

論文95-32B-1-19

계층구조 시간지연 신경망을 이용한 한국어 변이음 인식에 관한 연구

(A Study on Korean Allophone Recognition Using Hierarchical Time-Delay Neural Network)

金秀一 * , 林海彰 **

(Soo-il Kim and Hae-Chang Rim)

要 約

연속음성인식을 위한 기본 단위로 많이 사용되는 음소(phoneme)는 인식대상의 갯수가 충분히 적어서 학습이 가능하지만, 주변 음소에 영향을 많이 받는 조음결합현상(coarticulation)에 의해 일관성이 떨어지는 문제 가 있다. 본 논문에서는 이러한 음소단위 인식의 문제점을 해결하기 위하여 변이음단위 인식을 제안한다. 변이음을 연속음성인식의 인식단위로 사용하기 위하여 먼저 한 음소의 모든 변이음을 고려하면서 서로 유사한 변이음을 통합·분류하여 3 개의 변이음 군으로 나눈다. 인식방법으로는 시간지연 신경망을 사용하였고 모든 한국어의 음소와 변이음을 효율적으로 인식하기 위해서 음향음성학적인 특성에 따라 나누어진 소규모 시간지연 신경망들을 모듈 별로 학습한 후, 계층적으로 통합하여 전체적인 시간지연 신경망을 구성하였다. 본 연구에서는 변이음 단위 인식의 성능을 음소단위 인식과 비교하기 위하여 한국어 파열음에 대해 인식실험을 수행하였다. 인식 실험을 통하여, 변이음 단위 인식이 음소단위 인식에서 문제가 되는 조음결합현상을 해결할 수 있음을 확인하였고, 변이음 인식의 결과인 변이음 열이 제공하는 부가적인 정보를 음운·파싱에 이용하는 방법에 대해 고찰하였다.

Abstract

In many continuous speech recognition systems, phoneme is used as a basic recognition unit. However, the coarticulation generated among neighboring phonemes makes us difficult to recognize phonemes consistently. This paper proposes allophone as an alternative recognition unit. We have classified each phoneme into three different allophone groups by the location of phoneme within a syllable. For a recognition algorithm, time-delay neural network(TDNN) has been designed. To recognize all Korean allophones, TDNNs are constructed in modular fashion according to acoustic-phonetic features (e.g. voiced/unvoiced, the location of phoneme within a word). Each TDNN is trained independently, and then they are integrated hierarchically into a whole speech recognition system. In this study, we have experimented Korean plosives with phoneme-based recognition system and allophone-based recognition system. Experimental results show that allophone-based recognition is much less affected by the coarticulation.

* 正會員, 三聖綜合技術院 基盤技術研究所 音聲處理팀
(Samsung Advanced Institute of Technology)

** 正會員, 高麗大學校 電算科學科

(Dept. of Computer Science, Korea Univ.)
接受日字 : 1994年 6月 24日

I. 서 론

음성인식 기술은 1970년대부터 활발히 연구되어 왔으나 현재는 제한된 수의 단어를 인식하는 시스템이 실용화되는 단계로서 인간의 자연스러운 음성을 신뢰성 있게 인식하는 시스템은 아직도 연구단계에 머물러 있다^{[1][2]}. 이처럼 연속음성인식 시스템이 쉽게 실용화되지 못하는 것은 음성이 다음과 같은 특성을 갖기 때문이다^[3]. 첫째, 문어체 문장과는 달리 발음한 음성에서는 단어나 음절 사이의 목음구간을 정확히 구분할 수 없다. 둘째, 음소와 같은 기본 음성단위가 주변 음소 등에 의해 임의적으로 변한다. 셋째, 한 명의 화자가 같은 음을 발음하더라도 주변환경과 발음방법에 따라 다르게 들린다. 넷째, 나아니 성별이 다른 화자가 같은 음을 발음하더라도 다르게 들린다. 이러한 음성의 특징을 모두 고려할 때, 무제한 어휘의 연속음성인식 시스템을 만들려면 단어이하 단위로 인식의 기본단위를 정하는 것이 필수적이다^[4].

연속음성인식 시스템의 인식단위를 결정하는데 고려하는 척도에는 일관성(consistency)과 학습가능성(trainability)이 있다^{[4][5][6]}. 일관성이란 선택된 인식단위는 이것을 포함하는 단어나 문장에서 동일한 특성을 가져야 한다는 것이다. 학습가능성이란 학습하기에 충분한 수의 용례가 존재해야 한다는 것이다. 음소보다 상대적으로 큰 인식단위인 음절, 반음절, 디아폰(diphone) 등은 일관성을 갖지만 모델의 갯수가 너무 많아서 학습하기에 충분한 용례를 찾기 힘들다. 반면에 음소는 그 갯수가 충분히 적어서 학습이 가능하지만 주변 음소들에 영향을 많이 받는 조음결합현상(coarticulation)에 의해 일관성이 없다. 문맥의존(context-dependent) 음운인 트라이폰(triphone)과 변이음(allophone)은 일관성을 갖는 인식단위이지만 갯수가 너무 많아서 학습시키기 힘들다. 그러나 음운간 유사도가 큰 것들을 적절히 통합한 일반화된(generalized) 트라이폰 또는 변이음으로 음성을 모델링하면 충분히 학습시킬 수 있을 뿐만 아니라 음성인식의 궁극적인 목적인 무제한 어휘의 연속음성을 인식하는 것이 가능하다.

음성인식용 신경망은 음성신호의 시간축 왜곡 현상을 처리할 수 있어야 한다. 즉 다음 음절(또는 음소)이 어디서 시작하는지 정확히 예측할 수 없으므로 해석 구간내의 어느 부분에 해당 음절이 위치하더라도 찾아낼 수 있어야 한다. 또한 음성신호의 크기와는 무관한 스케일 불변성(scale-invariant)이 있어야 한다. 이 밖에 음성인식용 신경망은 음성 신호의 포만트(form-

closure)과 같은 특성을 추출하는 능력이 있어야 한다. 시간지연 신경망은 이와 같은 불변 특성과 패턴인식 능력을 갖는 대표적인 신경망으로서 음성의 시간에 따른 음향학적 특징 변화를 학습할 수 있기 때문에 시간축 왜곡 현상과 음소간 경계 분리 문제를 자연스럽게 해결할 수 있다^[7].

시간지연 신경망을 이용하여 한국어의 모든 음소를 인식하는 경우 40여개의 출력노드를 갖는 신경망을 구성해야 한다. 그러나 40개 정도의 출력 노드를 갖는 단일구조(monolithic) 시간지연 신경망을 학습시키는 것은 거의 불가능하다. 따라서 분류하는 특성에 따라 나누어진 여러 개의 소규모 시간지연 신경망들을 따로 학습시킨 후 이들을 계층적으로 통합하여 커다란 시간지연 신경망을 구성해야 한다^[8].

본 논문에서는 음소단위 음성인식에서 문제가 되는 조음결합현상을 극복하기 위해 변이음단위 인식을 제안한다. 먼저 한 음소의 여러 환경에서 다르게 나타나는 모든 변이음을 고려하고, 유사한 변이음을 통합·분류하여 몇 개의 변이음을 군으로 나눈다. 인식방법으로는 음소인식률에서 우수한 성능을 보인 시간지연신경망을 사용하며, 전체 한국어 음소 및 변이음을 인식하기 위해 여러 소규모 시간지연 신경망을 모듈화하여 학습한 후 계층적으로 통합한다. 변이음단위 인식의 성능을 분석하기 위해, 일반적으로 서로 구별하기 어렵다고 알려진 6 가지 한국어 파열음의 변이음에 대해 인식실험을 하였다.

II. 변이음 단위 인식

1. 음성학에서의 변이음

변이음이란 어떤 단어를 발음할 때 단어안에 있는 어떤 음소가 여러 가지 요인에 의해서 일정하게 또는 임의적으로 변하여 발음되는 것이다. 한 음소의 여러 가지 변이음을 발생시키는 요인에는 다음과 같은 것들이 있다^[6].

- (1) 발음상의 변이: 좌/우 음소, 단어들 사이의 문맥, 단어내에서의 위치 등
- (2) 언어학적인 변이: 운율(prosody), 억양(intonation), 강세(stress) 등
- (3) 화자에 따른 변이: 소리크기, 발화속도, 성도길이 등

현재 연속음성인식의 인식단위로 사용되는 대부분의 음성단위는 위의 변이 요소들 중 일부만 고려한 것이다. 즉, 디아폰(diphone)은 바로 이전 또는 이후에 오는

한가지 음소를 고려한 것이고, 트라이폰(triphone)은 앞뒤에 오는 두가지 음소를 고려한 것이라고 할 수 있다.

2. 음성인식 단위로서의 변이음^{[4][9]}

연속음성인식을 위한 기본단위는 명확히 정의되고 학습하기에 충분하도록 자주 발생해야 할 뿐만 아니라 이웃하는 단위에 영향을 받지 않아야 한다. 음소단위 인식에서 문제가 되는 조음결합현상을 해결하기 위해 사용하는 문맥의존(context-dependent) 단위에는 다이폰, 트라이폰, 그리고 변이음 등이 있다. 문맥의존이란 이웃하는 음소와의 관계를 반영한다는 것을 뜻한다. 다이폰과 트라이폰은 모두 모델의 갯수가 너무 많아서 모든 모델을 충분히 학습시킬 수 없다는 문제점이 있다. 따라서 유사한 트라이폰 모델을 통합한 일반화된 트라이폰(generalized triphones)이 제안되어 HMM(hidden Markov model)을 이용한 음성인식에 적용되었으며 상당히 우수한 성능을 보였다. 그러나 트라이폰은 변이음의 많은 발생 요인중 단지 2가지 요인만을 고려한 것으로, 보다 많은 변이 발생 요인을 고려하고 유사한 변이음을 통합하여 구성한 일반화된 변이음(generalized allophones)을 인식단위로 사용하면 기존의 음소를 단위로 한 음성인식의 문제점을 해결할 수 있고 인식률도 높일 수 있다.

3. 한국어 파열음의 변이음 분류

본 연구에서는 변이음단위 인식의 성능을 음소단위 인식과 비교하기 위해 한국어 자음중 서로간의 구별이 어렵다고 알려진 6 가지 파열음을 실험대상으로 하였다.

표 1. 변이음 군의 분류 기준

Table 1. Criteria for classifying a phoneme into three allophone groups.

변이음 군	분류 기준	예
제 1 변이음	단어의 첫번째 음절의 초성으로 발음될 경우	'가다'에서 /ㄱ/
제 2 변이음	단어 중간에 있는 음절의 초성으로서 앞뒤 음이 유성음인 경우 (이때 유성음은 단모음 8개와 유성자음 4개: ㅏ, ㅓ, ㅗ, ㅜ, ㅡ, ㅣ, ㅐ, ㅔ, ㅚ, ㅟ, ㅕ, ㅞ)	'아가'에서 /ㄱ/ '장가'에서 /ㄱ/
제 3 변이음	단어의 마지막 음절의 종성	'사적'에서 /ㄱ/

한국어 파열음중 경음을 제외한 평음을 격음 6 가지

(ㄱ, ㄷ, ㅂ, ㅋ, ㅌ, ㅍ)를 표 1과 같이 크게 세가지 변이음 군으로 나누었다. 이 분류는 변이음의 발생 요인중 단어내 음소의 위치가 변이음간 구별을 가장 명확히 해주는 특성이라고 보고 정한 것이다.

표 1의 분류에 포함되지 않는 변이음은 다음과 같은 규칙에 의해 처리된다.

(1) 연음 규칙: '복어'는 발음상 /부거/가 되어 첫째 음절의 종성 'ㄱ'은 연음되어 제 2 변이음으로 분류하는 것이 적합하다. 연음으로 발음된 단어를 원래의 단어로 인식하려면, 이 단어가 발음될 때의 문맥 정보를 고려해야 한다.

(2) 경음화: '숙적'은 발음상 /숙쩍/이 되어 둘째 음절의 초성 'ㅈ'은 /ㅉ/으로 경음화되었다. 경음화된 단어를 원래의 단어로 인식하려면, 먼저 경음 인식기를 추가하여 경음을 인식하고 인식된 경음을 문맥 정보에 따라 원래의 음으로 변환해야 한다.

(3) 기타 여러 음운 규칙에 의해 생성되는 변이음은 위에서 분류한 군 중의 하나로 인식한 후, 문법이나 문맥 정보를 이용한 후처리 부분에서 원래의 음으로 변환한다.

변이음단위 인식실험 이전에 행한 파열음소의 각 변이음간 분류 실험을 통해 이와 같은 분류가 타당한지 알아 보았다.

표 2. 파열음소의 변이음간 분류 실험 결과

Table 2. Results of inter-allophone recognition of a phoneme.

TDNN 종류	학습률 (%)	인식률 (%)	인식오류 수 / 입력데이터 수
ㄱ1/ㄱ2/ㄱ3	100	100	0 / 75
ㄷ1/ㄷ2/ㄷ3	100	96.00	3 / 75
ㅂ1/ㅂ2/ㅂ3	100	98.67	1 / 75
ㅋ1/ㅋ2	100	86.00	7 / 50
ㅌ1/ㅌ2	100	100	0 / 50
ㅍ1/ㅍ2	100	98.0	1 / 50

표2는 제안한 변이음 분류 방법을 이용하여 6가지 파열음소를 각각 3가지(무성 파열음인 경우는 2가지) 변이음군들로 나눈 다음 TDNN을 이용하여 동일 음소에서 파생된 변이음들이 서로 얼마나 잘 구별되는지 확인하는 실험의 결과이다. 각 파열음소의 변이음간 구별이 'ㅋ'의 변이음들을 제외하고는 모두 높은 인식률과 함께 인식됨을 알 수 있으며 이것은 파열음의 각 변이음은 음향음성학적으로 명확히 구별되는 특성을 갖는다는 것을 의미하고, 이 변이음을 한가지 음소로 일괄적으로 인식하는 것이 인식률 저하의 요인이 됨을 알 수 있다.

III. 시간지연 신경망을 이용한 음성인식

1. 시간지연 신경망의 구조^{[1][2]}

시간지연 신경망을 음성인식에 적용할 경우, 발음된 음성의 입력 패턴에 대해 시간 순서대로 일정한 크기의 입력 윈도우를 오른쪽으로 조금씩 옮겨가면서 시간지연 신경망의 입력층에 입력시키면, 은닉층(hidden layer)을 거쳐 최종적으로 출력층의 특정 노드를 활성화시켜 인식이 이루어진다. 그럼 1은 '/k/'의 세가지 변이음(/k/, /g/, /kV/)을 구별하는 시간지연 신경망의 구조를 나타낸 것이다. 이것은 출력노드가 3 개인 3 계층 시간지연 신경망이다. 여기에서 입력 패턴의 세로축은 16 구간의 멜 스케일로 변환된 주파수 구간을 나타낸다.

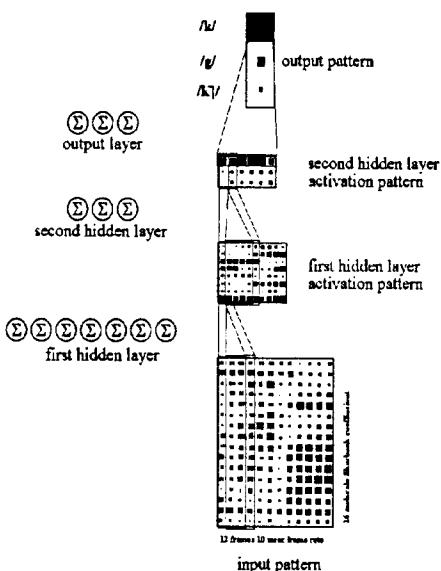


그림 1. 시간지연 신경망의 구조
Fig. 1. Basic structure of TDNN.

전체적인 인식과정은 다음의 순서대로 이루어진다. 첫번째 은닉층에서는 3개의 지연된 입력을 동시에 받아들여서 가중치(weight)를 곱한 후 시그모이드(sigmoid) 함수를 거쳐 두번째 은닉층에 전달한다. 두번째 은닉층에서는 첫번째 은닉층에서 생성된 활성화 패턴으로부터 5개의 지연된 입력을 동시에 받아들여서 가중치를 곱한 후 시그모이드 함수를 거쳐 출력층에 전달한다. 이렇게 함으로써 상위 계층으로 갈수록 입력의 넓은 시간 영역내에 포함된 특성을 학습할 수 있다^{[1][2]}. 출력층에서는 6개의 지연된 입력을 동시에 받아들인다. 그러나 은닉층에서와는 달리 가중치를 곱

하지 않고 단순히 각 출력 노드에 해당하는 두번째 은닉층 노드의 모든 활성화 패턴을 합하여 시그모이드 함수를 취한다. 즉 출력층의 역할은 단순히 두번째 은닉층의 결과를 합하여 최대값을 갖는 출력 노드를 활성화시키는 것이다.

2. 시간지연 신경망의 학습^{[1][2][3][4]}

시간지연 신경망은 기본적으로 다계층 신경망(multi-layer perceptron)의 구조를 가지고 있기 때문에 복잡한 비선형적 결정 공간(complex nonlinear decision surfaces)을 학습할 수 있다. 입력층에서 출력층에 이르는 동안 점차적으로 보다 넓은 범위의 시간 변화를 학습하도록 연결이 이루어져 있다. 또한 각 계층의 입력 윈도우를 일정 간격으로 이동하면서 입력을 받아들이므로써 입력 패턴의 음향학적 특징 변화가 어느 곳에 위치하더라도 이것을 감지할 수 있다. 따라서 시간지연 신경망은 입력 패턴에 존재하는 음향학적 특징의 시간적 변화를 학습하기 때문에 발음 속도차에 의한 음성 데이터의 시간축 왜곡 현상이나 음소간 경계분리 문제를 자연스럽게 해결할 수 있다.

시간지연 신경망의 학습은 오류역전파(error back-propagation) 알고리즘으로 이루어진다. 그러나 시간적으로 지연된 입력 윈도우가 중복되어 입력되기 때문에 다음과 같은 변경이 필요하다.

- 1) 일반적인 다계층 신경망에서 첫번째 은닉층의 오류는 다음 공식을 이용하여 두번째 은닉층으로부터 전달된다.

$$\delta_i = x_i(1-x_i) \sum_j \delta_j w_{ij}$$

여기서 δ_i 와 δ_j 는 각각 첫번째 은닉층 노드 j 의 오류, 두번째 은닉층 노드 i 의 오류를 의미한다. x_i 는 노드 j 의 활성화 정도이고, w_{ij} 는 두번째 은닉층 노드 i 에서 첫번째 은닉층 노드 j 로 연결된 가중치이다. 시간지연 신경망에서는 시간지연된 값이 동시에 입력되고, 전체적으로 입력 윈도우가 10 ms 간격으로 이동하면서 중복하여 입력되기 때문에 첫번째 은닉층의 활성화 패턴은 여러 개의 두번째 은닉층의 활성화 패턴을 생성하는데 중복해서 사용된다. 따라서 순방향 진행시(forward pass) 연결되었던 모든 경우에 대하여 오류를 계산하고 이들의 합을 실제 역전파된 오류로 사용한다. 즉 첫번째 은닉층의 오류는 다음과 같은 공식을 이용하여 두번째 은닉층으로부터 전달된다.

$$\delta_{t,i} = x_{t,j}(1-x_{t,j}) \sum_l \sum_r \delta_{t,r} w_{r,i}$$

여기서 $\delta_{t,i}$ 는 첫번째 은닉층의 노드 i 가 t_1 프레임에서 입력한 활성화 패턴 $x_{t,i}$ 에 대하여 두번째 은닉층으로부터 전달된 오류이다. $\delta_{t,i}$ 는 두번째 은닉층의 노드 i 가 t_2 프레임의 활성화 패턴을 생성할 때 발생한 오류이다.

2) 입력 원도우가 10 ms 간격으로 이동하면서 처리하기 때문에 같은 기중치를 사용하여 입력 패턴을 입력하게 된다. 따라서 오류 역전파시 각 원도우에 대한 오류의 평균을 실제 발생한 오류로 사용한다.

3. 계층구조 시간지연 신경망^[1]

일반적으로 신경망의 크기가 커질수록 학습에 필요한 데이터 수와 학습에 걸리는 시간이 급격히 늘어난다. 시간지연 신경망은 일반적인 다계층 신경망보다 많은 연결을 가지므로 학습하는데 많은 시간이 필요하다. 한국어의 모든 음소를 인식하는 경우 40 개의 출력 노드를 갖는 시간지연 신경망이 필요하게 된다. 그러나 40 개의 출력 노드를 갖는 단일구조(monolithic) 시간지연 신경망을 학습시키는 것은 거의 불가능하다. 따라서 여러 개의 소규모 시간지연 신경망을 학습시킨 후 이를 통합하여 커다란 시간지연 신경망을 구성하는 방법이 필요하다.

계층구조 시간지연 신경망은 음소군 분류(phoneme group spotting) 시간지연 신경망과 음소 분류(phoneme spotting) 시간지연 신경망을 모듈 별로 학습시킨 후, 음소군 분류 시간지연 신경망을 상위계층으로 하여 각 음소 분류 시간지연 신경망을 계층적(hierarchical)으로 연결함으로써 전체 음소 인식 시스템으로 확장하는 것이다. 계층 구조 시간지연 신경망에서는 단일구조 시간지연 신경망의 두번째 은닉층을 학습하는 과정이 생략되지만 단일구조 시간지연 신경망에 비해 짧은 학습시간과 적은 양의 데이터로도 동등한 인식률을 얻을 수 있다.^[13]

IV. 실험 방법

1. 변이음 추출을 위한 음성 데이터 생성

본 연구에서는 제안한 변이음 분류 방법에 의해 6개의 한국어 파열음을 유성 파열음은 각각 3 가지 군으로, 무성 파열음은 각각 2 가지 군으로 나누어 모두 15 가지 군으로 구분하였다. 이때 무성 파열음인 ‘ㅋ’, ‘ㅌ’, ‘ㅍ’은 종성의 대표음화 현상에 의해 제 3 변이음을 구분할 필요가 없다. 각 변이음의 추출을 위한 단어의 설정 방법은 다음과 같다.

(1) 제 1 변이음: 해당 파열음을 초성으로 하고 8 가

지 단모음과 결합되는 단어들을 선정하였다. 이때 음의 변이에 거의 영향을 끼치지 않는 종성 결합 여부는 고려치 않았다.

(2) 제 2 변이음: 단모음 8 개와 유성자음 4 개로 구성된 유성음들 사이에 해당 파열음이 있는 단어를 선정하였다. 그러나 ‘산길’/산길/과 같이 경음화되는 단어는 제외하였다.

(3) 제 3 변이음: 단어의 마지막 음절 종성으로 해당 파열음이 나타나는 단어를 선정하였다.

각 군마다 해당 변이음을 포함하는 임의의 단어를 25 개씩 선택한 후 한 사람의 남성 화자가 한 단어를 2 번씩 발음하여 녹음하였다. 실험에 사용된 음성 데이터의 수는 각 변이음마다 50 개씩이고 모두 합하여 750 개이다. 녹음 방법은 컴퓨터가 작동하고 있는 일반 사무실 환경에서 발음한 음성을 마이크를 통해 녹음하고, 16 kHz로 샘플링(sampling)하여 14-bit 데이터열로 변환한 다음 PC에 저장하였다.

2. 음성 신호 처리

시간지연 신경망의 입력 패턴을 생성하기 위한 음성 신호 처리 과정은 그림 2와 같다.

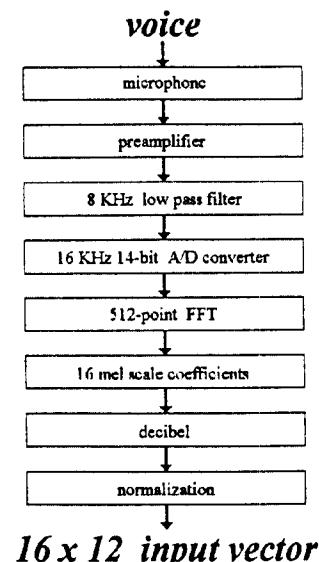


그림 2. 음성 신호 처리

Fig. 2. Speech signal processign.

음성 데이터의 스펙트로그램(spectrogram)을 통해 모음 시작부분을 중심으로 142 ms의 변이음을 추출하였다. 추출한 음소를 512-포인트 해밍 원도우(Hamming window)를 10 ms씩 오른쪽으로 옮겨 가면서 다시 512-포인트 FFT(fast Fourier transform)를

수행하여 256×12 의 파워 스펙트럼 계수(power spectrum coefficients)를 만들었다.

낮은 주파수의 음성 신호에 더 민감한 귀의 특성을 반영하기 위해 파워 스펙트럼 계수를 다시 16×12 의 멜 스케일 필터뱅크(mel-scale filterbank) 계수로 변환하였다^[14]. 그리고 소리의 크기에 대한 귀의 특성을 고려하기 위해 멜 스케일 필터뱅크 파워 스펙트럼을 다시 데시벨(decibel)로 변환하였다^[15].

3. 구현 환경

TDNN Simulator는 C 언어를 사용하여 구현되었으며, 신경망의 학습과 인식 실험은 Intel 486DX-50MHz CPU가 장착된 PC에서 행하였다. 계충구조 TDNN의 구현은 각 TDNN의 인식결과를 통합하여 전체적인 인식 시스템을 구성하는 방법을 사용하였다.

4. 시간지연 신경망의 학습 및 실험

신경망의 노드수를 적게 하면 학습 데이터를 일반화하지 못하고 반대로 노드수가 많으면 학습을 제대로 못하는 특성이 있다^[11].

표 3. 시간지연 신경망의 노드수

Table 3. Number of nodes.

TDNN 종류	Node 수	1st Hidden Layer	2nd Hidden Layer	Output
ㄱ/ㄷ/ㅌ/ㅋ/ㅌ/ㅍ	4	2		2
단어초/유성음사이/단어말 ㄱ/ㄷ/ㅂ	7	3		3
ㅋ/ㅌ/ㅍ	9	3		3
ㄱ/ㄷ/ㅌ/ㅂ/ㅍ ㄱ/ㄷ/ㅌ/ㅂ/ㅌ ㄱ/ㄷ/ㅌ/ㅌ/ㅌ ㄱ/ㅌ/ㅌ/ㅌ/ㅌ ㄱ/ㅌ/ㅌ/ㅌ/ㅌ	9	3		3
ㄱ/ㄷ/ㅌ/ㅌ/ㅌ ㄱ/ㅌ/ㅌ/ㅌ/ㅌ ㄱ/ㅌ/ㅌ/ㅌ/ㅌ ㄱ/ㅌ/ㅌ/ㅌ/ㅌ ㄱ/ㅌ/ㅌ/ㅌ/ㅌ	9	3		3

따라서 여러가지 노드수의 적용을 통한 실험들에서 인식률이 가장 좋은 경우일 때의 값을 택하였다. 그 결과는 표 3과 같다. 시간지연 신경망은 다계층 신경망에 비하여 가중치의 갯수는 적지만 입력 윈도우가 10 ms 간격으로 이동하면서 반복적으로 적용되기 때문에 실제적인 계산량은 다계층 신경망에 비하여 많다. 이에 따라서 학습시간도 급격히 증가한다. 본 연구에서 학습 속도를 개선하는데 사용된 방법은 다음과 같다^{[12]~[16]} [17].

(1) 오류 역전파시에는 첫번째 온너층의 오류를 계산할 때 순방향 진행시(forward pass) 연결되었던 모든 경우에 대하여 오류를 계산하여야 한다. 이때 두 번째 온너층에서 전달된 오류의 평균이 아닌 합을 사용

하여 오류계산에 드는 비용을 줄이고 학습시간을 줄였다.

(2) 두번째 온너층의 활성화된 값을 제곱하지 않고 단순히 합하여 출력층에 전달하였다.

(3) 매 입력 패턴마다 가중치를 조정하면 학습속도는 개선되지만 진동할 가능성이 있고, 가중치 조정을 위한 부가적인 계산이 필요하다. 따라서 무작위로 입력 패턴을 배열하고 모든 입력 패턴을 적용한 후 가중치 조정 간격을 점차 늘려갔다.

(4) 시간지연 신경망에 입력되는 입력벡터의 각 에너지값을 $-1.0 \sim 1.0$ 이 되도록 정규화하였다.

(5) 에러가 E_{MIN} 이하인 입력 패턴에 대해서는 학습을 생략하였다.(본 연구에서 사용한 E_{MIN} 값은 0.001이다.)

(6) 학습률(learning rate) η 는 학습이 진행됨에 따라서 0.01~0.1사이에서 동적으로 변경된다.

(7) 모멘텀(momentum) α 는 학습이 진행됨에 따라서 0.1~0.9 사이에서 동적으로 변경된다.

V. 실험 결과

1. 인식 결과

그림 3과 그림 4는 각각 기존의 음소인식 계충구조 TDNN과 본 논문에서 제안한 변이음단위 인식을 위해 구축한 계충구조 TDNN을 나타낸다.

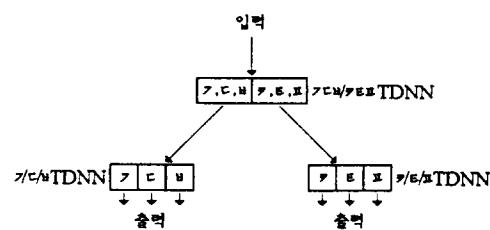


그림 3. 음소인식을 위한 계충구조 TDNN

Fig. 3. Hierarchical TDNNs for phoneme-based recognition.

두 계충구조 TDNN에서 사용된 음소군 분류 TDNN, 음소 인식 TDNN, 변이음군 분류 TDNN, 그리고 변이음 인식 TDNN의 인식률은 표 4와 표 5에 나타내었다. 생성된 변이음 데이터 750 개중 절반은 학습에 사용하였으며, 학습에 사용되지 않은 나머지 절반의 데이터를 인식 실험을 위해 사용하였다. ‘ㄱ’, ‘ㄷ’, ‘ㅂ’, ‘ㅋ’, ‘ㅌ’, ‘ㅍ’을 분류해내는 음소인식 계충구조 시간

지연 신경망을 그림 3과 같이 구축하고 인식 실험한 결과 전체 파열음에 대해 81.07%의 인식률을 얻었다. 본 연구에서 제안한 변이음단위 인식을 위하여 구성한 계층구조 시간지연 신경망을 그림 4와 같이 구축하고 인식 실험한 결과 전체 파열음에 대해 79.07%의 인식률을 얻었다.

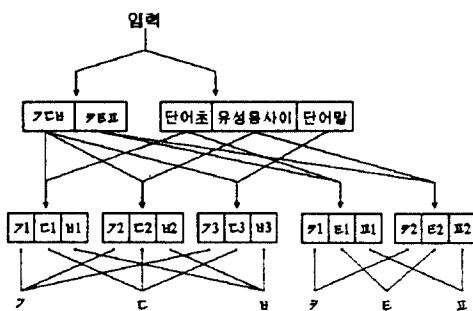


그림 4. 변이음 인식을 위한 계층구조 TDNN
Fig. 4. Hierarchical TDNNs for allophone-based recognition.

두 계층구조 TDNN에서 모두 사용된 유성음과 무성음을 분류 하는 ㄱㄷㅂ/ㅋㅌㅍ TDNN에서 전체 인식률을 저하시키는 대부분의 인식 오류가 발생함을 알 수 있다.

표 4. 음소 인식 오류 갯수와 음소 인식률
Table 4. Error rates and recognition performance of phoneme-based recognition.

TDNN 종류	인식오류 갯수 / 입력데이터 갯수	인식률 (%)
ㄱㄷㅂ/ㅋㅌㅍ	48 / 375	87.20
ㄱ/ㄷ/ㅂ	19 / 225	91.56
ㅋ/ㅌ/ㅍ	13 / 150	91.33
합계	71 / 375	81.07

그 이유를 살펴보면, 'ㄱ'의 변이음인 /k/(예: '갈')과 'ㅋ'의 변이음 /kh/(예: '칼')과 같이 동일 화자가 발음하더라도 스펙트로그램 등의 음향음성학적 특징이 거의 구별할 수 없을 만큼 유사하여 유성음/무성음 분류기(ㄱㄷㅂ/ㅋㅌㅍ TDNN)에서 초성 파열음이 오인식되는 경우가 많기 때문이다. 이와 같은 현상은 음소 단위 인식과 변이음단위 인식에서 모두 발생되는 문제로서 상위 인식기의 오류를 근본적으로 줄여야 해결될 수 있다^[17].

전체 인식률에서는 음소단위 인식이 변이음 인식보

다 약간 더 나은 성능을 보였지만, 하위 인식기에서의 성능은 오히려 변이음단위 인식이 우수함을 알 수 있다. 즉 변이음단위 인식 TDNN의 5 개 하위 인식기에서 발생한 오류 갯수는 24 개로서 음소단위 인식 TDNN의 두 하위 인식기에서 발생한 오류 갯수 32 개 보다 적다. 이것은 음소단위 인식의 문제점인 조음결합 현상에 의해 발생했던 오류가 변이음단위 인식에서는 발생하지 않았기 때문이다. 또한 음소단위 인식 TDNN에서는 유/무성음 인식기에서 주로 발생하는 오류("가다"에서 'ㄱ'을 'ㅋ'으로 오인식)들이 하위인식 기에서도 대부분 인식되지 않지만, 변이음단위 인식 TDNN의 하위인식기에서는 올바르게 인식("가다"에서 'ㄱ'을 초성의 'ㄱ'으로 인식)될 수 있다.

표 5. 변이음 인식 오류 갯수와 변이음 인식률
Table 5. Error rates and recognition performance of allophone-based recognition.

TDNN 종류	인식오류 갯수 / 입력데이터 갯수	인식률 (%)
단어초/유성음사이/단어말	21 / 375	94.40
ㄱㄷㅂ/ㅋㅌㅍ	48 / 375	87.20 (위와 동일)
ㄱ/ㄷ/ㅂ	7 / 75	90.67
ㄱ/ㄴ/ㅂ	4 / 75	94.67
ㄱ/ㄷ/ㅂ	2 / 75	97.33
ㅋ/ㅌ/ㅍ	6 / 75	92.00
ㅋ/ㅌ/ㅍ	5 / 75	93.33
합계	78 / 375	79.20

변이음단위 인식의 성능을 보다 향상시키려면, 음소의 단어내 위치 뿐만 아니라 운율, 억양, 강세와 같은 보다 많은 변이 요소를 고려하고 이것을 분류하는 인식기를 추가하는 것이 필요하다.

2. 변이음 인식 결과를 이용한 음성인식기의 후처리 방법^[18]

'아버지가방에 들어가신다.'라는 문장이 입력되었을 때, '가방'의 /ㄱ/과 /ㅂ/이 위의 변이음 군 중 제 1 변이음 또는 제 2 변이음으로 적절히 분류된다면, 구문적인 파싱(parsing)이 가능해진다. 먼저, /ㄱ/이 제 2 변이음, /ㅂ/이 제 1 변이음으로 인식되었다면, 위 문장은 '아버지가 방에 들어가신다.'라는 명확한 의미를 가진 문장으로 해석될 수 있다. 반면에, /ㄱ/이 제 1 변이음, /ㅂ/이 제 2 변이음으로 인식되었다면, 위 문장은 '아버지 가방에 들어가신다.'라는 문장으로 분석되고 위의 첫번째 문장과는 전혀 다른 의미로 해석될 것이다. 이처럼 변이음 인식 결과는 음소인식에서는

기대할 수 없는 유익한 정보까지도 출력하므로 부가적인 잇점이 있다.

VI. 결론 및 추후 연구 과제

본 논문에서는 연속음성인식에서 음소를 기본 인식 단위로 할 때 발생하는 조음결합현상을 극복하는 방법으로서 변이음단위로 인식하는 것을 제안하였다. 그리고 음소의 모든 변이음을 고려하고 서로 유사한 변이음을 통합·분류하여 인식단위로 사용하였다.

일반 계층 신경망보다 연结이 많은 시간지연신경망을 이용하여 모든 음소(또는 변이음)을 인식하는 단일구조 신경망을 구성하여 학습시키기는 거의 불가능 하므로, 각각 서로 다른 분류기능을 갖는 소규모 시간지연 신경망을 따로 학습시킨 후, 계층적으로 통합하여 전체 한국어 인식을 위한 시간지연 신경망을 구성하였다.

변이음단위 인식과 음소단위 인식의 성능을 비교하기 위해 한국어의 6 가지 파열음에 대한 인식실험을 하였으며, 각각 79.20%와 81.07%의 성능을 나타내었다. 이것은 상위 계층의 오류가 그대로 하위 계층 오류되어 발생된 결과이다. 그러나, 하위 인식기들의 성능만을 비교하면 변이음단위 인식이 음소단위 인식보다 적은 오류를 나타낸다를 확인하였다. 이와 같은 결과는 음소단위인식에서 문제가 되는 조음결합현상이 변이음단위 인식에서는 나타나지 않았음을 나타낸다. 또한 변이음단위 인식에서 출력 결과로 나오는 변이음 열은 음운·파상에 이용될 수 있는 정보를 제공해 주는 부가적인 잇점이 있다.

계층구조 시간지연 신경망의 상위 계층 오류를 하위 계층에서 검출해 내는 방법을 찾는다면 음소 또는 변이음 인식 계층구조 시간지연 신경망의 성능 향상이 가능하다. 또한 운율, 억양, 강세 등의 보다 많은 변이오소를 고려한다면 인식성능 향상과 함께 출력된 변이음 열이 갖고 있는 유익한 정보를 이용할 수 있다.

참 고 문 현

- [1] 김기호, “음성인식과 합성에 있어서의 음성학과 음운론의 역할”, 제1회 음성학 학술대회 자료집, pp. 125-144, 1994년 2월
- [2] 윤종관, 연속 음성 인식 시스템의 개발 연구, 제1차년도 최종보고서, 한국과학기술원, 1992년

12월

- [3] J. Mariani, “Recent Advances in Speech Processing”, Proceedings of ICASSP, pp. 429-440, May 1993.
- [4] Kai-Fu Lee, “Context-Dependent Phonetic Hidden Markov Models for Speaker-Independent Continuous Speech Recognition”, IEEE Trans. ASSP, vol. 38, no. 4, pp. 599-609, April 1990.
- [5] Hsiao-Wuen Hon, Kai-Fu Lee, “On Vocabulary-Independent Speech Modeling”, Proceedings of ICASSP, pp. 725-728, April 1990.
- [6] Kai-Fu Lee et al., “Allophone Clustering for Continuous Speech Recognition”, Proceedings of ICASSP, pp. 749-752, April 1990.
- [7] 유통석, 한국어 음소 인식을 위한 시간지연 신경망의 확장에 관한 연구, 석사학위논문, 고려대학교, 1992
- [8] Hidefumi Sawai et al., “Parallelism Hierarchy, Scaling in Time-Delay Neural Networks for Spotting Japanese Phonemes/ CV-Syllables”, Proceedings of IEEE International Joint Conference on Neural Networks, vol. 2, pp. 81-88, June 1989.
- [9] Chin-Hui Lee, Lawrence R. Rabiner, “Automatic Speech Recognition-Current State and Future Directions”, Proceeding of ATR International Workshop on Speech Translation, 1993.
- [10] Alex Waibel et al., “Phoneme Recognition Using Time-Delay Neural Networks”, IEEE Trans. ASSP, vol. 37, no. 3, pp. 328-339, March 1989.
- [11] Richard P. Lippmann, “An Introduction to Computing with Neural Nets”, IEEE ASSP Magazine, pp. 4-22, April 1987.
- [12] D. E. Rumelhart et al., “Learning Internal Representations by Error Propagation” in D. E. Rumelhart et al., Parallel Distributed Processing: Explorations in the Microstructure of Cognition, vol. 1, pp. 318-362, MIT Press, 1986.

- [13] Alex Waibel et al., "Modularity and Scaling in Large Phonemic Neural Networks", IEEE Trans. ASSP, vol.37, no. 12, pp.1888-1898, December 1989.
- [14] S. Furui, Digital Speech Processing, Synthesis, and Recognition, Marcel Dekker, p. 232, 1991.
- [15] D.O'Shaughnessy, Speech Communication, Addison-Wesley Publishing Company, p. 141, 1990.
- [16] P. Haffner et al., "Fast Back-Propagation Learning Methods for Neural Networks in Speech", Technical Report TR-I-0058, ATR Interpreting Telephone Research Laboratories, November 1988.
- [17] Kevin J. Lang et al., "A Time-Delay Neural Network Architecture for Isolated Word Recognition", Neural Networks, vol. 3, pp. 23-43, 1990.
- [18] 구명완, "음성인식 기술의 현황과 전망", 정보과학회지, 제11권 제5호, pp. 21-34, 1993년 10월

저자 소개



金秀一(正會員)

1992年 2月 고려대학교 정보공학과 졸업(학사). 1994년 8월 고려대학교 전산과학과 졸업(석사). 1994년 9월 ~ 현재 삼성 종합기술원 연구원



林海彰(正會員)

1979년 2월 고려대학교 독어독문 학과 학사. 1983년 12월 Missouri 주립대학 전산학 석사. 1990년 12 월 Texas 주립대학 전산학 박사. 1991년 ~ 현재 고려대학교 전산 과학과 부교수. 관심분야는 자연어 처리, 정보검색, 인공지능