
시그마 포인트를 이용한 채널 등화용 순환신경망 훈련 알고리즘

권 오 신 *

Training Algorithm of Recurrent Neural Network Using a Sigma Point
for Equalization of Channels

Ohshin Kwon *

이 논문은 2005년도 군산대학교 학술연구비의 지원에 의하여 연구되었음

요 약

고속 통신 시스템의 채널 등화에 순환 신경망이 자주 이용되고 있다. 기존의 등화방법은 대부분 시불변 채널을 주로 다루었다. 그러나 이동통신과 같은 현대의 통신환경은 페이딩으로 인하여 시변특성을 갖는다. 본 논문에서는 비선형 시변 시스템에 적용하여 성능이 우수한 결정 피드백 순환신경망을 채널등화기로 이용하며, 또한 채널 등화에 빠른 수렴속도와 우수한 추적성능을 지니는 확장된 칼만필터와 시그마 포인트 칼만필터를 이용한 두 종류의 훈련 알고리즘을 제안한다. 확장된 칼만필터를 이용한 경우 비선형 시스템의 1차 선형화 과정에서 키다란 오차를 유발할 수도 있으며, 이에 대한 대안으로 시그마 포인트 칼만필터를 이용하여 이러한 문제점을 극복할 수 있다.

ABSTRACT

A recurrent neural network has been frequently used in equalizing the channel for fast communication systems. The existing techniques, however, have mainly dealt with time-invariant channels. The modern environments of communication systems such as mobile ones have the time-varying feature due to fading. In this paper, powerful decision feedback - recurrent neural network is used as channel equalizer for nonlinear and time-varying system, and two kinds of algorithms, such as extended Kalman filter (EKF) and sigma-point Kalman filter (SPKF), are proposed; EKF is for fast convergence and good tracing function, and SPKF for overcoming the problems which can be developed during the process of first linearization for nonlinear system EKF.

키워드

Sigma-Point Kalman Filter, Extended Kalman Filter, Recurrent Neural Network, Channel Equalization.

I. 서 론

일반적으로 디지털 통신 시스템에서 채널 대역폭의 효율적인 이용은 심볼간 간섭(intersymbol interference,

ISI)에 의해서 제한을 받는다. 이러한 제한을 완화시키기 위하여 일반적으로 통신시스템의 수신부에 등화기 (equalizer)가 널리 이용된다. 그러나 이때 사용되는 등화기 중 선형 등화기는 왜곡이 심한 채널인 경우 성능에 있

어서 신뢰할 수 없는 경우가 많다[1]. 그러므로 심볼간 간섭이 심한 경우에는 동일한 수준의 복잡도를 갖는 선형 등화기보다 성능 면에서 우수한 비선형 등화기인 결정 피드백 등화기(decision feedback equalizer, DFE)가 널리 이용되고 있다[2]. 한편 기존에 발표된 대부분의 등화기들은 시불변(time-invariant) 채널을 주로 다루었다. 그러나 이동통신과 같은 통신환경은 페이딩(fading)으로 인하여 시변(time-varying) 특성을 갖는다. 과거에 사용 하던 등화기들은 시불변 채널에 대하여 좋은 성능을 보여 주었지만 빠른 페이딩 채널에는 비교적 적합하지 않다. 페이딩 채널의 시변 특성은 불확실성을 갖는 동적 시스템으로 해석 할 수 있다. 본 논문에서는 순환신경망 등화기의 채널에 대한 빠른 수렴속도와 우수한 추적성능을 지니는 두 종류의 훈련 알고리즘을 제안한 후 그 특성을 비교한다. 두 종류의 훈련 알고리즘으로 확장된 칼만필터(extended Kalman filter, EKF)[3]와 시그마 포인트를 이용한 칼만필터(sigma point Kalman filter, SPKF)를 적용한다. EKF는 신경회로망의 훈련에 자주 이용되며 빠른 수렴특성을 보인다. EKF는 신경회로망 훈련 시 Jacobian 행렬 연산이 필요하며 비선형 시스템의 선형화에 따른 모델링 오차에 의해 필터의 성능이 저하되는 단점을 지니고 있다[7].

또 다른 훈련 알고리즘으로 최근에 발표된 SPKF 알고리즘을 들 수 있는데 이 방법은 아직 순환신경망에 적용하는 방법이 그리 많이 발표되지 않았다. EKF는 때로는 필터의 준최적(sub-optimal) 성능을 갖게 하기도 하며, 초기 추정오차가 큰 경우에는 EKF 구현에 필요한 Jacobian 행렬에 심각한 문제점이 발생하므로 필터는 발산 할 수도 있는 단점을 지니고 있다[8]. 반면에 SPKF에서는 Jacobian 행렬 계산이 필요 없으므로 큰 초기추정오차에 강인한(robust) 특성을 지니고 있다. 본 논문에서는 순환신경망의 훈련 알고리즘으로 EKF와 SPKF를 적용하고, 시변채널에 대한 등화 실험을 통하여 두 알고리즘의 성능을 비교 검토하여 제안한 알고리즘의 우수성을 입증한다.

II. 순환신경망 등화기

본 논문에서는 RNN 모델 중 동적시스템의 표준 상태 공간 모델을 표현할 수 있는 Elman 구조[4]를 순환신경망 등화기(recurrent neural equalizer, RNE)로 설정하였으

며 구조는 그림1과 같다. 여기에서 한 개의 출력 뉴론을 갖는 Elman 신경망 구조의 이산시간 상태공간 방정식은식(1),(2)와 같은 형태로 표현된다.

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

$$y(k) = f(\mathbf{x}(k), \mathbf{w}_o) \quad (2)$$

$\mathbf{r}(k)$, $\mathbf{u}(k)$ 및 $\mathbf{x}(k)$ 는 각각 수신단에 도착한 입력벡터, 결정되며 임 입력 벡터 및 신경망의 은닉층으로부터 순환 되는 상태벡터이다. $y(k)$ 는 RNN의 출력, W_h 는 입력 층과 은닉층 사이의 연결강도 행렬이고, ω_0 는 은닉층과 출력층 사이의 연결강도 벡터이다. 여기에서 W_h 와 ω_0 는 각각 다음과 같이 정의된다.

$$W_h = [\mathbf{w}_1 \mathbf{w}_2 \cdots \mathbf{w}_p]^T \quad (3)$$

$$\mathbf{w}_o = [w_1 w_2 \cdots w_p]^T \quad (4)$$

식 (1)과 (2)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. 여기에서 상수 1은 바이어스 입력, 함수 $D(\cdot)$ 는 결정장치, 그리고 $s(k)$ 는 결정장치의 출력으로써 추정된 전송 심볼을 나타낸다.

$$\mathbf{x}(k) = \psi(W_h[1 \ r^T(k) \ u^T(k) \ x^T(k-1)])^T \quad (5)$$

$$y(k) = \mathbf{w}_o^T [1 \ x^T(k)]^T \quad (6)$$

$$\hat{s}(k) = D(y(k)) \quad (7)$$

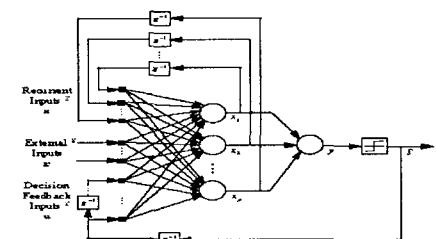


그림 1. 결정 계환 순환신경망 등화기
Fig.1. The Proposed Recurrent Neural Equalizer with Decision Feedback.

III. 확장 칼만필터 및 훈련 알고리즘

EKF가 신경망 훈련에 이용되는 경우 빠른 수렴 속도를 얻을 수 있는데, 이는 고속 디지털 통신시스템에 적합하다. EKF 구현에 적합한 RNE의 동특성은 다음의 비선형 이산시간 방정식과 같다.

$$w(k+1) = w(k) + \omega(k) \quad (8)$$

$$y_d(k) = h(w(k), z(k)) + \nu(k) \quad (9)$$

윗 식에서 $z(k)$ 는 다음 식(10)과 같이 표시된다.

$$z(k) = (r(k), u(k), x(k-1), x(k)) \quad (10)$$

연결강도 벡터 w 는 식 (7)과 (8)에 주어진 연결강도를 이용하여 다음과 같이 재구성되었다.

$$w = [w_1^T w_2^T \cdots w_p^T w_0^T]^T \quad (11)$$

프로세스 방정식인 식(8)은 프로세스 잡음 $\omega(k)$ 에 의해서 오염된 정적 프로세스(stationary process)로 특성화되는 RNE의 상태를 표시한다. 이 때 시스템의 상태는 RNE의 연결강도 벡터 $w(k)$ 로 주어진다. 측정 방정식인 식(9)은 출력 $y_d(k)$ 를 나타낸다. 훈련하기 위한 EKF 계산 알고리즘은 다음과 같이 주어진다[3].

$$A(k) = [R(k) + H^T(k)P(k)H(k)]^T \quad (12)$$

$$K(k) = [R(k)H(k)A(k)] \quad (13)$$

$$\hat{w}(k+1) = \hat{w}(k) + K(k)e(k) \quad (14)$$

$$P(k+1) = P(k) - K(k)H^T(k)P(k) + Q(k) \quad (15)$$

벡터 $\hat{w}(k)$ 는 시간 k 에서 시스템의 상태(즉, RNE의 연결강도)의 추정치를 나타낸다. 이 추정치는 칼만 이득 행렬 $K(k)$ 와 오차 $e(k)$ 의 함수이다. Jacobian 행렬 $H(k)$ 는 RNN에 대하여 다음 식과 같이 정의 된다.

$$H(k) = \frac{\partial h(k, \hat{w}, z)}{\partial w(k)} \quad (16)$$

이때 i -th 미분벡터는 다음 식(17)과 같이 정의 한다.

$$\nabla_w h_i(k) = \left[\frac{\partial h_i(k)}{\partial w_1} \frac{\partial h_i(k)}{\partial w_2} \cdots \frac{\partial h_i(k)}{\partial w_L} \right]^T \quad (17)$$

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

IV. 시그마 포인트 기반 칼만필터 및 훈련 알고리즘

확장 칼만필터는 선형화에 따른 모델링 오차에 의해 필터의 성능이 저하되는 단점을 갖고 있다[7]. 실제로 확장 칼만필터는 비선형 시스템 선형화를 위한 Jacobian 행렬 계산에 문제점을 갖고 있다. 시그마 포인트들을 사용하여 확률 분포를 근사화 하는 Unscented Transformation (UT)[6]를 이용하여 확장된 칼만필터의 단점을 극복할 수 있다. 시그마 포인트는 이전시간(prior) 확률 분포함수의 평균과 공분산 정보를 내포하고 있으며 비선형 함수를 통해 직접 시간 전파된 시그마 포인트를 사용하여 이후시간(posterior) 평균과 공분산을 계산한다. UT는 비선형 변환을 통한 랜덤 변수의 통계적 특성을 계산하는 방법으로 시그마 포인트 칼만필터 알고리즘 기본을 이룬다. 우선 이산시간 비선형 함수를 다음과 같이 정의한다[8].

$$x_{k+1} = f(x_k) + \omega_k, \omega_k \sim N(0, Q) \quad (19)$$

$$y_k = h(x_k) + v_k, v_k \sim n(0, R) \quad (20)$$

상태변수와 공분산은 다음과 같이 확장된다.

$$\hat{x}_0^a = E[x_0^T \omega_0^T v_0^T] = [\hat{x}_0^T \ 0 \ 0] \quad (21)$$

$$P_o^a = E[(x_0 - \hat{x}_0^T)(x_0 - \hat{x}_0^T)^T] = \begin{bmatrix} P_0 & 0 & 0 \\ 0 & Q & 0 \\ 0 & 0 & R \end{bmatrix} \quad (22)$$

그리고 마지막 초기화로 시그마 포인트의 가중치를 위해 다음과 같이 필터 구동 전에 미리 구성 한다.

$$W_0^{(m)} = \lambda / (L + \lambda) \quad (23)$$

$$W_0^{(c)} = \lambda / (L + \lambda) + (1 - \alpha^2 + \beta) \quad (24)$$

$$W_i^{(m)} = W_i^{(c)} = 1/2(L + \lambda), \quad i = 1, \dots, 2L \quad (25)$$

SPKF에서는 시그마 포인트를 설정하는 것이 중요하며 다음과 같이 설정한다.

$$\chi_{k-1}^a = \lfloor \hat{x}_{k-1}^a \hat{x}_{k-1}^a \pm \sqrt{(L + \lambda) P_{k-1}^a} \rfloor \quad (26)$$

그 다음 설정된 시그마 포인트는 다음과 같이 비선형 시스템 함수를 통하여 독립적으로 시간 전파 된다.

$$\chi_{k|k-1}^x = f(\chi_{k-1}^x) + \chi_{k-1}^x \quad (27)$$

이렇게 계산된 시그마 포인트를 사용하여 다음과 같이 상태변수, 공분산, 그리고 측정치의 추정치가 계산된다.

$$\hat{x}_k = \sum_{i=0}^{2L} W_i^{(m)} \chi_{i,k|k-1}^x \quad (28)$$

$$P_k = \sum_{i=0}^{2L} W_i^{(c)} [\chi_{i,k|k-1}^x - \hat{x}_k] [\chi_{i,k|k-1}^x - \hat{x}_k]^T \quad (29)$$

$$\hat{y}_k = \sum_{i=0}^{2L} W_i^{(m)} [h(\chi_{i,k|k-1}^x) + \chi_{k-1}^v] \quad (30)$$

관측 값에 따라 다음과 같이 필터 이득(gain)을 구한다.

$$K_k = P_{x_k y_k} P_{y_k y_k}^{-1} \quad (31)$$

여기서 공분산 $P_{x_k y_k}$, $P_{y_k y_k}$ 는 다음 식과 같다.

$$P_{x_k y_k} = \sum_{i=0}^{2L} W_i^{(c)} [\chi_{i,k|k-1}^x - \hat{x}_k] [h(\chi_{i,k|k-1}^x) - \hat{y}_k]^T \quad (32)$$

$$P_{y_k y_k} = \sum_{i=0}^{2L} W_i^{(c)} [h(\chi_{i,k|k-1}^x) - \hat{y}_k] [h(\chi_{i,k|k-1}^x) - \hat{y}_k]^T \quad (33)$$

상태변수와 공분산은 다음과 같이 측정치가 생긴다.

$$\hat{x}_k = \hat{x}_{\bar{k}} + K_k (y_k - \hat{y}_{\bar{k}}) \quad (34)$$

$$P_k = P_{\bar{k}} - K_k P_{y_k y_k} K_k^T \quad (35)$$

식(34)에 나타낸 상태변수의 생기는 순환신경망의 연결강도 벡터 w 의 변화으로 생각할 수 있다.

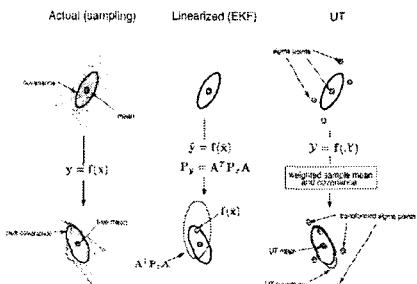


그림 2. 시그마 포인트에 의한 평균과 공분산 전달
Fig.2. Example of the sigma-point approach for mean and covariance propagation

그림 2.는 지금까지 설명한 확장된 칼만필터(EKF)와 시그마 포인트 칼만필터(SPKF) 훈련 알고리즘을 적용한 경우 평균값과 공분산 전달의 한 예를 보인 것이다 [11].

V. 시뮬레이션

5.1. 통신 시스템 모델링

EKF와 SPKF를 이용한 훈련 알고리즘을 적용하기 위하여 그림 3.과 같이 선형과 비선형 왜곡 상태를 모두 포함하고 있는 결정 피드백 등화기(decision feedback equalizer, DFE)를 포함한 디지털 통신 시스템을 구성하였다[12].

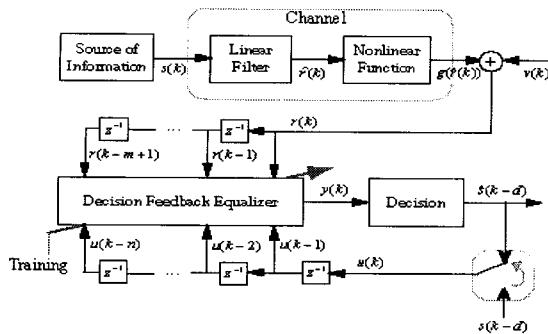


그림 3. DFE로 구성된 디지털 통신 시스템
Fig.3 A digital communications system with decision feedback equalizer

채널 모델은 다음 식과 같이 표현된다.

$$\begin{aligned} r(k) &= g(\hat{r}(k)) + \nu(k) \\ &= g\left(\sum_{i=0}^{N-1} h_i s(k-i)\right) + \nu(k) \end{aligned} \quad (36)$$

여기에서 $g(\bullet)$ 는 비선형 왜곡을 나타내며 h 는 길이 N 인 채널의 유한 임펄스 응답(finite impulse response, FIR)이다. 그리고 $\nu(k)$ 는 평균이 0이고 분산이 σ_0^2 인 AWGN이다.

5.2. 수렴속도에 대한 시뮬레이션

비선형 시변채널 모델의 전달 함수를 다음 식과 같이 설정한다.

$$C(z) = (c_0 + b_0(k)) + (c_1 + b_1(k))z^{-1} + (c_2 + b_2(k))z^{-2} \quad (37)$$

채널 임펄스 응답은 $c = [0.3482 \ 0.8704 \ 0.3482]^T$ 이다. 비선형 채널은 다음 식과 같이 모델링 되었는데, 여기에서 비선형성은 선형 채널의 출력에 적용되었다.

$$\begin{aligned} r(k) &= g(\hat{r}(k)) + \nu(k) \\ &= \hat{r}(k) + 0.2(\hat{r}(k))^2 + \nu(k) \end{aligned} \quad (38)$$

이러한 채널의 비선형 왜곡은 전송 시스템에서 기인하는 포화현상을 나타낼 수도 있다. 위에서 기술한 시변 채널에 대하여 확장된 칼만필터를 이용한 순환신경망 등화기와 시그마 포인트를 이용한 순환 신경망 등화기

의 성능을 비교한다. 시뮬레이션에서 등화기의 전향차수는 $m=3$, 결정지연은 전향차수로 부터 $d=m-1$, 결정피드백 차수는 $n=2$ 로 정해진다. EKF에 대한 파라미터들은 $\eta = 0.1$, $\varepsilon = 0.01$, 그리고 $q=0.01$ 로 설정하였으며, UKF에 필요한 forgetting 계수는 $\lambda_{RLS} = 0.999$ 로 선택하였고, 채널모델에 대하여 두 종류의 순환신경망 등화기(EKF, SPKF)의 수렴특성을 MSE의 선형 스케일로 그림 4에 나타내었다.

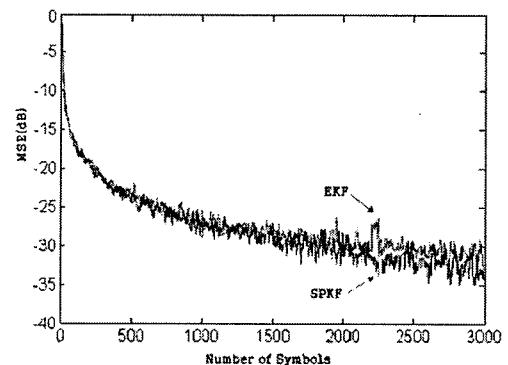


그림 4. 채널 모델에 대한 등화기의 수렴 특성
Fig. 4. Convergence properties of equalizer for channel

그림에서 알 수 있듯이 SPKF의 수렴특성은 EKF에 비하여 수렴하는 속도 면에서 그다지 빠른 특성을 보여주지는 못함을 볼 수 있다. 그러나 이 방법은 기존의 그레디언트 기반 훈련 방법에 비해서 매우 빠른 수렴 특성을 보이는 특징이 있다. 따라서 세안한 두 방법은 모두 정보 전송의 효율을 높일 수 있으며, 고속 디지털 통신 시스템에 적합한 특성을 갖는다.

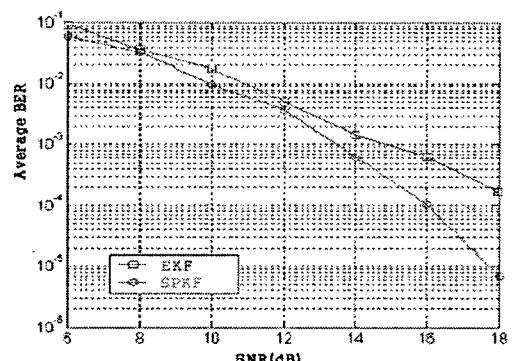


그림 5. 채널모델에 대한 등화기의 BER 성능
Fig. 5. BER performance of the equalizer for channel

또한 채널모델에 대한 비트에러율(Bit Error Rate, BER) 성능을 그림 5.에 비교하였다. 시뮬레이션에서 두 종류의 등화기의 BER 성능은 최초의 100개의 심볼을 훈련에 상용하였고, 나머지 10^5 개의 심볼은 테스트에 사용하였다. 그림은 20회의 Monte Carlo 실험을 통하여 얻은 결과이다. 실험에서 모든 등화기 연결강도 벡터는 훈련심볼을 이용하여 학습과정에서 갱신되며, BER 계산 시 즉, 테스트 모드 동안에는 바뀌지 않고, 학습과정에서 훈련된 연결강도 벡터를 그대로 사용한다.

그림에서 알 수 있듯이 SPKF 알고리즘에 의한 경우가 EKF를 이용한 경우에 비하여 10^{-4} 의 BER 지점에서 약 1.5-2 [dB] 정도가 향상되었음을 보여준다. 특히 SPKF에 의한 훈련 방법을 이용한 등화기의 경우 16[dB] 이상인 경우 전송된 심볼은 에러율이 거의 없이 완전하게 복원하고 있다. 따라서 SPKF는 EKF를 이용한 훈련 방법에 비하여 BER의 성능이 견실함을 알 수 있었다.

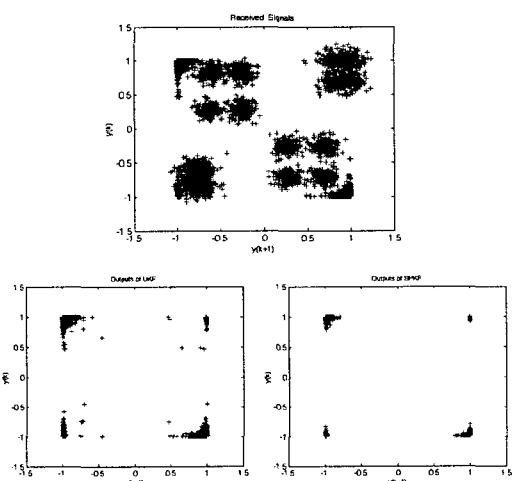


그림 6. 채널모델 데이터의 아이 다이어그램
Fig. 6 Eye diagram for Channel Model during tracking mode

그림 6.은 3×10^3 개의 심볼을 사용하였을 경우 오염된 데이터를 두 가지 방법으로 복원하였을 경우 그 결과를 보여주는 아이 다이어그램이다. 여기에서 SPKF 알고리즘에 의해 등화된 후의 결과에서 결정 경계지역(0.5 또는 -0.5)에 위치하는 값들은 존재하지 하지 않는 반면, EKF 알고리즘에 의해 등화된 후의 출력에서는 결정 경계구역에서 오차를 유발할 수 있는 데이터들이 존재함을 알 수 있다.

VI. 결 론

본 논문에서는 칼만필터를 이용하여 순환신경망을 훈련시키는 두가지 (EKF, SPKF) 알고리즘에 대하여 비교하였다. 제안한 훈련 알고리즘에 의한 결과는 채널에 대한 등화 실험을 통하여 상호간에 비교 되었다. 우선 EKF에 의한 훈련 알고리즘은 비선형 추정 시스템에 대한 1차 근사화를 제공하는데 이 과정에서 매우 큰 초기 오차를 포함할 수 있어 시스템이 수렴하지 않고 발산할 수 있는 문제점이 있는 반면, SPKF에 의한 알고리즘은 같은 시스템에 대하여 2차 근사화 까지 포함하기 때문에 이러한 단점을 해결할 수 있다. 또한 두 가지 알고리즘 모두 수렴속도 면에서는 큰 차이를 보이지는 않았지만 비트 에러율 성능 면에서는 SPKF가 EKF에 비하여 매우 견실 함을 알 수 있었다. 결론적으로 고속 통신 시스템에서 등화기는 EKF 보다 SPKF를 이용한 알고리즘이 보다 적합한 것으로 평가된다.

참고문헌

- [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. Haykin, "Neural Networks: a Comprehensive Foundation, 2nd Ed. Upper Saddle River, NJ: Prentice Hall, 1999.
- [4] J. Elman, "Finding structure in time," Cognitive Science, vol. 14, pp. 179-211, 1990.
- [5] S. Haykin, Adaptive Filter Theory, 4th Ed. Upper Saddle River, NJ: Prentice Hall, 2002.
- [6] S. J. Julier and J. K. Uhlmann, "A new extension of the Kalman filter to nonlinear systems," in Proceeding of AeroSence: The 11th International Symposium on Aerospace/Defence Sensing, Simulation and Controls, 1997.
- [7] H.S. Hong, C. G. Park, J. G. Lee, "An Extended Kalman Filter Robust to Linearization Error," Journal of Cont. and System Eng., Vol. 12, No.2, pp. 93-100, February 2006

- [8] S. Y. Cho, W. S. Choi, "Improving the Performance of DR/GPS Integrated System for Land Navigation Using Sigma Point Based RHKF Filter," *Journal of Cont. and System Eng.*, Vol. 12, No.2, pp. 174-185, February 2006
- [9] J. Choi, M. B. Bouchard, T. H. Yeap, O. Kwon, "A Derivative-Free Kalman Filter for Parameter Estimation of Recurrent Neural Networks and Its Applications to Nonlinear Channel Equalization," *Eng. of Intelligent Systems EIS' 2004*, Portugal, March, 2004
- [10] J. Choi, O. Kwon, "Equalization of Time-varying Channels using a Recurrent Network Trained with Kalman Filters," *Journal of Cont. and System Eng.*, Vol. 9, No.11, pp. 917-924, 2003
- [11] Rudolph van der Merwe & Eric Wan, "Sigma-Point Kalman Filters for Probabilistic Inference in Dynamic State-Space Models," *Journal of Oregon Health & Science University, USA*, 2004

저자소개



권 오 신 (Ohshin Kwon)

1978년 전북대학교 전기공학과 공학사
1984년 전북대학교 전기공학과 공학석사

1988년 전북대학교 전기공학과 공학박사
1988년-현재 군산대학교 공과대학 전자정보공학부 교수
※ 관심분야: 신경망, 인공지능, 적응필터,