4Conv_100	GCN4Conv_200	GCN4Conv_400
64,28%	57,85%	72,40%	53,15%	52,78%	59,62%

Πίνακας 56 ROC AUC των μοντέλων GCNConv

Οι Πίνακας 55 και Πίνακας 56 περιγράφουν τους πίνακες σύγχυσης και τις τιμές ROC AUC των μοντέλων GCNConv. Παρατηρούμε ότι το μοντέλο GCN4Conv_200 σημειώνει τιμή ROC AUC 52,78% δηλαδή απαντάει σχεδόν τυχαία και δεν μπορεί να κατανοήσει το πρόβλημα, χαρακτηριστικό παράδειγμα είναι ότι από το πίνακα σύγχυσης βλέπουμε ότι τα δεδομένα της κλάσης «νόμιμης συναλλαγής» χωρίστηκαν στην μέση. Τη μεγαλύτερη τιμή ROC AUC σημειώνει το μοντέλο GCN2Conv_400 με 72,40%, παρατηρούμε όμως ότι η τιμή παραμένει μικρή και το μοντέλο δεν μπόρεσε να απαντήσει σωστά, η τιμή αυτή επιβεβαιώνεται από το confusion matrix που δείχνει τα δεδομένα της κλάσης «ύποπτη συναλλαγή» να είναι χωρισμένα.

7.8. Σύγκριση Διαφορετικών Αρχιτεκτονικών

Μοντέλο	ROC AUC	Recall Υποπτων	Χρόνος Εκπαίδευσης	Χρόνος Συλλογισμού
G2Sage_100	50,55%	0,99	17m 46s	5s 298ms
G2Sage_200	79,88%	0,99	32m 27s	4s 13ms
G2Sage_400	93,58%	0,92	1h 3m 37s	3s 910ms
G4Sage_100	85,34%	0,75	25m 56s	6s 383ms
G4Sage_200	93,54%	0,9	52m 18s	6s 934ms
G4Sage_400	84,36%	0,69	1h 44m 20s	6s 227ms
G2GraphSAGE_100	78,78%	0,99	20m 24s	8s 947ms
G2GraphSAGE_200	94,16%	0,92	40m 31s	6s 873ms
G2GraphSAGE_400	94,64%	0,75	1h 13m 50s	5s 876ms
GCN2Conv_100	64,28%	0,79	21m 57s	6s 201ms
GCN2Conv_200	57,85%	0,24	44m 57s	6s 469ms
GCN2Conv_400	72,40%	0,55	1h 24m 18s	5s 861ms
GCN4Conv_100	53,15%	0,93	36m 24s	7s 473ms
GCN4Conv_200	52,78%	0,95	1h 9m 39s	8s 380ms
GCN4Conv_400	59,62%	0,89	2h 16m 56s	7s 849ms
G2Gat_20	50,28%	0,97	1h 2m 31s	1m 4s 582ms
G2Gat_100	85,24%	0,99	4h 53m 34s	1m 11s 581ms

Πίνακας 57 Συγκεντρωτικά αποτελέσματα.

- 100 Εποχές Εκπαίδευσης

G2Sage	G4Sage	G2GraphSage	GCN2Conv	GCN4Conv	G2Gat
50,55%	85,34%	78,78%	64,28%	53,15%	85,24%

Πίνακας 58 ROC AUC Score μοντέλων που εκπαιδεύτηκαν σε 100 εποχές

Στα μοντέλα που εκπαιδεύτηκαν για 100 εποχές παρατηρούμε ότι υπάρχουν χαμηλές τιμές ROC AUC. Πιο καλά αποτελέσματα εμφανίζουν τα μοντέλα G4Sage και το G2Gat. Αξίζει να σημειωθεί εδώ η χρονική διαφορά μεταξύ των δύο μοντέλων, καθώς το ένα

χρειάστηκε περίπου 25 λεπτά χρόνος εκπαίδευσης και 6 δευτερόλεπτα χρόνο συλλογισμού, ενώ το G2Gat χρειάστηκε σχεδόν 5 ώρες χρόνος εκπαίδευσης και 1 λεπτό και 11 δευτερόλεπτα χρόνο συλλογισμού.

- 200 Εποχές Εκπαίδευσης

G2Sage	G4Sage	G2GraphSage	GCN2Conv	GCN4Conv
79,88%	93,54%	94,16%	57,85%	52,78%

Πίνακας 59 ROC AUC Score μοντέλων που εκπαιδεύτηκαν σε 200 εποχές

Στα μοντέλα που εκπαιδεύτηκαν για 200 εποχές παρατηρούμε ότι οι τιμές ROC AUC βελτιώνονται σημαντικά . Πιο καλά αποτελέσματα εμφανίζουν τα μοντέλα G4Sage και το G2GraphSAGE. Τα δύο μοντέλα είναι πολύ κοντά σε αποτελέσματα και εμφανίζουν και πολύ υψηλό recall, το G4Sage 90% για την κλάση «ύποπτη συναλλαγή», ενώ το G2GraphSAGE 94%. Καθώς η φύση του προβλήματος είναι τέτοια που το υψηλό recall είναι απαραίτητη προϋπόθεση, θεωρούμε τα αποτελέσματα πολύ θετικά.

- 400 Εποχές Εκπαίδευσης

G2Sage	G4Sage	G2GraphSage	GCN2Conv	GCN4Conv
93,58%	84,36%	94,64%	72,40%	59,62%

Πίνακας 60 ROC AUC Score μοντέλων που εκπαιδεύτηκαν σε 400 εποχές

Στα μοντέλα που εκπαιδεύτηκαν για 400 εποχές παρατηρούμε επίσης βελτιωμένα αποτελέσματα. Πιο καλά αποτελέσματα εμφανίζουν τα μοντέλα G2Sage και το G2GraphSAGE. Τα δύο μοντέλα είναι πολύ κοντά σε αποτελέσματα και εμφανίζουν και πολύ υψηλό recall, το G2Sage 92% για την κλάση «ύποπτη συναλλαγή», ενώ το G2GraphSAGE 97%. Καθώς η φύση του προβλήματος είναι τέτοια που το υψηλό recall είναι απαραίτητη προϋπόθεση, θεωρούμε τα αποτελέσματα πολύ θετικά.

- Γενική Σύγκριση Μοντέλων με τα καλύτερα αποτελέσματα

Ως μοντέλα με τα καλύτερα αποτελέσματα θεωρούμε αυτά με τιμή ROC AUC μεγαλύτερη του 90%. Τα μοντέλα παρουσιάζονται στο παρακάτω πίνακα (βλ. Πίνακας 61) με το σύνολο των τιμών που συλλέχθηκαν γι' αυτά.

	Χρόνος Εκπαίδευσης	Accuracy	Confusion Matrix		ROC AUC	Χρόνος Συλλογισμού	Recall Νόμιμο	Recall Ύποπτο
G2Sage_400	1h 3m 37s	94,94%	6310374	336034	93,58%	3s 910ms	0,95	0,92
G4Sage_200	52m 18s	97,51%	544	6445	93,54%	6s 934ms	0,98	0,9
			6481198	165210				
G2GraphSage_200	40m 31s	94,53%	729	6260	94,16%	6s 873ms	0,95	0,94
			6282846	363562				
G2GraphSage_400	1h 13m 50s	91,96%	434	6555	94,64%	5s 876ms	0,92	0,97
			6111935	534473				
			187	6802				

Πίνακας 61 Συγκεντρωτικά αποτελέσματα μοντέλων

Παρατηρούμε από το παραπάνω πίνακα ότι και τα τέσσερα μοντέλα εμφανίζουν πολύ θετικά αποτελέσματα. Το μοντέλο με το υψηλότερο recall και ROC AUC είναι το G2GraphSAGE_400, επίσης πολύ κοντά σαν αποτελέσματα είναι το μοντέλο G2GraphSAGE_200, δηλαδή το ίδιο μοντέλο αρχιτεκτονικά αλλά με 200 εποχές εκπαίδευσης λιγότερες. Τα μοντέλα που ολοκληρώνουν την λίστα είναι και εκείνα της κατηγορίας GraphSAGE, το G4Sage και το G2Sage.

Παρατηρούμε ότι στην συγκεκριμένη λίστα δεν υπάρχει κανένα μοντέλο της κατηγορίας GCNConn και GAT, οπότε η μέθοδος υλοποίησης GraphSAGE, ήταν πιο κατάλληλη για την επίλυση ενός γράφου οικονομικών συναλλαγών. Αυτό οφείλεται στο μέγεθος ενός τέτοιου γράφου και στην μεγάλη διαφορά στο πλήθος των κλάσεων του συνόλου δεδομένων.

7.9. Σύγκριση με Classifier χωρίς χρήση embeddings

Στα πλαίσια της ανάλυσης συστημάτων εύρεσης ύποπτων συναλλαγών με χρήση μεθόδων τεχνητής νοημοσύνης, δημιουργήθηκε και μια αρχιτεκτονική νευρωνικού δικτύου που δεν χρησιμοποιεί embeddings αλλά μόνο ένα απλό classifier, ακολουθεί μια σύντομη περιγραφή των μοντέλων που προέκυψαν από τη συγκεκριμένη αρχιτεκτονική.

Η αρχιτεκτονική ονομάστηκε SimpleClassifier (SC) και εκπαιδεύτηκε αντίστοιχα με τα υπόλοιπα μοντέλα για 100, 200, 400 εποχές. Η συγκεκριμένη αρχιτεκτονική περιείχε δυο γραμμικά layers. Με βάση την τιμή ROC-AUC από τα 3 παραγόμενα μοντέλα τα καλύτερα αποτελέσματα είχε το SC_100. Με βάση αυτό το μοντέλο θα γίνει και σύγκριση με το μοντέλο G2GraphSAGE_400 που στην αντίστοιχη μετρική είχε τα καλύτερα αποτελέσματα όπως φάνηκε στις προηγούμενες αναλύσεις.

	Χρόνος Εκπαίδευσης	Accuracy	Confusion Matrix		ROC AUC	Χρόνος Συλλογισμού	Recall Νόμιμο	Recall Ύποπτο
SC_100	3m 37s	97,54%	6489442	156966	51,07%	2s	0,98	0,05
G2GraphSage_400	1h 13m 50s	91,96%	6674	315	94,64%	5s 876ms	0,92	0,97
			6111935	534473				
			187	6802				

Πίνακας 62 Σύγκριση αποτελεσμάτων μεταξύ SC_100 και G2GraphSAGE_400

Παρατηρούμε από το Πίνακας 62 ότι ο απλός classifier δεν καταφέρνει να αναλύσει το πρόβλημα και ενώ με την χρήση embeddings υπάρχουν πολύ καλύτερα αποτελέσματα, η ύποπτη κλάση, επίσης παρατηρούμε ότι ο απλός classifier απαντά σχεδόν με ίδια αποτελέσματα με ένα classifier που θα απαντούσε με τυχαιότητα.

8. Συμπεράσματα

Συμπερασματικά, η εφαρμογή τεχνικών τεχνητής νοημοσύνης στην ανάλυση γράφων για την ταξινόμηση παράνομων συναλλαγών αποτελεί ένα ιδιαίτερα υποσχόμενο πεδίο έρευνας, με σημαντικές προεκτάσεις στην καταπολέμηση της οικονομικής εγκληματικότητας. Οι μέθοδοι νευρωνικών δικτύων για γράφους (Graph Neural Networks - GNNs) και άλλων τεχνικών μηχανικής μάθησης επιτρέπουν την εκμετάλλευση της πληροφορίας των συναλλαγών όχι μόνο σε επίπεδο χαρακτηριστικών, αλλά αναδεικνύοντας μοτίβα και σχέσεις που δεν θα ήταν εύκολα ανιχνεύσιμα με κλασικές προσεγγίσεις. Επιπλέον, η χρήση στρατηγικών διαχείρισης ανισορροπίας δεδομένων, όπως η εφαρμογή κατάλληλων βαρών κλάσεων, συμβάλλει στην αύξηση της ακρίβειας των μοντέλων και στη μείωση των ψευδώς αρνητικών προβλέψεων, γεγονός κρίσιμο για την ανίχνευση παράνομων δραστηριοτήτων, καθώς στα προβλήματα ανίχνευσης απάτης, είναι κυριότερο χαρακτηριστικό η ακρίβεια των αποτελεσμάτων, δηλαδή η σωστή κατηγοριοποίηση όλων των παράνομων συναλλαγών. Παρά τις προκλήσεις, όπως η ανάγκη για διαφάνεια και επεξηγησιμότητα των μοντέλων, καθώς και η διαχείριση της πολυπλοκότητας των δεδομένων, η συνεχής έρευνα στον τομέα των αλγορίθμων γραφημάτων και της βαθιάς μάθησης μπορεί να οδηγήσει σε ακόμα πιο αποδοτικά και αξιόπιστα συστήματα ανίχνευσης. Η εξέλιξη των τεχνικών αυτών, σε συνδυασμό με τη βελτίωση της ποιότητας των δεδομένων και την ενσωμάτωση κανονιστικών πλαισίων, μπορεί να συμβάλει καθοριστικά στη δημιουργία ισχυρών εργαλείων για την πρόληψη και την καταπολέμηση του οικονομικού εγκλήματος σε παγκόσμιο επίπεδο.

Η εξέλιξη των νευρωνικών δικτύων για γράφους (GNNs) και των τεχνικών αυτοεπιβλεπόμενης και ενισχυτικής μάθησης αναμένεται να προσφέρει ακόμα μεγαλύτερη ακρίβεια και προσαρμοστικότητα στα μοντέλα ανίχνευσης. Παράλληλα, η ενσωμάτωση ερμηνεύσιμων τεχνολογιών τεχνητής νοημοσύνης (Explainable AI - XAI) θα επιτρέψει τη βελτίωση της διαφάνειας και της επεξηγησιμότητας των αποφάσεων των αλγορίθμων, διευκολύνοντας τη συνεργασία με ρυθμιστικές αρχές και χρηματοπιστωτικά ιδρύματα. Επιπλέον, η χρήση πιο αποδοτικών τεχνικών επεξεργασίας μεγάλων δεδομένων (Big Data) και η ενσωμάτωση σε πραγματικού χρόνου συστήματα ανίχνευσης θα μπορούσαν να οδηγήσουν στη δημιουργία αυτόματων και προληπτικών μηχανισμών ασφαλείας. Παρά τις προκλήσεις που εξακολουθούν να υπάρχουν, όπως η προστασία της ιδιωτικότητας των δεδομένων και η ανάγκη για προσαρμογή σε διαρκώς εξελισσόμενες μορφές οικονομικού εγκλήματος, η έρευνα σε αυτόν τον τομέα αναμένεται να συμβάλει καθοριστικά στην ανάπτυξη και υιοθέτηση προηγμένων συστημάτων ανίχνευσης, καθιστώντας τη χρηματοοικονομική βιομηχανία πιο ασφαλή και ανθεκτική απέναντι στις σύγχρονες απειλές.

Με βάση τα παραπάνω η συγκεκριμένη εργασία έχει πολλές διαφορετικές προοπτικές εξέλιξης. Θα μπορούσε να γίνει εξέλιξη των νευρωνικών δικτύων υπολογισμού embeddings με χρήση πιο πολύπλοκων δικτύων. Επίσης θα μπορούσε να γίνει χρήση ενός συνδυασμού διάφορων τεχνικών, όπως ένα δίκτυο που θα περιλαμβάνει αρχικά layers GCN και στην συνέχεια SAGE layers. Επίσης μια διαφορετική επιλογή εξέλιξης θα μπορούσε να είναι, η περεταίρω ανάλυση δικτύων GAT τα οποία φάνηκε να είχαν πολύ θετικά αποτέλεσμα αλλά υψηλό χρόνο εκπαίδευσης. Επιπλέον η χρήση ενός πιο

εξελιγμένου classifier ώστε να γίνει καλύτερη χρήση των embeddings για την εύρεση αποτελεσμάτων.

9. Bibliography

- [1] L. Euler.
- [2] L. Wu, P. Cui, J. Pei and L. Zhao, "Graph Neural Networks: Foundations, Frontiers, and Applications," *Springer Singapore*, p. 725, 2022.
- [3] M. W. Thomas Kipf, 2017.
- [4] P. Veličković, 2018.
- [5] M. W. Thomas N. Kipf, 2016.
- [6] L. J. Grover Aditya, "Node2Vec," *International Conference on Knowledge Discovery and Data Mining*, vol. 2016, p. 855–864, 2016.
- [7] W. Bender, 2010.
- [8] D. R., "Graph Theory".
- [9] K. H. Rossen, Διακριτά Μαθηματικά και Εφαρμογές τους.
- [10] C. E. L. R. L. R. C. S. THOMAS H. CORMEN, Εισαγωγή Στους Αλγορίθμους.
- [11] T. D. Jayawickrama, "towardsdatascience.com," [Online]. Available: <https://towardsdatascience.com/community-detection-algorithms-9bd8951e7dae>.
- [12] R. Norvig, "Τεχνητη Νοημοσύνη Μια σύγχρονη Προσέγγιση".
- [13] B. Phillip, "Power and Centrality: A Family of Measures," *American Journal of Sociology*, 1987.
- [14] J. R. M. A. R. Mohammed, "Machine Learning with Oversampling and Undersampling Techniques: Overview Study and Experimental Results," *11th International Conference on Information and Communication Systems (ICICS)*, 2020.
- [15] Y. B. E. A. G. a. S. L. Haibo He, "ADASYN: Adaptive synthetic sampling approach for imbalanced learning," 2008.
- [16] S. Y. T. T. M. S. H. K. Akira Tanimoto, "Expert Systems with Applications," vol. 201, 2022.
- [17] K. W. B. L. O. H. W. P. K. N. V. Chawla, "SMOTE: Synthetic Minority Over-sampling Technique," 2011.
- [18] L. Ferrer, "Analysis and Comparison of Classification Metrics," 2022.
- [19] D. C. F. A. M. B. H. D. a. G. A. B. Oztas, "Enhancing Anti-Money Laundering: Development of a Synthetic Transaction Monitoring Dataset," *IEEE International Conferenc*, p. 54, 2023.