

反復最適化に基づくニューラルネットワークを用いた 2 値振幅ホログラム生成 Generation of binary amplitude holograms using an iterative optimization-based neural network

片山 祥吾[†] 遠藤 優[‡]
Shogo Katayama Yutaka Endo

1. はじめに

計算機合成ホログラム (CGH: computer-generated hologram) は、計算によりホログラム画像を生成する手法であり、CGH を空間光変調器 (SLM: spatial light modulator) に表示することで任意の波面を再生できる。CGH は自然な 3 次元像を再生できることから、近年、仮想・拡張現実 (VR/AR) 分野などでその活用が期待されている。

CGH における課題の一つは、高速かつ高画質な CGH 生成の実現である。既存の SLM は振幅または位相のみを変調するため、再生像の画質向上には、SLM の種類に合わせて CGH を最適化する必要がある。代表的な手法として、Gerchberg-Saxton (GS) アルゴリズム[1]、Wirtinger ホログラフィ[2]などが挙げられるが、これらは反復計算を必要とし、長い計算時間を要する。そこで、近年、ニューラルネットワークを用いた CGH 生成手法[3]が提案されており、高速性と高画質化の両立が図られている。

本研究では、2 値振幅ホログラムを対象とし、反復最適化に基づくニューラルネットワークを用いた新たな CGH 生成手法を提案し、高速かつ高画質な CGH 生成を実現することを目的とする。

2. CGH 最適化

CGH は、目標とする光強度分布が忠実に再生されるように、かつ SLM の表示制約を満たすように計算される。SLM に表示できる CGH には制限があるため、高画質な再生像を得るためには、SLM の表示制約に合わせて CGH を最適化する必要がある。本研究では、DMD (digital micromirror device) などの 2 値振幅 SLM に表示する想定で、2 値振幅 CGH の最適化に取り組んだ。

2.1 反復最適化アルゴリズム

CGH を反復的に最適化する代表的な手法として、GS アルゴリズムと Wirtinger ホログラフィがある。

GS アルゴリズムでは、CGH に対して、伝搬・逆伝搬計算を繰り返し、目標の強度分布に近づくようにホログラムを最適化する。CGH $a_{\text{CGH}}^{(i)}$ の更新は以下のように表される。

$$a_{\text{CGH}}^{(i+1)} = \Pi_{\text{CGH}} \left\{ \mathcal{P}^{-1} \left\{ \Pi_{\text{target}} \left\{ \mathcal{P} \left\{ a_{\text{CGH}}^{(i)} \right\} \right\} \right\} \right\}$$

ここで、 \mathcal{P} と \mathcal{P}^{-1} は伝搬・逆伝搬計算、 Π_{target} と Π_{CGH} は目標分布と CGH に関する制約を表す。

Wirtinger ホログラフィとは、CGH 再生像と目標強度分布との誤差から、Wirtinger 導関数により勾配を求め、誤差を最小化することで、CGH を最適化する手法である、

CGH $a_{\text{CGH}}^{(i)}$ の更新は以下のように表される。

$$a_{\text{CGH}}^{(i+1)} = \Pi_{\text{CGH}} \left\{ a_{\text{CGH}}^{(i)} - t \nabla \mathcal{L} \left(\left| \mathcal{P} \left\{ a_{\text{CGH}}^{(i)} \right\} \right|, a_{\text{target}} \right) \right\}$$

ここで、 a_{target} は目標強度分布、 \mathcal{L} は誤差関数、 t はステップサイズを表す。

2.2 U-Net

反復的最適化の他に CGH の最適化手法として、ニューラルネットワークを用いた手法も注目されている。ニューラルネットワークは学習の際に、大量のデータセットが必要となるが、一度学習を完了させれば、その後は高速に最適化を行えるという利点がある。本研究では提案手法の比較対象として U-Net を構築する。U-Net は、図 1 で示されるように、U 字型のネットワーク構造を持つ畳み込みニューラルネットワーク (CNN: Convolutional Neural Network) モデルの一種であり、主に画像のセグメンテーションを行う為に開発された。通常の CNN と異なり、エンコーダとデコーダの間に skip-connection の構造があり、これは、エンコーダ部のダウンサンプリングで失われた特徴マップをデコーダ部に連結させることによりアップサンプリング時に物体の位置情報を補完する働きを持つ。データセットとして 2 値のランダムパターンとその伝搬後の強度分布を用意し、強度分布を U-Net に入力して最適化された CGH が出力されるようにネットワークを学習する。学習の際には、最適化された CGH と 2 値のランダムパターンの損失を求め、学習パラメータを更新する。




図 1: U-Net の概形

2.3 反復最適化に基づくニューラルネットワーク

本研究では、反復最適化アルゴリズムに由来する構造をもつニューラルネットワークを用いて、2 値振幅 CGH を生

[†] 金沢大学大学院自然科学研究科 Graduate School of Natural Science and Technology, Kanazawa University

[‡] 金沢大学理工研究域 Institute of Science and Engineering, Kanazawa University

成する手法を提案する。提案手法では、Wirtinger ホログラフィでの CGH に関する制約の計算を、パラメータ θ のニューラルネットワーク N_θ として構成する。つまり、1 回の反復計算は以下のように表される。

$$a_{\text{CGH}}^{(i+1)} = N_\theta \left\{ a_{\text{CGH}}^{(i)} - t \nabla \mathcal{L} \left(\mathcal{P} \left\{ a_{\text{CGH}}^{(i)} \right\}, a_{\text{target}} \right) \right\}$$

となる。この計算を N 回行うものとして、全体のネットワークモデルを構築する。提案手法では、ニューラルネットワーク N_θ には、U-Net を使用した。パラメータ θ は、図 2 のように、画像データセットを用いて学習する。1 回目の学習では、すべての画素値を、二値化の閾値である 0.5 とした画像を 2 値振幅 CGH の初期画像とし、それに伝搬計算を適用した伝搬画像と正解画像で損失を計算する。そして、その損失を基に提案モデルの N_θ のパラメータを更新する。2 回目以降の学習では、初期画像の代わりに提案モデルの出力画像を使用する。

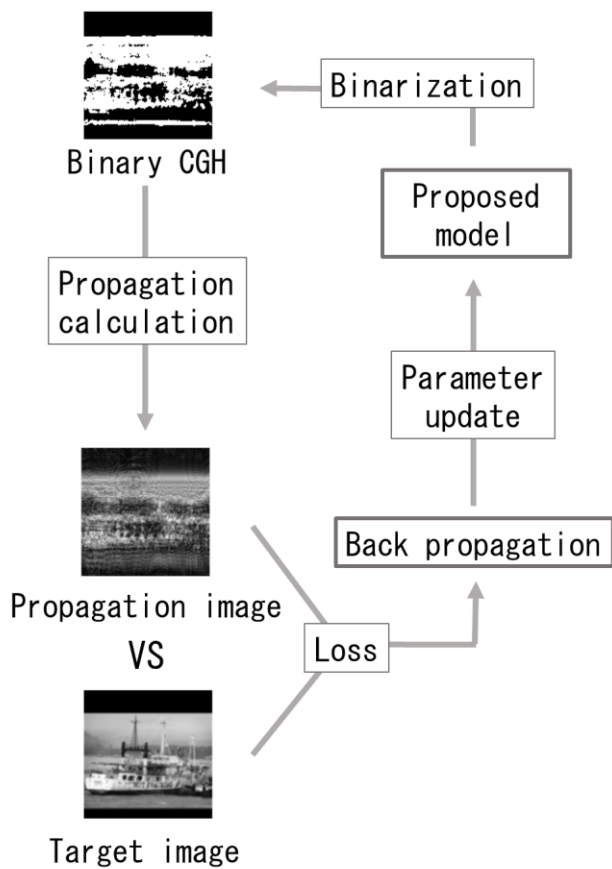


図 2: 反復最適化に基づくニューラルネットワークの学習

3. シミュレーション

シミュレーションにより、CGH の計算速度と再生像画質の評価を行った。CGH の画素数は 128×128 、画素サイズは $1.4 \mu\text{m}$ とし、CGH から再生像までの距離は 0.2 mm とした。比較対象として、GS アルゴリズム、Wirtinger ホログラフィ、U-Net による CGH 最適化の評価を行った。GS アルゴリズムおよび Wirtinger ホログラフィでは、100 回のループで最適化を行った。

性能評価とニューラルネットワークモデルの学習には、飛行機や車などの 10 種類のカテゴリからなる画像データセットである STL-10 を使用した。このデータセットのうち、学習に 10,000 枚の画像を用い、性能評価に 128 枚の画像を用いた。また、性能評価のための損失関数には平均二乗誤差 (MSE: mean squared error) を用いた。

シミュレーション結果を表 1 に示す。GS アルゴリズムや Wirtinger ホログラフィと比較して、提案手法はある程度の画質を保ちながら、計算時間を 1/4 以下に短縮できた。また U-Net と比べても、提案手法はある程度の計算速度を達成しながら、画質を大幅に向上させることができた。

表 1: CGH 計算速度と再生像画質の評価

	GS	Wirtinger	U-Net	提案手法
計算時間 [s]	13.19	17.58	1.571	2.692
MSE	0.048	0.066	0.123	0.062

4. おわりに

本研究では、反復最適化に基づくニューラルネットワークを用いて、2 値振幅 CGH の最適化を行った。その結果、従来の反復最適化手法である GS アルゴリズムや Wirtinger ホログラフィよりも高速で、U-Net による最適化法よりも高精度な CGH 生成を実現した。しかし、提案手法は GS アルゴリズムと比べて精度が劣っており、さらなるモデル構造の改善が必要だと考えられる。また、今回はシミュレーションでの検証のみ行ったが、今後は実際に光学系を用いた再生像精度の検証を行っていく。

謝辞

本研究は JSPS 科研費 JP22K17908 の助成を受けたものです。

参考文献

- [1] R. W. Gerchberg and W. O. Saxton, "A practical algorithm for the determination of phase from image and diffraction plane pictures", *Optik*, Vol.35, No.2 (1972).
- [2] P. Chakravarthula, Y. Peng, J. Kollin, H. Fuchs, and F. Heide, "Wirtinger holography for near-eye displays," *ACM Trans. Graph.* Vol.38, No.6 (2019).
- [3] Y. Peng, S. Choi, N. Padmanaban, and G. Wetzstein, "Neural holography with camera-in-the-loop training," *ACM Trans. Graph.* Vol.39, No.6 (2020).