

誤差逆伝播法を用いたゴーストイメージング投影パターンの最適化 Optimization of Illuminated Patterns for Ghost Imaging Using Back Propagation

星 郁雄[†] 下馬場 朋禄[†] 角江 崇[†] 伊藤 智義[†]
Ikuro Hoshi Tomoyoshi Shimobaba Takashi Kakue Tomoyoshi Ito

1. 研究背景と目的

ゴーストイメージング[1,2]はシングルピクセルイメージング画像再構成手法の一つである。複数の受光素子から構成された二次元受光素子を用いる通常のイメージングとは異なり、単一の受光素子を用いてイメージングを行う。図1のように、被写体に複数のパターンをプロジェクタにより撮影対象に投影し、その透過光や反射光を単一受光素子でパターン毎に検出する。その検出光と投影パターンを既知情報として、計算処理により再構成画像を得る。

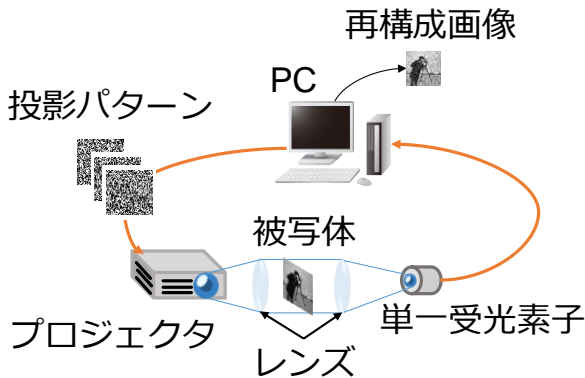


図1 ゴーストイメージングの概略図

ゴーストイメージングは単一の受光素子を用いる特徴から、高感度なイメージングが可能、小型かつ安価、幅広い波長帯でイメージングが可能である。また、ゴーストイメージングは相関計算を用いて画像を再構成するのでノイズに強い利点を持つ。しかし欠点として、再構成画像がノイズの多いざらついた画像になるほか、投影パターン数が少ないと更に画質が低下してしまう。

そこで我々は、この欠点を克服するために誤差逆伝播法を用いた投影パターン最適化を提案する。本稿では、提案手法実証のため、Python のディープラーニング向けフレームワークである Keras を用いて投影パターン最適化を行い、その評価までを行う。

2. 提案手法

誤差逆伝播法とは、一般的に機械学習分野で用いられる最適化手法である。対象となる演算から出力を求め、その出力と目標データとの誤差を損失関数で定義する。その誤差から、演算をさかのぼるように各パラメータの勾配を求めることで値を更新していく。最初の演算を順方向と考えると、出力方向から誤差が逆方向に伝播していく様子から誤差逆伝播法と呼ばれている。誤差逆伝播法では、微分の連鎖律を用いて局所的に誤差を伝えていくため、誤差逆伝

[†] 千葉大学大学院工学研究院

Graduate School of Engineering, Chiba University

播法を用いるための条件として、対象の演算が全体を通して微分可能である必要がある。

ここでゴーストイメージングの再構成計算を式(1)に示す。本稿では Differential Ghost Imaging(DGI)[2]と呼ばれる再構成計算を採用している。

$$\langle O_i(x, y) \rangle = \langle S_i \cdot I_i(x, y) \rangle - \frac{\langle S_i \rangle}{\langle R_i \rangle} \langle R_i \cdot I_i(x, y) \rangle \quad (1)$$

$\langle O_i(x, y) \rangle$ は再構成画像の各画素の値、 $I_i(x, y)$ は投影パターンの画素値を表している。また、添え字の*i*は投影パターンの番号となっていて、 $\langle \rangle$ はアンサンブル平均を表す。 S_i は取得した光強度、 R_i は投影パターン全体の光強度でそれぞれ式(2),(3)で表される。ここで、 $T(x, y)$ は被写体の光強度を正規化した係数である。

$$S_i = \iint T(x, y) \cdot I_i(x, y) dx dy \quad (2)$$

$$R_i = \iint I_i(x, y) dx dy \quad (3)$$

式(2),(3)は全画素値に対して積分を実行しているため演算としては加算処理になる。よって全ての演算が四則演算で行われているのでこの計算式は微分可能であり誤差逆伝播法を用いてパラメータの最適化が可能である。

従来のゴーストイメージングでは、投影パターンは乱数を用いてランダムに決定されたバイナリパターンを用いることが一般的であった。本稿では投影パターンをゴーストイメージングにおけるパラメータと考え、前述の誤差逆伝播法を用いて更新し最適なパラメータを取得する。

3. 実験と評価

実際に提案手法で最適な投影パターンを取得可能か確認するため、Keras のカスタムレイヤ機能を用いることで式(1)~(3)を、投影パターンをパラメータとしたオリジナルレイヤとして実装し実験を行った。開発環境には Python3.5.4 を用いた。画像データは 32×32 [pix] の cifar-10 データセット[3]をグレースケール変換した画像セットを用いた。訓練データを 50,000 枚、バリデーションデータ 5,000 枚、テストデータ 5,000 枚に分割し用いた。投影パターン枚数は 333 枚として、損失関数には元画像との平均二乗誤差を用いた。また、オプティマイザには Adam を用いてパラメータの更新を行った。

パラメータの学習は[4]と同様二段階に分割して行った。一段階目の学習では、初期値を[0,1]区間の乱数で設定し、そのまま学習を行った。二段階目の学習では、1 段階目で学習したパラメータを初期値として用いて、更に式(4)に示すバイナリ化の制約をパラメータに課すことで投影パターンの各画素を 0 と 1 のバイナリ値として再学習する。最後

に整数値の 0 と 1 に丸め込んだ。二段階に分割した理由は、初めから 0 と 1 のバイナリ値に学習させようとする場合、0 の要素が増加することで学習が進まなくなることを避けるためである。式(4)の N はパターンの総数、 X, Y は画像サイズである。

$$\sum_i \sum_x \sum_y (I_i(x, y))^2 (1 - I_i(x, y))^2 \quad (4)$$

図 2 にランダムなパターンと学習されたパターンの一例を示す。それぞれのパターンはすべて 32×32 [pix] のものとなっている。ランダムなパターンでは、0 と 1 が一様に分布しているように見えるが、学習済みパターンではパタ



図 2 パターンの比較画像

ーンごとに明確な偏りがみられた。

次に、再構成画像の画質比較を図 3 に示す。評価用画像として、cifar-10 に含まれていない二値の正方形画像と、cifar-10 テストデータからランダムに抽出した馬の画像を用意した。ランダムパターンを用いて再構成した画像は、パターン投影枚数が少ないため非常に不鮮明な再構成画像となっている。一方、学習済みのパターンを用いて画像を再構成した場合には、ランダムパターンを用いた場合よりも、大幅にノイズが軽減され比較的鮮明な再構成画像が確認できた。また、このことから学習済みパターンは画質を向上させる方向に正しく学習されていたことが確認できた。

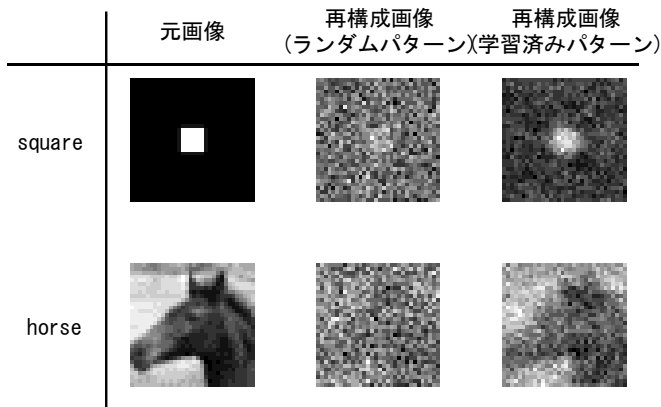


図 3 再構成画像の比較

表 1 には図 3 の再構成画像における定量評価を示す。評価には PSNR と SSIM を用いた。どちらの評価指標を用いた場合でも、学習済みパターンを用いた場合の方が画質の向上がみられることが確認できる。

表 1 再構成画像の定量評価

画像	パターン	PSNR[dB]	SSIM
square	ランダム	6.89	0.05
	学習済み	11.67	0.11
horse	ランダム	11.16	0.20
	学習済み	15.17	0.41

再構成画像で、horse の画質向上率が高いことに関しては、square が全体的にスパースな画像となっているためノイズにより元画像との差異が大きく画質評価指標の値が低いことや、訓練データに cifar-10 のような階調を持つ画像を用いたことなどが原因だと考えられる。特に、訓練データに関しては mnist などの階調を持たない画像データセットを合わせて学習させることでより汎化した性能を見込めると考えている。

4. まとめ

本稿では、誤差逆伝播法を用いたゴーストイメージング投影パターンの最適化を提案し、実験結果から、DGI を用いる場合に学習されたパターンを投影する事によって画質が改善されることが確認できた。今後の課題として、誤差逆伝播法を DGI に用いた場合の勾配計算定式化や、異なるデータセットを用いた場合、損失関数を変更した場合での変化の確認、ほかの再構成手法との比較評価などが挙げられる。

謝辞

本研究の一部は双葉電子財団博士後期課程奨学金および矢崎科学技術振興記念財団の助成により行われました。ここに深く感謝致します。

参考文献

- [1] J. H. Shapiro, "Computational ghost imaging," Phys. Rev. A **78**(6), 061802(2008).
- [2] F. Ferri, D. Magatti, L. A. Lugiato, and A. Gatti, "Differential ghost imaging," Phys. Rev. Lett. **104**(25), 253603 (2010).
- [3] A. Krizhevsky. "Learning multiple layers of features from tiny images," Tech Report (2009).
- [4] C. F. Higham, R. Murray-Smith, M. J. Padgett, and M. P. Edgar, "Deep learning for real-time single-pixel video," Sci. Rep. **8**, 2369 (2018).