

# 畳み込みニューラルネットワークに基づく複素ホログラム計算の量子化 Quantization of Convolutional Neural Network-based Complex Hologram Calculation

遠藤 優<sup>1)</sup> 老川 稔<sup>2)</sup> 下馬場 朋禄<sup>3)</sup> 伊藤 智義<sup>3)</sup>  
Yutaka Endo Minoru Oikawa Tomoyoshi Shimobaba Tomoyoshi Ito

## 1. はじめに

近年、拡張現実 (AR: augmented reality) のためのディスプレイ技術として計算機合成ホログラフィ (CGH: computer-generated holography) が注目されている<sup>[1]</sup>. CGH は計算によって生成したホログラムを用いて、光波を制御する技術である. これにより目に負担の少ない 3 次元像の表示が可能であり、さらにプログラマブルな収差補正ができることから、小型な光学系を実現できるポテンシャルを持つ. 一方、CGH はホログラム生成に必要な計算コストが高く、リアルタイム処理に向けて高速化が求められている<sup>[2]</sup>.

CGH では、3D シーンがホログラム面に作る光波場 (複素ホログラム) を光伝搬計算によって求める必要がある. 光伝搬計算は、3D シーンを点光源の集合とみなし、各点がホログラム面に作る光波場を足し合わせることで行われる. この場合、計算量はホログラムの画素数と 3D シーンを構成する点光源の数に比例して大きくなる<sup>[3]</sup>. そこで近年、理論的に導かれる数式を使う代わりに、畳み込みニューラルネットワーク (CNN: convolutional neural network) を用いて効率的に光伝搬計算を行う手法が提案された<sup>[4]</sup>. しかし、この手法をリアルタイム処理するには高性能な GPU が必要であり、計算リソースが限られた AR ヘッドセットやヘッドアップディスプレイへ応用するには、モデルのさらなる軽量化が必要である.

本研究では、光伝搬計算のための CNN に量子化を活用することで、軽量のモデルを開発した. 開発したモデルは先行研究で提案された tensor holography モデル<sup>[4]</sup>をベースにしており、量子化時における出力精度の低下を防ぐためにアーキテクチャに修正を加えている. 開発したモデルの精度、サイズ、計算速度を評価し、量子化の有効性を検証した.

## 2. 手法

### 2.1 CNN を用いた複素ホログラム計算

CNN を用いた複素ホログラム計算では、入力となる 3D データと光伝搬計算によって生成された複素ホログラムとの対応関係を CNN に学習させる. 学習した CNN は光伝搬計算を効率的に近似できるようになる. 図 1 に本研究で使用したモデルを示す. このモデルは先行研究の tensor holography モデル<sup>[4]</sup>をベースに修正を加えている. 入力データは RGB-D 画像を用い、出力データは複素ホログラム (振幅と位相) となる. モデルは 2 つの 3×3 畳み込み層、バッチ正規化、ReLU6 からなる残差ブロックで構成される.

最終段の残差ブロックの出力と、スキップ結合された入力データはそれぞれ 3×3 depthwise convolution される. その後、この二つは結合され、1×1 pointwise convolution が行われる. モデル出力の振幅・位相分布は Hardtanh で [0, 1] の範囲にクリッピングされる. モデル内の 3×3 畳み込み層の数は 30、各層のカーネルの数は 24 とした.

モデルの実装と学習には PyTorch 2.1.0 を用いた. 学習には、RGB-D 画像と複素ホログラムのペアからなるデータセットである MIT-CGH-4K<sup>[4]</sup>を使用した. このデータセットは 384×384 ピクセルの RGB-D 画像と、その RGB-D 画像から計算された RGB の複素ホログラムの 4,000 サンプルから構成されている. 4,000 サンプルのうち、3,800 サンプルをトレーニング、100 サンプルをバリデーション、100 サンプルをテストのために使用した. 損失関数には振幅と位相それぞれの MSE (mean squared error) を用いた. 最適化アルゴリズムには Adam を用いて、学習率 0.0001、エポック数 100 で学習を行なった.




図 1 複素ホログラム生成モデル

### 2.2 ニューラルネットワークの量子化

ニューラルネットワークの量子化とは、モデル内で使用される重みとアクティベーションのビット数を削減することで、モデルを軽量化する手法である<sup>[5,6]</sup>. 多くの機械学習フレームワークでは、モデルの重みとアクティベーションは 32 bit 浮動小数点数 (FP32) で表される. しかし、より低精度である 8 bit 整数 (INT8) などを用いても、適切にパラメータを設定することで、FP32 モデルと近い出力が得られることが知られている. 低精度数値フォーマットの使用により、モデルサイズ、メモリ使用量、計算コストを削減でき、モデルを軽量化できる. 一方で、量子化を行うと出力精度が低下してしまう. 量子化に伴う精度低下を抑えるには、適切な量子化方法の選択とアーキテクチャの改善が必要となる.

本研究では post-training static quantization を用いて、FP32 モデルを INT8 モデルに変換した. これは学習済みモデルからサンプルデータを使って、重みとアクティベーションの量子化パラメータを決定する手法である. 量子化は PyTorch FX Graph Mode Quantization を用いて行なった. ターゲットバックエンドは QNNPACK とし、そのデフォルト設定を用いた.

1) 金沢大学理工研究域 Institute of Science and Engineering, Kanazawa University

2) 高知大学自然科学系理工学部 Science and Technology Unit, Natural Sciences Cluster, Kochi University

3) 千葉大学大学院工学研究院 Graduate School of Engineering, Chiba University

### 3. 結果

量子化の有効性を検証するため、FP32 モデルと INT8 モデルの性能評価を行なった。またモデルへの修正の有無が与える評価するため、修正前と修正後のモデルを同じ設定でトレーニング・量子化し、その性能を評価した。

#### 3.1 画質評価

FP32 モデルと INT8 モデルを用いて生成された複素ホログラムの画質評価を行なった。画質評価には、ホログラムの振幅部と位相部それぞれの PSNR (peak signal-to-noise ratio) と SSIM (structural similarity index measure) を用いた。表 1 に画質評価結果を示す。FP32 では、アーキテクチャの修正の有無に関わらず同程度の画質となった。INT8 では、修正前モデルの画質が大幅に低下している。それに対し、修正後の INT8 モデルの画質低下はわずかなものに抑えられている。

各モデルを用いて生成されたホログラムからシミュレーションによって計算した再生像を図 2 に示す。再生シミュレーションには角スペクトル法を用いて、ホログラムから 6 mm 離れた位置の再生像を計算した。修正前の INT8 モデルでは再生像が完全に失われている。しかし、修正後の INT8 モデルでは FP32 モデルと同等の再生像が得られている。以上から、モデルに対して修正を加えることで、FP32 モデルと同等の画質をもつ INT8 モデルを作成できた。

表 1 ホログラムの画質評価

モデル	精度	PSNR [dB]		SSIM	
		振幅	位相	振幅	位相
修正前	FP32	29.1	28.3	0.907	0.903
修正後	FP32	30.1	28.3	0.915	0.904
修正前	INT8	7.78	24.3	0.205	0.555
修正後	INT8	29.3	27.9	0.899	0.888



図 2 シミュレーションによる再生像

#### 3.2 モデルサイズと計算速度の評価

修正後の FP32 モデルと INT8 モデルのサイズと実行速度を評価した。モデルサイズは PyTorch の state\_dict のファイルサイズを用いて評価した。実行速度は、1280×720 画素の入力画像に対するレイテンシとフレームレートで評価した。モデルは PyTorch 上で実行し、計算デバイスには CPU (AMD Ryzen 7 5800) を用いた。表 2 にモデルサイズと実行速度を示す。FP32 モデルと比べて、INT8 モデルはサイズが 70%削減され、実行速度は約 4 倍速くなった。このことから、量子化はホログラム生成モデルのサイズと実行速度の改善に有効であることを実証した。

表 2 修正後モデルのサイズと実行速度

精度	サイズ [kB]	レイテンシ [ms]	フレームレート [fps]
FP32	631	1,714	0.607
INT8	198	427	2.360

### 4. おわりに

本研究では、複素ホログラムを生成する CNN モデルに対して INT8 量子化を導入することで、モデルサイズと実行速度を削減した。また先行研究で提案されたモデルに修正を加えることで、FP32 モデルに匹敵する画質をもつ INT8 モデルを作成することができた。これらの結果は、特にリソースの限られた組み込みシステムに CGH 計算を実装する際に重要な役割を果たす。今後は、アルゴリズムの改善による実行速度の向上や、開発したアルゴリズムを実際に組み込みシステムへ応用していく。

#### 謝辞

本研究は JSPS 科研費 JP22K17908, JP22KK0183 の助成を受けたものです。

#### 参考文献

- [1] C. Chang, K. Bang, G. Wetzstein, B. Lee, and L. Gao, "Toward the next-generation VR/AR optics: a review of holographic near-eye displays from a human-centric perspective", *Optica*, 7(11), 1563–1578 (2020).
- [2] D. Blinder, T. Birnbaum, T. Ito, and T. Shimobaba, "The state-of-the-art in computer generated holography for 3D display", *Light: Advanced Manufacturing*, 3(0), 1 (2022).
- [3] T. Sugie, T. Akamatsu, T. Nishitsuji, R. Hirayama, N. Masuda, H. Nakayama, Y. Ichihashi, A. Shiraki, M. Oikawa, N. Takada, Y. Endo, T. Kakue, T. Shimobaba, and T. Ito, "High-performance parallel computing for next-generation holographic imaging," *Nat Electron* 1, 254–259 (2018).
- [4] L. Shi, B. Li, C. Kim, P. Kellnhofer, and W. Matusik, "Towards real-time photorealistic 3D holography with deep neural networks", *Nature*, 591, 234–239 (2021).
- [5] H. Wu, P. Judd, X. Zhang, M. Isaev, P. Micikevicius, "Integer Quantization for Deep Learning Inference: Principle", arXiv preprint, 2004.09602 (2020).
- [6] A. Gholami, S. Kim, Z. Dong, Z. Yao, M. W. Mahoney, and K. Keutzer, "A Survey of Quantization Methods for Efficient Neural Network Inference," *Low-Power Computer Vision* (Chapman and Hall/CRC, 2022).