



ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΙΑΣ

ΣΧΟΛΗ ΘΕΤΙΚΩΝ ΕΠΙΣΤΗΜΩΝ

ΔΙΑΤΜΗΜΑΤΙΚΟ ΠΡΟΓΡΑΜΜΑ ΜΕΤΑΠΤΥΧΙΑΚΩΝ ΣΠΟΥΔΩΝ

ΠΛΗΡΟΦΟΡΙΚΗ ΚΑΙ ΥΠΟΛΟΓΙΣΤΙΚΗ ΒΙΟΪΑΤΡΙΚΗ

Τεχνικές Μηχανικής Μάθησης σε Οπτικά Δίκτυα

Κουρκοβής Γρηγόριος

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Επιβλέπουσα Καθηγήτρια

Μπαζιάνα Περιστέρα

Λαμία, 2023

Υπεύθυνη Δήλωση μη λογοκλοπής και ανάληψης προσωπικής ευθύνης

Με πλήρη επίγνωση των συνεπειών του νόμου περί πνευματικών δικαιωμάτων, και γνωρίζοντας τις συνέπειες της λογοκλοπής, δηλώνω υπεύθυνα και ενυπογράφως ότι η παρούσα εργασία με τίτλο «Τεχνικές Μηχανικής Μάθησης σε Οπτικά Δίκτυα» αποτελεί προϊόν αυστηρά προσωπικής εργασίας και όλες οι πηγές από τις οποίες χρησιμοποίησα δεδομένα, ιδέες, φράσεις, προτάσεις ή λέξεις, είτε επακριβώς (όπως υπάρχουν στο πρωτότυπο ή μεταφρασμένες) είτε με παράφραση, έχουν δηλωθεί κατάλληλα και ευδιάκριτα στο κείμενο με την κατάλληλη παραπομπή και η σχετική αναφορά περιλαμβάνεται στο τμήμα των βιβλιογραφικών αναφορών με πλήρη περιγραφή. Αναλαμβάνω πλήρως, ατομικά και προσωπικά, όλες τις νομικές και διοικητικές συνέπειες που δύναται να προκύψουν στην περίπτωση κατά την οποία αποδειχθεί, διαχρονικά, ότι η εργασία αυτή ή τμήμα της δεν μου ανήκει διότι είναι προϊόν λογοκλοπής.

Ο ΔΗΛΩΝ

03/04/2023

Κουρκοβής Γρηγόριος

Πίνακας περιεχομένων

Λίστα Πινάκων.....	4
Λίστα Εικόνων	4
Λίστα Κώδικα.....	5
Λίστα Ακρωνύμιων	6
1. Περίληψη.....	8
2. Εισαγωγή	9
2.1 Περιγραφή Προβλήματος	9
2.2 Σχετική Βιβλιογραφία.....	10
2.3 Αναμενόμενα Αποτελέσματα.....	13
3. Οπτικά Δίκτυα	15
3.1 Κατηγορίες Οπτικών Δικτύων	15
3.2 Κύρια Στοιχεία Οπτικών Δικτύων	18
3.3 Πρωτόκολλα Προσπέλασης Μέσου	20
4. Αρχιτεκτονικές Ελέγχου.....	22
4.1 Βασικές Πληροφορίες Control Plane σε οπτικά δίκτυα.....	22
4.2 Software – Defined Οπτικά Δίκτυα	23
4.3 OpenFlow Πρωτόκολλο	27
5. Μηχανική Μάθηση.....	30
5.1 Βασικές Αρχές Μηχανικής Μάθησης.....	30
5.2 Τεχνικές Μηχανικής Μάθησης.....	31
5.3 Εργαλεία Μηχανικής Μάθησης	36
5.4 Deep Learning και Artificial Intelligence	39
6. Μηχανική Μάθηση σε Δίκτυα.....	41
6.1 Προβλήματα Δικτύων που Επιλύονται με Μηχανική Μάθηση	41
6.2 Χρησιμοποιούμενες Τεχνικές Μηχανικής Μάθησης σε Δίκτυα	43
6.3 Deep Learning και Artificial Intelligence σε Δίκτυα.....	51
6.4 Αποτελέσματα Χρήσης Μηχανικής Μάθησης σε Δίκτυα	54
7. Ανάπτυξη Αλγορίθμων και Αποτελέσματα	57
7.1 Αλγόριθμοι Μηχανικής Μάθησης.....	57
7.2 Χρησιμοποιηθέντα Δεδομένα	62
7.3 Περιγραφή Τρόπου Υλοποίησης	67
7.4 Αποτελέσματα Μετρήσεων (Μελέτης)	74
8. Συμπεράσματα	89

8.1	Σχολιασμός Αποτελεσμάτων.....	89
8.2	Επέκταση Αποτελεσμάτων σε Οπτικά Δίκτυα.....	92
8.2	Μελλοντική Έρευνα.....	94
9.	Βιβλιογραφία.....	96

Λίστα Πινάκων

Πίνακας 1 - Κατηγορίες Οπτικών Δικτύων	16
Πίνακας 2 - Αλγόριθμοι Μηχανικής Μάθησης	33
Πίνακας 3 - Αυτόματα Εργαλεία Μηχανικής Μάθησης.....	38
Πίνακας 4 - Εργαλεία Μηχανικής Μάθησης ανά Γλώσσα Προγραμματισμού.....	38
Πίνακας 5 - Αλγόριθμοι Μηχανικής Μάθησης για Πρόβλεψη Κίνησης Δικτύου	44
Πίνακας 6 - Αλγόριθμοι Μηχανικής Μάθησης για Δρομολόγηση Δικτύου.....	45
Πίνακας 7 - Αλγόριθμοι Μηχανικής Μάθησης για Προβλήματα RWA και RSA	46
Πίνακας 8 - Αλγόριθμοι Μηχανικής Μάθησης για Απόδοση Δικτύου	48
Πίνακας 9 - Αλγόριθμοι Μηχανικής Μάθησης για Ποιότητα Εκπομπής	49
Πίνακας 10 - Αλγόριθμοι Μηχανικής Μάθησης για Διαχείριση Σφαλμάτων.....	50
Πίνακας 11 - Πλεονεκτήματα / Μειονεκτήματα Αλγορίθμων Μηχανικής Μάθησης	61
Πίνακας 12 - Χαρακτηριστικά Ροών Δεδομένων	66
Πίνακας 13 - Ομαδοποίηση Χαρακτηριστικών Ροών Δεδομένων	66

Λίστα Εικόνων

Εικόνα 1 - Πρωτόκολλα Πολλαπλής Πρόσβασης.....	21
Εικόνα 2- Αρχιτεκτονική SDON Δικτύου.....	25
Εικόνα 4- Περιβάλλον Εξαγωγής Δεδομένων	64
Εικόνα 5 - Throughput Per Window	75
Εικόνα 6- Drop Rate Per Window.....	76
Εικόνα 7 - Delay Duration Per Window.....	77
Εικόνα 8 - Throughput and Drop Rate Pwe Window, kMeans Zero Cluster	78
Εικόνα 9 - Throughput and Drop Rate Per Window, kMeans One Cluster	78
Εικόνα 10 - Throughput and Drop Rate Per Window, kMeans Two Cluster.....	79
Εικόνα 11 - Delay Time Per Window, kMeans	79
Εικόνα 12 -Throughput and Drop Rate Per Window, miniBatch Zero Cluster	80
Εικόνα 13 - Throughput and Drop Rate Per Window, miniBatch One Cluster.....	81
Εικόνα 14 - Throughput and Drop Rate Per Window, miniBatch Two Cluster	81
Εικόνα 15 - Delay Time Per Window, miniBatch	82
Εικόνα 16 - Throughput and Drop Rate Per Window, Naive Bayes Zero Cluster	83
Εικόνα 17 - Throughput and Drop Rate Per Window, Naive Bayes One Cluster	83
Εικόνα 18- Delay Time Per Window, Naive Bayes.....	84
Εικόνα 19 - Throughput and Drop Rate Per Window, kNN Zero Cluster	84
Εικόνα 20 - Throughput and Drop Rate Per Window, kNN One Cluster.....	85

Εικόνα 21 - Delay Time Per Window, kNN	85
Εικόνα 22 - Throughput Per Window, Comparison Initial with Best ML Algorithms	86
Εικόνα 23 - Drop Rate Per Window, Comparison Initial With Best ML Algorithms	87
Εικόνα 24 - Delay Time Per Window, Comparison Initial With Best ML Algorithms	88

Λίστα Κώδικα

Κώδικας 1 - Αρχείο Main	68
Κώδικας 2 - Αρχείο labelingCSV	69
Κώδικας 3 - Αρχείο rowsDelete	70
Κώδικας 4 - Αρχείο machineLearningAlgorithms	70
Κώδικας 5 - Αρχείο loadAndThroughputCSVCreation	71
Κώδικας 6 - Αρχείο loadAndThroughputCalculation	72
Κώδικας 7 - Αρχείο lineGraphicPerSecondCreation	72
Κώδικας 8 - Αρχείο delayCalculation	73
Κώδικας 9 - Αρχείο delayStatisticsComputation	73

Λίστα Ακρωνύμων

ΔΔΧ	Διεπαφή Ελέγχου Χρήστη – Δικτύου
ΕΔΔΔ	Εξωτερική Διεπαφή Δικτύου – Δικτύου
ΑΕ	Auto Encoder
ΑΙ	Artificial Intelligence
ΑΛΟΗΑ	Additive Links On-line Hawaii Area
ΑΝΝ	Artificial Neural Network
ΑΡΙ	Application Plane Interface
ΑΡΦ	Adaptive Random Forest
ΒεΡ	Bit Error Rate
CNN	Convolutional Neural Network
DBSCAN	Density-Based Spatial Clustering of Applications with Noise
DNN	Deep Neural Network
EON	Elastic Optical Network
FON	Flexible Optical Network
FTTB	Fiber to the Building
FTTH	Fiber to the Home
IoT	Internet of Things
kNN	k Nearest Neighbor
LSTM	Long Short-Term Memory
OLAN	Optical Local Area Network
OPSF	Open Shortest Path First
OSNR	Optical Signal to Noise Ratio
PCA	Principal Component Analysis
PON	Passive Optical Network
QoS	Quality of Service
RCA	Receiver Collision Avoidance
RNN	Recurrent Neural Network
RSA	Routing and Spectrum Assignment
RWA	Routing and Wavelength Assignment
SDN	Software Defined Network
SDON	Software Defined Optical Network

SNR	Signal to Noise Ratio
SOM	Self-Organizing Map
SVM	Support Vector Machine
TDMA	Time Division Multiple Access
VFDT	Very Fast Decision Tree
WDM	Wavelength Division Multiplexing

1. Περίληψη

Τα τελευταία χρόνια η ανάπτυξη των οπτικών δικτύων είναι αλματώδης αφού απευθύνονται σε όλο και περισσότερους χρήστες. Το γεγονός αυτό σε συνδυασμό με την πληθώρα των συσκευών που συνδέονται στο διαδίκτυο και την ευρεία χρήση του από τους χρήστες σε κάθε πτυχή της καθημερινότητάς τους, έχει οδηγήσει στην ανάγκη για εύρεση αποτελεσματικών τρόπων για την καλύτερη δυνατή απόδοσή του και τη βέλτιστη διαχείριση του διαθέσιμου εύρους ζώνης. Η μηχανική μάθηση αποτελεί μια λύση στα συγκεκριμένα ζητήματα, αφού είναι σε θέση να επεξεργαστεί μεγάλο όγκο δεδομένων σε σύντομο χρονικό διάστημα, ακόμα και αν τα δεδομένα είναι πραγματικού χρόνου, όπως συμβαίνει στην περίπτωση των δικτύων επικοινωνιών.

Στην παρούσα διπλωματική εργασία έχουν υλοποιηθεί κάποιοι αλγόριθμοι μηχανικής μάθησης και έχει αναλυθεί η απόδοσή τους στα πεδία της διεκπαιρευτικής ικανότητας (throughput), του χρόνου καθυστέρησης (delay time) και του ρυθμού απόρριψης δεδομένων (drop rate). Αρχικά, γίνεται μια παρουσίαση εργασιών σχετικών με το αντικείμενο, καθώς και των αναμενόμενων αποτελεσμάτων της διπλωματικής. Στη συνέχεια γίνεται σύντομη αναφορά στα οπτικά δίκτυα, και πιο συγκεκριμένα στις κατηγορίες τους, τα κύρια στοιχεία τους, τα πρωτόκολλα προσπέλασης μέσου, καθώς και δύο συγκεκριμένων αρχιτεκτονικών ελέγχου που χρησιμοποιούνται ευρέως τα τελευταία χρόνια, τα λεγόμενα software-defined optical networks (SDON) και της OpenFlow αρχιτεκτονικής. Ακολούθως, παρουσιάζονται βασικά στοιχεία της μηχανικής μάθησης αλλά και ο τρόπος με τον οποίο η μηχανική μάθηση εφαρμόζεται σε δίκτυα. Τέλος, παρουσιάζεται η ανάπτυξη του κώδικα που πραγματοποιήθηκε, όπως επίσης και τα αποτελέσματα που έχουν προκύψει και εξάγονται κάποια χρήσιμα συμπεράσματα.

2. Εισαγωγή

2.1 Περιγραφή Προβλήματος

Η χρήση του διαδικτύου έχει γνωρίσει σημαντική και ταχεία άνοδο τα τελευταία χρόνια. Η άνοδος αυτή οφείλεται στο γεγονός ότι εκτός των ηλεκτρονικών υπολογιστών, πληθώρα συσκευών χρησιμοποιούν το Διαδίκτυο, όπως είναι για παράδειγμα οι έξυπνες συσκευές ενώ συνεχώς επεκτείνεται η χρήση του Internet of Things (IoT) τόσο από δημόσιους και ιδιωτικούς φορείς όσο και από τους απλούς χρήστες. Όλα τα παραπάνω έχουν δημιουργήσει αυξανόμενες ανάγκες για καλύτερη διαχείριση του εύρους ζώνης του δικτύου [1]. Ειδικότερα, οι εφαρμογές πολυμέσων και επικοινωνίας, οι οποίες προσφέρουν, μεταξύ άλλων υπηρεσιών, και υπηρεσίες βιντεοκλήσεων και τηλεδιασκέψεων [2], έχουν δημιουργήσει μια ιδιαίτερη πρόκληση στους διαχειριστές των δικτύων, προκειμένου να επιτύχουν τη βέλτιστη δομή του ίδιου του δικτύου, αλλά και τη βέλτιστη κατανομή των πόρων του δικτύου, ώστε να επιτευχθεί η καλύτερη δυνατή εξυπηρέτηση των χρηστών [3].

Επιπρόσθετα η τεχνολογία 5G που έχει αρχίσει και χρησιμοποιείται ευρέως όλο και περισσότερο [4], σε συνδυασμό με την αυξανόμενη ζήτηση για μεγαλύτερο εύρος ζώνης εξαιτίας του cloud computing και των μεγάλων data – centers που λειτουργούν [5], έχει οδηγήσει στην ανάγκη για δίκτυα μεγάλης χωρητικότητας. Όλη αυτή η ζήτηση για χωρητικότητα έχει περαιτέρω αυξηθεί λόγω της πανδημίας του COVID19, καθώς πολλές δραστηριότητες σε εταιρείες και πανεπιστήμια διενεργούνται εξ'αποστάσεως, επιβαρύνοντας ακόμα περισσότερα τα δίκτυα επικοινωνίας [6].

Βασικά στοιχεία ώστε να γίνει πραγματικότητα η καλύτερη δυνατή αξιοποίηση των δικτυακών πόρων και να εξλειφθούν όσο το δυνατόν περισσότερα προβλήματα, αποτελούν η βελτιστοποίηση του χρόνου επεξεργασίας των δεδομένων του δικτύου από τη μια και η ελαχιστοποίηση της καθυστέρησης μεταφοράς των δεδομένων από την άλλη [7]. Μια από τις αναδυόμενες τεχνικές που χρησιμοποιούνται ώστε να υπάρξει το επιθυμητό αποτέλεσμα είναι η μηχανική μάθηση. Μέσα από την πληθώρα των αλγορίθμων που έχουν αναπτυχθεί σχετικά

με τη μηχανική μάθηση και τα οπτικά δίκτυα [8], μπορεί να επιλεγεί ο πλέον κατάλληλος αλγόριθμος μηχανικής μάθησης για κάθε δίκτυο και τα ιδιαίτερα χαρακτηριστικά του, έχοντας ως στόχο την όσο το δυνατόν καλύτερη εξυπηρέτηση των χρηστών του δικτύου, με τρόπο γρήγορο, αυτόματο αλλά ταυτόχρονα έξυπνο, αφού αυτά είναι βασικά στοιχεία της μηχανικής μάθησης [9].

Ζητούμενο της παρούσας διπλωματικής εργασίας αποτελεί η συγκριτική μελέτη της απόδοσης συγκεκριμένων αλγορίθμων μηχανικής μάθησης που υλοποιήθηκαν ως προς τη διεκπεραιωτική ικανότητα (throughput) του δικτύου, τον ρυθμό απόρριψης πακέτων του δικτύου, καθώς επίσης και του χρόνου καθυστέρησης, ώστε τελικά να επιλεγεί ο αλγόριθμος που αξιοποιεί με τον καλύτερο δυνατό τρόπο τους πόρους του δικτύου και επιτυγχάνει ταχύτερη και πιο αξιόπιστη μετάδοση δεδομένων.

2.2 Σχετική Βιβλιογραφία

Τα τελευταία χρόνια, δεδομένης της συνεχόμενης ανάπτυξης των οπτικών δικτύων, έχει υπάρξει έντονο ενδιαφέρον στον τομέα της μηχανικής μάθησης με εφαρμογή στα οπτικά δίκτυα. Άξιο αναφοράς είναι το γεγονός πως το ενδιαφέρον αυτό δεν έχει επικεντρωθεί σε έναν συγκεκριμένο τομέα των δικτύων ή σε μια συγκεκριμένη κατηγορία προβλημάτων, τα οποία επιλύονται με τη χρήση μεθόδων μηχανικής μάθησης, αλλά υπάρχει πληθώρα μελετών που αφορά σχεδόν στο σύνολο των χαρακτηριστικών των οπτικών δικτύων και των προκλήσεων που σχετίζονται με τα εν λόγω δίκτυα.

Στη συνέχεια θα γίνει μια σύντομη αναφορά σε ερευνητικά δεδομένα που είναι διαθέσιμα για το πεδίο αυτό, καθώς στο Κεφάλαιο 6 θα γίνει μια πιο αναλυτική παρουσίαση τόσο των προβλημάτων των δικτύων που επιλύονται με τη μηχανική μάθηση, όσο και των τεχνικών μηχανικής μάθησης που χρησιμοποιούνται σε δίκτυα.

Στο [8] γίνεται αναλυτική παρουσίαση των τρόπων με τους οποίους μπορεί να εφαρμοστεί η μηχανική μάθηση στο φυσικό επίπεδο αλλά και στο επίπεδο δικτύου. Στο φυσικό επίπεδο, η μηχανική μάθηση μπορεί να χρησιμοποιηθεί για εκτίμηση της ποιότητας εκπομπής, για παρακολούθηση της απόδοσης και για αναγνώριση της μορφής της διαμόρφωσης. Σχετικά με την ποιότητα της εκπομπής, αυτή βασίζεται στον υπολογισμό κάποιων μετρικών εκπομπής, όπως το Bit Error Rate (BER) και το Optical Signal-to-Noise Ratio (OSNR). Οι αλγόριθμοι που έχουν αναπτυχθεί είναι μη εποπτευόμενοι και μεταξύ άλλων είναι οι Random Forest [10], regression [11] και k-nearest neighbor [12] που χρησιμοποιούν συνθετικά δεδομένα ως δεδομένα εκπαίδευσης, και τα νευρωνικά δίκτυα [13],[14] που χρησιμοποιούν πραγματικά δεδομένα για την εκπαίδευση των αλγορίθμων. Όσον αφορά την παρακολούθηση της απόδοσης υλοποιείται και αυτή με εποπτευόμενους αλγορίθμους μηχανικής μάθησης, όπως τα μοντέλα Gauss [15] που χρησιμοποιούν πραγματικά δεδομένα εκπαίδευσης και νευρωνικά δίκτυα που χρησιμοποιούν τόσο συνθετικά δεδομένα [16] όσο και πραγματικά [17],[18]. Τέλος, για την αναγνώριση της μορφής της διαμόρφωσης έχουν αναπτυχθεί clustering μη εποπτευόμενοι αλγόριθμοι [19] που χρησιμοποιούν συνθετικά δεδομένα, αλλά και εποπτευόμενοι αλγόριθμοι που κάνουν χρήση τόσο πραγματικών δεδομένων, όπως ο k-means [20], όσο και συνθετικών δεδομένων, όπως τα νευρωνικά δίκτυα [21]. Στο επίπεδο διασύνδεσης δεδομένων και στο επίπεδο δικτύου η μηχανική μάθηση είναι σε θέση να χρησιμοποιηθεί ώστε να γίνει πρόβλεψη της κίνησης του δικτύου, διαχείριση των σφαλμάτων του καθώς και υπολογισμός του βέλτιστου δρόμου αποστολής πακέτου. Για την πρόβλεψη της κίνησης του δικτύου έχουν αναπτυχθεί εποπτευόμενοι αλγόριθμοι, όπως τα νευρωνικά δίκτυα [22] και η ενισχυμένη μάθηση (Reinforcement Learning) [23], που χρησιμοποιούν συνθετικά δεδομένα εκπαίδευσης, αλλά και μη εποπτευόμενοι αλγόριθμοι clustering [24] που κάνουν χρήση πραγματικών δεδομένων εκπαίδευσης. Η διαχείριση των σφαλμάτων του δικτύου επιτυγχάνεται με εποπτευόμενους αλγόριθμους μηχανικής μάθησης που χρησιμοποιούν πραγματικά δεδομένα εκπαίδευσης, όπως για παράδειγμα τα Bayesian δίκτυα [25], regression [26] και decision tree [27]. Τέλος, για τον υπολογισμό του βέλτιστου δρόμου για την αποστολή ενός πακέτου στον προορισμό του έχει αναπτυχθεί, μεταξύ άλλων, Q-Learning εποπτευόμενος αλγόριθμος, ο

οποίος κάνει χρήση συνθετικών δεδομένων για την εκπαίδευσή του [28]. Παρά την ύπαρξη αρκετών αλγορίθμων για τα ζητήματα που αναφέρθηκαν προηγουμένως, όπως και βιβλιογραφίας στην οποία γίνεται σύγκριση κάποιων αλγορίθμων, η βιβλιογραφία περιορίζεται συνήθως στη σύγκριση μιας μετρικής κάθε φορά. Για το λόγο αυτό επιλέχθηκε στην παρούσα εργασία να γίνει σύγκριση αλγορίθμων μηχανικής μάθησης σε τρεις διαφορετικές μετρικές, όπως θα αναφερθεί και σε επόμενο κεφάλαιο.

Στο [29] παρουσιάζονται πέντε βασικοί τομείς που αφορούν τη μηχανική μάθηση και τα οπτικά δίκτυα. Αρχικά, αναφέρονται οι λόγοι και τα κίνητρα που έχουν οδηγήσει στη χρήση της μηχανικής μάθησης στα συγκεκριμένα δίκτυα, στη συνέχεια γίνεται αναφορά στις βασικές κατηγορίες της μηχανικής μάθησης και ακολούθως αναλύονται αλγόριθμοι μηχανικής μάθησης που χρησιμοποιούνται σε προβλήματα ελέγχου και διαχείρισης των πόρων του δικτύου, καθώς και παρακολούθησης και επιβιωσιμότητας των δικτύων. Τέλος, αναφέρονται οι προκλήσεις που υπάρχουν ακόμα στο συγκεκριμένο πεδίο και πιθανές λύσεις σχετικά με τις προκλήσεις αυτές. Κάποιοι από τους λόγους για τους οποίους χρησιμοποιείται η μηχανική μάθηση είναι η ανάγκη για χρήση παλαιότερων δεδομένων του δικτύου, ώστε να γίνει καλύτερη πρόβλεψη της μελλοντικής του συμπεριφοράς, η μείωση της απαιτούμενης υπολογιστικής ισχύος και τέλος η μείωση της απαιτούμενης γνώσης από τους διαχειριστές των δικτύων [30], [31]. Σχετικά με το πρόβλημα ελέγχου και διαχείρισης των πόρων του δικτύου έχουν αναπτυχθεί τόσο νευρωνικά δίκτυα [32], βαθιά νευρωνικά δίκτυα με δύο κρυφά επίπεδα [33], όσο και ο Long short-term memory (LSTM) αλγόριθμος [34], [35]. Για την παρακολούθηση της λειτουργίας του δικτύου και την αύξηση της επιβιωσιμότητάς του έχουν αναπτυχθεί τεχνητά νευρωνικά δίκτυα (ANN) [36], [37], [38], βαθιά νευρωνικά δίκτυα [39], Random Forest αλγόριθμος [40], Support Vector Machine αλγόριθμος [41], Naïve Bayes αλγόριθμος [42] και k-Means αλγόριθμος [43]. Τέλος, στο [44] πραγματοποιείται μια εκτενής παρουσίαση της μηχανικής μάθησης σε δίκτυα σε έντεκα διαφορετικούς τομείς. Αναλύεται τόσο ο τρόπος με τον οποίο γίνεται η συλλογή και επεξεργασία δεδομένων κατάλληλων για την εφαρμογή των αλγορίθμων μηχανικής μάθησης, όσο και ο τρόπος με τον οποίο τα

δεδομένα αυτά αξιοποιούνται στη συνέχεια στους διάφορους τομείς που παρουσιάζονται, όπως για παράδειγμα στον έλεγχο συμφόρησης, την ταξινόμηση του φόρτου και την ασφάλεια του δικτύου μεταξύ άλλων. Οι τομείς στους οποίους επεκτείνεται η συγκεκριμένη βιβλιογραφική αναφορά είναι η πρόβλεψη, κατηγοριοποίηση και δρομολόγηση της κίνησης του δικτύου, ο έλεγχος των συγκρούσεων, η διαχείριση των πόρων του δικτύου και των σφαλμάτων του, η διαχείριση της ποιότητας των προσφερόμενων υπηρεσιών του δικτύου και η ασφάλειά του [44]. Για καθέναν από αυτούς τους τομείς αναφέρονται αλγόριθμοι μηχανικής μάθησης που έχουν υλοποιηθεί ήδη, περιγράφοντας συνοπτικά τον τρόπο λειτουργίας τους και τα αποτελέσματά τους από πλευράς ακρίβειας προβλέψεων.

2.3 Αναμενόμενα Αποτελέσματα

Σκοπός της παρούσας διπλωματικής εργασίας είναι η συγκριτική αποτίμηση κάποιων βασικών αλγορίθμων μηχανικής μάθησης μέσω της χρήσης συγκεκριμένων μετρικών. Οι μετρικές που έχουν χρησιμοποιηθεί είναι η διεκπεραιωτική ικανότητα, ο χρόνος καθυστέρησης και ο ρυθμός απόρριψης δεδομένων. Η διεκπεραιωτική ικανότητα χρησιμοποιείται ώστε να υπάρχουν προσεγγίσεις σχετικά με την ποσότητα της πληροφορίας που αναμένεται να μεταδοθεί στο δίκτυο αναλόγως του αλγορίθμου μηχανικής μάθησης που υλοποιείται. Ο χρόνος καθυστέρησης χρησιμοποιείται ώστε να προσεγγιστεί ο χρόνος που απαιτείται, ώστε να φτάσει στον προορισμό του κάθε πακέτο και τέλος μέσω του ρυθμού απόρριψης δεδομένων αποκτάμε εικόνα της ποσότητας των δεδομένων που δε φτάνουν στον προορισμό τους, λόγω υπέρβασης του χρονικού ορίου αναμονής σε κάποιον κόμβο του δικτύου.

Λίγο πιο αναλυτικά, θα υπολογιστούν οι συγκεκριμένες μετρικές με τη χρήση πραγματικών μετρήσεων κίνησης σε ένα δίκτυο πανεπιστημίου χωρίς τη χρήση κάποιου αλγορίθμου μηχανικής μάθησης, ώστε να εκτιμηθεί η απόδοσή του. Στη συνέχεια, θα αναπτυχθούν οι αλγόριθμοι μηχανικής μάθησης που θα

παρουσιαστούν αναλυτικά και στο Κεφάλαιο 7, και θα γίνει νέος υπολογισμός των μετρικών αυτών για κάθε αλγόριθμο. Μέσω των συγκεκριμένων μετρικών δίνεται η δυνατότητα να επιτευχθεί η βελτιστοποίηση της αξιοποίησης των δικτυακών πόρων που χρησιμοποιεί το δίκτυο, γεγονός που θα οδηγήσει στην καλύτερη απόδοση του δικτύου όσον αφορά την ταχύτητα μετάδοσης δεδομένων και τη μετάδοση χωρίς απώλειες. Απώτερος στόχος είναι η επιλογή του αποδοτικότερου αλγορίθμου μηχανικής μάθησης, δηλαδή του αλγορίθμου με τις καλύτερες τιμές μετρικών, ώστε η επίβλεψη των εν λόγω μετρήσεων να γίνεται αυτόματα και σε πραγματικό χρόνο μέσω του αλγορίθμου, χωρίς να απαιτείται από τους διαχειριστές να αναλύουν τα δεδομένα, μια διαδικασία ιδιαίτερα χρονοβόρα.

3. Οπτικά Δίκτυα

3.1 Κατηγορίες Οπτικών Δικτύων

Στο κεφάλαιο αυτό θα αναφερθούν κάποιες κατηγορίες οπτικών δικτύων, όπως επίσης και το κριτήριο βάσει του οποίου έγινε η κατηγοριοποίηση αυτή, και στη συνέχεια θα γίνει μια σύντομη ανάλυση των βασικών χαρακτηριστικών κάθε κατηγορίας. Τα κριτήρια αυτά είναι η τεχνολογία πρόσβασης και ο τρόπος με τον οποίο ο χρήστης του δικτύου έχει πρόσβαση σε αυτό, το μέγεθος του δικτύου και η αρχιτεκτονική του. Στον Πίνακα 1 που ακολουθεί παρουσιάζονται κάποιες κατηγορίες οπτικών δικτύων, καθώς και το κριτήριο κατηγοριοποίησής τους.

Κριτήριο Κατηγοριοποίησης	Κατηγορία Οπτικού Δικτύου
Τεχνολογία πρόσβασης	Παθητικά οπτικά δίκτυα (PONs) - Οπτική ίνα στο x (x: σπίτι, κτήριο κ.α)
	Οπτικό δίκτυο ελεύθερου χώρου
Έκταση κάλυψης δικτύου	Οπτικό δίκτυο μεγάλων αποστάσεων (long haul network)
	Οπτικό δίκτυο μητροπολιτικής περιοχής (MAN)
	Τοπικά Οπτικά Δίκτυα (LAN)
	Οπτικά Δίκτυα μικρής Κλίμακας πχ. δίκτυα κέντρων δεδομένων
Αρχιτεκτονική δικτύου	Flexible οπτικό δίκτυο (FON)
	Elastic οπτικό δίκτυο (EON)
Τρόπος διασύνδεσης	Δίκτυο οπτικών συνδέσμων
	Οπτικό δίκτυο εκπομπής και επιλογής (broadcast -and-select)
	Οπτικό δίκτυο δρομολόγησης μήκους κύματος
	Δίκτυο μεταγωγής οπτικής ριπής

Πίνακας 1 - Κατηγορίες Οπτικών Δικτύων

Βάσει της τεχνολογίας πρόσβασης τα οπτικά δίκτυα μπορούν να χωριστούν σε παθητικά οπτικά δίκτυα (PONs), οπτικά δίκτυα στο x για παράδειγμα οπτικό δίκτυο στο σπίτι fiber to the home και οπτικά δίκτυα ελεύθερου χώρου μεταξύ άλλων. Στα παθητικά οπτικά δίκτυα βασικό στοιχείο τους αποτελεί η ύπαρξη ενός παθητικού διαχωριστή μεταξύ του τελικού χρήστη και του δικτύου [45]. Τα οπτικά δίκτυα τύπου «οπτική ίνα στο x» (Fiber to the x) διαφοροποιούνται αναλόγως του x που εκφράζει το σημείο στο οποίο τερματίζει η οπτική ίνα. Το σημείο αυτό μπορεί να είναι το σπίτι, όπου έχουμε δίκτυο FTTH, κτήριο που το δίκτυο ονομάζεται FTTB κ.ο.κ [45]. Τα οπτικά δίκτυα ελεύθερου χώρου συνδυάζουν την οπτική με την ασύρματη τεχνολογία, ώστε να επιτευχθεί ευρεία πρόσβαση στα δίκτυα από πολλαπλούς χρήστες με αξιόπιστη ταχύτητα [45].

Βάσει του μεγέθους του δικτύου μπορεί να υπάρξει οπτικό δίκτυο ευρείας ζώνης, οπτικό δίκτυο μητροπολιτικής περιοχής, τοπικά οπτικά δίκτυα και οπτικά δίκτυα μικρής κλίμακας. Στην πρώτη περίπτωση έχουμε διασύνδεση του οπτικού δικτύου σε μια ευρεία γεωγραφική περιοχή, η οποία μπορεί να περιλαμβάνει ακόμα και διασύνδεση μεταξύ χωρών [45]. Στη δεύτερη περίπτωση έχουμε διασύνδεση των κόμβων του οπτικού δικτύου, αλλά σε μικρότερο εύρος περιοχής, το οποίο μπορεί να περιλαμβάνει μέχρι και μια ολόκληρη πόλη, και στη συνέχεια το MAN δίκτυο διασυνδέεται με το WAN [45]. Τα τοπικά οπτικά δίκτυα έχουν ακόμα μικρότερη γεωγραφική έκταση σε σχέση με ένα MAN δίκτυο, και συνήθως αναπτύσσονται σε πανεπιστήμια, νοσοκομεία και επιχειρήσεις [45], όπου δεν υπάρχουν μεγάλες αποστάσεις μεταξύ των κόμβων του δικτύου. Και σε αυτή την περίπτωση το LAN δίκτυο συνδέεται στη συνέχεια με το MAN δίκτυο και έπειτα με το WAN δίκτυο. Τα τελευταία χρόνια έχουν αναπτυχθεί και τα οπτικά δίκτυα μικρής κλίμακας, τα οποία είναι δίκτυα που είναι αναπτυγμένα εντός ενός υπολογιστή συνήθως [46]. Τα εν λόγω δίκτυα προτιμούνται συνήθως όταν υπάρχουν συστήματα πολλαπλών πυρήνων, όπου η απαίτηση για μεγάλες ταχύτητες επικοινωνίας, με μεγάλο εύρος και χαμηλή κατανάλωση είναι μεγάλη [200].

Η χρήση όλο και περισσότερων κέντρων δεδομένων (data centers) και cloud computing έχει οδηγήσει στη συνεχή αύξηση της ζήτησης για μεγαλύτερο ρυθμό

μετάδοσης δεδομένων. Αυτό έχει ως αποτέλεσμα η αρχιτεκτονική οπτικών δικτύων με σταθερή ανάθεση μήκους κύματος στις οπτικές ίνες να μην είναι σε θέση να υποστηρίξει την αυξανόμενη ζήτηση, και να δημιουργηθούν τα Flexible οπτικά δίκτυα. Όταν χρησιμοποιούμε τον όρο flexible για ένα δίκτυο αναφερόμαστε στην ικανότητα του δικτύου να τροποποιεί δυναμικά τους πόρους, αναλόγως των απαιτήσεων κάθε κόμβου [47]. Στα flexible οπτικά δίκτυα, πιο συγκεκριμένα, υπάρχει δυνατότητα για μεταβολή του μήκους κύματος και άλλων χαρακτηριστικών του δικτύου, όπως η μορφή της διαμόρφωσης του σήματος [47]. Μια κατηγορία των Flexible οπτικών δικτύων είναι τα ελαστικά οπτικά δίκτυα (Elastic Optical Networks), τα οποία είναι δίκτυα που περιλαμβάνουν συντονιζόμενους (tunable) πομπούς και δέκτες και «έξυπνους» κόμβους δικτύου [45]. Στα ελαστικά οπτικά δίκτυα γίνεται κατανομή του φάσματος αναλόγως της κίνησης του δικτύου και οι πομποδέκτες προσαρμόζονται στο μήκος κύματος που μεταδίδεται σε κάθε χρονική στιγμή. Επιπλέον οι σταθμοί των χρηστών είναι σε θέση να κατανοήσουν και να προσαρμοστούν στις αλλαγές αυτές [45].

Όσον αφορά τα οπτικά δίκτυα, βάσει του τρόπου διασύνδεσης και μεταφοράς δεδομένων, αυτά μπορεί να είναι αρχικά δίκτυα οπτικών συνδέσμων στα οποία υπάρχουν οπτικοί σύνδεσμοι point-to-point ή διαμοιραζόμενου μέσου. Επίσης, μπορεί να είναι δίκτυα εκπομπής και επιλογής στα οποία υπάρχουν αποκλειστικά συντονιζόμενοι οπτικοί αποδέκτες και μεταδότες, δίκτυα δρομολόγησης μήκους κύματος στα οποία χρησιμοποιούνται συντονιζόμενοι οπτικοί μεταδότες και αποδέκτες και μπορεί να είναι ενός ή πολλαπλών βημάτων. Ακόμη, υπάρχουν και τα δίκτυα μεταγωγής οπτική ριπής, στα οποία γίνεται συνδυασμός των τεχνικών μεταγωγής κυκλώματος και μεταγωγής πακέτου, ώστε να μην υπάρχει χρόνος εγκαθίδρυσης του κυκλώματος, δηλαδή χρόνος ώστε να βρεθεί το μονοπάτι το οποίο θα χρησιμοποιηθεί για τη μετάδοση της πληροφορίας [48].

3.2 Κύρια Στοιχεία Οπτικών Δικτύων

Τα βασικά στοιχεία ενός οπτικού δικτύου θα αναφερθούν επιγραμματικά στην συνέχεια:

- Οπτική ίνα: η οπτική ίνα χρησιμοποιείται λόγω της πολύ μικρής εξασθένησης που παρουσιάζεται κατά τη διάδοση του φωτός. Μπορεί να είναι είτε μονότροπη είτε πολύτροπη [48].
- Πηγές δημιουργίας φωτός: οι πηγές φωτός χρησιμοποιούνται ώστε να δημιουργηθεί το οπτικό φέρον σήμα για την για τη μεταφορά της πληροφορίας. Μπορούν να διακριθούν σε πομπούς laser και διόδους εκπομπής φωτός [48].
- Οπτικοί δέκτες: οι οπτικοί δέκτες αποτελούν ένα από τα κρίσιμα στοιχεία σε ένα οπτικό δίκτυο, καθώς συνήθως το σήμα που φτάνει στον δέκτη είναι εξασθενημένο και απαιτείται ο δέκτης να έχει την κατάλληλη ευαισθησία για να το αξιοποιήσει [48].
- Οπτικοί ενισχυτές: οι οπτικοί ενισχυτές είναι απαραίτητοι όταν η απόσταση μετάδοσης είναι μεγάλη, καθώς το οπτικό σήμα απαιτεί ενίσχυση κάθε 60-80 km περίπου [45]. Σε περιπτώσεις, λοιπόν, που χρειάζεται η μετάδοση να υπερβεί την απόσταση αυτή, τοποθετούνται οπτικοί ενισχυτές για την διασφάλιση της μετάδοσης.
- Οπτικά φίλτρα: τα οπτικά φίλτρα είναι στοιχείο του δέκτη και χρησιμοποιούνται όταν χρειάζεται να περιοριστεί η μετάδοση του φωτός, επιτρέποντας σε συγκεκριμένα μήκη κύματος να διέλθουν μέσα από αυτά, εμποδίζοντας στα υπόλοιπα τη διέλευση [48]. Τα οπτικά φίλτρα μπορεί να είναι είτε σταθερά είτε συντονιζόμενα [45]. Τα σταθερά οπτικά φίλτρα έχουν προκαθορισμένα τα μήκη κύματος που επιτρέπουν να διέλθουν και αυτά που δεν επιτρέπουν, σε αντίθεση με τα συντονιζόμενα που η επιτρεπτή ζώνη μηκών κύματος μπορεί να διαφοροποιηθεί αναλόγως των απαιτήσεων του δικτύου [45].
- Οπτικός πολυπλέκτης/αποπολυπλέκτης: όταν χρησιμοποιείται η τεχνική της πολύπλεξης με διαίρεση μήκους κύματος (WDM technique), είναι

απαραίτητο οπτικά κανάλια μετάδοσης από διαφορετικές ίνες να ενωθούν σε μια οπτική ίνα. Αυτό επιτυγχάνεται μέσω του οπτικού πολυπλέκτη, ενώ η αντίθετη διαδικασία, δηλαδή ο διαχωρισμός του φωτός στα επιμέρους κανάλια μετάδοσης επιτυγχάνεται μέσω του οπτικού αποπολυπλέκτη [45].

- Παθητικές συσκευές ζεύξης: οι παθητικές συσκευές ζεύξης είναι συσκευές οι οποίες μπορούν να συνδυάσουν ή να διαχωρίσουν το οπτικό σήμα με διαφορετικές αναλογίες διαχωρισμού, αναλόγως των θυρών που έχουν [45].
- $N \times N$ ζεύξη αστέρα: ο συζευκτής τύπου αστέρα $N \times N$ είναι από τις διαδεδομένες παθητικές συσκευές που χρησιμοποιούνται στα οπτικά δίκτυα, καθώς έχει τη δυνατότητα τα σήματα εισόδου που λαμβάνει να τα στέλνει σε όλες τις θύρες εξόδου ταυτόχρονα [45]. Για παράδειγμα ένας 2×2 συζευκτής αστέρα στις δύο θύρες εξόδου θα κατευθύνει και τα δύο σήματα εισόδου που δέχεται.
- Δρομολογητές μήκους κύματος: βασική λειτουργία των δρομολογητών μήκους κύματος αποτελεί ο έλεγχος κάθε πακέτου που μεταδίδεται σε ένα δίκτυο και η πρόωθσή του στη σωστή κατεύθυνση. Επιπλέον, η δρομολόγηση γίνεται αναλόγως του μήκους κύματος εισόδου [48], ενώ οι δρομολογητές αυτοί μπορεί να είναι είτε σταθεροί, είτε να έχουν δυνατότητα αναδιάταξης.
- Συνδυαστές/διαχωριστές: όταν είναι απαραίτητο να συνδυαστεί η ισχύς από τουλάχιστον δύο διαφορετικές οπτικές ίνες σε μια τελική ίνα τότε η χρήση του συνδυαστή είναι απαραίτητη. Αντίστοιχα, όταν είναι απαραίτητο να διαχωριστεί η ισχύς από μια οπτική ίνα σε τουλάχιστον δύο οπτικές ίνες εξόδου, τότε ο διαχωριστής είναι το στοιχείο που πρέπει να χρησιμοποιηθεί [48].
- Μετατροπέας μήκους κύματος: ο μετατροπέας μήκους κύματος χρησιμοποιείται όταν είναι απαραίτητη η μετατροπή ενός μήκους κύματος σε ένα άλλο μήκος κύματος διαφορετικό του πρώτου, ώστε να υπάρξει βελτίωση της απόδοσης του δικτύου [45]. Απαραίτητη προϋπόθεση αποτελεί το μήκος κύματος στο οποίο γίνεται η μετατροπή να είναι μέσα στα όρια λειτουργίας του συστήματος.

3.3 Πρωτόκολλα Προσπέλασης Μέσου

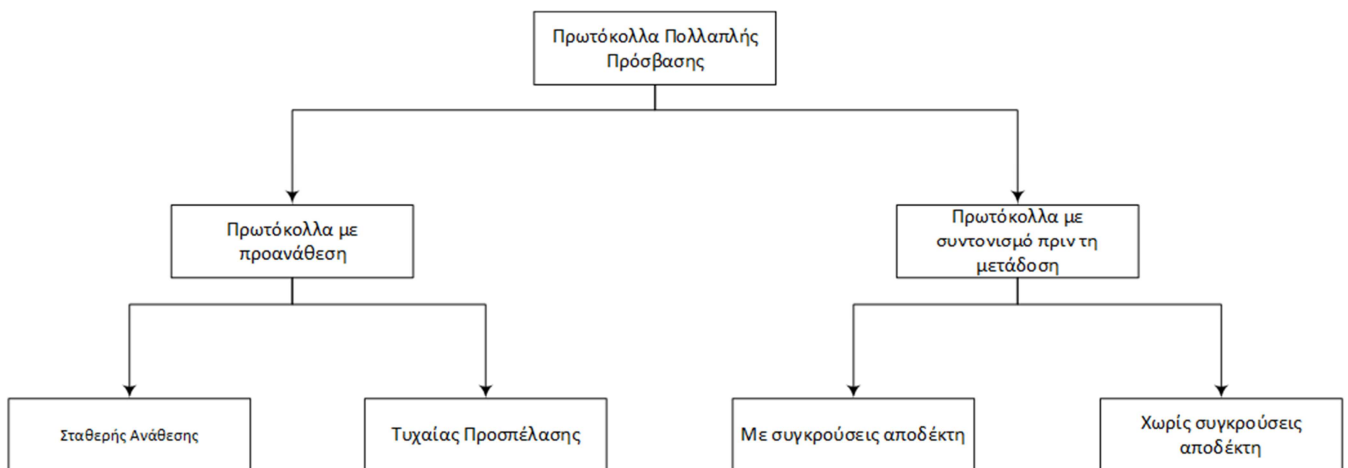
Στο κεφάλαιο αυτό θα γίνει αναφορά στα πρωτόκολλα προσπέλασης μέσου, τα οποία χρησιμοποιούν τα δίκτυα εκπομπής και επιλογής. Τα πρωτόκολλα αυτά είναι δύο κατηγοριών. Αυτά της προανάθεσης και τα πρωτόκολλα που εμπεριέχουν συντονισμό πριν τη μετάδοση [48]. Κοινό χαρακτηριστικό και των δύο αυτών κατηγοριών αποτελεί ο προσδιορισμός του τρόπου με τον οποίο πραγματοποιείται η εκπομπή και επιλογή. Βασική επιδίωξη των πρωτοκόλλων είναι ότι ο συντονισμός των μεταδόσεων που λαμβάνουν χώρα στο δίκτυο. Ταυτόχρονα, τίθενται οι κανόνες που ακολουθεί ένας κόμβος όταν χρειάζεται να εκπέμψει ένα πακέτο, αλλά τα πακέτα προς αποστολή είναι περισσότερα του ενός, οπότε πρέπει να γίνει μια προτεραιοποίηση των αποστολών βάσει κάποιων κανόνων.

Δύο υποκατηγορίες των πρωτοκόλλων με προανάθεση (pre-allocation protocols) είναι τα πρωτόκολλα σταθερής ανάθεσης και τα πρωτόκολλα της τυχαίας προσπέλασης [48]. Σε αυτά τα πρωτόκολλα όλα τα διαθέσιμα μήκη κύματος χρησιμοποιούνται αποκλειστικά ως κανάλια μέσα από τα οποία θα γίνει η διέλευση των δεδομένων. Ειδικότερα, στα πρωτόκολλα σταθερής ανάθεσης οι χρονικές στιγμές κατά τις οποίες επιτρέπεται στους κόμβους να έχουν πρόσβαση στα κανάλια έχουν προσδιοριστεί εκ των προτέρων, αποφεύγοντας με τον τρόπο αυτό τις συγκρούσεις πακέτων από τυχόν προσπάθεια ταυτόχρονης εκπομπής δύο σταθμών. Αντίθετα, στα πρωτόκολλα τυχαίας προσπέλασης οι κόμβοι έχουν τη δυνατότητα να προσπελάσουν τα κανάλια με τυχαίο και μη καθορισμένο εκ των προτέρων τρόπο, κάτι όμως που έχει ως αποτέλεσμα να υπάρχουν συγκρούσεις πακέτων στο δίκτυο.

Στα πρωτόκολλα με συντονισμό πριν τη μετάδοση αυτό που διαφέρει σε σχέση με τις δύο προαναφερθείσες κατηγορίες πρωτοκόλλων είναι ότι υπάρχουν κάποια κανάλια ελέγχου ώστε να πραγματοποιείται συντονισμός πριν τη μετάδοση των δεδομένων [48]. Για να επιτευχθεί αυτό, η μετάδοση υλοποιείται σε δύο στάδια. Αρχικά, γίνεται η αναγγελία στο κανάλι ελέγχου ότι κάποιος από τους σταθμούς θέλει να μεταδώσει δεδομένα και στο επόμενο και τελευταίο στάδιο γίνεται η μετάδοση των δεδομένων αυτών. Είναι χαρακτηριστικό ότι παρά το γεγονός ότι

συγκρούσεις μπορεί να συμβούν σε οποιοδήποτε από τα δύο στάδια ή και στα δύο, υπάρχουν κάποια πρωτόκολλα με συντονισμό προμετάδοσης που εξαλείφουν τις συγκρούσεις, όπως για παράδειγμα ένα τροποποιημένο ALOHA πρωτόκολλο, το πρωτόκολλο αποφυγής συγκρούσεων αποδέκτη (RCA) και το πρωτόκολλο πολλαπλής πρόσβασης με διαίρεση χρόνου (TDMA-W) [48]. Τα πρωτόκολλα με συντονισμό πριν τη μετάδοση μπορούν να είναι είτε πρωτόκολλα με συγκρούσεις αποδέκτη είτε πρωτόκολλα χωρίς συγκρούσεις αποδέκτη, που είναι και οι δύο υποκατηγορίες των πρωτοκόλλων αυτών [48].

Στην *Εικόνα 1* που ακολουθεί παρουσιάζονται συνοπτικά τα πρωτόκολλα πολλαπλής πρόσβασης που έχουν αναφερθεί στο κεφάλαιο αυτό [48].



Εικόνα 1 - Πρωτόκολλα Πολλαπλής Πρόσβασης

4. Αρχιτεκτονικές Ελέγχου

4.1 Βασικές Πληροφορίες Control Plane σε οπτικά δίκτυα

Στα δίκτυα επικοινωνιών και κατ'επέκταση και στα οπτικά δίκτυα, η αρχιτεκτονική του control plane διαφέρει αναλόγως αν το δίκτυο είναι καθοριζόμενο από το λογισμικό (software-defined) ή όχι. Η διαφορά έγκειται στο γεγονός ότι στα δίκτυα που δεν είναι software-defined οι λειτουργίες του control plane εκτελούνται σε κάθε συσκευή του δικτύου, σε αντίθεση με τα software-defined δίκτυα, όπου γίνεται διαχωρισμός και οι λειτουργίες του control plane εκτελούνται από ένα ξεχωριστό στοιχείο του δικτύου (controller) που τρέχει ένα λογισμικό κεντρικοποιημένου ελέγχου. Το λογισμικό αυτό έχει πλήρη γνώση της τοπολογίας του δικτύου και είναι σε θέση να διαμορφώσει και να προγραμματίσει τον τρόπο που θα γίνεται προώθηση των δεδομένων από κάθε συσκευή του δικτύου. Αντίθετα, στα δίκτυα που δεν είναι software-defined η δρομολόγηση και προώθηση των δεδομένων υλοποιείται βάσει κάποιου αποκεντρωμένου πρωτοκόλλου.

Εντούτοις, ανεξάρτητα αν το δίκτυο είναι software-defined ή όχι, τα βασικά στοιχεία του control plane δεν διαφοροποιούνται σημαντικά, όπως επίσης και οι γενικές λειτουργίες που επιτελούνται. Σχετικά με τις λειτουργίες του control plane, μπορούμε να αναφέρουμε ότι έχουν δύο χαρακτηριστικά:

- Εκτελούνται μέσα στο δίκτυο και πιο συγκεκριμένα στους κόμβους του δικτύου,
- Η επικοινωνία κάθε λειτουργίας με την αντίστοιχα λειτουργία ενός άλλου κόμβου επιτυγχάνεται με τη χρήση ειδικών πρωτοκόλλων σχεδιασμένων για τον σκοπό αυτό [50].

Τέλος, θα αναφερθούν μερικές βασικές λειτουργίες του control plane. Μια από τις κύριες λειτουργίες του επιπέδου ελέγχου είναι η δρομολόγηση και η κατανομή των πόρων (Resource allocation). Η τελευταία χωρίζεται σε δύο υπολειτουργίες, αυτή της δημιουργίας της τοπολογίας του δικτύου και εύρεσης κατάλληλων πόρων, και αυτή του υπολογισμού του απαιτούμενου μονοπατιού [51]. Άλλη μια σημαντική λειτουργία του επιπέδου αυτού είναι η σηματοδότηση μεταξύ των κόμβων του δικτύου, λειτουργία πολύ σημαντική αφού η σηματοδότηση επιτρέπει την επικοινωνία μεταξύ των στοιχείων του δικτύου [51]. Επιπλέον, η εύρεση πληροφοριών γειτονικών κόμβων είναι ακόμα μια λειτουργία του επιπέδου ελέγχου, αφού με τον τρόπο αυτό αποφασίζονται οι λεπτομέρειες της σύνδεσης που πρέπει να δημιουργηθεί για την μεταξύ τους επικοινωνία [52].

Η λειτουργία των software-defined δικτύων έχει συνεισφέρει στον καλύτερο έλεγχο και τη βελτιστοποίηση της απόδοσης των δικτύων, αφού μέσω της αυτόματης προώθησης της πληροφορίας επιτυγχάνονται καλύτεροι χρόνοι εξυπηρέτησης των χρηστών [53]. Η ποιότητα των υπηρεσιών (Quality-of-Service) έχει επίσης βελτιωθεί παρέχοντας μικρότερο αριθμό σφαλμάτων κατά τη μετάδοση των δεδομένων [54]. Επιπροσθέτως, μέσω των software-defined δικτύων δίνεται η δυνατότητα για ανακατεύθυνση της κίνησης του δικτύου μεταξύ των διαθέσιμων servers, χωρίς να υπάρχει ανάγκη να δημιουργηθεί κάποιο νέο σύστημα ή να προστεθεί κάποιος νέος server, εξοικονομώντας πόρους και χρόνο [54]. Όλα αυτά τα χαρακτηριστικά των software-defined δικτύων δείχνουν τους τομείς στους οποίους αυτά υπερτερούν σε σχέση με τα αποκεντρωμένα δίκτυα, επιλύοντας κάποια από τα προβλήματα των τελευταίων. Η μεγάλη ανάπτυξη των οπτικών δικτύων έχει οδηγήσει αναπόφευκτα και στη δημιουργία των software-defined οπτικών δικτύων, τα οποία θα αναλυθούν περαιτέρω στον επόμενο κεφάλαιο.

4.2 Software – Defined Οπτικά Δίκτυα

Εξαιτίας της ραγδαίας αύξησης της κίνησης στα τηλεπικοινωνιακά δίκτυα, η ύπαρξη ενός ευέλικτου και προγραμματιζόμενου δικτύου αποτελεί μια διαρκή

απαίτηση. Για την αντιμετώπιση αυτής της αύξησης της κίνησης, δημιουργήθηκαν Software-Defined οπτικά δίκτυα, τα οποία έχουν ως κύριο χαρακτηριστικό τους ότι τα control και data plane είναι προγραμματιζόμενα και ευέλικτα όσον αφορά τη διαμόρφωση και τις λειτουργίες τους [55]. Η τοπολογία του δικτύου είναι πλήρως ευέλικτη και ταυτόχρονα επεκτάσιμη αναλόγως τις απαιτήσεις σε κίνηση που υπάρχουν κάθε στιγμή στο δίκτυο.

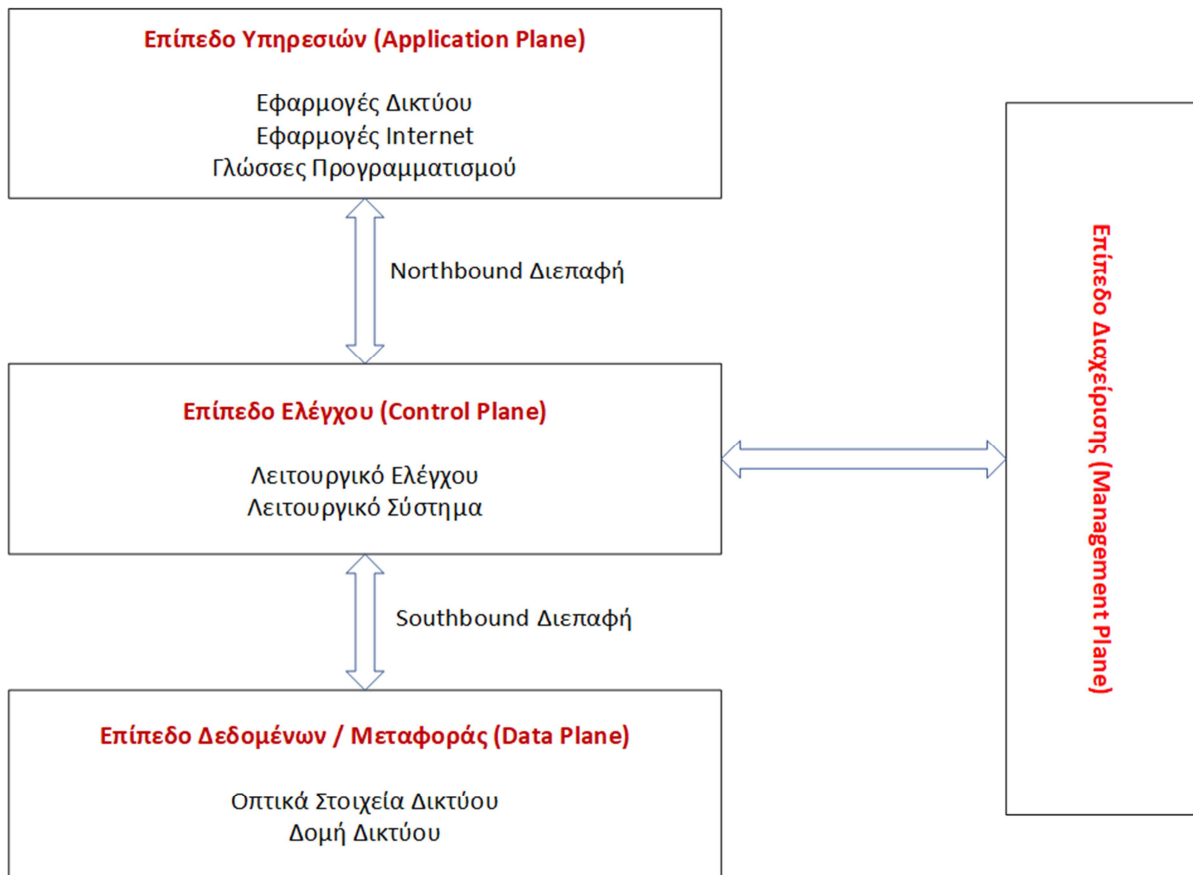
Τα Software-Defined οπτικά δίκτυα διέπονται από τρεις βασικές αρχές στην αρχιτεκτονική τους, οι οποίες είναι οι ακόλουθες:

- Οι λειτουργίες του control plane με τις λειτουργίες του data plane είναι τελείως διαχωρισμένες [53],
- Οι λειτουργίες του δικτύου είναι πλήρως προγραμματιζόμενες [53] και τέλος,
- Ο έλεγχος των λειτουργιών και του δικτύου γενικότερα γίνεται κεντρικά μέσα από συγκεκριμένους controllers [45].

Ο διαχωρισμός των επιπέδων λειτουργίας και δεδομένων που αναφέρθηκε είναι ο παράγοντας που επέτρεψε ουσιαστικά και τη δημιουργία των δικτύων αυτών [53]. Μέσω του συγκεκριμένου διαχωρισμού βελτιώθηκε αισθητά ο απαιτούμενος χρόνος για την προώθηση των πακέτων, [54], ειδικά στα οπτικά δίκτυα, όπου το διαθέσιμο bandwidth είναι μεγάλο [54]. Επιπλέον, το γεγονός ότι τα επίπεδα λειτουργίας διαχωρίστηκαν έδωσε τη δυνατότητα στα οπτικά δίκτυα να εκμεταλλευτούν σε μεγαλύτερο βαθμό τη μεγάλη χωρητικότητά τους και τη χαμηλή κατανάλωση ισχύος [54]. Ακόμη, επιλύεται το πρόβλημα διαμοίρασης πόρων δικτύου που δημιουργείται όταν πολλοί διαφορετικοί χρήστες προσπαθούν να χρησιμοποιήσουν τους ίδιους πόρους του δικτύου, ενώ μέσω του διαχωρισμού των επιπέδων λειτουργίας δημιουργούνται και διασυνδέονται πολλαπλοί χρήστες του δικτύου ταυτόχρονα, κατοχυρώνοντας με τον τρόπο αυτό την ασφάλεια της επικοινωνίας και την ανεξαρτησία από πιθανές βλάβες στο δίκτυο [56]. Ταυτόχρονα, αρκετοί δείκτες που αναφέρονται στην ποιότητα μετάδοσης στο δίκτυο, όπως οι δείκτες BER και Q-factor, παρουσιάζουν αισθητή βελτίωση στις

τιμές τους σε software-defined οπτικά δίκτυα, συγκριτικά με τα αποκεντρωμένα δίκτυα [55]. Όλα τα παραπάνω δείχνουν κάποιους από τους λόγους για τους οποίους έχει υλοποιηθεί ο διαχωρισμός των επιπέδων λειτουργίας, καθώς επίσης και τις απαιτήσεις που υπάρχουν από ένα SDON δίκτυο.

Η βασική αρχιτεκτονική ενός SDON δικτύου απεικονίζεται στην *Εικόνα 2*.



Εικόνα 2- Αρχιτεκτονική SDON Δικτύου

Βασικό χαρακτηριστικό του data plane είναι ότι πρέπει να είναι ευέλικτο και προγραμματιζόμενο [45]. Αυτό συνεπάγεται ότι όλα τα στοιχεία που υπάρχουν στο δίκτυο πρέπει να έχουν αυτές τις δυνατότητες. Επιπλέον, στο συγκεκριμένο επίπεδο υπάρχουν και τα οπτικά στοιχεία που απαρτίζουν το δίκτυο, τα οποία μπορεί να είναι οπτικοί πομποί, οπτικοί δέκτες καθώς και πλήρως προγραμματιζόμενα switches. Βασική λειτουργία του data plane είναι ότι ανταλλάσσει πληροφορίες και δεδομένα με τα υπόλοιπα planes του δικτύου [56].

Το control plane αποτελεί τον πυρήνα ενός Software – Defined οπτικού δικτύου. Αποτελείται από χάρτη που περιέχει τις βασικές ροές του δικτύου, καθώς και από έναν ελεγκτή, ο οποίος είναι υπεύθυνος για το λειτουργικό σύστημα [45]. Εξαιτίας του ότι είναι ο ενδιάμεσος μεταξύ των data plane και application plane, πρέπει να παρέχει δεδομένα σχετικά με τα πακέτα, τις χρονοθυρίδες, τα μήκη κύματος που χρησιμοποιούνται κ.ά., δηλαδή για τους πόρους που χρησιμοποιεί το δίκτυο, αναδεικνύοντας τον κρίσιμο ρόλο που έχει στην αρχιτεκτονική των εν λόγω δικτύων. Η απαραίτητη επικοινωνία με τα άλλα δύο planes γίνεται μέσω των northbound και southbound διεπαφών. Ο υπολογισμός των μονοπατιών των δεδομένων, η συλλογή πληροφοριών σχετικά με την τοπολογία του δικτύου και την κατάσταση των συνδέσεων του δικτύου είναι μερικές από τις κύριες λειτουργίες του επιπέδου αυτού [56].

Στο application plane εκτελούνται λειτουργίες όπως η δρομολόγηση, ο έλεγχος της πρόσβασης, η ασφάλεια του δικτύου και η ανάκτηση των δεδομένων σε περίπτωση σφάλματος [45]. Ειδικότερα, οι λειτουργίες που είναι απαραίτητες για τη διαχείριση της κίνησης και του ίδιου του δικτύου γίνονται μέσω του OpenFlow πρωτοκόλλου, το οποίο θα αναλύθει στο επόμενο κεφάλαιο.

Αν και το management plane δεν είναι ευρέως αποδεκτό ακόμα ως ένα επίπεδο της αρχιτεκτονικής των Software – Defined οπτικών δικτύων [53], εντούτοις ο ρόλος του καθίσταται όλο και πιο σημαντικός, καθώς το συγκεκριμένο επίπεδο είναι υπεύθυνο ώστε όλες οι υπομονάδες του δικτύου να συνεργάζονται ομαλά με τον ελεγκτή [53]. Η πιο συνηθισμένη δομή στο συγκεκριμένο επίπεδο είναι η ύπαρξη ενός γενικού ελεγκτή, ο οποίος με τη σειρά του συνδέεται με έναν ή περισσότερους ελεγκτές [53], ώστε οι απαιτούμενες αποφάσεις να διενεργούνται σε πολύ μικρό χρονικό διάστημα και αυτόματα.

Από τα παραπάνω διαφαίνονται κάποιοι από τους λόγους που έχουν οδηγήσει στην ευρεία χρήση των συγκεκριμένων δικτύων, καθώς ο διαχωρισμός του ελέγχου και της δρομολόγησης των δεδομένων, σε συνδυασμό με τον προγραμματιζόμενο χαρακτήρα του και τη δυνατότητα να αναπτυχθεί οποιοδήποτε λογισμικό στο δίκτυο [54], έχουν συντελέσει ώστε τα Software – Defined δίκτυα να προτιμώνται

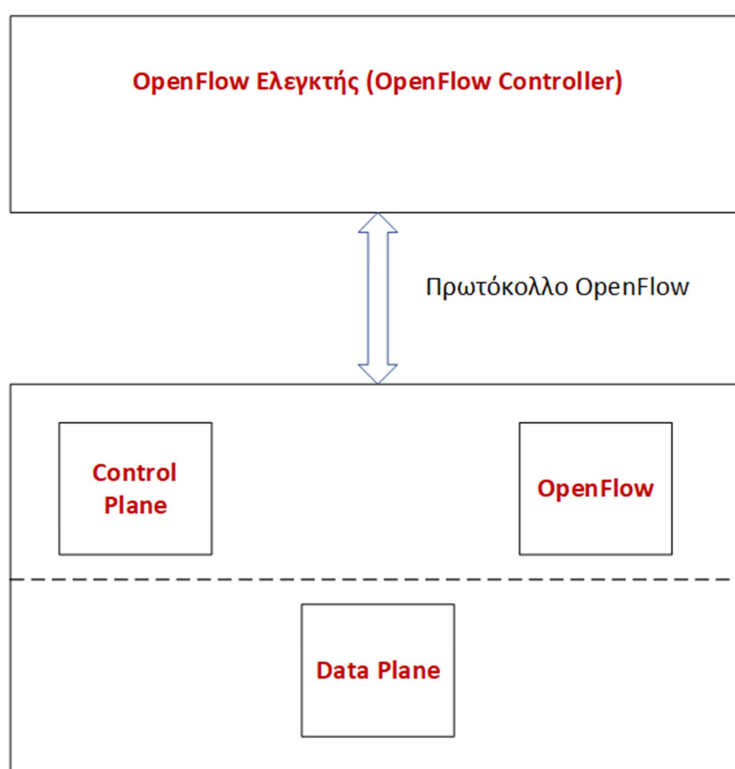
έναντι των αποκεντρωμένων δικτύων. Επιπρόσθετα των ανωτέρω, η συγκεκριμένη αρχιτεκτονική των SDON οπτικών δικτύων έχει και κάποια επιπλέον πλεονεκτήματα έναντι των αποκεντρωμένων δικτύων. Η αναβάθμιση και επέκταση των δικτύων αυτών μπορεί να υλοποιηθεί πιο γρήγορα και εύκολα, ενώ μπορεί να επιτευχθεί αυξημένη διαθεσιμότητα και αυξημένη ανίχνευση σφαλμάτων που οδηγεί με τη σειρά της σε αποδοτικότερη λειτουργία των δικτύων [57]. Ακόμη, ο διαχωρισμός των control και data plane έχει μεγιστοποιήσει τον ρυθμό μεταφοράς πακέτων μέσω του δικτύου, αφού η σύγκρουση των πακέτων μπορεί να μειωθεί αισθητά [57]. Εκτός των άλλων, μέσω των SDON οπτικών δικτύων επιτυγχάνεται καλύτερη χρήση των πόρων του δικτύου, δηλαδή τόσο των συσκευών του όσο και των διασυνδέσεων μεταξύ των συσκευών του, και υπάρχει μείωση της απαιτούμενης ενέργειας για τη λειτουργία του δικτύου, αφού μέσω του κεντρικού ελέγχου μπορεί να γίνει καλύτερη διαχείριση της χρήσης της ενέργειας [57].

4.3 OpenFlow Πρωτόκολλο

Το OpenFlow πρωτόκολλο χρησιμοποιεί μια διεπαφή προγραμματισμού εφαρμογών (Application Plane Interface), ώστε να είναι σε θέση να εγκαθιδρύσει και να φέρει εις πέρας επικοινωνία μεταξύ ενός υπολογιστή, ο οποίος ανήκει στο control plane, και ενός στοιχείου του δικτύου, όπως για παράδειγμα ενός router ή switch, το οποίο ανήκει στο data plane [58]. Το API αποτελεί το σύνολο των διαδικασιών και των τρόπων που παρέχει ένα λειτουργικό σύστημα ή μια εφαρμογή, ώστε να επιτρέπεται η ανταλλαγή δεδομένων με άλλα προγράμματα [58]. Για παράδειγμα, όταν χρειάζεται να δημιουργηθούν κάποια εικονικά μονοπάτια ή να δημιουργηθεί ένα εικονικό switch, το οποίο να λειτουργεί όπως και τα φυσικά switch, τότε χρησιμοποιείται το OpenFlow πρωτόκολλο. Μέσω του πρωτοκόλλου δημιουργούνται οι κανόνες προώθησης των πακέτων από τον υπολογιστή προς μια πόρτα του switch και αυτό στην συνέχεια προωθεί τα πακέτα προς όλες τις πόρτες του, συνδέοντας με τον τρόπο αυτό συσκευές και χρήστες γρήγορα και αξιόπιστα [58]. Ο τρόπος με τον οποίο επιτυγχάνεται η επικοινωνία και η ανταλλαγή πληροφοριών είναι ο ακόλουθος: ο υπολογιστής αρχικά στέλνει

κάποια ερωτήματα στο στοιχείο του δικτύου με το οποίο θέλει να επικοινωνήσει, το στοιχείο του απαντάει και στη συνέχεια ο υπολογιστής στέλνει μηνύματα που περιέχουν ρυθμίσεις ή αλλαγές σε παραμέτρους του δικτύου.

Βασική επιδίωξη του OpenFlow πρωτοκόλλου είναι ο έλεγχος ενός SDON δικτύου μέσω ενός ασφαλούς καναλιού επικοινωνίας μεταξύ του control plane και των συσκευών του δικτύου [54], [55]. Κύριο χαρακτηριστικό του αποτελεί το γεγονός ότι είναι ένα open πρωτόκολλο, δηλαδή ένα πρωτόκολλο που μπορεί να χρησιμοποιηθεί σε όλα τα συστήματα και δίκτυα, χωρίς ιδιαίτερες απαιτήσεις σε επίπεδο εξοπλισμού [53], καθιστώντας το ένα από τα πιο διαδεδομένα εργαλεία διαχείρισης οπτικών δικτύων.



Εικόνα 3 - OpenFlow Αρχιτεκτονική

Βασικά στοιχεία στην αρχιτεκτονική OpenFlow, όπως απεικονίζονται και στην *Εικόνα 3*, αποτελούν ο ελεγκτής OpenFlow και οι συσκευές του δικτύου [45]. Μέσω των στοιχείων αυτών μπορεί να υλοποιηθεί ο διαχωρισμός των data και control planes,. Μέσω του OpenFlow είναι εφικτός ο προγραμματισμός ολοκλήρου του data plane και η δημιουργία εικονικών δικτύων (virtual networks), όπου το καθένα

χρησιμοποιεί τα δικά του πρωτόκολλα δικτύου, ώστε να μπορέσει να λειτουργήσει αποδοτικά και σε συνεργασία με τα υπόλοιπα την ίδια στιγμή.

Βασική λειτουργία του πρωτοκόλλου OpenFlow είναι η όσο το δυνατόν καλύτερη και αυτοματοποιημένη επικοινωνία μεταξύ των υπολογιστών που υπάρχουν στο δίκτυο, καθώς και των συσκευών του δικτύου [45]. Για να εκτελεστεί αυτό το πρωτόκολλο, κάθε συσκευή του δικτύου περιέχει κάποιους πίνακες στους οποίους αποθηκεύει πληροφορίες σχετικά με τα δεδομένα, όπως τη διάρκεια, τον προορισμό και την αφετηρία τους, και ενημερώνει τους πίνακες αυτούς αναλόγως της κίνησης. Επιπλέον, το πρωτόκολλο είναι αρμόδιο να ενημερώνει το λειτουργικό σύστημα για κάθε αλλαγή που συμβαίνει στους πίνακες αυτούς, επιτρέποντας έτσι να γίνεται άμεση και αποτελεσματική διαχείριση των δεδομένων, πολλές φορές πριν ακόμα φτάσει σε σημείο το δίκτυο να μην μπορεί να εξυπηρετήσει όλο τον όγκο πληροφορίας που έχει να διαχειριστεί.

5. Μηχανική Μάθηση

5.1 Βασικές Αρχές Μηχανικής Μάθησης

Η πρώτη αναφορά σχετικά με τη μηχανική μάθηση γίνεται από τον διάσημο μαθηματικό Alan Turing το 1948, διερευνώντας με ποιους τρόπους είναι εφικτό οι υπολογιστικές μηχανές να επιδείξουν μια έξυπνη και αυτόνομη συμπεριφορά [59]. Στη συνέχεια, το 1959 ο Arthur Samuel δίνει έναν πρώτο ορισμό για την έννοια της μηχανικής μάθησης, προσδιορίζοντάς την ως την ικανότητα των υπολογιστών να μαθαίνουν μέσα από διαδικασίες για τις οποίες δεν έχουν προγραμματιστεί ρητά [60]. Ακολούθως, ο Mitchell το 1983 προτείνει έναν ορισμό σχετικά με τη Μηχανική Μάθηση πιο τυποποιημένο και μαθηματικό, σύμφωνα με τον οποίο ένα πρόγραμμα κάποιου υπολογιστή μαθαίνει από μια εμπειρία E ως προς μια κλάση εργασιών και ένα μέτρο επίδοσης P , μόνο αν η επίδοση του σε εργασίες της κλάσης T βελτιώνεται με την εμπειρία E , όπως αυτή αποτιμάται από το μέτρο P [61].

Παρατηρούμε δηλαδή ότι βασική αρχή της μηχανικής μάθησης αποτελεί η ικανότητα των αλγορίθμων να προβλέψουν κάποιες καταστάσεις ή να κάνουν κάποιες επιλογές βάσει των δεδομένων που δέχονται ως είσοδο. Τα δεδομένα εισόδου, λοιπόν, αξιοποιούνται ώστε ο αλγόριθμος να εκπαιδευτεί με έναν αυτόνομο τρόπο και να φτάσει σε κάποια συμπεράσματα σχετικά με αυτά, είτε με τη μορφή προβλέψεων είτε με τη μορφή αποφάσεων. Σημαντικό στοιχείο αποτελεί επίσης και ο όγκος πληροφορίας που χρησιμοποιείται. Όσο μεγαλύτερος είναι ο όγκος πληροφορίας, τόσο καλύτερα εκπαιδεύεται ο αλγόριθμος και προσφέρει ακριβέστερα αποτελέσματα.

Ιδιαίτερα στη σημερινή εποχή όπου τα δεδομένα που παράγονται αυξάνονται καθημερινά [62], η διαχείριση, ανάλυση και εξαγωγή συμπερασμάτων για τα δεδομένα αυτά από τον ίδιο τον άνθρωπο αποτελεί μια διαδικασία που είναι ανέφικτη τόσο από άποψη χρόνου όσο και πόρων. Η χρήση των υπολογιστών και της μηχανικής μάθησης πιο συγκεκριμένα, βοηθά στον τομέα αυτό, ώστε οι πληροφορίες που απαιτούνται να εξαχθούν από τα δεδομένα εισόδου να είναι διαθέσιμες όσο το δυνατόν πιο γρήγορα και αξιόπιστα.

Όπως είναι αναμενόμενο υπάρχουν περιορισμοί κατά τη χρήση της μηχανικής μάθησης αλλά και προκλήσεις ώστε να επιτευχθούν τα καλύτερα δυνατά αποτελέσματα. Κάποιοι από τους περιορισμούς είναι η διάρκεια που απαιτείται για την εκπαίδευση ενός αλγόριθμου μηχανικής μάθησης. Πολλές φορές η διάρκεια εκπαίδευσης μπορεί να κυμανθεί από μερικές ημέρες έως και μερικές εβδομάδες χωρίς να υπάρξουν τα επιθυμητά αποτελέσματα, κάνοντας τη διαδικασία ενός νέου υπολογισμού με διαφορετικές παραμέτρους ιδιαίτερα χρονοβόρα. Επιπλέον, απαιτείται αρκετή υπολογιστική ισχύς, κάτι που συνεπάγεται και αυξημένο κόστος στην προμήθεια υλικών που θα καταστήσουν έναν υπολογιστή ικανό για γρήγορους υπολογισμούς [63]. Κάποιες από τις προκλήσεις που αντιμετωπίζει η μηχανική μάθηση αποτελούν το overfitting και underfitting των δεδομένων εκπαίδευσης. Overfitting ονομάζεται το φαινόμενο κατά το οποίο στα δεδομένα εκπαίδευσης του αλγόριθμου εισέρχεται και θόρυβος, αφού στην προσπάθεια επίτευξης της βέλτιστης πρόβλεψης, πολλές φορές τοποθετούνται πολλά δεδομένα, άκριτα και μέσα σε αυτά υπάρχει και θόρυβος [64]. Πρακτικά, το κατά πόσο ο αλγόριθμος, δηλαδή προσαρμόζεται επαρκώς στα δεδομένα εισόδου, όπως επίσης και η επαρκής ποσότητα και ποιότητα των δεδομένων εισόδου αποτελούν στοιχεία μέσα από τα οποία μπορούμε να διακρίνουμε αν υπάρχει overfitting στον αλγόριθμο. Underfitting ονομάζεται το φαινόμενο κατά το οποίο ο αλγόριθμος μηχανικής μάθησης δεν είναι σε θέση να διακρίνει τις συσχετίσεις που έχουν τα δεδομένα μεταξύ τους, έχοντας ως επακόλουθο τη δημιουργία μεγάλου ρυθμού σφαλμάτων. Αυτό επηρεάζει τα αποτελέσματα που παράγει ο αλγόριθμος, αφού δεδομένα που δεν παρουσιάζουν συσχετίσεις μεταξύ τους είναι αρκετά δύσκολο να οδηγήσουν σε ασφαλή συμπεράσματα [65].

5.2 Τεχνικές Μηχανικής Μάθησης

Οι τεχνικές και οι αλγόριθμοι μηχανικής μάθησης που έχουν αναπτυχθεί είναι πάρα πολλοί και καλύπτουν μεγάλο εύρος των δραστηριοτήτων. Στον Πίνακα 2 που ακολουθεί παρουσιάζονται μερικοί αλγόριθμοι μηχανικής μάθησης που είναι διαθέσιμοι στη βιβλιογραφία. Πρέπει να τονιστεί ότι οι συγκεκριμένοι αλγόριθμοι

δεν αντιπροσωπεύουν το σύνολο των διαθέσιμων αλγορίθμων, αλλά είναι αυτοί οι οποίοι έχουν χρησιμοποιηθεί εκτεταμένα, ιδιαίτερα στον τομέα των δικτύων υπολογιστών και των οπτικών δικτύων.

Τύπος Αλγορίθμου Μηχανικής Μάθησης	Αλγόριθμος Μηχανικής Μάθησης
Clustering	kMeans Clustering [1]
	Hierarchical Clustering [1]
	miniBatch Clustering [31]
	Density-based spatial clustering of applications with noise (DBSCAN)[1]
Instance Based	k-Nearest Neighbour (kNN) [67]
	Self-Organizing Map (SOM) [67]
	kTree Nearest Neighbour [68]
	Fuzzy kNN [69]
Dimensionality Reduction	Principal Component Analysis (PCA) [70]
	Auto Encoder (AE) [70]
Decision Tree	Very Fast Decision Tree (VFDT) [71]
	Adaptive Random Forest (ARF) [71]
Bayesian	Naïve Bayes [67]
	Selective Naïve Bayes [72]
	Tree Augmented Naïve Bayes [72]
	Bayesian network [73]
Regression	Logistic Regression [73]
	Linear Regression [73]
Ensemble	Boosting [67]
	AdaBoost [67]
	Bootstrapped Aggregation [67]
Neural Network	Perceptron [74]
	Multi-layer Perceptron [71]
	Artificial Neural Network (ANN) [73]

Deep Learning	Convolutional Neural Network (CNN) [74]
	Recurrent Neural Network (RNN) [73]
	Deep Neural Network (DNN) [73]

Πίνακας 2 - Αλγόριθμοι Μηχανικής Μάθησης

Οι αλγόριθμοι μηχανικής μάθησης σε σχέση με τον τρόπο που εκπαιδεύονται μπορούν να χωριστούν σε τέσσερις μεγάλες κατηγορίες:

- Εποπτευόμενοι (supervised) αλγόριθμοι,
- Μη εποπτευόμενοι (unsupervised) αλγόριθμοι,
- Ημι-εποπτευόμενοι (semi-supervised) αλγόριθμοι και
- Ενισχυτική μάθηση (reinforcement learning) [8].

Βασικό χαρακτηριστικό των εποπτευόμενων αλγορίθμων μηχανικής μάθησης αποτελεί το γεγονός ότι χρησιμοποιούν δεδομένα για τα οποία ο χρήστης έχει κάνει μια αρχική κατηγοριοποίηση, ώστε να μπορέσουν να προβλέψουν μια ή και περισσότερες μεταβλητές εξόδου, όπως για παράδειγμα το μέγεθος του επόμενου πακέτου προς αποστολή ή την τιμή στο urgent bit του επόμενου πακέτου προς αποστολή, ανεξάρτητα αν οι μεταβλητές εξόδου έχουν συνεχείς ή διακριτές τιμές [8].

Κάθε μονάδα δεδομένων δηλαδή, περιέχει τιμές για όλα τα χαρακτηριστικά εισόδου του, και μετά από τον υπολογισμό μιας συνάρτησης ο αλγόριθμος υπολογίζει την τιμή στο χαρακτηριστικό εξόδου του. Τα συνηθέστερα προβλήματα που επιλύονται με τη χρήση εποπτευόμενης μάθησης είναι η ταξινόμηση (classification) και οπισθοδρόμηση (regression) [75]. Στην πρώτη περίπτωση ο αλγόριθμος προσπαθεί να προβλέψει σε ποια κατηγορία δεδομένων ανήκει κάθε νέα είσοδος. Οι κατηγορίες όπως αναφέρθηκε ήδη μπορεί να είναι είτε δύο είτε και περισσότερες. Στη δεύτερη κατηγορία ο αλγόριθμος προσπαθεί να προβλέψει την έξοδο αρκεί όμως οι τιμές εισόδου να είναι συνεχείς και όχι διακριτές. Χρησιμοποιείται κυρίως σε προβλέψεις όπου υπάρχει χρονική αλληλουχία γεγονότων, όπως για παράδειγμα η πρόβλεψη καιρικών συνθηκών.

Οι μη εποπτευόμενοι αλγόριθμοι σε αντίθεση με τους εποπτευόμενους αλγόριθμους, χρησιμοποιούν δεδομένα χωρίς ετικέτα χρήστη, ώστε να είναι σε θέση να βρουν ένα μοτίβο στα δεδομένα αυτά [70]. Οι συγκεκριμένοι αλγόριθμοι, δηλαδή, προσπαθούν να κάνουν μια ομαδοποίηση στα δεδομένα που δέχονται με βάση κάποια κοινά χαρακτηριστικά ή κάποια ομοιότητα που μπορεί να έχουν μεταξύ τους. Τα συνηθέστερα προβλήματα τα οποία επιλύονται με τους συγκεκριμένους αλγορίθμους είναι η ομαδοποίηση (clustering) και συσχέτιση (association) [75]. Στην πρώτη περίπτωση, τα δεδομένα ομαδοποιούνται με τέτοιο τρόπο ώστε όσα ανήκουν στην ίδια ομάδα να είναι πιο όμοια μεταξύ τους, συγκριτικά με τα δεδομένα από άλλες ομάδες. Στη δεύτερη περίπτωση, ο αλγόριθμος προσπαθεί να εντοπίσει κάποια συσχέτιση μεταξύ των χαρακτηριστικών των δεδομένων. Η δεύτερη κατηγορία μπορεί να χρησιμοποιηθεί κυρίως για συσχετίσεις μεταξύ ηλικιακών ομάδων, προτιμήσεων αγορών κ.α. Όταν τα δεδομένα που είναι διαθέσιμα δεν περιέχουν όλα ετικέτες από τον χρήστη, αλλά αποτελούν ένα σύνολο δεδομένων με ετικέτες και δεδομένων χωρίς ετικέτες, τότε χρησιμοποιούνται οι ημι-εποπτευόμενοι αλγόριθμοι [8]. Οι εν λόγω αλγόριθμοι χρησιμοποιούνται για ίδιου τύπου προβλήματα με τους εποπτευόμενους αλγορίθμους, δηλαδή προβλήματα ταξινόμησης και οπισθοδρόμησης, με τη διαφορά ότι προτιμώνται όταν τα δεδομένα δεν είναι εύκολα προσβάσιμα και χωρίς ετικέτες στο σύνολο τους. Τα δεδομένα που περιέχουν ετικέτες χρησιμοποιούνται ώστε να δημιουργηθούν οι κατηγορίες δεδομένων και να ενταχθούν όλα τα δεδομένα σε κάποια κατηγορία, ενώ τα δεδομένα χωρίς ετικέτα χρησιμοποιούνται για να υπολογιστούν τα όρια που υπάρχουν μεταξύ των κατηγοριών [65]. Οι ημι-εποπτευόμενοι είναι αλγόριθμοι μηχανικής μάθησης που έχουν στοιχεία τόσο από τους εποπτευόμενους όσο και από τους μη εποπτευόμενους αλγορίθμους. Βασικό στοιχείο των συγκεκριμένων αλγορίθμων είναι ότι τα δεδομένα που χρησιμοποιούν δεν έχουν κατηγοριοποιηθεί όλα, όπως στους εποπτευόμενους αλγορίθμους, ούτε όμως είναι όλα χωρίς ετικέτα χρήστη, όπως στους μη εποπτευόμενους. Στους αλγορίθμους αυτούς κάποια από τα δεδομένα έχουν κατηγοριοποιηθεί και στη συνέχεια χρησιμοποιούνται στη διαδικασία της εκμάθησης, ώστε να επιτευχθεί καλύτερη ομαδοποίηση των δεδομένων χωρίς ετικέτες, σε σχέση με τους μη εποπτευόμενους αλγορίθμους [11].

Με τον τρόπο αυτό, επιτυγχάνεται αύξηση της ταχύτητας και της ακρίβειας της μάθησης [35], την ίδια στιγμή όμως υπάρχει ο κίνδυνος αν στα αρχικά κατηγοριοποιημένα δεδομένα υπάρχουν σφάλματα αυτά να επηρεάσουν μεγάλο όγκο δεδομένων στη συνέχεια της διαδικασίας [35].

Στην ενισχυτική μάθηση οι αλγόριθμοι είναι σε θέση να μάθουν μια πολιτική επιβράβευσης, όπου κάθε φορά που ο αλγόριθμος καταλήγει σε επιθυμητό αποτέλεσμα, επιβραβεύει τον εαυτό του, ενώ σε αντίθετη περίπτωση υπάρχει κάποιου είδους ποινής [70]. Με τον τρόπο αυτό, ο αλγόριθμος πρέπει αυτόνομα να κατανοήσει ποια στρατηγική είναι η καλύτερη για τον ίδιο, δηλαδή ποια αλληλουχία βημάτων του αποφέρει τις μεγαλύτερες επιβραβεύσεις. Οι συγκεκριμένοι αλγόριθμοι χρησιμοποιούνται κυρίως στη ρομποτική, καθώς και στη δημιουργία συστημάτων εκπαίδευσης τα οποία παρέχουν εκπαιδευτικό υλικό αναλόγως των επιδόσεων των μαθητών.

Τα νευρωνικά δίκτυα, ανήκουν στους εποπτευόμενους αλγορίθμους μηχανικής μάθησης, και χρησιμοποιούνται κυρίως σε ιδιαίτερα πολύπλοκα προβλήματα, όπως για παράδειγμα σε ιατρικά ζητήματα εύρεσης γενετικών ακολουθιών [76]. Βασικό πλεονέκτημά τους αποτελεί η ικανότητα για διαχείριση μεγάλου όγκου πληροφορίας, με ικανοποιητική ανοχή σε σφάλματα και θόρυβο, ενώ βασικό μειονέκτημά τους αποτελεί η απαίτηση για μεγάλη υπολογιστική ισχύ [73]. Δομικό στοιχείο των νευρωνικών δικτύων αποτελεί ο νευρώνας ή *perceptron*, ο οποίος έχει σχεδιαστεί για να μιμείται τον τρόπο λειτουργίας του ανθρώπινου εγκεφάλου στις λειτουργίες διαχείρισης και εκμάθησης πληροφορίας [77]. Βασικά στοιχεία ενός νευρωνικού δικτύου, εκτός του νευρώνα, είναι η συνάρτηση ενεργοποίησης των νευρώνων, η οποία ουσιαστικά καθορίζει τον τρόπο με τον οποίο υπολογίζεται η έξοδος στους νευρώνες, το πλήθος των νευρώνων στο επίπεδο εισόδου, το πλήθος των νευρώνων στο επίπεδο εξόδου και η συνάρτηση κόστους, η οποία αποδίδει κάποιες τιμές στους νευρώνες εισόδου, ώστε να υπολογιστεί στη συνέχεια η έξοδος τους [78].

Τέλος οι αλγορίθμοι μηχανικής μάθησης βαθιάς μάθησης (*Deep Learning*) δημιουργούν νευρωνικά δίκτυα, τα οποία εκτός του επιπέδου εισόδου και εξόδου

έχουν και ενδιάμεσα επίπεδα, που ονομάζονται κρυφά επίπεδα [79]. Οι νευρώνες που αποτελούν τα κρυφά επίπεδα έχουν τα ίδια χαρακτηριστικά με τους νευρώνες των επιπέδων εισόδου και εξόδου, δηλαδή έχουν συνάρτηση ενεργοποίησης και κόστους. Η έξοδος από κάθε νευρώνα κρυφού επιπέδου οδηγείται ως είσοδος σε όλους τους νευρώνες του επόμενου κρυφού επιπέδου ή επιπέδου εξόδου αν είναι το τελευταίο επίπεδο [79]. Με τον τρόπο αυτό επιτυγχάνεται αύξηση της υπολογιστικής δυνατότητας του αλγορίθμου και επίτευξη καλύτερων αποτελεσμάτων [73].

5.3 Εργαλεία Μηχανικής Μάθησης

Στον τομέα της μηχανικής μάθησης υπάρχει πληθώρα εργαλείων τα οποία μπορεί ο χρήστης να χρησιμοποιήσει ώστε να υλοποιήσει κάποιον από τους διαθέσιμους αλγορίθμους. Τα εργαλεία αυτά μπορούν να ταξινομηθούν αναλόγως του τρόπου με τον οποίο χρησιμοποιούνται και των αποτελεσμάτων που παράγονται. Στο επίπεδο του προγραμματισμού, τα διαθέσιμα εργαλεία μπορούν να χωριστούν περαιτέρω σε δύο υποκατηγορίες, αναλόγως με το αν υπάρχει κάποιο διαθέσιμο λογισμικό αυτοματοποιημένης διαδικασίας μηχανικής μάθησης ή αν υπάρχει διαθέσιμο κάποιο έτοιμο πακέτο συναρτήσεων σε διάφορες γλώσσες προγραμματισμού.

Κάποια από τα διαθέσιμα εργαλεία μηχανικής μάθησης είναι τα κάτωθι:

- Εργαλεία αναζήτησης,
- Εργαλεία προβολής,
- Εργαλεία εξαγωγής δεδομένων και
- Εργαλεία σύνθεσης [80].

Τα εργαλεία της μηχανικής μάθησης που αφορούν την αναζήτηση έχουν αναπτυχθεί με διπλό σκοπό. Αφενός να πραγματοποιείται ένα φιλτράρισμα των κειμένων προς αναζήτηση όσο το δυνατόν πιο γρήγορα και αφετέρου να παρουσιάζονται σχετικά δημοσιεύματα και άρθρα αναλόγως της αναζήτησης που

έχει πραγματοποιηθεί, ώστε ο κάθε χρήστης να μπορεί άμεσα και χωρίς νέα αναζήτηση να εντοπίζει θέματα παρόμοιου ενδιαφέροντος.

Τα εργαλεία προβολής συνεισφέρουν στην καλύτερη και ακριβέστερη πρόταση σε κάθε χρήστη στοιχείων που είναι στον τομέα ενδιαφερόντων του. Τα εργαλεία αυτά, μέσω των δεδομένων αναζήτησης τα οποία ανανεώνονται συνεχώς, δίνουν τη δυνατότητα στους διαχειριστές των συστημάτων να εξετάσουν κάποιο μικρό δείγμα των δεδομένων αυτών και στη συνέχεια οι αλγόριθμοι μηχανικής μάθησης να προβάλλουν τα πιο σχετικά από αυτά.

Στην εξαγωγή δεδομένων τα εργαλεία που έχουν αναπτυχθεί είναι σε θέση μέσα από μεγάλο όγκο δεδομένων να εντοπίσουν τα στοιχεία αυτά που διαθέτουν τα χαρακτηριστικά που επιθυμεί ο χρήστης. Για να μπορέσουν τα συγκεκριμένα εργαλεία να συνεισφέρουν ουσιαστικά, πρέπει να υπάρχει συνεχής εκπαίδευση όσον αφορά τον αλγόριθμο και τα δεδομένα.

Τέλος, τα εργαλεία σύνθεσης έχουν τη δυνατότητα να δέχονται δεδομένα από διαφορετικές πηγές και να εξάγουν χρήσιμα συμπεράσματα από αυτά, να συνθέτουν δηλαδή συμπεράσματα μέσα από πολλαπλές πηγές δεδομένων.

Σε προγραμματιστικό επίπεδο, αλγόριθμοι μηχανικής μάθησης έχουν αναπτυχθεί σε πληθώρα γλωσσών προγραμματισμού. Η πλειοψηφία, όπως θα τονιστεί και στη συνέχεια, αφορά πακέτα στις γλώσσες προγραμματισμού Python και R. Τα τελευταία χρόνια όλο και περισσότερες εταιρείες έχουν προσπαθήσει να δημιουργήσουν πλατφόρμες και εργαλεία που διαθέτουν αυτοματοποιημένες διαδικασίες και αλγορίθμους Μηχανικής Μάθησης [81]. Στον Πίνακα 3 που ακολουθεί θα παρουσιαστούν μερικά τέτοια εργαλεία καθώς και η πλατφόρμα στην οποία υλοποιούνται, όπου αυτή είναι διαθέσιμη.

Εργαλείο	Πλατφόρμα
Auto-Weka [82]	
Auto-keras [83]	
Google AutoML [84]	Google Cloud
Azure ML [85]	Azure

H2O-Driveless AI [86]	AWS, Azure
DataRobot [87]	AWS, Azure
Auto-sklearn [88]	
TransmogriAI [89]	Apache Spark

Πίνακας 3 - Αυτόματα Εργαλεία Μηχανικής Μάθησης

Σχετικά με τα διαθέσιμα πακέτα σε γλώσσες προγραμματισμού θα γίνει μια σύντομη αναφορά κάποιων δημοφιλών πακέτων μηχανικής μάθησης, όπως επίσης και της γλώσσας προγραμματισμού που αυτά έχουν υλοποιηθεί στον Πίνακα 4 που ακολουθεί.

Εργαλείο	Γλώσσα Προγραμματισμού
TensorFlow [63]	Python, C++
Keras [63]	Python
Theano [90]	Python
Numpy [91]	Python
Pandas [93]	Python
Scikit-learn [91]	Python
Alibi [93]	Python
XGBoost [94]	Python, R, Java
Anchor [95]	Python, R, Java
Smile [96]	Java

Πίνακας 4 - Εργαλεία Μηχανικής Μάθησης ανά Γλώσσα Προγραμματισμού

Αξίζει να σημειωθεί ότι έχει δοθεί ιδιαίτερη έμφαση στην ανάπτυξη εργαλείων ειδικά σχεδιασμένων για το αντικείμενο για το οποίο προορίζονται να αναπτυχθούν, ώστε το εργαλείο αυτό να είναι πλήρως προσαρμοσμένο στις ανάγκες της εκάστοτε περίπτωσης και να έχει την καλύτερη δυνατή απόδοση, όπως για παράδειγμα εργαλεία τα οποία έχουν σχεδιαστεί για έρευνα στον τομέα της Βιολογίας και της Ιατρικής [97].

5.4 Deep Learning και Artificial Intelligence

Ως τεχνητή νοημοσύνη (Artificial Intelligence) ορίζεται ο τομέας της επιστήμης, όπως επίσης και η μεθοδολογία που ακολουθείται, ώστε να δημιουργηθούν μηχανές με νοημοσύνη [98]. Βασικός στόχος της τεχνητής νοημοσύνης στον τομέα της επιστήμης των υπολογιστών και κατ' επέκταση των δικτύων είναι οι υπολογιστές να είναι σε θέση να σκεφτονται και να πράττουν με τον τρόπο που το κάνουν οι άνθρωποι, δηλαδή να διαθέτουν κάποιου είδους ευφυΐα, προσαρμοστικότητα, να εξαγάγουν συμπεράσματα και να επιλύουν προβλήματα.

Η τεχνητή νοημοσύνη μπορεί να διακριθεί σε δύο μεγάλες υποκατηγορίες. Στην κλασική και την υπολογιστική [63.] Στην πρώτη περίπτωση γίνεται χρήση συμβόλων όπως επίσης και κανόνων υψηλού επιπέδου, κανόνων δηλαδή που προσομοιώνουν καλύτερα τον ανθρώπινο τρόπο έκφρασης και έχουν δυνατότητα εκτέλεσης σε οποιοδήποτε υπολογιστή, ώστε να κατανοηθεί όσο το δυνατόν καλύτερα η ανθρώπινη νοημοσύνη και να εξομοιωθεί με αλγορίθμους. Στη δεύτερη περίπτωση γίνεται χρήση αριθμητικών μοντέλων τα οποία κάνουν προσομοίωση κάποιων πραγματικών βιολογικών διαδικασιών, ώστε να επιτευχθεί η μίμηση του ανθρώπινου εγκεφάλου. Στο σημείο αυτό πρέπει να σημειωθεί ότι η μηχανική μάθηση που αναφέρθηκε στο προηγούμενο κεφάλαιο αποτελεί τομέα της τεχνητής νοημοσύνης [65] και μάλιστα έναν από τους ανεπτυγμένους τομείς της.

Η βαθειά μάθηση (Deep Learning) αποτελεί την υποκατηγορία της Μηχανικής Μάθησης που χρησιμοποιεί νευρωνικά δίκτυα για την υλοποίηση των αλγορίθμων και την επίλυση των προβλημάτων [65]. Ουσιαστικά αποτελεί την εξέλιξη της μηχανικής μάθησης σε ζητήματα που απαιτείται μεγάλος χρόνος υπολογισμού και δεν επιθυμούμε την εμπλοκή του ανθρώπινου παράγοντα [60]. Στη βαθειά μάθηση δε συζητάμε για αλγορίθμους αλλά για αρχιτεκτονικές, αφού δομικό στοιχείο της αποτελεί ο νευρώνας και ο τρόπος με τον οποίο συνδέονται μεταξύ τους οι νευρώνες που αποτελούν τα νευρωνικά δίκτυα.

Οι σημαντικότερες αρχιτεκτονικές, όπως αναφέρθηκαν και στον Πίνακα 2, είναι τα Deep Neural Networks τα συνελκτικά νευρωνικά δίκτυα (Convolutional Neural Networks) και τα επαναλαμβανόμενα νευρωνικά δίκτυα (Recurrent Neural Networks). Τα Deep Neural Networks αποτελούνται από αριθμό κρυφών επιπέδων νευρώνων [73]. Τα κρυφά επίπεδα αυτά μπορεί να είναι από ένα έως αρκετά μεγάλος αριθμός. Υπάρχει, ακόμα, ένα επίπεδο εισόδου και ένα επίπεδο εξόδου. Σε κάθε επίπεδο υπάρχει κάποιος αριθμός από νευρώνες που δεν είναι συγκεκριμένος αλλά εξαρτάται από τις ρυθμίσεις που θα γίνουν, ενώ στην πλειοψηφία των περιπτώσεων κάθε επίπεδο επικοινωνεί μόνο με το επόμενο και δεν υπάρχει δυνατότητα να επικοινωνήσει με το προηγούμενο [73]. Τα Convolutional Neural Networks είναι κατηγορία Deep Neural Network με όλα τα χαρακτηριστικά που αναφέρθηκαν για αυτά προηγουμένως [74]. Βασική τους επιδίωξη αποτελεί η αναγνώριση σχημάτων δύο διαστάσεων, με μεγάλο πλεονέκτημά τους την πολύ καλή ανοχή στην παραμόρφωση των δεδομένων [65]. Το χαρακτηριστικό το οποίο διαφέρει στα Recurrent Neural Networks σε σχέση με τα Deep Neural Networks είναι ο τρόπος με τον οποίο ενεργούν οι νευρώνες, όπου σε αυτή την περίπτωση ενεργούν χρονικά, δηλαδή για κάθε χρονική στιγμή που υπάρχει έξοδος, αυτή η χρονική στιγμή θεωρείται και είσοδος στην επόμενη κατάστασή τους [65].

6. Μηχανική Μάθηση σε Δίκτυα

6.1 Προβλήματα Δικτύων που Επιλύονται με Μηχανική Μάθηση

Η ευρεία χρήση και ο αρκετά μεγάλος αριθμός συσκευών, πρωτοκόλλων και εφαρμογών που χρησιμοποιούνται στα δίκτυα [9], δημιουργεί και πολλά προβλήματα. Η μηχανική μάθηση αποτελεί έναν από τους καλύτερους τρόπους με τον οποίο τα προβλήματα αυτά μπορούν να απαλειφθούν. Ακολούθως θα αναφερθούν κάποια από τα προβλήματα που αντιμετωπίζουν τα δίκτυα και είναι σε θέση να επιλυθούν με τη χρήση τεχνικών μηχανικής μάθησης.

Σε πολλές περιπτώσεις η απόκριση του δικτύου δεν είναι η αναμενόμενη όσον αφορά την ταχύτητα μεταφοράς δεδομένων, καθώς οι αλλαγές που γίνονται στα δίκτυα, τόσο σε επίπεδο όγκου μεταδιδόμενης πληροφορίας όσο και σε επίπεδο πολλές φορές διαθέσιμου υλικού και υπηρεσιών, είναι συνεχόμενες, κάτι που απαιτεί από το δίκτυο να είναι σε θέση να παρακολουθεί τις αλλαγές αυτές και να παίρνει τις καλύτερες αποφάσεις αναλόγως της κατάστασης [9]. Επιπλέον, η πολυπλοκότητα των δικτύων όλο και μεγαλώνει, με αποτέλεσμα να υπάρχει η απαίτηση ο έλεγχος των δικτύων να είναι όσο το δυνατόν πιο αυτόνομος, γρήγορος και έξυπνος [9]. Ακόμη, σε πολλές περιπτώσεις η ποιότητα των προσφερόμενων υπηρεσιών μπορεί να διαφέρει μεταξύ επιμέρους δικτύων σε ένα σύνολο υποδικτύων [29]. Αυτό έχει ως άμεσο αποτέλεσμα τα δίκτυα να πρέπει να παρέχουν διαφορετικά επίπεδα υπηρεσιών και ποιότητας εξυπηρέτησης, κάτι που για να επιτευχθεί χρειάζεται να λειτουργεί ένας αυτοματοποιημένος μηχανισμός, όπως κάποιος αλγόριθμος μηχανικής μάθησης. Η διαχείριση των πόρων είναι ακόμα ένας τομέας που η χρήση μηχανικής μάθησης είναι αναγκαία στα δίκτυα [29]. Δεδομένου ότι σε ένα δίκτυο πρέπει να γίνει διαχείριση πολλών διαφορετικών πόρων ταυτόχρονα και με τρόπο αποδοτικό, όπως για παράδειγμα οι χρονοθυρίδες, η διαμόρφωση των πακέτων και ο τρόπος μετάδοσης πληροφοριών, η μηχανική μάθηση με τις μεθόδους που παρέχει μπορεί να βοηθήσει ουσιαστικά στον τομέα αυτό.

Αρκετά συχνό είναι και το φαινόμενο της υποβάθμισης της ποιότητας των υπηρεσιών σε ένα δίκτυο [2]. Αυτό μπορεί να οφείλεται σε λόγους, όπως η λανθασμένη χρήση του μηχανισμού ελέγχου πόρων, του μηχανισμού δηλαδή που είναι υπεύθυνος για την παρακολούθηση της σωστής λειτουργίας τόσο του υλικού εξοπλισμού του δικτύου όσο και των υπηρεσιών του. Η ταξινόμηση της κίνησης ενός δικτύου αποτελεί ένα από τα συχνά εμφανιζόμενα προβλήματα [3]. Με τη χρήση διάφορων παραμέτρων η κίνηση του δικτύου μπορεί να κατηγοριοποιηθεί, ώστε αυτή στη συνέχεια να χωριστεί σε κατάλληλες κλάσεις, οι οποίες με τη σειρά τους να δρομολογηθούν με τέτοιο τρόπο, ώστε να υπάρξει η καλύτερη δυνατή απόδοση για τους χρήστες του δικτύου. Αντίστοιχα και η ικανότητα ενός δικτύου να πραγματοποιήσει την καλύτερη δυνατή πρόβλεψη σχετικά με τη μελλοντική κίνηση που θα έχει, αποτελεί ένα πρόβλημα που μπορεί να αντιμετωπιστεί με τη χρήση της μηχανικής μάθησης [74]. Η σημασία της όσο το δυνατόν καλύτερης πρόβλεψης είναι ιδιαίτερα σημαντική, αν αναλογιστεί κάποιος ότι ένα δίκτυο που είναι σε θέση να γνωρίζει εκ των προτέρων την κίνηση θα αντιμετωπίσει στο επόμενο χρονικό διάστημα, θα είναι σε θέση να τη διαχειριστεί πολύ πιο αποδοτικά σε σχέση με κάποιο που διαχειρίζεται τη κίνηση τη στιγμή που τη δέχεται και δεν έχει προβεί σε προληπτικές ενέργειες αποτελεσματικής αντιμετώπισης του αυξημένου φόρτου.

Ένα από τα προβλήματα στο οποίο έχει δοθεί ιδιαίτερη έμφαση από πολλούς ερευνητές είναι και αυτό της κατανομής πόρων και δρομολόγησης [6]. Τα δύο αυτά προβλήματα, που στην πλειοψηφία των περιπτώσεων συχνά μελετώνται ταυτόχρονα, συναντώνται τόσο όταν στο δίκτυο υπάρχει στατική κίνηση όσο και όταν υπάρχει δυναμική κίνηση. Η στατική κίνηση δικτύου αναφέρεται στην κίνηση που δεν παρουσιάζει ιδιαίτερες αυξομειώσεις αλλά παραμένει ενός συγκεκριμένου εύρους (όπως για παράδειγμα όταν δημιουργούνται αντίγραφα ασφαλείας των ρυθμίσεων του δικτύου) [6]. Η δυναμική κίνηση αναφέρεται στις περιπτώσεις που η κίνηση του δικτύου παρουσιάζει αυξομειώσεις αναλόγως των δεδομένων που αποστέλλονται στο δίκτυο (για παράδειγμα όταν υπάρχουν πολλοί χρήστες στο δίκτυο και γίνεται συνεχόμενη ανταλλαγή δεδομένων) [6]. Στην περίπτωση της στατικής κίνησης στο δίκτυο, η εύρεση του συντομότερου μονοπατιού αποτελεί το συνηθέστερο πρόβλημα, ενώ όταν υπάρχει δυναμική κίνηση στο δίκτυο η ανάγκη

τα δεδομένα που απορρίπτονται να μειωθούν όσο το δυνατόν περισσότερο αποτελεί συνηθισμένο εμπόδιο [6]. Ένα επιπλέον πρόβλημα των δικτύων που μπορεί να αντιμετωπιστεί με τη χρήση της μηχανικής μάθησης είναι η δυνατότητα για πρόβλεψη πληροφοριών που πρόκειται να μεταδοθούν και υπάρχει πιθανότητα να εκπεμφθούν την ίδια χρονική στιγμή [100]. Ένα δίκτυο που έχει τη δυνατότητα αυτή μπορεί να προσφέρει υπηρεσίες υψηλότερου επιπέδου, με υψηλότερες ταχύτητες εξυπηρέτησης και χωρίς αισθητές απώλειες δεδομένων.

Εν κατακλείδι, κάποια από τα προβλήματα των δικτύων μπορούν να ταξινομηθούν σε δύο κατηγορίες, στα προβλήματα που αφορούν το φυσικό επίπεδο και σε αυτά που αφορούν το επίπεδο δικτύου. Στο φυσικό επίπεδο κάποια από τα προβλήματα που αντιμετωπίζει ένα δίκτυο και η μηχανική μάθηση είναι σε θέση να προσφέρει λύσεις, αποτελούν η αναγνώριση όλων των συσκευών που απαρτίζουν το δίκτυο, η αναγνώριση της διαμόρφωσης των πακέτων που αποστέλλονται στο δίκτυο, καθώς και η παρακολούθηση της απόδοσης του δικτύου [8]. Στο επίπεδο δικτύου, μερικά από τα προβλήματα στα οποία η μηχανική μάθηση μπορεί να προσφέρει λύσεις είναι ο αυτόματος σχεδιασμός εικονικών υποδικτύων, καθώς και η παραμετροποίηση τους, η αποδοτική διαχείριση των σφαλμάτων που εμφανίζονται στο δίκτυο και ο υπολογισμός του καλύτερου τρόπου μετάδοσης κάθε πακέτου [8].

6.2 Χρησιμοποιούμενες Τεχνικές Μηχανικής Μάθησης σε Δίκτυα

Τα τελευταία χρόνια έχει πραγματοποιηθεί εκτεταμένη έρευνα πάνω στον τομέα της μηχανικής μάθησης στα δίκτυα. Έχουν διερευνηθεί ποικίλα ζητήματα που αναφέρθηκαν στην προηγούμενη ενότητα, όπου για το κάθε πρόβλημα έχουν προταθεί περισσότερων της μίας τεχνικές μηχανικής μάθησης που είναι σε θέση να το επιλύσουν σε ικανοποιητικό βαθμό. Λόγω των πολυπληθών προβλημάτων και των τεχνικών για κάθε πρόβλημα, στο κεφάλαιο αυτό θα γίνει μια απλή αναφορά σε μερικές τεχνικές που έχουν χρησιμοποιηθεί ανά κατηγορία προβλήματος.

Αρχικά, θα παρουσιαστούν τεχνικές που χρησιμοποιούνται σχετικά το πρόβλημα της όσο δυνατόν καλύτερης πρόβλεψης της κίνησης του δικτύου:

Χρησιμοποιηθείς Αλγόριθμος Μηχανικής Μάθησης	Στόχος Αλγορίθμου	Βιβλιογραφικές Αναφορές
Long-Term Memory Network (Recurrent Neural Network)	Πρόβλεψη κίνησης δικτύου	[101]
Neural Network	Πρόβλεψη κίνησης δικτύου	[102],[103],[104]
Recurrent Neural Network	Πρόβλεψη κίνησης δικτύου	[105]
Reinforcement Learning	Πρόβλεψη κίνησης δικτύου	[106], [107]
Support Vector Machines	Πρόβλεψη κίνησης σε κάθε κόμβο του δικτύου	[108]

Πίνακας 5 - Αλγόριθμοι Μηχανικής Μάθησης για Πρόβλεψη Κίνησης Δικτύου

Ο Long Term Memory Network αλγόριθμος κάνει χρήση των δεδομένων σχετικά με τον χρόνο αναμονής, το εύρος ζώνης, την καθυστέρηση έναρξης εκπομπής και το ιστορικό της κίνησης του δικτύου, ώστε να προβλέψει με τον καλύτερο δυνατό τρόπο την αναμενομένη κίνηση του δικτύου [101]. Για αλγόριθμο με νευρωνικό δίκτυο αναπτύχθηκε νευρωνικό δίκτυο ενός κρυφού επιπέδου, το οποίο λαμβάνει τα δεδομένα κίνησης σε πραγματικό χρόνο, στην συνέχεια τα μοντελοποιεί, ώστε να προβλέψει την μελλοντική κίνηση του δικτύου και να ληφθούν οι απαραίτητες αποφάσεις ώστε οι πληροφορίες να μεταδίδονται όσο το δυνατόν πιο γρήγορα στον προορισμό τους [102], [103], [104]. Με τη χρήση ενός Recurrent Neural Network έγινε προσπάθεια να γίνει πρόβλεψη της κίνησης των επόμενων 30 λεπτών προκειμένου να γίνει καλύτερη κατανομή των πακέτων προς μετάδοση στα διαθέσιμα κανάλια. Αυτό επετεύχθη με τη χρήση των δεδομένων που αφορούν τη διαμόρφωση του δικτύου σε επίπεδο router και δρομολόγησης μεταξύ των router, τόσο σε πραγματικό χρόνο όσο και δεδομένων που αφορούν προηγούμενες

χρονικές στιγμές, με στόχο να υπάρχουν αρκετά δεδομένα που θα δοθούν ως είσοδος στον αλγόριθμο [105]. Ο αλγόριθμος Reinforcement Learning δημιουργεί έναν πίνακα στον οποίο τοποθετούνται τιμές σχετικά με κάθε διαθέσιμο μονοπάτι του δικτύου, βάσει της εκτιμώμενης κατανάλωσης ενέργειας, αν ένα πακέτο αποσταλλεί μέσω του συγκεκριμένου μονοπατιού και της πιθανότητας σύγκρουσης με άλλο πακέτο. Στη συνέχεια, γίνεται επιλογή του μονοπατιού με την καλύτερη τιμή, ώστε να γίνει η μετάδοση του πακέτου [106], [107]. Βασικό χαρακτηριστικό των Support Vector Machines αλγορίθμων είναι ότι έχουν τη δυνατότητα να γενικεύσουν τα αποτελέσματά τους σε δεδομένα που δεν τα έχουν δεχθεί ως είσοδο ακόμα, αλλά και να δέχονται συνεχώς δεδομένα, να εκπαιδεύονται δηλαδή συνεχώς όσο υπάρχουν δεδομένα. Εισάγοντας στον αλγόριθμο, λοιπόν, τα δεδομένα κίνησης που είναι ήδη διαθέσιμα για ένα δίκτυο, ο αλγόριθμος είναι σε θέση να προβλέψει ικανοποιητικά την αναμενόμενη κίνηση του δικτύου [108].

Ακολούθως, θα παρουσιαστούν κάποιες από τις τεχνικές μηχανικής μάθησης που έχουν χρησιμοποιηθεί σχετικά με τη δρομολόγηση στα δίκτυα:

Χρησιμοποιηθείς Αλγόριθμος Μηχανικής Μάθησης	Στόχος Αλγορίθμου	Βιβλιογραφικές Αναφορές
Logistic Regression	Βελτίωση δρομολόγησης πακέτων στο δίκτυο	[109]
Bayesian Network	Βελτίωση δρομολόγησης πακέτων στο δίκτυο	[110]
Long-Term Memory Network (Recurrent Neural Network)	Βελτίωση δρομολόγησης πακέτων στο δίκτυο	[111]
Q-Learning	Υπολογισμός βέλτιστου μονοπατιού	[112]

Πίνακας 6 - Αλγόριθμοι Μηχανικής Μάθησης για Δρομολόγηση Δικτύου

Μέσω του Logistic Regression αλγορίθμου βρίσκεται η καλύτερη δυνατή δρομολόγηση για κάθε πακέτο που είναι προς μετάδοση. Για να επιτευχθεί αυτό,

γίνονται μετρήσεις της κίνησης του δικτύου και του χρόνου που απαιτείται ώστε ένα πακέτο να φτάσει στον κόμβο προορισμού του σε τακτά χρονικά διαστήματα, οι οποίες τοποθετούνται σε πίνακες, ώστε οι επόμενες μετρήσεις να αντικαταστήσουν τις προηγούμενες αν είναι καλύτερες από αυτές [109]. Ο αλγόριθμος που χρησιμοποιεί Bayesian δίκτυο προτείνει έναν τρόπο δρομολόγησης ο οποίος χρησιμοποιεί τους λιγότερο χρησιμοποιημένους κόμβους και ζεύξεις, κάτι που έχει ως αποτέλεσμα την αισθητή βελτίωση στη δρομολόγηση και ταχύτητα μετάδοσης των δεδομένων [110]. Ο Long-Term Memory Network αλγόριθμος βασίζεται στο γεγονός ότι οι μελλοντικές αποφάσεις δρομολόγησης μπορούν να επηρεαστούν από το ιστορικό των προηγούμενων δρομολογήσεων σε ένα δίκτυο. Συσχετίζει δηλαδή τις δρομολογήσεις, την κίνηση του δικτύου και τις δυνατότητες των συνδέσεων μεταξύ των κόμβων με το ιστορικό κίνησης του δικτύου, ώστε να επιτύχει καλύτερη δρομολόγηση των πακέτων που είναι προς μετάδοση [111]. Τέλος, με τον αλγόριθμο Q-Learning επιλέγεται το βέλτιστο μονοπάτι για κάθε πακέτο, αφού πρώτα υπολογιστούν όλα τα διαθέσιμα μονοπάτια που μπορούν να χρησιμοποιηθούν προκειμένου το πακέτο να φτάσει στον προορισμό του και υπολογιστεί για κάθε μονοπάτι η τιμή της πιθανότητας σύγκρουσης πακέτων, οπότε τελικά επιλέγεται το μονοπάτι με τη μικρότερη τιμή [112].

Για τα προβλήματα δρομολόγησης και εκχώρησης μήκους κύματος (RWA) και δρομολόγησης και εκχώρησης φάσματος (RSA) έχουν επίσης χρησιμοποιηθεί τεχνικές μηχανικής μάθησης:

Χρησιμοποιηθείς Αλγόριθμος Μηχανικής Μάθησης	Στόχος Αλγορίθμου	Βιβλιογραφικές Αναφορές
Logistic Regression	Επίλυση RWA	[113]
Reinforcement Learning	Επίλυση RWA	[114], [115], [116]
Q-Learning	Επίλυση RWA	[117], [118]
Linear Regression	Επίλυση RWA	[119]
Artificial Neural Network	Επίλυση RSA	[120]
K Nearest Neighbor	Επίλυση RSA	[121]

Πίνακας 7 - Αλγόριθμοι Μηχανικής Μάθησης για Προβλήματα RWA και RSA

Ο αλγόριθμος Logistic Regression δέχεται ως είσοδο έναν πίνακα που περιέχει τα δεδομένα κίνησης του οπτικού δικτύου και υπολογίζει τη βέλτιστη δρομολόγηση, ενώ ταυτόχρονα μειώνει τον απαιτούμενο χρόνο υπολογισμού κατά 93% συγκριτικά με τον χρόνο που απαιτείται χωρίς τη χρήση του συγκεκριμένου αλγορίθμου [113]. Κατά τη χρήση του αλγορίθμου Reinforcement Learning, για κάθε κόμβο του δικτύου δημιουργείται ένας πίνακας που περιέχει τιμές για όλα τα πιθανά μονοπάτια προς τους υπόλοιπους κόμβους του δικτύου βάσει μιας συνάρτησης επιβράβευσης που εξαρτάται από το ποσοστό απώλειας πληροφορίας για κάθε μονοπάτι. Οι τιμές του πίνακα περιοδικά ανανεώνονται και με τον τρόπο αυτό επιλέγεται το καλύτερο μονοπάτι προς μετάδοση της πληροφορίας [114], [115], [116]. Στον Q-Learning αλγόριθμο δημιουργείται, επίσης, ένας πίνακας για κάθε κόμβο που περιέχει τιμές για κάθε γειτονικό κόμβο σε αυτή τη περίπτωση. Οι τιμές του πίνακα υπολογίζονται βάσει όλων των γειτονικών κόμβων και αν αυτοί είναι προσβάσιμοι ή όχι και πόσος χρόνος απαιτείται ένα δοκιμαστικό σήμα να μεταδοθεί ως τον επόμενο κόμβο, επιλέγοντας το μονοπάτι που απαιτεί τον λιγότερο χρόνο για την πραγματική πληροφορία να μεταδοθεί [117], [118]. Για τον αλγόριθμο Linear Regression χρησιμοποιήθηκε μια μεγάλη βάση δεδομένων που περιείχε δοκιμαστικά δεδομένα παρόμοια με τα πραγματικά, ώστε να γίνει κατάλληλη εκπαίδευση του αλγορίθμου με τη μικρότερη δυνατή υπολογιστική ισχύ και στη συνέχεια χρησιμοποιήθηκε ο αλγόριθμος για την επίλυση του RWA προβλήματος στο ίδιο δίκτυο, επιτυγχάνοντας ικανοποιητικά αποτελέσματα [119]. Για τον αλγόριθμο Artificial Neural Network αναπτύχθηκε νευρωνικό δίκτυο με ένα κρυφό επίπεδο, το οποίο είχε ως είσοδο τα χαρακτηριστικά κάθε πακέτου προς μετάδοση, ώστε να παράξει ως έξοδο την κατάλληλη διαμόρφωση του σήματος, με απώτερο στόχο τη βέλτιστη εκχώρηση φάσματος, που θα εξασφαλίζει ταυτόχρονα γρήγορη μετάδοση της πληροφορίας με τη χρήση όσο το δυνατόν μικρότερου εύρους ζώνης [120]. Τέλος, στον αλγόριθμο k Nearest Neighbor η επίλυση του RSA προβλήματος και η επιλογή του βέλτιστου φάσματος εκπομπής γίνεται λαμβάνοντας υπόψιν μόνο την απόσταση που έχει να διανύσει κάθε πακέτο μέχρι τον προορισμό του, αφού με την εφαρμογή του επιδιώκεται η ελαχιστοποίηση της πιθανότητας αποκλεισμού λόγω περιορισμένου εύρους ζώνης [121].

Στον πίνακα που ακολουθεί παρουσιάζονται αλγόριθμοι μηχανικής μάθησης σχετικά με την απόδοση του δικτύου και την παρακολούθηση της απόδοσης του δικτύου:

Χρησιμοποιηθείς Αλγόριθμος Μηχανικής Μάθησης	Στόχος Αλγορίθμου	Βιβλιογραφικές Αναφορές
Artificial Neural Network	Παρακολούθηση απόδοσης δικτύου	[122],[123],[124],[125]
Neural Network	Παρακολούθηση απόδοσης δικτύου	[126]
Convolutional Neural Network	Παρακολούθηση απόδοσης δικτύου	[127], [128]

Πίνακας 8 - Αλγόριθμοι Μηχανικής Μάθησης για Απόδοση Δικτύου

Για τον αλγόριθμο Artificial Neural Network αναπτύχθηκε νευρωνικό δίκτυο ενός κρυφού επιπέδου, το οποίο με τη χρήση δεδομένων και χαρακτηριστικών του δικτύου παρακολουθεί συνεχώς τα επίπεδα του Signal to Noise Ratio (SNR), του τρόπου πόλωσης και της χρωματικής διασποράς μεταξύ άλλων, στοιχείων δηλαδή που είναι ενδεικτικά της απόδοσης του δικτύου [122], [123], [124], [125]. Ο δεύτερος αλγόριθμος χρησιμοποιεί και αυτός νευρωνικό δίκτυο ενός κρυφού επιπέδου, ώστε να παρακολουθεί τα ίδια στοιχεία με τον προηγούμενο αλγόριθμο. Η ουσιαστική διαφορά έγκειται στο γεγονός ότι ο συγκεκριμένος αλγόριθμος κάνει χρήση του ιστορικού της κίνησης του δικτύου, ώστε να εξάγει τα συμπεράσματα [126]. Τέλος, σχετικά με το Convolutional Neural Network αναπτύχθηκε και σε αυτή τη περίπτωση νευρωνικό δίκτυο ενός κρυφού επιπέδου, που έχει στόχο τη συνεχή παρακολούθηση των τιμών του Signal to Noise Ratio (SNR), ώστε να παρακολουθείται με τον τρόπο αυτό και η απόδοση του δικτύου. Αυτό επιτυγχάνεται μέσω του υπολογισμού του SNR για έξι διαφορετικές διαμορφώσεις σήματος και σύγκρισης των αποτελεσμάτων μεταξύ τους [127], [128].

Η απόδοση του δικτύου όσον αφορά την εκπεμπόμενη πληροφορία και την επιτυχή αποστολή της, είναι το επόμενο πρόβλημα για το οποίο θα παρουσιαστούν διάφορες τεχνικές που έχουν χρησιμοποιηθεί με στόχο την επίλυση του:

Χρησιμοποιηθείς Αλγόριθμος Μηχανικής Μάθησης	Στόχος Αλγορίθμου	Βιβλιογραφικές Αναφορές
Random Forest	Εκτίμηση δείκτη bit error rate (BER)	[129]
Neural Network	Εκτίμηση ποιότητας εκπομπής ανά κανάλι	[130],[131],[132]
Regression	Εκτίμηση Signal to Noise Ratio (SNR)	[133], [134]
k-Nearest neighbor	Εκτίμηση δείκτη bit error rate (BER)	[135]

Πίνακας 9 - Αλγόριθμοι Μηχανικής Μάθησης για Ποιότητα Εκπομπής

Ο αλγόριθμος Random Forest χρησιμοποιεί τα δεδομένα κίνησης του δικτύου, την επιθυμητή διαδρομή για τη μεταφορά της πληροφορίας και τον τύπο της διαμόρφωσης του σήματος, ώστε να προβλέψει αν ο δείκτης bit error rate (BER) για διαδρομές που δεν έχουν εγκαθιδρυθεί ακόμα, έχει αποδεκτές τιμές, προκειμένου στη συνέχεια οι διαδρομές αυτές να εγκαθιδρυθούν ή να απορριφθούν [129]. Στον επόμενο αλγόριθμο έχουν χρησιμοποιηθεί νευρωνικά δίκτυα. Πιο συγκεκριμένα, δημιουργήθηκε νευρωνικό δίκτυο που διαθέτει 120 νευρώνες εισόδου, 120 νευρώνες εξόδου και ένα κρυφό επίπεδο 480 νευρώνων. Χωρίς να υπάρχει απαίτηση για πρότερη γνώση των χαρακτηριστικών του δικτύου στο οποίο χρησιμοποιείται ο αλγόριθμος, μόνο με τη χρήση των δεδομένων κίνησης του δικτύου, είναι σε θέση να προβλέψει την απόδοση κάθε κόμβου του δικτύου [91], [131], [132]. Ο Regression αλγόριθμος χρησιμοποιεί τα επίπεδα εκπεμπόμενης ισχύος των μεταδιδόμενων σημάτων και των καταστάσεων των καναλιών, αν είναι high ή low, ώστε να εκπαιδευτεί κατάλληλα και να μπορέσει να προβλέψει πιθανές εκπομπές μεγάλης ισχύος, όπως επίσης και το Signal to Noise Ratio για κάθε εκπομπή [133], [134]. Τέλος, για τον k-Nearest Neighbor αλγόριθμο υπολογίζει το

bit error rate (BER) ως ο λόγος της απαιτούμενης ενέργειας για να μεταδοθεί ένα bit προς τον θόρυβο του καναλιού εκπομπής. Δημιουργούνται με τον τρόπο αυτό νέα δεδομένα τα οποία χρησιμοποιεί ο αλγόριθμος, ώστε να ταξινομήσει τις πιθανές διαδρομές του φωτός βάσει των τιμών του bit error rate (BER) [135].

Η διαχείριση των σφαλμάτων αποτελεί το τελευταίο ζήτημα για το οποίο θα παρουσιαστούν αλγόριθμοι μηχανικής μάθησης που έχουν αναπτυχθεί για αυτό:

Χρησιμοποιηθείς Αλγόριθμος Μηχανικής Μάθησης	Στόχος Αλγορίθμου	Βιβλιογραφικές Αναφορές
Support Vector Machine	Πρόβλεψη σφαλμάτων	[136]
Naïve Bayes	Πρόβλεψη σφαλμάτων	[137],[138],[139],[140]
Clustering	Ανίχνευση ανωμαλιών στο δίκτυο	[141]
k-Means	Εντοπισμός πηγής σφαλμάτων στο δίκτυο	[142]
Decision Tree	Αναγνώριση σφαλμάτων	[143]

Πίνακας 10 - Αλγόριθμοι Μηχανικής Μάθησης για Διαχείριση Σφαλμάτων

Ο Support Vector Machine αλγόριθμος χρησιμοποιείται για να προβλέψει με μεγάλη ακρίβεια πιθανή αστοχία στον εξοπλισμό ενός οπτικού δικτύου, όπως των ενισχυτών για παράδειγμα, αυξάνοντας με τον τρόπο αυτό την σταθερότητα του δικτύου και την αδιάλειπτη λειτουργία των υπηρεσιών του δικτύου [136]. Ο Naïve Bayes αλγόριθμος είναι σε θέση να εντοπίσει, να αναγνωρίσει και τελικώς, μετά την απαραίτητη εκπαίδευσή του, να προβλέψει την πιο πιθανή αιτία ενός σφάλματος στο δίκτυο, μέσω της παρακολούθησης διάφορων παραμέτρων της μετάδοσης των δεδομένων, όπως της ισχύος του λαμβανόμενου σήματος και των διακαναλικών παρεμβολών [137], [138], [139], [140]. Με τη χρήση του Clustering αλγορίθμου μηχανικής μάθησης, γίνεται αρχικά ανάλυση των δεδομένων κίνησης ενός οπτικού δικτύου, στη συνέχεια γίνεται εντοπισμός πιθανών κοινών μοτίβων στα δεδομένα αυτά, με σκοπό, στο τελικό βήμα, ο αλγόριθμος να αποκτήσει την ικανότητα να ανιχνεύει πιθανές μη αναμενόμενες λειτουργίες του δικτύου, χωρίς να υπάρχει

απαίτηση για μεγάλο όγκο δεδομένων [141]. Ο k-Means αλγόριθμος χρησιμοποιείται ώστε να δημιουργηθεί ένας χάρτης που περιέχει όλες τις bit error rate (BER) μετρήσεις για όλα τα πιθανά μονοπάτια διάδοσης του φωτός στο δίκτυο για μια συγκεκριμένη χρονική περίοδο, ώστε στη συνέχεια, μέσω των κατάλληλων υπολογισμών, να εντοπιστεί το μονοπάτι που αν χρησιμοποιηθεί θα υπάρξει η μικρότερη μείωση της απόδοσης του δικτύου [142]. Τέλος, ο αλγόριθμος Decision Tree είναι σε θέση να αναγνωρίσει σφάλματα σε οπτικά δίκτυα, μέσω της σύγκρισης δεδομένων που έχουν εξαχθεί με τρεις διαφορετικούς τρόπους. Στην πρώτη περίπτωση, τα δεδομένα έχουν ληφθεί κατευθείαν από το δίκτυο, στη δεύτερη περίπτωση, τα δεδομένα έχουν υποστεί επεξεργασία ελαφρώς, και στην τρίτη περίπτωση, τα δεδομένα έχουν υποστεί επεξεργασία σε βάθος μέσω ενός αλγορίθμου σχεδιασμένου για τον σκοπό αυτό [143].

Στη συγκεκριμένη ενότητα παρουσιάστηκαν κάποια από τα σημαντικότερα προβλήματα των δικτύων, για τα οποία έχουν αναπτυχθεί αλγόριθμοι και τεχνικές μηχανικής μάθησης που έχουν στόχο να επιλύσουν τα προβλήματα αυτά όσο το δυνατόν καλύτερα και αποδοτικότερα. Λόγω της ύπαρξης εκτενούς βιβλιογραφίας που περιλαμβάνει το σύνολο σχεδόν των δικτυακών προβλημάτων, αλλά και μια πληθώρα προτεινόμενων τεχνικών για κάθε ένα από τα προβλήματα αυτά, έγινε μια επιλογή των πιο διαδεδομένων και συνηθέστερων προβλημάτων που αντιμετωπίζουν τόσο τα δίκτυα υπολογιστών όσο και τα οπτικά δίκτυα υπολογιστών, όπως επίσης και των τεχνικών που έχουν ερευνηθεί πιο αναλυτικά.

6.3 Deep Learning και Artificial Intelligence σε Δίκτυα

Όπως έχει ήδη αναφερθεί η μηχανική μάθηση αποτελεί κλάδο της τεχνητής νοημοσύνης και η βαθιά μάθηση την εξέλιξη της μηχανικής μάθησης. Αυτό συνεπάγεται ότι για τα περισσότερα από τα προβλήματα που παρουσιάστηκαν στην προηγούμενη ενότητα έχει γίνει προσέγγιση επίλυσης τους τόσο υπό το πρίσμα της τεχνητής νοημοσύνης όσο και υπό αυτό της βαθιάς μάθησης. Ιδιαίτερα στις προσεγγίσεις της βαθιάς μάθησης, όπως θα αναφερθεί στη συνέχεια της ενότητας

αυτής, υπάρχει, στην πλειονότητα των περιπτώσεων, ένας συνδυασμός τεχνικών μηχανικής μάθησης με βαθιά μάθηση, δημιουργώντας με τον τρόπο αυτό ιδιαίτερα πολύπλοκα, αλλά ταυτόχρονα και ακριβέστερα συστήματα που επιλύουν τα προβλήματα των δικτύων.

Στον τομέα της τεχνητής νοημοσύνης έχουν γίνει αρκετές έρευνες, στις οποίες γίνεται διερεύνηση των τεχνικών που μπορούν να χρησιμοποιηθούν, ώστε να γίνει ο έλεγχος και η λειτουργία των δικτύων με τον αποδοτικότερο τρόπο [144]. Βασικός στόχος των τεχνικών αυτών αποτελεί η καλύτερη διαχείριση των πόρων του δικτύου, ώστε αυτό να συντελέσει στην καλύτερη εξυπηρέτηση των χρηστών του δικτύου [144]. Οι τεχνικές αυτές έχουν εξεταστεί σε ένα γενικό πλαίσιο λειτουργίας [145], καθώς έχει δοθεί μεγαλύτερη έμφαση στους υποτομείς της τεχνητής νοημοσύνης, δηλαδή την μηχανική μάθηση και τη βαθιά μάθηση, αφού οι περισσότεροι αλγόριθμοι και τεχνικές έχουν αναπτυχθεί και εξεταστεί υπό το πρίσμα των κλάδων αυτών.

Βασικό χαρακτηριστικό της βαθιάς μάθησης, το οποίο έχει οδηγήσει στην ευρεία χρήση της στα δίκτυα, είναι η ικανότητα που έχουν οι αλγόριθμοι που βασίζονται σε αυτήν να εξάγουν χρήσιμα συμπεράσματα και βασικά χαρακτηριστικά από τα αρχικά δεδομένα με τρόπο αυτόματο [146], μειώνοντας αισθητά τόσο τον χρόνο, όσο και την απαιτούμενη εργασία που έπρεπε να γίνει από μη αυτόματα συστήματα. Επιπλέον, η ικανότητα των αλγορίθμων βαθιάς μάθησης να εισάγει τα αρχικά δεδομένα απευθείας στο νευρωνικό δίκτυο που έχει αναπτυχθεί και στη συνέχεια τα επιθυμητά χαρακτηριστικά και συμπεράσματα να εξάγονται κατευθείαν [147], είναι ακόμα ένας βασικός παράγοντας για τη διαδεδομένη χρήση των τεχνικών αυτών.

Στη συνέχεια θα αναφερθούν εφαρμογές της βαθιάς μάθησης σε επιμέρους ζητήματα των δικτύων. Με τη χρήση Deep Neural Networks είναι εφικτό να γίνει τόσο καλύτερη πρόβλεψη των απαιτήσεων σε πόρους δικτύου [148], όσο και εκτίμηση της αναμενόμενης κίνησης του δικτύου [149]. Επιπλέον, είναι εφικτό να κατανεμηθούν και οι πόροι του δικτύου, αλλά και να υλοποιηθεί ένας προγραμματισμός σχετικά με την κατανομή αυτή [150]. Η κατανομή αυτή μπορεί να γίνει και με τη χρήση τεχνικής βαθιάς μάθησης που υλοποιείται σε δύο επίπεδα

[151], ενώ υπάρχουν και αλγόριθμοι που είναι σε θέση να αναπτυχθούν ανεξαρτήτου μέσου διάδοσης [152].

Με τη χρήση Deep Neural Networks μπορεί επιπλέον να αντιμετωπιστεί και το πρόβλημα της εκχώρησης μήκους κύματος (RWA) ([153],[154]), ενώ με τεχνικές Deep Reinforcement Learning η εκχώρηση φάσματος (RSA) μπορεί να καταστεί πολύ πιο αποδοτική ([155], [156]). Η μείωση των πιθανοτήτων συγκρούσεων και απόρριψης δεδομένων στα προβλήματα της εκχώρησης φάσματος μπορούν να μειωθούν αν οι κατάλληλες τεχνικές Deep Neural Networks [157] και Deep Reinforcement Learning εφαρμοστούν [158].

Η απόδοση του δικτύου είναι μια σημαντική παράμετρος ώστε ένα δίκτυο να θεωρηθεί ότι εξυπηρετεί επαρκώς τους χρήστες του, όποτε και η παρακολούθηση της απόδοσης του αποτελεί ένα κρίσιμο στοιχείο. Για τον λόγο αυτό και στον συγκεκριμένο τομέα, η χρήση Deep Neural Networks είναι σημαντική καθώς είναι σε θέση να υπολογίσει τον λόγο σήματος προς θόρυβο, έναν δείκτη πολύ σημαντικό για την ποιότητα του δικτύου ([159], [160]). Η σχέση μεταξύ της ποιότητας των προσφερόμενων υπηρεσιών και της ποιότητας του δικτύου αποτελεί μια εξίσου σημαντική παράμετρο σχετικά με το δίκτυο και τις υπηρεσίες που είναι σε θέση να προσφέρει και η χρήση Deep Neural Networks και σε αυτή την περίπτωση μπορεί να ωφελήσει το δίκτυο ιδιαίτερα [161].

Τα Deep Neural Networks μπορούν να χρησιμοποιηθούν και για τον εντοπισμό και την αναγνώριση σφαλμάτων στο δίκτυο, ώστε να επιταχυνθούν οι διαδικασίες επαναφοράς του δικτύου στην κατάσταση που βρίσκονταν πριν τα σφάλματα [162]. Η ασφάλεια των δικτύων αποτελεί ίσως και τον πιο κρίσιμο τομέα, στον οποίο η βαθιά μάθηση έχει βοηθήσει ώστε να ενισχυθεί όσο το δυνατόν περισσότερο. Η έγκαιρη ανίχνευση πρόσπαθειας μη εξουσιοδοτημένης πρόσβασης στο δίκτυο και αποτροπής της μπορεί να επιτευχθεί με τη χρήση Deep Neural Networks [163].

Όπως και στην περίπτωση της μηχανικής μάθησης, όπου οι τεχνικές που είναι διαθέσιμες για να αντιμετωπιστούν τα διάφορα προβλήματα που υπάρχουν στα δίκτυα είναι πολλές και έχει πραγματοποιηθεί εκτεταμένη έρευνα σε αυτές, το ίδιο συμβαίνει στη βαθιά μάθηση. Αναλογιζόμενοι το γεγονός ότι η τελευταία αποτελεί την εξέλιξη της πρώτης και τα προβλήματα των δικτύων δεν έχουν

επιλυθεί πλήρως, είναι αναμενόμενο η έρευνα να έχει στραφεί στους πιθανούς τρόπους με τους οποίους μπορεί η βαθιά μάθηση να ενισχύσει περαιτέρω την απόδοση των δικτύων στους τομείς που αναφέρθηκαν.

6.4 Αποτελέσματα Χρήσης Μηχανικής Μάθησης σε Δίκτυα

Στις προηγούμενες ενότητες αναφέρθηκαν τόσο τα προβλήματα που αντιμετωπίζουν τα δίκτυα, όσο και οι διαθέσιμες τεχνικές και αλγόριθμοι μηχανικής μάθησης και της βαθιάς μάθησης που έχουν αναπτυχθεί για την επίλυση των προβλημάτων αυτών. Παρόλο που τα προβλήματα αυτά δεν έχουν επιλυθεί πλήρως, καθώς τα δίκτυα εξελίσσονται συνεχώς, με αποτέλεσμα οι λύσεις που έχουν υλοποιηθεί να απαιτούν διαρκώς τροποποιήσεις, εντούτοις, έχουν εξαχθεί χρήσιμα συμπεράσματα από τους υλοποιημένους αλγορίθμους.

Όσον αφορά την εκτίμηση της επιτυχούς εκπομπής, της εκπομπής δηλαδή χωρίς σφάλματα, και την παρακολούθηση της απόδοσης του δικτύου, η χρήση τεχνικών τόσο μηχανικής όσο και βαθιάς μάθησης έχει οδηγήσει στη μείωση του δείκτη BER, του δείκτη δηλαδή που υπολογίζει το ρυθμό σφάλματος ανά bit [8]. Αυτό έχει ως άμεσο αποτέλεσμα το δίκτυο να εμφανίζει μικρότερο αριθμό σφαλμάτων, αφού είναι σε θέση να προβλέψει αν η εκπομπή θα είναι με ή χωρίς σφάλματα, αλλά και το πλήθος των σφαλμάτων, και να την προσαρμόσει αναλόγως των δεδομένων που υπάρχουν την εκάστοτε χρονική στιγμή.

Αλλά και στη διαχείριση σφαλμάτων η χρήση των τεχνικών αυτών έχει ωφελήσει τα δίκτυα. Συγκεκριμένα, μέσω της διαδικασίας ελέγχου και διαχείρισης σφαλμάτων, το δίκτυο μπορεί όχι μόνο να διαχειριστεί αποτελεσματικά τα σφάλματα που παρουσιάζονται, αλλά και να είναι σε θέση να αποφύγει την ύπαρξη ίδιων λαθών στο μέλλον, καθώς και να επιτύχει την καλύτερη διαχείρισή τους, αφού θα έχει ήδη διαχειριστεί παρόμοια [8].

Από όσα αναφέρθηκαν προηγουμένως σχετικά με τα αποτελέσματα της χρήσης τεχνικών μηχανικής μάθησης, στα δίκτυα διαφαίνεται ότι πέρα από τα οφέλη ανά κατηγορία προβλήματος, υπάρχουν και γενικά οφέλη, όπως για παράδειγμα η ικανότητα του δικτύου να αντιδρά και να ανταποκρίνεται άμεσα σε

οποιαδήποτε μη επιθυμητή κατάσταση δημιουργείται, όπως επίσης η δημιουργία αυτοματοποιημένων και έξυπνων λύσεων, όπου το δίκτυο μπορεί να επανέρχεται από μη επιθυμητές καταστάσεις, χωρίς την παρέμβαση του ανθρώπινου παράγοντα, κάτι που κοστίζει σε χρόνο και πόρους [9].

Παρά τα θετικά αποτελέσματα που περιγράφηκαν για τη χρήση των τεχνικών μηχανικής μάθησης στα δίκτυα, δεν πρέπει να παραβλεφθούν και τα μειονεκτήματα που απορρέουν από τη χρήση αυτή. Πιο συγκεκριμένα, το κόστος των προβλέψεων, τόσο υπολογιστικό όσο και υλικό, αποδεικνύεται ιδιαίτερα υψηλό στην πλειοψηφία των περιπτώσεων, όπως επίσης η διαδικασία αναγνώρισης σφαλμάτων και εξαγωγής αναφορών για αυτά, ώστε να είναι σε θέση οι διαχειριστές των δικτύων να προβούν σε διορθωτικές ενέργειες [44]. Επίσης, η ανάπτυξη πολύπλοκων, τις περισσότερες φορές, αλγορίθμων επιβαρύνει τη σταθερότητα του δικτύου αλλά και την ποιότητα των υπηρεσιών [44]. Ενώ από τη μια πλευρά οι αλγόριθμοι χρησιμοποιούνται ώστε να βελτιωθούν τα δύο αυτά χαρακτηριστικά, την ίδια στιγμή επιβαρύνουν το δίκτυο, αναδεικνύοντας έτσι ότι η διαδικασία εύρεσης της χρυσής τομής μεταξύ επιβάρυνσης και οφέλους είναι αυτό που επιζητείται. Το βασικότερο ίσως πρόβλημα που αντιμετωπίζουν τα δίκτυα και οι αλγόριθμοι είναι η έλλειψη δεδομένων από πραγματικά δίκτυα [44]. Τέτοια δεδομένα είναι ελάχιστα και ανεπαρκή τόσο σε αριθμό όσο και σε όγκο δεδομένων, με αποτέλεσμα οι αλγόριθμοι να αναπτύσσονται και να εκπαιδεύονται με πειραματικά δεδομένα στην πλειονότητα των περιπτώσεων, τα οποία αφενός προσομοιώνουν τα πραγματικά δεδομένα, αφετέρου δεν είναι δυνατόν να εξαχθούν τα ίδια συμπεράσματα σε σχέση με τα πραγματικά, έχοντας ως αποτέλεσμα τα δίκτυα να μην ωφελούνται με τον βέλτιστο τρόπο.

Τέλος, θα αναφερθούν εν συντομία κάποιες προκλήσεις που έχουν να αντιμετωπίσουν η μηχανική και βαθιά μάθηση όσον αφορά τα δίκτυα. Μια από τις σημαντικότερες προκλήσεις είναι η διαθεσιμότητα δεδομένων που να μπορούν να χρησιμοποιηθούν από όλους τους αλγορίθμους [73]. Επιπλέον, είναι απαραίτητο τα διαθέσιμα μοντέλα να μπορέσουν να αποκτήσουν ένα πιο γενικό πλαίσιο, ώστε να είναι σε θέση να χρησιμοποιηθούν σε περισσότερες περιστάσεις, ενώ και η υπολογιστική πολυπλοκότητα των αλγορίθμων είναι αναγκαίο να μειωθεί, ώστε το αντίστοιχο κόστος να μειωθεί και να είναι πιο γρήγορη η εκτέλεσή τους [73]. Ακόμη,

μια πολύ σημαντική πρόκληση αποτελεί η απαίτηση ώστε οι αλγόριθμοι μηχανικής μάθησης να έχουν δοκιμαστεί πλήρως και να μην περιέχουν κανένα κενό ασφαλείας που θα μπορέσει να εκθέσει το δίκτυο σε πιθανούς κινδύνους, όπως για παράδειγμα μια πιθανή μόλυνση από κακόβουλο λογισμικό στο δίκτυο που έχει αναπτυχθεί ο αλγόριθμος και η μη εξουσιοδοτημένη πρόσβαση στα δεδομένα που χρησιμοποιούν οι αλγόριθμοι μηχανικής μάθησης [73]. Η χρήση και ανάπτυξη των αλγορίθμων θα πρέπει να γίνει με τέτοιο τρόπο ώστε τα δίκτυα, τα οποία αντιμετωπίζουν συνεχώς τις προκλήσεις αυτές, να μην εκτεθούν σε επιπρόσθετους κινδύνους, δημιουργώντας με τον τρόπο αυτό μια ανισορροπία ανάμεσα στα οφέλη και τους κινδύνους που παρέχουν η μηχανική και βαθιά μάθηση.

7. Ανάπτυξη Αλγορίθμων και Αποτελέσματα

7.1 Αλγόριθμοι Μηχανικής Μάθησης

Στην ενότητα 5.2 παρουσιάστηκαν κάποιοι από τους αλγορίθμους μηχανικής μάθησης που είναι διαθέσιμοι και μπορούν να χρησιμοποιηθούν σε προβλήματα των δικτύων. Στη συγκεκριμένη εργασία επιλέχθηκαν και υλοποιήθηκαν δύο Supervised και δύο Unsupervised αλγόριθμοι. Πιο συγκεκριμένα, εφαρμόστηκαν οι αλγόριθμοι kMeans Clustering και miniBatch Clustering Unsupervised και οι αλγόριθμοι Naïve Bayes Classification και kNN Classification Supervised. Στη συνέχεια, ακολουθεί μια σύντομη ανάλυση κάθε αλγορίθμου, των χαρακτηριστικών, των πλεονεκτημάτων και των μειονεκτημάτων του και τέλος, των λόγων για τους οποίους εφαρμόστηκαν οι συγκεκριμένοι αλγόριθμοι.

- **kMeans Clustering ([164], [165]):**
 - ο Περιγραφή: Αυτός ο αλγόριθμος στοχεύει να διαχωρίσει τα δεδομένα σε έναν συγκεκριμένο αριθμό ομάδων, όπου τα στοιχεία που βρίσκονται στο ίδιο ομάδα έχουν κάποιες ομοιότητες μεταξύ τους [70]. Ουσιαστικά, ο αλγόριθμος προσπαθεί να βρει ένα μοτίβο στα δεδομένα και στη συνέχεια να χωρίσει τα δεδομένα με βάση αυτό το μοτίβο.
 - ο Λειτουργία: Αρχικά, τα δεδομένα χωρίζονται σε k clusters, μετά υπολογίζεται το κέντρο από κάθε cluster και τέλος κάθε δεδομένο τοποθετείται στο cluster στο οποίο βρίσκεται πιο κοντά στο κέντρο του [8]. Αυτή η διαδικασία επαναλαμβάνεται είτε μέχρι να μην αλλάξουν δεδομένα για 2 επαναλήψεις, είτε μέχρι να εφαρμοστεί ένας συγκεκριμένος αριθμός επαναλήψεων που δίνονται από τον χρήστη. Αξίζει να σημειωθεί ότι ο βέλτιστος αριθμός k των ομάδων που δημιουργούνται μπορεί να βρεθεί με τον υπολογισμό συγκεκριμένων μετρήσεων, όπως ο Συντελεστής Silhouette.
 - ο Χαρακτηριστικά: Ο αριθμός των ομάδων μπορεί να βρεθεί είτε μέσω κάποιων μετρήσεων είτε πειραματικά από τον χρήστη, αν και η τελευταία περίπτωση είναι πολύ χρονοβόρα. Ο τρόπος με τον οποίο

τερματίζεται συνήθως ορίζεται από τον χρήστη, καθώς, εξαιτίας του γεγονότος ότι ο αλγόριθμος χρησιμοποιείται για δεδομένα μεγάλης κλίμακας [1], είναι χρονοβόρο να «αποφασίσει» ο αλγόριθμος πότε θα σταματήσει. Τέλος, επειδή το κριτήριο με το οποίο διαχωρίζονται οι συστάδες αποτελεί το ποσοστό ομοιότητας, είναι ένας πολύ αποτελεσματικός αλγόριθμος για την ανίχνευση ανωμαλιών στα δεδομένα [166].

- **miniBatch Clustering [66]:**

- Περιγραφή: Αυτός ο αλγόριθμος είναι μια παραλλαγή του kMeans Clustering. Ο τρόπος που τα δεδομένα τοποθετούνται στις ομάδες σε κάθε επανάληψη είναι αυτός που διαφέρει στον συγκεκριμένο αλγόριθμο σε σχέση με τον kMeans Clustering. Και σε αυτόν τον αλγόριθμο, τα δεδομένα διαχωρίζονται με βάση την ομοιότητα και ο αλγόριθμος αναζητά να βρει ένα μοτίβο στα δεδομένα για να τα διαχωρίσει αργότερα ([167], [168], [66]).
- Λειτουργία: Όπως ήδη αναφέρθηκε, ο τρόπος λειτουργίας είναι παρόμοιος με τον αλγόριθμο kMeans. Τα δεδομένα χωρίζονται σε k ομάδες και στη συνέχεια υπολογίζεται το κέντρο από κάθε ομάδα. Υπάρχει μια διαφορά στο επόμενο βήμα, όπου σε αυτόν τον αλγόριθμο μόνο ένα κομμάτι δεδομένων εξετάζεται και τοποθετείται σε ομάδες και όχι όλα τα δεδομένα όπως στο kMeans [66]. Και σε αυτόν τον αλγόριθμο η διαδικασία ολοκληρώνεται είτε μετά από 2 επαναλήψεις, όπου δεν χρειάζεται να τοποθετήσουμε κανένα στοιχείο σε μια ομάδα, είτε όταν φτάσουμε στον αριθμό των επαναλήψεων που έχει ορίσει ο χρήστης. Επίσης, ο βέλτιστος αριθμός ομάδων μπορεί να βρεθεί υπολογίζοντας τις ίδιες μετρήσεις στην περίπτωση του αλγόριθμου kMeans.
- Χαρακτηριστικά: Ο αλγόριθμος έχει παρόμοια χαρακτηριστικά με αυτά του αλγορίθμου kMeans. Η μόνη άλλη ουσιαστική διαφορά είναι το γεγονός ότι αυτός ο αλγόριθμος προτιμάται για μεγάλες βάσεις δεδομένων, αφού σε κάθε επανάληψη δεν εξετάζονται όλα τα

δεδομένα αλλά μερικά από αυτά, επιτυγχάνοντας έτσι πολύ πιο γρήγορους υπολογισμούς [66].

- **Naïve Bayes Classification [169]:**

- Περιγραφή: Η κεντρική ιδέα του αλγορίθμου είναι ο διαχωρισμός των δεδομένων που είναι διαθέσιμα σε κατηγορίες όσο το δυνατόν ακρίβεστερα και στη συνέχεια να προβλέψει την κατηγορία από κάθε δεδομένο. Για να επιτευχθεί αυτό, ο αλγόριθμος υποθέτει ότι όλα τα χαρακτηριστικά των δεδομένων είναι υπό όρους ανεξάρτητα, δεδομένης της ετικέτας κλάσης τους [170]. Αν και αυτή η υπόθεση δεν είναι συνήθως αληθινή, καθώς τα δεδομένα είναι συχνά αλληλένδετα και αλληλοεξαρτώμενα, ο αλγόριθμος παράγει καλά αποτελέσματα [171].
- Λειτουργία: Ο αλγόριθμος μπορεί να ταξινομήσει τόσο δεδομένα που ταξινομούνται σε δύο κλάσεις όσο και δεδομένα που ταξινομούνται σε πολλαπλές κλάσεις. Για να επιτευχθεί αυτό, ο αλγόριθμος περιγράφει τα ακόλουθα βήματα. Πρώτα δηλώνεται η μεταβλητή στόχος, στη συνέχεια τα δεδομένα χωρίζονται σε σετ εκπαίδευσης, δοκιμής και επικύρωσης και ακολουθεί η διαδικασία όπου εκπαιδεύεται ο αλγόριθμος και τελικά παράγει τα αποτελέσματα.
- Χαρακτηριστικά: Το κύριο χαρακτηριστικό του αλγορίθμου είναι ότι δε διαθέτει παράμετρο που πρέπει να επιλεγεί ή να υπολογιστεί πειραματικά κατά τη φάση υλοποίησης. Επιπλέον, ο αλγόριθμος παράγει καλύτερα αποτελέσματα όταν τα δεδομένα είναι είτε εντελώς ανεξάρτητα (όπως αρχικά υπέθεσε) είτε εντελώς εξαρτημένα [171]. Τέλος, πρέπει να σημειωθεί ότι υπάρχουν αρκετές παραλλαγές του αλγορίθμου Naïve Bayes, όπως Gaussian, Multinomial, Bernoulli Naïve Bayes [72]. Οι διαφορές μεταξύ αυτών των παραλλαγών αφορούν στον τρόπο υπολογισμού των μεταβλητών στο μαθηματικό υπόβαθρο του αλγορίθμου και το κριτήριο ταξινόμησης.

- **kNN Classification ([172],[173]):**

- Περιγραφή: Η κεντρική ιδέα του αλγορίθμου kNN είναι παρόμοια με τον αλγόριθμο Naïve Bayes, καθώς προσπαθεί να ταξινομήσει τα

δεδομένα όσο το δυνατόν καλύτερα, για να προβλέψει την κατηγορία δεδομένων. Για την επίτευξη του στόχου, ο αλγόριθμος υποθέτει ότι εάν η πλειονότητα των k πιο πανομοιότυπων δειγμάτων ανήκει σε ένα σημείο (σημείο ερωτήματος) q του χώρου χαρακτηριστικών, τότε μπορούμε να συμπεράνουμε ότι το σημείο ερωτήματος q ανήκει σε αυτή την κατηγορία [174].

- Λειτουργία: Ο αλγόριθμος k NN είναι αρκετά παρόμοιος με τον τρόπο που λειτουργεί ο αλγόριθμος Naïve Bayes. Συγκεκριμένα, πρώτα δηλώνεται η μεταβλητή στόχος, μετά τα δεδομένα χωρίζονται σε σετ εκπαίδευσης, δοκιμής και επικύρωσης, ακολουθείται η διαδικασία όπου πρέπει να καθοριστούν οι παράμετροι του αλγορίθμου και τέλος ακολουθεί η διαδικασία εκπαίδευσης και παραγωγής αποτελεσμάτων.
- Χαρακτηριστικά: Ένα βασικό χαρακτηριστικό του αλγορίθμου που τον κάνει διαφορετικό από τον προαναφερθέντα Naïve Bayes είναι ότι δεν κάνει υποθέσεις σχετικά με τα διαθέσιμα δεδομένα ([68], [69]). Επιπλέον, αυτός ο αλγόριθμος δε "μαθαίνει" απευθείας κατά τη φάση της εκπαίδευσης, αλλά αντ' αυτού αποθηκεύει τη βάση δεδομένων και ενεργεί σε αυτήν όταν απαιτείται [175]. Επιπλέον, κατά τη φάση υλοποίησης, ο αλγόριθμος έχει αρκετές παραμέτρους που πρέπει να καθοριστούν, καθιστώντας έτσι δύσκολη και χρονοβόρα τη διαδικασία εύρεσης των βέλτιστων τιμών παραμέτρων.

Στη συνέχεια θα παρουσιαστούν εν συντομία μερικά από τα πλεονεκτήματα και μειονεκτήματα των αλγορίθμων που επιλέχθηκαν προς υλοποίηση.

Αλγόριθμος	Πλεονεκτήματα	Μειονεκτήματα
kMeans Clustering	Σχετικά εύκολη υλοποίηση [138]	Τα μη φυσιολογικά δεδομένα και ο θόρυβος επηρεάζουν πολύ τον αλγόριθμο [10]
	Οι επαναλήψεις εκτελούνται αρκετά γρήγορα [139]	Ο αριθμός k του συμπλέγματος δεν μπορεί να προσδιοριστεί εκ των προτέρων. Είναι προκαθορισμένος αναλόγως του προβλήματος [10]
	Το χαρακτηριστικό εισόδου μπορεί να αλλάξει το σύμπλεγμα όταν υπολογιστούν ξανά τα κεντροειδή [137]	Τα αποτελέσματα επηρεάζονται από την αρχική σειρά δεδομένων [138]

miniBatch Clustering	Ταχύτερος από άλλους αλγόριθμους ομαδοποίησης, ειδικά για μεγάλα σύνολα δεδομένων [31]	Ο αλγόριθμος πρέπει να εκτελεστεί πολλές φορές με διαφορετικό σημείο εκκίνησης για να βρεθεί η καλύτερη λύση [10]
	Βελτιωμένη χρονική πολυπλοκότητα [140]	Δεν είναι εγγυημένη η βέλτιστη λύση σε κάθε πρόβλημα [10]
	Ένας από τους απλούστερους unsupervised αλγόριθμους [140]	Όπως και στον kMeans τα αποτελέσματα επηρεάζονται από την αρχική σειρά δεδομένων [138]
Naïve Bayes Classification	Απλός και υπολογιστικά απλός αλγόριθμος [37]	Πρόβλημα μηδενικής πιθανότητας, που σημαίνει ότι μια τιμή χαρακτηριστικού στο σύνολο δοκιμής μπορεί να μην εμφανιστεί ποτέ μαζί με μια κλάση στο σύνολο εκπαίδευσης [37]
	Δεν υπάρχει ανάγκη για μεγάλο όγκο δεδομένων για εκπαίδευση [37]	Πρόβλημα συνεχούς χαρακτηριστικού, που σημαίνει ότι όσο πιο συνεχείς ιδιότητες χρησιμοποιούνται, τόσο περισσότερες πληροφορίες χάνονται [37]
	Ανθεκτικό σε θόρυβο και άσχετα χαρακτηριστικά [141]	Υπερευαίσθητος αλγόριθμος σε περιττά δεδομένα και χαρακτηριστικά [37]
kNN Classification	Έχει καλή απόδοση με μεγάλα σύνολα δεδομένων [143]	Μεγάλη χρήση μνήμης, καθώς διατηρεί όλα τα δείγματα εκπαίδευσης στη μνήμη [142]
	Απλή υλοποίηση [136]	Η επιλογή της καλύτερης τιμής της παραμέτρου k είναι περίπλοκη [143]
	Η χρονική πολυπλοκότητα είναι αποδεκτή (γραμμική) [137]	Χαμηλός ρυθμός πρόβλεψης εάν στην παράμετρο k έχει δοθεί σταθερή τιμή [144]

Πίνακας 11 - Πλεονεκτήματα / Μειονεκτήματα Αλγορίθμων Μηχανικής Μάθησης

Τέλος, θα αναφερθούν και οι λόγοι για τους οποίους έγινε η επιλογή για την ανάπτυξη των συγκεκριμένων αλγορίθμων. Η επιλογή της εφαρμογής δύο εποπτευόμενων και δύο αλγορίθμων χωρίς επίβλεψη έγινε κυρίως για δύο λόγους. Αρχικά, για να γίνει η πληρέστερη δυνατή σύγκριση μεταξύ διαφορετικών τύπων αλγορίθμων που ανήκουν στις 2 αναφερόμενες κατηγορίες, καθώς η λήψη δεδομένων μέσω διαφορετικών τύπων αλγορίθμων βοηθά στην εξαγωγή πληρέστερων συμπερασμάτων. Επιπλέον, σε ένα δίκτυο υπολογιστών, καθώς και σε ένα οπτικό δίκτυο, για να επιτευχθεί η καλύτερη δυνατή διαχείριση σε όλες τις πτυχές (κοινή χρήση πόρων, κοινή χρήση εύρους ζώνης κ.λπ.) οι αποφάσεις σχετικά με την απόδοση και τη δομή του κινούνται σε δύο επίπεδα.

Σε πρώτη φάση, η κίνηση του δικτύου μπορεί να αναλυθεί από τους διαχειριστές του, οι οποίοι στη συνέχεια μπορούν να κάνουν τις απαραίτητες τροποποιήσεις, κάτι που επιτυγχάνεται με αλγόριθμους ομαδοποίησης, αλλά ταυτόχρονα το δίκτυο πρέπει να μπορεί να τροποποιεί

σε πραγματικό χρόνο και χωρίς ανθρώπινη παρέμβαση τα χαρακτηριστικά του. Η δίχως ανθρώπινη παρέμβαση αλλαγή των χαρακτηριστικών του δικτύου μπορεί να επιτευχθεί μέσω των εποπτευόμενων αλγόριθμων που έχουν αναπτυχθεί.

Οι συγκεκριμένοι αλγόριθμοι ομαδοποίησης επιλέχθηκαν, καθώς ο kMeans Clustering είναι ο πιο διαδεδομένος αλγόριθμος ικανός να διαχειρίζεται μεγάλους όγκους δεδομένων σε ικανοποιητικό χρόνο, κάτι που συμβαίνει με τον αλγόριθμο miniBatch Clustering, με τη διαφορά ότι εκτελείται ακόμη πιο γρήγορα. Οι αλγόριθμοι Naïve Bayes και kNN Classification επιλέχθηκαν, καθώς επιτυγχάνουν υψηλό βαθμό ακρίβειας και είναι απλοί στην εφαρμογή τους, γεγονός που τους καθιστά από τους πιο ευρέως χρησιμοποιούμενους εποπτευόμενους αλγόριθμους.

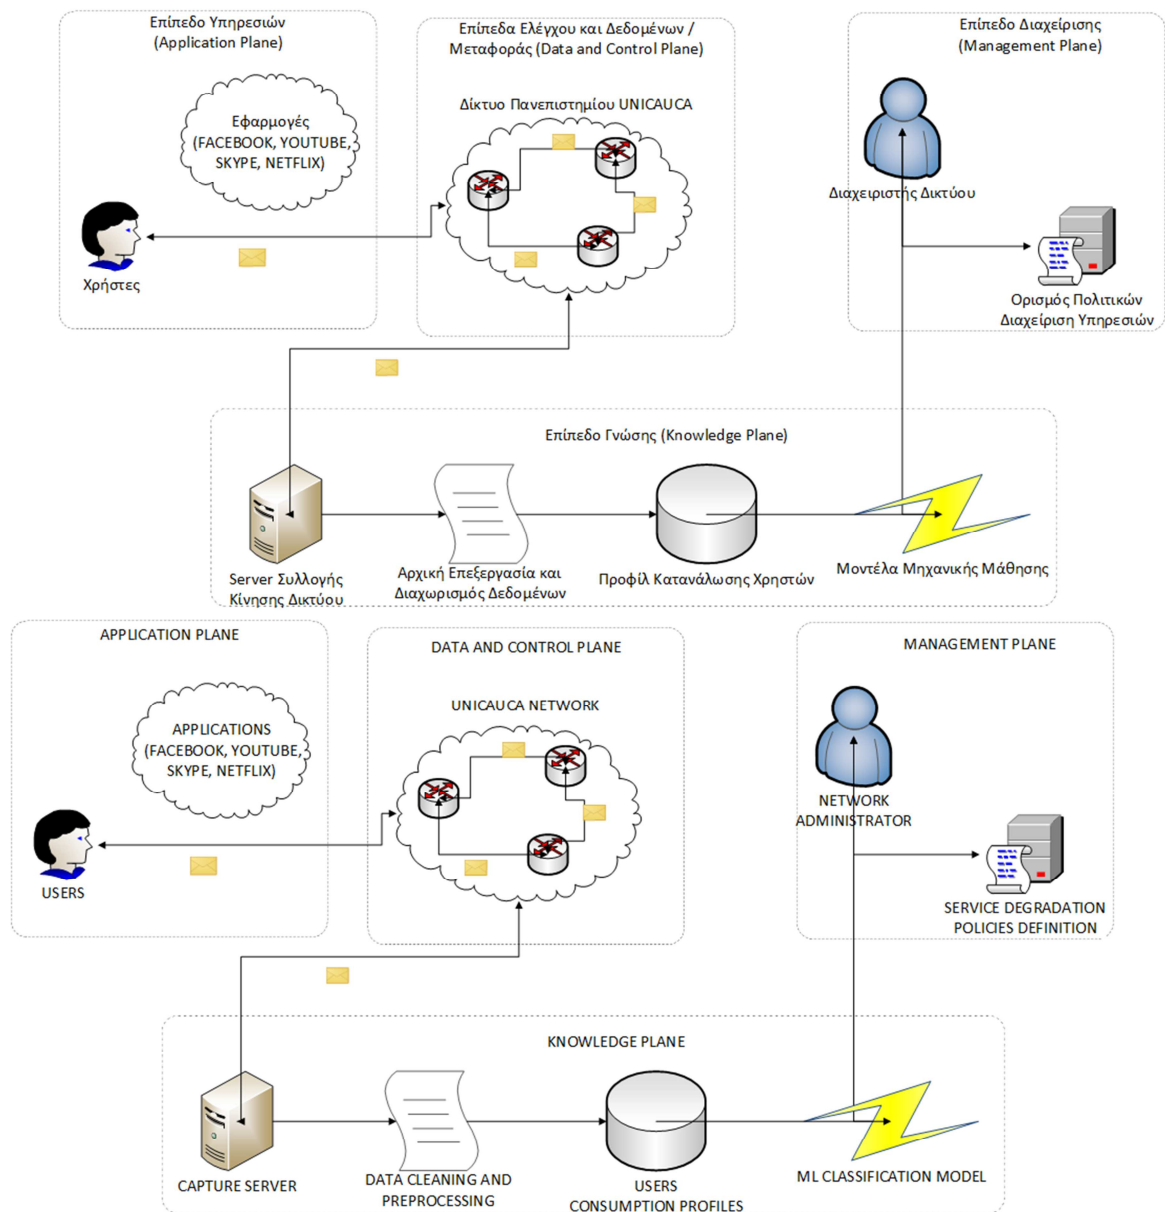
7.2 Χρησιμοποιηθέντα Δεδομένα

Στη συγκεκριμένη ενότητα θα πραγματοποιηθεί ανάλυση του δικτύου από το οποίο τα δεδομένα που χρησιμοποιήθηκαν έχουν εξαχθεί, σε επίπεδο μοντέλου δεδομένων και διάρθρωσης, και ανάλυση των δεδομένων που χρησιμοποιήθηκαν στην υλοποίηση της διπλωματικής εργασίας.

Το δίκτυο, μέσω του οποίου κυκλοφόρησαν όλα τα δεδομένα, το οποίο στη συνέχεια δημιούργησε τη βάση δεδομένων στην οποία έγιναν οι μετρήσεις, είναι ένα δίκτυο του Πανεπιστημίου της Κολομβίας και πιο συγκεκριμένα του Πανεπιστημίου Del Cauca στην πόλη Porayaan της Κολομβίας [183]. Είναι ένα δίκτυο τύπου πελάτη/διακομιστή, το οποίο περιέχει όχι μόνο υπολογιστές αλλά και smartphone και tablet. Δεν υπάρχουν ακριβείς πληροφορίες για την τοπολογία του δικτύου, αλλά έχοντας κατά νου ότι τα δεδομένα έχουν συλλεχθεί από όλες τις συσκευές που έχουν πρόσβαση στο διαδίκτυο, μπορούμε να πούμε με ασφάλεια ότι δεν υπάρχει συγκεκριμένη τοπολογία, αλλά ένας συνδυασμός τοπολογιών με κυρίαρχο σενάριο να είναι η ύπαρξη υβριδικής τοπολογίας, όπου η σύνδεση τύπου δέντρου θα συνδυάζεται με σύνδεση τύπου δακτυλίου και αστέρα,, ώστε να

επιτυγχάνεται πλήρης και γρήγορη πρόσβαση στο δίκτυο από όλους τους χρήστες και τα διαθέσιμα μέσα πρόσβασης.

Σχετικά με την αρχιτεκτονική του δικτύου, μπορεί να αναλυθεί στις περιοχές των στοιχείων (hardware) που έχουν χρησιμοποιηθεί, στον τρόπο μετάδοσης των δεδομένων, τόσο σε επίπεδο υλικού όσο και σε επίπεδο πρωτοκόλλου, καθώς και στον ρυθμό δεδομένων. Σε επίπεδο υλικού, στο δίκτυο υπάρχουν αρκετοί διαθέσιμοι χρήστες που χρησιμοποιούν τόσο τις προσωπικές τους συσκευές όσο και τους υπολογιστές του Πανεπιστημίου για να συνδεθούν στο δίκτυο. Η εφαρμογή wireshark εγκαθίσταται σε κάθε συσκευή δικτύου που χρησιμοποιείται για την καταγραφή της κίνησης, προκειμένου να καταγράφεται λεπτομερώς κάθε ανταλλαγή πληροφοριών συσκευής με το δίκτυο [67]. Η μετάδοση δεδομένων σε επίπεδο υλικού γίνεται τόσο με ενσύρματο τρόπο, χωρίς ειδικότερα να αναφέρεται ο τρόπος ενσύρματης σύνδεσης των κόμβων και συσκευών του δικτύου, εάν γίνεται με χάλκινους αγωγούς ή οπτικές ίνες, όσο και ασύρματα μέσω κατάλληλων δρομολογητών και επαναλήπτων. Όσον αφορά το πρωτόκολλο επικοινωνίας που χρησιμοποιείται σε αυτό το δίκτυο δεν είναι ένα αλλά ένα πλήθος πρωτοκόλλων, όπως FTP, TCP/IP, UDP, HTTPS, Ethernet, αφού υπάρχει ανάγκη για διαφορετικούς τύπους συνδέσεων και μεταφοράς δεδομένων εντός του δικτύου [67]. Πιο αναλυτικά, ο τρόπος με τον οποίο πραγματοποιείται η εξαγωγή δεδομένων φαίνεται στην εικόνα που ακολουθεί [36].



Εικόνα 3- Περιβάλλον Εξαγωγής Δεδομένων

Πρώτα, υπάρχει το επίπεδο εφαρμογής, το οποίο περιέχει τις εφαρμογές των χρηστών του δικτύου και στο οποίο καταγράφονται τα δεδομένα και η κίνηση, το επίπεδο δεδομένων και ελέγχου, που περιέχει όλες τις συσκευές του δικτύου, καθώς και την τοπολογία του δικτύου. Υπάρχει, επίσης, το επίπεδο γνώσης, το οποίο περιέχει έναν πρόσθετο διακομιστή που είναι υπεύθυνος για τη συλλογή της κίνησης του δικτύου, στη συνέχεια, γίνεται η επεξεργασία των δεδομένων και τέλος, υπάρχει το σχέδιο διαχείρισης, όπου οι διαχειριστές του δικτύου είναι υπεύθυνοι για την ομαλή λειτουργία του δικτύου [71]. Ένα σημαντικό στοιχείο της διαμόρφωσης του δικτύου είναι ο ρυθμός μετάδοσης δεδομένων ανά ζεύξη (data

rate). Ο ρυθμός μετάδοσης μπορεί να οριστεί ως το πηλίκο του μέσου μεγέθους ροής σε bits προς τη μέση διάρκεια ροής. Σε αυτό το δίκτυο το μέσο μέγεθος ροής είναι ίσο με 856132.856×10^6 bit και η μέση διάρκεια ροής είναι ίση με 53.613 sec. Άρα ο ρυθμός μετάδοσης ανά σύνδεση δικτύου είναι ίσος με $15968,46 \times 10^6$ bps. Όσον αφορά τα δεδομένα που έχουν συλλεχθεί από το δίκτυο, έχει εγκατασταθεί σε κάθε χρήστη του δικτύου η εφαρμογή wireshark, η οποία καταγράφει όλες τις κινήσεις ενός χρήστη με το δίκτυο [67]. Η καταγραφή έχει γίνει σε διαφορετικές ώρες και ημέρες κατά την περίοδο Απριλίου έως Ιουνίου 2019 και περιλαμβάνει συνολικά 2704839 ροές δεδομένων, όπου για κάθε ροή υπάρχουν 50 διαθέσιμα χαρακτηριστικά [183]. Ο ακόλουθος πίνακας συνοψίζει όλα τα χαρακτηριστικά που σχετίζονται με τις ροές δεδομένων.

Όνομα χαρακτηριστικού	Περιγραφή χαρακτηριστικού	Κατεύθυνση		
		Προς τα εμπρός	Προς τα πίσω	Αμφίδρομη
flow_key	Αναγνωριστικό ροής μέσω ενός αλγόριθμου κατακερματισμού	N.A	N.A	✓
src_ip_numeric	IP πηγής σε δεκαδική μορφή	N.A	N.A	✓
src_ip	IP πηγής σε δικτυακή μορφή	N.A	N.A	✓
src_port	Αριθμός port πηγής	N.A	N.A	✓
dst_ip	IP προορισμού σε δικτυακή μορφή	N.A	N.A	✓
dst_port	Αριθμός port προορισμού	N.A	N.A	✓
proto	Αριθμός πρωτοκόλλου μεταφοράς σύμφωνα με το IANA (π.χ. 1 για ICMP, 6 για TCP)	N.A	N.A	✓
pktTotalCount	Συνολικός αριθμός πακέτων και προς τις δύο κατευθύνσεις	✓	✓	✓
octetTotalCount	Σύνολο byte που ανταλλάσσονται και προς τις δύο κατευθύνσεις, εστιάζοντας μόνο στο ωφέλιμο φορτίο IP	✓	✓	✓
min_ps	Ελάχιστο μέγεθος πακέτου στη ροή	✓	✓	✓
max_ps	Μέγιστο μέγεθος πακέτου στη ροή	✓	✓	✓
avg_ps	Μέσο μέγεθος πακέτου στη ροή	✓	✓	✓
std_dev_ps	Τυπική απόκλιση μεγέθους πακέτου	✓	✓	✓
flowStart	Χρόνος έναρξης ροής σε δευτερόλεπτα χρησιμοποιώντας μορφή ώρας UNIX	✓	✓	✓
flowEnd	Χρόνος λήξης ροής σε δευτερόλεπτα χρησιμοποιώντας τη μορφή ώρας UNIX	✓	✓	✓

flowDuration	Συνολική διάρκεια ροής σε δευτερόλεπτα χρησιμοποιώντας μορφή χρόνου UNIX	✓	✓	✓
min_piat	Ελάχιστος χρόνος ενδιάμεσης άφιξης πακέτων στη ροή	✓	✓	✓
max_piat	Μέγιστος χρόνος ενδιάμεσης άφιξης πακέτων στη ροή	✓	✓	✓
avg_piat	Μέσος χρόνος ενδιάμεσης άφιξης πακέτων στη ροή	✓	✓	✓
std_dev_piat	Τυπική απόκλιση των χρόνων άφιξης πακέτων	✓	✓	✓
flowEndReason	Λόγος για τον οποίο η ροή έληξε και στάλθηκε στον τελικό πίνακα που θα μετατραπεί σε αρχείο csv - 0 ανενεργό χρονικό όριο έληξε - 1 ενεργό χρονικό όριο έληξε - 2 αναγκαστική λήξη λόγω λήξης του αρχείου pcap ή διακοπή της ζωντανής λήψης - Εντοπίστηκε 3 σημαία FIN και στα δύο οδηγίες - Εντοπίστηκε 4 σημαία RST - 5 Σημαία FIN Εντοπίστηκε μόνο σε μία κατεύθυνση και ο χρονοδιακόπτης έληξε	N.A	N.A	✓
category	Κατηγορία της επικοινωνίας όπως παραδόθηκε από το nDPI	N.A	N.A	✓
application_protocol	Πρωτόκολλο εφαρμογής για τη ροή (π.χ. TLS, HTTP, DNS κ.λπ.) που ανιχνεύεται από το nDPI	N.A	N.A	✓
web_service	Υπηρεσία Ιστού που εντοπίστηκε από nDPI (π.χ. Facebook, WhatsApp, Google, κ.λπ.)	N.A	N.A	✓

Πίνακας 12 - Χαρακτηριστικά Ροών Δεδομένων

Από τον προηγούμενο πίνακα που περιέχει τα χαρακτηριστικά κάθε ροής, μπορούμε να συμπεράνουμε ότι τα χαρακτηριστικά αυτά μπορούν να ομαδοποιηθούν σε 5 βασικές κατηγορίες. Αυτές οι κατηγορίες καθώς και μια σύντομη περιγραφή τους δίνονται ακολούθως.

Attribute group	Attributes included	Description
Network Identifiers	flow_key, src_ip_numeric, src_ip, src_port, dst_ip, dst_port, proto	Πληροφορίες που σχετίζονται με την πηγή και τον προορισμό κάθε ροής και πακέτου.
Packet Descriptors	pktTotalCount, octetTotalCount, min_ps, max_ps, avg_ps, std_dev_ps	Πληροφορίες που σχετίζονται με πακέτα που περιέχει κάθε ροή.
Interarrival Times	min_piat, max_piat, avg_piat, std_dev_piat	Πληροφορίες που σχετίζονται με τους χρόνους μεταξύ αφίξεων μεταξύ κατεύθυνσης προς τα εμπρός και προς τα πίσω για κάθε ροή.
Flow Descriptors	flowStart, flowEnd, flowDuration, flowEndReason	Πληροφορίες σχετικά με την εγκατάσταση και τον τερματισμό κάθε ροής.
Application Descriptors	Category, application_protocol, web_service	Πληροφορίες που σχετίζονται με την εφαρμογή προορίζεται για κάθε ροή.

Πίνακας 13 - Ομαδοποίηση Χαρακτηριστικών Ροών Δεδομένων

7.3 Περιγραφή Τρόπου Υλοποίησης

Στο κεφάλαιο αυτό θα πραγματοποιηθεί παρουσίαση του τρόπου υλοποίησης του πειραματικού σκέλους της εργασίας. Αρχικά, θα αναφερθούν τα τεχνικά χαρακτηριστικά που χρησιμοποιήθηκαν, δηλαδή το λειτουργικό σύστημα και τα προγράμματα, και στη συνέχεια θα γίνει μια σύντομη παρουσίαση του τρόπου με τον οποίο αναπτύχθηκε ο κώδικας.

Η ανάπτυξη των αλγορίθμων μηχανικής μάθησης που χρησιμοποιήθηκαν πραγματοποιήθηκε σε λειτουργικό σύστημα Windows 10 x64. Ο υπολογιστής διαθέτει επεξεργαστή Intel(R) Core(TM) i5-3470 CPU @ 3.20GHz x 4, κάρτα γραφικών NVIDIA GeForce GTX 650 και 8,00 GB RAM. Για την ανάπτυξη του κώδικα χρησιμοποιήθηκε η πλατφόρμα προγραμματισμού PyCharm – Professional v. 2021.2.2. Ως γλώσσα προγραμματισμού επιλέχθηκε η Python v.3.10.0, αφού θεωρείται από τις πιο ευέλικτες γλώσσες προγραμματισμού για ζητήματα μηχανικής μάθησης. Πέραν των ενσωματωμένων βιβλιοθηκών της Python έγινε χρήση και των κάτωθι βιβλιοθηκών:

- ✓ Pandas: χρησιμοποιείται για τον χειρισμό και την ανάλυση δεδομένων μέσω της χρήσης dataframes, όπου το αρχείο που περιέχει τα δεδομένα μετατρέπεται σε dataframe για την καλύτερη επεξεργασία του από το πρόγραμμα [185].
- ✓ Numpy: χρησιμοποιείται, κυρίως, όταν πρέπει να γίνει επεξεργασία πινάκων μεγάλου μεγέθους και πολλών διαστάσεων, διαθέτοντας πληθώρα μαθηματικών συναρτήσεων, σχετικών με την επεξεργασία των πινάκων αυτών [185].
- ✓ CSV: η συγκεκριμένη βιβλιοθήκη παρέχει μεθόδους σχετικές με την ανάγνωση και επεξεργασία αρχείων τύπου csv, ένας τύπος αρχείου που είναι αρκετά διαδεδομένος όταν έχουμε δεδομένα που χρησιμοποιούνται από αλγορίθμους Μηχανικής Μάθησης [186].

- ✓ Matplotlib: η εν λόγω βιβλιοθήκη χρησιμοποιείται για την απεικόνιση των δεδομένων και των αποτελεσμάτων επεξεργασίας τους μέσω της δημιουργίας γραφημάτων διάφορων τύπων [187].
- ✓ Scikit-learn: αποτελεί μια βιβλιοθήκη Μηχανικής Μάθησης που κάνει χρήση της βιβλιοθήκης numpy, και περιέχει αλγορίθμους clustering, regression και classification. Μέσω της βιβλιοθήκης αυτής μπορούν να υλοποιηθούν αρκετοί αλγόριθμοι Μηχανικής Μάθησης, ρυθμίζοντας κάθε φορά τις κατάλληλες παραμέτρους [188].
- ✓ Keras: χρησιμοποιείται για τη δημιουργία νευρωνικών δικτύων, καθώς και για την αναγκαία ρύθμιση των παραμέτρων τους [189]. Υπάρχει δυνατότητα να λειτουργήσει πάνω από άλλες βιβλιοθήκες της Python, όπως για παράδειγμα τις βιβλιοθήκες TensorFlow και Theano.

Στη συνέχεια, θα παρουσιαστεί τόσο ο κώδικας συνοπτικά όσο και επιμέρους σημεία του κώδικα.

- Κώδικας Αρχείου Main:

Ανάγνωση αρχείου δεδομένων
 Δημιουργία κατάλληλων label
 Διαγραφή μη αναγκαίων δεδομένων
 Υλοποίηση αλγορίθμων Μηχανικής Μάθησης
 Υπολογισμός μετρικών throughput, drop rate
 Δημιουργία γραφημάτων
 Υπολογισμός μετρικής delay time
 Δημιουργία γραφημάτων

Κώδικας 1 - Αρχείο Main

Αρχικά, γίνεται ανάγνωση του αρχείου που περιέχει τα δεδομένα, ώστε στη συνέχεια να γίνουν όλοι οι απαραίτητοι υπολογισμοί και διεργασίες. Έπειτα, δημιουργούνται οι απαραίτητες ετικέτες (labels) που είναι απαραίτητες για τους μετέπειτα υπολογισμούς. Οι ετικέτες αυτές αφορούν στις πόρτες έναρξης και προορισμού κάθε ροής δεδομένων, τη διάρκεια και τη μοναδικότητα κάθε ροής και τέλος τους αλγορίθμους μηχανικής μάθησης. Ακολούθως, γίνεται υπολογισμός των

δύο πρώτων μετρικών που χρησιμοποιούνται στην παρούσα εργασία και είναι οι μετρικές throughput και drop rate και απεικονίζονται μέσω γραφημάτων. Καταλήγοντας, υπολογίζεται και η τελευταία μετρική, το delay time και απεικονίζεται και αυτή μέσω γραφημάτων.

Στο υπόλοιπο του κεφαλαίου θα παρουσιαστεί ο κώδικας κάθε αρχείου με τη μορφή ψευδοκώδικα και θα γίνει μια σύντομη ανάλυση του.

- Κώδικας Αρχείου labelingCSV:

Δημιουργία ετικέτας σχετικά με το source port (τιμή 0 αν source port == 0, αλλιώς τιμή 1)

Δημιουργία ετικέτας σχετικά με το destination port (τιμή 0 αν destination port == 0, αλλιώς τιμή 1)

Δημιουργία ετικέτας σχετικά με τη διάρκεια ροής (τιμή 0 αν flow duration == 0, αλλιώς τιμή 1)

Δημιουργία ετικέτας σχετικά με τη μοναδικότητα ροής (τιμή 0 αν η ροή δεν είναι μοναδική, αλλιώς τιμή 1)

Δημιουργία ετικέτας σχετικά με clustering αλγόριθμο (τιμή 0 αν μέγεθος ροής <65 bytes, 1 αν μέγεθος < 552, αλλιώς 2)

Δημιουργία ετικέτας σχετικά με classification αλγόριθμο (τιμή 0 αν μέγεθος ροής < 552, αλλιώς 1)

Κώδικας 2 - Αρχείο labelingCSV

Στο αρχείο labelingCSV δημιουργούνται όλες οι αναγκαίες ετικέτες που θα χρησιμοποιηθούν στη συνέχεια της υλοποίησης. Αρχικά, εξετάζεται αν η πόρτα πηγής είναι 0, δηλαδή η ροή δεν έχει ξεκινήσει καν για τον προορισμό της και δημιουργείται το αντίστοιχο label. Αντίστοιχα, δημιουργείται η κατάλληλη ετικέτα αναλόγως με το αν η πόρτα προορισμού έχει τιμή 0, δηλαδή αν η ροή δεν έφτασε ποτέ στον προορισμό της. Με την ίδια διαδικασία δημιουργούνται τα labels σχετικά με τη διάρκεια κάθε ροής, όπου έχουμε τιμή 0 αν η ροή δεν έχει διάρκεια, δηλαδή για κάποιο λόγο δεν ξεκίνησε για τον προορισμό της, τη μοναδικότητα κάθε ροής, όπου έχουμε τιμή 1 αν η ροή εμφανίζεται μόνο μια φορά, και τους αλγορίθμους clustering και classification, όπου αναλόγως του μεγέθους κάθε ροής τοποθετείται και το αντίστοιχο label. Οι τελευταίες ετικέτες, εκτός από τη χρήση κατά τη διάρκεια

του υπόλοιπου προγράμματος, χρησιμεύουν ώστε να γίνει και μια αποτίμηση της απόδοσης όσων αλγορίθμων δεν διαθέτουν τέτοιες συναρτήσεις.

- Κώδικας Αρχείου rowsDelete:

Διαγραφή όσων δεδομένων έχουν source και destination port == 0.

Διαγραφή όσων δεδομένων έχουν destination port == 0.

Κώδικας 3 - Αρχείο rowsDelete

Στο αρχείο rowsDelete πραγματοποιείται διαγραφή όσων δεδομένων έχουν ως πόρτα πηγής και προορισμού με τιμή 0, δηλαδή αποτελούν ροές τις οποίες το δίκτυο δεν έστειλε σε κάποιον κόμβο του και δεν είχε σκοπό να στείλει, καθώς πιθανότατα αποτελούσαν δοκιμαστικά πακέτα. Στη συνέχεια, διαγράφονται τα δεδομένα με πόρτα προορισμού με τιμή 0, που συνεπάγεται ότι είναι δεδομένα που για κάποιον λόγο δεν έφτασαν ποτέ στον προορισμό τους, οπότε δεν χρησιμεύουν στους μετέπειτα υπολογισμούς.

- Κώδικας Αρχείου machineLearningAlgorithms:

Προετοιμασία δεδομένων για την υλοποίηση των αλγορίθμων

Υλοποίηση kMeans Clustering αλγορίθμου

Υλοποίηση miniBatch Clustering αλγορίθμου

Υλοποίηση Naïve Bayes Classification αλγορίθμου

Δημιουργία 7 μικρότερων αρχείων με τα δεδομένα

Υλοποίηση kNN Classification αλγορίθμου σε κάθε αρχείο από τα 7 μικρότερα

Προσθήκη των αποτελεσμάτων στο αρχικό αρχείο

Κώδικας 4 - Αρχείο machineLearningAlgorithms

Στο machineLearningAlgorithms αρχείο, αρχικά, γίνεται η απαραίτητη διαδικασία προετοιμασίας των δεδομένων πριν αυτά χρησιμοποιηθούν στους αλγορίθμους μηχανικής μάθησης. Πιο συγκεκριμένα, αρχικά μετατρέπονται όσα δεδομένα δεν είναι σε μορφή ακεραίου σε αυτή την μορφή, αφού όλοι οι υπολογισμοί στους αλγορίθμους γίνονται με δεδομένα τύπου ακεραίου. Ακολούθως, υλοποιείται ο αλγόριθμος kMeans, όπου στο τέλος αποθηκεύεται σε ποιο cluster ανήκει κάθε ροή. Πρέπει να τονιστεί ότι ο εντοπισμός των πιο

κατάλληλων παραμέτρων για κάθε αλγόριθμο έχει υλοποιηθεί σε διαφορετικό αρχείο πριν την υλοποίηση των αλγορίθμων μηχανικής μάθησης. Στην πορεία, υλοποιούνται οι αλγόριθμοι miniBatch Clustering και Naïve Bayes Classification, όπου και για αυτούς αποθηκεύεται τόσο σε ποιο cluster ανήκει κάθε ροή στην περίπτωση του miniBatch, όσο και η πρόβλεψη που πραγματοποιεί ο Naïve Bayes σχετικά με το μέγεθος κάθε ροής. Στον αλγόριθμο Naïve Bayes τα δεδομένα χωρίζονται σε training και test set σε αναλογία 70% και 30%, τα δεδομένα τυποποιούνται κι ύστερα παράγονται τα labels. Λόγω της μεγάλης υπολογιστικής ισχύος που απαιτείται για την υλοποίηση του kNN αλγορίθμου, τα δεδομένα χωρίστηκαν σε 7 μικρότερα αρχεία, στα οποία έτρεξε ο kNN αλγόριθμος, παρήγαγε τα labels, τα οποία εν συνεχεία ενοποιήθηκαν εκ νέου, ώστε να εισαχθούν στο αρχικό αρχείο.

- Κώδικας Αρχείου loadAndThroughputCSVCreation:

Ταξινόμηση δεδομένων βάσει στιγμής έναρξης ροής

Δημιουργία νέων αρχείων με την ύπαρξη μόνο των απαραίτητων χαρακτηριστικών κάθε ροής

Δημιουργία αρχείων για κάθε label κάθε αλγορίθμου Μηχανικής Μάθησης

Δημιουργία αρχείων για τα δεδομένα που θα απεικονιστούν στα γραφήματα.

Κώδικας 5 - Αρχείο loadAndThroughputCSVCreation

Στο loadAndThroughputCSVCreation αρχείο το πρώτο βήμα είναι να ταξινομηθούν όλα τα δεδομένα, σύμφωνα με τη χρονική στιγμή έναρξης της ροής. Αυτό χρησιμεύει, διότι υπάρχουν ροές που δεν είναι μοναδικές, οπότε όταν στα επόμενα βήματα τα δεδομένα θα αντιγραφούν σε νέα αρχεία, θα πρέπει να γίνει με τέτοιο τρόπο, ώστε να υπάρχει μια συγκεκριμένη σειρά. Έπειτα, δημιουργούνται 10 αρχεία, εκ των οποίων 3 αφορούν στον αλγόριθμο kMeans, 3 στον αλγόριθμο miniBatch, 2 στον αλγόριθμο Naïve Bayes και 2 στον αλγόριθμο kNN, δηλαδή έχουμε ένα αρχείο για κάθε label κάθε αλγορίθμου. Στα αρχεία αυτά μεταφέρονται όσα δεδομένα αφορούν το αντίστοιχο label κάθε αλγορίθμου και από τα δεδομένα αυτά μόνο όσα χαρακτηριστικά θα χρησιμεύσουν σε μεταγενέστερους

υπολογισμούς. Αντίστοιχα, δημιουργούνται 10 κενά αρχεία, ένα για κάθε label κάθε αλγορίθμου, όπου θα τοποθετηθούν αργότερα τιμές που είναι απαραίτητες για τη δημιουργία των γραφημάτων.

- Κώδικας Αρχείου loadAndThroughputCalculation:

Υπολογισμός κίνησης δικτύου ανά 50sec

Διαγραφή όσων χρονικών στιγμών δεν περιέχουν κίνηση δικτύου

Υπολογισμός window load per second

Υπολογισμός throughput per second

Κώδικας 6 - Αρχείο loadAndThroughputCalculation

Το αρχείο loadAndThroughputCalculation υπολογίζει όλες τις απαραίτητες μεταβλητές που θα χρησιμοποιηθούν στη δημιουργία των γραφημάτων. Αρχικά, υπολογίζεται το φορτίο που μεταφέρεται μέσα στο δίκτυο ανά 50sec. Επιλέχθηκε η τιμή αυτή, καθώς είναι η μέση τιμή της διάρκειας των ροών του δικτύου. Στη συνέχεια, για όσα χρονικά διαστήματα (windows) δεν υπάρχει φορτίο, δηλαδή για όσα window δεν έχουν μεταφερθεί δεδομένα εντός της χρονικής διάρκειάς τους, διαγράφονται. Ακολούθως, υπολογίζεται το φορτίο ανά δευτερόλεπτο και η διαμετακομιστική ικανότητα ανά δευτερόλεπτο. Όλοι οι προαναφερθέντες υπολογισμοί εισάγονται στα αντίστοιχα αρχεία για τη μετέπειτα χρήση τους.

- Κώδικας Αρχείου lineGraphicPerSecondCreation:

Υπολογισμός μέσου όρου κίνησης δικτύου ανά 1Gbps

Υπολογισμός throughput ανά 1Gbps

Υπολογισμός drop rate ανά 1Gbps

Δημιουργία γραφημάτων

Κώδικας 7 - Αρχείο lineGraphicPerSecondCreation

Η δημιουργία των γραφημάτων που αφορούν τις μετρικές throughput και drop rate γίνεται στο αρχείο lineGraphicPerSecondCreation. Αρχικά, υπολογίζεται ο μέσος όρος της κίνησης του δικτύου ανά 1Gbps, δηλαδή υπολογίζεται η κίνηση μέχρι 1Gbps, στην συνέχεια μεταξύ 1Gbps – 2Gbps κ.ο.κ μέχρι τα 13Gbps. Αντίστοιχα, υπολογίζονται και οι τιμές για throughput και drop rate.

Δημιουργούνται όλα τα απαραίτητα γραφήματα, τα οποία παρουσιάζονται στο επόμενο κεφάλαιο.

- Κώδικας Αρχείου delayCalculation:

Ταξινόμηση δεδομένων βάσει flow_key, τιμή των labels και στιγμή έναρξης ροής

Εύρεση όσων ροών δεν είναι μοναδικές

Υπολογισμός ενδιάμεσων μεταβλητών για τελικό υπολογισμό καθυστέρησης

Υπολογισμός καθυστέρησης ανά ροή

Κώδικας 8 - Αρχείο delayCalculation

Στο delayCalculation υπολογίζεται η καθυστέρηση κάθε ροής. Αρχικά πραγματοποιείται ταξινόμηση βάσει του χαρακτηριστικού αναγνώρισης κάθε ροής, της τιμής των labels ανά αλγόριθμο και τέλος ανά στιγμή έναρξης κάθε ροής. Αυτό συμβαίνει, διότι είναι απαραίτητο για τα επόμενα δύο βήματα στα οποία υπολογίζονται απαραίτητες μεταβλητές που είναι αναγκαίες για τον τελικό υπολογισμό της καθυστέρησης. Ακολούθως, γίνεται εντοπισμός όσων ροών δεν είναι μοναδικές αλλά εμφανίζονται τουλάχιστον δύο φορές και στη συνέχεια υπολογίζονται κάποιες μεταβλητές ώστε να υλοποιηθεί και ο υπολογισμός της καθυστέρησης κάθε ροής που είναι και το τελικό βήμα. Στο σημείο αυτό πρέπει να τονιστεί ότι ως καθυστέρηση έχει οριστεί ο χρόνος αναμονής στην ουρά (queuing buffer).

- Κώδικας Αρχείου delayStatisticsComputation:

Υπολογισμός delay per second

Υπολογισμός delay ανά 1Gbps

Δημιουργία γραφημάτων

Κώδικας 9 - Αρχείο delayStatisticsComputation


Στο αρχείο delayStatisticsComputation, που είναι και το τελευταίο της υλοποίησης, δημιουργούνται τα γραφήματα σχετικά με τη καθυστέρηση. Έχοντας υπολογίσει το window load per second και window load ανά 1Gbps σε προηγούμενα αρχεία, όπως επίσης και το delay από κάθε ροή, το τελευταίο βήμα είναι ο υπολογισμός της καθυστέρησης ανά sec και ανά 1Gbps. Στο τελευταίο βήμα δημιουργούνται και τα γραφήματα που απεικονίζονται στο επόμενο κεφάλαιο.

7.4 Αποτελέσματα Μετρήσεων (Μελέτης)

Προτού παρουσιαστούν τα αποτελέσματα της υλοποίησης, κρίνεται σκόπιμο να αναφερθούν ποιες είναι οι μετρικές που χρησιμοποιήθηκαν, δίνοντας έναν όρισμο για την καθεμία.

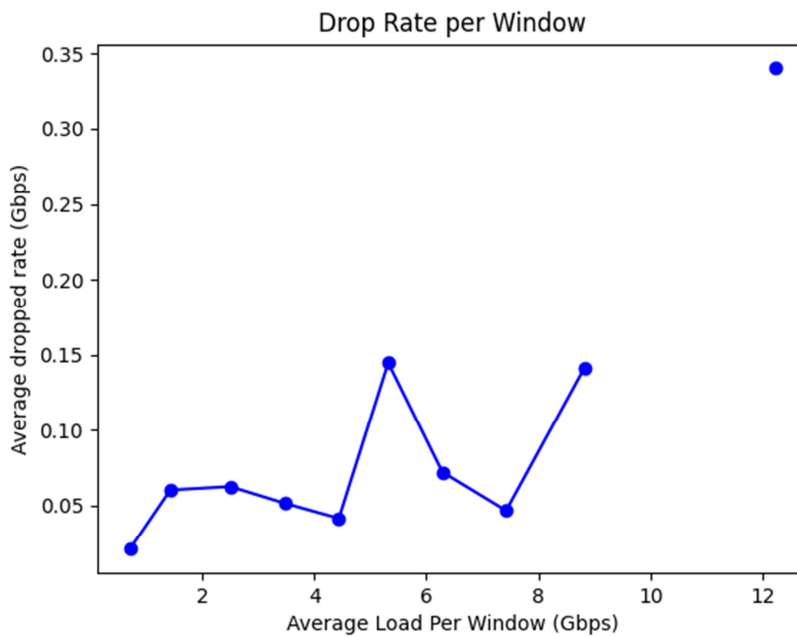
- Throughput: Με τον όρο throughput εννοούμε τη ποσότητα πληροφοριών σε bits που μπορεί να περάσει μέσα από ένα δίκτυο σε μια ορισμένη χρονική περίοδο [190], ενώ μπορεί επίσης να οριστεί ως ο όγκος πληροφοριών που διέρχεται από το δίκτυο σε μια συγκεκριμένη χρονική περίοδο[191].
- Drop rate: Το drop rate ορίζεται ως ο όγκος των πληροφοριών που δεν έφτασε στον προορισμό ανεξάρτητα από τον λόγο, ενώ μπορεί επίσης να οριστεί ως ο όγκος των πληροφοριών που δεν προωθήθηκαν στον προορισμό τους στη μονάδα χρόνου [192].
- Delay: Ως καθυστέρηση ορίζουμε τον χρόνο που απαιτείται για μια ροή να φτάσει στον προορισμό της, έχοντας προσθέσει τυχόν καθυστερήσεις που μπορεί να έχει συναντήσει σε ενδιάμεσους κόμβους ή στην πορεία της, όπως ο χρόνος αναμονής στην ουρά [193].

Παρακάτω θα παρουσιαστούν οι τιμές που μετρήθηκαν για τις μετρικές απόδοσης στο αρχικό αρχείο πριν από τη χρήση αλγορίθμων μηχανικής εκμάθησης. Θα παρουσιαστούν, επίσης, μέτρα απόδοσης, πιο αναλυτικά το throughput, το drop rate και ο χρόνος καθυστέρησης. Σχετικά με την ρυθμοαπόδοση, παρατηρείται ότι δεν υπάρχουν τιμές για φορτίο μεταξύ 8-12 Gbps, αφού σε αυτές τις τιμές δεν υπάρχουν ροές στο δίκτυο με αυτό το φορτίο. Οι τιμές της ρυθμοαπόδοσης είναι πολύ κοντά στις τιμές του φορτίου παραθύρου, όπως φαίνεται στην *Εικόνα 5* που ακολουθεί, γεγονός που μας οδηγεί στο συμπέρασμα ότι το δίκτυο καταφέρνει να μεταφέρει πολύ ικανοποιητικά τον όγκο των πληροφοριών που απαιτείται για αποστολή.



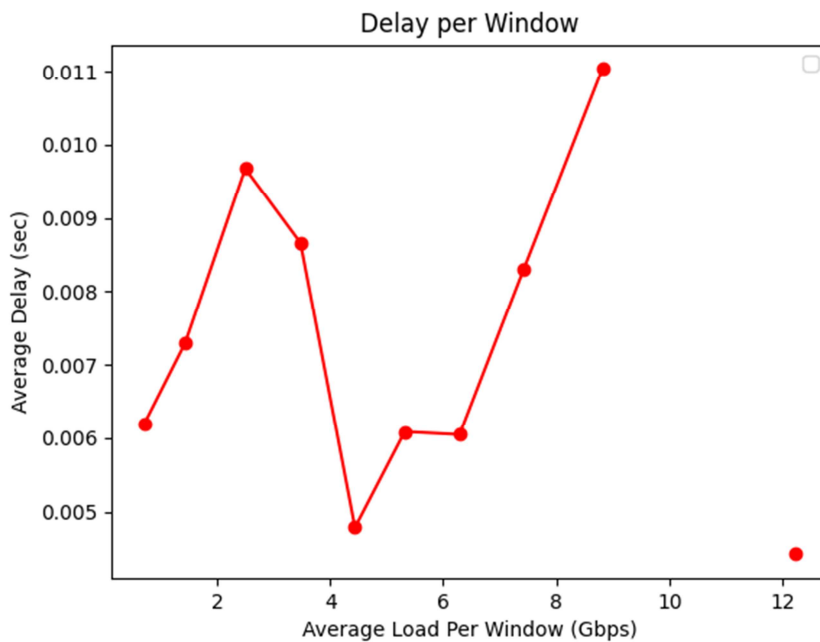
Εικόνα 4 - Throughput Per Window

Σχετικά με το drop rate, και σε αυτή την περίπτωση δεν υπάρχουν τιμές για φόρτο 8-12 Gbps, αφού δεν υπάρχουν ροές στο δίκτυο με αυτό το φορτίο. Οι τιμές του ρυθμού απόρριψης είναι αρκετά χαμηλές, κάτι θετικό για την ικανότητα του δικτύου να μην "χάνει" πακέτα αλλά να μεταδίδει σωστά τις περισσότερες πληροφορίες, κάτι που φαίνεται στην *Εικ. 6*. Το γεγονός ότι στην περιοχή των 8-12 Gbps δεν υπάρχουν δεδομένα προς απεικόνιση είναι αναμενόμενο, αφού και στο γράφημα της ρυθμοαπόδοσης παρατηρήθηκε ότι δεν υπήρχαν ροές σε αυτό το εύρος. Επιπρόσθετα, όσο περισσότερο είναι το φορτίο τόσο μεγαλύτερο είναι και το drop rate, κάτι αναμενόμενο αφού υπάρχουν περισσότερα δεδομένα προς μετάδοση, άρα θα είναι και περισσότερα αυτά που θα απορριφθούν, με εξαίρεση την περιοχή των 5 Gbps, όπου υπάρχει μια άνοδος στην τιμή του drop rate. Αυτή η αύξηση οφείλεται πιθανώς ότι στο συγκεκριμένο εύρος φορτίου υπήρχαν πολλά πακέτα σχετικά με την κατάσταση του δικτύου, όπως επίσης και δοκιμαστικά πακέτα, τα οποία δεν είχαν υψηλή προτεραιότητα μετάδοσης, με αποτέλεσμα να μη μεταδοθούν και να αυξήσουν το drop rate.



Εικόνα 5- Drop Rate Per Window


Τέλος, όσον αφορά τον χρόνο καθυστέρησης, σε αυτό το μέτρο απόδοσης στην *Εικ. 7* που ακολουθεί, μπορούμε να παρατηρήσουμε ότι κυμαίνεται σε χαμηλά επίπεδα, ένα άλλο στοιχείο που δείχνει ότι το δίκτυο διαχειρίζεται αποτελεσματικά τον όγκο των πληροφοριών που απαιτείται. Και σε αυτό το γράφημα δεν υπάρχουν τιμές στην περιοχή 8-12 Gbps, κάτι αναμενόμενο, αφού όπως αναφέρθηκε ήδη, δεν υπάρχουν ροές σε αυτή την περιοχή. Παρατηρείται ότι η καθυστέρηση έχει υψηλές τιμές στις περιοχές των 3 Gbps και 8 Gbps, κάτι που υποδηλώνει ότι στις περιοχές αυτές τα πακέτα προς μετάδοση ήταν περισσότερα από αυτά που μπορούσε το δίκτυο να διαχειριστεί τη δεδομένη στιγμή.




Εικόνα 6 - Delay Duration Per Window

Στη συνέχεια, θα παρουσιαστούν τα γραφήματα που απεικονίζουν τη σχετική διακύμανση των μέτρων απόδοσης για ρυθμοαπόδοση, ρυθμό απόρριψης και χρόνο καθυστέρησης, για όλους τους αλγόριθμους μηχανικής μάθησης που εφαρμόζονται, kMeans Clustering, mini Clustering, Naïve Bayes Classification, kNN Classification.


Όσον αφορά τον αλγόριθμο kMeans, όπως φαίνεται στις *Εικ. 8*, *Εικ. 9*, *Εικ. 10*, *Εικ. 11*, παρατηρούμε ότι όσον αφορά τη ρυθμοαπόδοση και τον ρυθμό απόρριψης, οι ετικέτες 1 και 2 επιτυγχάνουν καλά αποτελέσματα, σε αντίθεση με την ετικέτα 0 όπου περιέχει ελάχιστες ροές, και τα αποτελέσματά του δεν μπορούν να χρησιμοποιηθούν για την εξαγωγή συμπερασμάτων. Αντίστοιχα για το χρόνο καθυστέρησης, η ετικέτα 0 δεν περιέχει αρκετές τιμές για την εξαγωγή συμπερασμάτων, ενώ η ετικέτα 1 επιτυγχάνει χαμηλότερες τιμές χρόνου καθυστέρησης σε σύγκριση με την ετικέτα 2.



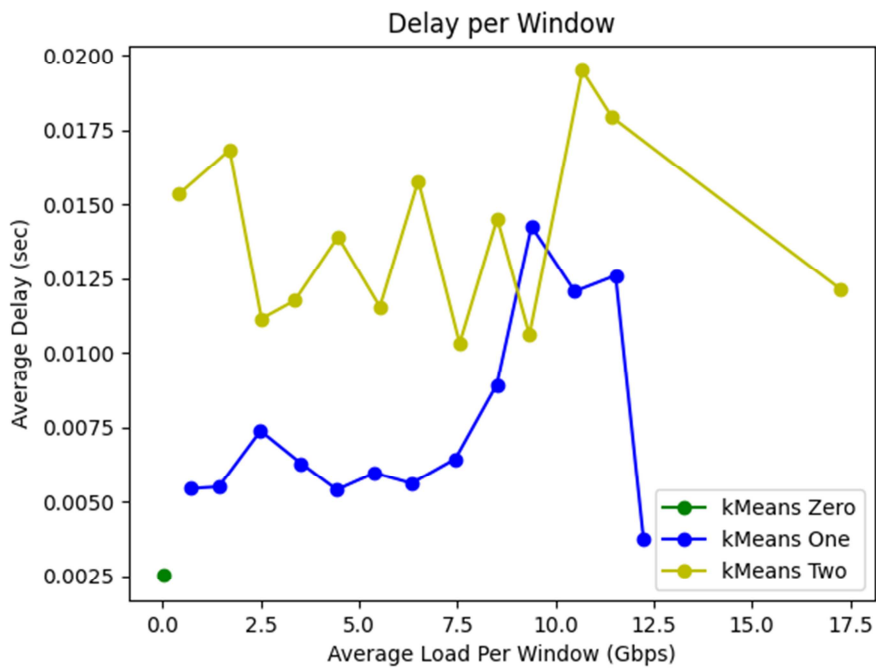
Εικόνα 7 - Throughput and Drop Rate Pwe Window, kMeans Zero Cluster



Εικόνα 8 - Throughput and Drop Rate Per Window, kMeans One Cluster




Εικόνα 9 - Throughput and Drop Rate Per Window, kMeans Two Cluster




Εικόνα 10 - Delay Time Per Window, kMeans

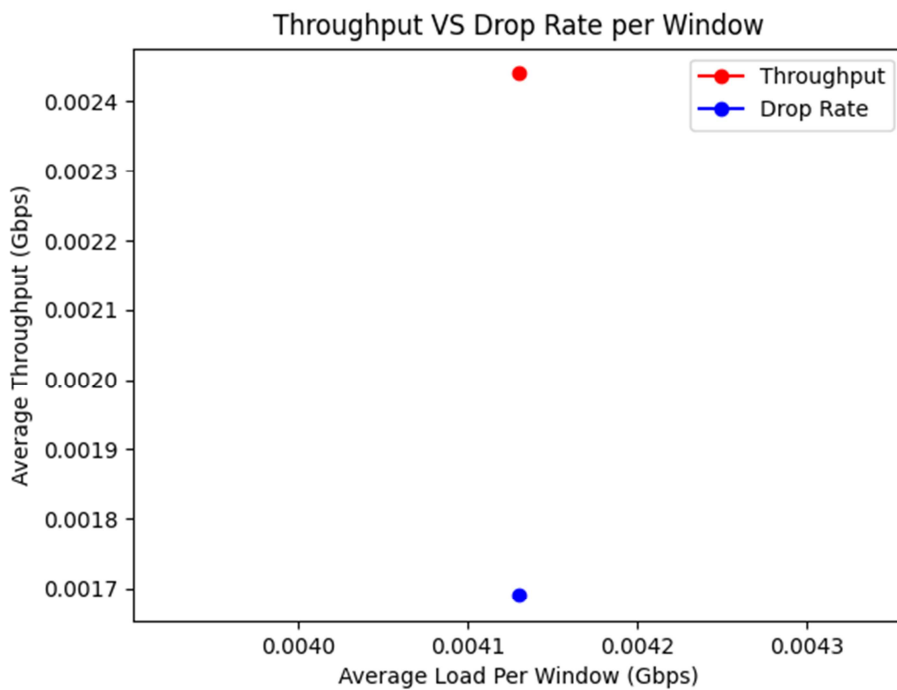
Αντίστοιχα, στον αλγόριθμο miniBatch Clustering, στις *Εικ. 12, Εικ. 13, Εικ. 14, Εικ. 15*, παρατηρούμε ότι τόσο στις τιμές ρυθμοαπόδοσης όσο και στις τιμές του ρυθμού απόρριψης οι ετικέτες 0 και 1 επιτυγχάνουν καλά αποτελέσματα, σε αντίθεση με την ετικέτα 2 για τα οποία δεν υπάρχουν αρκετά δεδομένα για εμφάνιση. Το ίδιο συμβαίνει και με το χρόνο καθυστέρησης, όπου στην ετικέτα 2 δεν υπάρχουν αρκετά δεδομένα, ενώ στην ετικέτα 0 έχουμε καλύτερη απόδοση για τη συγκεκριμένη μέτρηση απόδοσης.



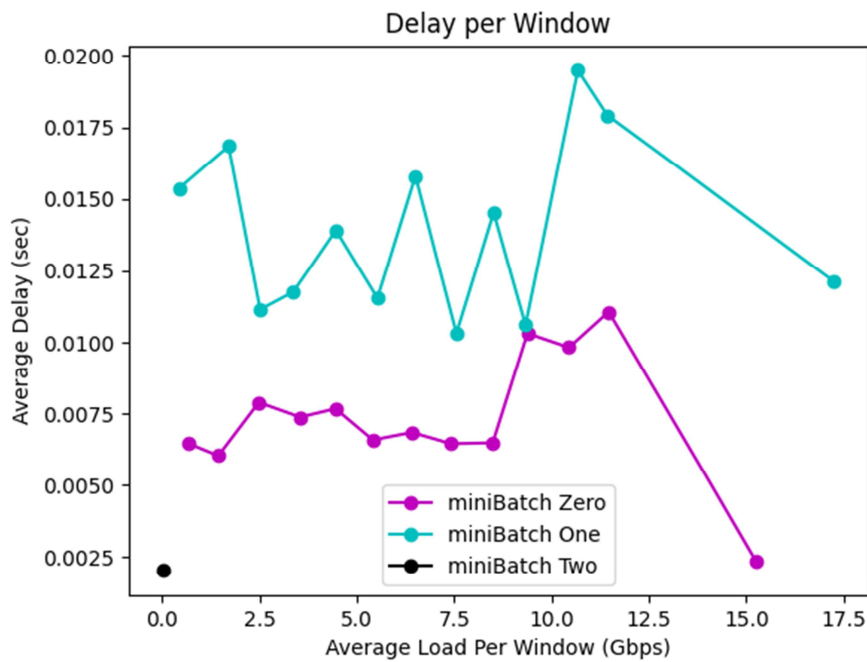
Εικόνα 11 -Throughput and Drop Rate Per Window, miniBatch Zero Cluster



Εικόνα 12 - Throughput and Drop Rate Per Window, miniBatch One Cluster




Εικόνα 13 - Throughput and Drop Rate Per Window, miniBatch Two Cluster




Εικόνα 14 - Delay Time Per Window, miniBatch

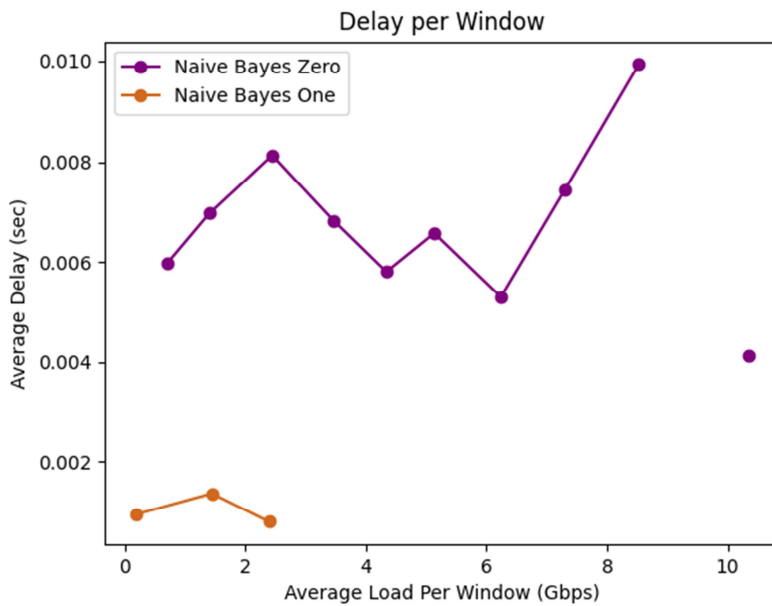
Στον αλγόριθμο Naïve Bayes, στην ετικέτα 1 τα δεδομένα είναι αρκετά μικρά για την ρυθμοαπόδοση των μετρήσεων και τον ρυθμό απόρριψης, *Εικ. 16, Εικ. 17*, σε αντίθεση με την ετικέτα 0, όπου υπάρχουν αρκετά δεδομένα και οι τιμές τους είναι σε κανονικά επίπεδα. Το ίδιο συμβαίνει και με τον μετρικό χρόνο καθυστέρησης, όπου στην ετικέτα 0 έχουμε περισσότερα δεδομένα από την ετικέτα 1 και ο χρόνος καθυστέρησης δεν έχει υψηλές τιμές, όπως φαίνεται στην *Εικ. 18*.



Εικόνα 15 - Throughput and Drop Rate Per Window, Naive Bayes Zero Cluster




Εικόνα 16 - Throughput and Drop Rate Per Window, Naive Bayes One Cluster




Εικόνα 17- Delay Time Per Window, Naive Bayes

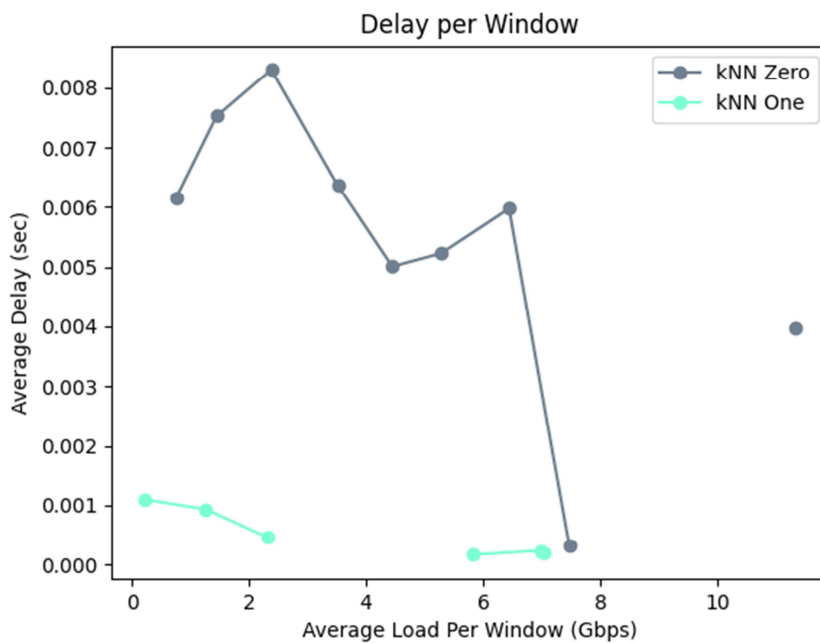
Τέλος, στον αλγόριθμο kNN, όπως φαίνεται στις *Εικ. 19*, *Εικ. 20*, *Εικ. 21*, παρατηρούνται τα ίδια αποτελέσματα που είχαμε στον αλγόριθμο Naïve Bayes, δηλαδή στην ετικέτα 0 να έχουμε αρκετά δεδομένα για εμφάνιση, σε αντίθεση με την ετικέτα 1, για όλες τις μετρήσεις που έχουν υπολογιστεί.



Εικόνα 18 - Throughput and Drop Rate Per Window, kNN Zero Cluster

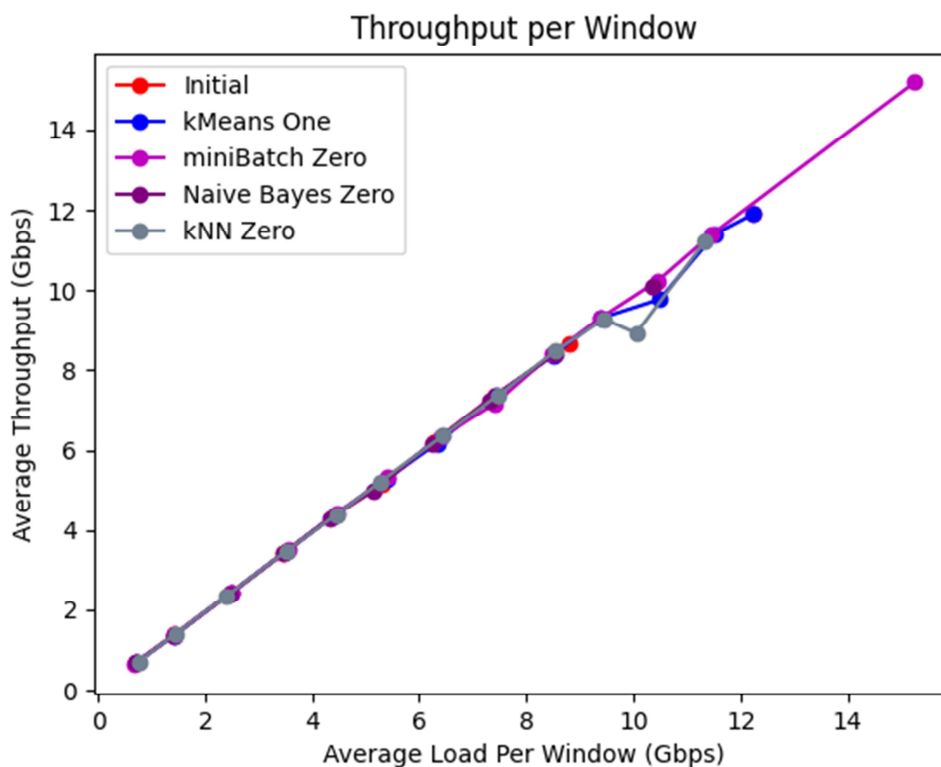


Εικόνα 19 - Throughput and Drop Rate Per Window, kNN One Cluster



Εικόνα 20 - Delay Time Per Window, kNN

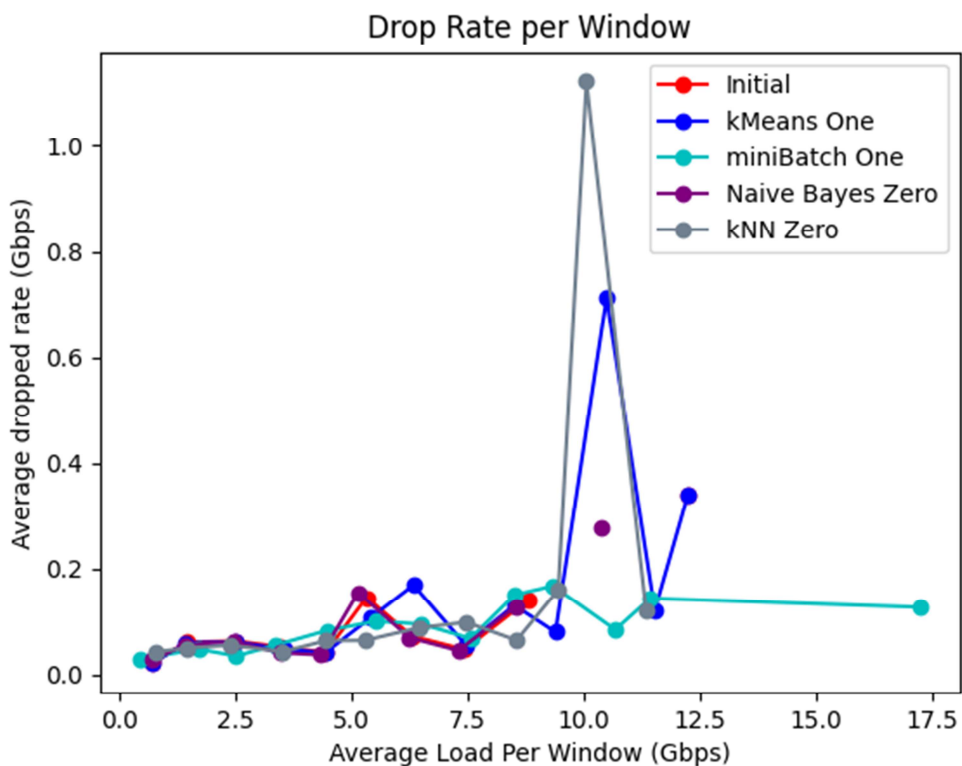
Καταλήγοντας, θα γίνει μια συγκριτική αποτίμηση όλων μετρικών απόδοσης του αρχικού αρχείου με τη ακριβέστερη πρόβλεψη από κάθε αλγόριθμο. Στην *Εικ. 22*, που δείχνει τη μετρική ρυθμοαπόδοση, παρατηρούμε ότι σε σχέση με τις τιμές του αρχικού αρχείου, οι αλγόριθμοι kMeans Label One, miniBatch Label Zero, Naïve Bayes Label Zero και kNN Label Zero, καταφέρνουν να είναι όσο το δυνατόν πιο κοντά στις τιμές του αρχικού αρχείου. Πιο συγκεκριμένα, ο αλγόριθμος Naïve Bayes Label Zero είναι ο πλησιέστερος στις αρχικές τιμές, ακολουθούμενος από kNN Label Zero, kMeans Label One και τέλος miniBatch Label Zero. Οι λόγοι που συμβαίνει αυτό, καθώς και ο σχολιασμός των αποτελεσμάτων θα γίνει στο επόμενο κεφάλαιο, μετά την παρουσίαση όλων των τιμών των μετρικών απόδοσης των αλγορίθμων μηχανικής μάθησης σε σχέση με τις τιμές των μετρικών στο αρχικό αρχείο.



Εικόνα 21 - Throughput Per Window, Comparison Initial with Best ML Algorithms


Το ίδιο ισχύει και για τον μετρικό ρυθμό απόρριψης, όπως φαίνεται στην *Εικ. 23*, όπου ακόμη και σε αυτήν την περίπτωση οι αλγόριθμοι kMeans Label One, miniBatch Label One, Naïve Bayes Label Zero και kNN Label Zero έχουν επιτύχει

τιμές πιο κοντινές από τους άλλους αλγόριθμους, με τον αλγόριθμο Naïve Bayes Label Zero να είναι ο πλησιέστερος στις αρχικές τιμές. Η μόνη διαφορά με τη μετρική της ρυθμοαπόδοσης είναι ότι στην περίπτωση του ρυθμού απόρριψης, ο αλγόριθμος miniBatch Label One επιτυγχάνει κοντινότερες τιμές σε σχέση με τις τιμές του αρχικού αρχείου, σε αντίθεση με τη μετρική απόδοση όπου αυτό επιτυγχάνεται με τον αλγόριθμο miniBatch Label Zero.



Εικόνα 22 - Drop Rate Per Window, Comparison Initial With Best ML Algorithms

Όσον αφορά τον χρόνο καθυστέρησης, σε σχέση με τις τιμές του αρχικού αρχείου, ο αλγόριθμος Naïve Bayes Label Zero επιτυγχάνει τις πλησιέστερες τιμές και ακολουθούν οι αλγόριθμοι kNN Label Zero, kMeans Label One και miniBatch label Zero, όπως φαίνεται στην *Εικ.24*.



Εικόνα 23 - Delay Time Per Window, Comparison Initial With Best ML Algorithms

8. Συμπεράσματα

8.1 Σχολιασμός Αποτελεσμάτων

Παρατηρώντας τα αποτελέσματα που αφορούν στα δεδομένα του δικτύου πριν τη χρήση αλγορίθμων μηχανικής μάθησης, παρατηρούμε ότι το δίκτυο μεταφέρει σε πολύ ικανοποιητικό βαθμό τα δεδομένα χωρίς σημαντικές απώλειες. Παρατηρούμε ότι η απόδοση δηλαδή του δικτύου είναι αρκετά ικανοποιητική, με εξαίρεση την περιοχή των 9-11Gbps, όπου δεν υπάρχουν δεδομένα προς μετάδοση. Το συμπέρασμα αυτό μπορεί να επιβεβαιωθεί και από το γράφημα του drop rate, στο οποίο παρατηρούμε ότι σε κανένα σημείο δεν υπερβαίνει τα 0,17Gbps, με εξαίρεση μόνο την περιοχή των 12Gbps όπου το drop rate έχει τιμή 0.35Gbps, η οποία βέβαια δεν είναι ιδιαίτερα υψηλή. Σχετικά με τον χρόνο καθυστέρησης, και σε αυτή τη μετρική το δίκτυο επιτυγχάνει καλές τιμές, αφού σε κανένα σημείο δεν παρουσιάζει καθυστέρηση μεγαλύτερη των 0.011sec. Μετά την υλοποίηση των αλγορίθμων μηχανικής μάθησης που περιγράφηκαν ήδη, παρουσιάζουν ιδιαίτερο ενδιαφέρον τα αποτελέσματα. Αρχικά, παρατηρείται ότι και στους δύο αλγόριθμους Clustering, δηλαδή τον kMeans και miniBatch Clustering υπάρχει μια ετικέτα στον καθένα στην οποία υπάρχουν ελάχιστα δεδομένα. Για τον kMeans αλγόριθμο αυτή είναι η ετικέτα 0, ενώ για τον miniBatch αλγόριθμο αυτό είναι αυτή είναι η ετικέτα 2. Στους δύο αυτούς αλγόριθμους, δηλαδή, δεν έχει επιτευχθεί ο διαχωρισμός των δεδομένων με ομοιόμορφο τρόπο, αφού μέσα από τα εκατομμύρια των δεδομένων που περιέχει η βάση που χρησιμοποιήθηκε, ελάχιστα τοποθετήθηκαν στις ετικέτες αυτές, κάτι που δείχνει ότι ίσως οι αλγόριθμοι αυτοί να μην είναι οι πλέον κατάλληλοι. Και στους δύο βέβαια αλγόριθμους, στις άλλες δύο ετικέτες, οι τιμές της ρυθμοαπόδοσης και του ρυθμού απόρριψης κινούνται σε πολύ ικανοποιητικά επίπεδα, αφού όσα δεδομένα έχουν τοποθετηθεί σε αυτά τα clusters μεταφέρονται σχεδόν όλα και ελάχιστα είναι αυτά που απορρίπτονται. Αντίστοιχα, και στον χρόνο καθυστέρησης υπάρχει μια καλή απόδοση των αλγορίθμων, όπου στον kMeans επιτυγχάνεται καλύτερη απόδοση στην ετικέτα 1, ενώ στον miniBatch την καλύτερη απόδοση την επιτυγχάνει η ετικέτα 0. Κάτι αντίστοιχο συμβαίνει και στον Naïve Bayes αλγόριθμο, όπου στην ετικέτα 1 δεν έχουν τοποθετηθεί αρκετά δεδομένα

από τον αλγόριθμο, χωρίς όμως να είναι στον ίδιο βαθμό με αυτόν των Clustering αλγορίθμων. Η συμπεριφορά του Naïve Bayes αλγορίθμου με ετικέτα 0 στον τομέα της ρυθμοαπόδοσης και του ρυθμού απόρριψης είναι σχεδόν πανομοιότυπη με τα δεδομένα προ χρήσης μηχανικής μάθησης, κάτι που δείχνει ότι ο αλγόριθμος έχει πολύ καλύτερη απόδοση από τους δύο προηγούμενους. Στον χρόνο καθυστέρησης παρατηρείται ότι η μέγιστη τιμή του είναι 0.010sec, τιμή πανομοιότυπη με αυτή των αρχικών δεδομένων που ήταν 0.011sec.

Τα αποτελέσματα του kNN αλγορίθμου κινούνται και αυτά σε ικανοποιητικά επίπεδα. Παρ'όλο που και σε αυτή την περίπτωση υπάρχει ετικέτα που δεν περιέχει αρκετά δεδομένα, η ετικέτα 1 συγκεκριμένα, εντούτοις, όπως και στην περίπτωση του Naïve Bayes δεν είναι ελάχιστα. Στον τομέα της ρυθμοαπόδοσης και του ρυθμού απόρριψης, ο αλγόριθμος κινείται σε πολύ ικανοποιητικά επίπεδα, με τη διαφορά, σε σχέση με τα αρχικά δεδομένα, ότι δεν περιέχει δεδομένα στην περιοχή πάνω από 11Gbps. Σχετικά με τον χρόνο καθυστέρησης, επιτυγχάνει τιμές πολύ κοντά στις τιμές των αρχικών δεδομένων, ένα ακόμα στοιχείο που δείχνει και την αρκετά καλή απόδοση του συγκεκριμένου αλγορίθμου.

Στον τομέα της συγκριτικής αποτίμησης των τιμών των αρχικών δεδομένων σε σχέση με τους αλγορίθμους μηχανικής μάθησης, αρχικά πρέπει να βρεθεί από κάθε αλγόριθμο ποια ετικέτα είναι η πιο αντιπροσωπευτική. Για τον kMeans αυτή είναι η ετικέτα 1, για τον Naïve Bayes η ετικέτα 0, για τον kNN η ετικέτα 0, ενώ για τον miniBatch παρατηρείται το παράδοξο στις μετρικές ρυθμοαπόδοση και χρόνος καθυστέρησης να είναι η ετικέτα 0 και στην μετρική ρυθμός απόρριψης η ετικέτα 1. Αυτό αποδεικνύει ότι ο αλγόριθμος αυτός δεν έχει καλή απόδοση, αφού αναλόγως της μετρικής υπάρχει και διαφορετική ετικέτα που έχει καλύτερη και πιο κοντά στα αρχικά δεδομένα απόδοση.

Όσον αφορά την ρυθμοαπόδοση, παρατηρούμε ότι ο αλγόριθμος kMeans αρχικά μέχρι την περιοχή των 10 Gbps συμπίπτει με τα αρχικά δεδομένα αλλά στην συνέχεια αποκλίνει και φτάνει σε τιμές μεγαλύτερες από αυτές των αρχικών δεδομένων. Ο αλγόριθμος miniBatch αν και συμπίπτει με τα αρχικά δεδομένα σε όλες τις τιμές, εντούτοις, οι μέγιστες τιμές του είναι κατά πολύ μεγαλύτερες από

αυτές των αρχικών δεδομένων. Ο Naïve Bayes αλγόριθμος στη συνέχεια, παρατηρούμε ότι και συμπίπτει σε όλο το φάσμα των τιμών με τα αρχικά δεδομένα αλλά και οι μέγιστες τιμές του είναι πολύ κοντά στις μέγιστες τιμές των αρχικών δεδομένων. Τέλος, ο kNN αλγόριθμος, όπως και ο kMeans αλγόριθμος, μέχρι την περιοχή των 9 Gbps συμπίπτει με τα αρχικά δεδομένα, στην πορεία αποκλίνει μερικώς και καταλήγει να έχει μέγιστες τιμές ίδιες με αυτές των αρχικών δεδομένων. Συμπερασματικά δηλαδή, ο αλγόριθμος Naïve Bayes επιδεικνύει την καλύτερη συμπεριφορά σχετικά με την μετρική της ρυθμοαπόδοσης.

Σχετικά με τον ρυθμό απόρριψης, ο kMeans αλγόριθμος ξεκινάει να αποκλίνει από την περιοχή των 6 Gbps περίπου συγκριτικά με τα αρχικά δεδομένα, έχοντας μια μεγάλη απόκλιση από την περιοχή των 9 Gbps και έπειτα. Ο miniBatch αλγόριθμος με τη σειρά του, συμπεριφέρεται καλύτερα μέχρι την περιοχή των 10 Gbps, όπου από το σημείο αυτό αν και οι τιμές παραμένουν χαμηλές, δεν ανταποκρίνονται με τις αρχικές και φτάνουν στην περιοχή των 17 Gbps που τα αρχικά δεδομένα δεν έχουν τιμές εκεί. Και σε αυτή την περίπτωση ο Naïve Bayes συμπίπτει σε όλο το φάσμα με τις τιμές των αρχικών δεδομένων με τις μέγιστες τιμές να είναι πλησίον των μέγιστων τιμών των αρχικών δεδομένων. Τέλος, ο kNN αλγόριθμος αν και μέχρι την περιοχή των 10 Gbps κινείται σε πολύ καλά επίπεδα, στη συνέχεια παρουσιάζει τη μεγαλύτερη απόκλιση σε σχέση με τα αρχικά δεδομένα από όλους τους αλγορίθμους, φτάνοντας να έχει τιμές ρυθμού απόρριψης ακόμα και 1 Gbps, τιμή αρκετά υψηλή. Παρατηρούμε ότι και στη μετρική του ρυθμού απόρριψης, ο αλγόριθμος Naïve Bayes επιδεικνύει την καλύτερη συμπεριφορά συγκριτικά με τους υπόλοιπους αλγορίθμους.

Σχετικά με τον χρόνο καθυστέρησης ο kMeans αλγόριθμος μέχρι την περιοχή των 9 Gbps παρουσιάζει κοινή συμπεριφορά με τα αρχικά δεδομένα, αλλά στη συνέχεια εμφανίζει αρκετά υψηλές τιμές καθυστέρησης κάτι που δεν εμφανίζεται και στα αρχικά δεδομένα. Ο miniBatch αλγόριθμος παρουσιάζει μικρές αποκλίσεις σε σχέση με τα αρχικά δεδομένα μέχρι την περιοχή των 9 Gbps και αυτός αλλά στη συνέχεια παρουσιάζει, όπως και ο kMeans, μεγάλες αποκλίσεις, συνεχίζοντας μάλιστα σε τιμές που δεν εμφανίζονται στα αρχικά δεδομένα. Ο Naïve Bayes αλγόριθμος ακολουθεί την ίδια πορεία με τα αρχικά δεδομένα, αν και με ακόμα

μικρότερες αποκλίσεις στις τιμές σε σχέση με αυτά, αλλά έχει την ίδια συμπεριφορά με αυτά και έχουν μέγιστες τιμές κοινές. Τέλος, ο kNN αλγόριθμος μέχρι την περιοχή των 6 Gbps παρουσιάζει καλή απόδοση, στο σημείο όμως εκείνο έχει μια απότομη πτώση στις τιμές, γεγονός να μεν επιθυμητό, εντούτοις αυτό αποδεικνύει ότι δεν μπορεί να ανταποκριθεί στην συμπεριφορά των αρχικών δεδομένων που είναι και το τελικό ζητούμενο. Και σε αυτή την περίπτωση την καλύτερη απόδοση την παρουσιάζει ο Naïve Bayes αλγόριθμος.

Συμπερασματικά, λαμβάνοντας υπόψιν ότι ο αλγόριθμος Naïve Bayes έχει αρκετά δεδομένα και στις δύο ετικέτες, αν και στην ετικέτα 1 θα ήταν επιθυμητό να υπήρχαν περισσότερα δεδομένα, παρουσιάζει την καλύτερη συμπεριφορά μεταξύ των υπόλοιπων αλγορίθμων αλλά και τις πιο κοντινές τιμές σε σχέση με τις τιμές των αρχικών δεδομένων. Μπορούμε λοιπόν να φτάσουμε στο συμπέρασμα ότι είναι ο πιο αποδοτικός αλγόριθμος και αυτός που πρέπει να επιλεγεί για τα συγκεκριμένα δεδομένα.

8.2 Επέκταση Αποτελεσμάτων σε Οπτικά Δίκτυα

Όπως ήδη αναφέρθηκε στο Κεφάλαιο 1 της Ενότητας II, δεν υπάρχουν λεπτομέρειες σχετικά με το δίκτυο και τον τρόπο δομής του. Αν πρόκειται για οπτικό δίκτυο, δίκτυο χαλκοσωλήνων ή συνδυασμό αυτών. Ωστόσο, δεδομένου ότι ο ρυθμός δεδομένων που υπολογίζεται στο Κεφάλαιο 2 της Ενότητας II είναι περίπου 15 Gbps, μας οδηγεί στο συμπέρασμα ότι το δίκτυο χρησιμοποιεί και χάλκινα καλώδια όσο και οπτικές ίνες για τις διαπαφές μεταξύ των στοιχείων του (διακομιστές, σταθμοί εργασίας, δρομολογητές κ.λπ.).

Είναι ιδιαίτερα ενδιαφέρον να μελετήσουμε τη συμπεριφορά του δικτύου εάν αποτελούνταν αποκλειστικά από οπτικές ίνες και πώς θα άλλαζαν οι μετρήσεις των μέτρων απόδοσης σε αυτή την περίπτωση. Δηλαδή, εάν θα υπήρχαν διαφορές στις μετρήσεις της ρυθμοαπόδοσης, του ρυθμού απόρριψης και του χρόνου καθυστέρησης και ποιες θα ήταν αυτές οι διαφορές, στην περίπτωση που ο ρυθμός μετάδοσης ήταν της τάξης των 40 Gbps και άνω, τιμές που επιτυγχάνονται στα

οπτικά δίκτυα. Δεδομένου ότι τα υπάρχοντα δεδομένα δεν προέρχονται από αμιγώς οπτικό δίκτυο, δεν είναι δυνατή η ανάλυση και εμφάνιση των συγκεκριμένων δεδομένων. Αντίθετα, θα γίνει ανάλυση κάθε αλγόριθμου με βάση το πώς λειτουργεί ο καθένας και πώς θα επηρεάζονταν τα αποτελέσματα που παράγονται εάν είχαμε υψηλότερο ρυθμό δεδομένων.

Πρώτα θα αναλυθούν οι δύο αλγόριθμοι ομαδοποίησης που χρησιμοποιούνται, δηλαδή ο kMeans και ο miniBatch Clustering. Ο αλγόριθμος miniBatch είναι ουσιαστικά μια παραλλαγή του αλγόριθμου kMeans, επομένως θα παρουσιαστούν οι πιθανές αλλαγές στα μέτρα απόδοσης από την αύξηση του ρυθμού μετάδοσης στον αλγόριθμο kMeans Clustering, ο οποίος θα ισχύει και για τον αλγόριθμο miniBatch Clustering. Ο αλγόριθμος kMeans διαιρεί τα δεδομένα σε συστάδες μέσω μιας επαναληπτικής διαδικασίας ([194], [195]). Ο τρόπος με τον οποίο υλοποιείται ο συγκεκριμένος αλγόριθμος δεν λαμβάνει υπόψη κανένα ιδιαίτερο χαρακτηριστικό των δεδομένων, όπως τον όγκο κάθε ροής ή τη διάρκεια κάθε ροής, αλλά μέσω του συνόλου των χαρακτηριστικών κάθε ροής υπολογίζει σε ποια ομάδα ανήκει κάθε δεδομένο. Αυτός ο αλγόριθμος δεν επιτρέπει στη διαδικασία να επικεντρωθεί σε ένα συγκεκριμένο χαρακτηριστικό των δεδομένων, καθιστώντας την έτσι έναν αλγόριθμο που δεν επηρεάζεται από τον ρυθμό δεδομένων. Δηλαδή, μια αύξηση του ρυθμού δεδομένων δεν επηρεάζει τις μετρήσεις και τις τιμές των μετρικών απόδοσης που έχουν αναλυθεί, την ρυθμοαπόδοση, τον ρυθμό απόρριψης και τον χρόνο καθυστέρησης. Συμπερασματικά, οι αλγόριθμοι kMeans και miniBatch Clustering δεν θα εμφανίζουν αλλαγές στις μετρήσεις τους με πιθανή αλλαγή στον ρυθμό δεδομένων.

Αντίθετα, ο αλγόριθμος ταξινόμησης Naïve Bayes επηρεάζεται από μια αλλαγή στον ρυθμό δεδομένων και επομένως οι μετρήσεις απόδοσης θα αλλάξουν επίσης. Αυτό συμβαίνει, επειδή μια βασική ιδιότητα αυτού του αλγορίθμου είναι να ταξινομεί τα δεδομένα όσο το δυνατόν καλύτερα, ώστε να ακολουθήσει η καλύτερη δυνατή πρόβλεψη των δεδομένων [196]. Για να επιτευχθεί αυτό, η δήλωση του στόχου παίζει βασικό ρόλο, ώστε να γίνει η πιο ακριβής πρόβλεψη για την ομάδα στην οποία τα νέα δεδομένα ανήκουν... Η δυνατότητα πρόβλεψης του αλγορίθμου συνεπάγεται ότι με την αλλαγή του ρυθμού δεδομένων θα υπάρξει διαφοροποίηση

των μετρήσεων της ρυθμοαπόδοσης, του ρυθμού απόρριψης και του χρόνου καθυστέρησης. Η αύξηση λοιπόν του ρυθμού δεδομένων από 15 Gbps σε 40 Gbps ελάχιστο, θα οδηγήσει σε σημαντική βελτίωση των μετρήσεων, αλλά δεν είναι ξεκάθαρο το ποσοστό βελτίωσης, καθώς επηρεάζεται όχι μόνο από την αλλαγή του ρυθμού δεδομένων αλλά και από το χαρακτηριστικό στόχο και τις ομάδες που αυτό χωρίζεται.

Αντίστοιχα, ο αλγόριθμος ταξινόμησης kNN θα επηρεαστεί από μια πιθανή αλλαγή στον ρυθμό δεδομένων δικτύου. Αυτό με τη σειρά του θα επηρεάσει τις μετρήσεις των μετρικών απόδοσης. Ο λόγος είναι παρόμοιος με τον αλγόριθμο Naïve Bayes, αφού σε αυτόν τον αλγόριθμο ο κύριος στόχος είναι η ταξινόμηση των δεδομένων με τέτοιο τρόπο, ώστε στη συνέχεια να επιτύχουμε την καλύτερη δυνατή πρόβλεψη για τα νέα δεδομένα που θα αναλύσει ο αλγόριθμος ([197] , [198]). Η δήλωση του χαρακτηριστικού στόχου είναι το βασικό στοιχείο και σε αυτόν τον αλγόριθμο, ώστε να γίνει η καλύτερη δυνατή πρόβλεψη για την ομάδα στην οποία ανήκουν τα νέα δεδομένα που θα εισαχθούν στον αλγόριθμο. Η επιλογή των κατάλληλων χαρακτηριστικών ενός δικτύου οδηγεί στη βελτιστοποίηση της απόδοσής του αυτόματα, αφού η διαδικασία υλοποιείται από τον αλγόριθμο στα νέα δεδομένα κάθε φορά και όχι μόνο στα δεδομένα που έχουν ήδη δημιουργηθεί, επιτρέποντάς μας έτσι να επιτύχουμε βελτιώμενες τιμές στις μετρικές απόδοσης, εάν αυξηθεί ο ρυθμός δεδομένων στο δίκτυο. Αν και η βελτίωση θα είναι αισθητή σε περίπτωση τριπλασιασμού του ρυθμού δεδομένων από 15 Gbps σε 40 Gbps, ωστόσο το ακριβές ποσοστό της βελτίωσης δεν μπορεί να υπολογιστεί, καθώς αυτό επηρεάζει τόσο τον ρυθμό αλλαγής του ρυθμού δεδομένων όσο και την επιλογή της δυνατότητας στόχου και τις ομάδες που χωρίζει τα δεδομένα.

8.2 Μελλοντική Έρευνα

Βασική ώθηση σε μια μελλοντική έρευνα και συνέχιση της εργασίας αποτελεί η εύρεση μιας βάσης δεδομένων που να περιέχει δεδομένα από οπτικό δίκτυο

αποκλειστικά. Η εύρεση βέβαια τέτοιων δεδομένων αποτελεί μια διαδικασία ιδιαίτερα δύσκολη, καθώς δεν υπάρχουν διαθέσιμα σε κάποιον από τους ιστοτόπους που περιέχουν δεδομένα, κατάλληλα για χρήση από τους αλγόριθμους μηχανικής μάθησης, ενώ και η αναζήτηση δεδομένων μέσω πανεπιστημίων ή εταιρειών δεν αποδίδει στην πλειονότητα των περιπτώσεων. .

Ένας ακόμα τομέας που είναι δυνατόν να διερευνηθεί σε μια μελλοντική έρευνα αποτελεί και η υλοποίηση και άλλων αλγορίθμων μηχανικής μάθησης πέραν αυτών που υλοποιήθηκαν στη συγκεκριμένη εργασία. Μέσω της διαδικασίας αυτής θα υπάρχει μια ακόμα μεγαλύτερη βάση αλγορίθμων και της απόδοσης τους, ώστε να εξαχθούν ασφαλέστερα συμπεράσματα σχετικά με τον πλέον κατάλληλο αλγόριθμο.

Εν καταλείδι, η χρήση επιπλέον μετρικών, εκτός των τριών που αναλύθηκαν στην παρούσα εργασία, είναι σε θέση να παράξει χρήσιμα επιπλέον συμπεράσματα σχετικά με το δίκτυο και τα χαρακτηριστικά των ροών του. Στη συνέχεια, τα συμπεράσματα αυτά μπορούν να χρησιμοποιηθούν για την καλύτερη διαχείριση του δικτύου που θα οδηγήσει τελικά και στην καλύτερη απόδοση του που θα ωφελήσει τους χρήστες του.

9. Βιβλιογραφία

- [1]: Aouedi, O., Piamrat, K., Hamma, S., & Perera, J. M. (2021). Network Traffic Analysis using Machine Learning: an unsupervised approach to understand and slice your network. *Annals of Telecommunications*, 1-13.
- [2]: Rojas, J. S., Rendon, A., & Corrales, J. C. (2019). Consumption behavior analysis of over the top services: Incremental learning or traditional methods?. *IEEE Access*, 7, 136581-136591.
- [3]: Rojas, J. S., Gallón, Á. R., & Corrales, J. C. (2018). Personalized service degradation policies on OTT applications based on the consumption behavior of users. In *Computational Science and Its Applications–ICCSA 2018: 18th International Conference, Melbourne, VIC, Australia, July 2–5, 2018, Proceedings, Part III 18* (pp. 543-557). Springer International Publishing.
- [4]: Gupta, A., & Jha, R. K. (2015). A survey of 5G network: Architecture and emerging technologies. *IEEE access*, 3, 1206-1232.
- [5]: Gupta, A., & Jha, R. K. (2015). A survey of 5G network: Architecture and emerging technologies. *IEEE access*, 3, 1206-1232.
- [6]: Khan, A. N., Ahmed, H. Y., Zeghid, M., Belhaouari, S. B., Imtiaz, W. A., & Khattak, K. S. (2021). Hybrid optimized approaches for routing and resource reservation protocols in optical networks. *IEEE Photonics Journal*, 13(4), 1-13.
- [7]: Hall, M. N., Foerster, K. T., Schmid, S., & Durairajan, R. (2021). A survey of reconfigurable optical networks. *Optical Switching and Networking*, 41, 100621.
- [8]: Musumeci, F., Rottondi, C., Nag, A., Macaluso, I., Zibar, D., Ruffini, M., & Tornatore, M. (2018). An overview on application of machine learning techniques in optical networks. *IEEE Communications Surveys & Tutorials*, 21(2), 1383-1408.
- [9]: Gao, R., Liu, L., Liu, X., Lun, H., Yi, L., Hu, W., & Zhuge, Q. (2020). An overview of ML-based applications for next generation optical networks. *Science China Information Sciences*, 63, 1-16.

- [10]: Rottondi, C., Barletta, L., Giusti, A., & Tornatore, M. (2018). Machine-learning method for quality of transmission prediction of unestablished lightpaths. *Journal of Optical Communications and Networking*, 10(2), A286-A297.
- [11]: Seve, E., Pesic, J., Delezoide, C., Bigo, S., & Pointurier, Y. (2018). Learning process for reducing uncertainties on network parameters and design margins. *Journal of Optical Communications and Networking*, 10(2), A298-A306.
- [12]: Aladin, S., & Tremblay, C. (2018, March). Cognitive tool for estimating the QoT of new lightpaths. In *2018 Optical Fiber Communications Conference and Exposition (OFC)* (pp. 1-3). IEEE.
- [13]: Mo, W., Huang, Y. K., Zhang, S., Ip, E., Kilper, D. C., Aono, Y., & Tajima, T. (2018, March). ANN-based transfer learning for QoT prediction in real-time mixed line-rate systems. In *Optical Fiber Communication Conference* (pp. W4F-3). Optica Publishing Group.
- [14]: Proietti, R., Chen, X., Castro, A., Liu, G., Lu, H., Zhang, K., ... & Yoo, S. B. (2018, March). Experimental demonstration of cognitive provisioning and alien wavelength monitoring in multi-domain EON. In *Optical Fiber Communication Conference* (pp. W4F-7). Optical Society of America.
- [15]: Meng, F., Yan, S., Nikolovgenis, K., Ou, Y., Wang, R., Bi, Y., ... & Simeonidou, D. (2018, March). Field trial of Gaussian process learning of function-agnostic channel performance under uncertainty. In *Optical Fiber Communication Conference* (pp. W4F-5). Optica Publishing Group.
- [16]: J Jargon, J. A., Wu, X., Choi, H. Y., Chung, Y. C., & Willner, A. E. (2010). Optical performance monitoring of QPSK data channels by use of neural networks trained with parameters derived from asynchronous constellation diagrams. *Optics Express*, 18(5), 4931-4938.
- [17]: Tanimura, T., Hoshida, T., Rasmussen, J. C., Suzuki, M., & Morikawa, H. (2016, July). OSNR monitoring by deep neural networks trained with asynchronously sampled data. In *2016 21st OptoElectronics and*

Communications Conference (OECC) held jointly with 2016 International Conference on Photonics in Switching (PS) (pp. 1-3). IEEE.

[18]: Thrane, J., Wass, J., Piels, M., Diniz, J. C., Jones, R., & Zibar, D. (2016). Machine learning techniques for optical performance monitoring from directly detected PDM-QAM signals. *Journal of Lightwave Technology*, 35(4), 868-875.

[19]: Boada, R., Borkowski, R., & Monroy, I. T. (2015). Clustering algorithms for Stokes space modulation format recognition. *Optics express*, 23(12), 15521-15531.

[20]: Gonzalez, N. G., Zibar, D., & Monroy, I. T. (2010, September). Cognitive digital receiver for burst mode phase modulated radio over fiber links. In *36th European Conference and Exhibition on Optical Communication* (pp. 1-3). IEEE.

[21]: Zhang, S., Peng, Y., Sui, Q., Li, J., & Li, Z. (2016). Modulation format identification in heterogeneous fiber-optic networks using artificial neural networks and genetic algorithms. *Photonic Network Communications*, 32, 246-252.

[22]: Morales, F., Ruiz, M., & Velasco, L. (2016, March). Virtual network topology reconfiguration based on big data analytics for traffic prediction. In *Optical Fiber Communication Conference* (pp. Th3I-5). Optica Publishing Group.

[23]: Fernández, N., Durán, R. J., de Miguel, I., Merayo, N., Sánchez, D., Angelou, M., ... & Abril, E. J. (2012, April). Cognition to design energetically efficient and impairment aware virtual topologies for optical networks. In *2012 16th International Conference on Optical Network Design and Modelling (ONDM)* (pp. 1-6). IEEE.

[24]: Troia, S., Sheng, G., Alvizu, R., Maier, G. A., & Pattavina, A. (2017, March). Identification of tidal-traffic patterns in metro-area mobile networks via matrix factorization based model. In *2017 IEEE International Conference on*

Pervasive Computing and Communications Workshops (PerCom Workshops) (pp. 297-301). IEEE.

[25]: Ruiz, M., Fresi, F., Vela, A. P., Meloni, G., Sambo, N., Cugini, F., ... & Castoldi, P. (2016, September). Service-triggered failure identification/localization through monitoring of multiple parameters. In *ECOC 2016; 42nd European Conference on Optical Communication* (pp. 1-3). VDE.

[26]: Vela, A. P., Shariati, B., Ruiz, M., Cugini, F., Castro, A., Lu, H., ... & Velasco, L. (2018). Soft failure localization during commissioning testing and lightpath operation. *Journal of Optical Communications and Networking*, 10(1), A27-A36.

[27]: Shahkarami, S., Musumeci, F., Cugini, F., & Tornatore, M. (2018, March). Machine-learning-based soft-failure detection and identification in optical networks. In *2018 Optical Fiber Communications Conference and Exposition (OFC)* (pp. 1-3). IEEE.

[28]: Kiran, Y. V., Venkatesh, T., & Murthy, C. S. R. (2007). A reinforcement learning framework for path selection and wavelength selection in optical burst switched networks. *IEEE Journal on Selected Areas in Communications*, 25(9), 18-26.

[29]: Gu, R., Yang, Z., & Ji, Y. (2020). Machine learning for intelligent optical networks: A comprehensive survey. *Journal of Network and Computer Applications*, 157, 102576.

[30]: LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.

[31]: Wang, D., Zhang, M., Li, Z., Li, J., Song, C., Li, J., & Wang, M. (2017, September). Convolutional neural network-based deep learning for intelligent OSNR estimation on eye diagrams. In *2017 European Conference on Optical Communication (ECOC)* (pp. 1-3). IEEE.

[32]: Guo, J., & Zhu, Z. (2018). When deep learning meets inter-datacenter optical network management: Advantages and vulnerabilities. *Journal of Lightwave Technology*, 36(20), 4761-4773.

- [33]: Guo, J., & Zhu, Z. (2018). When deep learning meets inter-datacenter optical network management: Advantages and vulnerabilities. *Journal of Lightwave Technology*, 36(20), 4761-4773.
- [34]: Singh, S. K., & Jukan, A. (2018). Machine-learning-based prediction for resource (re) allocation in optical data center networks. *Journal of Optical Communications and Networking*, 10(10), D12-D28.
- [35] Klinkowski, M., Ruiz, M., Velasco, L., Careglio, D., Lopez, V., & Comellas, J. (2012). Elastic spectrum allocation for time-varying traffic in flexgrid optical networks. *IEEE journal on selected areas in communications*, 31(1), 26-38.
- [36]: Jargon, J. A., Wu, X., & Willner, A. E. (2008). Optical performance monitoring using artificial neural networks trained with eye-diagram parameters. *IEEE Photonics Technology Letters*, 21(1), 54-56.
- [37]: Tanimura, T., Hoshida, T., Kato, T., Watanabe, S., & Morikawa, H. (2019). Convolutional neural network-based optical performance monitoring for optical transport networks. *Journal of Optical Communications and Networking*, 11(1), A52-A59.
- [38]: Tanimura, T., Hoshida, T., Rasmussen, J. C., Suzuki, M., & Morikawa, H. (2016, July). OSNR monitoring by deep neural networks trained with asynchronously sampled data. In *2016 21st OptoElectronics and Communications Conference (OECC) held jointly with 2016 International Conference on Photonics in Switching (PS)* (pp. 1-3). IEEE.
- [39]: Proietti, R., Chen, X., Zhang, K., Liu, G., Shamsabardeh, M., Castro, A., ... & Yoo, S. B. (2019). Experimental demonstration of machine-learning-aided QoT estimation in multi-domain elastic optical networks with alien wavelengths. *Journal of Optical Communications and Networking*, 11(1), A1-A10.
- [40]: Rottondi, C., Barletta, L., Giusti, A., & Tornatore, M. (2018). Machine-learning method for quality of transmission prediction of unestablished lightpaths. *Journal of Optical Communications and Networking*, 10(2), A286-A297.

- [41]: Wang, Z., Zhang, M., Wang, D., Song, C., Liu, M., Li, J., ... & Liu, Z. (2017). Failure prediction using machine learning and time series in optical network. *Optics Express*, 25(16), 18553-18565.
- [42]: Boitier, F., Lemaire, V., Pesic, J., Chavarría, L., Layec, P., Bigo, S., & Dutisseuil, E. (2017, September). Proactive fiber damage detection in real-time coherent receiver. In *2017 European Conference on Optical Communication (ECOC)* (pp. 1-3). IEEE.
- [43]: Vela, A. P., Ruiz, M., & Velasco, L. (2018, March). Applying data visualization for failure localization. In *Optical Fiber Communication Conference* (pp. W1D-5). Optica Publishing Group.
- [44]: Boutaba, R., Salahuddin, M. A., Limam, N., Ayoubi, S., Shahriar, N., Estrada-Solano, F., & Caicedo, O. M. (2018). A comprehensive survey on machine learning for networking: evolution, applications and research opportunities. *Journal of Internet Services and Applications*, 9(1), 1-99.
- [45]: Chadha, D. (2019). *Optical WDM Networks: From Static to Elastic Networks*. John Wiley & Sons.
- [46]: Wu, X., Xu, J., Ye, Y., Wang, X., Nikdast, M., Wang, Z., & Wang, Z. (2014). An inter/intra-chip optical network for manycore processors. *IEEE Transactions on Very Large Scale Integration (VLSI) Systems*, 23(4), 678-691.
- [47]: Tomkos, I., Azodolmolky, S., Sole-Pareta, J., Careglio, D., & Palkopoulou, E. (2014). A tutorial on the flexible optical networking paradigm: State of the art, trends, and research challenges. *Proceedings of the IEEE*, 102(9), 1317-1337.
- [48]: Papadimitiou G., Tsimoulaw P., Obaidat. M., Pomportsis. A., (2005). *Οπτικά Δίκτυα Τεχνολογίας WDM*, Εκδόσεις ΚΛΕΙΔΑΡΙΘΜΟΣ.
- [49]: Abdou, A., van Oorschot, P. C., & Wan, T. (2018). Comparative analysis of control plane security of SDN and conventional networks. *IEEE Communications Surveys & Tutorials*, 20(4), 3542-3559.

- [50]: Μακρής, Δ. (1999). *Αρχιτεκτονική επιπέδου ελέγχου για δίκτυα ευρείας ζώνης με ασύγχρονη πολύπλεξη και λογισμικό διαχείρισης για τους κόμβους τους* (Doctoral dissertation, Εθνικό Μετσόβιο Πολυτεχνείο (ΕΜΠ). Τμήμα Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών. Τομέας Πληροφορικής).
- [51]: Zervas, G. S., & Simeonidou, D. (2010, June). Cognitive optical networks: Need, requirements and architecture. In *2010 12th International Conference on Transparent Optical Networks* (pp. 1-4). IEEE.
- [52]: Saha, D., Rajagopalan, B., & Bernstein, G. (2003). The optical network control plane: state of the standards and deployment. *IEEE Communications Magazine*, 41(8), S29-S34.
- [53]: Thyagaturu, A. S., Mercian, A., McGarry, M. P., Reisslein, M., & Kellerer, W. (2016). Software defined optical networks (SDONs): A comprehensive survey. *IEEE Communications Surveys & Tutorials*, 18(4), 2738-2786.
- [54]: Leytón, G. V. (2019, May). Software-defined optical network (SDON), new generation networks. In *IOP Conference Series: Materials Science and Engineering* (Vol. 519, No. 1, p. 012013). IOP Publishing.
- [55]: Jha, R. K., & Llah, B. N. M. (2019). Software Defined Optical Networks (SDON): proposed architecture and comparative analysis. *Journal of the European Optical Society-Rapid Publications*, 15, 1-15.
- [56]: Li, W., Yang, Z., Zhao, W., Qi, Z., & Liu, F. (2019, January). A review of research on software-defined optical network. In *2019 International Conference on Intelligent Transportation, Big Data & Smart City (ICITBS)* (pp. 155-160). IEEE.
- [57]: Bhaumik, P., Zhang, S., Chowdhury, P., Lee, S. S., Lee, J. H., & Mukherjee, B. (2014). Software-defined optical networks (SDONs): a survey. *Photonic Network Communications*, 28, 4-18.
- [58]: Costa, L. C., Vieira, A. B., e Silva, E. D. B., Macedo, D. F., Vieira, L. F., Vieira, M. A., ... & Correia, L. H. (2021). OpenFlow data planes performance evaluation. *Performance Evaluation*, 147, 102194.

- [59]: Turing, A. M. (1948). Intelligent machinery, a heretical theory. *The Turing test: Verbal behavior as the hallmark of intelligence*, 105..
- [60]: Samuel, A. L. (1959). Machine learning. *The Technology Review*, 62(1), 42-45.
- [61]: Carbonell, J. G., Michalski, R. S., & Mitchell, T. M. (1983). An overview of machine learning. *Machine learning*, 3-23.
- [62]: Koripi, M. (2020). A Review on Architectures and Needs in Advanced Wireless-communication Technologies. *A Journal Of Composition Theory*, 13, 208-214.
- [63]: Λευκαδίτης, Χ. (2020). *Αυτόνομη πλοήγηση με χρήση μηχανικής μάθησης και επαυξημένης πραγματικότητας* (Bachelor's thesis).
- [64]: Dietterich, T. (1995). Overfitting and undercomputing in machine learning. *ACM computing surveys (CSUR)*, 27(3), 326-327.
- [65]: Λιάγος, Ι. (2020). *Ανίχνευση Ανωμαλιών με Τεχνικές Μηχανικής Μάθησης* (No. GRI-2020-27296). Aristotle University of Thessaloniki.
- [66]: Sculley, D. (2010, April). Web-scale k-means clustering. In *Proceedings of the 19th international conference on World wide web* (pp. 1177-1178).
- [67]: Rojas, J. S., Gallón, Á. R., & Corrales, J. C. (2018, May). Personalized service degradation policies on OTT applications based on the consumption behavior of users. In *International Conference on Computational Science and Its Applications* (pp. 543-557). Springer, Cham.
- [68]: Zhang, S., Li, X., Zong, M., Zhu, X., & Wang, R. (2017). Efficient kNN classification with different numbers of nearest neighbors. *IEEE transactions on neural networks and learning systems*, 29(5), 1774-1785.
- [69]: Shang, W., Huang, H., Zhu, H., Lin, Y., Wang, Z., & Qu, Y. (2005). An improved kNN algorithm—fuzzy kNN. In *Computational Intelligence and Security: International Conference, CIS 2005, Xi'an, China, December 15-19, 2005, Proceedings Part I* (pp. 741-746). Springer Berlin Heidelberg.

- [70]: Jones, R. T. (2019). Machine learning methods in coherent optical communication systems. *International Series of Monographs on Physics; Technical University of Denmark: Kongens Lyngby, Denmark.*
- [71]: Rojas, J. S., Pekar, A., Rendón, Á., & Corrales, J. C. (2020). Smart user consumption profiling: Incremental learning-based OTT service degradation. *IEEE access*, 8, 207426-207442.
- [72]: Al-Aidaros, K. M., Bakar, A. A., & Othman, Z. (2010, March). Naive Bayes variants in classification learning. In *2010 International Conference on Information Retrieval & Knowledge Management (CAMP)* (pp. 276-281). IEEE.
- [73]: Gu, R., Yang, Z., & Ji, Y. (2020). Machine learning for intelligent optical networks: A comprehensive survey. *Journal of Network and Computer Applications*, 157, 102576.
- [74]: Wang, M., Cui, Y., Wang, X., Xiao, S., & Jiang, J. (2017). Machine learning for networking: Workflow, advances and opportunities. *Ieee Network*, 32(2), 92-99.
- [75]: Τσιάρας Κ. (2020). *Χρηματιστηριακές Προβλέψεις με χρήση Νευρωνικών Δικτύων LSTM* (Πτυχιακή Εργασία ,Εθνικό και Καποδιστριακό Πανεπιστήμιο Αθηνών). <https://pergamos.lib.uoa.gr/uoa/dl/object/2898087/file.pdf>
- [76]: Basheer, I. A., & Hajmeer, M. (2000). Artificial neural networks: fundamentals, computing, design, and application. *Journal of microbiological methods*, 43(1), 3-31.
- [77]: Tsiaras G.K (2020). *Stock Market Predictions using LSTM Neural Networks* (National and Kapodistrian University of Athens). Scholl of Science, Department of Informatics and Telecommnication.
- [78]:]: Hornik, K., Stinchcombe, M., & White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural networks*, 2(5), 359-366.
- [79]: Panchal, G., Ganatra, A., Kosta, Y. P., & Panchal, D. (2011). Behaviour analysis of multilayer perceptrons with multiple hidden neurons and hidden layers. *International Journal of Computer Theory and Engineering*, 3(2), 332-337.

- [80]: Marshall, I. J., & Wallace, B. C. (2019). Toward systematic review automation: a practical guide to using machine learning tools in research synthesis. *Systematic reviews*, 8, 1-10.
- [81]: Truong, A., Walters, A., Goodsitt, J., Hines, K., Bruss, C. B., & Farivar, R. (2019, November). Towards automated machine learning: Evaluation and comparison of AutoML approaches and tools. In *2019 IEEE 31st international conference on tools with artificial intelligence (ICTAI)* (pp. 1471-1479). IEEE.
- [82]: Kotthoff, L., Thornton, C., Hoos, H. H., Hutter, F., & Leyton-Brown, K. (2019). Auto-WEKA: Automatic model selection and hyperparameter optimization in WEKA. In *Automated Machine Learning* (pp. 81-95). Springer, Cham.
- [83]: Feurer, M., Klein, A., Eggenberger, K., Springenberg, J., Blum, M., & Hutter, F. (2015), *Efficient and robust automated machine learning*. In *Advances in Neural Information Processing Systems 28* (pp. 2962– 2970).
- [84]: Jin, H., Song, Q., & Hu, X. (2019, July). Auto-keras: An efficient neural architecture search system. In *Proceedings of the 25th ACM SIGKDD international conference on knowledge discovery & data mining* (pp. 1946-1956).
- [85]: “Datarobot documentation,” <https://www.datarobot.com/about-us/>, [Online accessed: 2022-05-10].
- [86]: “H2o-driverlessai,” <http://docs.h2o.ai/driverless-ai/lateststable/docs/userguide/index.html>, [Online accessed: 2022-05-10].
- [87]: “Google cloud automl,” <https://cloud.google.com/automl/>, [Online accessed: 2022-05-10].
- [88]: “Automated machine learning with azureml,” <https://github.com/Azure/MachineLearningNotebooks/tree/master/howto-use-azureml/automated-machine-learning>, [Online accessed: 2022-05-10].
- [89]: “Transmogrifai,” <https://github.com/salesforce/TransmogrifAI>, [Online accessed: 2022-05-10].

- [90]: Bergstra, J., Bastien, F., Breuleux, O., Lamblin, P., Pascanu, R., Delalleau, O., ... & Bengio, Y. (2011). Theano: Deep learning on gpus with python. In *NIPS 2011, BigLearning Workshop, Granada, Spain* (Vol. 3, pp. 1-48). Granada: Citeseer.
- [91]: Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... & Duchesnay, E. (2011). Scikit-learn: Machine learning in Python. *the Journal of machine Learning research*, 12, 2825-2830.
- [92]: McKinney, W. (2011). pandas: a foundational Python library for data analysis and statistics. *Python for high performance and scientific computing*, 14(9), 1-9.
- [93]: Klaise, J., Van Looveren, A., Vacanti, G., & Coca, A. (2020). Alibi: Algorithms for monitoring and explaining machine learning models. URL <https://github.com/SeldonIO/alibi>. [Online accessed 2022-05-10].
- [94]: Chen, T., & Guestrin, C. (2016, August). Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining* (pp. 785-794).
- [95]: Agarwal, N., & Das, S. (2020, December). Interpretable machine learning tools: A survey. In *2020 IEEE Symposium Series on Computational Intelligence (SSCI)* (pp. 1528-1534). IEEE.
- [96]: Li, H. (2016). Smile-statistical machine intelligence and learning engine. URL <http://haifengl.github.io/smile>. [Online accessed 2022-05-10]
- [97]: Nicora, G., Vitali, F., Dagliati, A., Geifman, N., & Bellazzi, R. (2020). Integrated multi-omics analyses in oncology: a review of machine learning methods and tools. *Frontiers in oncology*, 10, 1030.
- [98]: McCarthy, J. (2007). What is artificial intelligence?.
- [99]: Chaliaskou A. (2020). *Review, parameterization and implementation of automated object recognition algorithms*. (Πτυχιακή Εργασία, Πανεπιστήμιο Θεσσαλίας).

- [100]: Zhang, Y., Xin, J., Li, X., & Huang, S. (2020). Overview on routing and resource allocation based machine learning in optical networks. *Optical Fiber Technology*, 60, 102355.
- [101]: Singh, S. K., & Jukan, A. (2018). Machine-learning-based prediction for resource (re) allocation in optical data center networks. *Journal of Optical Communications and Networking*, 10(10), D12-D28.
- [102]: Morales, F., Ruiz, M., & Velasco, L. (2016, March). Virtual network topology reconfiguration based on big data analytics for traffic prediction. In *Optical Fiber Communication Conference* (pp. Th3I-5). Optical Society of America.
- [103]: Yu, A., Yang, H., Bai, W., He, L., Xiao, H., & Zhang, J. (2018, March). Leveraging deep learning to achieve efficient resource allocation with traffic evaluation in datacenter optical networks. In *2018 Optical Fiber Communications Conference and Exposition (OFC)* (pp. 1-3). IEEE.
- [104]: Mo, W., Gutterman, C. L., Li, Y., Zussman, G., & Kilper, D. C. (2018, March). Deep neural network based dynamic resource reallocation of BBU pools in 5G C-RAN ROADM networks.
- [105]: In *Optical Fiber Communication Conference* (pp. Th1B-4). Optical Society of America.
- [106]: Fernández, N., Durán, R. J., de Miguel, I., Merayo, N., Sánchez, D., Angelou, M., & Abril, E. J. (2012, April). Cognition to design energetically efficient and impairment aware virtual topologies for optical networks. In *2012 16th International Conference on Optical Network Design and Modelling (ONDM)* (pp. 1-6). IEEE.
- [107]: Fernández, N., Durán, R. J., de Miguel, I., Merayo, N., Aguado, J. C., Fernández, P. & Tomkos, I. (2012, October). Survivable and impairment-aware virtual topologies for reconfigurable optical networks: A cognitive approach. In *2012 IV International Congress on Ultra Modern Telecommunications and Control Systems* (pp. 793-799). IEEE.
- [108]: Bermolen, P., & Rossi, D. (2009). Support vector regression for link load prediction. *Computer Networks*, 53(2), 191-201.

- [109]: Troia, S., Rodriguez, A., Martín, I., Hernández, J. A., De Dios, O. G., Alvizu, R., & Maier, G. (2018, September). Machine-learning-assisted routing in SDN-based optical networks. In *2018 European Conference on Optical Communication (ECOC)* (pp. 1-3). IEEE.
- [110]: Lévesque, M., & Elbiaze, H. (2009). Graphical probabilistic routing model for OBS networks with realistic traffic scenario. In *GLOBECOM 2009-2009 IEEE Global Telecommunications Conference* (pp. 1-6). IEEE.
- [111]: Zhong, Z., Hua, N., Yuan, Z., Li, Y., & Zheng, X. (2019, March). Routing without routing algorithms: an AI-based routing paradigm for multi-domain optical networks. In *Optical Fiber Communication Conference* (pp. Th2A-24). Optical Society of America.
- [112]: Kiran, Y. V., Venkatesh, T., & Murthy, C. S. R. (2007). A reinforcement learning framework for path selection and wavelength selection in optical burst switched networks. *IEEE Journal on Selected Areas in Communications*, 25(9), 18-26.
- [113]: Martín, I., Troia, S., Hernández, J. A., Rodríguez, A., Musumeci, F., Maier, G., ... & de Dios, Ó. G. (2019). Machine learning-based routing and wavelength assignment in software-defined optical networks. *IEEE Transactions on Network and Service Management*, 16(3), 871-883.
- [114]: Kiran, Y. V., Venkatesh, T., & Murthy, C. S. R. (2007). A reinforcement learning framework for path selection and wavelength selection in optical burst switched networks. *IEEE Journal on Selected Areas in Communications*, 25(9), 18-26.
- [115]: Pointurier, Y., & Heidari, F. (2007, September). Reinforcement learning based routing in all-optical networks. In *2007 Fourth International Conference on Broadband Communications, Networks and Systems (BROADNETS'07)* (pp. 919-921). IEEE.
- [116]: Koyanagi, I., Tachibana, T., & Sugimoto, K. (2009, November). A reinforcement learning-based lightpath establishment for service differentiation in all-optical WDM networks. In *GLOBECOM 2009-2009 IEEE Global Telecommunications Conference* (pp. 1-6). IEEE.

- [117]: Garcia, P., Zsigri, A., & Guitton, A. (2003, June). A multicast reinforcement learning algorithm for WDM optical networks. In *Proceedings of the 7th International Conference on Telecommunications, 2003. ConTEL 2003*. (Vol. 2, pp. 419-426). IEEE..
- [118]: Kiran, Y. V., Venkatesh, T., & Murthy, C. S. R. (2007). A reinforcement learning framework for path selection and wavelength selection in optical burst switched networks. *IEEE Journal on Selected Areas in Communications*, 25(9), 18-26.
- [119]: Martín, I., Hernández, J. A., Troia, S., Musumeci, F., Maier, G., & de Dios, O. G. (2018, September). Is machine learning suitable for solving RWA problems in optical networks?. In *2018 European Conference on Optical Communication (ECOC)* (pp. 1-3). IEEE.
- [120]: Ghazijahani, H. A., Seyedarabi, H., Niya, J. M., & Cheung, N. M. (2019). Deep learning-assisted adaptive modulation level assignment for video communication over an elastic optical network. *Optical Fiber Technology*, 52, 101987.
- [121]: Klinkowski, M., Ksieniewicz, P., Jaworski, M., Zalewski, G., & Walkowiak, K. (2020). Machine learning assisted optimization of dynamic crosstalk-aware spectrally-spatially flexible optical networks. *Journal of Lightwave Technology*, 38(7), 1625-1635.
- [122]: Jargon, J. A., Wu, X., & Willner, A. E. (2008). Optical performance monitoring using artificial neural networks trained with eye-diagram parameters. *IEEE Photonics Technology Letters*, 21(1), 54-56.
- [123]: Jargon, J. A., Wu, X., & Willner, A. E. (2008). Optical performance monitoring using artificial neural networks trained with eye-diagram parameters. *IEEE Photonics Technology Letters*, 21(1), 54-56.
- [124]: Wu, X., Jargon, J. A., Jia, Z., Paraschis, L., Skoog, R. A., & Willner, A. E. (2009, September). Optical performance monitoring of PSK data channels using artificial neural networks trained with parameters derived from delay-tap

asynchronous diagrams via balanced detection. In *2009 35th European Conference on Optical Communication* (pp. 1-2). IEEE.

[125]: Wu, X., Jargon, J. A., Paraschis, L., & Willner, A. E. (2010). ANN-based optical performance monitoring of QPSK signals using parameters derived from balanced-detected asynchronous diagrams. *IEEE Photonics Technology Letters*, 23(4), 248-250.

[126]: Shen, T. S. R., Meng, K., Lau, A. P. T., & Dong, Z. Y. (2010). Optical performance monitoring using artificial neural network trained with asynchronous amplitude histograms. *IEEE Photonics Technology Letters*, 22(22), 1665-1667.

[127]: Tanimura, T., Hoshida, T., Kato, T., Watanabe, S., & Morikawa, H. (2019). Convolutional neural network-based optical performance monitoring for optical transport networks. *Journal of Optical Communications and Networking*, 11(1), A52-A59.

[128]: Wang, D., Zhang, M., Li, Z., Li, J., Song, C., Li, J., & Wang, M. (2017, September). Convolutional neural network-based deep learning for intelligent OSNR estimation on eye diagrams. In *2017 European Conference on Optical Communication (ECOC)* (pp. 1-3). IEEE

[129]: Rottondi, C., Barletta, L., Giusti, A., & Tornatore, M. (2018). Machine-learning method for quality of transmission prediction of unestablished lightpaths. *Journal of Optical Communications and Networking*, 10(2), A286-A297.

[130]: Samadi, P., Amar, D., Lepers, C., Lourdiane, M., & Bergman, K. (2017, September). Quality of transmission prediction with machine learning for dynamic operation of optical WDM networks. In *2017 European Conference on Optical Communication (ECOC)* (pp. 1-3). IEEE.

[131]: Mo, W., Huang, Y. K., Zhang, S., Ip, E., Kilper, D. C., Aono, Y., & Tajima, T. (2018, March). ANN-based transfer learning for QoT prediction in real-time mixed line-rate systems. In *2018 Optical Fiber Communications Conference and Exposition (OFC)* (pp. 1-3). IEEE.

[132]: Proietti, R., Chen, X., Castro, A., Liu, G., Lu, H., Zhang, K., ... & Yoo, S. B. (2018, March). Experimental demonstration of cognitive provisioning and alien wavelength monitoring in multi-domain EON. In *Optical Fiber Communication Conference* (pp. W4F-7). Optical Society of America.

[133]: Huang, Y., Samoud, W., Gutterman, C. L., Ware, C., Lourdiane, M., Zussman, G., ... & Bergman, K. (2016, September). A machine learning approach for dynamic optical channel add/drop strategies that minimize EDFA power excursions. In *ECOC 2016; 42nd European Conference on Optical Communication* (pp. 1-3). VDE.

[134]: Huang, Y., Cho, P. B., Samadi, P., & Bergman, K. (2017, March). Dynamic power pre-adjustments with machine learning that mitigate EDFA excursions during defragmentation. In *2017 Optical Fiber Communications Conference and Exhibition (OFC)* (pp. 1-3). IEEE.

[135]: Aladin, S., & Tremblay, C. (2018, March). Cognitive tool for estimating the QoT of new lightpaths. In *Optical Fiber Communication Conference* (pp. M3A-3). Optical Society of America.

[136]: Wang, Z., Zhang, M., Wang, D., Song, C., Liu, M., Li, J., ... & Liu, Z. (2017). Failure prediction using machine learning and time series in optical network. *Optics Express*, 25(16), 18553-18565.

[137]: Boitier, F., Lemaire, V., Pesic, J., Chavarría, L., Layec, P., Bigo, S., & Dutisseuil, E. (2017, September). Proactive fiber damage detection in real-time coherent receiver. In *2017 European Conference on Optical Communication (ECOC)* (pp. 1-3). IEEE.

[138]: Ruiz, M., Fresi, F., Vela, A. P., Meloni, G., Sambo, N., Cugini, F., ... & Castoldi, P. (2016, September). Service-triggered failure identification/localization through monitoring of multiple parameters. In *ECOC 2016; 42nd European Conference on Optical Communication* (pp. 1-3). VDE

[139]: Tembo, S. R., Vaton, S., Courant, J. L., & Gosselin, S. (2016, September). A tutorial on the EM algorithm for Bayesian networks: Application to self-diagnosis of GPON-FTTH networks. In *2016 International Wireless*

Communications and Mobile Computing Conference (IWCMC) (pp. 369-376). IEEE.

[140]: Gosselin, S., Courant, J. L., Tembo, S. R., & Vaton, S. (2017, May). Application of probabilistic modeling and machine learning to the diagnosis of FTTH GPON networks. In *2017 International Conference on Optical Network Design and Modeling (ONDM)* (pp. 1-3). IEEE.

[141]: Chen, X., Li, B., Proietti, R., Zhu, Z., & Yoo, S. B. (2019). Self-taught anomaly detection with hybrid unsupervised/supervised machine learning in optical networks. *Journal of Lightwave Technology*, 37(7), 1742-1749.

[142]: Vela, A. P., Ruiz, M., & Velasco, L. (2018, March). Applying data visualization for failure localization. In *Optical Fiber Communication Conference* (pp. W1D-5). Optical Society of America.

[143]: Shariati, B., Ruiz, M., Comellas, J., & Velasco, L. (2019). Learning from the optical spectrum: failure detection and identification. *Journal of Lightwave Technology*, 37(2), 433-440.

[144]: Mestres, A., Rodriguez-Natal, A., Carner, J., Barlet-Ros, P., Alarcón, E., Solé, M., ... & Cabellos, A. (2017). Knowledge-defined networking. *ACM SIGCOMM Computer Communication Review*, 47(3), 2-10.

[145]: Mata, J., de Miguel, I., Duran, R. J., Merayo, N., Singh, S. K., Jukan, A., & Chamania, M. (2018). Artificial intelligence (AI) methods in optical networks: A comprehensive survey. *Optical switching and networking*, 28, 43-57.

[146]: LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.

[147]: Wang, D., Zhang, M., Li, Z., Li, J., Song, C., Li, J., & Wang, M. (2017, September). Convolutional neural network-based deep learning for intelligent OSNR estimation on eye diagrams. In *2017 European Conference on Optical Communication (ECOC)* (pp. 1-3). IEEE.

[149]: Yu, A., Yang, H., Bai, W., He, L., Xiao, H., & Zhang, J. (2018, March). Leveraging deep learning to achieve efficient resource allocation with traffic evaluation in datacenter optical networks. In *2018 Optical Fiber Communications Conference and Exposition (OFC)* (pp. 1-3). IEEE.

- [150]: Mao, H., Alizadeh, M., Menache, I., & Kandula, S. (2016, November). Resource management with deep reinforcement learning. In *Proceedings of the 15th ACM workshop on hot topics in networks* (pp. 50-56).
- [151]: Troia, S., Alvizu, R., Zhou, Y., Maier, G., & Pattavina, A. (2018, July). Deep learning-based traffic prediction for network optimization. In *2018 20th International Conference on Transparent Optical Networks (ICTON)* (pp. 1-4). IEEE.
- [152]: Gao, Z., Eisen, M., & Ribeiro, A. (2021). Resource Allocation via Model-Free Deep Learning in Free Space Optical Communications. *IEEE Transactions on Communications*.
- [153]: Martín, I., Troia, S., Hernández, J. A., Rodríguez, A., Musumeci, F., Maier, G., ... & de Dios, Ó. G. (2019). Machine learning-based routing and wavelength assignment in software-defined optical networks. *IEEE Transactions on Network and Service Management*, 16(3), 871-883.
- [154]: Martín, I., Troia, S., Hernández, J. A., Rodríguez, A., Musumeci, F., Maier, G., ... & de Dios, Ó. G. (2019). Machine learning-based routing and wavelength assignment in software-defined optical networks. *IEEE Transactions on Network and Service Management*, 16(3), 871-883.
- [155]: Chen, X., Guo, J., Zhu, Z., Proietti, R., Castro, A., & Yoo, S. B. (2018, March). Deep-RMSA: A deep-reinforcement-learning routing, modulation and spectrum assignment agent for elastic optical networks. In *2018 Optical Fiber Communications Conference and Exposition (OFC)* (pp. 1-3). IEEE.
- [156]: Luo, X., Shi, C., Wang, L., Chen, X., Li, Y., & Yang, T. (2019). Leveraging double-agent-based deep reinforcement learning to global optimization of elastic optical networks with enhanced survivability. *Optics express*, 27(6), 7896-7911.
- [157]: Yu, J., Cheng, B., Hang, C., Hu, Y., Liu, S., Wang, Y., & Shen, J. (2019, August). A deep learning based RSA strategy for elastic optical networks. In *2019 18th International Conference on Optical Communications and Networks (ICOON)* (pp. 1-3). IEEE.

- [158]: Chen, X., Li, B., Proietti, R., Lu, H., Zhu, Z., & Yoo, S. B. (2019). DeepRMSA: a deep reinforcement learning framework for routing, modulation and spectrum assignment in elastic optical networks. *Journal of Lightwave Technology*, 37(16), 4155-4163.
- [159]: Tanimura, T., Hoshida, T., Rasmussen, J. C., Suzuki, M., & Morikawa, H. (2016, July). OSNR monitoring by deep neural networks trained with asynchronously sampled data. In *2016 21st OptoElectronics and Communications Conference (OECC) held jointly with 2016 International Conference on Photonics in Switching (PS)* (pp. 1-3). IEEE.
- [160]: Proietti, R., Chen, X., Zhang, K., Liu, G., Shamsabardeh, M., Castro, A., ... & Yoo, S. B. (2019). Experimental demonstration of machine-learning-aided QoT estimation in multi-domain elastic optical networks with alien wavelengths. *Journal of Optical Communications and Networking*, 11(1), A1-A10.
- [161]: Demirbilek, E., & Grégoire, J. C. (2017). Machine Learning--Based Parametric Audiovisual Quality Prediction Models for Real-Time Communications. *ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)*, 13(2), 1-25.
- [162]: Zhao, X., Yang, H., Guo, H., Peng, T., & Zhang, J. (2019, March). Accurate fault location based on deep neural evolution network in optical networks for 5G and beyond. In *Optical Fiber Communication Conference* (pp. M3J-5). Optical Society of America.
- [163]: Tang, T. A., Mhamdi, L., McLernon, D., Zaidi, S. A. R., & Ghogho, M. (2016, October). Deep learning approach for network intrusion detection in software defined networking. In *2016 international conference on wireless networks and mobile communications (WINCOM)* (pp. 258-263). IEEE.
- [164]: Lloyd, S. (1982). Least squares quantization in PCM. *IEEE transactions on information theory*, 28(2), 129-137.
- [165]: MacQueen, J. (1967, June). Some methods for classification and analysis of multivariate observations. In *Proceedings of the fifth Berkeley*

symposium on mathematical statistics and probability (Vol. 1, No. 14, pp. 281-297).

[166]: Hodge, V., & Austin, J. (2004). A survey of outlier detection methodologies. *Artificial intelligence review*, 22(2), 85-126.

[167]: Peng, K., Leung, V. C., & Huang, Q. (2018). Clustering approach based on mini batch kmeans for intrusion detection system over big data. *IEEE Access*, 6, 11897-11906.

[168]: Feizollah, A., Anuar, N. B., Salleh, R., & Amalina, F. (2014, August). Comparative study of k-means and mini batch k-means clustering algorithms in android malware detection using network traffic analysis. In *2014 international symposium on biometrics and security technologies (ISBAST)* (pp. 193-197). IEEE.

[169]: Duda, R. O., & Hart, P. E. (1973). *Pattern classification and scene analysis* (Vol. 3, pp. 731-739). New York: Wiley.

[170]: Murphy, K. P. (2006). Naive bayes classifiers. *University of British Columbia*, 18(60), 1-8.

[171]: Rish, I. (2001, August). An empirical study of the naive Bayes classifier. In *IJCAI 2001 workshop on empirical methods in artificial intelligence* (Vol. 3, No. 22, pp. 41-46).

[172]: Fix, E., & Hodges Jr, J. L. (1952). *Discriminatory analysis-nonparametric discrimination: Small sample performance*. California Univ Berkeley.

[173]: Altman, N. S. (1992). An introduction to kernel and nearest-neighbor nonparametric regression. *The American Statistician*, 46(3), 175-185.

[174]: Kuang, Q., & Zhao, L. (2009). A practical GPU based kNN algorithm. In *Proceedings. The 2009 International Symposium on Computer Science and Computational Technology (ISCSCI 2009)* (p. 151). Academy Publisher.

[175]: Deng, Z., Zhu, X., Cheng, D., Zong, M., & Zhang, S. (2016). Efficient kNN classification algorithm for big data. *Neurocomputing*, 195, 143-148.

- [176]: Santini, M. (2016). Advantages & disadvantages of k-means and hierarchical clustering (unsupervised learning). URL: http://santini.se/teaching/ml/2016/Lect_10/10c_UnsupervisedMethods.pdf (Accessed 2022-05-10).
- [177]: Likas, A., Vlassis, N., & Verbeek, J. J. (2003). The global k-means clustering algorithm. *Pattern recognition*, 36(2), 451-461.
- [178]: Chavan, M., Patil, A., Dalvi, L. A. T. A., & Patil, A. (2015). Mini Batch K-Means Clustering On Large Dataset. *Int. J. Sci. Eng. Technol. Res*, 4, 1356-1358.
- [179]: Xie, Z., Hsu, W., Liu, Z., & Lee, M. L. (2002, May). Snnb: A selective neighborhood based naive Bayes for lazy learning. In *Pacific-Asia Conference on Knowledge Discovery and Data Mining* (pp. 104-114). Springer, Berlin, Heidelberg.
- [180]: Moldagulova, A., & Sulaiman, R. B. (2017, May). Using KNN algorithm for classification of textual documents. In *2017 8th International Conference on Information Technology (ICIT)* (pp. 665-671). IEEE.
- [181]: Zhang, S. (2020). Cost-sensitive KNN classification. *Neurocomputing*, 391, 234-242.
- [182]: Zhang, S., Li, X., Zong, M., Zhu, X., & Cheng, D. (2017). Learning k for knn classification. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 8(3), 1-19.
- [183]: <https://www.kaggle.com/datasets/jsrojas/labeled-network-traffic-flows-114-applications>
- [184]: <https://pandas.pydata.org/>
- [185]: <https://numpy.org/>
- [186]: <https://docs.python.org/3/library/csv.html>
- [187]: <https://matplotlib.org/>
- [188]: <https://scikit-learn.org/stable/>
- [189]: <https://keras.io/>

- [190]: Jyothi, S. A., Singla, A., Godfrey, P. B., & Kolla, A. (2016, November). Measuring and understanding throughput of network topologies. In *SC'16: Proceedings of the International Conference for High Performance Computing, Networking, Storage and Analysis* (pp. 761-772). IEEE.
- [191]: Kubat, P. (1988). Assessing throughput and reliability in communication and computer networks. *IEEE transactions on reliability*, 37(3), 208-211.
- [192]: Liu, W., Zhao, D., & Zhu, G. (2014). End-to-end delay and packet drop rate performance for a wireless sensor network with a cluster-tree topology. *Wireless Communications and Mobile Computing*, 14(7), 729-744.
- [193]: Tsang, Y., Coates, M., & Nowak, R. D. (2003). Network delay tomography. *IEEE Transactions on Signal Processing*, 51(8), 2125-2136.
- [194]: Lloyd, S. P. (1957). *Least squares quantization in PCM*. Technical Report RR-5497, Bell Lab, September 1957.
- [195]: MacQueen, J. (1967, June). Some methods for classification and analysis of multivariate observations. In *Proceedings of the fifth Berkeley symposium on mathematical statistics and probability* (Vol. 1, No. 14, pp. 281-297).
- [196]: Duda, R. O., & Hart, P. E. (1973). *Pattern classification and scene analysis* (Vol. 3, pp. 731-739). New York: Wiley.
- [197]: Fix, Evelyn, Hodges, Joseph L. (1951). *Discriminatory Analysis, Nonparametric Discrimination: Consistency Properties (Report)*. USAF School of Aviation Medicine, Randolph, Field, Texas.
- [198]: Altman, N. S. (1992). An introduction to kernel and nearest-neighbor nonparametric regression. *The American Statistician*, 46(3), 175-185.