
적응필터 및 신경회로망에 의한 음장의 역 필터링

최재승*

Reverse Filtering of Sound Field by Adaptive Filter and Neural Network

Jae-seung Choi*

요 약

본 논문에서는 두 개의 음으로부터 전달되어온 음장의 상태를 구하여 역 필터를 구성하는 적응필터 및 신경회로망을 사용한 음장의 역 필터링 시스템을 제안한다. 본 논문에서는 최소 2승 평균법을 사용하여 FIR 필터의 계수를 계산하여 이를 갱신함으로써 역 필터링을 구축하는 방법을 사용한다. 본 논문에서 제안한 신경회로망 및 적응필터의 기법에 의하여 비선형 왜곡이 있는 간단한 파형이 학습 가능한 것을 실험 결과로부터 확인할 수 있었다.

ABSTRACT

This paper proposes a reverse filtering system of sound field obtaining a state of sound field transmitted from two sounds, using an adaptive filter and neural network. The proposed system uses the reverse filtering method with calculating and renewing a coefficient of a filter, using least mean square. Based on training the neural network, experiments confirm that the proposed system is effective for a simple waveform with non-linear distortion, by using neural network and adaptive filtering method.

키워드

Reverse filtering, Adaptive filter, Neural network, Least mean square.

1. 서 론

일반적으로 음장의 역 필터링 기법은 실 생활 속에서 소음을 제거할 뿐만아니라 사람의 귀에 들리는 음들을 인간 생활의 다양한 장소에 전달할 수 있다. 또한 이 기법은 청각의 연구 및 실험에 없어서는 안되는 것으로 생각 된다 [1, 2]. 본 논문에서는 먼저 어떤 음을 듣고 있는 사람이 음원으로부터 나온 음과 동일한 음을 들을 수 있는 시스템을 구축하는 것을 목적으로 하여, 음원으로부터 나온 음과 도달지점에 도착한 음을 알고 있다는 점을 전제로 한다. 따라서 이 두 개의 음

으로부터 전달되어온 음장의 상태를 구하여 이 역 필터를 구성하는 방법을 연구한다.

본 논문에서는 이전부터 실시되어온 주요한 역 필터의 구성방법을 조사하여, 최소 2승 평균법(Least Mean Square, LMS) [3]을 사용하여 FIR(Finite Impulse Response) 필터 [4]의 계수를 계산하여 이를 갱신함으로써 역 필터링을 구축하는 방법을 사용한다. 또한 이 방법과는 별도로 오차역전파 알고리즘(Back Propagation, BP) [5]에 의한 신경회로망(Neural Network, NN) [6, 7]을 사용한다. 신경회로망은 비선형함수의 학습의 효과를 가지기 때문에 종래의 방법으

* 신라대학교 전자공학과(jschoi@silla.ac.kr)
접수일자 : 2010. 03. 09

심사완료일자 : 2010. 04. 13

로는 LMS법의 일부분을 신경회로망에 대처하기 어렵기 때문에 비선형 왜곡의 수정 등 새로운 역 필터의 방법이 필요하다. 따라서 본 논문에서는 네트워크 자체를 필터로 생각하여 LMS법의 일부분을 신경회로망에 대처하는 방법을 제안한다.

따라서 본 논문에서 제안한 적응필터 및 신경회로망에 의하여 비선형 왜곡이 있는 간단한 과형이 학습 가능한 것을 실험 결과로부터 확인할 수 있었다.

II. 음장의 역 필터링의 이론 및 문제점

2.1. 주요한 역 필터링 방법

음장의 역 필터링은 미지의 시스템의 전달함수의 역함수를 구하는 문제이다. 이 미지의 시스템의 전달함수의 역함수를 구하는 모델링에는 적응필터[8]를 사용하는 경우가 많다. 역 필터링의 개념을 그림 1에 나타낸다. 먼저 미지의 시스템의 출력을 적응필터에 입력한다. 미지 시스템에의 입력을 δ 만큼 지연시킨 것이 적응필터의 응답의 목표값이다. 오차를 최소화하기 위해서는 적응 필터가 미지 시스템의 역 필터로 되어 있는 관계로부터 미지 시스템과 적응 필터의 직렬 접속의 단위 임펄스 응답이 동일한 단위 임펄스로 되도록 전달함수를 실현시켜야 한다. 이렇게 하기 위해서는 오차 ϵ 을 최소화하도록 적응 필터를 학습시키면 된다. 이 때에 적응 필터에는 미지 시스템의 역 함수가 생성된다.




그림 1. 역 모델링
Fig. 1 Reverse modeling.

그러나 그림 1의 방법은 적응 필터의 출력의 입력에 대한 오차를 가지고 학습을 실시하여야할 제한을 가지고 있다. 따라서 이 방법은 본 논문의 목표인 청각 실험에 사용하기 위한 시스템에는 부적당하다고 판단된다. 그 이유는 이 시스템에서는 본 논문에서 목

표로 하는 미지의 시스템의 출력을 제어하기가 어렵기 때문이다. 그림 1의 제한을 없애기 위해서는 통계적으로 미지 시스템의 출력을 예측하는 모델이 제안되어 있으며 이 방법을 그림 2에 나타낸다.




그림 2. 적응적 예측 역 모델링
Fig. 2 Reverse modeling by adaptive prediction.

그림 2의 방법은 동일한 필터를 2개 준비한다. 이 중에서 적응 필터에는 미지의 시스템의 출력을 δ 만큼 지연시킨 것을 입력하며, 적응 필터의 응답의 목표값은 다른 하나의 필터(슬레이브 필터)의 출력으로 한다. 필터의 가중치 계수는 학습이 진행되면 어떤 값으로 수축한다. 이 수축한 가중치 계수는 δ 만큼 지연시킨 현재의 입력을 최우선으로 예측하는 값이다. 입력을 I , 미지의 시스템의 전달함수를 M , 슬레이브 필터의 전달함수를 S , 적응필터의 전달함수를 A , 지연을 $e^{-j\delta\omega}$ 로 표현하면, 학습에 의하여 $\epsilon = IS(e^{-j\delta\omega} - MA) \rightarrow 0$ 이 되어 $A = M^{-1} \cdot e^{-j\delta\omega}$ 가 된다. A 를 S 와 동일하게 되도록 항상 조정하여 두면, 미지 시스템의 출력은 $IM^{-1} \cdot e^{-j\delta\omega}M = Ie^{-j\delta\omega}$ 이 되어, δ 만큼 지연된 입력 신호를 구한다. 즉, 이 시스템을 사용함으로써 입력과 동일한 과형의 출력이 구해진다. 슬레이브 필터의 가중치는 적응필터에 의하여 계산된 최적인 가중치이다.

이 방법은 미지의 음장을 통과하기 전에 음을 수정하는 것이 가능하기 때문에 본 논문의 실험에도 적용된다. 본 실험에서는 이 방법을 참고로 하여 시스템을 구성한다.

2.2. 역 필터링에서 사용하는 일반적인 학습법

역 필터링에 사용되는 학습법의 최근 경향은 LMS법 [3]이다. 이 방법은 2승 평균오차의 최소값에 적응되게 하는 방법으로 다음식과 같은 최급강하법에 기초를 두고 있다.

$$e(k) = y(k) - x^T(k) \hat{h}(k) \quad (1)$$

$$\hat{h}(k+1) = \hat{h}(k) - K \nabla_{\hat{h}(k)} e^2 \quad (2)$$

여기에서 $x(k)$, $y(k)$, $e(k)$ 는 파형 $x(k)$, $y(k)$, $e(k)$ 의 표본점 kT 에서의 순간값으로, $x^T(k)$ 와 $\hat{h}^T(k)$ 는 $[x(k), x(k-1), \dots, x(k-N+1)]$ 및 $[\hat{h}_0(k), \hat{h}_1(k), \hat{h}_2(k), \dots, \hat{h}_{N-1}(k)]$ 와 같은 요소를 가진 벡터이다. 여기에서 N 은 필터의 차수이고, K 는 루프 게인, e^2 은 2승평균오차, ∇ 는 경사 연산자를 나타낸다. 만약 2승오차의 순시값이 2승평균오차와 거의 동등하다고 가정하면, 식 (2)는 다음식과 같이 된다.

$$\hat{h}(k+1) = \hat{h}(k) + 2Ke(k)x(k) \quad (3)$$

이 알고리즘은 N 차수 필터의 반복에 대해서 $O(2N)$ 회의 연산과 $O(2N)$ 회의 합만으로 계산 가능하다. 여기에서 $O(J)$ 는 J 의 차수를 의미한다. 그러나 이 알고리즘에는 다음과 같은 문제점을 가지고 있다. 그것은 입력 신호의 자기상관행렬의 고유값의 크기에 대해서 수속도의 의존성이 있다는 것이다. 입력신호가 넓은 스펙트럼을 가진다면, 이것은 본 논문에서 희망하는 주파수 성분을 가지고 있는가 없는가와 상관없이 이 알고리즘의 수속도는 상당히 느리게 된다. 따라서 어떤 입력에 대해서도 동일한 수속도로서 수속하도록 하는 점을 고려하여야 한다.

III. 신경회로망

본 실험에 사용한 신경회로망은 중간층을 한 개 가진 3층 구조의 계층형 신경회로망이며, 학습법은 BP 방법을 사용하였으며 학습의 순서는 다음과 같다. (1) 가중치를 초기화한다. (2) 미지의 시스템 및 NN에 의한 지연시간 δ 전의 목표값을 필터용 NN에 입력하여 출력 $u(t)$ 를 계산한다. (3) 미지의 시스템을 통과한 출력 $y(t)$ 를 학습용 NN에 입력하여 출력 $\hat{u}(t-1)$ 을 계산한다. (4) $\hat{u}(t-1)$ 과 $u(t-1)$ 과의 오차를 사용하여 NN을 학습시킨다. (5) 학습용 NN의 가중치를 필터용 NN에 복사한다. (6) (2)에 돌아가서 반복한다. 이러한 방법을 온라인 학습의 General Learning

Architecture라고 한다.

실제로 이러한 학습을 하기 위해서는 부가적인 선형 제어 등의 NN의 학습을 촉진시키는 보조적인 시스템이 필요하지만 본 알고리즘에서는 이점이 고려되어 있지 않다. 이대로의 구성으로는 미 학습의 NN으로부터 미지의 시스템에의 입력이 정수만이 되므로 학습 데이터를 구하는 것을 고려하지 않으면 안된다. 즉, $u(t)$ 로서 학습이 어느 정도 진행되기까지는 다른 학습하기 쉬운 값을 교사 데이터로서 입력할 필요가 있다. 이 문제에 관해서는 제 V장에서 고려하기로 한다. 또한 전절에서 기술한 것과 같이 relative order가 1이 아닌 경우도 고려하여 본 실험에서는 4개 앞의 희망 출력까지 NN의 입력으로 하고 있다.

IV. 역 필터링의 실험 방법

본 장에서는 본 실험에서 사용하는 역 필터의 실험 방법과 알고리즘에 대해서 기술한다. 본 실험에 사용한 역 필터링 시스템의 간략도는 그림 3과 같다. 그림 3은 II.1절에서 기술한 그림 2와 상당히 비슷하다. 즉, 그림 2에서 기술한 적응적 예측 역 모델링에서는 1 지연 시간 δ 전의 출력만을 적응필터에의 입력으로 하여 다음 출력을 예측하고 있다. 반면에 그림 3의 시스템에서는 이 지연시간으로부터 더욱 2개 이상 전의 출력을 신경회로망에의 입력으로써 학습을 실시하여 다음 출력을 예측하고 있다.




그림 3. 시스템 개략도
Fig. 3 System block diagram.

미지 시스템(즉 미지의 음장)은 다음의 이산시간의 SISO(Single Input Single Output)의 비선형 동적 시스템으로 표현하는 것으로 가정한다. 즉,

$$x(t+1) = f(x(t), u(t)) \quad (4)$$

$$y(t) = h(x(t)) \quad (5)$$

여기에서 $x(t) \in \mathcal{R}^n$, $y(t) \in \mathcal{R}$, $u(t) \in \mathcal{R}$ 는 각각 시각 t 에서의 상태량, 미지시스템의 출력 및 입력이며, $f(x, u)$, $h(x)$ 는 해석적인 사상이다. 간단함을 위하여 relative order는 1, 즉 $h(f(x, u))$ 의 정칙점 (x_0, u_0) 의 근방 U_0 에 있어서 식 (6)이 성립된다고 가정한다.

$$\frac{\partial h(f(x, u))}{\partial u} \neq 0 \quad (6)$$

또한 본 실험은 외부입력에 미지시스템의 출력을 추종하기 때문에, 외부로부터 입력된 출력의 목표치 열을 $y_D(0), y_D(1), y_D(2), \dots$ 으로 한다. 단, relative order가 1인 것으로 가정하고 있기 때문에, 시각 t 에 있어서 $y_D(t+1)$ 이 필요하다.

식 (6)이 성립하고 있기 때문에 (x_0, u_0) 의 근방이 존재하여, 이 근방에 있어서 $y(t+1) = h(f(x(t), u(t)))$ 의 $u(t)$ 에 관한 역사상이 존재한다.

$$u(t) = \alpha(x(t), y(t+1)) \quad (7)$$

따라서 NN에 함수 $\alpha(x(t), y(t+1))$ 를 학습시킴으로써 다음 식을 구할 수 있다.

$$y(t+1) = h(\alpha(x(t), \tilde{y}_D(t+1))) \quad (8)$$

따라서 이 계열은 목표치를 출력으로 한다. 그러나 본 실험에 사용한 방법에서는 모두의 상태량을 입력으로 하고 있지는 않기 때문에 모든 y_D 에 대해서 완전히 $y(t+1) = y_D(t+1)$ 로 하는 것은 가능하지 않다. 이것을 보충하기 위하여 NN에 병렬로 선형의 보상을 붙여서 실시할 필요하다(그림 3 참조).

V. 실험

본 장에서는 앞에서 설명한 교사 데이터의 문제를 어떻게 처리하는가, 또는 이때에 어떤 파라미터를 사용한 것인가에 대하여 기술한다. 또한 이 파라미터의 사용에 있어서 미세한 차이를 논의하여 이 실험 결과를 제시한다.

4.1. 교사 데이터의 선택

본 실험에서 제안한 시스템의 개략도를 그림 4에 나타낸다.




그림 4. 제안한 시스템

Fig. 4 Block diagram of proposed system.

먼저 최초 교사 데이터를 전혀 고려하지 않고 시물레이션을 실시한 경우, 입력이 직류일 때에는 그림 5와 같은 수속 결과를 보였지만, 그 이외의 입력(예를 들면 사인파)에 대해서는 다른 계수를 사용하여도 수속이 잘 되지 않았다. 이 이유를 생각하면, (1) 교사 데이터가 적절하지 않다. (2) 방법이 틀려있다. (3) 프로그램이 틀린다, 의 3가지를 생각할 수 있으나 이 경우에는 교사 데이터가 절절하지 않다고 생각되며, 이것을 개선하는 다음의 연구를 하였다. 먼저 제일 첫 번째로 교사데이터를 보다 완전하게 하기 위하여 처음에는 실제의 입력을 기본으로 한 출력을 교사 데이터로 하여, 이 출력이 안정되었을 때에 예측학습을 시키기로 하였다.




그림 5. 시물레이션 1

Fig. 5 Simulation 1.

이 경우에 이쪽이 출력이 안정된 때라고 생각하여 예측학습을 시작한 경우에도 좀처럼 학습을 하지 않

는 상태가 계속되었다 (그림 6). 이것은 학습초기의 상태로는 어느 쪽을 교사 데이터로써 사용하여도 전혀 학습이 되지 않기 때문이다. 그러나 이전의 다른 실험 보다 양호한 결과를 가져왔기 때문에 이 방법으로 실험을 실시하였다.




그림 6. 시뮬레이션 2
Fig. 6 Simulation 2.

이상의 결과를 낸 프로그램에 대한 학습법은 어떤 방법에 대해서도 동일한 것이며, 이 중에서 비선형 함수는 다음의 식과 같이 상한 및 하한의 부분을 제외한 아날로그적인 출력을 나타내고 있다.

$$sig(x) = \begin{cases} 0.9999 & x > 0.9999 \\ x & -0.9999 \leq x \leq 0.9999 \\ -0.9999 & x < -0.9999 \end{cases} \quad (9)$$

이 학습방법은 수정 모멘트법으로 불리우는 방법이며, 이 학습방법을 설명하면 다음과 같다.

- (1) 가중치 w_{ji}^n 를 작은 난수로 초기화한다. (2) 구 가중치 $o w_{ji}^n$ 를 0으로 초기화한다. (3) 일시적으로 가중치 $d w_{ji}^n$ 를 0으로 초기화한다. (4) 출력을 계산한다. (5) 델타 계산을 실시한다. (6) 델타 계산의 결과를 다음 식을 사용하여 일시적으로 가중치에 쌓아두고 스텝 4에 되돌아간다.

$$d w_{ji}^{n-1}(t+1) = d w_{ji}^{n-1}(t) + \alpha \delta_j^n(t) o_j^{n-1}(t) \quad (10)$$

(7) 어떤 횟수 마다(예를 들면 전 패턴에 대한 학습을 1회 실시할 때마다) 다음 식에 의해서 구 가중치 및 가중치의 갱신을 한다.

$$o w_{ji}^n(t+1) = m \times o w_{ji}^n(t) + (1.0 - m) \times d w_{ji}^n(t) \quad (11)$$

$$w_{ji}^n(t+1) = w_{ji}^n(t+1) + o w_{ji}^n(t+1) \quad (12)$$

(8) 모멘트 m 을 수정모멘트 dm 에 의해서 식 $m = m + dm$ 에 의하여 갱신한 후에 스텝3에 돌아간다.

이 방법을 사용한 이유는 통상의 학습방법으로는 값이 양수 및 음수로 변동하는 것과 같은 입력에 대해서 너무나 유연성이 없기 때문이다. 이 수정 모멘트법에서는 일정한 학습횟수 마다 모멘트를 증가시켜 학습을 실시하기 때문에 변동에 강하다.

4.2. 실험에 사용한 파라미터

본 실험에서는 경험적으로 다음과 같은 파라미터를 사용한다.

표 1. 실험에 사용한 파라미터
Table 1. Parameters used in the experiment.

α	0.0003
β	0.00006
가중치의 갱신을 하는 횟수	10,000

여기에서 β 는 문턱치를 갱신하기 위한 계수이다. 이 계수가 아주 크면 출력값은 상당히 커다란 값이 되어 버리며, 또한 아주 작으면 전혀 수속하지 않게 된다.

4.3. 실험 결과

본 절에서 기술한 실험 결과는 시뮬레이션 2의 방법 및 V.2절에서 기술한 계수를 사용하여 사인파에 대한 실험 결과이다. 이 실험 결과는 오차의 수속율로서 평가하며 이 결과를 그림 7에 나타낸다.




그림 7. 실험 결과
Fig. 7 Simulation result.

이 실험 결과를 보면 처음에서는 상당히 원래의 파형에 가까운 곳에 근접하고 이후에는 거의 변화하지 않는 것을 알 수 있다. 단지, 전절의 계수를 선택함에 있어서는 이러한 평가를 하지 않았고 어디까지나 오실로스코프 및 실제로 귀로 들어서 평가하였기 때문에, 객관적인 평가는 아니지만 목적으로 하는 파형에 수속하고 있는 것을 알 수 있다.

따라서 지금까지 연구된 방법과 본 논문에서 제안한 새로운 NN에 의한 방법(예를 들면, 제 II장에서 기술한 LMS 알고리즘)을 조합하여 사용한 경우가 효과적이라고 생각된다. 또한 이외에 선형왜곡, 비선형왜곡의 각각에 대하여 이것들을 제어하는 방법이 다수 제안되어 있기 때문에, 여러 가지로 다른 방법으로 시험해보는 것도 좋은 방법이라고 생각한다. 또한 본 실험과 같은 선형예측을 하는 뉴런 모델을 사용한 알고리즘뿐만 아니라 본래의 비선형 특성을 가진 NN에 의한 방법을 병용하는 것도 하나의 방법으로 생각되어진다.

이와 같이 본 실험에서 구해진 결과를 이용하여 향후 더욱 연구의 방법을 개량함으로써 소정의 목적을 달성할 수 있다고 생각한다.

VI. 결 론

본 논문에서는 어떤 음원으로부터 나온 음과 동일한 음을 들을 수 있는 시스템을 구축하는 것을 목적으로 하여, 두 개의 음으로부터 전달되어온 음장의 상태를 구하여 이 역 필터를 구성하는 방법을 연구하였다. 따라서 본 논문에서는 네트워크 자체를 필터로 생각하여 LMS법의 일부분을 신경회로망에 대처하는 방법을 제안하였다. 또한 비선형 왜곡이 있는 간단한 파형이 제안한 신경회로망에 의하여 학습 가능한 것을 실험 결과로부터 확인할 수 있었다.

향후의 연구과제로서는 보다 파라미터를 상세하게 나누고 객관적인 실험을 하여, 외부로부터 스피커의 출력보다 큰 잡음이 혼입한 경우에도 네트워크의 수속율을 높이는 연구도 필요하다. 또한 신경회로망의 입력의 수를 변경했을 때의 효과도 검토해야 하며, 사인파와 같은 간단한 파형뿐만 아니라 더욱 다양한 파형에도 대응하는 것이 필요하다고 본다.

따라서 본 실험의 최종적인 목적은 어떤 입력에 대해서도 그것과 동일한 파형을 출력하기 위한 NN을 학습시켜 이것을 청각실험에 응용하는 것이었다. 이것을 위하여 상기와 같은 문제점을 해결할 뿐만 아니라 중심적인 처리를 실시하는 DSP의 고속화도 필요하며, 청각의 실험을 위해서는 인공귀에 의한 집음도 필요하다. 본 연구를 더욱더 발전시킴으로써 청각실험에 도움이 된다고 기대한다.

참고 문헌

- [1] Y. Matsuyama, R. Gray, "Voice Coding and Tree Encoding Speech Compression Systems Based Upon Inverse Filter Matching", IEEE Transactions on Communications, Vol. Com-30, No. 4, April 1982.
- [2] S. R. Powell, P. M. Chau, "Time reversed filtering in real-time", IEEE International Symposium on Circuits and Systems, Vol. 2, pp.1239-1243, May 1990.
- [3] A. Mahmoodzadeh, H. R. Abutalebi, H. Agahi, "Speech enhancement using a Kalman-based normalized LMS algorithm", International Symposium on Telecommunications, pp.555-558, Aug. 2008.
- [4] W. Bobillet, E. Grivel, R. Guidorzi, M. Najim, "Cancelling convolutive and additive coloured noises for speech enhancement", IEEE International Conference on Acoustics, Speech, and Signal Processing, Vol. 2, pp.11- 777-780, May 2004.
- [5] A. V. Ooyen and B. Nienhuis, "Improving the convergence of the back-propagation algorithm", Neural Networks, Vol. 5, No. 3, pp. 465-471, 1992.
- [6] W. G. Knecht, M. E. Schenkel, and G. S. Moschytz, "Neural network filters for speech enhancement", IEEE Trans. Speech and Audio Processing, Vol. 3, No. 6, pp.433-438, 1995.
- [7] S. Tamura, "An analysis of a noise reduction neural network", IEEE International Conference on Acoustics, Speech, and Signal Processing. Vol. 89, No. 3, pp.2001-2004, 1989.
- [8] M. R. Sambur, "Adaptive noise cancelling for speech signals", IEEE Transactions on Aco-

ustics, Speech, and Signal Processing, Vol. 26,
No. 5, pp.419-423, 1978.

저자 소개



최재승(Jae-seung Choi)

1989년 조선대 전자공학과 졸업
(공학사)

1995년 일본 오사카시립대학 전자
정보공학부 졸업 (공학석사)

1999년 일본 오사카시립대학 전자정보공학부 졸업
(공학박사)

2000년~2001년 일본 마쯔시타 전기산업주식회사
AVC사 연구원

2002년~2007년 경북대 디지털기술연구소 책임연구원

2007년~현재 : 신라대학교 전자공학과 교수

※ 주 관심분야 : 음성신호처리, 신경회로망, 적응필
터와 잡음제거, 디지털 TV 및 멀티미디어 등