

一般セッション(ポスター講演)| FS フォーカストセッション「AIエレクトロニクス」：FS.1 フォーカストセッション「AIエレクトロニクス」

■ 2023年9月19日(火) 16:00 ~ 18:00 | 会 P06 (熊本城ホール)

■ [19p-P06-1~8] FS.1 フォーカストセッション「AIエレクトロニクス」

[19p-P06-1] 単電子リザーバコンピューティング回路の学習機能に関する検討

○渡邊 隼弥¹、大矢 剛嗣¹ (1.横国大院理工)

[19p-P06-2] 振動変形を検出可能な物理リザーバの開発(1)

○(M1)水野 敦浩¹、長谷川 剛¹ (1.早大先進理工)

[19p-P06-3] Ag ドープ Ta₂O₅薄膜を用いた物理リザーバの基本動作特性評価

○林 泰甫¹、伊藤 達也¹、神田 侑奈¹、郷原 李紗¹、長谷川 剛¹ (1.早大先進理工)

[19p-P06-4] Delaying and multiplying Analog Input Signal at In-Materio Reservoir Computing

○(M1)Takuya Kawabata¹, Yuki Usami¹, Hirofumi Tanaka¹ (1.Kyutech)

[19p-P06-5] 磁気光学回折型ディープニューラルネットワークの最適化

○(M1C)赤川 怜央¹、坂口 穂貴¹、野中 尋史²、栗野 博之³、チャフィ ファティマ ザーハラ¹、石橋 隆幸¹ (1.長岡技科大、2.愛知工大、3.豊田工大)

[19p-P06-6] モンテカルロ法による磁気光学回折型ディープニューラルネットワークの学習(1)

○大谷 陸¹、坂口 穂貴¹、野中 尋史²、栗野 博之³、石橋 隆幸¹、チャフィ ファティマ ザーハラ¹ (1.長岡技大、2.愛知工大、3.豊田工大)

[19p-P06-7] 磁気光学効果を利用した光回折型ディープニューラルネットワークの磁区書き込み誤差に関する評価

○(M1C)池田 朱莉¹、坂口 穂貴¹、野中 尋史²、栗野 博之³、チャフィ ファティマ ザーハラ¹、石橋 隆幸¹ (1.長岡技科大、2.愛知工大、3.豊田工大)

◆ 英語発表

[19p-P06-8] Training of MO Diffractive Deep Neural Networks by Monte Carlo Method (2)

○FatimaZahra Chafi¹, Riku Oya¹, Hotaka Sakaguchi¹, Hirofumi Nonaka², Hiroyuki Awano³, Takayuki Ishibashi¹ (1.Nagaoka Univ. Tech., 2.Aichi Inst. Tech, 3.Toyota Tech. Inst)

単電子リザーバコンピューティング回路の学習機能に関する検討

Investigation of Learning Function in Single-Electron Reservoir Computing Circuit

○渡邊 隼弥, 大矢 剛嗣 (横国大院理工)

○Shunya Watanabe, Takahide Oya (Yokohama National Univ.)

Email: watanabe-shunya-cb@ynu.jp

1. 研究背景・目的

近年、ナノテクノロジーの発展により単電子回路を含め、さまざまなナノデバイスが登場している。単電子回路は電子を1個単位で制御できる回路である。単電子回路の非線形動作などの特徴を応用した研究が行われているが、未だ単電子回路に適した情報処理手法は確立されていない。

単電子振動子という単電子回路素子はニューロンに似た挙動をする^[1]。これを踏まえ本研究ではリカレントニューラルネットワーク(RNN)の一種であるリザーバコンピューティング(RC)^[2]に着目している。

RCは入力層、リザーバ層、出力層の3層で構成される。RCは出力層の重みのみが学習され、リザーバ層の重みは学習されないことが特徴である。そのためリザーバ層を非線形な物理系で置き換えることが可能で、様々な研究^[3]が報告されている。

ニューロンに似た動作をする単電子振動子と物理系で置き換えることのできるリザーバ層を持つRCの組み合わせは相性が良いと考えられる。本研究は単電子回路の情報処理手法の一つとして、単電子振動子をリザーバ層に用いた単電子RC回路の設計を目的とする。

2. 研究内容

前回、単電子RC回路(Fig. 1)に用いていた単電子振動子を多重トンネル接合型単電子振動子に変更したこと、それにより波形予測において学習性能が向上したことについて報告した^[4]。

今回は単電子RC回路の出力層における学習機能について検討したことを報告する。具体的には、次の2点について検討した。1) 出力層への接続本数の変更。2) デイレイ機能の導入による学習への効果。1) について、接続本数の増加によりリザーバ層からの信号の量が増えることで、より高精度な学習が期待できる。2) について、デイレイ機能はリザーバ層からの信号を

遅らせて出力に伝える機能である。タイミングが変化した信号を集めて出力することで、より複雑な出力を生成でき、より複雑な学習タスクへの対応が期待できる。詳細は講演にて述べる。




Fig. 1 Schematic of single-electron reservoir computing circuit. The reservoir layer utilizes positive-biased single-electron oscillators (SEOs) or multiple-tunnel-junction SEOs (MJSEOs), represented by filled circles, and negative-biased SEOs or MJSEOs, represented by empty circles. The input layer is equipped with voltage sources to apply trigger voltages. In the output layer, the signals from the reservoir layer are multiplied by their respective weights and then summed up using the following formula:

$$\text{Output} = \sum_i w_i x_i \quad \left(\begin{array}{l} w_i = \text{Weights} \\ x_i = \text{Signals} \end{array} \right).$$

【参考文献】

- [1] T. Oya, et al, Journal of Unconventional Computing, vol.1, pp. 177-194, 2005.
- [2] B. Schrauwen, et al, ESANN'2007 proceedings, pp. 471-473, 2007.
- [3] K. Nakajima, et al., Sci. Rep. **5**, No. 10487, 2015.
- [4] 渡邊隼弥, 大矢剛嗣, 第 70 回応用物理学会春季学術講演会, 18a-D221-2, 2023.

【謝辞】

本研究の一部は JSPS 科研費・基盤研究(A)(JP23H00169), (B)(JP19H02545)、および(公財)栢森情報科学振興財団の助成を受け実施された。

振動変形を検出可能な物理リザーバーの開発(1)

Toward development of a physical reservoir that detects vibration (1)

早大先進理工 ○(M1)水野敦浩, 長谷川剛

Waseda Univ., °Atsuhiko Mizuno, Tsuyoshi Hasegawa

E-mail: baseballmizuno1@akane.waseda.jp

はじめに：近年、物理リザーバーを用いた手書き文字認識や音声認識に関する研究が盛んに行われている。これらの研究の多くでは、画像データや音声データを電圧信号に変換し、リザーバーに入力している。しかしこの信号変換は、情報処理の高速化の妨げとなったり、消費電力の増大を招く可能性がある。特にエッジデバイスとして用いる場合には、様々な形態の信号を直接リザーバーに入力できることが望ましい。そこで我々は、基板変形によって非線形特性が変化する物理リザーバーを開発することで、音声信号の直接入力を目指している。今回は、振動によって容易に変形する PET 基板上に Ag_2S リザーバーを作製し、その基本特性を評価した。

実験：PET 基板上の 4 つの $\text{Au}(100\text{nm})/\text{Ti}(10\text{nm})$ 電極に囲まれた $400\mu\text{m}$ 四方の領域に $\text{Ag}(20\text{nm})$ を蒸着し、気相硫化を行うことで多結晶 Ag_2S 薄膜を作製した。1 つの電極に三角波の電圧を入力し、他の 3 つの電極からの出力電圧を測定することで、PET 基板上の Ag_2S リザーバーの特性の評価を行った。

結果：振幅 5V、周波数 1,000Hz の三角波を入力した場合の出力電圧測定例を Fig. 1a に示す。入力履歴にも依存して出力が変化していることが分かる。短期記憶特性の周波数および入力電圧の振幅依存性測定結果を Fig. 1b に示す。振幅に対する依存性は明瞭には観測されなかったが、いずれの振幅でも 1,000Hz 付近で最大の短期記憶容量が得られた。現在、Fig. 1c のようなりザーバー部分が振動しやすい素子を用いて、振動変形によって非線形特性が変化するか否かの検証実験を行っている。当日は、これらの結果をまとめて報告する。




Fig.1 (a) Change in input voltage and output voltage. (b) Short-term memory capacity as a function of voltage and frequency. (c) Device fabricated to detect vibration.

Ag ドープ Ta₂O₅ 薄膜を用いた物理リザーバーの基本動作特性評価

Characteristics of a Physical Reservoir Using a Ag-doped Ta₂O₅ Thin Film

早大先進理工 ○(B) 林 泰甫, 伊藤 達也, 神田 侑奈, 郷原 李紗, 長谷川 剛

Waseda Univ., °Taisuke Hayashi, Tatsuya Ito, Yuna Kanda, Risa Gobara, Tsuyoshi Hasegawa

E-mail: h_taisuke@moegi.waseda.jp

はじめに：最近、イオン分布が作る内部電場を利用した物理リザーバーの開発が進められている。我々の研究室でも、多結晶硫化銀薄膜内における銀イオンの移動を利用した物理リザーバーの動作を実証してきた[1]。本研究では、抵抗変化素子の材料として使われてきた Ag ドープ Ta₂O₅ 薄膜を用いて物理リザーバーを作製し、その基本動作特性を評価した。

実験方法：SiO₂ 基板上に、直径 400μm の円周上に等間隔で先端が配置された 4 つの電極を作製した。この直径 400μm の領域に Ag ドープ Ta₂O₅ 薄膜をスパッタ成膜した。成膜には Ag と Ta₂O₅ の混合ターゲットを用いた。Ag と Ta₂O₅ の混合比（重量比）が 2:1, 1:1, 1:4, 1:8 の 4 種類のターゲットを用いることで、リザーバー動作の Ag ドープ量依存性を測定した。測定は室温・大気中で行った。乱数で正負を決めた三角波列を一つの電極に入力し、残りの 3 電極で出力を測定した。周波数および電圧値を変数として、短期記憶特性を評価した。

結果と考察：Fig.1 (a)に短期記憶容量の周波数および Ag-Ta₂O₅ 混合比依存性を示す。混合膜の膜厚はいずれも 10nm、入力電圧振幅は 2V である。Ag のドープ量が多いほど短期記憶容量が大きくなっている。また、極大値を示す周波数も高くなっている。これらは Ag イオンの量が多いほど大きな内部電場を形成できるため、および、拡散現象が早く飽和状態に達するためであると考えられる。短期記憶タスクについて、決定係数の遅延依存性の測定例を Fig.1 (b)に、ターゲット波形と合成波形の比較例を Fig.1 (c)に示す。混合膜厚および入力電圧も変数として測定を行ったが、周波数ほどの依存性は確認できなかった。このほか、パリティチェックタスクも行った。当日は、硫化銀薄膜を用いた物理リザーバーとの比較結果なども含めて報告する。




Fig. 1 Results of short-term memory task. (a) Memory capacity measured for four Ag-doped Ta₂O₅ physical reservoirs with different Ag-Ta₂O₅ ratio. (b) Change in determination coefficient measured with 4,000 Hz and 2V. (c) Target waves (red) and synthesized waves (blue) in the STM task for delay 1 and delay 2.

[1] Y. Shimizu et al., JJAP 62, SG1001 (2023). K. Minegishi et al, JJAP 62, SG1032 (2023).

遅延信号を用いたインマテリアルリザーバー演算素子に関する研究

Delaying and multiplying Analog Input Signal at In-Materio Reservoir Computing

九工大 生命体工¹, 九工大 Neumorph センター² °(M1)川端 拓哉¹, 宇佐美 雄生^{1,2}, 田中 啓文^{1,2}

LSSE Kyushu Inst. Tech. (Kyutech)¹, Neuromorphic Center, Kyutech²,

°Takuya Kawabata¹, Yuki Usami^{1,2}, Hirofumi Tanaka^{1,2}

E-mail: tanaka@brain.kyutech.ac.jp

1. 研究背景

近年, 消費エネルギー削減限界の理由の一つとしてノイマンボトルネックが指摘され, その解消のために注目されているのが, インメモリコンピューティング(IMC)と呼ばれる概念である[1]. リザーバーコンピューティング(RC)は, 機械学習領域におけるIMCの主要な適用例とされており, RCの一部を物理系で置き換えた, 物理RCも多く報告されている. インマテリアルリザーバーコンピューティング(IMRC)もその一種である. 現状, 高度なRCを行うにはリザーバー層の大規模化が必要となる. また, マテリアルリザーバー(MR)を含む多くの物理リザーバーでは, 作製後における回路制御が難しい. そのため, 本研究では物理RCに対する小規模かつ制御可能な補助機構の開発を目指した.

2. 実験方法

先行研究では, RCにおいて入力データに対して, シフトレジスタ由来の遅延を用いた前処理を加えることで, RCの性能向上が確認された[3]. 本研究では, この前処理をコンピュータにより行い, IMRCに入力し, その演算性能変化を確認した. また, 図1(b)に示すオールパスフィルタ(APF)による同前処理を用いて, 性能変化を調べた. 本研究ではMRとして, 128電極を有する Ag_2Se ナノワイヤランダムネットワークデバイスを用いた[2]. 約80パターンの遅延処理に対し, その各々の記憶容量(MC)の変化を調べた. その後, APFによる前処理をLTSpiceによるシミュレーションを行い, 得られた遅延処理済み入力データを用いて, MCを計算した. 加えて, 非線形自己回帰移動平均(NARMA)タスクを行い, 遅延処理の演算性能向上に対し有用性を調べた.




図1. 遅延処理の方法: (a)シフトレジスタ, (b)APF

3. 実験結果と考察

図2はIMRCによるMCの結果である. 図2(a)は遅延処理を加えずにIMRCを行った結果であり, 図2(b)は, コンピュータで作成した遅延処理により1ステップずつシフトした計10個の入力信号を用いてIMRCを行った結果である. 評価指標には決定係数 r^2 を使用し, 目標信号とIMRC出力結果の一致度を見た. 学習用データ入力時とテスト用データ入力時, それぞれでの決定係数を r_{train}^2 と r_{pre}^2 とした. 遅延処理導入によりMCが大きく向上していることを確認した. 図3は, APFによる遅延処理で, 計10個の入力信号を用いてIMRCを行った結果である. 図2(b)同様MCの向上が見られ, さらにNARMA10タスクの精度も大幅に向上した.




図2. (a)遅延処理なしの場合の忘却曲線 (b) シフトレジスタによる遅延処理を施した際の忘却曲線




図3. APFを施した際の (a)忘却曲線および (b)NARMA10タスクの結果

4. まとめ

本研究では, 遅延処理のIMRCの演算性能に対する影響を調べ, APFによる遅延処理がRCの性能を向上させることが分かった. 今後, 消費電力の更なる低減を期待しMRとAPFの統合デバイス構築を試みる.

参考文献 [1] Abu Sebastian, et al. Memory devices and applications for in-memory computing. Nature Nanotechnology, Vol. 15, pp. 529–544, 7 2020. [2] Takumi Kotooka, et al. Ag_2Se nanowire network as an effective in-materio reservoir computing device, 2021 (arXiv) [3] T. Kawabata. Private communication,

磁気光学回折型ディープニューラルネットワークの最適化

Optimization of Magneto-Optical Diffraction Deep Neural Networks

長岡技科大¹, 愛知工大², 豊田工大³ 赤川 怜央¹ 坂口 穂貴¹, 野中 尋史², 栗野 博之³,

Fatima Zahra Chafi¹, 石橋 隆幸¹

Nagaoka Univ. Tech.¹, Aichi Inst. Tech.², Toyota Tech. Inst.³, R. Akagawa¹, H. Sakaguchi¹,

H. Nonaka², H. Awano³, F. Z. Chafi¹, T. Ishibashi¹

E-mail: s191001@stn.nagaokaut.ac.jp

【はじめに】

近年、Deep Neural Network(DNN)が注目され、急速な発展を遂げ、画像処理や自然言語処理、音声認識など様々な分野で応用されている。しかし、複雑なモデルでは、処理速度や消費電力の増大が問題となっている。これらの問題を解決するために我々はこれまで、磁気光学効果を利用した光回折型ディープニューラルネットワーク (Magneto-optical Diffractive Deep Neural Network: MO-D²NN)を提案した¹⁾。しかし、MO-D²NNには多くの考慮しなければならないパラメータが存在している。そのため今回は、各層間の距離を変化させ、MO-D²NNの性能評価を行った。

【実験方法】

1 μ m 角の大きさの磁区を 100 $\times$ 100 並べた隠れ層を 2 層としたモデル (Fig.1) を構築し、入力層から 1 層目までの距離 d_1 と 2 層目から出力層までの距離 d_2 を変化させ偏光面の回転角を出力信号として学習を行った。入射光は、波長 532 nm の直線偏光とした。計算には、Python3.9.16 と Tensorflow2.9.2 を使用した。評価は、MNIST の手書き数字データセットに対する分類について行った。

【結果と考察】

入力層から 1 層目までの距離を 2 mm に固定し、2 層目から出力層までの距離を 0 mm から 5 mm 変化させて学習した時のテスト画像に対する正解率の変化を Fig.2 に示す。距離が 0.5 mm から 2 mm では正解率が 70%以上であるが、それ以上距離を離すと正解率は大きく減少した。この結果は、MO-D²NNの精度の向上のためには、層間距離の最適化が重要であることを示している。その他の層間距離の変化に対する正解率の変化等、詳細は当日報告する。




Fig.1 A schematic drawing of MO-D²NN




Fig.2 Accuracy for handwritten digits, depending on the distance d_2 .

【謝辞】 本研究の一部は JSPS 科研費 JP23H04803 の助成を受けたものです。

【参考文献】 1) T. Fujita et al., Optics Express, Vol. 30, 36889 (2022)

モンテカルロ法による磁気光学回折型ディープニューラルネットワークの学習(1)


Training of MO Diffractive Deep Neural Networks by Monte Carlo Method (1)

長岡技大¹、愛知工大²、豊田工大³ ○大谷 陸¹、坂口 穂貴¹、野中 尋史²、栗野 博之³、Fatima Zahra Chafi¹、石橋 隆幸¹Nagaoka Univ. Tech.¹, Aichi Inst. Tech.², Toyota Tech. Inst.³ ○R. Oya¹, H. Sakaguchi¹, H. Nonaka²,H. Awano³, F. Z. Chafi¹, T. Ishibashi¹


E-mail: s203207@stn.nagaokaut.ac.jp

【はじめに】近年、画像認識や音声認識、翻訳などさまざまな作業をディープニューラルネットワークによって可能になった。一方、演算処理にかかるエネルギーの増大が問題となっている。そこで我々は計算自体に消費電力を必要としない、磁気光学効果を利用した磁気光学回折型ディープニューラルネットワーク (MO-D²NN) を提案した¹⁾。これまで、隠れ層に用いる磁区パターンは、あらかじめ逆誤差伝搬法を用いて求めていたが、今回は、学習の一部を物理的に行うことを目指し、モンテカルロ (MC) 法による磁区パターンの決定方法について検討した。

【実験方法】設定した MO-D²NN の模式図を Fig.1 に示す。1 μ m 角の磁区を 28 $\times$ 28 並べた隠れ層を 2 層とし、入力層、隠れ層および出力層の間隔はすべて 0.5 mm とした。隠れ層のファラデー回転角を $\pi/2$ rad、入射直線偏光の波長を 633 nm とした。MNIST の手書き数字データセットを入力信号とし、出力光が指定された領域に集光するように磁区パターンを決定した。ランダムに選んだ磁区の磁化が反転したときに、領域内の平均光強度 I_{in} が大きくなる場合と領域外の平均光強度 I_{out} との比 I_{in}/I_{out} が大きくなる場合のみ磁化反転させた。このプロセスを 1000 回繰り返した。

Fig.1 A schematic drawing of MO-D²NN.

【結果と考察】手書き数字 “9” の入力画像について、 I_{in}/I_{out} を磁化反転の試行回数に対してプロットしたグラフを Fig.2 に示す。ランダムに生成された 10 種類の初期磁区パターンについて、試行回数が進むにつれて I_{in}/I_{out} が増加し、指定した領域に集光していることがわかる。このことから MC 法により、MO-D²NN の隠れ層の磁区パターンを決定することができることがわかった。

Fig.2 Ratio of average intensities I_{in}/I_{out} plotted for to the number of attempts

【謝辞】本研究の一部は JSPS 科研費 JP23H04803 の助成を受けたものです。

1) T. Fujita et al., Optics Express, **30**, 36889 (2022).

磁気光学効果を利用した光回折型ディープニューラルネットワークの 磁区書き込み誤差に関する評価

Evaluation on recording error of Magnetic domains in Magneto-Optical Diffractive Deep Neural Networks using Magneto-Optical Effect

長岡技科大¹, 愛知工大², 豊田工大³ ○(M1)池田 朱莉¹, (D)坂口 穂貴¹, 野中 尋史²,
栗野 博之³, Fatima Zahra Chafi¹, 石橋 隆幸¹

Nagaoka Univ. Tech.¹, Aichi Inst. Tech.², Toyota Tech. Inst.³

○J. Ikeda¹, H. Sakaguchi¹, H. Nonaka², H. Awano³, F. Z. Chafi¹, T. Ishibashi¹

E-mail: s191005@stn.nagaokaut.ac.jp

【はじめに】

光回折型ディープニューラルネットワークは、積層型の光ニューラルネットワークの一種であり、低消費電力かつ高速な計算の実行が期待されている。しかし、可視光で動作し、書き換えが可能なデバイスの開発が課題となっている。我々は、それらの課題を解決すべく、磁性材料の磁気光学効果を利用した Magneto-Optical Diffractive Deep Neural Network (MO-D²NN)を提案した¹⁾。今回は、MO-D²NN において書き込み誤差が手書き数字の分類の正解率に与える影響について調べた。

【実験と計算】

波長 633 nm の直線偏光の光を入射光とし、ファラデー回転角が $(\pi/100)$ rad.で $1\mu\text{m}$ 角の大きさの磁区を 100×100 並べた隠れ層を 5 層としたモデルを構築し、Python 3.10.11 を用いて計算を行った。ここで、隠れ層の磁区は Bernoulli 分布に従い確率 p で消磁または磁化反転するとした。この消磁または磁化反転する確率が書き込み誤差に相当する。評価はMNISTの手書き数字データセットに対する分類について行った。

【結果】

Fig.1 は MO-D²NN のシミュレーションにおける MNIST の分類正解率と書き込み誤差 p の関係を示す。(a)は磁区が消磁した場合、(b)は磁化反転した場合のシミュレーション結果である。Fig. 1 から、磁区の 70% が消磁した場合でも 70%以上の正解率で分類されることがわかる。一方、磁化反転の割合の増加に伴って正解率は急速に減少するが、20%程度であれば 70%以上の正解率が得られることがわかった。このことから MO-D²NN のモデルが磁区パターンの書き込み誤差に強いモデルであると考察される。実験結果との比較など詳細は当日報告する。

【謝辞】

本研究の一部は JSPS 科研費 JP23H04803 の助成を受けたものです。

【参考文献】 1) T. Fujita et al., Optics Express. Vol. 30, 36889




Fig.1 Classification accuracy of test images with recording errors, (a) demagnetization and (b) magnetization reversal.

Training of MO Diffractive Deep Neural Networks by Monte Carlo Method (2)

Nagaoka Univ. Tech.¹, Aichi Inst. Tech.², Toyota Tech. Inst.³,

[°]F. Z. Chafi¹, R. Oya¹, H. Sakaguchi¹, H. Nonaka², H. Awano³, T. Ishibashi¹

E-mail: cfz@vos.nagaokaut.ac.jp

Deep Neural Networks (DNNs) have been surprisingly developed and implemented in various applications. However, as the DNNs have become more complicated, the high-speed computing and the energy consumption are much challenging. To solve those issues, we have proposed magneto-optical diffractive deep neural network (MO-D²NN) device [1,2]. In this study, we propose optimization of the learning process of MO-D²NN by Monte Carlo Method (MCM).

The proposed model in this calculation consists of two hidden layers, with a domain size set to 1 μm , the wavelength of the incident linearly polarized light was kept 633 nm, and the distance between the layers and the hidden layers was fixed at 0.5 mm. MNIST dataset has been chosen as input data for the simulation of handwritten digit classification. Magnetic domain patterns in the hidden layers, which were randomly prepared, were rewritten using the MCM with steps of 1 – 1000 for an input of one handwritten digit. This procedure was repeated in series for seven inputs of the handwritten digits.

Figure 1 shows input images of seven handwritten digits, output images obtained after calculations with 1000 steps of MCM for the seven handwritten digits, and the ideal output images. The outputs reflected the convergence of the light intensity towards the appropriate area for each digit, which matched to the target images. This confirms the reliability of the Monte Carlo method to optimize the magnetic domain patterns in the MO-D²NN.

This work has been supported by JSPS Grant-in-Aid Scientific Research JP23H04803.




Fig. 1 Input images of seven handwritten digits, output images obtained after calculations with 1000 steps of MCM for the seven handwritten digits, and the target output images

- [1]. T. Fujita, *et al.*, Opt. Exp. 30, 36889 (2022).
- [2]. H. Sakaguchi, *et al.*, DOI 10.1109/TMAG.2023.3281842 (2023).