

# 효율적인 가변 변수를 이용한 아크탄젠트 비용함수 기반 diffusion NLMS 알고리즘

박종훈\*, 김진\*, 남상원<sup>o</sup>

## Arctangent-Cost-Function Based Diffusion NLMS Algorithm with an Efficient Variable Parameter

JongHun Park\*, Jin Kim\*, Sang Won Nam<sup>o</sup>

### 요약

본 논문은 효율적 가변 변수를 이용한 아크탄젠트 비용함수 기반의 충격잡음에 강인한 diffusion NLMS 알고리즘을 제안한다. 특히, 지수 함수 형태의 기존 가변 변수 기법은 충격 잡음의 발생 확률 정보가 요구되는 반면에, 제안하는 가변 변수 기반 diffusion NLMS는 사전 정보가 요구되지 않으면서도 아크탄젠트 비용함수의 특징을 이용하여 충격 잡음 환경에서 기존의 diffusion NLMS보다 적은 연산량으로 높은 MSD 수렴 성능을 보인다. 끝으로, 시스템 추정 시뮬레이션을 통해 제안된 알고리즘의 수렴 성능을 검증한다.

**Key Words** : Adaptive filter, diffusion LMS, efficient variable parameter, robust against impulsive noise

### ABSTRACT

In this paper, we propose an arctangent-cost-function based diffusion NLMS algorithm with an efficient variable parameter, robust against impulsive noise in the adaptive network. Compared with conventional algorithms where the variable parameter is an exponential function and the occurrence probability of impulsive noise is required, the proposed distributed estimation algorithm, utilizing the characteristics of the arctangent cost function is of less computational complexity and requiring no prior knowledge on impulsive noise, yields improved MSD convergence. Finally, its convergence performance is verified by using computer simulations for system identification.

### 1. 서론

미지의 시스템을 추정할 수 있는 적응 필터는 선형 예측, 능동 소음 제어와 같은 다양한 분야에 적용되고

있다<sup>[1]</sup>. 예로서, 여러 제곱을 비용함수로 갖는 LMS(Least Mean Squares) 알고리즘과 센서 네트워크에서의 diffusion LMS 알고리즘들이 연구되어왔다<sup>[2]</sup>. 그러나 이러한 여러 제곱 형태의 비용함수 기반

\* This work was supported by National Research Foundation of Korea (NRF) grant funded by the Korea government (MEST) (No. 2015R1A2A2A01004533)

• First Author : (ORCID:0000-0003-3512-6423) Hanyang University, Department of Electronics and Computer Engineering, kendhc123@naver.com, 학생회원

◦ Corresponding Author : (ORCID:0000-0001-9185-6928) Hanyang University, Department of Electronic Engineering, swnam@hanyang.ac.kr, 정회원

\* (ORCID:0000-0003-2357-2290) Hanyang University, Department of Electronics and Computer Engineering, bing50@hanyang.ac.kr, 학생회원

논문번호 : 201806-0-076-SE, Received April 30, 2018; Revised July 22, 2018; Accepted July 23, 2018

LMS 알고리즘들은 순간적 큰 잡음인 충격잡음이 발생하는 환경에서는 심각한 수렴 성능 저하가 발생하여 실제 적용이 어렵다. 특히, 센서 네트워크 추정에서는 이러한 문제점을 극복하기 위해 여러 형태 충격잡음에 강한 diffusion LMS 알고리즘들이 연구되었다. 구체적으로, 충격 잡음에 강인함을 보이기 위해, 에러의 부호 값만 이용하는 diffusion sign-error LMS 알고리즘<sup>[3]</sup>, 로그 비용함수를 이용한 diffusion least logarithmic absolute difference 알고리즘<sup>[4]</sup>, 그리고 아크탄젠트 비용함수를 이용하여 강인하면서 수렴 성능이 우수한 arc-DNLMS(arc tangent cost function based diffusion NLMS)알고리즘<sup>[5]</sup>들이 보고되었다. 본 논문에서는 기존 arc-NLMS(NLMS algorithm based on variable parameter cost function)<sup>[6]</sup>에서의 디자인 파라미터를 보다 개선한 효율적 가변 변수를 제안하고, 이를 기존 arc-DNLMS에 추가 적용하여 시스템을 추정함으로써, 사전적으로 충격 잡음 정보가 요구되지 않고 연산량 또한 감소된, 빠른 MSD 수렴 성능의 arc-DNLMS 알고리즘을 제안한다.

본 논문의 구성은 다음과 같다. II 절에서 기본적인 diffusion LMS에 대해 설명한 다음, 기존 arc-DNLMS와 arc-NLMS에서 사용된 가변 변수 방법을 기술하고, 이를 개선한 효율적 가변 변수를 적용한 arc-DNLMS 알고리즘을 제안한다. III 절에서는 시스템 추정 컴퓨터 시뮬레이션을 통해 제안하는 arc-DNLMS 알고리즘과 기존 알고리즘들과의 수렴 성능을 비교한다. 끝으로 IV 절에서는 결론을 맺는다.

## II. 본 론

### 2.1 Diffusion LMS<sup>[2]</sup>

$N$ 개의 센서들을 노드로 갖는 센서 네트워크를 고려한다. 각  $k$ 번째 노드는 시행  $i$ 마다 크기  $M \times 1$ 의 입력 벡터  $\mathbf{u}_{k,i}$ 와 측정되는 신호  $d_{k,i}$ 가 측정된다. 각 노드에서 필터 길이가  $M$ 인 FIR(Finite Impulse Response) 선형 시스템  $\mathbf{w}_o$ 를 추정할 때,  $d_{k,i}$ 는 다음과 같이 표현된다.

$$d_k(i) = \mathbf{u}_{k,i}^T \mathbf{w}_o + v_{k,i} \quad (1)$$

여기서  $v_{k,i}$ 는 일반적으로 Gaussian 분포를 따르는 측정 잡음을 나타낸다. 또한, 충격잡음을 고려하는 상황에서  $v_{k,i}$ 는 Bernoulli-Gaussian 모델의 충격 잡음

을 포함하는 측정 잡음이다.

Diffusion LMS은 시스템 추정 방식에는 적응 단계와 조합 단계의 순서에 따라 두 가지 구조들이 있다. 즉, ATC(Adapt Then Combine) 구조와 CTA(Combine Then Adapt) 구조로 나뉜다. 일반적인 상황에서 ATC 구조가 MSD(Mean Square Deviation) 수렴성능이 뛰어나며, ATC diffusion LMS 알고리즘은 다음과 같이 나타낼 수 있다<sup>[2]</sup>.

$$\boldsymbol{\psi}_{k,i} = \mathbf{w}_{k,i-1} + \mu_k \mathbf{u}_{k,i} (d_k(i) - \mathbf{u}_{k,i}^T \mathbf{w}_{k,i-1}) \quad (2)$$

$$\mathbf{w}_{k,i} = \sum_{l \in \mathcal{N}_k} a_{l,k} \boldsymbol{\psi}_{l,i} \quad (3)$$

식 (2)는 적응 단계이고, 식 (3)은 조합 단계이다. 또한,  $a_{l,k}$ 는 노드 간의 추정된 시스템 값의 교환하는 비율을 조정하는 상수이며,  $\mathcal{N}_k$ 는  $k$ 번째 노드의 자신을 포함하는 이웃의 집합으로 조합 상수는 조건  $\sum_{l \in \mathcal{N}_k} a_{l,k} = 1$ 을 만족해야한다. 모든 조건을 만족하는 ATC diffusion LMS는 다음의 그림 1 모형으로 요약될 수 있다.

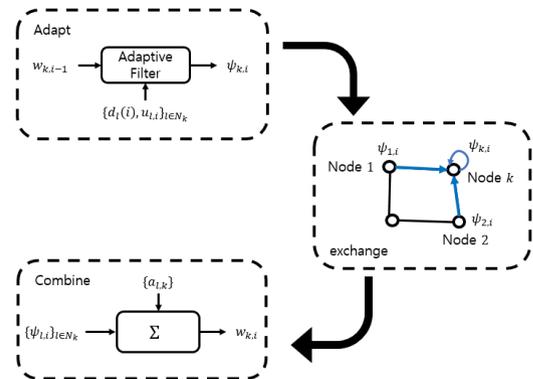


그림 1. ATC diffusion LMS 모형  
Fig. 1. ATC diffusion LMS model

### 2.2 arc-DNLMS<sup>[5]</sup>

아크탄젠트 비용함수를 이용하여 ATC diffusion LMS의 적응 단계의 식을 충격 잡음에 강한 업데이트 식은 다음과 같이 유도된다<sup>[5]</sup>.

$$f_k^{loc}(\mathbf{w}) = \sum_{l \in \mathcal{N}_k} c_{l,k} \left( E \left[ \arctan \left( \beta \left( \frac{d_l(i) - \mathbf{u}_{l,i}^T \mathbf{w}_{l,i-1}}{\|\mathbf{u}_{l,i}\|^2} \right) \right) / 2\beta \right] \right) \quad (4)$$

$$\psi_{k,i} = \mathbf{w}_{k,i-1} + \mu_k \frac{\mathbf{u}_{k,i} e_{k,i}}{\|\mathbf{u}_{k,i}\|^2 + \beta^2 e_{k,i}^4 / \|\mathbf{u}_{k,i}\|^2} \quad (5)$$

구체적으로, arc-DNLMS에서는 식 (4)을 미분하여 업데이트 식 (5)이 유도된다<sup>5)</sup>. 유도된 식 (5)은 식 (2)을 대체할 수 있다. 식 (4)-(5)에서 각  $\psi_{k,i}$ 와  $\mathbf{w}_{k,i}$ 는 추정 전·후에 각 노드가 갖는 시스템 계수들이며,  $\beta$ 는 고정된 디자인 파라미터,  $\mu_k$ 는 스텝사이즈,  $c_{l,k}$ 는 각 노드에서의 조합 계수들이다. 각 노드의 에러  $e_{k,i}$ 는  $e_{k,i} = d_k(i) - \mathbf{u}_{k,i}^T \mathbf{w}_{k,i-1}$ 로 일반적인 적응 필터와 동일하며,  $\|\cdot\|$ 은 2-norm 이며, 벡터는 모두 볼드체로 표기되어있다.

일반적인 에러 제곱 형태의 비용 함수가 아닌 아크탄젠트 비용함수를 이용함으로써 유도된 알고리즘이 아크탄젠트 특징을 그대로 유지한다. 즉, 아크탄젠트 함수에서는 크기가 큰 값이 입력될 때, 값이 거의 변하지 않게 되며 이는 기울기가 '0'에 근접한다고 할 수 있다. 이러한 특징은 경사 하강법(gradient descent)을 기반으로 하는 LMS를 이용하는 알고리즘에서 큰 에러 상황에서는 업데이트하는 값을 '0'으로 적용하여, 충격 잡음과 같은 상황에서 이전의 값을 유지하여 충격 잡음에 강한 성질을 만들어준다.

### 2.3 arc-NLMS의 가변 변수<sup>6)</sup>

2절에서의 arc-DNLMS는 각 노드마다 고정 값의 디자인 파라미터  $\beta$ 을 갖는다. 일반적인 적응필터의 특징에서  $\beta$ 가 크면 수렴속도가 느리지만 좋은 MSD 성능을 갖고, 반대의 경우 성능이 저하되지만 수렴 성능이 우수함이 알려져 있다.  $\beta$ 에 따른 수렴 MSD는 시스템 추정 시뮬레이션을 통해 알 수 확인할 수 있는데, 디자인 파라미터  $\beta$ 에 따른 MSD 성능을 나타낸

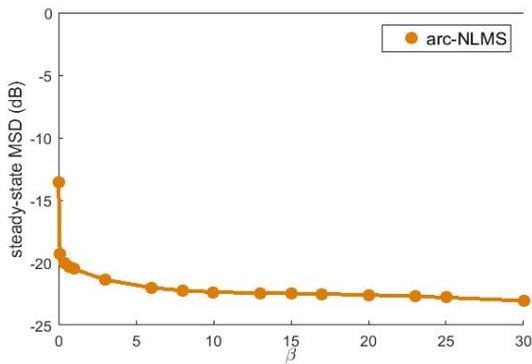


그림 2. 디자인 파라미터  $\beta$ 에 따른 MSD 성능  
Fig. 2. MSD performance based on design parameter  $\beta$

그림 2에서와 같이 MSD가 수렴되었다고 판단되었을 때  $\beta$ 의 값을 증가시켜야함을 알 수 있다.

따라서, 식 (5)에서 에러가 작을수록 큰 값을 갖는 가변(시행  $i$ 마다 변하는) 변수  $\beta(i)$ 로 대체할 수 있다. 이를 수식적으로 나타내면  $\beta$ 는 에러에 따른 다음과 같이 감소함수 형태의 가변 변수로 표현될 수 있다<sup>5)</sup>.

$$\beta(i+1) = k_\beta e^{-k_e \bar{e}(i)} \quad (6)$$

충격 잡음에 의해 비정상적으로 에러가 커질 수 있으므로 식 (4)로부터 추정된 에러의 절대 평균  $\bar{e}(i)$ 을 추정하여 사용한다. 즉,  $N_w$ 와 같은 차원의  $\mathbf{A}_e(i) = [|e(i)| |e(i-1)| \dots |e(i-N_w+1)|]$  벡터의 중간값(median) 필터가 적용된 값을 이용한 지수평활법으로 구할 수 있다<sup>6)</sup>.

$$\bar{e}(i) = \eta \bar{e}(i-1) + (1-\eta) C \text{median}(\mathbf{A}_e(i)) \quad (7)$$

식 (7)에서 상수  $C$ 는  $1.483(1+5/(N_w-1))$ 의 값을 갖는다<sup>6)</sup>. 특히, arc-DNLMS의 업데이트 식은 가변 변수를 갖는 식으로 변환될 수 있다. 가변 변수를 갖는 arc-DNLMS의 업데이트 식은 Diffusion LMS의 구조적 특징을 살리기 위해 노드마다 고유한 값을 가진 가변 변수  $\beta_k(i)$ 을 식 (5)에 적용하면 다음과 같이 표현된다.

$$\psi_{k,i} = \mathbf{w}_{k,i-1} + \mu_k \frac{\mathbf{u}_{k,i} e_{k,i}}{\|\mathbf{u}_{k,i}\|^2 + \beta_k(i)^2 e_{k,i}^4 / \|\mathbf{u}_{k,i}\|^2} \quad (8)$$

### 2.4 제안된 효율적 가변 변수를 갖는 arc-DNLMS

기존의 가변 변수는 충격잡음에 강한 특징을 갖기 위하여 식 (7)과 같이 에러의 절대 평균을 중간값 필터를 사용하여 추정한다. 길이  $N_w$ 만큼의 에러 벡터  $\mathbf{A}_e(i)$ 가 필요하며, 실제 환경에서는 환경의 충격잡음 확률 정보를 알 수 없기 때문에 중간값 필터의 길이  $N_w$  또한 추정하기 어렵다. 추가로, 충격잡음의 발생 확률이 큰 경우,  $N_w$ 가 큰 값을 적용해야 하므로 적응 필터의 연산량이 크게 증가하게 된다.

본 절에서는 식 (6)과 달리 절대값 에러의 평균을 사용하지 않는 새로운 효율적인 가변 변수를 제안하여 arc-DNLMS에 적용한다. 제안하는 가변 변수에서

는 아크탄젠트 비용함수를 통해 충격잡음에 강인한 특성을 이미 갖고 있는 그레디언트 벡터의 크기를 사용한다. 특히, 자주 변하는 값을 안정시키고 연산량 감소를 위해 벡터 크기의 제곱값을 지수평활법으로 연산한 값을 사용한다. 즉, 재사용하는  $l$ 번째 노드의 그레디언트 벡터  $g_l(i)$ 은 다음과 같다.

$$g_l(i) = \frac{u_{l,i} e_{l,i}}{\|u_{l,i}\|^2 + \beta(i)^2 e_{l,i}^4 / \|u_{l,i}\|^2} \quad (9)$$

$$G_l(i) = \lambda G_l(i-1) + (1-\lambda) \|g_l(i)\|^2 \quad (10)$$

즉, 기존 가변 변수 식 (6)과는 달리, 제안하는 효율적인 가변 변수는 식 (9) 및 식 (10)으로부터 다음과 같이 나타낼 수 있다.

$$\beta_l(i+1) = \frac{1}{k_b G_l(i) + \epsilon} \quad (11)$$

식 (11)은 그레디언트의 크기 제곱이 작을수록 디자인 파라미터  $\beta$ 가 커져야하는 반비례 특징이 이용되었으며, 지수 함수와 형태가 유사하면서 보다 적은 연산량을 요구하는 분수 함수를 사용하였다.

기존의 알고리즘과 제안하는 알고리즘의 연산을 대략적으로 비교하면 다음과 같다. 기존의 알고리즘은 지수 연산  $O(e^x)$ 와 일반적인 중간값 필터에 필요한  $O(N_w \log N_w)$ 의 합으로 표현할 수 있다. 충격 잡음에 따라  $N_w$ 의 결정이 어렵고, 짧은 길이의 벡터는 성능을 해칠 수 있다. 성능과 연산의 편의성을 고려하여  $N_w$ 가  $M$ 의 길이를 갖는다고 설정하고, 지수 연산이 빠르다고 가정하면 모든 노드마다  $O(M \log M)$ 의 연산이 필요한 것을 알 수 있다. 반면에 제안하는 알고리즘은 이미 사용되는 그레디언트 벡터를 사용한다. 2절에서 언급한 것처럼 아크탄젠트 비용함수 자체가 이미 충격잡음에 강인한 성질을 갖고 있기 때문에 그레디언트 벡터를 재사용하여 불필요한 연산을 줄일 수 있다. 업데이트에 사용되는 벡터를 재사용하여 제안하는 알고리즘은 식 (10)과 식 (11)의 간단한 연산으로 가변 변수를 구할 수 있다. 벡터의 내적 제곱 연산을 계산하면 제안하는 알고리즘은  $O(M)$ 의 연산량을 갖는 것을 알 수 있다.

직접적으로 연산량을 비교할 수는 없지만, 제안하는 알고리즘이 적은 연산이 필요하다는 것을 확인할 수 있다. 또한 중간값 필터의 특성상 최소 한번의  $N_w$

만큼의 비교 연산이 필요하다. 이는 순차적인 연산이 반드시 필요하다고 바꾸어 말할 수 있다. 실제 구현에서 파이프라인 등의 기법을 적용하여 여러 개의 곱셈 등을 동시에 처리하여 더 빠르게 연산할 수 있음을 고려했을 때, 제안하는 알고리즘이 연산과 시간 복잡도에서 기존보다 더 효율적이라고 판단할 수 있다. 이는 두 알고리즘의 시뮬레이션을 통해 확인해 볼 수 있다.

식 (5)과 식 (8)을 기반으로 하여 제안하는 가변 변수 식 (11)을 적용한 diffusion NLMS 알고리즘 구성은 다음의 두 단계로 요약될 수 있다. 먼저 적응 단계에서는 식 (8)과 같은 업데이트 식을 이용하여 각 노드에서 적응 필터가 동작한다. 이후 식 (9)과 식 (10)을 이용하여 식 (11)의 가변 변수를 업데이트 한다. 이때, 식 (8)에서 사용한 그레디언트 벡터를 식 (10)에 재사용함으로써 연산량을 줄일 수 있다. 다음의 조합 단계에서는 각 노드에서 얻은 추정된 시스템 계수를 조합한다. 본 논문에서 가변 변수를 갖는 arc-DNLMS는 VP-arc-DNLMS로 표기하였다. 또한, 효율적인 가변 변수를 이용한 알고리즘은 기존의 VP(Variable Parameter)를 수정했다는 의미에서 modified-VP-arc-DNLMS로 표기하였다.

### III. 실험

#### 3.1 충격잡음 모델

베르누이-가우시안 프로세스(Bernoulli-Gaussian process)는 적응 필터에서 사용되는 가장 흔한 충격 잡음 모델이다<sup>3,7)</sup>. 이 모델은 충격잡음이 아닌 경우 일반적으로 적용하는 가우시안 분포의 잡음에 충격 잡음 확률  $p$ 를 생각하여 상대적으로 큰 분산을 가지는 가우시안 분포의 잡음을 더한 모델이다. 1보다 매우 큰  $\kappa$ 를 설정하여 평균이 1이고, 분산이  $\sigma_a^2, \sigma_b^2 = \kappa \sigma_a^2$ 인 가우시안 분포를 이용해 충격 잡음 모델의 분산은 다음과 같이 표현된다.

$$\sigma_v^2 = \sigma_a^2 + p \sigma_b^2 \quad (12)$$

다양한 충격 잡음 환경을 나타내기 위해 안정 분포(stable distribution)를 이용하여 FSNR(fractional-order SNR)로 상대적 크기를 나타내는 모델이 있다<sup>8)</sup>. 이 모델은 잡음이  $\alpha$ 안정 분포를 갖는다고 가정하며  $0 < p < \alpha$ 인  $p$ 를 정하여 다음과 같이 FSNR을 나타낸다.

$$FSNR = 10\log_{10}(E(d^p)/E(v^p)) \quad (13)$$

이 모델은  $\alpha-S$  프로세스를 기반으로 하기 때문에 실제 환경에 더 적합하며, 최근에도 시뮬레이션 환경으로 사용되고 있다<sup>9)</sup>. 본 논문에서는 모든 환경에서 제안하는 알고리즘이 잘 동작함을 보이기 위하여 두 모델을 각각 적용한다.

### 3.2 시스템 추정 시뮬레이션

총 세 가지 시뮬레이션 결과를 보인다. 모든 시뮬레이션에서 LLAD의  $\alpha$ 는 20, [5]의 고정된 파라미터  $\beta$ 와 각 가변변수의 초기 값은 0.7로 설정하였다. 2장 3절과 5절의 최대  $\beta$  상수  $k_\beta$ 는 1000으로 설정하였고, 같은 환경을 위해  $\epsilon$ 은 1/1000으로 설정하였다. 지수 평활법에 사용되는  $\eta$ 와  $\lambda$ 는 모두 0.95를 사용하였고, 식 (10)의  $G_l(i)$ 의 초기값은 1, 식 (11)의  $\beta_l(1) = 1/(k_b + \epsilon)$ 으로 설정하였다. 모든 시뮬레이션은 500번 ensemble 평균하였다. 시스템 추정에서의 공정한 성능 비교를 위해 각 알고리즘의 스텝사이즈는 다르게 설정되었다. 베르누이-가우스 프로세스 충격잡음 모델을 사용한 경우와 충격잡음이 없는 경우는 각 스텝사이즈  $\mu_k$ 의 값을 다음과 같이 설정하였다: Sign-error-DNLMS<sup>[3]</sup>에서는 0.06, LLAD-DNLMS<sup>[4]</sup>에서는 0.08, arc-DNLMS<sup>[5]</sup>에서는 0.33, 그리고 제안하는 알고리즘에서는 0.33을 사용하였다.  $\alpha-S$  프로세스를 기반으로 하는 모델에서 sign-error-DNLMS에서는 0.11, LLAD-DNLMS에서는 0.05, arc-DNLMS에서는 0.33, 그리고 제안하는 알고리즘에서는 0.33을 사용하였다. 마찬가지로 모든 시뮬레이션에서  $M$ 은 8로 설정하였다.

그림 3(a)과 같은 센서 네트워크에서 시뮬레이션을 하였으며, 각 노드는 그림 3(b)과 같은 SNR(signal to noise ratio) 환경을 갖는 경우를 다루었다.

첫 번째 시뮬레이션(그림 4 참조)에서 각 노드들은 SIR(signal to impulsive noise ratio)이 -30dB를 가지며 발생 확률은 0.3으로 설정하였다. 시뮬레이션 결과에서 기존 가변 변수 방법의 MDS 수렴 성과와 비교하였을 때, 본 논문에서 제안하는 효율적인 가변 변수 방법이 보다 우수한 MSD 수렴 성능을 보임을 확인할 수 있다. 기존의 알고리즘은 0.5보다는 적지만 큰 확률의 충격 잡음이 발생하는 상황에서 안정적 동작을 위해  $N_w$ 는 60으로 설정하였음에도 불구하고 수렴하였을 때, 충격잡음의 영향을 받는 것을 알 수 있다. 반면에 제안하는 알고리즘은 아크탄젠트 비용합수

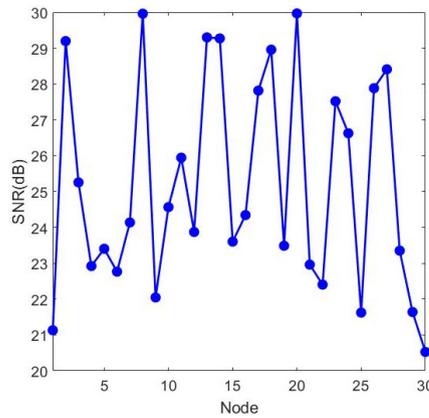
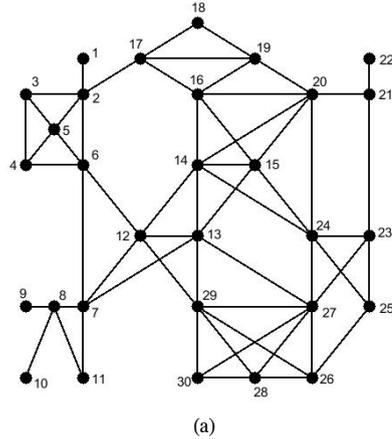


그림 3. 시뮬레이션 환경; (a) 센서 네트워크, (b) SNR 환경  
Fig. 3. Simulation environment; (a) Sensor network and (b) SNR environment

의 특징을 살려 연산량을 줄이면서도 충격잡음의 영향을 거의 제외할 수 있음을 알 수 있다.

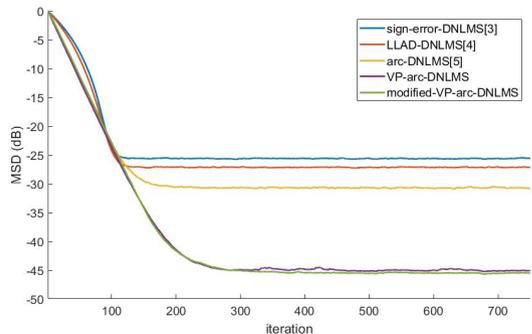


그림 4. MSD 학습 곡선, 충격 잡음 확률 P=0.3  
Fig. 4. MSD learning curve, Impulsive noise probability P=0.3

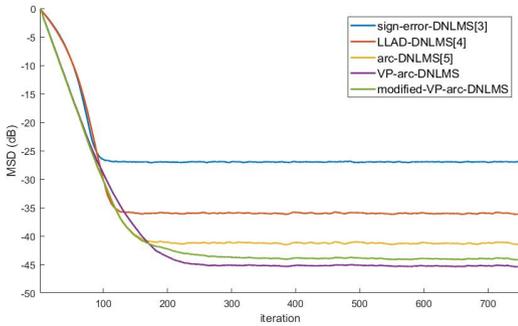


그림 5. MSD 학습 곡선, 충격 잡음 없음  
Fig. 5. MSD learning curve, No impulsive noise

두 번째 시뮬레이션(그림 5 참조)은 첫 번째와 유사한 환경으로 실험하였으며, 충격 잡음의 확률만 0으로 설정하여 충격 잡음이 없는 환경에서도 잘 동작하는 것을 확인할 수 있다. 또한, diffusion LMS의 MSD 성능은 다음과 같이 정의된다.

$$MSD(i) = \frac{1}{N} \sum_{k=1}^N \frac{\| \mathbf{w}_0 - \mathbf{w}_{k,i} \|_2^2}{\| \mathbf{w}_0 \|_2^2} \quad (14)$$

끝으로 세 번째 시뮬레이션(그림 6 참조)에서 FSNR은 15,  $\alpha$ 는 0.8로 설정하였고, 조건에 맞게  $p$ 는 0.6으로 하였다. 연산량 차이가 많이 나지만 약간의 차이를 제외하고 동등한 수렴 성능을 나타내는 것을 확인할 수 있다. 이는 충격잡음이 극단적으로 크게 나타나는 베르누이-가우스 프로세스와 달리 충격잡음이라고 부를 수 있지만 너무 크지 않은 잡음이 자주 섞이기 때문이라고 할 수 있다. 이러한 환경에서 제안하는 알고리즘과 충분히 큰  $N_w$ 를 가지는 기존의 알고리즘이 충격잡음의 영향을 거의 받지 않는다고 볼 수

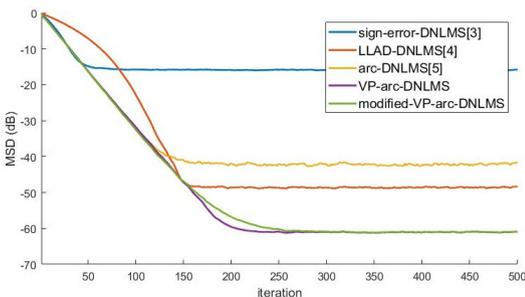


그림 6. MSD 학습 곡선, 충격 잡음 FSNR=15,  $\alpha=0.8$ ,  $p=0.6$   
Fig. 6. MSD learning curve, Impulsive noise FSNR=15,  $\alpha=0.8$ ,  $p=0.6$

있다.

#### IV. 결론

본 논문에서는 효율적 가변 변수를 이용한 arc-DNLMS를 제안하였다. 기존의 arc-DNLMS에서의 디자인 파라미터를 가변 변수로 적용하여 보다 더 높은 MSD 수렴 성능을 가질 수 있었다. 특히, 본 논문에서는 가변 변수의 특징을 분석하고 이미 적용된 아크탄젠트 비용 함수의 특징을 이용하여, 제안한 arc-DNLMS 알고리즘이 충격 잡음의 발생 확률 정보를 요구되지 않으면서도 연산량을 감소시키고, MSD 수렴 성능을 유지할 수 있음을 시스템 추정 컴퓨터 시뮬레이션을 통해 검증하였다.

#### References

- [1] S. Haykin, *Adaptive Filter Theory*, 5<sup>th</sup> Ed., Pearson, 2014.
- [2] F. S. Cattivelli and A. H. Sayed, "Diffusion LMS strategies for distributed estimation," *IEEE Trans. Signal Process.*, vol. 58, no. 3, pp. 1035-1048, Mar. 2010.
- [3] J. Ni, J. Chen, and X. Chen, "Diffusion sign-error LMS algorithm: formulation and stochastic behavior analysis," *Signal Process.*, vol. 128, pp. 142-149, 2016.
- [4] F. Chen, T. Shi, S. Duan, L. Wang, and J. Wu, "Diffusion least logarithmic absolute difference algorithm for distributed estimation," *Signal Process.*, vol. 142, pp. 423-430, 2018.
- [5] J. Park, J. Kim, and S. W. Nam, "An arctangent cost function based diffusion NLMS algorithm for distributed estimation," *IEIE Autumn Conf. Regular Meeting*, pp. 491-493, Songdo, Korea, Nov. 2017.
- [6] F. Huang, J. Zhang, and S. Zhang, "NLMS algorithm based on variable parameter cost function robust against impulsive interferences," *IEEE Trans. Circuits Syst. II, Exp. Briefs.*, vol. 64, no. 5, pp. 600-604, May 2017.
- [7] J. H. Kim, J.-H. Chang, and S. W. Nam, "Sign subband adaptive filter with  $l_1$ -norm

minimisation-based variable step-size,” *Electronics Lett.*, vol. 49, no. 21, pp. 1325-1326, Oct. 2013.

- [8] E. E. Kuruoglyu, P. J. W. Rayner, and W. J. Fitzgerald, “Least  $l_p$ -norm impulsive noise cancellation with polynomial filters,” *Signal Process.*, vol. 69, no. 1, pp. 1-14, May 1998.
- [9] S. Zhang, J. Zhang, and H. Han, “Robust shrinkage normalized sign algorithm in an impulsive noise environment,” *IEEE Trans. Circuits Syst. II, Exp. Briefs*, vol. 64, no. 1, pp. 91-95, Jan. 2017.

**박 종 훈 (JongHun Park)**



2016년 2월 : 한양대학교 융합  
전자공학부 졸업 (학사)  
2018년 2월 : 한양대학교 전자  
컴퓨터통신공학과 졸업 (석  
사)  
2018년 4월~현재 : (주)나라컨  
트롤 재직

<관심분야> 신호처리, 통신공학, 임베디드

**김 진 (Jin Kim)**



2012년 2월 : 한양대학교 전자  
통신컴퓨터공학과 졸업 (학  
사)  
2012년 2월~현재 : 한양대학교  
전자컴퓨터통신공학과 석·  
박사 통합과정  
<관심분야> 신호처리, 적응필  
터, Active Noise Control

**남 상 원 (Sang Won Nam)**



1981년 2월 : 서울대학교 전자  
공학과 졸업 (학사).  
1987년 5월 : 텍사스 오스틴대  
학교 전기컴퓨터공 학과 졸  
업 (공학 석사).  
1990년 : 텍사스 오스틴대학교  
전기컴퓨터공학과 졸업 (공  
학박사)

1991~현재 : 한양대학교 융합전자공학부 교수  
<관심분야> 신호처리, 필터설계, Active Noise  
Control