

深層学習を用いた光干渉ゴーストイメージングの散乱体計測

シャフケティ アリフ^{1,2}, 呼延 徳才², 椎名 達雄^{1,2}

¹三菱電機株式会社 情報技術総合研究所 (〒247-8501 神奈川県鎌倉市大船 5-1-1)

²千葉大学大学院工学研究院 (〒263-8522 千葉市稲毛区弥生町 1-33)

Target sensing in scattering media using Deep Learning for Ghost Imaging-Optical Coherence Tomography

Alifu XIAFUKAITI^{1,2}, Decai HUYAN², and Tatsuo SHIINA²

¹Information Technology R&D Center, Mitsubishi Electric Corp., 5-1-1 Ofuna, Kamakura, Kanagawa 247-8501

²Graduate School of Engineering, Chiba Univ., Yayoicho, Inage-ku, Chiba-shi, Chiba, 263-8522

Abstract: Measuring targets in scattering media is a crucial task for advancements in biomedical imaging and environmental measurements. A novel sensing approach, known as GI-OCT, integrates the capabilities of Ghost Imaging (GI) and Optical Coherence Tomography (OCT) to capture target images within scattering media. However, this technique requires numerous irradiations of random patterns in ghost imaging to reconstruct a high-quality image of the object, consequently extending the measurement time. To address this issue and facilitate real-time measurement in GI-OCT, we have applied the Deep Image Prior (DIP) method in this work. This approach significantly reduces the number of measurements required to obtain a clear image in the simulation by 90%. In practical experiments, the number of OCT measurements needed to achieve an equivalent Structural Similarity Index Method (SSIM) value is reduced by half.

Key Words: Ghost imaging, optical coherence tomography, scattering media, deep learning, deep image prior.

1. はじめに

散乱媒体中における物体検出を非接触・非侵襲に行うことは、バイオイメージングや環境リモートセンシングの進歩に重要な役割を果たす。ゴーストイメージング (Ghost Imaging, GI) と光干渉断層法 (Optical Coherence Tomography, OCT) を組み合わせた新しい GI-OCT センシング手法は、GI の高いノイズ耐性と OCT の断層計測が可能な機能を統合し、散乱媒体内物体の三次元イメージの可視化に期待できる^{1,2}。しかし、GI では、被測定物の高品質なイメージを再構築するために、多数のランダムパターンの照射を必要とし、結果として計測時間が延長することを避けられない。この課題を解決し、GI-OCT でのリアルタイム測定を容易にするために、本研究では、GI-OCT 測定手法に Deep Image Prior (DIP) という深層学習を導入し、従来手法に比べて短時間計測で顕著な改善が見られた³。本原稿では、GI-OCT の構成とアルゴリズム、および深層学習の適用過程について述べ、シミュレーションと実験により取得した結果をもとに、本手法の有効性を評価する。

2. GI-OCT

2.1 装置構成

図 1 に GI-OCT 装置の構成図を示す。Time Domain OCT (TD-OCT) の送受信プローブからの出力光は、コリメートレンズとビームエキスパンダを通して拡大された平行なビームに変換される。デジタルマイクロミラーデバイス (Digital Micromirror Device, DMD) を用いることで、平行ビームの断面光強度をランダムに変調され、物体を設置した散乱媒質に照射される。DMD とは、多数の可動式の微小鏡面 (マイクロミラー) を、CMOS プロセスで作られた集積回路上に、平面状に配列した表示素子 (MEMS デバイス) である。配列されたマイクロミラーの角度を調整することで、DMD に照射された光の強度分布が制御できる。つまり、空間光変調器 (Spatial Light Modulator, SLM) と同じ役割を果たす。散乱媒質と物体からの後方散乱光は、送受信プローブで受光され、TD-OCT に装着された単一検出器で断面ごとの干渉信号が取得される。従来の OCT では、参照パスによる深度方向スキャン (A-scan) とプローブと直交する方向に移動するスキャン (B-scan) に、物体の三次元イメージを生成できる⁴。しかし、この計測に長い計測時間が必要となり、時間変化がない物体や散乱媒質の計測のみに適用できる。GI-OCT では、点計測の代わりに軸方向に対する断面二次元計測が可能

となり、散乱媒体によって引き起こされる他の方向への光の進行や遅延を計測することができる。また、分解能について、OCT に使用される SLD 光源のスペクトル幅によって深度方向の分解能が決まり、DMD の画素数とサイズによって物体表面の分解能が決まる。




Figure 1 Experiment configuration for target sensing configuration.




Figure 2 Schematic diagram of conventional GI within scattering media using GI-OCT System.

2.2 解析手法

図 2 に示すように GI では、光パターンの照射を用いた計測後に、各光パターンとそれに対する散乱光の信号群との相関を計算し、散乱媒質と物体のイメージを再構築する⁵。 m 回のランダムパターン照射において、単一検出器によって取得される光強度 I'_m は次の式

$$I'_m = \int P_m(x, y) G(x, y) dx dy \quad (1)$$

で得られる。 (x, y) 、 P_m と G は、それぞれ物体平面の横座標、ランダムパターンと物体の強度分布である。従来の GI の演算アルゴリズムに従って、既知のランダムパターンとそれに対する強度変動との相関関係によって、未知な像のイメージを再構築することができ、再構築イメージは次の式

$$\tilde{G}(x, y) = \frac{1}{m} \sum_{i=1}^m (I_i - \langle I_i \rangle) (P_i - \langle P_i \rangle) \quad (2)$$

を用いて計算上で実現できる。ここで、 $\langle \cdot \rangle$ はすべての m 回の平均測定値を表す。しかし、この演算はデジタルアートやメディアの分野で使用される技術で、映画や特殊効果を作成するための 3D コンピュータグラフィックスを指すために使用される。本研究では、式 (2) のような計算上での GI 解析手法を使わず、乱流大気条件や光散乱を通じた計測のような実行不可能な状況で特に有用である Differential ghost imaging (DGI) 法を用い、式 (3) に

$$\begin{aligned} \tilde{G}'(x, y) &= \frac{1}{m} \sum_{i=1}^m \left(I_i - \frac{\langle I \rangle}{\langle I' \rangle} I'_i \right) (P_i - \langle P_i \rangle) \\ &= \frac{1}{m} \sum_{i=1}^m I'_i (P_i - \langle P_i \rangle) \end{aligned} \quad (3)$$

より再構築イメージ $\tilde{G}'(x, y)$ が計算できる。ここで、物体なしの各光パターンに対する全光強度 I'_i を考慮し、散乱条件下でのイメージ再構築を行った。DGI 法では、GI 解析手法より何桁も高い信号対雑音比を持つ物体イメージを再構築することが可能である⁶。

2.3 深層学習

本研究では、GI-OCT システムに DIP 法を導入して計測回数を低減することで、短い計測時間において物体のイメージを再構築した。図 3(a) に DIP 法を示し、ランダムパターン P_i 、と後方散乱光強度 I'_i の計測値、および式 (3) による算出された構成イメージ $\tilde{G}'(x, y)$ が入力としてランダムに初期化されたニューラルネットワーク (CNN) に送り込む。ここで、 f はランダムな初期化された CNN を示し、 θ と T は、それぞれネットワークパラメータと 10^{-9} の正則化パラメータである。正則化は、モデルの過学習を減らすための機械学習手法で

あり、 L は反復回数を指し、CNNを使用した訓練回数である。CNNでは、高品質の再構築イメージを取得するための光強度の推定値 $\tilde{I}_i$ が出力され、測定値と計測値との間の誤差を最小化するように、CNNの重みが更新される。誤差が最小化されると、CNNの出力は高品質の再構築イメージに必要な光強度に収束・最適化される。CNN内の重みは、初期学習率が0.01のADAM最適化（CNNの訓練に使用される適応学習率を持つ最適化アルゴリズムである）を使用して更新される。 I_i の最適解は反復訓練を通じて得られ、 $\tilde{G}'(x,y)$ はネットワークの最適出力として、高品質の再構成イメージが取得できる。

図3(b)にDIP法を実行するために使用した深層学習モデルU-netを示す。U-netモデルは⁷、優れた特徴抽出能力とピクセルレベルのエッジ検出を持ち、比較的シンプルで訓練が容易であるため、医療画像、衛星画像などの分野で広く使用されている^{8,9}。本研究では、入力層、エンコーダ層、スキップ接続、デコーダ層、出力層から構成された10層のU-netモデルを使用し、入力層に、DGI法による得た再構築イメージ、ランダムパターンと後方散乱光強度を入れる。エンコーダ層で5つの畳み込み層とプーリング層で構成され、U-netの特徴の一つであるスキップ接続により、エンコーダとデコーダの間で接続を行い、イメージのより多くの情報を保持する。デコーダ層は4つの逆畳み込み層と畳み込み層で構成され、出力層はモデルの予測結果を出す。

(a)

Algorithm 1 DIP algorithm

```

1: procedure GIOCT ( $\tilde{G}'(x,y), P_i, I_i$ )
2:   initialization: a randomly initialized network  $f_\theta, T = 10^{-9}, L = 400$ 
3:   for  $L = 1, 2, 3 \dots N$  do
4:      $\tilde{I}_i = P_i f_\theta(\tilde{G}'(x,y))$ 
5:      $f_\theta \leftarrow \text{ADAM}(\text{MSE}(\tilde{I}_i, I_i) + T[f_\theta(\tilde{G}'(x,y))])$ 
6:   end for
7:    $\tilde{G}'(x,y) = \frac{1}{m} \sum_{i=1}^m I_i^*(P_i - \langle P_i \rangle)$ 
8: end procedure

```

(b)




Figure 3: (a) Depicts the algorithm for the function used to reconstruct the object image; (b) Illustrates a 10-layer U-net model composed of input, encoder, skip connection, decoder, and output layers.




Figure 4 Simulation results of the GI-OCT with DIP algorithm at different iterations.




Figure 5 Experiment results of the GI-OCT algorithm (a) without U-net and (b) with U-net processes.

3. 結果と考察

実験とシミュレーションでは、図1の実験システムに示しているアルファベット文字「E」を被測定物として使用された。ランダムパターンを 64×64 に設定し、つまり、出力物体イメージも同じサイズになる。GI-OCT法を用いた400回の計算（4096回の計算で高品質なイメージが取得できる）による取得したシミュレーション結果は図4に示し、図4(a)はニューラルネットワークなしの場合、SSIM値は-0.088であった。SSIMは画像の品質評価でよく使用される指標であり、画像の品質が高い場合、SSIMの値が1に近づく。図4(b)~(c)にニューラルネットワークを使用した結果であり、それぞれ1回、100回と200回の反復訓練を行った再構築イメージである。1回の反復で-0.001の低いSSIM値を取得し、100回と200回の反復では0.654と0.904のSSIM値を取得した。ニューラルネットワークなしとニューラルネットワークありの1回反復訓練の

結果を比較してみると、ニューラルネットワークありの 100 回と 200 回反復訓練の結果には大きな違いがある。従来の GI や深層学習なしの処理法で取得したイメージから被測定物の認識が難しくなり、今回の深層学習ありの GIOCT 法により少ない計測回数で高品質なイメージを再構成できた。また、400 回の計算だけ計測時間を 90%に低減できるという根拠が得られた。図 5 に(a)深層学習ありと(b) 深層学習なしの条件下での再構築イメージ結果を示す。実験では、被測定物とした文字「E」は完全に認識可能となり、ノイズが周囲に広がっていることも確認できる。0.1 の SSIM 値を取得し、これは散乱媒質による多重散乱光の影響とみられる。

4. まとめ

本研究では、測定回数を減らすために GI-OCT 法を提案した。深層学習の高いノイズ特性を用い、再構成イメージの品質を改善できた。さらに、再構成するために必要な測定回数を低減した。シミュレーションで物体イメージの再構成を達成し、10%のサンプリングレートで明瞭なイメージを得ることができた。これにより、64×64 サイズでの再構成に必要な測定回数が大幅に削減された。200 回の反復で再構成イメージを強化することが確認された。同様に、実験でも短時間計測により物体イメージの再構築が実現でき、散乱媒質による多重散乱光の影響により、シミュレーションと同じ品質を取得できなかった。本研究での発想は、従来のレーザ走査型ライダーを用いた大気リモートセンシングにおいて、大気浮遊粒子、風やガスのリアルタイムイメージングに期待でき、イメージングライダーの進化につながる。今後、本 GI-OCT 法を用いて、散乱媒質の三次元メーをリアルタイムで計測する予定である。

参考文献

- 1) D. Huyan, et al.: APL Photonics **7** (2022) 086104.
- 2) D. Huyan, et al.: Photonics **10** (2023) 146.
- 3) V. Lempitsky, et al: 2018 IEEE/CVF Conf. on Comput. Vis. Pattern 380 Recognit. **128**, (2018) 9446.
- 4) R. Leitzgeb, et al.: Opt Express. **11** (2003) 889.
- 5) B.I. Erkmen et al: Adv. Opt. Photon. **2**, (2010) 405.
- 6) F. Ferri et al.: Phys. Rev. Lett. **104**, (2010) 1.
- 7) O. Ronneberger, et al.: in IEEE Access, **9** (2015), 234.
- 8) R. Azad, et al.: Sci. Reports **7**, (2022) 1.
- 9) N. J. Singh et al.: Arab. J. for Sci. Eng. **48**, (2023) 1193.