



**ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ**

**ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ**

**ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ  
ΥΠΟΛΟΓΙΣΤΩΝ**

**Διπλωματική Εργασία**

**Χρήση τεχνικών Μηχανικής Μάθησης για την αντιμετώπιση  
των φαινομένων διάδοσης σε οπτικές επικοινωνίες**

**Machine Learning methods for optical communication systems and  
networks**

**Δημήτριος Δασαργύρης**

**AM: 711141295**

**Επιβλέπων καθηγητής: Αντώνης Μπόγγρης**

**Αθήνα, Σεπτέμβριος 2021**



**Τίτλος εργασίας: Χρήση τεχνικών μηχανικής μάθησης για την αντιμετώπιση των φαινομένων διάδοσης σε οπτικές επικοινωνίες**

**Μέλη Εξεταστικής Επιτροπής συμπεριλαμβανομένου και του Εισηγητή**

Η διπλωματική εργασία εξετάστηκε επιτυχώς από την κάτωθι Εξεταστική Επιτροπή:

<b>A/a</b>	<b>ΟΝΟΜΑ ΕΠΩΝΥΜΟ</b>	<b>ΒΑΘΜΙΑΔΑ/ΙΔΙΟΤΗΤΑ</b>	<b>ΨΗΦΙΑΚΗ ΥΠΟΓΡΑΦΗ</b>
1	Αντώνης Μπόργης	Καθηγητής	
2	Παναγιώτης Καρκαζής	Επ. Καθηγητής	
3	Νίκος Μυριδάκης	Επ. Καθηγητής	

## ΔΗΛΩΣΗ ΣΥΓΓΡΑΦΕΑ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ

Ο κάτωθι υπογεγραμμένος/η Δασαργύρης Δημήτριος του Νικολάου, με αριθμό μητρώου 711141295 φοιτητής του Πανεπιστημίου Δυτικής Αττικής της Σχολής Μηχανικών του Τμήματος Μηχανικών Πληροφορικής και Υπολογιστών, δηλώνω υπεύθυνα ότι:

«Είμαι συγγραφέας αυτής της διπλωματικής 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».

Ο Δηλών  
Δασαργύρης Δημήτριος



\* Ονοματεπώνυμο /Ιδιότητα

(Υπογραφή)

Ψηφιακή Υπογραφή Επιβλέποντα

*\* Σε εξαιρετικές περιπτώσεις και μετά από αιτιολόγηση και έγκριση του επιβλέποντα, προβλέπεται χρονικός περιορισμός πρόσβασης (embargo) 6-12 μήνες. Στην περίπτωση αυτή θα πρέπει να υπογράψει ψηφιακά ο/η επιβλέπων/ουσα καθηγητής/τρια, για να γνωστοποιεί ότι είναι ενημερωμένος/η και συναινεί. Οι λόγοι χρονικού αποκλεισμού πρόσβασης περιγράφονται αναλυτικά στις πολιτικές του Ι.Α. (σελ. 6):*

[https://www.uniwa.gr/wp-content/uploads/2021/01/%CE%A0%CE%BF%CE%BB%CE%B9%CF%84%CE%B9%CE%BA%CE%B5%CC%81%CF%82\\_%CE%99%CE%B4%CF%81%CF%85%CE%BC%CE%B1%CF%84%CE%B9%CE%BA%CE%BF%CF%85%CC%81\\_%CE%91%CF%80%CE%BF%CE%B8%CE%B5%CF%84%CE%B7%CF%81%CE%B9%CC%81%CE%BF%CF%85\\_final.pdf](https://www.uniwa.gr/wp-content/uploads/2021/01/%CE%A0%CE%BF%CE%BB%CE%B9%CF%84%CE%B9%CE%BA%CE%B5%CC%81%CF%82_%CE%99%CE%B4%CF%81%CF%85%CE%BC%CE%B1%CF%84%CE%B9%CE%BA%CE%BF%CF%85%CC%81_%CE%91%CF%80%CE%BF%CE%B8%CE%B5%CF%84%CE%B7%CF%81%CE%B9%CC%81%CE%BF%CF%85_final.pdf)



## Ευχαριστίες – Αφιερώσεις

Η παρούσα διπλωματική εργασία ολοκληρώθηκε μετά από επίμονες προσπάθειες, σε ενδιαφέροντα γνωστικά αντικείμενα, όπως αυτά της Μηχανικής Μάθησης και των Οπτικών Επικοινωνιών. Την προσπάθειά μου αυτή υποστήριξε ο επιβλέπων καθηγητής μου, τον οποίο θα ήθελα να ευχαριστήσω. Ακόμα θα ήθελα να ευχαριστήσω και την οικογένειά μου που με στηρίζει σε κάθε μου βήμα.

# Πρόλογος

Τα σημερινά τηλεπικοινωνιακά δίκτυα είναι πηγές μεγάλης ποσότητας ετερογενών δεδομένων, όπως δεδομένα για μονοπάτια κίνησης στο δίκτυο, ειδοποιήσεις δικτύου, δείκτες ποιότητας σήματος, δεδομένα συμπεριφοράς χρήστη κλπ.

Είναι απαραίτητο να χρησιμοποιούνται προηγμένα μαθηματικά εργαλεία που επεξεργάζονται αυτά τα δεδομένα ώστε να εξάγονται χρήσιμες πληροφορίες και να παίρνονται αποφάσεις για την ορθή λειτουργία των δικτύων.

Οι Τεχνικές Μηχανικής Μάθησης (Machine Learning) είναι πολλά υποσχόμενο εργαλείο για την ανάλυση δεδομένων του δικτύου, και δίνουν τη δυνατότητα σε αυτό να αυτορυθμίζεται και να κάνει διαχείριση λαθών. Η πρωτοφανής αύξηση της πολυπλοκότητας των δικτύων οπτικών επικοινωνιών τα τελευταία χρόνια, έχει οδηγήσει στην υιοθέτηση Τεχνικών Μηχανικής μάθησης και σε αυτά. Αυτή η αύξηση της πολυπλοκότητας οφείλεται στην εισαγωγή πολύ μεγάλου αριθμού ρυθμιζόμενων και αλληλεξαρτώμενων παραμέτρων του συστήματος (όπως ρυθμίσεις δρομολόγησης, τρόπος διαμόρφωσης, ρυθμός συμβόλων, σχήματα κωδικοποίησης) που ενεργοποιούνται από τη χρήση συνεκτικών τεχνολογιών μετάδοσης/λήψης, προηγμένης επεξεργασίας ψηφιακού σήματος και αντιστάθμιση μη γραμμικών φαινομένων διάδοσης σε δίκτυα οπτικών ινών.

Στην παρούσα διπλωματική εργασία θα γίνει εισαγωγή στις μεθόδους Μηχανικής Μάθησης και ανάλυσης των εφαρμογών τους στο πεδίο των οπτικών επικοινωνιών και της οπτικής δικτύωσης: Ξεκινάει με μια εισαγωγή σε βασικές έννοιες των οπτικών επικοινωνιών που είναι χρήσιμες για τη συνέχεια, και συνεχίζει επίσης με μια εισαγωγή στη Μηχανική Μάθηση. Στη συνέχεια προχωράει στην εφαρμογή της μηχανικής μάθησης στις οπτικές επικοινωνίες και γίνεται συνοπτική ταξινόμηση πολλών περιπτώσεων χρήσης του θέματος που αναφέρονται στη βιβλιογραφία μέχρι σήμερα. Ακολουθεί πολύ αναλυτική περιγραφή δύο επιλεγμένων σεναρίων χρήσης με τεχνικές MM, ένα για έλεγχο οπτικών ενισχυτών στο φυσικό επίπεδο και ένα για διαχείριση σφάλματος στο επίπεδο δικτύου. Στη συνέχεια γίνεται μια αξιολόγηση αλγορίθμων και η εργασία τελειώνει με συζήτηση για μελλοντικές κατευθύνσεις και γενικά συμπεράσματα.

**Όροι Κλειδιά:** Μηχανική Μάθηση, Ανάλυση Δεδομένων, Οπτική δικτύωση και επικοινωνίες, Νευρωνικά Δίκτυα, ρυθμός σφάλματος bit, λόγος σήματος προς θόρυβο, παρακολούθηση δικτύου

# Πίνακας περιεχομένων

ΕΥΧΑΡΙΣΤΙΕΣ – ΑΦΙΕΡΩΣΕΙΣ .....	III
ΠΡΟΛΟΓΟΣ .....	IV
ΠΙΝΑΚΑΣ ΠΕΡΙΕΧΟΜΕΝΩΝ .....	V
ΠΙΝΑΚΑΣ ΕΙΚΟΝΩΝ .....	VIII
ΠΙΝΑΚΑΣ ΠΙΝΑΚΩΝ .....	X
<b>ΚΕΦΑΛΑΙΟ 1. ΟΙ ΟΠΤΙΚΕΣ ΪΝΕΣ .....</b>	<b>1</b>
1.1 ΕΙΣΑΓΩΓΗ .....	1
1.1.1 Εισαγωγή στις οπτικές ίνες .....	1
1.1.2 Η δομή της οπτικής ίνας.....	3
1.1.3 Είδη οπτικών ινών.....	4
1.2 ΦΑΙΝΟΜΕΝΑ ΔΙΑΔΟΣΗΣ ΣΕ ΟΠΤΙΚΕΣ ΪΝΕΣ .....	5
1.2.1 Εξασθένηση – Attenuation .....	5
1.2.2 Σκέδαση – Scattering .....	5
1.2.3 Απορρόφηση – Absorption .....	7
1.2.4 Απώλειες λόγω κάμψης – Bending .....	7
1.2.5 Επίδραση υδρογόνου και ακτινοβολίας .....	7
1.2.6 Διασπορά – Dispersion.....	7
1.2.7 Διασπορά τρόπου μετάδοσης.....	7
1.2.8 Διασπορά Υλικού (DM) – Χρωματική διασπορά (CD).....	8
1.2.9 Διασπορά Κυματοδηγού (DW).....	8
1.2.10 Συνολική Διασπορά (D) .....	8
1.3 ΧΑΡΑΚΤΗΡΙΣΜΟΣ ΚΑΙ ΜΕΤΡΙΚΕΣ ΠΟΙΟΤΗΤΑΣ ΣΗΜΑΤΟΣ .....	9
1.3.1 Διάγραμμα οφθαλμού (Eye diagram).....	9
1.3.2 Ο παράγοντας ποιότητας Q (Q-factor).....	11
1.3.3 Ρυθμός λήψης λαθών (BER) .....	12
1.3.4 Σχέση BER και Q-factor .....	13
<b>ΚΕΦΑΛΑΙΟ 2. ΕΙΣΑΓΩΓΗ ΣΤΗΝ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ .....</b>	<b>14</b>
2.1 ΕΙΣΑΓΩΓΗ .....	14
2.2 ΚΑΤΗΓΟΡΙΕΣ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ .....	15
2.3 Η ΕΠΙΒΛΕΠΟΜΕΝΗ ΜΑΘΗΣΗ .....	16
2.3.1 Παραμετρικά Μοντέλα – Νευρωνικά Δίκτυα .....	16



2.3.2	Μη Παραμετρικά Μοντέλα.....	21
2.4	Η ΜΗ ΕΠΙΒΛΕΠΟΜΕΝΗ ΜΑΘΗΣΗ.....	22
2.4.1	Ομαδοποίηση Κ-μέσων.....	22
2.4.2	Γκαουσιανό Μοντέλο πιθανοτήτων (GMM).....	23
2.5	Η ΗΜΙΕΠΙΒΛΕΠΟΜΕΝΗ ΜΑΘΗΣΗ.....	24
2.6	ΕΝΙΣΧΥΤΙΚΗ ΜΑΘΗΣΗ.....	25
2.7	ΥΠΕΡΕΚΠΑΙΔΕΥΣΗ, ΥΠΟΕΚΠΑΙΔΕΥΣΗ ΚΑΙ ΕΠΙΛΟΓΗ ΜΟΝΤΕΛΟΥ.....	26
<b>ΚΕΦΑΛΑΙΟ 3. Η ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ ΣΤΙΣ ΟΠΤΙΚΕΣ ΕΠΙΚΟΙΝΩΝΙΕΣ .....</b>		<b>28</b>
3.1	ΕΙΣΑΓΩΓΗ.....	28
3.2	ΚΙΝΗΤΡΑ ΓΙΑ ΕΦΑΡΜΟΓΗ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΣΤΙΣ ΟΠΤΙΚΕΣ ΕΠΙΚΟΙΝΩΝΙΕΣ.....	30
3.3	ΕΦΑΡΜΟΓΕΣ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΣΤΟΝ ΤΟΜΕΑ ΦΥΣΙΚΟΥ ΕΠΙΠΕΔΟΥ.....	32
3.3.1	Εκτίμηση QoT.....	32
3.3.2	Έλεγχος οπτικών ενισχυτών.....	33
3.3.3	Αναγνώριση μορφής διαμόρφωσης (MFR).....	34
3.3.4	Αντιστάθμιση Μη Γραμμικότητας.....	34
3.3.5	Παρακολούθηση οπτικής απόδοσης(OPM).....	35
3.4	ΕΦΑΡΜΟΓΕΣ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΣΤΟΝ ΤΟΜΕΑ ΕΠΙΠΕΔΟΥ ΔΙΚΤΥΟΥ.....	36
3.4.1	Πρόβλεψη κυκλοφορίας.....	36
3.4.2	Σχεδιασμός εικονικής τοπολογίας (VTD) και επαναδιαμόρφωση.....	37
3.4.3	Διαχείριση σφαλμάτων.....	38
3.4.4	Ταξινόμηση ροής κυκλοφορίας.....	39
3.4.5	Υπολογισμός διαδρομής.....	40
<b>ΚΕΦΑΛΑΙΟ 4. ΛΕΠΤΟΜΕΡΗΣ ΕΠΙΣΚΟΠΗΣΗ ΤΗΣ ΕΦΑΡΜΟΓΗΣ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΣΤΙΣ ΟΠΤΙΚΕΣ ΕΠΙΚΟΙΝΩΝΙΕΣ</b>		<b>41</b>
4.1	ΕΦΑΡΜΟΓΕΣ ΜΜ ΣΤΟ ΦΥΣΙΚΟ ΕΠΙΠΕΔΟ.....	41
4.1.1	Εκτίμηση Ποιότητας Μετάδοσης.....	41
4.1.2	Έλεγχος Οπτικών Ενισχυτών.....	44
4.1.3	Αναγνώριση Μορφής Διαμόρφωσης (MFR).....	46
4.1.4	Αντιστάθμιση Μη Γραμμικότητας.....	47
4.1.5	Παρακολούθηση Οπτικής Απόδοσης.....	49
4.2	ΕΦΑΡΜΟΓΕΣ ΜΜ ΣΤΟ ΕΠΙΠΕΔΟ ΔΙΚΤΥΟΥ.....	51
4.2.1	Πρόβλεψη κίνησης και σχεδιασμός εικονικής τοπολογίας.....	51
4.2.2	Διαχείριση Σφάλματος.....	53
4.2.3	Ταξινόμησης Ροής.....	57
4.2.4	Υπολογισμός μονοπατιού.....	58
4.3	ΣΥΜΠΕΡΑΣΜΑ ΕΝΟΤΗΤΑΣ.....	60

**ΚΕΦΑΛΑΙΟ 5. ΑΝΑΛΥΤΙΚΗ ΠΕΡΙΓΡΑΦΗ ΕΠΙΛΕΓΜΕΝΩΝ ΣΕΝΑΡΙΩΝ ΜΕ ΧΡΗΣΗ ΤΕΧΝΙΚΩΝ ΜΜ ΣΤΙΣ ΟΠΤΙΚΕΣ ΕΠΙΚΟΙΝΩΝΙΕΣ 61**

5.1 ΑΝΤΙΣΤΟΙΧΙΣΗ ΕΙΚΟΝΑΣ ΘΟΡΥΒΟΥ ΚΑΙ ΟΜΑΛΟΤΗΤΑΣ ΑΠΟΛΑΒΗΣ ΕΝΙΣΧΥΤΩΝ EDFA ΠΑΝΩ ΑΠΟ ΜΑΣΚΑ ΙΣΧΥΟΣ ΜΕ ΧΡΗΣΗ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ..... 61

5.1.1 Εισαγωγή..... 62

5.1.2 Χαρακτηρισμός Ενισχυτή ..... 63

5.1.3 Αντιστοίχιση NF και GF χρησιμοποιώντας Νευρωνικά Δίκτυα MLP..... 67

5.1.4 Πειραματική εγκατάσταση ..... 69

5.1.5 Αποτελέσματα..... 71

5.1.6 Συμπεράσματα..... 75

5.2 ΑΝΙΧΝΕΥΣΗ ΚΑΙ ΕΝΤΟΠΙΣΜΟΣ ΕΛΑΦΡΙΩΝ ΣΦΑΛΜΑΤΩΝ ΣΕ ΟΠΤΙΚΑ ΔΙΚΤΥΑ ΜΕ ΧΡΗΣΗ ΜΜ ..... 76

5.2.1 Εισαγωγή..... 76

5.2.2 Πλαίσια ανίχνευσης και αναγνώρισης ελαφριών σφαλμάτων ..... 78

5.2.3 Αριθμητικά αποτελέσματα ..... 80

5.2.4 Συμπέρασμα ..... 82

**ΚΕΦΑΛΑΙΟ 6. ΑΞΙΟΛΟΓΗΣΗ ΑΛΓΟΡΙΘΜΩΝ ΜΜ ΣΤΙΣ ΟΠΤΙΚΕΣ ΕΠΙΚΟΙΝΩΝΙΕΣ.....83**

6.1 ΜΕΤΡΙΚΕΣ ΑΠΟΔΟΣΗΣ ..... 83

6.2 ΠΟΣΟΤΙΚΗ ΣΥΓΚΡΙΣΗ ΑΛΓΟΡΙΘΜΩΝ ..... 85

**ΚΕΦΑΛΑΙΟ 7. ΣΥΖΗΤΗΣΗ ΓΙΑ ΜΕΛΛΟΝΤΙΚΕΣ ΚΑΤΕΥΘΥΝΣΕΙΣ .....87**

**ΚΕΦΑΛΑΙΟ 8. ΣΥΜΠΕΡΑΣΜΑΤΑ.....91**

**ΠΙΝΑΚΑΣ ΏΡΩΝ .....92**

**ΒΙΒΛΙΟΓΡΑΦΙΑ.....93**

## Πίνακας Εικόνων

Εικόνα 1 - Υβριδικό δίκτυο χαλκού - οπτικής ίνας HFC.....	1
Εικόνα 2 - Κυματοδηγήση μέσω ολικής ανάκλασης σε οπτική ίνα.....	3
Εικόνα 3 - Τυποποιημένα μεγέθη τιμών (9/125, 50/125, 62.5/125 και 100/140) .....	4
Εικόνα 4 – Φαινόμενο σκέδασης.....	6
Εικόνα 5 – Το φαινόμενο της σκέδασης εξαρτάται από το μήκος κύματος.....	6
Εικόνα 6 - Υπερτιθέμενα bits και δημιουργία διαγράμματος ματιού .....	9
Εικόνα 7 – Eye diagram σε παλμογράφο και στάθμες bit.....	10
Εικόνα 8 – Άνοιγμα «ματιού» σε διαφορετικά διαγράμματα.....	10
Εικόνα 9 – Μέση τιμή και τυπική απόκλιση.....	11
Εικόνα 10 – μέση τιμή και κατώφλι.....	12
Εικόνα 11-Σχέση BER και Q-factor .....	13
Εικόνα 12 – Παράδειγμα Νευρωνικού Δικτύου με 2 επίπεδα και περιγραφή νευρωνίου.....	17
Εικόνα 13 – Διαφορά κ-μέσων με GMM ομαδοποιώντας ένα σύνολο δειγμάτων δεδομένων .....	23
Εικόνα 14 – Πλαίσιο Ταξινόμησης.....	43
Εικόνα 15 – EDFA Power Mask.....	44
Εικόνα 16 – Αναπαράσταση Χώρου Stokes για μορφές διαμόρφωσης DP-BPSK, DP-QPSK και DP-8-QAM.....	46
Εικόνα 17 - Ο εντοπισμός αστοχίας και το πλαίσιο ανίχνευσης .....	57
Εικόνα 18 – Διάγραμμα που παρουσιάζει τον ρόλο του επιπέδου ελέγχου το οποίο φιλοξενεί του αλγορίθμους MM και πολιτικές για τη διαχείριση των οπτικών δικτύων .....	60
Εικόνα 19 – Ορισμός Μάσκας Ισχύος.....	63
Εικόνα 20 – Πειραματική Εγκατάσταση χαρακτηρισμού ενισχυτή .....	65
Εικόνα 21 – Μάσκες Ισχύος με τα αποτελέσματα του χαρακτηρισμού όσον αφορά a.NF b.GF και c.ακρίβεια AGC.....	66
Εικόνα 22 – Η αρχιτεκτονική MLP που χρησιμοποιείται για αντιστοίχιση NF και GF σαν συνάρτηση του $P_{in}$ και $P_{out}$ .....	68
Εικόνα 23 – Καμπύλη σύγκλισης για τις διαδικασίες επικύρωσης και δοκιμής σαν συνάρτηση του αριθμού των εποχών .....	71
Εικόνα 24 – Θηκόγραμμα του σφάλματος δοκιμής σαν συνάρτηση του αριθμού των νευρωνίων στο κρυφό επίπεδο για Μάσκα Ισχύος 1db.....	72
Εικόνα 25 - Θηκόγραμμα του σφάλματος δοκιμής σαν συνάρτηση του αριθμού των νευρωνίων στο κρυφό επίπεδο για Μάσκα Ισχύος 3db.....	72

Εικόνα 26 – Θηκόγραμμα του σφάλματος δοκιμής σαν συνάρτηση του βήματος για 4 νευρώνια στο κρυφό επίπεδο.....	73
Εικόνα 27 – Παράδειγμα GF καμπύλης που δημιουργήθηκε με τη χρήση του MLP, με την ισχύ εισόδου και εξόδου να ποικίλλει με ανάλυση 0,1 db .....	74
Εικόνα 28 – Παράδειγμα NF καμπύλης που δημιουργήθηκε με τη χρήση του MLP, με την ισχύ εισόδου και εξόδου να ποικίλλει με ανάλυση 0,1 db.....	74
Εικόνα 29 – Πλαίσιο ανίχνευσης και αναγνώρισης ελαφριάς αστοχίας.....	78
Εικόνα 30 – Εγκατάσταση πειράματος.....	80
Εικόνα 31 – Αριθμητικά αποτελέσματα που προέκυψαν για τα πλαίσια DET-F (α και β) και IDENT-F (c) .....	80

## Πίνακας Πινάκων

Πίνακας 1 – Σύγκριση Χαλκού και Οπτικής ίνας.....	1
Πίνακας 2 – Εξασθένηση του οπτικού σήματος συναρτήσει μήκους κύματος.....	5
Πίνακας 3 – Πίνακας αποτελεσμάτων από τη διαδικασία χαρακτηρισμού με μερικά σημεία	66
Πίνακας 4 – ο αριθμός των σημείων που χρησιμοποιούνται για κάθε μάσκα για την εκπαίδευση, επικύρωση και δοκιμή.....	70
Πίνακας 5: Σύγκριση αλγορίθμων MM και μετρικών απόδοσης για περιπτώσεις χρήσης	86

# Κεφάλαιο 1. Οι Οπτικές Ίνες

## 1.1 Εισαγωγή

### 1.1.1 Εισαγωγή στις οπτικές ίνες

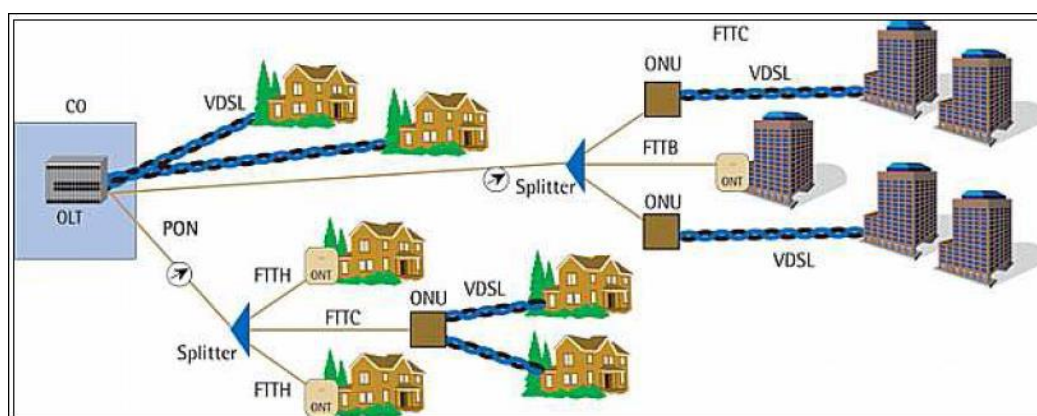
Οι οπτικές ίνες αποτελούν το περισσότερο τεχνολογικά προηγμένο ενσύρματο μέσο μετάδοσης όπως φαίνεται από τον παρακάτω πίνακα. Εκείνο το οποίο θα μπορούσαμε να παρατηρήσουμε, είναι ότι με τη χρήση των οπτικών ιών μπορούμε να έχουμε μετάδοση πληροφορίας με αυξημένες απαιτήσεις σε bandwidth, σε μεγάλες αποστάσεις λόγω της μικρής εξασθένησης σήματος. [2]

Πίνακας 1 - Σύγκριση Χαλκού και Οπτικής ίνας

	<i>Απόσταση</i>	<i>Bandwidth</i>	<i>Κανάλια Φωνής</i>
<b>Χαλκός</b>	2,5 Km	1,5 Mbps	24
<b>Οπτική Ίνα</b>	20 Km	2,5+ Gbps	32000+

Ανάλοδα με το πόσο κοντά φτάνει η οπτική ίνα στον πελάτη (of customer) έχουμε:

- FFTC – Fiber to the Curb: Η ίνα φτάνει μέχρι τον εξωτερικό καταναμητή που βρίσκεται σε κοντινή απόσταση από τον πελάτη.
- FFTB – Fiber to the Building: Η ίνα φτάνει στις εγκαταστάσεις του πελάτη οι οποίες βρίσκονται εντός κτηρίου.
- FFTH – Fiber to the Home: Η ίνα φτάνει μέχρι το σπίτι του συνδρομητή.
- FFTD – Fiber to the Desk: Η ίνα φτάνει μέχρι το γραφείο του συνδρομητή.



Εικόνα 1 - Υβριδικό δίκτυο χαλκού - οπτικής ίνας HFC

Τα πλεονεκτήματα των οπτικών ινών σε σύγκριση με τα χάλκινα καλώδια συνοψίζονται παρακάτω:


- Πρακτικά απεριόριστο εύρος ζώνης: Στην πράξη η επίδοση ανά ζεύξη υπερβαίνει τα 10 Gbps, η οποία θα μπορούσε να εξυπηρετήσει περίπου 150000 συνδρομητικές γραμμές φωνής ( $64 \text{ kbps} * 150000 = 10 \text{ Gbps}$ ). Η χωρητικότητα της ίνας μπορεί να πολλαπλασιαστεί με χρήση πολυπλεξίας μήκους κύματος Wavelength Division Multiplexing WDM. Μπορούμε να επιτύχουμε πολυπλεξία μήκους κύματος των 8 ή των 16 ή και των 64ρων με αποτέλεσμα να έχουμε 3 Terabits/sec σε μήκος 40 km.
- Πολύ μικρή εξασθένηση: Μόλις υπερβαίνει το 0,1 db/km (για μονότροπες ίνες, και σε μήκος κύματος 1500 nm), επιτρέποντας την υλοποίηση ζεύξεων σε απόσταση άνω των 200 Km χωρίς τη χρήση ενδιάμεσων βαθμίδων αναγέννησης. Το γεγονός αυτό είναι ιδιαίτερα σημαντικό σε υποθαλάσσιες ζεύξεις. Επίσης η νόθευση των οπτικών ινών με Erbium μπορεί να πενταπλασιάσει την απόσταση αυτή επιτρέποντας υποβρύχιες ζεύξεις πάνω από 1000 km.
- Μικρές διαστάσεις: Διατομή ίνας 0,25 mm συμπεριλαμβανόμενης της πρωτεύουσας επικάλυψης του μανδύα. Επίσης έχουν μικρό βάρος με αποτέλεσμα να επιτρέπουν την τοποθέτηση μεγάλου αριθμού ινών στο ίδιο καλώδιο, χωρίς να αυξάνεται η διατομή και το βάρος του καλωδίου. Σε καλώδια διαμέτρου 1,75 cm τοποθετούνται συνήθως από 8 έως 144 ίνες. Στην Ιαπωνία συγκεκριμένα έχουν πετύχει κατασκευή καλωδίου 200 ινών, με τη χρήση σε δομή ταινίας (ribbon fibers)
- Αναισθησία σε ηλεκτρομαγνητική ακτινοβολία: Οπτικές ίνες μπορούν να χρησιμοποιηθούν σε βιομηχανικό περιβάλλον με υψηλά επίπεδα ηλεκτρομαγνητικής παρεμβολής (EMI)
- Προστασία των δεδομένων από υποκλοπή: Επειδή το οπτικό σήμα περιορίζεται εντός του πυρήνα της οπτικής ίνας δεν είναι δυνατή η υποκλοπή των δεδομένων χωρίς υποβάθμιση της στάθμης του σήματος που γίνεται όμως αντιληπτή στο δέκτη εγείροντας σχετική σηματοδосία (Alarm)
- Μόνωση: Η οπτική ίνα αποτελείται από διηλεκτρικό υλικό, και ως εκ τούτου δε μεταφέρει ηλεκτρικό ρεύμα, το οποίο μπορεί να προκαλέσει ηλεκτρικό σπινθήρα με κίνδυνο πρόκλησης έκρηξης ή πυρκαγιάς. Για το λόγο αυτό ένα οπτικό καλώδιο μπορεί να διατρέξει τοξικά ή εκρηκτικά περιβάλλοντα.
- Χαμηλότερο κόστος πρώτης ύλης: Η πρώτη ύλη παρασκευής των οπτικών ινών είναι το πυρίτιο το οποίο βρίσκεται σε αφθονία σε αντίθεση με τον χαλκό του οποίου το κόστος είναι αυξημένο.

### 1.1.2 Η δομή της οπτικής ίνας

Η οπτική ίνα είναι ένας γυάλινος κυματοδηγός κυλινδρικής διατομής. Η βασική της δομή περιλαμβάνει μια κεντρική ράβδο που ονομάζεται πυρήνας (core) και έναν σωλήνα που περιβάλλει τον πυρήνα και ονομάζεται μανδύας (cladding). Για λόγους προστασίας από εξωτερικούς παράγοντες, ο μανδύας καλύπτεται από πρωτογενή επικάλυψη πλαστικού γνωστή ως πρωτεύουσα επικάλυψη ή εξωτερικό περίβλημα (coating).

Τόσο ο πυρήνας, όσο και ο μανδύας είναι συνήθως κατασκευασμένα από συνθετικό γυαλί υψηλής καθαρότητας ( $\text{SiO}_2$  - με συντελεστή διάθλασης 1,46), ενώ ο πυρήνας περιλαμβάνει προσμίξεις  $\text{GeO}_2$  (με συντελεστή διάθλασης 1,48) και άλλως προσμίξεων, που μεταβάλλουν τον συντελεστή διάθλασης του πυρήνα, επιτυγχάνοντας τη διαφορά από το συντελεστή διάθλασης του μανδύα.  $\Delta n = 0,01$  που απαιτείται για την κυματοδότηση. Τυπικές τιμές συντελεστών διάθλασης είναι για τον πυρήνα  $n_1 = 1,47$  ενώ για τον μανδύα  $n_2 = 1,46$ . Επισημαίνουμε ότι η διαφορά  $\Delta n$  είναι επιθυμητή.

Το οπτικό σήμα κυματοδηγείται στον πυρήνα της οπτικής ίνας μέσω του φαινομένου των ολικών ανακλάσεων στην κοινή επιφάνεια με γωνία μεγαλύτερη της κρίσιμης γωνίας, ανακλάται ολικά και συνεχίζει τη διαδρομή της εντός του πυρήνα, μέσω συνεχών ανακλάσεων. Αντίθετα αν η γωνία πρόσπτωσης είναι μικρότερη της κρίσιμης γωνίας τότε το φως διαθλάται μέσα από τον μανδύα και χάνεται μετά από κάποια απόσταση.




Εικόνα 2 - Κυματοδότηση μέσω ολικής ανάκλασης σε οπτική ίνα



Τα ειδικότερα χαρακτηριστικά της μετάδοσης του φωτός σε έναν οπτικό κυματοδηγό εξαρτώνται:

- Από τη διάμετρο του πυρήνα
- Τους συντελεστές διάθλασης πυρήνα και μανδύα
- Το μήκος κύματος του φωτός

Στην παρακάτω εικόνα 3 δίνονται διάφορα μεγέθη διαστάσεων που εκφράζονται από τη διάμετρο του πυρήνα ακολουθούμενη από τη διάμετρο του μανδύα. Επί παραδείγματι το 50/125 δηλώνει 50 μm διάμετρο πυρήνα και 125 μm διάμετρο μανδύα.



Εικόνα 3 - Τυποποιημένα μεγέθη τιμών (9/125, 50/125, 62.5/125 και 100/140)

### 1.1.3 Είδη οπτικών ινών

Οι οπτικές ίνες κατηγοριοποιούνται ως προς:

A) Το υλικό κατασκευής πυρήνα και μανδύα:

- Εξ ολοκλήρου γυάλινες οπτικές ίνες: Αποτελούν το περισσότερο διαδεδομένο είδος οπτικών ινών στις τηλεπικοινωνίες. Τόσο ο πυρήνας όσο και ο μανδύας είναι κατασκευασμένα από συνθετικό γυαλί υψηλής καθαρότητας σε διοξείδιο του πυριτίου  $\text{SiO}_2$  στο οποίο έχουν προστεθεί κατάλληλες προσμίξεις προκειμένου να επιτευχθεί η επιδιωκόμενη διαφορά στον συντελεστή διάθλασης πυρήνα-μανδύα.
- Ίνα γυάλινου πυρήνα και πλαστικού μανδύα: Η χρήση τους τείνει να αντικατασταθεί από εξ ολοκλήρου πλαστικές ίνες.
- Εκ ολοκλήρου πλαστικές ίνες: Συγκρινόμενες με άλλα είδη ινών παρουσιάζουν εμφανώς κατώτερες επιδόσεις, ως προς την ελάχιστη εξασθένιση (0,15 dbm στα 650 nm) και το διαθέσιμο εύρος ζώνης καθώς και μεγάλη ευαισθησία σε θερμοκρασιακές μεταβολές.

B) Την μεταβολή του δείκτη διάθλασης από τον πυρήνα στον μανδύα.

C) Το πλήθος των τρόπων μετάδοσης που υποστηρίζουν:

- Πολύτροπες – βηματικού δείκτη (step index) ή βαθμιαίου δείκτη (graded index)
- Μονότροπες – βηματικού δείκτη (step index) [2]

## 1.2 Φαινόμενα Διάδοσης σε Οπτικές Ύνες

### 1.2.1 Εξασθένηση - Attenuation


Ως εξασθένηση ορίζεται η απώλεια οπτικής ισχύος κατά την κυματοδότηση και ανέρχεται σε 150 dB/km για τις πλαστικές ίνες ενώ μόνο 0,21 dB/km σε μονότροπες ίνες. Στον παρακάτω πίνακα δίνονται χαρακτηριστικές τιμές εξασθένησης για μερικά είδη οπτικών ινών:

Πίνακας 2 - Εξασθένηση του οπτικού σήματος συναρτήσει μήκους κύματος


Είδος Ύνας	Διαστάσεις Πυρήνα/Μανδύα	Εξασθένηση (dB/km)
Μονότροπη	9/125	2 - 5 για $\lambda = 850$ nm 0,35 για $\lambda = 1300$ nm 0,21 για $\lambda = 1550$ nm
Πολύτροπη (βαθμιαίας μεταβολής)	50/125	4,00 για $\lambda = 850$ nm 2,50 για $\lambda = 1300$ nm
	62,5/125	6,00 για $\lambda = 850$ nm
	85/125	7,00 για $\lambda = 850$ nm
Πολύτροπη (βηματικής μεταβολής)	200/380	6,00 για $\lambda = 850$ nm
	300/440	6,00 για $\lambda = 850$ nm
PCS (γυάλινου πυρήνα με πλαστικό μανδύα)	200/350	10,00 για $\lambda = 790$ nm
	400/550	10,00 για $\lambda = 790$ nm
	600/900	6,00 για $\lambda = 790$ nm
Πλαστική	750	150 για $\lambda = 650$ nm
	1000	200 για $\lambda = 650$ nm

### 1.2.2 Σκέδαση - Scattering

Απώλειες οπτικής ενέργειας λόγω απωλειών στη βασική δομή της ίνας. Σε χαμηλά μήκη κύματος εμφανίζεται η σκέδαση Raleigh, που οφείλεται στη μη κανονικότητα της κρυσταλλικής δομής της ίνας. Το φαινόμενο είναι αντιστρόφως ανάλογο της τέταρτης δύναμης του μήκους κύματος ( $1/\lambda^4$ ). Άρα όσο υψηλότερο το μήκος κύματος μετάδοσης τόσο περισσότερο ελαχιστοποιείται η απώλεια σκέδασης Raleigh.



Εικόνα 4 - Φαινόμενο σκέδασης



Εικόνα 5 - Το φαινόμενο της σκέδασης εξαρτάται από το μήκος κύματος

Ένα άλλο είδος σκέδασης οφείλεται στις ατέλειες της κυλινδρικής δομής της ίνας. Η σκέδαση αυτή ονομάζεται σκέδαση Mie. Τέτοιες απώλειες οφείλονται στην κοινή επιφάνεια πυρήνα/μανδύα, λόγω μικρών μεταβολών στους συντελεστές διάθλασης των υλικών, διαφοροποιήσεων της διαμέτρου πυρήνα κατά μήκος της ίνας και λόγω ύπαρξης μικρών φυσαλίδων. Οι απώλειες αυτές ελαχιστοποιούνται με βελτίωση στη διαδικασία κατασκευής.

Εκτός από τα ανωτέρω είδη γραμμικής σκέδασης υπάρχουν και φαινόμενα μη γραμμικής σκέδασης που εμφανίζονται κυρίως, όταν οι οπτικές ίνες δέχονται μεγάλα επίπεδα οπτικής ισχύος. Τα γνωστότερα είδη μη γραμμικής σκέδασης είναι η σκέδαση Brillouin και Raman. [2]

### **1.2.3 Απορρόφηση – Absorption**

Λόγω ύπαρξης ξένων μοριακών δομών στο διοξείδιο του πυριτίου κατά την παραγωγή της οπτικής ίνας το φως απορροφάται από το υλικό μετάδοσης και η ενέργειά του μετατρέπεται σε θερμότητα.

### **1.2.4 Απώλειες λόγω κάμψης – Bending**

Αν και οι οπτικές ίνες αποθηκεύονται τυλιγμένες σε ειδικά στροφεία, η καμπυλότητα πέραν μιας ελάχιστης ακτίνας κάμψης μπορεί να προκαλέσει σπάσιμο της ίνας. Οι κάμψεις έχουν βασικές επιπτώσεις στις μονότροπες ίνες.

### **1.2.5 Επίδραση υδρογόνου και ακτινοβολίας**

Η εμφάνιση υδρογόνου οφείλεται στην εισχώρηση υγρασίας στο εσωτερικό του οπτικού καλωδίου. Το υδρογόνο εκλύεται είτε από την ηλεκτρολυτική επίδραση της υγρασίας στην μεταλλική δομή θωράκισης του καλωδίου είτε από χημική αποσύνθεση των υλικών του μανδύα. Η πρόσθετη εξασθένηση εμφανίζεται σωρευτικά. Το φαινόμενο αυτό είναι ιδιαίτερο αισθητό σε υποβρύχιες ζεύξεις. Επίσης η έκθεση των οπτικών ινών σε ραδιενεργά περιβάλλοντα τα οποία μπορεί να προκληθούν από πυρηνικά ατυχήματα προκαλεί την μοριακή τους αποσύνθεση με αποτέλεσμα να δημιουργούνται χρωματικά κέντρα απορρόφησης του οπτικού σήματος.

### **1.2.6 Διασπορά – Dispersion**

Ως διασπορά ορίζεται η διαφορετική χρονική καθυστέρηση της διάδοσης των τμημάτων του φασματικού περιεχομένου του σήματος πληροφορίας (αναλογικό ή ψηφιακό ηλεκτρικό ή οπτικό) από τον πομπό στον δέκτη. Στο ψηφιακό σήμα αυτό παρατηρείται ως μια διεύρυνση των παλμών από τον πομπό στον δέκτη με αποτέλεσμα όσο μεγαλύτερη διασπορά έχουμε, τόσο μειώνεται ο ρυθμός μετάδοσης.

### **1.2.7 Διασπορά τρόπου μετάδοσης**

Η διασπορά τρόπου μετάδοσης – modal dispersion εμφανίζεται μόνο σε πολύτροπες ίνες και οφείλεται στο γεγονός ότι το οπτικό σήμα διαδίδεται εντός της ίνας με παραπάνω του ενός τρόπου. Με άλλα λόγια, το οπτικό σήμα κατά τη διάδοσή του εντός της πολύτροπης ίνας διασπάται σε διαφορετικές ακτίνες φωτός οι οποίες ακολουθούν

διαφορετικούς δρόμους τεθλασμένων γραμμών. Κατά συνέπεια κάθε διαδρομή έχει και διαφορετική ταχύτητα. Η τιμή της διασποράς του τρόπου μετάδοσης αυξάνει ανάλογα με το πλήθος των τρόπων μετάδοσης που υποστηρίζει ο κυματοδηγός. Άρα εξαρτάται κυρίως από τον πυρήνα.

### **1.2.8 Διασπορά Υλικού (DM) – Χρωματική διασπορά (CD)**

Η διασπορά υλικού – material dispersion ή χρωματική διασπορά – chromatic dispersion εμφανίζεται τόσο σε πολύτροπες ίνες όσο και σε μονότροπες, και οφείλεται στο γεγονός ότι ο συντελεστής διάθλασης του πυρήνα εξαρτάται και από το μήκος κύματος της οδηγούμενης ακτίνας φωτός. Όταν το οπτικό σήμα του πομπού περιλαμβάνει περισσότερα από ένα μήκη κύματος τότε το καθένα από αυτά βλέπει διαφορετικό συντελεστή διάθλασης και τα αντίστοιχο μεταφερόμενο μέρος του σήματος κινείται με διαφορετική ταχύτητα προκαλώντας διασπορά του οπτικού σήματος στον δέκτη. Πιθανόν το οπτικό σήμα να προέρχεται από τη σύνθεση διαφορετικών μηκών κύματος. Άλλωστε δεν υπάρχει ιδανική πηγή φωτός που να εκπέμπει φως συγκεντρώνοντας την ισχύ του σε ένα και μόνο μήκος κύματος.

### **1.2.9 Διασπορά Κυματοδηγού (DW)**

Η διασπορά κυματοδηγού – waveguide dispersion οφείλεται στη διαφορετική ταχύτητα μετάδοσης μεταξύ πυρήνα και μανδύα, λόγω της μικρής μεταξύ τους διαφοράς ως προς τον συντελεστή διάθλασης. Εμφανίζεται κυρίως σε μονότροπες ίνες, όπου ένα μεγάλο μέρος της κυματοδηγούμενης οπτικής ενέργειας διέρχεται από τον μανδύα, ενώ είναι ασήμαντη στις πολύτροπες ίνες.

### **1.2.10 Συνολική Διασπορά (D)**

Ως συνολική διασπορά (total dispersion) της μονότροπης οπτικής ίνας ορίζουμε το άθροισμα της διασποράς υλικού και της διασποράς κυματοδηγού. Η συνολική διασπορά εξαρτάται τόσο από το μήκος κύματος της πηγής φωτός όσο και από το υλικό της ίνας.

[2]


## 1.3 Χαρακτηρισμός και μετρικές ποιότητας σήματος

Κάθε σύστημα μετάδοσης αλλοιώνει σε κάποιο βαθμό την ποιότητα του μεταδιδόμενου σήματος. Η ποιότητα των οπτικών σημάτων αξιολογείται με δύο κυρίως τρόπους:

- Εποπτικά με την παρατήρηση διαγραμμάτων οφθαλμού (eye-diagrams)
- Με τον παράγοντα ποιότητας Q-Factor.
- Με μετρήσεις ρυθμού λαθών (BER) που λαμβάνει ο δέκτης, συναρτήσει του παράγοντα ποιότητας Q (Q-factor).

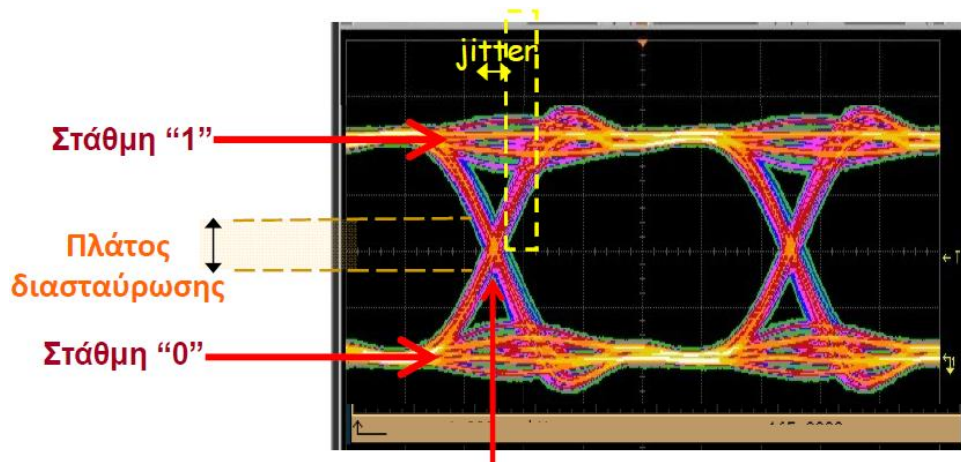
### 1.3.1 Διάγραμμα οφθαλμού (Eye diagram)

Διάγραμμα Οφθαλμού ονομάζεται το σχήμα που προκύπτει από την υπέρθεση των bits σε χρονικό παράθυρο ίσο με την περίοδο του bit. Λέγεται έτσι επειδή «μοιάζει» με το ανθρώπινο μάτι.



Εικόνα 6 - Υπερτιθέμενα bits και δημιουργία διαγράμματος ματιού

Σε έναν παλμογράφο το διάγραμμα οφθαλμού απεικονίζεται κάπως έτσι:



Εικόνα 7 – Διάγραμμα Οφθαλμού σε παλμογράφο και στάθμες bit

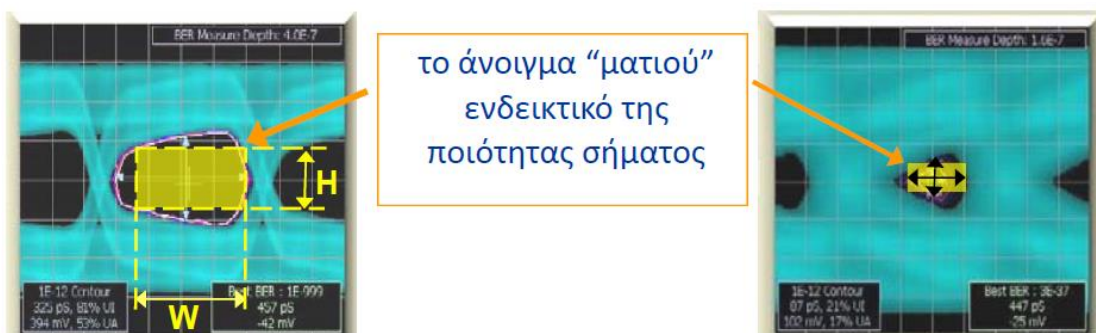
Timing jitter: Εύρος πλαϊνών γραμμών “αρχής” και “τέλους” του διαγράμματος  
ματιού

Θόρυβος στο ‘0’: Εύρος γραμμής της στάθμης του λογικού “0”

Θόρυβος στο ‘1’: Εύρος γραμμής της στάθμης του λογικού “1”

Το jitter αποτυπώνεται στο εύρος των πλαϊνών γραμμών. Ο θόρυβος κυρίως στο εύρος των δύο οριζόντιων γραμμών (“0” και “1”)

Στην παρακάτω εικόνα βλέπουμε δυο διαφορετικά διαγράμματα οφθαλμών:

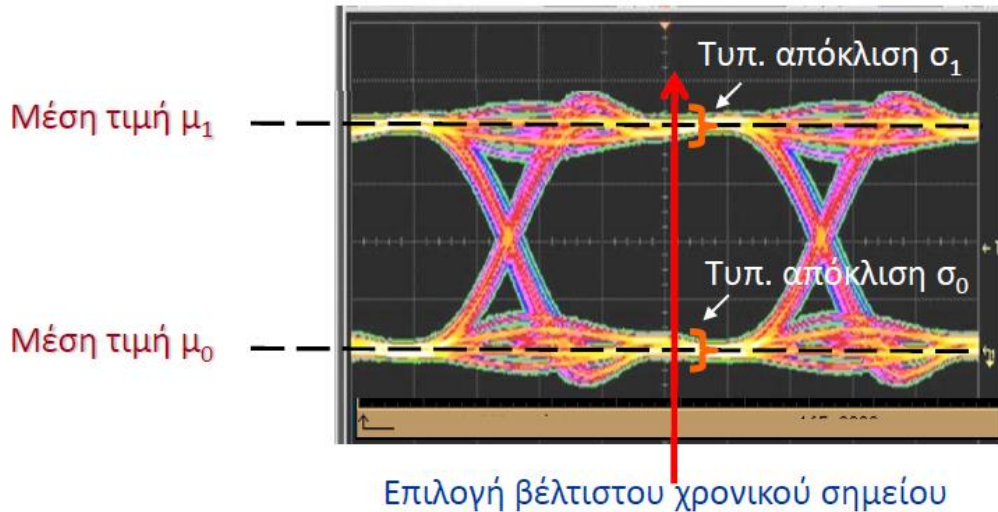


Εικόνα 8 – Άνοιγμα «ματιού» σε διαφορετικά διαγράμματα

Εύκολα διαπιστώνεται από τα παραπάνω διαγράμματα ότι όσο μεγαλύτερο είναι το άνοιγμα του «ματιού» τόσο καλύτερη είναι η ποιότητα του σήματός.

### 1.3.2 Ο παράγοντας ποιότητας Q (Q-factor)

Σε ένα διάγραμμα οφθαλμού παίρνουμε τη μέση τιμή  $\mu_0, \mu_1$  στις γραμμές θορύβου στο «0» και στο «1» αντίστοιχα, καθώς και τις αντίστοιχες τυπικές αποκλίσεις  $\sigma_1, \sigma_2$  για το βέλτιστο σημείο που επιλέχθηκε, όπως φαίνεται και από την παρακάτω εικόνα:



Εικόνα 9 - Μέση τιμή και τυπική απόκλιση

Τότε:

Λόγος σβέσης θα λέγεται η σχέση:

$$EX = \log \left( \frac{\mu_1}{\mu_0} \right)$$

Παράγοντας ποιότητας (Q-factor) θα λέγεται η σχέση:

$$Q = \frac{\mu_1 - \mu_0}{\sigma_1 + \sigma_0}$$

Παρακάτω θα δούμε πώς ο Q-factor συνδέεται με τον ρυθμό λήψης λαθών (BER).



### 1.3.3 Ρυθμός λήψης λαθών (BER)

Το μέγεθος BER ορίζεται ως ο ρυθμός με τον οποίο λαμβάνουν χώρα σφάλματα σε ένα σύστημα μετάδοσης. Το BER ισούται με τον λόγο του αριθμού των εσφαλμένων bit προς τον συνολικό αριθμό των μεταδιδόμενων bit. Μία τιμή  $10^{-12}$  σημαίνει ότι από τα  $10^{12}$  bit τα οποία μεταδόθηκαν, το 1 ήταν εσφαλμένο. Όπως καταλαβαίνουμε θέλουμε η τιμή του μεγέθους αυτού να είναι όσο το δυνατό μικρότερη. Αυτό βέβαια εξαρτάται και από τις απαιτήσεις του συστήματος. Αποδεκτές τιμές είναι  $10^{-9}$ ,  $10^{-12}$ .

$$BER = n_0 p(0|1) + n_1 p(1|0)$$

Όπου  $n_0$  και  $n_1$  είναι το ποσοστό των '0' και '1' που έχουν μεταδοθεί. Αντίστοιχα  $p(0|1)$  και  $p(1|0)$  είναι οι δεσμευμένες πιθανότητες να αναγνωρίσει ο δέκτης '0' (ή '1') ενώ έχει μεταδοθεί '1' (ή '0' αντίστοιχα).

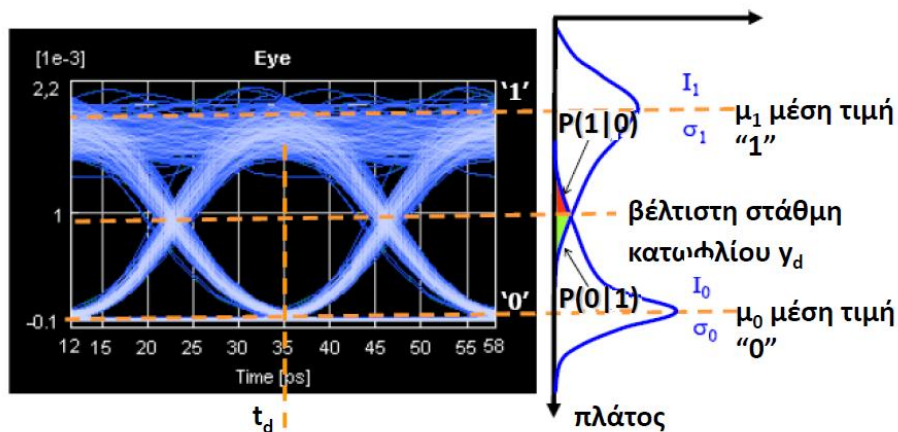
Αν σταλούν ίσοι αριθμοί '1' και '0', δηλαδή  $n_1 = n_0 = 1/2$ , τότε:

$$BER = \frac{1}{2} [p(0|1) + p(1|0)]$$

Στα σημερινά συστήματα μετάδοσης απαιτείται BER περίπου  $10^{-12}$

Τα σφάλματα στα bits είναι αποτέλεσμα λανθασμένων αποφάσεων του δέκτη για το αν το ληφθέν bit είναι '1' ή '0'.

Διασθητικά φαίνε οι "ουρές" των κατανομών που επικαλύπτονται.



Λήψη δείγματος

Εικόνα 10 - μέση τιμή και κατώφλι

Η βέλτιστη τιμή κατωφλίου  $y_d$  είναι αυτή για την οποία η πιθανότητα να αναγνωριστεί λανθασμένα ένα μεταδιδόμενο '0' ισούται με την πιθανότητα να αναγνωριστεί λανθασμένα ένα μεταδιδόμενο '1'.

Μία αρκετά καλή προσέγγιση είναι:

$$p(0|1) = p(1|0) \Rightarrow y_d = \frac{\sigma_0 \mu_1 - \sigma_1 \mu_0}{\sigma_0 + \sigma_1}$$

Το BER σε αυτήν την περίπτωση είναι:

$$BER = \frac{1}{2} \operatorname{erfc} \left( \frac{Q}{\sqrt{2}} \right) = \frac{1}{\sqrt{2\pi}Q} \exp \left( \frac{-Q^2}{2} \right)$$


όπου

$$Q = \frac{\mu_1 - \mu_0}{\sigma_1 + \sigma_0}$$

### 1.3.4 Σχέση BER και Q-factor

Από τους παραπάνω μαθηματικούς τύπους γίνεται εύκολα κατανοητό πώς συνδέονται το BER με το Q-factor. Για παράδειγμα,  $Q > 6 \Rightarrow BER < 10^{-9}$  και  $Q > 7 \Rightarrow BER < 10^{-12}$ . Η τιμή του Q factor θέλουμε να είναι όσο το δυνατό μεγαλύτερη. Η ποσότητα Q ορίζεται ακόμα και αν ο θόρυβος δεν είναι Gauss. Στην περίπτωση όμως που είναι Gauss, καθορίζει πλήρως το BER:

$$BER = \frac{1}{\sqrt{2\pi}Q} \exp \left( \frac{-Q^2}{2} \right)$$



Εικόνα 11-Σχέση BER και Q-factor

## Κεφάλαιο 2. Εισαγωγή στην Μηχανική Μάθηση

### 2.1 Εισαγωγή

Η Μηχανική μάθηση είναι ο κλάδος της τεχνητής νοημοσύνης που υλοποιεί την ιδέα ότι μια μηχανή μπορεί να κάνει πρόβλεψη, να «σκεφτεί» και να «μάθει» μόνη της πώς να λύνει ένα συγκεκριμένο πρόβλημα, έχοντας πρόσβαση στα κατάλληλα δεδομένα. Αξιοποιεί σύνθετα μαθηματικά μοντέλα και στατιστικά εργαλεία, και καθιστά τις μηχανές ικανές να εκτελούν εργασίες «διανόησης» που παραδοσιακά εκτελούνται από την ανθρώπινη σκέψη.

Η μηχανική μάθηση διερευνά τη μελέτη και την κατασκευή αλγορίθμων που μπορούν να μαθαίνουν από τα δεδομένα και να κάνουν προβλέψεις σχετικά με αυτά. Τέτοιοι αλγόριθμοι λειτουργούν κατασκευάζοντας μοντέλα από πειραματικά δεδομένα, προκειμένου να κάνουν προβλέψεις βασιζόμενες στα δεδομένα ή να εξάγουν αποφάσεις που εκφράζονται ως το αποτέλεσμα.

Στο πεδίο της ανάλυσης δεδομένων, η μηχανική μάθηση είναι μια μέθοδος που χρησιμοποιείται για την επινόηση πολύπλοκων μοντέλων και αλγορίθμων που οδηγούν στην πρόβλεψη. Τα αναλυτικά μοντέλα επιτρέπουν στους ερευνητές, τους επιστήμονες δεδομένων, τους μηχανικούς και τους αναλυτές να παράγουν αξιόπιστες αποφάσεις και αποτελέσματα και να αναδείξουν αλληλοσυσχετίσεις μέσω της μάθησης από ιστορικές σχέσεις και τάσεις στα δεδομένα. [1]

## 2.2 Κατηγορίες Μηχανικής Μάθησης

Οι εργασίες μηχανικής μάθησης συνήθως ταξινομούνται σε τρεις μεγάλες κατηγορίες, ανάλογα με τη φύση του εκπαιδευτικού «σήματος» ή την «ανατροφοδότηση» που είναι διαθέσιμα σε ένα σύστημα εκμάθησης. Αυτές είναι:

- **Επιβλεπόμενη Μάθηση (supervised learning):** Το υπολογιστικό πρόγραμμα δέχεται τις παραδειγματικές εισόδους καθώς και τα επιθυμητά αποτελέσματα από έναν «δάσκαλο», και ο στόχος είναι να μάθει έναν γενικό κανόνα προκειμένου να αντιστοιχίσει τις εισόδους με τα αποτελέσματα.
- **Μη Επιβλεπόμενη Μάθηση (unsupervised learning):** Χωρίς να παρέχεται κάποια εμπειρία στον αλγόριθμο μάθησης, πρέπει να βρεί την δομή των δεδομένων εισόδου. Η μη επιτηρούμενη μάθηση μπορεί να είναι αυτοσκοπός (ανακαλύπτοντας κρυμμένα μοτίβα σε δεδομένα) ή μέσο για ένα τέλος (χαρακτηριστικό της μάθησης).
- **Ενισχυτική Μάθηση:** Ένα πρόγραμμα υπολογιστή αλληλοεπιδρά με ένα δυναμικό περιβάλλον στο οποίο πρέπει να επιτευχθεί ένας συγκεκριμένος στόχος (όπως η οδήγηση ενός οχήματος), χωρίς κάποιος δάσκαλος να του λέει ρητά αν έχει φτάσει κοντά στο στόχο του. Ένα άλλο παράδειγμα είναι να μάθει να παίζει ένα παιχνίδι εναντίον κάποιου αντιπάλου.

Μεταξύ της επιβλεπόμενης και της μη επιβλεπόμενης μάθησης είναι η ημι-επιβλεπόμενη μάθηση, όπου ο δάσκαλος δίνει ένα ελλιπές εκπαιδευτικό σήμα: ένα σύνολο εκπαίδευσης με κάποια (συχνά πολλά) από τα αποτελέσματα στόχους να λείπουν. Η Μεταγωγή είναι μια ειδική περίπτωση της αρχής αυτής, όπου το σύνολο των καταστάσεων του προβλήματος είναι γνωστό κατά το χρόνο εκμάθησης, όμως ένα μέρος των στόχων λείπουν.

Μια άλλη κατηγοριοποίηση των προβλημάτων μηχανικής μάθησης προκύπτει όταν κάποιος θεωρήσει το επιθυμητό αποτέλεσμα του συστήματος μηχανικής μάθησης:

- **Ταξινόμηση:** Τα δεδομένα εισόδου χωρίζονται σε δύο ή περισσότερες κλάσεις, και η μηχανή πρέπει να κατασκευάσει ένα μοντέλο, το οποίο θα αντιστοιχίζει τα δεδομένα σε μία ή περισσότερες (multi-label ταξινόμηση) κλάσεις. Αυτό συνήθως εμπίπτει στην επιτηρούμενη μάθηση. Τα φίλτρα Spam είναι ένα παράδειγμα ταξινόμησης, όπου οι εισοδοί είναι τα emails ή άλλα μηνύματα και οι κλάσεις είναι "spam" και "όχι spam".

- Παλινδρόμηση: Είναι επίσης πρόβλημα επιτηρούμενης μάθησης, τα αποτελέσματα είναι συνεχή και όχι διακριτά.
- Συσταδοποίηση: Ένα σύνολο εισόδων πρόκειται να χωριστεί σε ομάδες. Σε αντίθεση με την ταξινόμηση, οι ομάδες δεν είναι γνωστές εκ των προτέρων, καθιστώντας αυτόν τον διαχωρισμό τυπική εργασία μη επιτηρούμενης μάθησης.
- Εκτίμηση πυκνότητας: Βρίσκει την κατανομή των δεδομένων εισόδου σε κάποιο χώρο.
- Προβλήματα μείωσης διαστασιμότητας (dimensionality reduction): Τα δεδομένα απλοποιούνται και αντιστοιχίζονται σε ένα χώρο λιγότερων διαστάσεων. Το στατιστικό μοντέλο θεμάτων (Topic modeling) είναι ένα σχετικό πρόβλημα, όπου η μηχανή καλείται να βρει έγγραφα που καλύπτουν παρόμοια θέματα από ένα σύνολο εγγράφων γραμμένων σε φυσική γλώσσα.

## 2.3 Η Επιβλεπόμενη Μάθηση

Η επιβλεπόμενη μάθηση χρησιμοποιείται σε πληθώρα εφαρμογών, όπως αναγνώριση ομιλίας, ανίχνευση spam, αναγνώριση αντικειμένου. Σκοπός είναι η πρόβλεψη της τιμής μιας ή περισσότερων μεταβλητών εξόδου δεδομένου διανύσματος τιμών εισόδου. Η έξοδος μπορεί να είναι συνεχής μεταβλητή (πρόβλημα παλινδρόμησης) ή διακριτή μεταβλητή (πρόβλημα ταξινόμησης). Το σύνολο των δεδομένων εκπαίδευσης περιλαμβάνει  $N$  δείγματα μεταβλητών εισόδων και τις αντίστοιχες τιμές μεταβλητών εξόδου. Οι διάφορες μέθοδοι επιβλεπόμενης μάθησης κατασκευάζουν μια συνάρτηση  $y(x)$  η οποία επιτρέπει την πρόβλεψη της τιμής της εξόδου αντίστοιχα για κάθε νέα τιμή της εισόδου.


Η επιβλεπόμενη μάθηση διακρίνεται σε 2 υποκατηγορίες: α) Παραμετρικά Μοντέλα, και β) Μη παραμετρικά μοντέλα

### 2.3.1 Παραμετρικά Μοντέλα – Νευρωνικά Δίκτυα

Στα παραμετρικά μοντέλα η συνάρτηση  $y$  είναι συνδυασμός σταθερού αριθμού παραμετρικών βασικών συναρτήσεων. Αυτά τα μοντέλα χρησιμοποιούν τα δεδομένα εκπαίδευσης για να υπολογίσουν ένα σταθερό σύνολο παραμέτρων βαρών  $w$ . Κάθε φορά που θα μπει στο στάδιο ελέγχου (δηλαδή όταν θα πρέπει να γίνει πρόβλεψη τιμής εξόδου για άγνωστη έξοδο) η πρόβλεψη θα γίνει μόνο βάσει του συγκεκριμένου τελικού συνόλου βαρών που έχει προκύψει μετά την εκπαίδευση. Γραμμικά μοντέλα παλινδρόμησης και ταξινόμησης που αποτελούνται από γραμμικό συνδυασμό μη γραμμικών βασικών

συναρτήσεων, είναι τα πιο απλά παραμετρικά μοντέλα, από την άποψη των αναλυτικών και υπολογιστικών ιδιοτήτων. Υπάρχει πληθώρα διαφορετικών βασικών συναρτήσεων, μπορεί να είναι για παράδειγμα Πολυωνυμικές, Γκαουσιανές, Σιγμοειδής κλπ. Σε περίπτωση πολλαπλών τιμών εξόδου είναι δυνατή η χρήση διαφορετικής βασικής συνάρτησης για να προκύψει η κάθε έξοδος, αν και συνήθως χρησιμοποιείται για όλες το ίδιο σύνολο συναρτήσεων. Σε αυτά τα μοντέλα, τα βάρη είναι πάντα γραμμικά στις παραμέτρους  $w$ .

Τα Νευρωνικά δίκτυα είναι το κυριότερο παράδειγμα παραμετρικού μοντέλου. Ένα Νευρωνικό Δίκτυο είναι δίκτυο κόμβων που ονομάζονται Νευρώνια (ή νευρώνες). Η βασική συνάρτηση(ή συνάρτηση ενεργοποίησης), που χρησιμοποιείται από κάθε νευρώριο, είναι μη γραμμική και παίρνει ως όρισμα έναν γραμμικό συνδυασμό των εισόδων του. Οι συντελεστές αυτού του γραμμικού συνδυασμού των εισόδων ονομάζονται βάρη, τα οποία υπολογίζονται κατά τη διάρκεια της εκπαίδευσης. Σε κάθε νευρώριο υπάρχει πάντα μια είσοδος που ισούται με τη μονάδα ( $= 1$ ) και το βάρος που αντιστοιχεί σε αυτή ονομάζεται κατώφλι (ή πόλωση). Κατά τη διάρκεια της εκπαίδευσης υπολογίζεται το σύνολο  $w$  των βαρών. Όταν τελειώσει η εκπαίδευση προκύπτει το τελικό σύνολο των βαρών το οποίο στην επόμενη φάση θα χρησιμοποιείται για την πρόβλεψη των εξόδων από άγνωστες εισόδους. Οι πιο συνηθισμένες μη γραμμικές συναρτήσεις ενεργοποίησης που χρησιμοποιούνται είναι η σιγμοειδής ή η υπερβολική εφαπτόμενη(Hyperbolic Tangent). Στα Νευρώνια εξόδου χρησιμοποιούνται ως συναρτήσεις ενεργοποίησης η ταυτοτική συνάρτηση, η σιγμοειδής και η softmax, για προβλήματα παλινδρόμησης, δυαδικής ταξινόμησης και ταξινόμησης πολλαπλών κλάσεων, αντίστοιχα.



Εικόνα 12 – Παράδειγμα Νευρωνικού Δικτύου με 2 επίπεδα και περιγραφή νευρονίου

Διαφορετικός τύπος συνδέσεων των νευρωνίων δίνουν διαφορετικό είδος Νευρωνικών Δικτύων με διακριτά χαρακτηριστικά. Όλα τα νευρώνια μεταξύ εισόδων και εξόδων ονομάζονται κρυφά νευρώνια. Τα νευρώνια σε ένα Νευρωνικό Δίκτυο σχηματίζουν έναν άκυκλο κατευθυνόμενο γράφο. Επίσης είναι τοποθετημένα σε επίπεδα. Τα ενδιάμεσα επίπεδα, που αποτελούνται από τα κρυφά νευρώνια, ονομάζονται κρυφά επίπεδα. Τα νευρώνια θα παίρνουν πάντα τις εισόδους από τις εξόδους αυτών του αμέσως προηγούμενου επιπέδου και θα προωθούν την έξοδο σε αυτά του αμέσως επόμενου επιπέδου. Νευρωνικά δίκτυα με ένα κρυφό επίπεδο μπορούν να προσεγγίσουν αρκετά καλό αποτέλεσμα με την προϋπόθεση ότι θα υπάρχει επαρκής αριθμός κρυφών νευρωνίων.

Δοσμένου ενός συνόλου εκπαίδευσης (γνωστές εισοδοί- γνωστές έξοδοι) ένα νευρωνικό δίκτυο εκπαιδεύεται ώστε να ελαχιστοποιείται μία συνάρτηση σφάλματος και προσαρμόζει τα βάρη ανάλογα. Επίσης ανάλογα με τον τύπο του προβλήματος και την αντίστοιχη επιλογή των συναρτήσεων ενεργοποίησης των νευρωνίων εξόδου, χρησιμοποιούνται και διαφορετικές συναρτήσεις σφάλματος. Σε μοντέλα παλινδρόμησης χρησιμοποιείται για το σφάλμα η μέθοδος των ελαχίστων τετραγώνων, σε αυτά της ταξινόμησης χρησιμοποιείται cross-entropy συνάρτηση σφάλματος. Η συνάρτηση σφάλματος είναι μη κυρτή συνάρτηση των παραμέτρων του δικτύου για το οποίο υπάρχουν πολλές βέλτιστες τοπικές λύσεις. Οι επαναληπτικές αριθμητικές μέθοδοι που βασίζονται σε gradient information είναι από τις πιο κοινές μεθόδους που χρησιμοποιούνται για την εύρεση του διανύσματος  $w$  που ελαχιστοποιεί τη συνάρτηση σφάλματος. Στα νευρωνικά δίκτυα χρησιμοποιείται κυρίως ο αλγόριθμος error backpropagation (οπισθοδιάδοση σφάλματος), ο οποίος παρέχει αξιόπιστη μέθοδο για να αξιολογεί τα παράγωγα της συνάρτησης λάθους σε σχέση με το σύνολο των βαρών  $w$ . Πριν την εκπαίδευση του νευρωνικού δικτύου, το σύνολο εκπαίδευσης τυπικά πρέπει να υποστεί γραμμικό μετασχηματισμό ώστε να γίνει αλλαγή κλίμακας στις τιμές εισόδου, ανεξάρτητα από το αν είναι συνεχή ή διακριτά τα δεδομένα. Οι μετασχηματισμένες μεταβλητές έχουν μηδενικό μέσο όρο και μοναδιαία τυπική απόκλιση. Η ίδια διαδικασία εφαρμόζεται και στις τιμές του στόχου σε περίπτωση προβλημάτων παλινδρόμησης. Σε περίπτωση διακριτών κατηγορικών δεδομένων, χρησιμοποιείται ένα σχήμα κωδικοποίησης 1-K-K. Αυτή η μορφή προ επεξεργασίας είναι γνωστή ως «κανονικοποίηση χαρακτηριστικών» και χρησιμοποιείται πριν από την εκπαίδευση στους περισσότερους αλγορίθμους Μηχανικής Μάθησης, αφού τα περισσότερα μοντέλα έχουν σχεδιαστεί με την υπόθεση ότι όλα τα χαρακτηριστικά έχουν συγκρίσιμες κλίμακες.

### 2.3.1.1 Πολυστρωματικά Νευρωνικά Δίκτυα Perceptron

Όπως είδαμε προηγουμένως, ένα τεχνητό νευρωνικό δίκτυο (ANN) μπορεί να οριστεί ως μια δομή που αποτελείται από ένα σύνολο απλών διασυνδεδεμένων μονάδων επεξεργασίας, που ονομάζονται τεχνητοί νευρώνες. Κάθε νευρώνας έχει ένα σύνολο εισόδων που αντιστοιχίζονται σε μία έξοδο. Ο κάθε νευρώνας είναι υπεύθυνος να εκτελέσει ένα σταθμισμένο άθροισμα των εισόδων και να θέσει την έξοδο σύμφωνα με μια μη γραμμική συνάρτηση ενεργοποίησης.

Το απλούστερο μοντέλο ANN προτάθηκε από τον Frank Rosenblatt το 1958 και ονομάζεται Perceptron. Σε αυτό το μοντέλο, ένα σύνολο τεχνητών νευρώνων συνδέεται σε μία μόνο μονάδα εξόδου. Αν και το Perceptron παρουσιάζει την ικανότητα να "μαθαίνει" μέσω παραδειγμάτων και να αυξάνει την ακρίβεια της εξόδου του προοδευτικά με τον χρόνο, αυτός ο τύπος ANN δεν είναι σε θέση να λύσει προβλήματα που είναι μη γραμμικά διαχωρίσιμα. Έτσι, για να λυθεί αυτό το πρόβλημα, ήρθε σαν εναλλακτική το δίκτυο πολλαπλών επιπέδων perceptron (MLP). Το MLP είναι μια γενίκευση του Perceptron που οργανώνει τα Perceptrons σε πολλαπλά διασυνδεδεμένα μεταξύ τους επίπεδα. Το παραδοσιακό MLP αποτελείται από τουλάχιστον τρία στρώματα και κάθε επίπεδο εκτελεί μια συγκεκριμένη εργασία. Στο επίπεδο εισόδου, ο κάθε νευρώνας αντιπροσωπεύει μια μεταβλητή εισόδου του προβλήματος, ενώ ο κάθε νευρώνας στο επίπεδο εξόδου του MLP αντιστοιχεί σε μία έξοδο του συστήματος. Το κρυφό επίπεδο, ή το σύνολο των κρυφών επιπέδων, είναι υπεύθυνο για την ικανότητα να αναπαρίστανται μη γραμμικότητες στις εργασίες ταξινόμησης ή παλινδρόμησης που έχουν ανατεθεί στο MLP. Ωστόσο, για να επιτευχθεί αυτός ο στόχος, οι νευρώνες πρέπει να χρησιμοποιήσουν μια μη γραμμική συνάρτηση ενεργοποίησης. Η σιγμοειδής συνάρτηση είναι η πιο κοινή συνάρτηση ενεργοποίησης.

Είναι απαραίτητο να χρησιμοποιηθεί αλγόριθμος για να βρεθεί το σύνολο των βαρών που βελτιστοποιεί την απόδοση του MLP. Το πρόβλημα στην εκπαίδευση του MLP είναι ότι το σφάλμα στο κρυφό επίπεδο είναι άγνωστο και αυτό το σφάλμα είναι απαραίτητο για να τρέξει η ρύθμιση των βαρών. Το 1974, ο Werbos πρότεινε μια γενίκευση του κανόνα δέλτα που χρησιμοποιήθηκε από τον Widrow και τον Hoff για να πραγματοποιήσει την εκπαίδευση ενός νευρωνικού δικτύου που ονομάζεται ADALINE. Ο αλγόριθμος που προτείνει ο Werbos ονομάζεται backpropagation (BP, οπισθοδιάδοση). Το κύριο χαρακτηριστικό του αλγορίθμου BP είναι η δυνατότητα διάδοσης του σφάλματος αναδρομικά μέσω των στρωμάτων του MLP. Ο αλγόριθμος χωρίζεται σε δύο βήματα. Στο πρώτο, οι τιμές των νευρώνων (σήματα) διαδίδονται με κατεύθυνση προς τα εμπρός (από το επίπεδο εισόδου στο επίπεδο εξόδου) και υπολογίζεται το σφάλμα,



αλλά τα βάρη δεν ενημερώνονται. Στο δεύτερο βήμα, τα σφάλματα διαδίδονται αναδρομικά (από το επίπεδο εξόδου στο επίπεδο εισόδου) και τα βάρη ενημερώνονται σύμφωνα με τον κανόνα προσαρμογής βάρους (γενικευμένο κανόνα δέλτα).

Έχει δειχτεί από τον Hornik ότι ένα MLP με μόλις ένα κρυφό στρώμα που χρησιμοποιεί αυθαίρετες συναρτήσεις μεταφοράς (π.χ. σιγμοειδή) είναι σε θέση να προσεγγίσει οποιαδήποτε συνάρτηση. Αυτό συνεπάγεται ότι κάθε αποτυχία στην εφαρμογή του MLP πρέπει να οφείλεται είτε σε ανεπαρκή μάθηση, σε ανεπαρκή αριθμό κρυφών νευρώνων ή την έλλειψη μιας ντετερμινιστικής σχέσης μεταξύ εισόδου και στόχου.

Ορισμένες πτυχές είναι σημαντικές για την προσέγγιση λειτουργίας με ένα MLP:

- Προ επεξεργασία δεδομένων: Τα δεδομένα πρέπει να υποβληθούν σε επεξεργασία πριν από την χρησιμοποίησή τους από το MLP. Αυτή η επεξεργασία αποτελείται γενικά από: Κανονικοποίηση των τιμών, ανακάτεμα ολόκληρου του συνόλου δεδομένων και ορισμό των συνόλων δεδομένων εκπαίδευσης, επικύρωσης και δοκιμής. Η κανονικοποίηση είναι απαραίτητη για την αποφυγή ασυμφωνίας μεταξύ των τιμών που θα υποβληθούν σε επεξεργασία από το MLP. Το ανακάτεμα θα βοηθήσει το MLP να μάθει από διαφορετικά μοτίβα του προβλήματος ταυτόχρονα, και το τμήμα θα καθορίσει τα σύνολα δεδομένων εκπαίδευσης, επικύρωσης και δοκιμής. Χρησιμοποιούμε το 50%, 25% και 25% των δεδομένων για εκπαίδευση, επικύρωση και δοκιμή, αντίστοιχα.
- Συνθήκη τερματισμού: Η διαδικασία εκπαίδευσης εκτελείται με την παρουσίαση των δεδομένων εκπαίδευσης στο MLP. Ο αριθμός των φορών που παρουσιάζουμε όλα τα παραδείγματα εκπαίδευσης ονομάζεται εποχές. Η επιλογή του σωστού αριθμού των εποχών μέχρι τη διακοπή της εκπαίδευσης είναι πολύ σημαντική για να αποφευχθεί μια πρόωρη σύγκλιση ή, αντίθετα, για να αποφευχθεί μια κατάσταση απώλειας της ικανότητας γενίκευσης. Στα περισσότερα προβλήματα, όταν το MLP αρχίζει να “διακοσμή” (decorate), το σφάλμα επικύρωσης αρχίζει να αυξάνεται, επομένως είναι η καλύτερη στιγμή για να τελειώσει η εκπαίδευση. Ωστόσο, υπάρχουν περιπτώσεις που το σφάλμα δεν αυξάνεται, αλλά παραμένει στην ίδια τιμή για μεγάλο χρονικό διάστημα, οπότε η εκπαίδευση μπορεί να διακοπεί σε μια τέτοια περίοδο.
- Αριθμός νευρώνων στο κρυμμένο επίπεδο: Η ικανότητα του MLP να επιλύει μη γραμμικά προβλήματα εξαρτάται από το κρυφό επίπεδο. Επομένως, ο αριθμός των νευρώνων επηρεάζει την απόδοση του δικτύου ανάλογα με τον βαθμό μη γραμμικότητας του χώρου απόφασης εισόδου.

### 2.3.2 Μη Παραμετρικά Μοντέλα

Στις μη παραμετρικές μεθόδους, ο αριθμός των παραμέτρων εξαρτάται από το σύνολο εκπαίδευσης. Αυτές οι μέθοδοι διατηρούν ένα υποσύνολο ή το σύνολο των δεδομένων εκπαίδευσης και τα χρησιμοποιούν κατά τη διάρκεια της πρόβλεψης. Σε τέτοιες μεθόδους χρησιμοποιούνται συνήθως μοντέλα κ-πλησιέστερων γειτόνων ή Support Vector Machines (SVM, Μηχανές Διανυσμάτων Υποστήριξης). Και οι δυο αυτές προσεγγίσεις μπορούν να χρησιμοποιηθούν για προβλήματα είτε ταξινόμησης είτε παλινδρόμησης.

#### β1. κ-Πλησιέστεροι γείτονες

Στην περίπτωση των μεθόδων κ-πλησιέστερων γειτόνων όλα τα δεδομένα εκπαίδευσης αποθηκεύονται (φάση εκπαίδευσης). Κατά τη διάρκεια της πρόβλεψης ανασύρονται τα κ-πλησιέστερα δείγματα στην νέα είσοδο. Στα προβλήματα ταξινόμησης υπάρχει κάποιος μηχανισμός επιλογής. Στα προβλήματα παλινδρόμησης ο μέσος όρος ή ο διάμεσος των κ πλησιέστερων γειτόνων δίνει την πρόβλεψη. Ανάλογα και με τη διάσταση του συνόλου εκπαίδευσης, η επαναληπτική προσπέλαση όλων των δειγμάτων για τον υπολογισμό των κ πλησιέστερων γειτόνων ίσως να μην είναι εύκολη ή εφικτή. Σε αυτή την περίπτωση μπορούν να χρησιμοποιηθούν δομές όπως k-d δέντρα ή locality-sensitive hash tables.

#### β2. Support Vector Machines (SVM - Μηχανές Διανυσμάτων Υποστήριξης)

Στις τεχνικές SVM, οι βασικές συναρτήσεις επικεντρώνονται σε δείγματα εκπαίδευσης: Η διαδικασία της εκπαίδευσης επιλέγει ένα υποσύνολο των βασικών συναρτήσεων. Ο αριθμός των βασικών συναρτήσεων και αυτός των δειγμάτων εκπαίδευσης που έχουν αποθηκευτεί, συνήθως είναι πολύ μικρότερος από το βασικό στοιχείο του συνόλου δεδομένων εκπαίδευσης. Δημιουργείται ένα γραμμικό σύνορο απόφασης με την μεγαλύτερη δυνατή απόσταση από τα δείγματα εκπαίδευσης. Μόνο τα πλησιέστερα σημεία στο διαχωριστικό, που ονομάζονται διανύσματα υποστήριξης, αποθηκεύονται. Για τον προσδιορισμό των παραμέτρων των SVM, πρέπει να επιλυθεί ένα μη γραμμικό πρόβλημα βελτιστοποίησης με μια κυρτή αντικειμενική συνάρτηση, για την οποία υπάρχουν αποτελεσματικοί αλγόριθμοι. Ένα σημαντικό χαρακτηριστικό των SVMs είναι ότι με την εφαρμογή μιας συνάρτησης πυρήνα μπορούν να απεικονίσουν τα δεδομένα σε χώρο μεγαλύτερων διαστάσεων, στον οποίο χώρο τα σημεία μπορούν να διαχωριστούν γραμμικά. Η συνάρτηση πυρήνα μετράει την ομοιότητα μεταξύ δύο σημείων που ανήκουν στον χώρο εισόδου: Εκφράζεται ως το εσωτερικό γινόμενο των σημείων εισόδου που έχουν απεικονιστεί σε διανυσματικό χώρο μεγαλύτερων διαστάσεων, ώστε

τα δεδομένα να είναι γραμμικά διαχωρίσιμα. Το απλούστερο παράδειγμα είναι ο γραμμικός πυρήνας, στον οποίο η μέθοδος απεικόνισης είναι η ταυτοτική απεικόνιση. Παρά το γεγονός ότι μπορούμε να εκφράσουμε τα πάντα μέσω απεικονίσεων του πυρήνα, δεν είναι απαραίτητο αυτό να γίνει για όλα τα χαρακτηριστικά. Πράγματι, στην περίπτωση μιας από τις συνηθέστερα χρησιμοποιούμενες συναρτήσεις πυρήνα, ο Γκαουσιανός πυρήνας, ο χώρος των χαρακτηριστικών έχει άπειρες διαστάσεις.

## **2.4 Η Μη Επιβλεπόμενη Μάθηση**

Η ανάλυση των κοινωνικών δικτύων, η ομαδοποίηση των γονιδίων, και η έρευνα της αγοράς συγκαταλέγονται στις πλέον επιτυχημένες εφαρμογές μεθόδων Μη επιβλεπόμενης μάθησης. Στην περίπτωση της Μη Επιβλεπόμενης Μάθησης το σύνολο εκπαίδευσης περιέχει μόνο ένα σύνολο διανυσμάτων εισόδου  $x$ . Η μη επιβλεπόμενη μάθηση μπορεί να χρησιμοποιηθεί σε πολλούς τομείς, αλλά η ομαδοποίηση(συσταδοποίηση) και η ανάλυση ομάδας είναι ο πιο συνηθισμένος. Η συσταδοποίηση είναι η διαδικασία κατανομής των δεδομένων σε ομάδες (συστάδες) έτσι ώστε η ομοιότητα εντός της ίδιας ομάδας να είναι υψηλή και μεταξύ διαφορετικών ομάδων χαμηλή. Η ομοιότητα συνήθως μετριέται με συνάρτηση απόστασης, η οποία εξαρτάται από τον τύπο των δεδομένων. Υπάρχει μεγάλη ποικιλία από προσεγγίσεις συσταδοποίησης. Στη συνέχεια θα αναλυθούν η ομαδοποίηση K-μέσων και το Γκαουσιανό μοντέλο.


### **2.4.1 Ομαδοποίηση K-μέσων**

Η ομαδοποίηση κ-μέσων είναι ίσως ο πιο γνωστός αλγόριθμος συσταδοποίησης. Είναι επαναληπτικός αλγόριθμος που ξεκινάει από τον αρχικό διαχωρισμό των δεδομένων σε  $k$  συστάδες. Στη συνέχεια υπολογίζεται το κέντρο κάθε συστάδας και τα σημεία δεδομένων αντιστοιχίζονται στη συστάδα με το κοντινότερο σε αυτά κέντρο. Η διαδικασία (υπολογισμός κέντρου και αντιστοίχιση σε αυτό των δεδομένων-σημείων) επαναλαμβάνεται μέχρι που να μη συμβαίνουν άλλες αλλαγές ή μέχρι να τελειώσει ο προκαθορισμένος αριθμός επαναλήψεων. Έτσι μπορεί να προκύψει ικανοποιητικός διαχωρισμός σε ομάδες. Όμως ο αλγόριθμος κ-μέσων είναι ευαίσθητος στις ακραίες τιμές. Πρέπει να υπάρχουν (και υπάρχουν) τρόποι που να υπολογίζεται αυτόματα το ικανοποιητικό  $k$ .

## 2.4.2 Γκαουσιανό Μοντέλο πιθανοτήτων (GMM)

Ενώ η μέθοδος κ-μέσων αντιστοιχίζει αυστηρά τα σημεία των δεδομένων σε αποκλειστικά μία συστάδα το καθένα, η προσέγγιση με πιθανότητες επιτρέπει μία πιο ήπια αντιστοίχιση και παρέχει ένα μέτρο αβεβαιότητας για αυτή. Το μοντέλο GMM είναι μια γραμμική υπέρθεση από Γκαουσιανές κατανομές και είναι ευρέως χρησιμοποιούμενο για πιθανοτική προσέγγιση στη συσταδοποίηση. Οι παράμετροι του μοντέλου είναι ο συντελεστής ανάμιξης κάθε Γκαουσιανού στοιχείου, ο μέσος όρος και η συνδιακύμανση κάθε Γκαουσιανής κατανομής. Για να μεγιστοποιηθεί η λογαριθμική συνάρτηση πιθανότητας σε σχέση με τις παραμέτρους που δίνονται σε ένα σύνολο δεδομένων, χρησιμοποιείται ο αλγόριθμος προσδοκίας-μεγιστοποίησης, καθώς δεν υπάρχει λύση κλειστής μορφής σε αυτή την περίπτωση.

Η αρχικοποίηση των παραμέτρων μπορεί να γίνει χρησιμοποιώντας μέθοδο κ-μέσων. Ο μέσος όρος και η συνδιακύμανση κάθε Γκαουσιανού στοιχείου μπορούν να αρχικοποιηθούν με δείγματα μέσων και συνδιακυμάνσεων από τη συστάδα που δημιουργείται με τη μέθοδο των κ-μέσων και οι συντελεστές ανάμιξης μπορούν να οριστούν στο κλάσμα των σημείων δεδομένων που έχουν οριστεί από τον αλγόριθμο κ-μέσων σε κάθε συστάδα. Μετά την αρχικοποίηση των παραμέτρων και την εύρεση της αρχικής τιμής της λογαριθμικής συνάρτησης πιθανότητας, ο αλγόριθμος εναλλάσσεται μεταξύ δύο βημάτων: Στο βήμα «προσδοκίας» οι τρέχουσες τιμές των παραμέτρων χρησιμοποιούνται για να καθορίσουν την «ευθύνη» κάθε στοιχείου του συνόλου δεδομένων παρατήρησης (για παράδειγμα η δεσμευμένη πιθανότητα των λανθάνουσών μεταβλητών, δεδομένου του συνόλου δεδομένων. Στο βήμα «μεγιστοποίησης» χρησιμοποιούνται οι «ευθύνες» για να εκτιμηθεί η μέγιστη πιθανοφάνεια των παραμέτρων του μοντέλου. Η σύγκλιση ελέγχεται είτε με τη λογαριθμική συνάρτηση πιθανότητας ή με τις παραμέτρους.



Εικόνα 13 – Διαφορά κ-μέσων με GMM ομαδοποιώντας ένα σύνολο δειγμάτων δεδομένων

## 2.5 Η Ημιεπιβλεπόμενη Μάθηση

Οι τεχνικές ημιεπιβλεπόμενης μάθησης είναι συνδυασμός των δύο παραπάνω τεχνικών που αναφέρθηκαν και αντιμετωπίζουν προβλήματα όπου τα περισσότερα από τα δείγματα εκπαίδευσης είναι χωρίς ετικέτα ενώ μόνο κάποια λίγα σημεία δεδομένων με ετικέτα είναι διαθέσιμα. Το προφανές πλεονέκτημα είναι ότι σε πολλούς τομείς υπάρχει πληθώρα σημείων δεδομένων χωρίς ετικέτα. Η ημι-επιβλεπόμενη μάθηση χρησιμοποιείται για τον ίδιο τύπο εφαρμογών με την επιβλεπόμενη μάθηση. Είναι ιδιαίτερα χρήσιμο όταν τα σημεία δεδομένων με ετικέτα δεν είναι τόσο κοινά ή πολύ ακριβά για να αποκτηθούν, και έτσι η χρήση διαθέσιμων δεδομένων χωρίς ετικέτα μπορεί να βελτιώσει την απόδοση.

Η αυτοεκπαίδευση είναι η παλαιότερη μορφή ημι-επιβλεπόμενης μάθησης. Είναι μια επαναληπτική διαδικασία: Κατά τη διάρκεια του πρώτου σταδίου μόνο τα σημεία δεδομένων που έχουν ετικέτα χρησιμοποιούνται από έναν αλγόριθμο επιβλεπόμενης μάθησης. Στη συνέχεια, σε κάθε βήμα, μερικά από τα σημεία χωρίς ετικέτα αποκτούν ετικέτα σύμφωνα με τη διαδικασία πρόβλεψης από τη συγκεκριμένη μέθοδο εκπαίδευσης και στη συνέχεια χρησιμοποιούνται μαζί με τα υπόλοιπα σημεία που έχουν ετικέτα, ώστε σε επόμενο βήμα να συνεχιστεί με όλα μαζί η εκπαίδευση με τον ίδιο αλγόριθμο επιβλεπόμενης μάθησης.

Η ιδέα της χρήσης μαζί δεδομένων με ετικέτα και χωρίς, έχει οδηγήσει στη δημιουργία πολλών αλγορίθμων ημιεπιβλεπόμενης μάθησης που χωρίζονται στις κατηγορίες:

- Μέθοδοι βασισμένοι σε γενετικά μοντέλα.
- Μέθοδοι που βασίζονται στην υπόθεση ότι το όριο απόφασης πρέπει να βρίσκεται σε μια περιοχή χαμηλής πυκνότητας.
- Μέθοδοι βασισμένοι σε γραφικά.
- Μέθοδοι δύο βημάτων.

## 2.6 Ενισχυτική Μάθηση

Η ενισχυτική μάθηση χρησιμοποιείται, κατά κανόνα, σε εφαρμογές όπως Ρομποτική, Χρηματοοικονομικά (όπως αποφάσεις για επενδύσεις) όπου ο σκοπός είναι η εκπαίδευση για μια συγκεκριμένη πολιτική, όπως πχ η αντιστοίχιση καταστάσεων του περιβάλλοντος με αντίστοιχες ενέργειες που πρέπει να γίνουν, ενώ υπάρχει άμεση αλληλεπίδραση με το περιβάλλον. Η Ε.Μ επιτρέπει στους πράκτορες να εκπαιδευτούν εξερευνώντας τις διαθέσιμες ενέργειες και αξιολογώντας τη συμπεριφορά τους με ανατροφοδότηση αξιολόγησης. Ο σκοπός του πράκτορα είναι να μεγιστοποιήσει μακροχρόνια την απόδοσή του. Έτσι ο πράκτορας δεν λαμβάνει υπόψη μόνο την άμεση ανταμοιβή, αλλά αξιολογεί τις συνέπειες των ενεργειών της και στο μέλλον. Η καθυστερημένη ανταμοιβή και η μέθοδος δοκιμής-σφάλματος αποτελούν τα δύο κυριότερα χαρακτηριστικά της ενισχυτικής μάθησης.

Η ενισχυτική μάθηση συχνά εκτελείται στο πλαίσιο διαδικασίας απόφασης Markov. Η αντίληψη του πράκτορα τη στιγμή  $k$  αναπαρίσταται ως μια κατάσταση  $S_k \in S$  όπου  $S$  είναι το πεπερασμένο σύνολο των καταστάσεων του περιβάλλοντος. Ο πράκτορας αλληλοεπιδρά με το περιβάλλον εκτελώντας ενέργειες. Τη χρονική στιγμή  $k$  ο πράκτορας επιλέγει μια ενέργεια  $a_k \in A$ , όπου  $A$  είναι το πεπερασμένο σύνολο ενεργειών που μπορεί να κάνει ο πράκτορας και μπορούν να προκαλέσουν μετάβαση σε μία νέα κατάσταση. Ο πράκτορας θα λάβει μια ανταμοιβή σαν αποτέλεσμα της μετάβασης, σύμφωνα με τη συνάρτηση ανταμοιβής  $\rho: S \times A \times S \rightarrow \mathbb{R}$ . Ο σκοπός των πρακτόρων είναι να βρουν την ακολουθία ζευγαριών καταστάσεων-ενεργειών η οποία μεγιστοποιεί την αναμενόμενη ανταμοιβή, δηλαδή τη βέλτιστη πολιτική.

Στη διαδικασία απόφασης Markov έχει αποδειχθεί ότι υπάρχει μια βέλτιστη, ντετερμινιστική και σταθερή πολιτική. Υπάρχουν πολλοί αλγόριθμοι που μαθαίνουν τη βέλτιστη πολιτική, είτε είναι γνωστές οι συναρτήσεις μετάβασης καταστάσεων και οι συναρτήσεις ανταμοιβής (μάθηση βασιζόμενη σε μοντέλο), είτε δεν είναι. (μάθηση χωρίς μοντέλο). Ο πιο συνηθισμένος αλγόριθμος στην Ε.Μ είναι ο Q-Learning, αλγόριθμος που δεν βασίζεται σε μοντέλο, που εκτιμάει τη βέλτιστη συνάρτηση ενέργειας-τιμής. Μία συνάρτηση ενέργειας-τιμής που ονομάζεται Qfunction δίνει την αναμενόμενη επιστροφή από ζευγάρι κατάστασης-ενέργειας για μια δοσμένη πολιτική.

Η βέλτιστη συνάρτηση ενέργειας-τιμής, η  $Q^*$ , αντιστοιχεί στη μέγιστη αναμενόμενη επιστροφή για ένα ζευγάρι κατάστασης-ενέργειας. Αφού εκπαιδευτεί με τη συνάρτηση  $Q^*$  ο πράκτορας επιλέγει την ενέργεια με το αντίστοιχο μέγιστο Q-value σε αντιστοιχία με την τρέχουσα κατάσταση. Μια λύση βασιζόμενη σε πίνακα, όπως αυτή που περιγράφηκε παραπάνω είναι κατάλληλη μόνο σε περίπτωση προβλημάτων με

περιορισμένο αριθμό καταστάσεων-ενεργειών. Για να γενικευτεί η πολιτική σε αντιστοιχία με καταστάσεις που δεν έχει «βιώσει» ο πράκτορας οι μέθοδοι ενισχυτικής μάθησης μπορούν να συνδυαστούν με άλλες μεθόδους όπως τα νευρωνικά δίκτυα.

## 2.7 Υπερεκπαίδευση, Υποεκπαίδευση και επιλογή μοντέλου

Υπερεκπαίδευση και υποεκπαίδευση είναι οι δυο πλευρές του ίδιου νομίσματος: Κακή επιλογή μοντέλου. Η υπερεκπαίδευση συμβαίνει όταν το μοντέλο που χρησιμοποιούμε είναι υπερβολικά σύνθετο για το διαθέσιμο σύνολο δεδομένων. (Για παράδειγμα ένα μεγάλο πολυώνυμο στην περίπτωση της γραμμικής παλινδρόμησης με πολυωνυμικές συναρτήσεις βάσεις, ή υπερβολικά μεγάλος αριθμός κρυμμένων νευρώνων σε ένα νευρωνικό δίκτυο). Σε αυτή την περίπτωση το μοντέλο μπορεί να προσεγγίσει πολύ καλά τα δεδομένα εκπαίδευσης, συμπεριλαμβανομένων των δειγμάτων θορύβου και τις ακραίες τιμές, αλλά θα οδηγήσει σε πολύ κακή γενίκευση, όπως ότι θα παρέχει μη ακριβείς προβλέψεις για καινούργια σημεία δεδομένων. Στον αντίποδα, η υποεκπαίδευση συμβαίνει με την επιλογή μοντέλων που δεν είναι αρκετά σύνθετα για να «καταγράψουν» χαρακτηριστικά των δεδομένων. (Όπως για παράδειγμα να χρησιμοποιούμε γραμμικό μοντέλο για δεδομένα που ταιριάζουν σε πολυωνυμικό μοντέλο 2ου βαθμού).

Αφού το σφάλμα που μετριέται στα δείγματα εκπαίδευσης είναι ανεπαρκής δείκτης για τη σωστή γενίκευση, για να αξιολογηθεί πιο σωστά η επίδοση του μοντέλου το σύνολο δεδομένων χωρίζεται σε δύο μέρη: Το «σύνολο εκπαίδευσης» και το «σύνολο αξιολόγησης». Το μοντέλο εκπαιδεύεται μόνο με το σύνολο εκπαίδευσης και μετά αξιολογείται χρησιμοποιώντας το σύνολο αξιολόγησης. Τυπικά περίπου το 70% των δειγμάτων κατανέμεται στο σύνολο εκπαίδευσης και το υπόλοιπο 30% στο σύνολο αξιολόγησης.

Άλλη δυνατότητα που είναι πολύ χρήσιμη σε περίπτωση μικρού αριθμού δεδομένων είναι η διασταυρούμενη επικύρωση, έτσι ώστε τα περισσότερα από τα διαθέσιμα δεδομένα να διατεθούν για εκπαίδευση. Σε αυτή την περίπτωση το σύνολο δεδομένων διαχωρίζεται σε  $k$  υποσύνολα. Το μοντέλο εκπαιδεύεται  $k$  φορές χρησιμοποιώντας τα  $k-1$  υποσύνολα για εκπαίδευση και το  $k$  υποσύνολο για την αξιολόγηση. Η επίδοση αξιολογείται με έναν μέσο όρο από τις  $k$  επαναλήψεις.

Σε περίπτωση υπερεκπαίδευσης το σφάλμα που μετρήθηκε στο σύνολο αξιολόγησης είναι υψηλό ενώ το σφάλμα στο σύνολο εκπαίδευσης είναι χαμηλό. Σε περίπτωση υποεκπαίδευσης και τα δύο σφάλματα που μετρήθηκαν στα σύνολα εκπαίδευσης και αξιολόγησης είναι συνήθως υψηλά.

Υπάρχουν πολλοί διαφορετικοί τρόποι για να επιλεγεί ένα μοντέλο που να μην παρουσιάζει υπερεκπαίδευση ή υποεκπαίδευση. Ένας τρόπος είναι να εκπαιδευτεί μια σειρά από μοντέλα, να συγκριθεί η επίδοσή τους σε ένα ανεξάρτητο σύνολο δεδομένων(σύνολο επικύρωσης) και μετά να επιλεγεί αυτό με την καλύτερη επίδοση. Ωστόσο ο πιο κοινός τρόπος είναι η κανονικοποίηση. Βασίζεται στην προσθήκη ενός επιπλέον όρου (του όρου κανονικοποίησης) στη συνάρτηση σφάλματος που χρησιμοποιήθηκε στο στάδιο της εκπαίδευσης. Η απλούστερη μορφή του όρου κανονικοποίησης είναι το άθροισμα των τετραγώνων όλων των παραμέτρων, το οποίο είναι γνωστό ως αποσύνθεση βάρους και οδηγεί τις παραμέτρους κοντά στο μηδέν.

Μια άλλη συνηθισμένη επιλογή είναι το άθροισμα των απόλυτων τιμών των παραμέτρων. Μια επιπλέον παράμετρος, ο συντελεστής κανονικοποίησης  $\lambda$ , ζυγίζει τη σχετική σημασία του όρου κανονικοποίησης και του, εξαρτώμενου από τα δεδομένα, σφάλματος. Μια μεγάλη τιμή  $\lambda$  επιβαρύνει σημαντικά τις απόλυτες τιμές των παραμέτρων. Θα πρέπει να επισημανθεί ότι το, εξαρτώμενο από τα δεδομένα, σφάλμα που υπολογίζεται πάνω στο σύνολο εκπαίδευσης, αυξάνει με το  $\lambda$ . Το σφάλμα που υπολογίζεται πάνω στο σύνολο επικύρωσης είναι υψηλό τόσο και για μικρές και για μεγάλες τιμές του  $\lambda$ . Στην πρώτη περίπτωση, ο όρος κανονικοποίησης έχει ελάχιστη επίδραση, που μπορεί να έχει ως αποτέλεσμα την υπερεκπαίδευση. Στην τελευταία περίπτωση, το σφάλμα που εξαρτάται από τα δεδομένα είναι αυτό που έχει ελάχιστη επίδραση και έχει ως αποτέλεσμα την κακή επίδοση του μοντέλου. Μια απλή αυτοματοποιημένη διαδικασία για την επιλογή του βέλτιστου  $\lambda$  είναι η εκπαίδευση του μοντέλου με ένα εύρος τιμών για τις παραμέτρους κανονικοποίησης και η επιλογή της τιμής που αντιστοιχεί στο ελάχιστο σφάλμα επικύρωσης. Στην περίπτωση των Νευρωνικών Δικτύων με μεγάλο αριθμό κρυμμένων νευρώνων, η τεχνική αφαίρεσης(dropout), τεχνική κατά την οποία τυχαία αφαιρούνται νευρώνια και συνδέσεις τους κατά τη διάρκεια της εκπαίδευσης, έχει αποδειχθεί ότι αποδίδει καλύτερα από άλλες μεθόδους κανονικοποίησης.



# Κεφάλαιο 3. Η Μηχανική Μάθηση στις Οπτικές Επικοινωνίες

## 3.1 Εισαγωγή

Η ιδέα της αυτοματοποίησης των σύνθετων διεργασιών απασχολεί και τον τομέα της δικτύωσης, καθώς πολλές δραστηριότητες που εμπλέκονται στον σχεδιασμό και τη λειτουργία των δικτύων θα μπορούσαν να ανατεθούν και να εκτελούνται αυτόματα από τα μηχανήματα. Για την αυτοματοποίηση αυτή, σε διάφορους τομείς της δικτύωσης έχει ήδη εφαρμοστεί η Μηχανική Μάθηση και ανταποκρίνεται στις προσδοκίες, όπως στην ανίχνευση εισβολέα, στη διαχείριση κυκλοφορίας, στον έλεγχο συμφόρησης και μετάδοσης. Η Μηχανική Μάθηση μπορεί να είναι χρήσιμη ειδικά για ρυθμίσεις μεταξύ των διαφορετικών επιπέδων, όπου η ανάλυση των δεδομένων στο φυσικό επίπεδο (πχ παρακολούθηση του B.E.R) μπορεί να προκαλέσει αλλαγές στο επίπεδο δικτύου (σε δρομολόγηση, ανάθεση σφάλματος και διαμόρφωσης)

Η Μηχανική Μάθηση μελετάται και εξελίσσεται εδώ και τρεις δεκαετίες, όμως μόλις πρόσφατα ξεκίνησε να εφαρμόζεται στις οπτικές επικοινωνίες. Αυτό οφείλετε και στο ότι η πρόσφατη ραγδαία ανάπτυξη τόσο του συστήματος οπτικών επικοινωνιών όσο και του επιπέδου δικτύου έφεραν απότομα μεγάλη αύξηση της πολυπλοκότητας. Από την πλευρά του συστήματος, ενώ η μοντελοποίηση οπτικών καναλιών ήταν πάντα περίπλοκη, η πρόσφατη υιοθέτηση σύμφωνων τεχνολογιών (coherent technologies) έχει καταστήσει ακόμη πιο δύσκολη την προτυποποίηση με την εισαγωγή μιας πληθώρας ρυθμιζόμενων παραμέτρων σχεδιασμού (όπως μορφές διαμόρφωσης, ρυθμός συμβόλων, προσαρμογή ρυθμών κωδικοποίησης, flexible channel spacing) με σκοπό τη βελτίωση των συστημάτων μεταφοράς. Επιπλέον, αυτό που κάνει αυτή τη βελτιστοποίηση ακόμα πιο δύσκολη είναι ότι το οπτικό κανάλι είναι εξαιρετικά μη γραμμικό.

Από την πλευρά της δικτύωσης, η αύξηση της πολυπλοκότητας έχει προκαλέσει μεγάλη πρόοδο στα επίπεδα δεδομένων και ελέγχου. Στο επίπεδο δεδομένων έχει αναπτυχθεί το πρότυπο EON (Ελαστικού τύπου οπτικό δίκτυο) κατά το οποίο οι πόροι του δικτύου κατανέμονται με ελαστικό τρόπο. Σε αντίθεση με αρχιτεκτονικές WDM σταθερής κατανομής του εύρους ζώνης, η αρχιτεκτονική EON προσφέρει δυνατότητα προσαρμοζόμενου εύρους ζώνης συνεχώς. Η κατανομή των πόρων στο EON μπορεί να πραγματοποιηθεί λαμβάνοντας υπ' όψη τις μεταβλητές που προκύπτουν από τα νέα δίκτυα μετάδοσης, όπως διαφορετικές

τεχνικές μετάδοσης (OFDM,NWDM), τύπους αναμεταδότη(BVT, S-BVT), μορφές διαμόρφωσης (QPSK,QAM) και ρυθμούς συμβόλων. Αυτή η ελαστικότητα στην κατανομή των πόρων αποτελεί μια πρόκληση για τους μηχανικούς δικτύων. Στο επίπεδο ελέγχου, εφαρμόζεται δυναμικός έλεγχος, όπως συμβαίνει στα SDN δίκτυα, που υπόσχεται διαρκή επαναρρύθμιση ανάλογα με τις ζητούμενες συνθήκες. Επιπλέον η επαναρρύθμιση του οπτικού υποστρώματος (optical substrate) παρουσιάζει προκλήσεις σε θέματα όπως Βελτιστοποίηση δικτύου, κατακερματισμός του φάσματος, ρυθμίσεις ισχύος ενισχυτή, ξαφνικά σφάλματα λόγω μη γραμμικότητας, τα οποία απαιτούν αυστηρή συνεργασία μεταξύ των στοιχείων ελέγχου (όπως οι SDN controllers ή ενορχηστρωτές δικτύου) και οπτικούς μετρητές απόδοσης σε επίπεδο εξοπλισμού.

Όλοι αυτοί οι βαθμοί ελευθερίας και περιορισμών είναι μια μεγάλη πρόκληση για τους μηχανικούς δικτύου για να αποφασίσουν ποιο είναι το πιο κατάλληλο σύστημα ή σχεδιασμός δικτύου. Η Μηχανική Μάθηση είναι το μέλλον για τον σχεδιασμό μελλοντικών οπτικών δικτύων και συστημάτων. Τέτοιες τεχνικές θα επιτρέπουν την εξαγωγή χρήσιμων συμπερασμάτων από διάφορους δείκτες ποιότητας (όπως ποιότητα σήματος, δείγματα κίνησης) που με άλλους τρόπους δεν θα ήταν εύκολο ή άμεσο να εξαχθούν. Κάποιες υποσχόμενες εφαρμογές της στον τομέα των οπτικών επικοινωνιών περιλαμβάνουν την πρόβλεψη σφαλμάτων, ανίχνευση εισβολέα, ασφάλεια φυσικής ροής, impairment-aware routing, low-margin design, traffic-aware capacity reconfigurations, αλλά και άλλες ακόμα που θα εξετασθούν παρακάτω. [1]

## 3.2 Κίνητρα για εφαρμογή Μηχανικής Μάθησης στις οπτικές επικοινωνίες

Τα τελευταία χρόνια η εφαρμογή μαθηματικών προσεγγίσεων που προέρχονται από τους κανόνες Μηχανικής Μάθησης έχει τραβήξει το ενδιαφέρον πολλών ερευνητών και επαγγελματιών στο πεδίο των οπτικών επικοινωνιών και δικτύων. Γενικά τα υποκ1.1είμενα κίνητρα για αυτή την τάση μπορούμε να πούμε ότι είναι τα εξής:

- Αυξανόμενη Πολυπλοκότητα του συστήματος
- Αυξανόμενη Διαθεσιμότητα των Δεδομένων

### ***Αυξανόμενη Πολυπλοκότητα του συστήματος:***

Η υιοθέτηση προηγμένων τεχνικών μετάδοσης, όπως αυτές που προβλέπονται από τη συνεκτική τεχνολογία, και η εισαγωγή εξαιρετικά ευέλικτων αρχών δικτύωσης, όπως π.χ. το πρότυπο EON, έχουν καταστήσει το σχεδιασμό και τη λειτουργία οπτικών δικτύων εξαιρετικά περίπλοκο, λόγω του υψηλού αριθμού ρυθμιζόμενων παραμέτρων που θα πρέπει να ληφθούν υπ' όψη. (Όπως για παράδειγμα μορφές διαμόρφωσης, ρυθμοί συμβόλων, προσαρμογή ρυθμών κωδικοποίησης, προσαρμογή εύρους ζώνης καναλιού κ.λπ.). Σε μία τέτοια περίπτωση, η ακριβής μοντελοποίηση του συστήματος με μέσα κλειστού τύπου είναι συχνά πολύ δύσκολη, αν όχι και αδύνατη, και στην πραγματικότητα συνήθως υιοθετούνται «κατώφλια» στα αναλυτικά μοντέλα, οδηγώντας σε υποχρησιμοποίηση πόρων και συνεπώς σε αυξημένο κόστος συστήματος.

Αντιθέτως, οι μέθοδοι ML μπορούν να «συλλάβουν» περίπλοκες μη γραμμικές συμπεριφορές συστήματος με μια σχετικά απλή εκπαίδευση με χρήση εποπτευόμενων, ή μη, αλγορίθμων που εκμεταλλεύονται τη γνώση του ιστορικού των δεδομένων δικτύου, και επομένως για την επίλυση σύνθετων διαστρωματικών προβλημάτων, που προκύπτουν τυπικά στο πεδίο της οπτικής δικτύωσης.

### ***Αυξανόμενη Διαθεσιμότητα των Δεδομένων:***

Τα σύγχρονα οπτικά δίκτυα είναι εξοπλισμένα με μεγάλο αριθμό παρακολουθητών(monitors), ικανά να παρέχουν αρκετούς τύπους πληροφοριών για ολόκληρο το σύστημα, όπως για παράδειγμα π.χ. ίχνη κυκλοφορίας, δείκτες ποιότητας σήματος (όπως BER), ειδοποιήσεις βλάβης εξοπλισμού, συμπεριφορά χρηστών κ.λπ. Εδώ, η βελτιστοποίηση που φέρνει η Μηχανική Μάθηση συνίσταται στην ταυτόχρονη

αξιοποίηση της πληθώρας συλλεγόμενων δεδομένων και την ανακάλυψη κρυφών σχέσεων μεταξύ διαφόρων τύπων πληροφοριών.

Η εφαρμογή της Μηχανικής Μάθησης στο Φυσικό Επίπεδο οφείλεται κυρίως στην παρουσία μη γραμμικών φαινομένων σε οπτικές ίνες, τα οποία καθιστούν τα αναλυτικά τα μοντέλα ανακριβή ή και πάρα πολύ σύνθετα. Αυτό έχει επιπτώσεις π.χ. στις προβλέψεις απόδοσης των οπτικών συστημάτων επικοινωνίας, όσον αφορά τον BER, τον παράγοντα ποιότητας (Q-factor) και επίσης για την αποδιαμόρφωση σήματος.

Πηγαίνοντας από το φυσικό επίπεδο στο επίπεδο δικτύωσης, ισχύουν και εκεί παρόμοια κίνητρα ισχύει για την εφαρμογή τεχνικών Μηχανικής Μάθησης. Συγκεκριμένα, ο σχεδιασμός και η διαχείριση των οπτικών δικτύων εξελίσσεται συνεχώς, λόγω της τεράστιας αύξησης της μεταφερόμενης κίνησης και των δραστικών αλλαγών στις απαιτήσεις κυκλοφορίας π.χ. όσον αφορά τη χωρητικότητα, την καθυστέρηση, την εμπειρία χρήστη και την Ποιότητα της Υπηρεσίας (QoS). Επομένως, τα τωρινά οπτικά δίκτυα αναμένεται να μπορούν να λειτουργούν υποστηρίζοντας πολύ μεγαλύτερη χρήση από ό,τι στο παρελθόν, παρέχοντας αυστηρές εγγυήσεις για την παρεχόμενη ποιότητα των υπηρεσιών. Ενώ απαιτούνται επιθετικές μεθοδολογίες βελτιστοποίησης και μηχανικής κίνησης για την επίτευξη αυτών των στόχων, τέτοιες πολύπλοκες μεθοδολογίες ενδέχεται να αντιμετωπίζουν κλιμακούμενα προβλήματα και να απαιτούν μη αποδεκτή υπολογιστική πολυπλοκότητα. Σε αυτό το πλαίσιο, η Μηχανική Μάθηση θεωρείται ως πολλά υποσχόμενος τομέας μεθοδολογιών για την αντιμετώπιση αυτού του ζητήματος, καθώς επιτρέπει την αυτοματοποιημένη αυτορρύθμιση του δικτύου και τη γρήγορη λήψη αποφάσεων αξιοποιώντας την πληθώρα δεδομένων που μπορούν να ανακτηθούν μέσω παρακολουθητών δικτύου και επιτρέποντας στους μηχανικούς δικτύου να δημιουργήσουν μοντέλα που θα οδηγούνται βάσει δεδομένων για πιο ακριβή και βελτιστοποιημένη παροχή υπηρεσιών και διαχείριση δικτύου.

Πολλές περιπτώσεις χρήσης μπορούν να επωφεληθούν από την εφαρμογή τεχνικών ανάλυσης δεδομένων και Μηχανικής Μάθησης. Στην παρούσα εργασία παρακάτω θα μελετηθούν περιπτώσεις χρήσης στους τομείς i. Φυσικού Επιπέδου και ii. Επιπέδου δικτύου.

## 3.3 Εφαρμογές Μηχανικής Μάθησης στον τομέα Φυσικού Επιπέδου

Όπως αναφέρθηκε προηγουμένως, μπορεί να υπάρξουν πολλές προκλήσεις που πρέπει να αντιμετωπιστούν στο φυσικό επίπεδο ενός οπτικού δικτύου, συνήθως για την αξιολόγηση της απόδοσης του συστήματος μετάδοσης και για τον έλεγχο εάν τυχών υποβάθμιση του σήματος (signal degradation) επηρεάζει τις υπάρχουσες δέσμες φωτός. Τέτοια παρακολούθηση μπορεί να χρησιμοποιηθεί, για παράδειγμα, για την ενεργοποίηση προληπτικών διαδικασιών, όπως έλεγχος ισχύος, έλεγχος κέρδους σε οπτικούς ενισχυτές, διαφορετική μορφή διαμόρφωσης κ.λ.π. προτού συμβεί μη αναστρέψιμη υποβάθμιση σήματος. Στη συνέχεια παρουσιάζεται μια περιγραφή των εφαρμογών Μηχανικής Μάθησης στο φυσικό επίπεδο:

- Εκτίμηση QoT
- Έλεγχος οπτικών ενισχυτών
- Αναγνώριση μορφής διαμόρφωσης (MFR)
- Αντιστάθμιση Μη Γραμμικότητας
- Παρακολούθηση οπτικής απόδοσης (OPM)

### 3.3.1 Εκτίμηση QoT

Πριν από την ανάπτυξη ενός νέου lightpath (οπτικού μονοπατιού), ένας μηχανικός συστήματος πρέπει να εκτιμήσει την ποιότητα μετάδοσης (QoT) για το νέο lightpath, καθώς και για τα ήδη υπάρχοντα. Η έννοια της ποιότητας μετάδοσης γενικά αναφέρεται σε έναν αριθμό παραμέτρων φυσικού επιπέδου, όπως ο λόγος σήματος προς θόρυβο (OSNR), το BER, ο συντελεστής Q, κ.λ.π. που επηρεάζουν την «αναγνωσιμότητα» του οπτικού σήματος στο δέκτη. Τέτοιες παράμετροι δίνουν ένα ποσοτικό μέτρο για τον έλεγχο αν θα ήταν εγγυημένο να παρέχεται ένα προκαθορισμένο επίπεδο QoT και αυτό επηρεάζεται από αρκετές συντονιζόμενες παραμέτρους σχεδιασμού, όπως, π.χ η μορφή διαμόρφωσης, ρυθμός μετάδοσης συμβόλων, ρυθμός κωδικοποίησης, φυσικό μονοπάτι στο δίκτυο κ.λ.π. Επομένως, η βελτιστοποίηση αυτής της επιλογής δεν είναι ασήμαντη και συχνά αυτή η μεγάλη ποικιλία πιθανών παραμέτρων προκαλεί την ικανότητα ενός μηχανικού συστήματος να χειρίζεται χειροκίνητα όλους τους πιθανούς συνδυασμούς ανάπτυξης lightpath.

Οι υπάρχουσες (πριν την ανάπτυξη) τεχνικές εκτίμησης για το QoT του lightpath ανήκουν σε δύο κατηγορίες:

1) «Ακριβή» αναλυτικά μοντέλα που εκτιμούν τα σφάλματα του φυσικού στρώματος, που παρέχουν ακριβή αποτελέσματα, αλλά χρειάζονται βαριές υπολογιστικές απαιτήσεις.

2) Μοντέλα με κατώφλι, που είναι υπολογιστικά πιο γρήγορα, αλλά συνήθως χρησιμοποιούν υψηλά κατώφλια που οδηγούν σε υποαξιοποίηση των πόρων του δικτύου.

Επιπλέον, αξίζει να σημειωθεί ότι, λόγω της πολύπλοκης αλληλεπίδρασης των πολλαπλών παραμέτρων συστήματος (π.χ. ισχύς σήματος εισόδου, αριθμός καναλιών, τύπος σύνδεσης, μορφή διαμόρφωσης, ρυθμός συμβόλων, απόσταση μεταξύ καναλιών κ.λπ.) και, το πιο σημαντικό, λόγω της μη γραμμικής διάδοσης σήματος μέσω του οπτικού καναλιού, η εφαρμογή αναλυτικών μοντέλων είναι μια δύσκολη εργασία, και πρέπει να γίνουν παραδοχές σχετικά με το υπό εξέταση σύστημα προκειμένου να υιοθετηθούν κατά προσέγγιση μοντέλα. Αντιθέτως, η M.M αποτελεί ένα πολλά υποσχόμενο μέσο για την αυτόματη πρόβλεψη για το εάν τα, ακόμα, μη εγκατεστημένα lightpaths θα πληρούν το απαιτούμενο κατώφλι για το QoT του συστήματος.

*Σχετικές τεχνικές Μηχανικής Μάθησης:*

Οι ταξινομητές που βασίζονται σε ΜΘ μπορούν να εκπαιδευτούν χρησιμοποιώντας επιβλεπόμενη μάθηση για να δημιουργήσουν άμεση σχέση εισόδου-εξόδου μεταξύ QoT που παρατηρείται στον δέκτη και της αντίστοιχης διαμόρφωσης lightpath όσον αφορά, π.χ., χρησιμοποιούμενη μορφή διαμόρφωσης, ρυθμό baud και/ή φυσική διαδρομή στο δίκτυο.

### **3.3.2 Έλεγχος οπτικών ενισχυτών**

Στα τρέχοντα οπτικά δίκτυα, η παροχή lightpath γίνεται πιο δυναμική, ως απάντηση στην αναγκαιότητα της εμφάνισης νέων υπηρεσιών που απαιτούν τεράστιο εύρος ζώνης για περιορισμένες χρονικές περιόδους. Δυστυχώς, η δυναμική ρύθμιση και η κατάργηση των lightpath σε διαφορετικά μήκη κύματος αναγκάζει τους χειριστές του δικτύου να αναδιαμορφώσουν τις συσκευές δικτύου «εν κινήσει» για να διατηρήσουν τη σταθερότητα τού φυσικού επιπέδου. Σε απάντηση στις ταχείες αλλαγές της ανάπτυξης του lightpath, οι ενισχυτές οπτικών ινών Erbium Doped Fiber (EDFAs) υποφέρουν από εξάρσεις ισχύος (power excursions) που εξαρτώνται από το μήκος κύματος. Δηλαδή, όταν δημιουργείται ένα νέο lightpath ή όταν ένα υπάρχον καταργείται, η απόκλιση των επιπέδων ισχύος σήματος μεταξύ διαφορετικών καναλιών (δηλαδή, μεταξύ των lightpaths που λειτουργούν σε διαφορετικά μήκη κύματος) εξαρτάται από το συγκεκριμένο το μήκος κύματος που προστίθεται ή αφαιρείται από το σύστημα.

Επομένως, χρειάζεται αυτόματος έλεγχος των επιπέδων ισχύος του σήματος προ της ενίσχυσης, ειδικά σε περίπτωση διέλευσης από πολλαπλούς EDFA, για να αποφευχθεί η παραμόρφωση του σήματος που μπορεί να προκληθεί από την υπερβολική απόκλιση ισχύος μετά την ενίσχυση, μεταξύ διαφορετικών lightpaths.

*Σχετικές τεχνικές Μηχανικής Μάθησης:*

Χάρη στη διαθεσιμότητα του ιστορικού των δεδομένων που ανακτώνται από την παρακολούθηση της κατάστασης του δικτύου, οι αλγόριθμοι παλινδρόμησης MM μπορούν να εκπαιδευτούν για να προβλέψουν με ακρίβεια την έκρηξη ισχύος μετά την ενίσχυση, σε αντιστοιχία με την προσθήκη/αφαίρεση συγκεκριμένων μηκών κύματος από το σύστημα.

### **3.3.3 Αναγνώριση μορφής διαμόρφωσης (MFR)**

Οι σύγχρονοι οπτικοί πομποί και δέκτες παρέχουν υψηλή ευελιξία στο χρησιμοποιούμενο εύρος ζώνης, τη συχνότητα φορέα και τη μορφή διαμόρφωσης, κυρίως για την προσαρμογή της μετάδοσης στον απαιτούμενο ρυθμό bit και την οπτική εμβέλεια σε ένα εύλικτο και ελαστικό περιβάλλον δικτύωσης. Δεδομένου ότι στην πλευρά του πομπού μπορεί να υιοθετηθεί μια αυθαίρετη συνεκτική μορφή οπτικής διαμόρφωσης, η γνώση αυτής της μορφής από την πλευρά του δέκτη δεν είναι πάντα εκ των προτέρων δυνατή, και αυτό μπορεί να επηρεάσει τη σωστή αποδιαμόρφωση σήματος και, κατά συνέπεια, την επεξεργασία και ανίχνευση.

*Σχετικές τεχνικές Μηχανικής Μάθησης:*

Χρήση εποπτευόμενων αλγορίθμων MM μπορεί να βοηθήσει στην αναγνώριση μορφής διαμόρφωσης στο δέκτη, χάρη στη δυνατότητα να εκπαιδευτούν με την αντιστοίχιση μεταξύ των μορφών διαμόρφωσης που έχουν υιοθετηθεί και των χαρακτηριστικών του οπτικού σήματος εισόδου.

### **3.3.4 Αντιστάθμιση Μη Γραμμικότητας**

Λόγω φαινομένων της μη γραμμικότητας οπτικών ινών, όπως το φαινόμενο Kerr, η αυτό-διαμόρφωση φάσης (SPM) και η ετερο-διαμόρφωση φάσης (XPM), η συμπεριφορά πολλών παραμέτρων απόδοσης, όπως το BER, ο συντελεστής Q, η Χρωματική διασπορά (CD), η Διασπορά Τρόπου και Πόλωσης (PMD), είναι εξαιρετικά απρόβλεπτη και αυτό μπορεί να προκαλέσει παραμόρφωση σήματος στον δέκτη (π.χ. ανισορροπία I/Q και

θόρυβος φάσης). Επομένως, συχνά υιοθετούνται πολύπλοκα αναλυτικά μοντέλα για να ανασχέσουν την υποβάθμιση του σήματος ή και να αντισταθμίσουν τα ανεπιθύμητα μη γραμμικά αποτελέσματα.

*Σχετικές τεχνικές Μηχανικής Μάθησης:*

Ενώ τα κατά προσέγγιση αναλυτικά μοντέλα υιοθετούνται συνήθως για την επίλυση τέτοιων περίπλοκων προβλημάτων μη γραμμικότητας, τα μοντέλα εποπτευόμενης Μ.Μ μπορούν να σχεδιαστούν για να προλάβουν ευθέως τα αποτελέσματα τέτοιας μη γραμμικότητας, τυπικά αξιοποιώντας τη γνώση του ιστορικού δεδομένων και δημιουργώντας σχέσεις εξόδου-εισόδου μεταξύ των παραμέτρων που παρακολουθούνται και των επιθυμητών εξόδων.

### **3.3.5 Παρακολούθηση οπτικής απόδοσης(OPM)**

Με τις απαιτήσεις χωρητικότητας στα οπτικά συστήματα επικοινωνίας να είναι αυξανόμενες, η παρακολούθηση της απόδοσης είναι ζωτικής σημασίας για την εξασφάλιση ισχυρών και αξιόπιστων δικτύων. Η παρακολούθηση της οπτικής απόδοσης στοχεύει στην εκτίμηση των παραμέτρων μετάδοσης του συστήματος οπτικών ινών, όπως το BER, ο συντελεστής Q, CD, PMD, κατά τη διάρκεια ζωής του lightpath. Η γνώση τέτοιων παραμέτρων μπορεί στη συνέχεια να χρησιμοποιηθεί για την ολοκλήρωση διαφόρων εργασιών, όπως π.χ. ενεργοποίηση μονάδων για αντισταθμισμό πόλωσης, ρύθμιση ισχύος (adjusting launch power), μεταβολή της επιλεγμένης μορφής διαμόρφωσης, αλλαγή διαδρομής των lightpaths κ.λ.π. Συνήθως, οι παράμετροι οπτικής απόδοσης πρέπει να συλλέγονται σε διάφορα σημεία παρακολούθησης κατά μήκος του lightpath, επομένως απαιτείται μεγάλος αριθμός παρακολουθητών(monitors) , προκαλώντας αυξημένο κόστος συστήματος. Επομένως, απαιτείται αποτελεσματική ανάπτυξη παρακολουθητών οπτικής απόδοσης στις κατάλληλες τοποθεσίες δικτύου για την εξαγωγή πληροφοριών του δικτύου με λογικό κόστος.

*Σχετικές τεχνικές Μηχανικής Μάθησης:*

Για να μειωθεί ο αριθμός των παρακολουθητών (monitors) που θα αναπτυχθούν στο σύστημα, ειδικά σε ενδιάμεσα σημεία των lightpaths, μπορούν να χρησιμοποιηθούν εποπτευόμενοι αλγόριθμοι εκμάθησης για την αντιστοίχιση μεταξύ των παραμέτρων του καναλιού οπτικών ινών και των ιδιοτήτων του σήματος που λαμβάνεται στον δέκτη, οι οποίες μπορούν να ανακτηθούν, όπως π.χ. παρατηρώντας στατιστικά στοιχεία από power eye διαγράμματα, πλάτος σήματος, OSNR κ.λ.π.



## 3.4 Εφαρμογές Μηχανικής Μάθησης στον τομέα Επιπέδου Δικτύου

Όπως στο Φυσικό Επίπεδο, έτσι και στο επίπεδο δικτύου, προκύπτουν πολλές ακόμα περιπτώσεις χρήσης Μ.Μ. Η παροχή νέων lightpaths ή η αποκατάσταση των υπαρχόντων σε ενδεχόμενη αποτυχία του δικτύου, απαιτεί πολύπλοκες και γρήγορες αποφάσεις που εξαρτώνται από πολλά και ,γρήγορα εξελισσόμενα, δεδομένα, καθώς, π.χ. οι χειριστές πρέπει να λαμβάνουν τις επιπτώσεις επάνω στις υπάρχουσες συνδέσεις που παρέχονται από την νέο-εισερχόμενη κυκλοφορία. Σε γενικές γραμμές, μια εκτίμηση των απαιτήσεων των χρηστών και των υπηρεσιών είναι επιθυμητή για μια αποτελεσματική λειτουργία του δικτύου, καθώς επιτρέπει την αποφυγή της κατασπατάλησης πόρων του δικτύου και την ανάπτυξη πόρων με τα λογικά περιθώρια και σε λογικό κόστος. Μπορούμε να κατατάξουμε τις περιπτώσεις χρήσης στις παρακάτω κύριες κατηγορίες:

- Πρόβλεψη κυκλοφορίας.
- Σχεδιασμός εικονικής τοπολογίας (VTD) και επαναδιαμόρφωση.
- Διαχείριση σφαλμάτων.
- Ταξινόμηση ροής κυκλοφορίας.
- Υπολογισμός διαδρομής.

### 3.4.1 Πρόβλεψη κυκλοφορίας

Η ακριβής πρόβλεψη κυκλοφορίας στον χώρο και τον χρόνο επιτρέπει στους χειριστές να σχεδιάζουν και να λειτουργούν αποτελεσματικά τα δίκτυά τους. Στη φάση σχεδιασμού, η πρόβλεψη κυκλοφορίας επιτρέπει τη μείωση της υπερχρησιμοποίησης πόρων όσο το δυνατόν περισσότερο. Κατά τη λειτουργία του δικτύου, η χρήση πόρων μπορεί να βελτιστοποιηθεί εκτελώντας μηχανική κυκλοφορίας βασιζόμενη σε δεδομένα πραγματικού χρόνου, τελικά επαναδρομολογώντας την υπάρχουσα κίνηση και δεσμεύοντας πόρους για μελλοντικά αιτήματα εισερχόμενης κίνησης.

*Σχετικές τεχνικές Μηχανικής Μάθησης:*

Μέσω της γνώσης του ιστορικού δεδομένων σχετικά με τη συμπεριφορά των χρηστών και τα προφίλ επισκεψιμότητας στον χώρο και τον χρόνο, ένας επιβλεπόμενος αλγόριθμος MM μπορεί να εκπαιδευτεί για να προβλέψει τις μελλοντικές απαιτήσεις κίνησης και τις αντίστοιχες ανάγκες πόρων. Αυτό επιτρέπει στους μηχανικούς του δικτύου να ενεργοποιούν π.χ προληπτική επαναδρομολόγηση της κυκλοφορίας και

περιοδικά βελτιστοποίηση του δικτύου, έτσι ώστε να εξυπηρετούν την κυκλοφορία όλων των χρηστών και ταυτόχρονα να μειώνουν τη χρήση των πόρων του δικτύου.

Επιπλέον, αλγόριθμοι μάθησης χωρίς επίβλεψη μπορούν επίσης να χρησιμοποιηθούν για την εξαγωγή κοινών μοτίβων κυκλοφορίας σε διαφορετικά τμήματα του δικτύου. Με αυτόν τον τρόπο, παρόμοιες διαδικασίες σχεδιασμού και διαχείρισης (π.χ. ανάπτυξη ή και δέσμευση χωρητικότητας δικτύου) μπορούν να ενεργοποιηθούν επίσης σε διαφορετικά μέρη του δικτύου, τα οποία δείχνουν ομοιότητες ως προς τις απαιτήσεις κυκλοφορίας, δηλαδή ανήκουν σε ένα ίδιο σύνολο με προφίλ κυκλοφορίας.

Αξίζει να σημειωθεί, ότι η εφαρμογή της πρόβλεψης της κυκλοφορίας και οι σχετικές τεχνικές M.M, ποικίλλουν σημαντικά ανάλογα με το εξεταζόμενο τμήμα ή είδος δικτύου (π.χ., οι προσεγγίσεις για δίκτυα μεταξύ κέντρων δεδομένων ενδέχεται να διαφέρουν από αυτές για τα δίκτυα πρόσβασης), καθώς τα χαρακτηριστικά κίνησης εξαρτώνται σε μεγάλο βαθμό από τον εξεταζόμενο τομέα του δικτύου.

### **3.4.2 Σχεδιασμός εικονικής τοπολογίας (VTD) και επαναδιαμόρφωση**

Η αφαίρεση των υπηρεσιών δικτύου επικοινωνίας μέσω μιας εικονικής τοπολογίας υιοθετείται ευρέως από τους χειριστές του δικτύου και τους παρόχους υπηρεσιών. Αυτή η αφαίρεση συνίσταται στην αναπαράσταση της συνδεσιμότητας μεταξύ δύο τελικών σημείων σημείο προς σημείο (π.χ. δύο κέντρων δεδομένων) μέσω μιας γειτνίασης στην εικονική τοπολογία (δηλαδή, έναν εικονικό σύνδεσμο), αν και τα δύο τερματικά σημεία δεν είναι απαραίτητα φυσικά συνδεδεμένα. Μετά τον καθορισμό του συνόλου όλων των εικονικών συνδέσμων, δηλαδή, αφού αναγνωριστούν όλα τα αιτήματα για lightpath, το VTD απαιτεί την επίλυση ενός προβλήματος δρομολόγησης και εκχώρησης μήκους κύματος (RWA) για κάθε lightpath πάνω από το υποκείμενο φυσικό δίκτυο. Σε γενικές γραμμές, πολλές εικονικές τοπολογίες μπορούν να συνυπάρχουν στο ίδιο φυσικό δίκτυο και ενδέχεται να αντιπροσωπεύουν π.χ., υπηρεσίες που απαιτούνται από διαφορετικούς πελάτες ή ακόμη και διαφορετικές υπηρεσίες που παρέχονται στον ίδιο πελάτη, καθεμία με ένα συγκεκριμένο σύνολο απαιτήσεων (π.χ. όσον αφορά το QoS, το εύρος ζώνης ή και την καθυστέρηση).

Το VTD δεν είναι απαραίτητο μόνο για την εκχώρηση νέων πόρων δικτύων για την παροχή νέας υπηρεσίας. Σε ορισμένες περιπτώσεις, π.χ. όταν συμβαίνουν αστοχίες δικτύου ή όταν θα πρέπει να γίνουν διαδικασίες για επαναχρησιμοποίηση πόρων δικτύου, οι υπάρχουσες (δηλαδή, οι ήδη σχεδιασμένες) εικονικές τοπολογίες θα αναδιατάσσονται και σε αυτές τις περιπτώσεις αναφερόμαστε στην VT-αναδιάρθρωση.

Για την εκτέλεση του σχεδιασμού και της αναδιάρθρωσης των εικονικών τοπολογιών, οι διαχειριστές δικτύου όχι μόνο πρέπει να παρέχουν (ή να ανακατανέμουν) χωρητικότητα δικτύου για τις απαιτούμενες υπηρεσίες, αλλά μπορεί επίσης να χρειαστεί να παρέχουν πρόσθετους πόρους σύμφωνα με τα ειδικά χαρακτηριστικά της υπηρεσίας, π.χ. για την εγγύηση της προστασίας των υπηρεσιών ή και για να πληρούν τις προϋποθέσεις QoS ή καθυστέρησης. Αυτός ο τύπος παροχής υπηρεσιών αναφέρεται συχνά ως κατακερματισμός δικτύου, λόγω του γεγονότος ότι κάθε παρεχόμενη υπηρεσία (δηλαδή, κάθε VT) αντιπροσωπεύει ένα κομμάτι του συνολικού δικτύου.

#### *Σχετικές τεχνικές Μηχανικής Μάθησης:*

Για την εκτέλεση της VTD και VT αναδιάρθρωσης, χρησιμοποιούνται ταξινομητές M.M που μπορούν να εκπαιδευτούν ώστε να αποφασίζουν βέλτιστα πώς να κατανέμουν πόρους δικτύου, λαμβάνοντας υπ' όψη ταυτόχρονα μεγάλο αριθμό διαφορετικών και ετερογενών απαιτήσεων υπηρεσίας για μια ποικιλία εικονικών τοπολογιών (δηλ. τομέων δικτύου), επιτρέποντας γρήγορη λήψη αποφάσεων και βελτιστοποιημένη παροχή πόρων, ειδικά υπό συνθήκες δυναμικά μεταβαλλόμενου δικτύου.

### **3.4.3 Διαχείριση σφαλμάτων**

Κατά τη διαχείριση ενός δικτύου, η δυνατότητα εκτέλεσης ανίχνευσης και εντοπισμού κάποιου σφάλματος ή ακόμη και προσδιορισμού της αιτίας του σφάλματος του δικτύου, είναι ζωτικής σημασίας καθώς μπορεί να επιτρέψει στους χειριστές να πραγματοποιήσουν άμεσα επαναδρομολόγηση της κίνησης, προκειμένου να διατηρήσουν την υπηρεσία στη σωστή κατάσταση, και να πληρούν τις συμφωνίες επιπέδου υπηρεσίας (SLAs), και να ανακάμψουν γρήγορα από το σφάλμα. Ο χειρισμός σφαλμάτων δικτύου μπορεί να επιτευχθεί σε διαφορετικά επίπεδα. Για παράδειγμα, η εκτέλεση ανίχνευσης σφάλματος, δηλαδή, ο προσδιορισμός του συνόλου *lightpaths* που επηρεάστηκαν από ένα σφάλμα, είναι μια σχετικά απλή εργασία, η οποία επιτρέπει στους χειριστές δικτύου να αναδιαμορφώσουν μόνο τις επηρεαζόμενα *lightpaths*, π.χ., με αλλαγή δρομολόγησης της αντίστοιχης κίνησης. Επιπλέον, η ικανότητα της εκτέλεσης του εντοπισμού του σφάλματος επιτρέπει την ενεργοποίηση των διαδικασιών αποκατάστασης. Με αυτόν τον τρόπο, το δίκτυο μπορεί να επιστρέψει στην κατάσταση που βρισκόταν πριν από το σφάλμα, η οποία είναι, γενικά, μια βελτιστοποιημένη κατάσταση από την άποψη της χρήσης πόρων. Επιπλέον, ο προσδιορισμός της αιτίας του σφάλματος του δικτύου (π.χ. προσωρινή κυκλοφοριακή συμφόρηση, διακοπή συσκευών, ή ακόμη και ανώμαλης συμπεριφοράς από αποτυχία αισθητήρων), είναι χρήσιμος για την επιλογή των κατάλληλων διαδικασιών επαναφοράς και επαναρρύθμισης της

κυκλοφορίας, καθώς μερικές φορές η απομακρυσμένη επαναρρύθμιση των lightpaths μπορεί να είναι αρκετή για τον χειρισμό του σφάλματος, ενώ σε ορισμένες άλλες περιπτώσεις απαιτείται επιτόπια παρέμβαση. Επιπλέον, η έγκαιρη αναγνώριση της αιτίας του σφάλματος επιτρέπει τη γρηγορότερη επισκευή του εξοπλισμού και την επακόλουθη μείωση του μέσου χρόνου επισκευής (MTTR).

*Σχετικές τεχνικές Μηχανικής Μάθησης:*

Η M.M μπορεί να βοηθήσει στον χειρισμό του μεγάλου όγκου πληροφοριών που προέρχονται από τη συνεχή δραστηριότητα ενός τεράστιου αριθμού αισθητήρων δικτύου και ειδοποιήσεων. Π.χ. οι αλγόριθμοι ταξινόμησης M.M μπορούν να εκπαιδευτούν για να διακρίνουν μεταξύ κανονικής και ανώμαλης (δηλαδή υποβαθμισμένης) μετάδοσης. Σε τέτοιες περιπτώσεις, μπορούν επίσης να χρησιμοποιηθούν ημιεπιβλεπόμενες προσεγγίσεις, όποτε τα δεδομένα με ετικέτα είναι λιγοστά, αλλά υπάρχει μεγάλη ποσότητα δεδομένων χωρίς ετικέτα. Επιπλέον, οι ταξινομητές M.M μπορούν να εκπαιδευτούν ώστε να διακρίνουν τις αιτίες του σφάλματος, εκμεταλλευόμενοι τη γνώση που προκύπτει από αστοχίες που προέκυψαν προηγουμένως.

#### **3.4.4 Ταξινόμηση ροής κυκλοφορίας**

Όταν συνυπάρχουν διαφορετικοί τύποι υπηρεσιών στην ίδια υποδομή δικτύου, η ταξινόμηση των αντίστοιχων ροών κίνησης πριν από την παροχή τους, μπορεί να επιτρέψει την αποτελεσματική κατανομή πόρων, ελαχιστοποιώντας τον κίνδυνο υποχρησιμοποίησης ή υπερχρησιμοποίησης. Επιπλέον, η ακριβής ταξινόμηση των ροών αξιοποιείται επίσης για ήδη παρεχόμενες υπηρεσίες για την εφαρμογή συγκεκριμένων πολιτικών ροών, π.χ. για χειρισμό προτεραιότητας πακέτων, για εκτέλεση ελέγχου ροής και συμφόρησης και για διασφάλιση κατάλληλου QoS σε κάθε ροή σύμφωνα με τους SLAs.

*Σχετικές τεχνικές Μηχανικής Μάθησης:*

Με βάση τα διάφορα χαρακτηριστικά κυκλοφορίας και την εκμετάλλευση του μεγάλου όγκου πληροφοριών που περιέχονται στα πακέτα δεδομένων, οι επιβλεπόμενοι αλγόριθμοι M.M μπορούν να εκπαιδευτούν για να εξαγάγουν κρυμμένα χαρακτηριστικά της κυκλοφορίας και να εκτελούν γρήγορη ταξινόμηση πακέτων και διάκριση ροών.

### 3.4.5 Υπολογισμός διαδρομής

Κατά την εκτέλεση της κατανομής πόρων του δικτύου για μια εισερχόμενη αίτηση υπηρεσίας, θα πρέπει να επιλεγεί μια κατάλληλη διαδρομή προκειμένου να αξιοποιηθούν αποτελεσματικά οι διαθέσιμοι πόροι του δικτύου για να ικανοποιηθεί η ζητούμενη κίνηση με το επιθυμητό QoS και χωρίς να επηρεάσει τις υπάρχουσες υπηρεσίες, που ήδη παρέχονταν από το δίκτυο. Παραδοσιακά, ο υπολογισμός διαδρομής εκτελείται χρησιμοποιώντας αλγόριθμους δρομολόγησης βάσει κόστους, όπως αλγόριθμοι Dijkstra, Bellman-Ford, Yen, οι οποίοι βασίζονται στον ορισμό μιας προκαθορισμένης μετρικής κόστους (π.χ με βάση την απόσταση μεταξύ πηγής και προορισμού, την end-to-end καθυστέρηση, η την κατανάλωση ενέργειας ή ακόμα και ένας συνδυασμός πολλών μετρικών) για να διακρίνει μεταξύ εναλλακτικών διαδρομών.

*Σχετικές τεχνικές Μηχανικής Μάθησης:*

Σε αυτό το πλαίσιο, η χρήση επιβλεπόμενης M.M μπορεί να είναι χρήσιμη καθώς επιτρέπει ταυτόχρονα να εξετάσουμε πολλές παραμέτρους που περιλαμβάνουν το εισερχόμενο αίτημα υπηρεσίας μαζί με τις τρέχουσες πληροφορίες κατάστασης δικτύου και να αντιστοιχηθούν αυτές τις πληροφορίες σε μια βελτιστοποιημένη λύση δρομολόγησης, χωρίς να απαιτούνται περίπλοκες αξιολογήσεις κόστους δικτύου και έτσι να επιτρέπεται γρήγορη επιλογή διαδρομής και παροχή υπηρεσιών.

# Κεφάλαιο 4. Λεπτομερής επισκόπηση της εφαρμογής Μηχανικής Μάθησης στις οπτικές επικοινωνίες

## 4.1 Εφαρμογές MM στο Φυσικό Επίπεδο

### 4.1.1 Εκτίμηση Ποιότητας Μετάδοσης

Η εκτίμηση QoT συνίσταται με υπολογισμό μετρικών ποιότητας μετάδοσης όπως το OSNR, το BER, ο συντελεστής Q, CD ή PMD με μετρήσεις που συλλέγονται απευθείας από τους παρακολουθητές (performance monitors) απόδοσης οπτικού δικτύου που είναι εγκατεστημένοι στην πλευρά του δέκτη, ή και από τα χαρακτηριστικά του lightpath.

Η εκτίμηση QoT διαχωρίζεται συνήθως σε δύο σενάρια:

- Πρόβλεψη της ποιότητας μετάδοσης για μη εγκατεστημένων ακόμα lightpaths, βάσει του ιστορικού παρατηρήσεων και μετρήσεων που έχουν συλλεχθεί από ήδη εγκατεστημένα.
- Παρακολούθηση της ποιότητας μετάδοσης σε ήδη εγκατεστημένα lightpaths με σκοπό τον εντοπισμό σφαλμάτων και δυσλειτουργιών.

Η πρόβλεψη QoT για μη εγκατεστημένα lightpaths βασίζεται σε έξυπνα εργαλεία, ικανά να προβλέψουν εάν ένα υποψήφιο lightpath θα πληρεί την απαιτούμενη ποιότητα που εγγυάται η υπηρεσία (QoS, αντιστοιχίζεται σε τιμές κατωφλίου συντελεστών όπως OSNR, BER ή Q factor). Το πρόβλημα διατυπώνεται συνήθως ως πρόβλημα δυαδικής ταξινόμησης, όπου ο ταξινομητής δίνει για έξοδο μια απάντηση ναι/όχι με βάση τα χαρακτηριστικά του lightpath (π.χ. το μήκος του, τον αριθμό των συνδέσμων, τη μορφή διαμόρφωσης που χρησιμοποιείται για τη μετάδοση, τη συνολική κατάληψη φάσματος των διασταυρούμενων συνδέσμων κλπ.).

Προτείνεται μια πρώτη προσέγγιση με λογική αιτιολογίας βάσει περιπτώσεων (Case Based Reasoning, CBR), που βασίζεται στη διατήρηση μιας γνωσιακής βάσης δεδομένων όπου αποθηκεύονται πληροφορίες για τα μετρημένα Q-factor από τα ήδη ανεπτυγμένα Lightpaths μαζί με τη διαδρομή τους, το επιλεγμένο μήκος κύματος, το συνολικό μήκος, συνολικό αριθμό και τυπική απόκλιση του αριθμού των Lightpaths που συν-διαδίδονται σε κάθε σύνδεση. Όταν φτάνουν αιτήματα νέας κίνησης, το περισσότερο όμοιο σε αυτά (όπου η ομοιότητα υπολογίζεται μέσω της Ευκλείδειας απόστασης στον πολυδιάστατο χώρο των κανονικοποιημένων χαρακτηριστικών) ανακτάται από τη βάση δεδομένων και παίρνεται μια απόφαση συγκρίνοντας τη συσχετισμένη μέτρηση Q-factor με ένα προκαθορισμένο από το σύστημα κατώφλι. Όσο πιο σωστή είναι διαστασιολόγηση και η

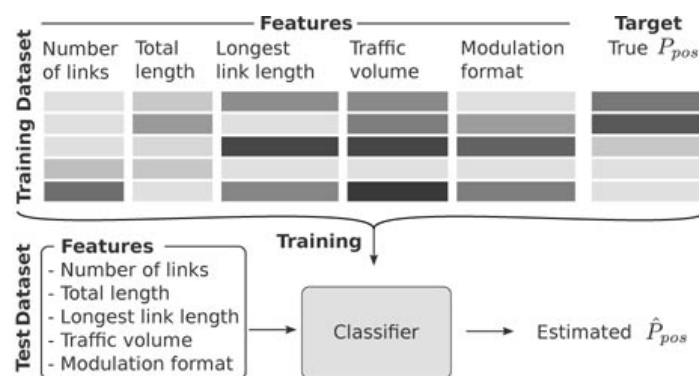
συντήρηση της βάσης δεδομένων τόσο πιο σημαντικά επηρεάζεται η απόδοση της CBR τεχνικής. Υπάρχουν αλγόριθμοι που την κρατάνε ενημερωμένη και διαγράφουν παλιές ή άχρηστες εγγραφές.

Μια δεύτερη προσέγγιση επίσης με βάση δεδομένων προτείνεται επίσης για τη μείωση της αβεβαιότητας σχετικά με τις παραμέτρους δικτύου και τα περιθώρια σχεδιασμού, όπου τα δεδομένα πεδίου συλλέγονται από έναν ελεγκτή δικτύου που ορίζεται από λογισμικό και αποθηκεύονται σε ένα κεντρικό αποθετήριο. Στη συνέχεια ένα Q εργαλείο (Qtool) χρησιμοποιείται για να παράξει μια εκτίμηση του μετρημένου στο πεδίο SNR βασιζόμενο σε educated εικασίες σε (άγνωστες) παραμέτρους δικτύου και τέτοιες εικασίες επαναληπτικά ενημερώνονται μέσω αλγορίθμων κατάβασης κλίσης, μέχρι η διαφορά μεταξύ των εκτιμώμενων και μετρημένων στο πεδίο SNR πέσει κάτω από ένα προ-ορισμένο κατώφλι. Η νέες εκτιμώμενες παράμετροι αποθηκεύονται στη βάση δεδομένων και μπορούν να χρησιμοποιηθούν για μελλοντικές απαιτήσεις. Το trade-off μεταξύ του μεγέθους της βάσης δεδομένων και του φάσματος σφάλματος εκτίμησης SNR αξιολογείται μέσω αριθμητικών προσομοιώσεων.

Επίσης, στο πλαίσιο μετάδοσης με πολυδιανομή, υπάρχει τεχνική όπου ένα Νευρωνικό δίκτυο εκπαιδεύεται για να προβλέψει πότε το Q-factor θα υπερβεί ένα προκαθορισμένο από το σύστημα κατώφλι, χρησιμοποιώντας ως χαρακτηριστικά το συνολικό μήκος του Lightrpath, τον αριθμό των ενισχυτών EDFA που διασταυρώνονται, το μέγιστο μήκος της σύζευξης, ο βαθμός του κόμβου προορισμού και το μήκος κύματος του καναλιού που χρησιμοποιείται για τη μετάδοση με τα υποψήφια Lightrpaths. Το Νευρωνικό δίκτυο εκπαιδεύεται Online με μικρά σύνολα δεδομένων, σύμφωνα με την εξέλιξη του δικτύου, ώστε να είναι δυνατές τακτικές ενημερώσεις για το μοντέλο πρόβλεψης. Μια τεχνική διαφυγής υιοθετείται κατά την εκπαίδευση ώστε να αποφευχθεί η υπερεκπαίδευση(overfitting). Η έξοδος από την ταξινόμηση, αξιοποιείται από έναν ευριστικό αλγόριθμο για δυναμική δρομολόγηση και εκχώρηση φάσματος, ο οποίος αποφασίζει πότε το αίτημα θα πρέπει να εξυπηρετηθεί ή να αποκλειστεί. Η επίδοση του αλγορίθμου αξιολογείται ως προς την πιθανότητα αποκλεισμού.

Σε άλλη τεχνική ένας δυαδικός ταξινομητής τυχαίου δάσους χρησιμοποιείται για να προβλέψει την πιθανότητα κατά την οποία το BER από μη εγκατεστημένα lightrpaths θα ξεπεράσει ένα προκαθορισμένο από το σύστημα κατώφλι. Όπως φαίνεται παρακάτω στην εικόνα 14 ο ταξινομητής παίρνει σαν είσοδο ένα σύνολο χαρακτηριστικών που περιλαμβάνουν το συνολικό μήκος και μέγιστο μήκος σύζευξης από το υποψήφιο lightrpath, τον αριθμό των διασταυρωμένων συνδέσεων, την ποσότητα της κίνησης που είναι να μεταδοθεί και τον τύπο της διαμόρφωσης που θα υιοθετηθεί για τη μετάδοση.

Εξετάζονται διάφοροι εναλλακτικοί συνδυασμοί διαδρομών και μορφών διαμόρφωσης και ο ταξινομητής προσδιορίζει αυτούς που πιθανότατα θα ικανοποιήσουν τις απαιτήσεις BER. Σε άλλη παραλλαγή, χρησιμοποιείται ένας ταξινομητής τυχαίου δάσους μαζί με άλλο έναν με κ-πλησιέστερους γείτονες και έναν SVM. Επίσης μπορούν να χρησιμοποιηθούν αυτοί οι τρεις ταξινομητές ώστε να αντιστοιχήσουν ετικέτες QoT με ένα μεγάλο σύνολο από lightpaths με σκοπό να αναπτύξουν μια βάση γνώσης και να ανακαλύψουν ποιος είναι ο καλύτερος ταξινομητής. Από την ανάλυση προκύπτει ότι το SVM είναι καλύτερος σε επίδοση από τους άλλους δύο αλλά απαιτεί περισσότερο χρόνο υπολογισμού.



Εικόνα 14 - Πλαίσιο Ταξινόμησης


Δυο εναλλακτικές προσεγγίσεις που ονομάζονται *network kriging* και *norm L2 minimization* μπορούν να εφαρμοστούν στο πλαίσιο της εκτίμησης του QoT: Βασίζονται στην εγκατάσταση lightpaths-ανιχνευτών τα οποία δεν μεταφέρουν δεδομένα χρήστη αλλά χρησιμοποιούνται για τη συλλογή μετρήσεων πεδίου. Οι προτεινόμενες μεθοδολογίες συμπερασμάτων εκμεταλλεύονται τη χωρική συσχέτιση μεταξύ των μετρήσεων QoT των lightpath-ανιχνευτών και των lightpath μεταφοράς δεδομένων που μοιράζονται κάποιους φυσικούς συνδέσμους για να παρέχουν μια εκτίμηση του παράγοντα Q των ήδη αναπτυγμένων ή μελλοντικών lightpaths. Αυτές οι μέθοδοι μπορούν να εφαρμοστούν υποθέτοντας είτε ένα κεντρικό εργαλείο λήψης αποφάσεων είτε με κατανεμημένο τρόπο, όπου κάθε κόμβος έχει μόνο τοπικές γνώσεις για τις μετρήσεις του δικτύου. Καθώς η εγκατάσταση lightpaths-ανιχνευτών είναι κοστοβόρα και καταλαμβάνει φασματικούς πόρους, μελετάται η αντιστάθμιση μεταξύ του αριθμού των ανιχνευτών και της ακρίβειας της εκτίμησης. Η αντικατάσταση των lightpath-ανιχνευτών μπορεί να γίνει με διάφορους ευριστικούς αλγόριθμους.



Επιπλέον, για την πρόβλεψη απόδοσης των WDM συστημάτων οπτικών επικοινωνιών μπορεί να χρησιμοποιηθεί μια προσέγγιση βάσει δεδομένων, που χρησιμοποιεί τεχνική μηχανικής μάθησης με γκαουσιανές διαδικασίες μη γραμμικής παλινδρόμησης (GPR), η οποία αποδεικνύεται πειραματικά. Ο πυρήνας αυτής της προσέγγισης (και μάλιστα οποιασδήποτε τεχνικής ML) είναι η γενίκευση: Πρώτα το μοντέλο «μαθαίνει» από τα μετρημένα δεδομένα που αποκτήθηκαν κάτω από ένα σύνολο ρυθμίσεων συστήματος και στη συνέχεια το μοντέλο πρόβλεψης εφαρμόζεται ώστε να εκτελέσει προβλέψεις για ένα νέο σύνολο ρυθμίσεων. Το πλεονέκτημα της προσέγγισης είναι ότι οι δυναμικές σύνθετου συστήματος μπορούν πιο εύκολα να προκύψουν από μετρημένα δεδομένα παρά από προσομοιώσεις. Ακριβείς προβλέψεις για το BER, συναρτήσεως ενέργειας εισόδου, μήκους μετάδοσης, ρυθμού συμβόλου και απόστασης μεταξύ καναλιών, μπορούν να αναφερθούν με αριθμητικές προσομοιώσεις και επικύρωση με πειραματική απόδειξη αρχής για ένα 24 X 28 GBd QPSK WDM οπτικό σύστημα μετάδοσης.

#### 4.1.2 Έλεγχος Οπτικών Ενισχυτών

Το σημείο λειτουργίας των οπτικών ενισχυτών EDFA επηρεάζει την εικόνα θορύβου τους (NF) και την ομαλότητα απολαβής(GF), τα οποία έχουν σημαντική επίδραση στο συνολικό QoT του ligtrath. Η προσαρμογή του σημείου λειτουργίας με βάση την ισχύ εισόδου του σήματος μπορεί να επιτευχθεί μέσω αλγορίθμων ML. Πολλές από τις υπάρχουσες μελέτες βασίζονται σε μια προκαταρκτική διαδικασία χαρακτηρισμού ενισχυτή που στοχεύει στην πειραματική αξιολόγηση της τιμής των μετρήσεων μεγεθών ενδιαφέροντος (όπως π.χ. NF, GF και ακρίβεια του ελέγχου κέρδους) μέσα στη μάσκα ισχύος (δηλαδή, η περιοχή λειτουργίας του ενισχυτή, που απεικονίζεται στην εικόνα 15).



Εικόνα 15 - EDFA Power Mask

Τα αποτελέσματα χαρακτηρισμού στη συνέχεια παρουσιάζονται ως ένα σύνολο διακριτών τιμών εντός της περιοχής λειτουργίας. Στις υλοποιήσεις EDFA, οι state-of-the-art μικροελεγκτές δεν μπορούν εύκολα να λάβουν τιμές GF και NF για σημεία που δεν μετρήθηκαν κατά τη διάρκεια του χαρακτηρισμού. Δυστυχώς, η παραγωγή μεγάλης ποσότητας σωστών μετρήσεων είναι χρονοβόρα. Για την αντιμετώπιση αυτού του ζητήματος, οι αλγόριθμοι ML μπορούν να χρησιμοποιηθούν για την παρεμβολή της λειτουργίας αντιστοίχισης σε μη μετρημένα σημεία. Στο επόμενο κεφάλαιο θα παρουσιαστεί αναλυτικά τέτοιο σενάριο χαρακτηρισμού ενισχυτών με χρήση Νευρωνικών Δικτύων πολλών στρωμάτων (MLP).

Για την παρεμβολή μπορεί να υιοθετηθεί μια εφαρμογή NN που είναι και feed-forward και backward error propagation. Τα πειραματικά αποτελέσματα με απλούς και διαδοχικούς ενισχυτές αναφέρουν σφάλματα παρεμβολής κάτω από 0,5 dB. Αντίθετα, μια γνωστική μεθοδολογία μπορεί να εφαρμόζεται σε δυναμικά σενάρια δικτύου κατά την άφιξη ενός νέου αιτήματος lightpath: διατηρείται μια βάση δεδομένων, όπου αποθηκεύονται μετρήσεις για τα κέρδη του ενισχυτή σε ήδη εγκατεστημένα lightpaths, μαζί με τα διάφορα χαρακτηριστικά του lightpath (π.χ. αριθμός συνδέσμων, συνολικό μήκος κ.λπ.) καθώς και η τιμή OSNR που μετρήθηκε στον δέκτη. Ανακτώνται οι καταχωρήσεις από τη βάση δεδομένων οι οποίες δείχνουν να έχουν τις περισσότερες ομοιότητες με το lightpath του νέου αιτήματος, λαμβάνονται υπόψη τα διανύσματα των κερδών που σχετίζονται με τους αντίστοιχους ενισχυτές και δημιουργείται μια καινούργια επιλογή για τα κέρδη βάσει αυτών των τιμών. Στη συνέχεια, εκτιμάται η τιμή OSNR που θα υιοθετηθεί, μαζί με το νέο διάνυσμα των κερδών, μέσω προσομοίωσης και αποθηκεύεται στη βάση δεδομένων ως νέα καταχώριση. Στη συνέχεια, το διάνυσμα που αντιστοιχεί στο υψηλότερο OSNR χρησιμοποιείται για την προσαρμογή των κερδών όταν αναπτυχθεί το νέο lightpath.

Μια άλλη εφαρμογή είναι η προσαρμογή σημείου ρύθμισης ενισχυτή EDFA σε πραγματικό χρόνο χρησιμοποιώντας το επίπεδο ελέγχου GMPLS και κανόνα παρεμβολής που βασίζεται σε υπολογισμό σταθμισμένης με βάρη Ευκλείδειας απόστασης. Μπορεί να επεκταθεί και σε διαδοχικούς ενισχυτές.


Διαφορετικά από τις προηγούμενες αναφορές, το ζήτημα της εξάρτησης από το κανάλι της έξαρσης ισχύος του ενισχυτή EDFA προσεγγίζεται με τον καθορισμό ενός προβλήματος παλινδρόμησης, όπου το σύνολο των χαρακτηριστικών εισόδου είναι ένα διάνυσμα από δυαδικές τιμές που υποδεικνύουν την κατάληψη του φάσματος κάθε καναλιού σε ένα πλέγμα WDM και η προβλεπόμενη μεταβλητή είναι η διαφορά ισχύος μετά το EDFA.

Δύο προσεγγίσεις MM (δηλαδή, τα μοντέλα παλινδρόμησης Ridge και Kernelized Bayesian) συγκρίνονται για μια εγκατάσταση με 2 και 3 διαστήματα ενίσχυσης, στην περίπτωση μονού καναλιού αλλά και προσθαφαιρέσεις πολλαπλών καναλιών. Με βάση τις προβλεπόμενες τιμές, μπορεί να προταθεί κατανομή φάσματος που να διασφαλίζει τη μικρότερη απόκλιση ισχύος μεταξύ των καναλιών.

### 4.1.3 Αναγνώριση Μορφής Διαμόρφωσης (MFR)

Το ζήτημα της αυτόνομης αναγνώρισης μορφής διαμόρφωσης σε ψηφιακούς σύμφωνους δέκτες (δηλαδή χωρίς να απαιτούνται πληροφορίες από τον πομπό) αντιμετωπίζεται μέσω μιας ποικιλίας αλγορίθμων MM όπως με ομαδοποίηση  $k$ -μέσων και με Νευρωνικά δίκτυα. Δυο αναφορές επωφελούνται από την αναπαράσταση Stokes (εικόνα 10) για την αναπαράσταση των DP-BPSK, DP-QPSK και DP-8-QAM), η οποία δεν επηρεάζεται από τυχών μετατοπίσεις συχνότητας και φάσης.

Η πρώτη αναφορά συγκρίνει την απόδοση 6 μη εποπτευόμενων αλγορίθμων ομαδοποίησης για διάκριση μεταξύ 5 διαφορετικών μορφών (π.χ. BPSK, QPSK, 8-PSK, 8-QAM, 16-QAM) από την άποψη του True Positive Rate και του χρόνου λειτουργίας ανάλογα με το OSNR του δέκτη. Για ορισμένους από τους εξεταζόμενους αλγόριθμους, το ζήτημα του προκαθορισμού του αριθμού των συστάδων επιλύεται μέσω του συντελεστή σιλουέτας, ο οποίος αξιολογεί τη στεγανότητα των διαφορετικών δομών ομαδοποίησης λαμβάνοντας υπόψη τις ενδιάμεσες αποστάσεις μεταξύ των συνόλων. Η δεύτερη αναφορά υιοθετεί έναν μη εποπτευόμενο αλγόριθμο Bayes μεγιστοποίησης-προσδοκίας για να μετρήσει τον αριθμό των συστάδων στην αναπαράσταση του χώρου Stokes του λαμβανόμενου σήματος και παρέχει μια είσοδο σε μια συνάρτηση κόστους που χρησιμοποιείται για τον προσδιορισμό της μορφής διαμόρφωσης. Η πειραματική επικύρωση πραγματοποιείται μέσω διαμορφωμένων σημάτων  $k$ -PSK (με  $k = 2, 4, 8$ ) και  $n$ -QAM (με  $n = 8, 12, 16$ ).



Εικόνα 16 - Αναπαράσταση Χώρου Stokes για μορφές διαμόρφωσης DP-BPSK, DP-QPSK και DP-8-QAM

Αντίστροφως, χαρακτηριστικά που εξάγονται από ασύγχρονα ιστογράμματα πλάτους που έχουν προκύψει από λήψη δείγματος από το διάγραμμα οφθαλμών μετά την εξίσωση σε ψηφιακούς συνεκτικούς πομποδέκτες χρησιμοποιούνται σε άλλη αναφορά για την εκπαίδευση ΝΔ. Σε αυτή ένα ΝΔ χρησιμοποιείται για ιεραρχική εξαγωγή των χαρακτηριστικών των ιστογραμμάτων πλάτους, προκειμένου να ληφθεί μια συμπιεσμένη αναπαράσταση, με στόχο τη μείωση του αριθμού των νευρώνων στα κρυμμένα στρώματα σε σχέση με τον αριθμό των χαρακτηριστικών. Ένα νευρωνικό δίκτυο χρησιμοποιείται για ιεραρχική εξαγωγή των χαρακτηριστικών των ιστογραμμάτων πλάτους, προκειμένου να ληφθεί μια συμπιεσμένη αναπαράσταση, με στόχο τη μείωση του αριθμού των νευρώνων στα κρυμμένα στρώματα σε σχέση με τον αριθμό των χαρακτηριστικών. Ένα νευρωνικό δίκτυο συνδυάζεται με έναν γενετικό αλγόριθμο για τη βελτίωση της αποτελεσματικότητας της διαδικασίας επιλογής βάρους κατά τη διάρκεια της φάσης εκπαίδευσης. Και οι δύο μελέτες παρέχουν αριθμητικά αποτελέσματα σε σχέση με δεδομένα που έχουν δημιουργηθεί πειραματικά: η πρώτη επιτυγχάνει ποσοστό σφάλματος 0% κατά τη διάκριση μεταξύ τριών μορφών διαμόρφωσης (PM-QPSK, 16-QAM και 64-QAM), η τελευταία δείχνει την αντιστάθμιση μεταξύ του ποσοστού σφάλματος και του αριθμού των bins ιστογράμματος λαμβάνοντας υπόψη έξι διαφορετικές μορφές (NRZ-OOK, ODB, NRZDPSK, RZ DQPSK, PM-RZ-QPSK και PM-NRZ-16-QAM).

#### **4.1.4 Αντιστάθμιση Μη Γραμμικότητας**

Μία από τις μετρικές απόδοσης που χρησιμοποιούνται συνήθως για οπτικά συστήματα επικοινωνίας είναι το γινόμενο του ρυθμού δεδομένων με την απόσταση. Λόγω των απωλειών οπτικών ινών πρέπει να χρησιμοποιηθεί οπτική ενίσχυση, έτσι για την αύξηση της απόστασης μετάδοσης, πρέπει να χρησιμοποιηθεί ένας αυξανόμενος αριθμός οπτικών ενισχυτών. Όμως οι οπτικοί ενισχυτές προσθέτουν θόρυβο και για να διατηρηθεί η αναλογία σήματος προς θόρυβο αυξάνεται η ισχύς του οπτικού σήματος. Ωστόσο, η αύξηση της ισχύος του οπτικού σήματος πέρα από μια συγκεκριμένη τιμή θα ενισχύσει τις μη γραμμικότητες των οπτικών ινών που οδηγούν σε θόρυβο μη γραμμικής παρεμβολής (Nonlinear Interference NLI), ο οποίος θα επηρεάσει την ανίχνευση συμβόλων. Έτσι εφαρμόζονται διάφορες προσεγγίσεις MM για εκτέλεση βέλτιστης ανίχνευσης συμβόλων.

Σε γενικές γραμμές, σκοπός του δέκτη είναι να πραγματοποιήσει τη βέλτιστη ανίχνευση συμβόλων. Σε 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  $s = s_k \mid k = 1, \dots, M$ . Αυτός ο τύπος ανίχνευσης συμβόλων θα έχει τότε γραμμικά όρια αποφάσεων. Για την περίπτωση μη γραμμικότητας χωρίς μνήμη, όπως θόρυβος μη γραμμικής φάσης, διαμορφωτής I/Q και μη γραμμικότητα ηλεκτρονικών οδηγών (driving electronics nonlinearity), ο θόρυβος που σχετίζεται με το σύμβολο  $y_k$  ενδέχεται να μην είναι πλέον κυκλικά συμμετρικός. Αυτό σημαίνει ότι οι συστάδες στο διάγραμμα αστερισμού παραμορφώνονται (ελλειπτικά σχήματα αντί κυκλικά συμμετρικές σε ορισμένες περιπτώσεις). Σε αυτές τις συγκεκριμένες περιπτώσεις, η βέλτιστη ανίχνευση συμβόλων δεν βασίζεται πλέον στον πίνακα Ευκλείδειας απόστασης και η γνώση και η πλήρης παραμετροποίηση της συνάρτησης πιθανότητας,  $p(y_k | x_k)$ , είναι απαραίτητη. Για να προσδιοριστεί και να παραμετροποιηθεί η συνάρτηση πιθανότητας και τελικά να εκτελεστεί η βέλτιστη ανίχνευση συμβόλων, μπορούν να χρησιμοποιηθούν τεχνικές MM, όπως SVM, εκτιμητής πυκνότητας πυρήνα,  $k$ -πλησιέστεροι γείτονες και μοντέλα Gaussian μειγμάτων. 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.

Μπορεί επίσης να χρησιμοποιηθεί ένας σταθμισμένος με απόσταση ταξινομητής  $k$ -πλησιέστερων γειτόνων για την αντιστάθμιση των βλαβών 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. (υιοθετείται ένα νευρωνικό δίκτυο ανά υποφέρουσα, με αριθμό νευρώνων ίσο με τον αριθμό των συμβόλων). Για να μειωθεί η υπολογιστική πολυπλοκότητα της φάσης εκπαίδευσης, μπορεί να χρησιμοποιηθεί ένας ισοσταθμιστής Extreme Learning Machine (ELM). Το ELM είναι ένα ΝΔ όπου τα βάρη που ελαχιστοποιούν το σφάλμα αντιστοίχισης 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 μετριασμού της μη γραμμικότητας, γενικά, της μείωσης των βλαβών, υπάρχει μια ομάδα αναφορών που εφαρμόζουν εξισορρόπηση του οπτικού σήματος

χρησιμοποιώντας μια ποικιλία αλγορίθμων MM 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 συνελκτικό 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.

Επίσης εφαρμογές νευρωνικών δικτύων μπορούν να χρησιμοποιηθούν για τον περιορισμό βλαβών ενός οπτικού σήματος. Ένα νευρωνικό δίκτυο προσεγγίζει πολύ αποτελεσματικά τη λειτουργία της ψηφιακής οπισθοδιάδοσης (digital backpropagation, DBP), η οποία είναι μια πολύ γνωστή τεχνική για την επίλυση της μη γραμμικής εξίσωσης Schrodinger χρησιμοποιώντας τη μέθοδο Fourier split-step (SSFM). Νευρωνικό δίκτυο επίσης μπορεί να προσομοιώσει τη λειτουργία ενός δέκτη σε ένα μη γραμμικό σύστημα πολυπλεξίας διαίρεσης συχνότητας (NFDN).

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 βλάβες.

#### **4.1.5 Παρακολούθηση Οπτικής Απόδοσης**

Τα τεχνητά νευρωνικά δίκτυα είναι κατάλληλα εργαλεία μηχανικής μάθησης για την παρακολούθηση της οπτικής απόδοσης, αφού μπορούν να χρησιμοποιηθούν για να μάθουν την περίπλοκη σύνδεση μεταξύ δειγμάτων ή εξαγόμενων χαρακτηριστικών, από τα σύμβολα και τις παραμέτρους του καναλιού οπτικών ινών, όπως OSNR, PMD, απώλειες εξαρτώμενες από πόλωση (PDL), ρυθμός baud και CD. Τα χαρακτηριστικά με τα οποία τροφοδοτείται το νευρωνικό δίκτυο μπορούν να ληφθούν χρησιμοποιώντας διαφορετικές προσεγγίσεις βασισμένες στην εξαγωγή χαρακτηριστικών από:

- 1) Power Eye Διαγράμματα (Όπως Q-factor, διακύμανση, μέση τετραγωνική ρίζα, jitter και crossing amplitude).
- 2) Το δισδιάστατο διάγραμμα οφθαλμού και το πορτρέτο φάσης.
- 3) Ασύγχρονα διαγράμματα αστερισμού (δηλ. Διαγράμματα διανυσμάτων που περιλαμβάνονται επίσης μεταβάσεις μεταξύ συμβόλων)
- 4) Ιστογράμματα πλάτους σήματος ασύγχρονου δείγματος.

Το πλεονέκτημα της μη αυτόματης παροχής των χαρακτηριστικών στον αλγόριθμο, είναι ότι το ΝΔ μπορεί να είναι σχετικά απλό, π.χ. να αποτελείται από ένα κρυφό επίπεδο και έως και 10 κρυφές μονάδες και να μην απαιτεί μεγάλη ποσότητα δεδομένων για εκπαίδευση. Άλλη προσέγγιση είναι απλώς να περάσουν τα δείγματα στο επίπεδο συμβόλου και στη συνέχεια να χρησιμοποιηθούν περισσότερα επίπεδα που λειτουργούν ως εξαγωγείς χαρακτηριστικών (δηλαδή, εκτέλεση βαθιάς μάθησης). Να σημειωθεί ότι αυτή η προσέγγιση απαιτεί μεγάλη ποσότητα δεδομένων λόγω των υψηλών διαστάσεων του διανύσματος εισόδου στο ΝΔ.

Εκτός από το τεχνητό νευρωνικό δίκτυο, χρησιμοποιούνται και άλλα εργαλεία όπως μοντέλα Gaussian διαδικασιών που φαίνεται να αποδίδουν καλύτερα στην παρακολούθηση οπτικής απόδοσης σε σύγκριση με μοντέλα πρόβλεψης βασισμένα στη γραμμική παλινδρόμηση. Επίσης υπάρχουν ισχυρισμοί ότι μερικές φορές απλούστερα εργαλεία MM όπως το Gaussian Process (σε σύγκριση με το ANN) μπορούν να αποδειχθούν ισχυρά κάτω από αβεβαιότητες θορύβου και μπορούν εύκολα να ενσωματωθούν σε έναν ελεγκτή δικτύου.

## 4.2 Εφαρμογές MM στο Επίπεδο Δικτύου

### 4.2.1 Πρόβλεψη κίνησης και σχεδιασμός εικονικής τοπολογίας

Η πρόβλεψη της κυκλοφορίας σε οπτικά δίκτυα είναι πολύ σημαντική, ειδικά στο σχεδιασμό για πόρους και την καλύτερη αναβάθμισή τους. Δεδομένου ότι είναι μια από τις εγγενείς φιλοσοφίες των τεχνικών M.M είναι να εκπαιδεύεται ένα μοντέλο από ένα σύνολο δεδομένων και στη συνέχεια με αυτό το μοντέλο να γίνεται πρόβλεψη μελλοντικής συμπεριφοράς, η M.M μπορεί να χρησιμοποιηθεί αποτελεσματικά για πρόβλεψη κίνησης.

Για παράδειγμα, ένα μοντέλο αυτόματης κλιμάκωσης ενσωματωμένου κινούμενου μέσου όρου (ARIMA) είναι μια επιβλεπόμενη μέθοδος μάθησης που εφαρμόζεται σε δεδομένα χρονοσειρών. Επίσης αλγόριθμοι MM μπορούν να χρησιμοποιηθούν για να προβλέψουν την κυκλοφορία για τη διενέργεια αναδιάρθρωσης εικονικής τοπολογίας. 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 είναι με τη μορφή δεδομένων χρονοσειρών. Πιο συγκεκριμένα, οι εισοδοί 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 πολύ καλά με δεδομένα χρονοσειρών και ως εκ τούτου γίνεται μια προτιμώμενη επιλογή σε εφαρμογές όπως προβλέψεις κυκλοφορίας και αναδιαμορφώσεις εικονικής τοπολογίας. Επιπλέον, η σχετικά χαμηλή πολυπλοκότητα του ARIMA είναι επίσης προτιμότερη σε εφαρμογές όπου πρέπει να διατηρείται χαμηλότερη λειτουργική δαπάνη.

Σε γενικές γραμμές, η επιλογή ενός αλγορίθμου MM εξαρτάται πάντα από την αντιστάθμιση μεταξύ της ακρίβειας της μάθησης και της πολυπλοκότητας. Δεν υπάρχει εξαίρεση στην παραπάνω φιλοσοφία όσον αφορά την εφαρμογή MM σε οπτικά δίκτυα. Για παράδειγμα μπορεί να γίνει πρόβλεψη κυκλοφορίας, δηλαδή, αναδιάρθρωση εικονικής τοπολογίας, χρησιμοποιώντας νευρωνικά δίκτυα. Προτείνεται ένα είδος πρόβλεψης που βασίζεται σε ΝΔ το οποίο δημιουργεί τον πίνακα προορισμού-προέλευσης κίνησης. Αυτός ο προβλεπόμενος πίνακας κίνησης για την επόμενη περίοδο χρησιμοποιείται στη συνέχεια από μια διαδικασία λήψης αποφάσεων για να επιβεβαιώσει εάν η τρέχουσα τοπολογία εικονικού δικτύου (VNT) πρέπει να



αναδιαμορφωθεί. Σύμφωνα με μελέτη, το κύριο κίνητρο για τη χρήση Νευρωνικών Δικτύων είναι η καλύτερη προσαρμοστικότητα τους στις αλλαγές της κίνησης εισόδου και επίσης η ακρίβεια της πρόβλεψης της κυκλοφορίας εξόδου με βάση τις εισόδους (που είναι το ιστορικό της κίνησης).

Χρήση αλγορίθμου πρόβλεψης κίνησης και ανακατανομής πόρων βασισμένο σε βαθιά μάθηση μπορεί να γίνει για ένα δίκτυο μεταξύ κέντρων δεδομένων (datacenter). Το μοντέλο που βασίζεται στη βαθιά μάθηση υπερτερεί όχι μόνο των συμβατικών αλγορίθμων κατανομής πόρων, αλλά ακόμα και ενός αλγορίθμου βασισμένου σε ΝΔ ενός επιπέδου, όσον αφορά την απόδοση μπλοκαρίσματος και την αποδοτικότητα κατάληψης πόρων. Προφανώς η βαθιά μάθηση, η οποία είναι πιο περίπλοκη από μία κανονική μάθηση με ΝΔ, θα είναι πιο αποτελεσματική. Μερικές φορές ο τύπος εφαρμογής καθορίζει επίσης ποια συγκεκριμένη παραλλαγή ενός γενικού αλγορίθμου MM πρέπει να χρησιμοποιηθεί. Για παράδειγμα, τα επαναλαμβανόμενα νευρωνικά δίκτυα (RNN), τα οποία ταιριάζουν καλύτερα στην εφαρμογή που περιλαμβάνουν δεδομένα χρονοσειρών μπορούν να εφαρμοστούν για την πρόβλεψη της κίνησης της μονάδας βασικής ζώνης (BBU) σε ένα δίκτυο για cloud ασύρματης πρόσβασης 5G. Δεδομένου ότι η κυκλοφορία που συγκεντρώνεται σε διαφορετικές ομάδες BBU αποτελείται από διαφορετικές κατηγορίες όπως κίνηση κατοίκων, κίνηση γραφείων κ.λπ., με διαφορετικές χρονικές διακυμάνσεις, το ιστορικό σύνολο δεδομένων για τέτοια κίνηση έχει πάντα μια διάσταση στον χρόνο. Υπάρχει μελέτη στην οποία προτείνεται και εφαρμόζεται με καλό αποτέλεσμα ένα σύστημα πρόβλεψης κίνησης βασισμένο σε RNN. (αύξηση 7% στην απόδοση δικτύου και 18% αναφέρεται η μείωση των πόρων επεξεργασίας).

Άλλη έρευνα αναφέρει μια γνωστική μονάδα διαχείρισης δικτύου σε σχέση με το πλαίσιο ABNO (Application Based Network Operations), με ιδιαίτερη εστίαση στην πρόβλεψη κυκλοφορίας βασισμένη σε MM για την αναδιάρθρωση του VNT, αν και δεν είναι γνωστές οι λεπτομέρειες οποιουδήποτε συγκεκριμένου αλγορίθμου MM που χρησιμοποιείται για τον σκοπό της αναδιάρθρωσης VNT. Παρομοίως, προτείνεται Bayesian inference για την εκτίμηση της κυκλοφορίας του δικτύου και να αποφασίσει εάν και πότε θα αναδιαμορφώσει ένα δοσμένο εικονικό δίκτυο.

Ενώ το μεγαλύτερο μέρος της βιβλιογραφίας επικεντρώνεται στην πρόβλεψη κυκλοφορίας χρησιμοποιώντας αλγόριθμους MM για μια συγκεκριμένη άποψη των αναδιαμορφώσεων τοπολογίας εικονικού δικτύου, άλλη έρευνα παρουσιάζει ένα γενικό πλαίσιο εκτίμησης μοτίβου κίνησης από εγγραφές δεδομένων κλήσεων (CDR). Σε αυτή χρησιμοποιούνται πραγματικά σύνολα δεδομένων από παρόχους υπηρεσιών και χρησιμοποιεί αλγόριθμους βασισμένους σε παραμετροποίηση και ομαδοποίηση για να

αντλήσει χρήσιμες πληροφορίες από αυτά τα σύνολα δεδομένων, τα οποία μπορούν να χρησιμοποιηθούν για την καλύτερη ανάπτυξη των πόρων του δικτύου. Πιο συγκεκριμένα, χρησιμοποιείται CDR από 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 κ.λπ. στη μορφή ενός πίνακα, που ονομάζεται πίνακας CDR. 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 εφαρμόζονται στη συνέχεια σε έναν αλγόριθμο MM συσταδοποίησης που ονομάζεται μη αρνητική παραγοντοποίηση πίνακα (NMF) και μια παραλλαγή αυτού που ονομάζεται συλλεκτικό NMF (C-NMF). Η έξοδος των αλγορίθμων αντιστοιχίζει τους πίνακες εισόδου σε δύο μη αρνητικούς πίνακες, ο ένας δίνει τους διαφορετικούς τύπους βασικών μοτίβων κυκλοφορίας και ο άλλος δίνει τις ομοιότητες μεταξύ σταθμών βάσης όσον αφορά τα μοτίβα κυκλοφορίας.

Ενώ πολλές από τις αναφορές στη βιβλιογραφία επικεντρώνονται σε ένα ή λίγα συγκεκριμένα χαρακτηριστικά κατά την ανάπτυξη αλγορίθμων MM για προβλέψεις κυκλοφορίας και διαμορφώσεις εικονικής τοπολογίας, άλλοι απλώς αναφέρουν ένα γενικό πλαίσιο με κάποια μορφή «γνώσης» ενσωματωμένη σε συνδυασμό με τακτικούς αλγόριθμους βελτιστοποίησης.

#### **4.2.2 Διαχείριση Σφάλματος**

Οι τεχνικές MM μπορούν να υιοθετηθούν είτε για τον προσδιορισμό της ακριβούς τοποθεσίας σφάλματος ή δυσλειτουργίας στο δίκτυο ή είτε ακόμη και για να συμπεράνουμε ποιόν συγκεκριμένο τύπο σφάλματος έχουμε. Σε μία έρευνα χρησιμοποιείται δίκτυο kriging για να εντοπίσει την ακριβή θέση του σφάλματος κατά μήκος των ζεύξεων του δικτύου, με την υπόθεση ότι οι μόνες διαθέσιμες πληροφορίες στους κόμβους λήψης (που λειτουργούν και ως κόμβοι παρακολούθησης) των ήδη εγκατεστημένων lightpaths είναι ο αριθμός των σφαλμάτων που προέκυψαν κατά μήκος της διαδρομής του lightpath. Εάν δεν μπορεί να επιτευχθεί ακριβής εντοπισμός, η ανίχνευση lightpath μπορεί να λειτουργήσει προκειμένου να παρέχει πρόσθετες πληροφορίες, το οποίο αυξάνει τον βαθμό του πίνακα δρομολόγησης. Ανάλογα με το φορτίο του δικτύου, ο αριθμός των κόμβων παρακολούθησης που απαιτείται για να διασφαλιστεί ο ακριβής εντοπισμός του σφάλματος, ποικίλει. Παρμοίως, σε άλλη έρευνα οι μετρημένες χρονοσειρές του BER και η λαμβανόμενη ισχύς στους κόμβους στο τέλος

του lightpath παρέχονται ως είσοδοι σε ένα Bayesian δίκτυο το οποίο ανιχνεύει εάν συμβαίνει ένα σφάλμα κατά μήκος του lightpath και προσπαθεί να εντοπίσει την αιτία (π.χ. σκληρό φίλτράρισμα ή παρεμβολή καναλιού) με βάση συγκεκριμένα χαρακτηριστικά από τα μοτίβα μέτρησης. (όπως μέγιστες, μέσες και ελάχιστες τιμές, παρουσία και πλάτος βημάτων). Η αποτελεσματικότητα του ταξινομητή Bayesian αξιολογείται σε πειραματική δοκιμαστική βάση: τα αποτελέσματα δείχνουν ότι μόνο το 0,8% των τεσταρισμένων περιπτώσεων δεν είχαν ταξινομηθεί σωστά.

Σε άλλες έρευνες αναφέρονται περιπτώσεις εφαρμογής μοντέλων Bayesian για ανίχνευση και διάγνωση σφαλμάτων στα οπτικά δίκτυα, ειδικά σε GPON / FTTH. Στη μία περίπτωση το δίκτυο GPON / FTTH μοντελοποιείται ως Bayesian δίκτυο χρησιμοποιώντας μια πολυστρωματική προσέγγιση πανομοιότυπη με μία από τις προηγούμενες λειτουργίες τους. Το στρώμα 1 στην περίπτωση αυτή στην πραγματικότητα αντιστοιχεί στην τοπολογία του φυσικού δικτύου που αποτελείται από συσκευές ONT, ONU και οπτικές ίνες. Η αποτυχία μεταξύ διαφορετικών στοιχείων δικτύου που απεικονίζονται από κόμβους επιπέδου-1, μοντελοποιείται στο επίπεδο 2 χρησιμοποιώντας ένα σύνολο κατευθυνόμενων ακυκλικών γραφημάτων(γράφων?) που διασυνδέονται μέσω του επιπέδου 1. Οι αβεβαιότητες της διάδοσης αποτυχίας αντιμετωπίζονται στη συνέχεια με ποσοτικοποίηση των δυνατοτήτων των εξαρτήσεων μεταξύ των κόμβων του στρώματος 2 με τις υπό όρους κατανομές πιθανοτήτων που προκύπτουν από δεδομένα που προέρχονται από το δίκτυο. Ωστόσο, μερικά από αυτά τα δεδομένα που προκύπτουν από τα δίκτυα μπορεί να απουσιάζουν λόγω ακατάλληλων μετρήσεων ή να μην αναφέρονται σαν δεδομένα. Επομένως χρησιμοποιείται αλγόριθμος Μεγιστοποίησης - Προσδοκίας για τη διαχείριση δεδομένων που λείπουν για την ανάλυση των βασικών αιτιών των σφαλμάτων του δικτύου και βοηθά στην αυτοδιάγνωση. ο αλγόριθμος ΜΠ εκτιμά τα δεδομένα που απουσιάζουν έτσι ώστε η εκτίμηση να μεγιστοποιεί την αναμενόμενη συνάρτηση πιθανότητας που βασίζεται σε ένα δοσμένο σύνολο παραμέτρων. Σε άλλη περίπτωση ένας παρόμοιος συνδυασμός Bayesian μοντέλων πιθανοτήτων και Μεγιστοποίησης-Προσδοκίας χρησιμοποιείται για διάγνωση αστοχίας σε δίκτυα GPON / FTTH.

Στο πλαίσιο της ανίχνευσης σφάλματος, εκτός από τα δίκτυα Bayesian, έχουν χρησιμοποιηθεί και άλλες έννοιες και αλγόριθμοι Μ.Μ. Για παράδειγμα, σε μία μελέτη περιγράφονται δύο αλγόριθμοι ΜΜ που βασίζονται στην παλινδρόμηση, την ταξινόμηση, και ανίχνευση ανωμαλιών. Οι συγγραφείς προτείνουν έναν αλγόριθμο ανίχνευσης ανωμαλιών BER που παίρνει σαν είσοδο πληροφορίες από το ιστορικό, όπως το μέγιστο BER, το κατώφλι BER κατά την εγκατάσταση και το παρακολουθούμενο BER ανά lightpath και εντοπίζει τυχόν απότομες αλλαγές στο BER που θα μπορούσε να είναι

αποτέλεσμα μερικών αστοχιών των στοιχείων κατά μήκος ενός lightpath. Αυτός ο αλγόριθμος ανίχνευσης ανωμαλιών BER, ο οποίος ονομάζεται BANDO, εκτελείται σε κάθε κόμβο του δικτύου. Οι εξόδοι του BANDO είναι διαφορετικά γεγονότα που δηλώνουν εάν το BER είναι πάνω από ένα συγκεκριμένο κατώφλι ή κάτω από αυτό, εντός ενός προκαθορισμένου ορίου.

Αυτές οι πληροφορίες στη συνέχεια μεταφέρονται στην είσοδο άλλου αλγόριθμου επίσης βασισμένου σε MM που οι συγγραφείς ορίζουν ως LUCIDA. Το LUCIDA εκτελείται στον ελεγκτή δικτύου και παίρνει σαν είσοδο το ιστορικό του BER, το ιστορικό της ισχύος του δέκτη και τις εξόδους του BANDO. Αυτές οι εισοδοί μετατρέπονται σε τρία χαρακτηριστικά που μπορούν να ποσοτικοποιηθούν με χρονοσειρές και έχουν ως εξής:

- Λαμβανόμενη ισχύς πάνω από το επίπεδο αναφοράς (PRXhigh)
- BER positive trend (BERTrend)
- Περιοδικότητα BER (BERPeriod)

Το LUCIDA υπολογίζει τις πιθανότητες αυτών των χαρακτηριστικών και τις πιθανότητες πιθανών κλάσεων αποτυχίας και τελικά αντιστοιχίζει αυτές τις πιθανότητες χαρακτηριστικών στις πιθανότητες αποτυχίας.

Μια άλλη αξιοσημείωτη περίπτωση χρήσης για ανίχνευση αστοχίας στα οπτικά δίκτυα, που χρησιμοποιεί έννοιες MM: Δυο αλγόριθμοι προτείνονται, ο Testing optical Switching at connection SetUp time (TISSUE) και ο Failure cause Localization for optical Network (FEELING). Ο αλγόριθμος TISSUE παίρνει τις τιμές του εκτιμώμενου BER υπολογιζόμενου σε κάθε κόμβο κατά μήκος του lightpath και τις τιμές του BER που έχει μετρηθεί και τις συγκρίνει. Εάν οι διαφορές μεταξύ των κλίσεων του εκτιμώμενου και του θεωρητικού BER είναι πάνω από ένα ορισμένο όριο, αναμένεται να υπάρξει αποτυχία. Αν και δεν είναι σαφές εάν η εκτίμηση του BER στον αλγόριθμο TISSUE βασίζεται σε μεθόδους MM, ο αλγόριθμος FEELING εφαρμόζει δύο πολύ γνωστές μεθόδους MM, δηλαδή τα Δέντρα Αποφάσεων και το SVM.


Στο FEELING, το πρώτο βήμα είναι η επεξεργασία του συνόλου των δεδομένων εισόδου που έχουν τη μορφή ταξινομημένων ζευγών συχνότητας και ισχύος για κάθε οπτικό σήμα και η μετατροπή τους σε ένα σύνολο χαρακτηριστικών. Τα χαρακτηριστικά περιλαμβάνουν ορισμένα βασικά χαρακτηριστικά όπως το επίπεδο ισχύος στην κεντρική συχνότητα του σήματος και επίσης η ισχύς γύρω από άλλα σημεία αποκοπής του φάσματος του σήματος. Στο πλαίσιο του αλγόριθμου FEELING, μερικά δευτερεύοντα χαρακτηριστικά ορίζονται που είναι γραμμικοί συνδυασμοί των βασικών χαρακτηριστικών. Η διαδικασία εξαγωγής των χαρακτηριστικών πραγματοποιείται από μια μονάδα που ονομάζεται FeX. Το επόμενο βήμα είναι να εισαχθούν αυτές οι δυνατότητες σε έναν ταξινομητή πολλαπλών κλάσεων στη μορφή ενός δέντρου

αποφάσεων που παράγει μια ως έξοδο μια πρόβλεψη κλάσης μεταξύ των τριών επιλογών: 'Normal', 'LaserDrift' and 'FilterFailure' και 2<sup>ον</sup> ένα υποσύνολο σχετικών σημείων σήματος για την κλάση που έχει προβλεφθεί. Βασικά, το δέντρο αποφάσεων περιέχει έναν αριθμό από κανόνες απόφασης για αντιστοίχιση συγκεκριμένων συνδυασμών από τιμές χαρακτηριστικών με κλάσεις. Αυτό το στοιχείο με βάση τα δέντρα αποφάσεων, εκτελείται σε μια άλλη μονάδα που ονομάζεται μονάδα επαλήθευσης φάσματος σήματος (SSV). Οι μονάδες FeX και SSV βρίσκονται στους κόμβους δικτύου. Υπάρχουν δύο ακόμη μονάδες που ονομάζονται μονάδα σύγκρισης φάσματος σήματος (SSC) και μονάδα εκτίμησης τάσης λέιζερ (LDE) που λειτουργούν στον ελεγκτή δικτύου. Στη μονάδα SSC, συμβαίνει παρόμοια διαδικασία ταξινόμησης όπως στο SSV. Αλλά εδώ ένα σήμα διαγιγνώσκεται μόνο με βάση τις 3 διαφορετικές κατηγορίες σφαλμάτων που προκύπτουν από το φίλτράρισμα: Normal, FilterShift and TightFiltering. Η μονάδα SSC χρησιμοποιεί τεχνική SVM για την ταξινόμηση των σημάτων με βάση τις παραπάνω τρεις κατηγορίες. Πρώτον, το SVM ξεχωρίζει εάν το σήμα είναι «Κανονικό» ή υπέστη σφάλμα που σχετίζεται με φίλτρο. Στη συνέχεια, το SVM ταξινομεί το σήμα που θεωρείται ότι πάσχει από σφάλματα που σχετίζονται με το φίλτρο σε δύο κατηγορίες με βάση το εάν το σφάλμα οφείλεται σε αυστηρό φίλτράρισμα (TightFiltering) ή λόγω μετατόπισης φίλτρου (FilterShift). Μόλις ολοκληρωθούν αυτές οι ταξινομήσεις, το μέγεθος των σφαλμάτων που σχετίζονται με καθεμία από αυτές τις κατηγορίες εκτιμάται χρησιμοποιώντας μονάδα εκτιμητή που βασίζεται σε γραμμικές παρεμβολές, για κάθε μία από τις κατηγορίες αστοχίας. Τέλος, όλες αυτές οι πληροφορίες που παρέχονται από τις διάφορες μονάδες που περιγράφονται μέχρι τώρα, χρησιμοποιούνται στον αλγόριθμο FEELING για να την επιστροφή της τελικής λίστας σφαλμάτων.

Ένας παρόμοιος αλγόριθμος βασιζόμενος σε πολλαπλή μηχανική μάθηση επίσης προτείνεται στη συνέχεια: Στη μία περίπτωση χρησιμοποιούνται διάφοροι αλγόριθμοι MM, και ανάλογα με διάφορες παραμέτρους των μοντέλων, όπως ο χρόνος δειγματοληψίας BER και η ποσότητα των δεδομένων BER που απαιτούνται για την εκπαίδευση των μοντέλων, ένας ή περισσότεροι κατάλληλοι βελτιστοποιημένοι αλγόριθμοι επιλέγονται από δυαδικά ή πολλαπλής κλάσης SVMs, τυχαία δάση ή νευρωνικά δίκτυα. Στο επόμενο κεφάλαιο της παρούσας εργασίας οι αλγόριθμοι αυτής της περίπτωσης θα εξετασθούν αναλυτικά και θα συγκριθούν ως προς την ακρίβεια και την πολυπλοκότητά τους.

Σε άλλη έρευνα οι συγγραφείς προτείνουν αλγόριθμους ανίχνευσης αστοχίας και του λόγου που την προκαλεί, και επισημαίνουν ότι ένας χειριστής δικτύου που εντοπίζει έγκαιρα μια αστοχία (και την αιτία της) προτού το BER φτάσει στο όριο, μπορεί

προληπτικά να επαναδρομολογήσει την κίνηση που έχει επηρεαστεί από το σφάλμα μέσω ενός νέου lightpath έτσι ώστε να ελαχιστοποιηθεί το SLA violation και να επιταχυνθούν οι διαδικασίες αποκατάστασης του σφάλματος (όπως φαίνεται παρακάτω στην εικόνα 17). Σε άλλη περίπτωση, επίπεδα οπτικής ισχύος, κέρδος ενισχυτή, θερμοκρασία, current draw, εσωτερική οπτική ισχύ χρησιμοποιούνται για την πρόβλεψη σφάλματος χρησιμοποιώντας στατιστική παλινδρόμηση και αλγόριθμοι που βασίζονται σε Νευρωνικά Δίκτυα και βρίσκονται στους ελεγκτές SDN.



Εικόνα 17 - Ο εντοπισμός σφάλματος και το πλαίσιο ανίχνευσης

### 4.2.3 Ταξινόμησης Ροής

Ένας άλλος δημοφιλής τομέας εφαρμογής MM για οπτικά δίκτυα είναι η ταξινόμηση ροής. Σε μια μελέτη για παράδειγμα, ένα πλαίσιο περιγράφει ότι παρατηρούνται διαφορετικοί τύποι απώλειας πακέτου σε οπτικά δίκτυα burst-switched (OBS). Στη συνέχεια ταξινομεί τα δεδομένα απωλειών πακέτου, ως απώλεια συμφόρησης (congestion loss) ή contention loss χρησιμοποιώντας αλγόριθμους Hidden Markov Model (HMM) και μεγιστοποίησης προσδοκίας.

Στη συνέχεια ένα άλλο παράδειγμα ταξινόμησης ροής παρουσιάζεται: Εδώ ένα ΝΔ εκπαιδεύεται για την ταξινόμηση ροών σε οπτικά δίκτυο κέντρο κέντρου δεδομένων. Το διάνυσμα χαρακτηριστικών, που είναι 5-διάστατο, περιλαμβάνει (Διεύθυνση IP πηγής, διεύθυνση IP προορισμού, πόρτα πηγής, πόρτα προορισμού, πρωτόκολλο επιπέδου μεταφοράς). Μεγέθη πακέτων και ένα σύνολο χρονισμών εντός των ροών εντός των πρώτων 40 πακέτων ροής (Packet sizes and a set of intraflow timings within the first 40 packets of a flow) τα οποία αντιστοιχούν περίπου στα πρώτα 30 τμήματα TCP, χρησιμοποιούνται επίσης ως είσοδοι για τη βελτίωση της ταχύτητας της εκπαίδευσης και

για τον μετριασμό του προβλήματος ‘disappearing gradients’ ενώ χρησιμοποιείται μέθοδος καθόδου βασισμένη στην κλίση για οπισθοδιάδοση.

Το κύριο αποτέλεσμα του NN που χρησιμοποιείται στο παραπάνω παράδειγμα είναι η ταξινόμηση των ροών mice και elephant στο κέντρο δεδομένων (DC). Ο τύπος του νευρωνικού δικτύου που χρησιμοποιείται είναι ένας πολυστρωματικός perceptron (MLP) με τέσσερα κρυφά επίπεδα, αφού τα MLP είναι σχετικά απλούστερη στην εφαρμογή. Στα συμπεράσματα του παραπάνω παραδείγματος αναφέρεται επίσης το υψηλό επίπεδο αληθών αρνητικών αποτελεσμάτων ταξινόμησης που προκύπτουν με το MLP σημειώνουν τη διασφάλιση ότι τα mice δεν υπερχειλίζουν τις οπτικές διασυνδέσεις στο δίκτυο DC. Σε γενικές γραμμές, οι ροές mice ξεπερνούν στον αριθμό τις ροές των elephant πρακτικά στο DC δίκτυο, και επομένως προτείνεται να ξεπεραστεί αυτή η ανισορροπία τάξης μεταξύ ροών mice και elephant εκπαιδεύοντας το NN με μη αναλογική ποσότητα ροών mice και elephant.

#### **4.2.4 Υπολογισμός μονοπατιού**

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

Στην πρώτη περίπτωση οι συγγραφείς προτείνουν μια στρατηγική για επιλογή διαδρομής και μήκους κύματος για δίκτυα OBS με την οποία ελαχιστοποιείται η πιθανότητα απώλειας ριπής. Το πρόβλημα διατυπώνεται ως πρόβλημα multi-arm bandit problem (MABP) και επιλύεται χρησιμοποιώντας Q-learning. Ένα πρόβλημα MABP προέρχεται από τον χώρο του τζόγου 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, οι συγγραφείς σε αυτή την περίπτωση χρησιμοποιούν την ιδέα επιλογής διαδρομής για

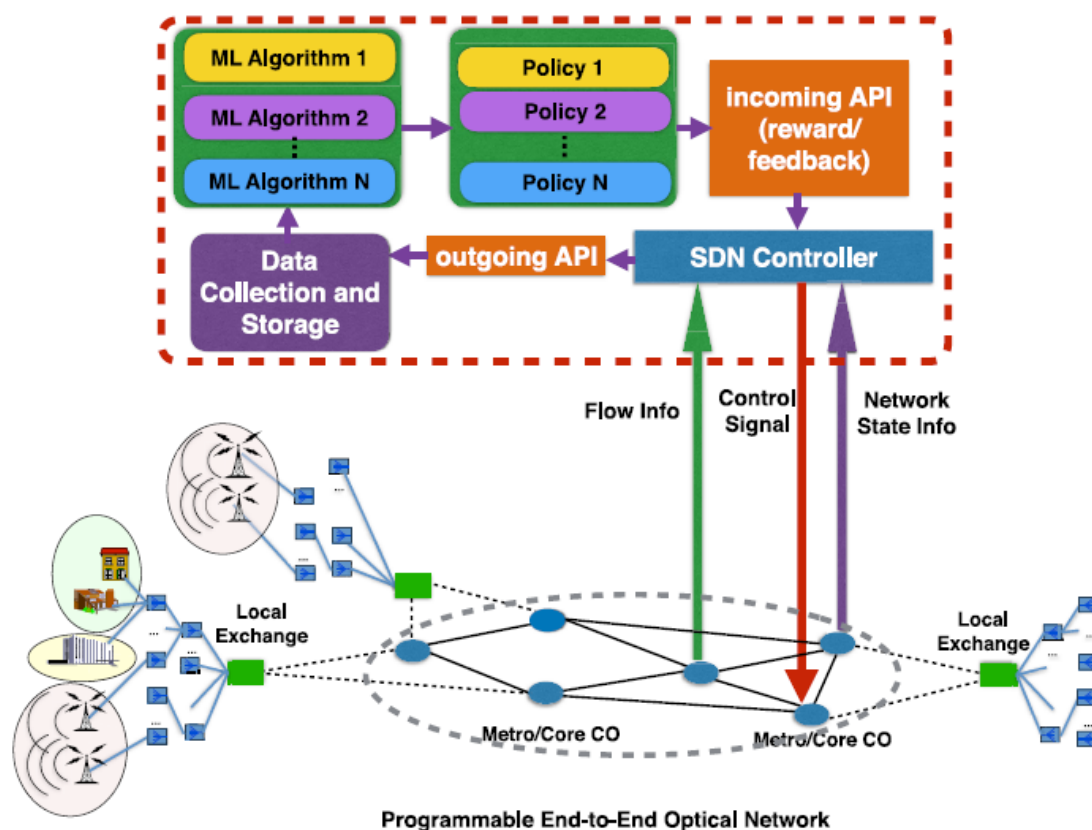
κάθε ζεύγος πηγής-προορισμού όπως το τράβηγμα ενός από τους βραχίονες σε έναν κουλοχέρη με επιβράβευση την ελαχιστοποίηση της πιθανότητας απώλειας ριπής. Γενικά το MABP πρόβλημα είναι ένα κλασικό πρόβλημα ενισχυτικής μάθησης και οι συγγραφείς προτείνουν Q-learning για την επίλυση αυτού του προβλήματος επειδή άλλες μέθοδοι δεν ταιριάζουν σωστά για πολύπλοκα προβλήματα. Επιπλέον, άλλες μέθοδοι επίλυσης MABP, όπως ο δυναμικός προγραμματισμός, οι δείκτες Gittins και αλγόριθμοι learning automata αποδεικνύεται να είναι δύσκολες όταν οι κατανομές των ανταμοιβών (δηλαδή, οι κατανομές της πιθανότητας απώλειας ριπών σε περίπτωση του σεναρίου OBS) είναι άγνωστες. Οι συγγραφείς στο [103] υποστηρίζουν επίσης ότι ο Q learning O αλγόριθμος έχει εγγυημένη σύγκλιση σε σύγκριση 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. Ο αλγόριθμος FCM παίρνει ως είσοδο χαρακτηριστικά όπως αιτήματα κυκλοφορίας, μήκη των lightpath, σύνολο μορφών διαμόρφωσης, OSNR, BER κ.λ.π 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.



### 4.3 Συμπέρασμα Ενότητας

Όπως μπορούμε να δούμε από τη συνολική συζήτηση σε αυτήν την ενότητα, μπορούν να χρησιμοποιηθούν διαφορετικοί αλγόριθμοι και πολιτικές MM αναλόγως με τις περιπτώσεις χρήσης και τις εφαρμογές που ενδιαφέρουν. Επομένως, κάποιος μπορεί να φανταστεί ένα συνοπτικό επίπεδο ελέγχου για την επόμενη γενιά οπτικών δικτύων μαζί με ένα αποθετήριο διαφορετικών αλγορίθμων και πολιτικών MM, όπως φαίνεται παρακάτω στην εικόνα 12. Το προβλεπόμενο επίπεδο ελέγχου στην εικόνα 12 μπορεί να θεωρηθεί ως «εγκέφαλος» του δικτύου, που αλληλοεπιδρά συνεχώς με το «σώμα του δικτύου» (δηλαδή διάφορα στοιχεία όπως αναμεταδότες, ενισχυτές, συνδέσεις κ.λ.π.) και αντιδρά στα «ερεθίσματα» (δηλαδή δεδομένα που δημιουργούνται από το δίκτυο) και εκτελεί ορισμένες "ενέργειες" (όπως υπολογισμός διαδρομής, αναδιαμόρφωση εικονικής τοπολογίας, ταξινόμηση ροής κλπ.)



Εικόνα 18 - Διάγραμμα που παρουσιάζει τον ρόλο του επιπέδου ελέγχου το οποίο φιλοξενεί του αλγορίθμους MM και πολιτικές για τη διαχείριση των οπτικών δικτύων

## **Κεφάλαιο 5. Αναλυτική περιγραφή επιλεγμένων σεναρίων με χρήση τεχνικών MM στις οπτικές επικοινωνίες**

Σε αυτό το κεφάλαιο επιλέχθηκαν δύο σενάρια με εφαρμογή τεχνικών Μηχανικής Μάθησης στις οπτικές επικοινωνίες, τα οποία και θα παρουσιαστούν αναλυτικά. Το πρώτο αφορά το φυσικό επίπεδο και τον έλεγχο οπτικών ενισχυτών [8], ενώ το δεύτερο αφορά το επίπεδο δικτύου και το κομμάτι της διαχείρισης σφάλματος [7].

### **5.1 Αντιστοίχιση Εικόνας Θορύβου και Ομαλότητας Απολαβής ενισχυτών EDFA πάνω από Μάσκα Ισχύος με χρήση Νευρωνικών Δικτύων**

Οι οπτικοί ενισχυτές παίζουν σημαντικό ρόλο στην αυτορρύθμιση των δικτύων οπτικών επικοινωνιών. Ο χαρακτηρισμός της συσκευής εντός του δυναμικού εύρους λειτουργίας είναι ζωτικής σημασίας για τη σωστή ανάπτυξη και χρήση τέτοιων συσκευών. Σε γενικές γραμμές, κάποιος πρέπει να μετρήσει έναν ορισμένο αριθμό σημείων λειτουργίας για να ολοκληρώσει τον χαρακτηρισμό. Παρ'όλα αυτά, σε πολλές περιπτώσεις υπάρχουν πολλά δεδομένα που απουσιάζουν. Θα δείξουμε ότι μπορούν να χρησιμοποιηθούν απλά νευρωνικά δίκτυα για την εκτέλεση μιας εργασίας παλινδρόμησης και να προκύψει μια συνεχή καμπύλη χαρακτηρισμού της ομαλότητας απολαβής (Gain Flatness) και της απόδοσης της εικόνας θορύβου(Noise Figure), σε ολόκληρη τη μάσκα ισχύος ενισχυτή. Αυτή η παλινδρόμηση μπορεί να γίνει χρησιμοποιώντας μικρότερο αριθμό σημείων από το συνηθισμένο. Λάβαμε εκτιμώμενα σφάλματα χαμηλότερα από 0,1 dB για την ομαλοποίησης κέρδους(GF) και του σχήματος θορύβου(NF) σε ολόκληρο το εύρος λειτουργίας. [8]

### 5.1.1 Εισαγωγή

Η συνεχώς αυξανόμενη ζήτηση κίνησης που δημιουργείται από τις νέες υπηρεσίες Διαδικτύου και Βίντεο έχει οδηγήσει την αγορά τηλεπικοινωνιών στο να αναπτύξει εξαντλητικά οπτικά συστήματα επικοινωνίας. Οι οπτικοί ενισχυτές EDFA (Erbium Doped Fiber Amplifiers) ήδη χρησιμοποιούνται με επιτυχία σε οπτικά συστήματα πολλαπλών καναλιών από τον περασμένο αιώνα για να αντισταθμίσουν τις απώλειες που προκαλούνται από τις ίνες μετάδοσης και τις οπτικές συσκευές. Γενικά σε ένα σύστημα πολλαπλών καναλιών τα διαφορετικά κανάλια μπορούν να ενισχυθούν με διαφορετικά κέρδη λόγω των διακυμάνσεων στο φάσμα κέρδους των EDFA. Αυτή η διακύμανση συμβαίνει κυρίως λόγω της κατανομής των υπο-επιπέδων εντός της ζώνης. Η ομαλότητα απολαβής (GF) ορίζεται ως η μέγιστη έκρηξη κέρδους εντός της ζώνης οπτικής μετάδοσης σχετικά με ένα προκαθορισμένο κέρδος, ενώ η ακρίβεια Αυτόματου Έλεγχου Κέρδους (AGC) ορίζεται ως η διαφορά μεταξύ του κέρδους του καθορισμένου σημείου και του μετρηθέντος κέρδους.

Επίσης, το φάσμα κέρδους μπορεί να ποικίλει ανάλογα με τη συνολική ισχύ του σήματος εισόδου. Επιπλέον, οι EDFA εισάγουν θόρυβο μέσα στη ζώνη μετάδοσης λόγω Ενισχυμένης Αυθόρμητης Εκπομπής (ASE). Ο λόγος οπτικού σήματος προς θόρυβο (OSNR) ορίζεται ως ο λόγος μεταξύ της ισχύος του σήματος και της ισχύος θορύβου (ASE) σε ένα συγκεκριμένο σημείο του συστήματος. Η υποβάθμιση του OSNR που δημιουργείται από μια συσκευή ορίζεται ως η εικόνα θορύβου (NF), η οποία δίνεται σε λογαριθμική κλίμακα (dB). Τα GF και τα NF είναι σημαντικές μετρικές για τον καθορισμό της ποιότητας των ενισχυτών, οι οποίοι με τη σειρά τους έχουν αντίκτυπο στην ποιότητα της μετάδοσης (QoT) σε οπτικά συστήματα επικοινωνίας.

Σε επαναρυθμιζόμενα οπτικά δίκτυα, η ανάγκη για μέτρηση αυτών των μεγεθών είναι ακόμη πιο σημαντική, καθώς ο αριθμός των καναλιών και η ισχύς τους μπορεί να ποικίλλουν δυναμικά, και μερικές φορές, απρόβλεπτα. Εξαιτίας αυτού, οι οπτικοί ενισχυτές που αναπτύσσονται στο σύστημα πρέπει να λειτουργούν σωστά μέσα σε ένα προκαθορισμένο εύρος ισχύος εισόδων και κερδών, εισάγοντας χαμηλό θόρυβο και παρέχοντας σταθερό κέρδος για όλα τα κανάλια πολυπλεξίας μήκους κύματος (WDM). Η γνώση της απόδοσης του ενισχυτή από πριν είναι απαραίτητη για την παροχή lightpath με υψηλό QoT για υποστήριξη διαφορετικών μορφών διαμόρφωσης και ρυθμών bit.

Ωστόσο, η διαδικασία χαρακτηρισμού ενός EDFA είναι αργή και τα δεδομένα χαρακτηρισμού που προκύπτουν ως αποτέλεσμα δεν παρέχουν ούτε συνεχείς ούτε υψηλής ανάλυσης καμπύλες κέρδους και NF. Σε αυτή την ενότητα θα μελετήσουμε την εφαρμογή του απλού και γνωστού τύπου τεχνητού νευρωνικού δικτύου, το Multilayer

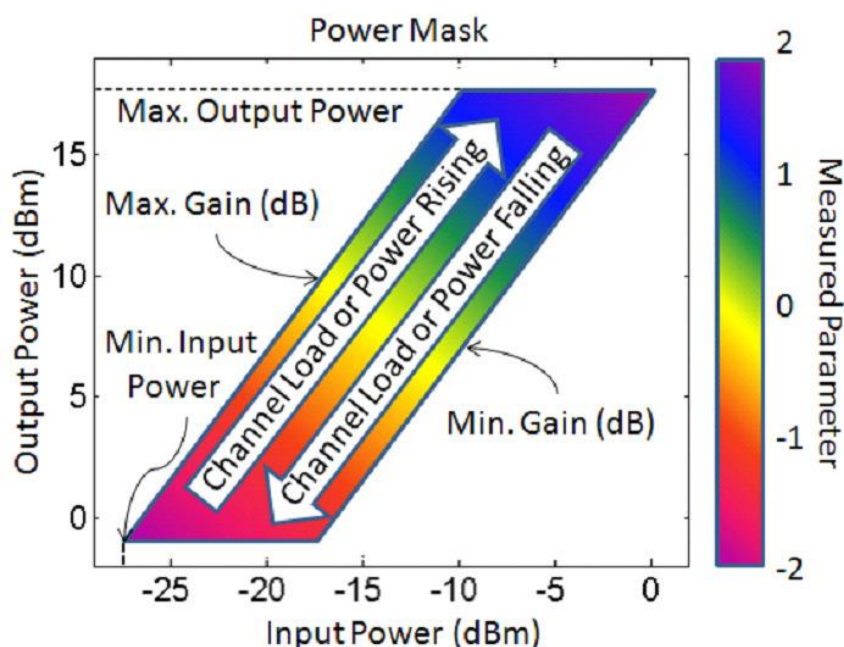
Perceptron (MLP) η οποία θα φέρει εις πέρας την εργασία παλινδρόμησης πάνω σε ολόκληρη τη μάσκα ισχύος, με ελάχιστο σφάλμα .

### 5.1.2 Χαρακτηρισμός Ενισχυτή

Σε αυτό το σημείο θα παρουσιαστεί το υπόβαθρο της διαδικασίας χαρακτηρισμού του ενισχυτή. Πρώτα θα περιγραφεί η έννοια της μάσκας ισχύος (Power Mask). Στη συνέχεια θα περιγραφεί λεπτομερώς η διαδικασία χαρακτηρισμού και στο τέλος θα φανεί πώς παρουσιάζονται τα αποτελέσματα του χαρακτηρισμού του ενισχυτή.

#### A. Μάσκα Ισχύος (Power Mask)

Η περιοχή λειτουργίας του ενισχυτή που ορίζεται από τις ισχύς εισόδου και εξόδου ορίζεται ως η μάσκα ισχύος του, όπως φαίνεται στην παρακάτω εικόνα 19. Στη Μάσκα Ισχύος, κάθε διαγώνιος αντιστοιχεί σε ένα σταθερό κέρδος, που ποικίλλει από ελάχιστη έως μέγιστη τιμή (από δεξιά προς αριστερά) κατά μήκος της μάσκας. Μια πτώση ισχύος εισόδου αντιστοιχεί σε μείωση του φορτίου του καναλιού ή σε μείωση ισχύος λόγω κάποιας βλάβης της γραμμής του ρεύματος.



Εικόνα 19 – Ορισμός Μάσκας Ισχύος

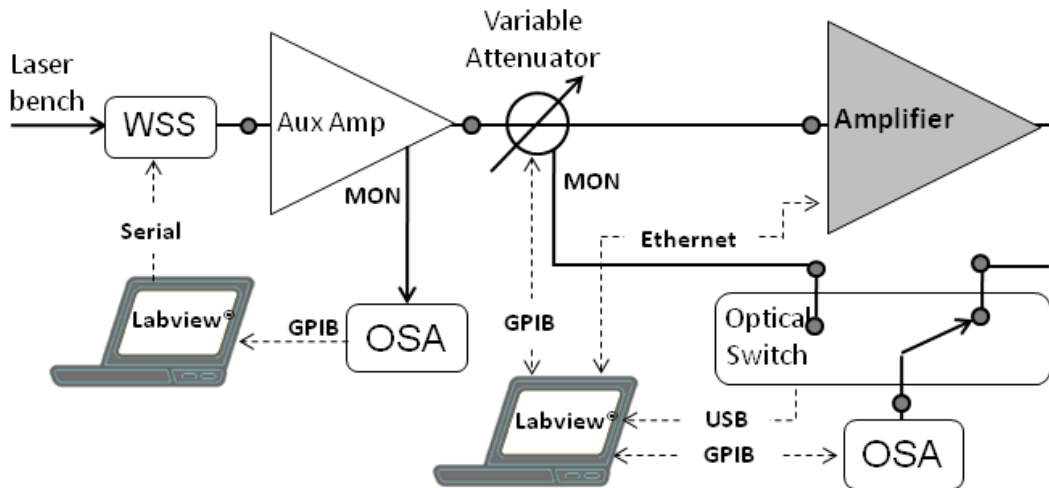
Παράμετροι, όπως NF, GF, ακρίβεια AGC και άλλες όπως η κατανάλωση ενέργειας του ενισχυτή και η θερμοκρασία του laser θα μπορούσαν να μετρηθούν και να τεθούν ως μάσκα ισχύος του ενισχυτή. Για αυτό, θα πρέπει να μετρηθούν οι τιμές για τις επιλεγμένες

μετρικές μεταβάλλοντας τις τιμές ισχύος εισόδου και εξόδου. Οι τιμές για τις επιλεγμένες μετρικές αναπαρίστανται σε χρώματα στη γραμμή χρωμάτων στη δεξιά μεριά, όπως φαίνεται στο σχήμα. Αυτό βοηθά στην οπτικοποίηση της συμπεριφοράς των μετρικών μέσα σε ολόκληρη τη Μάσκα Ισχύος. Αυτές οι μετρήσεις επιτυγχάνονται ανάλογα με τη διαδικασία χαρακτηρισμού που θα περιγραφεί στη συνέχεια.

## B. Διαδικασία Χαρακτηρισμού

Η διαδικασία χαρακτηρισμού χωρίζεται σε δύο στάδια: Την πειραματική φάση και τη φάση επεξεργασίας δεδομένων. Στην πειραματική φάση, 40 μη διαμορφωμένα και επιπεδωμένα (flattened) κανάλια με απόσταση 100 GHz συνθέτουν το πλέγμα σήματος εισόδου του ενισχυτή, το οποίο αποτελείται από επίπεδα κανάλια C-band (πλέγμα ITU-T). Αυτό το πλέγμα σήματος εισόδου μεταβάλλεται, από κοινού με ένα καθορισμένο κέρδος σημείου, για να χαρακτηρίσει ολόκληρη τη Μάσκα Ισχύος. Ο βαθμός λεπτομέρειας του χαρακτηρισμού ορίζεται από δύο ρυθμιζόμενες μεταβλητές, οι οποίες είναι το μέγεθος του βήματος και ο αριθμός των σημείων που πρέπει να μετρηθούν. Για κάθε σημείο, τα φάσματα εισόδου και εξόδου μετριοούνται και αποθηκεύονται.

Η πειραματική εγκατάσταση που φαίνεται στην παρακάτω εικόνα αποτελείται από μία δέσμη λέιζερ και έναν επιλεκτικό μεταγωγέα μήκους κύματος (WSS) που παρέχει ένα φορτίο επίπεδων καναλιών ζώνης C (C-band) μετρώντας ένα δείγμα του φάσματος του σήματος εισόδου και ρυθμίζοντας την ισχύ κάθε καναλιού μέσω μιας διαδικασίας βρόγχου που αποτελείται από τον οπτικό αναλυτή σήματος (OSA), τον υπολογιστή και το WSS: Όλα αυτά ελέγχονται από ένα πρόγραμμα Labview®. Ένας βοηθητικός ενισχυτής χρησιμοποιείται για να αυξήσει τη μέγιστη ισχύ εισόδου που έχει εισαχθεί στον ενισχυτή υπό τον χαρακτηρισμό. Ένα άλλο πρόγραμμα Labview® χρησιμοποιείται για τον έλεγχο του μεταβλητού οπτικού εξαθνητή (Variable Optical Attenuator, VOA) και του κέρδους ενισχυτή του επιλεγμένου σημείου, προκειμένου να σαρώνει ολόκληρη την περιοχή της μάσκας ισχύος. Το ίδιο πρόγραμμα Labview® χρησιμοποιείται για τη ρύθμιση του οπτικού μεταγωγέα προκειμένου να ληφθούν τα φάσματα εισόδου και εξόδου από το OSA. Όλες οι συνδέσεις από τον υπολογιστή στον εξοπλισμό επίσης απεικονίζονται στην παρακάτω εικόνα 20



Εικόνα 20 - Πειραματική Εγκατάσταση χαρακτηρισμού ενισχυτή

Όταν όλα τα σημεία έχουν πλέον καταγραφεί, χρησιμοποιείται ένα πρόγραμμα Matlab® για την επεξεργασία των δεδομένων. Σε αυτή τη φάση, τα φάσματα χρησιμοποιούνται για τον υπολογισμό του NF κάθε καναλιού χρησιμοποιώντας την ακόλουθη εξίσωση:

$$NF = \frac{P_{ASE}}{h\nu G \Delta\nu} + \frac{1}{G}$$

Το  $P_{ASE}$  είναι η ισχύς θορύβου που εκπέμπεται από τον ενισχυτή, το  $h$  είναι η σταθερά Planck,  $\nu$  είναι η συχνότητα του καναλιού,  $\Delta\nu$  είναι το μετρημένο εύρος ζώνης του σήματος και  $G$  είναι το κέρδος του καναλιού.

Ακόμα, στο στάδιο της επεξεργασίας δεδομένων, το GF και η ακρίβεια AGC υπολογίζονται επίσης και αποθηκεύονται σε έναν πίνακα από κοινού με το NF του χειρότερου καναλιού.

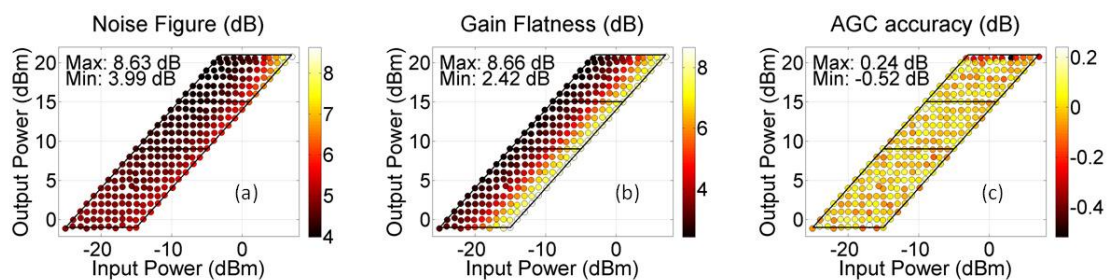
### C. Αποτελέσματα χαρακτηρισμού

Ως αποτέλεσμα της διαδικασίας χαρακτηρισμού, δημιουργείται ένας πίνακας με πληροφορίες για τις συνολικές ισχύεις εισόδου και εξόδου, το κέρδος του επιλεγμένου σημείου, NF, GF και ακρίβεια AGC. Ένα δείγμα αυτού του πίνακα, με λίγα μόνο σημεία, φαίνεται στον παρακάτω πίνακα σαν παράδειγμα των δεδομένων που ελήφθησαν.

**Πίνακας 3 – Πίνακας αποτελεσμάτων από τη διαδικασία χαρακτηρισμού με μερικά σημεία**

<b>Input Power (dBm)</b>	<b>Output Power (dBm)</b>	<b>Configured Gain (dB)</b>	<b>NF (dB)</b>	<b>GF (dB)</b>	<b>AGC accuracy (dB)</b>
<b>2.289</b>	13.182	11.000	5.976	3.151	-0.106
<b>1.819</b>	12.721	11.000	5.965	3.127	-0.098
<b>1.355</b>	12.244	11.000	5.956	3.157	-0.111
<b>0.832</b>	11.701	11.000	5.970	3.121	-0.131
<b>0.298</b>	11.163	11.000	5.938	3.137	-0.136
<b>-0.147</b>	10.754	11.000	5.959	3.122	-0.099
<b>-0.693</b>	10.164	11.000	5.983	3.171	-0.143
<b>-1.226</b>	9.637	11.000	5.963	3.202	-0.137
<b>-1.678</b>	9.183	11.000	5.974	3.122	-0.139

Η πληροφορία που φαίνεται στον παραπάνω πίνακα μπορεί επίσης να αναπαρασταθεί γραφικά όπως φαίνεται στην παρακάτω εικόνα 21. Στην 21a βλέπουμε παράδειγμα για NF, b για GF και c για ακρίβεια AGC, λαμβάνοντας υπ' όψιν τις ακόλουθες παραμέτρους της μάσκας ισχύος: Ελάχιστη ισχύ εισόδου -25 dbm, μέγιστη ισχύς εξόδου 21 dbm, ελάχιστο κέρδος 14 db, μέγιστο κέρδος 24 db και βήμα χαρακτηρισμού ίσο με 1 db.



**Εικόνα 21 – Μάσκες Ισχύος με τα αποτελέσματα του χαρακτηρισμού όσον αφορά a.NF b.GF και c.ακρίβεια AGC**

Να σημειωθεί ότι ανάλογα με την τιμή του βήματος που υιοθετήθηκε για τη διαδικασία χαρακτηρισμού και το μέγεθος της μάσκας ισχύος που λαμβάνεται υπόψη για τον ενισχυτή, ο αριθμός των γραμμών στον πίνακα αποτελεσμάτων μπορεί να αυξηθεί

σημαντικά. Εάν αυτές οι πληροφορίες αποθηκεύονται στον ενισχυτή ή σε κάποιο επίπεδο ελέγχου, μια αρκετά μεγάλη ποσότητα πληροφοριών μπορεί να καταλάβει ένα σημαντικό μέρος της περιοχής της μνήμης, η οποία θα μπορούσε να είναι απαραίτητη για άλλους σκοπούς σε πραγματικούς ενισχυτές.

Επιπλέον, τα αποτελέσματα χαρακτηρισμού αναπαρίστανται και αποθηκεύονται ως διακριτές τιμές. Κατά συνέπεια, δεν είναι εύκολο για έναν μικροελεγκτή που χρησιμοποιείται σε εφαρμογές ενισχυτών να αποκτήσει το NF ή το GF για σημεία που δεν μετρήθηκαν κατά τον χαρακτηρισμό.

### 5.1.3 Αντιστοίχιση NF και GF χρησιμοποιώντας Νευρωνικά Δίκτυα MLP


Όπως είδαμε και προηγουμένως, ο βαθμός λεπτομέρειας του χαρακτηρισμού εξαρτάται από το μέγεθος του βήματος που χρησιμοποιήθηκε για τη σάρωση των μεταβλητών που εμπλέκονται σε αυτή τη διαδικασία. Αν κάποιος χρειάζεται χαρακτηρισμό υψηλής ακρίβειας, θα είναι απαραίτητο να γίνουν πολλές μετρήσεις και η διαδικασία χαρακτηρισμού θα διαρκέσει πολύ χρόνο. Αντιθέτως, αν κάποιος αυξήσει το βήμα, η διαδικασία φυσικά θα είναι γρηγορότερη, αλλά θα υπάρξει μεγαλύτερο διάστημα μεταξύ των σημείων δεδομένων, τα οποία μπορεί να οδηγήσουν σε κακή προσέγγιση της λειτουργίας αντιστοίχισης.

Όπως φαίνεται και στην παρακάτω εικόνα 22, οι τιμές των NF και GF εξαρτώνται από τις τιμές της ισχύος εισόδου ( $P_{in}$ ) και της ισχύος εξόδου ( $P_{out}$ ). Έτσι η ιδέα είναι να χρησιμοποιήσουμε ένα νευρωνικό δίκτυο MLP για να παρεμβάλουμε τα αποτελέσματα του χαρακτηρισμού προκειμένου να δημιουργηθεί μια γενική συνάρτηση προσέγγισης για την έκφραση της εξάρτησης μεταξύ των εισόδων ( $P_{in}$  και  $P_{out}$ ) και των εξόδων (NF και GF). Η λογική είναι ότι κάνοντας την αντιστοίχιση των NF και GF με χρήση του MLP μπορεί να αποφευχθεί η αναγκαιότητα χρήσης μικρού βήματος για να προκύψει χαρακτηρισμός υψηλής ανάλυσης. Αυτό σημαίνει ότι, η χρήση ενός MLP ως βοηθητικού εργαλείου στη διαδικασία χαρακτηρισμού μπορεί να μειώσει το χρόνο που απαιτείται για τον χαρακτηρισμό ενός ενισχυτή στο πειραματικό στάδιο, ενώ συγχρόνως φτάνει και σε πολύ καλή ακρίβεια, δηλαδή το σφάλμα που δημιουργείται από τη διαδικασία παλινδρόμησης είναι χαμηλότερο από το σφάλμα που προκύπτει από τις μετρήσεις του φυσικού στρώματος. Αυτή η διαδικασία παρεμβολής μπορεί να εφαρμοστεί σε κάθε τύπο EDFA, συμπεριλαμβανομένων και αυτών με περισσότερα



από ένα στάδια. Αυτό συμβαίνει επειδή, ως γνωστόν ένα MLP μπορεί να προσεγγίσει οποιοδήποτε διαφορίσιμη μη γραμμική συνάρτηση.

Προκειμένου να αναπτυχθεί αυτό το βοηθητικό εργαλείο, σχεδιάστηκε ένα MLP που θα λάβει  $P_{in}$  και  $P_{out}$  ως εισόδους και στη συνέχεια θα επιστρέψει τα NF και GF ως εξόδους. Το σχήμα MLP παρουσιάζεται στην παρακάτω εικόνα 22. Το MLP έχει τρία στρώματα με δύο νευρώνες στο επίπεδο εισόδου, δύο νευρώνες στο επίπεδο εξόδου, και ο αριθμός των νευρώνων στο κρυφό επίπεδο θα καθοριστεί στην ανάλυση που θα γίνει στη συνέχεια. Οι νευρώνες στα επίπεδα εισόδου και εξόδου χρησιμοποιούν την ταυτοτική συνάρτηση ως συνάρτηση ενεργοποίησης. Από την άλλη πλευρά, ο νευρώνας στο κρυφό στρώμα χρησιμοποιεί τη σιγμοειδή συνάρτηση προκειμένου να ενεργοποιήσει τη δυνατότητα του MLP για την επίλυση μη γραμμικών προβλημάτων.



**Εικόνα 22 - Η αρχιτεκτονική MLP που χρησιμοποιείται για αντιστοίχιση NF και GF σαν συνάρτηση του  $P_{in}$  και  $P_{out}$ .**

Το σφάλμα που χρησιμοποιήθηκε σε όλα τα στάδια της διαδικασίας (εκπαίδευση, επικύρωση και δοκιμή) ήταν ο το μέσο απόλυτο σφάλμα λαμβάνοντας υπόψη τόσο το GF όσο και το NF. Ο αριθμός των εποχών εκπαίδευσης καθορίστηκε μετά από ανάλυση της συμπεριφοράς του σφάλματος εκπαίδευσης και του σφάλματος επικύρωσης.

### 5.1.4 Πειραματική εγκατάσταση

Προκειμένου να αξιολογηθεί η ακρίβεια του MLP για διαφορετικούς βαθμούς λεπτομέρειας του χαρακτηρισμού, χρησιμοποιούμε μάσκες ισχύος με διαφορετικά βήματα χαρακτηρισμού. Όλες οι Μάσκες Ισχύος δημιουργήθηκαν από μια μάσκα με το κέρδος να κυμαίνεται μεταξύ 11 dB και 24 dB και μια ελάχιστη είσοδο και μια μέγιστη έξοδο στα -30 dBm και 14 dBm αντίστοιχα. Χρησιμοποιήσαμε ένα βήμα κέρδους 0,5 dB με 41 πόντους χαρακτηρισμού για κάθε κέρδος, που έχει ως αποτέλεσμα συνολικά 1107 πόντους. Οι τιμές του βήματος, σε σχέση με την ισχύ εισόδου, που χρησιμοποιείται στα πειράματα είναι 1 dB, 1.5 dB, 2 dB, 2.5 dB, 3 dB, 3.5 dB, 4 dB και 6 dB. Χρησιμοποιήσαμε το βήμα κέρδους ίσο με 0,5 dB για όλα τα πειράματα.

Χωρίσαμε τα δεδομένα για να αξιολογήσουμε την ικανότητα του προτεινόμενου MLP να βρίσκει τιμές που δεν περιλαμβάνονται στο σύνολο εκπαίδευσης. Για παράδειγμα, το σύνολο εκπαίδευσης αποτελείται από τα σημεία λειτουργίας που απέχουν ακριβώς κατά 1 dB από τα γειτονικά τους σημεία στη Μάσκα Ισχύος με βήμα ίσο με 1 dB (ονομάζεται 1 dB Power Mask). Αυτό σημαίνει ότι μόνο τα μισά από τα σημεία της μάσκας ισχύος 0,5 dB χρησιμοποιήθηκαν για την εκπαίδευση του MLP με βήμα 1 dB, δηλαδή οι 567 πόντοι. Τα σημεία που δεν περιλαμβάνονται στο σύνολο εκπαίδευσης χρησιμοποιήθηκαν για τη σύνθεση των συνόλων δεδομένων επικύρωσης και δοκιμής. Αυτό δεν σημαίνει ότι όλα τα σημεία που δεν βρίσκονται μέσα στο σύνολο εκπαίδευσης θα χρησιμοποιηθούν υποχρεωτικά στα σύνολα επικύρωσης και δοκιμής. Ο αριθμός των πόντων που χρησιμοποιούνται για επικύρωση και δοκιμή είναι το μισό του συνολικού αριθμού των πόντων στο σύνολο δεδομένων εκπαίδευσης. Ο παρακάτω πίνακας 4 δείχνει τα μεγέθη των συνόλων για κάθε περίπτωση. Μπορούμε να παρατηρήσουμε ότι μικρότερος αριθμός σημείων είναι απαραίτητος καθώς αυξάνεται το βήμα εντός της μάσκας ισχύος.

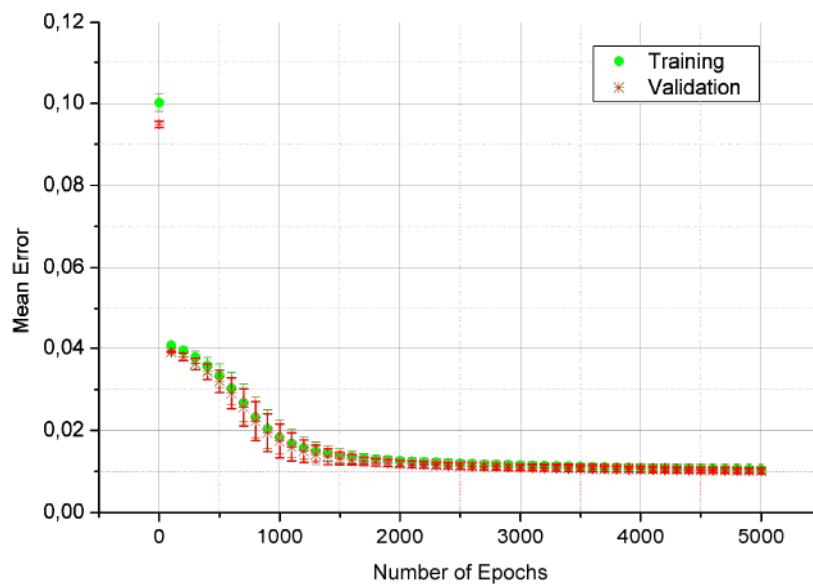
Όλα τα σημεία δεδομένων ανακατεύτηκαν και κανονικοποιήθηκαν μεταξύ 0,15 και 0,85 πριν από τη φάση της εκπαίδευσης του MLP. Κάθε αποτέλεσμα που παρουσιάζεται στην επόμενη παράγραφο προέκυψε μετά από 30 ανεξάρτητες δοκιμές από την ολοκληρωμένη διαδικασία εκπαίδευσης του MLP.

**Πίνακας 4 - ο αριθμός των σημείων που χρησιμοποιούνται για κάθε μάσκα για την εκπαίδευση, επικύρωση και δοκιμή**

<b>Power Mask</b>	<b>Number of Training Points</b>	<b>Number of Validation Points</b>	<b>Number of Test Points</b>
<b>1 dB</b>	567	257	257
<b>1.5 dB</b>	369	184	184
<b>2 dB</b>	277	138	138
<b>2.5 dB</b>	222	111	111
<b>3 dB</b>	186	93	93
<b>3.5 dB</b>	159	79	79
<b>4 dB</b>	139	69	69
<b>6 dB</b>	93	46	46

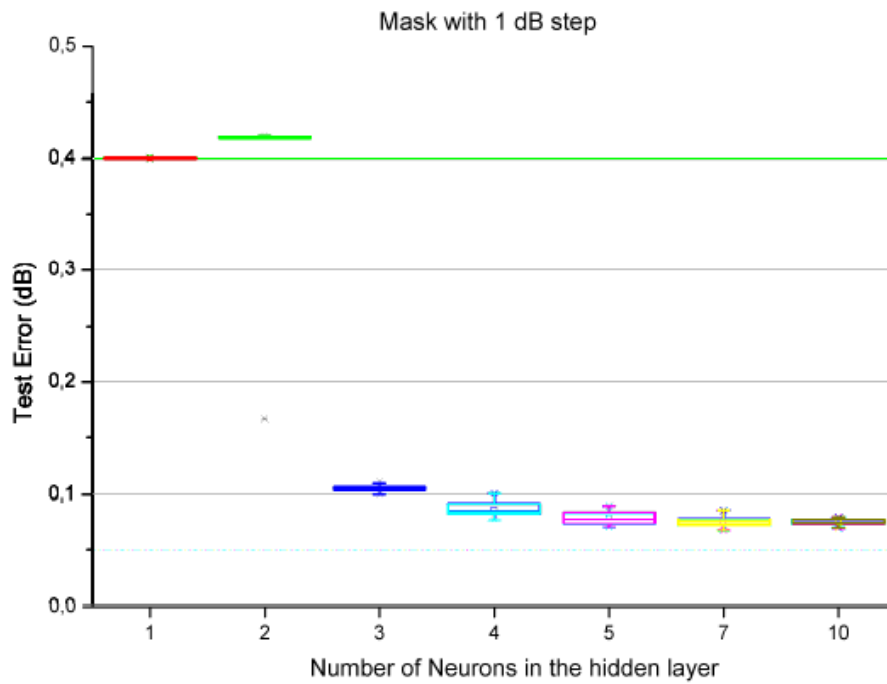
### 5.1.5 Αποτελέσματα

Η παρακάτω εικόνα 23 δείχνει την καμπύλη σύγκλισης της διαδικασίας εκπαίδευσης χρησιμοποιώντας 1 dB Μάσκα Ισχύος και 4 νευρώνες στο κρυφό στρώμα. Η μάσκα ισχύος 1 dB επιλέχθηκε αρχικά επειδή παρουσιάζει το μεγαλύτερο σύνολο δεδομένων εκπαίδευσης, πράγμα που σημαίνει ότι είναι απαραίτητος ένας μεγάλος αριθμός εποχών ώστε το MLP να διδαχθεί τα πρότυπα. Όπως μπορεί κανείς να παρατηρήσει, το σφάλμα επικύρωσης δεν αυξήθηκε με τον μεγάλο αριθμό εποχών, και έτσι με τις 5.000 εποχές η διαδικασία έφτασε σε μια σταθερή κατάσταση. Έτσι λοιπόν, στα επόμενα πειράματα χρησιμοποιήθηκαν 5.000 εποχές ως συνθήκη τερματισμού. [8]

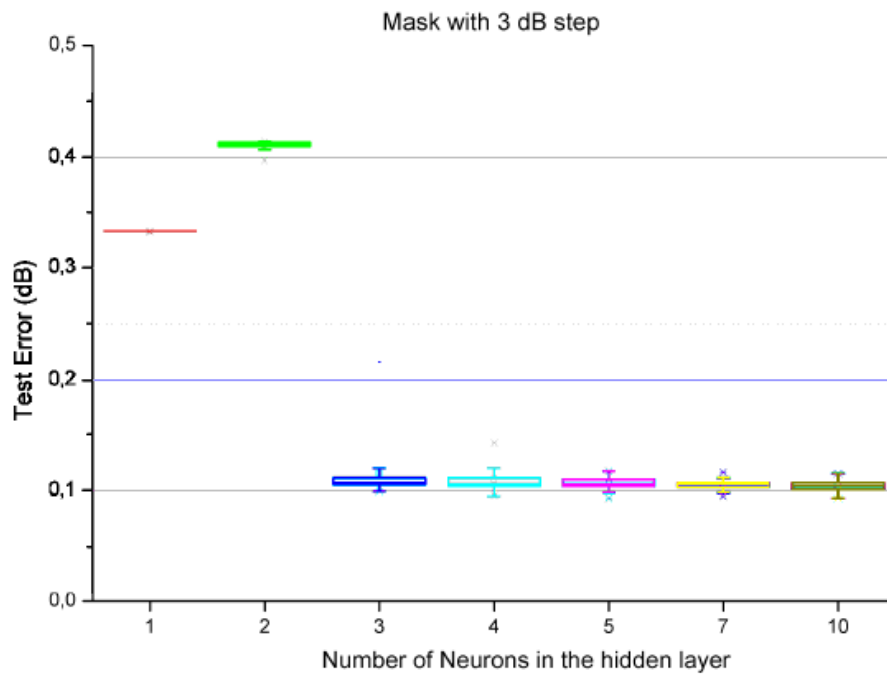


Εικόνα 23 - Καμπύλη σύγκλισης για τις διαδικασίες επικύρωσης και δοκιμής σαν συνάρτηση του αριθμού των εποχών

Οι εικόνες 24 και 25 παρουσιάζουν το θηκόγραμμα(box plot) του σφάλματος δοκιμής για διαφορετικούς αριθμούς νευρώνων στο κρυφό στρώμα με 1dB Μάσκα Ισχύος και 3 dB Μάσκα Ισχύος, αντίστοιχα. Κάποιος μπορεί να παρατηρήσει ότι μόλις κάποιοι λίγοι νευρώνες είναι απαραίτητοι για την ολοκλήρωση της διαδικασίας μάθησης και στις δύο περιπτώσεις. Έτσι χρησιμοποιήσαμε 4 νευρώνες για να αποφύγουμε τις ακραίες τιμές.




Εικόνα 24 - Θηκόγραμμα του σφάλματος δοκιμής σαν συνάρτηση του αριθμού των νευρωνίων στο κρυφό επίπεδο για Μάσκα Ισχύος 1db




Εικόνα 25 - Θηκόγραμμα του σφάλματος δοκιμής σαν συνάρτηση του αριθμού των νευρωνίων στο κρυφό επίπεδο για Μάσκα Ισχύος 3db

Η εικόνα 26 δείχνει τα αποτελέσματα του θηκογράμματος (box plot) του σφάλματος δοκιμής σαν συνάρτηση με το βήμα για 4 νευρώνες στο κρυφό στρώμα και 5.000 εποχές που επηρεάζουν το βήμα της Μάσκας Ισχύος. Όπως μπορεί κανείς να παρατηρήσει, το σφάλμα του MLP αυξάνεται ελαφρώς καθώς αυξάνεται το βήμα, αλλά διατηρεί ένα σφάλμα περίπου 0,1 dB για μέγιστο βήμα 3 dB.




**Εικόνα 26 - Θηκόγραμμα του σφάλματος δοκιμής σαν συνάρτηση του βήματος για 4 νευρώνια στο κρυφό επίπεδο**

Οι εικόνες 27 και 28 απεικονίζουν ένα παράδειγμα καμπυλών GF και NF που δημιουργούνται με τη χρήση του MLP, που κυμαίνεται η ισχύς εισόδου και ισχύς εξόδου με ανάλυση 0,1 dB.



Εικόνα 27 – Παράδειγμα GF καμπύλης που δημιουργήθηκε με τη χρήση του MLP, με την ισχύ εισόδου και εξόδου να ποικίλλει με ανάλυση 0,1 db



Εικόνα 28 – Παράδειγμα NF καμπύλης που δημιουργήθηκε με τη χρήση του MLP, με την ισχύ εισόδου και εξόδου να ποικίλλει με ανάλυση 0,1 db

### 5.1.6 Συμπεράσματα

Οι οπτικοί ενισχυτές αναπτύσσονται ευρέως στις οπτικές επικοινωνίες. Έτσι, ένας κατάλληλος χαρακτηρισμός εντός του εύρους λειτουργίας είναι απαραίτητος για πρακτική χρήση. Ο χαρακτηρισμός πραγματοποιείται με μέτρηση ενός ορισμένου αριθμού σημείων της Εικόνας Θορύβου (NF) και της Ομαλότητας Απολαβής (GF) και ο ενισχυτής θα λειτουργήσει σε ένα από αυτά τα σημεία. Δείξαμε ότι κάποιος μπορεί να χρησιμοποιήσει Perceptron πολλαπλών στρωμάτων για αντιστοίχιση των NF και GF σαν συνάρτηση των ισχύων εισόδου και εξόδου που εφαρμόζονται στον ενισχυτή. Είδαμε επίσης ότι τα MLP μπορεί να παρακάμψουν την αναγκαιότητα του μικρού βήματος για να επιτύχουν χαρακτηρισμό υψηλό ανάλυσης και αρκεί ένα μεγαλύτερο. Αυτό σημαίνει ότι η χρήση ενός MLP ως βοηθητικού εργαλείου στη διαδικασία χαρακτηρισμού μπορεί να μειώσει το χρόνο που απαιτείται για τον χαρακτηρισμό ενός ενισχυτή στο στάδιο πειράματος μετρώντας μόνο τα σημεία λειτουργίας με ένα διάστημα κέρδους 3 dB, το οποίο έχει ως αποτέλεσμα την παρουσία μόνο χαμηλών σφαλμάτων της τάξης των 0,1 dB.

Οι συνεχείς καμπύλες για τον χαρακτηρισμό του ενισχυτή, που λαμβάνονται από το προτεινόμενο σχήμα MLP, θα έχουν αντίκτυπο στην εφαρμογή γνωστικού (αυτό-προσαρμοζόμενου) επιπέδου ελέγχου στους EDFA, για δυναμικά και αυτορρυθμιζόμενα οπτικά δίκτυα.



## 5.2 Ανίχνευση και Εντοπισμός ελαφριών σφαλμάτων σε Οπτικά Δίκτυα με χρήση MM

### 5.2.1 Εισαγωγή

Η ακριβής παρακολούθηση της ποιότητας του λαμβανόμενου σήματος παρέχει μια πολύτιμη πηγή πληροφοριών για την ασφάλιση της απόδοσης των οπτικών δικτύων και την εγγύηση της ποιότητας μετάδοσης. Κατά τη λειτουργία του δικτύου, διάφορα είδη ελαφριών σφαλμάτων (σε αντίθεση με πιο σοβαρά σφάλματα), όπου το σήμα αλλοιώνεται εντελώς) μπορούν να επηρεάσουν την ποιότητα του σήματος και να προκαλέσουν ανωμαλίες στο BER στον δέκτη, οδηγώντας τελικά σε απώλειες πακέτων ή ακόμη και σε διακοπή των υπηρεσιών. Ως εκ τούτου, είναι ζωτικής σημασίας ένας σταθερός μηχανισμός για ανίχνευση ελαφριών σφαλμάτων, εντοπισμό (δηλαδή προσδιορισμό του σημείου στο δίκτυο στο οποίο συνέβη το σφάλμα και αναγνώριση της αιτίας που προκάλεσε το σφάλμα, καθώς μπορεί να χρησιμοποιηθεί από χειριστές για την εκ νέου δρομολόγηση της κυκλοφορίας και την ταχεία αποκατάσταση των βλαβών.

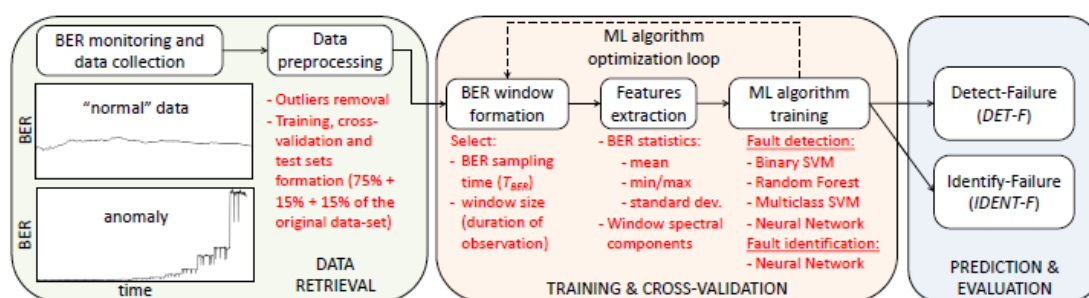
Συνεκτικοί αναμεταδότες νέας γενιάς δίνουν τη δυνατότητα παρακολούθησης διάφορων παραμέτρων που σχετίζονται με τη μετάδοση του οπτικού σήματος, όπως Optical Signal-to-Noise-Ratio (OSNR), Q-factor, ή Pre-Forward Error Connection Bit Error (προ-FEC BER). Ο όγκος των δεδομένων που προκύπτουν είναι τεράστιος και απαιτεί προηγμένες τεχνικές ανάλυσης δεδομένων ώστε να εξαχθούν οι χρήσιμες πληροφορίες από αυτά τα μεγάλα σύνολα δεδομένων. Σε αυτό το πλαίσιο, διάφορες τεχνικές μηχανικής μάθησης (ML) θεωρούνται ισχυρά εργαλεία για την αντιμετώπιση αυτού του ζητήματος, καθώς η MM επιτρέπει την αυτοματοποιημένη αυτορρύθμιση του δικτύου και τη γρήγορη λήψη αποφάσεων αξιοποιώντας αποτελεσματικά την πληθώρα δεδομένων που μπορούν να ανακτηθούν μέσω παρακολουθητών δικτύου. Προηγούμενες μελέτες έχουν ήδη αξιοποιήσει τη MM για παρακολούθηση και τον εντοπισμό αστοχιών σε οπτικά δίκτυα. Όμως εκκρεμούν ακόμα αρκετά ερωτήματα, όπως πχ ποιες πληροφορίες είναι πιο σημαντικές για χρήση, πόσο συχνά θα πρέπει να γίνεται η λήψη τους, και ποια τεχνική MM (στο μεγάλο σύνολο των ήδη υπαρχόντων και καθιερωμένων εργαλείων) ταιριάζει καλύτερα για την ανίχνευση ελαφριού σφάλματος που βασίζεται στην ανάλυση του BER στον δέκτη του σήματος.

Για την απάντηση ορισμένων από αυτά τα ερωτήματα, σε αυτή την ενότητα παραθέτουμε τα εξής:

- 1) Ορίζουμε ένα πλαίσιο για τον εντοπισμό ανωμαλιών στο BER το οποίο βασίζεται σε δεδομένα που προκύπτουν από παρακολούθηση για αυτό. Εδώ θα χρησιμοποιήσουμε διαφορετικούς αλγόριθμους MM, και θα αξιολογήσουμε την αντιστάθμιση μεταξύ πολυπλοκότητας και ακρίβειας πρόβλεψης.
  - 2) Πραγματοποιούμε ανάλυση ακρίβειας των διαφόρων τεχνικών MM προκειμένου να προσδιοριστεί ο σωστός χρόνος δειγματοληψίας του BER, δηλαδή, πόσο συχνά οι τιμές του BER θα πρέπει να συλλέγονται και να αναλύονται.
  - 3) Προτείνουμε μια μεθοδολογία βασιζόμενη σε MM που διακρίνει μεταξύ των διαφορετικών πηγών ελαφριών σφαλμάτων, επιτρέποντας την ικανότητα διάκρισης εάν η ανωμαλία BER προέρχεται από στενό φιλτράρισμα (δηλαδή λόγω κακής ευθυγράμμισης φίλτρων) ή από μειωμένη ενίσχυση (π.χ. λόγω δυσλειτουργίας του ενισχυτή, επηρεάζοντας την απόδοση του OSNR στο ενδιάμεσο χρονικό διάστημα).
- Σε αυτό το πλαίσιο, η MM παρέχει τεράστιες δυνατότητες στην εξαγωγή κρυφών προτύπων από τα δεδομένα του BER, ενώ η χρήση άλλων προσεγγίσεων θα απαιτούσε τη διαθεσιμότητα και ανάλυση πρόσθετων παραμέτρων όπως π.χ. OSNR και/ή παράγοντα ποιότητας Q. Ολόκληρη η ανάλυση πραγματοποιείται χρησιμοποιώντας πραγματικά ίχνη του BER που ελήφθησαν μέσω οπτικού δικτύου για πεδίο δοκιμών, το οποίο περιλαμβάνει 380 km οπτικής ζεύξης με ενίσχυση, και μια εμπορική συνεκτική πολικότητα M-QPSK σε 100 Gb/sec σύστημα μετάδοσης. [7]

## 5.2.2 Πλαίσια ανίχνευσης και αναγνώρισης ελαφριών σφαλμάτων

Το προτεινόμενο πλαίσιο MM για την εκτέλεση ανίχνευσης και αναγνώρισης ελαφριών σφαλμάτων συνοψίζεται παρακάτω στην εικόνα 19. Το αρχικό βήμα είναι η ανάκτηση δεδομένων. Πρώτον, τα δείγματα BER παρακολουθούνται περιοδικά και συλλέγονται σε σύνολα δεδομένων. Δύο παραδείγματα πραγματικού ίχνους δεδομένων για το BER (δηλαδή, «κανονικού» BER και «προβληματικού» BER) που εξετάζονται σε αυτή την ενότητα φαίνονται επίσης στην εικόνα. Στη συνέχεια, πραγματοποιείται προεπεξεργασία δεδομένων για την απομάκρυνση των ακραίων τιμών και το συνολικό σύνολο δεδομένων χωρίζεται σε σύνολα εκπαίδευσης, διασταυρούμενης επικύρωσης και σύνολα δοκιμών που λαμβάνουν 75%, 15% και 15% του αρχικού συνόλου δεδομένων, αντίστοιχα.



Εικόνα 29 – Πλαίσιο ανίχνευσης και αναγνώρισης ελαφριού σφάλματος


Μετά την ανάκτηση των δεδομένων, εφαρμόζονται τα δομικά στοιχεία των αλγορίθμων MM. Δηλαδή συγκεκριμένα, χωρίζουμε πρώτα τα δείγματα σε ένα σύνολο «παραθύρων» που περιέχουν πολλές διαδοχικές τιμές του BER. Για να εκπαιδύσουμε τους αλγόριθμους MM, ορίζουμε τον χρόνο δειγματοληψίας BER  $T_{\text{BER}}$  (δηλαδή, το χρόνο μεταξύ δύο διαδοχικών παρατηρήσεων του BER στο παράθυρο) και του μεγέθους «παραθύρου» (δηλαδή, τη χρονική του διάρκεια). Να σημειωθεί ότι, για ένα δεδομένο  $T_{\text{BER}}$  και μέγεθος παραθύρου, διαφορετικά παράθυρα (δηλαδή, διαφορετικά δείγματα) μπορεί να περιλαμβάνουν κοινές τιμές BER που καταγράφονται, και ως εκ τούτου θα μπορούσε να συσχετιστούν. Για παράδειγμα, θεωρούμε το παράθυρο «Α» με δείγματα από το #1 έως το #15 και το παράθυρο «Β» που περιέχει δείγματα BER από το #2 έως #16: Και τα δύο παράθυρα περιέχουν 15 καταγεγραμμένες παρατηρήσεις BER και έχουν κοινές τις τιμές BER από #2 έως και #15. Στη συνέχεια, εξάγονται χαρακτηριστικά για κάθε παράθυρο, λαμβάνοντας

υπόψη ορισμένα στατιστικά στοιχεία (δηλαδή, ελάχιστη, μέγιστη, μέση και τυπική απόκλιση του BER στο παράθυρο) καθώς και τα ισχυρότερα φασματικά συστατικά του παραθύρου, που εξάγονται με εφαρμογή μετασχηματισμού Fourier. Τέλος, μπορούν πια να εκπαιδευτούν οι αλγόριθμοι MM. Για την εκπαίδευση της μονάδας ανίχνευσης αστοχίας (η ανίχνευση βλάβης χρειάζεται για να προβλέψει εάν μια ακολουθία BER θα οδηγήσει σε αποτυχία ή όχι) χρησιμοποιούμε διαφορετικούς τύπους μεθόδων ταξινόμησης MM για ανίχνευση αστοχιών, συγκεκριμένα Binary Support Vector Machine (SVM), Random Forest (RF), Multiclass SVM και Νευρωνικό Δίκτυο (ΝΔ) με ένα κρυφό επίπεδο νευρωνίων. Από την άλλη πλευρά, για να εκπαιδευτεί η μονάδα αναγνώρισης σφάλματος (η αναγνώριση σφάλματος χρειάζεται για τον προσδιορισμό της αιτίας της βλάβης), χρησιμοποιούμε ένα ΝΔ με δύο κρυμμένα επίπεδα. Ενώ ο δυαδικός SVM είναι ένας ημιεπιβλεπόμενος αλγόριθμος ταξινόμησης, όλες οι άλλες προσεγγίσεις είναι (πλήρως) επιβλεπόμενες. Να σημειωθεί ότι, σε ημι-επιβλεπόμενα μοντέλα, απαιτούνται λιγότερα δεδομένα εκπαίδευσης για να υπάρχει υψηλή ακρίβεια. Αντίθετα, σε εποπτευόμενες προσεγγίσεις, θα πρέπει να είναι διαθέσιμα επαρκή δεδομένα για όλες τις τάξεις για να εκπαιδευτεί το μοντέλο σωστά. Στο πείραμά που ακολουθεί, για την πρώτη περίπτωση χρησιμοποιούμε μόνο "κανονικά" δεδομένα BER (δηλαδή, τιμές του BER που δεν οδηγούν σε σφάλμα), ενώ για τις τελευταίες περιπτώσεις χρειαζόμαστε μεγαλύτερο σύνολο δεδομένων, αποτελούμενο και από «κανονικά» δεδομένα για το BER αλλά και από δεδομένα από όλους τους διαφορετικούς τύπους σφαλμάτων, επηρεάζοντας έτσι τις απαιτήσεις αποθήκευσης δεδομένων και την ακρίβεια του μοντέλου, η οποία, για ένα δεδομένο μέγεθος συνόλου δεδομένων, είναι χαμηλότερη σε σύγκριση με τις ημι-εποπτευόμενες προσεγγίσεις.

Αφού εκπαιδεύσουμε τις μονάδες MM, τις δοκιμάζουμε και αξιολογούμε την απόδοσή τους χρησιμοποιώντας τις μονάδες Detect-Failure (DET-F) και Identify-Failure (IDENT-F). Το DET-F είναι σε θέση να ανιχνεύσει ακολουθίες ανωμαλιών BER, ενώ το IDENT-F ταξινομεί τις πηγές της αστοχίας, δηλαδή κάνει διάκριση εάν αυτή προέρχεται από κακή ευθυγράμμιση φίλτρων ή από μειωμένη ενίσχυση.


### 5.2.3 Αριθμητικά αποτελέσματα

Για να λάβουμε αριθμητικά αποτελέσματα υιοθετούμε την πειραματική εγκατάσταση που φαίνεται στην παρακάτω εικόνα 20:



Εικόνα 30 - Εγκατάσταση πειράματος

Οι μετρήσεις πραγματοποιήθηκαν σε σύστημα μετάδοσης Ericsson μήκους 380 χιλιομέτρων, το οποίο χρησιμοποιούσε διαμόρφωση PM-QPSK με ρυθμό μετάδοσης δεδομένων γραμμής 100 Gb/s και 30.071 Gbaud. Το σήμα ενισχύεται μέσω μιας σειράς 6 ενισχυτών EDFA ακολουθούμενοι από Variable Optical Attenuators (VOAs). Το πρώτο Bandwidth Variable-Wavelength Selective Switch (BV-WSS 1) έχει ρυθμιστεί ώστε να εισάγει στενό φίλτράρισμα ή επιπλέον εξασθένηση στο ενδιαμέσο εύρος, με την πρόθεση να μιμηθεί δύο πιθανές βλάβες που προκαλούν υποβάθμιση του BER, δηλαδή κακή ευθυγράμμιση φίλτρου και ανεπιθύμητη μείωση κέρδους ενισχυτή, αντίστοιχα. Αυτό μας επιτρέπει να συλλέξουμε δεδομένα που αντιπροσωπεύουν δύο διαφορετικές αιτίες υποβάθμισης του BER, πάνω στις οποίες θα μπορούσαμε να εκπαιδεύσουμε και να δοκιμάσουμε τη μονάδα IDENT-F. Το BV-WSS 2 δεν εισάγει επιπλέον εξασθένηση ούτε αποτελέσματα φιλτραρίσματος και χρησιμοποιείται μόνο για μείωση θορύβου. Κατασκευάσαμε το σύνολο δεδομένων μας συλλέγοντας δείγματα του BER για 24 ώρες, με διαστήματα δειγματοληψίας 22 δευτερολέπτων και 3 δευτερολέπτων σε περίπτωση ανίχνευσης ή αναγνώρισης ελαφριού σφάλματος, αντίστοιχα. [7]



Εικόνα 31 - Αριθμητικά αποτελέσματα που προέκυψαν για τα πλαίσια DET-F (α και β) και IDENT-F (c)

Αρχικά αξιολογούμε την απόδοση του αλγορίθμου Binary-SVM αξιολογώντας την ακρίβειά του για διαφορετικές τιμές  $T_{BER}$  όπως φαίνεται στην παραπάνω εικόνα 21a. Αξίζει να σημειωθεί, ότι για μια δεδομένη τιμή του  $T_{BER}$ , δεν λαμβάνουμε υπόψη όλες τις πιθανές διάρκειες του παραθύρου, αλλά θα σταματήσουμε την αξιολόγηση όταν φτάσουμε στο 100% της ακρίβειας του μοντέλου. Από την εικόνα 21a παρατηρούμε ότι για χαμηλότερο  $T_{BER}$ , ένα μικρότερο παράθυρο είναι επαρκές για τη συλλογή αρκετών δειγμάτων BER ώστε να επιτυγχάνεται η βελτιστοποίηση της απόδοσης (επιτυγχάνεται ακρίβεια 100% για διάρκεια παραθύρου περίπου 18 λεπτά). Αντιστρόφως, καθώς αυξάνεται το  $T_{BER}$ , απαιτείται μεγαλύτερη διάρκεια παραθύρου για να γίνει αποδεκτή η απόδοση, προκειμένου να συμπεριληφθούν περισσότερα δείγματα BER και να εξαχθούν πιο σημαντικά χαρακτηριστικά. Για παράδειγμα, με  $T_{BER} = 44$  δευτερόλεπτα απαιτείται παράθυρο διάρκειας περίπου 73 λεπτών για να προκύψει ακρίβεια 98%.

Στην εικόνα 21b συγκρίνουμε την ακρίβεια (που είναι ο αριστερός άξονας  $Y$  του σχήματος b) των τριών εποπτευόμενων μοντέλων που χρησιμοποιούνται για ανίχνευση ελαφριάς αστοχίας DET-F, καθώς και την πολυπλοκότητά τους, εκφρασμένη ως τη διάρκεια εκπαίδευσης του μοντέλου (ο δεξιός άξονας  $Y$ ). Για καθένα από τα τρία αυτά μοντέλα θεωρούμε ότι οι τιμές του  $T_{BER}$  και της διάρκειας παραθύρου προσδίδουν την υψηλότερη πιθανή ακρίβεια. Η χαμηλότερη πολυπλοκότητα επιτυγχάνεται με την προσέγγιση με χρήση νευρωνικού δικτύου, αλλά όμως προκύπτει η χειρότερη ακρίβεια (98,2%) μεταξύ των τριών μοντέλων. Από την άλλη πλευρά, η προσέγγιση με SVM βελτιώνει σημαντικά την ακρίβεια σε σύγκριση με τη χρήση ΝΔ φτάνοντας ακόμα και στο 99%, όμως απαιτεί περισσότερη εκπαίδευση του μοντέλου, λόγω της πολυπλοκότητας του αλγορίθμου SVM. Η βέλτιστη ισορροπία μεταξύ ακρίβειας και πολυπλοκότητας προκύπτει από το RF, το οποίο παρέχει την υψηλότερη ακρίβεια (99,1%), αλλά έχει δραστικά χαμηλότερη υπολογιστική πολυπλοκότητα σε σύγκριση με το SVM.

Τέλος, στην εικόνα 21c αξιολογούμε την ακρίβεια της μεθόδου IDENT-F για τον εντοπισμό σφάλματος, χρησιμοποιώντας πολυστρωματικό ΝΔ για διαφορετικά μεγέθη παραθύρων και  $T_{BER}$ . Όπως ήταν αναμενόμενο, αυξάνοντας το μέγεθος του παραθύρου η ακρίβεια του IDENT-F αυξάνεται ανάλογα. Επιπλέον, για μια δεδομένη διάρκεια παραθύρου, η αύξηση του  $T_{BER}$  μειώνει την ακρίβεια αναγνώρισης, αφού το μεγαλύτερο  $T_{BER}$  μειώνει τον όγκο δεδομένων που χρησιμοποιούνται για την εκπαίδευση του μοντέλου. Γενικά, ένα μέγεθος παραθύρου διάρκειας περίπου 15 λεπτών είναι αρκετό για να παρέχει 100% ακρίβεια για όλες τις τιμές του  $T_{BER}$ . Εν κατακλείδι, η προτεινόμενη προσέγγιση MM υπόσχεται ότι θα είναι σε θέση να προσδιορίσει διαφορετικές πηγές

ελαφριών σφαλμάτων, με εξαγωγή χαρακτηριστικών που σχετίζονται με την αστοχία από το σύνολο δεδομένων μας.

#### **5.2.4 Συμπέρασμα**

Σε αυτή την ενότητα μελετήσαμε και συγκρίναμε διάφορες μεθόδους που βασίζονται σε MM για έγκαιρη ανίχνευση ελαφριών σφαλμάτων (DET-F) και για τον εντοπισμό της αιτίας σφάλματος (IDENT-F), βασισμένες στη συνεχή παρακολούθηση του BER. Διερευνήσαμε την αντιστάθμιση μεταξύ της ακρίβειας και της πολυπλοκότητας του κάθε μοντέλου, που προκύπτει από τους διαφορετικούς αλγόριθμους MM, χρησιμοποιώντας αρκετές παραμέτρους μοντέλου, όπως ο χρόνος της δειγματοληψίας του BER και η ποσότητα των δεδομένων του BER που απαιτούνται για την εκπαίδευση των μοντέλων. Η σωστή αρμονία των παραμέτρων επιτρέπει στο DET-F να φτάσει την ακρίβεια στο 100% σε όλες τις υποψήφιες προσεγγίσεις MM. Για το πλαίσιο IDENT-F, επιτυγχάνεται ακρίβεια 98% στο διαθέσιμο σύνολο δεδομένων.

## Κεφάλαιο 6. Αξιολόγηση Αλγορίθμων MM στις Οπτικές Επικοινωνίες

Σε αυτήν την ενότητα, παρέχεται μια πιο ποσοτική σύγκριση ορισμένων από τις εφαρμογές MM που περιγράφονται στο Κεφάλαιο 4. Για να το κάνουμε αυτό, παρέχουμε πρώτα μια επισκόπηση των τυπικών μετρικών απόδοσης που υιοθετήθηκαν στη MM. Στη συνέχεια, επιλέγουμε μερικές από τις μελέτες που συζητήθηκαν στα Κεφάλαια 5 και 6 και επικεντρωνόμαστε στο πώς οι αλγόριθμοι MM που χρησιμοποίησαν αυτές οι εργασίες συγκρίνονται ποσοτικά χρησιμοποιώντας αυτές τις μετρικές απόδοσης.

### 6.1 Μετρικές Απόδοσης

Κατά την εφαρμογή MM σε ένα πρόβλημα ταξινόμησης, μια συνηθισμένη προσέγγιση για την αξιολόγηση της απόδοσης ενός αλγορίθμου MM είναι να φανεί η ακρίβεια ταξινόμησης και να υπολογιστεί ένα μέτρο πολυπλοκότητας του αλγορίθμου, που συνήθως εκφράζεται με τη μορφή της διάρκειας του χρόνου εκπαίδευσης. Η ακρίβεια ταξινόμησης αντιπροσωπεύει το κλάσμα των δειγμάτων δοκιμών που έχουν ταξινομηθεί σωστά. Αν και αυτή η μετρική είναι διαισθητική, αποδεικνύεται κακή μετρική σε σύνθετα προβλήματα ταξινόμησης, ειδικά όταν το διαθέσιμο σύνολο δεδομένων περιέχει μια ποσότητα από δείγματα σε μεγάλο βαθμό μη ισορροπημένα μεταξύ των διαφορετικών κλάσεων. (π.χ. ένα δυαδικό σύνολο δεδομένων όπου το 90% των δειγμάτων ανήκει σε μία τάξη). Σε τέτοιες περιπτώσεις, μπορούν να χρησιμοποιηθούν άλλες μετρικές, όπως και αυτές που ακολουθούν:

- **Πίνακας Σύγχυσης:** Σε ένα δυαδικό πρόβλημα ταξινόμησης, όπου τα δείγματα του συνόλου δοκιμών ανήκουν σε μία κλάση Θετικών είτε σε μία κλάση Αρνητικών, ο πίνακας σύγχυσης δίνει μια καλή εικόνα για την απόδοση της ταξινόμησης, δείχνοντας:  
1) Τα αληθώς θετικά (Δηλαδή δείγματα που έχουν ταξινομηθεί σωστά στην κλάση True, True Positives, TP) και τα αληθώς αρνητικά (Δηλαδή δείγματα που έχουν ταξινομηθεί σωστά στην κλάση Negative, True Negatives, TN).  
2) Τα ψευδώς θετικά (FP) και τα ψευδώς αρνητικά (FN) (Δηλαδή αυτά που ταξινομήθηκαν σε λάθος ομάδα). Έτσι λοιπόν σύμφωνα με αυτούς τους ορισμούς η ακρίβεια μπορεί να εκφραστεί με τη σχέση  $(TP + TN) / (TP + TN + FP + FN)$ .
- **Ρυθμός Αληθώς Θετικών:** Εκφράζεται από τη σχέση  $TPR = TP / (TP + FN)$ . Αυτή η μετρική παίρνει τιμές στο  $[0,1]$  και αντιπροσωπεύει την ικανότητα εντοπισμού θετικών δειγμάτων στο σύνολο δεδομένων (όσο μεγαλύτερο το σύνολο, τόσο το καλύτερο).



- **Ρυθμός Αληθώς Αρνητικών:** Εκφράζεται από τη σχέση  $FPR = FP / (FP + TN)$ . Αυτή η μετρική παίρνει τιμές στο  $[0,1]$  και αντιπροσωπεύει την ικανότητα εντοπισμού αρνητικών δειγμάτων στο σύνολο δεδομένων (όσο μεγαλύτερο το σύνολο, τόσο το καλύτερο).
- **Χαρακτηριστική καμπύλη λειτουργίας δέκτη (ROC):** Σε ένα δυαδικό ταξινομητή, ένα αυθαίρετο όριο  $\gamma$  μπορεί να τεθεί ώστε να διαχωρίζει μεταξύ των θετικών και αρνητικών περιπτώσεων: Αυξάνοντας την τιμή του  $\gamma$  μειώνουμε τον αριθμό των περιπτώσεων που ταξινομούνται ως θετικά και αυξάνουμε τον αριθμό των δειγμάτων που ταξινομούνται αρνητικά. Αυτό έχει ως συνέπεια να μειώνονται τα TP ενώ αντιστοίχως αυξάνονται τα FN, αλλά και να αυξάνονται τα TN ενώ αντιστοίχως μειώνονται τα FP, ως εκ τούτου τόσο το TPR όσο και το FPR μειώνονται. Για διαφορετικές τιμές του  $\gamma$ , η καμπύλη ROC σχεδιάζεται από το TPR στον κάθετο άξονα και το FPR στον οριζόντιο άξονα. Για  $\gamma=1$  όλα τα δείγματα ταξινομούνται ως αρνητικά, ενώ  $TPR = FPR = 0$ . Αντιστρόφως, για  $\gamma=0$  όλα τα δείγματα ταξινομούνται ως θετικά, ενώ  $TPR = FPR = 1$ . Για οποιονδήποτε ταξινομητή, η καμπύλη ROC του πάντα συνδέει αυτές τις δύο ακραίες τιμές. Οι ταξινομητές συλλαμβάνουν χρήσιμες πληροφορίες από μία καμπύλη ROC, πάνω από τη διαγώνιο του επιπέδου (FPR, TPR) και στοχεύουν να προσεγγίσουν ιδανικό ταξινομητή, ο οποίος διασυνδέει τα σημεία (0,0), (0,1), (1,1).
- **Περιοχή κάτω από την καμπύλη ROC (AUC):** Η AUC λαμβάνει τιμές στο διάστημα  $[0,1]$  και δείχνει κατά πόσο ένας δοσμένος ταξινομητής προσεγγίζει την απόδοση ιδανικού ταξινομητή. Ενώ η καμπύλη ROC είναι ένα αποτελεσματικό μέσο για την αξιολόγηση της απόδοσης ενός ταξινομητή, το AUC είναι ένα σύνθετο αριθμητικό μέτρο που δείχνει την απόδοση του αλγορίθμου ανεξάρτητα από την επιλογή συγκεκριμένου κατωφλιού.
- **Akaike Information Criteria (AIC):** Είναι μία μετρική που αποτυπώνει την καλή εφαρμογή για ένα συγκεκριμένο μοντέλο. Μετράει την απόκλιση ενός επιλεγμένου στατιστικού μοντέλου από το «αληθινό μοντέλο» ορίζοντας ως κριτήριο μια μαθηματική συνάρτηση του αριθμού των εκτιμώμενων παραμέτρων από το μοντέλο, και της μέγιστης συνάρτησης πιθανότητας. Το μοντέλο με ελάχιστο AIC θεωρείται ως το καλύτερο μοντέλο που ταιριάζει σε ένα σύνολο δεδομένων.
- **Μετρήσεις από το οπτικό πεδίο δικτύωσης:** Εκτός από αριθμητικές και γραφικές μετρήσεις που χρησιμοποιούνται παραδοσιακά στο πλαίσιο της MM, μετρήσεις από το πεδίο δικτύωσης μπορούν επίσης να υιοθετηθούν σε συνδυασμό με τέτοιες μετρικές, προκειμένου να έχουμε ποσοτική κατανόηση του πώς ο αλγόριθμος MM επηρεάζει το οπτικό δίκτυο / σύστημα. Π.χ., ένας χειριστής μπορεί να ενδιαφέρεται,

αναπτύσσοντας ελάχιστους αισθητήρες οπτικής απόδοσης κατά μήκος του lightpath, να ταξινομήσει σωστά μια υποβαθμισμένη μετάδοση με δεδομένη ακρίβεια. Παρομοίως, το ελάχιστο OSNR και / ή το επίπεδο ισχύος σήματος που απαιτείται σε έναν οπτικό δέκτη ώστε να αναγνωρίσει σωστά το υιοθετημένο MF. Επιπλέον, ένας χειριστής μπορεί επίσης να αναρωτιέται πόσο συχνά θα πρέπει να συλλέγονται δείγματα BER για να προβλέπει ή να εντοπίζει σωστά μια οπτική αστοχία κατά μήκος ενός lightpath με συγκεκριμένη ακρίβεια.

## 6.2 Ποσοτική Σύγκριση Αλγορίθμων

Παρέχουμε τώρα μια σχηματική σύγκριση ορισμένων αλγορίθμων MM που εστιάζουν σε ορισμένες από τις περιπτώσεις χρήσης που συζητήθηκαν στο κεφάλαιο 4. Για να πραγματοποιήσουμε αυτήν τη σύγκριση, επιλέγουμε, μεταξύ των περιπτώσεων που μελετήθηκαν στα κεφάλαια 5 και 6, εκείνες όπου μπορούν να εφαρμοστούν διαφορετικοί αλγόριθμοι MM οι οποίοι και συγκρίνονται στο ίδιο σύνολο δεδομένων. Σημειώστε ότι μια δίκαιη ποσοτική σύγκριση μεταξύ αλγορίθμων σε διαφορετικά έγγραφα είναι δύσκολη λόγω του γεγονότος ότι, σε κάθε έγγραφο, οι διάφοροι αλγόριθμοι έχουν σχεδιαστεί για να ταιριάζουν με το συγκεκριμένο διαθέσιμο σύνολο δεδομένων. Κατά συνέπεια, ένας δεδομένος αλγόριθμος μπορεί να αποδίδει εξαιρετικά καλά εάν εφαρμόζεται σε ένα συγκεκριμένο σύνολο δεδομένων, αλλά ταυτόχρονα μπορεί να εμφανίζει κακή απόδοση εάν το σύνολο δεδομένων αλλάξει, αν και όχι ουσιαστικά.

Ο Πίνακας III παρέχει μια τέτοια επισκόπηση, επισημαίνοντας, για κάθε υπό εξέταση περίπτωση χρήσης και την αντίστοιχη αναφορά, τους αλγόριθμους MM και τις μετρικές αξιολόγησης που χρησιμοποιήθηκαν για τη σύγκριση. Στον παρακάτω πίνακα παρέχουμε επίσης μια συνθετική περιγραφή του αποτελέσματος του εγγράφου.

**Πίνακας 5: Σύγκριση αλγορίθμων MM και μετρικών απόδοσης για περιπτώσεις χρήσης**

Περίπτωση Χρήσης	Αλγόριθμοι που χρησιμοποιήθηκαν	Μετρικές	Αποτέλεσμα Σύγκρισης
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 σε αυτούς στους τρεις αλγόριθμους MM, η ακρίβεια βελτιώνεται με το μέγεθος της Γνωσιακής Βάσης (KB)
Διαχείριση Αποτυχίας	Μπαεσιανή 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 κλπ)	Με τις σωστές παραμέτρους μοντέλων, 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

## Κεφάλαιο 7. Συζήτηση για μελλοντικές κατευθύνσεις

Σε αυτήν την ενότητα συζητάμε για το πώς αυτή η περιοχή έρευνας θα μπορούσε να επεκταθεί τα επόμενα χρόνια εστιάζοντας σε συγκεκριμένους τομείς που πιστεύουμε ότι θα απαιτήσουν περισσότερη προσοχή μελλοντικά.

**Μεθοδολογίες Μηχανικής Μάθησης:** Παρατηρούμε πώς η συντριπτική πλειονότητα των υπάρχουσών μελετών που υιοθετούν MM σε οπτικά δίκτυα χρησιμοποιούν offline μεθόδους επιβλεπόμενης μάθησης, δηλαδή, για παράδειγμα προϋποθέτουν ότι οι αλγόριθμοι MM εκπαιδεύονται με δεδομένα από το ιστορικό πριν χρησιμοποιηθούν για τη λήψη αποφάσεων στο πεδίο. Αυτή η προϋπόθεση είναι συχνά μη ρεαλιστική για δίκτυα οπτικών επικοινωνιών, όπου τα σενάρια εξελίσσονται δυναμικά ως προς το χρόνο, κάτι που οφείλεται πχ στις διάφορες παραλλαγές της κυκλοφορίας ή στις αλλαγές στη συμπεριφορά των οπτικών στοιχείων που προκαλείται από τη φθορά τους με την πάροδο του χρόνου. Προβλέπουμε λοιπόν ότι, αφού γίνει εκπαίδευση από μια παρτίδα διαθέσιμων παρελθόντων δειγμάτων, άλλοι τύποι αλγορίθμων, στον τομέα της ημιεπιβλεπόμενης ή και μη επιβλεπόμενης MM, θα μπορούσαν να εφαρμοστούν ώστε να λαμβάνουν σταδιακά δεδομένα εισόδου από αυτά που γίνονται διαθέσιμα από το επίπεδο ελέγχου του δικτύου. Υπό μια διαφορετική οπτική, θα πρέπει να διερευνηθεί η επανεκπαίδευση των επιβλεπόμενων μηχανισμών ώστε να μπορούν να επεκτείνουν τη δυνατότητα εφαρμογής τους σε π.χ. διαφορετικές υποδομές δικτύου (η εκπαίδευση σε μια δεδομένη τοπολογία μπορεί να μην είναι κατάλληλη για μια άλλη διαφορετική τοπολογία) ή στην υποδομή του ίδιου του δικτύου σε ένα διαφορετικό χρονικό σημείο (η εκπαίδευση πραγματοποιείται σε ένα συγκεκριμένο χρονικό σημείο όπως εβδομάδα / μήνας / έτος και μπορεί να μην είναι έγκυρη πλέον μετά από κάποιο χρονικό διάστημα). Κατά μία έννοια, οι νέες τεχνικές MM αναπτύχθηκαν επί τούτου για να επιλύσουν προβλήματα της οπτικής δικτύωσης που μπορεί να προκύψουν. Θα βοηθούσε, για παράδειγμα, ενεργοί αλγόριθμους MM να μπορούσαν να ρωτήσουν αλληλεπιδραστικά τον χρήστη να παρατηρήσει δεδομένα εκπαίδευσης με συγκεκριμένα χαρακτηριστικά. Με αυτόν τον τρόπο, ο αριθμός των δειγμάτων που απαιτούνται για τη δημιουργία ενός ακριβούς μοντέλου πρόβλεψης μπορεί να συνεπώς να μειωθεί, κάτι που μπορεί να οδηγήσει σε σημαντική εξοικονόμηση σε περίπτωση που η διαδικασία δημιουργίας συνόλων δεδομένων για εκπαίδευση είναι κοστοβόρα. (π.χ., όταν θα πρέπει να αναπτυχθούν αισθητήρες στα lightpaths).

**Διαθεσιμότητα δεδομένων:** Προς το παρόν, οι πωλητές και οι φορείς εκμετάλλευσης δεν έχουν ακόμη αποκαλύψει μεγάλο σύνολο από δεδομένα πεδίου ώστε να δοκιμαστεί

κατά πόσο είναι πρακτικές οι υφιστάμενες λύσεις. Αυτό το πρόβλημα μπορεί εν μέρει να αντιμετωπιστεί με προσομοίωση σχετικών γεγονότων, όπως αποτυχίες ή υποβαθμίσεις σήματος, μέσω testbeds οπτικού δικτύου, ακόμα κι αν είναι είναι απλώς αδύνατο να αναπαραχθεί η ποικιλία των σεναρίων ενός πραγματικού δικτύου σε εργαστηριακό περιβάλλον. Επιπλέον, ακόμη και σε καταστάσεις πλήρους πρόσβασης σε πραγματικά δεδομένα, για ορισμένες από τις περιπτώσεις χρήσης που αναφέρθηκαν προηγουμένως, πρακτικά είναι δύσκολο να συλλεχθούν εκτεταμένα σύνολα δεδομένων κατά τη διάρκεια συνθηκών με σφάλματα στη λειτουργία, δεδομένου ότι τα δίκτυα συνήθως διαστασιολογούνται και διαχειρίζονται μέσω συντηρητικών προσεγγίσεων σχεδιασμού που καθιστούν την πιθανότητα αστοχίας αμελητέα (στην τιμή της υποχρησιμοποίησης των πόρων του δικτύου).

**Χρονοδιαγράμματα:** Ελάχιστη προσοχή έχει αφιερωθεί μέχρι τώρα στο γεγονός ότι διαφορετικές εφαρμογές ενδέχεται να έχουν πολύ διαφορετικά χρονοδιαγράμματα πάνω στα οποία τα δεδομένα που παρακολουθούνται δείχνουν να είναι ενδιαφέροντα για παρατήρηση και για χρήσιμες αλλαγές του μοτίβου. (π.χ., η φθορά λόγω χρόνου θα μετέβαλλε τη συμπεριφορά ενός στοιχείου με πολύ αργό ρυθμό, ενώ οι συχνές αλλαγές της κίνησης επηρεάζουν με πολύ πιο γρήγορο ρυθμό, και σε διαφορετικά χρονοδιαγράμματα, π.χ. ριπές σε καθημερινό, εβδομαδιαίο, ή ετήσιο επίπεδο. Η κατανόηση του σωστού χρονοδιαγράμματος για την παρακολούθηση των παραμέτρων, που θα πρέπει να τροφοδοτηθούν σε αλγόριθμους MM, δεν είναι σημαντική μόνο για να βελτιστοποιηθεί η ακρίβεια του αλγορίθμου (και συνεπώς και η απόδοση του συστήματος), αλλά είναι θεμελιώδες για τη διάσταση του ποσού του εύρους ζώνης ελέγχου/παρακολούθησης που απαιτείται για την πραγματική εφαρμογή του συστήματος MM. Παρ' ότι ένας αλγόριθμος MM μπορεί να λειτουργεί τέλεια, αν απαιτεί πολύ μεγάλη ποσότητα δεδομένων που δειγματοληπτούνται πολύ συχνά, τότε το πρόσθετο εύρος ζώνης ελέγχου που απαιτείται θα εμποδίσει την πρακτική εφαρμογή του αλγορίθμου.

**Ένα πλήρες γνωστικό σύστημα ελέγχου:** Ένα άλλο σημαντικό ζήτημα είναι ότι όλες οι υπάρχουσες λύσεις που βασίζονται σε MM έχουν αντιμετωπίσει συγκεκριμένα και μεμονωμένα ζητήματα στην οπτική δικτύωση και τις οπτικές επικοινωνίες. Λαμβάνοντας υπόψη ότι η δικτύωση διαχειριζόμενη από λογισμικό έχει αποδειχθεί ότι είναι ικανή με επιτυχία να συγκλίνει σε έλεγχο μέσω πολλαπλών επιπέδων δικτύου και τεχνολογιών, ένας τέτοιος ενιαίος έλεγχος θα μπορούσε επίσης να συντονιστεί πολλές διαφορετικές εφαρμογές MM, για παροχή ολιστικού σχεδιασμού για ευέλικτα οπτικά δίκτυα. Στην πραγματικότητα, οι αλγόριθμοι MM μπορούν να υιοθετηθούν για την εκτίμηση διαφορετικών χαρακτηριστικών του συστήματος σε διαφορετικά επίπεδα, όπως το QoT,

συμβάντα αποτυχίας, μοτίβα κυκλοφορίας κ.λπ. κάποια από τα οποία εξαρτώνται αμοιβαία (π.χ., το QoT ενός lightpath σχετίζεται πολύ με την παρουσία βλαβών κατά μήκος της σύνδεσής του ή στους κόμβους του) ενώ άλλα δεν εμφανίζουν εξάρτηση (π.χ., τα μοτίβα κυκλοφορίας και οι διακυμάνσεις τους συνήθως δεν εμφανίζουν καμία εξάρτηση με την κατάσταση του εξοπλισμού μετάδοσης). Απαιτείται περισσότερη έρευνα για τη διερεύνηση της εφαρμοστικότητας και για την αξιολόγηση των πλεονεκτημάτων των ενοποιημένων πλαισίων ελέγχου που βασίζονται σε MM, όπου όλες οι εκτιμώμενες μεταβλητές μπορούν να ληφθούν υπόψη όταν παίρνονται αποφάσεις όπως το πού να δρομολογηθεί ένα νέο lightpath (π.χ. από άποψη εκχώρησης φάσματος και core/mode), πότε να επαναδρομολογηθεί ένα υπάρχον, ή πότε να τροποποιηθούν οι παράμετροι μετάδοσης όπως η μορφή διαμόρφωσης και ο ρυθμός μετάδοσης συμβόλων.

**Ανάνηψη από αποτυχία:** Ένας άλλος υποσχόμενος και καινοτόμος τομέας για εφαρμογή MM σε συνδυασμό με έλεγχο SDN είναι η ανάνηψη του δικτύου από σφάλματα και αποτυχίες. Τα εργαλεία ελέγχου ενός οπτικού δικτύου τυπικά είναι διαμορφωμένα σαν έμπειρα συστήματα που βασίζονται σε κανόνες, όπως πχ (IF <συνθήκες> THEN <ενέργειες>), οι οποίοι καλύπτουν τυπικά σενάρια αποτυχίας. Αυτοί οι κανόνες είναι εξειδικευμένοι και ντετερμινιστικοί και συνήθως μόνο μερικές δεκάδες σε πλήθος, και άρα δεν μπορούν να καλύπτουν όλες τις πιθανές περιπτώσεις δυσλειτουργίας. Η εφαρμογή της MM σε αυτό το ζήτημα, εκτός από την ικανότητα να λαμβάνονται υπ' όψιν δεδομένα από όλα τα επίπεδα, θα μπορούσε να φέρει επίσης έναν πιθανοτικό χαρακτηρισμό (πχ κάνοντας χρήση γκαουσιανών διαδικασιών, κατανομές πιθανότητας εξόδου αντί μεμονωμένων αριθμητικών/κατηγορικών τιμών) παρέχοντας έτσι πλουσιότερες πληροφορίες σε σχέση με τα μοντέλα που βασίζονται σε κατώφλι.

**Οπτικοποίηση:** Η ανάπτυξη αποτελεσματικών εργαλείων οπτικοποίησης, ώστε να καταστούν άμεσα προσβάσιμες και κατανοητές στους τελικούς χρήστες οι, πλούσιες σε πληροφορίες, έξοδοι που παράγονται από αλγόριθμους MM είναι βασικός παράγοντας για την απρόσκοπτη ενσωμάτωση των τεχνικών ML σε οπτικά πλαίσια διαχείρισης δικτύου είναι βασικός παράγοντας για την απρόσκοπτη ενσωμάτωση των τεχνικών MM σε πλαίσια διαχείρισης οπτικού δικτύου. Αν και έχουν γίνει κάποια προκαταρκτικά ερευνητικά βήματα προς αυτή την κατεύθυνση, πρέπει ακόμα να επινοηθούν και διερευνηθούν κατευθυντήριες γραμμές για διαισθητικές προσεγγίσεις οπτικοποίησης ανάλογα με τον συγκεκριμένο στόχο κάθε φορά της χρήσης MM (πχ παρακολούθηση δικτύου, εντοπισμός αστοχίας κ.λπ.).

**Εμπορευματοποίηση και τυποποίηση:** Αν και είναι ακόμα σε αρχικά στάδια, οι εφαρμογές MM στην οπτική δικτύωση έχουν ήδη προσελκύσει το ενδιαφέρον των χειριστών δικτύου αλλά και των πωλητών οπτικού εξοπλισμού, και αναμένεται ότι αυτό το ενδιαφέρον θα αυξηθεί ακόμα πιο γρήγορα στο εγγύς μέλλον. Μεταξύ των άλλων, παρατηρούμε ορισμένες εργασίες όπως για τη βελτιστοποίηση εκτίμησης QoT για μείωση κατώφλιου και αναδρομολόγηση λαμβάνοντας υπ' όψιν τα σφάλματα, για τον σχεδιασμό οπτικού δικτύου με χαμηλά κατώφλια, για την πρόβλεψη κίνησης, για την ανίχνευση ανωμαλιών. Επίσης, οι οργανισμοί τυποποίησης άρχισαν να εξετάζουν την εφαρμογή της MM για την επίλυση προβλημάτων δικτύωσης. Παρ' όλο που προς το παρόν δεν υπάρχει συγκεκριμένη δραστηριότητα τυποποίησης με ειδική εστίαση στα οπτικά δίκτυα, αξίζει να σημειωθεί ότι υπάρχει ο οργανισμός τυποποίησης ITU-T ο οποίος συντονίζει πρότυπα τηλεπικοινωνιών και Τεχνολογίας Επικοινωνίας Πληροφοριών και οι δραστηριότητές του περιλαμβάνουν διάφορες πτυχές της μελλοντικής δικτύωσης όπως αρχιτεκτονικές, διεπαφές, πρωτόκολλα, αλγορίθμους και μορφές δεδομένων. Μεταξύ των άλλων περιλαμβάνει και πρότυπα Y.3172 και Y.3173 για MM.

**Οπτική για μηχανική μάθηση (έναντι μηχανικής μάθησης για οπτική):** Τέλος, ένας ενδιαφέρων τομέας μελλοντικής έρευνας είναι η εφαρμογή της MM σε όλες τις οπτικές συσκευές και τα οπτικά δίκτυα. Λόγω της εγγενούς μη γραμμικής συμπεριφοράς τους, τα οπτικά στοιχεία θα μπορούσαν να διασυνδεθούν για να σχηματίσουν δομές ικανές να υλοποιήσουν εργασίες μάθησης. Αυτή η προσέγγιση αντιπροσωπεύει μια ολοκληρωμένη οπτική εναλλακτική λύση έναντι των παραδοσιακών υλοποιήσεων λογισμικού.

Εν κατακλείδι, η εφαρμογή της MM στην οπτική δικτύωση είναι ένας ταχέως αναπτυσσόμενος τομέας, ο οποίος βρίσκει όλο και περισσότερη ανταπόκριση και στη βιομηχανία αλλά και από ακαδημαϊκούς ερευνητές. Σε αυτή την ενότητα μελετήθηκαν μόνο λίγες από τις πιθανές μελλοντικές κατευθύνσεις, είναι βέβαιο ότι στο μέλλον θα προκύψουν και πολλές ακόμα περιπτώσεις έρευνας σε αυτόν τον τομέα.

## Κεφάλαιο 8. Συμπεράσματα

Κατά την τελευταία δεκαετία, τα οπτικά δίκτυα εξελίσσονται «έξυπνα» με την εισαγωγή τεχνικών όπως δικτύωσης που διαχειρίζεται από λογισμικό, συνεκτική μετάδοση, flexible grid, που είναι μόνο λίγες από τις ανερχόμενες τεχνολογικές κατευθύνσεις. Η συνδυασμένη πρόοδος του υψηλής απόδοσης υλικού και του έξυπνου λογισμικού, που ενσωματώνεται μέσω μιας πλατφόρμας SDN, παρέχει μια σταθερή βάση για πολλά υποσχόμενες καινοτομίες στην οπτική δικτύωση. Οι προηγμένοι αλγόριθμοι μηχανικής μάθησης μπορούν να κάνουν χρήση της μεγάλης ποσότητας δεδομένων που διατίθεται από τα στοιχεία παρακολούθησης του δικτύου, για να κάνουν τα δίκτυα να «μάθουν» από την εμπειρία και να γίνουν πιο ευέλικτα και προσαρμοστικά.

Οι ερευνητές έχουν ήδη αρχίσει να διερευνούν την εφαρμογή αλγορίθμων μηχανικής μάθησης για να δημιουργηθούν «έξυπνα» οπτικά δίκτυα και σε αυτή την εργασία έχουν καταγραφεί κάποιες από τις υπάρχουσες περιπτώσεις που προέρχονται από τη βιβλιογραφία και έχουν αναφερθεί και κάποιες πιθανές μελλοντικές κατευθύνσεις.



## Πίνακας Όρων

Αγγλικός Όρος	Ελληνικός Όρος
Lightpath	Οπτικό μονοπάτι
BER (Bit Error Correction)	Ρυθμός Λήψης Λαθών
Q Factor	Παράγοντας Q
Eye diagram	Διάγραμμα Οφθαλμού
Hyperbolic Tangent	Υπερβολική Εφαπτομένη
Backpropagation	
Random Forest Clustering	Ταξινομητής τυχαίου δάσους
Support Vector Machines (SVM)	Μηχανές Διανυσμάτων Υποστήριξης
k-means clustering	Ομαδοποίηση κ-μέσων
Gaussian mixture model clustering	Γκαουσιανό Μοντέλο πιθανοτήτων
Overfitting, Underfitting	Υπερεκπαίδευση, Υποεκπαίδευση
regularization coefficient	Συντελεστής Κανονικοποίησης
Nonlinearity Mitigation:	Αντιστάθμιση Μη Γραμμικότητας
Network monitors	Παρακολουθητές δικτύου
Optical performance monitors	Παρακολουθητές Οπτικής Απόδοσης
coherent technologies	Σύμφωνες τεχνολογίες
radiation	Ακτινοβολία
Gaussian process	Γκαουσιανή Διαδικασία
cognitive network management module	Μονάδα γνωστικής διαχείρισης δικτύου
educated guesses	Εκπαιδευμένες προβλέψεις
Failure Management	Διαχείριση Αποτυχίας (ή Αστοχίας ή Σφάλματος)
Gain Flatness (GF)	Ομαλότητα απολαβής
Noise Figure (NF)	Εικόνα θορύβου
Power Mask	Μάσκα Ισχύος
flattened C-band load channels	Επίπεδα κανάλια C-band
Variable Optical Attenuator (VOA)	Μεταβλητός οπτικός εξαθηνητής
Soft Failure	Ελαφριό Σφάλμα

## Βιβλιογραφία

- [1] 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 et al.(2018). An Overview on Application of Machine Learning Techniques in Optical Networks
- [2] Μεντεσίδης Γεώργιος, Γιαλαμπρινος Σεραφείμ (2010), *Δίκτυα Οπτικών Ινών και Τεχνολογίες Fttx* (Πτυχιακή Εργασία). ΤΕΙ Καβάλας, Σχολή Τεχνολογικών Εφαρμογών, Τμήμα Ηλεκτρολογίας
- [3] <https://www.wikipedia.org/>
- [4] Agrawal G.P.(2016). *Συστήματα Επικοινωνιών με Οπτικές Ίνες*. Αθήνα, Εκδόσεις Τζιόλα.
- [5] Χριστάκος Γεώργιος (2012), *Διαχείριση της χρωματικής σε μια ινοοπτική ζεύξη με τη χρήση οπτικής ίνας αντιστάθμισης ισχύος* (Πτυχιακή Εργασία). ΑΤΕΙ Καλαμάτας παράρτημα Σπάρτης, Τμήμα Τεχνολογίας Πληροφορικής και Επικοινωνιών
- [6] Σημειώσεις μαθήματος «Συστήματα μετάδοσης & δίκτυα οπτικών ινών», καθηγητή Ηρακλή Αβραμόπουλου, Ε.Μ.Π, σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών
- [7] Shahin Shahkarami, Francesco Musumeci, Filippo Cugini, Massimo Tornatore et al.(2018). Machine-Learning-Based Soft-Failure Detection and Identification in Optical Networks
- [8] Carmelo J. A. Bastos-Filho, Erick de A. Barboza, Joaquim F. Martins-Filho, Uiara C. de Moura, Juliano R. F. de Oliveira et al.(2013). Mapping EDFA Noise Figure and Gain Flatness Over the Power Mask Using Neural Networks