

뉴로-퍼지제어기를 이용한 적응 능동소음제어

김종우* · 공성곤

Adaptive Active Noise Control Using Neuro-Fuzzy Controller

Jong-Woo Kim* · Seong-Gon Kong

Abstract - This paper presents the adaptive Active Noise Control(ANC) system using the Neuro-Fuzzy controller. In general, the character of noise is time-varying and nonlinear. Thus controller must have the adaptivness so that applied in Active Noise Control system to cancel the noise. This paper propose the Neuro-Fuzzy controller trained with back-propagation learning algorithm to optimize the parameters of controller. The objects of this paper are cancel the noise, extract the original(speech) signal polluted by noise and design the Neuro-Fuzzy controller.

1. 서 론

소음공해로 인한 육체적, 정신적인 피해가 증가함에 따라 소음을 제거하려는 노력이 계속되어져 왔다. 소음을 제거하는 방법에는 크게 수동소음제어와 능동소음제어 두가지로 나눌 수 있다. 수동소음제어란 물리적인 방음벽에 의존하여 방음하는 것을 말하며 이는 그 재질과 두께 및 크기에 따라 성능에 차이가 있다. 수동소음제어는 제거하고자 하는 잡음의 한주기 길이와 같은두께의 방음벽이 필요하므로 비효율적이다. 이에반해 능동소음제어는 잡음과 크기가 같고, 위상이 반대인 신호를 제어기의 출력으로 스피커를 통해 내어줌으로써 잡음과 상쇄되도록 한다.[1] 이는 고주파잡음은 물론 저주파잡음도 제어 가능하고 제한된 공간내에서 큰부피를 차지하지 않아 효율적이다.

소음은 비선형성이 강하고 시변특성을 갖기 때문에 일반 고정제어기로 제어하기 어렵다. 본 논문에서는 소음에 적응적으로 대처하기 위해 비선형 특성을 갖는 뉴로-퍼지 제어기를 이용한 제어시스템을 모델링한다. 제안한 뉴로-퍼지제어기는 T-S-K 퍼지모델, 가우시안 입력 멤버쉽함수, 그리고 Subtractive 클러스터링 방법을 이용한다. T-S-K 퍼지모델의 후건부는 입력변수의 선형조합으로 이루어진다. 후건부 파라미터는 임의값으로 초기화 한다. 이후 Back-Propagation 학습 알고리즘을 이용하여 오차가 최소가 되도록 입력 멤버쉽함수의 중심값, 폭 그리고 후건부 파라미터를 미세조정 한다.[2][4]

본 논문에서는 잡음의 왜곡경로인 1차 왜곡경로와 제어신호의 왜곡경로인 2차 왜곡경로를 고려한다. 1차 왜곡경로는 시간지연, 크기감소, 잡음첨가 요소를 고려하여 임의로 설정하고, 2차 왜곡경로는 잡음첨가 요소만을 고려한다.

2. 본 론

2.1 적응 잡음제거 시스템

적응 잡음제거 시스템이란 잡음을 제거하고자 하는 공간내에 외부로부터 유입되는 잡음을 적응적으로 제거하고, 또 잡음에 의해 오염된 원신호에서 잡음성분을 제거하여 원신호를 복원코저 하는 시스템이다.

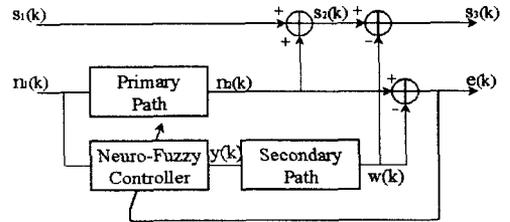


그림 1. 시스템 전체 구성도

그림 1은 본 논문에서 제안한 적응잡음제거 시스템의 구성도이다. $n_1(k)$ 는 잡음원, $n_2(k)$ 는 1차 왜곡경로를 거친 잡음, $y(k)$ 는 제어기출력, $w(k)$ 는 2차 왜곡경로를 거친 제어기출력, $e(k)$ 는 오차, $s_1(k)$ 는 원신호, $s_2(k)$ 는 1차 왜곡경로를 거친 잡음과 합쳐진 원신호, $s_3(k)$ 는 복원된 원신호를 나타낸다. 제어기 출력은 1차 왜곡경로에 의해 왜곡된 잡음 $n_2(k)$ 를 추종하게 된다. 2차 왜곡경로는 제어기이후 파워앰프, 스피커의 전달경로이다.[3] 왜곡된 잡음 $n_2(k)$ 와 제어부 출력 $w(k)$ 의 합인 오차 $e(k)$ 가 최소가 되도록 제어기 파라미터를 조정한다. 그림 1에서 합산기는 모두 같은 마이크이며, $s_3(k)$ 와 $w(k)$ 출력은 같은 제어스피커를 통한 출력이다.

2.1.1 뉴로-퍼지제어기 내부구조

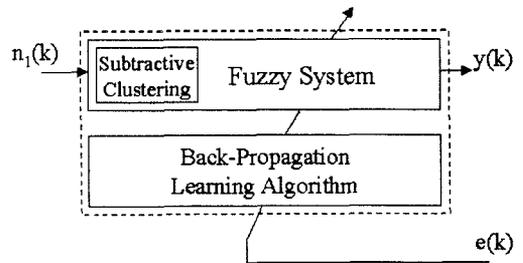


그림 2. 뉴로-퍼지제어기 내부구조

그림 2는 뉴로-퍼지제어기의 내부구조이다. 잡음원 $n_1(k)$ 를 입력으로 하여 Subtractive 클러스터링을 한다. 그 결과로 멤버쉽함수의 초기 중심값과 폭을 설정한다. Subtractive 클러스터링은 각 파라미터의 초기값을 설정하기 위해 학습데이터를 이용해 처음 한번만 실행하며, 이후 잡음입력은 Subtractive 클러스터링을 하지않고 생성된 초기 퍼지시스템으로 직접 입력된다. 퍼지시스템의 출력 $y(k)$ 는 2차 왜곡경로를 통해 최종출력 $w(k)$ 가 되며 이 값은 $n_2(k)$ 와 더해져 오차 $e(k)$ 을 생성한다. Back-Propagation 학습 알고리즘을 이용하여 오차 $e(k)$ 를 줄이는 방향으로 입력 멤버쉽함수의 중심값과 폭, 후건부 파라미터를 조정한다.

2.1.2 뉴로-퍼지제어기 입력

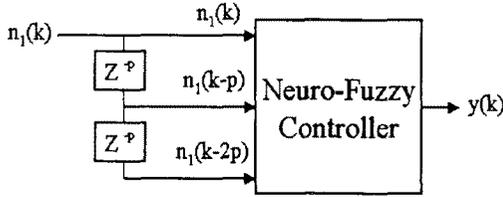


그림 3. 뉴로-퍼지제어기 입력

그림 3은 뉴로-퍼지제어기의 입력 구성도이다. 원잡음 신호 $n_1(k)$ 와 p 만큼 시간지연된 $n_1(k-p)$, $2p$ 만큼 시간지연된 $n_1(k-2p)$ 를 입력으로 고려한다.

2.2 뉴로-퍼지제어기의 파라미터

2.2.1 파라미터 초기화

본 논문에서 제안한 뉴로-퍼지제어기에서 초기화되어야 할 파라미터들은 입력 멤버십함수의 중심값, 폭, 후건부 파라미터이다. 이중 입력 멤버십함수의 중심값과 폭은 Subtractive 클러스터링 방법에 의하여 결정된다. Subtractive 클러스터링 방법은 퍼지시스템을 모델링하는 방법중 하나이다. 본 논문에서는 초기 퍼지시스템을 모델링하고 입력 멤버십함수의 초기값을 결정하는 용도로만 사용한다. 이는 각각의 데이터를 입출력 공간상에 표현하고, 정규화과정을 거친 후 각 데이터에서 데이터 간의 거리를 나타내는 함수를 이용하여 식(1)과 같이 포텐셜을 구한다.

$$P_i = \sum_{j=1}^K \exp(-\alpha \|X_i - X_j\|^2) \quad \text{단, } i=1,2,3 \dots, K \quad (1)$$

P_i 는 i 번째 데이터의 포텐셜 값이며 α 는 $4/r_a^2$ 로 주어지며, r_a 는 양의 상수로서 r_a 밖의 데이터는 포텐셜값에는 거의 영향을 주지 못한다. 식(1)에 의해 구한 포텐셜값중 가장 큰 값을 P_1^* 로 표시하고 이때의 데이터를 첫번째 클러스터 중심 X_1^* 로 설정한다. 첫번째 클러스터 중심의 영향을 제거하기 위해서 식(2)에 의해 새로운 포텐셜값을 구한다.

$$P_i' = P_i - P_1^* \exp(-\beta \|X_i - X_1^*\|^2) \quad \text{단, } i=1,2,3 \dots, K \quad (2)$$

P_i' 는 첫번째 중심의 영향을 제거한 i 번째 포텐셜값이고 β 는 $4/r_b^2$ 로 주어지며, r_b 는 양의 상수로 r_a 보다 큰 수를 취해 클러스터 중심 근처에 다음 클러스터 중심이 나타나지 않도록 한다. 구한 P_i' 중 가장 큰 값을 P_2^* 라 표시하고 이때의 데이터를 두번째 클러스터 중심을 X_2^* 로 설정한다. k 번째 클러스터 중심 X_k^* 가 선정되면 k 번째 클러스터 중심의 영향을 제거한 포텐셜값은 식(3)과 같고 이중 가장 큰 값을 $(k+1)$ 번째 클러스터 중심값으로 설정한다.

$$P_i' = P_i - P_k^* \exp(-\beta \|X_i - X_k^*\|^2) \quad \text{단, } i=1,2,3 \dots, K \quad (3)$$

$\bar{\epsilon}$ 와 $\underline{\epsilon}$ 은 클러스터 중심 선정의 상하기준이 되는 상수로서 0부터 1사이의 값이 된다. 즉 P_k^* 를 P_1^* 로 나눔으로써 첫번째 포텐셜값의 크기를 1로 만들었으며, 또한 클러스터 중심선정의 상하기준 ($\bar{\epsilon}$, $\underline{\epsilon}$)을 설정하여 P_k^*/P_1^* 이 $\bar{\epsilon}$ 보다 크면 클러스터 중심으로 결정하고, $\underline{\epsilon}$ 보다 작으면 클러스터 중심으로 결정하지 않는다. 그 사이일 경우에는 조건부로 클러스터 중심으로 선정한다. 이러한 조건부를 선정기준에 넣음으로써 포텐셜값이 낮더라도 클러스터 중심간의 거리 d_{min} 이 크면 클러스터 중심으로 결정한다.[4]

초기 퍼지모델을 설정하기 위해 Subtractive 클러스터링을 사용한다. Subtractive 클러스터링의 결과로 다음

세계의 퍼지규칙을 생성한다. 퍼지규칙의 후건부 파라미터는 임의의 값으로 초기화 한다.

Rule 1

If $n_1(k)$ is OV_{11} AND $n_1(k-p)$ is DIN_{12} AND $n_1(k-2p)$ is $DDIN_{13}$ THEN $y_1(k) = a_{10} + a_{11}n_1(k) + a_{12}n_1(k-p) + a_{13}n_1(k-2p)$

Rule 2

If $n_1(k)$ is OV_{21} AND $n_1(k-p)$ is DIN_{22} AND $n_1(k-2p)$ is $DDIN_{23}$ THEN $y_2(k) = a_{20} + a_{21}n_1(k) + a_{22}n_1(k-p) + a_{23}n_1(k-2p)$

Rule 3

If $n_1(k)$ is OV_{31} AND $n_1(k-p)$ is DIN_{32} AND $n_1(k-2p)$ is $DDIN_{33}$ THEN $y_3(k) = a_{30} + a_{31}n_1(k) + a_{32}n_1(k-p) + a_{33}n_1(k-2p)$

2.2.2 파라미터 학습

본 논문에서는 Back-Propagation 학습 알고리즘을 이용하여 오차가 최소가 되는 방향으로 초기화된 파라미터를 조정한다. Back-Propagation 학습 알고리즘을 적용하기 위해서는 다음과 같은 세가지 조건이 필요하다. 첫째, Implication 과정에서 'min' operation 대신 'product' operation을 사용하는 Larsen's method를 적용한 Simplified Reasoning을 사용한다. 둘째, 적합도 (Degree Of Fire)를 구하는데 있어서 'min' operation 대신 'product' operation을 사용한다. 셋째, 입력 멤버십함수로 가우시안 함수를 사용한다. 가우시안 함수를 멤버십함수로 사용할 경우, 입력이 주어질 때 싱글톤방법을 이용하여 퍼지화 한 후 적합도를 찾는 과정에서 'product' operation을 사용하므로 지수부분의 합으로 표현한다. 제시된 퍼지규칙은 세가지 조건으로부터 다음과 같은 식으로 표현한다.

$$y = \frac{\sum_{i=1}^3 \tau_i y_i^*}{\sum_{i=1}^3 \tau_i} \quad \text{단, } y_i^* \text{는 } i \text{번째 규칙의 후건부} \quad (4)$$

$$y = \sum_{i=1}^3 v_i y_i^* \quad (5)$$

$v_i = \tau_i / \sum_{i=1}^3 \tau_i$ 라 할 경우 v_i 를 정규화된 적합도 (Normalized DOF)라 하며, 식(4)는 식(5)와같이 쓸 수 있다. 식(4)에서 y 는 퍼지시스템 최종출력, τ_i 는 i 번째 규칙의 적합도를 나타내며, Simplified Reasoning 방법에 의한 퍼지시스템 최종 출력식이다.

$$\tau_i = \prod_{j=1}^3 \left[\exp\left(-\frac{1}{2} \left(\frac{u_j - x_{ij}^*}{\sigma_{ij}}\right)^2\right) \right] = \exp\left(-\frac{1}{2} \sum_{j=1}^3 \left(\frac{u_j - x_{ij}^*}{\sigma_{ij}}\right)^2\right) \quad (6)$$

식(6)은 입력 멤버십함수로 가우시안 함수를 적용한 경우 적합도 τ_i 를 정의한 식이다. x_{ij}^* 는 각 퍼지 입력 멤버십함수의 중심값이며, σ_{ij} 는 폭이다.

$$E_k = \frac{1}{2} (n_2(k) - y(k))^2 = \frac{1}{2} (e)^2 \quad \text{단, } e = n_2(k) - y(k) \quad (7)$$

식(7)은 오차를 정의한 식이다. 식(4), 식(5), 식(6), 식(7)을 이용하고, Gradient Descent법과 Chain Rule을 적용한 학습식은 다음과 같다.[2]

$$a_{i0}(k+1) = a_{i0}(k) - \alpha \frac{\partial E_k}{\partial a_{i0}} = a_{i0}(k) - \alpha v_i e \quad (8)$$

$$a_{ij}(k+1) = a_{ij}(k) - \alpha \frac{\partial E_k}{\partial a_{ij}} = a_{ij}(k) - \alpha v_i e u_j \quad \text{단, } j=(1, r) \quad (9)$$

$$x_{ij}^*(k+1) = x_{ij}^*(k) - \alpha \frac{\partial E_k}{\partial x_{ij}^*} = x_{ij}^*(k) - \alpha v_i (a_{i0} + a_{i1}u_1 + \dots + a_{ir}u_r - y) e \frac{u_j - x_{ij}^*(k)}{\sigma_{ij}^2(k)} \quad (10)$$

$$\sigma_{ij}^*(k+1) = \sigma_{ij}^*(k) - \alpha \frac{\partial E_k}{\partial \sigma_{ij}^*} = \sigma_{ij}^*(k) - \alpha v_i (a_{i0} + a_{i1}u_1 + \dots + a_{ir}u_r - y) e \frac{(u_j - x_{ij}^*(k))^2}{\sigma_{ij}^3(k)} \quad (11)$$

2.3 시뮬레이션

2.3.1 시뮬레이션 환경

제거하고자 하는 잡음이 4KHz이하의 주파수를 갖는

다면 수동소음제어에 의존시 약 10[Cm]이상의 방음제가 필요하기 때문에 비효율적이다. 시뮬레이션 데이터로 일상생활에서 접할 수 있는 4(KHz)이하의 저주파 잡음을 선택하여 실험한다. 잡음을 800(Hz)로 샘플링한 500개의 데이터를 학습데이터로 이용한다. 학습된 파라미터는 퍼지시스템에 대입되며, 8(KHz)로 샘플링된 625(ms)의 5000개 잡음신호 데이터에 적용한다. 원신호가 있는 경우와 없는 경우에 대한 시뮬레이션을 한다. 원신호는 음성신호 '오'라는 단일음을 잡음과 같은 크기로 샘플링하여 사용한다.

2.3.2 원신호가 없는 경우

원신호(음성신호 $s_1(k)$)가 없는 경우 즉, 잡음만이 존재하는 경우 시뮬레이션 결과이다.

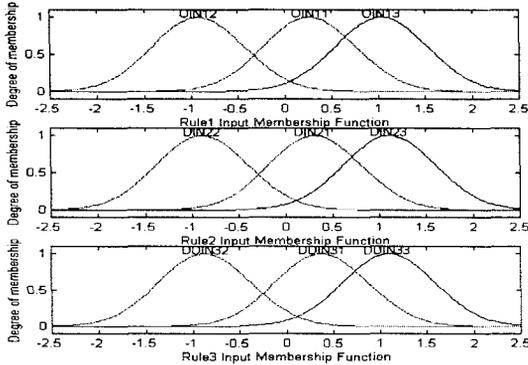


그림 4. 파라미터 튜닝 후 입력 멤버쉽 함수

그림 4는 Subtractive 클러스터링 이후 생성된 초기 퍼지시스템을 Back-Propagation 학습 알고리즘으로 파라미터 튜닝한 후의 입력 멤버쉽 함수이다.

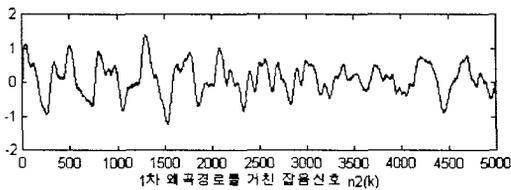


그림 5. $n_2(k)$

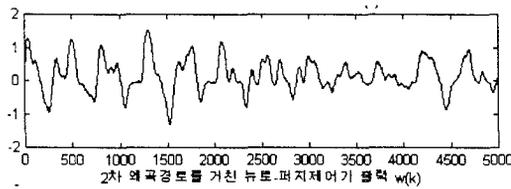


그림 6. $w(k)$

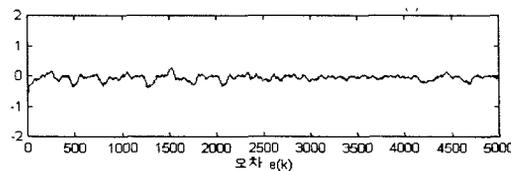


그림 7. $e(k)$

그림 5는 1차 왜곡경로를 거친 잡음신호이며, 그림 6은 2차 왜곡경로를 거친 뉴로-퍼지제어기 신호이다. 그림 7은 이 두 신호의 차이인 오차신호이다.

표 1. 원잡음신호와 오차의 평균 power 비교

	$n_2(k)$	$e(k)$
실험 1	0.2167	0.0452
실험 2	0.2156	0.0321
실험 3	0.2189	0.0467

표 1은 1차 왜곡경로를 거친 잡음의 평균 power와 오차신호의 평균 power를 비교하였다.

2.3.3 원신호가 있는 경우

원신호(음성신호 $s_1(k)$)가 있는 경우 시뮬레이션 결과이다.

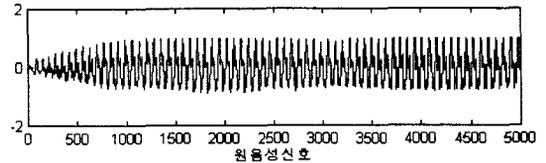


그림 8. $s_1(k)$

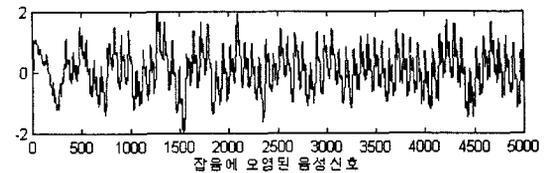


그림 9. $s_2(k)$

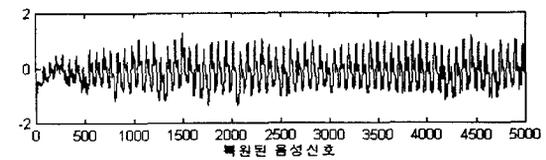


그림 10. $s_3(k)$

그림 8은 '오'라는 단일 음성신호이고, 그림 9는 1차 왜곡경로를 거친 잡음신호 $n_2(k)$ 에 의해 오염된 음성신호이며, 그림 10은 뉴로-퍼지제어기의 출력신호로 잡음성분이 제거되어 복원된 음성신호이다.

3. 결론

본 논문에서는 뉴로-퍼지제어를 이용한 능동소음제어 시스템을 구성하였다. 비선형성이 강한 잡음을 제어하는데 뉴로-퍼지제어를 적용 함으로써 효과적으로 대처함을 보였다.

[참고 문헌]

- [1] F. Jiang and H. Tsuji, "Adaptation for Active Noise Control," *IEEE Trans. on Control Systems*, Vol. 17, No. 6, 36-47, Dec. 1997.
- [2] R. Yager and P. Filev, *Essentials of Fuzzy Modeling and Control*, John-Wiley and Sons, 1994.
- [3] B. Widrow and S. D. Stearns, *Adaptive Signal Processing*, Prentice Hall, 1985.
- [4] 박희경, 공성곤, "뉴로-퍼지제어를 이용한 밀폐공간 소음 제어", 대한전기학회 컴퓨터 및 인공지능연구회, 38-41, 1998. 11.