

論文97-34S-9-3

# 결정 궤환 재귀 신경망을 이용한 비선형 채널의 등화

## (Nonlinear Channel Equalization using a Decision Feedback Recurrent Neural Network)

邕成煥\*, 劉哲雨\*, 洪大植\*

(Sunghwan Ong, Cheolwoo You, and Daesik Hong)

### 요약

본 논문에서는 선형, 비선형 왜곡이 심한 채널의 적응 등화를 위하여 결정 궤환 재귀 신경망 등화기를 제안한다. 제안한 등화기는 기존의 신경망 등화기들과는 달리 IIR 여과기 구조를 갖는 등화기이다. 결정 궤환 재귀 신경망 등화기의 학습 알고리듬으로는 재귀 신경망의 학습에 널리 사용되는 실시간 학습 알고리듬 (Real-Time Learning Algorithm)이 변형되어 사용된다. 제안한 등화기를 심볼간의 간섭만이 존재하는 채널과 심볼간의 간섭뿐만 아니라 비선형 왜곡이 있는 디지털 자기 기록 채널에 적용하여 보았다. 그리고, 그 성능을 기존의 선형 등화기, 결정 궤환 등화기, 신경망을 이용한 등화기들과 오차율 측면과 평균 자승 에러 측면에서 성능을 비교, 분석하였다. 제안한 등화기는 간단한 구조를 가지면서 다른 어떠한 기존의 등화기보다도 우수한 왜곡 보상 능력을 보였으며, 수렴 속도 또한 매우 빠르고 안정적임을 보여주었다.

### Abstract

In this paper, a decision feedback recurrent neural equalization (DFRNE) scheme is proposed for adaptive equalization problems. The proposed equalizer models a nonlinear infinite impulse response (IIR) filter. The modified Real-Time recurrent Learning Algorithm (RTRL) is used to train the DFRNE. The DFRNE is applied to both linear channels with only intersymbol interference and nonlinear channels for digital video cassette recording (DVCR) system. And the performance of the DFRNE is compared to those of the conventional equalization schemes, such as a linear equalizer, a decision feedback equalizer, and neural equalizers based on multi-layer perceptron (MLP), in view of both bit error rate performance and mean squared error (MSE) convergence. It is shown that the DFRNE with a reasonable size not only gives improvement of compensating for the channel introduced distortions, but also makes the MSE converge fast and stable.

### I. 서론

일반적인 통신 시스템에서 신뢰성 있는 통신을 방

\* 正會員, 延世大學校 電子工學科 情報通信研究室

(Information & Telecommunication LAB. Dept. of Electronic Eng., Yonsei Univ.)

※ 이 논문은 정보통신연구관리단의 대학기초 연구지원 사업과 영상 기기 조합의 학술지원하에 이루어졌다.

接受日字: 1997年5月6日, 수정완료일: 1997年7月26日

해하는 가장 큰 요소는 심볼간의 간섭이다. 심볼간의 간섭은 통신 채널의 특성이 이상적이지 못하여, 전송된 신호가 인접한 심볼들에 의해 왜곡되어지는 현상을 말한다. 채널의 주파수 대역내에 널이 심한 경우일 수록 심볼간의 간섭에 의한 왜곡이 커진다.

통신 시스템의 수신단에서 심볼간의 간섭을 제거하여 전송된 신호를 올바르게 복원하기 위해 사용되는 신호 처리 기법이 등화 기법 (equalization)이다. 이러한 경우에 MLP를 이용한 신경망 등화기들이나 MLSE가 사용되기도 한다. MLSE와 MLP를 이용한

신경망 등화기들은 구조적으로 비선형 특성을 가지고 있기 때문에, 선형 등화기나 결정 채환 등화기와 비해 탁월한 비선형 왜곡 보상 능력을 가지고 있다<sup>[2], [3]</sup>. 하지만 MLSE와 MLP를 이용한 신경망 등화기들은 구조가 너무 복잡하다는 단점을 가지고 있어서 실제 시스템에 적용하기가 어렵다.

전송된 신호에 가해지는 선형, 비선형 왜곡을 간단한 구조로 효율적으로 보상해주기 위해 비선형 IIR 여과기의 구조를 가지는 Recurrent Neural Network을 이용한 등화기법 (Recurrent Neural Equalizer : RNE)을 Kechriotis와 Manola- 위에서 언급한 문제를 해결하기 위하여 이 논문에서는 결정 채환 재귀 신경망 등화기 (Decision Feedback Recurrent Neural Equalizer : DFRNE)를 제안한다. 제안된 결정 채환 재귀 신경망 등화기는 기존의 MLP를 이용한 신경망 등화기들과는 달리 현재 노드의 출력 값을 계산할 때, 과거 출력 값들이 재귀적으로(recursively) 영향을 주는 IIR 여과기 구조를 갖는다.

이 논문에서는 짐볼간의 간접만이 있는 채널들과 채널 자체에 비선형 특성을 가지고 있는 DVCR 시스템에 제안한 등화기를 적용하여, 기존의 선형 등화기, 결정 채환 등화기, MLP를 이용한 신경망 등화기들과 비트 오류율 (bit error rate) 측면과 수렴 속도의 관점에서 제안한 등화기의 성능을 비교 분석한다.

2장에서는 재귀 신경망을 이용한 등화기(RNE)에 대해 간략히 설명하고, 3장에서는 제안한 결정 채환 재귀 신경망 등화기의 구조와 학습 방법에 대하여 설명한다. 4장에서는 여러 가지 채널에서 실험한 등화기들의 성능을 비교, 설명하고, 5장에서 결론을 맺는다.

## II. 재귀 신경망 등화기

재귀 신경망은 기존에 많이 사용되어온 MLP를 이용한 신경망과는 달리 feedback 경로를 가지고 있는 IIR 여과기 구조의 신경망이다. 재귀 신경망은 Kechriotis 등에 의해 채널 등화에 적용되기 시작하였다<sup>[4]</sup>. 그림 1에 외부 입력이 3 개이고 외부 출력도 3 개, 은닉층에 노드 3개를 사용한 재귀 신경망 등화기의 구조를 나타내었다.

그림 1에 나타나 있는 재귀 신경망 등화기에서 각 노드에서의 계산되어지는 net-value들은 다음과 같이 계산되어진다.

$$S_i(t) = \sum_{j \in I \cup L} w_{ij}(t) \cdot z_j(t) \quad (1)$$

여기서,  $w_{ij}$ 는 각 노드 사이의 연결 강도를 나타내며,  $z_j(t)$ 는 노드의 현재 출력값에 영향을 주는 현재의 노드 입력을 의미하는데, 다음과 같이 나타내어진다.

$$z_j(t) = \begin{cases} x_j(t), & \text{if } j \in I \\ y_j(t-1), & \text{if } j \in L \end{cases} \quad (2)$$

위의 식에서 집합  $I$ 는 외부 입력들의 집합을 나타내고, 집합  $L$ 은 과거 출력 값들의 집합을 나타낸다.

식 (1)과 (2)로부터 각 노드의 출력 값  $y_j(t+1)$ 은 다음과 같이 구할 수 있다.

$$s_i(t) = \sum_{j \in I} w_{ij}(t) \cdot x_j(t) + \sum_{j \in L} w_{ij}(t) \cdot y_j(t-1) \quad (3)$$

$$y_j(t+1) = f(s_i(t)), \quad f(x) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (4)$$

식 (4)에서  $f(\cdot)$ 은 신경망의 여기 함수(excitation function)를 나타내는데, 식 (4)에서와 같이  $\tanh(\cdot)$ 으로 표현되어진다. 여기서, 단위 시간 (symbol duration) 전의 net-value를 가지고 출력값을 계산하는 것에 주의하여야 한다<sup>[4]</sup>.

식 (1)에서 (4)로 부터, 재귀 신경망의 현재 노드 출력 값을 계산하는 과정에 과거 노드 출력 값들이 사용되어짐을 알 수 있다. 이를 통해 기존의 MLP를 이용한 신경망 등화기들이 비선형 FIR 여과기의 구조를 갖는 것과 달리 재귀 신경망 등화기는 비선형 IIR 여과기의 구조를 갖는다는 것을 알 수 있다.

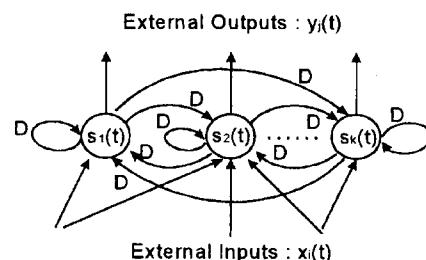


그림 1. 재귀 신경망 등화기의 구조

Fig. 1. Structure of a recurrent neural equalizer.

재귀 신경망 등화기는 IIR 구조를 갖기 때문에 FIR 구조의 MLP를 이용한 신경망 등화기에 비해 간단한 구조를 가지고도, MLP를 이용한 신경망 등화기들과 비슷하거나 더 우수한 성능을 나타낼 수 있는 장점을

가지고 있다. 하지만, IIR 구조의 특징 때문에 시스템이 전체적으로 불안하여 자주 수렴에 실패하는 단점을 가지고 있다.

재귀 신경망을 학습시키는데는 일반적으로 Williams와 Zipser 등이 제안한 실시간 학습 알고리듬 (Real-Time Recurrent Learning : RTRL) [5] 이 사용된다.

### III. 결정 케환 재귀 신경망 등화기

결정 케환 재귀 신경망 등화기는 재귀 신경망을 이용한 등화기이다. 그러나, Kechriotis가 제안한 등화기 와는 달리 과거의 노드 출력 값들을 그대로 케환시키는 것이 아니고 과거의 노드 출력 값들을 먼저 검출하고 난 후, 그 결과값들을 케환시키는 구조를 갖는다. 그럼 2에 제안한 결정 케환 재귀 신경망 등화기의 구조를 나타내었다.

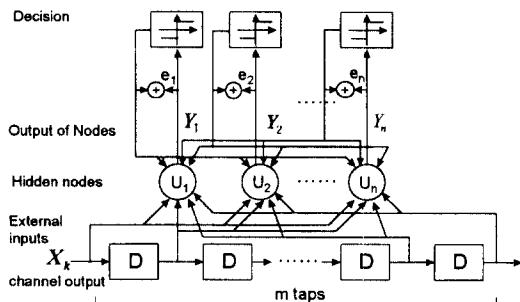


그림 2. 결정 케환 재귀 신경망 등화기의 구조  
Fig. 2. Structure of a decision feedback recurrent neural equalizer.

그림 2에서 알 수 있듯이 각 노드들에서 출력 값이 계산되어질 때 사용되는 것이 원 전송 신호에 에러 값들이 포함된 결과값들이 아니고, 검출된 값(학습 시에 원 신호 값)이 사용된다. 즉, 결정 케환 재귀 신경망 등화기에서 각 노드들의 출력 값들은 다음과 같이 계산되어진다.

$$S_i(t) = \sum_{j=1}^L w_{ij}(t) \cdot x_j(t) + \sum_{j=L}^n w_{ij}(t) \cdot \hat{y}_j(t-1) \quad (5)$$

$$\hat{y}_i(t) = \begin{cases} +1, & \text{if } y_i(t) > 0.5 \\ -1, & \text{if } y_i(t) < 0.5 \end{cases} \quad (6)$$

위의 식 (6)에서와 같은 검출식은 전송 신호가 Bipolar 신호라고 가정하였을 경우이다. 전송 신호가

이진 신호일 경우에는 다음과 같은 검출식에 의해 케환되어지는 값이 결정된다.

$$\hat{y}_i(t) = \begin{cases} 1, & \text{if } y_i(t) > 0.5 \\ 0, & \text{if } y_i(t) < 0.5 \end{cases} \quad (7)$$

식 (5)를 보면, 기존의 재귀 신경망 등화기와는 달리 검출된 값, 즉 원 신호에서 에러 값이 제거된 값들이 현재 각 노드 출력 값의 계산에 사용됨을 알 수 있다. 재귀 신경망 등화기에서는 에러 값들이 포함된 상태의 과거 출력 값들이 반복하여 노드의 출력 값 계산에 이용되어 시스템이 불안정하였던 단점을 케환되는 값들에서 에러 값들을 제거함으로써 보완할 수 있다.

결정 케환 재귀 신경망 등화기를 학습시키는데는 재귀 신경망 등화기의 학습에 사용되었던 실시간 학습 알고리듬이 변형되어 사용된다. 아래에 그 학습 방법을 정리하였다.

결정 케환 재귀 신경망 등화기의 연결 강도들은 각 순간에서의 모든 노드들의 순시 에러값들의 제곱의 합으로 나타내어지는 비용 함수를 최소화 시키는 방향으로 학습을 시킨다. 어떤 한 순간에서의 비용 함수는 다음과 같이 나타낼 수 있다.

$$J(T+1) = \frac{1}{2} \sum_{k=1}^N E_k^2(T+1) \quad (8)$$

여기서,  $E_k^2(t+1)$ 는 각 노드에서의 순시 에러 값을 나타낸다. 각 순시 에러 값은 다음과 같이 계산되어 진다.

일단, 식 (5), (6), (7)을 이용하여 등화기의  $i$ 번째 노드의 출력 값을 계산한다. 그리고 난 후, 원하는 출력 값과 등화기의 출력 값의 차이, 즉 에러 값을 다음과 같이 계산한다.

$$e_k(t+1) = d_k(t+1) - y_k(t+1) \quad (9)$$

여기서 원하는 출력 값은 학습시키는 데이터들을 메모리에 기억시켜 놓았다가 순차적으로 추출하여 사용한다. 이렇게 구한 각 노드의 에러 값을 이용하여 비용 함수 값을 계산할 수 있다.

여기서, 기존의 실시간 학습 방법에서처럼 민감도 함수  $p_{ij}^k(t)$ 를 다음과 같이 정의한다.

$$P_{ij}^k(t) = \frac{\partial y_k(t)}{\partial w_{ij}} \quad (10)$$

첨자  $i, j, k$ 들은 각각 은닉 층의 노드, 입력 층의 노드, 출력이 나오는 노드를 나타낸다. 이와 같이 민감도 함수를 정의하면, 다음과 같은 과정을 통해 비용 함수를 최소화시키는 학습이 가능하다.

각 노드의 민감도 함수는 다음과 같이 각 순간마다 보정되어진다.

$$P_{ij}^k(t+1) = f(S_k(t+1)) \left( \sum_{l=1}^L w_{kl}(t) P_{lj}^l(t) + \delta_{ik} x_i(t) \right) \quad (11)$$

여기서,  $\delta_{ik}$ 는 크로네커 (Kronecker) 델타 함수를 나타내고,  $f(\cdot)$ 은 여기 함수의 미분 함수를 나타낸다.

식 (11)에서 계산된 민감도 함수를 이용하여, 각 노드들 사이에 모두 연결되어 있는 연결 강도들을 다음과 같이 보정할 수 있다.

$$w_{ij}(t+1) = w_{ij}(t) + \alpha \sum_{k=1}^M e_k(t+1) P_{ij}^k(t+1) \quad (12)$$

여기서,  $\alpha$ 는 학습 계수를 나타내는데 일반적으로 충분히 작은 양수로 정하여 준다.

위에서 설명된 식 (5)에서 식 (12)까지를 반복적으로 수행함으로써 결정 케환 재귀 신경망 등화기는 식 (8)에서 정의한 비용 함수 값을 감소시키는 방향으로 학습시킬 수 있다.

#### IV. 실험 및 결과

이 장에서는 여러 종류의 채널들에서의 실험을 통하여 기존의 선형 등화기, 결정 케환 등화기, 신경망을 이용한 등화기들, 그리고 재귀 신경망 등화기와 제안한 등화기의 성능을 비교분석하여 본다.

##### 1. 심볼간의 간섭 환경에서의 성능 비교

먼저, 전송 신호가 주로 심볼간의 간섭으로 인해 왜곡되어지는 환경하에서의 여러 등화기들의 성능에 대해서 살펴보았다.

표 1에 실험에 사용된 채널들의 전달 함수들을 Z-변환식으로 나타내었다. 채널 A는 채널의 주파수 대역 내에 심한 널(null)이 존재하는 채널이고, 채널 B는 채널의 주파수 대역 내에 널이 존재할 뿐만 아니라, 표 1에 나타나있듯이 수신단에서의 수신 신호에 비선형 왜곡이 가해지는 채널이다. 표 2에는 실험에 사용된 등화기들의 구조를 정리하였다. 각 등화기들의 구조를

과 학습 계수는 실험을 통하여 가장 적합한 것을 찾은 것이다.

그림 3과 그림 4에, 각각 채널 A와 채널B에서 선형 등화기, 결정 케환 등화기, 재귀 신경망 등화기, 그리고 제안한 결정 케환 재귀 신경망 등화기들의 BER(bit error rate) 성능을 나타내었다.

채널 A는 그림 3에서 나타나 있는 것과 같이 선형 등화기로는 채널의 주파수 대역내에 있는 널을 보상할 수 없는, 심볼간의 간섭이 심한 채널이다. 이러한 환경에서, 기존의 결정 케환 등화기, 재귀 신경망 등화기, 결정 케환 재귀 신경망 등화기들이 채널의 등화에 성공하였음을 알 수 있다. 이 때, 결정 케환 등화기에 비해 신경망을 이용한 등화기들, 즉 재귀 신경망 등화기와 결정 케환 재귀 신경망 등화기들의 성능이 우수함을 알 수 있다. 신경망이 채널 A와 같이 심볼간의 간섭이 심한 채널 등화에 효율적임을 보여주고 있다. 특히, 제안한 결정 케환 재귀 신경망 등화기의 성능이 다른 등화기들에 비해 23dB 이상 우수함을 알 수 있다.

채널 B는 표 1에서 나타낸 것처럼 심볼간의 간섭뿐 아니라, 비선형 왜곡이 가해지는 채널이다. 그림 4를 통해 비선형 왜곡이 존재하는 환경에서, 등화기들의 성능 차는 보다 분명해짐을 알 수 있다. 특히, 비선형 왜곡 현상이 추가되어짐에 따라 신경망을 사용한 등화기들과 사용하지 않은 등화기들의 성능 차이가 두드러진다.

표 1. 실험에 사용된 채널들의 전달 함수

Table 1. Transfer functions of the channels.

채널	Z-변환식
채널 A	$H(z) = 0.227 z^{-0} + 0.460z^{-1} + 0.688z^{-2} + 0.460z^{-3} + 0.227 z^{-4}$
채널 B	$H(z) = 0.407 z^{-0} + 0.815z^{-1} + 0.407z^{-2}$ 위의 채널을 통과한 수신 신호 $r_k(t)$ 에 다음과 같은 비선형 왜곡을 가한다. $r_k(t) = \begin{cases} +1.0, & \text{if } r_k(t) > +1.0 \\ -1.0, & \text{if } r_k(t) < -1.0 \\ r_k(t), & \text{if }  r_k(t)  < +1.0 \end{cases}$

표 2. 실험에 사용된 등화기들의 구조

Table 2. Structures of the equalizers used in the experiments.

등화기 종류	구조	학습계수
선형 등화기	31개 템	0.02
결정 케환 등화기	31개 템	0.02
재귀 신경망 등화기	입력 11개 템 은닉 4개 템	0.3
결정 케환 재귀 신경망 등화기	입력 11개 템 은닉 4개 템	0.3

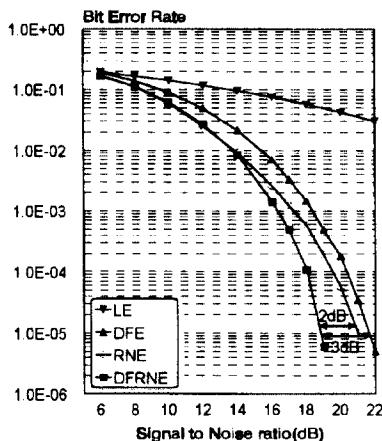


그림 3. 채널 A에서 등화기들의 BER 성능  
Fig. 3. BER Performances of various equalizers for the channel A.

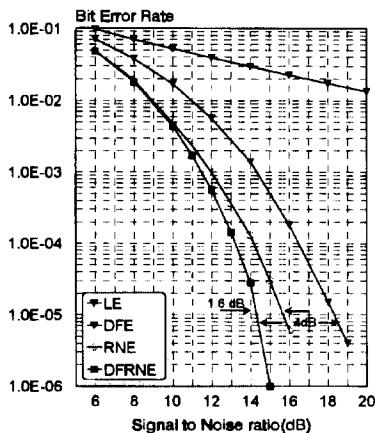


그림 4. 채널 B에서 등화기들의 BER 성능  
Fig. 4. BER Performances of various equalizers for the channel B.

위의 결과들을 통하여, 세 가지 사실을 알 수 있다. 첫 번째는 채널이 비선형 왜곡을 가하는 경우에, 신경망을 사용하는 등화기들이 그렇지 않은 등화기들에 비해 효율적으로 왜곡을 보상한다는 것이다. 두 번째 사실은 재귀 신경망을 이용한 등화기는 기존의 신경망을 이용한 등화기들과는 달리 IIR 구조를 가짐으로써, 선형 등화기나 결정 계획 등화기에 비교하여 시스템의 복잡도나 계산량이 그리 증가하지 않음을 표 2를 통하여 알 수 있다. 그리고 나머지 하나는 제안한 결정 계획 등화기가 기존의 재귀 신경망 등화기 보다 우수한 선형, 비선형 왜곡 보상 능력을 갖고 있다는 것이다.

그림 5에는 채널 B에서 결정 계획 등화기와 재귀

신경망 등화기, 그리고 제안한 등화기의 MSE 곡선을 나타내었다. 모든 등화기들에 대해 SNR은 15dB로 고정한 상태로 200번 실험을 하여 양상을 평균을 취한 결과이다.

재귀 신경망을 이용한 등화기들이 그렇지 않은 결정 계획 등화기보다 MSE를 더 작은 값으로 빠르게 수렴 시킴을 알 수 있다. 하지만, 재귀 신경망 등화기의 경우는 수렴이 된 상태에서 진동이 매우 심한 것으로 보아 IIR 구조를 갖는 시스템의 단점인 시스템의 불안정성 문제를 극복하지 못하고 있다는 사실을 알 수 있다. 하지만, 제안한 등화기는 IIR 구조를 갖음에도 불구하고 재귀 신경망 등화기와는 달리, 진동이 거의 없는 매우 안정된 수렴 곡선을 보여준다. 이는 결정된 값들을 계획 시킴으로써 신경망 내에 계속 잔재할 수 있는 여러 값들을 제거하여 보다 안정된 동작을 하는 것이다.

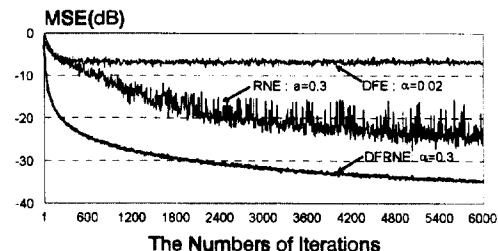


그림 5. 채널 B에서 등화기들의 정규화된 MSE 곡선  
Fig. 5. Normalized MSE graphs of various equalizers for the channel B.

## 2. DVCR시스템에서의 성능 비교

다음에는 채널에 비선형 특성이 강하게 내포되어 있는 고밀도 자기 기록 시스템에서의 여러 등화기들의 성능을 비교한다.

자기 기록 채널은 자기 기록 매체의 물리적 특징으로 인하여 기록된 신호에 심한 비선형 왜곡을 가한다 [6], [7], [8]. 자기 기록 채널에 기록되는 신호 패턴은 일반적으로 로렌츠 펄스(Lorenzian pulse)로 모델링 되어진다 [3], [6]. 여기에 자기 기록 매체의 비선형 특성인 천이 이동 현상(transition shift)과 천이 확장 현상(transition broadening), 그리고 중첩 기록 현상(overwrite effect) 등을 포함시킨 형태로 비선형 자기 기록 채널을 모델링한다. 자기 기록 매체에 기록할 정보를  $\{+1, -1\}$ 의 값을 갖는  $\{a_k(t)\}$ 라 하였을 때, 실제로 자기 기록 매체에 기록되는 정보의 형태는

$$b_k(t) = a_k(t) - a_{k-1}(t) \quad (13)$$

로 나타내어 진다. 여기서,  $t$ 는 기록 순간을 나타내며, 첨자  $k$ 는 그 순간 TDL구조 내의 위치를 나타낸다. 이와 같은 방식으로 모델링 되어진 비선형 자기 기록 매체는 아래 식으로 표현되어진다<sup>[3]</sup>.

$$\begin{aligned} h(t, PW50) = & \sum_k \frac{b_k(t)}{1 + \Delta PW50 |b_k(t) \cdot b_{k-1}(t)|} \cdot \\ & \frac{1}{1 + \left[ \frac{\left( b_k(t) - \frac{\varepsilon_1}{4} b_k(t) \cdot b_{k-1}(t) - \frac{\varepsilon_2}{4} b_k(t) \cdot b_{k-2}(t) \right)}{PW50 + \Delta PW50 |b_k(t) \cdot b_{k-1}(t)|} \right]} \end{aligned} \quad (14)$$

여기서,  $\varepsilon_1$ ,  $\varepsilon_2$ 는 각각 바로 한 비트 이전의 천이에 의한 천이 이동 현상과 두 비트 이전의 천이에 의한 천이 이동 현상을 나타내는 인자들이고,  $\Delta PW50$ 는 천이 확장 현상을 나타내는 인자이다.

자기 기록 매체는 정보를 저장하는 밀도가 증가함에 따라, 비선형 왜곡의 정도 역시 심해진다. 고밀도로 저장된 자기 기록 채널에서 기록된 정보를 올바르게 복원하는 데는 일반적으로 선형 등화기나 결정 케환 등화기가 많이 쓰여왔다. 그러나, 이들 등화기로는 자기 기록 매체의 비선형 왜곡 현상 때문에, 기록된 신호를 효율적으로 복원해낼 수 없다. 그래서, 최근에는 비선형 왜곡에 강한 MLP구조의 신경망 등화기들이 자기 기록 매체에서의 신호 복원에 사용되었다. 그러나, 기존의 MLP 구조의 신경망 등화기들은 그 구조가 너무 복잡하고 계산량이 많아 실제 시스템에 사용되기 어렵다.

그림 6, 그림 7, 그림 8에, 자기 기록 채널에서 여러 등화기들의 비트 에러율 성능 곡선을 나타내었다. 그리고 표 3에 사용된 등화기들의 구조를 정리하였다. BER성능의 비교 기준은 일반적으로 DVCR 시스템에서 요구하는  $10^{-4}$ 의 에러율에서의 SNR로 한다.

실험 결과들을 두 가지 측면으로 분석하였다. 첫 번째 측면은 구조적으로 유사한 선형 등화기와 신경망 등화기(LE vs NE)의 성능 비교와, 결정 케환 등화기와 신경망을 이용한 결정 케환 등화기(DFE vs NDFE)의 성능 비교이고, 두 번째 측면은 제안한 등화기와 다른 등화기들과의 성능 비교이다.

그림 6에는 기록 밀도 2.0일 때의 선형 등화기, 결정 케환 등화기, 신경망 등화기, 결정 케환 신경망 등화기와 제안한 등화기의 BER 성능을 나타내었다. 기

록 밀도 2.0일 때의 자기 기록 채널은 밀도 2.5나 3.0일 때에 비해 인접한 심볼들에 의한 심볼간의 간섭 왜곡이나 비선형 왜곡이 상대적으로 그리 크지 않다. 이러한 경우에는 신경망을 이용한 등화기와 신경망을 이용하지 않은 등화기의 성능 차이가 거의 없고, 제안한 등화기의 성능 이득도 1dB 정도로 그리 크지 않다.

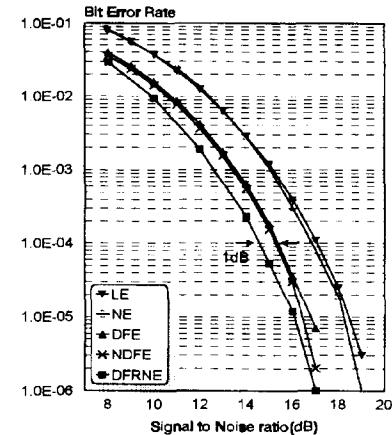


그림 6. 밀도 2.0에서 등화기들의 BER 성능

Fig. 6. BER performances of various equalizers at density 2.0 (PW50/T=2.0).

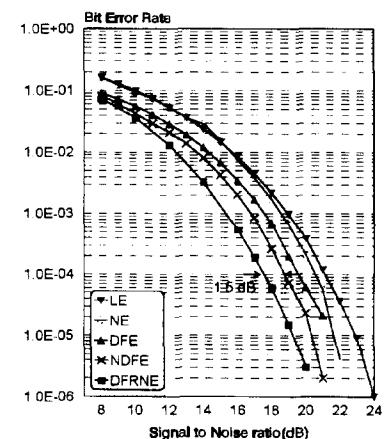


그림 7. 밀도 2.5에서 등화기들의 BER 성능

Fig. 7. BER performances of various equalizers at density 2.5 (PW50/T=2.5).

그림 7과 그림 8에는 기록 밀도 2.5, 3.0인 자기 기록 채널에서의 등화기들의 비트 에러율 곡선을 나타내었다. 기록 밀도가 증가하여 비선형 왜곡이 커지자, 신경망을 이용한 등화기들이 그렇지 않은 등화기들에 비해 1~5 dB 정도의 이득을 보인다. 뿐만 아니라, 제안

한 등화기의 다른 등화기들에 대한 성능 향상도 1.5~3 dB로 증가함을 알 수 있다.

자기 기록 채널에서의 실험을 통하여 다음과 같은 사실들을 알 수 있다. 첫 번째는 자기 기록 채널의 기록 밀도가 증가함에 따라 증가하는 비선형 왜곡에 대해 신경망을 이용한 등화기들이 그렇지 않은 등화기들에 비해 강하다는 사실이다. 두 번째는 표 3에서 알 수 있듯이, 신경망을 이용한 등화기들이 성능 이득을 얻기 위해서는 시스템의 복잡도나 계산량 측면에서 손실이 있는 데에 반해, 제안한 등화기는 신경망을 이용하면서도 IIR 구조를 갖는 특성으로 인해 훨씬 간단한 구조를 가지고 보다 효율적인 왜곡 보상 능력을 보인다는 것이다.

표 3. 실험에 사용된 등화기들의 구조  
Table 3. Structures of the equalizers used in the experiments.

등화기 종류	밀도 2.0	밀도 2.5	밀도 3.0
선형 등화기	31 taps	31 taps	31 taps
결정 계획 등화기	31 taps	31 taps	31 taps
신경망 등화기	입력 25 taps 은닉 11 taps	입력 29 taps 은닉 21 taps	입력 33 taps 은닉 15 taps
결정 계획 신경망 등화기	입력 25 taps 은닉 11 taps	입력 29 taps 은닉 27 taps	입력 29 taps 은닉 27 taps
결정 계획 재귀 신경망 등화기	입력 25 taps 은닉 11 taps	입력 11 taps 은닉 4 taps	입력 11 taps 은닉 4 taps

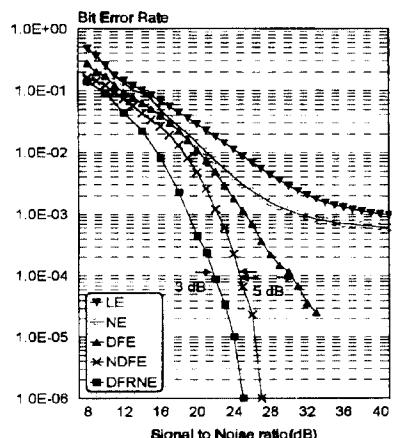


그림 8. 밀도 3.0에서 등화기들의 BER 성능  
Fig. 8. BER performances of various equalizers at density 3.0 (PW50/T=3.0)

## V. 결 론

제안한 결정 계획 재귀 신경망 등화기는 IIR 구조

를 갖는 신경망 등화기이다. 제안한 등화기는 신경망을 이용함으로써 채널에 의해 비선형적으로 왜곡된 신호를 효율적으로 복원할 수 있다. 그리고, 기존의 MLP를 이용한 신경망 등화기들이 비선형 FIR 구조의 등화기였던 것과는 달리 제안한 등화기는 비선형 IIR 구조의 등화기이어서, FIR 구조의 등화기에 비해 간단한 구조를 가지면서 보다 효율적인 왜곡 보상 능력을 보인다. 뿐만 아니라, 기존의 재귀 신경망 등화기와는 달리 과거의 노드 출력 값들을 검출한 후에 궤환 시킴으로써, 과거의 여러 값들이 시스템에 계속 잔재하여 시스템을 불안정하게 만드는 문제점도 보완할 수 있음을 보여주었다.

## 참 고 문 헌

- [1] John G. Proakis, Digital Communication, 3<sup>rd</sup> ed., McGraw-Hill, 1995.
- [2] J. M. Cioffi, W. L. Abbott, H. K. Tharp, C. M. Melas, and K. D. Fisher, "Adaptive Equalization for Magnetic-Disk Storage Channels," *IEEE Commun. Mag.*, pp. 14-29, Feb. 1990.
- [3] Jae-hee Cho, Cheol-woo You, and Dae-sik Hong, "The Neural Decision Feedback Equalizer for Nonlinear Digital Magnetic Recording Systems," *ICC '96*, Vol. 1, pp. 573-576, Dallas, Texas, U.S.A, 1996.
- [4] G. Kechriotis, E. Zervas, and E. S. Manolakos, "Using Recurrent Neural Networks for Adaptive Communication Channel Equalization," *IEEE Trans. on Neural Networks*, Vol. 5, no. 2, March 1994.
- [5] Williams, R. J., and Zipser, D., "A Learning Algorithm for Continually Running Fully Recurrent Neural Networks," *Neural Computation*, Vol. 1, pp. 270-280, 1989a.
- [6] I. Megory-Cohen, C. M. Melas, M. Hassner, and T. Howell, "An Analytic Model for Magnetic Readback Pulses," *IBM Res. Rep. RJ 5236*, July 1986.
- [7] P. Newby and R. Wood, "The effects of Nonlinear Distortion on Class IV Partial Response," *IEEE Trans. On Magnetics*,

- Vol. MAG-22, no. 5, pp. 1203-1205, Sep. 1986.
- [8] Jaekyun Moon and Jian-Gang Zhu, "Nonlinear Effects Transition Broadening," *IEEE Trans. On Magnetics*, Vol. MAG-27, pp. 4831-4833, Nov. 1991.
- [9] 조재희, 이종화, 강창언, 홍대식, "디지털 자기기록 장치에서의 신경망을 이용한 등화기 연구", 대한전자공학회 논문지, 제 33권 B편, 6호, pp. 164175, 1996. 6
- [10] 김영환, 옹성환, 유철우, 강창언, 홍대식, "디지털 자기기록 시스템에서의 부분 응답 신호의 검출방식", 대한전자공학회 논문지, 제33권 B호, 11호, pp. 83-88, 1996. 11

## 저자소개

邕成煥(正會員) 第 33卷 B編 第 11號 參照  
 1995년 연세대학교 전자공학 공학  
 사. 1997년 2월 연세대학교 전자  
 공학 공학석사. 1997년 3월 ~ 현  
 재 연세대학교 전자공학 박사과정  
 재학중

劉哲雨(正會員) 第 33卷 A編 第 4號 參照  
 현재 연세대학교 전자공학 박사과  
 정 재학중

洪大植(正會員) 第 33卷 A編 第 4號 參照  
 현재 연세대학교 전자공학 박사과  
 정 재학중