

---

# 신경회로망에 의한 역 필터링 기법

최재승\*

\*신라대학교

## Reverse Filtering Method by Neural Network

Jae-seung Choi\*

\*Silla University

E-mail : jschoi@silla.ac.kr

### 요 약

본 논문에서는 음원으로부터 나온 음과 동일한 음을 들을 수 있는 시스템을 구축하는 것을 목적으로 하여 이 두 개의 음으로부터 전달되어온 음장의 상태를 구하여 이 역 필터를 구성하는 방법을 연구한다. 본 논문에서는 최소 2승 평균법(Least Mean Square, LMS)을 사용하여 FIR 필터(Finite Impulse Response)의 계수를 계산하여 이를 갱신함으로써 역 필터법을 구축하는 방법을 사용한다. 또한 이 방법과는 별도로 LMS법의 부분을 신경회로망에 대처하는 알고리즘을 제안하였다. 시뮬레이션 실험으로부터 상당히 간단한 파형에 비선형인 왜곡이 있는 것을 본 논문에서 제안한 신경회로망에 의한 학습 가능한 것을 확인하였다.

### 키워드

Reverse filtering, adaptive filter, neural network, least mean square.

### I. 서 론

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 음으로부터 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) [1]을 사용하여 FIR(Finite Impulse Response) 필터 [2]의 계수를 계산하여 이를 갱신함으로써 역 필터법을 구축하는 방법을 사용한다. 또한 이 방법과는 별도로 오

차역전파(Back Propagation, BP) 알고리즘 [3]에 의한 신경회로망(Neural Network, NN) [4, 5]을 사용한다. 신경회로망은 비선형함수의 학습의 효과를 가지기 때문에 종래의 방법으로는 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 파형이 학습 가능한 것을 실험 결과로부터 확인할 수 있었다.

## II. 음장의 역 필터링의 이론

음장의 역 필터링은 미지의 시스템의 전달함수의 역함수를 구하는 문제이다. 이 미지의 시스템의 전달함수의 역함수를 구하는 모델링에는 적응필터(Adaptive filter) [6]를 사용하는 경우가 많다. 역 필터링의 개념을 그림 1에 나타낸다. 먼저 미지의 시스템의 출력을 적응필터에 입력한다. 미지 시스템에의 입력을  $\delta$ (그림에서는 1 표본 시간으로 되어 있지만, 일반적으로는 미지의 시스템과 적응필터를 통과할 때의 지연시간)만큼 지연시킨 것이 적응필터의 응답의 목표값이다. 여기에서는 설명을 간단히 하기 위하여 지연이 없는 것( $\delta=0$ )으로 가정한다. 오차를 최소화하기 위해서는 적응필터가 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  $\varepsilon$ 을 최소화하도록 적응 필터를 학습시키면 된다. 이 때에 적응 필터에는 미지 시스템의 역 함수가 생성된다.




그림 1. 역 모델링

## III. 신경회로망

계층형 신경회로망의 학습방법은 1986년에 Rumelhart [7] 등에 의해서 발표된 오차역전파 알고리즘(Back Propagation Algorithm, BP) [3]이 일반적으로 사용되고 있다. 이 학습법은 일반화 델타법으로도 불리우고 있는 방법이다.

본 실험에 사용한 신경회로망은 중간층을 한 개 가진 3층 신경회로망이며, 학습법은 BP법을 사용하였으며 학습의 순서는 다음과 같다. (1) 가중치를 초기화한다. (2) 미지의 시스템 및 NN에 의한 지연시간  $\delta$  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.

## IV. 역 필터링의 실험 방법

본 장에서는 본 실험에서 사용하는 역 필터 실험의 방법과 알고리즘에 대해서 기술한다. 본 실험에 사용한 역 필터링 시스템의 간략도는 그림 2와 같다.

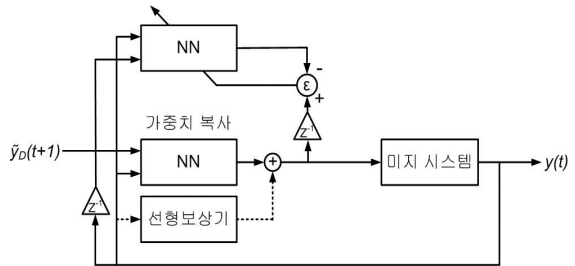


그림 2. 실험에 사용한 시스템 개략도

그림 2의 시스템에서는 이 지연시간으로부터 2개 이상 전의 출력을 신경회로망에의 입력으로써 학습을 실시하여 다음 출력을 예측하고 있다.

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

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

$$y(t) = h(x(t)) \dots\dots (2)$$

여기에서  $x(t) \in \mathbb{R}^n$ ,  $y(t) \in \mathbb{R}$ ,  $u(t) \in \mathbb{R}$ 는 각각 시간 t에서의 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

$$\frac{\partial h(f(x, u))}{\partial u} \neq 0 \dots\dots (3)$$

이 성립된다고 가정한다. 또한 식 (9)와 식 (10)은 비선형 최소 위상계이다.

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

때문에, 시각  $t$ 에 있어서  $y_D(t+1)$ 이 필요하다. 식 (3)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 역 사상이 존재한다.

$$u(t) = \alpha(x(t), y(t+1)) \dots\dots (4)$$

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

$$y(t+1) = h(\alpha(x(t), \tilde{y}_D(t+1))) \dots\dots (5)$$

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 보상기를 붙여서 실시할 필요가 있다.

또한 relative order가 1인 가정으로부터  $y_D(t+1)$ 이 필요하게 되지만, 1보다도 큰 경우에는 더욱이 미래의 희망출력이 필요로 하는 경우도 고려할 필요가 있다.

### V. 실험 결과

본 실험에서 제안한 시스템의 개략도를 그림 3에 나타낸다.




그림 3. 제안한 시스템

먼저 최초 교사 데이터를 전혀 고려하지 않고 시뮬레이션을 실시한 경우, 입력이 직류일 때에는 그림 4와 같은 수속 결과를 보였지만, 그 이외의 입력(예를 들면 사인파)에 대해서는 다른 계수를 사용하여도 수속이 잘 되지 않았다. 이 이유를 생각하면, (1) 교사데이터가 적절하지 않다. (2) 방법이 틀려있다. (3) 프로그램이 틀린다, 의 3가지를

생각할 수 있으나 이 경우에는 교사 데이터가 적절하지 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 4. 시뮬레이션

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

$$sig(x) = \begin{cases} 0.9999 & x > 0.9999 \\ x & -0.9999 \leq x \leq 0.9999 \\ -0.9999 & x < -0.9999 \end{cases} \quad (6)$$

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

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

$$dw_{ji}^{n-1}(t+1) = dw_{ji}^{n-1}(t) + \alpha \delta_j^n(t) o_j^{n-1}(t) \quad (7)$$

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

$$ow_{ji}^n(t+1) = m \times ow_{ji}^n(t) + (1.0 - m) \times dw_{ji}^n(t) \quad (8)$$

$$w_{ji}^n(t+1) = w_{ji}^n(t+1) + ow_{ji}^n(t+1) \quad (9)$$

8. 모멘트  $m$ 을 수정 모멘트  $dm$ 에 의해서 식  $m = m + dm$ 에 의하여 갱신한 후에 스텝 3에 되돌아 간다.

본 실험에서는 경험적으로 다음과 같은 파라미터를 사용한다.

표 1. 실험에 사용한 파라미터

$\alpha$	0.0003
$\beta$	0.00006
가중치의 갱신을 하는 횟수	10,000

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

본 절에서 기술한 실험 결과는 V.2절에서 기술한 계수를 사용하여 사인파만에 대한 실험 결과이다. 이 실험 결과는 오차의 수속율로서 평가하며 이 결과를 그림 5에 나타낸다.




그림 5. 실험 결과

이 실험 결과를 보면 처음에서는 상당히 원래의 파형에 가까운 곳에 근접하고 이후에는 거의 변화하지 않는 것을 알 수 있다. 단지, 전질의 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.

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

## VI. 결론

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.

## 참고 문헌

- [1] 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.
- [2] 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. II- 777-780, May 2004.
- [3] A. V. Ooyen and B. Nienhuis, "Improving the convergence of the back-propagation algorithm", Neural Networks, Vol. 5, No. 3, pp. 465-471, 1992.
- [4] 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.
- [5] 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.
- [6] B. Widrow, R. John, J. R. Glover, J. M. McCool, J. Kaunitz, C. S. Williams, R. H. Hearn, J. R. Zeidler, E. Dong, R. C. Goodlin, "Adaptive noise cancelling: Principles and applications", Proc. IEEE, Vol. 63, No. 12, pp. 1692-1716, 1975.
- [7] D. Rumelhart, "Parallel Distributed Processing, vol. 1 and 2, MIT Press, Cambridge, MA, 1986.