

---

# 직접순차 확산 스펙트럼 시스템에서 데이터 재순환 적응 횡단선 필터의 LMS 알고리즘을 이용한 고속 수렴 속도 개선

김광준\* · 윤찬호\*\* · 김천석\*\*\*

## The Improvement of High Convergence Speed using LMS Algorithm of Data-Recycling Adaptive Transversal Filter in Direct Sequence Spread Spectrum Systems

Gwang-Jum Kim\* · Chan-Ho Yoon\*\* · Chun-Suk Kim\*\*\*

---

본 논문은 여수대학교 2004년도 학술연구과제 지원비에 의하여 연구되었음

---

### 요 약

본 논문에서 직접순차 확산 스펙트럼 시스템의 적응 횡단선 필터에서 LMS 알고리즘의 수렴 속도를 향상시키기 위한 효율적인 신호간섭 제어기법을 제안한다. 수신 데이터를 재순환하여 심볼 시간 주기에 계수들을 곱함으로써 적용되는 제안된 알고리즘의 수렴특성이 수렴 속도의 향상을 이론적으로 증명하기 위해 분석한다. 스텝-크기 매개변수  $\mu$ 가 증가됨에 따라 알고리즘의 수렴 속도가 제어된다. 또한, 스텝-크기 매개변수  $\mu$ 의 증가는 실험적으로 계산된 학습 곡선에서 분산을 감소시키는 효과를 갖는다. 고유치 확산을 증가시킴에 따라 적응 등화기의 수렴속도를 천천히 제어하고 평균 자승 에러의 안정-상태 값을 증가시키는 효과를 나타내며 데이터-재사용 LMS 기술이 수렴속도를 (B+1)배만큼 증가시켜 필터 알고리즘에서 신호간섭제어의 우수성을 입증한다.

### ABSTRACT

In this paper, an efficient signal interference control technique to improve the high convergence speed of LMS algorithm is introduced in the adaptive transversal filter of DS/SS. The convergence characteristics of the proposed algorithm, whose coefficients are multiply adapted in a symbol time period by recycling the received data, is analyzed to prove theoretically the improvement of high convergence speed. According as the step-size parameter  $\mu$  is increased, the rate of convergence of the algorithm is controlled. Also, an increase in the step-size parameter  $\mu$  has the effect of reducing the variation in the experimentally computed learning curve. Increasing the eigenvalue spread has the effect of controlling which is downed the rate of convergence of the adaptive equalizer. Increasing the steady-state value of the average squared error, proposed algorithm also demonstrate the superiority of signal interference control to the filter algorithm increasing convergence speed by (B+1) times due to the data-recycling LMS technique.

### 키워드

LMS Algorithm, High Convergence Speed, Step-size Parameter, Data-Recycling Adaptive Transversal Filter

---

\* 여수대학교 컴퓨터공학과  
접수일자 : 2005. 1. 12

\*\* 조선대학교 컴퓨터공학과  
\*\*\* 여수대학교 전자통신공학과

## 1. 서론

통신 시스템에서 더욱 개선된 실행을 요구하는 필요성을 만족시키기 위해 적응 필터는 필수적이다. 또한, 빠른 수렴 속도를 갖는 적응 필터 알고리즘과 비교적 낮은 평균 자승 에러(MSE : Mean Square Error), 하드웨어 성능에 대한 실용성을 요구한다[1,2].

횡단선 적응필터에 수신되는 간섭신호를 제거하기 위한 방법으로 최소 평균 자승(LMS : Least Mean Square) 알고리즘이 이용되는데 이 방식은 간결성과 효율성 때문에 광범위하게 이용되어왔다[3,4,5]. 그러나 횡단선 필터 탭 계수들을 조절하기 위한 새로운 반복 알고리즘이 개발되어 왔으며[6], 이 알고리즘은 탭 계수들의 상수를 유지하는 개별 탭 계수를 갱신하기 위해 LMS 알고리즘을 이용한다.

본 논문에서는 LMS 알고리즘을 이용한 탭 계수 지연 라인(TDL : Tapped Delay Line) 적응 필터의 빠른 수렴 속도에 대해 효율적인 신호간섭 제어기법을 제시한다.

적응 필터의 탭 가중치를 적응 제어하기 위해 단일 탭 입력 벡터를 이용하는 대신에 몇몇의 한정된 버퍼들에 저장되는 탭 입력 벡터들을 이용하는 데이터 재순환 알고리즘을 이용함으로써 적응 탭 가중치 벡터의 갱신을 통한 빠른 수렴성을 나타내기 위해 새로운 구조를 제안하고, 연산 복잡성을 증가시키지 않고 충분히 수렴속도를 (B+1)배로 향상시킨다.

LMS 알고리즘의 계수특성을 분석하고 탭 계수에 따른 신호 간섭 제어와 LMS 알고리즘의 수렴 조건 및 연산의 복잡성 제어에 관하여 분석하여 제안한 데이터-재사용 LMS 알고리즘을 이용한 컴퓨터 시뮬레이션 결과를 통해 이론적 분석이 부합함을 보인다.

제안된 TDL 필터가 LMS 알고리즘과 동일한 수렴 조건을 가지고 실행될 때 연산의 복잡성의 실질적 부담을 배제하고, TDL 필터의 수렴속도를 증가시킬 수 있다는 신호간섭 제어의 우수성을 입증한다.

## II. LMS 알고리즘의 모델링

### 2.1 적응가중치 조절 메카니즘

적응 횡단선 필터의 탭 가중치를 갱신하기 위해서는 두 가지 처리 과정으로 이루어진다[3,4]. 첫 번째는 최적의 이론으로 잘 알려진 급경사 방법을

이용하는데 최적의 해로 정의된 행렬 Wiener-Hopf 방정식을 통하여 시스템을 수정한다. 두 번째는 통계적 특성으로 가정된 경사 벡터에 대한 추정치를 유도하기 위해 상관에 대한 연속적인 값을 필요로 한다. 본 논문은 이러한 처리과정을 모두 만족시키는 LMS 알고리즘을 응용하여 실수 값 데이터러 가진 횡단선 필터의 탭 가중치 벡터에서 갱신된 탭 가중치 값과 탭 입력 벡터 에러 신호 그리고 학습을 변수를 기술한다.

각각의 반복 순차 n에서 기울기 벡터  $\nabla J(n)$ 의 정확한 측정을 하고 스텝 크기 매개변수  $\mu$ 가 적절하게 선택되어지면, 급 경사 알고리즘을 이용하여 계산된 탭 가중치 벡터는 최적의 Wiener 해에 근접한다. 그러나, 실제로 탭 입력의 상관 행렬 R과 탭 입력과 원하는 응답 사이의 교차 상관 벡터 p를 사전에 알 수 있어야 하므로 경사 벡터의 정확한 측정이 불가능하다. 그러므로 경사 벡터는 가능한 데이터로부터 측정되어야 한다[7].

경사 벡터  $\nabla J(n)$ 의 측정을 향상시키기 위해 가장 확실한 방법은 상관 행렬 R과 교차 상관벡터 p를 빼는 것으로서 식 (2.1)과 같이 나타낸다.

$$\nabla J(n) = -2p + 2Rw(n) \quad (2.1)$$

R과 p를 위한 선택은 개별적으로 다음과 같이 정의된 탭 입력 벡터와 요구된 응답의 표본 값을 기반으로 하는 순간적 예측을 사용하는 것으로 식 (2.2), (2.3)과 같다.

$$\hat{R}(n) = u(n)u^H(n) \quad (2.2)$$

$$\hat{p}(n) = u(n)d^*(n) \quad (2.3)$$

기울기 벡터의 순간 예측은 식 (2.4)와 같다.

$$\hat{\nabla} J(n) = -2u(n)d^*(n) + 2u(n)u^H(n)\hat{w}(n) \quad (2.4)$$

순간 예측은 탭 가중치 예측 벡터  $\hat{w}(n)$ 이 탭 입력 벡터 u(n)에 의존하는 임의의 벡터이기 때문에 교차된다.

예측  $\hat{\nabla} J(n)$ 은 순간적 자승 오차  $|e(n)|^2$ 을 적용한 기울기 연산자  $\nabla$ 로 한다. 식 (2.2)의 예측은  $w(n+1) = w(n) + 1/2 \mu [-\hat{\nabla} J(n)]$ 에서 나타난 경사가 급 경사하는 알고리즘에서 기울기 벡터

$\nabla J(n)$ 로 대체시키므로, 탭 가중치 벡터를 갱신하기 위한 새로운 순환적 관계는 식 (2.5)와 같다.

$$\hat{w}(n+1) = \hat{w}(n) + \mu u(n) [d^*(n) - u^H(n) \hat{w}(n)] \quad (2.5)$$

경사가 급 경사 알고리즘으로 얻어진 값을 구분하기 위해 탭 가중치 벡터를 위한 심볼 위에  $\hat{w}$ 을 사용한다. 필터 출력, 에러측정 및 가중치 적용을 기술하는 식은 각각 식 (2.6), (2.7) 및 식 (2.8)과 같다.

$$y(n) = \hat{w}^H(n) u(n) \quad (2.6)$$

$$e(n) = d(n) - y(n) \quad (2.7)$$

$$\hat{w}(n+1) = \hat{w}(n) + \mu u(n) e^*(n) \quad (2.8)$$

식 (2.6)과 (2.7)은 예측 오차  $e(n)$ 와 탭 가중치 벡터  $\hat{w}(n)$ 의 예측을 기반으로 한 계산을 정의하고, 식 (2.8)에서 우변의 두 번째 항  $\mu u(n) e^*(n)$ 은 탭 가중치 벡터  $\hat{w}(n)$ 에 대한 현재의 예측에 적용된 교정을 나타낸다. 반복적 처리 절차는 초기 추정  $\hat{w}(0)$ 에서 시작한다.

식 (2.6)과 (2.8)에서 나타난 알고리즘은 LMS 알고리즘의 복잡한 형태이나 각각의 반복 또는 시간 갱신에서 가장 최근의 값을 요구하기 때문에  $u(n)$ 과  $d(n)$  그리고  $\hat{w}(n)$ 은 LMS 알고리즘의 통계학적 기율기에 대한 집합이 된다. 특히, LMS 알고리즘은 통계학적 입력들과 다음번의 반복 주기까지 스텝은 임의로 중단되고 실제 기율기 방향으로 간주될 수 없는 방향에서 수락된 집합을 연산한다.

그림 1은 폐환 모델에서 LMS 알고리즘의 신호 흐름 선도를 보여준다. 이 신호 흐름 선도는 기율기가 급 경사 알고리즘을 나타낸 흐름선도로서 폐환 모델[8]과 밀접한 유사성을 갖는다.

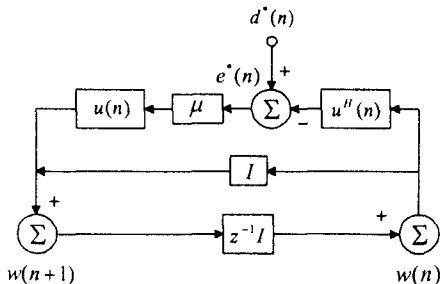


그림 1. LMS 알고리즘의 신호 흐름  
Fig. 1 Signal-flow graph representation of the LMS algorithm

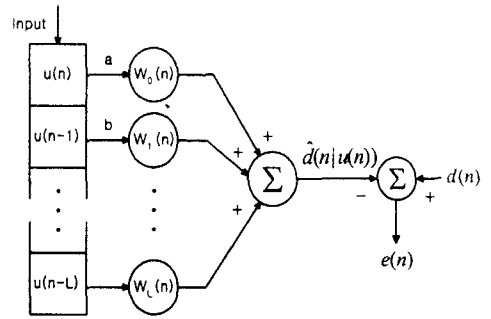


그림 2. 적응 횡단선 필터  
Fig. 2 Adaptive transversal filter

그림 2의 상위 부분에서 나타낸 횡단선 필터 구조를 고려하면, 필터 출력의 추정치  $\hat{d}(n | u(n))$ 는 입력 신호 벡터  $u(n)$ 와 탭 가중치 벡터  $w(n)$ 로 다음의 식 (2.9)을 얻는다.

$$\begin{aligned} \hat{d}(n | u(n)) &= \sum_{j=0}^L w_j(n) \cdot u(n-j) \\ &= \hat{w}^H(n) \cdot u(n) \end{aligned} \quad (2.9)$$

에러 신호  $e(n)$ 는 요구된 신호  $d(n)$ 와 횡단선 필터 출력  $\hat{d}(n | u(n))$  사이의 차로써 나타낸다. 따라서, 적응 가중치 조절 메카니즘을 통하여 조절된 탭 가중치는 식 (2.10)과 같다.

$$\begin{aligned} w(n+1) &= w(n) - \mu \cdot \left( \frac{\delta e^2(n)}{\delta w(n)} \right) \\ &= w(n) + 2\mu \cdot e(n) \cdot u(n) \end{aligned} \quad (2.10)$$

탭 계수를 갱신하기 위해 단일 탭 입력 데이터  $u(n)$ 을 이용하는 대신에, 몇몇의 한정된 버퍼에 저장되는 탭 입력 데이터 ( $u(n-1)$ ,  $u(n-2)$ ,  $u(n-3)$ ...)을 이용하고 탭 가중치 벡터의 갱신 처리와 재활용 데이터에 이용되는 버퍼를 갖는 구조는 그림 2와 같다.

### 2.2 데이터 재순환 적응 횡단선 필터

그림 3은 그림 2의 입력 벡터에서 탭 가중치를 조절하기 위해 이용된 두 개의 탭 a, b에 각각 버퍼를 두어 폐기된 데이터를 재활용하는 재활용 데이터(B=2)를 이용한 제안된 구조를 나타내었다.

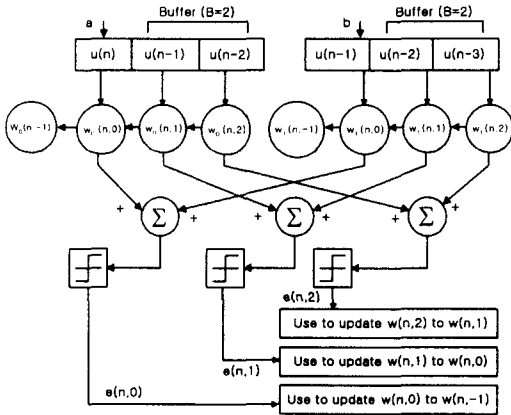


그림 3. 제안된 데이터-재사용 필터의 구조  
Fig. 3 The proposed data-recycling filter structure

그림 3에서 나타낸 바와 같이 처음에 탭 a의 버퍼에서 재사용 데이터  $u(n-2)$  와 탭 b의 버퍼에서 재사용 데이터  $u(n-3)$ 은 에러  $e(n,2)$ 을 이용하여  $w(n,2) = [w_0(n,2), w_1(n,2)]^H$ 을  $w(n,1) = [w_0(n,1), w_1(n,1)]^H$ 로 갱신하고 다음으로  $w(n,1) = [w_0(n,1), w_1(n,1)]^H$ 는  $u(n,1) = [u(n-1), u(n-2)]^H$ 와  $e(n,0)$ 을 이용하여  $w(n,0) = [w_0(n,0), w_1(n,0)]^H$ 로 갱신된다.

마지막으로 탭 입력 데이터 벡터  $u(n-0) = [u(n-0), u(n-1)]^H$ 와 탭 가중치 벡터  $w(n,0) = [w_0(n,0), w_1(n,0)]^H$ 는  $e(n,0)$ 을 생성한다.  $w(n,-1)$ 는 횡단선 필터의 다음 출력 추정치  $\hat{d}(n+1 | u(n+1))$ 을 생성하는데 이용될 수 있는 횡단선 필터 탭 가중치 벡터  $w(n+1)$ 에 복사된다.

### III. LMS 알고리즘 계수특성에 의한 신호간섭제어

#### 3.1 탭 계수속도 신호제어

데이터 재순환 알고리즘을 이용하여 탭 가중치 벡터를 갱신하기 위한 처리 과정은 다음 4단계로 구분하여 실현될 수 있다.

단계 1 : 횡단선 필터 구조의 입력신호벡터  $u(n)$ 와 탭 가중치 벡터  $w(n)$ 를 초기화 한다.

단계 2 : 재순환 데이터  $B$ 를 결정한다.

단계 3 : 에러  $e(n)$ 를 이용하여 탭 가중치 벡터

$w(n)$ 를 갱신하기 위하여 재순환 데이터 수만큼 반복하여 갱신한다.

단계 4 : 횡단선 필터 출력  $\hat{d}(n+1 | u(n+1))$ 을 생성하는데 이용되는 필터 계수 벡터  $w(n)$ 를  $w(n+1)$ 에 복사한다.

여기서  $w(n+1)$ 과  $w(n)$  사이의 관계는 다음 식 (3.1)과 같다.

$$w(n+1) = w(n) + 2\mu \sum_{i=0}^B e(n,i) u(n-i) \quad (3.1)$$

에러추정치  $e(n,i) = d(n-i) - w^H(n,i)u(n-i)$ 의 이용과 식 (3.1)의 탭 가중치 갱신의 기대 값을 취하면 식 (3.2)을 얻는다.

$$\begin{aligned} E[w(n+1)] &= E[w(n)] + 2\mu \sum_{i=0}^B (E[d(n-i)u(n-i)] \\ &\quad - E[u(n-i)u(n-i)^H]E[w(n,i)]) \end{aligned} \quad (3.2)$$

식 (3.2)에서 탭 입력 데이터와 탭 가중치는 독립적이라고 가정할 수 있으며, 상관행렬  $R$ 을  $R = E[uu^H]$ 라 정의하면, 다음과 같은 식 (3.3)을 얻는다.

$$\begin{aligned} E[w(n+1)] &= E[w(n)] + 2\mu \sum_{i=0}^B (E[d(n-i)u(n-i)] \\ &\quad - R \cdot E[w(n,i)]) \end{aligned} \quad (3.3)$$

$R$ 이 정측행렬일 경우를 가정하면,  $R$ 과 최적 탭 가중치 벡터  $w^0$ 의 적분이  $E[\hat{d}(n-1 | u(n-1))u(n-1)]$ 과 동일하다. 따라서  $E[w(n+1)] = E[w(n)] + 2\mu \sum_{i=0}^B (Rw^0 - RE[w(n,i)])$ 이다.

다른 측면에서 입력 상관 행렬  $R$ 은 일반적 형태  $R = Q \Lambda Q^{-1}$ 로 표현되며, 여기서  $\Lambda$ 는 대각 고유치 행렬이고  $Q$ 는  $R$ 의 고유치 벡터 행렬이다.  $V = Q^{-1}V$ 를 이용하는 중심축으로  $V(n)$ 를 회전하면, 결과는 식 (3.4)와 같다.

$$\begin{aligned} V'(n+1) &= Q^{-1}(d(n) - 2\mu R)QV'(n) \\ &\quad - 2\mu \sum_{i=0}^B Q^{-1}RQV'(n,i) \\ &= (d(n) - 2\mu \Lambda)V'(n) - 2\mu \sum_{i=0}^B \Lambda V'(n,i) \end{aligned} \quad (3.4)$$

$V'(n+1)$  그리고  $V'(n)$ 와  $V'(n,i)$ 의  $j$  번째 인수는 각각  $v'(n+1,0,j)$ ,  $v'(n,0,j)$  그리고  $v'(n,i,j)$ 이다. 이렇게 대응하는 인수를 이용함으로써, 식 (3.4)을 식 (3.5)과 같이 쓸 수 있다.

$$\begin{aligned} v'(n+1,0,j) &= (1-2\mu\lambda_j)v'(n,0,j) - 2\mu\lambda_j v'[v'(n,i,j) \\ &\quad + v'(n,2,j) + \dots + v'(n,B,j)] \\ &= v'(n,0,j) - 2\mu\lambda_j[v'(n,0,j) + v'(n,1,j) \\ &\quad + v'(n,2,j) + \dots + v'(n,B,j)] \end{aligned} \quad (3.5)$$

$v'(n,B,j)$ 의 항은 다음 식 (3.6)의 반복에 의해  $v'(n,0,j)$ 가 된다.

$$v'(n,B-i,j) = (1-2\mu\lambda_j)v'(n,B-i+1,j) \quad (3.6)$$

기하학적 비율  $1-2\mu\lambda$ 인 식은 다음의 식 (3.7), (3.8)과 같다.

$$\begin{aligned} v'(n+1,0,j) &= v'(n,0,j) - 2\mu\lambda_j \left[ \frac{v'(n,0,j)(1-(1-2\mu\lambda_j)^{B+1})}{(1-(1-2\mu\lambda_j))} \right] \end{aligned} \quad (3.7)$$

$$v'(n+1,j) = v'(n,j) \left[ \frac{1-2\mu\lambda_j(1-(1-2\mu\lambda_j)^{B+1})}{(1-(1-2\mu\lambda_j))} \right] \quad (3.8)$$

위 식을 재배열하면 식 (3.9)과 같다.

$$v'(n+1,j) = v'(n,j) - 2\mu\lambda_j \frac{\left[ \frac{v'(n,j)}{2\mu\lambda_j} - \frac{v'(n,j)(1-2\mu\lambda_j)^{B+1}}{2\mu\lambda_j} \right]}{v'(n,j)(1-2\mu\lambda_j)^{B+1}} \quad (3.9)$$

식 (3.9)은 현재의 탭 계수와 최적화 계수사이의 차이가 이들의 기하학적 비율인  $(1-2\mu\lambda_j)^{B+1}$ 로 감소함을 나타낸다. LMS 알고리즘  $1-2\mu\lambda_j$ 에 대한 기하학적 비율과 비교해 보면, MSE 비율은 다음의 식 (3.10), (3.11)과 같다.

$$MSE \text{ ratio} = (1-2\mu\lambda_j)^{2(B+1)} \quad (3.10)$$

또한

$$\log(MSE \text{ ratio}) = (B+1)\log(1-2\mu\lambda_j)^2 \quad (3.11)$$

위 식의 결과로 인해 본 연구에서 제안한 LMS 알고리즘에 의해 얻은 결과는 기존의 LMS 알고리즘에 의해 얻은 결과와 비교하여 (B+1)배 만큼의 개선된 수렴 속도를 갖게 됨으로써 비트 제어가 안정적임을 입증하였다. 식 (3.11)의 결과는 제안된 알고리즘의 비트 에러 제어가 안정적이고 식 (3.12)과 같을 때  $j$ 번째 계수에 대해 수렴된다.

$$\lim_{k \rightarrow \infty} (1-2\mu\lambda_j)^{(B+1)k} = 0 \quad (3.12)$$

식 (3.12)에서, 식 (3.13)을 충족하는 스텝 크기 매개 변수  $\mu$ 의 수렴조건은 다음 식과 같다.

$$0 < \mu < \frac{1}{\lambda_{\max}} \quad (3.13)$$

위 식에서  $\lambda_{\max}$ 가 횡단선 필터의 탭 입력 데이터 상관행렬  $R$ 의 최대 고유치 일 때, 식 (3.13)의 조건은 LMS 알고리즘과 동일한 결과이므로 평균 자승에서 LMS 알고리즘의 수렴은 실제 조건에 상응하는 스텝 크기 매개변수  $\mu$ 를 선택함에 의해 안정적인 비트 에러 제어가 보장되기 때문에 LMS 알고리즘에서 적절한 스텝 크기 매개변수의 선택은 중요하다.

### 3.2 연산의 복잡성 제어

정적 채널(Static Channel)보다 급격히 변하는 빠른 페이딩 채널의 적응 등화에는 탭 수가 증가하므로 전방 탭 계수(FN : Forward N)를 8개, 후방 탭 계수(BN : Backward N)를 2개로 하여 결정 케환 등화기(DFE : Decision Feedback Equalizer) 알고리즘을 고려할 때 계수 갱신을 위한 연산의 복잡성은 RLS의 경우 100 (N<sup>2</sup>)이고 LMS의 경우 21 (2N+1)이다. 또한 LS 격자 필터의 경우 131(18FN+39BN-39+2LF)이고 Kalman 필터의 경우 297(2.5 N<sup>2</sup>+4.5N+2)이다[9,10].

제안된 알고리즘은 각각의 탭 계수에 대하여 (2N+1)번의 곱셈 연산과 재사용 데이터 수 B에 대하여 (B+1)번의 곱셈 연산을 하여 전체 탭 계수를

모두 갱신하기 위한  $(2N+1)(B+1)$ 가 되므로  $B$ 를 2개로 할 때 연산의 복잡도는 63이 되며 성능은 기존의 LMS 알고리즘보다 3배가 개선된다. 여기서  $N$ 은 탭 계수를 나타내고,  $B$ 는 재활용 데이터의 수이다.

위의 4가지 알고리즘에서 LMS 결정 궤환 알고리즘에 대해서만 연산의 복잡도가 높으나 본 논문에서 제안된 알고리즘이 기존 LMS 알고리즘의 수렴 속도를  $(B+1)$ 배 만큼 증가시킨다는 것을 고려하면 제안된 알고리즘이 연산 복잡성이 증가하지 않으면서 수렴속도를 제어한다.

#### IV. 컴퓨터 시뮬레이션 결과

##### 4.1. 적응 횡단선 필터의 임펄스 응답

적응 등화기에서 왜곡을 생성하는 선형 분산 채널의 적응 등화를 위해 LMS 알고리즘을 이용하며, 모든 데이터는 실수 값으로 가정한다.

그림 4는 적응 등화기 시뮬레이션을 위한 블록도를 나타내고 있다. 그림 4에서 나타낸 바와 같이 데이터 발생기는 채널 입력신호  $u(n)$ 을 발생시키고 상호 심볼간 간섭(ISI)을 일으키는 채널의 출력에 부가적 백색 가우시안 잡음  $v(n)$ 을 더하여 적응 횡단선 등화기에 입력되어지도록 잡음 발생기에 의해 백색 잡음을 발생시킨다. 적응 등화기는 부가적인 백색 가우시안 잡음이 존재하는 곳에서 채널에 의해 생성되는 왜곡을 정정한다. 또한 데이터 발생기에서 발생된 신호를 지연시킨 후에 순열의 형태로 적응 등화기에 적용하기 위해 원하는 응답에 제공된다. 여기서, 발생된 데이터 순열  $u(n)$ 은  $\pm 1$ 을 가진 *Bernoulli* 순열로 구성되어 채널에 입력된 후의 채널 임펄스 응답은 식 (4.1)과 같다.

$$h_n = \begin{cases} \frac{1}{2} \left[ 1 + \cos\left(\frac{2\pi}{W}(n-2)\right) \right], & n=1,2,3 \\ 0, & \text{otherwise} \end{cases} \quad (4.1)$$

위 식에서 매개변수  $W$ 는 채널에 의해 생성된 왜곡의 진폭 크기와 증가를 나타낸다. 또한 매개변수  $W$ 는 등화기에서 탭 입력 상관 행렬의 고유치 확산  $\chi(R)$ 을 조절하고, 고유치 확산은  $W$ 로 증가된다.

잡음 발생기에서 생성된 부가적 백색 가우시안 잡음 순열  $v(n)$ 은 영-평균과 0.001의 분산 값을 가진다.




그림 4. 적응 횡단선 필터의 시뮬레이션 블록도  
Fig. 4. Block diagram of adaptive Transversal Filter experiment

적응 횡단선 등화기의 상관 행렬을 나타내기 위해 시간  $n$ 에 대한 등화기의 첫 번째 탭 입력은 식 (4.2)과 같다.

$$u(n) = \sum_{k=1}^n h_k a(n-k) + v(n) \quad (4.2)$$

식 (4.2)에서 모든 매개변수는 실수 값이다. 그러므로 등화기의 11개 탭 입력  $u(n), u(n-1), \dots, u(n-10)$ 들에 대한 상관 행렬  $R$ 은  $11 \times 11$ 의 대칭 행렬이다. 또한 임펄스 응답  $h_n$ 은  $n$ 이 1, 2, 3 인 경우에 대해 0이 아닌 값을 가지며, 잡음 처리  $v(n)$ 은 영-평균 백색 가우시안이고, 분산은  $\sigma_v^2$ 이며, 상관 행렬  $R$ 은 식 (4.3)과 같다.

$$R = \begin{bmatrix} r(0) & r(1) & r(2) & 0 & \dots & 0 \\ r(1) & r(0) & r(1) & r(2) & \dots & 0 \\ r(2) & r(1) & r(0) & r(1) & \dots & 0 \\ 0 & r(2) & r(1) & r(0) & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & 0 & \dots & r(0) \end{bmatrix} \quad (4.3)$$


즉, 상관행렬  $R$ 은  $r(0)$ 일 때 주 대각선으로 하여 위, 아래에 두 개의 대각선을 가진 형태로 나타난다. 식 (4.3)에서  $r(0) = h_1^2 + h_2^2 + h_3^2 + \sigma_v^2$ ,  $r(1) = h_1 h_2 + h_2 h_3$ ,  $r(2) = h_1 h_3$ 을 의미한다. 백색 가우시안 잡음 분산인  $\sigma_v^2$ 가 0.001이면  $h_1, h_2, h_3$ 은 식 (4.1)에서 매개변수  $W$ 에 할당된 값에 의해 결정된다. 식 (4.1)과 (4.3)를 이용하여 지연  $l = 0, 1, 2$ 에 대해 자동 상관 함수  $r(l)$ 의 값을 구할 수 있다. 매개변수  $W$ 에 따라 상관 행렬  $R$ 의 가장 큰 고유치에 가장 적은 고유치로 나눔으로써 고유치 확산 영역  $\chi(R)$ 을 구할 수 있다.

매개변수  $W$ 가 2.9일 때 상관 행렬  $R$ 의 가장 큰 고유치는 2.0295로 나타나고, 가장 적은 고유치는 0.3339이다.  $W$ 가 3.1일 때 가장 큰 고유치는 2.3761


이고, 가장 적은 고유치는 0.2136임을 알 수 있다. 또한  $W$ 가 3.3일 때 가장 큰 고유치는 2.7263으로 가장 적은 고유치는 0.1256으로 나타난다.  $W$ 가 3.5일 때 가장 큰 고유치는 3.0707이고, 가장 적은 고유치는 0.0656임을 알 수 있다. 따라서 고유치 확산 영역은  $W$ 가 2.9일 때 6.0782로,  $W$ 가 3.1일 때는 11.1238로 나타난다. 매개변수  $W$ 가 3.3일 때는 21.7132로 나타나고,  $W$ 가 3.5일 때는 46.8216으로 분포되어짐을 알 수 있다. 스텝 크기 매개변수  $\mu$ 를 0.001로 고정하였으며, 이는 평균 자승 수렴을 위해  $W$ 가 3.5일 때 자동 상관 행렬  $R$ 의 가장 큰 고유치가 3.0707로서 식 (3.12)에 의해 스텝 크기 매개변수  $\mu$ 가 0부터 0.325 범위 내에 있으므로 조건을 만족한다.

그림 5는 4개의 서로 다른 고유치 확산에 대한 1000번의 반복 수행 후 적응 등화기의 임펄스 응답을 컴퓨터 시뮬레이션을 통해 나타냈다. 시뮬레이션 결과는 각각의 경우에 있어 적응 등화기의 임펄스 응답이 중앙 탭을 고려할 때 대칭적이고 고유치 확산이 클수록, 즉 탭 입력들에 대한 상관 행렬이 나쁘게 조절될수록 임펄스 응답은 큰 폭으로 변화함을 보여준다


그림 6은 탭 계수  $M$ 이 11이고 스텝 크기 매개변수  $\mu$ 를 0.001로 설정하고 500번의 반복 수행을 통해 다양한 고유치 확산 범위  $\chi(R)$ 에 따른 LMS 알고리즘 평균 자승 에러의 컴퓨터 시뮬레이션 결과를 나타냈다. 시뮬레이션 결과로부터 고유치 확산 영역이 증가함에 따라 평균 자승 에러 값이 증가함을 알 수 있다.



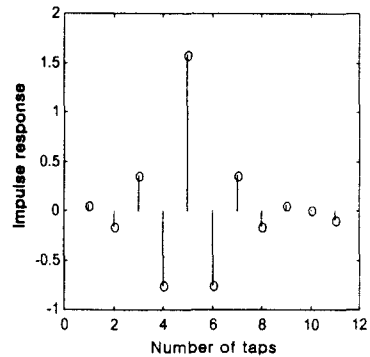
(a)  $W=2.9 \quad \chi(R)=6.0782$



(b)  $W=3.1 \quad \chi(R)=11.1238$



(c)  $W=3.3 \quad \chi(R)=21.7132$



(d)  $W=3.5 \quad \chi(R)=46.8216$

그림 5. 4개의 서로 다른 고유치 확산에 대한 적응 횡단선 필터의 임펄스 응답

Fig. 5 Impulse response of the adaptive Transversal filter for each of four different eigenvalue spreads




그림 6. 탭 수  $M=11$ , 스텝 크기 매개변수  $\mu=0.0075$ 에서 다양한 고유치 확산  $\chi(R)$ 에 따른 적응 등화기의 LMS 알고리즘 학습곡선

Fig. 6 Learning curves of the LMS algorithm for adaptive equalizer with number of taps  $M=11$ , step-size parameter  $\mu=0.001$ , and varying eigenvalue spread  $\chi(R)$

그림 5와 그림 6으로부터 상관 행렬  $R$ 의 고유치가 넓게 확산될 때, LMS 알고리즘에 의해 산출된 초과 평균 자승 오차는 가장 큰 고유치들에 의해 초기에 결정되고 수렴하기 위해 평균 탭 가중치 벡터에 의해 얻어진 시간은 가장 작은 고유치 확산에 의해 제한되고 평균 자승 에러 또한 상관행렬  $R$ 의 고유치 확산에 의해 영향을 받는다. 고유치 확산이 클 때(탭 입력들의 상관 행렬이 나쁘게 조절될 때) LMS 알고리즘의 수렴은 늦게 내려간다.

그림 7은 식 (24)을 이용하여 적응 횡단선 등화기에서 탭 입력의 상관행렬  $R$ 에 대한 고유치 확산 범위  $\chi(R)$ 을 11.1238로 산출하는 매개변수  $W$ 를 3.1로 고정시킨 후에 스텝 크기 매개변수  $\mu$ 를 0.0001, 0.001, 0.01 값으로 변화시키면서 1000번의 반복수에 따른 연속적인 자승 에러의 평균치를 나타냈다. 시뮬레이션 결과로부터 스텝 크기 매개변수  $\mu$ 에 따라 적응 등화기의 수렴율이 밀접하게 변화됨을 알 수 있다. 스텝 크기 매개변수  $\mu$ 가 클 때 반복수에 따른 수렴율이 빠르고 동일한 반복수에 대한 평균 자승 에러 값이 가장 적음을 알 수 있다.

반면에 스텝 크기 매개변수  $\mu$ 에 작은 값이 할당될 때, 수렴 속도는 느려진다. 이것은 긴 "메모리"를 가진 LMS 알고리즘과 동등하다. 유사하게, 평균에서 적응 이후 평균 자승 에러는 다량의 데이터가 기울기 벡터를 추정하는 알고리즘에 의해 사용

되었기 때문에 작아진다. 따라서, LMS 알고리즘을 이용한 선형 적응 필터는 스텝 크기 매개변수  $\mu$ 에 크게 의존함을 알 수 있다.




그림 7. 탭 수  $M=11$ , 고유치 확산  $\chi(R)=11.1238$ 에서 스텝 크기 매개변수  $\mu$ 에 따른 적응 등화기의 LMS 알고리즘 학습곡선

Fig. 7 Learning curves of the LMS algorithm for adaptive equalizer with different step-size parameter  $\mu$  in the number of taps  $M=11$ , eigenvalue spread  $\chi(R)=11.1238$

반복수에 따른 연속적인 자승 에러의 평균치를 나타냈다. 시뮬레이션 결과로부터 스텝 크기 매개변수  $\mu$ 에 따라 적응 등화기의 수렴율이 밀접하게 변화됨을 알 수 있다. 스텝 크기 매개변수  $\mu$ 가 클 때 반복수에 따른 수렴율이 빠르고 동일한 반복수에 대한 평균 자승 에러 값이 가장 적음을 알 수 있다. 반면에 스텝 크기 매개변수  $\mu$ 에 작은 값이 할당될 때, 수렴 속도는 느려진다. 이것은 긴 "메모리"를 가진 LMS 알고리즘과 동등하다. 유사하게, 평균에서 적응 이후 평균 자승 에러는 다량의 데이터가 기울기 벡터를 추정하는 알고리즘에 의해 사용되었기 때문에 작아진다. 따라서, LMS 알고리즘을 이용한 선형 적응 필터는 스텝 크기 매개변수  $\mu$ 에 크게 의존함을 알 수 있다.

**4.2 재사용 버퍼를 이용한 컴퓨터 시뮬레이션 결과**  
적응 등화기에서 컴퓨터 시뮬레이션에 위해 적응 횡단선 필터에서 탭 수는 11개로 설정하였으며, 스텝 크기 매개변수  $\mu$ 는 0.001로 하고, 백색 가우시안 잡음 분산 값  $\sigma_w^2$ 은 0.001로 하였다.

그림 8은 탭 수에 따른 재사용 버퍼를 이용함으



로서 LMS 알고리즘의 평균 자승 에러 비의 학습 곡선을 나타낸 컴퓨터 시뮬레이션 결과로서 식 (3.12)의 수렴속도가 (B+1)배만큼 개선되어짐을 알 수 있다. 식 (3.12)에서 식 (3.10)의 결과는 제안된 알고리즘의 비트에러제어가 안정적이고 식 (3.13)과 같을 때 j번째 계수에 대해 수렴된다.

그림 9는 제안된 데이터 재사용 필터 구조에서 다양한 버퍼 수를 갖는 상태에서 LMS 알고리즘을 이용하였으며, 반복회수를 1000번으로 할 때 평균 자승 에러를 나타내었다.

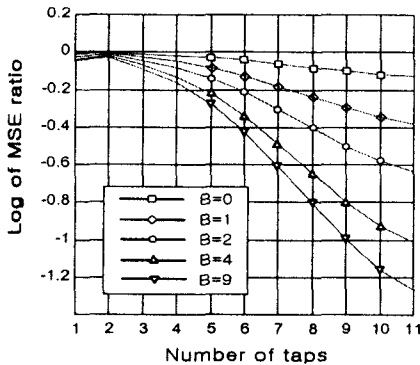


그림 8. 탭수에 따른 데이터 재사용 버퍼 B=0,1,2, 4,9를 가진 LMS 알고리즘의 평균 자승 에러비의 학습 곡선  
Fig. 8 MSE ratio learning curves of LMS algorithm with reusing data buffer B=0,1,2,4,9 according to number of taps






그림 9. 탭 수 M=11, 스텝 크기 매개변수  $\mu=0.001$ , 고유치 확산  $\chi(R)=46.8216$ , 재사용 데이터 버퍼 B=0, 1, 2, 4, 9를 가진 LMS 알고리즘의 평균 자승 에러 학습 곡선  
Fig. 9. MSE learning curves of LMS algorithm with number of taps M=11, step-size parameter  $\mu=0.001$ , eigenvalue spread  $\chi(R)=46.8216$  and reusing data buffer B=0, 1, 2, 4, 9

필요한 탭 수는 11개, 스텝 크기 매개변수  $\mu$ 는 0.001, 고유치 확산  $\chi(R)$ 은 46.8216, 백색 가우시안 잡음 분산 값을 0.001로 동일하게 설정한 상태에서 재사용 데이터 버퍼 B를 0개, 1개, 2개, 4개, 9개를 이용하였을 경우의 시뮬레이션 결과를 나타냈다.


그림 9에 나타낸 시뮬레이션의 결과로부터 적응 횡단선 필터에 사용된 재사용 데이터 버퍼 구조에서 제안한 LMS 알고리즘을 적용함으로써 조정된 탭 가중치 벡터에 비례하여 평균 자승 수렴의 속도는 재사용 데이터 버퍼 수 B가 증가함으로써 (B+1) 배 만큼 증가한다는 것을 알 수 있었다.




(a)  $\chi(R) = 6.0782$



(b)  $\chi(R) = 11.1238$



(c)  $\chi(R) = 21.7132$



(d)  $\chi(R) = 46.8216$

그림 10. 탭 수  $M=11$ , 스텝 크기 매개변수  $\mu=0.01$ , 재사용 데이터 버퍼  $B=0\sim 9$  일 때 다양한 고유치 확산  $\chi(R)$ 에 따른 LMS 알고리즘의 평균 자승 에러 학습 곡선

Fig. 10 MSE learning curves of LMS algorithm according to various eigenvalue spread  $\chi(R)$  with number of taps  $M=11$ , step-size parameter  $\mu=0.01$ , and reusing data buffer  $B=0\sim 9$

그림 10은 제안된 데이터 재사용 필터 구조에서 각각의 다양한 고유치 확산  $\chi(R)$ 을 갖는 상태에서 LMS 알고리즘을 이용하였다. 필요한 탭 수는 11개, 스텝 크기 매개변수  $\mu$ 는 0.01, 백색 가우시안 잡음 분산 값을 0.001, 반복회수를 500번으로 설정한 상태에서 다양한 고유치 확산  $\chi(R)$ 에 따라 재사용 데이터 버퍼  $B$ 를 0~9개를 이용하였을 경우 평균 자승 에러를 나타내었다.

시뮬레이션 결과로부터 밝은 부분은 MSE에 로그를 취한 값이 크게 나타났고 반대로 어두운 부분은 작은 값이 나타났다. 그림 9의 시뮬레이션에 4개의 서로 다른 고유치 확산을 적용하여 시뮬레이션 한 결과는 고유치 확산이 작은  $W=2.9$  ( $\chi(R) = 6.0782$ )에서  $B$ 가 9인 경우 MSE에 로그를 취한 값이 -14로 나타났고 고유치 확산이 큰  $W=3.5$  ( $\chi(R) = 46.8216$ )에서는 동일한 조건에서 -8이 나타났다.


그러나 수렴 속도에 있어 매개 변수  $W$ 에 따른 수렴율은 차이가 없었다. 결국, 고유치 확산에 따른 수렴율은 차이가 없고 단지 고유치 확산이 작을 경우 MSE가 낮아짐을 알 수 있었다.

### 4.3 채널 균등화기의 컴퓨터 시뮬레이션


채널 등화기에서 LMS 알고리즘을 이용한 컴퓨터 시뮬레이션은 적응 횡단선 필터에서 입력되는 채널의 시간 분산을 이용하였으며, 채널의 임펄스 응답은 식 (4.2)을 이용하였다. 적응 횡단선 필터에

서 탭 수는 11개로 설정하였으며, 스텝 크기 매개변수  $\mu$ 는 0.001로 고정하고, 백색 가우시안 잡음 분산  $\sigma_n^2$ 은 0.001로 하였다.


그림 11(a)는 제안된 데이터 재사용 필터 구조에서 버퍼가 없는 즉  $B=0$ 인 상태에서 통상적인 LMS 알고리즘을 이용하였으며, 적응 횡단선 필터의 실제적인 추정치와 원하는 응답의 차이인 에러를 이용하여 조정된 탭 가중치 벡터를 사용함으로써 평균 자승 에러의 수렴상태를 삼차원으로 컴퓨터 시뮬레이션 한 결과이다. 그림 11에서 나타난  $x$ 축은 샘플의 반복수를 나타낸 것으로서 500개의 샘플을 설정하고,  $y$ 축은 진폭의 왜곡( $w$ )의 정도로서 1부터 4까지의 변화값을 주었으며  $z$ 축은 평균 자승 에러(MSE) 값을 나타내었다. 채널 균등화기의 이상적인 출력과 채널 임펄스 응답의 실제 출력 차이인 에러를 LMS 알고리즘을 이용하여 적응 가중치를 구함으로써 평균 자승 에러의 수렴특성을 나타내었다.



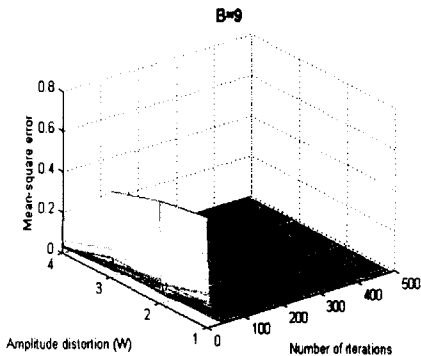
(a)  $B=0$



(b)  $B=2$



(c) B=4



(d) B=9

그림 11. 탭 수  $M=11$ , 스텝 크기 매개변수  $\mu=0.001$ , 진폭 왜곡  $W$ 에 따른 재사용 데이터 버퍼  $B=0, 2, 4, 9$ 를 갖는 LMS 알고리즘의 평균 자승 에러 학습 곡선  
 Fig. 11 MSE learning curves of LMS algorithm with number of taps  $M=11$ , step-size parameter  $\mu=0.001$ , varying amplitude distortion  $W$  and reusing data buffer  $B=0, 2, 4, 9$

그림 11(a)에서 나타낸 시뮬레이션 결과는 진폭 왜곡( $W$ )에 비례하여 고유치 확산 영역  $\chi(R)$ 의 값의 변화에 대해 반복 수에 따른 평균 자승 에러의 수렴상태를 나타낸 것으로서 진폭 왜곡이 커짐에 따라 평균 자승 에러의 값이 증가함을 알 수 있다. 이는 그림 6의 고유치 확산  $\chi(R)$ 에 따른 적응 등화기에서 LMS 알고리즘 학습 곡선의 결과와 부합된다. 그림 11(b)로부터 그림 11(d)까지의 시뮬레이션 결과는 그림 11(a)에 필요한 탭 수, 스텝 크기 매개변수, 백색 가우시안 잡음 분산 값, 고유치 확산 영역  $\chi(R)$ 을 동일하게 설정하여 재사용 데이터 버퍼  $B$ 를 2개, 4개, 9개를 이용하였을 경우 컴퓨터 시뮬레이션 결과를 나타내었다. 시뮬레이션 결과로부터 재사용 데이터 버퍼수가 증가함으로써

평균 자승 에러의 값은 현저하게 적어짐을 알 수 있다. 또한 그림 10의 결과로부터 적응 횡단선 필터에 사용된 재사용 데이터 버퍼 구조에서 제안한 LMS 알고리즘을 적용함으로써 조정된 탭 가중치 벡터에 비례하여 평균 자승 수렴의 속도가 재사용 데이터 버퍼 수  $B$ 가 증가함으로써  $(B+1)$ 배 만큼 증가하여 비트 에러가 제어됨을 알 수 있었고 결국, 제안된 알고리즘이 비트 에러 제어가 되었음이 컴퓨터 실험에 의해 증명되었다.

### V. 결론

탭 가중치를 적응 제어하기 위해 데이터 재순환 알고리즘을 이용함으로써 적응 탭 가중치 벡터의 갱신을 통해 빠른 수렴성을 나타내기 위한 새로운 방식을 제안하였다. 제안된 알고리즘의 전체 연산은  $(2N+1)(B+1)$ 로써 LMS 알고리즘의 연산 복잡성이  $(2N+1)$ 임을 고려하면 제안된 알고리즘의 연산 복잡성은 실질적으로 증가하지 않았다.

적용 예측에서 적응 등화기의 수렴율이 스텝 크기 매개변수  $\mu$ 와 고유치 확산  $\chi(R)$ 과의 관계에 대해  $\mu$ 가 클 때 반복 횟수에 따른 평균 자승 에러 값과 수렴상태가 빠르게 안정되었다. 채널 균등화는 TDL 필터에 사용된 재순환 데이터 버퍼 구조에 제안한 LMS 알고리즘을 적용함으로써 조정된 탭 가중치 벡터에 비례하여 평균 자승 수렴의 속도는 재순환 데이터 버퍼 수  $B$ 가 증가함으로써  $(B+1)$ 배 만큼 증가한다는 것을 알 수 있었다.

3차원 시뮬레이션 결과로부터 다양한 매개변수 및 표본 수에 따른 최소 평균 자승 학습 곡선이 이론적 분석에 적합하다는 것을 입증하였으며, 이산-시간 채널에 대한 MSE 학습 곡선과 관계를 갖는 결론의 이론적 분석은 시뮬레이션 결과와 부합함을 보였다. 이는 데이터 재순환 버퍼 알고리즘을 이용한 제안된 TDL 필터가 LMS 알고리즘과 동일한 수렴 조건을 가지고 실행될 때 연산의 복잡성의 실질적 부담감을 배제하고, TDL 필터의 수렴속도를 증가시킬 수 있다는 것은 신호간섭 제어의 우수성을 보인 것이다.

### 참고문헌

[1] Po-An Sung, Kwang-Cheng Chen, "A Linear Minimum Mean Square Error Multiuser Receiver in Rayleigh-Fading Channels", IEEE J. Select. Areas Commun.,

Vol.14, No.8, pp.1583-1593, Oct. 1996

- [2] Jiangzhou Wang, Laurence Z. Milstein, "Adaptive LMS Filters for Cellular CDMA Overlay Situation", IEEE J. Select. Areas Commun., Vol.14, No.8, pp.1548-1559, Oct. 1996
- [3] Simon Haykin, "Adaptive Filter Theory: Third Edition", Prentice Hall International Editions, pp.365-439, 1996
- [4] B. Widrow, Adaptive Signal Processing, Prentice-Hall, 1985.
- [5] S. U. H Qureshi, "Adaptive Equalization," Proc. IEEE, vol. 73, No. 9, pp.1349-1387, Sep. 1985
- [6] Nam Yong Kim, Chang Eon Kang, "An LMS Tapped Delay Line Equalizer using Each Tap Adaptation," Submitted to IEEE Trans. on. Comm.
- [7] Jiangnan Chen, Roland Priener, "An Inequality by Which to Adjust the LMS Algorithm Step-Size", IEEE Trans. Commun. Vol.43, No.2/3/4, pp.1477-1483, Feb./Mar./Apr. 1995
- [8] Satorius, E. H. and Pack, J. D., "Application of Least squares Lattice Algorithms to Adaptive Equalization," IEEE Trans. Communications, vol. COM-29, pp.136-142, February 1981.
- [9] Satorius, E. H. and Pack, J. D., "Application of Least squares Lattice Algorithms to Adaptive Equalization," IEEE Trans. Communications, vol. COM-29, pp.136-142, February 1981.
- [10] Bergmans, J.W.M., "Tracking capabilities of the LMS adaptive filter in the presence of gain variations," IEEE Trans. Acoust. Speech Signal Process. vol.38, pp. 712-714, 1990.
- [11] J. Shynk and S. Roy, "Convergence properties and stationary points of a perceptron learning algorithm," Proceedings of the IEEE, vol. 78, pp. 1599-1604, Oct. 1990.
- [12] A. Gersho, "Adaptive equalization of high dispersive channels for data transmission," B.S.T.J., vol. 48, pp. 55-70, Jan. 1969.

## 저자 소개

### 김광준(Gwang-Jun Kim)



1993년 조선대학교 컴퓨터공학과 졸업(공학사)  
 1995년 조선대학교 대학원 컴퓨터공학과 졸업(공학석사)  
 2000년 조선대학교 대학원 컴퓨터공학과 졸업(공학박사)

2000년~2001년 Dept. of Electrical & Computer Eng. Univ. of California Irvine Postdoc.

2003년~현재 여수대학교 컴퓨터공학과 전임강사

※관심분야 : ATM망, 인터넷 통신, 컴퓨터 네트워크, 실시간 통신 프로그래밍, 영상 처리 및 통신, 프로그래밍 언어(Visual C++, Java), 이동 통신 등

### 윤찬호(Chan-ho Yoon)




1997년 호남대학교 컴퓨터공학과 졸업(공학사)

2000년 조선대학교 대학원 컴퓨터공학과 졸업(공학석사)

현재 : 조선대학교 대학원 컴퓨터공학과 박사과정

※관심분야 : ATM망, 데이터 통신, 컴퓨터 네트워크, TCP/IP 혼잡제어, 이동 통신 등

### 김천석(Chun-Suk Kim)



1980년 광운대학교 전기공학과 졸업(공학사)

1982년 건국대학교 대학원 전기공학과 졸업(공학석사)

1998년 경남대학교 대학원 전기공학과 졸업(공학박사)

1980년~현재 여수대학교 전자통신공학과 교수

※관심분야 : 디지털 신호 처리, 무선 통신, 정보 이론, ATM망, 인터넷 통신, 컴퓨터 네트워크 등