

# 모듈화한 신경 회로망을 이용한 광대역 음성 복원

우동현(부산대), 고참한(삼성전자), 강현민(부산대), 정진희(부산대)  
김유신(부산대), 김형순(부산대)

## <차 례>

1. 서론
2. 신경 회로망을 이용한 협대역 음성의 광대역 변환
3. 모듈화한 신경 회로망을 이용한 협대역 음성의 광대역 변환
4. 퍼지연산을 이용한 모듈화한 신경 회로망의 출력 개선
5. 모의 실험 결과와 고찰
6. 결론

## <Abstract>

### Wideband Speech Reconstruction Using Modular Neural Networks

Dong Hun Woo, Charm Han Ko, Hyun Min Kang, Jin Hee Jeong,  
Yoo Shin Kim, Hyung Soon Kim

Since telephone channel has bandlimited frequency characteristics, speech signal over the telephone channel shows degraded speech quality. In this paper, we propose an algorithm using neural network to reconstruct wideband speech from its narrowband version. Although single neural network is a good tool for direct mapping, it has difficulty in training for vast and complicated data. To alleviate this problem, we modularize the neural networks based on appropriate clustering of the acoustic space. We also introduce fuzzy computing to compensate for probable misclassification at the cluster boundaries. According to our simulation, the proposed algorithm showed improved performance over the single neural network and conventional codebook mapping method in both objective and subjective evaluations.

\* Keywords: Wideband speech reconstruction modular neural network, Fuzzy computing

## 1. 서론

일반적으로 음성 신호는 0 Hz에서 8000Hz 정도에 걸친 스펙트럼 특성을 가지는 데 반하여, 전화망을 통과한 음성은 300Hz에서 3400Hz 사이로 대역폭이 제한되어 있어서 상대적으로 자연스럽지 못하고 둔탁한(muffled) 소리를 나타낸다. 실제로 원음성, 즉 광대역(wideband) 음성과 전화망을 통과한 음성, 즉 협대역(narrowband) 음성 사이에는 많은 상관관계(correlation)가 있다. 그러므로 이 상관관계를 이용해 협대역 음성으로부터 광대역 음성을 복원하려는 시도들이 진행되어 왔다[1]-[3]. 이 과정은 단순히 음질 개선 뿐 아니라 음성 압축에서도 유용하게 사용될 수 있다.

이 목적을 위한 여러 알고리즘 중에 대표적인 것으로 codebook mapping 방식 [1]을 들 수 있는데, 이 방식의 가장 큰 단점은 벡터 양자화 과정에서 양자화 오류가 발생한다는 것이다. 이러한 양자화 오류를 극복하기 위해, 협대역 음성의 스펙트럼 포락선에서 직접 해당 광대역 음성의 스펙트럼 포락선으로 mapping하는 방법들을 찾는 연구들이 이루어졌다. 그 중 대표적인 것으로 Gaussian Mixture Model(GMM) 기반의 변환 방식[2] 및 신경 회로망을 이용하는 방식[2]이 있다.

그 중에서도 신경 회로망은 비선형 처리를 통해 원하는 출력값이 나오도록 가중치를 조절하는 방식으로 문자 인식, 숫자 인식 등과 같은 패턴 인식 분야[4] 뿐만 아니라, 영상 보간 등과 같은 함수 추정(function approximation) 분야에도 성공적으로 적용되어 왔다[5]. Tanaka는 그의 논문[3]에서 단일 신경 회로망을 이용한 협대역 음성의 광대역 변환 방법을 제안하였다. 그러나 단일 신경 회로망을 이용한 방법은 데이터의 크기와 복잡도가 커질수록 학습이 정체되는 단점이 있다.

본 논문에서는 BP (Back Propagation) 알고리즘을 가지는 다수의 MLP (Multi-Layer Perceptron)들을 모듈화 시킴으로써, 개별적인 신경 회로망은 전체 훈련 데이터 중 상관도가 높은 일부분만을 담당하도록 하는 방식에 기반을 둔 광대역 음성 복원 방법을 제안한다. 따라서 제안 알고리즘은 대용량이면서 복잡한 데이터를 훈련할 때, 단일 신경 회로망이 빠지기 쉬운 훈련의 정체를 피하고 mapping 성능을 높일 수 있다.

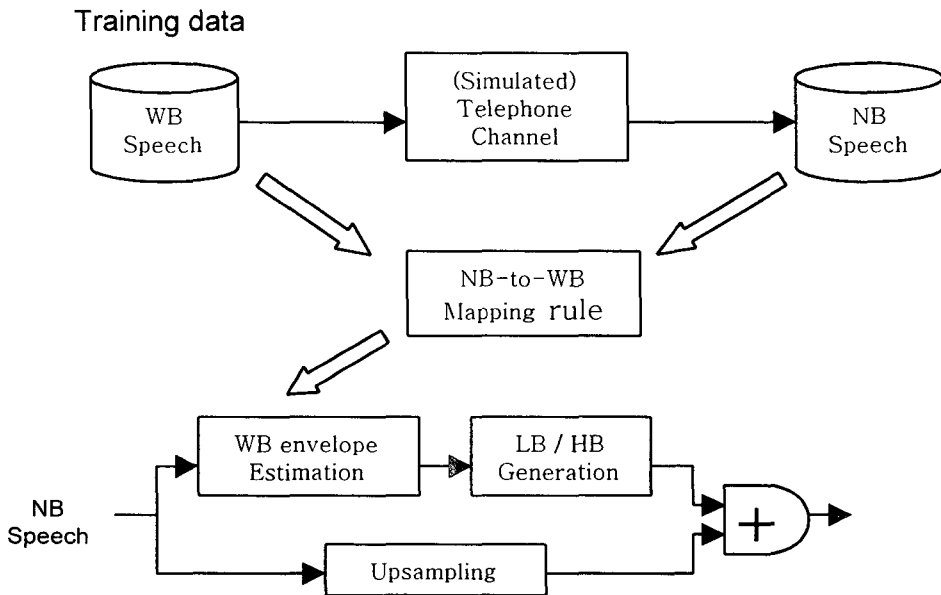
모듈화를 위한 군집(cluster)들을 만들기 위해서 본 논문에서는 K-means 알고리즘을 사용하였으며, 이 K-means 알고리즘에 의해 만들어진 군집들 각각에 대해 하나의 신경 회로망을 할당하였다. 또 군집화 과정에서 생길 수 있는 오분류를 보정해 주기 위해 몇 개의 후보 군집들을 두고, 그 후보 군집들 각각에 대한 신경 회로망들의 출력들을 fuzzy 연산 개념을 이용하여 결합하였다.

본 논문의 구성은 다음과 같다. 2장에서는 신경 회로망을 사용한 협대역 음성의 광대역 변환의 전체적인 개념과 단일 신경 회로망을 사용했을 때의 장단점에 대해 언급하고, 3장에서는 K-means 알고리즘을 이용해 모듈화한 신경 회로망을 사용하여 변환하는 방법에 대해 설명하며, 4장에서는 모듈화한 신경 회로망의 출력부분을 개선하는 방법을 보여준다. 5장에서 실험 결과를 살펴보고 그 의미를 고찰

한 후, 마지막으로 6장에서 결론을 맺는다.

## 2. 신경 회로망을 이용한 협대역 음성의 광대역 변환

<그림 1>은 협대역 음성에서 광대역 음성으로의 변환 알고리즘의 전체 블록도이다.

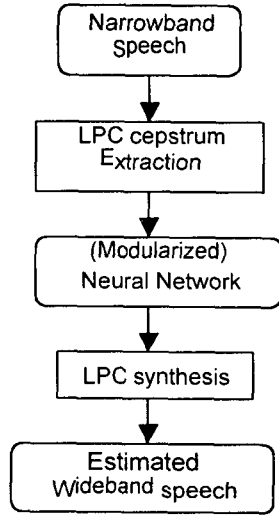


<그림 1> 협대역 음성의 광대역 변환의 전체 블록도

<그림 1>에서 보는 바와 같이, 먼저 알고리즘의 훈련을 위해서 광대역 음성은 전화망의 통과 대역(300-3400Hz)을 가지는 bandpass 필터에 의해 필터링 되고, 이를 훈련용 협대역 음성으로 사용한다. 이들 훈련 데이터를 가지고, 협대역 음성 스펙트럼에서 광대역 음성 스펙트럼으로의 변환 알고리즘을 훈련시킨다. 이렇게 훈련된 알고리즘을 통해 입력으로 들어온 협대역 음성을 광대역 음성으로 변환하게 되고, 이 변환된 음성은 upsampling한 협대역 음성의 스펙트럼 영역에서 빠진 부분에 해당하는 0-300Hz 대역과 3400Hz-8000Hz 대역 자리에 들어가서 최종 변환된 광대역 음성을 만들게 된다.


<그림 2>는 <그림 1>의 WB envelope estimation에 대한 상세 블록도이다. 본 논문에서는 스펙트럼 포락선을 표현하기 위해 LPC 켈스트럼을 사용한다. 따라서 입력으로 들어온 협대역 음성에서 LPC 켈스트럼 벡터가 추출되고, 이는 신경 회로망의 입력이 된다. 그리고 신경 회로망을 통해 나온 출력인 광대역 음성의 LPC

캡스트럼 벡터는 LPC 합성 과정을 통해서, 광대역 음성으로 만들어진다.



<그림 2> 신경 회로망을 이용한 협대역 음성의 광대역 변환 블록도

본 논문에서 사용된 신경 회로망은 BP 훈련 알고리즘을 가지는 MLP이며, 이는 패턴 인식이나 함수 추정(function approximation) 등에서 뛰어난 성능을 보여왔다[4][5]. <그림 3>은 BP 알고리즘을 가지는 MLP의 전형적인 구조이다.



<그림 3> BP 알고리즘을 가지는 MLP

여기서  $\mathbf{x}$ 는 신경 회로망의 입력 벡터이고,  $\mathbf{y}$ 는 출력 벡터이다. 신경 회로망의 가중치(weight)는 delta learning rule에 의해 조절된다.

$$\Delta w_{kj} = -\eta \frac{\partial E}{\partial w_{kj}}, \quad \Delta v_{ji} = -\eta \frac{\partial E}{\partial v_{ji}} \tag{1}$$

식 (1)에서  $\Delta w_{kj}$ 는 출력층의 가중치 변화량이며,  $\Delta v_{ji}$ 는 은닉층의 가중치 변화량이다. 또한  $E$ 는 각 훈련 데이터에 대한 에러이며,  $\eta$ 는 학습 계수이다. 식

(1)에서와 같이 MLP는 훈련 데이터에 대해 에러를 감소시키는 방향으로 가중치를 조절한다[3]. <그림 3>에서 보는 바와 같이, 협대역에서 광대역으로의 변환에서 MLP의 입력은 협대역 음성의 LPC 켈스트럼 벡터이고, 출력은 광대역 음성의 LPC 켈스트럼 벡터이다.

신경 회로망을 이용한 변환 방법은 서론에서 언급한 codebook mapping 방식의 단점인 양자화 오류를 극복하게 해준다. 즉, 신경 회로망은 codebook mapping 방식과는 달리 하나의 협대역 음성의 LPC 켈스트럼 벡터와 그에 해당하는 광대역 음성의 LPC 켈스트럼 벡터 사이에 에러를 감소시키는 방향으로 가중치를 조절하므로, 각 협대역 음성과 그에 해당하는 광대역 음성 사이에 직접 mapping을 해줄 수 있다.

한편, 훈련 데이터가 규모가 크고 복잡해질수록 최적의 가중치를 찾는 과정에서 MLP는 국부 최소값(local minimum)에 빠질 수가 있다[6]. 또 그렇지 않은 경우에도 찾은 최적의 가중치의 성능이 모든 데이터에 대해 에러를 고려한 것이므로 열화한 성능을 보인다.

### 3. 모듈화한 신경 회로망을 이용한 협대역 음성의 광대역 변환

위에서 언급한 단일 MLP에서의 성능의 열화를 개선하기 위해서 본 논문에서는 모듈화한 신경 회로망을 제안한다. 본 논문에서 제안된 모듈화한 신경 회로망은 다음과 같은 특징을 가진다.

훈련 LPC 켈스트럼 벡터들에 대해 K-means 알고리즘을 사용하여 여러 개의 군집으로 나누고 각각의 군집에 대해 하나의 MLP를 할당한다. 여기서, K-means 알고리즘은 음성 프레임에 비슷한 스펙트럼 특성을 가지는 것들끼리 묶어준다. 그러므로 각 MLP는 비슷한 주파수 특성을 가지는 훈련 데이터들만 식 (1)에 의해 에러를 감소시키므로, 보다 정밀한 훈련이 가능하다. 실제 모의 실험에서도 제안된 알고리즘은 단일 MLP 보다 개선된 성능을 보여주었다. 식 (2)는 입력 LPC 켈스트럼 벡터를 여러 군집 MLP 중 하나에 할당하는 수식이다.

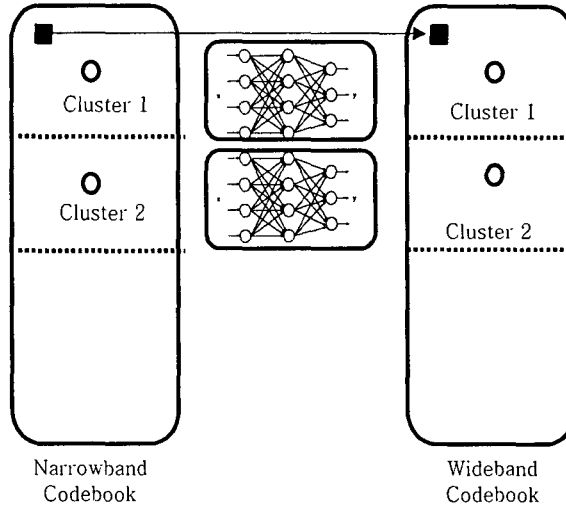
$$j = \arg \min_j \{ d_1, d_2, \dots, d_n \}, \quad d_i = \| C_i - \mathbf{x} \| \quad (2)$$

여기서  $\mathbf{x}$ 는 입력 LPC 켈스트럼 벡터이며,  $C_i$ 는 k-means 알고리즘에 의해 결정된  $i$  번째 군집의 중심(centroid)이다. 식 (2)와 같이 입력 벡터를  $j$  번째 군집에 할당한 후에 식 (3)을 통해 추정된 WB 음성 LPC 켈스트럼이 생성된다.

$$\mathbf{o} = \Gamma [ \mathbf{W}_j [ \Gamma [ \mathbf{V}_j; \mathbf{x} ] ] \quad (3)$$

여기서  $\mathbf{o}$ 는 MLP의 출력이며,  $\mathbf{W}_j$ 와  $\mathbf{V}_j$ 는 각각  $j$  번째 신경 회로망의 출력층 가중치 행렬 및 은닉층 가중치 행렬이고,  $\Gamma$ 는 활성화 함수(activation function) 행렬이다[3].

<그림 4>은 모듈화한 MLP의 구조이다.



<그림 4> 모듈화한 MLP의 구조

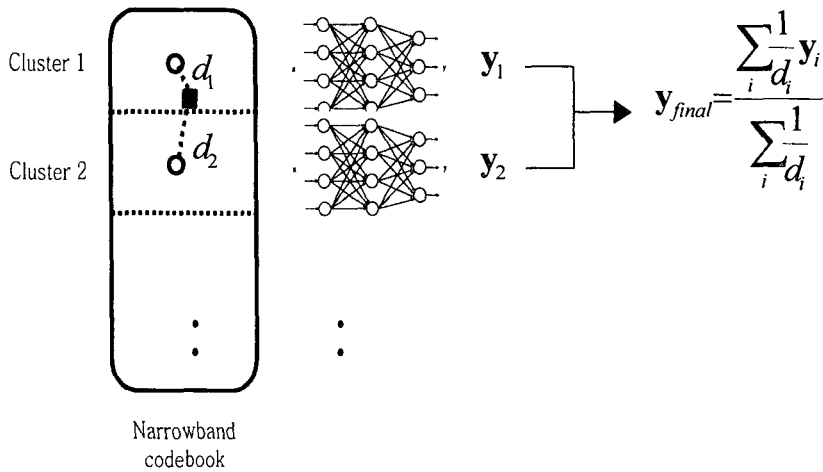
#### 4. 퍼지 연산을 이용한 모듈화한 신경 회로망의 출력 개선

모듈화한 MLP의 입력이 인접하는 두 군집의 경계 가까이 있을 경우, 이를 하나의 군집에만 할당하지 않고 두 군집에 모두 할당한 후, 각 MLP의 출력을 적절히 조합해서 최종 출력을 내는 것이 보다 합리적이다. <그림 5>는 이 개념을 보여주고 있다. 여기서 입력이 경계 근처에 있는가 여부는 경험적인 문턱값을 사용해서 판단하도록 하였다.

<그림 5>에서 검은 정사각형은 입력 LPC 캡스트럼 벡터의 협대역 코드책(narrowband codebook) 상의 위치이다.  $d_1$ ,  $d_2$ 는 각각 입력 LPC 캡스트럼 벡터와 군집 1과 군집 2의 중심 사이의 Euclidean 거리이다. 각 클러스터의 MLP의 출력  $\mathbf{y}_1$ ,  $\mathbf{y}_2$ 는 식 (4)와 같이 합성된다.

$$y_{final} = \frac{\sum_i \frac{1}{d_i} y_i}{\sum_i \frac{1}{d_i}} \quad (4)$$

식 (4)에서, 최종 광대역 LPC 켈스트럼 벡터는 입력 LPC 켈스트럼 벡터와 각 군집의 중심과의 거리를 membership 함수로 갖는 fuzzy 연산의 결과이다. 모의 실험에서 이 방법은 하나의 MLP만을 사용했을 때보다 개선된 성능을 보여준다.



<그림 5> 퍼지 연산을 이용한 신경 회로망의 출력 개선

### 5. 모의 실험 결과와 고찰

제안된 알고리즘의 성능을 평가하기 위해서 본 논문에서는 원광대에서 구축한 한국어 음소 균형 문장(Phonetically Balanced Sentence(PBS)) 데이터베이스[7]를 사용하였다. 본 논문에서는 이중 24명의 남성 화자와 24명의 여성 화자의 음성을 훈련 데이터로 사용하였고, 각 화자 당 50문장을 추출하였다. 그리고 테스트 데이터로는 남녀 각각 6명의 음성을 사용했으며, 각 화자 당 20문장이 추출되었다.

제안된 알고리즘의 객관적 성능 비교를 위해 원음성의 LPC 켈스트럼 계수와 복원 음성의 LPC 켈스트럼 계수 사이의 MSE(Mean Square Error)를 구하였으며, 다른 알고리즘과의 비교를 위해 codebook mapping과 단일 신경 회로망에 대한 실험도 같이 행해졌다. 그 결과들은 <표 1>에 나타나 있다. <표 1>에서 MNN (Modular Neural Network)은 모듈화한 신경 회로망을 사용하는 제안 방법을 뜻한다.

&lt;표 1&gt; 제안된 알고리즘과 다른 알고리즘들과의 객관적 성능 비교

	MNN with Fuzzy Computing (64 clusters)	MNN (64 clusters)	Single Neural Network	Codebook Mapping
MSE	0.237	0.245	0.306	0.485

<표 2>는 제안된 알고리즘이 군집의 수에 따라 MSE가 어떻게 변하는지를 보여준다. 표에서 보여주는 것같이 제안 알고리즘은 군집의 수가 증가함에 따라 성능이 개선됨을 알 수 있다. 그러나 클러스터의 수가 128개인 경우는 오히려 열화한 성능이 나타나는데, 이는 너무 많은 군집에 대해서는 군집 당 학습 데이터의 수가 작아져서 충분한 학습을 할 수 없기 때문으로 판단된다.

&lt;표 2&gt; 모듈화한 신경 회로망의 군집 수에 따른 성능 변화

Number of Clusters	MSE of MNN	MSE of MNN with Fuzzy Computing
2	0.288	0.287
4	0.282	0.280
8	0.273	0.269
16	0.263	0.258
32	0.253	0.247
64	0.245	0.237
128	0.256	0.245

<표 1>의 실험에서는 훈련 데이터가 순차적(sequential)으로 입력되었다. 그러나 음성 신호와 같이 비슷한 특성의 훈련 데이터가 일정 시간 동안 계속되는 데이터의 경우에는 순차적인 방식보다 임의의 순서대로 입력을 넣어주는 것이 MLP의 훈련의 편중을 막아주므로, 보다 나은 성능을 낸다고 알려져 있다[6]. <표 3>는 훈련 데이터가 임의로(randomly) 입력되었을 때의 결과이다.

&lt;표 3&gt; 훈련 데이터의 입력 순서를 임의로 하였을 때의 성능 비교

	MNN with Fuzzy computing (64 clusters)	MNN (64 clusters)	Single Neural Network	Codebook Mapping
MSE	0.225	0.231	0.242	0.485

<표 3>의 결과를 볼 때, 여전히 제안 알고리즘이 가장 좋은 성능을 보여준다. 그러나 단일 신경 회로망에 대한 성능 개선의 폭은 순차적인 입력 때보다는 작아



졌다. 이는 모듈화한 신경 회로망의 경우는 입력 데이터가 각 군집들에 할당되면서, 어느 정도 입력 데이터가 뒤섞인 효과가 있기 때문이다. 그러므로 제안 알고리즘은 학습 시에 입력 데이터의 임의화(randomization) 과정을 거치지 않아도 성능 저하가 적은 장점을 지닌다.

제안 알고리즘에 대한 주관적 평가는 다음과 같이 수행되었다. 먼저, 20명의 평가자들에 대해 협대역 음성과 제안된 알고리즘의 결과 음성을 들려주고 어느 쪽을 더 선호하는지 답하게 하였다. 두 번째로, codebook mapping의 결과 음성과 제안 알고리즘의 음성을 가지고 첫번째와 같은 방식으로 평가하도록 했다. <표 4>과 <표 5>는 이들 평가의 결과를 보여준다.

<표 4> 협대역 음성과 제안된 알고리즘에 의해 복원된 음성의 주관적 비교

	NB Speech	No Difference	MNN with Fuzzy Computing
Training speech	10%	0%	90%
Test speech	0%	0%	100%


<표 5> Codebook mapping과 제안된 알고리즘에 의해 복원된 음성의 주관적 비교

	Codebook Mapping	No Difference	MNN with Fuzzy Computing
Training speech	5%	5%	90%
Test speech	15%	20%	65%


위의 표에서 No difference는 평가자들이 어느 음성을 더 선호하는 지를 명확히 알 수 없을 경우를 뜻한다. 표에서 보는 바와 같이, 제안 알고리즘은 주관적 평가에서도 협대역 음성이나 codebook mapping 방식보다 우수한 성능을 나타내었다.

테스트에 사용된 음성의 유성음 부분의 두 개의 프레임의 스펙트럼이 각 알고리즘 별로 <그림 6>에 나타나 있다. 각 스펙트럼은 512 포인트 FFT를 사용해서 구하였다. 그림에서 보이는 것처럼 직접적인 mapping을 시도하는 신경 회로망이 스펙트럼의 윤곽을 보다 잘 복원하는 것을 볼 수 있으며, 결과적으로 제안 알고리즘이 codebook mapping보다 더 개선된 음성 특성을 나타낸다.


다만, 그림에서 원 음성과 달리 복원된 음성 스펙트럼의 경우 모든 주파수 대역에 걸쳐 하모닉 성분을 가지는 것을 볼 수 있다. 이는 본 음성생성을 위한 여기 신호의 경우 유/무성음 여부 판단에 따라 주기적인 임펄스 및 랜덤 잡음으로 단순하게 표현했기 때문이다. 본 논문에서는 음성 스펙트럼 포락선의 복원에 초점을 맞추고 있으나, 향후 복원된 음성의 음질 개선을 위해 여기신호를 보다 잘 표현해 줄 필요가 있음을 알 수 있다.




(a)



(b)



(c)



(d)

<그림 6> 음성 스펙트럼들의 비교 (a) 광대역 음성 (b) 협대역 음성 (c) codebook mapping에 의한 복원 음성 (d) 모듈화한 신경 회로망에 의한 복원 음성

제안된 알고리즘은 훈련 데이터의 크기가 커질수록 단일 신경 회로망에 비해 개선의 폭이 커진다. 이는 훈련 데이터가 많아질수록 단일 신경 회로망의 경우에는 데이터의 복잡성이 증가하므로 학습의 효율이 떨어지는 반면, 제안된 모듈화 구조에서는 각 신경 회로망은 유사한 특성들만을 학습하므로 그 효율의 하락을 줄일 수 있다. <표 6>의 결과는 훈련 데이터를 위해 30명의 남성 화자와 30명의 여성 화자를 선택하고, 각 사람 당 50 문장을 추출했을 때의 결과이다. 테스트 데이터를 위해 5명의 남성 화자와 5명의 여성 화자에 대해, 각 사람 50문장을 추출하였다. 또한 훈련 데이터는 임의의 순서대로 입력에 들어가도록 했다. <표 5>와 <표 6>을 비교해 볼 때, 훈련 데이터의 규모가 크면 클수록 제안된 알고리즘과 단일 신경 회로망을 사용한 방법과의 격차가 커지는 것을 알 수 있다.

<표 6> 규모가 더 큰 훈련 데이터에 대한 제안 알고리즘의 성능 비교

	MNN with Fuzzy computing (64 clusters)	MNN (64 clusters)	Single Neural Network
MSE	0.346	0.349	0.381

## 6. 결 론

본 논문에서는 전화망 상의 협대역 음성의 광대역 변환 방법으로 모듈화한 신경 회로망을 제안하였다. 신경 회로망을 이용한 변환은 원래의 광대역 음성을 목표로 학습하므로 직접적인 mapping이 가능하다는 장점이 있다. 그러나 신경 회로망은 학습 데이터의 크기가 크고 복잡도가 높을수록 학습 효율이 낮아진다. 따라서 보다 나은 학습을 위해 본 논문에서는 음성 데이터를 K-means 알고리즘을 사용하여 여러 개의 군집으로 나누고, 각 군집에 하나의 신경 회로망을 할당함으로써 학습 효율을 높이고 성능을 개선시킬 수 있었다. 모의 실험에서 제안한 알고리즘은 객관적 평가에서 단일 신경 회로망에 비해 개선된 성능을 보였고, 주관적 평가에서도 codebook mapping이나 협대역 음성에 비해 좋은 평가를 얻었다. 본 논문에서의 광대역 음성 복원 방식에서는 LPC 칩스트림에 의한 음성 스펙트럼 포락선의 복원에 주안점을 두었으나, 앞으로 광대역 여기신호의 복원에 대해서도 많은 연구가 필요할 것으로 사료된다.

## 참 고 문 헌

- [1] Y. Yoshida, M. Abe, "An algorithm to reconstruct wideband speech from narrowband speech based on codebook mapping", *Proc. ICSLP*, pp.1591-1594, 1994.
- [2] K. Y. Park, H. S. Kim, "Narrowband to wideband conversion of speech using GMM based transformation", *Proc. ICASSP*, Vol. 3, pp.1843-1846, 2000.
- [3] Y. Tanaka, N. Hatazoe, "Reconstruction wideband speech from telephone-band speech by multi-layer neural networks", *Spring Meeting of ASJ*, 1-4-19, pp.255-256, 1995.
- [4] S. W. Lee, "Off-line recognition of totally unconstrained handwritten numerals using multilayer cluster neural networks", *IEEE Transaction on Pattern Analysis and Machine Intelligence*, Vol. 18, pp.648-652, June 1996.
- [5] N. Plaziac, "Image interpolation using neural network", *IEEE Transaction on Image Processing*, Vol. 8, pp.1647-1651, 1999.
- [6] J. M. Zurada, *Introduction to artificial neural network*, PWS Publishing Co., 1995.
- [7] 이용주, *음성 데이터베이스 설계 및 제작, 용역 결과 보고서*, 한국 전자통신연구소, 1996.

접수일자: 2003년 11월 10일

게재결정: 2003년 12월 12일

▶ 우동현(Dong Hun Woo)

주소: 509-735 부산광역시 금정구 장전동 산30번지 부산대학교

소속: 부산대학교 전자공학과 지능정보처리 연구실

전화: 051) 510-1698

E-mail: dhwoo@pusan.ac.kr

▶ 고참한(Charm Han Ko)

주소: 442-742 경기도 수원시 팔달구 매탄3동 416 삼성전자

소속: 삼성전자 DM 총괄 DVS 사업부

전화: 031) 200-3684

E-mail: charmhan.ko@samsung.kr

▶ 강현민(Hyun Min Kang)

주소: 609-735 부산광역시 금정구 장전동 산30번지 부산대학교

소속: 부산대학교 전자공학과 지능정보처리 연구실

전화: 051) 510-1698

E-mail: kanghm@pusan.ac.kr

▶ 정진희(Jin Hee Jeong)

주소: 609-735 부산광역시 금정구 장전동 산30번지 부산대학교

소속: 부산대학교 전자공학과 지능정보처리 연구실

전화: 051) 510-1698

E-mail: jeongjh@pusan.ac.kr

▶ 김유신(Yoo Shin Kim)

주소: 609-735 부산광역시 금정구 장전동 산30번지 부산대학교

소속: 부산대학교 전자공학과

전화: 051) 510-2376

E-mail: kimys@pusan.ac.kr

▶ 김형순(Hyung Soon Kim)

주소: 609-735 부산광역시 금정구 장전동 산30번지 부산대학교

소속: 부산대학교 전자공학과

전화: 051) 510-2452

E-mail: kimhs@pusan.ac.kr