

# ディープニューラルネットワークは、3Dポイントスプレッド関数から正確に位相情報を読み出す

ほとんどの光学イメージング技術は、強度情報のみをとらえる、つまりセンサに入ってくる位相情報は失われる。ある種のイメージングシステム、例えば顕微鏡では、対象が透明だとしても位相に影響を与えるかもしれないので、位相情報の検出つまり読み出しがイメージングプロセスの改善に役立つ。位相読み出しは、強度情報から隠れた位相情報を計算的に回復することであり、これは存在するが従来の形式では遅い。役に立つ量の位相情報を読み出すには集中的な計算が必要である。

この問題に対処して、米スタンフォード大のレオンハート・メクル氏 (Leonhard Möckl)、ペター・ペトロフ氏 (Petar Petrov) と W. E. モーナー氏 (Moerner) は、深層残差ニューラルネットワーク (NN) に基づいて位相読み出し技術を開発した。これは、一般的なポイントスプレッド関数 (PSF) の隠れた位相を迅速かつ正確に抽出し、その情報をゼルニケ係数として返す。ディープNNは、入力と出力の間にマルチネットワーク層を持つ。このタイプのNNでは、データは入力から出力へ、フィードバック (データの後ろループ) なしで層を通して進む。

スタンフォード大の位相読み出しアプローチは、いわゆる残差NNに基づいている。ここでは、NNを介して浸透する情報が層をスキップすることがあり、これがNNのトレーニングに役立つ。NNをトレーニングした後、それは入力として、焦点位置の範囲でとられ

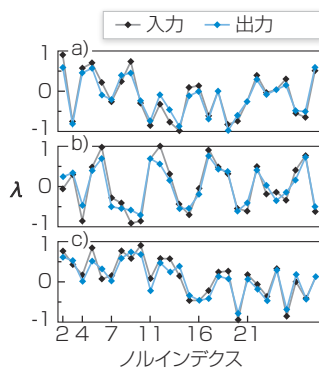


図 ここに示した2～28のノルインデクス、さまざまなゼルニケ係数の大きさは、深層残差ニューラルネットワークで分析されたテストPSFの入力(黒)と出力(青)で比較されている。入力と出力ゼルニケがよく一致していること見て取れる。

たPSFの一連の2D強度計測を利用する。NNは、その情報を処理し、1～6次 (いわゆる2～28のノルインデクスに対応する。ノルインデクスは、一次元数であり、特殊ゼルニケ次数がシングルナンバーで表される) のゼルニケ係数を出力する。

そのNNの効果をテストするためにスタンフォード大の研究者は、多数のPSFをシミュレートした。それぞれがランダムに選ばれた一連の異なる1～6次のゼルニケの結果となる。PSFシミュレーションは、焦点位置-1、-0.5、0、0.5及び1 $\mu\text{m}$ で計算され、ゼルニケ係数における変動は、2 $\lambda$ 。結果としてのPSFは、NNの入力として使用された。

## ニューラルネットワーク トレーニング

NNのトレーニングで、研究者は多数のトレーニングPSFが必要と判断した。

20万では十分でなく、最終的に200万PSF量を設定した。残差NNアーキテクチャを決める前に、異なるタイプのNN数を考慮した。トレーニング時間は約12時間かかった。結果として得られたトレーニングしたシステムは、i7-6700プロセッサ、16GB RAM、GPUなしの標準的なデスクトップPCを利用して5msでPSFを解析できた。とはいえ、付加的スピードは、標準デスクトップPCにそのシステムが実装した64GB RAM、Intel Xeon E5-1650プロセッサ、及びNvidia GeForce GTX Titan GPUによるものである。

NNは、解析した各PSFでゼルニケ係数を非常に正確に予測することに成功している (図参照)。研究者は、出力ゼルニケを取り出して結果としてのPSFを計算し、それらを入力PSFと比較した。これはよく一致していることを示している。加えて、所定のPSF、いわゆるTetra6 PSFを解析した。これは、3Dでナノスケールエミッタを見つけるために実際に使用されている。NNはゼルニケ係数を正確に予測した、これにはNNのトレーニング範囲になかったものも含まれている。

研究者は、そのアプローチが非ゼルニケ的位相情報の読み出しに拡張でき、また、位相マスクの設計でも役立つと付け加えている。(John Wallace)

### 参考文献

- (1) L. Möckl, P. Petrov, and W. E. Moerner, *Appl. Phys. Lett.*, 115, 251106 (2019); <https://doi.org/10.1063/1.5125252>.