

ニューラルネットワークの高速学習アルゴリズムとその適応等化器への応用

正 員 宮嶋 照行[†] 正 員 長谷川孝明[†] 正 員 羽石 操[†]

A Fast Learning Algorithm of Neural Networks and Its Applications to Adaptive Equalizers

Teruyuki MIYAJIMA[†], Takaaki HASEGAWA[†] and Misao HANEISHI[†], Members

あらまし 本論文では、ニューラルネットワークの高速学習アルゴリズムを提案している。更に本学習アルゴリズムで学習するニューラルネットワークを用いた適応等化器について検討し周波数選択性フェージング伝送路における性能評価を行っている。ニューラルネットワークの学習に広く用いられている Back Propagation (BP) はこう配降下法に基づいているため収束が遅いという欠点がある。そこで本論文では、線形適応フィルタの適応アルゴリズムとして収束特性が非常に速いことで知られている Recursive Least-Squares (RLS) アルゴリズムを用いた高速学習アルゴリズムを提案している。提案するアルゴリズムは、出力層のニューロンの内部ポテンシャルの 2 乗誤差和を評価関数とすることで RLS アルゴリズムの使用を可能にしている。XOR 問題を行い、提案するアルゴリズムは BP と比べて学習回数で約 8.8 倍高速であるという結果を得ている。一方、最近ニューラルネットワークの応用分野として適応等化器が注目されているが、陸上移動体通信で見られる周波数選択性フェージング伝送路において、ニューラルネットワークを用いた適応等化器の検討を行った例はこれまでにない。本論文では、提案する学習アルゴリズムを用いたニューラルネットワークを適応等化器に応用し、周波数選択性フェージング伝送路における性能の評価を行っている。特に、我々が以前に提案した選択的に教師なし学習を行うニューラルネットワークについて検討を行っている。本適応等化器は、選択的に学習することで誤った学習を防ぐことができる。シミュレーションにより、本適応等化器は、従来の適応等化器や従来のニューラルネットワークを用いる適応等化器より優れた性能を有することを示している。

キーワード ニューラルネットワーク、学習アルゴリズム、評価関数、適応等化器、周波数選択性フェージング伝送路

1. ま え が き

ニューラルネットワークは多数の非線形処理素子からなり、学習により高度な情報処理を行うことができるシステムである。これまでにパターン認識などの分野で優れた成果が多数報告されている⁽¹⁾。学習アルゴリズムとしては Back Propagation (BP)⁽²⁾ が最も広く用いられている。しかしながら BP はこう配降下法に基づいているため、収束が遅いという欠点があった。これまでに学習の高速化のために、学習率の動的変更⁽³⁾、非線形最適化法の利用⁽⁴⁾、評価関数の変更⁽⁵⁾、重みの初期値設定⁽⁶⁾、中間層ニューロン数の削減⁽⁷⁾ 等のさまざまな学習アルゴリズムが提案されている。最近、

線形適応フィルタの適応アルゴリズムとして高速な収束特性を有することが知られている Recursive Least-Squares (RLS) アルゴリズムを用いた学習アルゴリズムがいくつか独立に提案され、非常に高速であることが報告されている⁽⁸⁾⁻⁽¹⁰⁾。文献(8)では、ニューロンの出力関数にシグモイド関数の代わりに区分線形関数を用いることで、また文献(9)、(10)では、各ニューロンの望ましい内部ポテンシャルを推定し、各ニューロンの内部ポテンシャルの 2 乗誤差和を最小化することで、RLS アルゴリズムの使用を可能にした。

本論文では、これらとは異なる導出法に基づく RLS アルゴリズムを用いたニューラルネットワークの学習アルゴリズムを提案する。本論文で提案する学習アルゴリズムは、評価関数に出力層のニューロンの実際の内部ポテンシャルと望ましい内部ポテンシャル(出力関数の逆関数より求めることができる)の 2 乗誤差和

[†] 埼玉大学工学部電気電子工学科, 浦和市
Faculty of Engineering, Saitama University, Urawa-shi, 338
Japan

を用いることで、RLS アルゴリズムの使用を可能にしている。Exclusive-OR 問題を行い、提案する学習アルゴリズムは特に収束に必要な学習回数を大幅に減少できることを示す。

次に、学習回数が少ないことが望まれる応用の一つとして適応等化器を取り上げる。通信システムにおける伝送路の適応等化の問題をパターン認識の問題として考えると、符号間干渉のある伝送路の適応等化の問題は、本質的に線形分離不可能な問題であることが報告されている⁽¹¹⁾。線形分離不可能なパターンの分離が可能な階層形ニューラルネットワークを用いた適応等化器は、従来の線形トランスバースアルフィルタを用いる適応等化器より優れた性能を有することが報告されている⁽¹¹⁾。

現在適応等化器の検討が進められている陸上移動体通信においては、伝送路特性の時間変動の克服が重要な課題である⁽¹²⁾。従ってニューラルネットワークを用いた適応等化器についても時変伝送路での性能評価が必要となる。これまでに時変伝送路におけるニューラルネットワークを用いた適応等化器の性能評価を行った報告がいくつかあるが^{(13),(14)}、これらの報告で検討している伝送路はあまり現実的でなく、陸上移動体通信で見られるような周波数選択性フェージング伝送路については検討されていない。

そこで本論文では、前半で提案する学習アルゴリズムで学習を行うニューラルネットワークを判定帰還形適応等化器 (Decision Feedback Equalizer; DFE) へ応用し、その周波数選択性フェージング伝送路における性能の評価を行う。

一方、我々は以前に、選択的に教師なし学習を行うニューラルネットワーク (Selectively Unsupervised Learning Neural Network; SULNN)⁽¹⁵⁾ を提案している。SULNN は、既知の学習データによる一定の学習期間の後、未知の評価データについてネットワークの出力結果から教師信号を生成して学習を行うことで環境の変化に追従できる。また雑音などの影響で誤った判定をした場合に誤った教師信号を生成してしまうが、学習を選択的に行うことで誤った学習を防ぐことができるという特長を有する。従って SULNN は、雑音の存在する時変環境下でのパターン認識に適していると考えられる。実際に、接続機器が時間と共に切り換わる電灯線におけるスペクトル拡散通信の検波に SULNN を用い、従来手法より優れた結果が得られている⁽¹⁶⁾。

本論文では、特に SULNN を用いた DFE について検討を行い、その有効性を示す。

2. 高速学習アルゴリズムの提案

2.1 ニューラルネットワーク

L 層のネットワークについて検討する。時刻 t の第 l 層の i 番目のニューロン (図 1) の内部ポテンシャル $y_i^{(l)}(t)$ と出力 $x_i^{(l)}(t)$ は次式で表される。

$$y_i^{(l)}(t) = \sum_{j=0}^{N_{l-1}} w_{ij}^{(l)}(t-1) x_j^{(l-1)}(t) \quad (1)$$

$$x_i^{(l)}(t) = f(y_i^{(l)}(t)) \quad (2)$$

ここで、 N_{l-1} は第 $l-1$ 層のニューロン数、 $w_{ij}^{(l)}(t)$ は時刻 t の第 $l-1$ 層の j 番目のニューロンから第 l 層の i 番目のニューロンへの結合の重み係数、 $f(\cdot)$ は出力関数である。 $x_i^{(l)}(t)$ は常に 1 であり、しきい値のための定数である。入力層 ($l=1$) のニューロンは入力信号をそのまま出力する。

2.2 学習アルゴリズムの導出

評価関数を次式で定義し、これを最小にすることを考える。

$$E(t) = \frac{1}{2} \sum_{n=0}^t \lambda^{t-n} \sum_{i=1}^{N_t} e_i^{(L)}(n, t)^2 \quad (3)$$

ここで、

$$e_i^{(L)}(n, t) = d_i^{(L)}(n) - y_i^{(L)}(n, t) \quad (4)$$

λ ($0 < \lambda \leq 1$) は忘却の係数であり、時変環境での追従性を良くするために用いられる。 $y_i^{(L)}(n, t)$ 、 $e_i^{(L)}(n, t)$ はそれぞれ、時刻 n の入力データに対する、時刻 t の結合の重みを有するネットワークの出力層の i 番目のニューロンの実際の内部ポテンシャルおよび内部ポテンシャルの誤差である。 $d_i^{(L)}(n)$ は時刻 n の入力データに対する出力層の i 番目のニューロンの望ましい内部ポテンシャルであり、望ましい出力 (教師信号) に出力関数の逆関数を適用し得られる。式 (3) を各重み係数 $w_{ij}^{(l)}(t)$ で偏微分したものを 0 とすることで次式が得られる。




図 1 ニューロンモデル
Fig. 1 Neuron model.

$$\sum_{n=0}^t \lambda^{t-n} e_i^{(l)}(n, t) x_j^{(l-1)}(n, t) = 0 \quad (5)$$

ここで $x_j^{(l-1)}(n, t)$ は、時刻 n の入力データに対する、時刻 t の結合の重みを有するネットワークの第 $l-1$ 層の j 番目のニューロンの出力である。 $e_i^{(l)}(n, t)$ は出力層の場合は式(4)であり、中間層(第 l 層)の場合は次式で表される。

$$e_i^{(l)}(n, t) = f'(y_i^{(l)}(n, t)) \sum_{k=1}^{N_{l-1}} w_{ki}^{(l+1)}(t) e_k^{(l+1)}(n, t) \quad (6)$$

ここで図1に示すように、中間層の $e_i^{(l)}(n, t)$ を出力層と同様に望ましい内部ポテンシャルと実際の内部ポテンシャルの差と考える。

$$e_i^{(l)}(n, t) = d_i^{(l)}(n) - \sum_{k=0}^{N_{l-1}} w_{ik}^{(l)}(t) x_k^{(l-1)}(n, t) \quad (7)$$

式(7)を式(5)に代入することで決定論的正規方程式⁽¹⁷⁾が得られる。この決定論的正規方程式から RLS アルゴリズム⁽¹⁷⁾を用いて再帰的な学習アルゴリズムが得られる。

得られた学習アルゴリズムを以下にまとめる。

[Step 1] 初期化

すべての重み係数 $w_{ij}^{(l)}(0)$ を小さいランダムな値に初期化する。第 $l \in [2, L]$ 層の $(N_{l-1}+1) \times (N_{l-1}+1)$ 相関行列 $\mathbf{P}^{(l)}(0)$ を単位行列に初期化する。

[Step 2] 出力の計算

各ニューロンの内部ポテンシャル $y_i^{(l)}(t)$ および出力 $x_i^{(l)}(t)$ を式(1), (2)に従って計算する。

[Step 3] カルマンゲインと相関行列の更新

第 l 層のカルマンゲイン $\mathbf{K}^{(l)}(t)$ と相関行列 $\mathbf{P}^{(l)}(t)$ を更新する。

$$\mathbf{K}^{(l)}(t) = \frac{\mathbf{P}^{(l)}(t-1) \mathbf{X}^{(l-1)T}(t)}{\lambda + \mathbf{X}^{(l-1)T}(t) \mathbf{P}^{(l)}(t-1) \mathbf{X}^{(l-1)}(t)} \quad (8)$$

$$\mathbf{P}^{(l)}(t) = \frac{1}{\lambda} \{ \mathbf{P}^{(l)}(t-1) - \mathbf{K}^{(l)}(t) \mathbf{X}^{(l-1)T}(t) \mathbf{P}^{(l)}(t-1) \} \quad (9)$$

ここで $\mathbf{X}^{(l-1)}(t)$ は第 $l-1$ 層のニューロンの出力 $x_i^{(l-1)}(t)$ ($i \in [0, N_{l-1}]$) を要素とするベクトル、 T は転置を表す。

[Step 4] 誤差信号の計算

出力層の場合、次式を誤差信号とする。

$$e_i^{(l)}(t) = d_i^{(l)}(t) - y_i^{(l)}(t) \quad (10)$$

ここで、

$$d_i^{(l)}(t) = f^{-1}(t_i(t)) \quad (11)$$

$t_i(t)$ は出力層の i 番目のニューロンの望ましい出力(教師信号)を表す。中間層(第 $l \in [2, L-1]$ 層)の場合

は次式を用いる。

$$e_i^{(l)}(t) = f'(y_i^{(l)}(t)) \sum_{j=1}^{N_{l+1}} w_{ji}^{(l+1)}(t-1) e_j^{(l+1)}(t) \quad (12)$$

[Step 5] 重みの更新

第 $l-1$ 層から第 l 層の i 番目のニューロンへ結合している重みベクトルを次式に従って更新する。

$$\mathbf{W}_i^{(l)}(t) = \mathbf{W}_i^{(l)}(t-1) + \mathbf{K}^{(l)}(t) e_i^{(l)}(t) \quad (13)$$

誤差が十分収束するまで、Step 2 から Step 5 を繰り返す。

3. 高速学習アルゴリズムの動作確認

2.で提案した学習アルゴリズムの性能を計算機シミュレーションにより評価する。BPと比較を行う。Exclusive-OR問題⁽²⁾について検討する。ネットワークのニューロン数は、入力層が2、中間層が2、出力層が1とした。重みの初期値は -0.5 から $+0.5$ の一様乱数で与えた。提案する学習アルゴリズムとBPアルゴリズムともに同じ重みの初期値を用いた。重み係数の初期値を変えてそれぞれ1,000回シミュレーションを行った。学習パターンは#1から#4の順で呈示した。提案する学習アルゴリズムの忘却係数は0.5から0.95まで0.05刻みで、またBPの学習係数と慣性項の係数はそれぞれ0.2から1.0まで0.2刻みでシミュレーションを行い、80%以上収束したもののうち最も早く収束したものをを用いた。忘却係数は0.8、学習係数は1.0、慣性項の係数は0.8とした。ここでは出力関数として、Exclusive-OR問題で通常用いられる次式のシグモイド関数を用いる。

$$f(x) = \frac{1}{1 + e^{-x}} \quad (14)$$

式(14)の逆関数は次式で与えられる。

$$f^{-1}(x) = \ln \frac{x}{1-x} \quad (15)$$

教師信号を0と1とすると式(15)が無限大になってしまうので、望ましい出力を0.01と0.99とした。

図2に学習曲線の一例を示す。この図より提案する学習アルゴリズムではBPに比べ、格段に少ない学習回数で2乗誤差が小さくなることがわかる。

次に収束に要する学習回数、時間について検討する。出力の2乗誤差が4回続けて、0.001以下になったとき学習を終了した。10,000回の学習で収束しない場合は学習を打ち切った。

結果を表1にまとめる。収束に要する学習回数について、提案する学習アルゴリズムはBPに比べ約8.8倍高速である。また1回の学習に要するCPU時間に

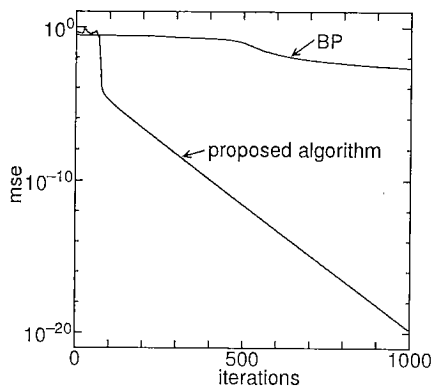


図 2 XOR の学習曲線
Fig. 2 Learning curves of XOR.

表 1 XOR のシミュレーション結果

	提案学習法	BP
平均学習回数	234	2057
収束率 [%]	98.9	81.0
1 回の学習に要する CPU 時間 [msec]	0.202	0.125

ついて、提案する学習アルゴリズムは BP の約 1.6 倍である。従って収束に要する CPU 時間について、提案する学習アルゴリズムは BP に比べ約 5.5 倍高速である。

提案する学習アルゴリズムの収束は、BP と同様に結合の重みの初期値に依存し、必ずしも評価関数の最小値に収束する保証はなく、ローカルミニマムに収束する可能性がある。

式(8)から(13)より明らかなように、提案するアルゴリズムは、基本的に、従来の BP の誤差逆伝搬と RLS アルゴリズムを合わせたものである。従って、ニューロンへの入力の数 N とするとき、BP の計算量が N に比例するのに対して、提案するアルゴリズムでは、RLS アルゴリズムに必要な N^2 の計算⁽¹⁷⁾ が支配的になり、計算量は N^2 に比例する。従って N が非常に大きくなった場合、提案する学習アルゴリズムの収束に要する CPU 時間は非常に長くなる。しかしながら適応等化器⁽¹²⁾ などの、一定の時間間隔で学習データがシステムに与えられ、短時間で環境の変化に追従しなければならないシステムでは、学習回数が少ないことが本質的に必要である。このような応用分野においては提案する学習アルゴリズムは特に有用であると考えられる。そこで 4. では、本学習アルゴリズムを用いた

ニューラルネットワークの適応等化器への応用について述べる。

4. 適応等化器への応用

4.1 判定帰環形適応等化器

近年、陸上移動体通信の周波数選択性フェージング対策として非線形等化器である判定帰環形適応等化器 (DFE) が検討されている⁽¹²⁾。DFE は分数間隔形 (2 taps/symbol) のフィードフォワードフィルタと、等化器の判定結果を遅延させたフィードバックフィルタからなる。RLS アルゴリズムなどを用いて、等化器出力と教師 (参照) 信号の差の 2 乗平均値が最小となるようにフィルタのタップ係数を調節する。DFE は構成が簡単で、かつ効果も高い。

DFE のフィードバック信号に誤りがないものとして、DFE への入力パターンの最適な分離を行うためには、非線形な分離面が必要であることが知られている⁽¹⁸⁾。しかしながら従来の DFE では、フィードフォワードフィルタに線形トランスバースアルフィルタを用いているため、線形な分離面しか形成できない。一方ニューラルネットワークは非線形な分離面を形成できる。ニューラルネットワークを用いた DFE は、従来の DFE より優れていることが、静的な周波数選択性伝送路の場合について報告されている^{(18),(19)}。本章では、2. で提案した学習アルゴリズムで学習するニューラルネットワークを用いた DFE について、周波数選択性フェージング伝送路における性能の評価を行う。特に動的なパターン認識に適した SULNN⁽¹⁵⁾ を用いた DFE について詳しく検討する。

4.2 SULNN を用いた DFE

図 3 に SULNN を用いた DFE の構成を示す。処理する信号が複素数なので、入力層と出力層には複素信号の実部と虚部に相当するニューロンを用意した。従来のニューラルネットワークと SULNN の違いは、確からしきニューロンと判断システムが加わった点である。以下にこれらの動作を説明する。

通常 DFE は 2 種類のモードで動作する。つまり学習モードと追従モードである。学習モードにおいては、既知の学習データについて学習を行う。追従モードにおいては、未知の情報データについて判定を行いながら、伝送路の変動に追従するために判定結果を教師信号として用いて学習を行う。これは判定参照モードと呼ばれている。しかしながら判定参照モードでは、雑音などの影響により判定を誤った場合、誤った教師信

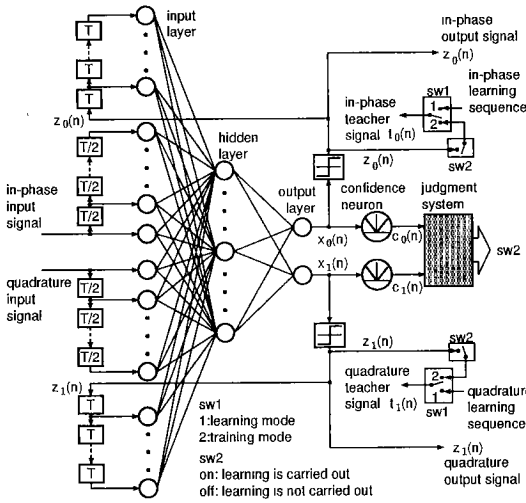


図 3 SULNN を用いた DFE の構成
Fig. 3 Structure of the DFE using SULNN.

号で学習を行ってしまい、性能が劣化する。そこで SULNN を用いた DFE では追従モードにおいて選択的に学習を行うことで誤った学習を防ぐ。確からしきニューロンは出力層のニューロンと 1 対 1 に対応しており、対応する出力層のニューロンの出力値の絶対値を出力する。

$$c_i = |x_i^{(L)}| \quad i=0, 1 \quad (16)$$

ここで c_i は確からしきニューロンの出力で、確からしきと呼ばれる。 $i=0$ は出力信号の実数成分、 $i=1$ は虚数成分に相当する。判断システムではこの確からしきをもとに、現在の入力データについて学習を行うかどうかを判断する。学習を行う場合には、判定参照モードと同様に判定結果を教師信号として用いる。また判断基準はどのような変調方式を用いるかによって変わる。変調方式に BPSK を用いた場合について以下に示す。

$$\begin{cases} t_0 = z_0, t_1 = 0 & (c_0 > T_s) \\ \text{学習しない} & (c_0 \leq T_s) \end{cases} \quad (17)$$

ここで判定結果 z_i は

$$z_i = \begin{cases} 1 & x_i^{(L)} > 0 \\ -1 & x_i^{(L)} \leq 0 \end{cases} \quad (18)$$

である。また c_0 は等化器出力の実数成分に対応する確からしきである。 T_s はあらかじめ設定されるしきい値で、自己判断のしきい値と呼ばれる。自己判断のしきい値を適切に設定することで、誤った学習を防ぐことができる。

本論文では、変調方式が BPSK の場合を検討するの

で、送信シンボルは 1 または -1 の値をとる。従ってここでは、出力関数として、-1 から 1 の値をとる次のシグモイド関数を用いる。

$$f(x) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (19)$$

式(19)の逆関数は次式で与えられる。

$$f^{-1}(x) = \ln \frac{1+x}{1-x} \quad (20)$$

検討する DFE は 2. で提案した学習アルゴリズムを用いるので、教師信号 t_0 を ± 1 の代わりに ± 0.99 とした。

出力関数に式(19)の -1 から 1 の値をとるシグモイド関数を用いるので、確からしきは 0 から 1 の値をとる。従って自己判断のしきい値を 0 に設定した場合、すべてのデータについて学習を行うので、この場合 SULNN を用いた DFE は従来のニューラルネットワークを用いた DFE と等価になる。

4.3 シミュレーションモデル

シミュレーションは等価低域システムで行った。図 4 にシミュレーションモデルを示す。表 2 にシミュレーション諸元を示す。伝送路特性は 2 波モデルで、直接波と遅延波からなる。各波の電力は等しく、それぞれ独立にレイリーフェージングを受けている。遅延波の遅延時間は 1 シンボル時間長 T とした。搬送波の同期はとれていると仮定した。時刻 t の復調された複素ベースバンド信号は次式で表される⁽²⁰⁾。

$$u(t) = v(t)g_0(t) + v(t-T)g_1(t) + n(t) \quad (21)$$

ここで $v(t)$ は送信された複素ベースバンド信号である。 $n(t)$ は等価低域システムで表された白色ガウス雑音である。 $g_i(t)$ は平均が 0 の複素ガウス過程であり、帯域が $\pm f_d$ に制限されている。 f_d は最大ドップラー周波数である。 $g_i(t)$ の包絡線はレイリー分布則に、位相は一様分布則に従う。本論文では $f_d T = 1/12800$ の場合について検討する。これは例えば、伝送速度が 1024 kbit/s の場合 $f_d = 80$ Hz である。また搬送波の周波数が 900 MHz の場合、 $f_d = 80$ Hz は車速が時速 96 km に相当する。ネットワークの重み $w_i^{(j)}$ と相関行列 $P^{(i)}$ は追従性を向上させるために各バーストごとに初期化した。

3. で述べたように、提案する学習アルゴリズムはローカルミニマムに収束する可能性があるが、ネットワークの重み $w_i^{(j)}$ を各バーストごとに初期化するので、もしローカルミニマムに収束しても、それによる性能劣化は 1 バースト以内に抑えることができる。

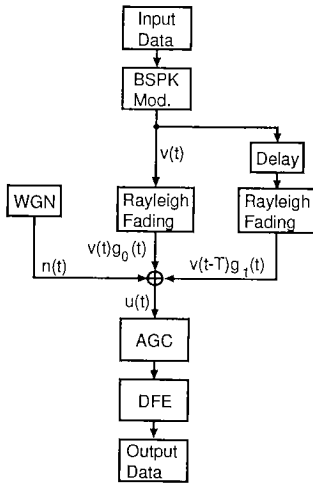


図 4 シミュレーションモデル
Fig. 4 Simulation model.


表 2 シミュレーション諸元

学習データ系列長	50 bit
情報データ系列長	500 bit
変調方式	BPSK
復調方式	同期検波
ロールオフ率	1.0
タップ数	FF 4 FB 1
タップスペース	FF T/2 FB T
入力層のニューロン数	10
中間層のニューロン数	8
出力層のニューロン数	2
忘却係数 (RLS)	0.98
忘却係数 (提案法)	0.99
B P の学習係数	0.4
B P の慣性の係数	0.2
$f_D T$	1/12800
遅延波の遅延時間	T


FF: フィードフォワード
FB: フィードバック

4.4 性能評価


まずニューラルネットワークの有効性および提案学習アルゴリズムの高速性を確認する。図 5 に、 $E_b/N_0=20$ dB の場合の学習曲線を示す。 E_b は遅延波も含めた受信信号 1 ビット当りのエネルギー、 N_0 は雑音の片側パワースペクトル密度を表す。教師信号は既知で、帰環信号は正解の信号とした。従来型の DFE は、タップ係数が複素数の複素等化器であり、学習は RLS アルゴリズムを用いている。BP (b) と提案学習アルゴリズム



(a) conventional DFE



(b) BP



(c) proposed algorithm

図 5 学習曲線

Fig. 5 Learning curves.

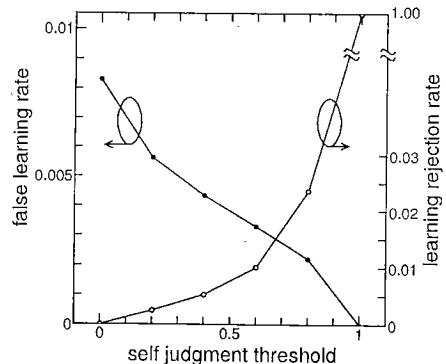


図 6 自己判断のしきい値と全判定回数に対する誤った学習の実行率および学習の非実行率

Fig. 6 The false learning rate and the learning rejection rate vs. self judgment threshold.

μ(c)で学習したニューラルネットワークは、従来型の DFE(a)に比べて平均 2 乗誤差を低く抑えることができるのがわかる。これは、ニューラルネットワークの非線形性によるためである。また提案学習アルゴリズムは既に述べたように、BP に比べて収束が速く、フェージング伝送路のような時変環境に適していると考えられる。

次に提案する学習アルゴリズムで学習する

SULNN を用いた DFE について検討する。検討する DFE は 4.2 で述べたように、自己判断のしきい値 T_s に性能が依存する。自己判断のしきい値にどのように性能が依存するかについて検討する。図 6 に自己判断のしきい値と、全判定回数に対する誤った学習の実行率および学習の非実行率の関係を示す。ここで $E_b/N_0 = 10$ dB である。この図より、自己判断のしきい値が高くなるにつれて誤った学習の実行率は減少し、学習の非実行率は増加することがわかる。 T_s が小さすぎると、誤った学習の実行率が高くなり適切な等化が行われず、また T_s が大きすぎると、学習の非実行率が高くなり伝送路の変化に追従することが困難になると考えられる。従って T_s は 0 から 1 の間の適切な値に設定する必要がある。図 7 に自己判断のしきい値とビット誤り率の関係を示す。 T_s を適切に設定することで、提案する学習アルゴリズムで学習する従来のニューラルネットワークを用いた DFE ($T_s = 0$ に相当) より誤り

率を低く抑えることができることがわかる。この図より、自己判断のしきい値が 0.6 の場合が最適である。 E_b/N_0 などの条件によって、最適な自己判断のしきい値は変わるが、0.6 程度であれば常に十分満足できる結果が得られた。以下のシミュレーションでは自己判断のしきい値を 0.6 とした。

図 8 に誤り率特性を示す。BP で学習するニューラルネットワークを用いた DFE が最も悪い結果を与えているが、これは BP は学習速度が遅いため、伝送路の変化に追従できないためであると思われる。提案する学習アルゴリズムで学習する従来のニューラルネットワークを用いた DFE は、学習が高速なので伝送路の変化に追従でき、かつニューラルネットワークの非線形性を生かすことで従来型の DFE より優れた結果を示していると考えられる。提案する学習アルゴリズムで学習する SULNN を用いた DFE は、学習の高速性とニューラルネットワークの非線形性に加えて、選択的な学習により誤った学習を防ぐことで更なる向上を得ている。以上の結果より、提案する学習アルゴリズムで学習する SULNN を用いた DFE が最も優れており、次いで提案する学習アルゴリズムで学習する従来のニューラルネットワークを用いた DFE が優れていることが確認され、周波数選択性フェージング伝送路の等化にこれらの手法が有効であることが示された。

5. むすび

本論文では、RLS アルゴリズムを用いたニューラルネットワークの高速学習アルゴリズムを提案し、その応用として、周波数選択性フェージング伝送路における判定帰還形適応等化器に用いることを検討した。

本学習アルゴリズムは評価関数に出力層のニューロンの内部ポテンシャルと望ましい内部ポテンシャルの 2 乗誤差和を用いることで、線形適応フィルタの適応アルゴリズムとして有用な RLS アルゴリズムの使用を可能にしている。Exclusive-OR 問題を行い、BP に比べ学習回数で約 8.8 倍高速であるという結果を得た。本学習アルゴリズムは、学習回数が少ないことが望まれる応用分野において特に有用である。

更に本学習アルゴリズムを我々が以前に提案した SULNN に応用し、それを用いた DFE について検討した。本 DFE は選択的な学習により誤った学習を防ぐことができる。周波数選択性フェージング伝送路における性能評価を行い、従来型の DFE、BP で学習するニューラルネットワークを用いた DFE、本学習アル

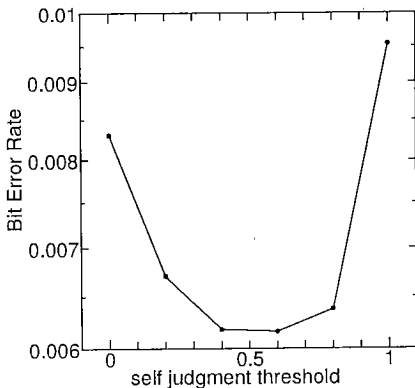


図 7 自己判断のしきい値と誤り率の関係
Fig. 7 Bit error rate vs. self judgment threshold.

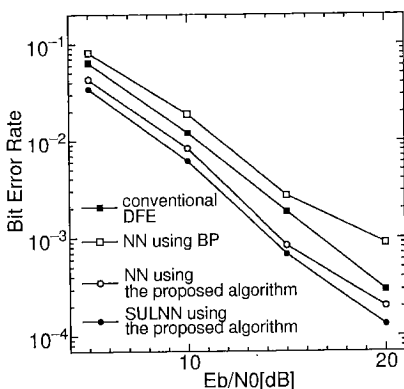


図 8 誤り率特性
Fig. 8 Bit error rates.

ゴリズムで学習する従来のニューラルネットワークを用いた DFE に比べ、本 DFE は優れていることを示した。

提案学習アルゴリズムの計算量の削減が今後の課題である。また遅延波の遅延時間が長い場合や最大ドップラー周波数がより高い場合の本 DFE の性能評価も今後検討すべきであろう。また自己判断のしきい値の最適設定法の開発も今後行いたい。

謝辞 日ごろ御指導頂く埼玉大学工学部電気電子工学科小林禧夫教授に深謝致します。

文 献

- (1) Lippmann R. P.: "Pattern Classification Using Neural Networks", IEEE Commun. Mag., **27**, pp. 47-64 (Nov. 1989).
- (2) Rumelhart D. E., Hinton G. E. and Williams R. J.: "Learning representation by back-propagating errors", Nature, **323**, pp. 533-536 (1986).
- (3) Jacobs R. A.: "Increased Rates of Convergence Through Learning Rate Adaptation", Neural Networks, **1**, pp. 295-307 (1988).
- (4) 高木英行, 坂上茂生, 戸川隼人: "ニューラルネット学習における非線形最適化手法の効果", 信学論(D-II), **J74-D-II**, 4, pp. 528-535 (1991-04).
- (5) 丹 康雄, 加藤喜永, 江島俊朗: "誤差評価関数による PDP モデルの高速化", 信学論(D-II), **J73-D-II**, 12, pp. 2022-2028 (1990-12).
- (6) 賈 棋, 戸田尚宏, 白井支朗: "ニューラルネットワークにおける逆伝搬学習アルゴリズムの初期値設定に関する一考察", 信学論(D-II), **J73-D-II**, 8, pp. 1179-1185 (1990-08).
- (7) 萩原将文: "淘汰機能を有するバックプロパゲーション学習回数の低減と中間層ユニットの削減法", 信学論(D-II), **J74-D-II**, 6, pp. 812-818 (1991-06).
- (8) Azimi-Sadjadi M. R. and Liou R.: "Fast Learning Process of Multilayer Neural Networks Using Recursive Least Squares Method", IEEE Trans. Signal Process., **40**, 2, pp. 446-450 (Feb. 1992).
- (9) Scalero R. S. and Tepedelenioglu N.: "A Fast New Algorithm for Training Feedforward Neural Networks", IEEE Trans. Signal Process., **40**, 1, pp. 202-210 (Jan. 1992).
- (10) Palmieri F. and Shah S. A.: "Fast training of multilayer perceptrons using multilinear parametrization", Proc. IJCNN 1990, **1**, pp. 696-699 (Jan. 1990).
- (11) Gibson G. J., Siu S. and Cowan C. F. N.: "Multilayer perceptron structures applied to adaptive equalisers for data communications", Proc. ICASSP '89, pp. 1183-1186 (1989).
- (12) Sampei S.: "Development of Japanese Adaptive Equalizing Technology toward High Bit Rate Data Transmission in Land Mobile Communications", Trans. IEICE, **E74**, 6, pp. 1512-1521 (June 1991).
- (13) 宮嶋照行, 長谷川孝明: "時変伝送路における選択的に教師なし学習を行うニューラルネットを用いた判定環形適応等化器", 信学 '92 春大, A-151.
- (14) 金田隆二, 真鍋武嗣, 藤井智史: "Forward Only Counter-propagation ネットワークを用いた適応等化器の評価", 信学 '92 春大, A-150.
- (15) 宮嶋照行, 長谷川孝明, 羽倉幸雄, 羽石操: "選択的に教師なし学習を行うニューラルネットワーク", 信学論(D-II), **J75-D-II**, 1, pp. 137-145 (1992-01).
- (16) 大保寺孝至, 長谷川孝明: "接続機器が変化した場合の電灯線 SS 通信の NN 検波方式に関する一検討", 信学 '91 秋大, A-94.
- (17) Haykin S. 著, 武部幹訳: "適応フィルタ入門", 現代工学社 (1987).
- (18) Chen S., Gibson G. J., Cowan C. F. N. and Grant P. M.: "Reconstruction of binary signals using an adaptive radial-basis-function equalizer", Signal Processing, **22**, pp. 77-93 (1992).
- (19) Siu S., Gibson G. J. and Cowan C. F. N.: "Decision feedback equalisation using neural network structures and performance comparison with standard architecture", IEE Proc. I, **137**, 4, pp. 221-225 (Aug. 1990).
- (20) 三瓶政一: フェージング対策, 信学誌, **73**, 8, pp. 829-835 (1990-08).

(平成 4 年 11 月 6 日受付, 5 年 2 月 9 日再受付)



宮嶋 照行

平 1 埼玉大・工・電気卒, 平 3 同大大学院博士前期課程了。現在同大大学院博士後期課程在学中。ニューラルネット, 通信方式に興味をもつ。



長谷川孝明

昭 56 慶大・工・電気卒, 昭 61 同大大学院博士課程了。工博, 同年, 埼玉大・工・電気助手。現在, 同電気電子工学科助教授。スペクトル拡散通信システム, ニューラルネット, ヒューマンテクノロジーに興味をもつ。平 2 年度篠原記念学術奨励賞受賞。著書に「スペクトラム拡散技術の基礎と応用」(分担執筆), 「スペクトラム拡散通信方式応用技術」(分担執筆), 「プライマリー C 言語ノート」がある。IEEE, 情報理論とその応用学会各会員。



羽石 操

昭 42 埼玉大・理工・電気卒, 昭 44 都立大大学院修士課程了。同年埼玉大・工・助手。以来, 表面波アンテナ, マイクロストリップアンテナ, 通信方式等の研究に従事。現在, 同教授。工博, 昭 51 年度学術奨励賞受賞。