

## 機械学習を用いたマルチモードファイバ波長計の高分解能化に関する研究 ～CNNを用いたスペックルパターンの画像分類～

### A Machine Learning Approach for the High-Resolution Wavemeter Based on a Multi-Mode Fiber ～CNN-Based Image Classification of Speckle Patterns～

奥山 皓介<sup>1</sup>, 西脇 大輔<sup>2</sup>, 松野 裕<sup>3</sup>, 行方 直人<sup>4</sup>, 井上 修一郎<sup>5</sup>  
Kosuke Okuyama<sup>1</sup>, Daisuke Nishiwaki<sup>2</sup>, Yutaka Matsuno<sup>3</sup>, Naoto Namekata<sup>4</sup>, Shuichiro Inoue<sup>5</sup>

Abstract: In recent years, the deep learning has attracted much attention in a variety of fields. In particular, it has been used to solve an image classification problem and applied to a broad area of research that complex image processing and analysis are necessary. We applied the deep learning process to the estimation of a laser wavelength using a multi-mode-fiber spectrometer system. The image classification technique based on the deep learning enables us to well distinguish speckle patterns projected by the multi-mode fiber. The accuracy of the wavelength estimation was found to be 99% with a wavelength resolution of 0.01 nm with low computational cost.

#### 1. 概要

分光器とは測定対象となる光を波長ごとに分離しその相対強度を測定できる装置であり、基礎研究、医療、食品分析などに広く利用されている。分光器はグレーティングやプリズムによる光の回折を用いたものが一般的であるが、小型でかつ高波長分解が可能な手法の開発が進められている。その一つに、マルチモードファイバ(MMF)分光器が挙げられる[1]。MMFの複数伝播モードが干渉することによって発生するスペックルパターン(2次元強度分布: SP)から入力波長またはスペクトルを推定することができる。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推定を実現している。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、その実験における雑音等の影響を強く受ける。よって、より尤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。文献[1]では、シミュレーテッドアニーリングによる最適化を行っている。実験における雑音、揺らぎ、不確かさが大きくなるほど逆伝達関数を用いる準解析的手法の優位性は低くなり、統計的手法による最適化の重要性が大きくなると言える。本研究では、高分解MMF分光計の実現を目指し、SP画像から入力光スペクトル再構成する手順を全て深層学習に置き換えることを検討する。今回、その前段的試みとして、畳み込みニューラルネットワーク(Convolutional Neural Network: CNN)を用いた画像識別を利用し、MMFの波長計としての性能評価を実施した。波長計とは、単一縦モードの連続(CW)光の波長を計測するものである。

#### 2. 実験方法(CNNを用いた画像識別)

今回、長さ20mのMMF(コア径100 $\mu$ m、開口数0.25)の出射端におけるSPを画像データとして取得した。入射光の空間モードを単一とするため、そして入射位置を安定化するためにCW光(外部共振器レーザー: Santec, TSL-550)はMMF入射端に融着接続された単一モードファイバを通して入射している。また、MMFはアクリル真空チャンバ内で $25 \pm 0.05$ °Cに温度安定され、外部環境による応力変化や膨張伸縮を極力低減させた。

MMF出射端には開口数0.5の非球面レンズによるコリメーターを付け、そこから出力された平行光をチューブレンズを通してその結像面に近赤外撮像管カメラ(VTC)を置いた。こうする事によりMMF出射端面のSP(近視野象)を取得することができる。外部共振器レーザーの波長制御、VTCでのSP撮像、そしてデータ保存などの一連の実験作業はLabVIEWを利用して自動化された。ここで、VTCの残像を除去するため、撮像間隔は10秒とした。深層学習を行うための訓練用SP画像データを取得する際、波長分解幅を0.1nmとした場合は、波長1550.0nm～1550.9nmまでの10クラスとし、波長分解幅を0.01nmとした場合は、1550.00nm～1550.09nmまでの10クラスとした。取得したデータの種類とSP画像データ数についてまとめたものを表1に示す。

表1 取得する画像データ種類

波長分解幅	訓練データ数	テストデータ数	合計
0.1nm	24	6	30
0.01nm	24	6	30




図2 波長変化量 0.01 nm としたときの SP 画像の例

前処理として、取得した SP 画像を 300×300 にリサイズし、また、複数取得した SP 像より無作為選んだ2割をテストデータとし学習を行う。リサイズした SP 画像データの例を図2に示す。入力光の波長を 0.01 nm ごとに変化させると SP パターンが変化していることがわかる。これは、20 m の MMF が持つ原理的な波長分解能が 0.01 nm 以下であることを示唆している。この SP パターンを学習させることにより画像の分類分けを行い評価を行った。今回は分類分けにおいて学習試行回数は 100 回に固定しテストを行い、精度の測定に当たっては 10 回の精度結果の平均をとって結果を出す。

### 3. 分類試験

今回は、画像認識の中でも CNN の構造を用いて学習を行った。精度(accuracy)を以下のように定義する。

$$\text{Accuracy} = \frac{\text{予測値が正解だったテストデータ数}}{\text{全体のテストデータ}} \quad (1)$$

分類分けにあたって今回は学習試行回数は 100 回に固定してテストを行っている。また、精度の測定にあたって、10 回の精度結果の平均をとって結果とした。分類分けを行った結果を表2に示す。また、波長分解幅 0.1 nm、0.01 nm の場合に対して学習を行った時の試行回数に対する Accuracy を図3,4にそれぞれ示す。図3、4より、波長分解幅が 0.1 nm、0.01 nm のいずれの場合においても精度はほぼ 99%に到達しているが、

表2 スペックル画像のテスト結果

	波長ステップ	平均値
Loss	0.1nm	0
	0.01nm	0.1
Accuracy	0.1nm	1
	0.01nm	0.99




図3 0.1nm step Accuracy




図4 0.01nm step Accuracy

波長分解幅が細かいほど試行回数が必要であることがわかる。より波長分解幅が細かい場合に関しては、外部共振器レーザーの安定度(±0.005 nm)が不足する領域となり、不確かさや誤りの多い学習データとなることが考えられる。従って、高精度を得るためには余計に多くの試行回数が必要であることが予想され、より効率的なモデルの検討も課題となる。

### 4. まとめ

MMF 分光器において、SP から入力光波長を推定する手法として深層学習 (CNN モデル) の適用を試みた。波長計としての動作においては、100 回以下と少ない試行回数で高い波長推定精度 99%が得られ、CNN モデルの有用性を確認できた。今後は、CNN 以外のネットワークモデルとの比較や更に高い波長分解能の達成 (例えば 0.001 nm) や、10 クラス以上の画像識別を行えるか検討していく。

文献

- [1] B. Redding, S. Popoff, and H. Cao. "All-fiber spectrometer based on speckle pattern reconstruction," *Opt. Express* **21**, 6584 (2013).
- [2] CS 230 - 畳み込みニューラルネットワーク チートシート(参照日 2021/9/1)