

ニューラルネットを用いた時間領域等化器の一検討

A-9 A Study of Time Domain Equalizer Using Neural Network

井坂 開¹

Kai Isaka

宮嶋 照行²

Teruyuki Miyajima

杉谷 栄規²

Yoshiki Sugitani

茨城大学工学部¹

College of Engineering, Ibaraki University

茨城大学大学院理工学研究科²

Graduate School of Science and Engineering, Ibaraki University

1 まえがき

符号間干渉対策として知られる時間領域等化器 (TEQ) において、線形 TEQ は装置が簡単であるが性能に限界がある。一方、非線形 TEQ は線形 TEQ よりも性能が良いが、膨大な計算量が必要となることが知られている。文献 [1] では、計算量低減のために順伝播型ニューラルネットワーク (FFNN) を非線形 TEQ とする方法が提案された。しかし、通信路が変化すると再度学習しなければならず、トレーニングシンボルの送信によりスループットが低下する。本稿では、異なる通信路に対して事前に学習する FFNN を用いる TEQ を提案し、その有効性を確認する。

2 提案法




図1 提案する等化器.

図1に提案する等化器を示す。提案法は、受信信号の他に通信路インパルス応答 (IR) を1つのFFNNに入力し、異なる通信路の情報をオフライン学習させる。学習したFFNNは異なる通信路に対応した出力をする。つまり、オフラインで学習した異なる通信路に対して、1つのFFNNで等化するシステムである。

時刻 n の送信機の送信シンボルを s_n 、既知の通信路を $\mathbf{h} = [h_0 \cdots h_{L_h-1}]^T$ (L_h は通信路長) として、時刻 n の受信機の受信信号は

$$r_n = \sum_{i=0}^{L_h-1} h_i s_{n-i} + v_n, \quad (1)$$

となる。ただし、 v_n は平均0、分散 σ_v^2 の白色ガウス雑音である。また、簡単のため s_n 、 \mathbf{h} 、 v_n は実数とする。入力する受信信号の数を L_w として、 $\mathbf{r}_n = [r_n \cdots r_{n-(L_w-1)}]^T$ とする。ここで、任意の L 層 FFNN への時刻 n の入力を

$$\mathbf{x}_n = [\mathbf{r}_n^T \ \mathbf{h}^T]^T, \quad (2)$$

として、FFNN 出力 \hat{s}_n に対する目標出力は s_n とする。

FFNN の $(l-1)$ 層第 i ユニットと l 層第 j ユニット間の結合重みを $w_{ji}^{(l)}$ 、 l 層第 j ユニットのバイアスを $b_j^{(l)}$ とする ($l=2, \dots, L$)。また、 $\mathbf{W}^{(l)}$ を (j, i) 成分が $w_{ji}^{(l)}$ の行列、 $\mathbf{b}^{(l)}$ を j 成分が $b_j^{(l)}$ の列ベクトルとする。中間層における活性化関数をシグモイド関数 $f(x) = (1 + e^{-x})^{-1}$ とすると、FFNN 出力は

$$\hat{s}_n = \mathbf{W}^{(L)} f(\cdots f(\mathbf{W}^{(2)} \mathbf{x}_n + \mathbf{b}^{(2)}) \cdots) + \mathbf{b}^{(L)}, \quad (3)$$

となる。また、評価関数を

$$J = \sum_n |s_n - \hat{s}_n|^2, \quad (4)$$

として、 J について最適な $\mathbf{W}_{\text{opt}}^{(l)}$ 、 $\mathbf{b}_{\text{opt}}^{(l)}$ ($l=2, \dots, L$) を誤差逆伝播法 (BP 法) [2] により学習する。通信路 IR を含んだ \mathbf{x}_n による学習で $\mathbf{W}_{\text{opt}}^{(l)}$ 、 $\mathbf{b}_{\text{opt}}^{(l)}$ が決まると、学習させた異なる通信路に対して、式 (3) の \hat{s}_n が決まる。

一方、線形 TEQ について、線形 FIR フィルタの重みを $\mathbf{w} = [w_0 \cdots w_{L_w-1}]^T$ とすると、 \mathbf{r}_n を用いて出力は

$$\hat{s}_{\text{linear}, n} = \mathbf{w}^T \mathbf{r}_n, \quad (5)$$

となる。 $\hat{s}_{\text{linear}, n}$ はある通信路に対応した \mathbf{w} を決めることで求められる。しかし、通信路が異なる \mathbf{r}_n が入力されると、最適な \mathbf{w} ではなくなるため、所望の $\hat{s}_{\text{linear}, n}$ が得られなくなる。

3 シミュレーション

図2に提案法によるFFNNのBER特性を示す。横軸を受信SNR ($= \|\mathbf{h}\|^2 / \sigma_v^2$) とした。 $s_n = \{1, -1\}$ 、 $L_h = L_w = 2$ 、 $L = 3$ 、中間層ユニット数6、活性化関数を $f(x)$ 、BP法の学習係数 $\epsilon = 0.007$ 、モメンタム係数 $\mu = 0.9$ とし、 $\mathbf{h} = [1 \ 0.5]^T$ または $[0.5 \ 1]^T$ をランダムに発生し学習させた。更新回数 2×10^5 時点のFFNNを用いてBERを求めた。また、比較としてMMSE線形等化のBERも示す。図2より、提案法のBER特性がMMSE線形等化よりも優れていることが分かる。

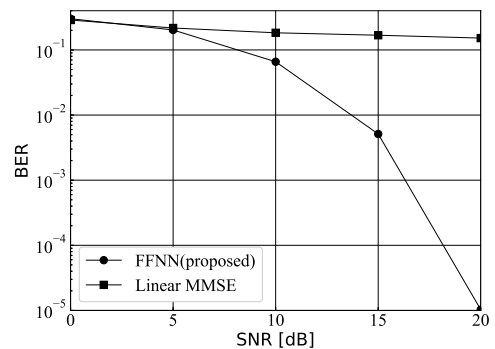


図2 BER特性.

4 まとめ

異なる通信路を学習するFFNNによるTEQを提案し、有効性をシミュレーションで確認した。

参考文献

- [1] G.J.Gibson, et al., "The application of nonlinear structures...", IEEE Trans. Signal Process., vol.39, no.8, pp.1877-1884, Aug. 1991.
- [2] 岡谷貴之, 深層学習, 杉山将 (編), 講談社, 東京, 2018.