

論文98-35S-11-5

병렬 적응 NLMS 알고리즘을 이용한 Echo Canceller

(An Echo Canceller Using the Parallel Adaptation NLMS Algorithm)

鄭基碩 *

(Ki Seog Jeong)

要 約

본 논문에서는 전이중 디지털 가입자 선로 모뎀에서 사용될 수 있는 새로운 echo canceller를 제안하였다. 제안된 echo canceller는 적응알고리즘으로 NLMS알고리즘에 기반을 둔 병렬적응(parallel adaptation) NLMS 알고리즘을 사용하였다. 2개의 NLMS과정으로부터 비정체성 대 부가잡음비의 추정치를 구하고 이로부터 최적수렴제어 파라미터를 선택하는 PA-NLMS알고리즘을 유도하였다. 컴퓨터 시뮬레이션 결과 제안된 PA-NLMS 알고리즘은 가장 빠른 NLMS의 수렴속도와 비슷하였으나 misadjustment at convergence (MAC) 성능에서는 상당히 우수함을 보였다.

Abstract

This paper proposes a new echo canceller that can be used in a full-duplex digital subscriber loop modem. The proposed echo canceller uses a NLMS-based parallel adaptation NLMS (PA-NLMS) algorithm. The PA-NLMS algorithm that an estimate of the nonstationarity to additive noise ratio (NNR) gained from two distinct NLMS processes is used to select the value of NLMS convergence-controlling parameter has been developed. Numerical results based on computer simulation show that the proposed algorithm has a convergence rate approaching that of the fastest possible NLMS process while improving on its MAC performance considerably.

I. 서 론

여러 가지 새로운 디지털서비스에 대한 요구는 전화네트워크의 디지털서비스 집적화를 촉진시켜 종합정보통신망(ISDN)의 출현을 가져왔다.

2-선 가입자선로(2-wire subscriber loop)의 고속 전이중(full-duplex) 디지털 전송을 위한 디지털 가입자선로 트랜시버의 설계에서 가장 중요한 부분 중의 하나가 echo canceller이다.

2-선을 사용하여 양방향으로 신호를 전송하기 위하

여는 4선→2선 변환기 즉, 하이브리드 결합기(hybrid coupler)가 필요하다. 이 때 하이브리드 결합기 내의 균형임피던스가 케이블의 임피던스와 일치하면 전송신호는 완전히 상대단으로 전송되지만 케이블의 특성임피던스는 주파수, 시간, 온도 등의 복잡한 함수이므로 정확히 정합하기 어렵다. 따라서 전송신호의 일부분은 상대단으로 전송되지 못하고 누설되어 수신신호와 섞이게 되는데 이 누설신호를 제거하기 위하여 echo canceller를 사용한다.

Echo canceller의 가장 기본적인 구조는 트랜스버설필터(FIR)이다. 텁지연선의 출력은 가중되고 반복알고리즘의 제어하에 더해진다. 반복알고리즘으로는 LMS알고리즘, Sign알고리즘, RLS알고리즘 등이 사용된다.

* 正會員, 永同大學校 電子工學部

(Faculty of Electronic Eng., Youngdong Univ.)

接受日字: 1998年6月30日, 수정완료일: 1998年10月26日

LMS알고리즘은 확률경사(stochastic gradient)에 기반을 두고 있으며 계산이 간단하고 이해하기 쉽고 구현의 용이성 때문에 가장 많이 사용되고 있다.^[1] Sign알고리즘은 오류신호의 극성 정보만을 사용하여 필터계수를 보정(update)하므로 계산이 간단하다는 장점은 있으나 수렴속도가 너무 느리다.^[2] RLS알고리즘은 수렴속도는 LMS알고리즘 보다 빠르지만 계산이 복잡하다는 단점을 지닌다.^[3]

LMS알고리즘의 특별한 형태로 NLMS (Normalized LMS)알고리즘이 있다. LMS알고리즘은 가중치 벡터가 텁 입력벡터에 직접 비례하므로 입력벡터가 커지면 경사잡음 증폭 문제를 일으키나 NLMS에서는 이 문제를 극복할 수 있다.^[4] 또한, LMS와 비교해서 NLMS의 장점은 입력신호분포의 변화에 덜 민감하기 때문에 미지의 그리고 비정체(nonstationary)환경에 더 적합하다는 것이다.^[5]

LMS알고리즘에서 수렴속도와 MSE(Mean Square Error)는 반비례한다. 즉, 수렴상수가 작으면 MSE는 작아지나 수렴이 느리고 반대로 수렴상수를 크게하면 속도는 빨라지지만 MSE는 커진다. 그래서 수렴속도와 MSE를 향상시키기 위하여 시간에 따라 변하는 수렴상수(time-varying μ : TVM))가 제안되었다.^[6] 그러나 TVM 방법과 고정- μ 방법을 비교하는 것은 어렵다. 왜냐하면 TVM방법의 학습곡선은 LMS에서처럼 지수적이 아닐 수도 있기 때문이다. 따라서 비교는 학습곡선의 초기기울기와 같은 수렴의 정의에 따라 이루어져야 한다.

최근에 2개의 적응과정을 사용하여 수렴성능을 향상시킨 병렬 적응(parallel adaptation) 방법이 등장하였다.^[7] 따라서 본 논문에서는 병렬 적응을 NLMS에 적용시킨 병렬적응 NLMS (PA-NLMS)알고리즘을 사용하는 새로운 echo canceller를 제안한다.

본 논문의 구성은 II장에서 LMS와 비정체 조건에서 NLMS의 MAC와 최적수렴상수에 대해서 고찰하고, III장에서 PA-NLMS알고리즘을 유도하고, IV장에서 컴퓨터 시뮬레이션에 의하여 NLMS와 성능비교를 하고, 끝으로 V장에서 결론을 맺는다.

II. 적응 알고리즘

1. LMS 알고리즘

Echo canceller의 기본모형을 나타내면 그림 1과

같다.

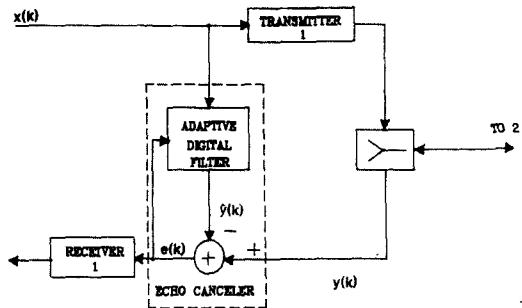


그림 1. Echo canceller 의 기본모형

Fig. 1. Basic configuration of echo canceller.

N차 트랜스버설 필터의 필터탭 가중치(weight)를 \hat{w}_k 로 나타내고, echo canceller의 입력벡터를

$$\mathbf{x}_k = [x(k-N+1), x(k-N+2), \dots, x(k)]^T$$

라고 한다. 여기에서 $x(k)$ 는 샘플k에서의 필터입력이고, 첨자T는 전치를 나타낸다.

벡터 \mathbf{x}_k 는 공분산(covariance) $R = E(\mathbf{x}\mathbf{x}^T)$ 를 갖는 정체적 0 평균(stationary zero-mean) 랜덤과정이다.

이때, 이 필터의 출력은 $\hat{y}_k = \hat{w}_k^T \mathbf{x}_k$ 가 된다.

LMS 적응 필터는 반향(echo)과 필터출력 사이의 제곱평균오류(mean-square error:MSE)를 최소화하기 위하여 텁 가중치를 보정한다. 이 오류를 e_k 라 하면

$$e_k = y_k - \hat{y}_k = \mathbf{x}_k^T (\mathbf{w}_k - \hat{w}_k) + \varepsilon_k \quad (1)$$

\mathbf{w}_k : 반향경로(echo path) 벡터

ε_k : 부가잡음, 정체적 백색 가우시안(stationary white Gaussian) 이라고 가정.

표준 LMS는 MSE의 경사 대신에 순시 오류를 사용한다. 즉,

$$\nabla_{\hat{w}} E(e_k^2) \approx \nabla_{\hat{w}} e_k^2 = -2e_k \mathbf{x}_k$$

그러므로, LMS 반복 방정식은 다음과 같아 된다.

$$\begin{aligned} \hat{w}_{k+1} &= \hat{w}_k - \mu_k \nabla_{\hat{w}} e_k^2 \\ &= \hat{w}_k + 2\mu_k e_k \mathbf{x}_k \end{aligned} \quad (2)$$

μ_k : 수렴제어 파라미터

LMS에서 수렴제어 파라미터 μ_k 는 상수이다.

2. NLMS 알고리즘

NLMS에서 수렴제어 파라미터는

$$\mu_k = \frac{\bar{\mu}}{c + \mathbf{x}_k^T \mathbf{x}_k}$$

가 사용된다. μ_k 는 입력에 따라서 변하고 결국 시간에 따라서 변한다. 상수 c 는 분모가 0이 되는 것을 방지한다. 여기서는 $c=0$ 으로 한다.

NLMS의 장점은 입력의 사전지식 없이도 수렴이 보장될 수 있다는 것이다. NLMS의 과정에서 μ_k 의 시간종속은 다른 적응 체제로 성능을 개선하기 위해서 라기 보다는 미지의 그리고 비정체(nonstationary) 입력 벡터를 다루기 위해서이다.

일반적으로 어떤 비정체 조건에서도 최상의 성능을 제공하는 μ_k 의 값을 얻는 것은 불가능하다. 따라서 어떤 특별한 비정체 경우에 대해서 고찰한다.

이제 반향경로 벡터가 각 iteration에서 변하는 경우를 생각하자.

$$\mathbf{w}_{k+1} = \mathbf{w}_k + \mathbf{z}_k$$

\mathbf{z}_k : 백색, 0 평균 가우시안 벡터, $E(\mathbf{z}_k \mathbf{z}_k^T) = \mathbf{Z}_N$

또, 가중치오류를

$$\mathbf{v}_k = \mathbf{w}_k - \hat{\mathbf{w}}_k$$

라고 정의하자.

그러면, NLMS 가중치오류 반복은

$$\mathbf{v}_{k+1} = \mathbf{v}_k + \mathbf{z}_k - \frac{2 \bar{\mu} \mathbf{e}_k \mathbf{x}_k}{\mathbf{x}_k^T \mathbf{x}_k} \quad (3)$$

가 된다.

식(3)의 내적을 취하면

$$\begin{aligned} \mathbf{v}_{k+1}^T \mathbf{v}_{k+1} &= \mathbf{v}_k^T \mathbf{v}_k + \mathbf{z}_k^T \mathbf{z}_k + 2 \mathbf{v}_k^T \mathbf{z}_k \\ &+ \frac{-\bar{\mu}^2 \mathbf{e}_k^2 - 2 \bar{\mu} \mathbf{e}_k \mathbf{x}_k^T \mathbf{z}_k - 2 \bar{\mu} \mathbf{e}_k (\mathbf{e}_k - \mathbf{e}_k)}{\mathbf{x}_k^T \mathbf{x}_k} \end{aligned} \quad (4)$$

가 된다.

정상상태(steady state), 즉 $k \rightarrow \infty$ 일 때 식(4)의 양변에 기대값을 취하면 $E(\mathbf{v}_{k+1}^T \mathbf{v}_{k+1}) = E(\mathbf{v}_k^T \mathbf{v}_k)$ 가 되므로 식(4)는 다음과 같아 된다.

$$(2 - \bar{\mu})E\left(\frac{\mathbf{e}^2}{\mathbf{x}^T \mathbf{x}}\right) = \frac{\text{tr} \mathbf{Z}}{\bar{\mu}} + 2 \sigma_e^2 E\left(\frac{1}{\mathbf{x}^T \mathbf{x}}\right) \quad (5)$$

$\text{tr}(\cdot \cdot \cdot)$: trace

식(5)를 간단히 하기 위하여 다음과 같은 근사치를 사용한다.

$$E[(\mathbf{x}^T \mathbf{x})^{-1}] \approx E(\mathbf{x}^T \mathbf{x})^{-1} = (\text{tr} \mathbf{R})^{-1} \quad (6)$$

$$E[\mathbf{e}^2(\mathbf{x}^T \mathbf{x})^{-1}] \approx \frac{E(\mathbf{e}^2)}{E(\mathbf{x}^T \mathbf{x})} \quad (7)$$

식(6)은 $N \circ$ 를 때 가능하다. 예를 들어 독립적이고 동일하게 분포한(independent and identically distributed(iid)) 가우시안 입력이고 $N \gg 2$ 일 때

$$E[(\mathbf{x}^T \mathbf{x})^{-1}] = [(N-2) \sigma_x^2]^{-1} \approx (N \sigma_x^2)^{-1} = E(\mathbf{x}^T \mathbf{x})^{-1}$$

가 된다.^[5]

식(7)은 식(6)을 이용하여 구하였다. $N \circ$ \mathbf{x} 의 중요 자기상관의 폭보다 훨씬 더 클 때 $\mathbf{x}^T \mathbf{x}$ 는 \mathbf{e} 와 독립적으로 되고 (7)과 같이 된다.

이들 근사값을 사용함으로써 MSE는

$$E(\mathbf{e}^2) = \frac{2 + \frac{q}{\bar{\mu}}}{2 - \bar{\mu}} \sigma_e^2 \quad (8)$$

$$0 < \bar{\mu} < 2$$

가 된다. 여기서 q 는 LMS알고리즘의 해석에서 비정체 정도를 나타내기 위하여 도입된 것^[8]으로 정규화된 비정체 대 부가잡음비 (normalized nonstationarity to additive noise ratio:NNR)

$$q = \frac{\text{tr} \mathbf{R} \text{tr} \mathbf{Z}}{\sigma_e^2}, \quad \text{NNR} = 10 \log_{10}(q)$$

로 정의된다.

대응하는 misadjustment는 식(1)로부터 다음과 같이 정의 된다.

$$\frac{E(\mathbf{e}^2)}{\sigma_e^2} - 1$$

따라서, misadjustment at convergence(MAC)는

$$MAC_{NLMS} = \frac{\bar{\mu} + \frac{q}{\bar{\mu}}}{2 - \bar{\mu}} \quad (9)$$

가 된다.

최적 MSE를 구하기 위해서 식(9)를 $\bar{\mu}$ 에 대해서 미분하여 우변을 0으로 놓고 $\bar{\mu}$ 를 구하면

$$\bar{\mu}^* = \frac{1}{2} [-q + \sqrt{(q(q+4))}] \quad (10)$$

가 된다.

i) q 가 작을 때 $\bar{\mu}^* \approx \sqrt{q}$

ii) q 가 커짐에 따라 $\bar{\mu}^* \rightarrow 1$ 에 접근하고, 이 값은

가장 빠른 NLMS 수렴을 하는 값이다.^[5]

트랜스버설 필터에서 가중치 오류벡터에 대한 MSE 성능면의 2차성질로부터 가장 빠른 수렴이 수렴제한의 중간 $\bar{\mu}$ 값이라는 사실은 너무도 당연한 일이다. NLMS작동에서 $\bar{\mu} > 1$ 의 값은 더 좋지 않은 수렴과 MAC를 가져온다.

III. PA-NLMS 알고리즘

q 의 신뢰할 수 있는 추정치(estimate)를 구할 수 있다면 최적 정상상태 NLMS 적용 과정을 얻을 수 있다. 그러나 q 는 하나의 NLMS적용필터의 성능만 가지고는 추정될 수 없다. 왜냐하면 성능은 부가잡음 전력과 NNR 모두에 달려있는데 부가잡음전력은 미지의 양으로 가정하기 때문이다.

따라서 충분히 다른값의 $\bar{\mu}$ 를 갖는 2개의 독립적인 NLMS과정을 사용하면 식(8)로부터 q 와 σ_e^2 의 추정치를 구할 수 있다. 이 원리를 병렬적용이라 하고 RLS(recursive least square)에 적용된 바 있다.^[7]

가변- $\bar{\mu}$ NLMS 기본과정과 2 개의 고정- $\bar{\mu}$ (하나는 크고, 다른하나는 작다)과정을 생각하자. 각각의 과정을 첨자 v, h 로 나타낸다.

$$\bar{\mu}_v = 1, \quad \bar{\mu}_h = \alpha \quad 0 < \alpha \ll 1 \text{ 이라고 하자.}$$

2개의 고정- $\bar{\mu}$ 과정으로부터 비정체성 대 부가잡음 비 q 의 추정치를 얻을 수 있고, 이 q 를 이용해서 식(10)으로부터 최적 수렴제어 파라미터 $\hat{\mu}^*$ 를 구할 수 있다.

이 개념도를 그림 2에 나타내었다.

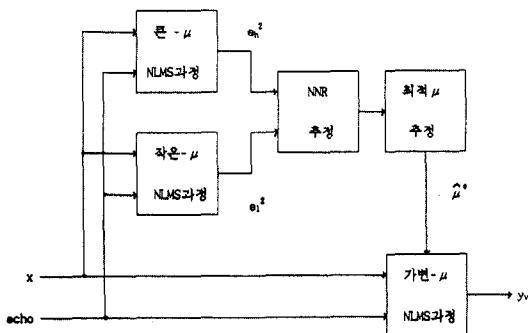


그림 2. PA-NLMS알고리즘의 개념도.

Fig. 2. Block representation of the PA-NLMS algorithm.

식(8)에서 큰 $\bar{\mu}$ 와 작은 $\bar{\mu}$ 과정의 MSE를 순시 값 e^2 으로 대체하고 q 를 구하면 q 의 순시 근사치는 다음과 같이 된다.

$$\hat{q}_k = \frac{2\alpha[(2-\alpha)e_{l,k}^2 - e_{h,k}^2]}{e_{h,k}^2 - \alpha(2-\alpha)e_{l,k}^2}$$

이 근사치의 반복(update)은 다음과 같이 쓸 수 있다.

$$\hat{q}_k = \lambda_q \hat{q}_{k-1} + (1 - \lambda_q) \tilde{q}_k \quad (11)$$

그러나, \hat{q}_k 의 분자와 분모를 식(11)의 형태로 하면 성능향상을 가져오고 해석이 간단해 진다.

$$\hat{q}_k = \frac{\hat{q}_{z,k}}{\hat{q}_{\epsilon,k}} = \frac{\lambda_z \hat{q}_{z,k-1} + (1 - \lambda_z)2\alpha[(2-\alpha)e_{l,k}^2 - e_{h,k}^2]}{\lambda_\epsilon \hat{q}_{\epsilon,k-1} + (1 - \lambda_\epsilon)[e_{h,k}^2 - \alpha(2-\alpha)e_{l,k}^2]} \quad (12)$$

여기서, $\lambda_\epsilon, \lambda_z$ 는 적용에 달려 있으나 일반적으로 1에 가까운 값이다.

새로운 적용필터의 정성적인 동작은 식(12)으로부터 추론할 수 있다. 정체(stationary)와 수렴조건에서 작은 $\bar{\mu}$ 과정의 MSE는 큰 $\bar{\mu}$ 과정의 MSE보다 더 작다. 어떤 구간에서 $e_l^2 < e_h^2$ 이면 q 가 감소되리라는 것을 알 수 있다. 반대로 수렴으로부터 먼(far-from-convergence) 조건에서 큰 $\bar{\mu}$ 과정은 작은 $\bar{\mu}$ 과정보다 더 작은 MSE를 갖는다. e_h^2 이 e_l^2 보다 지속적으로 작다면 \hat{q} 가 $\hat{q}_\epsilon > 0$ 조건에서 증가하는 것을 알 수 있다.

따라서 최적 수렴제어 파라미터 $\hat{\mu}^*$ 의 순시 추정치는 식(10)으로부터 다음과 같이 쓸 수 있다.

$$\hat{\mu}^* = \begin{cases} \bar{\mu}^*(\hat{q}_k), & \hat{q}_k > 0 \\ 0, & \text{otherwise} \end{cases} \quad (13)$$

식(13)은 다음과 같은 형태로 쓸 수 있다.

$$\bar{\mu}_{v,k+1} = \hat{\mu}_k = \lambda_\mu \hat{\mu}_{k-1} + (1 - \lambda_\mu) \tilde{\mu}_k \quad (14)$$

PA-NLMS알고리즘이 미지의 정체(unknown stationary)환경에 적용될 때 수렴과 거리가 먼(far-from-convergence)상태는 빠르게 변하는 random walk로 해석될 필요가 있다. 즉, 수렴이 일어날 때 그 환경은 천천히 변하는 것으로 해석될 필요가 있다.

따라서 미지의 정체적 적용에서는 $\lambda_z = \lambda_\epsilon \approx 1$ 이 사용되지 않고, 적어도 이 두 파라미터 중 하나는 q 의

추정치가 짧은 시간 구간에서 수렴하도록 감소되어야 한다. 이 추정치의 초기값은 식(12)로부터

$$\hat{q}_0 = \frac{2(1-\lambda_z)\alpha}{(1-\lambda_e)(1-\alpha)} \quad (15)$$

가 된다.

이 값은 α 를 증가시키지 않고 크게하기 위해서는 $\lambda_z < \lambda_e \approx 1$ 의 값을 선택하는 것이 요구되고, 그렇게 함으로써 $\bar{\mu}$ 의 초기값은 커지게 된다.

PA-NLMS 반복 방정식을 요약하면 다음과 같다.

$$\hat{w}_{v,k+1} = \hat{w}_{v,k} + \bar{\mu}_{v,k} (\hat{x}_k^\top \hat{x})^{-1} e_{v,k} \hat{x}_k$$

$$\bar{\mu}_{v,k+1} = \hat{\mu}_k$$

$$\hat{w}_{h,k+1} = \hat{w}_{h,k} + \bar{\mu}_{h,k} (\hat{x}_k^\top \hat{x})^{-1} e_{h,k} \hat{x}_k$$

$$\hat{w}_{l,k+1} = \hat{w}_{l,k} + \bar{\mu}_{l,k} (\hat{x}_k^\top \hat{x})^{-1} e_{l,k} \hat{x}_k$$

$$y_{PA-NLMS} = y_t$$

IV. 시뮬레이션 및 검토

컴퓨터 시뮬레이션에서 사용한 반향경로 임펄스 응답(echo path impulse response)은

$$w(k) = e^{-0.8k} \quad 1 \leq k \leq N$$

이고, 입력 데이터는 biphase code를 사용하였으며, 적응필터의 템수는 $N=20, 50, 100$ 3가지 경우로 하였다. 시뮬레이션은 하나의 템수에 대해서 각 파라미터를 변화시키면서 수행되었다. 이 시뮬레이션의 결과는 1000 양상불평균이다.

$N=20, \mu_h=1.0, \mu_1=0.975, \lambda_z=0.001, \lambda_e=0.995$, 일 때 α 를 파라미터로 하여 $\mu_1=\alpha=0.2, \mu_1=\alpha=0.1, \mu_1=\alpha=0.001$ 에 대하여 시뮬레이션한 결과를 그림 3에 나타내었다. 그림 3에서 보듯이 α 에 따라 수렴속도는 변화가 없으나 MAC는 $\alpha=0.2$ 일 때 가장 크고 α 가 감소함에 따라 점점 작아지는 것을 알 수 있다. 이는 $\mu_1=\alpha$ 이므로 α 가 작아지면 작은 μ 과정의 수렴상수가 작아지므로 MAC가 작아지는 것이다.

$\mu_h=1.0, \mu_1=0.125, \lambda_\mu=0.975, \lambda_z=0.001, \lambda_e=0.995$, 일 때 N 을 파라미터로 하여 시뮬레이션한 결과를 그림 4에 나타내었다. 그림 4에서 MAC는 같으나 수렴 속도는 N 이 커질수록 느려지는 것을 볼 수 있다.

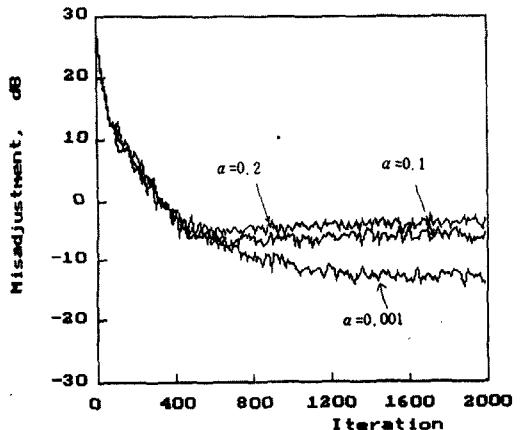


그림 3. α 를 파라미터로한 PA-NLMS의 수렴특성
Fig. 3. Convergence characteristics of PA-NLMS with α as a parameter.

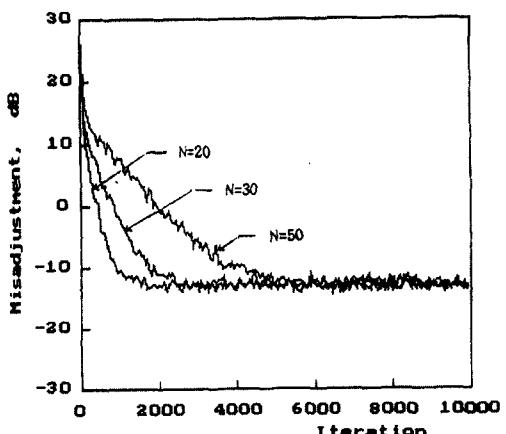


그림 4. N을 파라미터로한 PA-NLMS의 수렴특성
Fig. 4. Convergence characteristics of PA-NLMS with N as a parameter.

$N=20, \mu_h=1.0, \mu_1=0.125, \lambda_\mu=0.975, \lambda_e=0.995$ 일 때 λ_z 를 변화시키면서 시뮬레이션한 결과를 그림 5에 나타내었다. 그림 5에서 볼 수 있듯이 λ_z 에 따라 수렴속도는 작을수록 조금 빨랐으며, MAC는 $\lambda_z=0.01$ 이 때 가장 작고 λ_z 가 증가함에 따라 커지는 것을 알 수 있다. 이는 미지의 정체적 환경에서는 λ_z 가 1 보다 작아야 한다는 III장에서의 해석과 일치함을 보이는 것이다.

$N=20$ 일 때 NLMS알고리즘의 $\bar{\mu}=1.0, 0.125$ 일 때의 수렴곡선과 제안된 PA-NLMS 알고리즘의 $\mu_h=1.0, \mu_1=0.125$ 일 때의 수렴곡선을 그림 6에 나타내었다. 그림 6에서 PA-NLMS 알고리즘은 초기에

는 $\bar{\mu} = 1.0$ 의 수렴상수(초기 수렴)로 수렴하다가 수렴에 근접함에 따라 수렴상수 $\bar{\mu} = 0.125$ 로 수렴하여 수렴속도는 NLMS의 가장 빠른 경우와 비슷하였으나 MAC는 NLMS 알고리즘의 $\bar{\mu} = 0.125$ 일 때 보다 더 작은 값을 갖는 것을 볼 수 있다.

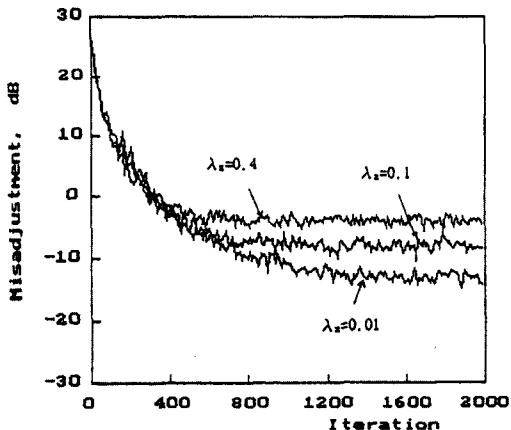


그림 5. λ_z 를 파라미터로 한 PA-NLMS의 수렴특성
Fig. 5. Convergence characteristics of PA-NLMS with λ_z as a parameter.

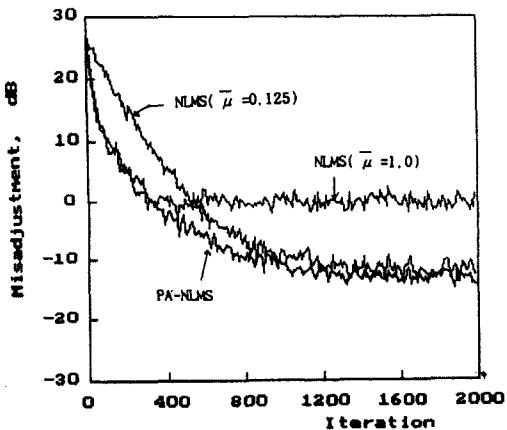


그림 6. PA-NLMS과 NLMS의 비교
Fig. 6. Comparison of PA-NLMS algorithm with NLMS algorithm.

또한, PA-NLMS 알고리즘과 NLMS 알고리즘을 ERLE(Echo Return Loss Enhancement)에 의하여 비교한 결과를 그림 7에 나타내었다. ERLE는 다음과 같이 정의된다.^[9]

$$ERLE = 10 \log_{10} \frac{E[y^2]}{E[e^2]}$$

즉, ERLE는 제거 후의 잔류반향(residual echo)

제곱의 평균치에 대한 제거 전의 반향 제곱의 평균치의 비로 나타내며 echo canceller의 수렴특성을 알 수 있는 양이다.

그림 7에서 PA-NLMS 알고리즘은 1000 iterations 근처에서 수렴에 도달하는 반면에 NLMS 알고리즘은 2400 iterations을 지나서 수렴에 도달하는 것을 볼 수 있다. 따라서 PA-NLMS 알고리즘이 NLMS 알고리즘보다 더 빠른 속도로 수렴에 도달하는 것을 알 수 있다. NLMS에서 사용한 $\bar{\mu}$ 는 0.125이다. $\bar{\mu}$ 를 크게하면 속도는 빨라지지만 ERLE는 작아진다.

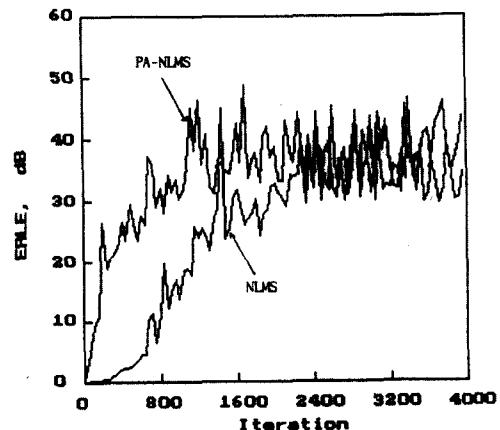


그림 7. PA-NLMS 알고리즘과 NLMS 알고리즘의 ERLE
Fig. 7. ERLE of PA-NLMS algorithm and NLMS algorithm.

V. 결 론

본 논문에서는 전이중 디지털 가입자 선로 모델에서 사용할 수 있는 새로운 echo canceller를 제안하였다. 제안된 echo canceller는 적응알고리즘으로 PA-NLMS 알고리즘을 사용하였다. 큰 $\bar{\mu}$ 와 작은 $\bar{\mu}$ 2개의 NLMS 알고리즘 과정을 이용하여 각 과정의 MSE로부터 비정체성 대 부가점음비의 추정치를 구해서 최적수렴제어 파라미터를 얻는 병렬적용 NLMS(PA-NLMS) 알고리즘을 제안하였고, 미지의 정체적 환경에서 해석하였다. 컴퓨터 시뮬레이션을 통하여 미지의 정체 환경에서는 $\lambda_z < \lambda_e \approx 1$ 이 되는 해석의 타당성을 입증하였고, 제안된 PA-NLMS 알고리즘이 큰 $\bar{\mu} = 1.0$ 이고 작은 $\bar{\mu} = 0.125$ 일 때 $\bar{\mu}=1.0$ 와 $\bar{\mu}=0.125$ 인 NLMS 알고리즘과 수렴특성을 비교하여

초기의 수렴속도는 $\bar{\mu}=1.0$ 일 때와 비슷하나 MAC는 $\bar{\mu}=0.125$ 일 때 보다 더 작은 것을 볼 수 있었다. 이는 수렴속도와 MAC가 반비례하는 NLMS알고리즘의 특성을 개선한 것이다. 또한 템수에 따라서는 템수가 클수록 수렴속도가 감소하는 것을 알 수 있었다. 제안된 PA-NLMS알고리즘은 다른적용, 예를들면 등화기(equalizer)등에도 적용 가능할 것으로 생각된다.

참 고 문 헌

- [1] B. Widrow and S. D. Stearns, *Adaptive Signal Processing*, Englewood Cliffs, NJ: Prentice-Hall, 1985.
- [2] C-L Wang and R-Y Chen, "Optimum Design of the Hard-Switching Dual Sign Algorithm for Adaptive Echo Cancellation," *IEEE Trans. on Signal Processing*, vol. 41, no. 5, pp. 1970-1974, May 1993.
- [3] J. M. Cioffi and T. Kailath, "An efficient RLS Data Driven echo canceller for fast initialization of full-duplex data transmission," *IEEE Trans. on Communication*, vol. 33, no. 1, pp. 601-611, Jan. 1985.
- [4] S. Haykin, *Adaptive Filter Theory*, 3rd ed.
- [5] D. T. M. Slock, "On the Convergence Behavior of the LMS and Normalized LMS Algorithms," *IEEE Trans. on Signal Processing*, vol. 41, no. 9, pp. 2811-2825, Sept. 1993.
- [6] R. H. Kwong and E. W. Johnston, "A variable step size LMS algorithm," *IEEE Trans. on Signal Processing*, vol. 40, no. 9, pp. 1633-1642, July 1992.
- [7] S. D. Peters and A. Antoniou, "A Parallel Adaptation Algorithm for Recursive-Least-Squares Adaptive Filters in Nonstationary Environments," *IEEE Trans. on Signal Processing*, vol. 43, no. 11, pp. 2484-2495, Nov. 1995.
- [8] O. Macchi, "Optimization of adaptive identification for time-varying filters," *IEEE Trans. on Automatic Control*, vol. AC-31, no. 3, pp. 283-287, Mar. 1986.
- [9] M. R. Asharif and F. Amano, "Acoustic Echo-Canceler Using the FBAF Algorithm," *IEEE Trans. on Commu.*, vol. 42, no. 12, pp. 3090-3094, Dec. 1994.

저 자 소 개



鄭 基 穎(正會員)

1983년 고려대학교 전자공학과 졸업. 1988년 고려대학교 전자공학과 석사과정 졸업(공학석사). 1992년 고려대학교 전자공학과 박사과정 졸업(공학박사). 1994년 ~ 현재 영동대학교 전자공학부 부교수. 주관심분야는 디지털 통신, 적응신호처리, 통신시스템