

G-1

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波長分解能の拡大

Increasing the Number of Distinguishable Wavelengths in Machine Learning-Based Multimode Fiber Wavemeters

○栗原拓海¹, 西脇大輔², 行方直人³

*Takumi Kurihara¹, Daisuke Nishiwaki², Naoto Namekata³

Abstract: We propose a machine-learning-based multimode-fiber (MMF) wavemeter with high wavelength resolution. A convolutional neural network (CNN) achieved 10-class classification with a wavelength resolution of 0.1 nm and > 99% accuracy. To increase the number of classes, we employed a two-stage approach that combines coarse (0.1 nm) and fine (0.01 nm) classifications enabled stable recognition of 100 classes with an accuracy ranging from 90 to 100%. We also attempted the classification with a wavelength resolution of 1 pm, demonstrating the potential of deep learning for the compact and high-resolution wavemeter.

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、一般的に波長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^[1]。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

1:日大理工・院(前)・情報 2:日大理工・教員・情報 3: 日大量子光学研究所・教員

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、その射出端における 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. クラス数拡大に向けた検討

現行モデルは構造的制約からクラス拡大に限界があるが、10 クラス識別は安定して高精度が得られるため、本研究ではその特性を活かし二段階分類による拡大を試みた。具体的には、波長分解幅 0.1 nm で 10 クラスを識別した後、0.01 nm で再分類することで最終的に 100 クラスの識別を目指した。本手法ではネットワークを 11 個構築する必要があるが、計算コストの増加は小さく、クラス拡大の検証に有効である。

識別精度については各バンドで 100 回以上の繰り返し学習を行い、外れ値を除外し評価した結果、波長分解幅 0.01 nm での二段階識別は 90~100% の安定した精度が得られた。その代表的な結果を Table 1 に示す。

Table 1. Two-stage class classification

Wavelength band	Accuracy
10 classes (width = 0.01 nm)	
1550.00 ~ 1550.09 nm	90~100%
1550.10 ~ 1550.19 nm	90~100%
~	~
1550.90 ~ 1550.99 nm	90~100%

この結果から、初期段階では大まかな識別を行い、第二段階で各カテゴリー内においてより細かい識別を行うという手法が有効であることが示された。特に第二段階では各クラス間のスペックル像の差異が小さいものの、その特徴に特化したネットワークにより、安定して高い精度が得られたといえる。

4. 0.001nm 波長の識別

本章では、より高精度な波長識別を目指し、波長分解幅 0.001 nm での識別に挑戦した。波長分解幅が小さくなるにつれて波長発生装置の微小なばらつきが結果に与える影響が無視できなくなる。そのため、本研究では取得画像が設定波長そのものであると仮定し、識別の前提とした。

初めに、1550.000~1550.008 nm の範囲を 0.002 nm 刻

みで区切り、5 クラスに分類を行った。その結果、特に隣接クラス間での誤判定が多く見られた。その結果を Table 2 に示す。

Table 2. Five-class classification (nm)

	.000	.002	.004	.006	.008
.000	103	0	0	0	0
.002	111	0	0	0	0
.004	0	0	107	0	0
.006	0	0	0	95	0
.008	0	0	0	0	96

次に、誤分類が多く見られた中心波長 1550.002 nm を対象とし、隣接するクラスのみを用いた 3 クラス分類を行った。その結果、誤分類の発生件数自体は減少したものの、依然として誤分類は確認された。

MMF 波長計における物理的な波長分解能は MMF の長さに依存する。MMF 長さ 1 m における波長分解能は 0.01 nm のオーダーであるとされている (ただし、伝達関数によるアプローチ)。機械学習における波長分類はその分解能を完全に達成し、むしろそれを超える分解能を達成しているとも言える。隣接クラス間の誤分類は物理的分解能の現れとして見ることができる。しかし、その分散幅は予測される ~0.01 よりも 1 桁近く小さいこととなる。これは、実際の物理系の理想系に対するわずかな差異を機械学習が識別した結果であると考察される。

5. まとめ

本研究では、MMF 波長計において深層学習を用いたクラス数拡大と高分解能化を検討した。二段階分類により波長分解幅 0.01 nm での 100 クラス識別を安定的に実現し、外れ値を除けば 90~100% の高精度が得られた。また、波長分解能 0.001 nm での識別にも挑戦し、既存方法による波長分解能を超えた「超分解能」の実現が示唆された。

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ック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).