



ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ
ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ
ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ
ΥΠΟΛΟΓΙΣΤΩΝ

Πρόγραμμα Μεταπτυχιακών Σπουδών
Επιστήμη και Τεχνολογία της Πληροφορικής
και των Υπολογιστών
Ειδίκευση Δικτύων Επικοινωνιών & Κατακεμημένων
Συστημάτων

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Τεχνικές μηχανικής μάθησης για την αντιμετώπιση των
φαινομένων διάδοσης σε δίκτυα οπτικών ινών

Δημήτριος Ι. Τζήκας
A. M. mcse_20016

Υπ. Καθηγητής: Αντ. Μπόγρης
Καθηγητής

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

**Τεχνικές μηχανικής μάθησης για την αντιμετώπιση των
φαινομένων διάδοσης σε δίκτυα οπτικών ινών**

Δημήτριος Ι. Τζήκας

A. M. mcse_20016

Επιβλέπων:

Αντώνιος Μπόγρης, Καθηγητής

Εξεταστική Επιτροπή:

Βασίλειος Μάμαλης, Καθηγητής

Νικόλαος Ψαρράς, Λέκτορας

Ημερομηνία εξέτασης: 10/02/2023

ΔΗΛΩΣΗ ΣΥΓΓΡΑΦΕΑ ΜΕΤΑΠΤΥΧΙΑΚΗΣ ΕΡΓΑΣΙΑΣ

Ο κάτωθι υπογεγραμμένος

Δημήτριος Τζήκας του Ιωάννη, με αριθμό μητρώου mcse_20016 φοιτητής του Προγράμματος Μεταπτυχιακών Σπουδών Επιστήμη και Τεχνολογία της Πληροφορικής και των Υπολογιστών του Τμήματος Μηχανικών Πληροφορικής και Υπολογιστών της Σχολής Μηχανικών του Πανεπιστημίου Δυτικής Αττικής, δηλώνω ότι:

«Είμαι συγγραφέας αυτής της μεταπτυχιακής εργασίας και ότι κάθε βοήθεια την οποία είχα για την προετοιμασία της, είναι πλήρως αναγνωρισμένη και αναφέρεται στην εργασία. Επίσης, οι όποιες πηγές από τις οποίες έκανα χρήση δεδομένων, ιδεών ή λέξεων, είτε ακριβώς είτε παραφρασμένες, αναφέρονται στο σύνολό τους, με πλήρη αναφορά στους συγγραφείς, τον εκδοτικό οίκο ή το περιοδικό, συμπεριλαμβανομένων και των πηγών που ενδεχομένως χρησιμοποιήθηκαν από το διαδίκτυο. Επίσης, βεβαιώνω ότι αυτή η εργασία έχει συγγραφεί από μένα αποκλειστικά και αποτελεί προϊόν πνευματικής ιδιοκτησίας τόσο δικής μου, όσο και του Ιδρύματος.

Παράβαση της ανωτέρω ακαδημαϊκής μου ευθύνης αποτελεί ουσιώδη λόγο για την ανάκληση του πτυχίου μου».

Επιθυμώ την απαγόρευση πρόσβασης στο πλήρες κείμενο της εργασίας μου μέχρι τις 28/2/2023 και έπειτα από αίτηση μου στη Βιβλιοθήκη και έγκριση του επιβλέποντα καθηγητή.

Ο Δηλών



Ευχαριστίες

Η παρούσα διπλωματική εργασία ολοκληρώθηκε μετά από επίμονες προσπάθειες, σε ένα ενδιαφέρον γνωστικό αντικείμενο, όπως αυτό των δικτύων οπτικών ινών καθώς και αυτό της μηχανικής μάθησης. Την προσπάθειά μου αυτή υποστήριξε ο επιβλέπων καθηγητής μου κ. Μπόγγρης Αντώνιος τον οποίο θα ήθελα να ευχαριστήσω.

Επιπλέον θα ήθελα να ευχαριστήσω την οικογένεια μου για τη στήριξη της σε όλη αυτή την πορεία των ακαδημαϊκών μου χρόνων.

Περίληψη

Στη σημερινή εποχή τα δίκτυα τηλεπικοινωνιών αποτελούν πηγές μεγάλης ποσότητας ετερογενών δεδομένων, όπως για παράδειγμα δεδομένα για επιλογή των κατάλληλων μονοπατιών κίνησης στο δίκτυο, ειδοποιήσεις δικτύου, δείκτες ποιότητας σήματος και δεδομένα συμπεριφοράς χρήστη. Για το λόγο αυτό, κρίνεται απαραίτητο να εκπαιδεύονται και να χρησιμοποιούνται προηγμένες μαθηματικές προσεγγίσεις που να επεξεργάζονται το σύνολο των εισαγόμενων δεδομένων με σκοπό την εξαγωγή χρήσιμων πληροφοριών και συμπερασμάτων προκειμένου οι αποφάσεις που θα ληφθούν να οδηγήσουν στην σωστή λειτουργία των δικτύων. Η εφαρμογή τεχνικών μηχανικής μάθησης αποτελεί ένα σημαντικό και πολλά υποσχόμενο εργαλείο για την καλύτερη ανάλυση δεδομένων του δικτύου.

Η τεράστια αύξηση της πολυπλοκότητας στα δίκτυα οπτικών επικοινωνιών τα τελευταία χρόνια, έχει οδηγήσει τους διάφορους ερευνητές και επιστήμονες στην αυξημένη υιοθέτηση τεχνικών μηχανικής μάθησης. Η συγκεκριμένη αύξηση στην πολυπλοκότητα οφείλεται στην εισαγωγή του μεγάλου αριθμού ρυθμιζόμενων και αλληλεξαρτώμενων παραμέτρων του συστήματος όπως για παράδειγμα ρυθμίσεων δρομολόγησης, τρόπων διαμόρφωσης, ρυθμού συμβόλων και σχημάτων κωδικοποίησης, τα οποία ενεργοποιούνται από τη χρήση συνεκτικών τεχνολογιών μετάδοσης και λήψης, προηγμένης επεξεργασίας ψηφιακού σήματος και αντιστάθμισης μη γραμμικών φαινομένων διάδοσης σε δίκτυα οπτικών ινών.

Αντικείμενο της παρούσας διπλωματικής εργασίας είναι η διερεύνηση σύγχρονων τεχνικών μηχανικής και βαθιάς μάθησης για την αντιμετώπιση των μη γραμμικών και γραμμικών φαινομένων μετάδοσης. Ο κεντρικός άξονας της εργασίας αυτής αφορά τη βιβλιογραφική έρευνα για τις σύγχρονες τεχνικές μηχανικής μάθησης που αξιοποιούνται σε συστήματα άμεσης και ομόδυνης φώρασης με σκοπό να περιοριστούν ή και να εξαλειφθούν τα μη γραμμικά φαινόμενα.

Abstract

Nowadays, telecommunication networks are sources of a large amount of heterogeneous data, such as for example data for the selection of appropriate network movement paths, network alerts, signal quality indicators and user behavior data. For this reason, it is considered necessary to train and use advanced mathematical approaches that process all the input data in order to extract useful information and conclusions in order for the decisions to be made to lead to the correct operation of the networks. The application of machine learning techniques is an important and promising tool for better network data analysis.

The enormous increase of complexity in optical communication networks in recent years has led various researchers and scientists to the increased adoption of machine learning techniques. This particular increase in complexity is due to the introduction of a large number of configurable and interdependent system parameters such as routing settings, modulation modes, symbol rates and coding schemes, enabled by the use of coherent transmission and reception technologies, advanced digital signal processing and compensation of non-linear propagation effects in fiber optic networks.

The subject of this thesis is the investigation of modern engineering and deep learning techniques to deal with non-linear and linear transmission phenomena. The central axis of this work concerns the bibliographic research on modern machine learning techniques that are used in direct and homogeneous feed systems in order to limit or even eliminate non-linear effects.

Περιεχόμενα

Ευχαριστίες.....	7
Περίληψη.....	9
Abstract.....	10
Περιεχόμενα	11
Κατάλογος Εικόνων.....	15
Κατάλογος Σχημάτων.....	16
Κατάλογος Πινάκων	17
ΚΕΦΑΛΑΙΟ 1 ^ο - ΣΤΟΙΧΕΙΑ ΟΠΤΙΚΩΝ ΙΝΩΝ	18
1. 1 Εισαγωγή στις οπτικές ίνες	18
1. 2 Δομή οπτικών ινών.....	19
1. 3 Κατηγορίες οπτικών ινών	20
ΚΕΦΑΛΑΙΟ 2 ^ο – ΟΠΤΙΚΕΣ ΙΝΕΣ – ΧΑΡΑΚΤΗΡΙΣΤΙΚΑ ΜΕΓΕΘΗ.....	22
2. 1 Η εξασθένιση στις οπτικές ίνες	22
2. 2 Το φαινόμενο της σκέδασης	22
2. 2. 1 Εισαγωγή.....	22
2. 2. 2 Η γραμμική σκέδαση.....	23
2. 2. 3 Η σκέδαση Rayleigh	23
2. 2. 4 Η σκέδαση Mie.....	24
2. 2. 5 Η μη γραμμική σκέδαση	24
2. 3 Η απορρόφηση του υλικού και του φωτός στις οπτικές ίνες	25
2. 4 Φαινόμενα διασποράς στις οπτικές ίνες	26
2. 4. 1 Εισαγωγή.....	26
2. 4. 2 Διασπορά στον τρόπο μετάδοσης	27
2. 4. 3 Διασπορά του υλικού.....	27
	11

2. 4. 4 Διασπορά κυματοδήγησης	28
2. 4. 5 Διασπορά πόλωσης -τρόπου μετάδοσης.....	28
2. 5 Μη γραμμικά φαινόμενα	29
2. 5. 1 Αντιμετώπιση μη γραμμικών φαινομένων	30
ΚΕΦΑΛΑΙΟ 3 ^ο – ΣΥΣΤΗΜΑΤΑ ΜΕΤΑΔΟΣΗΣ	32
3. 1 Συστήματα μικρών ή μεσαίων αποστάσεων (< 80 km).....	32
3. 2 Συστήματα μεγάλων αποστάσεων (> 80 km).....	33
3. 3 400 Gb Ethernet	36
3. 3. 1 Εισαγωγή.....	36
3. 3. 2 Οι οικονομικοί περιορισμοί Shannon	37
3. 3. 3 Προκλήσεις μετάβασης στα 400 GbE σε φυσικό επίπεδο	39
3. 4 Σύμφωνη Πολυπλεξία διαίρεσης μήκους κύματος (WDM coherent). 41	
3. 4. 1 Εισαγωγή.....	41
3. 4. 2 Σύμφωνη ανίχνευση(coherent detection)	42
ΚΕΦΑΛΑΙΟ 4 ^ο – ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ	44
4. 1 Εισαγωγή.....	44
4. 2 Μάθηση με Επίβλεψη	45
4. 2. 1 Δέντρα αποφάσεων	45
4. 2. 2 Αλγόριθμος Bayes	46
4. 2. 3 Μηχανές διανυσμάτων υποστήριξης.....	47
4. 2. 4 Μάθηση βασισμένη σε στιγμιότυπα	48
4. 3 Μάθηση χωρίς Επίβλεψη.....	49
4. 4 Μάθηση με Ημι-Επίβλεψη	50
4. 5 Μηχανική Μάθηση με ενίσχυση	52
4. 6 Νευρωνικά δίκτυα.....	53
4. 6. 1 Ορισμός.....	53

4. 6. 2 Δομή Νευρωνικού Δικτύου	54
4. 6. 3 Αρχιτεκτονική Νευρωνικού Δικτύου	55
4. 6. 4 Τοπολογίες Νευρωνικών Δικτύων	63
4. 6. 5 Εκπαίδευση Νευρωνικών Δικτύων	69
4. 7 Deep learning	72
ΚΕΦΑΛΑΙΟ 5 ^ο – ΑΝΑΛΥΣΗ ΣΥΣΤΗΜΑΤΩΝ ΜΕ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ	74
5. 1 Εισαγωγή	74
5. 2 Προκλήσεις μηχανικής μάθησης σε δίκτυα οπτικών ινών	75
5. 3 Εφαρμογές μηχανικής μάθησης σε φυσικό επίπεδο	76
5. 3. 1 Εκτίμηση Ποιότητας Μετάδοσης	77
5. 3. 2 Έλεγχος οπτικών ενισχυτών	79
5. 3. 3 Αναγνώριση σχήματος διαμόρφωσης	80
5. 3. 4 Εξομάλυνση μη γραμμικότητας	80
5. 3. 5 Παρακολούθηση αποδοτικότητας οπτικού επιπέδου	81
5. 4 Εφαρμογές μηχανικής μάθησης σε επίπεδο δικτύου	84
5. 4. 1 Πρόβλεψη κίνησης	85
5. 4. 2 Σχεδίαση και αναδιαμόρφωση της εικονικής τοπολογίας	86
5. 4. 3 Διαχείριση απωλειών	87
5. 4. 4 Υπολογισμός διαδρομής	89
ΚΕΦΑΛΑΙΟ 6 ^ο – ΑΝΑΛΥΤΙΚΗ ΠΕΡΙΓΡΑΦΗ ΕΠΙΛΕΓΜΕΝΩΝ	92
ΕΦΑΡΜΟΓΩΝ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΣΤΑ ΟΠΤΙΚΑ ΔΙΚΤΥΑ	92
6. 1 Εφαρμογές μηχανικής μάθησης για την εξομάλυνση της μη	92
γραμμικότητας	92
6. 2 Εφαρμογές μηχανικής μάθησης για την πρόβλεψη της κίνησης και..	94
σχεδιασμού της εικονικής τοπολογίας	94
6. 3 Εφαρμογές μηχανικής μάθησης για τον υπολογισμό διαδρομής	98

6. 4 Αξιολόγηση αλγορίθμων μηχανικής μάθησης στα οπτικά δίκτυα.....	99
6. 4. 1 Ανάλυση μετρικών απόδοσης.....	99
6. 4. 2 Ποσοτική σύγκριση αλγορίθμων	102
ΚΕΦΑΛΑΙΟ 7 ^ο – ΣΥΜΠΕΡΑΣΜΑΤΑ-ΜΕΛΛΟΝΤΙΚΕΣ ΕΞΕΛΙΞΕΙΣ	104
7. 1 Μελλοντικές εξελίξεις	104
7. 2 Συμπεράσματα	108
ΒΙΒΛΙΟΓΡΑΦΙΑ.....	110

Κατάλογος Εικόνων

Εικόνα 1: Δομή οπτικής ίνας.....	17
Εικόνα 2: Απεικόνιση κατηγοριών οπτικών ινών.....	19
Εικόνα 3: Το φαινόμενο της σκέδασης Rayleigh.....	21
Εικόνα 4: Το φαινόμενο της σκέδασης Mie.....	22
Εικόνα 5: Είδη μη γραμμικής σκέδασης.....	23
Εικόνα 6: Το φαινόμενο της διασποράς.....	24
Εικόνα 7: Το φαινόμενο της διασποράς πόλωσης-τρόπου μετάδοσης PMD..	27
Εικόνα 8: Είδη μη γραμμικών φαινομένων στις οπτικές ίνες.....	28
Εικόνα 9: Ταξινόμηση (A) γραμμική, (B) μη γραμμική.....	45
Εικόνα 10: Αποτελέσματα εφαρμογής αλγορίθμου K-NN.....	46
Εικόνα 11: Μεθοδολογία μάθησης χωρίς επίβλεψη.....	47
Εικόνα 12: Μεθοδολογία μάθησης με ημι- επίβλεψη.....	48
Εικόνα 13: Απεικόνιση μηχανικής μάθησης με ενίσχυση.....	51
Εικόνα 14: Απεικόνιση δομής ενός νευρωνικού δικτύου.....	52
Εικόνα 15: Απεικόνιση ενός Feed-Forward νευρωνικού δικτύου ενός κρυφού επιπέδου(3 νευρώνων).....	54
Εικόνα 16: Απεικόνιση ενός Feedback νευρωνικού δικτύου.....	55
Εικόνα 17: Απεικόνιση ενός τεχνητού νευρώνα Perceptron.....	62
Εικόνα 18: Απεικόνιση ενός Multi-Layer Perceptron με δύο κρυφά επίπεδα..	63
Εικόνα 19: Προσέγγιση για την εκτίμηση του OSNR των WDM μηκών κύματος..	76

Κατάλογος Σχημάτων

Σχήμα 1: Υλοποίηση ενός συνεκτικού συστήματος μετάδοσης.....	41
Σχήμα 2: Κατηγοριοποίηση ειδών μηχανικής μάθησης.....	42
Σχήμα 3: Δομή δένδρου απόφασης.....	44
Σχήμα 4: Διαδικασία Βηματική Συνάρτηση ενεργοποίησης.....	56
Σχήμα 5: Γραμμική Συνάρτηση ενεργοποίησης.....	57
Σχήμα 6: Σιγμοειδής Συνάρτηση ενεργοποίησης.....	58
Σχήμα 7: Συνάρτηση υπερβολικής εφαπτομένης	59
Σχήμα 8: Σύγκριση σιγμοειδούς συνάρτησης με συνάρτηση υπερβολικής εφαπτομένης	59
Σχήμα 9: Ανορθωτική Γραμμική Συνάρτηση	60
Σχήμα 10: Συνάρτηση Softmax	61
Σχήμα 11: Αρχιτεκτονική μονάδας Αναδρομικού Νευρωνικού Δικτύου RNN.....	65
Σχήμα 12: Αρχιτεκτονική Συνελκτικού Νευρωνικού Δικτύου CNN.....	66
Σχήμα 13: Διάγραμμα ροής εκμάθησης Τεχνητού Νευρωνικού Δικτύου....	68
Σχήμα 14: Διάγραμμα εύρεσης ιδανικού σημείου εκπαίδευσης για αποφυγή της υπερεκπαίδευσης.....	69

Κατάλογος Πινάκων

Πίνακας 1: Περιπτώσεις χρήσης στο φυσικό επίπεδο και τα χαρακτηριστικά τους.....	83
Πίνακας 2: Περιπτώσεις χρήσης στο επίπεδο δικτύου και τα χαρακτηριστικά τους.....	91
Πίνακας 3: Σύγκριση αλγορίθμων μηχανικής μάθησης και μετρικών απόδοσης για διάφορες περιπτώσεις χρήσης.....	103

ΚΕΦΑΛΑΙΟ 1^ο - ΣΤΟΙΧΕΙΑ ΟΠΤΙΚΩΝ ΙΝΩΝ

1.1 Εισαγωγή στις οπτικές ίνες


Η κατασκευή καλωδίων από χαλκό και η χρησιμοποίησή τους ως μέσο μεταφοράς πληροφοριών γίνεται σε λιγοστά κράτη του κόσμου με αποτέλεσμα όλες οι υπόλοιπες χώρες να είναι εξαρτημένες από τις χώρες παραγωγούς. Το γεγονός αυτό ώθησε τους ερευνητές από πολύ νωρίς στην πρόταση εναλλακτικών λύσεων για τη γρηγορότερη και αποδοτικότερη μεταφορά πληροφοριών με σκοπό την απεξάρτηση των υπόλοιπων χωρών από τις χώρες-παραγωγούς χαλκού, την αποτροπή υποκλοπών στο χώρο των τηλεπικοινωνιών και τη μεταφορά μεγαλύτερου όγκου πληροφοριών. Η ανάγκη αυτή οδήγησε στην κατασκευή των οπτικών ινών. Η χρήση του φωτός ως μέσο μεταφοράς πληροφορίας δεν αποτελεί κάτι καινούργιο καθώς ο άνθρωπος από πολύ νωρίς χρησιμοποιούσε οπτικές περιοχές για να μεταδώσει πληροφορίες σε κοντινές αλλά και μακρινές αποστάσεις [1]. Οι οπτικές ίνες αποτελούν μεγάλο κεφάλαιο στο χώρο των τηλεπικοινωνιών, το οποίο προσφέρει μετάδοση ήχου, εικόνας και video σε πολύ υψηλές ταχύτητες και χρησιμοποιούνται τόσο σε τοπικά δίκτυα (local networks) όσο και σε δίκτυα ευρείας περιοχής (wide area networks).

Η χρήση των οπτικών ινών παρουσιάζει σημαντικά πλεονεκτήματα έναντι των καλωδίων χαλκού, με τα κυριότερα εξ αυτών να είναι το μεγαλύτερο εύρος ζώνης που οδηγεί σε υψηλότερους ρυθμούς μετάδοσης, η πολύ μικρή απόσβεση που επιτρέπει την επικοινωνία μεγαλύτερων αποστάσεων, η θωράκισή τους έναντι των ηλεκτρομαγνητικών παρεμβολών και παρεμβολών ραδιοσυχνοτήτων, η μη πρόκληση παρεμβολών προς άλλα φυσικά μέσα, ο σημαντικά χαμηλός ρυθμός εμφάνισης σφαλμάτων (Bit Error Rate, BER), το ελαφρύ και μικρού όγκου υλικό καθώς και η ασφάλεια έναντι υποκλοπών με φυσική επέμβαση σε αυτές.

1.2 Δομή οπτικών ινών

Η οπτική ίνα είναι ένας γυάλινος κυματοδηγός με κυλινδρική διατομή στον οποίο καθοδηγείται το φως μέσω του φαινομένου της ολικής εσωτερικής ανάκλασης. Αποτελείται από διάφορα υλικά όπου καθένα από αυτά έχει διαφορετικό δείκτη διάθλασης ώστε να περιορίζεται και να καθοδηγείται το φως με το σωστό τρόπο. Το κυριότερο μέρος μιας οπτικής ίνας είναι ο πυρήνας (core) της, ο οποίος είναι η κύρια περιοχή όπου καταλήγει η πληροφορία μέσω του φωτός.

Τυπικές διαστάσεις πυρήνα για χρήση στις τηλεπικοινωνίες είναι 8.3 μm στην περίπτωση μονότροπων ινών, 50 μm και 62.5 μm στην περίπτωση πολύτροπων ινών. Επιπλέον μία οπτική ίνα αποτελείται από την επένδυση (cladding) η οποία βρίσκεται πλησίον του πυρήνα και το υλικό κατασκευής της είναι το γυαλί. Διαθέτει μικρότερο δείκτη διάθλασης σε σχέση με τον πυρήνα με αποτέλεσμα το φως να μην διαπερνάει την επένδυση αλλά να παραμένει στην περιοχή του πυρήνα. Η διάμετρος της επένδυσης είναι στα 125 μm , ενώ ο πυρήνας δεν μπορεί να διαχωριστεί από την επένδυση καθώς η κατασκευή τους είναι στο ίδιο κομμάτι γυαλιού πυριτίου με ελάχιστες διαφορές στην σύνθεσή τους. Το τελευταίο μέρος της οπτικής ίνας είναι το επίστρωμα (coating) το οποίο αποτελεί το εξωτερικό στρώμα της ίνας κατασκευασμένο από πλαστικό με σκοπό την προστασία της από εξωτερικούς παράγοντες (όπως υγρασία, μεταβολές θερμοκρασίας). Κατά τη διαδικασία της εγκατάστασης το επίστρωμα αφαιρείται από την επένδυση με σκοπό την κατάληξή του σε ένα οπτικό σύστημα μετάδοσης. Η διάμετρος του επιστρώματος είναι 250 μm ή 900 μm [2].



Εικόνα 1. Δομή οπτικής ίνας

1.3 Κατηγορίες οπτικών ινών

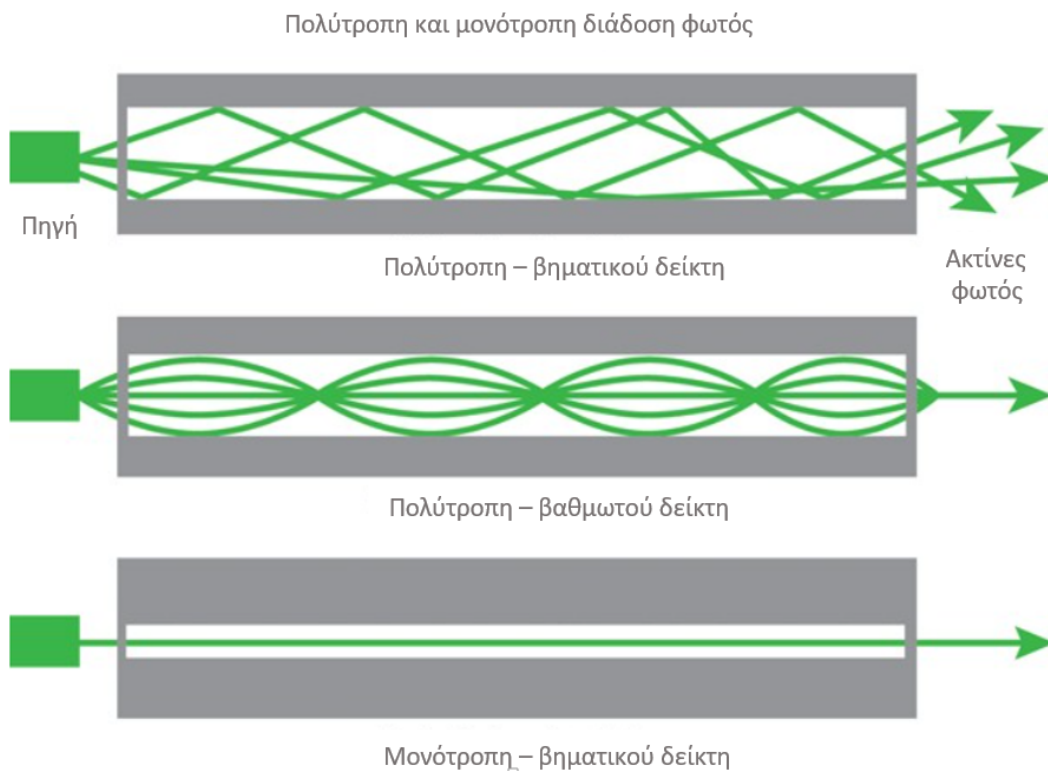
Οι οπτικές ίνες διακρίνονται σε κατηγορίες ανάλογα με το υλικό κατασκευής του πυρήνα και του μανδύα τους, τη μεταβολή του δείκτη διάθλασης από τον πυρήνα στον μανδύα καθώς επίσης και από το σύνολο των τρόπων μετάδοσης που υποστηρίζουν. Όσο αναφορά το υλικό κατασκευής υπάρχουν εξ ολοκλήρου οπτικές ίνες φτιαγμένες από γυαλί οι οποίες αποτελούν και το πιο ευρέως γνωστό είδος οπτικών ινών με χρησιμότητα στις τηλεπικοινωνίες. Σε αυτή την κατηγορία τόσο η κατασκευή του πυρήνα όσο και του μανδύα είναι αμιγώς από συνθετικό γυαλί διοξειδίου του πυριτίου, στο οποίο περιέχονται επιπλέον προσμίξεις προκειμένου να επιτευχθεί η προσδοκώμενη διαφορά στο συντελεστή διάθλασης μεταξύ πυρήνα και μανδύα. Υπάρχουν οι ίνες με γυάλινο πυρήνα και πλαστικό μανδύα, οι οποίες τείνουν να αντικατασταθούν από τις πλαστικές ίνες και υπάρχουν και οι αμιγώς πλαστικές ίνες οι οποίες σε σχέση με τα υπόλοιπα είδη παρουσιάζουν τη χειρότερη απόδοση ως προς την ελάχιστη εξασθένιση, το επιδιωκόμενο εύρος ζώνης και τις μεταβολές της θερμοκρασίας.

Το μεγαλύτερο ενδιαφέρον επικεντρώνεται στην κατηγορία που σχετίζεται με τους τρόπους μετάδοσης που υποστηρίζουν οι οπτικές ίνες. Στην κατηγορία αυτή έχουμε τις πολύτροπες οπτικές ίνες (multimode fiber optics) οι οποίες διακρίνονται σε μεγέθη όπως 50 μm έως 125 μm , 62.5 μm έως 125 μm , 85 μm έως 125 μm ή 100 μm έως 140 μm με πιο συνηθισμένο το μέγεθος των 62.5 μm έως 125 μm [3]. Μία οπτική ίνα που περιέχει εκτός από συνθετικές ίνες συνθετικό περίβλημα έχει διάμετρο 900 μm . Η αρχή μετάδοσης στις πολύτροπες οπτικές ίνες περιλαμβάνει διάφορες ακτίνες του οπτικού σήματος, οι οποίες αφού εισαχθούν στην οπτική ίνα περιφέρονται ανακλώμενες υπό διαφορετικές γωνίες. Ο συγκεκριμένος τρόπος ανάκλασης ονομάζεται πολύτροπος λόγω των πολλών δρόμων μετάδοσης που αντιστοιχούν σε διαφορετικές γωνίες ανάκλασης. Έτσι προκύπτει ο διαχωρισμός των πολύτροπων οπτικών ινών σε δύο υποκατηγορίες εκείνες του διακριτού βήματος (step index) και εκείνες του βαθμιαίου βήματος (graded index)[4].

Στις οπτικές ίνες διακριτού βήματος δημιουργείται απότομη μεταβολή του δείκτη διάθλασης ανάμεσα στην κεντρική ίνα και στο υλικό επίστρωσης. Αυτό έχει

σαν αποτέλεσμα οι ακτίνες φωτός να εμφανίζουν μία περίπλοκη πορεία όπως φαίνεται στην Εικόνα 2. Στις οπτικές ίνες βαθμιαίου βήματος ο δείκτης διάθλασης του υλικού της κεντρικής ίνας μεταβάλλεται με βαθμιαίο τρόπο. Επιπλέον συμβαίνει και μία βαθμιαία μείωση κατά την απομάκρυνση από την κεντρική προς την εξωτερική επιφάνεια του γυαλιού. Αυτό έχει σαν αποτέλεσμα η πορεία των ακτινών να είναι διαφορετική από εκείνη των οπτικών ινών διακριτού βήματος.

Η μεγαλύτερη διαφορά εντοπίζεται στην κατηγορία των μονότροπων οπτικών ινών όπου η διάμετρος της κεντρικής ίνας είναι τόσο μικρή σε μέγεθος σε σημείο που εξισώνεται με το μήκος κύματος του εκπεμπόμενου σήματος. Το μέγεθος της διαμέτρου της κεντρικής ίνας κυμαίνεται από 5 μm έως 10 μm με πιο σύνηθες τα 8.3 μm . Ο τρόπος μετάδοσης στην περίπτωση αυτή ονομάζεται αξονικός και η πορεία των ακτινών φαίνεται επίσης στην Εικόνα 2.



Εικόνα 2. Απεικόνιση κατηγοριών οπτικών ινών

ΚΕΦΑΛΑΙΟ 2^ο – ΟΠΤΙΚΕΣ ΙΝΕΣ – ΧΑΡΑΚΤΗΡΙΣΤΙΚΑ ΜΕΓΕΘΗ

2. 1 Η εξασθένιση στις οπτικές ίνες

Η εξασθένιση (απώλεια) στις οπτικές ίνες αποτελεί έναν από τους βασικούς περιοριστικούς παράγοντες στις τηλεπικοινωνίες καθώς μειώνει τη μέση ισχύ που φτάνει τελικά στο δέκτη. Η απώλεια της ίνας εξαρτάται από το μήκος κύματος του φωτός που μεταδίδεται κατά την κυματοδήγηση, τυπικές τιμές απωλειών είναι 150 db/km για τις πλαστικές ίνες και 0,21 db/km στις μονότροπες ίνες[5].

Ως επί των πλείστων, υπάρχουν πολλοί και διαφορετικοί μηχανισμοί που ευθύνονται για την εξασθένιση του σήματος μέσα σε μία οπτική ίνα. Μπορεί να γίνει διαχωρισμός σε κατηγορίες οι οποίες να περιλαμβάνουν μηχανισμούς όπως η απορρόφηση και η σκέδαση του υλικού καθώς επίσης και οι ατέλειες του κυματοδηγού. Οι πιο σημαντικοί παράγοντες από αυτούς που αναφέρονται παραπάνω είναι η απορρόφηση του υλικού και η σκέδαση Rayleigh οι οποίες θα αναφερθούν στις παρακάτω υποενότητες.

2. 2 Το φαινόμενο της σκέδασης

2. 2. 1 Εισαγωγή

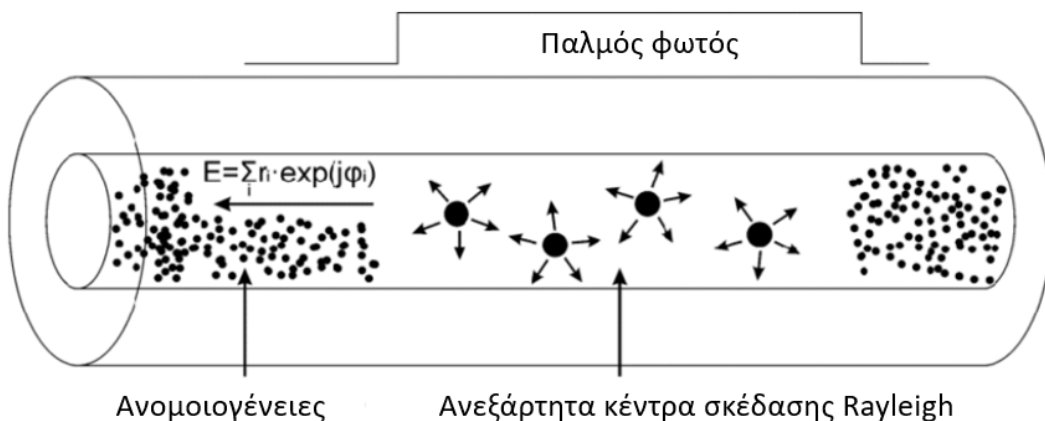
Ως σκέδαση ορίζονται οι απώλειες της οπτικής ενέργειας που εμφανίζονται λόγω των απωλειών που δημιουργούνται στη βασική δομή της οπτικής ίνας. Τα βασικά είδη σκέδασης είναι η γραμμική σκέδαση, η σκέδαση Rayleigh, η σκέδαση Mie και η μη γραμμική σκέδαση.

2. 2. 2 Η γραμμική σκέδαση

Η γραμμική σκέδαση αποτελείται από μηχανισμούς οι οποίοι μπορούν να οδηγήσουν στη γραμμική μεταφορά κάποιου μικρού ποσοστού ή ολόκληρης της οπτικής ισχύος κατά τη διάρκεια της μετάδοσης του σήματος. Το φαινόμενο της γραμμικής σκέδασης διαιρείται σε δύο υποκατηγορίες τις σκεδάσεις Rayleigh και Mie.

2. 2. 3 Η σκέδαση Rayleigh


Η σκέδαση Rayleigh αποτελεί ένα από τους βασικούς μηχανισμούς απώλειας ο οποίος δημιουργείται από διακυμάνσεις που λαμβάνουν χώρα στην πυκνότητα. Πιο συγκεκριμένα, από την τυχαία κίνηση των μορίων του πυριτίου επέρχεται σταθεροποίηση κατά τη φάση δημιουργίας της οπτικής ίνας. Οι διακυμάνσεις της πυκνότητας οδηγούν στην τυχαία διακύμανση του δείκτη διάθλασης σε κλίμακα μικρότερη του οπτικού μήκους κύματος λ . Επομένως όσο υψηλότερο είναι το μήκος κύματος μετάδοσης τόσο περισσότερο ελαχιστοποιείται η απώλεια σκέδασης Rayleigh[6].



Εικόνα 3. Το φαινόμενο της σκέδασης Rayleigh

2. 2. 4 Η σκέδαση Mie

Ο οπτικός τρόπος μετάδοσης χωρίς διαρροές ενέργειας στο στρώμα του περιβλήματος προκαλείται από μια ιδανική μονότροπη οπτική ίνα με ιδανική κυλινδρική δομή. Ουσιαστικά, επιπλέον απώλειες μπορεί να δημιουργηθούν στην περιοχή όπου ενώνονται ο πυρήνας και το στρώμα του περιβλήματος, συνεισφέροντας έτσι στις συνολικές απώλειες της καθαρής οπτικής ίνας. Η δημιουργία τέτοιων απωλειών οφείλεται στο φαινόμενο της σκέδασης Mie το οποίο εμφανίζεται εξαιτίας της ανομοιογένειας του δείκτη διάθλασης, στις διάφορες διαφοροποιήσεις που αφορούν τη διάμετρο του πυρήνα σε όλο το μήκος της οπτικής ίνας καθώς και στην ύπαρξη μικρών φυσαλίδων[6].



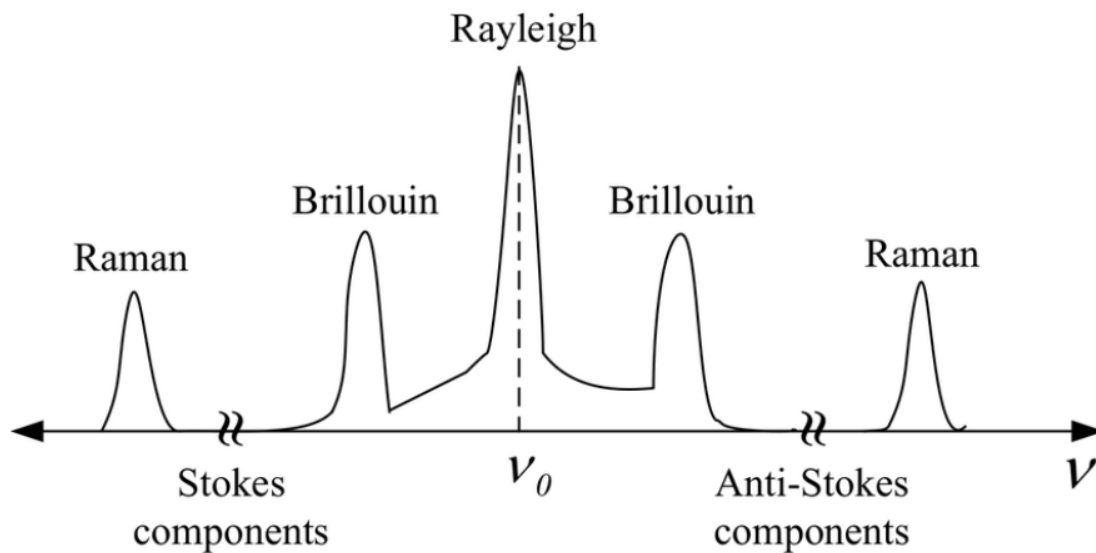
Εικόνα 4. Το φαινόμενο της σκέδασης Mie

2. 2. 5 Η μη γραμμική σκέδαση

Η συμπεριφορά των οπτικών κυματοδηγών ως πλήρως γραμμικά κανάλια συμπίπτει με την αναλογική αύξηση οπτικής ισχύος εισόδου σε σχέση με την οπτική ισχύ εξόδου. Στην περίπτωση αυτή δημιουργούνται διάφορα μη γραμμικά φαινόμενα τα οποία όπως και με το φαινόμενο της σκέδασης οδηγούν σε μία μη αναλογική εξασθένιση (συγκεκριμένα στα υψηλά επίπεδα ισχύος). Η μη γραμμική

σκέδαση έχει ως αποτέλεσμα τη μεταφορά της οπτικής ισχύος από τον έναν τρόπο μετάδοσης σε κάποιον άλλο ο οποίος έχει διαφορετική συχνότητα. [7][8]

Η παραπάνω μη γραμμική συμπεριφορά βασίζεται σε μεγάλο βαθμό στην πυκνότητα που παρουσιάζει η οπτική ισχύς της οπτικής ίνας με αποτέλεσμα η εξάρτηση αυτή να καθορίζει τις τιμές ισχύος πάνω από ορισμένα επίπεδα κατωφλίου. Οι δύο πιο σημαντικοί τύποι με γραμμικής σκέδασης που συναντώνται στις οπτικές ίνες είναι η διεγερόμενη σκέδαση Raman και η διεγερόμενη σκέδαση Brillouin οι οποίες απαντώνται μόνο για υψηλές πυκνότητες οπτικής ισχύος[9]. Η σκέδαση Rayleigh ανήκει τις ελαστικές σκεδάσεις για τις οποίες η συχνότητα (ενέργεια φωτονίου) του σκεδαζόμενου φωτός παραμένει αμετάβλητη.



Εικόνα 5. Είδη μη γραμμικής σκέδασης

2.3 Η απορρόφηση του υλικού και του φωτός στις οπτικές ίνες


Είναι ευρέως γνωστό ότι η κατασκευή των οπτικών ινών είναι από πυρίτιο το οποίο έχει υποστεί τήξη. Η απορρόφηση του υλικού είναι ένας μηχανισμός απωλειών ο οποίος σχετίζεται με τη σύνθεση του υλικού αλλά και της οπτικής ίνας

με αποτέλεσμα να οδηγεί στην κατανάλωση ενός ποσοστού της οπτικής ισχύος που μεταδίδεται στον κυματοδηγό με τη μορφή θερμότητας. Η απορρόφηση του φωτός διακρίνεται σε ενδογενής δηλαδή να οφείλεται στις απώλειες που προκαλούνται από το καθαρό πυρίτιο και σε εξωγενής δηλαδή να οφείλεται στην πρόσμιξη του γυαλιού. Καθένα από τα υλικά παρουσιάζουν απορρόφηση σε συγκεκριμένα μήκη κύματος το καθένα, τα οποία αντιστοιχούν σε ηλεκτρονικούς συντονισμούς οι οποίοι συσχετίζονται ως ένα βαθμό με τα μόρια.

2. 4 Φαινόμενα διασποράς στις οπτικές ίνες

2. 4. 1 Εισαγωγή

Το φαινόμενο της διασποράς προκαλεί παραμορφώσεις στο ψηφιακό και τον αναλογικό τρόπο μετάδοσης κατά μήκος μιας οπτικής ίνας. Από το μηχανισμό της διασποράς προκαλείται διεύρυνση των παλμών του μεταδιδόμενου φωτός κατά τη διάρκεια της μετάδοσής τους σε όλο το μήκος του καναλιού της οπτικής ίνας.



Εικόνα 6. Το φαινόμενο της διασποράς

2. 4. 2 Διασπορά στον τρόπο μετάδοσης

Η διασπορά στον τρόπο μετάδοσης είναι ένα φαινόμενο το οποίο εμφανίζεται μόνο στις πολύτροπες οπτικές ίνες και οφείλεται στη μετάδοση του οπτικού σήματος εντός της ίνας με παραπάνω από έναν τρόπους. Πιο συγκεκριμένα, δημιουργείται διάσπαση του οπτικού σήματος κατά τη διάδοσή του στο εσωτερικό της οπτικής ίνας σε ακτίνες φωτός οι οποίες διαχέονται έχοντας πορεία τεθλασμένων γραμμών. Επομένως, κάθε διαδρομή των ακτινών έχει διαφορετική ταχύτητα σε σχέση με τις άλλες. Έτσι, ανάλογα με το μέγεθος του πυρήνα της οπτικής ίνας, η διασπορά που αφορά τον τρόπο μετάδοσης αυξάνεται σύμφωνα με τον αριθμό των εκάστοτε τρόπων μετάδοσης που υποστηρίζονται κάθε φορά από τον κυματοδηγό [10].

2. 4. 3 Διασπορά του υλικού

Η διασπορά του υλικού ή αλλιώς χρωματική διασπορά δύναται να εμφανιστεί και στις δύο κατηγορίες οπτικών ινών πολύτροπες και μονότροπες. Ο σημαντικότερος λόγος για τον οποίο εμφανίζεται η χρωματική διασπορά συνδέεται με το γεγονός ότι ο συντελεστής διάθλασης του πυρήνα της οπτικής ίνας εξαρτάται άμεσα από το μήκος κύματος της οδηγούμενης ακτίνας φωτός. Πιο συγκεκριμένα, όταν το οπτικό σήμα που ξεκινάει να μεταδίδεται από τον πομπό περιέχει περισσότερα από ένα μήκη κύματος τότε το κάθε μήκος κύματος παρουσιάζει διαφορετικό συντελεστή διάθλασης. Αυτό έχει ως αποτέλεσμα το αντίστοιχο μέρος του σήματος που μεταφέρεται να έχει διαφορετική ταχύτητα κίνησης προκαλώντας διασπορά οπτικού σήματος στο δέκτη. Υπάρχει περίπτωση το οπτικό σήμα να έχει συντεθεί από διαφορετικά μήκη κύματος καθώς δεν υπάρχει ιδανική πηγή φωτός όπου να συγκεντρώνεται η ισχύς του εκπεμπόμενου φωτός μόνο σε ένα μήκος κύματος [10].

2. 4. 4 Διασπορά κυματοδήγησης


Το φαινόμενο της διασποράς κυματοδήγησης προκαλείται από τη διαφορετική ταχύτητα μετάδοσης της ομάδας με το μήκος κύματος μεταξύ του πυρήνα και του μανδύα της οπτικής ίνας εξαιτίας της διαφοράς που παρουσιάζουν στο συντελεστή διάθλασης. Η εμφάνιση του φαινομένου απαντάται κυρίως στις μονότροπες οπτικές ίνες όπου ένα μεγάλο ποσοστό κυματοδηγούμενης ενέργειας οπτικού σήματος διέρχεται από τον μανδύα. Όσο αναφορά τις πολύτροπες οπτικές ίνες η διασπορά του κυματοδηγού θεωρείται σχεδόν αμελητέα σε σχέση με εκείνη του υλικού εξαιτίας της πλειονότητας των τρόπων μετάδοσης μακριά από την αποκοπή (cutoff).

2. 4. 5 Διασπορά πόλωσης -τρόπου μετάδοσης

Το φαινόμενο της διασποράς πόλωσης-τρόπου μετάδοσης(Polarized Mode Dispersion) σχετίζεται με τη διπλοθλαστικότητα της οπτικής ίνας. Οι μικρές αποκλίσεις από την άψογη κυλινδρική συμμετρία μπορεί να οδηγήσουν σε διπλοθλαστικότητα εξαιτίας της διαφοράς στον δείκτη του τρόπου μετάδοσης, ο οποίος σχετίζεται με τις ορθογώνια πολωμένες συνιστώσες του κύριου τρόπου μετάδοσης της οπτικής ίνας [11]. Στην περίπτωση που ο παλμός εισόδου διεγείρει και τις δύο συνιστώσες πόλωσης επέρχεται διεύρυνσή του στην έξοδο εξαιτίας του διασκορπισμού των δύο συνιστωσών κατά μήκος της οπτικής ίνας. Αυτό συμβαίνει λόγω της διαφορετικής ταχύτητας ομάδας που διαθέτει η καθεμία.

Ο υπολογισμός της PMD με τη βοήθεια μόνο μιας εξίσωσης είναι αρκετά δύσκολος για τις συνηθισμένες οπτικές ίνες των σημερινών συστημάτων επικοινωνίας. Ο λόγος που συμβαίνει αυτό είναι η ύπαρξη μιας τυχαίας ζεύξης μεταξύ των δύο τρόπων μετάδοσης οι οποίοι επάγονται λόγω των τυχαίων διαταραχών της διπλοθλαστικότητας που υπάρχει κατά μήκος της οπτικής ίνας. Έτσι, η PMD μπορεί να αποτελέσει περιοριστικό παράγοντα για τα συστήματα

τηλεπικοινωνιών οπτικών ινών, τα οποία έχουν σχεδιαστεί να λειτουργούν σε μεγάλες αποστάσεις στο μήκος της μηδενικής διασποράς.



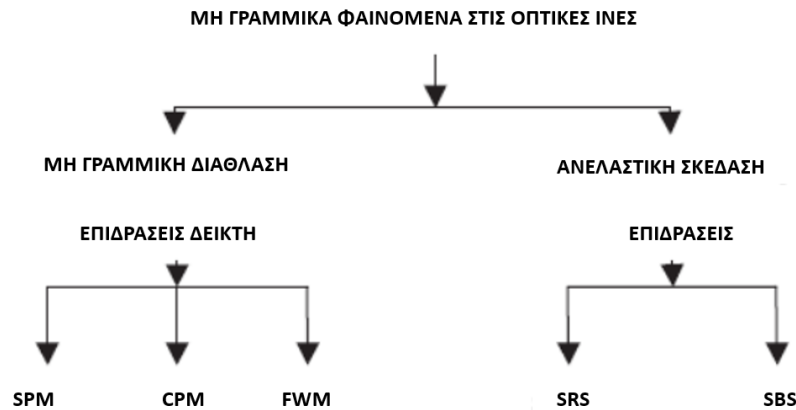
Εικόνα 7. Το φαινόμενο της διασποράς πόλωσης-τρόπου μετάδοσης PMD

2.5 Μη γραμμικά φαινόμενα

Τα μη γραμμικά φαινόμενα μπορούν να διαδραματίσουν σπουδαίο ρόλο στην αναβάθμιση της επίδοσης των οπτικών ινών με τη δημιουργία νέων λειτουργιών αλλά ταυτοχρόνως μπορούν να προκαλέσουν καταστρεπτικές καταστάσεις επηρεάζοντας σε μεγάλο βαθμό τα οπτικά συστήματα. Υπάρχουν δύο λόγοι εμφάνισης των μη γραμμικών φαινομένων στις οπτικές ίνες, ο ένας είναι η εξάρτηση της έντασης από το δείκτη διάθλασης του μέσου και ο άλλος είναι εξαιτίας φαινομένων ανελαστικής σκέδασης [12].

Με τους όρους γραμμικά και μη γραμμικά αποτυπώνονται φαινόμενα τα οποία εξαρτώνται ή μη από την ισχύ. Η εξάρτηση της ισχύος από το δείκτη διάθλασης είναι γνωστή και ως φαινόμενο Kerr. Αναλόγως του τύπου του σήματος εισόδου η μη γραμμικότητα Kerr εκδηλώνεται σε τρία διαφορετικά φαινόμενα την αυτό-διαμόρφωση φάσης (Self-phase modulation SPM), τη διασταυρούμενη διαμόρφωση φάσης (Cross-phase modulation CPM) και τη μείξη τεσσάρων κυμάτων (four wave mixing FWM) [13]. Στην περίπτωση όπου έχουμε υψηλά επίπεδα ισχύος τα φαινόμενα ανελαστικής σκέδασης είναι ικανά να δημιουργήσουν νέα φαινόμενα

όπως το Stimulated-Brillouin-Scattering (SBS) και το Stimulated-Raman -Scattering (SRS).



Εικόνα 8. Είδη μη γραμμικών φαινομένων στις οπτικές ίνες

Εξαιρώντας τη SPM και τη CPM, τα υπόλοιπα μη γραμμικά φαινόμενα παρέχουν κέρδος σε κάποια κανάλια επικοινωνίας περιορίζοντας την ισχύ σε κάποια άλλα. Η SPM και η CPM έχουν αντίκτυπο μόνο στη φάση των σημάτων προκαλώντας διεύρυνση του φάσματος που έχει ως συνέπεια αυξημένη διασπορά. Όσο αναφορά έντονα ηλεκτρομαγνητικά πεδία, κάθε διηλεκτρικό μέσο που βρίσκεται σε αυτά μπορεί να συμπεριφέρεται ως μη γραμμικό μέσο. Η συγκεκριμένη μη γραμμικότητα προέρχεται από τη μη αρμονική κίνηση των δέσμιων ηλεκτρονίων κάτω από την επίδραση του εφαρμοζόμενου πεδίου.

2. 5. 1 Αντιμετώπιση μη γραμμικών φαινομένων

Τα μη γραμμικά φαινόμενα μπορούν να προκαλέσουν αίσθηση ακόμα και για χαμηλές τιμές οπτικής ισχύος, λόγω της μικρής ενεργού περιοχής και της χαμηλής εξασθένισης που παρουσιάζουν. Είναι γενικά αποδεκτό ότι όσο πιο μεγάλη είναι η

διατομή του πυρήνα της οπτικής ίνας τόσο πιο μικρή θα είναι η χωρική πυκνότητα ισχύος με αποτέλεσμα να είναι λιγότερο επιβλαβής η επίδραση των μη γραμμικοτήτων. Βασισμένοι στην παραπάνω λογική οι ερευνητές πρότειναν την ίνα τύπου LEAF (Large Effective Area Fiber) η οποία παρουσιάζει μεγαλύτερη ενεργό διατομή πυρήνα με σκοπό την ελαχιστοποίηση της επίδρασης των μη γραμμικοτήτων κατά τη διάρκεια της μετάδοσης πολλών χρωματικών καναλιών [14][15]. Ανεξαρτήτως της σχεδίασης τύπου LEAF υπάρχουν και άλλοι τρόποι αποφυγής των μη γραμμικών φαινομένων οι οποίοι εξαρτώνται κάθε φορά από τη φύση των φαινομένων.

Στην περίπτωση WDM (Wavelength Division Multiplexing) μετάδοσης σε SMF (Single Mode optical Fiber), η επίδραση του FWM (Four-Wave Mixing)[63] αν και μικρή δεν μπορεί να αποφευχθεί παρά μόνο εφαρμόζοντας πολυπλεξία πόλωσης ή εφαρμογή διαμόρφωσης φάσης ή συχνότητας. [64] Στην περίπτωση μετάδοσης σε DSF (Dispersion-shifted fiber) όπου το FWM έχει μεγαλύτερη ισχύ, η λύση είναι η εφαρμογή άνισων αποστάσεων συχνότητας μεταξύ των WDM καναλιών [65]. Η ύπαρξη κατωφλίου Stimulated Brillouin Scattering (SBS) μπορεί να προσεγγίσει υψηλές τιμές επιτρέποντας με αυτόν τον τρόπο τη διάδοση ισχυρότερων κυμάτων στην περίπτωση που εφαρμοστεί μια διαμόρφωση χαμηλής συχνότητας στο ρεύμα του laser εκπομπής ή μια διαμόρφωση φάσης. Το φαινόμενο SBS είναι στην ουσία η μεταφορά ενέργειας από τα μικρότερα προς τα μεγαλύτερα μήκη κύματος κανάλια [66] και αντιμετωπίζεται σε συνδυασμό με την αντιμετώπιση της μη επίπεδης απόκρισης των Erbium-Doped Fiber Amplifiers (EFDA) κατά μήκος της ζεύξης με εξίσωση ισχύος των διαφόρων καναλιών WDM μετάδοσης [67].

ΚΕΦΑΛΑΙΟ 3^ο – ΣΥΣΤΗΜΑΤΑ ΜΕΤΑΔΟΣΗΣ

3.1 Συστήματα μικρών ή μεσαίων αποστάσεων (< 80 km)

Τα τελευταία χρόνια, οι οπτικές συνδέσεις μικρών αποστάσεων έχουν προσελκύσει το ενδιαφέρον όλο και περισσότερων ερευνητών καθώς και επιχειρήσεων με αποτέλεσμα να αποτελούν βασικό τμήμα της αγοράς λόγω της ταχείας ανάπτυξης εφαρμογών σε κέντρα δεδομένων και λόγω της ραγδαίας ανάπτυξης υπηρεσιών που βασίζονται στο cloud. Ο κυριότερος παράγοντας που οδήγησε στην ανάπτυξη οπτικών συστημάτων μικρών αποστάσεων είναι η διαμόρφωση πλάτους παλμών τεσσάρων επιπέδων (PAM4), η οποία είναι μια πολλά υποσχόμενη μορφή διαμόρφωσης που παρέχει τόσο υψηλό ρυθμό μετάδοσης δεδομένων όσο και σχετικά χαμηλό κόστος για οπτικές συνδέσεις μικρής απόστασης. Παρόλαυτα, ο άμεσος ανιχνευτής (direct detector) και τα χαμηλού κόστους εξαρτήματα προκαλούν τεράστιες προκλήσεις, οι οποίες δεν μπορούν να προβλεφθούν στη σύμφωνη μετάδοση (coherent transmission).

Για την αντιστάθμιση και την αντιμετώπιση των απωλειών καθώς και για την πραγματική κάλυψη των απαιτήσεων ρυθμού δεδομένων με όσο το δυνατόν οικονομικά αποδοτικότερο τρόπο, έχουν προταθεί και διερευνηθεί διάφορες τεχνολογίες επεξεργασίας ψηφιακού σήματος (DSP) για οπτικές ζεύξεις PAM4 μικρών αποστάσεων [68].

Τα φαινόμενα χαμηλοπερατού φιλτραρίσματος που προκαλούνται από το περιορισμένο εύρος ζώνης του πομπού και του δέκτη μπορεί να προκαλέσουν σοβαρές παρεμβολές μεταξύ των συμβόλων (ISI). Οι συσκευές χαμηλού κόστους όπως τα λείζερ, οι διαμορφωτές, οι φωτοδίοδοι (PD) και οι ενισχυτές trans-σύνθετης αντίστασης (TIA) παράγουν επίσης μη γραμμικές παραμορφώσεις, όπως η κλίση που εξαρτάται από το επίπεδο και ο θόρυβος που εξαρτάται από τη στάθμη. Επιπλέον, η αλληλεπίδραση μεταξύ χρωματικής διασποράς (CD) και άμεσης ανίχνευσης θα οδηγήσει σε ένα φαινόμενο εξασθένησης ισχύος, όπου το σήμα που ανιχνεύεται μπορεί να περιέχει εγκοπές συχνότητας μετά από μετάδοση πολλών χιλιομέτρων με υψηλό ρυθμό συμβόλων. Έτσι, οδηγούμαστε στη διερεύνηση διαφόρων τεχνολογιών

εξισορρόπησης που βασίζονται στην επεξεργασία ψηφιακού σήματος (DSP) και αφορούν συνδέσεις μικρής απόστασης. Συμβατικοί ισοσταθμιστές, όπως ο ισοσταθμιστής ανάδρασης (FFE) ή ο εξισωτής ανάδρασης απόφασης (DFE), χρησιμοποιούνται για να αντισταθμίσουν τις γραμμικές βλάβες που προκαλούνται από το περιορισμένο εύρος ζώνης και τη χρωματική διασπορά (CD), ενώ ο ισοσταθμιστής που βασίζεται στη σειρά Volterra χρησιμοποιείται για να μετριάσει τη μη γραμμική παραμόρφωση. Μερικές νέες τεχνικές εξισορρόπησης, όπως για παράδειγμα ο αλγόριθμος άμεσης ανίχνευσης ο οποίος είναι γρηγορότερος από τον Nyquist (DD-FTN), ο αλγόριθμος κατευθυνόμενης έντασης FFE/DFE (ID-FFE/ID-DFE) και ανάκτησης κοινού ρολογιού και αλγόριθμος FFE (CR-FFE), έχουν πρόσφατα προταθεί για την επίλυση διαφορετικών προβλημάτων στην πρακτική εφαρμογή [69]. Επιπλέον, μέθοδοι μηχανικής μάθησης όπως η μηχανή διανυσμάτων υποστήριξης (SVM) και νευρωνικό δίκτυο (NN) έχουν διερευνηθεί για την περαιτέρω εξάλειψη των απωλειών του συστήματος για τη διαμόρφωση PAM4 [70].

3. 2 Συστήματα μεγάλων αποστάσεων (> 80 km)

Τα τελευταία πέντε χρόνια, οι συνεκτικές τεχνολογίες μετάδοσης έχουν βελτιωθεί ραγδαία όσο αναφορά τα συστήματα μετάδοσης DWDM μεγάλων αποστάσεων. Η εξέλιξη αυτή έχει οδηγήσει στην ανάπτυξη τεχνολογιών που μπορούν να προσφέρουν μετάδοση πέραν των 100 G.

Η σταδιακή εξέλιξη των τεχνολογιών των πομπών συμπεριλαμβανομένης της διαμόρφωσης παλμών Nyquist και της μη γραμμικής αντιστάθμισης των συσκευών των πομπών αποτελεί σημαντικό παράγοντα για τη δημιουργία λειτουργικών μοντέλων σύμφωνης μετάδοσης πέρα των 100 G. Επιπλέον, η ανάπτυξη τεχνολογιών για τη μη γραμμική αντιστάθμιση των φαινομένων διάδοσης καθώς και οι περαιτέρω πρόοδοι στην τεχνολογία FEC σε συνδυασμό με την ανάπτυξη ενός ευέλικτου πλέγματος DWDM και συνεκτικών υπερ-καναλιών προσφέρουν μετάδοση πέραν των 100 G.

Στα σημερινά δεδομένα, η απόδοση του Rx ADC περιορίζει τους ρυθμούς μετάδοσης ανά μήκος κύματος σε περίπου 35 GBaud, με τη συγκεκριμένη απόδοση να μην αναμένεται να κλιμακωθεί γραμμικά στο εγγύς μέλλον. Αναμένεται ότι το σημείο συμφόρησης απόδοσης για το ρυθμό συμβόλων μετάδοσης θα μετατοπιστεί στις αναδυόμενες τεχνολογίες πομπών που θα εισαχθούν για να διευκολύνουν τη διαμόρφωση υψηλότερης τάξης (δηλαδή, μεταφορά περισσότερων bit σε κάθε σύμβολο διαμόρφωσης). Αυτό το σημείο συμφόρησης θα είναι πιθανότατα στον ψηφιακό-αναλογικό μετατροπέα (DAC) και στο μη γραμμικό DSP αντιστάθμισης στην επόμενη γενιά συνεκτικών πομπών διαμόρφωσης υψηλότερης τάξης. Έτσι, σε συνδυασμό με τη διαμόρφωση υψηλότερης τάξης [77], είναι απαραίτητο να αναπτυχθούν τεχνικές διαμόρφωσης παλμού που βελτιστοποιούν τη φασματική απόδοση και τεχνικές μη γραμμικής αντιστάθμισης για τον μετριασμό των επιπτώσεων από τη μη γραμμικότητα της συσκευής και της διάδοσης μέσω οπτικών ινών. Οι παραπάνω τεχνικές απαιτούν οπτικό ηλεκτρονικά εξαρτήματα αιχμής για μια επιτυχημένη εφαρμογή.

Η μη γραμμικότητα ινών μπορεί να ταξινομηθεί σε εφέ μονού καναλιού (single channel effects) όπως SPM (Self-phase modulation) και σε εφέ WDM όπως XPM (Cross-phase modulation) και μίξη τεσσάρων κυμάτων (FWM). Οι τεχνικές που είναι αποτελεσματικές για την αντιστάθμιση του SPM μπορεί να μην είναι το ίδιο αποτελεσματικές για το XPM και αντίστροφα. Έτσι, σχεδόν σε όλες τις εφαρμογές επικρατούν τα εφέ WDM (ιδιαίτερα τα XPM). Έχουν αναπτυχθεί και διερευνηθεί εκτενώς αλγόριθμοι NLC (nonlinearity compensation) οι οποίοι βασίζονται σε τεχνικές όπως η ψηφιακή αντίστροφη διάδοση (DBP: digital backward propagation), η μη γραμμική ακύρωση συνομιλίας πόλωσης (NPCC: nonlinear polarization crosstalk cancellation) και ISI (Intersymbol interference) μεταβαλλόμενου χρόνου.

Όσο αναφορά το FEC, προστίθενται πρόσθετα bit στα δεδομένα που θα επιτρέψουν στους επεξεργαστές του δέκτη να αναγνωρίσουν και, το πιο σημαντικό, να ανακτήσουν σφάλματα που προέκυψαν κατά τη μετάδοση. Η εξέλιξη του FEC είναι άμεση συνέπεια της αυξανόμενης διαθεσιμότητας ψηφιακής επεξεργαστικής ισχύος. Η εξέλιξη της FEC θεωρείται γενικά ότι έχει τρεις διαφορετικές γενιές. Στους αλγόριθμους HD-FEC (Hard Decision) πρώτης και δεύτερης γενιάς, ο

αποκωδικοποιητής FEC θα ανίχνευε σφάλματα bit χρησιμοποιώντας μια δυαδική απόφαση όπου οτιδήποτε πάνω από το αυστηρό όριο απόφασης ερμηνεύεται ως 1 και οτιδήποτε παρακάτω ερμηνεύεται ως 0.

Όσο αναφορά το ευέλικτο πλέγμα DWDM και πιο συγκεκριμένα το Nyquist DWDM και τα υπερ-κανάλια ασκείται πίεση στο υπάρχον μοντέλο DWDM σταθερού δικτύου το οποίο περιγράφεται στο ITU-T G. 694. 1. Έχει αναγνωριστεί μια πιο ευέλικτη προσέγγιση για την κατανομή του φάσματος και η ITU-T έχει ορίσει ένα ευέλικτο πλέγμα στην τελευταία έκδοση αυτού του προτύπου [78]. Το ευέλικτο πλέγμα ορίζει ευέλικτες υποδοχές συχνότητας με φασματικό πλάτος $M \times 12,5$ GHz, για να φιλοξενήσει οποιονδήποτε συνδυασμό οπτικών φορέων, διαμορφώσεων και ρυθμού δεδομένων. Επιπλέον, το $M \times 12,5$ GHz φασματικό πλάτος ενός υπερ-καναλιού flex-grid μπορεί να ρυθμιστεί, επιτρέποντας γρήγορες αλλαγές όταν οι προδιαγραφές λειτουργίας του υπερ-καναλιού ποικίλλουν. Αν και δεν σχετίζεται άμεσα με την απόδοση ηλεκτρονικών ή οπτικών εξαρτημάτων, η ευελιξία επιτρέπει στους σχεδιαστές δικτύων DWDM να επωφεληθούν πλήρως από τη φασματική απόδοση των υπερκαναλιών DWDM μεταβλητού πλάτους που ενεργοποιούνται χρησιμοποιώντας προηγμένη οπτικοηλεκτρονική επεξεργασία.

Ο όρος υπερ-κανάλια αναφέρεται σε μια εξέλιξη στη μετάδοση DWDM στην οποία πολλαπλοί συνεκτικοί οπτικοί φορείς υλοποιούνται σε μια κάρτα ενιαίας γραμμής, τίθενται σε λειτουργία σε έναν μόνο λειτουργικό κύκλο και θεωρούνται ως μια ενιαία μονάδα ψηφιακής χωρητικότητας από τις υπηρεσίες που τη χρησιμοποιούν [79]. Χάρη στις προόδους της τεχνολογίας διαμόρφωσης παλμών, υπάρχει μικρή ή καθόλου ποινή φασματικής απόδοσης στη χρήση μιας προσέγγισης υπερ-καναλιού σε σύγκριση με έναν μόνο φορέα υψηλής ταχύτητας δεδομένων. Για παράδειγμα, μια λύση ενός φορέα 1,2 Tb/s που χρησιμοποιεί διαμόρφωση PM-QPSK θα καταλάμβανε περίπου 460 GHz φάσματος και θα χρειαζόταν να μεταδίδει σύμβολα στα 384 GBaud. Όπως αναφέρθηκε παραπάνω, τα περιοριστικά στοιχεία θα περιλαμβάνουν την απόδοση DAC στον πομπό διαμόρφωσης παλμών, την απόδοση Rx ADC και το εύρος ζώνης στοιχείων Tx και Rx. Αντίθετα, μια κάρτα γραμμής υπερ-καναλιού 12 φορέων 1,2 Tb/s θα απαιτούσε μόνο ρυθμούς συμβόλων 32 GBaud και τα σχετικά ηλεκτρονικά. Αξίζει να σημειωθεί ότι για την ίδια τιμή

γραμμής, η χρήση πολλαπλών υποφορέων με χαμηλότερο ρυθμό baud έχει επίσης ελαφρώς μεγαλύτερη ανοχή στη μη γραμμική διάδοση σε σύγκριση με την προσέγγιση ενός φορέα [80]. Δεδομένου ότι η εφαρμογή υπερκαναλιών με μεγάλο αριθμό υποφορέων χρησιμοποιώντας διακριτά οπτικά εξαρτήματα δεν είναι πρακτική, τα μεγάλης κλίμακας φωτονικά ολοκληρωμένα κυκλώματα (PIC) αποτέλεσαν τη βάση των πρώτων εμπορικών εφαρμογών υπερ-καναλιών. Αυτά είναι υπερ-κανάλια 500 Gb/s και ένα βασικό ερώτημα που προσπαθούν να επιλύσουν οι ερευνητές είναι εάν η τεχνολογία PIC μπορεί να κλιμακωθεί σε υψηλότερους συνολικούς ρυθμούς στο μέλλον.

3.3 400 Gb Ethernet

3.3.1 Εισαγωγή

Η συνεχώς αυξανόμενη ανάπτυξη εφαρμογών που βρίσκονται στο cloud καθώς και η ακόρεστη όρεξη των καταναλωτών για περιεχόμενο κατ' απαίτηση (on demand content) έχουν οδηγήσει στην ανάπτυξη και μετάβαση σε έναν νέο κύκλο επενδύσεων δικτύου.

Πολλαπλές γενιές Ethernet αναπτύχθηκαν ανά τα χρόνια, συνοδευόμενες από αντίστοιχους ρυθμούς οπτικού μήκους κύματος, χωρίς σημαντική στροφή προς τις ενσωματωμένες αρχιτεκτονικές οπτικών δικτύων IP. Ένα σημαντικό εμπόδιο σε μια τέτοια ολοκλήρωση ήταν ο αυξημένος χώρος και το αποτύπωμα ισχύος που απαιτούνται για την εφαρμογή πολυπλεξίας διαίρεσης μήκους κύματος υψηλής ταχύτητας (WDM) σε ηλεκτρο-οπτικά δίκτυα. Αυτό εμπόδισε τους χειριστές να χρησιμοποιούν οπτικούς πομποδέκτες WDM με δυνατότητα σύνδεσης που βασίζονται σε δρομολογητές, καθώς χρησιμοποιούσαν συσκευές μεταγωγής πακέτων για τη μετάβαση σε νέους, ταχύτερους ρυθμούς Ethernet. Ως αποτέλεσμα, οι χειριστές συνέχισαν να χρησιμοποιούν διακριτούς και αποκλειστικούς οπτικούς αναμεταδότες για τη WDM μεταφορά συνδέσεων IP [71].

Ωστόσο, οι πρόσφατες εξελίξεις στην ηλεκτρο-οπτική, ιδιαίτερα στη φωτονική του πυριτίου, έχουν γεφυρώσει αυτό το χάσμα επιτρέποντας σε συνεκτικά οπτικά WDM 400G να αναπτυχθούν περαιτέρω. Είναι η πρώτη φορά, όπου υπάρχει πρόοδος η οποία να συμπίπτει με την επέκταση της υιοθέτησης του νέου ρυθμού 400GE και να επιτρέπει την ενοποίηση των δύο κόσμων, που εφαρμόζεται απευθείας από μια θύρα δρομολογητή σε ένα οπτικό μήκος κύματος μέσω ενός συνδεδεμένου ψηφιακού συνεκτικού οπτικού συστήματος ή ενός DCO πομποδέκτη (Digital Optics Transceiver).

Το πιο σημαντικό χαρακτηριστικό ενός συνδεδεμένου DCO είναι ότι μπορεί να φιλοξενηθεί απευθείας στο δρομολογητή, γεγονός που αφαιρεί τις απαιτήσεις χώρου, την κατανάλωση ενέργειας και τα έξοδα ενός ξεχωριστού οπτικού αναμεταδότη. Τοποθετώντας τους κυρίαρχους συντελεστές μορφής 400GE με δυνατότητα σύνδεσης, τα 400G WDM DCO επιτρέπουν στους δρομολογητές να απολαμβάνουν την ίδια πυκνότητα θύρας όταν χρησιμοποιούνται για μετάδοση WDM σε μεγάλες αποστάσεις όπως και για συνδεσιμότητα μικρής απόστασης. Ταιριάζει τέλεια για την αναπτυσσόμενη εφαρμογή της διασύνδεσης των κέντρων δεδομένων και επιτρέπει την απαραίτητη κλιμάκωση των δικτύων των metro networks [72].

3.3.2 Οι οικονομικοί περιορισμοί Shannon

Οι πολλαπλές παραλλαγές της τελευταίας γενιάς συνεκτικών οπτικών αλληλοσυμπληρώνονται και βελτιστοποιούνται γύρω από τους οικονομικούς περιορισμούς που κυριαρχούν στις εφαρμογές δικτύου-στόχων τους. Οι αντισταθμίσεις σχεδιασμού που πραγματοποιούνται από τους DCO αντικατοπτρίζουν τις μικρές αποστάσεις, τον περιορισμένο χώρο και την ισχύ και τις άφθονες ίνες που διατίθενται σε περιοχές του μετρώ. Τα συνεκτικά οπτικά υψηλής απόδοσης μεγιστοποιούν την εμβέλεια και τη φασματική απόδοση όπου οι ίνες είναι σπάνιες και οι λειτουργίες δαπανηρές. Καθώς κατασκευάζονται δίκτυα που βασίζονται σε 400GE τα επόμενα χρόνια, οι φορείς εκμετάλλευσης δικτύων θα επιτύχουν τόσο το χαμηλότερο κόστος όσο και την υψηλότερη απόδοση.

Η εποχή του 400G ανατέλλει με την ευθυγράμμιση αυτών των πολλαπλών καινοτομιών και τεχνολογιών. Το 400 GE θα ενεργοποιήσει έναν κύκλο επενδύσεων και θα τονώσει τη ζήτηση για μήκη κύματος 400 G. Οι συνεκτικοί πομποδέκτες 400G με σύνδεση κόστους και χώρου θα επιτρέψουν τελικά τη φυσική ενοποίηση του IP και του οπτικού κόσμου, ενώ η τελευταία γενιά σύμφωνης τεχνολογίας υψηλής απόδοσης εξουσιοδοτεί τη μετάδοση 400G σε οποιαδήποτε απόσταση [73].

Οι συνεχείς καινοτομίες στη σύμφωνη τεχνολογία αύξησαν σταθερά τη χωρητικότητα των συστημάτων οπτικών μεταφορών, ενώ παράλληλα μειώνουν το κόστος ανά bit μεταφοράς. Το αποτέλεσμα είναι ότι οι φορείς εκμετάλλευσης δικτύων μπόρεσαν να αντιμετωπίσουν τον κατακλυσμό της κυκλοφορίας διατηρώντας παράλληλα ένα ουσιαστικά σταθερό επίπεδο κεφαλαιακής δαπάνης. Αυτή η αργή ανάπτυξη του CAPEX είναι κρίσιμη για την ικανότητά τους να παραμείνουν κερδοφόροι ενόψει των στάσιμων εσόδων των συνδρομητών. Καθώς εισερχόμαστε στην εποχή των 400G, οι προκλήσεις για τους φορείς εκμετάλλευσης δικτύων είναι να συνεχίσουν να κλιμακώνουν τα δίκτυά τους, να μειώνουν το κόστος και να βελτιστοποιούν τη μεταφορά γύρω στα 400 GE. Τα γρήγορα κέρδη σε χωρητικότητα και μείωση κόστους που επιτρέπονται από διαδοχικές γενιές συνεκτικών οπτικών ανήκουν σε μεγάλο βαθμό στο παρελθόν. Η μείωση του κόστους ανά bit οφείλεται σε μεγάλο βαθμό στις βελτιώσεις στη φασματική απόδοση των συνεκτικών μηκών κύματος. Η μεταφορά περισσότερων bit σε λιγότερες διεπαφές και λιγότερες ίνες μειώνει το κόστος.

Ωστόσο, η φασματική απόδοση περιορίζεται περίφημα από το Όριο Shannon. Το Οικονομικό όριο Shannon ουσιαστικά σημαίνει ότι οι περαιτέρω προσπάθειες για τη μεγιστοποίηση της φασματικής απόδοσης είναι απίθανο να δημιουργήσουν καλύτερη απόδοση της επένδυσης (χαμηλότερο κόστος για τους φορείς εκμετάλλευσης) από την εξερεύνηση εναλλακτικών τεχνολογικών οδών που μειώνουν το κόστος με άλλες μετρήσεις. Ουσιαστικά το επίκεντρο της επένδυσης και της καινοτομίας θα μετατοπιστεί από τη συμπίεση μεγαλύτερης φασματικής απόδοσης από μια ίνα ή τη σχετική μέτρηση της επίτευξης υψηλότερων ρυθμών μήκους κύματος σε τεχνολογίες που βελτιστοποιούν την ισχύ και τον χώρο για να ταιριάζουν καλύτερα συνεκτικές διεπαφές με συγκεκριμένες εφαρμογές, όπως

καθώς και μεγιστοποίηση της εμβέλειας της διεπαφής για ταχύτητες εργασίας όπως τα 400G.

Κάθε νέα γενιά σύμφωνης τεχνολογίας αύξησε τους ρυθμούς baud και μείωσε την ισχύ ανά bit. Η λειτουργία σε υψηλότερους ρυθμούς baud αυξάνει την εμβέλεια ενός δεδομένου ρυθμού μήκους κύματος. Με την ισοπέδωση της φασματικής απόδοσης, αυτό έχει γίνει το κύριο πλεονέκτημα των νέων γενεών επεξεργαστών ψηφιακού σήματος (DSP). Χαμηλότερη ισχύς ανά bit ενεργοποιείται από κάθε νέα γενιά πυριτίου, η οποία επιτρέπει στους μηχανικούς DSP να αναπτύξουν μια πιο εξελιγμένη διαδικασία επεξεργασίας σήματος και υψηλότερους ρυθμούς τοποθετώντας τους στον ίδιο φάκελο ισχύος.

3. 3. 3 Προκλήσεις μετάβασης στα 400 GbE σε φυσικό επίπεδο

Δεδομένης της ταχείας ανάπτυξης των δικτύων, των κέντρων δεδομένων και της υψηλής ζήτησης για το μεγαλύτερο δυνατό εύρος ζώνης και πυκνότητας θυρών, ασκείται μεγάλη πίεση στη βιομηχανία ώστε να αντιμετωπίσει γρήγορα αυτά τα ερωτήματα. Από φυσική πλευρά, ο κλάδος αντιμετωπίζει τις ακόλουθες προκλήσεις [74].

Μία πρόκληση είναι η διαλειτουργικότητα. Ενώ το πρότυπο IEEE έχει εγκριθεί, η εμπειρία δείχνει ότι η διαλειτουργικότητα πολλών προμηθευτών στον πραγματικό κόσμο απαιτεί την αντιμετώπιση πολλών λεπτομερειών στις προδιαγραφές του προϊόντος, το σχεδιασμό και την κατασκευή. Αυτό θα απαιτήσει όχι μόνο προσοχή στη λεπτομέρεια, αλλά πραγματικές δοκιμές σε plugfests (όπως αυτές στο Πανεπιστήμιο του New Hampshire) και σε εργαστήρια δοκιμών υπερκλίμακας τα οποία περιέχουν πρωτότυπα δίκτυα.

Η αξιοπιστία του πομποδέκτη είναι επίσης μία σημαντική πρόκληση. Υπάρχουν ζητήματα όπου οι κατασκευαστές οπτικών πομποδεκτών δυσκολεύονται να παραμείνουν εντός του προϋπολογισμού ισχύος της συσκευής, με αποτέλεσμα ζητήματα θερμότητας, τα οποία προκαλούν προβλήματα με την ευθυγράμμιση των ινών, οπτικές παραμορφώσεις και απώλεια πακέτων. Αυτό το ζήτημα αξιοπιστίας

πηγάξει, εν μέρει, από την παλιά σχεδίαση του Quad Small Form-factor Pluggable (QSFP) πομποδέκτη με χρήση παράγοντα μορφής στα 400 GbE που σχεδιάστηκε για 40 GbE. Αυτή είναι μια πραγματική πρόκληση στο φυσικό επίπεδο. Υπάρχουν παρόμοιες προκλήσεις για τις νεότερες μονάδες που χρησιμοποιούνται σε συστήματα 400 GbE, όπως οι παράγοντες μορφής CFP8 και QSFP-DD.

Ο τομέας της οπτικής κωδικοποίησης είναι μία από τις προκλήσεις που αξίζει να ερευνηθεί περαιτέρω. Η προδιαγραφή IEEE μετακινήθηκε από έναν γνωστό τύπο κωδικοποίησης που χρησιμοποιείται για 100 GbE και κάτω, ο οποίος ονομάζεται NRZ (δυναμική μη επιστροφή στο μηδέν) και χρησιμοποιούσε δύο επίπεδα οπτικής σηματοδότησης, στο PAM-4 (διαμόρφωση πλάτους παλμού), το οποίο περιέχει τέσσερα επίπεδα σηματοδότησης. Η κωδικοποίηση και η αποκωδικοποίηση τεσσάρων επιπέδων απαιτεί σημαντικά μεγαλύτερη πολυπλοκότητα, καθώς και πιο ακριβό υλικό. Το PAM-4 είναι επίσης πιο ευαίσθητο στο θόρυβο στην οπτική γραμμή. Το PAM-4 είναι ένα μεγάλο ζήτημα ακόμη και ένα μόνο μεγάλο κατασκευαστή, γεγονός που καθιστά τη διαλειτουργικότητα πολλών προμηθευτών ακόμη πιο δύσκολη.

Τέλος, τα υπερβολικά πτερύγια σύνδεσης(link flaps). Κάθε φορά που υπάρχει μια σειρά σφαλμάτων ή άλλων αστοχιών σε μια οπτική σύνδεση, και οι δύο πομποδέκτες πρέπει να εκτελούν αυτόματη διαπραγμάτευση AN/LT και εκπαίδευση σύνδεσης προτού τα δεδομένα αρχίσουν να ρέουν ξανά. Όταν τέτοια σφάλματα συμβαίνουν συχνά πολλές φορές το λεπτό λειτουργούν ως πτερύγιο σύνδεσης και μπορούν να επηρεάσουν δραματικά την απόδοση. Με τις ώριμες οπτικές τεχνολογίες, το πτερύγιο σύνδεσης είναι σπάνιο και συνήθως προκαλείται από ελαττωματικό καλώδιο, σφάλμα διαμόρφωσης ή ελαττωματικό πομποδέκτη. Με τις αναδυόμενες τεχνολογίες όπως τα 400 GbE, τα πτερύγια σύνδεσης μπορεί επίσης να συμβούν λόγω ζητημάτων θερμότητας, προβλημάτων σχεδιασμού με τις μονάδες πομποδέκτη ή προβλημάτων με τους ίδιους τους διακόπτες.

3. 4 Σύμφωνη Πολυπλεξία διαίρεσης μήκους κύματος (WDM coherent)

3. 4. 1 Εισαγωγή

Ένας σημαντικός στόχος ενός συστήματος οπτικών ινών μεγάλων αποστάσεων είναι η μετάδοση της υψηλότερης απόδοσης δεδομένων στη μεγαλύτερη απόσταση χωρίς αναγέννηση σήματος. Δεδομένων των περιορισμών στο εύρος ζώνης που επιβάλλονται από τους οπτικούς ενισχυτές και τελικά από την ίδια την ίνα, είναι σημαντικό να μεγιστοποιηθεί η φασματική απόδοση, μετρούμενη σε bit/s/Hz. Λόγω των περιορισμών στην ισχύ του σήματος που επιβάλλονται από τη μη γραμμικότητα της ίνας, είναι επίσης σημαντικό να μεγιστοποιηθεί η απόδοση ισχύος (ή SNR), δηλαδή να ελαχιστοποιηθεί η απαιτούμενη μέση μεταδιδόμενη ενέργεια ανά bit (ή η απαιτούμενη αναλογία σήματος-τόνου ανά bit). Τα περισσότερα τρέχοντα συστήματα χρησιμοποιούν δυαδικές μορφές διαμόρφωσης, όπως πηκτρολόγηση onoff ή διαφορική πηκτρολόγηση μετατόπισης φάσης, που κωδικοποιούν ένα bit ανά σύμβολο. Δεδομένων των πρακτικών περιορισμών στα φίλτρα για πολυπλεξία πυκνής διαίρεσης μήκους κύματος (DWDM), μπορεί να επιτευχθεί φασματική απόδοση 0.8 bit/s/Hz ανά πόλωση. Τα φασματικά όρια απόδοσης για διάφορες μεθόδους ανίχνευσης και διαμόρφωσης έχουν μελετηθεί στο γραμμικό και στο μη γραμμικό καθεστώς. Η μη σύμφωνη ανίχνευση και η διαφορικά σύμφωνη ανίχνευση προσφέρουν καλή απόδοση ισχύος μόνο σε χαμηλή φασματική απόδοση, επειδή περιορίζουν τους βαθμούς ελευθερίας που είναι διαθέσιμοι για την κωδικοποίηση πληροφοριών [75].

Η πιο πολλά υποσχόμενη τεχνική ανίχνευσης για την επίτευξη υψηλής φασματικής απόδοσης με παράλληλη μεγιστοποίηση της απόδοσης ισχύος (ή SNR), είναι η σύμφωνη ανίχνευση με πολυπλεξία πόλωσης, καθώς οι αποφάσεις συμβόλων λαμβάνονται χρησιμοποιώντας τα σήματα εντός φάσης (I) και τετραγωνισμού (Q) στις δύο πολώσεις πεδίων, επιτρέποντας την κωδικοποίηση πληροφοριών σε όλους τους διαθέσιμους βαθμούς ελευθερίας. Όταν γίνεται δειγματοληψία των εξόδων ενός οπτικοηλεκτρονικού καθοδικού μετατροπέα με ρυθμό Nyquist, η ψηφιοποιημένη κυματομορφή διατηρεί τις πλήρεις πληροφορίες

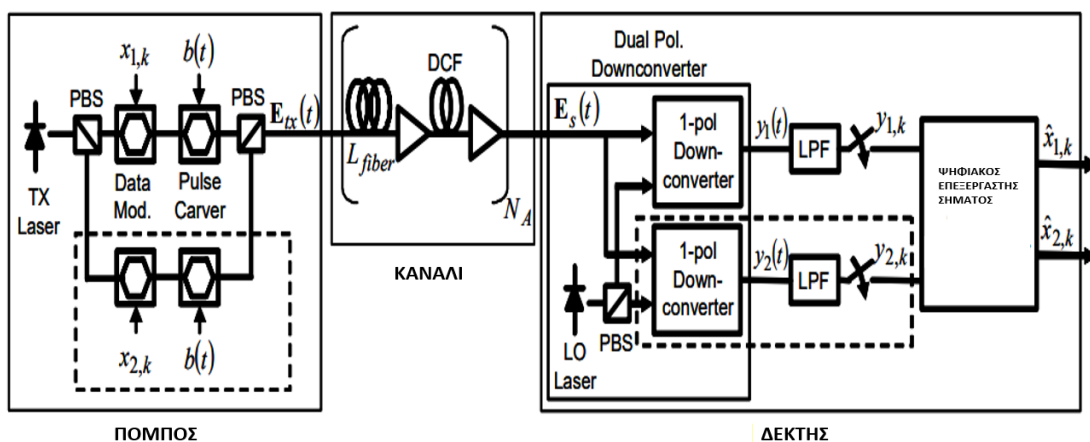
του ηλεκτρικού πεδίου, γεγονός που επιτρέπει την αντιστάθμιση των απωλειών μετάδοσης με επεξεργασία ψηφιακού σήματος (DSP). Ένας δέκτης που βασίζεται σε DSP είναι εξαιρετικά πλεονεκτικός επειδή μπορούν να χρησιμοποιηθούν προσαρμοστικοί αλγόριθμοι για την αντιστάθμιση χρονικά μεταβαλλόμενων απωλειών μετάδοσης. Μπορεί επίσης να εφαρμοστεί προηγμένη κωδικοποίηση διόρθωσης σφαλμάτων προς τα εμπρός. Επιπλέον, τα ψηφιοποιημένα σήματα μπορεί να καθυστερήσουν, καθώς επίσης να υπάρξει ταυτοχρόνως διαχωρισμός και ενίσχυση χωρίς υποβάθμιση στην ποιότητα του σήματος. Οι δέκτες που βασίζονται σε DSP διαδραματίζουν σημαντικό ρόλο στα συστήματα ασύρματων και ψηφιακών συνδρομητικών γραμμών (DSL) με χαμηλότερους ρυθμούς δεδομένων. Σε τέτοια συστήματα, έχουν αποδειχθεί υπολογιστικά εντατικές τεχνικές, όπως η ορθογώνια πολυπλεξία διαίρεσης συχνότητας (OFDM) με μετάδοση πολλαπλών εισόδων-πολλαπλών εξόδων (MIMO) σε ασύρματη σύνδεση 1 Gbit/s σε πραγματικό χρόνο [76]. Οι συνεχείς βελτιώσεις υλικού θα επιτρέψουν την ανάπτυξη συνεκτικών οπτικών συστημάτων που βασίζονται σε DSP τα επόμενα χρόνια.

3. 4. 2 Σύμφωνη ανίχνευση(coherent detection)

Η πιο προηγμένη μέθοδος ανίχνευσης είναι η σύμφωνη ανίχνευση(coherent detection), όπου ο δέκτης υπολογίζει τις μεταβλητές απόφασης με βάση την ανάκτηση του πλήρους ηλεκτρικού πεδίου, το οποίο περιέχει πληροφορίες πλάτους και φάσης. Η σύμφωνη ανίχνευση επιτρέπει έτσι μεγαλύτερη ευελιξία στις μορφές διαμόρφωσης, καθώς οι πληροφορίες μπορούν να κωδικοποιηθούν σε πλάτος και φάση, ή εναλλακτικά σε συνιστώσες εντός φάσης (I) και σε τετραγωνικά στοιχεία (Q) ενός φορέα. Η σύμφωνη ανίχνευση απαιτεί από τον δέκτη να έχει γνώση της φέρουσας φάσης, καθώς το λαμβανόμενο σήμα αποδιαμορφώνεται από ένα LO που χρησιμεύει ως απόλυτη αναφορά φάσης. Παραδοσιακά, ο συγχρονισμός φορέα εκτελείται από έναν βρόχο κλειδώματος φάσης PLL (phase-locked loop). Τα οπτικά συστήματα μπορούν να χρησιμοποιήσουν ένα οπτικό PLL (OPLL)(Optical Phase-Locked loop) που συγχρονίζει τη συχνότητα και τη φάση του LO λέιζερ με το TX λέιζερ

ή ένα ηλεκτρικό PLL όπου η καθοδική μετατροπή με χρήση λέιζερ LO ελεύθερης λειτουργίας ακολουθείται από αποδιαμόρφωση δεύτερου σταδίου από αναλογικό ή ψηφιακό ηλεκτρικό VCO(Voltage Controlled Oscillator) του οποίου η συχνότητα και η φάση συγχρονίζονται. Η χρήση ενός ηλεκτρικού PLL μπορεί να είναι επωφελής σε συστήματα διπλής όψης, καθώς ο πομποδέκτης μπορεί να χρησιμοποιεί ένα λέιζερ τόσο ως TX όσο και ως LO. Τα PLL είναι ευαίσθητα στην καθυστέρηση διάδοσης στη διαδρομή ανάδρασης και η απαίτηση καθυστέρησης μπορεί να είναι δύσκολο να ικανοποιηθεί. Ο συγχρονισμός φορέα παροχής τροφοδοσίας FF(Feed Forward) ξεπερνά αυτό το πρόβλημα. Επιπλέον, καθώς ένας συγχρονιστής FF χρησιμοποιεί τόσο παλιά όσο και μελλοντικά σύμβολα για να εκτιμήσει τη φάση του φορέα, μπορεί να επιτύχει καλύτερη απόδοση από ένα PLL το οποίο, ως σύστημα ανάδρασης, μπορεί να χρησιμοποιήσει μόνο σύμβολα του παρελθόντος. Πρόσφατα, το DSP επέτρεψε την ευθυγράμμιση πόλωσης και τον συγχρονισμό φορέα να εκτελούνται σε λογισμικό. και η απαίτηση καθυστέρησης μπορεί να είναι δύσκολο να ικανοποιηθεί .

Ο συγχρονισμός φορέα παροχής τροφοδοσίας (FF) ξεπερνά αυτό το πρόβλημα. Επιπλέον, καθώς ένας συγχρονιστής FF χρησιμοποιεί τόσο παλιά όσο και μελλοντικά σύμβολα για να εκτιμήσει τη φάση του φορέα, μπορεί να επιτύχει καλύτερη απόδοση από ένα PLL το οποίο, ως σύστημα ανάδρασης, μπορεί να χρησιμοποιήσει μόνο σύμβολα του παρελθόντος. Πρόσφατα, το DSP επέτρεψε την εκτέλεση της ευθυγράμμισης πόλωσης και του συγχρονισμού φορέα στο λογισμικό.



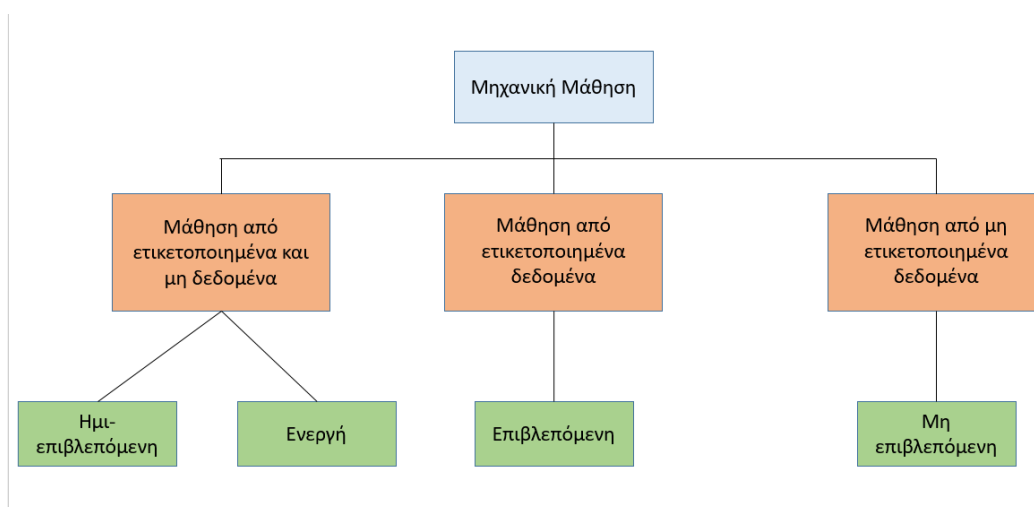
Σχήμα 1. Υλοποίηση ενός συνεκτικού συστήματος μετάδοσης

ΚΕΦΑΛΑΙΟ 4^ο – ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

4. 1 Εισαγωγή

Η ανάπτυξη αλγορίθμων για τη δημιουργία μοντέλων οι οποίοι στηρίζονται στη συλλογή στοιχείων και γεγονότων έχει δημιουργήσει ένα νέο τομέα στο χώρο της επιστήμης των υπολογιστών, αυτόν της μηχανικής μάθησης. Τα στοιχεία που συλλέγονται και αποτελούν είσοδο στους αλγόριθμους μπορεί να ανήκουν σε φυσικά φαινόμενα, σε ανθρώπινα μοντέλα που έχουν κατασκευαστεί για συγκεκριμένο σκοπό αλλά ακόμα και να προέρχονται από στοιχεία που δημιουργήθηκαν από άλλους αλγόριθμους. Με αυτό τον τρόπο ένας αλγόριθμος μπορεί να υπάρχει, να ενεργεί και να μαθαίνει μέσα σε ένα περιβάλλον που διαρκώς αλλάζει.

Στη μηχανική μάθηση κυριαρχούν τέσσερις βασικές ομάδες αλγορίθμων και διαφοροποιούνται ανάλογα με τον τύπο της μάθησης που επιζητούν. Οι κατηγορίες αυτές είναι: μάθηση με επίβλεψη (supervised learning), μάθηση χωρίς επίβλεψη (unsupervised learning), μάθηση με ημι-επίβλεψη (semi-supervised learning) και τέλος μάθηση με ενίσχυση (reinforcement learning) ή ενεργή μάθηση (active learning) [16].



Σχήμα 2. Κατηγοριοποίηση ειδών μηχανικής μάθησης

4. 2 Μάθηση με Επίβλεψη

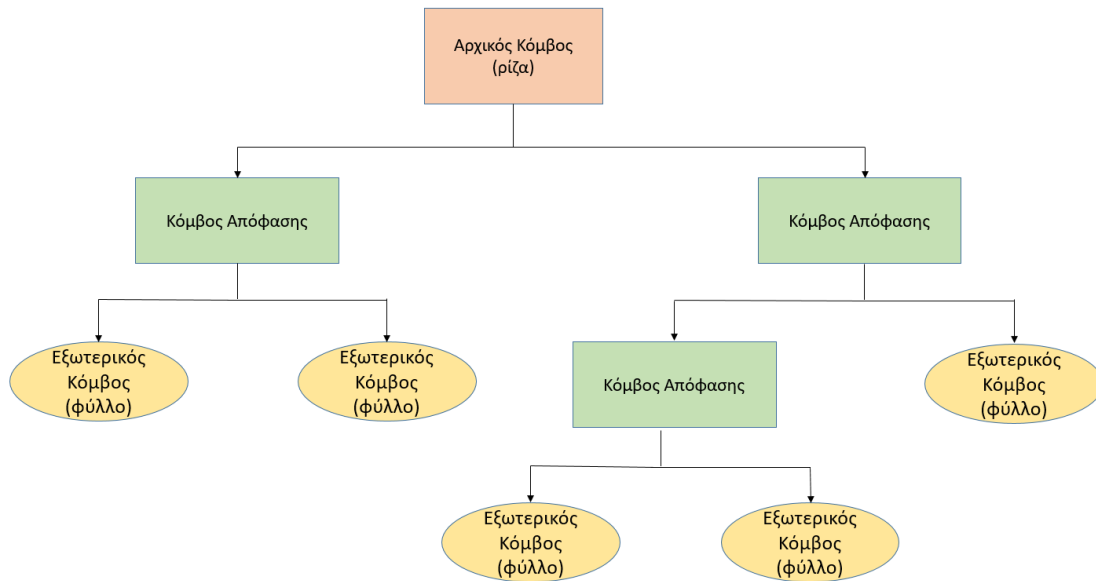
Στην πρώτη κατηγορία συναντάμε μοντέλα αλγορίθμων τα οποία εκπαιδεύονται μέσα από ένα πλήθος δεδομένων τα οποία συνήθως καλούμε δεδομένα εκπαίδευσης (training data). Στα δεδομένα αυτά υπάρχουν τιμές με χαρακτηριστικά στοιχεία εισόδων παράλληλα με τις τιμές των μεταβλητών απόφασης (έξοδος). Στηριζόμενος ο αλγόριθμος στα στοιχεία αυτά δημιουργεί ένα μοντέλο ταξινόμησης ώστε να εξάγει μελλοντικές τιμές εξόδου για αντίστοιχες τιμές εισόδου. Η τιμή της μεταβλητής εξόδου μπορεί να παίρνει τόσο διακριτές τιμές όσο και συνεχείς, για το σκοπό αυτό η συγκεκριμένη κατηγορία αλγορίθμων έχει διαχωριστεί σε δύο υποκατηγορίες: ταξινόμησης με διακριτές τιμές, παλινδρόμησης με συνεχείς τιμές [17].

Ο έλεγχος της βέλτιστης λειτουργίας και ορθότητας του προβλεπόμενου μοντέλου γίνεται μέσα από ένα σύνολο δεδομένων εισόδου-εξόδου το οποίο ονομάζουμε δεδομένα για έλεγχο (test set).

4. 2. 1 Δέντρα αποφάσεων

Μία σημαντική μέθοδος κατηγοριοποίησης δεδομένων είναι τα δένδρα αποφάσεων (decision trees). Η συγκεκριμένη μέθοδος βασίζεται στον υπολογισμό μιας συνάρτησης απόφασης (κατηγορήμα) και εφαρμόζοντας κριτήρια διαχωρισμού όπως η τεχνική “διαίρει και βασίλευε” καταλήγει στο επιθυμητό αποτέλεσμα.

Σχηματικά ένα δένδρο απόφασης είναι η γραφική απεικόνιση όλων των πιθανών διαδρομών που χρησιμοποιούνται για να φτάσουμε στο τελικό αποτέλεσμα.




Σχήμα 3. Δομή δένδρου απόφασης

Ένα δένδρο απόφασης αποτελείται από αρκετές κατηγορίες κόμβων όπως τον αρχικό κόμβο(ρίζα), ο οποίος δεν περιλαμβάνει εισερχόμενες ακμές, τους εσωτερικούς κόμβους που αντιστοιχούν σε μία μεταβλητή η οποία χρησιμοποιείται για επιπλέον διαχωρισμό του δένδρου και τους εξωτερικούς κόμβους (φύλλα) οι οποίοι περιέχουν τα αποτελέσματα [18]. Αξίζει να σημειωθεί ότι στις εξερχόμενες ακμές του αρχικού ή κάθε εσωτερικού κόμβου υπάρχει μία συνθήκη για έλεγχο η οποία στηρίζεται στην τιμή της μεταβλητής.

4. 2. 2 Αλγόριθμος Bayes

Μία αποδοτική μέθοδος ταξινόμησης είναι αυτή με χρήση μοντέλων πιθανοτήτων τα οποία βασίζονται στον γνωστό νόμο της δεσμευμένης πιθανότητας του Bayes. Σύμφωνα με τη σχέση $P(A|B) = \frac{P(A)P(B|A)}{P(B)}$, η δεσμευμένη πιθανότητα του ενδεχομένου A δεδομένου ότι έχει συμβεί το B εξαρτάται τόσο από την πιθανότητα των A, B αλλά και την πιθανότητα να συμβεί το B στην περίπτωση που έχει συμβεί το A [19].



Εικόνα 9. Ταξινόμηση (A) γραμμική, (B) μη γραμμική

Έτσι ο ταξινομητής αυτός μπορεί να εφαρμοσθεί για να εκτιμήσουμε την πιθανότητα που έχει ένα στιγμιότυπο να είναι μέρος μίας προκαθορισμένης κλάσης εκτιμώντας ως δεδομένο ότι τα κύρια χαρακτηριστικά είναι ανεξάρτητα μεταξύ τους πράγμα που σε γενικές γραμμές δεν ισχύει αλλά με αυτή τη θεώρηση απλοποιείται σε σημαντικό βαθμό το μοντέλο χωρίς να απαιτείται μεγάλο σύνολο εκπαίδευσης.


4. 2. 3 Μηχανές διανυσμάτων υποστήριξης

Μια ιδιαίτερα διαδεδομένη μέθοδος κατηγοριοποίησης είναι η χρησιμοποίηση αλγορίθμων που βασίζονται σε Μηχανές Διανυσμάτων Υποστήριξης (Support Vector Machine, SVM). Η μέθοδος αυτή δύναται να χρησιμοποιηθεί για ποιοτικές μεταβλητές αλλά και για δεδομένα πολλών διαστάσεων. Πιο συγκεκριμένα, μέσα από κάθε κλάση γίνεται επιλογή ενός μικρού δείγματος από δεδομένα εκπαίδευσης, τα οποία καλούνται ως διανύσματα υποστήριξης. Τα διανύσματα αυτά βρίσκονται σε κοντινή απόσταση με τα διανύσματα άλλων γειτονικών κλάσεων και σε συνδυασμό χρησιμοποιούνται για την ανεύρεση ενός επιπέδου με το μέγιστο περιθώριο, απόρροιας του γραμμικού διαχωρισμού που υπέστησαν σε προηγούμενο στάδιο [20].

4. 2. 4 Μάθηση βασισμένη σε στιγμιότυπα

Μία εξίσου σημαντική μέθοδος είναι εκείνη της μάθησης που βασίζεται σε στιγμιότυπα. Η μέθοδος αυτή στηρίζεται στην ομοιότητα που παρουσιάζουν τα δεδομένα που χρησιμοποιούνται, την οποία υπολογίζουμε με τη χρήση κατάλληλων συναρτήσεων(μετρικών). Από το σύνολο των διαφορετικών αλγορίθμων που χρησιμοποιούνται για αυτόν τον σκοπό, πιο διακεκριμένος είναι εκείνος των k πλησιέστερων γειτόνων (k -NN).

Η λογική του συγκεκριμένου αλγορίθμου είναι ο εντοπισμός κατάλληλων k στιγμιοτύπων από το σύνολο των δεδομένων της εκπαίδευσης, τα οποία βρίσκονται στην πιο κοντινή απόσταση με ένα συγκεκριμένο στιγμιότυπο. Στη συνέχεια αποδίδει και κατηγοριοποιεί το στιγμιότυπο αυτό σε εκείνη την κλάση η οποία είναι η κυρίαρχη μεταξύ των υπόλοιπων k στιγμιοτύπων [21].



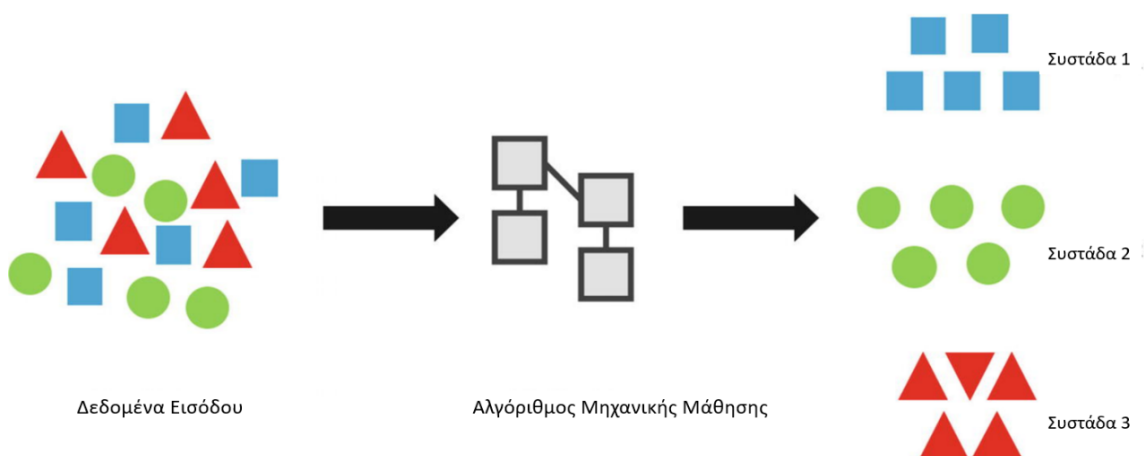
Εικόνα 10. Αποτελέσματα εφαρμογής αλγορίθμου K -NN

Σημαντικό ρόλο στην αποτελεσματικότητα της παραπάνω μεθόδου κατέχουν ορισμένες παράμετροι όπως το σύνολο των δεδομένων που χρησιμοποιούνται για την εκπαίδευση, η τιμή του k η οποία έχει καθοριστεί από το πλήθος των πλησιέστερων γειτόνων και η κατάλληλη μετρική που χρησιμοποιείται προκειμένου να γίνει ο υπολογισμός της απόστασης μεταξύ των εξεταζόμενων στιγμιοτύπων.

Ιδιαίτερα σημαντικό είναι το γεγονός ότι η μέθοδος των k πλησιέστερων γειτόνων χρησιμοποιείται κατά κόρον για την επίλυση δύσκολων προβλημάτων κατηγοριοποίησης αφού πρώτα υποστεί την κατάλληλη τροποποίηση.

4.3 Μάθηση χωρίς Επίβλεψη

Στη μάθηση χωρίς επίβλεψη, τα μοντέλα μάθησης χρησιμοποιούν συνολα δεδομένων εκπαίδευσης για τα οποία η κλάση τους είναι άγνωστη και προσπαθούν να τα κατηγοριοποιήσουν με βάση κοινά ή μη σημεία που μπορεί να παρουσιάζουν μεταξύ τους. Λόγω της δυσκολίας εύρεσης δεδομένων των οποίων οι κλάσεις είναι γνωστές είναι σχεδόν ακατόρθωτο να γίνει ποσοτική αξιολόγηση σχετικά με την απόδοση του συστήματος. Έτσι δημιουργούνται προβλήματα όπως η συσταδοποίηση, στην οποία τα υπάρχοντα δεδομένα διαχωρίζονται σε n ομάδες (συστάδες), η ελάττωση διαστάσεων στην οποία απεικονίζονται περιπτώσεις με δεδομένα εκπαίδευσης τα οποία περιέχουν μικρότερο αριθμό χαρακτηριστικών χωρίς όμως να αποχωρίζονται τις χαρακτηριστικές ιδιότητες των δεδομένων τους και ο εντοπισμός καινοτομιών όπου οι περιπτώσεις είναι ελάχιστες και διαφορετικές από τις συγκεντρωτικές περιπτώσεις [22][23].

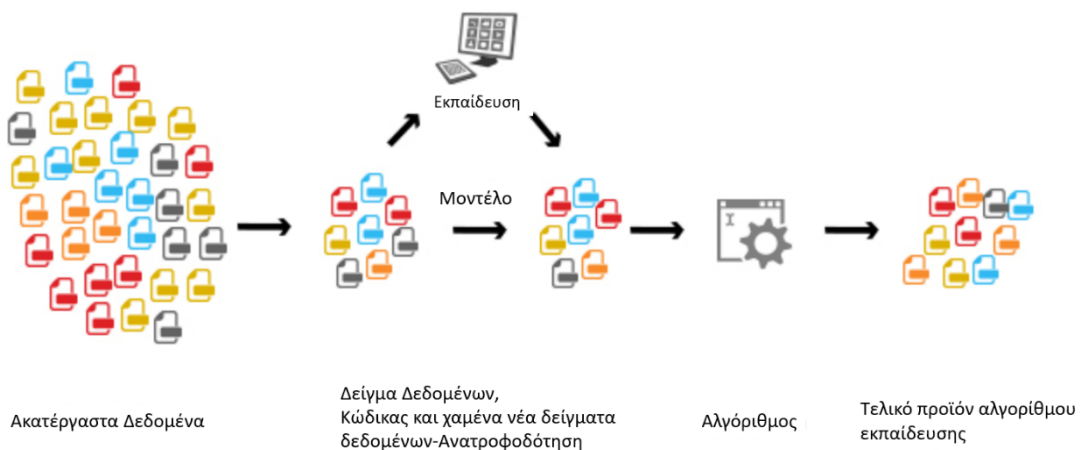


Εικόνα 11. Μεθοδολογία μάθησης χωρίς επίβλεψη

4. 4 Μάθηση με Ημι-Επίβλεψη

Στα συστήματα τα οποία στηρίζονται στην μάθηση με ημι-επίβλεψη έχουν ως αρχικό σύνολο ένα πλήθος δεδομένων εκπαίδευσης με γνωστές τις κλάσεις τους ικανό να εξάγει ένα τις κλάσεις ενός μεγάλου πλήθους δεδομένων του οποίου οι κλάσεις είναι άγνωστες. Έτσι μέσα από κατάλληλους υπολογισμούς και διαδικασίες παράγει προβλέψεις για τα νέα δεδομένα.

Η ημι-επιβλεπόμενη μάθηση χρησιμοποιείται επί των πλείστων για την επίλυση προβλημάτων όπου η συλλογή δεδομένων με άγνωστες κλάσεις είναι εύκολο να πραγματοποιηθεί ενώ αντίθετα στην περίπτωση των γνωστών κλάσεων η συλλογή των δεδομένων γίνεται με δύσκολο τρόπο εξαιτίας της απαίτησης του χρόνου και του μεγάλου κόστους. Υπάρχουν πολλοί και διαφορετικοί τύποι προβλημάτων στην μάθηση με ημι-επίβλεψη όπως για παράδειγμα η ταξινόμηση, η πρόβλεψη τιμής καθώς και η ταξινόμηση που βασίζεται σε κριτήρια. Πολλές έρευνες[24][25][26] έχουν καταλήξει στο συμπέρασμα ότι ο συνδυασμός της μάθησης με επίβλεψη και εκείνης χωρίς επίβλεψη μπορεί να καταλήξει μέσω της σωστής αξιοποίησης των δεδομένων που παρέχονται στη δημιουργία μοντέλων μάθησης πιο αποδοτικών σε σχέση με εκείνα που δημιουργούνται μέσω της μάθησης με επίβλεψη.



Εικόνα 12. Μεθοδολογία μάθησης με ημι-επίβλεψη

Παραδείγματα μεθόδων ημι-επιβλεπόμενης μάθησης είναι το self-training η οποία έχει επικρατήσει ως η πιο απλή και συγχρόνως αποτελεσματική μέθοδος μάθησης με ημι-επίβλεψη [27]. Η εκπαίδευση της συγκεκριμένης μεθόδου βασίζεται σε δεδομένα τα οποία δεν περιέχουν ετικέτα και σε προβέψεις που παράγονται από την ίδια. Η διαδικασία ξεκινά με την εκπαίδευση ενός ταξινομητή σε ετικετοποιημένα δεδομένα μικρού μεγέθους στο σύνολο της εκπαίδευσης με σκοπό στη συνέχεια να προβλεφθούν οι κλάσεις των δεδομένων που δεν έχουν ετικετοποιηθεί. Οι προβέψεις με τη μεγαλύτερη ακρίβεια προστίθενται στο σύνολο των δεδομένων χωρίς ετικέτα και η διαδικασία εκτελείται ξανά και ξανά για συγκεκριμένο πλήθος επαναλήψεων.

Η μέθοδος co-training έχει χρησιμοποιηθεί αρκετές φορές για την επίλυση πολλών και δύσκολων προβλημάτων ημι-επιβλεπόμενης μάθησης. Η συγκεκριμένη μέθοδος βασίζεται στην υπόθεση που γίνεται ότι για κάθε στιγμιότυπο μπορεί να υπάρξει διαχωρισμός σε δύο διακριτά σύνολα από χαρακτηριστικά, τα οποία ορίζονται ως πεδία. Κάθε πεδίο θεωρείται ότι είναι επαρκές προκειμένου να υπάρξει σωστή κατηγοριοποίηση, ενώ συνάμμα είναι ανεξάρτητο από τα υπόλοιπα πεδία. Στη συγκεκριμένη υπόθεση πραγματοποιείται εκπαίδευση δύο αλγορίθμων μάθησης ξεχωριστά για κάθε πεδίο με βάση τα δεδομένα εκπαίδευσης που περιέχουν ετικέτα. Οι πιο σίγουρες προβλέψεις του καθενός αλγορίθμου προστίθενται στις προβλέψεις του άλλου και η διαδικασία επαναλαμβάνεται για συγκεκριμένο πλήθος επαναλήψεων [28].

Μία ακόμη μέθοδος είναι το tri-training, η οποία είναι παραλλαγή της μεθόδου co-training χωρίς όμως να χρειάζεται την συνεργασία δύο ανεξάρτητων πεδίων. Αντιθέτως, βασίζεται στη μέθοδο εμφωλίας η οποία δημιουργεί αυτοδύναμα υποσύνολα από το αρχικό πλήθος δεδομένων με το ίδιο μέγεθος και τα οποία λαμβάνονται μέσω μίας επαναληπτικής διαδικασίας δειγματοληψίας. Μετέπειτα χρησιμοποιούνται τρεις αλγόριθμοι μάθησης που εκπαιδεύονται με βάση τα υποσύνολα αυτά. Ουσιαστικά πρόκειται για έναν αλγόριθμο εμφωλίας ο οποίος περιέχει τρεις ταξινομητές. Το αποτέλεσμα προκύπτει από την συμφωνία για την πρόβλεψη μίας κλάσης ενός μη ετικετοποιημένου στιγμιότυπου των δύο εκ των

τριών αλγορίθμων. Αν υπάρχει συμφωνία μεταξύ των δύο αλγορίθμων τότε το στιγμιότυπο αυτό χρησιμοποιείται για την εκπαίδευση του τρίτου αλγορίθμου [29].

Ακόμη μία μέθοδος η οποία αποτελεί παραλλαγή της co-training μεθόδου είναι η democratic co-training. Σε αυτήν την περίπτωση εκπαιδεύονται τρεις αλγόριθμοι στο ίδιο σύνολο δεδομένων που περιέχουν ετικέτα. Αν τα αποτελέσματα των δύο αλγορίθμων συμφωνούν για την πρόβλεψη μιας κλάσης ενός στιγμιότυπου το οποίο δεν περιέχει ετικέτα τότε το συγκεκριμένο στιγμιότυπο θα χρησιμοποιηθεί για την εκπαίδευση του τρίτου αλγορίθμου.

Γενικά συναντώνται πολλές μέθοδοι που αποτελούν τροποποιήσεις ή παραλλαγές της μεθόδου co-training όπως η tri-training with editing, η RASCO και η Rel-RASCO, οι οποίες έχουν χρησιμοποιηθεί επιτυχώς για την επίλυση πολύπλοκων προβλημάτων μηχανικής μάθησης με ημι-επίβλεψη.

4.5 Μηχανική Μάθηση με ενίσχυση

Με ανάλογο τρόπο όπως αναφέρθηκε στη μάθηση με ημι-επίβλεψη, η μάθηση με ενίσχυση λαμβάνει ως είσοδο ένα σύνολο δεδομένων εκπαίδευσης το οποίο περιλαμβάνει μικρό αριθμό δεδομένων με γνωστές κλάσεις και μεγάλο αριθμό δεδομένων με άγνωστες κλάσεις παράγοντας μετά από υπολογισμούς προβλέψεις για καινούργια δεδομένα. Η παρούσα μέθοδος διαφοροποιείται στο εξής σημείο: εάν κατά τη διαδικασία της πρόβλεψης διαπιστωθούν περιπτώσεις τιμών που είναι αβέβαιος ο υπολογισμός της μεταβλητής απόφασης τότε για αυτές τις τιμές δημιουργούνται από τον αλγόριθμο ερωτήματα τα οποία καλείται να απαντήσει ο χρήστης δημιουργώντας κατά αυτό τον τρόπο μία τεχνική πρόβλεψης υψηλής ακρίβειας διατηρώντας χαμηλό το πλήθος των ερωτημάτων που θα τεθούν [30].



Εικόνα 13. Απεικόνιση μηχανικής μάθησης με ενίσχυση

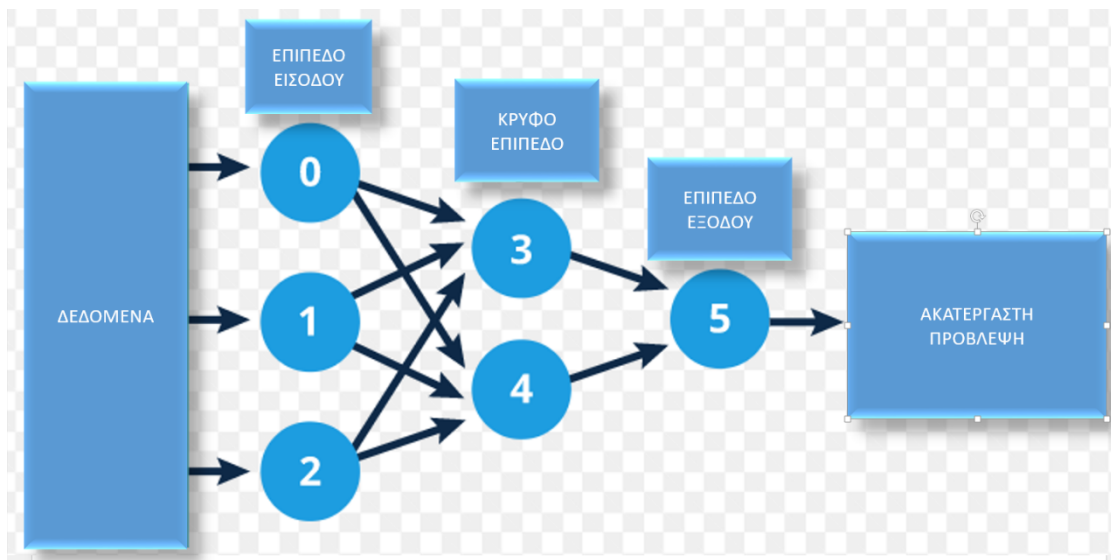
4. 6 Νευρωνικά δίκτυα

4. 6. 1 Ορισμός

Η βάση των νευρωνικών δικτύων βρίσκεται σε μαθηματικά μοντέλα τα οποία αντιστοιχούνται πλήρως με τα βιολογικά νευρωνικά δίκτυα. Περιέχονται από ένα πλήθος επεξεργαστικών μονάδων που ονομάζονται κόμβοι ή εναλλακτικά νευρώνες, οι οποίοι βρίσκονται ομαδοποιούνται σε διαφορετικά στρώματα. Οι συνδέσεις που συμβαίνουν μεταξύ των κόμβων καλούνται ως συνάψεις. Σημαντικά χαρακτηριστικά είναι επίσης το bias και οι συναρτήσεις ενεργοποίησης. Οι κόμβοι/νευρώνες που δεν συνδέονται με κάποιον προγενέστερο κόμβο καλούνται ως εισοδοί ενώ εκείνοι που δεν συνδέονται με κάποιον επόμενο κόμβο καλούνται ως έξοδοι. Τα νευρωνικά δίκτυα ξεκινούν την επεξεργασία πληροφοριών μόλις λάβουν εξωτερικά ερεθίσματα (πχ εισοδοί) και αποτελούνται από ένα πλήθος τεχνητών νευρώνων με τον κάθε νευρώνα να μπορεί να λαμβάνει πολλαπλές εισόδους κάθε φορά και να παράξει μόνο μία έξοδο.

4. 6. 2 Δομή Νευρωνικού Δικτύου

Η δομή των Νευρωνικών Δικτύων περιέχει τρία είδη στρωμάτων (layers). Το πρώτο επίπεδο είναι το επίπεδο εισόδου (input layer) όπου εισάγονται στο νευρωνικό δίκτυο οι τιμές εισόδου από το χρήστη, το δεύτερο αποτελείται από τα κρυφά επίπεδα (hidden layers) όπου το νευρωνικό δίκτυο βρίσκεται σε κατάσταση επεξεργασίας των δεδομένων που έλαβε από το χρήστη με σκοπό να παράξει μία πρόβλεψη και το τρίτο επίπεδο το οποίο ονομάζεται επίπεδο εξόδου (output layer) όπου το νευρωνικό δίκτυο παραδίδει την πρόβλεψή του. Αξίζει να σημειωθεί ότι το επίπεδο των κρυφών στρωμάτων μπορεί να περιέχει πολλαπλά ή μηδέν κρυφά στρώματα[31].



Εικόνα 14. Απεικόνιση δομής ενός νευρωνικού δικτύου

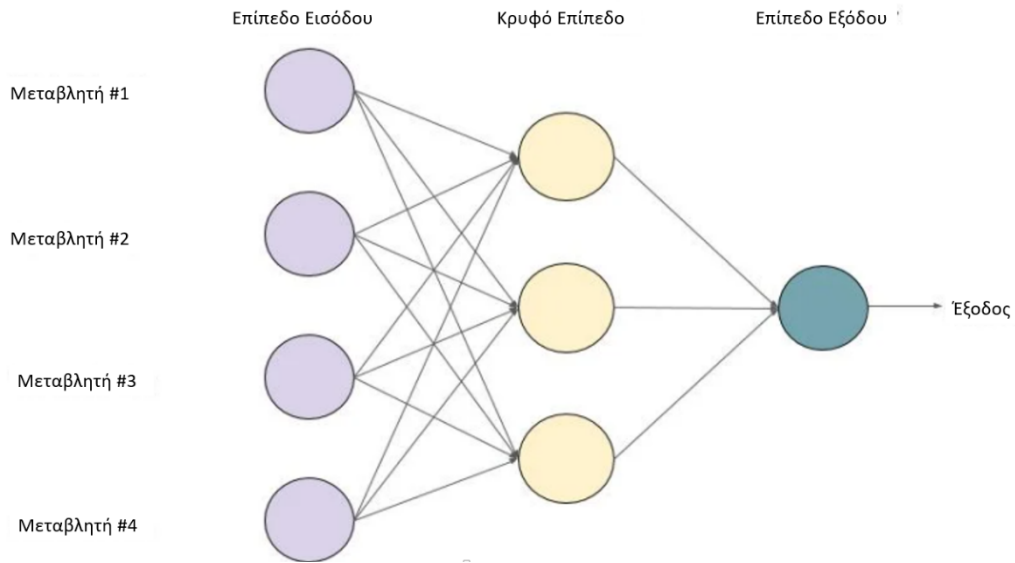
Τα επίπεδα δικτύου περιέχουν έναν αριθμό κόμβων ο οποίος ορίζεται κάθε φορά από το δημιουργό του νευρωνικού δικτύου. Οι κόμβοι αυτοί συνδέονται μεταξύ τους με τέτοιο τρόπο ώστε ο καθένας από αυτούς να συνδέεται με περισσότερους από έναν κόμβους ή με κόμβους που βρίσκονται στο ίδιο στρώμα (layer). Εξαιτίας της συνδεσιμότητας αυτής δημιουργείται μία σχέση επιρροής του ενός κόμβου με τους άλλους με σκοπό να καταλήξει το νευρωνικό δίκτυο σε μία επιτυχημένη τελική πρόβλεψη. Για το λόγο αυτό, σε κάθε κόμβο εφαρμόζεται η

συνάρτηση ενεργοποίησης, η οποία επηρεάζει το δίκτυο δίνοντας του μία μη γραμμική συμπεριφορά. Επομένως για να είναι επιτυχής η δομή ενός νευρωνικού δικτύου θα πρέπει ο δημιουργός να ορίσει με ιδανικό τρόπο κάποιες παραμέτρους όπως ο αριθμός των κρυφών επιπέδων, ο αριθμός των κόμβων/νευρώνων ανά στρώμα (layer), τον ορισμό σωστής συνάρτησης ενεργοποίησης, τον τρόπο που θα συνδέονται οι κόμβοι μεταξύ τους και τον καθορισμό αλγορίθμου για τη διαδικασία της εκπαίδευσης.

4. 6. 3 Αρχιτεκτονική Νευρωνικού Δικτύου

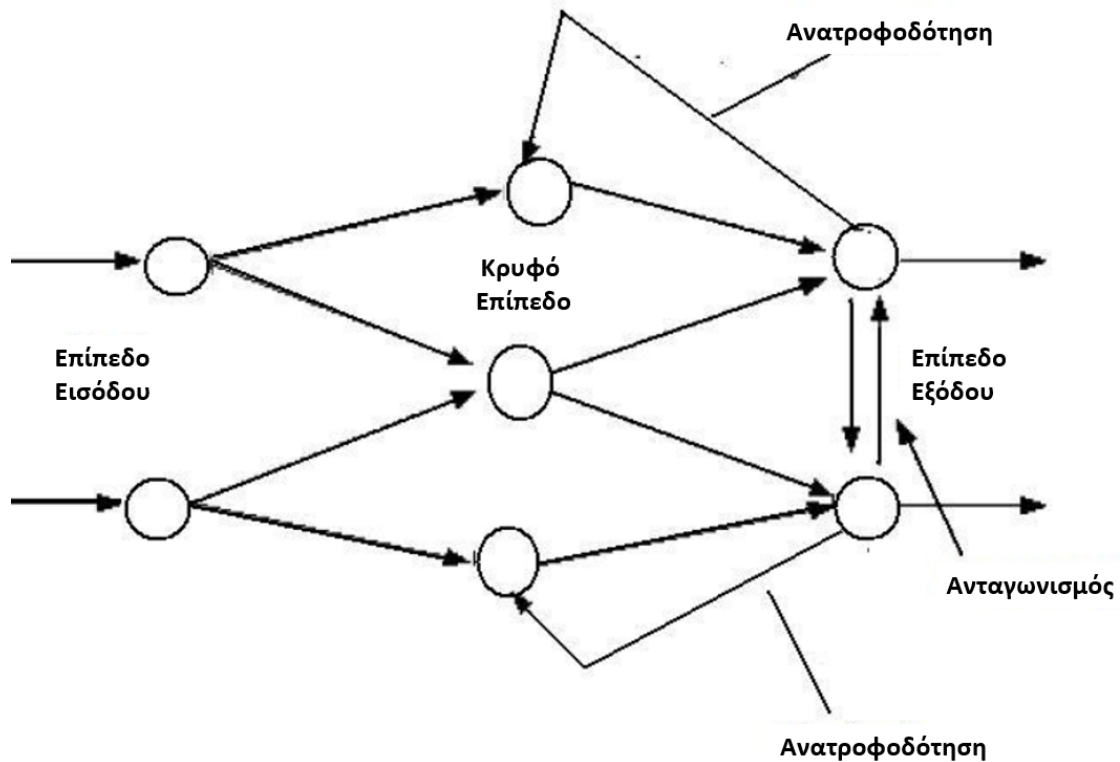
Οι δύο βασικοί τύποι που προκύπτουν από τον τρόπο σύνδεσης των μονάδων των νευρωνικών δικτύων είναι ο τύπος της πρόσθιας τροφοδότησης (feed forward) και ο τύπος της ανατροφοδότησης (feedback).

Το feed forward νευρωνικό δίκτυο είναι από τους πρώτους τύπους που επινοήθηκε. Το όνομά του προέκυψε από την κίνηση των πληροφοριών προς μία μόνο κατεύθυνση(πάντοτε προς τα μπροστά) όπως φαίνεται στην Εικόνα 15. Οι πληροφορίες που προέρχονται από το επίπεδο εισόδου του νευρωνικού δικτύου οδηγούνται στα κρυφά επίπεδα και έπειτα καταλήγουν στο επίπεδο εξόδου. Εν αντιθέσει με άλλου τύπου νευρωνικά δίκτυα τα οποία μπορεί να περιέχουν βρόγχους, στη συγκεκριμένη περίπτωση οι πληροφορίες κατευθύνονται σε μία μόνο κατεύθυνση αποτελώντας την πιο κοινή αρχιτεκτονική νευρωνικού δικτύου [32]. Ένα παράδειγμα είναι το δίκτυο Single Layer Perceptron(SLP), το οποίο αποτελείται από μία είσοδο που τροφοδοτείται απευθείας σε μία έξοδο. Επιπλέον υπάρχει και το Multi- Layer Perceptron(MLP), το οποίο βασίζεται στο perceptron αποτελώντας έτσι την πιο διαδεδομένη και χρησιμοποιούμενη εφαρμογή των νευρωνικών δικτύων πρόσθιας τροφοδότησης.



Εικόνα 15. Απεικόνιση ενός Feed-Forward Νευρωνικού Δικτύου με ένα κρυφό επίπεδο(3 νευρώνων)

Τα Νευρωνικά Δίκτυα Ανατροφοδότησης (feedback) ή αλλιώς αναδρομικά (recurrent, RNN) παρουσιάζουν μία βασική διαφορά σε σχέση με τα feed-forward δίκτυα η οποία είναι η ύπαρξη ενός νευρώνα που μπορεί να επικοινωνεί στέλνοντας πληροφορίες σε νευρώνα προηγούμενου επιπέδου ή και στον ίδιο του τον εαυτό όπως φαίνεται στην Εικόνα 16. Νευρώνες τέτοιου είδους ονομάζονται feedback loop και στην ουσία πρόκειται για δίκτυα τα οποία είναι πολύ ισχυρά με πολύ υψηλά επίπεδα πολυπλοκότητας. Τα recurrent δίκτυα παρουσιάζουν δυναμική φύση δεδομένου ότι υπόκεινται σε συνεχή αλλαγή της κατάστασής τους μέχρις ότου να σταθεροποιηθούν σε ένα σημείο ισορροπίας, του οποίου η κατάσταση θα αλλάξει πάλι όταν λάβουν νέες εισόδους [33].



Εικόνα 16. Απεικόνιση ενός Feedback Νευρωνικού Δικτύου


4. 6. 3. 1 Συναρτήσεις Ενεργοποίησης

Η αρχιτεκτονική των Τεχνητών Νευρωνικών Δικτύων (ΤΝΔ) περιέχει συνήθως μία σταθερή συνάρτηση ενεργοποίησης (activation function) η οποία παρουσιάζει μη γραμμική συμπεριφορά σε κάθε νευρώνα [81]. Στην περίπτωση που ένα νευρωνικό δίκτυο δεν περιέχει συνάρτηση ενεργοποίησης, παρουσιάζει μια συμπεριφορά ενός μοντέλου γραμμικής παλινδρόμησης χωρίς να έχει την ίδια ισχύ και απόδοση σε σχέση με ένα ΤΝΔ που περιέχει συνάρτηση ενεργοποίησης και επιλύει μη γραμμικά προβλήματα. Οι συναρτήσεις ενεργοποίησης με την πιο συχνή χρήση στην αρχιτεκτονική των ΤΝΔ είναι η δυαδική βηματική συνάρτηση (binary step function), η γραμμική συνάρτηση (linear function), η σιγμοειδής συνάρτηση (sigmoid function), η συνάρτηση υπερβολικής εφαπτομένης (tanh function), η ανορθωτική γραμμική συνάρτηση (ReLU function) και η συνάρτηση Softmax οι οποίες αναλύονται αναλυτικά στη συνέχεια.

Η δυαδική βηματική συνάρτηση (Binary Step Function) γενικά χρησιμοποιείται στον γραμμικό ταξινομητή Perceptron. Αποτελεί την πιο απλή συνάρτηση ενεργοποίησης όπως φαίνεται και από τον μαθηματικό τύπο:

$$f(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases}$$


Με βάση τον ταξινομητή κατωφλίου αποφασίζει αν θα ενεργοποιηθεί ο επόμενος νευρώνας ανάλογα με την τιμή που έχει λάβει ως είσοδο. Στην περίπτωση που αποφασιστεί ότι ο επόμενος νευρώνας δεν θα ενεργοποιηθεί τότε η έξοδος δεν θα περάσει ως είσοδος στον επόμενο νευρώνα. Η συγκεκριμένη συνάρτηση ενεργοποίησης χρησιμοποιείται μόνο για την περίπτωση της δυαδικής ταξινόμησης και εφαρμόζεται σε λιγότερες από δύο κλάσεις [82].



Σχήμα 4. Δυαδική Βηματική Συνάρτηση ενεργοποίησης


Η γραμμική συνάρτηση ενεργοποίησης (Linear Function) είναι μια απλή συνάρτηση ενεργοποίησης ευθείας γραμμής όπου η συνάρτηση είναι ευθέως ανάλογη με το σταθμισμένο άθροισμα των νευρώνων ή της εισόδου. Οι συναρτήσεις γραμμικής ενεργοποίησης είναι καλύτερες στο να δίνουν ένα ευρύ φάσμα

ενεργοποιήσεων και μια γραμμή θετικής κλίσης η οποία μπορεί να αυξήσει τον ρυθμό πυροδότησης καθώς αυξάνεται ο ρυθμός εισόδου [82]. Η γραμμική συνάρτηση παρουσιάζει ως έξοδο ανάλογο αποτέλεσμα με την είσοδό της, δηλαδή είναι γραμμικά εξαρτημένη όπως φαίνεται στο Σχήμα 5. Η συνάρτηση είναι η γνωστή ως $f(x) = ax$ όπου το a ορίζεται από τον χρήστη και είναι μια σταθερή τιμή μέσω της οποίας υποδηλώνεται η κλίση της γραμμικής συνάρτησης [82].



Σχήμα 5. Γραμμική Συνάρτηση ενεργοποίησης


Η σιγμοειδής συνάρτηση ενεργοποίησης (Sigmoid Function) αποτελεί μια ευρέως χρησιμοποιούμενη συνάρτηση ενεργοποίησης καθώς μπορεί να προσδώσει μη γραμμική συμπεριφορά στο τεχνητό νευρωνικό δίκτυο. Ο ρόλος της συγκεκριμένης συνάρτησης είναι η μετατροπή όλων των τιμών που δέχεται ως είσοδο σε τιμές οι οποίες βρίσκονται στο διάστημα $(0, 1)$ κατά την έξοδο [82]. Ο μαθηματικός τύπος που περιγράφει την σιγμοειδή συνάρτηση είναι $f(x) = \frac{1}{1+e^{-x}}$.



Σχήμα 6. Σιγμοειδής Συνάρτηση ενεργοποίησης


Η συνάρτηση υπερβολικής εφαπτομένης (Tanh Function) είναι μια συνεχής και παραγωγίσιμη συνάρτηση η οποία είναι παρόμοια με τη σιγμοειδή συνάρτηση. Η μοναδική διαφορά τους είναι ότι το Y μπορεί να έχει και αρνητικές τιμές έχοντας ως όρια $(-1, 1)$ και η έξοδός της είναι κεντραρισμένη στο σημείο $(0, 0)$ όπως φαίνεται

στο Σχήμα 7. Ο μαθηματικός τύπος είναι $f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$.




Σχήμα 7. Συνάρτηση υπερβολικής εφαπτομένης

Σε σχέση με τη σιγμοειδή συνάρτηση, η συνάρτηση υπερβολικής εφαπτομένης παρουσιάζει ένα μεγάλο πλεονέκτημα το οποίο είναι ότι οι αρνητικές τιμές εισόδου θα καταλήξουν σε αρνητικές τιμές και οι μηδενικές τιμές εισόδου θα καταλήξουν κοντά στο 0 εν αντιθέσει με τη σιγμοειδή όπου οι αρνητικές τιμές εισόδου καταλήγουν σε θετικές τιμές όπως φαίνεται στη σύγκριση του Σχήματος 8.



Σχήμα 8. Σύγκριση σιγμοειδούς συνάρτησης με συνάρτηση υπερβολικής εφαπτομένης

Η ανορθωτική γραμμική συνάρτηση (ReLU function) αποτελεί την πιο συχνά χρησιμοποιούμενη συνάρτηση καθώς είναι η βασική συνάρτηση όλων των συνελκτικών νευρωνικών δικτύων (CNN). Πρόκειται για μια συνάρτηση η οποία δίνει μηδενική τιμή για τιμές μικρότερες ή ίσες με το μηδέν ενώ για μεγαλύτερες τιμές του μηδενός η έξοδος λαμβάνει την ίδια ακριβώς τιμή όπως φαίνεται στο Σχήμα 8. Ο μαθηματικός της τύπος είναι $f(x) = \max(0, x)$ [82]. Το κύριο πλεονέκτημα της συγκεκριμένης συνάρτησης είναι η αντιμετώπιση του προβλήματος των εξαφανιζόμενων κλίσεων (vanishing gradient problem) [83].




Σχήμα 9. Ανορθωτική Γραμμική Συνάρτηση

Η συνάρτηση Softmax χρησιμοποιείται για την αντιμετώπιση προβλημάτων κατηγοριοποίησης. Παραδείγματος χάριν η σιγμοειδής συνάρτηση μπορεί να χειριστεί μέχρι δύο κλάσεις κάτι το οποίο τις περισσότερες φορές δεν είναι αρκετό. Η συνάρτηση Softmax η οποία αποτελεί μια γενίκευση της λογιστικής συνάρτησης μπορεί να επιλύσει το πρόβλημα αυτό. Χρησιμοποιείται στο τελευταίο στρώμα ενός νευρωνικού δικτύου το οποίο αποτελείται από τις τιμές εξόδου του δικτύου και λειτουργεί συμπυκνώνοντας τις τιμές αυτές έτσι ώστε να βρίσκονται στο διάστημα $(0, 1)$ και το άθροισμά τους να ισούται με την μονάδα. Επομένως κάθε τιμή της

εξόδου της συνάρτησης Softmax ισοδυναμεί με μία κατηγορική συνάρτηση πιθανότητας [82]. Η συγκεκριμένη συνάρτηση χρησιμοποιείται ευρέως στα βαθιά

νευρωνικά δίκτυα (DNN) και ο μαθηματικός της τύπος είναι $\sigma(z)_i = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}}$



Σχήμα 10. Συνάρτηση Softmax

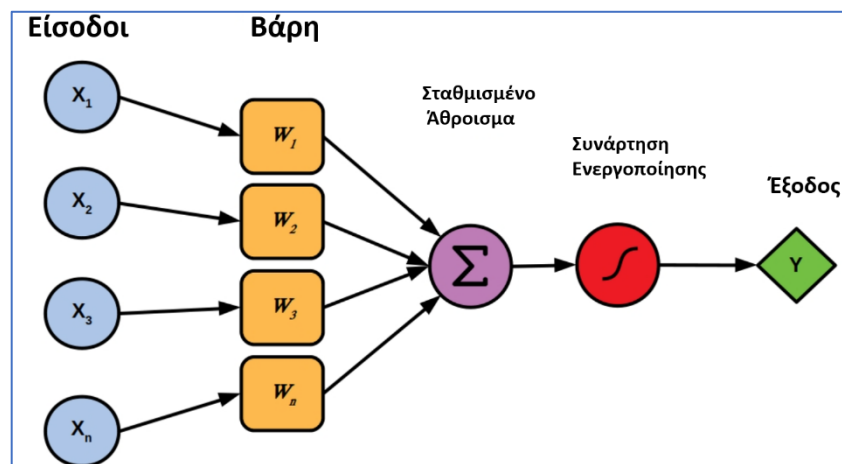
4. 6. 4 Τοπολογίες Νευρωνικών Δικτύων

Στην παράγραφο αυτή θα περιγραφούν οι κυριότερες τοπολογίες των νευρωνικών δικτύων.

4. 6. 4. 1 Νευρωνικό Δίκτυο Perceptron

Το πρώτο Νευρωνικό Δίκτυο αναπτύχθηκε από τον Frank Rosenblatt στα τέλη της δεκαετίας του 1950 (συγκεκριμένα το 1958) και φέρει την ονομασία Perceptron[34]. Στην ουσία πρόκειται για ένα νευρωνικό δίκτυο πρόσθιας

τροφοδότησης το οποίο περιέχει πολλές εισόδους και μία μόνο έξοδο όπως φαίνεται στην Εικόνα 15. Στην σημερινή εποχή όλα τα νευρωνικά δίκτυα τα οποία δεν περιέχουν στη δομή τους κρυφό επίπεδο αποκαλούνται perceptron. Ο συγκεκριμένος τύπος είναι ο πιο απλός και καλείται να αντιμετωπίζει προβλήματα δυαδικής ταξινόμησης γραμμικής φύσεως. Λόγω της αδυναμίας των perceptron να επιλύσουν προβλήματα μη γραμμικής φύσεως αναπτύχθηκαν τα νευρωνικά δίκτυα με κρυφά επίπεδα. Το perceptron όταν εκπαιδεύεται μπορεί να αποδώσει κατάλληλες αριθμητικές τιμές στα βάρη (weights) από τα οποία αποτελείται με σκοπό να δώσει την σωστότερη πρόβλεψη.



Εικόνα 17. Απεικόνιση ενός Τεχνητού Νευρώνα Perceptron

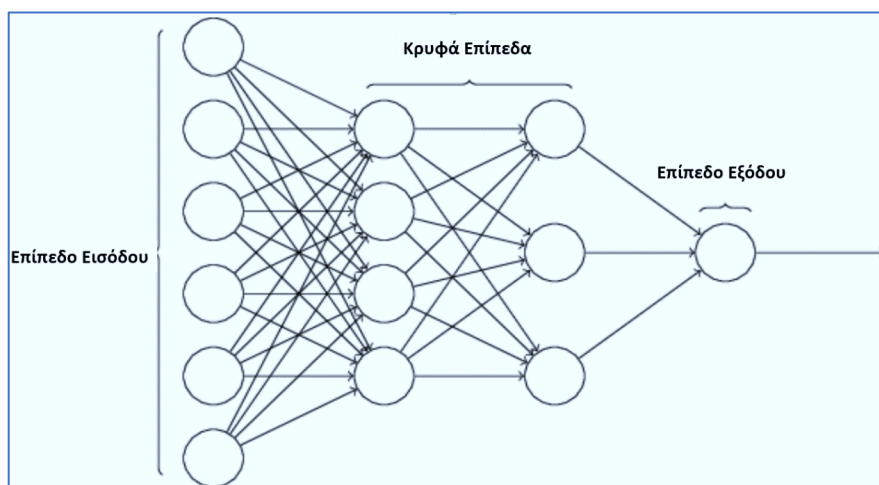
4. 6. 4. 2 Νευρωνικό Δίκτυο Πολλαπλών επιπέδων

Για την επίλυση πιο πολύπλοκων προβλημάτων από εκείνο της δυαδικής ταξινόμησης αναπτύχθηκε ένα perceptron πολλαπλών επιπέδων (Multilayer Perceptron, MLP) το οποίο αποτελείται από πολλαπλά perceptron τα οποία είναι συνδεδεμένα μεταξύ τους[35]. Στη συγκεκριμένη περίπτωση, ο κάθε νευρώνας εισόδου συνδέεται άμεσα με όλους τους νευρώνες που υπάρχουν στο αμέσως επόμενο επίπεδο και η ροή της πληροφορίας έχει κατεύθυνση μόνο ως προς τη μία

πλευρά(προς τα μπροστά ή αλλιώς προς τα δεξιά) όπως φαίνεται στην Εικόνα 18. Στις περισσότερες περιπτώσεις τα perceptron πολλαπλών στρωμάτων αποτελούνται μόνο από τρία επίπεδα (επίπεδο εισόδου, κρυφό επίπεδο και επίπεδο εξόδου) με αποτέλεσμα να ονομάζονται είτε “ρηχά” νευρωνικά δίκτυα(Shallow Neural Networks)[36] είτε “μη βαθιά”(Non-Deep)[37].

Υπάρχουν όμως και περιπτώσεις όπως για παράδειγμα η επίλυση πολύπλοκων προβλημάτων όπου τα Νευρωνικά Δίκτυα περιέχουν παραπάνω από τρία επίπεδα. Τέτοιου τύπου δίκτυα τα οποία περιέχουν τουλάχιστον δύο κρυφά επίπεδα ονομάζονται “βαθιά” νευρωνικά δίκτυα (Deep Neural Networks, DNN)[38]. Ανεξάρτητα με τον αριθμό των επιπέδων που θα αποτελείται το νευρωνικό δίκτυο ο δημιουργός πρέπει να πάρει αποφάσεις σχετικά με τον αριθμό των νευρώνων που θα έχει κάθε επίπεδο, την επιλογή της κατάλληλης συνάρτησης ενεργοποίησης καθώς και την σωστή επιλογή αλγορίθμου ενεργοποίησης.

Ο τρόπος λειτουργίας των MLP δεν διαφέρει σε σημαντικό βαθμό από εκείνον του perceptron αφού δέχεται δεδομένα σαν είσοδο, τα πολλαπλασιάζει με τα βάρη και έπειτα προωθεί την πληροφορία στο επόμενο επίπεδο όπου εφαρμόζεται ακριβώς η ίδια λογική. Παρόλα αυτά η πολυπλοκότητα ενός MLP μπορεί να αυξηθεί εξαιτίας του μεγάλου αριθμού κόμβων που μπορεί να περιέχει το κάθε επίπεδο ή της ύπαρξης πολλαπλών κρυφών επιπέδων. Από την άλλη πλευρά τα συγκεκριμένα χαρακτηριστικά καθιστούν το MLP αρκετά ισχυρό στην επίλυση πολύπλοκων προβλημάτων.



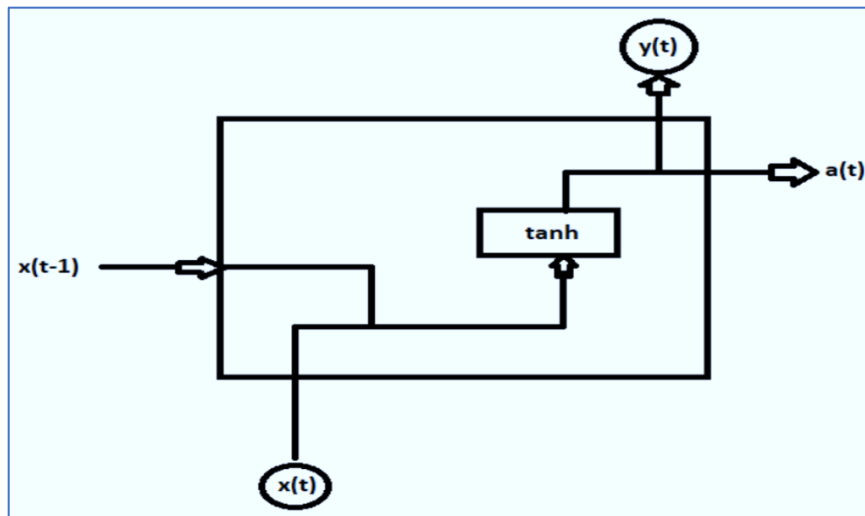
Εικόνα 18. Απεικόνιση ενός Multi-Layer Perceptron με δύο κρυφά επίπεδα

Επιπλέον, εξαιτίας της χρησιμοποίησης συνάρτησης ενεργοποίησης διαφορετικής από τη δυαδική βηματική, όπως για παράδειγμα της πολυχρησιμοποιημένης σιγμοειδούς, καταλήγουμε σε διαφορετικές πραγματικές τιμές στην έξοδο σε σχέση με εκείνες της δυαδικής ταξινόμησης που είναι 0 και 1 ή -1 και 1. Στην περίπτωση των προβλημάτων ταξινόμησης οι παραπάνω τιμές έχουν τη μορφή πιθανότητας υποδηλώνοντας την πιθανότητα οι εκάστοτε είσοδοι να αποτελούν μέρος κάποιας κατηγορίας. Τα MLPs είναι ικανά να δώσουν λύσεις σε προβλήματα ταξινόμησης εισόδων πολλαπλών κατηγοριών και όχι για δύο κατηγορίες μόνο[39].

4. 6. 4. 3 Αναδρομικά Νευρωνικά Δίκτυα

Τα Αναδρομικά Νευρωνικά Δίκτυα (Recurrent Neural Networks, RNN) είναι η απλούστερη μορφή ανδρομικών νευρωνικών δικτύων. Αντίθετα με την αρχιτεκτονική των υπόλοιπων νευρωνικών δικτύων, τα συγκεκριμένα περιέχουν βρόγχους, προκειμένου να διατηρούν τις πληροφορίες κατά την ανατροφοδότηση της εξόδου τους ως είσοδο [40]. Συναντώνται συνήθως σε περιπτώσεις όπου χρησιμοποιούνται διαδοχικά δεδομένα (sequential data) ως είσοδος τα οποία παρουσιάζουν αλληλοσυσχέτιση μεταξύ τους με αποτέλεσμα η ανατροφοδότηση να επιλύει το πρόβλημα.

Το σύνολο των αναδρομικών νευρωνικών δικτύων παρουσιάζει μία αρχιτεκτονική της μορφής μιας αλυσίδας από επαναλαμβανόμενες μονάδες νευρωνικού δικτύου. Στα κλασικά RNN η δομή της μονάδας αυτής είναι αρκετά απλή όπως ένα μονό στρώμα tanh, γεγονός που επιτρέπει στα RNN δίκτυα να δέχονται τα δεδομένα εισόδου τα οποία ενώνονται με τα δεδομένα εξόδου της προηγούμενης μονάδας του δικτύου και τελικώς εισέρχονται στην συνάρτηση ενεργοποίησης tanh. Στη συνέχεια, τα αποτελέσματα της εξόδου της συνάρτησης ενεργοποίησης προωθούνται στην έξοδο της μονάδας του νευρωνικού καθώς και στην είσοδο της επόμενης RNN μονάδας [41].



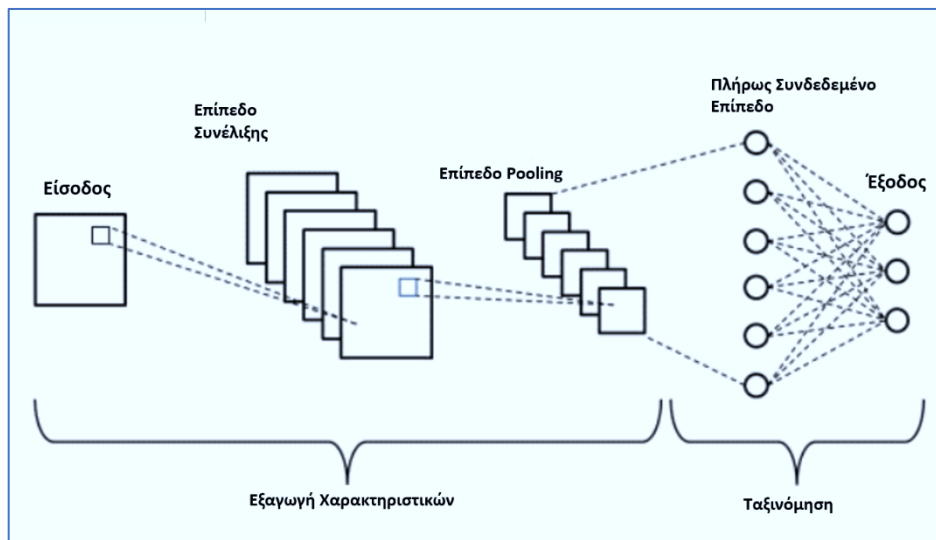
Σχήμα 11. Αρχιτεκτονική μονάδας Αναδρομικού Νευρωνικού Δικτύου RNN

Τα αναδρομικά νευρωνικά δίκτυα είναι η κατάλληλη λύση στο διαχειρισμό προβλημάτων σχετικά με τη πρόβλεψη δεδομένων σε κοντινές χρονικές περιόδους, δηλαδή δεδομένων που παρουσιάζουν μικρή χρονική εξάρτηση όπως παραδείγματος χάριν η πρόβλεψη του επόμενου γράμματος ή της επόμενης λέξης σε μία πρόταση. Ένα μεγάλο πρόβλημα που δεν μπορούν να επιλύσουν τα αναδρομικά νευρωνικά δίκτυα είναι στον τρόπο διαχείρισης των μακροπρόθεσμων (long-term) εξαρτήσεων δεδομένων που η μεταξύ τους απόσταση ανέρχεται σε αρκετά χρονικά βήματα. Για την επίλυση των προβλημάτων αυτών αναπτύχθηκαν τα LSTM(Long Short Term Memory) δίκτυα[42], τα οποία είναι ειδική υποκατηγορία των RNN δικτύων.

4. 6. 4. 4 Συνελικτικά Νευρωνικά Δίκτυα

Τα Συνελικτικά Νευρωνικά Δίκτυα(Convolutional Neural Networks, CNN) ανήκουν στην κατηγορία νευρωνικών δικτύων βαθιάς μηχανικής μάθησης(Deep Learning) και ο λόγος που επινοήθηκαν είναι για τη αναγνώριση προτύπων, εικόνων

βίντεο και την κατηγοριοποίηση τους. Στην επίλυση των συγκεκριμένων προβλημάτων τα CNN υπερτερούν έναντι των άλλων κλασικών μεθόδων[43]. Η ReLU (Rectified Linear Unit) αποτελεί την πιο συχνά χρησιμοποιούμενη συνάρτηση ενεργοποίησης στα CNN και η άνοδός της σχετίζεται με την ταυτόχρονη άνοδο των CNN. Η αρχιτεκτονική των δικτύων αυτών αποτελείται από τρία είδη στρωμάτων, τα συνελκτικά (convolution), το pooling και τα πλήρως συνδεδεμένα στρώματα (fully-connected)[44].



Σχήμα 12. Αρχιτεκτονική Συνελκτικού Νευρωνικού Δικτύου CNN

Για παράδειγμα, οι εικόνες είναι ουσιαστικά ένας πίνακας δύο διαστάσεων όπου το CNN πραγματοποιεί συνέλιξη του πίνακα αυτού χρησιμοποιώντας το φίλτρο Kernel[45] με σκοπό την εξαγωγή των χαρακτηριστικών των εικόνων που έλαβε ως είσοδο. Όσο αναφορά το pooling layer, το CNN μειώνει την ανάλυση της εικόνας και κρατάει μόνο τις απαραίτητες πληροφορίες που χρειάζονται για να καταλήξει σε πρόβλεψη. Στη σημερινή εποχή υπάρχουν πολλές και διαφορετικές αρχιτεκτονικές και αλγόριθμοι εκπαίδευσης των CNN τα οποία παρουσιάζουν μεγάλη πολυπλοκότητα και συνεχιζόμενη εξέλιξη [46].

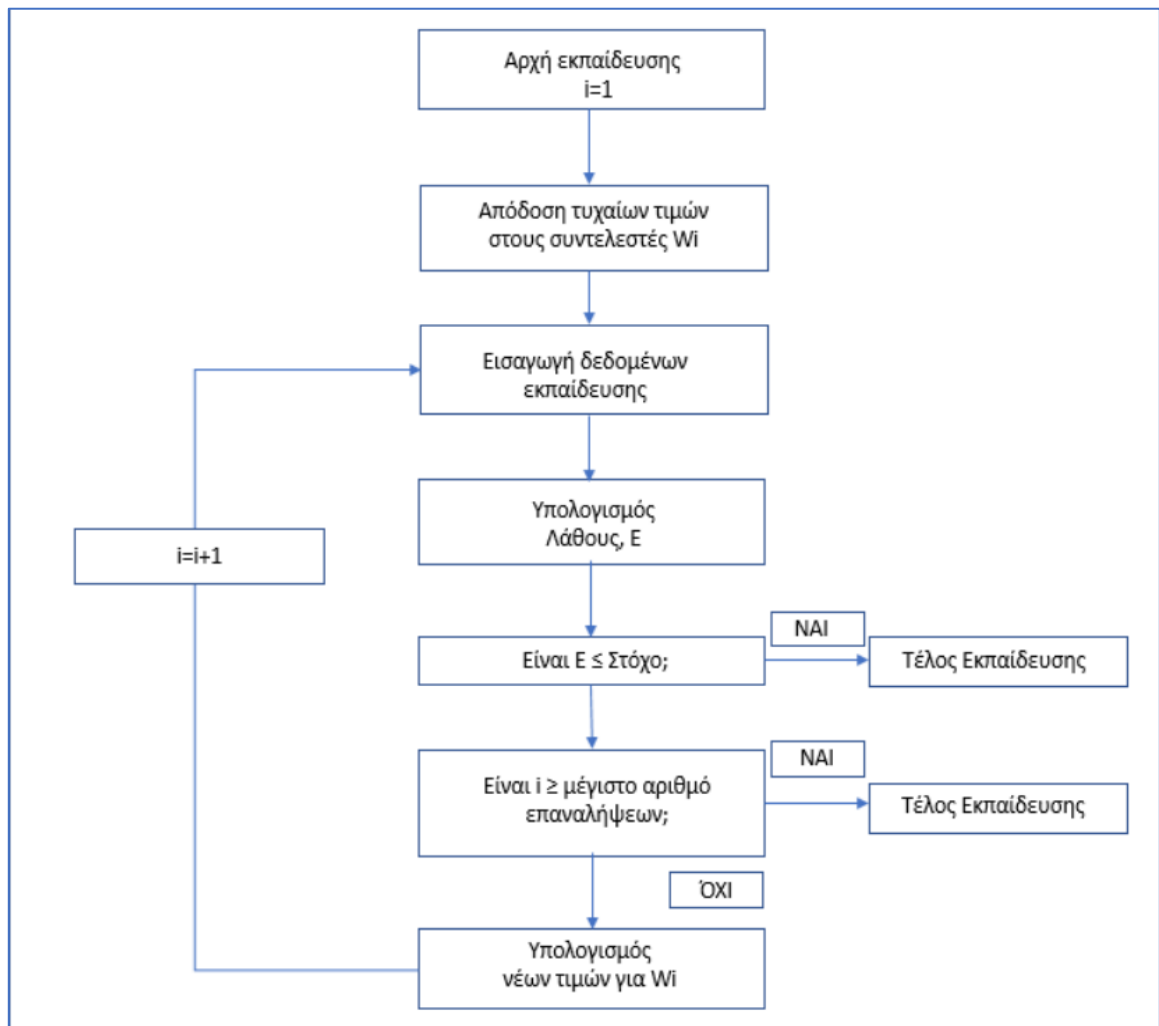
4. 6. 5 Εκπαίδευση Νευρωνικών Δικτύων

Η εκπαίδευση (training) είναι η διαδικασία κατά τη διάρκεια της οποίας το νευρωνικό δίκτυο εκπαιδεύεται μέσω της προσαρμογής των βαρών w_i ώστε να παράγει ένα συγκεκριμένο διάνυσμα εξόδου. Στόχος της συγκεκριμένης διαδικασίας είναι η ικανότητα γενίκευσης, δηλαδή η δυνατότητα του νευρωνικού δικτύου να παράγει σωστές προβλέψεις ως έξοδο για άγνωστα πρότυπα[53]. Οι μέθοδοι εκπαίδευσης που εφαρμόζονται στην εκπαίδευση ενός τεχνητού νευρωνικού επιπέδου μπορούν να διαχωριστούν στην εκπαίδευση με επίβλεψη ή επιτηρούμενη (supervised training), στην εκπαίδευση χωρίς επίβλεψη (unsupervised training) και στην εκπαίδευση με ενίσχυση ή ενισχυμένη (reinforcement training).

Η πιο συνηθισμένη μέθοδος εκπαίδευσης ενός νευρωνικού δικτύου είναι η εκπαίδευση με επίβλεψη. Στη συγκεκριμένη μέθοδο η πληροφορία του σφάλματος περιέχει πεδίο εφαρμογής στην αλλαγή των συντελεστών των συνάψεων, αποστέλλεται προς τα πίσω έχοντας δηλαδή αντίθετη φορά από τη διεύθυνση διάδοσης της διέγερσης(backward-error propagation ή back propagation) [54]. Η σωστή εκπαίδευση του συστήματος χωρίς την απαίτηση επιπρόσθετης εκμάθησης οδηγεί στην σταθεροποίηση των βαρών. Στην εκπαίδευση με επίβλεψη παρέχεται ταυτόχρονα ως είσοδος στο νευρωνικό δίκτυο ένα σύνολο με δεδομένα (data set) καθώς επίσης και τα επιθυμητά αποτελέσματα του συγκεκριμένου προβλήματος που μελετάται. Υπάρχουν πολλές τεχνικές μάθησης που χρησιμοποιούνται κατά τη διάρκεια της εκπαίδευσης με επιτήρηση αλλά η πιο γνωστή είναι ο κανόνας Δέλτα (Delta Rule). Σαν δέλτα θεωρείται η διαφορά μεταξύ της τιμής υπολογισμού του νευρωνικού δικτύου και της πραγματικής τιμής που χρησιμοποιείται για την εκπαίδευσή του, η οποία καλείται ως συνάρτηση συντελεστών w_i [55].

Στην εκπαίδευση χωρίς επίβλεψη το νευρωνικό δίκτυο μετά από έλεγχο αναγνωρίζει τις ομοιότητες στα δεδομένα εισόδου με τα οποία έχει τροφοδοτηθεί και στη συνέχεια τα κατηγοριοποιεί σε ομάδες. Η συγκεκριμένη διαδικασία επαναλαμβάνεται για όσες φορές καθίσταται αναγκαίο μέχρις ότου να μην παρατηρούνται αλλαγές στην ταξινόμηση των δεδομένων [56].

Στην εκπαίδευση με ενίσχυση ή αλλιώς αυτο-επιτηρούμενη (self-training)[57], η εκμάθηση του Τεχνητού Νευρωνικού Δικτύου γίνεται μέσω μιας στρατηγικής ενεργειών που ακολουθεί και μέσα από την αλληλεπίδρασή του με το ίδιο το σύστημα. Τα στάδια που ακολουθούνται για την απόδοση τιμών κατά τη διάρκεια της εκπαίδευσης με επίβλεψη περιγράφονται στο Σχήμα 13.




Σχήμα 13. Διάγραμμα ροής εκμάθησης Τεχνητού Νευρωνικού Δικτύου

Κατά τη διάρκεια της εκπαίδευσης ενός τεχνητού νευρωνικού δικτύου υπάρχει ο κίνδυνος της υπερεκπαίδευσης (overtraining) ή της υποεκπαίδευσης (undertraining). Στην περίπτωση της υπερεκπαίδευσης η ικανότητα της γενίκευσης που παρουσιάζει το ΤΝΔ επηρεάζεται σε αρνητικό βαθμό. Από τη στιγμή που ένα ΤΝΔ θα παρουσιάσει μεγαλύτερη πολυπλοκότητα από την επιθυμητή, το αποτέλεσμα θα είναι να μάθει τη λεπτομέρεια και το θόρυβο των δειγμάτων. Έτσι το

νευρωνικό δίκτυο δεν θα είναι σε θέση να ανταπεξέλθει με επιτυχία στους στόχους της εκπαίδευσης και στη γενίκευση άγνωστων δειγμάτων. Για να αποφευχθεί η υπερεκπαίδευση και να γίνει έλεγχος της γενίκευσης ενός νευρωνικού δικτύου εφαρμόζεται η διαδικασία της πρόωρης διακοπής (early stopping) [58].

Τα δείγματα δεδομένων που χρησιμοποιούνται στην εκπαίδευση χωρίζονται σε δεδομένα εκπαίδευσης (training data), τα οποία χρησιμοποιούνται για την προσαρμογή των βαρών στο νευρωνικό δίκτυο, σε δεδομένα ελέγχου εκπαίδευσης (validation data), τα οποία εξυπηρετούν την αξιολόγηση της γενικευμένης παρουσίας του εκπαιδευόμενου νευρωνικού δικτύου κατά την εισαγωγή νέων δεδομένων και σε δεδομένα ελέγχου γενίκευσης (testing data), τα οποία προσδιορίζουν την κατάλληλη στιγμή τερματισμού της διαδικασίας της εκπαίδευσης.

Πιο συγκεκριμένα, κατά τη διαδικασία της εκπαίδευσης μέσω των δεδομένων εκπαίδευσης υπολογίζεται το σφάλμα (training error). Το εκπαιδευόμενο ΤΝΔ τροφοδοτείται με τα δεδομένα ελέγχου και καταλήγει στο αποτέλεσμα υπολογίζοντας το σφάλμα ελέγχου (testing error). Ο υπολογισμός της βέλτιστης τιμής για την εφαρμογή της πρόωρης διακοπής με σκοπό να αποφευχθεί η υπερεκπαίδευση διακρίνεται στο Σχήμα 14.



Σχήμα 14. Διάγραμμα εύρεσης ιδανικού σημείου εκπαίδευσης για αποφυγή της υπερεκπαίδευσης

Στο Σχήμα 14 παρατηρούμε ότι όσο ο αριθμός των βημάτων εκπαίδευσης αυξάνεται, το σφάλμα εκπαίδευσης μειώνεται ενώ το σφάλμα ελέγχου μειώνεται αρχικά και στη συνέχεια μόλις ξεπεράσει το σημείο της πρόωρης διακοπής ακολουθεί αυξητική πορεία. Ο στόχος της εκπαίδευσης έγκειται στην εύρεση του χαμηλότερου σημείου του σφάλματος ελέγχου στο οποίο σηματοδοτείται ο τερματισμός της εκπαίδευσης ενός νευρωνικού δικτύου.

4.7 Deep learning

Ο όρος βαθιά μάθηση (deep learning) ουσιαστικά αναφέρεται για τα νευρωνικά δίκτυα τα οποία περιέχουν περισσότερα από δύο εσωτερικά κρυφά στρώματα (hidden layers). Στο κοντινό παρελθόν η δυσκολία στην εκπαίδευση τέτοιων μοντέλων είχε να κάνει με το πλήθος των στρωμάτων (layers) όσο ο αριθμός τους αυξανόταν. Η απότομη αύξηση των gradients (exploding gradient)[47] και η εξαφάνιση (vanishing gradient) δημιούργησε μεγάλη πρόκληση σε συνδυασμό με τη μέθοδο gradient descent η οποία χρησιμοποιείται για τον υπολογισμό των παραμέτρων του νευρωνικού δικτύου. Η αντιμετώπιση του προβλήματος της απότομης αύξησης έγινε με ευκολία μέσω τεχνικών όπως του gradient clipping[48] και της L1 ή L2 regularization [49]. Παρόλαυτα, το πρόβλημα της εξαφάνισης (vanishing gradient) λόγω της πολυπλοκότητάς του αποτελούσε για πολλά χρόνια μεγάλη πρόκληση.

Προκειμένου να υπολογίσουν τις διάφορες παραμέτρους, τα νευρωνικά δίκτυα χρησιμοποιούν τον αλγόριθμο backpropagation. Ο αλγόριθμος αυτός αποτελεί έναν αποτελεσματικό αλγόριθμο ο οποίος υπολογίζει τα gradients (κλίσεις) χρησιμοποιώντας τον κανόνα αλυσίδα δηλαδή τον κανόνα υπολογισμού των παραγώγων σύνθετων συναρτήσεων [50]. Σύμφωνα με τον αλγόριθμο gradient descent [51], οι παράμετροι του νευρωνικού δικτύου ενημερώνονται ανάλογα με τη μερική παράγωγο της συνάρτησης κόστους σε σχέση με την τρέχουσα παράμετρο και αυτό συμβαίνει σε κάθε επανάληψη της εκπαίδευσης. Το πρόβλημα στην συγκεκριμένη περίπτωση εντοπίζεται στο γεγονός ότι η κλίση είναι μικρή

(εξαφάνιση) εμποδίζοντας έτσι την αλλαγή των τιμών ορισμένων παραμέτρων με αποτέλεσμα το νευρωνικό δίκτυο να οδηγηθεί σε τερματισμό της εκπαίδευσής του. Έτσι γεννάται το πρόβλημα της εξαφάνισης της κλίσης.

Οι κλασικές συναρτήσεις ενεργοποίησης όπως για παράδειγμα η συνάρτηση της υπερβολικής εφαπτομένης (\tanh) παρουσιάζουν κλίσεις στο διάστημα $(0, 1)$ και ο αλγόριθμος backpropagation υπολογίζει τις κλίσεις εφαρμόζοντας τον κανόνα της αλυσίδας. Αποτελέσματα των παραπάνω είναι ο πολλαπλασιασμός η μικρών αριθμών για τον υπολογισμό των κλίσεων των προηγούμενων επιπέδων (της αριστερής πλευράς) σε ένα νευρωνικό δίκτυο με n επίπεδα με αποτέλεσμα τη εκθετική μείωση της κλίσης ως προς n . Έτσι οδηγούμαστε στην αργή ή και καθόλου εκπαίδευση των προηγούμενων στρωμάτων.

Ωστόσο στη σημερινή εποχή, η συνεχής ανάπτυξη αλγορίθμων μάθησης των νευρωνικών δικτύων έχει οδηγήσει στη δημιουργία αλγορίθμων με τριψήφιο αριθμό επιπέδων. Η συνάρτηση ενεργοποίησης ReLU επηρεάζει σε λιγότερο βαθμό σε σχέση με το πρόβλημα που προκαλεί ο vanishing gradient [52]. Τα LSTM (long short-term memory) νευρωνικά δίκτυα καθώς και οι διάφορες τεχνικές που έχουν δημιουργηθεί όπως τα skip connections που χρησιμοποιούνται στα residual νευρωνικά δίκτυα επιτρέπουν την εκπαίδευση δικτύων χιλιάδων επιπέδων ανοίγοντας το δρόμο στους ευρενητές.

Δεδομένου ότι τα προβλήματα εξαφάνισης και εκτόξευσης της κλίσης έχουν επιλυθεί ως έναν βαθμό, ο όρος Deep Learning αναφέρεται στην εκπαίδευση νευρωνικών δικτύων με τη χρησιμοποίηση αλγορίθμων και μαθηματικών μοντέλων ανεξαρτήτως του βάθους του νευρωνικού δικτύου. Μεγάλος αριθμός προβλημάτων μπορεί να επιλυθεί με νευρωνικά δίκτυα 2 ή 3 επιπέδων.

ΚΕΦΑΛΑΙΟ 5^ο – ΑΝΑΛΥΣΗ ΣΥΣΤΗΜΑΤΩΝ ΜΕ ΜΗΧΑΝΙΚΗ

ΜΑΘΗΣΗ

5. 1 Εισαγωγή

Στη σημερινή εποχή κυριαρχεί η μετατροπή των τηλεπικοινωνιακών δικτύων σε μέσα κίνησης μεγάλου όγκου ετερογενών δεδομένων προερχόμενων είτε από ίχνη του δικτύου κυκλοφορίας, είτε από alarms που συμβαίνουν στο δίκτυο, είτε από διάφορους δείκτες ποιότητας σημάτων, είτε από δεδομένα που προκύπτουν από τη συμπεριφορά των χρηστών. Για την εξαγωγή χρήσιμων πληροφοριών από δεδομένα του ίδιου του δικτύου προκειμένου να ληφθούν αποφάσεις για την ορθή λειτουργία του δικτύου απαιτείται η χρησιμοποίηση προηγμένων μαθηματικών μοντέλων και εργαλείων. Μεταξύ των πολλών μοντέλων και εργαλείων κυριαρχεί η χρήση της Μηχανικής Μάθησης μέσα από την οποία επιτυγχάνεται η σωστότερη ανάλυση των δεδομένων δικτύου, η ταυτοποίησή τους και η διαχείριση των απωλειών[59].

Η εκθετική αύξηση της πολυπλοκότητας των οπτικών δικτύων έχει οδηγήσει στην συχνότερη υιοθέτηση και χρησιμοποίηση τεχνικών μηχανικής μάθησης. Η συγκεκριμένη αύξηση οφείλεται στο γεγονός ότι έχει εισαχθεί τεράστιος αριθμός από ρυθμιζόμενες και αλληλοεξαρτώμενες παραμέτρους συστήματος. Παραδείγματα τέτοιων παραμέτρων είναι η εισαγωγή ρυθμίσεων δρομολόγησης, οι αλλαγές στις μορφές διαμόρφωσης, ο ρυθμός των συμβόλων και τα σχήματα κωδικοποίησης τα οποία ενεργοποιούνται μέσω της χρήσης τεχνολογιών μετάδοσης και λήψης που είναι σύμφωνες μεταξύ τους με σκοπό την εύρυθμη και τεχνολογικά άρτια επεξεργασία του ψηφιακού σήματος με αποτέλεσμα την αντιστάθμιση των μη γραμμικών επιδράσεων όσο αναφορά τη διάδοση του σήματος στο εσωτερικό της οπτικής ίνας.

Απαραίτητο συστατικό στη φυσική υποδομή όλων των δικτύων των μεγάλων παρόχων της παγκόσμιας αγοράς αποτελούν τα οπτικά δίκτυα καθώς παρουσιάζουν υψηλή χωριτικότητα, χαμηλό κόστος και άλλες σημαντικές ιδιότητες[60]. Η διεξόδυσή τους σε σημαντικές αγορές όπως τα DataCom (Data Communications)

υποδηλώνει τη εγκαθίδρυση μιας τεχνολογίας που δεν θα υποκατασταθεί στο άμεσο μέλλον. Έχουν γίνει πολλές μελέτες και έχουν εξεταστεί πολλές προσεγγίσεις προκειμένου να βελτιωθεί η απόδοση των οπτικών δικτύων όπως για παράδειγμα η δρομολόγηση, η εκχώρηση του σωστού μήκους κύματος, η διαχείριση της κυκλοφορίας στο δίκτυο και η επιβιωσιμότητα[61][62].

5. 2 Προκλήσεις μηχανικής μάθησης σε δίκτυα οπτικών ινών

Η εφαρμογή τεχνικών μηχανικής μάθησης έχει προσελκύσει τα τελευταία χρόνια το ενδιαφέρον της επιστημονικής και ερευνητικής κοινότητας στο χώρο των οπτικών τηλεπικοινωνιών και δικτύων. Οι λόγοι που οδήγησαν στο ενδιαφέρον αυτό είναι η αυξημένη πολυπλοκότητα που παρουσιάζουν τα σημερινά συστήματα οπτικών ινών καθώς και η μεγάλη διαθεσιμότητα δεδομένων που συνεχώς αυξάνεται.

Η διαρκής αύξηση της πολυπλοκότητας των συστημάτων οπτικών ινών οφείλεται στην ανάπτυξη και υιοθέτηση εξελιγμένων τεχνικών μετάδοσης [84] καθώς και στην εισαγωγή ευέλικτων και καινοτόμων τεχνικών δικτύωσης (ελαστικά οπτικά δίκτυα). Τα παραπάνω έχουν οδηγήσει στη δημιουργία υψηλής πολυπλοκότητας όσον αφορά το σχεδιασμό και τη λειτουργία των οπτικών δικτύων εξαιτίας του υψηλού πλήθους ρυθμιζόμενων παραμέτρων που παρουσιάζουν βαρύνουσα σημασία (όπως για παράδειγμα οι διάφορες μορφές διαμόρφωσης, οι ρυθμοί των συμβόλων, οι προσαρμοστικοί ρυθμοί όσο αναφορά τη κωδικοποίηση και τέλος το προσαρμοστικό εύρος ζώνης των καναλιών). Στη συγκεκριμένη περίπτωση, η ακριβής μοντελοποίηση του συστήματος είναι συχνά πολύ δύσκολη και σε πολλές περιπτώσεις ακατόρθωτη. Τα αναλυτικά μοντέλα ως επί των πλείστων υιοθετούν περιθώρια (margins), τα οποία οδηγούν σε μία κατάσταση υποχρησιμοποίησης του συστήματος έχοντας πλήθος δεσμευμένων πόρων και συνεπώς αυξημένο κόστος. Αντιθέτως, η χρησιμοποίηση τεχνικών μηχανικής μάθησης οδηγεί στην καταγραφή των σύνθετων και κατ'επέκταση μη γραμμικών συμπεριφορών του συστήματος. Έτσι η δημιουργία εκπαιδευμένων μοντέλων

χρησιμοποιώντας τεχνικές μηχανικής μάθησης με επίβλεψη, των οποίων η εκπαίδευση έχει επέλθει από προηγούμενες καταγραφές δεδομένων του δικτύου έχει ως στόχο να επιλύσει προβλήματα σε πολλαπλά επίπεδα, ιδιαίτερα του κλάδου των οπτικών δικτύων.

Η αυξημένη διαθεσιμότητα που υπάρχει σε δεδομένα οφείλεται στο γεγονός ότι τα οπτικά δίκτυα της σύγχρονης εποχής είναι εξοπλισμένα με πλήθος συσκευών παρακολούθησης του δικτύου, ικανές για την αδιάλειπτη παροχή πληροφοριών για ολόκληρο το δίκτυο. Τέτοιες πληροφορίες μπορεί να είναι τα ίχνη κίνησης (traffic traces), οι δείκτες ποιότητας σήματος (BER- bit error rate), τα alarms απωλειών του συστήματος και η συμπεριφορά των χρηστών του συστήματος. Σε τέτοιες περιπτώσεις, το πλεονέκτημα της ανάπτυξης και χρησιμοποίησης τεχνικών μηχανικής μάθησης οφείλεται στην αξιοποίηση του πλήθους δεδομένων που έχουν συλλεχθεί μέσω της παράλληλης μελέτης εξαρτήσεων μεταξύ των διαφορετικών ειδών δεδομένων.

5.3 Εφαρμογές μηχανικής μάθησης σε φυσικό επίπεδο

Η χρησιμοποίηση της μηχανικής μάθησης σε φυσικό επίπεδο έχει ως σκοπό την αντιμετώπιση των μη γραμμικών φαινομένων στις οπτικές ίνες, τα οποία οδηγούν τα μοντέλα στην παραγωγή ανακριβών αποτελεσμάτων ή μερικές φορές και στην αύξηση της πολυπλοκότητας. Δημιουργούνται έτσι πολλές επιπτώσεις από τα φαινόμενα αυτά σε περιπτώσεις όπως η πρόβλεψη της απόδοσης των οπτικών δικτύων σχετικά με το BER, ο παράγοντας ποιότητας (Q-factor) καθώς επίσης και η αποδιαμόρφωση που υφίσταται το σήμα [85].

Επομένως οδηγούμαστε στο σημείο όπου αρκετές προκλήσεις πρέπει να αντιμετωπιστούν στο φυσικό επίπεδο των οπτικών δικτύων προκειμένου να εκτιμηθεί με τον σωστό τρόπο η απόδοση του συστήματος μετάδοσης καθώς και κατά πόσο επηρεάζονται τα οπτικά κανάλια στην περίπτωση της υποβάθμισης του σήματος κατά την μετάδοση. Τα αποτελέσματα των παραπάνω διαδικασιών μπορούν να αποτελέσουν τη βάση για την εφαρμογή άλλων προληπτικών

διαδικασιών, όπως για παράδειγμα η ρύθμιση της παροχής ισχύος, ο έλεγχος των κερδών των οπτικών ενισχυτών καθώς επίσης και οι διαφορετικές μορφές διαμόρφωσης, προτού γίνει η υποβάθμιση του σήματος.

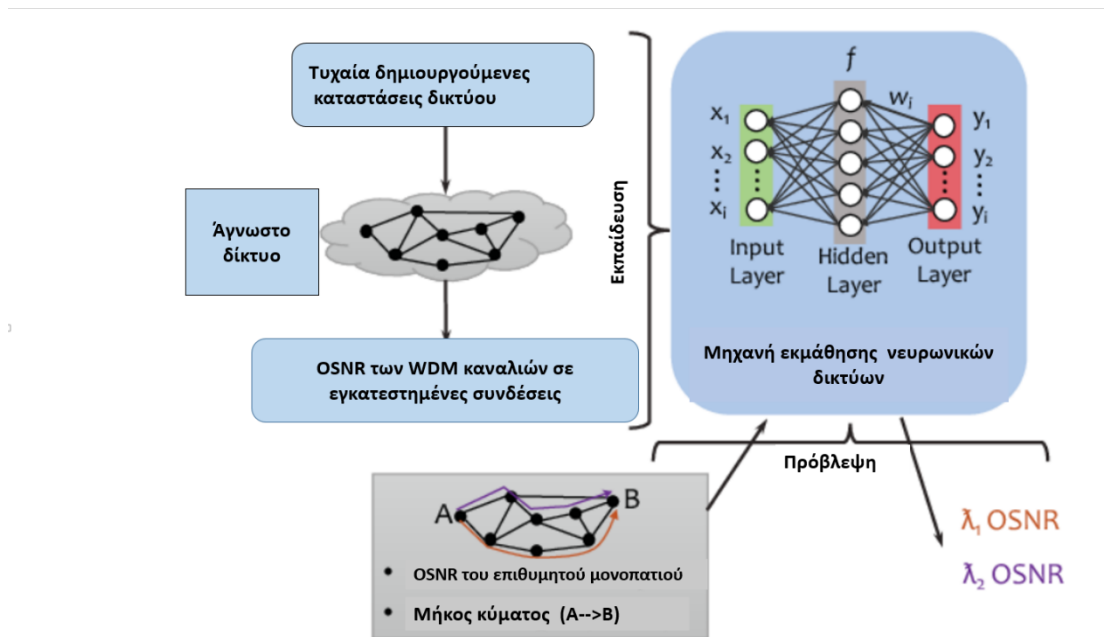
5. 3. 1 Εκτίμηση Ποιότητας Μετάδοσης

Μία από τις πιο σημαντικές εφαρμογές της μηχανικής μάθησης στο επίπεδο του φυσικού δικτύου είναι στην Εκτίμηση Ποιότητας Μετάδοσης (Quality of Transmission, QoT). Προκειμένου να αναπτυχθεί ένα νέο οπτικό μονοπάτι απαιτείται να εκτιμηθεί η ποιότητα της μετάδοσης (QoT) του μονοπατιού, καθώς επίσης και των ήδη υπαρχόντων. Ο όρος της ποιότητας μετάδοσης γενικά ορίζεται ως ένας αριθμός παραμέτρων που υπάρχουν στο φυσικό επίπεδο. Τέτοιου είδους παράμετροι είναι ο λαμβάνων οπτικός σηματο-θορυβικός λόγος (Optical Signal to Noise Ratio – OSNR), ο ρυθμός των λανθασμένων συμβόλων (bit error rate – BER) και ο παράγοντας Q (Q-factor), οι οποίες επηρεάζουν σημαντικά την «αναγνωσιμότητα» του οπτικού σήματος στον δέκτη και προσδίδουν ένα ποσοτικό μέτρο για τον έλεγχο της εγκυρότητας ενός προκαθορισμένου επιπέδου QoT[88]. Οι συγκεκριμένοι παράμετροι επηρεάζονται κάθε φορά από διάφορες άλλες παραμέτρους σχεδιασμού, όπως για παράδειγμα η μορφή διαμόρφωσης, ο ρυθμός μετάδοσης συμβόλων (baud rate), ο ρυθμός κωδικοποίησης καθώς και από τα φυσικά μονοπάτια του δικτύου. Όπως γίνεται εύκολα αντιληπτό, η βελτιστοποίηση της ποιότητας μετάδοσης εξαρτάται από τη ρύθμιση όλων των παραπάνω παραμέτρων καθώς και από την εύρεση του βέλτιστου συνδυασμού τους.

Οι προμελετημένες τεχνικές εκτίμησης της ποιότητας μετάδοσης μοιράζονται σε δύο κατηγορίες, στα μοντέλα ακριβής ανάλυσης, τα οποία οδηγούν σε αρκετά ακριβή αποτελέσματα όσο αναφορά τις αστοχίες που δημιουργούνται στο φυσικό επίπεδο απαιτώντας όμως αρκετή υπολογιστική ισχύ, και στις διακριτές μεθόδους (marginated formulas) οι οποίες ναι μεν υπολογιστικά είναι πιο γρήγορες και αποτελεσματικές αλλά έχουν ένα σημαντικό μειονέκτημα καθώς εισάγουν διαλείψεις στη μετάδοση με αποτέλεσμα να οδηγούν στην υποχρησιμοποίηση του

δικτύου. Επιπλέον, μια σημαντική παρατήρηση είναι ότι η δημιουργία αναλυτικών μοντέλων με μεγάλο κόστος είναι μία αρκετά απαιτητική διαδικασία λόγω της πολυπλοκότητας των αλληλεπιδράσεων των πολλών παραμέτρων του συστήματος (όσο αναφορά την ισχύ του σήματος που λαμβάνεται ως είσοδος, το πλήθος των καναλιών του δικτύου, ο τύπος των συνδέσμων, ο ρυθμός των συμβόλων) και εξαιτίας της μη γραμμικότητας που παρουσιάζει η μετάδοση του σήματος μέσω των οπτικών καναλιών.

Μια τεχνική μηχανικής μάθησης που μπορεί να δώσει λύση στο πρόβλημα είναι η χρήση ταξινομητών (classifiers), οι οποίοι εκπαιδεύονται μέσω της μάθησης με επίβλεψη, ώστε να δημιουργηθεί μια άμεση σχέση εισόδου-εξόδου μεταξύ του δείκτη QoT που υπάρχει στο δέκτη και στην αντίστοιχη διαδικασία διαμόρφωσης του οπτικού μονοπατιού, σχετικά με τη χρησιμοποιούμενη μορφή διαμόρφωσης, το ρυθμό baud και της φυσικής διαδρομής του δικτύου.



Εικόνα 19. Προσέγγιση για την εκτίμηση του OSNR των WDM μικών κύματος

5. 3. 2 Έλεγχος οπτικών ενισχυτών

Στα σημερινά οπτικά δίκτυα, εξαιτίας της εμφάνισης καινούργιων υπηρεσιών οι οποίες απαιτούν την εφαρμογή τεράστιου εύρους ζώνης για περιορισμένες χρονικές περιόδους, η ανάθεση και η παραμετροποίηση των οπτικών μονοπατιών γίνεται με δυναμικό τρόπο. Η δυναμική ρύθμιση σε συνδυασμό με την κατάργηση των οπτικών καναλιών με διαφορετικά μήκη κύματος οδηγεί στην επαναρύθμιση των δικτύων προκειμένου να διατηρηθεί η σταθερότητα των δικτύων στο φυσικό επίπεδο. Λύση στη γρήγορη αλλαγή της εγκατάστασης των οπτικών μονοπατιών έρχονται να δώσουν οι Erbium-Doped Fiber Amplifiers (EDFAs), οι οποίοι παρουσιάζουν κενά ισχύος εξαρτώμενα από το μήκος κύματος[86]. Πιο συγκεκριμένα, κατά την εγκατάσταση ενός νέου οπτικού μονοπατιού ή γίνεται κατάργηση ενός ήδη εγκατεστημένου. Αυτό οδηγεί στη δημιουργία απόκλισης μεταξύ των επιπέδων ισχύος του σήματος ανάμεσα στα διαφορετικά κανάλια (δηλαδή μεταξύ των καναλιών που λειτουργούν σε διαφορετικό μήκος κύματος), η οποία εξαρτάται από το συγκεκριμένο μήκος κύματος που προστίθεται ή καταργείται στο σύστημα. Έτσι, απαιτείται η εφαρμογή ενός αυτόματου ελέγχου μεταξύ των επιπέδων ισχύος του σήματος προενίσχυσης προκειμένου να αποφευχθεί η υπερβολική απόκλιση ισχύος που υπάρχει μεταξύ των οπτικών μονοπατιών, η οποία οδηγεί πολλές φορές σε παραμόρφωση του σήματος [87]. Στη συγκεκριμένη κατάσταση, η εφαρμογή τεχνικών μηχανικής μάθησης κρίνεται αναγκαία. Εξαιτίας της μεγάλης διαθεσιμότητας σε δεδομένα, τα οποία καταγράφονται και ανακτώνται μέσω της παρακολούθησης του δικτύου, μπορεί να εκπαιδευτεί μία κατηγορία regression αλγορίθμων για να προβλέψουν με ακρίβεια τα κενά ισχύος τα οποία καθίστανται ως απόκριση στην προσθήκη και τον τερματισμό του εκάστοτε μήκους κύματος.

5. 3. 3 Αναγνώριση σχήματος διαμόρφωσης

Στη σημερινή εποχή, οι εξελιγμένοι οπτικοί πομποί και δέκτες προσδίδουν τεράστια ευελιξία όσο αναφορά το χρησιμοποιούμενο εύρος ζώνης, τη συχνότητα του φέροντος σήματος αλλά και τη μορφή διαμόρφωσης. Έτσι καταλήγουμε στην επιτυχημένη προσαρμογή της μετάδοσης του απαιτούμενου ρυθμού μετάδοσης και οπτικής εμβέλειας ενός περιβάλλοντος δικτύου το οποίο χαρακτηρίζεται από ευελιξία και ελαστικότητα. Δεδομένου ότι η φάση της μετάδοσης ορίζεται από μια αυθαίρετη σύμφωνη οπτική μορφή μετάδοσης, η προηγούμενη γνώση της απόφασης από την πλευρά του δέκτη δεν είναι πάντα εφικτή. Επομένως, μπορεί να επηρεαστεί η μετάδοση του σήματος, με αποτέλεσμα να επηρεαστεί η επεξεργασία και η ανίχνευση του. Η χρήση αλγορίθμων μάθησης με επίβλεψη οδηγεί στην ενίσχυση της αναγνώρισης της μορφής διαμόρφωσης (Modulation format recognition - MFR) από την πλευρά του δέκτη, εξαιτίας της δυνατότητας που διαθέτουν στην εκμάθηση της τοπολογίας μεταξύ της επιλεγμένης μορφής διαμόρφωσης και του εισερχόμενου οπτικού σήματος.

5. 3. 4 Εξομάλυνση μη γραμμικότητας

Η συμπεριφορά ορισμένων παραμέτρων απόδοσης όπως του BER, του Q-factor και της χρωματικής διασποράς (Chromatic Dispersion – CD) είναι αρκετά απρόβλεπτη λόγω της παρουσίας μη γραμμικών φαινομένων στις οπτικές ίνες όπως για παράδειγμα το φαινόμενο Kerr. Η συγκεκριμένη συμπεριφορά ενδεχομένως προκαλεί παραμόρφωση του σήματος στην πλευρά του δέκτη. Προκειμένου να αντιμετωπιστεί το εν λόγω πρόβλημα υιοθετούνται συχνά πολύπλοκα μοντέλα αναλύσεων με σκοπό την αντίστροφη λειτουργία όσο αναφορά την υποβάθμιση του σήματος ή την αντιστάθμιση της επίδρασης των μη γραμμικών φαινομένων.

Μία εναλλακτική λύση στην αντιμετώπιση του προβλήματος είναι η δημιουργία και εκπαίδευση μοντέλων μηχανικής μάθησης με επίβλεψη, ικανών να εντοπίσουν τα μη γραμμικά φαινόμενα χρησιμοποιώντας και αξιοποιώντας τη γνώση

από τα δεδομένα που έχουν ανακτηθεί από το δίκτυο με τελικό σκοπό τη δημιουργία σχέσεων μεταξύ εισόδου και εξόδου λαμβάνοντας υπόψιν τις παραμέτρους που εξετάζονται και των επιθυμητών εξόδων.

5.3.5 Παρακολούθηση αποδοτικότητας οπτικού επιπέδου

Στα σημερινά οπτικά δίκτυα επικοινωνίας, οι απαιτήσεις για χωρητικότητα συνεχώς αυξάνονται με αποτέλεσμα η παρακολούθηση του δικτύου στο οπτικό επίπεδο να είναι ζωτικής σημασίας για ένα ισχυρό και αξιόπιστο δίκτυο. Η παρακολούθηση της οπτικής απόδοσης έχει ως στόχο να εκτιμηθούν οι παράμετροι που καθορίζουν την μετάδοση του συστήματος (όπως το BER, ο Q-factor και η CD) κατά τη διάρκεια της κυκλικής λειτουργίας των οπτικών μονοπατιών. Η εμπειριστατωμένη γνώση των παραπάνω παραμέτρων αξιοποιείται για πολλές και διαφορετικές διαδικασίες. Μερικές από αυτές είναι η ενεργοποίηση μονάδων του αντισταθμιστή πόλωσης, η ρύθμιση της παροχής ισχύος, η μεταβολή της υιοθετούμενης μορφής διαμόρφωσης καθώς και η αλλαγή των διαδρομών των οπτικών καναλιών.

Στην περίπτωση που οι παράμετροι της οπτικής απόδοσης συλλέγονται από διαφορετικά σημεία «παρακολούθησης» κατά μήκος του οπτικού μονοπατιού οδηγούμαστε στην απαίτηση αυξημένου όγκου μονάδων καταγραφής με αποτέλεσμα να αυξάνεται το κόστος της υποδομής[89]. Για την μείωση του όγκου των μονάδων καταγραφής κατά μήκος της υποδομής του δικτύου, ειδικά στην περίπτωση ενδιάμεσων σημείων του δικτύου και κατ' επέκταση για τη μείωση του κόστους της υποδομής, κρίνεται αναγκαίο να αναπτυχθούν και να εφαρμοστούν αλγόριθμοι μηχανικής μάθησης με επίβλεψη. Οι συγκεκριμένοι αλγόριθμοι εκπαιδεύονται ώστε να χαρτογραφήσουν τις παραμέτρους του οπτικού καναλιού καθώς και των ιδιοτήτων σήματος που λαμβάνει ο δέκτης, τα οποία ανακτώνται από δεδομένα όπως για παράδειγμα τα στατιστικά που λαμβάνονται από διαγράμματα ισχύος, το πλάτος του σήματος και το OSNR.

Παράδειγμα εφαρμογής	Κατηγορία μηχανικής μάθησης	Μεθοδολογία μηχανικής μάθησης	Δεδομένα εισόδου	Δεδομένα εξόδου	Δεδομένα εκπαίδευσης	
Εκτίμηση ποιότητας μετάδοσης (QoT estimation)	επιβλεπόμενη (supervised)	Kriging,L2-ελαχιστοποίηση του κανόνα	OSNR(ιστορικά δεδομένα)	OSNR	συνθετικά	
			OSNR/Q-factor	BER	συνθετικά	
			OSNR/PMD/CD/SPM	blocking prob	συνθετικά	
			case-based reasoning (CBR)	διανυσματικό μέγεθος σφάλματος,OSNR	Q-factor	πραγματικά
				διαδρομή του φωτεινού μονοπατιού,μήκος, αριθμός ταυτόχρονα πολλαπλασιαζόμενων φωτεινών μονοπατιών	Q-factor	συνθετικά
			RF	πορεία του φωτεινού μονοπατιού,μήκος,MF,όγκος κίνησης	BER	συνθετικά
			οπισθοδρόμηση (regression)	SNR(ιστορικά δεδομένα)	SNR	συνθετικά
			NN	διαδρομή του φωτεινού μονοπατιού και μήκος, αριθμός διασχισμένων EDFAs,βαθμός προορισμού, χρησιμοποιημένο μήκος κύματος καναλιού	Q-factor	συνθετικά
			k- κοντινότερων γειτόνων, RF,SVM	συνολικό μήκος συνδέσμου,μήκος ανοίγματος, ισχύς εκκίνησης καναλιού,ρυθμός MF και δεδομένων	BER	συνθετικά
			NN	φορτώσεις καναλιών και ρυθμίσεις ισχύος εκκίνησης	Q-factor	πραγματικά
	NN	κόμβοι πηγής-προορισμού,απασχόληση συνδέσμου,MF, μήκος μονοπατιού,ρυθμός δεδομένων	BER	πραγματικά		
Οπτικοί Ενισχυτές (OPM)	επιβλεπόμενη (supervised)	NN	διάγραμμα οφθαλμού και παράμετρος πλάτους διαγράμματος	OSNR/PMD/CD	πραγματικά	
		NN,SVM	ασύγχρονο ιστόγραμμα πλάτους	MF	πραγματικά	
		NN	ασύγχρονο διάγραμμα σχηματισμού και παράμετρος πλάτους διαγράμματος	OSNR/PMD/CD	συνθετικά	
		Παλινδρόμηση κορυφογραμμής με βάση τον πυρήνα	διάγραμμα οφθαλμού και πορτραίτα φάσης	PMD/CD	πραγματικά	
		NN	οριζόντια και κάθετα πολωμένα I/O δείγματα από ADC	OSNR, MF, Ρυθμός Συμβόλων	πραγματικά	
		Gaussian processes	δεδομένα παρακολούθησης (OSNR vs λ)	Q-factor	πραγματικά	

Έλεγχος οπτικών ενισχυτών (OPM control)	επιβλεπόμενη (supervised)	case-based reasoning (CBR)	ισχύς παραμέτρου μάσκας(NF,GF)	OSNR	πραγματικά
		NNs, παλινδρόμηση κορυφογραμμής,	ισχύς εισόδου/εξόδου EDFA	σημείο λειτουργίας EDFA	πραγματικά
		παλινδρόμηση Bayes με βάση τον πυρήνα	χρήση καναλιού WDM	ασυμφωνία ισχύος μετά το EDFA	πραγματικά
	μη-επιβλεπόμενη (unsupervised)	Εξελικτικός αλγόριθμος	ισχύς εισόδου/εξόδου EDFA	σημείο λειτουργίας EDFA	πραγματικά
Αναγνώριση μορφής διαμόρφωσης (Modulation Format Recognition)	μη-επιβλεπόμενη (unsupervised)	6 αλγόριθμοι ομαδοποίησης	παράμετρος χώρου stokes	MF	συνθετικά
		k-Means	λαμβανόμενα σύμβολα	MF	πραγματικά
	μη-επιβλεπόμενη (unsupervised)	NN	ασύγχρονο ιστόγραμμα πλάτους	MF	συνθετικά
		NN, SVM	ασύγχρονο ιστόγραμμα πλάτους	MF	πραγματικά
		Μεταβλητές τεχνικών Bayes για GMM	παράμετρος χώρου stokes	MF	πραγματικά
Μετριασμός μη γραμμικότητας (Nonlinearity Mitigation)	επιβλεπόμενη (supervised)	Φιλτράρισμα Bayes, NNs, EM	λαμβανόμενα σύμβολα	OSNR, ποσοστό σφάλματος συμβόλων	πραγματικά
		ELM	λαμβανόμενα σύμβολα	αυτοφασική διαμόρφωση	συνθετικά
		k-κοντινότεροι γείτονες	λαμβανόμενα σύμβολα	BER	πραγματικά
		SVM βασισμένο σε Newton	λαμβανόμενα σύμβολα	Q-factor	πραγματικά
		Δυαδικό SVM	λαμβανόμενα σύμβολα	όρια απόφασης συμβόλων	συνθετικά
		NN	λαμβανόμενα σύμβολα υποφορέα	Q-factor	συνθετικά
		GMM	μετα-εξισορροπημένα σύμβολα	αποκωδικοποιεί μενόμενα σύμβολα με εκτιμώμενη ή/και μετριασμένη απομείωση	πραγματικά
		Ομαδοποίηση	λαμβανόμενος αστερισμός με μη-γραμμικότητες	μη γραμμικότητα σημείων αστερισμού	πραγματικά
		NN	δειγματοληψία ακολουθιών ληφθέντων σημάτων	ισοσταθμισμένο σήμα με μειωμένο ISI	πραγματικά
	μη-επιβλεπόμενη (unsupervised)	k-Means	λαμβανόμενος αστερισμός	χωρικά σημεία αστερισμών με βάση την πυκνότητα και τα οπτικά κεντροειδή τους	πραγματικά

Πίνακας 1. Περιπτώσεις χρήσης στο φυσικό επίπεδο και τα χαρακτηριστικά τους

5. 4 Εφαρμογές μηχανικής μάθησης σε επίπεδο δικτύου

Όσο αναφορά το επίπεδο δικτύου παρατηρούμε την ύπαρξη των ίδιων προκλήσεων στην εφαρμογή μεθόδων της μηχανικής μάθησης. Πιο συγκεκριμένα, παρατηρείται μία διαρκής εξέλιξη στο σχεδιασμό και τη διαχείριση των οπτικών δικτύων λόγω της τεράστιας αύξησης των αναγκών για μεταφερόμενη κίνηση και για δραστικές αλλαγές στις απαιτήσεις κυκλοφορίας σχετικά με τη χωρητικότητα, την καθυστέρηση, την εμπειρία του χρήστη και την ποιότητα της προσφερόμενης υπηρεσίας (Quality of Service - QoS). Έτσι, τα σύγχρονα οπτικά δίκτυα αναμένεται να λειτουργούν στο μέλλον με πολύ μεγαλύτερη αξιοποίηση των παραμέτρων τους σε σχέση με το παρελθόν, καθώς η παροχή εγγυήσεων για την ποιότητα της παρεχόμενης υπηρεσίας έχει γίνει αυστηρότερη. Για την επίτευξη του συγκεκριμένου στόχου επιβάλλεται η ανάπτυξη και εφαρμογή συγκεκριμένων τεχνικών διαχείρισης κίνησης και βελτιστοποίησης, οι οποίες ενδεχομένως να αντιμετωπίσουν ζητήματα επεκτασιμότητας και μη αποδεκτής υπολογιστικής πολυπλοκότητας.

Έτσι, η μηχανική μάθηση θεωρείται ως μία πολλά υποσχόμενη μεθοδολογική προσέγγιση των ζητημάτων αυτών, καθώς υποστηρίζει την αυτό-διαμόρφωση του δικτύου και την άμεση λήψη αποφάσεων αξιοποιώντας την πληθώρα που υπάρχει σε διαθέσιμα δεδομένα του δικτύου. Αυτό έχει σαν αποτέλεσμα να δημιουργούνται μοντέλα για πιο ακριβή και βέλτιστη τροφοδοσία καθώς και καλύτερη διαχείριση του δικτύου. Για παράδειγμα, η παροχή καινούργιων οπτικών μονοπατιών ή η μη αποκατάσταση των ήδη υπάρχοντων έπειτα από μία απώλεια στο δίκτυο απαιτούν περίπλοκες και ταχύτερες αποφάσεις οι οποίες εξαρτώνται από διαφορετικά και διαρκώς αναπτυσσόμενα δεδομένα.

5. 4. 1 Πρόβλεψη κίνησης

Μία περίπτωση χρήσης εφαρμογών μηχανικής μάθησης στο επίπεδο δικτύου των οπτικών δικτύων σχετίζεται με την ακριβή επίβλεψη της κίνησης όσο αναφορά το πεδίο του χωροχρόνου αποσκοπώντας στον επιτυχημένο σχεδιασμό και διαχείριση των υφιστάμενων δικτύων[90]. Πιο συγκεκριμένα, στη φάση του σχεδιασμού η πρόβλεψη της κίνησης μειώνει την υπερτροφοδοσία του δικτύου με πόρους που δεν θα χρησιμοποιηθούν. Η αξιοποίηση των πόρων μπορεί να βελτιστοποιηθεί μέσω εφαρμογών τεχνικών κίνησης, οι οποίες χρησιμοποιούν πραγματικά δεδομένα με αποτέλεσμα την επαναδρομολόγηση της υπάρχουσας κίνησης εξοικονομώντας έτσι πόρους για μελλοντικές ανάγκες.

Η εκπαίδευση αλγορίθμων μηχανικής μάθησης με επίβλεψη έχει σημαντική εφαρμογή στη συγκεκριμένη περίπτωση καθώς επιτρέπει την εκμετάλλευση των δεδομένων που έχουν συλλεχθεί και αφορούν τα μοτίβα της κίνησης καθώς και τη συμπεριφορά των χρηστών με απώτερο σκοπό το σχεδιασμό μοντέλων για την πρόβλεψη της μελλοντικής κίνησης και των απαιτήσεων της διαχείρισης πόρων. Έτσι επιτυγχάνεται η προληπτική επανδρομολόγηση της κίνησης καθώς και η τακτική επαναβελτιστοποίηση του δικτύου με σκοπό την καλύτερη εξυπηρέτηση της κίνησης του δικτύου με ταυτόχρονη μείωση στη χρήση των πόρων.

Επιπλέον, στη συγκεκριμένη περίπτωση μπορεί να χρησιμοποιηθούν και αλγόριθμοι μηχανικής μάθησης χωρίς επίβλεψη, οι οποίοι θα εξάγουν μοτίβα κίνησης σε διαφορετικά σημεία του δικτύου. Έτσι, οδηγούμαστε στην ανάπτυξη παρόμοιων διαδικασιών σχεδιασμού και διαχείρισης πόρων όπως για παράδειγμα η εγκατάσταση δικτύου καθώς και η δέσμευση χωρητικότητας σε διαφορετικά σημεία του δικτύου με σκοπό τον εντοπισμό ομοιοτήτων των απαιτήσεων της κίνησης. Αυτό θα έχει σαν αποτέλεσμα όλες οι διαδικασίες να ανήκουν στο ίδιο cluster προφίλ κίνησης.

Σημαντική επισήμανση αποτελεί το γεγονός ότι η πρόβλεψη της κίνησης καθώς και των τεχνικών μηχανικής μάθησης που χρησιμοποιούνται διαφέρουν σημαντικά ανάλογα με το τμήμα του δικτύου που εξετάζεται κάθε φορά. Αναλυτικότερα, όσο αναφορά τα εσωτερικά δίκτυα των κέντρων δεδομένων

ακολουθούνται διαφορετικές τεχνικές σε σχέση με τις τεχνικές που εφαρμόζονται στα δίκτυα πρόσβασης εξαιτίας της ποικιλομορφίας των χαρακτηριστικών και παραμέτρων της κίνησης που είναι διαρκώς αλληλένδετα με το αντίστοιχο τμήμα του οπτικού δικτύου.

5. 4. 2 Σχεδίαση και αναδιαμόρφωση της εικονικής τοπολογίας

Μία ακόμη περίπτωση εφαρμογής της μηχανικής μάθησης στο επίπεδο δικτύου των οπτικών δικτύων σχετίζεται με την μοντελοποίηση των επικοινωνιακών δικτύων μέσω εικονικής τοπολογίας, η οποία εφαρμόζεται ευρέως στην σημερινή εποχή. Η μοντελοποίηση περιέχει την αναπαράσταση της σύνδεσης δύο τελικών σημείων (όπως για παράδειγμα δύο data center) μέσω μίας γειτνίασης στην εικονική τοπολογία, δηλαδή μέσω ενός εικονικού συνδέσμου, παρόλο που τα δύο endpoints δεν είναι απαραίτητο να είναι συνδεδεμένα μεταξύ τους με φυσικό τρόπο. Αφού καθοριστούν όλοι οι εικονικοί σύνδεσμοι, δηλαδή μετά τη διαδικασία της ταυτοποίησης των αιτημάτων των οπτικών μονοπατιών, προκειμένου να σχεδιαστεί η εικονική τοπολογία (Virtual Topology Design - VTD) απαιτείται να επιλυθεί το πρόβλημα της δρομολόγησης και της ανάθεσης του μήκους κύματος (Routing and Wavelength Assignment - RWA) για κάθε οπτικό μονοπάτι πάνω από το φυσικό δίκτυο. Σε αυτό το σημείο αξίζει να σημειωθεί πως η πλειονότητα των εικονικών τοπολογιών μπορεί να συνυπάρξει με το φυσικό δίκτυο, με αποτέλεσμα την αναπαράσταση υπηρεσιών που απαιτούνται από διαφορετικούς χρήστες καθώς ακόμα και διαφορετικών υπηρεσιών, με ξεχωριστές απαιτήσεις η κάθε μία όσον αφορά την ποιότητα της υπηρεσίας (Quality of Service - QoS), το εύρος ζώνης και την καθυστέρηση (latency) που παρέχονται στο συγκεκριμένο τελικό χρήστη. Ο σχεδιασμός της εικονικής τοπολογίας δεν είναι απαραίτητος μόνο σε περιπτώσεις παροχής νέων υπηρεσιών και εκχώρησης νέων πόρων στο δίκτυο.

Σε διάφορες περιπτώσεις, όπως για παράδειγμα σε περιπτώσεις αστοχιών δικτύου ή χρησιμοποίησης πόρων του δικτύου που υπόκεινται σε διαδικασίες

επαναβεβελτιστοποίησης, οι ήδη σχεδιασμένες εικονικές τοπολογίες που προϋπάρχουν μπορούν να ρυθμιστούν ξανά με τη διαδικασία αυτή να ονομάζεται αναδιαμόρφωση εικονικής τοπολογίας (VT reconfiguration). Προκειμένου να σχεδιαστεί και να αναδιαμορφωθεί μία εικονική τοπολογία δεν απαιτείται μόνο η παροχή χωρητικότητας στο δίκτυο για τις απαιτούμενες υπηρεσίες, αλλά απαιτείται ακόμη και η παροχή πρόσθετων πόρων η οποία πρέπει εκτός των άλλων να είναι σύμφωνη με τα ειδικά χαρακτηριστικά των υπηρεσιών. Η προαναφερθείσα περίπτωση παροχής υπηρεσιών ονομάζεται τεμαχισμός δικτύου (network slicing), με αποτέλεσμα κάθε παρεχόμενη υπηρεσία, δηλαδή ουσιαστικά κάθε εικονική τοπολογία αναπαριστά ένα τμήμα (slice) του συνολικού δικτύου[91].

Η μηχανική μάθηση κατέχει σημαντική θέση στη σχεδίαση των εικονικών τοπολογιών και στην διαδικασία αναδιαμόρφωσή τους. Στην περίπτωση εφαρμογής αλγορίθμων μάθησης κυρίως με επίβλεψη και χρήση ταξινομητών (classification), το μοντέλο εκπαιδεύεται με σκοπό τη βέλτιστη κατανομή των διαθέσιμων πόρων στο δίκτυο, λαμβάνοντας ταυτοχρόνως υπόψιν έναν μεγάλο αριθμό ετερογενών απαιτήσεων που προκύπτουν από υπηρεσίες για ένα είδος εικονικών τοπολογιών (network slice), επιτρέποντας έτσι τη ταχύτερη λήψη αποφάσεων που θα οδηγήσει στη βέλτιστη παροχή πόρων του δικτύου. Η δυνατότητα αυτή είναι σημαντική ειδικά στην περίπτωση που οι συνθήκες του δικτύου μεταβάλλονται με δυναμικό τρόπο.

5. 4. 3 Διαχείριση απωλειών

Μία από τις σημαντικότερες περιπτώσεις χρήσης των εφαρμογών της μηχανικής μάθησης στη διαχείριση του δικτύου των διάφορων οπτικών δικτύων είναι η ικανότητα ανίχνευσης απωλειών καθώς και ο προσδιορισμός των αιτιών τους. Η ανίχνευση των απωλειών κάθε είδους αποτελεί σημαντικό κομμάτι καθώς επιτρέπει την έγκαιρη επαναδρομολόγηση της κίνησης στην περίπτωση που υπάρχει κάποια απώλεια προκειμένου να διατηρηθεί το επίπεδο υπηρεσίας που έχει

συμφωνηθεί (με Service Level Agreements - SLAs) με σκοπό την γρηγορότερη επανάκαμψη του δικτύου. Η διαχείριση των απωλειών μπορεί να επιτευχθεί με διάφορους τρόπους και σε διάφορα επίπεδα κάθε φορά. Το πρώτο επίπεδο είναι η ανίχνευση της απώλειας, δηλαδή να εντοπιστεί και να προσδιοριστεί ο αριθμός των οπτικών μονοπατιών που επηρεάστηκαν από την αποτυχία. Παρόλο που ο προσδιορισμός δεν αποτελεί σχετικά μια απλή διαδικασία, η σημαντικότητα της διαδικασίας αυτής είναι μείζονος σημασίας καθώς επιτρέπει στα μονοπάτια που επηρεάστηκαν να αναδιαμορφωθούν μέσω της επαναδρομολόγησης της αντίστοιχης κίνησης. Επιπλέον, ένα ακόμη χρήσιμο χαρακτηριστικό που παρουσιάζει η ικανότητα εντοπισμού των απωλειών είναι η ενεργοποίηση διαδικασιών επαναφοράς του δικτύου. Έτσι μπορεί να ανακτηθεί η κατάσταση που υπήρχε πριν τη απώλεια στο δίκτυο, η οποία αποτελεί μία βέλτιστη κατάσταση σχετικά με τη διαχείριση των πόρων. Επίσης, ο προσδιορισμός των αιτιών της εκάστοτε απώλειας όπως η προσωρινή συμφόρηση που εμφανίζεται κατά τη διάρκεια της κυκλοφορίας, η διακοπή λειτουργίας των διάφορων συσκευών, ακόμα και οι αστοχίες που μπορεί να παρατηρηθούν στις μονάδες καταγραφής των δεδομένων αποτελούν ένα σημαντικό παράγοντα για την υιοθέτηση των κατάλληλων διαδικασιών επαναφοράς και αναδιαμόρφωσης της κίνησης του δικτύου. Τέλος, το πιο σημαντικό χαρακτηριστικό είναι η έγκαιρη αναγνώριση της αιτίας μιας απώλειας γεγονός που επιτρέπει την ταχύτερη επισκευή του εξοπλισμού μειώνοντας έτσι το μέσο χρόνο επισκευής (Mean Time To Repair - MTTR)[92].

5. 4. 4 Υπολογισμός διαδρομής

Κατά την διαδικασία της κατανομής των διαθέσιμων πόρων στο δίκτυο στην περίπτωση μιας εισερχόμενης αίτησης για παροχή μιας συγκεκριμένης υπηρεσίας, θα πρέπει να επιλεγεί η καταλληλότερη διαδρομή προκειμένου να αξιοποιηθούν όσο το δυνατόν αποτελεσματικότερα οι διαθέσιμοι πόροι του δικτύου για την καλύτερη εξυπηρέτηση της ζητούμενης κίνησης με το επιθυμητό QoS(Quality of Service) και χωρίς να επηρεαστούν οι ήδη υπάρχουσες υπηρεσίες του δικτύου. Επί των πλίστων, ο υπολογισμός της κατάλληλης διαδρομής γίνεται μέσω της χρήσης αλγόριθμων δρομολόγησης που βασίζονται στο υπολογισμό του κόστους. Τέτοιοι αλγόριθμοι είναι του Dijkstra, του Bellman-Ford και του Yen, οι οποίοι έχουν σαν βάση μία προκαθορισμένη μετρική κόστους όπως για παράδειγμα η απόσταση μεταξύ αφετηρίας και τερματισμού, η καθυστέρηση που υπάρχει από άκρο σε άκρο, η κατανάλωση ενέργειας, καθώς επίσης και ο συνδυασμός άλλων μετρικών που χρησιμοποιούνται για την καλύτερη διάκριση μεταξύ των εναλλακτικών διαδρομών[93][94].

Σε αυτή την περίπτωση, η χρήση μεθόδων μηχανικής μάθησης με επίβλεψη είναι σημαντική καθώς επιτρέπει την ταυτόχρονη εξέταση πολλών παραμέτρων του εισερχόμενου αιτήματος για παροχή υπηρεσίας και την αλληλεπίδραση των αποτελεσμάτων με τις πληροφορίες που ήδη υπάρχουν για την τρέχουσα κατάσταση του δικτύου. Έτσι δημιουργείται μία χαρτογράφηση των πληροφοριών αυτών με σκοπό την παροχή μιας βέλτιστης λύσης δρομολόγησης χωρίς να χρειάζονται πολύπλοκες εκτιμήσεις κόστους στο δίκτυο. Με αυτό τον τρόπο θα επιλεγεί η ταχύτερη διαδρομή που θα οδηγήσει στην γρηγορότερη παροχή υπηρεσίας.

Παράδειγμα εφαρμογής	Κατηγορία μηχανικής μάθησης	Μεθοδολογία μηχανικής μάθησης	Δεδομένα εισόδου	Δεδομένα εξόδου	Δεδομένα εκπαίδευσης
Πρόβλεψη κυκλοφορίας και επανασχεδιασμός εικονικής τοπολογίας	επιβλεπόμενη (supervised)	ARIMA	Ιστορικοί πίνακες κυκλοφορίας σε πραγματικό χρόνο	Προβλεπόμενος πίνακας κίνησης	συνθετικά
		NN	Ιστορική κυκλοφορία μέγιστου ρυθμού bit από άκρο σε άκρο	Προβλεπόμενη κίνηση από άκρο σε άκρο	συνθετικά
		Μάθηση ενίσχυσης	Προηγούμενες λύσεις πολλαπλών GA για VTD	Εκσυγχρονισμένο VT	συνθετικά
		Επαναλαμβανόμενο NN	Ιστορική συγκεντρωτική κίνηση σε διαφορετικά BBU pools	Προβλεπόμενη κίνηση BBU pools	πραγματικά
		NN	Ιστορική κυκλοφορία σε δίκτυο intra-DC	Προβλεπόμενη κίνηση intra-DC	πραγματικά
	μη-επιβλεπόμενη (unsupervised)	NMF, ομαδοποίηση	CDR, Pol matrix	Μοτίβα ομοιότητας στην κίνηση του σταθμού βάσης	πραγματικά
Διαχείριση αποτυχιών	επιβλεπόμενη (supervised)	Τεκμήριο Bayes	BER, λαμβανόμενη ισχύς	Λίστα αποτυχιών για όλα τα μονοπάτια φωτός	πραγματικά
		Τεκμήριο Bayes, EM	Σετ δεδομένων FTTH δικτύου με δεδομένα που λείπουν	Ολοκληρωμένο σετ δεδομένων	πραγματικά
		Kriging	Προγενέστερα καθιερωμένα μονοπάτια φωτός με ήδη διαθέσιμα δεδομένα εντοπισμού και παρακολούθησης αστοχιών	Εκτίμηση εντοπισμού αστοχίας σε επίπεδο ζεύξης για όλα τα μονοπάτια φωτός	πραγματικά
		(1) LUCIDA: Παλινδρόμηση και Ταξινόμηση	(1) LUCIDA: ιστορικό BER και λαμβανόμενη ισχύς, ειδοποιήσεις από BANDO	(1) LUCIDA: ταξινόμηση αποτυχίας	πραγματικά
		(2) BANDO: Ανίχνευση ανωμαλιών	(2) BANDO: μέγιστο BER, κατώφλι BER στο set-up, παρακολουθούμενο BER	(2) BANDO: ανωμαλίες στο BER	
		Παλινδρόμηση, δένδρο απόφασης, SVM	BER, ζεύγη συχνότητας-ισχύος	Τοπικό σύνολο αστοχιών	πραγματικά
		SVM, RF, NN	BER	Σύνολο αστοχιών	πραγματικά
		Παλινδρόμηση και NN	Επίπεδα οπτικής ισχύος, κέρδος ενισχυτή, θερμοκρασία ραφίου, έλξη ρεύματος, εσωτερική οπτική ισχύς	Ανιχνευμένα σφάλματα	πραγματικά

Ταξινόμηση ροής	επιβλεπόμενη (supervised)	HMM,EM	δεδομένα απώλειας πακέτων	Ταξινόμηση απωλειών: απώλειες συμφώρησης ή απώλειες ισχυρισμού	συνθετικά
		NN	Πηγή/προορισμός IP διευθύνσεων, θύρες πηγών/προορισμού, πρωτόκολλο επιπέδου μεταφοράς, μεγέθη πακέτων και ένα σετ από χρονοδιαγράμματα ενδοροής μέσα στα πρώτα 40 πακέτα μιας ροής	Ταξινομημένη ροή για DC	συνθετικά
Υπολογισμός μονοπατιού	επιβλεπόμενη (supervised)	Q-Learning	Απαιτήσεις κίνησης, σύνολο υποψήφιων μονοπατιών μεταξύ του κάθε ζευγαριού πηγής-προορισμού	βέλτιστες διαδρομές για κάθε ζεύγος πηγής-προορισμού για την ελαχιστοποίηση της πιθανότητας απώλειας ριπής	συνθετικά
	μη-επιβλεπόμενη (unsupervised)	FCM	Απαιτήσεις κίνησης, μήκη μονοπατιών, σύνολο μορφών διαμόρφωσης, OSNR, BER	αντιστοίχιση μιας βέλτιστης μορφής διαμόρφωσης σε ένα μονοπάτι φωτός	συνθετικά

Πίνακας 2. Περιπτώσεις χρήσης στο επίπεδο δικτύου και τα χαρακτηριστικά τους

ΚΕΦΑΛΑΙΟ 6^ο – ΑΝΑΛΥΤΙΚΗ ΠΕΡΙΓΡΑΦΗ ΕΠΙΛΕΓΜΕΝΩΝ

ΕΦΑΡΜΟΓΩΝ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΣΤΑ ΟΠΤΙΚΑ ΔΙΚΤΥΑ

6.1 Εφαρμογές μηχανικής μάθησης για την εξομάλυνση της μη γραμμικότητας

Η μετρική απόδοσης που παρουσιάζει το μεγαλύτερο ενδιαφέρον και χρησιμοποιείται συνήθως στα συστήματα οπτικών επικοινωνιών είναι το γινόμενο του ρυθμού δεδομένων με την απόσταση. Εξαιτίας των απωλειών που υπάρχουν στις οπτικές ίνες χρειάζεται να εφαρμοστεί οπτική ενίσχυση. Έτσι, προκειμένου να αυξηθεί η απόσταση της μετάδοσης, πρέπει να χρησιμοποιηθεί ένας αυξανόμενος αριθμός οπτικών ενισχυτών. Το μειονέκτημα της εισαγωγής των οπτικών ενισχυτών είναι η εισαγωγή θορύβου, επομένως για να διατηρηθεί η αναλογία σήματος προς το θόρυβο χρειάζεται να αυξηθεί η ισχύς του οπτικού σήματος. Ωστόσο, η αύξηση της ισχύος του οπτικού σήματος πέρα από μια συγκεκριμένη τιμή θα έχει ως αποτέλεσμα την αύξηση των μη γραμμικοτήτων των οπτικών ινών που οδηγούν σε θόρυβο μη γραμμικής παρεμβολής (Nonlinear Interference NLI), ο οποίος εν τέλει θα επηρεάσει την τελική ανίχνευση των συμβόλων. Επομένως, για να περιοριστεί ή να εξαληφθεί η αύξηση αυτή, μπορούν να εφαρμοστούν διάφορες προσεγγίσεις μηχανικής μάθησης με σκοπό την εκτέλεση της βέλτιστης ανίχνευσης συμβόλων.

Πιο συγκεκριμένα, σκοπός του δέκτη είναι να πραγματοποιήσει τη βέλτιστη ανίχνευση συμβόλων. Στην περίπτωση που ο θόρυβος έχει κυκλική συμμετρική Γκαουσιανή κατανομή, η βέλτιστη ανίχνευση συμβόλων πραγματοποιείται ελαχιστοποιώντας την Ευκλείδεια απόσταση μεταξύ του λαμβανόμενου συμβόλου y_k και όλων των πιθανών συμβόλων του αστερισμού του αλφαβήτου $s = s_k \mid k = 1, \dots, M$, με το συγκεκριμένο τύπο ανίχνευσης συμβόλων να έχει σε αυτή την περίπτωση γραμμικά όρια αποφάσεων. Για την περίπτωση της μη γραμμικότητας χωρίς μνήμη, όπως για παράδειγμα ο θόρυβος μη γραμμικής φάσης, ο διαμορφωτής I/Q και η μη γραμμικότητα ηλεκτρονικών οδηγών (driving electronics nonlinearity), ο θόρυβος που σχετίζεται με το σύμβολο y_k ενδέχεται να μην είναι πλέον κυκλικά

συμμετρικός. Αυτό ουσιαστικά σημαίνει ότι οι συστάδες του διαγράμματος αστερισμού παραμορφώνονται (δημιουργούνται ελλειπτικά σχήματα αντί για κυκλικά που να είναι συμμετρικά σε ορισμένες περιπτώσεις). Στις συγκεκριμένες περιπτώσεις, η βέλτιστη ανίχνευση συμβόλων δεν βασίζεται πλέον στον πίνακα Ευκλείδειας απόστασης και έτσι η γνώση και η πλήρης παραμετροποίηση της συνάρτησης πιθανότητας, $p(y_k | x_k)$, κρίνεται απαραίτητη. Προκειμένου να προσδιοριστεί και να παραμετροποιηθεί η συνάρτηση πιθανότητας και τελικά να εκτελεστεί η βέλτιστη ανίχνευση συμβόλων, χρησιμοποιούνται τεχνικές μηχανικής μάθησης, όπως για παράδειγμα SVM, ο εκτιμητής πυκνότητας πυρήνα, οι k -πλησιέστεροι γείτονες και τα μοντέλα Gaussian μειγμάτων. Από διάφορες μελέτες που έχουν γίνει έχει αποδειχθεί ότι επιτυγχάνεται κέρδος περίπου 3 dB στην ισχύ εισόδου της ίνας, με χρήση μοντέλου μείγματος Gauss σε συνδυασμό με μεγιστοποίηση προσδοκίας για μετάδοση 14 Gbaud DP 16-QAM πάνω σε ζεύξη 800 χιλιομέτρων με αντιστάθμιση διασποράς [99]. Επιπλέον, μπορεί να χρησιμοποιηθεί ένας σταθμισμένος με απόσταση ταξινομητής k πλησιέστερων γειτόνων για την αντιστάθμιση των απωλειών του συστήματος σε μηδενικές διασπορές, σε ζεύξεις με ή χωρίς διαχείριση διασποράς σε 16-QAM μετάδοση, όπως επίσης μπορούν να χρησιμοποιηθούν Νευρωνικά Δίκτυα για μη γραμμική εξίσωση σε 16-QAM OFDM μετάδοση. Στην περίπτωση αυτή, υιοθετείται ένα νευρωνικό δίκτυο ανά υποφέρουσα, με αριθμό νευρώνων ίσο με τον αριθμό των συμβόλων[99].

Για να μειωθεί η υπολογιστική πολυπλοκότητα της φάσης εκπαίδευσης, μπορεί να χρησιμοποιηθεί ένας ισοσταθμιστής Extreme Learning Machine (ELM). Το ELM είναι ένα νευρωνικό δίκτυο όπου τα βάρη που ελαχιστοποιούν το σφάλμα αντιστοίχησης εισόδου-εξόδου μπορούν να υπολογιστούν μέσω μιας γενικευμένης αντιστροφής πίνακα, χωρίς να απαιτείται κανένα βήμα βελτιστοποίησης των βαρών. Όλες οι προαναφερθείσες προσεγγίσεις οδηγούν σε βελτίωση 0,5 - 3 dB όσον αφορά το BER / Q-factor. Στο πλαίσιο του περιορισμού της μη γραμμικότητας και ουσιαστικά της μείωσης των βλαβών, υπάρχει ένα σύνολο αναφορών που εφαρμόζουν εξισορρόπηση του οπτικού σήματος χρησιμοποιώντας μια ποικιλία αλγορίθμων μηχανικής μάθησης όπως μοντέλα Gaussian μειγμάτων, ομαδοποίηση και τεχνητά νευρωνικά δίκτυα. Σε περιπτώσεις που χρησιμοποιούνται νευρωνικά δίκτυα για

εξισορρόπηση, συνήθως ένα διάνυσμα από δείγματα συμβόλων που έχουν ληφθεί χρησιμοποιείται ως η είσοδος στα νευρωνικά δίκτυα με την έξοδο να είναι το εξισορροπημένο σήμα με μειωμένη την διασυμβολική παρεμβολή (ISI). Για παράδειγμα, ένα συνελικτικό νευρωνικό δίκτυο (CNN) θα χρησιμοποιείται για την ταξινόμηση διαφορετικών κατηγοριών σήματος PAM χρησιμοποιώντας το λαμβανόμενο σήμα ως είσοδο. Ο αριθμός των εξόδων του CNN θα εξαρτηθεί από το αν το σήμα είναι PAM - 4, 8 ή 16 [99].

Επίσης εφαρμογές νευρωνικών δικτύων μπορούν να χρησιμοποιηθούν για τον περιορισμό απωλειών ενός οπτικού σήματος. Ένα νευρωνικό δίκτυο προσεγγίζει σε αποτελεσματικό βαθμό τη λειτουργία της ψηφιακής οπισθοδιάδοσης (digital backpropagation, DBP), η οποία είναι μια ευρέως διαδεδομένη τεχνική για την επίλυση της μη γραμμικής εξίσωσης Schrödinger χρησιμοποιώντας τη μέθοδο (Fourier split-step, SSFM). Επίσης, ένα νευρωνικό δίκτυο μπορεί να οδηγήσει στην προσομοίωση της λειτουργίας ενός δέκτη σε ένα μη γραμμικό σύστημα πολυπλεξίας διαίρεσης συχνότητας (NFDM)[99]. Μια άλλη προσέγγιση βασίζεται σε νευρωνικά δίκτυα για αντιστάθμιση μη γραμμικότητας, στην οποία το νευρωνικό δίκτυο λαμβάνει δείγματα σημάτων από διαφορετικούς χρήστες σε ένα Radio-over-Fiber σύστημα και επιστρέφει ένα διάνυσμα σήματος διορθωμένο από τις απώλειες[99].

6. 2 Εφαρμογές μηχανικής μάθησης για την πρόβλεψη της κίνησης και σχεδιασμού της εικονικής τοπολογίας

Η πρόβλεψη της κυκλοφορίας σε οπτικά δίκτυα είναι μια πολύ σημαντική μετρική, ειδικά στο σχεδιασμό και στη σωστή κατανομή των πόρων με σκοπό την καλύτερη αναβάθμισή τους. Δεδομένου ότι η εκπαίδευση ενός μοντέλου από ένα σύνολο δεδομένων είναι μια από τις βασικές αρχές λειτουργίας των τεχνικών μηχανικής μάθησης γίνεται αντιληπτό ότι με το εκπαιδευμένο πλέον μοντέλο μπορεί να γίνει πρόβλεψη μελλοντικής συμπεριφοράς. Για παράδειγμα, ένα μοντέλο αυτόματης κλιμάκωσης ενσωματωμένου κινούμενου μέσου όρου (autoregressive integrated moving average, ARIMA) είναι μια επιβλεπόμενη μέθοδος μηχανικής

μάθησης που εφαρμόζεται σε δεδομένα χρονοσειρών. Επίσης, αλγόριθμοι μηχανικής μάθησης μπορούν να χρησιμοποιηθούν για να προβλέψουν την κυκλοφορία για τη διενέργεια αναδιάρθρωσης εικονικής τοπολογίας. Πιο συγκεκριμένα, προτείνεται μια μονάδα σχεδιασμού δικτύου και λήψης αποφάσεων (NPDM) για την πρόβλεψη της κυκλοφορίας χρησιμοποιώντας μοντέλα ARIMA.

Στη συνέχεια, το NPDM αλληλοεπιδρά με άλλες ενότητες για να πραγματοποιηθεί η αναδιάρθρωση της εικονικής τοπολογίας. Δεδομένου ότι, η εικονική τοπολογία πρέπει να προσαρμοστεί σύμφωνα με τις διακυμάνσεις στην κίνηση που ποικίλλουν ανάλογα με το χρόνο, το σύνολο των δεδομένων εισόδου μπορεί να εισαχθεί με τη μορφή δεδομένων χρονοσειρών. Πιο συγκεκριμένα, οι είσοδοι είναι οι πίνακες κίνησης σε πραγματικό χρόνο που παρατηρούνται σε ένα χρονικό διάστημα λίγο πριν από την τρέχουσα περίοδο. Το ARIMA είναι μια τεχνική πρόβλεψης που λειτουργεί άψογα με δεδομένα χρονοσειρών και ως εκ τούτου γίνεται μια στοχευμένη επιλογή σε εφαρμογές όπως προβλέψεις κυκλοφορίας και αναδιαμορφώσεις εικονικής τοπολογίας. Επιπλέον, η σχετικά χαμηλή πολυπλοκότητα του ARIMA είναι επίσης προτιμότερη σε εφαρμογές οι οποίες πρέπει να διατηρούν χαμηλότερο λειτουργικό κόστος.

Σε ένα γενικό πλαίσιο, η επιλογή ενός αλγορίθμου μηχανικής μάθησης εξαρτάται πάντα από την αντιστάθμιση μεταξύ της ακρίβειας της παρεχόμενης μάθησης και της πολυπλοκότητάς της. Για παράδειγμα μπορεί να γίνει πρόβλεψη κυκλοφορίας, δηλαδή ουσιαστικά αναδιάρθρωση εικονικής τοπολογίας, χρησιμοποιώντας νευρωνικά δίκτυα. Στη συγκεκριμένη περίπτωση, προτείνεται ένα είδος πρόβλεψης που βασίζεται σε νευρωνικό δίκτυο το οποίο δημιουργεί τον πίνακα προορισμού προέλευσης κίνησης. Ο προβλεπόμενος πίνακας κίνησης για την επόμενη περίοδο χρησιμοποιείται στη συνέχεια από μια διαδικασία λήψης αποφάσεων ώστε να επιβεβαιωθεί εάν η τρέχουσα τοπολογία εικονικού δικτύου (Virtual Network Topology, VNT) πρέπει να αναδιαμορφωθεί ή όχι. Το κυριότερο κίνητρο για τη χρήση νευρωνικών δικτύων είναι η ισχυρή προσαρμοστικότητα που παρουσιάζουν στις αλλαγές της κίνησης εισόδου και επίσης η ακρίβεια της πρόβλεψης της κυκλοφορίας εξόδου με βάση τις εισόδους που ουσιαστικά αποτελούν το ιστορικό της κίνησης [99].

Παραδείγματος χάριν, χρήση αλγορίθμου πρόβλεψης κίνησης και ανακατανομής πόρων βασιζόμενο σε βαθιά μάθηση μπορεί να γίνει για ένα δίκτυο μεταξύ κέντρων δεδομένων (datacenters). Το μοντέλο που βασίζεται στη βαθιά μάθηση (deep learning) υπερτερεί όχι μόνο των συμβατικών αλγορίθμων κατανομής πόρων, αλλά ακόμα και ενός αλγορίθμου βασισμένου σε νευρωνικό δίκτυο ενός επιπέδου, όσον αφορά την απόδοση μπλοκαρίσματος και την αποδοτικότητα δέσμευσης των διαθέσιμων πόρων. Στην περίπτωση αυτή συνίσταται η χρήση τεχνικών βαθιάς μάθησης, η οποία είναι πιο περίπλοκη σε σχέση με απλές τεχνικές μηχανικής μάθησης με νευρωνικό δίκτυο και κατ' επέκταση θα είναι πιο αποτελεσματική.

Πολλές φορές ο τύπος εφαρμογής καθορίζει επίσης το είδος ή την παραλλαγή ενός γενικού αλγορίθμου μηχανικής μάθησης που πρέπει να χρησιμοποιηθεί σε κάθε περίπτωση. Ένα παράδειγμα μπορούν να αποτελέσουν τα επαναλαμβανόμενα νευρωνικά δίκτυα (RNN), τα οποία εφαρμόζουν καλύτερα σε περιπτώσεις που χρησιμοποιούνται δεδομένα χρονοσειρών και έτσι μπορούν να χρησιμοποιηθούν για την πρόβλεψη της κίνησης της μονάδας βασικής ζώνης (Baseband Unit, BBU) σε ένα δίκτυο cloud ασύρματης πρόσβασης 5G. Δεδομένου ότι η κυκλοφορία που συγκεντρώνεται σε διαφορετικές ομάδες BBU αποτελείται από διαφορετικές κατηγορίες όπως κίνηση κατοίκων και κίνηση γραφείων, με διαφορετικές χρονικές διακυμάνσεις, το ιστορικό σύνολο δεδομένων για τέτοια κίνηση έχει πάντα μια διάσταση στον χρόνο[99]. Υπάρχει μελέτη στην οποία προτείνεται και εφαρμόζεται με καλό αποτέλεσμα ένα σύστημα πρόβλεψης κίνησης βασιζόμενο σε RNN, το οποίο παρουσιάζει αύξηση 7% στην απόδοση δικτύου και το 18% αναφέρεται στη μείωση των πόρων επεξεργασίας[99].

Άλλη έρευνα αναφέρει τις διαφορές μιας γνωστικής μονάδας διαχείρισης δικτύου σε σχέση με το πλαίσιο Application Based Network Operations, ABNO, δίνοντας ιδιαίτερη έμφαση στην πρόβλεψη κυκλοφορίας βασιζόμενη σε μηχανική μάθηση για την αναδιάρθρωση του VNT, αν και δεν έχουν γίνει γνωστές οι λεπτομέρειες οποιουδήποτε αλγορίθμου μηχανικής μάθησης που χρησιμοποιείται για τον σκοπό της αναδιάρθρωσης της VNT[99]. Παρομοίως, προτείνεται Bayesian inference για την εκτίμηση της κυκλοφορίας του δικτύου ώστε να αποφασιστεί εάν

και πότε θα αναδιαμορφωθεί ένα συγκεκριμένο εικονικό δίκτυο. Ενώ το μεγαλύτερο μέρος της βιβλιογραφίας επικεντρώνεται στην πρόβλεψη κυκλοφορίας χρησιμοποιώντας αλγόριθμους μηχανικής μάθησης για μια συγκεκριμένη άποψη των αναδιαμορφώσεων τοπολογίας εικονικού δικτύου, άλλη έρευνα παρουσιάζει ένα γενικό πλαίσιο εκτίμησης μοτίβου κίνησης από εγγραφές δεδομένων κλήσεων (CDR)[99]. Στη συγκεκριμένη περίπτωση χρησιμοποιούνται πραγματικά σύνολα δεδομένων από παρόχους υπηρεσιών και χρησιμοποιούνται αλγόριθμοι βασισμένοι σε παραμετροποίηση και ομαδοποίηση ώστε να αντλήθούν χρήσιμες πληροφορίες από τα εκάστοτε σύνολα δεδομένων, τα οποία μπορούν να χρησιμοποιηθούν για την καλύτερη ανάπτυξη των πόρων του δικτύου.

Ένα παράδειγμα χρήσης CDR παρατηρείται σε διαφορετικούς σταθμούς βάσης από την πόλη του Μιλάνου. Το σύνολο δεδομένων περιέχει πληροφορίες όπως το αναγνωριστικό της κυψέλης, το χρονικό διάστημα των κλήσεων, ο κωδικός χώρας, ληφθέντα SMS, απεσταλμένα SMS, εισερχόμενες κλήσεις, εξερχόμενες κλήσεις, στη μορφή ενός πίνακα, που ονομάζεται πίνακας CDR(Call Detail Records). Εκτός από τον πίνακα CDR, το σύνολο δεδομένων εισόδου περιλαμβάνει επίσης έναν πίνακα σημείων ενδιαφέροντος (POI) που περιέχει πληροφορίες σχετικά με διάφορα σημεία ενδιαφέροντος ή περιοχές που είναι επισκέψιμες και καλύπτονται από κάθε σταθμό βάσης. Όλοι αυτοί οι πίνακες εισόδου χρησιμοποιούνται στη συνέχεια ως είσοδος σε έναν αλγόριθμο μηχανικής μάθησης συσταδοποίησης που ονομάζεται μη αρνητική παραγοντοποίηση πίνακα (Nonnegative matrix factorization, NMF) και μια παραλλαγή αυτού που ονομάζεται συλλεκτικό NMF (C-NMF). Τα δεδομένα εξόδου των αλγορίθμων αντιστοιχίζονται στους πίνακες εισόδου σε δύο μη αρνητικούς πίνακες, όπου ο ένας δίνει τους διαφορετικούς τύπους βασικών μοτίβων κυκλοφορίας και ο άλλος δίνει τις ομοιότητες μεταξύ σταθμών βάσης όσον αφορά τα μοτίβα κυκλοφορίας.

Τέλος, ενώ πολλές από τις βιβλιογραφικές αναφορές επικεντρώνονται σε ένα ή σε λιγότερα συγκεκριμένα χαρακτηριστικά κατά την ανάπτυξη αλγορίθμων μηχανικής μάθησης για προβλέψεις κυκλοφορίας και διαμορφώσεις εικονικής τοπολογίας, υπάρχουν και άλλες που παρουσιάζουν ένα γενικό πλαίσιο με κάποια

μορφή γνώσης ενσωματωμένη σε συνδυασμό με τακτικούς αλγόριθμους βελτιστοποίησης.

6.3 Εφαρμογές μηχανικής μάθησης για τον υπολογισμό διαδρομής

Ο υπολογισμός ή η επιλογή της διαδρομής, που βασίζεται σε διαφορετικές παραμέτρους φυσικού επιπέδου και επιπέδου δικτύου, είναι ένα κοινό πρόβλημα που μελετάται συχνά στις οπτικές επικοινωνίες. Παράμετροι φυσικού επιπέδου όπως για παράδειγμα QoT, μορφή διαμόρφωσης και OSNR εκτιμώνται χρησιμοποιώντας τεχνικές μηχανικής μάθησης. Ο κύριος στόχος είναι να ληφθεί μια απόφαση σχετικά με την καλύτερο οπτικό μονοπάτι που θα επιλεγεί μεταξύ των πολλών διαφορετικών εναλλακτικών που υπάρχουν. Η συνολική διαδικασία υπολογισμού διαδρομής μπορεί επομένως να θεωρηθεί ως μέθοδος πολλαπλών επιπέδων με εφαρμογή τεχνικών μηχανικής μάθησης σε πολλαπλά επίπεδα. Εδώ εντοπίζονται αναφορές σε δύο περιπτώσεις που αντιμετωπίζουν τον υπολογισμό ή την επιλογή διαδρομής σε οπτικά δίκτυα με προοπτική επιπέδου δικτύου.

Στην πρώτη περίπτωση, προτείνεται από μελέτες που έχουν γίνει μια στρατηγική για επιλογή διαδρομής και μήκους κύματος για δίκτυα OBS με την οποία ελαχιστοποιείται η πιθανότητα απώλειας ριπής[99]. Το πρόβλημα διατυπώνεται ως πρόβλημα multi-arm bandit problem (MABP) και επιλύεται χρησιμοποιώντας Q-learning. Παράδειγμα ενός προβλήματος MABP μπορεί να παρουσιαστεί από τον χώρο τυχερών παιγνίων όπου ένας παίκτης προσπαθεί να τραβήξει έναν από τους βραχίονες ενός κουλοχέρη με στόχο να μεγιστοποιήσει το ποσό των ανταμοιβών μετά από πολλά τραβήγματα του βραχίονα. Στο σενάριο δικτύου OBS, χρησιμοποιείται η ιδέα επιλογής διαδρομής για κάθε ζεύγος πηγής-προορισμού όπως το τραβήγμα ενός από τους βραχίονες σε έναν κουλοχέρη με επιβράβευση την ελαχιστοποίηση της πιθανότητας απώλειας ριπής.

Γενικά το MABP πρόβλημα είναι ένα κλασικό πρόβλημα ενισχυτικής μάθησης και προτείνεται Q-learning για την επίλυσή του, επειδή άλλες μέθοδοι δεν δίνουν λύση σε πολύπλοκα προβλήματα. Επιπλέον, άλλες μέθοδοι επίλυσης MABP, όπως ο

δυναμικός προγραμματισμός, οι δείκτες Gittins και αλγόριθμοι learning αποδεικνύονται να παρουσιάζουν μία πολυπλοκότητα όταν οι κατανομές των ανταμοιβών δηλαδή, οι κατανομές της πιθανότητας απώλειας ριπών σε περίπτωση του σεναρίου OBS είναι άγνωστες. Επιπλέον παρατηρείται ότι ο Q learning αλγόριθμος έχει εγγυημένη σύγκλιση σε σχέση με άλλες μεθόδους επίλυσης του προβλήματος MABP.

Στη δεύτερη περίπτωση μια μονάδα επιπέδου ελέγχου λήψης αποφάσεων για υπολογισμό διαδρομής σύμφωνα με το QoS προτείνεται χρησιμοποιώντας αλγόριθμο Fuzzy C-Means Clustering (FCM). Ο αλγόριθμος FCM προστίθεται στο επίπεδο ελέγχου του οπτικού δικτύου (SDON) που διαχειρίζεται από λογισμικό, προκειμένου να επιτευχθεί καλύτερη απόδοση δικτύου, σε σύγκριση με ένα μη γνωστικό επίπεδο ελέγχου. Λαμβάνει ως είσοδο χαρακτηριστικά όπως αιτήματα κυκλοφορίας, μήκη των lightpaths, σύνολο μορφών διαμόρφωσης, OSNR, BER και στη συνέχεια ταξινομεί κάθε lightpath σύμφωνα με τις καλύτερες δυνατές παραμέτρους του φυσικού στρώματος. Το αποτέλεσμα της ταξινόμησης είναι μια αντιστοίχιση του κάθε lightpath με μια διαφορετική παράμετρο φυσικού επιπέδου και πόσο στενά συνδέεται ένα lightpath με μια παράμετρο φυσικού επιπέδου από άποψη μιας βαθμολογίας συμμετοχής. Στη συνέχεια αυτές οι πληροφορίες βαθμολογίας συμμετοχής θα χρησιμοποιηθούν για τη δημιουργία ορισμένων κανόνων με τους οποίους σε πραγματικό χρόνο θα λαμβάνονται αποφάσεις για τη δημιουργία των lightpaths.

6. 4 Αξιολόγηση αλγορίθμων μηχανικής μάθησης στα οπτικά δίκτυα

6. 4. 1 Ανάλυση μετρικών απόδοσης

Κατά την περίπτωση εφαρμογής της μηχανικής μάθησης με σκοπό την επίλυση ενός προβλήματος ταξινόμησης, μια κοινή προσέγγιση προκειμένου να αξιολογηθεί η απόδοση του αλγορίθμου μηχανικής μάθησης είναι να αναδειχθεί η

ακρίβεια ταξινόμησης καθώς και ο υπολογισμός απόδοσης του μέτρου της πολυπλοκότητας του αλγορίθμου, ο οποίος εξαρτάται από τη μορφή της διάρκειας της φάσης εκπαίδευσης. Η ακρίβεια της ταξινόμησης συντίθεται από το κλάσμα των δειγμάτων δοκιμής, τα οποία έχουν ταξινομηθεί σωστά. Αν και αυτή η μέτρηση φαίνεται σωστή, αποδεικνύεται ότι είναι μια κακή μετρική όσο αναφορά σύνθετα προβλήματα ταξινόμησης, ειδικά όταν το διαθέσιμο σύνολο δεδομένων περιέχει έναν αριθμό δειγμάτων μη ισορροπημένο μεταξύ των διαφόρων τάξεων όπως για παράδειγμα σε ένα δυαδικό σύνολο δεδομένων όπου το 90% των δειγμάτων ανήκει σε μία κατηγορία. Σε αυτές τις περιπτώσεις, μπορούν να χρησιμοποιηθούν διάφορες μετρικές σαν αυτές που θα αναλυθούν παρακάτω[99].

Μία μετρική είναι ο πίνακας σύγχυσης. Δεδομένου ενός προβλήματος δυαδικής ταξινόμησης, όπου τα δείγματα που χρησιμοποιούνται στο σύνολο δοκιμής ανήκουν είτε σε θετική είτε σε αρνητική κλάση, ο πίνακας σύγχυσης δίνει μια πλήρη επισκόπηση της απόδοσης του ταξινομητή, δείχνοντας αρχικά τα αληθώς θετικά (True Positives TP) και ακολούθως τα αληθώς αρνητικά (True Negatives TN), δηλαδή το σύνολο των δειγμάτων της τάξης true και false, αντίστοιχα, που έχουν ταξινομηθεί σωστά, και στη συνέχεια τα ψευδώς θετικά (False Positives FP) και ψευδώς αρνητικά (False Negatives FN), δηλαδή τον αριθμό των δειγμάτων της τάξης true και false, αντίστοιχα, τα οποία έχουν ταξινομηθεί εσφαλμένα. Επομένως αξιοποιώντας τους παραπάνω ορισμούς, η ακρίβεια μπορεί να εκφραστεί ως $(TP+TN)/(TP+TN+FP+FN)$.

Μία ακόμη μετρική είναι ο ρυθμός των αληθώς θετικών, ο οποίος προκύπτει από τη σχέση $TPR=TP/(TP+FN)$. Η συγκεκριμένη μετρική εμπίπτει στο εύρος [0, 1] και καταγράφει την ικανότητα αναγνώρισης πραγματικά θετικών δειγμάτων σε όλο το σύνολο δοκιμών δηλαδή, όσο μεγαλύτερα, τόσο καλύτερα. Αντίστοιχα, υπάρχει και ο ρυθμός των ψευδών θετικών (False Positive Rate), που δίνεται από τη σχέση $FPR=FP/(FP+TN)$. Επίσης, η συγκεκριμένη μετρική εμπίπτει στην περιοχή [0, 1] και αντιπροσωπεύει το κλάσμα των αρνητικών δειγμάτων στο σύνολο δοκιμών που ταξινομούνται εσφαλμένα ως θετικά δηλαδή, όσο χαμηλότερα, τόσο καλύτερα.

Μία από τις πιο σημαντικές μετρικές είναι η καμπύλη χαρακτηριστικής λειτουργίας δέκτη (Receiver Operating Characteristic ROC curve). Σε έναν δυαδικό

ταξινομητή, ένα αυθαίρετο όριο γ μπορεί να ρυθμιστεί για διάκριση μεταξύ των αληθινών και ψευδών περιπτώσεων. Έτσι αυξάνοντας την αξία του γ , μειώνεται ο αριθμός των περιπτώσεων που ταξινομούνται ως θετικές και αυξάνεται ο αριθμός των δειγμάτων που ταξινομούνται ως αρνητικά. Αυτό έχει ως αποτέλεσμα τη μείωση των TP ενώ αντίστοιχα αυξάνεται ο αριθμός των FN και ταυτόχρονα την αύξηση των TN ενώ αντίστοιχα μειώνονται τα FP.

Ως εκ τούτου, παρατηρείται μείωση τόσο στο TPR όσο και στο FPR. Για διαφορετικές τιμές του γ , η καμπύλη ROC απεικονίζει το TPR (στον κατακόρυφο άξονα) και το FPR (στον οριζόντιο άξονα). Για $\gamma = 1$, όλα τα δείγματα ταξινομούνται ως αρνητικά, ενώ ισχύει η σχέση $TPR=FPR=0$. Αντίθετα, για $\gamma = 0$, όλα τα δείγματα ταξινομούνται ως θετικά, επομένως ισχύει η σχέση $TPR=FPR=1$. Για οποιονδήποτε άλλο ταξινομητή, η καμπύλη ROC συνδέει σε κάθε περίπτωση αυτά τα δύο άκρα. Οι ταξινομητές που καταγράφουν χρήσιμες πληροφορίες παράγουν μια καμπύλη ROC πάνω από τη διαγώνιο στο (FPR, TPR) στοχεύοντας έτσι στην προσέγγιση του ιδανικού ταξινομητή, ο οποίος εν τέλει οδηγεί στη διασύνδεση των τα σημείων (0, 0), (0, 1) και (1, 1).

Στην περίπτωση της περιοχής κάτω από την καμπύλη ROC (Area under the ROC Curve, AUC) το εύρος λήψης τιμών στην περιοχή κυμαίνεται στο διάστημα [0, 1] και καταγράφει κατά πόσο ένας δεδομένος ταξινομητής προσεγγίζει την απόδοση ενός ιδανικού ταξινομητή. Παρόλο που η καμπύλη ROC είναι ένα αποτελεσματικό γραφικό μέσο για την αξιολόγηση της απόδοσης ενός ταξινομητή, το AUC είναι ένα συνθετικό αριθμητικό μέτρο που παρουσιάζει την απόδοση του αλγορίθμου ανεξάρτητα από τη επιλογή του ορίου γ .

Η επόμενη μετρική που θα αναλυθεί είναι τα κριτήρια πληροφοριών Akaike (AKAIKE Information Criteria, AIC) τα οποία αποτυπώνουν την καλή εφαρμογή για ένα συγκεκριμένο μοντέλο. Από τα συγκεκριμένα κριτήρια υπολογίζεται το κατά πόσο αποκλίνει ένα επιλεγμένο στατιστικό μοντέλο από το «αληθινό μοντέλο» ορίζοντας ένα κριτήριο που είναι μια μαθηματική συνάρτηση του αριθμού των εκτιμώμενων παραμέτρων από το μοντέλο και τη συνάρτηση μέγιστης πιθανότητας. Το μοντέλο που παρουσιάζει ελάχιστο AIC θεωρείται ως το καλύτερο μοντέλο για την επεξεργασία ενός συνόλου δεδομένων.

Τέλος, μία σημαντική μετρική αποτελούν οι μετρήσεις από το πεδίο οπτικής δικτύωσης. Εκτός από τις αριθμητικές και γραφικές μετρήσεις που χρησιμοποιούνται παραδοσιακά κατά τη χρήση της μηχανικής μάθησης, μπορούν να αξιοποιηθούν και μετρήσεις από το πεδίο δικτύωσης, προκειμένου να κατανοηθεί ποσοτικά πώς ο αλγόριθμος μηχανικής μάθησης επηρεάζει το οπτικό δίκτυο/σύστημα. Για παράδειγμα, ένας χειριστής μπορεί να ενδιαφέρεται για τον ελάχιστο αριθμό οθονών οπτικής απόδοσης που θα αναπτυχθούν κατά μήκος ενός φωτεινού μονοπατιού για τη σωστή ταξινόμηση μιας υποβαθμισμένης μετάδοσης με δεδομένη ακρίβεια. Ομοίως, το ελάχιστο επίπεδο ισχύος OSNR ή/και σήματος που απαιτείται σε έναν οπτικό δέκτη για την ορθή αναγνώριση του εγκεκριμένου MF. Επιπλέον, ένας χειριστής μπορεί επίσης να αναρωτηθεί πόσο συχνά πρέπει να συλλέγονται δείγματα BER για να προβλέψουν ή να εντοπίσουν σωστά μια οπτική αστοχία κατά μήκος ενός φωτεινού μονοπατιού με μια ορισμένη ακρίβεια.

6. 4. 2 Ποσοτική σύγκριση αλγορίθμων

Στη συγκεκριμένη ενότητα παρουσιάζεται μια σχηματική σύγκριση ορισμένων αλγορίθμων μηχανικής μάθησης, η οποία βασίζεται σε μερικές από τις περιπτώσεις χρήσης (use cases) που αναφέρθηκαν σε προηγούμενες ενότητες, χρησιμοποιώντας σε κάθε περίπτωση το ίδιο σύνολο δεδομένων ως είσοδο[99]. Σε κάθε περίπτωση μια δίκαιη ποσοτική σύγκριση μεταξύ αλγορίθμων σε διαφορετικά έγγραφα θα είχε μεγάλο βαθμό δυσκολίας λόγω του γεγονότος ότι, σε κάθε use case, οι διάφοροι αλγόριθμοι έχουν σχεδιαστεί για να ταιριάζουν με το συγκεκριμένο διαθέσιμο σύνολο δεδομένων κάθε φορά. Κατά συνέπεια, ένας δεδομένος αλγόριθμος μπορεί να έχει απίστευτα καλή απόδοση εάν εφαρμοστεί σε ένα συγκεκριμένο σύνολο δεδομένων, αλλά ταυτόχρονα μπορεί να παρουσιάζει κακή απόδοση στην περίπτωση που το σύνολο δεδομένων αλλάξει.

Περίπτωση Χρήσης (Use Case)	Αλγόριθμοι χρήσης	Μετρικές	Αποτελέσματα Συγκρίσεων
Εκτίμηση QoT (Ταξινόμηση BER)	Naive Bayes, Δέντρο Απόφασης, RF, J4.8 tree, CBR	Ακρίβεια, Ψευδώς Θετικά	Το CBR έχει μεγαλύτερη ακρίβεια (99%) με πολύ χαμηλά ψευδώς θετικά(0.43), το Δέντρο Απόφασης φτάνει το μικρότερο ποσοστό σε ψευδώς θετικά σε τιμή όμως χαμηλότερης ακρίβειας (86%)
Εκτίμηση QoT (Ταξινόμηση BER)	KNN, RF	Ακρίβεια, AUC, χρόνος εκτέλεσης	Το RF έχει μεγαλύτερο AUC και ακρίβεια από το KNN αλλά ο χρόνος δοκιμής είναι τουλάχιστον μία τάξη μεγέθους χαμηλότερος από το RNN
Εκτίμηση QoT (Ταξινόμηση BER)	KNN, RF, SVM	Ακρίβεια, Πίνακας Σύγκυσης, καμπύλες ROC	Το SVM έχει την καλύτερη ακρίβεια ανάμεσα στους τρεις αλγόριθμους ML, η ακρίβεια βελτιώνεται με το μέγεθος της Γνωσιακής Βάσης (KB)
Διαχείριση Αποτυχίας	Μπασειανή συμπερασματολογία, EM	Πίνακας Σύγκυσης	Η ανίχνευση αποτυχίας που βασίζεται στη μάθηση από τις παραμέτρους του δικτύου, είναι πιο ακριβής σε σύγκριση με την περίπτωση που ένας ειδικός καθορίζει τις παραμέτρους με βάση ορισμένους ντετερμινιστικούς κανόνες.
Διαχείριση Αποτυχίας	NN, RF, SVM	Ακρίβεια σε σύγκριση με παραμέτρους μοντέλου (χρόνος δειγματοληψίας BER, ποσότητα δεδομένων BER)	Με τις σωστές παραμέτρους μοντέλων, το δυαδικό SVM μπορεί να φτάσει 100% ακρίβεια για διαχείριση αποτυχίας
Ταξινόμηση Ροής	HMM, EM	Πιθανότητα λάθους ταξινόμησης (παρομοίως με FPR)	Το HMM έχει καλύτερη ακρίβεια και έχει μικρότερη πιθανότητα λάθους ταξινόμησης για στατικό τύπο κίνησης σε σύγκριση με τον δυναμικό, η πιθανότητα λάθους ταξινόμησης μειώνεται επίσης αυξάνοντας τον αριθμό μήκους κύματος ανά link.

Πίνακας 3. Σύγκριση αλγορίθμων μηχανικής μάθησης και μετρικών απόδοσης για διάφορες περιπτώσεις χρήσης

ΚΕΦΑΛΑΙΟ 7^ο – ΣΥΜΠΕΡΑΣΜΑΤΑ-ΜΕΛΛΟΝΤΙΚΕΣ ΕΞΕΛΙΞΕΙΣ

7. 1 Μελλοντικές εξελίξεις

Η ερευνητική δραστηριότητα των επιστημόνων θα μπορούσε να επεκταθεί τα επόμενα χρόνια εστιάζοντας σε συγκεκριμένους τομείς οι οποίοι παρουσιάζουν ιδιαίτερο ενδιαφέρον από άποψη τεχνολογίας.

Ένας τομέας είναι εκείνος των μεθολογιών της μηχανικής μάθησης που χρησιμοποιούνται στις διάφορες μελέτες. Παρατηρείται σε συχνή βάση, ότι οι αλγόριθμοι μηχανικής μάθησης συνήθως της επιβλεπόμενης μάθησης που χρησιμοποιούνται σε οπτικά δίκτυα εκπαιδεύονται έχοντας ως είσοδο τις περισσότερες φορές ιστορικά δεδομένα γεγονός που δεν οδηγεί στη σωστή λήψη αποφάσεων. Αυτό έχει ως συνέπεια, τα αποτελέσματα να μην είναι ρεαλιστικά όσο αναφορά τα δίκτυα οπτικών επικοινωνιών καθώς εκεί τα διάφορα σενάρια που εκτυλίσσονται είναι δυναμικά λόγω των συχνών αλλαγών που συμβαίνουν στη συμπεριφορά των οπτικών στοιχείων εξαιτίας της φθοράς που υπόκεινται με την πάροδο του χρόνου. Μία καλή λύση για το πρόβλημα της ιστορικότητας των δεδομένων εισόδου θα ήταν η δημιουργία και έπειτα η εφαρμογή άλλων τύπων αλγορίθμων όπως της ημι-επιβλεπόμενης και μη μηχανικής μάθησης, μετά το πέρας της εκπαίδευσης αλγορίθμων με παρελθοντικά δείγματα ώστε να είναι δυνατή η λήψη δεδομένων εισόδου τα οποία προκύπτουν από το επίπεδο ελέγχου του δικτύου[99].

Εναλλακτικά, θα μπορούσε να διερευνηθεί περαιτέρω η επανεκπαίδευση των μηχανισμών επίβλεψης ώστε να μπορεί να επεκταθεί η εφαρμογή τους σε υποδομές δικτύου διαφορετικής αρχιτεκτονικής όπου η εκπαίδευση σε συγκεκριμένες τοπολογίες μπορεί να μην είναι κατάλληλη σε σχέση με άλλες. Για το λόγο αυτό, αναπτύχθηκαν νέες τεχνικές μηχανικής μάθησης ώστε να αντιμετωπίσουν και τελικά να επιλύσουν προβλήματα της οπτικής δικτύωσης που μπορεί να προκύψουν κατά τη διάρκεια. Ένα επιπλέον χρήσιμο χαρακτηριστικό, θα ήταν η ανάπτυξη ενεργών αλγορίθμων μηχανικής μάθησης με σκοπό την παραγωγή ερωτήσεων αλληλεπιδραστικά στον χρήστη ώστε να τον βοηθήσουν να λάβει

καλύτερα δεδομένα εκπαίδευσης με βάση συγκεκριμένα χαρακτηριστικά. Έτσι, το πλήθος των δειγμάτων που απαιτούνται για την ανάπτυξη ενός μοντέλου πρόβλεψης που χαρακτηρίζεται από ακρίβεια μπορεί να μειωθεί αρκετά, γεγονός που μπορεί να μειώσει σε σημαντικό βαθμό το πλήθος των πόρων που απαιτούνται σε περίπτωση που η διαδικασία δημιουργίας πλήθους δεδομένων για εκπαίδευση παρουσιάζει μεγάλο κόστος όπως για παράδειγμα, στην περίπτωση ανάπτυξης αισθητήρων στα διάφορα lightpaths[99].

Ο προσδιορισμός των χρονοδιαγραμμάτων είναι ο επόμενος τομέας που θα αναλυθεί καθώς μέχρι στιγμής έχει αφιερωθεί ελάχιστη προσοχή στις εφαρμογές που ενδέχεται να διαφέρουν έχοντας πολύ διαφορετικά χρονοδιαγράμματα, καθώς τα δεδομένα που προκύπτουν από την παρακολούθησή τους δείχνουν μεγάλο ενδιαφέρον με αποτέλεσμα να μπορούν να οδηγήσουν σε χρήσιμες αλλαγές του μοτίβου. Τέτοιες αλλαγές μπορεί να προκύψουν από τη φθορά λόγω του χρόνου, η οποία θα μπορούσε να μεταβάλλει τη συμπεριφορά ενός στοιχείου με πολύ αργό ρυθμό, ενώ η συχνότητα στην αλλαγή της κίνησης επηρεάζει το ίδιο στοιχείο με ταχύτερο ρυθμό, και σε διαφορετικά χρονοδιαγράμματα όπως για παράδειγμα ριπές σε χρονικό επίπεδο ημέρας, εβδομάδας και έτους. Η κατανόηση και επιλογή του σωστότερου χρονοδιαγράμματος για την παρακολούθηση των παραμέτρων, με τις οποίες θα πρέπει να τροφοδοτηθούν οι αλγόριθμοι μηχανικής μάθησης, καθίσταται σημαντική για το σκοπό της βελτιστοποίησης της ακρίβειας του αλγορίθμου και συνεπώς της απόδοσης ολόκληρου του συστήματος[99].

Επίσης ο σωστός προσδιορισμός των χρονοδιαγραμμάτων είναι σημαντικός όσο αναφορά την ποσοτική διάσταση του εύρους ζώνης ελέγχου και της παρακολούθησης που απαιτείται ώστε να εφαρμοστεί ένα σύστημα μηχανικής μάθησης[95]. Παρόλο που η εκτέλεση ενός αλγορίθμου μηχανικής μάθησης μπορεί να γίνει απρόσκοπτη και επιτυχημένη, στην περίπτωση που απαιτηθεί μία πολύ μεγάλη ποσότητα δεδομένων η οποία απαιτεί συχνή δειγματοληψία, τότε το επιπλέον εύρος ζώνης ελέγχου που χρειάζεται θα προκαλέσει προβλήματα στην πρακτική εκτέλεση του αλγορίθμου.

Ένας ακόμη τομέας που χρήζει μεγαλύτερης ανάλυσης είναι εκείνος της ύπαρξης ενός πλήρους γνωστικού συστήματος ελέγχου. Οι υπάρχουσες λύσεις που

Βασίζονται σε αλγορίθμους μηχανικής μάθησης παρουσιάζουν συγκεκριμένα ζητήματα στην οπτική δικτύωση και γενικότερα στις οπτικές επικοινωνίες. Είναι τεχνολογικά αποδεκτό ότι η δικτύωση ορισμένη από το λογισμικό είναι ικανή με μεγάλη επιτυχία να συντονίσει τον έλεγχο κατά μήκος πολλαπλών επιπέδων δικτύου και διαφορετικών τεχνολογιών. Στο πλαίσιο αυτό, ένας ενιαίος έλεγχος θα μπορούσε επίσης να συντονίσει πολλές και διαφορετικές εφαρμογές μηχανικής μάθησης, με σκοπό την παροχή ολιστικού σχεδιασμού που θα οδηγήσουν τελικά στην ευελιξία των οπτικών δικτύων[99].

Στην πραγματικότητα, οι αλγόριθμοι μηχανικής μάθησης μπορούν να χρησιμοποιηθούν προκειμένου να εκτιμήσουν διαφορετικά χαρακτηριστικά του συστήματος τα οποία ανήκουν σε διαφορετικά επίπεδα, όπως το QoT(Quality of Things) προσφέροντας σημαντικές λύσεις τόσο σε συμβάντα αποτυχίας όσο και σε μοτίβα κυκλοφορίας. Η εξάρτηση πολλών από τα παραπάνω είναι αμοιβαία όπως για παράδειγμα το QoT ενός lightpath που σχετίζεται σε μεγάλο βαθμό με την ύπαρξη απωλειών κατά μήκος της σύνδεσής του ή στους κόμβους του ενώ υπάρχουν και άλλα που δεν παρουσιάζουν εξάρτηση όπως για παράδειγμα τα μοτίβα κυκλοφορίας και οι διακυμάνσεις τους, τα οποία τις περισσότερες φορές δεν εμφανίζουν καμία εξάρτηση όσο αναφορά την τρέχουσα κατάσταση του εξοπλισμού μετάδοσης[96].

Ένας τομέας που χρειάζεται να διερευνηθεί περαιτέρω είναι η αξιολόγηση των πλεονεκτημάτων που παρουσιάζουν τα ενοποιημένα πλαίσια ελέγχου που βασίζονται σε μηχανική μάθηση, όπου όλες οι εκάστοτε εκτιμώμενες μεταβλητές μπορούν να συντελέσουν στην καλύτερη λήψη μιας απόφασης όπως για παράδειγμα η δρομολόγηση ενός νέου lightpath όπως για παράδειγμα η εκχώρηση φάσματος, η επαναδρομολόγηση ενός υπάρχοντος, ή ο προγραμματισμός τροποποίησης των παραμέτρων μετάδοσης όπως οι μορφές διαμόρφωσης και οι ρυθμοί μετάδοσης των συμβόλων.

Ο τομέας της οπτικοποίησης είναι ο επόμενος τομέας που χρειάζεται περαιτέρω μελέτη. Η ανάπτυξη αποτελεσματικών μεθόδων και εργαλείων οπτικοποίησης, με σκοπό να οπτικοποιηθούν οι πληροφορίες εξόδου των αλγορίθμων μηχανικής μάθησης ώστε να γίνουν επεξεργάσιμες και κατανοητές σε

όλους τους χρήστες αποτελεί βασικό παράγοντα για την συνεχή ενσωμάτωση των τεχνικών μηχανικής μάθησης στα πλαίσια διαχείρισης του οπτικού δικτύου[98]. Παρόλο που έχουν γίνει κάποια αρχικά ερευνητικά βήματα για την κάλυψη της κατεύθυνσης αυτής, χρειάζεται ακόμα να εφευρεθούν κατευθυντήριες προσεγγίσεις στον τομέα της οπτικοποίησης με σκοπό την παρακολούθηση δικτύου ή τον εντοπισμό αστοχιών.

Ο τομέας της εμπορευματοποίησης και της τυποποίησης παρουσιάζει αυξητικό ενδιαφέρον αν και το έδαφος δεν είναι ακόμα γόνιμο. Οι εφαρμογές της μηχανικής μάθησης στην οπτική δικτύωση έχουν κερδίσει το ενδιαφέρον των χειριστών αλλά και των πωλητών εξοπλισμού οπτικών δικτύων, και αναμένεται ακόμη μεγαλύτερη αύξηση του ενδιαφέροντος στο κοντινό μέλλον. Πολλές έρευνες έχουν επικεντρωθεί στη βελτιστοποίηση της εκτίμησης του QoT προκειμένου να επέλθει μείωση του κατωφλιού και στην αναδρομολόγηση λαμβάνοντας υπ' όψη μεταξύ άλλων τα σφάλματα που αφορούν τον σχεδιασμό του οπτικού δικτύου με χαμηλά κατώφλια, την πρόβλεψη κίνησης και την έρευνα ανωμαλιών στα οπτικά δίκτυα. Επιπλέον, οργανισμοί τυποποίησης ξεκίνησαν την έρευνα για την εφαρμογή της μηχανικής μάθησης με σκοπό την επίλυση προβλημάτων δικτύωσης αν και προς το παρών η έρευνα για το συγκεκριμένο τομέα βρίσκεται σε πρώιμα στάδια.

Ένας σημαντικός τομέας που χρειάζεται να επεκταθεί είναι εκείνος της διαθεσιμότητας των δεδομένων. Μέχρι στιγμής, οι διάφοροι ερευνητές και φορείς εκμετάλλευσης δεν έχουν ακόμη ανακαλύψει το μεγάλο εύρος δεδομένων πεδίου ώστε να δοκιμαστεί η λειτουργικότητα των υφιστάμενων λύσεων. Το συγκεκριμένο πρόβλημα μπορεί αρχικά να αντιμετωπιστεί με προσομοιώσεις σχετικών γεγονότων, όπως για παράδειγμα αποτυχίες, αστοχίες ή υποβαθμίσεις σήματος και έπειτα μέσω testbeds οπτικού δικτύου, ακόμα και σε περιπτώσεις που η αναπαραγωγή της ποικιλομορφίας των σεναρίων ενός πραγματικού δικτύου στο περιβάλλον του εργαστηρίου καθίσταται αδύνατη. Επιπρόσθετα, ακόμη και σε καταστάσεις όπου υπάρχει πρόσβαση σε πραγματικά δεδομένα, για ορισμένες από τις προαναφερθείσες περιπτώσεις χρήσης, καθίσταται δύσκολη η εκτεταμένη συλλογή συνόλων δεδομένων κατά τη διάρκεια συνθηκών όπου συμβαίνουν σφάλματα στη λειτουργία. Δεδομένου ότι η διάσταση και η διαχείριση των δικτύων γίνεται μέσω

συντηρητικών προσεγγίσεων σχεδιασμού, η πιθανότητα αστοχίας καθίσταται αμελητέα έως και μηδενική.

Ένας από τους πιο σημαντικούς τομείς που χρειάζεται να επεκταθεί είναι εκείνος της ανάνηψης σε περίπτωση αποτυχίας. Η εφαρμογή της μηχανικής μάθησης σε συνδυασμό με έλεγχο μέσω της δικτύωσης που είναι ορισμένη από λογισμικό (SDN) μπορεί να οδηγήσει σε ταχύτερη ανάνηψη του δικτύου αντιμετωπίζοντας ευκολότερα και σε γρήγορο χρονικό διάστημα σφάλματα και αποτυχίες. Τα εργαλεία ελέγχου που χρησιμοποιούνται σε ένα οπτικό δίκτυο έχουν διαμορφωθεί σε συστήματα τα οποία στηρίζονται σε κανόνες, όπως για παράδειγμα ικανοποιώντας τη σχέση [IF <συνθήκες> THEN <ενέργειες>], καλύπτοντας έτσι διάφορα σενάρια αποτυχίας[97].

Το μοναδικό ίσως μειονέκτημα των κανόνων αυτών είναι η εξειδίκευση και ο αριθμός τους, με αποτέλεσμα να μην μπορούν να καλύψουν και να αντιμετωπίσουν όλες τις πιθανές περιπτώσεις δυσλειτουργίας. Η εφαρμογή της μηχανικής μάθησης στη συγκεκριμένη περίπτωση, εκτός από την ικανότητα να συλλέγει δεδομένα όλων των επιπέδων του δικτύου, θα μπορούσε να χρησιμοποιήσει διαδικασίες Gauss, κατανομές πιθανότητας εξόδου στη θέση συγκεκριμένων αριθμητικών και κατηγορικών τιμών με σκοπό την παροχή έτσι περισσότερων πληροφοριών σε σχέση με μοντέλα που στηρίζονται σε κατώφλι.

7.2 Συμπεράσματα

Το τελευταίο χρονικό διάστημα, η εξέλιξη των οπτικών δικτύων είναι διαρκής και εκτεταμένη. Η εισαγωγή νέων πολλά υποσχόμενων τεχνολογιών όπως της δικτύωσης ορισμένης από λογισμικό(SDN), της σύμφωνης μετάδοσης και του flexible grid έχει ωφελήσει τους ερευνητές και έχει δημιουργήσει γόνιμο έδαφος για τη δημιουργία πολλών υποσχόμενων μελλοντικών καινοτομιών στην οπτική δικτύωση. Επιπλέον, ο ταυτόχρονος τεχνικός σχεδιασμός σε συνδυασμό με την εκτεταμένη πρόοδο της απόδοσης hardware και του software, που ενσωματώνονται σε μια πλατφόρμα SDN οδηγούν στη δημιουργία γόνιμων συνθηκών για περαιτέρω έρευνα.

Η ανάπτυξη προηγμένων αλγορίθμων μηχανικής μάθησης έχει οδηγήσει τους ερευνητές να χρησιμοποιήσουν μεγάλο όγκο δεδομένων, τα οποία προκύπτουν από τα στοιχεία παρακολούθησης του δικτύου, προκειμένου τα δίκτυα να οδηγηθούν σε μεγαλύτερη ευελιξία και προσαρμοστικότητα. Έχει ήδη αρχίσει η διερεύνηση της εφαρμογής αλγορίθμων μηχανικής μάθησης προκειμένου να καταλήξουμε στην δημιουργία έξυπνων οπτικών δικτύων με τα μέχρι τώρα αποτελέσματα να δείχνουν ενθαρρυντικά[99].

BIBΛΙΟΓΡΑΦΙΑ

- [1] John Crisp – Barry Elliott, “Introduction to Fiber Optics, Third Edition”, 2005
- [2] [www. signalbooster. com/blogs/news/fiber-optic-cable-construction-and-types-available](http://www.signalbooster.com/blogs/news/fiber-optic-cable-construction-and-types-available)
- [3] [www. datatronix. com/DT_Singlemode_vs_Multimode_Optical_Fibre](http://www.datatronix.com/DT_Singlemode_vs_Multimode_Optical_Fibre)
- [4] [www. brainkart. com/article/Difference-between-Step-Index-fiber-and-Graded-Index-fiber](http://www.brainkart.com/article/Difference-between-Step-Index-fiber-and-Graded-Index-fiber)
- [5] Measurement of Attenuation of the Optical Fiber ‘A bdulrahman Suratman 1, Ong Sin Yee 2, Nurul Shafikah Mohd Zain 3, Mohamud Mire 4 Radar Communication Laboratory, Faculty of Electrical EngineeringUniversiti Teknologi Malaysia, 81310 Skudai, Johor, Malaysia
- [6] An experiment to measure Mie and Rayleigh total scattering cross sections A. J. Cox, Alan J. DeWeerd, a) and Jennifer Linden Department of Physics, University of Redlands, Redlands, California 92373 ~Received 9 July 2001; accepted 7 February 2002
- [7] A. Yariv, D. Fekete, D . M. Papper, “Compensation for channel dispersion by non-linear phase conjugation”, Optics Letters, Vol. 4, No. 2, pp. 52-54, 1979
- [8] NONLINEAR SCATTERING EFFECTS IN OPTICAL FIBERS S. P. Singh, R. Gangwar, and N. Singh Department of Electronics and Communication University of Allahabad Allahabad-211002, India
- [9] Govind P. Agrawal, in Nonlinear Fiber Optics (Sixth Edition), 2019
- [10] International Journal of Scientific and Research Publications, Volume 2, Issue 12, December 2012 1 ISSN 2250-3153 Different Types of Dispersions in an Optical Fiber N. Ravi Teja, M. Aneesh Babu, T. R. S. Prasad, T. Ravi
- [11] PMD fundamentals: Polarization mode dispersion in optical fibers J. P. Gordon and H. Kogelnik
- [12] Book: Overview of Nonlinear Optics Elsa Garmire Dartmouth College, USA
- [13] Optical Nonlinearities in Fibers: Review, Recent Examples, and Systems Applications J. Toulouse

[14]]Y. M. Liu, A. J. Antos, “Dispersion-shifted large-effective-area fiber for amplified high-capacity longdistance systems,” Optical Fiber Communication '97, pp. 69, 1997.

[15] A. J. Lucero, S. Tsuda, V. L. da Silva, “320Gbits/sec WDM transmission over 450Km of LEAF optical fiber,” Optical Fiber Communication '99, paper ThO2-1, pp. 215, 1999.

[16]Book Artificial Intelligence: A Modern Approach Paperback – January 1, 2015 by Russell (Author)

[17] Shovan Chowdhury, Marco P. Schoen, “Research Paper Classification using Supervised Machine Learning Techniques”

[18] Classification Based on Decision Tree Algorithm for Machine Learning Bahzad Taha Jijo, Adnan Mohsin Abdulazeez

[19] D. Sony, “Introduction to Naive Bayes Classification”, 2018.

[20] S. Patel, “Chapter 2 : SVM (Support Vector Machine) - Theory”, 2017.

[21] Research and Implementation of Machine Learning Classifier Based on KNN Lishan Wang Fujian Normal University, Fuzhou 350108, China

[22] L. K. Saul and S. T. Roweis. “Think Globally, Fit Locally: Unsupervised Learning of Low Dimensional Manifolds. ” Journal of Machine Learning Research 4 (2003), 119-155.

[23] Unsupervised Machine Learning for Networking: Techniques, Applications and Research Challenges MUHAMMAD USAMA , JUNAID QADIR , AUNN RAZA, HUNAIN ARIF, KOK-LIM ALVIN YAU , YEHIA ELKHATIB , AMIR HUSSAIN, AND ALA AL-FUQAHA

[24]Sugata Basu, “Semi-supervised Clustering: Probabilistic Models, Algorithms and Experiments”, Doctoral Thesis, University of Texas, Austin, August 2005

[25]] Xiaojin Zhu, John Lafferty, Zoubin Ghahramani, “Combining Active Learning and Semi-Supervised Learning Using Gaussian Fields and Harmonic Functions, ” Proceedings of the ICML-2003 Workshop on The Continuum from Labelled to Unlabelled Data, Washington DC, 2003.

[26] Gregory Druck, Chris Pal, Xiaojin Zhu, Andrew McCallum, “Semi-Supervised Classification with Hybrid Generative/Discriminative Methods”, KDD’07, August 12–15, 2007, San Jose, California, USA.

[27] Self-Training With Progressive Representation Enhancement for Unsupervised Cross-Domain Person Re-Identification Hang Zhang, Huanhuan Cao, Xu Yang, Student Member, IEEE, Cheng Deng, Senior Member, IEEE, and Dacheng Tao, Fellow, IEEE

[28] Y. Chen, T. Pan, and S. Chen, “Development of co-training support vector machine model for semi-supervised classification, ” in 2017 36th Chinese Control Conference (CCC), pp. 11077–11080, July 2017.

[29] Z. H. Zhou and M. Li, Tri-Training: Exploiting Unlabeled Data Using Three Classifiers, IEEE Transactions on Knowledge and Data Engineering, 2005, 17(11):1529-1541.

[30] Khan E. Reinforcement control with unsupervised learning [A]. Int. Joint Conference on Neural Network [C], Beijing, 1992, 88 – 93.

[31] Learning Structures for Deep Neural Networks Jinhui Yuan, Fei Pan, Chunting Zhou, Tao Qin, Tie-Yan Liu

[32] Understanding the Feedforward Artificial Neural Network Model From the Perspective of Network Flow Dawei Dai, Weimin Tan, Hong Zhan

[33] Yee L. , Chen K. Z. , Gao X. B. (2003) A high-performance feedback neural network for solving convex nonlinear programming problems. IEEE Transactions on Neural

[34] Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain.

[35] Application of Multi layer (Perceptron) Artificial Neural Network in the Diagnosis System: A Systematic Review Arti Rana Arvind Singh Rawat Anchit Bijalwan Himanshu Bahuguna

[36] Shallow Neural Network can Perfectly Classify an Object following Separable Probability Distribution Youngjae Min, Hye Won Chung

[37] NON-DEEP NETWORKS Ankit Goyal, Alexey Bochkovskiy, Jia Deng, Vladlen Koltun, Princeton University, Intel Labs

- [38] Deep Learning in Neural Networks: An Overview Juergen Schmidhuber
- [39] Multilayer Perceptron: Architecture Optimization and Training Hassan Ramchoun, Mohammed Amine Janati Idrissi, Youssef Ghanou, Mohamed Ettaouil
- [40] Recurrent Neural Network TINGWU WANG, MACHINE LEARNING GROUP, UNIVERSITY OF TORONTO FOR CSC 2541, SPORT ANALYTICS
- [41] An overview and comparative analysis of Recurrent Neural Networks for Short Term Load Forecasting Filippo Maria Bianchi, Enrico Maiorino, Michael C. Kampffmeyer, Antonello Rizzi, Robert Jenssen
- [42] Understanding LSTM -- a tutorial into Long Short-Term Memory Recurrent Neural Networks Ralf C. Staudemeyer, Eric Rothstein Morris
- [43] Face Recognition across Time Lapse Using Convolutional Neural Networks Hachim El Khiyari, Harry Wechsler
- [44] An Optimized Architecture of Image Classification Using Convolutional Neural Network Muhammad Aamir, Ziaur, Yihuan Road, Chengdu, Waheed Ahmed Abro, Muhammad Tahir, Syed Mustajar Ahmed
- [45] Novel Convolution Kernels for Computer Vision and Shape Analysis based on Electromagnetism Dominique Beainia, Sofiane Achichea, Yann-Seing Law-Kam Cioa, Maxime Raison
- [46] Review of deep learning: concepts, CNN architectures, challenges, applications, future directions Laith Alzubaidi, Jinglan Zhang, Amjad J. Humaidi, Ayad Al-Dujaili, Ye Dua
- [47] A Gentle Introduction to Exploding Gradients in Neural Networks by Jason Brownlee on December 18, 2017 in Long Short-Term Memory Networks
- [48] Understanding Gradient Clipping In Incremental Gradient Methods Jiang Qian Yuren Wu Bojin Zhuang Shaojun Wang Jing Xiao
- [49] Feature selection, L1 vs. L2 regularization, and rotational invariance Andrew Y. Computer Science Department, Stanford University, Stanford, CA 94305
- [50] NEURAL NETWORKS AND BACK PROPAGATION ALGORITHM Vladislav Skorpil, Jiri Stastny
- [51] An overview of gradient descent optimization algorithms, Sebastian Ruder

[52] The Challenge of Vanishing/Exploding Gradients in Deep Neural Networks
download Share Yash Bohra — June 18, 2021

[53] How to Train Your Neural Network: A Comparative Evaluation Shu-Huai
Lin, Daniel Nichols, Siddharth Singh, Abhinav Bhatele

[54] Learning representations by back-propagating errors David E. Rumelhart,
Geoffrey E. Hinton & Ronald J. Williams

[55] BACKPROPAGATION GENERALIZED DELTA RULE FOR THE SELECTIVE
ATTENTION SIGMA-IF ARTIFICIAL NEURAL NETWORK MACIEJ HUK Institute of
Informatics Wrocław University of Technology, Wyb. Wyspiańskiego 27, 50-370
Wrocław, Poland

[56] Unsupervised Learning Based On Artificial Neural Network: A Review,
Happiness Ugochi Dike; Yimin Zhou; Kranthi Kumar Deveerasetty; Qingtian Wu

[57] Learning How to Self-Learn: Enhancing Self-Training Using Neural
Reinforcement Learning Chenhua Chen, Yue Zhang

[58] Appeared in Neural Networks 1998 Automatic Early Stopping Using Cross
Validation: Quantifying the Criteria Lutz Prechelt Universit Karlsruhe Germany

[59] An Overview on Application of Machine Learning Techniques in Optical
Networks Francesco Musumeci, Member, IEEE, Cristina Rottondi, Member, IEEE,
Avishek Nag, Member, IEEE, Irene Macaluso, Darko Zibar, Member, IEEE, Marco
Ruffini, Senior Member, IEEE, and Massimo Tornatore, Senior Member, IEEE

[60] Analyses of the Key Technologies and Development Trends of Optical
Networks from the Perspective of Standard Essential Patents by Shu-Hao Chang

[61] K. Zhu and B. Mukherjee, «Traffic grooming in an optical WDM mesh
network, » IEEE Journal on Selected Areas in Communications, vol. 20, no 1, p. pp.
122–133, Jan 2002.

[62] Future Optical Networks in a 10 Year Time Frame Andrew Lord, Catherine
White, and Asif Iqbal

[63] Four-Wave Mixing in Optical Fibers and Its Applications by Osamu Aso,
Masateru Tadakuma and Shu Namiki

[64] I. Neokosmidis, T. Kamalakis, A. Chipouras, and T. Sphicopoulos, “New
techniques for the suppression of the four-wave mixing-induced distortion in nonzero

dispersion fiber WDM systems, " IEEE Journal of Lightwave Technology, vol. 23, pp. 1137, 2005.

[65] F. Forghieri, R. W. Tkach, and A. R. Chraplyvy, "WDM systems with unequally spaced channels, " IEEE Journal of Lightwave Technology, vol. 13, pp. 889, 1995.

[66] Stimulated Brillouin Scattering Thresholds in Optical Fibers for Lasers Linewidth Broadened with Noise V. R. Supradeepa OFS Laboratories, 19 Schoolhouse Road, suite 105, Somerset, NJ 08873, USA

[67] R. Ramaswami, K. N. Sivarajan, Optical Networks: A practical perspective, Morgan Kaufmann Publishers, Second Edition, 2002

[68] Recent Advances in Equalization Technologies for Short-Reach Optical Links Based on PAM4 Modulation: A Review Honghang Zhou, Yan Li *, Yuyang Liu, Lei Yue, Chao Gao, Wei Li, Jifang Qiu, Hongxiang Guo, Xiaobin Hong, Yong Zuo and Jian Wu *

[69] Zhou, H. Li, Y. Lu, D. Yue, L. Gao, C. Liu, Y. Hao, R. Zhao, Z. Li, W. ; Qiu, J. et al. Joint clock recovery and feed-forward equalization for PAM4 transmission. Opt. Express 2019, 8, 11385–11395.

[70] Chen, G. ; Du, J. ; Sun, L. ; Zhang, W. ; Xu, K. ; Chen, X. ; Reed, G. T. ; He, Z. Nonlinear Distortion Mitigation by Machine Learning of SVM Classification for PAM-4 and PAM-8 Modulated Optical Interconnection. J. Lightw. Technol. 2018, 3, 650–657

[71] Coherent-Lite for beyond 400GbE 07/20/2021 IEEE 802. 3 B400G SG Meeting Cedric Lam, Xiang Zhou, and Hong Liu

[72] Technology Options for 400G Implementation OIF-Tech-Options-400G-01. 0 July 2015

[73] 400G Everywhere Using the latest generation of coherent optics to build application-optimized IP-optical networks

[74] Challenges-and-Opportunities-of-Transitioning-to-400G-White-Paper

[75] J. M. Kahn and K. -P. Ho, "Spectral efficiency limits and modulation/detection techniques for DWDM Systems, J. Sel. Top. Quantum Electron. 10, 259–271 (2004)

[76] V. Jungnickel, A. Forck, T. Haustein, S. Schiffermuller, C. Helmolt, F. Luhn, M. Pollock, C. Juchems, M. Lampe, S. Eichnger, W. Zirwas, E. Schulz, "1 Gbit/s MIMO-OFDM transmission experiments, " in Proceedings of IEEE Conference on Vehicular Technol. (Institute of Electrical and Electronics Engineers, Dallas, 2005), pp. 861–866

[77] G. Bosco et al. , "On the Performance of Nyquist-WDM Terabit Superchannels Based on PM-BPSK, PM-QPSK, PM-8QAM or PM-16QAM Subcarriers, " J. Lightwave Tech. , vol. 29, no. 1, Jan. , 2011, pp. 53–61

[78] ITU-T Rec. G. 694. 1, "Spectral Grids for WDM Applications: DWDM Frequency Grid. "

[79] X. Liu and S. Chandrasekhar, "Superchannel for Next Generation Optical Networks, " W1H. 5, OFC 2014.

[80] M. Mitchell et al, "Optical Integration and Multi-Carrier Solutions for 100G and Beyond, " Optical Fiber Tech. , vol. 17, 2011, pp. 412–20

[81] Learning Activation Functions to Improve Deep Neural Networks Forest Agostinelli, Matthew Hoffman, Peter Sadowski, Pierre Baldi

[82] ACTIVATION FUNCTIONS IN NEURAL NETWORKS Siddharth Sharma, Simone Sharma UG Scholar, Dept. of Computer Science and Engineering, Global Institute of Technology, Jaipur Anidhya Athaiya Assistant Professor, Dept. of Computer Science and Engineering, Global Institute of Technology, Jaipur

[83] The Vanishing Gradient Problem During Learning Recurrent Neural Nets and Problem Solutions Sepp Hochreiter Johannes Kepler University Linz

[84] Optical Networks A Practical Perspective Third Edition Rajiv Ramaswami Kumar N. Sivarajan Galen H. Sasaki

[85] J. T. M. P. R. J. a. D. Z. J. Wass, «Gaussian Process Regression for WDM System Performance Prediction, » Optical Fiber Communication Conference (OFC), March 2017.

[86] <https://www.fiberlabs.com/glossary/erbium-doped-fiber-amplifier>

[87] Erbium doped fiber amplifier (EFDA) development for long haul optical fiber communication system structure and characteristic of the semiconductor optical amplifier in optical fiber communication system S. M. Idrus, H. Lim, Han Yoong Looi Published 2008

[88] Machine-Learning Method for Quality of Transmission Prediction of Unestablished Lightpaths Cristina Rottondi, Luca Barletta, Alessandro Giusti, and Massimo Tornatore

[89] Optical Performance Monitoring D. C. Kilper, R. Bach, D. J. Blumenthal, D. Einstein, T. Landolsi, L. Ostar, M. Preiss, and A. E. Willner

[90] K. Zhu and B. Mukherjee, «Traffic grooming in an optical WDM mesh network» IEEE Journal on Selected Areas in Communications, vol. 20, no 1, p. pp. 122–133, Jan 2002.

[91] A. Castro, «Dynamic routing and spectrum (re)allocation in future flexgrid optical networks, vol. 56, » Computer Networks, pp. pp. 2869-2883, 2012.

[92] Machine Learning for Failure Management in Optical Networks, Francesco Musumeci, Optical Fiber Communication Conference 2021 Washington, DC United States 6–11 June 2021

[93] Traffic prediction based on machine learning for elastic optical networks, Michal Aibin British Columbia Institute of Technology

[94] A Survey on Machine Learning for Optical Communication [Machine Learning View] M. A. Amirabadi

[95] Machine learning techniques for quality of transmission estimation in optical networks Yvan Pointurier

[96] Machine Learning for Intelligent Optical Networks: A Comprehensive Survey Rentao Gao, *, Zeyuan Yang, Yuefeng Jia aBeijing Laboratory of Advanced Information Network, Beijing University of Posts and Telecommunications (BUPT), Beijing, 100876, China.

[97] Failure prediction using machine learning and time series in optical network Zhilong Wang, Min Zhang, Danshi Wang, Chuang Song, Min Liu, Jin Li, Liqi Lou, and Zhuo Liu

[98] SOON: self-optimizing optical networks with machine learning Yongli Zhao, Boyuan Yan, Dongmei Liu, Yongqi He, Dajiang Wang, and Jie Zhang

[99] An Overview on Application of Machine Learning Techniques in Optical Networks Francesco Musumeci , Member, IEEE, Cristina Rottondi , Member, IEEE,

Avishek Nag , Senior Member, IEEE, Irene Macaluso, Darko Zibar , Member, IEEE,
Marco Ruffini, Senior Member, IEEE, and Massimo Tornatore , Senior Member, IEEE