

論文95-32A-8-2

高速 온라인 適應機能을 갖는 非線形 適應等化器

(A Nonlinear Adaptive Equalizer with Fast On-line Adaptation)

吳 德 吉 * , 崔 鎮 榮 ** , 李 忠 雄 ***

(Deock Gil Oh, Jin Young Choi, and Choong Woong Lee)

요 약

채널 데이터의 어파인 (affine) 寫像 結果를 퍼지規則 및 퍼지推論에 의해 綜合하여 전송 데이터의 推定值를 생성하는 非線形 適應等化器를 提案하였다. 提案된 非線形 適應等化器는 既存의 非線形 適應等化器 보다 適應 알고리즘에 따른 계산량이 越等히 減少되면서도 BER (Bit Error Rate) 性能은 既存의 非線形 等化器와 거의 類似하거나 優秀하다. 또한 提示한 방법에서는 빠른 收斂특성과 적은 계산량을 갖는 특성에 의해 既存의 非線形 適應等化器보다 온라인 (on-line) 適應시에 有利하며, 채널에 대한 精確한 事前知識에 의해 判定케환 벡터를 使用하는 퍼지 適應필터와는 달리 一般의인 DFE (Decision Feedback Equalizer) 형태로 쉽게 具現할 수 있는 長點이 있다.

Abstract

This paper proposes a nonlinear adaptive equalizer which is based on fuzzy rules and fuzzy inference of several affine mappings for the received channel data. The proposed nonlinear adaptive equalizer has the comparable BER performance to the existing nonlinear adaptive equalizers with the significantly lower computational complexity. Also it can be applied to the on-line adaptation environments owing to its fast convergence characteristics and the lower computational load. When using the decision feedback vectors, this equalizer can be easily realized in the form of the DFE structure without the requirement for the perfect channel knowledge as in the case of the fuzzy adaptive filter.

I. 序 論

一般적으로 디지털 통신채널은 ISI (Inter-Symbol

Interference)나 AWGN (Additive White Gaussian Noise)에 의해 신호의 歪曲이 발생하며 채널에 따라서는 時變특성을 갖는 非線形性的 影響을 받기 때문에 전송 데이터의 精確한 檢出을 위해서는 수신단에서 適應等化器의 使用이 必需的이다. 線形채널에서의 適應等化器는 채널 전달函數의 逆 函數에 해당하는 線形 필터링에 의해 ISI를 제거하는 LTE (Linear Transversal Equalizer)와 과거심벌의 判定值를 케환시켜 ISI를 제거하는 DFE, 그리고 전송 심벌열에 대해 最適推定을 수행하는 MLSE (Maximum Likelihood Sequence Estimator)가 많이 사용된다.

*正會員, 韓國電子通信研究所 衛星放送시스템研究室
(Satellite Broadcasting System Section, ETRI)

** 서울大學校 制御計測工學科
(Dept. of Control & Instrumentation Eng., Seoul Nat'l Univ.)

*** 서울大學校 電子工學科
(Dept. of Elec. Eng., Seoul Nat'l Univ.)

接受日字: 1994年 9月 22日, 수정완료日: 1995年 7月 31日

LTE는 最小位相 채널에서는 限定된 필터 탭수에 의해 具現이 可能하나, 非最小位相 채널에서는 이론적으로 無限個의 필터 탭수가 필요하게 되어 具現이 不可能하다. 반면에 DFE는 과거 심벌의 判定値를 補償시키는 방법에 의해 限定된 탭수에 의해서도 非最小位相 채널의 ISI를 제거할 수 있다. 한편, MLSE는 채널推定이 정확하여야 만이 最適判定을 할 수 있고, MLSE 고유의 성질때문에 비교적 긴 判定遲延이 발생한다. 또한 MLSE는 ISI를 유발하는 심벌수 및 심벌의 상태수가 증가하는 경우에는 알고리즘에 소요되는 演算量이 幾何級數的으로 증가하며, 非線形 채널과 같은 非安定 채널에서는 성능의 급격한 低下때문에 심벌단위 判定을 하는 LTE나 DFE가 주로 사용된다^[11]. 한편, 線形 채널의 경우에도 수신신호의 判定領域에서 最適檢出을 위한 判定境界는 非線形 函數가 되어 既存의 LTE나 DFE에서 사용하는 線形필터에 의해서는 實現이 不可能하다^{[2,3]12}. 따라서 線形 適應等化器로는 最適推定을 위한 수신기의 具現이 不可能할 뿐만 아니라 근본적으로 非線形 채널에서는 사용할 수가 없다.

最近에는 線形 適應等化器의 이러한 短點을 극복하기 위하여 신경회로망이나 퍼지필터를 이용하여 심벌의 最適判定이 가능하고 非線形 채널에서의 等化가 가능한 다양한 형태의 非線形 適應等化器가 提案되고 있다. 代表的인 非線形 適應等化器로는 多層認識子 (MLP : Multi-Layer Perceptron)에 근거한 MLP형 非線形 適應等化器^{[2,6]1}, 방사형 기저함수 망 (RBFN : Radial Basis Function Network)에 근거한 RBFN형 非線形 適應等化器^{[3,4]1}와 퍼지 適應필터 (FAF : Fuzzy Adaptive Filter)에 근거한 FAF형 非線形 適應等化器를 들 수 있다^{[5,7]1}. 이러한 非線形 適應等化器는 最適等化器와 거의 같은 성능을 얻을 수 있을 뿐만 아니라 非線形 채널에서도 매우 우수한 수신 성능을 얻을 수 있다. 그러나 非線形 適應等化器는 線形 適應等化器에 비해 收斂성능이 저하되게 되며 適應시 상당한 계산량을 요구하게 된다. 경사추적법의 한 종류인 誤差 逆傳播 (EBP : Error Back Propagation) 알고리즘에 의해 適應되는 MLP형 非線形 適應等化器는 收斂속도가 매우 늦을 뿐만 아니라 最小値가 아닌 局部 極小値로 收斂하는 등, 收斂性 또한 保障할 수가 없다^{[12]1}. 반면에 RBFN형 非線形 適應等化器는 收斂속도는 빠르나 RLS (Recursive Least Squares)나 LMS (Least Mean Square)

알고리즘을 사용할 경우 線形 適應等化器에 비해 훨씬 많은 계산량을 요구한다^{[2,3,5,7]1}. FAF형 適應等化器는 근본적으로 RBFN형 適應等化器와 類似한 방법으로 전송심벌을 推定하나 채널 및 判定領域의 知識에 대하여 퍼지規則을 사용하는 점이 다르다. 이러한 퍼지規則은 適應等化器의 收斂성능을 改善시키게 되나 퍼지規則의 수에 따라서는 상당한 계산량을 요구하게 되어 RLS 알고리즘을 사용하는 FAF형 適應等化器는 실제 環境에의 適用이 곤란할 수도 있고^{[5]1}, DFE 형태로 구성할 경우는 채널상태에 대하여 거의 完璧한 事前知識을 요구하게 되는 短點이 있다^{[7]1}.

본 논문에서는 퍼지규칙과 어파인 寫像 (mapping)을 이용하여 전송심벌을 推定하므로써 既存의 非線形 適應等化器 보다 성능이 우수하거나 대등하고, 適應시의 계산량은 越等히 減少된 새로운 FIAM (Fuzzy Inferred Affine Mapping)형 非線形 適應等化器를 提案하고 이의 성능을 既存 방식과 비교 분석하고자 한다.

II. 非線形 適應等化器 모델

심벌 단위로 判定을 수행하는 適應等化器는 전송된 심벌을 判定遲延, 후에 전송심벌의 推定値, $\bar{s}(k-d)$ 를 豫測하는 適應필터라 할 수 있다. 그림 1과 같이 適應等化器의 입력신호로는 수신된 채널신호 벡터, $\mathbf{x}(k) = [x(k), \dots, x(k-n+1)]^T$ 와 과거심벌의 檢出신호 벡터, $\bar{\mathbf{s}}(k-d) = [\bar{s}(k-d-1), \dots, \bar{s}(k-d-m)]^T$ 를 사용할 수 있다.




그림 1. 디지털 통신채널에서의 비선형등화기 모델
Fig. 1. Nonlinear equalizer model for digital communication channel.

便宜上 適應等化器의 입력신호 벡터, $\mathbf{x}(k)$ 를 DFE 형태를 포함하도록 $\mathbf{x}(k) = [x(k), \bar{s}_f(k-d)]$ 로 표시할 경우 一般的인 非線形 適應等化器는 심벌구간 k 마

다 입력신호 벡터, $\mathbf{x}(k)$ 로 부터 심벌 推定值, $y(k)$ 를 생성하는, 즉 $f: R^{m+n} \rightarrow R$ 의 寫像기능을 갖는 適應필터라 할 수 있다. 일반적으로 심벌 推定值, $y(k)$ 는 (2)식과 같은 심벌 판정기에 의해 전송심벌을 檢出한다.

$$y(k) = f(\mathbf{x}(k)) \quad (1)$$

$$\bar{s}(k-d) = \text{sgn}(y(k)) \quad (2)$$

단, $\text{sgn}(y)$ 는 $y \geq 1$ 이면 $\text{sgn}(y) = 1$, $y < 1$ 이면 $\text{sgn}(y) = -1$ 을 출력하는 심벌 검출기이다.

본 논문에서 제안하는 FIAM형 非線形 適應等化器는 심벌 判定領域에서 전송심벌이 존재하는 해당 局部領域을 우선 推定하여 심벌 推定值인 어파인 寫像值(線形寫像에 常數가 더해진 형태의 寫像)를 생성한 후 퍼지規則 및 무게중심형 퍼지推論에 의해 最終 非線形 필터 $f(\cdot)$ 를 形成한다. 局部領域은 전송심벌이 존재하는 領域으로 無雜音時의 채널 狀態벡터 c_i 를 中心으로 形成되는 領域이다. 본 논문에서는 局部領域에서의 심벌을 어파인 寫像으로 推定하는 퍼지規則을 사용하는 데 이러한 퍼지規則은 Takagi-Sugeno가 提案한 퍼지規則과 同一하며 다음과 같다^[8].

Rule(i): If $x \in RF_i$,

$$\text{then } y(k) = \phi_i(\mathbf{x}(k), i=1, \dots, N)$$

여기서, RF_i (Receptive Field)는 i 번째 퍼지規則의 局部領域을 의미하며, N 은 퍼지規則의 수를 나타낸다. i 번째 局部領域 RF_i 에서의 심벌 推定值는 앞의 설명과 같이 (3)식과 같은 어파인 寫像이 된다.

$$\phi_i(\mathbf{x}) = \sum_{j=1}^n w_{ij}x_j + w_{i(n+1)} \quad (3)$$

단, w_{ij} 와 x_j 는 연결加重值 벡터 w_i 와 입력벡터 \mathbf{x} 의 j 번째 원소를 의미한다. 여기서, 퍼지規則의 if 부분은 참고문헌 [9]에서 지적한 퍼지推論 시스템과 방사형 기저함수와와의 等價性에 의해 (4)식과 같은 방사형 기저함수로 具現할 수 있다.

$$\mu_{RF_i}(\mathbf{x}) = \exp(-d_i^2(\mathbf{x})/\gamma) \quad (4)$$

단, $d_i(\mathbf{x})$ 는 유클리디안 (Euclidean) 거리 $\|\mathbf{x} - c_i\|$ 를 의미하고, γ 는 局部領域의 크기를 결정하는 파라미터이다. 본 등화기에서도 FAF형 等化器와 같이 무게중심형의 퍼지推論^[10]을 이용하기 때문에

(5)식과 같은 퍼지 기저함수에 의해 等化器 出力을 생성한다.

$$\bar{\mu}_{RF_i}(\mathbf{x}) = \frac{\mu_{RF_i}(\mathbf{x})}{\sum_k \mu_{RF_k}(\mathbf{x})} \quad (5)$$

上記의 퍼지規則 및 퍼지推論에 의해 생성되는 最終 適應필터 $f(\cdot)$ 는 다음식으로 表示된다.

$$f(\mathbf{x}(k)) = \sum_j \bar{\mu}_{RF_j}(\mathbf{x}) \phi_j(\mathbf{x}) \quad (6)$$

한편, 提案된 FIAM형 非線形 適應等化器는 그림 2와 같은 신경회로망 형태로 쉽게 具現할 수 있다. 즉, FIAM형 適應等化器는 가우시안 함수 노드 (GFN : Gaussian Function Node)와 어파인 寫像 노드 (AMN : Affine Mapping Node) 雙으로 構成되는 하나의 隱匿層을 갖는 신경회로망으로 構成할 수 있다. GFN은 노드중심, c_i 와 等化器 입력벡터, \mathbf{x} 와의 유클리디안 거리를 계산하여 GFN 노드에의 包含與否, 즉 심벌 判定領域에서 특정 局部領域에 包含되는 程度를 나타내는 값을 출력시킨다. 이에 의해 GFN은 RBFN형의 適應等化器와 기능이 유사한 의 $\mu: R^{m+n} \rightarrow R$ 寫像기능인 (4)식을 具現하는 노드이고, AMN은 MLP형의 適應等化器와 마찬가지로 입력벡터와 해당 노드와의 연결 加重值 간에 (3)식과 같은 어파인 寫像을 행하여 심벌 推定值를 생성하는 노드이다. 따라서, FIAM형 等化器에서 한개의 隱匿層 노드 雙에 의한 심벌 推定值, 즉 하나의 局部領域에서 출력하는 심벌 推定值는 GFN과 AMN 노드 出力值의 積이 되어 (7)식이 된다.




그림 2. FIAM형 비선형 적응등화기 블록 다이어그램.
Fig. 2. Block diagram of nonlinear adaptive equalizer based on FIAM.

$$h_i(\mathbf{x}) - \bar{\mu}_{RF,i}(\mathbf{x})\phi(\mathbf{x}) \quad (7)$$

각 노드 變의 심벌 推定値는 그림 2의 퍼지推論 과정과 출력 노드를 거쳐서 최종 심벌 推定値를 생성한다.

III. 適應 알고리즘

FIAM형 等化器의 適應 알고리즘은 MLP나 RBFN에서 通常적으로 사용되는 指導學習 (Supervised Learning)과 獨自學習 (Unsupervised Learning) 알고리즘을 사용할 수 있다. 본 논문에서는 指導學習 알고리즘과 獨自學習 알고리즘을 結合하여 自己構成 (Self-organizing) 기능을 갖는 適應 알고리즘을 사용하였다. 適應等化器에 입력벡터가 인가되면 GFN은 자기 局部領域에서의 包含程度를 나타내는 값을 출력하는데, 이때 모든 GFN 노드의 出力值 合이 미리 정해진 문턱값 Γ ($0 < \Gamma < 1$)보다 적으면 새로운 GFN과 AMN 노드가 생성된다. 이 경우 생성된 GFN 노드중심 c_i 는 입력벡터 $\mathbf{x}(k)$ 로 초기화 되고, 새로운 AMN의 연결 加重值 벡터, $\bar{\mathbf{w}}_i = [w_i, w_{n+1}]$ 는 랜덤 (random) 벡터로 초기화 된다. 만약에 GFN 노드 출력치의 합이 문턱값 Γ 보다 크면, 즉 適應等化器의 입력벡터가 어느 局部領域, RF,에 속하게 되면 가장 큰 값을 갖는 GFN 노드중심, c_i 는 K-means 클러스터링 (clustering) 알고리즘에 의해 (8)식과 같이 갱신되고, 이에 對應되는 AMN 노드와 입력벡터 간의 연결 加重值는 다음 절의 指導學習 알고리즘에 의해 適應된다.

$$\bar{c}_i(k+1) = \bar{c}_i(k) + \frac{1}{k+1}(x - \bar{c}_i(k)) \quad (8)$$

여기서, k 는 \bar{c}_i 의 갱신回數를 나타낸다. FIAM형 非線形 適應等化器에서는 이러한 獨自學習과 自己構成 방법을 사용하기 때문에 RBFN형 適應等化器 보다 GFN 노드수를 적게하면서도 그 이상의 等化性能을 얻을 수 있고, FAF형의 適應等化器에서 처럼 채널특성을 完壁하게 알아야 하는 短點을 극복할 수 있다^[5,7].

AMN 노드의 연결 加重值는 경사 추적법에 근거한 방법이나, LMS 또는 RLS 알고리즘 등과 같은 指導學習 알고리즘을 사용할 수 있는데, 일반적으로 RLS 알고리즘이 收斂속도가 빠르고 最適 加重值를 빠른 시

간내에 얻을 수 있는 長點이 있다. 따라서 본 논문에서는 RLS 알고리즘을 사용하는 FIAM형 等化器와 [5,7]에서 사용한 RLS 알고리즘과의 계산량을 比較하고자 한다. RLS 알고리즘은 수신 신호벡터, $\mathbf{x}(k)$ 와 원하는 신호 $s(k-d)$ 가 주어질 경우 (9)식의 코스트 (cost) 函數를 最小化하는 방법으로 等化器 파라미터를 適應시킨다.

$$J(k) = \sum_{i=0}^k \lambda^{k-i} [s(k-d) - f(\mathbf{x}(i))]^2 \quad (9)$$

단, $\lambda \in (0, 1)$ 의 값을 취하는 常數이다. FIAM형 非線形 適應等化器에서는 임의의 심벌구간 k 에서 최대 값을 갖는 GFN 노드에 對應되는 AMN 노드의 연결 加重值 算을 다음 식에 의해 適應시킨다.

$$G_i(k) = \frac{R_i(k-1) \bar{\mathbf{x}}}{\lambda + \bar{\mathbf{x}}^T R_i(k-1) \bar{\mathbf{x}}}, \quad (10)$$

$$R_i(k) = 1/\lambda [R_i(k-1) - G_i(k) \bar{\mathbf{x}}^T R_i(k-1)], \quad (11)$$

$$\bar{\mathbf{w}}_i(k) = \bar{\mathbf{w}}_i(k-1) + G_i(k) [s(k-d) - f(\mathbf{x}(k))], \quad (12)$$

$$R_i(0) = \alpha I, \quad (13)$$

여기서, $\bar{\mathbf{x}} = [\mathbf{x}, 1]$, I 는 $(n+m+1) \times (n+m+1)$ 次的 유니트 (unit) 행렬을 나타내며 α 는 $\alpha > 1$ 을 만족하는 常數이다.

IV. 既存 非線形 適應等化器와의 比較

본 논문에서 提案한 構造를 중심으로 代表的인 非線形 適應等化器가 갖는 근사화된 寫像기능을 알아보기로 한다. MLP형의 等化器에서는 수신 신호벡터와 노드 間의 연결 加重值들의 線形 結合值가 문턱값 (常數)을 갖는 시그모이드 (sigmoid) 函數로 活性化시키는 형태의 非線形 寫像에 의해 (14)식과 같이 근사화된 심벌 推定値를 생성하며 채널 等化器의 경우 通常적으로 2층 이상의 隱匿層을 사용한다^[2,6]

$$f(\mathbf{x}(k)) = \sum \omega_i \phi_i(\mathbf{x}) \quad (14)$$

단, β_i 는 인접 層사이의 연결 加重值를, $\mu_i(x)$ 는 시그모이드 活性化 函數를 나타낸다.

MLP는 구조적 특성상 경사 추적법을 사용하여야 하나 이는 莫大한 反復學習을 요구하므로 계산량은 매

우 많다. 반면에 RBFN의 경우에는 (15)식과 같이 방사형 기저함수와 隱匿層 및 출력층 사이의 연결 加重值들의 線形結合에 의해 심벌 推定值를 생성한다.

$$f(x(k)) = \sum_i \beta_i \mu_i(x) \quad (15)$$

여기서, β_i 는 隱匿層과 출력층 간의 연결 加重值이고, $\mu_i(x)$ 는 방사형 기저함수를 의미하는데 RBFN 노드 수는 채널 탭과 등화기 탭수에 좌우된다^[3]. 한편, FAF형의 適應等化器는 근본적으로 RBFN형과 동일한 構造이나 퍼지規則과 퍼지 기저함수를 사용하며 (16)식의 형태로 심벌을 推定한다^[15]

$$f(x(k)) = \sum_i \theta_i \bar{\mu}_i(x) \quad (16)$$

단, θ_i 는 수신 判定領域에서 定規化된 멤버십 함수 $\bar{\mu}_i(x)$ 에 의해 결정되는 파라미터로 퍼지規則의 수에 좌우된다. (6)식과 (14)식을 비교할 경우, (6)식의 $\bar{\mu}_{RF}(x)$ 는 (14)식의 w_i 에 대응하는 파라미터로 볼 수 있는데 FIAM형 適應等化器의 $\bar{\mu}_{RF}(x)$ 는 MLP의 無限길이 평면을 局部領域으로 제한하는 효과를 나타내게 되어 고속의 學習을 가능하게 한다. 따라서 FIAM형 適應等化器는 MLP의 경우보다 빠른 學習특성을 갖는다. 한편, (15)식과 (16)식의 常數 파라미터인 β_i 와 θ_i 는 (6)식의 $\phi_i(x)$ 에 대응하는데, $\phi_i(x)$ 는 어파인 寫像이기 때문에 常數보다는 非線形 함수로의 寫像이 쉽게 수행될 수 있다. 이러한 특성을 종합하면 FIAM형 適應等化器는 既存의 非線形 適應等化器에 비해 收斂속도 및 非線形 應答 특성이 改善될 수 있음을 알 수 있다.

표 1. 代表的인 非線形 適應等化器의 RLS 計算量 비교

Table 1. RLS computational load of the representative nonlinear adaptive equalizers.

等化器 형태	生成되는 GFN 노드數	I의 次數
RBFN	$2^{(n_s+n)}$	$2^{(n_s+n)} \times 2^{n_s+n}$
FAF	N^n	$N^n \times N^n$
FIAM	$\leq 2^{(n_s+n)}$ and/or $\leq N^n$	$(n+1) \times (n+1)$
LTE/DFE	-	$(n) \times (n)$

한편, RBFN, FAF, FIAM 및 LTE형 等化器에서

RLS 학습에 따른 계산량은 각 等化器 파라미터, 즉 RBFN의 β_i , FAF의 θ_i , FIAM의 어파인 寫像을 위한 및 LTE의 선형필터 계수에 대하여 RLS 학습시 필요한 유니트 행렬, I의 次數에 의해 상대적으로 비교될 수 있다. 채널의 次數가 n_c 이고 等化器 次數가 n , 즉 $x(k), x(k-1), \dots, x(k-n)$ 을 適應等化器 입력벡터로 사용할 경우에 있어서 각 適應等化器의 유니트 행렬의 次數는 표 1과 같다.

위에서 알 수 있듯이 FIAM형의 경우 RLS 계산량은 適應等化器에 인가되는 입력 탭수에 좌우되며, RBFN의 경우는 (15)식으로 부터 RBFN 노드 수에 좌우되는데 표 1과 같이 通常의 RBFN 노드 수는 FIAM형 適應等化器의 입력 탭수보다 훨씬 큰 값을 갖게 된다. 한편, FAF형 適應等化器의 RLS 계산량은 입력 탭에 적용되는 퍼지規則의 수에 좌우되며 퍼지規則의 수도 等化器의 입력 탭수 보다는 훨씬 큰 값을 갖게된다^[15]. 고속 온라인 適應을 위해서는 매 심벌 구간에서 適應알고리즘에 따른 계산량이 既存의 방식보다 월등히 감소되어야 한다. RLS 適應시 매 심벌 구간에서의 계산량은 等化器 파라미터 次數 N에 의해 결정되는데 파라미터 벡터의 適應 계산량은 2N번의 덧셈과 2N번의 곱셈이 필요하게 되고 상관행렬의 逆행렬을 適應하기 위해서는 $3N(N+1)/2$ 번의 덧셈과 $2N(N+1)$ 번의 곱셈이 필요하다. 따라서 제안한 適應等化器는 표 1에서와 같이 等化器 파라미터의 次數가 線形等化器와 비슷하기 때문에 다른 非線形 等化器와는 달리 온라인 適應이 可能함을 알 수 있다.

V. 非線形 채널에의 應用

衛星通信이나 移動通信 채널에서는 高出力 증폭기에 의한 非線形성과 多重經路 페이딩(fading)과 같이 가우시안 형태가 아닌 干涉 신호가 존재하며, 이러한 非線形 채널에서는 기존의 線形 適應等化器로는 만족할 만한 BER 성능을 얻을 수 없다. 따라서, 이의 解決을 위해서는 非線形 適應等化器의 사용이 必需的이다. 본 절에서는 最近 發表되었던 非線形 適應等化器와 FIAM형 非線形 適應等化器와의 성능비교를 위해 [4,5,6]에서 사용하였던 (17)식, (18)식 및 (19)식과 같은 非線形 채널과 非最小位相 채널에 대해 성능을 비교하고자 한다. 여기서 채널은 전송필터, 전송媒體 및 수신

필터를 包含하는 것으로 假定하고, 채널의 출력신호에는 가우시안 雜音, n_k 가 加算되는 것으로 假定한다.

$$r(k) = s(k) + 0.5s(k-1) - 0.9[s(k) + 0.5s(k-1)]^3 + n_k \quad (17)$$

$$r(k) = 0.4084s(k) + 0.8164s(k-1) + 0.4084s(k-2) + n_k \quad (18)$$

$$r(k) = 0.5[0.4084s(k) + 0.8164s(k-1) + 0.4084s(k-2)]^3 + n_k \quad (19)$$

(17)식 채널의 경우 RLS 알고리즘을 사용하는 FAF형 適應等化器는 2차원 判定領域 (判定제한없이 $r(k), r(k-1)$ 을 사용하는 判定領域) 상에서 각각 9개의 퍼지規則을 사용하였을 때 最適 等化器와 같은 성능을 얻을 수 있는 것으로 報告된 바 있다¹⁵⁾. 이 결과와 FIAM형 適應等化器의 결과를 비교하기 위해서 適應等化器의 입력 탭수를 [5]의 FAF형 適應等化器와 같이 제한없이 $r(k), r(k-1)$ 만을 사용하도록, 즉 $m=0, n=2, d=1$ 이 되도록 設定하였다. 이때 RLS 適應等化器의 파라미터를 $\lambda=1, \gamma=0.1, \Gamma=0.03$ 로 設定한 후 1,000 심벌 구간 동안 適應等化器를 學習시킨 후에 SNR에 따른 BER을 분석하였다. 이 채널에 $m=n=2, d=1$ 이 되도록 設定하여 DFE 형태로 동작시키면 BER 성능이 더욱 改善됨을 알 수 있다. 그림 3에 보인 바와 같이 FIAM형 非線形 適應等化器의 BER 성능은 FAF형 非線形 適應等化器 성능과 거의 같음을 알 수 있으나, RLS 계산량 (I 의 次數)을 고려하면 FAF형의 경우는 $81(=9^2)$ 인 반면에 FIAM형의 경우는 $3(=m+n+1)$ 이 되고, 判定 제한이 있는 경우는 5가 되어 越等한 계산량 減少 效果를 얻을 수 있다.




그림 3. 채널 (16)에 대한 BER 성능 비교
Fig. 3. BER performance comparison for the channel (16).

한편, (18)식과 같은 非最小位相 채널인 경우는 上記의 RLS를 사용하는 FAF형 適應等化器나 判定 제한 탭이 없는 FIAM형 ($m=0, n=2, d=1$) 非線形 適應等化器에 의해서는 그림 4의 결과와 같이 만족할 만한 BER 성능을 얻을 수 없다. 그러나 FIAM형 適應等化器의 파라미터를 判定 제한 탭 ($m=n=2, d=1$)이 있도록 設定하면 FAF형 適應等化器로는 얻을 수 없었던 優秀한 BER 성능을 얻을 수 있다. 이러한 제한 탭을 갖는 DFE 형태의 FIAM형 適應等化器의 RLS 계산량 (I 의 次數)의 增加量은 거의 無視할 수 있을 정도이다. 본 實驗에서는 (17)식의 채널에서와 같이 각각 9개의 퍼지規則을 갖는 FAF형 適應等化器를 사용하였는데 이 경우 FAF형의 RLS 次數는 81인 반면에 FIAM형의 경우는 $5(=m+n+1)$ 로 매우 미미한 증가량을 갖는다.




그림 4. 채널 (17)에 대한 BER 성능 비교
Fig. 4. BER performance comparison for the channel (17).

한편, 그림 5는 (19)식과 같은 非線形 채널에서의 FIAM형 ($m=n=2, d=1$) 等化器와 5개의 입력노드, 8개의 隱匿層 노드와 1개의 출력노드를 갖는 構造를 취하면서 誤差 逆傳播 방법을 사용하는 MLP형 ($m=3, n=2, d=1$) 等化器의 BER 성능을 나타낸다. 여기서 MLP형 경우는 FIAM형 等化器와 비슷한 결과를 얻기 위하여 10^5 심벌구간의 學習이 필요하기 때문에 10^3 개 정도의 學習심벌을 필요로 하는 FIAM형 等化器가 適應시의 收斂속도, 適應시의 계산량면에서는 越等히 優秀함을 알 수 있다. 이러한 實驗結果에서 알 수 있듯이 본 논문에서 提案한 FIAM형 非線形 適應等化器는 非線形性이 심한 채널이나 非最小位相 채널 모

두에서 既存의 非線形 適應等化器 보다 優秀한 特성을 가짐을 알 수 있다.




그림 5. 채널 (18)에 대한 BER 성능 비교
Fig. 5. BER performance comparison for the channel (16).

VI. 結 論

본 論文에서 提案한 FIAM형 非線形 適應等化器는 非最小位相 채널이나 非線形 채널에 適用할 경우에 既存의 非線形 適應等化器와 類似한 BER 性能을 가지면서도, 고속의 學習이 可能할 뿐만 아니라 신경회로망과 퍼지 適應필터의 結合에 의해 두 構造의 長點을 쉽게 實現할 수 있는 構造的 融通性이 있다. 또한 [5,7]에서와 같이 RLS 適應 알고리즘을 適用할 境遇 既存의 非線形 適應等化器와는 달리 每 심벌 구간마다 오직 한 쌍의 AMN과 GFN 노드만이 適應되기 때문에 適應시의 계산량이 거의 線形 適應等化器의 境遇와 같게 되어 on-line 適應이 可能함을 알 수 있다. 한편, 채널의 특성에 따라서 靚환 템을 자유롭게 挿入하므로써 一般의 DFE 형태로 쉽게 具現될 수 있는 長點이 있을 뿐만 아니라 FAF형 適應等化器에서와 같이 퍼지規則의 設定시 要求되는 채널특성에 대한 거의 完璧한 事前知識이 없어도 만족할 만한 BER 性能을 얻을 수 있는 長點을 갖는다.

참 고 문 헌

[1] J. G. Proakis, *Digital Communications*, McGraw-Hill, 2. Ed., 1989.
[2] M. Meyer and G. Pfeiffer, "Multilayer

perceptron based decision feedback equalizers for channels with intersymbol interferences", *IEE proceedings-I*, vol. 140(6), pp. 420-424, 1993.

[3] S. Chen, B. Mulgrew and P. M. Grannt, "A Clustering technique for digital communication channel equalization using radial basis function network", *IEEE Trans. Neural Network*, vol. 4, no. 4, pp. 570-579, July 1993.
[4] S. Chen, B. Mulgrew and S. McLaughlin, "Adaptive Bayesian equalizer with decision feedback", *IEEE Trans. Signal Processing*, vol 41, no. 9, pp. 2918-2927, September 1993.
[5] L. X. Wang and J. M. Mendel, "Fuzzy Adaptive Filters, with Application to Nonlinear Channel Equalization", *IEEE Trans. Fuzzy Systems*, vol. 1, no. 3, pp. 161-170, August 1993.
[6] M. Meyer and G. Pfeiffer, "Multilayer Perceptron based Equalizers applied to Nonlinear Channels", *Proceedings of International Workshop on Applications of Neural Networks to Telecommunications*, pp. 188-195, 1993.
[7] K. Y. Lee, "Fuzzy adaptive decision feedback equaliser", *Electronics Letters*, vol. 30, no. 10, pp. 749-751, May 1994.
[8] T. Takagi and M. Sugeno, "Fuzzy Identification of systems and its application to Modeling and Control", *IEEE Trans. Systems, man and Cybernetics*, vol. 15, no. 1, pp.116-132, 1985.
[9] J.-S. R. Jang and C.-T. Sun, "Functional Equivalence between Radial Basis Function Networks and Fuzzy Inference Systems", *IEEE Trans. Neural Networks*, vol. 4, no. 1, pp.156-159, January 1993.
[10] L.X. Wang and J.M. Mendel, "Fuzzy basis functions, universal approximation and orthogonal least squares learning", *IEEE Trans. Neural Networks*, vol. 3, no. 5, pp.807-814, May 1993.

저 자 소 개

吳 德 吉(正會員)

1957년 11월 28일생. 1980년 서울대학교 전자공학과 졸업. 1982년 서울대학교 대학원 전자공학과 졸업. 1990년 서울대학교 대학원 전자공학과 박사과정 수료. 1995년 ~ 현재 한국전자 통신연구소 위성통신기술연구단 책임연구원. 주관심분야는 통신신호처리, 적응신호처리, 통신시스템 및 퍼지시스템 등임.

李 忠 雄(正會員)

1935년 5월 3일생. 1958년 서울대학교 전자공학과 졸업. 1960년 서울대학교 대학원 전자공학과 졸업. 1972년 동경대학교 공학박사. 1964년~ 현재 서울대학교 전자공학과 교수. 1989년 1월~1989년 12월 대한전자공학회 회장. 1989년 1월~현재 IEEE Fellow. 1991년 6월~현재 서울대학교부설 뉴미디어통신 공동연구소 소장. 주관심분야는 통신시스템, 화상 & HDTV 신호처리, 의용전자 등임.

崔 鎮 榮(正會員)

1959년 7월 16일생. 1982년 서울대학교 제어계측공학과 학사. 1984년 서울대학교 대학원 제어계측공학과 석사. 1993년 서울대학교 제어계측공학과 박사. 1984년~1994년 2월 한국전자통신연구소 선임연구원. 1994년~현재 서울대학교 제어계측공학과 전임강사. 주관심분야는 Neuro-Fuzzy System, Adaptive & Learning System, Adaptive Control of Autopilot, Detection & Recognition System.