

C-BLRNN을 이용한 위성채널 등화기

정희원 박동철*, 정태균**

Satellite Communication Equalizer Using Complex Bilinear Recurrent Neural Network

Dong-Chul Park*, Tae-Kyun Jung** *Regular Members*

요약

C-BLRNN을 이용한 위성 통신 채널 등화기가 본 논문에서 제안되었다. BLRNN은 쌍선형 다항식에 기초한 것으로 MLPNN형태의 신경망보다 비선형 시스템의 모델링에서 탁월한 성능을 보여왔으므로, 매우 비선형적이고 시계열적 특성을 가지는 위성 채널 등화기에 적용될 수 있다. C-BLRNN 등화기가 M-PSK 신호에 대해 Volterra 등화기, DFE 등화기, C-MLPNN 등화기등과 실험적으로 비교되었는데, 그 결과, 기존의 등화기들 보다, 제안된 C-BLRNN 등화기가 MSE 와 BER의 성능에서 모두 매우 향상된 결과를 보여주었다.

ABSTRACT

Equalization of satellite communication using Complex-Bilinear Recurrent Neural Network(C-BLRNN) is proposed in this paper. Since the BLRNN is based on the bilinear polynomial and it has been more effectively used in modeling highly nonlinear systems with time-series characteristics than multi-layer perceptron type neural networks(MLPNN), it can be applied to satellite equalizer. The proposed C-BLRNN based equalizer for M-PSK with a channel model is compared with Volterra filter Equalizer, DFE, and conventional Complex MLPNN Equalizer. The results show that the proposed C-BLRNN based equalizer gives very favorable results in both of MSE and BER criteria over other equalizers.

I. 서론

인공위성의 제한된 출력상황에서 고속의 데이터 전송을 위해 효과적인 대역폭의 사용과 출력의 유용한 활용은 최근 활발한 연구가 진행되고 있는 위성채널을 통한 디지털 통신에서의 주요한 연구 관심사이다^{[1][3]}. 위성 통신에서 인공위성내의 증폭기는 고효율을 얻기 위해서 포화영역 내지는 그 근처에서 작동하는데, 이 포화영역 특성은 위성채널의 비선형 왜곡을 초래한다. 고속 데이터 전송을 위해서는 고율변조(higher-level modulation)가 필요하기

때문에 비선형 왜곡이 위성 시스템의 동작을 제한하는 주된 요소이다. 비선형 특성을 가진 채널에서 선형 신호처리는 왜곡을 보상하는데 많은 제한을 가지고 있기 때문에 비선형 신호처리가 요구된다. 이를 위한 방법으로는 위성증폭기의 선형화 기법과 잡음이나 비선형성에 적용하는 비선형 등화기의 디자인 등이 있다. 여러가지 비선형 등화기(Equalizer) 기술이 보고되고 있는데, 이는 두 가지 부류로 나눌 수 있다. 이는 Volterra 필터에 기반한 기술과^{[1][4]} 신경망에 기반한것이다^{[2][5]}. Volterra filter 에 기반한 접근방법은 선형필터와 비교할 때 SNR 측면에서 많은 향상을 보여왔으나 여기에는 구현상의 어

* 명지대학교 정보제어공학과 정보통신교육센터(parkd@wh.myongji.ac.kr),

** 명지대학교 정보제어공학과(circuit@icrl.myongji.ac.kr)

논문번호: 99090-0308, 접수일자: 1999년 3월 8일

※ 본 연구는 정보통신부지원 정보통신 우수 시범학교 지원 사업에 의해 수행되었음




그림 1. 위성통신채널

려움이 뒤따랐다. 반면 신경망에 기반한 기술 또한 비선형 시스템을 모델링 하는데 큰 효과를 보이고 있을 뿐만 아니라 단순한 구조와 학습의 간편함 때문에 유용하기 때문에, 적용된 여러 분야에서 보여 지듯이 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 위성통신용 등화기 문제에 잘 적용 될 수 있다. 이전의 등화기에 적용된 신경망은 다층구조 perceptron 형태의 단순한 구조의 신경망 형태였다. 그러나 최근의 연구에서 보여지듯이 회귀성분을 가진 신경망이 비선형 시스템의 모델링이나 시계열 예측에 더욱 효과적임을 보여주고 있다⁶⁾.

이 논문에서는 쌍선형 다항식에 기반한 새로운 신경망을 이용하여 적응형 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 신경망이⁷⁾ 표현할 수 있는 시스템을 경제적인 방법으로 추정할 수 있다.

II. 채널모델(Channel Model)

위성채널은 그림 1에서와 같이 두개의 radio link, 즉 uplink 와 downlink에 의해 연결된 TX 와 RX 의 두 구조로 이루어진다. 위성 링크에서 위성으로의 변조된 입력신호는 HPA(High Power Amplifier)인 TWT(traveling Wave Tube)에 의해 증폭된다. 위성의 제한된 출력 때문에 이 증폭기는 일반적으로 최대효율을 얻기 위해서 포화영역 근처에서 작




그림 2. TWTA의 입력/출력 특성

동된다. 이런 이유로 TWTA(TWT Amplifier) 는 크기와 위상의 비선형 왜곡을 일으킨다. TWTA의 전형적인 입력-출력사이의 특성에 대한 그래프는 그림 2에 나타나 있고 다음 두 식에 의해 표현될 수 있다⁸⁾.

$$A(r) = \frac{\alpha_a r}{1 + \beta_a r^2} \tag{1}$$

$$\phi(r) = \frac{\alpha_\phi r^2}{1 + \beta_\phi r^2}$$

여기서 r 은 TWTA 의 입력신호의 크기이고, $A(r)$ 은 AM-AM 변환으로 표현되는 r 의 함수이며, ϕ 는 AM-PM 변환에 관한 함수이다. 한편 $\alpha_a, \beta_a, \alpha_\phi, \beta_\phi$ 는 TWTA 에 의해 결정되는 변수들이다. TWTA가 비메모리 비선형 시스템으로 모델링된다고 하더라도 선형 TX필터와 RX 필터의 delay 소자 때문에 메모리를 갖는 비선형 채널 시스템이 된다. 채널을 통과한 symbol-rate sampling은 Volterra series를 사용해서 다음과 같이 나타낼 수 있다^{9,10)}.

$$r(k) = \sum_{i_1=1}^{\infty} \sum_{k_1}^{\infty} \dots \sum_{k_{2i-1}}^{\infty} a_{k-k_1} a_{k-k_2} \dots a_{k-k_i} \cdot a_{k-k_{i+1}}^* \dots a_{k-k_{2i-1}} H_{k_1, \dots, k_{2i-1}}^{(2i-1)} + v(k) \tag{3}$$

$$a(n) = e^{\frac{2\pi(i_n+1/2)}{M}}, \quad i_n = 0, \dots, M-1 \tag{4}$$




그림 3. QPSK 와 8PSK 의 채널 출력 Constellation

여기서 $v(n)$ 은 복소 Gaussian down-link noise 이고 이산입력 이산출력 채널 Volterra 상수 $H_k^{(1)}, H_{k_1, k_2, k_3}^{(3)}, \dots$, 는 symbol a_k 에 비선형 채널 특성을 표현해주는 복소 상수이다. 식 (4) ($M=4, 8$)와 같은 입력 symbol이 비선형 채널을 거치면 채널의 메모리 때문에 현재뿐만 아니라 과거의 신호까지 비선형적인 영향을 미칠 수 있고, 이는 채널의 출력 신호를 왜곡시키고 symbol을 군집형태의 모양으로 만든다. 그림 3은 27dB 의 AWGN 을 가진 TWTA 채널을 통과한 QPSK 와 8PSK symbol을 나타낸 것이다.

III. 복소형 쌍선형 회귀성 신경망

쌍선형 다항식(bilinear polynomial) 은 간단한 회귀성 시스템 모델이다. Volterra 시스템을 포함하는 많은 비선형 시스템은 제한된 정도의 정확도를 가 정하여 쌍선형 다항식에 의해 근사화될 수 있다. 쌍 선형 다항식의 일차원의 입력력을 가진 예에서 입 출력에 대한 관계식은 다음과 같은데, 여기서 사용 되는 쌍선형회귀항은 출력만의 회귀에 비해 고차수 비선형 mapping을 더욱 효과적으로 수행할 수 있게 한다.

$$y[n] = \sum_{i=1}^{N-1} a_i y[n-i] + \sum_{i=0}^{N-1} \sum_{j=1}^{N-1} b_{ij} y[n-j] x[n-i] + \sum_{i=0}^{N-1} c_i x[n-i] \quad (5)$$

여기서 $x[i]$ 는 입력, $y[i]$ 는 출력, 그리고 N 는 회귀도의 차수이다. 차수가 축소된 Volterra series 대신 쌍선형 회귀성 다항식의 출력을 신경망의 은닉층의 출력으로 표현하는 쌍선형 회귀성 신경망 (Bilinear Recurrent Neural Network:BLRNN)의 구조를 얻을 수 있는데, BLRNN 에 관한 보다 자세한 설명은 [11],[12]에서 얻을 수 있다.

다음은 BLRNN의 간단한 설명이다. BLRNN은 N 개의 입력뉴런, M 의 은닉층 뉴런 그리고 $K(=N-1)$ 차의 다항식을 사용한다. 입력신호와 은닉층에서 사용되는 입력신호의 비선형 값들은 다음으로 표현된다.

$$\vec{X}[n] = [x[n], x[n-1], \dots, x[n-K]]^T \quad (6)$$

$$\vec{O}[n] = [o_1[n], o_2[n], \dots, o_M[n]]^T \quad (7)$$

여기서 회귀항은 다음과 같은 $M \times K$ 차의 행렬식이다.

$$Z[n] = \begin{bmatrix} o_1[n-1] & o_1[n-2] & \dots & o_1[n-K] \\ o_2[n-1] & o_2[n-2] & \dots & o_2[n-K] \\ \vdots & \vdots & \ddots & \vdots \\ o_M[n-1] & o_M[n-2] & \dots & o_M[n-K] \end{bmatrix} \quad (8)$$

$$\vec{Z}_p[n] = [o_p[n-1], o_p[n-2], \dots, o_p[n-K]] \quad (9)$$

은닉층의 입력을 위한 입력신호의 계산식은 다음과 같다.

$$s_p[n] = w_p + \sum_{k_1=1}^{N-1} a_p[k_1] o_p[n-k_1] + \sum_{k_1=1}^{N-1} \sum_{k_2=0}^{N-1} b_p[k_1, k_2] o_p[n-k_1] x[n-k_2] + \sum_{k_2=0}^{N-1} c_p[k_2] x[n-k_2] \quad (10)$$

$$= w_p + \vec{A}_p^T \vec{Z}_p^T[n] + \vec{Z}_p[n] \vec{B}_p^T \vec{X}_p^T + \vec{C}_p^T \vec{X}_p^T$$

여기서 w_p 는 바이어스 뉴런의 연결강도, \vec{A}_p 는 회귀항의 연결강도 벡터, \vec{B}_p 는 쌍선형 회귀항의 연결강도 행렬, 그리고 \vec{C}_p 는 전방향의 연결강도 이다. 여기서 p 는 은닉층의 수이다.

ϕ 를 은닉층의 활성화함수라 한다면, p 차의 은닉층의 출력은 다음과 같다.

$$o_p[n] = \phi(s_p[n]) \quad (11)$$

한편, 은닉층에서 출력층까지는 feedforward형식의

전형적인 신경망의 구조와 유사하다. 시간 n 에서 출력층의 l 번째의 출력을 $o_l[n]$ 라고 하면 이는 다음과 같다.

$$o_l[n] = \phi \left(\sum_{p=0}^{N_p-1} w_{lp} o_p[n] \right) \quad (12)$$

여기서 w_{lp} 는 은닉층에서 출력층으로의 연결강도이다.

이제 BLRNN의 복소형태인 Complex-BLRNN (C-BLRNN)은 다음과 같이 요약되는데, 먼저 복소형태의 신호를 처리하기 위해 다음과 같은 활성화 함수가 정의된다^[13]:

$$\phi(z) = \text{sgm}(z_R) + j \text{sgm}(z_I) \quad (13)$$

위에서 $\text{sgm}(z)$ 는 일반적인 sigmoid 함수이다.

주어진 C-BLRNN에 대한 복소형태의 학습 알고리즘은 기본적으로 steepest gradient descent 방법에 의해 구해진다. 먼저 그 error 함수는 다음으로 정의 되는데,

$$E[n] = \frac{1}{2} \sum_{i=1}^{N_o} (d_i[n] - o_i[n]) (d_i^*[n] - o_i^*[n]) \quad (14)$$

여기서 N_o 는 출력 뉴런의 수, ‘*’는 복소수쌍(complex conjugate), 그리고 $d_i[n]$ 은 n 번째 데이터에 대한 목표를 나타낸다. 이 error함수로부터 복소형 연결강도(weight)를 고려한 조정식은 다음과 같이 유도된다.

$$w_{lp}[n+1] = w_{lp}[n] - \frac{1}{2} \eta \left(\frac{\partial E[n]}{\partial w_{rp}[n]} + j \frac{\partial E[n]}{\partial w_{ip}[n]} \right) \quad (15)$$

여기에서 실수에 대한 error 함수의 미분은 chain rule을 적용하여 다음과 같이 나타낼 수 있다.

$$\frac{\partial E[n]}{\partial w_{rp}} = \frac{\partial E[n]}{\partial o_i[n]} \frac{\partial o_i[n]}{\partial s_i[n]} \frac{\partial s_i[n]}{\partial w_{rp}} + \frac{\partial E[n]}{\partial o_i^*[n]} \frac{\partial o_i^*[n]}{\partial s_i^*[n]} \frac{\partial s_i^*[n]}{\partial w_{rp}} \quad (16)$$

위 식의 각각 도함수로부터 실수와 허수에 대한 error함수의 미분식은 다음으로 주어진다

$$\begin{aligned} \frac{\partial E[n]}{\partial w_{rp}} = & - (d_i^*[n] - o_i^*[n]) \phi'(s_i[n]) o_p[n] \\ & - (d_i[n] - o_i[n]) \phi'(s_i^*[n]) o_p^*[n] \end{aligned} \quad (17)$$

$$\begin{aligned} \frac{\partial E[n]}{\partial w_{ip}} = & -j (d_i^*[n] - o_i^*[n]) \phi'(s_i[n]) o_p[n] \\ & + j (d_i[n] - o_i[n]) \phi'(s_i^*[n]) o_p^*[n] \end{aligned} \quad (18)$$

위의 두 식으로부터 다음과 같은 복소형태의 미분식을 얻어낼 수 있고,

$$\begin{aligned} \frac{\partial E[n]}{\partial w_{rp}} + j \frac{\partial E[n]}{\partial w_{ip}} = & -2 (d_i[n] - o_i[n]) \phi'(s_i^*) o_p^*[n] \end{aligned} \quad (19)$$

이식을 식(15)에 대입하면, 다음의 복소형태의 연결강도 학습에 관한 공식이 성립된다.

$$\begin{aligned} w_{lp}[n+1] = & w_{lp}[n] \\ & + \mu_w (d_i[n] - o_i[n]) \phi'(s_i^*[n]) o_p^*[n] \end{aligned} \quad (20)$$

같은 방법으로 구해지는 a, b, c 항에 대한 학습식은 다음과 같다

$$\begin{aligned} c_{pi}[n+1] = & c_{pi}[n] + \mu_c \left[\sum_{i=1}^{N_o} (d_i[n] - o_i[n]) \phi'(s_i^*[n]) w_{ip}^* \right] \cdot \phi(s_i^*[n]) x_i^* \end{aligned} \quad (21)$$

$$\begin{aligned} a_{pi}[n+1] = & a_{pi}[n] + \mu_a \left[\sum_{i=1}^{N_o} (d_i[n] - o_i[n]) \phi'(s_i^*[n]) w_{ip}^* \right] \cdot \phi(s_i^*[n]) z_i^* \end{aligned} \quad (22)$$

$$\begin{aligned} b_{pij}[n+1] = & b_{pij}[n] + \mu_b \left[\sum_{i=1}^{N_o} (d_i[n] - o_i[n]) \phi'(s_i^*[n]) w_{ip}^* \right] \cdot \phi(s_i^*[n]) z_i^* x_i^* \end{aligned} \quad (23)$$

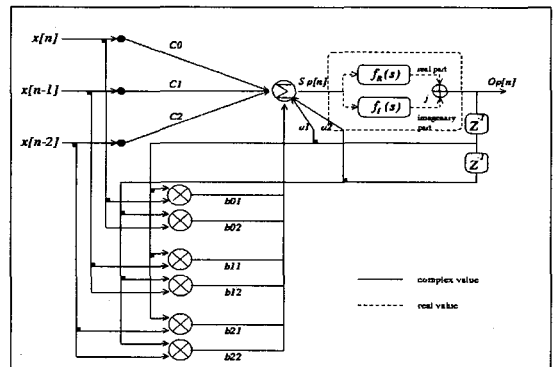


그림 4. 간단한 C-BLRNN의 구조

그림 4는 C-BLRNN(Complex Bilinear Recurrent Neural Network)의 간단한 예이다.

IV. 실험 및 결과

실험에 사용하기 위한 비선형 위성채널의 모델링을 위해 4개의 탭의 1차, 3차, 5차 kernel의 Volterra series^[3,10]이 사용되었고, 여기에 사용된 Volterra Series 계수는 Table 1에 나타나 있다. 전송된 데이터 symbol은 무작위 추출된 M-PSK 신호이다. TWTA 를 통과한 전송신호는 또한 AWGN 으로 더럽혀지게 된다. 그래서 수신단 측에서 받는 전송신호는 크기와 위상이 왜곡된 symbol을 수신하게 되고, 이는 그림 3에서와 같은 성단모양의 군집을 이루게 된다. 각 실험에서 무작위의 30,000 개의 symbol이 등화기의 학습에 사용되고, 다른 1,500,000개의 symbol로 등화기의 성능 측정에 사용되었다.

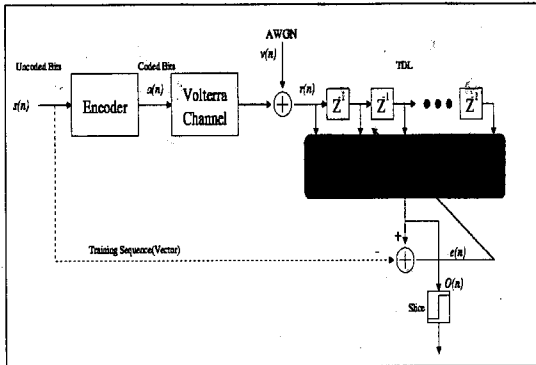


그림 5. 위성채널 등화기의 구성도

C-BLRNN에 기초한 위성채널용 등화기는 일반적으로 사용되는 Volterra 등화기, DFE(Decision Feedback Equalizer)와 Complex MLPNN 등화기와 비교되었다. 그림 5은 등화기 개발을 위한 전체 구성도이고, 실험 결과는 MSE, BER로 나타내었다.




그림 6. QPSK 시스템의 학습곡선

비교된 등화기의 구조를 표현하기 위해 신경망 기반의 C-MLPNN 와 C-BLRNN 등화기는 C-MLPNN(n_b, n_1, n_2, n_o)와 C-BLRNN(n_b, n_1, n_o)로 표현한다. 여기서 n_b 는 forward taps 의 수, n_1 는 첫 번째 은닉층의 뉴런수, n_2 는 두 번째 은닉층의 뉴런수, 그리고 n_o 는 출력 수를 나타낸다. 같은 방법으로 LMS형 DFE(n_f, n_b)로 정의하고 n_f 와 n_b 는 전방향화 feedback 탭수를 나타낸다. M-PSK 시스템에 사용된 등화기 구조는, 5-tab 3rd-order Volterra 등화기, C-MLPNN(5,10,8,1), DFE(5,4), 그리고 C-BLRNN(5,2,1)이 실험에 사용되었다.

실험에 사용된 각 등화기 구조의 계산된 연결강도의 수는 Volterra, C-MLPNN, and C-BLRNN가 각각 130, 138, 그리고 60 이다. 그림 6에 나타난 바와 같이 C-BLRNN 의 수렴 속도는 다른 알고리즘에 비해 월등히 앞서는 것을 볼 수 있고 최종 MSE에서도 가장 작은 값을 갖는다.

실험에서 사용된 각 등화기의 연산 속도를 비교하기 위해 8-PSK 신호 1개를 한번 학습하는데 소요되는 CPU 시간을 측정(Pentium-400 Dual System)하

표 1. 사용된 Volterra Series 계수

Linear Part	3rd Order Nonlinearities	5th Order Nonlinearities
$H_0^{(1)} = 1.22 + j 0.646$	$H_{002}^{(3)} = 0.039 + j 0.022$	$H_{00011}^{(5)} = 0.039 + j 0.022$
$H_1^{(1)} = 0.063 - j 0.001$	$H_{330}^{(3)} = 0.018 - j 0.018$	
$H_2^{(1)} = -0.024 - j 0.014$	$H_{001}^{(3)} = 0.0355 - j 0.035$	
$H_3^{(1)} = 0.036 + j 0.031$	$H_{003}^{(3)} = -0.040 + j 0.009$	
	$H_{110}^{(3)} = -0.01 + j 0.0017$	

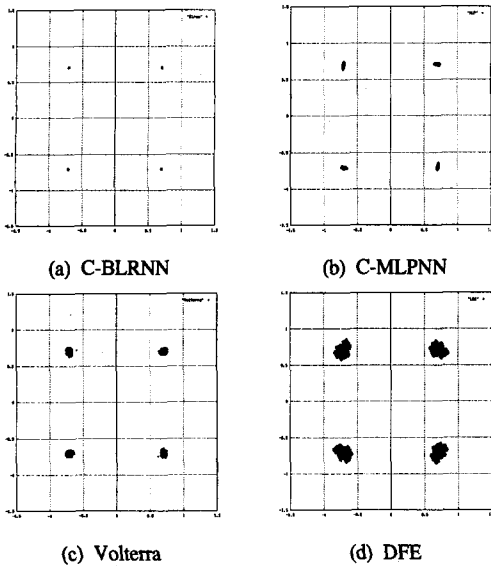


그림 7. 등화기 통과후의 QPSK Constellation 비교

표 2. 한주기에서의 계산량 비교 (CPU 시간 $\times 10^{-3}$ ch)

DFE	Volterra	C-MLPNN	C-BLRNN
0.36	3.08	2.24	1.21

였는데, 그 결과가 표 2에 주어져 있다. 표 2에서 볼 수 있듯이 C-BLRNN은 Volterra나 C-MLPNN보다 매우 적은 계산량만 필요함을 알 수 있어 실제 시스템에서 실시간 응용에 많은 장점이 있음을 알 수 있다.

그림 7은 AWGN(SNR=27dB)일때 C-BLRNN, C-MLPNN, Volterra filter, DFE의 QPSK 시스템에 관한 constellation 을 보여주고 있다.

그림 7에서 보여지듯이 C-BLRNN은 거의 완벽한 결과를 나타낸다. 이것은 C-BLRNN이 위성채널의 TWTA를 통하는 QPSK 시스템에서 가장 적절하게 이용될 수 있음을 알 수 있다. 위의 결과에서 볼 때 신경망의 비선형 모델링 기능 때문에 C-BLRNN과 C-MLPNN는 Volterra filter나 DFE 보다 잡음의 제거기능이 월등한 것으로 볼 수 있다.

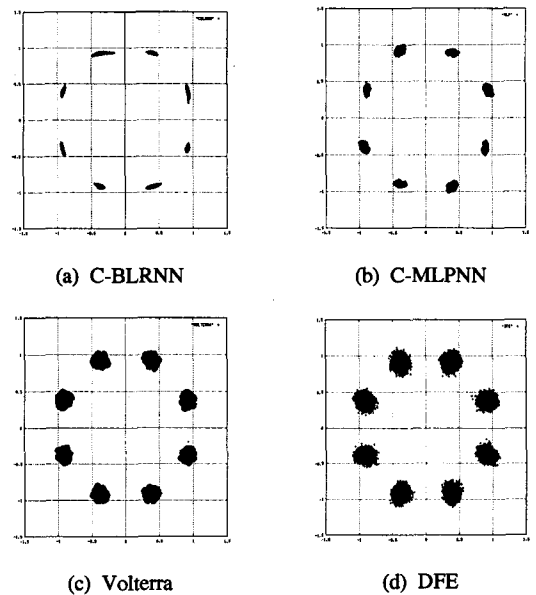


그림 9. 등화기 통과후의 8PSK Constellation 비교




그림 8. 비선형 등화기 성능의 QPSK 오류확률 비교




그림 10. 비선형 등화기 성능의 8PSK 오류확률 비교

더욱이 C-BLRNN의 회귀항과 교차항은 C-MLP에 비해서 위성채널의 지연효과를 충분히 제거해주고 있다. 각각의 잡음의 SNR당 비트 오차율은 1,000,000개의 symbol 테스트후 취해지는데, 그림 8에서 보여지듯이 C-BLRNN은 BER=10⁻⁴에서 Volterra, C-MLP, DFE 보다 각각 0.8dB, 1.2dB, 1.8dB의 향상을 가져왔다.

그림 9 와 10 은 8PSK에 대한 실험의 결과인데, QPSK의 경우에서와 같이 다른 등화기에 비해 향상된 결과를 보여주고 있다.

V. 결론

이 논문에서 우리는 C-BLRNN(Complex-Bilinear Recurrent Neural Network)을 이용한 비선형 위성 채널 등화기의 개발을 제안하였다. 위성채널은 Volterra series와 계산된 계수로 모델링 하였다.

C-BLRNN은 MLPNN 형태의 신경망의 비선형 모델링 기능과 Volterra series의 고차수 특성을 동시에 지니고 있다. 따라서, C-BLRNN 은 효과적으로 TWTA 에 의해 발생하는 메모리와 비선형적인 특성을 가지는 위성채널의 등화기에 적용될 수 있다. QPSK와 8PSK 시스템을 위한 등화기의 실험에서 보여지듯이, C-BLRNN을 이용한 등화기는 Volterra, DFE, C-MLPNN에 비해 빠른 학습 속도와 비선형성의 효과적인 제거를 보인다.

참고 문헌

[1] S. Benedetto, E. Biglieri, and V. Castellani,

Digital Transmission Theory, Prentice-Hall Inc., New Jersey, 1987.

[2] P. Chang and B. Wang, "Adaptive Decision Feedback Equalization for Digital Satellite Channels Using Multilayer Neural Networks," *IEEE JOURNAL ON SELECTED AREAS IN COMMUNICATIONS*, V.13, No.2, Feb. 1995.

[3] A. Gutierrez and W. Ryans, "Performance of adaptive Volterra equalizers on nonlinear satellite channels," *Proc. IEEE Int'l Conf. Commun*, V.1, pp.448-492, Seattle, Washington, 1995.

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

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

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


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

[8] A. Saleh, "Frequency-Independent and Frequency-Dependent Nonlinear Models of TWT Amplifiers." *IEEE Trans, on Communi-*

cations, V. COM29, No. 11, pp. 1715-1720, Nov. 1981.

- [9] S. Benedetto et. al, "Modeling and evaluation of nonlinear satellite links - A Volterra series approach," *IEEE Trans Aerosp, Electron Syst*, AES-15, pp. 494-506, July 1979.
- [10] S. Benedetto and E. Biglieri, "Nonlinear equalization of digital satellite channels," *IEEE Trans, J, Select. Areas Commun.*, vol. SAC-1 pp.57-62, Jan. 1983.
- [11] Dong C. Park and Y. Zhu, "BiLinear Recurrent Neural Network", *Proc. of ICNN'94*, pp 1459-1464, June 1994.
- [12] M. Mohler and W. Kolodziej, "An Overview of Bilinear System Theory and Applications," *IEEE Tr. on Sys., Man, and Cybrn.*, Vol 10, No.10, pp.683-687, 1980
- [13] N. Benvenuto and F. Piazza, "On the complex backpropagation algorithm," *IEEE Trans. on Signal Processing*, V.40, No.4, pp.967-969, April 1992.

정 태 균(Tae-Kyun Jung)




1997년 2월 : 명지대학교 제어계
측공학과 학사
1999년 2월 : 명지대학교 정보제
어공학과 석사
1999년 3월~현재 :
(주)삼성반도체근무

<주관심 분야> 신경망, DSP 응용

박 등 철(Dong-Chul Park)

정회원



1980년 2월 : 서강대학교 전자공
학과(공학사)
1982년 2월 : 한국과학기술원
전기 및 전자공학과
(공학석사)
1990년 6월 : Ph.D in Electrical
Engineering University
of Washington at Seattle

1990년 8월~1994년 2월 : Florida Int'l Univ. 조교수(The State Univ. of Florida at Miami)

1994년 3월~현재 : 명지대 정보제어공학과 부교수

1997년~현재 : IEEE Tr. on Neural Networks Associate Editor

1999년~현재 : IEEE Senior Member

<주관심 분야> 신경망 알고리즘개발, 음성인식, 신경망의 통신 시스템에의 응용.