

# 動画の圧縮イメージングのための 慣性項付き深層展開ネットワーク

## Deep Unfolding Network with Inertial Terms for Video Snapshot Compressive Imaging

岩永 将樹<sup>†</sup>

長沼 一輝<sup>‡</sup>

早川 諒<sup>‡</sup>

<sup>†</sup>東京農工大学 工学部

<sup>‡</sup>東京農工大学 大学院工学研究院

Masaki IWANAGA<sup>†</sup>

Kazuki NAGANUMA<sup>‡</sup>

Ryo HAYAKAWA<sup>‡</sup>

<sup>†</sup>Faculty of Engineering, Tokyo University of Agriculture and Technology

<sup>‡</sup>Institute of Engineering, Tokyo University of Agriculture and Technology

**アブストラクト** 動画 SCI (Snapshot Compressive Imaging) は、高フレームレートの動画を時間的に圧縮された観測から復元するための技術である。近年では、学習済みのノイズ除去器を最適化アルゴリズムに組み込むことで復元精度を改善する PnP (Plug-and-Play) が注目されている。本研究では、まず、PnP を適用した ADMM (Alternating Direction Method of Multipliers) による動画 SCI に対して、収束を加速するための AA (Anderson Acceleration) を導入する。得られたアルゴリズムのパラメータを深層展開に基づいて学習することで、少ない反復数でも高精度に復元できるアルゴリズムの構築を目指す。計算機シミュレーションによって、従来の PnP-ADMM と比較して最終的な復元精度が向上することがわかった。

## 1 はじめに

動画 SCI (Snapshot Compressive Imaging) は、複数フレームからなる動画を 1 つの画像に圧縮したものから復元する技術である。復元のためのアプローチの 1 つとして、学習済みのノイズ除去器を最適化アルゴリズムに組み込む PnP (Plug-and-Play) がある [1]。PnP に基づく手法では、ノイズ除去器のパラメータとしてノイズ除去の強さを指定する必要がある。復元アルゴリズムの各反復で適切なノイズ除去の強さを定めるために、深層展開を応用してその値を学習する手法が提案されている [2]。

本研究では、PnP に基づく動画 SCI のための深層展開ネットワークに対して AA (Anderson Acceleration) を適用した手法を提案する。AA は反復アルゴリズムの収束を加速するための手法であり、過去の複数の反復の情報をを用いて次の反復を計算する [3]。過去の反復をどの程度利用するかは加重係数を用いて決定される。提案する深層展開ネットワークでは、従来のネットワークで学習して

いたノイズ除去の強さだけでなく、加重係数も学習パラメータとして学習する。計算機シミュレーションの結果、従来の深層展開ネットワークと比較して、提案手法による復元精度の向上が見られた。

## 2 研究背景

### 2.1 動画 SCI のための PnP-ADMM

動画 SCI では、サイズが  $N_x \times N_y$  でフレーム数  $N_t$  の動画が 1 枚の観測画像に圧縮されるモデルとして

$$\mathbf{y} = \Phi \mathbf{x} + \mathbf{e} \quad (1)$$

を考える。ここで、 $\mathbf{y} \in \mathbb{R}^{N_x N_y}$  は観測画像、 $\mathbf{x} \in \mathbb{R}^{N_x N_y N_t}$  は未知動画、 $\Phi \in \mathbb{R}^{N_x N_y \times N_x N_y N_t}$  は圧縮時のマスクの情報から構成される観測行列、 $\mathbf{e} \in \mathbb{R}^{N_x N_y}$  はノイズである。未知動画を復元するための最適化問題として、

$$\underset{\mathbf{x}, \mathbf{v}}{\text{minimize}} \frac{1}{2} \|\mathbf{y} - \Phi \mathbf{x}\|_2^2 + \lambda R(\mathbf{v}) \text{ s.t. } \mathbf{v} = \mathbf{x} \quad (2)$$

がある [1]。第一項の  $\frac{1}{2} \|\mathbf{y} - \Phi \mathbf{x}\|_2^2$  はデータ忠実項、第二項の  $R(\mathbf{v})$  は正則化関数、 $\lambda$  は正則化パラメータである。

式 (2) の最適化問題に対する ADMM (Alternating Direction Method of Multipliers) に、ノイズ除去の強さを表すパラメータ  $\theta_k$  を含む学習済みノイズ除去器  $\mathcal{D}_{\theta_k}$  を PnP によって組み込むと、その更新式は

$$\mathbf{x}^{k+1} = \mathbf{v}^k - \mathbf{u}^k + \Phi^\top \Psi (\mathbf{y} - \Phi (\mathbf{v}^{k+1} - \mathbf{u}^{k+1})) \quad (3)$$

$$\mathbf{v}^{k+1} = \mathcal{D}_{\theta_k} (\mathbf{x}^{k+1} + \mathbf{u}^k) \quad (4)$$

$$\mathbf{u}^{k+1} = \mathbf{u}^k + \mathbf{x}^{k+1} - \mathbf{v}^{k+1} \quad (5)$$

となる [2]。ここで  $\Psi = \text{diag}(\frac{1}{\rho + \psi_1}, \dots, \frac{1}{\rho + \psi_{N_x N_y}})$  であり、 $\rho$  はパラメータ、 $\psi_n$  は  $\Phi \Phi^\top$  の  $n$  番目の対角成分である。

---

**Algorithm 1** PnP-ADMM with AA

---

**Require:**  $\Phi, \mathbf{y}, \rho, \theta_k > 0, K, m \in \mathbb{N}_+$ **Ensure:**  $\mathbf{x}^K$ 

- 1: Initial:  $\hat{\mathbf{v}}^0 = \Phi^\top \mathbf{y}, \hat{\mathbf{u}}^0 = \mathbf{0}$
  - 2: Compute  $\psi_n (n = 1, \dots, N_x N_y)$
  - 3:  $\Psi = \text{diag} \left( \frac{1}{\rho + \psi_1}, \dots, \frac{1}{\rho + \psi_{N_x N_y}} \right)$
  - 4: **for**  $k = 0, 1, \dots, K - 1$  **do**
  - 5:    $\mathbf{x}^{k+1} = \hat{\mathbf{v}}^k - \hat{\mathbf{u}}^k + \Phi^\top \Psi (\mathbf{y} - \Phi (\hat{\mathbf{v}}^{k+1} - \hat{\mathbf{u}}^{k+1}))$
  - 6:    $\mathbf{v}^{k+1} = \mathcal{D}_{\theta_k} (\mathbf{x}^{k+1} + \hat{\mathbf{u}}^k)$
  - 7:    $\mathbf{u}^{k+1} = \hat{\mathbf{u}}^k + \mathbf{x}^{k+1} - \hat{\mathbf{v}}^{k+1}$
  - 8:    $\hat{\mathbf{v}}^{k+1} = \mathbf{v}^k + \sum_{i=0}^{m-1} c_i^{(k)} (\mathbf{v}^{k-i} - \mathbf{v}^{k-i-1})$
  - 9:    $\hat{\mathbf{u}}^{k+1} = \mathbf{u}^k + \sum_{i=0}^{m-1} c_i^{(k)} (\mathbf{u}^{k-i} - \mathbf{u}^{k-i-1})$
  - 10: **end for**
- 

## 2.2 Anderson Acceleration (AA)

AA は、反復アルゴリズムにおいて過去の複数の更新結果を次の反復に利用し、収束を加速させる手法である [3]. 各反復における更新が  $\mathbf{z}^{(k+1)} = q(\mathbf{z}^{(k)})$  のように書けるとき、AA を適用した場合の更新式は

$$\mathbf{z}^{(k+1)} = q(\mathbf{z}^{(k)}) + \sum_{i=1}^{m-1} c_i^{(k)} (\mathbf{z}^{(k-i)} - \mathbf{z}^{(k-i-1)}) \quad (6)$$

となる. ここで、 $c_i^{(k)}$  は過去の変数をどの程度利用するかを決める加重係数であり、 $m$  は利用する過去の変数の個数である.

## 3 提案手法

本研究では、2.1 節で述べた PnP-ADMM に 2.2 節の AA を適用して得られるアルゴリズム (Algorithm 1) に対し、ノイズ除去器のパラメータであるノイズ除去の強さ  $\theta_k$  と加重係数  $c_i^{(k)}$  を深層展開で学習する. 学習のための損失関数は原動画と復元動画の平均二乗誤差とする.

## 4 実験

実験では、 $256 \times 256$  の 6 フレーム動画に対し、標準偏差  $\sigma = 0.01$  のガウスノイズを加えることで観測画像を生成した. ADMM のパラメータは  $\rho = 0.01, K = 30$  とし、PnP で組み込むノイズ除去器としては FastDVDNet を採用した. AA の適用に際しては  $m = 5$  とした. 提案手法ではノイズ除去の強さ  $\theta_k$  と加重係数  $c_i^{(k)}$  を学習し、従来の PnP-ADMM に対してはノイズ除去の強さ  $\theta_k$  のみを学習した. 学習率は 0.01 とした.

6 つのテストデータについて、AA を用いた場合と用いなかった場合の反復ごとの PSNR (Peak Signal-to-Noise Ratio) を図 1 に示す. 最終的な反復結果は AA を用いた方が PSNR が約 1.52 dB 高く、また SSIM (Structural

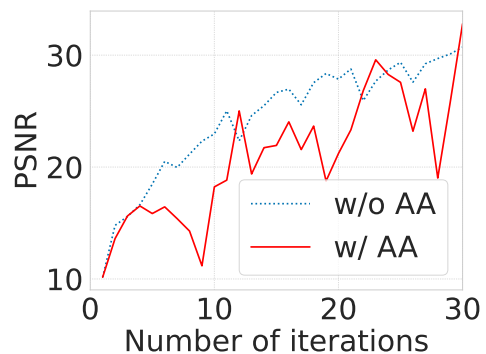


図 1: 反復数に対する平均 PSNR の推移. 最終的な PSNR と SSIM は提案手法がそれぞれ 32.81 dB, 0.94, 既存手法が 31.29 dB, 0.92 となった.



(PSNR [dB], SSIM) (39.21, 0.98) (41.82, 0.99)  
(a) 元フレーム (b) AA なし (c) AA あり

図 2: 動画 SCI の結果.

Similarity Index Measure) も約 0.02 高い結果となった. これにより、AA における加重係数の学習によって PnP-ADMM の最終的な復元精度が向上することがわかった.

あるデータに対して AA を用いず復元した動画 SCI の結果を図 2 (b) に、用いて復元した結果を図 2 (c) に示す. これらの結果から、AA を用いた手法が靴の模様などの詳細成分を復元できたことがわかる.

**謝辞** 本研究の一部は、(公財) マツダ財団研究助成および JSPS 科研費 JP24K17277 の助成を受けたものである.

## 参考文献

- [1] Xin Yuan, David J., Brady and Aggelos K. Katsaggelos, “Snapshot compressive imaging,” *IEEE Signal Process. Mag.*, vol. 38, no. 2, pp. 65–88, Mar. 2021.
- [2] T. Matsuda, R. Hayakawa, and Y. Iiguni, “Deep unfolding-aided parameter tuning for plug-and-play-based video snapshot compressive imaging,” *IEEE Access*, vol. 13, pp. 24867–24879, Feb. 2025.
- [3] Dawei Wang, Yunhui He1, and Hans De Sterck, “On the asymptotic linear convergence speed of anderson acceleration applied to ADMM,” *J.Scientific Comput.*, vol. 88, no. 38, Jun. 2021.