

경쟁 학습을 갖는 Radial Basis Function Networks 결정 제한 등화기

서창우*, 허창원*, 강영태*, 이기용**, 하판봉*

*창원대학교 전자공학과

**숭실대학교 정보통신과

Radial Basis Function Networks Decision Feedback Equalizer with Competitive Learning

ChangWoo Seo*, ChangWon Heo*, YeongTae Kang*, KiYong Lee**, PanBong Ha*

*Dept. of Electronics Engineering, Changwon University

**Dept. of Information and Telecommunications Engineering, Soongsil University

<요약>

본 논문에서는 Bayesian 결정 이론을 이용한 기존의 Radial Basis Function Networks 이되는 출력층에서 선형 조합되는 것과는 다른 형태의 방법을 제안하고자 한다. 제안하고자 하는 방법은 은닉층의 출력값과 가중치와의 곱해진 값이 출력층의 입력으로 들어오는데 이들 입력신호를 경쟁을 통하여 가장 큰 값을 출력신호로 인정하는 방법이다. 이런 경우에 파라미터 갱신을 할 때도 모든 가중치를 다 갱신하는 것이 아니라 출력되는 은닉층에 연결된 가중치만을 갱신하게 된다. 이렇게 할 경우 계산량 감소뿐만 아니라 학습시간을 단축할 수 있다는 장점이 있다. 그리고 제안한 방법을 이용할 경우 비선형 분류 문제에서도 우수한 성능 결과를 확인할 수 있었으며, 기존의 RBFN과 Wiener Filter와 성능을 비교하였다.

I. 서론

많은 디지털 통신 채널은 심볼간 간섭 (intersymbol interference : ISI)에 영향을 받으며 부가 잡음원을 갖는 FIR 필터로 특성화된다[1,2]. 수신기에서 심볼간 간섭 (ISI)은 전송된 심볼을 복원하기 위해서 보상되어야만 하는데, 이것이 채널 등화의 임무이다. 송신기 필터, 전송 매개물, 그리고 수신기 필터간의 콘볼루션이 일어나는 채널은 다음과 같은 전달함수를 갖는 FIR 필터로 모델될 수 있다.

$$H(z) = \sum_{i=0}^{n_s-1} a_i z^{-i} \quad (1)$$

여기서 n_s 는 채널 임펄스 응답의 길이가 된다. 기본적으로 채널 등화에는 열 추정 (sequence estimation)과 심볼 결정 등화기 (symbol-decision equalizer)의 두 가지 접근 방법이 있다. 열 추정 등화기로는 모든 전송된 심볼의 최대 근사화 검출 (maximum likelihood detection)의 이론을 기본으로 하는 MLSE

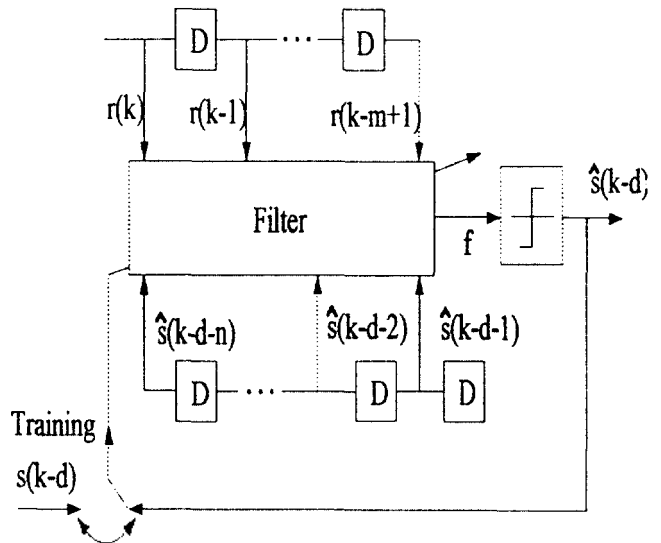


그림 1. 일반적인 결정 제한 등화기 (DFE)의 구조

는 어떤 등화기보다 우수한 성능을 제공하지만 계산량이 많다는 단점이 있다. 반면에 심볼 결정 등화로 잘 알려진 구조는 TE (transversal equalizer)와 DFE (decision feedback equalizer)가 있다. 일반적인 선형 TE는 구조가 간단하고 계산량이 적다는 장점이 있지만 심각한 심볼간 간섭 (ISI)이 존재하는 채널의 경우에는 다소 성능이 떨어지는 단점이 있다. 이런 선형 TE에 등화 성능을 향상시키기 위한 강력한 기법이 결정 제한 (DF)을 적용하는 것이다[1]. DFE는 비선형 등화기로 선형 등화기보다 우수하며 수신된 심볼의 결정치를 제한시켜 검출될 심볼의 ISI를 없앤다. 일반적인 DFE의 구조는 그림 1과 같으며, 여기서 m , n , 그리고 d 는 각각 등화기 순방향 차수, 역방향 차수, 그리고 결정 지연이다. 이런 구조는 과거에 검출된 심볼을 포함하기 위해 TE의 입력을 확장함으로써 얻어진다. 본 논문에서는 최근 연구 결과가 활발히 보고되고 있는 신경망

(Neural Networks)을 이런 DFE에 적용하고자 한다. 신경망중에서, 특히 Multilayer Perceptron (MLP)과 RBF를 이용하여 채널에서의 왜곡된 신호를 보정하는 문제를 해결하는데 있어서 좋은 연구 결과가 나왔다. 그러나 MLP는 높은 비선형 파라메타 구조로 인한 느린 학습 시간과 학습 자체가 실패하는 경우 때문에 실제적인 응용에서 다소 어려움이 있다. 이와는 달리 선형 파라메타 구조를 가지며 효과적인 학습으로 빠른 수렴과 좋은 결과를 얻을 수 있는 RBFN[5,6,7]이 많이 이용된다. 본 논문에서 제안하고자 하는 방법은 기존의 RBFN이 출력층에서 선형 조합되는 구조를 갖는 것과는 달리, 경쟁을 하여서 가장 큰 값을 갖는 것을 출력값으로 인정하는 방법이다. 이런 경우에 있어서 파라미터를 갱신할 때 모든 파라미터를 갱신하는 것이 아니라 출력되는 은닉층에 연결된 가중치만을 갱신하므로 계산량 감소뿐만 아니라 빠른 학습 시간을 갖는 잇점이 있다. 논문의 구성은 다음과 같다. 먼저 II장에서는 제안한 경쟁학습을 갖는 RBFN의 구조를 설명하며, 다음 III장에서는 학습 알고리즘과 지도 clustering 알고리즘을 설명한다. 그리고 IV장에서는 시스템 모의 실험 결과를 제시하고, 이 결과를 기존의 RBF, Wiener Filter와 비교하며, 마지막 V장에서는 결론과 앞으로의 방향에 대해서 논의한다.

II. 경쟁 학습을 갖는 Radial Basis Function Networks의 구조

RBF는 그 함수의 중심, 즉 센터에서 가장 큰 값을 갖고 센터에서 멀어질수록 0으로 단조감소(monotonically decreasing)하는 함수로 센터를 고정하므로서 파라미터는 선형이 되며 그리고 은닉층은 비선형성을 갖는 2층 네트워크이다[8]. RBFN의 구조는 그림 2와 같이 네트워크 입력과 센터 사이의 유클리디안 거리를 갖는다. 유클리디안 거리는 센터 확산 파라메타로 나누어져서 비선형 함수를 통과하게 된다. 그리고 은닉층의 출력값과 가중치(weight)가 곱해져서 출력층의 입력으로 들어가는데 본 논문에서는 출력층에서 선형 조합이 일어나는 기존의 RBFN와는 달리 경쟁을 통하여 가장 큰 값을 갖는 것을 출력값으로 인정하는 경우이다. 그림 2의 RBFN의 출력 응답은 다음과 같다.

$$f(r) = \max |w_i \phi(\|r - c_i\| / \rho)| \quad 1 \leq i \leq n_s \quad (2)$$

여기서 w_i 는 i 번째 은닉층 출력의 가중치이며, c_i 는 i 번째 센터 벡터, ρ 는 센터 확산 파라메타, $\phi(\cdot)$ 는 노드의 비선형 함수이다. 그리고 n_s 는 RBF의 센터와 은닉층의 수가 되며 $n_s = 2^n \cdot m^{-1}$ 로 결정된다. 수식 (2)와 같이 전체적인 출력값은 가중치와 비선형 함수가 곱해진 값 중에서 가장 큰 경우만을 고려한다




그림 2. 경쟁 학습을 갖는 RBFN의 구조

III. RBFN을 위한 학습 알고리즘

RBFN의 전체적인 채널 임펄스 응답의 정확한 추정을 얻기 위해서, 지도학습 방법인 k -means clustering 알고리즘을 사용하였으며 계산식은 다음과 같다.

$$\begin{aligned} & \text{if } (s(k) = s_i) \{ \\ & \quad c_i(k) = \text{center} + c_i(k-1) + r(k); \\ & \quad \text{counter}_i(k) = \text{counter}_i + 1; \\ & \quad c_i(k) = c_i(k) / \text{counter}_i; \end{aligned} \quad (3)$$

k -means clustering은 RBF 센터가 중심점에 정확히 수렴하도록 잡음을 효과적으로 제거한다. 이 방법으로 센터를 결정한 후 이들을 고정하고 학습 데이터를 이용하여 은닉층과 출력층 사이의 가중치 w_i 를 적응적으로 개선할 수 있다. 그리고 가중치 초기치는 센터 c_i 가 '+'이면 '+1', c_i 가 '-'이면 '-1'을 갖는다. 가중치의 조정은 비교적 계산량이 적은 최소 평균 제곱 (Least Mean Squares)을 적용하였다.

$$f_i(r) = w_i \phi(\|r - c_i\| / \rho), \quad 1 \leq i \leq n_s, \quad (4)$$

$$j = \arg \left[\max_i \{ f_i(r) \} \quad 1 \leq i \leq n_s \right] \quad (5)$$

$$e(k) = s(k-d) - w_j(k-1) \phi_j(k) \quad (6)$$

$$w_j(k) = w_j(k-1) + g_w e(k) \phi_j(k) \quad (7)$$

그림 2에서의 출력값 f_I 을 이용하여 가중치를 갱신하는데 이 경우에도 마찬가지로 모든 가중치들

갱신하는 것이 아니라 f_i , $1 \leq i \leq n$, 중에서 가장 큰 값을 갖는 f_i 번째 값을 갱신하게 된다. 이렇게 할 경우의 잇점은 학습을 할 때 계산량을 줄일 수 있을 뿐만 아니라 학습시간도 단축할 수 있다. 이때, 수렴 속도와 안정도는 학습율 g_w 로 고려되며, $\|\cdot\|$ 는 유클리디안 거리가 된다.

표 1. 채널 $H(z) = 0.407 + 0.815z^{-1} + 0.407z^{-2}$ 일 때의 심볼과 채널 상태. $m=2, d=1$

| $s(k)$ | $s(k-1)$ | $s(k-2)$ | $s(k-3)$ | $\hat{f}(k)$ | $\hat{f}(k-1)$ |
|--------|----------|----------|----------|--------------|----------------|
| 1 | 1 | 1 | 1 | 1.6290 | 1.6290 |
| 1 | 1 | 1 | -1 | 1.6290 | 0.8150 |
| 1 | 1 | -1 | 1 | 0.8150 | -0.0010 |
| 1 | 1 | -1 | -1 | 0.8150 | -0.8150 |
| -1 | 1 | 1 | 1 | 0.8150 | 1.6290 |
| -1 | 1 | 1 | -1 | 0.8150 | 0.8150 |
| -1 | 1 | -1 | 1 | 0.0010 | -0.0010 |
| -1 | 1 | -1 | -1 | 0.0010 | -0.8150 |
| 1 | -1 | 1 | 1 | -0.0010 | 0.8150 |
| 1 | -1 | 1 | -1 | -0.0010 | 0.0010 |
| 1 | -1 | -1 | 1 | -0.8150 | -0.8150 |
| 1 | -1 | -1 | -1 | -0.8150 | -1.6290 |
| -1 | -1 | 1 | 1 | -0.8150 | 0.8150 |
| -1 | -1 | 1 | -1 | -0.8150 | 0.0010 |
| -1 | -1 | -1 | 1 | -1.6290 | -0.8150 |
| -1 | -1 | -1 | -1 | -1.6290 | -1.6290 |




그림 4. 채널 $H(z) = 0.3482 + 0.8704z^{-1} + 0.3482z^{-2}$ 일 때의 최적의 결정 경계, SNR = 15 dB

IV. 실험 및 결과 고찰

본 절에서는 II, III 절에서 제안한 방법의 RBFN를 이용하여 디지털 채널 등화의 비선형 분류 (nonlinear classification) 문제에 적용하여 보았다. 이때 결정 경계 (decision boundary) 판별은 다음과 같다.

$$\{r \mid fr(r) = 0\} \quad (8)$$

수식(8)은 $\hat{s}(k-d) = \pm 1$ 에 따라서 관측공간을 두 결정 영역으로 분할한다. 표 1에는 심볼 $s(k)$ 와 센터 값이 나와있으며, 기하학적인 구조로 이러한 결과들을 볼 때 결과는 그림 3, 4와 같다. 그림에서 센터는 "o"와 "x"를 사용하였으며, 경계 판별은 2차 평면에서 곡선으로 나타나는데 논문에서 제안한 방법이 우수한 비선형 분류 능력을 갖고있음을 확인할 수 있다. 그리고 기존의 RBF와 Wiener Filter를 이용한 DFE의 성능을 비교하였다. 그리고 성능 비교에서 사용된 샘플의 수는 10^4 개이며, 비최소 위상 채널 (non-minimum phase channel)을 사용하였다. 그림 5에서 나타난 성능을 비교해 보면, 제안된 경쟁 학습을 갖는 RBF 적은 계산량에도 불구하고 기존의 RBF와 같은 성능 결과를 볼 수 있었다.

V. 결론

본 논문에서는 기존의 RBF가 빠른 수렴 속도와




그림 3. $H(z) = 0.407 + 0.815z^{-1} + 0.407z^{-2}$ 일 때의 최적의 결정 경계, SNR = 15 dB

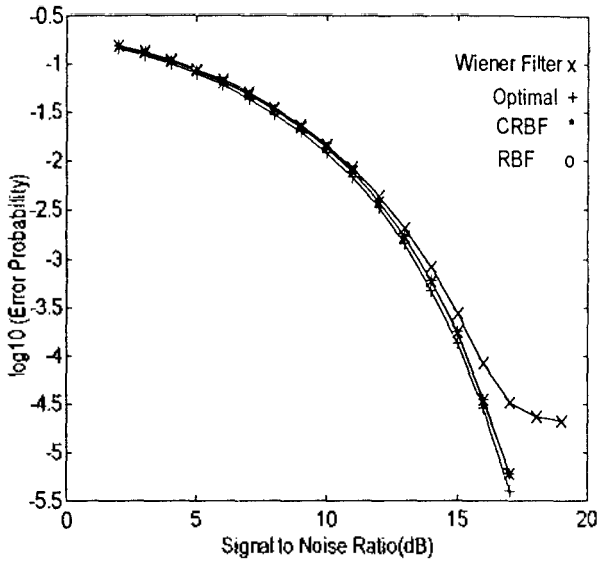


그림 5. $H(z) = 0.407 + 0.815z^{-1} + 0.407z^{-2}$ 채널 인
 때의 성능비교 $m=3, n=2, d=2$

좋은 성능을 보이고 있지만, 비교적 계산량이 많고 학습시간이 많이 필요하다는 단점을 갖고있다. 이러한 문제점을 극복하기 위해서 경쟁학습을 갖는 RBF를 제안하였으며, 이러한 방법을 사용할 경우 계산량을 줄일 수 있을 뿐만 아니라 학습시간을 줄일 수 있다는 장점도 갖고 있다. 또한 기존의 RBF, Wiener Filter와 성능 비교를 했을 때 기존의 RBF와는 같은 성능 결과임을 알 수 있었고 Wiener Filter 보다는 훨씬 우수한 성능을 갖고 있음을 확인할 수 있었다. 비선형 분류 문제에 적용했을 때도 우수한 성능 결과를 볼 수 있었다.

참고 문헌

- [1] S. U. H. Qureshi, "Adaptive equalization," *Proc. IEEE*, vol. 73, no. 9, pp. 1349-1387, 1985.
- [2] J. G. Proakis, *Digital communications, 3rd Ed.*, New York, McGraw-Hill, 1995.
- [3] G.D. forney, "Maximum-likelihood sequence estimation of digital sequence in the presence of intersymbol interference," *IEEE Trans. Information Theory*, vol. IT-18, No. 3, pp.363-378, 1972.
- [4] F.R. Magee and J.G. Proakis, "Adaptive maximum-likelihood sequence estimation for digital signaling in the presence of intersymbol interference", *IEEE Trans. Information Theory*, vol. IT-19, No. 1, pp.120-124, 1973.
- [5] S. Chen, B. Mulgrew, and P. M. Grant, "A clustering technique for digital communications channel equalization using radial basis function networks," *IEEE Trans. Neural Networks*, vol. 4, no. 4, pp. 570-579, 1993.
- [6] S. Chen, C. F. N. Cowan, and P. M. Grant,

"Orthogonal least squares learning algorithm for radial basis function networks," *IEEE Trans. Neural Networks*, vol. 2, no.2, pp. 302-309, 1991.

- [7] I. Cha and S. A. Kassam, "Channel equalization using adaptive complex radial basis function networks," *IEEE Jour. Sel. Areas in Commun.*, vol. 13, no. 1, pp. 122-131, 1995.
- [8] B. Yuhaz, and N. Ansari, *Neural Networks in telecommunications, KAP*, 1994.