

# 칼만필터로 훈련되는 순환신경망을 이용한 시변채널 등화

## Equalization of Time-Varying Channels using a Recurrent Neural Network Trained with Kalman Filters

최종수, 권오신\*  
(Jongsoo Choi and Oh-Shin Kwon)

**Abstract :** Recurrent neural networks have been successfully applied to communications channel equalization. Major disadvantages of gradient-based learning algorithms commonly employed to train recurrent neural networks are slow convergence rates and long training sequences required for satisfactory performance. In a high-speed communications system, fast convergence speed and short training symbols are essential. We propose decision feedback equalizers using a recurrent neural network trained with Kalman filtering algorithms. The main features of the proposed recurrent neural equalizers, utilizing extended Kalman filter (EKF) and unscented Kalman filter (UKF), are fast convergence rates and good performance using relatively short training symbols. Experimental results for two time-varying channels are presented to evaluate the performance of the proposed approaches over a conventional recurrent neural equalizer.

**Keywords :** recurrent neural network, extended kalman filter, unscented kalman filter, channel equalization, time-varying channel.

### I. 서론

통신시스템에서 전송신호는 멀티페스 전달 지역으로 인하여 발생하는 심볼간 간섭(intersymbol interference, ISI)에 의해 손상된다. 고속 디지털 통신 시스템에서 채널 대역폭의 효율적인 이용은 ISI에 대해서 제한을 받는다. 일반적으로 ISI의 영향을 완화시키기 위해 등화기(equalizer)가 수신단에 이용된다. 디지털 통신 시스템의 등화에 널리 이용되고 있는 선형 등화기는 deep spectral nulls 또는 왜곡(distortion)이 심한 채널에 대하여 성능이 좋지 않다[1]. 따라서, ISI가 심한 경우 비선형 등화기인 결정되며 등화기(decision feedback equalizer, DFE)가 널리 이용되며, 동일 수준의 복잡도를 갖는 선형 등화기에 비해 성능이 우수한 것으로 잘 알려져 있다[2].

신경망(neural networks)과 DFE가 결합된 결정되며 등화기[3]는 기존 DFE와 결정되며 등화기이 없는 신경망 등화기와 비교해 수렴 속도 및 평균제곱오차 (mean-squared error, MSE) 면에서 향상된 성능을 얻을 수 있다. 이것은 신경망이 역채널 모델의 비선형 사상을 제공하며 수신 데이터에 포함된 불확실성을 처리할 수 있기 때문이다. 다중 퍼셉트론(multiplayer perceptrons, MLP)이나 RBF(radial basis function) 신경망과 같은 전향신경망(feedforward neural networks)은 구조적 간편성 때문에 등화기 설계에 많이 이용되고 있다[4,5]. 그러나, 최근의 연구 결과들은 순환신경망(recurrent neural networks)[6]이 비선형 시스템 모델링 및 시계열 신호 예측 등의 응용에서 전향신경망보다 우수함을 보여주고 있다. 통

신 시스템에서도 채널 등화에 순환신경망이 최근 널리 이용되고 있다[7,8,9,10].

한편, 역전달(back-propagation, BP) 알고리즘이나 실시간 순환학습(real-time recurrent learning, RTRL)[11]과 같은 그레디언트 기반 학습 방법이 전향신경망 및 순환신경망 학습에 각각 이용된다. 그레디언트 기반 학습방법의 주요 단점은 수렴속도가 느리고, 만족스러운 채널 등화 성능을 얻기 위해서 많은 훈련 심볼을 필요로 한다는 것이다. Ortiz-Feunes 등[12]은 RTRL을 이용하는 세 종류의 순환신경망 등화기의 성능이 큰 차이가 없고, 결과적으로 RTRL이 순환신경망 등화기의 학습에 적합하지 않음을 지적하였다.

과거에 발표된 대부분의 등화기들은 시불변(time-invariant) 채널을 주로 다루어 왔다. 그러나, 이동통신과 같은 실생활의 통신환경은 페이딩(fading)으로 인하여 시변(time-varying) 특성을 갖는다. 기존의 등화기들이 시불변채널에 대하여 좋은 성능을 보여 주었지만 빠른 페이딩채널에는 적합하지 않다. Liang 등[13]은 시변채널을 위해 적응 격자(adaptive lattice)구조 DFE를 제안하는 등 최근에 시변채널에 대한 다양한 등화기 구조들이 발표되었다[4,14,15]. 페이딩채널의 시변 특성을 불확실성을 갖는 동적 시스템으로 해석 할 수 있다. 전향신경망 등화기[4]가 시변 채널 등화에 응용되었지만, 전향신경망은 구조 자체가 비선형 정적 시스템이므로 시변채널과 같은 동적 시스템을 효율적으로 모델링 하는데 한계가 있다. 따라서, 전향신경망보다 동적 시스템 모델링에 대한 성능이 우수한 순환신경망을 시변채널 등화기에 적용하고자 한다.

이 논문에서는 비선형 등화기로서 사용되는 순환신경망 구조와 시변채널에 대한 빠른 수렴속도와 우수한 추적성능을 보장하는 순환신경망 등화기의 학습 알고리즘을 제안한다. 학습 알고리즘으로서 두 종류의 칼만 필터 즉, 확장 칼만 필터(extended Kalman filter, EKF)와 언센티아드 칼만필터

\* 책임저자(Corresponding Author)

논문접수 : 2002. 8. 29., 채택확정 : 2003. 4. 3.

최종수, 권오신: School of Information Technology & Engineering, University of Ottawa, Canada. (Dr. Kwon is on leave from Kunsan National University.) (jchoi@site.uottawa.ca/kos@kunsan.ac.kr)

※ 본 연구는 군산대학교 BK21학술연구지원비에의해서 일부 지원되었음.

(unscented Kalman filter, UKF)를 적용한다. EKF는 신경회로망의 학습에 널리 이용되며 그레디언트 기반 알고리즘에 비해 빠른 수렴성을 보장하는 것으로 알려져 있다. 그러나, 비선형시스템의 선형 근사화 과정에서 많은 오차를 포함할 수 있으며, 신경회로망 훈련시 Jacobian 행렬의 연산을 필요로 하지 않는 장점을 가지고 있다.

최근, EKF로 훈련되는 순환신경망의 응용들은 많이 발표되었지만 시변 채널에 대한 성능 평가는 아직까지 발표되지 않았다. 더욱이, 최근에 발표된 UKF 알고리즘의 순환신경망에의 응용 또한 발표되지 않았다. 따라서, 이 논문에서는 EKF와 UKF 알고리즘을 순환신경망 등화기의 훈련에 적용하고, 시변채널에 대한 등화 실험을 통해서 두 알고리즘의 성능을 비교 검토한다. 그리고, RTRL을 사용하여 훈련되는 기준의 순환신경망 등화기와의 성능 비교를 통해서 제안한 등화기들의 우수성을 입증한다.

## II. 결정되며 임 순환신경망 등화기

### 1. 결정되며 임 등화기(DFE)

그림 1은 DFE를 갖는 디지털 통신시스템의 일반적인 모델을 보여준다. 정보소스로부터 추출된 시퀀스  $\{s(k)\}$ 가 전송되고, 전송된 심볼들은 부가백색잡음(additive white Gaussian noise, AWGN)에 의해 오염된다. 이와 같은 채널 모델은 다음과 같이 표현된다.

$$r(k) = \sum_{i=0}^{N-1} h_i s(k-i) + v(k) \quad (1)$$

여기에서  $h$ 는 길이가  $N$ 인 채널의 유한 임펄스 응답(finite impulse response, FIR)이다. 그리고  $v(k)$ 는 평균이 0이고 분산이  $\sigma_0^2$ 인 AWGN이다.

DFE는 세 개의 변수에 의해서 결정된다. 즉, 전향 차수  $m$ , 되며 임 차수  $n$  그리고 결정지연  $d$ 이다. 그러므로, DFE로의 입력은 전향 입력  $r(k)=[r(k-1), \dots, r(k-m+1)]^T$ 과 되며 임 입력  $u(k)=[u(k-1), \dots, u(k-n)]^T$ 으로 구성된다. DFE의 출력은  $y(k)$ 이고, 이 출력은 추정 심볼  $\hat{s}(k-d)$ 를 결정하기 위해서 결정장치 (decision device)를 통과한다. 되며 임 차수  $n$ 은 시간  $k$ 에서 등화기의 결정에 공헌하는 전송된 심볼들이 전향 차수  $m=d+1$ 에 대하여  $s(k)=[s(k), s(k-1), \dots, s(k-m-N+2)]^T$ 로 주어지므로 식 (2)와 같이 된다[2,16].

$$n = N + m - d - 2 \quad (2)$$

### 2. 순환신경망 등화기

다양한 종류의 순환신경망(recurrent neural networks, RNN) 구조와 응용이 발표되었다[6]. RNN 구조 중에서 완전연결 순환구조가 통신 시스템의 채널 등화에 널리 응용되고 있다[7, 8, 10]. 이 논문에서는 RNN 모델의 하나로서 동적시스템의 표준 상태공간 모델을 표현할 수 있는 Elman 구조 [17]를 순환신경망 등화기(recurrent neural equalizer, RNE)로 제안한다. 제안하는 RNE 구조는 그림 2에 나타났다. 한 개의 출력 뉴론을 갖는 Elman 신경망 구조의 이산시간 상태공간 방정식은

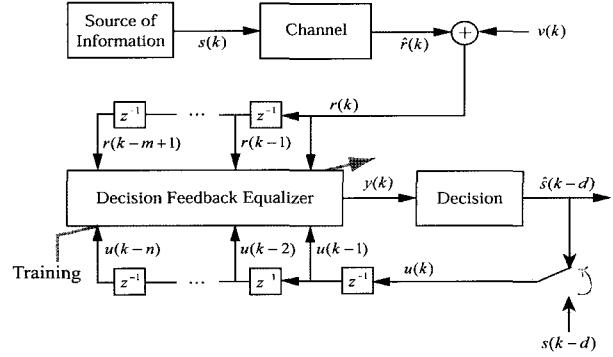


그림 1. DFE로 구성된 디지털 통신 시스템.

Fig. 1. A digital communications system with decision feedback equalizer.

(3),(4)와 같은 형태로 표현된다.

$$\mathbf{x}(k) = \phi(\mathbf{r}(k), \mathbf{u}(k), \mathbf{x}(k-1), W_h) \quad (3)$$

$$y(k) = f(\mathbf{x}(k), \mathbf{w}_o) \quad (4)$$

여기에서  $\mathbf{r}(k)$ ,  $\mathbf{u}(k)$  및  $\mathbf{x}(k)$ 는 각각 수신단에 도착한 입력벡터, 결정되며 임 입력 벡터 및 신경망의 은닉층으로부터 순환되는 상태벡터이다.  $y(k)$ 는 RNN의 출력을 나타낸다.  $W_h$ 는 입력층과 은닉층 사이의 연결강도 행렬이고,  $\mathbf{w}_o$ 는 은닉층과 출력층 사이의 연결강도 벡터이다. 그림 2에서와 같이 RNE가  $p$ 개의 은닉층 뉴론을 갖는다면  $W_h$ 와  $\mathbf{w}_o$ 는 각각 다음과 같이 정의된다.

$$W_h = [\mathbf{w}_1 \mathbf{w}_2 \cdots \mathbf{w}_p]^T \quad (5)$$

$$\mathbf{w}_o = [w_1 w_2 \cdots w_p]^T \quad (6)$$

(5)에서  $\mathbf{w}_i = [w_{0i} w_{1i} \cdots w_{qi}]^T$  ( $i=1,2,\dots,p$ ,  $q$ 는 바이어스 입력을 제외한 총 입력의 개수)이다. (3)과 (4)에서 출력층 뉴론에 적용되는 활성화 함수  $f(\cdot)$ 는 선형함수이고, 은닉층 뉴론에 적용되는 비선형 활성화 함수는  $\psi(\cdot) = \tanh(\cdot)$ 이다. 따라서 바이어스 입력을 포함한 RNE의 동특성은 행렬식 표현으로 다음과 같이 나타낼 수 있다.

$$\mathbf{x}(k) = \psi(W_h [1 \ r^T(k) \ u^T(k) \ x^T(k-1)]^T) \quad (7)$$

$$y(k) = \mathbf{w}_o^T [1 \ x^T(k)]^T \quad (8)$$

$$\hat{s}(k) = D(y(k)) \quad (9)$$

윗 식에서 상수 1은 바이어스 입력, 함수  $D(\cdot)$ 는 결정장치, 그리고  $\hat{s}(k)$ 는 결정장치의 출력으로써 추정된 전송심볼을 나타낸다. RNE의 연결강도는 3절 및 4절에서 기술되는 학습 알고리즘에 의해서 최적화 된다.

## III. 확장 칼만필터를 이용한 학습 알고리즘

RNN의 학습 알고리즘으로서 RTRL[11]과 BPTT[18]가 널리 이용된다. 이와 같은 그레디언트 기반 알고리즘의 주요

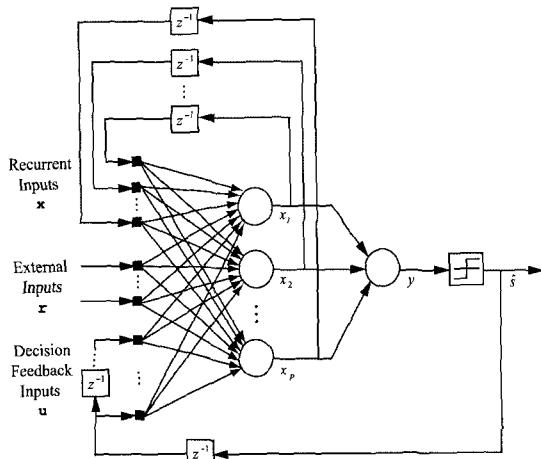


그림 2. 제안한 결정케이블 순환신경망 등화기.

Fig. 2. The Proposed Recurrent Neural Equalizer with Decision Feedback.

단점은 느린 학습속도에 있다. 그러나 고속 디지털 통신시스템에서 빠른 수렴속도가 요구된다.

RNE의 학습 알고리즘은 비선형 시스템에 대한 파라미터 추정 문제로 다룰 수 있다. 비선형 시스템 방정식을 선형화하고 선형화된 시스템에 칼만필터를 적용함으로서 구현되는 확장 칼만필터(이하 EKF)의 특징은 비선형 동적 시스템의 상태에 대한 최소변위 추정기(minimum-variance estimator)라는 점이다. 따라서 EKF는 신경망의 학습에 응용되는 경우 그레디언트에 기초한 학습 알고리즘보다 빠른 수렴속도를 보장한다[6].

결정장치를 제외한 RNE 동특성은 EKF 알고리즘 응용에 적합하도록 바꾸어 표현할 수 있다. EKF 구현에 적합한 RNE의 동특성은 다음의 비선형 이산시간 방정식과 같다.

$$\mathbf{w}(k+1) = \mathbf{w}(k) + \omega(k) \quad (10)$$

$$y_d(k) = \mathbf{h}(\mathbf{w}(k), r(k), u(k), x(k-1)) + v(k) \quad (11)$$

윗 식에서 연결강도 벡터  $\mathbf{w}$ 는 (7)과 (8)에 주어진 연결강도를 이용하여 다음과 같이 재구성되었다.

$$\mathbf{w} = [\mathbf{w}_1^T \mathbf{w}_2^T \cdots \mathbf{w}_p^T]^T \quad (12)$$

프로세스 방정식으로 알려진 첫번째 방정식 (10)은 프로세스 잡음  $\omega(k)$ 에 의해서 오염된 정적 프로세스(stationary process)로 특성화되는 RNE의 상태를 기술한다. 이 때 시스템의 상태는 RNE의 연결강도 벡터  $\mathbf{w}(k)$ 로 주어진다. 측정 방정식으로 알려진 두번째 방정식 (11)은 연결강도  $\mathbf{w}(k)$ , 입력벡터  $r(k)$ , 결정되며 입력  $u(k)$ , 순환노드의 출력  $x(k)$  및 불규칙 측정 잡음  $v(k)$ 의 함수로 표현되는 RNE의 이상적인 출력 (desired output)  $y_d(k)$ 를 나타낸다.  $y_d(k)$ 는 등화기의 학습 모드에서는  $s(k)$ 에 해당하고 결정지향(decision-directed) 모드에서는  $\hat{s}(k)$ 에 해당한다.

EKF를 이용한 RNE(이하, RNE-EKF)의 학습은 모든 관측 데이터를 이용하여 오차 ( $e(k) = y_d(k) - y(k)$ )의 평균제곱오차 (mean-squared error, MSE)를 최소화하는 연결강도 벡터  $\mathbf{w}$ 를

찾는 것이다. RNE를 학습하기 위한 EKF 계산 알고리즘은 다음과 같이 주어진다[19].

$$A(k) = [R(k) + H^T(k)P(k)H(k)]^T \quad (13)$$

$$K(k) = P(k)H(k)A(k) \quad (14)$$

$$\hat{\mathbf{w}}(k+1) = \hat{\mathbf{w}}(k) + K(k)e(k) \quad (15)$$

$$P(k+1) = P(k) - K(k)H^T(k)P(k) + Q(k) \quad (16)$$

벡터  $\hat{\mathbf{w}}(k)$ 는 시간  $k$ 에서 시스템의 상태(즉, RNE의 연결강도)의 추정치를 나타낸다. 이 추정치는 칼만 행렬  $K(k)$ 와 오차  $e(k)$ 의 함수이다.  $K(k)$ 는 오차 공분산 행렬  $P(k)$ , 모든 연결강도에 대한 RNE 출력의 편미분 행렬 (즉, Jacobian 행렬)  $H(k)$  및 환산 행렬  $A(k)$ 의 함수이다. Jacobian 행렬  $H(k)$ 은  $L$ 개의 연결 강도 파라미터와  $N$ 개의 출력노드를 갖는 RNN에 대하여 다음 식과 같이 정의 되며 BPTT 알고리즘[18]에 의해서 계산될 수 있다.

$$H(k) = \begin{bmatrix} \frac{\partial h_1}{\partial \omega_1} & \frac{\partial h_2}{\partial \omega_1} & \dots & \frac{\partial h_N}{\partial \omega_1} \\ \frac{\partial h_1}{\partial \omega_2} & \frac{\partial h_2}{\partial \omega_2} & \dots & \frac{\partial h_N}{\partial \omega_2} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial h_1}{\partial \omega_L} & \frac{\partial h_2}{\partial \omega_L} & \dots & \frac{\partial h_N}{\partial \omega_L} \end{bmatrix} \quad (17)$$

환산 행렬  $A(k)$ 는 측정잡음 공분산 행렬  $R(k)$ , Jacobian 행렬  $H(k)$  및 오차 공분산 행렬  $P(k)$ 의 함수이다. 연결강도 벡터의 추정치 갱신에 공헌하는 행렬  $P(k)$ 는 프로세스잡음 공분산 행렬  $Q(k)$ 에 의해서 증폭된다.

EKF 알고리즘에서 측정잡음 공분산 행렬  $R(k)$ 과 프로세스잡음 공분산 행렬  $Q(k)$ 는 모든 훈련 심볼에 대하여 임의로 정해지고, 근사 오차 공분산 행렬  $P(k)$ 는 학습 시간 전에 초기화된다. 이 행렬들의 초기화는 다음과 같이 표현된다.

$$R(0) = \eta^{-1} \mathbf{I} \quad (18)$$

$$Q(0) = q \mathbf{I} \quad (19)$$

$$P(0) = \varepsilon^{-1} \mathbf{I} \quad (20)$$

EKF 알고리즘의 성능은 초기화시에 결정되어야 할 세 파라미터  $n$ ,  $q$  및  $\varepsilon$ 에 상당히 의존한다. 학습에 이용되는 입출력 데이터가 절적한 범위(예를 들면, 평균이 0이고, 분산이 1인 범위)로 환산된다고 가정하고, 연결강도 값들은 평균이 0인 균등 분포 또는 정규 분포로 부터 취해진 작은 랜덤값들로 초기화된다고 가정하자. 그러면, 안정한 EKF 알고리즘의 수렴을 위해 다음과 같은 지침에 따라 세 파라미터를 결정할 수 있다. 잡음을 포함하고 있는 훈련 데이터에 대하여 좋은 성능을 얻기 위해 학습률  $n$ 은 작은 값으로 정해야 한다. 학습률은 보통 [0.001, 1] 내에서 결정된다. 다음, 프로세스잡음 공분산 행렬을 결정하는 파라미터  $q$ 는 0에 가까운 아주 작은 값으로 결정해야 한다. 이 값은 일반적으로 훈련과정에서  $10^{-1}$ 의 차수를 갖는 값으로부터 시작하여  $10^0$ 의 작은 값으로 담금질(annealing) 된다. 이 과정은 수렴률을 가속화하는데 도움을

주며, 프로세스 잡음을 0이 아닌 값으로 유지함에 따라 (16)의 오차 공분산 행렬 갱신시 발산을 피할 수 있다. 마지막으로, 오차 공분산 행렬은 연결강도를 초기화하는데 이용된 사전지식(a priori knowledge)이 없다고 가정하고 초기화된다. 따라서 오차 공분산 행렬은 초기화를 결정하는  $\varepsilon$  역시 작은 값( $10^{-3}$  또는  $10^{-2}$ )으로 설정한다.

알고리즘의 간략성을 위해 이 논문에서는 BPTT에 대한 절단(truncation) 깊이를 1이라 가정한다. 이 경우 Jacobian 행렬  $H(k)$ 는 다음과 같이 표현된다.

$$H(k) = \mathbf{z}(k)\Psi^T(k) \quad (21)$$

여기에서  $\mathbf{z}(k) = [r^T(k) \ u^T(k) \ x^T(k-1)]^T$ 와  $\Psi(k)$ 는 각각 입력 벡터와 RNE 출력에 대한 역전달 미분계수 벡터이다[20].

#### IV. 엔센티아드 칼만필터를 이용한 학습 알고리즘

EKF 알고리즘은 비선형 시스템의 선형화를 통해서 최적 비선형 추정에 대한 1차 근사화를 제공한다. 이 근사화는 변환된 가우시안 랜덤변수의 사후(posterior) 평균 및 공분산에 큰 오차를 포함할 수 있다. Julier 등[21]에 의해서 처음으로 제안되고 Wan 등[22,23]에 의해서 확장 연구된 엔센티아드 칼만필터(이하, UKF)는 EKF 알고리즘의 단점을 보충해 줄 수 있는 하나의 대안이다[19]. UKF는 가우시안 분포에 대하여 프로세스 오차 및 측정 오차에 대하여 Taylor 시리즈 확장에 의해 2차 근사화를 제공하므로, EKF보다 상태 추정 및 파라미터 추정에 대한 응용에서 우수한 성능을 보였다. 또한 UKF는 EKF 알고리즘 구현시 프로세스 방정식 및 측정 방정식의 선형화시에 필요한 Jacobian 행렬 계산을 필요로 하지 않는 장점이 있다. 이점은 역행렬 계산을 피할 수 있는 간편한 알고리즘 구현을 가져오지만, EKF에 비해 더 많은 계산 시간을 필요로 한다. UKF 알고리즘 유도는 언센티아드 변환(Unscented Transformation, UT)으로부터 출발한다.

##### 1. 언센티아드 변환

언센티아드 변환(UT)은 비선형 변환을 통해서 랜덤변수의 통계적 특성을 계산하는 방법으로, UKF 알고리즘의 근간을 이룬다. 비선형 변환  $y=f(x)$ 를 통해서 랜덤변수  $y$ 를 만들어내는 L-by-1 랜덤변수  $x$ 를 고려하자.  $y$ 의 통계적 특성을 계산하기 위해서  $2L+1$ 개의 시그마 벡터  $\chi_i$ 의 행렬  $\chi$ 는 다음과 같이 표현된다[21].

$$\begin{aligned} \chi_o &= \bar{\mathbf{x}} \\ \chi_i &= \bar{\mathbf{x}} + (\sqrt{(L+\lambda)P_{xx}})_i, \quad i=1,\dots,L \\ \chi_{i-L} &= \bar{\mathbf{x}} - (\sqrt{(L+\lambda)P_{xx}})_{i-L}, \quad i=L+1,\dots,2L \end{aligned} \quad (22)$$

여기에서  $(\sqrt{(L+\lambda)P_{xx}})_i$ 는 square root 행렬(즉, lower-triangular Cholesky factorization)의  $i$ 번째 열이고,  $\bar{\mathbf{x}}$  와  $P_{xx}$ 는  $\mathbf{x}$ 의 평균과 공분산으로 다음과 같이 정의 된다.

$$\bar{\mathbf{x}} = E[\mathbf{x}] \quad (23)$$

$$\mathbf{P}_{xx} = E[(\mathbf{x} - \bar{\mathbf{x}})(\mathbf{x} - \bar{\mathbf{x}})^T] \quad (24)$$

여기에서  $E(\cdot)$ 는 기대치 연산자이다. (22)에서  $\lambda$ 는  $\lambda = \alpha^2(L+\kappa) - L$ 로 정의되는 환산계수이다. 상수  $\alpha(0.001 < \alpha < 1)$ 은  $\bar{\mathbf{x}}$  근처의 시그마 포인트의 퍼짐(spreading) 정도를 결정한다. 상수  $\kappa$  역시 환산계수이며 보통  $(3-L)$ 로 정해진다.  $\kappa$ 는 근사화의 고차 모멘트를 정교하게 조정하기 위한 자유도를 제공하며, 예측오차를 줄이는데 이용된다. 랜덤변수  $\mathbf{x}$ 가 Gaussian 분포를 갖는다면 경험지식을 바탕으로  $L+\kappa=3$ 으로 정하는 것이다. 만일  $\mathbf{x}$ 가 다른 분포를 갖는다면  $\kappa$ 는 다른 값으로 정해져야 한다[21]. 시그마 포인트  $\{\chi_i\}_{i=0}^{2L}$ 는 다음의 비선형 함수를 통해서 전달된다.

$$y_i = f(\chi_i), \quad i=0, 1, \dots, 2L \quad (25)$$

이 식은 비선형 변환 벡터  $y$ 의 평균과 공분산 행렬을 추정하는데 이용되는 벡터 집합을 만들어 낸다.  $y$ 의 평균과 공분산 행렬은 사후 시그마 포인트의 가중 샘플 평균 및 공분산을 이용하여 다음 식과 같이 근사화된다[22].

$$\bar{y} = \sum_{i=0}^{2L} W_i^m y_i \quad (26)$$

$$P_{yy} = \sum_{i=0}^{2L} W_i^c (y_i - \bar{y})(y_i - \bar{y})^T \quad (27)$$

여기에서 가중계수는 다음과 같이 주어진다.

$$\begin{aligned} W_0^m &= \frac{\lambda}{L+\lambda} \\ W_0^c &= \frac{\lambda}{L+\lambda} (1-\alpha^2 + \beta) \\ W_i^m &= W_i^c = \frac{1}{2(L+\lambda)}, \quad i=1,2,\dots,2L, \end{aligned} \quad (28)$$

위 식에서 위첨자  $m$ 과  $c$ 는 각각 평균과 공분산을 의미한다.  $\beta$ 는  $\mathbf{x}$ 의 분포에 관한 사전 지식을 고려하기 위해서 이용되며, 보통  $\beta=2$ 가 가우시안 분포에 대하여 최적의 선택값이다.

##### 2. UKF를 이용한 파라미터 측정

(10)과 (11)에 주어진 RNE의 상태공간 모델로부터, 최소화되는 MSE 비용함수는 다음과 같다.

$$J(\mathbf{w}) = [\mathbf{y} - \mathbf{h}(\mathbf{w}, \mathbf{z})]^T R^{-1} [\mathbf{y} - \mathbf{h}(\mathbf{w}, \mathbf{z})] \quad (29)$$

여기에서 수식의 간략한 표현을 위해 시간  $k$ 는 생략하였다. 프로세스 잡음 공분산  $Q(k) = E[\omega(k)\omega(k)^T]$ 는 수령 속도와 추적 성능에 영향을 미친다. 프로세스 잡음 공분산은 다음과 같이 정의된다.

$$Q(k) = (\lambda_{RLS}^{-1} - 1)P(k) \quad (30)$$

여기에서  $\lambda_{RLS} \in (0,1]$ 는 RLS(recursive least-squares) 알고리즘에서 forgetting계수로 알려져 있다[19].

UKF 알고리즘은 EKF 알고리즘과 달리 Jacobian 행렬 계산을

위해 미분연산을 수행하지 않고 시그마 포인트 전달을 통해서 효과적으로 평가할 수 있다. UKF를 이용한 RNE(이하 RNE-UKF) 알고리즘의 연산 과정은 파라미터 초기화, 시그마 포인트 연산 및 측정 방정식 생성 과정으로 분류할 수 있으며 다음과 같이 요약된다.

- 연결강도 벡터 및 공분산 행렬의 초기화:

$$\hat{\mathbf{w}}(0) = E[\mathbf{w}] \quad (31)$$

$$P(0) = E[(\mathbf{w} - \hat{\mathbf{w}}(0))(\mathbf{w} - \hat{\mathbf{w}}(0))^T] \quad (32)$$

- 시그마 포인트 연산 과정:

$$\Gamma(k) = (L + \lambda)(P(k) + Q(k)) \quad (33)$$

$$\Lambda(k) = [\hat{\mathbf{w}}(k), \hat{\mathbf{w}}(k) + \sqrt{\Gamma(k)}, \hat{\mathbf{w}}(k) - \sqrt{\Gamma(k)}] \quad (34)$$

$$D(k) = \mathbf{h}(\Lambda(k), \mathbf{r}(k), \mathbf{u}(k), \mathbf{x}(k-1)) \quad (35)$$

$$\hat{\mathbf{y}}(k) = \mathbf{h}(\hat{\mathbf{w}}(k), \mathbf{r}(k), \mathbf{u}(k), \mathbf{x}(k-1)) \quad (36)$$

- 측정 방정식 생성 과정:

$$P_{yy}(k) = \sum_{i=0}^{2L} W_i^c (D_i(k) - \hat{\mathbf{y}}(k))(D_i(k) - \hat{\mathbf{y}}(k))^T + \mathbf{R}(k) \\ P_{xy}(k) = \sum_{i=0}^{2L} W_i^c (\Lambda_i(k) - \hat{\mathbf{w}}(k))(\Lambda_i(k) - \hat{\mathbf{w}}(k))^T \quad (37)$$

$$\gamma(k) = P_{wy}(k) P_{yy}^{-1}(k) \quad (38)$$

$$\hat{\mathbf{w}}(k+1) = \hat{\mathbf{w}}(k) + \gamma(k) e(k) \quad (39)$$

$$P(k+1) = P(k) - \gamma(k) P_{yy}(k) \gamma(k)^T \quad (40)$$

RNE-UKF의 연결강도 벡터는 위에 기술한 과정의 반복을 통해서 온라인으로 생성된다.

## V. 시변채널에 대한 성능 평가

### 1. 시변채널 모델

제안한 순환신경망 등화기의 성능은 시변채널 모델을 대상으로 평가된다.

채널모델1: 시변채널 모델은 다음과 같이 표현된다.

$$H(z) = (h_0 + a_0(k)) + (h_1 + a_1(k))z^{-1} + (h_2 + a_2(k))z^{-2} \quad (41)$$

여기에서  $\mathbf{h} = [h_0, h_1, h_2]$  는 채널의 임펄스 응답으로서  $\mathbf{h} = [0.3482, 1,8704, 0.3482]$ 이며, 실제 통신 시스템에서 자주 직면하는 비최소위상 시스템이다[7,9,24]. 채널의 시변 특성을 결정하는  $\mathbf{a}(k) = [a_0(k), a_1(k), a_2(k)]$ 는 채널 임펄스 응답에 더해지는 시변 계수로서 백색 가우시안 잡음 소스가 2차 Butterworth 저역통과 필터를 구동하는 2차 Markov 모델을 응용하여 생성된다[4,13,14,15]. 시뮬레이션에서 차단 주파수가 0.1인 2차 Butterworth 필터가 이용된다. 시변계수  $a_i(k)(i=0, 1, 2)$ 로 이용되는 가우시안 시이퀀스는 표준편차  $\gamma$ 에 의해서 크기가 결정된다. 예를 들면,  $\gamma=0.1$ 과 0.3인 경우에 대한 시변계수에 대한 예를 그림 3(a)에 보였다.

채널모델 2: 두 번째 시변채널 모델의 전달함수는

$$H(z) = a_0(k) + a_1(k)z^{-1} + a_2(k)z^{-2} \quad (42)$$

과 같이 표현되는 페이딩채널이다. 시변계수  $a_i(k)$ 는 시간  $k$ 에 따라 변화하며, 첫번째 채널모델에서와 동일한 방법으로 생성된다. Butterworth 필터의 대역폭은 채널의 상대적 대역폭(페이딩률)을 결정한다. 공칭 2[kHz] 채널, 2000 (symbols/sec)샘플링률 및 0.5[Hz]의 대역폭을 갖는 2차 Butterworth 필터라 가정하면, 시변 채널 임펄스응답의 곡선은 그림 Fig. 3(b)와 같다. 이 페이딩 시나리오는 참고문헌 [4],[13],[15]등에서 채용된 일반적인 방법이다.

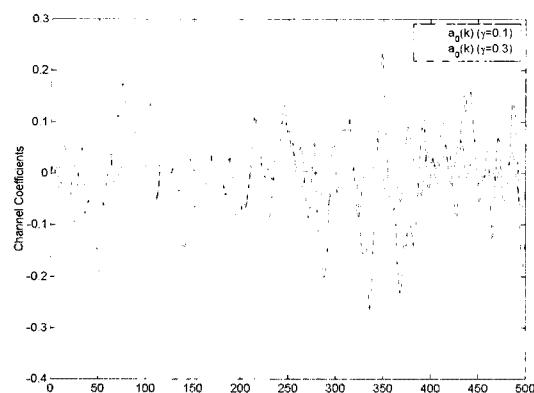
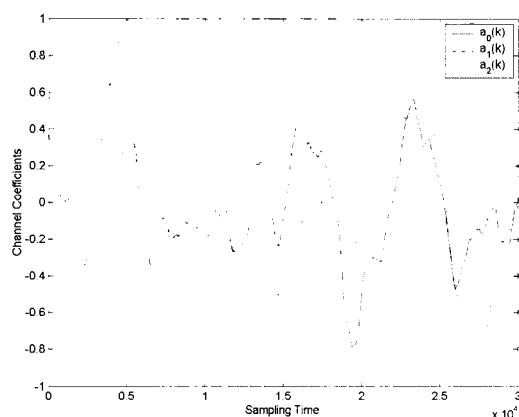
### 2. 성능 평가

5.1절에서 기술한 두 시변채널에 대하여 제안한 두 순환신경망 등화기(RNE-EKF 및 RNE-UKF)의 성능을 비교한다. 또한, 기존의 선형 등화기, DFE 및 신경망 등화기보다 우수한 성능을 보인 순환신경망 등화기인 DFRNE[8]와 제안한 등화기의 성능을 비교한다.

시뮬레이션에서 등화기의 진향차수는  $m=3$ , 결정지연은 전향차수로부터  $d=m-1$ 로 정해진다. RNE-EKF 및 RNE-UKF에 대하여 결정되며 차수는  $n=2$ 로 정해진다. DFRNE는 구조 자체에 결정되며 차수는  $n$ 을 필요로 하지 않는다. 비교를 위해 네트워크 크기는 최대한 유사한 메모리 갯수를 갖도록 할당하였다. 즉, DFRNE는 4개의 뉴론을 할당하였고(32개의 연결 강도), RNE-EKF 및 RNE-UKF는 동일한 네트워크 구조를 이용하며 3개의 은닉층 뉴론과 1개의 출력층 뉴론을 할당하였다(31개의 연결강도). 균등하게 분포하는 BPSK(Binary Phase Shift Keying) 신호로부터 추출된 정보가 이용된다. DFRNE에서 학습률은 안정한 수렴특성을 보장하도록 0.1로 설정하였다. RNE-EKF에 대한 파라미터들은  $\eta=0.1$ ,  $\epsilon=0.01$  그리고  $q=0.01$ 로 설정하였으며, RNE-UKF에 필요한 forgetting 계수는  $\lambda_{RLS}=0.999$ 로 선택하였다. 모든 파라미터들은 시행착오법을 통해서 최적으로 설정되었다.

채널모델1에 대하여 세 순환신경망 등화기(RNE-EKF, RNE-UKF 및 DFRNE)의 수렴 특성을 그림 4에 나타냈다. 이 결과는 그림 3에 보인 바와 같이 시변계수의 크기를 결정짓는 표준편차  $\gamma=0.1$ 을 이용하였고, 100회의 Monte Carlo 시뮬레이션을 수행하여 평균을 취한 것이다. 매 실험마다 모든 등화기에 대하여 다른 BPSK 랜덤 시이퀀스와 랜덤 초기화 연결강도를 적용하여 16[dB]의 SNR에서 수행하였다. 결과를 통해서 제안한 RNE-EKF 및 RNE-UKF는 DFRNE에 비해 매우 빠른 속도로 수렴함을 확인 할 수 있었다. 반면에, RNE-EKF와 RNE-UKF의 수렴특성은 거의 동일한 특성을 보였다. 즉, DFRNE의 MSE값은 3,000개의 심볼을 학습한 후에 정상상태의 MSE값(약 -27[dB])에 도달하였다. 그러나, RNE-EKF 및 RNE-UKF의 MSE 수준은 단지 500개의 심볼을 학습한 후에 -27[dB]에 도달하였으며, -35[dB] 이하에서 정상상태에 도달하였다. 제안한 두 등화기는 빠른 수렴특성으로 인하여 훈련심볼을 현저히 줄일 수 있으므로 정보전송의 효율을 높일 수 있으며, 고속 디지털 통신 시스템에 적합한 특성을 갖는다.

채널모델 1에 대한 비트에러율(Bit Error Rate, BER) 성능을

(a)  $\gamma = 0.1$  and  $0.3$ 

(b) Fading rate = 0.5 [Hz]

그림 3. 시변채널 계수의 예제.

Fig. 3. Profiles of coefficients for time-varying channels.

그림 5에 비교하였다. 시뮬레이션에서 표준편차  $\gamma$ 는 0.1을 적용하였고, SNR은 6[dB]부터 18[dB]까지 2[dB]간격으로 설정하였다. 그림 5(a)와 (b)에 제시한 세 등화기의 BER 성능은 각각 최초의 100 또는 200 개의 심볼을 학습에 사용하였고, 나머지  $10^5$  개의 심볼은 테스트에 사용하였다.

이 결과는 20회의 Monte Carlo 실험을 통해서 얻은 결과이다. 실험에서 모든 등화기 연결강도 벡터는 훈련 심볼을 이용하여 학습과정에서 갱신되며, BER 계산시 즉, 테스트 모드 동안에는 갱신되지 않고 학습과정에서 훈련된 연결강도 벡터를 사용한다. 100개의 훈련심볼을 사용한 결과(그림 5(a))로부터  $10^{-4}$  의 BER 지점에서 RNE-UKF는 DFRNE에 비해 3[dB] 이상, RNE-EKF에 비해 약 2[dB] 정도의 성능을 개선되었음을 확인할 수 있었다. RNE-EKF 역시 DFRNE에 비해 약 1.5[dB]의 성능개선을 보여준다. RNE-EKF와 RNE-UKF는 각각 16 및 18[dB] 이상의 SNR 지역에서 오차없이 전송한 심볼을 완전히 검출할 수 있다. 한편, 200개의 훈련 심볼을 적용한 그림 5(b)에서는 100개의 훈련 심볼을 이용한 경우에 비해 각 등화기 간의 성능 차이가 다소 줄었으나, 제안한 두 등화기는 DFRNE에 비해 우수한 성능을 보였다.

이 결과에서도 RNE-EKF와 RNE-UKF에 비해 우수한 성능을 보인다. 이 결과에서도 RNE-EKF와 RNE-UKF에 비해

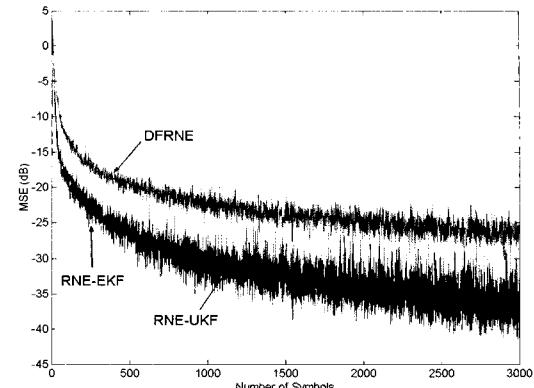


그림 4. 채널모델 1에 대한 등화기들의 수렴특성.

Fig. 4. Convergence properties of equalizers for Channel Model 1.

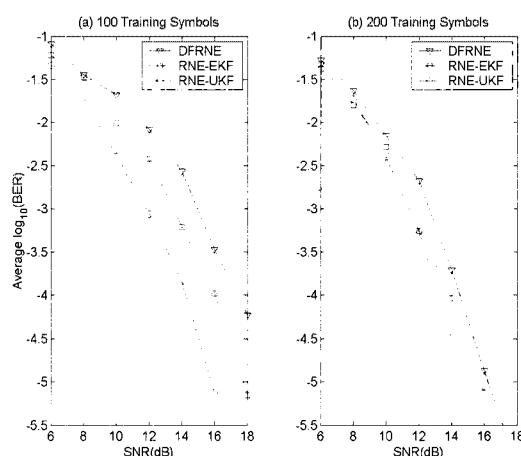


그림 5. 채널모델 1에 대한 등화기들의 BER 성능.

Fig. 5. BER performance of the equalizers for Channel Model 1.

다소 성능이 우수하며, 각각 15[dB] 및 16[dB] 이상에서 완전한 심볼검출 성능을 보인다. 결과적으로, 기존의 DFE 및 전향신경망 등화기들은 만족할 만한 BER 성능을 얻기 위해 수천 개의 훈련심볼을 필요로 하는 것과 대조로, 제안한 등화기들은 단지 수백 개의 훈련 심볼을 이용하여 만족할 만한 BER 성능을 얻을 수 있다.

다음 실험에서, 채널모델 1에 대하여 시변계수 크기 변화에 대한 세 등화기의 강인성을 평가하였다. 실험은 SNR을 16 [dB]에 고정시키고  $\gamma$  값을 0.15부터 0.3까지 변화시켜 BER 성능을 비교하였다. 앞서 언급한 바와 같이 표준편차  $\gamma$  값이 증가할수록 시변계수 값이 증가하게 된다. 각  $\gamma$  값에 대하여 200개의 훈련 심볼과 1,000개의 테스트 심볼을 적용하여 200 회의 Monte Carlo 시뮬레이션을 수행한 후 평균을 취하였고, 결과는 그림 6에 나타냈다. 그림 6(a)는 각 실현에 대한 평균 BER를 나타냈고, 그림 6(b)에는 각 실현에서 얻는 BER에 대한 표준편차를 보였다. 이 결과로부터 다음 사항들을 관측할 수 있다.

1) 평균 BER 성능 비교에서, 제안한 두 등화기는 DFRNE 보다 월등히 우수하였고, RNE-EKF와 RNE-UKF에 비해 다소 우수함을 확인 할 수 있다.

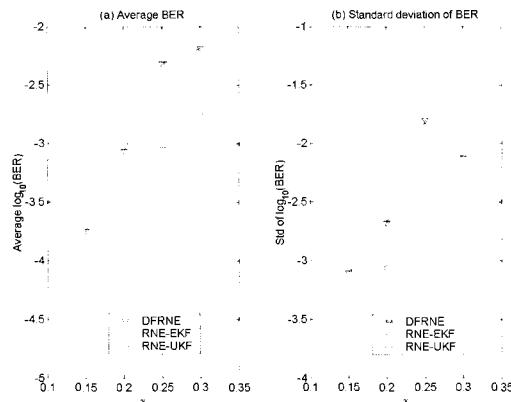


그림 6. 표준편차 변화에 대한 BER 성능 비교.

Fig. 6. BER performance comparison with changing standard deviation.

2) BER에 대한 표준편차 비교에서, 제안한 등화기들은 시변계수 값의 증가에 대하여 DFRNE보다 강인한 특성을 보여주며, RNE-UKF는 RNE-EKF에 비해 견실함을 관찰할 수 있다. 특히, 그림 6(b)에서 DFRNE는  $\gamma=0.25$ 인 경우에 대한 BER 표준편차 성능에서 매우 큰 오차를 보이고 있다. 이것은 RTRL 훈련 알고리즘을 이용하는 DFRNE의 성능이 시변채널 계수의 증가에 대하여 강인하지 않음을 보여주는 한 예이다.

채널모델 2에 대하여 페이딩률이 각각 0.5 및 1.0 [Hz]인 경우의 BER 성능을 그림 7에 나타냈다. 페이딩률이 1.0 [Hz]인 경우는 0.5 [Hz]인 경우에 비해 더욱 빠른 시변채널 특성을 갖는다. 따라서, 페이딩률이 크면 클수록 채널 등화가 어렵다. 실험에서 BER 성능은 100개의 훈련 심볼과 1000개의 테스트 심볼을 적용하여 100회의 Monte Carlo 실험을 수행한 후 평균을 취하였다. 채널모델 1에서와 달리, 세 등화기들의 연결강도는 채널의 페이딩 특성을 추적하기 위하여 테스트 동안에도 학습을 통해서 온라인으로 개선된다. 페이딩률이 0.5 [Hz]에 대한 결과인 그림 7(a)에서 알 수 있듯이 DFRNE의 BER 성능은 매우 저조하다. 반면에 RNE-UKF 및 RNE-EKF는 채널의 페이딩 특성을 잘 추적하며 우수한 BER 성능을 보여준다. 빠른 페이딩 채널 특성을 갖는 그림 7(b)에서도 DFRNE는 채널 등화를 수행하지 못하고 있다. 반면, 제안한 두 등화기는 우수한 채널 등화 성능을 보여준다. 특히, RNE-UKF는 15 [dB] 이상에서 전송된 심볼을 완전하게 복원하고 있다.

그러나, RNE-EKF는 16 [dB] 이상에서 BER 평탄화 현상을 보이고 있는데, 이것은 기존의 전향신경망 등화기에서는 관측된 특성으로 채널의 빠른 페이딩 특성에 대하여 등화기의 성능이 한계가 있음을 보여준다[4]. 요약하면, RTRL을 채용한 DFRE에 비해 칼만 필터를 채용한 RNE-UKF 및 RNE-EKF의 성능이 월등히 우수하다. 이 결과는 RTRL에 비해서 UKF 및 EKF의 파라미터 추적성능이 우수한 것에 기인한다. 결과적으로, DFRNE는 빠른 페이딩 채널의 등화에 적합하지 않음을 보여준다. 반면에, RNE-EKF 및 RNE-UKF는 우수한 채널 등화 및 추적 성능을 보여준다.

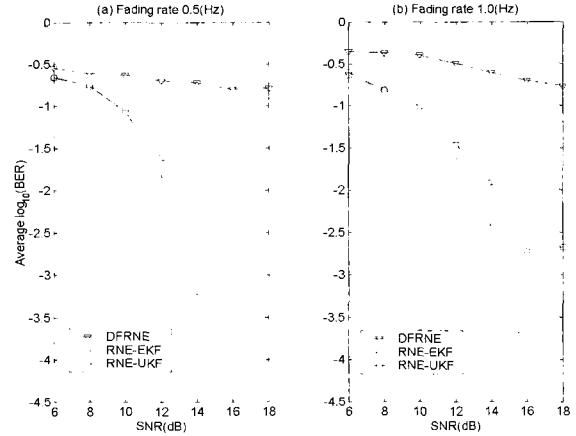


그림 7. 채널모델 2에 대한 BER 성능.

Fig. 7. BER performance for Channel Model 2.

대부분의 디지털 통신 시스템에서는 복잡한 변조 방법을 사용하고, 이동통신과 같은 채널들은 복소 신호(Complex-valued Signal)로 모델링 된다. 따라서, 이러한 시그널링 환경에서 등화기는 복소 신호를 처리할 수 있도록 구현되어야 한다. 이 논문에서는 구현의 간편성을 위해 실수 신호(Real-valued Signal)와 간단한 BPSK 변조 기법을 고려하였다. 따라서, 복소신호 처리를 위한 제안한 등화기에 대한 알고리즘이 개발되어야 한다.

### 3. 연산 복잡도

연산 복잡도는 등화기의 상태 ( $S$ ) 및 연결강도 ( $L$ ) 갯수를 이용하여 표현할 수 있다. DFRNE에서 이용된 RTRL의 연산 시간은 차수  $O(L + S)$ 에 따라 증가하고, 제안한 등화기에 이용된 EKF 및 UKF 알고리즘은 각각  $O(L^2)$  와  $O(L^3)$ 에 따라 증가한다[6,22]. EKF 및 UKF 알고리즘은 RTRL보다 연산 시간이 많이 소요될지도라도 수렴속도, MSE 및 BER 성능 면에서 우수하다. EKF는 UKF에 비해 BER 성능에서 다소 떨어지는 반면에 수렴속도에서는 동등한 성능을 유지한다. 따라서 RNE-EKF의 BER 성능이 허용범위 내에 있다면, EKF는 UKF에 비해 연산 복잡도가 낮아 실제 구현시에 계산 비용 면에서 유리하다. 한편, 네트워크 크기가 증가함에 따라 전송된 심볼을 훈련하는데 필요한 계산비용은 증가하게 된다. 하지만 제안한 RNE는 단지 적은 수의 뉴론을 사용할 뿐만 아니라 훈련시에 상대적으로 적은 훈련심볼을 필요로 한다.

## VI. 결론

이 논문에서는 칼만 필터로 훈련되는 순환신경망을 이용한 채널 등화기들을 제안하였다. 제안한 등화기들의 성능은 시변 채널에 대한 등화 실험을 통해서 상호간에 비교되었다. 시뮬레이션 결과, 이 논문에서 제안한 RNE-EKF 및 RNE-UKF는 기존의 순환신경망 등화기인 DFRNE에 비하여 수렴 속도, BER 성능 및 추적 능력에서 우수함이 입증 되었다. RNE-UKF는 구현상의 연산 복잡도가 RNE-EKF에 비해 다소 증가하지만 우수한 성능을 보였다. 이것은 UKF 알고리즘이 비선형 추정 시스템에 대한 1차 근사화를 제공하는 EKF 알고리즘에 비해 2차 근사화를 제공하고 있기 때문으로 평가

된다. 또한, 제안한 등화기들은 칼만 필터 알고리즘의 빠른 수렴특성 때문에 적은 훈련심볼을 이용하고도 만족스러운 성능을 얻을 수 있다. 결론적으로 제안한 등화기들은 고속 채널 등화를 필요로 하는 통신 시스템에 적합한 것으로 평가된다.

### 참고 문헌

- [1] S. Qureshi, "Adaptive equalization," *Proceedings of the IEEE*, vol. 73, no. 9, pp. 1349-1387, 1985
- [2] S. Chen, B. Mulgrew, and S. McLaughlin, "Adaptive Bayesian equalizer with decision feedback," *IEEE Transactions on Signal Processing*, vol. 41, pp. 2918-2927, September 1993.
- [3] S. Siu, G. J. Gibson, and C. F. N. Cowan, "Decision feedback equalization using neural network structures and performance comparison with standard architecture," *IEEE Proceedings: Part I*, vol. 137, no. 4, pp. 221-225, 1990.
- [4] A. Zerguine, A. Shafi, and M. Bettayeb, "Multilayer perception-based DFE with lattice structure," *IEEE Transactions on Neural Networks*, vol. 12, pp. 532-545, May 2001.
- [5] B. Mulgrew, "Applying radial basis function networks," *IEEE Signal Processing Magazine*, pp. 50-65, March 1996.
- [6] S. Haykin, *Neural Networks: a Comprehensive Foundation*, 2nd Ed. Upper Saddle River, NJ: Prentice Hall, 1999.
- [7] G. Kekriotis, E. Zervas, and E. S. Manolakos, "Using recurrent neural networks for adaptive communication channel equalizations," *IEEE Transactions on Neural Networks*, vol. 5, pp. 267-278, March 1994.
- [8] S. Ong, C. You, S. Choi, and D. Hong, "A decision response filter," *IEEE Transactions on Signal Processing*, vol. 45, pp. 2851-2858, November 1997.
- [9] R. Parisi, E. D. D. Claudio, G. Orlandi, and B. D. Rao, "Fast adaptive digital equalization by recurrent neural networks," *IEEE Transactions on Signal Processing*, vol. 45, pp. 2731-2739, November 1997.
- [10] K. Hacioglu, "An improved recurrent neural network for M-PAM symbol detection," *IEEE Transactions on Neural Networks*, vol. 8, pp. 779-783, May 1997.
- [11] R. J. Williams and D. Zipser, "A learning algorithm for continually running fully recurrent neural networks," *Neural Computation*, vol. 1, pp. 270-280, 1989.
- [12] J. D. Ortiz-Fuentes and M. L. Forcada, "A comparison Conference on Acoustics, Speech, and Signal Processing, pp. 3281-3284, 1997.
- [13] F. Ling and J. G. Proakis, "Adaptive lattice decision feedback equalizers-Their performance and application to time-variant multipath channels," *IEEE Transactions on Communications*, vol. 33, pp. 348-356, April 1985.
- [14] Q. Liang and J. M. Mendel, "Equalization of nonlinear time-varying channels using type-2 fuzzy adaptive filters," *IEEE Transactions on Fuzzy Systems*, vol. 8, pp. 551-563, October 2000.
- [15] C. Cowan and S. Semnani, "Time-variant equalization using a novel non-linear adaptive structure," *International Journal of Adaptive Control and Signal Processing*, vol. 12, no. 2, pp. 195-206, 1998.
- [16] M. Solazzi, A. Uncini, E. D. D. Claudio, and R. Parisi, "Complex discriminative learning Bayesian neural equalizer," in *Proceedings of the 1999 IEEE International Symposium on Circuits and Systems (ISCAS '99)*, pp. 343-346, 1999.
- [17] J. Elman, "Finding structure in time," *Cognitive Science*, vol. 14, pp. 179-211, 1990.
- [18] P. J. Werbos, "Back-propagation through time: What it does and how to do it," *Proceedings of the IEEE*, vol. 78, pp. 1550-1560, October 1990.
- [19] S. Haykin, *Adaptive Filter Theory*, 4th Ed. Upper Saddle River, NJ: Prentice Hall, 2002.
- [20] L. A. Feldkamp and G. V. Puskorius, "A signal processing framework based on dynamic neural networks with application to problems in adaptation, filtering and classification," *Proceedings of the IEEE*, vol. 86, pp. 2259-2277, 1998.
- [21] S. J. Julier and J. K. Uhlmann, "A new extension of the Kalman filter to nonlinear systems," in *Proceedings of AeroSense: The 11th International Symposium on Aerospace/Defence Sensing, Simulation and Controls*, 1997.
- [22] E. A. Wan and R. van der Merwe, "The unscented Kalman filter," in *Kalman Filtering and Neural Networks*, Edited by S. Haykin. John Wiley and Sons, Inc., 2001.
- [23] E. A. Wan and R. van der Merwe, "The unscented Kalman filter for nonlinear estimation," in *Proceedings of the IEEE 2000 Adaptive Systems for Signal Processing, Communications and Control Symposium (AS-SPCC)*, pp. 153-158, 2000.
- [24] S. Chen, B. Mulgrew, and S. McLaughlin, "Adaptive equalization of finite nonlinear channels using multilayer perceptrons," *Signal Processing*, vol. 20, 1990.

### 최 종 수

전북대학교 전기공학과에서 학사(90), 석사(92), 박사(96) 학위를 받았고, 1994년부터 1999년까지 포항산업과학 연구원 자동화연구 부문에서 선임연구원으로 근무 하였음. 2000년 캐나다 University of Waterloo에서 방문연구원으로 근무한 후, 2002년까지 캐나다 McMaster University 전기 및 컴퓨터 공학과 박사과정에서 수학하였음. 현재 캐나다 University of Ottawa 정보기술공학부 박사과정에 재학중임. 관심연구 분야는 지능시스템, 적응신호처리, 다중안테나 시스템 및 터보 수신기.

### 권 오 신

전북대학교 전기공학과에서 학사(78), 석사(82), 박사(88)학위를 받았음. 1988년부터 2003년 현재 군산대학교 공과대학 전자정보공학부 교수로 재직중임. 1993년에서 1994년 까지 Japan Osaka Electro-Communication University Visiting professor로 근무. 2003년 현재 캐나다 university of Ottawa 정보기술공학부 Visiting professor로 근무중 임. 관심연구분야는 신경회로망, 퍼지제어, 지능시스템 및 통신 시스템.