

# 修士論文

光コヒーレント伝送における

ニューラルネットワークを用いた非線形劣化補償

Nonlinear Distortion Compensation using Neural Networks in  
Coherent Optical Transmission Systems

---

報告者

学籍番号: 1235118

氏名: 上山 峻央

---

指導教員

岩下 克 教授

---

令和3年2月12日

高知工科大学大学院 基盤工学専攻 電子・光工学コース

## 目次

第1章	序論	1
1.1	研究背景・目的	1
1.2	論文構成	2
第2章	非線形劣化補償 NN における新たな学習方法の提案	3
2.1	従来法の問題点	3
2.2	新たな学習法の提案	5
2.3	現実の伝送路における非線形劣化補償 NN の使用方法	7
第3章	光コヒーレント伝送	8
3.1	光ファイバにおける光信号の伝搬	8
3.2	スプリットステップフーリエ法	9
3.3	DBP (Digital Back Propagation Method)	9
3.4	コサインロールオフフィルタ (Raised Cosine Filter)	10
3.5	位相同期回路 (PLL: Phase Locked Loop)	11
3.5.1	位相の不確定性の補償	12
第4章	ニューラルネットワーク	14
4.1	CvNN (Complex valued Neural Network)	14
4.2	RvNN (Real valued Neural Network)	15
4.3	活性化関数	16
4.4	学習に関して	17
4.4.1	データセットの分割	17
4.4.2	誤差逆伝播法	18
4.4.3	勾配消失問題	20
第5章	シミュレーション・結果	23
5.1	光コヒーレント伝送システムモデル	23
5.1.1	学習データの準備	23
5.2	結果	24
第6章	まとめ	30
	参考文献	
	付録	

## 第1章 序論

### 1.1 研究背景・目的

インターネットトラフィックが爆発的に増加し続けている。2022年には1月あたりのIPトラフィックは396EBにまで増加すると予測されている。2017～2022年のIPトラフィックの推移及び予測を図1-1に示す[1]。こういった動向を受け、大容量ネットワーク、特に大容量光ネットワークの需要が大幅に増加している。光ネットワーク大容量化のためには、光ファイバへの入力光強度を大きくする必要がある。しかし、入力光強度が大きいほど、光ファイバでの非線形劣化が大きくなってしまふ。これによって光ネットワークの通信容量は制限されてしまふ。この問題を解決するために、Digital Back Propagation (DBP) [2]や Volterra Series Transfer Function (VSTF) [3]など、光ファイバの非線形劣化に対するいくつかの補償法が提案されている。DBPは、スプリットステップフーリエ法[4]を使用して、光ファイバにおける光信号伝搬を表す非線形シュレディンガー方程式の解を近似する。VSTFは、Volterra 伝達関数の逆関数を用いて、波長分散と光ファイバの非線形劣化を補償する。ただし、DBPとVSTFは膨大な計算量を必要とし、これが実装における大きな欠点となる。従って、光ネットワークの容量をさらに増やすには、計算量が少なく、実装に適した補償法が必要となる。

近年、新たな光ファイバ非線形劣化補償法として、ニューラルネットワーク (NN) を用いた非線形劣化補償法が注目されている[5-10]。NNは、非線形関数である活性化関数を用いることにより、光ファイバの非線形劣化補償を可能にする。[5-7]では、1-3層の隠れ層で構成されるNNを使用する非線形劣化補償法が提案され、DBPよりも少ない計算量でDBPと同等の補償性能を持つことが示された。ただし、これらの方法では、光源の線幅による位相雑音が大きい場合に光ファイバの非線形劣化を補償することができない。これは、位相雑音存在下で非線形劣化を補償するための機構が組み込まれていないためである。一方、[8]では、光源の線幅が大きい場合でも光ファイバの非線形劣化を補償できる実用的な方法が提案された。[8]では、位相雑音存在下でもNNに非線形劣化補償を学習させるために、何層かの静的な隠れ層が使用された。しかし、この方法では、伝送距離が長くなり、非線形劣化が大きくなると、予めその伝送距離よりも短い距離で学習したNNが学習のために必要となる。このように、現在は長距離伝送でNNの学習を行うことは容易ではない。その理由の1つは、光ファイバの非線形劣化の増加により、学習時に必要とされる位相推定を正確に行えなくなってしまうことである。

本研究では位相推定に関するこの問題を解決するために、非線形劣化補償 NN の新たな学習方法を提案する。この学習方法は、伝送距離 4,000km の 32Gbaud 16QAM 光コヒーレント伝送において検討した。

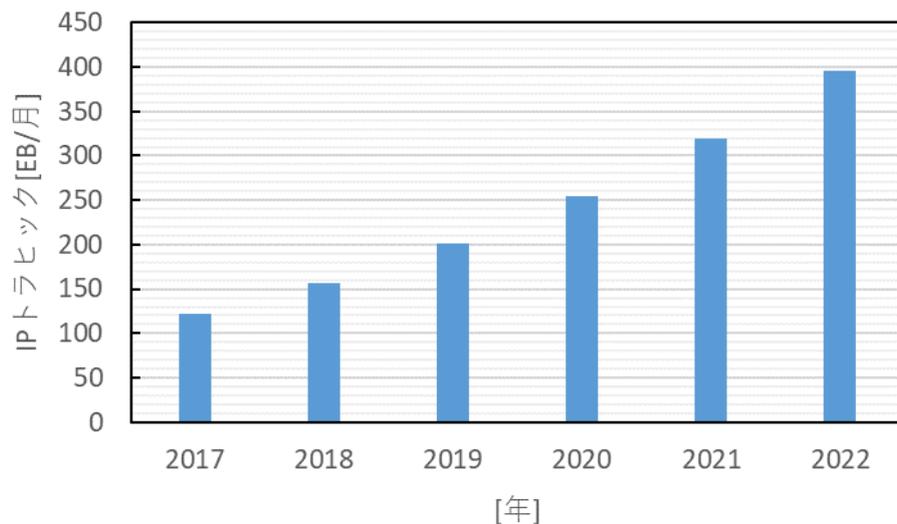


図 1-1 IP トラフィックの推移[1]

## 1.2 論文構成

本論文は、6章に分けて構成されている。第2章では、非線形劣化補償 NN の新たな学習方法について述べている。第3章では、光コヒーレント伝送について述べている。第4章では、本論文で用いた NN の構造など、ニューラルネットワークについて述べている。第5章では、本論文で用いた具体的なシミュレーション構成と結果について述べている。第6章では、本論文のまとめを述べている。

## 第2章 非線形劣化補償 NN における新たな学習方法の提案

光ネットワークの大容量化のために、光ファイバへの入力光強度を大きくする必要がある。しかし、入力光強度が大きいほど、非線形劣化が大きくなってしまい、これが光ネットワークの大容量化を阻害する。非線形劣化とは、波形の広がりによって信号品質が劣化してしまう現象のことで、振幅や位相に変化が生じる。非線形劣化については次の章で詳しく述べる。近年、この問題を解決するために、NN を用いた光ファイバ非線形劣化補償法が多く提案されている[5-9]。しかし、[5-7]で用いられている学習方法だと、レーザー線幅による位相雑音が大きいうちに非線形劣化の学習を行えなくなってしまう。位相雑音とは、レーザーの発振波長揺らぎで発生する雑音のことで、送信レーザーとローカルレーザーそれぞれで発生する。また、本論文では、位相雑音において、変化が緩やかな位相変化を位相ドリフトと呼び、初期位相のずれを位相オフセットと呼ぶことにする。

### 2.1 従来法の問題点

従来法が抱える問題について述べていく。従来法[5-7]は、下の図 2-1 に示すように、NN を用いて非線形劣化補償を行う。送信信号は伝送路で劣化していき、受信される。ここでは、非線形劣化、波長分散、位相雑音などの様々な要因によって信号が大きく劣化している。次に、波長分散補償が行われる。この状態から非線形劣化補償を行っていく。

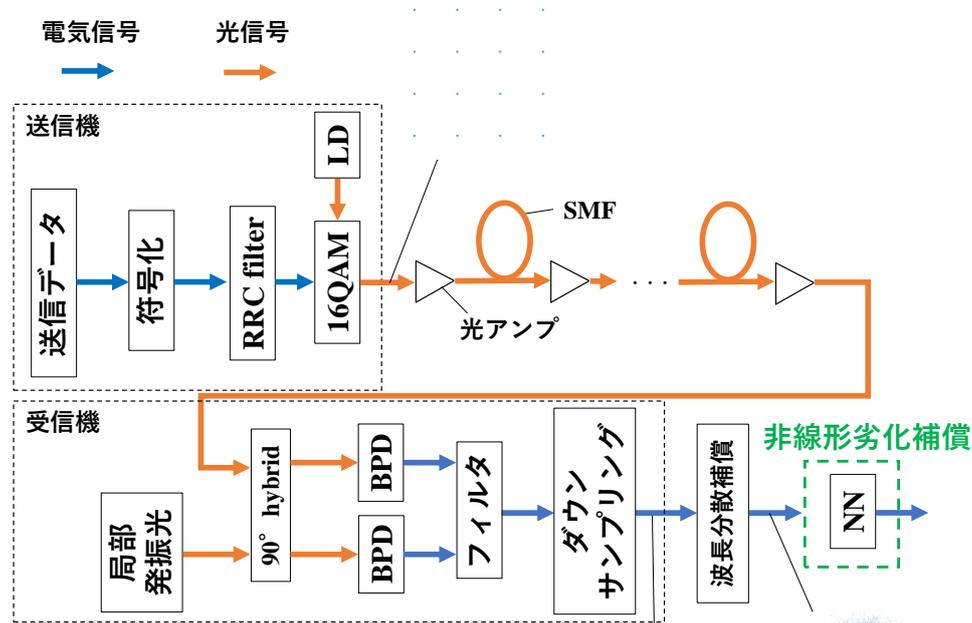


図 2-1 従来法における非線形劣化補償の流れ (SMF: Single Mode Fiber, BPD: Balance Phot Diode)

NNには下の図2-2のような構造のものが用いられた。 $x(t)$ は波長分散補償後の受信信号のことで、NNに対象のシンボルとその両側複数シンボルを入力することによって、非線形劣化によるシンボル間の干渉を学習し、非線形劣化補償を可能とした。

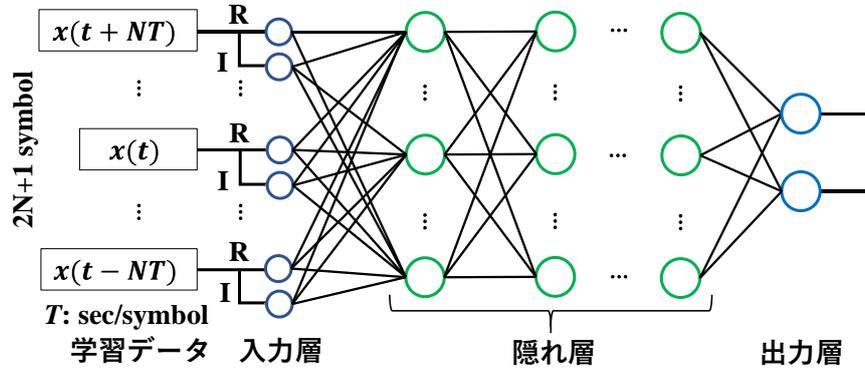


図 2-2 従来法で用いられた NN の構造

しかし、この方法には、レーザー線幅による位相雑音が大きの場合において学習が進まなくなってしまうという問題がある。これは、送信データをそのまま正解データとしていることが原因である。まず、振幅成分を $A(t)$ 、変調成分を $\varphi(t)$ とおくと、送信信号 $x_t(t)$ は以下の式(2.1)によって表される。

$$x_t(t) = A(t)\exp(j\varphi(t)) \quad (2.1)$$

送信後に伝送路で加わる非線形劣化や雑音に加わった振幅を $A'(t)$ 、非線形劣化による位相変化を $\theta(t)$ 、送信レーザーとローカルレーザーの線幅による位相雑音を $\delta(t)$ とすると、受信信号 $x_r(t)$ は以下のように表すことができる。伝送途中で波長分散も加わるが、これは NN に入力する前に線形計算による補償を行うので、ここでは含まれていないことに注意する。

$$x_r(t) = A'(t)\exp(j(\varphi(t) + \theta(t) + \delta(t))) \quad (2.2)$$

従来法では、この受信信号に対する正解データとして、送信信号をそのまま用いる。すなわち、受信信号 $x_r(t)$ に対する正解データ $T(t)$ は

$$T(t) = x_t(t) = A(t)\exp(j\varphi(t)) \quad (2.3)$$

とされる。つまり、NN は、非線形劣化による位相変化 $\theta(t)$ とレーザー線幅による位相雑音 $\delta(t)$ を補償するように学習していく。非線形劣化による位相変化 $\theta(t)$ は、上で述べた NN のように、非線形劣化による干渉の範囲を NN に入力すれば学習することができる。しかし、位相雑音 $\delta(t)$ を補償するためには、PLLのような位相補償機構が必要になる。しかし、これらの機構は NN の学習において用いられる誤差逆伝播法が適用できない構造のため、NN 内に実装することができない。従って、従来法ではレーザー線幅による位相雑音が存在する状況下では、非線形劣化の学習が行えなくなってしまう。これが従来法の抱える問題である。

## 2.2 新たな学習法の提案

位相雑音に関して従来法が抱える問題を解決するために、本論文では下の図 2-3 のような構成を用いた。従来法との違いは、NN の後ろに PLL が置かれているかどうかである。この PLL によって位相雑音の補償を行うため、NN では位相雑音の補償を行わなくてよくなる。ただし、この構成そのものは[8]でも似た構成が用いられており、本論文で行う提案の肝ではない。本論文で行う提案の肝は、下で述べる新たな学習方法である。

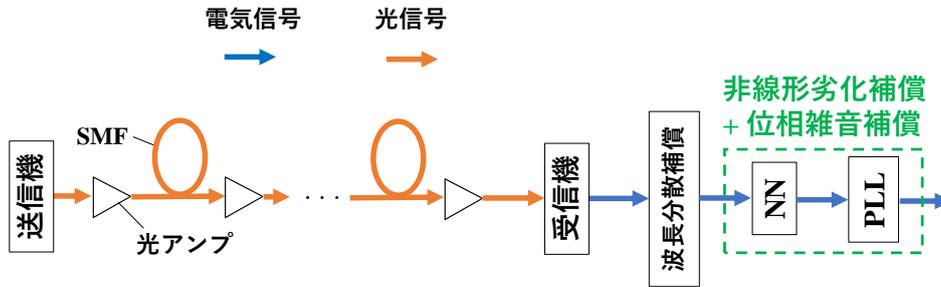


図 2-3 本論文で用いた補償構成

図 2-3 に示した構成における NN は非線形劣化補償のみを行う。すなわち、学習時に位相雑音を無視する必要がある。これは簡単なことではない。本論文では、位相雑音を無視して学習を行うために、下の図 2-4 に示す新たな学習方法を提案する。この学習方法の特徴は、正解データを、受信信号と送信信号を用いて生成することである。

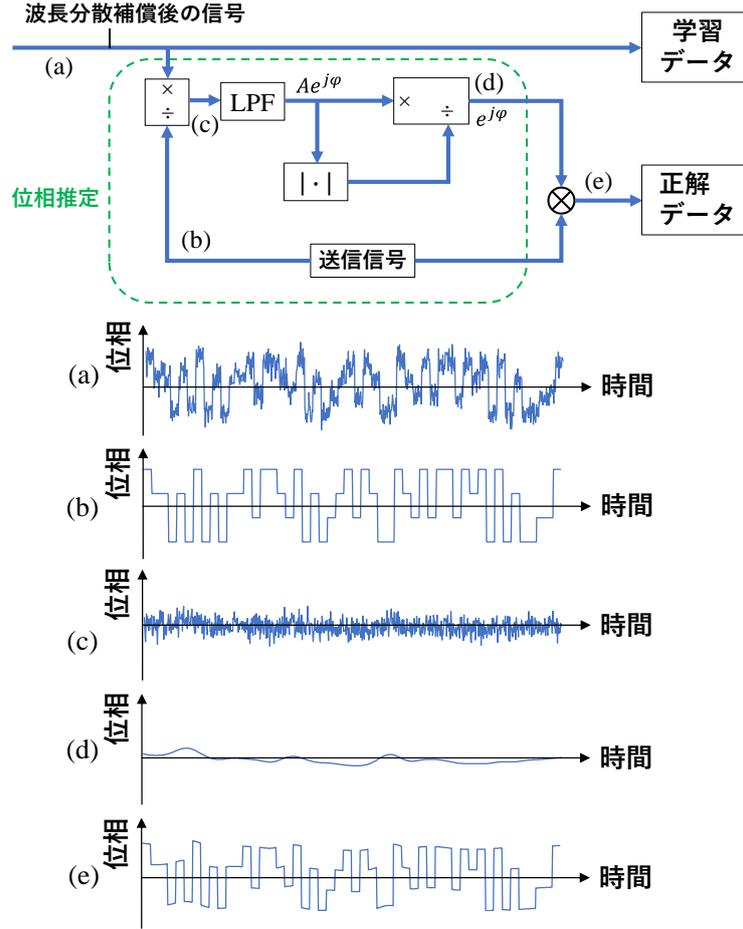


図 2-4 提案法における学習方法

まず、波長分散補償後の受信信号が入力される((a)). これは従来法と同様で、

$$x_{(a)}(t) = A'(t)\exp(j(\varphi(t) + \theta(t) + \delta(t))) \quad (2.4)$$

となる. 次に、入力された信号は送信信号((b))によって逆変調される((c)).

$$\begin{aligned} x_{(c)}(t) &= A'(t)\exp(j(\varphi(t) + \theta(t) + \delta(t))) \cdot A(t)^{-1}\exp(-j\varphi(t)) \\ &= A'(t)A(t)^{-1}\exp(j(\theta(t) + \delta(t))) \end{aligned} \quad (2.5)$$

逆変調された信号は、位相雑音（送信レーザーとローカルレーザー、カー効果）と光ファイバの非線形劣化によって生成される振幅変動で構成されている. その後、ローパスフィルタ（LPF）で高周波成分が除去される. LPF 通過後の振幅、非線形劣化、位相雑音をそれぞれ  $A_{LPF}(t)$ ,  $\theta_{LPF}(t)$ ,  $\delta_{LPF}(t)$  とすると、

$$\begin{aligned} x_{LPF}(t) &= LPF \left[ A'(t)A(t)^{-1}\exp(j(\theta(t) + \delta(t))) \right] \\ &= A_{LPF}(t)\exp(j(\theta_{LPF}(t) + \delta_{LPF}(t))) \end{aligned} \quad (2.6)$$

となる。ただし、周波数帯の低い位相ドリフトに対し、非線形劣化は高周波数帯も多く含むため、LPFのパラメータを適切に設定すれば、LPF通過後の位相ドリフト  $\delta_{LPF}(t)$  に対して、LPF通過後の非線形劣化  $\theta_{LPF}(t)$  は十分に小さくなる。また、位相オフセットは一定であるため、LPF通過後もそのまま残る。従って、式(2.6)は、

$$x_{LPF}(t) \approx A_{LPF}(t) \exp(j\delta_{LPF}(t)) \quad (2.7)$$

となる。その後、絶対値ブロックで振幅変動も除去され、位相ドリフトのみが残る((d)).

$$\begin{aligned} x_{(d)}(t) &= A_{LPF}(t) \exp(j\varphi\delta_{LPF}(t)) \cdot A_{LPF}(t)^{-1} \\ &= \exp(j\delta_{LPF}(t)) \end{aligned} \quad (2.8)$$

以上の計算によって求められた位相ドリフトと位相オフセットは送信信号  $x_t(t)$  に乗算される((e)).

$$x_{(e)}(t) = A(t) \exp(j\varphi(t)) \cdot \exp(j\delta_{LPF}(t)) = A(t) \exp(j(\varphi(t) + \delta_{LPF}(t))) \quad (2.9)$$

従って、正解データには送信信号と位相ドリフト、位相オフセットが含まれる。つまり、NN は位相ドリフトと位相オフセットを無視するようになるため、学習を行えるようになる。

提案法における最大の利点は、送信信号を使用しているため、位相推定を誤ることが絶対にならないことである。この利点により、提案法は光ファイバの非線形劣化が大きい状況下であっても、位相ドリフトと位相オフセットを正確に推定することができる。従って、提案法は長距離伝送における非線形劣化補償 NN の学習に適していると言える。本論文とは異なる方法で位相雑音存在下での学習を可能にした学習方法[8]も提案されており、この方法でも学習のために位相推定を行うのだが、位相推定の精度に問題点があり、伝送距離に制限が生じてしまう。解決策として、対象の伝送距離よりも短い距離で学習した NN を用いて予め非線形劣化補償をある程度行った後に位相推定を行う方法が挙げられているが、これには手間がかかってしまう。さらに、伝送路の状況が大きく変わった際に再学習できない可能性がある。提案法はこれらのいずれの問題も克服している。

### 2.3 現実の伝送路における非線形劣化補償 NN の使用方法

現実の伝送路において非線形劣化補償 NN を使用する時も、同様の学習方法を用いることができる。しかし、シミュレーションとは異なり、現実の伝送路では、学習のために用いる既知の送信信号がどの時間から始まっているのかがわからない。従って、学習を始める前に、受信信号と既知の送信信号の相互相関をとり、タイミングを合わせる必要がある。また、現実の伝送路のパラメータは変動していく。例えば、波長分散係数は温度変化によって変化する。こういったパラメータの変化に対しては、こまめに非線形劣化補償 NN の学習を繰り返すことによって対処する。

まず、非線形劣化補償 NN の学習は上で述べた新たな学習方法によって行われる。ただし、実際に現実の伝送路において非線形劣化補償 NN が用いられる際は、伝送路パラメータの変動に合わせてこまめに学習が行われる。

### 第3章 光コヒーレント伝送

#### 3.1 光ファイバにおける光信号の伝搬

まず、光ファイバの波長分散と非線形劣化（カー効果）について図 3-1 で説明していく。光ファイバに入力される光パルスは下の図 3-1(a)のように、光強度が時間的に変化している。次に、この光強度の時間変化に応じて、図 3-1(b)のように光ファイバ内の屈折率が変化する。次に、屈折率の変化によって、図 3-1(c)のように光波長が変化する。次に、波長分散によって光パルスの伝搬速度が変化する。波長分散とは、波長によって光の伝搬速度が異なる現象のことで、図 3-1(d)のように表される。この波長分散により、入力された光パルスは図 3-1(e)のように、時間的に広がったり狭まったりする。光ファイバ内ではこの一連の劣化が次々と起こっていくので、伝送距離が長いほどこれらによる劣化が大きくなっていく。

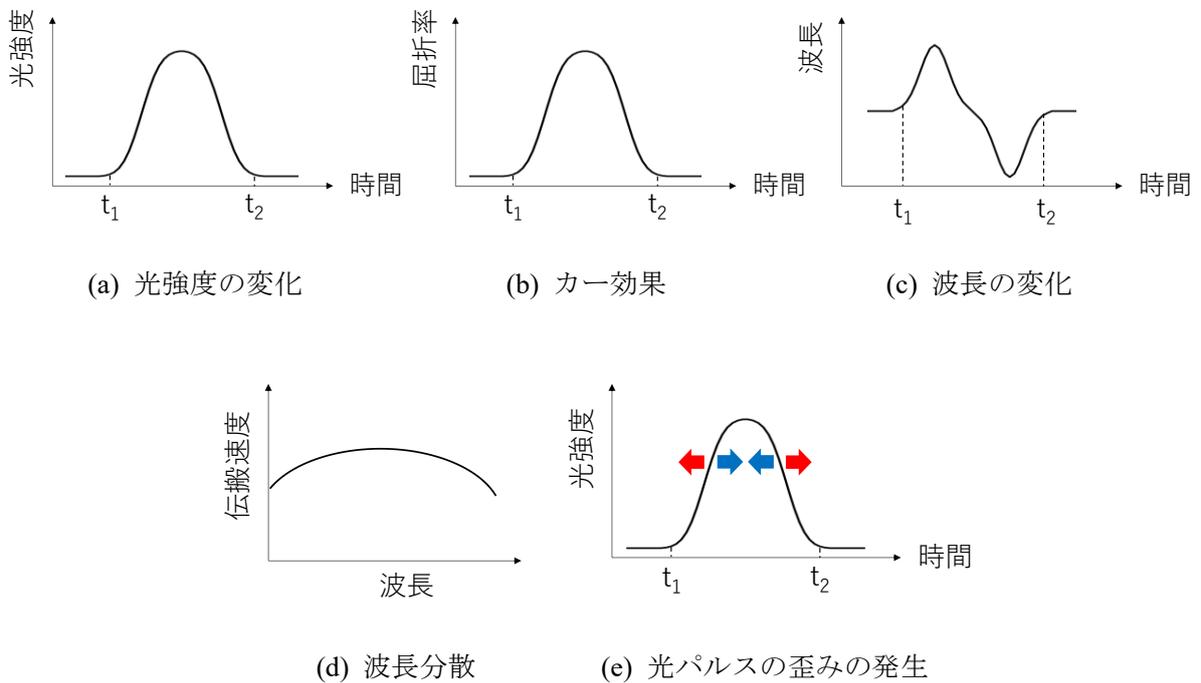


図 3-1 光ファイバ内での光信号劣化

次に、光ファイバの波長分散と非線形劣化について式で説明していく。光ファイバ中の光信号伝搬は非線形シュレディンガー方程式によって下の式(3.1)のように表すことができる。

$$\frac{\partial E}{\partial z} = (\hat{D} + \hat{N})E \quad (3.1)$$

ここで、 $\hat{D}$  は線形媒質における波長分散と減衰を表す微分演算子で、 $\hat{N}$  はパルス伝播における非線形劣化を表す非線形演算子である。E は複素包絡線振幅を表す。これらの演算子は以下の式(3.2)と式(3.3)によって表される。

$$\hat{D} = -\frac{j}{2}\beta_2 \frac{\partial^2}{\partial t^2} - \frac{\alpha}{2} \quad (3.2)$$

$$\hat{N} = j\gamma|E|^2 \quad (3.3)$$

$\beta_2, \alpha, \gamma$ はそれぞれ群速度分散係数、損失係数、非線形係数である。

### 3.2 スプリットステップフーリエ法

スプリットステップフーリエ法[4]では、図 3-2 のように、光ファイバ伝送路を区間  $h$  毎に細かく分割し、それぞれの区間  $h$  において波長分散と非線形劣化がそれぞれ独立して発生すると仮定することによって近似解を得る。

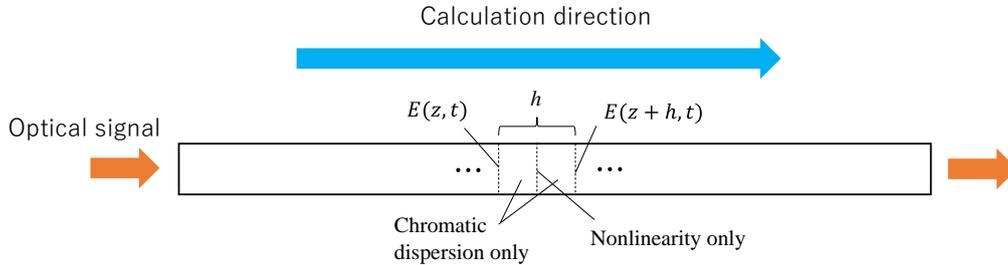


図 3-2 スプリットステップフーリエ法

まず、微小区間  $h$  の前半  $h/2$  において  $\hat{N} = 0$  として波長分散のみを計算する。次に、微小区間  $h$  の中間において  $\hat{D} = 0$  として非線形劣化のみを計算する。最後に、区間  $h$  の後半  $h/2$  において  $\hat{N} = 0$  として波長分散のみを計算する。これは式(3.1)より、

$$E(z+h, t) \cong \exp\left(\frac{h}{2}\hat{D}\right) \exp\left(\int_z^{z+h} \hat{N}(z')dz'\right) \exp\left(\frac{h}{2}\hat{D}\right) E(z, t) \quad (3.4)$$

と表される。区間  $h$  の前半と後半で波長分散は以下の式(3.5)のようにフーリエ変換を用いて計算される。

$$\exp\left(\frac{h}{2}\hat{D}\right) E(z, t) = \left\{ F^{-1} \exp\left[\frac{h}{2}\hat{D}(i\omega)\right] F \right\} E(z, t) \quad (3.5)$$

区間  $h$  の中間で非線形劣化は以下の式(3.6)のように台形近似を用いて計算される。

$$\int_z^{z+h} \hat{N}(z')dz' \cong \frac{h}{2} [\hat{N}(z) + \hat{N}(z+h)] \quad (3.6)$$

ここで、区間  $h$  を短くし、伝送路を細かく分割するほど高精度な解を得ることができる。

### 3.3 DBP (Digital Back Propagation Method)

本論文では、非線形劣化補償 NN の性能が優れていることを示すための比較対象として DBP を用いた。DBP では、スプリットステップフーリエ法の逆算を行う。すなわち、式(3.1)より、

$$\frac{\partial E}{\partial z} = (\hat{D}^{-1} + \hat{N}^{-1})E \quad (3.7)$$

で表される非線形シュレディンガー方程式の解を求める。従って、スプリットステップフーリエ法と同様に、光ファイバ伝送路を区間  $h$  毎に細かく分割し、これを遡りながら波長分散と非線形劣化を補償する。

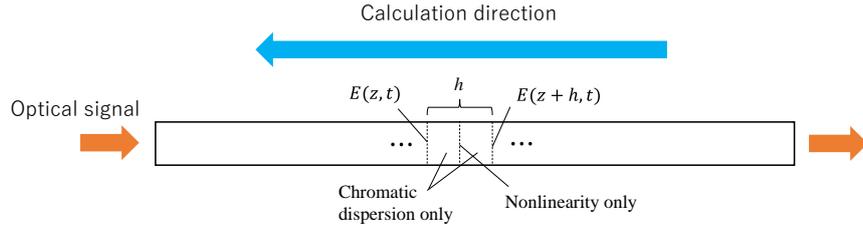


図 3-3 DBP

式(3.7)より,

$$E(z+h, t) \cong \exp\left(\frac{h}{2}\hat{D}^{-1}\right) \exp\left(\int_z^{z+h} \hat{N}^{-1}(z') dz'\right) \exp\left(\frac{h}{2}\hat{D}^{-1}\right) E(z, t) \quad (3.8)$$

を計算すればよい. スプリットステップフーリエ法と同様に, 分割を細かくするほど高精度な補償が行われる. しかし, 分割が細かいほど計算量が多くなっていき, 非線形劣化の補償に多くの時間がかかってしまうという問題がある.

### 3.4 コサインロールオフフィルタ (Raised Cosine Filter)

本論文では, 波形整形のためにコサインロールオフフィルタを用いた. 周波数応答は下の式(3.9)と図 3-4 によって表される. ロールオフ係数 $\alpha$ によってフィルタの特性を調整することができる. また,  $\omega_1 = \pi/T_0$ である.

$$H(\omega) = \begin{cases} \frac{1}{2} \left[ 1 - \sin\left\{ \frac{\pi(|\omega| - \omega_1)}{2\alpha\omega_1} \right\} \right] & [(1-\alpha)\omega_1 \leq |\omega| \leq (1+\alpha)\omega_1] \\ 1 & [|\omega| \leq (1-\alpha)\omega_1] \\ 0 & [|\omega| \geq (1+\alpha)\omega_1] \end{cases} \quad (3.9)$$

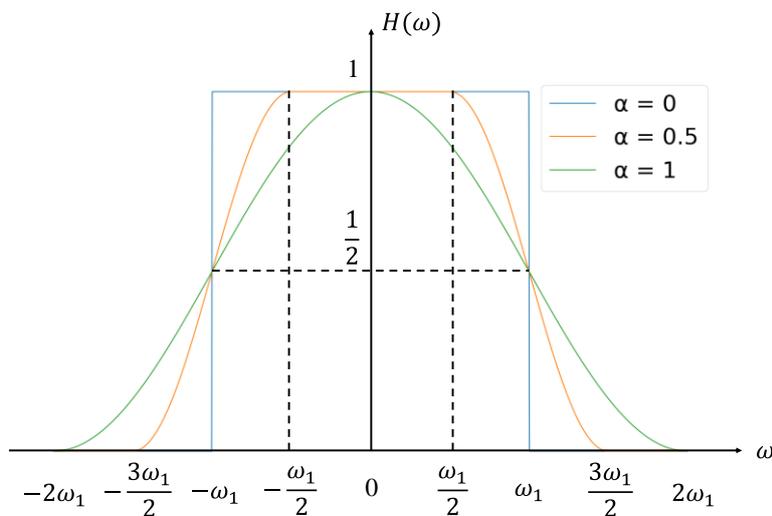


図 3-4 コサインロールオフフィルタの周波数応答

本論文では、このコサインロールオフフィルタの平方根をとった Root Raised Cosine フィルタを送信側と受信側において用いた。

### 3.5 位相同期回路 (PLL: Phase Locked Loop)

図 3-5 は PLL の線形モデルである。

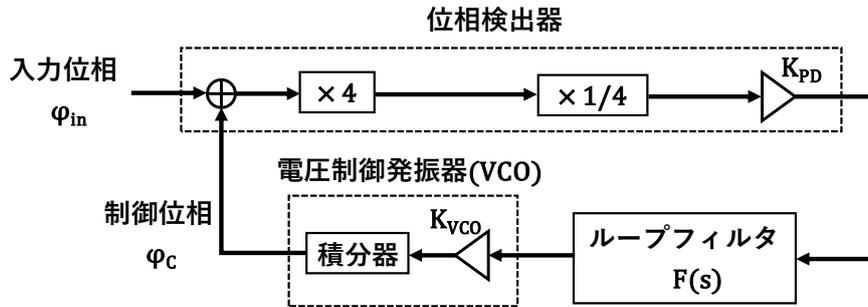


図 3-5 PLL の線形モデル

このような線形モデルの PLL では入力位相は非常に小さいので、 $\sin \varphi_{in} \approx \varphi_{in}$  と考えられる。入力信号は  $\varphi_{in}$  と表すことができ、以下のように考えられる。信号光と局部発振光の初期位相をそれぞれ  $\theta_s, \theta_l$ 、初期位相差を  $\Delta\theta = \theta_s - \theta_l$ 、変調成分を  $\varphi_s = 0, \pi/2, \pi, 3\pi/2$  とする。

$$\varphi_{in} = \Delta\theta + \varphi_s(t) \quad (3.10)$$

入力位相  $\varphi_{in}$  と制御位相  $\varphi_c$  の差は以下のようになり、

$$\varphi_{in} - \varphi_c = \Delta\theta + \varphi_s(t) - \varphi_c \quad (3.11)$$

4 通倍方式であるのでこれを 4 倍する。

$$4(\varphi_{in} - \varphi_c) = 4(\Delta\theta + \varphi_s(t) - \varphi_c) \quad (3.12)$$

変調成分  $\varphi_s$  は 4 倍すると以下のようになくなってなくなる。

$$4\varphi_s(t) = \frac{n\pi}{2} \times 4 = 2n\pi = 0 \quad (n = 0, 1, 2, 3) \quad (3.13)$$

よって、式(3.12)は以下のようになる。

$$4(\varphi_{in} - \varphi_c) = 4(\Delta\theta - \varphi_c) \quad (3.14)$$

これを 4 で割ることで元の周波数領域に戻すことができる。

$$\varphi_{in} - \varphi_c = \Delta\theta - \varphi_c \quad (3.15)$$

ここで、 $K_{PD}$  は位相検出器の利得であり、位相検出器で検出された位相差は、位相雑音 $\Delta\theta$ のみが含まれており、以下のようなになる。

$$K_{PD}(\varphi_{in} - \varphi_c) = K_{PD}(\Delta\theta - \varphi_c) \quad (3.16)$$

検出された位相差はループフィルタに入力され、制御電圧  $V_C$  が出力される。

$$V_C = F(s) \cdot K_{PD}(\varphi_{in} - \varphi_c) \quad (3.17)$$

ここで、 $\varphi_{in}$  はループフィルタに入力された位相である。ループフィルタから出力された制御電圧  $V_C$  が VCO (電圧制御発振器) に入力され、それに応じた制御位相 $\varphi_c$  が生成される。VCO は、VCO の利得 $K_{VCO}$  と積分器により表される。VCO に入力された制御電圧 $V_C$  は以下のようなになり、

$$K_{VCO} = \frac{d\varphi_c}{dt} = \frac{\varphi_c(n) - \varphi_c(n-1)}{\Delta t} \quad (3.18)$$

出力される制御位相 $\varphi_c$  は、

$$\varphi_c = \varphi_c(n) - \varphi_c(n-1) = \Delta t \cdot K_{VCO} \cdot V_C \quad (3.19)$$

となり、得られた制御位相 $\varphi_c$  を入力位相にフィードバックすることで受信信号に含まれる、変調成分 $\varphi_s(t)$ 以外の位相成分を取り除くことができる。

### 3.5.1 位相の不確定性の補償

PLL の出力は、 $\pi/2$  の整数倍だけ位相が本来の位相から回転している可能性がある。従って、これを本来の位相に戻す必要がある。図 3-6 のように、本来の位相を  $\theta$ 、位相のずれを  $\varphi$  とすると、PLL で得られたデータの位相が  $\theta + \varphi$  となっている可能性がある。ここで、位相の不確定性  $\varphi$  は、 $\varphi = 0, \pi/2, \pi, 3\pi/2$  のいずれかとなる。

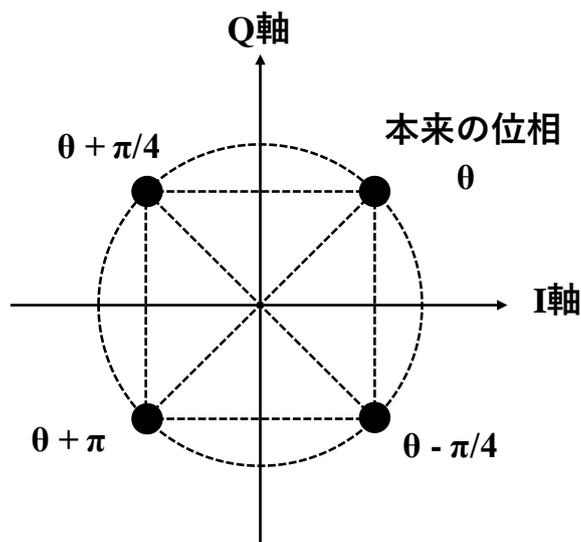


図 3-6 位相補償に関するコンスタレーション

位相のずれ  $\varphi$  は、送信信号の一部に組み込まれた既知の信号を利用して計算される。受信信号の既知信号部分に送信信号の既知信号部分の逆数を掛け合わせることで位相のずれ  $\varphi$  が得られる。この時、送信信号は  $e^{j\theta}$ 、受信信号は  $e^{j(\theta+\varphi)}$  と表され、これらを掛け合わせると、

$$e^{j(\theta+\varphi)} \times e^{-j\theta} = e^{j\varphi} \quad (3.20)$$

となり、位相のずれ  $\varphi$  を求めることができる。さらに、以下のように求めた位相のずれの逆数を受信信号に掛け合わせれば受信信号の位相を補償することができる。

$$e^{j(\theta+\varphi)} \times e^{-j\varphi} = e^{j\theta} \quad (3.21)$$

本論文では、この節で述べた計算は PLL ブロックに含むことに注意する。

## 第4章 ニューラルネットワーク

### 4.1 CvNN (Complex valued Neural Network)

図 4-1 に CvNN の構造を示す.

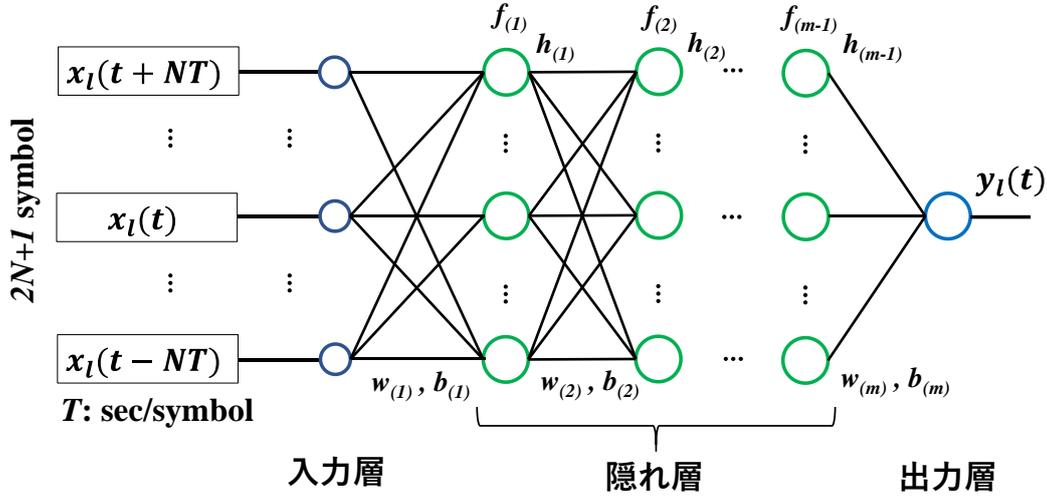


図 4-1 CvNN の構造

$l$  番目の入力  $\mathbf{x}_l$  は, 判定したいシンボルである  $x_l(t)$  を中心とした合計  $2N+1$  のシンボルによって構成され,  $\mathbf{x}_l = (x_l(t-NT), \dots, x_l(t), \dots, x_l(t+NT))$  と表される. この時, 判定したいシンボルだけでなくその両側の複数シンボルも入力しているのは, 非線形劣化によって複数シンボルに広がった干渉を NN に学習させるためである. そして, この入力  $\mathbf{x}_l$  は複素数として隠れ層に伝搬していく. 出力層では,  $x_l(t)$  に関する計算結果が複素数値として出力される.  $m-1$  層の隠れ層を持つ CvNN において, 出力層における  $l$  番目の出力を  $\mathbf{y}_l$ ,  $k$  層目の隠れ層の出力を  $\mathbf{h}_{(k)}$ , 活性化関数と重み行列, バイアスペクトルをそれぞれ  $f_{(k)}$ ,  $\mathbf{w}_{(k)}$ ,  $\mathbf{b}_{(k)}$  とおくと, 各層の出力は以下の式(4.1)-(4.3)によって表される.

$$\mathbf{h}_{(1)} = f_{(1)}(\mathbf{w}_{(1)}\mathbf{x}_l + \mathbf{b}_{(1)}) \quad (4.1)$$

$$\mathbf{h}_{(k)} = f_{(k)}(\mathbf{w}_{(k)}\mathbf{h}_{(k-1)} + \mathbf{b}_{(k)}) \quad (k = 2, \dots, m-1) \quad (4.2)$$

$$\mathbf{y}_l = \mathbf{w}_{(m)}\mathbf{h}_{(m-1)} + \mathbf{b}_{(m)} \quad (4.3)$$

ここで,  $\mathbf{w}$ ,  $\mathbf{h}$ ,  $\mathbf{b}$  は複素数なので, 活性化関数の計算は以下の式(4.4)のように実装した.  $\mathbf{z}$  は複素数の入力を表す.

$$f_{(k)}(\mathbf{z}) = f_{(k)}(\text{Re}(\mathbf{z})) + jf_{(k)}(\text{Im}(\mathbf{z})) \quad (4.4)$$

また, 誤差関数には, 以下の式(4.5)のように表される 2 乗平均誤差関数が用いられた. 入力  $\mathbf{x}_l$  に関する正解データを  $\mathbf{t}_l$ , 入力  $\mathbf{x}_l$  の総数を  $L$  とおいた.

$$E = \frac{1}{L} \sum_{l=1}^L |y_l - t_l|^2 \quad (4.5)$$

次に、この誤差関数は AMSGrad によって最適化が行われた。重みまたはバイアスを  $\theta$  とおくと、AMSGrad の更新式は以下の式(4.6)-(4.13)によって表される。ここで、 $m_{rt}$  と  $v_{rt}$ 、 $m_{it}$  と  $v_{it}$  はそれぞれ、実部と虚部における移動平均を表している。

$$m_{r0} = m_{i0} = v_{r0} = v_{i0} = \hat{v}_{r0} = \hat{v}_{i0} = 0 \quad (4.6)$$

$$m_{rt} = \beta_{r1} m_{r(t-1)} + (1 - \beta_{r1}) \frac{\partial E}{\partial \text{Re}(\theta_t)} \quad (4.7)$$

$$m_{it} = \beta_{i1} m_{i(t-1)} + (1 - \beta_{i1}) \frac{\partial E}{\partial \text{Im}(\theta_t)} \quad (4.8)$$

$$v_{rt} = \beta_{r2} v_{r(t-1)} + (1 - \beta_{r2}) \frac{\partial^2 E}{\partial \text{Re}(\theta_t)^2} \quad (4.9)$$

$$v_{it} = \beta_{i2} v_{i(t-1)} + (1 - \beta_{i2}) \frac{\partial^2 E}{\partial \text{Im}(\theta_t)^2} \quad (4.10)$$

$$\hat{v}_{rt} = \max(\hat{v}_{r(t-1)}, v_{rt}) \quad (4.11)$$

$$\hat{v}_{it} = \max(\hat{v}_{i(t-1)}, v_{it}) \quad (4.12)$$

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_{rt}} + \epsilon} m_{rt} - \frac{\eta}{\sqrt{\hat{v}_{it}} + \epsilon} m_{it} \quad (4.13)$$

## 4.2 RvNN (Real valued Neural Network)

RvNN は以下の図 4-2 のように表され、入力層において入力が実部と虚部に分けられて隠れ層に伝搬していく。

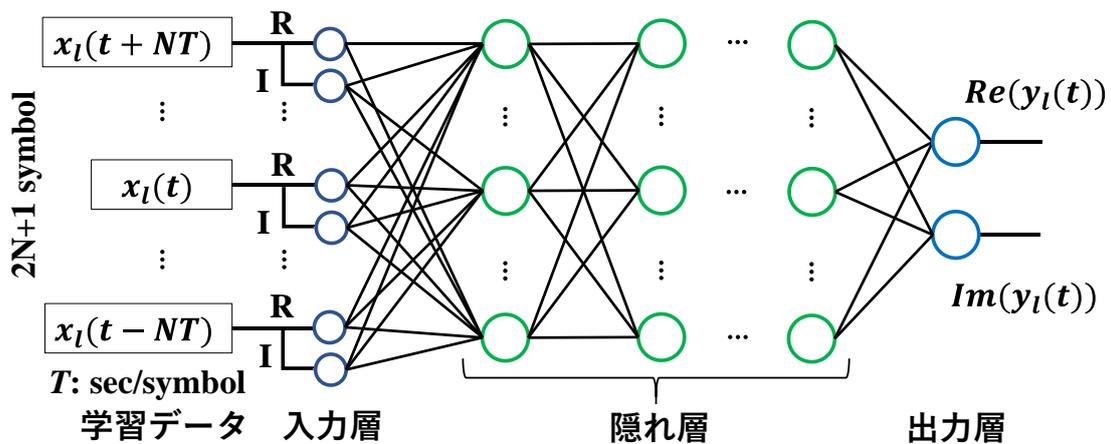


図 4-2 RvNN の構造

式に関しては、CvNN と基本的に同様で、虚部に関する部分が 0 になるだけである。

### 4.3 活性化関数

活性化関数はニューロンへの入力に対して出力をどのように発火させるかを定めるための関数である。活性化関数には様々な種類がある。本論文では、その中でも有効性が高いと考えられる活性化関数を用いた。本論文で用いた活性化関数は以下の式と図 4-3 によって表される。

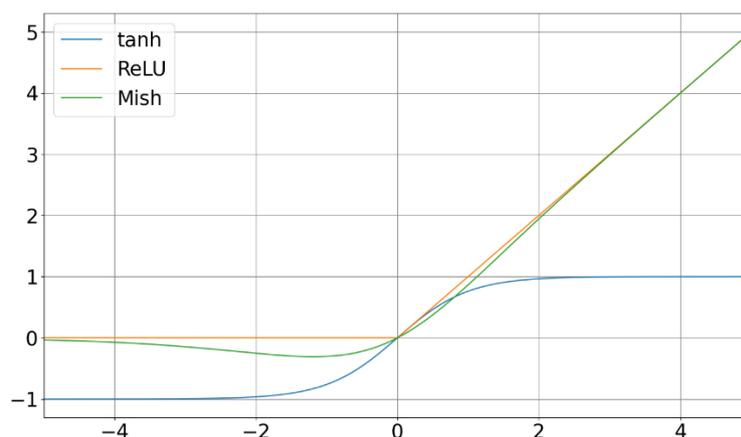
双曲線正接関数 ( $\tanh$ ) は下の式(4.14)と図 4-3(a)のように表される。シグモイド関数が抱える「勾配消失問題」を解決するために考案された活性化関数である。詳しくは勾配消失問題の項目で述べる。ReLU 関数は下の式(4.15)と図 4-3(a)のように表される。近年ではこの活性化関数が多い。双曲線正接関数と同様に、シグモイド関数が抱える「勾配消失問題」を解決するために考案された活性化関数である。式がシンプルで計算コストが低いこともメリットである。Swish 関数[11]は下の式(4.16)と図 4-3(b)のように表される。シグモイド関数がベースとなっており、 $\beta$ は定数である。ReLU 関数とは異なり、全範囲で微分可能である。ReLU 関数よりも良い性能となることが多い一方で、シグモイド関数が多い。Swish 関数よりもさらに良い活性化関数として提案された。

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (4.14)$$

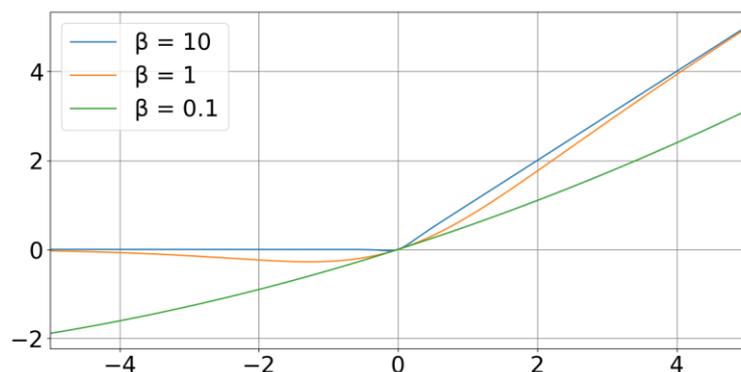
$$ReLU(x) = \begin{cases} x & (x > 0) \\ 0 & (x \leq 0) \end{cases} \quad (4.15)$$

$$Swish(x) = \frac{x}{1 + e^{-\beta x}} \quad (4.16)$$

$$Mish(x) = x \cdot \tanh(\ln(1 + e^x)) \quad (4.17)$$



(a) tanh, ReLU, Mish



(b) Swish

図 4-3 本論文で用いた活性化関数

## 4.4 学習に関して

### 4.4.1 データセットの分割

機械学習の目標は、未知のデータに対して正しい出力を得ることである。そのためには、学習の際にモデルの性能を正確に評価することが重要となる。従って、データセット全てを学習に用いるのではなく、それを学習用と評価用に分割する必要がある。本論文ではホールドアウト法を用いた。ホールドアウト法のデータセット分割方法を図4-4に示す。元のデータセットをトレーニングデータセットとテストデータセットに分割する。トレーニングデータセットはモデルの学習に用いられ、テストデータセットはモデルの性能評価に用いられる。

しかし、ホールドアウト法にはある問題がある。それは、データセットをどのように分割するかによってモデルの性能評価に差が出てしまう場合があることである。これは元のデータセットのデータ量が少ない場合に起こりやすい。ただ、本論文においてこれは当てはまらないので、ホールドアウト法を用いて良いと判断し、これを用いた。

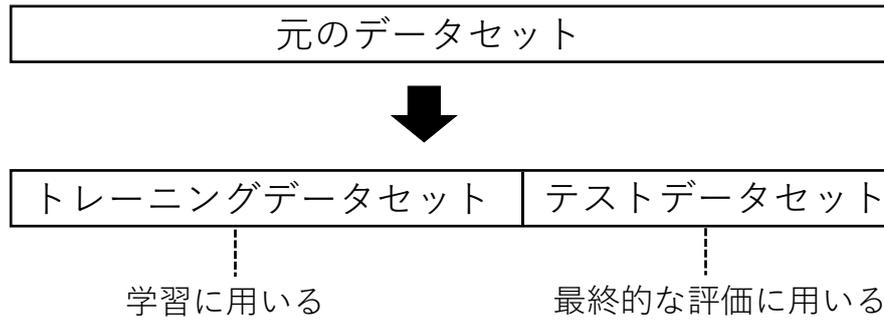


図 4-4 ホールドアウト法

#### 4.4.2 誤差逆伝播法

勾配降下法において学習を進めていくためには、誤差関数  $E(\mathbf{w}, \mathbf{b})$  の勾配  $\partial E(\mathbf{w}, \mathbf{b})/\partial \mathbf{w}$  と  $\partial E(\mathbf{w}, \mathbf{b})/\partial \mathbf{b}$  をそれぞれ求めていく必要があった。しかし、これまでのように入力層から出力層に向かって計算を行うと、多層のモデルにおいては計算コストが非常に大きくなってしまう。これを解決するために用いられる方法が誤差逆伝播法である。この方法では、勾配の計算を出力層から入力層に向かって行っていく。

下のような3層のニューラルネットワークを例として誤差逆伝播法について説明していく。

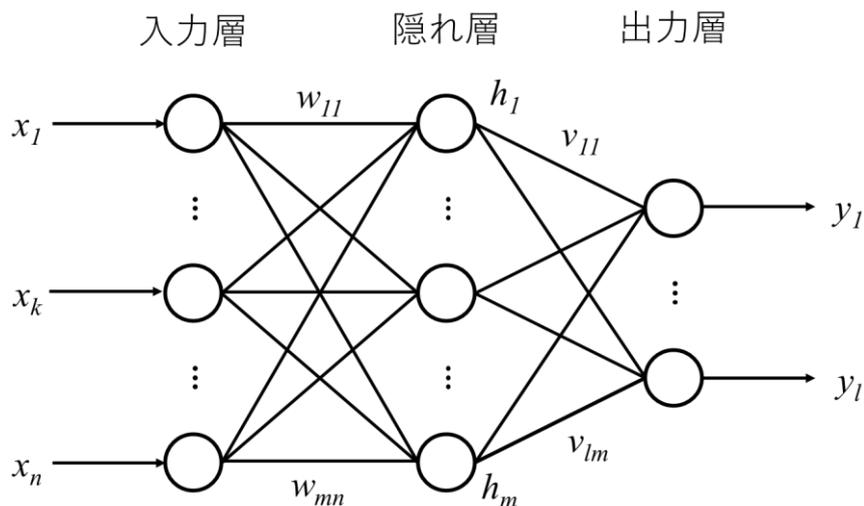


図 4-5 3層のニューラルネットワーク

まず、隠れ層の出力  $\mathbf{h}$  は、重み  $\mathbf{W}$ 、バイアス  $\mathbf{b}$ 、活性化関数を  $f(\cdot)$  において

$$\mathbf{h} = f(\mathbf{W}\mathbf{x} + \mathbf{b}) \quad (4.18)$$

と表される。従って、出力層の出力  $\mathbf{y}$  は、重み  $\mathbf{V}$ 、バイアス  $\mathbf{c}$  において

$$\mathbf{y} = \mathbf{V}\mathbf{h} + \mathbf{c} \quad (4.19)$$

と表される。以降、 $E$  以外におけるデータの順番を表すベクトルの添え字を省略する。各層の活性化前の値をそれぞれ

$$p = Wx + b \quad (4.20)$$

$$q = Vh + c \quad (4.21)$$

とおく. 次に, 誤差関数  $E$  の各パラメータに対する勾配を求めていく.

$$W = (\mathbf{w}_1 \mathbf{w}_2 \cdots \mathbf{w}_j)^T \quad (4.22)$$

$$V = (\mathbf{v}_1 \mathbf{v}_2 \cdots \mathbf{v}_k)^T \quad (4.23)$$

とすると勾配は,

$$\begin{cases} \frac{\partial E_n}{\partial \mathbf{w}_j} = \frac{\partial E_n}{\partial p_j} \frac{\partial p_j}{\partial \mathbf{w}_j} = \frac{\partial E_n}{\partial p_j} \mathbf{x} \\ \frac{\partial E_n}{\partial b_j} = \frac{\partial E_n}{\partial p_j} \frac{\partial p_j}{\partial b_j} = \frac{\partial E_n}{\partial p_j} \end{cases} \quad (4.24)$$

$$\begin{cases} \frac{\partial E_n}{\partial \mathbf{v}_k} = \frac{\partial E_n}{\partial q_k} \frac{\partial q_k}{\partial \mathbf{v}_k} = \frac{\partial E_n}{\partial q_k} \mathbf{h} \\ \frac{\partial E_n}{\partial c_k} = \frac{\partial E_n}{\partial q_k} \frac{\partial q_k}{\partial c_k} = \frac{\partial E_n}{\partial q_k} \end{cases} \quad (4.25)$$

となり,  $\partial E_n / \partial p_j$  と  $\partial E_n / \partial q_k$  を求めれば各パラメータの勾配が求まる.

ここで, 出力層における  $\partial E_n / \partial \mathbf{v}_k$  と  $\partial E_n / \partial c_k$  を計算する.  $E_n$  を

$$E_n = \frac{1}{2} (y_k - t_k)^2 \quad (4.26)$$

とおくと,

$$\begin{aligned} \frac{\partial E_n}{\partial \mathbf{v}_k} &= \frac{1}{2} \frac{\partial}{\partial y_k} (y_k - t_k)^2 \frac{\partial y_k}{\partial \mathbf{v}_k} \\ &= (y_k - t_k) \mathbf{h} \end{aligned} \quad (4.27)$$

同様に,

$$\frac{\partial E_n}{\partial c_k} = y_k - t_k \quad (4.28)$$

となる. 従って, 式(4.25)と式(4.27), (4.28)を比較すると,

$$\frac{\partial E_n}{\partial q_k} = y_k - t_k \quad (4.29)$$

となり,  $\partial E_n / \partial p_j$  を求めればよいことがわかる. これは偏微分の連鎖律より,

$$\begin{aligned} \frac{\partial E_n}{\partial p_j} &= \sum_{k=1}^K \frac{\partial E_n}{\partial q_k} \frac{\partial q_k}{\partial p_j} \\ &= \sum_{k=1}^K \frac{\partial E_n}{\partial q_k} (f'(p_j) v_{kj}) \end{aligned} \quad (4.30)$$

とすることができ, これによって全ての勾配を計算することができる.

ここで,

$$\delta_j = \frac{\partial E_n}{\partial p_j} \quad (4.31)$$

$$\delta_k = \frac{\partial E_n}{\partial q_k} \quad (4.32)$$

とおく.  $\delta_j$ と $\delta_k$ は誤差項と呼ばれる. これを用いると式(4.30)は,

$$\delta_j = f'(p_j) \sum_{k=1}^K v_{kj} \delta_k \quad (4.33)$$

となる. 誤差逆伝播法では以上のようにして勾配を計算していく.

#### 4.4.3 勾配消失問題

誤差逆伝播法を用いた学習の妨げとなる問題として, 勾配消失問題が挙げられる. ここでは勾配消失問題について述べていく.

下のように隠れ層が2層あるニューラルネットワークにおいて考えていく.

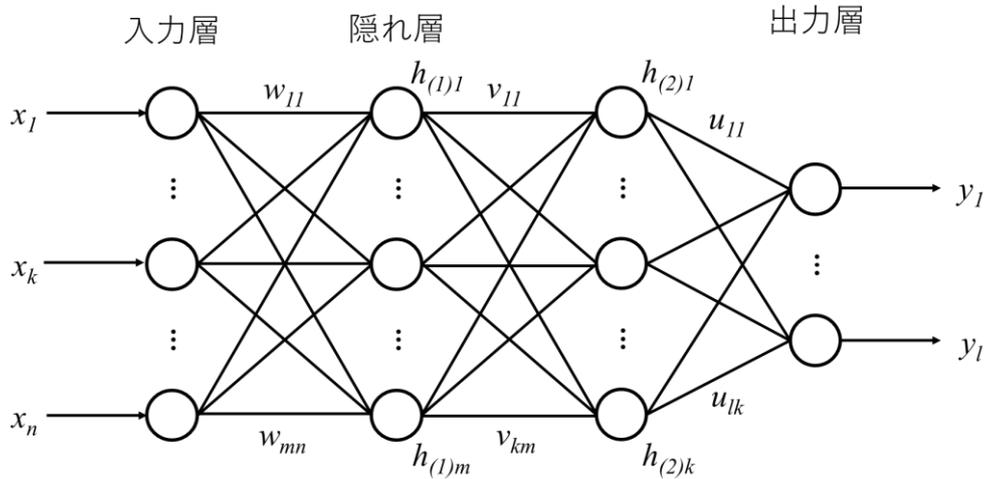


図 4-6 隠れ層が2層あるニューラルネットワーク

ニューラルネットワークへの入力を $\mathbf{x}$ , 隠れ層の出力をそれぞれ $\mathbf{h}_{(1)}, \mathbf{h}_{(2)}$ , 出力層の出力を $\mathbf{y}$ とする. 各層間の重み行列とバイアスベクトルをそれぞれ $W, V, U$ と $\mathbf{b}, \mathbf{c}, \mathbf{d}$ とする. 活性化関数は $f(\cdot)$ とする. この時, 各層の出力は, 二乗平均誤差関数を用いるならば,

$$\mathbf{h}_{(1)} = f(W\mathbf{x} + \mathbf{b}) \quad (4.34)$$

$$\mathbf{h}_{(2)} = f(V\mathbf{h}_{(1)} + \mathbf{c}) \quad (4.35)$$

$$\mathbf{y} = U\mathbf{h}_{(2)} + \mathbf{d} \quad (4.36)$$

となる. ここで,

$$\mathbf{p} = W\mathbf{x} + \mathbf{b} \quad (4.37)$$

$$\mathbf{q} = V\mathbf{h}_{(1)} + \mathbf{c} \quad (4.38)$$

$$\mathbf{r} = U\mathbf{h}_{(2)} + \mathbf{d} \quad (4.39)$$

とおくと, 重み $W = (\mathbf{w}_1 \ \mathbf{w}_2 \ \dots \ \mathbf{w}_j)^T$ に対する勾配は,

$$\begin{aligned}\frac{\partial E_n}{\partial \mathbf{w}_j} &= \frac{\partial E_n}{\partial p_j} \frac{\partial p_j}{\partial \mathbf{w}_j} \\ &= \frac{\partial E_n}{\partial p_j} \mathbf{x}\end{aligned}\tag{4.40}$$

となり, 次は  $\partial E_n / \partial p_j$  を求める.

$$\begin{aligned}\frac{\partial E_n}{\partial p_j} &= \sum_{k=1}^K \frac{\partial E_n}{\partial q_k} \frac{\partial q_k}{\partial p_j} \\ &= \sum_{k=1}^K \frac{\partial E_n}{\partial q_k} (f'(p_j) v_{kj})\end{aligned}\tag{4.41}$$

となる. さらに  $\partial E_n / \partial q_k$  も求めていくと,

$$\begin{aligned}\frac{\partial E_n}{\partial q_k} &= \sum_{l=1}^L \frac{\partial E_n}{\partial r_l} \frac{\partial r_l}{\partial q_k} \\ &= \sum_{l=1}^L \frac{\partial E_n}{\partial r_l} (f'(q_k) u_{lk})\end{aligned}\tag{4.42}$$

となり,  $\partial E_n / \partial r_l$  は出力層部分なので,

$$\frac{\partial E_n}{\partial r_l} = y_l - t_l\tag{4.43}$$

となる. 誤差項を

$$\delta_j = \frac{\partial E_n}{\partial p_j}\tag{4.44}$$

$$\delta_k = \frac{\partial E_n}{\partial q_k}\tag{4.45}$$

$$\delta_l = \frac{\partial E_n}{\partial r_l}\tag{4.46}$$

とおくと, 式(4.41)は,

$$\begin{aligned}\delta_j &= \sum_{k=1}^K f'(p_j) v_{kj} \delta_k \\ &= \sum_{l=1}^L \sum_{k=1}^K (f'(q_k) f'(p_j)) (u_{lk} v_{kj}) \delta_l\end{aligned}\tag{4.47}$$

となる. 以上により, 隠れ層が 2 層あるニューラルネットワークにおける誤差逆伝播法の式が求まった. ここで,  $f'(q_k) f'(p_j)$  の部分に注目する. この項は活性化関数の微分の積で構成されている. 従って, 傾きが小さな活性化関数が用いられればこの項は小さな値となる. 隠れ層がさらに増えていくと, 限りなく 0 に近づいていく. こうなってしまうと, 誤差逆伝播法は上手く働かなくなり, ネットワークの学習が進まなくなってしまう. これを勾配消失問題と呼ぶ. これを解決す

るためには、傾きが適度に大きな活性化関数を用いればよい。これらの活性化関数については上で述べた。

## 第5章 シミュレーション・結果

### 5.1 光コヒーレント伝送システムモデル

提案法を用いた光コヒーレント伝送システムのシミュレーション構成を図 5-1 に示す。送信機では、ランダムパターンで構成される 32Gbaud 16QAM (128Gbps) 信号がルートレイズドコサイン (RRC) フィルタによって整形されて送信された。ロールオフ係数は 1.0, オーバーサンプリングは 16 とした。50km のシングルモードファイバを M 回繰り返し伝送されることにより、伝送距離を  $50 \times M$  km とした。ここでは、 $M=80$  とした。光ファイバのパラメータは、損失  $\alpha = 0.2 \text{ dB/km}$ , 分散係数  $D = 1 \text{ ps}/(\text{km} \cdot \text{nm})$ , 非線形係数  $\gamma = 1.4 \text{ W}^{-1}/\text{km}$ , およびレーザー線幅  $\nu = 100 \text{ kHz}$  とした。光ファイバ伝送は、偏波多重がない場合において、1 スパン (50km) あたり 15 分割 (以下では steps / span という単位で表現する), すなわち  $h = 10/3 \text{ km}$  としてスプリットステップフーリエ法[4]を適用してシミュレーションを行った。また、 $\beta_2 = -\lambda^2 D / 2\pi c$  ( $\lambda$ : 波長[nm],  $c$ : 光速[km/s]) として式(3.5)に適用した。その後受信された信号は、送信側と同じロールオフ係数の RRC フィルタを通過し、1 シンボルあたり 2 サンプルにダウンサンプリングされた。次に、波長分散補償が行われ、NN に入力された。NN と PLL はそれぞれ非線形劣化, 位相ドリフトを補償した。非線形劣化補償に用いられる NN には、実ニューラルネットワーク (RvNN) または複素ニューラルネットワーク (CvNN) を用いた。

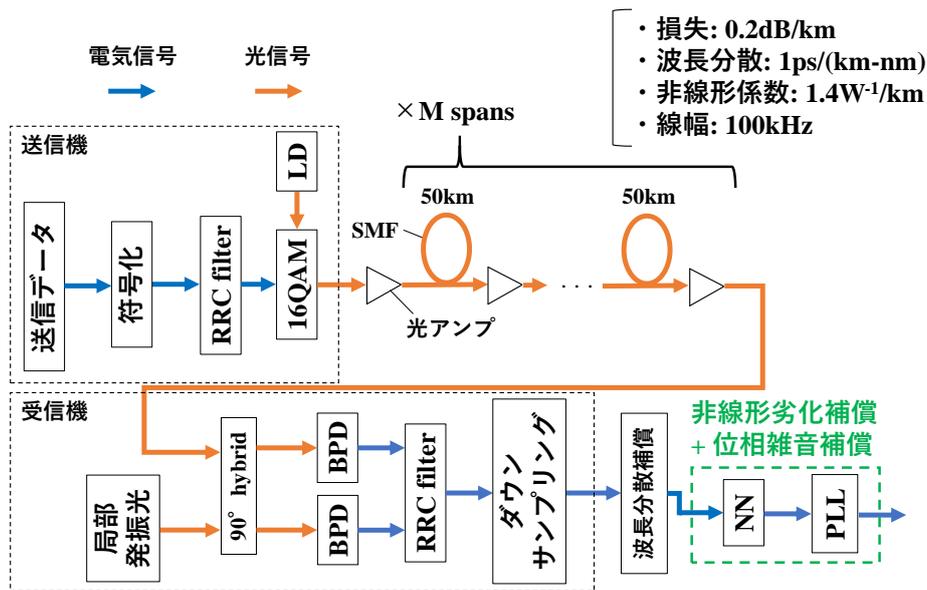


図 5-1 光コヒーレント伝送システム (RRC: Root Raised Cosine, SMF: Single Mode Fiber, BPD: Balance Phot Diode)

#### 5.1.1 学習データの準備

学習は、それぞれが 100,000 シンボル (400,000 ビット) のランダムパターンで構成された 1000 セットの学習データを用いて、図 2-4 の構成によって行われた。学習を行った NN の性能評価は、学習に用いられていないランダムパターンで構成された 100,000 シンボルのテストデータを用いて、図 5-1 の構成によって行われた。

## 5.2 結果

まず、光ファイバの非線形劣化補償に最適な活性化関数を探した。入力光強度-1dBm、光源の線幅 100kHz, 80 スパンにおいて, tanh と ReLU, Swish ( $\beta = 2$ ), および Mish のそれぞれの活性化関数を用いた場合のビット誤り率 (BER)を比較した。RvNN と CvNN におけるこれらの結果を図 5-2 示す。Swish と Mish を用いた場合の BER が低いことがわかった。さらに、活性化関数の計算量が Swishの方が Mish よりも少ないので Swish を採用した。

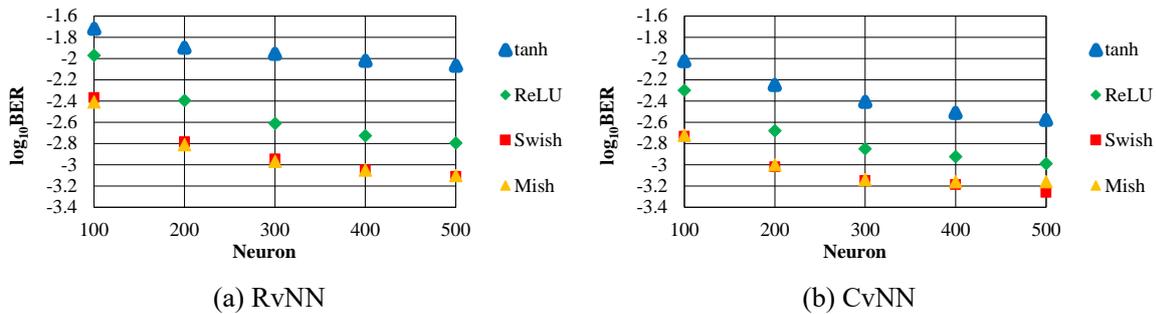


図 5-2 活性化関数の性能比較

次に、提案法の有効性を示すために、提案法を用いて学習を行った場合と、送信信号をそのまま正解データとして学習を行った場合の補償性能の比較を行った。図 5-3 は、100,000 シンボルの学習データセットを用いて、1kHz, 10kHz, および 100kHz の線幅における CvNN のトレーニングの進行状況を示している。線幅を 100kHz までとしたのは、通常用いられるレーザーの線幅が 100kHz だからである。送信信号をそのまま正解データとした場合は、線幅が大きくなっていくにつれて学習精度が低下した。一方、提案法を用いた場合は、線幅が大きくなって学習精度が高いまだだった。この結果から、提案法の、レーザー線幅による位相雑音への有効性が示された。2 章で述べたように、従来法には位相雑音存在下で学習を行うための機構が組み込まれていない。一方、提案法には、位相雑音存在下で学習を行うための機構と、NN の出力に残った位相雑音を補償するための PLL が組み込まれている。

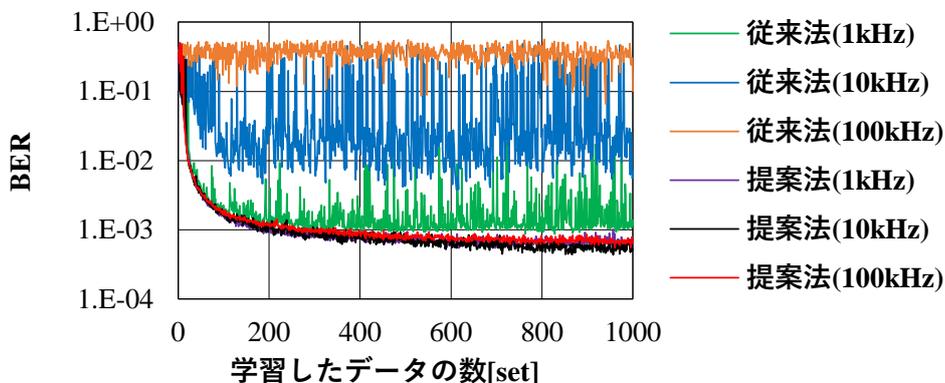


図 5-3 線幅による学習進捗の変化

次に、初期位相のずれがあっても学習できることを示すために、初期位相のずれがない場合と

ある場合において学習の進捗の比較を行った。この時、初期位相ありの場合は、ランダムな初期位相を加えた。結果は下の図 5-4 のようになり、初期位相のずれの有無に関わらず学習を進められることが示された。

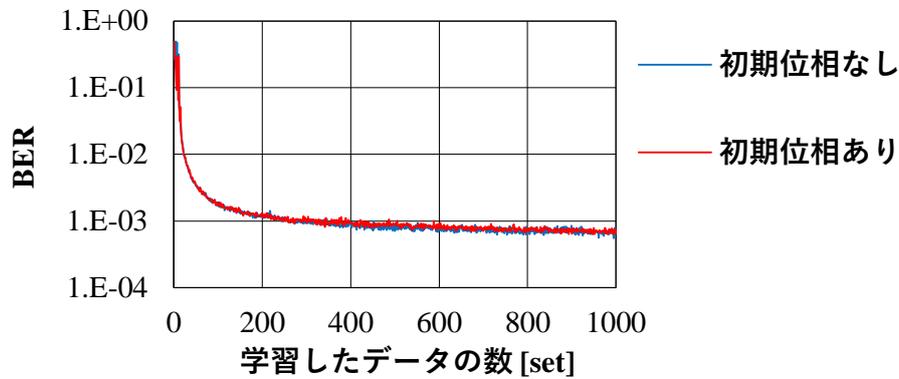


図 5-4 初期位相がない場合とある場合の学習の進捗の比較

次に、学習した非線形劣化補償 NN が本当にランダムな初期位相存在下において非線形劣化補償を行えるかどうかを調べるために、任意の初期位相のずれを受信信号に与えて NN を用いた時の非線形劣化補償性能を調べた。結果は下の図 5-5 のようになり、初期位相に依存せず非線形劣化を補償できることが示された。

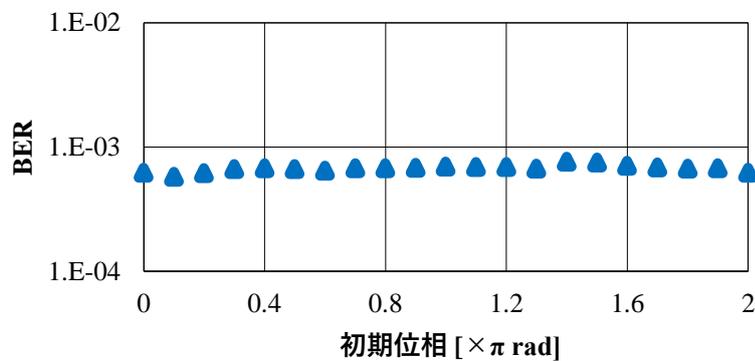
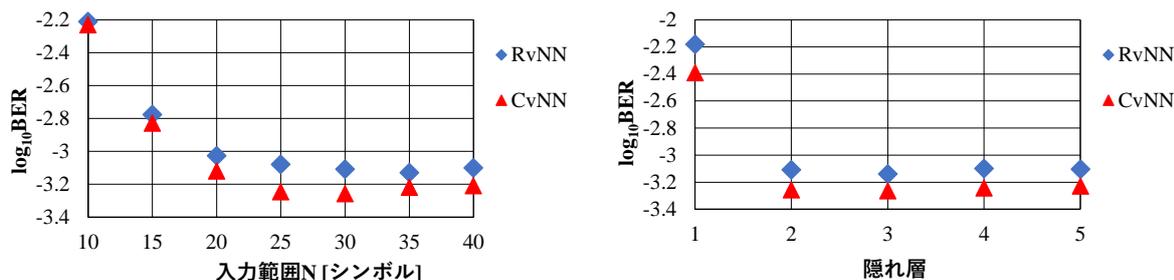


図 5-5 非線形劣化補償性能の初期位相依存性

次に、提案法によって学習を行った非線形劣化補償 NN の補償性能が優れていることを示すために、伝送距離 80 スパンで、BER の入力光強度依存性において DBP との比較を行った。ただし、RvNN と CvNN のそれぞれのハイパーパラメータ（入力範囲、隠れ層数、ニューロン数）は、入力光強度毎に最適化が行われた。例えば、入力光強度-1dBm においては、入力範囲と隠れ層数、隠れ層 1 層当たりのニューロン数が下の図 5-6 のように最適化された。

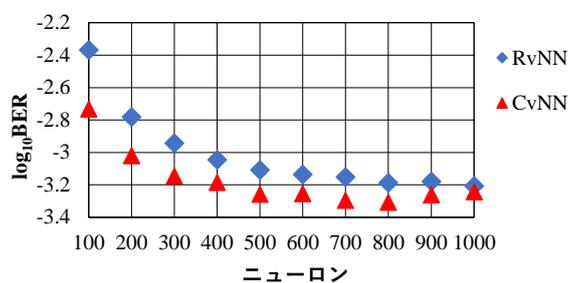


(a) 入力範囲 N の最適化

(b) 隠れ層数の最適化

隠れ層数: 2  
ニューロン数: 500

入力範囲 N: 30  
ニューロン数: 500



(c) ニューロン数の最適化

入力範囲 N: 30  
隠れ層数: 2

図 5-6 -1dBm におけるハイパーパラメータの最適化

この結果から, -1dBm でのハイパーパラメータは表 1 のように設定された.

表 1 RvNN と CvNN の最適なハイパーパラメータ

	Input symbol	Hidden layer	Neuron
RvNN	61 (N = 30)	2	800
CvNN	61 (N = 30)	2	800

結果は図 5-7 のようになり, BER において, RvNN と CvNN の両方が DBP (4steps / span) よりも優れていることがわかった. また, CvNN の方が RvNN よりもわずかに BER が低く, DBP (4steps / span) と比較して 0.3 倍の BER となった. 入力光強度が一定以下である時に BER が悪化しているのは, 信号に対して光アンプで加わる雑音 (ASE (amplified spontaneous emission) 雑音) が大きくなる (信号対雑音比が悪化する) からである. 入力光強度が一定以上である時に BER が悪化しているのは, 入力光強度の増大によって非線形劣化が大きくなり, 補償しきれなくなるからである. NN の非線形劣化補償性能は DBP よりも優れているため, 最適な入力光強度が DBP よりも大きく

なっている. ASE 雑音と非線形劣化のバランスが最適な入力光強度において BER が最小となる.

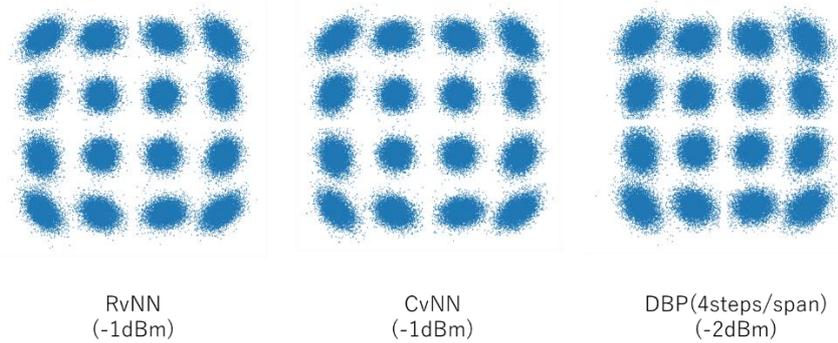
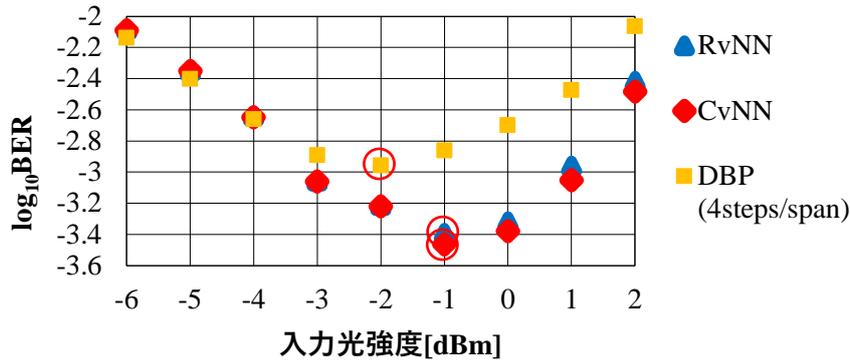


図 5-7 RvNN と CvNN, DBP における BER の入力光強度依存性

次に, 計算時間が DBP と比べて改善されていることを示すために, RvNN, CvNN, および DBP (4steps / span) における計算時間の伝送距離依存性を調べた. 計算は, Intel (R) Core (TM) i9-9900KF CPU @ 3.60GHz 3.60, NVIDIA GeForce RTX 2080 SUPER を使用して行われた. また, DBP (4steps / span) の計算時間によって正規化を行った. 結果は図 5-8 のようになり, RvNN と CvNN の両方において, DBP (4steps / span) よりも計算時間が大幅に改善されており, RvNN の計算時間が最も短いことがわかった. RvNN の計算時間は, DBP (4steps / span) と比較して  $8 \times 10^{-3}$  倍に改善された. RvNN の計算時間が CvNN よりも短いのは, CvNN では複素数の行列計算が行われているのに対して, RvNN では実数の行列計算が行われているからである.

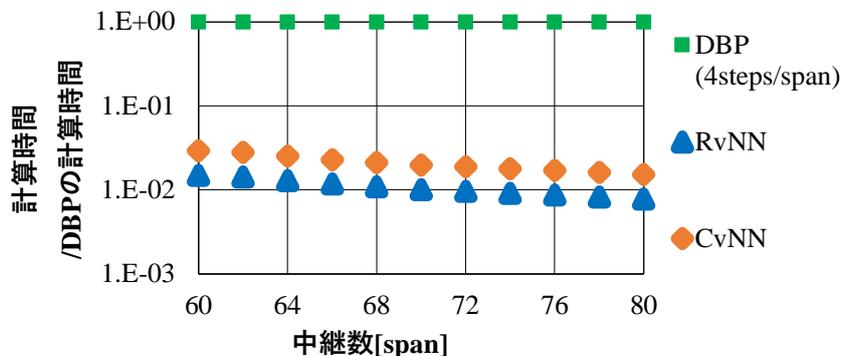


図 5-8 RvNN と CvNN, DBP における計算時間の伝送距離依存性

以上の結果より、BER と計算時間の両方を考えると、非線形補償 NN には RvNN を用いるべきである。従って、以下の結果では RvNN のみを用いた。

次に、中継距離は 50km のままで合計の伝送距離を変えた場合の BER の入力光強度依存性を調べた。結果は下の図 5-9 のようになり、伝送距離が長いほど BER は大きくなり、最適な入力光強度が小さくなることがわかった。これは、伝送距離の変化によって ASE 雑音と非線形劣化のバランスが変わったからだと考えられる。

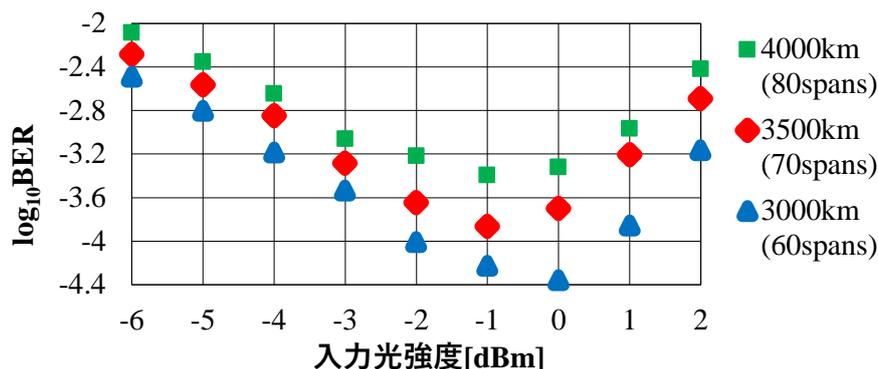


図 5-9 伝送距離別の BER の入力光強度依存性

次に、合計の伝送距離は 4000km のままで中継距離を変えた場合の BER の入力光強度依存性を調べた。結果は下の図 5-10 のようになり、中継距離が短いと、BER は低くなり、最適な入力光強度が小さくなることがわかった。これは、中継距離が短く、すなわちアンプ間の距離が短くなったことによって信号対雑音比が良くなったからだと考えられる。

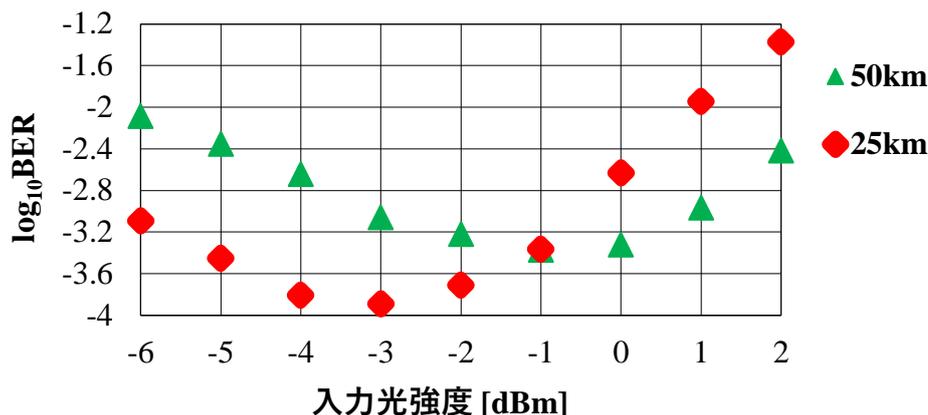
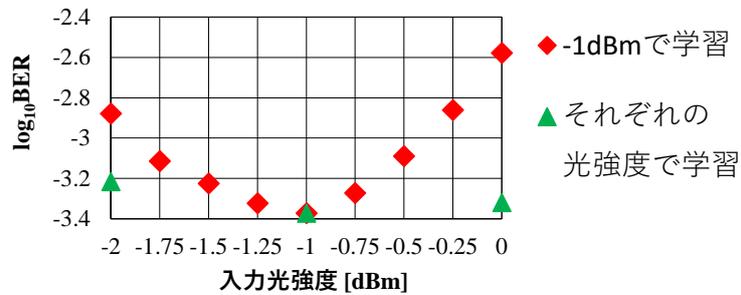


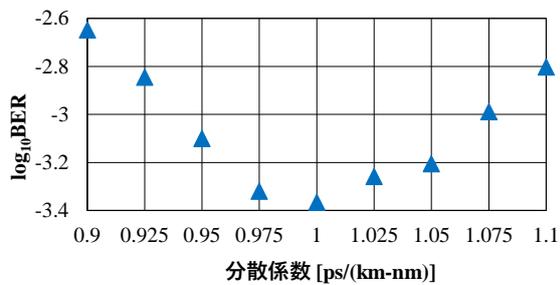
図 5-10 中継距離別の BER の入力光強度依存性

次に、学習を行った非線形劣化補償 NN が伝送路パラメータの変動に対してどれほどのトレランスを持つのかを調べた。この時、入力光強度-1dBm、分散係数 1ps/(km-nm)、光アンプの雑音指数 4.5dB において学習を行った RvNN を用いて、入力光強度と分散係数と光アンプの雑音指数に

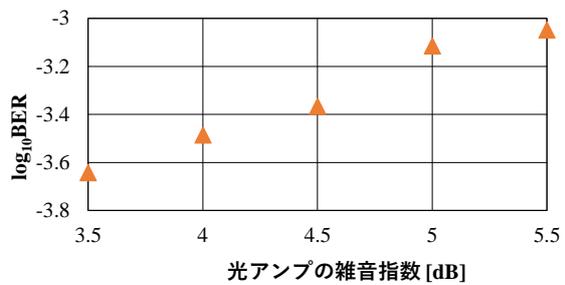
対するトレランスを調べた。それぞれに対する結果は下の図 5-11 のようになった。入力光強度と分散係数の変動によって BER が悪化していることから、入力光強度と分散係数の変動に合わせて NN の学習を行っていく必要があることがわかった。光アンプの雑音指数の変動に関しては、大きな悪化はしておらず、雑音の増減による自然な BER の変化であると考えられるため、学習を行う必要はないと考えられる。



(a) 入力光強度に対するトレランス



(b) 分散係数に対するトレランス



(c) 光アンプの雑音指数に対するトレランス

図 5-11 伝送路パラメータの変動に対するトレランス

## 第6章 まとめ

本論文では、非線形劣化補償 NN の新たな学習方法を提案した。この学習方法は、受信信号を送信信号で逆変調し、これに LPF を用いた後に再び送信信号を掛け合わせることによって、受信信号から非線形劣化を取り除いた信号を生成し、これを正解データとした。これによって、光源の線幅による位相雑音が存在する条件下における非線形劣化の学習を可能にした。この学習方法は、非線形劣化補償 NN と PLL からなる補償構成における NN に用いられた。提案法により、従来法が抱えていた、光源の線幅による位相雑音が存在する状況下で非線形劣化を学習・補償できないという問題を解決することができた。さらに、提案した学習方法は逆変調法と LPF を用いているため、非線形劣化が大きな伝送路においても正確に位相推定を行えるという大きなメリットも併せ持っている。これによって、長距離光コヒーレント伝送における非線形劣化の学習・補償を可能とした。伝送距離 4000km の 32Gbaud 16QAM 伝送では、提案法を用いた非線形劣化補償 NN は DBP (4steps / span) と比較して、BER が 0.3 倍、計算時間が  $8 \times 10^{-3}$  倍になり改善された。

提案法によって学習した非線形劣化補償 NN は BER と計算時間の両方において優れた性能を持ち、光ファイバ非線形劣化補償の新たな方法として有効であることがわかった。

## 謝辞

本研究を進めるにあたり、多大な助言、丁寧な指導を賜った岩下克教授、小林弘和准教授に厚く感謝を申し上げます。

同期の小野一成氏、河邊智弘氏、横川恒助氏、さらに研究室の皆様には感謝いたします。

## 参考文献

- [1] Cisco Visual Networking Index: Forecast and Trends, 2017–2022
- [2] E. Ip, “Nonlinear Compensation Using Backpropagation for Polarization-Multiplexed Transmission,” *J. Lightw. Technol.* 28(6), pp.939-951, 2010.
- [3] F. P. Guiomar, J. D. Reis, A. L. Teixeira, and A. N. Pinto, “Mitigation of intra-channel nonlinearities using a frequency-domain Volterra series equalizer,” *Opt. Exp.* 20(2), pp.1360-1369, 2012.
- [4] G. Agrawal, *Nonlinear Fiber Optics*, 6th ed., Academic, 2019.
- [5] Y. Fukumoto, S. Owaki, T. Sakamoto, N. Yamamoto, and M. Nakamura, “Experimental Demonstration of SPM Compensation Based on Digital Signal Processing Using a Complex-Valued Neural Network for 40-Gbit/s Optical 16QAM Signals,” in *23rd Opto-Electronics and Communications Conference (OECC)*, 2018.
- [6] O. Sidelnikov, A. Redyuk, and S. Sygletos, “Equalization performance and complexity analysis of dynamic deep neural networks in long haul transmission systems,” *Opt. Exp.* 26(25), pp.32765–32776, 2018.
- [7] G. S. Yadav, T. Tsuritani, S. Beppu, H. Takahash, I. Morita, K. M. Feng, and J. H. Yan, “Dynamic complex deep Neural Network Nonlinear Equalizer for 64 QAM Long-haul Transmission Systems,” in *24th Opto-Electronics and Communications Conference (OECC)*, MB1-2, 2019.
- [8] B. I. Bitachon, A. Ghazisaeidi, M. Eppenberger, B. Baeurle, M. Ayata, and J. Leuthold, “Deep learning based digital backpropagation demonstrating SNR gain at low complexity in a 1200 km transmission link,” *Opt. Exp.* 28(20), pp.29318–29334, 2020.
- [9] 上山峻央, 森文香, 小林弘和, 岩下克, “QPSK 光コヒーレント伝送における深層学習による非線形劣化補償,” 2020年電子情報通信学会総合大会, B-10-37, 2020.
- [10] 上山峻央, 森文香, 小林弘和, 岩下克, “16QAM光コヒーレント伝送における深層学習による非線形劣化補償,” 令和2年度電気・電子・情報関係学会四国支部連合大会, 12-17, 2020.
- [11] P. Ramachandran, B. Zoph, and Q. V. Le, “Searching for Activation Functions,” arXiv:1710.05941 [cs], 2017.
- [12] D. Misra, “Searching for Activation Functions,” arXiv: 1908.08681 [cs], 2018.