

博士論文

コヒーレント光送受信器における光電場の
深層学習を用いた状態推定と制御

指導教員 森川 博之 教授



東京大学大学院 工学系研究科
先端学際工学専攻

氏名 37-157157 谷村 崇仁

提出日 2017年12月1日

目次

第 1 章	序論	1
1.1	本論文の背景と目的	3
1.2	本論文の構成	5
第 2 章	デジタル化された光電場の状態推定と制御	7
2.1	はじめに	9
2.2	ネットワーク上を流れる情報の大容量化と多様化	9
2.2.1	光送受信器の大容量化技術	11
2.2.2	光送受信器のフレキシブル化技術	12
2.3	モニタリングベース光ネットワーク	14
2.4	光物理層モニタとその課題	16
2.5	プログラマブル光送受信器とその課題	18
2.6	むすび	19
第 3 章	深層学習を用いた光電場の状態推定	20
3.1	はじめに	22
3.2	深層学習とは	23
3.3	深層ニューラルネットワーク	25
3.3.1	深層ニューラルネットワークのアーキテクチャ	26
3.3.2	全結合型深層ニューラルネットワーク	28
3.3.3	畳み込みニューラルネットワーク	30
3.4	深層ニューラルネットワークの訓練	33
3.4.1	深層ニューラルネットワークの出力層と損失関数	34
3.4.2	ミニバッチ確率的勾配降下法によるパラメータの更新	36
3.4.3	適応的な学習率	37

3.4.4	誤差逆伝播法	38
3.5	汎化	39
3.5.1	正則化	40
3.5.2	バッチ正規化	42
3.5.3	データ拡張	43
3.6	光モニタリングの先行研究	44
3.6.1	OSNR モニタリング	45
3.6.2	変調方式およびシンボルレートのモニタリング	47
3.6.3	波長分散量のモニタリング	49
3.7	深層ニューラルネットワークを用いた光モニタリング	51
3.7.1	深層ニューラルネットワークを用いた光モニタリングの訓練と推論	53
3.8	実験系	55
3.8.1	本研究で用いた深層ニューラルネットワーク	55
3.8.2	データ収集用実験系	57
3.8.3	データ拡張	59
3.9	結果と考察	60
3.9.1	OSNR の推定	60
3.9.2	波長分散量の推定	69
3.9.3	変調方式・シンボルレート識別	72
3.10	むすび	74
第 4 章	光送受信器を用いた光電場の制御	75
4.1	はじめに	77
4.2	プログラマブル光送受信器の先行研究	77
4.3	AoPot の概要	79
4.3.1	誤り訂正部における処理遅延の制御	80
4.3.2	デジタルコヒーレント光送受信ハードウェア	80
4.3.3	デジタル信号処理部	82
4.3.4	パラメータ設定部	84
4.4	評価実験系	88
4.5	実験結果と考察	90
4.5.1	光送受信器の不完全性指標の評価	90

4.5.2	処理遅延と誤り訂正の関係評価	91
4.5.3	ユースケース環境下での DSP/FEC パラメータ推定	94
4.5.4	ユースケース環境下でのシステム特性の確認	97
4.6	むすび	99
第 5 章	結論	100
5.1	本論文の主たる成果	102
5.2	今後の課題と展望	102
5.2.1	モニタリングの精緻化	103
5.2.2	モニタリングの抽象化	104
5.2.3	モニタリングの適応化	105
謝辞		106
参考文献		107
発表文献		119

目次

1.1	(a) 伝統的な光ファイバ受信システムの概念図, (b) デジタルコヒーレント受信システムの概念図	5
1.2	本論文の構成	6
2.1	通信サービスの多様化	10
2.2	デジタルコヒーレント技術の要素	13
2.3	モニタリングベース光ネットワークを用いた運用管理の高度化	15
2.4	運用管理の高度化によるシステム性能向上の手順	15
2.5	従来の光物理層モニタに用いられてきた情報処理手法と本論文の手法	17
3.1	人工知能と機械学習および深層学習の関係図	24
3.2	(a) 従来型の「浅い」機械学習の処理パイプライン、(b) 深層学習の処理パイプライン	25
3.3	深層ニューラルネットワークによる演算	27
3.4	全結合型ニューラルネットワークの概念図	28
3.5	全結合型ニューラルネットワーク中のニューロン (ユニット) の概念図	29
3.6	Rectified linear unit(ReLU) 関数	29
3.7	畳み込みニューラルネットワークの概念図	30
3.8	ドロップアウトによる複数の部分ネットワークの構成	41
3.9	光モニタリングの概念図	44
3.10	4/16/64QAM コンステレーション	48
3.11	深層ニューラルネットワークを用いた光モニタリング	52
3.12	訓練モードでの深層ニューラルネットワークを用いた光モニタ	54
3.13	推論モードでの深層ニューラルネットワークを用いた光モニタ	54

3.14	実験で用いられた深層ニューラルネットワーク：(a)OSNR 推定向け全結合型ニューラルネットワーク，(b) OSNR および残留波長分散量推定向け畳み込みニューラルネットワーク，(c) 変調方式およびシンボルレート識別向け畳み込みニューラルネットワーク．	56
3.15	実験系. LD：レーザーダイオード，EDFA：エルビウム添加ファイバ光増幅器，VOA：可変光減衰器，ASE：自然放射増幅光源，OBPF：光バンドパスフィルタ，DAC：デジタル・アナログ変換器，InP IQM：インジウムリン・ベース IQ 光変調器，ADC：アナログ・デジタル変換器.	58
3.16	FC-DNN による OSNR 推定結果. 訓練データ数：5,000，赤色菱形点：訓練データセット，青色丸点：テストデータセット. 半透明の範囲は標準偏差を表す.	61
3.17	FC-DNN による OSNR 推定結果. 訓練データ数：50,000，赤色菱形点：訓練データセット，青色丸点：テストデータセット. 半透明の範囲は標準偏差を表す.	61
3.18	FC-DNN による OSNR 推定結果. 訓練データ数：500,000，赤色菱形点：訓練データセット，青色丸点：テストデータセット. 半透明の範囲は標準偏差を表す.	62
3.19	CNN による OSNR 推定結果. 訓練データ数：5,000，赤色菱形点：訓練データセット，青色丸点：テストデータセット. 半透明の範囲は標準偏差を表す.	63
3.20	CNN による OSNR 推定結果. 訓練データ数：50,000，赤色菱形点：訓練データセット，青色丸点：テストデータセット. 半透明の範囲は標準偏差を表す.	63
3.21	CNN による OSNR 推定結果. 訓練データ数：500,000，赤色菱形点：訓練データセット，青色丸点：テストデータセット. 半透明の範囲は標準偏差を表す.	64
3.22	FC-DNN および CNN による OSNR 推定のバイアス誤差. 赤色丸点：FC-DNN，青色菱形点：CNN.	65
3.23	FC-DNN および CNN による OSNR 推定の標準偏差. 赤色丸点：FC-DNN，青色菱形点：CNN.	66

3.24	CNN による OSNR 推定. (a) 16 GBd DP-QPSK データによる訓練、(b) 14 GBd DP-QPSK データによる訓練、(c) 14 GBd/16 GBd DP-QPSK 混合データによる訓練. 赤色 : 14 GBd DP-QPSK による評価結果、青色 : 16 GBd DP-QPSK による評価結果.	67
3.25	14 GBd 信号を入力した際の訓練済み CNN による OSNR 推定結果. (a) DP-QPSK, (b) DP-16QAM, (c) DP-64QAM.	67
3.26	16 GBd 信号を入力した際の訓練済み CNN による OSNR 推定結果. (a) DP-QPSK, (b) DP-16QAM, (c) DP-64QAM.	68
3.27	0, 5000, 10000, 20000, 30000, 40000, 50000 ps/nm の波長分散を付加した 16 GBd DP-64QAM 信号に対する訓練済み CNN の OSNR 推定結果	69
3.28	波長分散推定タスクを学習した際の訓練損失および検証損失の変化 . . .	70
3.29	訓練済み CNN による波長分散量の推定 (0–1500 ps/nm)	70
3.30	訓練済み CNN による波長分散量推定結果の誤差 (0–1500 ps/nm). 半透明の領域は標準偏差を示す.	71
3.31	訓練済み CNN による波長分散量の推定 (-2000 – +2000 ps/nm) . . .	71
3.32	訓練済み CNN による変調方式・シンボルレート識別の混同行列 (訓練データ)	72
3.33	訓練済み CNN による変調方式・シンボルレート識別の混同行列 (テストデータ)	73
3.34	訓練済み CNN による変調方式・シンボルレート識別精度の OSNR 依存性	74
4.1	アプリケーション指向型光送受信器の概念図	79
4.2	光送信器の概念図	80
4.3	光受信器の概念図	82
4.4	送信側デジタル信号処理のブロック図	83
4.5	アプリケーション指向光送受信器におけるサブチャネルの配置	84
4.6	受信側デジタル信号処理のブロック図	85
4.7	光モニタリングと連動した光送受信器の概念図	85

4.8	実験系. VOA: variable optical attenuator, LD: laser diode, FE: front end, CPL: coupler, ASE: amplified spontaneous emission source, PD: photodiode, DAC: digital to analog converter, InP-IQM: Indium Phosphide-based IQ modulator, ADC: analog to digital converter, SC: sub-channel, CW: continuous-wave, GB: guard-band, LLR: log-likelihood ratio.	89
4.9	DP-4QAM, DP-16QAM, DP-64QAM のコンステレーション (片偏波のみ示した)	90
4.10	各変調方式の OSNR 対 BER 測定結果	91
4.11	光パワー配分比率を変化させた際の光スペクトラム	92
4.12	光パワー差 2 dB 時の OSNR 対 BER 測定結果	92
4.13	光パワー差 4 dB 時の OSNR 対 BER 測定結果	93
4.14	光パワー差 6 dB 時の OSNR 対 BER 測定結果	93
4.15	各復号繰り返し数での誤り訂正前 Q 値対誤り訂正後 BER	94
4.16	復号繰り返し数 対 所要誤り訂正前 Q 値	95
4.17	光パワー配分比 対 Q マージン	97
4.18	パラメータ最適化有無での OSNR 対 誤り訂正後 BER の変化 (Back-to-back)	98
4.19	パラメータ最適化有無での OSNR 対 誤り訂正後 BER の変化 (40 km 伝送後)	99

表目次

3.1	変調方式の例	47
-----	------------------	----

第 1 章

序論

If you are lucky enough to have lived in Paris as a young man, then wherever you go for the rest of your life, it stays with you, for Paris is a movable feast.

E. Hemingway, *A Moveable Feast*,
1964

1.1 本論文の背景と目的

2006年は偶然にも、当時ほとんど接点のなかった2つの分野が、同時に転換を迎えた年であった。その一つは機械学習、もう一つは光ファイバ通信である。十余年の年月を経た2つの分野は、今度は偶然ではない接点を持ちつつある。

光ファイバ通信を研究する多くの者にとって、2006年はコヒーレント通信 [1,2] がリバイバルした年として記憶されているだろう [3,4]。半導体技術の発達は、従来のコヒーレント通信では難しかった信号・局発光間の位相同期をデジタル信号処理により解決することを可能にし、光ファイバ通信における高多値変調の利用と、波形劣化のデジタル信号処理による等化への道を開いた [5,6]。デジタルコヒーレント光受信器は、光信号をデジタルデータに変換し、専用に設計された集積回路 (Application Specific Integrated Circuit: ASIC) 上で変復調および等化のデジタル信号処理を行っている。デジタルデータ上で数値的に表現された光電場には、理論上、どのような操作でも可能である。そのため、従来は光領域で行われてきた光電場の操作 (波長分散補償、偏波モード分散補償、復調処理……) は、そのほとんどがデジタル領域へと移動した [7]。デジタル領域への移動は、光ファイバ伝送路の大きな特徴である非線形性の補償にまで及んでいる [8,9]。

2006年は同時に、ニューラルネットワークが深層ニューラルネットワーク (Deep Neural Network) としてリバイバルした年でもあった [10]。従来のニューラルネットワークより多数の層を持つこのニューラルネットワークは、この10年で最も成功した機械学習 (Machine Learning) [11] フレームワークのひとつである。今日、深層ニューラルネットワークは、碁の打筋を見つけ出すこと [12] から、カメラからの画像を認識して自動車を運転すること [13] まで、様々なことに応用されている [14]。深層学習の成功の理由は、いまだ未解明の部分が多い。しかしながらアルゴリズムの改良に加えて、学習に必要な大量のデータが手に入るようになったこと、強力なコンピューティングパワーが安価に手に入るようになったことが、深層学習が可能になった主要な理由であることは間違いない。

本論文では、リバイバルを経たこの二つの領域、すなわちデジタルコヒーレント光ファイバ伝送と、深層学習を結びつけることを試みる。しかしながら、なぜ今、この二つの領域が結び付くのだろうか？ その答えは、巨大なデータの存在である。

両者を結び付ける巨大データは、デジタル空間上の数値データとして表された「仮想的」光電場データである。最新のデジタルコヒーレント光送受信器は、数十 GSample/sec の速度で、受信した光電場をデジタルデータに変換している。これは、

おそらく現在の世界で最も高速に動作するアナログ・デジタル変換システムのひとつであろう。通常のデジタルコヒーレント受信器は4つのアナログ・デジタル変換器 (Analog-to-digital converter: ADC) を備える。各々のADCのビット精度が8 bitであり、サンプリングレートが64 GSample/sという標準的な構成を考えたとしても、このたった1台の受信器は、毎分15 TBのデータを生成している。そしてこの人差し指ほどの大きさのデジタルコヒーレント受信器は、現代の光ネットワーク上に多数設置されているのである。

これは、明らかに伝統的な光ファイバ伝送システム、例えば On-off keying (OOK) を用いた 10 Gbit/s/λ 高密度波長分割多重 (Dense wavelength division multiplexing, DWDM) システムとは異なる。この様子を、図 1.1 に示す。デジタルコヒーレント以前の伝統的システムでは、波長分散補償などの処理はすべて光領域で行われ、その後、光信号がデジタルデータに変換された。そこで我々が得るのは、ある閾値で 0/1 に変換された送信ビット列の復元のみであった。しかしデジタルコヒーレント技術の導入により、状況は変化した。光電場は波長分散補償などの処理に先立って、アナログ・デジタル変換器によって、ある解像度 (例: 8 bit=256 諧調) を持ってデジタルデータに変換される。ここで得られるのは、送信ビット列の単なる復元ではない。これは、光ファイバや光増幅器、その他の光機器を通過して受信器にたどり着いた光電場そのものの写像である。

実世界から計算機上の世界に写像されたこの巨大な光電場データは、デジタルコヒーレント光送受信と深層学習という二つの領域が融合する未来を拓く鍵となり得る。というのも、深層学習を利用可能にし得る前提条件の一つが、巨大でデジタル化された訓練データの存在だからである。深層学習では一般に、従来の機械学習アルゴリズムと比較して桁違いに大量の例示データが学習に必要といわれる。従来の光ネットワーク上では、深層学習の訓練に十分な量の、光電場に関するデータを安価に収集することは困難であった。しかしながら、この状況は変わりつつある。2006 年の最初の実証から間をおかず、2010 年前後には実用的なデジタルコヒーレント方式光送受信器が開発され、基幹系光ファイバネットワークを中心に導入が始まった。今日では多数のデジタルコヒーレント受信器がネットワーク上に配備されている。デジタルコヒーレントへの置き換えは現在、より短距離のシステムにも順次進展している。

今日は、デジタルコヒーレント方式の普及により、光ネットワーク上を流れる光電場が、日常的に計算機上の光電場へと写像され、処理されるようになった初めての時代である。この巨大デジタルデータとしての光電場が、巨大訓練データの存在を前提とする深層学習の、光通信ネットワーク分野における利用を拓きつつある。

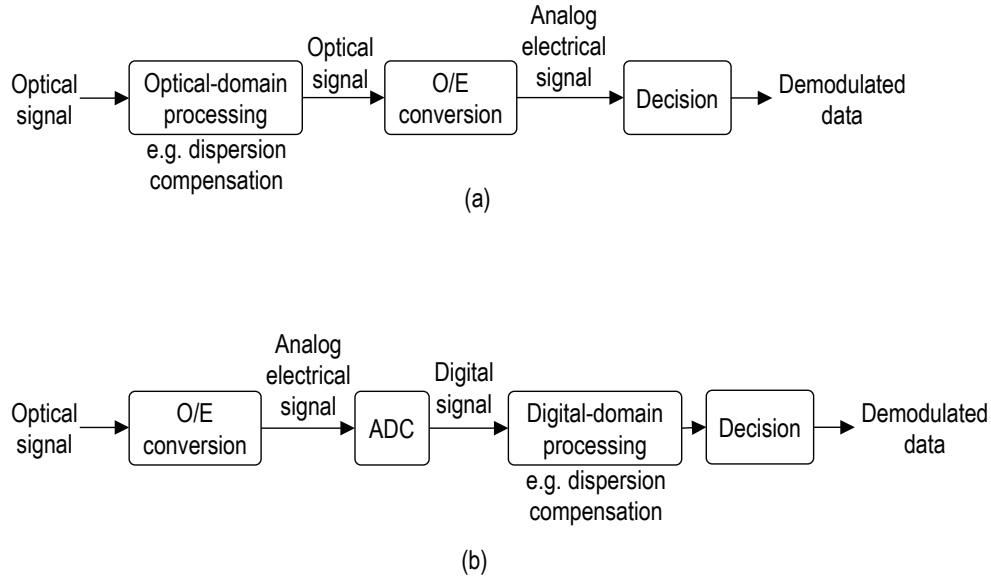


図 1.1 (a) 伝統的な光ファイバ受信システムの概念図, (b) デジタルコヒーレント受信システムの概念図

1.2 本論文の構成

本論文の具体的な構成は次の通りである。

第 1 章 序論

第 2 章 デジタル化された光電場の状態推定と制御

第 3 章 深層学習を用いた光電場の状態推定

第 4 章 光送受信器を用いた光電場の制御

第 5 章 結論

図 1.2 は、これらの各章の関係を表したものである。本論文の流れを簡単に説明すれば以下のようなになる。

第 1 章では、巨大デジタルデータとしての光電場を媒介にして、深層学習とデジタルコヒーレント技術が結びつくことを述べた。第 2 章では、深層学習とデジタルコヒーレント技術の結びつきが、光ファイバネットワークにおける知的な柔軟性の増大をもたらし、これがクラウド上での多様なアプリケーションの実行を支えることを明らかにする。続く第 3 章では、深層学習（深層ニューラルネットワーク）を用いて、デジタル化

された光電場の状態を推定し、その要約的記述を取り出すことを試みる。具体的には、14 GBd および 16 GBd DP-QPSK, DP-16QAM, DP-64QAM で変調された光信号をデジタル化して深層ニューラルネットワークに入力し、OSNR、波長分散量、変調方式およびシンボルレートを取り出せることを実験的に検証する。このとき、使用した深層ニューラルネットワークを用いたモニタリングスキームは、人手によるアルゴリズムの構築や特微量の選択を必要としないことを示す。第4章では、光電場の状態推定で得られた情報を基に光送受信器を制御する試みについて述べる。深層ニューラルネットワークを用いて推定された伝送路の状態と、物理層での処理遅延を含むクラウドサービス毎の伝送要件の双方を満たす光信号を、光送受信器の制御により生成・受信可能なことを実験的に示す。第5章にて、本論文の結論と今後の展望を述べる。

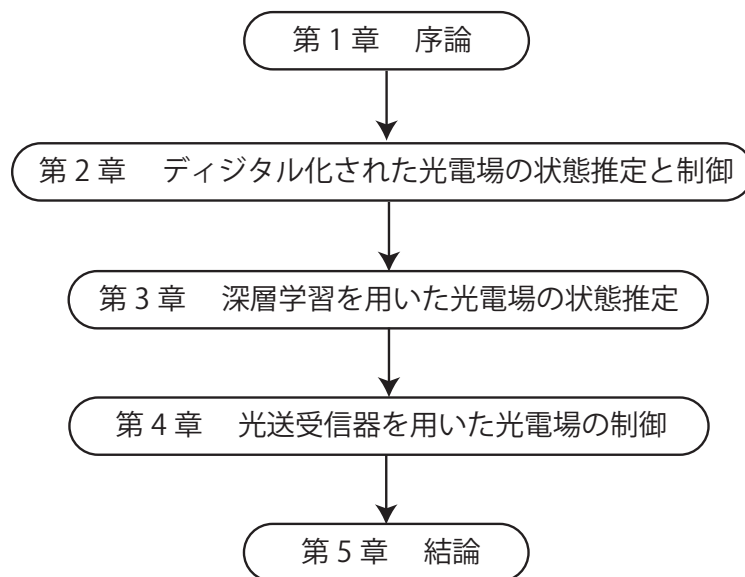


図 1.2 本論文の構成

第2章

デジタル化された光電場の状態推定と制御

More is different.

P. W. Anderson, 1972

2.1 はじめに

第1章では、巨大デジタルデータとしての光電場を媒介にして、深層学習とデジタルコヒーレント技術が結び付くことを議論した。では、この結びつきは、どのような利点を我々にもたらすのであろうか。

本章では、この問いに答えるため、将来における光ファイバネットワークの発展方向を論じ、その際の課題について議論する。まず、近年のクラウドサービスの多様化が、これを支える光ファイバネットワークのプログラマブル化と運用管理の高度化を要求することを概説し、その際、モニタリングと機能制御が重要な要素となることを述べる。そして、プログラマブル化した光ネットワークにおいて、人手による処理なしで新たな種類のモニタを追加可能なモニタリング・フレームワークと、処理遅延を制御可能な光送受信器が、将来光ファイバネットワークにおける自律性の高い運用管理を実現する上での技術課題であることを述べる。最後に、モニタリング機構への深層学習技術の導入と、光送受信器における誤り訂正を含むデジタル信号処理の制御が、これらの技術課題を解決することを示す。

2.2 ネットワーク上を流れる情報の大容量化と多様化

光ネットワーク上を流れる情報量は、絶え間なく増大している。Cisco Visual Networking Index [15] によれば、2015年にIPトラフィックは1 ZB (Zetta= 10^{21}) を上回った。2017年の現在では、このトラフィックは1.4 ZBに達しているはずである。この増加するトラフィックを収容するために、新しい光ファイバ伝送技術が次々と開発され、ネットワークとして展開されている。^{*1}

一方で、ネットワーク上を流れるデータはその量を増加させるだけでなく、その質も変化させている。初期の光ファイバネットワークは、主にデジタル化された電話回線を多重し伝送するという単一サービスに対して設計されていた。その後、光ファイバネットワークは、地理的に離れたコンピュータ間での情報交換にも用いられるようになった。これはインターネットを生み出し、数多くのネットワーク・サービスを生み出した。我々は

^{*1} 伝送容量の非線形シャノン限界 [16] に近づくため、変調方式、符号化、波形等化手法の改善が盛んに研究されている。非線形シャノン限界とは、ファイバフェーズ [17] による光ファイバ1コアあたりに導入可能な光パワーの上限と光ファイバの非線形性、および情報理論によって規定される光ファイバ1コア当たりで伝送可能な容量の理論限界である。また、1コア当たりの非線形シャノン限界を乗り越えファイバ1本当たりの伝送容量を上昇させるため、光ファイバのマルチコア化 [18] が研究されている。

今日、eメール、Text messaging、web ブラウズなどのサービスを日常的に利用している。現在では、コンピュータによる情報交換と情報処理の一体化が進み、クラウドと呼ばれる、情報処理を手元の端末と、ネットワークの「雲」の向こうにある大規模データセンタで分割処理する機構が作り上げられている。

近年、クラウド上においては、従来型サービスに加え、拡張現実 (Augmented Reality: AR) ゲーミング、HD ビデオカンファレンス、触覚 (Tactile) インターネット、Connected vehicles safety applications などの次世代サービスの普及が準備されつつある。これら実世界とのインタラクションを含む新しいタイプのサービスでは、実世界との相互作用を円滑に行うため、ネットワークのスピードだけでなく、レイテンシの低減と保証が重要な要件となる [19]。このような低遅延性を含むサービスの見取り図を、図 2.1 に示す。

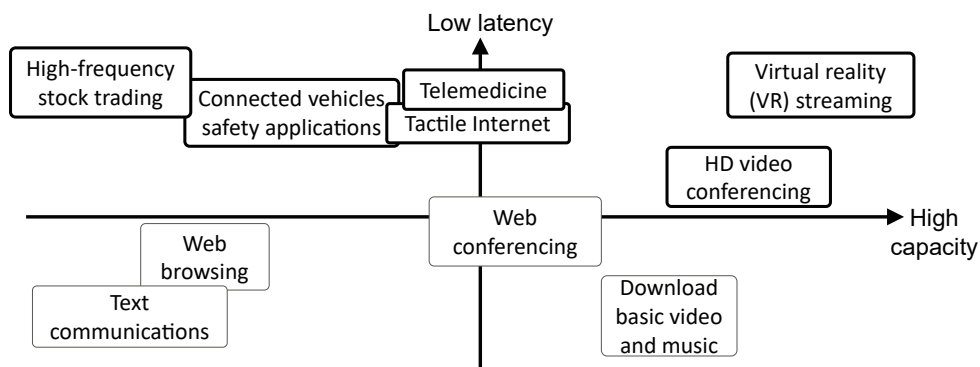


図 2.1 通信サービスの多様化

レイテンシの低減をサポートするため、伝送路を短距離化し、なるべくユーザーに近いエッジサイドで情報を処理する流れが加速している。北米においては、2021 年には、総トラフィックの半分以上が、regional-backbone や cross-country backbone を経由しない、都市内だけで完結する通信になると予測されている（この都市内で完結する通信の割合は、2016 年においては 35% に過ぎなかった） [15]。

これらをまとめると、クラウド上で実行される多様なサービス群は、各々に適した通信速度と遅延、もしくはその両方をネットワークに要求する。また、これらクラウドサービスのなかでも特に大規模かつミッションクリティカルなものは、通信速度と遅延要件を保証するため、複数のネットワーク技術領域にわたるエンドツーエンドのサービス実行を必要とするだろう。そのため、光ネットワークがサポートすべき通信要件も、同時に多様化すると見込まれる。これらの要件を実現するため、将来の情報伝送（光ファイバネットワーク）は、情報処理（コンピューティング）と、より密接に連携しながら、精密に制御

される必要があると見込まれる。

2.2.1 光送受信器の大容量化技術

初期の光ファイバ通信においては、情報の1と0はレーザーのOnとOffとして符号化され(On-Off Keying: OOK)、物理メディアとしての光ファイバ上を伝播した。光ファイバの低損失と、レーザーの発振周波数の高さが、光ファイバ通信による大容量かつ長距離の情報伝送を実現した。エルビウム添加光ファイバ増幅器(Erbium Doped Fiber Amplifier: EDFA)の発明による広帯域一括増幅は、この利点をさらに増幅させた。これにより我々の社会では、人々が長大な距離(例えば太平洋)で隔てられた場合であっても、低廉な価格で互いにコミュニケーションをとることが可能になった。しかしながらこの場合、光伝送システムが実現した大容量は、主にレーザーの発振周波数(キャリア周波数)の高さと、EDFAの増幅帯域の広さ(C帯でおおよそ4 THz)に依っていた。伝送システムの性能指標の一つとして、周波数帯域1 Hzあたりに送れるビットレートを示す、周波数利用効率(Spectral Efficiency: SE)があるが、OOKではこの値は、例えば50 GHz 波長多重間隔 10 Gbit/s Non-Return-to-Zero On-Off Keying (NRZ-OOK)で、0.2 bit/s/Hzに過ぎなかった。

波長多重技術の進展とともに、広大と思われた光ファイバ通信の利用可能帯域(例えばEDFAの増幅可能帯域)にも限界が見え始めた。そのため、デバイスとしてのレーザーの性能(例:位相雑音、周波数安定性)の改善とともに、周波数利用効率の上昇が新たな課題として立ち上がった。例えば、遅延干渉計を用いた差動検波方式が一部システムに用いられた。これは光の位相に情報をコードする方式であり、複数の位相状態を識別することで、従来より周波数利用効率を上昇させることが可能である。例えば、差動4値位相変調(Differential Quadrature Phase Shift Keying, DQPSK)を用いたシステムは、実用システムで0.8 bit/s/Hz(50 GHz 波長間隔 40 Gbit/s 信号)の周波数利用効率を達成した。

半導体技術の急速な発展とともに、2006年にデジタルコヒーレント受信による光電場のデジタル化がデモンストレーションされると、この技術の恩恵により、周波数利用効率は急激な上昇を見せる。初期のデジタルコヒーレントは、光の位相を4値を分割した4値位相変調(Quadrature Phase Shift Keying: QPSK)に加え、光波の偏波自由度—水平(Horizontal: H)偏波と垂直(Vertical: V)偏波—を用いることで、最大4 bit/s/Hz(実用上は50 GHz 波長間隔 100 Gbit/s 信号で2 bit/s/Hz)の周波数利用効率を達成した。信号変調に光偏波を組み合わせる方法は、偏波多重(Dual Polarization: DPあるいはPolarization-Division Multiplexing: PDM)とよばれる。

これらデジタルコヒーレント技術による大容量化の理由は、光電場を直接操作することよりも、デジタルコヒーレント方式によりデジタル化された光電場を操作することが、格段に容易であったためである。特に光領域では難しかった偏光回転への（無限）追従と偏波モード分散（Polarization Mode Dispersion: PMD）の補償をデジタル領域で行えたことは、特筆に値する。その後、短期間で、ナイキストパルス整形による波長多重間隔削減、位相と振幅を組み合わせた直交振幅変調（Quadrature Amplitude Modulation: QAM）等の技術が相次いで導入された。これにより、例えば Nyquist-DP-16QAM を用いることで最大 8 bit/s/Hz、Nyquist-DP-64QAM を用いることで最大 12 bit/s/Hz 等の高い周波数利用効率が達成されるようになった。また、デジタルコヒーレント技術は、これら直交振幅変調のみならず、偏波や隣接シンボルも合わせた多次元変調 [20,21] をも可能にした。

2.2.2 光送受信器のフレキシブル化技術

光ファイバ通信におけるフレキシブル化は、まず ROADM（Reconfigurable optical add/drop multiplexer）[22–24] に代表される光ノードのフレキシブル化から始まり、次に光送受信器のフレキシブル化へと進んだ。周波数利用効率の向上と同様に、光送受信器に柔軟性を持たせる際にも、デジタルコヒーレント技術は、大きな役割を果たした。というのも、デジタルコヒーレント光送受信機においては、物理要素として同一の光・電気ハードウェアを用いたまま、プログラマブル要素である送信および受信側の DSP を変更することで、1 台の送受信器で複数の変調方式を切り替えて用いることが可能だからである [21,25–32]。^{*2}

図 2.2 に示すように、現代的なデジタルコヒーレント送受信器は 3 つの要素に分解できると考えられる。

最初の要素は物理要素で、これは共通ハードウェアとしてデジタルコヒーレント送受信器の基盤となる要素であり、後述するプログラマブル要素の指示に従って任意の光電場状態を作り出し、また任意の光電場状態の持つ情報を計測するものである [5]。送信側において一般的に用いられる、偏波多重 IQ 変調器とデジタル・アナログ変換器（Digital-to-Analog Converter: DAC）の組み合わせは、理論上^{*3}、DAC や変調器の帯域内で任意の光電場の生成を可能にする。また光受信器における偏波ダイバーシティ光

^{*2} これら光送受信器のプログラマビリティは、伝送情報の多様化に対応するための鍵となると同時に、ネットワークの容量の増加にも用いられている [33,34]。

^{*3} DAC の量子化雑音や変調器の消光比などが十分に小さいと仮定した場合

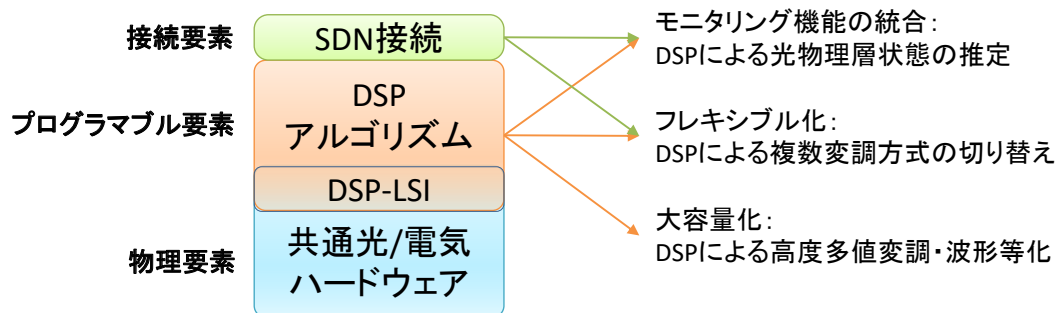


図 2.2 デジタルコヒーレント技術の要素

ハイブリッドとフォトダイオード（Photo Diode: PD）、アナログ・デジタル変換器（Analog-to-Digital Converter: ADC）の組み合わせは、ADC とフォトダイオードの帯域内の光電場のすべての物理量（位相・振幅・偏波）の測定を可能にする*4。これは、ある帯域内においては、どのような光送受信器も原理的には共通のハードウェア上でエミュレーション可能であることを意味する [5]。

次の要素はプログラマブル要素で、その主たるものは、受信し測定されたデジタルデータから、もとのデータを取り出すデジタル信号処理（Digital Signal Processing: DSP）のアルゴリズムである [7]。主変復調処理アルゴリズムと協調して動作する、受信信号の状態をモニタリングする各種アルゴリズムもこの要素に含まれる [35]。アルゴリズムを実際に動作させる集積回路（Large-Scale Integrated circuit: LSI）は、物理要素とプログラマブル要素の中間に位置する。理想的には、この LSI は任意のデジタル信号処理アルゴリズムを実行できることが望ましいが、光送受信器に求められる高速動作*5を実現するため、一般には特定アプリケーション向けにカスタマイズされた集積回路（Application Specific Integrated Circuit: ASIC）が用いられることが多い。この場合でも、ASIC に多数の動作モードを持たせ、また DSP アルゴリズムに与えるパラメータを可変にすることで、ある程度のプログラマビリティが実現される。

第 3 の要素は接続要素で、これは狭い意味でのデジタルコヒーレント技術には含まれない。しかしながら、この要素は、デジタルコヒーレント技術の持つプログラマビリティを活用するために、無視できない要素である。接続要素は具体的には、有線もしくは

*4 ADC の量子化雑音や、局発/送信光源の位相雑音が十分に小さいと仮定した場合

*5 例えば 25 GHz のシンボルレートを持つ信号を標本化定理を満たすため 50 GSa/s のサンプリングレートと 8 bit の解像度を持つ 4 基の ADC でサンプリングする場合、後続の LSI は少なくとも、200 GB/s 以上の処理速度を持たなければならない

無線通信を介して、デジタルコヒーレント送受信器の持つプログラマブル要素をコントロールするための機能である。もっとも一般的な接続要素は、デジタルコヒーレント通信器が受け持つ主たる伝送ネットワークとは異なる制御用ネットワークを介して、特定のプロトコル、例えば OpenFlow [36] でコントローラと接続するための要素である。しかしながら接続要素の実現形態はこれに限らず、例えば主信号に重畳された低速制御信号 [37, 38] も接続要素とみなせる。いずれにしても、デジタルコヒーレント送受信機のプログラマブル要素は、接続要素を介して変更可能となるよう設計される。

これらの三要素を用いることで、デジタルコヒーレント送受信器はプログラマビリティを発揮する。具体的には、接続要素を介して得た上位レイヤからの指示に従い、プログラマブル要素に設定されるパラメータを変更することで、送受信器全体の動作モードを変更する。

2.3 モニタリングベース光ネットワーク

光ファイバネットワークの各要素がプログラム可能となると、ネットワーク上には、多くの種類の光信号が共存し、全体では、複雑で異質な伝送環境が形作られることになる。またファイバ中の非線形効果により、新しく配置される伝送チャネルは従来のチャネルと相互に劣化を生じることから、問題はより複雑なものとなる。ネットワークの保守運用費 (Operational Expense: OPEX) 削減圧力がますます高まりつつある今日では、このような複雑な環境を人間の管理者によって管理することは、運用のスピード、正確性、コストの面から、徐々に難しくなりつつあるといえる。そのため、モニタリングをベースにした光ファイバネットワークの自律的制御が検討され始めている。

一般的に、サービスに合わせ光ネットワークを調整し、光資源を有効に活用するには、(1) 現在の光ネットワークの状態を認識し、(2) 目的に合わせて光ネットワークの状態を制御する、ことが必要となる。光ネットワークの状況を on-demand に認識するため、各種の光物理層状態モニタリングを行い、その結果を用いて、光ネットワークを制御するモニタリングベースのダイナミック光ファイバネットワークの研究がなされている。一般化されたモニタリングベース光ファイバネットワーク制御の概念を、図 2.3 に示す。これは、モニタリング (観測)・判断・機能制御の 3 要素からなり、これらの要素の順次実行ループを繰り返すことで、個々の伝送路の現状を推定し、その現状に合わせて光通信機器を制御する [39, 40]。

具体的には、文献 [41] で、光ネットワークにおけるクロスレイヤ最適化とアクティブ制御機能のモニタリング情報が検討されている。また、BER をモニタリングすることで、

2.3 モニタリングベース光ネットワーク第2章 デジタル化された光電場の状態推定と制御

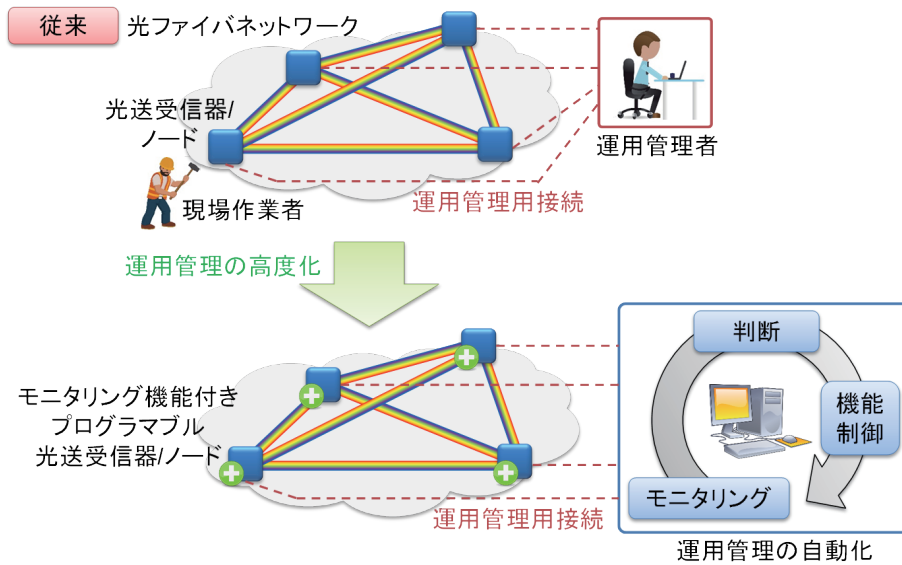


図 2.3 モニタリングベース光ネットワークを用いた運用管理の高度化

光パスレベルの性能から、マージンを削減した運用限界を学習することが検討されている [42]。光パフォーマンスモニタリング技術によって、コグニティブ光ネットワーク [43]、コグニティブ SDN オーケストレーション [44]、オンデマンド制御プレーン機能 [45] をサポートすることも検討されている。




図 2.4 運用管理の高度化によるシステム性能向上の手順

これら運用管理の高度化によるシステム性能向上の手順を抽象化すると、図 2.4 のようになる。この手順の最もシンプルな例のひとつとして、システムの初期マージン活用があげられる。現在の光通信システムにおいては、機器の老朽化による性能低下を見込み、十分な設計余裕（マージン）を持った設計がなされている。システムの初期時に、これらの設計マージンを活用してベストエフォートでの容量増大が可能かの検討が行われている。具体的には、最初に物理層の状況からマージン量を推定するモニタリングを行い、このモニタリング結果に基づいて、光送受信器の伝送レート調整する機能制御を行うことで、システム性能の改善（伝送容量の増大）が達成される。この例ではシステム性能改善指標として伝送容量の増大が検討されているが、これに限らず、システム性能向上は様々な面か

ら図られる。そのため、個々の状況に合わせて、多種のモニタリングと機能制御を組み合わせることが重要となる。しかしながら、モニタリングベース・ネットワーク制御の従来の研究は、固定的なモニタ機能を用いた、特定のユースケースに焦点を当てていた。言い換えると、多様化するサービスに合わせた光ネットワークの分析を行うために、必要な種類の物理層モニタリングを必要な時に提供する、一般的なフレームワークについての議論が欠けていた。より具体的には、これら従来研究において、物理層モニタは特定のアプリケーションに向けて準備された固定的な種類のもので、物理層モニタそれ自身は柔軟性を有していなかった。時節では、この課題の詳細を分析する。

2.4 光物理層モニタとその課題

従来の光物理層モニタリングは、光測定部で得たデータに光ファイバ層における物理現象の知識を基にしたデータ処理を行い、モニタ値を得ていた。データ処理部には、モニタ対象に応じて、エンジニアにより考案されたアルゴリズムが実装されていた。こうした光モニタは、設計者が与えた固定的な処理を行うことができるが、新たな環境やデータに適応する柔軟性に欠けている。

光モニタに柔軟性を与えるため、機械学習のアルゴリズムを用いて、処理アルゴリズムを手でプログラミングするのではなく、データから学習する手法の研究がなされてきた。これらの研究は、機械学習アルゴリズムによって、データから各種のモニタ量（例：OSNR, 変調方式）をモニタリングする手法を自動学習することが可能であることを示したが、基本的には、事前に特徴量設計、あるいは特徴量選択と呼ばれる手動の情報処理が必要であった。たとえば、[46]においては、OSNRの推定に有用と思われる量として事前に、アイダイアグラムから求めた、Q-factor, eye closure, root-mean-square (RMS) jitter, crossing amplitude を選択し、これを機械学習アルゴリズムに与える特徴量とすることが提案されている。その他にも、変調方式や条件に合わせ、各種の特徴量が手動で設計され、提案されてきた [47-51]。この様子を、図 2.5 に示す。

これら従来方法の限界は、機械学習アルゴリズムの学習の前に、適用ドメイン（この場合は光通信工学）の知識を持った人間のエンジニアが、目標とするモニタ量を良く説明するであろう成分（特徴量）を手動で同定し、計算する点である。このことは本質的に、目標モニタ量や周辺環境の変化が起こる度に、選択した特徴量が適しているかを再検討しなければならないことを意味し、スケーラビリティの欠如を示唆する。また、人間のエンジニアが、良い特徴量を設計できないほど複雑な量のモニタができないことも示唆している。

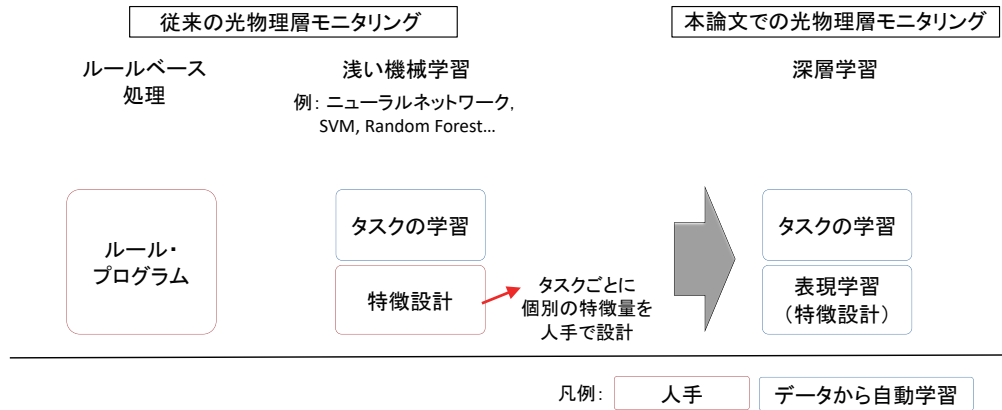


図 2.5 従来の光物理層モニタに用いられてきた情報処理手法と本論文の手法

なお、この課題を一部解決する検討が、[52, 53] で行われた。この論文では、パターン認識（基準特徴量ベクトルからのユークリッド距離に応じた分類）を用いて OSNR の推定が行われているが、パターン認識の前に、主成分分析（principal component analysis）を用いることで、手動の特徴量設計に頼るのでなく、寄与の大きい特徴量を自動的に取り出すことが試みられている。しかしながら、この方法は特徴量の線形な関係を前提にしているため、測定データ間に非線形な関係がある場合への適用には、限界がある。

まとめると、より柔軟なモニタリングを可能にするため、モニタリング手順を自動的に学習する、機械学習を用いた物理層モニタリングの方式が提案されている。これらの方式は、特定の特徴量を機械学習アルゴリズムに与えることで、十分な精度でのモニタを可能にしている。しかしながら特徴量の設計はエンジニアの手動に依る場合が多く、自動的な抽出を試みた場合でも、入力データに制限のある手法が採用されていた。そのため、データ間に非線形関係がある場合も含む一般的な測定データから直接、物理量をモニタする関数を直接学習することには課題があった。

本論文の第3章では、これらの課題を解決するため、デジタル化された光電場の状態推定について論ずる。デジタルコヒーレント受信器で受信した光電場を深層ニューラルネットワークを用いた深層学習手法で処理する方法を提案し実験的に検証する。この方法は、正確なモニタリングを可能にするばかりではなく、特徴量前処理を行わない end-to-end の学習が可能である、様々なモニタ対象に適用できる柔軟性も持つことを示す。

2.5 プログラマブル光送受信器とその課題

本節では、従来行われてきたプログラマブル光送受信器研究の課題を議論する。光送受信器が用いる帯域幅と周波数利用効率に柔軟性を持たせる試みは、活発に研究されてきた [20, 21, 25–32, 54–58]。これら従来の研究に共通することは、プログラマビリティを、伝送距離とスループットの間のトレードオフを調整することに限って用いてきたことである。従来、光ファイバ通信技術は主に、光ファイバの伝送遅延自体が支配的になる長距離の伝送に適用されてきたため、レイテンシの要件は軽視されてきた。しかしながら、近年、都市内データセンタ間でのデータ交換など比較的短距離の伝送需要が増加したこと、遠隔地の機器操作や自動運転制御、遠隔データセンタ間での連携データ処理などの低レイテンシ・アプリケーションが提唱されつつあることから、レイテンシ要件が重要になりつつある。

物理層におけるレイテンシを考えると、光ファイバ伝送部を除く光電場の生成・受信における処理遅延の内、最も大きな部分のひとつを占めるのは、誤り訂正の復号演算であろう。誤り訂正の種類や復号方法にフレキシビリティを持たせることで、伝送路に合わせた最適な誤り訂正方式を選択し、物理層における遅延を最小限に抑えることができる。

このレイテンシ制約も含む多様な伝送要件を満足させるため、光送受信器の柔軟性の向上は課題である。例えば、レイテンシ削減のため復号処理遅延の低い誤り訂正を用いることができるが、この選択は一般に、誤り訂正の Net Coding Gain を減少させ、受信の際の所要信号対雑音比を増大させる。そのため、誤り訂正の変更は、その他の属性（変調方式・パワー割り当てなど）へも連鎖的に影響を与える。この連鎖を制御するためには、各動作モードの制約と現在の伝送路で得られる効用を正確に見積もることが重要である。つまり、現在の伝送路状態 s に対して、動作モード m を選択した時の効用 $u(s, m)$ の関係式が分かれば、我々はより大きな効用を得る選択肢を選ぶことができる。

第4章では、レイテンシの削減という新たな軸を含む際の、光電場の制御について述べる。レイテンシおよびその補償要素としてのパワー配分比のパラメータを組み込むことで、制御パラメータの組み合わせ数は爆発的に増大するが、伝送路状態の推定と制御パラメータ群の制約を組み合わせることで、このパラメータ組み合わせ数を削減できることを示す。また、第3章で議論した深層学習ベースの物理層モニタリングを組み合わせることで、伝送路状態とサービス要件の双方を考慮した、光送受信器の制御が可能であることを示す。

2.6 むすび

本章では、将来における光ファイバネットワークの発展方向を論じ、その際の課題について議論した。近年のクラウドサービスの多様化が、これを支える光ファイバネットワークのプログラマブル化を要求することを概説し、その際、モニタリングと機能制御が重要な要素となることを述べた。そして、プログラマブル化した光ネットワークにおいて、人手による処理なしで新たな種類のモニタを追加可能なモニタリング・フレームワークと、処理遅延を制御可能な光送受信器が、将来光ファイバネットワークにおける自律性の高い運用管理を実現する上での技術課題であることを述べた。最後に、モニタリング機構への深層学習技術の導入と、光送受信器における誤り訂正を含むデジタル信号処理の制御が、これらの技術課題を解決することを示した。

第3章

深層学習を用いた光電場の 状態推定

The Analytical Engine has no pretensions to originate anything. It can do whatever we know how to order it to perform.

Augusta Ada King, Countess of Lovelace, 1842

3.1 はじめに

長年の間、機械は予め設計された反応以外の新しい知識と技能を獲得する能力、すなわち知性を持っていない、と一般に信じられてきた [59]。これは世界で初めてのプログラマとしても知られるラブレース伯爵夫人による 1842 年の回想に現れる「解析機関には何かを発明するようなことはできない。それは私たちがどうやって行うか知っていることなら、なんでも行うことができる」という言葉に要約されよう。

しかしながら近年、機械学習 (Machine learning: ML) と呼ばれる分野が急速に進歩することで、一部の研究者の間に限らず、この認識は変わりつつある。機械学習とは、タスクに応じた特定のプログラミングをすることなく、与えられたタスクをコンピュータに実行させるための方法である [11]。これは、コンピュータ科学の一分野であり、一般に「人工知能 (Artificial intelligence: AI)」と呼ばれる分野の一部であると考えられている。

機械学習のフレームワークは、光ファイバ通信のいくつかの側面、例えば、偏波分離 [60]、非線形雑音の抑圧 [61–66]、レーザー光の位相推定 [67]、コンポーネントの挙動の同定 [64, 68]、クロストークの抑圧 [69]、そして光モニタリング [46–53, 70, 71] に応用されてきた。機械学習の光ファイバ通信への応用は、現在急速に拡大しつつある分野である。最新のサーベイは、[72] あるいは [73] に詳しい。

機械学習の手法は一般に、雑音 (あるいは抽象的に言えば非本質的情報) に塗れた測定データから、本質的情報 (あるいはユーザーにとって有用な情報) を取り出す枠組みを与える。この枠組みは、特定のプログラミングなしで動作し、システム自身や雑音の特性に関する詳細な事前知識を必要とせず、データから有用な情報を取り出すことを可能とする。

しかしながら、従来の機械学習アルゴリズムにおいては、データからタスク処理の方法を学習する手前に、特徴抽出と呼ばれる人手によりデータの特徴表現を与えるプロセスが存在する。このプロセスでは、タスクにとって重要と思われる量 (特徴量) をタスク処理に関する知識を持つエンジニアが人手でデータから抽出・設計する。こうして人間が設計し与えた表現を基に、機械学習アルゴリズムはタスクを学習・実行してきた。しかしながら、データからプログラミングなしで処理方法を学ぶ普遍的な手法を目指す場合、個々のタスクごとに人手で特徴量を設計するアプローチは、完全な方法とはいえない。

本章では、機械学習の中でも特に深層学習 [14, 74] と呼ばれる、深層ニューラルネットワークを用いた手法に焦点を当てる。深層学習では、データの表現 (特徴量の抽出) も、

データ自身から学習する^{*1}ことで、より高度なタスクの end-to-end での学習と実行を可能にする。

本章の主たる目的は、この深層学習技術の光ファイバネットワーク・モニタリングへの応用を試みることである。本論文では、光ネットワークの中でも、特に伝送、すなわち物理層のモニタリング [75-77] に焦点を当てる。これは、物理層が上位層の論理ネットワークと異なり、文字通り物理的な実体物（光ファイバ、レーザー光源、変調素子、光増幅器など）で形作られたネットワークであり、その挙動を明確なルールとして書き下すことが難しいからである。物理層においてエンジニアは、人為的に策定された通信プロトコルではなく、実際の光ファイバの曲げ、汚れ、コネクタの損傷、製造バラつきのある部品、そして物理法則に支配されたレーザー光の挙動などを取り扱わねばならない。これら現実世界の実体物を測定したデータは、さまざまな種類の雑音に塗れ、また相互に（場合によっては非線形の）影響を与え合っている。

従来のエンジニアは、これらの測定データから、システムや雑音の特性に関する事前知識、あるいは自身の経験に基づき構築した仮説をもとに、有用な情報を引き出してきた。これらエンジニアの営為をアルゴリズムに落とし込んだものは、光モニタと呼ばれる。光モニタの中には、事前知識を利用した情報処理が組み込まれ、光信号の測定データから、有用な情報（OSNR、波長分散……）を自動的に取り出す。

光モニタにおける情報処理は通常、システム自身や雑音の特性に関する詳細な事前知識に基づいて設計されたアルゴリズムによってなされる。しかしながら、もしもシステム自身や雑音の特性に関する事前知識を必要とせず、測定データから任意の有用な情報を取り出すことができれば、それは究極の汎用光モニタとなるであろう。本章では、深層学習と光コヒーレント受信を組み合わせることで、この汎用モニタが可能であることを示す。

3.2 深層学習とは

人工知能研究の初期には、形式的で明確なルールで記述できるタスクを、コンピュータで解くことが急速に進んだ。しかしながら、我々、つまり人間の知的活動および熟練した技能の多くは、このような明確なルールで記述できるタスクに留まらない。その多くは、我々が実行することはできるが、形式的にそのルールを記述することは難しい、といった種類のものである。

このようなタスクを実行するためには、ルールを明確に書き下すより、経験から学ぶア

^{*1} これは表現学習と呼ばれる

アプローチが有用と考えられる。機械学習と呼ばれる情報処理の方法論では、コンピュータはデータから学習することで人手による明示的なプログラミングなしでタスクの実行を可能にする。これにより、人間が設計し実装する固定的なプログラムでは難しい種類のタスクに取り組むことが可能になる。

本論文で焦点を当てる深層学習（deep learning）は、機械学習の一分野である。包含関係を図 3.1 に示す。

学習された挙動が、経験した事例の単なる再演に留まらず一般化を伴うには、経験を抽象化した概念の獲得と、その概念の階層化が必要と考えられる。概念をユニット間の接続で表現する、接続主義に基づく人工知能へのアプローチがニューラルネットワークであるが、その接続グラフをより深く、数多くの階層を持つものとし、階層的な概念獲得を目指すアプローチが、一般に深層学習と呼ばれる [74]。

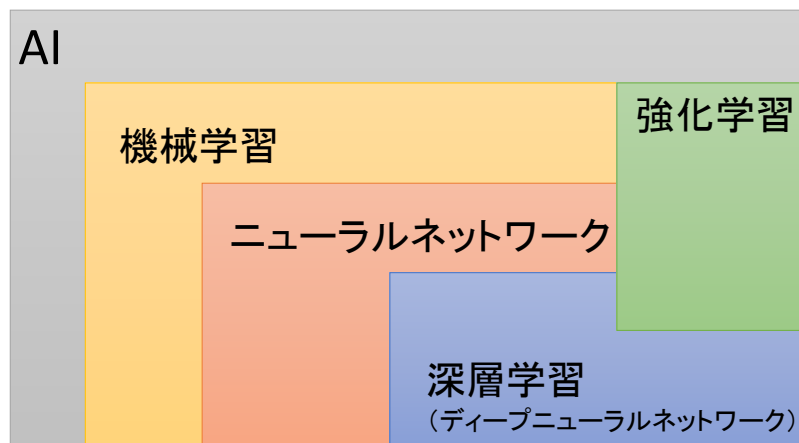


図 3.1 人工知能と機械学習および深層学習の関係図

従来用いられてきた（深層学習以外の）機械学習アルゴリズムは、その学習を、人間によって与えられたデータの表現（representation）に頼ってきた。データの表現は、特徴量（feature）とも呼ばれる。これは機械学習に用いるデータの表現形態である。一般には、生データに人間が手を加え、分析に不要な情報を落とすなどして、データの本質をうまく表現する量へと整えなおし、機械学習の精度を上げることが行われる。このような、解決すべきタスクに応じた、より良い特徴量の集合を人間のエンジニアが設計することを、表現工学（representation engineering）あるいは特徴量工学（feature engineering）とよぶ。この情報処理のパイプラインを図 3.2 に示す。事実、従来の機械学習の性能の大きな部分は、個々のタスクに応じたデータ表現を手で作れるかに依存していた。しかし

ながら、いくつかのタスクにおいて、「良い」特徴量を知ることは困難である。例えば、写真に猫が写っているか、犬が写っているかを判定するプログラムを作成するとしよう。このとき、アルゴリズムに与えるべき「良い」特徴量とは何であろうか？データの中に潜む複雑なパターンは、人間が言語化／定式化できるような簡単な特徴量ではうまくモデル化できない場合がある。

深層学習では、上記の特徴量設計の問題を、end-to-end 学習と呼ばれる方法で解決する。これは、特徴量を入力とするタスクの実行のみならず、入力の生データから特徴量を抽出することも同時に学習するアプローチである（図 3.2）。この特徴量抽出は、表現学習（representation learning）ともよばれる。ここで、データは、特徴量の推定と、実際のタスクの実行という、二つの目的に同時に利用される。学習された表現は、人間のエンジニアが手動で設計した特徴量よりも良い表現、すなわちより良い結果でタスクを実行できる表現であることが多い。一般に、この特徴の学習は、データの単純な特徴をとらえることから始まり、それらを階層的に組み合わせることで、より複雑な特徴に到達することでなされる [74]。このような end-to-end 学習の特徴から一般に、深層学習は、人手により特徴量を捉えることが困難な種類のタスクにとって有用であると考えられている。

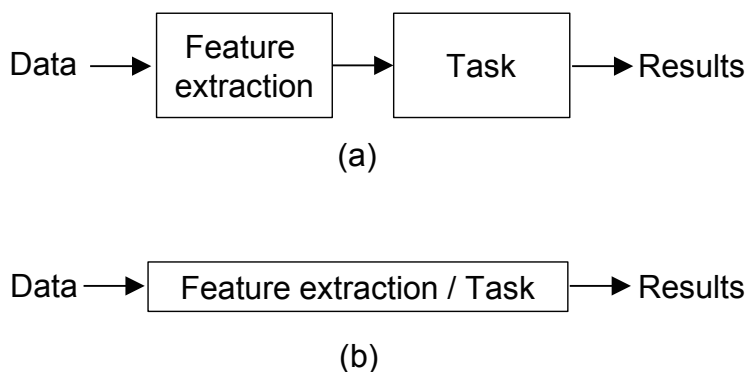


図 3.2 (a) 従来型の「浅い」機械学習の処理パイプライン、(b) 深層学習の処理パイプライン

3.3 深層ニューラルネットワーク

深層学習を実装する一つの方法が、深層ニューラルネットワーク（Deep Neural Network, DNN）である。この節では、深層ニューラルネットワークのなかでも、順伝播型と

よばれるモデルについて説明する。ここで順伝播型とは、入力 \mathbf{x} から、出力 \mathbf{y} へとモデルが順に計算され、モデルの出力をモデル自体に戻すようなフィードバック接続がないことを示す。^{*2}以下では、 \mathbf{x} のようなボールド体で示された変数は、要素 x を有するベクトルもしくはマトリクスである。

順伝播型深層ニューラルネットワークの目的は、タスクを実行する関数 f^* を近似することである [74]。具体的には、入力 \mathbf{x} 、出力 \mathbf{y} 、ネットワークのパラメータ θ を用いて、 $\mathbf{y} = f(\mathbf{x}; \theta)$ なる関係のなかで、パラメータ θ を最適化することで、 f^* を近似する。

順伝播型ニューラルネットワークのモデルは、層とよばれる構造が多数連なった形式をとる。 k 番目の層が関数 $f^{(k)}$ を表す時、 N 層のニューラルネットワーク全体が表す関数 $f(\mathbf{x})$ は、図 3.3 に示すように、 $f(\mathbf{x}) = f^{(N)}(f^{(N-1)}(\dots f^{(2)}(f^{(1)}(\mathbf{x})))$ なる連鎖構造をとる。連鎖の長さ全体が、モデルの深さを表す。一般にモデルの深さが 3 層より深い時、従来の人工ニューラルネットワークと区別して、深層ニューラルネットワークという言葉が用いられる場合が多い [78]。最初の層は入力層、最後の層は出力層、それ以外の層は隠れ層と呼ばれる。

ニューラルネットワークの訓練時には、タスクを実行する関数 $f^*(\mathbf{x})$ に一致するように、ニューラルネットワークの表現する関数 $f(\mathbf{x})$ を変化させる。訓練は、訓練データに基づいて行われる。訓練データは、さまざまな入力点 \mathbf{x} での期待される出力、 $\mathbf{y} = f^*(\mathbf{x})$ の組である。これは、教師あり学習と呼ばれる。 \mathbf{y} はラベルともよばれる。学習アルゴリズムは、この訓練事例を再現し、かつ訓練事例以外の入力に対しても期待される値を出力するように、ニューラルネットワークのパラメータ θ を調整する。

3.3.1 深層ニューラルネットワークのアーキテクチャ

深層ニューラルネットワーク全体構造を示す言葉として、アーキテクチャという言葉が用いられる。この節では、深層ニューラルネットワークのアーキテクチャ、すなわち各層が表現すべき関数と、そういった層をどのように積み重ねていけばよいのかの指針について議論する [74]。

最初に、深層ニューラルネットワークの各層が表す関数 $f^{(k)}$ として、どのような条件が課されるべきであろうか。もっとも簡単なものとして、 $f^{(k)}$ として線形関数を考えることができるが、これはあまり有用な結果をもたらさない。というのも、線形関数の層を重ねた場合、全体として得られる関数は依然として線形関数の範囲にとどまるからである。

^{*2} フィードバック接続を有するものは、Recurrent Neural Network (RNN) と呼ばれ、音声認識等で用いられているが、この論文では取り扱わない

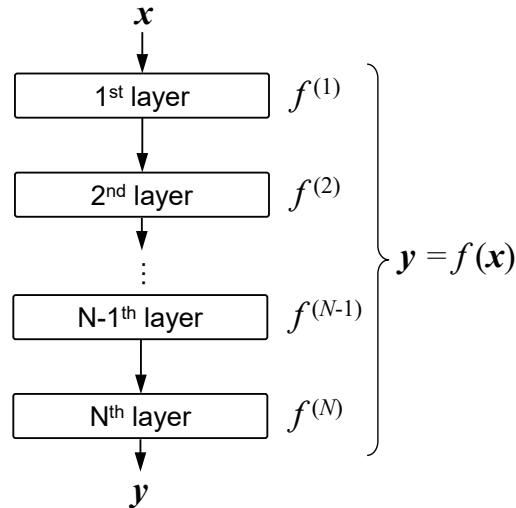


図 3.3 深層ニューラルネットワークによる演算

これは、 $f^{(1)}(\mathbf{x}) = \mathbf{W}_1 \mathbf{x}$ および $f^{(2)}(\mathbf{x}) = \mathbf{W}_2 \mathbf{x}$ の連鎖、 $f^{(2)}(f^{(1)}(\mathbf{x})) = \mathbf{W}_2 \mathbf{W}_1 \mathbf{x}$ を考えると、ほぼ自明と言える。このため、非線形関数を含む一般的な関数 f^* を近似しようとする場合、各層に非線形性を導入する必要がある。

非線形関数として多数の種類が考えられるが、万能近似定理 (universal approximation theorem) [79] によれば、ニューラルネットワークが非線形性を持つ十分な数の隠れユニットをもてば、どのような連続関数*³でも任意の精度で近似できることが知られている。このため、特定の非線形関数を近似しようとする場合、我々はその学習したい非線形関数の種類に応じた特定の非線形関数をニューラルネットワーク内に導入する必要はなく、ある決まった非線形関数を持つ層を、多数連鎖させればよい。万能近似定理は、大まかに言えば、どのような関数を学習するかに関わらず、十分に大きなニューラルネットワークはその関数を近似表現できることを示している。

次に、層を積み重ねることで与えられたタスクに対して「十分に大きな」ネットワークをどのように構築するかを議論する。基本的な課題として、ネットワークの1層を大きくするのが良いのか、それとも比較的限られた大きさの層を多数積み重ねるのが良いのか、という議論がある。この議論について明確な決着がなかったことはないが、[80] では、深い ReLU ネットワーク*⁴で表現できる関数を、浅いネットワークで表現するには、指数関数

*³ より正確には、どのようなボレル可測関数

*⁴ 後述するように、近年の深層ニューラルネットワークでは、非線形性を導入する活性化関数として

的に大きな数の隠れユニットが必要になることが示されている。この結果は、ニューラルネットワークの層を深くすることは、浅いネットワークのユニットを増やすことよりも表現力の高いモデルを得やすいことを示唆している。これは実験的に知られている傾向とも一致する。しかしながら、深いネットワークは訓練課程における勾配消失の問題を引き起こしやすく、訓練が難しくなる傾向がある。そのため、現実的にはタスクに応じた試行錯誤的な設計が必要となる。

3.3.2 全結合型深層ニューラルネットワーク

この節では、順伝播型かつ全結合型のディープニューラルネットワーク (Fully-connected deep neural network, FC-DNN) を説明する。まず、図 3.4 に、複数の隠れ層を持つ FC-DNN の模式図を示す。FC-DNN は、層状に並べたユニット (ニューロン) が、隣接の層間でのみ結合している。連鎖する各層は、入力として前の層の出力を使用する。




図 3.4 全結合型ニューラルネットワークの概念図

各層のニューロンの詳細を図 3.5 に示す。ニューロンは複数の入力から、一つの出力を計算する。各ニューロンは重み係数 $\mathbf{w} = (w_1, w_2, \dots, w_N)$ およびバイアス b を利用して、出力 y を以下の様に計算する。

$$y = f \left(\sum_{k=1}^N w_k x_k + b \right) \quad (3.1)$$

ここで f は活性化関数 (activation function) であり、システムに非線形性を導入するために用いられる。活性化関数としては、ロジステックシグモイド関数や \tanh 関数が用いられることもあるが、近年では、正規化線形関数 (Rectified linear unit, ReLU [81]) が

ReLU [81] を用いることが多い

多く用いられている。ReLU 関数は図 3.6 に示すような、 $x > 0$ では入力値をそのまま返し、 $x < 0$ では零を返す関数、

$$y = \max(0, x) \quad (3.2)$$

である。




図 3.5 全結合型ニューラルネットワーク中のニューロン（ユニット）の概念図




図 3.6 Rectified linear unit(ReLU) 関数

全結合型深層ニューラルネットワークの最初の層は入力層（input layer）、最後の層は出力層（output layer）、中間の層は隠れ層（hidden layer）と呼ばれる。この中で特に中間層が 1 層のみの「浅い」ニューラルネットワークは、深層ニューラルネットワークと区別され、単に人工ニューラルネットワーク（artificial neural network: ANN）と呼ばれることが多い。^{*5}

^{*5} 定まった定義はないが、いくつかの議論 [78] に依れば、中間層を 2 層以上含む場合には、深層ニューラルネットワークと呼ぶ場合が多い。

3.3.3 畳み込みニューラルネットワーク

畳み込みニューラルネットワーク (Convolutional neural network, CNN) は、哺乳類の脳の1次視覚野に対する知見^{*6}に刺激を受けて生まれた、格子状構造を持つデータの処理に用いられる深層ニューラルネットワークの一種である。1次元格子状データの例として、時系列データがある。これは等しい時間間隔でサンプリングされたデータが、1次元に配列されたものである。また、2次元格子状データの例として画像データがある。これは画素データが2次元に配列されたものと考えることができる。

畳み込みニューラルネットワークは、少なくともどこか一つの層で畳み込みが行われる。また多くの場合プーリング (pooling) が行われる。もっとも基本的な畳み込みニューラルネットワークは、図3.7に示すように、いくつかの畳み込み層とプーリング層が繰り返された後、全結合層が付け加えられたものである。しかしながら畳み込みニューラルネットワークのアーキテクチャに関する研究はきわめて速い速度で進んでおり、次々と新しいアーキテクチャが提案されていることには、注意が必要である^{*7}。

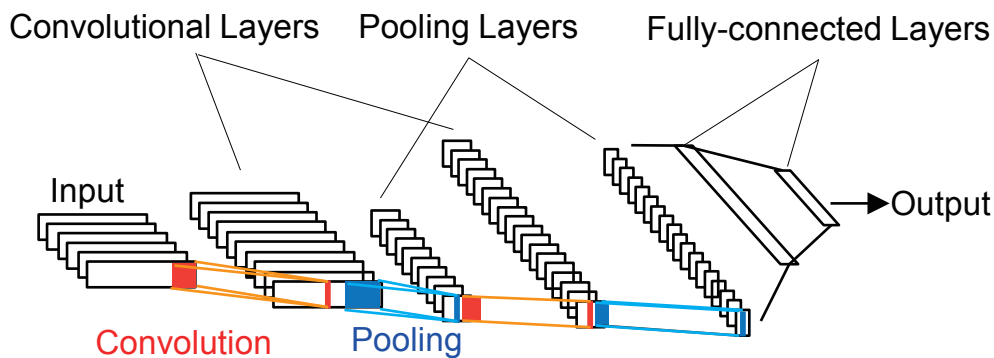


図 3.7 畳み込みニューラルネットワークの概念図

^{*6} 具体的には受容野 (receptive field) における単純型細胞 (simple cell) と複雑型細胞 (complex cell) の存在。

^{*7} 近年では、メモリ消費量の多い全結合層を廃したアーキテクチャを採用する CNN もあるが、これについては、本論文の範囲外である

(a) 畳み込み層

最初に、畳み込みについて説明する。1次元データ（例えば時系列データ） $x(t)$ への畳み込み処理は、以下の式であらわされる。

$$s(t) = \int x(u)w(t-u)du \quad (3.3)$$

ここで、 x は入力 (input)、 w はカーネル (kernel)、 s は特徴マップ (feature map) と呼ばれる。ほとんどの応用例のように、入力が離散的な場合には、積分を和に置き換えて、

$$s_i = \sum_{p=-\infty}^{\infty} x_{i+p}w_p \quad (3.4)$$

と書ける。ここで、 i と p は整数値を取る。これは複数の軸に対する畳み込みに容易に拡張できる。たとえば二次元入力 I (例：画像) に対する畳み込みは、2次元カーネル K を用いて、

$$S(i, j) = \sum_m \sum_n I(m, n)K(i-m, j-n) \quad (3.5)$$

と書ける。

CNNにおける畳み込み層では、カーネルの係数が訓練によって学習されるパラメータである。信号処理の観点から見ると、このカーネルは、デジタルフィルタであるとみなせる。例えばカーネルの係数を変化させることにより、ローパスフィルタ、ハイパスフィルタ、あるいはエッジ抽出フィルタなどが構成され得る。従来、人手により入力データの特徴を抽出するための様々な形式のフィルタやそのパラメータが提案され、試行されてきたが、この過程は、CNNにおいてはend-to-end学習という形でデータから学習される。

実際の畳み込み層においては、カーネル w の長さは有限であるから、この長さを H として、1次元畳み込みは以下のように書ける。

$$s_i = \sum_{p=0}^{H-1} x_{i-p}w_p \quad (3.6)$$

また、実際の畳み込み層においては、多チャネルの入力に対して、複数個のカーネルの畳み込みを行う場合が多い。ここでチャネルとは、例えば画像におけるRGBの3チャネルである。本論文で用いるデジタルコヒーレント受信器と深層ニューラルネットワークを組み合わせたモニタリング手法 (3.7節) では、複素光電場の各偏波の実部と虚部 (HI、

HQ、VI、VQ) の4チャンネルがこれにあたる。入力データのチャンネル数を K とした場合、各カーネルは、入力と同じチャンネル数 K を持つ。このときカーネルのサイズは、 $H \times K$ である。 K チャンネルに対する畳み込みは、以下の式であらわされる。

$$s_i = \sum_{k=0}^{K-1} \sum_{p=0}^{H-1} x_{i-p,k} w_{p,k} \quad (3.7)$$

ここで注意すべきは k に対する加算のため、入力データのチャンネル数に関わらず、1つのカーネルからの出力は、常に1チャンネルになることである。そのため、複数のカーネルを用意し、同様の処理を並列に行うと、畳み込み層の出力データのチャンネル数は、入力データのチャンネル数に関わらず、カーネルの個数と同じになる。

畳み込みの結果 s_i に、各カーネルごとに異なるバイアス b を足し合わせ、活性化関数 f を演算した結果が、畳み込み層の最終的な出力である。

(b) プーリング層

次にプーリング層における処理について述べる。プーリングとは、ある場所での出力を、周辺の要約統計量で置き換える処理である。この処理は、入力の小さな変化に対する不変性を獲得するのに役に立つ。ここでは例として、1次元入力に対する最大プーリング(max pooling)を説明する。

まず最初に、プーリング層への入力データの各チャンネルごとに、データ点 x_i を中心とした長さ L の領域を取り、この中に含まれるデータ点の集合を P_i とする。 P_i のなかで最大値を取るものを、出力 u_i とする。すなわち、

$$u_i = \max_{p \in P_i} x_p \quad (3.8)$$

である。 i の取り方として、間隔が1となるように、すなわち $i = 1, 2, 3, \dots$ と取るのではなく、 s ずつずらしながら計算することができる。この間隔 s を、ストライド (stride) と呼ぶ。ストライドを行った場合、 s 毎に要約統計量 (max pooling の場合には最大値) を出力するので、適切なデータパディングと一緒に用いた場合、データ長は $1/s$ となる。ストライドは、ハイパーパラメータとして予め与えられている。そのため、プーリング層においては学習によって変化するパラメータはない。

(c) 全結合層

全結合層は、3.3.2 節で説明した、全結合型深層ニューラルネットワークと同じものである。畳み込み層もしくはプーリング層の出力は、多チャンネルかつ多次元な出力であることが多い。一方、全結合型ニューラルネットワークにおいてはすべてのニューロンが平等に扱われるため、その入力次元は1次元である。そのため、畳み込み層もしくはプーリング層から全結合層へデータを渡す前に、多次元データを1次元データに並び替える、flatten化が行われる。これは、例えば、畳み込み層もしくはプーリング層の出力が、各チャンネルが長さ L のデータをもつ M チャンネル出力であった場合、これを長さ $M \times L$ の1次元ベクトルに並び替える処理に当たる。

3.4 深層ニューラルネットワークの訓練

深層ニューラルネットワークの学習は一般に、ミニバッチ確率的勾配降下法 (Minibatch stochastic gradient descent: Minibatch SGD) と呼ばれる以下の手順で行われる。深層ニューラルネットワークの学習とは、訓練データ集合が与えられたとき、損失関数 E を最小化する重みパラメータ \mathbf{w} とバイアスパラメータ \mathbf{b} を求めることである [74]。

手順 1: 訓練データの準備

訓練データの中から、ランダムに一部のデータを選ぶことで、訓練データのミニバッチを生成する。計算の高速化のため、全訓練データをランダムに並べ替え、一定の個数 (ミニバッチの個数) 毎に分割することで、ミニバッチを生成することが多い。

手順 2: 損失関数の計算

ミニバッチのデータを用いて、深層ニューラルネットワークの順伝播を計算し、損失関数 E を計算する。具体的な損失関数の形状については、3.4.1 節で述べる。

手順 3: 勾配の計算

損失関数 E を減少させる方向を示す量である、重みパラメータの勾配を求める。勾配を高速に計算する手法である誤差逆伝播法については、3.4.4 節で詳しく説明する。

手順 4: パラメータの更新

重みパラメータを勾配方向に微小量変化させる。この変化量は学習率とよばれる。

手順 5: 繰り返し

手順 1-4 を繰り返す。繰り返しによって全訓練データを提示し終わることを「エポック」と呼ぶ。1 エポックが終了した場合、全訓練データを再度ランダムに並べ替え、手順 1-4 をさらに繰り返す。このとき、学習率を調整する場合がある。一般に最初は大きく、学習が進むに従い小さく設定する。学習率を動的に変化させる方法については、3.4.3 節で説明する。

以下の節では、この深層ニューラルネットワークの訓練に必要な、各要素技術について述べる。

3.4.1 深層ニューラルネットワークの出力層と損失関数

この節では、手順 2 の損失関数の計算について詳しく述べる。損失関数は、深層ニューラルネットワークの出力層の形式と、そのニューラルネットワークが解こうとするタスクの種類と密接に関連している。様々なタスクと損失関数が考えられるが、最も一般的な機械学習のタスクと損失関数として、以下が考えられる。

(a) 回帰のための線形出力層と平均二乗誤差損失

回帰 (Regression) とは、ある入力から、対応する数値を予測するタスクである。

回帰タスクを行う出力層のひとつに、非線形関数を用いない線形層がある。入力特徴量 h が与えられたとき、線形層はベクトル $\hat{y} = \mathbf{W}^T \mathbf{h} + \mathbf{b}$ を出力する。ここで \mathbf{W} は重み係数、 \mathbf{b} はバイアスと呼ばれる、訓練によって変化するパラメータである。

ネットワークの出力 \hat{y} が、目標出力 t にどの程度近いかを表現するため、平均二乗誤差、

$$E = \frac{1}{2} \sum_{i=1}^M (t_i - \hat{y}_i)^2 \quad (3.9)$$

を誤差関数に取る。ここで M はミニバッチの個数、また係数 $1/2$ は、微分した時に係数が 1 になるための調整項である。

線形層が、条件付きガウス分布の平均を出力するとき、対数尤度の最大化は、平均二乗誤差の最小化と等価である。本論文では、OSNR および波長分散量の推定タスクに、線形出力層と平均二乗誤差損失を用いている。

(b) 分類のためのソフトマックス出力層とクロスエントロピー損失

分類 (Classification) とは、ある入力を、 K 個のカテゴリのいずれかに分類するタスクである。例えば、画像を入力し、その画像に写っている物体に応じて画像を分類するなど

があげられる。分類モデルは形式的に、入力をベクトル \mathbf{x} , 出力を \mathbf{y} として、 $\mathbf{y} = f(\mathbf{x})$ と書ける。モデルは、ベクトル \mathbf{x} で記述される入力を、数値コード \mathbf{y} で特定されるカテゴリに割り当てる。数値コード \mathbf{y} としては、one-hot と呼ばれる表現が一般的に用いられる。これは K 次元のベクトルであり、あるカテゴリは、 K 次元ベクトルのひとつの要素に関連付けられる。例えば、10 クラス分類における 3 番目のカテゴリを示すには、 $\mathbf{y} = [0, 0, 1, 0, 0, 0, 0, 0, 0, 0]$ という数値コードが用いられる。

この層では、最初に線形層で正規化されていない対数確率 z を予測する： $\mathbf{z} = \mathbf{W}^T \mathbf{h} + \mathbf{b}$ 。ただし、 $z_i = \log P(y = i|x)$ である。これを基に、活性化関数としてソフトマックス関数 (softmax function)

$$y_k = \frac{\exp(z_k)}{\sum_{j=1}^K \exp(z_j)} \quad (3.10)$$

を演算し、出力 y_k を得る。

多クラス分類問題を解くとき、損失関数として、以下のクロスエントロピーが用いられる。

$$E = - \sum_{i=1}^M \sum_{k=1}^K t_{i,k} \log y_k \quad (3.11)$$

ここで、 M はミニバッチの個数、 K はカテゴリの数、 t は one-hot 表現であらわされた教師信号である。

ソフトマックス関数を通すことで、出力 y_1, \dots, y_K の和が常に 1 となるよう規格化される。これは出力を各カテゴリに属する確率とみなす時に有用な特徴である。ソフトマックス関数はまた、ユニット間に競争を発生させているとも理解できる。ソフトマックスの出力の和が 1 であるため、あるユニットの出力を大きくすることは、他のユニットの出力を小さくすることにつながる。極端な場合には、ひとつのユニットの出力のみが 1 となり、他のユニットの出力は零になる。クラス分類では、ある一つのクラスに属するものが、同時に他のクラスに属することはないとの仮定を置いているため、この動作は合理的である。

本論文では、入力光信号の変調方式およびシンボルレート識別タスクに、この形式を用いている。

3.4.2 ミニバッチ確率的勾配降下法によるパラメータの更新

現代の深層ニューラルネットワークの訓練には、概ねミニバッチ確率的勾配降下法 (Stochastic gradient decent, SGD) が用いられる。最初に、訓練データ集合から小さなサンプルセットであるミニバッチをサンプリングする。ミニバッチに含まれるサンプルの個数を M とする。このとき、ミニバッチの事例を用いて、勾配の推定値は、

$$g = \frac{1}{M} \frac{\partial}{\partial \mathbf{w}} \sum_{i=1}^M E_i(\mathbf{w}) \quad (3.12)$$

と計算できる。この結果を用いて、パラメータ θ を

$$\theta \leftarrow \theta - \epsilon g \quad (3.13)$$

と更新する。ここで ϵ は学習率である。

ニューラルネットワークの非線形性によって、損失関数は一般に非凸になるため、この勾配降下法による探索は、局所的な極小解に陥る可能性がある。^{*8} しかしながら、勾配降下法によるニューラルネットワークの訓練は、こういった局所収束の可能性にもかかわらず、実用上は上手くいく場合が多い。このメカニズムについては、現在進行形で研究が進んでいる。例えば [82] では、大きなニューラルネットワークでは、ニューラルネットワークの殆どすべての極小解が最適解となることが報告されている。これは、十分に大きいニューラルネットワークでは、損失関数の極小値（最小値ではない）を見つけ出すことで、良い性能を発揮できる可能性が高くなることを示している。

ここで訓練データ集合の全体について勾配を計算するのではなく、ミニバッチについて勾配を計算する理由について議論しよう [74]。この理由は大きく二つある。

ひとつは、そのほうが高速に計算できるからである。高速に計算できる理由のうち最も簡単なものは、単純にメモリ量の問題である。現実のコンピュータのメモリ（特に実践的には、高速に計算を実行できる GPU のメモリ）には制限がある。そのため、訓練データ集合が巨大になると、すべてのデータをメモリに格納することが現実的に難しくなる。ミニバッチを採用することで、訓練データ集合が大きい場合でも、計算時にメモリに展開するデータの量を一定量に抑えることができる。もうひとつの幾分か理論的な理由は、統計的なものである。n 個のサンプルから推定される平均の標準誤差は、 $1/\sqrt{n}$ に比例する。これは例えば、一回の勾配を計算するのに用いる訓練データ数を 100 倍にしても（計算時

^{*8} 多くの深層ニューラルネットワークでは、極めて多数の極小解が存在することが示されている [74]

間も 100 倍になる)、標準誤差は $1/10$ にしかならないことを意味する。ほとんどの最適化アルゴリズムでは、正確な勾配をゆっくりと計算するよりも、近似的な勾配を素早く推定するほうが、合計計算時間の点でより高速に収束する場合が多い。

ミニバッチを用いるもう一つの理由は、訓練データ集合の持つ冗長性である。訓練データは現実世界から採取されたもので、類似のデータが多数含まれている場合が多い。例えば、ある訓練データセットをコピーし、2 倍の長さを持つ新たなデータセットを得たとしてよう。この新しい訓練データセット全てを用いて勾配の計算を行った場合、計算時間は 2 倍になるにも関わらず、計算結果は変化しない。しかしデータをランダムに並べ替えたうえでミニバッチを用いれば、冗長性のある新データセットを用いても、旧データセットを用いた時と同じ計算時間で同様の結果が得られると期待される。

3.4.3 適応的な学習率

学習率は、モデルの学習に大きな影響を与えることが知られている。そのため、学習率にいかなる値を設定するか、また学習が進むにつれてどのように変化させるべきかは、モデルの学習における重要な課題となる。学習率を自動的に調整する手法として、Adagrad [83]、Adadelta [84]、RMSProp^{*9}などが知られている。本論文では、Adadelta や RMSprop で用いられる、過去の勾配の 2 次モーメントに加え、過去の勾配の 1 次モーメントも利用して学習率を調整する Adam [85] を、学習率最適化アルゴリズムとして用いる。具体的な Adam のアルゴリズムを、以下に示す。

手順 1: ハイパーパラメータの決定

Adam アルゴリズムに必要なハイパーパラメータである、ステップ幅 ϵ 、モーメント推定の指数減衰率 ρ_1 および ρ_2 、アルゴリズム安定のための小さな定数 δ 、初期パラメータ θ を決める

手順 2: 初期化

1 次および 2 次モーメント変数 s と r 、および時間ステップ t を 0 に初期化する。

手順 3: 勾配計算

勾配 g を計算する。この手順での操作は従来手法と同じである。また時間ステップを進める： $t \leftarrow t + 1$

手順 4: バイアス付モーメント推定の更新

^{*9} RMSProp は正式に論文化はされていないが、Geoff Hinton が Coursera の講義中に提案したといわれている

バイアス付の1次モーメントの推定を $s \leftarrow \rho_1 s + (1 - \rho_1)g$ に従い更新する。また、バイアス付の2次モーメントの推定を $r \leftarrow \rho_2 r + (1 - \rho_2)g^2$ に従い更新する。

手順5: モーメントのバイアスの修正

1次モーメントのバイアスを $\hat{s} \leftarrow \frac{s}{(1-\rho_1^t)}$ に従い修正する。また、2次モーメントのバイアスを $\hat{r} \leftarrow \frac{r}{(1-\rho_2^t)}$ に従い修正する。

手順6: パラメータの更新量を計算する

$$\Delta\theta = -\epsilon \frac{\hat{s}}{(\sqrt{\hat{r} + \delta})}$$

手順7: パラメータを更新する

$$\theta \leftarrow \theta + \Delta\theta$$

手順8: 繰り返し

手順3から7を繰り返す

3.4.4 誤差逆伝播法

損失関数 E のパラメータ w での傾き $\partial E / \partial w$ を計算できれば、損失関数を（少なくとも局所的に）小さくする向きが分かる。誤差逆伝播法 [86] は、この傾き（勾配）を高速に計算する方法である。勾配を求めるために誤差関数の微分を計算するとき、誤差逆伝播法では、出力層から入力層へ向かって計算を行う。これが「逆伝播」の名前の由来である。

以下に、誤差逆伝播法の手順を述べる。

手順1: 順伝播

入力層からニューラルネットワークに訓練データ x を入力し、順に値を計算し、出力 y を得る。このとき、中間層を含むすべての層のユニットの出力 z_i と、活性化 $a_j = \sum_i w_{ji} z_i$ を記録しておく。

手順2: 出力層の誤差 δ_k の計算

順伝播で求めた出力 y と教師ラベル t から、出力層の誤差 $\delta_j = \partial E_n / \partial a_j$ を計算する。

手順3: 誤差の逆伝播

逆伝播公式 $\delta_j = h'(a_j) \sum_k w_{kj} \delta_k$ を利用することで、誤差 δ_k から、ひとつ前の層の誤差 δ_j を求める。逆伝播公式を繰り返し用いることで、入力層までのすべての δ を計算する。

手順4: 勾配の計算

手順3で求めた δ_i と、手順1で記録したユニット出力 z_i に、 $\partial E_n / \partial w_{ji} = \delta_j z_i$ を

用いることで、勾配を計算する。

手順2において、出力層の誤差 δ を計算する際、これは用いる出力層および損失関数に依存する。ここでは例として、二乗誤差損失関数

$$E_{se} = \frac{1}{2} \sum_k (t_k - y_k)^2 \quad (3.14)$$

に対する δ を求めておこう。ここで、誤差 δ に関する式 $\delta_j = \partial E_n / \partial a_j$ を、連鎖律を用いて以下のように変形する。

$$\delta_j = \frac{\partial E_n}{\partial a_j} = \frac{\partial E_n}{\partial z_j} \frac{\partial z_j}{\partial a_j} \quad (3.15)$$

このとき、活性化関数 h を用いて、 $z_j = h(a_j)$ と書けるので、 $\partial z_j / \partial a_j = h'(a_j)$ と書ける。そのため、

$$\delta_j = h'(a_j) \frac{\partial E_n}{\partial z_j} \quad (3.16)$$

となる。式 3.16 および線形出力層では活性化関数が恒等写像とみなせることを用いれば、この場合の δ は、

$$\delta_j = 1 \times \frac{\partial}{\partial y_k} \frac{1}{2} \sum_k (t_k - y_k)^2 = y_k - t_k \quad (3.17)$$

となる。

3.5 汎化

深層ニューラルネットワークは、訓練データだけでなく、モデルが経験したことのない未知データに対しても同様の性能を発揮することが期待される。過去に経験していないデータに対してもうまく機能する能力を、汎化 (generalization) と呼ぶ。

前節までで述べたように、深層ニューラルネットワークは訓練データ集合を用いて、誤差 (訓練誤差) が小さくなるように訓練される。これは単純な最適化問題であるが、深層ニューラルネットワークの訓練が最適化問題と異なるのは、この目的が訓練誤差を小さくすることではなく、汎化誤差 (generalization error) を小さくしたい点である。汎化誤差は、データの真の生成分布全体に関する誤差である [74]。

もし、真のデータの生成分布 p_{data} が既知ならば、 p_{data} 全体で誤差 E の期待値を取ることで、汎化誤差を小さくできるであろう。だが、実際には p_{data} は未知であり、訓練データ集合のみが利用できる場合が大半である。そのため、汎化誤差は通常、訓練データ集合とは分離された、テストデータ集合を用いて計測される。

深層ニューラルネットワークのモデル容量 (capacity) が大きい時、深層ニューラルネットワークは、テストデータ集合にとっては意味をなさない、訓練データ集合の微細な特徴を学習してしまうことがあり得る。これにより、訓練誤差は小さくなるものの、逆に汎化誤差は大きくなってしまふことがあり得る。これを過学習 (overfitting) と呼ぶ。

過学習を防ぐ方法のひとつとして、適切な容量のモデルを利用することが考えられる。しかしながら、現実的には、それは難しい。これは深層ニューラルネットワークのモデル容量を適切に見積もるための理論的な研究が完全ではないことと、画像認識や音声認識といった複雑なタスクに対する適切なモデル容量を見積もることが難しいという、両面からの理由による。そのため実践的には、深層ニューラルネットワークを用いる場合、大きいモデルを後述する適切な正則化とともに用いることになる。このアプローチは過学習を回避しながら、良好な結果を導くことが多い。

3.5.1 正則化

深層ニューラルネットワークは、訓練データだけでなく、モデルが経験したことのない未知データに対しても同様の性能を発揮することが期待される。正則化とは、訓練誤差でなく、汎化誤差を減少させることを目的とした、学習アルゴリズムに対する修正である。正則化は長年、機械学習の研究にとっての中心的な課題であり、多くの手法が提案されている。本節では、深層ニューラルネットワークに用いられる正則化の手法のいくつかを説明する。

(a) L^2 パラメータ正則化

最も一般的な正則化の手法の一つとして、 L^2 パラメータ正則化がある。これは重み減衰 (weight decay) としても知られる。

この正則化手法では、損失関数に重みの二乗和に相当する正則化項を付け加える：

$$E' = E + \frac{\lambda}{2} |\mathbf{w}|^2 \quad (3.18)$$

ここで E は L^2 正則化を行う前の損失関数、 λ は正則化の強さを制御するハイパーパラメータである。 L^2 パラメータ正則化の詳細な議論については、例えば [11] でなされて

いる。

(b) ドロップアウト

ドロップアウト (Dropout) [87] とは、学習時において、各層のユニットを決まった確率 p で無効化し、無効化されなかったユニットのみで部分ネットワークを構築する手法である。ミニバッチ学習においては、ミニバッチ内の訓練データを用いてこの部分ネットワークの最適化を行い重みを更新する。一度重みを更新した後、次のミニバッチでは、無効化するユニットを新たに選び直し、新しい部分ネットワークを同様に訓練する。推論時においては、すべてのユニットを用いて順方向伝播を行う。この際、ドロップアウトの対象になったユニットの出力を $1 - p$ 倍する。

ドロップアウトは、図 3.8 に示すように、深層ニューラルネットワークから確率的にユニットを削除することで、複数の部分ネットワークからなるアンサンブルモデルを学習する方法とみなせる [74]。

これは、複数の異なるモデルの応答を合成することでより良い回答が得られるという、アンサンブル学習の模倣である。ただし、通常アンサンブル学習の様に個別の独立したモデルを学習することは、深層ニューラルネットワークにおいては計算コストが高すぎる。そのため、ドロップアウトでは、部分ネットワーク間で共有しているユニットでは、同じパラメータを用いる。パラメータ共有により、ドロップアウトでは限られたメモリのサイズで多くのモデルを表現できる。

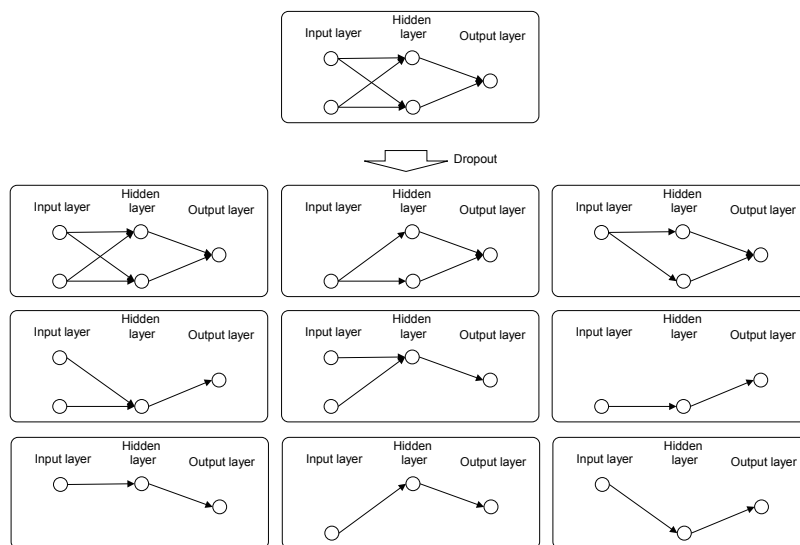


図 3.8 ドロップアウトによる複数の部分ネットワークの構成

ドロップアウトは強力な手法だが、モデルにドロップアウトを導入した場合、モデルの表現力を削減してしまう。これは部分ネットワークが、基本ネットワークより常に小さいことから容易に導ける。この効果を相殺するには、基本ネットワークを十分に大きくしなくてはならない。モデルサイズを大きくすることは、当然、訓練課程の反復を増加させるなど計算量の増加を引き起こす。

3.5.2 バッチ正規化

深層ニューラルネットワークは、複数の層の連鎖で成り立っている。この多層性は、モデル容量の増加や、階層的な概念獲得などの大きな利点を有する反面、深層ニューラルネットワークの学習が難しい原因でもある。多層化により学習が難化する要因の一つとして、内部共変量シフト (internal covariate shift) が指摘されている。バッチ正規化 (Batch normalization) [88] は、内部共変量シフトを防ぐことで、深層ニューラルネットワークの学習を容易にする手法であり、2015年の登場以来、現在では広く用いられるようになっている。

一般に、訓練に用いる説明変数 x の分布 $p_0(x)$ と、推論に用いるときの分布 $p_1(x)$ が異なることを、共変量シフト (covariate shift) とよぶ。深層ニューラルネットワークの多層構造においては、第 k 層の出力 $z^{(k)}$ も、ある分布 $p_k(z^{(k)})$ からのサンプルとみなせる。深層ニューラルネットワークの学習時には、各層の勾配は、他の層が変わらないという仮定の下で更新され、第 k 層は、 $p_k(z^{(k)})$ に近づくように学習される。しかしながら、実際には、深層ニューラルネットワークのすべての層は同時に更新されるため、第 k 層の前層のパラメータも更新されており、 $z^{(k)}$ のパターンも変化してしまい、学習の目標である $p_k(z^{(k)})$ の形も異なってしまう。バッチ正規化を用いることで、この多層にわたる更新を調停することができる。

バッチ正規化の基本的なアイデアは、各層での活性の分布を、適切に調整することである。具体的には各ミニバッチごとに、データの分布の平均値を 0、分散が 1 となるように、以下の様な処理を行う。いま、 h をバッチ正規化する活性の集合 (ミニバッチから計算された) とするとき、

$$\hat{h} = \frac{h - \mu}{\sigma} \quad (3.19)$$

ここで、

$$\mu = \frac{1}{m} \sum_{i=1}^m h_i, \quad (3.20)$$

$$\sigma = \sqrt{\epsilon + \frac{1}{m} \sum_{i=1}^m (h_i - \mu)^2} \quad (3.21)$$

ただし、 m はミニバッチの個数、 ϵ は小さな正の値で0除算を防ぐためのものである。さらに、上記の正規化されたデータに対して、スケーリングおよびシフトを行う：

$$y_i = \gamma \hat{h}_i + \beta \quad (3.22)$$

ここで、 γ と β はパラメータであり、学習によって適した値に調整される。

データを正規化した後、わざわざ、もう一度スケーリングとシフト演算を行うのは、なぜだろうか？それは、学習のダイナミクスを変えるためである。バッチ正規を行わない場合、活性の集合 h の平均は、下位層のパラメータ間の複雑な相関関係で決まる。そのため、学習のたびに目標が変化する、いたちごっこが起ってしまう。バッチ正規化後の $\gamma \hat{h} + \beta$ では、これは下位層とは関係なく γ および β のみで決まるため、このようないたちごっこが、防止されるのである。

以上は訓練時の動作であるが、テスト時には、 μ と σ を、学習時に収集された移動平均に置き換えて実行する。

バッチ正規化には、(1) 学習率を大きくとることができる（学習の高速化）、(2) 初期値依存性の低減、(3) 過学習の抑制、といった様々な利点があると考えられている。

3.5.3 データ拡張

モデルの汎化性能を高めるための単純で強力な方法は、訓練データ数を増やすことである。しかしながら、一般的にデータの収集およびラベリングにはコストがかかるため、この方法を単純には実行できないことが多い。この問題を回避するため、既存の訓練データから、「新しい」データを創り出す、データ拡張（Data augmentation）が用いられる。

このアプローチは、物体認識タスク（与えられた画像データに写っている物体を認識し、特定のクラスに分類するタスク）において、大きな効果を発揮してきた。このタスクにおいては、訓練データのラベル（例：猫）を変えずに、入力データを変形（例：平行移動、回転、反転、明暗の調整など）することで新しいデータを創り出すことは、比較的容

易であったからである。しかしながら、多くの種類のタスクにとっては、データ拡張をおこなう方法は、必ずしも明確でない。

3.7で議論する、デジタルコヒーレント受信によって光電場の全情報をデジタル化したデータを入力に持つ深層ニューラルネットワークの場合、光電場に対する物理的な知識を利用することで、データ拡張を行うことができる。これは、本論文で提案するモニタリングアーキテクチャの持つ利点の一つである。本論文で提案するモニタリングアーキテクチャで用いるデータ拡張の具体例については、3.8.3節で述べる。

3.6 光モニタリングの先行研究

本節では、光信号の状態を推定する、光モニタリングの先行研究について述べる。図3.9に光モニタリングの高水準概念を示す。光モニタは、入力光信号からデータを収集するための Optical measurement-and-digitization 部と、測定されたデータセットから有用な情報を抽出する Data analytics 部から構成される。これにより、光モニタは、光伝送システム中の光を入力とし、その光信号の持つ属性、あるいは状態を推定し、要約量として出力する。出力された情報は、人間のネットワークオペレータおよびネットワーク制御プログラムによって使用される。出力の種類により、複数のモニタが考えられるが、以下では例として、光モニタの出力として OSNR_r、変調方式、波長分散量を推定するものに焦点を当てる。




図 3.9 光モニタリングの概念図

3.6.1 OSNR モニタリング

(a) OSNR

光信号対雑音比 (Optical Signal to Noise Ratio: OSNR) は、光伝送システムの伝送路状態を示す基本的な尺度であり、信号電力 P_S と雑音電力 P_N との比として定義される。

$$OSNR = \frac{P_S}{P_N} = \frac{P_S}{\rho N_0 B_r}. \quad (3.23)$$

ここで、平均的な雑音パワーは、雑音電力スペクトラム密度 N_0 と基準帯域 B_r であらわされる。偏波多重システムの時、 $\rho = 2$ であり、シングル偏波システムの時、 $\rho = 1$ である。 B_r には、12.5 GHz が用いられる場合が多い。OSNR は一般に dB 単位であらわされることが多いため、

$$OSNR_{dB} = 10 \log_{10} \frac{P_S}{P_N} = 10 \log_{10} \frac{P_S}{\rho N_0 B_r}. \quad (3.24)$$

となる。

短距離のシステムでは、雑音電力は主に、ファイバ損失を補償するために用いられる光増幅器に由来する。最も一般的な増幅器は、エルビウム添加ファイバ光増幅器 (EDFA) である [89]。この増幅器は、C バンド ($1525 \text{ nm} < \lambda < 1565 \text{ nm}$) もしくは L バンド ($1570 \text{ nm} < \lambda < 1610 \text{ nm}$) をカバーする増幅帯域幅を有する。信号光は、980 nm または 1480 nm の波長のポンプレーザー光と一緒に、エルビウム添加ファイバに入力されることによって増幅される。ポンプレーザー光は、エルビウムイオンをより高いエネルギーレベルに励起する。信号波長での光子との相互作用により、イオンは信号と同じ波長の光子を放出し、より低いエネルギーレベルに遷移する。この効果を誘導放出と呼ぶ。この誘導放出とは別に、ポンプレーザー光によって励起されたエルビウムイオンは、自発的に^{*10}低エネルギーレベルに遷移することもある。この自然放射増幅光 (Amplified Spontaneous Emission: ASE) は、増幅器の効率を低下させ、ノイズを発生させる。ASE の効果は、加法的白色ガウス雑音 (AWGN) プロセスによって記述することができる。

(b) OSNR モニタリングの先行研究

OSNR は最も基本的な伝送路状態の指標であり、多くのモニタリング方法が提案されてきた [77]。本節では特に、図 3.9 の Data analytics 部において、機械学習を用いる方法

*10 真空からの量子的な刺激により

に焦点を当て、先行研究のレビューを行う。

機械学習のアルゴリズムとして、隠れ層が1層のみの浅いニューラルネットワークを用いる方法が数多く検討されてきた。「ニューラルネットワーク」という術語を共有しているが、一般にこの浅いネットワークは、3.2節で述べた深層学習とは異なり、特徴量の抽出も含めた end-to-end 学習には不適である。そのため、OSNR を推定するために必要な様々な特徴量が提案されてきた。

[46] においては、推定に有用と思われる量として事前に、アイダイアグラムから求めた、Q-factor, eye closure, root-mean-square (RMS) jitter, crossing amplitude が特徴量として提案されている。また、[47, 48] においては、モニタリングの対象として高次変調 (QPSK) への拡張を行うに当たり、Asynchronous constellation diagrams の各象限の分布から求める特徴量を用いることが提案されている。[49] では、ニューラルネットワークへ入力する特徴量として Empirical Moments が提案されている。[50] では、単純にアイダイアグラムの分散値を OSNR 推定のためのニューラルネットワークへ入力する特徴量として選択している。[51] では、OSNR 推定時の波長分散耐性を高めるため、受信信号の低域成分のパワーを抽出し、特徴量として用いている。

これらの方法の限界は、機械学習アルゴリズム (ニューラルネットワーク) の学習の前に、OSNR を良く説明するであろう成分 (特徴量) を、手動で同定し、計算する点である。これには、変調方式の変更・残留波形劣化の有無など OSNR 以外の環境変化が起こる度に、アルゴリズムを再検討しなければならないことを意味する。

この課題を一部解決する検討が、[52, 53] で行われた。この論文では、パターン認識 (基準特徴量ベクトルからのユークリッド距離に応じた分類) を用いて OSNR の推定が行われているが、パターン認識の前に、主成分分析 (principal component analysis) を用いることで、手動の特徴量設計に頼るのでなく、寄与の大きい特徴量を自動的に取り出すことが試みられている。しかしながら、この方法は特徴量の線形な関係を前提にしているため、測定データ間に非線形な関係がある場合への適用に限界がある。

まとめると、より柔軟なモニタリングを可能にするため、測定データを要約し OSNR を抽出する関数を自動的に学習する、機械学習を用いた OSNR 推定の方式が提案されている。これらの方式は、良く設計された特徴量を機械学習アルゴリズムに与えることで、十分な精度での OSNR モニタを可能にしている。しかしながら特徴量の設計は手動に頼る場合が多く、自動的な抽出を試みた場合でも、入力データに制限のある手法が採用されていた。そのため、データ間に非線形関係がある場合も含む一般的な測定データから直接、OSNR をモニタする関数を学習することには課題があった。

3.6.2 変調方式およびシンボルレートのモニタリング

(a) 変調方式とシンボルレート

デジタル通信システムでは、送信側から伝送路を介して受信側に情報が伝送される。光ファイバ通信においては、レーザー光を所定の変調方式で変調し、光ファイバ上を伝播させることで、これを行う。変調過程では、ビットレート $R_b = 1/T_b$ bit のデータをシンボルレート（またはボーレート） $R_S = 1/T_S$ を有する光信号列にマッピングする。 T_b および T_S はそれぞれビットおよびシンボル間時間である。二つの量の比率 R_b/R_S は、1シンボルが運ぶビット数を表し、この量が大きいほど、単位光帯域当たりの伝送量が大きいことを示す。表 (a) に、例を示す。

表 3.1 変調方式の例

変調方式	M	R_b/R_S (bit/symbol)
4QAM(QPSK)	4	2
16QAM	16	4
64QAM	64	6

近年のデジタルコヒーレント光通信システムでは、光の変調方式として直交振幅変調 (QAM) を多く用いる [90]。これは、データを、同じ周波数 f_c を有するが位相が 90 度異なる 2 つの光搬送波の振幅を変調することによって伝送する方式である。QAM 変調方式を表現する一般的な方法として、コンスタレーションダイアグラムがある。このとき、同相成分 (In-phase: I) と直交成分 (Quadrature-phase: Q) は、複素数の実数部と虚数部として表される。コンスタレーションダイアグラム中のシンボル点の数 M は、デジタル QAM 変調方式の次数を示す。コンスタレーションダイアグラム中に M 個のシンボル点があるとき、これを M-ary QAM または M-QAM と呼ぶ。^{*11} 図 3.10 は、QPSK と等価であり、2bit/symbol のスペクトル効率を有する 4-QAM から、6bit/symbol のスペクトル効率を有する 64QAM までの様々な正方形 QAM コンスタレーション図を示している。M-QAM は、1 シンボル当たり $\log_2 M$ bit のデータを送ることができる。すなわち、

^{*11} M 個のシンボル点を複素平面上に分布させる方法は多数あるため、複数の M-QAM 方式があり得るが、この論文では、商用伝送システムで主に使用されている正方形 QAM コンスタレーションに焦点を当てる。正方形の QAM コンスタレーションでは、シンボルは、垂直方向および水平方向に等しい間隔で正方形のグリッドに配置される。

$\log_2 M = R_b/R_S$ であるから、トータルビットレートは $R_b = R_S \log_2 M$ となる。多くのデジタルコヒーレントシステムでは、光の水平偏波 (Horizontal polarization, H-pol.) と垂直偏波 (Vertical polarization, V-pol.) のもつ同相および直交成分を独立に変調することで、偏波多重 (Dual-polarization, DP) を実現している。このとき、各偏波ごとの M-QAM 変調が考えられるので、全体としてはシングル偏波時の2倍、すなわち偏波多重されたシンボルひとつあたり $2 \log_2 M$ bit のデータを送ることができる。これにより、トータルビットレートは $R_b = 2R_S \log_2 M$ となる。

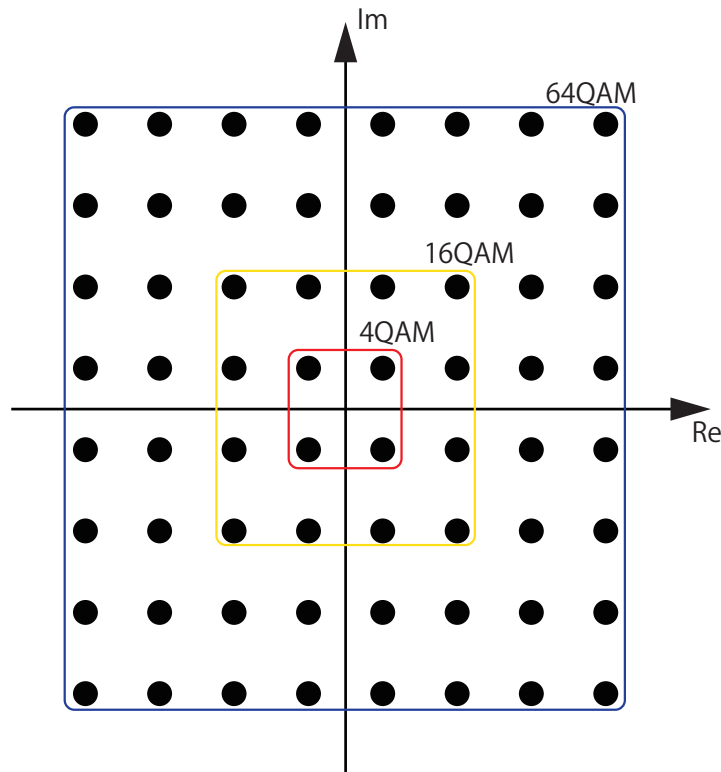


図 3.10 4/16/64QAM コンステレーション

(b) 変調方式およびシンボルレートモニタリングの先行研究

今後、收容サービスが多様化し、また光資源を非線形シャノン限界まで最大限に利用しようとする、光ネットワーク内には多数の種類の変調方式およびシンボルレートの光信号が混在することとなる。このとき、光レベルでの誤接続・誤ルーティングを考慮すると、受信側で到達光信号の種別を識別できることは重要である。この機能は変調方式識

別 (Modulation format identification: MFI) または変調方式認識 (Modulation format recognition: MFR) とよばれ、研究がおこなわれてきた。

[91] では、k-means clustering を用いてコンスタレーションダイアグラム中のシンボルの数をカウントすることで、QPSK、8PSK、16QAM 変調方式を識別している。しかしながらこの方法は、コンスタレーションダイアグラムを得る前に変調方式に依存する信号処理、例えば Decision-Directed 適応等化処理を行っている場合には機能しないため、典型的なデジタルコヒーレント受信システムで用いる際には課題があった。

この課題を解決するため、[70] では適応等化処理の手前で、信号のストークスパラメータを計算し、これを VBEM-GMM を用いてクラスタリングすることで、変調方式識別を行っている。また、[50] では、アイダイアグラムの異なるサンプル点の平均値や分散などからなる 8 つの特徴量を用いてサポートベクターマシン (Support Vector Machine, SVM) の訓練と推論を行い、変調方式の識別を行っている。これらの方法は、変調方式に依存するデジタル信号処理の前で変調方式を識別できる利点を有するが、ストークスパラメータの算出やアイダイアグラムの描画のために、信号からクロック再生を行う必要があった。

クロック再生を用いない方法として、[92] では、非同期サンプリングされた振幅ヒストグラムというより単純な特徴量を、隠れ層が 1 層のみの浅いニューラルネットワークに入力し、変調方式識別が行われている。また、[52, 53] では、遅延検出を用いて測定したデータから主成分分析 (principal component analysis) を用いて、10 個の特徴量を選択し、基準値からのユークリッド距離に応じたパターン認識により、変調方式の識別を行っている。これらの方法は、クロック再生前の測定データから有用な特徴量を取り出し、直接受信系の変調方式 (例: RZ-OOK, ODB) を含む広範な変調方式の識別を実現しているが、16QAM より上の高次 QAM 変調方式の識別には至っていない。

今後大容量化する光ネットワークを考慮した場合、クロック再生および変調方式依存デジタル信号処理の前の測定データを用いて、より高次の変調、例えば 64QAM を含む変調方式の識別が必要となるだろう。このためには、変調方式識別に役立つより精緻な特徴量を測定データから取り出すことが、一つの挑戦となる。

3.6.3 波長分散量のモニタリング

(a) 波長分散

分散は、光ファイバ伝送システムにおける信号歪みの主な原因である。シングルモードファイバ (SMF) は、注入されたパルスのエネルギーがシングルモードのみによって輸

送されるので、モード間の分散が存在しないという利点を有する。しかし、パルス広がり、波長分散のために完全には消えない。本節では、光ファイバ中の波長分散の振る舞いについて説明する [89]。

波長分散（色分散）は、すべての光信号が有限のスペクトル幅を有し、異なるスペクトル成分がファイバを通して異なる速度で移動するために生じる。この速度差の1つの原因は、SMFの屈折率 $n(\omega)$ が周波数依存性であることである。これは材料分散と呼ばれ、シングルモードファイバにおける波長分散の支配的な原因となる。波長分散の別の原因は、ファイバ内の光の断面分布も異なる波長に対して変化することである。より短い波長はファイバコアに完全に閉じ込められ、より長い波長の光パワーの大部分はクラッド内を伝搬する。コアの屈折率がクラッドの屈折率よりも大きいので、この空間的な分布の差は、伝播速度の変化を引き起こす。この現象は構造分散と呼ばれる。一般的に、構造分散は材料分散に比べて比較的小さい。

波長分散を持つ光ファイバ中を伝播する光電場は

$$\frac{\partial E}{\partial z} = \frac{j\beta_2}{2} \frac{\partial^2}{\partial t^2} E, \beta_2 = \frac{\partial^2 \beta}{\partial \omega^2}, \quad (3.25)$$

であらわされる。ここで、 E は光電場、 β は光ファイバの伝播定数である。

光ファイバの波長分散特性は、通常、群速度分散パラメータ D_{CD} によって与えられる。

$$D_{CD} = -2\pi \frac{c}{\lambda^2} \frac{d^2 \beta}{d\omega^2} = 2\pi \frac{c}{v_g^2 \lambda^2} \frac{dv_g}{d\omega}. \quad (3.26)$$

ここで、 $\lambda = 2\pi c/\omega$ は波長、 $v_g = d\omega/d\beta$ は、群速度、 c は真空中の光速度である。

(b) 波長分散量モニタリングの先行研究

波長分散量を推定する方法として大きく、(1) 特定の波形パターンを用いてモニタリングを行う手法、(2) 特段の制約を設けない光波形から推定を行うブラインド手法、がある。(1)の方法としては、例えば [93] があり、特定のデータパターンをパイロットとしてデータ信号に付加し、受信側における波形変化を解析することで波長分散量を推定している。しかしながら、さまざまな変調方式・データフォーマットの光波形が混在すると想定される将来の光ネットワークでは、特定パターンの送受を行う形に制約されない、ブラインド手法が求められるであろう。以下では、この方法の先行研究について述べる。

デジタルコヒーレント光通信における波長分散推定のうち最も基本的なものは、適応等化器のタップ係数を用いるものである [35, 94]。デジタルコヒーレント受信器のデジタル信号処理部で実行される適応等化器は、例えばバタフライ型の有限インパルス応答

(finite impulse response、FIR) フィルタとして実装される。この FIR フィルタのタップ係数を取り出し加工することで、伝送路の逆特性関数が得られる。この逆特性関数に、光ファイバ伝送路中での光電場発展の知識を組み合わせることで、波長分散の値を取り出す。

しかしながら、適応等化器を用いた波長分散量推定には、長距離の伝送がもたらす大きな波長分散量を推定しづらいという課題がある。これは、適応等化器を LSI に実装する際に要する回路規模が大きいため、大きな波長分散量に対応する長いタップ係数を持つ適応等化器の実装が難しいためである。この課題に対処するため、適応等化器の前には、回路規模の比較的少ない、固定波長分散補償器が設置されている。この固定波長分散補償器を用いて、波長分散量を推定する手法が提案されている [94,95]。この方法では、あるコスト関数（例：光信号のピーク電力対平均電力比 (Peak to average power ratio、PAPR)）を計測しながら、固定波長分散補償器に設定する波長分散補償量を変化させ、コスト関数が最小化あるいは最大化した時に指定していた波長分散補償量を、波長分散量として出力する。この方法は巨大な波長分散量に対しても現実的な回路規模で対応可能だが、欠点はスイープを用いるため、波長分散量を同定するまでの所要計測時間が長いことである。

これまでの方法では、光ファイバ中で光波が波長分散を受けてどのように変化するか知識を用いて、人間が推定のためのアルゴリズムを設計していた。より一般的な枠組みの一部として波長分散推定を行うために、機械学習アルゴリズムをもちいて、波長分散推定処理を自動的に学習させる試みが行われている。

機械学習アルゴリズムとして、隠れ層が1層のみの浅いニューラルネットワークを用いたものとして、[46-49] がある。これらの取り組みにおいては、波長分散量推定に有用な所定の特徴量（例：アイダイアグラムから求めた、Q-factor, eye closure, root-mean-square (RMS) jitter, crossing amplitude）が、事前に手動設計されている。同様に、[52,53] では、主成分分析 (principal component analysis) とパターン認識が、[71] では、statistical machine learning を用いて、波長分散量の推定アルゴリズムの学習が行われている。

3.7 深層ニューラルネットワークを用いた光モニタリング

図 3.9 に示したように、光モニタとは、入力光信号を Optical measurement-and-digitization 部において測定し、Data analytics 部において、測定されたデータから有用な要約情報を抽出する機構である。

本節では、光モニタの一種として我々が提案した、深層ニューラルネットワークをもちいた光モニタリング [96,97] について説明する。概要を図 3.11 に示す。ここで、図 3.9 の

Optical measurement-and-ditization 部は、市販のデジタルコヒーレント受信機ハードウェアによって実現される*¹²。この部分は受信機の帯域幅内において、両偏波の光振幅および位相の完全なデジタル化された情報を提供する [98]。これは測定データセットからさまざまな種類の有用な情報を抽出できる可能性を提供する。ADC を使用して非同期的にサンプリングされた波形は、メモリまたはデータベースに格納される。

続く、Data-analytic 部は、深層ニューラルネットワークによって実行される。

ここでは、デジタル情報が分析され、雑音を含んだ高次元情報から、光ネットワークの運用管理に有用な要約記述情報が取り出される。この部分ではいわば情報の分解 (disentanglement) が行われており、入力光電場の持つ属性が取り出される。本論文では、この部分に深層学習を用いることで、柔軟で拡張性の高いモニタリング・スキームを構築している。深層ニューラルネットワークの利用により、チャンネルやコンポーネントの特性を事前にモデリングしなくとも、入力データセットから自動的に設計された信号処理を得ることができる。

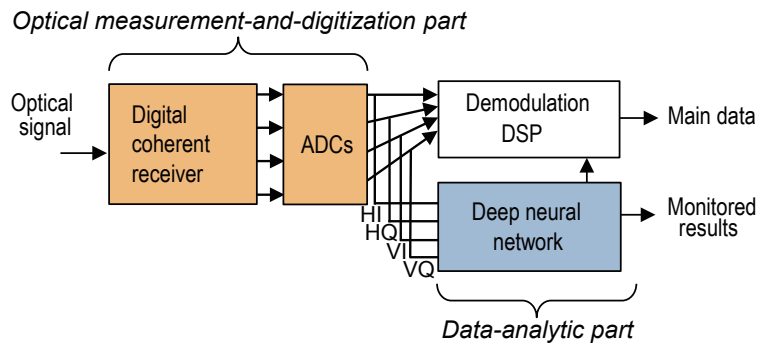


図 3.11 深層ニューラルネットワークを用いた光モニタリング

この深層ニューラルネットワークを用いた光モニタリング手法の特徴は、人手による介入を最小限に抑え end-to-end で学習を行う点にある。これは、(1) デジタルコヒーレント技術により帯域内の全物理量を含むデータを大量に取得できること、(2) 深層ニューラルネットワークを用いることで、大量のデータを活かし、手作業による特徴量設計なしで学習が行えること、による。人手による特徴量エンジニアリングが必要ないことは、多彩な情報処理によって監視の柔軟性を最大化する有望な方法となる。以下の節では、この提

*¹² 光信号を計測し最終的にはアナログ・デジタル変換器 (ADC) を用いて計算可能なデジタル情報に変換するこの部分は、いわば、画像処理において、風景をピクセルの集合に変換するデジタルカメラに相当するものと言える。

案モニタの概念検証のため、同じデータから OSNR 推定、波長分散推定、変調方式／シンボルレート識別の複数の種類のモニタリングが可能であることを示している。複数の種類のモニタリングは、単一のアルゴリズムで実現され、必要なことは学習過程を変えることだけである。

3.7.1 深層ニューラルネットワークを用いた光モニタリングの訓練と推論

深層ニューラルネットワークを用いた光モニタリングには、(1) 訓練モードと (2) 推論モードの2つの動作モードがある。以下では、各々のモードでの動作の詳細について議論する。

(a) 訓練モード

図 3.12 は、訓練モードでの動作を示している。通常、この訓練は、工場で機器の出荷前に行われると想定されている。まず、デジタルコヒーレント受信器で光信号が測定され、Raw-waveform database に保存される。この格納されたデータに、3.5.3 節で議論されたデータ拡張処理を施し、データ数を増加させる。拡張されたデータセットは、Training database に格納される。Training database からのデータと、対応するラベル（期待される DNN 出力である教師データ）が、DNN に提示され 3.4 節で議論した方法により、DNN が訓練される。

(b) 推論モード

図 3.13 は、推論モードでの動作を示している。推論モードのモニタ中の DNN では、訓練モードで学習した重み係数およびバイアスを用いる。推論モードにおいて DNN は単純に、入力信号に対して順方向伝播の演算を行う。我々は DNN の出力結果をモニタ結果として用いる。

推論モードの演算を行う手法として、データセンタベースと光送受信器ベースの、二つが考えられる。以下で各々について議論する。

データセンタベースでの演算

DNN への入力データが十分小さいならば、この入力データをデータセンタに転送し、コンピュータ上で処理を行うことができる。例えば、本論文で用いた DNN への入力データは、一度の推論につき、2kB (= $512 \times 4 \times 8bit$) であるため、1 秒

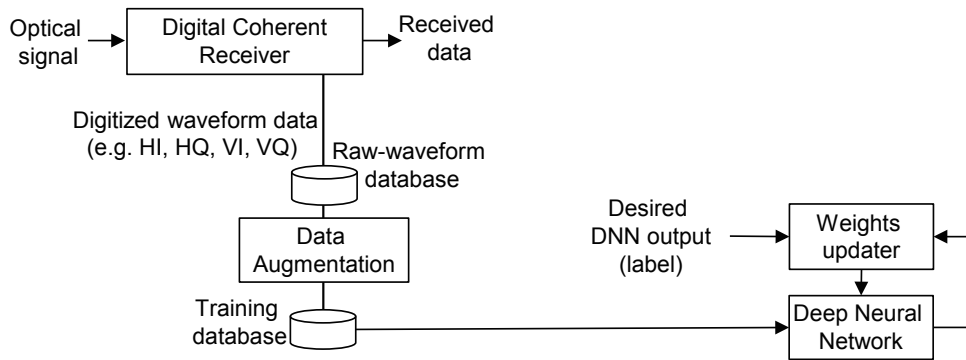


図 3.12 訓練モードでの深層ニューラルネットワークを用いた光モニタ




図 3.13 推論モードでの深層ニューラルネットワークを用いた光モニタ

に 10 回、別の測定データからの推論を行う場合でも、所要転送速度は 20kB/s 程度である。この方法の利点は 2 つある。ひとつは、DNN 演算に割り当てる計算能力と消費電力を緩和できることである。一般に光送受信器が設置されている局舎やフィールドに比べ、よく整備されたデータセンタでは、高い電力効率で計算を処理できる。2 つ目の利点は、データの再利用性が高いということである。複数の拠点で収集されたデータが、単一のデータセンタに集められるため、より高度な分析が実行できる可能性がある。

光送受信器ベースでの演算

推論モードの演算量は訓練モードの演算量に比べ小さい [99] ため、光送受信器内部もしくは付属機器として動作させることも可能であろう。具体的には、組み込み機

器向けの CPU、GPU、FPGA、あるいは ASIC 上での実行が可能と見込まれる。推論モードの演算量が、訓練モードと比較して小さいことその他、DNN の推論がモニタ用途であることを利用し、半リアルタイム動作のためのバースト処理を行うことができる。すなわち、モニタ用途のリフレッシュレートは、波形データの ADC サンプルングレートよりも数桁小さいため、この目的の場合には、DNN をリアルタイム・ストリーミング処理として設計する必要はなく、サンプリングされ測定されたデータの一部のみを使用してバッチ的に計算することが可能である。これは回路の再利用性を高め、より小さな回路規模で DNN の推論を可能にする。光送受信器ベース演算のメリットは、データセンタまでの通信によるレイテンシを受けることなくモニタ結果を参照できることである。これは、送受信器側でモニタ結果に応じた素早いレスポンスが必要な場合、有用な特徴である。

3.8 実験系

3.8.1 本研究で用いた深層ニューラルネットワーク

図 3.14 に、本論文で用いた DNN を示す。すべての DNN は Tensorflow library [100] を用いて構築された。過学習を防ぐために、ドロップ確率 0.5 のドロップアウト [87] とバッチ正規化 [88] が、すべてのネットワークで用いられた。

OSNR 推定向け FC-DNN

図 3.14(a) は、3 つの隠れ層と 1 つの出力層を持つ、全結合型深層ニューラルネットワークである。この DNN は、OSNR の推定に用いられた。隠れ層の数は、我々の以前の研究 [96] の分析を参考に決定された。入力は 40 GSa/s で非同期に AD 変換されたイントラダイン受信器の出力である。HI, HQ, VI, VQ に相当する各成分ごとに、512 サンプルずつが取られ、トータルで 512×4 のデータとなる。これは、図 3.14(b) および (c) の入力と共通である。この多チャンネル入力は、すぐさま flatten 処理され、2048 の 1 次元データに変換された。2048 個のデータは、隠れ第 1 層に入力された。3 層の隠れ層 (FC 1,2, および 3) は、すべて同じ構造を持ち、各々 500 個のニューロンと、ReLU 活性化関数 [81] を持つ。FC 4 は、出力層である。出力層は 1 つの出力ユニットを持ち、活性化関数は線形 (恒等変換) である。訓練のための損失関数として、平均二乗誤差が用いられた。

OSNR および波長分散推定向け CNN

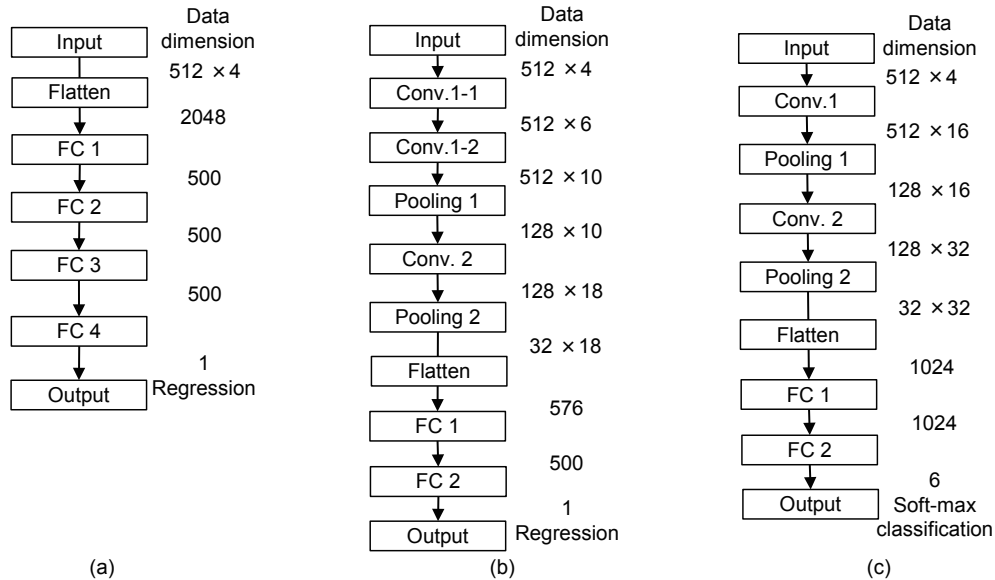


図 3.14 実験で用いられた深層ニューラルネットワーク：(a)OSNR 推定向け全結合型ニューラルネットワーク，(b) OSNR および残留波長分散量推定向け畳み込みニューラルネットワーク，(c) 変調方式およびシンボルレート識別向け畳み込みニューラルネットワーク。

図 3.14(b) は、3 つの畳み込み層と 2 つのプーリング層、2 つの全結合層を持つ、畳み込みニューラルネットワークである。このネットワークは、OSNR の推定と、残留波長分散値の推定に用いられた。入力は図 3.14(a) と同じく、40 GSa/s で非同期に AD 変換されたイントラダイン受信器の出力である。HI, HQ, VI, VQ に相当する各成分ごとに、512 サンプルずつが取られ、 512×4 のデータが用いられた。この 4 チャンネル入力は、Conv.1-1 および 1-2 層を通ることで、10 チャンネルの特徴マップを持つ出力となる。なおこのネットワークのすべての畳み込み層では、ReLU 活性化関数 [81] が用いられた。また、すべての畳み込み層とプーリング層で、ゼロパディングによるエッジ処理が行われた。続く、Pooling 1 ではストライド 4 の最大プーリングが取られ、データ長が $1/4$ となる。Conv.2 層では特徴マップが 18 まで増やされ、Pooling 2 (ストライド 4) で、データ長がさらに $1/4$ にされる。Pooling 2 の後、データは flatten 処理され、 32×18 のデータから、576 の 1 次元データに変換される。576 個のデータは、500 個のニューロンを持つ全結合層 FC 1 に入力される。FC 1 の活性化関数は ReLU 活性化関数である。FC 2 は、出

力層である。出力層は1つの出力ユニットを持ち、活性化関数は線形（恒等変換）である。訓練のための損失関数として、平均二乗誤差が用いられた。

変調方式・シンボルレート識別向け CNN

図 3.14(c) は、2つの畳み込み層と2つのプーリング層、2つの全結合層を持つ、畳み込みニューラルネットワークである。このネットワークは、変調方式およびシンボルレートの識別タスクに用いられた。入力は図 3.14(a) と同じく、40 GSa/s で非同期に AD 変換されたイントラダイン受信器の出力である。HI, HQ, VI, VQ に相当する各成分ごとに、512 サンプルずつが取られ、 512×4 のデータが用いられた。この4チャンネル入力は、Conv. 1層を通ることで、16チャンネルの特徴マップを持つ出力となる。なおこのネットワークのすべての畳み込み層では、ReLU 活性化関数が用いられた。また、すべての畳み込み層とプーリング層で、ゼロパディングによるエッジ処理が行われた。続く、Pooling 1ではストライド4の最大プーリングが取られ、データ長が1/4となる。Conv. 2層では特徴マップが32まで増やされ、Poolin 2（ストライド4）で、データ長がさらに1/4にされる。Pooling 2の後、データはflatten処理され、 32×32 のデータから、1024の1次元データに変換される。1024個のデータは、1024個のニューロンを持つ全結合層 FC 1に入力される。FC 1の活性化関数はReLU 活性化関数である。FC 2は、出力層である。出力層は6つの出力ユニットを持ち、活性化関数はソフトマックス関数である。訓練のための損失関数として、クロスエントロピーが用いられた。このCNNの訓練時には、正則化として重み減衰が用いられた。

これら DNN の訓練及び評価時には、データセット全体をシャッフルし、(1) 訓練用データと (2) テストデータの2つのサブデータセットに分けた。訓練用データセットの数は5,000個、50,000個、および500,000個の3種類が作成された。各訓練用データセットでDNNをトレーニングした後、テストデータセットを使用して訓練されたDNNを評価した。訓練時の学習率の制御にはAdam [85] が用いられた。

3.8.2 データ収集用実験系

ニューラルネットワークの訓練および評価用データを収集するための実験系 [101] を図 3.15 に示す。送信器では、193.3THz のレーザー光源として、外部共振器レーザー（レーザー線幅が約 25 kHz のもの）を使用した。レーザー光は偏波多重型 IQ 変調器に接続された。偏波多重型 IQ 変調器は、4チャンネルのデジタル・アナログ変換器（DAC,

64 GSa/s, 8 bit physical resolution) を使用して生成された駆動信号によって駆動された。DAC の駆動信号は、CW パイロット信号を重畳した 14 もしくは 16 Gbaud (GBd) の DP-4QAM、16QAM、または 64QAM 信号である。送信側 DSP の詳細は、4.3.3 に述べられている。各信号は、ナイキストフィルタ (Roll-off factor = 0.01) により、スペクトラム整形されている。送信側の変調情報 (ボーレート 2 種類、変調方式 3 種類の組み合わせで、計 6 種類) は、DNN の教師あり学習のためのラベルとして記録された。

変調信号は、エルビウム添加ファイバ光増幅器 (EDFA) に送られた後、追加の ASE 雑音が付加された。この光の OSNR は、光スペクトルアナライザ (OSA) を使用して測定された。OSA で測定された OSNR の値は、DNN の教師あり学習のためのラベルとして記録された。

受信器では、局部発振レーザー (レーザー線幅 ~25 kHz) と、信号光が、偏波ダイバーシティ型 90 度ハイブリッドで重畳された。ハイブリッドの出力は、4 つのバランス型フォトダイオードで受信された。4 つのフォトダイオードの出力は 40 GS/s の 4 チャンネル アナログ・デジタル変換器 (ADC) を用いてデジタル化された。デジタル化されたサンプルは、コンピュータ上でオフラインで処理された。図には示していないが、復調後のビット誤り率を評価することにより、送信データの正しい受信を確認した。デジタル化された HI, HQ, VI, VQ データから複素電場が再構成され、コンピュータ上で波長分散が付加された。付加した波長分散の量は、DNN の教師あり学習のためのラベルとして記録された。最終的に、波長分散が付加された HI, HQ, VI, VQ のデータが、Raw-waveform database に格納された。

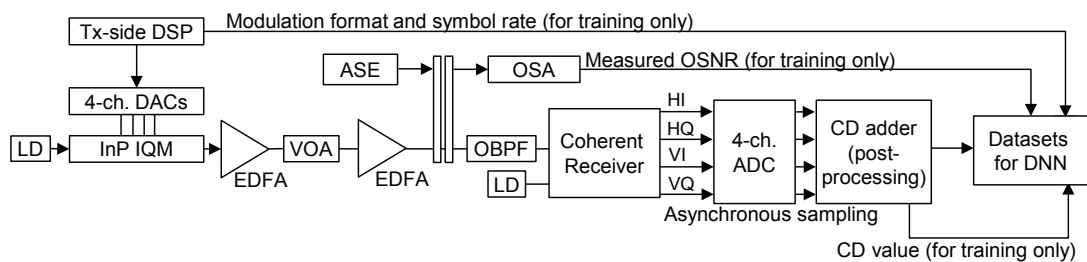


図 3.15 実験系. LD : レーザーダイオード, EDFA : エルビウム添加ファイバ光増幅器, VOA : 可変光減衰器, ASE : 自然放射増幅光源, OBPF : 光バンドパスフィルタ, DAC : デジタル・アナログ変換器, InP IQM : インジウムリン・ベース IQ 光変調器, ADC : アナログ・デジタル変換器.

3.8.3 データ拡張

3.7.1節で示したように、Raw-waveform database から呼び出されたデータには、データ拡張処理が施された後、Training database に格納される。本実験で施されたデータ拡張は、偏波回転と、周波数オフセット印加の2つである。

(a) 偏波回転

偏波回転によるデータ拡張を行うため、サンプリングレート f_s (Hz) でサンプルされた HI, HQ, VI, VQ のデータから、時間変化する Jones vector

$$\begin{pmatrix} E_x(nT_s) \\ E_y(nT_s) \end{pmatrix} = \begin{pmatrix} HI(nT_s) + jHQ(nT_s) \\ VI(nT_s) + jVQ(nT_s) \end{pmatrix} \quad (3.27)$$

を構成する。ここで、 j は虚数単位、 T_s はサンプリングレート f_s の逆数、 $n = 0, 1, 2, \dots$ は時間を示すインデックスである。この Jones vector に 2×2 複素ユニタリ行列 U

$$\begin{pmatrix} a & b \\ -\bar{b} & \bar{a} \end{pmatrix} \quad (3.28)$$

を掛けることで、偏波回転後の新たな Jones vector

$$\begin{pmatrix} \tilde{E}_x(nT_s) \\ \tilde{E}_y(nT_s) \end{pmatrix} = U \begin{pmatrix} E_x(nT_s) \\ E_y(nT_s) \end{pmatrix} \quad (3.29)$$

を計算することができる。ただし、 $a\bar{a} + b\bar{b} = |a|^2 + |b|^2 = 1$ である。

本実験におけるデータ拡張においては、9種類の異なる U をランダムに設定し、元のデータと掛けあわせることで、元データと合わせて計 10種類の偏波状態をデータ中に含めた。

(b) 周波数オフセット

受信側の光ハイブリッドにおいて信号光と局発光が干渉するとき、信号光-局発光間の周波数差により、光ハイブリッドの出力をサンプリングしたデジタル化光電場に、周波数のオフセットが重畳される。2つのレーザーの周波数を完全に一致させることは難しいため、測定データには各測定ごとに異なる周波数オフセットが重畳されることになる。そのため、推論時には、訓練データとは異なる周波数オフセットが重畳されたデータが入力される可能性が高い。このような周波数オフセットの揺らぎに対応するため、測定データに以下のようにランダムな追加周波数オフセットを付加するデータ拡張を行う。

$$\tilde{E}_{x/y}(nT_s) = E_{x/y}(nT_s) \exp(j2\pi f_{max} unT_s) \quad (3.30)$$

ここで、 j は虚数単位、 T_s はサンプリングレート f_s の逆数、 $n = 0, 1, 2, \dots$ は時間を示すインデックス、 f_{max} は追加する周波数オフセットの最大値、 u は、-1 から +1 までの一様乱数、 $E_x(nT_s) = HI(nT_s) + jHQ(nT_s)$ 、 $E_y(nT_s) = VI(nT_s) + jVQ(nT_s)$ である。

本実験におけるデータ拡張においては、 $f_{max} = 400MHz$ として、DNN への各入力データ (512 サンプル) 毎にランダムな周波数オフセットを印加した。

3.9 結果と考察

3.9.1 OSNR の推定

(a) トレーニングデータ数の依存性

最初に、図 3.14(a) に示した FC-DNN を、異なる数の訓練データセットで訓練することで、訓練データセット数によるモデル性能の変化を調べた。訓練および評価データセットは、OSNR 8 dB から 28 dB までの 14 GBd DP-QPSK 信号と 16 GBd DP-QPSK 信号が混在したデータである。訓練データ中の 14 GBd DP-QPSK 信号と 16 GBd DP-QPSK 信号のデータ数の比は 1:1 に調整された。3.8.3 節で説明した偏波回転および周波数オフセットが、データ拡張として行われた。

最初に、5,000 個の訓練データで訓練した FC-DNN による OSNR 推定の結果を図 3.16 に示す。黒色の破線は、FC-DNN の出力が実際に OSA で測定された OSNR と等しい線を示し、DNN が正しく訓練された場合、結果がこの破線上に乗るであろう期待値でもある。赤色の菱形点は、訓練データセットを用いた場合の DNN の出力である。青色の丸点は、テストデータセットを用いた場合の DNN の出力である。半透明の範囲は、標準偏差を示す。5,000 個の訓練データセットにより訓練された FC-DNN は、訓練データセットに対しては期待される結果を返すが、未知のデータであるテストデータセットに対しては、期待値と大きく異なる挙動を返した。これは、少ない訓練データ数が、過学習を誘発していることを示している。

図 3.17 は、訓練データセットの数を 10 倍 (50,000 個) とした場合の結果である。50,000 個のデータを用いても、過学習は継続していた。訓練データをさらに 10 倍とし、500,000 個のデータで訓練した結果を、図 3.18 に示す。この場合、過学習は緩和され、訓練データセットとテストデータセットに対応する FC-DNN 出力がほぼ重なっていることを示している。大量の訓練データセット (例: 500,000 個) が、ニューラルネットワークの過学習を回避し、既知の訓練データセットだけでなく未知のテストデータセットに対して FC-DNN ベースの OSNR 推定の使用を可能にすることを示している。




図 3.16 FC-DNN による OSNR 推定結果. 訓練データ数: 5,000, 赤色菱形点: 訓練データセット, 青色丸点: テストデータセット. 半透明の範囲は標準偏差を表す.

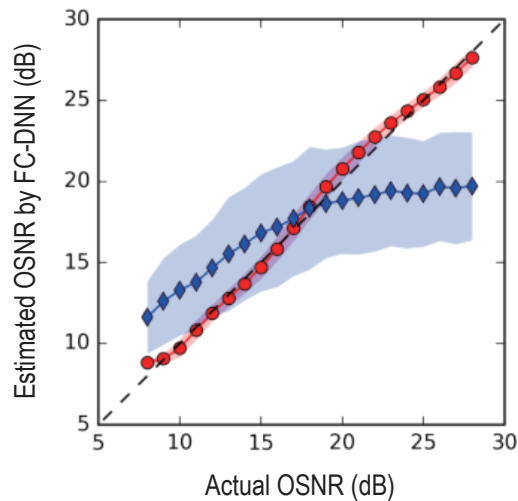


図 3.17 FC-DNN による OSNR 推定結果. 訓練データ数: 50,000, 赤色菱形点: 訓練データセット, 青色丸点: テストデータセット. 半透明の範囲は標準偏差を表す.




図 3.18 FC-DNN による OSNR 推定結果。訓練データ数：500,000，赤色菱形点：訓練データセット，青色丸点：テストデータセット。半透明の範囲は標準偏差を表す。

(b) FC-DNN と CNN の比較

本節では、前節で FC-DNN を用いて行った OSNR の推定を、CNN を用いて行うことで改善を試みる。図 3.14(b) の CNN を訓練し、OSNR の推定を行った。訓練データは前節で FC-DNN の訓練に用いたものと同じである。訓練データ数が 5,000 個、50,000 個、500,000 個の結果を、図 3.19、図 3.20、図 3.21 にそれぞれ示す。注目すべきことは、図 3.19 に見られるように、この CNN は、前節で用いた FC-DNN よりもより少ない訓練データの個数で、テストデータに対しても概ね正しい値を返すことである。訓練データ数が 5,000 および 50,000 個の場合、OSNR が高い部分で推定値にバイアスが載っていることが見て取れるが、これも図 3.21 に見られるように、訓練データ数が 500,000 個まで上昇すると消失した。

(c) CNN が過学習に陥ることなく OSNR 推定を行えることについての考察

前節でみたように、CNN は FC-DNN と比較して、少数の訓練データにおいても、訓練データのみならずテストデータにおいても、良好な OSNR 推定を学習している。これは推定すべき量である OSNR が、本ニューラルネットワークに入力されるデータの軸（時間軸）に対して不変であることから、畳み込みとプーリングを用いて時間軸方向の普遍性を獲得しつつ、ニューラルネットワークのパラメータ数を効果的に削減できているためと




図 3.19 CNN による OSNR 推定結果. 訓練データ数 : 5,000, 赤色菱形点 : 訓練データセット, 青色丸点 : テストデータセット. 半透明の範囲は標準偏差を表す.




図 3.20 CNN による OSNR 推定結果. 訓練データ数 : 50,000, 赤色菱形点 : 訓練データセット, 青色丸点 : テストデータセット. 半透明の範囲は標準偏差を表す.




図 3.21 CNN による OSNR 推定結果. 訓練データ数: 500,000, 赤色菱形点: 訓練データセット, 青色丸点: テストデータセット. 半透明の範囲は標準偏差を表す.

推測される。

具体的には、畳み込み型ニューラルネットワークの畳み込み層は、全結合型の層間の結合に、カーネルの係数が入力データ全域にわたって共有されるという制約を課したものとみなすことができる。これにより、畳み込み型ニューラルネットワークでは、全結合型と比較して独立なパラメータ数が大幅に削減されている。また、パラメータ共有により、出力は畳み込みの軸に対する不変性を、自然に要請される。

上記の特徴は、OSNR モニタリングのみならず、より一般的なモニタリングに適用できる概念である。なぜならば、入力する光信号に対して要約量を出力するというモニタリングの本来的挙動からして、少なくとも短時間の入力データ内では、時間軸方向に対する不変性獲得が要求されるからである。

(d) CNN ベース OSNR 推定の従来手法との比較

異なるニューラルネットワークを用いた時の推定誤差を比較するため、テストデータを用いて OSNR 8 dB から 28 dB までの推定バイアスおよび標準偏差を平均したものを図 3.22 および図 3.23 に示す。両グラフとも赤色の丸点が FC-DNN、青色の菱形点が CNN を示す。バイアスおよび標準偏差とも訓練データ数を増加させること減少する傾向が見取れる。特に CNN を用いた場合は、500,000 個の訓練データを用いた場合で、バイアスが ~ 0.1 dB、標準偏差が ~ 0.4 dB という推定精度を示している。この推定精度を直接先

先行研究と比較することは、本論文の手法が手動での特徴量抽出を用いないことと比較し、先行研究においては手動での特徴量抽出が行われていること、また、試験に用いている光信号種（変調方式やシンボルレート等）が異なることから、一般には難しいと思われる。しかしながら最終的に得られた OSNR モニタの精度としては、本モニタの結果は、例えば先行研究 [46] ^{*13}で示されている OSNR モニタのバイアスエラー 0.58 dB (推定 OSNR 範囲 16 から 32 dB) および 1.23 dB (推定 OSNR 範囲 12 から 32 dB) との比較に耐える精度といえる。^{*14}




図 3.22 FC-DNN および CNN による OSNR 推定のバイアス誤差。赤色丸点：FC-DNN，青色菱形点：CNN。

(e) 訓練データのシンボルレートに対する依存性

ここまで、14 GBd と 16 GBd の信号が 1:1 で混在する訓練データを用いて DNN の訓練を行ってきた。訓練データの持つこの多様性は、本質的に必要なものであったのだろうか？この問いに答えるため、(a) 訓練データを 16 GBd に限ったもの、(b) 訓練データを 14 GBd に限ったもの、を用いて CNN の訓練を行った。訓練済みの CNN は、14 GBd

^{*13} 隠れ層が 1 層のみの浅いニューラルネットワークを用いている。

^{*14} [48] で報告されている OSNR 推定範囲 16–28 dB に対して root-mean-square (RMS) error 1.27 dB、[47] での OSNR 推定範囲 14–30 dB に対して RMS error 0.77 dB、[50] での OSNR 推定範囲 4–30 dB に対して推定誤差 0.7 dB、[52] での OSNR 推定範囲 14–28 dB に対して平均推定誤差 1.0 dB、等と比較しても良好な結果である。

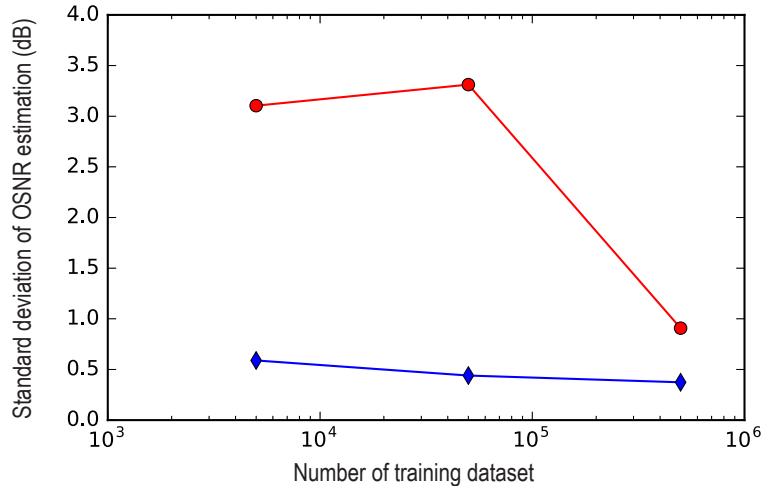


図 3.23 FC-DNN および CNN による OSNR 推定の標準偏差. 赤色丸点 : FC-DNN, 青色菱形点 : CNN.

もしくは 16 GBd の信号で個別にテストされた。訓練データ数は、500,000 個である。結果を図 3.24 に示す。

図 3.24(a) は、16 GBd 信号を用いて CNN を訓練した際の結果である。この場合、訓練データに含まれる 16 GBd 信号 (青色) に対しては正しい OSNR 推定がなされるが、訓練データに含まれていなかった 14 GBd 信号 (赤色) に対しては、正しい推定が行えていない。図 3.24(b) は、14 GBd 信号を用いて CNN を訓練した際の結果であるが、同様の結果である。すなわち、訓練データに含まれる 14 GBd 信号 (赤色) に対してのみ、正しい OSNR 推定がなされている。訓練データに多様性を持たせ、14/16 GBd 信号を 1:1 で含むようにすると、どちらのボーレートに対しても正しい推定が行えるようになる (図 3.24(c))。

(f) 変調方式に対する独立性

本節では、前節で訓練された図 3.14(b) の CNN を用いた OSNR 推定器について、複数の変調フォーマットとシンボルレートに対応しているかを調査する。本節では、訓練データセット 500,000 個で訓練された CNN を用いる。訓練データ中の 14 GBd 信号と 16 GBd 信号のデータ数の比率は 1:1 とした。ここで、訓練過程で、シンボルレートについては 14 および 16 GBd が混在したデータを用いて CNN を訓練したが、変調方式につ




図 3.24 CNN による OSNR 推定. (a) 16 GBd DP-QPSK データによる訓練、(b) 14 GBd DP-QPSK データによる訓練、(c) 14 GBd/16 GBd DP-QPSK 混合データによる訓練. 赤色 : 14 GBd DP-QPSK による評価結果、青色 : 16 GBd DP-QPSK による評価結果.

いては DP-QPSK に固定していたことを思い出そう。そのため、訓練済みの CNN が複数の変調方式に対応するかは自明ではない。

訓練済みの CNN に対して、14 GBd の DP-QPSK、DP-16QAM、DP-64QAM のテストデータで OSNR 推定をテストした結果を図 3.25 に示す。訓練データに含まれていた 14 GBd DP-QPSK 信号だけでなく、異なる変調方式 (DP-16QAM および DP-64QAM) においても、正しい OSNR 推定がなされていることがわかる。次に、16 GBd の DP-QPSK、DP-16QAM、DP-64QAM のテストデータで OSNR 推定をテストした結果を図 3.26 に示す。こちらにおいても、訓練データに含まれていた 16 GBd DP-QPSK 信号だけでなく、異なる変調方式でも、正しい OSNR 推定がなされていた。

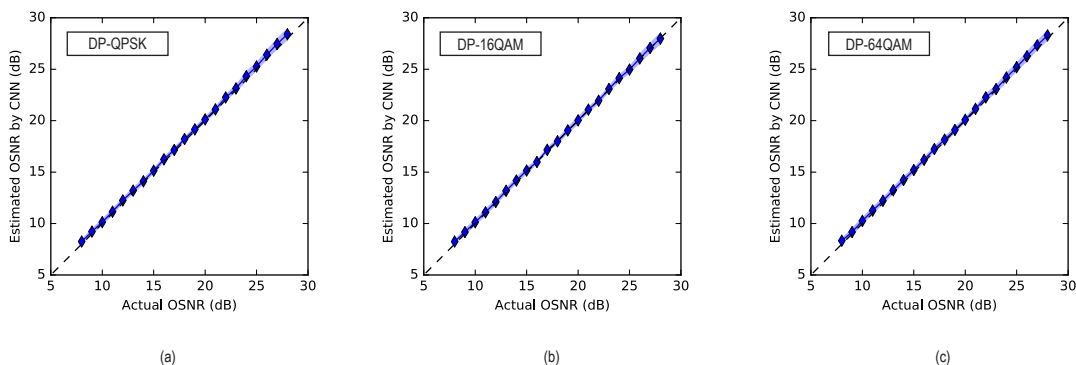


図 3.25 14 GBd 信号を入力した際の訓練済み CNN による OSNR 推定結果. (a) DP-QPSK, (b) DP-16QAM, (c) DP-64QAM.




図 3.26 16 GBd 信号を入力した際の訓練済み CNN による OSNR 推定結果. (a) DP-QPSK, (b) DP-16QAM, (c) DP-64QAM.

(g) 波長分散に対する独立性

本節では、訓練された図 3.14(b) の CNN を用いた OSNR 推定器について、残留波長分散耐力を調査する。本節では、訓練データセット 500,000 個で訓練された CNN を用いる。ここで、訓練課程では波長分散の付加されていないデータを用いて CNN を訓練したことを思い出そう。そのため、訓練済みの CNN が残留波長分散に対してどの程度の耐力を有しているかは自明ではない。

我々は、16 GBd DP-64QAM 信号に、最大で 50,000 ps/nm の波長分散を付加したテストデータを準備し、訓練済み CNN を試験した。この波長分散量は標準シングルモードファイバで 2,500km 以上を波長分散補償なしで伝送した際の累積波長分散量に対応する。これは多くの陸上光ファイバ伝送システムにおける最大伝送距離に相当する。

図 3.27 に、各残留波長分散量での CNN による OSNR 推定の様子を示す。ここで注目すべきポイントは、この CNN 自体は残留波長分散量がゼロのデータで訓練されているにもかかわらず、少なくとも 50,000 ps/nm までは、OSNR 推定精度が残留波長分散量には依存しないことである。この事実に対する説明はいくつか考えられるが、一つの可能な説明としては、CNN の内部では、OSNR の推定をある種の周波数コンポーネントを介して行っている可能性がある。一部の周波数コンポーネント、例えばパワースペクトラムは、アイパターン等の時間波形と異なり、波長分散の付加によってその形を変えないからである。

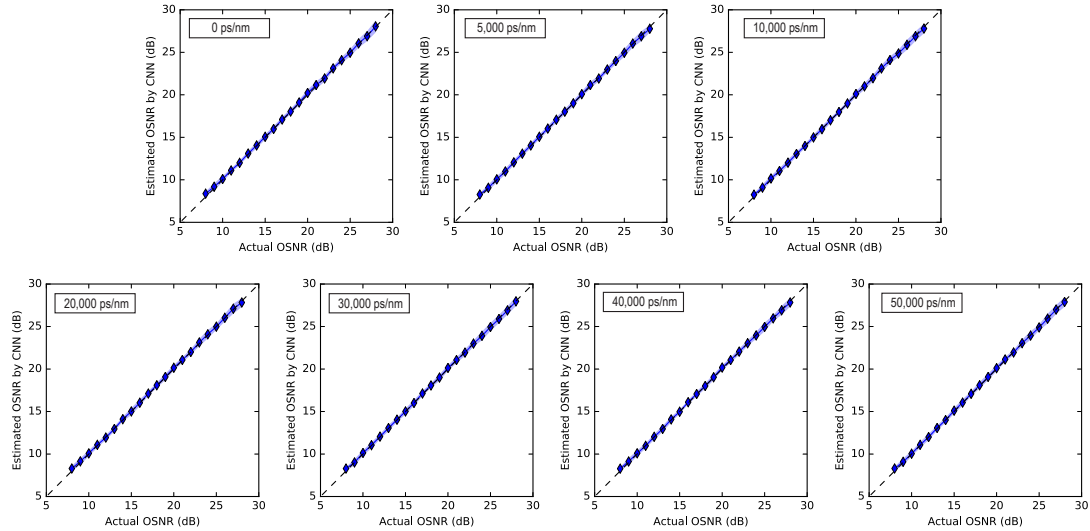


図 3.27 0, 5000, 10000, 20000, 30000, 40000, 50000 ps/nm の波長分散を付加した 16 GBd DP-64QAM 信号に対する訓練済み CNN の OSNR 推定結果

3.9.2 波長分散量の推定

本節では、CNN ベースの光モニタが、光信号に含まれる残留波長分散量の推定にも転用可能なことを示す。この節では、図 3.14(b) に示された CNN を用いて、入力光信号に含まれる波長分散量を推定した。この CNN は、OSNR 推定に用いたものと同じ構造である。訓練および試験データとして、0 から 1500 ps/nm までの範囲のランダムな波長分散 (1 ps/nm 刻み) が付加された、16 GBd DP-QPSK 信号 (OSNR = 31 dB) を用いた。学習時の訓練損失および評価損失を図 3.28 に示す。訓練データセットと Validation データセットの両方で損失が下がり、過学習が上手く回避できていることが分かる。

5000 epoch 後の訓練済み CNN を用いて、波長分散量推定の評価を行った結果を図 3.29 に示す。0 から 1500 ps/nm まで、100 ps/nm 刻みのテストデータを用いて、各波長分散ごとに推定値の平均値を求め、プロットした。OSNR 推定と同様の CNN アーキテクチャを用いることによって、学習範囲内の波長分散が、精度よく推定できていることが見て取れる。

細部を観察するため、CNN によって推定された波長分散の値から実際の波長分散値 (ラベル値) を差し引き、各点のバイアスと標準偏差を求めた。図 3.30 に結果を示す。プロット点がバイアス、青い半透明で塗られた領域が各点の標準偏差を表す。標準偏差を考




図 3.28 波長分散推定タスクを学習した際の訓練損失および検証損失の変化




図 3.29 訓練済み CNN による波長分散量の推定 (0–1500 ps/nm)

慮した場合でも、CNN による推定の誤差が ± 50 ps/nm を超えないことが見て取れる。

次に、試験データに付加された波長分散の値を、訓練に用いられた 0 から 1500 ps/nm を超える、-2000 から +2000 ps/nm に拡大した結果を図 3.31 に示す。プロット点が各波長分散での平均値、青い半透明で塗られた領域が各点の推定値の標準偏差を表す。この結果は、訓練データに含まれた 0 から 1500 ps/nm の波長分散量はよく推定できているが、訓練範囲を超える波長分散推定能力までは、CNN が獲得していない様子を示す。注目すべき点は、推定波長分散量が、付加分散量の正負で概ね対称になっていることであろう。これは、訓練データセットに正の波長分散しか含まれていなかったため、CNN が波長分散量の絶対値のみに着目した学習を行った可能性を示唆する。




図 3.30 訓練済み CNN による波長分散量推定結果の誤差 (0–1500 ps/nm)。半透明の領域は標準偏差を示す。




図 3.31 訓練済み CNN による波長分散量の推定 (-2000 – +2000 ps/nm)

3.9.3 変調方式・シンボルレート識別

本節では、CNN ベースの光モニタを用いて、光信号の変調方式および変調シンボルレートを識別できることを示す。この節では、図 3.14(c) に示された CNN を用いて、入力光信号を 6 つのカテゴリに分類した。各カテゴリは信号が、(1) 14 GBd DP-QPSK、(2) 16 GBd DP-QPSK、(3) 14 GBd DP-16QAM、(4) 16 GBd DP-16QAM、(5) 14 GBd DP-64QAM、(6) 16 GBd DP-64QAM、で変調されていることを示す。

訓練および試験データとして、上記 6 カテゴリの変調方式が同数混在したデータセットを用いた。このとき OSNR は各変調方式ごとに 10dB から 28dB まで (1 dB 刻み) を均等に混在させた。波長分散は 0ps/nm であった。訓練済みの CNN を用いて、6 カテゴリの分類を行った結果を図 3.32 および 3.33 に示す。




図 3.32 訓練済み CNN による変調方式・シンボルレート識別の混同行列 (訓練データ)

図 3.32 は、訓練データセットを用いた時の混同行列 (confusion matrix)、図 3.33 はテストデータセットを用いた時の混同行列である。各変調方式において若干の違いがみられるが、どの変調方式+シンボルレートにおいても、訓練データセットを用いた時には、> 98.5% の、テストデータセット時は、> 93.0% の識別率が得られた。この混同行列で注目すべきことは、どの場合でも誤った識別をする場合は、同じシンボルレートの異なった変調方式 (例えば、14 GBd DP-QPSK を、14 GBd DP-16QAM と誤認する) という




図 3.33 訓練済み CNN による変調方式・シンボルレート識別の混同行列（テストデータ）

ことである。評価した範囲内では、別のシンボルレートと誤認する例は見られなかった。これは、変調方式識別よりも、シンボルレート識別のほうが、この CNN にとって容易なタスクであったことを示唆する。

識別率の詳細を議論するため、テストデータセットで調べた識別率を各 OSNR 毎にプロットしたものを図 3.34 に示す。このグラフから、どの変調方式でも、受信 OSNR が悪い領域では、識別率が下がる様子が見て取れる。興味深いことは、簡単な変調方式（例：QPSK）においても、複雑な変調方式（例：64QAM）においても、OSNR の劣化に伴う識別率の下落は、同程度であるという点であろう。

なお、この変調方式+シンボルレートの識別は、CNN への 1 データ入力、すなわち光波の実時間における 12.8 ns ($= 512 \times (1/40 \text{ GHz})$) 分のデータのみに基づいた判別である。これは通常期待されるモニタリングの周期と比較して短い時間間隔であるため、所定の時間内に複数回の推定を行うことが可能であろう。そのため複数回推定のアンサンブルを取ることによって、最終的な識別率の上昇が期待される。

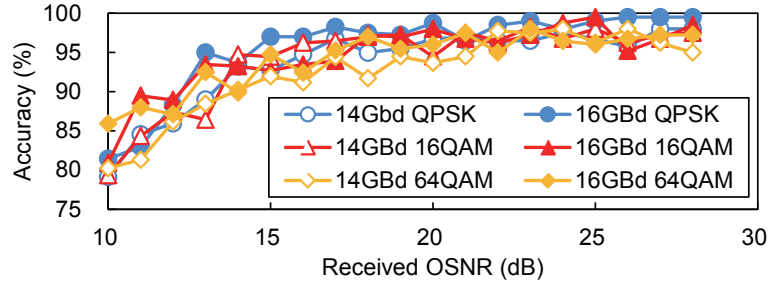


図 3.34 訓練済み CNN による変調方式・シンボルレート識別精度の OSNR 依存性

3.10 むすび

本章では深層ニューラルネットワークとデジタルコヒーレント受信器を組み合わせた光物理層モニタを提案し、実験的に実証した。デジタルコヒーレント受信器を利用して非同期にサンプリングされた 16 GBd/14 GBd DP-QPSK 信号を用いて訓練された FC-DNN/CNN ベースの OSNR 推定器は、6 種類の変調方式/シンボルレートを持つ光信号の OSNR を推定可能であった。またこの訓練済み CNN による OSNR の推定は、残留波長分散に依らず可能であった。深層ニューラルネットワークを用いた光モニタはまた、波長分散量の推定にも用いられた。OSNR 推定を行った CNN と同じ CNN を用いて、波長分散の推定が可能であることを示した。深層ニューラルネットワークを用いた光モニタのフレームワークはまた、変調方式とシンボルレートの識別にも適用可能であった。訓練された CNN は、6 種類の変調方式/シンボルレートを持つ光信号を、93% 以上の精度で識別した。

第4章

光送受信器を用いた光電場の制御

But if we conceive a being whose faculties are so sharpened that he can follow every molecule in its course, such a being, whose attributes are still as essentially finite as our own, would be able to do what is at present impossible to us.

J. C. Maxwell, *Theory of Heat*, 1872

4.1 はじめに

デジタル信号処理 (Digital signal processing: DSP) [7] および誤り訂正 (Forward error collection: FEC) [102, 103] の利用は、コヒーレント光受信 [5] における大容量伝送システムを可能にした。近年では、メトロエリア内で地理的に分散したデータセンタ間で通信を行う、データセンタ間接続 (datacenter interconnection: DCI) に向けて [104–106]、大容量のみならず、低レイテンシな光ファイバ伝送システムが注目されている。

この章では、上位層から要求される複数の伝送要件 (スループット、信号品質、および遅延) を同時に満足する光信号の伝送を行えるよう、光送受信器の柔軟性を拡張する。要件の異なる複数のサービスを同時に伝送するため、この光送受信器では、1 台の光送受信器が複数の光サブチャネルを生成・受信する。複数の要件を同時に満たすため、光送受信器のパラメータ群 (変調方式、シンボルレート、光パワー割り当て、及び FEC) が、光物理層モニタの情報に従って制御される。

ここで、複数のサブチャネルが誤り訂正を含む多くのパラメータを持つため、これらのパラメータの組み合わせ数は爆発的に増加する。そのため、パラメータの最適な組み合わせを簡単に見つけられるように、これをうまく管理することが重要となる。提案した送受信器のコントローラ部は、解析モデルとパラメータ群の制約条件を用いて、現在の光送受信器および光物理層モニタによって推定された伝送路での送受信が可能なパラメータ群を発見する。

我々は、この種の光送受信器がサービス/アプリケーション側の要求に従って光電場を制御することから、アプリケーション指向プログラマブル光送受信器 (Application oriented programmable optical transceiver, AoPot) と呼んでいる [101]。

我々は、この AoPot を CNN を用いた OSNR モニタによる伝送路状態推定と組み合わせることで、処理遅延に敏感なアプリケーションを備えたユースケースにおける、光信号種の設定とデプロイを、実験的に検証した。

4.2 プログラマブル光送受信器の先行研究

光送受信器が用いる帯域幅と周波数利用効率に柔軟性を持たせる試みは、EDFA 光増幅器の増幅帯域に限りがあることから、これを有効に活用するべく活発に研究されてきた。たとえば、Heinrich Hertz Institute (HHI) のグループによる、BPSK、QPSK、

16QAM 光信号の生成が可能な FPGA ベースのプログラマブル光送受信器の研究があげられる [25]。同グループはその後、同光送受信器で利用できる変調方式を 4 次元変調方式にまで拡張した [20]。多様な変調方式を組み合わせることで、光信号の周波数利用効率を制御するさまざまな手法が提案されてきた [21, 26–31]。最近ではコンスタレーション点の出現確率を調整することで、精緻な周波数利用効率制御を行う、Probabilistic shaping 方式が注目を集めている [32]。

こうした変調方式の可変と、光レベルのスライシングを組み合わせたネットワークの利用は、Jinno によって、Flexible Optical Network あるいは Elastic Optical Network として体系的に議論された [54]。Bristol 大学のグループからも同様に、光レベルのスライシングと DSP レベルの変調を併用した方法が発表されている [55]。

また、変調方式やそれに関わる DSP を変更するのではなく、誤り訂正符号を変更することで同様の効果を得る研究もおこなわれている [56–58]。

これらの、プログラム可能なパラメータ群を有する光送受信器は、光レベルの信号処理（例：Wavelength selective switch (WSS) によるスライシング）とデジタルレベルの信号処理（例：変復調 DSP および FEC）のパラメータを制御することで、所望の光信号を得る。しかしながら従来の研究に共通することは、この種の光送受信器がパラメータ群を調整する目的が、伝送距離とスループットの間のトレードオフを調整することに限られていたことである。

光ファイバ伝送において、もう一つの重要なパラメータである遅延とのトレードオフが軽視されてきたことは、驚くべきことではない。なぜならば、数百 km 以上の長距離を伝送する従来の光ファイバ通信では、全体の遅延の中で光ファイバの伝送遅延が占める割合が支配的であり、送受信器のパラメータ群の制御で調整可能な光送受信器内での処理遅延は、相対的に小さなものであったからである。

しかしながら、この状況は二つの側面から変わりつつある。ひとつは、近年において大容量光ファイバ通信の伝送距離が、短距離化しつつあるという事実である。多年にわたる努力の積み重ねにより、現在、光伝送技術は非線形シャノン限界に漸近しつつある。これは、長距離伝送と大容量伝送の両立が難しくなったことを意味する。この制約下で伝送容量の大容量化を志向すれば、それは必然的に短距離化をもたらす。

もう一つの側面は、低レイテンシ通信需要の増大である。現在、都市内に分散したデータセンタ間を結ぶデータセンタ間接続（Data center interconnect: DCI）光ファイバネットワークが、急速に構築されつつある。この DCI においては、複数のデータセンタ間で協調動作を行うため、低レイテンシが要求される。また次世代アプリケーションとして、遠隔地の機器操作や自動運転制御、仮想現実（Virtual Reality: VR）ストーリーミングな

どが提唱されている。これらのアプリケーションのためには、通信ネットワークによるレイテンシを最小限に保つ必要があるだろう。

4.3 AoPot の概要

この節では、DSP と FEC のプログラマブルなパラメータ群を制御する光送受信器である、AoPot について説明する [101,107]。AoPot が既存のフレキシブル光トランシーバと異なる点は、複数の要件を同時に満たすようパラメータを調整する点である。具体的に AoPot は、伝送距離とスループットの間のトレードオフだけでなく、伝送距離・スループット・遅延の 3 者間のトレードオフを調停する。図 4.1 に、AoPot の概念図を示す。

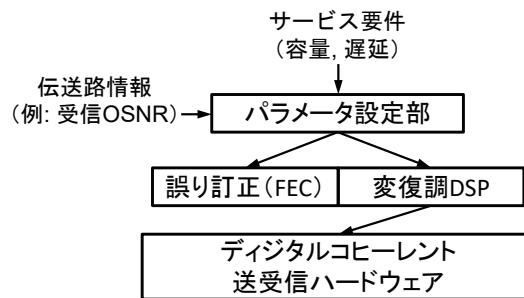


図 4.1 アプリケーション指向型光送受信器の概念図

AoPot はパラメータ設定部、デジタルコヒーレント光送受信ハードウェア部（光/電気コンポーネント）、DSP/FEC 部で構成される。パラメータ設定部は、AoPot を制御するコントローラである。光物理層モニタによって推定された伝送路の情報を利用して、DSP/FEC を制御する。

デジタルコヒーレント光送受信ハードウェアと DSP/FEC の詳細については、後の節で議論しよう。ここで重要なことは、AoPot では、DSP/FEC 以外の光/電気コンポーネントとして、既製のデジタルコヒーレント光送受信器のものが流用できるということである。これにより、AoPot は、ハードウェア面におけるコスト優位性を享受することができる。

一方、AoPot コントローラ（パラメータ設定部）の主たる機能は、膨大なパラメータ組み合わせから、複数の要件を同時に満たし、かつ、現在の送受信器と伝送路で実行可能な、パラメータ群の部分集合を選び出すことである。AoPot コントローラの詳細については、続く節で議論される。

4.3.1 誤り訂正部における処理遅延の制御

誤り訂正 (Forward Error Collection: FEC) は、大容量の光ファイバ伝送システムを実現するキー技術の一つである。特に、近年重要になりつつある短距離伝送では、FEC の処理遅延を含む光送受信器の処理遅延は、物理層の総レイテンシのうち、無視できない部分を占めると予測される。例えば、25 km の標準シングルモードファイバ (Standard single mode fiber: SSMF) 上の 1550 nm の波長の光信号は、約 $122\mu s$ の伝搬遅延を生み出す [108]。この遅延量と比較して、FEC 復号化で発生する処理遅延の範囲は $15\sim 150\mu s$ と考えられている [108]。例えば、[109] では、90 nm CMOS (Complementary metal-oxide-semiconductor) プロセス技術におけるレイアウト後シミュレーション (スループット 81.9 Gbit/s) において、誤り訂正処理の内のひとつである、G975.1-I.3 連結 BCH デコーダが、 $25.5\mu s$ の処理遅延を生むことを報告している。これらの事実は、FEC を含む DSP のアルゴリズムを最適化することによって、少なくとも短距離伝送においては、物理層で生成されるレイテンシを最小限に抑えることができることを示唆している。

4.3.2 デジタルコヒーレント光送受信ハードウェア

(a) 光送信器

図 4.2 に、光送信器の概念図を示す。偏波多重信号を生成する光変調器には多くの実装が存在するが、この節では、最も一般的に使用され、任意の光信号生成が可能なアーキテクチャである、IQ 変調器を説明する。^{*1}




図 4.2 光送信器の概念図

^{*1} IQ 変調器は、Nested Mach-Zehnder 変調器、Triple Mach-Zehnder 変調器、Cartesian 変調器とも呼ばれる。

IQ 変調器で用いられる Mach-Zehnder 変調器 (Mach-Zehnder modulator: MZM) は、レーザーダイオード (LD) から発するレーザー光を 2 つに分割し、片方の光の位相をもう片方の位相に対してシフトさせた後、両者を再結合する。再結合された光は相対位相に従い干渉するので、二つの光の相対位相を調整することで、出力における光の強度を制御することが可能となる。^{*2}

この MZM による光電場の制御は、複素平面上のひとつの軸に限るものである。そのため、光電場を複素平面上の任意の点に変調するために、もうひとつ別の MZM が用いられる。各々の MZM が、光電場の I 成分と Q 成分を独立に変調する。最終的に二つの光は合成され、複素平面全体にわたる変調が実現される。

偏波多重変調を行うには、上記の IQ 変調器をさらに並列させる。レーザー光が最初に偏光ビームスプリッタ (PBS) で二つの直線偏光 (H 偏光と V 偏光) に分割され、IQ 変調器が各々の光を変調した後、もう一つの PBS で光が合波される。

これら偏波多重型 IQ 変調器 (Dual-polarization IQ modulator: DP-IQM) を、Tx-DSP に従い DAC が生成した電気波形信号で駆動することで、任意の光波形を生成可能な、光偏波多重送信器が構成される。

(b) 偏波ダイバーシティ光コヒーレント受信器

本節では、偏波ダイバーシティ光コヒーレント受信器の概要を示す (図 4.3)。偏波ダイバーシティ光コヒーレント受信器は、光-電気変換をとまなう光ダウンコンバータとして動作する。すなわち 190 THz 付近の高いキャリア周波数の周りで変調されていた信号を、局部発振レーザー (Local oscillator: LO) と干渉させることにより、はるかに低い中間帯域 (多くの場合、GHz オーダーの周波数) にダウンコンバートする。ダウンコンバートされた信号はフォトダイオード (PD) と ADC によって、デジタル化される。

偏波ダイバーシティ光コヒーレント受信器の動作概要は、以下の通りである。最初に、入力信号光および LO 光は、偏光ビームスプリッタ (PBS) により直交する各偏波に分割され、同じ偏波同士が結合される。これは各偏波ごとの、90 度光ハイブリッドによって行われる。2 つの 90 度光ハイブリッドからの 8 つの光電場は、バランスドフォトダイオードを用いて検出される。フォトダイオードの光電流 I は、入射電場 E の二乗に比例し、ハイブリッドの 8 つの出力ポートは、次式によって与えられる。

^{*2} MZM の伝達関数は正弦波の形をしているため、BPSK や QPSK などの変調方式を用いる場合には、変調器をヌルポイントにバイアスし、振幅 $2V_{\pi}$ で駆動し雑音を抑えるが、AoPot として任意の変調を実現する場合には、駆動振幅を小さくし、MZM の伝達関数がほぼ線形になるヌルポイントの周りのみで用いることで、線形送信器を構成する。




図 4.3 光受信器の概念図

$$\begin{pmatrix} I_{HI+} \\ I_{HI-} \\ I_{HQ+} \\ I_{HQ-} \\ I_{VI+} \\ I_{VI-} \\ I_{VQ+} \\ I_{VQ-} \end{pmatrix} = \begin{pmatrix} \frac{1}{2}\text{Re}(E_H E_{LO}^*) + \frac{1}{4}|E_H|^2 + \frac{1}{8}|E_{LO}|^2 \\ -\frac{1}{2}\text{Re}(E_H E_{LO}^*) + \frac{1}{4}|E_H|^2 + \frac{1}{8}|E_{LO}|^2 \\ \frac{1}{2}\text{Im}(E_H E_{LO}^*) + \frac{1}{4}|E_H|^2 + \frac{1}{8}|E_{LO}|^2 \\ -\frac{1}{2}\text{Im}(E_H E_{LO}^*) + \frac{1}{4}|E_H|^2 + \frac{1}{8}|E_{LO}|^2 \\ \frac{1}{2}\text{Re}(E_V E_{LO}^*) + \frac{1}{4}|E_V|^2 + \frac{1}{8}|E_{LO}|^2 \\ -\frac{1}{2}\text{Re}(E_V E_{LO}^*) + \frac{1}{4}|E_V|^2 + \frac{1}{8}|E_{LO}|^2 \\ \frac{1}{2}\text{Im}(E_V E_{LO}^*) + \frac{1}{4}|E_V|^2 + \frac{1}{8}|E_{LO}|^2 \\ -\frac{1}{2}\text{Im}(E_V E_{LO}^*) + \frac{1}{4}|E_V|^2 + \frac{1}{8}|E_{LO}|^2 \end{pmatrix} \quad (4.1)$$

ここで、 E_H 、 E_V 、 E_{LO} はそれぞれ、水平偏波の信号複素光電場、垂直偏波の信号複素光電場、局発光源の複素光電場を表す。添え字 + の信号と、添え字 - の信号の差動を取ることで、コモンモードノイズを抑圧する。差動を取った後の出力は、

$$\begin{pmatrix} I_{HI} \\ I_{HQ} \\ I_{VI} \\ I_{VQ} \end{pmatrix} \propto \begin{pmatrix} \frac{1}{2}\text{Re}(E_H E_{LO}^*) \\ \frac{1}{2}\text{Im}(E_H E_{LO}^*) \\ \frac{1}{2}\text{Re}(E_V E_{LO}^*) \\ \frac{1}{2}\text{Im}(E_V E_{LO}^*) \end{pmatrix} \quad (4.2)$$

となる。上記の受信信号は、光信号電場の虚部および実部を表している。

光電流はトランスインピーダンス増幅器により電圧に変換された後、ADCによりデジタル化される。これにより光信号電場の虚部および実部は、コンピュータあるいはデジタル信号処理回路上で処理できるようになる。デジタル化された光電場データは、後段のデジタル信号処理部 (Rx-DSP) へと送られる。

4.3.3 デジタル信号処理部

(a) Tx-side DSP

本節では、AoPot の概念を実現する DSP のひとつの実装例として、(1) CW パイロットベース搬送波位相再生 (Carrier phase recovery: CPR) および周波数オフセット補償 (Frequency offset compensation: FOC)、(2) ナイキストフィルタリングされたサブ

チャンネル信号の周波数分割多重 (Nyquist-FDM)、を含む構成を説明する [110]。(1) の DSP は、各サブチャンネルの任意の変調フォーマットおよびシンボルレートをサポートし、(2) の DSP は、異なる要件を持つアプリケーションごとに生成された複数のサブチャンネルを単一の光送受信器上に集約することを可能にする [54]。送信側信号処理の全体図を、図 4.4 に示す。

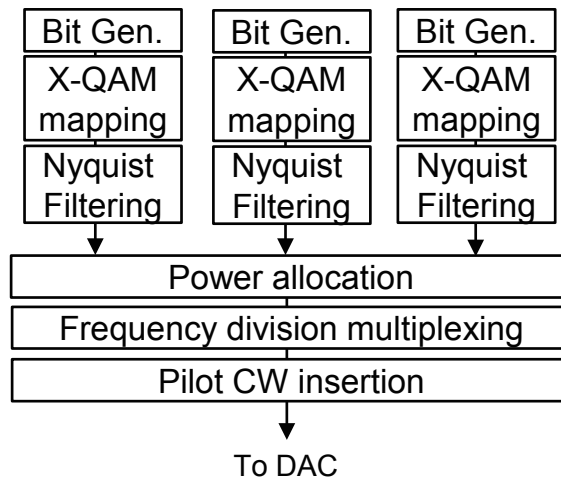


図 4.4 送信側デジタル信号処理のブロック図

CW パイロットベースの CPR および FOC では、送信信号スペクトラムの最外部に、2 つの CW パイロット信号が挿入される。このとき、信号サブチャンネルと CW パイロット間のクロストークを避けるために、ガードバンド (PilotGB) が挿入される。周波数の正側に挿入する CW パイロットと、負側に挿入する CW パイロットの偏波状態は、直交させる。信号配置の様子を、図 4.5 に示す。

2 つの CW パイロットの間に、複数のサブチャンネル信号を収容する。ここで、複数のサブチャンネル信号は、Nyquist-FDM 技術 [111] を用いて多重される。サブチャンネル間のクロストークを低減するため、ガードバンド (DataGB) が設定される。

Nyquist-FDM ブロックにおいてサブチャンネル信号を多重する際に、光パワー割り当てが実行される。この光パワー割り当てブロックは、各サブチャンネルの割り当てられた光パワーを調整することで、レイテンシ・スループット・伝送距離要件を、すべてすべてのサブチャンネル信号が同時に満たすことを助ける。

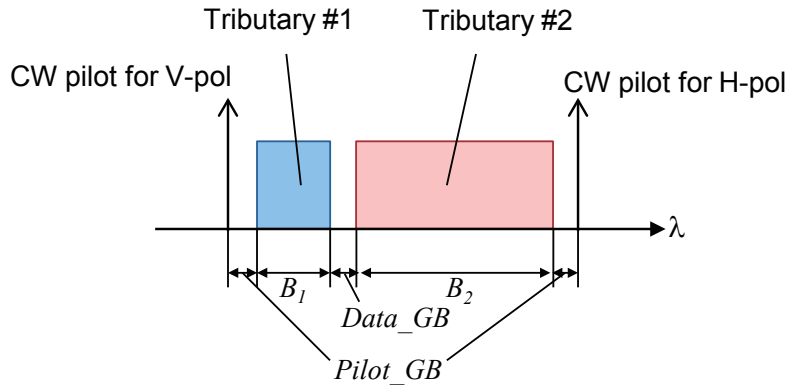


図 4.5 アプリケーション指向光送受信器におけるサブチャネルの配置

(b) Rx-side DSP

図 4.6 に、受信側のデジタル信号処理を示す。受信側では、送信側で挿入された CW パイロット信号をデジタル領域で分離する。最初に、周波数の正側と負側に挿入された CW パイロット信号の重心を取ることで、周波数オフセット情報を取り出す。この情報を用いて、周波数オフセットを補償する。次に、分離した CW パイロット信号の位相情報を抽出する。CW パイロット信号の瞬時位相の逆の位相回転を信号にかけあわせることで、搬送波位相再生 (CPR) を行う。CW パイロット信号はまた、受信器側で粗い偏波分離を行う。これらの CW パイロット信号ベースの DSP の後、MMSE (Minimum Mean Square Error) ベースのバタフライ構造有限インパルス応答 (FIR) フィルタによって実現される適応等化器が、各サブチャネルの等化のために使用される。

その後、対数尤度比 (Log-Likelihood Ratio: LLR) 算出ブロックにおいて、事後確率が計算される。これは軟判定誤り訂正符号のために必要なものである。LLR をもとに、軟判定の誤り訂正復号が行われる。本論文では、LDPC (Low-density parity-check code) 符号が用いられた。レイテンシや受信 BER 限界などの要件を満たすために、誤り訂正復号のイテレーション数が調整される。

4.3.4 パラメータ設定部

AoPot では、制御可能な DSP および FEC のパラメータの組み合わせ数が増加するため、パラメータ管理の煩雑化を伴う。この節では、パラメータ管理の煩雑さを緩和するために、現在のシステムでは実行不可能なパラメータの組み合わせを除外する方法を説明す

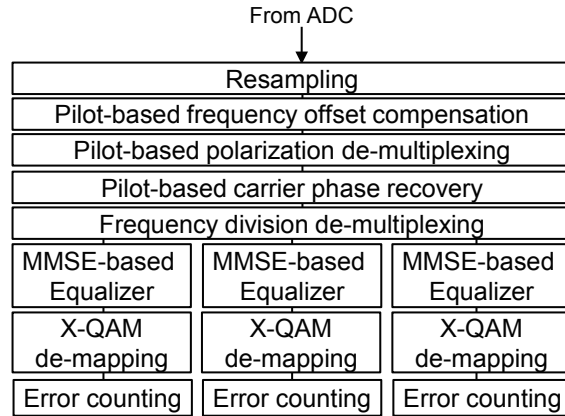


図 4.6 受信側デジタル信号処理のブロック図

る [101]。この方法では、実行の可否を決定するため、光モニタリングによるシステムの状態推定が用いられる。

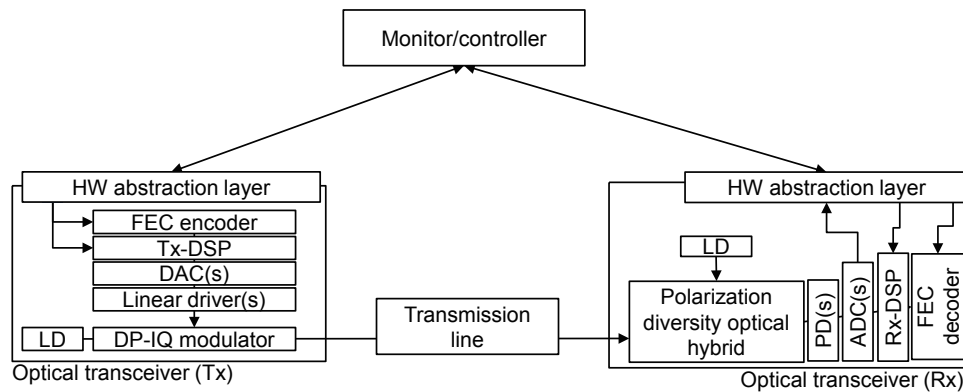


図 4.7 光モニタリングと連動した光送受信器の概念図

最初に、実行可能なパラメータは、スループットの制約として、

$$T_i \leq 2 \log_2(m_i) r_i s_i \quad (4.3)$$

を満たすことが必要である。ここで、 s_i 、 m_i 、 r_i は各々、シンボルレート、コンスタレーション点の数（例： $m = 4$ for QPSK, $m = 64$ for 64QAM）、誤り訂正のコードレートである。添え字の i は、 i 番目のサブチャネル信号を示す。ここで変調信号は偏波多重を仮定した。サブチャネルシンボルレート s_i はまた、以下の制約条件を満たす必要がある。

$$s_i > 0, \sum_{i=1}^N s_i \leq R_s \quad (4.4)$$

ここで、 N はサブチャネル数、 R_s は AoPot のハードウェアが扱える総シンボルレートを表す。

次に、レイテンシに関する以下の制約を満たす必要がある。

$$u_i(m_i, r_i, s_i, c_i)n_i + L_i^{DSP} + L_i^{Trans} \leq L_i \quad (4.5)$$

ここで、 u_i は、FEC デコーダの 1 イテレーションに必要な処理遅延を示す。これは一般に、コンスタレーションサイズ m_i 、コードレート r_i 、シンボルレート s_i 、FEC アルゴリズム種 c_i の関数である。 n_i はイテレーションの回数である。ここでは、ブロックコードを仮定し、FEC デコードの総処理時間は、 u_i と n_i の積で与えられるとした。 L^{Trans} と L^{DSP} は、各々、光ファイバ伝送と FEC 以外の DSP 処理にかかる遅延時間である。

式 4.3 と式 4.5 では、要求スループットとレイテンシが、光送受信器および伝送路の上で、形式的に実行可能かがチェックされる。実際にはこれに加え、伝送後の光信号が実際に受信可能かが、判定されなければならない。

各サブチャネルが受信可能かを判定する条件を議論するために、補助パラメータ ε を導入する。 ε_i は、 i 番目のサブチャネルにおける光信号パワーが、総信号光パワー P の中で占める割合を表す。 i 番目のサブチャネルの光パワーを p_i とすると、

$$p_i = \varepsilon_i P, 0 \leq \varepsilon_i \leq 1, \sum_{i=1}^N \varepsilon_i = 1 \quad (4.6)$$

である。ここで、 $\varepsilon = (\varepsilon_1, \varepsilon_2, \dots, \varepsilon_N)$ とする。受信可否の判定を行うためにまず、FEC 前の Q-factor を計算する関数 f を導入する。形式的に、これは各サブチャネルの FEC 前 BER を表す BER_i を用いて、

$$f = \sqrt{2} \operatorname{erfcinv}(2BER_i) \quad (4.7)$$

とかける。ここで、 $\operatorname{erfcinv}$ は、inverse complementary error function である。 BER_i は、理論的には、 m_i 、 s_i 、 ε 、OSNR の関数として、

$$BER_i^{(Ideal)} \approx \frac{1}{2 \log_2 m_i} a(m_i) \operatorname{erfc} \left(\frac{d(m_i)}{2} \sqrt{\frac{B_n}{s_i \log_2 m_i} \varepsilon_i \text{OSNR}} \right) \quad (4.8)$$

と書ける。ここで、 $a(m_i)$ は、隣接コンスタレーション点の平均数であり、 $m = 4, 16, 64$ に対して各々、 $a(m) = 2, 3, 3.5$ である。 $d(m)$ はコンスタレーション点間の最小距離であり、 $m = 4, 16, 64$ に対して各々、 $d(m) = 2, 2/5(10)^{0.5}, 2/7(7)^{0.5}$ である。 erfc は、complementary error function、 B_n は ASE 雑音の帯域 (12.5 GHz) である。

ここでまた、関数 g を導入する。これは、現在考えている誤り訂正処理 (c_i, r_i, m_i) において、所要の FEC 後 Q-factor を達成するために必要な、FEC 前 Q-factor を返す関数である。これは、FEC を実際に評価した結果である、FEC 前 Q-factor 対 FEC 後 BER のグラフから求められる。

以上の関数を用いて、受信制約条件は、

$$g(Q_i, c_i, r_i, m_i, n_i) \leq f(s_i, m_i, \epsilon, OSNR) - \Delta \quad (4.9)$$

で与えられる。ここで Δ は、Q バジレットとして知られる、設計マージンである。

ここで、この受信制約条件は、理想的な BER 特性を持つ受信器に対して設定されたことに注意しよう。実際のシステム、特に高次 QAM 変調方式において、光送受信器の特性は理想状態からずれることが多い。したがって、実際の光送受信器の制限に起因するこれらの差分を含むよう、式 4.8 を修正する必要がある。我々は二つのパラメータ η と κ を導入する。修正された式は、

$$BER_i^{(with\text{imperfection})} \approx \frac{1}{2 \log_2 m_i} a(m_i) \text{erfc} \left(\frac{d(m_i)}{2} \sqrt{\frac{B_n}{s_i \log_2 m_i} \kappa \frac{\epsilon_i OSNR}{1 + \eta(1 + \epsilon_{k \neq i}) OSNR}} \right) \quad (4.10)$$

となる [112]。パラメータ κ は送受信器間のマッチング不完全の度合いを示し、おもに BER カーブの OSNR シフトを導入する。パラメータ η は、高 OSNR 領域におけるエラーフロアを導入する。

最終的に、AoPot のコントローラ部では、次の手順で実行可能なパラメータ群が算出される。

手順 1

実行可能パラメータ群を見つける。上位層からの要求要件 $[T_i, L_i, Q_i]$ ($i = 1 \dots N$) に対して、式 4.3、4.5、4.9 を満たすパラメータセット $[s_i, m_i, n_i, \epsilon_i]$ ($i = 1 \dots N$) を列挙する。

手順 2

もし、手順 1 で条件を満たすパラメータセットが一つも存在しない場合、上位層か

らの要求要件 $[T_i, L_i, Q_i]$ ($i = 1 \dots N$) は、現在の伝送システムにとって過剰である。伝送不可能な旨を、上位層に返す。

手順3

もし、手順1で条件を満たすパラメータセットが複数存在した場合、別途設定された上位層からの目的を最大にする解を選択する。

4.4 評価実験系

AoPot コントローラとプログラマブル光送受信器からなる実験系を図4.8に示す。

本論文におけるAoPot コントローラ(パラメータ設定部)は、Pythonで実装されたソフトウェアである。制約条件チェッカー(Constraints checker)は、式4.3、式4.5、式4.9を満たす実現可能なパラメータ群を抽出する。実行可能なパラメータ群の中から、事前に定められた基準(Policy)に従い、実際に光送受信器に設定するパラメータが選択された。

光送受信のデジタル信号処理(Tx-DSPおよびRx-DSP)は、Matlabで実装され、オフラインで実行された。デジタル信号処理の詳細は、4.3.3節で述べられている。DSPのなかで、サブチャネル毎の変調方式、光パワー、誤り訂正複合のイテレーション数が、AoPot コントローラによって制御された。複数のサブチャネルを合計した信号の帯域は16 GHzであり、CWパイロット信号と全サブチャネルを合わせた総信号電力のパワー比は、-16 dBに設定された。サブチャネルとCWパイロット間のクロストークを避けるために、 $PilotGB = 200$ MHzが挿入された。Nyquist-FDMはロールオフ係数0.01で使用され、サブチャネル間には、ガードバンドとして $DataGB = 100$ MHzが挿入された。

Tx-DSPで生成された仮想光電場は、光・電気ハードウェア上で実行された。光送信器は、193.3 THzで発振する外部共振器レーザー(LD)と、インジウム・リン(InP)ベースの偏波多重型IQ変調器、4チャンネルのデジタル・アナログ変換機(DAC)と、電気増幅器からなる。使用したDACのサンプルレートは64 GSample/s、物理分解能は8ビットである。変調された信号は、エルビウム添加ファイバ光増幅器(EDFA)で増幅された後、純シリカコアファイバ(PSCF: $Loss = 0.163$ dB/km、 $A_{eff} = 135$ μm^2 、 $D = 20.9$ ps/nm/km)で伝送された。ファイバ長は40 km、ファイバ入力パワーは0 dBmに設定した。伝送後、追加のASE雑音を付加することで、受信OSNRを変化させた。

受信側において、局部発振レーザーの発する光と、受信した信号光は、偏波ダイバシティ型 90 度光ハイブリッドにおいて干渉させられた。ハイブリッドの光出力は、4 つのバランストフォトダイオードで電気信号に変換された後、40 GS/s のサンプルレートおよび 16 GHz の帯域幅を有する 4 つのアナログ・デジタル変換器 (ADC) によってデジタル化された。デジタル化されたデータは、Rx-DSP と CNN ベースの OSNR モニタ ((f) 節で議論されたもの) の双方に送られた。Rx-DSP のバタフライ型 FIR フィルタのタップ数として、101 を設定した。誤り訂正としては、DVB-S.2 [113] ベースの LDPC コード (ブロック長 16200 ビット、21.6 % オーバーヘッド) が用いられた。このとき、誤り訂正の復号イテレーション回数は、1 から 15 までの間で設定された。

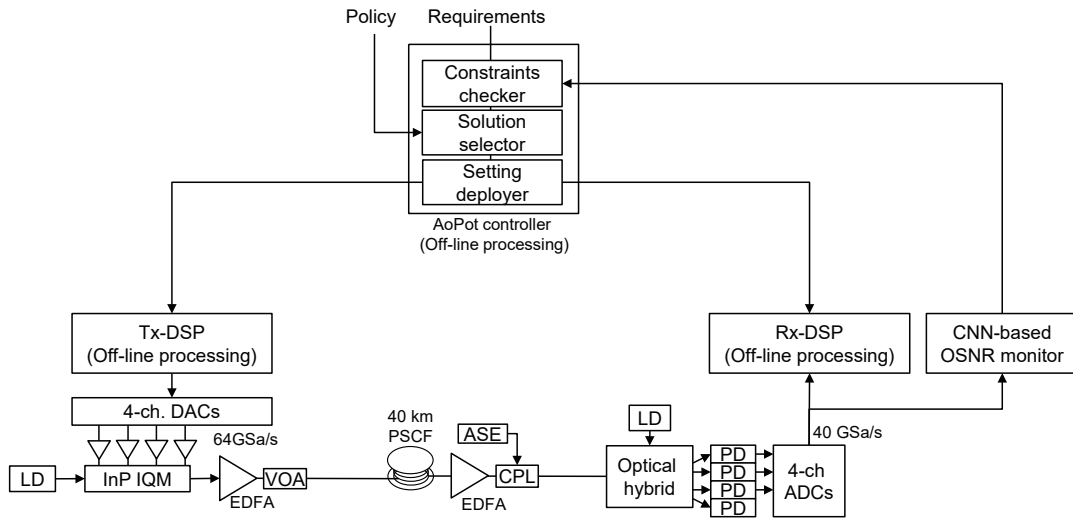


図 4.8 実験系. VOA: variable optical attenuator, LD: laser diode, FE: front end, CPL: coupler, ASE: amplified spontaneous emission source, PD: photodiode, DAC: digital to analog converter, InP-IQM: Indium Phosphide-based IQ modulator, ADC: analog to digital converter, SC: sub-channel, CW: continuous-wave, GB: guard-band, LLR: log-likelihood ratio.

4.5 実験結果と考察

4.5.1 光送受信器の不完全性指標の評価

この節では、実装された AoPot の BER 性能を特徴付けるパラメータ κ および η を決定する。この実験では、AoPot の全帯域幅 (16 GHz) は 2 つの 8 GBd サブチャネルに分割され、DP-mQAM ($m = 4, 16, 64$) で変調された。

まず、変調方式の組み合わせごとに各サブチャネルの光パワーが等しい場合を検討した。サブチャネル 1 の変調方式を DP-4QAM に固定し、サブチャネル 2 の変調方式を DP-4QAM から 64QAM まで変化させた。OSNR 31 dB で測定された、各変調方式のコンステレーション図を、図 4.9 に示す。これらのコンステレーションは、4.3.3 節で説明した DSP を使用することで、4QAM から 64QAM までのすべての光信号が正常に復調されたことを示している。図 4.10 に、各変調方式での、OSNR 対 BER のグラフを示す。




図 4.9 DP-4QAM, DP-16QAM, DP-64QAM のコンステレーション (片偏波のみ示した)

ここで OSNR は、CW パイロット信号とすべてのサブチャネルを含む総信号電力によって定義される。図 4.10 の破線は、式 4.8 によって予測される BER を示す。実験的に測定された BER は、式 4.8 による理論的予測から外れている。この差分は、実験系の様々な制限によるものである。例えば、ADC/DAC ビット数の制限は、エラーフロアにつながる。この差分を補正するため、パラメータ κ および η を導入し、式 4.10 を用いる。実験的に測定された DP-4QAM、16QAM、および 64QAM 信号の BER を用いてフィッティングを行い、パラメータ κ および η を同定した。このシステムにおいては、 $\kappa = 0.917$ および $\eta = 0.00248$ であった。以下の節ではこの値を用いる。同定された κ および η と式 4.10 を用いて計算された値を、図 4.10 の実線で示す。この実線は、すべての変調方式にわたり、実験結果との間の優れた一致を示した。

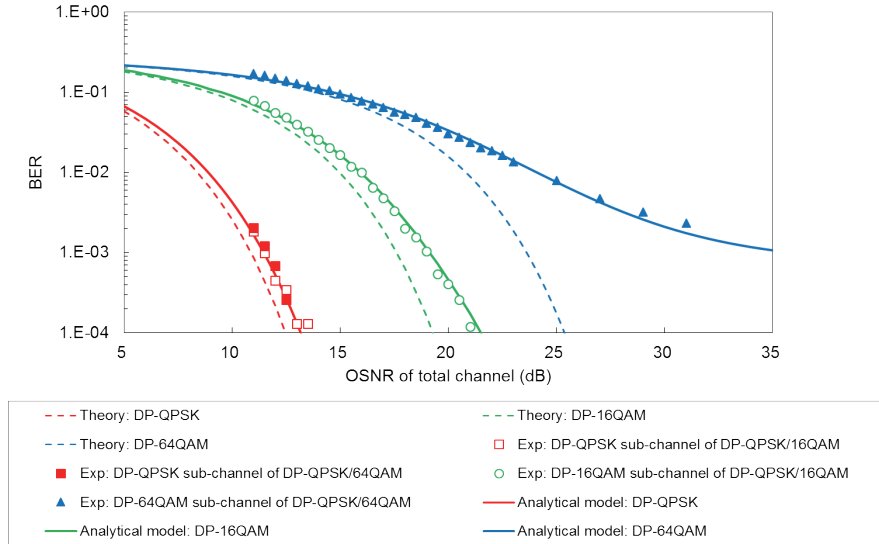


図 4.10 各変調方式の OSNR 対 BER 測定結果

次に、我々は同定した κ と η の汎用性を確認するため、二つのサブチャンネルに割り当てる光パワーを変更した。図 4.11 に、測定された光スペクトラムを示す。設定したサブチャンネル間で光パワー差に応じた光スペクトラムが生成されていることが確認できる。信号スペクトラムの最外部に見える突起は、DSP 部で議論した CW パイロット信号である。

図 4.12、4.13、4.14 は、二つのサブチャンネル間の光パワー差が 0 dB から 6 dB の時の測定 BER を示す。図 4.12、4.13、4.14 の実線と破線は、式 4.10 で計算された BER を示している。このとき、 κ および η は、サブチャンネル間光パワー差がない状態で同定されたものを利用している。図 4.12、4.13、4.14 は、サブチャンネル間に光パワー差があっても、式 4.10 が正しい BER を推定することを示している。

4.5.2 処理遅延と誤り訂正の関係評価

この節では、C 言語で実装した軟判定誤り訂正 (FEC) 復号器を用いた実験結果を示す。ここでは、DVBS-2 LDPC 誤り訂正が用いられている。

この節の検証では、割り当て光パワーの等しい 2 つの 8 GBd DP-16QAM サブチャンネルで構成された光信号を用いた。サブチャンネル 1 の FEC 復号器前の Q-factor (Pre-FEC Q) と、FEC 復号器後の BER (Post-FEC BER) を図 4.15 に示す。ここで AWGN (Additive White Gaussian Noise) 環境下でのシミュレーション結果を実線で示す。プロット点は、




図 4.11 光パワー配分比率を変化させた際の光スペクトラム




図 4.12 光パワー差 2 dB 時の OSNR 対 BER 測定結果

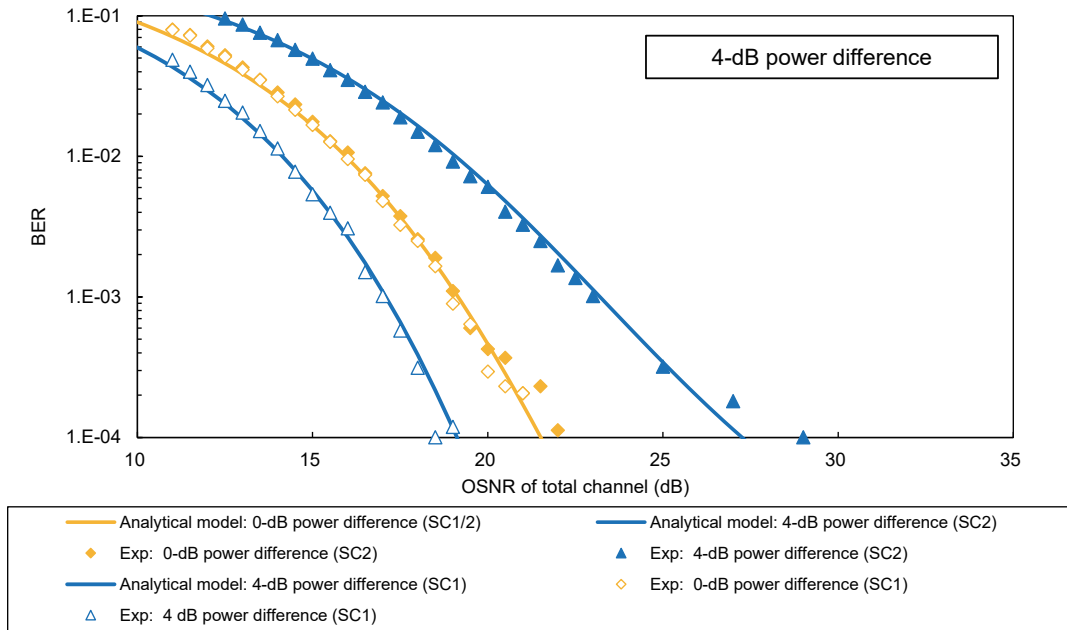


図 4.13 光パワー差 4 dB 時の OSNR 対 BER 測定結果




図 4.14 光パワー差 6 dB 時の OSNR 対 BER 測定結果

実際の光信号を用いた実験で得られたものである。




図 4.15 各復号繰り返し数での誤り訂正前 Q 値対誤り訂正後 BER

FEC 復号器における復号の繰り返し数（イテレーション数）を変化させながら、図 4.15 に点をプロットした。イテレーションを 1 から 15 まで変化させると、FEC 後 BER が 10^{-5} となる FEC 前 Q-factor が、約 3.9 dB 変化した。図 4.16 に、この結果を分かりやすく示すため、FEC 後 BER が 3.4×10^{-5} (Q-factor = 12 dB に対応する) となるために必要な FEC 前 Q-factor を、FEC 復号器のイテレーション数の関数として示す。イテレーション数が増加すると、必要な FEC 前 Q-factor は減少する。減少は、イテレーション数が 15 周辺で飽和している。

この節で注意すべきは、イテレーション数を上昇させることで、光信号の受信に必要な所要 Q-factor は減少するが、このとき、復号に要する処理遅延は上昇しているということである。なぜならば、処理遅延はイテレーション一回に必要な処理時間 u と、イテレーション数 n を用いて、 un と書けるからである。

4.5.3 ユースケース環境下での DSP/FEC パラメータ推定

次に、本 AoPot 型光送受信器に、前章で実証した CNN ベースの OSNR モニタを組み合わせることで、さまざまなサービスが持つ要件を満たすための AoPot 操作のユース




図 4.16 復号繰り返し数 対 所要誤り訂正前 Q 値

ケースを実験的に実証した。

本ユースケースでは、(1) 標準サービス、(2) レイテンシ重視サービス、の 2 種類のサービスを同時に伝送することを想定する。ここで、アプリケーション (1) をサブチャネル 1 に、アプリケーション (2) をサブチャネル 2 に収容する。光送受信器の機器関連パラメータとして、 $u_i = 1.5 \mu s$ 、 $L_i^{DSP} = 9 \mu s$ 、 $L_i^{Trans} = 200 \mu s$ を仮定する。サブチャネルを示す番号 i は、 $i = 1, 2$ を示す。 κ および η は、前節で同定した値を用いた。 $\Delta = 0.5 \text{ dB}$ とした。FEC のアルゴリズムとして、DVB-S.2 [113] に基づいた LDPC 符号が用いられた。コードレートは、 $i = 1, 2$ の両方に対して、 $r_i = 37/45$ である。

選択可能なパラメータとして、 $s_i \in [0.1, 0.2, \dots, 0.9] \times 16 \text{ GHz}$ 、 $m_i \in [4, 16, 64]$ 、 $10 \log_{10}(\varepsilon_1/\varepsilon_2) \in [-6.0, -5.5, -5.0, \dots, +5.5, +6.0]$ 、 $n_i \in [1, 2, 3, \dots, 15]$ を考慮した。

具体的な制御手順は以下の通りである。

手順 1: 上位層からの要件の通知

上位層から、AoPot に収容する各サービス（サービス識別番号 i ($i = 1 \dots N$)) に対する、スループット、レイテンシ、信号品質に関する要求要件 $[T_i, L_i, Q_i]$ ($i = 1 \dots N$) が通知される。

手順 2: 伝送路状態の推定

送受信器間で光信号を通信し、深層学習に基づいたモニタリングにより、伝送路の状態を推定する。具体的には試験信号として、16 GBd DP-QPSK 信号を送受信し、3 章で説明した訓練済み CNN-based OSNR モニタを利用することで、OSNR

値を測定した。

手順 3: 実行可能パラメータの列挙

上位層からの要求 $[T_i, L_i, Q_i]$ および、推定された OSNR 値 $OSNR$ を基に、式 4.3、4.5、4.9 を満たすパラメータセット $[s_i, m_i, n_i, \varepsilon_i]$ ($i = 1 \cdots N$) を列挙する。もし、手順 3 で条件を満たすパラメータセットが一つも存在しない場合、上位層からの要求要件 $[T_i, L_i, Q_i]$ ($i = 1 \cdots N$) は、現在の伝送システムにとって過剰である。伝送不可能な旨を、上位層に返す。

手順 4: 目的の最大化

もし、手順 3 で条件を満たすパラメータセットが複数存在した場合、上位層からの目的を最大にする解を選択する。具体的に本シナリオでは、各アプリケーション毎の伝送限界からのマージンの最小値、 $\min(\Delta Q)$ を最大化することを目的とした。ここで $\Delta Q = [\Delta Q_1, \Delta Q_2, \dots, \Delta Q_N]$ は、アプリケーション番号 i にたいする伝送可能 Q-factor $Q_{i,limit}$ と、アプリケーション番号 i に対応するサブチャネル信号の予測される Q-factor $Q_{i,est}$ の差分、 $\Delta Q_i = Q_{i,est} - Q_{i,limit}$ の $i = 1, \dots, N$ までのベクトルである。関数 \min は、与えられたベクトルの要素のうち最小要素を返す関数である。

手順 1 において、本ユースケースでは、 $N = 2$ として、標準サービス向けに $[T_1, Q_1, L_1] = [50Gbps, 12dB, 240\mu s]$ 、レイテンシ重視サービス向けに $[T_2, Q_2, L_2] = [50Gbps, 12dB, 211\mu s]$ が要求されたと仮定する。

次に手順 2 において、16 GBd DP-4QAM 信号が AoPot 間で送受信された。このとき 3 章で説明した訓練済み CNN-based OSNR モニタを利用することで、OSNR 値を測定した。OSNR モニタの出力揺らぎを抑制するため、OSNR モニタからの 21 回の出力を平均化するフィルタが、モニタの後段に取り付けられた。CNN モニタによって測定された受信 OSNR は、17.1 dB であった。これは、別途光スペクトラムアナライザで確認した受信 OSNR 17 dB とほぼ等しい。

手順 3 において、AoPot コントローラは、実行可能パラメータを検索した。今回の実験においては、可能なパラメータの組み合わせは、455,625 個あったが、式 4.3、4.5、4.9 を満たす、実行可能なパラメータのみを抜き出すことによって、候補を 30 個まで減らすことができた。

手順 4 において、目的を最大化するパラメータの組み合わせが選択された。選択されたパラメータは、 $[s_1, m_1, \varepsilon_1, n_1] = [8e9, 16, 0.69, 1]$ および $[s_2, m_2, \varepsilon_2, n_2] = [8e9, 16, 0.31, 15]$ であった。手順 3 および 4 の処理は、Python 言語で実装され、標

準的なパーソナルコンピュータ (Intel Core i5 CPU と 10 GB RAM) の上で処理された。この場合、両手順を合わせた処理時間は 40 ms 以下であった。

4.5.4 ユースケース環境下でのシステム特性の確認

前節で算出されたパラメータが妥当なものかを検証するため、本節では算出されたパラメータの周りの AoPot 光送受信器の挙動を検証する。

最初に、前節で算出された、要求 $[T_1, Q_1, L_1] = [50\text{Gbps}, 12\text{dB}, 240\mu\text{s}]$ および $[T_2, Q_2, L_2] = [50\text{Gbps}, 12\text{dB}, 211\mu\text{s}]$ に対するパラメータセット、 $[s_1, m_1, \varepsilon_1, n_1] = [8e9, 16, 0.69, 1]$ および $[s_2, m_2, \varepsilon_2, n_2] = [8e9, 16, 0.31, 15]$ のうち、 ε_1 および ε_2 を変化させ、システムの挙動を調べた。式 4.6 の制約から、 $\varepsilon_1 + \varepsilon_2 = 1$ であるので、パラメータとして、Power difference = $10 \log_{10}(\varepsilon_1/\varepsilon_2)$ を設定し、これを 0 から 6 dB まで変化させた。結果を図 4.17 に示す。縦軸は、各サブチャネルに割り当てられた FEC limit からの Q マージンである。図 4.17 中の実線とプロットは、それぞれ解析モデル (式 4.10) と実験 (Back-to-back および 40 km 伝送) から得られた結果を示している。図 4.17 には、Power difference を AoPot コントローラが指定した 3.5 dB (すなわち $\varepsilon_1 = 0.69$ と $\varepsilon_2 = 0.31$) に設定することで、必要なすべての制約を満たし Q マージンを最大にすることが、実験的に示されている。




図 4.17 光パワー配分比 対 Q マージン

最後に、AoPot 光送受信器にパラメータ $[s_1, m_1, \varepsilon_1, n_1] = [8e9, 16, 0.69, 1]$ および $[s_2, m_2, \varepsilon_2, n_2] = [8e9, 16, 0.31, 15]$ を設定した上で、OSNR 対 FEC 後 BER を測定し

た。上位層からの要求が $Q_i = 12\text{dB}$ であるので、FEC 後 BER が 3.4×10^{-5} 以下を満たせばよい。図 4.18 に、Back-to-back での測定結果を示す。比較のために、サブチャンネル間の光パワー差が未調整の結果、すなわちパラメータセット $[s_1, m_1, \varepsilon_1, n_1] = [8e9, 16, 0.5, 1]$ および $[s_2, m_2, \varepsilon_2, n_2] = [8e9, 16, 0.5, 15]$ で測定した BER の結果も黒線で示す。サブチャンネル間光パワーを調整しない場合（黒線）、要求レイテンシに合わせて調整された誤り訂正の効果によって、サブチャンネル 1 と 2 が $Q_i = 12\text{dB}$ のために要求する信号対雑音比には、大きな差があることが分かる。両方のサブチャンネルを同時に受信するには、高いほうの要求 OSNR が必要となる。これは言い換えると、要求 OSNR が低いほうのサブチャンネルに、過剰な光リソースを割り当てているといえる。赤色および青色で着色された線は、AoPot コントローラによって指定されたパラメータによる測定結果である。このとき、割り当て光パワーが最適化されているため、サブチャンネル 1 と 2 が $Q_i = 12\text{dB}$ のために要求する信号対雑音比は、ほぼ同じことが見て取れます。これは、片方のサブチャンネルに過剰に割り当てられていた光リソースが、適切に分配されたことを意味する。




図 4.18 パラメータ最適化有無での OSNR 対 誤り訂正後 BER の変化 (Back-to-back)

図 4.19 は、同様の測定を、40 km 伝送後に行った結果である。この結果は、短距離伝送条件（それは、光送受信器の処理遅延が相対的に重要となる条件でもある）の下で、提案する方式が動作することを示す。これは短距離伝送では光ファイバの非線形効果による

影響が小さいことによる。




図 4.19 パラメータ最適化有無での OSNR 対 誤り訂正後 BER の変化 (40 km 伝送後)

4.6 むすび

我々はスループット、信号品質、およびレイテンシ要件を満足させるために、複数のパラメータ（変調方式、シンボルレート、光パワー割当、及び誤り訂正）の同時最適化を可能にする光送受信器の構成を提案した。提案した構成は、複数サブチャネルと複数変調方式（DP-4/16/64QAM）、誤り訂正復号にけるイテレーション数の可変、サブチャネル間の可変光パワー割り当て機能を備えた光送受信器として実験的に実装された。この光送受信器と、実行可能性制約要件を用いて光送受信器パラメータの探索範囲を縮小するコントローラ部と、伝送路品質（OSNR）を推定する CNN ベースモニタを用いて、特定ユースケースのもとで、提案光送受信システムの動作を確認した。

第 5 章

結論

We can only see a short distance ahead, but we can see plenty there that needs to be done.

A. Turing, *Computing machinery and intelligence*, 1950

5.1 本論文の主たる成果

本論文では、デジタルコヒーレント受信によってデジタル化された光電場から、深層ニューラルネットワークを用いたモニタリングスキームを使って、受信光電場の状態推定（OSNR、変調方式、シンボルレート、残留波長分散）を行う方法を提案し、実験的に実証した。また、推定された光電場の状態から伝送路の状態を推定し、推定された伝送路状態と、スループット・レイテンシ・受信波形品質を含む伝送要件を満たすよう、光送受信器の制御を行う方法を提案し、実験的に実証した。

具体的に、第 1 章では、巨大デジタルデータとしての光電場を媒介にして、深層学習とデジタルコヒーレント技術が結び付くことを述べた。第 2 章では、深層学習とデジタルコヒーレント技術の結びつきが、光ファイバネットワークにおける知的な柔軟性の増大をもたらし、これがクラウド上での多様なアプリケーションの実行を支えることを明らかにした。続く第 3 章では、深層ニューラルネットワークを用いて、デジタル化された光電場の状態を推定し、その要約的記述を取り出した。具体的には、14 GBd および 16 GBd DP-QPSK, DP-16QAM, DP-64QAM で変調された光信号をデジタル化して深層ニューラルネットワークに入力し、OSNR、波長分散量、変調方式およびシンボルレートを取り出せることを実験的に検証した。このとき使用した深層ニューラルネットワークを用いたモニタリングスキームは、人手によるアルゴリズムの構築や特徴量の選択を必要としなかった。第 4 章では、光電場の状態推定で得られた情報を基に光送受信器を制御する試みについて述べた。深層ニューラルネットワークを用いて推定された伝送路の状態と、物理層での遅延を含むアプリケーション毎の伝送要件の双方を満たす光信号を、光送受信器の制御により生成・受信可能なことを実験的に示した。

5.2 今後の課題と展望

本論文で提示したコンセプトのもとで、今後検討すべき数多くの領域が残っているであろう。方向性として、モニタリングの精緻化、抽象化、適応化の三つの方向性があると考えられる。以下では各方向性の中での検討課題の例と、現時点で想定される検討のアイデアを示す。

5.2.1 モニタリングの精緻化

(a) 非線形モニタリング

本論文で提案したスキームは、光電場が光ファイバ中で受ける非線形効果^{*1}のモニタリングにも応用可能と考えられる。

現代の光ファイバ伝送システムで幅広く用いられている、各伝送スパン毎の波長分散補償が存在しない伝送路 (Dispersion uncompensated link) においては、ファイバ非線形によって生じた位相方向の雑音は、波長分散との相互作用によってガウシアン様の分布に変化してしまう [114]。このため、非線形量のモニタリングを、単純なノイズ分布分析によって行うことは難しい。しかしながら、[115] での理論的検討によれば、特に XPM において時間的に近接するシンボルがもつ非線形雑音は、ガウス雑音とは異なる特性を持つ。

本論文で提案した深層学習を用いたモニタリングフレームワークでは、測定部として、デジタルコヒーレント受信器の高速サンプリング機能を利用している。そのため、同フレームワークを用いて、時間的に近接するシンボル間に潜む、非線形効果の痕跡を取り出せる可能性が高いと予測される。

(b) ローカライゼーション

本論文でこれまで議論したモニタは、伝送路全体で累積した量を受信端でモニタリングする、累積量モニタリングであった。光ファイバネットワーク運用管理の高度化には、これら累積量モニタリングのほかに、ネットワークのどの箇所でも異常 (故障の他、各物理量 (OSNR、光パワー等) の予想外の変動も含む) が生じたかを同定する、ローカライゼーションが重要になる。これは、もしローカライゼーションが正しく行えれば、故障修理や部品交換のオペレーションコスト削減や、光経路のリルーティングを最小限に抑えることによるネットワークの効率的利用が可能になるためである。モニタを地理的に分散した各箇所に配置することで、ローカライゼーションを行うことができるが、この方法はコスト面で課題がある。そのため、受信端信号の解析によってローカライゼーションが行えれば、運用管理高度化のための強力なツールになり得る。

一般的に、線形伝送路においては、伝送路 A と伝送路 B の接続順序を A・B から、B・A と変更しても、受信端の信号は変化しないため、受信端信号の解析によってローカライゼーションを行うことは難しい。しかしながら、非線形伝送路である光ファイバ伝送路で

^{*1} 具体的には光カー効果によっておこる自己位相変調 (Self phase modulation: SPM) および相互位相変調 (Cross phase modulation: XPM) など

は、伝送路 A と伝送路 B の接続順序を A・B から、B・A と変更すると、受信端で受信される信号が変化する。このような光ファイバ伝送路の非可換性と、深層学習の優れた弁別性を用いて、受信端信号の解析によってローカライゼーションが行える可能性は存在すると思われる。

5.2.2 モニタリングの抽象化

(a) 異常検知モニタリング

本論文で議論したモニタは、具体的な光の物理状態をモニタリングするものであったが、一段階抽象的に、システムの正常状態を判定し、受信光電場が正常状態から逸脱したときに警告を発するモニタが考えられる。

このモニタを訓練する際の難点は、「異常状態」のデータを収集することの難しさにあると考えられる。システムはその稼働の大半の時間正常に動作しているので、実際のシステムにおいてレアケースである異常状態のデータを収集するコストは極めて高い。このため、十分な数の異常状態訓練データを準備することは難しい。この課題を解決するため、実システムでなく、シミュレーション等で異常状態を模擬することも考えられるが、この場合は、あらかじめ想定された異常モード以外の異常データが收拾できないという課題がある。

これらの課題を解決するため、異常状態を直接学習するのではなく、データ収集が比較的容易な「システムが正常稼働している際の受信光電場」データを用いて学習することが考えられる。収集された正常状態光電場を深層ニューラルネットワークに入力し、出力として全く同じ正常状態光電場を再現するよう、モデルを訓練する。この時、ニューラルネットワーク中にユニット数の少ないボトルネック層を埋め込んでおくことで、入力層から出力層に直接データが流れるのではなく、いったんデータをボトルネック層で抽象化し、その抽象化されたデータから光電場を再現することができる。

このボトルネック層を含むニューラルネットワークは、入力正常状態光電場であるときに動作するよう訓練されるので、もし異常データが入力されると、正しく入力データを再現できなくなるであろう。そのため、モデルへの入力と、モデルからの出力の差分をとると、正常状態では差分が零に近いが、異常状態では大きな差分が出力されることが考えられる。以上のような仕組みを用いて、異常状態を検出するモニタを訓練できる可能性がある。

5.2.3 モニタリングの適応化

(a) 経路切り替え時の異なる送受信器への対応

光パスの切り替え等で、モニタリングを行う光送受信器の組み合わせが変化する場合、学習済みのニューラルネットワークが環境変化に対応できない可能性がある。特に相互接続性が保証されているが製造会社の異なる機器間では、光・電気部品のアナログ特性の違いから、推定精度が低下する恐れがある。この課題には、光送受信器の特性差を補償するため、新たなデータセットを用いて再学習することで対処できるが、再学習時に、本学習と同等の多数のデータセットが必要になることが課題と考えられる。

再学習時に必要となるデータセット数を削減するため、転移学習を用いた深層ニューラルネットワークのファインチューニングが手段として考えられる。これは、再学習前にタスク実行（モニタリング）に必要な学習の大半は完了しており、光送受信器の組み合わせが変化することによる変化には、ニューラルネットワークの細部の微調整のみで対応可能と考えられるからである。ファインチューニングを用いることで、少ない訓練データ量で高速に再学習が可能となると予想される。

ファインチューニングの一つの実装方法として、主に特徴抽出を担っている深層ニューラルネットワークの前段層パラメータを、既学習のもので固定する方法がある。その代わりに、深層ニューラルネットワークの後段層（典型的には最終層のみ）を再学習させ、パラメータを変化させる。この手順により、以前に学習したタスク（例：OSNR 推定）の記憶を保持しながら（学習結果を転移しながら）、新たな環境（例：新規の光送受信器）に対応することが可能になると見込まれる。

謝辞

本研究を進めるに当たり、直接ご指導頂いた森川博之教授に深く感謝いたします。研究に関する鋭いご指摘はもちろんのこと、文章の書き方からプレゼンテーション技法まで様々な知見を頂きました。多忙にも関わらずいつも笑顔で、穏やかさを湛える様子は私を大いに元気づけてくれました。

鈴木誠助教（現ソナス株式会社 CTO）には、ミーティングの際幾度となく独自の視点から貴重なご意見を頂きました。成末義哲助教には、1年という短い期間ながら大変お世話になり、時たま挟まる研究以外の会話も私を元気づけてくれました。

博士課程の安田晃久さん、Tin Petrovic さん、関口浩さんには、主に機械学習の分野で議論をしていただきました。また同博士課程の廖椿豪さん、Theerat Sakdejayont さんには、博士論文の執筆の進め方一般について相談に乗っていただきました。感謝いたします。

また共同研究者であり著者の上司でもある Dr. Ing. Jens C. Rasmussen（現 Socionext Europe GmbH, Langen, Germany）および星田剛司博士（株式会社富士通研究所）に深く感謝いたします。お二人の理解と支援がなければ、この論文を書き終えることはできなかったでしょう。

その他、ここで名前を挙げることはいたしません。著者の二度目の大学生活に活力を与えてくださった森川研究室の皆様方、印象的な講義を通じて新たな分野の知見を与えてくださった工学系研究科および情報理工学系研究科の先生方に感謝いたします。

最後に、著者の幼いころからの自然に対する知的興味を方向づけてくれた父母に感謝いたします。ありがとうございました。

2017年12月1日

参考文献

- [1] Kazuro Kikuchi, Takanori Okoshi, Masato Nagamatsu, and Naoya Henmi. Degradation of bit-error rate in coherent optical communications due to spectral spread of the transmitter and the local oscillator. *Journal of lightwave technology*, Vol. 2, No. 6, pp. 1024–1033, 1984.
- [2] Takanori Okoshi and Kazuro Kikuchi. *Coherent optical fiber communications*, Vol. 4. Springer Science & Business Media, 1988.
- [3] D. S. Ly-Gagnon, S. Tsukamoto, K. Katoh, and K. Kikuchi. Coherent detection of optical quadrature phase-shift keying signals with carrier phase estimation. *Journal of Lightwave Technology*, Vol. 24, No. 1, pp. 12–21, 2006.
- [4] S. Tsukamoto, D.-S. Ly-Gagnon, K. Katoh, and K. Kikuchi. Coherent demodulation of 40-Gbit/s polarization-multiplexed QPSK signals with 16-GHz spacing after 200-km transmission. In *Proc. of Optical Fiber Communication Conference (OFC) 2005*, p. PDP29, 2005.
- [5] K. Kikuchi. Fundamentals of coherent optical fiber communications. *J. Lightw. Technol.*, Vol. 34, No. 1, pp. 157–179, 2016.
- [6] F. Derr. Coherent optical QPSK intradyne system: concept and digital receiver realization. *Journal of Lightwave Technology*, Vol. 10, No. 9, pp. 1290–1296, 1992.
- [7] S. J. Savory. Digital coherent optical receivers: algorithms and subsystems. *IEEE J. Sel. Topics Quantum Electron.*, Vol. 16, No. 5, pp. 1164–1179, 2010.
- [8] E. Ip. Nonlinear compensation using backpropagation for polarization-multiplexed transmission. *Journal of Lightwave Technology*, Vol. 28, No. 6, pp. 939–951, 2010.
- [9] T. Tanimura, T. Hoshida, S. Oda, T. Tanaka, C. Ohsima, Z. Tao, and J. C. Rasmussen. Systematic analysis on multi-segment dual-polarisation nonlinear

- compensation in 112 Gb/s DP-QPSK coherent receiver. In *2009 35th European Conference on Optical Communication*, 2009.
- [10] G. E. Hinton and R. R. Salakhutdinov. Reducing the dimensionality of data with neural networks. *Science*, Vol. 313, No. 5786, pp. 504–507, 2006.
- [11] C. M. Bishop. *Pattern Recognition and Machine Learning*. Springer, 2006.
- [12] David Silver, Aja Huang, Chris J. Maddison, Arthur Guez, Laurent Sifre, George van den Driessche, Julian Schrittwieser, Ioannis Antonoglou, Veda Panneershelvam, Marc Lanctot, Sander Dieleman, Dominik Grewe, John Nham, Nal Kalchbrenner, Ilya Sutskever, Timothy Lillicrap, Madeleine Leach, Koray Kavukcuoglu, Thore Graepel, and Demis Hassabis. Mastering the game of Go with deep neural networks and tree search. *Nature*, Vol. 529, pp. 484–489, 2016.
- [13] Mariusz Bojarski, Davide Del Testa, Daniel Dworakowski, Bernhard Firner, Beat Flepp, Praseon Goyal, Lawrence D. Jackel, Mathew Monfort, Urs Muller, Jiakai Zhang, Xin Zhang, Jake Zhao, and Karol Zieba. End to end learning for self-driving cars. *arXiv:1604.07316*, 2016.
- [14] Y. LeCun, Y. Bengio, and G. Hinton. Deep learning. *Nature*, Vol. 521, pp. 436–444, 2015.
- [15] Cisco visual networking index: Forecast and methodology 2016-2021.
- [16] R. J. Essiambre, G. Kramer, P.J. Winzer, G.J. Foschini, and B. Goebel. Capacity limits of optical fiber networks. *J. Lightw. Technol.*, Vol. 28, No. 4, pp. 662–701, 2010.
- [17] R.Kashyap and K.J.Blow. Observation of catastrophic self-propelled self-focusing in optical fibres. *Electron. Lett.*, Vol. 24, No. 1, pp. 47–49, 1988.
- [18] T. Morioka. New generation optical infrastructure technologies: EXAT initiative towards 2020 and beyond. In *2009 14th OptoElectronics and Communications Conference*, 2009.
- [19] Cisco global cloud index: Forecast and methodology 2015-2020.
- [20] J. K. Fischer, S. Alreesh, R. Elschner, F. Frey, M. Nolle, and C. Schubert. Bandwidth-variable transceivers based on 4D modulation formats for future flexible networks. In *Proc. of 39th European Conference and Exhibition on Optical Communication (ECOC 2013)*, pp. 1–3, 2013.
- [21] P. Johannisson, M. Sjodin, T.A. Eriksson, and M. Karlsson. Four-dimensional modulation formats for long-haul transmission. in *Proc. of Optical Fiber Com-*

- munications Conference and Exhibition (OFC) 2014*, No. M2C.4.
- [22] B. P. Keyworth. ROADM subsystems and technologies. In *Proc. of OFC/NFOEC Technical Digest 2005.*, 2005.
- [23] T. A. Strasser and J. L. Wagener. Wavelength-selective switches for ROADM applications. *IEEE Journal of Selected Topics in Quantum Electronics*, Vol. 16, No. 5, pp. 1150–1157, 2010.
- [24] P. Roorda and B. Collings. Evolution to colorless and directionless ROADM architectures. In *Proc. of Conference on Optical Fiber Communication/National Fiber Optic Engineers Conference (OFC/NFOEC) 2008*, 2008.
- [25] R. Elschner, F. Frey, C. Meuer, J. K. Fischer, S. Alreesh, C. Schmidt-Langhorst, L. Molle, T. Tanimura, and C. Schubert. Experimental demonstration of a format-flexible single carrier coherent receiver using data-aided digital signal processing. *Optics Express*, Vol. 20, No. 27, pp. 28786–28791, 2012.
- [26] M. Eiselt, B. Teipen, K. Grobe, A. Autenrieth, and J. P. Elbers. Programmable modulation for high-capacity networks. in *Proc. of 37th European Conference and Exhibition on Optical Communication (ECOC) 2011*, No. Tu.5.A.5.
- [27] W. Idler, F. Buchali, L. Schmalen, K. Schuh, and H. Buelow. Hybrid modulation formats outperforming 16QAM and 8QAM in transmission distance and filtering with cascaded WSS. in *Proc. of Optical Fiber Communications Conference and Exhibition (OFC) 2015*, No. M.3.G.4.
- [28] Q. Zhuge, X. Xu, M. Morsy-Osman, M. Chagnon, M. Qiu, and D.V. Plant. Time domain hybrid QAM based rate-adaptive optical transmissions using high speed DACs. *Proc. of Optical Fiber Communication Conference and Exposition and the National Fiber Optic Engineers Conference (OFC/NFOEC) 2013*, No. OTh4E.6.
- [29] X. Zhou, L.E. Nelson, P. Magill, R. Isaac, B. Zhu, D.W. Peckham, P.I. Borel, and K. Carlson. High spectral efficiency 400 Gb/s transmission using PDM time-domain hybrid 32-64QAM and training-assisted carrier recovery. *IEEE Journal of Lightwave Technology*, Vol. 31, No. 7, pp. 999–1005, 2013.
- [30] J.K. Fischer, S. Alreesh, R. Elschner, F. Frey, M. Nolle, C. Schmidt-Langhorst, and C. Schubert. Bandwidth-variable transceivers based on four-dimensional modulation formats. *J. Lightw. Technol.*, Vol. 32, No. 16, pp. 2886–2895, 2014.
- [31] N. Sambo, P. Castoldi, A.D. Errico, E. Riccardi, A. Pagano, M.S. Moreolo, J.M.

- Fabrega, D. Rafique, A. Napoli, S. Frigerio, E.H. Salas, G. Zervas, M. Nolle, J. K. Fischer, A. Lord, and J.P.F.-P Gimenez. Next generation sliceable bandwidth variable transponders. *IEEE Commun. Mag.*, pp. 163–171, 2015.
- [32] F. Buchali, F. Steiner, G. Bocherer, L. Schmalen, P. Schulte, and W. Idler. Rate-adaptation and reach increase by probabilistically shaped 64-QAM: an experimental demonstration. *J. Lightw. Technol.*, Vol. 34, No. 7, pp. 1599–1609, 2016.
- [33] Mark Filer, Jamie Gaudette, Monia Ghobadi, Ratul Mahajan, Tom Issenhuth, Buddy Klinkers, and Jeff Cox. Elastic optical networking in the Microsoft cloud. *Journal of Optical Communications and Networking*, Vol. 8, No. 6, pp. A45–A54, 2016.
- [34] Yvan Pointurier. Design of low-margin optical networks. *J. Opt. Commun. Netw.*, Vol. 9, No. 1, pp. A9–A17, 2017.
- [35] F. N. Hauske, M. Kuschnerov, B. Spinnler, and B. Lankl. Optical performance monitoring in digital coherent receivers. *Journal of Lightwave Technology*, Vol. 27, No. 16, pp. 3623–3631, Aug 2009.
- [36] Nick McKeown, Tom Anderson, Hari Balakrishnan, Guru Parulkar, Larry Peterson, Jennifer Rexford, Scott Shenker, and Jonathan Turner. Openflow: Enabling innovation in campus networks. *SIGCOMM Comput. Commun. Rev.*, Vol. 38, No. 2, pp. 69–74, 2008.
- [37] Takahito Tanimura, Takeshi Hoshida, Hisao Nakashima, Yuichi Akiyama, Meng Yan, Zhenning Tao, and Jens C. Rasmussen. In-band FSK supervisory signaling between adaptive optical transceivers employing digital signal processing. In *Proc. of 37th European Conference and Exposition on Optical Communications (ECOC) 2011*, p. We.7.A.6, 2011.
- [38] Takahito Tanimura, Takeshi Hoshida, Shoichiro Oda, Yuichi Akiyama, Hisao Nakashima, Yasuhiko Aoki, Yinwen Cao, Meng Yan, Zhenning Tao, and Jens C. Rasmussen. Superimposition and detection of frequency modulated tone for light path tracing employing digital signal processing and optical filter. In *Proc. of Optical Fiber Communication Conference (OFC) 2012*, p. OW4G.4, 2012.
- [39] S. Yan, A. Aguado, Y. Ou, R. Wang, R. Nejabati, and D. Simeonidou. Multi-layer network analytics with SDN-based monitoring framework. *IEEE J. Opt. Commun. Netw.*, Vol. 9, No. 2, pp. A271–A279, 2017.

-
- [40] F. Meng, Y. Ou, S. Yan, K. Sideris, M. D. G. Pascual, R. Nejabati, and D. Simeonidou. Field trial of a novel SDN enabled network restoration utilizing in-depth optical performance monitoring assisted network re-planning. In *Proc. of OFC 2017*, p. Th1J.8., 2017.
- [41] A. Di Giglio and A. Pagano. Cross-layer, dynamic network orchestration, leveraging software-defined optical performance monitors. In *Fotonica AEIT Italian Conf. on Photonics Technologies*, 2015.
- [42] S. Oda, M. Miyabe, S. Yoshida, T. Katagiri, Y. Aoki, J. C. Rasmussen, M. Birk, and K. Tse. A learning living network for open ROADM networks. In *Proc. of European Conf. and Exhibition on Optical Communication (ECOC) 2016*, p. 262264, 2016.
- [43] A. Caballero, R. Borkowski, D. Zibar, and I. T. Monroy. Performance monitoring techniques supporting cognitive optical networking. In *Int. Conf. on Transparent Optical Networks*, p. Tu.B1.3., 2013.
- [44] Y. Yoshida, K. Kitayama, Y. Kai, M. Nishihara, R. Okabe, T. Tanaka, T. Takahara, J. C. Rasmussen, N. Yoshikane, X. Cao, T. Tsuritani, I. Morita, A. Mayoral, J. M. Fbrega, R. Vilalta, R. Casellas, R. Martinez, M. Svaluto Moreolo, R. Muoz, K. Habel, R. Freund, V. Lpez, A. Aguado, S. Yan, D. Simeonidou, T. Szyrkowiec, A. Autenrieth, M. Shiraiwa, Y. Awaji, and N. Wada. First demonstration of cognitive SDN orchestration: A real-time congestion-aware services provisioning over OFDM-based 400G OPS and flexi-WDM OCS networks. In *Proc. of Optical Fiber Communication Conf. (OFC) 2016*, p. Th5B.2, 2016.
- [45] R. Casellas, J. M. Fabrega, R. Munoz, L. Nadal, R. Vilalta, M. Svaluto Moreolo, and R. Martinez. On-demand allocation of control plane functions via SDN/NFV for monitoring enabled flexi-grid optical networks with programmable BVTs. In *Proc. of European Conf. and Exhibition on Optical Communication (ECOC) 2016*, pp. 515–517, 2016.
- [46] X.Wu, J.A.Jargon, R.A.Skoog, L.Paraschis, and A.E.Willner. Applications of artificial neural networks in optical performance monitoring. *J. Lightw. Technol.*, Vol. 27, No. 16, pp. 3580–3589, 2009.
- [47] J. A. Jargon, X. Wu, H. Y. Choi, Y. C. Chung, and A. E. Willner. Optical performance monitoring of QPSK data channels by use of neural networks trained

- with parameters derived from asynchronous constellation diagrams. *Opt. Express*, Vol. 18, No. 5, pp. 4931–4938, 2010.
- [48] X. Wu, J. A. Jargon, L. Paraschis, and A. E. Willner. ANN-based optical performance monitoring of QPSK signals using parameters derived from balanced-detected asynchronous diagrams. *IEEE Photon. Technol. Lett.*, Vol. 23, No. 4, pp. 248–250, 2011.
- [49] F. N. Khan, T. S. R. Shen, Y. Zhou, A. P. T. Lau, and C. Lu. Optical performance monitoring using artificial neural networks trained with empirical moments of asynchronously sampled signal amplitudes. *IEEE Photon. Technol. Lett.*, Vol. 24, No. 12, pp. 982–984, 2012.
- [50] J. Thrane, J. Wass, M. Piels, J. C. M. Diniz, R. Jones, and D. Zibar. Machine learning techniques for optical performance monitoring from directly detected PDM-QAM signals. *J. Lightw. Technol.*, Vol. 35, No. 4, pp. 868–875, 2017.
- [51] T. S. R. Shen, Q. Sui, and A. P. T. Lau. OSNR monitoring for PM-QPSK systems with large inline chromatic dispersion using artificial neural network. *IEEE Photon. Technol. Lett.*, Vol. 24, No. 17, pp. 1564–1567, 2012.
- [52] M. C. Tan, F. N. Khan, W. H. Al-Arashi, Y. D. Zhou, and A. P. T. Lau. Simultaneous optical performance monitoring and modulation format/bit-rate identification using principal component analysis. *J. Opt. Commun. Netw.*, Vol. 6, No. 5, pp. 441–448, 2014.
- [53] F. N. Khan, Y. Yu, M. C. Tan, W. H. Al-Arashi, C. Yu, A. P. T. Lau, and C. Lu. Experimental demonstration of joint OSNR monitoring and modulation format identification using asynchronous single channel sampling. *Opt. Express*, Vol. 23, pp. 30337–30346, 2015.
- [54] M. Jinno, H. Takara, K. Yonenaga, and A. Hirano. Virtualization in optical networks from network level to hardware level. *J. Opt. Commun. Netw.*, Vol. 5, No. 10, pp. A46–A56, 2012.
- [55] Y. Ou, S. Yan, A. Hammad, B. Guo, S. Peng, R. Nejabati, and D. Simeonidou. Demonstration of virtualizeable and software-defined optical transceiver. *J. Lightw. Technol.*, Vol. 34, No. 8, pp. 1916–1924, 2016.
- [56] G-H. Gho and J. M. Kahn. Rate-adaptive modulation and low density parity-check coding for optical fiber transmission systems. *IEEE/OSA J. Opt. Comm. Netw.*, Vol. 4, No. 10, pp. 760–768, 2012.

-
- [57] K. Sugihara, S. Kametani, K. Kubo, T. Sugihara, and W. Matsumoto. A practicable rate-adaptive FEC scheme flexible about capacity and distance in optical transport networks. *in Proc. of Optical Fiber Communications Conference and Exhibition (OFC) 2016*, No. M3A.5.
- [58] B. Teipen, M. Filer, H. Grieser, M. Eiselt, and J.P. Elbers. Forward error correction trade-offs in reduced-latency optical fiber transmission systems. *in Proc. of 38th European Conference and Exhibition on Optical Communications (ECOC) 2012*, No. P4.07.
- [59] Alan M. Turing. Computing machinery and intelligence. *Mind*, Vol. 59, No. 236, p. 433, 1950.
- [60] X. Xie, F. Yaman, X. Zhou, and G. Li. Polarization demultiplexing by independent component analysis. *IEEE Photon. Technol. Lett.*, Vol. 22, No. 11, pp. 805 – 807, 2010.
- [61] D. Zibar, O. Winther, N. Franceschi, R. Borkowski, A. Caballero, V. Arlunno, M. N. Schmidt, N. G. Gonzales, B. Mao, Y. Ye, K. J. Larsen, and I. T. Monroy. Nonlinear impairment compensation using expectation maximization for dispersion managed and unmanaged PDM 16-QAM transmission. *Opt. Express*, Vol. 20, pp. B181–B196, 2012.
- [62] T. Koike-Akino, C. Duan, K. Parsons, K. Kojima, T. Yoshida, T. Sugihara, and T. Mizuochi. High-order statistical equalizer for nonlinearity compensation in dispersion-managed coherent optical communications. *Opt. Express*, Vol. 20, pp. 15769–15780, 2012.
- [63] M. Li, S. Yu, J. Yang, Z. Chen, Y. Han, and W. Gu. Non-parameter nonlinear phase noise mitigation by using m-ary support vector machine for coherent optical systems. *IEEE Photon. J.*, Vol. 5, No. 6, p. 7800312, 2013.
- [64] D. Zibar, M. Piels, R. Jones, and C. G. Schaeffer. Machine learning techniques in optical communication. *J. Lightw. Technol.*, Vol. 34, No. 6, pp. 1442 – 1452, 2016.
- [65] J. Estaran, R. Rios-Muller, M. A. Mestre, F. Jorge, H. Mardoyan, A. Konczykowska, J.-Y. Dupuy, and S. Bigo. Artificial neural networks for linear and non-linear impairment mitigation in high-baudrate IM/DD systems. *In Proc. of ECOC 2016*, p. M2B.2, 2016.
- [66] D. Wang, M. Zhang, Z. Li, C. Song, M. Fu, J. Li, and X. Chen. System impair-

- ment compensation in coherent optical communications by using a bio-inspired detector based on artificial neural network and genetic algorithm. *Optics Communications*, Vol. 399, pp. 1–12, 2017.
- [67] D. Zibar, L. H. H. de Carvalho, M. Piels, A. Doberstein, J. Diniz, B. Nebendahl, C. Franciscangelis, J. Estaran, H. Haisch, N. G. Gonzalez, J. C. R. F. de Oliveira, and I. T. Monroy. Application of machine learning techniques for amplitude and phase noise characterization. *J. Lightw. Technol.*, Vol. 33, No. 7, pp. 1333–1343, 2015.
- [68] Y. Huang, C. L. Gutterman, P. Samadi, P. B. Cho, W. Samoud, C. Ware, M. Lourdiane, G. Zussman, and K. Bergman. Dynamic mitigation of EDFA power excursions with machine learning. *Opt. Express*, Vol. 25, No. 3, pp. 2245–2258, 2017.
- [69] E. Giacomidis, J. Wei, S. Mhatli, M. F. C. Stephens, N. J. Doran, A. D. Ellis, and B. J. Eggleton. Nonlinear inter-subcarrier intermixing reduction in coherent optical OFDM using fast machine learning equalization. In *Proc. of OFC 2017, W3J.2*, 2017.
- [70] R. Borkowski, D. Zibar, A. Caballero, V. Arlunno, and I. T. Monroy. Stokes space-based optical modulation format recognition for digital coherent receivers. *IEEE Photon. Technol. Lett.*, Vol. 25, No. 21, pp. 2129–2132, 2013.
- [71] T. B. Anderson, A. Kowalczyk, K. Clarke, S. D. Dods, D. Hewitt, and J. C. Li. Multi impairment monitoring for optical networks. *J. Lightw. Technol.*, Vol. 27, No. 16, pp. 3729–3736, 2009.
- [72] Darko Zibar, Henk Wymeersch, and Ilya Lyubomirsky. Machine learning under the spotlight. *Nature Photonics*, Vol. 11, No. 12, pp. 749–751, 2017.
- [73] Javier Mata, Ignacio de Miguel, Ramón J Durán, Noemí Merayo, Sandeep Kumar Singh, Admela Jukan, and Mohit Chamania. Artificial intelligence (AI) methods in optical networks: A comprehensive survey. *Optical Switching and Networking*, Vol. 28, pp. 43–57, 2018.
- [74] I. Goodfellow, Y. Bengio, and A. Courville. *Deep Learning*. MIT Press, 2016.
- [75] B. Szafraniec, T. S. Marshall, and B. Nebendahl. Performance monitoring and measurement techniques for coherent optical systems. *J. Lightw. Technol.*, Vol. 31, No. 4, pp. 648–663, 2013.
- [76] Z. Dong, F. N. Khan, Q. Sui, K. Zhong, C. Lu, and A. P. T. Lau. Optical

- performance monitoring: a review of current and future technologies. *J. Lightw. Technol.*, Vol. 34, No. 2, pp. 525–543, 2016.
- [77] C. C. K. Chan et al. *Optical Performance Monitoring: Advanced Techniques for Next-Generation Photonic Network*. Academic Press, 2010.
- [78] L. Deng and D. Yu. Deep learning: methods and applications. In *Foundations and Trends in Signal Processing*, Vol. 7, pp. 197–387, 2014.
- [79] George Cybenko. Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals, and Systems (MCSSS)*, Vol. 2, No. 4, pp. 303–314, 1989.
- [80] Guido Montúfar, Razvan Pascanu, Kyunghyun Cho, and Yoshua Bengio. On the number of linear regions of deep neural networks. In *Proceedings of the 27th International Conference on Neural Information Processing Systems - Volume 2*, NIPS’14, pp. 2924–2932, 2014.
- [81] X. Glorot, A. Bordes, and Y. Bengui. Deep sparse rectifier neural networks. In *Proc. of 14th International Conference on Artificial Intelligence and Statistics (AISTATS)*, pp. 315–323, 2011.
- [82] Quynh Nguyen and Matthias Hein. The loss surface of deep and wide neural networks. *arXiv preprint arXiv:1704.08045*, 2017.
- [83] John Duchi, Elad Hazan, and Yoram Singer. Adaptive subgradient methods for online learning and stochastic optimization. *Journal of Machine Learning Research*, Vol. 12, No. Jul, pp. 2121–2159, 2011.
- [84] Matthew D Zeiler. Adadelata: an adaptive learning rate method. *arXiv preprint arXiv:1212.5701*, 2012.
- [85] J. Ba and D. Kingma. Adam: a method for stochastic optimization. In *Proc. of 3rd International Conference on Learning Representations (ICLR)*, 2015.
- [86] David E. Rumelhart, Geoffrey E. Hinton, and Ronald J. Williams. Learning representations by back-propagating errors. *Nature*, Vol. 323, pp. 533–536, 1986.
- [87] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov. Dropout: a simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, Vol. 15, pp. 1929–1958, 2014.
- [88] S. Ioffe and C. Szegedy. Batch normalization: accelerating deep network training by reducing internal covariate shift. In *32nd International Conference on Machine Learning (ICML)*, 2015.

-
- [89] Govind Agrawal. *Nonlinear Fiber Optics*. Academic Press, 4th edition, 2006.
- [90] Masataka Nakazawa, Kazuro Kikuchi, and Tetsuya Miyazaki. *High Spectral Density Optical Communication Technologies*. Springer, 2010.
- [91] N. G. Gonzalez, D. Zibar, and I. T. Monroy. Cognitive digital receiver for burst mode phase modulated radio over fiber links. In *Proc. of 36th European Conference and Exhibition on Optical Communication*, pp. 1–3, 2010.
- [92] Faisal Nadeem Khan, Yudi Zhou, Alan Pak Tao Lau, and Chao Lu. Modulation format identification in heterogeneous fiber-optic networks using artificial neural networks. *Opt. Express*, Vol. 20, No. 11, pp. 12422–12431, May 2012.
- [93] M. Kuschnerov, M. Chouayakh, K. Piyawanno, B. Spinnler, E. de Man, P. Kainzmaier, M. S. Alfiad, A. Napoli, and B. Lankl. Data-aided versus blind single-carrier coherent receivers. *IEEE Photonics Journal*, Vol. 2, No. 3, pp. 387–403, 2010.
- [94] R. Andres Soriano, F. N. Hauske, N. Guerrero Gonzalez, Z. Zhang, Y. Ye, and I. Tafur Monroy. Chromatic dispersion estimation in digital coherent receivers. *Journal of Lightwave Technology*, Vol. 29, No. 11, pp. 1627–1637, 2011.
- [95] F. N. Hauske, Z. Zhang, C. Li, C. Xie, and Q. Xiong. Precise, robust and least complexity CD estimation. In *Proc. of Optical Fiber Communication Conference and Exposition and the National Fiber Optic Engineers Conference (OFC/NFOEC) 2011*, pp. 1–3, 2011.
- [96] T. Tanimura, T. Hoshida, J.C. Rasmussen, M. Suzuki, and H. Morikawa. OSNR monitoring by deep neural networks trained with asynchronously sampled data. In *Proc. of OECC/PS 2016, TuB3-5*, 2016.
- [97] T. Tanimura, T. Hoshida, T. Kato, S. Watanabe, J. C. Rasmussen, M. Suzuki, and H. Morikawa. Deep learning based OSNR monitoring independent of modulation format, symbol rate and chromatic dispersion. In *Proc. of ECOC 2016, Paper Tu2C.2.*, 2016.
- [98] K. Kikuchi. Fundamentals of coherent optical fiber communications. *J. Lightw. Technol.*, Vol. 34, No. 1, pp. 157–179, 2016.
- [99] T. V. Sze, Y. H. Chen, J. Emer, A. Suleiman, and Z. Zhang. Hardware for machine learning: challenges and opportunities. In *IEEE Custom Integrated Circuits Conference (CICC)*, 2017.
- [100] M. Abadi et al. Tensorflow: a system for large-scale machine learning. In

-
- 12th USENIX Symposium on Operating Systems Design and Implementation (OSDI)*, 2016.
- [101] T. Tanimura, T. Hoshida, T. Kato, S. Watanabe, M. Suzuki, , and H. Morikawa. Throughput and latency programmable optical transceiver by using DSP and FEC control. *Opt. Express*, Vol. 25, No. 10, pp. 10815–10827, 2017.
- [102] K. Sugihara, K. Ishii, K. Dohi, K. Kubo, T. Sugihara, and W. Matsumoto. Scalable SD-FEC for efficient next-generation optical networks. *in Proc. of 42nd European Conference on Optical Communication (ECOC) 2016*, pp. 568–570, 2016.
- [103] A. Leven and L. Schmalen. Status and recent advances on forward error correction technologies for lightwave systems. *J. Lightw. Technol.*, Vol. 32, No. 16, pp. 2735–2750, 2014.
- [104] P. Samadi, K. Wen, J. Xu, and K. Bergman. Software-defined optical network for metro-scale geographically distributed data centers. *Opt. Express*, Vol. 24, pp. 12310–12320, 2016.
- [105] V. Bahl. Cloud 2020: the emergence of micro datacenter for mobile computing. *Microsoft Available online at <https://www.microsoft.com/en-us/research/wp-content/uploads/2016/>*, 2015.
- [106] P. Samadi, M. Fiorani, Y. Shen, L. Wosinska, and K. Bergman. Flexible architecture and autonomous control plane for metro-scale geographically distributed data centers. *J. Lightw. Technol.*, Vol. PP, No. 99, 2017.
- [107] T. Tanimura, L. Dou, X. Su, T. Hoshida, Y. Aoki, Z. Tao, J. Rasmussen, M. Suzuki, and H. Morikawa. Latency and bandwidth programmable transceivers with power arbitration among multi-tenanted signals. *In Proc. of OFC 2016, W4A.6*, 2016.
- [108] V. Bobrovs, S. Spolitis, and G. Ivanovs. Latency causes and reduction in optical metro networks. *in Proc. of SPIE 9008, Optical Metro Networks and Short-Haul Systems VI*, Vol. 90080C, , 2013.
- [109] K. Lee, H. G. Kang, J. I. Park, and H. Lee. 100Gb/s two-iteration concatenated BCH decoder architecture for optical communications. *IEEE Workshop on Signal Processing Systems 2010*, pp. 404–409, 2010.
- [110] L. Dou, X. Su, Y. Fan, H. Chen, Y. Zhao, Z. Tao, T. Tanimura, T. Hoshida, and J. Rasmussen. 420Gbit/s dp-64QAM Nyquist-FDM single-carrier system.

-
- In *Proc. of Optical Fiber Communications Conference and Exhibition (OFC) 2016, Tu3A.5*, 2016.
- [111] M. Qiu, Q. Zhuge, M. Chagnon, Y. Gao, X. Xu, M. Morsy-Osman, and D.V. Plant. Digital subcarrier multiplexing for fiber nonlinearity mitigation in coherent optical communication systems. *Opt. Express*, Vol. 22, pp. 18770–18777, 2014.
- [112] E. Torrenco, R. Cigliutti, G. Bosco, A. Carena, V. Curri, P. Poggiolini, A. Nespola, D. Zeolla, and F. Forghieri. Experimental validation of an analytical model for nonlinear propagation in uncompensated optical links. *Opt. Express*, Vol. 19, pp. B790–B798, 2011.
- [113] DVB-S.2 standard specification. *ETSI EN 302 307 V1.1.1 (2005-03)*.
- [114] A. Carena, V. Curri, G. Bosco, P. Poggiolini, and F. Forghieri. Modeling of the impact of nonlinear propagation effects in uncompensated optical coherent transmission links. *Journal of Lightwave Technology*, Vol. 30, No. 10, pp. 1524–1539, 2012.
- [115] Ronen Dar, Meir Feder, Antonio Mecozzi, and Mark Shtaif. Properties of nonlinear noise in long, dispersion-uncompensated fiber links. *Optics Express*, Vol. 21, No. 22, pp. 25685–25699, 2013.

発表文献

論文誌 (査読あり)

- [1] T. Tanimura, T. Hoshida, T. Kato, S. Watanabe, M. Suzuki, and H. Morikawa, “Throughput and latency programmable optical transceiver by using DSP and FEC control,” *Optics Express*, Vol. 25, No. 10, pp. 10815–10827, 2017.

国際会議における発表

- [2] T. Tanimura, L. Dou, X. Su, T. Hoshida, Y. Aoki, Z. Tao, J. C. Rasmussen, M. Suzuki, and H. Morikawa, “Latency and bandwidth programmable transceivers with power arbitration among multi-tenanted signals,” in *Proc. of Optical Fiber Communications Conference and Exhibition (OFC) 2016*, W4A.6, 2016.
- [3] T. Tanimura, T. Hoshida, J. C. Rasmussen, M. Suzuki, and H. Morikawa, “OSNR monitoring by deep neural networks trained with asynchronously sampled data,” in *Proc. of OptoElectronics and Communications Conference (OECC) 2016*, TuB3-5, 2016.
- [4] T. Tanimura, T. Hoshida, T. Kato, S. Watanabe, J. C. Rasmussen, M. Suzuki, and H. Morikawa, “Deep learning based OSNR monitoring independent of modulation format, symbol rate and chromatic dispersion,” in *Proc. of 42nd European Conference on Optical Communication (ECOC) 2016*, Tu.2.C.2, 2016.
- [5] T. Tanimura, T. Hoshida, T. Kato, S. Watanabe, and H. Morikawa, “Data-analytics-based Optical Performance Monitoring Technique for Optical Transport Networks (Invited),” to be presented at *Optical Fiber Communications Conference and Exhibition (OFC) 2018*, Tu3E.3, 2018.

国際会議におけるワークショップでの発表

- [6] T. Tanimura, “Deep learning in optical performance monitoring,” at 43rd European Conference on Optical Communication (ECOC) 2017 Workshop “Opportunities for machine learning in optical communication: from components characterization, systems design and network optimization,” WS8, 2017.
- [7] T. Tanimura, to be presented at Optical Fiber Communications Conference and Exhibition (OFC) 2018 Workshop “AI-assisted Automated Network Operation: Getting Matured or Not?,” 2018.

国内学会・研究会

- [8] 谷村崇仁, 星田剛司, Jens C. Rasmussen, 鈴木誠, 森川博之, 「ハイブリッド・ナイキスト周波数多重を用いた処理遅延および帯域可変光送受信器の実験的検討」, 電子情報通信学会 OCS 研究会, 信学技報, Vol. 116, No. 164, OCS2016-21, pp. 5–10, 2016.
- [9] 谷村崇仁, 星田剛司, Jens C. Rasmussen, 鈴木誠, 森川博之, 「アプリケーション指向型光送受信器の提案と実験的検討」, 電子情報通信学会総合大会, , B10-40, 九州大学 (伊都キャンパス), 2016.

商業誌における解説記事

- [10] 谷村崇仁, 「深層ニューラルネットワークを用いた光ネットワークのモニタリング」, 光技術コンタクト Vol. 55, No. 12, 2017.