

複素振幅を扱うニューラルネットワークとそのエレクトロニクスにおける利点

廣瀬 明[†] 丁 天本[†]

Neural Networks to Deal with Complex Amplitude and Its Strength in Electronics

Akira HIROSE[†] and Tianben DING[†]

あらまし 本論文は、複素ニューラルネットワークのエレクトロニクスでの利点を、概念的な側面と具体的な例示によって議論する。本質的に複素ニューラルネットワークは波動を扱う際に有効な汎化特性をもつ。複素数の実 2×2 行列表現を見ながらこれを論じる。また具体例として、通信チャネルを一つの複素実体として捉えて移動体通信のチャネル予測に複素ニューラルネットワークを適用する場合を挙げ、その優位性と背景にある考え方を述べる。

キーワード 汎化、複素ニューラルネットワーク、レーダイメージング、合成開口レーダ、通信チャネル予測

1. まえがき

脳の機能がどのように発現し発揮されるのか、その基本原理の解明を目指して、ニューラルネットワークの研究は数理・物理・生理・心理が協力することで推進されてきた。それに加えて、脳の原理を工学的に役立て、人間の脳を一面では超える機能を実現することも研究の重要な側面である。複素ニューラルネットワークは、その取り扱う信号やニューロンの荷重が複素数であるニューラルネットワークである[1]~[6]。その性質や利用について、本会誌の特集号も含めて、広範な分野でさまざまに示されてきた[7]。例えば、位相周期性を有効利用した情報分類手法[8]や、いわゆる連想記憶のダイナミックス[9]、層状ニューラルネットワークのダイナミックスの変化とカオスの関係[10],[11]や予測機能[12]、位相表現と多値複素ニューロンによる画像の修復[13]、通信での信号表現方法[14]、更には3次元に拡張された複素数である四元数を使ったカラー画像処理[15]など、多種多様である。

複素ニューラルネットワークは、人間の生理・心理の解明を目的とするというよりは、むしろニューラル

ネットワークの考え方を生かした数理的・物理的な面白さの探求や電気電子分野を中心とする工学利用を指向している[16]~[18]。電気電子工学的には、複素ニューラルネットワークは複素振幅を扱うニューラルネットワークである、と言える。あるいは位相情報を整合的に扱うコヒーレントなニューラルネットワークである、と表現できる。電波伝搬の位相や偏波を考慮する必要がある衛星・航空機搭載合成開口レーダ[19]~[22]や地中レーダ[23]~[26]、また量子コンピューティング[27]~[29]などは、その強みが最も発揮されると期待される工学分野である。光波コンピューティングや波動情報の学習[30]、周波数多重で学習する光波ニューロコンピューティング[31],[32]なども複素ニューロに特徴的である。エレクトロニクス利用をターゲットにした学習や処理の性質の理論解析も増えている。複素多様体での検討[33],[34]や、通信システムでの特性解析[35]などがある。

これを逆に、エレクトロニクスの視点から次のように見ることもできる。学習や自己組織化といった適応的な信号情報処理は、アダプティブアンテナや散乱逆問題などの分野を中心に、古くから広く利用されてきた[36]。線形な適応処理では、複素数を扱う複素最小2乗アルゴリズムが1975年に提案され[37]、最急降下法や共役勾配法などの複素領域での反復最適化に利用されている[38]。複素ニューラルネットワークは、こ

[†] 東京大学大学院工学系研究科電気系工学専攻, 東京都

Department of Electrical Engineering and Information Systems, The University of Tokyo, 7-3-1 Hongo, Bunkyo-ku, Tokyo, 113-8656 Japan

れを更に一般化し、非線形性を取り入れたり、階層構造等のさまざまな結合様式を許したりしたものである、という見方も可能である。このような視点も含め、最近の特集号 [39] でも複素ニューラルネットワークの理論論 [40], [41] とその応用面 [42]～[45] の双方で活発な議論が行われている。

一般にニューラルネットワークを道具として利用する研究者の一部は、次のような意見をもつかもしれない。「ニューラルネットワークは問題の解決方法をブラックボックスにしてしまい、解決の道筋を提示しない。」しかし、これは誤解である。古くは砂時計型ニューラルネットワーク、またネオコグニトロン [46], [47] やそれを含む畳み込みニューラルネットワークや近年のディープラーニング（深層学習）にみられるように、問題の分析や特徴抽出を行うニューラルネットワークも多く存在する。ニューラルネットワークは外界をよく反映する。そのため、課題に応じたより良い形でニューラルネットワークを準備することも可能である。それはアダプティブアンテナの状況を考えても明らかである。複素ニューラルネットワークは、「波動の物理を取り込んだニューラルネットワーク」であると言ってもよい。またそれは、電波伝搬・散乱の物理（モノ）と適応的・統計的な情報処理の数理（コト）を融合するものである。

複素ニューラルネットワークは、例えば宇宙からの地球観測でもその威力を発揮している。その概念を図 1 に示す。地上数百 km 上空の人工衛星からマイクロ波を地表に照射し、合成開口技術によって地表散乱の状況に依存した散乱波の振幅、位相、偏波などを観測して、地表の情報を得ようとする。その際、電波伝搬にとまらぬ回折や屈折、干渉、空間的・時間的な離散化などによりデータに歪が生じる。この物理と計測に依存してひずんだデータから、知りたい地表の真の情報を得るためには、それをより良く推定・予測する技術が必要になる。そこに、電波伝搬の物理を上手に反映するニューラルネットワーク適応処理が大いに活躍する [48], [49]。それが、波動現象を前提とする表現を用いる、複素振幅ニューラルネットワークである。また同時に、その作業は、適応的また統計的に情報を扱うための数理を波動の物理と融合することでもある。

その有用性は広がりつつある。位相情報に基づく広範で精密な地形変化の計測による火山・地震の災害把握や減災、氷河・極地雪氷や森林バイオマスの観測による地球温暖化監視、偏波情報をアダプティブに利用




図 1 「電波伝搬や散乱の物理を取り込んで推定や予測を実現する脳機能」の発想の概念図 [1]

Fig.1 Conceptual illustration to represent “the brain functioning as estimator and predictor intrinsically based on the physics of electromagnetic-wave propagation and scattering” [1].

した穀物収量把握など、現代社会が直面している幅広い課題の解決に資する技術基盤になりつつある。

本論文の構成は次のとおりである。2. で複素ニューラルネットワークに特徴的で本質的な次の点について考察する。すなわち、波動利用コンピューティングや波動信号情報処理に適した汎化特性である。3. で、具体的な例として移動体通信におけるチャネル予測を取り上げる。4. はまとめである。この考察を、複素ニューラルネットワークのエレクトロニクスでの今後の一層の展開に役立つものとした。

2. 汎化特性

汎化特性は、ニューラルネットワークに限らず適応的な処理を行う際にきわめて重要な概念である。ここでは、複素ニューラルネットワークの汎化特性 [48] を詳しく見る。

2.1 自由度、スパース性

一般にニューラルネットワークはそれが含むニューロン間結合の荷重の値を信号や環境に応じて調節することにより、所望の機能を得る。その調節は、学習（教師あり学習や強化学習）であったり、自己組織化（教師なし学習）であったりする。このとき調節される荷重の個数が多いほど、適応の自由度が高い。

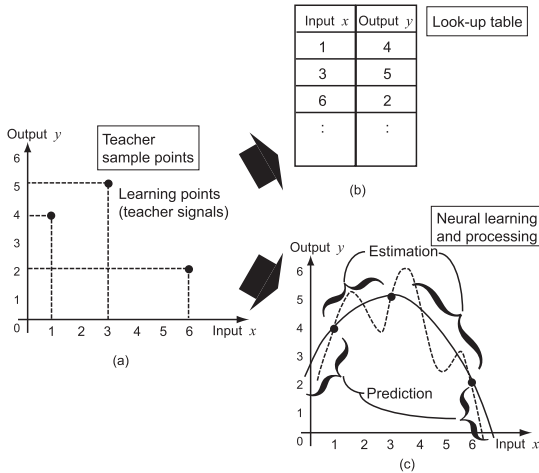


図 2 (a) 入力-出力教師サンプル信号対のセット, (b) 参照テーブル, 及び (c) ある汎化特性 (実線) 及び別の汎化特性 (破線) をもつ場合の推定や予測の処理
 Fig. 2 (a) A set of teacher input-output signals, (b) a look-up table and (c) processing with one (solid) or another (broken) generalization characteristic for estimation and prediction.

ここでは具体的に、ニューラルネットワークの教師あり学習による関数近似を考える。図 2(a) に示すような 3 点で表される三つの 1 入力 x - 1 出力 y の関係を教師あり学習で学習する。これらの点は学習点または教師点とよばれる。それらを \hat{x} をつけて表すことにすれば図 2 の例の場合、 $(\hat{x}, \hat{y}) = (1, 4), (3, 5), (6, 2)$ の 3 点である。この状況は、アダプティブアンテナでパイロット信号を使って荷重を最適化する場合や、散乱逆問題で例題を学習する場合に相当する。もしこの 3 点の状況のみを学習したいならば、実は学習は不要である。図 2(b) の参照テーブルを作成 (メモリに記録) するだけでよい。しかしここで期待したいのは、図 2(c) に示すように、学習した入力以外の入力値に対しても、なんらかの適切な出力をだすことである。その能力を汎化能力とよび、その出力特性を汎化特性とよぶ。良い汎化特性は、3 つの学習点での学習誤差の二乗和 $\sum (y - \hat{y})^2$ を 0 にするだけでは達成できない。ただし y は、入力 \hat{x} に対する学習の途中や終了時の出力の値である。また実は、どのような曲線が良い汎化特性であるのかは、具体的なタスクが決まらなければ判断ができない。

一般に、自由度が小さすぎると教師点で学習誤差が 0 に収束しない。一方、自由度が大きすぎると関数が必要以上に蛇行し、適切な推定や予測ができなくなっ

てしまう。適度な自由度が好ましい。例えば、多めのニューロンや荷重を用意しておき、学習中に追加のダイナミクスによって結合を間引いてスパース (疎) にすることも行われることがある。また、0 でない荷重の結合を少なくするものの、残ったものが有意義な、すなわちタスクに合致した、機能につながるように、その性質を吟味することが重要になる。この意味で、荷重を複素数にすることは波動情報を扱う際に非常に有効である。これは次のように理解できる。

2.2 複素数の実 2×2 行列表現

複素数の表し方にはさまざまなものがある。ハミルトンは 1835 年に複素数 z を実数 x と y の順序対によって $z \equiv (x, y)$ と表し、代数的に定義した。その和と積の定義は次のとおりであり、特に積が複素数の特徴づける。

$$(x_1, y_1) + (x_2, y_2) \equiv (x_1 + x_2, y_1 + y_2) \quad (1)$$

$$(x_1, y_1) \cdot (x_2, y_2) \equiv (x_1 x_2 - y_1 y_2, x_1 y_2 + y_1 x_2) \quad (2)$$

また次のように、複素数は 2×2 実行列で表すこともできる。別の複素数 $c = a + ib$ (ただし i は虚数単位) を z に対して作用する C 線形写像に対応付けることができる。

$$T_c : C \rightarrow C, z \mapsto cz = ax - by + i(bx + ay) \quad (3)$$

ここで複素平面 C を 2 次元の実空間 R^2 と同一と考える。

$$z = x + iy = \begin{pmatrix} x \\ y \end{pmatrix} \quad (4)$$

すると、次のように複素数は行列で表すことができる。

$$\begin{aligned} T_c \begin{pmatrix} x \\ y \end{pmatrix} &= \begin{pmatrix} ax - by \\ bx + ay \end{pmatrix} \\ &= \begin{pmatrix} a & -b \\ b & a \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix} \end{aligned} \quad (5)$$

すなわち、 $c = a + ib$ である変換 T_c は行列 $\begin{pmatrix} a & -b \\ b & a \end{pmatrix}$ で表される。一般に 2×2 行列による変換は非可換だが、この行列は可換である。そしてもちろん、複素数に特徴的な乗算は、位相 θ の回転と振幅 r の増幅・減衰を意味している。

$$\begin{pmatrix} a & -b \\ b & a \end{pmatrix} = r \begin{pmatrix} \cos \theta & -\sin \theta \\ \sin \theta & \cos \theta \end{pmatrix} \quad (6)$$

2.3 複素ニューラルネットワークでの複素荷重と汎化特性の関係

単純な例として、教師あり学習によって、図 3 にあるような 2 次元の入力 \mathbf{x}^{IN} をおなじく 2 次元の出力 \mathbf{x}^{OUT} にマップする写像を考える。図 4(a) に示すような単層 2 入力 2 出力フィードフォワード型の実数ニューラルネットワークを学習させる。状況を簡単にするため、ここではニューロンのいわゆる活性化関数の非線形性は陽には考えないことにする (恒等関数)。




図 3 \mathbf{x}^{IN} を \mathbf{x}^{OUT} に移す写像 [48]
Fig. 3 A mapping that maps \mathbf{x}^{IN} to \mathbf{x}^{OUT} [48].




図 4 図 3 の写像を学習する場合：(a) 実数の単層 2 入力 2 出力のニューラルネットワーク、(b) 縮退してあまり役に立たない学習結果の例、(c) 複素数の単層 1 入力 1 出力のニューラルネットワーク、及び (d) この自由度が少ないときの学習結果 [48]

Fig. 4 A simple case to learn the mapping in Fig. 3: (a) A real-valued single-layered two-input two-output feedforward network, (b) a possible degenerate learning result that is mostly unuseful, (c) a complex-valued neural network seemingly identical to (a), and (d) the learning result obtained in this small-degree-of-freedom case [48].

またしきい値も考えない。結合の荷重 w_{ji} を最適化する。とりあえず教師信号は 1 組のみとする。入出力の関係は一般に、四つのパラメータ a, b, c, d を使って次のように書ける。

$$\begin{pmatrix} x_1^{\text{OUT}} \\ x_2^{\text{OUT}} \end{pmatrix} = \begin{pmatrix} a & b \\ c & d \end{pmatrix} \begin{pmatrix} x_1^{\text{IN}} \\ x_2^{\text{IN}} \end{pmatrix} \quad (7)$$

学習結果にはさまざまな可能性がある。機能の相違は汎化特性の相違になって現れる。その中には例えば、図 4(c) に示すような縮退するものも含まれる。それは現実には有用でない場合が少なくない。

一方、同じ状況を、複素数 $\mathbf{x}^{\text{IN}} = (x_1^{\text{IN}}, x_2^{\text{IN}})$ を $\mathbf{x}^{\text{OUT}} = (x_1^{\text{OUT}}, x_2^{\text{OUT}})$ にマップする、図 4(c) に示すような複素ニューラルネットワークであったと考える。この場合、荷重 w は一つの複素数である。これを (7) と同様に表せば次になる。

$$\begin{pmatrix} x_1^{\text{OUT}} \\ x_2^{\text{OUT}} \end{pmatrix} = \begin{pmatrix} |w| \cos \theta & -|w| \sin \theta \\ |w| \sin \theta & |w| \cos \theta \end{pmatrix} \begin{pmatrix} x_1^{\text{IN}} \\ x_2^{\text{IN}} \end{pmatrix} \quad (8)$$

ただし $\theta \equiv \arg(w)$ である。二つのパラメータ $|w|, \theta$ のみが含まれる。学習結果を図示すると、図 4(d) になる。すなわち実数の場合に比べて学習の自由度が低下し、解の任意性が減少して、回転と拡大・縮小を組み合わせることによる解が得られることになる。これは、波動の伝搬を考える場合には良好な解である。

一般的にニューラルネットワークの自由度は、その構成や入出力の数、教師信号の数などによってさまざまに変化するが、複素荷重を掛ける、という操作を行うかぎり、ここに述べた特徴の傾向には普遍性がある。ニューラルネットワークの本来の利点は、学習や自己組織化における高い自由度にある。しかし、扱う対象の第一義的な量が「位相」や「振幅」であるとあらかじめ分かっているならば、複素ニューラルネットワークを採用することによって、有害になりがちな高すぎる自由度をむしろ減少させることができ、より意味のある汎化特性をもつ学習や自己組織化を進められる。複素数の乗法がもつ「回転」の機能が、シナプスでの要素機構として機能する [18], [48]。

このような位相回転と振幅増減に基づく要素処理によって構成されるニューラルネットワークは、全体としても位相回転と振幅増減に整合的な処理を行うことになる。この性質は、複素ニューラルネットワークに

よって電磁波や光波などの波動を対象として扱う場合に極めて有用である。また、フーリエ変換等を介した周波数領域処理や、フーリエ合成の概念を併用することによって、任意の信号の処理に有効に用いることができる。

3. 移動体通信でのチャンネル予測:複素ニューラルネットワークで複素チャンネルを実体として扱う

本章では、物理的な描像も取り入れることによってニューラルネットワークのダイナミクスが改善される具体的な例として、移動体通信におけるチャンネル予測を取り上げ、その意味を詳しく論じる。なお技術自体の詳細については、文献 [50] を参照されたい。

移動体通信でのチャンネル予測は、マルチパス環境でのフェージング対策として、将来の有効な予等価や送信パワー制御などを行う際に欠かせない機能である。これまでに時間領域予測や超解像度法を含めた周波数領域予測などが提案されているが、いずれも予測精度の低さや必要計算量の多さに問題があり、実用的な解決が難しかった。しかし著者らのグループは最近、チャープ z 変換 (chirp Z transform: CZT) と複素ニューラルネットワークの組み合わせによってこの問題の解決に成功した [50]。

図 5 に、そのチャンネル予測手法の概要を示す。図 5 (a) の受信チャンネルに CZT を施し、離散性を緩和した形で周波数領域の信号に変換し、(b) スペクトルを得る。そのピークを検出することにより、いわゆる Jakes モデルに基づきパス分離を行う。パス m のドプラ周波数 \hat{f}_m とその振幅 \hat{a}_m を推定値として得る。また (c) 位相スペクトルを参照して各パスの位相値 $\hat{\theta}_m$ を推定値として得る。

以前には、これらチャンネルパラメータ \hat{f}_m , \hat{a}_m , $\hat{\phi}_m$ の時間変化からそれぞれの時刻 $t=0$ での値 \tilde{f}_m , \tilde{a}_m , $\tilde{\phi}_m$ を線形予測やラグランジュ外挿で予測し、それに基づき将来 $t \geq 0$ のチャンネル状態 $\tilde{c}(t)$ を次のように予測した [51], [52]。

$$\tilde{f}_m, \tilde{a}_m, \tilde{\phi}_m \stackrel{\text{Predict}}{\leftarrow} \hat{f}_m, \hat{a}_m, \hat{\phi}_m \quad (9)$$

$$\tilde{c}(t) = \sum_m \tilde{a}_m e^{(j2\pi\tilde{f}_m t + \tilde{\phi}_m)} \quad (10)$$

この手法はおおむね良好であった。しかし、移動体端末が複数の散乱体の真横を通りながら直接波も受ける図 6 のような場合など、難しい状況ではうまく予測で

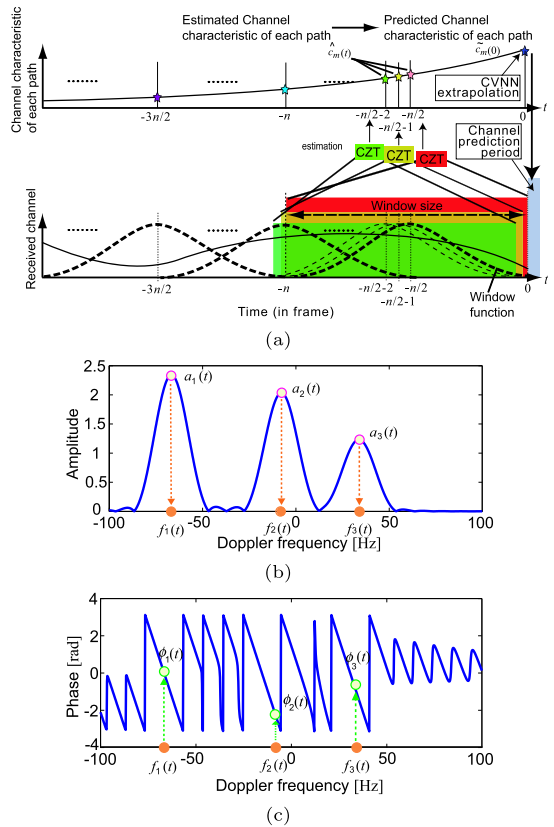


図 5 (a) チャープ z 変換によって過去のチャンネル情報を周波数領域に変換して周波数領域チャンネルパラメータすなわち (b) 振幅パラメータ a_m と周波数パラメータ f_m , そして (c) 位相パラメータ ϕ_m を取得する概念図 [50]

Fig. 5 Conceptual illustrations representing (a) the chirp z-transform to convert the past channel information into the frequency domain for the extraction of the frequency-domain channel parameters, namely, (b) amplitude a_m and Doppler frequency f_m , and (c) phase ϕ_m respectively [50].




図 6 二つの散乱体、一つの基地局、見通しのある一つのユーザーを含む、厳しいフェーディングを起こしやすい幾何的配置 [50]

Fig. 6 Geometrical setup including two scatterers, a base station and a mobile user in the line of sight, which can cause severe fading [50].




図 7 計算コストが軽い小規模の層状複素ニューラルネットワーク [50]

Fig. 7 Layered complex-valued neural network having a small size to reduce the calculation cost [50].

きないこともあった。

それに対して新たな手法では、チャンネルを複素的な実体 \tilde{c}_m と考え、これを図 7 のような階層型複素ニューラルネットワークと複素バックプロパゲーションを用いて、CZT によって推定された過去の状態 $\hat{c}_m(t-1), \dots, \hat{c}_m(t-I_{ML})$ から予測した。

$$\hat{c}_m(t) \equiv \hat{a}_m(t)e^{j\hat{\theta}_m(t)}$$

$$(\hat{\theta}_m(t) \equiv 2\pi\hat{f}_m(t)t + \hat{\phi}_m(t)) \quad (11)$$

$$\tilde{c}_m(t) \stackrel{\text{Predict}}{\leftarrow} \hat{c}_m(t-1), \dots, \hat{c}_m(t-I_{ML}) \quad (12)$$

そして出力された 1 時刻先の予測チャンネル $\tilde{c}_m(t)$ も入力とみなし、入力信号を 1 時刻分ずらして、次の 1 時刻先の予測チャンネル $\tilde{c}_m(t+1)$ を得る。これを繰り返してチャンネルの時系列を得る。最後に各パスの予測結果を足し合わせることで、所望の時刻の予測結果とした。

$$\tilde{c}(t) = \sum_m \tilde{c}_m(t) \quad (13)$$

各パラメータの推定値 \hat{f}_m , \hat{a}_m , $\hat{\theta}_m$ からその未来の値を予測するよりも、推定されたチャンネル \hat{c}_m からその未来の値を予測するほうが、測定値を見ると一見難しそうに見えた。しかしチャンネルは、ゆらぎが大きいもののかかなり正弦波的な振る舞いをすることが、観測値から示唆された。そのため、位相の回転と振幅の変化を処理要素とする複素ニューラルネットワークを適用することにより、高精度なチャンネル予測を実現できた。例えば、図 8 は図 6 のような予測の難しい状況での通信の符号誤り率 (bit error rate: BER) を表している。




図 8 厳しいフェージングをともないながらチャンネル状態が激しく変動する際に、TD-Linear 予測、TD-RTRL-CVNN-based 予測、CZT 推定のみ、CZT-Linear 予測、CZT-Lagrange-based 予測、CZT-AR-model-based 予測、CZT-RTRL-CVNN-based 予測、CZT-ML-CVNN-based 予測、及び比較用に実際のチャンネル特性情報を利用した場合の、符号誤り率曲線 [50]

Fig. 8 BER curves obtained for TD-Linear prediction, TD-RTRL-CVNN-based prediction, CZT only, CZT-Linear prediction, CZT-Lagrange-based prediction, CZT-AR-model-based prediction, CZT-RTRL-CVNN-based prediction, CZT-ML-CVNN-based prediction, and actual channel characteristics when the geometry causes strongly channel changes with severe fading [50].

それぞれの略号は、時間領域線形予測 (TD-Linear 予測)、時間領域実時間リカレント複素ニューラルネットワーク予測 (TD-RTRL-CVNN-based 予測)、CZT により推定された周波数領域パラメータを (予測せず推定を) そのまま利用する (CZT only)、周波数領域線形予測 (CZT-Linear 予測)、周波数領域ラグランジュ予測 (CZT-Lagrange-based 予測)、周波数領域自己帰帰予測 (CZT-AR-model-based 予測)、周波数領域実時間リカレント複素ニューラルネットワーク予測 (CZT-RTRL-CVNN-based 予測)、周波数領域多層複素ニューロ予測 (CZT-ML-CVNN-based 予測)、及び比較用に実際のチャンネル特性情報 (Actual) が得られたと仮定してそれを利用した場合 (現実には不可能)、をそれぞれ表している。CZT と組み合わせた階

層型複素ニューラルネットワーク (CZT-ML-CVNN) が従来手法よりも低い誤り率での通信が実現できることを示している。その計算コストも小規模ニューラルネットワークの逐次学習で小さく抑えることができた。この結果は、複素ニューラルネットワークが波動情報を扱う際に示す優れた汎化特性を直接示すものである。

4. む す び

本論文は、複素ニューラルネットワークのエレクトロニクスでの利点を議論した。特に汎化特性に焦点をあて、複素ニューラルネットワークが本質的にも汎化特性が、波動情報を扱う際に有利に働くことを、複素数の実 2×2 行列表現に言及して論じた。また、波動情報を扱う代表的システムの一つである移動体通信のチャネル予測に複素ニューラルネットワークを適用し、その優位性がどのように発揮されるのか、その提案の背景にある考え方とともに示した。

文 献

- [1] A. Hirose, *Complex-Valued Neural Networks*, 2nd Edition, Springer, Heidelberg, Berlin, New York, 2012.
- [2] 廣瀬 明, 複素ニューラルネットワーク, SGC ライブラリ No.38, サイエンス社, 2005.
- [3] A. Hirose (Ed.), *Complex-Valued Neural Networks: Advances and Applications*, IEEE Press Series on Computational Intelligence, IEEE Press and Wiley, New Jersey, U.S.A., 2013.
- [4] D.P. Mandic and V.S.L. Goh, *Complex Valued Non-linear Adaptive Filters - Noncircularity*, Widely Linear and Neural Models, Wiley, 2009.
- [5] T. Nitta, *Complex-Valued Neural Networks: Utilizing High-Dimensional Parameters*, T. Nitta, ed., Information Science Reference, Pennsylvania, 2009.
- [6] I. Aizenberg, *Complex-Valued Neural Networks with Multi-Valued Neurons*, Studies in Computational Intelligence, Springer, 2011.
- [7] 廣瀬 明, “エレクトロニクスを豊かにする複素ニューラルネットワーク,” 信学誌, vol.87, no.6, pp.447-449, June 2004.
- [8] 新田 徹, “たった一つの複素ニューロンができること,” 信学誌, vol.87, no.6, pp.450-453, June 2004.
- [9] 黒江康明, “複素連想記憶のモデルとそのダイナミクス,” 信学誌, vol.87, no.6, pp.454-459, June 2004.
- [10] 根本 幾, “パーセプトロンと単一ニューロンモデルの複素化,” 信学誌, vol.87, no.6, pp.460-464, June 2004.
- [11] A. Hirose and T. Nagashima, “Predictive self-organizing map for vector quantization of migratory signals and its application to mobile communications,” *IEEE Trans. Neural Netw.*, vol.14, no.6, pp.1532-1540, 2003.
- [12] M.F. Amin, R. Savitha, M.I. Amin, and K. Murase, “Orthogonal least squares based complex-valued functional link network,” *Neural Netw.*, vol.32, pp.257-266, 2012.
- [13] 青木宏之, “自然画像を扱う複素ニューラルネットワーク,” 信学誌, vol.87, no.6, pp.465-470, June 2004.
- [14] 宮嶋照行, 山中一雄, “非興奮状態を持つ複素ニューラルネットワーク,” 信学誌, vol.87, no.6, pp.476-481, June 2004.
- [15] 松井伸之, “四元数ニューラルネットワークによるカラー画像処理,” 信学誌, vol.87, no.6, pp.471-475, June 2004.
- [16] A. Hirose, *Complex-Valued Neural Networks: Theories and Applications*, A. Hirose, ed., vol.5, Series on Innovative Intelligence, World Scientific Publishing, Singapore, New Jersey, London, 2003.
- [17] 廣瀬 明, “複素ニューラルネットワークの応用における新展開,” 計測と制御, vol.51, no.4, pp.351-357, April 2012.
- [18] 廣瀬 明, “複素ニューラルネットワーク (特集解説),” 電学論 (C), vol.131, no.1, pp.2-8, Jan. 2011.
- [19] 廣瀬 明, A.B. Suksmono, 川田宗太郎, “位相と振幅を見るスーパ右脳—干渉型レーザイメージングシステム及び適応的な光波位相等化器への応用,” 信学誌, vol.87, no.6, pp.482-487, June 2004.
- [20] A.B. Suksmono and A. Hirose, “Interferometric SAR image restoration using Monte Carlo metropolis method,” *IEEE Trans. Signal Process.*, vol.50, no.2, pp.290-298, 2002.
- [21] A.B. Suksmono and A. Hirose, “Adaptive noise reduction of InSAR image based on complex-valued MRF model and its application to phase unwrapping problem,” *IEEE Trans. Geosci. Remote Sens.*, vol.40, no.3, pp.699-709, 2002.
- [22] R. Yamaki and A. Hirose, “Singular unit restoration in interferograms based on complex-valued Markov random field model for phase unwrapping,” *IEEE Geosci. Remote Sens. Lett.*, vol.6, no.1, pp.18-22, Jan. 2009.
- [23] T. Hara and A. Hirose, “Plastic mine detecting system using complex-valued self-organizing map that deals with multiple-frequency interferometric images,” *Neural Netw.*, vol.17, no.8-9, pp.1201-1210, Nov. 2004.
- [24] T. Hara and A. Hirose, “Adaptive plastic-landmine visualizing radar system: Effects of aperture synthesis and feature-vector dimension reduction,” *IEICE Trans. Electron.*, vol.E88-C, no.12, pp.2282-2288, Dec. 2005.
- [25] Y. Nakano and A. Hirose, “Improvement of plastic landmine visualization performance by use of ring-CSOM and frequency-domain local correlation,” *IEICE Trans. Electron.*, vol.E92-C, no.1, pp.102-108, Jan. 2009.
- [26] Y. Nakano and A. Hirose, “Taper-walled linearly tapered slot antenna,” *IEEE J. Selected Topics in Ap-*

- plied Earth Observations and Remote Sensing, vol.4, no.4, pp.779–784, April 2011.
- [27] 佐藤茂雄, 金城光永, 中島康治, “量子ニューラルネットワーク実現への試み—量子ビットをニューロンとして使うために,” 信学誌, vol.87, no.6, pp.488–492, June 2004.
- [28] S. Sato, M. Kinjo, O. Takahashi, Y. Nakamiya, and K. Nakajima, “A study on neuromorphic quantum computation,” International Joint Conference on Neural Networks (IJCNN) 2004, vol.4, pp.3253–3256, 2004.
- [29] E.C. Behrman, R.E.F. Bonde, J.E. Steck, and J.F. Behrman, “On the correction of anomalous phase oscillation in entanglement witnesses using quantum neural networks,” IEEE Trans. Neural Netw. Learn. Syst., vol.25, no.9, pp.1696–1703, Sept. 2014.
- [30] A. Hirose and R. Eckmiller, “Behavior control of coherent-type neural networks by carrier-frequency modulation,” IEEE Trans. Neural Netw., vol.7, no.4, pp.1032–1034, 1996.
- [31] S. Kawata and A. Hirose, “Coherent optical neural network that learns desirable phase values in frequency domain by using multiple optical-path differences,” Optics Lett., vol.28, no.24, pp.2524–2526, 2003.
- [32] S. Kawata and A. Hirose, “Frequency-multiplexing ability of complex-valued Hebbian learning in logic gates,” Int. J. Neural Syst., vol.12, no.1, pp.43–51, 2008.
- [33] S. Fiori, “Extended Hamiltonian learning on Riemannian manifolds: Theoretical aspects,” IEEE Trans. Neural Netw. Learn. Syst., vol.22, no.5, pp.687–700, May 2011.
- [34] S. Fiori, “Extended Hamiltonian learning on Riemannian manifolds: Numerical aspects,” IEEE Trans. Neural Netw. Learn. Syst., vol.22, no.5, pp.7–21, May 2012.
- [35] X. Hong and S. Chen, “Modeling of complex-valued Wiener systems using B-spline neural network,” IEEE Trans. Neural Netw., vol.22, no.5, pp.818–825, May 2011.
- [36] B. Widrow, P.E. Mantey, L.J. Griffiths, and B.B. Goode, “Adaptive antenna systems,” Proc. IEEE, vol.55, no.12, pp.2143–2159, Dec. 1967.
- [37] B. Widrow, J. McCool, and M. Ball, “The complex LMS algorithm,” Proc. IEEE, vol.63, pp.719–720, 1975.
- [38] K. Takao and N. Kikuma, “An adaptive array utilizing an adaptive spatial averaging technique for multipath environments,” IEEE Trans. Antennas Propag., vol.AP-35, pp.1389–1396, 1987.
- [39] A. Hirose, I. Aizenberg, and D.P. Mandic, “Guest editorial: Special issue on complex- and hypercomplex-valued neural networks,” IEEE Trans. Neural Netw. Learn. Syst., vol.25, no.9, pp.1597–1599, Sept. 2014.
- [40] G.M. Georgiou, “The field of values of a matrix and neural networks,” IEEE Trans. Neural Netw. Learn. Syst., vol.25, no.9, pp.1613–1620, Sept. 2014.
- [41] Z. Zhang, C. Lin, and B. Chen, “Global stability criterion for delayed complex-valued recurrent neural networks,” IEEE Trans. Neural Netw. Learn. Syst., vol.25, no.9, pp.1704–1708, Sept. 2014.
- [42] K. Subramanian, R. Savitha, and S. Suresh, “A metacognitive complex-valued interval type-2 fuzzy inference system,” IEEE Trans. Neural Netw. Learn. Syst., vol.25, no.9, pp.1659–1672, Sept. 2014.
- [43] S. Chen, X. Hong, J. Gao, and C.J. Harris, “Complex-valued B-spline neural networks for modeling and inverting Hammerstein systems,” IEEE Trans. Neural Netw. Learn. Syst., vol.25, no.9, pp.1673–1685, Sept. 2014.
- [44] K. Terabayashi, R. Natsuaki, and A. Hirose, “Ultra-wideband direction-of-arrival estimation using complex-valued spatiotemporal neural networks,” IEEE Trans. Neural Netw. Learn. Syst., vol.25, no.9, pp.1727–1732, Sept. 2014.
- [45] R. Song, W. Xiao, H. Zhang, and C. Sun, “Adaptive dynamic programming for a class of complex-valued nonlinear systems,” IEEE Trans. Neural Netw. Learn. Syst., vol.25, no.9, pp.1733–1739, Sept. 2014.
- [46] 福島邦彦, “位置ずれに影響されないパターン認識機構の神経回路のモデル—ネオコグニトロン,” 信学論 (A), vol.J62-A, no.10, pp.658–666, Oct. 1979.
- [47] K. Fukushima, “Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position,” Biological Cybernetics, vol.36, no.4, pp.193–202, 1980.
- [48] A. Hirose and S. Yoshida, “Generalization characteristics of complex-valued feedforward neural networks in relation to signal coherence,” IEEE Trans. Neural Netw. Learn. Syst., vol.23, no.4, pp.541–551, 2012.
- [49] A. Hirose, “Nature of complex number and complex-valued neural networks,” Frontiers of Electrical and Electronic Engineering in China, vol.6, no.1, pp.171–180, 2011.
- [50] T. Ding and A. Hirose, “Fading channel prediction based on combination of complex-valued neural networks and chirp Z-transform,” IEEE Trans. Neural Netw. Learn. Syst., vol.25, no.9, pp.1686–1695, Sept. 2014.
- [51] S. Ozawa, S. Tan, and A. Hirose, “Errors in channel prediction based on linear prediction in frequency domain — Combination of time-domain and frequency-domain techniques,” URSI Radio Science Bulletin, vol.337, pp.25–29, 2011.
- [52] S. Tan and A. Hirose, “Low-calculation-cost fading channel prediction using chirp z-transform,” Electron. Lett., vol.45, no.8, pp.418–420, 2009.

(平成 27 年 4 月 1 日受付, 9 月 10 日公開)



廣瀬 明 (正員：シニア会員)

1987 東大・大学院工学系研究科電子工学専攻博士課程中途退学，同年東大・先端科学技術研究センター光デバイス分野・助手。同・新領域創成科学研究科基盤情報学専攻などを経て，2007 同・大学院工学系研究科電気系工学専攻・教授。ワイヤレス

エレクトロニクス，ニューラルネットワークなどの研究に従事。工博。本会エレクトロニクスソサイエティ（エレス）賞などを受賞。日本神経回路学会会長，本会英文論文誌（C）編集長，エレス副会長（編集出版担当）などを歴任。IEEE フェロー。



丁 天本

2012 横国大・工学部知能物理工卒，2014 東大・大学院工学系研究科電気系工学専攻修士課程修了，現在，同博士課程在学。ニューラルネットワーク及びワイヤレスエレクトロニクスに関する研究に従事。