

FSN 을 이용한 금액 인식 시스템

함정표, 신원호, 이충용, 윤대회, 차일환
연세대학교 전자공학과

Price Recognition System using FSN

Jeong-Pyo Ham, Won-Ho Shin, Choongyong Lee, Dae-Hee Youn, Il-Whan Cha

Dept. of Electronic Eng. Yonsei Univ.

e-mail : jpham@radar.yonsei.ac.kr

요 약

본 논문에서는 금액을 인식 대상으로 하는 음성 인식 시스템의 성능 향상을 위하여 프레임 동기 네트워크(Frame Synchronous Network)를 이용하였다. 연속음 인식에서 인식 대상이 가지는 규칙을 적용했을 경우 성능 향상을 기대할 수 있다. 금액이 가지는 반복적인 특징과 자릿수의 상하 관계가 인식 성능에 미치는 효과를 이용하여 다양한 수준의 제약을 갖는 FSN을 제안하였다. 제안된 FSN의 성능을 다양한 환경과 특징 벡터에 대하여 이산 hidden Markov model(S)을 이용하여 실험을 수행하였다. 인식 결과 제안된 FSN을 이용하여 금액 어휘의 인식 성능을 향상시킬 수 있었다.

1. 서 론

본 논문에서 사용되는 금액과 같은 인식 대상을 몇 개의 단독음이 연결된 형태로 모델링할 수 있다. 이러한 연결음(connected word)의 경우는 인식 대상 인접음 분장이 몇 개로 이루어져 있으며, 구성하는 단독음 단어들이 어디에서 경계를 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, 작은 계산량으로 처리할 수 있어서 매우 우수한 알고리즘이라고 할 수 있다.

본 논문에서 사용된 금액은 특정한 규칙을 가지고 반복되고 이것을 이용하여 인식률을 향상시킬 수 있다. 첫번째 나오는 단어가 몇몇한 화자를 이용하는 bi-gram 등이 그러하다. 이러한 문법적 특징을 구조적으로 지원 분장을 모델링하는 방법으로 FSN(Frame Synchronous Network)이 있다. 본 논문에서는 금액 인식을 위하여 인접음 인식 대상 중에 하나의 금액의 문법적 특징을 명확하고, 분산된 규칙들에 결합된 형태의 FSN을 제안하여 인식률 향상을 목표로 하였다.

2. 금액의 문법적 특징 분석

모든 금액 문장은 단위와 숫자로 구성되고, 이들은 번갈아 나타난다. 금액을 구성하는 단위와 숫자는 각각 독특한 문법적인 특징을 지니고 있다.

먼저 단위에 대하여 살펴보면, 단위로 사용되는 단위는 다음의 것들이 있다. /경/, /조/, /억/, /만/, /천/, /백/, /십/, /원/. 하지만, 실험에 사용된 시스템의 최고 인식 단위는 수 천원으로, 만의 집합에서 /경/, /조/는 인식 대상에 포함되지 않는다고 가정한다.

단위는 크게 두 가지로 분류된다. 첫째는 4 자리 숫자마다 반복되어 한 자리씩 끊어주는 /억/, /만/ 등의 '만 단위'이다. 이 '만 단위' 사이에 오는 구조인 '수천 수백 수십 수'는 모든 만 자리마다 동일하게 반복된다. 둘째는 '만 단위' 사이에서 자릿수를 표기하는 /천/, /백/, /십/의 '자리 단위'가 있다. '만 단위' 끼리와 '자리 단위' 끼리는 서로 순서가 바뀌어서 나올 수 없다. 즉, /억/ > /만/ 이고, /천/ > /백/ > /십/ 으로 서로 큰 관계가 있으며, 이 순서가 바뀌어 나오는 문장은 문법적으로 잘못된 문장이 된다. 그러나, '만 단위'와 '자리 단위' 사이에서는 서로 섞여 나오는 것이 문법적으로 잘못된 문장은 아니다. 이것은 문법적인 오류를 말하는 것이지 인식된 결과가 정확하다는 것을 뜻하진 않는다. 또한 특수한 단위로 /원/이 있다. /원/은 모든 금액 문장의 끝에 붙어 나오는 것으로 금액임을 표시한다. /원/의 경우 '만 단위'의 하나로 가장 가치가 작은 것으로 해석하여 일반화할 수 있다.

숫자는 다음의 여덟 가지 발음을 인식 대상으로 한다. /일/, /이/, /삼/, /사/, /오/, /육/, /칠/, /팔/, /구/. 숫자를 표기할 때 '0' (= /영/ 혹은 /영/)은 표기되지만 일반적으로 금액에서 발음되지 않고 강조하는 경우에만 발음된다. 본 논문에서 구현한 시스템에서는 발음되지 않는 것을 원칙으로 한다. 특수한 숫자로 '1' (= /일/)이 있다. /일/의 경우 '자리 단위' 앞에서는 발음되지 않으며 4 자리마다 반복되는 '만 단위' 앞에서는 발음된다. 하지만, 가장 앞에 오는 /일/의 '만 단위' 앞이라 하더라도 일반적으로 발음되지 않는다. 혹은 발음하는 경우도 있지만

/만/의 경우 주로 발음되지 않고 /억/의 경우는 발음된다.

3. 제안된 FSN

앞서 고찰한 금액의 문법 구조를 이용하여 다음의 세 가지 유형의 FSN 을 제안한다. 이들은 각각 다른 정도의 문법적 제한 사항을 누는 점에 차이가 있다. 문법적인 제약이 작은 순서대로 FSN0, FSN1, FSN2 라고 한다.

FSN 의 호를 이루는 인식 대상 단어들을 각각 하나의 어산 HMM 으로 구성하였다[7]. 이들은 숫자 집합과 단어 집합의 합집합이다. 그리고, 단어 사이에 포함되는 묵음을 식별하기 위하여 묵음 모델을 하나 추가하였다. [/억/, /만/, /천/, /백/, /십/, /원/, /일/, /어/, /삼/, /사/, /오/, /육/, /칠/, /팔/, /구/, '묵음'] 앞에 수록된 단어 모델들은 네트워크의 설삼 사이를 잇는 호로 사용되며 대부분 숫자는 병렬로 사용된다.

3.1 FSN0

제안된 FSN 중에서 가장 문법적인 제한을 두고 있지 않은 유형으로 FSN0 을 아래 그림 1에서 볼 수 있다. One path 알고리즘과 동일한 기능을 하는 FSN 으로 무한 개수의 숫자와 단위가 무작위로 섞인 인식 결과가 나올 수 있다. 즉, 임의의 개수를 가지는 단위와 숫자의 조합을 인식할 수 있지만, 숫자나 단위만 연속적으로 인식된다든지 혹은 낮은 단위가 높은 단위보다 먼저 나오는 것과 같은 문법적인 오류가 있는 문장이 결과로 나올 수도 있다.



그림 1. 'FSN0'의 구조

3.2 FSN1

FSN1 을 제안하기 전에 먼저 sub-FSN 을 정의 한다. 단어 모델 뿐만이 아니라 다른 FSN 또한 그보다 높은 단계 FSN 의 호로 사용할 수 있다. 한 단계 아래에서 다른 FSN 의 부분을 이룬다고 하여 sub-FSN 이라고 부른다. 문법적으로 '만단위'와 '자리 단위' 중에서 '만단위' 앞에서만 나오는 특수한 숫자인 '0'을 FSN 에서 구현할 때, 편의를 위해 다음의 두 가지 sub-FSN 을 정의 한다. 이를 포함하여 null arc 가 없는 '숫자1' FSN 과, 0 을 표현하지 않고 1 대신 null arc 를 포함하는 '숫자2' FSN 을 정의한 그림이 아래 그림 2와 그림 3에 있다. '숫자1'은 단어 모델 '1', '2', '3', ... '9'가 병렬로 합쳐져서 연결되어 같은 위치에서 인식될 수 있는 숫자를 표현하고 있는 형태이다. '숫자2'는 1 대신 null arc 가 병렬로 연결되어 0이 인식되는 경우에는 0이 발음되지 않는 경우가 문법적인 특성을 고려한 형태이다. 앞의

금액의 문법적인 특성을 살펴본 바와 같이 '숫자1' 네트워크는 '만단위' 앞에 오고 '숫자2' 네트워크는 '자리 단위' 앞에 온다.




그림 2. Sub-FSN '숫자1'의 구조




그림 3. Sub-FSN '숫자2'의 구조

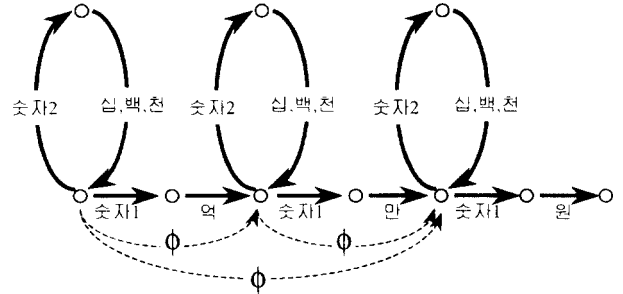


그림 4. 'FSN1'의 구조

그림 4는 '만단위'마다 반복되는 금액의 특성을 이용하여 제안된 'FSN1'이다. '숫자1'과 '숫자2'는 위에서 정의된 sub-FSN 을 의미한다. '십, 백, 천'은 단어 모델 '십', '백', '천'이 병렬로 구성된 호이다. 이것은 FSN0 에 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 연결된 null arc 는 최고 자리가 어딘지 만 단위에 속해 있는지 알 수 없기 때문에 연결되었다. 끝, 최고 자리가 '수 백만'이면, 최종 경로는 앞의 '억'으로 끝나는 만 단위는 null arc 를 통해 뒤어남게 된다. 이와 같이 FSN 을 연결 구조만으로 문법을 구현함으로써 인공물의 향상을 기대할 수 있다. FSN1 역시 많이 제한되었지만 '자리단위'의 상하 관계에서 문법적 오류가 발생할 수 있다. 예를 들어 '수백 수천 수십'으로 인식된 결과가 출력될 수 있다.

3.3 FSN2

FSN2 를 정의하기 전에 subnet(x)를 정의한다. FSN1 에서 만 단위 사이의 단위를 필자시 하나의 네트워크로 구성된 것을 subnet(x)로 정의한다. 변수 x는 임의의 '만단위'에 대치하게 된다. 어느 자리에서 시작하는 것 없이, 중간에 0이 있는 자리, 단위끼리 모두 병용이 되기 없으므로 모두 null arc 로 연결하여 다른 것

으로 중간 호를 거치지 않고 권이할 수 있도록 하여, '수천 수십'과 같이 중간에 '수백'이 '0'에 의해 생략된 경우를 표현할 수 있도록 하였다. subnet(x)는 '자리단위'가 알릴로 연결된 형태이므로, 상하 관계에 의한 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 금액의 모든 문법적인 구조를 활용하여 문법적인 오류를 가지는 결과는 출력될 수 없으며, 오류가 없는 후보를 대상으로 인식하게 되므로 세가지 네트워크 중에서 가장 높은 인식률을 보이기 된다. '만단위'마다 규칙적인 subnet(x)이 반복적으로 나타나며, FSN1과 같이 자릿수 시작을 일의의 위치에서 가능하도록 하기 위하여 null arc를 두었다. FSN2는 문법적인 제약이 제안된 네트워크 중에서 가장 심화적인 특징 벡터를 사용하더라도 높은 인식률을 보였다는 장점이 있다. 반면에 절점의 수가 증가하여 인식 과정에 수행 시간이 따라 증가한다는 단점이 있다.




그림 6. FSN2의 구조

4. 실험 및 결과

실험에 사용되는 데이터 베이스를 구축하기 위하여 남녀 모두 50명을 대상으로, 각각 한 명의 화자가 40개의 문맥 문장을 발음하였다. 이 중에서 남자는 20명씩 모두 40명이 발음한 문장을 학습 데이터 베이스로 사용하고, 나머지 10명의 문장을 시험 데이터 베이스로 사용하였다. 금액은 천의 단위까지 인하여 가능하도록 수집되었으며, 발음되는 문장은 숫자가 모두 비슷한 것으로 발음되게 하였으며, 모든 경우가 포함될 수 있도록 임의적으로 수집되었다. 아래 표에 데이터 베이스의 구성이 요약되어 있다.

표 1. 데이터 베이스의 구성 요약

인식 대상	금액의 문맥 (억, 천, 십, 수천)
발음의 방법	20Hz, 40Hz, 80Hz, 160Hz, 320Hz, 640Hz, 1280Hz
학습 데이터	남자 20명, 여자 20명, 총 40명 발음한 문장
시험 데이터	남자 10명, 여자 10명, 총 20명 발음한 문장

실험에 사용되는 음성 신호는 11.025 kHz로 표본화되고 $1 - 0.95z^{-1}$ 의 전달 함수를 갖는 프리엠퍼시스 필터를 사용하여 고역을 강조한다. 신호의 분석은 매 10ms마다 20ms에 해당하는 220 샘플의 길이를 갖는 해밍 윈도우(hamming window)를 사용하여 수행되었다 [8]. 멜 캡스트럼(MFCC)와 루트 멜 캡스트럼(R_MFCC)의 경우 각 음성 프레임마다 1024 point FFT를 통하여 멜 주파수 벡터로 변환한 후, 벡터별로 MFCC는 대수를 취하고 R_MFCC는 루트를 취한 값에 대하여 DCT를 하여 12개의 MFCC와 R_MFCC를 얻는다[6]. 캡스트럼이 구해지면 동작 특성을 이용하기 위하여 멜타 캡스트럼을 구하여 사용하였다. 원래 프레임을 중심으로 한 후, 각 2 프레임 간격에 대한 차분에 의하여 델타 캡스트럼 계수를 구하였다. 에너지에 대하여도 동일한 방법을 취하여 각각 델타 에너지와 델타 델타 에너지를 구하여 함께 사용하였다. 따라서 캡스트럼 값을 사용하여 모두 12개의 특징 벡터를 사용한 경우를 cep이라고 표시하고, 캡스트럼과 델타 캡스트럼 함께 사용하여 모두 24개의 특징 벡터를 사용한 경우를 cep+d_cep이라고 표시하며, 캡스트럼, 델타 캡스트럼, 델타 에너지, 그리고 델타 델타 에너지를 함께 사용하여 모두 26개의 특징 벡터를 사용한 경우를 cep+d_cep+eng라고 표시한다.

본 논문에서 사용된 음성 분석 방법 및 특징 벡터를 정리하면 다음 표와 같다.

표 2. 음성 분석 방법 및 특징 벡터

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

제안된 FSN을 이용하여 인식 대상인 금액의 규칙에 의한 성능을 평가하기 위하여 LPCC, MFCC, 그리고 R_MFCC의 세 가지 특징 벡터를 대상으로 FSN0, FSN1, FSN2를 사용하여 각각 실험하였다. FSN0은 금액의 문법을 사용하지 않는 경우이고, FSN1은 금액의 반복적인 규칙만을 사용한 경우이며, FSN2는 FSN1에 화자의 상하 관계 규칙까지 포함한 경우를 일컫을 수 있다.

그림 7은 특징 벡터로 캡스트럼만 사용한 경우이다. 그림 8은 캡스트럼과 델타 캡스트럼을 특징 벡터로 사용하고, 그림 9는 캡스트럼, 델타 캡스트럼, 그리고 델타 에너지와 델타 델타 에너지까지 모두 사용한 결과이다.

결과에서 볼 수 있듯이 문법적 제약이 많을수록 성능이 보다 향상되는 것을 알 수 있다. 특히 금액이 반복적인 규칙을 사용하는 경우 이도 것도 사용하지 않는

경우보다 성능이 많이 향상된다. 자릿수에 의하여 상하 관계가 생기는 규칙까지 사용한 경우는 성능이 더욱 향상되어 아무 문법도 사용하지 않은 경우와 비교 30%의 성능 개선을 관찰할 수 있다.




그림 7. FSN 에 따른 성능 비교(cep)




그림 8. FSN 에 따른 성능 비교(cep+d_cep)




그림 9. FSN 에 따른 성능 비교(cep+d_cep+eng)

또한 특징 벡터를 많이 사용하면 성능이 좋아지는 것을 관찰할 수 있다. 특징 벡터를 많이 사용하면 성능이 좋아지는 것은 문법이 약한 경우 두드러지게 나타난다. FSN2 의 경우는 특징 벡터를 많이 사용하여 인식이 향상되는 것이 FSN0 나 FSN1 과 비교하여 작다.

본 실험에서 또 하나 관찰할 수 있는 것은 특징 벡터간의 성능 차이이다. 일반적으로 강가 특징을 그대로 인

영한 MFCC 가 가장 성능이 좋게 나타났다. 잡음 환경에서 성능이 좋다고 알려져 있는 R_MFCC 의 경우는 실험에서 보듯이 조용한 환경에서는 MFCC 보다 성능이 좋지 않은 결과가 나온다. LPCC 의 경우 실험에 사용된 세 가지 특징 벡터 중에서 가장 성능이 나쁘게 나왔지만 푸리에 변환을 거치지 않고 특징 벡터를 뽑는 방법으로 계산량이 적은 장점이 있다.

5. 결론

본 논문에서는 금액의 반복적인 규칙과 상하 관계의 규칙을 이용하여 인식 성능 향상을 연구하였다. 여러 가지 종류의 특징 벡터와 델타 캡스트럼과 델타 에너지, 델타 델타 에너지를 함께 사용한 경우를 대상으로 실험한 결과, 모든 경우에서 문법 제약은 인식 성능을 향상시키는 결과를 얻었다. 그 중에서도 FSN1 을 통하여 문법적인 규칙을 일부만 사용하여도 인식 성능 향상을 얻을 수 있었다. 최대 성능 향상은 LPCC 를 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, "A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition," *Proc. IEEE*, vol. 77, no. 2, Feb. 1989.
- [6] L. R. Rabiner and B. H. Juang, *Fundamentals of Speech Recognition*, Prentice Hall, 1993.
- [7] X. D. Huang, Y. Arikai and M. A. Jack, *Hidden Markov Models for Speech Recognition*, Edinburgh University Press, 1990.
- [8] E. C. Ifeachor and B. W. Jervis, *Digital Signal Processing*, Addison-Wesley Publishing Company Inc., 1993.