

論文99-36S-1-13

이차 시그모이드 신경망 등화기

(Quadratic Sigmoid Neural Equalizer)

崔 淳 龍 * , 崔 成 煥 * , 劉 哲 雨 * , 洪 大 植 *

(Sooyong Choi, Sunghwan Ong, Cheolwoo You, and Daesik Hong)

要 著

본 논문에서는 기존의 신경망 등화기의 비트 오류 확률 관점에서의 성능 향상을 위해 이차 시그모이드 함수를 활성 함수로 이용한 이차 시그모이드 신경망 등화기 등화기를 제안한다. 비선형 왜곡을 보정하기 위해 사용되어온 기존의 신경망 등화기들은 일반적으로 활성 함수로서 시그모이드 함수를 이용한다. 기존의 시그모이드 함수를 이용한 신경망 등화기의 경우 하나의 뉴론은 한 개의 선형적인 경계 면을 형성한다. 따라서 복잡한 경계 면을 형성하기 위해 많은 수의 뉴론이 필요하게 된다. 하지만 제안하는 신경망 등화기에서는 한 뉴론이 평행한 두 개의 직선을 가지고 평면 영역을 분할하기 때문에 보다 간단한 구조로 비트 오류 확률 관점에서 우수한 성능을 얻을 수 있다. 제안한 이차 시그모이드 신경망 결정궤환 등화기를 통신 환경 및 디지털 자기기록 시스템에 적용하였을 때, 기존의 결정궤환 등화기와 신경망 결정궤환 등화기에 비해 같은 비트 오류 확률 관점에서 신호 대 잡음비가 1.5dB~8.3dB 정도의 성능 향상을 보인다. 특히 심벌간의 간섭이 심하거나, 비선형성이 강한 환경에서 기존의 일반적인 결정궤환 등화기와 신경망 결정궤환 등화기에 비하여 비트 오류 확률 관점에서 두드러진 신호 대 잡음비의 성능 이득을 보인다.

Abstract

In this paper, a quadratic sigmoid neural equalizer(QSNE) is proposed to improve the performance of conventional neural equalizer in terms of bit error probability by using a quadratic sigmoid function as the activation function of neural networks. Conventional neural equalizers which have been used to compensate for nonlinear distortions adopt the sigmoid function. In the case of sigmoid neural equalizer, each neuron has one linear decision boundary. So many neurons are required when the neural equalizer has to separate complicated structure. But in case of the proposed QSNE and quadratic sigmoid neural decision feedback equalizer(QSNDFE), each neuron separates decision region with two parallel lines. Therefore, QSNE and QSNDFE have better performance and simpler structure than the conventional neural equalizers in terms of bit error probability. When the proposed QSNDFE is applied to communication systems and digital magnetic recording systems, it has an improvement of approximately 1.5dB~8.3dB in signal to noise ratio(SNR) over the conventional decision feedback equalizer(DFE) and neural decision feedback equalizer(NDFE). As intersymbol interference(ISI) and nonlinear distortions become severer, QSNDFE shows astounding SNR performance gain over the conventional equalizers in the same bit error probability.

* 正會員, 延世大學校 電子工學科

(Yonsei University, Electronic Engineering)

※ 본 연구는 한국과학재단지정 정보저장기기연구센터

의 지원(과제번호 97K3-0803-01-04-1)을 받아

이루어졌으며, 이에 관계자 여러분께 감사드립니다.

接受日字: 1997年11月6日, 수정완료일: 1998年10月2日

I. 서 론

디지털 자기기록 시스템과 이동 통신 같은 디지털 통신 시스템 등에서는 전송 데이터의 대용량화와 고속 전송에 따른 채널의 비선형화가 매우 중요한 문제로 대두되고 있다. 최근에 와서 신경망의 비선형 시스템 예로의 적용 예가 날로 증가하고 있으며, 비선형 사상과 관련된 분야에서 탁월한 성능의 향상을 이미 입증하고 있다. 특히 비선형이 강한 위성 채널이나 자기기록 채널에서 신경망은 등화기로 구현되어 월등한 성능의 향상을 나타내고 있다^[1-6].

신경망은 여러 가지 형태 중, 시그모이드 함수를 이용한 다층 퍼셉트론(multi-layer perceptron : MLP) 구조가 대표적으로 사용되고 있으며, 이의 개선을 위한 연구는 계속되고 있다. 신경망을 개선하기 위한 방법은 크게 두 가지로 분류할 수 있다. 하나는 신경망의 구조를 개선하여 더 간단하면서도 필요한 만큼의 성능을 보일 수 있는 방법에 대한 연구이고, 또 다른 하나는 순수하게 신경망의 성능을 개선하기 위한 연구이다. 신경망 구조의 개선은 시스템을 보다 단순화하기 위한 연구로서 학습 알고리듬 등의 향상으로 인한 계산량의 감소와 신경망 구조 자체의 단순화 등으로 분류할 수 있으며, 성능 개선에 대한 연구 역시 신경망의 연결성을 증대시키는 연구와 새로운 활성 함수의 연구 등으로 분류할 수 있다^[2, 7].

본 논문에서는 새로운 활성 함수를 이용한 신경망 등화기를 구현하여 기존의 시그모이드 함수를 이용한 신경망 등화기의 성능과 구조를 개선하고자 한다. 즉, 이차 시그모이드 함수를 이용한 신경망 등화기(quadratic sigmoid neural equalizer : QSNE)와 결정궤환 방식의 이차 시그모이드 신경망 결정궤환 등화기(quadratic sigmoid neural decision feedback equalizer : QSNDFE)를 제안한다. 제안한 등화기는 시그모이드 함수보다 강한 비선형성을 내재적으로 가지고 있는 이차 시그모이드 함수를 이용한다. 또한 QSNDFE는 결정궤환 방식을 취하기 때문에 채널 상에 존재하는 심각한 왜곡에 의한 심벌간의 간섭이나 물리적인 특성으로 야기되는 비선형 왜곡 현상을 기존의 등화기들보다 더욱 효과적으로 보상해 줄 수 있을 것으로 기대된다. 특히 디지털 자기기록 채널과 같은 비선형 왜곡이 심한 환경에서 시그모이드 함수를 이용한 신경망 결정궤환 등화기(neural decision feed-

back equalizer : NDFE)^[1-6, 8]보다 간단한 구조로 향상된 성능을 얻을 수 있을 것으로 기대된다.

디지털 자기기록 시스템의 비선형 왜곡 현상을 모델링하는 방법에는 크게 두 가지가 있다. 한 가지 방법으로는 현재 보편적으로 쓰이는 자기기록 장치의 기록밀도인 1.5와 2.5 사이일 때 가장 정확한 모델링 방법으로 알려진 부분 삭제 모델(partial erasure model)이 있다. 또 다른 방법으로는 천이 이동(transition shift)과 천이 확장(transition broadening)과 같은 demagnetization현상을 모델링하는 방법이다^[9-14].

본 논문에서는 일반적인 통신 채널과 앞에서 언급한 두 가지 자기기록 채널에 QSNDFE를 적용하여 기존의 DFE, NDFE와 비트 오류 확률(BER : bit error ratio or bit error probability) 관점에서 성능을 비교하고자 한다. 본 논문의 구성은 다음과 같다. 2장에서는 기존의 DFE와 NDFE에 대하여 간단히 설명하고, 기존의 시그모이드 함수를 이용한 신경망과 이차 시그모이드 함수를 이용한 신경망의 특성을 비교한다. 또한 이차 시그모이드 함수를 활성 함수로 이용한, 다층 퍼셉트론의 구조의 신경망 등화기를 제안한다. 3장에서 실험에 사용한 통신 채널과 자기기록 채널에 대하여 설명한다. 4장에서 QSNDFE를 통신 채널과 다양한 디지털 자기기록 채널에 적용하여 기존의 등화기들과 성능을 비교 분석한다. 5장에서 결론을 맺는다.

II. 이차 시그모이드 신경망 등화기

이번 장에서는 기존 방식의 등화기로서 DFE와 NDFE에 대하여 알아보고, 이차 시그모이드 함수를 이용한 신경망 등화기를 제안한다.

1. 기존의 등화기

본 논문에서 사용한 일반적인 DFE^[15] 구조는 그림 1 (a)와 같으며, NDFE의 구조^[1, 4, 6, 9]는 그림 1 (b)와 같다. 결정궤환 방식의 등화기 구조를 살펴보면 채널의 재생 신호 열 $\{r_k\}$ 를 입력으로 갖는 TDL(tapped delay line)구조의 버퍼 열이 입력 층을 형성하고, 또 이는 K_1+1 개의 텁을 갖는 전방 필터와 K_2 개의 텁을 갖는 후방 필터 부분으로 구분된다. 따라서 DFE의 입력은 모두 $K_1 + K_2 + 1 = N_0$ 개이다. 입력 층의 전방 필터와 후방 필터는 채널의 재생 신호 열 $\{r_k\}$ 와 채널의 입력 신호 열 $\{a_k\}$ 의 추정 치인 $\{\hat{a}_k\}$

로 채워진다. 출력 층에서는 모두 하나의 템을 갖는다.

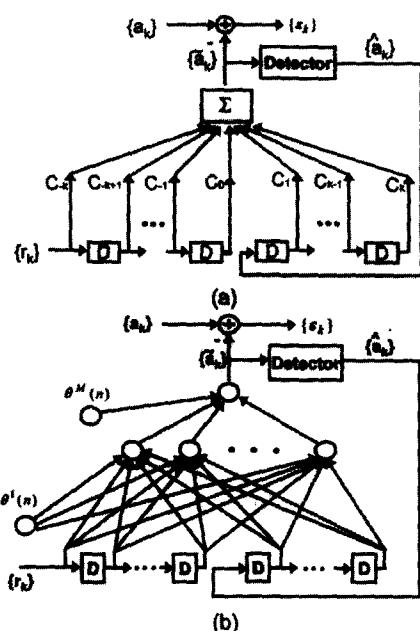


그림 1. 기존의 등화기 (a) 결정궤환 등화기(DFE) (b) 신경망 결정궤환 등화기(NDFE)

Fig. 1. Conventional equalizer (a) Decision Feedback Equalizer (DFE) (b) Neural Decision Feedback Equalizer (NDFE)

또한 그림 1 (b)와 같이 NDFE는 $M-1$ 개의 은닉 층을 추가로 가지며, BP(Back-Propagation) 알고리듬을 이용하여 연결 가중치를 조절한다. NDFE의 출력은 신호 레벨이 $-1, +1$ 의 두 가지이므로 노드의 활성함수는 tanh함수를 사용한다.

2. 이차 시그모이드 신경망 등화기

기존의 신경망은 활성 함수로 시그모이드 함수, tanh함수 또는 그의 변형이 주로 사용된다. 이 논문에서 사용하는 신경망의 활성 함수인 이차 시그모이드 함수의 형태는 다음 식과 같고,

$$f(net, \theta) = \frac{2}{1 + \exp(net^2 - \theta)} - 1, \quad (1)$$

이 함수의 미분 형태는 다음과 같이 원래 함수인 식 (1)의 합과 곱의 형태로 표현 할 수 있다.

$$\frac{df(net, \theta)}{dnet} = -4 net \frac{e^{net^2 - \theta}}{(1 + e^{net^2 - \theta})^2} = -net \{ 1 + f(net, \theta) \} \{ 1 - f(net, \theta) \}, \quad (2)$$

$$\frac{df(net, \theta)}{d\theta} = \frac{2e^{net^2 - \theta}}{(1 + e^{net^2 - \theta})^2} = \frac{1}{2} \{ 1 + f(net, \theta) \} \{ 1 - f(net, \theta) \}, \quad (3)$$

여기서, $net = (w_0^T W X)$ 이며, w_0 와 W, X 는 각각 바이어스, 연결 가중치 벡터, 입력 벡터를 나타낸다. 또 θ 는 각 뉴런의 임계 치로 양의 값을 갖는 인자이다. 임계 치에 따른 이차 시그모이드 함수의 형태는 그림 2와 같다.

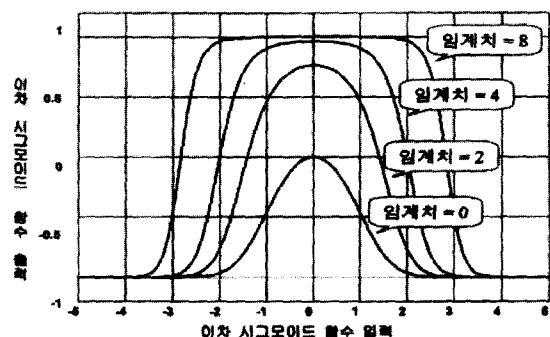


그림 2. 임계 치(θ)의 값에 따른 이차 시그모이드 함수의 형태

Fig. 2. The graphs of quadratic sigmoid function according to various threshold values.

그림 2에서와 같이 임계 치에 따라 이차 시그모이드 함수는 가우시안 함수와 비슷한 형태를 유지하며 계속 변화한다. 함수의 정점은 임계 치가 커짐에 따라 0에서 1까지 증가하며, 1 이상으로는 더 이상 증가하지 않는다. 그리고 임계 치가 증가함에 따라 이차 시그모이드 함수의 폭과 정점의 폭이 넓어지는 모양을 갖는다. 이러한 함수를 활성 함수로 사용하는 신경망의 각 노드(뉴론)는 이차 시그모이드 함수의 정점과 -1 , 두 가지 값으로 각각 수렴한다. 이러한 신경망을 학습시키는 학습 알고리듬 역시 BP 알고리듬과 같은 방법으로 다음과 같이 유도할 수 있다^[7, 9].

연결 가중치 조절식 :

$$w_k^s(n+1) = w_k^s(n) + \alpha_1 G_k^s(n) + \beta_1 \Delta w_k^s(n-1), \quad (4)$$

$$\text{where } \delta_k^s(n) = \begin{cases} (d_k(n) - o_k^s(n))f'(net_k^s(n), \theta_k^s(n)) & s=M \\ f'(net_k^s(n), \theta_k^s(n)) \sum_{i=1}^{N_{k+1}} \delta_i^{(s+1)} w_{ik}^{s+1} & s=1, \dots, M-1 \end{cases}$$

$$(5)$$

임계 치 조절식 :

$$\theta_k^s(n+1) = \theta_k^s(n) + \alpha_2 Q_k^s(n) + \beta_2 \Delta \theta_k^s(n-1), \quad (6)$$

$$\text{where } \gamma_k^s(n) = \begin{cases} (d_k(n) - o_k^s(n))f'_k(\text{net}_k^s(n), \theta_k^s(n)) & s=M \\ f'_k(\text{net}_k^s(n), \theta_k^s(n)) \sum_{i=1}^{M-1} \gamma_i^{(s+1)} w_{ik}^{s+1} & s=1, \dots, M-1 \end{cases}$$

(7)

여기서, α_1, α_2 는 각각 연결 가중치와 임계 치의 학습 계수, β_1, β_2 는 연결가중치와 임계 치의 모멘텀 계수이다. 그리고, $\Delta w_{kj}^s(n-1)$ 은 $w_{kj}^s(n)$ 과 $w_{kj}^s(n-1)$ 사이의 차로 연결 가중치의 모멘텀이며, $\Delta \theta_k^s(n-1)$ 은 $\theta_k^s(n)$ 과 $\theta_k^s(n-1)$ 사이의 차로 임계 치의 모멘텀을 나타낸다. 이들 모멘텀들은 수렴 속도를 향상시키는 역할을 한다. 또, $f'(\cdot)$ 는 이차 시그모이드 함수 $f(\cdot)$ 를 $w_{kj}^s(n)$ 로 편 미분한 함수로서 시그모이드 함수를 사용하는 경우처럼, 식 (1)의 원 함수 $f(\cdot)$ 의 합과 곱으로 간단히 대치되어 미분을 대신함으로서 계산 양을 상당히 줄일 수 있다. 시그모이드 함수를 이용한 신경망에서와 마찬가지로 연결 가중치들은 $[-0.5, 0.5]$ 사이의 값을 이용하여 각각 임의로 초기화시키며, 임계치들은 $[0, 4]$ 사이의 임의 값을 이용하여 초기화시킴으로써 수렴 속도의 향상을 가질 수 있다.

이차 시그모이드 함수를 이용한 신경망이 결정 영역을 어떻게 분할하는지를 알아보면 다음과 같다. 신경망의 학습 단계가 완전히 끝난 후, 신경망의 각 뉴론은 임계 치에 따른 포물선의 정점 값과 -1로 수렴되며, 선형방정식을 풀면 다음과 같다.

$$\begin{aligned} \text{If } \mathbf{W}'\mathbf{X} < -\sqrt{\theta} \text{ and } \mathbf{W}'\mathbf{X} \geq +\sqrt{\theta}, \text{ then } \mathbf{X} \in \text{Class 1} \\ \text{If } -\sqrt{\theta} \leq \mathbf{W}'\mathbf{X} < +\sqrt{\theta}, \text{ then } \mathbf{X} \in \text{Class 2}. \end{aligned} \quad (8)$$

즉, 일반적인 시그모이드 함수를 이용한 신경망에서는 각각의 뉴론이 평면을 하나의 직선으로 분할하며, 이러한 직선의 조합을 이용하여 결정 영역을 분할한다. 이와 달리 이차 시그모이드 함수를 이용한 신경망은 하나의 뉴론이 평행한 두 개의 직선을 가지고 평행선 내부와 외부의 두 부분으로 평면을 분할하며, 이러한 평행선의 조합으로 결정 영역을 분할한다.

그림 3에 QSNDFE의 구조를 나타내었다. 그림 3의 QSNDFE를 살펴보면 채널의 출력 신호 열 $\{r_k\}$ 와 신경망 등화기의 출력의 결정궤환 값을 입력으로 갖는 TDL구조의 버퍼 열이 신경망의 입력 층을 형성하고, $M-1$ 개의 은닉 층과 하나의 노드를 갖는 출력 층을 포함한다. 입력 층의 전방 필터와 후방 필터는 채널의 출력 신호 열 $\{r_k\}$ 와 채널의 입력 신호 열 $\{a_k\}$ 의 추

정 치인 $\{\hat{a}_k\}$ 가 결정 궤환되어 각각 채워진다. 또 은닉 층에는 이차 시그모이드 함수를 출력 층에는 선형 함수를 신경망의 노드 활성 함수로 사용한다.

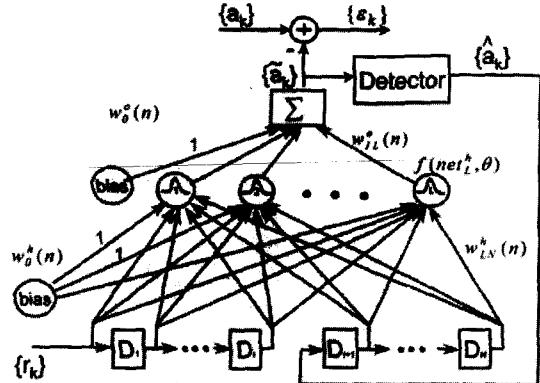


그림 3. 이차 시그모이드 신경망 결정궤환 등화기 (QSNDFE)의 구조

Fig. 3. The structure of Quadratic Sigmoid Neural Decision Feedback Equalizer (QSNDFE).

III. 통신 채널과 디지털 자기기록 채널

1. 디지털 통신 채널

이 절에서는 그림 3의 이차 시그모이드 신경망 결정궤환 등화기를 디지털 통신 시스템에 적용한다. 실험에 사용하는 채널의 전달함수를 표 1에 나타내었다. 채널 B는 고주파 영역에 골(NULL)이 있는 채널이며, 채널 C는 대역의 중간에 심한 골(NULL)이 있는 채널이다^[14]. 그리고 채널 S는 참고 문헌 [15]에서 사용한 것과 같은 방법으로 채널 B에 비선형 왜곡을 인위적으로 첨가한 채널이다. 그림 4에 채널 B와 S, C의 크기에 대하여 정규화한 주파수 스펙트럼의 형태를 나타내었다^[14].

표 1. 디지털 통신 시스템 실험에 사용한 채널의 전달함수

Table 1. Channel transfer functions in simulations of digital communication systems.

채널	채널 전달 함수(Z변환 함수)
B	$0.407 + 0.815z^{-1} + 0.407z^{-2}$
C	$0.227 + 0.460z^{-1} + 0.688z^{-2} + 0.460z^{-3} + 0.227z^{-4}$
S	$0.407 + 0.815z^{-1} + 0.407z^{-2};$ $y(t) = x(t) + 0.2x^2(t) - 0.1x^3(t),$ 여기서 $x(t)$ 는 채널 출력

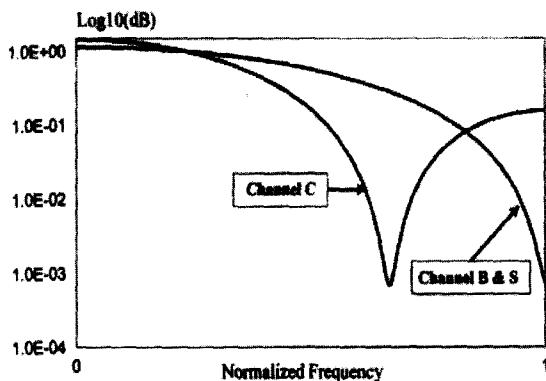


그림 4. 채널 B, S, C의 크기 스펙트럼

Fig. 4. Amplitude spectra for the channels B, S and C.

2. 선형 자기기록 채널

이상적인 기록 재생 환경을 고려할 때 디지털 자기기록 장치의 재생신호는 일반적으로 저장매체에 기록된 고립 자화 천이 응답(isolated magnetic transition response)의 선형 중첩으로 표현된다. 자성체의 히스테리시스특성 때문에 일반적으로 디지털 자기기록 장치에서는 포화 기록(saturation recording) 방식을 사용한다^[11, 12]. 포화 기록 방식으로 기록된 정보는 자계의 미분 특성으로 인해 재생 헤드에 의해 자화의 방향이 아닌 자화의 천이(magnetic transition)가 재생 신호로 읽힌다. 자기기록 장치의 고립 자화 방향 천이는 다음의 로렌즈 필스로 모델링된다^[4-6, 9, 11-13].

$$h(t) = \frac{1}{1 + (\frac{2t}{PW50})^2}, \quad (9)$$

또 기록된 양 또는 음의 필스는 $g(t) = h(t) - h(t-T)$ 로 모델링된다. 식(9)에서 PW50은 $h(t)$ 의 크기가 첨두 치의 1/2되는 위치의 필스 폭을 나타내고, T 는 연속된 두 심벌 사이의 시간 간격이다. 또한 PW50을 사용하여 자기기록 장치의 기록 밀도를 나타내기도 한다. 즉 본 논문에서는 $Density = PW50/T$ 를 기록 밀도의 척도로 사용한다.

3. 비선형 자기기록 채널의 모델링

디지털 자기기록 장치의 기록 밀도가 커지면 인접 심벌에 의한 간섭이 커지고 비선형적인 현상이 나타난다. 이 때문에 이상적인 스텝 응답의 선형 중첩을 사용하여 신호의 입출력 관계를 나타난 식은 정확도가 떨어지게 된다^[11-13]. 디지털 자기기록 장치에서 비선

형적인 특성을 표현하는 방법 중 대표적인 것은 비선형 자화 방향 천이 이동 현상과 자화 방향 천이 확장 현상이다. 이러한 비선형 왜곡은 일반적으로 demagnetization 현상으로 해석한다^[11-13]. 이러한 비선형 왜곡 현상을 하나의 식으로 나타내면 다음과 같다.

$$r(t) = \sum_{k=0}^{\infty} \frac{1}{2} (a_k - a_{k-1}) h(t - kT + u(a_k, \varepsilon), \quad (10) \\ PW50 + w(a_k, \Delta PW50)) + n(t).$$

여기서 a_k 는 입력 신호 열 벡터이고, ε 은 자화 천이 현상에 따른 이동의 크기를 나타내는 값이다. 그리고 이 두 벡터를 포함하는 식 $u(a_k, \varepsilon)$ 로 전체적인 자화 방향 천이 이동 현상의 정도가 표현된다. 또한 천이 확장 현상은 demagnetization 필드가 현재의 자화 방향 천이의 변화율에 영향을 주게 되어 생기는 현상으로 자기 매체에 자화 방향의 변화로 기록된 정보는 자기 헤드에 의해 그 자화 방향의 변화율이 재생된다. 식 (10)에서 $\Delta PW50$ 은 확장의 정도를 나타내는 값이며, 이를 포함하는 식인 $w(a_k, \Delta PW50)$ 로 전체적인 자화 방향 천이 확장 현상의 정도가 표현된다^[4-6, 9-13].

4. 부분 삭제 모델

포화 기록의 특성으로 인해 자기기록 채널은 두 레벨(± 1) 값인 a_k 는 자기기록 채널의 입력으로 사용되는 쌍극(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 γ 를 곱해주어 채널의 비선형성을 나타낸다. 이 때, γ 는 현재의 심벌을 기준으로 앞·뒤에 천이가 있는지 즉, b_k 가 ± 1 인지 아닌지에 따라 정해진다^[3, 6, 9].

IV. 실험 결과

이번 장에서는 QSNDFE를 통신 시스템과 디지털 자기기록 시스템에 적용, BER (Bit Error Ratio) 관점에서 성능을 비교, 분석한다.

1. 디지털 통신시스템에서의 QSNDFE

본 논문에서는 결정제환 방식인 DFE와 NDFE, 그리고 제안한 QSNDFE를 비교하여 등화기의 성능을 BER 관점에서 비교, 분석하고자 한다. 실험에 쓰인

NDFE의 구조는 그림 1 (b)와 같으며, LMS(Least Mean Square) 알고리듬을 사용하는 DFE의 구조는 그림 1 (a)와 같다.

실험에 쓰인 각 등화기의 텁 수 및 학습 계수 등을 표 2에 나타내었다. 실험에서 쓰인 노드의 수는 DFE가 전방 텁 16개, 후방 텁 15개로 모두 31개이며, NDFE는 입력 층에서 전방 텁 6개, 후방 텁 5개로 모두 11개, 은닉 층에서 11개가 사용되었다. 또한 QSNDFE는 입력 층에서 전방 텁 3개, 후방 텁 2개로 모두 5개를 사용하였고, 은닉 층에서는 9개의 노드를 사용하여 실험하였다. 출력 층에서는 모두 1개의 노드를 사용하였다. 학습 계수는 DFE가 0.01, NDFE와 QSNDFE는 0.1을 각각 사용하였고, 모멘텀 계수는 NDFE가 0.4, QSNDFE는 0.1을 사용하였다. 실험에 쓰인 노드 수와 학습 계수 등은 모두 최적의 BER을 얻기 위해, 여러 차례의 반복적인 실험에 의하여 결정하였다.

표 2. 디지털 통신 시스템의 실험에 쓰인 등화기 텁 수와 학습 계수

Table 2. The number of taps and learning rate of equalizers in simulations of digital communication systems

등화기	DFE	NDFE	QSNDFE
학습 계수	0.01	0.1 Momentum : 0.4	0.1 Momentum : 0.1
노드 수	31	입력 : 11 은닉 : 11	입력 : 5 은닉 : 9

그림 5는 채널 B와 C 그리고 채널 B에 비선형 왜곡을 가한 디지털 통신 채널에 DFE, NDFE, 그리고 QSNDFE를 각각 적용하여 얻은 비트 오류 확률 곡선이다. 채널 B의 경우에 일반적으로 통신에서 요구하는 10^{-5} 의 오차율을 기준으로 하여 10^{-5} 에 도달하는 SNR을 관찰하면, DFE의 경우에는 약 18.6dB에서 10^{-5} 의 오차율을 얻었으며, NDFE는 약 17.8dB에서 10^{-5} 의 오차율을 얻었다. 제안한 QSNDFE는 약 17.3dB 정도의 SNR이 요구되어, DFE보다는 약 1.3dB, NDFE보다는 약 0.5dB 정도의 성능 개선을 얻을 수 있었다. 채널 C에 DFE, NDFE 그리고 QSNDFE를 적용하여 얻은 BER 곡선의 경우를 살펴보자. 역시 QSNDFE가 NDFE보다 적은 수의 노드

로서 가장 우수한 BER 성능을 나타내며, 신경망을 이용한 등화기들이 일반적인 결정체환 등화기보다 우수함을 알 수 있다. 채널 B에 비선형 왜곡 현상을 주어 실험을 한 경우의 BER 그래프를 보면, DFE는 전혀 등화기로서 동작을 하지 못하며, NDFE는 약 19.7dB에서 10^{-5} 의 오차율을 얻었다. 제안한 QSNDFE는 약 19.2dB 정도의 SNR이 요구되었다. 여기서도 제안한 QSNDFE가 NDFE보다 약 0.5dB 정도의 성능 개선을 얻을 수 있다.

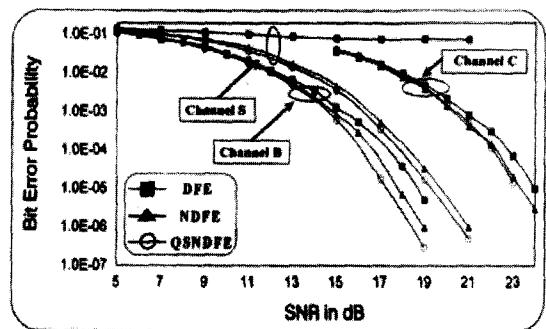


그림 5. 채널 B, C, S에서의 등화기 BER 곡선

DFE : 결정체환 등화기

NDFE : 신경망 결정체환 등화기

QSNDFE : 이차 시그모이드 신경망 결정체환 등화기

Fig. 5. BER graphs of equalizers for channel B, C and S

DFE : Decision Feedback Equalizer

NDFE : Neural Decision Feedback Equalizer

QSNDFE : Quadratic Sigmoid Neural Decision Feedback Equalizer

실험 결과 신경망을 이용한 결정체환 등화기들이 일반적인 결정체환 등화기보다 우수함을 알 수 있다. 또한 QSNDFE는 입력 노드 수에서는 6개, 은닉 노드 수에서는 2개가 적음에도, NDFE보다 우수한 성능을 확인할 수 있다. 신경망 등화기들을 통신 채널에서 실험을 하였을 때 심벌간의 간섭만의 제거 면에 있어서는 그리 주목할 만한 성능의 향상은 나타내지 못했다. 하지만 비선형 왜곡 현상이 있는 상태에서 우세한 성능의 향상을 보인다.

2. Demagnetization 현상에 의한 채널 모델에서의 QSNDFE

이 절에서는 비선형 자기기록 채널에 대한 등화기

성능을 비교 분석한다. 자기기록 채널에서 기록 밀도가 증가하면 디지털 자기기록 장치에서 재생된 신호는 심벌간 간섭과 비선형 왜곡에 점점 더 많은 영향을 받게 된다. 여기서는 density = 2.5, 3.0일 때 비선형 자기기록 채널에서의 각 등화기 성능을 BER 관점에서 비교한다.

표 3은 실험에 사용한 각각의 디지털 자기기록 채널의 기록 밀도에 따른 비선형 자화 방향 천이 이동 계수($\varepsilon_1, \varepsilon_2$)와 자화 방향 천이 확장 계수($\Delta PW50$)를 보여준다. 비선형 자화 방향 계수 중 ε_2 는 그 영향이 적고 또 기록 매체가 임의로 자화되어 있을 경우 잡음으로 간주되기 때문에 실험에서는 사용하지 않았다. 등화기의 텁 수와 등화기 학습 계수 등의 실험 인자들은 가장 안정적이며, 최상의 BER 결과를 얻을 수 있는 값들을 여러 차례 반복적인 실험을 통하여 구하였다. 모든 실험에서 결정궤환 등화기의 학습 계수는 0.007이 사용되었고, BP 알고리듬을 사용하는 NDDE는 학습 계수 0.007, 모멘텀 계수는 0.4를 사용하였다. 또한 QSNDDE는 연결 가중치 학습 계수, 임계 치 학습 계수 모두 0.07을 사용하였고, 모멘텀 계수는 0.1을 사용하였으며, 적응 적인 학습 계수 알고리듬을 이용하였다. 그리고 각 실험에서 임의의 10^6 개의 실험 표본을 사용하였다.

표 3. 비선형 자기기록 채널의 실험에 사용한 비선형 계수 및 텁 수

Table 3. The nonlinear factor and the number of taps of equalizers in simulations of nonlinear magnetic recording channels.

기록 밀도	등화기	DFE	NDDE	QSNDDE
2.5	비선형 계수	$\varepsilon_1 = 0.275, \varepsilon_2 = 0.0625, \Delta PW50 = 0.1$		
	등화기 텁 수	27	입력 : 29 온닉 : 27	입력 : 17 온닉 : 24
3.0	비선형 계수	$\varepsilon_1 = 0.33, \varepsilon_2 = 0.075, \Delta PW50 = 0.12$		
	등화기 텁 수	31	입력 : 29 온닉 : 27	입력 : 17 온닉 : 27

그림 6에는 밀도 2.5와 3.0인 자기기록 채널에서의 BER 성능곡선을 나타내었다. 자기기록 밀도 2.5인 경우를 먼저 보면, DFE는 19.5dB정도에서 기록장치의 요구 값인 10^{-4} 의 오차율을 얻는데 비해, NDDE는

19dB정도에서 10^{-4} 의 오차율을 얻는다. 제안한 QSNDDE는 17dB에서 10^{-4} 의 오차율을 얻는다. QSNDDE가 DFE에 비해서는 2.5dB, NDDE에 비해서는 2dB정도의 SNR 이득을 얻음을 알 수 있다. 밀도 2.5인 경우에서 제안한 등화기는 가장 우수한 오차율 성능을 나타내었다. 밀도 3.0인 경우에는 밀도가 증가하여 비선형성이 증가하자 신경망을 이용한 등화기들의 성능이 기존의 DFE에 비해 더욱 향상됨을 볼 수 있다. DFE는 30dB정도에서 10^{-4} 의 오차율의 수렴에 성공하는데 비해 NDDE는 약 25dB에 수렴시키며, 제안한 QSNDDE는 21.7dB에서 10^{-4} 의 오차율을 얻을 수 있다. 밀도 2.5에서 DFE와 NDDE는 0.5dB정도의 SNR 성능 차이를 보였는데 비해, 밀도가 증가하여 채널의 비선형성이 증가함에 따라, SNR 차이가 5dB로 크게 증가하였다. QSNDDE와 NDDE의 성능 차이도 증가하여, 3.3dB정도의 SNR 차이를 나타내었고, DFE와는 8.3dB의 성능 차이를 나타내었다.

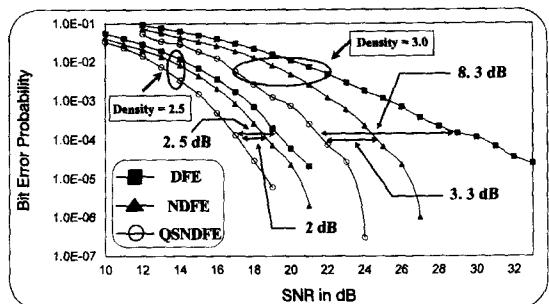


그림 6. 밀도 2.5, 3.0인 비선형 자기기록 채널에서의 등화기 BER 곡선

Fig. 6. BER graphs of equalizers for nonlinear magnetic recording channel with density 2.5 and 3.0.

결론적으로 밀도의 증가에 따른 채널의 비선형 왜곡 현상의 심화로 인해, DFE와 신경망 등화기와의 성능 차이가 커졌다. 그리고 NDDE와 제안한 QSNDDE와의 성능 차이도 커졌다. 이러한 차이는 신경망 등화기가 DFE에 비해 비선형 왜곡에 강하다는 사실을 나타내며, QSNDDE는 구조의 특성상 이차 시그모이드 활성 함수의 비선형성이 기존의 시그모이드 함수보다 강함으로써 기존의 MLP를 이용한 등화기보다 채널의 심벌간의 간섭 현상과 비선형 왜곡 현상을 효율적으로 보상해 줌을 나타낸다.

실험에 사용되었던 DFE, NDFE와 QSNDFE의 구조 복잡도 측면을 BER 성능과 함께 살펴보자. 실험에 쓰인 각 등화기의 학습 계수와 노드 수는 여러 번의 실험을 통하여 최적의 실험 결과를 나타내는 것을 선택하였다. 표 3에 정리했던 대로 DFE는 밀도가 2.5일 때 전방 14개, 후방 13개로 27개의 입력 노드를, 밀도가 3.0일 때는 전방 16개, 후방 15개로 31개의 입력 노드를 사용했다. 이에 비해, NDFE는 밀도가 2.5, 3.0일 때 전방 15개, 후방 14개로 모두 29개의 입력 노드를 사용하였고, 은닉 노드로 27개를 사용하였다. DFE에 비해 오차율 성능에서는 향상이 있지만, 구조가 복잡해짐을 알 수 있다. QSNDFE는 밀도가 2.5일 때 전방 9개, 후방 8개로 17개의 입력 노드와 24개의 은닉 노드가 사용되었고, 밀도가 3.0일 때 전방 9개, 후방 8개로 17개의 입력 노드와 27개의 은닉 노드가 사용되었다. 즉 QSNDFE는 NDFE보다 적은 노드의 수로 모든 밀도에서 우수한 BER 성능을 보인다.

3. 부분 삭제 모델에서의 QSNDFE

이번에는 자기 기록 장치의 모델 방법 중 밀도가 2.0인 부분 삭제 모델에 QSNDFE를 적용하여 성능을 BER 관점에서 DFE, NDFE와 비교, 분석한다.

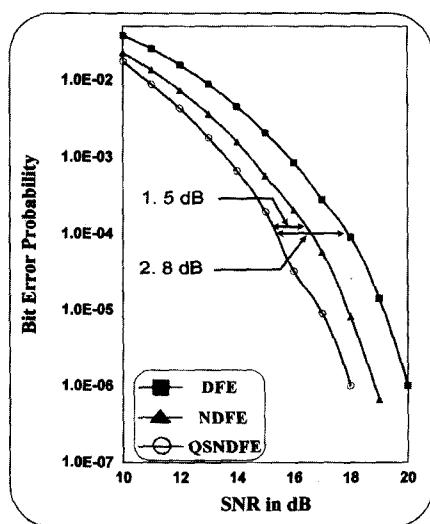


그림 7. 밀도 2.0인 부분 삭제 모델에서의 등화기 BER 곡선

Fig. 7. BER graphs of equalizers for partial erasure model with density 2.0.

밀도가 2.0인 부분 삭제 모델은 부분 삭제 감쇠 인자 $\alpha = 0.7$ 이다. 이는 현재 심벌의 앞뒤에 천이가 모

두 존재하면, 천이가 존재하지 않을 때보다, 다시 말하면, 비선형 왜곡이 존재하지 않을 때의 심벌 크기보다 약 절반으로 크기가 줄어들게 된다. 또 심벌의 앞, 뒤 중에 한 쪽에만 천이가 존재하면, 원래 심벌의 약 1/3 정도 크기가 줄어들게 된다. 그럼 7은 밀도가 2.0인 부분 삭제 모델에서의 DFE, NDFE, 그리고 QSNDFE의 BER 곡선이다.

실험에서 쓰인 노드의 수는 DFE가 입력으로 전방 노드 9개, 후방 노드 8개로 모두 17개이며, NDFE가 입력 층에 전방 노드 13개, 후방 노드 12개로 모두 25개, 은닉 층에 11의 노드가 사용되었으며, 출력 층에서는 모두 1개씩의 노드를 사용했다. 또한 QSNDFE는 입력 층에서 전방 노드 7개, 후방 노드 6개로 모두 13개를 사용하였고, 은닉 층에서 15개의 노드를 사용하여 실험하였다. 학습 계수는 DFE가 0.01을 사용하였고, NDFE와 QSNDFE는 0.1, 모멘텀 계수는 NDFE가 0.4, QSNDFE는 0.1을 사용하였다. NDFE와 QSNDFE 모두 빠른 수렴과 안정적인 학습을 위해 점차 학습 계수를 감소시켜 가는 적응 적인 학습 계수 알고리듬을 이용하였다.

DVCR(Digital Video Recording Systems) 시스템에서 요구하는 $BER = 10^{-4}$ 을 얻기 위하여 DFE는 18dB의 SNR이 필요하며, NDFE는 16.7dB 정도의 SNR이 필요하다. 이에 비해 제안한 QSNDFE는 15.2dB 정도에서 10^{-4} 의 BER을 얻었다. 즉, QSNDFE는 DFE에 비해 2.8dB정도 이득을 얻을 수 있었으며, NDFE에 비해 8개의 노드 수가 적음에도 불구하고 1.5dB정도의 SNR 이득을 얻을 수 있었다.

결론적으로 제안한 QSNDFE는 이차 시그모이드 함수를 신경망의 활성 함수로 이용하였기 때문에 채널의 비선형 왜곡에 보다 강하며, 기존의 시그모이드 함수를 이용한 MLP 구조의 신경망 등화기보다 더 적은 수의 노드를 사용하여 구조가 간단하면서도 좋은 BER 성능을 얻을 수 있음을 확인하였다. 이는 일반적인 시그모이드 함수를 사용하는 신경망 등화기에서 개개의 뉴론이 결정 영역을 직선으로 양분하여 영역을 분리하는 것과는 달리 이차 시그모이드 함수를 사용하는 신경망 등화기에서는 학습이 진행되어 감에 따라 개개의 뉴론이 포물선의 내부와 외부로 영역을 분리하며, 학습이 완전히 수행된 후에는 평행한 직선 두 개로 영역을 분리하기 때문에 보다 비선형 왜곡 현상에 강해진 구조를 갖고, 또한 보다 복잡한 구조를 분리할

수 있다.

V. 결 론

본 논문에서 제안하는 QSNDFE는 심벌간의 간섭이나 비선형 왜곡에 의해 심하게 손상된 신호에 대한 보상 능력이 기존의 등화기들에 비해 현저히 우수하며, 구조적으로도 기존의 신경망 등화기에 비해 간단해 진다는 사실을 알 수 있었다.

통신 채널에서 실험한 결과, QSNDFE는 기존의 NDFE보다 간단한 구조로 우세한 성능을 나타내었다. 또한 비선형 왜곡이 심한 자기기록 채널 환경에서 실험한 결과, QSNDFE는 DFE는 물론 일반적인 시그 모이드 함수를 활성 함수로 사용한 다중 퍼셉트론 구조의 NDFE보다도 자기기록 채널의 기록 밀도가 높아짐에 따라 1.5~3.3dB 정도의 우수한 오차율 성능을 나타내었다. 그러면서도 구조의 복잡도는 오히려 NDFE에 비해 비교적 간단한 구조를 갖는다는 장점을 보여주었다. 즉, 제안한 QSNDFE가 신경망을 이용하여 비선형 왜곡이나 심벌간의 간섭으로 심하게 왜곡된 신호의 복원에 적합하며, 동시에 보다 강한 활성 함수의 비선형성으로 인하여 구조가 간단하다는 장점을 갖는다.

향후 연구 과제로는 실질적인 많은 통신 시스템에의 적용을 위해 결정궤환 등화기들과의 MSE 수렴 과정 상에서의 차이에 대한 수식적인 비교와 함께, 다단계에 적합한 활성 함수와 복소수 신호에 대한 활성 함수의 연구가 필요하다. 또한 학습되어야 할 인자가 동시에 두 개이어서 학습 자체가 불안정할 때가 존재하는 데, 이를 극복할 수 있는 일반적인 방안에 대한 연구가 필요하다. 그리고 Digital Signal Processor (DSP) 칩을 이용하여 제안한 QSNDFE의 효율적인 하드웨어 구현에 대한 연구가 필요하다.

참 고 문 현

- [1] 조재희, “디지털 자기 기록 장치에서의 신경망을 이용한 등화기 연구,” 연세대학교 석사 학위 논문, 1995
- [2] 옹성환 “결정궤환 재구 신경망 등화기에 대한 연구”, 연세대학교 석사 학위 논문, 1996
- [3] 최수용, 옹성환, 조재희, 유철우, 강창언, 홍대식, “부분 삭제 모델로 나타난 비선형 자기 기록 장치에서의 신경망 등화 기법,” 제5회 인공지능, 신경망 및 퍼지시스템 종합 학술대회 논문집, pp. 280-283, 1996
- [4] S. Y. Choi, S. H. Ong, J. H. Cho, C. W. You and D. S. Hong, “Performance of Neural Equalizers on Partial Erasure Model,” INTERMAG '97, CR10, Apr., 1997.
- [5] 조 재희, 이 종화, 강 창언, 홍 대식, “디지털 자기기록 장치에서의 신경망을 이용한 등화기 연구,” 대한전자공학회 논문지, 제 33권, B편, 6호, pp. 164-175, 1996
- [6] Sooyong Choi, Sunghwan Ong, Jaehhee Cho, Cheolwoo You and Daesik Hong, “Performance of Neural Equalizers on Partial Erasure Model,” IEEE Trans. Magn. vol. 33, no. 5, pp. 2788-2790, Sept. 1997.
- [7] C. C. Chiang and H. C. Fu, “A variant of second-order multilayer perceptron and its application to function approximations,” in IJCNN '92, Baltimore, MD, pp. III:88 7-892, 1992.
- [8] 권 성락, 이 영조, 강 성철, 강 창언, 홍 대식, “역 전파 알고리듬을 이용한 다계층 퍼셉트론 구조의 결정 궤환 등화기,” 대한전자공학회 논문지, 제 33권, B편, pp. 1-9, 1996
- [9] 최수용, “디지털 자기 기록 장치에서의 신경망을 이용한 등화기 연구,” 연세대학교 석사 학위 논문, 1995
- [10] John M. Cioffi, William L. Abbott, Hemant K. Thaper, C. Michael Melas and Kevin D. Fisher, “Adaptive Equalization in Magnetic-disk Storage Channels”, IEEE Communication Magazine, vol. 28, no. 2, pp. 14-29. Feb. 1990.
- [11] Nicholas P. Sands, Nonlinear Intersymbol Interference in Digital Magnetic Recording, 박사 학위 논문, 1993
- [12] Inkyu Lee, Takashi Yamauchi and John M. Cioffi, “Performance Comparison of Recovers in a simple Partial Erasure Model”, IEEE Trans. Magn., vol. 30. pp. 1465-1469, July, 1994.
- [13] R. D. Barndt, A. J. Armstrong, H.

- N.Bertram, and J. K. Wolf, "A Simple Statistical Model of Partial Erasure in Thin Film Disk Recording Systems", IEEE Trans. Magn. vol. 27, no. 6, pp. 4978-4980, Nov. 1991.
- [14] John G. Proakis, Digital Communication, 3th edition, McGraw-Hill, 1995.
- [15] Sheng Chen, Bernard Mulgrew, and Peter M. Grant, "A Clustering Techniques for Digital Communications Channel Equalization Using Radial Basis Function Networks", IEEE Trans. on Neural Networks, vol. 4, no. 4, July, 1993.

저자소개

崔洙龍(正會員) 第36卷, S編, 第12號 參照

崔成煥(正會員) 第34卷, S編, 第9號 參照

劉哲雨(正會員) 第34卷, S編, 第9號 參照

洪大植(正會員) 第34卷, S編, 第9號 參照