

# 機械学習を活用した通信用光増幅器設計

小野 浩孝\*

## Design of optical amplifier for telecommunications utilizing machine learning

Hiroataka ONO

### Abstract:

Neural network (NN)-based inverse design is applied to erbium-doped fiber amplifiers (EDFAs), which are used as optical repeaters in optical fiber transmission systems, and show that EDFA parameters can be derived from target characteristics, demonstrating the effectiveness of inverse design for EDFAs. It is shown that the EDFA parameters can be derived from the target characteristics, demonstrating the effectiveness of inverse design for EDFAs.

**Keywords:** Inverse design, neural network, optical communication, erbium-doped fiber amplifier

### 要旨:

複雑化した光ファイバ通信システムを構成する光部品・装置の設計に 機械学習を活用した研究が進められている。本報告では、光ファイバ伝送システムでは光中継器として使用されるエルビウム添加ファイバ増幅器 (EDFA) にニューラルネットワーク (NN) を用いた逆設計を適用し、目標特性からEDFAパラメータを導出することができることを示し、EDFAに対する逆設計の有効性を示す。

**キーワード:** 逆設計, ニューラルネットワーク, 光通信, エルビウム添加ファイバ増幅器

## 1. はじめに

光ファイバ通信分野では、デジタル信号処理を利用したデジタルコヒーレント受信や非線形補償の導入、再構築可能な光分岐挿入装置 (ROADM) による光ネットワーク内における信号経路の再設定、エルビウム添加ファイバ増幅器 (EDFA) とファイバラマン増幅器 (FRA) を併用した光中継、マルチコアファイバやフューモード空間分割多重 (SDM) などの新しい技術により、システムの複雑さが増加している。複雑化した光ファイバ通信システムを構成する光部品・装置を最適に設計したり、システムを最適な状態で運用したりするために、機械学習を活用した研究が進められている[1]–[6]。その中でもニューラルネットワーク (NN) を用いた逆設計は、FRAにおける任意の利得スペクトルを実現する励起光波長および励起光パワーや、10モード偏波保持フューモードファイバを実現するファイバパラメータの導出

に応用され 良好な結果が得られており 光ファイバ通信システムや通信用光デバイスの設計に逆設計が有効であることが示されてきている[5],[6]。

光ファイバ伝送システムでは光中継器としてEDFAを使用する。EDFAはファイバのコアにエルビウムイオンを添加したエルビウム添加ファイバ(EDF)を増幅媒体とする。従来のEDFAはシングルコア・シングルモードEDFを用いており、確立したEDFAの動作モデルがあって、その設計はシミュレーションにより比較的容易に行える。しかし、従来システムの伝送容量限界を打破するSDM光ファイバ伝送で用いられるマルチコアEDFA(MC-EDFA)やフューモードEDFA(FM-EDFA)は、複数のコアを有していたり複数のモードを有していたりするために、従来EDFAに比べて設計の複雑さが増している。

そこで本報告では、将来的にMC-EDFAおよびFM-EDFAへ機械学習を活用した逆設計を適用する前段階として、従来EDFAに対するNNを用いた逆設計の適用性を調べた結果を示す。

\*湘南工科大学 工学部 電気電子工学科 教授

## 2. エルビウム添加ファイバ増幅器と逆設計の機械学習モデル

### 2.1 EDFA の概要

図1にEDFAの概要図を示す。EDFAに入力した信号光は励起用半導体レーザ (LD) から出力される励起光と合波器(不図示)によって合波されて エルビウム添加ファイバ (EDF) へ入力する。EDFでは、励起光により励起状態となったエルビウムイオンの誘導放出により信号光は増幅される。このとき、誘導放出と一緒に自然放光も発生し、信号光と同方向および逆方向に伝搬して増幅され、自然放光増幅 (ASE) 光となる。EDFAの出力端からは増幅された信号光に加え、信号光と同方向に伝搬したASE光も出力され、ASE光は雑音光となる。EDFAの信号光増幅動作は エルビウムイオンの励起準位、増幅始準位、増幅終準位に関するレート方程式と、信号光、励起光、ファイバの両方向に伝搬するASE光の各伝搬方程式との 連立微分方程式で記述される [7]。

EDFAの設計パラメータは、図2に示すEDFのパラ

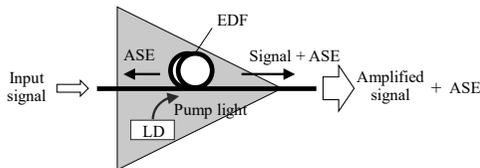


図 1 EDFA の概要図

メータである、コア半径  $a$  , コアとクラッドの比屈折率差  $\Delta n$  , エルビウムイオン添加濃度  $\rho$  と、EDFの長さ、励起光パワー が主なものである。

図3に典型的なEDFAの利得スペクトルを示す。同図は、信号光は1530.33 – 1561.41 nm (195.9–192.0 THz) に100 GHz間隔で配置された 40チャンネルの波長分割多重 (WDM) 信号の各チャンネル利得を示している。利得スペクトルは波長依存性があるため、

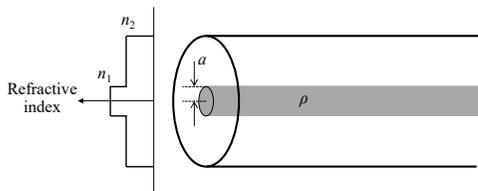


図 2 EDF のパラメータ

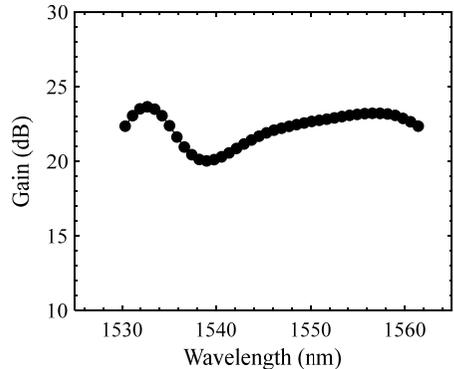


図 3 EDFA の利得スペクトルの典型例

適用する光伝送システムから要請される利得値を超える最小利得を確保しつつ、チャンネル間利得差を相殺する光フィルタの適用後に最大の利得帯域を得られるように、EDFA増幅では最長波長チャンネルの利得と最短波長チャンネルとの差 (利得チルト) をなくすようにEDFAを動作させる。このようなEDFA動作におけるEDFA特性の指標は利得スペクトルの形状そのものであり、個々の40チャンネル利得値が設計の目標となりうる。他には、最小利得と利得チルトのセットも特性指標になりうる。

### 2.2 逆設計の機械学習モデル

図4 (a) にEDFAの連立微分方程式による設計の概念図、(b) にEDFA逆設計のNNモデルを示す。図4 (a) に示すように、通常の連立微分方程式の数値計算による設計では EDFAパラメータ  $\mathbf{X} = \{x_1, x_2, \dots, x_M\}^T$  ( $T$  は転置を示す) に対して  $\mathbf{Y} = f(\mathbf{X})$  によりEDFAの特性特性  $\mathbf{Y} = \{y_1, y_2, \dots, y_N\}^T$  を演算する。関数  $f$  は前述のとおり 連立微分方程式となる。 $\mathbf{Y} = f(\mathbf{X})$  において、エルビウム添加ファイバ (EDF) の入力端は、入力信号光パワーや信号光と同方向に伝搬する励起光パワーとASE光パワー、出力端は、信号光と反対方向に伝搬する励起光パワーとASE光パワーの初期値を持つため、EDF入力端及び出力端が境界値条件を与える。すなわち、 $\mathbf{Y} = f(\mathbf{X})$ によりEDFAの動作シミュレーションを行うことは、連立微分方程式の2点境界値問題を解く計算となり、シミュレーションにおいてはファイバの光伝搬の繰り返し計算を一定の条件下で収束させることになる。そして試行錯誤的に目標特性  $\mathbf{Y}^{ts} = \{y_1^{ts}, y_2^{ts}, \dots, y_N^{ts}\}^T$  に対する目標パラメータ  $\mathbf{X}^{ts} = \{x_1^{ts}, x_2^{ts}, \dots, x_M^{ts}\}^T$  を得る。一方、図4 (b) に示す逆設計では、EDFAの目標とする

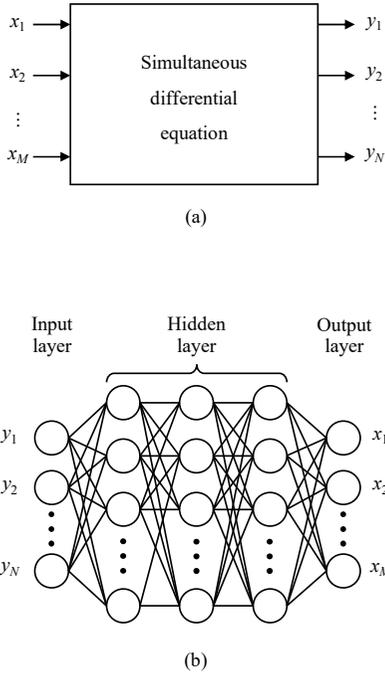


図 4 (a)連立微分方程式による設計の概念図, (b) 逆設計の NN モデル

特性  $\mathbf{Y}^r$  与えられ、それに対応する EDFA パラメータ  $\mathbf{X}^r$  を決定することが目的となり、 $\mathbf{X} = f^{-1}(\mathbf{Y})$  を解くことになり、関数  $f^{-1}$  を多層 NN で求める。EDFA パラメータ  $\mathbf{X}^r = \{x_1^r, x_2^r, \dots, x_M^r\}^T$  に対する EDFA の特性  $\mathbf{Y}^r = \{y_1^r, y_2^r, \dots, y_N^r\}^T$  を学習データとしてネットワークの重みを最適化アルゴリズムを用いた逆伝播により決定して最適な多層 NN を得る。最適化された多層 NN の入力に所望の EDFA 特性  $\mathbf{Y}^r$  を入力して、それに対応する EDFA パラメータ  $\mathbf{X}^r$  を得る。なお、図 4 は隠れ層が 3 層の NN を示しているが、隠れ層の層数は 3 には限らない。

### 3. シミュレーション結果と解析

#### 3.1 EDF 長と励起光パワー

EDF 長と励起光パワーを求める EDFA パラメータ

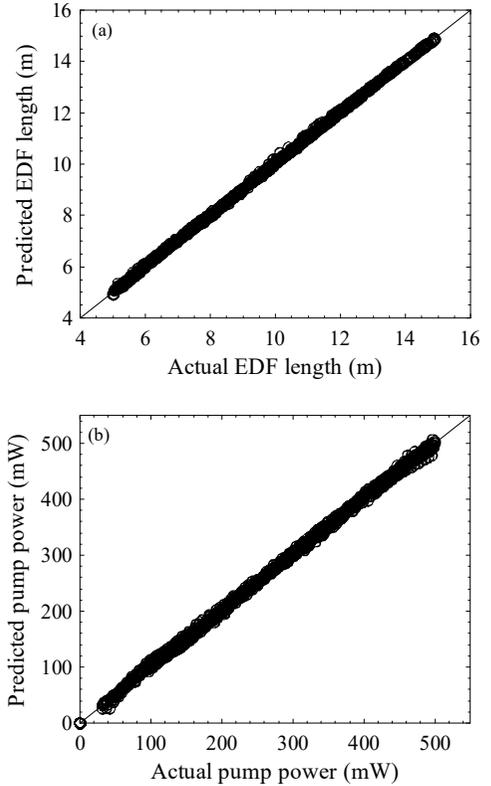


図 5 (a)EDF 長, (b)励起光パワーに対する実際の EDF パラメータと予測 EDFA パラメータの相関図

とし、目標特性、すなわち NN 入力を最小利得と利得チルトとした EDFA 逆設計を行った。EDFA のその他のパラメータは、比屈折率差を 0.7%、コア半径を  $2.4 \mu\text{m}$ 、エルビウムイオン添加濃度を  $1.0 \times 10^{25} \text{ m}^{-3}$  とした。

学習・検証データとして、4127 個の最小利得、利得チルト、EDF 長、励起光パワーのセットを用意し、その 80% を NN の学習に、残り 20% を NN の検証に用いた。NN は Relu 関数を活性化関数とする 50 個のノードからなる 2 層の隠れ層を有する。NN の学習は推定値とサンプル値の平均二乗誤差 (MSE) を計算し、RMSprop 最適化アルゴリズムを用いた逆伝播により行った。

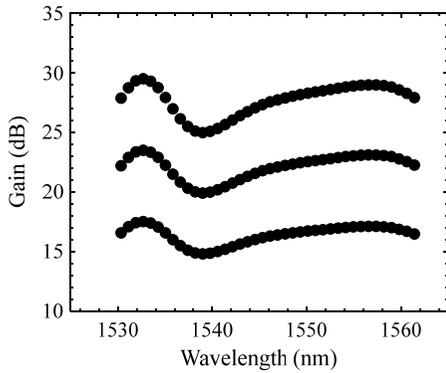


図 6 学習後 NN により得られた EDFA パラメータを用いて計算した利得スペクトル

エポック数10000とした場合の実際のEDFAパラメータと予測EDFAパラメータの相関図を図5に示す。同図において、(a)はEDF長、(b)は励起光パワーの相関図であり、実線はターゲットを示すものである。EDF長、励起光パワーともに相関係数は0.99以上となり、予測されたEDFパラメータが実際のEDFAパラメータとよく一致することがわかる。学習後のNNに、目標特性として利得チルトを0 dBとし、最小利得15, 20, 25 dBとした3種類の入力したときの NNから出力されたEDFパラメータは、各最小利得に対してそれぞれEDF長は6.8 m, 9.0, 11.3 m, 励起光パワーは49.3, 147.2, 479.0 mWであった。これらEDFAパラメータを用いて連立微分方程式を計算して得られた40チャンネル利得は図6に示すように平坦な利得スペクトルが得られた。誤差は最小利得0.2 dB, 利得チルト0.1 dBであり、NNにより得たEDFAパラメータにより ほぼ目標どおりの利得スペクトルが得られていることがわかる。

### 3.2 比屈折率差, コア半径, エルビウムイオン添加濃度

EDFのコア半径, 比屈折率差, エルビウムイオン添加濃度を求めるEDFAパラメータとし, NN入力を40チャンネル利得スペクトルとした EDFA逆設計を行った。EDFAのその他のパラメータは, EDF長9 m, 励起光パワー150 mW とした。

学習・検証データとして, 2408個の最小利得, 利得チルト, EDF長, 励起光パワーのセットを用意し, その80%をNNの学習に, 残り20%をNNの検証に用いた。NNはシグモイド関数を活性化関数とする20個のノードからなる7層の隠れ層を有する。NNの学習は推定値とサンプル値のMSEを計算し, レーベン

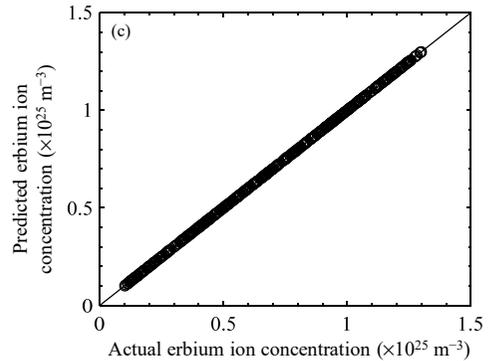
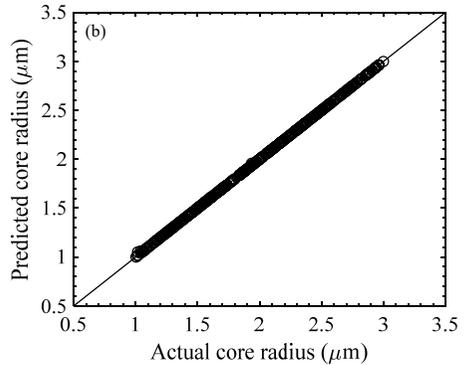
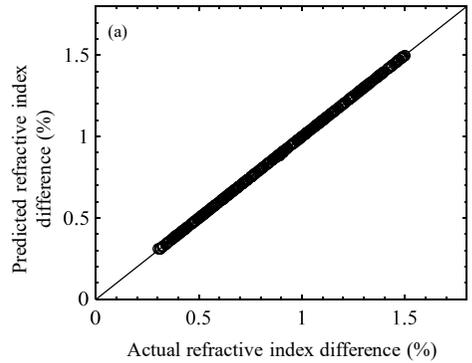


図 7 (a)比屈折率差, (b)コア半径, (c)エルビウムイオン添加濃度に対する実際の EDF パラメータと予測 EDFA パラメータの相関図

バーグ・マルカート法を用いた逆伝播により行った。エポック数2000とした場合の実際のEDFAパラメータと予測EDFAパラメータの相関図を図7に示す。

同図において、(a)は比屈折率差、(b)はコア半径、(c)はエルビウムイオン濃度の相関図であり、実線はターゲットを示すものである。EDF長、励起光パワーともに相関係数は0.99以上となり、予測されたEDFパラメータが実際のEDFAパラメータとよく一致することがわかる。学習後のNNに、目標特性として図3に示した40チャンネル利得値を入力すると、比屈折率差0.62%、コア半径2.56  $\mu\text{m}$ 、エルビウムイオン添加濃度 $1.00 \times 10^{25} \text{ m}^{-3}$ が得られた。これらEDFAパラメータを用いて連立微分方程式を計算して得られた利得は図3の各チャンネル利得の誤差0.1 dB未満でほぼ一致する結果が得られた。

#### 4. まとめ

目標特性を入力とし、EDFAパラメータを出力とするニューラルネットワーク学習モデルを用いて、従来EDFAに対する逆設計の適用性を調べた。目標特性を最小利得と利得チルトし、EDFAパラメータとしてEDF長と励起光パワーを求める逆設計と、目標特性をと40チャンネル利得し、EDFAパラメータとして比屈折率差、コア半径、エルビウムイオン添加濃度を求める逆設計の2種類について逆設計によりEDFAパラメータを求めた結果、いずれも良好な結果が得られ、従来EDFAに対してニューラルネットワークを用いた逆設計が可能であることを示した。本検討により従来EDFAへの逆設計適用ができることが明らかになった。今後、これを発展させて従来EDFAより設計が複雑化するMC-EDFAやFM-EDFAの設計へ逆設計を適用し、その効果を検証していく。

#### 参考文献

- [1] D. Zibar, M. Piels, R. Jones, C. G. Schäffer, "Machine learning techniques in optical communication," *J. Lightwave Technol.*, vol. 34, no. 6, pp. 1442–1452, 2016.
- [2] J. Mata, I. de Miguel, R. J. Durán, N. Merayo, S. K. Singh, A. Jukan, M. Chamania, "Artificial intelligence (AI) methods in optical networks: A comprehensive survey," *Opt. Switch. Netw.*, vol. 28, pp. 43–57, 2018.
- [3] S. Chugh, A. Gulistan, S. Ghosh, and B. M. A. Rahman, "Machine learning approach for computing optical properties of a photonic crystal fiber," *Opt. Express*, vol. 27, no. 25, pp. 36414–36425, 2019.
- [4] D. Zibar, A. Ferrari, V. Curri, and A. Carena, "Machine learning-based Raman amplifier design," in *Proc. Opt. Fiber Commun. Conf.*, 2019, paper M1J.1.
- [5] D. Zibar, A. M. R. Brusin, U. C. de Moura, F. D. Ros, V. Curri, and A. Carena, "Inverse system design using machine learning: the Raman amplifier case," *J. Lightwave Technol.*, vol. 38, no. 4, pp. 736–753, 2020.
- [6] F. Teng, Z. Jin, S. Chen, and H. Tian, "Neural network for the inverse design of polarization maintaining few-mode panda-type ring-core fiber," in *Proc. Asia Commun. and Photon. Conf./Int. Conf. Info. Photon. and Opt. Commun.*, 2020, paper M4A.63.
- [7] P. C. Becker, N. A. Olsson, and J. R. Simpson, *Erbium-doped fiber amplifiers, fundamentals and technology*, Academic Press, 1997, Chap. 5.