

自己参照型ホログラフィの原理を用いた光電子 深層ニューラルネットワークハードウェア Optoelectronic deep neural network hardware using principle of self-referential holography

高林 正典^{1,2}, 富岡 莉生³ Masanori Takabayashi^{1,2}, Rio Tomioka³

¹九州工業大学 大学院情報工学研究院, 〒820-8502 福岡県飯塚市川津 680-4

¹Faculty of Computer Science and Systems Engineering, Kyushu Institute of Technology, 680-4 Kawazu, Iizuka, Fukuoka 820-8502, Japan

²九州工業大学 ニューロモルフィック AI ハードウェア研究センター, 〒820-8502 福岡県北九州市若松区ひびきの 2-4

²Research Center for Neuromorphic AI Hardware, Kyushu Institute of Technology, 2-4 Hibikino, Wakamatsu, Kitakyushu 808-0196, Japan

³九州工業大学 大学院情報工学府, 〒820-8502 福岡県飯塚市川津 680-4

³Graduate School of Computer Science and Systems Engineering, Kyushu Institute of Technology, 680-4 Kawazu, Iizuka, Fukuoka 820-8502, Japan

Abstract : Self-referential holography (SRH) is a purely one-beam holographic data recording geometry based on a volume hologram recorded by self-interference of a spatially phase-modulated light. We have proposed to apply the principle of SRH for a holographic data storage without use of a reference beam, which is named self-referential holographic data storage (SR-HDS). Also, recently, we have found that SRH can be used as a deep neural network hardware by combining it with electronic calculations. In this paper, we mainly introduce the self-referential holographic deep neural network (SR-HDNN) and show proof-of-principle simulation results of 4-class image recognition task.

Keyword : Volume holography, Self-referential holography, Spatial phase modulation, Holographic data storage, Optical neural network, Opto-electronic deep neural network

はじめに

ホログラフィは光波面の記録再生を行う技術で、立体表示や高度情報処理、定量位相イメージングなどの多くの魅力的な応用に繋がることから広く知られている。通常、ホログラムを記録するためには、被記録光である「物体光」とそれとコヒーレントな「参照光」の二光波が必要であるが、いくつかの応用においてはこのことがしばしば問題となる。例えば、次世代光記録技術として知られるホログラフィックメモリにおいては、高密度な記録や高速な転送が可能になると引き換えに、一光波のみで実現される CD や DVD などの従来の光記録技術と比較すると振動などの環境耐性が低くなってしまふ。

自己参照型ホログラフィ (SRH: Self-referential holography) は、ホログラフィの新しい実施形態であり、参照光を必要としないことを特長とする。具体的には、記録光と記録光自身の干渉によってホログラムを

形成する記録過程と、読み出し光をホログラムに照射することで読み出し光の強度分布を変化させる読み出し過程からなる。SRH は、ホログラフィという名を冠しているものの、光波面の記録再生を行うわけではなく、光に変調されているパターンの記録再生を行う。つまり、記録再生したい対象が光そのものではなく、光に変調されるパターンであるような応用において活用できる技術であるとも言える。我々はこれまで、SRH の応用技術として、読み出し光強度分布が記録光と読み出し光の位相分布の関係によって制御できることを利用した一光束ホログラフィックメモリシステムである自己参照型ホログラフィックメモリ (SR-HDS: Self-referential holographic data storage) を提案している¹⁻⁴⁾。SR-HDS は一光束光学系を基本とするため高い安定性を有する点で優位性がある。

また最近では、SRH の原理を空間変調型光ニューラルネットワークハードウェアとして利用する自己参照

型ホログラフィックニューラルネットワーク (SR-HDNN: Self-referential holographic deep neural network) を提案している⁵⁾。空間変調型光ニューラルネットワークハードウェアは、近年再燃している光ニューラルネットワークハードウェアの一つであり、光の空間並列性を活かして大規模かつ多様なニューラルネットワークのハードウェア実装を可能にするものである⁶⁻⁸⁾。本論文では、はじめにSRHの基本原理について説明する。次に、SRHの魅力的な応用の一つであるSR-HDSについて概説する。さらに、SRHの最近の研究例であるSR-HDNNについて、SR-HDNNの実現方法と4クラス手書き数字画像識別シミュレーションの結果について説明する。最後にSR-HDNNに関する今後の期待や展望についてまとめる。

自己参照型ホログラフィ

図1にSRHの典型的な光学系を示す。位相変調型空間光変調器 (P-SLM: Phase-only spatial light modulator), 凸レンズ (L1), 記録媒質, 凸レンズ (L2), カメラによって4f光学系が構築されている。記録媒質には、体積ホログラムが記録できるフォトポリマー材料などが選ばれる。SRHはホログラムを記録する記録過程とホログラムに光を照射する読み出し過程からなる。

記録過程では、P-SLMに記録パターン (WP: Writing pattern) を表示することで、WPが光波に位相変調された記録光を生成する。P-SLMに入射する光の振幅および位相が空間的に一様であるとき、P-SLMを通過した直後の記録光複素振幅分布 $u_w(x, y)$ は、

$$u_w(x, y) = \exp[j\phi_w(x, y)], \quad (1)$$

となる。記録光がL1によって集光されると、記録光が自分自身と干渉することで、焦平面付近に配置された記録媒質内にホログラムが誘起される。この自己干渉は、P-SLM面上の点から射出した球面波がL1によって平面波に変換され、それら同士が干渉する現象であると解釈することもできる。そこで、簡単のために、P-SLM面上の二点 (x_A, y_A) および (x_B, y_B) に着目する。これらを光源とする平面波同士の干渉によって形成されるホログラムは、

$$n(\mathbf{r}) = n_0 + n_1 \cos[\mathbf{K} \cdot \mathbf{r} + \Delta\phi_w], \quad (2)$$

と書ける。ここで、 n_0 と n_1 はそれぞれ記録媒質の平均屈折率と屈折率の変調振幅である。また、 \mathbf{K} は格子波数ベクトルであり、その大きさと方向はP-SLM面上の二点の位置関係およびレンズの焦点距離によって決まる。さらに、

$$\Delta\phi_w = \phi_w(x_A, y_A) - \phi_w(x_B, y_B), \quad (3)$$

である。本論文では、このようにP-SLM上の二点間の干渉によって形成されたホログラムを「要素ホログラム」とよぶことにする。

読み出し過程では、P-SLMに読み出しパターン (RP: Reading pattern) を表示し、RPが光波に位相変調された読み出し光でホログラムを照射する。記録過程と同様に、P-SLMに入射する光の振幅および位相が空間的に一様であるとき、P-SLM通過直後の読み出し光複素振幅分布 $u_r(x, y)$ は、

$$u_r(x, y) = \exp[j\phi_r(x, y)], \quad (4)$$

となる。読み出し過程においてもP-SLM面上の二点 (x_A, y_A) および (x_B, y_B) に着目すると、それらの位相差は、記録過程における二光波間の位相差とは異なり、

$$\Delta\phi_r = \phi_r(x_A, y_A) - \phi_r(x_B, y_B), \quad (5)$$

となる。ここで、

$$\Delta\phi = \Delta\phi_w - \Delta\phi_r, \quad (6)$$

として記録過程と読み出し過程の二点間の位相差の差を定義すると、読み出し過程に照射する二光波からは要素ホログラムが $\Delta\phi$ の空間位相ずれを有しているように感じる。その結果、カメラ面において観測される二点の強度は互いに異なるものになる。このことはKogelnikの結合波動理論などを用いて解析することができ¹⁹⁾、カメラ面における二点間の強度差 ΔI は $\Delta\phi$ に対して正弦的に変化し、 $\Delta\phi = \pi/2$ で最大となる。

一方、実際にP-SLM面上にあるのは二点ではなく無数の点である。したがって、実際には無数の点を由来とする光によって形成されるやはり無数の要素ホログラムが形成される。これらの要素ホログラムは選択的に読み出すことができないので、カメラ面における読み出し光強度分布は、先に説明した二点間相互作用の単純な重ね合わせにはならないはずである。しかし、要素ホログラムを空間的に拡散させるなどの方法によって、カメラ面における読み出し光強度分布があたかも二点間相互作用の重ね合わせで説明できるような状況になることが見出されている²⁾。この場合、カメラ面における読み出し光強度分布は、 $\phi_w(x, y)$ と $\phi_r(x, y)$ の関係によって制御可能であると解釈できる。以下では、このことを利用した具体的な応用について述べる。

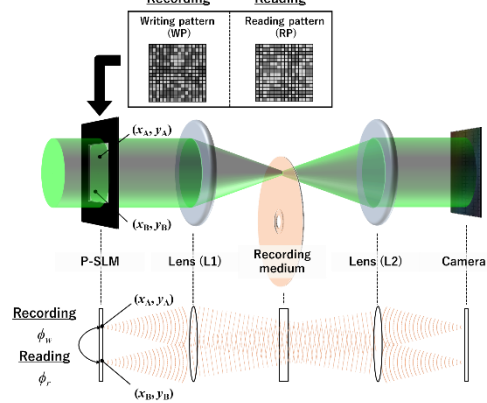


図1 SRHの概念図

自己参照型ホログラフィックメモリ

SR-HDS は、SRH の原理を利用したホログラフィックメモリの新たな実施形態であり、従来必要不可欠とされていた参照光を用いない光学系と、位相変調されたデータページを強度分布として読み出すという特長を有する。つまり、光波面の記録再生ではなく、光波に変調されたパターンの記録再生を行う。SR-HDS では、WP を被記録パターン (SP: Signal pattern) と追加パターン (AP: Additional pattern) の和とする。また、RP は AP と等しい分布に設定する。SP と AP が特定の条件を満たすとき、出力光強度分布が SP と一対一対応することが見出されており^{1,2)}、SR-HDS ではこのことを利用して SP の記録再生を行う。SP が満たすべき条件は一つではないが³⁾、典型的には位相差 $\pi/2$ のバイナリパターンとするのがよい。一方の AP は記録光の焦平面強度分布が拡散するように定める²⁾。例えば SP よりも細かなピクセルを有する AP や、記録光の焦平面強度分布が拡散するように局所探索アルゴリズムや深層学習を用いて設計した AP を用いることが効果的である^{2,4)}。図 2 に、さまざまな AP を用いた SR-HDS の記録再生シミュレーション結果を示す^{2,4)}。焦平面光強度分布が拡散しているときに高い品質で SP を再生できることが分かる。

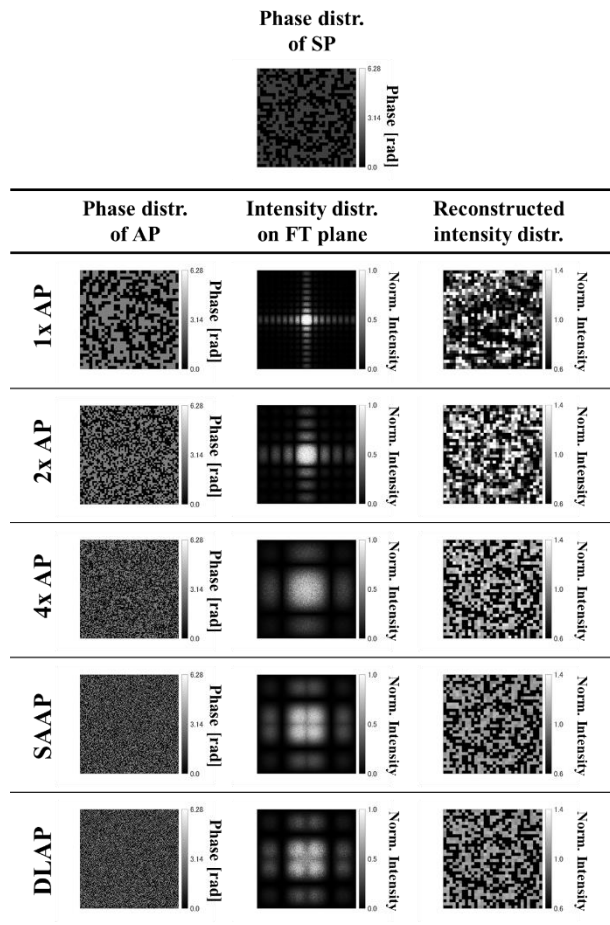


図 2 さまざまな AP を用いた SR-HDS 記録再生シミュレーション結果

共通の SP に対して、SP よりも $M \times M$ 倍細かい「 $M \times AP (M=1,2,4)$ 」、局所探索アルゴリズムを用いて設計した「SAAP」、SP と SAAP のペアで学習した深層ニューラルネットワークを用いて設計した「DLAP」を AP として用いた。FT 面強度分布が拡散するように設計された AP を用いることで高品質な SP の記録再生が行えることが分かる。

自己参照型ホログラフィック深層ニューラルネットワーク

SRH では記録光と読み出し光の位相差分布によって読み出し光の強度分布を変化させる。この性質に着目して、SRH をニューラルネットワークハードウェアとして機能させようとする技術が SR-HDNN である。具体的には、P-SLM 面上の点をノード、ホログラムをニューラルネットワーク、WP をニューラルネットワークの形を決定する変数、RP をエッジの重みを制御する学習変数、カメラで取得する分布を出力とすることでニューラルネットワークの動作を実現する。さらに、カメラと P-SLM を電子接続し、電子演算部を介したフィードバックを形成すれば、プーリング演算や非線形演算などを含む深層ニューラルネットワークにも拡張できる。本論文では、SRH による並列光演算と電子演算による非線形演算や多層化を含めた全体のシステムを SR-HDNN とよぶ。

1. SR-HDNN の動作概要

図 3 に SR-HDNN の概念図を示す。ここでは SR-HDNN によって画像識別を実行するタスクを想定して説明する。SR-HDNN は、ホログラムネットワークを形成する記録過程、既知の情報を使って教師あり学習を行う学習過程、未知の情報に対して推論を行う推論過程からなる。

記録過程では、適当な WP を用いて自己参照型ホログラムを記録する。例えばランダムな WP を用いれば全結合ネットワークのような役割を持つホログラムネットワークを、記録スケジュールや WP の分布を工夫することで特定のノード同士を結合させるようなホログラムネットワークを形成できると期待される。また、互いに異なるホログラムネットワークを記録媒質の異なる位置に書き込んでおけば、層ごとに別のホログラムネットワークを通過させることも可能である。

学習過程では、 $i (i = 1, 2, \dots, N)$ 層目において入力画像と学習画像を足し合わせた画像を位相変調する。ここで、入力画像の変調方法は位相変調に限定されないが、ここでは簡単のため位相変調を想定する。 i 層目の P-SLM 通過直後の複素振幅分布は、

$$u_i(x, y) = \exp\{j[\phi_i^I(x, y) + \phi_i^T(x, y)]\}, \quad (7)$$

と書ける. ここで, $\phi_i^i(x, y)$ と $\phi_i^T(x, y)$ はそれぞれ i 層目の入力画像と学習画像を変調した場合の位相分布である. 式(7)において, $i = 1$ のときは被識別画像を, $i > 1$ のときは前層の出力結果に処理を加えた分布とする. SRH の原理により, 式(7)で与えられる光波がホログラムを通過すると P-SLM 面上の点間相互作用, つまりノード間結合が生じる. その結果, カメラ面における複素振幅分布は入力面の複素振幅分布とは異なるものになる. これを一般的な形式で書けば,

$$v_i(x, y) = a_i(x, y)\exp[j\theta_i(x, y)], \quad (8)$$

となる. ここで, $a_i(x, y)$ と $\theta_i(x, y)$ はそれぞれ i 層目のカメラ面における振幅分布と位相分布である. $i + 1$ 層の入力は, 電子演算部で加える処理を $f\{\}$ で表せば,

$$\phi_{i+1}^i(x, y) = f\{a_i(x, y)\exp[j\theta_i(x, y)]\}, \quad (9)$$

と書ける. 式(7)~(9)の処理を層数分だけ繰り返すことで N 層のニューラルネットワークを再現できる. 最終層となる $i = N$ 層においては, 撮像面の複素振幅分布 $v_N(x, y)$ に処理 $g\{\}$ を加え,

$$o(x, y) = g[v_N(x, y)], \quad (10)$$

を得る. この分布と理想的な出力分布のずれを定量的に評価し, これを損失とする. 学習過程では, 複数の入力に対して損失が減少するように各層の学習分布の値を決定する.

推論過程では, 学習過程で獲得した学習分布を用いて推論を行う. 正しく学習ができている場合, これらの学習分布は汎化性能を持つため, 1 層目の入力分布を未知の被識別画像にした際, 所望の出力結果が得られると期待される.

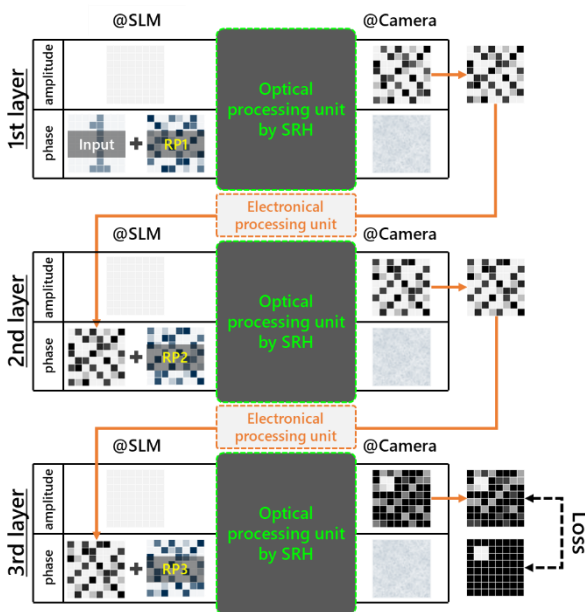



図3 SR-HDNN の概念図

2. SR-HDNN による画像識別シミュレーション

SR-HDNN の動作を確かめるために手書き数字画像の識別シミュレーションを行った⁵⁾. 本シミュレーションでは, MNIST 手書き数字画像のデータセットから「0」「1」「2」「3」の4クラスの画像を抽出し, これらを識別することを目標とする. 本シミュレーションで想定する SR-HDNN の構成は図3と同様の3層で, WP は 32×32 ピクセルのランダムパターンとした. また, 入力画像および学習画像のピクセル数は 32×32 , 変調方法は位相変調とする. 各層において, 入力画像の位相変調範囲を $[0, \pi]$ とするために, 式(9)の演算として以下を電子的に実行する.

$$\phi_{i+1}^i(x, y) = \frac{|v_i(x, y)|^2}{\max[|v_i(x, y)|^2]} \pi. \quad (11)$$

最終層においては, 式(10)の処理として, $o(x, y) = |v_N(x, y)|^2$ とした. これは単純にカメラで撮像する処理に相当する. 入力画像のラベルに対応する局所領域の光強度が最も強くなる状態を理想とし, その状態との差異を定量化した. 具体的には, 不正解ラベルに対応する領域の強度和 I_{ic} と正解ラベルに対応する領域の強度 I_c の比 I_{ic}/I_c を損失とした. 学習過程では, 各ラベル 50 枚の計 200 枚の入力画像に対して損失を減少させるように, $\{0, \pi/4, \dots, 7\pi/4\}$ を候補とする 8 値の学習分布のピクセル値を決定した. 推論過程においては, 学習過程で使用していない各ラベル 500 枚の計 2000 枚の入力画像を学習済みの学習分布とともに変調した. 図 4(a)は入力画像とそれに対応する出力画像の例であり, いずれも正解と判定された場合である. 識別に用いる領域のみに注目するためマスクを利用すると, 各ラベルに対応する領域の強度が最も強くなっていることが分かる. また, 出力画像において強度が最大となる局所領域に対応するラベルを推定ラベルとし, 推論に用いた全ての入力画像に対する推定ラベルを求めたところ, 図 4(b)に示すような混同行列が得られた. ラベルによる多少のばらつきはあるものの, 平均で 80%以上の識別率が確認された. 数値シミュレーションの結果ではあるが, これは SRH のニューラルネットワークハードウェアとしての応用可能性が示されたものであると言える. より識別率を高めるためには, 学習変数の数 (ピクセル数) や階調数を増やすこと, 学習に用いる画像を増やすこと, ネットワークの構成や電子層での演算を適切に設計することなどが有効であると考えられる. また, 今回は画像識別の結果を示したが, 画像のデノイズなどの画像変換タスクなども同様の光学システムで行えることが期待される.



(a)

		Predicted label				Total	Accuracy [%]
		"0"	"1"	"2"	"3"		
True label	"0"	392	32	55	21	500	78.4
	"1"	0	479	16	5	500	95.8
	"2"	28	46	395	31	500	79.0
	"3"	15	58	76	351	500	70.2
Total		435	615	542	408	2000	80.9

(b)

図4 SR-HDNNによる画像識別シミュレーション

(a) 入力画像と出力画像の例. (b) 混同行列.

おわりに

SRHの原理とその応用例であるSR-HDSとSR-HDNNについて解説した。SRHは記録光の自己干渉によるホログラムの記録と、記録光と読み出し光の空間位相分布の違いによって生じる読み出し光強度分布の変化を基本とする技術であり、参照光を用いないホログラフィックメモリや、P-SLM面上の点をノード、ホログラムをニューラルネットワークと見なした光ニューラルネットワークハードウェアへの応用が期待できる。特に、近年注目が高まっている空間変調型光ニューラルネットワークとしての活用法であるSR-HDNNについて、基本動作を説明したのち、4クラス手書き数字画像識別シミュレーション結果について紹介した。数値シミュレーションによって得られた結果は、SR-HDNNの実現可能性を示唆するものであった。

将来的には、WPによるホログラムネットワーク形状の変更や電子演算部を活用した多様な演算機能の実現も期待される。また、画像識別タスクだけでなくデノイズなどの画像変換タスクなどにも応用できる可能性がある。特に注目すべきなのは、SR-HDSとSR-HDNNが同じ光学系で実現できるという点である。SR-HDSや一般的な位相変調型ホログラフィックメモリの光学系には、P-SLM、記録媒質（ホログラム）、カメラなどのSR-HDNNに必要なリソースが含まれている。そのため、ホログラフィックメモリにおける読み出し画像のデノイズやブロック符号の検出などのニューラルネットワークの活用が期待される場面において^{10,11)}、必要な演算機能の一部または全てを、光学系の追加な

しに実装できる可能性がある。一方、電子フィードバックを伴うSR-HDNNなどの系はどうしてもデバイス性能の制約を受けてしまう。その点でSR-HDNNは、多様な問題に適用される汎用的なニューラルネットワークハードウェアというよりはむしろ、SR-HDSなどの相性がよいアプリケーションに適切に組み込まれることで利用価値が高まる技術であると期待される。

【参考文献】

- 1) Takabayashi, M. and Okamoto A.: "Self-referential holography and its applications to data storage and phase-to-intensity conversion," *Optics Express*, 21 (2013) 3669-3681.
- 2) Takabayashi, M., et al.: "Recording procedures for high-quality signal readout in self-referential holographic data storage," *Appl. Opt.*, 54 (2015) 5167-5174.
- 3) 高林正典ら: "自己参照型ホログラフィックメモリにおける多値データページの記録方法," *信学技報*, 117 (2017) 17-22.
- 4) Chijiwa, K. and Takabayashi, M.: "Deep learning-based design of additional patterns in self-referential holographic data storage," *Opt. Rev.* (2023). (*in press*)
- 5) Tomioka, R. and Takabayashi, M.: "Numerical simulations on optoelectronic deep neural network hardware based on self-referential holography" *Opt. Rev.*, **30**, (2023) 387-396.
- 6) Lin, X., et al.: "All-optical machine learning using diffractive deep neural networks," *Science*, 361 (2018) 1004-1008.
- 7) Chang, J., et al.: "Hybrid optical-electronic convolutional neural networks with optimized diffractive optics for image classification," *Sci. Rep.*, 8 (2018) 12324.
- 8) Zhou, et al.: "Large-scale neuromorphic optoelectronic computing with a reconfigurable diffractive processing unit," *Nat. Photon.*, 15 (2021) 367-373.
- 9) Kogelnik H.: "Coupled-wave theory for thick hologram grating," *Bell Syst. Tech. J.*, 48, (1969) 2909-2947.
- 10) Katano, Y., et al.: "CNN-based demodulation for a complex amplitude modulation code in holographic data storage," *Opt. Rev.*, 28 (2021) 662-672.
- 11) Kurokawa, S. and Yoshida, S.: "Demodulation scheme for constant-weight codes using convolutional neural network in holographic data storage," *Opt. Rev.*, 29 (2022) 375-381.