

# RBFN을 이용한 Bayesian Equalizer에서의 비선형 다층 결합 기법

정회원 최수용\*, 고균병\*\*, 홍대식\*\*

## Nonlinear Multilayer Combining Techniques in Bayesian Equalizer Using Radial Basis Function Network

Soo-Yong Choi\*, Kyun-Byoung Ko\*\*, Dae-Sik Hong\*\* *Regular Members*

### 요 약

본 논문에서는 optimal Bayesian equalization solution인 RBF(radial basis function)를 이용한 등화기(RE)의 구조를 보다 단순화하고, 비선형 왜곡 등의 심각한 정보 신호의 손상에 대한 보상 능력을 향상시키기 위하여 비선형 다층 결합을 갖는 RBF를 이용한 등화기(RNE)를 새로이 제안한다. 기존의 RE는 RBF로 구성된 은닉층의 출력 값을 선형 결합하여 등화기 출력을 얻는다. 이와 달리 새로이 제안하는 RNE는 기존의 RE에서 RBF로 구성된 은닉층의 출력 값에 대한 결합 기법으로 perceptron을 이용한 비선형 다층 결합을 사용한다. 제안한 equalizer를 결정계환 방식이 있는 경우와 없는 경우의 등화기로 각각 구현한다. 실험 결과 제안한 등화기는 선형 간섭이 존재하는 디지털 통신 시스템과 비선형 왜곡이 존재하는 자기기록 시스템에서보다 간단한 구조로 기존의 optimal Bayesian 등화기와 거의 같거나 우수한 비트 오류 확률 성능 및 MSE(mean squared error) 수렴 특성을 나타내었다.

### ABSTRACT

In this paper, an equalizer(RNE) using nonlinear multilayer combining techniques in Bayesian equalizer with a structure of radial basis function network is proposed in order to simplify the structure and enhance the performance of the equalizer(RE) using a radial basis function network. The conventional RE produces its output using linear combining the outputs of the basis functions in the hidden layer while the proposed RNE produces its output using nonlinear combining the outputs of the basis function in the first hidden layer. The nonlinear combiner is implemented by multilayer perceptrons(MLPs). In addition, as an infinite impulse response structure, the RNE with decision feedback equalizer (RNDFE) is proposed. The proposed equalizer has simpler structure and shows better performance than the conventional RE in terms of bit error probability and mean square error.

### I. 서 론

RBFN(Radial basis function network)을 이용한 연구는 지금까지 폭 넓게 수행되어 왔으며 다양한 분야에 적용되어 그 성능의 우수함을 보여 주어왔다. 채널 등화기로서 RBF를 이용한 등화기(RE)는 그 성능이 최적의 Bayesian 등화 해와 등

가이며, 적응 등화기로서의 정적 통계 특성을 갖는 시불변 채널에서뿐만 아니라 시변 다중 경로 페이딩 채널에서 우수한 성능을 보였다[1, 2]. 또한 RBF는 등화기에서 뿐만 아니라 다중 사용자 검출기에서도 사용되어 매우 우수한 성능을 나타낸다[3]. 하지만 성능의 이득에 비하여 RBFN는 구조의 복잡도 면에 있어서 많은 문제점을 가지고 있으며,

\* Institute for Neural Computation, University of California, San Diego(csyong@itl.yonsei.ac.kr 또는 sychoi@ucsd.edu)

\*\* 연세대학교 전기전자공학과 정보통신연구실(pumi@itl.yonsei.ac.kr, daesikh@itl.yonsei.ac.kr)

논문번호 : 020504-1127, 접수일자 : 2002년 11월 27일

※본 논문은 한국과학재단의 목적기초연구 사업(R01-2002-000-00153-0(2002))의 지원으로 수행되었습니다.

basis 함수의 인자와 초기화에 따라 매우 민감한 성능을 나타내고 있다[3]. 이러한 문제점들은 RBF를 사용함으로써 생기는 필연적인 문제로 이를 극복하기 위하여 많은 연구가 이루어지고 있다.

RBFN의 이용에 있어서 가장 큰 문제점인 복잡도 해결을 위하여 RBF의 중심 수를 줄이려는 노력이 [4]와 [5]에서 등화기의 관점으로 이루어 졌으나 RBF의 수 감소에 따른 성능의 저하가 필연적이며, 만족할 만한 성능을 위해서는 역시 큰 크기의 RBF 수가 필요하다. 또 다른 복잡도 해결의 노력으로서 RBF 중심 값의 계산량 감소와 정확도 향상을 위해 다양한 연구[6]가 이루어지고 있지만 이는 초기화와 RBF 중심 추정을 위한 연산 감소를 위한 것이며, RBFN 구조를 단순화시키기 위한 연구는 아니다. [7]에서 기존 RE의 성능을 개선하기 위해 결정계환과 출력단에서 tanh 함수를 이용한 새로운 등화기를 제안, 기존 등화기에 비해 우수한 성능을 보여주었지만, 복잡도면에 있어서 개선 효과를 얻지 못했다.

본 논문에서는 최적의 Bayesian 등화 해를 갖는 RE의 구조를 단순화하고, 비선형 왜곡 등의 심각한 정보 신호의 손상에 대한 보상 능력을 향상시키기 위하여 비선형 다층 결합(NMC : nonlinear multilayer combining 또는 combiner)을 갖는 RBF를 이용한 등화기(RNE)를 새로이 제안한다. 기존의 RBF를 이용한 등화기와 검출기는 그림 1과 같이 입력 값이 들어오면  $J$ 개의 RBF로 이루어진 은닉층에서 비선형 변환이 이루어지고, 변환이 이루어진 값들은 출력 단에서 선형적으로 결합되어 선형적인 결정 경계에 의하여 출력 값이 정해진다. 이러한 RBF를 이용한 등화기나 다중 사용자 검출기를 설계함에 있어서 가장 중요한 요인이 basis 함수의 정확한 중심 추정이며, 지금까지 대부분의 연구가 basis 함수의 정확한 중심 값을 구하는 것에 관한 것이다. 하지만 본 논문에서는 이제까지와는 달리 그림 2와 같이  $J$ 개의 RBF 함수로 이루어진 첫 번째 은닉층을 통과한 후  $K$ 개로 이루어진 두 번째 은닉층과 1개의 출력 노드로 이루어진 출력단에서 다층 구조를 이용한 NMC를 제안한다. 이러한 NMC 기법을 사용함으로써 등화기의 성능 저하를 최소화하는 동시에 구조의 단순화를 꾀하고자 한다.

## II. Suboptimal Bayesian Equalizer with Nonlinear Multilayer Combining




그림 1. 은닉층이 1개인 RE 구조




그림 2. 은닉층이 2개인 RNE 구조

### 1. Optimal Bayesian Equalizer Using RBF with Linear Combining

일반적인 symbol-decision equalizer로서 RE의 구조는 그림 1과 같이 구현할 수 있다. 등화기의 차수가  $m$ , 지연이  $\tau$ 이고, 채널이  $n$ 개의 탭으로 구성되어 있다면, 필요한 RBF의 수는 채널 입력의 신호열  $\mathbf{s}(t) = \{s(t) \ s(t-1) \ \dots \ s(t-m+1-n)\}$ 의  $p=2^{n \cdot m}$ 개의 조합이 존재하고, 채널의 출력  $m$ 차원인  $y$ 일 때, 등화기의 출력  $\tilde{s}(t-\tau)$ 은  $\tilde{s}(t-\tau) = \sum_{i=1}^p w_i \exp(-\|\mathbf{y} - \mathbf{c}_i\|^2 / \rho_i)$ 이다. 여기서  $\mathbf{c}_i$ 는  $i$ 번째  $m$ 차원을 갖는 RBF의 중심 벡터이고,  $\rho_i$ 는  $i$ 번째 RBF의 폭을,  $w_i$ 는  $i$ 번째 RBF와 출력을 연결하는 선형 결합을 위한 weight로서 일반적으로 LMS(least mean square) 알고리즘[3]에 의하여 학습된다. Weight에 대한 학습은 LMS 알고리즘에 의하여 충분한 학습 과정을 거치면 최적 weight에 도달하게 되므로[3], 본 논문의 모든 실험에서는

LMS 알고리즘을 이용한 weight의 학습을 MSE의 변화가 거의 없을 때까지 충분히 수행한 후, 각 등화기에 대한 BER 성능 실험을 수행하였다. RBF의 중심  $c_i$ 는 일반적으로 두 가지 학습 과정을 이용한다. 하나는 supervised 학습 알고리즘인 supervised k-means clustering[1, 3] 알고리즘이며, 또 다른 학습 알고리즘은 unsupervised clustering 알고리즘이다[1, 3]. 이러한 과정을 거친 후 얻은 등화기 출력  $\hat{s}(t-\tau)$ 는 심벌 주기인  $T$ 간격으로 샘플링 되어  $s_k$ 를 얻을 수 있고, 다음의 규칙에 의하여 정보 신호  $s(t-\tau)$ 의 추정치인  $\hat{s}(t-\tau)$ 를 결정함으로써 최적의 Bayesian 등화 해를 얻는다 [1].

$$\hat{s}(t-\tau) = \text{sgn}(s_k) = \begin{cases} 1, & s_k \geq 0 \\ -1, & s_k < 0. \end{cases} \quad (1)$$

우리는 [1]의 예를 이용하여 그림 3과 같은 시스템에 RE를 채널 등화기로서 적용한다. 사용 채널은

$$H(z) = 0.3482 + 0.8704z^{-1} + 0.3482z^{-2} \quad (2)$$

와 같고, 정보 신호는 BPSK(binary phase shift keying) 신호라 가정한다. 참고 문헌 [1]에서와 같이 등화기 차수  $m=4$ 이고 지연  $\tau=1$ 일 때 desired center 수  $p = 64$ 이므로 필요한 RBF의 수, 즉 4차원의 desired center 수는 64개이다. 실험에서 함수의 중심은 unsupervised clustering 학습을 사용하였고, RE의 weight는 LMS 학습 알고리즘을 이용하여 MSE의 변화가 거의 없을 때까지 충분한 학습을 수행한 후 BER을 측정하였다.

그림 4는 RBF의 수에 따른 BER 곡선으로 함수의 수, 즉 RBF의 수가 줄어들에 따라 등화기의 성능이 급격하게 저하됨을 알 수 있다. 함수의 수가 desired center수의 약 절반이하로 줄어들게 되면, 4개의 차수만을 사용하는 선형 등화기보다 나쁜 성능을 나타냄을 알 수 있다. 그림 5는 채널 추정에 오차가 있는 경우, 즉 등화기 입력 차수의 변화에 따른 BER 곡선이다. 등화기의 입력 차수가 낮아짐에 따라 BER이 급격하게 저하됨을 알 수 있다. 따




그림 3. 정보 전송 시스템

라서 RE의 성능은 RBF 함수의 수와 채널 상태의 추정에 많은 영향을 받음을 알 수 있다.

## 2. Suboptimal Bayesian Equalizer Using RBF with Nonlinear Multilayer Combining

RE는 앞의 예에서와 같이 RBF의 중심과 채널 추정에 따른 성능 의존도가 매우 심각하다. 이를 위하여 본 논문에서는 이와 같은 단점을 보완하는 동시에 구조의 단순화를 위하여 NMC를 갖는 RBF를 이용한 등화기(RNE)를 그림 2와 같이 제안한다. 채널의 출력이 등화기 입력으로 들어오면, 먼저 입력층과 RBF로 이루어진 첫 번째 은닉층에 의하여 비선형 변환이 행하여지고, 변환이 이루어진 RBF의 출력은 두 번째 은닉층으로 입력된다. 두 번째 은닉층으로 입력된 값은 두 번째 은닉층과 출력층을 통과하며, 각각의 해당 class로 선형적인

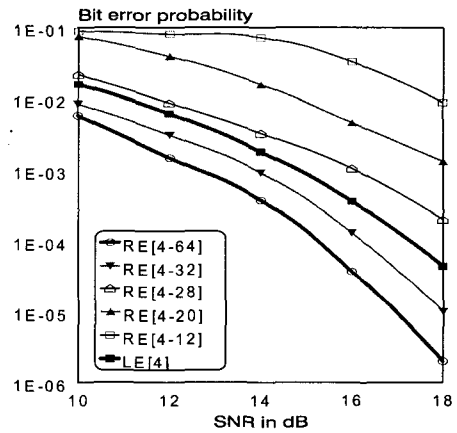


그림 4. RBF 수에 따른 RE의 BER, RE[입력수-RBF수], LE[입력수], 최적 Bayesian 등화기 = RE[4-64]




그림 5. 입력수에 따른 RE의 BER, RE[입력수-RBF수], LE[입력수], 최적 Bayesian 등화기 = RE[4-64]

linear boundary에 의한 것이 아니고, nonlinear decision boundary에 의하여 분류된다. 전체 등화기가 입력은  $I$ 개, 첫 번째 은닉층은  $J$ 개, 두 번째 은닉층은  $K$ 개, 그리고 출력층이 1개의 차수로 구성되어 있다고 가정하자. 채널 출력이  $m$ 차원인  $y$ 일 때, RBF로 이루어진 첫 번째 은닉층의  $j$ 번째 RBF 출력  $o_j^{1stH}(t)$ 는

$$o_j^{1stH}(t) = \exp\left(-\frac{\|y - c_j\|^2}{\rho_j}\right), \quad 1 \leq j \leq J \quad (3)$$

와 같고,  $c_j$ 는  $j$ 번째  $m$ 차원을 갖는 RBF의 중심 벡터이고,  $\rho_j$ 는  $j$ 번째 RBF 폭을 나타낸다. 이러한 함수의 출력 값은 weight가 곱하여져서 두 번째 은닉층의 입력이 된다. 두 번째 은닉층의  $k$ 번째 노드의 함수의 입력  $net_k^{2ndH}(t)$ 는

$$net_k^{2ndH}(t) = \sum_{j=1}^J w_{kj}^{1stH}(t) o_j^{1stH}(t) + w_{k0}^{1stH}(t), \quad 1 \leq k \leq K \quad (4)$$

이고, 여기서  $w_{kj}^{1stH}(t)$ 는 첫 번째 은닉층의  $j$ 번째 함수의 출력과 두 번째 은닉층의  $k$ 번째 노드를 연결하는 weight이고  $w_{k0}^{1stH}(t)$ 는 두 번째 은닉층의  $k$ 번째 노드의 입력에 연결된 바이어스이다. 따라서 두 번째 은닉층의  $k$ 번째 함수의 출력  $o_k^{2ndH}(t)$ 는

$$o_k^{2ndH}(t) = \frac{1 - \exp[-ne_k^{2ndH}(t)]}{1 + \exp[-ne_k^{2ndH}(t)]}, \quad 1 \leq k \leq K \quad (5)$$

이다. 따라서 최종 등화기 출력은  $\hat{s}(t-\tau)$ 는

$$\hat{s}(t-\tau) = \sum_{k=1}^K w_k^o(t) o_k^{2ndH}(t) + w_0^o(t) \quad (6)$$

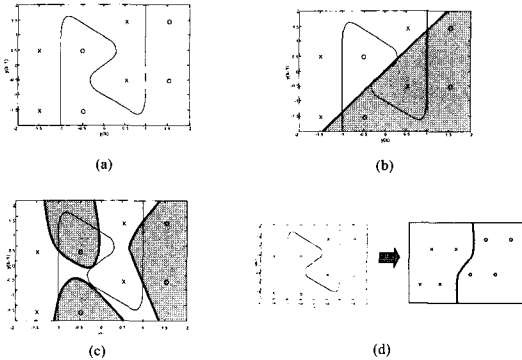


그림 6. 결정 경계 (a) 최적의 Bayesian 분류기, (b) 선형분류기, (c) 다층퍼셉트론, (d) RE

이고, 여기서  $w_k^o(t)$ 는 두 번째 은닉층의  $k$ 번째 노드와 출력층 노드를 연결하는 weight이고  $w_0^o(t)$ 는 출력층 노드에 연결된 바이어스이다. 출력  $\hat{s}(t-\tau)$ 는 심벌 주기인  $T$ 간격으로 샘플링되어  $s_k$ 를 얻을 수 있고, 식 (1)에 의하여 원하는 정보 신호  $s(t-\tau)$ 의 추정치인  $\hat{s}(t-\tau)$ 를 얻을 수 있다. 제안한 등화기의 인자들에 대한 학습은 여러 가지 방법에 의하여 이루어 질수 있다. 본 논문에서는 첫 번째 은닉층의 basis 함수의 중심에 대한 학습 방법으로는 RE에서의 RBF의 중심에 대한 학습과 같은 방법을 이용하고, 첫 번째 은닉층과 두 번째 은닉층을 연결하는 weight와 두 번째 은닉층과 출력층을 연결하는 weight는 다음의 BP(backpropagation) 알고리즘 [8]을 이용한다. 먼저 출력층에서의 error 항목은

$$\delta^{2ndH}(t) = s(t-\tau) - \hat{s}(t-\tau) \quad (7)$$

이고, 두 번째 은닉층의  $j$ 번째 노드의 error 항목은

$$\delta_j^{1stH} = \frac{1}{2} \sum_{k=1}^K (1 + o_k^{2ndH}(t))(1 - o_k^{2ndH}(t)) \delta^o w_k^o, \quad 1 \leq j \leq J \quad (8)$$

이다. 따라서 두 번째 은닉층과 출력층을 연결하는  $k$ 번째 weight 학습 식과 첫 번째 은닉층의  $j$ 번째 노드와 두 번째 은닉층의  $k$ 번째 노드를 연결하는 weight 학습 식은 각각 다음과 같다.

$$w_k^o(t) = w_k^o(t-1) + \eta \delta^o(t) o_k^{2ndH}(t), \quad 1 \leq k \leq K \quad (9)$$

$$w_{kj}^{1stH}(t) = w_{kj}^{1stH}(t-1) + \eta \delta_j^{1stH}(t) o_j^{1stH}(t), \quad 1 \leq j \leq J, \quad 1 \leq k \leq K \quad (10)$$

### 3. RNE의 설계 방법

채널의 전달 함수가  $H(z) = 0.5 + 1.0z^{-1}$ 이고, BPSK 신호인 경우를 고려하면, 등화기는 두 가지 부류, 즉  $\{-1, 1\}$ 로 신호를 분류한다. 이러한 과정을 2차원의 채널 출력 영역에서 도식적으로 보면 그림 6과 같다. 그림 6(a)는 최적의 Bayesian 분류기의 결정 영역 분할 결과이다. 선형 등화기의 분할 결과인 그림 6(b)를 보면 채널 출력, 즉 등화기 입력 신호열들을 LMS 알고리즘에 의하여 선형적인 decision boundary에 의하여 신호를 분류한다 [8]. 따라서 선형 등화기의 경우 더 많은 차수의 등화기 입력을 필요로 하며, 성능 상에 있어서 많은 문제점

을 가지게 된다. 다층 perceptron을 이용한 등화기와 검출기[9, 10]의 경우 그림 6(c)에서와 같이 nonlinear decision boundary에 의하여 결정 영역을 여러 개로 분할하기 때문에 비선형 왜곡 등이 존재하더라도 우월한 성능을 나타낸다. 하지만 신경망의 구조가 증가함에 따라 학습 과정상의 불확실성, 느린 수렴 특성, 지역 극소, 구조의 복잡도 등의 문제점을 갖는다. 마지막으로 RE의 경우를 그림 6(d)에 나타내었다. RE의 경우 입력이 들어오면, 입력 데이터는 비선형 변환을 거치면서 linearly separable의 경우로 바뀐다. 이렇게 변환한 데이터는 선형 결함을 통하여 선형적으로 분리됨으로써 최적의 Bayesian 해를 구현한다. 하지만 linearly separable한 상태로의 데이터 변환 시에 많은 수의 RBF와 채널 상태 등의 인자들에 대한 정확한 추정을 필요로 한다. 본 논문에서는 출력단에서 2-3개의 다층 perceptron을 이용하여 비선형 결함을 사용함으로써 신경망 등화기의 단점을 보완하고, 장점만을 취하고자 한다. 이러한 신경망 등화기의 장점과 RBF의 특성을 결합함으로써 적은 수의 RBF를 이용하여 비선형 변환을 취한 후, nonlinear decision boundary에 의한 신호 분류를 함으로써 성능의 저하 없이 구조의 단순화를 꾀하고자 한다.

우리는 새로운 등화기를 설계하는 데 있어 두 가지 설계 기준을 설정한다. 기존의 optimal Bayesian 등화기의 구조를 단순화하기 위해, 연산 수가 기존의 것보다 적어야 한다는 것과 앞에서 언급한 신경망의 노드 수 증가에 따른 여러 가지 문제점을 예방하기 위하여 NMC에 사용하는 노드의 수를 가능한 한 적게 사용한다는 것이다. 다음 장에서의 실험 결과를 보면 4개 이상의 NMC 노드를 사용하더라도 성능상의 이득은 거의 없었고, 오히려 앞에서 언급한 신경망의 여러 문제점들이 나타났다. 따라서 본 논문에서는 NMC node의 수를 3개 이내로 제한하였고, NMC를 사용함으로써 얻을 수 있는 성능상의 이득에 필요한 node의 수는 3개 정도면 충분하였다.

다양한 실험을 통하여 이와 같은 문제점을 고려하여 본 논문에서 제안하는 설계 방법은 NMC를 이용한 등화기의 설계 시에 RBF를 1/2씩 줄일 때마다 1개의 NMC 노드를 증가하는 것이다. 우선 기존의 RE 등화기의 경우를 NMC node가 하나인 기준 RNE로 간주한다. BPSK의 경우를 예로 보자. 한쪽 class, 즉 1 또는 -1에 속하는 RBF의 중심

표 1. Steps in the design of RNE

Step	
1	Design Bayesian equalizer using RBF : Obtain input $m$ , RBF units $p$ .
2	Design RNE : $I$ input, $J$ RBFs, $K$ NMC nodes
3	Design new RNE 1) Averaging the closest 2 centers among the centers of RBF in the same class. 2) Twice the widths of each RBF. 3) 1 NMC node added. → RNE with $I$ input, $J$ RBF units, $K$ NMC nodes
4	Repeat Step 3

중에서 서로 가장 인접한 2개의 평균을 취함으로써 등화기 RBF의 수를 절반으로 줄이고, 각 RBF 폭,  $\rho_i$ 를 2배로 증가시킨다. RNE의 RBF의 수가 기준 RNE의 RBF 수에 비하여 1/2로 줄었으므로 NMC node의 수는 2개이다. 이렇게 함으로써 첫 번째 단순화 된 등화기의 설계가 끝나게 된다. 이러한 과정을 한번 더 반복함으로써 기준 RNE의 RBF수보다 새로운 RNE의 RBF 수가 1/4로 줄고, NMC node의 수는 3개가 되어 두 번째 단순화된 등화기의 설계가 완료된다. 표 1에 등화기 설계 흐름도를 나타내었다. 예를 들면 앞의 식 (2)의 채널 특성을 갖는 RE의 구성을 보면 입력에 4개, RBF 64개의 구성을 필요로 한다. 우리는 첫 번째 단계 등화기 구성 방법으로 입력은 그대로 유지하고 RBF수를 64개의 절반인 32개로 줄이고, 2개의 NMC 노드를 사용한다. 두 번째 단계로는 32개의 절반인 16개의 RBF를 사용하고 3개의 NMC를 사용한다. 이러한 방법으로 기존의 RE의 구조를 단순화하고자 한다.

등화기들의 복잡도 비교를 위해 각 등화기의 연산수를 비교한다. RE는  $I$  입력,  $J$  RBFs 이고 RNE는  $I$  입력,  $J$  RBFs,  $K$  NMC 노드일 때, 두 등화기의 동작과 학습을 위한 연산수 비교를 표 2에 나타내었다. 표 2에 나타난 각 연산의 수는 각 등화기에서 중심을 위한 알고리즘으로는 계산량이 적은 supervised clustering을 사용한다고 가정하고, weight에 대한 학습은 RE의 경우 LMS 알고리즘을, RNE는 BP 알고리즘을 가정했을 경우이다.

등화기를 설계할 경우  $K=2$ 이면, 즉 NMC node의 수가 2개이면, RNE의 RBF 수는 RE의 RBF 수  $J$ 의 절반이다. 또한  $K=3$ 이면 RNE의 RBF 수는 RE의 RBF 수  $J$ 의 1/4이다. 각각의 경우에 대

표 2. Complexity of each equalizer

	RE	RNE
연산 종류	$I$ inputs, $J$ RBFs	$I$ inputs, $J$ RBFs, $K$ NMC nodes
곱셈	$(I+3)J$	$(K+I+2)J+7K$
나누기	$J$	$J+K$
덧셈	$(2I+1)J$	$(I+K)J+6K$
exp 계산	$J$	$J+K$

하여 RNE가 RE보다 연산수가 적은 조건을 구해보면

$$\text{if } K=2, \text{ then } (I+2)J > 28 : \text{multiplication} \quad (11)$$

$$IJ > 8 : \text{plus}$$

이므로 등화기 차수가 2이상이면, RNE가 모든 연산 횟수가 적으며,

$$\text{if } K=3, \text{ then } (3I+7)J > 84 : \text{multiplication} \quad (12)$$

$$(7I+1)J > 72 : \text{plus}$$

이므로 등화기 차수가 2이상이면, RNE의 연산 횟수가 더 적다. 따라서 기존의 등화기에 비하여 간단한 구조와 적은 계산량의 등화기를 설계할 수 있다.

### III. 등화 실험 결과

제안한 등화기에 대한 성능 비교를 위하여 다음의 측면을 고려한다. 먼저 식 (2)와 같은 채널 응답을 갖는 디지털 통신 시스템에서의 각 등화기에 대한 BER 성능과 복잡도 비교를 한다. 또한 비선형 왜곡 현상이 존재하는 자기기록 채널 환경에서 각 등화기들의 BER 성능을 비교하고, MSE 수렴 특성을 기존의 등화기들과 비교 분석한다. 마지막으로 제안한 등화기를 결정회환 방식으로 구성하여 error propagation 특성을 알아본다. BER을 구하기 위하여 각 등화기의 weight에 대한 학습은 MSE 값의 변화가 거의 없을 때까지 충분한 학습을 수행한 후, 결정 모드로 전환하여 BER을 계산하였다.

#### 1. 디지털 통신 시스템에서의 성능 비교

먼저 그림 3과 같은 시스템에 식 (2)에 나타난 채널의 전달함수를 이용하여 제안한 RNE를 각 등화기들과 MSE와 BER 측면에서 성능을 비교한다. 제안한 등화기를 앞에서 언급한 설계 방법에 따라 구성하였다. 우선 4개의 입력과 32개의 RBF, 2개의 NMC node로 구성된 등화기와 4개의 입력과 16개의 RBF, 3개의 NMC node로 각각 구성된 등화기

의 성능을 MSE 관점에서 그림 7에 비교하였다. 신호 대 잡음 비(SNR : signal-to-noise ratio)는 18dB이며 모든 등화기의 학습률은 0.01로 같게 하였다. 그림 7을 보면 선형 등화기가 가장 구조가 간단하므로, 가장 빠른 수렴 특성을 나타내었으나 최종 MSE 성능은 가장 열악하였다. 반면에 제안한 등화기는 초기 수렴 속도는 RE에 비하여 느리지만 최종 MSE 수렴 속도는 RE보다 빠르며, 월등히 우수한 MSE로 수렴함을 확인할 수 있었다.

그림 8은 각 등화기의 BER 성능을 나타낸다. 제안한 RNE는 optimal Bayesian 등화기와 BER 성능에 있어서 차이가 거의 없음을 알 수 있다. 또한 그림 8에서 알 수 있듯이 더 많은 NMC node를 사용하여도 성능상의 이득은 없었으며, 오히려 지역 극소에 쉽게 빠져, 학습에 많은 어려움이 따랐다. 따라서 실험 결과, 16이하로 RBF를 감소시키면 등화기는 성능 면에 있어서 급격한 하락을 나타내었다. RBF를 16이하로 감소시키는 경우에 있어서 NMC node의 증가에 따른 성능상의 이득은 거의 없었으며, 오히려 지역 극소, 느린 수렴 등의 신경망의 문제점이 대두되었다. 이는 계속된 실험에서도 나타나는 데 기존 RBF 수의 1/4 보다 적은 수의 RBF를 사용할 경우에 급격한 성능 하락 현상을 나타낸다.




그림 7. 각 등화기의 MSE 수렴 곡선

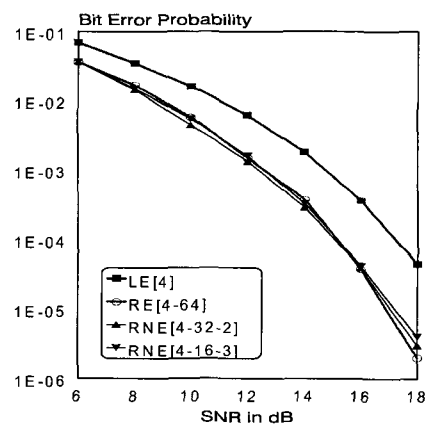


그림 8. 심벌간의 간섭이 존재하는 환경에서의 등화기의 BER 성능 비교

표 3. Complexity of the equalizers in simulation

연산 종류	RE[4-64]	RNE[4-32-2]		RNE[4-16-3]	
	연산수	연산수	연산감소율(%)	연산수	연산감소율(%)
곱셈	448	238	46.9	165	63.2
나누기	64	34	46.9	19	70.3
덧셈	576	204	64.6	130	77.4
exp 계산	64	34	46.9	19	70.3

이번에는 각 등화기의 복잡도를 연산 횟수 측면에서 표 3에 비교하였다. 표 3의 연산 횟수와 연산 횟수의 감소율 비교를 보면 제안한 등화기들은 기존의 RE보다 모든 연산에서 대폭 감소함을 알 수 있다. 연산 횟수에 있어서 NMC node의 수가 2개인 등화기는 기존의 RE에 비하여 절반에 가까운 구조 단순화를, NMC node가 3개인 제안한 등화기는 약 1/3에 가까운 구조 단순화를 이루었음에도 불구하고 기존 RE와 유사한 BER 성능을 나타낸다.

이번에는 채널 추정 등의 오차로 인해 등화기의 설계가 정확히 이루어지지 못했을 경우, 제안한 등화기의 성능 하락 정도를 알아본다. 그림 9는 입력 차수를 3으로 했을 때, NMC node 수의 변화에 따른 BER 성능 곡선이다. NMC의 영향으로 인하여 기존의 optimal Bayesian 등화기보다는 어느 정도의 성능하락이 나타나지만 기존의 선형 등화기보다는 아직 우세한 성능을 나타내었다. 따라서 실험 결과 제안한 RNE는 채널 추정 등의 오차에 기존의 RE에 비하여 더욱 강한 특성을 나타내었다.

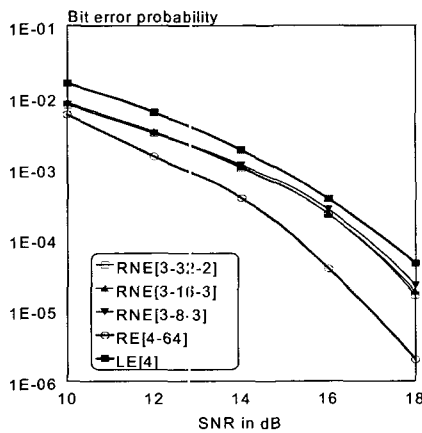


그림 9. 입력 차수의 추정 오차가 존재할 경우의 등화기 BER 성능 비교

2. 디지털 자기기록 시스템에서의 성능 비교

이번에는 비선형 왜곡이 존재하는 디지털 자기기록 시스템에서 등화기의 성능을 비교한다. 실험에 사용하는 디지털 자기기록 시스템은 그림 10과 같다. 포화 기록의 특성으로 인해 자기기록 채널은 두 레벨(±1)만을 허용하고 미분 특성으로 인해 앞·뒤 심벌의 변화만이 기록된다[11]. 그림 10에서  $a_k$ 는 자기기록 채널의 입력으로 bipolar 이진 전류 신호를 나타낸다. 이 신호는 자기기록 채널의 미분 특성에 의해 부분 응답 신호인 '1-D' 형태, 즉  $b_k$ 로 자기기록 시스템에 기록되게 된다. 부분 삭제 모델에서는 이  $b_k$ 에 감쇠 효과인  $\gamma$ 를 곱해주어 채널의 비선형성을 나타낸다. 이 때,  $\gamma$ 는 현재의 심벌을 기준으로 앞·뒤에 천이가 있는지 즉,  $b_k$ 가 ±1인지 아닌지에 따라 다음 식과 같이 값이 정해진다[11].

$$\gamma = \begin{cases} a^2, & \text{앞·뒤 심벌 모두 천이가 있을 때} \\ a, & \text{앞·뒤 심벌중 하나만 천이가 있을 때} \\ 1, & \text{앞·뒤 심벌 모두 천이가 없을 때,} \end{cases} \quad (13)$$

자기기록 채널에서 앞·뒤 심벌에 천이가 있을 경우에 비선형 특성이 가장 크게 나타나며, 앞·뒤 심벌에 천이가 없을 경우에는 비선형 특성이 거의 작용하지 않는다. 기록 밀도에 따라 감쇠 효과  $\alpha$ 를 실험에 의해 결정된 값을 사용한다. 본 논문에서는 기록 밀도가 2.0인 경우 즉  $\alpha=0.7$ 인 경우를 사용하여 실험을 수행한다. 이와 같이 결정된 감쇠 효과를  $b_k$ 에 곱하여 비선형 특성을 모델링한 뒤, 로렌즈 펄스 모델 (Lorentzian pulse model)을 이용하여 전체 자기기록 채널의 출력,  $y(t)$ 를 얻는다.

$$y(t) = \sum_k (\gamma \cdot b_k) * h(t) = \sum_k c_k * h(t) \quad (14)$$

여기서  $h(t)$ 는 다음과 같은 Lorentzian 펄스이다.

$$h(t) = \frac{\gamma}{1 + \left(\frac{2t}{PW50}\right)^2} \quad (15)$$




그림 10. 부분 삭제 모델을 이용한 디지털 자기기록 시스템

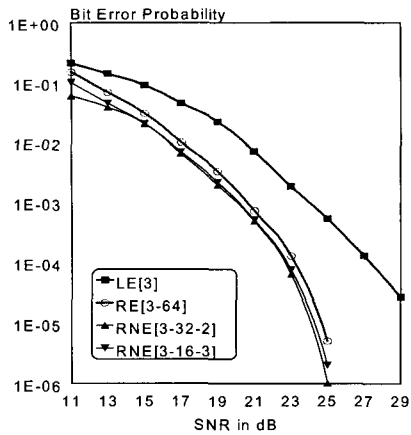


그림 11. 자기기록 시스템에서 등화기 BER 곡선

또 기록된 양 또는 음의 펄스는  $g(t) = h(t) - h(t-T)$ 이다. 식 (15)에서 PW50은  $h(t)$ 의 크기가 최대 값의 1/2되는 위치의 펄스 폭을 나타내고,  $T$ 는 연속된 두 심벌 사이의 시간 간격이다.

그림 11은 부분 삭제 모델로 표현한 자기기록 시스템에서 등화기의 BER 성능 곡선이다. BER =  $10^{-4}$ 에서의 각 등화기에 대한 요구 SNR을 보면 LE는 약 28dB, RE는 약 23.2dB로서 LE보다 약 4.8dB 우수하며, RNE는 약 22.4dB의 SNR이 요구되어 LE보다는 약 5.6dB, RE보다는 약 0.8dB의 개선 효과를 얻을 수 있었다. 비선형 왜곡이 있는 경우에는 오히려 기존의 RE보다 제안한 등화기가 훨씬 간단한 구조로 더욱 우수한 성능을 나타낸다. 이는 첫 번째 은닉층과 두 번째 은닉층에 모두 우수한 비선형 사상 능력을 갖는 신경망 전달 함수를 사용하는 노드를 포함하기 때문이다.

이번에는 제안한 등화기의 입력을 결정계환 방식으로 구현하여 앞의 자기기록 채널에서 BER 성능을 측정하였다. 그림 12에서 실선의 BER 곡선을 보면 BER= $10^{-4}$ 에서 제안한 등화기의 결정계환 방식인 RDNFE가 DFE보다 약 1dB, RE의 결정계환 방식인 RDNFE보다는 약 0.3dB 정도 우수하였다. 이번에는 error propagation 특성을 살펴보자. 그림 12에서 실선으로 나타낸 BER 곡선은 등화기 출력을 결정계환의 값으로 이용하였고, 점선으로 표시한 BER 곡선은 정확한 값을 결정계환 하였다. BER= $10^{-4}$ 에서 error propagation에 의한 성능 손실을 살펴보면 약간의 차이는 존재하지만 DFE와 RDNFE는 거의 1dB에 가까운 손실이 발생한다. 그러나 제안한 등화기는 약 0.5dB 정도의 손실만이

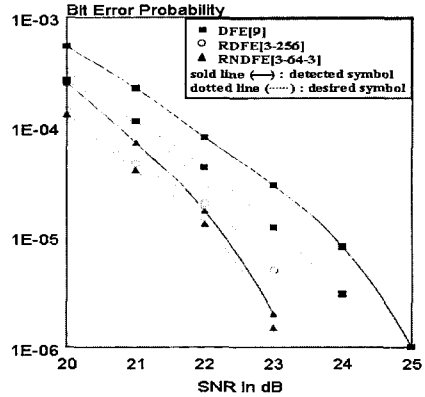


그림 12. 자기기록 시스템에서의 등화기 BER 성능 곡선과 error propagation에 따른 성능 변화

발생하여 error propagation에 가장 강건함을 나타내었다.

이상의 실험 결과 제안한 등화기는 선형적인 왜곡 현상이 존재하는 환경에서 성능 저하가 거의 없이 기존의 RE를 간단한 구조로 구현할 수 있으며, 비선형 왜곡 등 정보 신호에 심한 손실이 존재하는 환경에서는 오히려 기존의 등화기보다 훨씬 간단한 구조로 보다 우수한 성능을 나타내었다. 또한 제안한 등화기를 결정계환 방식으로 구현하여 정보 신호의 손실이 심한 환경에 적용한 결과 보다 간단한 구조로 우수한 성능을 나타내었으며, error propagation 영향도 가장 적음을 알 수 있다.

#### IV. 결론

본 논문에서는 최적 Bayesian 등화 해인 RE의 구조를 보다 단순화하고, 비선형 왜곡 등의 심각한 정보 신호의 손상에 대한 보상 능력을 향상시키기 위하여 비선형 다층 결합을 갖는 RNE를 새로이 제안하였다. 제안한 등화기를 선형 간섭이 있는 통신 시스템과 비선형 왜곡 현상이 존재하는 자기기록 시스템에 채널 등화기로서 적용하였다. 선형 간섭이 존재하는 통신 환경에서는 RE와 비교하여 보다 간단한 구조로 거의 유사한 BER 성능을 나타내었으며, 비선형 왜곡이 존재하는 자기기록 시스템에서는 RE에 비하여 훨씬 간단한 구조로 우수한 성능을 나타내었다. 또한 기존의 RE는 RBF 중심과 채널 상태 등, 요소 인자들의 추정에 대한 정확성에 성능이 크게 좌우되는 데에 비하여 제안한 등화기는 어느 정도의 강인함을 확인하였다. 제안한 RNE를 결정계환 구조로 구현하여 자기기록 시스템에



