

# 自己参照型ホログラフィックメモリにおける深層学習の利用と実装

高林 正典<sup>1,2</sup>

<sup>1</sup>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

<sup>2</sup>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

〒808-0196 福岡県北九州市若松区ひびきの 2-4

E-mail: takabayashi@phys.kyutech.ac.jp

**あらまし** 自己参照型ホログラフィックメモリ (SR-HDS) は、ホログラフィックメモリ (HDS) の実装形態の一つであり、参照光を用いないことを特長とする。参照光を用いないため光学系が安定ではあるが、設計の自由度が低いという側面もある。このことは、SR-HDS の記録再生品質を向上させるという目的において、光学設計によるアプローチには限界があることを示唆している。そこで本研究では、近年注目されている深層学習を用いるアプローチに着目する。具体的には、記録再生光の位相分布の設計、再生データページのデノイズおよびブロック符号の復号などに深層学習を適用することができると期待される。さらに我々は、深層学習に必要な一部の演算を SR-HDS に記録されているホログラムと少しの電子処理に担わせる実装方法、つまり、深層学習の機能を内在する SR-HDS の確立を目指している。本稿では、SR-HDS と SR-HDS の光学系を用いた深層ニューラルネットワーク (DNN) ハードウェアの実装方法であ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 (SR-HDNN) を紹介する。最後にそれらの融合に対する期待と展望を述べる。

**キーワード** 自己参照型ホログラフィックメモリ、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、深層学習

## Use and implementation of deep learning in self-referential holographic data storage

Masanori Takabayashi<sup>1,2</sup>

<sup>1</sup>Faculty of Computer Science and Systems Engineering, Kyushu Institute of Technology,

680-4 Kawazu, Iizuka, Fukuoka 820-8502, Japan

<sup>2</sup>Research Center for Neuromorphic AI Hardware, Kyushu Institute of Technology,

2-4 Hibikino, Wakamatsu, Kitakyushu 808-0196, Japan

E-mail: takabayashi@phys.kyutech.ac.jp

**Abstract** Self-referential holographic data storage (SR-HDS) is one of the implementations of holographic data storage (HDS), and does not require a reference light which is required in conventional HDS systems including two-beam and collinear geometries. By this feature, the optical system of SR-HDS is enabled to be stable and compact, however the degree of freedom of optical design is limited. This means that the significant improvement of the recording qualities by optical design approach is not expected. Therefore, we have focused on approaches using deep learning which have been attracting attention in recent years. For example, we expect to use deep learning-based approaches in design of the phase pattern used in recording and reading processes, denoising of the reconstructed datapages, and decoding block codes. In this paper, we introduce SR-HDS and how to implement deep neural network (DNN) hardware by the same optical system as SR-HDS, which is named self-referential holographic deep neural network (SR-HDNN). Finally, we discuss how to establish SR-HDS internalizing deep learning capabilities.

**Keyword** Self-referential holographic data storage, Self-referential holographic deep neural network, Deep learning

## 1. はじめに

ホログラフィックメモリ (HDS: Holographic data storage) は、ホログラフィの原理を利用した被記録情報変調光波の記録再生を通じて情報を記録再生する次世代光記録技術である<sup>1)</sup>。二次元データページが変調された光波面の記録再生に由来する高い転送速度と、ホログラムの多重記録に由来する高い記録密度を特長としている。一方、ホログラムを介した光波面の記録再生には被記録光波である物体光 (HDS では信号光とよばれる) とそれとコヒーレントな参照光の二光波を要するため、一光波のみで実現されてきた従来の光記録技術と比較すると光学系が大型かつ複雑となり、結果として環境耐性が低くなってしまう。

このような状況に際し、我々は純粋な一光束でホログラフィックな情報記録再生を可能にす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<sup>2)</sup>。ホログラムの記録再生に用いる二光波は「光波面」の記録再生に必要なものではあるが、光波に変調された「情報」の記録再生には必ずしも必要でないという発想に基づいている。SR-HDS 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生じる読み出し光強度分布の変化に基づく読み出し過程からなり、記録過程において光に位相変調したデータページが読み出し過程において強度分布となって現れる。つまり、記録時の記録光波面が読み出し時に再生されるわけではない。SR-HDS は純粋な一光束光学系で実現できるのでシステムの観点からの優位性があるが、データページの再生品質にはまだ改善の余地がある。これまで、従来の HDS も含め、再生品質改善手法といえば光学系等の改善による光学的アプローチか符号化方式などの改善による情報科学的アプローチが主流であったが、SR-HDS の光学系の設計自由度が低いため特に光学的アプローチによる大幅な再生品質の改善は見込めない。そこで、近年注目を集める深層学習を用いた再生品質改善アプローチに着目する。深層学習は現在広範な分野で活用されており、画像を対象とした汎用的な処理も可能になる。HDS においては、データページに対する処理、例えばデノイズなどの目的に好適であると考えられる。

一方、深層学習ではタスクが複雑になると学習変数が増加し、結果として計算コストが増加してしまう。そこで、深層学習に処理に係る一部またはすべての演算を汎用電子計算機以外の物理演算系に頼ることで消費電力を少なく抑えられる深層ニューラルネットワーク (DNN: Deep neural network) ハードウェアが注目されている<sup>3,4)</sup>。我々も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) と名付けた大規模な DNN ハードウェアを提案している<sup>5,6)</sup>。SR-HDNN の魅力的な特長の一つは、SR-HDS と同一の光学系で実現できるということであり、例えば SR-HDS の再生データページのデノイズ処理を自身のシステムをリソースとして実行する「深層学習の機能を内在する SR-HDS」の実現が期待できる。

本稿では、SR-HDS と SR-HDNN に共通する技術である自己参照型ホログラフィ (SRH) の説明から始める。SR-HDS におけるデータページの記録再生手順について概説したのち、SR-HDNN の実装手順とそのデモンストレーション結果を紹介する。最後に、まとめに変えて、SR-HDS と SR-HDNN の融合技術、つまり深層学習の機能を内在する SR-HDS に関する今後の期待および展望について述べる。

## 2. 自己参照型ホログラフィ (SRH)

図1はSRHの典型的な光学配置で、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), カメラからなる4f光学系である。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。WPが位相変調された光波を記録光とよぶ。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を通過した直後の面における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形成される。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できる。ここで、P-SLM通過直後の光波断面内にある二点に着目し、これらの点の位相差を  $\Delta\phi_w$  とする。以下では、P-SLM通過直後の任意の二点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を「要素ホログラム」とよぶ。

読み出し過程では、P-SLMに読み出しパターン (RP: Reading pattern) を表示する。RPが位相変調された光波を読み出し光とよぶ。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通過直後の面における記録光複素振幅分布  $u_r(x, y)$  は、

$$u_r(x, y) = \exp[j\phi_r(x, y)], \quad 2$$

となる。記録過程で着目した二点間の位相差は変化し、これを  $\Delta\phi_r$  とする。ここで、 $\Delta\phi = \Delta\phi_w - \Delta\phi_r$  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。このとき、カメラ面における当該二点間の強度差  $\Delta I$  は  $\Delta\phi$  に対して正弦的に変化し、 $\Delta\phi = \pi/2$  で最大となる。

実際にはP-SLMを通過した光断面にある無限個の点を由来とする光によって無限個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独立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と、カメラ面における読み出し光強度分布が上述の二点間相互作用の重ね合わせで説明できるようになることが見出されている。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  $\phi_r(x, y)$  の関係によって決まる。SRHにおいてP-SLMに与えるWPおよびRPを工夫することによって参照光が不要なホログラフィックメモリとして機能するSR-HDSや変調パターンの各ピクセルをDNNのノードとして取り扱う大規模なDNNハードウェアとして機能するSR-HDNNを実現できる。以下では、SR-HDSおよびSR-HDNNのそれぞれの実現方法を説明したのち、数値シミュレーションのよって得られたデモンストレーション結果を示す。

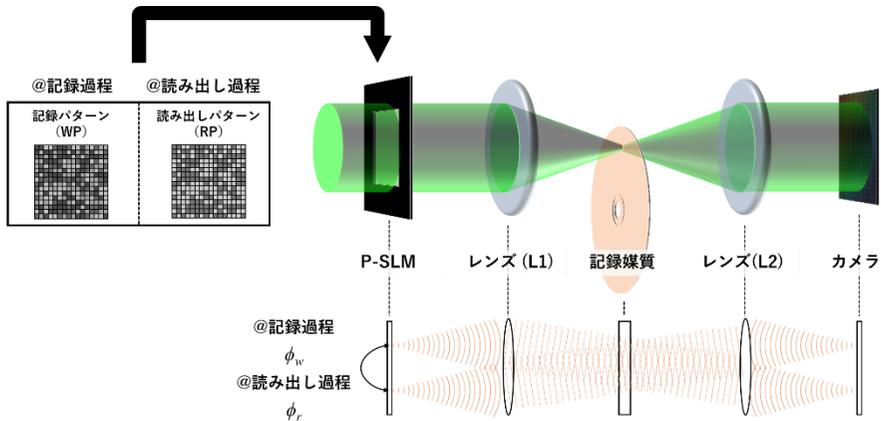


図 1 SRH の光学系

### 3. 自己参照型ホログラフィックメモリ (SR-HDS)

本章では SR-HDS の実現方法について説明する. SR-HDS では, 図 2 に示すように, 信号パターン (SP: Signal pattern) と追加パターン (AP: Additional pattern) の和を WP, 記録時に用いた AP を RP とする. つまり, P-SLM 面における記録光と読み出し光の複素振幅分布  $u_w(x, y)$  および  $u_r(x, y)$  はそれぞれ,

$$u_w(x, y) = \exp\{j[\phi_s(x, y) + \phi_a(x, y)]\} \tag{3}$$

$$u_r(x, y) = \exp[j\phi_a(x, y)] \tag{4}$$

となる. ここで,  $\phi_s(x, y)$  と  $\phi_a(x, y)$  はそれぞれ, SP と AP を変調した光波の位相分布である. SP と AP が適切な条件を満たすとき, 読み出し過程においてカメラ面で観測される光強度分布が SP と一致することで SP の記録再生が行える. 以下では, SP と AP が満たすべき条件について解説する.

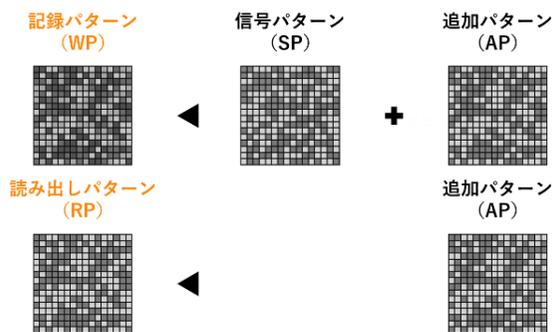


図 2 SR-HDS における記録パターン (WP) と読み出しパターン (RP)

#### 3.1 SP が満たすべき条件

2 章で述べたように, P-SLM 面の任意の二点に着目すると, カメラ面における当該二点間の強度差  $\Delta I$  は記録光と読み出し光の P-SLM 面における当該二点間の位相差  $\Delta\phi$  に依存する. 具体的には,  $\Delta I$  は  $\Delta\phi$  に対して正弦的に変化し,  $\Delta\phi = \pi/2$  で最大となる. つまり, 強度差  $\Delta I$  が 0 とならないように位

相差  $\Delta\phi$  を設定すると、記録過程の P-SLM 面における二点間位相差が読み出し過程のカメラ面における当該二点間強度差に対応する。強度差  $\Delta I$  が 0 とならないための位相差は、整数  $k$  を用いて  $\Delta\phi \neq k\pi$  と書ける。また、読み出し過程で当該二点間位相差を固定すれば、記録光の位相が読み出し光強度に対応するようにできる。複数点間の相互作用を考える場合にも同様で、複数の二点間相互作用がそれぞれ独立に取り扱えると仮定すると、 $\phi_s x, y$  が位相差  $\Delta\phi \neq k\pi$  のバイナリパターンであるとき、 $\phi_s x, y$  が読み出し過程のカメラ面強度分布に対応付けられる。したがって、 $\phi_s x, y$  が満たすべき条件の一つは「位相差が  $\pi$  の整数倍とならないバイナリパターン」である。なお、 $\Delta\phi = \pi/2$  のときに読み出し光強度分布のコントラストが最も高くなる。

SP を多値分布とする場合、SP の値は慎重に設計する必要がある。任意の位相値を許容せず、 $\phi_s x, y = \{0, \pi/2, \pi, 3\pi/2\}$  などとしても SP の記録再生はできない。この場合、例えば  $\phi_s x, y = \pi/2$  の点にとつて、 $\phi_s x, y = 0$  の点との相互作用と  $\phi_s x, y = \pi$  の点との相互作用は対称的であり、全体として位相分布に対応した見かけの強度変化が起こらないためである。つまり、 $\phi_s x, y$  を構成する位相値は非等間隔とする必要がある。4 値の場合について具体的な位相の組み合わせを数値的に調べたところ、 $\phi_s x, y = \{0, \theta, \pi, \theta + \pi\}$  あるいは  $\phi_s x, y = \{0, \theta, 2\theta, 2\theta + \pi\}$  を満たさないときに記録光の P-SLM 面における位相が読み出し光のカメラ面強度に対応することが導かれた<sup>7)</sup>。特に、 $\phi_s x, y = \{0, \pi/4, 9\pi/20, 7\pi/10\}$  のときに強度分布のコントラストが高くなる。

### 3.2 AP が満たすべき条件

AP に求められる役割は「要素ホログラムを拡散させること」である。ホログラムは焦平面付近に形成されるため、焦平面光強度分布または空間パワースペクトルの拡散と言い換えてもよい。SP とは異なり、AP には制約がなく、任意のパターンを用いることができる。本節では、SP と AP の和である WP を変調した記録光が拡散した焦平面光強度分布を達成するための 3 つの手法、Oversampling (OS) 法、Searching algorithm (SA) 法、Deep learning (DL) 法を簡単に紹介する。

OS 法は SP よりも細かなピクセルを持つ AP を用いる方法である<sup>8)</sup>。具体的には、図 3 に示すように、SP の 1 ピクセルに対して AP の  $n \times n$  ピクセルを対応させる。このときの AP を「 $n \times AP$ 」と表記する。一般的に、 $n$  が大きくなるほど焦平面分布は拡散するが、SP に割り当てられる最大ピクセル数は SLM のピクセル数の  $n^{-2}$  倍となる。

SA 法は WP を変調した光波の焦平面強度分布が拡散するように AP の各ピクセル値を決定する方法である。まず、 $\phi_a x, y$  の候補となる位相値と理想的な焦平面強度分布を定めておく。この理想分布は大まかでもよく、例えば大きさを定めたような矩形領域などとしてもよい。次に、初期状態の AP を用いた場合の焦平面光強度分布と理想的な焦平面光強度分布の違いを定量的に評価する。評価指標には SNR (Signal to noise ratio) や RMSE (Root mean squared error) などを用いる。AP の各ピクセルの値を候補値の中から順に適用し、現状よりも評価値が改善するようにピクセル値を決定していく。すべてのピクセルに対してこの操作をする作業を 1 サイクルとし、これを数サイクル繰り返すことで設計 AP を得る。それ

それぞれの SP に適した AP を設計できるが、AP の設計に要する時間は長くなるという問題がある。

DL 法は深層学習を用いて設計 AP を得る手法であり、SA 法に比べて設計に要する時間を大幅に短縮できる<sup>9)</sup>。DL 法に使用する深層学習モデルには画像変換を行うモデルが使用される。SP とその SP に対して SA 法で設計された設計 AP をあらかじめ複数組用意しておき、それらを用いて深層学習モデルを学習する。学習が完了し、深層学習モデルが汎化性能を持つと、任意の SP を入力したときに設計 AP を瞬時に得ることができる。そのため、DL 法は SA 法の設計時間の問題を解消することができる。なお、学習用データセットの作成過程には長い時間を要するが一度限りのプロセスであるため問題にはならない。

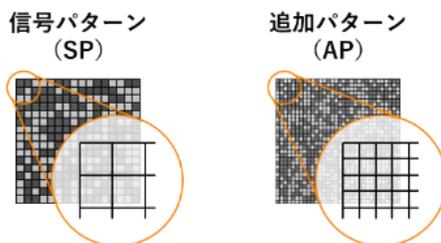


図 3 OS 法の概念図

### 3.3 SR-HDS の記録再生シミュレーション

図 4 に共通の SP に対してそれぞれの手法を用いて得られた AP を付与した場合における焦平面光強度分布および再生光強度分布を示す。SP は位相差が  $\pi/2$  のバイナリパターン、OS 法、SA 法、DL 法の学習に用いる AP は位相差が  $\pi$  のバイナリパターンとした。記録過程において光波に位相変調されていた SP が、読み出し過程においてカメラ面光強度分布として読み出されていることが分かる。また、WP を変調した光波の焦平面光強度分布と再生品質には関係があり、焦平面光強度分布が拡散しているときに高品質な SP の記録再生が行えていることが分かる。

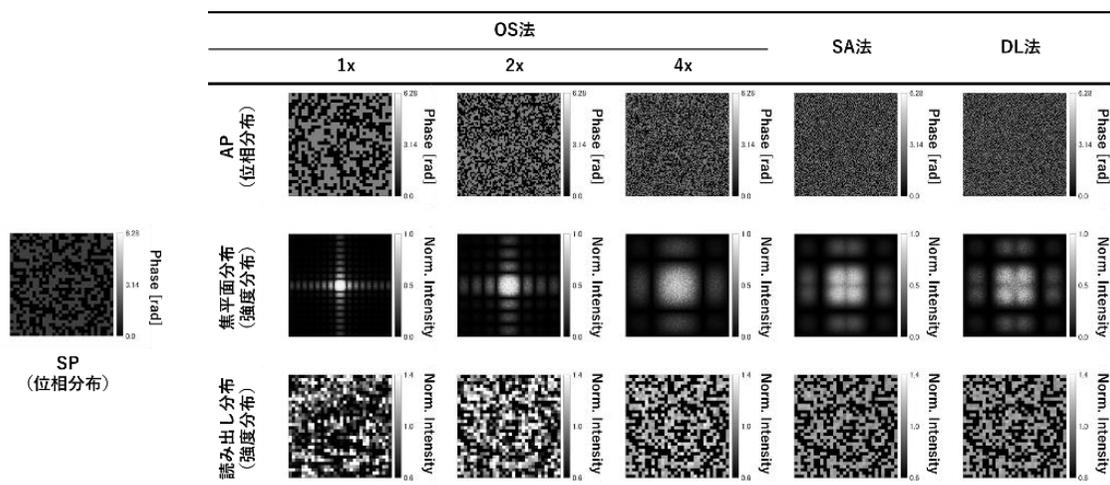


図 4 様々な AP を用いた SR-HDS の記録再生シミュレーション

#### 4. 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 (SR-HDNN)

SRHの本質的な動作は、記録光と読み出し光のP-SLM面における位相分布の差によって読み出し光のカメラ面における強度分布を制御することである。このことに着目して、DNNハードウェアを実現する技術がSR-HDNNである。具体的には、P-SLM面上の点(変調パターンのピクセル)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。ホログラムにおける回折は光学的に線形なので、P-SLM面とカメラ面の複素振幅分布の関係は一つの複素行列(透過行列)で関係付けられる。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、正規化処理やプーリング演算、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。本稿では、SRHによる並列光演算と電子フィードバック演算からなる図5のようなシステムをSR-HDNNとよぶ。

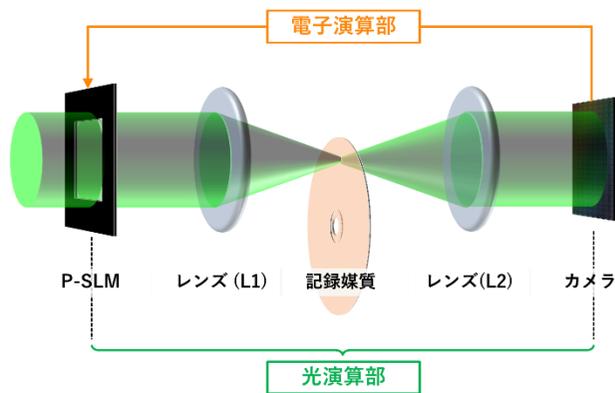


図5 SR-HDNNの概念図

##### 4.1 SR-HDNNの概要

本節では、画像識別を実行するタスクを例にとってSR-HDNNの動作を説明する。SR-HDNNは、ネットワークとして作用させるホログラムを記録する記録過程、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。システム全体のイメージフローを図6に示す。

記録過程では、適当なWPを用いてホログラムを記録する。このときに使用するWPには制約がなく、自由に設定することができるが、WPの設定方法によってどのようなピクセル間相互作用が生じるかが決まる。例えばランダムなWPを用いることで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形成できると期待される。また、互いに異なる性質を持つホログラムを記録媒質の異なる位置に書き込んでおいて、層ごとに別のホログラムを作用させるようにすれば層ごとに形状の異なるネットワークを作用させることも可能であると考えられる。

学習過程では、 $l$  ( $l = 1, 2, \dots, L$ ) 層目において入力パターン (IP: Input pattern) と学習パターン (TP: Training pattern) を足し合わせたパターンをRPとする。ここで、IPの変調方法は限定されないが、ここ

では簡単のため位相変調を仮定する。  $l$  層目の P-SLM 通過直後の複素振幅分布は、

$$u_l x, y = \exp\{j[\phi_{i,l} x, y + \phi_{t,l} x, y]\} \tag{5}$$

と書ける。ここで、 $\phi_{i,l} x, y$  と  $\phi_{t,l} x, y$  はそれぞれ  $l$  層目の IP と TP を変調した光波の位相分布である。式(5)において、 $l = 1$  のときは被識別画像を、 $l > 1$  のときは前層の出力結果に処理を加えた分布を IP とする。式(5)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、

$$v_l x, y = a_l x, y \exp[j\theta_l x, y] \tag{6}$$

となる。ここで、 $a_l x, y$  と  $\theta_l x, y$  はそれぞれ  $l$  層目のカメラ面における振幅分布と位相分布である。なお、ホログラムは光学的に線形なので、式(5)および(6)で表される複素振幅分布は、

$$v_l = M u_l \tag{7}$$

と関係付けられる。ここで、 $u_l, v_l$  は式(5)および(6)で表される複素振幅分布を一次元ベクトル形式で記述したものである。 $M$  は透過行列として知られており<sup>10)</sup>、散乱イメージングの分野等で用いられている。 $l+1$  層の入力は、電子演算部で作用させる処理を  $f\{\bullet\}$  で表せば、

$$\phi_{i,l+1} x, y = f\{v_l x, y\} \tag{8}$$

と書ける。式(5)から式(8)に至る処理を層数分繰り返すことで  $L$  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  $l = L$  の層においては、撮像面の複素振幅分布  $v_L x, y$  に処理  $g\{\bullet\}$  を加え、

$$o x, y = g[v_L x, y] \tag{9}$$

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 TP を用いて推論を行う。正しく学習ができている場合、TP は汎化性能を持つため、1層目の TP を未知の被識別画像にしても、所望の出力結果が得られると期待される。

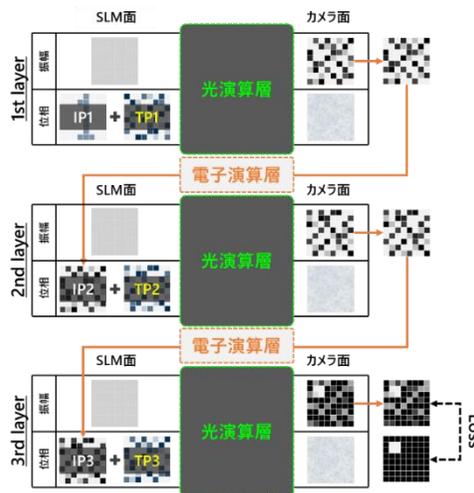


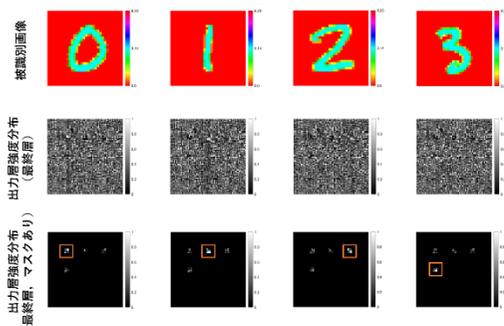
図 6 SR-HDNN におけるイメージフローの例

## 4.2 SR-HDNN による手書き数字画像の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<sup>5)</sup>。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。SR-HDNN は3層で、WP は32×32ピクセルからなるランダムパターンとした。また、IP およびTP のピクセル数は32×32、変調方法は位相変調とした。各層において、IP の位相変調範囲を  $[0, \pi]$  とするために、式(8)の演算として以下を実行した。

$$\phi_{i,l+1}(x,y) = \frac{|v_l(x,y)|^2}{\max[|v_l(x,y)|^2]} \pi. \quad (10)$$

最終層においては、式(9)の処理として、 $o(x,y) = |v_L(x,y)|^2$  とした。これは光波の複素振幅分布をカメラで撮像する処理に相当する。被識別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枚の被識別画像を学習済みのTPとともに変調した。図7(a)は被識別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の中から選んでいる。識別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被識別画像に対する推定ラベルを求めたところ、図7(b)の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。これはSRHのDNN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。なお、本稿で示したシミュレーションでは順伝搬過程に基づくピクセル値の逐次決定による非効率な学習を行っているが、誤差逆伝搬法などを適用して学習に用いる画像を大幅に増加させることも可能である。



(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7 SR-HDNN による画像識別シミュレーション結果 (a) 入出力画像, (b) 混同行列

## 5. まとめ

本稿では、SRHの応用技術としてSR-HDSとSR-HDNNを紹介した。SR-HDSは参照光を用いずにホログラフィックな情報記録再生を可能にする技術である。参照光を用いないため光学系が簡素化できるという利点などがある。一方のSR-HDNNはホログラムによって光波に変調されたパターンのピクセル間相互作用を誘起し、電子フィードバックを組み合わせることでDNNハードウェアを実現する技術である。ホログラムによる柔軟なピクセル間相互作用の実現可能性に関する利点のほか、SR-HDSと光学系を同一にできるという特長がある。以下では、SR-HDSとSR-HDNNの融合技術、つまり深層学習の機能を内在するSR-HDSに関する今後の期待および展望について述べる。

HDSに深層学習を利用する研究報告事例はこれまでにいくつかあり、再生データページのデノイズやブロック符号の検出などに適用された例が示されている<sup>11,12</sup>。SR-HDSにもこれらは適用可能であると考えられ、また本稿で述べたようにAPの設計においても深層学習が活用できる。一方、深層学習を従来の汎用計算機でソフトウェア実装する場合、しばしば計算コストが問題となる。特に、大規模なニューラルネットワークを用いる場合、学習過程だけでなく推論過程においても大規模な行列ベクトル積を実行しなければならない。このような状況に際し、深層学習をハードウェア実装する技術が注目されているが、多くの場合、当該ハードウェアはシステム本体とは別に実装されるため、光学系が複雑化する恐れがある。一方、本稿で紹介したSR-HDNNにはSR-HDSと同じ光学系で実装できるため、光学系の拡張なしに深層学習機能を内在したSR-HDSを実現できる可能性がある。その際問題になるのが、SR-HDNNにAP設計やデノイズのための画像生成・変換機能やブロック符号検出のための局所領域に対する動作が可能かどうかという点であるが、最近これらの動作が可能であることを示唆するシミュレーション結果が得られている。この結果については、発表の場において簡単に触れる。

## 謝辞

本稿で紹介した研究成果に多大な貢献していただいた九州工業大学の富岡莉生氏、千々和一輝氏、高津太一氏、江藤優太氏、透過行列に関して有益なご議論をいただいた北海道大学の渋川敦史准教授に感謝申し上げます。

## 参考文献

- (1) 志村努 (監修) : ホログラフィックメモリのシステムと材料, シーエムシー出版 (2006).
- (2) M. Takabayashi and A. Okamoto, "Self-referential holography and its applications to data storage and phase-to-intensity conversion," *Opt. Express* 21, 3669 (2013).
- (3) G. Wetzstein, *et al.*, "Inference in artificial intelligence with deep optics and photonics," *Nature* 588, 39 (2020).
- (4) J. Hu, *et al.*, "Diffractive optical computing in free space," *Nat. Commun.* 15, 1525 (2024).
- (5) R. Tomioka and M. Takabayashi, "Numerical simulations on optoelectronic deep neural network hardware based on self-referential holography," *Opt. Rev.* 30, 387 (2023).

- (6) 高林 正典, 富岡 莉生, “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,” フォトニクスニュース 9(3), 147 (2024).
- (7) 高林正典, 室園 大貴, 岡本 卓, “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, 17 (2017).
- (8) M. Takabayashi, *et al.*, “Recording procedures for high-quality signal readout in self-referential holographic data storage,” *Appl. Opt.* 54, 5167 (2015).
- (9) K. Chijiwa and Masanori Takabayashi, “Deep learning-based design of additional patterns in self-referential holographic data storage,” *Opt. Rev.* 31, 28 (2024).
- (10) S. Popoff, *et al.*, “Measuring the Transmission Matrix in Optics: An Approach to the Study and Control of Light Propagation in Disordered Media,” *Phys. Rev. Lett.* 104, 100601 (2010).
- (11) T. Shimobaba, *et al.*, “Convolutional neural network-based data page classification for holographic memory,” *Appl. Opt.* 56, 7327 (2017).
- (12) S. Kurokawa and S. Yoshida, “Demodulation scheme for constant-weight codes using convolutional neural network in holographic data storage,” *Opt. Rev.* 29, 375 (2022).