

機械学習を用いたマルチモードファイバ波長計測における識別クラス拡大

A study on handling a large number of classes for classification
in a machine-learning-based multimode-fiber wavemeter○栗原拓海¹, 西脇大輔², 行方直人³*Takumi Kurihara¹, Daisuke Nishiwaki², Naoto Namekata³

Abstract: We proposed a machine-learning-based optical wavemeter. Then the estimation of wavelength of an input CW laser was successfully carried out as a 10-class classification using a convolutional neural network (CNN). However, the number of classes must be increased by 100 ~ 1000 in the practical viewpoint. In this study, in order to handle a large number of classes for optical-wavelength classification, we adopt a multi-stage classification approach. The developed two-stage classifier offers the possibility to realize the wavelength estimation with a wavelength span from 1550.00 to 1550.99 nm and a resolution 0.01 nm, which corresponds to 100-class classification.

1. まえがき

分光器は、入力された光を波長ごとに分離し、相対的な強度を測定できる装置である。分光器は物理・化学実験や医療・食品分析など、幅広い分野で用いられている。典型的な分光器は、回折格子やプリズムを利用して光を回折・分散させることによって分光を実現している。この方法では、一般的に分解能と光学系サイズはトレードオフの関係にあり、10 pm (10^{-12} m) 未満の波長分解を得るためには極めて大きな光学系を要する。

高波長分解能かつコンパクトな分光器の候補として、分散体にマルチモード光ファイバ(MMF)を用いたものが挙げられる。分散体は光を波長ごとに分解する要素で、プリズムや回折格子などが一般的に使用される。MMF 内を伝播する複数のモードの干渉により生じるスペckルパターン(2次元強度分布: SP)から、入力光の波長やスペクトルを推定できる^[1]。

文献[1]では、MMF 出力端面上の SP を画像データとして取得し、MMF の逆伝達関数を利用して入力光スペクトルの再構成や波長再構成を実現している。ここで、逆伝達関数は実験によって得られたパラメータから計算されるため、雑音・光の強度揺らぎの影響を強く受ける。よって、より精度の高い光スペクトル再構成を実現するためには、補助的に何かしらの最適化手順を必要とする。最適化は何かしら統計的手法を利用することとなる^[1]。

本研究では、Fig.1 に示すように、SP 画像から入力光スペクトル再構成するプロセスを全て多層ニューラルネットワークに置き換えることを検討している^[2, 3]。連続(CW)光を MMF に入射した際に得られる SP を

10クラスの識別問題として学習し、入力 CW 光の波長推定を行った。その結果、波長分解 100 pm, 精度 99% 超の波長推定を実現した。また、入力 CW 光が極めて微弱である場合の強度雑音耐性が高いことも確かめられた^[3]。しかしながら、識別クラスは 10 と少なく、応用・実用へ向けて大きくそれを増やす必要がある(一般的な分光, 波長計測の場合, 128~1064 クラスが必要)。そのため、識別クラスを 100 まで増やし、精度良く波長識別が可能かを調べた。




Figure 1. spectral reconstruction with deep learning

2. CNN を用いた SP からの光波長識別実験

MMF 波長系の概略を Fig.2 に示す。文献[3]で構築した光学系と同様であるが、SP 画像を取得するためのカメラを InGaAs カメラ (Xenics 社製, Bobcat320) へ置き換えた。これまではビジコンチューブカメラを用い




Figure 2. the MMF wavemeter

ていたが、数秒にわたる残像があったため像取得に膨大な時間を要していた。InGaAs カメラは 10 ミリ秒程度での撮像が可能であり、大量の SP 画像データを短時間に取得できるようになった。

波長 1550 nm 帯外部共振器レーザーからの CW 光を温度安定化された長さ 1 m の MMF に入射し、その出射端における SP をテレセントリック光学系と InGaAs カメラによって取得した。

3. 波長識別精度の評価

前述のように SP 像取得用カメラを変更したため、今回用いた InGaAs カメラで取得した SP データによって先行研究と同様に波長推定が行えるかを確認した。学習には訓練データをそれぞれのクラスで 144 枚、テストデータを訓練データから 1 割とした。波長分解幅を 0.1 nm として波長 1550.0 nm ~ 1550.9 nm の 10 クラス、波長分解幅を 0.01 nm として波長 1550.00 nm ~ 1550.09 nm の 10 クラスでそれぞれ波長識別精度の評価を実施した。その結果、Table 1 に示す通り、先行研究と同様に識別精度 100% の実現が確認できた。

次に、波長分解幅を 0.01 nm として波長 1550.00 nm ~ 1550.19 nm の 20 クラスで測定を行った。その結果、識別精度が 3.9% と著しく低下した (Table 1)。

Table 1. Results of class identification

Wavelength-bin width	The number of bins (classes)	Accuracy
0.1 nm	10	100%
0.01 nm	10	100%
0.01 nm	20	3.9%

4. クラス数拡大に向けた検討

前章の実験結果から明らかなように、現行モデルによる学習ではクラス数の拡大は望めない。理由として、階層やチャンネル不足がまず考えられる。一方、波長分解幅に寄らず 10 クラス識別は高精度で行えている。そこで、その 10 クラス識別を多段で行うことで最終的なクラス数拡大を試みた。具体的には、まず波長分解幅 0.1 nm による 10 クラス識別を行い、その結果からさらに細かく 10 クラス識別 (波長分解幅 0.01 nm) を実施することで、最終的に $10 \times 10 = 100$ クラスの識別を実現する。本アプローチでは、10 クラス識別用のネットワークを計 11 個構築することとなるが、学習にかかる時間的コストは著しく増大せず、クラス数拡大の原理検証としては十分である。

現在、0.01 nm の各バンド (計 10 個) についての学習 (2 段階目の 10 クラス識別) を行っている最中である。その途中結果を Table 2 に示す。波長幅 0.1 nm の各バンド (4 つ) における波長分解幅 0.01 nm の識別は高い精度を達成した。

Table 2. Two-stage class classification

Wavelength band	Accuracy
10 classes (width = 0.01 nm)	
1550.00 ~ 1550.09 nm	100%
1550.10 ~ 1550.19 nm	100%
1550.20 ~ 1550.29 nm	90%
1550.30 ~ 1550.39 nm	90%

初期段階では大まか (波長分解幅 0.1 nm) な分類を、第二段階では各カテゴリー内において、より細かい (波長分解幅 0.01 nm) に基づく個別クラスの識別を行っている。つまり、第二段階では各クラスの SP 間の差異がより少ないが、それに特化したチューニングが可能となったため比較的小さいネットワークによって精度よく波長推定が行えたと言える。

5. まとめ

本研究では、MMF 波長計の開発において、深層学習技術を適用した新たなアプローチを検討した。先行研究からの実験装置変更による影響はなく、同程度の波長推定精度を得られた。

今後の展望として、多クラスの分類について 2 段階分類を使用して、モデルの精度を確認し、2 段階識別が適切であったかどうかの評価や、判明した問題点を修正しながら精度の向上を目指す。

6. 参考文献

- [1] B. Redding, S. Popoff, and H. Cao. "All-fiber spectrometer based on speckle pattern reconstruction," *Opt. Express* 21, 6584 (2013.3).
- [2] 井出和輝, "ファイバ分光器の実現に向けた深層学習によるスペckルパターンの波長識別," 日本大学理工学部応用情報工学科卒業論文 (2019.3).
- [3] 奥山, 西脇, 松野, 行方, 井上, "機械学習を用いたマルチモードファイバ波長系とそのポアソン強度揺らぎと暗計数に対する耐性", 第 70 回応用物理学会春季学術講演会, 15p-A202-11 (2023.3).