

심층학습 알고리즘을 이용한 보청기의 음향궤환 및 잡음 제거

이행우*

Acoustic Feedback and Noise Cancellation of Hearing Aids by Deep Learning Algorithm

Haeng-Woo Lee*

요약

본 논문에서는 보청기의 음향궤환 및 잡음을 제거하기 위한 새로운 알고리즘을 제안한다. 이 알고리즘은 기존의 FIR 구조를 이용하는 대신 신경망 적응예측필터를 이용한 심층학습 알고리즘으로 궤환 및 잡음제거 성능을 향상시킨다. 먼저 궤환제거기가 마이크 신호에서 궤환신호를 제거하고, 이어서 Wiener 필터기법을 이용하여 잡음을 제거한다. 잡음 제거는 음성신호가 가진 주기적 성질에 따라 선형예측모델을 이용하여 잡음이 포함된 음성신호로부터 음성을 추정해내는 것이다. 한 루프 안에 포함된 두 적응 시스템의 안정적 수렴을 보장하기 위해 궤환제거기 및 잡음제거기의 계수 업데이트를 분리하여 실시하며 제거 후 생성된 잔차신호를 이용하여 수렴시키는 과정을 진행한다. 본 연구에서 제안한 궤환 및 잡음제거기의 성능을 검증하기 위하여 시뮬레이션 프로그램을 작성하고 모의실험을 수행하였다. 실험 결과, 제안한 심층학습 알고리즘을 사용하면 기존의 FIR 구조를 사용하는 경우보다 궤환제거기에서 약 10 dB의 SFR(: Signal to Feedback Ratio), 잡음제거기에서 약 3 dB의 SNRE(: Signal to Noise Ratio Enhancement) 개선효과를 얻을 수 있는 것으로 확인되었다.

ABSTRACT

In this paper, we propose a new algorithm to remove acoustic feedback and noise in hearing aids. Instead of using the conventional FIR structure, this algorithm is a deep learning algorithm using neural network adaptive prediction filter to improve the feedback and noise reduction performance. The feedback canceller first removes the feedback signal from the microphone signal and then removes the noise using the Wiener filter technique. Noise elimination is to estimate the speech from the speech signal containing noise using the linear prediction model according to the periodicity of the speech signal. In order to ensure stable convergence of two adaptive systems in a loop, coefficient updates of the feedback canceller and noise canceller are separated and converged using the residual error signal generated after the cancellation. In order to verify the performance of the feedback and noise canceller proposed in this study, a simulation program was written and simulated. Experimental results show that the proposed deep learning algorithm improves the signal to feedback ratio(: SFR) of about 10 dB in the feedback canceller and the signal to noise ratio enhancement(: SNRE) of about 3 dB in the noise canceller than the conventional FIR structure.

키워드

Hearing Aids, Acoustic Feedback, Noise Reduction, Deep Learning, Neural Network
보청기, 음향 궤환, 잡음 제거, 심층 학습, 신경망

* 교신저자: 남서울대학교 정보통신공학과
• 접수일 : 2019. 10. 01
• 수정완료일 : 2019. 11. 07
• 게재확정일 : 2019. 12. 15

• Received : Oct. 01, 2019, Revised : Nov. 07, 2019, Accepted : Dec. 15, 2019
• Corresponding Author : Haeng-Woo Lee
Dept. of Information Communication, Namseoul University,
Email : hwlee@nsu.ac.kr

I. 서론

난청환자의 청각손실은 인간의 음성이 부분적으로 차단되는 것을 의미한다. 이러한 난청환자에게 청각손실을 보상해주는 디지털 보청기가 국가보조금이 지원되기 시작하면서 최근에 많이 보급되고 있다. 반도체 및 DSP 기술의 발달에 의해 개발된 디지털 보청기는 아날로그 신호를 디지털 신호로 변환한 후, 각 음색의 최적 파라미터 값을 효율적으로 적용하여 보청기의 기능을 매우 정밀하게 제어할 수 있다. 즉 각 환자의 청각특성에 따라 주파수 대역별로 이득조정을 달리 함으로서 보다 정확하게 청각손실을 보정해줄 수 있다.

디지털 보청기를 사용함에 있어 청력손실뿐만 아니라 잡음 및 음향궤환(acoustic feedback) 신호가 보청기 사용자들에게 불쾌감을 주고 음성인식을 어렵게하는 요인이 되고 있다. 음향궤환은 보청기 외벽과 귀 사이의 좁은 틈(vent)을 통하여 리시버 신호의 일부가 마이크로 궤환되는 신호이다[1]. 이 신호는 감쇠가 적은 공진 주파수에 해당하는 신호가 증폭기에 의해 공진함으로서 귀에 거슬리는 소리를 발생한다. 일반적으로 궤환신호는 궤환경로를 통과하면서 40~50 dB 정도 감쇠되지만, 7 kHz 부근의 주파수 영역에서는 감쇠가 20 dB 정도로 적은 반면, 보청기에 필요한 증폭이득은 15~50 dB가 요구된다. 따라서 이 주파수 영역에서 궤환되는 음향신호는 입력신호와 비슷한 크기가 되어 쉽게 공진이 발생하게 된다[2].

이와 같이 보청기의 성능을 저하시키는 문제를 해결하기 위하여 음향 궤환경로를 적응적으로 추정하여 궤환성분을 제거하는 적응 궤환제거기가 사용되고 있다[3-5]. 이러한 방법은 보청기 사용자에게 음향신호를 전달함과 동시에 연속적으로 적응필터 계수를 갱신하는 것으로, 잔차신호에 보청기 입력신호가 포함되어 궤환신호를 제거하는데 장애물로 작용하게 된다. 즉 적응필터는 리시버 출력신호에 따라 궤환경로를 추정하여 궤환신호 성분을 제거하게 되는데, 잔차신호에 입력신호가 존재하면 적응필터가 궤환경로를 추정하는데 어려움이 있다. 또한 보청기의

마이크로 유입되는 신호는 주변 잡음신호가 포함되며, 증폭기에서 음성신호와 함께 증폭되어 음질을 저하시키고 궤환제거기의 수렴을 방해하게 된다. 따라서 보청기 시스템은 궤환신호뿐만 아니라 잡음의 제거기능도 필요로 한다[6].

딥러닝은 신경망을 기반으로 많은 수의 은닉층을 사용하는 복잡도가 큰 머신러닝 모델이다. 최근 딥러닝 모델이 여러 분야에서 큰 성과를 내고 있는 것은 많은 수의 층으로 구성된 다층 신경망을 학습할 수 있는 기술이 개발되었기 때문이다. 다층망을 학습시키는 오류 역전파(back propagation) 알고리즘이 상위층을 학습하기 전에 먼저 하위층의 시냅스(synapse)를 미리 학습 시킴으로서 많은 수의 층을 쓰는 딥네트워크도 학습이 가능하게 되었다. 현재 가장 많이 사용되는 딥러닝 모델은 Convolutional Neural Network(: CNN)[7-8]이다. 본 연구에서는 신경망 필터의 심층학습(deep learning) 알고리즘을 이용하여 궤환 및 잡음신호를 제거하는 방법을 제안하고, 컴퓨터 시뮬레이션을 통하여 궤환 및 잡음제거 성능을 평가하였다.

논문의 내용은 II절에서 다층 신경망의 학습알고리즘을 살펴보고, III절에서는 CNN 신경망 필터구조의 새로운 궤환 및 잡음제거 알고리즘을 제안하였다. IV절에서는 이 알고리즘에 대한 시뮬레이션 및 그 결과에 대하여 기술하였으며, 끝으로 V절에서 결론을 도출하였다.

II. 다층 신경망의 학습 알고리즘

다층 퍼셉트론(multi-layer perceptron)은 한 개 이상의 은닉층(hidden layer)을 가지는 다층 전방향 신경망의 구조를 가지고 있다. 그림 1은 l 개의 입력 뉴런(neuron)을 가지는 입력층, m 개의 은닉 뉴런을 가지는 은닉층, n 개의 출력 뉴런을 가지는 출력층으로 구성된 다층 퍼셉트론을 나타낸다. 다층 퍼셉트론의 입력 뉴런의 값은 l 차원 벡터 $x = [x_1, x_2, \dots, x_i, \dots, x_l]$ 로 나타내고, 은닉 뉴런의 값은 m 차원 벡터 $a^1 = [a_1^1, a_2^1, \dots, a_j^1, \dots, a_m^1]$ 로 나타내며, 출력 뉴

런의 값은 n 차원 벡터 $a^2 = [a_1^2, a_2^2, \dots, a_k^2, \dots, a_n^2]$ 로 표현한다. 그리고 입력층과 은닉층 사이의 가중치(weight)를 w_{ij}^1 , 바이어스(bias)를 b_j^1 로 나타내고, 은닉층과 출력층 사이의 가중치를 w_{jk}^2 , 바이어스를 b_k^2 로 나타낸다. 또한, j 번째 은닉 뉴런으로 입력되는 가중합을 u_j^h , k 번째 출력 뉴런으로 입력되는 가중합을 u_k^o 라 하고, 은닉 뉴런의 활성화함수는 ϕ_h , 출력 뉴런의 활성화 함수는 ϕ_o 로 표현한다.




그림 1. 다층 신경망 구조
Fig. 1 Multi-layer neural network

그러면 은닉 뉴런과 출력 뉴런의 출력값은 식(1), 식(2)로 나타낼 수 있다.

$$a_j^1 = \phi(u_j^h) = \phi_h\left(\sum_{i=1}^l w_{ij}^1 x_i + b_j^1\right) \quad (1)$$

$$a_k^2 = \phi(u_k^o) = \phi_o\left(\sum_{j=1}^m w_{jk}^2 a_j^1 + b_k^2\right) \quad (2)$$

모든 가중치와 바이어스를 하나의 파라미터로 나타내면 입력 x 가 주어졌을 때 k 번째 출력 뉴런의 값을 함수 $f_k(x, \theta)$ 로 나타내면 식(3)과 같이 표현된다.

$$f_k(x, \theta) = a_k^2 \quad (3)$$

$$= \phi_o\left(\sum_{j=1}^m w_{jk}^2 \phi_h\left(\sum_{i=1}^l w_{ij}^1 x_i + b_j^1\right) + b_k^2\right)$$

역전파 학습알고리즘은 다층 퍼셉트론을 학습

시킬 수 있는 알고리즘으로 1980년대 중반 David Rumelhart, Geoffrey Hinton 및 Ronald Williams, David Parker, 그리고 Yann LeCun 등에 의하여 개발되었다[9]. 다층 퍼셉트론의 지도학습은 학습목표 출력값이 주어지고 다층 퍼셉트론에 의해 출력되는 값의 차이를 이용한 오차함수가 정의되어야 한다. 학습데이터와 목표 출력값이 입출력의 순서쌍 $(x_i, t_i)(i = 1, \dots, N)$ 으로 주어졌을 때 학습 데이터 전체 X 에 대한 오차는 식(4)와 같이 평균제곱오차로 정의할 수 있다.

$$E(X, \theta) = \frac{1}{2N} \sum_{i=1}^N \|t_i - f(x_i, \theta)\|^2 \quad (4)$$

위 식에서 오차함수 $E(X, \theta)$ 는 데이터 집합 X 와 파라미터 θ 가 주어지면 하나의 값으로 정해지는데 데이터 집합 X 는 외부에서 주어지는 값이고 최적화해야 하는 대상은 θ 이므로 일반적으로 $E(\theta)$ 로 나타낼 수 있다. 역전파 학습 알고리즘은 오차함수 $E(\theta)$ 를 최소화하기 위한 파라미터를 찾기 위해 경사하강법(gradient descent method)을 사용한다. 경사하강법은 어떤 비용함수의 값을 최소화시키는 파라미터를 반복적 탐색으로 찾는 알고리즘으로 식(5)로 표현된다.

$$\theta(t+1) = \theta(t) + \Delta\theta(t) \quad (5)$$

$$= \theta(t) - \eta \frac{\partial E(\theta)}{\partial \theta}$$

여기서 η 는 학습의 속도를 조절하는 학습률(learning rate)이다. 다층 퍼셉트론에서 역전파 학습은 각 가중치마다 하나의 데이터를 사용하여 업데이트하는 확률(stochastic) 경사하강법을 적용하면 하나의 데이터에 대한 오차함수 $E(x, \theta)$ 를 사용한다.

$$E(x, \theta) = \frac{1}{2} (t_k - a_k^2)^2 \quad (6)$$

$$= \frac{1}{2} \left(t_k - \phi_o\left(\sum_{j=1}^m w_{jk}^2 a_j^1 + b_k^2\right) \right)^2$$

위 식에서 학습을 통해 수정해주어야 하는 파라미터는 은닉층과 출력층 사이의 가중치 w_{jk}^2 와

바이어스 b_k^2 , 그리고 입력층과 은닉층 사이의 가중치 w_{ij}^1 와 바이어스 b_j^1 이다. 따라서 오차함수를 출력층 파라미터로 편미분하면 식(7), 식(8)과 같다.

$$\frac{\partial E}{\partial w_{jk}^2} = \frac{\partial E}{\partial u_k^o} \frac{\partial u_k^o}{\partial w_{jk}^2} \quad (7)$$

$$= -\phi_o'(u_k^o)(t_k - a_k^2)a_j^1 = \delta_k a_j^1$$

$$\frac{\partial E}{\partial b_k^2} = \frac{\partial E}{\partial u_k^o} \frac{\partial u_k^o}{\partial b_k^2} \quad (8)$$

$$= -\phi_o'(u_k^o)(t_k - a_k^2) = \delta_k$$

여기서 $\phi_o'(u_k^o)$ 는 출력 뉴런의 활성화 함수의 미분값이며 일반적으로 ReLU 함수 ($\max\{0, u_k^o\}$)가 많이 사용되므로 단위계단함수인 $\phi_o'(u_k^o) = u(t)$ 이다. 그리고 δ_k 는 출력 뉴런이 오차에 미치는 영향이다. 이어서 오차함수를 입력층 파라미터로 편미분하면 식(9), 식(10)과 같다.

$$\frac{\partial E}{\partial w_{ij}^1} = \frac{\partial E}{\partial u_j^h} \frac{\partial u_j^h}{\partial w_{ij}^1} \quad (9)$$

$$= \phi_h'(u_j^h) \sum_{j=1}^m w_{jk}^2 \delta_k x_i = \delta_j x_i$$

$$\frac{\partial E}{\partial b_j^1} = \frac{\partial E}{\partial u_j^h} \frac{\partial u_j^h}{\partial b_j^1} \quad (10)$$

$$= \phi_h'(u_j^h) \sum_{j=1}^m w_{jk}^2 \delta_k = \delta_j$$

종합해보면 입력층과 은닉층 사이의 파라미터는 은닉층과 출력층 사이의 가중치와 각각의 출력 뉴런이 오차에 미치는 영향인 δ_k 를 곱하여 합한 값에 영향을 받는 것을 알 수 있다. 이처럼 출력 뉴런의 오차가 은닉 뉴런에 거꾸로 전파되어 은닉 뉴런의 파라미터 조절에 영향을 미치기 때문에 다층 퍼셉트론의 경사하강 학습법을 오류 역전파(Error back propagation) 학습 알고리즘[10]이라고 명명하게 되었고 최종적으로 각 파라미터는 식(11) - (14)에 의해 업데이트된다.

$$w_{jk}^2(t+1) = w_{jk}^2(t) + \eta \phi_o'(u_k^o)(t_k - a_k^2)a_j^1 \quad (11)$$

$$b_k^2(t+1) = b_k^2(t) + \eta \phi_o'(u_k^o)(t_k - a_k^2) \quad (12)$$

$$w_{ij}^1(t+1) = w_{ij}^1(t) - \eta \phi_h'(u_j^h) \sum_{j=1}^m w_{jk}^2 \delta_k x_i \quad (13)$$

$$b_j^1(t+1) = b_j^1(t) - \eta \phi_h'(u_j^h) \sum_{j=1}^m w_{jk}^2 \delta_k \quad (14)$$

III. 신경망 필터구조의 제한 및 잡음 제거 알고리즘

마이크를 통해서 유입된 음향은 음성 및 잡음 뿐만 아니라 케환신호도 포함하고 있으며 ADC에 의해 디지털 신호로 변환된다. 리시버에서 증폭된 음성출력은 귀 내부와 외부의 공기압을 조절해주는 통풍구 또는 보청기 외벽과 귀 사이의 좁은 틈을 통하여 외부로 유출되고, 이 신호가 다시 마이크를 통하여 유입됨으로서 음향케환이 발생하게 된다. 통풍구의 주파수 특성에 있어서 감쇠가 적은 공진 주파수에 해당하는 신호가 증폭기에 의해 공진함으로서 귀에 거슬리는 소리를 낸다. 즉 케환신호의 주파수 성분이 입력 음향신호와 동위상이고 크기가 같거나 크면 공진이 발생하게 된다. 원활한 음성청취를 위해서는 입력된 디지털 신호에서 음성을 제외한 케환 및 잡음신호는 적절히 제거되어야 한다. 그리고 출력신호는 약 40 dB 증폭된 후 DAC에 의해 다시 아날로그 신호로 변환되어 리시버를 통해 출력된다. 그림 2는 일반적인 케환 및 잡음제거 시스템의 구조를 보여주고 있다.

케환제거기는 리시버에서 마이크에 이르는 음향 케환경로를 특성화하여 리시버신호에 의한 케환신호의 복제를 구하고, 이를 마이크 출력신호로부터 감산함으로서 음향케환효과를 제거할 수 있다. 케환경로의 특성은 시간 및 주위환경, 즉 귓속 내부공간의 크기나 형태, 보청기와 피부 접촉면의 상태, 리시버와 마이크의 상대적 위치, 또는 음의 크기 등에 따라 다양하게 나타나기 때문에 케환제거기는 적응적으로 동작하는 구조를 갖게 된다. 리시버신호에 의한 케환신호의 경로는 샘플된 임펄스응답의 선형 시스템으로 모

델팅되므로 마이크로 입력되는 궤환신호는 적응 FIR 필터를 사용하여 제거할 수 있다.




그림 2. 궤환 및 잡음제거 시스템
Fig. 2 Feedback and noise cancellation system

또한 보청기 시스템은 궤환신호의 제거뿐만 아니라 잡음도 제거해야 한다. 그림 3은 음성신호의 준주기적 특성을 이용하여 선형예측방법으로 1-샘플 지연된 신호들로부터 현재 음성을 예측하는 기존의 단일입력 적응 잡음제거시스템이다. 한 두 피치 지연된 입력신호는 음성신호 성분과는 높은 상관관계를 갖고 잡음 성분과는 매우 낮은 상관관계를 가진다. 여기서 음성신호는 잡음과 아무 상관관계가 없으며 최소자승오차를 갖도록 수렴해나간다.




그림 3. 적응 잡음제거시스템
Fig. 3 Adaptive noise reduction system

마이크 입력신호는 궤환제거기에서 만들어진 궤환복제신호가 차감되어 잔차신호가 된다. 이 잔차신호는 궤환제거기의 필터 계수값을 갱신하는 기준신호로 사용된다. 그러나 잔차신호는 대담자의 음성을 포함하고 있어 적응필터가 수렴하는데 장애요인으로 작용한다. 입력음성과 궤환

신호는 상호상관도가 높기 때문에 필터 계수의 수렴속도가 현저하게 저하된다. 따라서 본 논문에서는 이를 해결하기 위해 그림 4와 같이 커널폭이 4인 신경망 필터를 사용하며 인접한 뉴런의 입력 데이터들이 중첩되어 구성된다.

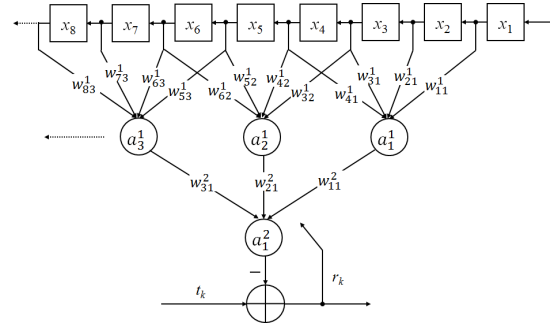


그림 4. 신경망 필터구조의 음향캐환제거기
Fig. 4 Feedback canceller by neural network filter

편의상 바이어스는 제로라 가정하고 활성화함수로 많이 사용되는 ReLU(Rectified Linear Unit)를 이용하면 각 레이어의 출력은 식(15), 식(16)과 같다.

$$a_j^1 = \phi_{ReLU}(u_j^h) = \begin{cases} \sum_{i=1}^l w_{ij}^1 x_i & \text{for } u_j^h > 0 \\ 0 & \text{otherwise} \end{cases} \quad (15)$$

$$a_k^2 = \phi_{ReLU}(u_k^o) = \begin{cases} \sum_{j=1}^m w_{jk}^2 a_j^1 & \text{for } u_k^o > 0 \\ 0 & \text{otherwise} \end{cases} \quad (16)$$

목표값 대비 출력뉴런의 오차값은 $r_k = t_k - a_k^2$ 이고, 활성화함수의 미분값은 $u > 0$ 일 때 $\phi'(u) = 1$ 이다. NLMS(: Normalized Least Mean Square) 알고리즘을 이용하면 각 레이어의 가중치는 $u > 0$ 인 경우에 식(17), 식(18)과 같이 업데이트된다.

$$w_{jk}^2(t+1) = w_{jk}^2(t) + \eta r_k \frac{a_j^1}{E\{a_m^1\}} \quad (17)$$

$$w_{ij}^1(t+1) = w_{ij}^1(t) + \eta r_k \frac{x_i}{E\{x_l\}} \sum_{j=1}^m w_{jk}^2 \quad (18)$$

IV. 모의실험 및 분석

본 논문에서 제안한 음향케환 및 잡음제거 시스템의 성능을 검증하기 위해 Python을 이용하여 시뮬레이션 프로그램을 작성하였다. 입력신호는 8kHz로 샘플링되며, 실험에 사용된 케환제거기와 잡음제거기는 각각 64-tap, 32-tap 신경망 필터구조로서 가중치의 갱신 스텝의 크기는 $\eta = 0.0005$ 으로 설정하였다. 그리고 성능평가지수는 각각 이동평균 신호대케환비(SFR: Signal to Feedback Ratio) 및 이동평균 신호대잡음비(SNRE: Signal to Noise Ratio Enhancement)를 사용하였다.

$$SFR(k) = 10 \log \frac{E\{s^2(k)\}}{E\{(f(k) - \hat{f}(k))^2\}} \quad (19)$$

$$SNR_I(k) = 10 \log \frac{E\{s^2(k)\}}{E\{n^2(k)\}} \quad (20)$$

$$SNR_O(k) = 10 \log \frac{E\{s^2(k-D)\}}{E\{(b(k) - s(k-D))^2\}} \quad (21)$$

$$SNRE(k) = SNR_O(k) - SNR_I(k) \quad (22)$$

평균값은 $E\{x(k)\} = (1-\lambda)E\{x(k-1)\} + \lambda x(k)$ 와 같이 이동평균으로 계산되며 $\lambda \approx 0.015$ 의 상수값을 갖는다. 기존의 적응필터 구조와 제안한 알고리즘의 SFR 및 SNRE 개선특성을 그림 5, 6에서 비교하였다. 그림 5의 곡선은 케환제거기의 SFR을 나타내고, 그림 6의 곡선은 잡음제거기의 SNRE 개선특성을 나타낸다.




그림 5. 케환제거기의 SFR 특성
Fig. 5 SFR of feedback canceller

그림 5는 음향케환 및 잡음제거기에서 케환제거기의 SFR 결과를 나타내는데 기존의 FIR 구조로 구현하였을 경우(F)와 새로운 신경망 구조로 구현하였을 경우(N)를 비교하였다. 초기 60,000 샘플까지는 계수의 수렴을 위해 훈련모드로 동작하고 이후에는 정상모드로 동작한다. 훈련모드에서 신경망 구조는 FIR 구조보다 더 우수한 수렴 성능을 나타내며 정상모드에서도 신경망 구조는 FIR 구조보다 10 dB 이상 개선된 SFR 성능을 보여주고 있다.




그림 6. 잡음제거기의 SNRE 개선특성
Fig. 6 SNRE of noise canceller

그리고 그림 6은 음향케환 및 잡음제거기에서 잡음제거기의 SNRE 결과를 나타내는데 기존의 FIR 구조로 구현하였을 경우(F)와 새로운 신경망 구조로 구현하였을 경우(N)를 비교하였다. 여기서 신호대잡음비 개선을 나타내는 SNRE는 입력신호의 신호대잡음비 SNR_I와 출력신호의 신호대잡음비 SNR_O의 차이이다. 마찬가지로 잡음제거기도 초기 60,000 샘플까지는 훈련모드로 동작하고 이후에는 정상모드로 동작한다. 이 그림으로부터 훈련모드에서는 신경망 구조가 FIR 구조보다 명확하게 우수한 수렴 성능을 나타낼 수 있으나 정상모드에서는 신경망 구조도 FIR 구조보다 개선정도가 미미함을 알 수 있다. 이는 전단에 있는 케환제거기의 영향을 받아 잡음제거기의 성능이 떨어지는 것으로 판단된다. 그림에도 불구하고 신경망 구조의 SNRE가 약 3 dB 개선된 것을 볼 수 있다.

V. 결 론

최근 고령화 사회로 진입하면서 보청기의 수요가 점차 증대되고 있어 성능이 우수한 케환 및 잡음제거기의 개발이 요구되고 있다. 본 논문에서는 보청기의 케환 및 잡음제거기의 수렴특성을 향상시키기 위한 새로운 적응 알고리즘을 제안하였다. 이 알고리즘은 기존의 FIR 구조를 이용하는 대신 신경망 구조를 이용한 심층학습 알고리즘으로 케환 및 잡음제거 성능을 향상시킨다.

케환제거기는 64-tap 신경망 적응예측필터로서 심층학습 역전파 알고리즘을 사용하고, 잡음제거기는 32-tap 신경망 Wiener 필터구조로서 딥러닝 기법을 사용하였다. 보청기를 수렴시키는 과정은 케환제거기와 잡음제거기를 동시에 수렴시키되, 안정된 동작을 위하여 케환제거 및 잡음제거 후 각각의 잔차신호를 이용하여 계수를 업데이트하도록 하였다.

본 연구에서 제안한 케환 및 잡음제거기의 성능을 검증하기 위하여 시뮬레이션 프로그램을 작성하고 모의실험을 수행하였다. 실험 결과, 제안한 심층학습 알고리즘을 사용하면 기존의 FIR 구조를 사용하는 경우에 비해 케환제거기는 약 10 dB의 SFR, 그리고 잡음제거기는 약 3 dB의 SNRE 개선효과가 있는 것으로 나타났다.

감사의 글

이 논문은 2019년도 남서울대학교 학술연구비 지원에 의해 연구되었음.

References

[1] J. Kates, "Feedback cancellation in hearing aids : results from a computer simulation," *IEEE Trans. Signal Processing*, vol. 39, no. 3, Mar. 1991, pp. 553-562.

[2] J. Maxwell and P. Zurek, "Reducing acoustic feedback in hearing aids," *IEEE Trans., Speech Audio Processing*, vol. 3, no. 4, July 1995, pp. 304-313.

[3] M. Siqueira and A. Alwan, "Steady-state analysis

of continuous adaptation in acoustic feedback reduction system for hearing-aids," *IEEE Trans. Speech Audio Processing*, vol. 8, no. 4, July 2000, pp. 443-453.

[4] H. Lee, "Double-talk control using blind signal separation based on geometric concept in acoustic echo canceller," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 12, no. 3, 2017, pp.419-425.

[5] H. Lee, "Acoustic echo cancellation based on convolutive blind signal separation method," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 13, no. 5, 2018, pp.979-986.

[6] A. Spriet, G. Rombouts, M. Moonen, and J. Wouters, "Combined feedback and noise suppression in hearing aids," *IEEE Trans. Audio Speech Language Processing*, vol. 15, no. 6, Aug. 2007, pp. 1777-1790.

[7] L. Hui, M. Cai, C. Guo, L. He, W. Zhang, and J. Liu, "Convolutional Maxout Neural Networks for Speech Separation," *IEEE ISSPIT*, Dec. 2015, pp. 24-27.

[8] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, vol. 86, no. 11, Nov. 1998, pp. 2278-2324.

[9] J. Schmidhuber, "Deep learning in neural networks: An overview," *Neural Networks*, vol. 61, 2015, pp. 85-117.

[10] D. Rumelhart, G. Hinton, and R. Williams, "Learning representations by back-propagating errors," *Cognitive modeling*, vol. 5, 1988, pp. 3.

저자 소개

이행우(Haeng-Woo Lee)



1985년 광운대학교 전자공학과 (공학사)

1987년 서강대학교 대학원 전자공학과 (공학석사)

2001년 전북대학교 대학원 전자공학과 (공학박사)

1987년~1998년 한국전자통신연구원 선임연구원

2001년~현재 남서울대학교 정보통신공학과 교수

※ 관심분야 : VLSI 설계, 딥러닝, 케환 제거

