

PC-BLRNN을 이용한 무선 비동기 전송 채널 등화기

정회원 박동철*, 이실*

Equalization with PC-BLRNN for Wireless ATM Channel

Dong-Chul Park*, Sil Lee* *Regular Member*

요약

PC-BLRNN을 이용한 무선 비동기 전송 채널 등화기가 본 논문에서 제안되었다. BLRNN은 쌍선형 다항식에 기초한 것으로 MLPNN형태의 신경망보다 비선형 시스템의 모델링에 탁월한 성능을 보여왔으므로, 매우 비선형적이고 시계열적 특성을 가지는 무선 비동기 전송 채널 등화기에 이용될 수 있다. PC-BLRNN 등화기가 QPSK 신호에 대해 C-DFE, C-MLPNN 등화기등과 실험적으로 비교되었는데, 그결과, 기존의 등화기들 보다, 제안된 PC-BLRNN 등화기가 MSE와 BER의 성능에서 모두 매우 향상된 결과를 보여주었다.

ABSTRACT

Equalization of wireless Asynchronous Transfer Mode (ATM) using Pruned Complex BiLinear Recurrent Neural Network (PC-BLRNN) is proposed in this paper. Since the BLRNN is based on the bilinear polynomial, it has been more effectively used in modeling highly nonlinear systems with time-series characteristics than multi-layer perceptron type neural networks (MLPNN). The BLRNN is, first, expanded to its pruned multi-layer complex version for dealing with the highly nonlinear and complex valued input signals in this paper. PC-BLRNN is then applied to equalization of a wireless ATM communication channels for QPSK which has the impulse prolongation resulting from multipath propagation. The proposed PC-BLRNN based equalizer for a channel models is compared with currently used Complex Decision Feedback Equalizer (C-DFE), conventional Complex MLPNN(C-MLPNN) Equalizer. The results show that the proposed PC-BLRNN based equalizer gives favorable results in MSE and BER criteria over Complex DFE, Complex MLPNN Equalizers.

I. 서론

여러 가지 혼합된 방식의 네트워크에 경유하며 최종단으로 무선으로 지역 연결 시스템을 경유하는 형식을 가지는 통신 네트워크 시스템은 비동기 전송 방식(Asynchronous Transfer Mode)을 지원해야 하는데, 이러한 비동기 전송 방식은 무선 통신 방식의 특성과 복잡한 형태의 멀티미디어 데이터를 특징으로 가지는 미래의 복잡한 형태의 시스템에도 적용할 수 있다는 장점이 있다^[1]. 그러나, 이러한 전송방식의 시스템에서 가장 큰 문제는 고속의 무선

데이터 전송에서 발생하게되는 다중 경로를 통과할 때 발생하는 신호들 사이의 간섭에 의한 지연이다. 단일 간섭에 의한 신호의 지연 범위가 길어서 다음 신호에 영향을 준다면, 이것은 symbol간의 간섭을 야기시킨다. 한편, 채널의 비선형적 특성에 의해 신호의 비선형 왜곡은 신호의 지연에 의한 symbol 사이의 간섭과 함께 무선 통신의 이상적 효율성을 제한하는 주된 요소이다. 이러한 전송 채널의 이상적이지 못한 특성을 보상하기 위해 쓰이는 것이 등화기이다^[2].

비선형 특성을 가진 채널에서 선형 신호처리하는 왜

* 명지대학교 지능 컴퓨팅 연구실(parkd@mju.ac.kr, sillee@mju.ac.kr)
논문번호 : 00453-1128, 접수일자 : 2000년 11월 28일

곡을 보상하는데 많은 제한을 가지고 있기 때문에 비선형 신호처리가 요구되지만, 기존의 무선 비동기 전송 방식에 쓰인 등화기는 등화기 자체의 실시간 동작을 보장하기 위해 Decision Feedback Estimator (DFE) 같은 선형 필터였다^[3]. 그러나, 이러한 선형 신호 처리에 기반한 방법들은 채널의 비 선형적인 특징 때문에 비선형 채널의 왜곡을 처리하는데는 한계가 있다. 이러한 선형필터의 제약을 극복하기 위해, 여러가지 비선형 등화기 (Equalizer) 기술이 무선 통신에 이용될 수 있는데, 이는 두 가지 부류로 나눌 수 있다. 이는 Volterra 필터에 기반한 기술과^[4,5] 신경망에 기반한 것이다^[6,7]. Volterra filter에 기반한 접근방법은 선형필터와 비교할 때 SNR 측면에서 많은 향상을 보여왔으나 여기에는 구현상의 어려움이 뒤따랐다. 반면 신경망에 기반한 기술 또한 비선형 시스템을 모델링 하는데 큰 효과를 보이고 있을 뿐만 아니라 단순한 구조와 학습의 간편함 때문에, 적용된 여러 분야에서 보여지듯이 신경망은 성공적으로 복잡한 비선형 시스템이나 신호 예측에 적용되어 왔다.

비선형 시스템을 모델링하는 일반적인 기술에 비해 신경망의 가장 두드러진 특징은 학습능력에 있다. 신경망은 시스템의 입력과 출력사이에 놓여진 관계를 학습할 수 있다. 신경망이 적절히 학습되면 시스템의 입력이 잡음에 왜곡됐다고 할지라도 신경망은 결과값에 근사한 출력을 낼 수 있다. 이런 신경망의 학습능력과 잡음에 잘 적응하는 능력은 무선 통신용 등화기 문제에 잘 적용될 수 있다. 이전의 등화기에 적용된 신경망은 다층 구조 퍼셉트론 (Multi Layer Perceptron) 형태의 단순한 구조의 신경망 형태였다. 그러나 최근의 연구에서 보여지듯이 회귀성분을 가진 신경망이 비선형 시스템의 모델링이나 시계열 예측에 더욱 효과적임을 보여주고 있다^[8].

이 논문에서는 무선 비동기 전송 채널과 같은 복잡한 시스템에 효율적으로 적용되기 위해, 쌍선형 다항식에 기반하며, 최소의 구조를 가지는 회귀성 신경망을 이용한 적용형 비선형 등화기가 제안되었다. 쌍선형 다항식은 Volterra series 모델과 같이 비선형 시스템을 모델링 하는데 IIR Filter 가 FIR Filter 보다 적은 수의 계수로 시스템을 표현하는 것과 같은 원리로 널리 이용되어 왔다. 이런 원리를 이용하여 쌍선형 다항식을 사용하는 신경망은 Volterra series를 기반으로 하는 고차수 신경망이^[9] 표현할 수 있는 시스템을 경제적인 방법으로 추정할 수 있다. 이 논문은 신경망과 Volterra series와 같은 고차수 다항식

(High-Order Polynomial)의 기능을 포괄하는 쌍선형 다항식을 기반으로 하는 회귀성 신경망을 소개하고, 이의 구조를 최소화하는 전지 알고리즘을 적용한 적용형 비선형 등화기를 개발하였다. 2장에서는 논문에 적용된 무선 비동기 전송 채널들의 모델링에 대해 설명하고, 3장에서 BiLinear Recurrent Neural Network (BLRNN)과 BLRNN의 연산속도를 최소화하기 위한 전지 알고리즘을 소개한다. 그리고, 4장과 5장에서는 실험에 대한 결과와 간단한 결론이 주어진다.

II. 채널 모델 (Channel Model)

본 논문에서 사용되는 무선통신 채널은 Denver와 Bristol의 측정에 기반한 30~40GHz 범위의 고정 라디오 주파수 광대역 셀룰라 채널인데^{[10][11]}, 실험에 사용된 4가지 채널모델에 대한 채널 임펄스 응답 $h'(t/T)$ 은 다음과 같이 정의된다.

$$h'(t/T) = \sum_i a_i \cdot \delta(t/T - \tau_i) \cdot e^{j\phi_i(t/T)}$$

여기서 $\delta(t)$ 는 다이락 임펄스를 나타내며, $T = 12.8 \text{ ns}$ 이고, 128Mbit/s 신호의 지속시간을 나타내며, ϕ_i 는 임의의 위상각이다. 변조 방법으로는 QPSK 방식이 고려되었다. 각 채널에 사용된 a_i , τ_i 와 ϕ_i 는 표 1과 같다. 그림 4, 6, 8 그리고 10의 a)에 보여진 각각의 그림은 QPSK 시스템이 각 채널을 통과하고 난 후에 20 dB의 AWGN에 의해 더럽혀진 각 채널의 constellation을 보여준다.

표 1. 각 채널에 사용된 a_i , τ_i 와 ϕ_i

채널 I	a_i	0, 4/8, 9/8, 13/8, 21/8, 39/8
	τ_i	1, 0.5, 0.4, 0.32, 0.1, 0.08
	ϕ_i	0, 90, 140, 90, 330, 10
채널 II	a_i	0, 1/8, 2/8, 4/8, 5/8, 7/8, 10/8, 11/8, 15/8
	τ_i	1, 0.8, 0.56, 0.056, 0.056, 0.1, 0.032, 0.032, 0.032
	ϕ_i	0, 175, 150, 90, 330, 10, 330, 10, 10
채널 III	a_i	0, 3/8, 6/8, 13/8, 25/8, 37/8, 63/8
	τ_i	1, 0.8, 0.56, 0.4, 0.28, 0.18, 0.032
	ϕ_i	0, 90, 140, 90, 330, 10, 10
채널 IV	a_i	0, 13/8, 37/8, 62/8, 125/8, 155/8, 187/8
	τ_i	1, 0.5, 0.32, 0.18, 0.18, 0.1, 0.032
	ϕ_i	0, 90, 140, 90, 330, 10, 10

III. 전지 쌍선형II. 채널 모델 (Channel Model) 회귀성 신경망 (Pruned Complex BiLinear Recurrent Neural Network)

1. 복소 쌍선형 회귀성 신경망 (Complex BiLinear Recurrent Neural Network)

쌍선형 다항식(bilinear polynomial)은 간단한 회귀성 시스템 모델이다. Volterra 시스템을 포함하는 많은 비선형 시스템은 제한된 정도의 정확도를 가정하여 쌍선형 다항식에 의해 근사화될 수 있는데, 쌍선형 다항식의 일차원의 입, 출력을 가진 예에서 입출력에 대한 관계식은 다음과 같다.

$$y[n] = \sum_{i=1}^{N-1} a_{ip}[n-i] + \sum_{i=0}^{N-1} \sum_{j=1}^{N-1} b_{ij}y[n-i]x[n-j] + \sum_{i=0}^{N-1} c_i x[n-i] \quad (1)$$

여기서 $x[i]$ 는 입력, $y[i]$ 는 출력, 그리고 N 는 회귀도의 차수이다. 우리는 차수가 축소된 Volterra series 대신 쌍선형 회귀성 다항식의 출력을 신경망의 은닉층의 출력으로 표현하는 새로운 쌍선형 회귀성 신경망 (Bilinear Recurrent Neural Network : BLRNN)의 구조를 얻을 수 있으며, BLRNN에 관한 보다 자세한 설명은 [12][13]에서 얻을 수 있다. 이를 일반화 시키기 위해, BLRNN은 N 개의 입력뉴런, M 의 은닉층 뉴런 그리고 $K=N-1$ 차의 다항식을 사용한다. 입력신호와 은닉층에서 사용되는 입력신호의 비선형 값들은 다음으로 표현된다:

$$X[n] = [x[n], x[n-1], \dots, x[n-K]]^T \quad (2)$$

$$NET[n] = [net_1[n], net_2[n], \dots, net_M[n]]^T \quad (3)$$

여기서 회귀함은 $M \cdot K$ 차의 벡터이다. :

$$Z[n] = [NET[n-1]^T, \dots, NET[n-K]^T]^T \quad (4)$$

$$Z_p[n] = [net_p[n-1], net_p[n-2], \dots, net_p[n-K]] \quad (5)$$

은닉층의 입력을 위한 입력신호의 계산식은 다음과 같다.

$$net_{p}[n] = w_p + \sum_{k_1=1}^{N-1} a_p[k_1]net_p[n-k_1]$$

$$+ \sum_{k_1=1}^{N-1} \sum_{k_2=0}^{N-1-k_1} b_p[k_1][k_2] net_p[n-k_1]x[n-k_2] + \sum_{k_2=0}^{N-1} c_p[k_2]x[n-k_2] \quad (6)$$

$$= w_p + A^T Z^T[n] + Z_p^T B^T X[n] + C^T X[n]$$

여기서 w_p 는 바이어스 뉴런의 연결강도, A_p 는 회귀함의 연결 강도 벡터, B_p 는 쌍선형 회귀함의 연결강도 행렬 그리고 C_p 는 전방향의 연결강도이다. 여기서 p 는 은닉층의 수이다.

ϕ 를 은닉층의 활성화함수라 한다면, p 차의 은닉층의 출력은

$$o_{p}[n] = \phi(net_p[n]) \quad (7)$$

은닉층에서 출력층까지는 feedforward 형식의 전형적인 신경망의 구조와 유사하다. 시간 n 에서 출력층의 l 번째의 출력 $o_l[n]$ 은 다음으로 정의된다.

$$net_l[n] = \sum_{p=0}^N w_{lp} o_p[n] \quad (8)$$

$$o_l[n] = \phi(net_l[n]) \quad (9)$$

여기서 w_{lp} 는 은닉층에서 출력층으로의 연결강도이다. 복소형태의 신호를 처리하기 위해 다음과 같은 활성화함수가 정의된다.

$$\phi(Z) = sgm(z_R) + jsgm(z_I) \quad (10)$$

이 활성화함수에서 sigmoid 함수 $sgm(z)$ 는 일반적인 $(1 - \exp(-x)) / (1 + \exp(-x))$ 이며, 다음은 복소형태의 연결 강도에 대한 학습 공식이다.

$$w_{lp}[n+1] = w_{lp}[n] + \mu(d_l[n] - o_l[n])\phi'(net_p^*[n])o_p^*[n] \quad (11)$$

$$c_p[n+1] = c_p[n] + \mu \sum_{i=1}^N (d_i[n] - o_i[n])\phi'(net_p^*[n])w_{ip}^* \cdot \phi(net_p^*[n])x_i^* \quad (12)$$

$$a_p[n+1] = a_p[n] + \mu \sum_{i=1}^N (d_i[n] - o_i[n])\phi'(net_p^*[n])w_{ip}^* \cdot \phi(net_p^*[n])z_i^* \quad (13)$$

$$b_{pi}[n+1] = b_{pi}[n] + \mu \sum_{i=1}^N (d_i[n] - o_i[n])\phi'(net_p^*[n])w_{ip}^* \cdot \phi(net_p^*[n])z_i^* x_j^* \quad (14)$$

그림 1은 C-BLNN(Complex BiLinear Recurrent Neural Network)의 퍼셉트론의 간단한 예이며, 이 C-BLNN에 대한 자세한 설명은 [14]에서 얻을 수 있다.

2 전지 알고리즘 (Pruning Algorithm)

채널신호의 비선형적 특성으로 인해, 증가된 채널의 비선형 특성을 모델링하기 위해 복소 쌍선형 회귀성 신경망의 구조 또한 복잡해지게 되었다. 이로 인해 발생된 문제점은 신경망이 복잡한 채널의 특성을 학습하지 못하거나 학습하더라도 너무나 거대한 망 구조를 요구한다는 것이다. 이런 문제를 해결하기 위해 전지 알고리즘을 적용한 전지 복소 쌍선형 회귀성 신경망이 본 논문에서 개발되었는데, 이는 주어진 신호의 비선형성에 기인하는 문제의 복잡도를 해결하기 위해 사용되는 신경망의 구조를 필요이상으로 크게 함으로서 발생하는 불필요한 연산량의 증가를 최소화하기 위함이다. 즉, 무선 통신채널의 증가된 비선형성에 대응하기 위해서는 신경망의 구조가 비선형적으로 증가하게되는데, 이는 연산량의 엄청난 증가를 수반하게되어, 결과적으로 동화기의 반응속도를 극도로 느리게 할 수 있다. 따라서, 증가된 신경망의 구조를 허용하면서, 동시에 동화기의 반응속도를 최소화하기 위한 노력으로, 불필요하게 사용되는 신경망 구조속의 뉴런과 연결된 연결 강도들을 제거하고자 하는 방안으로 전지 알고리즘(Pruning Algorithm)[15]이 C-BLNN에 적용되었다. 다음은 일반적인 신경망의 전지 방법이다.

신경망의 학습과정은 다음의 E 를 감소시키는 방향으로 연결 강도를 조절하는 과정이다.

$$E = \sum_p \sum_i (o_{pi} - t_{pi})^2 \quad (15)$$

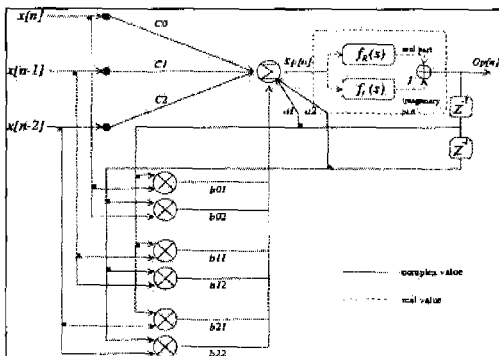


그림 1. 간단한 C-BLNN의 구조

여기서, b 는 입력 패턴이고 i 는 출력 뉴런이며, o 는 신경망의 출력값, t 는 목적값을 표시한다. $0 < \beta < 1$ 의 momentum 계수와 학습률 η 을 가지는 일반적인 학습관계식은 다음으로 표현되는데,

$$w_{ij}(n+1) = -\eta \frac{\partial E}{\partial w_{ij}}(n) + \beta w_{ij}(n) \quad (16)$$

여기서, 불필요한 연결강도, w_{ij} 는 학습이 진행되는 동안에 에러를 감소시키는데 많은 영향을 미치지 못한다고 가정하면, $\partial E / \partial w_{ij} \approx 0$ 이다. 즉,

$$w_{ij}(n) \approx \beta^n w_{ij}(0)$$

위의 기중치의 제거는 E 에 약간의 손실 부분을 더해주는 것과 같으며, 이는 다음과 같다.

$$E' = E + \beta' \sum_i w_{ij}^2 \quad (17)$$

Mozzer와 Smolensky[16]에 의해 제안된 불필요한 뉴런의 소거를 위한 에러 함수의 민감도, S_{ij} 는 다음으로 정의된다.

$$S_{ij} = E(w_{ij} = 0) - E(w_{ij} = w_{ij}^t) \quad (18)$$

여기서 w_{ij}^t 는 training이 끝난 후에 연결강도의 최종값이다.

여기서 신경망을 학습시키는 것과 전지될 뉴런을 찾는 일은 완전히 별개의 일이며 이것은 학습 과정이 외부의 과정에 의해 간섭받지 않음을 의미한다. 전지에 대한 접근은 각 기중치를 제거하기 위하여 에러 함수의 민감도를 평가하고, 민감도가 낮은 기중치를 잘라내는 것이다. 식(18)에서 정의된 민감도 S_{ij} 는 다음과 같이 다시 쓸 수 있다.

$$S_{ij} = - \frac{E(w_{ij}^t) - E(0)}{w_{ij}^t - 0} w_{ij}^t \quad (19)$$

여기서 $w = w_{ij}$ 이고 E 는 w 의 함수로 표현되며 다른 모든 연결 강도는 고정된 것으로 간주한다. 전형적인 학습 과정은 $w=0$ 가 아니라 오히려 보통 무작위로 선택된 작은 초기값 w^i 로 시작한다. $E(0)$ 는 모르는 값이기 때문에, w^i 와 w^i 사이에서 측정된 평균 기울기로 0에서 w^i 로 움직일 때 $E(w)$ 의 기울기로 다음과 같이 근사화 할 수 있다.

$$S_{ij} \approx - \frac{E(w^i) - E(0)}{w^i - 0} w^i \quad (20)$$

표 2. 각 등화기 구조의 복잡도 및 가중치 계산

	복잡도	실제 계산수
C-DFE	$N_f \times N_b$	Net : 15,30 복잡도 : 45
C-MLPNN	$\sum_{i=0}^{N-1} M_i(N_i+1)$	Net : 15-15-15-15-1 복잡도 : 720
C-BLRNN	$\sum_{i=0}^{N-1} M_i(N_i+(N_i-1)+2N_i(N_i-1))$	Net : 15-2-2-1 복잡도 : 914
PC-BLRNN	$\sum_{i=0}^{N-1} (M_i N_i + (N_i - 1) + 2N_i(N_i - 1))$	Net : 15-2-2-1 복잡도 : 480

또는, 연결부 w_{ij} 의 제거에 의한 민감도는 다음의 식으로 근사화될 수 있으며,

$$\hat{S}_{ij} = - \sum_{i=0}^{N-1} \frac{\partial E}{\partial w_{ij}}(n) \Delta w_{ij}(n) \frac{w_{ij}^f}{w_{ij}^f - w_{ij}^i} \quad (21)$$

여기서 N 은 학습반복횟수이다. 민감도에 대한 위의 측정은 보통의 학습 과정에서 얻을 수 있는 항들을 사용한다. 따라서 위의 과정을 수행하는데 필요한 여분의 계산은 식(21)에서의 더하기 연산 뿐이다.

이 총 계산도 단지 식(21)에서 S_{ij} 를 만들기 위해, 측정된 항들을 계산하는데 필요하다. 식(15)에 따라 가중치의 조절이 이루어지므로 식(21)은

$$\hat{S}_{ij} = \sum_{i=0}^{N-1} [\Delta w_{ij}(n)]^2 \frac{w_{ij}^f}{\eta(w_{ij}^f - w_{ij}^i)} \quad (22)$$

가 된다. 학습이 끝나면 각 연결부는 민감도에 대한 리스트를 한 개씩 가지게 된다. 이 부분에서 민감도가 가장 작은 가중치가 소거되게 된다. 이러한 과정이 주어진 최종 학습 에러의 범위를 만족시키는 한도 내에서 반복적으로 수행되어, 최종적으로 불필요한 연결 강도들을 소거하게 된다. 실험에서 사용된 C-BLRNN의 경우 최초의 구조는 15-2-2-1의 매우 큰 규모로 총 914개의 연결강도를 가지는 큰 구조였으나, 전지과정을 2번째 은닉층과 출력층 사이의 연결 강도들로부터 적용시켜, 불필요한 연결강도들을 소거하고, 결과적으로 480개의 연결강도만을 가지는 매우 축소된 형태의 구조를 구할 수 있었다.

IV. 실험 및 결과

실험에 사용하기 위한 비선형 무선 비동기 전송 채널의 모델링을 위해 4가지의 채널이 사용되었으며,

여기에 사용된 채널 임펄스 응답 수식과 계수들은 2장에 자세하게 기술되었다. 전송된 데이터 symbol은 무작위 추출된 QPSK신호이다. 무선 비동기 채널을 통과한 전송신호는 또한 AWGN (Adaptive White Gaussian Noise)으로 더럽혀지게 된다. 그래서 수신단 측에서 받는 전송신호는 크기와 위상이 왜곡된 symbol을 수신하게되고 이는 그림 1에서와 같은 성단모양의 여러 개의 서로 다른 constellation을 이루게 된다. 각 실험에서 무작위의 5,000 개의 symbol이 등화기의 학습에 사용되고, 다른 1,000,000개의 데이터 symbol로 등화기의 성능 측정에 사용되었다. 그림 2는 실험 과정을 표현한 그림이다.

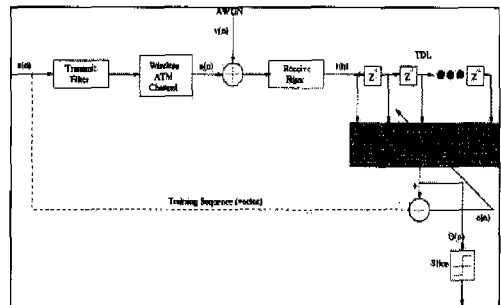


그림 2. 실험 과정 블럭도

PC-BLRNN에 기초한 무선 비동기 전송 등화기는 기존에 제안된 Complex Decision Feedback Equalizer (C-DFE) 와 그리고 다른 형태의 일반적 신경망인 Complex Multi-Layer Perceptron Neural Network (C-MLPNN) 등화기와 비교 실험되었으며, 실험 결과는 BER과 MSE로 비교되었다. 실험에서 비교된 등화기를 간단히 나타내기 위해 LMS형 C-DFE는 C-DFE(n_f, n_b)로 표현된다. 여기서 n_f 는 전방향 탭의 개수 그리고 n_b 는 feedback 탭의 개수를 나타낸

표 2. 각 등화기 구조의 복잡도 및 가중치 계산

	복잡도	실제 계산 수
C-DFE	$N_f \times N_b$	Net : 15,30 복잡도 : 45
C-MLPNN	$\sum_{i=0}^{L-1} M_i(N_i+1)$	Net : 15-15-15-15-1 복잡도 : 720
C-BLRNN	$\sum_{i=0}^{L-1} M_i(N_i+(N_i-1)+2N_i(N_i-1))$	Net : 15-2-2-1 복잡도 : 914
PC-BLRNN	$\sum_{i=0}^{L-1} (M_i N_i + (N_i-1) + 2N_i(N_i-1))$	Net : 15-2-2-1 복잡도 : 480

다. 또한, 신경망 기반의 C-MLPNN과 PC-BLRNN 등화기는 C-MLPNN(n_i, n_1, n_2, n_3, n_0)와 PC-BLRNN(n_i, n_1, n_2, n_0)로 표현된다. 여기서 n_i 는 입력층의 개수를 나타내며 n_1 은 첫 번째 은닉층의 뉴런수, n_2 는 두 번째 은닉층의 뉴런수, n_3 는 세 번째 은닉층의 뉴런수 그리고 n_0 는 출력 뉴런의 수를 나타낸다. 실험에 사용된 등화기 구조는 C-DFE(15,30), C-MLPNN(15-10-10-10-1), C-BLRNN(15-2-2-1), PC-BLRNN(15-2-2-1)이 사용되었다. 표 2는 실험에 쓰인 여러 등화기에 사용된 가중치의 총수이다. 이것은 채널 등화시에 사용되는 계산량을 나타낸다. N_i 는 각 층의 뉴런수이며, M_i 는 바로 다음 층의 뉴런의 개수이다. 즉 N_0 는 입력 뉴런의 수이며 M_0 는 첫 번째 은닉 층의 뉴런수이다. 여기서 우리는 제안된 PC-BLRNN이 C-MLPNN보다 적은 계산량을 요구함을 알 수 있다.

표 3은 각 채널마다 사용된 PC-BLRNN의 학습률이다. 그림 3은 채널 I에서 각 등화기의 학습 epoch당 MSE를 표시한 것이다. 결과에서 볼 수 있듯이 PC-BLRNN은 다른 등화기에 비해, 한 epoch당 연산량을 고려할 때, 매우 빠르거나, 최소한 대등한 수렴 속도를 가지며, 최종 MSE 또한 월등히 작은 값을 갖는다.

이러한 현상은 다른 3가지의 채널에서도 공통적으로

로 나타나는 현상이다. 각 채널별로 기존의 C-DFE에 비해 각각 23.7dB, 41.9 dB, 38.4 dB과 35.3 dB의 성능 향상을 가져왔다.




그림 3. 채널 I에서의 MSE 학습 곡선

그림 4, 그림 6, 그림 8, 그림 10은 AWGN (SNR=20dB)일 때 채널 I, II, III, IV에서 C-DFE, C-MLPNN과 PC-BLRNN의 QPSK 시스템에 대한 채널 등화 후의 constellation을 보여준다. 각 그림에서 보듯이 PC-BLRNN은 거의 완벽한 결과를 나타낸다. 이것은 PC-BLRNN이 무선 ATM 채널을 통과하는 QPSK 시스템에서 가장 적절하게 이용될 수 있음을 알 수 있다. 위의 결과에서 볼 때 신경망의 비선형 모델링 기능때문에 PC-BLRNN과 C-MLPNN은 C-DFE 보다 잡

표 3. PC-BLRNN에 쓰인 각 채널의 학습 이득값

	μ_{a1}	μ_{a2}	μ_{b1}	μ_{b2}	μ_{c1}	μ_{c2}	μ_w
채널 I	5×10^{-4}	1×10^{-4}	5×10^{-4}	1×10^{-5}	0.1	0.05	0.05
채널 II	5×10^{-4}	5×10^{-6}	5×10^{-5}	1×10^{-5}	0.1	0.1	0.1
채널 III	5×10^{-4}	5×10^{-6}	5×10^{-5}	5×10^{-6}	0.05	0.05	0.05
채널 IV	7×10^{-4}	1×10^{-6}	7×10^{-5}	7×10^{-6}	0.1	0.07	0.07

표 4. 각 채널에서의 PC-BLRNN의 BER 이득 (BER = 10⁻⁴)

	채널 I	채널 II	채널 III	채널 VI
C-DFE와 비교	1.59 dB	1.74 dB	2.02 dB	1.31 dB
C-MLPNN와 비교	0.78 dB	0.93 dB	1.41 dB	0.69 dB

음의 제거기능이 월등한 것으로 볼 수 있다. 더욱이 PC-BLRNN의 회귀항과 교차항은 C-MLPNN에 비해서 무선 비동기 전송 채널의 지연효과를 충분히 제거해주고 있다. 한편, PC-BLRNN이 기존의 C-BLRNN에 비해 학습 속도의 관점에서 비교될 때, 제거된 불필요한 연결강도의 영향으로 매우 향상된 결과를 보여주고 있다.

각각의 잡음의 SNR당 비트 오차율은 1,000,000개의 symbol을 테스트한 후에 취해지는데, 그림 5에서 보여지듯이 채널 I의 경우 PC-BLRNN은 BER=10⁻⁴에서 C-MLPNN, C-DFE 보다 각각 0.78 dB, 1.59 dB의 향상을 가져왔다. 각 채널에 대한 PC-BLRNN의 BER 이득은 표 4에서 보여진다. 위의 결과는 PC-BLRNN이 무선 비동기 전송 채널을 통과하는 QPSK 시스템에서 가장 적절하게 이용될 수 있음을 알 수 있다.

V. 결론

이 논문에서 우리는 PC-BLRNN (Pruning Complex BiLinear Recurrent Neural Network)을 이용한 무선 ATM 채널 등화기의 개발을 제안하였다. 제안된 PC-BLRNN의 특징은 Volterra 필터의 고차수 특성과 MLPNN의 맵핑 기능을 동시에 가지고서 효과적으로 무선 ATM 채널에서 발생하게 되는 신호의 지연과 왜곡 현상을 제거할 수 있었다. 각 채널의 QPSK 시스템을 위한 등화기의 실험에서 보여지듯이, PC-BLRNN을 이용한 등화기는 C-DFE 등화기, C-MLPNN 등화기에 비해 채널 특성을 신속히 제거할 수 있도록 빠르고 정확히 수렴하고 비선형적 특성을 효과적으로 제거함을 보여준다.





그림 4. 채널 I의 여러 가지 등화기 통과후의 QPSK Constellation 비교




그림 5. 채널 I에서의 오류확률 비교 오차

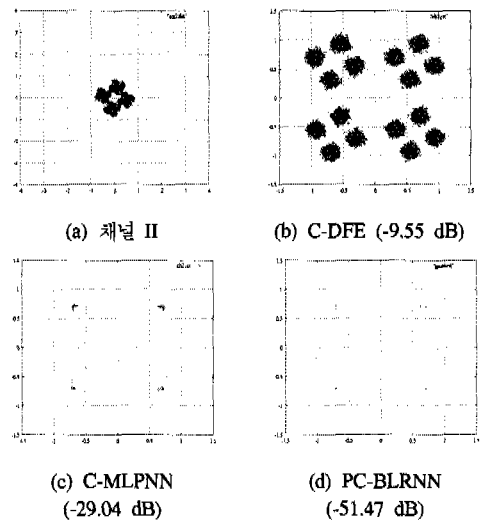


그림 6. 채널 II의 여러 가지 등화기 통과후의 QPSK Constellation 비교




그림 7. 채널 II 에서의 오류확률 비교 오차

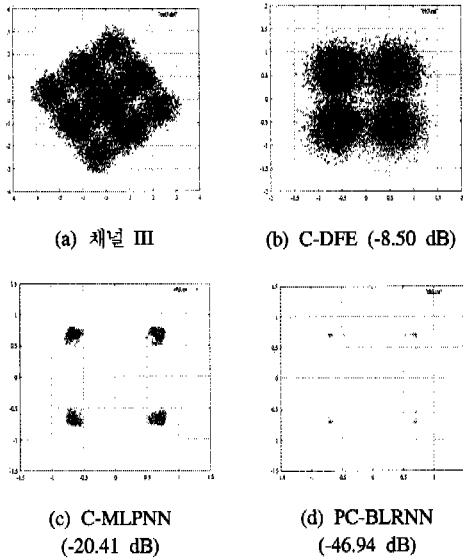


그림 8. 채널 III의 여러 가지 등화기 통과후의 QPSK Constellation 비교.




그림 9. 채널 III 에서의 오류확률 비교 오차

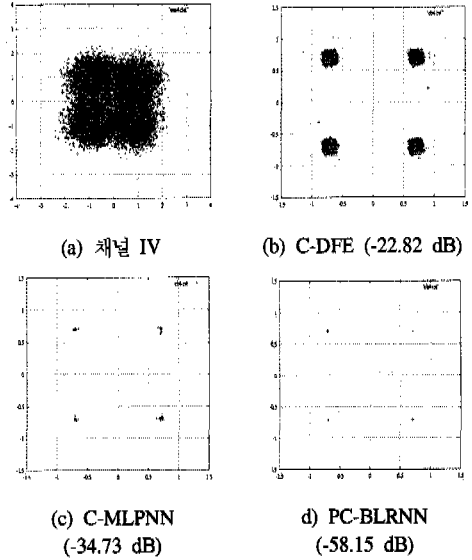


그림 10. 채널 IV의 여러 가지 등화기 통과후의 QPSK Constellation 비교




그림 11. 채널 VI 에서의 오류확률 비교 오차

참고 문헌

- [1] C. Drewes, R. Hasholzner, I. Ruge, "Breitbandige Teilnehmeranschlüsse uber Funk," *Telekom praxis*, Vol. 73, No. 12, pp.23-32, Dec. 1996.
- [2] F. G. Stremler, "Introduction to Communication Systems," pp 578-579, 3rd edition, *Addson-Wesley*, 1990.
- [3] C. Drewes, R. Hasholzner, J. S. Hammer-schmidt, "Adaptive Equalization for wireless ATM," *13th Int. Conf. DSP' 97*, Santorini, Greece, July 1997.

[4] S. Benedetto, E. Biglieri, and V. Casterllani, *Digital Transmission Theory*, Prentice-Hall Inc., New Jersey, 1987.

[5] C. Tseing and E. Powers, "Nonlinear Channel Equalization in Diigital Satellite Systems," *Conf. Record fo GLOBECOM'93*, pp.1639-1643, Dec. 1993.

[6] P. Chang and B. Wang. "Performance of adaptive Volterra equalizer on nonlinear saltellite Channels Using Multilayer Neural Networks," *IEEE Journal on Selected Areas in Communications*, Vol. 13, No. 2, Feb. 1995.

[7] N. Bencenuto et. al, "Nonlinear Satellite Radio Links Equalizer Using Blind Neural Networks," *Proc, ICASSP 91*, pp.1521-1524, July 1991.

[8] O. Nerrand et. al. "Traning Recurrent Networks : Why and How? An Illustration in Dynamical Process Modeling," *IEEE Tr. on Neural Networks*, Vol. 5. No.2, March 1994.

[9] V. Mathews, "Adaptive polynomial Filters," *IEEE signal processing magazine*, pp.10-26, July 1991.

[10] E. J. Violette, R. H. Espeland, R. O. DeBolt, and F. Schwering, "Millimetre-wave propagation at street level in an urban enviroment," *IEEE Trans. Geosc. and Remote Sensing*, vol. 26, pp.368-380, May. 1988.

[11] J. N. H. Grond, H. P. J. Hecker, and C. Shepherd, "Broadband on the move," *Int. Conf. on Intergrated Broadband Services and Networks*, London, pp. 206-210, Oct. 1990.

[12] Dong C. Park and Y. Zhu, "BiLinear Recurrent Neural Networks," *Proc. of ICNN'94*, pp. 1459-1464, June 1994.

[13] M. Mohler and W. Kolodziej, "An Overview of Bilinear System Theory and Application," *IEEE Tr. on Sys., Man and Cybrn.*, Vol 10, No, 10. pp. 683-687, 1980

[14] D. C. Park., T. K. Jung "C-BLRNN을 이용한 위성 채널 등화기," *한국 통신학회 논문지*, Vol. 25, No. 3, 1999.

[15] E. D. Karnin, "A Simple Procedure for Pruning Back-propagation Trained Neural Network," *IEEE Trans. On Neural Network*, Vol. 1, No. 2 June 1990.

[16] M. C. Mozer and P. Smolensky, "Skeleto-nization: A technique for trimming the fat from a network via relevance assessment," in *Advances in Neural Information Processing(1)*, D.S. Touretzky, Ed. Morgan Kaufmann, pp. 177-185, 1989.

박 동 철(Dong-chul Park)

정회원



1980년 : 서강대학교 전자공학과 (학사)

1982년 : 한국과학기술원 전기 및 전자공학과 (석사)

1990~1994년 : Florida International University(State University of Florida at Miami)

Dept. of Electrical and Computer Engineering (조교수)

1994~현재 : 명지대학교 정보제어공학과 부교수

이 실(Sill Lee)

정회원



1999년 2월 : 명지대학교

제어계측공학과 졸업

2001년 2월 : 명지대학교

정보제어공학과 석사

2001년3월~현재 : (주)LG 중견