

문법적 제약을 이용한 연속음 인식의 성능 향상

Improvement of Connected Word Recognition using Grammatical Constraint

함정표, 양태영, 신원호, 이충용, 차일환

연세대학교 신자공학과

Jeong-Pyo Ham, Tae-Young Yang, Won-Ho Shin, Chungyong Lee, Il-Whan Cha

Dept. of Electronic Engineering Yonsei University

< 본 논문은 한국통신 연구개발본부의 1998년도 수탁과제연구 지원에 의한 결과입니다. >

요약

연속음 인식에서 인식 대상이 가지는 규칙을 적용했을 경우 성능 향상을 가져올 수 있다. 본 논문에서는 연속음 중에서 연결 숫자음을 인식 대상으로 하는 음성 인식 시스템의 성능 향상을 위하여 프레임 동기 네트워크(Frame Synchronous Network)을 이용하였다. 연결 숫자음이 가지는 반복적인 특성과 자릿수의 상하 관계가 인식 성능에 미치는 효과를 이용하여 다양한 수준의 제약을 갖는 FSN을 제안하였다. 본 논문에서는 연속 숫자음 중에서 금액을 대상으로 인식 결과 제안된 FSN을 이용하여 금액 어휘의 인식 성능을 향상시킬 수 있었다.

I. 서 론

인결음은 몇 개의 단독음이 연결된 형태로 모델링 할 수 있다. 이러한 연결음(connected word)의 경우는 인식 대상 연결음 문장이 몇 개로 이루어져 있으며, 구성하는 단독음 단위들이 아니라에서 상계를 이루며 어떤 단어들로 이루어져 있는가 하는 문제를 해결해야 한다. 이러한 문제들을 해결하기 위해서 two level 알고리즘[1], level building 알고리즘[2], one path 알고리즘[3] 등이 있다. 이 중에서 one path 알고리즘은 입력 프레임에 동기적(synchronous)으로 구현할 수 있을 뿐만 아니라, 적은 계산량으로 처리할 수 있어서 매우 우수한 알고리즘이라고 할 수 있다.

본 논문에서 사용된 인식 숫자음 중의 하나인 금액은 특성한 규칙을 가지고 발음되고 이것을 이용하여 인식률을 향상 시킬 수 있다. 이러한 문법적 특징을 구조적으로 시연 문장을 모델링하는 방법으로 FSN이 있다. 본 논문에서는 금액 인식을 위하여 연결음 인식 대상 중에 하나인 금액에 문법적 특성을 분석하고, 분석된 규칙을에 적합한 형태의 FSN을 제안하여 인식률 향상

을 목표로 하였다.

II. 금액의 문법적 특징 분석

모든 금액 문장은 단위 다음에 숫자가 나오는 형태로 구성되고, 이들은 번갈아 나타난다. 먼저 단위에 대하여 살펴보면, 단위로 사용되는 단어는 다음의 것들이 있다. (/억/, /만/, /천/, /백/, /십/, /원/).

단위는 크게 두 가지로 분류된다. 첫째는 4 자리 숫자마다 반복되어 만 자리씩 끊어주는 /억/, /만/ 등의 '만 단위'이나, 둘째는 '만단위' 사이에서 자릿수를 표기하는 /천/, /백/, /십/의 '자리 단위'가 있다. '만단위' 끼리와 '자리 단위' 끼리는 서로 순서가 바뀌어서 나올 수 없다. 즉, /억/ > /만/이고, /천/ > /백/ > /십/으로 서로 크기 관계가 있으며, 이 순서가 바뀌어 나오는 문장을 문법적으로 잘못된 문장이 된다. 또한 특수한 단위로 /원/이 있다. /원/은 모든 금액 문장의 끝에 붙어 나오는 것으로 금액임을 표시한다. /원/의 경우 '만단위'의 하나로 가장 가치가 작은 것으로 해석하여 일반화 할 수 있다.

숫자는 다음의 아홉 가지 발음을 인식 대상으로 한다. (/영/, /이/, /삼/, /사/, /오/, /육/, /칠/, /팔/, /구/). 특수한 숫자로서 표기할 때 '0' (=영/ 혹은 공/)은 표기되지만 발음되지 않는다. 또한, 특수한 숫자로 '1' (=일/)이 있다. /일/이 경우 '자리단위' 앞에서는 발음되지 않으며 4 자리마다 반복되는 '만단위' 앞에서만 발음된다. 하지만, 가장 앞에 오는 /일/은 '만단위' 앞이라 하더라도 일반적으로 발음되지 않는다. 혹은 발음하는 경우도 있지만 /만/의 경우 주로 발음되지 않고 /억/의 경우는 발음된다.

III. 제안된 FSN


인식 고장한 금액의 문법 구조를 이용하여 다음의

세 가지 유형의 FSN을 제안한다. 이들은 각기 다른 정도의 문법적 제한 사항을 두는 점에 차이가 있다. 문법적인 제약이 작은 순서대로 FSN0, FSN1, FSN2라고 한다.

FSN의 호를 이루는 인식 대상 단어들을 각각 하나의 아산 HMM으로 구성하였다[6]. 이들은 숫자 집합과 단어 집합의 합집합이다. 그리고, 단어 사이에 포함되는 묵음을 적절히 표현하기 위하여 묵음 모델을 하나 추가하였다. { /억/, /만/, /천/, /백/, /십/, /원/, /일/, /이/, /삼/, /사/, /오/, /육/, /칠/, /팔/, /구/, '묵음' } 앞에 수록된 단어 모델들은 네트워크의 설계 사이를 잇는 호로 사용되며 대부분 숫자는 병렬로 사용된다.

1. FSN0

제안된 FSN 중에서 가장 문법적인 제한을 두고 있지 않은 유형으로 FSN0을 아래 그림 1에서 볼 수 있다. FSN0은 무한 개수의 숫자와 단위가 무작위로 섞인 인식 결과가 나올 수 있다. 즉, 일의의 개수를 가지는 단위와 숫자의 조합을 인식할 수 있지만, 숫자나 단위만 연속적으로 인식된다든지 혹은 낮은 단위가 높은 단위보다 먼저 나오는 결과 같은 문법적인 오류가 있는 문장이 결과로 나올 수도 있다.



2. FSN1

FSN1을 제안하기 전에 먼저 sub-FSN을 정의 한다. 단어 모델 뿐만이 아니라 다른 FSN 또한 그보다 높은 단계 FSN의 호로 사용할 수 있다. 한 단계 아래에서 다른 FSN의 부분을 이룬다고 하여 sub-FSN이라고 부른다. 문법적으로 '만단위'와 '자리 단위' 중에서 '만단위' 앞에서만 나오는 특수한 숫자인 '1'을 FSN에서 표현할 때, 편의를 위해 다음의 두 가지 sub-FSN을 정의 한다. '1'을 포함하여 null arc가 없는 '숫자 1' FSN과, '1'을 표현하지 않고 1 대신 null arc를 포함하는 '숫자 2' FSN을 정의한 그림이 아래 그림 2와 그림 3에 있다.

'숫자 1'은 단어 모델 '1', '2', '3', ..., '9'가 병렬로 양쪽 노드에 연결되어 같은 위치에서 인식될 수 있는 숫자를 표현하고 있는 형태이다. '숫자 2'는 '1' 대신 null arc가

병렬로 연결되어 '1'이 인식되는 경우는 '1'이 발음되지 않는 경우의 문법적인 특성을 고려한 형태이다. 앞서 글액의 문법적인 특성을 살펴본 바와 같이 '숫자 1' 네트워크는 '만단위' 앞에 있고 '숫자 2' 네트워크는 '자리 단위' 앞에 온다.






그림 4는 '만단위'마다 반복되는 글액의 특성을 이용하여 제안된 'FSN1'이다. 이것은 FSN0에 비교하여 발생할 수 있는 문법적인 오류를 많이 제한한다. '만단위' 사이에는 루프를 두어 '숫자 + 자리단위'의 구조가 반복되는 것을 이용하였다. 따라서, 숫자나 단위만 반복해서 인식 결과가 될 수 있는 오류를 막았다. '만단위'마다 인접된 null arc는 죄고 자리가 어느 만 단위에 속해 있는지 알 수 없기 때문에 연결되었다. 곧, 죄고 자리가 '수 백만'이면, 최적 경로는 앞의 '억'으로 올라가는 만 단위는 null arc를 통해 뛰어넘게 된다. 이와 같이 FSN은 인식 구조만으로 문법을 구현함으로써 인식률의 향상을 가져올 수 있다. FSN1 역시 많이 제한되었지만 '자리단위'의 상하 관계에서 문법적 오류가 발생할 수 있다. 예를 들어, '수백 수천 수십'으로 인식된 결과가 출현될 수 있다.

3. FSN2

FSN2를 정의하기 전에 subnet(x)를 정의한다. FSN1에서 만 단위 사이의 루프를 펼쳐서 하나의 네트워크로 구성한 것을 subnet(x)로 정의한다. 변수 x는 입의 '만단위'가 대치하게 된다. 어느 자리에서 시작하는 자

모로며, 중간에 '0'이 있는 자리는 단위까지 모두 발음이 되지 않으므로 모두 null arc로 연결하여 다른 절점으로 중간 호를 거치지 않고 천이할 수 있도록 하여, '수천 수십'과 같이 중간에 '수백'이 '0'에 의해 생략된 경우를 표현할 수 있도록 하였다. subnet(x)는 '자리단위'가 일렬로 연결된 형태이므로, 상하 관계에 따른 인식 결과의 오류는 발생할 수 없다.

그림 5에 subnet(x)의 구조가 나타나 있다.




그림 5. subnet('만단위')의 구조

그림 6에는 subnet(x)을 이용하여 FSN2를 정의하였다. FSN2는 앞 절에 기록한 글액의 모든 문법적인 구조를 활용하여 문법적인 오류를 가지는 결과는 출력될 수 없으며, 오류가 없는 후보를 대상으로 인식하게 되므로 세 가지 네트워크 중에서 가장 높은 인식률을 보이며 된다. '만단위'마다 규칙적인 subnet(x)이 반복적으로 나타나며, FSN1과 같이 자릿수 시작을 임의의 위치에서 가능하도록 하기 위하여 null arc를 두었다.




그림 6. 'FSN2'의 구조

IV. 실험 및 결과

실험에 사용되는 데이터 베이스를 구축하기 위하여 남녀 모두 50명을 대상으로, 각각 한 명의 화자가 40개의 글액 문장을 발음하였다. 이중에서 남녀 각 20명은 모두 40명이 만유한 문장을 하습 데이터 베이스로 사용하고, 나머지 10명의 문장을 서립 데이터 베이스로 사용하였다. 글액은 절의 단위까지 인식이 가능하도록 수집되었으며, 발음되는 문장을 64자씩 모두 비슷한 횟수로 변환화해 하였으며, 모든 경우가 포함될 수 있도록 일의적으로 구성되었다. 아래 표 1에 데이터 베이스의 구성이 요약되어 있다.

표 1. 데이터 베이스의 구성 요약

인식 어휘	한국어 글액, 최고 단위 수 천억
샘플링 방법	16bit Linear PCM, 11.025 kHz sampling
학습 데이터	30대 남녀 각 20명 (총40명), 1인당 40문장
시험 데이터	20대 남녀 각 5명 (총10명), 1인당 40문장

실험에 사용되는 음성 신호는 11.025 kHz로 표본화되고 $1 - 0.95 z^{-1}$ 의 전달 함수를 갖는 프리엔페시스 필터를 사용하여 고역을 강조한다. 신호의 분석은 매 10ms마다 20ms에 해당하는 220 샘플의 길이를 갖는 해밍 윈도우(hamming window)를 사용하여 수행되었다 [7]. 멜 캡스토럼(MFCC)과 루트 멜 캡스토럼(R_MFCC)의 경우 각 음성 프레임마다 1024 point FFT를 사용하였다[5]. 캡스토럼이 구해지면 동적 특성을 이용하기 위하여 델타 캡스토럼을 구하여 사용하였다. 에너지에 대하여도 동일한 방법을 취하여 각각 델타 에너지와 델타 델타 에너지를 구하여 함께 사용하였다. 앞으로 캡스토럼 반을 사용하여 모두 12 차의 특징 벡터를 사용한 경우를 cep이라고 표시하고, 캡스토럼과 델타 캡스토럼 함께 사용하여 모두 24 차를 사용한 경우를 cep+d_cep이라고 표시하며, 캡스토럼, 델타 캡스토럼, 델타 에너지, 그리고 델타 델타 에너지를 함께 사용하여 모두 26 차의 특징 벡터를 사용한 경우를 cep+d_cep+eng라고 표기한다.

본 논문에서 사용된 음성 분석 방법 및 특징 벡터를 정리하면 다음 표 2와 같다.

표 2. 음성 분석 방법 및 특징 벡터

Pre-Emphasis	$1 - 0.95 z^{-1}$
Window Size	220 samples (20ms)
Shift Size	110 samples (10ms)
Window	Hamming Window
FFT Size	1024
mel 뱅크 수	22
특징 벡터	캡스토럼 (12차)
	델타 캡스토럼 (12차)
	델타 에너지+델타델타 에너지 (2차)

제안된 FSN을 이용하여 인식 대상인 글액의 유저에 의한 성능을 평가하기 위하여 LPCC, MFCC, 그리고 R_MFCC의 세 가지 특징 벡터를 대상으로 FSNO, FSN1, FSN2를 사용하여 각각 실험하였다. 아래 그림에서 그림 7은 특징 벡터로 캡스토럼만 사용한 경우이다. 그림 8은 캡스토럼과 델타 캡스토럼을 특징 벡터로 사용하고,

그림 9는 캡스트럼, 멜타 캡스트럼, 그리고 멜타 에너지와 멜타 멜타 에너지 까지 모두 사용한 결과이다.

결과에서 볼 수 있듯이 문법적 제약이 많을수록 성능이 보다 향상되는 것을 알 수 있다. 특히 금액의 반복적인 규칙을 사용하는 경우 아무 것도 사용하지 않는 경우보다 성능이 많이 향상된다. 사릿수에 의하여 상하 관계가 생기는 규칙까지 사용한 경우는 성능이 더욱 향상되어 아무 문법도 사용하지 않은 경우와 최고 30%의 성능 개선을 관찰할 수 있다.




그림 7. FSN에 따른 성능 비교(cep)




그림 8. FSN에 따른 성능 비교(cep+d_cep)




그림 9. FSN에 따른 성능 비교(cep+d_cep+eng)

또한 특징 벡터를 많이 사용할수록 성능이 좋아지게 결과를 관찰할 수 있다. 특징 벡터를 많이 사용할수록

성능이 좋아지는 것은 문법이 약한 경우 두드리자체 나타난다. FSN2의 경우는 특징 벡터를 많이 사용하여 인식률이 향상되는 폭이 FSN0나 FSN1과 비교하여 작다.

V. 결론

본 논문에서는 금액의 반복적인 규칙과 상하 관계의 규칙을 이용하여 인식 성능 향상을 연구하였다. 여러 가지 종류의 특징 벡터와 멜타 캡스트럼과 멜타 에너지, 멜타 멜타 에너지를 함께 사용한 경우를 대상으로 실험한 결과, 모든 경우에서 문법 제약은 인식 성능을 향상시키는 결과를 얻었다. 그 중에서도 FSN1을 통하여 문법적인 규칙을 일부만 사용하여서도 인식 성능 향상을 얻을 수 있었다. 최대 성능 향상은 LPCC를 특징 벡터로 캡스트럼만 사용한 경우 문법을 사용하지 않는 50.53%에서 모든 문법을 사용하는 85.42%로 약 30% 이상 성능 향상이 있었다.

참고 문헌

- [1] H. Sakoe, "Two Level DP Matching - A Dynamic Programming-Based Pattern Matching Algorithm for Connected Word Recognition," IEEE Trans. on Acoust., Speech, and Signal Processing, vol. ASSP-27, no. 6, Dec. 1979.
- [2] C. S. Myers and L. R. Rabiner, "A Level Building Dynamic Time Warping Algorithm for Connected Word Recognition," IEEE Trans. on Acoust., Speech, and Signal Processing, vol. ASSP-29, no. 2, April 1981.
- [3] H. Ney, "The Use of a One-Stage Dynamic Programming Algorithm for Connected Word Recognition," IEEE Trans. on Acoust., Speech., and Signal Processing, vol. ASSP-32, no. 2, Apr. 1984.
- [4] C. H. Lee, and L. R. Rabiner, "A Frame-Synchronous Network Search Algorithm for Connected Word Recognition," IEEE Trans. on Acoust., Speech, and Signal Processing, vol. 37, no. 11, Nov. 1989.
- [5] L. R. Rabiner and B. H. Juang, *Fundamentals of Speech Recognition*, Prentice Hall, 1993.
- [6] X. D. Huang, Y. Ariki and M. A. Jack, *Hidden Markov Models for Speech Recognition*, Edinburgh University Press, 1990.
- [7] E. C. Heachor and B. W. Jervis, *Digital Signal Processing*, Addison-Wesley Publishing Company Inc., 1993.