

[招待講演] 深層学習に基づく無線通信技術 — 研究の現状と展望 —

和田山 正†

† 名古屋工業大学

〒 466-8555 名古屋市昭和区御器所町

E-mail: †wadayama@nitech.ac.jp

あらまし 近年の無線通信工学に関する研究においては、大容量・高信頼・低遅延性を持つ無線通信ネットワークの構築が目標とされており、特に無線物理層における無線通信系アルゴリズム (MIMO 復調、誤り訂正符号の復号、等化処理、通信路推定、端末位置推定など) の高性能化への要求がますます高まりつつある。一方、深層学習技術は、画像認識、音声認識、自然言語処理などの分野において基盤技術としての位置を確立しており、それら以外の分野への応用研究 (医療分野や自動運転など) も増加の一途を辿っている。無線通信系の研究も例外ではなく、特に海外では深層学習技術に基づく無線通信技術に関する研究が非常に活発化してきている。5G から 6G へと移りゆく過程において、より高い性能が要求されるであろう通信系アルゴリズムに対して、深層学習技術が革新の端緒を与える可能性は高い。本講演では、まず深層学習の基礎的事項を簡潔に紹介した上で、無線通信の代表的な問題に対して深層学習技術がどう貢献するのかを関連研究をベースにして論じる。さらに最近の深層学習を利用した無線通信系アルゴリズムに関する研究の動向を紹介する。

キーワード 無線通信, 機械学習, 深層学習

[Invited Talk] Deep Learning-Aided Wireless Communications — Overview and Prospects —

Tadashi WADAYAMA†

† Nagoya Institute of Technology,

Gokiso-cho, Showa-ku, Nagoya, 466-8555 Japan

E-mail: †wadayama@nitech.ac.jp

Abstract Towards next generation wireless networks with high speed, low latency, and massive capacity, high performance algorithms for wireless communications are required such as massive MIMO detection, decoding of error correcting codes, equalization, channel estimation, and terminal localization. Deep learning (DL) has been established as a standard technology in the fields such as image recognition, speech recognition and natural language processing. Recently, applications of deep learning to wireless communications is becoming a hot topic because of the expectation such that it leads to novel algorithms outperforming the conventional ones. In this talk, basic strategies to combine DL and wireless communication algorithms are first introduced and a brief survey of related works is then given.

Key words Wireless communications, machine learning, deep learning, wireless physical layer

1. はじめに

近年、無線通信技術の開発に機械学習技術を積極的に利用していく機運が急速に高まりつつある。例えば、IEEE ICC や Globecom においては、ここ数年で機械学習と関連のある無線

通信技術に関する研究発表やワークショップ、チュートリアルが急増中であり、多くの参加者の興味を惹きつけている。いまこの時期に機械学習技術を無線通信技術に取り入れていくという流れが顕在化してきたのにはいくつかの理由があると考えられる。まず1つ目の理由は、深層学習技術 [9] の登場である。よく

知られているように深層学習技術、ならびにその応用に関する研究が様々な分野において爆発的な勢いで進展中である。画像認識 [1, 2]・音声認識 [4, 12] などの分野においては、特定の状況において人間の認識能力に匹敵する認識性能を与える深層学習ベースの認識アルゴリズムが報告されている。また自然言語処理 (テキスト分類・機械翻訳など) の分野でも、深層学習技術は広く活用され始めている。深層学習技術がもたらしたブレークスルーは、従前では機械学習技術と関連が薄いと思われていた分野 (医療分野・材料工学など) にも波及しつつあり、本講演の主題とする無線物理層における研究開発もその例外ではない。

2つ目の理由は、より複雑な無線通信環境の到来である。スタートが間近である 5G やその先に来ようであろう 6G で利用が見込まれるミリ波 (さらにテラヘルツ波) を利用するセルラ通信では、高度なビーム形成・ユーザ位置推定・電力等リソース割り当て・スペクトルセンシングなどを実現していく必要がある。これらの実現のためには、リアルタイムに大規模な凸最適化問題、または非凸最適化問題を解くことが求められる。無線通信品質を左右する信号検出アルゴリズムへの技術的要求も将来的により厳しくなることが予想される。例えば、ミリ波 Massive MIMO 信号検出や大量のパイロット信号が必要とされないブラインド型通信路推定、より高度化した誤り訂正符号の復号などの処理が必要とされ、これらはいずれも計算量的に困難な信号処理である。深層ニューラルネットワークに基づく最適化・信号処理技術は、これらの難題に対する一つの処方箋として期待されている。

3つ目の理由は、社会全体の AI・機械学習技術への需要の増加である。自動運転・デバイス間通信など自律的システムの台頭により、AI 技術と無線通信技術はより密接な連携を深めることが予想される。そのような時代においては、大規模な分散 AI 技術を支えることが無線通信の非常に重要なタスクになるとともに、逆に分散 AI 技術に支えられた高度機能を有する無線ネットワークの出現が予想される。それほど遠くない未来において、AI 技術と無線技術は、いわば表裏一体・渾然一体の形で社会の根幹に根付いていくのではないだろうか。

本講演では、まず深層学習の基礎的事項を簡潔に紹介した上で、無線通信の代表的な問題に対して、深層学習技術がどのように貢献するのかを関連研究をベースにして論じる。そして最近の深層学習を利用した無線通信系アルゴリズムに関する研究の動向を紹介する^(注1)。

2. 深層学習に関する基礎的事項

本節では、本稿の議論で必要とされる深層学習に関する基礎的事項 [9] を解説する^(注2)。

2.1 2 値推定関数の学習

いま、統計的性質が全く未知の通信路 $P(y|x)$ が与えられているものと仮定しよう。関数 $P(y|x)$ は条件付確率密度関数を

表し、 $\mathbf{y} \in \mathbb{R}^n$ であり、 $x \in \{+1, -1\}$ である。すなわち、送信器は $x = +1$ もしくは、 $x = -1$ の信号を通信路に入力する。そして受信器は、確率密度関数 $P(\mathbf{y}|x)$ に従う受信ベクトル \mathbf{y} を受信する。受信側では、送信シンボルを可能な限り正しく推定したいものとする。さらに、受信器はデータセット $D := \{(x_1, \mathbf{y}_1), (x_2, \mathbf{y}_2), \dots, (x_K, \mathbf{y}_K)\}$ を保持している。ここで、 \mathbf{y}_i は x_i に対応する受信語であり、 $\mathbf{y}_i \sim P(\mathbf{y}|x_i)$ である。

もし、 $P(\mathbf{y}|x)$ が完全に既知の状況ならば、最尤推定則 $\hat{x} := \arg \max_{x \in \{+1, -1\}} P(\mathbf{y}|x)$ に従い、尤度の最大化により誤り率最小の推定が可能である。しかし、上記の仮定では、 $P(\mathbf{y}|x)$ が未知であるので最尤推定則を直接利用することはできない。ここでは、最尤推定則の代わりに、推定関数 $\hat{x} = f(\mathbf{y})$ をデータセットから学習するというアプローチを考える。この問題は、機械学習の文脈においては、2 クラス判別問題と呼ばれる問題設定である。

以下では、推定関数 f が複数の学習可能パラメータの集合 Θ により特徴づけられているとする。具体的な関数の内部構造としては、深層ネットワークモデルと呼ばれる深層ニューラルネットワーク (2.2 節参照) を仮定する。深層ネットワークモデルに含まれる学習可能パラメータの値を変更することで関数 f の形状が変化する。以下では、学習可能パラメータへの依存を明示するため、 $\hat{x} = f(\mathbf{y}; \Theta)$ と表記することにしよう。

機械学習の文脈では、学習プロセスとは、与えられたデータセット D に基づき、誤差関数 (もしくは、損失関数) を最小化するようにパラメータ Θ を調整する過程を指す。データセット全体を一度に利用して Θ の最適化を行うバッチ学習法ではなく、深層学習においては一般的にミニバッチ学習法が利用される。ミニバッチ学習法では、 D の部分集合 $D_{mini} \subset D$ をランダムに選び出し、例えば 2 乗誤差関数に基づく誤差関数を

$$E(\Theta) := \frac{1}{|D_{mini}|} \sum_{(x, \mathbf{y}) \in D_{mini}} |x - f(\mathbf{y}; \Theta)|^2 \quad (1)$$

と定義する^(注3)。この $E(\Theta)$ に基づき Θ を更新する処理を確率的勾配法と呼ぶ。確率的勾配法では誤差関数の勾配ベクトル $\nabla E(\Theta)$ に基づくパラメータ更新式 $\Theta := \Theta - \alpha \nabla E(\Theta)$ を反復的に複数回実行する^(注4)。ただし、実行ごとにミニバッチ D_{mini} の内容はランダムに選択されるものとしている。ここで α は学習係数と呼ばれる正実数である。このようにして得られたパラメータを Θ^* とするとき、受信側では、推定則 $\hat{x} = f(\mathbf{y}; \Theta^*)$ を利用して、推定信号を得ることができる。ただし、学習プロセスの最終的な目標は誤差関数の最小化ではなく、訓練中に見ることがなかった入力に対して質の良い推定値を出力する推定器を学習することにあり、その意味では推定器の“汎化性能”が推定性能を決めることに注意しておきたい。

上記の深層ネットワークと勾配法による学習プロセスは、線形シンボル干渉通信路における等化器のタップ係数を定めるた

(注1): 本稿のサーベイはそれほど詳細なものではない。最近では、[25] などの良質な分野サーベイも出始めているので、是非そちらも参考にしていきたい。

(注2): さらに深層学習技術の詳細に興味のある読者は、定番の教科書 [9] などを参照されることを勧める。

(注3): 判別問題では、誤差関数としてクロスエントロピーが利用されることが多いが、ここでは簡単化のため 2 乗誤差関数を例として挙げた。

(注4): Θ を集合として定義しているので、正確には左辺の記述は厳密ではない。計算手続きを表す一種の疑似コードと考えておいていただきたい。

めの訓練プロセスに類似している [19]。実際、通信路が線形システムとして記述でき、 f として線形モデルを利用するならば、線形等化器の訓練と深層学習における学習プロセスは、強い類似性を持つ。

線形等化器の学習と状況が異なる点についても、言及しておきたい。次の節において示す深層ネットワークモデルにおいては、通常、複数の非線形関数が活性化関数として利用されている。これらの非線形要素の影響で誤差関数は一般には非凸関数となる。よく知られるように非凸関数の大域的最小値を見出すことは計算量的に非常に困難であり、また、その目的関数は多数の停留点、極小値を持つ。この点は、誤差関数が凸関数となる線形システムの場合との大きな違いである。

2.2 深層ネットワークモデル

図 1 に $f(y; \Theta)$ の構造である深層ネットワークモデルを示す。

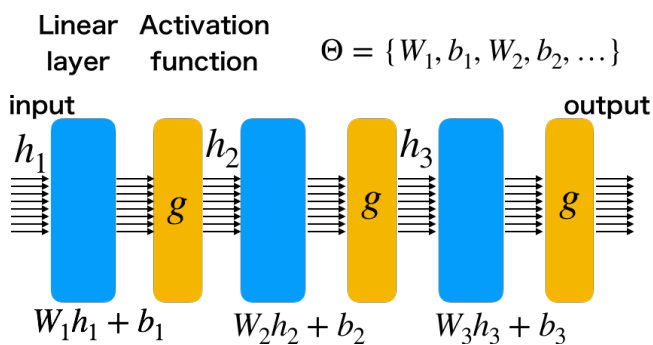


図 1 深層ネットワークモデル $f(y; \Theta)$ の構造

同図を左側から見ていこう。入力ベクトルをここでは $h_1 \in \mathbb{R}^{n_1}$ とする。入力信号 h_1 は線形層^(注5)と活性化関数層を通り、中間出力 $h_2 := g_1(W_1 h_1 + b_1)$ に変換される。ここで、 $h_2 \in \mathbb{R}^{n_2}$ であり、行列 $W_1 \in \mathbb{R}^{n_2 \times n_1}$ は学習可能パラメータである。ベクトル $b_1 \in \mathbb{R}^{n_2}$ はバイアスベクトルと呼ばれ、これも学習可能パラメータである。関数 $g_1: \mathbb{R} \rightarrow \mathbb{R}$ は活性化関数と呼ばれる関数である。機械学習系の論文においてよく利用される記法であるが、関数 $g: \mathbb{R} \rightarrow \mathbb{R}$ と $h = (h_1, h_2, \dots, h_n)^T \in \mathbb{R}^n$ に対して、 $g(h) := (g(h_1), g(h_2), \dots, g(h_n))$ と定義する。深層学習でよく利用される活性化関数として、ReLU 関数・シグモイド関数・双曲線正接関数・恒等関数・ソフトマックス関数 [9] などが挙げられる。

深層ネットワークモデルでは、同様の部分構造 $h_{i+1} := g_i(W_i h_i + b_i)$ が反復的に繰り返されて最終的に h_T が出力される。モデル内のすべての学習可能パラメータをまとめると $\Theta := \{W_1, b_1, W_2, b_2, \dots, W_{T-1}, b_{T-1}\}$ となる。画像認識によく利用される畳み込み型深層ニューラルネットワークでは、行列 W_i に対して特殊な構造 (畳み込み層やプーリング層) が課されているが、図 1 に示される構造がその基本構造となる。

確率的勾配法を利用するためには、これらパラメータ W_i, b_i に含まれる要素の偏微分値を効率よく計算する必要がある。こ

れらの学習パラメータの勾配ベクトルを計算するためには、誤差逆伝播法 [20] が利用される。この誤差逆伝播法の実行時間が深層学習の学習プロセスの計算時間において支配的である。

適切な確率的勾配法の選択 (SGD, RMSprop, Adam など [9])、学習率の設定とそのスケジューリング、ミニバッチサイズなどは、ミニバッチ学習において重要なハイパーパラメータ群であり、学習結果の良否はこれらの設定の良し悪しに強く影響される。良いハイパーパラメータ設定を見つけるためには、場合によってはかなりの試行錯誤のプロセスが必要となることもある。

3. 深層学習を利用した無線通信系技術

深層学習技術に基づく無線通信系技術に関する論文・国際会議発表はすでに膨大な数になっているため、それらを脈絡なく紹介するのは、時間と紙幅がいくらあってもキリがない。そこで、本講演では関連技術を下記の通り、大きく 5 つのカテゴリ:

- (1) ブラックボックスモデル [18]
- (2) 深層展開 (deep unfolding) [10] [22]
- (3) 最適化模擬 (learning to optimize) [23]
- (4) 分散学習 (distributed learning) [24]
- (5) 強化学習

に分類し、そのカテゴリの特徴と著者の主観のもとに選んだ代表的な研究について紹介を行う。ただし、筆者の力量と紙幅の関係から、本稿では (1)(2) に議論を絞る。

3.1 ブラックボックスモデル

現実の通信路において取得された実データ、または信頼されている通信路モデルに従ってランダムに生成された人工データに基づいて、深層ネットワークモデルで表現された通信路系全体や推定器を学習することは可能である。そのような通信路モデルや推定器では、通信路の統計的モデルに関する事前知識を全く利用せず、言わばブラックボックスとして深層ネットワークを扱うことから、本稿ではこの種のモデルをブラックボックスモデル呼ぶ。ブラックボックスモデルにより、推定器をニューラルネットワークを構成したり、送信信号点配置の設計を行うことが可能となる。

ブラックボックスモデルに基づき構成された深層ネットワークの学習プロセスにおいては、訓練データ以外には何も必要とされておらず、その意味では、未知の通信路に対して最大限の柔軟性を持つ通信システムを構成するために有効な手法であると考えられる。また、通信中にオンラインで学習する仕組みを付与するならば、通信路の統計的特性の時間的変化に対して高い追従性を持つ方式を実現できる可能性がある。

ブラックボックスモデルのひとつの欠点のひとつは、学習の結果得られたパラメータを見ても、その深層ネットワークの動作機序を読み取ることがほぼ不可能である点が挙げられる。この種の問題は、“解釈可能性 (interpretability) 問題” として知られている。学習の結果得られた推定器に何らかの不備があった場合でも、その不備の理由を探りだすことは困難であり、その解決策を見出すことも容易ではない可能性がある。

(注5): 実際にはアフィン変換だが慣習的に線形層と呼ばれる。

また、通信技術者・研究者の立場からは、過去からの知見・知識を有効に通信系アルゴリズムの設計に活かしたいと考えるのが至極自然であるが、そのような知見を盛り込むことが難しい点も（少なくとも筆者にとっては）多少の不満の残るところである。

3.1.1 自己符号化器による通信路の模擬

O'Shea と Hoydis [18] は、通信系（送信側・通信路・受信側）全体を自己符号化器（autoencoder）としてモデル化するというアイデアを提案した。自己符号化器では、深層ネットワークモデルの入出力関係を $\hat{x} = f(x; \Theta)$ とするとき、 $\hat{x} \simeq x$ となるように学習時に Θ を調整する（図 2 参照）。




図 2 自己符号化器による通信路の模擬

入力 s とネットワークから得られる推定出力 \hat{s} の間の誤差が小さくなるように自己符号化器を訓練することにより、送信側では信号点配置の自動設計が、受信側では対応する信号推定器の自動設計が可能になることを彼らは実験的に確認した。自己符号化器ネットワークは、現実の通信路に即した雑音を送信信号に加える雑音レイヤ、送信信号に関する制約条件（例えば、平均エネルギー制約）を満足させるための正規化レイヤを含む。例えば、通信路が非線形歪・非線形干渉を持ち、信号依存性雑音が生じるような場合、所望の条件（平均エネルギー制約など）を満たしつつ、その通信路に適した信号点配置を見出す問題は単純な問題ではない。彼らの手法は、複雑な通信路モデルに対する信号点配置設計のための新しいアプローチを提供している。

3.1.2 深層ネットワークに基づく信号推定器

O'Shea らの仕事は、送信器・受信器を含む通信系全体をニューラルネットワークでモデル化するというアプローチであったが、受信器（信号推定関数）のみをニューラルネットワークでモデル化する試みも盛んに行われている。信号検出問題の代表的な例として、MIMO 検出問題を考える。よく知られるように MIMO 最尤信号検出問題は、計算量的に困難なクラス（NP 困難問題）に属する問題であり、変調信号点数・送受信アンテナ数が増加すると最尤推定法の計算量が指数的に増大してしまう。ZF, MMSE 復調といった簡便な推定法による推定精度は、最尤推定に比べて著しく劣るため、最尤推定法と MMSE 復調との間に位置する近似的推定法の研究開発には大いに意義があ

る。Samuel らは彼らの論文で 2 種類のニューラルネットワークに基づく MIMO 検出器を提案している。そのうちの 1 つ目（FullyCon）が深層ネットワークモデルに基づく MIMO 検出器である。Farsad [8] らは、RNN（Recursive Neural Network）を利用したボアソン通信路に対する信号検出アルゴリズムを提案している。Gruber らは、誤り訂正符号の復号器を深層ネットワークで表現し学習することを提案している [11]。ただしこのアプローチで取り扱える符号長は極めて短い（16 ビット程度）ようである。

3.2 深層展開

反復的構造を持つ信号処理・通信系アルゴリズムの信号の流れを信号流グラフとして図 3(a) に示す。図中のサブプロセス A, B, C は多変数を入力とする非線形ベクトル値関数である。図 3(a) の反復処理過程を時間方向に展開して得られる信号流グラフを図 3(b) に示す。

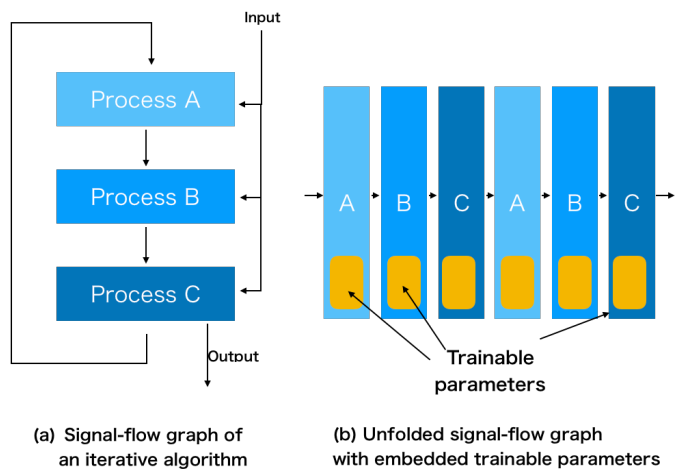


図 3 (a) 反復アルゴリズムの信号流グラフ, (b) 時間方向に展開された信号流グラフ (unfolded graphs)

入力信号は図 3(b) の信号流グラフの左側から入り、右方向に流れる。この展開された信号流グラフは、フィードフォワード型ニューラルネットワークに非常に良く似ている。実際、信号流グラフが含むサブプロセス A, B, C の非線形関数が微分可能であり、かつ、非ゼロの導関数値を持つ多変数関数であるならば、標準的な深層学習技術（誤差逆伝播法・確率的勾配法）をこの信号流グラフに適用することが可能である。すなわち、図 3(a)(b) のアルゴリズムの内部に調整可能なパラメータを埋め込んでおけば、ミニバッチ学習によりそれらのパラメータ値を調整することができる。

このように深層学習技術は必ずしもその対象が深層ニューラルネットワークに限られず、入出力を伴う“微分可能な反復型アルゴリズム”に対して適用することが可能である。従前から知られている優れた反復型アルゴリズムを基礎として、その中に学習可能パラメータや学習可能な構造（ニューラルネットワークに基づく可塑的な非線形関数^(注6)）を埋め込むことで、デー

(注6): 適切な条件を満たす多段ニューラルネットワークは万能関数近似器として利用することができる。

タに基づく学習可能性を持つ柔軟な派生アルゴリズムを構成できる。

このアプローチの可能性を最初に示したのは、スパース信号推定のための反復アルゴリズムである ISTA [3, 5] (Iterative Soft Thresholding Algorithm) の改良を行った Gregor と LeCun [10] である。最近では、このアプローチを深層展開 (deep unfolding) と呼ぶことが多くなってきている。また、LeCun は深層展開のコンセプトをプログラミング一般に広げた“可微分プログラミング” (differentiable programming) の概念を提唱している^(注7)。サーベイ文献 [22] は、深層展開の最近の研究動向をよくまとめている。

3.2.1 BP 復号アルゴリズムの改善

Nachmani ら [17] は、LDPC(Low-Density Parity-Check) 符号の復号アルゴリズムであるピリーフプロパゲーション (BP) 復号法の性能改善のために深層学習技術を初めて利用した。BP 復号法では、変数ノード処理・チェックノード処理により算出されるメッセージの交換を反復することにより復号プロセスが進行する。Nachmani らは、変数ノードメッセージに乗じる形の学習可能パラメータを導入し、ミニバッチ学習によりそれらの学習パラメータの最適化を行っている。実験の結果として、BCH 符号のように比較的密度が高い検査行列を持つ符号に対して、顕著な BP 復号特性の改善が確認されている。これは、復号に悪影響を及ぼすタナーグラフに含まれる短いループの影響を軽減するように乗数が学習されたものと考えられている。

3.2.2 スパース信号再現アルゴリズムの改善

圧縮センシング問題は、劣決定系である線形観測システムにおいて、線形観測ベクトルから元信号である疎ベクトルを推定する問題である。無線通信の文脈では、圧縮センシングは、通信路推定 (マルチパスフェーディング通信路)、到来波角度推定、スペクトルセンシング、MIMO 検出技術と深く関係している。本小節では、手前味噌になるが筆者のグループで行っているスパース信号再現アルゴリズムである TISTA [13, 14](Trainable ISTA) を紹介しつつ、関連の研究についても述べる。

圧縮センシングの問題設定を述べる。原信号 $x \in \mathbb{R}^N$ は非ゼロ要素数が N に対して十分に小さい疎ベクトルであると仮定する。観測ベクトル $y \in \mathbb{R}^M$ ($M < N$) は $y = Ax + w$ と与えられる。ここで、行列 $A \in \mathbb{R}^{M \times N}$ ($N > M$) は観測行列と呼ばれる実行列である。また、ベクトル $w \in \mathbb{R}^M$ は、ガウス雑音ベクトルである。圧縮センシングでは、与えられた観測ベクトル y から原信号 x を可能な限り高い精度で再現することを目標とする。注意すべき点は $M < N$ が仮定されていることから、この問題は劣決定性問題となっていることである。

疎ベクトル再現アルゴリズムは従来から様々な手法が知られているが、ここでは深層学習技術を利用するアルゴリズムのみ

を紹介する。Gregor と LeCun [10] は、反復型のスパース信号再現アルゴリズムである ISTA の中に登場する線形推定式の推定行列を学習可能パラメータとして学習するアプローチを提案した。この論文は、反復型信号処理アルゴリズムに対して、深層学習技術を適用した最初の論文である。学習の結果として、オリジナルの ISTA に対して大幅に収束速度の向上が得られることを示しており、深層学習技術の信号処理アルゴリズム設計における可能性を初めて示した論文として高く評価できる。Borgerding と Schniter [7] は、スパース信号再現アルゴリズムとして近年活発に関連研究が成されている AMP に学習可能パラメータを導入した。

伊藤・高邊・和田山ら [13, 14] は、ISITA に対して深層展開を適用し、スパース信号再現アルゴリズム TISTA を提案した。TISTA の最も大きな特徴は、ISTA 内の勾配法ステップにおいて現れるステップサイズパラメータを学習プロセスにより調節することにある。実験的評価の結果、ほとんどの場合、ISTA, LISTA, AMP, OAMP に比べて、TISTA の出力は解への速い収束を示すことが確認されている。また、広いクラスの観測行列 (2 値行列, 悪条件の行列など) において、TISTA は優れた収束性能を示しており、ロバストな性質を持つことが明らかになっている。TISTA は、ISTA に各層ごとにひとつの学習可能パラメータを導入するという形で構成された非常にシンプルな ISTA の派生アルゴリズムであるが、現時点で知られている強力なスパース信号再現アルゴリズム (AMP, LISTA, LAMP, OAMP) よりも高速な収束特性を示しており、この事実は、深層学習技術を利用した信号処理アルゴリズム設計の有用性、ならびに深層展開の可能性を示す一例になっている。例えば、TISTA を原型として、射影勾配法に基づく過負荷 MIMO 復調法 [16]、ペナルティ関数法に基づく LDPC 復号法 [15] が提案されている。

4. む す び

無線通信分野は、信号設計理論・信号検出理論・確率論・情報理論などの工学・数学の諸理論に支えられる工学分野であり、基本原則から演繹的に導かれたアルゴリズムがそのベースになっている。筆者自身も、長らく符号理論・誤り訂正符号の研究を続けていたこともあり、原理から理論的・演繹的にすっきり導かれるアルゴリズムに親しみを感じるとともに、アルゴリズムの構成原理として信頼を置いている。

しかし、深層学習を利用した通信系技術の研究をしていると、ふと上記とはまったく異なる気分になることがある。例えるなら、見たことのない生き物の生態を理解を試みる研究者が観察を通して対象の生態を薄皮を一枚づつ剥いていくように理解していく、そんな営みに近い気がする時がある。

深層学習を利用したアルゴリズムは、演繹的に単純な原理・原則から導いたアルゴリズムではなく、データセットから帰納的に構成されたアルゴリズムとなるため、内部で何が起きているのかを完全に理解することは困難であり、その動作機序についての確かな描像を持つことも難しい。すなわち、学習結果に関する解釈可能性の問題がどうしてもつきまとい、従来の立場

(注7): LeCun は facebook で可微分プログラミングについて次のようにコメントしている。“But the important point is that people are now building a new kind of software by assembling networks of parameterized functional blocks and by training them from examples using some form of gradient-based optimization.” <https://www.facebook.com/yann.lecun/posts/10155003011462143>

からは、どうもすっきりとした気分になれないときもある。

しかし、研究の過程を通して、深層学習技術により従来法ではできなかったことが可能になる事例、従来法で到達できない性能に到達できる事例などを実際に見るにつれて、深層学習技術を利用した通信技術に対して、われわれ研究者としても考え方を切り替えて付き合っていくことが求められているのではないかと徐々に思えてきつつある。たとえブラックボックス的部分が残ったとしても、観察や実験結果を積み上げてアルゴリズムに対して十分な理解を得ることができるならば、情報通信工学への着実な貢献となり得るのではないだろうか。

本稿で紹介できなかった話題も多いが(例えば、量子化器設計問題 [21])、ここで論じた研究課題の多くは機械学習と通信工学に跨る研究課題であり、それらにアプローチするためには分野横断的な研究姿勢が求められる。冒頭で述べた 6G に向けた複雑な無線環境の到来や社会全体の AI・機械学習技術への需要増大に応える無線通信技術を開発するためには、機械学習技術への前向きなコミットが無線通信関連研究者・技術者に求められる状況になりつつあるように感じている。

深層学習技術を利用する無線通信技術に関する研究発表が活性化してきたのは、ここ 2,3 年のことであり、まだまだ価値あるアイデアが発見されず埋もれている可能性は高いものと思われる。特に若手研究者の参入を期待したい。

謝 辞

本講演の機会を与えてくださった電子情報通信学会 RCS 研究会の皆様へ感謝申し上げます。大阪市立大学の林和則氏には、様々な機会に無線通信技術についてご教示いただいた。名古屋工業大学の高邊賢史氏との日頃の議論は本稿の内容に対して大いに影響を与えている。両氏に厚く感謝の意を表する。本稿の研究の一部は、科研費基盤 (A)17H01280、科研費基盤 (B)19H02138 に基づく。

文 献

- [1] G. E. Hinton, R. R. Salakhutdinov, "Reducing the dimensionality of data with neural networks," *Science*, vol. 313, no. 5786, pp. 504-507, Jun. 2006.
- [2] A. Krizhevsky, I. Sutskever, G. E. Hinton, "Imagenet classification with deep convolutional neural networks." *Advances in Neural Inf. Proc. Sys.* 2012, pp. 1097-1105, 2012.
- [3] A. Chambolle, R. A. DeVore, N. Lee, and B. J. Lucier, "Nonlinear wavelet image processing: variational problems, compression, and noise removal through wavelet shrinkage," *IEEE Trans. Image Process.*, vol. 7, no. 3, pp. 319-335, Mar, 1998.
- [4] G. E. Dahl, D. Yu, L. Deng and A. Acero, "Context-Dependent Pre-Trained Deep Neural Networks for Large-Vocabulary Speech Recognition," in *IEEE Transactions on Audio, Speech, and Language Processing*, vol. 20, no. 1, pp. 30-42, Jan. 2012.
- [5] I. Daubechies, M. Defrise, and C. De Mol, "An iterative thresholding algorithm for linear inverse problems with a sparsity constraint," *Comm. Pure and Appl. Math.*, col. 57, no. 11, pp. 1413-1457, Nov. 2004.
- [6] D. L. Donoho, A. Maleki, and A. Montanari, "Message-passing algorithms for compressed sensing," *Proceedings of the National Academy of Sciences*, vol. 106, no. 45, pp. 18914-18919, Nov. 2009.
- [7] M. Borgerding and P. Schniter, "Onsager-corrected deep

- learning for sparse linear inverse problems," 2016 IEEE Global Conf. Signal and Inf. Proc. (GlobalSIP), Washington, DC, Dec. pp. 227-231, 2016.
- [8] N. Farsad, and A. Goldsmith, "Neural Network Detection of Data Sequences in Communication Systems," *IEEE Transactions on Signal Processing*, vol. 66, Issue: 21, pp. 5663-5678, Nov., 2018.
- [9] I. Goodfellow, Y. Bengio, A. Courville "Deep learning," The MIT Press, 2016.
- [10] K. Gregor, and Y. LeCun, "Learning fast approximations of sparse coding," *Proc. 27th Int. Conf. Machine Learning*, pp. 399-406, 2010.
- [11] T. Gruber, S. Cammerer, J. Hoydis, and S. ten Brink, "On deep learning-based channel decoding," arXiv:1701.07738, 2017.
- [12] G. Hinton, L. Deng, D. Yu, G. Dahl, A. Mohamed, N. Jaitly, A. Senior, V. Vanhoucke, P. Nguyen, T. Sainath, and B. Kingsbury, "Deep neural networks for acoustic modeling in speech recognition: The Shared Views of Four Research Groups," *IEEE Signal Processing Magazine*, vol. 29, no. 6, pp. 82-97, Nov. 2012.
- [13] D. Ito, S. Takabe, and T. Wadayama, "Trainable ISTA for sparse signal recovery," *IEEE International Conference on Communications (ICC2019), Workshop on Promises and Challenges of Machine Learning in Communication Networks*, Kansas city, May, 2018.
- [14] D. Ito, S. Takabe, and T. Wadayama, "Trainable ISTA for sparse signal recovery," *IEEE Trans. Signal Processing*, vol. 67, no. 12, pp. 3113-3125, Jun., 2019.
- [15] T. Wadayama and S. Takabe, "Deep learning-aided trainable projected gradient decoding for LDPC Codes," accepted to *IEEE Int. Symposium on Information Theory (ISIT)*; arXiv:1901.04630, 2019.
- [16] S. Takabe, M. Imanishi, T. Wadayama, and K. Hayashi, "Deep learning-aided projected gradient detector for massive overloaded MIMO channels," *IEEE International Conference on Communications (ICC2019)*; ; <https://arxiv.org/abs/1806.10827>, 2019.
- [17] E. Nachmani, Y. Beéry and D. Burshtein, "Learning to decode linear codes using deep learning," *2016 54th Annual Allerton Conf. Comm., Control, and Computing*, pp. 341-346, 2016.
- [18] T. O'Shea and J. Hoydis, "An introduction to deep learning for the physical layer," *IEEE Transactions on Cognitive Communications and Networking*, vol.3, issue 4, pp. 563-575, 2017.
- [19] J. G. Proakis, "Digital communications," McGraw-Hill Book, 1989.
- [20] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Learning representations by back-propagating errors," *Nature*, vol. 323, no. 6088, pp. 533-536, 1986.
- [21] T. Wadayama and S. Takabe, "Joint quantizer optimization based on neural quantizer for sum-product decoder," *IEEE Globecom, Abu Dhabi*; arXiv:1804.06002, 2018.
- [22] A. Balatsoukas-Stimming and C. Studer "Deep unfolding for communications systems: a survey and some new directions," arXiv:1906.05774, 2019.
- [23] H. Sun, X. Chen, Q. Shi, M. Hong, Xiao Fu, and N. D. Sidiropoulos, "Learning to optimize: training deep neural networks for interference management," *IEEE Trans. on Signal Processing*, vol.56, no.20, pp.5438-5453, Oct., 2018.
- [24] J. Konecny, H. B. McMahan, D. Ramage, P. Richtik, "Federated optimization: distributed machine learning for on-device intelligence," arXiv:1610.02527, 2018.
- [25] D. Guinduz, P. de Kerret, N. D. Sidiropoulos, D. Gesbert, C. Murthy, M. van der Schaar, "Machine learning in the air," arXiv:1610.02527, 2018.