

Analiza metoda predviđanja prometa u optičkoj mreži

Brdar, Antonio

Master's thesis / Diplomski rad

2024

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Transport and Traffic Sciences / Sveučilište u Zagrebu, Fakultet prometnih znanosti**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:119:792460>

Rights / Prava: [In copyright](#) / [Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-07-13**



Repository / Repozitorij:

[Faculty of Transport and Traffic Sciences -
Institutional Repository](#)



SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI

Antonio Brdar

ANALIZA METODA PREDVIĐANJA PROMETA U
OPTIČKOJ MREŽI

DIPLOMSKI RAD

Zagreb, 2024.

Zagreb, 9. travnja 2024.

Zavod: **Zavod za informacijsko komunikacijski promet**
Predmet: **Planiranje telekomunikacijskih mreža**

DIPLOMSKI ZADATAK br. 7416

Pristupnik: **Antonio Brdar (0135242928)**
Studij: **Promet**
Smjer: **Informacijsko-komunikacijski promet**

Zadatak: **Analiza metoda predviđanja prometa u optičkoj mreži**

Opis zadatka:

U diplomskom radu je potrebno opisati glavne značajke optičkih mreža. Analizirati značajke prometa optičkih mreža. Utvrditi načine prikupljanja podataka u optičkim mrežama. Prikazati i usporediti metode predviđanja prometa u optičkim mrežama. Analizirati metode i tehnike predviđanja prometa u optičkoj mreži korištenjem modernih metoda strojnog učenja.

Mentor:

Predsjednik povjerenstva za
diplomski ispit:

izv. prof. dr. sc. Ivan Grgurević

Sveučilište u Zagrebu
Fakultet prometnih znanosti

DIPLOMSKI RAD

ANALIZA METODA PREDVIĐANJA PROMETA U OPTIČKOJ MREŽI

ANALYSIS OF TRAFFIC FORECASTING METHODS IN THE OPTICAL NETWORK

Mentor: Izv. prof. dr. sc. tech. Ivan Grgurević

Student: Antonio Brdar

JMBAG: 0135242928

Zagreb, lipanj 2024.

ANALIZA METODA PREDVIĐANJA PROMETA U OPTIČKOJ MREŽI

SAŽETAK

Optička mreža je podatkovna komunikacijska mreža koja koristi tehnologiju svjetlovodnog vlakna za prijenos podataka, a karakterizira ju visoka propusnost i velika brzina prijenosa podataka. U ovom diplomskom radu opisane su neke od mogućih izvedbi, arhitekture tih izvedbi te neke od tehnologija koje se koriste u optičkim mrežama. Također su opisani i razni prometni parametri koji postoje u optičkim mrežama, neki od njih su specifični za većinu komunikacijskih mreža, dok su neki specifični isključivo za optičke mreže. Nadalje, prikazane su i objašnjene tehnike praćenja i prikupljanja prometnih podataka u optičkim mrežama. Uz navedene prikazane su i analizirane relevantne metode i tehnike strojnog učenja u optičkim mrežama, a koje mogu poslužiti za predviđanje varijabilnosti odabranih prometnih parametara. U diplomskom radu je također objedinjena i prikazana praktična primjena odabranih metoda strojnog učenja kroz relevantna dostupna istraživanja.

KLJUČNE RIJEČI: Optička mreža, prometni parametri, prikupljanje podataka, strojno učenje, predviđanje prometnih parametara

ANALYSIS OF TRAFFIC FORECASTING METHODS IN THE OPTICAL NETWORK

SUMMARY

An optical network is a data communication network that uses fiber optic technology for data transmission, characterized by high bandwidth and high data transfer speeds. This thesis describes some of the possible implementations, architectures of these implementations, and some of the technologies used in optical networks. Various traffic parameters existing in optical networks are also described, some of which are common to most communication networks, while others are specific to optical networks. Furthermore, techniques for monitoring and collecting traffic data in optical networks are presented and explained. In addition, relevant machine learning methods and techniques in optical networks that can be used to predict the variability of selected traffic parameters are also analyzed. The thesis also consolidates and presents the practical application of selected machine learning methods through relevant available research.

KEYWORDS: Optical network, traffic parameters, data collection, machine learning, forecasting of traffic parameters

Sadržaj

1.	UVOD.....	1
2.	OPĆENITO O OPTIČKIM MREŽAMA.....	3
2.1.	Vrste optičkih mreža.....	5
2.1.1.	Aktivne optičke mreže.....	5
2.1.2.	Pasivne optičke mreže.....	6
2.1.3.	Elastične optičke mreže.....	7
2.1.4.	Softverski definirane optičke mreže.....	8
2.2.	Izvedbe optičkih mreža.....	10
2.2.1.	FTTH.....	10
2.2.2.	FTTB.....	11
2.2.3.	FTTN.....	11
2.2.4.	FTTC.....	12
2.2.5.	FTTD.....	13
3.	ZNAČAJKE PROMETA OPTIČKIH MREŽA.....	14
3.1.	Optička snaga i optička nelinearnost.....	14
3.2.	Optički odnos signal-šum.....	14
3.3.	Disperzija.....	15
3.4.	Volumen prometa.....	16
3.5.	Vjerojatnost blokiranja.....	17
3.6.	Pojasna širina (<i>Bandwidth</i>).....	17
3.7.	Broj pogrešno prenesenih bitova i Q faktor.....	18
3.8.	Varijacija kašnjenja (<i>Jitter</i>).....	19
4.	NAČINI PRIKUPLJANJA PODATAKA U OPTIČKIM MREŽAMA.....	20
4.1.	Sustavi izravne detekcije.....	21
4.1.1.	Tehnike praćenja u vremenskoj domeni.....	22
4.1.2.	Tehnike praćenja u frekvencijskoj domeni.....	23
4.1.3.	Tehnike praćenja u polarizacijskoj domeni.....	23
4.2.	Tehnike praćenja višestrukih parametara temeljene na digitalnoj obradi signala.....	23
4.2.1.	AAH.....	24
4.2.2.	ADTS.....	24
4.2.3.	Ostale tehnike asinkronog uzorkovanja.....	25
4.3.	Prikupljanje podataka u digitalnim koherentnim sustavima.....	25
4.3.1.	Prikupljanje podataka o disperziji.....	26
4.3.2.	Prikupljanje OSNR podataka.....	27
5.	METODE PREDVIĐANJA PROMETA U OPTIČKIM MREŽAMA.....	29

5.1.	Neuronske mreže	29
5.2.	Potporni vektori.....	31
5.3.	Analiza glavnih komponenta.....	33
5.4.	Statistički modeli	34
5.5.	Linearna regresija	35
6.	ANALIZA METODA/TEHNIKA PREDVIĐANJA PROMETA	37
6.1.	Predviđanje prometa korištenjem NN	37
6.2.	Predviđanje prometa korištenjem SVM.....	41
6.3.	Predviđanje prometa korištenjem PCA	44
6.4.	Predviđanje prometa korištenjem statističkih modela	45
6.5.	Predviđanje prometa korištenjem linearne regresije	47
6.6.	Usporedba analiziranih metoda.....	49
7.	ZAKLJUČAK.....	52
	LITERATURA	54
	POPIS KRATICA I AKRONIMA.....	61
	POPIS SLIKA.....	65
	POPIS GRAFIKONA	66
	POPIS TABLICA	67

1. Uvod

U današnjem suvremenom društvu, Internet i njegove aplikacije postale su ključno sredstvo komunikacije za širok spektar korisnika koji obavljaju svakodnevne aktivnosti. To rezultira stvaranjem značajnog i dinamičnog volumena mrežnog prometa te se iz tog razloga sve više primjenjuju optičke mreže zbog svoje velike propusnosti. Međutim, kako bi se adekvatno nosile s tim izazovima, optičke mreže suočavaju se s rastućom složenošću, posebno zbog uvođenja velikog broja prilagodljivih parametara. Stoga, predviđanje prometa u optičkim mrežama postaje ključno za implementaciju inteligentnog upravljanja, adaptivnih prilagodbi, optimizacije i unapređenja korisničkog iskustva. Danas, sposobnosti umjetne inteligencije i dubokog učenja otvaraju revolucionarne mogućnosti s fokusom na unapređenju efikasnosti mreže i korisničkog iskustva. Pojavljuje se niz novih tehnologija koje donose različite inovacije u funkcioniranju optičkih mreža, a algoritmi strojnog učenja i umjetna inteligencija omogućuju razvoj ovog područja istraživanja. Budući da strojno učenje može koristiti podatke prikupljene iz mrežnih elemenata, sposobno je pronaći optimalna rješenja za različite scenarije, čime se stvaraju dinamičnije i fleksibilnije mreže.

Svrha diplomskog rada je prikaz mjerenja i predviđanja prometa u optičkim mrežama korištenjem modernih metoda strojnog učenja. Metode strojnog učenja će biti prikazane kroz kategorije, analizirat će se način na koji svaka pojedina metoda funkcionira te za mjerenje kakve vrste prometa je najpogodnija. Bit će objašnjeni i prednosti i nedostaci svake metode strojnog učenja.

Cilj diplomskog rada je provesti preglednu analizu metoda/tehnika predviđanja prometa optičke mreže.

Diplomski rad je podijeljen u sedam povezanih cjelina:

1. Uvod
2. Općenito o optičkim mrežama
3. Značajke prometa optičkih mreža
4. Načini prikupljanja podataka u optičkim mrežama
5. Metode predviđanja prometa u optičkim mrežama
6. Analiza metoda/tehnika predviđanja prometa
7. Zaključak

U uvodnom dijelu rada opisana je struktura, cilj i svrha završnog rada.

U drugom poglavlju rada opisane su značajke, izvedbe te vrste arhitektura optičkih mreža.

U trećem poglavlju opisani su parametri koji utječu na kvalitetu prijenosa u optičkim mrežama.

U četvrtom poglavlju opisane su metode i tehnike kojima se mogu mjeriti prometni parametri u optičkim mrežama.

U petom poglavlju opisane su tehnike koje se mogu koristiti za predviđanje prometa i prometnih parametara u optičkim mrežama.

U šestom poglavlju prikazani su i opisani primjeri primjene metoda navedenih u prethodnom poglavlju kroz dosadašnja istraživanja.


U sedmom poglavlju, Zaključku, sintetizirane su sve informacije prikupljene i obrađene tijekom izrade diplomskog rada.

Na kraju rada, nalazi se Literatura koja daje uvid u sve članke, knjige i analitike korištene pri izradi diplomskog rada.

2. Općenito o optičkim mrežama

Pojava tehnologija poput virtualne stvarnosti, Internet stvari, pametnih gradova, *Blockchain*¹ tehnologije itd. zahtijevaju veliku propusnost i brzinu prijenosa te su stoga optičke mreže sve potrebnije.

Optička mreža je vrsta podatkovne komunikacijske mreže visokog kapaciteta, izgrađena tehnologijom optičkih vlakana. Zbog upotrebe svjetlosti kao prijenosnog medija, optička mreža jedna je od najbržih komunikacijskih mreža, a funkcioniра tako da optički odašiljač pretvara električni signal, primljen od mrežnog čvora, u svjetlosni impuls te ga usmjerava i šalje prema odredištu kroz optički kabel. [1] Opća shema optičke mreže prikazana je na slici 1.



Slika 1.: Opća shema optičke mreže [2]

Za razliku od bakrene parice svjetlosni impulsi optičke mreže mogu se prenositi na znatno veće udaljenosti, a tada se, na određenim dijelovima puta, ti impulsi obnove putem optičkog repetitora. Nakon što se signal dostavi na odredišnu mrežu, pretvara se u električni signal pomoću optičkog prijemnika i šalje na primateljski čvor. Osim toga, optička mreža manje je podložna vanjskim smetnjama i gubitku signala te može postići znatno veće brzine prijenosa podataka od mreža bakrene parice.

Glavne prednosti optičke komunikacije uključuju visoku propusnost, iznimno niski gubitak, veliki domet prijenosa te odsustvo elektromagnetskih smetnji. Nedostaci optičke komunikacije uključuju visoke troškove implementacije i održavanja kabla, odašiljača/prijemnika i ostale potrebne opreme, kao i potrebne vještine i stručnost prilikom instalacije kabla i međusobnog povezivanja. [1]

Postoji nekoliko glavnih komponenti koje se koriste za ispravno funkcioniranje optičkih mreža, a to su optički primopredajnici, multipleksor i demultipleksor, optički kabel, pojačala te prespojници.

Optički predajnik pretvara električni signal u svjetlosni te ga odašilje. Najčešće korišteni odašiljači su poluvodički uređaji, kao što su svjetlosne diode (engl. *light-emitting diode*, LED) i laserske diode.

¹ *Blockchain* je decentralizirana digitalna knjiga koja sigurno bilježi transakcije preko mnogih računala, omogućujući transparentnost i otpornost na manipulaciju podacima.


Optički prijamnik se najčešće sastoji od foto-detektora koji pretvara svjetlost u električnu energiju koristeći fotoelektrični efekt. Foto-detektor je obično fotodioda² na bazi poluvodiča.

Optičko pojačalo je uređaj koji se koristi za izravno pojačavanje optičkih signala bez pretvaranja u električne signale. Postavlja se na određenim mjestima u mreži kako bi se pojačali oslabljeni optički signali što je osobito važno kod dugačkih optičkih kablova kako bi se signal uspješno prenio kroz cijelu duljinu.

Optički prespojnik odnosi se na bilo koji komad preklopne opreme koji je postavljen između vlakana, a koristi se za slanje i primanje prijenosnih podataka te za određivanje smjera svakog pojedinog podatkovnog paketa.

Optički priključak je fleksibilni uređaj koji povezuje optičke kablove omogućavajući brzo spajanje i razdvajanje.

Optički kabel je vrsta kabela koji povezuje određeni broj optičkih vlakana, koja su dodatno zaštićena plastičnim omotačima [3], a njegova struktura prikazana je na slici 2.



Slika 2.: Struktura optičkog kabela [4]

Sastav optičkog kabela počinje s vanjskim omotačem koji je izrađen od čvrstog i često savitljivog materijala, nakon toga slijedi plastični omotač koji se koristi za spajanje pojedinačnih optičkih niti, a optička nit obično je okružena plaštom s nižim indeksom loma. Zbog tog nižeg indeksa loma, svjetlost u optičkom kابلu putuje kroz jezgru, neprestano se odbijajući od plašta, što je princip koji se naziva potpuna unutarnja refleksija. Budući da plašt ne apsorbira svjetlost iz jezgre, svjetlosni valovi putuju na veće udaljenosti. Vrste kablova mogu biti jednomodalne³ i multimodalne⁴. [3]

² Fotodioda je poluvodički uređaj koji pretvara svjetlost u električni signal, koristeći fotoelektrični efekt za detekciju i mjerenje svjetlosne energije.

³ Jednomodalno optičko vlakno je vrsta optičkog vlakna koja omogućava prijenos svjetlosti samo jednim načinom (modom), što omogućava prijenos na velike udaljenosti uz minimalno izobličenje i gubitak signala.

⁴ Višemodalno optičko vlakno, s druge strane, omogućava prijenos svjetlosti kroz više modova, što može dovesti do veće disperzije i izobličenja signala na većim udaljenostima.

Multiplesor je mrežni uređaj koji omogućava da se brojni podatkovni tokovi, tj. optički signali različitih valnih duljina spajaju u jedan i prenose jednom optičko niti kako bi se optimizirala učinkovitost komunikacije i smanjili troškovi.

Demultiplesor je softverski ili hardverski alat koji stvara dva ili više toka podataka iz jednog toka ulaznih podataka, odnosno obavlja inverznu funkciju multiplesora. [3], [5]

Kod optičkih mreža najčešća tehnika multiplesiranja je tehnika valnog multiplesiranja (engl. *wavelength division multiplexing*, WDM) te njegove varijante kao što je multiplesiranje s grubom valnom podjelom (engl. *coarse wavelength division multiplexing*, CWDM) i multiplesiranje s gustom valnom podjelom (engl. *dense wavelength division multiplexing*, DWDM).

WDM omogućuje dvosmjernu komunikaciju kao i povećanje kapaciteta signala, a mogu obraditi 160 signala što može povećati brzinu prijenosa optičkim vlaknom s 10 Gbit/s na 1,6 Tbit/s.

CWDM prenosi manji broj kanala i koristi širi razmak između njih za udaljenosti do 60 km, a tipične brzine prijenosa su od 1 Gbps do 10 Gbps. CWDM ima razmak između kanala do 20 nm te zato može podnijeti znatno veće fluktuacije temperature u odnosu na DWDM kojemu je razmak 1.6 nm.

DWDM tipično ima razmak između kanala 100GHz za 40 kanala ili 50GHz za 80 kanala. Svaki kanal sadrži vremenski multiplesiran (engl. *time division multiplex*, TDM)⁵ signal, a svaki od 80 kanala može prenositi podatke optičkim vlaknom brzinom od 2.5 Gbps do 200 Gbps. [5]

2.1. Vrste optičkih mreža

U današnje vrijeme postoji mnogo vrsta optičkih mreža od kojih svaka ima svoje prednosti i nedostatka. Neke od najučestalijih vrsta optičkih mreža su aktivne optičke mreže (engl. *active optical networks*, AON), pasivne optičke mreže (engl. *pasive optical networks*, PON), elastične optičke mreže (engl. *elastic optical networks*, EON) i modernije softverski definirane optičke mreže (engl. *software-defined optical networks*, SDON).


2.1.1. Aktivne optičke mreže

AON je točka-do-točke (engl. *point-to-point*, P2P) mrežna struktura što znači da svaki pretplatnik ima svoje optičko vlakno koje se završava na optičkom koncentratoru⁶. AON mreža sadrži električne preklopne elemente kao što su usmjernik ili preklopni agregator koji služe za usmjeravanje signala korisniku, a pretplatnici mogu odabrati hardver koji pruža odgovarajuću brzinu prijenosa podataka i povećavati kapacitet kako im potrebe rastu, bez restrukturiranja

⁵ TDM ili vremenski multiples je tehnika prijenosa podataka koja omogućava višestrukim signalima dijeljenje istog komunikacijskog kanala tako što se svaki signal prenosi u različitim vremenskim intervalima.

⁶ Optički koncentrator je uređaj u aktivnoj optičkoj mreži koji prikuplja i konsolidira optičke signale iz više izvora u jedan izlazni signal radi učinkovitijeg prijenosa podataka.

mreže. Međutim, AON mreža zahtijeva najmanje jedan preklopni agregator za svakog pretplatnika te ima domet do 90 km. [6] Arhitektura AON mreže prikazana je slikom 3.



Slika 3.: Arhitektura AON mreže [7]

Postoje 3 ključna elementa za izvedbu ovog tipa mreže, a to su pojačala, transponderi i modulatori.


Pojačala imaju ključnu ulogu u pojačavanju intenziteta svjetlosti koje putuje kroz optičko vlakno. Postoje dva glavna tipa: analogni i digitalni, gdje se analogna pojačala, iako su ekonomičnija, često koriste u velikim okruženjima poput podatkovnih centara i bolnica. S druge strane, digitalna pojačala koriste lasere za generiranje svjetlosti, pružajući napredne mogućnosti za specifične primjene.

Transponderi služe kao pretvarači signala, pretvarajući signale iz jednog formata u drugi.

Modulatori dijele sličnosti s transponderima, ali umjesto da pretvaraju signale iz jednog formata u drugi, modulatori mijenjaju valnu duljinu optičkog signala kako bi se osigurala kompatibilnost s optičkim medijem. [6]

2.1.2. Pasivne optičke mreže

PON je mrežna struktura u kojoj se, za razliku od AON mreže, ne koristi električno napajana oprema već se koriste pasivni optički razdjelnici za razdvajanje i spajanje optičkih signala. Optički razdjelnici omogućuju PON mreži da posluži više pretplatnika jednim optičkom vlaknom bez potrebe za postavljanjem pojedinačnih vlakana između čvorišta i krajnjih korisnika. Električno napajana oprema u PON mreži je ipak potrebna, ali samo na izvornom i prijemnom kraju mreže. To je mrežna struktura točka-do-više točaka (engl. *point-to-multipoint*, P2MP) što znači da se jedan signal dijeli na više korisnika te tako svaki korisnik dobiva frakciju početnog signala. Za razliku od AON mreže, PON mreža je cjenovno jeftinija, ali korisniku pruža nešto slabiji signal i ima domet do 20 km. [8] Arhitektura PON mreže prikazana je na slici 4.



Slika 4.: Arhitektura PON mreže [9]

U ovoj mreži postoji nekoliko ključnih komponenti koje su neophodne za njenu izvedbu, a to su optički linijski terminal (engl. *Optical Line Terminal*, OLT), optički mrežna jedinica (engl. *Optical Network Unit*, ONU) te planarni valovodni optički razdjelnici (engl. *planar waveguide circuit splitter*, PLC).

OLT je centralni uređaj u PON-u odgovoran za slanje i primanje optičkih signala prema korisničkoj strani koji se obično nalazi u centralnom uredu ili podatkovnom centru pružatelja usluga i upravlja cijelom PON mrežom.

ONU je uređaj na korisničkoj strani instaliran u kućama ili poslovnim prostorima koji prima optičke signale iz OLT-a i pretvara ih u električne signale za upotrebu terminalnim uređajima. ONU često djeluje kao kućni pristupnik, pružajući telefonske, televizijske i internetske usluge.

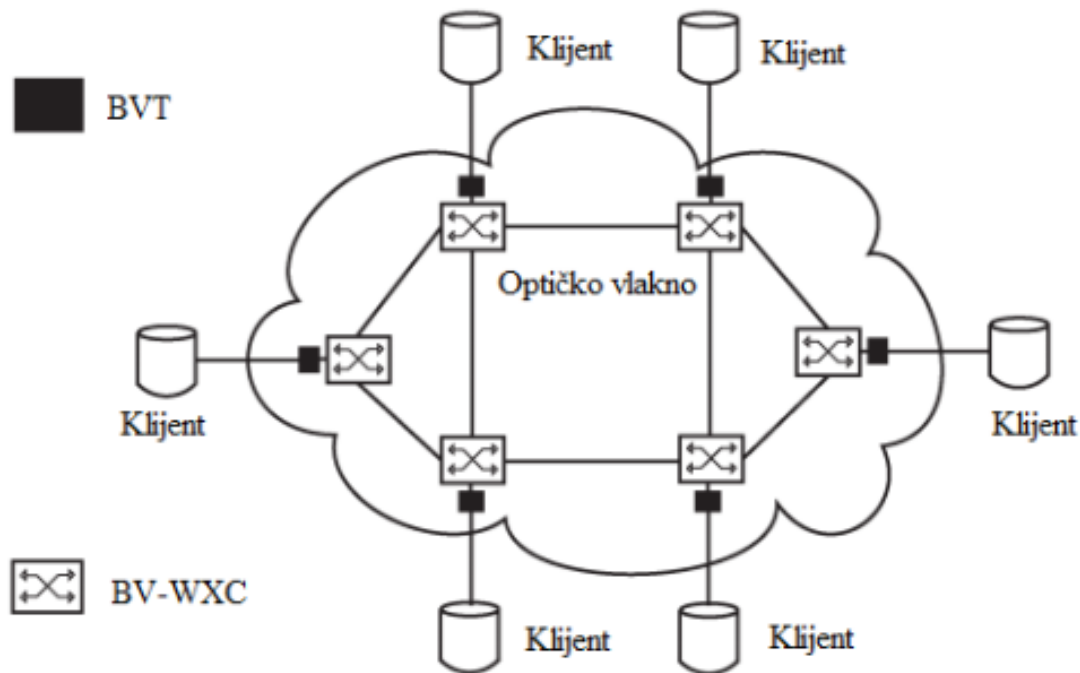
OLT i ONU moduli namijenjeni su uređajima s utorima, omogućavajući operaterima mreže proširenje ili nadogradnju PON mreže prema potrebi.

PLC razdjelnici kombiniraju višestruke optičke signale u jedan izlaz ili uzimaju jedan optički ulaz i distribuiraju ga na višestruke odvojene izlaze. PLC razdjelnici za PON su dvosmjerni što znači da se optički signali mogu slati iz centralnog ureda prema korisnicima, ali i od korisnika prema centralnom uredu. [8]

2.1.3. Elastične optičke mreže

Budući da je WDM tehnologija sve teže podržavala rastuće prometne zahtjeve, kao odgovor je nastao koncept elastičnih optičkih mreža. Elastičnost u optičkim mrežama se postiže fleksibilnom alokacijom optičkog propusnog pojasa, a to znači da se opseg valnih duljina može povećavati ili smanjivati kroz optičko vlakno s obzirom na trenutno stanje mreže, što se temelji

na konceptu „propusnosti prema zahtjevu“ (*bandwidth on demand*)⁷. Određeni parametri kao što su vrsta modulacije, razmak između kanala i brzina prijenosa koji su u drugim izvedbama optičkih mreža fiksni, postaju promjenjivi i podesivi u elastičnim optičkim mrežama. Uvođenjem elastičnosti u optičke mreže značajno se može utjecati na efikasniju upotrebu mrežnih resursa i na smanjenje troškova. [10] Arhitektura EON mreže prikazana je slikom 5.



Slika 5.: Arhitektura elastične optičke mreže [10]

EON arhitektura zahtijeva primjenu specifičnih hardverskih elemenata kao što su optički križni konektori promjenjivog kapaciteta (engl. *Bandwidth Variable Wavelength Cross-Connect*, BV-WXC) za usmjeravanje, rekonfigurabilni optički multipleksori koji se koriste za dinamičko prosljeđivanje valne duljine bez optoelektroničke pretvorbe u čvorovima, kao i prilagodljive optičke odašiljače i prijamnike (engl. *Bandwidth Variable Transponder*, BVT), koji se softverski prilagođavaju vrsti modulacija, protoku i centralnoj frekvenciji dolaznog signala. [10]

2.1.4. Softverski definirane optičke mreže


Moderne SDON mreže nastaju integracijom optičkih mreža sa softverski definiranim mrežama (engl. *software defined networks*, SDN), odnosno kombinacijom EON i SDN.

SDN je tehnologija programskih mreža koja se temelji na odvajanju podatkovnog od upravljačkog djela. Upravljački dio služi za određivanje pravila prosljeđivanja, izračunavanje ruta te praćenje topoloških promjena, dok se podatkovni dio koristi za prosljeđivanje prometa i

⁷ Propusnost prema zahtjevu je tehnika ili usluga u telekomunikacijama koja omogućava dinamičko prilagođavanje i alokaciju mrežnog kapaciteta (propusnog opsega) prema trenutnim potrebama korisnika ili aplikacija.

prikupljanje statistika na temelju pravila upravljačkog sloja. Između dva sloja nalazi se softverska komponenta, SDN kontroler, koji upravlja podatkovnim dijelovima. [11]

Softverski definirane optičke mreže imaju slične karakteristike kao i SDN, kao npr. centraliziranu kontrolu za mrežno upravljanje, a mrežni uređaji u infrastrukturi pružaju visoku fleksibilnost kako bi podržali različite mrežne uvjete. [12] SDON arhitektura prikazana je slikom 6.



Slika 6.: Arhitektura softverski definirane optičke mreže [12]

SDON arhitektura se sastoji od 3 glavne razine. Najviša, aplikacijska razina omogućuje krajnjem korisniku da upravljačkom aplikacijom primijeni promjene na mreži bez ikakvih poteškoća. Aplikacijska razina komunicira s upravljačkom razinom putem aplikacijskog programskog sučelja (engl. *Application Programming Interface*, API)⁸ u kojoj se nalazi centralizirani kontroler. Centralizirani kontroler upravlja mrežom i softverski je prilagođava te time omogućuje optimizaciju energije, alokaciju resursa i zaštitu. Najniže se nalazi podatkovna razina u kojoj se nalazi programibilna optička hardverska oprema kao npr. odašiljači, prijemnici, pojačala, modulatori itd., koji obavljaju operacije poput prijenosa, modulacije, regulacija elastičnog propusnog opsega te time omogućavaju uspostavu optimizacije i upravljanje SDON-om. Kako bi se održao korak s vremenom, u SDON mreže se integriraju

⁸ Aplikacijsko programsko sučelje je skup definiranih metoda i protokola koji omogućuju različitim softverskim aplikacijama da međusobno komuniciraju.

razne tehnologije kao npr. strateško dodjeljivanje usluge, programibilni optički uređaji, ali i strojno učenje. [12]

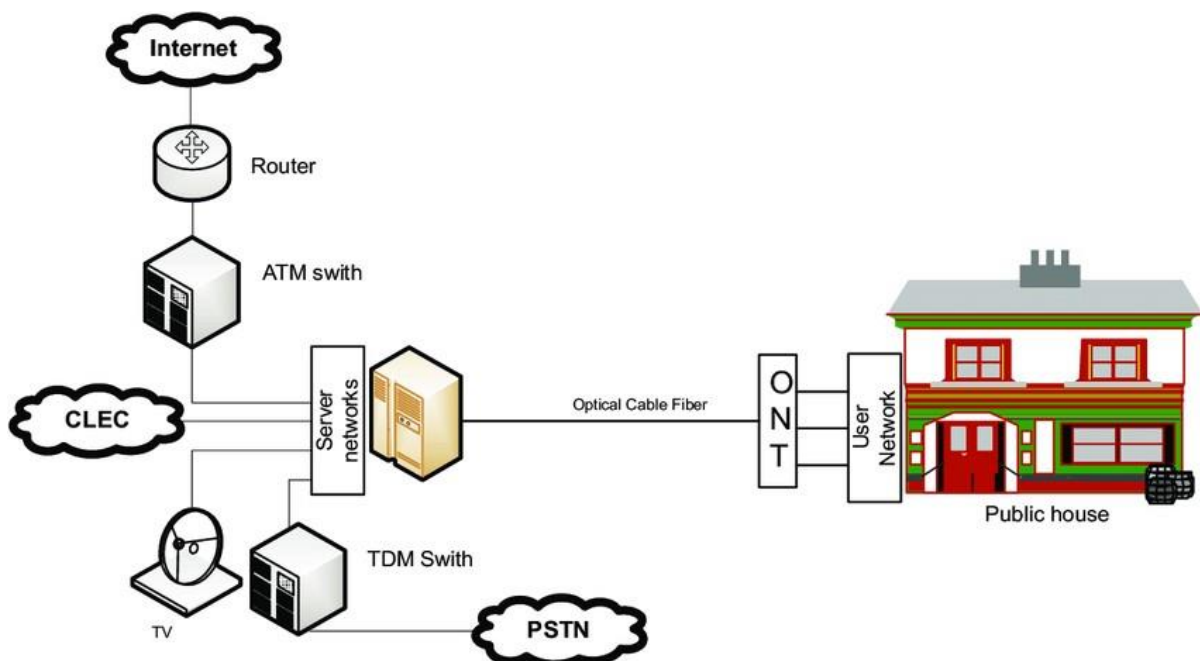
2.2. Izvedbe optičkih mreža

Koncept optičko vlakno do X (engl. *Fibre to the X*, FTTx) je kolektivni termin koji se koristi za opisivanje različitih tipova arhitektura širokopojsnih mreža, ovisno o tome gdje su im završeci. „X“ u FTTx predstavlja određeni objekt, a to može biti kuća, ormarić ili bilo koji prostor krajnjeg korisnika. Kao rezultat toga, FTTx izvedbe mogu biti vlakno do doma (engl. *Fibre to the Home*, FTTH), vlakno do zgrade (engl. *Fibre to the Building*, FTTB), vlakno do čvora (engl. *Fibre to the Node*, FTTN), vlakno do ivičnjaka (engl. *Fibre to the Curb*, FTTC), vlakno do stola (engl. *Fiber to the Desk*, FTTD) i dr.

Skupina izvedbi kod koje se usluga koja se optičkim kablom vodi korisniku do određenog korisničkog objekta, jednim imenom se zove vlakno do objekta (engl. *Fiber to the Premises*, FTTP) te u nju spadaju FTTH, FTTB, FTTD, itd. [13]

2.2.1. FTTH

FTTH pristupne mreže su izvedene na način da optički kabel vodi od središnjeg ureda kroz distribucijska čvorišta te zatim kroz mrežnu pristupnu točku i na posljepku ulaze u kućanstvo kroz terminal koji služi kao razvodna kutija. Budući da ova opcija može biti skupa za instalaciju, postala je raširenija u područjima novih gradnji. FTTH garantira brzine prijenosa do 100 Mbps, a te brzine su 20 do 100 puta brže od tipičnih veza putem bakrene parice. Arhitektura FTTH mreže je prikazana na slici 7.




Slika 7.: Arhitektura FTTH mreže [14]

Jedna potencijalna mana FTTH-a je postavljanje električnih vodova, a budući da se električna energija ne može dostaviti putem optičkih kabela, ova izvedba može zahtijevati potpuno odvojene električne vodove za instalaciju. Unatoč tim izazovima, FTTH je postao jedna od najpopularnijih primjena diljem svijeta. [13]

2.2.2. FTTB

Ovo je izvedba spajanja na svjetlovodnu mrežu gdje se svjetlovodni kabel proteže do same zgrade, a odatle se podaci distribuiraju unutar zgrade koristeći postojeću internu kablovsku infrastrukturu. FTTB izvedba je pogodna za stambene i uredske zgrade ili slične objekte, a sama implementacija zahtijeva blisku suradnju između mrežnih operatera i vlasnika ili upravitelja zgrada kako bi se ispravno povezo i optimizirao optički kabel s unutarnjom infrastrukturom zgrade. FTTB arhitektura je prikazana slikom 8.




Slika 8.: Arhitekture FTTB mreže [15]

Iako je cijena FTTB izvedbe nešto veća u odnosu na ostale izvedbe, ona pruža visoku propusnost i brze internetske veze za stanare ili korisnike zgrade. [13]

2.2.3. FTTN

FTTN se izvodi na način da se optičko vlakno poveže od poslužitelja do konekcijskog čvora, koji je uglavnom ormarić na koji je također spojena postojeća bakrena ili koaksijalna infrastruktura, kojom se zatim signal prenosi do krajnjeg korisnika. Konekcijski čvor se uglavnom nalazi u blizini susjedstva ili područja koje signal pokriva, a sam radijus pokrivanja je velik i može iznositi do 1,6 kilometara. Arhitektura FTTN mreže prikazana je na slici 9.




Slika 9.: Arhitektura FTTN mreže [15]

Veliki nedostatak ovog prijenosa može biti znatan gubitak snage signala od čvora do korisnika jer bakrena ili koaksijalna infrastruktura ne može prenijeti količinu podataka ili poslati signal brzinama i pouzdanošću optičkog vlakna. Što je veća udaljenost od čvora do korisnika, to je značajniji gubitak snage signala. Ipak, ova izvedba je isplativija od ostalih FTTx izvedbi i pruža bolju kvalitetu prijenosa od same bakrene parice ili koaksijalnog kabla. [13]

2.2.4. FTTC

Ova izvedba je vrlo slična FTTN izvedbi jer se optičko vlakno također spaja na ormarić, a signal se dalje prenosi bakrenom paricom ili koaksijalnim kablom to krajnjeg korisnika. Razlika je u tome što se ormarić nalazi znatno bliže korisniku, a izvedba FTTC mreže prikazana je na slici 10.



Slika 10.: Izvedba FTTC mreže [15]

Udaljenost ormarića može iznositi od 300 metara do maksimalno 900 metara od krajnjeg korisnika, te zbog tako male udaljenosti dolazi do manje degradacije signala u odnosu na FTTN izvedbu. FTTC je i dalje jeftinija i dostupnija izvedba u odnosu na FTTP, ali i pruža manje brzine prijenosa. [13]

2.2.5. FTTD

FTTD se odnosi na proširenje optičke infrastrukture izravno do korisničkih lokacija, gdje se optički kablovi izravno povezuju s radnim stolovima, prijenosnim računalima ili drugom komunikacijskom opremom. FTTD se najčešće koristi u poduzećima, financijskim institucijama i agencijama koje zahtijevaju visoku sigurnost i brzinu prijenosa podataka, jer zadovoljava zahtjeve za povećanjem propusnosti te prijenosom velikih količina podataka pri visokim brzinama. FTTD može omogućiti uslugu na lokacijama slabijeg napajanja te pružiti sigurniju vezu za organizacije koje su osjetljive na prisluškivanje i druge sigurnosne ranjivosti. U odnosu na bakrenu paricu, optički kabel je teže prisluškivati jer se za prijenos koristi svjetlovod, a i imun je na elektromagnetske i radio-frekvencijske smetnje pa ga je teže hakirati. Još jedna prednost u odnosu na bakrenu paricu su brzine prijenosa do 100Gbit/s, ali je isto tako ova izvedba znatno skuplja. [16]

3. Značajke prometa optičkih mreža

U optičkim mrežama značajke prometa igraju ključnu ulogu u oblikovanju i upravljanju učinkovitim prijenosom podataka. Postoje razni prometni parametri od kojih će neki biti opisani u nastavku poglavlja. Svi ti prometni parametri objedinjeno čine mjeru koja se koristi za procjenu kvalitete prijenosa signala kroz optičku mrežu, a ta se mjera naziva kvaliteta prijenosa (engl. *Quality of transmission*, QoT). Ocjenjivanje QoT-a može pomoći operatorima mreža u otkrivanju problema u prijenosu i održavanju optimalne razine performansi mreže. [17]


3.1. Optička snaga i optička nelinearnost

Optička snaga je mjera snage svjetlosnog signala koja prolazi kroz optički kabel ili optičko vlakno, a obično se izražava u decibelima ili milivatima. Najvažnija je mjera za procjenu performansi optičkog sustava jer utječe na kvalitetu prijenosa signala i udaljenost koju signal može prevaliti prije nego što se oslabi do neprihvatljive razine. Praćenje optičke snage u optičkim mrežama važno je za osiguranje stabilnog i pouzdanog prijenosa podataka jer previsoka ili premalena optička snaga može rezultirati problemima poput preopterećenja optičkih prijemnika ili gubitka signala, što može dovesti do loše kvalitete veze ili čak prekida komunikacije.

Optička nelinearnost nastaje u optičkom vlaknu zbog ovisnosti o snazi indeksa loma i rezultira interferencijom signala između različitih kanala kada prenesena snaga premaši određeni prag. Ona može ograničiti kapacitet i udaljenost prijenosa signala te je zato neophodno praćenje optičke nelinearnosti. [17]

3.2. Optički odnos signal-šum

Optički odnos signal-šum (engl. *Optical signal to noise ratio*, OSNR) je omjer snage signala prema snazi buke optičkog kanala nakon prolaska kroz optičku mrežu i najizravniji je parametar za napredno praćenje optičkih performansi. Pruža procjenu u to koliko je snaga buke optičkih komponenti degradirala optički signal te je ključan parametar za procjenu zdravlja optičke mreže i za osiguranje zadovoljavajućih performansi i pouzdanosti mreže. Što je OSNR veći, to je bolje za cjelokupni sustav. Praćenje OSNR-a često je izazovno jer može biti teško izdvojiti šum od optičkog signala, stoga je jedna od metoda praćenja korištenje optičke polarizacije jer će optički signal imati dobro definiranu polarizaciju, dok će optički šum biti nepolariziran. Međutim, tehnike elektroničkog mjerenja spektra koje mjere šum unutar spektra podataka najefikasnije su za praćenje OSNR-a jer mjere šum izravno na podacima. [18] Grafički prikaz OSNR-a prikazan je na grafikonu 1.



Grafikon 1.: Grafički prikaz utjecaja OSNR-a na optičko vlakno [19]

Prema [20], opća formula za izračunavanje OSNR-a je formula (1):

$$\text{OSNR} = 10 * \log(S/N) \quad (1)$$


gdje je S snaga signala, a N snaga buke, obje izražene u vatima ili milivatima.

Vrijednosti OSNR-a najvažnije su na prijammniku jer niska vrijednost znači da prijammnik neće detektirati signal. Tipično, OSNR bi trebao biti veći od 15 dB do 18 dB na prijammniku, ali ova vrijednost ovisi o mnogim faktorima kao što su brzina prijenosa podataka, potreban BER i sl. [20]

3.3. Disperzija


U optičkim mrežama, vlakna i druge disperzivne komponente prethodno su prilagođene za disperziju, a prijenosna veza je projektirana kako bi se prilagodila ili ispravila ta vrijednost. Međutim, mrežne greške, kvarovi u disperzivnim komponentama i nepravilno instalirani mrežni elementi potencijalni su izvori disperzije, a ti problemi često se rješavaju u statičkim mrežama, izvanmrežnim testiranjem tijekom instalacije. Povećana osjetljivost na okolišne učinke potaknula je razvoj uređaja za aktivnu kompenzaciju, a u dinamičkim optičkim mrežama, gdje različiti signali mogu prolaziti različitim putovima u različito vrijeme, ciljana je disperzija postala vremenski ovisna, a njeno praćenje otežano. U optičkim mrežama postoje dvije vrste disperzije svjetlosti, to su kromatska disperzija i polarizacijska modna disperzija.

Kromatska disperzija (engl. *chromatic dispersion*, CD) je učinak koji proizlazi iz frekvencijske ovisnosti indeksa loma u optičkom vlaknu i jedan je od glavnih čimbenika koji ograničavaju performanse sustava optičkih vlakana. Za robusne sustave visokih brzina ključno je da se disperzija kompenzira unutar strogo definiranih tolerancija. [18] Vizualni prikaz kromatske disperzije prikazan je na slici 11.



Slika 11.: Vizualni prikaz kromatske disperzije u jednomodnom vlaknu [21]

Polarizacijska modna disperzija (engl. *polarization-mode-dispersion*, PMD) je ograničenje u optičkim komunikacijskim sustavima koje se temelji na konceptu da se ista spektralna komponenta optičkih podataka dijeli na dva ortogonalna stanja polarizacije unutar vlakna, a ta dva dijela putuju vlaknom različitim brzinama. Vizualni prikaz polarizacijske modne disperzije prikazan je na slici 12.



Slika 12.: Vizualni prikaz polarizacijsko modne disperzije [22]

Štetni učinci PMD-a mijenjaju se s vremenom, ovise o temperaturi i pogoršavaju se kako raste brzina prijenosa u bitovima. [18]

3.4. Volumen prometa

Volumen prometa u optičkim mrežama odnosi se na količinu podataka koja se prenosi kroz mrežu u određenom vremenskom razdoblju. To može uključivati različite vrste podataka, poput tekstualnih podataka, slika, audio i videozapisa te drugih multimedijских sadržaja. Volumen prometa može varirati ovisno o vrsti mreže, njezinoj veličini, geografskom području

koje pokriva, vremenskim uzorcima, ali i o potrebama korisnika i aplikacija koje se koriste na mreži. U optičkim mrežama, koje su poznate po visokoj propusnosti, volumen prometa može biti izuzetno visok. Upravljanje i optimizacija volumena prometa ključni su aspekti dizajniranja i upravljanja optičkim mrežama kako bi se osigurala učinkovita isporuka podataka, minimalizirao gubitak podataka te osigurala pouzdanost i kvaliteta usluge za korisnike. [23]


3.5. Vjerojatnost blokiranja

Vjerojatnost blokiranja u optičkim mrežama odnosi se na vjerojatnost da će zahtjev za uspostavu veze u optičkoj mreži biti blokiran ili odbijen zbog nedostatka resursa ili kapaciteta unutar mreže. Drugim riječima, to je vjerojatnost da se veza između dvije točke u mreži ne uspostavi jer nema dovoljno dostupnih optičkih kanala ili valnih duljina koje bi mogle zadovoljiti zahtjev.

Visoka vjerojatnost blokiranja može dovesti do degradacije mrežnih performansi i nezadovoljstva korisnika, posebno u mrežama gdje su zahtjevi za propusnošću visoki. Minimiziranje vjerojatnosti blokiranja ključni je cilj pri dizajniranju i upravljanju optičkim mrežama, a često uključuje tehnike poput dinamičkog usmjeravanja, dodjele valnih duljina i pružanja resursa kako bi se resursi mreže učinkovito iskoristili i zadovoljili prometni zahtjevi. [24]

3.6. Pojasna širina (*Bandwidth*)

Bandwidth u optičkim mrežama je najveća moguća količina podataka koja se prenese optičkim vlaknom u jedinici vremena, a mjeri se u bit/s. Na slici 13. je prikazana usporedba pojasne širine između dva modulirana kanala i jednog moduliranog kanala na električnoj domeni. [25]



Slika 13.: Usporedba *bandwidtha* između dva modulirana kanala i jednog moduliranog kanala [26]

Bandwidth se može opisati i kao frekvencijski spektar koji svjetlosni signal zauzme prilikom prijenosa podataka. [25]


3.7. Broj pogrešno prenesenih bitova i Q faktor

Broj pogrešno prenesenih bitova (engl. *bit error rate*, BER) omjer je pogrešno prenesenih bitova s ukupnim brojem prenesenih bitova u određenom vremenskom razdoblju, izražen u postocima. Postoji mnogo čimbenika koji utječu na BER, kao što su optički odnos signal-šum, gubitak optičke snage, optička nelinearnost itd. BER je preferirani parametar za upravljanje kvarovima te je ključno pronaći točnu lokaciju gdje nastaje. Kada se BER prati na odašiljaču, signal se regenerira i oštećenja se ne akumuliraju, dok se na pojačalu signal samo pojačava, a ne potpuno regenerira, stoga i nastaje BER. [18], [27]

Q-faktor je mjera kvalitete digitalnog signala u optičkom komunikacijskom sustavu, odnosno funkcija stope BER-a, snage signala i snage buke. Q-faktor se često koristi za procjenu performansi optičkog sustava jer izravno utječe na sposobnost sustava da točno prenosi podatke. Visok Q-faktor ukazuje na to da sustav učinkovito razlikuje više različitih stanja signala (kao što su "0" i "1" u binarnom sustavu), što rezultira nižim BER-om. Ova mjera kvalitete posebno je važna u optičkim sustavima visokih brzina gdje je kritično minimizirati greške u svrhu održavanja pouzdanosti. Analiza Q-faktora korisna je i za dijagnosticiranje problema u optičkom sustavu, kao što su loša kvaliteta komponenti ili nepovoljni uvjeti prijenosa, a održavanje visokog Q-faktora ključno je za osiguravanje optimalnog rada i dugovječnosti optičkih komunikacijskih mreža. Izračunava se kao omjer udaljenosti između prosječnih razina signala dvaju susjednih simbola i standardne devijacije šuma. [18], [27]

3.8. Varijacija kašnjenja (*Jitter*)

U optičkim mrežama, *jitter* se odnosi na varijaciju u vremenskom intervalu između dolazaka ili odlazaka signala. Drugim riječima, to je fluktuacija u vremenu dolaska ili odlaska podataka u odnosu na očekivani ili idealni vremenski raspored. Utjecaj *jittera* na signal prikazan je na slici 14.



Slika 14.: Utjecaj *jittera* na optički signal [29]

Jitter može biti rezultat različitih faktora, uključujući propusnost mreže, optičke karakteristike prijenosnog medija, razlike u brzinama prijenosa podataka između uređaja u mreži ili različite latencije u mreži. U optičkim mrežama, *jitter* se može pojaviti zbog različitih optičkih efekata poput disperzije ili nehomogenosti u signalu.

Visok *jitter* može imati negativan utjecaj na QoT u mreži, posebno u aplikacijama koje zahtijevaju konstantnu brzinu prijenosa podataka, poput glasovnih ili videosustava. Stoga je kontrola *jittera* važan aspekt u dizajniranju i upravljanju optičkim mrežama kako bi se osigurala stabilna i pouzdana komunikacija. [28]

Vremenski *jitter* teško je pratiti i kompenzirati, a najčešće se povezuje s predajnikom pa se može tamo i pratiti. Općeniti monitori OSNR-a, kao što su Q-faktor i BER, indirektno su osjetljivi na *jitter* i mogu se koristiti za identifikaciju njegovog izvora. [18]

4. Načini prikupljanja podataka u optičkim mrežama

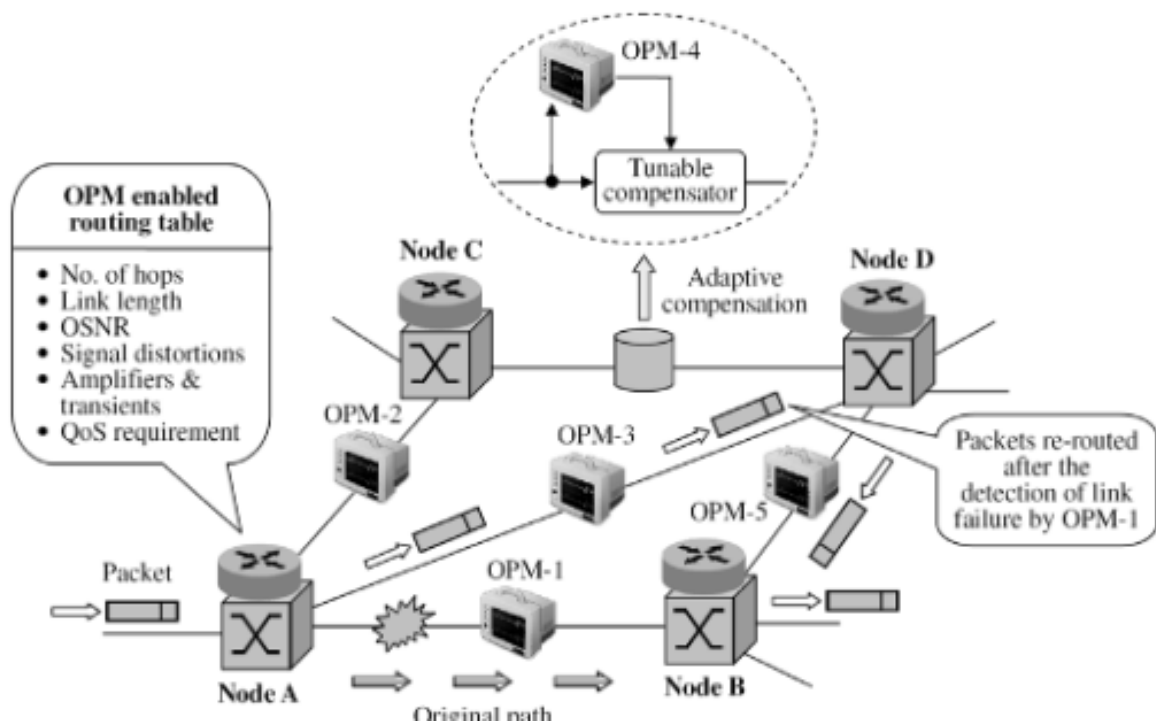
Prikupljanje podataka u optičkim mrežama često je vrlo kompleksno, a najčešće se odrađuje na fizičkom ili mrežnom sloju. Prikupljanje podataka u optičkim mrežama predstavlja veliki izazov, budući da mrežni putevi nisu statični, a učinci koji narušavaju prijenos podataka mogu se mijenjati promjenom temperature, starenjem i održavanjem optičkog vlakna. Fizička arhitektura optičke mreže može se konfigurirati, a dodatne elektroničke komponente mogu se dodati na različite točke kako bi se prikupljali i pratili podaci o signalu. [30]

Svrha prikupljanja podataka u optičkoj mreži jest izoliranje specifičnog uzroka i lokacije problema te omogućavanje nekoliko važnih funkcionalnosti mreže, uključujući:

Prilagodljivo kompenziranje oštećenja – oštećenja u optičkim mrežama su vremenski varijabilna zbog čestih konfiguracija mreže što znači da i metode kompenziranja oštećenja moraju biti dinamičke. Prikupljanjem mrežnih podataka može se učinkovito procijeniti degradacija uzrokovana optičkom vezom te se te informacije zatim mogu upotrijebiti za pružanje povratnih informacija za adaptivnu kompenzaciju ovih oštećenja što je prikazano na slici 15.

Pouzdan rad mreže – prikupljanje podataka može pružiti informacije o stanju optičke mreže u stvarnom vremenu te o mjestu i opsegu kvara. Davateljima usluga to pomaže u procjeni početka pogoršavanja podatkovnog signala te im omogućava poduzimanje preventivnih mjera kako bi se osigurao pouzdan rad mreže, a to je također prikazano na slici 15.

Učinkovitu alokaciju resursa, usmjeravanje s obzirom na stanje mreže te elastične optičke mreže – Prikupljanje podataka može učinkovito olakšati korištenje dostupnih mrežnih resursa. Na primjer, ako je kvaliteta veze vrlo dobra u dinamičkoj optičkoj mreži, prijenosna snaga signala može se smanjiti, a time se smanjuje i OSNR. Prikupljanje podataka pruža uvid i u stanje optičke mreže te se pomoću tih podataka mogu ažurirati tablice usmjeravanja što omogućava usmjeravanje na temelju raznih parametara, kao npr. duljina vlakna, OSNR, zagušenost itd. Usmjeravanje s obzirom na stanje mreže je isto tako pokazano na slici 15. Tehnologija prikupljanja podataka u optičkim mrežama također je ključna tehnologija koja omogućava EON, kod kojih se ti podaci koriste za prilagođavanje mrežnih elemenata u svrhu optimizacije prijenosa. [17]




Slika 15.: Prilagodljivo kompenziranje oštećenja, pouzdan rad mreže te usmjeravanje s obzirom na stanje mreže omogućeno kroz prikupljanje podataka u optičkoj mreži [17]

Značajke koje određuju koja se će se metoda prikupljanja prometnih podataka primijeniti, određene su s nekoliko faktora kao npr. stanje optičke mreže, brzina prijenosa te cijena implementacije, a od samih tih značajki očekuje se da zadovolje kriterije kao što su preciznost, dinamički raspon, niska potrošnja snage, isplativost, brzo vrijeme odziva, implementacija na različitim kanalima te najbitnije, ne smije se ometati stvarni promet. [17]

4.1. Sustavi izravne detekcije

Prijamnici u sustavima izravne detekcije koriste fotodetektore⁹ za otkrivanje intenziteta optičkog signala, a prvenstveno služe za prikupljanje podataka o disperziji, optičkoj snazi, OSNR-u i optičkoj nelinearnosti. Metode direktne detekcije se generalno mogu podijeliti u analogne i digitalne, a detaljnija podjela je prikazana na slici 16.

⁹ Fotodetektor je uređaj koji pretvara svjetlost (fotone) u električni signal.



Slika 16.: Klasifikacija metoda prikupljanja podataka u sustavima direktne detekcije [17]

Digitalne metode, npr. prikupljanje podataka o BER, osiguravaju informacije o ukupnoj degradaciji kvalitete signala uzrokovane oštećenjima mreže, ali se ne može izolirati njihov pojedinačan utjecaj.

Analogne tehnike direktne detekcije se koriste za otkrivanje informacija o oštećenju kanala na način da se analizira valni oblik analognog signala. Analogne tehnike se dijele na niz potkategorija koje su opisane u nastavku. [17]

4.1.1. Tehnike praćenja u vremenskoj domeni

Uzorci prikupljanja podataka kod ovakve tehnike mogu se podijeliti u asinkrone i sinkronizirane, ovisno o tome je li brzina prikupljanja podataka sinkronizirana s brzinom simbola ili ne. Sinkronizirane tehnike zahtijevaju i oporavak sata.

Dijagram oka (engl. *Eye diagram*) je jedna od sinkroniziranih tehnika koja služi za prikupljanje podataka o svim efektima koji kvalitativno utječu na QoT. Međutim, ne može kvantificirati učinke pojedinačnih efekata.

Q faktor je još jedna sinkronizirana tehnika koja je vrlo učinkovita kod upravljanja greškama zbog svoje velike korelacije s BER-om. Q-faktor je u osnovi OSNR koji ako se mjeri pomoću prijemnika je točno elektronički SNR, a ako se mjeri drugim sredstvima kao što je optičko uzorkovanje, tada je to optički OSNR. [17], [18]

4.1.2. Tehnike praćenja u frekvencijskoj domeni

Ove tehnike mogu se podijeliti na tehnike temeljene na optičkom spektru i na tehnike temeljene na radiofrekvencijskom spektru.

Tehnike temeljene na optičkom spektru mogu služiti za mjerenje optičke snage korištenjem optičkog filtera koji je podešen preko pojasne širine kanala, a spektralna rezolucija određena je pojasnom širinom filtera. Druga vrste primjene ove tehnike je izvođenje homodinske detekcije, gdje se podesivi laserski signal odašilje i miješa s nadziranom signalom, čineći interferencijski signal koji se zatim koristi za spektralnu analizu. Tehnike temeljene na optičkom spektru mogu prikupljati podatke o OSNR-u, ukupnoj optičkoj snazi te se njima mogu prikupljati podaci više WDM kanala istovremeno, ali se ne mogu pratiti CD i PMD.

Podaci prikupljeni tehnikom praćenja temeljenoj na radiofrekvencijskom spektru mogu pružiti bolju procjenu kvalitete signala u usporedbi s tehnikama temeljenim na optičkom spektru jer analiziraju spektar signala koji je kodiran u optičkom nosaču¹⁰. Ove tehnike koriste ili tonske signale prisutne u spektru različitih vrsta modulacija ili koriste umetnute pilotske tonove različitih frekvencija u svaki kanal na predajniku. Tehnike prikupljanja podataka temeljene na tonskim signalima mogu mjeriti CD i PMD te su ovisne o brzini prijenosa podataka i vrsti modulacije. S druge strane, prikupljanje podataka temeljeno na pilotskim tonovima može mjeriti parametre poput valne duljine, OSNR-a, CD i PMD, dodjeljivanjem jedinstvene frekvencije tona svakom WDM signalu i praćenjem njegovog puta. Tehnike prikupljanja podataka pilotskim tonovima su neovisne o brzini prijenosa podataka i vrsti modulacije. Međutim, negativan učinak korištenja pilotskih tonova je taj što mogu izazvati interferenciju s podatkovnim signalom, što pak rezultira povećanjem BER-a. [17]

4.1.3. Tehnike praćenja u polarizacijskoj domeni

Tehnike prikupljanja podataka u polarizacijskoj domeni koriste promjene u polarizacijskim karakteristikama optičkih signala, uzrokovane raznim degradacijama kanala, za praćenje kvarova na mreži. Ove tehnike mogu prikupljati podatke o OSNR-u kao i podatke o PMD, npr. mjerenjem stupnja polarizacije primljenog signala. Ove tehnike imaju prednost jer su transparentne za brzine prijenosa podataka i formate modulacije. Međutim, nisu primjenjive na polarizacijski multipleksirane signale, što ozbiljno ograničava njihovu uporabu u koherentnim prijenosnim sustavima. [17]

4.2. Tehnike praćenja višestrukih parametara temeljene na digitalnoj obradi signala


Ove tehnike koriste statistička svojstva podatkovnih signala nakon optičko/električne konverzije za procjenu kritičnih parametara kvalitete signala. Ove tehnike omogućuju troškovno učinkovito prikupljanje podataka više parametara kvalitete signala istovremeno, za

¹⁰ Optički nosač u kontekstu optičke mreže odnosi se na svjetlovodni val (ili optički signal) koji prenosi podatke kroz optičko vlakno.

nekoliko brzina prijenosa podataka i vrsta modulacije, bez potrebe za modifikacijom hardvera. Tehnike praćenja temeljene na digitalnoj obradi signala obično izvode asinkrono uzorkovanje amplitude električnog signala, a zatim generiraju jednodimenzionalne ili dvodimenzionalne histograme uzoraka signala. Statističke značajke ovih histograma potom se koriste za praćenje višestrukih parametara primjenom statističke obrade signala, umjetne inteligencije i tehnika digitalne obrade slika. Neke istaknute takve tehnike prikupljanja podataka za sustave izravne detekcije uključuju tehnike asinkronog histograma amplitude (engl. *asynchronous amplitude histograms*, AAH), asinkrone krivulje odgode i preslušavanja (engl. *asynchronous delay-tap plots*, ADTP), asinkrone krivulje dvostrukog preslušavanja (engl. *asynchronous two-tap plots*, ATTP) i asinkronog uzorkovanja jednog kanala (engl. *asynchronous single channel sampling*, ASCS). [17]

4.2.1. AAH

Tehnike temeljene na digitalnoj obradi koje koriste AAH su vrlo jednostavne i fleksibilne, a njihov način rada je prikazan na slici 17.




Slika 17.: Konceptualni prikaz prikupljanja podataka AAH tehnikom [17]

Da bi se dobio AAH, nasumično se prikupljaju uzorci amplitude električnog signala, po stopi mnogo nižoj od brzine simbola. Nakon što se prikupi dovoljan broj uzoraka te se dobije potpuna statistika signala, generira se histogram. Oblik AAH odražava svojstva signala, a budući da je signal iskrivljen zbog nekoliko optičkih oštećenja, statističke značajke AAH također se razlikuju u skladu s tim, čime se procjenjuje razina oštećenja koja degradira optički signal. Prednosti tehnika prikupljanja podataka temeljenih na AAH su isplativost, manja složenost implementacije te transparentnost za brzine prijenosa podataka i vrstu modulacije. Međutim, njihov nedostatak je što su parametri koji utječu na oštećenje signala izmiješani pa je nemoguće izolirati jedan parametar za praćenje, a točnost ovisi o broju prikupljenih uzoraka što može rezultirati dužim vremenskim razdobljem za izračun. [17], [31]

4.2.2. ADTS

Tehnike praćenja temeljene na ADTS-u funkcioniraju na identičan način kao i AAH tehnike osim što, umjesto jednodimenzionalnog histograma, ove tehnike generiraju

dvodimenzionalne histograme. Konceptualni prikaz ADTS tehnike prikazan je na slici 18. Poput AAH tehnika, prednost ADTS-a je da je njome moguće pratiti više vrsta optičkih oštećenja te su transparentne za brzine prijenosa podataka i vrste modulacije. Međutim, njihova implementacija je složenija od tehnika temeljenih na AAH.



Slika 18.: Konceptualni prikaz prikupljanja podataka ADTS tehnikom te konverzija u ADTP [17]

Amplituda električnog signala se nakon izravne detekcije asinkrono uzorkuje u parovima s poznatim konstantnim vremenskim odmakom između njih. Grupiranje parova uzoraka (p i q) u dvodimenzionalni histogram generira ADTP ili dijagram raspršenja, kao što je također prikazano na slici 14. ADTP prikazuje velik broj informacija, a njegove značajke ovise o formatu modulacije, brzini prijenosa podataka, vremenskom odmaku, kao i o raznim izobličenjima signala poput CD, PMD, itd. Međutim, važno je napomenuti da je ADTP prvenstveno grafički prikaz koji omogućuje kvalitativnu procjenu svojstava signala. Za izdvajanje kvantitativnih informacija iz ADTP-a potrebna je daljnja analiza pristupima kao što su statistička obrada umjetna inteligencija i strojno učenje. [32], [33]

4.2.3. Ostale tehnike asinkronog uzorkovanja


Uz prethodno navedene tehnike, postoji još nekoliko vrsta uzorkovanja koje su korisne u optičkim mrežama, a to su ASCS, ATTS i tehnike praćenja temeljene na empirijskim momentima.

U ASCS tehnici pravi se dvodimenzionalni dijagram raspršenja, prikupljanjem parova uzoraka amplitude signala koji je ekvivalentan ADTP-u. Složenost i troškovi implementacije ove tehnike niži su u odnosu na ADTS tehniku. [17]

4.3. Prikupljanje podataka u digitalnim koherentnim sustavima

Osnovna karakteristika digitalnih koherentnih sustava je upotreba polarizacijskog optičkog nosioca te napredne vrste modulacija, što omogućava brzine prijenosa veće od

100Gbit/s. Standardni digitalni koherentni prijemnik s blokovima algoritama za oporavak podataka prikazan je na slici 19.



Slika 19.: Shema standardnog koherentnog optičkog prijemnika s algoritmom za oporavak podataka [17]

Tehnološki napredak koji je donijela digitalna koherentna komunikacija utjecao je i na funkcionalnosti i istraživanja tehnika prikupljanja podataka. Primjerice, mnoge uobičajene tehnike prikupljanja prometa predložene za sustave izravne detekcije više nisu prikladne za digitalne koherentne sustave s vrlo uskim razmacima kanala, Nyquistovim oblikovanjem pulsa¹¹ i polarizacijskim multipleksiranjem. [17]

4.3.1. Prikupljanje podataka o disperziji

CD i PMD su linearna prijenosna izobličenja koja se mogu u potpunosti kompenzirati linearnim filtrima na prijemniku i mogu se jednostavno pratiti čitanjem postavki filtera. U digitalnim koherentnim sustavima, disperzija neće nužno pogoršati kvalitetu prijenosa kao u sustavima izravne detekcije, dok god se pravilno procjenjuje. Stoga, prikupljanje podataka nije

¹¹ Nyquistovo oblikovanje pulsa je tehnika u telekomunikacijama i digitalnoj obradi signala koja se koristi za minimiziranje međusobnog interferiranja između uzastopnih impulsa u sustavu za prijenos podataka. Ova tehnika omogućuje efikasniji prijenos podataka preko ograničenih frekvencijskih pojaseva, čime se povećava kapacitet kanala i smanjuje mogućnost pogrešaka u prijenosu.

previše bitno, ali je bitno predviđanje ovih parametara u prijemniku. Postoji nekoliko tehnika procjene disperzije bez skeniranja sustava, a jedan od primjera je tehnika neovisna o vrsti modulacije do 3000 ps/nm iz faze koherentno primljenog signala na četiri frekvencije. Drugi primjer je tehnika procjene disperzije temeljena na polinomskom prilagođavanju za digitalni koherentni optički sustav s jednim nosiocem, koja može procijeniti disperziju do 12800 ps/nm s točnošću boljom od 200 ps/nm. [17], [34]

4.3.2. Prikupljanje OSNR podataka

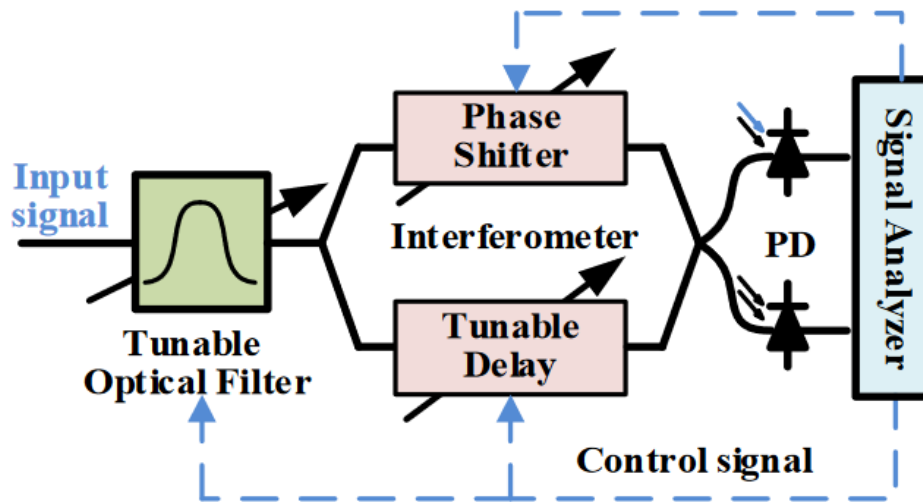
Budući da se sva linearna izobličenja mogu u potpunosti kompenzirati, performanse prijenosa uglavnom određuje OSNR i stoga je praćenje OSNR-a posebno važno za digitalne koherentne sustave. Prikupljanje OSNR podataka u ovim sustavima može se podijeliti na prikupljanje na digitalnom koherentnom prijammiku i na prikupljanje između čvorova.

Prikupljanje podataka na prijammiku najčešće se izvodi pomoću pilotskih tonova, koji se koriste za umetanje specifičnih frekvencija koje služe kao referentne točke za mjerenje različitih parametara mreže, ili pomoću posebno dizajniranih testnih signala koji se generiraju i šalju mrežom tako da ne ometaju stvaran protok podataka. Jedan od primjera takvog prikupljanja podatak je korištenje OSNR monitora s velikom tolerancijom na nelinearnosti, temeljen na odašiljanju pilotskog signala na strani predajnika zajedno s algoritmima digitalne obrade signala (engl. *digital signal processing*, DSP)¹². Kada nema nelinearnosti, spektar signala u periodu pilotskog signala sastoji se od jedne spektralne komponente koja označava šum pojačala te se tada lako može izmjeriti OSNR. Međutim, u prisutnosti nelinearnost, spektar će se proširiti i šum pojačala se neće moći lako izmjeriti iz spektralnih komponenti. U tom slučaju mogu se generirati kvadrurno-fazne modulacijske (engl. *Quadrature Phase Shift Keying*, QPSK) konstelacijske točke u sekvencama pilotskog tona, u smjeru kazaljke na satu i suprotno od kazaljke na satu u horizontalnim i vertikalnim polarizacijama. Takvim dizajnom, šum pojačala može se izolirati od nelinearnog šuma unutar i između kanala u frekvencijskoj domeni i koristiti za izračun OSNR-a. [35].

Drugi primjer prikupljanja podataka na prijammiku jest tehnika za mjerenje OSNR-a za sustave koji rade u linearnim i nelinearnim uvjetima, uzimajući u obzir nelinearno induciranu spektralnu deformaciju signala. Uspoređivanjem prenesenog optičkog spektra s deformiranim referentnim spektrom dobivenog na strani predajnika, OSNR se može dobiti čak i u nelinearnom režimu. [36]

Tipično prikupljanje OSNR podataka između čvorova temelji se na interferometru s odgođenom linijom (engl. *delay-line interferometer*, DLI) [37], što je prikazano na slici 20.

¹² DSP algoritam to je skup računalnih tehnika koje se koriste za analizu, obradu i poboljšanje kvalitete optičkih signala u mrežama.



Slika 20.: Prikupljanje OSNR podataka korištenjem DLI [17]

Budući da je signal koherentan i doživljava konstruktivnu i destruktivnu interferenciju u DLI-u, a buka unutar pojasa je nefunkcionalna i neosjetljiva na konstruktivnu i destruktivnu interferenciju, omjer razdvajanja snage između signala i buke između priključaka DLI-a različit je. Stoga, mjerenjem optičke snage konstruktivnih i destruktivnih izlaznih priključaka pomoću fotodioda, može se odrediti snaga povezana sa signalom i bukom te se tako dobiva OSNR.

Prema [17] OSNR u digitalnim koherentnim sustavima može se izračunati formulom (2):

$$\text{OSNR (dB)} = 10 \log_{10} \left(\frac{(\alpha+1) \times (\delta-\beta)}{(\beta+1) \times (\alpha-\beta)} \times \frac{NEB}{0.1nm} \right) \quad (2)$$

U gornjoj formuli, α , β i δ predstavljaju faktore distribucije signala, buke i kanala pod testom, redom, a NEB se definira kao ekvivalentna širina pojasa za filter. [17]


5. Metode predviđanja prometa u optičkim mrežama

Primjena strojnog učenja u optičkim mrežama može se povezati s pojavom i sve većom popularnošću umjetne inteligencije. Dok se umjetna inteligencija usredotočuje na stvaranje „pametnih“ strojeva, strojno učenje je grana umjetne inteligencije koja nastoji strojeve učiniti pametnijima kroz tzv. „učenje“, odnosno „treniranje“ povijesnim podacima [38]. U skladu s razvojem računalnih tehnologija, povećanjem složenosti sustava i dostupnosti podataka, umjetna inteligencija putem metoda strojnog učenja postala je efikasno rješenje za optičke mreže zbog brzih brzina obrade i fleksibilnosti kroz automatizirano donošenje odluka. [39]

Paralelno s podacima generiranim iz fizičke opreme, opreme za praćenje i SDON-ova, postoji i stalno rastuća količina povijesnih podataka i stručnog znanja, a sve te informacije mogu se koristiti kako bi se kvalitetnije podesili uređaji strojnog učenja za buduća predviđanja. Primjerice, dugoročnim povijesnim podacima moguće je podesiti uređaje strojnog učenja za filtriranje šuma, jer mogu uspoređivati trenutačne promjene s povijesnim promjenama u stanju signala [40], [41]. Još jedna motivacija za upotrebu strojnog učenja može biti smanjenje vremena potrebnog za ručnu kalibraciju mreže, a taj proces može smanjiti potrebu za računalnim procesima u stvarnom vremenu na mreži i smanjiti troškove, osiguravajući pritom da usluga na mreži u stvarnom vremenu ne bude ugrožena [42].

5.1. Neuronske mreže

Neuronske mreže (engl. *neural networks*, NN) su algoritmi strojnog učenja koji se koriste za rješavanje problema metodom obrade podataka, a funkcioniraju na način na koji funkcioniraju i moždane stanice u ljudskom mozgu. Opći model neuronske mreže, prikazan na slici 21., a sastoji se od 3 sloja: ulaznog sloja, izlaznog sloja te dva skrivena sloja. Prvi sloj sastoji se od ulaznih neurona. Ti neuroni šalju podatke skrivenim slojevima, koji zauzvrat šalju konačne izlazne podatke posljednjem izlaznom sloju. Skriveni sloj se sam može sastojati od više slojeva i u njemu se mogu koristiti različiti algoritmi kojima se obrađuju podaci. Ulazni podaci se mrežom kreću kroz niz različitih, međusobno povezanih čvorova pri čemu se svaki čvor ispočetka ponderira i preračunava. [43]



Slika 21.: Opći model neuronske mreže s dva skrivena sloja [43]

Neuronske mreže koriste povijesne podatke ili trening podatke za učenje i poboljšavanje svoje točnosti tijekom vremena, a te informacije se unutar neuronskih mreža vrjednuju po internom sustavu. U fazi nadziranog učenja, kada je izlaz označen kao pogreška, informacija se šalje natrag u model te se prema tome ažurira proporcionalno tome koliko je bila odgovorna za pogrešku. Na taj način se pogreška koristi za ponovno kalibriranje čvorova neuronske mreže kako bi se uzela u obzir razlika između željenog i stvarnog rezultata. Tako se, s vremenom, minimizira mogućnost pogrešaka i neželjenih rezultata. Kada se dovoljnom količinom povijesnih podataka podese zadovoljavajuća razina točnosti, neuronske mreže postaju moćan alat za obradu podataka velikom brzinom, a u mrežnom okruženju vrlo su korisne kod predviđanja prometa. Mogu se koristiti za mnoge praktične primjene, kao što su prediktivna analiza u poslovanju, detekcija neželjene pošte, obrada prirodnog jezika itd. [44]

Postoji nekoliko primjera izvedbi neuronskih mreža, kao npr.:

- Unaprijedne neuronske mreže - jedna od najjednostavnijih varijanti neuronskih mreža koje prenose informacije u jednom smjeru, kroz razne ulazne čvorove, sve dok ne stignu do izlaznog čvora. Mreža može ili ne mora imati skrivene slojeve, što ih čini jednostavnijima za implementaciju.
- Rekurentne neuronske mreže (engl. recurrent neural networks, RNN) – složenije su izvedbe, a funkcioniraju tako da spremaju izlazne vrijednosti čvorova i ponovno unose rezultat u model. RNN model uči predviđati ishod sloja, a svaki čvor modela djeluje kao memorijska ćelija, nastavljajući proračun i izvršavanje operacija. Ova neuronska mreža


započinje s istim unaprijednim širenjem kao unaprijedna mreža, ali zatim pamti sve obrađene informacije kako bi ih ponovno koristila u budućnosti. Ako je predikcija mreže netočna, sustav se sam uči i nastavlja raditi prema točnoj predikciji.

- Dugoročno-kratkoročna memorija (engl. *long short-term memory, LSTM*) – dio su rekurentnih neuronskih mreža koje koriste LSTM blokove kako bi dobile podatke o načinu na koji program prima ulaze i stvara izlaze.
- Konvolucijske neuronske mreže (engl. *convolutional neural networks, CNN*) - jedan su od najpopularnijih modela danas, a koriste varijaciju višeslojnih perceptrona¹³ i sadrže jedan ili više konvolucijskih slojeva koji mogu biti potpuno povezani. Koristi se u mnogim najnaprednijim primjenama umjetne inteligencije, uključujući prepoznavanje lica, digitalizaciju teksta i obradu prirodnog jezika.
- Dekonvolucijske neuronske mreže - koriste obrnut proces CNN modela. Pokušavaju pronaći izgubljene značajke ili signale koji su izvorno smatrani nebitnima za zadatak CNN sustava.
- Modularne neuronske mreže - ove mreže sadrže više neuronskih mreža koje rade odvojeno jedna od druge i ne komuniciraju niti ometaju aktivnosti drugih tijekom procesa izračuna. Posljedično, složeni ili veliki računalni procesi mogu se izvoditi učinkovitije. [44]

5.2. Potporni vektori

Potporni vektori (engl. *support vector machine, SVM*) su algoritam strojnog učenja koji se koristi za klasifikaciju neoznačenih prikupljenih podataka u dvije označene kategorije, odnosno za razdvajanje skupa podataka u jasno definirane binarne grupe [45]. Ovom metodom izvodi se kompleksna transformacija podataka ovisno o odabranoj jezgri funkcije i , na temelju tih transformacija, nastoje se maksimizirati granice razdvajanja između podataka ovisno o prethodno definiranim oznakama ili klasama. Potporni vektori se široko koriste u disciplinama poput zdravstva, obrade signala te u područjima prepoznavanja govora i slika. [43] Grafikon 2. prikazuje skup podataka klasificiran u klasu 1 (zelena) i klasu 2 (plava).

¹³ Perceptron je osnovna jedinica neuronske mreže, koja se koristi kao model za binarnu klasifikaciju. Radi se o jednostavnom linearnom klasifikatoru koji donosi odluke na temelju skupa ulaznih značajki.



Grafikon 2.: Podjela podatak u dvije klase metodom potpornih vektora [43]

Metodom potpornih vektora nastoji se definirati linija koja maksimizira razdvajanje između dvije klase podataka u dvodimenzionalnom prostoru. Pomoću definirane linije određuje se ravnina, a podaci s najmanjom udaljenošću od te ravnine zovu se potporni vektori. Izračun razdvajanja podataka ovisi o jezgrenoj funkciji koja može biti polinomna, Gaussova itd. Funkcija pojednostavljuje granicu razdvajanja podataka za nelinearne probleme dodavanjem više dimenzija kako bi se mapirali složeniji podaci, a tijekom tog procesa, podaci nisu potpuno transformirani jer to može biti računalno zahtjevan proces. Ideju iza SVM algoritma prvi su put predstavili Vladimir N. Vapnik i Alexey Ya. Chervonenkis 1963. godine. Potporni vektori mogu se klasificirati u dva tipa, a to su linearni i nelinearni.


Linearni potporni vektori odnose se na tip SVM-a koji se koristi za klasifikaciju linearno razdvojivih podataka, što znači da se skup podataka može razdvojiti u kategorije ili klase pomoću jedne ravne linije. Osim toga, klasifikator koji klasificira takve podatke naziva se linearnim SVM klasifikatorom. Linearni potporni vektori tipično se koriste za rješavanje problema klasifikacije i regresijske analize.

Nelinearni podaci, koji se ne mogu razdvojiti u različite kategorije pomoću ravne linije, klasificiraju se pomoću nelinearnog potpornog vektora, kod kojeg se klasifikator naziva nelinearnim klasifikatorom. Klasifikacija se može izvesti s nelinearnim tipom podataka dodavanjem značajki u više dimenzija umjesto oslanjanja na 2D prostor. Ovdje se novo dodane značajke svrstavaju u hiperplohu koja pomaže u jednostavnom razdvajanju klasa ili kategorija. Nelinearni potporni vektori se obično koriste za rješavanje optimizacijskih problema koji imaju više varijabli. [43], [45], [46]

5.3. Analiza glavnih komponentata

Analiza glavnih komponentata (engl. *principal component analysis*, PCA) je tehnika koja se koristi za identifikaciju manjeg broja nepovezanih varijabli, poznatih kao glavne komponente, iz većeg skupa podataka. Odnosno, to je metoda manipulacije ili redukcije kojom se smanjuje količina promatranih podataka, dok se istovremeno količina izgubljenih informacija svodi na minimum. Analiza se provodi na način da se početne varijable ortogonalnom transformacijom transformiraju u novi skup varijabli nazvanih glavne komponente. Glavne komponente se zatim poredaju, a rezultat toga je da početne varijable zadržavaju veći dio informacija. Dijagram analize glavnih komponentata s dvije glavne komponente prikazan je na grafikonu 3.

Jedna od posebnih prednosti povezanih s analizom glavnih komponenti je podržavanje kompresije podataka nakon pronalaska obrazaca u relevantnim podacima. To je korisno za smanjenje broja varijabli ili za izbjegavanje multikolinearnosti. [43]



Grafikon 3.: Raspodjelni dijagram koji prikazuje primjer analize glavnih komponentata generirajući dvije glavne komponente [43]

Osim svoje jednostavnosti i estetske razumljivosti, ova analiza također ima prednosti u analizi podataka te mnoštvu drugih djelatnosti kao što su kompresija slika, prepoznavanje lica, neuroznanost, računalna grafika itd. Fokuseranjem na ključne parametre pospješuje se učinkovitost i kvaliteta rezultata jer prekomjerni podaci koji ne utječu na ponašanje modela mogu uzrokovati šum i činiti analizu manje učinkovitom. [47]

PCA se tipično izvodi kroz pet glavnih koraka, a to su:


1. **Standardizacija** - Cilj ovog koraka je standardizacija raspona kontinuiranih početnih varijabli tako da svaka od njih jednako doprinosi analizi

2. Izračun kovarijacijske matrice – U ovom koraku nastoji se razumjeti kako se varijable ulaznog skupa podataka razlikuju u odnosu jedna na drugu. Odnosno, vidjeti postoji li kakva veza među njima, jer se ponekad varijable korelirane tako da sadrže suvišne informacije.
3. Izračun vrijednosti iz matrica za određivanje glavnih komponenata - Eigenvektori i eigenvrijednosti su linearni algebarski koncepti koje je potrebno izračunati iz kovarijacijske matrice kako bi se odredile glavne komponente podataka. Rangiranjem eigenvektora prema njihovim eigenvrijednostima, od najviše do najniže, dobivaju se glavne komponente.
4. Stvaranje značajki vektora - U ovom koraku određuje se hoće li se zadržati sve komponente ili odbaciti one manje značajne (s niskim eigenvrijednostima), te s preostalima formirati matricu vektora koja se naziva vektor značajki.
5. Preoblikovanje podataka duž osi glavnih komponenata - U ovom koraku cilj je koristiti vektor značajki kako bi se ponovno usmjerili podaci s originalnih osi na one predstavljene glavnim komponentama. [48]

5.4. Statistički modeli

Statistički modeli imaju ključnu ulogu u predviđanju prometa i upravljanju optičkim mrežama. Poissonov model, Gaussov model, Markovljev model i dr. pružaju jedinstvene prednosti i dolaze s određenim ograničenjima, a odabir najprikladnijeg modela ovisi o specifičnim karakteristikama prometa i zahtjevima mreže. Dok statistički modeli mogu pružiti vrijedne uvide, uvijek je važno kombinirati ih s detaljnim poznavanjem mrežne infrastrukture i prometnih uzoraka za najbolje rezultate. [43]

Markovljev model predviđa promet na temelju stanja sistema i vjerojatnosti prijelaza između tih stanja. Ovi modeli su posebno korisni u optičkim mrežama za modeliranje prometnih uzoraka koji pokazuju ovisnosti o prethodnim stanjima, kao što su uzorci pristupa aplikacijama ili korisničkog ponašanja. Markovljevi lanci omogućavaju detaljno modeliranje i analizu prometnih uzoraka, uključujući predviđanje zagušenja i optimizaciju alokacije resursa. Međutim, složenost modela može eksponencijalno rasti s povećanjem broja stanja, što može otežati njegovu praktičnu primjenu. [49] Vizualni prikaz Markovljevog modela prikazan je na slici 22.




Slika 22.: Primjer vizualnog prikaza Markovljevog modela [50]

Poissonov model je jedan od najstarijih i najčešće korištenih modela za predviđanje prometa u telekomunikacijama, uključujući i optičke mreže. Temelji se na pretpostavci da su dolasci zahtjeva (npr., broj paketa podataka) slučajni i neovisni događaji koji se događaju s konstantnom prosječnom stopom. Iako Poissonov model može biti efikasan za predviđanje ukupnog volumena prometa u mrežama s niskom do srednje visokom upotrebom, on često ne uspijeva točno modelirati promet u vršnim satima ili u mrežama s visokom prometnom varijabilnošću zbog svoje pretpostavke o neovisnosti događaja. [51]

Gaussov model (ili normalna distribucija) primjenjuje se kada se prometne karakteristike distribuiraju simetrično oko srednje vrijednosti. Ovaj model je koristan za analizu prometa koji pokazuje predvidljive uzorke varijabilnosti i može se koristiti za procjenu vjerojatnosti odstupanja od prosječnog prometa. Gaussov model je posebno koristan za mreže s velikim količinama prometa, gdje centralni granični teorem omogućuje prijelaz iz Poissonove distribucije u normalnu distribuciju. Ipak, ograničenje ovog modela leži u pretpostavci simetrije, što može biti nerealno za optičke mreže. [52]

5.5. Linearna regresija

Linearna regresija je uobičajena tehnika koja se koristi u statističkoj analizi za pronalaženje i procjenu odnosa između dva ili više skupova varijabli, bez obzira na to kako su raspoređene. Varijable za regresijsku analizu moraju sadržavati isti broj opažanja, ali mogu imati bilo koju veličinu ili sadržaj. Odnosno, nema ograničenja za provođenje regresijske analize samo nad skalarnim varijablama, već se mogu koristiti i kategoričke varijable. [43] Grafikon 4. prikazuje dijagram raspršenja s linearnom linijom.



Grafikon 4.: Prikaz dijagrama linijske regresije [43]

Od ovih varijabli, jedna se naziva zavisna varijabla, a pretpostavka je da sve ostale varijable nose naziv nezavisne varijable i da postoji uzročna veza između nezavisnih i zavisne varijable. Nezavisna varijabla je prediktor ili objašnjavajuća varijabla koja ostaje nepromijenjena zbog promjene drugih varijabli, a zavisna se varijabla mijenja s fluktuacijama nezavisne varijable. Regresijski model predviđa vrijednost analizirane zavisne varijable, pa je zato linearna regresija algoritam nadziranog učenja koji simulira matematičku vezu između varijabli i daje predviđanja za kontinuirane ili numeričke varijable. Model linearne regresije također se može učinkovito trenirati na normaliziranim i standardiziranim skupovima podataka. U tom slučaju, ovaj model može se koristiti za predviđanje ishoda za testni skup i mjerenje raznih parametara. [43], [53]

6. Analiza metoda/tehnika predviđanja prometa

Postoji mnogo dostupnih istraživanja koja se bave ispitivanjem prometa na komunikacijskim mrežama korištenjem metoda strojnog učenja. Također, velik dio tih istraživanja ima fokus na optičkim mrežama te daje važnost predviđanju prometa. U istraživanjima se testiraju razne metode i tehnike, a većina tih tehnika se oslanja na značajnu količinu prikupljanja podataka u stvarnom vremenu. Pretpostavlja se da su mrežni uređaji opremljeni za prikupljanje podataka, koji se potom analiziraju različitim algoritmima i metodama za predviđanje prometnih parametara i kvarova u optičkim mrežama.

6.1. Predviđanje prometa korištenjem NN


U istraživanjima [54], [55] koriste se skupovi podataka o serijama promet u vremenu dobiveni od pružatelja mrežnih usluga u kombinaciji s metodologijom dugoročno-kratkoročne memorije i RNN, za predviđanje mrežnog prometa u vremenskim razdobljima od 5 minuta i 1 sat, gdje RNN mreža sadrži povratnu petlju u skrivenom sloju koja pamti rezultate prethodnog vremena. Problem s RNN-om je da se njegova memorija s vremenom degradira, što se naziva nestajanje gradijenata te stoga nije prikladna za predviđanje dugoročnih podatkovnih ovisnosti, uključujući i autokorelaciju. LSTM je varijanta RNN-a koja smanjuje ovaj problem tako što svaka neuronska ćelija sadrži dodatne memorijske jedinice, čuvajući stanja ćelija kroz duže periode ili zaboravljajući informacije koje se smatraju neprimjenjivima. U ovom primjeru, LSTM se koristi za predviđanje autokorelacije tako da se podaci prvo propuštaju kroz LSTM neuronsku mrežu, a izlaz se zatim propušta kroz standardnu duboku neuronsku mrežu (engl. *deep neural network*, DNN). Jedan nedostatak korištenja LSTM modela je duži vremenski period potreban za treniranje modela, odnosno potrebno je više iteracija treninga prije nego model može točno predvidjeti mrežni promet.

U istraživanju [56] koristi se neuronska mreža s propagacijom unazad (engl. *backpropagation neural network*, BPNN) za predviđanje budućih veza u elastičnoj optičkoj mreži kako bi se postigle bolje performanse povećanjem *bandwidth*-a i smanjenjem vjerojatnosti blokiranja. BPNN se koristi za predviđanje vremena dolaska podataka i vremena zadržavanja budućih veza u mreži. U ovom primjeru se ove vrijednosti u radu nazivaju „buduće veze“, a „dodijeljene veze“ su veze u kojima su vrijeme dolaska i vrijeme zadržavanja poznati jer su spektralni resursi unaprijed određeni duž određenog puta. Algoritam minimalne sveobuhvatne težine (engl. *minimum comprehensive weight algorithm*, MCW) predviđa buduće vrijednosti vremena dolaska i zadržavanja na mrežnim putevima, dok se druge strane, algoritam minimalne mrežne konkurencije (engl. *minimum network competition algorithm*, MNC) koristi za izračunavanje konkurencije resursa za sve mrežne puteve koji se zatim uspoređuju, a optimalan put je onaj s najmanjom konkurencijom i s najmanjom vjerojatnošću blokiranja. Studija je pokazala da MCW postiže bolje rezultate od drugih algoritama u performansama elastične optičke mreže.

U istraživanju [57] Također se predlaže generativna suparnička mreža s grafičkom konvolucijom za predviđanje skokova prometa u kratkom i dugačkom vremenskom periodu. mreža s grafičkom konvolucijom (engl. *graph convolution network*, GCN) bilježi topološko stanje mreže, a generativna suparnička mreža (engl. *generative adversarial network*, GAN) koristi za predviđanje budućih naglih porasta prometa, dok se jednostavna unaprijedna neuronska mreža koristi se za predviđanje najvjerojatnijeg budućeg stanja mreže. Jednotjedni prikazi mreže korišteni su u GCN-GAN modelu za rješavanje problema kratkoročnog predviđanja, dok su tromjesečni prikazi korišteni za dugoročno predviđanje. U modelu su se koristili stvarni prometni podaci iz *Telus Fiber Network*¹⁴, a rezultati su pokazali da je GCN-GAN model bio učinkovitiji u predviđanju naglih porasta prometa u usporedbi s LSTM modelom u smislu nižih vrijednosti srednje kvadratne pogreške i nižeg precjenjivanja količine prometa.

U istraživanju [58], prikazano je istraživanje predviđanja prometa stvarne optičke mreže u zapadnom dijelu Kine, između gradova Peking, Nanjing, Guangzhou, Chengdu, Shanghai, Xian, Wuhan i Tianjin. Definiran problem vremenskih i prostornih autokorelacija prometa između čvorova optičke mreže koristeći usmjereni graf čiji čvorovi su mrežni usmjernici, a rubovi označavaju veze među čvorovima optičke mreže. Istraživanje je provedeno neuronskom mrežom, metodom grafičke konvolucijske mreže s kontroliranim rekurentnim blokom (engl. *Graph Convolutional Network with the Gated Recurrent Unit*, GCN-GRU), gdje GCN koristi grafički prikaz za učenje o međuovisnostima čvorova, a GRU se koristi za prikupljanje uzoraka prometa u određenom vremenskom periodu. Prikaz arhitekture GCN-GRU modela koji se koristio u svrhu ovog istraživanja prikazan je na slici 23.

¹⁴ *Telus Fiber Network* je optička mreža koju implementira telekomunikacijska tvrtka Telus.



Slika 23.: Prikaz GCN-GRU arhitekture [58]

Model je evaluiran stvarnim skupom podataka s okosnice optičke mreže, odnosno s 34 optička vlakna u razdoblju od 4. rujna 2018. do 11. rujna 2018., a istraživanje je rezultiralo točnošću predviđanja od 98 %.

U istraživanju [59] predlaže se algoritam za upravljanje optičkim putevima s fokusom na potrošnju energije (engl. *power-aware lightpath management*, PALM) kako bi se smanjila potrošnja energije prilikom pucanja i ponovnog uspostavljanja optičkih puteva, jer uspostavljanje optičkih puteva u elastičnim optičkim mrežama može činiti 15 % ukupne potrošnje energije. Modul za predviđanje prometa integriran je s EON, a sastoji se od BPNN uz dodatak algoritma optimizacije rojem čestica (engl. *particle swarm optimization*, PSO) za određivanje početnih ulaznih vrijednosti. PSO algoritam radi tako da najprije inicijalizira nasumične vrijednosti za svaki ulazni parametar, a svaka čestica ima vrijednost brzine pridruženu sebi i pamti svoju prethodnu najbolju brzinu. Sa svakom iteracijom, vrijednost brzine se ažurira kako bi se kretala prema boljoj vrijednosti uzimajući u obzir svoju prethodnu najbolju, a ovaj proces se ponavlja sve dok se ne utvrdi optimalna vrijednost brzine kao ulaz za BPNN. PALM algoritam ovisi o izlaznim vrijednostima predviđanja iz PSO i BPNN-a kako bi se odredilo hoće li se optički put ostaviti otvorenim ili preusmjeriti zahtjev za prometom na određeni neaktivni optički put. Simulirani rezultati pokazuju da PSO-BPNN pri pragu iskorištenosti optičkog puta od 80 % ima 31–36 % poboljšanje u smanjenju potrošnje energije u usporedbi s energetski učinkovitim *manycastom* (engl. *energy-efficient anycast*, EEM) algoritmom tijekom jednog mjeseca. PALM je uspješan u značajnom smanjenju potrošnje energije u EON-ima, međutim, u tom slučaju se povećava omjer blokiranja propusnosti za 5 %.

U istraživanju [60] uspoređuju se i procjenjuju različite izvedbe rekurentnih neuronskih mreža za predviđanje mrežnog prometa na GEANT¹⁵ okosnici optičke mreže. Testiranja su bila rađena na izvedbama LSTM, unaprijednih neuronskih mreža, jedinicom s povratnim petljama (engl. *gated recurrent unit*, GRU) i identifikacijskom rekurentnom neuronskom mrežom (engl. *identify recurrent neural network*, IRNN). U stvarnim mrežnim skupovima podataka, LSTM je pokazao bolje rezultate u usporedbi s drugim izvedbama neuronskih mreža, međutim, performanse GRU i IRNN tehnika su usporedive s LSTM-om. Štoviše, GRU mreža imala je niže računalne troškove u usporedbi s LSTM mrežama. Zaključno, sve metode rekurentnih neuronskih mreža su pokazale zadovoljavajuću preciznost predviđanja prometa optičke mreže.

U istraživanju [61] želi se ostvariti kašnjenje od približno jedne ms te energetska učinkovitost u jedinici optičke mreže (ONU) na način da je razvijena metoda predviđanja *bandwidth*-a koja se temelji na LSTM metodi. Predloženom shemom se predviđaju zahtjevi za propusnošću u oba smjera za svaki ONU te se određuje redosljed i vrijeme početka prijenosa za svaki ONU na temelju predviđenih zahtjeva za *bandwidth* i kašnjenje. Na taj način, predložena shema minimizira gubitak *bandwidth*-a mreže kao i ukupno vrijeme rada svakog ONU-a te se stoga postiže niska latencija i smanjuje se potrošnja energije, jer se produžuje vrijeme mirovanja. Rezultati simulacija pokazuju da predložena shema može smanjiti prosječno kašnjenje paketa u jednom smjeru za najmanje 28,9 % i može smanjiti potrošnju energije po bitu za 73,7 % kada se radi o prijenosu podataka pod uvjetom latencije od 1 ms.

U istraživanju [62] predložena je metoda temeljena na neuronskim mrežama za brzo i precizno predviđanje spektralne snage duž vlakna, u svrhu procijene QoT. Kako bi se zadovoljili zahtjevi brzine i efikasno predvidjela snaga s obzirom na frekvenciju i udaljenost prijenosa, predlažu se tri različite umjetne neuronske mreže (engl. *artificial neural network*, ANN) uzimajući u obzir više scenarija. Testiranja uključuju scenarije različite vrijednosti snage po kanalu, različite vrste vlakana i različite duljine vodova. Dva ANN-a koriste sintetičke podatke kod modeliranja sustava kako bi procijenile utjecaj linearnih i nelinearnih oštećenja vlakna. Konkretno, jedna verzija ANN-a se koristi za predviđanje promjene spektralnih profila snage duž vlakna, dok se druga verzija ANN-a koristi za procjenu koeficijenata koji se kasnije učitavaju u zatvoreni matematički model. Treća verzija ANN-a radi na eksperimentalnim podacima i koristi se za predviđanje profila snage na kraju vlakna, a ti se podaci tada koriste za brze procjene performansi sustava. Dobiveni rezultati izračunati između predviđenih i stvarnih profila snage pokazuju izuzetno točna predviđanja koja ne prelaze 0,2 dB za otprilike 97 % slučajeva za sintetičke podatke i uvijek su ispod 0,5 dB za eksperimentalne podatke. Takvi rezultati dokazuju potencijal predloženog pristupa čineći ga pogodnim za primjenu u stvarnom vremenu procjene QoT-a.

¹⁵ paneuropska istraživačka i obrazovna mreža koja povezuje nacionalne istraživačke i obrazovne mreže diljem Europe.

U istraživanju [63] predložen je analizator dijagram oka (engl. *eye diagram*)¹⁶ koji može procijeniti Q faktor i duljinu veze nakon obrade slika, a temelji se na više varijanti konvolucijskih neuronskih mreža koje se u ovom istraživanju i uspoređuju. CNN modeli korišteni za dijagram oka testiraju se na nekoliko modulacijskih formata, a performanse ovih modela procjenjuju se u smislu točnosti, srednje kvadratne pogreške i tolerancije na pogreške. CNN modeli su pokazali zadovoljavajuću preciznost predviđanja, dok su najbolji rezultati pokazali vrijednost srednje kvadratne pogreške od 0.00188 i 0.00036. Donesen je zaključak da ovaj analizator dijagrama oka temeljen na CNN može biti obećavajući pristup za analizu i optimizaciju optičkih komunikacijskih sustava bez ljudske intervencije.

U istraživanju [64] predložena je ANN metoda za predviđanje QoT za velike optičke mreže između podatkovnih centara te je ta metoda zatim uspoređena s dva druga analitička modela koji procjenjuju podatke temeljene na šumu pojačala, nelinearnosti i distorziji pretvarača. Model je testiran s 200000 nasumičnih skupova podataka, s brzinama prijenosa od 200, 400, 600 i 800 Gb/s i osam tipova pretvarača, a predviđali su se parametri BER i OSNR. Rezultati su pokazali da je postignuta standardna devijacija pogreške procjene QoT-a od 0,3 dB, što nadmašuje analitičke modele. Također je dokazana i demonstrirana korisnost ANN modela i kod prebacivanja optičkih puteva koji su česti za ovakav tip optičkih mreža.

6.2. Predviđanje prometa korištenjem SVM

U radu [65] je provedeno istraživanje metodom potpornih vektora koji su trenirani s prethodnim podacima u simulacijama izvan mreže kako bi predvidjeli kvalitetu prijenosa u optičkim mrežama. Za izvan mrežno testiranje korišteni su podaci iz 14 čvorova *Deutsche Telekom* optičke mreže, a u obzir su uzete 32 i 64 valne duljine po linku, dok se sam SVM izračun odradio u programskom alatu MATLAB. Za istraživanje je razvijen procjenitelj kvalitete prijenosa koji klasificira svjetlosne putove u kategorije visoke i niske kvalitete na temelju praga Q-faktora definiranog od strane korisnika. Konkretno, ovaj prag je postavljen na 16,9 dB, što odgovara razini BER od 10^{-12} , dakle, svjetlosni putovi označeni vrijednošću Q-faktora iznad praga, tj. s niskim BER-om, smatraju se da zadovoljavaju zahtjeve kvalitete, dok se oni ispod praga smatraju neodrživim svjetlosnim putovima. Tako prikupljene vrijednosti prikupljene u različitim trenucima i s različitim opterećenjima mrežnog prometa, sastoje se od skupova atributa koji opisuju svjetlosni put i njihovih pridruženih Q-faktora. Konkretno, opis svjetlosnog puta sadrži izvorne i odredišne čvorove, skup linkova koje prelazi, odgovarajuću valnu duljinu i ukupnu duljinu. U početku se provodi faza treniranja gdje se različiti podskupovi podataka koji pripadaju području nesigurnosti unose u SVM modul, a zatim se provodi proces unakrsne validacije s 10 presjeka kako bi se temeljito okarakterizirala očekivana izvedba tako konstruiranog modela. Jednom kada je model izgrađen i okarakteriziran, performanse sustava se testiraju s različitim novim podskupovima podataka, a utvrđeno je da takav pristup rezultira

¹⁶ Dijagram oka je grafički alat koji se koristi za procjenu kvalitete optičkih signala, a dobiva se prikazivanjem prijemnog optičkog signala na specijaliziranom analizatoru. Signal se ponavlja kroz više perioda i prikazuje se na način da se svi periodi preklapaju, stvarajući oblik koji podsjeća na ljudsko oko.

točnošću od 99.95 % u klasifikaciji svjetlosnih puteva te znatno smanjuje vrijeme potrebno za izračun.


U istraživanju [66] predlaže se tehnika višefunkcionalne optičke spektralne analize temeljena na strojnome učenju koja uz obavljanje konvencionalnih analitičkih funkcija, obavlja i proširene analitičke funkcije, uključujući detekciju središnje valne duljine, izračun OSNR-a, prepoznavanje širine pojasa te dijagnozu spektralne distorzije¹⁷. Za ovu svrhu testirana su i uspoređena četiri algoritma strojnog učenja uključujući SVM, neuronske mreže i statističke modele. U prvom su se testu obrađivale valne duljine, OSNR i širine pojasa optičkih signala temeljene na spektralnim podacima, pomoću četiri metode strojnog učenja. Rezultati su pokazali da je SVM metoda postigla najbolje performanse, postigavši optimalnu točnost od 100 % i najmanje vrijeme testiranja, ispod 0,34 s. Za potrebe praktične primjene istražen je i složeniji slučaj, gdje su valna duljina, OSNR i širina pojasa istovremeno promjenjivi. Čak i u ovom slučaju, ukupna točnost SVM metode je i dalje veća od 99,1 %, a vrijeme izračuna je bilo 0,776 s. Osim toga, proučavane su i proširene analitičke funkcije za dijagnosticiranje spektralne distorzije uzrokovane efektom kaskadnog filtriranja¹⁸ i efektom pomaknutog filtriranja¹⁹. Navedeni parametri mogu se također efikasno procijeniti pomoću SVM metode s visokom prosječnom točnošću i niskom standardnom devijacijom, što je korisno za otkrivanje kvarova i oporavak od distorzije. Zaključeno je da ova tehnika ima potencijal za primjenu u optičkom spektrometru za provedbu višefunkcionalne spektralne analize ili u optičkom monitoru performansi za izvršavanje dijagnoze spektralne distorzije.

U istraživanju [67] predložena je shema predviđanja kvarova u SDON mrežama temeljena na LSTM i SVM metodama. LSTM se koristi za predviđanje parametara optičke mreže, a zatim se SVM metodom predviđa hoće li doći do kvara mreže. Dijagram arhitekture predložene sheme prikazan je na slici 24., a funkcionira na način da SDON kontroler prikuplja podatke iz optičke mreže u stvarnom vremenu te na temelju rezultata predviđanja, kada se predvidi kvar, SDON kontroler šalje upute za promjene usmjeravanja kako bi se izbjegli kvarovi.

¹⁷ Distorzija je pojava kada se izvorni signal mijenja ili izobličuje tijekom prijenosa kroz mrežu.

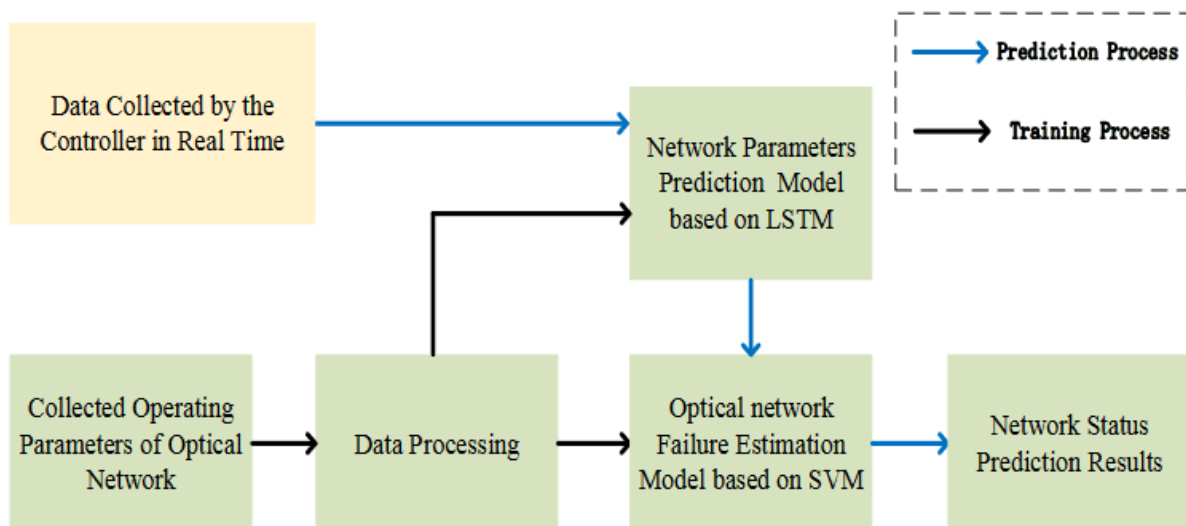
¹⁸ Kaskadno filtriranje odnosi se na propuštanje signala kroz više optičkih filtara zbog čega može doći do kumulativnih efekata koji mijenjaju karakteristike signala.

¹⁹ Pomaknuto filtriranje se odnosi na situaciju kada je središnja frekvencija filtra neusklađena s frekvencijom signala.



Slika 24. Arhitektura sheme predviđanja LSTM/SVM modelom u SDON mreži [67]

Slika 25. prikazuje tijek rada modela za predviđanje kvarova, gdje crna strelica predstavlja proces treniranja, a plava strelica proces predviđanja.



Slika 25. Tijek predviđanja LSTM/SVM modela u SDON mreži [67]

U procesu treniranja prvo se prikupljeni podaci iz optičke mreže prethodno obrađuju, a zatim se predaju LSTM-u i SVM-u za treniranje. Za izračun se koriste razni parametri kao što su

OSNR, ulazna snaga, izlazna snaga itd., a u predloženom mehanizmu LSTM modeli su trenirani za svaku značajku, dok je skup podataka podijeljen na skup za treniranje i testiranje. U SVM modelu korištene su metode pretraživanja mreže²⁰ i desetostruke unakrsne validacije²¹ kako bi se odredili optimalni parametri, kao što je funkcija jezgre. Rezultati istraživanja su pokazali učinkovitost ove metode s točnošću predviđanja do 90,63 %.

U istraživanju [68] predložen je model za predviđanje stupnja zagušenja optičke mreže temeljen na SVM. Budući da *bandwidth* određuje stupanj zagušenja mreže, ovaj rad klasificira stupanj zagušenja mreže u tri kategorije prema prosječnoj iskorištenosti propusnosti linkova. SVM model je za simulaciju koristio podatke o veličini *bandwidth*-a za svaku uslugu, trajanju svake usluge, izvornom čvoru i odredišnom čvoru, a simulacija je simulirala dinamički promet dvije okosnice optičke mreže. Rezultati simulacije su pokazali da preciznost klasifikacije može doseći 97,8 % te je zaključeno da model za predviđanje zagušenja optičke mreže temeljen na SVM-u pruža dobru strategiju za upravljanjem i planiranjem optičke mreže, alokacijom resursa i poboljšanjem kvalitete usluge.

6.3. Predviđanje prometa korištenjem PCA

U istraživanju [69] koristi se umjetna neuronska mreža s osam ulaznih parametara za procjenu performansi u optičkim mrežama s usmjeravanjem po valnim duljinama (engl. *wavelength-routed optical networks*, WRON). Ovaj pristup se razlikuje od drugih metodologija s neuronskim mrežama tako što se uključuje ulazni parametar fizičkog sloja u neuronsku mrežu, a svrha metodologije je pružiti brz i jednostavan način za procjenu vjerojatnosti blokiranja u WRON-ovima uzimajući u obzir fizička oštećenja. Nezavisne varijable povezane s fizičkim slojem i topološkim svojstvima WRON-a određene su analizom glavnih komponenta koja je provedena kako bi se generalizirale i identificirale varijable koje bi olakšale treniranje modela i omogućile njegovu uporabu u različitim mrežama. Najbolji skup parametara zatim je korišten za treniranje neuronske mreže, a rezultati su uspoređeni s rezultatima mreže simuliranim pomoću simulatora zvanog SIMPTON. SIMPTON je korišten za simulaciju mreža s različitim prometnim opterećenjima od 100 i 200 Erlanga, ovdje su rezultati pokazali da je neuronska mreža učinkovit način za procjenu vjerojatnosti blokiranja u slučajevima gdje je potrebno neadekvatno treniranje mreže i vrijeme izvršenja. Postoje dva nedostatka ovog pristupa, prvi je da se isti ulazni kriteriji moraju koristiti za točnu procjenu vjerojatnosti blokiranja mreže, a drugi je da se pogreška povećava u mrežama s nižim prometnim opterećenjima.

U istraživanju [70] predložen je model složene potpuno povezane neuronske mreže zasnovan na složenoj PCA analizi te je eksperimentalno demonstriran na sustavu koherentne

²⁰ Metoda pretraživanja mreže je postupak koji ispituje unaprijed definirane raspone parametara kako bi pronašao optimalne vrijednosti.

²¹ Deseterostruka unakrsna validacija je metoda validacije modela koja dijeli skup podataka na deset dijelova, koristi devet za treniranje, a jedan za testiranje, te ponavlja postupak deset puta kako bi se procijenila učinkovitost modela.

optičke komunikacijske mreže s dualnom polarizacijom i modulacijom 64-kvadrature amplitude, dugačkom 375 km. Definirani problem istraživanja je ublažavanje Kerrovog nelinearnog učinka²², a model bi trebao služiti za njegovo predviđanje. PCA je upotrijebljen u kombinaciji s neuronskom mrežom kako bi dodatno smanjio računalnu složenost i vrijeme procijene. Kod izračuna je u obzir uzet parametar Q faktor, a rezultati su pokazali da je PCA postigao smanjenje vremena izračuna za 40 % i smanjenje prostorne složenosti za 70 %.

6.4. Predviđanje prometa korištenjem statističkih modela

U istraživanju [71] je provedeno simulacija temeljena na Markovljevom modelu, kojom su se testirali pristupi optimizacije i predviđanja prometa kod pružatelja usluga računarstva u oblaku. Predviđani prometni parametar u ovome je slučaju bila vjerojatnost blokiranja. Štoviše, model je predviđen kako bi se omogućilo predviđanje prometa u problemima optimizacije između podatkovnih centara za slučajeve orijentirane na pružatelje usluga. Pristup predviđanja prometa, iako pruža rješenje s većim troškom, rezultirao je niskim postotkom blokiranja zahtjeva i učinkovitijim korištenjem resursa mreže.

U istraživanju [72] koristi se pristup u tri faze za poboljšanje kvalitete usluge u optičkim WDM mrežama temeljen na Markovljevom statističkom modelu. Predložena je tehnika za uravnoteženje opterećenja radi poboljšanja QoS za uspostavljanje svjetlosnih putova (engl. *load balancing technique to improve QoS for lightpath establishment*, LBIQLE) procjenjuju se parametri propusnosti, vjerojatnosti blokiranja i mjernih podataka kašnjenja. Model ima dva sloja, skriveni sloj i vidljiv sloj, a za određivanje najvjerojatnijeg budućeg stanja sustava, računa se niz vjerojatnosti u skrivenom sloju i prenosi u vidljiv sloj. Takav niz vjerojatnosti naziva se Markovljev lanac, a pretpostavlja tvrdnju da sljedeće stanje ovisi samo o trenutnom stanju sustava, a ne o bilo kojem prethodnom stanju. U drugom koraku koristi se redosljed valnih duljina za smanjenje interferencije između kanala, dok se u trećem koraku koristi algoritam za modificiranje virtualne topologije kako bi se najbolje zadovoljila predviđena potražnja prometa iz prvog koraka. LBIQLE metodom se pokazuje veća stopa iskorištenje mreže te smanjenje vjerojatnost blokiranja i kašnjenja.

U pasivnim optičkim mrežama, OLT šalje pakete podataka prema ONU smještenima kod korisnika te se u istraživanju [73] koristi Bayesova²³ procjena za predviđanje vremena između dolazaka paketa od OLT-a do ONU-a. Izračuni poput nakupljanja prometa tijekom mirovanja provode se na OLT-u, a naredba se tada šalje od OLT-a do ONU-a, govoreći mu kada da miruje, a kada da se aktivira kako bi primio sljedeći paket. ONU procjenjuje prosječno vrijeme između dolazaka paketa koristeći Bayesovu procjenu i vraća svoju procjenu OLT-u za daljnje izračune. Bayesova procjena je statistička metoda temeljena na vjerojatnosti, korištena u ovom primjeru kako bi se pronašao najvjerojatniji prosječni broj dolaznih paketa, a proces se

²² Kerr-ov nelinearni učinak je fenomen u optičkim vlaknima gdje indeks loma materijala postaje ovisan o intenzitetu svjetlosti koja prolazi kroz njega.

²³ Bayesov model predviđanja je statistički pristup koji kombinira prethodno znanje s novim informacijama kako bi izračunao vjerojatnost.

ponavlja kako bi se ažurirala vjerojatnost prosječnog broja paketa sa svakim dodatnim mjerenjem. Rezultati ovog izračuna prikazuju uštedu energije od 63 %, uz smanjenje prosječnog kašnjenja od 13 % koje se očekuje od mirovanja i aktiviranja ONU-a.

U istraživanju [74] predlaže se uporaba algoritama za optimizaciju dijeljenja valnih duljina kako bi se maksimizirala propusnost prometa tijekom perioda vršnog prometa u elastičnim optičkim mrežama. Umjesto uključivanja i isključivanja opreme u svrhu obrade visokih prometnih volumena, promet se dijeli na različite svjetlosne puteve kada se dosegne određeni prag, a promet se obrađuje kroz četiri algoritma kako bi se odredio broj točaka dijeljenja, svjetlosni putevi koji će se podijeliti, alokacija resursa nakon dijeljenja i usmjeravanje dodatnog prometa. Rezultati su pokazali da optimizacija dijeljenja valnih duljina može povećati ukupnu propusnost prometa u mreži, pod pretpostavkom da se mrežni promet može podijeliti. Jedan nedostatak dijeljenja prometa je taj da se prekida mrežni promet na kratko vrijeme kako bi se srušili i stvorili novi svjetlosni putevi. Međutim, predložena tehnika optimizacije je održivo rješenje za kratkotrajne vršne promete koji traju od nekoliko sati do nekoliko dana jer zahtijeva samo nekoliko minuta za izračun i rekonfiguraciju mreže.

U istraživanju [75] predlaže se tehnika korištenjem Bayesovih mreža, odnosno mehanizam predviđanja kvarova čvorova optičke mreže koje ne ometa rad mreže. Mrežni čvorovi opremljeni su dnevničkim datotekama koje programeri koriste za otklanjanje problema, a promatrajući dnevnik prošlih kvarova, pojavljuju se obrasci u slijedu događaja koji dovode do kvara. Ti događaji su predstavljeni kao čvorovi u usmjerenom acikličkom grafu (engl. *directed acyclic graph*, DAG), koji može se koristiti kao mehanizam predviđanja kvarova temeljen na Bayesovoj mreži. Kvalitativne informacije o tome koliko se često kvarovi događaju dobivene su od programera, a te informacije se zatim koriste za generiranje uvjetnih vjerojatnosti o pojavljivanju kvarova. Bayesova mreža koristi te vjerojatnosti, a predviđanje kvarova provodi se na temelju događaja koji se događaju u stvarnom vremenu, izvučenih iz dnevnika mrežnih čvorova. Rezultati ovog istraživanja su pokazali da ovaj mehanizam pokazuje visoku točnost kod predviđanja kvarova na čvorovima.

U istraživanju [76] korišten je algoritam temeljen na Monte Carlo metodi²⁴ za predviđanje volumena prometa u elastičnim optičkim mrežama, a rezultati su zatim uspoređeni s rezultatima predviđanja pomoću neuronskih mreža. Eksperimenti su pokazali da predložene metode za predviđanje prometa imaju superiorne performanse kada se primjenjuju na standardne algoritme korištene u elastičnim optičkim mrežama te potencijalno mogu postati novi smjer za optimizaciju performansi optičkih mreža. Rezultati su pokazali da se Monte Carlo model bolje prilagođava prometnim promjenama u kraćem vremenu u odnosu na neuronske mreže.

²⁴ Monte Carlo metoda je skup numeričkih tehnika koje koriste slučajno uzorkovanje za procjenu matematičkih i statističkih funkcija te za simulaciju različitih fizičkih i matematičkih sustava.

Istraživanje [77] se razlikuje od svih prethodnih jer je prvo koje koristi Bayesovo modeliranje za procjenu dostupnosti mrežnih optičkih veza. U ovom istraživanju je izgrađen statistički model u kojega su uneseni podaci prikupljeni u određenom vremenskom intervalu, a neovisan je o usmjeravanju i sigurnosnim mehanizmima. Model je proveden kroz niz simulacijskih eksperimenata, a rezultati su pokazali smanjenje pogreške predviđanja dostupnosti optičkih veza za 52 %. Zaključeno da je ovaj model izuzetno koristan za scenarije s ograničenim podacima jer je dokazana stabilnost s obzirom na nasumičnost podataka, a glavne prednosti modela su točnost, pouzdanost te procjena nesigurnosti.

Istraživanje [78] je nastavak na istraživanje [86] gdje se također koristi Bayesov model kod predviđanja dostupnosti optičkih veza. U ovu svrhu je razvijen novi Bayesov model za predviđanje dostupnosti veza u optičkim mrežama, koristeći ukupna vremena dostupnosti i nedostupnosti linkova. Model je uspoređen s drugim pristupima predviđanja kao što su empirijska intervalna dostupnost²⁵ ili polinomnih i recipročnih regresija²⁶, a rezultati su pokazali da razvijeni model pruža veću točnost u odnosu na njih. Razvijeni Bayesov model pokazao je najbolje ukupne performanse u eksperimentima između različitih topologija i vremenskih razdoblja, a eksperiment s najboljim rezultatima rezultirao je smanjenjem pogreške procjene dostupnosti veza za 75 %.

U istraživanju [79] istražen je pristup temeljen na Bayesovoj optimizaciji s podacima dobivenim iz aktivne optičke mreže u sklopu terenskog ispitivanja, kako bi se prikupili teško mjerljivi parametri, a ti parametri su potom korišteni za procjenu QoT-a. Predloženi Bayesov model koristi podatke mjerenja OSNR-a te se primjenjuje u aktivnoj optičkoj mreži kao dio terenskog ispitivanja. Modelom se nastoje predvidjeti četiri faktora neizvjesnosti, a to su faktor šuma pojačala, gubitak na spojevima, gubitak u vlaknu i indikator izjednačavanja snage. Ti parametri nisu jedini izvor neizvjesnosti, ali najviše doprinose šumu u izračunu OSNR-a. Rezultati ispitivanja su pokazali da je Bayesov model poboljšao točnost procjene QoT-a do 1,78 dB.

6.5. Predviđanje prometa korištenjem linearne regresije


U istraživanju [80] predlaže se regresijski model strojnog učenja kako bi se dobila najbolja kombinacija opterećenja vlakna koja minimizira fragmentaciju mreže. Model je testiran u dinamičkom scenariju te je pokazao zadovoljavajuće rezultate. Razvijen je algoritam svjestan vertikalne i horizontalne fragmentacije koji pokazuje da predložena metrika i dodijeljeno opterećenje vlakana smanjuju fragmentaciju mreže, a posljedično tome, predloženo rješenje omogućuje smanjenje vjerojatnosti blokiranja propusnosti na kratki rok.

²⁵ empirijska intervalna dostupnost je pristup koji se oslanja na stvarne podatke o dostupnosti veza ili mreže tijekom određenog vremenskog razdoblja kako bi se procijenila njihova dostupnost.

²⁶ polinomna i recipročna regresija je metoda regresijske analize koja se koristi za modeliranje odnosa između zavisnih i nezavisnih varijabli.

Istraživanje [81] opisuje kako se linearna regresija može koristiti i dijeliti u optičkim mrežama za procjenu kvalitete prijenosa i uzoraka podatkovnog prometa kako bi pomogla u usmjeravanju i distribuciji resursa. Na početku je definiran izvršni put kojim će teći komunikacija čime se objašnjavaju ulazne vrijednosti, a zatim se izračunata vrijednost prikazuje kao sigmoidna funkcija. Izračunati put tada se postavlja kao linearna regresija. Prilikom ispitivanja put prijenosa podataka mora biti usmjeren, a izvor mora biti distribuiran u stvarnom vremenu na temelju postojećeg resursnog položaja mreže te se posljedično tome određuje usmjeravanje za svaki prometni zahtjev. Tako je moguće pretvoriti poteškoće usmjeravanja i alokacije resursa u probleme klasifikacije. Zaključeno je da je linearna regresije jednostavna za izvođenje, analizu i standardizaciju, međutim, ne može točno riješiti nelinearne poteškoće.

U istraživanju [82] predlaže se rješenje za smanjenje odstupanja snage u dinamičkim optičkim mrežama koje su opremljene erbijskim dopiranim optičkim pojačalom (engl. *erbium-doped fiber amplifier*, EDFA). EDFA sustav automatski održava razine snage u mrežnim pojačalima, ali se suočava s problemom neželjenih odstupanja snage koja se događaju kada povećanje ukupne snage rezultira da kanal s visokim pojačanjem krade snagu od kanala s niskim pojačanjem. U istraživanju je predstavljen jednostavan linearni regresijski model za karakterizaciju ovisnosti kanala o fluktuacijama snage u višestruko raspodijeljenim EDFA vezama. Povijesni mrežni podaci prikupljaju se i matematički generaliziraju, a nakon što je model istreniran, sposoban je predvidjeti najučinkovitije tehnike za ublažavanje neželjenih gubitaka snage. Ovaj pristup ne ometa stvarni mrežni promet. Slika 24. prikazuje funkcionalnosti linearnog regresijskog modela.



Slika 24.: Funkcionalnosti linearnog regresijskog modela za minimiziranje gubitaka snage [82]

Linearni regresijski model je treniran na 400 postojećih podataka za obuku dok se ne postigne konvergencija srednje kvadratne pogreške, a nakon konvergencije, model preporučuje kanale

za dodavanje ili uklanjanje, uzimajući u obzir njihove procijenjene standardne vrijednosti pogreške. Točnost modela je provjerena poznatim standardnim devijacijama snage mjerenim tijekom tjedna te se očekuje da će ovaj pristup biti primjenjiv za dulje periode s različitim EDFA mrežnim dizajnima.

U istraživanju [83] predstavljen je koncept optičke mreže s integriranom metodom linearne regresije koja vodi evidenciju o performansama na razini. Prikupljaju se podaci o BER-u, a metodom linearne regresije se procjenjuje OSNR za buduće zahtjeve za uslugom. Rezultati su pokazali zadovoljavajuću točnost kod procijene OSNR-a.

U istraživanju [84] analizirano je više metoda strojnog učenja, podijeljenih u kategorije klasifikacije i regresije, za predviđanja volumena prometa u optičkim mrežama. Među regresijskim metodama strojnog učenja, testirana je bila i metoda linearne regresije. Testiranja su bila provedena s pet skupova podataka koji su bili generirani pomoću simulatora, a generirani prometa odražava stvarni promet temeljen na vremenski promjenjivim podacima preuzetim s točke razmjene interneta u Seattleu. Podaci su prikupljeni tijekom jednog mjeseca iz datoteka prometa koje su periodično učitavane s vremenskim razmacima od 5 minuta po vremenskom intervalu. Istraživanja na modelima strojnog učenja su provedena u programskom alatu *Python*, a provodila su se u tri razine ovisno o količini simuliranog prometa. Rezultati testiranja su pokazali da su u svim testovima regresijske metode pokazale znatno bolje rezultate predviđanja volumena prometa u odnosu na klasifikacijske metode. Od regresijskih metoda, upravo je metoda linearne regresije pokazala najbolje rezultate u većini testova.

U istraživanju [85] predlaže se model za predviđanje volumena prometa u optičkim mrežama, sastavljen od nekoliko regresijskih modela, a temelji se na modelu linearne regresije. Model je testiran sintetičkim prometnim skupovima podataka koji su prilagođeni kako bi simulirali prirodnije ponašanje prometa te je testiranje također provedeno na dvije mrežne topologije. Model je pokazao zadovoljavajuće rezultate predviđanja te je dokazano da ovakav kombinirani model daje preciznije rezultate od pojedinačnih regresijskih modela.

6.6. Usporedba analiziranih metoda

U tablici 1. prikazana je usporedba metoda strojnog učenja za predviđanje prometa u optičkim mrežama na temelju svih prethodno opisanih istraživanja. U stupcu „Metoda“ navedene su kategorije strojnog učenja, dok su u stupcu „Vrste metoda“ prikazane specifične vrste pojedinih kategorija strojnog učenja. U stupcu „Prometni parametar“ navedeni su prometni parametri koji su bili predviđani metodama strojnog učenja, a u stupcu „Vremenska klasifikacija“, metode strojnog učenja su podijeljene u vremenske klase. Na posljetku, u stupcu „Istraživanje“, kao primjer su navedene reference prethodno opisanih istraživanja.

Tablica 1.: Usporedba metoda strojnog učenja predviđanja prometa u optičkoj mreži

Metoda	Vrsta metode	Prometni parametar	Vremenska klasifikacija	Istraživanje
NN	LSTM	Vjerojatnost blokiranja	Dugoročno	[54]
		<i>Bandwidth</i>	Kratkoročno	[61]
	GCN-GAN	Volumen prometa	Dugoročno	[55], [57]
	BPNN	Vjerojatnost blokiranja	Kratkoročno	[56]
		Volumen prometa	Dugoročno	[59]
	GCN-GRU	Volumen prometa	Kratkoročno	[58]
	RNN	Volumen prometa	Kratkoročno	[60]
	ANN	QoS	QoS	Kratkoročno
Dugoročno			[64]	
CNN	Q faktor	Kratkoročno	[63]	
SVM	SVM	QoS	Dugoročno	[65], [66]
		Zagušenje mreže	Kratkoročno	[68]
	Hibridni model	Predviđanje kvarova	Kratkoročno	[67]
PCA	PCA	Vjerojatnost blokiranja	Kratkoročno	[69]
		Optička nelinearnost	Dugoročno	[70]
Statistički modeli	Markovljev model	Vjerojatnost blokiranja	Kratkoročno	[71]
		Volumen prometa	Dugoročno	[72]
	Bayesov model	Volumen prometa	Kratkoročno	[73]
		Kvarovi na čvorovima	Dugoročno	[75]
		Dostupnost veze	Dugoročno	[77], [78]
	QoS	Kratkoročno	[79]	
	Statistička analiza	Volumen prometa	Kratkoročno	[74]
Monte Carlo metoda	Volumen prometa	Kratkoročno	[76]	
Linearna regresija	Linearna regresija	Fragmentacija mreže	Dugoročno	[80]
		QoS	Kratkoročno	[81]
		Gubitak optičke snage	Kratkoročno	[82]
		OSNR	Dugoročno	[83]
		Volumen prometa	Kratkoročno	[84], [85]

Metode predviđanja prometa često se mogu primijeniti u različitim vremenskim razdobljima te ih je potrebno vremenski klasificirati, a za potrebe ovog diplomskog rada, klasificirane su u „Kratkoročno“ i „Dugoročno“. Kratkoročne metode se odnose na predviđanje i primjenu metoda u vremenu od nekoliko minuta, sati i dana, dok se dugoročne odnose na predviđanje i primjenu metoda za tjedne, mjeseci i godine. Specifična metoda klasificira se kao kratkoročna ili dugoročna ovisno o tome:

1. jesu li ciljevi predviđanja kratkoročni ili dugoročni;
2. primjenjuje li se u simulaciji za kratkoročno ili dugoročno razdoblje;
3. predviđa li promet za kratkoročne ili dugoročne vremenske intervale;
4. je li vremenski ovisna ili neovisna.

U slučaju da je tehnika vremenski neovisna, klasificirati će se kao dugoročna jer se vremenski neovisne metode mogu primijeniti bez obzira na vremensko razdoblje.

7. Zaključak

Optičke komunikacijske mreže se s vremenom i napretkom tehnologije sve više razvijaju te nastavljaju rasti u veličini, složenosti i inteligenciji. Danas postoji mnogo vrsta i izvedbi optičkih mreža koje mogu biti i jesu prigodne za poslovne, privatne i druge korisnike, ovisno o mrežnim karakteristikama. Razne napredne tehnologije se integriraju u optičke mreže koje utječu na unaprjeđenje njihove sigurnosti, kvalitete prijenosa i upravljanja kvarovima. Postoji mnogo faktora i prometnih parametara koji utječu na kvalitetu prijenosa podataka optičkim mrežama te ih je bitno pratiti i nadzirati kako bi se održala zadovoljavajuća stopa kvalitete prijenosa. Uz to, bitno je i predviđanje tih parametara kako bi se spriječili mrežni kvarovi i efikasnije isplaniralo usmjeravanje mrežom.

Tehnologije strojnog učenja i umjetne inteligencije uvode se kako bi mreža bolje upravljala situacijama visokog prometnog volumena i osigurala kvalitetu usluge. U ovom diplomskom radu analizirano je više radova relevantnih za predviđanje mrežnog prometa te su izdvojene tehnologije koje su najzastupljenije kod primjene u optičkim mrežama. Te tehnologije su podijeljene na neuronske mreže, potporne vektore, analizu glavnih komponenti, statističke modele te metode linearne regresije. Kod svake od analiziranih metoda moraju se razmotriti razni faktori, kao što su zahtjevi za obradu, vrijeme izračuna, potrošnja energije i topologija mreže. Metode strojnog učenja i statistički modeli mogu se učitati na fizičke uređaje povezane s optičkom komunikacijskom mrežom za praćenje, predviđanje i konfiguraciju mreže, a sve veća dostupnost kvalitetnih povijesnih podataka također može osigurati brže i točnije treniranje ovih modela.

Analizom je utvrđeno da su tehnike neuronskih mreža najčešći alati korišteni za predviđanje parametara mrežnog prometa te postoji najveći broj istraživanja tih tehnika, slijede ih statistički modeli, dok su metoda potpornih vektora i analiza glavnih komponenti nešto manje zastupljene. Povratne neuronske mreže i rekurentne neuronske mreže efikasnije su za preciznije predviđanje budućih stanja mreže, što je rezultat njihovih povratnih mehanizama koji im omogućuju da djeluju kao memorija. Autori nekih od istraživanja također predlažu rješenja koja se uglavnom koriste u obradi slika, kao što je metoda GCN-GAN, te ih prilagođavaju problemima povezanim s predviđanjem mrežnog prometa. Najčešći predviđani prometni parametri pomoću neuronskih mreža su vjerojatnost blokiranja i volumen prometa, ali se koriste i kod predviđanja kvalitete prijenosa te predviđanja *bandwidth*-a i Q faktora. Metoda potpornih vektora se pokazala korisnom kod predviđanja kvalitete prijenosa uzimajući u obzir Q faktor i BER, a još jedna prednost je kratko vrijeme izračuna. Metoda potpornih vektora također je korisna i kod mrežnog upravljanja, jer se može koristiti za predviđanje kvarova i zagušenja mreže. Analiza glavnih komponenti se najčešće koristi u kombinaciji s neuronskim mrežama kod generaliziranja i klasificiranja varijabli za treniranje neuronskih mreža, a uglavnom se koristi u istraživanjima gdje je cilj odrediti vjerojatnost blokiranja. Međutim, pokazala se korisnom i kod predviđanja optičke nelinearnosti. Statistički modeli imaju široku primjenu u predviđanju prometnih parametara u optičkim mrežama, a najčešće se koriste za predviđanje

volumena prometa. Međutim, poneka istraživanja dokazuju njihovu korisnost čak i kod predviđanja kvarova u čvorovima optičkih mreža te predviđanja dostupnosti veze i kvalitete usluge. Linearna regresija se najčešće koristi za predviđanje volumena prometa i fragmentacije mreže, ali i za predviđanje kvalitete prijenosa, OSNR-a te razine snage.

Analizom je također utvrđeno da su volumen mrežnog prometa i vjerojatnost blokiranja bili najčešći metrički podaci za predviđanje u optičkim komunikacijskim mrežama, a neka istraživanja su koristila i predviđanje prometa u svrhu konfiguracije mreže. Svaka od navedenih tehnika se može koristiti i za kratkoročno i dugoročno predviđanje prometa optičke mreže. Složenije metode poput neuronskih mreža su pogodnije za precizna dugoročna predviđanja, dok su tehnike poput analize glavnih komponenti i linearne regresije pogodnije za kratkoročne izračune. Metoda potpornih vektora i statistički modeli su podjednako korisni i kod kratkoročnih i dugoročnih predviđanja prometa optičkih mreža.

Buduća mrežna rješenja trebaju adekvatno odgovoriti na stalno rastuću potražnju za prijenosom podataka bez povećanja složenosti, s istodobnim smanjenjem vremena koje operatori elektroničke komunikacijske mreže ulažu u operacije i upravljanje mrežom. Uz to, analizirana rješenja (metode) trebaju biti lako održiva, a njihove sposobnosti trebaju se neprestano ažurirati minimalnim angažmanom ljudskog čimbenika. Navedeni zahtjevi su mogući unaprjeđenjem softverski definiranih optičkih mreža što povećava dinamičku prilagodljivost optičkih mreža na promjene vezane uz prometne varijabilnosti.

Literatura

- [1] Altahir M., Ahmed A.: *Optical networks. EE Department, College of Engineering, King Saud University. Riyadh, 2000.*
- [2] Siddhart S.: *Optical network architecture. Slideshare, 2015.* Preuzeto s: <https://www.slideshare.net/Yashu9218/optical-network-architecture> (Pristupljeno: svibanj 2024.)
- [3] Somani A. K.: *Survivability and Traffic Grooming in WDM Optical Networks.* Cambridge University Press, 2005.
- [4] Kim J.: *Fiber optics: What i sit? And How does it Work?. Dgtl Infra, 2023.* Preuzeto s: <https://dgtlinfra.com/fiber-optics/> (Pristupljeno: svibanj 2024.)
- [5] Winzer, Peter.: *Modulation and multiplexing in optical communication systems. IEEE LEOS Newsletter, 2009.*
- [6] Wosinska L., Chen J., Larsen C. P.: *Fiber Access Networks: Reliability Analysis and Swedish Broadband Market. IEICE Transactions on Communications.* 2009;92(10): 3006-3014
- [7] Babu M., Ramakrishnan M., Rajkumar S., Sikkander A. R. M.: *Backhaul performance of 5G TWDM-PON network using energy efficient clustering. Caribbean Journal of Science.* 2022;53(2): 2355-2362 Preuzeto s: https://www.researchgate.net/publication/364830207_BACKHAUL_PERFORMANCE_OF_5G_TWDM-PON_NETWORK_USING_ENERGY_EFFICIENT_CLUSTERING (Pristupljeno: lipanj 2024.)
- [8] Hernandez S. S., Altabas J. A., Lazaro J. A.: *Passive Optical Networks: Introduction.* Wiley Online Library, 2018.
- [9] Pravena S. M., Vennila I., Vaishnavi R.: *Investigation of Passive Optical Network Based on QoS Issues in Wireless Fibre to the Home Architecture for Fault Identification and Detection. Springer.* 2017;96(1): 961-976 Preuzeto s: <https://link.springer.com/article/10.1007/s11277-017-4213-4> (Pristupljeno: lipanj 2024.)
- [10] Miladić S., Marković G.: *Elastične optičke mreže. XXXIII Simpozijum o novim tehnologijama u poštanskom i telekomunikacionom saobraćaju. Beograd, 2015.* Preuzeto s: <https://postel.sf.bg.ac.rs/simpozijumi/POSTEL2015/RADOVI%20PDF/Telekomunikacioni%20saobracaj%20i%20mreze/7.%20Miladic-Markovic.pdf> (Pristupljeno: lipanj 2024.)
- [11] Ranjan P., Pande P., Oswal R., Qurani Z.: *A Survey of Past, Present and Future of Software Defined Networking.* vol. 7782, pp. 238–248. *Institute of Electrical and Electronics Engineers, 2014.*

- [12] Leytón G. V.: *Software-Defined Optical Network (SDON), new generation networks. IOP Conference Series: Materials Science and Engineering* 519. Pasto, 2013. Preuzeto s: <https://iopscience.iop.org/article/10.1088/1757-899X/519/1/012013> (Pristupljeno: lipanj 2024.)
- [13] Borzycki K.: *FTTx Access Networks: Technical Developments and Standardization. IntechOpen*. London, 2018.
- [14] Mendes de Lima G.: *Decoding Passive Optical Network Surveillance Based Upon Constraint Management Techniques*. 126 p. *Ph.D. Thesis Qualify – Faculty of Electrical Engineering, Federal University of Uberlândia*. Uberlândia, 2014. Preuzeto s: https://www.researchgate.net/publication/273143774_Decoding_Passive_Optical_Network_Surveillance_Based_Upon_Constraint_Management_Techniques (Pristupljeno: lipanj 2024.)
- [15] Hervet C.: *Optimization of optical network deployment. Consideration on demand uncertainty. ENSTA ParisTech*. Pariz, 2013. Preuzeto s: https://www.researchgate.net/publication/282213069_Optimization_of_optical_network_deployment_Considerations_on_demand_uncertainty (Pristupljeno: lipanj 2024.)
- [16] Radovanović I., Etten W., Freriks H.: *Ethernet-Based Passive Optical Local-Area Networks for Fiber-to-the-Desk Application. Journal of Lightwave Technology*. 2003;21(11): 2534- 2545
- [17] Dong Z., Khan F. N., Qi S., Zhong K., Lu C., Lau A.: *Optical Performance Monitoring: A Review of Current and Future Technologies. Journal of Lightwave Technology*. 2016;34(2): 525-543. Preuzeto s: https://ira.lib.polyu.edu.hk/bitstream/10397/64498/1/Khan_Optical_Performance_Monitoring.pdf (Pristupljeno: svibanj 2024.)
- [18] Kilper D. C., Bach R., Blumenthal D. J., Einstein D., Landolsi T., Ostar L., Preiss M., Willner A. E.: *Optical Performance Monitoring. Journal of Lightwave Technology*. 2004;22(1): 294-304.
- [19] Joshi T., Kumar A., Kumar M.: *Performance analysis & Optimization of WDM-EPON for Metropolitan Area Networking. International Journal of Scientific and Research Publications*. 2012;2(6): 1-4. Preuzeto s: https://www.researchgate.net/publication/264276725_Performance_analysis_Optimization_of_WDM-EPON_for_Metropolitan_Area_Networking (Pristupljeno: lipanj 2024.)
- [20] Tao: *How to calculate attenuation in optical fiber cable? Qsfptek Global*, 2021. Preuzeto s: <https://www.qsfptek.com/qt-news/how-to-calculate-attenuation-in-optical-fiber-cable.html> (Pristupljeno: lipanj 2024.)
- [21] Muhammad F., Muhammad U., Ali F., Khan I., Habib U., Kim S.: *Time Domain Equalization and Digital Back-Propagation Method-Based Receiver for Fiber Optic Communication Systems. International Journal of Optics*. 2020. Preuzeto s: https://www.researchgate.net/publication/338774052_Time_Domain_Equalization_and_Digital_Back-Propagation_Method-

[Based Receiver for Fiber Optic Communication Systems](#) (Pristupljeno: lipanj 2024.)

- [22] Okamoto K.: *Fundamentals of Optical Waveguides*. Academic Press; 2006. Preuzeto s: <https://www.sciencedirect.com/book/9780125250962/fundamentals-of-optical-waveguides> (Pristupljeno: svibanj 2024.)
- [23] Tarutani Y., Ohsita Y., Murata M.: *Optical-Layer Traffic Engineering with Link Load Estimation for Large-Scale Optical Networks*. *Journal of Optical Communications and Networking*. 2006;6(1): 1-13.
- [24] Saini H. S., Wason A.: *Optimization of blocking probability in all-optical network*. *Optik*. 2016;127(20): 8678-8684.
- [25] Sanghyun Kim, Ji-Hoon Yun: *Wider-Bandwidth Operation of IEEE 802.11 for Extremely High Throughput: Challenges and Solutions for Flexible Puncturing*. *IEEE Access*. 2020.;8:213840-213853.
- [26] Beas J., Castanon G., Aldaya I. A., Campuzano G.: *Radio over Fiber Access Networks for Broadband Wireless Communications*. *IEEE communications surveys & tutorials*. 2013. Preuzeto s: https://www.researchgate.net/publication/286062151_Radio_over_Fiber_Access_Networks_for_Broadband_Wireless_Communications (Pristupljeno: svibanj 2024.)
- [27] Burdah S., Samijayani O. N., Syahriar A., Ramdhani R., Alamtaha R.: *Performance Analysis of Q Factor Optical Communication in Free Space Optics and Single Mode Fiber*. *Universal Journal of Electrical and Electronic Engineering*. 2019;6(3): 167-175.
- [28] Huang T., Fan Z., Su J., Qiu Q.: *Time Jitter Analysis of an Optical Signal Based on Gated On-Off Optical Sampling and Dual-Dirac Modeling*. *Electronics* 2023;12(3): 633
- [29] Drego N. A.: *A low-skew, low jitter receiver circuit for on-chip optical clock distribution*. *Massachusetts Institute of Technology*, 2003. Preuzeto s: https://www.cppsim.com/Publications/Theses/ndrego_mthesis.pdf (Pristupljeno: svibanj 2024.)
- [30] Rad, M.M.; Fouli, K.; Fathallah, H.A.; Rusch, L.A.; Maier, M.: *Passive optical network monitoring: Challenges and requirements*. *IEEE Commun. Mag.* 2011;49(2): 45–52.
- [31] Shen T.S.R., Meng K., Lau A.P.T., Dong Z.Y.: *Optical performance monitoring using artificial neural network trained with asynchronous amplitude histograms*. *IEEE Photonics Technology Letters*. 2010;22(22): 1665–1667.
- [32] Dods S.D., Anderson T.B.: *Optical performance monitoring technique using delay tap asynchronous waveform sampling*. *Proc. Optical Fiber Communication Conference*. Anaheim, 2006
- [33] Li Z., Jian Z., Cheng L., Yang Y., Lu C., Lau A.P.T., Yu C., Tam H. Y., Wai P. K. A.: *Signed CD monitoring of 100Gbit/s CS-RZ-DQPSK signal by evaluating the asymmetry ratio of delay-tap sampling*. *Optics Express*. 2010;18(3): 3149–3157.

- [34] Wang J., Jiang X., He X., Weng Y., Pan Z.: *Chromatic dispersion estimation methods using polynomial fitting in PDM-QPSK or other multilevel-format coherent optical systems*. *Optical Fiber Technology*. 2013;19(2): 162-168.
- [35] Dou L., Tao Z., Zhao Y., Oda S., Aoki Y., Hoshida T., Rasmussen J. C.: *Differential pilots aided in-Band OSNR monitor with large nonlinear Tolerance*. *Proc. Optical Fiber Communication Conference*, 2015.
- [36] Gariepy D., Searcy S., He G., Tibuleac S.: *Non-intrusive in-band OSNR measurement of polarization multiplexed signals operating in the non-linear regime*. *Proc. Optical Fiber Communication Conference*, 2015
- [37] Liu X., Kao Y. H., Chandrasekhar S., Kang I., Cabot S., Buhl L. L.: *OSNR monitoring method for OOK and DPSK based on optical delay interferometer*. *IEEE Photonics Technology Letters*. 2007;19(15) 1172–1174.
- [38] Woo W.L.: *Human-machine co-creation in the rise of AI*. *IEEE Instrumentation and Measurement Magazine*. 2020;23(2): 71–73.
- [39] Musumeci F., Rottondi C., Nag A., Macaluso I., Zibar D., Ruffini M., Tornatore M.: *An Overview on Application of Machine Learning Techniques in Optical Networks*. Cornell University. Ithaca, 2018.
- [40] Gu R., Yang Z., Ji, Y.: *Machine learning for intelligent optical networks: A comprehensive survey*. Cornell University. Ithaca, 2020.
- [41] Aibin M.: *Traffic prediction based on machine learning for elastic optical networks*. *Optical Switching and Networking*. 2018;30(10): 33–39.
- [42] Aibin M., Walkowiak K.: *Monte Carlo Tree Search with Last-Good-Reply Policy for Cognitive Optimization of Cloud-Ready Optical Networks*. *Journal of Network and Systems Management*. 2020;28(4): 1722–1744.
- [43] Chen, A., Law, J., Aibin, M.: *A Survey on Traffic Prediction Techniques Using Artificial Intelligence for Communication Networks*. Telecom, 2021. Preuzeto s: <https://www.mdpi.com/2673-4001/2/4/29> (Pristupljeno: svibanj 2024.)
- [44] Pan Y.: *Different Types of Neural Networks and Applications: Evidence from Feedforward, Convolutional and Recurrent Neural Networks*. *Highlights in Science, Engineering and Technology*. 2024;85: 247-255.
- [45] Noble W.S.: *What is a support vector machine?* *Nat. Biotechnol.* 2006;24: 1565–1567.
- [46] Cervantes J., Garcia-Lamont F., Rodriguez-Mazahua L., Lopez A.: *A comprehensive survey on support vector machine classification: Applications, challenges and trends*. *Neurocomputing*, 2020;408: 189-215.
- [47] Greenacre M., Groenen P. J. F., Hasie T., D'Enza A.: *Principal component analysis*. *Nature Reviews Methods Primers*, 2022.
- [48] Jaadi Z.: *A Step-by-Step Explanation of Principal Component Analysis (PCA)*. *Built in*, 2024. Preuzeto s: <https://builtin.com/data-science/step-step-explanation-principal-component-analysis> (Pristupljeno: svibanj 2024.)

- [49] Ibe O. C.: *Markov Processes for Stochastic Modeling*. Academic Press. Cambridge, 2013. Preuzeto s: <https://doi.org/10.1016/C2012-0-06106-6> (Pristupljeno: lipanj 2024.)
- [50] Seyr H., Muskulus M.: *Use of Markov Decision Processes in the Evaluation of Corrective Maintenance Scheduling Policies for Offshore Wind Farms*. *Energies*. 2019;12(15):2993. Preuzeto s: <https://www.mdpi.com/1996-1073/12/15/2993#metrics> (Pristupljeno: svibanj 2024.)
- [51] Last G., Penrose M.: *Lectures on the Poisson Process*. Cambridge University Press. Cambridge, 2017. Preuzeto s: https://www.math.kit.edu/stoch/~last/seite/lectures_on_the_poisson_process/media/lastpenrose2017.pdf (Pristupljeno: svibanj 2024.)
- [52] Gonzalez J.: *Gaussian processes for decision making under uncertainty*. Prezentacija. Oxford, 2018. Preuzeto s: <https://isp.uv.es/projects/kermes/talk.pdf> (Pristupljeno: svibanj 2024.)
- [53] Montgomery D. C., Peck E. A., Vining G. G.: *Introduction of linear regression analysis, 6th edition*. Wiley. New Jersey, 2021. Preuzeto s: <https://ocd.lcwu.edu.pk/cfiles/Statistics/Stat-503/IntroductiontoLinearRegressionAnalysisbyDouglasC.MontgomeryElizabethA.PeckG.GeoffreyViningz-lib.org.pdf> (Pristupljeno: svibanj 2024.)
- [54] Aibin M.: *Deep Learning for Cloud Resources Allocation: Long-Short Term Memory in EONs*. In *Proceedings of the International Conference on Transparent Optical Networks*. Angers, 2019.
- [55] Aibin M., Chung N., Gordon T., Lyford L., Vinchoff C.: *On Short-and Long-Term Traffic Prediction in Optical Networks Using Machine Learning*. ONDM. Gothenburg, 2021.
- [56] Jia W.B., Xu Z.Q., Ding Z., Wang K.: *An efficient routing and spectrum assignment algorithm using prediction for elastic optical networks*. *International Conference on Information System and Artificial Intelligence*. Hong Kong, 2017.
- [57] Vinchoff C., Chung N., Gordon T., Lyford L., Aibin M.: *Traffic Prediction in Optical Networks Using Graph Convolutional Generative Adversarial Networks*. In *Proceedings of the International Conference on Transparent Optical Networks*. Bari, 2020.
- [58] Gui Y., Wang D., Guan L., Zhang M.: *Optical Network Traffic Prediction Based on Graph Convolutional Neural Networks*. *Opto-Electronics and Communications Conference*. Peking, 2020. Preuzeto s: https://www.researchgate.net/publication/347341352_Optical_Network_Traffic_Prediction_Based_on_Graph_Convolutional_Neural_Networks (Pristupljeno: svibanj 2024.)
- [59] Xiong Y., Shi J., Lv Y., Rouskas G.N.: *Power-aware lightpath management for SDN-based elastic optical networks*. *International Conference on Computer Communications and Networks*. Vancouver, 2017.
- [60] Vinayakumar R., Soman KP., Prabakaran P.: *Applying Deep Learning Approaches for Network Traffic Prediction*. IEEE, 2017.

- [61] Li P., Lv Y., Bi M.: *Bandwidth Prediction Based Resource Allocation Scheme for Low-Latency and Energy-Efficient PONs With Heterogeneous ONU Propagation Delays*. *IEEE Photonics Journal*, 2024.
- [62] Brusin A. M. R., Nespola A., Zefrech M. R., Piciaccia S., Poggiolini P., Forghieri F., Carena A.: *ML-Based Spectral Power Profiles Prediction in Presence of ISRS for Ultra-Wideband Transmission*. *Journal of lightwave technology*. 2024;42(1): 37-47
- [63] Al-Shamayleh S. A., Raza A., Ali Z., Malik S., Iqbal S., Raza B., Iqbal M., Etiah A.: *Performance Evaluation of Optical Transmission Based on Link Estimation by Using Deep Learning Techniques*. *IEEE Access*, 2024.
- [64] He Y., Chandramouli K., Zhai Z., Chen S., Dou L. Xie C., Lu C., Lau A.: *QoT Estimation for Large-scale Mixed-rate Disaggregated Metro DCI Networks by Artificial Neural Networks*. *Optica Publishing Group*. San Diego, 2024.
- [65] Mata J., De Miguel I., Durán R.J., Aguado J.C., Merayo N., Ruiz L., Fernández P., Lorenzo R.M., Abril E.J.: *A SVM approach for lightpath QoT estimation in optical transport networks*. *IEEE International Conference*. Pariz, 2017.
- [66] Wang D., Zhang M., Zhang Z., Li J., Gao H., Zhang F., Chen X.: *Machine Learning-Based Multifunctional Optical Spectrum Analysis Technique*. *IEEE Access*, 2019.
- [67] Liu P., Ji W., Liu Q., Liu F., Xue X., Zhu Y.: *Failure Prediction Based on LSTM and SVM under SDON Architecture*. *International Conference on Computer and Communications*. Chengdu, 2021. Preuzeto s: https://www.researchgate.net/publication/357889908_Failure_Prediction_Based_on_LSTM_and_SVM_under_SDON_Architecture (Pristupljeno: svibanj 2024.)
- [68] Sun Q., Lan H., Yang X.: *Prediction of Optical Network Congestion Based on SVM*. *International Conference on Computer Science and Network Technology*. Dalian, 2019.
- [69] De Araújo D.R., Bastos-Filho C.J., Martins-Filho J.F.: *Methodology to obtain a fast and accurate estimator for blocking probability of optical networks*. *J. Opt. Commun. Netw.* 2015;7(5): 380–391.
- [70] Huang X., Wang Y., Li C., Gao R., Zhang Q., Han L., Xin X.: *Complex principal component analysis-based complex-valued fully connected NN equalizer for optical fibre communications*. *Optics Express*. 2023;31(25): 42310-42326.
- [71] Aibin M., Walkowiak K., Haeri S., Trajkovic, L.: *Traffic Prediction for Inter-Data Center Cross-Stratum Optimization Problems*. *International Conference on Computing*. Maui, 2018.
- [72] Chitra K., Senkumar M.R.: *Hidden Markov model based lightpath establishment technique for improving QoS in optical WDM networks*. *International Conference on Current Trends in Engineering and Technology*. Coimbatore, 2014.
- [73] Dias M.P.I., Karunaratne B.S., Wong E.: *Bayesian estimation and prediction-based dynamic bandwidth allocation algorithm for sleep/doze-mode passive optical networks*. *J. Light. Technol.* 2014;32(14): 2560–2568.

- [74] Zhong Z., Hua N., Tornatore M., Li J., Li Y., Zheng X., Mukherjee B.: *Provisioning Short-Term Traffic Fluctuations in Elastic Optical Networks. International Conference on Transparent Optical Networks*. Angers, 2019.
- [75] Das D., Imteyaz M. F., Bapat J., Das D.: *A Data Augmented Bayesian Network for Node Failure Prediction in Optical Networks. International Conference on Artificial Intelligence in Information and Communication*. Jeju Island, 2021.
- [76] Aibin M.: *Traffic prediction based on machine learning for elastic optical networks. Optical Switching and Networking*. 2018;30: 33-39
- [77] Christou F.: *Availability Estimation of Optical Network Links Using Multilevel Bayesian Modeling. International Conference on Optical Network Design and Modeling. Coimbra, 2023*.
- [78] Christou F.: *Availability estimation of optical network links using a Bayesian model. Journal of Optical Communications and Networking*. 2024;16(5): 1-15.
- [79] Ayassi R., Triki A., Guyader B., Frank F., Marcot T., Rouzic E., Laye M., Minerva R., Crespi N.: *Field Trial to Assess Bayesian Optimization for Improving QoT Estimation. European Conference on Optical Communications*. Glasgow, 2023.
- [80] Lechowicz P.: *Regression-based fragmentation metric and fragmentation-aware algorithm in spectrally-spatially flexible optical networks. Computer Communications*. 2021;175(4): 156–176.
- [81] Rai S., Garg A.K.: *Analysis of RWA in WDM optical networks using machine learning for traffic prediction and pattern extraction. Journal of Optics*, 2021.
- [82] Huang Y., Samoud W., Gutterman C.L., Ware C., Lourdiane M., Zussman G., Samadi P., Bergman K.: *A Machine Learning Approach for Dynamic Optical Channel Add/Drop Strategies that Minimize EDFA Power Excursions. European Conference on Optical Communication. Anaheim, 2016*. Preuzeto s: <https://ieeexplore.ieee.org/document/7767549> (Pristupljeno: lipanj 2024.)
- [83] Oda S., Miyabe M., Yoshida S., Katagiri T., Aoki Y., Hoshida T., Rasmussen J.C., Birk M., Tse K.: *A learning living network with open ROADMS. J. Lightwave Technol.* 2017;35(8): 1350–1356.
- [84] Szostak D., Włodarczyk A., Walkowiak K.: *Machine Learning Classification and Regression Approaches for Optical Network Traffic Prediction. Electronics*. Wroclaw, 2021
- [85] Ulanowicz B., Dopart D., Knapinska A., Lechowicz P., Walkowiak K.: *Combining Random Forest and Linear Regression to Improve Network Traffic Prediction. Conference on Transparent Optical Networks*. Bucharest, 2023.

Popis kratica i akronima

Kratica	Značenje
AAH	(engl. <i>asynchronous amplitude histograms</i>) asinkroni histogram amplitude
ADTP	(engl. <i>asynchronous delay-tap plots</i>) asinkrone krivulje odgode i preslušavanja
ANN	(engl. <i>artificial neural network</i>) umjetne neuronske mreže
AON	(engl. <i>active optical networks</i>) aktivan optička mreža
API	(engl. <i>Application Programming Interface</i>) aplikacijsko programsko sučelje
ASCS	(engl. <i>asynchronous single channel sampling</i>) asinkrono uzorkovanje jednog kanala
ATTP	(engl. <i>asynchronous two-tap plots</i>) asinkrone krivulje dvostrukog preslušavanja
BER	(engl. <i>bit error rate</i>) broj pogrešno prenesenih bitova
BPNN	(engl. <i>backpropagation neural network</i>) neuronska mreža s propagacijom unazad
BVT	(engl. <i>Bandwidth Variable Transponder</i>) prilagodljivi optički odašiljači i prijammnici
BV-WXC	(engl. <i>Bandwidth Variable Wavelength Cross-Connect</i>) optički križni konektori promjenjivog kapaciteta
CD	(engl. <i>chromatic dispersion</i>) kromatska disperzija
CNN	(engl. <i>convolutional neural networks</i>) konvolucijske neuronske mreže
CWDM	(engl. <i>coarse wavelength division multiplexing</i>) multipleksiranje s grubom valnom podjelom
DAG	(engl. <i>directed acyclic graph</i>) usmjereni aciklički graf
DLI	(engl. <i>delay-line interferometer</i>) interferometru s odgođenom linijom
DWDM	(engl. <i>dense wavelength division multiplexing</i>) multipleksiranje s gustom valnom podjelom
EDFA	(engl. <i>erbium-doped fiber amplifier</i>) erbijski dopirano optičko pojačalo

EEM	(engl. <i>energy-efficient multicast</i>) energetski učinkoviti multicast
EON	(engl. <i>elastic optical networks</i>) elastična optička mreža
FTTB	(engl. <i>Fibre to the Building</i>) vlakno do zgrade
FTTC	(engl. <i>Fibre to the Curb</i>) vlakno do ivičnjaka
FTTD	(engl. <i>Fiber to the Desk</i>) vlakno do stola
FTTH	(engl. <i>Fibre to the Home</i>) vlakno do doma
FTTN	(engl. <i>Fibre to the Node</i>) vlakno do čvora
FTTP	(engl. <i>Fiber to the Premises</i>) vlakno do objekta
FTTx	(engl. <i>Fibre to the X</i>) vlakno do X
GAN	(engl. <i>generative adversarial network</i>) generativna suparnička mreža
GCN	(engl. <i>graph convolution network</i>) mreža s grafičkom konvolucijom
GCN-GRU	(engl. <i>Graph Convolutional Network with the Gated Recurrent Unit</i>) Grafička konvolucijska mreža s kontroliranim rekurentnim blokom
GRU	(engl. <i>gated recurrent unit</i>) jedinica s povratnim petljama
IRNN	(engl. <i>identify recurrent neural network</i>) identifikacijska rekurentna neuronska mreža
LBIQLE	(engl. <i>load balancing technique to improve QoS for lightpath establishment</i>) uravnoteženje opterećenja radi poboljšanja QoS za uspostavljanje svjetlosnih putova
LED	(engl. <i>light-emitting diode</i>) svjetlosna dioda
LSTM	(engl. <i>long short-term memory</i>) dugoročno-kratkoročna memorija
MCW	(engl. <i>minimum comprehensive weight algorithm</i>) algoritam minimalne sveobuhvatne težine
MNC	(engl. <i>minimum network competition algorithm</i>) algoritam minimalne mrežne konkurencije

NN	(engl. <i>neural networks</i>) neuronske mreže
OLT	(engl. <i>Optical Line Terminal</i>) optički linijski terminal
ONU	(engl. <i>Optical Network Unit</i>) optički mrežna jedinica
OSNR	(engl. <i>Optical signal to noise ratio</i>) optički odnos signal-šum
P2MP	(engl. <i>point-to-multipoint</i>) točka-do-više točaka
P2P	(engl. <i>point-to-point</i>) točka-do-točke
PALM	(engl. <i>power-aware lightpath management</i>) upravljanje optičkim putevima s fokusom na potrošnju energije
PCA	(engl. <i>principal component analysis</i>) analiza glavnih komponenata
PLC	(engl. <i>planar waveguide circuit splitter</i>) planarni valovodni optički razdjelnici
PMD	(engl. <i>polarization-mode-dispersion</i>) polarizacijska modna disperzija
PON	(engl. <i>passive optical networks</i>) pasivna optička mreža
PSO	(engl. <i>particle swarm optimization</i>) optimizacija rojem čestica
QoT	(engl. <i>Quality of transmission</i>) kvaliteta prijenosa
QPSK	(engl. <i>Quadrature Phase Shift Keying</i>) kvadraturno-fazna modulacija
RNN	(engl. <i>recurrent neural networks</i>) rekurentne neuronske mreže
SDN	(engl. <i>software defined networks</i>) softverski definirane mreže
SDON	(engl. <i>software-defined optical networks</i>) softverski definirana optička mreža
SVM	(engl. <i>support vector machine</i>) potporni vektori
TDM	(engl. <i>time division multiplex</i>) vremenski multipleks
WDM	(engl. <i>wavelength division multiplexing</i>) valno multipleksiranje

WRON

(engl. *wavelength-routed optical networks*) usmjeravanje po valnim duljinama

Popis slika

Slika 1.: Opća shema optičke mreže.....	3
Slika 2.: Struktura optičkog kabela	4
Slika 3.: Arhitektura AON mreže.....	6
Slika 4.: Arhitektura PON mreže	7
Slika 5.: Arhitektura elastične optičke mreže	8
Slika 6.: Arhitektura softverski definirane optičke mreže	9
Slika 7.: Arhitektura FTTH mreže	10
Slika 8.: Arhitekture FTTB mreže.....	11
Slika 9.: Arhitektura FTTN mreže	12
Slika 10.: Izvedba FTTC mreže	12
Slika 11.: Vizualni prikaz kromatske disperzije u jednomodnom vlaknu	16
Slika 12.: Vizualni prikaz polarizacijsko modne disperzije	16
Slika 13.: Usporedba <i>bandwidtha</i> između dva modulirana kanala i jednog moduliranog kanala	18
Slika 14.: Utjecaj <i>jittera</i> na optički signal	19
Slika 15.: Prilagodljivo kompenziranje oštećenja, pouzdan rad mreže te usmjeravanje s obzirom na stanje mreže omogućeno kroz prikupljanje podataka u optičkoj mreži.....	21
Slika 16.: Klasifikacija metoda prikupljanja podataka u sustavima direktne detekcije	22
Slika 17.: Konceptualni prikaz prikupljanja podataka AAH tehnikom.....	24
Slika 18.: Konceptualni prikaz prikupljanja podataka ADTS tehnikom te konverzija u ADTP	25
Slika 19.: Shema standardnog koherentnog optičkog prijavnika s algoritmom za oporavak podataka.....	26
Slika 20.: Prikupljanje OSNR podataka korištenjem DLI.....	28
Slika 21.: Opći model neuronske mreže s dva skrivena sloja.....	30
Slika 22.: Primjer vizualnog prikaza Markovljevog modela	35
Slika 23.: Prikaz GCN-GRU arhitekture	39
Slika 24.: Funkcionalnosti linearnog regresijskog modela za minimiziranje gubitaka snage ..	48

Popis grafikona

Grafikon 1.: Grafički prikaz utjecaja OSNR-a na optičko vlakno	15
Grafikon 2.: Podjela podatak u dvije klase metodom potpornih vektora	32
Grafikon 3.: Raspodjelni dijagram koji prikazuje primjer analize glavnih komponenata generirajući dvije glavne komponente.....	33
Grafikon 4.: Prikaz dijagrama linijske regresije	36

Popis tablica

Tablica 1.: Usporedba metoda strojnog učenja predviđanja prometa u optičkoj mreži50

Sveučilište u Zagrebu
Fakultet prometnih znanosti
Vukelićeva 4, 10000 Zagreb

IZJAVA O AKADEMSKOJ ČESTITOSTI I SUGLASNOSTI

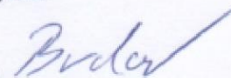
Izjavljujem i svojim potpisom potvrđujem da je _____ diplomski rad
(vrsta rada)

isključivo rezultat mojega vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu, a što pokazuju upotrijebljene bilješke i bibliografija. Izjavljujem da nijedan dio rada nije napisan na nedopušten način, odnosno da je prepisan iz necitiranog rada te da nijedan dio rada ne krši bilo čija autorska prava. Izjavljujem, također, da nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Svojim potpisom potvrđujem i dajem suglasnost za javnu objavu završnog/diplomskog rada pod naslovom Analiza metoda predviđanja prometa u optičkoj mreži, u Nacionalni repozitorij završnih i diplomskih radova ZIR.

U Zagrebu, 24.6.2024.

Student/ica:

Antonio Brdar, 
(ime i prezime, potpis)